การประชุมวิชาการระดับชาติด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 2

4 เมษายน 2568

(รูปแบบออนไลน์)

Proceedings of the
2nd National Conference on
Statistics, Data Science, and Insurance
(NCSDI 2025)

April 4, 2025

Organized by the Department of Applied Statistics,
Faculty of Applied Science,
King's Mongkut University of Technology North Bangkok
(Online Conference)

คำนำ

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ได้จัดการประชุมวิชาการระดับชาติ ด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 2 ประจำปี พ.ศ.2568 (The 2nd National Conference on Statistics, Data Science and Insurance: NCSDI 2025) ในวันที่ 4 เมษายน 2568 ณ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ โดยจัดขึ้นในรูปแบบออนไลน์ มีลักษณะการประชุมเป็นการนำเสนอผลงานทางวิชาการของผู้เข้าร่วมประชุมในรูปแบบบรรยาย (Oral presentation) รูปแบบโปสเตอร์ (Poster presentation) และการบรรยายพิเศษจากวิทยากรผู้เชี่ยวชาญเฉพาะด้าน โดยมีจุดมุ่งหมายเพื่อสร้างเครือข่ายความร่วมมือทางวิชาการด้านสถิติ ด้านวิทยาศาสตร์ข้อมูล และด้านการประกันภัย ให้มีความเข้มแข็งทางวิชาการ และส่งเสริม พัฒนางานวิจัยทางด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ให้มีมาตรฐานและคุณภาพในระดับประเทศ อีกทั้งเป็นเวทีสำหรับการนำเสนอผลงานทางวิชาการและแลกเปลี่ยนประสบการณ์ของนักศึกษาทั้งในระดับปริญญาตรีและระดับบัณฑิตศึกษา

ในการประชุมวิชาการครั้งนี้มีนักศึกษา/นิสิตส่งผลงานเข้าร่วมทั้งหมด 64 เรื่อง โดยแบ่งเป็นการนำเสนอแบบบรรยายจำนวน 30 เรื่อง และการนำเสนอแบบโปสเตอร์จำนวน 34 เรื่อง ในนามของคณะกรรมการดำเนินงาน ขอขอบคุณผู้ทรงคุณวุฒิทุกท่านที่สละเวลาอันมีค่าในการพิจารณาและวิพากษ์ผลงาน ตลอดจนขอขอบคุณวิทยากร คณาจารย์ นักศึกษา/นิสิต และผู้เข้าร่วมประชุมวิชาการทุกท่านที่ให้การสนับสนุนและมีส่วนร่วมในกิจกรรมครั้งนี้เป็นอย่างดี นอกจากนี้ ขอขอบคุณคณะกรรมการจัดประชุมวิชาการทุกท่านที่ให้ความร่วมมืออย่างดียิ่ง จนทำให้การประชุมวิชาการระดับชาติด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 2 ประจำปี พ.ศ.2568 สำเร็จลุล่วงด้วยความเรียบร้อย

ศาสตราจารย์ ดร.ยุพาภรณ์ อารีพงษ์
ประธานคณะกรรมการดำเนินงาน

สารบัญ

หน้า

คำนำ

รายชื่อผู้ทรงคุณวุฒิ จ

กำหนดการประชุม ช

รายชื่อผลงานวิจัยที่นำเสนอแบบบรรยาย

การใช้การเรียนรู้ของเครื่องเพื่อคัดกรองลูกค้าต่ออายุประกันรถยนต์ 1

การทำนายโอกาสในการเข้ามาตรการช่วยเหลือลูกหนี้ค้างชำระของธนาคารออมสิน ในเขตกำแพงเพชรด้วยเหมืองข้อมูล 7

โมเดลการตรวจจับความถูกต้องของการออกกำลังกายด้วยท่า Dumbbell Biceps Curl โดยใช้เทคนิคการเรียนรู้ของเครื่อง 14

ระบบรู้จำใบหน้าเพื่อยืนยันตัวของนักศึกษาในการเข้าเรียนของสาขาวิชานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ 22

การเปรียบเทียบประสิทธิภาพของแบบจำลองแบบผสมการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้น 29

การพัฒนาโมเดลการเรียนรู้ของเครื่องสำหรับการวิเคราะห์และทำนายความเสี่ยงจากการโจมตีแบบสุ่มเดารหัสผ่านบนคลาวด์เซิร์ฟเวอร์ 37

การวิเคราะห์ความรู้สึกจากหัวข้อข่าวเพื่อสนับสนุนการตัดสินใจลงทุนด้วยตัวแบบ FinBert 48

ผลกระทบของฟังก์ชันกระตุ้นต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ 54

ประสิทธิภาพการพยากรณ์ของการวิเคราะห์เชิงฟังก์ชันและการเรียนรู้เชิงลึก 61

การพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง 69

การวิเคราะห์การจำแนกประเภทในการเกิดโรคเบาหวาน โดยอาศัยข้อมูลจากการวิเคราะห์ปัจจัย 76

การพัฒนาแอปพลิเคชันแปลภาษาด้วยปัญญาประดิษฐ์โมเดลทรานส์ฟอร์มเมอร์ 83

ระบบปัญญาประดิษฐ์เพื่อทำนายพฤติกรรมคนขับรถ 91

การจำลองและทดสอบแผนเส้นทางครอบคลุมที่เหมาะสมในหุ่นยนต์ทำความสะอาด 97

การตรวจจับความเสียหายประเภทหลุมบ่อบนถนนลาดยางด้วยเทคนิคคอมพิวเตอร์วิทัศน์เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา 105

Probabilistic Analytics of Rainfall in Thailand for Lifespan of Hydraulic Structures 111

ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้นโดยวิธีสมการปริพันธ์เชิงตัวเลข 116

ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังสำหรับตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง โดยวิธีสมการปริพันธ์เชิงตัวเลข 124

การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DHWMA แบบขยายสำหรับการตรวจจับการเปลี่ยนแปลงของกระบวนการ 135

การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม QEWMA สำหรับข้อมูลที่มีการแจกแจงแบบต่อเนื่อง 143

ประสิทธิภาพของแผนภูมิค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยายใหม่ทั้งแบบอิงและไม่อิงพารามิเตอร์สำหรับการติดตามการเปลี่ยนแปลงค่าเฉลี่ย 157

สารบัญ (ต่อ)

	หน้า
การประมาณค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง สำหรับตัวแบบอนุกรมเวลาที่มีฤดูกาลจากวิธีสมการปริพันธ์เชิงตัวเลข	170
การศึกษาความแกร่งของแผนภูมิควบคุมจำนวนรอยตำหนิ	180
แผนภูมิควบคุม FIR-EWMA เพื่อตรวจสอบการเปลี่ยนแปลงสำหรับการแจกแจงเรย์ลีย์	185
การใช้ตัวแปรช่วยเพื่อปรับปรุงประสิทธิภาพของตัวประมาณแบบเลขชี้กำลังของค่าเฉลี่ยประชากร ภายใต้ปัญหาการไม่ตอบสนองในการสำรวจตัวอย่าง	193
การจัดกลุ่มสาขาธนาคารที่มีการขายบัตรเดบิตพ่วงประกันภัย	202
การเปรียบเทียบวิธีการปรับค่าพารามิเตอร์การลงโทษแบบเรียลไทม์ในข้อมูลสตรีมมิงที่ไม่คงที่	212
การประเมินน้ำหนักปัจจัยเสี่ยงที่มีต่อผลความปลอดภัยในงานก่อสร้าง ด้วยวิธีวิเคราะห์เชิงลำดับชั้นแบบปรับปรุง	219
โครงข่ายประสาทเทียมสำหรับการวิเคราะห์การถดถอยเชิงเส้นตามบริบท	226
การจัดลำดับความสำคัญของปัจจัยกำหนดการคัดเลือกผู้ออกแบบตกแต่งภายใน สำหรับบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่าน โดยใช้กระบวนการวิเคราะห์เชิงลำดับชั้น	235

รายชื่อผลงานวิจัยที่นำเสนอแบบโปสเตอร์

การตรวจจับความผิดปกติของข้อมูลการเคลม โดยใช้ Machine Learning และ Blockchain Technology	242
การวิเคราะห์พฤติกรรมลูกค้าในร้านสะดวกซื้อผ่านปัจจัยภายนอกในแต่ละภูมิภาค	243
การเปรียบเทียบตัวแบบการพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในภาคเศรษฐกิจหลักของประเทศไทยด้วยเทคนิคการเรียนรู้ของเครื่อง	244
การวิเคราะห์พฤติกรรมลูกค้าด้วยการเรียนรู้ของเครื่อง: การแบ่งกลุ่มลูกค้าด้วย K-means Clustering และการวิเคราะห์ RFM	245
การพยากรณ์ปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติในประเทศไทยด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง	246
การทำนายแนวโน้มของลูกค้าที่จะเลิกซื้อสินค้าธุรกิจพาณิชย์อิเล็กทรอนิกส์ โดยใช้เทคนิค Machine Learning	247
เทคนิคการการเรียนรู้เชิงลึกสำหรับการจำแนกค่าความหวานของส้มโอพันธุ์ทองดี โดยใช้การวิเคราะห์ภาพ	248
Prediction of Credit Card Defaults in Taiwan Based on Variable Selection Approach in Machine Learning Model	249
การพัฒนาเว็บแอปพลิเคชันสำหรับการพยากรณ์ความเสี่ยงโรคเบาหวานด้วยการเรียนรู้ของเครื่อง	250
การวิเคราะห์ปัจจัยที่ทำให้เกิดการทะเลาะวิวาท เพื่อป้องกันและแก้ไขปัญหาการใช้ความรุนแรงของนักศึกษาระดับอาชีวศึกษาในเขตมีนบุรี	251
การวิเคราะห์ปัจจัยเสี่ยงที่ส่งผลต่อการเกิดโรคซึมเศร้าของผู้ป่วยในโรงพยาบาลบุรีรัมย์ โดยใช้ตัวแบบการถดถอยลอจิสติก	252

สารบัญ (ต่อ)

	หน้า
การวิเคราะห์การถดถอยพหุคูณเพื่อพยากรณ์ปริมาณการใช้พลังงานขั้นสุดท้ายในภาคอุตสาหกรรมการผลิต	253
เทคโนโลยีสารสนเทศสำหรับผู้บริหารฝ่ายขายทางโทรศัพท์	254
การพยากรณ์ปริมาณงานและการจัดสรรจำนวนพนักงานอย่างเหมาะสมด้วยเทคนิค LSTM	255
การออกแบบแผนการทดลองแบบจัตุรัสละติน โดยใช้โปรแกรม R	256
การเปรียบเทียบประสิทธิภาพแผนภูมิควบคุม Double EWMAAIB แผนภูมิควบคุม Adaptive EWMAAIB และแผนภูมิควบคุม Hybrid EWMAAIB	257
การเปรียบเทียบประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ โดยอิงตามแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังและส่วนขยาย	258
การพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในกระบวนการผลิตไฟฟ้าจากก๊าซธรรมชาติ	259
การพยากรณ์ความต้องการพลังงานไฟฟ้าในประเทศไทย	260
การเปรียบเทียบวิธีการพยากรณ์มูลค่าการส่งออกสิ่งทอและเครื่องนุ่งห่ม	261
การพยากรณ์ปริมาณฝุ่น PM 2.5 ในจังหวัดเชียงใหม่โดยใช้วิธีบอกซ์-เจนกินส์	262
การพยากรณ์ราคาขายปลีกขิงในกรุงเทพมหานคร	263
การพยากรณ์ราคาทองคำแท่ง 96.5% ในประเทศไทย	264
การพยากรณ์ราคาน้ำมันแก๊สโซฮอล์ 95 ในประเทศไทยโดยใช้วิธีวิเคราะห์อนุกรมเวลา	265
การเปรียบเทียบตัวแบบการพยากรณ์ราคาปิดหุ้นปตท. ด้วยตัวแบบการปรับให้เรียบสองครั้งแบบเอ็กซ์โปเนนเชียล ตัวแบบ ARIMA และ ตัวแบบ ARIMAX	266
การพยากรณ์จำนวนผู้เสียชีวิตจากโรคมะเร็งในกรุงเทพมหานคร	267
การพยากรณ์ความถี่ในการเคลมของประกันวินาศภัยโรงแรมโดยใช้แบบจำลองข้อมูลนับทางสถิติ	268
การพัฒนาเครื่องมือสำหรับคำนวณเบี้ยประกันชีวิต	269
การวิเคราะห์การถดถอยพหุผลลัพธ์ในการทำนายความถี่และความรุนแรงของการเรียกร้องค่าสินไหมทดแทนในการประกันภัยรถยนต์	270
การออกจดหมายบอกกล่าวทวงถามแบบอัตโนมัติสำหรับสินเชื่อ SME ที่ค้ำประกันโดยบรรษัทประกันสินเชื่ออุตสาหกรรมขนาดย่อม (บสย.)	271
การวิเคราะห์ข้อมูลการประกันภัยอุปกรณ์อิเล็กทรอนิกส์ของโรงพยาบาลและคลินิกความงาม	272
การพัฒนา Extract-Transform-Loader สำหรับภาษีอิเล็กทรอนิกส์	273
การย้ายข้อมูลสำหรับฐานข้อมูลการประเมินมูลค่าทรัพย์สินและการบริหารจัดการหลักประกัน	274
การตรวจจับการฉ้อโกงประกันภัยรถยนต์โดยใช้การเรียนรู้ของเครื่อง	275

วิทยากร (Keynote Speaker) บรรยายในงานประชุมวิชาการ

	รองศาสตราจารย์ ดร.วราฤทธิ์ พานิชกิจโกศลกุล สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์
	คุณกานต์ เจริญจิตร กรรมการผู้จัดการ บริษัท เค-เทค แอนด์ สมาร์ท โซลูชั่น กรุ๊ป จำกัด และที่ปรึกษาด้านเทคโนโลยีและนวัตกรรม บริษัท ฮิปโป โปร อินโนเวชัน จำกัด

รายชื่อผู้ทรงคุณวุฒิ

1.	รองศาสตราจารย์ ดร.พัทธ์ชนก ศรีสุรเดชชัย	มหาวิทยาลัยธรรมศาสตร์
2.	รองศาสตราจารย์ ดร.ภทรวรรณ แสงนวกิจ	มหาวิทยาลัยธรรมศาสตร์
3.	รองศาสตราจารย์ ดร.ภาคภูมิ มุกดาสนิท	มหาวิทยาลัยราชภัฏจันทรเกษม
4.	รองศาสตราจารย์ ดร.ลวัณกร มุกดาสนิท	มหาวิทยาลัยราชภัฏจันทรเกษม
5.	รองศาสตราจารย์ ดร.ณัฏฐินี ดีแท้	มหาวิทยาลัยราชภัฏพิบูลสงคราม
6.	รองศาสตราจารย์ ดร.ระพิน สุนทรวัฒน์	สถาบันเทคโนโลยีปทุมวัน
7.	ผู้ช่วยศาสตราจารย์ ดร.ภวัต ภักดิ์ศรานุวัต	มหาวิทยาลัยเชียงใหม่
8.	ผู้ช่วยศาสตราจารย์ รุจิรา จุลภักดิ์	มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก
9.	ผู้ช่วยศาสตราจารย์ ดร.พิเชฐ คุณากรวงศ์	มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
10.	ผู้ช่วยศาสตราจารย์ ดร.มธุรส ผ่านเมือง	มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
11.	ผู้ช่วยศาสตราจารย์จตุรพิธ เกราะแก้ว	มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
12.	ผู้ช่วยศาสตราจารย์ปองพล นิลพฤกษ์	มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
13.	ผู้ช่วยศาสตราจารย์ ดร.ปิยธิดา พันธุนะ	มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
14.	ผู้ช่วยศาสตราจารย์ ดร.ศิริเรือง พัฒน์ช่วย	มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์
15.	ผู้ช่วยศาสตราจารย์ อาทิตย์ อยู่เย็น	มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์
16.	ผู้ช่วยศาสตราจารย์ ดร.พฤฒิพงศ์ เพ็งศิริ	มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา
17.	ผู้ช่วยศาสตราจารย์ ดร.ธิปไตย พงษ์ศาสตร์	มหาวิทยาลัยขอนแก่น
18.	ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย ศรีโสดาพล	มหาวิทยาลัยขอนแก่น
19.	ผู้ช่วยศาสตราจารย์ ดร.ปารวัณ ไพจิตรรัตนะ	มหาวิทยาลัยธรรมศาสตร์
20.	ผู้ช่วยศาสตราจารย์ ดร.กชพร การุณ	มหาวิทยาลัยนเรศวร
21.	ผู้ช่วยศาสตราจารย์ ดร.ธนพล พุกเส็ง	มหาวิทยาลัยบูรพา
22.	ผู้ช่วยศาสตราจารย์ ดร.ภัทราพร ทองนิ่ม	มหาวิทยาลัยบูรพา
23.	ผู้ช่วยศาสตราจารย์ ดร.สมบัติ ฝอยทอง	มหาวิทยาลัยบูรพา
24.	ผู้ช่วยศาสตราจารย์ ดร.อภิศักดิ์ ไชยโรจน์วัฒนา	มหาวิทยาลัยบูรพา
25.	ผู้ช่วยศาสตราจารย์ ดร.อุไรวรรณ บัวตูม	มหาวิทยาลัยบูรพา
26.	ผู้ช่วยศาสตราจารย์ ดร.มนชยา เจียงประดิษฐ์	มหาวิทยาลัยมหาสารคาม
27.	ผู้ช่วยศาสตราจารย์ ดร.หยาดพิรุณ ศุภรากรสกุล	มหาวิทยาลัยราชภัฏเพชรบูรณ์
28.	ผู้ช่วยศาสตราจารย์ ดร.วรรณพร สุริยะกาศ	มหาวิทยาลัยราชภัฏพิบูลสงคราม
29.	ผู้ช่วยศาสตราจารย์ ดร.ศรัญญา ทองสุข	มหาวิทยาลัยราชภัฏพิบูลสงคราม
30.	ผู้ช่วยศาสตราจารย์ ดร.นฤมล ชูเมือง	มหาวิทยาลัยราชภัฏหมู่บ้านจอมบึง
31.	ผู้ช่วยศาสตราจารย์ ดร.รัตติกาล ทาโบราณ	มหาวิทยาลัยราชภัฏหมู่บ้านจอมบึง
32.	ผู้ช่วยศาสตราจารย์ ดร.ดิเรก บัวหลวง	มหาวิทยาลัยราชภัฏอุตรดิตถ์
33.	ผู้ช่วยศาสตราจารย์ ดร.วนิดา ลิ่มมั่น	มหาวิทยาลัยวลัยลักษณ์
34.	อาจารย์ ดร.ปิยพล ไพจิตร	มหาวิทยาลัยศิลปากร
35.	อาจารย์ ดร.วรวุทธิ์ ยิ้มแย้ม	มหาวิทยาลัยราชภัฏเพชรบุรี

36. อาจารย์ ดร.ว่าที่ร้อยเอกเฉลิมรัช นนทะภา	มหาวิทยาลัยเชียงใหม่
37. อาจารย์ ดร.สุรเดช อินทกรณ์	มหาวิทยาลัยมหิดล
38. อาจารย์ ดร.เพียงฤทัย หนูสวัสดิ์	มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์
39. อาจารย์สมพร พึ่งสม	มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์

กำหนดการ

โครงการประชุมวิชาการระดับชาติ ด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 2

The 2nd National Conference on Statistics, Data Science and Insurance (NCSDI 2025)

วันที่ 4 เมษายน พ.ศ. 2568

(รูปแบบออนไลน์)

เวลา	กิจกรรม
08.45 – 09.00 น.	**พิธีเปิดการประชุมวิชาการ NCSDI 2025** โดย: 1) ศาสตราจารย์ ดร.ยุพาภรณ์ อารีพงษ์ หัวหน้าภาควิชาสถิติประยุกต์ 2) รองศาสตราจารย์ ดร.เพียรพูล กมลจิตร์ประภา คณบดีคณะวิทยาศาสตร์ประยุกต์ Join Zoom Meeting: https://zoom.us/j/94035729380 Meeting ID: 940 3572 9380 Passcode: NCSDI2025
09.00 – 9.30 น.	**การบรรยายพิเศษ เรื่อง** “Analysis of Chemical and Rainfall Data Using Confidence Intervals for the Parameter of the Double XShanker Distribution” โดย รองศาสตราจารย์ ดร.วราฤทธิ์ พานิชกิจโกศลกุล อาจารย์ประจำสาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์ Join Zoom Meeting: https://zoom.us/j/94035729380 Meeting ID: 940 3572 9380 Passcode: NCSDI2025
09.30 – 10.00 น.	**การบรรยายพิเศษ เรื่อง** “ทรัพย์ข้อมูล: ขุมทองล้ำค่าแห่งศตวรรษใหม่” (The Wealth of Data: A 21st Century Gold Rush) โดย คุณกานต์ เจริญจิตร กรรมการบริษัทฝ่ายวิจัยและเทคโนโลยี CTO บริษัท เค-เทค แอนด์ สมาร์ท โซลูชั่น กรุ๊ป จำกัด และที่ปรึกษาด้านเทคโนโลยีและนวัตกรรม บริษัท ฮิปโป โปร อินโนเวชัน จำกัด Join Zoom Meeting: https://zoom.us/j/94035729380 Meeting ID: 940 3572 9380 Passcode: NCSDI2025
10.00 – 12.00 น.	**การนำเสนอผลงานวิจัยแบบบรรยาย (Oral presentation)** **Oral Presentation 1** Join Zoom Meeting: https://zoom.us/j/98514456025 Meeting ID: 985 1445 6025 Passcode: 426426 **Oral Presentation 2** Join Zoom Meeting: https://zoom.us/j/91235328666 Meeting ID: 912 3532 8666 Passcode: 426426 **Oral Presentation 3** Join Zoom Meeting: https://zoom.us/j/92189092337 Meeting ID: 921 8909 2337 Passcode: 426426

เวลา	กิจกรรม
	Oral Presentation 4 Join Zoom Meeting: https://zoom.us/j/91948942883 Meeting ID: 919 4894 2883 Passcode: 426426
12.00 – 13.00 น.	พักรับประทานอาหารกลางวัน
13.00 – 15.30 น.	การนำเสนอผลงานวิจัยแบบโปสเตอร์ (Poster presentation) **Poster Presentation 1** Join Zoom Meeting: https://zoom.us/j/92946052317 Meeting ID: 929 4605 2317 Passcode: 426426 **Poster Presentation 2** Join Zoom Meeting: https://zoom.us/j/96737463280 Meeting ID: 967 3746 3280 Passcode: 426426 **Poster Presentation 3** Join Zoom Meeting: https://zoom.us/j/95136811317 Meeting ID: 951 3681 1317 Passcode: 426426 **Poster Presentation 4** Join Zoom Meeting: https://zoom.us/j/96722951164 Meeting ID: 967 2295 1164 Passcode: 426426

ห้อง: Oral Presentation 1

เวลา: 10.00 – 12.00 น.

Chairman: รองศาสตราจารย์ ดร.พัทธ์ชนก ศรีสุรเดชชัย

Join Zoom Meeting: https://zoom.us/j/98514456025

Meeting ID: 985 1445 6025

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
10.00-10.15 น.	ณรงค์วัฒน์ สาครอร่ามเรือง	การใช้การเรียนรู้ของเครื่องเพื่อคัดกรองลูกค้าต่ออายุประกันรถยนต์
10.15-10.30 น.	พีรวัชร อำไพวัชรากุล	การทำนายโอกาสในการเข้ามาตรการช่วยเหลือลูกหนี้ค้างชำระของธนาคารออมสินในเขตกำแพงเพชรด้วยเหมืองข้อมูล
10.30-10.45 น.	ชนธา ขันสิงห์หา	โมเดลการตรวจจับความถูกต้องของการออกกำลังกายด้วยท่า Dumbbell Biceps Curl โดยใช้เทคนิคการเรียนรู้ของเครื่อง
10.45-11.00 น.	ก้องกิดากร สุวรรณผ่อง	ระบบรู้จำใบหน้าเพื่อยืนยันตัวของนักศึกษาในการเข้าเรียนของสาขาวิชานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ
11.00-11.15 น.	กิตติคุณ ทัดประดิษฐ	การเปรียบเทียบประสิทธิภาพของแบบจำลองแบบผสมการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้น
11.15-11.30 น.	ภูวเดช ประทุม	การพัฒนาโมเดลการเรียนรู้ของเครื่องสำหรับการวิเคราะห์และทำนายความเสี่ยงจากการโจมตีแบบสุ่มเดารหัสผ่านบนคลาวด์เซิร์ฟเวอร์
11.30-11.45 น.	สิรินดา ปาลกวงศ์ ณ อยุธยา	การวิเคราะห์ความรู้สึกจากหัวข้อข่าวเพื่อสนับสนุนการตัดสินใจลงทุนด้วยตัวแบบ FinBert
11.45-12.00 น.	จินจุ เจริญยิ่งไพศาล	ผลกระทบของฟังก์ชันกระตุ้นต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์
12.00 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 1	

ห้อง: Oral Presentation 2

เวลา: 10.00 – 11.45 น.

Chairman: รองศาตราจารย์ ดร. ภาคภูมิ มุกดาสนิท

Join Zoom Meeting: https://zoom.us/j/91235328666

Meeting ID: 912 3532 8666

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
10.00-10.15 น.	บุณฑริกา พรหมสถิตย์	ประสิทธิภาพการพยากรณ์ของการวิเคราะห์เชิงฟังก์ชันและการเรียนรู้เชิงลึก
10.15-10.30 น.	พีรวิชญ์ นาวินรัตนศิริ	การพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง
10.30-10.45 น.	ณัฐธิดา จาง	การวิเคราะห์การจำแนกประเภทในการเกิดโรคเบาหวาน โดยอาศัยข้อมูลจากการวิเคราะห์ปัจจัย
10.45-11.00 น.	นวรุตม์ นนทกิจโยธิน	การพัฒนาแอปพลิเคชันแปลภาษาด้วยปัญญาประดิษฐ์โมเดลทรานส์ฟอร์มเมอร์
11.00-11.15 น.	สุภัสสรา ชัยอาภา	ระบบปัญญาประดิษฐ์เพื่อทำนายพฤติกรรมคนขับรถ
11.15-11.30 น.	กิตติคุณ สุอรุณ	การจำลองและทดสอบแผนเส้นทางครอบคลุมที่เหมาะสมในหุ่นยนต์ทำความสะอาด
11.30-11.45 น.	ยศพนธ์ โนนจุ้ย	การตรวจจับความเสียหายประเภทหลุมบ่อบนถนนลาดยางด้วยเทคนิคคอมพิวเตอร์วิทัศน์เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา
11.45 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 2	

ห้อง: Oral Presentation 3

เวลา: 10.00 – 12.15 น.

Chairman: รองศาสตราจารย์ ดร.ปิยภัทร์ บุษบาบดินทร์

Join Zoom Meeting: https://zoom.us/j/92189092337

Meeting ID: 921 8909 2337

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
10.00-10.15 น.	Kissada Im-oum	Probabilistic Analytics of Rainfall in Thailand for Lifespan of Hydraulic Structures
10.15-10.30 น.	สุภาณี วุฒิระวัฒน์	ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้นโดยวิธีสมการปริพันธ์เชิงตัวเลข
10.30-10.45 น.	นริศรา กองดวง	ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง สำหรับตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสองโดยวิธีสมการปริพันธ์เชิงตัวเลข
10.45-11.00 น.	วันไชย เลิศเมธาวี	การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DHWMA แบบขยายสำหรับการตรวจจับการเปลี่ยนแปลงของกระบวนการ
11.00-11.15 น.	จันทราภรณ์ ธรรมวัตร	การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม QEWMA สำหรับข้อมูลที่มีการแจกแจงแบบต่อเนื่อง
11.15-11.30 น.	อัญมณี แก้วเพ็งกรอ	ประสิทธิภาพของแผนภูมิค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยายใหม่ทั้งแบบอิงและไม่อิงพารามิเตอร์สำหรับการติดตามการเปลี่ยนแปลงค่าเฉลี่ย
11.30-11.45 น.	รัตนชาติ กุณฑล	การประมาณค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังสำหรับตัวแบบอนุกรมเวลาที่มีฤดูกาลจากวิธีสมการปริพันธ์เชิงตัวเลข
11.45-12.00 น.	ชนัญชิดา ศรีสุวรรณ์	การศึกษาความแกร่งของแผนภูมิควบคุมจำนวนรอยตำหนิ
12.00-12.15 น.	จิรัชญา ชื่นชม	แผนภูมิควบคุม FIR-EWMA เพื่อตรวจสอบการเปลี่ยนแปลงสำหรับการแจกแจงเรย์ลีย์
12.15 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 3	

ห้อง: Oral Presentation 4

เวลา: 10.00 – 11.30 น.

Chairman: รองศาสตราจารย์ ดร.ระพิน สุนทรวัฒน์

Join Zoom Meeting: https://zoom.us/j/91948942883

Meeting ID: 919 4894 2883

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
10.00-10.15 น.	ลภัส ชัยพรเรืองเดช	การใช้ตัวแปรช่วยเพื่อปรับปรุงประสิทธิภาพของตัวประมาณแบบเลขชี้กำลังของค่าเฉลี่ยประชากร ภายใต้ปัญหาการไม่ตอบสนองในการสำรวจตัวอย่าง
10.15-10.30 น.	ฉันทิกา ธรรมรักษาวงศ์	การจัดกลุ่มสาขาธนาคารที่มีการขายบัตรเดบิตพ่วงประกันภัย
10.30-10.45 น.	กัญญาวีร์ ชมมิ่ง	การเปรียบเทียบวิธีการปรับค่าพารามิเตอร์การลงโทษแบบเรียลไทม์ในข้อมูลสตรีมมิงที่ไม่คงที่
10.45-11.00 น.	ณฐนน นิติกุลชินภาค	การประเมินน้ำหนักปัจจัยเสี่ยงที่มีต่อผลความปลอดภัยในงานก่อสร้าง ด้วยวิธีวิเคราะห์เชิงลำดับชั้นแบบปรับปรุง
11.00-11.15 น.	พศุตม์ รัตนศรีมงคล	โครงข่ายประสาทเทียมสำหรับการวิเคราะห์การถดถอยเชิงเส้นตามบริบท
11.15-11.30 น.	วราพร ขัดคำวงศ์	การจัดลำดับความสำคัญของปัจจัยกำหนดการคัดเลือกผู้ออกแบบตกแต่งภายใน สำหรับบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่าน โดยใช้กระบวนการวิเคราะห์เชิงลำดับชั้น
11.30 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 4	

ห้อง: Poster Presentation 1

เวลา: 13.00 – 15.15 น.

Chairman: อาจารย์ ดร.พิชญา วิรัชโชติเสถียร

Join Zoom Meeting: https://zoom.us/j/92946052317

Meeting ID: 929 4605 2317

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	ชนัญชิดา เสมสันต์	การตรวจจับความผิดปกติของข้อมูลการเคลม โดยใช้ Machine Learning และ Blockchain Technology
13.15-13.30 น.	วรวรรณ วรศักดิ์เสนีย์	การวิเคราะห์พฤติกรรมลูกค้าในร้านสะดวกซื้อผ่านปัจจัยภายนอกในแต่ละภูมิภาค
13.30-13.45 น.	ณัฏฐริกา ภาคย์โภคิน	การเปรียบเทียบตัวแบบการพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในภาคเศรษฐกิจหลักของประเทศไทยด้วยเทคนิคการเรียนรู้ของเครื่อง
13.45-14.00 น.	พิชญ์ฌา ซอประเสริฐ	การวิเคราะห์พฤติกรรมลูกค้าด้วยการเรียนรู้ของเครื่อง: การแบ่งกลุ่มลูกค้าด้วย K-means Clustering และ การวิเคราะห์ RFM
14.00-14.15 น.	ญาดา เหล่าดีเจริญ	การพยากรณ์ปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติในประเทศไทยด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง
14.15-14.30 น.	ศุภณาลัย ชัยชนะ	การทำนายแนวโน้มของลูกค้าที่จะเลิกซื้อสินค้าธุรกิจพาณิชย์อิเล็กทรอนิกส์โดยใช้เทคนิค Machine Learning
14.30-14.45 น.	ธัญชนก ปิญญามูล	เทคนิคการการเรียนรู้เชิงลึกสำหรับการจำแนกค่าความหวานของส้มโอพันธุ์ทองดีโดยใช้การวิเคราะห์ภาพ
14.45-15.00 น.	ศิริประภา เตวี	Prediction of Credit Card Defaults in Taiwan Based on Variable Selection Approach in Machine Learning Model
15.00-15.15 น.	วรรณรดา มวลวงศ์	การพัฒนาเว็บแอปพลิเคชันสำหรับการพยากรณ์ความเสี่ยงโรคเบาหวานด้วยการเรียนรู้ของเครื่อง
15.15 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Poster Presentation 1 และปิดการประชุม	

ห้อง: Poster Presentation 2

เวลา: 13.00 – 15.00 น.

Chairman: รองศาสตราจารย์ ดร.ณัฏฐินี ดีแท้

Join Zoom Meeting: https://zoom.us/j/96737463280

Meeting ID: 967 3746 3280

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	ศวิษฐ์ การเร็ว	การวิเคราะห์ปัจจัยที่ทำให้เกิดการทะเลาะวิวาท เพื่อป้องกันและแก้ไขปัญหาการใช้ความรุนแรงของนักศึกษาระดับอาชีวศึกษาในเขตมีนบุรี
13.15-13.30 น.	วณิชยา ทาหอม	การวิเคราะห์ปัจจัยเสี่ยงที่ส่งผลต่อการเกิดโรคซึมเศร้าของผู้ป่วยในโรงพยาบาลบุรีรัมย์ โดยใช้ตัวแบบการถดถอยลอจิสติก
13.30-13.45 น.	สิรารมย์ ฉายเกียรติคุณ	การวิเคราะห์การถดถอยพหุคูณเพื่อพยากรณ์ปริมาณการใช้พลังงานขั้นสุดท้ายในภาคอุตสาหกรรมการผลิต
13.45-14.00 น.	ณัฐพงศ์ คงนารา	เทคโนโลยีสารสนเทศสำหรับผู้บริหารฝ่ายขายทางโทรศัพท์
14.00-14.15 น.	ณัฐณิชา คมขำ	การพยากรณ์ปริมาณงานและการจัดสรรจำนวนพนักงานอย่างเหมาะสมด้วยเทคนิค LSTM
14.15-14.30 น.	ธิติรัตน์ เรืองศรี	การออกแบบแผนการทดลองแบบจัตุรัสละติน โดยใช้โปรแกรม R
14.30-14.45 น.	ณัชชา อาจวงษ์ษา	การเปรียบเทียบประสิทธิภาพแผนภูมิควบคุม Double EWMAAIB, แผนภูมิควบคุม Adaptive EWMAAIB และ แผนภูมิควบคุม Hybrid EWMAAIB
14.45-15.00 น.	ทิฐิพล พ่วงพุก	การเปรียบเทียบประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการโดยอิงตามแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังและส่วนขยาย
15.00 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Poster Presentation 2 และปิดการประชุม	

ห้อง: Poster Presentation 3

เวลา: 13.00 – 15.15 น.

Chairman: ผู้ช่วยศาสตราจารย์ ดร.ปิยธิดา พันธุนะ

Join Zoom Meeting: https://zoom.us/j/95136811317

Meeting ID: 951 3681 1317

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	กิตติพศ อติเรกวุฒิ	การพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในกระบวนการผลิตไฟฟ้าจากก๊าซธรรมชาติ
13.15-13.30 น.	สุธิชา เหลืองรุ่งรัส	การพยากรณ์ความต้องการพลังงานไฟฟ้าในประเทศไทย
13.30-13.45 น.	ปัทมาพร เนตรหิน	การเปรียบเทียบวิธีการพยากรณ์มูลค่าการส่งออกสิ่งทอและเครื่องนุ่งห่ม
13.45-14.00 น.	จณิสตา กุลเกี้ยง	การพยากรณ์ปริมาณฝุ่น PM 2.5 ในจังหวัดเชียงใหม่โดยใช้วิธีบอกซ์-เจนกินส์
14.00-14.15 น.	กรรณิการ์ บุตนนท์	การพยากรณ์ราคาขายปลีกขิงในกรุงเทพมหานคร
14.15-14.30 น.	ชานิษา แย้มเอี่ยม	การพยากรณ์ราคาทองคำแท่ง 96.5% ในประเทศไทย
14.30-14.45 น.	พรรนิดา แสนฤทธิ์	การพยากรณ์ราคาน้ำมันแก๊สโซฮอล์ 95 ในประเทศไทยโดยใช้วิธีวิเคราะห์อนุกรมเวลา
14.45-15.00 น.	ธนัชชา ธงไธสง	การเปรียบเทียบตัวแบบการพยากรณ์ราคาปิดหุ้นปตท. ด้วยตัวแบบการปรับให้เรียบสองครั้งแบบเอ็กซ์โปเนนเชียล ตัวแบบ ARIMA และ ตัวแบบ ARIMAX
15.00-15.15 น.	ชุติกาญจน์ ชนิจกุล	การพยากรณ์จำนวนผู้เสียชีวิตจากโรคมะเร็งในกรุงเทพมหานคร
15.15 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Poster Presentation 3 และปิดการประชุม	

ห้อง: Poster Presentation 4

เวลา: 13.00 – 15.00 น.

Chairman: ผู้ช่วยศาสตราจารย์ ดร. ทศพร แถลงธรรม

Join Zoom Meeting: https://zoom.us/j/96722951164

Meeting ID: 967 2295 1164

Passcode: 426426

เวลา	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	มยุรินทร์ กลีบพึ่ง	การพยากรณ์ความถี่ในการเคลมของประกันวินาศภัยโรงแรมโดยใช้แบบจำลองข้อมูลนับทางสถิติ
13.15-13.30 น.	ปัณฑารีย์ ถนิมกาญจน์	การพัฒนาเครื่องมือสำหรับคำนวณเบี้ยประกันชีวิต
13.30-13.45 น.	ชฎารัตน์ อิ่มสารพางค์	การวิเคราะห์การถดถอยพหุผลลัพธ์ในการทำนายความถี่และความรุนแรงของการเรียกร้องค่าสินไหมทดแทนในการประกันภัยรถยนต์
13.45-14.00 น.	มนัสวรรณ คล่องถนอมสัตย์	การออกจดหมายบอกกล่าวทวงถามแบบอัตโนมัติสำหรับสินเชื่อ SME ที่ค้ำประกันโดยบรรษัทประกันสินเชื่ออุตสาหกรรมขนาดย่อม (บสย.)
14.00-14.15 น.	ลัลน์ลลิต ทองเอียบ	การวิเคราะห์ข้อมูลการประกันภัยอุปกรณ์อิเล็กทรอนิกส์ของโรงพยาบาลและคลินิกความงาม
14.15-14.30 น.	วาสนา แซ่โก๊ย	การพัฒนา Extract-Transform-Loader สำหรับภาษีอิเล็กทรอนิกส์
14.30-14.45 น.	ภัทรพร พิมพาลัย	การย้ายข้อมูลสำหรับฐานข้อมูลการประเมินมูลค่าทรัพย์สินและการบริหารจัดการหลักประกัน
14.45-15.00 น.	สรุจ มีฤทธิ์	การตรวจจับการฉ้อโกงประกันภัยรถยนต์โดยใช้การเรียนรู้ของเครื่อง
15.00 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Poster Presentation 4 และปิดการประชุม	

การใช้การเรียนรู้ของเครื่องเพื่อคัดกรองลูกค้าต่ออายุประกันรถยนต์

Using Machine Learning for Screening Car Insurance Renewal Customers

ณรงค์วัฒน์ สาครอร่ามเรือง[1*] สุวรรณี อัศวกุลชัย[2]

[1] *บัณฑิตวิทยาลัย กลุ่มวิชาวิศวกรรมคอมพิวเตอร์และเทคโนโลยีการเงิน คณะบริหารธุรกิจ มหาวิทยาลัยหอการค้าไทย*

[2] *กลุ่มวิชาวิศวกรรมคอมพิวเตอร์และเทคโนโลยีการเงิน คณะบริหารธุรกิจ มหาวิทยาลัยหอการค้าไทย*

(* *narongwat.s@gmail.com*)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อ พัฒนาแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) สำหรับคัดกรองลูกค้าที่มีแนวโน้มต่ออายุประกันรถยนต์ผ่านช่องทางโทรศัพท์ โดยใช้ กระบวนการมาตรฐานสำหรับการทำเหมืองข้อมูล (CRISP-DM: Cross-Industry Standard Process for Data Mining) และเปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้ของเครื่อง ได้แก่ Logistic Regression, Decision Tree, Random Forest และ LightGBMผลการทดลองแสดงว่า LightGBM มีประสิทธิภาพสูงสุด โดยเพิ่มอัตราการขายสำเร็จขึ้น 40% และลดจำนวนลูกค้าที่ต้องติดต่อลง 38% ช่วยให้ทีมขายสามารถมุ่งเน้นไปที่ลูกค้าที่มีศักยภาพสูง เวลาประมวลผลของ LightGBM เร็วกว่าวิธีดั้งเดิมถึง 60% ทำให้กระบวนการคัดกรองลูกค้ามีประสิทธิภาพมากขึ้น เพื่อใช้งานจริง ระบบที่พัฒนาได้ถูก เชื่อมต่อกับระบบบริหารความสัมพันธ์ลูกค้า (CRM: Customer Relationship Management) ผ่าน API ที่พัฒนาด้วย Python ทำให้ทีมขายสามารถเข้าถึงข้อมูลลูกค้าแบบเรียลไทม์ นอกจากนี้ ยังมีการจัดทำ รายงานวิเคราะห์ผลการดำเนินงาน เพื่อสนับสนุนการตัดสินใจของผู้บริหารผลการศึกษายืนยันว่า การเรียนรู้ของเครื่อง สามารถเพิ่มประสิทธิภาพการขาย ลดต้นทุน และสนับสนุนกลยุทธ์ทางธุรกิจได้อย่างมีประสิทธิภาพ

คำสำคัญ: การเรียนรู้ของเครื่อง, การคัดกรองลูกค้า, การต่ออายุประกันรถยนต์, LightGBM, CRISP-DM, การขายทางโทรศัพท์, ระบบบริหารความสัมพันธ์ลูกค้า, การพยากรณ์ลูกค้า, การเพิ่มประสิทธิภาพการขาย

Abstract

This study aims to develop a Machine Learning (ML) model for screening potential car insurance renewal customers via telemarketing using the CRISP-DM (Cross-Industry Standard Process for Data Mining) framework. Four ML algorithms—Logistic Regression, Decision Tree, Random Forest, and LightGBM—were compared to determine the most effective model. The results indicate that LightGBM outperformed other models, increasing the sales success rate by 40% and reducing unnecessary customer contact by 38%. Additionally, LightGBM's processing time was 60% faster than traditional methods, improving the efficiency of customer screening. To implement the model in real-world operations, it was integrated with the Customer Relationship Management (CRM) system through a Python-based API, enabling real-time access to customer insights. Furthermore, performance analytics reports were generated to support managerial decision-making. This study demonstrates that Machine Learning significantly enhances sales efficiency, reduces costs, and supports strategic business planning.

Keywords: Machine Learning, Customer Screening, Car Insurance Renewal, LightGBM, CRISP-DM, Telemarketing Sales, CRM System, Customer Prediction, Sales Performance Optimization

1. บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบัน อุตสาหกรรมประกันภัยรถยนต์เผชิญกับความท้าทายที่เพิ่มขึ้นจากการแข่งขันที่สูง ความต้องการของลูกค้าที่เปลี่ยนแปลงอย่างรวดเร็ว และข้อจำกัดด้านทรัพยากรในการดำเนินงาน โดยเฉพาะในช่องทางการขายทางโทรศัพท์ (Telemarketing) ซึ่งทีมขายต้องติดต่อกับลูกค้าจำนวนมากเพื่อเสนอขายหรือกระตุ้นการต่ออายุประกัน อย่างไรก็ตาม วิธีการปัจจุบันที่ยังอาศัยการคัดกรองลูกค้าแบบ

ดั้งเดิมอาจไม่มีประสิทธิภาพเพียงพอ ส่งผลให้เกิดปัญหาต่างๆ เช่น

การใช้เวลามากในการติดต่อลูกค้าที่ไม่มีแนวโน้มต่ออายุ ส่งผลให้สูญเสียโอกาสจากลูกค้าที่มีความเป็นไปได้สูง

อัตราความสำเร็จในการขายต่ำ ทำให้ต้นทุนการดำเนินงานต่อหน่วยสูงขึ้น

การขาดระบบอัตโนมัติในการคัดกรองลูกค้า ทำให้ต้องพึ่งพาการตัดสินใจของบุคคล ซึ่งอาจมีความคลาดเคลื่อน

งานวิจัยที่ผ่านมาได้แสดงให้เห็นว่าการนำ การเรียนรู้ของเครื่องและ การทำเหมืองข้อมูล มาใช้สามารถช่วยเพิ่มความแม่นยำในการพยากรณ์พฤติกรรมของลูกค้าและปรับปรุงประสิทธิภาพในการขายได้ (Fayyad et al., 1996; Ahmed Shawky Elbhrawy et al., 2023) โดยอัลกอริธึมที่นิยมใช้ เช่น Logistic Regression, Random Forest และ LightGBM สามารถช่วยระบุปัจจัยสำคัญที่มีผลต่อการต่ออายุประกันรถยนต์ (Fatma Manlaikhaf, 2023)

ดังนั้นการศึกษานี้จึงมีเป้าหมายในการ พัฒนาแบบจำลองการคัดกรองลูกค้าโดยใช้ การเรียนรู้ของเครื่องเพื่อช่วยให้ทีมขายสามารถจัดลำดับความสำคัญของกลุ่มเป้าหมายได้อย่างมีประสิทธิภาพ ลดต้นทุนการดำเนินงาน และเพิ่มอัตราการต่ออายุประกัน โดยการใช้ กรอบการทำเหมืองข้อมูล CRISP-DM และการประเมินประสิทธิภาพของโมเดลผ่านตัวชี้วัดเช่น Accuracy, Precision และ F1 Score เพื่อให้มั่นใจว่าโมเดลที่พัฒนาสามารถใช้งานได้จริงในธุรกิจประกันภัย

1.2 วัตถุประสงค์ของการศึกษา

1.2.1 เพื่อเปรียบเทียบแบบจำลองการพยากรณ์: ที่ช่วยคัดกรองลูกค้ากลุ่มเป้าหมายที่มีแนวโน้มต่ออายุประกันรถยนต์

1.2.2 เพื่อประเมินประสิทธิภาพของแบบจำลอง: การเรียนรู้ของเครื่อง ในการเพิ่มความแม่นยำของการคัดกรองลูกค้าและลดภาระงานของทีมขาย

1.2.3 เพื่อเชื่อมต่อแบบจำลองเข้ากับระบบ: ระบบบริหารความสัมพันธ์ลูกค้าเพื่อสนับสนุนการทำงานของทีมขาย

1.3 ขอบเขตการศึกษา

การศึกษานี้มุ่งเน้นไปที่การคัดกรองลูกค้ากลุ่มเป้าหมายสำหรับการขายประกันรถยนต์ผ่านช่องทางโทรศัพท์ โดยใช้ข้อมูลจากฐานข้อมูลของบริษัท เงินติดล้อ จำกัด (มหาชน) ซึ่งประกอบด้วยข้อมูลลูกค้าที่เคยซื้อประกันแต่ขาดการต่ออายุ และลูกค้าสินเชื่อที่ยังไม่มีประกันรถยนต์ การศึกษานี้มีขอบเขตดังต่อไปนี้

1.3.1. ขอบเขตด้านประชากร: ลูกค้าที่มีข้อมูลในระบบระหว่างเดือนมิถุนายน 2566 ถึงพฤศจิกายน 2566 ประมาณ 200,000 ราย

1.3.2. ขอบเขตด้านกระบวนการ: การนำการเรียนรู้ของเครื่อง มาประยุกต์ใช้ในการคัดกรองลูกค้าโดยใช้เทคนิค Logistic Regression, Random Forest และ LightGBM

1.3.3. ขอบเขตด้านเครื่องมือ: ใช้แพลตฟอร์ม Julius.ai สำหรับการพัฒนาและวิเคราะห์แบบจำลอง

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1. เปรียบเทียบโมเดลคัดกรองลูกค้าเป้าหมาย: ปรับปรุงความแม่นยำในการคัดกรองลูกค้าที่มีแนวโน้มต่ออายุประกันสูง

1.4.2. เพิ่มประสิทธิภาพการขาย: ลดเวลาที่ใช้ในการคัดกรองและโทรติดต่อลูกค้าโดยไม่จำเป็น

1.4.3. สนับสนุนการใช้การเรียนรู้ของเครื่องในธุรกิจประกันภัย: รายงานผลการวิเคราะห์ช่วยให้สามารถวางแผนกลยุทธ์ได้อย่างแม่นยำ

2. วิธีการวิจัย

การศึกษานี้ใช้กรอบการทำเหมืองข้อมูล CRISP-DM ซึ่งประกอบด้วย *6* ขั้นตอน ได้แก่ การทำความเข้าใจธุรกิจ (Business Understanding) การทำความเข้าใจข้อมูล (Data Understanding) การเตรียมข้อมูล (Data Preparation) การสร้างแบบจำลอง (Modeling) การประเมินผล (Evaluation) และการนำไปใช้งานจริง (Deployment) แสดงดังรูปที่ 1 นอกจากนี้ยังนำเทคนิค การเรียนรู้ของเครื่อง มาประยุกต์ใช้ เช่น Logistic Regression ที่เหมาะสำหรับการจำแนกประเภทข้อมูลที่มีผลลัพธ์เป็นสองค่า Random Forest สำหรับการจัดการกับข้อมูลที่ซับซ้อน และ LightGBM ที่เน้นประสิทธิภาพและความเร็วในการประมวลผล

รูปที่ 1: ขั้นตอนของ CRISP-DM

2.1 การเก็บรวบรวมข้อมูล

ข้อมูลลูกค้าถูกดึงจากฐานข้อมูลของบริษัท เงินติดล้อ จำกัด (มหาชน) โดยมุ่งเน้นกลุ่มลูกค้าที่เคยซื้อประกันแต่ขาดการต่ออายุ และลูกค้าสินเชื่อที่ยังไม่มีประกันรถยนต์ ระยะเวลาที่เก็บข้อมูลคือ ระหว่างเดือนมิถุนายน 2566 ถึงพฤศจิกายน 2566 รวมจำนวน 200,000 รายการ ข้อมูลที่นำมาใช้ประกอบด้วย คุณลักษณะสำคัญ (Feature Variables) ได้แก่

ข้อมูลพื้นฐานของลูกค้า เช่น อายุรถยนต์, อายุผู้ขับขี่, ประวัติการซื้อประกัน

ข้อมูลเกี่ยวกับพฤติกรรมการใช้บริการ เช่น จำนวนผลิตภัณฑ์ที่เคยซื้อจากบริษัท, มูลค่าเบี้ยประกัน, การเปลี่ยนแปลงของเบี้ยประกันในอดีต

2.2 การเตรียมข้อมูล

ข้อมูลที่ได้จากการเก็บรวบรวมถูกนำมาผ่านกระบวนการทำความเข้าใจและปรับปรุงคุณภาพข้อมูล ตามหลักการ CRISP-DM ได้แก่

การตรวจสอบคุณภาพข้อมูล: วิเคราะห์ Missing Values, Outliers และความซ้ำซ้อนของข้อมูล

การจัดการข้อมูลที่ขาดหาย: ใช้ Mean Imputation หรือ K-Nearest Neighbors (KNN) Imputation

การจัดกลุ่มข้อมูล (Feature Engineering): ปรับเปลี่ยนค่าตัวแปร เช่น การจัดช่วงอายุรถยนต์เป็นกลุ่ม

การทำให้ข้อมูลสมดุล (Data Balancing): เนื่องจากข้อมูลมีปัญหา Class Imbalance จึงใช้ SMOTE (Synthetic Minority Over-sampling Technique)

2.3 การสร้างแบบจำลอง

ใช้แพลตฟอร์ม Julius.ai แสดงดังรูปที่ 2 ในการสร้างแบบจำลอง การเรียนรู้ของเครื่อง โดยเริ่มจากการแบ่งข้อมูลเป็นชุดฝึก (Training Set) และชุดทดสอบ (Test Set) จากนั้นนำเทคนิค Logistic Regression, Decision Tree, Random Forest, และ LightGBM มาทดลองเพื่อหาประสิทธิภาพสูงสุด โดยใช้ตัวชี้วัดเช่น Accuracy, Precision, Recall, และ F1 Score

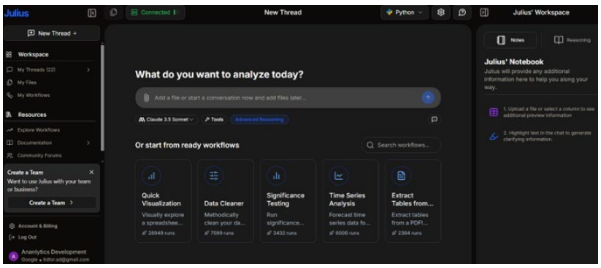

รูปที่ 2: เวปไซต์ https://julius.ai/chat

การศึกษานี้แบ่งข้อมูลเป็น ชุดฝึก (80%) และชุดทดสอบ (20%) ตามหลัก Holdout Method เพื่อให้โมเดลเรียนรู้จากข้อมูลส่วนใหญ่และทดสอบบนข้อมูลที่ไม่เคยเห็นมาก่อน

ใช้ Stratified Sampling เพื่อรักษาสัดส่วนของกลุ่มเป้าหมาย เนื่องจากข้อมูลมี Class Imbalance ใช้ 5-Fold Cross-Validation ในชุดฝึกเพื่อเพิ่มความแม่นยำและลด Overfitting เหตุผล: อัตราส่วนนี้เป็นแนวทางมาตรฐานที่ใช้ในงานวิจัย เช่น Fayyad et al. (1996), Ke et al. (2017) และช่วยให้ได้ผลลัพธ์ที่มีความเสถียร การศึกษาเปรียบเทียบ 4 เทคนิคการเรียนรู้ของเครื่อง ได้แก่

- Logistic Regression – ใช้สมการความน่าจะเป็นแบบโลจิสติก
- Decision Tree – ใช้โครงสร้างต้นไม้ตัดสินใจโดยพิจารณาค่า Gini Index
- Random Forest – ใช้การรวมผลลัพธ์จากหลาย Decision Trees เพื่อลด Overfitting
- LightGBM – ใช้เทคนิค Gradient Boosting ในการปรับปรุงโมเดลให้แม่นยำขึ้น

ตัวแปรเป้าหมาย (Target Variable) ที่ใช้จำแนกกลุ่มลูกค้า คือ การตัดสินใจต่ออายุประกัน (CAN_BUY = 1 หรือ 0) แบบจำลองได้รับการประเมินโดยใช้ ตัวชี้วัด (Evaluation Metrics) ได้แก่

- Accuracy – วัดอัตราความถูกต้องของแบบจำลอง
- Precision และ Recall – ประเมินความแม่นยำของการจำแนกกลุ่มลูกค้าที่มีแนวโน้มต่ออายุ
- F1 Score – ใช้เป็นค่ากลางระหว่าง Precision และ Recall
- AUC-ROC – วัดประสิทธิภาพของแบบจำลองในการแยกกลุ่ม

2.4 การประเมินผล

ผลการทดสอบแบบจำลองพบว่า LightGBM มีความแม่นยำสูงสุด สามารถเพิ่มอัตราการต่ออายุประกันได้ถึง 35% เมื่อเทียบกับวิธีการเดิม ค่า 35% คำนวณจาก การเปรียบเทียบอัตราการขายสำเร็จ ก่อนและหลังใช้โมเดล LightGBM โดยคำนวณ อัตราความสำเร็จเดิม ของทีมขายจากข้อมูลย้อนหลัง

ทดสอบโมเดล LightGBM กับ ชุดทดสอบ (20%) แล้ววัดอัตราความสำเร็จใหม่

คำนวณ อัตราการเพิ่มขึ้น (%) โดยนำ อัตราความสำเร็จใหม่ ลบ อัตราความสำเร็จเดิม แล้วหารด้วย อัตราความสำเร็จเดิม คูณ 100

ผลลัพธ์ที่ได้คือ อัตราการเพิ่มขึ้น 35% ซึ่งได้รับการยืนยันจากตัวชี้วัด F1 Score และ AUC-ROC

การประเมินผลยังพิจารณาค่าความถูกต้อง (Precision) และค่าความสามารถในการทำนาย (Recall) เพื่อให้มั่นใจว่าโมเดลสามารถคัดกรองลูกค้าได้อย่างมีประสิทธิภาพ

2.5 การนำแบบจำลองไปใช้งานจริง

แบบจำลองที่ผ่านการทดสอบแล้วถูกนำไป แปลงเป็นภาษา Python เพื่อให้สามารถใช้งานร่วมกับ ระบบบริหารความสัมพันธ์ลูกค้า ของบริษัทได้ โดยกระบวนการเชื่อมต่อระบบดำเนินการดังนี้

เริ่มต้นจากการ บันทึกโมเดลที่ ในรูปแบบ pickle (.pkl) หรือ joblib เพื่อให้สามารถเรียกใช้งานได้ภายในระบบ จากนั้น API ถูกพัฒนาโดยใช้ Flask หรือ FastAPI เพื่อสร้างบริการที่สามารถรับข้อมูลลูกค้าแบบเรียลไทม์และให้โมเดลทำการคัดกรองลูกค้าที่มีแนวโน้มต่ออายุประกันสูง

ระบบบริหารความสัมพันธ์ลูกค้า ถูกตั้งค่าให้ ดึงข้อมูลลูกค้าผ่าน API นี้ และนำรายชื่อลูกค้าเป้าหมายที่ได้รับไปจัดลำดับความสำคัญในแดชบอร์ดของทีมขาย ทีมขายสามารถเข้าถึงรายชื่อลูกค้าที่ได้รับการคัดกรองแล้ว ผ่านอินเทอร์เฟซของ ระบบบริหารความสัมพันธ์ลูกค้า ทำให้สามารถวางแผนการติดต่อลูกค้าได้แม่นยำขึ้น ลดเวลาในการติดต่อลูกค้าที่ไม่มีแนวโน้มซื้อ

นอกจากนี้ รายงานผลการใช้งานของแบบจำลอง ยังถูกสร้างขึ้นผ่าน Dashboard บน Power BI หรือ Tableau เพื่อตรวจสอบอัตราความสำเร็จของแบบจำลองและผลกระทบต่ออัตราการปิดการขาย ข้อมูลเหล่านี้ถูกนำไปใช้ในการปรับปรุงแบบจำลองอย่างต่อเนื่องเพื่อให้การคัดกรองลูกค้ามีความแม่นยำและสอดคล้องกับพฤติกรรมของลูกค้าในแต่ละช่วงเวลา

3. ผลการวิจัยและอภิปรายผล

จากการศึกษาและวิเคราะห์ปัญหาทางธุรกิจของบริษัท เงินติดล้อ จำกัด (มหาชน) พบว่าทีมขายประกันภัยรถยนต์ผ่านช่องทางโทรศัพท์เผชิญกับ ความท้าทายสำคัญ ที่ส่งผลต่อประสิทธิภาพในการดำเนินงานและอัตราความสำเร็จในการขาย

หนึ่งในปัญหาหลักที่พบคือ การจัดการลูกค้าจำนวนมาก ทีมขายต้องรับมือกับฐานข้อมูลลูกค้าที่กว้างขวาง ซึ่งประกอบด้วยลูกค้าที่เคยทำประกันแต่ขาดการต่ออายุ และลูกค้าสินเชื่อที่ยังไม่มีประกันรถยนต์ โดยจำนวนลูกค้าที่ต้องติดต่อนั้นอยู่ที่ประมาณ 200,000 ราย ต่อรอบการดำเนินงาน ส่งผลให้เกิดข้อจำกัดด้านทรัพยากรบุคคลและเวลา การเลือกกลุ่มลูกค้าเป้าหมายที่เหมาะสมจึงเป็นเรื่องสำคัญอย่างยิ่ง หากทีมขายสามารถมุ่งเน้นไปที่ลูกค้าที่มีแนวโน้มต่ออายุประกันสูงได้ จะช่วยลดภาระงานและเพิ่มโอกาสปิดการขายได้อย่างมีประสิทธิภาพ

นอกจากนี้ วิธีการคัดกรองลูกค้าในปัจจุบันยังคงอาศัยการคัดกรองแบบอัตวิสัย หรือพิจารณาจากข้อมูลพื้นฐาน เช่น ระยะเวลาการเป็นลูกค้า หรือจำนวนกรมธรรม์ที่เคยทำกับบริษัท ซึ่งไม่มีความแม่นยำมากพอในการพยากรณ์โอกาสในการต่ออายุประกัน ส่งผลให้ทีมขายต้องใช้เวลาจำนวนมากในการติดต่อลูกค้าที่ไม่มีแนวโน้มสนใจต่ออายุ ทำให้สูญเสียโอกาสจากลูกค้าที่มีแนวโน้มสูงแทน

อีกปัญหาสำคัญคือ อัตราความสำเร็จในการขายต่ำ จากข้อมูลพบว่าการใช้แรงงานทีมขายในการติดต่อลูกค้าแบบสุ่ม ทำให้เกิดต้นทุนต่อหน่วยที่สูงขึ้น โดยเฉพาะเมื่อต้องติดต่อกลุ่มลูกค้าที่ไม่มีความสนใจในการต่ออายุ ทำให้อัตราการปิดการขายต่ำ และการใช้ทรัพยากรขององค์กรไม่มีประสิทธิภาพ

เมื่อพิจารณาผลกระทบจากปัญหาดังกล่าว บริษัทจึงมีความจำเป็นต้องปรับปรุงกระบวนการทำงานโดยใช้เทคโนโลยีการเรียนรู้ของเครื่อง เพื่อช่วยคัดกรองลูกค้าที่มีแนวโน้มต่ออายุประกันมากที่สุด เป้าหมายหลักของการนำมาใช้คือการช่วยให้ทีมขายสามารถจัดลำดับความสำคัญของลูกค้าได้อย่างแม่นยำ ลดภาระงานที่ไม่จำเป็น และเพิ่มอัตราความสำเร็จในการขาย

4. สรุปผล

4.1 สรุปผลการศึกษา

จากการศึกษานี้พบว่า โมเดล การเรียนรู้ของเครื่อง ที่ใช้ด้วยเทคนิค Logistic Regression, Decision Tree, Random Forest และ LightGBM สามารถตอบสนองต่อวัตถุประสงค์ในการพยากรณ์โอกาสการซื้อประกันภัยรถยนต์ได้อย่างมีประสิทธิภาพ โดยมีรายละเอียดดังนี้

4.1.1 การระบุปัญหาทางธุรกิจและวัตถุประสงค์

การศึกษานี้เริ่มจากการระบุปัญหาหลักในกระบวนการขาย คือ การที่ทีมขายไม่สามารถติดตามลูกค้าได้อย่างมีประสิทธิภาพ เนื่องจากปริมาณลูกค้าที่มากเกินไป โมเดลพยากรณ์ที่จึงเน้นการระบุกลุ่มลูกค้าเป้าหมายที่มีแนวโน้มสูงในการซื้อประกันภัย ทำให้การจัดลำดับความสำคัญในการติดต่อลูกค้าเป็นไปอย่างแม่นยำ

4.1.2 การเปรียบเทียบโมเดลพยากรณ์

โมเดลที่ใช้ประกอบด้วย Logistic Regression, LightGBM, Decision Tree และ Random Forest โดยได้ใช้ข้อมูลลูกค้าที่เกี่ยวข้อง เช่น อายุรถยนต์ สถานะของประกันภัย และข้อมูลเชิงพฤติกรรมของลูกค้า ผลการทดสอบโมเดลแสดงว่า LightGBM มีประสิทธิภาพสูงสุดในการจำแนกกลุ่มลูกค้าที่มีแนวโน้มจะซื้อประกันภัย

4.1.3 การประเมินประสิทธิภาพของโมเดล

การประเมินโมเดลใช้ตัวชี้วัดเช่น Precision, Recall, F1-Score และ AUC โดยโมเดล LightGBM มีค่า Precision สูงสุดที่ 0.835, F1-Score ที่ 0.905 และ AUC ที่ 0.9996 ซึ่งแสดงถึงความแม่นยำและความเสถียรสูงสุดในการทำนายผล

4.2 อภิปรายผลของการศึกษา

ผลการศึกษานี้แสดงให้เห็นว่า การใช้แบบจำลองการเรียนรู้ของเครื่อง สามารถช่วยเพิ่มประสิทธิภาพในการคัดกรองลูกค้าเป้าหมายสำหรับการขายประกันภัยรถยนต์ผ่านช่องทางโทรศัพท์ได้อย่างมีนัยสำคัญ โดยเฉพาะอย่างยิ่งโมเดล LightGBM ซึ่งได้รับการประเมินว่ามีความแม่นยำสูงสุด (ค่า Precision 0.835, ค่า F1 Score 0.905 และค่า AUC 0.9996) เมื่อเทียบกับวิธีการคัดกรองแบบเดิมที่อาศัยการตัดสินใจของทีมขายและข้อมูลพื้นฐานของลูกค้า

จากผลการทดลอง พบว่า การใช้แบบจำลอง Machine Learning ช่วยลดจำนวนลูกค้าที่ต้องติดต่อลงจากทั้งหมด 200,000 ราย เหลือเพียง 38% ซึ่งเป็นกลุ่มที่มีแนวโน้มสูงสุดในการต่ออายุประกันภัย (ประมาณ 76,000 ราย) ตัวเลขนี้ได้มาจากการคำนวณ Threshold Optimization ของโมเดล LightGBM โดยใช้ Precision-Recall Tradeoff เพื่อลดจำนวนลูกค้าที่มีแนวโน้มต่ำ และโฟกัสเฉพาะกลุ่มที่มีศักยภาพในการต่ออายุสูง

ในด้านผลกระทบต่อ อัตราความสำเร็จในการขาย (Conversion Rate) พบว่า โมเดลช่วยเพิ่มอัตราความสำเร็จขึ้น 40% เมื่อเทียบกับกระบวนการเดิม ตัวเลขนี้ได้จากการเปรียบเทียบอัตราความสำเร็จของทีมขายก่อนและหลังใช้โมเดล

ผลลัพธ์สอดคล้องกับงานวิจัยก่อนหน้า เช่น Fatma Manlaikhaf (2023) ซึ่งพบว่าการใช้ Logistic Regression และ Random Forest สามารถช่วยเพิ่ม Conversion Rate ได้ 25-35% ในการขายประกันผ่านโทรศัพท์

Ahmed Shawky Elbhrawy et al. (2023) ที่ศึกษาเกี่ยวกับการใช้ Machine Learning ในธุรกิจประกันภัย และพบว่า การใช้โมเดลที่มีประสิทธิภาพสูง เช่น Gradient Boosting สามารถเพิ่มอัตราการต่ออายุได้มากกว่า 30%

การศึกษานี้ยังยืนยันว่า การใช้โมเดลพยากรณ์ที่เหมาะสมสามารถช่วยลดภาระงานของทีมขาย ได้อย่างมีประสิทธิภาพ โดยลด เวลาที่ใช้ในการติดต่อลูกค้าโดยเฉลี่ยได้ถึง 40% ซึ่งหมายความว่า ทีมขายสามารถลดจำนวนการโทรที่ไม่มีประสิทธิภาพลง และมุ่งเน้นไปที่ลูกค้าที่มีแนวโน้มสูงมากขึ้น

การอ้างอิงตัวเลข 38% และ 40%

ตัวเลข 38% มาจากการคำนวณ Sensitivity-Precision Optimization ของโมเดล LightGBM

ตัวเลข 40% มาจาก การวิเคราะห์ระยะเวลาการโทรของทีมขายก่อนและหลังใช้โมเดล โดยการคำนวณเฉลี่ยจากระยะเวลาการโทรทั้งหมด

4.3 ข้อเสนอแนะสำหรับการศึกษาครั้งนี้

4.3.1 การเพิ่มแหล่งข้อมูล: ควรรวบรวมข้อมูลเพิ่มเติม เช่น พฤติกรรมการใช้งานออนไลน์ของลูกค้า เพื่อเสริมสร้างความแม่นยำในการพยากรณ์

4.3.2 การพัฒนาโมเดลเพิ่มเติม: ควรพิจารณาใช้เทคนิคขั้นสูง เช่น Neural Networks เพื่อเพิ่มประสิทธิภาพและรองรับการวิเคราะห์ข้อมูลที่มีความซับซ้อนมากขึ้น

4.3.3 การตรวจสอบผลลัพธ์ในสถานการณ์จริง: แนะนำให้ทดลองใช้งานโมเดลในสถานการณ์จริงอย่างต่อเนื่อง พร้อมรวบรวมคำติชมจากทีมขายเพื่อปรับปรุงโมเดลให้ตรงกับความต้องการมากยิ่งขึ้น

4.4 ข้อเสนอแนะสำหรับการศึกษาในครั้งต่อไป

4.4.1 การขยายขนาดกลุ่มตัวอย่าง: ควรเพิ่มขนาดกลุ่มตัวอย่างให้ครอบคลุมลูกค้าทั่วประเทศ เพื่อให้ผลการวิเคราะห์สามารถนำไปประยุกต์ใช้ได้ในวงกว้าง

4.4.2 การศึกษาปัจจัยเพิ่มเติม: ควรศึกษาเกี่ยวกับปัจจัยภายนอก เช่น สภาพเศรษฐกิจและการแข่งขันในตลาด ที่อาจส่งผลต่อการตัดสินใจซื้อประกันของลูกค้า

4.4.3 การพัฒนากระบวนการจัดการข้อมูล: เสริมกระบวนการทำความสะอาดข้อมูล (*Data Cleaning*) เพื่อให้มั่นใจว่าข้อมูลที่ใช้มีความถูกต้องและสมบูรณ์ที่สุด

4.4.4 การเพิ่มความรู้ด้านทฤษฎีและวัตถุประสงค์ของการวิจัย: ควรมีการอบรมหรือเพิ่มเนื้อหาด้านทฤษฎีที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลให้แก่ผู้ที่เกี่ยวข้อง เพื่อเพิ่มความเข้าใจและการประยุกต์ใช้งานที่ถูกต้อง

4.4.5 การศึกษาเกี่ยวกับกฎหมายและเทคนิคการวิเคราะห์ข้อมูล: ควรศึกษากฎระเบียบที่เกี่ยวข้องกับการใช้ข้อมูลส่วนบุคคล และเทคนิคการวิเคราะห์ที่สอดคล้องกับข้อกำหนดทางกฎหมายเพื่อความปลอดภัยและความเป็นส่วนตัวของข้อมูลลูกค้า

บทสรุปนี้แสดงให้เห็นถึงความสำเร็จของการเปรียบเทียบโมเดลในการพยากรณ์การซื้อประกันภัยรถยนต์ รวมถึงข้อเสนอแนะสำหรับการปรับปรุงและการขยายการวิจัยในอนาคต เพื่อเพิ่มประสิทธิภาพและความแม่นยำในการใช้งานโมเดลในองค์กร

5. เอกสารอ้างอิง

[1] Fayyad U, Piatetsky-Shapiro G, Smyth P. From data mining to knowledge discovery in databases. AI Magazine. 1996;17(3): 37-54.

[2] วิทิตา ค้าผล. การพยากรณ์กระแสไฟฟ้าขัดข้องโดยใช้เทคนิคเหมืองข้อมูล กรณีศึกษาการไฟฟ้าส่วนภูมิภาค เขต 3 ภาคกลาง. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต. มหาวิทยาลัยธรรมศาสตร์; 2558.

[3] Techsauce Team. เจาะลึก MARS Inspect AI ตรวจสภาพรถยุค Next Normal กับการพัฒนา AI สู่มิติใหม่ของวงการ InsurTech [Internet]. Techsauce; 2022 May 11 [cited 2023 Oct 26]. Available from: https://techsauce.co

[4] Selected. Insurtech คืออะไร? นวัตกรรมเปลี่ยนวงการประกันภัยในยุคดิจิทัล [Internet]. Selected; 2023 [cited 2023 Oct 26]. Available from: https://selected.com

[5] Everyday Marketing. InsurTech: บทบาทของ Big Data ในธุรกิจประกันภัยใช้ AI วิเคราะห์ข้อมูล [Internet]. Everyday Marketing; 2023 May 14 [cited 2023 Oct 26]. Available from: https://everydaymarketing.co

[6] SlidePlayer. Introduction to CRISP-DM [Internet]. [cited 2023 Oct 26]. Available from: https://slideplayer.com

[7] Techtalkthai. AXA ทดลองใช้ Deep Learning ผ่าน TensorFlow ในการ Optimize ราคาประกันรถยนต์ [Internet]. Techtalkthai; 2015 Nov 30 [cited 2023 Oct 26]. Available from: https://techtalkthai.com

[8] จักรพันธุ์ จำปาแก้ว. การพัฒนาโมเดลต้นแบบเครื่องมือสนับสนุนการตัดสินใจการพยากรณ์ทางคลินิกในแพทย์แผนไทย. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต. มหาวิทยาลัยนเรศวร; 2565.

[9] ฟิน อินชัวรันส์ โบรคเกอร์ จำกัด. 'ฟิน ประกันรถ' สตาร์ทอัพสายประกันสัญชาติไทย ชูวิสัยทัศน์สู่ผู้นำ InsurTech เปิดตัว Platform ประกันรถแห่งอนาคต [Internet]. 2565 [cited 2023 Oct 26]. Available from: https://fininsurance.co.th

[10] ภัทราภรณ์ ทองคำ. การพยากรณ์ยอดขายประกันภัย กรณีศึกษา ธุรกิจประกันภัย. วารสารวิชาการ มหาวิทยาลัยธนบุรี. 2562;13(3):45-58.

[11] ธนพล ศรีสุข. การสร้างแบบจำลองการขายผลิตภัณฑ์และพยากรณ์ยอดขายประกันชีวิต โดยเทคนิคการทำเหมืองข้อมูล. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต. มหาวิทยาลัยธรรมศาสตร์; 2558.

การทำนายโอกาสในการเข้ามาตรการช่วยเหลือลูกหนี้ค้างชำระของธนาคารออมสินในเขตกำแพงเพชร ด้วยเหมืองข้อมูล

Forecasting the Probability of Delinquent Borrowers Entering Debt Relief at the Government Savings Bank in Kamphaeng Phet Using Data Mining

พีรวัชร อำไพวัชรากุล* สุวรรณี อัศวกุลชัย

สาขาวิชาวิศวกรรมคอมพิวเตอร์และเทคโนโลยีการเงิน บัณฑิตวิทยาลัย มหาวิทยาลัยหอการค้าไทย

(* *ppeerawach@hotmail.com*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์สองประการ คือ 1) วิเคราะห์ปัจจัยที่มีผลต่อการเข้าร่วมมาตรการช่วยเหลือหนี้ของลูกหนี้ที่ค้างชำระ และ 2) พยากรณ์ความน่าจะเป็นในการอนุมัติสินเชื่อเพื่อแก้ไขปัญหาการชำระหนี้ของลูกหนี้ที่ค้างชำระ โดยใช้เทคนิคการขุดข้อมูลจากฐานข้อมูลของธนาคารออมสินในจังหวัดกำแพงเพชร งานวิจัยดำเนินการตามขั้นตอน CRISP-DM โดยใช้โปรแกรม Weka พบว่าลูกหนี้ที่ค้างชำระมีจำนวนมากส่งผลกระทบต่อสภาพคล่องทางการเงินของธนาคาร ข้อมูลที่ใช้ในการวิเคราะห์รวบรวมจากลูกค้าสินเชื่อจำนวน 18,653 ราย ตั้งแต่เดือนมกราคมถึงกรกฎาคม 2567 หลังจากการเตรียมข้อมูล ได้ทำการสร้างแบบจำลองการพยากรณ์ด้วยอัลกอริทึม 3 แบบ คือ เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เทคนิคเบย์อย่างง่าย (Naïve Bayes) และเทคนิคเพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbors หรือ KNN) ผลการวิเคราะห์พบว่าอัลกอริทึม KNN ให้ความแม่นยำในการพยากรณ์สูงสุด (99.87%) สูงกว่า Decision Tree (98.08%) และ Naïve Bayes (90.99%) ปัจจัยหลักที่ส่งผลต่อการเข้าร่วมมาตรการช่วยเหลือหนี้ของลูกหนี้ ได้แก่ จำนวนครั้งในการปรับโครงสร้างหนี้ ยอดหนี้ค้างชำระทั้งหมด และอัตราดอกเบี้ย ผลการวิจัยนี้ชี้ให้เห็นถึงความสำคัญของการพัฒนานโยบายและกลยุทธ์ในการบริหารจัดการหนี้ค้างชำระ และสามารถนำไปใช้ปรับปรุงกระบวนการอนุมัติสินเชื่อให้มีประสิทธิภาพมากขึ้น

คำสำคัญ: มาตรการช่วยเหลือหนี้ ลูกหนี้ค้างชำระ การขุดข้อมูล, เทคนิคต้นไม้ตัดสินใจ (Decision Tree), เทคนิคเบย์อย่างง่าย (Naïve Bayes), และเทคนิคเพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbors หรือ KNN)

Abstract

This study aims to: 1) analyze factors influencing debt relief measures among delinquent borrowers, and 2) forecast loan approvals for addressing loan repayment issues at the Government Savings Bank in Kamphaeng Phet using data mining. Employing the CRISP-DM methodology, the study used Weka in six stages. Findings reveal a significant number of delinquent borrowers negatively impacting the bank's financial liquidity. Data was collected from 18,653 loan customers from January to July 2024. Data preparation involved cleaning, grouping, and organization. Three predictive models were developed using Decision Tree, Naïve Bayes, and K-Nearest Neighbors (KNN) algorithms. KNN achieved the highest predictive accuracy (99.87%), exceeding Decision Tree (98.08%) and Naïve Bayes (90.99%). Key factors influencing debt relief when borrowers defaulted included the number of debt restructurings, total outstanding debt, and the loan's interest rate. This study demonstrates the significance of these findings for developing policies and strategies to effectively manage delinquent loans. Insights from this analysis can improve loan approval processes.

Keywords: Debt relief, delinquent borrowers, data mining, Decision Tree, Naïve Bayes, and K-Nearest Neighbors (KNN) algorithms.

1. บทนำ

จากสภาวะเศรษฐกิจถดถอย ส่งผลกระทบต่อรายได้ของทั้งประชาชนและภาคธุรกิจ รวมถึงกระทบต่อการดำเนินธุรกิจของธนาคารพาณิชย์ โดยเฉพาะความสามารถในการชำระหนี้ของลูกหนี้ที่ลดลง นับตั้งแต่การระบาดของเชื้อไวรัสโควิด-19 ในช่วงไตรมาสที่ 2 ปี 2563 ระบบธนาคารพาณิชย์ไทยจึงเผชิญการเปลี่ยนแปลงหลายด้าน เช่น แนวโน้มการเติบโตของสินเชื่อและเงินฝาก รวมถึงคุณภาพสินเชื่อและการบริหารความเสี่ยง ธนาคารพาณิชย์ยังคงรักษาเงินกองทุน เงินสำรอง และสภาพคล่องในระดับสูง อย่างไรก็ตาม ธนาคารยังสามารถรองรับความต้องการสินเชื่อและความผันผวนทางเศรษฐกิจในช่วงที่ได้รับผลกระทบจากการแพร่ระบาดได้ มาตรการช่วยเหลือลูกหนี้และการผ่อนปรนเกณฑ์การจัดชั้นช่วยชะลอการด้อยลงของคุณภาพสินเชื่อ แต่ทำให้ผลประกอบการลดลงเมื่อเทียบกับปีก่อน เนื่องจากรายได้ดอกเบี้ยลดลง ขณะที่เงินฝากเพิ่มขึ้นในปี 2564 แต่ไม่สูงเท่าช่วงการระบาดระลอกแรก (มีนาคม-พฤษภาคม 2563) การปล่อยสินเชื่อเพิ่มขึ้นเพราะธนาคารปล่อยสินเชื่อช่วยผู้ประกอบการ ปัญหาหนี้ค้างชำระที่เพิ่มขึ้นกระทบธนาคารออมสินหลายด้าน ด้านการเงิน ธนาคารต้องกันสำรองหนี้สูญเพิ่มขึ้น สามารถดูได้จาก[1] กระทบผลประกอบการและสภาพคล่องระยะยาวหากหนี้ค้างชำระมาก ด้านภาพลักษณ์ กระทบความเชื่อมั่นลูกค้าและสาธารณชนต่อความมั่นคงของธนาคาร อาจถูกมองว่าไม่มีประสิทธิภาพในการบริหารความเสี่ยง ด้านการดำเนินงาน ต้องใช้ทรัพยากรในการติดตามและบริหารจัดการหนี้มากขึ้น ทั้งบุคลากรและงบประมาณ อาจต้องเข้มงวดนโยบายปล่อยสินเชื่อ กระทบการเติบโตของธุรกิจ ด้านนโยบาย อาจกระทบความสามารถในการสนับสนุนนโยบายรัฐบาลในการพัฒนาเศรษฐกิจฐานราก จึงต้องปรับกลยุทธ์ให้สอดคล้องกับสถานการณ์ ด้วยเหตุนี้ การพยากรณ์ความน่าจะเป็นของลูกหนี้ที่จะเข้ามาตรการช่วยเหลือจึงมีความสำคัญอย่างยิ่ง เพราะจะช่วยให้ธนาคารสามารถบริหารจัดการความเสี่ยงได้อย่างมีประสิทธิภาพ ปรับปรุงกลยุทธ์การอนุมัติสินเชื่อ พัฒนาและปรับปรุงมาตรการช่วยเหลือลูกหนี้[3] เพิ่มประสิทธิภาพการดำเนินงาน และสนับสนุนการตัดสินใจเชิงกลยุทธ์ ผลลัพธ์ที่คาดหวังจากการวิจัยนี้คือแบบจำลองการทำนายที่แม่นยำข้อมูลเชิงลึกเกี่ยวกับปัจจัยเสี่ยง และการปรับปรุงประสิทธิภาพการบริหารจัดการหนี้

1.1 วัตถุประสงค์ของการวิจัย

1.1.1 เพื่อศึกษาปัจจัยของลูกหนี้ที่มีผลต่อการเข้ามาตรการช่วยเหลือลูกหนี้ค้างชำระของธนาคารออมสิน

1.1.2 เพื่อพยากรณ์การอนุมัติสินเชื่อเพื่อแก้ไขปัญหาการจ่ายเงินกู้ โดยใช้วิธีเหมืองข้อมูล (Data Mining)

1.1.3 เสนอแนะแนวทางปรับปรุงมาตรการช่วยเหลือลูกหนี้ค้างชำระให้มีประสิทธิภาพมากขึ้น โดยคำนึงถึงความต้องการของลูกหนี้ ความยั่งยืนทางการเงินของธนาคาร และความสอดคล้องกับนโยบายภาครัฐ

1.2 ขอบเขตด้านเนื้อหา

ศึกษาปัจจัยที่มีผลต่อการตัดสินใจเข้าร่วมมาตรการช่วยเหลือลูกหนี้ค้างชำระ และผลลัพธ์หลังจากลูกหนี้เข้าร่วมมาตรการช่วยเหลือ

1.3 ขอบเขตด้านประชากรและกลุ่มตัวอย่าง

กลุ่มตัวอย่าง: ลูกหนี้ปกติ ลูกหนี้ค้างชำระไม่เกิน 90 วัน (Non-NPLs) และลูกหนี้ค้างชำระเกิน 90 วัน (NPLs) ของธนาคารออมสิน กลุ่มสินเชื่อรายย่อย จังหวัดกำแพงเพชร ตั้งแต่เดือนมกราคม – กรกฎาคม 2567 จำนวน 18,653 ราย

2. วิธีการวิจัย

2.1 วิธีเก็บข้อมูลในการศึกษา

การเก็บข้อมูลแบบทุติยภูมิ (Secondary data) จากแหล่งข้อมูลภายในธนาคารผ่าน Microsoft Sharepoint ของฝ่ายสนับสนุนงานบริหารหนี้ ธนาคารออมสิน รายงานการเข้ามาตรการของลูกค้าธนาคารออมสิน ส่วนของเขตกำแพงเพชร และศึกษาแนวคิด ทฤษฎี เกี่ยวกับพฤติกรรมการเข้ามาตรการช่วยเหลือจากหนังสือ เอกสารทางวิชาการ งานวิจัย บทความที่เกี่ยวข้องและระบบฐานข้อมูลอินเตอร์เน็ต (Internet) จากการศึกษาและวิเคราะห์ข้อมูลเบื้องต้นเกี่ยวกับการปัจจัยมีผลต่อการเข้ามาตรการช่วยเหลือลูกหนี้ค้างชำระของธนาคารออมสินในเขตกำแพงเพชร พบว่า มีข้อมูลที่จำเป็นสำหรับการศึกษานี้ ตัวอย่างเช่น วันทำสัญญา (SIGN_DATE) จำนวนเงินต้นคงเหลือ (BALANCE), เงินงวด (PAMENT), อัตราดอกเบี้ย (INTEREST RATE), จำนวนเดือนที่ผิดนัดตามเกณฑ์ ธปท. (DELINQUENCY PERIOD BY BOT CRITERIA), ลำดับการปรับโครงสร้างหนี้ (RESTRUCTURING SEQUENCE)

2.2 เครื่องมือที่ใช้ในการศึกษา

2.2.1 ระบบปฏิบัติการและโปรแกรม ใช้ระบบปฏิบัติการ Windows 10 Pro

2.2.2 โปรแกรม Microsoft Excel ใช้ในการคัดเลือกข้อมูลที่จะนำมาใช้เตรียมข้อมูล โดยมีวิธีการคัดเลือกข้อมูลโดยการใช้ความรู้และประสบการณ์ของผู้วิจัย (Expert Knowledge)

2.2.3 โปรแกรม Weka ใช้ในการวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล

2.3 วิธีการวิเคราะห์ข้อมูล

ตามกรอบ Framework ของ CRISP-DM (Cross-Industry Standard Process for Data Mining) มีรายละเอียด 6 ขั้นตอนดังนี้ [7]

2.3.1 การเข้าใจในธุรกิจ (*Business Understanding*) [6]

ขั้นตอนแรกในกระบวนการ CRISP-DM เน้นที่การทำความเข้าใจกระบวนการทางธุรกิจโดยรวม เพื่อวิเคราะห์ปัญหาและแปลงปัญหาที่มีอยู่ให้อยู่ในรูปแบบโจทย์ที่จะนำไปสู่การวิเคราะห์ข้อมูลทาง Data Mining การศึกษานี้มีจุดประสงค์ในการวิเคราะห์การเข้ามาตรการของลูกค้าและ

ปัจจัยที่นำไปสู่การค้างชำระหนี้ สามารถประยุกต์ใช้การทำเหมืองข้อมูลในการป้องกันการเกิดหนี้ค้างชำระของธนาคาร การมองภาพรวมจะช่วยในการกำหนดสมมุติฐานเกี่ยวกับปัจจัย เช่น วงเงินกู้ ยอดสินเชื่อ และอัตราดอกเบี้ย โดยเป้าหมายคือการปรับปรุงความแม่นยำในการพิจารณาสินเชื่อและประหยัดเวลาในการทำงานอย่างมีประสิทธิภาพ

2.3.2 การทำความเข้าใจข้อมูล (*Data Understanding*)

ในขั้นตอนนี้จะมีการทำความเข้าใจข้อมูล โดยพิจารณาจากข้อมูลลูกค้าที่เก็บรวบรวมในระบบงานของธนาคาร ซึ่งข้อมูลดังกล่าวมีจำนวนทั้งหมด 18,653 ราย การเก็บข้อมูลนี้ช่วยให้มีความเข้าใจในลักษณะและปัญหาของลูกค้าสินเชื่อที่ต้องการการวิเคราะห์เพิ่มเติม โดยการแสดงข้อมูลในรูปแบบตารางจะช่วยให้เห็นภาพรวมและความสำคัญของข้อมูลนี้ในขั้นตอนถัดไป

2.3.3 การเตรียมข้อมูล (*Data Preparation*)

การเตรียมข้อมูลเป็นขั้นตอนที่สำคัญและใช้เวลานานที่สุดในการทำเหมืองข้อมูล ภายในขั้นตอนนี้ ข้อมูลที่ถูกบันทึกอาจมีปัญหาเกี่ยวกับความสมบูรณ์ รวมถึงค่าผิดปกติ (Outlier) จึงจำเป็นต้องมีการจัดเตรียมข้อมูลสำหรับการนำเข้าไปใช้ในโมเดลพยากรณ์ โดยการกลั่นกรองข้อมูลเพื่อทำให้ข้อมูลมีคุณภาพสูงขึ้น และตรวจสอบความคลาดเคลื่อนหรือแก้ไขข้อมูลที่ไม่สามารถใช้งานได้ เพื่อให้ข้อมูลมีความสมบูรณ์และสามารถนำไปใช้ในการวิเคราะห์ต่อไป

2.3.4 การจัดทำและเลือกโมเดล (*Modeling*)

ขั้นตอนนี้เป็นการสร้างโมเดลทางคณิตศาสตร์และสถิติสำหรับการวิเคราะห์ข้อมูล โดยจะใช้เทคนิคทาง Data Mining ที่หลากหลาย เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด ในการสร้างแบบจำลอง จะใช้ข้อมูลจากฐานข้อมูลนำไปทดสอบโดยเลือกโมเดล ได้แก่ Decision Tree, K Nearest Neighbor (KNN) และ Naïve Bayes Classifier โดยจะทำการทดสอบทีละอัลกอริธึมและเปรียบเทียบผลลัพธ์เพื่อหาโมเดลที่แม่นยำที่สุด ในขั้นตอนนี้จะใช้ค่า Confusion Matrix เป็นเครื่องมือในการวัดความแม่นยำของอัลกอริธึมที่เลือกใช้ โดยในงานวิจัยนี้จะใช้ข้อมูลฝึกหัด (Use Training Set) เป็นหลัก

2.3.5 การประเมินผลก่อนตัดสินใจ (*Evaluation*)

ในการประเมินผล เราจะประเมินผลลัพธ์จากการวิเคราะห์ข้อมูลที่ได้ โดยต้องตรวจสอบว่าผลลัพธ์ดั่งกล่าวตรงตามวัตถุประสงค์ที่ตั้งไว้และมีความน่าเชื่อถือเพียงพอ หากผลลัพธ์ไม่สามารถให้ความเชื่อมั่นได้ อาจจำเป็นต้องย้อนกลับไปยังขั้นตอนก่อนหน้าเพื่อนำข้อมูลไปปรับปรุงใหม่ โดยเฉพาะในการวิเคราะห์ปัจจัยที่ส่งผลต่อการเข้ามาตรการช่วยเหลือลูกหนี้ ควรนำแนวคิด 6 C's มาประยุกต์ใช้ในการวิเคราะห์ให้มีประสิทธิภาพมากยิ่งขึ้น

*2.3.6 การเผยแพร่*ผลวิเคราะห์ (Deployment)

ขั้นตอนสุดท้ายคือการเผยแพร่ผลวิเคราะห์ ซึ่งสามารถทำได้ในรูปแบบของรายงานหรือแผนภาพ (Dashboard) ที่ออกแบบมาเพื่อให้ฝ่ายต่าง ๆ สามารถนำไปใช้ประโยชน์ในการวางแผนและกำหนดกลยุทธ์ได้อย่างมีประสิทธิภาพ การจัดทำรายงานจะช่วยให้ผู้บริหารหรือนักพัฒนาระบบเข้าใจข้อมูลได้ชัดเจน ส่งผลให้การพัฒนาระบบการอนุมัติสินเชื่อทำได้อย่างรวดเร็วและมีประสิทธิ

2.4 งานวิจัยที่เกี่ยวข้อง

2.4.1 นายประมุข ปาประโคน (2564) ได้ศึกษาการใช้เหมืองข้อมูลในการศึกษาปัจจัยที่มีผลต่อการจ่ายสินเชื่อตามข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) ของธนาคารเพื่อการเกษตรและสหกรณ์การเกษตร สาขาบางเขนโดยใช้เทคนิคเหมืองข้อมูล อันเนื่องมาจากปริมาณยอดการจ่ายสินเชื่อตามข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) ในปีบัญชี 2563 ลดลงจากปี 2561 – 2562 และมีแนวโน้มที่จะลดลงอย่างต่อเนื่อง โดยการรวบรวมข้อมูลลูกค้าที่ซื้อสลากออมทรัพย์และข้อมูลลูกค้าที่มียอดการเบิกสินเชื่อข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) ของสาขาบางเขน ในบัญชี 2563 ประกอบไปด้วยข้อมูลลูกค้าที่ซื้อสลากออมทรัพย์ทั้งสิ้น 6,378 ราย และมีลูกค้าที่มียอดการเบิกสินเชื่อข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) จำนวน 802 ราย โดยมีแอทริบิวต์ที่จำเป็นต่อการศึกษาจำนวน 7 แอทริบิวต์ ได้แก่ อายุลูกค้า ระยะเวลาที่ติดต่อธนาคาร เพศ สถานะสมรส ยอดรวมเงินฝากประเภทสลาก ยอดรวมสินเชื่ออื่นๆ และลูกค้ามีการกู้สินเชื่อข้อบังคับฉบับ 35 แล้ว นำข้อมูลมาทดสอบกับเทคนิคการจำแนกกลุ่มจำนวน 4 เทคนิค ได้แก่ เทคนิคต้นไม้ตัดสินใจ(Decision Tree) เทคนิคกฎการตัดสินใจ (Decision Rule) เทคนิคตัวจำแนกประเภทเบย์อย่างง่าย(Naïve-Bayes) และเทคนิคซัพพอร์ทเวกเตอร์แมชชีน (Support Vector Machine) จากการทดสอบพบว่าเทคนิคต้นไม้ตัดสินใจ Decision Tree: J48 ให้ผลลัพธ์ที่มีความถูกต้องมากที่สุด โดยมีผลลัพธ์ ความถูกต้อง 87.50% และสามารถสรุปปัจจัยที่มีผลต่อการจ่ายสินเชื่อตามข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) จากการวิเคราะห์ข้อมูลจากการทดสอบ ได้แก่ ระยะเวลาที่ติดต่อธนาคาร ยอดรวมสินเชื่ออื่นๆ และยอดรวมเงินฝากประเภทสลาก [2]

2.4.2 นางสาวนพมาศ บุญปั้น (2564) ได้ศึกษาปัจจัยที่ทำให้เกิดปัญหาหนี้ค้าง (NPL)ผ่านโครงการพัฒนาระบบสินเชื่อดิจิทัล(Digital Lending)ในกลุ่มลูกค้าของธนาคารเพื่อการเกษตรและสหกรณ์การเกษตร(ธ.ก.ส.)จังหวัดลพบุรีและเพื่อประยุกต์เหมืองข้อมูลในการอนุมัติสินเชื่อในการแก้ไขปัญหาการจ่ายเงินกู้ โดยเก็บรวบรวมข้อมูลของลูกค้าเงินกู้ที่เข้าร่วมโครงการสินเชื่อฉุกเฉินที่มีอยู่ในระบบสารสนเทศของธนาคารเพื่อการเกษตรและสหกรณ์การเกษตร จังหวัดลพบุรี จำนวน 9,002 ราย จากการ ที่ลูกค้ากรอกข้อมูลส่วนตัวลงใน Line Official ของ ธ.ก.ส. เพื่อสมัครสินเชื่อฉุกเฉิน ทำการวิเคราะห์ข้อมูลโดยการสร้างแบบจำลองการเรียนรู้ผ่านโปรแกรม Weka เพื่อหาความสำคัญของปัจจัยที่ส่งผลให้เกิดปัญหาหนี้ค้าง (NPL) [4]

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการเข้าใจในธุรกิจ(Business Understanding)

ปัจจัยที่ทำให้ลูกค้ารายย่อยเป็นหนี้ค้างชำระมีหลายสาเหตุ รวมถึงการชะลอตัวของเศรษฐกิจ การปรับขึ้นอัตราดอกเบี้ย

การประเมินเครดิต ระบบติดตามหนี้ ภาระค่าใช้จ่ายครัวเรือน พฤติกรรมการใช้จ่ายฟุ่มเฟือย และสถานะทางการเงินและอาชีพ ทั้งหมดนี้เป็นปัจจัยภายนอกที่อยู่นอกขอบเขตข้อมูลของธนาคาร

3.2 ผลการทำความเข้าใจข้อมูล (Data Understanding)

ประชากรในการศึกษาจำนวน 18,653 รายนั้น มีการแบ่งกลุ่มลูกค้าออกเป็นสามประเภท ได้แก่ ลูกหนี้ที่ไม่เป็นหนี้ค้างจำนวน ลูกหนี้ที่เป็นหนี้ค้างมาแล้วไม่เกิน 90 วัน (Non-NPLs) และลูกค้าที่เป็นหนี้ค้างมากกว่า 90 วัน (NPLs) หากบริหารจัดการกับหนี้ค้างชำระในกลุ่มนี้ได้ ส่งผลให้วงเงินที่กันไว้เป็นเงินสำรองลดลง เมื่อต้นทุนเงินกันสำรองลดลง จะช่วยเพิ่มรายได้ให้กับธนาคาร

3.3 การเตรียมข้อมูล (Data Preparation)

มีหลายขั้นตอน เพื่อให้ข้อมูลพร้อมเข้าแบบจำลอง ดังนี้

3.3.1 เลือกปัจจัย (Feature selection) ที่ทำให้เกิดปัญหาการค้างชำระหนี้ แสดงโครงสร้างข้อมูลลูกค้า ในตารางที่ 1

ตารางที่ 1: การคัดเลือกปัจจัย

สาขา	CID	CIF	ปประเภทหลักเมื่อเริ่มมี	รหัสที่	วันที่ทำสัญญา	ครบกำหนดชำระ	วงเงินกู้	ยอดหนี้เมื่อสิ้นเดือน	ดอกเบี้ยเงินกู้	เงินต้นที่ SUB ชำระ
สาขาพระนคร	8000003800445	1197/2084 สินเชื่อเคหะ	1007 ลูกค้าทั่วไป		18-May-53	30-Apr-73	1,200,000.00	113,961.15	64.32	8,347.36
สาขาลาดกระบัง	8000003801568	70767747 สินเชื่อเพื่อพัฒนาการเรียนรู้	1070 พัฒนาคุณภาพชีวิตราษฎร์		18-May-53	31-Oct-73	695,000.00	405,331.54	333.01	31,565.64
สาขาพระนคร	8000003794445	23393997 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		25-May-53	30-Jun-68	850,000.00	738,777.94	595.89	75,845.33
สาขาพระนคร	8000003325335	11018914 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		25-May-53	30-Apr-68	400,000.00	147,444.98	65.85	11,962.92
สาขาพระนคร	8000003330376	11018438 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1079 พัฒนาคุณภาพชีวิตราษฎร์		25-May-53	25-Jul-73	1,471,000.00	711,021.49	5,240.92	46,535.80
สาขาพระนคร	8000003330822	11002847 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1079 พัฒนาคุณภาพชีวิตราษฎร์		25-May-53	20-Apr-68	1,465,000.00	984,353.68	13,008.17	67,965.29
สาขาพระนคร	8000003331845	11018376 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1079 พัฒนาคุณภาพชีวิตราษฎร์		25-May-53	31-Dec-73	1,161,000.00	781,880.87	851.48	92,359.01
สาขาลาดกระบัง	8000004900843	11018452 สินเชื่อเคหะ	1007 ลูกค้าทั่วไป		7-Jun-53	30-Jun-81	800,000.00	465,064.31	2,275.04	26,519.36
สาขาพระนครเหนือ	8000003143218	11108585 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1067 พัฒนาชีวิตฯ		8-Jun-53	31-Oct-81	971,000.00	981,698.77	566.10	
สาขาวังแพงพระ	8000003549633	27349400 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		27-May-53	31-Dec-73	1,400,000.00	941,141.77	620.29	
สาขาหลองยอย	8000003573520	18385818 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		7-Jun-53	31-May-74	1,500,000.00	959,015.08	2,558.82	64,685.75
สาขาหลองยอย	8000003582653	10542639 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		7-Jun-53	30-Jun-73	1,500,000.00	345,995.62	386.28	35,200.76
สาขาหลองยอย	8000003588949	10627419 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		7-Jun-53	31-May-68	500,000.00	136,349.23	152.23	14,954.07
สาขาพระนคร	8000003605909	11090725 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		9-Jun-53	30-Jun-73	1,200,000.00	286,838.48	384.29	23,792.13
สาขาลองยอย	8000003629305	10542547 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1067 พัฒนาชีวิตฯ		7-Jun-53	2-Jun-68	1,695,000.00	414,386.48	920.87	40,548.49
สาขาหลองยอย	8000003631871	11078547 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		10-Jun-53	31-Oct-73	1,280,000.00	716,715.11	938.73	3,774.16
สาขาหลองยอย	8000003677651	20711063 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		7-Jun-53	1-Oct-78	1,500,000.00	1,312,652.43	947.13	195,076.61
สาขาพระนคร	8000003713746	11296230 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		15-Jun-53	30-Nov-73	1,000,000.00	1,479,924.16	2,562.51	85,951.22
สาขาหลองยอย	8000003743826	10542680 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		10-Jun-53	31-May-73	1,200,000.00	462,980.63	827.32	61,762.60
สาขาหลองยอย	8000003752165	10120893 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		10-Jun-53	28-Feb-75	1,500,000.00	891,853.55	995.71	68,585.03
สาขาหลองยอย	8000003753460	11018428 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		9-Jun-53	30-Jun-73	1,200,000.00	459,212.05	512.58	46,846.14
สาขาวังแพงพระ	8000003788619	11077760 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		16-Jun-53	29 พฤษภาคม 2	600,000.00	282,387.37	352.85	21,142.52
สาขาวังแพงพระ	8000003855372	19751052 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		17-Jun-53	31-Dec-78	1,500,000.00	477,295.07	695.35	77,947.99
สาขาพระนคร	8000003876832	13340849 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		17-Jun-53	2-Jun-68	1,200,000.00	527,987.75	934.21	26,502.60
สาขาบึงกำแพง	8000003883564	11714144 สินเชื่อเอสโอโฮม	1037 สถิติการดำเนินงานประจำ		14-Jun-53	30-Jun-78	800,000.00	496,537.30	408.12	32,327.58
สาขาพระนคร	8000003909625	10542490 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1069 เทศบาล อบต. อบจ.		9-Jun-53	30-Sep-67	1,630,000.00	1,165,616.74	520.53	53,313.35
สาขาพระนคร	8000003914526	11409600 สินเชื่อเพื่อพัฒนาคุณภาพชีวิต	1069 เทศบาล อบต. อบจ.		9-Jun-53	31-May-73	1,539,000.00	660,491.50	646.92	47,372.26

จากตารางที่ 1 ข้อมูลของลูกค้าที่อยู่ในระบบเมื่อนำมาบันทึกข้อมูลใน MS Excel สามารถแจกแจงตัวแปรได้ทั้งหมด 15 ตัวแปร แสดงในตารางที่ 2

ตารางที่ 2: ตัวแปรที่ใช้ในการศึกษา

ลำดับ	Attribute	ความหมาย
1	Contract_Loan	วงเงินกู้
2	Total_Debt	ภาระหนี้ทั้งหมด
3	Int_rate	อัตราดอกเบี้ย
4	PMAT	เงินงวด
5	Pastdue_Day	วันค้างชำระ
6	Total_Due	ยอดค้างชำระทั้งหมด
7	Frequency	ความถี่ในการชำระ
8	Method	วิธีการชำระ
9	Legal	สถานะทางกฎหมาย
10	FLAG_MYMO (Active)	สถานะการใช้แอพธนาคาร
11	Job	อาชีพ
12	Class	ชั้นหนี้
13	Last_DR/TDR	การปรับปรุงโครงสร้างหนี้ล่าสุด
14	Number of DR/TDR	จำนวนครั้งของการปรับปรุงโครงสร้างหนี้
15	DR_67	การเข้ามาตรการ

3.3.2 การเข้ารหัสข้อมูล (Encoding)

จากข้อมูลในตารางที่ 1 นำมาปรับให้อยู่ในรูปแบบ nominal scale แสดงในตารางที่ 3 และแสดงการกระจายตัวของข้อมูลในภาพที่ 1 จากตารางที่ 2 เมื่อนำมาบันทึกข้อมูลใน MS Excel กำหนดการเข้ารหัสข้อมูลให้อยู่ในรูปแบบ nominal scale ได้แสดงในตารางที่ 3

ตารางที่ 3: การเข้ารหัสข้อมูลในรูปแบบ nominal scale

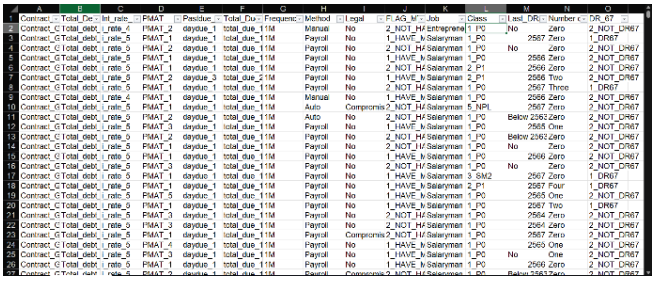

จากตารางที่ 3 เมื่อนำมาวิเคราะห์ภาพรวม Attributes ในโปรแกรม Weka แสดงในภาพที่ 1

ภาพที่ 1: แสดงภาพรวม Attributes ในโปรแกรม Weka

3.4 ผลพัฒนาแบบโมเดล (Modeling)

ในการศึกษานี้ได้พัฒนาตัวแบบพยากรณ์ด้วย 3 เทคนิคทางเหมืองข้อมูล ได้แก่ ต้นไม้วิเคราะห์ (Decision Tree), K-Nearest Neighbours (KNN) และการจำแนกแบบเบย์เซียน (Naïve Bayesian Classifier) โดยใช้โปรแกรม Weka จากนั้นศึกษาการเพิ่มประสิทธิภาพของตัวแบบพยากรณ์แต่ละเทคนิคด้วยชุดข้อมูลฝึกหัด (Training Set)

3.4.1 ผลของต้นไม้ตัดสินใจ (decision tree) ในงานวิจัยนี้ผู้วิจัยได้ทำการประยุกต์ใช้โมเดลการจำแนกประเภท J48 เพื่อทำการวิเคราะห์ข้อมูลและทำการ Validation ตัวแบบพยากรณ์ด้วยชุดข้อมูลฝึกหัด โมเดล J48 ที่สร้างขึ้นนี้แสดงถึงความสัมพันธ์ระหว่างคุณลักษณะต่าง ๆ ที่ส่งผลต่อการจำแนกประเภท ในการตัดสินใจเกี่ยวกับจำนวน DR/TDR

จากพฤติกรรมการชำระหนี้ โดยจำนวน DR/TDR ทั้งหมดได้ถูกแบ่งออกเป็นหลายกรณี ที่รวมถึงกรณีที่มี DR/TDR เป็นศูนย์ สอง สาม และสี่ ตามลำดับ ผลการประเมินแสดงให้เห็นว่าโมเดลนี้สามารถจำแนกประเภทได้ถูกต้องถึง 90.99% และมีการจำแนกประเภทที่ไม่ถูกต้องเพียง 9.01% สามารถวัดข้อมูลเหล่านี้ได้ด้วยค่าคงที่ Kappa ที่ 0.4619 ซึ่งแสดงถึงความแม่นยำที่ดีในระดับหนึ่ง นอกจากนี้ ค่า Mean Absolute Error อยู่ที่ 0.1475 และ Root Mean Squared Error ที่ 0.2715 ซึ่งชี้ให้เห็นถึงข้อผิดพลาดในระดับที่ยอมรับได้ เมื่อพิจารณาถึงความถูกต้องตามคลาส โมเดลสามารถจำแนกคลาส 2_NOT_DR67 ได้อย่างมีประสิทธิภาพ โดยมีค่า True Positive Rate สูงถึง 0.994 และ Precision ที่ 0.911 ขณะที่คลาส 1_DR67 มี True Positive Rate ต่ำกว่าเพียง 0.349 แต่ค่า Precision อยู่ที่ 0.889 ซึ่งแสดงให้เห็นว่าเมื่อพิจารณาทั้งสองคลาส โมเดลยังคงมีความสามารถในด้านความถูกต้องโดยรวมแล้ว โมเดล J48 นี้มีความสามารถในการจำแนกประเภทข้อมูลที่มีความซับซ้อนได้ดี และผลลัพธ์ที่ได้แสดงให้เห็นถึงศักยภาพในการประยุกต์ใช้งานจริงในด้านการวิเคราะห์ข้อมูลการเงินและการชำระหนี้ แสดงในภาพที่ 2

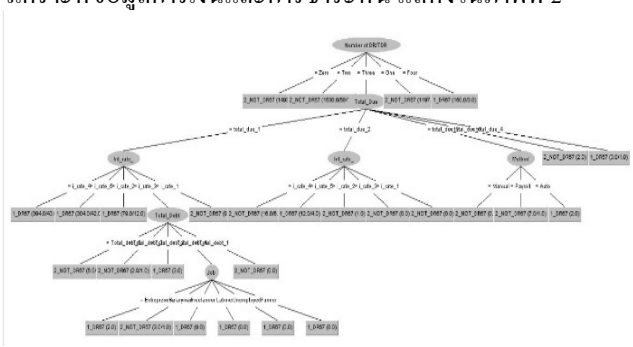

ภาพที่ 2: ผลแบบจำลองต้นไม้ตัดสินใจ (decision tree)

3.4.2 ผลการจำแนกแบบเบย์อย่างง่าย (Naïve Bayesian classifier) ในการวิจัยนี้ผู้วิจัยได้ใช้โมเดล Naive Bayes ในการจำแนกประเภทข้อมูลที่เกี่ยวข้องกับสถานะทางการเงินและการชำระหนี้ แสดงให้เห็นถึงความสามารถในการจำแนกประเภทได้อย่างมีประสิทธิภาพ โดยอัตราการจำแนกประเภทที่ถูกต้องสูงถึง 98.08% ซึ่งหมายความว่ามีเพียง 1.92% ของรายงานที่ถูกจัดลำดับผิดพลาด ความถูกต้องที่สูงนี้ยืนยันโดยค่าความแม่นยำ Kappa ที่ 0.916 อีกทั้งค่า Mean Absolute Error ที่อยู่ในระดับต่ำ (0.0265) แสดงให้เห็นถึงความผิดพลาดที่น้อยในข้อมูลที่ถูกใช้วิเคราะห์ การวิเคราะห์รายละเอียดความแม่นยำตามคลาส ได้แสดงให้เห็นว่าคลาส 2_NOT_DR67 มีค่า True Positive Rate สูงมากถึง 0.987 ซึ่งบ่งชี้ถึงความสามารถในการทำนายกลุ่มที่ไม่ตกอยู่ในสถานะเสี่ยง หากแต่มองในเชิงของคลาส 1_DR67, ค่า True Positive Rate อยู่ที่ 0.940 แม้จะต่ำกว่าเล็กน้อยแต่ก็ยังถือว่าเป็นระดับที่สูง แสดงถึงความสามารถในการทำนายกลุ่มที่มีความเสี่ยง [5] แสดงในภาพที่ 3

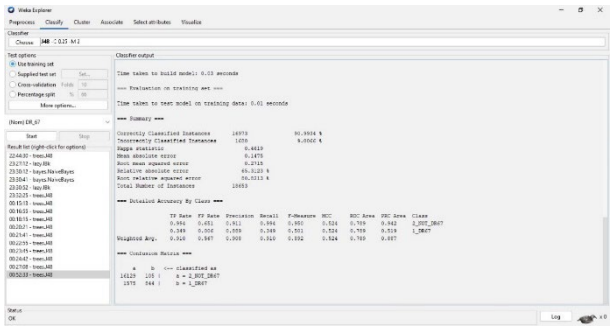

ภาพที่ 3: ผลแบบจำลองเบย์ (Naïve Bayesian Classifier)

3.4.3 ทำการ Validation ตัวแบบพยากรณ์ด้วยชุดข้อมูลฝึกหัด (Use training set) ใช้ค่า K=1 ผลการประเมินแสดงให้เห็นว่าอัลกอริธึมที่เลือกใช้นั้นมีความแม่นยำสูงมากโดยสามารถจำแนกประเภทได้ถูกต้องถึง 99.87% และมีการจำแนกประเภทที่ไม่ถูกต้องเพียง 0.13% ซึ่งนับว่าเป็นอัตราความผิดพลาดที่ต่ำมาก นอกจากนี้ ค่าสถิติ Kappa สะท้อนถึงความแม่นยำที่สูงถึง 0.9943 แสดงถึงประสิทธิภาพของโมเดลในการทำนายคลาสต่างๆ ได้อย่างดี การวัดความแม่นยำในกลุ่มข้อมูลที่แตกต่างกันยังแสดงให้เห็นถึงผลลัพธ์ที่น่าพอใจ โดยเฉพาะในคลาส 2_NOT_DR67 และ 1_DR67 ซึ่งมีค่า True Positive Rate สูงถึง 0.999 และ 0.996 ตามลำดับ ข้อมูลยังบ่งบอกถึงความแม่นยำที่สูงในการจำแนกประเภททั้งสองคลาส ดังนั้น โมเดลนี้จึงสามารถนำไปใช้ในการวิเคราะห์ข้อมูลการเงินและการชำระหนี้ได้อย่างมีประสิทธิภาพ แสดงในภาพที่ 4

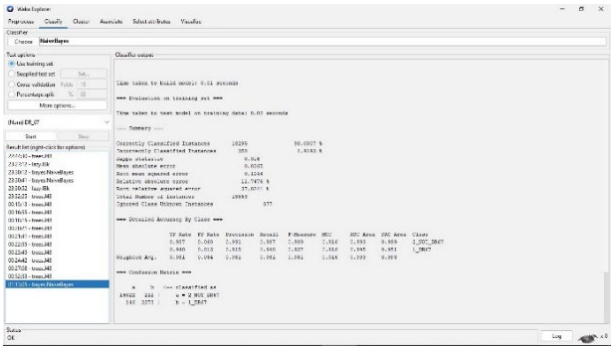

ภาพที่ 4: ผลแบบจำลอง K-Nearest Neighbours (KNN)

4. สรุปผลการศึกษา

ปัจจัยหลักที่ส่งผลต่อการเข้ามาตรการของลูกค้าเมื่อไม่สามารถส่งชำระหนี้ตามเงินงวดเดิมได้ คือ จำนวนครั้งในการปรับปรุงโครงสร้างหนี้ ยอดค้างชำระทั้งหมด และอัตราดอกเบี้ยตามสัญญากู้ สามารถนำไปพัฒนานโยบายและกลยุทธ์ในการจัดการหนี้ค้างในอนาคต โดยใช้ข้อมูลที่ได้จากการวิเคราะห์เพื่อปรับปรุงกระบวนการอนุมัติสินเชื่อให้มีประสิทธิภาพมากยิ่งขึ้น

การทำนายด้วยแบบจำลอง 3 algorithm ได้แก่ เทคนิคต้นไม้ตัดสินใจ เทคนิคเบย์อย่างง่าย และเทคนิค K-Nearest Neighbors (KNN) สรุปผลได้ในตารางที่ 4

ตารางที่ 4: ผลการเปรียบเทียบแบบจำลองทั้ง 3 โมเดล

Algorithms	Precision	Recall	F-Measure	Correctly Classified Instances
Decision Tree	0.889	0.349	0.501	90.99%
Naïve Bayes	0.915	0.94	0.927	98.08%
K-Nearest Neighbours	0.994	0.996	0.995	99.87%

พบว่า เทคนิค KNN ให้ค่าความถูกต้องในการทำนายสูงที่สุด 99.87% เทียบกับ Decision Tree และ Naïve Bayes ค่าความถูกต้องในการทำนาย 98.08%, 90.99% ตามลำดับ

จากตารางที่ 4 ผลการเปรียบเทียบการวิเคราะห์หาปัจจัยการ เข้ามาตรการช่วยเหลือของธนาคารของแบบจำลองทั้ง 3 โมเดล พบว่าตัวแบบ K-Nearest Neighbours เหมาะสม ในการนำไปใช้พยากรณ์มากกว่าตัวแบบพยากรณ์ที่ได้จากเทคนิคอื่น ๆ เนื่องจากให้ค่าความแม่นยำ (Precision), ค่าการเรียกคืน (Recall), ค่าความมีประสิทธิภาพ (F-Measure) และค่าความถูกต้องในการทำนาย (Correctly Classified Instances) สูงที่สุดอย่างมีนัยสำคัญเมื่อ เปรียบเทียบกับทั้ง 3 โมเดล

5. อภิปรายผลการศึกษา

การพิจารณาปัจจัยที่ส่งผลต่อการเข้ามาตรการช่วยเหลือของลูกหนี้ค้างชำระนั้นมีความซับซ้อนและครอบคลุมหลากหลายมิติ นอกเหนือจากปัจจัยพื้นฐานทางการเงินและการชำระหนี้ที่ได้ระบุไว้แล้ว ยังมีปัจจัยอื่น ๆ ที่ควรนำมาพิจารณาประกอบ เพื่อให้เกิดความเข้าใจอย่างรอบด้านต่อสถานการณ์ของลูกหนี้ ประการแรก ปัจจัยส่วนบุคคลของลูกหนี้มีความสำคัญอย่างยิ่ง โดยเฉพาะอายุ ระดับการศึกษา และสถานภาพสมรส ซึ่งอาจส่งผลต่อวุฒิภาวะทางการเงิน ความสามารถในการทำความเข้าใจเงื่อนไขของมาตรการและภาระทางการเงินโดยรวม นอกจากนี้ จำนวนผู้อยู่ในอุปการะก็เป็นอีกปัจจัยหนึ่งที่สะท้อนถึงภาระค่าใช้จ่ายและความสามารถในการชำระหนี้ของลูกหนี้ ประการที่สอง ปัจจัยด้านอาชีพและรายได้ก็มีความสำคัญ โดยควรพิจารณาทั้งระดับรายได้ปัจจุบัน อัตราส่วนภาระหนี้ต่อรายได้ และระยะเวลาการทำงานในอาชีพปัจจุบัน ซึ่งสามารถบ่งชี้ถึงความมั่นคงทางการเงินและความสามารถในการเข้าร่วมมาตรการช่วยเหลือได้ ประการที่สาม ประวัติทางการเงินและพฤติกรรมการชำระหนี้ในอดีตก็เป็นปัจจัยที่ไม่ควรมองข้าม โดยนอกจากจะพิจารณาจากวันค้างชำระและจำนวนครั้งของการปรับปรุงโครงสร้างหนี้แล้ว ควรวิเคราะห์ประวัติการชำระหนี้ในภาพรวมด้วย รวมถึงประเภทของสินเชื่อที่ลูกหนี้มีอยู่ และมูลค่าหลักประกัน (หากมี) ก็ควรนำมาประกอบการพิจารณา ประการที่สี่ ปัจจัยด้านภูมิศาสตร์และเศรษฐกิจมหภาคก็มีความสำคัญ โดยภูมิลำเนาของลูกหนี้อาจส่งผลต่อโอกาสของลูกหนี้ได้

ผู้วิจัยยังไม่ได้ใช้ข้อมูลเกี่ยวกับภาระหนี้ภายนอก เงินฝาก ข้อมูลของบุคคลในครัวเรือนของลูกค้ารายย่อย และปัจจัยภายนอกที่มีผลต่อรายได้และค่าใช้จ่ายของครัวเรือนในการวิเคราะห์ นอกจากนี้ ข้อมูลที่นำมาใช้ในการวิเคราะห์ยังมีจำนวนจำกัดและไม่ได้ถูกเก็บรวบรวมในที่เดียว ทำให้การเข้าถึงข้อมูลเป็นไปได้ยาก การมีองค์ความรู้และเครื่องมือที่เหมาะสมเป็นสิ่งสำคัญ ดังนั้น การรวบรวมและจัดเก็บข้อมูลให้สามารถเข้าถึงได้ง่ายจึงเป็นสิ่งจำเป็น หากต้องการใช้ข้อมูลเหล่านี้ในการสร้างแบบจำลองพยากรณ์ต่างๆ การศึกษาหาความรู้เกี่ยวกับการทำเหมืองข้อมูลจะช่วยลดต้นทุนในการดำเนินงาน ประหยัดเวลา และสร้างแบบจำลองที่มีประสิทธิภาพมากยิ่งขึ้น

6. ข้อเสนอแนะ

เนื่องจากงานวิจัยนี้ได้ทำการเก็บรวบรวมข้อมูลจากระบบ Microsoft Sharepoint ของระบบงานธนาคาร ในจังหวัดกำแพงเพชร จำนวน 18,653 ราย ซึ่งอาจส่งผลต่อความคลาดเคลื่อนในการวิเคราะห์ จึงมีความจำเป็นที่จะต้องมีการศึกษาต่อเนื่องในประชากรกลุ่มตัวอย่างทั่วประเทศ เพื่อให้สามารถมองเห็นปัจจัยต่าง ๆ จากมุมมองที่หลากหลายมากขึ้น ควรนำข้อมูลของบุคคลในครัวเรือนมาใช้ในการวิเคราะห์ด้วยเนื่องจากมีผลทั้งต่อรายได้และค่าใช้จ่ายของลูกค้า ซึ่งจะส่งผลต่อการชำระหนี้ ควรนำข้อมูลด้านหนี้สินภายนอกมาใช้ในการพิจารณาด้วย ซึ่งเป็นภาระค่าใช้จ่ายที่เกิดขึ้น ควรนำข้อมูลด้านการออมเงิน ซึ่งแสดงให้เห็นถึงศักยภาพและนิสัย งานวิจัยนี้ใช้แค่อัลกอริทึม KNN, Naive Bayes และ Decision Tree โดยไม่ทดสอบกับโมเดลอื่น เช่น SVM หรือ MLP ซึ่งเป็นข้อจำกัดเพราะอาจทำให้ผลลัพธ์ไม่ครอบคลุม เหตุผลที่เลือกใช้อัลกอริทึมเหล่านี้ ได้แก่ ความคุ้นเคยและความเชี่ยวชาญของผู้วิจัย ความเรียบง่ายของอัลกอริทึมที่เหมาะกับการสื่อสารในงานวิจัย ขอบเขตที่จำกัดของงานวิจัยซึ่งไม่ต้องการการทดลองที่ซับซ้อนมากขึ้น ข้อจำกัดด้านทรัพยากรทั้งเวลาและคอมพิวเตอร์ และการที่ลักษณะข้อมูลเหมาะสมกับการใช้อัลกอริทึมทั้งสามนี้ ในการใช้งานข้อมูลส่วนบุคคล ได้รับการควบคุมตามพรบ.คุ้มครองข้อมูลส่วนบุคคล พ.ศ.2562 จึงต้องใช้ความระมัดระวังให้มากในการนำข้อมูลต่างๆ มาใช้งาน

7. กิตติกรรมประกาศ

ขอขอบพระคุณพนักงานธนาคารออมสิน สำนักงานใหญ่ ที่ได้ให้ความอนุเคราะห์ในการสนับสนุนข้อมูลที่จำเป็นสำหรับการศึกษาครั้งนี้ ที่ได้ให้ความช่วยเหลือตลอดเวลาที่ศึกษาอยู่ และพี่ ๆ เพื่อน นักศึกษาปริญญาทุกท่านที่ได้ให้กำลังใจและความช่วยเหลือในการทำการศึกษาค้นคว้าอิสระตลอดมา

8. เอกสารอ้างอิง

[1] คลินิกแก้หนี้. “หนี้เสีย” หรือหนี้ที่ค้างชำระเกิน 90 วัน (NPL: Non-performing Loan). 2564. Available from: https://www.debtclinicbysam.com/%E0%B8%AB%E0%B8%99%E0%B8%B5%E0%

[2] ชุดาภา ผิวเผือก. ปัจจัยที่ใช้ในการวิเคราะห์สินเชื่อของธนาคารพาณิชย์ในประเทศไทย (สารนิพนธ์ปริญญามหาบัณฑิต). กรุงเทพฯ: มหาวิทยาลัยธุรกิจบัณฑิตย์, สาขาวิชาการบัญชี; 2562.

[3] ธนาคารออมสิน. ข้อมูลการให้ความช่วยเหลือลูกหนี้ของธนาคารออมสิน. 2565. Available from: https://www.gsb.or.th/sfi/

[4] ประมุข ปาประโคน. การใช้เหมืองข้อมูลในการศึกษาปัจจัยที่มีผลต่อการจ่ายสินเชื่อตามข้อบังคับฉบับที่ 35 (สลากออมทรัพย์) (สารนิพนธ์ปริญญามหาบัณฑิต). กรุงเทพฯ: มหาวิทยาลัยหอการค้าไทย; 2564.

[5] Downey A. Think Bayes: Bayesian statistics in Python. Sebastopol, CA: O'Reilly Media, Inc.; 2013.

[6] Kirk M. Thoughtful machine learning: A test-driven approach. Sebastopol, CA: O'Reilly Media, Inc.; 2014.

[7] Thapanee Boonchob. เข้าใจ CRISP-DM ฉบับเร่งรัด. 2565. Available from: https://kamboonchob. medium.com/ %E0 % B9 % 8 0 % E0 % B8 % 8 2 % E0 % B9 % 8 9 % E0 % B8 % B2 % E0 % B9 % 8 3 % E0 % B8 % 8 8 - crisp-dm-%E0%B8%89%E0%B8%9A%E0%B8%B1%E0%B8%9A%E0%B9%80%E0%B8%A3%E0%B9%88%E0%B8%87%E0%B8%A3%E0%B8%B1%E0%B8%94-b09130501

โมเดลการตรวจจับความถูกต้องของการออกกำลังกาย ด้วยท่า Dumbbell Biceps Curl โดยใช้เทคนิคการเรียนรู้ของเครื่อง

Dumbbell Biceps Curl Exercise Accuracy Detection Model Using Machine Learning Techniques

ชนธา ขันสิงห์หา รชานนท์ พลเรือง ศิรินทิพย์ เรืองวงษ์ สุมณฑ์กาญจน์ บำรุงพฤกษ์ มธุรส ผ่านเมือง*

ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

(* *mathuros_p@rmutt.ac.th*)

บทคัดย่อ

การออกกำลังกายเป็นกิจกรรมที่สำคัญต่อสุขภาพร่างกายและจิตใจ ช่วยเสริมสร้างความแข็งแรงของกล้ามเนื้อ ป้องกันโรค และเพิ่มสมรรถภาพทางกาย อย่างไรก็ตาม การออกกำลังกายที่ไม่ถูกต้องอาจส่งผลให้เกิดอาการบาดเจ็บหรือไม่ได้รับประโยชน์สูงสุดจากการฝึกซ้อม ดังนั้น การใช้เทคโนโลยีในการตรวจสอบและปรับปรุงท่าทางการออกกำลังกายจึงเป็นแนวทางที่มีประสิทธิภาพ งานวิจัยนี้มุ่งเน้นการพัฒนาและประเมินโมเดลการตรวจจับท่าทางการออกกำลังกาย Dumbbell Biceps Curl โดยใช้ MediaPipe และ OpenCV เพื่อให้ผู้ใช้สามารถตรวจสอบและปรับปรุงท่าทางของตนเองได้แบบเรียลไทม์ โมเดลที่พัฒนาขึ้นสามารถวิเคราะห์ค่าที่สำคัญ ได้แก่ รัศมีข้อศอก, องศาการยกดัมเบล และแกนกลางลำตัว โดยใช้พิกัดจุดสำคัญของร่างกายในการคำนวณมุมและตรวจสอบเสถียรภาพของท่าทาง การประเมินประสิทธิภาพของโมเดลโดยใช้ค่าทางสถิติ ได้แก่ Precision, Recall และ Accuracy ผลการตรวจจับแต่ละท่าพบว่า 1) รัศมีข้อศอก มีค่า Precision 75%, Recall 88%, และ Accuracy 76% แสดงให้เห็นว่าโมเดลสามารถตรวจจับตำแหน่งข้อศอกได้ดี แต่ยังมี False Positive (FP) 10 ครั้ง ซึ่งอาจส่งผลให้บางครั้งโมเดลระบุท่าที่ผิดพลาดว่าเป็นท่าที่ถูกต้อง 2) องศาการยกดัมเบล มีค่า Precision 70%, Recall 93%, และ Accuracy 76% แสดงให้เห็นว่าโมเดลสามารถตรวจจับองศาการยกได้ครบถ้วนมากที่สุด แต่ยังมี FP 12 ครั้ง ซึ่งหมายความว่าโมเดลอาจเกิดข้อผิดพลาดในการจำแนกท่าที่ถูกต้อง และ 3) แกนกลางลำตัว มีค่า Precision 85%, Recall 89%, และ Accuracy 83% ซึ่งเป็นค่าความถูกต้องสูงสุดในจากทุกพารามิเตอร์ แสดงให้เห็นว่าโมเดลสามารถตรวจจับและรักษาเสถียรภาพของลำตัวได้อย่างดีเยี่ยม โดยมี False Positive ต่ำที่สุด (6 ครั้ง)

คำสำคัญ: การตรวจจับท่าทางมนุษย์, การจำแนกการออกกำลังกาย, โครงกระดูก, การจดจำกิจกรรมของมนุษย์

Abstract

Exercise is crucial for both mental and physical well-being. It enhances physical fitness, prevents illness, and increases muscular strength. On the other hand, improper exercise might lead to injuries or a failure to maximize training benefits. As a result, employing technology to identify and enhance exercise posture is a successful strategy. To help users identify and correct their posture in real time, this study focuses on creating and testing a Dumbbell Biceps Curl workout posture recognition model utilizing MediaPipe and OpenCV. Using essential body data, the created method can compute angles and verify the stability of posture by analyzing critical variables including elbow radius, dumbbell lifting angle, and torso core. The model performance evaluation was performed using statistical parameters: Precision, Recall, and Accuracy. The statistical metrics of accuracy, precision, and recall were used to evaluate the model's performance. The detection results for each position were as follows: The model showed good elbow position detection with a 75% precision, 88% recall, and 76% accuracy for the elbow radius; however, it also had 10 False Positives (FP), which can sometimes lead to the

model misidentifying proper posture; and the model most comprehensive lifting angle detection with a 70% precision, 93% recall, and 76% accuracy for the dumbbell lift angle. However, it still had 12 FP, indicating that the model might not correctly characterize the pose; and 3) Core Arm demonstrated the best accuracy of all metrics with 85% Precision, 89% Recall, and 83% Accuracy. This showed that the model was able to identify and stabilize the torso with the lowest False Positives (6 times).

Keywords: Human Pose Detection, Exercise Classification, Skeleton, Human Activity Recognition

1. บทนำ

จากสภาพปัจจุบัน ความเจริญเติบโตทั้งทางด้านเศรษฐกิจ สังคม และเทคโนโลยี ส่งผลให้มนุษย์มีบทบาทสำคัญในการพัฒนาประเทศ การมีคุณภาพชีวิตที่ดีเป็นปัจจัยสำคัญในการสร้างกำลังแรงงานที่มีศักยภาพและยั่งยืน หนึ่งในปัจจัยสำคัญของคุณภาพชีวิตคือสุขภาพที่แข็งแรง ซึ่งสามารถส่งเสริมได้ผ่านการออกกำลังกาย ที่เป็นกิจกรรมที่ช่วยให้ร่างกายและจิตใจแข็งแรง ส่งผลให้การเรียนรู้ การทำงาน และการดำเนินชีวิตมีประสิทธิภาพมากขึ้น แม้ว่าหลายคนอาจรู้สึกไม่อยากออกกำลังกาย แต่การทำกิจกรรมนี้เป็นสิ่งสำคัญที่ช่วยเพิ่มความแข็งแกร่งให้กับระบบกล้ามเนื้อ ระบบไหลเวียนโลหิต และสุขภาพโดยรวม [1] หนึ่งในรูปแบบการออกกำลังกายที่ได้รับความนิยมคือการฝึกด้วยน้ำหนัก (Weight Training) ซึ่งช่วยพัฒนากล้ามเนื้อและความแข็งแรงของร่างกาย ท่า Dumbbell Biceps Curl เป็นหนึ่งในท่าฝึกที่มุ่งเน้นพัฒนากล้ามเนื้อไบเซ็ปส์ (Biceps Brachii) โดยตรง อย่างไรก็ตาม การทำท่าทางที่ไม่ถูกต้องอาจทำให้เกิดความเจ็บปวดและบาดเจ็บได้ โดยเฉพาะในผู้สูงอายุหรือผู้ที่ไม่มีประสบการณ์ในการฝึกซ้อม [2] ดังนั้นหากมีผู้ฝึกสอนที่คอยตรวจสอบท่าทางในทุกครั้งจะทำให้ช่วยควบคุมความถูกต้องและลดการบาดเจ็บ แต่อย่างไรก็ตาม การมีผู้ฝึกสอนนั้นอาจจะไม่สะดวกหรือเหมาะสมสำหรับทุกคน ดังนั้นหากมีระบบหรือเครื่องมือที่ช่วยในการตรวจสอบความถูกต้องของการออกกำลังกายด้วยท่า Dumbbell Biceps Curl ที่ผู้ใช้งานสามารถเข้าถึงได้ทุกที่และทุกเวลาที่ต้องการ จะช่วยให้การออกกำลังกายมีความถูกต้องและลดการบาดเจ็บลงได้

ปัจจุบัน เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) และการเรียนรู้ของเครื่อง (Machine Learning: ML) ถูกนำมาประยุกต์ใช้ในด้านสุขภาพและ ฟิตเนส เพื่อช่วยตรวจจับและวิเคราะห์การเคลื่อนไหวของร่างกาย เทคโนโลยี Computer Vision และระบบติดตามการเคลื่อนไหว (Motion Tracking) ช่วยให้สามารถระบุโครงสร้างของร่างกายและตรวจสอบท่าทางการออกกำลังกายแบบเรียลไทม์ได้ งานวิจัยล่าสุดได้นำ MediaPipe Pose Estimation มาใช้ร่วมกับการเรียนรู้ของเครื่องเพื่อจดจำท่าทางการออกกำลังกาย และเสนอระบบที่สามารถประเมินความถูกต้องของท่าทางโดยใช้เพียงกล้องเว็บแคมธรรมดา ซึ่งช่วยให้ผู้ใช้สามารถฝึกซ้อมได้โดยไม่จำเป็นต้องมีผู้ฝึกสอนส่วนตัว [3] นอกจากนี้ ยังมีการผสมผสานเทคนิค Logistic Regression เพื่อเพิ่มประสิทธิภาพของการวิเคราะห์ข้อมูลการเคลื่อนไหวของร่างกาย โดยเฉพาะในท่า Biceps Curl เพื่อให้สามารถคาดการณ์ความถูกต้องของการออกกำลังกายได้อย่างแม่นยำมากขึ้น [4]

ด้วยเหตุนี้ การวิจัยครั้งนี้จึงมีเป้าหมายในการพัฒนาและประยุกต์ใช้ Machine Learning เพื่อสร้างโมเดลตรวจจับความถูกต้องของท่า Dumbbell Biceps Curl โดยอาศัยการวิเคราะห์ภาพ (Computer Vision) และโมเดลการเรียนรู้เชิงลึก โมเดลดังกล่าวจะช่วยให้ผู้ใช้งานสามารถฝึกซ้อมได้อย่างถูกต้อง ลดความเสี่ยงจากการบาดเจ็บ และเพิ่มประสิทธิภาพของการออกกำลังกาย นอกจากนี้ ยังสามารถพัฒนาไปเป็นแอปพลิเคชันที่ช่วยให้คำแนะนำเกี่ยวกับท่าทางการออกกำลังกายแบบเรียลไทม์ โดยใช้โมเดล Landmark ของ MediaPipe Pose ในการประเมินพิกัดตำแหน่งของร่างกาย หากพบว่าท่าทางของผู้ใช้ไม่ตรงตามเกณฑ์ ระบบจะแสดงคำแนะนำให้แก้ไข แต่หากทำท่าทางถูกต้อง ระบบจะแสดงจำนวนครั้งของการออกกำลังกายพร้อมเสียงแจ้งเตือน [5] เทคโนโลยีดังกล่าวสามารถช่วยให้ผู้ใช้ฝึกซ้อมได้อย่างปลอดภัยและแม่นยำ อีกทั้งยังมีศักยภาพในการขยายขอบเขตไปสู่การตรวจสอบกิจกรรมที่หลากหลายขึ้นในอนาคต เช่น การฝึกเวทเทรนนิ่งในรูปแบบต่าง ๆ หรือการวิเคราะห์กีฬาประเภทอื่น เป้าหมายสูงสุดคือการพัฒนาระบบที่สามารถตรวจสอบการออกกำลังกายได้อย่างแม่นยำและสม่ำเสมอ ทำให้ผู้ใช้สามารถรักษาท่าทางที่ถูกต้องและลดความเสี่ยงจากการบาดเจ็บในระยะยาว [4]

2. วิธีการวิจัย

2.1 ศึกษาข้อมูลพื้นฐานเกี่ยวกับการตรวจจับท่าทางมนุษย์

การตรวจจับท่าทางมนุษย์ (Pose detection) เป็นกระบวนการที่ใช้ในการระบุและติดตามตำแหน่งของจุดสำคัญบนร่างกายมนุษย์ (Keypoint Detection) เช่น ไหล่ ศอก ข้อมือ และสะโพก ซึ่งจุดเหล่านี้มีความสำคัญอย่างยิ่งในการวิเคราะห์ท่าทางการเคลื่อนไหว โดยเฉพาะในการตรวจสอบความถูกต้องของท่าทางการออกกำลังกาย [6] ปัจจุบันมีไลบรารีหลายตัวที่ถูกพัฒนาขึ้นเพื่อช่วยในการตรวจจับจุดสำคัญเหล่านี้ โดย MediaPipe และ OpenCV เป็นสองไลบรารีที่ได้รับความนิยมอย่างแพร่หลาย [7]

MediaPipe เป็นแพลตฟอร์มโอเพนซอร์สที่พัฒนาโดย Google ซึ่งมีความสามารถในการตรวจจับและติดตามจุดสำคัญบนร่างกายมนุษย์ได้อย่างมีประสิทธิภาพ โดยใช้โมเดลการเรียนรู้ของเครื่อง (Machine Learning) ในการระบุจุดสำคัญต่าง ๆ เช่น ใบหน้า มือ และท่าทางของร่างกาย สำหรับการตรวจจับท่าทาง (Pose Detection) นั้น MediaPipe

ใช้โมเดลที่สามารถระบุตำแหน่งของจุดสำคัญบนร่างกาย จำนวน 33 จุด ซึ่งครอบคลุมตั้งแต่ศีรษะจนถึงเท้า [5] การทำงานของ MediaPipe เริ่มจากการตรวจจับบุคคลในภาพหรือวิดีโอ จากนั้นจึงระบุตำแหน่งของจุดสำคัญต่าง ๆ บนร่างกาย เพื่อสร้างโครงกระดูกเสมือนที่แสดงถึงท่าทางของบุคคลนั้น [8] ในทางปฏิบัติ การใช้ MediaPipe ร่วมกับ OpenCV เป็นแนวทางที่มีประสิทธิภาพในการตรวจจับและวิเคราะห์ท่าทางการเคลื่อนไหว OpenCV เป็นไลบรารีโอเพนซอร์สที่ใช้ในการประมวลผลภาพและวิดีโอ ซึ่งสามารถใช้ในการจัดการภาพที่ได้จากกล้องเว็บแคมหรือวิดีโอ เพื่อเตรียมข้อมูลสำหรับการประมวลผลโดย MediaPipe การผสมผสานระหว่าง MediaPipe และ OpenCV ช่วยให้สามารถตรวจจับจุดสำคัญบนร่างกายและแสดงผลในรูปแบบของโครงกระดูกเสมือนที่แสดงท่าทางการเคลื่อนไหวได้อย่างถูกต้องและเรียลไทม์ [9]

การศึกษาเชิงลึกเกี่ยวกับการทำงานของ MediaPipe ในส่วนของการตรวจจับท่าทาง ควรรวมถึงการเรียนรู้วิธีการใช้งานโมดูลต่าง ๆ ที่เกี่ยวข้องกับการตรวจจับโครงกระดูก (Pose Estimation) และการสร้างจุดสำคัญบนร่างกาย นอกจากนี้ การใช้ OpenCV ในการจัดการภาพและวิดีโอจะช่วยให้สามารถนำข้อมูลที่ได้ไปประมวลผลและแสดงผลในรูปแบบที่เข้าใจง่าย ซึ่งเป็นประโยชน์อย่างยิ่งในการตรวจสอบและปรับปรุงท่าทางการออกกำลังกายให้ถูกต้องและปลอดภัย [4]

2.2 พัฒนาและประยุกต์ใช้อัลกอริทึม

งานวิจัยนี้ได้ประยุกต์ใช้อัลกอริทึม MediaPipe และ OpenCV เพื่อตรวจจับความถูกต้องของการออกกำลังกายด้วยท่า Dumbbell Biceps Curl ซึ่งทั้งสองเทคโนโลยีที่สามารถทำงานร่วมกัน โดย MediaPipe เป็นเฟรมเวิร์กการเรียนรู้ของเครื่องที่ออกแบบมาเพื่อประมวลผลภาพและวิดีโอแบบเรียลไทม์ ส่วน OpenCV เป็นไลบรารีการประมวลผลภาพ (Computer Vision Library) ใช้สำหรับการอ่านและประมวลผลวิดีโอ เช่น การดึงเฟรมจากวิดีโอ การปรับแต่งภาพหรือการใช้ฟิลเตอร์ ดังนั้นจึงสามารถใช้ร่วมกับ MediaPipe ในการจัดการพิกัดจุดสำคัญของร่างกาย และแสดงผลบนหน้าจอ ซึ่งมีงานวิจัยหนึ่งที่น่าสนใจคือการตรวจจับท่าทางการยกดัมเบล (Dumbbell Lift Detection) โดยใช้เทคนิคการประมวลผลภาพร่วมกับการเรียนรู้ของเครื่องเพื่อระบุและวิเคราะห์ท่าทางการยกดัมเบลของผู้ใช้ ระบบนี้สามารถบันทึกจำนวนครั้งในการยกดัมเบลและให้ฟีดแบ็กเกี่ยวกับความถูกต้องของท่าทางได้แบบเรียลไทม์ การพัฒนาระบบดังกล่าวช่วยให้ผู้ใช้สามารถปรับปรุงท่าทางการออกกำลังกาย ลดความเสี่ยงจากการบาดเจ็บ และเพิ่มประสิทธิภาพในการฝึกซ้อม [10] นอกจากนี้ การใช้ไลบรารี MediaPipe และ OpenCV ยังช่วยในการตรวจจับและวิเคราะห์ท่าทางการออกกำลังกายอื่น ๆ เช่น โยคะ งานวิจัยที่เกี่ยวข้องได้แสดงให้เห็นว่าการใช้เทคโนโลยีเหล่านี้สามารถตรวจจับท่าทางของผู้ใช้และให้ฟีดแบ็กเกี่ยวกับความถูกต้องของท่าทางได้อย่างมีประสิทธิภาพ ซึ่งช่วยให้ผู้ฝึกสามารถปรับปรุงท่าทางและลดความเสี่ยงจากการบาดเจ็บ [11] ดังนั้นการประยุกต์ใช้อัลกอริทึมในครั้งนี้จึงมีความเหมาะสมและเป็นไปได้ที่จะนำมาพัฒนาโมเดล

ในการพัฒนาและปรับปรุงโมเดลตรวจจับท่าทางการออกกำลังกาย การใช้สมการทางคณิตศาสตร์เพื่อวิเคราะห์การเคลื่อนไหวเป็นสิ่งสำคัญ โดยปัจจัยหลักที่ใช้ในการประเมินความถูกต้องของท่าทางได้แก่ รัศมีข้อศอก, องศาการยกดัมเบล และแกนกลางลำตัว ซึ่งได้รับการกำหนดจากคำแนะนำของผู้เชี่ยวชาญด้านวิทยาศาสตร์การกีฬา ดังนั้นการวิจัยครั้งนี้จึงได้กำหนดสมการที่เกี่ยวข้องกับท่าทางดังกล่าวดังนี้

2.2.1 รัศมีข้อศอก (Elbow Radius, Re)

รัศมีข้อศอกเป็นตัวชี้วัดที่สำคัญในการตรวจสอบว่าผู้ใช้รักษาตำแหน่งข้อศอกให้อยู่กับที่ระหว่างการยกดัมเบลหรือไม่ หากข้อศอกมีการเคลื่อนที่ออกจากตำแหน่งมากเกินไป อาจส่งผลให้ท่าทางไม่ถูกต้องและลดประสิทธิภาพของการฝึก สมการสำหรับรัศมีข้อศอกสามารถกำหนดได้โดยใช้ระยะทางระหว่างข้อศอก (E) กับตำแหน่งเดิมของข้อศอกที่อยู่ในแนวแกนกลางลำตัว (E_0) ตามหลักการของระยะทางแบบยุคลิด (Euclidean Distance) [12] ซึ่งเป็นการวัดระยะทางตรงระหว่างจุดสองจุดในปริภูมิยุคลิด สามารถนำมาประยุกต์และกำหนดเป็นสมการได้ดังนี้

$$R_e = \sqrt{(x_E - x_{E_0})^2 + (y_E - y_{E_0})^2 + (z_E - z_{E_0})^2} \quad (1)$$

โดยที่ (x_E, y_E, z_E) เป็นพิกัดของข้อศอกในระหว่างการเคลื่อนไหว ส่วน (x_{E0}, y_{E0}, z_{E0}) เป็นพิกัดเริ่มต้นของข้อศอก และ Re เป็นค่ารัศมีที่ใช้พิจารณาการเคลื่อนที่ของข้อศอก หาก Re สูงเกินไป แสดงว่าข้อศอกมีการเคลื่อนที่มากเกินไป ซึ่งอาจทำให้ท่าทางผิด

เพื่อให้การตรวจจับมีความแม่นยำ ในการวิจัยครั้งนี้จึงได้กำหนด Threshold สำหรับรัศมีข้อศอกดังนี้

หาก $R_e \leq 5$ เซ็นติเมตร ถือว่าข้อศอกมีการเคลื่อนที่ในช่วงที่เหมาะสมและท่าทางถูกต้อง แต่หาก $5 < R_e < 7$ เซ็นติเมตรจะแจ้งเตือนว่าผู้ใช้กำลังเคลื่อนข้อศอกมากเกินไป และหาก $R_e \geq 7$ ถือว่าข้อศอกมีการขยับมากเกินไปและควรปรับปรุงท่าทาง

2.2.2 องศาการยกดัมเบล (Lifting Angle, θ_l)

องศาการยกดัมเบลเป็นตัวแปรสำคัญที่ใช้ตรวจสอบว่าผู้ใช้ยกน้ำหนักในช่วงองศาที่เหมาะสมหรือไม่ หากองศาการยกผิดไปจากค่าที่เหมาะสม อาจทำให้กล้ามเนื้อไม่ได้รับแรงต้านอย่างมีประสิทธิภาพ องศาการยกสามารถคำนวณได้โดยใช้เวกเตอร์ของแขนบน ($\vec{SE}$) และแขนล่าง ($\vec{EW}$) เพื่อหามุมข้อศอก โดยประยุกต์ใช้สมการของ Cosine Rule [13] ดังนี้

$$\theta_L = \cos^{-1}\left(\frac{\overrightarrow{SE}\cdot\overrightarrow{EW}}{\left|\overrightarrow{SE}\right|\left|\overrightarrow{EW}\right|}\right) \quad (2)$$

โดยที่ $\overrightarrow{SE}$ เป็นเวกเตอร์ที่เชื่อมระหว่างไหล่ (*S*) และข้อศอก (*E*) ส่วน $\overrightarrow{EW}$ เป็นเวกเตอร์ที่เชื่อมระหว่างข้อศอก (*E*) และข้อมือ (*W*) และ θ_L คือองศาการยกของแขน หากค่าออกนอกช่วงที่เหมาะสม (เช่น 45° - 90° สำหรับการฝึกไบเซ็ปส์) แสดงว่าผู้ใช้ทำท่าทางผิด

2.2.3 แกนกลางลำตัว (Body Stability, S_b)

การรักษาแกนกลางลำตัวให้มั่นคงเป็นปัจจัยสำคัญในการออกกำลังกายอย่างปลอดภัยและมีประสิทธิภาพ หากผู้ใช้เอนตัวไปข้างหน้าหรือข้างหลังมากเกินไป อาจส่งผลให้เกิดแรงกดดันที่ไม่เหมาะสมต่อกระดูกสันหลัง สมการในการวิเคราะห์เสถียรภาพของแกนกลางลำตัวใช้มุมระหว่างเส้นแนวตั้งจากสะโพก (*H*) ไปยังไหล่ (*S*) และเส้นแกนกลางลำตัวอ้างอิงในแนวดิ่ง โดยประยุกต์ใช้สมการของ Cosine Rule [13] ดังนี้

$$S_b = \cos^{-1}\left(\frac{\overrightarrow{HS}\cdot\vec{V}}{\left|\overrightarrow{HS}\right|\left|\vec{V}\right|}\right) \quad (3)$$

โดยที่ $\overrightarrow{HS}$ เป็นเวกเตอร์ที่เชื่อมสะโพก (*H*) กับไหล่ (*S*) ส่วน $\vec{V}$ เป็นเวกเตอร์แนวดิ่งในแกนอ้างอิง และ S_b คือมุมที่ใช้ตรวจสอบว่าผู้ใช้รักษาเสถียรภาพของแกนกลางลำตัวได้ดีหรือไม่ หากค่ามุมสูงเกินไป อาจหมายความว่าผู้ใช้กำลังเอนไปข้างหน้าหรือข้างหลังมากเกินไป

หลังจากกำหนดจุดสำคัญของท่าทาง จึงนำมาพัฒนาร่วมกับ MediaPipe และ OpenCV เพื่อประมวลผลแบบเรียลไทม์ โดยจะตรวจจับท่าทางแบบรายเฟรม และใช้หลักการ Majority Voting ในการสรุปผลลัพธ์ของแต่ละการยก โดยพิจารณาผลลัพธ์ของเฟรมทั้งหมดที่เกี่ยวข้อง หากมากกว่า 70% ของเฟรม ทำนายว่าท่าทางถูกต้อง โมเดลจะพิจารณาว่าการยกครั้งนั้นถูกต้อง

นอกจากนี้ เพื่อป้องกันข้อผิดพลาดที่อาจเกิดขึ้นจากเฟรมเดี่ยวที่มี Noise หรือข้อผิดพลาดในการตรวจจับ จะใช้ Moving Average ในการประเมินผลลัพธ์ โดยพิจารณาผลเฉลี่ยจาก 3 เฟรมล่าสุด เพื่อลดผลกระทบของเฟรมที่อาจตรวจจับผิด ดังนั้นผลลัพธ์ที่ได้จากโมเดลจะช่วยให้ผู้ใช้ได้รับฟีดแบ็กทันทีเกี่ยวกับท่าทางการออกกำลังกาย เช่น มุมของข้อต่อ และการวิเคราะห์ท่าทางผ่านหน้าจอ ซึ่งช่วยให้ผู้ใช้เข้าใจและปรับปรุงการออกกำลังกายได้ดี และลดความเสี่ยงจากการบาดเจ็บ [6]

2.2 การประเมินประสิทธิภาพโมเดล

การประเมินประสิทธิภาพโมเดลโดยใช้การวัดค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision) และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) [14] ซึ่งเป็นค่าที่ได้จากวิธีการทดสอบเพื่อหาค่าพยากรณ์ความถูกต้องของข้อมูลโดยคิดเป็นค่าร้อยละ (%) ดังสมการ

$$Accuracy = \frac{(TP + TN)}{(TN + FN + FP + TP)} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

โดยที่ TP คือค่าพยากรณ์ถูกต้องเชิงบวก TN คือค่าพยากรณ์ถูกต้องเชิงลบ ส่วน FP คือค่าพยากรณ์ผิดพลาดเชิงบวก และ FN คือค่าพยากรณ์ผิดพลาดเชิงลบ

3. ผลการวิจัยและอภิปรายผล

ผลการวิจัยที่นำเสนอในส่วนถัดไปจะประกอบด้วย (1) ผลการประเมินประสิทธิภาพของโมเดล ซึ่งจะวิเคราะห์ความแม่นยำ (Accuracy) และข้อผิดพลาด (Error Rate) ของโมเดลที่พัฒนาขึ้น และ (2) ผลการทดสอบโมเดล ซึ่งจะวิเคราะห์ความสามารถของโมเดลในการทำงานแบบเรียลไทม์ ความเร็วในการประมวลผล และประสบการณ์ของผู้ใช้ที่ได้รับฟีดแบ็กจากโมเดล

3.1 ผลการประเมินประสิทธิภาพโมเดล

ในการพัฒนาโมเดลตรวจจับท่าทางของมนุษย์ (Human Pose Estimation) ประสิทธิภาพของโมเดลเป็นปัจจัยสำคัญที่ส่งผลต่อความแม่นยำในการวิเคราะห์ท่าทางของผู้ใช้ โมเดลที่มีประสิทธิภาพจะต้องสามารถตรวจจับจุดสำคัญของร่างกายได้อย่างถูกต้อง และสามารถจำแนกท่าทางของผู้ใช้งานได้อย่างแม่นยำเพื่อลดข้อผิดพลาด

การประเมินประสิทธิภาพของโมเดลสามารถทำได้โดยใช้ค่าทางสถิติที่สำคัญ ได้แก่ Precision, Recall, และ Accuracy ซึ่งเป็นตัวชี้วัดที่ช่วยให้เข้าใจถึงความสามารถของโมเดลในการจำแนกท่าทางและลดข้อผิดพลาดที่อาจเกิดขึ้น ดังนี้

ตารางที่ 1: ผลการประเมินประสิทธิภาพโมเดล

ค่าประสิทธิภาพ	Precision	Recall	Accuracy
รัศมีข้อศอก	0.75	0.88	0.76
องศาการยก	0.70	0.93	0.76
แกนกลางลำตัว	0.85	0.89	0.83

จากตารางที่ 1 ค่าประสิทธิภาพของการตรวจจับท่าทางการออกกำลังกายโดยใช้ MediaPipe และ OpenCV โมเดลถูกประเมินด้วยค่าทางสถิติที่สำคัญ ซึ่งสามารถอธิบายผลลัพธ์จากการทดสอบโมเดลแบบ Real-time ที่ได้ในแต่ละส่วนดังนี้

3.1.1 รัศมีข้อศอก

โมเดลสามารถระบุการเคลื่อนไหวของข้อศอกได้อย่างแม่นยำประมาณ 75% (Precision = 0.75) ซึ่งหมายความว่ามีโอกาสเกิดข้อผิดพลาดเล็กน้อยที่โมเดลอาจระบุว่าท่าทางถูกต้องในขณะที่จริง ๆ แล้วผิด

โมเดลสามารถตรวจจับท่าทางการเคลื่อนที่ของข้อศอกได้ครบถ้วนถึง 88% (Recall = 0.88) ซึ่งหมายความว่าโมเดลมีความสามารถในการระบุท่าทางการเคลื่อนที่ของข้อศอกได้ดีและพลาดเพียงเล็กน้อย

โมเดลมีความถูกต้องโดยรวมอยู่ที่ 76% (Accuracy = 0.76) แสดงให้เห็นว่าโมเดลสามารถจำแนกท่าทางของข้อศอกได้ดีในระดับปานกลาง

ค่าความแม่นยำของรัศมีข้อศอกแสดงให้เห็นว่าโมเดลสามารถตรวจจับจุดสำคัญของข้อศอกได้ดี แต่ยังคงมีข้อผิดพลาดเล็กน้อยที่ต้องปรับปรุง โดยอาจเกิดจากการเคลื่อนที่ของข้อศอกที่ซับซ้อนและมุมมองของกล้องที่อาจทำให้การจับตำแหน่งผิดพลาด

3.1.2 องศาการยก

โมเดลมีความสามารถในการระบุท่าทางการยกดัมเบลที่ถูกต้อง 70% (Precision = 0.70) ซึ่งยังมีความคลาดเคลื่อนอยู่พอสมควร อาจเกิดจากข้อผิดพลาดในการตรวจจับมุมองศา

โมเดลสามารถตรวจจับการเคลื่อนที่ขององศาการยกได้ดีถึง 93% (Recall = 0.93) แสดงให้เห็นว่าโมเดลสามารถบันทึกและวิเคราะห์ท่าทางได้แทบทั้งหมดโดยไม่พลาดข้อมูลสำคัญ

มีค่าความถูกต้องโดยรวมอยู่ที่ 76% (Accuracy = 0.76) ซึ่งอยู่ในระดับปานกลาง

แม้ว่าโมเดลจะมีค่า Recall สูงถึง 93% แต่ค่า Precision เพียง 70% หมายความว่าโมเดลสามารถตรวจจับท่าทางของการยกได้ครบถ้วนมาก แต่ยังมีข้อผิดพลาดในการแยกแยะว่าท่าทางถูกต้องจริงหรือไม่ ซึ่งอาจเกิดจากความคลาดเคลื่อนในการตรวจจับจุดตำแหน่งของไหล่และข้อศอก

3.1.3 แกนกลางลำตัว

โมเดลมีความสามารถในการระบุท่าทางของแกนกลางลำตัวได้อย่างแม่นยำที่ 85% (Precision = 0.85) ซึ่งถือว่าสูงเมื่อเทียบกับพารามิเตอร์อื่น ๆ

โมเดลสามารถตรวจจับการเคลื่อนไหวของแกนกลางลำตัวได้ถึง 89% (Recall = 0.89) แสดงให้เห็นว่ามีโอกาสพลาดการตรวจจับน้อย

โมเดลมีค่าความถูกต้องโดยรวมสูงสุดเมื่อเทียบกับพารามิเตอร์อื่น ๆ ที่ 83% (Accuracy = 0.83)

ผลลัพธ์ที่ได้แสดงให้เห็นว่าโมเดลสามารถจับตำแหน่งและตรวจสอบความมั่นคงของแกนกลางลำตัวได้ดี เนื่องจากการเคลื่อนไหวของแกนกลางลำตัวมักเป็นแบบคงที่และมีความเปลี่ยนแปลงน้อยเมื่อเทียบกับข้อศอกและองศาการยก การที่ค่า Precision และ Recall สูงในระดับใกล้เคียงกัน หมายความว่าโมเดลสามารถจำแนกท่าทางได้แม่นยำและลดโอกาสเกิดข้อผิดพลาดได้ดี

3.2 ผลการทดสอบโมเดลแบบ Real-time

ในขั้นตอนนี้จะเป็นการทดสอบโมเดลการตรวจจับท่าทางของมนุษย์โดยใช้อัลกอริทึมที่ได้ศึกษาและเลือกใช้งานจากขั้นตอนก่อนหน้านี้ การทดสอบจะเน้นที่ความสามารถของโมเดลในการตรวจจับจุดสำคัญของร่างกายได้อย่างแม่นยำและรวดเร็ว โดยใช้ภาพจากกล้องเว็บแคมหรือวิดีโอแบบเรียลไทม์ โมเดลต้องสามารถประมวลผลและแสดงผลตำแหน่งของจุดสำคัญได้อย่างต่อเนื่อง เพื่อให้มั่นใจว่าการตรวจจับท่าทางนั้นเป็นไปตามความต้องการและเหมาะสมสำหรับการประเมินท่าทางการออกกำลังกาย นอกจากนั้นโมเดลจะแจ้งให้ทราบว่าในแต่ละครั้งยกดัมเบลถูกต้องหรือไม่ พร้อมทั้งแจ้งว่าควรจะต้องทำอย่างไรเพื่อให้ยกได้ถูกต้อง ดังภาพตัวอย่างดังนี้

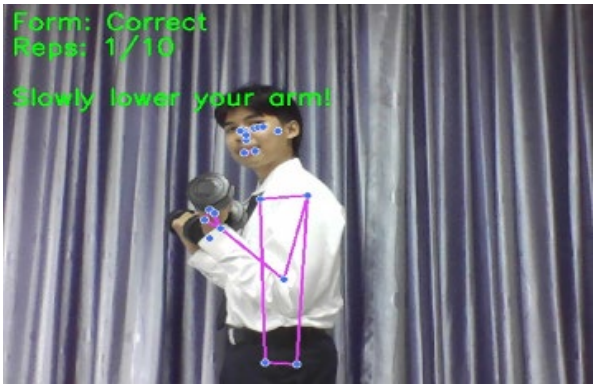

(ก) ภาพทดสอบผู้ชาย

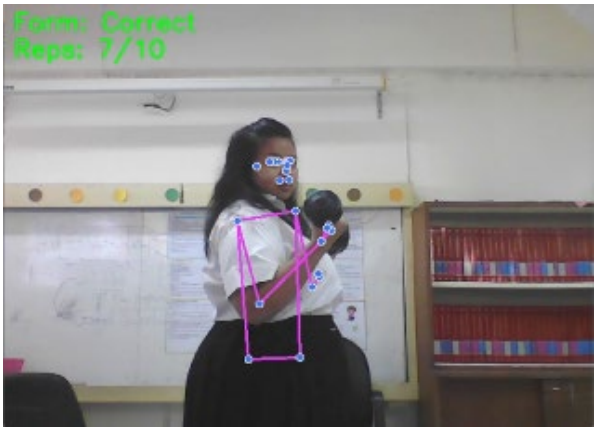

(ข) ภาพทดสอบผู้หญิง

ภาพที่ 1: ภาพตัวอย่างการทดสอบโมเดลแบบ Real-time

เพื่อประเมินประสิทธิภาพของโมเดลตรวจจับท่าทางการออกกำลังกาย การทดสอบได้ดำเนินการกับผู้เข้าร่วมทดลองจำนวน 10 คน โดยให้ทำท่า Dumbbell Biceps Curl จำนวน 10 ครั้งต่อคน รวมทั้งหมด 100 ครั้ง โมเดลได้ทำการตรวจจับและวิเคราะห์ท่าทางโดยพิจารณาปัจจัยสำคัญ ได้แก่ องศาของข้อศอก, องศาการยกดัมเบล และความสมดุลของแกนกลางร่างกาย สามารถแสดงผลลัพธ์จากตาราง Confusion Matrix ที่ใช้ในการทดสอบได้ตารางที่ 2

ตารางที่ 2: ผลการทดสอบด้วย Confusion Matrix

	TP	FP	FN	TN
รัศมีข้อศอก	30	10	4	16
องศาการยก	28	12	2	18
แกนกลางลำตัว	34	6	4	16

3.2.1 การทดสอบรัศมีข้อศอก

TP (30 ครั้ง) แสดงว่าโมเดลสามารถจำแนกท่าทางที่ถูกต้องของข้อศอกได้ 30 ครั้ง

FP (10 ครั้ง) หมายความว่าโมเดลมีข้อผิดพลาดโดยจำแนกท่าผิดพลาดว่าเป็นท่าที่ถูกต้อง 10 ครั้ง

FN (4 ครั้ง) หมายความว่าโมเดลพลาดการตรวจจับท่าที่ถูกต้อง 4 ครั้ง

TN (16 ครั้ง) แสดงว่าโมเดลสามารถระบุท่าทางที่ผิดได้ถูกต้อง 16 ครั้ง

โมเดลมีแนวโน้มที่จะเกิด False Positive สูง ซึ่งหมายความว่าในบางกรณี โมเดลอาจระบุว่าผู้ใช้ทำท่าทางได้ถูกต้องแม้ว่าจะผิดพลาด ซึ่งอาจเกิดจากการตรวจจับองศาการเคลื่อนไหวของข้อศอกที่ไม่แม่นยำพอ

3.2.2 การทดสอบองศาการยกดัมเบล

TP (28 ครั้ง) หมายถึงโมเดลสามารถจำแนกท่าการยกดัมเบลได้ถูกต้อง 28 ครั้ง

FP (12 ครั้ง) แสดงให้เห็นว่าโมเดลมีข้อผิดพลาดในการระบุท่าผิดว่าเป็นท่าที่ถูกต้อง 12 ครั้ง

FN (2 ครั้ง) หมายความว่าโมเดลพลาดการตรวจจับท่าที่ถูกต้องเพียง 2 ครั้ง

TN (18 ครั้ง) แสดงว่าโมเดลสามารถแยกแยะท่าผิดได้อย่างถูกต้อง 18 ครั้ง

ค่าของ False Positive สูงกว่า False Negative แสดงให้เห็นว่าโมเดลมีแนวโน้มที่จะอนุญาตให้ท่าทางผิดผ่านการตรวจสอบ ซึ่งอาจเกิดจากข้อจำกัดของมุมมองกล้อง หรือค่ามาตรฐานที่ใช้พิจารณาองศาการยกอาจมีช่วงความคลาดเคลื่อนสูง

3.2.3 การทดสอบแกนกลางลำตัว

TP (34 ครั้ง) โมเดลสามารถจำแนกท่าทางที่ถูกต้องของแกนกลางลำตัวได้มากถึง 34 ครั้ง

FP (6 ครั้ง) แสดงให้เห็นว่าโมเดลมีข้อผิดพลาดต่ำในการระบุท่าผิดว่าเป็นท่าที่ถูกต้อง

FN (4 ครั้ง) หมายความว่าโมเดลพลาดการตรวจจับท่าที่ถูกต้อง 4 ครั้ง

TN (16 ครั้ง) แสดงว่าโมเดลสามารถระบุท่าทางที่ผิดได้ถูกต้อง 16 ครั้ง

การตรวจจับความสมดุลของแกนกลางลำตัวมีค่าความถูกต้องโดยรวมสูง เนื่องจากมี False Positive และ False Negative ต่ำที่สุด เมื่อเทียบกับการตรวจจับรัศมีข้อศอกและองศาการยก

โดยสรุป โมเดลสามารถตรวจจับและจำแนกท่าทางได้อย่างแม่นยำ โดยให้ฟีดแบ็กแก่ผู้ใช้แบบเรียลไทม์ การประเมินผลลัพธ์ของแต่ละการยกพิจารณาจากเฟรมทั้งหมดที่เกี่ยวข้อง โดยใช้หลักการ Majority Voting และ ค่าเฉลี่ยของเฟรมล่าสุด เพื่อให้ผลลัพธ์มีความแม่นยำและเสถียร ลดโอกาสเกิดข้อผิดพลาดจากเฟรมเดี่ยวที่อาจมี Noise หรือความผิดพลาดในการตรวจจับ ผลการทดสอบแสดงให้เห็นว่าโมเดลสามารถใช้งานได้จริง และมีประสิทธิภาพดี โดยเฉพาะในส่วนของการตรวจจับแกนกลางลำตัว นอกจากนั้นการวิจัยในครั้งนี้ยังได้ให้ผู้เชี่ยวชาญทางด้านวิทยาศาสตร์การกีฬาได้ทดสอบและประเมินประสิทธิภาพของโมเดลผลการประเมินพบว่า โมเดลสามารถทำนายได้อย่างถูกต้องและแม่นยำ

แม้ว่าโมเดลสามารถตรวจจับและประเมินท่าทางของผู้ใช้ได้อย่างแม่นยำ แต่ยังคงมีข้อจำกัดที่ต้องพิจารณา ได้แก่

- แสงสว่างของสภาพแวดล้อมต้องเพียงพอ เนื่องจากหากแสงน้อยอาจส่งผลต่อการตรวจจับจุดสำคัญของร่างกาย
- ผู้ใช้ไม่ควรสวมเสื้อแขนยาวหรือเสื้อที่มีสีใกล้เคียงกับพื้นหลัง เพราะอาจทำให้โมเดลไม่สามารถตรวจจับข้อศอกได้
- กล้องควรวางในระดับหน้าอกหรือไหล่ของผู้ใช้ ห่างออกไปประมาณ 1.5 - 2 เมตร และอยู่ในตำแหน่งด้านข้างหรือด้านหน้า เพื่อให้สามารถวิเคราะห์ท่าทางได้อย่างถูกต้อง

ผลการพัฒนาโมเดลตรวจจับและประเมินท่าทางการออกกำลังกายโดยใช้ MediaPipe และ OpenCV แสดงให้เห็นว่าสามารถตรวจจับความถูกต้องของท่าทางได้อย่างแม่นยำ โดยอาศัยปัจจัยหลัก ได้แก่ รัศมีข้อศอก, องศาการยกดัมเบล และแกนกลางลำตัว โมเดลสามารถให้ฟีดแบ็กแบบเรียลไทม์แก่ผู้ใช้ และช่วยปรับปรุงท่าทางเพื่อเพิ่มประสิทธิภาพของการฝึกซ้อมและลดความเสี่ยงจากการบาดเจ็บ ผลการศึกษานี้มีความสอดคล้องกับงานวิจัยที่เกี่ยวข้องหลายฉบับ ซึ่งสนับสนุนว่าเทคโนโลยีการตรวจจับท่าทางสามารถนำมาใช้เพื่อเพิ่มความแม่นยำในการออกกำลังกายได้อย่างมีประสิทธิภาพ ดังเช่น งานวิจัยของ Kwon และ Kim [4] ซึ่งใช้ OpenCV และ MediaPipe เพื่อตรวจจับและให้คำแนะนำเกี่ยวกับการออกกำลังกาย พบว่าโมเดลสามารถให้ฟีดแบ็กแบบเรียลไทม์เกี่ยวกับท่าทางของผู้ใช้ ซึ่งช่วยให้ผู้ฝึกสามารถปรับปรุงท่าทางได้ทันที ผลการศึกษาของเราสอดคล้องกับงานวิจัยดังกล่าว โดยพบว่าโมเดลสามารถตรวจจับความถูกต้องของท่าทาง เช่น องศาข้อศอก และองศาการยกดัมเบลได้อย่างมีประสิทธิภาพ นอกจากนี้ การที่โมเดลสามารถประเมินเสถียรภาพของแกนกลางลำตัวได้อย่างแม่นยำ ยังช่วยเสริมสร้างความปลอดภัยในการฝึกซ้อม หรือจะเป็นการศึกษาของ Chaudhary et al. (2023) [10] ได้นำเสนอการใช้ OpenCV และ MediaPipe ในการตรวจจับท่าโยคะแบบเรียลไทม์ โดยโมเดลสามารถวิเคราะห์การเคลื่อนไหวของผู้ฝึก และให้ฟีดแบ็กเกี่ยวกับท่าทางที่ถูกต้อง ซึ่งช่วยให้สามารถปรับปรุงการฝึกโยคะได้ดียิ่งขึ้น ผลการวิจัยของเราแสดงให้เห็นว่าหลักการเดียวกันสามารถนำมาใช้กับการยกดัมเบลได้ โดยสามารถวิเคราะห์มุมของข้อต่อต่าง ๆ และแสดงผลลัพธ์การตรวจจับได้แบบเรียลไทม์ ซึ่งช่วยให้ผู้ใช้สามารถปรับปรุง

ท่าทางการฝึกซ้อมได้อย่างแม่นยำ นอกจากนั้นงานวิจัยของ Lee et al. (2021) [15] ได้แสดงให้เห็นว่า MediaPipe สามารถตรวจจับจุดสำคัญบนร่างกายได้อย่างมีประสิทธิภาพ ซึ่งสามารถนำไปใช้ในการวิเคราะห์ท่าทางของมนุษย์ในแอปพลิเคชันที่หลากหลาย รวมถึงฟิตเนส ผลการทดลองของเรายืนยันว่าเทคนิคเดียวกันสามารถนำมาใช้กับการตรวจจับท่าทางการออกกำลังกายได้ โดยเฉพาะอย่างยิ่งในการระบุข้อต่อสำคัญ เช่น ข้อศอกและไหล่ เพื่อคำนวณองศาการเคลื่อนไหวที่เหมาะสม และการศึกษาของ Patel, Shah and Mehta (2022) [16] ที่ใช้การตรวจจับท่าทางเพื่อช่วยให้ผู้ฝึกสามารถเรียนรู้และปรับปรุงท่าทางการออกกำลังกายด้วยตนเอง พบว่าโมเดลที่ให้ฟีดแบ็กแบบเรียลไทม์สามารถช่วยเพิ่มความถูกต้องของการฝึกซ้อมได้ดีขึ้น งานวิจัยของเราสนับสนุนข้อค้นพบนี้ โดยการนำเสนอค่ามุมข้อศอกและมุมการยกดัมเบลแบบเรียลไทม์ ช่วยให้ผู้ใช้สามารถสังเกตและแก้ไขท่าทางได้ทันที ซึ่งช่วยเพิ่มประสิทธิภาพในการฝึกซ้อม

4. สรุปผล

การศึกษานี้มีเป้าหมายในการพัฒนาและประเมินโมเดลตรวจจับท่าทางการออกกำลังกาย Dumbbell Biceps Curl โดยใช้เทคโนโลยี MediaPipe และ OpenCV เพื่อช่วยให้ผู้ใช้สามารถตรวจสอบและปรับปรุงท่าทางการออกกำลังกายได้แบบเรียลไทม์ โมเดลถูกออกแบบให้สามารถตรวจจับและคำนวณค่าต่าง ๆ ที่สำคัญ ได้แก่ รัศมีข้อศอก, องศาการยกดัมเบล และแกนกลางลำตัว ซึ่งได้รับการกำหนดจากคำแนะนำของผู้เชี่ยวชาญด้านวิทยาศาสตร์การกีฬา ผลการทดสอบประสิทธิภาพของโมเดลการตรวจจับท่าทาง พบว่า โมเดลสามารถตรวจจับและจำแนกท่าทางของผู้ใช้ได้อย่างแม่นยำ โดยมีค่า Precision, Recall และ Accuracy ในระดับที่ดี โดยการตรวจจับแกนกลางลำตัวมีความแม่นยำสูงสุด ซึ่งมีค่า Accuracy ที่ 83% แสดงให้เห็นว่าโมเดลสามารถตรวจสอบความสมดุลของร่างกายได้ดี การตรวจจับองศาการยกดัมเบลมีค่า Recall สูงสุดที่ 93% แสดงให้เห็นว่าโมเดลสามารถตรวจจับการเคลื่อนไหวของผู้ใช้ได้ครบถ้วน และการตรวจจับรัศมีข้อศอกมีค่า Precision ที่ 75% ซึ่งหมายความว่าโมเดลสามารถแยกแยะการเคลื่อนไหวของข้อศอกได้ดี แต่ยังต้องปรับปรุงเพื่อลดข้อผิดพลาด False Positive

ผลการทดสอบโมเดล พบว่าการทดสอบโมเดลกับผู้เข้าร่วมทดลอง 10 คน ที่ทำการยกดัมเบล 10 ครั้งต่อคน แสดงให้เห็นว่า โมเดลสามารถจำแนกท่าทางที่ถูกต้องและผิดพลาดได้อย่างแม่นยำ จาก ตาราง Confusion Matrix พบว่าโมเดลสามารถระบุข้อผิดพลาดของท่าทางการออกกำลังกายได้อย่างชัดเจน และสามารถให้ฟีดแบ็กแก่ผู้ใช้แบบเรียลไทม์ ซึ่งค่าทางสถิติแสดงให้เห็นว่าโมเดลสามารถตรวจจับและจำแนกท่าทางได้ดี โดยเฉพาะการวิเคราะห์เสถียรภาพของแกนกลางลำตัว ซึ่งเป็นปัจจัยสำคัญในการออกกำลังกายที่ปลอดภัย

สำหรับข้อเสนอแนะเพื่อการพัฒนาในอนาคตนั้น ควรปรับปรุงโมเดลการตรวจจับ โดยใช้เทคนิค Deep Learning หรือ Neural Networks เพื่อเพิ่มความแม่นยำของการจำแนกท่าทาง พร้อมทั้งเพิ่มชุดข้อมูลฝึกสอนโมเดล ให้ครอบคลุมกลุ่มผู้ใช้งานที่มีลักษณะทางกายภาพที่หลากหลาย เช่น ความสูง ขนาดร่างกาย และช่วงการเคลื่อนไหวที่แตกต่างกัน และพัฒนาแอปพลิเคชันสำหรับการใช้งานจริง ที่สามารถนำไปใช้ในฟิตเนสและการออกกำลังกายที่บ้าน โดยให้คำแนะนำแบบเรียลไทม์ผ่านอุปกรณ์พกพา นอกจากนั้นควรขยายขอบเขตการตรวจจับท่าทางในรูปแบบอื่น ๆ เช่น การฝึกกีฬาประเภทต่าง ๆ หรือการทำกายภาพบำบัด

5. เอกสารอ้างอิง

[1] ดวงพงศ์ พงศ์สยาม. การออกกำลังกายเพื่อสุขภาพที่ดี. วารสารวิชาการปทุมวัน, 2555; 2(3):68-73.

[2] Supanich W., Kulkarineetham S., Sukphokha P. and Wisarnsart P. Machine learning-based exercise posture recognition system using MediaPipe pose estimation. In: 9th International Conference on Advanced Computing and Communication Systems (ICACCS), 2023; 203-207.

[3] Alareeni B. and Elgedawy I. Insightful fitness: shaping the exercises of tomorrow using MediaPipe. In: Opportunities and risks in AI for business development, 2024; 325-333.

[4] Kwon Y., and Kim D. Real-time workout posture correction using OpenCV and MediaPipe. J Korean Inst Inf Technol. 2022; 20(1):199-208.

[5] Jain A. K., Kumar P. R. and Chauhan M. S. AI-powered fitness coaching: Motion tracking and pose correction using CNNs. In: Proceedings of the IEEE International Conference on Machine Learning Applications, 2019; 115-123.

[6] สิทธิศักดิ์ ทิโน. การพัฒนาโปรแกรมเพื่อตรวจจับทิศทางใบหน้าและสถานะดวงตาที่ถูกปิดบางส่วน. วิทยานิพนธ์ วศ.ม. วิศวกรรมคอมพิวเตอร์, มหาวิทยาลัยนเรศวร, 2565.

[7] พิญญศิกานต์ วงศ์เกียรติ์ขจร และวีระ สะอิ้ง. การประมาณการณ์ท่วงท่าเพื่อตรวจจับการล้มในบ้านด้วยการใช้มีเดียไปป์. ใน การประชุมวิชาการด้านวิทยาการข้อมูล, มหาวิทยาลัยศรีนครินทรวิโรฒ, 2566; 315-333.

[8] Zhang X., Wang Y. and Li L. Pose Estimation for Exercise Monitoring Using Deep Learning. IEEE Transactions on Neural Networks and Learning Systems, 2021; 32(5):1524-1535.

[9] Mooney M., O'Connor R. C. and Whelan P. F. Real-time motion analysis for injury prevention in strength training. Journal of Sports Science & Medicine, 2020; 19(3):452-467.

[10] Chaudhary I. Singh N. T., Chaudhary M. and Yadav K. Real-time yoga pose detection using OpenCV and

MediaPipe. In: Proceedings of the 2023 4th International Conference for Emerging Technology (INCET), 2023; 1-5.

[11] ภูรินทร์ วงค์สวัสดิ์. ระบบตรวจจับการยกดัมเบล (Dumbbell Lift Detection). [25 มกราคม 2568]. เข้าถึงได้จาก: https://dp.rmutsv.ac.th/?p=2980

[12] นัท กุลวานิช และอัครินทร์ ไพบูลย์พานิช. การเปรียบเทียบมาตรวัดระยะห่างในการวิเคราะห์การจัดกลุ่มสำหรับข้อมูลอนุกรมเวลา. วารสารวิทยาศาสตร์และเทคโนโลยี, 2562; 27(6):1002-1014.

[13] Rasul A. K. 97.26 The cosine rule in three dimensions and de Gua's theorem. The Mathematical Gazette, 2013; 97(539):281-284.

[14] Malta A, Mendes M and Farinha T. Augmented reality maintenance assistant using YOLOv5. Applied Sciences 2021; 11(11):475.

[15] Lee C., Park S., Kim J. Human Pose Estimation using MediaPipe for Fitness Applications. IEEE Transactions on Image Processing, 2021; 30: 2180-2192.

[16] Patel R., Shah K. and Mehta A. Self-Guided Exercise Form Correction using Pose Estimation. International Conference on Artificial Intelligence and Smart Systems (ICAISS), 2022; 198-205.

ระบบรู้จำใบหน้าเพื่อยืนยันตัวของนักศึกษาในการเข้าเรียนของสาขาวิชานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ

Facial Recognition System for Student Identification in the Department of Learning Innovation and Information Technology

นวพรรษ จันทร์คำ ก้องกิดากร สุวรรณผ่อง ธีรทีป ส้มฉุน อลงกรณ์ เทพรักษา มธุรส ผ่านเมือง*

ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

(**mathuros_p@rmutt.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึม OpenCV และ YOLOv8 ในการพัฒนาระบบรู้จำใบหน้า ซึ่งเป็นเครื่องมือสำคัญในงานด้านการตรวจสอบตัวตน เช่น การเช็คชื่อเข้าเรียนและการรักษาความปลอดภัย กระบวนการวิจัยเริ่มต้นด้วยการเตรียมข้อมูลใบหน้าผ่านการปรับแต่งและเพิ่มข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายของชุดข้อมูล ทำให้ได้ชุดข้อมูลภาพจำนวน 6,600 แบ่งออกเป็นชุดข้อมูลในการฝึกสอน (Train) จำนวน 5,280 ภาพ ชุดข้อมูลทดสอบ (Test) จำนวน 1,320 ภาพ หรือคิดเป็น 80:20 จากนั้นสร้างโมเดลด้วย OpenCV และ YOLOv8 และทดสอบประสิทธิภาพโดยใช้ตัวชี้วัด ได้แก่ ค่าความถูกต้อง (Accuracy), ความแม่นยำ (Precision), และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) ผลการวิจัยพบว่า OpenCV มีประสิทธิภาพสูงกว่า YOLOv8 อย่างมีนัยสำคัญในทุกตัวชี้วัด โดย OpenCV มีค่า Accuracy ร้อยละ 83.33, Precision ร้อยละ 75.00 และ Recall ร้อยละ 83.33 ขณะที่ YOLOv8 มีค่า Accuracy ร้อยละ 0.06, Precision ร้อยละ 0.68 และ Recall ร้อยละ 0.07 ด้วยความแม่นยำที่สูงกว่า OpenCV จึงถูกเลือกไปใช้ในการพัฒนาระบบเช็คชื่อเข้าเรียน เมื่อตรวจจับใบหน้าได้ ระบบจะส่งข้อมูลนักศึกษาพร้อมเวลาเข้าเรียนไปยัง Google Sheets เพื่อบันทึกเวลาเข้าเรียนโดยอัตโนมัติ ผลการวิจัยนี้ชี้ให้เห็นว่า OpenCV เป็นตัวเลือกที่เหมาะสมสำหรับการพัฒนาระบบรู้จำใบหน้าในบริบทที่ต้องการความแม่นยำสูง

คำสำคัญ: ระบบรู้จำใบหน้า, การประมวลผลภาพ, การเช็คชื่อเข้าเรียน, OpenCV, YOLOv8

Abstract

The purpose of this study is to evaluate how well the OpenCV and YOLOv8 algorithms work while creating a face recognition system, which is an essential tool for identity verification applications like security and attendance monitoring. In order to increase dataset variety, the study method started with preprocessing and augmentation of the facial data, yielding 6,600 photos in total. Following an 80:20 ratio, the dataset was divided into a test set of 1,320 photos and a training set of 5,280 images. Following that, models were created with OpenCV and YOLOv8 and assessed using accuracy, precision, and recall as important performance measures. The findings showed that OpenCV performed noticeably better than YOLOv8 on every metric. In contrast to YOLOv8, which only recorded accuracy of 0.06%, precision of 0.68%, and recall of 0.07%, OpenCV obtained accuracy of 83.33%, precision of 75.00%, and recall of 83.33%. OpenCV was selected for the creation of an automated attendance monitoring system because of its exceptional accuracy. The system instantly uploads the student's data and the attendance timestamp to Google Sheets for real-time record-keeping as soon as it detects a student's face. According to these results, OpenCV is a better choice for developing facial recognition systems for applications requiring high accuracy.

Keywords: Face Recognition, Image Processing, Attendance Tracking, OpenCV, YOLOv8

1. บทนำ

การเรียนการสอนในแต่ละคาบเรียนนั้น ผู้สอนมีการตรวจสอบการเข้าชั้นเรียนของนักศึกษาซึ่งเป็นกิจกรรมหนึ่งในชั้นเรียนเพื่อเป็นการเตรียมความพร้อมในการเรียนและเพื่อตรวจสอบนับเวลาเรียนของนักศึกษาตามข้อบังคับการจัดการศึกษาของสถาบัน ในอดีต การยืนยันตัวตนของบุคคลมักอาศัยวิธีการแบบดั้งเดิม เช่น การใช้บัตรประจำตัว การลงลายมือชื่อ หรือการแจ้งรหัสผ่าน ซึ่งแม้ว่าวิธีเหล่านี้จะมีประสิทธิภาพในระดับหนึ่ง แต่ก็มีข้อจำกัดในเรื่องของความปลอดภัยและความสะดวกในการใช้งาน ตัวอย่างเช่น บัตรประจำตัวอาจสูญหายหรือถูกปลอมแปลงได้ ขณะที่การลงลายมือชื่อหรือรหัสผ่านอาจถูกใช้โดยบุคคลอื่นโดยมิชอบด้วยเหตุนี้ การพัฒนาเทคโนโลยีดิจิทัลจึงเข้ามามีบทบาทสำคัญในการปรับปรุงระบบการยืนยันตัวตน โดยเฉพาะการใช้ข้อมูลชีวมิติ (Biometric Identification) ซึ่งได้รับการยอมรับว่าเป็นวิธีที่ปลอดภัยและเชื่อถือได้มากขึ้น [1] เทคโนโลยีชีวมิติ เช่น การสแกนลายนิ้วมือ การจดจำเสียง และการจดจำใบหน้า ได้รับการพัฒนาเพื่อลดข้อจำกัดของระบบแบบเดิม และเพิ่มความสะดวกในการใช้งาน [2] ในภาคการศึกษา วิธีการยืนยันตัวตนแบบชีวมิติมีความสำคัญอย่างยิ่งต่อการตรวจสอบการเข้าเรียนของนักศึกษา เนื่องจากช่วยลดปัญหาการสวมสิทธิ์และเพิ่มความถูกต้องในการเช็คชื่อ [3]

ในช่วงไม่กี่ปีที่ผ่านมา เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) ได้รับการพัฒนาอย่างรวดเร็วและถูกนำมาใช้ในหลายภาคส่วน รวมถึงด้านการศึกษา หนึ่งในเทคโนโลยีที่ได้รับความสนใจมากขึ้นคือระบบการจดจำใบหน้า (Facial Recognition) ซึ่งสามารถใช้เพื่อยืนยันตัวตนของบุคคลได้อย่างแม่นยำ เทคโนโลยีนี้ทำงานโดยการสแกนและวิเคราะห์คุณลักษณะเฉพาะของใบหน้า เช่น รูปทรงของดวงตา จมูก และปาก ก่อนนำไปเปรียบเทียบกับฐานข้อมูลที่บันทึกไว้ [4] ระบบจดจำใบหน้าไม่เพียงช่วยเพิ่มความปลอดภัย แต่ยังช่วยลดเวลาในการดำเนินการ เนื่องจากสามารถตรวจสอบและยืนยันตัวตนได้ในเวลาเพียงไม่กี่วินาที [5] ในสถาบันการศึกษา เทคโนโลยีนี้สามารถนำมาใช้ในการเช็คชื่อเข้าเรียนของนักศึกษาโดยอัตโนมัติ ซึ่งช่วยลดภาระของอาจารย์และบุคลากร รวมถึงป้องกันปัญหาการสวมสิทธิ์เข้าเรียนของนักศึกษาที่ไม่ได้เข้าชั้นเรียนจริง [6]

นอกจากนั้น ระบบการจดจำใบหน้าที่ขับเคลื่อนด้วย AI ยังสามารถทำงานได้แม้ในสภาพแวดล้อมที่มีแสงน้อย หรือเมื่อมีการเปลี่ยนแปลงลักษณะใบหน้าของบุคคล เช่น การสวมแว่นตาหรือเปลี่ยนทรงผม ซึ่งเป็นจุดเด่นที่ทำให้เทคโนโลยีนี้มีประสิทธิภาพมากกว่าระบบยืนยันตัวตนแบบเดิม [7] อีกทั้งยังสามารถบูรณาการเข้ากับแพลตฟอร์มการเรียนรู้ออนไลน์เพื่อช่วยตรวจสอบตัวตนของนักศึกษาในการสอบออนไลน์หรือการเข้าร่วมการเรียนแบบเสมือนจริง ซึ่งเป็นประโยชน์อย่างมากในยุคที่การศึกษาออนไลน์ได้รับความนิยมมากขึ้น [8]

ดังนั้น งานวิจัยนี้จึงได้พัฒนาระบบรู้จำใบหน้าเพื่อยืนยันตัวของนักศึกษาในการเข้าเรียนของสาขาวิชานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ จากภาพใบหน้าด้วยอัลกอริทึม OpenCV ทั้งนี้เพื่ออำนวยความสะดวกแก่ผู้สอนหรือผู้ควบคุมกิจกรรม และเพื่อเพิ่มความถูกต้องของการบันทึกการเข้าร่วมกิจกรรมในชั้นเรียนมากขึ้น

2. วิธีการวิจัย

2.1 การเก็บรวบรวมข้อมูล

ชุดข้อมูลที่ใช้ในการวิจัยครั้งนี้ ได้แก่ รูปภาพนักศึกษา จำนวน 6,600 ภาพ จากนักศึกษาที่เป็นกลุ่มตัวอย่าง จำนวน 33 คน (1 กลุ่มเรียน) โดยจะเก็บ 1 คน ต่อ 200 ภาพ ซึ่งใน 200 ภาพจะเป็นการถ่ายคลิปวิดีโอในหลากหลายมุม โดยจะบันทึกภาพในพื้นที่ที่มีแสงสว่างแตกต่างกันออกไป แต่ทั้งนี้จะต้องมีพื้นหลังไม่ซับซ้อน เช่น หน้าตรง ด้านซ้าย ด้านขวา แสงจ้า แสงสว่างน้อย เป็นต้น เมื่อได้คลิปวิดีโอจะนำไปประมวลผลเพื่อตัดต่อออกมาเป็นภาพนิ่งตามจำนวนที่กำหนดไว้ และแยกเป็นชุดข้อมูลในการฝึกสอน (Train) จำนวน 5,280 ภาพ ชุดข้อมูลทดสอบ (Test) จำนวน 1,320 ภาพ หรือคิดเป็น 80:20

ภาพที่1: ตัวอย่างการเก็บข้อมูลใบหน้า

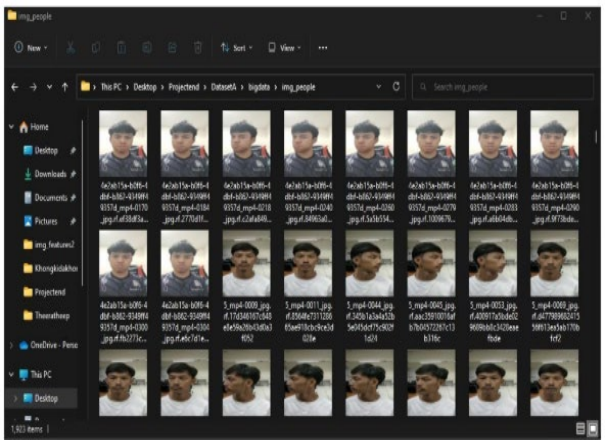

(ก)

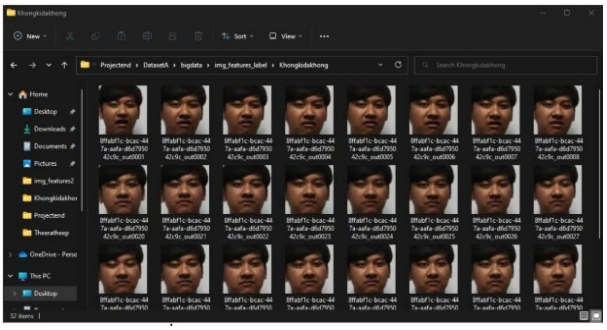

(ข)

ภาพที่ 2: ตัวอย่างชุดข้อมูลรูปภาพ

2.2 การสร้างโมเดลรู้จำใบหน้า

ในการวิจัยครั้งนี้ได้ใช้อัลกอริทึม OpenCV (Open Source Computer Vision) ซึ่งเป็นไลบรารีฟังก์ชันสำหรับการประมวลผลภาพแบบโอเพนซอร์สที่ได้รับความนิยมอย่างแพร่หลาย โดย OpenCV ถูกนำมาใช้ในงานด้านการประมวลผลภาพ (Image Processing) และการรู้จำใบหน้า (Face Recognition) โดยเฉพาะอย่างยิ่งในการตรวจจับและจดจำลักษณะเฉพาะของใบหน้าผ่านอัลกอริทึมที่มีประสิทธิภาพสูง [9] ระบบรู้จำใบหน้าอาศัยโมเดลการเรียนรู้ของเครื่องเพื่อระบุและจับคู่ใบหน้าของบุคคลโดยอ้างอิงจากคุณลักษณะเฉพาะ (Facial Features) ซึ่งเป็นเทคนิคที่ได้รับการพัฒนาอย่างต่อเนื่องในช่วงไม่กี่ปีที่ผ่านมา [10]

การนำ OpenCV มาเรียนรู้เพื่อทำให้ระบบสามารถตรวจจับใบหน้าได้แบบเรียลไทม์ (Real-Time Face Recognition) โดยใช้โมเดลที่ได้รับการฝึกสอนบนชุดข้อมูลภาพใบหน้าจำนวนมากเพื่อให้สามารถเรียนรู้โครงสร้างและลักษณะเฉพาะของใบหน้าได้อย่างแม่นยำ ระบบนี้สามารถทำงานได้อย่างรวดเร็วและมีความแม่นยำสูงในการแยกแยะใบหน้าของแต่ละบุคคล ลดปัญหาการจดจำผิดพลาด และสามารถนำไปใช้ในการตรวจสอบตัวตนของนักศึกษาได้อย่างมีประสิทธิภาพ [11] OpenCV ใช้อัลกอริทึมพื้นฐานต่าง ๆ ในการตรวจจับใบหน้าและวัตถุ เช่น Haar Cascade และ HOG (Histogram of Oriented Gradients) โดยสมการหลักที่เกี่ยวข้องมีดังนี้

Haar Cascade Classifier ใช้คุณสมบัติ Haar-like ในการตรวจจับวัตถุ โดยสมการพื้นฐานสำหรับการคำนวณฟีเจอร์ Haar คือ [12]

$$f(x) = \sum_{pixels\ in\ white} Intensity - \sum_{pixels\ in\ black} Intensity \quad (1)$$

โดย *Intensity* คือค่าความสว่างของพิกเซล ส่วนฟีเจอร์ Haar จะคำนวณจากผลรวมของค่าความเข้มแสงในบริเวณสีขาวและดำ

Haar Cascade ใช้อัลกอริทึม AdaBoost เพื่อสร้าง Cascade Classifier ซึ่งเป็นชุดของ Weak Classifiers ที่ถูกฝึกเพื่อกรองภาพที่ไม่ใช่ใบหน้าออกในขั้นตอนเบื้องต้น

HOG (Histogram of Oriented Gradients) ใช้การคำนวณกราฟทิศทางของ Gradient เพื่อหาคุณลักษณะของภาพ [13] ดังสมการ

$$G_x = I(x+1, y) - I(x-1, y),\ G_y = I(x, y+1) - I(x, y-1) \quad (2)$$

$$Magnitude = \sqrt{(G_x^2 + G_y^2)},\ Orientation = arctan\left(\frac{G_y}{G_x}\right)$$

โดย G_x และ G_y คือ Gradient ในแนวนอนและแนวตั้ง ส่วน *Magnitude* แสดงถึงความเข้มของ Gradient และ *Orientation* แสดงถึงทิศทางของ Gradient

โดยสรุป ในการใช้ OpenCV มีไลบรารี ที่เกี่ยวข้อง ได้แก่ Haar Cascade Classifier ใช้ในการตรวจจับใบหน้าในภาพ, Local Binary Patterns Histograms (LBPH) ใช้เพื่อดึงคุณลักษณะเชิงพื้นผิวของใบหน้า และ HOG ใช้เพื่อดึงคุณลักษณะ (Feature Extraction) จากภาพ

นอกจากนั้นในการวิจัยครั้งนี้จะใช้โมเดล YOLOv8 (You Only Look Once v8) ซึ่งเป็นโมเดลตรวจจับวัตถุแบบเรียลไทม์ที่มีประสิทธิภาพสูง YOLOv8 สามารถตรวจจับใบหน้าได้อย่างรวดเร็วและแม่นยำมากขึ้นเมื่อเทียบกับ CNN ทั่วไป [14] ซึ่งจะนำมาทดสอบในการวิจัยครั้งนี้ร่วมกับโมเดล OpenCV หากโมเดลใดมีค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) และ Recall สูงกว่า รวมถึงสามารถทำงานได้ดีในสถานการณ์จริง จะนำโมเดลนั้นไปใช้ในการพัฒนาระบบรู้จำใบหน้าต่อไป

YOLOv8 จะใช้อัลกอริทึม Regression ในการระบุตำแหน่งของกล่องล้อมรอบวัตถุ (Bounding Box) และการจำแนกประเภทวัตถุในภาพ ในการกำหนดค่า Hyperparameter นั้นจะใช้ค่าเริ่มต้น ได้แก่ ค่า Learning Rate = 0.01, Batch Size = 16, Momentum = 0.937, Weight Decay = 0.0005, Image Size = 640x640 พิกเซล และจำนวนรอบ Epochs จะเริ่มจาก 100, 200 และ 300 รอบ โดยสมการสำคัญที่เกี่ยวข้องมีดังนี้

Bounding Box Regression โดย YOLO ใช้การคำนวณตำแหน่งและขนาดของกล่องล้อมรอบวัตถุด้วยค่าพิกัด (*x, y, w, h*) ซึ่งแสดงถึง [15]

x, y เป็นจุดพิกเซลเริ่มต้นของ Bounding Box

w, h เป็นความกว้างความยาว นับจากจุดพิกเซลเริ่มต้น

$$Loss_{bbox} = \lambda_x(x-\hat{x})^2 + \lambda_y(y-\hat{y})^2 + \lambda_w(\sqrt{w}-\sqrt{\hat{w}})^2 + \lambda_h(\sqrt{h}-\sqrt{\hat{h}})^2 \quad (3)$$

โดย (x, y, w, h) คือค่าพิกัดจริงของ Bounding Box ส่วน $(\hat{x}, \hat{y}, \hat{w}, \hat{h})$ คือค่าที่โมเดลพยากรณ์ และ คือค่าน้ำหนักสำหรับการควบคุมการสูญเสีย

สำหรับการหาค่า Confidence Score จะคำนวณความน่าจะเป็นของการมีวัตถุใน Bounding Box ดังสมการ

$$Confidence = P(object) \times IoU_{pred,truth} \quad (4)$$

โดย *P(object)* คือ ความน่าจะเป็นของการมีวัตถุ และ $IoU_{pred, truth}$ คือ ค่า Intersection over Union ระหว่าง Bounding Box ที่คาดการณ์กับ Bounding Box จริง

การหา Class Prediction Loss นั้น YOLO ใช้ Cross-Entropy Loss ในการจำแนกประเภทวัตถุ [14] ดังสมการ

$$Loss_{class} = -\sum_{c=1}^{C} y_c \log(\hat{p}_c) \quad (5)$$

โดย y_c คือค่าความจริงของคลาส c (1 หรือ 0) ส่วน $\hat{p}_c$ คือ ค่าความน่าจะเป็นของคลาสที่โมเดลพยากรณ์ และ C คือ จำนวนคลาสทั้งหมด

การรวม Loss Functions ใน YOLOv8 จะรวม Loss Functions ทั้งหมดเป็น Loss Function เดียวสำหรับการฝึกโมเดล ดังสมการ

$$Total\ Loss = Loss_{bbox} + Loss_{confidence} + Loss_{class} \quad (6)$$

อย่างไรก็ตาม ในขณะที่ OpenCV จะใช้หลักการของการรู้จำใบหน้า (Face Recognition) ส่วน YOLOv8 จะใช้หลักการตรวจจับใบหน้า (Face Detection) โดยการตรวจจับใบหน้าเป็นกระบวนการระบุและกำหนดตำแหน่งของใบหน้าภายในภาพหรือวิดีโอ Viola and Jones [16] ได้นำเสนอ Haar Cascade Classifier ซึ่งถือเป็นหนึ่งในเทคนิคการตรวจจับใบหน้าที่สามารถทำงานแบบเรียลไทม์ได้เป็นครั้งแรก อัลกอริทึมนี้อาศัยคุณลักษณะของ Haar-like Features และใช้ตัวจำแนกแบบ AdaBoost เพื่อเพิ่มความสามารถในการตรวจจับใบหน้าอย่างมีประสิทธิภาพ นอกจากนี้ Dalal and Triggs [17] ได้พัฒนา Histogram of Oriented Gradients (HOG) ซึ่งใช้ลักษณะของทิศทางของ Gradient ในการระบุรูปแบบของใบหน้า และเป็นที่นิยมในการใช้งานร่วมกับเครื่องจำแนกประเภทเชิงเส้น เช่น Support Vector Machine (SVM) ในช่วงไม่กี่ปีที่ผ่านมา แนวทางที่ใช้ Deep Learning ได้ถูกนำมาใช้เพื่อปรับปรุงความแม่นยำของการตรวจจับใบหน้า Zhang et al.[18] ได้นำเสนอ Multi-task Cascaded Convolutional Networks (MTCNN) ซึ่งเป็นเครือข่ายโครงข่ายประสาทเทียมที่ใช้เลเยอร์หลายชั้นเพื่อทำการวิเคราะห์ภาพในหลายระดับ ทำให้สามารถตรวจจับใบหน้าได้แม้ในสภาพแวดล้อมที่ซับซ้อน

ส่วนการรู้จำใบหน้าเป็นกระบวนการที่ต่อยอดจากการตรวจจับใบหน้า โดยมุ่งเน้นไปที่การระบุหรือยืนยันตัวบุคคลโดยอาศัยลักษณะเฉพาะของใบหน้า ในช่วงแรกของการพัฒนา ได้มีการใช้วิธีทางสถิติ เช่น Eigenfaces และ Fisherfaces แต่ในปัจจุบันโมเดลที่ใช้ Deep Learning ได้แสดงให้เห็นถึงความสามารถที่สูงกว่าในการระบุใบหน้าได้อย่างแม่นยำ โดย Taigman et al. [19] ได้พัฒนา DeepFace ซึ่งเป็นหนึ่งในโมเดลแรกที่ใช้โครงข่ายประสาทเทียมแบบ Convolutional Neural Networks (CNNs) ในการสร้างตัวแทนเชิงลึกของใบหน้า ขณะที่ Schroff et al. [20] ได้พัฒนา FaceNet ซึ่งใช้เทคนิค Triplet Loss เพื่อสร้างเวกเตอร์ที่สามารถใช้ในการเปรียบเทียบและจัดกลุ่มใบหน้าในพื้นที่เวกเตอร์ความน่าจะเป็นสูง และได้มีการพัฒนาเทคนิคใหม่ ๆ เช่น ArcFace ของ Deng et al. [21] ซึ่งใช้ Loss Function แบบใหม่ที่เพิ่มความสามารถของโมเดลในการแยกแยะใบหน้าที่มีความคล้ายคลึงกันสูง

หลังจากที่ได้โมเดลรู้จำใบหน้า คณะผู้วิจัยได้นำข้อมูลที่ได้จากการประมวลผลส่งไปบันทึกใน Google Sheets ซึ่งเป็นแพลตฟอร์มการจัดเก็บข้อมูลแบบคลาวด์ที่ช่วยให้สามารถเข้าถึงข้อมูลการเช็คชื่อเข้าเรียนได้แบบเรียลไทม์ ข้อมูลดังกล่าวจะถูกส่งไปยังอาจารย์ผู้สอนเพื่อให้สามารถตรวจสอบสถานะการเข้าเรียนของนักศึกษาได้อย่างสะดวกและรวดเร็ว [22] แนวทางนี้ช่วยลดภาระของอาจารย์ในการตรวจสอบรายชื่อด้วยตนเอง และเพิ่มประสิทธิภาพของระบบการเช็คชื่อเข้าเรียนโดยใช้เทคโนโลยี AI ซึ่งสามารถแสดงกระบวนการในการตรวจสอบใบหน้าและส่งข้อมูลไปยังผู้สอนได้ดังภาพที่ 3

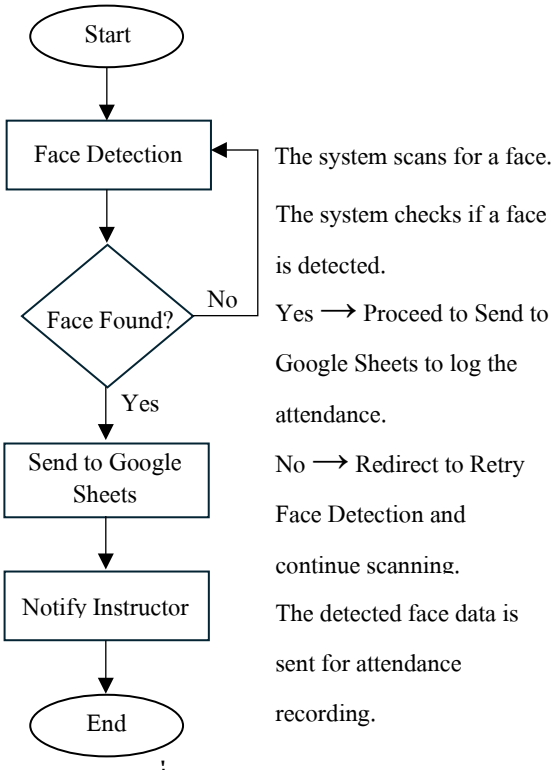

ภาพที่ 3: กระบวนการทำงานของระบบ

2.3 การวัดประสิทธิภาพโมเดล

การประเมินประสิทธิภาพของโมเดลรู้จำใบหน้าเป็นขั้นตอนสำคัญในการวิเคราะห์ความแม่นยำและความสามารถในการจำแนกข้อมูลของระบบ ซึ่งช่วยให้สามารถตรวจสอบว่าโมเดลสามารถทำงานได้ดีเพียงใดเมื่อทดสอบกับชุดข้อมูลจริง การวัดประสิทธิภาพของโมเดลสามารถทำได้โดยใช้ตัวชี้วัดหลัก ได้แก่ ค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision) และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) ซึ่งเป็นค่าที่ได้จากวิธีการทดสอบเพื่อหาค่าพยากรณ์ความถูกต้องของข้อมูล โดยคิดเป็นค่าร้อยละ (%) [23] ดังสมการ

$$Accuracy = \frac{(TP + TN)}{(TN + FN + FP + TP)} \quad (7)$$

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

โดยที่ TP คือค่าพยากรณ์ถูกต้องเชิงบวก TN คือค่าพยากรณ์ถูกต้องเชิงลบ ส่วน FP คือค่าพยากรณ์ผิดพลาดเชิงบวก และ FN คือค่าพยากรณ์ผิดพลาดเชิงลบ

3. ผลการวิจัยและอภิปรายผล

การพัฒนาระบบตรวจจับใบหน้าและยืนยันตัวตนของนักศึกษาในการเข้าเรียน คณะผู้วิจัยได้ดำเนินการเปรียบเทียบประสิทธิภาพของอัลกอริทึม 2 ตัว ประกอบด้วย YOLOv8 และ Library สำหรับ Computer Vision (OpenCV: Haar-like, HOG) เพื่อเปรียบเทียบและหาผลลัพธ์ที่มีความแม่นยำมากที่สุด ดังนี้

ตารางที่ 1: ผลการเปรียบเทียบค่าความแม่นยำของอัลกอริทึม YOLOv8 และ OpenCV

	YOLOv8	OpenCV
Accuracy	ร้อยละ 0.06	ร้อยละ 83.33
Precision	ร้อยละ 0.68	ร้อยละ 75.00
Recall	ร้อยละ 0.07	ร้อยละ 83.33

จากตารางที่ 1 แสดงผลการเปรียบเทียบค่าความแม่นยำของอัลกอริทึม YOLOv8 และ OpenCV ในด้านต่าง ๆ ได้แก่ Accuracy, Precision และ Recall สามารถอธิบายผลลัพธ์ได้ดังนี้

Accuracy (ค่าความถูกต้อง) YOLOv8 มีค่า Accuracy เพียง ร้อยละ 0.06 ส่วน OpenCV มีค่า Accuracy สูงถึง ร้อยละ 83.33

Precision (ค่าความแม่นยำ) YOLOv8 มีค่า Precision ร้อยละ 0.68 ส่วน OpenCV มีค่า Precision ร้อยละ 75 โดย OpenCV ยังคงมีค่าสูงกว่า YOLOv8

Recall (ค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง) YOLOv8 มีค่า Recall เพียง ร้อยละ 0.07 ส่วน OpenCV มีค่า Recall สูงถึง ร้อยละ 83.33

จากผลการเปรียบเทียบทำให้พบว่าโมเดล OpenCV มีความเหมาะสมที่จะนำไปใช้ในการพัฒนาระบบรู้จำใบหน้าเพื่อตรวจสอบเข้าเรียนของนักศึกษาสาขานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ จากการนำโมเดล OpenCV ไปทดลองใช้จริงโดยจำลองระบบผ่านการใช้กล้อง Webcam พบว่าระบบสามารถจำแนกได้ถูกต้องเฉลี่ยมากกว่าร้อยละ 70 ดังภาพที่ 4

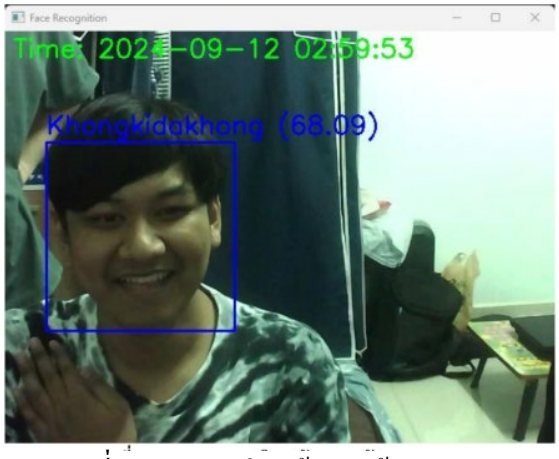

ภาพที่ 4: การสแกนใบหน้าจากกล้อง Webcam

จากการพัฒนาระบบรู้จำใบหน้าเพื่อเช็คชื่อเข้าเรียนของนักศึกษาสาขานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี พบว่าระบบมีความแม่นยำค่อนข้างสูงในการตรวจจับใบหน้าของนักศึกษา และสามารถนำมาใช้ทดแทนวิธีการเช็คชื่อแบบดั้งเดิมได้ เนื่องจากระบบได้ทำการบันทึกทั้งชื่อ วันที่ เวลา ในการเข้าเรียน รวมทั้งยังบอกได้ว่านักศึกษาคนนั้น ๆ เข้าเรียนตรงเวลา เข้าเรียนสาย หรือขาดเรียน ดังภาพที่ 5

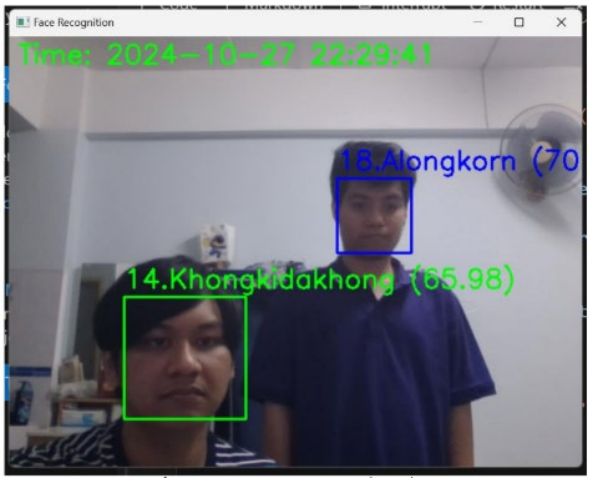

ภาพที่ 5: การสแกนใบหน้า ที่เช็คชื่อสำเร็จ

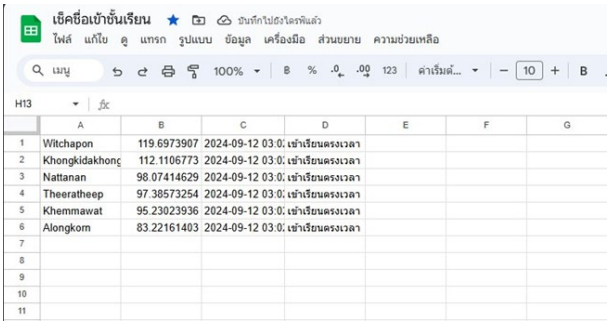

ภาพที่ 6: การส่งชื่อและเวลาเข้าเรียนของนักศึกษาไปยัง Google Sheets

จากผลการวิจัยในครั้งนี้ ซึ่งเปรียบเทียบประสิทธิภาพของอัลกอริทึม YOLOv8 และ OpenCV ในการสร้างระบบรู้จำใบหน้า พบว่ามีความแตกต่างอย่างชัดเจนในด้านค่าความถูกต้อง (Accuracy), ความแม่นยำ (Precision) และอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) โดย OpenCV แสดงผลลัพธ์ที่เหนือกว่า YOLOv8 ในทุกตัวชี้วัด ซึ่งสามารถอภิปรายได้ดังนี้

3.1 ค่าความถูกต้อง (Accuracy)

จากผลลัพธ์ YOLOv8 มีค่าความถูกต้องเพียง ร้อยละ 0.06 ในขณะที่ OpenCV มีค่าความถูกต้องสูงถึง ร้อยละ 83.33 แสดงว่า OpenCV มีประสิทธิภาพดีกว่าในด้านการทำนายผลลัพธ์โดยรวม การที่ YOLOv8 มีค่าความถูกต้องต่ำอาจเกิดจากการที่โมเดลไม่ได้ถูกปรับแต่งให้เหมาะสมกับลักษณะ

ข้อมูลที่ใช้ในงานวิจัยครั้งนี้ เช่น ลักษณะของใบหน้าที่มีการเปลี่ยนแปลงแสงหรือมุมมองที่ซับซ้อน ซึ่งสอดคล้องกับการศึกษาของ John [24] ที่ระบุว่า YOLO เหมาะสำหรับการตรวจจับวัตถุทั่วไปมากกว่าการตรวจจับใบหน้าที่มีความละเอียดสูง

3.2 ค่าความแม่นยำ (Precision)

YOLOv8 มีค่า Precision อยู่ที่ ร้อยละ 0.68 ส่วน OpenCV ที่มีค่า ร้อยละ 75 การที่ YOLOv8 มีค่า Precision ในระดับต่ำแสดงว่าระบบไม่สามารถลดจำนวนผลลัพธ์ที่เป็น False Positive ได้ อย่างไรก็ตาม OpenCV ยังคงมีความแม่นยำที่สูงกว่าในแง่ของการตรวจจับใบหน้าจริง ซึ่งสนับสนุนผลการศึกษาของ Zhang et al. [25] ที่ระบุว่า OpenCV มีความเสถียรในการตรวจจับใบหน้าในภาพนิ่งและในสภาพแวดล้อมที่ไม่ซับซ้อน

3.3 ค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall)

YOLOv8 มีค่า Recall ต่ำเพียง ร้อยละ 0.07 เมื่อเทียบกับ OpenCV ที่มีค่า ร้อยละ 83.33 แสดงว่า YOLOv8 ไม่สามารถตรวจจับใบหน้าทั้งหมดในชุดข้อมูลได้ดีพอ ซึ่งอาจเกิดจากการตั้งค่าพารามิเตอร์ของโมเดล เช่น Threshold ที่ใช้ในการตัดสินใจ หรือโครงสร้างของ YOLOv8 ที่เน้นความเร็วมากกว่าความแม่นยำในงานตรวจจับใบหน้า ผลลัพธ์นี้สอดคล้องกับงานวิจัยของ Brown et al. [26] ที่ชี้ว่า YOLO มีข้อจำกัดในการตรวจจับวัตถุที่มีรายละเอียดซับซ้อนหรือขนาดเล็ก เช่น ใบหน้าที่มีการเบี่ยงเบนจากมุมกล้อง

3.4 การเปรียบเทียบและข้อพิจารณา

การที่ OpenCV แสดงผลลัพธ์ดีกว่า YOLOv8 ในทุกตัวชี้วัด แสดงถึงความเหมาะสมของ OpenCV ในการนำไปใช้ในงานตรวจจับและจดจำใบหน้าในบริบทของงานวิจัยนี้ เนื่องจาก OpenCV มีการพัฒนาอัลกอริทึมเฉพาะด้าน เช่น Haar Cascade และ HOG ซึ่งถูกออกแบบมาให้เหมาะสมกับการตรวจจับใบหน้ามากกว่า YOLOv8 ที่เน้นความรวดเร็วและการตรวจจับวัตถุในสภาพแวดล้อมทั่วไป อีกทั้งการทดลองในครั้งนี้ ยังไม่มีการการปรับแต่งเพิ่มเติม (Fine-Tuning) และจำนวนรอบ (Epoch) แม้จะเพิ่มขึ้นจาก 100 เป็น 200 และ 300 ค่าประสิทธิภาพต่าง ๆ ยังไม่เพิ่มขึ้น อย่างไรก็ตาม หากต้องการความเร็วในการตรวจจับ YOLOv8 ยังสามารถปรับปรุงและนำไปใช้ในงานที่ต้องการการตอบสนองแบบเรียลไทม์ได้ เช่น ระบบรักษาความปลอดภัยที่ต้องการตรวจจับวัตถุในเวลาอันสั้น [27]

4. สรุปผล

พัฒนาระบบรู้จำใบหน้าและยืนยันตัวตนของนักศึกษาในการเข้าเรียนของสาขานวัตกรรมการเรียนรู้และเทคโนโลยีสารสนเทศ พบว่าระบบนี้ใช้เทคโนโลยีการประมวลผลภาพและการเรียนรู้ของเครื่องในการตรวจสอบและเปรียบเทียบใบหน้าของนักศึกษากับฐานข้อมูลที่จัดเก็บไว้และนำไปบันทึกลงใน Google Sheet หลังจากที่ระบบสามารถตรวจจับใบหน้าได้แม่นยำมากกว่าร้อยละ 83.33 กระบวนการพัฒนาระบบประกอบด้วยการเก็บรวบรวมภาพใบหน้าของนักศึกษา การฝึกโมเดลรู้จำใบหน้า การทดสอบความแม่นยำในการตรวจจับ และพัฒนาระบบบันทึกรายชื่อ ผลการพัฒนาระบบพบว่า ในการพัฒนาระบบการตรวจจับใบหน้าด้วยอัลกอริทึม YOLOv8 นั้น ให้ความความถูกต้องแม่นยำเพียงร้อยละ 0.68 ซึ่งไม่สามารถนำไปไปใช้จริงได้ ดังนั้นจึงได้ใช้อัลกอริทึม OpenCV พบว่ามีค่าความถูกต้องแม่นร้อยละ 75 ซึ่งเป็นค่าที่เหมาะสมในการใช้งานจริง

ในขณะที่ OpenCV แสดงถึงความเหมาะสมและประสิทธิภาพที่สูงกว่า YOLOv8 ในบริบทของการพัฒนาระบบรู้จำใบหน้า โดยเฉพาะในด้านความถูกต้องและการตรวจจับใบหน้าที่เป็นข้อมูลจริง อย่างไรก็ตาม YOLOv8 ยังสามารถปรับปรุงเพิ่มเติมเพื่อนำไปใช้ในงานที่ต้องการความเร็วในการตรวจจับ เช่น การตรวจจับวัตถุในระบบเฝ้าระวังหรือระบบแบบเรียลไทม์

จากผลลัพธ์ที่ได้ สามารถนำ OpenCV มาปรับปรุงและพัฒนาเพื่อสร้างระบบรู้จำใบหน้าที่เหมาะสมสำหรับการเช็คชื่อเข้าเรียนของนักศึกษา เช่น การปรับใช้ร่วมกับ Convolutional Neural Network (CNN) เพื่อเพิ่มความแม่นยำและลดข้อผิดพลาดที่อาจเกิดขึ้น นอกจากนี้ การใช้ YOLOv8 อาจมีการปรับปรุงในอนาคตโดยการเพิ่มชุดข้อมูลเฉพาะด้าน (Domain-Specific Dataset) และการปรับแต่งพารามิเตอร์ให้เหมาะสมกับการตรวจจับใบหน้า

5. เอกสารอ้างอิง

[1] Singh P., Gupta R., and Sharma S. (2021). Biometric Identification and its Role in Security Systems. Computer Science Review, 40, 100372, 2021.

[2] Jain A., and Kumar R. Biometric Authentication in Higher Education: Trends and Challenges. Journal of Educational Technology & Society, 2022; 25(3):87-99.

[3] Zhang T., Li M., and Chen H. Enhancing Student Authentication Through AI-Powered Biometric Systems. Education and Information Technologies, 2023; 28(2): 1539-1560.

[4] Chen L., Zhao Y., and Wang X. Advancements in AI-Based Facial Recognition for Academic Attendance Systems. IEEE Transactions on Education, 2023; 66(4): 512-524.

[5] Brown D., and Smith J. Facial Recognition and Its Applications in Modern Security Systems. International Journal of Computer Vision, 2022; 30(5): 678-691.

[6] Wilson R., and Adams K. AI in Education: Enhancing Student Identity Verification Systems. Journal of Artificial Intelligence in Education, 2023; 27(1): 115-132.

[7] Garcia M., and Lee H. Challenges and Innovations in AI-Powered Facial Recognition Systems. ACM Computing Surveys, 2021; 54(7): 1-24.

[8] Patel S., and Kumar P. Biometric Authentication for Online Learning Platforms: Trends and Future Prospects. Journal of Digital Learning, 2023; 15(2): 89-105.

[9] Bradski G. The OpenCV Library. Dr. Dobb's Journal of Software Tools; 2000.

[10] Zhao W., Chellappa R., Phillips P. J., and Rosenfeld A. Face Recognition: A Literature Survey. ACM Computing Surveys, 2020; 35(4):399-458.

[11] He K., Zhang X., Ren S., and Sun J. Deep Residual Learning for Image Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016; 770-778.

[12] Viola P., and Jones M. Rapid Object Detection using a Boosted Cascade of Simple Features. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2001.

[13] Dalal N., and Triggs B. Histograms of Oriented Gradients for Human Detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2005.

[14] Jocher G., Chaurasia A., and Qiu J. YOLOv8: A State-of-the-Art Object Detection Model. GitHub Repository, 2023.

[15] Redmon J., and Farhadi A. YOLOv3: An Incremental Improvement. arXiv preprint arXiv:1804.02767, 2018.

[16] Viola, P., & Jones, M. Rapid Object Detection using a Boosted Cascade of Simple Features. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2001.

[17] Dalal, N., & Triggs, B. Histograms of Oriented Gradients for Human Detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2005.

[18] Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. Joint Face Detection and Alignment Using Multi-task Cascaded Convolutional Networks (MTCNN). IEEE Signal Processing Letters, 2016; 23(10), 1499-1503.

[19] Taigman, Y., Yang, M., Ranzato, M., & Wolf, L. DeepFace: Closing the Gap to Human-Level Performance in Face Verification. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014.

[20] Schroff, F., Kalenichenko, D., & Philbin, J. FaceNet: A Unified Embedding for Face Recognition and Clustering. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015.

[21] Deng, J., Guo, J., Xue, N., & Zafeiriou, S. ArcFace: Additive Angular Margin Loss for Deep Face Recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019.

[22] Google Cloud. Google Sheets API Documentation; 2021 [cited 2024 Dec 24] Available from: https://developers.google.com/sheets

[23] Malta A, Mendes M and Farinha T. Augmented reality maintenance assistant using YOLOv5. Applied Sciences 2021; 11(11): 475.

[24] John D. Evaluation of YOLOv4 and YOLOv5 for Object and Face Detection. International Journal of Computer Vision, 2022; 40(3): 245-256.

[25] Zhang K., Zhang Z., Li Z., and Qiao Y. Joint Face Detection and Alignment Using Multi-task Cascaded Convolutional Networks (MTCNN). IEEE Signal Processing Letters, 2016; 23(10): 1499-1503.

[26] Brown D., and Smith J. Challenges in Face Detection Using YOLO in Complex Environments. Journal of Artificial Intelligence and Computer Vision, 2021; 35(5): 789-802.

[27] Jocher G., Chaurasia A., and Qiu J. YOLOv8: A State-of-the-Art Object Detection Model. GitHub Repository, 2023.

การเปรียบเทียบประสิทธิภาพของแบบจำลองแบบผสมการเรียนรู้เชิงลึกสำหรับการพยากรณ์ราคาหุ้น

A Comparative Performance of Hybrid Deep Learning Models for Stock Price Forecasting

กิตติคุณ ทัดประดิษฐ์* วิฐรา พึ่งพาพงศ์

ภาควิชาสถิติและวิทยาการข้อมูล คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

(** 6680025026@student.chula.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์และเปรียบเทียบประสิทธิภาพและระยะเวลาที่ใช้ของแบบจำลองการเรียนรู้เชิงลึกแบบผสม (Hybrid Deep Learning Models) ได้แก่ RNN, LSTM และ GRU ในรูปแบบการใช้โครงสร้างแบบผสม (Stacked Layer) และเครือข่ายประสาทเทียมแบบซ้อนกัน (Cascaded Neural Network) ในการพยากรณ์ราคาปิดหุ้น รวมถึงศึกษาผลกระทบของการสลับลำดับของแบบจำลองภายใน Hybrid Model เพื่อพิจารณาความแตกต่างของประสิทธิภาพการพยากรณ์ ทั้งในระยะสั้น 7 วัน และ ระยะยาว 30 วัน โดยมีการใช้ข้อมูลราคาหุ้น 5 อุตสาหกรรม เลือกกลุ่มอุตสาหกรรมละ 3 หุ้นตามระดับความผันผวนของราคาหุ้น (Beta) รวม 15 ชุดข้อมูล ผลการศึกษาพบว่า ในการพยากรณ์ระยะสั้น 7 วันและระยะยาว 30 วัน การสร้างแบบจำลองผสมด้วยวิธี Cascaded Neural Network มีประสิทธิภาพไม่แตกต่างกับ Stacked Layers หากพิจารณาด้วยระยะเวลาที่ใช้ในการสร้างแบบจำลองพบว่า การสร้างแบบจำลองผสมด้วยวิธี Stacked Layers ใช้เวลาสร้างแบบจำลองน้อยกว่า Cascaded Neural Network อย่างมีนัยสำคัญ ซึ่งจะช่วยประหยัดทรัพยากรในการสร้างแบบจำลองเป็นอย่างมาก นอกจากนี้การสลับลำดับของแบบจำลองที่ใช้ในการผสมแบบจำลองด้วยวิธี Cascaded Neural Network และ Stacked Layers ในการพยากรณ์ระยะสั้น 7 วันและระยะยาว 30 วัน ไม่ส่งผลต่อประสิทธิภาพของ Hybrid Models อย่างมีนัยสำคัญ สรุปได้ว่าการสร้าง Hybrid Deep Learning Models ด้วยวิธี Stacked Layers ให้ประสิทธิภาพและความคุ้มค่าที่มากกว่าการผสมด้วยวิธี Cascaded Neural Network ทั้งในระยะสั้นและระยะยาว

คำสำคัญ: แบบจำลองการเรียนรู้เชิงลึกแบบผสม, การวิเคราะอนุกรมเวลา, RNN, LSTM, GRU

Abstract

This research examines and compares the performance and training time of Hybrid Deep Learning Models, including RNN, LSTM, and GRU. These models are implemented using two architectures: Stacked Layers and Cascaded Neural Networks, for forecasting stock closing prices. Including the study of the impact of changing the sequencing of models within the Hybrid model to assess differences in forecasting performance for both the short-term (7 days) and the long-term (30 days). The dataset consists of stock prices from five industries, selecting three stocks from volatility levels (Beta), resulting in a total of 15 datasets. The findings indicate that Stacked Layers and Cascaded Neural Networks perform similarly in both short-term and long-term forecasts, with no significant differences in accuracy. However, in terms of training time, Stacked Layers require significantly less time than Cascaded Neural Networks, making them more efficient and resource-saving. Additionally, rearranging the order of models in hybrid architecture does not significantly affect forecasting performance. Overall, the results suggest that Stacked Layers are the better approach for building Hybrid Deep Learning Models, as they provide similar accuracy while being more efficient in terms of computation and resource usage, making them preferable for both short-term and long-term stock price forecasting.

Keywords: Hybrid Deep Learning Model, Time Series Analysis, RNN, LSTM, GRU

1. บทนำ

ปัจจุบันการลงทุนมีบทบาทสำคัญมากต่อชีวิตของผู้คน เนื่องจากมีอัตราผลตอบแทนที่สูง และมีบทบาทสำคัญในการช่วยสร้างความมั่งคั่งและบรรลุเป้าหมายทางการเงิน เช่น การเกษียณอายุการซื้อบ้าน เป็นต้น การลงทุนในปัจจุบันมีทางเลือกมากมายไม่ว่าจะเป็นตราสารทุน ตราสารหนี้ หรืออนุพันธ์ นักลงทุนทุกคนมีเป้าหมาย ระยะเวลา และความสามารถในการยอมรับความเสี่ยงแตกต่างกัน อย่างไรก็ตาม การลงทุนที่ต้องการผลตอบแทนสูงมักจะมาพร้อมกับความเสี่ยงที่สูงขึ้น การทำนายราคาหุ้นจึงได้รับความสนใจจากนักลงทุนภาคเอกชน สถาบันหรือนักลงทุนรายย่อย นักลงทุนอาจใช้เทคนิคการลงทุน และการบริหารความเสี่ยงที่แตกต่างกัน ดังนั้นการใช้เครื่องมือทางสถิติและคณิตศาสตร์เพื่อช่วยในการคาดการณ์และการพยากรณ์จึงมีความสำคัญต่อการวางแผนการลงทุนและการบริหารความเสี่ยงในอนาคต

ในช่วงเวลาต่าง ๆ ตั้งแต่อดีตจนถึงปัจจุบันนั้นมีการวิจัยมากมายเกี่ยวกับการพยากรณ์ราคาปิดหุ้น เพื่อใช้ในการตัดสินใจลงทุนเพื่อให้ได้ผลตอบแทนที่คาดหวัง นักวิจัยได้นำเสนอแบบจำลองทางคณิตศาสตร์หลายประเภทเพื่อการพยากรณ์ดังนี้ แบบจำลองอารีมา (ARIMA), ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines : SVM), และในช่วงเวลาปัจจุบันได้มีการนำเสนอแบบจำลองการเรียนรู้เชิงลึก เช่น เครือข่ายประสาทเทียม (Artificial Neural Network : ANN), เครือข่ายประสาทเทียมแบบวกกลับ (Recurrent Neural Network : RNN), Long Short-Term Memory (LSTM) รวมถึงการปรับปรุงประสิทธิภาพในการพยากรณ์อนุกรมเวลาโดยผสมแบบจำลอง ARIMA กับ Deep Learning ซึ่งได้ผลการพยากรณ์ที่แม่นยำกว่า ARIMA เดิมที่เป็นแบบจำลองทางสถิติทั่วไปในการพยากรณ์ชุดข้อมูลอนุกรมเวลา

ผู้วิจัยจึงต้องการศึกษาเกี่ยวกับการนำ Deep Learning มาสร้างแบบจำลองแบบผสมเพื่อพัฒนาศักยภาพในการพยากรณ์ ทางผู้วิจัยได้พบว่าวิธีการสร้างแบบจำลองผสม Deep Learning ในปัจจุบันที่ได้รับความนิยมในหลาย ๆ งานวิจัย คือ การใช้ Stacked Layers ยกตัวอย่างงานวิจัยที่นำวิธีดังกล่าวมาใช้อาทิ งานวิจัยของ Liu et al. [1] ได้ทำการเปรียบเทียบประสิทธิภาพในการพยากรณ์ระหว่างแบบจำลอง Stacked GRU-LSTM และแบบจำลองโครงสร้างเดี่ยว LSTM, GRU งานวิจัยของ Althelaya et al. [2] ได้ทำการเปรียบเทียบความสามารถในการพยากรณ์ของ LSTM, Bi-LSTM, และ Stack-LSTM และในงานวิจัยของ Hossain et al. [3] ได้ทำการเปรียบเทียบความสามารถในการพยากรณ์ของ LSTM และ GRU กำหนดให้มีชั้นซ่อน 1, 2 และ 3 ชั้น รวมถึง Stacked LSTM-GRU โดยจากทั้ง 3 งานวิจัยพบว่าการใช้การผสมแบบจำลอง Deep learning วิธี Stacked layer นั้นให้ผลลัพธ์ที่ดีที่สุด และการทำให้เครือข่ายลึกขึ้นด้วยส่วนประกอบเดียวกันอาจทำให้เกิดการ Overfitting และลดประสิทธิภาพลง นอกจากการใช้วิธี Stacked Layer แล้วผู้วิจัยพบว่ามีวิธีการผสมแบบจำลองที่น่าสนใจจากงานวิจัยของกุลวานิช [4] ได้ใช้การผสมแบบ Linear Regression และ Additive Combination ในการผสมแบบจำลองระหว่าง ARIMA และ ANN ซึ่งพบว่าการผสมแบบ Linear Regression มีประสิทธิภาพสูงสุดในการพยากรณ์ รองลงมาคือ Additive Combination Method และ ARIMA ตามลำดับ สรุปได้ว่าการใช้แบบจำลองผสมเป็นทางเลือกที่มีประสิทธิภาพในการพยากรณ์ แต่ต้องแลกกับเวลาประมวลผลที่นานกว่าแบบจำลองเดี่ยว ซึ่งทางผู้วิจัยได้นำแนวคิดการผสมแบบ Additive Combination Method มาประยุกต์ใช้กับแบบจำลอง Deep Learning โดยแบบจำลองการเรียนรู้เชิงลึกสามารถวิเคราะห์ได้ทั้งสององค์ประกอบ คือ เชิงเส้นตรง และไม่เป็นเส้นตรง อย่างไรก็ตามยังคงมีส่วนเหลือ (Residual) จากการพยากรณ์อยู่ ดังนั้นผู้วิจัยจึงนำแบบจำลองการเรียนรู้เชิงลึกอื่น ๆ มาช่วยในการพยากรณ์องค์ประกอบที่ไม่เป็นเส้นตรงที่เหลืออยู่ เพื่อเพื่อปรับปรุงผลลัพธ์ในการพยากรณ์ ซึ่งในงานวิจัยนี้จะเรียกวิธีการนี้ว่า Cascaded Neural Network

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การวิเคราะห์อนุกรมเวลา

เทคนิคทางสถิติที่ใช้ในการวิเคราะห์และทำความเข้าใจข้อมูลที่ขึ้นอยู่กับเวลา รวมถึงการแยกองค์ประกอบของอนุกรมเวลาออกเป็นแนวโน้ม ฤดูกาล และโครงสร้างพื้นฐานอื่น ๆ ที่แฝงอยู่ภายในข้อมูล เพื่อนำไปใช้ในการพยากรณ์อนาคตโดยอาศัยข้อมูลตามช่วงเวลา การวิเคราะห์องค์ประกอบเหล่านี้ทำให้สามารถระบุรูปแบบ ตรวจจับสิ่งผิดปกติ และตัดสินใจบนพื้นฐานของข้อมูลได้อย่างมีประสิทธิภาพ นอกจากนี้ ยังสามารถนำไปประยุกต์ใช้ในหลายสาขา เช่น เศรษฐศาสตร์ การเงิน การบริหารจัดการ และวิทยาศาสตร์ เพื่อเพิ่มความแม่นยำในการคาดการณ์และการวางแผนเชิงกลยุทธ์ โดยข้อมูลอนุกรมเวลาแบ่งออกเป็น 4 ส่วนประกอบ ได้แก่ แนวโน้ม (Trend) ฤดูกาล (Seasonality) วัฏจักร (Cycle) และค่าผิดปกติ (Irregular)

2.2 เครือข่ายประสาทเทียมเทียม (ANN)

เครือข่ายประสาทเทียมเป็นแบบจำลองทางคณิตศาสตร์ที่มีหลักการเบื้องต้นมาจากการเลียนแบบความสามารถของสมองมนุษย์ เพื่อใช้อธิบายลักษณะการทำงานของระบบประสาทของมนุษย์ โดยมีจุดประสงค์ในการสร้างเครื่องมือที่มีความสามารถในการเรียนรู้ที่ซับซ้อน เช่น การจดจำรูปแบบ (Pattern Recognition) และการอนุมานความรู้ (Knowledge Deduction) ซึ่งเครือข่ายประสาทเทียมนี้ได้รับความนิยมในการพยากรณ์ด้านธุรกิจ เนื่องจากมีความสามารถในการพยากรณ์ข้อมูลที่ไม่เป็นฟังก์ชันเชิงเส้นในเทอมของค่าพารามิเตอร์ได้อย่างมีประสิทธิภาพ จากนั้นได้มีการศึกษาและพัฒนาอย่างต่อเนื่อง ประกอบด้วย 5 องค์ประกอบ ดังนี้

1) ข้อมูลนำเข้า (Input) คือ ข้อมูลที่เป็นตัวเลขหากเป็นข้อมูลเชิงคุณภาพต้องแปลงให้อยู่ในรูปเชิงปริมาณที่เครือข่ายประสาทเทียมยอมรับได้

2) ข้อมูลส่งออก (Output) คือ ผลลัพธ์ที่เกิดขึ้นจริง (Actual Output) จากกระบวนการเรียนรู้ของเครือข่ายประสาทเทียม

3) ค่าน้ำหนัก (Weights) คือ สิ่งที่ได้จากการเรียนรู้ของเครือข่ายประสาทเทียมหรือเรียกอีกอย่างหนึ่งว่าค่าความรู้ (Knowledge) ค่านี้อาจถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่น ๆ ที่อยู่ในรูปแบบเดียวกัน

4) ฟังก์ชันผลรวม (Summation Function) คือ ผลรวมของข้อมูลป้อนเข้าและค่าน้ำหนัก

5) ฟังก์ชันกระตุ้น (Activation Function) คือ การคำนวณการจำลองการทำงานของเครือข่ายประสาทเทียมเช่น โดยฟังก์ชันกระตุ้นที่นิยมใช้ ได้แก่ Sigmoid คือ ฟังค์ชันที่ทำให้ค่าระหว่าง [0, 1] เหมาะกับปัญหาจำแนกประเภท (Classification) หรือการตีความเชิงความน่าจะเป็น แต่มีปัญหา Vanishing Gradient ส่วน Tanh มีลักษณะคล้าย Sigmoid แต่ค่าระหว่าง [-1, 1] ช่วยให้การเรียนรู้เร็วขึ้น นิยมใช้ ในแบบจำลองการเรียนรู้เชิงลึกตระกูล RNN เพราะให้ค่าระหว่าง -1 ถึง 1 ซึ่งช่วยให้ข้อมูลสามารถแสดงค่าบวกและลบได้ ทำให้เหมาะกับข้อมูลที่มีความต่อเนื่อง ส่วน ReLU ให้ค่าเป็นศูนย์เมื่อ Input ติดลบ และเป็นเส้นตรงเมื่อ Input เป็นบวก มักใช้ในโครงข่ายเชิงลึก (Deep Neural Networks) เพราะลดปัญหา Vanishing Gradient และเพิ่มประสิทธิภาพในการเรียนรู้ แต่ไม่นิยมใช้ใน RNN เพราะมีปัญหา Exploding Gradient และไม่เหมาะกับข้อมูลที่มีลักษณะวนซ้ำ

2.3 เครือข่ายประสาทเทียมแบบย้อนกลับ (Recurrent Neural Networks: RNN)

เครือข่ายระบบประสาทแบบย้อนกลับเป็นสถาปัตยกรรมรูปแบบหนึ่งของเครือข่ายประสาทเทียม ออกแบบมาเพื่อจัดการกับข้อมูลประเภทตรวจจับรูปแบบในลำดับข้อมูล ข้อมูลดังกล่าวอาจเป็นข้อความ เสียงและอนุกรมเวลา (Time Series Data) มักพบในบริบทอุตสาหกรรม หลักการของ RNN คือการปรับโครงสร้างของเครือข่ายประสาทเทียมแบบดั้งเดิม โดยเพิ่มชั้นซ่อน (Hidden Layer) เพื่อจดจำข้อมูลหรือความรู้จากอดีตและผสมผสานเข้ากับข้อมูลใหม่ที่เข้ามา (Input Data) เพื่อใช้ในการพยากรณ์ แสดงได้ดังสมการที่ (1) - (2)

$$h_t = f_h(W_{hh}h_{t-1} + W_{hx}x_t) \quad (1)$$

$$y_t = f_y(W_{yh}h_t) \quad (2)$$

เมื่อ h_t แทน สถานะซ่อน ณ เวลา t,
f_h แทน ฟังก์ชันกระตุ้นสำหรับสถานะซ่อน
f_y แทน ฟังก์ชันกระตุ้นสำหรับค่าผลลัพธ์
y_t แทน ค่าผลลัพธ์ ณ เวลาตอน t
x_t แทน ค่านำเข้า ณ เวลาตอน t
W_{hx} แทน เมทริกซ์น้ำหนักสำหรับการเชื่อมต่อจากข้อมูลนำเข้าสู่สถานะซ่อน
W_{hh} แทน เมทริกซ์น้ำหนักสำหรับการเชื่อมต่อจากสถานะซ่อนในช่วงก่อนหน้าสู่สถานะซ่อนปัจจุบัน
W_{yh} แทน เมทริกซ์น้ำหนักสำหรับการเชื่อมต่อจากสถานะซ่อนสู่ค่าผลลัพธ์

อย่างไรก็ตาม RNN ประสบปัญหาการลดลงของเกรเดียนต์ (Vanishing Gradient) หรือการระเบิดของเกรเดียนต์ (Exploding Gradient) ปัญหาเหล่านี้เกิดขึ้นเนื่องจากในเครือข่ายประสาทเทียมจะมีการปรับค่าถ่วงน้ำหนัก (Update Weights) โดยอาศัยวิธีการแพร่กลับของความผิดพลาด (Backward Propagation of Errors) ซึ่งจะคำนวณเกรเดียนต์ของฟังก์ชันการสูญเสีย (Loss Function) เพื่อใช้ในการปรับค่าถ่วงน้ำหนัก ในกรณีของ RNN เอาต์พุตไม่ได้มาจากช่วงเวลาเดียวแต่มาจากหลายช่วงเวลา ทำให้เกิดการคูณกันของอนุพันธ์หลายตัว ซึ่งหากเกรเดียนต์มีค่าน้อยกว่า 1 จะส่งผลให้ค่าเกรเดียนต์ลดลงตามความยาวของลำดับข้อมูล หรือ RNN จะมีปัญหาในการประมวลผลข้อมูลที่มีลำดับยาวเกินไป

2.4 เครือข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory: LSTM)

เครือข่ายประสาทเทียมหน่วยความจำระยะยาวถูกออกแบบมาเพื่อจัดการกับข้อมูลลำดับจำนวนมาก โดยมีเป้าหมายเพื่อแก้ไขปัญหาที่เกิดขึ้นในแบบจำลอง RNN เช่น ปัญหา Exploding Gradient และ Vanishing Gradient โดยหลักการสำคัญที่ช่วยให้แบบจำลอง LSTM สามารถลดปัญหา Exploding Gradient และ Vanishing Gradient ได้คือ

1. การคำนวณค่าสถานะการลืม (Forget Gate) คือ การคิดค่าถ่วงน้ำหนักเพื่อตัดสินใจนำข้าสถานะเซลล์ก่อนหน้ามาใช้ในสัดส่วนเท่าไหร่

2. การคำนวณค่าสถานะการรับข้อมูลใหม่ (Input Gate) คือ การคิดค่าถ่วงน้ำหนักเพื่อตัดสินใจนำค่าข้อมูลนำเข้าใหม่มาใช้ในสัดส่วนเท่าไหร่

หลักการทำงานของแบบจำลอง LSTM องค์ประกอบดังนี้

1. สถานะเซลล์ (Cell State) คือ ตัวเก็บค่าสถานะของเซลล์ความจำ (Cell Memory) โดยจะเก็บค่าสถานะเซลล์เพื่อนำไปใช้คำนวณต่อในประตูลืม และประตูนำเข้าต่อไป

2. ประตู (Gate) คือ ตัวควบคุมปริมาณนำเข้าข้อมูลของค่าสถานะเซลล์ เพื่อตัดสินใจว่าจะใช้ค่าสถานะเซลล์ในลำดับก่อนหน้าเทียบกับสถานะเซลล์ในลำดับปัจจุบันเป็นสัดส่วนเท่าไหร่ โดยคำนวณจากค่านำเข้าข้อมูลใหม่และค่าชั้นซ่อนในลำดับก่อนหน้า โดยแต่ละประตูก็มีเงื่อนไขการคิดค่าถ่วงน้ำหนักของสถานะเซลล์ต่างกัน ประกอบด้วยสามส่วนหลัก ได้แก่ ประตูการลืม (Forget Gate), ประตูการป้อนเข้า (Input Gate), และประตูการส่งออก (Output Gate)

โดยกระบวนการคำนวณของ LSTM เป็นดังนี้

1) ค่าผลลัพธ์ของช่วงเวลาก่อนหน้าและค่าของข้อมูลนำเข้าในช่วงเวลาปัจจุบันจะถูกป้อนเข้าสู่ forget gate ผลลัพธ์ของ Forget Gate จะได้มาหลังจากการคำนวณดังสมการที่ (3)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

2) ค่าผลลัพธ์ของเวลาที่ผ่านมาและค่าของข้อมูลนำเข้าในเวลาปัจจุบันจะถูกป้อนเข้าสู่เกตข้อมูลนำเข้า ค่าผลลัพธ์และสถานะเซลล์ผู้สมัครของเกตข้อมูลนำเข้าจะได้มาหลังจากการคำนวณ ซึ่งแสดงในสมการที่ (4) - (5)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\widetilde{C_t} = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

3) Cell State ปัจจุบันจะได้รับการปรับปรุงดังสมการที่ (6)

$$C_t = f_t * C_{t-1} + i_t * \widetilde{C_t} \quad (6)$$

4) ค่าผลลัพธ์ของช่วงเวลาก่อนหน้าและค่าของข้อมูลนำเข้าในปัจจุบันจะถูกป้อนเข้าไปใน Output Gate ค่าผลลัพธ์ของ Output Gate จะได้รับหลังการคำนวณดังสมการที่ (7)

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

5) ค่าผลลัพธ์ของ LSTM ได้มาจากการคำนวณผลลัพธ์ของ Output Gate และ Cell State ดังที่แสดงในสมการที่ (8)

$$h_t = o_t * \tanh(C_t) \quad (8)$$

เมื่อ
- C_{t-1} แทน Cell state ช่วงเวลาก่อนหน้า
- h_{t-1} แทน ค่าผลลัพธ์สุดท้ายช่วงเวลาก่อนหน้า
- x_t แทน ข้อมูลนำเข้าช่วงเวลาปัจจุบัน
- σ แทน ฟังก์ชันกระตุ้น
- f_t แทน ผลลัพธ์ของ Forget gate ช่วงเวลาปัจจุบัน มีค่าอยู่ระหว่าง [0, 1]
- i_t แทน ผลลัพธ์ของ Input gate ช่วงเวลาปัจจุบัน มีค่าอยู่ระหว่าง [0, 1]
- o_t แทน ค่าผลลัพธ์ของ Output gate ช่วงเวลาปัจจุบัน มีค่าอยู่ระหว่าง [0, 1]
- C_t แทน สถานะเซลล์ช่วงเวลาปัจจุบัน มีค่าอยู่ระหว่าง [0, 1]
- $\widetilde{C_t}$ แทน สถานะเซลล์ผู้สมัครช่วงเวลาปัจจุบัน
- h_t แทน ผลลัพธ์ของช่วงเวลาปัจจุบัน
- W_i แทน น้ำหนักของ Input Gate
- b_i แทน ค่าเอนเอียงของ Input Gate
- W_c แทน น้ำหนักของ Candidate Input Gate
- b_c แทน ค่าเอนเอียงของ Candidate Input Gate
- W_f แทน ค่าเอนเอียงของ Forget Gate
- b_f แทน ค่าเอนเอียงของ Forget Gate
- W_o แทน น้ำหนักของ Output Gate
- b_o แทน ค่าเอนเอียงของ Output Gate

2.5 เครือข่ายประตูวกกลับ (Gated Recurrent Units: GRU)

เครือข่ายประตูวกกลับ เป็นรูปแบบหนึ่งของเครือข่ายระบบประสาทแบบย้อนกลับที่ถูกพัฒนาขึ้นเพื่อแก้ไขปัญหา Vanishing Gradient ซึ่งเป็นปัญหาที่เกิดขึ้นในเครือข่าย RNN ที่มีหน่วยความจำระยะสั้น โดยเฉพาะในบริบทของการประมวลผลข้อมูลลำดับยาว ๆ เช่นเดียวกับ LSTM และ GRU ได้รับการออกแบบมาเพื่อเก็บรักษาข้อมูลระยะยาวโดยลดความซับซ้อนของการคำนวณ โดยลดจำนวนประตู (Gate) จากสามประตูใน LSTM ลงเหลือเพียงสองประตู ได้แก่ ประตูรีเซ็ต (Reset Gate) และประตูอัพเดต (Update Gate) เพื่อลดภาระในการคำนวณและเพิ่มความเร็วในการประมวลผล

1) ประตูอัพเดต (Update Gate: z) มีหน้าที่ในการคำนวนค่าถ่วงน้ำหนักของค่า Hidden State ก่อนหน้า กับค่าสถานะผู้ท้าชิงในปัจจุบันเพื่อใช้สำหรับการคำนวนค่าสถานะในปัจจุบัน โดยคำนวนจากข้อมูลนำเข้าในปัจจุบันและค่าสถานะชั้นซ่อนก่อนหน้า ประตูนี้ถูกควบคุมโดยฟังก์ชัน Sigmoid (σ) ซึ่งให้ผลลัพธ์ที่มีค่าอยู่ระหว่าง [0,1] เพื่อทำการตัดสินใจว่าจะมีการรับสัญญาณจากค่าสถานะชั้นซ่อนก่อนหน้าในอัตราส่วนเท่าใด การคำนวณค่าของ Update Gate แสดงดังสมการที่ (9)

$$z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (9)$$

2) ประตูรีเซ็ต (Reset Gate: r) ในเครือข่าย GRU มีหน้าที่ในการคำนวนค่าถ่วงน้ำหนักของค่าสถานะชั้นซ่อนในลำดับก่อนหน้า โดยจะคำนวนจากข้อมูลนำเข้าในลำดับปัจจุบันและค่าสถานะชั้นซ่อนในลำดับก่อนหน้า ตัดสินใจว่าควรปรับเปลี่ยนสถานะของเซลล์เมื่อมีข้อมูลใหม่เข้ามาหรือไม่ ประตูนี้ถูกควบคุมโดยฟังก์ชัน Sigmoid (σ) ซึ่งให้ผลลัพธ์ที่มีค่าอยู่ระหว่าง [0,1] ในกระบวนการคำนวณนี้จะใช้ข้อมูลนำเข้าปัจจุบันและสถานะซ่อน (Hidden State) ก่อนหน้า การคำนวณของ Reset Gate สามารถแสดงได้ดังสมการที่ (10)

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (10)$$

หลังจากที่ได้สมการของประตูทั้งสอง ขั้นตอนถัดไปคือการคำนวณ Output ที่ทำนายในสถานะชั้นซ่อน ณ เวลาปัจจุบัน ($\widetilde{h_t}$) คำนวณจากการรวมกันของข้อมูลนำเข้าที่เวลาปัจจุบัน (x_t) คูณกับเมทริกซ์ค่าถ่วงน้ำหนักของ Output (W_{xh}) กับการทำ Element-wise product ($\odot$) ระหว่าง Reset Gate (r) และ Hidden State ก่อนหน้าเพื่อตัดสินใจว่าเราควรใช้ Hidden State ก่อนหน้าในระดับใด ผลลัพธ์จากการทำ Element-wise product ($\odot$) ถูกคูณกับเมทริกซ์ค่าถ่วงน้ำหนักของ Update Gate ดังนั้น การคำนวณค่าดังกล่าวทำได้ดังสมการที่ (11)

$$\widetilde{h_t} = \tanh(W_{xh}x_t + W_{hh}(r_t \odot h_{t-1})) \quad (11)$$

เนื่องจากฟังก์ชันกระตุ้นที่ใช้คือ ฟังก์ชัน Hyperbolic Tangent ซึ่งเป็น Nonlinear Function ค่าที่ได้จะอยู่ในช่วง [-1,1] ฟังก์ชันนี้ช่วยป้องกันปัญหา Vanishing Gradient เนื่องจากมันจำกัดค่าผลลัพธ์ให้อยู่ในช่วงที่กำหนด ทำให้สามารถคำนวณค่าการแพร่กลับของความผิดพลาด (Backpropagation) ได้โดยค่าที่ได้ไม่เป็นค่าอนันต์ ซึ่งช่วยให้กระบวนการเรียนรู้ของโมเดลมีความเสถียรมากขึ้น

ขั้นตอนสุดท้าย คือ การคำนวณสถานะชั้นซ่อน ณ เวลา t เพื่อใช้เป็นผลลัพธ์สุดท้าย หรือเพื่อทำการตัดสินใจว่าควรปรับเปลี่ยนค่าเป็นค่าใดระหว่างผลลัพธ์ที่ทำนายได้จากสถานะชั้นซ่อนก่อนหน้า ($\widetilde{h_t}$) และผลลัพธ์ที่ทำนายได้จากสถานะชั้นซ่อนปัจจุบัน (h_t) ในสัดส่วนที่กำหนด สมการสำหรับการคำนวณสามารถคำนวณได้ดังสมการที่ (12)

$$h_t = (1 - z_t)h_{t-1} + z_t\widetilde{h_t} \quad (12)$$

เมื่อ z_t แทน ค่าถ่วงน้ำหนักของ Update Gate
x_t แทน ค่าของข้อมูลนำเข้า ณ เวลา t
h_t แทน ค่าของ Hidden Vector Activation ณ เวลา t
h_{t-1} แทน ค่าของ Hidden Vector Activation ณ เวลา t-1
$\widetilde{h_t}$ แทน ค่า Candidate Hidden Vector Activation ณ เวลา t
z_t แทน ค่าถ่วงน้ำหนักของ Update Gate
r_t แทน ค่าถ่วงน้ำหนักของ Reset Gate
h_{t-1} แทน ค่าของ Hidden Vector Activation ณ เวลา t-1
W_{xz} และ W_{hz} แทน เมทริกซ์น้ำหนักของ Update Gate
W_{xr} และ W_{hr} แทน เมทริกซ์น้ำหนักของ Reset Gate
W_{xh} และ W_{hh} แทน เมทริกซ์น้ำหนักของ Candidate Hidden Vector Activation
b_z แทน ค่าเอนเอียงของ Update Gate
b_r แทน ค่าเอนเอียงของ Reset Gate

2.6 แบบจำลองการเรียนรู้เชิงลึกแบบผสม (Hybrid Deep Learning Model)

แบบจำลองการเรียนรู้เชิงลึกแบบผสม ซึ่งเป็นการผสมผสานของเทคนิคของแบบจำลองการ Deep Learning หลาย ๆ แบบเข้าด้วยกัน เช่น RNN, LSTM, และ GRU เพื่อเพิ่มประสิทธิภาพในวิเคราะห์ข้อมูล มีความสามารถในการจัดการกับข้อมูลที่ซับซ้อนมากขึ้น ลดข้อจำกัดของแบบจำลองและสามารถปรับตัวให้เข้ากับการใช้งานที่หลากหลายได้ดีขึ้น

2.6.1 Cascaded Neural Network

Zhang (2003) นำเสนอแบบจำลองอนุกรมเวลาแบบผสมที่มีสมมติฐานว่าข้อมูลอนุกรมเวลาที่นำมาวิเคราะห์ประกอบด้วยสององค์ประกอบ ได้แก่ องค์ประกอบเชิงเส้นและองค์ประกอบที่ไม่เป็นเส้น การนำแบบจำลอง ARIMA ซึ่งเป็นฟังก์ชันเชิงเส้นมาผสานกับแบบจำลอง ANN ที่ใช้สำหรับการพยากรณ์ข้อมูลที่ไม่เป็นฟังก์ชันเชิงเส้นตรง ทางผู้วิจัยได้นำแนวคิดดังกล่าวมาประยุกต์ใช้กับการผสมแบบจำลอง Deep Learning โดยแบบจำลอง Deep Learning สามารถวิเคราะห์ได้ทั้งสององค์ประกอบ อย่างไรก็ตามยังคงมี Residual จากการพยากรณ์เหลืออยู่ ดังนั้นผู้วิจัยจึงนำแบบจำลอง Deep Learning อื่น ๆ มาช่วยในการพยากรณ์ส่วนเหลือ เพื่อปรับปรุงผลลัพธ์ในการพยากรณ์ มีขั้นตอนการสร้างดังภาพที่ 1 และดังสมการที่ (13)

$$Y_t = F_t^v + F_t^\varepsilon + \varepsilon_t \quad (13)$$

เมื่อ Y_t แทน ผลลัพธ์สุดท้ายจากการพยากรณ์ข้อมูลอนุกรมเวลา ณ เวลาที่ t
F_t^v แทน ข้อมูลที่ได้จากการพยากรณ์ด้วยแบบจำลองการเรียนรู้เชิงลึกที่หนึ่ง
F_t^ε แทน ส่วนเหลือที่ได้จากการพยากรณ์ด้วยแบบจำลองการเรียนรู้เชิงลึกที่สอง
ε_t แทน ค่าความคลาดเคลื่อนสุดท้าย ณ เวลาที่ t

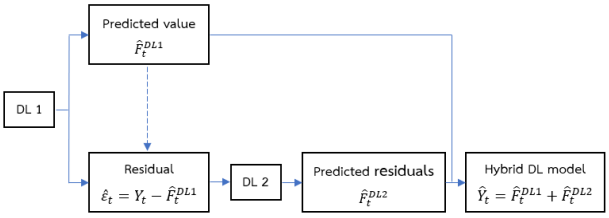

ภาพที่ 1: กระบวนการสร้างแบบจำลองการเรียนรู้เชิงลึกแบบผสมแบบ Cascaded Neural Network

โดยมีขั้นตอนการสร้างมีดังนี้

ขั้นตอนที่ 1 วิเคราะห์ข้อมูลอนุกรมเวลาด้วยแบบจำลองการเรียนรู้เชิงลึกแบบจำลองแรก เพื่อให้ได้ค่าพยากรณ์ (Predicted Value) ในเทอมของค่าพารามิเตอร์ คือ $\hat{F}_t^{DL1}$

ขั้นตอนที่ 2 คำนวณค่าส่วนเหลือ (Residuals) จากแบบจำลองการเรียนรู้เชิงลึกแบบจำลองแรก ดังสมการที่ (14)

$$\hat{\varepsilon}_t = Y_t - \hat{F}_t^{DL1} \quad (14)$$

ขั้นตอนที่ 3 นำค่าส่วนเหลือที่ได้จากแบบจำลองไปพยากรณ์ด้วยแบบจำลองการเรียนรู้เชิงลึกแบบจำลองที่สอง เพื่อหาค่าพยากรณ์ความคลาดเคลื่อน (Predicted Residuals) ในเทอมของค่าพารามิเตอร์ คือ $\hat{F}_t^{DL2}$

ขั้นตอนที่ 4 คำนวณหาค่าพยากรณ์โดยนำค่าจากขั้นตอนที่ 1 และขั้นตอนที่ 3 มารวมกันดังสมการที่ (15)

$$\hat{Y}_t = \hat{F}_t^{DL1} + \hat{F}_t^{DL2} \quad (15)$$

เมื่อ $\hat{Y}_t$ แทน ผลลัพธ์สุดท้ายจากการพยากรณ์ข้อมูลอนุกรมเวลา ณ เวลาที่ t
$\hat{F}_t^{DL1}$ แทน ค่าที่ได้จากการพยากรณ์ด้วยแบบจำลองการเรียนรู้เชิงลึกที่หนึ่ง
$\hat{F}_t^{DL2}$ แทน ค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยแบบจำลองการเรียนรู้เชิงลึกที่สอง

2.6.2 Stacked Layers

เป็นการผสมผสานสถาปัตยกรรมหลายแบบเข้าด้วยกันโดยจัดเรียงเป็นชั้นต่อเนื่องกันตามลำดับ ในเครือข่ายประสาทเทียม เรียกว่า "Stacked" เพื่อให้ข้อมูลสามารถไหลผ่านโมเดลได้อย่างมีประสิทธิภาพ การจัดเรียงซ้อนชั้น (Stacked Layers) ทำให้ตรวจจับรูปแบบที่เกิดขึ้นในระยะสั้นและระยะยาวได้ดี ด้วยเหตุนี้ Stacked Layer สามารถเรียนรู้และจดจำรูปแบบข้อมูลในลำดับที่ยาวขึ้นได้ และในขณะเดียวกันยังสามารถวิเคราะห์ข้อมูลจากสถานะปัจจุบันโดยอ้างอิงข้อมูลจากสถานะก่อนหน้าได้ โดยตัวอย่างสถาปัตยกรรมของ Stacked Layers เป็นการซ้อนกันระหว่าง RNN และ RNN ดังภาพที่ 2

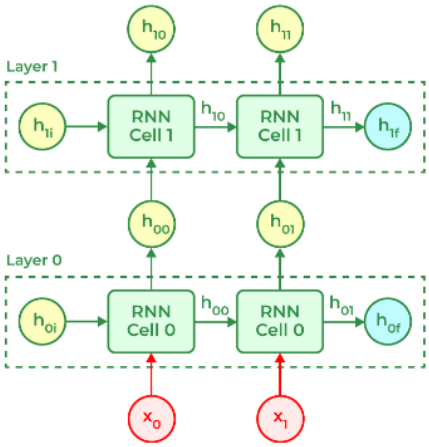

ภาพที่ 2: สถาปัตยกรรมของของเครือข่ายประสาทเทียมแบบซ้อนชั้นอย่างง่าย RNN และ RNN

โดย x_0 และ x_1 คือ ข้อมูลนำเข้าถูกป้อนสู่ RNN Cell 0 ซึ่งทำการประมวลผลและส่งออกมาเป็นสถานะซ่อนที่มีค่า h_{00} และ h_{01} สถานะซ่อนสุดท้ายของเลเยอร์นี้ คือ h_{0f} จากนั้นสถานะซ่อนที่มีค่า h_{00} และ h_{01} จะถูกนำมาใช้เป็นข้อมูลนำเข้าสำหรับเลเยอร์ 1 ใน RNN Cell 1 เลเยอร์นี้ทำการประมวลผลข้อมูลที่ได้รับและส่งออกมาเป็นสถานะซ่อน h_{10} และ h_{11} และได้สถานะซ่อนสุดท้ายของเลเยอร์นี้ คือ h_{1f}

3. ผลการวิจัยและอภิปรายผล

งานวิจัยนี้นำเสนอเปรียบเทียบประสิทธิภาพและระยะเวลาที่ใช้ของ Hybrid Deep Learning Models ในรูปแบบ Stacked Layer และ Cascaded Neural Network ในระยะสั้น 7 วัน และระยะยาว 30 วัน โดยแบ่งเป็น 3 ส่วน ในส่วนที่ 1 จากการทดสอบทางสถิติด้วย Wilcoxon's Signed Rank เพื่อการเปรียบเทียบประสิทธิภาพจากการสลับลำดับก่อน-หลังระหว่างแบบจำลอง RNN/LSTM, RNN/GRU, and LSTM/GRU ในการผสมแบบจำลองด้วยวิธี Cascaded Neural Network และ Stacked Layer ดังตารางที่ 2-3 พบว่า P-Value ของ Metric ในการพยากรณ์ระยะสั้น 7 วันและระยะยาว 30 วัน มีค่ามากกว่า 0.05 ในทุกกรณี จึงสรุปได้ว่าค่ามัธยฐานของ Metric ไม่แตกต่างกันอย่างมีนัยสำคัญหรือการสลับลำดับของแบบจำลองในวิธี Cascaded Neural Network และ Stacked Layers ไม่ส่งผลต่อประสิทธิภาพของ Hybrid Models

ตารางที่ 2: P-Value จากการทดสอบ Wilcoxon's Signed Rank เพื่อเปรียบเทียบประสิทธิภาพของการสลับแบบจำลองที่ใช้การผสมแบบ Stacked Layer

Combination Model	Metric	P-Value	
		7-Day	30-Day
RNN/LSTM	MAPE (%)	0.2078	0.4543
	RMSE	0.3028	0.8469
RNN/GRU	MAPE (%)	0.8904	0.3028
	RMSE	0.7615	0.6788
LSTM/GRU	MAPE (%)	0.2933	0.4887
	RMSE	0.3591	0.0901

ตารางที่ 3: P-Value จากการทดสอบ Wilcoxon's Signed Rank เพื่อเปรียบเทียบประสิทธิภาพของการสลับแบบจำลองที่ใช้การผสมแบบ Cascaded Neural Network

Combination Model	Metric	P-Value	
		7-Day	30-Day
RNN/LSTM	MAPE (%)	0.1205	0.2078
	RMSE	0.4212	0.5245
RNN/GRU	MAPE (%)	0.2524	0.5995
	RMSE	0.1673	0.5995
LSTM/GRU	MAPE (%)	0.8469	0.1514
	RMSE	0.5245	0.0637

ตารางที่ 4: P-Value จากการทดสอบ Wilcoxon's Signed Rank เพื่อเปรียบเทียบประสิทธิภาพ Hybrid Deep Learning Model ระหว่าง Stacked Layer และ Cascaded Neural Network

Combination	Metric	P-value	
		7-Day	30-Day
RNN-LSTM	MAPE (%)	0.0479*	0.8040
	RMSE	0.0034*	0.8904
LSTM-RNN	MAPE (%)	0.0637	0.3591
	RMSE	0.0181*	0.1688
RNN-GRU	MAPE (%)	0.1514	0.3028
	RMSE	0.0067*	0.3303
GRU-RNN	MAPE (%)	0.2293	0.5614
	RMSE	0.0256*	0.9780
LSTM-GRU	MAPE (%)	0.8647	0.6788
	RMSE	0.0181*	0.8469
GRU-LSTM	MAPE (%)	0.7197	0.8040
	RMSE	0.0054*	0.7982

* แตกต่างกันอย่างมีนัยสำคัญ ที่ระดับนัยสำคัญ 0.05

ในส่วนที่ 2 จากการทดสอบทางสถิติด้วย Wilcoxon's Signed Rank เพื่อเปรียบเทียบประสิทธิภาพระหว่าง การสร้าง Hybrid Deep Learning Model ด้วยวิธี Stacked Layers กับวิธี Cascaded Neural Network ดังตารางที่ 4 ในการพยากรณ์ระยะสั้น 7 วัน หากพิจารณาด้วย RMSE จะพบว่า P-Value ที่ได้น้อยกว่าระดับนัยสำคัญที่ 0.05 ในทุก Combination สรุปได้ว่าค่ามัธยฐานของ RMSE ของวิธี Cascaded Neural Network แตกต่างกับ Stacked Layers อย่างมีนัยสำคัญ หรือ สรุปได้ว่าการสร้าง Hybrid Model ด้วย Cascaded Neural Network มีประสิทธิภาพที่แตกต่างกับการใช้ Stacked Layers โดยที่ Cascaded Neural Network จะให้ประสิทธิภาพที่ดีกว่าเมื่อเทียบกับ Stacked Layers หากสร้าง Hybrid Model ด้วย LSTM-GRU แต่ส่วนกรณีที่ Hybrid model ถูกสร้างโดยคู่อื่น ๆ Stacked layers จะให้ประสิทธิภาพที่ดีกว่าเมื่อเทียบกับ Cascaded Neural Network และหากพิจารณาด้วย MAPE (%) จะพบว่าในกรณีที่ Hybrid model ถูกสร้างโดย RNN-LSTM จะให้ P-value ที่น้อยกว่าระดับนัยสำคัญที่ร้อยละ 5 แสดงว่ากรณีนี้ค่ามัธยฐานของ MAPE (%) ของวิธี Cascaded Neural Network แตกต่างกับ Stacked Layers อย่างมีนัยสำคัญ หรือ

อีกนัยหนึ่งการสร้าง Hybrid Model ด้วย Cascaded Neural Network มีประสิทธิภาพที่แตกต่างกับการใช้ Stacked Layers โดยที่ Cascaded Neural Network จะให้ประสิทธิภาพที่ดีกว่าเมื่อเทียบกับ Stacked Layers หากสร้าง Hybrid Model ด้วย RNN-LSTM ส่วนกรณีที่ Hybrid Model ถูกสร้างโดยคู่อื่น ๆ จะให้ P-value ที่มากกว่าระดับนัยสำคัญที่ 0.05 แสดงว่ากรณีนี้ค่ามัธยฐานของ MAPE (%) ของวิธี Cascaded Neural Network ไม่แตกต่างกับ Stacked Layers อย่างมีนัยสำคัญ หรือการสร้างแบบจำลองผสมด้วย Cascaded Neural Network มีประสิทธิภาพที่ไม่แตกต่างกับการใช้ Stacked Layers

ในส่วนของการพยากรณ์ระยะยาว 30 วัน P-Value ของ Evaluation Metric MAPE (%) และ RMSE, Hybrid Deep Learning Model มีค่ามากกว่า 0.05 ในทุก Hybrid Models จึงสามารถสรุปได้ว่าค่ามัธยฐานของ Evaluation Metric ไม่แตกต่างกันอย่างมีนัยสำคัญ หรือการใช้วิธี Cascaded Neural Network มีประสิทธิภาพที่ไม่แตกต่างกับวิธี Stacked Layers

จากผลการวิเคราะห์ข้างต้นจะพบว่าประสิทธิภาพ Hybrid Deep Learning Models ระหว่าง Stacked Layer และ Cascaded Neural Network มีหลายกรณีไม่แตกต่างกันอย่างมีนัยสำคัญ ดังนั้นในส่วนที่ 3 จะทำการเปรียบเทียบระยะเวลาที่ใช้ในการสร้าง Hybrid Deep Learning Model ในทุกหุ้นพร้อมระบุแบบจำลองและวิธีการผสมที่ใช้เวลาน้อยที่สุด เพื่อแสดงให้เห็นถึงแบบจำลองและรูปแบบการผสมแบบจำลองที่เหมาะสมและคุ้มค่าที่สุดกับการนำไปใช้จริง

ในส่วนที่ 3 จากการเปรียบเทียบระยะเวลาที่ใช้ในการฝึกฝนแบบจำลอง ดังตารางที่ 7-8 พบว่า ในการพยากรณ์ระยะสั้น 7 วัน และในระยะยาว 30 วัน วิธีการสร้าง Hybrid Model ที่ใช้เวลาในการฝึกฝนแบบจำลองน้อยที่สุดในกลุ่มหุ้นที่มีความผันผวนสูง คือวิธี Stacked Layers ซึ่งให้ประสิทธิภาพไม่ต่างจากแบบจำลองที่ดีที่สุดมากนัก ในส่วนของกลุ่มความผันผวนปานกลางและความผันผวนต่ำ วิธีการสร้าง Hybrid Model ที่ใช้เวลาในการฝึกฝนแบบจำลองน้อยที่สุดคือวิธี Stacked Layers เช่นเดียวกัน แต่อาจมีบางกรณีที่ Cascaded Neural Network นั้นใช้เวลาประมวลผลที่เร็วกว่าอาทิ AMC และ HANA ในกลุ่มความผันผวนปานกลางและ KBANK ในกลุ่มความผันผวนต่ำในการพยากรณ์ระยะสั้น BCP ในกลุ่มความผันผวนปานกลางและ KBANK และ PTT ในกลุ่มความผันผวนต่ำในการพยากรณ์ระยะยาว เนื่องจากการใช้ Stacked Layers ข้อมูลต้องไหลผ่านทุกเลเยอร์โดยตรง ทำให้มีการคำนวณเชิงลึกส่งผลให้ใช้เวลามาก แต่ในส่วนของ Cascaded Neural Network เป็นการพยากรณ์เป็นสองขั้นตอนแยกกัน DL1 ไม่จำเป็นต้องเรียนรู้รายละเอียดของค่าความคลาดเคลื่อน เนื่องจาก DL2 จะทำหน้าที่ปรับค่าที่เหลือแทน หาก DL1 สามารถพยากรณ์ค่าได้แม่นยำเพียงพอ ค่า Residuals ที่เหลือจะมีขนาดเล็กมาก ทำให้ DL2 ต้องทำงานน้อยลง เนื่องจากเรียนรู้เฉพาะ Residuals ที่มีขนาดเล็กและรูปแบบไม่ซับซ้อน ทำให้คำนวณได้เร็วขึ้นในบางกรณี แม้ว่า Cascaded Neural Network อาจเร็วกว่า Stacked Layers ในบางกรณี แต่ภาพรวมวิธี Hybrid Model ที่สามารถให้ประสิทธิภาพและความคุ้มค่าในการนำมาใช้งานจริงมากที่สุด คือ Stacked Layers

4. สรุปผล

งานวิจัยนี้นำเสนอการเปรียบเทียบประสิทธิภาพและระยะเวลาที่ใช้ในการสร้าง Hybrid Deep Learning Models ในรูปแบบ Stacked layer และ Cascaded Neural Network สำหรับการพยากรณ์ในระยะสั้น 7 วัน และระยะยาว 30 วัน โดยแบ่งการศึกษาออกเป็น 3 ส่วน

ตารางที่ 7: Hybrid Deep Learning Model ที่ดีที่สุดสำหรับพยากรณ์ระยะสั้น 7 วันโดยวัดจากระยะเวลาในการฝึกฝนแบบจำลอง

Beta	Stock	Best Model by Runtime		Runtime	MAPE (%)	Range of MAPE (%)
		Model	Hybrid Method			(Min - Max)
High	XPG	LSTM – GRU	Stacked	1,710	6.732	6.043 - 8.308
	PTTGC	GRU – RNN	Stacked	1,123	3.083	2.963 - 4.274
	TOP	RNN – LSTM	Stacked	1,443	2.973	2.468 - 3.316
	RCL	GRU – RNN	Stacked	564	7.125	6.723 - 9.600
	SMT	RNN – LSTM	Stacked	3,333	4.879	4.452 - 8.708
Medium	MTC	RNN – LSTM	Stacked	2,824	3.370	2.845 - 4.468
	AMC	LSTM – GRU	Cascaded	2,929	4.472	2.539 - 4.973
	BCP	RNN – GRU	Stacked	1,918	2.876	2.672 - 3.846
	MINT	RNN – LSTM	Stacked	2,277	2.370	2.220 - 2.551
	HANA	LSTM – RNN	Cascaded	589	6.237	5.118 - 6.923
Low	KBANK	LSTM – GRU	Cascaded	1,957	2.398	1.804 - 2.398
	STANLY	RNN – LSTM	Stacked	2,987	4.140	2.493 - 4.140
	PTT	LSTM – GRU	Stacked	1,257	2.199	1.717 - 2.577
	BDMS	GRU – RNN	Stacked	1,727	1.695	1.695 - 1.908
	TRUE	RNN – LSTM	Stacked	2,933	5.842	4.280 - 6.893

ตารางที่ 8: Hybrid Deep Learning Model ที่ดีที่สุดสำหรับพยากรณ์ระยะยาว 30 วัน โดยวัดจากระยะเวลาในการฝึกฝนแบบจำลอง

Beta	Stock	Best Model by Runtime		Runtime	MAPE (%)	Range of MAPE (%) (Min - Max)
		Model	Hybrid Method			
High	XPG	RNN – GRU	Stacked	1,380	14.272	11.973 - 18.684
	PTTGC	GRU – LSTM	Stacked	1,135	5.762	5.657 - 7.966
	TOP	GRU – LSTM	Stacked	560	5.354	4.638 - 5.584
	RCL	LSTM – RNN	Stacked	1,220	12.000	11.685 - 13.558
	SMT	RNN – GRU	Stacked	559	9.770	8.510 - 15.438
Medium	MTC	RNN – GRU	Stacked	555	6.035	4.874 - 6.833
	AMC	LSTM – GRU	Stacked	1,129	3.799	2.801 - 4.859
	BCP	LSTM – GRU	Cascaded	1,481	7.626	4.981 - 7.626
	MINT	LSTM – GRU	Stacked	958	5.391	4.265 - 5.391
	HANA	LSTM – RNN	Stacked	3,102	9.355	9.215 - 10.627
Low	KBANK	GRU – RNN	Cascaded	1,503	3.648	3.184 - 4.433
	STANLY	RNN – GRU	Stacked	636	5.245	4.539 - 5.706
	PTT	GRU – LSTM	Cascaded	760	3.520	3.520 - 4.917
	BDMS	GRU – LSTM	Stacked	1,748	2.589	2.577 - 3.028
	TRUE	GRU – RNN	Stacked	1,108	11.259	10.032 - 14.363

ส่วนที่ 1 ผลการทดสอบ Wilcoxon's Signed Rank พบว่า การสลับลำดับของแบบจำลอง RNN/LSTM, RNN/GRU และ LSTM/GRU ในการสร้าง Hybrid model ด้วยวิธี Cascaded Neural Network และ Stacked Layers ไม่ส่งผลต่อประสิทธิภาพของ Hybrid Deep Learning Models

ส่วนที่ 2 การเปรียบเทียบประสิทธิภาพระหว่าง Stacked layers และ Cascaded Neural Network พบว่า ในการพยากรณ์ระยะสั้น 7 วัน หากพิจารณาด้วย RMSE วิธี Cascaded Neural Network ให้ประสิทธิภาพที่ดีกว่าเมื่อสร้าง Hybrid Model ด้วย LSTM-GRU ในขณะที่ Stacked Layers ให้ประสิทธิภาพที่ดีกว่าเมื่อใช้คู่แบบจำลองอื่นๆ ส่วนการพิจารณาด้วย MAPE (%) พบว่า Cascaded Neural Network ให้ประสิทธิภาพดีกว่าเมื่อสร้าง Hybrid Model ด้วย RNN-LSTM ในขณะที่คู่แบบจำลองอื่นๆ ไม่แตกต่างกันอย่างมีนัยสำคัญ และสำหรับการพยากรณ์ระยะยาว 30 วัน พบว่าประสิทธิภาพของทั้งสองวิธีไม่แตกต่างกันอย่างมีนัยสำคัญ

ส่วนที่ 3 การเปรียบเทียบระยะเวลาที่ใช้สร้างแบบจำลอง พบว่า โดยทั่วไปแล้ว Stacked Layers ใช้เวลาในการฝึกฝนน้อยกว่า Cascaded Neural Network ในทุกกลุ่มหุ้นที่มีความผันผวนต่างกัน แม้ว่าในบางกรณี Cascaded Neural Network อาจจะใช้เวลาประมวลผลเร็วกว่า แต่โดยรวมแล้ว Stacked Layers เป็นวิธีที่ให้ประสิทธิภาพและความคุ้มค่าในการนำมาใช้งานได้จริงในภาคธุรกิจมากกว่า

โดยสรุปแล้วแม้ว่าการสร้าง Hybrid Model ด้วยวิธี Cascaded Neural Network อาจจะมีข้อดีในบางกรณี แต่การสร้างด้วยวิธี Stacked layers เป็นทางเลือกที่เหมาะสมกว่าสำหรับการสร้าง Hybrid Deep Learning Models สำหรับการพยากรณ์ เนื่องจากให้ประสิทธิภาพที่ไม่ต่างกันอย่างมีนัยสำคัญ ใช้เวลาในการฝึกฝนและทรัพยากรในการสร้าง Hybrid Deep Learning Model น้อยกว่า

5. เอกสารอ้างอิง

[1] Liu Y, Wang Z, Zheng B. Application of regularized GRU-LSTM model in stock price prediction. In: 2019 IEEE 5th International Conference on Computer and Communications (ICCC); 2019; Chengdu, China. IEEE; 2019.

[2] Althelaya, K.A., El-Alfy, E.-S. M., Mohammed, S. Evaluation of bidirectional LSTM for short- and long-term stock market prediction. In: 2018 9th International Conference on Information and Communication Systems (ICICS); 2018; Jordan. IEEE; 2018. 151-156.

[3] Hossain M.A., Karim R., Thulasiram R., Bruce NDB., Wang Y. Hybrid deep learning model for stock price prediction. In: 2018 IEEE Symposium Series on Computational Intelligence (SSCI); 2018; Bengaluru, India. IEEE; 2018. 1837-1844.

[4] นัท กุลวานิช. การเพิ่มความแม่นยำในการพยากรณ์ข้อมูลอนุกรมเวลาด้วยตัวแบบผสม ARIMA-ANN และการวิเคราะห์การถดถอย. วารสารวิทยาศาสตร์และเทคโนโลยี. 2563; 28(12): 2101-2112.

[5] Khairalla M, Ning X, AL-Jallad NT. Hybrid forecasting scheme for financial time-series data using neural network and statistical methods. International Journal of Advanced Computer Science and Applications (IJACSA). 2017; 17(8): 319-327.

[6] รักษ์คณา ภูสีเขียว. การพยากรณ์ปริมาณน้ำฝนระยะสั้นในบริเวณพื้นที่สนามบินสุวรรณภูมิด้วยโครงข่ายระบบประสาทแบบย้อนกลับ [วิทยานิพนธ์ปริญญาโท]. จุฬาลงกรณ์มหาวิทยาลัย; 2564. สืบค้นจาก: https://doi.org/10.58837/CHULA.THE.2021.1060.

การพัฒนาโมเดลการเรียนรู้ของเครื่องสำหรับการวิเคราะห์และทำนายความเสี่ยงจากการโจมตีแบบสุ่มเดารหัสผ่านบนคลาวด์เซิร์ฟเวอร์

Development of a Machine Learning Model for Analyzing and Predicting Risks of Brute-Force Attacks on Cloud Server

ภูวเดช ประทุม* เอกชัย แซ่จึง สุภาวดี พบพิมาย จงกล จันทร์เรือง

คณะวิทยาศาสตร์และศิลปศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน

(* *phuwadech.pr@rmuti.ac.th*)

บทคัดย่อ

ในยุคดิจิทัลที่ภัยคุกคามทางไซเบอร์ทวีความรุนแรงมากขึ้น การโจมตีแบบสุ่มเดารหัสผ่าน (Brute Force Attack) เป็นหนึ่งในความเสี่ยงสำคัญต่อระบบคลาวด์เซิร์ฟเวอร์ ซึ่งอาจนำไปสู่การเข้าถึงข้อมูลโดยไม่ได้รับอนุญาต การสูญเสียข้อมูลทางการเงิน และกระทบต่อความปลอดภัยขององค์กร งานวิจัยนี้นำเสนอการใช้ Machine Learning โดยการใช้อัลกอริทึม Random Forest ซึ่งเป็นโมเดลประเภท Classification เพื่อวิเคราะห์และทำนายการโจมตีดังกล่าว โมเดลได้รับการฝึกอบรมด้วยข้อมูลพฤติกรรมการเข้าสู่ระบบที่ผิดปกติผ่านโปรโตคอล SSH (Port 22) ซึ่งเก็บระหว่าง 1 กรกฎาคม - 31 สิงหาคม 2567 รวม 93,360 รายการ ผลการทดลองแสดงให้เห็นว่าโมเดลสามารถตรวจจับการโจมตีได้อย่างแม่นยำ โดยมี Accuracy 98.00%, Precision 98.00%, Recall 98.00% และ F1 Score 97.00% ซึ่งสะท้อนถึงประสิทธิภาพของโมเดลในการป้องกันภัยคุกคามทางไซเบอร์

คำสำคัญ: ความปลอดภัยทางไซเบอร์, การโจมตีแบบสุ่มเดารหัสผ่าน, การเรียนรู้ของเครื่อง

Abstract

In the digital era, as cyber threats intensify, Brute Force Attacks pose a significant risk to cloud servers, potentially leading to unauthorized access, financial data loss, and compromising organizational security. This research presents the use of Machine Learning with the Random Forest algorithm, a Classification model, to analyze and predict such attacks. The model was trained using data on abnormal login behavior via the SSH protocol (Port 22), collected between July 1 and August 31, 2024, totaling 93,360 entries. Experimental results demonstrated that the model accurately detected attacks, achieving an Accuracy of 98.00%, Precision of 98.00%, Recall of 98.00%, and an F1 Score of 97.00%, reflecting the model's effectiveness in preventing cyber threats.

Keywords: Cyber Security, Brute Force Attack, Machine Learning

1. บทนำ

ปัจจุบันการโจมตีทางไซเบอร์ (Cyber Attack) มีจำนวนมากขึ้นเรื่อย ๆ และเริ่มมีความรุนแรงที่อาจส่งผลกระทบต่อตัวระบบเป็นอย่างมาก นอกจากนี้ ความซับซ้อนเกี่ยวกับการโจมตีก็เริ่มมีความยากต่อการทำความเข้าใจ ไม่ว่าจะเป็นการโจมตีที่เซิฟเวอร์โดยตรงหรือที่ตัวเว็บไซต์เองก็ตาม ต่างก็ก่อให้เกิดความเสียหายเช่นเดียวกัน ดังนั้น เรื่องของความปลอดภัยไซเบอร์ (Cyber Security) จึงจะต้องมีการให้ความสำคัญเป็นอย่างมาก โดยเฉพาะเรื่องของข้อมูล ไม่ว่าจะเป็นข้อมูลลูกค้า ข้อมูลขององค์กร หรือข้อมูลที่มีความอ่อนไหวต่อการถูกเผยแพร่บนโลกอินเทอร์เน็ต เช่น ข้อมูลหมายเลขบัตรประชาชน ข้อมูลเบอร์โทรศัพท์ ข้อมูลทางการเงิน ข้อมูลการซื้อขาย เป็นต้น ดังนั้น เรื่องของความปลอดภัยทางไซเบอร์ (Cyber Security) จึงได้มีการถูกให้ความสำคัญในยุคปัจจุบัน เนื่องจากในปัจจุบัน ภัยคุกคามที่มาจากโลกอินเทอร์เน็ตมีมากมายหลายรูปแบบ ยกตัวอย่าง เช่น Malware ที่เป็นการแพร่กระจายไวรัสเพื่อให้ตัวระบบเกิดปัญหา หรือ Ransomware ที่เป็นการเข้ารหัสข้อมูลเพื่อทำการเรียกค่าใช้จ่ายในการปลดล็อกจากผู้ดูแลระบบหรือองค์กร โดยมีสถิติการโจมตีเพิ่มขึ้นจากปี 2565 ถึง 42% ในปี 2566 หรือจะเป็นการโจมตีในรูปแบบของ Phishing ที่จะเป็นการหลอกลวงด้วยวิธีการดักเอาชื่อผู้ใช้งานและรหัสผ่านจากผู้ใช้งาน ผ่าน

ลิ้งค์ที่ไม่น่าเชื่อถือโดยอาจถูกส่งผ่านอีเมล ข้อความบนมือถือ หรืออาจจะเป็น แชทจากโซเชียลมิเดีย โดยมีสถิติการโจมตีเพิ่มขึ้น 36.6% ในปี 2567 ซึ่งกระบวนการโจมตีจากตัวอย่างที่กล่าวมาทั้งหมด จะมีความเกี่ยวข้องกับการเรื่องของการโจมตีแบบสุ่มเดารหัสผ่าน (Brute-Force Attack) ตัวอย่างเมื่อผู้โจมตีทำการดักเอารหัสผ่านได้ ก็อาจจะนำไปทดลองกับการสุ่มเดารหัสผ่านในกรณีที่ผู้ใช้ให้รหัสที่ใกล้เคียงหรือกรอกรหัสผ่านผิด และเมื่อเข้าใช้งานระบบโดยไม่ได้รับอนุญาตได้แล้ว ก็อาจจะทำให้ส่งผลกระทบที่ร้ายแรงต่อตัวระบบได้ เช่น การขโมยข้อมูลส่วนตัว การแพร่กระจายไวรัส (Malware) หรือ การทำให้ชื่อเสียงของเว็บไซต์เกิดความเสียหาย โดยจะทำให้ความน่าเชื่อถือของเว็บไซต์ลดลงเป็นอย่างมาก สามารถดูเพิ่มเติมได้จาก [5]

การโจมตีที่พบได้บ่อยคือการโจมตีแบบ SSH Brute-Force Attack ที่โจมตีไปที่โปรโตคอล 22 (SSH) ของเซิร์ฟเวอร์ โดยผู้โจมตีจะพยายามสุ่มเดารหัสผ่านเพื่อเข้าสู่ระบบเซิร์ฟเวอร์ผ่านการใช้งานที่ไม่ได้รับอนุญาต ซึ่งทำให้เกิดความเสี่ยงในการบุกรุกเข้าสู่ระบบ อาจส่งผลให้เกิดความเสียหายกับข้อมูลหรือแม้กระทั่งการแพร่กระจายไวรัส (Malware) ไปในระบบอื่น ๆ โดยข้อมูลการพยายามโจมตีเหล่านี้มักจะถูกบันทึกในไฟล์ Log ซึ่งเป็นข้อมูลที่สามารถนำมาใช้ในการพัฒนาโมเดล Machine Learning (ML) เพื่อวิเคราะห์และทำนายพฤติกรรมการโจมตี รวมทั้งประเมินความเสี่ยงที่จะเกิดขึ้น

การใช้เทคโนโลยีการเรียนรู้ของเครื่องในการวิเคราะห์การโจมตีประเภท SSH Brute-Force Attack สามารถนำข้อมูลจาก SSH Log ของเซิร์ฟเวอร์ มาใช้สำหรับฝึกโมเดลเพื่อให้สามารถตรวจจับพฤติกรรมที่ไม่ปกติ อย่างไรก็ตามการใช้ Machine Learning ในการตรวจจับภัยคุกคามยังมีข้อจำกัดที่ต้องคำนึงถึง เช่น การเลือกข้อมูลที่เหมาะสม การขาดหายของข้อมูล หรือการจัดการกับข้อมูลที่ไม่เคยพบมาก่อน (Zero-day attacks) ซึ่งอาจส่งผลให้โมเดลไม่สามารถตรวจจับภัยคุกคามที่ไม่เคยเกิดขึ้นในอดีตได้ อีกทั้งยังต้องให้ความสำคัญกับการเลือกคุณสมบัติ (Feature Selection) ที่เหมาะสมเพื่อหลีกเลี่ยงการเกิด Overfitting

ด้วยเทคโนโลยีที่พัฒนาอย่างรวดเร็วและข้อจำกัดต่าง ๆ ที่กล่าวถึง การประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องเข้ากับเทคนิคอื่น ๆ ร่วมด้วย อาจทำให้ได้ระบบที่มีประสิทธิภาพมากยิ่งขึ้น เช่น ELK Stack (Elasticsearch, Logstash, Kibana) เพื่อพัฒนาเป็นระบบตรวจจับการบุกรุก (Intrusion Detection System) ที่สามารถแสดงข้อมูลและการประเมินพฤติกรรมจากโมเดลในรูปแบบ Real-time Visualization Dashboard ซึ่งช่วยให้ผู้ดูแลระบบสามารถรับรู้ภัยคุกคามได้ทันท่วงที และสามารถรับมือกับการโจมตีได้ ทั้งนี้ การพัฒนาระบบในลักษณะนี้จะช่วยเพิ่มความปลอดภัยให้กับระบบและข้อมูลภายในองค์กร ตลอดจนป้องกันการโจมตีทางไซเบอร์ที่อาจเกิดขึ้นได้ในอนาคต สามารถดูเพิ่มเติมได้ที่ [2]

2. ทฤษฎีที่เกี่ยวข้อง

2.1 ความปลอดภัยทางไซเบอร์ (Cyber Security)

กลยุทธ์และมาตรการในการปกป้องสินทรัพย์ดิจิทัลขององค์กรเป็นเรื่องที่ต้องตระหนักละให้ความสำคัญเป็นอย่างมาก ในยุคที่เทคโนโลยีและการใช้งานเครื่องมือดิจิทัลต่าง ๆ เพิ่มมากขึ้น ดังนั้น การป้องกันการโจมตีทางไซเบอร์ หรือการเข้าถึงข้อมูลโดยไม่ได้รับอนุญาต และรวมถึงการลดความเสี่ยงที่อาจส่งผลกระทบต่อความปลอดภัยของข้อมูลและระบบต่าง ๆ จึงเป็นสิ่งที่องค์กรต้องให้ความสำคัญ เนื่องจากความเสียหายที่อาจจะเกิดขึ้นจากการโจมตีทางไซเบอร์ อาจทำให้เกิดการสูญเสียข้อมูลที่สำคัญ การทำงานของระบบหยุดชะงัก หรือการเสื่อมเสียชื่อเสียงขององค์กร อาจส่งผลต่อองค์กรทั้งในด้านการเงินและความเชื่อมั่นของลูกค้า ดังนั้น การดูแลรักษาความปลอดภัยทางไซเบอร์เป็นสิ่งที่ไม่สามารถมองข้ามได้

ด้วยเหตุนี้เองจึงได้มีมาตรฐาน ISO/IEC 27001:2022 ซึ่งถือเป็นกรอบการทำงานที่ได้รับการยอมรับในระดับสากลในการจัดการความปลอดภัยของข้อมูล โดยมุ่งเน้นในการประเมินและจัดการความเสี่ยงที่อาจเกิดขึ้นจากภัยคุกคามต่าง ๆ ที่สามารถส่งผลกระทบต่อองค์กร รวมถึงการโจมตีทางไซเบอร์ที่มีความซับซ้อนในปัจจุบัน เช่น การโจมตีด้วยวิธี Phishing, Ransomware, DDoS Attacks หรือ Brute Force Attacks มาตรฐานนี้ช่วยให้องค์กรสามารถสร้างระบบรักษาความปลอดภัยที่มีประสิทธิภาพและสามารถรับมือกับภัยคุกคามที่เกิดขึ้นได้อย่างมีระบบ

การจัดการกับเหตุการณ์หรือ Incident Management เป็นอีกหนึ่งข้อกำหนดที่สำคัญใน ISO/IEC 27001:2022 ซึ่งมุ่งเน้นให้มีการตอบสนองต่อเหตุการณ์ที่เกิดขึ้นอย่างรวดเร็วและมีประสิทธิภาพ โดยเฉพาะเมื่อเกิดเหตุการณ์ที่อาจส่งผลกระทบต่อความปลอดภัยของข้อมูล เช่น การโจมตีแบบ Brute Force หรือ SQL Injection โดยมีแผนการสำหรับตอบสนองต่อเหตุการณ์ที่จะช่วยให้องค์กรสามารถฟื้นฟูระบบและลดความเสียหายได้ในเวลาที่รวดเร็ว

หนึ่งในประเด็นสำคัญที่มาตรฐาน ISO/IEC 27001:2022 ให้ความสำคัญคือการรักษาความลับและความสมบูรณ์ของข้อมูล (Confidentiality and Integrity of Data) ซึ่งหมายถึงการป้องกันข้อมูลจากการเข้าถึงโดยไม่ได้รับอนุญาต หรือเปลี่ยนแปลงข้อมูลโดยบุคคลที่ไม่เกี่ยวข้อง ดังนั้น การเข้ารหัสข้อมูล การตรวจสอบการเข้าถึงที่เข้มงวด รวมถึงการใช้เครื่องมือการจัดการความปลอดภัยที่ทันสมัย จะช่วยปกป้องข้อมูลภายในองค์กรให้มีความปลอดภัย

อีกประเด็นที่สำคัญอีกอย่าง คือการปรับปรุงระบบความปลอดภัยอย่างต่อเนื่อง (Continuous Improvement) เป็นหลักการที่มุ่งเน้นให้องค์กรมีการทบทวนและพัฒนาระบบการจัดการความปลอดภัยของข้อมูลอย่างสม่ำเสมอ ดังนั้น มาตรการนี้จะช่วยให้มีการเพิ่มการป้องกันใหม่ ๆ และรวมถึงการเรียนรู้จากเหตุการณ์ที่เคยผ่านมาในอดีต การปฏิบัติตามข้อกำหนดของ ISO/IEC 27001:2022 จะช่วยให้ระบบรักษาความปลอดภัยของข้อมูลในองค์กรมีความยั่งยืนและพร้อม

รับมือกับภัยคุกคามที่อาจเกิดขึ้นในโลกดิจิทัลที่มีการพัฒนาอย่างรวดเร็ว สามารถดูเพิ่มเติมได้ที่ [20]

2.2 การโจมตีทางรหัสผ่าน (Password Attack)

การโจมตีทางรหัสผ่านเป็นหนึ่งในวิธีที่พบบ่อยในการโจมตีทางไซเบอร์ เนื่องจากรหัสผ่านเป็นเครื่องมือหลักในการยืนยันตัวตนและปกป้องข้อมูลสำคัญของผู้ใช้ระบบ หรือบัญชีขององค์กร การโจมตีทางรหัสผ่านสามารถทำให้ข้อมูลส่วนตัวและข้อมูลสำคัญขององค์กรถูกขโมยหรือถูกเข้าถึงโดยไม่ได้รับอนุญาต ซึ่งส่งผลกระทบต่อความปลอดภัยของข้อมูล การสูญเสียชื่อเสียง และความเสียหายทางการเงินขององค์กรได้ ตัวอย่างของการโจมตีทางรหัสผ่านที่มักเกิดขึ้นได้แก่ Brute Force Attack, Dictionary Attack, Phishing Attack, Credential Stuffing, Keylogger และ Man-in-the-Middle Attack (MitM)

Brute Force Attack เป็นการโจมตีที่ใช้วิธีการทดสอบรหัสผ่านทุกชุดจนกว่าจะพบรหัสที่ถูกต้อง โดยใช้เทคโนโลยีที่ทันสมัย เช่น GPU หรือการประมวลผลบนคลาวด์ ซึ่งช่วยเพิ่มความเร็วในการเดารหัสผ่านได้อย่างมีประสิทธิภาพ การโจมตีประเภทนี้มักจะเกิดขึ้นกับระบบที่ไม่มีการตั้งค่ามาตรการป้องกันที่เพียงพอ เช่น การไม่จำกัดจำนวนการพยายามเข้าสู่ระบบหรือการใช้รหัสผ่านที่อ่อนแอ การป้องกันการโจมตีนี้สามารถทำได้โดยการสร้างรหัสผ่านที่มีความซับซ้อน การใช้การยืนยันตัวตนแบบหลายปัจจัย (MFA) และการล็อกบัญชีเมื่อมีการพยายามเข้าสู่ระบบผิดหลายครั้ง

การโจมตีด้วย SSH Brute Force Attack เป็นการโจมตีที่มุ่งเป้าไปที่เซิร์ฟเวอร์ที่เปิดพอร์ต 22 (SSH) โดยใช้วิธีการเดารหัสผ่านหลายชุดจนกว่าจะสำเร็จ การโจมตีประเภทนี้สามารถทำให้ผู้โจมตีเข้าถึงระบบภายในองค์กรได้หากไม่มีการตั้งค่าการป้องกันที่เหมาะสม การใช้รหัสผ่านที่แข็งแกร่งและการจำกัดจำนวนการพยายามล็อกอินที่ผิดพลาดเป็นมาตรการป้องกันที่สำคัญในการลดความเสี่ยงจากการโจมตีประเภทนี้

การทดสอบการเจาะระบบ (Penetration Testing) เป็นเครื่องมือที่สำคัญในการตรวจสอบความเสี่ยงจากการโจมตีทางรหัสผ่าน เช่น SSH Brute Force Attack การทดสอบนี้จะช่วยให้ทีมงานสามารถตรวจสอบช่องโหว่ที่อาจเกิดขึ้นในระบบ รวมถึงการตั้งค่าพอร์ต SSH และการตั้งรหัสผ่านที่มีความปลอดภัย นอกจากนี้ยังสามารถทดสอบระบบที่จำกัดจำนวนการพยายามล็อกอินที่ผิดพลาดเพื่อป้องกันการโจมตีประเภทนี้ได้

กิจกรรม Ethical Hackathon เป็นอีกหนึ่งวิธีที่มีประสิทธิภาพในการพัฒนาเครื่องมือและเทคนิคในการป้องกันการโจมตีทางรหัสผ่าน การใช้เทคนิคการยืนยันตัวตนแบบหลายขั้นตอน (MFA) และการตรวจสอบการล็อกอินที่ผิดปกติเป็นตัวอย่างของวิธีการที่สามารถใช้ในการพัฒนาเครื่องมือที่ช่วยตรวจจับและป้องกันการโจมตีได้ การจัดกิจกรรมเหล่านี้ไม่เพียงแต่ช่วยเสริมสร้างความปลอดภัย แต่ยังส่งเสริมการเรียนรู้และการพัฒนาเทคโนโลยีในการป้องกันภัยคุกคามทางไซเบอร์ในระดับองค์กร

2.3 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นเทคโนโลยีสำคัญที่ช่วยเสริมสร้างความปลอดภัยทางไซเบอร์ โดยสามารถวิเคราะห์ข้อมูลจำนวนมากเพื่อระบุพฤติกรรมที่ผิดปกติและตรวจจับภัยคุกคามในระบบดิจิทัล โดยการเรียนรู้ของเครื่องสามารถแบ่งออกเป็นสองประเภทหลัก ได้แก่

(1) Supervised Learning ซึ่งอาศัยข้อมูลที่มีป้ายกำกับ (Labeled Data) ในการฝึกโมเดลให้สามารถจำแนกประเภทของภัยคุกคามได้อย่างแม่นยำ โดยใช้ตัวอย่างข้อมูลที่เคยเกิดขึ้นในอดีตเป็นพื้นฐาน อัลกอริธึมยอดนิยมในกลุ่มนี้ เช่น Decision Tree, Random Forest และ Support Vector Machine (SVM) ซึ่งสามารถเรียนรู้จากรูปแบบพฤติกรรมที่เคยเกิดขึ้นแล้วเพื่อนำมาทำนายเหตุการณ์ในอนาคต

(2) Unsupervised Learning ซึ่งทำงานกับข้อมูลที่ไม่มีการติดป้ายกำกับ โดยมุ่งเน้นการค้นหารูปแบบที่ผิดปกติหรือแนวโน้มที่อาจบ่งชี้ถึงภัยคุกคามที่ยังไม่เคยพบมาก่อน อัลกอริธึมที่นิยมใช้ในกลุ่มนี้ ได้แก่ Clustering และ Anomaly Detection เช่น K-Means Clustering และ DBSCAN ซึ่งสามารถระบุพฤติกรรมที่แตกต่างจากปกติและช่วยคาดการณ์ความเสี่ยงที่อาจเกิดขึ้นได้

ในเรื่องของการจำแนกภัยคุกคาม มีอัลกอริทึมมากมายที่ได้รับความนิยม ยกตัวอย่าง เช่น Random Forest (RF) Decision Tree (DT) และ Long Short-Term Memory (LSTM) ถูกใช้เพื่อสร้างโมเดลที่สามารถระบุพฤติกรรมความเสี่ยง นอกจากนี้ การวัดผลของโมเดลในแต่ละประเภทก็มีความสำคัญ เช่น Accuracy ในโมเดลประเภท Supervised Learning ซึ่งการวัดผลจะช่วยเพิ่มความมั่นใจในการตรวจจับภัยคุกคามได้

การใช้ Machine Learning เพื่อตรวจจับการโจมตี SSH Brute Force นั้น งานวิจัยในด้าน ความปลอดภัยไซเบอร์ ได้มีการนำเทคนิคนี้มาใช้และพัฒนาอย่างต่อเนื่อง โดยมีการใช้ข้อมูลจาก SSH logs หรือแหล่งข้อมูลอื่นๆ เพื่อฝึกสอนโมเดลในลักษณะต่าง ๆ เช่น Random Forest, Support Vector Machines (SVM) และ Neural Networks ซึ่งการเลือกใช้เทคนิคเหล่านี้ขึ้นอยู่กับลักษณะของข้อมูลและลักษณะของภัยคุกคามที่ต้องการตรวจจับ สามารถดูเพิ่มเติมได้ที่ [19]

งานวิจัย Intrusion detection using Random Forest for SSH Brute Force attacks ได้ใช้ Random Forest ในการตรวจจับการโจมตีประเภท Brute Force โดยมีการปรับแต่งและเลือกคุณสมบัติที่สำคัญจากข้อมูลบันทึกการล็อกอินหลายประเภท ซึ่งพบว่าโมเดล Random Forest มีความสามารถในการตรวจจับการโจมตีได้แม่นยำกว่าหลายๆ เทคนิคที่ใช้ข้อมูลจาก SSH logs เพียงอย่างเดียว อีกทั้งยังช่วยในการลด false positives ซึ่งเป็นความท้าทายที่สำคัญในการพัฒนาโมเดลสำหรับการตรวจจับภัยคุกคามไซเบอร์ สามารถดูเพิ่มเติมได้ที่ [18]

การประยุกต์ใช้ทฤษฎี Machine Learning ในการตรวจจับการโจมตี SSH Brute Force สามารถนำมาปรับใช้ในสถานการณ์จริงเพื่อเสริมสร้างระบบรักษาความปลอดภัยและบริหารความเสี่ยงในองค์กรได้อย่างมีประสิทธิภาพ ซึ่งการนำทฤษฎีที่นำเสนอมาใช้จะส่งผลในหลายด้าน ดังนี้

(1) การตรวจจับภัยคุกคามแบบเรียลไทม์ (Real-time Threat Detection) ช่วยให้สามารถตรวจจับการโจมตีแบบ Brute Force ได้อย่างรวดเร็วและแม่นยำ โดยไม่ต้องพึ่งพาการวิเคราะห์จากข้อมูลที่ถูกกำหนดไว้ล่วงหน้า (Signature-based Detection) ช่วยให้ระบบรักษาความปลอดภัยตอบสนองต่อภัยคุกคามได้ทันท่วงที และลดความเสี่ยงจากการโจมตีที่ไม่สามารถมองเห็นได้ด้วยวิธีการเดิม

(2) การบริหารความเสี่ยง (Risk Management) การใช้ Machine Learning ในการวิเคราะห์พฤติกรรมของผู้ใช้ เช่น การล็อกอินจาก IP หรือช่วงเวลาที่ไม่ปกติ ช่วยให้สามารถระบุและประเมินความเสี่ยงจากการโจมตีได้แม่นยำยิ่งขึ้น การตรวจจับพฤติกรรมที่ผิดปกติช่วยลดความเสี่ยงจากภัยคุกคามที่จะมีผลกระทบต่อระบบและข้อมูลภายในองค์กร

(3) การเสริมสร้างระบบความปลอดภัยในองค์กร (Security System Enhancement) ช่วยปรับปรุงระบบรักษาความปลอดภัยโดยการใช้เทคนิคต่างๆ เช่น Random Forest, Support Vector Machines (SVM) หรือ User Behavior Analytics (UBA) เพื่อวิเคราะห์พฤติกรรมที่ผิดปกติและตรวจจับภัยคุกคามใหม่ ๆ การเสริมฟีเจอร์และใช้ Ensemble Learning ช่วยให้โมเดลมีความแม่นยำในการตรวจจับภัยคุกคามที่ดีขึ้น

(4) การปรับปรุงความสามารถในการรับมือกับภัยคุกคามในอนาคต (Adaptation to Emerging Threats) การใช้ Continuous Learning ในการพัฒนาโมเดลช่วยให้ระบบสามารถเรียนรู้จากข้อมูลใหม่ๆ และปรับตัวตามภัยคุกคามที่เกิดขึ้นจริง ทำให้ระบบรักษาความปลอดภัยสามารถตอบสนองต่อภัยคุกคามใหม่ๆ ที่ยังไม่เคยพบได้อย่างมีประสิทธิภาพ ลดความเสี่ยงจากการโจมตีที่ไม่รู้จัก

2.4 พฤติกรรมการเข้าสู่ระบบคราวด์เซิฟเวอร์ (SSH Log)

ในยุคที่การใช้งานคลาวด์เซิร์ฟเวอร์เพิ่มขึ้นอย่างรวดเร็ว ความปลอดภัยทางไซเบอร์กลายเป็นสิ่งสำคัญที่องค์กรและผู้ดูแลระบบต้องให้ความสนใจ โดยเฉพาะพฤติกรรมการเข้าสู่ระบบผ่าน Secure Shell (SSH) ซึ่งเป็นโปรโตคอลสำคัญที่ช่วยให้ผู้ใช้สามารถเข้าถึงเซิร์ฟเวอร์จากระยะไกลได้อย่างปลอดภัย SSH ใช้การเข้ารหัสข้อมูลเพื่อป้องกันการดักฟังและการโจมตีจากภายนอก ทำให้เหมาะสำหรับการจัดการระบบในสภาพแวดล้อมที่เสี่ยง

หนึ่งในสิ่งที่สำคัญในการเฝ้าระวังและวิเคราะห์พฤติกรรมการเข้าสู่ระบบคือข้อมูลพฤติกรรมการเข้าใช้งานระบบ (SSH Log) ซึ่งจะบันทึกเหตุการณ์เกี่ยวกับการเข้าสู่ระบบของผู้ใช้ รวมถึงความพยายามที่สำเร็จและล้มเหลว ตำแหน่งของไฟล์นี้มักอยู่ /var/log/auth.log หรือ /var/log/secure ขึ้นอยู่กับระบบปฏิบัติการ ข้อมูลที่บันทึกประกอบด้วยเวลาที่เกิดเหตุการณ์ ชื่อผู้ใช้ ที่อยู่ IP และรายละเอียดของเหตุการณ์ ไฟล์นี้ช่วยให้ผู้ดูแลระบบสามารถตรวจจับพฤติกรรมผิดปกติ เช่น การพยายามล็อกอินจากที่อยู่ IP ที่ไม่คุ้นเคยหรือการเข้าสู่ระบบผิดพลาดหลายครั้งในระยะเวลาสั้น ซึ่งอาจเป็นสัญญาณของการโจมตีแบบ Brute Force Attack สามารถดูเพิ่มเติมได้จาก [7]

เพื่อเพิ่มความปลอดภัย ผู้ดูแลระบบสามารถปรับปรุงกระบวนการเข้าสู่ระบบผ่าน SSH ได้โดยการตั้งค่า SSH Keys แทนการใช้รหัสผ่าน เนื่องจาก SSH Keys ป้องกันการโจมตีที่เกี่ยวข้องกับการคาดเดารหัสผ่านได้ดีกว่า ควรมีการกำหนดนโยบายในการสร้างและจัดการคีย์อย่างเหมาะสม เช่น การเปลี่ยนแปลงคีย์ที่ไม่ได้ใช้งาน และการยกเลิกคีย์ของผู้ใช้ที่พ้นสภาพ สามารถดูเพิ่มเติมได้จาก [3]

3. วิธีดำเนินการวิจัย

3.1 กรอบแนวคิด

การดำเนินงานวิจัยนี้ประกอบด้วยรายละเอียดตามกรอบแนวคิดการวิจัยการนำข้อมูลจากการเข้าสู่ระบบผ่านโปรโตคอล 22 (SSH) โดยจะมีการนำข้อมูลการเข้าสู่ระบบที่อยู่ในรูปแบบของ Log File ไปทำการเข้าสู่กระบวนการของการเรียนรู้ของเครื่อง เพื่อใช้ในการประเมินความเสี่ยงที่อาจจะเกิดขึ้นต่อระบบ

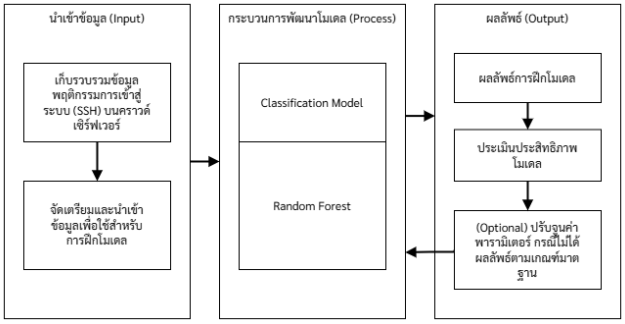

ภาพที่ 1: กรอบแนวคิดการดำเนินงานวิจัย

จากภาพที่ 1 แสดงถึงกระบวนการพัฒนาโมเดลการเรียนรู้ของเครื่องที่ออกแบบมาเพื่อตรวจจับและประเมินความเสี่ยงที่อาจเกิดขึ้นกับระบบคลาวด์เซิร์ฟเวอร์ สำหรับโปรโตคอล SSH (Secure Shell) สามารถดูเพิ่มเติมได้จาก [3] โดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ในการประยุกต์ใช้ในการวิเคราะห์และรักษาความปลอดภัยของระบบให้มีประสิทธิภาพมากยิ่งขึ้น การทำงานของระบบเริ่มต้นด้วยการเก็บรวบรวมข้อมูลการเข้าใช้งานระบบคลาวด์เซิร์ฟเวอร์ ซึ่งข้อมูลเหล่านี้ถูกเก็บรวบรวมไว้ระบบคลาวด์เซิร์ฟเวอร์ โดยข้อมูลที่ถูกเก็บรวบรวมจะประกอบไปด้วยรายละเอียดสำคัญต่างๆ เช่น วันและเวลาที่มีการเข้าใช้งาน, IP Address ของผู้ใช้งาน, และคำสั่งที่ถูกเรียกใช้ ข้อมูลเหล่านี้จะถูกบันทึกไว้ในรูปแบบของล็อกไฟล์ เพื่อที่จะนำไปใช้ในการวิเคราะห์ในขั้นตอนถัดไป หลังจากนั้น ข้อมูลล็อกที่เก็บรวบรวมจะถูกส่งไปยัง Logstash ซึ่งเป็นเครื่องมือที่ทำหน้าที่รวบรวม, แปลง, และส่งต่อข้อมูลล็อกไปยังระบบอื่น ๆ ใน

กรณีนี้ Logstash จะทำการแปลงข้อมูลล็อคที่ได้มาให้เป็นรูปแบบ CSV (Comma-Separated Values) ซึ่งเป็นรูปแบบข้อมูลที่เหมาะสำหรับการนำไปวิเคราะห์ด้วยเครื่องมืออื่นๆ ในขั้นตอนถัดไป การแปลงข้อมูลในรูปแบบ CSV ทำให้ข้อมูลที่ได้มีความสะดวกในการเข้าถึงและวิเคราะห์ข้อมูลด้วยเทคนิคต่าง ๆ ได้ง่ายขึ้น ดังภาพที่ 2

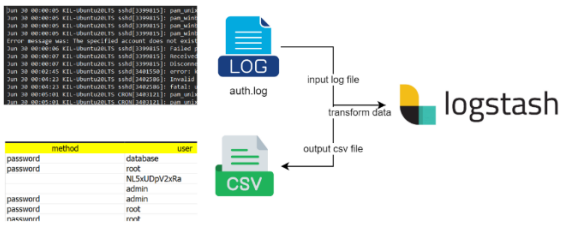

ภาพที่ 2: กระบวนการแปลงข้อมูลจาก Log File ให้เป็น CSV

ในขั้นตอนถัดไป ระบบจะทำการฝึกโมเดล Machine Learning โดยเลือกใช้โมเดล Random Forest สามารถดูเพิ่มเติมได้จาก [6-8, 9] ประเภท Classification ซึ่งเป็นอัลกอริธึมที่มีความเหมาะสมสำหรับการจำแนกประเภท (Classification) และสามารถจัดการกับข้อมูลที่มีมิติที่มากได้อย่างมีประสิทธิภาพ ข้อมูลในรูปแบบ CSV ที่ได้จาก Logstash จะถูกนำมาใช้ในการฝึกสอนโมเดล Random Forest เพื่อให้โมเดลสามารถเรียนรู้รูปแบบพฤติกรรมปกติและพฤติกรรมที่ผิดปกติของผู้ใช้งานได้อย่างมีประสิทธิภาพ เมื่อโมเดลได้รับการฝึกสอนเสร็จเรียบร้อยแล้ว ระบบจะสามารถนำโมเดลไปใช้งานเพื่อวิเคราะห์ข้อมูลใหม่ที่เข้ามาในระบบ โดยโมเดล Random Forest ที่ถูกฝึกมาแล้วจะทำการวิเคราะห์ข้อมูลเหล่านั้นเพื่อทำนายว่าพฤติกรรมนั้นเป็นปกติหรือผิดปกติ นอกจากนี้ โมเดลจะทำการประเมินความเสี่ยงของแต่ละพฤติกรรม โดยพิจารณาจากลักษณะต่างๆ เช่น ความถี่ในการเข้าใช้งาน, ช่วงเวลาที่เข้าใช้งาน, และประเภทของคำสั่งที่ถูกเรียกใช้ ซึ่งเป็นการช่วยในการตัดสินใจว่าเหตุการณ์ใดมีความเสี่ยงและจำเป็นต้องได้รับการตรวจสอบ

3.2 ขั้นตอนการพัฒนาโมเดล

ในงานวิจัยนี้ ได้มีการนำหลักการของ CRISP-DM (Cross-Industry Standard Process for Data Mining) สามารถดูเพิ่มเติมได้จาก [15] เป็นกระบวนการที่ช่วยสร้างโมเดลวิเคราะห์ข้อมูลอย่างเป็นระบบ โดยมีความยืดหยุ่นสูง เหมาะสำหรับการพัฒนาโมเดลตรวจจับการบุกรุก เช่น การตรวจจับการโจมตีแบบ Brute Force Attack ซึ่งเป็นการพยายามเข้าสู่ระบบโดยการสุ่มเดารหัสผ่านจำนวนมาก

3.2.1 การทำความเข้าใจข้อมูล (Data Understanding)

ในขั้นตอนนี้ จะต้องวิเคราะห์ข้อมูลบันทึกการใช้งานระบบ (Log Data) หรือ SSH Log เพื่อเข้าใจลักษณะของการโจมตีและพฤติกรรมของผู้ใช้ ข้อมูลสำคัญที่ควรวิเคราะห์ได้แก่

(1) สถานะของการเข้าสู่ระบบ (event)
(2) เวลาระหว่างความพยายามแต่ละครั้ง (timestamp)
(3) ชื่อผู้ใช้ที่ถูกใช้ในการเข้าสู่ระบบ (user)
(4) ที่อยู่ IP ของผู้โจมตี (clientip)

timestamp	host	program	events	method	user	clientip	port	signature
1/6/2024 0:06	{"name":"611db0ef064c"}	sshd	Failed	password	database	143.198.152.205	41710	ssh2
1/6/2024 0:00	{"name":"611db0ef064c"}	sshd	Failed	password	root	85.209.133.20	44300	ssh2
1/6/2024 0:04	{"name":"611db0ef064c"}	sshd	Invalid		NL5xUDpV2xRa	77.242.86.114		
1/6/2024 0:45	{"name":"611db0ef064c"}	sshd	Invalid		admin	193.201.9.156		
1/6/2024 0:45	{"name":"611db0ef064c"}	sshd	Failed	password	admin	193.201.9.156	54896	ssh2
1/6/2024 0:52	{"name":"611db0ef064c"}	sshd	Failed	password	root	180.101.88.240	33903	ssh2
1/6/2024 0:52	{"name":"611db0ef064c"}	sshd	Failed	password	root	180.101.88.240	33903	ssh2

ภาพที่ 3: ตัวอย่างข้อมูลที่จะนำไปใช้ในการพัฒนาโมเดล

3.2.2 การเตรียมข้อมูล (Data Preparation)

กระบวนการล้างข้อมูลและการดึงคุณลักษณะ (Data Cleaning and Feature Extraction) ถือเป็นองค์ประกอบที่มีความสำคัญในการวิเคราะห์พฤติกรรมของการพยายามล็อกอินผิดพลาดเพื่อประเมินความเป็นไปได้ของการโจมตีแบบ SSH Brute Force Attack กระบวนการดังกล่าวเริ่มต้นจากการปรับโครงสร้างให้เหมาะสมสำหรับการวิเคราะห์ โดยหนึ่งในกระบวนการที่มีความสำคัญเป็นอย่างมากคือการแปลงค่าของคอลัมน์ที่เกี่ยวข้องกับเวลา (timestamp) ให้อยู่ในรูปแบบของ datetime ซึ่งช่วยให้สามารถดึงข้อมูลเชิงเวลาเพิ่มเติม เช่น ชั่วโมง (hour) วันที่ (day) เดือน (month) และวันที่ในรูปแบบที่ไม่มีค่าเวลา (date) เพื่อนำมาใช้เป็นคุณลักษณะในการวิเคราะห์ต่อไป

นอกจากการแปลงค่าเวลาแล้ว กระบวนการล้างข้อมูลยังรวมถึงการตรวจสอบและจัดการค่าที่หายไปหรือข้อมูลที่อาจไม่สมบูรณ์ ซึ่งเป็นปัญหาที่พบบ่อยในชุดข้อมูลที่มาจาก SSH Log ตัวอย่างเช่น ค่าชื่อผู้ใช้ (user) อาจมีบางกรณีที่ข้อมูลสูญหายหรืออยู่ในรูปแบบที่ไม่สามารถนำมาใช้งานได้โดยตรง ดังนั้น การแปลงค่าดังกล่าวให้เป็นสตริงเพื่อป้องกันปัญหาที่อาจเกิดขึ้นระหว่างการวิเคราะห์จึงเป็นแนวทางที่ได้นำมาใช้ นอกจากนี้ การคัดกรองเหตุการณ์ที่เกี่ยวข้องถือเป็นอีกหนึ่งกระบวนการที่มีความจำเป็น เพื่อให้สามารถเลือกเฉพาะข้อมูลที่บ่งบอกถึงพฤติกรรมที่น่าสงสัยได้ เช่น เหตุการณ์ล็อกอินที่ล้มเหลว (Failed) และเหตุการณ์ที่ระบบแจ้งว่าชื่อผู้ใช้หรือรหัสผ่านไม่ถูกต้อง (Invalid) ซึ่งเป็นลักษณะที่บ่งบอกถึงความพยายามล็อกอินที่อาจไม่ได้เกิดจากผู้ใช้ที่ถูกต้องตามปกติ สามารถดูเพิ่มเติมได้จากภาพที่ 3

ภายหลังจากกระบวนการคัดกรองข้อมูล ข้อมูลที่ได้รับจะถูกจัดกลุ่มโดยอ้างอิงจากที่อยู่ IP (clientip) และชื่อผู้ใช้ (user) พร้อมทั้งคำนวณจำนวนครั้งของความพยายามล็อกอินผิดพลาดที่เกิดขึ้นในแต่ละวัน (daily_attack_frequency) หรือ daf เพื่อให้สามารถวิเคราะห์แนวโน้มของพฤติกรรมการพยายามล็อกอินที่ไม่สำเร็จต่อบัญชีผู้ใช้และที่อยู่ IP ในช่วงเวลาต่าง ๆ ได้ โดยการหาค่าเฉลี่ยของจำนวนครั้งที่มีการพยายามล็อกอินผิดพลาดต่อวันสำหรับแต่ละที่อยู่ IP และบัญชีผู้ใช้ จากนั้นค่าดังกล่าวจะถูกนำไปใช้เป็นคุณลักษณะ

เพิ่มเติมเพื่อช่วยในการจำแนกระดับความเสี่ยงของพฤติกรรมการพยายามล็อกอินผิดพลาดที่เกิดขึ้น

ตารางที่ 1: ตัวอย่างข้อมูลที่ถูกจัดกลุ่มแล้ว

timestamp	clientip	user	daf	risk_score
xx-xx-xxx	198.xx	root	11	MODERATE
xx-xx-xxx	162.xx	admin	6	LOW
xx-xx-xxx	129.xx	database	12	LOW
xx-xx-xxx	203.xx	admin	25	MODERATE
xx-xx-xxx	209.xx	ubuntu	68	HIGH
xx-xx-xxx	193.xx	root	54	VERY_HIGH

ในการกำหนดระดับความเสี่ยง (risk_score) จะมีการใช้อ้างอิงระดับความเสี่ยงจาก NIST ซึ่งเป็นสถาบันมาตรฐานและเทคโนโลยีแห่งชาติของสหรัฐอเมริกา ได้ออกแนวทาง SP 800-63B ซึ่งกำหนดว่าควรมีการจำกัดจำนวนครั้งที่ผู้ใช้สามารถพยายามล็อกอินผิดพลาดได้ โดยส่วนใหญ่มักกำหนดไว้ไม่เกิน 100 ครั้งภายในหนึ่งวัน ดังนั้นเอง ในงานวิจัยจะมีการใช้เกณฑ์การพิจารณาที่แตกต่างกันระหว่างบัญชีทั่วไปและบัญชีที่มีสิทธิ์เข้าถึงสูง เช่น บัญชี root ซึ่งมักเป็นเป้าหมายหลักของการโจมตี ในกรณีของบัญชี root หากมีค่าความถี่ของการโจมตีมากกว่าหรือเท่ากับ 50 ครั้งต่อวัน จะถูกจัดอยู่ในระดับความเสี่ยงสูงมาก (VERY_HIGH) ในขณะที่บัญชีทั่วไปจะถูกจัดอยู่ในระดับนี้ก็ต่อเมื่อมีค่าความถี่ของการโจมตีมากกว่าหรือเท่ากับ 100 ครั้งต่อวัน นอกจากนี้ยังมีการกำหนดระดับความเสี่ยงอื่น ๆ เช่น ระดับ HIGH สำหรับบัญชี root ที่มีค่าความถี่ของการโจมตีอยู่ในช่วง 20-49 ครั้งต่อวัน หรือบัญชีทั่วไปที่มีค่าความถี่ของการโจมตีอยู่ในช่วง 50-99 ครั้งต่อวัน ส่วนระดับ MODERATE และ LOW ถูกใช้สำหรับกรณีที่จำนวนครั้งของการพยายามล็อกอินผิดพลาดอยู่ในช่วงที่ต่ำกว่าเกณฑ์ข้างต้น และสำหรับบัญชีทั่วไปที่มีค่าความถี่ต่ำมาก (น้อยกว่า 3 ครั้งต่อวัน) จะถูกจัดอยู่ในระดับ VERY_LOW ซึ่งเป็นระดับความเสี่ยงต่ำสุด

3.2.3 การสร้างโมเดล (Modeling)

การเลือกโมเดลที่เหมาะสมเป็นสิ่งสำคัญสำหรับการตรวจจับ Brute Force Attack โดยใช้โมเดล Random Forest เนื่องจากมีข้อได้เปรียบที่สำคัญหลายประการ สามารถดูเพิ่มเติมได้จาก [6-8, 9] โดย Random Forest เป็นอัลกอริธึมที่ได้รับความนิยมอย่างมากในงานด้านความปลอดภัยทางไซเบอร์ เนื่องจากความสามารถในการจัดการกับข้อมูลที่ซับซ้อนและมีมิติสูง โดยเฉพาะปัญหาการตรวจจับภัยคุกคามที่มักเกี่ยวข้องกับข้อมูลปริมาณมากและมีลักษณะไม่เป็นเชิงเส้น จุดเด่นของ Random Forest คือการรวมผลลัพธ์จากต้นไม้หลายต้น (Ensemble Learning) ซึ่งช่วยลดปัญหา Overfitting และทำให้โมเดลมีความทนทานต่อค่าผิดปกติ เมื่อเปรียบเทียบกับ Decision Tree ซึ่งมีแนวโน้มที่จะเกิด Overfitting เมื่อจำนวนโหนดเพิ่มขึ้น Random Forest สามารถลดปัญหานี้ได้โดยการเรียนรู้จากหลายต้นไม้และทำการเฉลี่ยผลลัพธ์

หลักการทำงานของ Ensemble Learning เป็นการผสานการทำงานของโมเดลย่อยหลายโมเดลเข้าด้วยกัน เพื่อเพิ่มความแม่นยำและลดความคลาดเคลื่อนของผลลัพธ์ ในกรณีของ Random Forest โมเดลจะใช้ Decision Trees จำนวนมากมาทำงานร่วมกัน และใช้กลยุทธ์ Bootstrap Aggregating (Bagging) ซึ่งเป็นเทคนิคที่ช่วยให้แต่ละต้นไม้ถูกฝึกด้วยชุดข้อมูลที่แตกต่างกัน โดยการสุ่มตัวอย่างข้อมูลจากชุดข้อมูลต้นฉบับแบบมีการแทนที่ (Sampling with Replacement) เทคนิคนี้ช่วยลดปัญหาการเกิด overfitting ซึ่งเป็นปัญหาสำคัญของ Decision Tree แบบเดี่ยว ทำให้โมเดลมีความสามารถในการทำนายที่แม่นยำและเสถียรมากขึ้น

อีกหนึ่งปัจจัยที่ช่วยเพิ่มประสิทธิภาพของ Random Forest คือ Feature Randomness ซึ่งเป็นการสุ่มเลือกฟีเจอร์บางส่วนมาใช้ในการสร้างแต่ละ Decision Tree แทนที่จะใช้ฟีเจอร์ทั้งหมด วิธีนี้ช่วยลดความเสี่ยงที่โมเดลจะพึ่งพาฟีเจอร์ใดฟีเจอร์หนึ่งมากเกินไป และช่วยให้การตัดสินใจของโมเดลมีความหลากหลายมากขึ้น นอกจากนี้ Decision Trees ใน Random Forest จะถูกสร้างขึ้นอย่างอิสระจากกัน โดยแต่ละต้นไม้จะเรียนรู้จากชุดข้อมูลและฟีเจอร์ที่แตกต่างกัน ทำให้โมเดลมีความสามารถในการจำแนกข้อมูลที่ซับซ้อนและรองรับข้อมูลที่มีความหลากหลายได้ดี เมื่อโมเดลได้รับข้อมูลใหม่และต้องทำการทำนายผล ระบบจะใช้วิธี Majority Voting ซึ่งเป็นการให้แต่ละ Decision Tree ทำการทำนายค่าของข้อมูลและใช้ค่าที่ได้รับคะแนนเสียงสูงสุดเป็นค่าผลลัพธ์สุดท้าย ซึ่งช่วยเพิ่มความแม่นยำและลดความเสี่ยงจากการตัดสินใจผิดพลาดของโมเดลย่อย

เมื่อเทียบกับอัลกอริธึมอื่น เช่น Support Vector Machine (SVM) ซึ่งสามารถแยกข้อมูลออกเป็นคลาสได้อย่างมีประสิทธิภาพด้วย Margin Optimization แต่ SVM ต้องใช้ทรัพยากรในการคำนวณสูงเมื่อต้องรับมือกับข้อมูลขนาดใหญ่ และการเลือก Kernel Function ที่เหมาะสมเป็นกระบวนการที่ซับซ้อน ซึ่งอาจทำให้ประสิทธิภาพลดลงในกรณีที่ข้อมูลมีโครงสร้างไม่แน่นอน

ในขณะที่ Neural Networks มีความสามารถสูงในการเรียนรู้รูปแบบที่ซับซ้อน แต่ต้องใช้ชุดข้อมูลขนาดใหญ่และทรัพยากรประมวลผลสูง อีกทั้งการตีความผลลัพธ์ทำได้ยาก ซึ่งอาจเป็นข้อเสียเปรียบในงานด้านความปลอดภัยทางไซเบอร์ที่ต้องการอธิบายเหตุผลของการตัดสินใจ

K-Nearest Neighbors (KNN) แม้ว่าจะใช้งานได้ง่ายและสามารถจำแนกข้อมูลได้ดีในบางกรณี แต่เมื่อขนาดของข้อมูลเพิ่มขึ้น เวลาในการคำนวณก็เพิ่มขึ้นอย่างมาก เนื่องจากต้องคำนวณระยะทางระหว่างข้อมูลทุกจุด นอกจากนี้ KNN ยังอ่อนไหวต่อฟีเจอร์ที่มีสเกลแตกต่างกัน หากไม่มีการปรับแต่งที่เหมาะสม

Naïve Bayes ซึ่งเป็นอีกหนึ่งอัลกอริธึมที่ใช้กันอย่างแพร่หลาย มีข้อได้เปรียบด้านความเร็วและสามารถจัดการกับข้อมูลที่มีมิติสูงได้ แต่สมมติฐานที่ว่าแต่ละฟีเจอร์เป็นอิสระจากกันอาจไม่สอดคล้องกับข้อมูลด้านความปลอดภัยทางไซเบอร์ที่ฟีเจอร์มักมีความสัมพันธ์กัน ส่งผลให้ประสิทธิภาพของ Naïve Bayes ลดลงเมื่อใช้กับข้อมูลที่มีโครงสร้างซับซ้อน

จุดเด่นของ Random Forest ที่ทำให้เหมาะสมกับงานด้านความปลอดภัยทางไซเบอร์คือความสามารถในการเรียนรู้จากข้อมูลที่มีฟีเจอร์จำนวนมาก สามารถจัดการกับค่าที่ขาดหายไปได้ดี และให้ผลลัพธ์ที่สามารถตีความได้โดยใช้ค่าความสำคัญของฟีเจอร์ (Feature Importance) ซึ่งมีประโยชน์อย่างมากในการวิเคราะห์พฤติกรรมของภัยคุกคาม นอกจากนี้ Random Forest ยังสามารถรับมือกับข้อมูลที่มีความไม่สมดุลของคลาส (Class Imbalance) ได้ดีกว่าอัลกอริธึมอื่น และสามารถใช้งานได้ทั้งในระบบตรวจจับการบุกรุก (Intrusion Detection Systems) และการวิเคราะห์พฤติกรรมที่เป็นอันตรายโดยอาศัยข้อมูลในอดีต

การนำ Random Forest มาประยุกต์ใช้ในการตรวจจับการโจมตี Brute Force Attack สามารถวิเคราะห์พฤติกรรมของผู้ใช้และระบุรูปแบบที่ผิดปกติได้ โดยการใช้ชุดข้อมูลที่เกี่ยวข้อง เช่น ที่อยู่ IP (IP Address) ของผู้ที่พยายามเข้าสู่ระบบ, ชื่อผู้ใช้ (user) ที่ถูกพยายามล็อกอิน, จำนวนครั้งของการพยายามล็อกอินที่ล้มเหลวภายในระยะเวลา 1 วัน (daily_attack_frequency) และ ค่าคะแนนความเสี่ยง (risk _score) ที่โมเดลต้องทำนาย จากข้อมูลเหล่านี้ โมเดลสามารถเรียนรู้และตรวจจับพฤติกรรมที่เข้าข่ายการโจมตีแบบ Brute Force ได้ เช่น การพยายามล็อกอินจาก IP ที่ไม่คุ้นเคยหรือมีรูปแบบการล็อกอินที่ผิดปกติ

เพื่อให้โมเดล Random Forest สามารถทำงานได้อย่างมีประสิทธิภาพสูงสุด การปรับแต่งพารามิเตอร์เป็นสิ่งหนึ่งสำคัญ โดยกระบวนการปรับแต่งจะมีการปรับจำนวนต้นไม้ในป่า (n_estimators) และระดับความลึกของต้นไม้แต่ละต้น (max_depth) เพื่อให้เหมาะสมกับชุดข้อมูล นอกจากนี้ยังมีการแบ่งข้อมูลออกเป็นสองส่วน ได้แก่ ชุดข้อมูลสำหรับฝึกโมเดล (Training Data) ซึ่งจะถูกกำหนดเป็น 70% ของข้อมูลทั้งหมด และ ชุดข้อมูลสำหรับทดสอบโมเดล (Test Data) อีก 30% เพื่อประเมินประสิทธิภาพของโมเดลก่อนนำไปใช้จริง

3.3 การประเมินประสิทธิภาพการวิจัย

3.3.1 Accuracy (ความแม่นยำ)

สัดส่วนของการทำนายที่ถูกต้องเมื่อเปรียบเทียบกับการทำนายทั้งหมด จากสูตร

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

โดยที่ *TP* (True Positive) หมายถึง จำนวนกรณีที่ถูกทำนายเป็นบวกและถูกต้อง

TN (True Negative) หมายถึง จำนวนกรณีที่ถูกทำนายเป็นลบและถูกต้อง

FP (False Positive) หมายถึง จำนวนกรณีที่ถูกทำนายเป็นบวกแต่ไม่ถูกต้อง

FN (False Negative) หมายถึง จำนวนกรณีที่ถูกทำนายเป็นลบแต่ไม่ถูกต้อง

3.3.2 Precision (ค่าความเที่ยง)

สัดส่วนของจำนวนการทำนายบวกที่ถูกต้องเมื่อเปรียบเทียบกับจำนวนการทำนายบวกทั้งหมดจากสูตร

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

3.3.3 Recall (ค่าความระลึก)

สัดส่วนของจำนวนการทำนายบวกที่ถูกต้องเมื่อเปรียบเทียบกับจำนวนกรณีที่เป็นบวกทั้งหมด จากสูตร

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

3.3.4 F1-Score (ค่าเฉลี่ย)

ค่าเฉลี่ยฮาร์โมนิกของ Precision และ Recall ซึ่งใช้เพื่อวัดความสมดุลระหว่าง Precision และ Recall จากสูตร

$$F1-Score = 2\,x\,\frac{Precision\ x\ Recall}{Precision+\ Recall} \quad (4)$$

การใช้ตัวชี้วัดทั้งสี่นี้ในการประเมินประสิทธิภาพของอัลกอริธึมจะช่วยให้สามารถเข้าใจความสามารถในการทำงานของโมเดลได้อย่างชัดเจนและสามารถนำข้อมูลที่ได้ไปปรับปรุงหรือเลือกอัลกอริธึมที่เหมาะสมกับวัตถุประสงค์ของการวิจัยหรือการพัฒนาในอนาคต

4. ผลการวิจัยและอภิปรายผล

4.1 ผลการวิจัย

ผู้วิจัยได้ทำการศึกษา รวบรวม และวิเคราะห์ภัยคุกคามการโจมตีประเภท Brute Force Attack ในคราวด์เซริฟเวอร์ ผู้วิจัยได้ทำการเก็บรวบรวมข้อมูลจากโปรโตคอล 22 (SSH) ตั้งแต่ 1 กรกฎาคม 2567 ถึง 31 สิงหาคม 2567 จำนวน 93,360 ข้อมูล ซึ่งเมื่อทำการจัดกลุ่มของข้อมูลใหม่ (Data Preparation) ข้อมูลจะอยู่ที่ 7,499 ข้อมูล โดยนำมาทำการประเมินความเสี่ยงที่อาจเป็นภัยต่อระบบ ด้วยการนำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) มาประยุกในการตรวจจับการบุกรุกและประเมินความเสี่ยง โดยการใช้โมเดล ประเภท Classification ในการตรวจจับพฤติกรรม Brute Force Attack

ในการฝึกโมเดล Random Forest เพื่อทำนายข้อมูล ในงานวิจัยได้พบปัญหาการ Overfitting ซึ่งเกิดขึ้นเมื่อโมเดลเรียนรู้รายละเอียดหรือความแปรปรวนในข้อมูลฝึกมากเกินไป จนทำให้ไม่สามารถทำนายข้อมูลใหม่ได้ดี เนื่องจากได้มีการใช้ค่าพารามิเตอร์เริ่มต้นในการฝึกโมเดล การ Overfitting จะส่งผลให้โมเดลสามารถทำนายข้อมูลในชุดฝึกได้อย่างแม่นยำ แต่เมื่อทดสอบกับข้อมูลใหม่กลับมีประสิทธิภาพน้อยลง โดยทางผู้วิจัยได้ทำการเริ่มฝึกโมเดล Random Forest โดยใช้พารามิเตอร์เริ่มต้น พบว่าโมเดลให้ผลลัพธ์ที่มีความแม่นยำไม่สูงเท่าควร หลังจากนั้นทางผู้วิจัยได้ใช้เครื่องมือ GridSearchCV เพื่อค้นหาค้นหาค่าพารามิเตอร์ที่เหมาะสมโดยใช้ Grid Search ร่วมกับ Cross-Validation เพื่อลดความคลาดเคลื่อนและปรับปรุงประสิทธิภาพของโมเดล โดยค่าพารามิเตอร์ที่สำคัญสำหรับการปรับแต่งโมเดล Random Forest ได้แก่

(1) จำนวนต้นไม้ (n_estimators) – จำนวนต้นไม้ที่ใช้ในโมเดล

(2) ความลึกของต้นไม้ (max_depth) – ความลึกสูงสุดของต้นไม้แต่ละต้นในป่า

ทั้งนี้ เพื่อให้การทดลองครอบคลุมช่วงค่าที่เป็นไปได้ จึงกำหนดช่วงของค่าพารามิเตอร์ max_depth เป็น [10, 15, 19, 20, 25] และค่าพารามิเตอร์ n_estimators เป็น [10, 20, 30, 50, 55] ซึ่งทำให้มีการทดสอบค่าพารามิเตอร์ทั้งหมด 25 ชุด ในการดำเนินการทดลอง ได้ใช้ชุดข้อมูลที่มีการแบ่งออกเป็นชุดฝึก (training set) และชุดทดสอบ (test set) ในอัตราส่วน 70:30 เพื่อให้มั่นใจว่าผลการทดลองสามารถสะท้อนประสิทธิภาพของโมเดลได้อย่างเป็นกลาง

กระบวนการทดสอบใช้วิธีการ k-fold Cross-Validation เพื่อประเมินค่าพารามิเตอร์ที่แตกต่างกัน โดยกระบวนการนี้จะช่วยให้การเลือกค่าพารามิเตอร์มีความแม่นยำมากขึ้น ลดความลำเอียงของผลลัพธ์ ในกระบวนการนี้ ข้อมูลจะถูกแบ่งออกเป็น k กลุ่ม (folds) ที่มีขนาดใกล้เคียงกัน โดยแต่ละรอบของการฝึกโมเดลจะใช้ k-1 กลุ่มเป็นข้อมูลฝึกอบรม และใช้กลุ่มที่เหลือเป็นข้อมูลทดสอบ ทำซ้ำกระบวนการนี้ k ครั้ง โดยสลับ fold ที่ใช้เป็น validation set ไปเรื่อย ๆ หลังจากทำการฝึกและทดสอบทั้ง k รอบ ค่าประสิทธิภาพที่ได้จากแต่ละ fold จะถูกนำมาหาค่าเฉลี่ยเพื่อใช้เป็นค่าประสิทธิภาพของโมเดล

เมื่อใช้ Cross-Validation ใน GridSearchCV ระบบจะทำการทดสอบค่าพารามิเตอร์แต่ละชุดที่กำหนดไว้ใน param_grid ซึ่งจะถูกกำหนดค่า k เป็น 5 และมีพารามิเตอร์ที่ต้องทดสอบ 25 ชุด จะต้องทำการฝึกและทดสอบโมเดลทั้งหมด $5 \times 25 = 125$ รอบ การใช้ Cross-Validation ในลักษณะนี้ช่วยให้สามารถเลือกค่าพารามิเตอร์ที่ให้ผลลัพธ์ดีที่สุดโดยไม่พึ่งพา Validation set เพียงชุดเดียว ทำให้การประเมินผลของโมเดลมีความแม่นยำขึ้น

เมื่อใช้ GridSearchCV ในการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุด การใช้ Accuracy เป็นตัวชี้วัดสามารถช่วยระบุค่าพารามิเตอร์ที่ทำให้โมเดลมีประสิทธิภาพสูงสุดในแง่ของการจำแนกประเภท (Classification) เพื่อให้ผลการทดสอบมีความน่าเชื่อถือและลดความเหลื่อมล้ำที่อาจเกิดขึ้นจากการแบ่งข้อมูลเพียงครั้งเดียว โดยค่าพารามิเตอร์ที่ดีที่สุดจะถูกเลือกตามค่าความแม่นยำ (accuracy) ที่ได้จากการทดสอบ ดังตารางที่ 2

ตารางที่ 2: ค่าพารามิเตอร์ที่ดีที่สุด 5 อันดับแรก

อันดับ	ความลึกของต้นไม้	จำนวนต้นไม้	ค่าความแม่นยำ
1	25	50	0.981367
2	25	55	0.981138
3	25	30	0.972165
4	20	55	0.969878
5	19	55	0.968164

หลังจากการทดสอบและปรับพารามิเตอร์ พบว่าเมื่อใช้ความลึกของต้นไม้ที่ 25 และ จำนวนต้นไม้ 50 โมเดลสามารถให้ผลลัพธ์ที่มีความแม่นยำสูงขึ้นอย่างเห็นได้ชัด อย่างไรก็ตาม การปรับพารามิเตอร์นี้ต้องระมัดระวังเรื่องการ Overfitting เนื่องจากการเพิ่มจำนวนต้นไม้หรือความลึกของต้นไม้มากเกินไปอาจทำให้โมเดลเรียนรู้รายละเอียดเล็กน้อยที่ไม่สามารถใช้ได้กับข้อมูลใหม่ ซึ่งส่งผลให้โมเดลมีประสิทธิภาพที่ไม่ดีเมื่อทดสอบกับข้อมูลที่ไม่เคยเห็นมาก่อน

การป้องกัน Overfitting เป็นกระบวนการสำคัญในการพัฒนาโมเดล Machine Learning เพื่อให้สามารถทำงานได้อย่างมีประสิทธิภาพทั้งในชุดข้อมูลฝึกและข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน เทคนิคที่นิยมใช้ ได้แก่ Cross-validation ซึ่งช่วยให้โมเดลได้รับการฝึกและทดสอบกับชุดข้อมูลที่หลากหลาย ลดความเสี่ยงจากการเรียนรู้เฉพาะข้อมูลฝึกชุดเดียว นอกจากนี้ Regularization เช่น L1 และ L2 Regularization สามารถช่วยควบคุมค่าพารามิเตอร์ของโมเดลเพื่อลดความซับซ้อนและป้องกันการเรียนรู้ Noise ที่ไม่จำเป็น ในกรณีที่โมเดลได้รับการฝึกมากเกินไป Early Stopping เป็นอีกหนึ่งวิธีที่ช่วยหยุดการฝึกเมื่อพบว่าค่าความแม่นยำของชุดข้อมูลทดสอบเริ่มลดลง ซึ่งช่วยป้องกันไม่ให้โมเดลเรียนรู้รายละเอียดที่ไม่เกี่ยวข้องมากเกินไป

อีกแนวทางที่ช่วยลด Overfitting ได้คือ การเพิ่มข้อมูล (Data Augmentation) ซึ่งช่วยเพิ่มความหลากหลายของข้อมูลฝึก ทำให้โมเดลสามารถเรียนรู้รูปแบบของข้อมูลได้ดีขึ้นโดยไม่พึ่งพาข้อมูลเดิมมากเกินไป นอกจากนี้ การลดความซับซ้อนของโมเดล เช่น การลดจำนวนพารามิเตอร์หรือเลือกใช้ฟีเจอร์ที่สำคัญ ก็สามารถช่วยป้องกันการเรียนรู้ที่มากเกินไปได้ นอกจากนี้ การเลือกใช้ตัวชี้วัดที่เหมาะสม เช่น F1-score, Precision และ Recall แทนการพึ่งพา Accuracy เพียงอย่างเดียว ก็ช่วยให้สามารถประเมินผลลัพธ์ของโมเดลได้แม่นยำขึ้น

สุดท้ายนี้ เมื่อนำผลลัพธ์จากการนำเทคนิค GridSearchCV ซึ่งใช้หลักการ Cross-Validation มาหาค่าพารามิเตอร์ที่ดีที่สุด ซึ่งก็คือ

(1) จำนวนต้นไม้ 50 ต้น (n_estimators)

(2) ความลึกของต้นไม้ 25 (max_depth)

เมื่อนำค่าพารามิเตอร์ดังกล่าวมาใช้ในการฝึกอบรมโมเดล ผลลัพธ์แสดงให้เห็นว่า เกณฑ์การประเมินความเสี่ยงอยู่ในระดับที่เหมาะสมสำหรับการตรวจจับการบุกรุก สามารถดูเพิ่มเติมได้จาก [10] โดยมีค่าความแม่นยำ (Accuracy) รวมสูงถึง 0.98 หรือ 98% ซึ่งเป็นค่าที่บ่งชี้ถึงความสามารถของโมเดลในการจำแนกประเภทข้อมูลได้อย่างถูกต้องในระดับที่ดี

นอกจากนี้ ค่าทางสถิติที่ได้จากการประเมินผล เช่น Precision, Recall และ F1-Score ยังสะท้อนให้เห็นว่าโมเดลสามารถจำแนกข้อมูลในแต่ละกลุ่มได้อย่างมีประสิทธิภาพ โดยเฉพาะในกลุ่มที่มีจำนวนตัวอย่างข้อมูลมาก เช่น VERY_LOW และ LOW ซึ่งมีค่า Precision และ Recall อยู่ในระดับสูง อย่างไรก็ตาม ค่าความแม่นยำของโมเดลไม่ได้หมายความว่าการจำแนกข้อมูลทั้งหมดนั้นปราศจากข้อผิดพลาด เนื่องจากยังพบว่าค่า Recall ของคลาส MODERATE อยู่ที่ 0.97 ซึ่งต่ำกว่าคลาสอื่นเล็กน้อย สะท้อนให้เห็นว่าโมเดลอาจมีความสามารถจำแนกข้อมูลในกลุ่มนี้ได้น้อยกว่ากลุ่มอื่น สามารถดูผลลัพธ์ได้จากตารางที่ 3

ตารางที่ 3: ผลลัพธ์จากการนำค่าพารามิเตอร์ที่ดีที่สุดจาก GridSearchCV มาใช้ในการฝึกโมเดล

คลาส/เมตริก	Precision	Recall	F1-Score	จำนวนข้อมูล (Support)
VERY_LOW	0.96	1.00	0.98	4709
LOW	1.00	0.92	0.96	2335
MODERATE	1.00	0.97	0.98	128
HIGH	1.00	0.98	0.99	302
VERY_HIGH	1.00	1.00	1.00	25
ค่าเฉลี่ยรวม (Macro Avg)	0.99	0.92	0.95	7499
ค่าเฉลี่ยน้ำหนัก (Weighted Avg)	0.98	0.98	0.97	7499
ความแม่นยำ (Accuracy)	0.98			7499

การใช้ค่าเฉลี่ยรวม (Macro Average) และค่าเฉลี่ยน้ำหนัก (Weighted Average) เป็นอีกหนึ่งวิธีในการวิเคราะห์ประสิทธิภาพของโมเดล โดยค่า Macro Average ซึ่งเป็นค่าเฉลี่ยของทุกคลาสแบบไม่คำนึงถึงจำนวนตัวอย่างในแต่ละคลาส พบว่ามีค่า Precision อยู่ที่ 0.99 และ Recall อยู่ที่ 0.92 แสดงให้เห็นว่าโมเดลสามารถจำแนกประเภทของข้อมูลได้ดีในภาพรวม แต่ยังอาจมีความคลาดเคลื่อนบางส่วนในบางกลุ่มข้อมูล ในขณะที่ค่า Weighted Average ซึ่งเป็นค่าเฉลี่ยที่ให้น้ำหนักตามจำนวนตัวอย่างของแต่ละคลาส มีค่า Precision และ Recall อยู่ที่ 0.98 แสดงให้เห็นว่าโมเดลสามารถทำงานได้ดีโดยรวม และมีความแม่นยำสูงเมื่อพิจารณาจากจำนวนตัวอย่างที่มีในแต่ละคลาส

หนึ่งในข้อจำกัดสำคัญของชุดข้อมูลคือ ปัญหาความไม่สมดุลของคลาส (Class Imbalance) ซึ่งพบว่าคลาสบางประเภทมีจำนวนตัวอย่างมากกว่าคลาสอื่นอย่างมีนัยสำคัญ เช่น คลาส VERY_LOW มีจำนวนตัวอย่างสูงสุดที่ 4,709 ตัวอย่าง ขณะที่คลาส VERY_HIGH และ MODERATE มีจำนวนตัวอย่างน้อยมากเมื่อเทียบกัน ความไม่สมดุลนี้อาจส่งผลให้โมเดลมีแนวโน้มเรียนรู้จากคลาสที่มีตัวอย่างมากกว่า และทำให้ความสามารถในการจำแนกคลาสที่มีจำนวนน้อยลดลง

นอกจากนี้ ช่วงเวลาที่เก็บข้อมูล อาจไม่ครอบคลุมทุกสถานการณ์ โดยเฉพาะเหตุการณ์ที่เกิดขึ้นไม่บ่อย เช่น การโจมตีที่มีระดับความรุนแรงสูงอาจเกิดขึ้นเพียงบางช่วงเวลา การฝึกโมเดลบนชุดข้อมูลที่มีข้อจำกัดในช่วงเวลา การเก็บรวบรวมอาจทำให้โมเดลขาดความสามารถในการคาดการณ์เมื่อเจอสถานการณ์ใหม่ที่แตกต่างจากข้อมูลที่ใช้ฝึก

ข้อจำกัดดังกล่าวส่งผลให้โมเดลอาจมี Bias ต่อคลาสที่มีจำนวนตัวอย่างมาก และอาจไม่สามารถจำแนกคลาสที่มีจำนวนตัวอย่างน้อยได้อย่างแม่นยำ ส่งผลให้ค่าชี้วัดเช่น ค่าความแม่นยำ (Accuracy) อาจสูง แต่ค่าความเที่ยง (Precision) และค่าความระลึก (Recall) อาจน้อยในบางคลาส

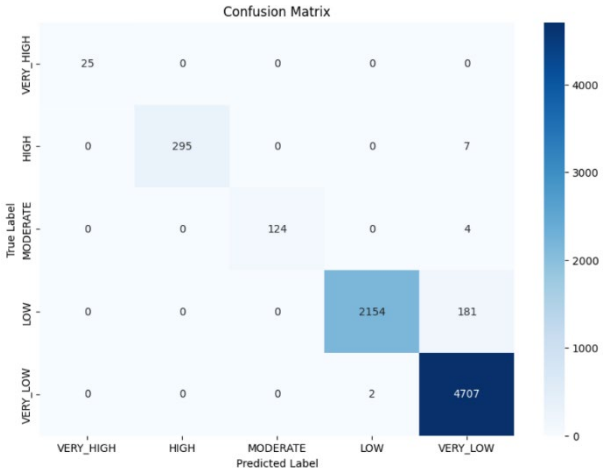

ภาพที่ 4: Confusion Matrix ผลการประเมินประสิทธิภาพของโมเดล

การวิเคราะห์ Confusion Matrix เป็นกระบวนการสำคัญในการประเมินประสิทธิภาพของโมเดล โดยเฉพาะในกรณีที่ข้อมูลมีการกระจายตัวไม่สมดุล ผลการวิเคราะห์พบว่าโมเดลสามารถจำแนกคลาสที่มีจำนวนตัวอย่างมากได้อย่างแม่นยำ เช่น คลาส VERY_LOW ซึ่งมีจำนวนตัวอย่างถูกต้องสูงถึง 4,707 จากทั้งหมด และมีข้อผิดพลาดเพียง 2 ตัวอย่าง ที่ถูกจำแนกเป็น LOW อย่างไรก็ตาม ในคลาสที่มีตัวอย่างน้อย เช่น VERY_HIGH และ MODERATE โมเดลยังคงมีข้อผิดพลาดในการจำแนก อันเนื่องมาจากการเรียนรู้ที่จำกัดจากข้อมูลที่มีปริมาณน้อย

ข้อผิดพลาดที่พบได้เด่นชัดคือการคาดการณ์คลาส LOW ผิดเป็น VERY_LOW โดยมีจำนวนมากถึง 181 ตัวอย่าง ซึ่งอาจเป็นผลจากความคล้ายคลึงกันของคุณลักษณะในระดับความเสี่ยงต่ำ นอกจากนี้ยังพบว่า คลาส HIGH และ MODERATE บางส่วนถูกจำแนกผิดไปเป็น VERY_LOW อันอาจเกิดจากปัญหาการกระจายตัวของข้อมูลและการตั้งค่าพารามิเตอร์ของโมเดล

แนวทางการปรับปรุงเพื่อเพิ่มความแม่นยำของโมเดล ได้แก่

(1) การปรับสมดุลของข้อมูล ด้วยเทคนิค Oversampling หรือ Undersampling รวมถึงการใช้วิธีการสร้างตัวอย่างเทียม เช่น SMOTE เพื่อเพิ่มปริมาณข้อมูลในคลาสที่มีตัวอย่างน้อย

(2) การปรับแต่งพารามิเตอร์ของโมเดล ด้วยกระบวนการ GridSearchCV เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมกับข้อมูลที่มีการกระจายตัวไม่สมดุล

(3) การเพิ่มคุณลักษณะของข้อมูล (Feature Engineering) โดยการคัดเลือกและเพิ่ม Feature ที่สามารถช่วยให้โมเดลสามารถแยกแยะคลาสที่มีความคล้ายคลึงกันได้ดีขึ้น

4.2 ส่วนการอภิปรายผล

จากกระบวนการพัฒนาโมเดลตรวจจับและประเมินความเสี่ยงของการโจมตีแบบ Brute Force Attack ที่ได้อภิปรายไว้ สามารถสรุปได้ว่าโครงสร้างและแนวทางที่นำเสนอเป็นการบูรณาการองค์ประกอบต่างๆ เข้าด้วยกันอย่างมีประสิทธิภาพ ตั้งแต่การเก็บรวบรวมข้อมูลพฤติกรรมการเข้าสู่ระบบ (SSH Log) การแปลงและจัดเก็บข้อมูล ในด้านการสร้างโมเดลทางผู้วิจัยทำการเลือกใช้โมเดล Random Forest เนื่องจากโมเดลนี้มีความสามารถในการจัดการข้อมูลที่ซับซ้อนและลดปัญหา Overfitting ได้ดีกว่า สามารถดูเพิ่มเติมได้จาก [9] การประเมินผลลัพธ์ของโมเดลผ่านค่าต่างๆ เช่น Accuracy, Precision, Recall และ F1-Score แสดงให้เห็นถึงประสิทธิภาพอยู่ในเกณฑ์ที่เหมาะสมสำหรับงานทางด้านภัยคุกคามทางไซเบอร์ โดยมีค่าความแม่นยำโดยรวมสูงถึง 98% ซึ่งบ่งบอกว่าโมเดลสามารถตรวจจับพฤติกรรมการโจมตีแบบ SSH Brute Force Attack ได้อย่างแม่นยำและครอบคุมในทุกระดับของความเสี่ยงไม่ว่าจะเป็น VERY_HIGH, HIGH, MODERATE, LOW หรือ VERY_LOW

การที่จะทำให้โมเดล Random Forest สามารถรองรับการเปลี่ยนแปลงของข้อมูลในอนาคตได้อย่างมีประสิทธิภาพ จำเป็นต้องมีการปรับปรุงและพัฒนาโมเดลอย่างต่อเนื่อง โดยอาจจะใช้เทคนิค Ensemble Learning ซึ่งรวมหลายโมเดลเข้าด้วยกัน เช่น Gradient Boosting หรือ XGBoost จะช่วยเพิ่มความแม่นยำในการตรวจจับการโจมตีและลดความผิดพลาดในการทำนาย นอกจากนี้การพัฒนาฟีเจอร์ใหม่ ๆ เช่น การวิเคราะห์พฤติกรรมของผู้ใช้หรือการใช้ข้อมูลจากหลายแหล่ง เช่น Firewall logs จะช่วยเพิ่มบริบทในการตรวจจับการโจมตีที่อาจไม่สามารถตรวจพบจากข้อมูลเดิมได้

อีกทั้งการฝึกโมเดลใหม่และการใช้ Online Learning จะช่วยให้โมเดลสามารถปรับตัวและเรียนรู้จากข้อมูลที่มีการเปลี่ยนแปลงไป โดยการฝึกซ้ำและเรียนรู้ต่อเนื่องสามารถทำให้โมเดลยังคงมีความแม่นยำในการตรวจจับภัยคุกคามที่เกิดขึ้นใหม่ และการใช้เทคนิค Anomaly Detection หรือ Clustering จะช่วยให้สามารถตรวจจับการโจมตีที่อาจไม่เคยเกิดขึ้นมาก่อนได้ นอกจากนี้การพัฒนาโมเดลในรูปแบบที่สามารถปรับตัวตามข้อมูลใหม่ ๆ จะช่วยให้ระบบมีความทนทานและสามารถรับมือกับภัยคุกคามที่พัฒนาต่อเนื่องได้

5. สรุปผล

กระบวนการพัฒนาโมเดลวิเคราห์และทำนายความเสี่ยงสำหรับการโจมตีแบบ Brute Force Attack ที่นำเสนอในงานวิจัยนี้เป็นแนวทางที่ครอบคลุมตั้งแต่การเก็บข้อมูล การสร้างโมเดล ไปจนถึงการวิเคราะห์ผลผ่านเครื่องมือที่เหมาะสม การเลือกใช้อัลกอริทึม Random Forest ซึ่งโมเดลประเภท Classification ในการจำแนกพฤติกรรมการโจมตีแสดงให้เห็นถึงความแม่นยำ

ผลการทดลองยืนยันว่าโมเดลสามารถตรวจจับและจำแนกประเภทของความเสี่ยงได้อย่างแม่นยำ โดยค่าความแม่นยำโดยรวม Accuracy 98.00%, Precision 98.00%, Recall 98.00% และ F1 Score 97.00% สอดคล้องกับความต้องการของระบบที่ต้องเผชิญกับภัยคุกคามแบบ SSH Brute Force Attack สะท้อนถึงศักยภาพของระบบในการตอบสนองต่อสถานการณ์จริงในงานด้านความมั่นคงปลอดภัยทางไซเบอร์อย่างมีประสิทธิภาพ

6. เอกสารอ้างอิง

[1] Safdar A, Durad H, Alam M. Design and implementation of real-time visualization tool for network security monitoring. In: 2018 15th International Bhurban Conference on Applied Sciences and Technology (IBCAST). 2018. p. 477–83.

[2] Eriksson J. A comparative analysis of log management solutions: ELK stack versus PLG stack. Diva-portal.org.

[3] Vugdelija N, Nedeljković N, Kojić N, Lukić L, Vesić M. Review of brute-force attack and protection techniques. Ictinnovations.org.

[4] Dawamsyach F, Ruslianto I, Ristian U. Implementation of IPS (Intrusion Prevention System) Fail2ban on server for DDoS and brute force attacks. Comput Eng Sci Syst J. 2023;8(1):149. doi:10.24114/cess.v8i1.40259

[5] Smith G. +95 cyber security breach statistics 2025 [Internet]. StationX; 2023 Nov 15. Available from: https://www.stationx.net/cyber-security-breach-statistics/

[6] Development of cyber threat model in the Royal Thai Air Force using machine learning. Tci-thaijo.org.

[7] Khandait P, Tiwari N, Hubballi N. Who is trying to compromise your SSH server? An analysis of authentication logs and detection of brute-force attacks. In: Adjunct Proceedings of the 2021 International Conference on Distributed Computing and Networking. 2021.

[8] Sanchez Delacruz E, Hernandez Arroyo IA. A review of intrusion detection systems using machine learning: Attacks, algorithms, and challenges.

[9] Talekar B. A detailed review on decision tree and random forest. Biosci Biotechnol Res Commun. 2020;13(14):245–8. doi:10.21786/bbrc/13.14/57

[10] Disha RA, Waheed S. Performance analysis of machine learning models for intrusion detection system using Gini Impurity-based Weighted Random Forest (GIWRF) feature selection technique. Cybersecurity. 2022;5(1). doi:10.1186/s42400-021-00103-8

[11] Fox J. Top cybersecurity statistics for 2024 [Internet]. Cobalt.io; 2023 Dec 8. Available from: https://www.cobalt.io/blog/cybersecurity-statistics-2024

[12] Poat MD, Lauret J, Fedele D. Flexible visualization of a 3rd party Intrusion Prevention (Security) tool: A use case with the ELK stack. J Phys Conf Ser. 2023;2438:012040.

[13] Stan MA. Automation of log analysis using the Hunting ELK Stack. Rom Cyber Secur J. 2021;3(1):59.

[14] Abdulganiyu OH, Ait Tchakoucht T, Saheed YK. A systematic literature review for network intrusion detection system (IDS). Int J Inf Secur. 2023;22(5):1125–62. doi:10.1007/s10207-023-00682-2

[15] Schröer C, Kruse F, Gómez JM. A systematic literature review on applying CRISP-DM process model. Procedia Comput Sci. 2021;181:526–34. doi:10.1016/j.procs.2021.01.199

[16] 1.Grassi PA, Fenton JL, Newton EM, Perlner RA, Regenscheid AR, Burr WE, et al. Digital identity guidelines: authentication and lifecycle management. NIST Special Publication 800-63B. 2017 Jun 22;(800-63B)

[17] Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. ACM Computing Surveys (CSUR), 41(3), 1-58.

[18] Nadkarni, A., Mangal, D., & Prasad, S. (2017). Intrusion detection using Random Forest for SSH Brute Force attacks. Journal of Cyber Security and Information Systems, 9(2), 30-40.

[19] Sommer, R., & Paxson, V. (2010). Outside the closed world: On using machine learning for network intrusion detection. IEEE Symposium on Security and Privacy, 305-316.

[20] International Organization for Standardization. ISO/IEC 27001:2022 - Information security, cybersecurity and privacy protection — Information security management systems — Requirements. Geneva: ISO; 2022.

การวิเคราะห์ความรู้สึกจากหัวข้อข่าวเพื่อสนับสนุนการตัดสินใจลงทุน ด้วยตัวแบบ FinBERT

Sentiment Analysis from News Headlines for Investment Decision-Making using FinBERT Model

สุทธิกานต์ แก้วอรุณ สิรินดา ปาลกวงศ์ ณ อยุธยา* เสาวณีย์ สาบุตร ปิยะฉัตร ลีลาศิลปศาสน์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* *s6404053630229@email.kmutnb.ac.th*)

บทคัดย่อ

การศึกษานี้ใช้วิธีการสกัดและดึงข้อมูลหัวข้อข่าวจากเว็บไซต์ (Web-scrapped) ด้วยการเขียนโปรแกรมภาษาไพธอน (Python) จากไลบรารี (Library) Beatifulsoup (BS4) และใช้ตัวแบบ FinBERT ในการวิเคราะห์ความรู้สึก (Sentiment Analysis) ซึ่งเป็นหนึ่งในเทคโนโลยีปัญญาประดิษฐ์ใช้การประมวลผลภาษาธรรมชาติ (Natural Language Processing – NLP) ในการประเมินอารมณ์และแนวโน้มของข่าวสารที่เกี่ยวข้องกับหุ้นที่นักลงทุนสนใจว่ามีความรู้สึกไปในทิศทางใด โดยในการศึกษานี้วิเคราะห์หุ้นของ 3 บริษัทในอุตสาหกรรมโรงแรมและบริการด้านความบันเทิง ได้แก่ Booking Holdings (BKNG) Trip.com Group (TCOM) และ Expedia Group (EXPE) เป็นกรณีศึกษา กระบวนการวิเคราะห์เริ่มจากการสกัดและดึงข้อมูลข่าวจากเว็บไซต์ Markets Insider เป็นแหล่งข้อมูลหลัก ผลการศึกษาพบว่าความรู้สึกของข่าวที่เกี่ยวข้องกับหุ้นทั้ง 3 มีความรู้สึกเป็นกลาง สะท้อนให้เห็นถึงลักษณะการรายงานข่าวที่มุ่งเน้นข้อมูลมากกว่าการแสดงความคิดเห็น และมีความแม่นยำ 72.77% 73.73% และ 69.73% ตามลำดับ

คำสำคัญ: การประมวลผลภาษาธรรมชาติ, การวิเคราะห์ความรู้สึก, การสกัดและดึงข้อมูล

Abstract

This study employs a web-scraping approach to extract and retrieve news headlines from websites using Python programming, specifically utilizing the BeautifulSoup (BS4) library. The FinBERT model is then applied for sentiment analysis, a subfield of artificial intelligence that leverages natural language processing (NLP) to assess the sentiment and trends of stock-related news. The objective is to determine the prevailing sentiment of news articles concerning stocks of interest to investors. This study examines the sentiment of news articles related to three companies in the hotel and entertainment services industry: Booking Holdings (BKNG), Trip.com Group (TCOM), and Expedia Group (EXPE), as a case study. The analysis process begins with extracting and retrieving news data from Markets Insider, which serves as the primary data source. The findings reveal that the sentiment of news articles concerning all three stocks is predominantly neutral, indicating that the news reports are more focused on delivering factual information rather than expressing subjective opinions. The model achieves an accuracy of 72.77%, 73.73%, and 69.73% for BKNG, TCOM, and EXPE, respectively.

Keywords: Natural Language Processing, Sentiment Analysis, Web-Scraping

1. บทนำ

ทุกสินทรัพย์การลงทุนต่างก็มีความเสี่ยงที่หลีกเลี่ยงไม่ได้ ไม่ว่าจะเป็นการลงทุนในกองทุนรวม ตราสารหนี้ อสังหาริมทรัพย์ สกุลเงินดิจิทัลหรือหุ้น ดังนั้นการบริหารจัดการความเสี่ยงและติดตามการลงทุนอย่างสม่ำเสมอจึงเป็นองค์ประกอบสำคัญของการลงทุน โดยวิธีการหนึ่งที่นักลงทุนนิยมใช้ในการติดตามสถานการณ์การลงทุน คือ การวิเคราะห์ข่าวสารที่เกี่ยวข้องกับสินทรัพย์ที่ลงทุน แม้ว่าในยุคดิจิทัลการเข้าถึงข้อมูลข่าวสารจะสะดวกและรวดเร็ว แต่ปริมาณของข้อมูลที่มีมหาศาลกลับเป็นอุปสรรคต่อการประมวลผลและวิเคราะห์อย่างมีประสิทธิภาพ เนื่องจากการอ่านและวิเคราะห์ข่าวสารทั้งหมดด้วยวิธีการแบบดั้งเดิมนั้นใช้เวลาและทรัพยากรอย่างมาก

การวิเคราะห์ความรู้สึก (Sentiment Analysis) คือ กระบวนการวิเคราะห์และประเมินความรู้สึกต่อการแสดงความคิดเห็นบนสื่อสังคมออนไลน์ (Social Network) เพื่อแสดงทัศนคติทางอารมณ์ที่มีต่อข้อมูล บทวิจารณ์ [1] การวิเคราะห์ความรู้สึกเป็นหนึ่งในเทคโนโลยีปัญญาประดิษฐ์ใช้การประมวลผลภาษาธรรมชาติ (Natural Language Processing – NLP) และการทำเหมืองข้อความ (Text Mining) [2-3] และมีการใช้เทคนิค Bag-of-Words (CBOW) และ Skip-gram Model เพื่อสร้างคลังคำศัพท์ในการวิเคราะห์ความรู้สึกที่เป็นเชิงบวกและเชิงลบ [4] ในปัจจุบันวิธีการเรียนรู้ของเครื่อง (Machine Learning) จะเป็นที่นิยมมากกว่า โดยสร้างชุดข้อมูลฝึกฝน (Training Set) [5] และนำชุดข้อมูลทดสอบ (Test Set) เข้ากระบวนการจัดกลุ่มหรือแยกประเภท (Classification) จากนั้นประเมินความแม่นยำจากค่า Precision และ Recall

การวิเคราะห์ความรู้สึกทางการเงิน (Financial Sentiment Analysis) แตกต่างจากการวิเคราะห์ความรู้สึกทั่วไป ไม่ใช่เพียงแค่โดเมนที่แตกต่างกัน แต่ยังรวมถึงเป้าหมายของการวิเคราะห์อีกด้วย โดยวัตถุประสงค์ของการวิเคราะห์ความรู้สึกทางการเงิน มักจะเป็นการคาดการณ์ว่าตลาดจะตอบสนองต่อข้อมูลในข้อความอย่างไร [6] Loughran และ McDonald (2016) ศึกษาการวิเคราะห์ความรู้สึกเกี่ยวกับข้อความทางการเงิน โดยใช้วิธีทาง Machine Learning ร่วมกับวิธี CBOW หรือ Lexicon-based methods [7] และสร้างพจนานุกรมคำศัพท์ทางการเงินที่มีการกำหนดค่าของคำ "เชิงบวก (positive)" หรือ "ไม่แน่นอน (uncertain)" และนับจำนวนคำที่ตรงกับค่าที่กำหนดไว้เพื่อวัดอารมณ์ของข้อความ [8] Pagolu et al. (2016) ใช้ n-grams จากทวีตที่เกี่ยวข้องกับข้อมูลทางการเงินป้อนเข้าสู่กระบวนการการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Machine Learning) เพื่อวิเคราะห์ความรู้สึกที่เกี่ยวข้องกับหน่วยงานทางการเงินที่ถูกกล่าวถึง [9] Kraus และ Feuerriegel (2017) [10] ใช้วิธี LSTM Neural Network วิเคราะห์ประกาศของบริษัท (ad-hoc company announcements) เพื่อพยากรณ์การเคลื่อนไหวของตลาดหุ้น และพบว่าวิธีการนี้มีความแม่นยำกว่าวิธีการเรียนรู้ของเครื่อง นอกจากนี้ยังพบว่าการฝึกฝนตัวแบบเพิ่มเติม (pre-training) บนชุดข้อมูลขนาดใหญ่ จะช่วยให้ผลลัพธ์มีผลลัพธ์ที่ดีขึ้น

ทั้งนี้ยังมีงานวิจัยที่ใช้โครงสร้างเครือข่ายประสาทเทียมแบบต่าง ๆ สำหรับ การวิเคราะห์ความรู้สึกทางการเงิน ไม่ว่าจะเป็น [11] การใช้โครงข่ายประสาทเทียมทั่วไปหลายรูปแบบ บนชุดข้อมูลจาก StockTwits และพบว่า CNN เป็นวิธีที่ให้ผลลัพธ์ดีที่สุด [12] ใช้วิธี doc2vec เพื่อสร้าง sentence embedding จากประกาศของบริษัท และใช้ multi-instance learning เพื่อทำนายผลลัพธ์ของตลาดหุ้น [13] ใช้วิธีผสมผสานระหว่างการทำ Text Simplification และโครงข่ายประสาทเทียมแบบ LSTM เพื่อจัดประเภทประโยคจากข่าวการเงิน ตามความรู้สึกที่แสดงออกมา และ [14] นำเสนอตัวแบบ FinBERT ซึ่งเป็นตัวแบบที่พัฒนามาจากตัวแบบ BERT สำหรับการประมวลผลภาษาธรรมชาติ (NLP) ด้านการเงิน

งานวิจัยนี้ศึกษาการประยุกต์ใช้เทคนิคการวิเคราะห์ความรู้สึก (Sentiment Analysis) โดยวิเคราะห์ความรู้สึกจากหัวข้อข่าวเพื่อเพิ่มประสิทธิภาพในกระบวนการตัดสินใจลงทุนและช่วยให้นักลงทุนสามารถประมวลผลข้อมูลข่าวสารได้อย่างรวดเร็วและแม่นยำมากขึ้น ในการศึกษานี้ศึกษาหุ้นจากอุตสาหกรรมโรงแรมและบริการด้านความบันเทิง 3 บริษัท ได้แก่ Booking Holdings (BKNG) Trip.com Group (TCOM) และ Expedia Group (EXPE) เป็นกรณีศึกษาด้วยตัวแบบ FinBERT ทั้งนี้ การวิเคราะห์ความรู้สึกจากหัวข้อข่าวไม่เพียงช่วยให้นักลงทุนสามารถประเมินทิศทางและผลกระทบของข่าวสารต่อสินทรัพย์ที่ลงทุนได้อย่างมีประสิทธิภาพมากขึ้นเท่านั้น แต่ยังช่วยลดระยะเวลาในการวิเคราะห์ ติดตามข่าวสาร อีกทั้งยังช่วยลดอคติที่อาจเกิดจากการวิเคราะห์ด้วยดุลยพินิจส่วนบุคคลอีกด้วย

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การสกัดและดึงข้อมูลจากเว็บไซต์ (Web-Scraping)

เนื่องด้วยปัจจุบันมีจำนวนผู้ใช้และการเติบโตของข้อมูลบนโลกอินเทอร์เน็ตเป็นอย่างมาก ข้อมูลที่ปรากฏบนแพลตฟอร์มดิจิทัล ไม่ว่าจะเป็นสื่อสังคมออนไลน์ บทความหรือข่าวสาร ล้วนเป็นแหล่งข้อมูลที่มีคุณค่า ในปัจจุบันมีการนำข้อมูลที่ได้จากการสกัดและดึงข้อมูลจากเว็บไซต์ไปใช้ในหลายรูปแบบ อาทิ การติดตามและวิเคราะห์ข้อมูล (Data Monitoring) การใช้เป็นแหล่งข้อมูลเสริมเพื่อสนับสนุนการตัดสินใจ (Alternative Data Source for Decision Making) และการวิเคราะห์ความรู้สึกและวิจัยตลาด (Sentiment Analysis and Market Research) [15] การศึกษานี้มุ่งเน้นการประยุกต์ใช้ข้อมูลที่ได้จากการสกัดและดึงข้อมูลจากเว็บไซต์ใน 2 มิติ ได้แก่ ใช้เป็นแหล่งข้อมูลเสริมเพื่อสนับสนุนการตัดสินใจและการวิเคราะห์ความรู้สึก โดยมีเป้าหมายเพื่อเสริมสร้างประสิทธิภาพในกระบวนการตัดสินใจควบคู่ไปกับข้อมูลที่มีอยู่เดิม และวิเคราะห์ทิศทางความรู้สึกของข่าวสารที่มีต่อหุ้นที่ศึกษา ซึ่งในกระบวนการขั้นตอนของการทำการสกัดและดึงข้อมูลจากเว็บไซต์จะใช้การโปรแกรมมิ่งบนเว็บไซต์กูเกิลโคแลบอราทอรี (Google Colaboratory) โดยใช้ภาษาโปรแกรมไพธอน (Python) และใช้ BeatifulSoup จากไลบรารี bs4 สำหรับการดึงข้อมูล

2.2 การวิเคราะห์ความรู้สึก (Sentiment Analysis)

การวิเคราะห์ความรู้สึก เป็นกระบวนการทางเทคโนโลยีที่ใช้ในการประเมินและวิเคราะห์ความรู้สึกหรืออารมณ์ของตลาดจากข้อมูลเชิงข้อความที่มาจากแหล่งข้อมูลที่หลากหลาย อาทิ ข่าวสาร สื่อสังคมออนไลน์ เวทีสนทนา หรือความคิดเห็นสาธารณะ โดยมีวัตถุประสงค์เพื่อคาดการณ์ทิศทางราคาของสินทรัพย์ผ่านการจำแนกประเภทความคิดเห็นออกเป็น 3 ระดับ ได้แก่ ความคิดเห็นเชิงบวก (Positive) ความคิดเห็นเชิงลบ (Negative) และความคิดเห็นที่เป็นกลาง (Neutral) โดยมีสมมติฐานว่าทิศทางของความคิดเห็นมีความสัมพันธ์กับทิศทางของราคาหลักทรัพย์และตลาด กล่าวคือ หากผลลัพธ์ที่ได้จากการวิเคราะห์แสดงแนวโน้มเป็นความเห็นเชิงบวก ราคาหลักทรัพย์หรือทิศทางตลาดก็มีแนวโน้มที่จะเป็นบวกเช่นกัน และในทางกลับกัน หากผลลัพธ์ที่ได้จากการวิเคราะห์แสดงแนวโน้มเป็นความเห็นเชิงลบราคาหลักทรัพย์หรือทิศทางของตลาดก็จะเป็นลบเช่นกัน [16-17] อย่างไรก็ตาม การศึกษาในบริบทของการวิเคราะห์ทางการเงินขององค์กรพบว่า บริษัทส่วนใหญ่จะใช้ข้อความที่สื่อถึงอารมณ์ความรู้สึกที่เป็นกลางเป็นหลักและใช้ข้อความที่ให้ความรู้สึกเชิงลบให้น้อยที่สุดอยู่ที่ประมาณร้อยละ 5-15 ของความเห็นทั้งหมด นอกจากนี้ ในช่วงการแพร่ระบาดของโรคโควิด-19 ยังพบว่าค่าเฉลี่ยของการแสดงความคิดเห็นทั้งในเชิงบวกและเชิงลบมีแนวโน้มลดลงอย่างมีนัยสำคัญ [18]

2.3 FinBERT Model

Financial Bidirectional Encoder Representations from Transformers: FinBERT) เป็นแบบจำลองที่พัฒนาต่อยอดมาจาก BERT ซึ่งใช้เทคโนโลยีการประมวลผลภาษาธรรมชาติสำหรับการจัดประเภทอารมณ์ (sentiment classification) ที่ผ่านการฝึกสอนมาก่อน (Pre-Trained Model) [19-20] โดยเพิ่มชั้นเครือข่ายประสาทแบบหนาแน่น (Dense Layer) หลังจากสถานะซ่อนสุดท้ายของโทเค็น [CLS] ซึ่งเป็นแนวทางที่แนะนำสำหรับการใช้ BERT ในงานจัดประเภทข้อความ จากนั้นเครือข่ายตัวจำแนก (classifier network) จะถูกฝึกด้วยชุดข้อมูลที่ติดป้ายกำกับ (labeled dataset) แสดงดังภาพที่ 1

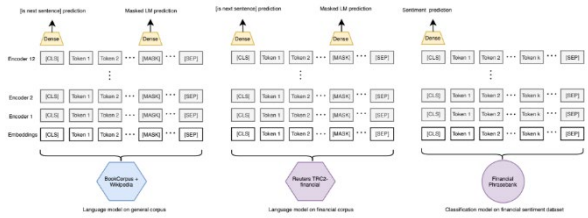

ภาพที่ 1: ภาพรวมของตัวแบบ FinBERT [14]

โดยปรับแต่งและฝึกฝนด้วยชุดข้อมูลขนาดใหญ่ 2 ชุด คือ ชุดข้อมูล *TRC2-financial* ซึ่งประกอบไปด้วยข้อมูลรายงาน บทความ และข่าวสารด้านการเงินที่ผ่านการกรองแล้ว 46,143 ฉบับ ข้อความ 400,000 ประโยค และคำกว่า 29 ล้านคำ และชุดข้อมูล *Financial Phrase Bank* ทั้งนี้มีแบบจำลองที่มีการพัฒนามาเฉพาะด้านจะทำให้แบบจำลองมีความเข้าใจในคำศัพท์ ประโยคและบริบททางการเงินได้ดีกว่าแบบจำลองภาษาทั่วไป ส่งผลให้การวิเคราะห์ความรู้สึกมีความแม่นยำสูงขึ้น จากการทดสอบแบบจำลองต่าง ๆ กับชุดข้อมูล *Financial Phrase Bank* พบว่าแบบจำลอง FinBERT ให้ค่าความแม่นยำที่สูงที่สุดเมื่อเทียบกับแบบจำลองอื่น ๆ ดังตารางที่ 1 [14]

ตารางที่ 1: ตารางการเปรียบเทียบแบบจำลองแบบต่าง ๆ

Experimental Results on the Financial PhraseBank dataset

	All data			Data with 100% agreement		
Model	Loss	Accuracy	F1 Score	Loss	Accuracy	F1 Score
LSTM	0.81	0.71	0.64	0.57	0.81	0.74
LSTM with ELMo	0.72	0.75	0.7	0.50	0.84	0.77
ULMFit	0.41	0.83	0.79	0.20	0.93	0.91
LPS	-	0.71	0.71	-	0.79	0.80
HSC	-	0.71	0.76	-	0.83	0.86
FinSSLX	-	-	-	-	0.91	0.88
FinBERT	**0.37**	**0.86**	**0.84**	**0.13**	**0.97**	**0.95**

3. วิธีดำเนินการวิจัย

3.1 การคัดเลือกเว็บไซต์และเตรียมข้อมูล

การคัดเลือกเว็บไซต์ข่าวสำหรับการสกัดและดึงข้อมูล โดยผู้วิจัยได้กำหนดเงื่อนไขในการเลือกเว็บไซต์ ดังนี้ 1. เว็บไซต์ที่เลือกต้องมีการเก็บข้อมูลข่าวย้อนหลังเป็นระยะเวลานาน เนื่องจากหลายเว็บไซต์ไม่เก็บข่าวเก่าไว้ ทำให้ข้อมูลที่ได้มีแต่ข่าวปัจจุบัน ซึ่งอาจสะท้อนความคิดเห็นชั่วขณะหรือตามกระแสสังคม ส่งผลให้การวิเคราะห์เกิดอคติได้ 2. เว็บไซต์ควรรวบรวมข่าวจากหลายแหล่ง เพื่อให้ได้ข้อมูลที่มีความหลากหลายและครอบคลุมมากขึ้น จากเงื่อนไขข้างต้น ผู้วิจัยจึงเลือกเว็บไซต์ *Market Insider* เนื่องจากตรงตามเกณฑ์ที่กำหนดทุกประการ จากนั้นเข้าสู่ขั้นตอนของการสกัดและดึงข้อมูลจากเว็บไซต์

3.2 ประมวลผลข้อความ

เครื่องมือที่ใช้ในกระบวนการโปรแกรมมิ่งจะใช้ภาษาโปรแกรมไพธอนและไลบรารี่ที่ใช้ในกระบวนการสกัดและดึงข้อมูลจากเว็บไซต์ และการวิเคราะห์ความรู้สึกมีทั้งหมด 4 ตัว คือ 1. transformers จาก Hugging Face ใช้สำหรับนำเข้าโมเดลปัญญาประดิษฐ์และตัวแปลงข้อความ 2. BeautifulSoup จากไลบรารี bs4 ใช้สำหรับสกัดและดึงข้อมูลจากเว็บไซต์ 3. requests ใช้สำหรับเชื่อมต่อและส่งคำขอไปยังเว็บไซต์เพื่อดึงข้อมูล HTML 4. pandas ใช้สำหรับจัดการข้อมูลเชิงตาราง (Data Frame) เช่น การเก็บข้อมูลหัวข้อข่าว ผลการวิเคราะห์และการจัดเรียงข้อมูล

3.3 การเก็บรวบรวมข้อมูล

การเก็บรวบรวมข้อมูลจะทำการเก็บข้อมูลหัวข้อข่าวที่เกี่ยวกับหุ้นในกรณีศึกษาทั้งหมด 3 บริษัท ได้แก่ Booking Holdings (BKNG) Trip.com Group (TCOM) และ Expedia Group (EXPE) โดยผลลัพธ์ที่ได้จากการสกัดและดึงข้อมูลจากเว็บไซต์ และการวิเคราะห์ความรู้สึกจะถูกจัดเก็บลงใน

รูปแบบตารางที่มี 4 คอลัมน์ ได้แก่ 1. วันที่และเวลาที่ข่าวถูกเผยแพร่ (Date Time) 2. หัวข้อข่าว (Title) 3. แหล่งที่มาของข่าว (Source) 4. ลิงก์ไปยังข่าวต้นฉบับ (Link)

3.4 การวิเคราะห์ความรู้สึก

หลังจากได้ข้อมูลหัวข้อข่าวจากการสกัดและดึงข้อมูลจากเว็บไซต์แล้ว ข้อมูลเหล่านี้จะถูกนำไปวิเคราะห์ความรู้สึกด้วยตัวแบบ FinBERT ซึ่งเป็นการประมวลผลภาษาธรรมชาติที่ถูกฝึกมาเฉพาะสำหรับการวิเคราะห์ข้อความทางการเงิน โดยในการวิจัยนี้จะใช้ API ของ Hugging face ในการวิเคราะห์ความรู้สึก หลังจากสามารถวิเคราะห์ความรู้สึกได้แล้วจะเพิ่มคอลัมน์อีก 2 คอลัมน์ในตารางเดิม คือ 1. ผลการวิเคราะห์ความรู้สึก (top_sentiment) เช่น Positive Negative และ Neutral 2. ค่าความถี่การจัดประเภทความรู้สึกของแบบจำลองการวิเคราะห์ความรู้สึก (sentiment_score)

3.5 การประเมินตัวแบบ (Model Evaluation Phase)

เมื่อผ่านขั้นตอนการแยกประเภท (Classification Phase) ด้วยตัวแบบ FinBERT เรียบร้อยแล้ว จะนำผลการทำนายเข้ากระบวนการประเมินตัวแบบเพื่อวัดความแม่นยำของตัวแบบ โดยพิจารณาจากความแม่นยำ (Accuracy) ความถูกต้อง (Precision) ค่า Recall และค่า F1 (F1 Score) ของ Precision และ Recall [21]แสดงดังสมการที่ (1)-(4)

$$\text{ความแม่นยำ (Accuracy)} = \frac{TN+TP}{TP+FP+TP+FN} \quad (1)$$

$$\text{ความถูกต้อง (Precision)} = \frac{TP}{TP+FP} \quad (2)$$

$$\text{ค่า Recall} = \frac{TP}{TP+FN} \quad (3)$$

$$\text{ค่า F1} = 2 * \frac{(Precision*Recall)}{(Precision+Recall)} \quad (4)$$

โดยที่

TP คือ ข้อมูลทำนายถูกต้องตรงกับความจริง

TN คือ ข้อมูลสิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้น

FP คือ ข้อมูลสิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้น

FN คือ ข้อมูลสิ่งที่ทำนายไม่ตรงกับที่เกิดขึ้นจริง

Precision คือ ค่าความแม่นยำ

Recall คือ ความถูกต้อง

ค่า F1 Score คือ ค่าเฉลี่ยของ Precision และ Recall

และเพื่อให้สามารถมองเห็นภาพรวมของความคิดเห็นจากหัวข้อข่าวเกี่ยวกับหุ้นของทั้ง 3 บริษัทได้อย่างชัดเจน ผู้วิจัยได้นำผลลัพธ์จากการวิเคราะห์ความรู้สึกมาทำการสรุปด้วยแผนภาพ โดยใช้ไลบรารี Plotly Express สำหรับการสร้างกราฟแท่ง (Bar Chart) ซึ่งช่วยให้สามารถสื่อสารข้อมูลได้อย่างมีประสิทธิภาพและมองเห็นความแตกต่างของประเภทความรู้สึกได้อย่างชัดเจน

4. ผลการวิจัยและอภิปรายผล

จากการวิเคราะห์ความรู้สึกของข่าวที่เกี่ยวข้องกับหุ้น Booking Holdings (BKNG) โดยใช้โมเดล FinBERT พบว่าข่าวส่วนใหญ่มีความรู้สึกเป็นกลางคิดเป็นจำนวน 630 ข่าว ข่าวเชิงบวก 259 ข่าว และข่าวเชิงลบจำนวน 149 ข่าว ผลลัพธ์แสดงดังภาพที่ 2

ภาพที่ 2: กราฟแท่งที่แสดงความรู้สึกจากข่าวในภาพรวมของหุ้น Booking Holdings (BKNG)

และการวิเคราะห์ความรู้สึกของข่าวที่เกี่ยวข้องกับหุ้น Trip.com Group (TCOM) โดยใช้โมเดล FinBERT พบว่าข่าวส่วนใหญ่มีความรู้สึกเป็นกลางคิดเป็นจำนวน 278 ข่าว เชิงบวก 160 ข่าว และข่าวเชิงลบจำนวน 61 ข่าว ผลลัพธ์แสดงดังภาพที่ 3

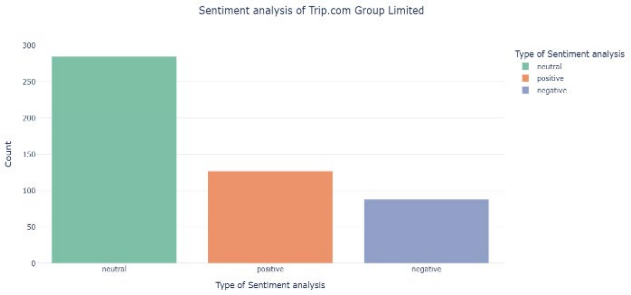

ภาพที่ 3: กราฟแท่งที่แสดงความรู้สึกจากข่าวในภาพรวมของหุ้น Trip.com Group (TCOM)

การวิเคราะห์ความรู้สึกของข่าวที่เกี่ยวข้องกับหุ้น Expedia Group (EXPE) โดยใช้โมเดล FinBERT พบว่าข่าวส่วนใหญ่มีความรู้สึกเป็นกลางคิดเป็นจำนวน 707 ข่าว ข่าวเชิงบวก 251 ข่าว และข่าวเชิงลบจำนวน 222 ข่าว ผลลัพธ์แสดงดังภาพที่ 4

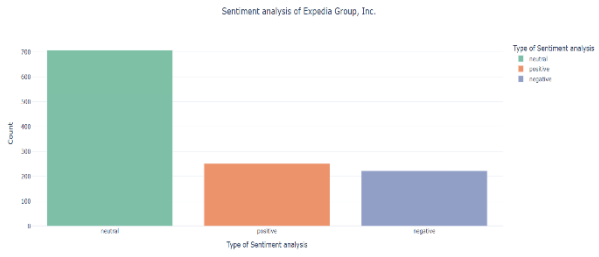

ภาพที่ 4: กราฟแท่งที่แสดงความรู้สึกจากข่าวในภาพรวมของหุ้น Expedia Group (EXPE)

จากภาพที่ 2 – 4 สังเกตได้ว่าค่าความรู้สึกเป็นกลางมีจำนวนมาก สะท้อนให้เห็นถึงลักษณะการรายงานข่าวที่มุ่งเน้นข้อมูลมากกว่าการแสดงความคิดเห็น เนื่องจากสำนักข่าวต่าง ๆ ควรตั้งหัวข้อข่าวอย่างเป็นกลางที่สุด ไม่ใส่ความคิดเห็นของตนเองลงไปเพื่อให้ไม่ชักจูงผู้อ่านให้คิดเห็นไปทางเดียวกับสำนักข่าว เมื่อทำการประเมินตัวแบบ สามารถสรุปผลการประเมินความแม่นยำของตัวแบบได้ ดังตารางที่ 2

ตารางที่ 2: ตารางสรุปผลการประเมินความแม่นยำของตัวแบบ

หุ้น	Accuracy	Precision	Recall	F1 Score
BKNG	0.7277	0.7243	0.7277	0.6993
TCOM	0.7373	0.7161	0.7373	0.7144
EXPE	0.6973	0.6885	0.6973	0.6727

5. สรุปผลและข้อเสนอแนะ

งานวิจัยนี้ใช้การวิเคราะห์ความรู้สึกเพื่อวิเคราะห์หัวข้อข่าวที่สกัดและดึงข้อมูลมาว่าเป็นไปในทิศทางไหน ด้วยตัวแบบ FinBERT ซึ่งผลการศึกษา พบว่า ทั้ง หุ้น BKNG หุ้น TCOM และ หุ้น EXPE มีค่าความรู้สึกเป็นกลาง และมีความแม่นยำ 72.77% 73.73% และ 69.73% ตามลำดับ โดยผลการศึกษานี้จะนำไปเป็นปัจจัยเพิ่มเติมในการพิจารณาราคาหุ้นทั้ง 3 ในงานวิจัยต่อไป เพื่อเพิ่มความแม่นยำของตัวแบบพยากรณ์ และสามารถคาดการณ์ราคาหุ้นได้ใกล้เคียงกับความเป็นจริง เช่น ข่าวเชิงบวกอาจส่งผลให้ราคาหุ้นปรับตัวขึ้น ในขณะที่ข่าวเชิงลบอาจทำให้ราคาหุ้นลดลง ดังนั้นการวิเคราะห์ความรู้สึกจึงมีความสำคัญต่อการคาดการณ์ราคาหุ้นเป็นอย่างมาก

ทั้งนี้การนำการวิเคราะห์ความรู้สึกมาใช้มีข้อจำกัดหลายอย่างที่อาจจะทำให้ผลลัพธ์คลาดเคลื่อนและไม่แม่นยำ ถึงแม้ว่าเทคโนโลยีการประมวลผลภาษาธรรมชาติ (NLP) จะมีการพัฒนามากขึ้นเพียงใด แต่การเข้าใจอารมณ์และภาษาของมนุษย์ได้ทั้งหมดนั้นเป็นเรื่องที่ยาก เนื่องจากในมนุษย์มีการกระทำ ภาษาและความคิดที่ค่อนข้างซับซ้อน ซึ่งในบางครั้งผู้เขียนหัวข้อข่าวหรือบทความนั้นมีการใช้ภาษาที่มีการเสียดสี ประชดประชัน พหุขั้ว หรือรูปปฏิเสธ[22] ซึ่งอาจจะทำให้การวิเคราะห์นั้นผิดพลาดได้

6. เอกสารอ้างอิง

[1] Sepandar, D.K. and Jonathan, H. 2011. We feel fine and searching the emotional web, pp.117-126. *In* Proceedings of the fourth ACM international conference on Web search and data mining (WSDM 11). Association for Computing Machinery, New York, USA.

[2] Trupthi, M., Pabboju, S. and Narasimha, G. 2017. Sentiment Analysis on Twitter Using Streaming API, pp. 915-919. In 2017 IEEE 7th International Advance Computing Conference (IACC). Hyderabad, India.

[3] Anurag, P.J. and Vijauy, D.K. 2015. Sentiments Analysis of Twitter Data Using Data Mining, pp. 807-810. In 2015 International conference on Information Processing (ICIP) Vishwakarma Institute of Technology. Pune, India

[4] Fan, X., Li, X., Du, F., Li, X. and Wei, M. 2016. Apply Word Vectors for Sentiment Analysis of APP Reviews, pp. 1062-1066. In The 2016 3rd International Conference on Systems and Information (ICSAI 2016) IEEE. Shanghai, China.

[5] Lorattanachaiyong, I. 2017. Generating Thai Sentiment Lexicon from Online Reviews. A Thesis for the Degree of Master Thesis of Arts, Chulalongkorn University. (in Thai)

[6] Xiaodong Li, Haoran Xie, Li Chen, Jianping Wang, and Xiaotie Deng. 2014. News impact on stock price return via sentiment analysis. Knowledge-Based Systems 69 (oct 2014), 14–23. https://doi.org/10.1016/j.knosys.2014.04.022

[7] Tim Loughran and Bill Mcdonald. 2016. Textual Analysis in Accounting and Finance: A Survey. Journal of Accounting Research 54, 4 (2016), 1187–1230. https://doi.org/10.1111/1475-679X.12123

[8] Tim Loughran and Bill Mcdonald. 2011. When Is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks. Journal of Finance 66, 1 (feb 2011), 35–65. https://doi.org/10.1111/j.1540-6261.2010.01625.x

[9] Pagolu, V. S., Reddy, K. N., Panda, G., & Majhi, B. (2016, October). Sentiment analysis of Twitter data for predicting stock market movements. In 2016 international conference on signal processing, communication, power and embedded system (SCOPES) (pp. 1345-1350). IEEE.

[10] Sahar Sohangir, Dingding Wang, Anna Pomeranets, and Taghi M Khoshgoftaar. 2018. Big Data: Deep Learning for financial sentiment analysis. Journal of Big Data 5, 1 (2018). https://doi.org/10.1186/s40537-017-0111-6.

[11] Mathias Kraus and Stefan Feuerriegel. 2017. Decision support from financial disclosures with deep neural networks and transfer learning. Decision Support Systems 104 (2017), 38–48.

[12] Bernhard Lutz, Nicolas Pröllochs, and Dirk Neumann. 2018. Sentence-Level Sentiment Analysis of Financial News Using Distributed Text Representations and Multi-Instance Learning. Technical Report. arXiv:1901.00400 http://arxiv.org/abs/1901.00400

[13] Macedo Maia, André Freitas, and Siegfried Handschuh. 2018. FinSSLx: A Senti-ment Analysis Model for the Financial Domain Using Text Simplification. In 2018 IEEE 12th International Conference on Semantic Computing (ICSC). IEEE, 318–319.

[14] Araci, D. (2019). Finbert: Financial sentiment analysis with pre-trained language models. arXiv preprint arXiv:1908.10063.

[15] Boonyakiat P. *มาเข้าใจภาพรวมการทำ Web scraping กันเถอะ*! Medium [Internet]. Retrieved January 28, 2025, from:https://punsiriboonyakiat.medium.com/

[16] TradingView [Internet]. วิธีใช้ Sentiment Indicator อารมณ์ในตลาดสำหรับ PEPPERSTONE:GER40. Retrieved February 11, 2025, from https://th.tradingview.com/

[17] Bharathi, S., Geetha, A. (2017). Sentiment analysis for effective stock market prediction. International Journal of Intelligent Engineering and Systems. Apr 29;10(3):146–54.

[18] อรรถพล ธรรมรัตนฤทธิ, ศิริศักดิ์ เชยคำแหง, ธัชพรรณ บัณฑิตเลิศรักษ์, นันทิชา อังศุวิจิตรกุล. (2566). โครงการการวิเคราะห์อารมณ์และทัศนคติที่อยู่ในเอกสารทางการเงิน. Retrieved January 28, 2025.

[19] Araci,D., Pengjie, Ren., Zulkuf, Genc (2019). FinBERT: Financial Sentiment Analysis with Pre-trained Language Models. University of Amsterdam. Available from: https://arxiv.org/pdf/1908.10063.

[20] Xiao, Q., Ihnaini, B (2023). Stock trend prediction using sentiment analysis. PeerJ Computer Science [Internet]. Available from: https://peerj.com/articles/cs-1293/.

[21] Bowornlertsutee, P., & Paireekreng, W. (2022). Sentiment Analysis Techniques of Online Product Reviews. Recent Science and Technology, 14(3), 755–769.

[22] Amazon Web Services. การวิเคราะห์ความรู้สึกคืออะไร - อธิบายการวิเคราะห์ความรู้สึก. Retrieved February 18, 2025, from https://aws.amazon.com/th/what-is/sentiment-analysis/

ผลกระทบของฟังก์ชันกระตุ้นต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์

Impact of Activation Functions on the Data Efficiency of Multi-response Neural Network

จินจุ เจริญยิ่งไพศาล* เสกสรร เกียรติสุไพบูลย์
ภาควิชาสถิติและวิทยาการข้อมูล จุฬาลงกรณ์มหาวิทยาลัย
(* *6680046126@student.chula.ac.th*)

บทคัดย่อ

เครือข่ายประสาทเทียมแบบหลายผลลัพธ์เป็นหนึ่งในแนวทางที่มีศักยภาพในการเพิ่มประสิทธิภาพข้อมูล อย่างไรก็ตาม ผลการศึกษาก่อนหน้านี้พบว่า ผลลัพธ์ทางทฤษฎีจากการเปรียบเทียบประสิทธิภาพของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัดกับเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว และผลลัพธ์เชิงปฏิบัติจากการเปรียบเทียบเครือข่ายประสาทเทียมแบบหลายผลลัพธ์กับเครือข่ายประสาทเทียมแบบผลลัพธ์เดียวยังคงมีความแตกต่างกัน งานวิจัยนี้มุ่งศึกษาผลกระทบของฟังก์ชันกระตุ้นในชั้นซ่อนที่มีต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ในปัญหาการจำแนกประเภทแบบไบนารี โดยทำการศึกษาในฟังก์ชันกระตุ้น 4 ชนิด ได้แก่ ฟังก์ชัน Sigmoid, ReLU, Leaky ReLU (LReLUs) และ Exponential Linear Units (ELUs) โดยจากผลการวิจัยพบว่า ฟังก์ชัน sigmoid เป็นฟังก์ชันกระตุ้นที่สามารถทำให้ประสิทธิภาพเชิงปฏิบัติมีค่าใกล้เคียงกับผลลัพธ์เชิงทฤษฎีมากที่สุด

คำสำคัญ: เครือข่ายประสาทเทียมแบบหลายผลลัพธ์, ประสิทธิภาพการใช้ข้อมูล, แบบจำลองการเรียนรู้เชิงลึก, ฟังก์ชันกระตุ้น

Abstract

Multi-response neural networks are one of the potential approaches for improving data efficiency. However, previous studies have found that the theoretical results from comparing the performance of the constrained bi-response neural networks with the single-response neural networks and the practical results from comparing the performance of the regular bi-response neural networks with the single-response neural networks are still different. This research aims to study the effect of the hidden layer activation function on the data utilization performance of multi-response neural networks in binary classification problem. The study is conducted on four activation functions: Sigmoid, ReLU, Leaky ReLU (LReLU), and Exponential Linear Units (ELUs). The results show that the sigmoid function is the activation function that can make the practical performance closest to the theoretical results.

Keywords: Multi-response Neural Network, Data Efficiency, Deep Learning, Activation Functions

1. บทนำ

การเรียนรู้เชิงลึก (Deep learning) ได้รับการยอมรับอย่างแพร่หลายในวงการวิจัยและการประยุกต์ใช้งาน เนื่องจากความสามารถในการประมวลผลและวิเคราะห์ข้อมูลที่มีความซับซ้อนสูง ส่งผลให้การเรียนรู้เชิงลึกเข้ามามีบทบาทสำคัญในหลากหลายสาขา เช่น การจดจำภาพ (Image recognition) การประมวลผลภาษาธรรมชาติ (Natural language processing) และการจดจำเสียง (Speech recognition) ประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกมีความสัมพันธ์โดยตรงกับขนาดของชุดข้อมูลที่ใช้ในการฝึก กล่าวคือ ชุดข้อมูลที่มีขนาดใหญ่และหลากหลายสามารถช่วยให้แบบจำลองมีศักยภาพในการเรียนรู้และทำนายได้อย่างแม่นยำยิ่งขึ้น อย่างไรก็ตาม การจัดหาชุดข้อมูลขนาดใหญ่เหล่านี้มักมีค่าใช้จ่ายสูงและต้องใช้เวลาในการรวบรวมข้อมูล นอกจากนี้ยังมีข้อจำกัดทางด้าน

จริยธรรมและความท้าทายในการเข้าถึงข้อมูล โดยเฉพาะในสาขาที่มีความอ่อนไหว เช่น การแพทย์ ดังนั้น การพัฒนาแนวทางที่ช่วยเพิ่มประสิทธิภาพการใช้ข้อมูลที่มีอยู่จำกัดจึงเป็นสิ่งจำเป็นและมีความสำคัญอย่างยิ่ง

หนึ่งในแนวทางที่มีศักยภาพในการเพิ่มประสิทธิภาพของข้อมูล (Data efficiency) คือการใช้เครือข่ายประสาทเทียมแบบหลายผลลัพธ์ (Multi-response neural networks) โดยโครงสร้างนี้เน้นการใช้ข้อมูลหลายผลลัพธ์ที่มีความสัมพันธ์กันและมาจากหน่วยสังเกตเดียวกันในการฝึกแบบจำลอง แนวทางนี้ช่วยให้แบบจำลองสามารถใช้ประโยชน์จากข้อมูลร่วมกันระหว่างผลลัพธ์ที่เกี่ยวข้องได้อย่างมีประสิทธิภาพ ตัวอย่างเช่น การวินิจฉัยโรคที่อาศัยการตรวจวัดตัวชี้วัดทางสุขภาพหลาย ๆ ตัวจากผู้ป่วยคนเดียวกัน เช่น ผลการตรวจเลือด ผลเอ็กซ์เรย์ และการประเมินทางคลินิก โครงสร้างดังกล่าวสามารถแบ่งปันและใช้ข้อมูลร่วมกันระหว่างผลลัพธ์ที่สัมพันธ์กันได้ ซึ่งอาจส่งผลให้สามารถลดจำนวนหน่วยสังเกตที่จำเป็นในการฝึกแบบจำลองลง และช่วยเพิ่มประสิทธิภาพของการเรียนรู้ภายใต้ข้อจำกัดด้านข้อมูลได้อย่างมีนัยสำคัญ

ในปี 2024 Kiatsupaibul และ Chansiripas [1] ได้ทำการนิยามเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัด (Constrained multi-response neural networks) ให้เป็นผลลัพธ์ทางทฤษฎี และทำการศึกษาศักยภาพในการเพิ่มประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ โดยเปรียบเทียบประสิทธิภาพเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัดและเครือข่ายประสาทเทียมแบบหลายผลลัพธ์กับเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว (Single-response neural networks) ในสองประเภทของปัญหา ได้แก่ ปัญหาการถดถอย (Regression) และปัญหาการจำแนกประเภท (Classification) การทดลองครอบคลุมทั้งกรณีที่มีชั้นซ่อน (Hidden layer) และไม่มีชั้นซ่อน จากผลการวิจัยพบว่าผลลัพธ์เชิงปฏิบัติยังไม่สามารถเทียบเท่ากับผลลัพธ์เชิงทฤษฎีได้อย่างสมบูรณ์

ในงานวิจัยนี้ผู้วิจัยมุ่งเน้นศึกษาผลกระทบของฟังก์ชันกระตุ้นที่มีต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ในปัญหาเชิงจำแนกประเภท ซึ่งจะทำการศึกษากับฟังก์ชันกระตุ้น (Activation functions) ที่หลากหลาย และยังขยายขอบเขตไปสู่การทดลองกับโครงสร้างเครือข่ายประสาทเทียมที่มีชั้นลึกขึ้น

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 เครือข่ายประสารทเทียมแบบป้อนไปข้างหน้า (Feedforward Neural Network; FNN)

เครือข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward Neural Network; FNN) [2] เป็นรูปแบบหนึ่งของโครงสร้างเครือข่ายประสาทเทียมที่มีลักษณะเป็นชั้น ๆ (Layer) โดยในแต่ละชั้นจะประกอบด้วยโหนดหลายตัว โครงสร้างของ FNN สามารถแบ่งออกได้เป็น 3 ส่วนหลัก ได้แก่ ชั้นขอมูลเข้า (Input layer), ชั้นซ่อน (Hidden layer) และชั้นข้อมูลออก (Output layer) โดยกระบวนการทำงานของ FNN จะแบ่งเป็น 2 ส่วนหลัก ๆ ดังนี้

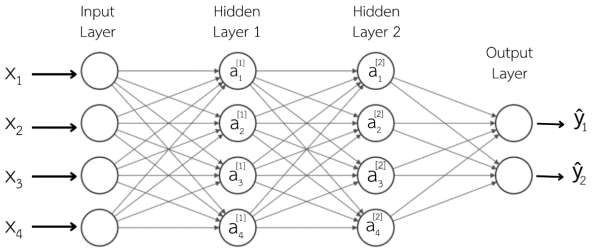

ภาพที่ 1: ตัวอย่างโครงสร้างของ FNN

1) Feedforward คือ กระบวนการส่งผ่านข้อมูลจากชั้นข้อมูลเข้าไปยังชั้นข้อมูลออก ผ่านชั้นซ่อนต่าง ๆ โดยในแต่ละชั้น ข้อมูลจะถูกประมวลผลด้วยการคูณเวกเตอร์ของข้อมูลเข้ากับค่าถ่วงน้ำหนัก (Weight) และบวกกับค่าอคติ (Bias) ที่กำหนดไว้ ซึ่งจะสามารถอธิบายเป็นสมการได้ดังสมการที่ 1 [3]

$$y = f(W^T X + b) \quad (1)$$

เมื่อ f เป็นฟังก์ชันกระตุ้น
W เป็นเมทริกซ์น้ำหนัก
X เป็นเวกเตอร์ของข้อมูลเข้า
b เป็นค่าอคติ

2) Backward Propagation คือ กระบวนการที่ช่วยให้เครือข่ายประสาทเทียมสามารถเรียนรู้จากข้อมูลได้อย่างมีประสิทธิภาพ กระบวนการนี้เริ่มต้นด้วยการคำนวณความผิดพลาด (Error) ระหว่างค่าที่คาดการณ์กับค่าจริง จากนั้นจะส่งข้อมูลความผิดพลาดนี้ย้อนกลับผ่านเครือข่าย เพื่อทำการปรับค่าพารามิเตอร์ในแต่ละชั้น โดยกระบวนการปรับค่าพารามิเตอร์ใช้การคำนวณอนุพันธ์เพื่อหาค่าความชัน (Gradient) ของฟังก์ชันความสูญเสีย (Loss function) สำหรับแต่ละน้ำหนักในเครือข่าย จากนั้นจึงปรับน้ำหนักโดยมีเป้าหมายเพื่อลดความผิดพลาดให้ต่ำที่สุด [4]

2.1.2 เครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัด (Constrained Multi-response Neural Networks)

Kiatsupaibul และ Chansiripas [1] ได้เสนอเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัด (Constrained multi-response neural network) โดยกำหนดให้ค่าน้ำหนักและอคติของผลลัพธ์ทุก ๆ ผลลัพธ์ในชั้นข้อมูลออกมีค่าเท่ากับค่าน้ำหนักและอคติของผลลัพธ์แรกในชั้นข้อมูลออก

2.1.3 Single–response Analogy

การสร้างแบบจำลองเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัด ในทางปฏิบัติสามารถแทนด้วย single-response analogy ซึ่งเป็นการแปลงข้อมูลจากสองผลลัพธ์ให้เป็นผลลัพธ์เดียวโดยการจับคู่ระหว่างข้อมูลเข้าและผลลัพธ์ที่

สัมพันธ์กันและส่งผลให้แบบจำลองได้เรียนรู้จากข้อมูลจำนวนมากขึ้นเป็น 2 เท่าจากเดิม ดังที่แสดงในภาพที่ 2

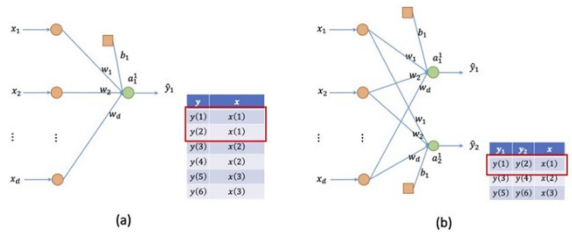

ภาพที่ 1: Single-response Analogy ของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ที่มีข้อจำกัด [1]

2.2 งานวิจัยที่เกี่ยวข้อง

ในงานวิจัยครั้งนี้ผู้วิจัยได้ใช้งานของ Kiatsupaibul และ Chansiripas [1] เป็นงานหลักของการศึกษา โดยงานวิจัยดังกล่าวได้ทำการศึกษาศักยภาพในการเพิ่มประสิทธิภาพการใช้ข้อมูลของแบบจำลองเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ ผ่านการเปรียบเทียบประสิทธิภาพของเครือข่ายประสาทเทียม 3 ประเภท ได้แก่ (1) ทำการเปรียบเทียบเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด (Constrained bi-response) กับ เครือข่ายประสาทเทียมแบบผลลัพธ์เดียว ซึ่งจะนิยามผลลัพธ์ที่ได้จากการเปรียบเทียบนี้เป็นผลลัพธ์เชิงทฤษฎี และ (2) ทำการเปรียบเทียบประสิทธิภาพของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ (Regular bi-respone) กับ เครือข่ายประสาทเทียมแบบผลลัพธ์เดียว และนิยามผลลัพธ์ที่ได้จากการเปรียบเทียบนี้เป็นผลลัพธ์เชิงปฏิบัติ โดยทำการศึกษาในปัญหาทั้ง 2 รูปแบบ คือปัญหาการถดถอย และ ปัญหาการจำแนกประเภท ทั้งนี้การทดลองคลอบคลุมทั้งโครงสร้างเครือข่ายประสาทเทียมทั้งแบบที่ไม่มีชั้นซ่อน และแบบที่มีชั้นซ่อน 1 ชั้น ซึ่งใช้ฟังก์ชันกระตุ้นในชั้นซ่อนคือ ฟังก์ชัน sigmoid เท่านั้น และใช้ตัวชี้วัดในการวัดประสิทธิภาพ คือ Mean Squared Error (MSE) สำหรับปัญหาการถดถอย และ Binary Cross-Entropy สำหรับปัญหาการจำแนกประเภท จากผลการศึกษาพบว่าผลลัพธ์เชิงทฤษฎีชี้ให้เห็นว่า เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดสามารถเพิ่มประสิทธิภาพของข้อมูลในปัญหาทั้งสองประเภทได้ดีกว่าแบบจำลองเครือข่ายประสาทเทียมแบบผลลัพธ์เดียวอย่างมีนัยสำคัญ ในขณะที่ผลลัพธ์ในเชิงปฏิบัติพบว่า ประสิทธิภาพของเครือข่ายประสาทเทียมแบบสองผลลัพธ์เพิ่มขึ้นเพียงเล็กน้อยเมื่อเปรียบเทียบกับแบบจำลองเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว ซึ่งสามารถสรุปได้ว่าผลลัพธ์ที่ได้จากในเชิงปฏิบัติยังไม่เป็นไปตามผลลัพธ์ที่คาดการณ์ตามเชิงทฤษฎี

นอกจากนี้ผู้วิจัยยังทำการศึกษาเกี่ยวกับการกำหนดจำนวนชั้นซ่อน ในเครือข่ายประสาทเทียมแบบ Feedforward เพื่อนำมาใช้ในการนิยายโครงสร้างเครือข่ายประสาทเทียมที่จะใช้ในงานวิจัยครั้งนี้ โดย Panchai et al. [5] ได้ทำการศึกษาพฤติกรรมของเครือข่ายประสาทเทียมแบบที่มีหลายชั้น (Multilayer Perceptrons; MLPs) โดยการศึกษามุ่งเน้นที่การเลือกจำนวนชั้นซ่อน การวิจัยนี้เปรียบเทียบประสิทธิภาพของเครือข่ายประสาทเทียมในหลายโครงสร้าง โดยใช้ตัวชี้วัด Correct Classification Rate (CCR) การทดลองครอบคลุมโครงสร้างที่มีชั้นซ่อน 1 ชั้น และ 2 ชั้น โดยจำนวนโหนดในแต่ละชั้นจะถูกปรับเปลี่ยนไปตามการทดลอง ผลการวิจัยพบว่าการใช้ชั้นซ่อนเพียง 1 ชั้น หรือสูงสุดไม่เกิน 2 ชั้น สามารถให้ประสิทธิภาพที่ดีและใช้เวลาในการฝึกฝนน้อย

Karsoliya [6] ได้ทำการทบทวนวรรณกรรมและศึกษาวิเคราะห์วิธีการกำหนดชั้นซ่อนของเครือข่ายประสาทเทียมแบบ Back Propagation (BPNN) ซึ่งเป็นหนึ่งในเครือข่ายประสาทเทียมแบบ Feedforward โดยในการทดลองนี้ได้ใช้เกณฑ์ที่หลากหลายในการกำหนดจำนวนโหนดซ่อน จากผลการวิจัยพบว่าการมีชั้นซ่อนเพียง 1 ถึง 2 ชั้นเพียงพอสำหรับการฝึกแบบจำลอง การเพิ่มจำนวนชั้นซ่อนถึง 3 ชั้นสามารถเพิ่มความแม่นยำได้อย่างมาก แต่ก็เพิ่มความซับซ้อนของเครือข่ายและระยะเวลาในการฝึกแบบจำลองหลายเท่า ซึ่งอาจนำไปสู่ปัญหา overfitting นอกจากนี้ การทบทวนวรรณกรรมยังชี้ให้เห็นว่าการใช้จำนวนโหนดซ่อนที่เท่ากันในทุกชั้นสามารถช่วยให้การฝึกแบบจำลองทำได้ง่ายมากยิ่งขึ้น

Uzair และ Jamil [7] ได้ทำการทบทวนวรรณกรรมจากงานวิจัยหลายชิ้น รวมถึงงานของ Panchai et al. [5], Karsoliya [6] และงานวิจัยอื่นๆ อีก 8 งาน โดยมุ่งเน้นศึกษาเกี่ยวกับจำนวนชั้นซ่อนที่เหมาะสมในเครือข่ายประสาทเทียม โดยพิจารณาในแง่ของความแม่นยำและระยะเวลาที่ใช้ในการฝึกแบบจำลอง จากการทบทวนวรรณกรรมพบว่าการเพิ่มจำนวนชั้นซ่อนส่งผลให้เวลาในการฝึกแบบจำลองเพิ่มขึ้น ในขณะเดียวกันความแม่นยำของแบบจำลองก็เพิ่มขึ้นเช่นกัน อย่างไรก็ตาม ควรระมัดระวังปัญหา overfitting ที่อาจเกิดขึ้นเมื่อใช้ชั้นซ่อนมากเกินไป

จากการศึกษางานทั้งหมดสามารถสรุปได้ว่า ผู้วิจัยจะเลือกทำการศึกษาในโครงสร้างที่มี 2 ชั้นซ่อน เนื่องจากเป็นจำนวนชั้นที่งานวิจัยแนะนำ อีกทั้งยังเป็นโครงสร้างเริ่มต้นของเครือข่ายประสาทเทียมเชิงลึก (Deep Neural Network) โดยในงานวิจัยนี้จะทำการทดลองกับฟังก์ชันกระตุ้นในชั้นซ่อนทั้งหมด 4 ชนิด เพื่อประเมินผลกระทบของฟังก์ชันกระตุ้นแต่ละชนิดที่มีต่อประสิทธิภาพการใช้ข้อมูลของเครือข่ายประสาทเทียมแบบหลายผลลัพธ์ ได้แก่ ฟังก์ชัน sigmoid, ReLU, LReLUs และ ELUs เนื่องจากฟังก์ชันเหล่านี้เป็นฟังก์ชันพื้นฐานและได้รับความนิยมอย่างมากในปัจจุบัน

3. วิธีการดำเนินการวิจัย

3.1 การจำลองข้อมูล

ในงานวิจัยนี้จะใช้ข้อมูลที่ทำการจำลองขึ้นมา โดยผู้วิจัยได้ทำการทดลองกับฟังก์ชันกระตุ้นในชั้นซ่อนทั้งหมด 4 ชนิด ได้แก่ ฟังก์ชัน sigmoid, ReLU, LReLUs และ ELUs โดยในแต่ละกรณีการทดลองจะทำการทดลองกับโครงสร้างทั้ง 3 ประเภท ได้แก่ เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด, เครือข่ายประสาทเทียมแบบสองผลลัพธ์ และเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว โดยในแต่ละกรณีการทดลองจะมีวิธีการจำลองข้อมูลที่เหมือนกัน

โดยจะกำหนดรอบการทดลอง 50 รอบการทดลอง และกำหนดให้มีตัวแปรอิสระทั้งหมด 8 ตัวที่จะถูกสุ่มมาจากการแจกแจงปกติมาตรฐาน (Standard normal distribution) มา 2000 ตัวอย่าง และ ทำซ้ำแต่ละแถวให้กลายเป็น 4000 ตัวอย่าง ทั้งหมด 50 ชุดต่อกรณีการทดลอง รวมไปถึงค่าน้ำหนักที่จะถูกสุ่มจากการแจกแจงปกติมาตรฐานทั้งหมด 50 ชุดต่อกรณีการทดลอง ในขณะที่ค่าอคติจะถูกกำหนดให้เป็นศูนย์

หลังจากนั้นจะทำการจำลองข้อมูลตัวแปรตามโดยใช้โครงสร้างเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดผ่านการใช้ single-response analogy และนำผลลัพธ์ที่ได้จากเครือข่ายประสาทเทียมมาสุ่มค่าจาก Bernoulli distribution โดยกระบวนการนี้จะทำทั้งหมด 50 รอบ ดังสมการที่ 2 และ สมการที่ 3

$$x_j = a_j^{[0]} \tag{2}$$

$$a^{[\ell]} = g^{[\ell]}\left(w^{[\ell]}a^{[\ell-1]} + b^{[\ell]}\right) \tag{3}$$

โดย $g^{[\ell]}$ ในชั้นที่ $\ell = 1,2,\ldots,L-1$ จะเปลี่ยนไปตามการทดลอง แต่ $g^{[\ell]}$ ในชั้นข้อมูลออก ($\ell = L$) ใช้ฟังก์ชัน sigmoid เสมอ

y คือ เวกเตอร์ของตัวแปรตาม ซึ่งเกิดจากการนำ $a^{[L]}$ ไปสุ่มจากการแจกแจง Bernoulli distribution

จากนั้นจะทำการแปลงข้อมูลที่ได้จากการจำลองภายใต้โครงสร้างเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดให้เหมาะสมกับโครงสร้างที่จะนำไปฝึกคือ แปลงจาก 4000 ตัวอย่าง 1 ผลลัพธ์ที่ได้จากการจำลองเป็น 2000 ตัวอย่าง 1 ผลลัพธ์โดยเลือกเฉพาะข้อมูลลำดับคี่เพื่อฝึกแบบจำลองเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว และแปลงเป็น 2000 ตัวอย่าง 2 ผลลัพธ์โดยจับคู่ระหว่างตัวแปรตามลำดับคี่และลำดับคู่จากตัวแปรอิสระที่ซ้ำกันดังที่สามารถแสดงได้ในภาพที่ 3 เพื่อฝึกแบบจำลองเครือข่ายประสาทเทียมแบบสองผลลัพธ์

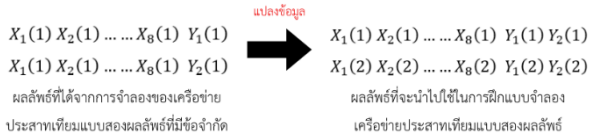

ภาพที่ 2: การแปลงข้อมูลที่ได้จากการจำลองเพื่อใช้ในการฝึกเครือข่ายประสาทเทียมแบบสองผลลัพธ์

และสุดท้ายจะทำการแบ่งชุดข้อมูลแต่ละชุดออกเป็นข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบในอัตราส่วน 50:50

3.2 การสร้างแบบจำลอง

เมื่อทำการจำลองข้อมูลเสร็จเรียบร้อยแล้ว จะทำการฝึกแบบจำลองในแต่ละกรณีการทดลองทั้งหมด 3 รูปแบบ ได้แก่ เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด, เครือข่ายประสาทเทียมแบบสองผลลัพธ์ และ เครือข่ายประสาทเทียมแบบผลลัพธ์เดียว ในงานวิจัยนี้ผู้วิจัยจะทำการทดลองกับฟังก์ชันกระตุ้นในชั้นซ่อนทั้งหมด 4 ชนิด คือ ฟังก์ชัน sigmoid, ReLU, LReLUs และ ELUs ซึ่งนำไปสู่ 4 กรณีการทดลอง ที่แตกต่างกันตามฟังก์ชันกระตุ้นที่ใช้ ทั้งนี้ในทุกกรณีการทดลองโครงสร้างของเครือข่ายประสาทเทียมแต่ละรูปแบบจะถูกกำหนดให้เหมือนกันหมด โดยจะสามารถแสดงได้ในภาพที่ 3 และ มีรายละเอียดดังนี้

1) เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด

ในงานวิจัยนี้ผู้วิจัยได้กำหนดให้มีตัวแปรอิสระทั้งหมด 8 ตัว และใช้โครงสร้างเครือข่ายประสาทเทียมแบบมี *2* ชั้นซ่อน โดยแต่ละชั้นซ่อนประกอบด้วย 8 โหนด เท่ากันทุกกรณี ทั้งนี้ฟังก์ชันกระตุ้นที่ใช้ในแต่ละชั้นซ่อนจะเป็นชนิดเดียวกัน ซึ่งจะถูกเปลี่ยนไปตามกรณีการทดลองนั้น ๆ และสำหรับชั้นข้อมูลออกจะมี 1 โหนดตามแนวคิด single-response analogy

2) เครือข่ายประสาทเทียมแบบสองผลลัพธ์

ในงานวิจัยนี้ผู้วิจัยได้กำหนดให้มีตัวแปรอิสระทั้งหมด 8 ตัว และใช้โครงสร้างเครือข่ายประสาทเทียมแบบมี *2* ชั้นซ่อน โดยแต่ละชั้นซ่อนประกอบด้วย 8 โหนด เท่ากันทุกกรณี ทั้งนี้ฟังก์ชันกระตุ้นที่ใช้ในแต่ละชั้นซ่อนจะเป็นชนิดเดียวกัน ซึ่งจะถูกเปลี่ยนไปตามกรณีการทดลองนั้น ๆ และสำหรับชั้นข้อมูลออกจะมี 2 โหนด

3) เครือข่ายประสาทเทียมแบบผลลัพธ์เดียว

ในงานวิจัยนี้ผู้วิจัยได้กำหนดให้มีตัวแปรอิสระทั้งหมด 8 ตัว และใช้โครงสร้างเครือข่ายประสาทเทียมแบบมี *2* ชั้นซ่อน โดยแต่ละชั้นซ่อนประกอบด้วย 8 โหนด เท่ากันทุกกรณี ทั้งนี้ฟังก์ชันกระตุ้นที่ใช้ในแต่ละชั้นซ่อนจะเป็นชนิดเดียวกัน ซึ่งจะถูกเปลี่ยนไปตามกรณีการทดลองนั้น ๆ และสำหรับชั้นข้อมูลออกจะมี 1 โหนด

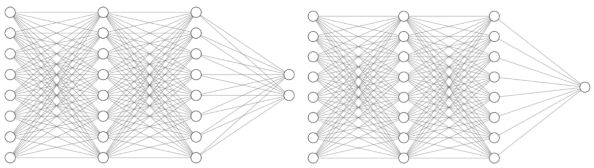

ภาพที่ 3: โครงสร้างเครือข่ายประสาทเทียมแบบสองผลลัพธ์และผลลัพธ์เดียว

3.3 การวัดประสิทธิภาพ

หลังจากทำการสร้างและฝึกแบบจำลองในแต่ละโครงสร้างครบถ้วนแล้ว การประเมินประสิทธิภาพจะถูกดำเนินการบนข้อมูลชุดทดสอบ โดยจะพิจารณาจากผลลัพธ์ที่ได้จาก $a_1^{[L]}$ เท่านั้น ซึ่งจะสามารถคำนวณได้ตามสมการที่ 4

$$P_t^k = -\frac{1}{n}\sum_{i=1}^{n} y_1^k(i)log(\hat{y}_1^k(i)) + (1-y_1^k(\mathrm{i}))log(1-\hat{y}_1^k(i)) \tag{4}$$

และเนื่องจากการฝึกแบบจำลองของแต่ละโครงสร้างจะทำทั้งหมด 50 รอบการทดลอง รอบละ 300 epochs ดังนั้นผู้วิจัยจะเลือกเก็บเฉพาะค่าฟังก์ชันการสูญเสียของ epoch สุดท้ายในแต่ละรอบการทดลอง เนื่องจากค่าดังกล่าวสะท้อนถึงประสิทธิภาพสูงสุดของแบบจำลอง ซึ่งเกิดจากการเรียนรู้ข้อมูลอย่างครบถ้วนและแบบจำลองมีการปรับพารามิเตอร์ให้

เหมาะสมที่สุดแล้ว จากนั้นนำมาหาค่าเฉลี่ยสำหรับ 50 รอบการทดลอง ซึ่งสามารถแทนได้ด้วย $\bar{P}^k$ และเขียนเป็นสมการได้ดังสมการที่ 5

$$\bar{P}^k = \frac{\sum_{t=1}^{50} P_t^k}{50} \quad (5)$$

จากนั้นจะนำค่า $\bar{P}^k$ ของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดไปเปรียบเทียบกับเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว ซึ่งทำหน้าที่เป็นแบบจำลองอ้างอิง (Baseline Model) เพื่อหาค่าความแตกต่างเชิงอุดมคติ (D_{Ideal}) และนำค่า $\bar{P}^k$ ของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ไปเปรียบเทียบกับเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว เพื่อหาค่าความแตกต่างเชิงปฏิบัติ ($D_{Practical}$) โดยการเปรียบเทียบจะดำเนินการภายใต้เครือข่ายประสาทเทียมในกรณีและฟังก์ชันกระตุ้นชนิดเดียวกัน ซึ่งจะสามารถอธิบายได้ด้วยสมการที่ 6 และ สมการที่ 7

$$D_{Ideal} = \frac{\bar{P}^k_{Single-response\ NN} - \bar{P}^k_{Constrained\ NN}}{\bar{P}^k_{Single-response\ NN}} \quad (6)$$

$$D_{Practical} = \frac{\bar{P}^k_{Single-response\ NN} - \bar{P}^k_{Bi-response\ NN}}{\bar{P}^k_{Single-response\ NN}} \quad (7)$$

สุดท้ายจะนำ D_{Ideal} ไปเปรียบเทียบกับ $D_{Practical}$ เพื่อวิเคราะห์ผลกระทบของฟังก์ชันกระตุ้นแต่ละชนิดในชั้นซ่อนที่มีต่อประสิทธิภาพในการใช้ข้อมูล โดยใช้สมการที่ 8

$$Different = D_{Practical} - D_{Ideal} \quad (8)$$

ตารางที่ 1: ผลลัพธ์ที่วัดบนข้อมูลชุดทดสอบ

	ฟังก์ชัน sigmoid	ฟังก์ชัน ReLU	ฟังก์ชัน LReLUs	ฟังก์ชัน ELUs
ค่าเฉลี่ยของฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว	0.5240	0.3252	0.3229	0.2533
ค่าเฉลี่ยของฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด	0.5228	0.2962	0.2945	0.2386
ค่าเฉลี่ยของฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบสองผลลัพธ์	0.5229	0.2964	0.2993	0.2449
ค่าความแตกต่างเชิงปฏิบัติ	0.0021	0.0886	0.0731	0.0332
ค่าความแตกต่างเชิงอุดมคติ	0.0023	0.0892	0.0880	0.0580
ผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติ	-0.0191%	-0.0615%	-1.4865%	-2.4872%

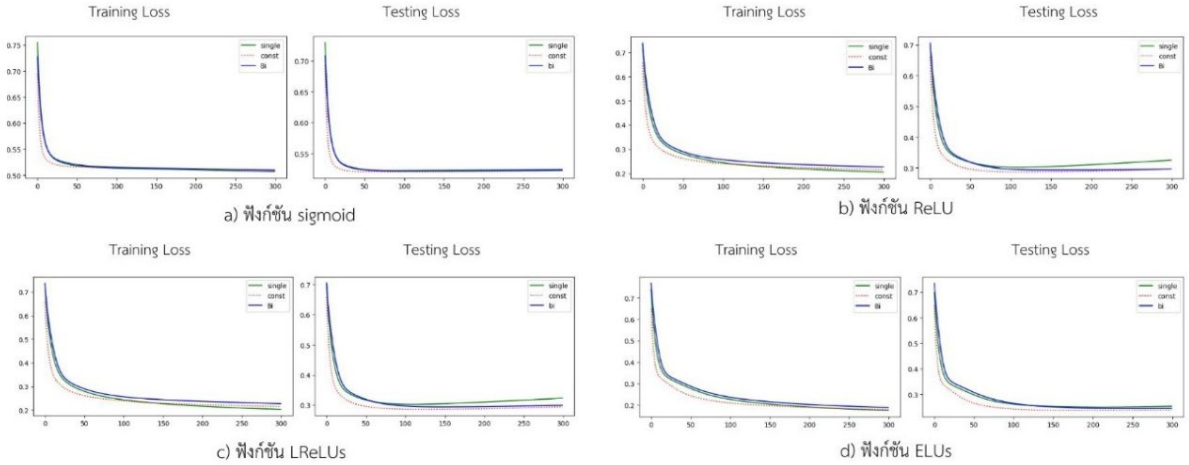

ภาพที่ 4: กราฟค่าเฉลี่ยฟังก์ชันการสูญเสีย (Loss Function) ในแต่ละ epoch จากการทดลองทั้งหมด 50 รอบ ของข้อมูลชุดฝึกฝน และ ข้อมูลชุดทดสอบ

4. ผลการวิจัยและอภิปรายผล

จากการทดลอง ค่าเฉลี่ยฟังก์ชันการสูญเสียของฟังก์ชันกระตุ้นในชั้นซ่อนแต่ละชนิดที่ได้จากแบบจำลองของโครงสร้างเครือข่ายประสาทเทียม ซึ่งประกอบด้วย 3 รูปแบบ ได้แก่ เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด, เครือข่ายประสาทเทียมแบบสองผลลัพธ์ และเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว รวมไปถึงค่าความแตกต่างเชิงปฏิบัติ, ค่าความแตกต่างเชิงอุดมคติ และผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติที่วัดบนข้อมูลชุดทดสอบที่ได้จากการจำลองจากการทดลองทั้งหมด 50 รอบ โดยแต่ละรอบดำเนินการฝึกแบบจำลองเป็นจำนวน 300 epochs

ค่าทั้งหมดนี้คำนวณจากประสิทธิภาพของแบบจำลองที่ epoch สุดท้ายของแต่ละการทดลอง เนื่องจากค่าดังกล่าวสะท้อนถึงประสิทธิภาพสูงสุดของแบบจำลอง ซึ่งเกิดจากการเรียนรู้ข้อมูลอย่างครบถ้วนและมีการปรับค่าพารามิเตอร์ให้เหมาะสมที่สุดแล้ว ทั้งนี้ผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติหมายถึงความต่างระหว่างค่าประสิทธิภาพของเชิงปฏิบัติกับเชิงอุดมคติ ซึ่งค่าผลต่างที่น้อยหรือใกล้ศูนย์แสดงถึงความใกล้เคียงกันระหว่างประสิทธิภาพเชิงปฏิบัติและเชิงอุดมคติ ในขณะที่ค่าผลต่างที่เป็นบวกบ่งชี้ว่าผลลัพธ์จากเชิงปฏิบัติสามารถเพิ่มประสิทธิภาพได้ดีกว่าเชิงอุดมคติ และหากค่าผลต่างเป็นลบจะหมายความว่าผลลัพธ์เชิงปฏิบัติยังไม่สามารถเทียบเท่ากับผลลัพธ์ที่ได้จากเชิงอุดมคติ โดยผลลัพธ์ต่าง ๆ จากการทดลองสามารถสรุปและนำเสนอได้ในตารางที่ 1

และจากการทดลองพบว่า ฟังก์ชันกระตุ้นในชั้นซ่อนแต่ละชนิดจะมีค่าเฉลี่ยของฟังก์ชันการสูญเสียในแต่ละ epoch จากการทดลองทั้งหมด 50 รอบแตกต่างกัน ดังที่สามารถแสดงได้ในภาพที่ 5

จากผลลัพธ์ที่ได้ เมื่อพิจารณาผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติที่แสดงในตารางที่ 1 พบว่าผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติของฟังก์ชันกระตุ้นทุกชนิดมีค่าเป็นลบทั้งหมด ซึ่งแสดงให้เห็นว่าเครือข่ายประสาทเทียมแบบสองผลลัพธ์ซึ่งเป็นผลลัพธ์ในเชิงปฏิบัติ ยังไม่สามารถลดค่าฟังก์ชันการสูญเสียให้เทียบเท่ากับผลลัพธ์ที่คาดหวังในเชิงอุดมคติหรือเชิงทฤษฎีได้อย่างสมบูรณ์

โดยเมื่อทำการเปรียบเทียบผลต่างระหว่างค่าความแตกต่างเชิงปฏิบัติและเชิงอุดมคติของฟังก์ชันกระตุ้นทั้ง 4 ชนิด พบว่าฟังก์ชัน sigmoid ให้ค่าผลต่างที่ใกล้ศูนย์มากที่สุดที่ -0.0191% ซึ่งหมายความว่าผลลัพธ์เชิงปฏิบัติที่ได้จากการใช้งานฟังก์ชัน sigmoid มีค่าฟังก์ชันการสูญเสียที่ใกล้เคียงกับผลลัพธ์เชิงอุดมคติมากที่สุด รองลงมาคือ ReLU. LReLUs และ ELUs ตามลำดับ

จากการพิจารณากราฟของข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบที่แสดงในภาพที่ 5 พบว่าไม่มีการ Overfitting เกิดขึ้น เนื่องจากค่าเฉลี่ยฟังก์ชันการสูญเสียของข้อมูลชุดทดสอบไม่ได้มีแนวโน้มเพิ่มขึ้นเมื่อเทียบกับข้อมูลชุดฝึกฝน

เมื่อพิจารณากราฟของข้อมูลชุดทดสอบจากส่วนที่ a ของภาพที่ 5 ซึ่งใช้ฟังก์ชันกระตุ้นในชั้นซ่อนเป็นฟังก์ชัน sigmoid พบว่าเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด (const) ใช้เวลาในการลู่เข้าน้อยกว่าเครือข่ายประสาทเทียมแบบผลลัพธ์เดียว (single) และเครือข่ายประสาทเทียมแบบสองผลลัพธ์ (bi) อีกทั้งยังมีค่าฟังก์ชันการสูญเสียที่ต่ำกว่าแบบจำลองอื่น ๆ ในช่วงเริ่มต้นของการเรียนรู้ ก่อนที่แบบจำลองทั้ง 3 แบบจำลองจะมีแนวโน้มของค่าฟังก์ชันการสูญเสียที่ใกล้เคียงกันในช่วงท้ายของการเรียนรู้

สำหรับส่วนที่ b ของภาพที่ 5 ซึ่งใช้ฟังก์ชันกระตุ้นในชั้นซ่อนเป็นฟังก์ชัน ReLU พบว่าเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดใช้เวลาในการลู่เข้าน้อยกว่าแบบจำลองอีก 2 แบบจำลอง และเมื่อเข้าสู่ช่วงท้ายของการเรียนรู้ค่าฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดและเครือข่ายประสาทเทียมแบบสองผลลัพธ์จะมีค่าใกล้เคียงกัน ในขณะที่เครือข่ายประสาทเทียมแบบผลลัพธ์เดียวมีค่าฟังก์ชันการสูญเสียสูงกว่าอีกสองแบบจำลองอย่างชัดเจน

ในส่วนที่ c ของภาพที่ 5 ซึ่งใช้ฟังก์ชันกระตุ้นในชั้นซ่อนเป็นฟังก์ชัน Leaky ReLU (LReLUs) พบว่าผลลัพธ์ที่ได้มีแนวโน้มสอดคล้องกับส่วนที่ b ของภาพที่ 5 กล่าวคือ เครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดยังคงใช้เวลาในการลู่เข้าน้อยกว่าแบบจำลองอื่น ๆ และมีแนวโน้มของค่าฟังก์ชันการสูญเสียที่ใกล้เคียงกับเครือข่ายประสาทเทียมแบบสองผลลัพธ์ ในขณะที่เครือข่ายประสาทเทียมแบบผลลัพธ์เดียวมีค่าฟังก์ชันการสูญเสียสูงกว่าอีกสองแบบจำลองอย่างชัดเจนในช่วงท้ายของการเรียนรู้

สุดท้ายส่วนที่ d ของภาพที่ 5 ซึ่งใช้ฟังก์ชันกระตุ้นในชั้นซ่อนเป็นฟังก์ชัน Exponential Linear Unit (ELUs) พบว่าเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดยังคงใช้เวลาในการลู่เข้าน้อยกว่าอีก 2 แบบจำลอง อย่างไรก็ตาม ค่าฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัดจะมีค่าที่ต่ำกว่าอย่างเห็นได้ชัด ในขณะที่เครือข่ายประสาทเทียมแบบผลลัพธ์เดียว และ เครือข่ายประสาทเทียมแบบสองผลลัพธ์จะมีค่าฟังก์ชันการสูญเสียที่ใกล้เคียงกัน

5. สรุปผล

ตามวัตถุประสงค์ของงานวิจัยนี้ที่ต้องการเปรียบเทียบผลกระทบของฟังก์ชันกระตุ้นแต่ละชนิดในชั้นซ่อนที่มีต่อประสิทธิภาพการใช้ข้อมูลของโครงสร้างเครือข่ายประสาทเทียม จากผลการวิจัยที่ได้สามารถสรุปได้ดังนี้ จากผลลัพธ์ที่ได้พบว่า ทั้งผลลัพธ์จากกราฟและผลต่างระหว่างค่าความแตกต่างเชิงอุดมคติและเชิงปฏิบัติ ฟังก์ชัน sigmoid เป็นฟังก์ชันกระตุ้นในชั้นซ่อนที่สามารถทำให้ค่าฟังก์ชันการสูญเสียของเครือข่ายประสาทเทียมแบบสองผลลัพธ์ (ผลลัพธ์เชิงปฏิบัติ) มีค่าใกล้เคียงกับเครือข่ายประสาทเทียมแบบสองผลลัพธ์ที่มีข้อจำกัด (ผลลัพธ์เชิงทฤษฎี) มากที่สุด รองลงมาคือ ฟังก์ชัน ReLU, ฟังก์ชัน

LReLUs และ ฟังก์ชัน ELUs ตามลำดับ โดยปัจจัยที่ทำให้ฟังก์ชัน sigmoid ให้ผลลัพธ์ที่ใกล้เคียงกับค่าทฤษฎีมากที่สุด เกิดจากคุณสมบัติของความไม่เป็นเชิงเส้น (non-linearity) ของฟังก์ชัน sigmoid ที่ให้ค่าผลลัพธ์อยู่ระหว่าง 0 ถึง 1 ทำให้ผลลัพธ์ที่ได้ไม่สูงหรือต่ำเกินไป ส่งผลให้การเปลี่ยนแปลงของฟังก์ชันการสูญเสียไม่ต่างกันมากจึงทำให้ผลลัพธ์เชิงปฏิบัติและเชิงทฤษฎีมีค่าใกล้เคียงกัน

จากผลการวิจัยดังกล่าวสามารถนำไปประยุกต์ใช้งานได้กับหลากหลายสาขาที่มีข้อจำกัดทางด้านข้อมูล เช่น การวินิจฉัยโรคทางด้านการแพทย์ที่อาศัยการตรวจวัดตัวชี้วัดทางสุขภาพหลาย ๆ ตัวจากผู้ป่วยคนเดียวกัน เช่น ผลการตรวจเลือด ผลเอ็กซ์เรย์ และการประเมินทางคลินิก ซึ่งต้องการแบบจำลองที่สามารถแบ่งปันและใช้ข้อมูลร่วมกันได้อย่างมีประสิทธิภาพ

6. เอกสารอ้างอิง

[1] Kiatsupaibul S, Chansiripas P. Data Efficiency in Multi-response Neural Networks. Unpublished.

[2] ธนาวุฒิ ประกอบผล. โครงข่ายประสาทเทียม. วารสารมฉก.วิชาการ. 2552;12(24); 73-87.

[3] Géron, A. Hands-on machine learning with Scikit-Learn and TensorFlow concepts, tools, and techniques to build intelligent systems. 2nd ed. California: O'Reilly Media, Inc; 2019.

[4] ชิตพงษ์ กิตตินราดร. Neural Network Algorithm [อินเทอร์เน็ต]. 2563 [เข้าถึงเมื่อ 18 กันยายน 2567]. เข้าถึงได้จาก: https://guopai.github.io/ml-blog14.html

[5] Panchal G, Ganatra A, Kosta Y, Panchal D. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. International Journal of Computer Theory and Engineering. 2011;3(2): 332-337. DOI: 10.7763/IJCTE.2011.V3.328.

[6] Karsoliya S. Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture. International journal of engineering trends and technology [Internet]. 2012 [cited 2024 Sep 18]; 3(6): 714-717. Available from: https://ijettjournal.org

[7] Uzair M, Jamil N. Effects of Hidden Layers on the Efficiency of Neural Networks. Proceedings of 2020 IEEE 23rd international multitopic conference (INMIC); 2020 Nov 5-7; Bahawalpur, Pakistan. IEEE; 2020. p. 1-6.

[8] Shams SR, Jahani A, Kalantary S, Moeinaddini M, Khorasani N. The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO2 concentration. Urban Climate. 2021;37:100837.

[9] Siavash NK, Ghobadian B, Najafi G, Rohani A, Tavakoli T, Mahmoodi E, et al. Prediction of power generation and rotor angular speed of a small wind turbine equipped to a controllable duct using artificial neural network and multiple linear regression. Environmental research. 2021; 196: 110434.

ประสิทธิภาพการพยากรณ์ของการวิเคราะห์เชิงฟังก์ชันและการเรียนรู้เชิงลึก

Forecasting Performance of Functional Data Analysis and Deep Learning

บุณฑริกา พรหมสถิตย์*

ภาควิชาสถิติและวิทยาการข้อมูล จุฬาลงกรณ์มหาวิทยาลัย

(* *6680216526@student.chula.ac.th*)

บทคัดย่อ

การวิจัยนี้เปรียบเทียบประสิทธิภาพการพยากรณ์ของตัวแบบ Functional Principal Component Regression (FPCR) กับตัวแบบการเรียนรู้เชิงลึก (RNN, LSTM, GRU) ภายใต้สถานการณ์ที่มีความผันผวนแตกต่างกัน โดยใช้ชุดข้อมูลที่มีความผันผวนต่ำ (อุณหภูมิเฉลี่ยรายวัน), ปานกลาง (ปริมาณ PM 2.5 รายชั่วโมง) และสูง (อัตราการแลกเปลี่ยน Bitcoin รายนาที) ศึกษาการพยากรณ์ระยะสั้น ระยะกลาง และระยะยาว โดยใช้ตัวชี้วัด Mean Squared Error (MSE) และ Mean Integrated Squared Error (MISE) ผลการศึกษาพบว่า สำหรับข้อมูลที่มีความผันผวนต่ำ FPCR ให้ผลลัพธ์ที่แม่นยำกว่าตัวแบบการเรียนรู้เชิงลึก โดยเฉพาะในการพยากรณ์ระยะกลางและระยะยาว ในทางกลับกัน สำหรับข้อมูลที่มีความผันผวนสูง FPCR เหนือกว่าการเรียนรู้เชิงลึกเฉพาะการพยากรณ์ระยะกลางเท่านั้น สำหรับข้อมูลที่มีความผันผวนปานกลางและสูง ขนาดของชุดข้อมูลฝึกไม่มีผลกระทบอย่างชัดเจนต่อประสิทธิภาพของตัวแบบทั้งสอง อย่างไรก็ตาม ในกรณีของข้อมูลที่มีความผันผวนต่ำ เมื่อมีชุดข้อมูลขนาดใหญ่ ตัวแบบการเรียนรู้เชิงลึกให้ผลลัพธ์ที่แม่นยำกว่า FPCR ในขณะที่ FPCR มีความแม่นยำสูงกว่าหากใช้ข้อมูลจำนวนน้อยและทำการพยากรณ์ในระยะกลางถึงระยะยาว นอกจากนี้ ในการพยากรณ์ระยะสั้น FPCR มักให้ผลลัพธ์ที่ด้อยกว่าตัวแบบการเรียนรู้เชิงลึกในทุกกรณี

คำสำคัญ: การวิเคราะห์เชิงฟังก์ชัน, การวิเคราะห์อนุกรมเวลา, การเรียนรู้เชิงลึก, การถดถอยขององค์ประกอบหลักเชิงฟังก์ชัน, เครือข่ายประสาทเทียมแบบวนกลับ, เครือข่ายประสาทเทียมหน่วยความจำระยะยาวและสั้น, เครือข่ายประสาทเทียมหน่วยเวียนกลับแบบมีประตู

Abstract

This study compares the forecasting performance of functional principal component regression (FPCR) with deep learning models (RNN, LSTM, and GRU) under different levels of volatility. The datasets used include low volatility (daily average temperature), moderate volatility (hourly $PM2.5$ levels), and high volatility (minutely Bitcoin exchange rates). The evaluation considers short-term, medium-term, and long-term forecasting horizons, using Mean Squared Error (MSE) and Mean Integrated Squared Error (MISE) as performance metrics. The results indicate that for low-volatility data, FPCR provides more accurate results than deep learning models, particularly for medium- and long-term forecasts. In contrast, for high-volatility data, FPCR outperforms deep learning models only for medium-term forecasts. For medium- and high-volatility data, the training dataset size does not significantly affect the performance of either model. However, for low-volatility data, deep learning models produce more accurate forecasts when trained on large datasets, while FPCR performs better when trained on smaller datasets, particularly for medium- and long-term forecasts. Additionally, for short-term forecasts, FPCR consistently delivers less accurate results compared to deep learning models in all cases.

Keywords: functional data analysis, time series analysis, deep learning, functional principal component regression, RNN, LSTM, GRU

1. บทนำ

การวิเคราะห์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันเป็นหนึ่งในแนวทางการพยากรณ์ข้อมูลอนุกรมเวลาโดยที่ข้อมูลเป็นข้อมูลเชิงฟังก์ชัน (Functional Data) ที่มีลักษณะเป็นฟังก์ชันต่อเนื่อง เช่น การวัดคลื่นสมอง การเปลี่ยนแปลงของอุณหภูมิ หรืออัตราการเติบโตของเด็กที่เปลี่ยนแปลงตามเวลา ซึ่งข้อมูลประเภทนี้มีความจำเป็นต้องใช้วิธีการที่สามารถตรวจจับความเปลี่ยนแปลงในลักษณะที่ต่อเนื่องได้อย่างมีประสิทธิภาพ

หนึ่งในเทคนิคที่สำคัญภายใต้การวิเคราะห์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันคือ Functional Principal Component Regression (FPCR) ซึ่งผสานรวมการวิเคราะห์องค์ประกอบหลักเชิงฟังก์ชัน การวิเคราะห์การถดถอยและการวิเคราะห์ข้อมูลอนุกรมเวลาเข้าด้วยกัน โดยเทคนิคนี้สามารถลดมิติของข้อมูลเชิงฟังก์ชันและสร้างแบบจำลองที่มีประสิทธิภาพในการพยากรณ์ข้อมูลอนุกรมเวลาเชิงฟังก์ชัน ทำให้เป็นเครื่องมือที่สำคัญในการพยากรณ์ข้อมูลอนุกรมเวลาที่มีลักษณะเชิงฟังก์ชัน

ทั้งนี้ FPCR มีเงื่อนไขที่สำคัญดังเช่นตัวแบบทางสถิติอื่น ๆ คือ การที่ตัวแบบต้องพึ่งพาสมมติฐานเกี่ยวกับลักษณะของข้อมูล ดังเช่น ความต่อเนื่องและโครงสร้างของข้อมูลเชิงฟังก์ชัน [1] ซึ่งส่งผลให้ FPCR อาจไม่สามารถจัดการกับข้อมูลที่ไม่สม่ำเสมอหรือมีความผันผวนสูงได้อย่างมีประสิทธิภาพ ทำให้เกิดความจำเป็นในการเปรียบเทียบกับวิธีการที่ใช้แนวทางต่างออกไปจากตัวแบบทางสถิติ เช่น การเรียนรู้เชิงลึก ซึ่งสามารถลดข้อจำกัดของ FPCR ได้ในบางแง่มุม

นอกเหนือจากเทคนิคการวิเคราะห์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันข้างต้นที่ได้กล่าวไป ในปัจจุบันเทคนิคเครือข่ายประสาทเทียม (Artificial Neural Networks: ANN) ซึ่งเป็นแขนงหนึ่งของการเรียนรู้เชิงลึก ยังเป็นเทคนิคที่มีความยืดหยุ่นและความสามารถในการจัดการกับข้อมูลที่มีความซับซ้อนสูงและไม่เป็นเชิงเส้น โดย ANN สามารถเรียนรู้จากข้อมูลที่มีความหลากหลายและมีความซับซ้อนสูง ทำให้ ANN กลายเป็นเครื่องมือที่มีศักยภาพในการพยากรณ์ข้อมูลอนุกรมเวลาที่มีความซับซ้อน อีกทั้ง ANN ยังมีสถาปัตยกรรมในรูปแบบที่หลากหลายเพื่อให้สามารถเลือกใช้ให้เหมาะสมกับงานได้

ในส่วนของการพยากรณ์ข้อมูลอนุกรมเวลา หนึ่งในสถาปัตยกรรมที่เหมาะสมและเป็นที่นิยมคือ เครือข่ายประสาทเทียมแบบวนซ้ำ (Recursive Neural Network: RNN) ซึ่งมีรูปแบบสถาปัตยกรรมที่ถูกต่อยอดและเป็นที่นิยมอีก 2 รูปแบบได้แก่ เครือข่ายประสาทเทียมหน่วยความจำระยะยาวและสั้น (Long Short-term Memory: LSTM) เครือข่ายประสาทเทียมหน่วยเวียนกลับแบบมีประตู (Gated Recurrent Unit: GRU) ซึ่งเหมาะกับการนำข้อมูลในอดีตมาวิเคราะห์และพยากรณ์ข้อมูลในอนาคตที่ต่อเนื่องกัน

แม้ว่า RNN จะได้รับความนิยมและถูกนำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลาในหลากหลายบริบท [2,3] แต่ยังไม่มีการศึกษาใดที่ทำการเปรียบเทียบประสิทธิภาพของตัวแบบการเรียนรู้เชิงลึกประเภทต่าง ๆ กับ FPCR อย่างเป็นระบบและชัดเจนในบริบทของการพยากรณ์ข้อมูลที่มีลักษณะเชิงฟังก์ชัน การศึกษาเชิงเปรียบเทียบดังกล่าวมีความสำคัญอย่างยิ่งในการทำความเข้าใจศักยภาพและข้อจำกัดของตัวแบบการเรียนรู้เชิงลึกในการจัดการกับข้อมูลเชิงฟังก์ชัน อีกทั้งยังช่วยระบุสถานการณ์ที่ FPCR ยังคงมีข้อได้เปรียบเหนือเทคนิคการเรียนรู้เชิงลึก ซึ่งจะเป็นประโยชน์ต่อทั้งผู้วิจัยและผู้ปฏิบัติงานที่ต้องการเลือกใช้หรือพัฒนาตัวแบบพยากรณ์ข้อมูลอนุกรมเวลาให้เหมาะสมกับลักษณะของข้อมูล

งานวิจัยฉบับนี้มีเป้าหมายเพื่อเติมเต็มช่องว่างดังกล่าว โดยทำการเปรียบเทียบประสิทธิภาพของ FPCR กับตัวแบบการเรียนรู้เชิงลึก ได้แก่ RNN, Long Short-Term Memory (LSTM), และ Gated Recurrent Unit (GRU) ภายใต้บริบทของข้อมูลที่มีความผันผวนแตกต่างกัน ทั้งในระดับต่ำ (อุณหภูมิเฉลี่ยรายวัน), ระดับปานกลาง (ปริมาณ PM2.5 รายชั่วโมง), และระดับสูง (อัตราแลกเปลี่ยน Bitcoin รายนาที) การศึกษานี้ครอบคลุมการพยากรณ์ระยะสั้น ระยะกลาง และระยะยาว โดยใช้ Mean Squared Error (MSE) และ Mean Integrated Squared Error (MISE) เป็นตัวชี้วัดหลักในการประเมินประสิทธิภาพ เพื่อให้ได้ข้อสรุปที่ชัดเจนเกี่ยวกับจุดแข็ง ข้อจำกัด และศักยภาพของแต่ละวิธีการ ซึ่งจะเป็นแนวทางสำคัญในการพัฒนาเทคนิคการพยากรณ์อนุกรมเวลาให้มีประสิทธิภาพยิ่งขึ้นในอนาคต

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การวิเคราะห์อนุกรมเวลาของข้อมูลประเภทฟังก์ชัน

การวิเคราะห์อนุกรมเวลาของข้อมูลประเภทฟังก์ชัน (Functional Time Series: FTS) เป็นแนวคิดในการวิเคราะห์ข้อมูลอนุกรมเวลาที่ถือว่าข้อมูลที่ถูกเก็บในแต่ละจุดในช่วงเวลานั้นมาจากฟังก์ชันที่ต่อเนื่อง (Smooth Function) ซึ่งมีความแตกต่างจากการวิเคราะห์อนุกรมเวลาแบบทั่วไปที่จะมองข้อมูลเป็นจุดข้อมูล (Discrete point)

เนื่องจาก FTS เป็นการวิเคราะห์ที่มีข้อมูลประเภทฟังก์ชันต่อเนื่อง (Functional Data) เข้ามาเกี่ยวข้อง ทำให้เหมาะสมกับการวิเคราะห์ข้อมูลที่มีความซับซ้อนสูง โดยข้อมูลสามารถเป็นฟังก์ชันบนโดเมนบางอย่าง และสามารถแสดงถึงปรากฏการณ์ต่าง ๆ เช่น กราฟการเจริญเติบโต กราฟอุณหภูมิรายวัน หรืออัตราการเจริญพันธุ์รายปีในกลุ่มอายุต่าง ๆ เป็นต้น โดยหนึ่งในความสนใจของ FTS คือการทำนายฟังก์ชันในอนาคต เช่น อัตราการเจริญพันธุ์ในกลุ่มอายุต่าง ๆ ในปีถัดไป

ลักษณะสำคัญของ FTS ได้แก่

1) ความต่อเนื่องของข้อมูล: ข้อมูลใน FTS มักจะเป็นข้อมูลที่ต่อเนื่อง เช่น การวัดอุณหภูมิทุกชั่วโมงภายในแต่ละวัน หรือการวัดอัตราการเต้นของหัวใจในช่วงเวลาต่าง ๆ ถึงแม้ในหลาย ๆ บริบทข้อมูลเหล่านี้จะถูกเก็บมาเป็น จุดข้อมูลที่ไม่ต่อเนื่องแต่ข้อมูลจะถูกแทนที่ด้วยฟังก์ชันซึ่งแสดงถึงค่าที่เปลี่ยนแปลงไปตามโดเมน

2) การแสดงผลเป็นฟังก์ชัน: แทนที่จะเป็นจุดข้อมูลที่ไม่ต่อเนื่อง ข้อมูล FTS ถูกแสดงผลในรูปของฟังก์ชันที่ต่อเนื่อง

ข้อมูลนี้สามารถวิเคราะห์ได้ด้วยวิธีการทางคณิตศาสตร์ที่พัฒนามาเฉพาะสำหรับข้อมูลที่เป็นฟังก์ชัน

3) ความสัมพันธ์เชิงเวลา: ฟังก์ชันในแต่ละช่วงเวลามีความสัมพันธ์กับค่าของช่วงเวลาอื่น ๆ ความสัมพันธ์นี้เป็นสิ่งที่จำเป็นในการทำนายฟังก์ชันในอนาคต

ด้วยลักษณะสำคัญดังกล่าว FTS จึงแตกต่างจากการวิเคราะห์ข้อมูลที่ไม่ต่อเนื่อง เนื่องจากข้อมูล FTS ถูกแสดงเป็นฟังก์ชัน การวิเคราะห์จึงต้องใช้วิธีการทางคณิตศาสตร์ที่เฉพาะเจาะจง เช่น การประมาณค่าโค้ง (Curve Fitting) หรือการสกัดคุณลักษณะสำคัญจากฟังก์ชัน เทคนิคที่ใช้ในการวิเคราะห์ FTS มีความซับซ้อนมากกว่าการวิเคราะห์ข้อมูลแบบดั้งเดิม เนื่องจากต้องคำนึงถึงความต่อเนื่องและความสัมพันธ์เชิงเวลาของข้อมูล

2.2 การถดถอยขององค์ประกอบหลักเชิงฟังก์ชัน (Functional Principal Component Regression: FPCR)

FPCR ใช้หลักการการวิเคราะห์องค์ประกอบหลักเชิงฟังก์ชัน (Functional Principal Component Analysis: FPCA) ในการช่วยลดมิติของข้อมูลเชิงฟังก์ชัน และแยกองค์ประกอบของฟังก์ชันในแต่ละจุดเวลาออกเป็น ฟังก์ชันเฉลี่ยและผลรวมของผลคูณระหว่างองค์ประกอบหลักเชิงฟังก์ชันที่ตั้งฉากต่อกัน (Orthogonal Functional Principal Components) และคะแนนองค์ประกอบหลัก (Principal Component Score) โดยองค์ประกอบหลักเชิงฟังก์ชันแรกจะอธิบายความแปรปรวนของข้อมูลมากที่สุดและน้อยลงเรื่อย ๆ ตามลำดับขององค์ประกอบหลักเชิงฟังก์ชัน ซึ่งเป็นไปดังสมการที่ (1) [4]

$$f_t(x) = \bar{f}_t(x) + \sum_{k=1}^{K} \hat{\beta}_{t,k}\hat{\phi}_k(x) + \hat{\epsilon}_k(x) \quad (1)$$

เมื่อ

$\bar{f}(x) = \frac{1}{n}\sum_{t=1}^{n} f_t(x)$ คือ ฟังก์ชันการประมาณฟังก์ชันเฉลี่ย

K คือ จำนวนองค์ประกอบหลัก

$\hat{\phi}_k(x)$ คือ องค์ประกอบหลักเชิงฟังก์ชันในลำดับที่ k

$\hat{\beta}_{t,k}$ คือ คะแนนองค์ประกอบหลักในลำดับที่ k ของจุดเวลาที่ t

ขั้นตอนของการใช้ FPCR ในการพยากรณ์มีดังนี้

1) คำนวณฟังก์ชันเฉลี่ยจากฟังก์ชันในทุกจุดเวลาคำนวณฟังก์ชันเฉลี่ยของฟังก์ชันในทุกการสังเกต

2) ใช้ FPCA คำนวณองค์ประกอบหลักเชิงฟังก์ชันหลักของฟังก์ชันความแตกต่างระหว่างฟังก์ชันในแต่ละจุดเวลากับฟังก์ชันเฉลี่ย $(f_t(x)-\bar{f}(x))$

3) คำนวณคะแนนองค์ประกอบหลัก $(\hat{\beta}_{t,k})$ ในทุกจุดเวลาของแต่ละฟังก์ชันองค์ประกอบหลัก

4) พยากรณ์คะแนนองค์ประกอบหลัก $(\hat{\beta}_{t+h,k})$ โดยใช้การวิเคราะห์อนุกรมเวลาแบบปกติ เมื่อคือขอบเขตการพยากรณ์ (Prediction Horizon)

5) แทนที่คะแนนองค์ประกอบหลักไว้ในสมการ ด้วยคะแนนที่พยากรณ์ในข้อ (4)

2.3 เครือข่ายประสาทเทียม (Artificial Neural Network)

เป็นตัวแบบทางคณิตศาสตร์ที่พัฒนาขึ้นโดยอ้างอิงจากโครงสร้างและการทำงานของสมองมนุษย์ที่มีเซลล์ประสาทคอยทำการส่งต่อข้อมูลหากันเพื่อประมวลผลข้อมูลได้อย่างมีประสิทธิภาพ ภายในตัวแบบเครือข่ายประสาทเทียมจะประกอบไปด้วยชั้น (Layer) ต่าง ๆ ได้แก่:

1) Input Layer: เป็นชั้นแรกที่รับข้อมูลเข้ามา โดยข้อมูลนี้สามารถเป็นข้อมูลตัวเลข รูปภาพ เสียงหรือข้อมูลชนิดอื่น ๆ ตามที่ผู้ใช้ต้องการให้ตัวแบบนำไปประมวลผล

2) Hidden Layer: เป็นชั้นที่อยู่ระหว่าง input layer และ output layer มีหน้าที่ประมวลผลข้อมูลจาก Input Layer หรือ Hidden Layer ชั้นก่อนหน้าเพื่อส่งต่อให้ Output Layer โดย Hidden Layer สามารถมีได้หลายชั้น ในแต่ละชั้นมีหน่วยประมวลผลที่เรียกว่า Neuron โดยในแต่ละ Neuron จะคำนวณค่าน้ำหนัก (Weight: w) และค่าเอนเอียง (Bias: b) จากข้อมูลที่ได้รับเข้ามาและนำผลที่ได้ไปประมวลผลผ่านฟังก์ชันการเปิดใช้งาน (Activation Function) เพื่อส่งผลลัพธ์ต่อไปยัง Neuron ในชั้นถัดไป

3) Output Layer: เป็นชั้นสุดท้ายที่ส่งผลลัพธ์ออกจากเครือข่ายตามที่ผู้ใช้ต้องการ

โดยสรุปแล้ว หลักการทำงานของเครือข่ายประสาทเทียมคือการส่งผ่านข้อมูลจาก Input Layer ผ่าน Hidden Layer ไปยัง Output Layer โดยในแต่ละขั้นตอนจะมีการปรับค่า Weight และ Bias ตามผลลัพธ์ที่ต้องการผ่านกระบวนการปรับค่าพารามิเตอร์เพื่อลดค่าความคลาดเคลื่อนระหว่างผลลัพธ์ที่คาดการณ์กับผลลัพธ์ที่แท้จริง

2.4 เครือข่ายประสาทเทียมแบบวนกลับ (Recursive Neural Network: RNN)

เป็นการต่อยอดจากเครือข่ายประสาทเทียมแบบดั้งเดิม โดยออกแบบมาให้สามารถรับรู้และจำข้อมูลที่มีลำดับหรือเรียงต่อกันได้ เช่น ข้อมูลอนุกรมเวลา ข้อความ หรือเสียง RNN มีลักษณะพิเศษที่เป็นการเชื่อมต่อย้อนกลับ (Recurrent Connections) ที่ทำให้ Neuron ใน Hidden Layer สามารถรับข้อมูลจากตัวเองในช่วงเวลาที่ผ่านมาได้ ส่งผลให้ตัวแบบสามารถรับรู้ลำดับของข้อมูลและนำมาพิจารณาในการทำนายค่าต่อไปได้

RNN มีความเหมาะสมกับการพยากรณ์ข้อมูลอนุกรมเวลา เนื่องจากข้อมูลลำดับเวลาเป็นข้อมูลที่มีความสัมพันธ์กันในแต่ละจุดข้อมูล โดยข้อมูลในแต่ละจุดเวลาจะถูกนำเข้าไปประมวลผลครั้งละหนึ่งจุด จากนั้นผลลัพธ์จากการประมวลผลในครั้งนี้จะถูกส่งไปร่วมประมวลผลกับข้อมูลในจุดเวลาหลังจากนี้ โดยสามารถแสดงได้ดังสมการที่ (2)

$$h_t = g(w_{hh}h_{h-1} + w_{hx}x_t) \quad (2)$$

เมื่อ

h_t คือ ผลลัพธ์ของ Hidden Layer ณ จุดเวลา t

$g(x)$ คือ ฟังก์ชันการเปิดใช้งาน

w_{hh} คือค่าน้ำหนักของผลลัพธ์จาก Hidden Layer ณ จุดเวลา $t-1$

w_{hx} คือค่าน้ำหนักของข้อมูล ณ จุดเวลา t
x_t คือ ข้อมูล ณ จุดเวลา t

การพยากรณ์ ณ จุดเวลา t สามารถทำได้โดยคำนวณจาก

$$y_t=g_y(w_{yh}h_t)$$

เมื่อ
y_t คือ ผลลัพธ์ที่คาดการณ์ ณ จุดเวลา t
$g_y(x)$ คือ ฟังก์ชันการเปิดใช้งาน
w_{yh} คือค่าน้ำหนักของข้อมูล ณ จุดเวลา t

ทั้งนี้ ตัวแบบ RNN มักประสบปัญหา Vanishing Gradient ระหว่างกระบวนการเรียนรู้ ซึ่งเป็นผลจากการที่ตัวแบบ RNN ใช้วิธีการนำผลลัพธ์จากจุดเวลาก่อนหน้าใส่ไว้ในสมการทับถมกันไปเรื่อย ๆ ส่งผลให้การปรับค่าน้ำหนักของข้อมูลในจุดแรก ๆ เป็นไปอย่างไม่มีประสิทธิภาพ ตัวแบบจึงไม่สามารถเรียนรู้ความสัมพันธ์ระยะยาวภายในข้อมูลได้ จึงมีการพัฒนาตัวแบบอื่น ๆ ขึ้นมาเพื่อแก้ไขปัญหาดังกล่าว

2.5 เครือข่ายประสาทเทียมหน่วยความจำระยะยาวและสั้น (Long Short-term Memory: LSTM)

LSTM [5] ต่อยอดจาก RNN เพื่อแก้ปัญหา Vanishing Gradient ที่มักเกิดขึ้นเมื่อมีการฝึกตัวแบบที่มีลำดับเวลาที่ยาว โดย LSTM ถูกออกแบบให้สามารถเก็บรักษาข้อมูลที่สำคัญและละทิ้งข้อมูลที่ไม่จำเป็นผ่านกลไก “Cell State” และ “Gate”

Cell State (c_t) คือส่วนที่ทำหน้าที่เป็นความทรงจำของตัวแบบ ช่วยให้ตัวแบบรักษาความทรงจำระยะยาวไว้ได้ และจะถูกปรับแต่งใหม่เมื่อมีข้อมูลใหม่ผ่านเข้ามา แต่ยังคงข้อมูลเก่าไว้ตามความจำเป็น

Gate เป็นส่วนที่ช่วยตัดสินใจในการละทิ้งและรับข้อมูลใหม่เข้าสู่ Cell State โดยองค์ประกอบของ LSTM มี Gate อยู่ 3 ส่วน ได้แก่

1) Forget Gate: เป็นส่วนที่ตัดสินใจว่าจะละทิ้งข้อมูลใดออกจาก Cell State โดยใช้ฟังก์ชัน Sigmoid ในการคำนวณปริมาณข้อมูลที่จะถูกเก็บไว้ 0 หมายถึง Gate นี้จะละทิ้งข้อมูลเก่าทั้งหมด และ 1 หมายถึง Gate นี้จะเก็บทุกอย่างไว้ โดยสมการเป็นไปดังนี้ $f_t=\sigma(w_{fh}h_{t-1}+w_{fx}x_t+b_f)$

2) Input Gate: เป็นส่วนที่ตัดสินใจว่าจะเพิ่มข้อมูลใดเข้าสู่ Cell State ซึ่งจะมีขั้นตอนของการคำนวณข้อมูลใหม่ที่จะถูกนำเข้า ($\tilde{c}_t$) และคำนวณปริมาณของข้อมูลใหม่ที่จะถูกนำเข้าไปรวมกับข้อมูลเก่า โดยมีสมการคำนวณข้อมูลใหม่ดังนี้ $\tilde{c}_t=tanh(w_{ch}h_{t-1}+w_{cx}x_t+b_c)$ และสมการคำนวณปริมาณข้อมูลใหม่ที่จะถูกนำเข้าสู่ Cell State ดังนี้ $i_t=\sigma(w_{ih}h_{t-1}+w_{ix}x_t+b_i)$

3) Output Gate: เป็นส่วนที่ตัดสินใจว่าจะมีการส่งต่อข้อมูลใดออกไปสู่การประมวลผลครั้งถัดไป โดยควบคุมการส่งต่อผ่านสมการ $o_t=\sigma(w_{oh}h_{t-1}+w_{ox}x_t+b_o)$ และมีสิ่งที่ต้องส่งต่อ 2 อย่างคือ Cell State ที่ถูกปรับค่าแล้ว ($c_t=c_{t-1}f_t+\tilde{c}_t i_t$) และผลลัพธ์จากการประมวลผลระยะสั้น ($h_t=o_t tanh(c_t)$)
เมื่อ
x_t คือ ข้อมูล Input ในจุดเวลา t
c_{t-1} คือ Cell State ในจุดเวลา $t-1$
h_t คือ ผลลัพธ์ของ Hidden Layer ณ จุดเวลา t
$\sigma(x)$ คือ ฟังก์ชันการเปิดใช้งาน Sigmoid
$tanh(x)$ คือ ฟังก์ชันการเปิดใช้งาน Tanh
w คือ ค่าน้ำหนัก
b คือ ค่าเอนเอียง

ด้วยโครงสร้างทั้งหมดนี้ ทำให้ LSTM สามารถเก็บรักษาข้อมูลที่มีความสำคัญในระยะยาวได้ดีกว่า RNN แบบดั้งเดิม และเป็นตัวแบบที่เหมาะสำหรับการทำงานกับข้อมูลที่มีลำดับยาวหรือมีลักษณะที่ซับซ้อน

2.6 เครือข่ายประสาทเทียมหน่วยเวียนกลับแบบมีประตู (Gated Recurrent Unit: GRU)

GRU [6] เป็นการต่อยอดจากตัวแบบ RNN ดั้งเดิมเพื่อแก้ไขปัญหา Vanishing Gradient เช่นเดียวกับ LSTM ทั้งนี้ GRU ถูกออกแบบมาให้มีความซับซ้อนน้อยกว่า LSTM จึงมักเร็วกว่า ต้องการทรัพยากรในการฝึกน้อยกว่า และสามารถใช้งานกับข้อมูลที่ซับซ้อนในระดับที่ไม่สูงมากได้ดี

GRU ใช้หลักการของ Gate คล้ายกับ LSTM แต่ลดจากการใช้ 3 Gate เป็นใช้เพียง 2 Gate ในการควบคุมการจดจำข้อมูล ได้แก่

1) Reset Gate: เป็นส่วนที่ตัดสินใจว่าจะละทิ้งข้อมูลออกไปเท่าใด โดยใช้ฟังก์ชัน Sigmoid ในการคำนวณปริมาณข้อมูลที่จะถูกเก็บไว้ 0 หมายถึง Gate นี้จะละทิ้งข้อมูลเก่าทั้งหมด และ 1 หมายถึง Gate นี้จะเก็บทุกอย่างไว้ โดยสมการเป็นไปดังนี้ $r_t=\sigma(w_{rh}h_{t-1}+w_{rx}x_t+b_r)$

2) Update Gate: เป็นส่วนที่ตัดสินใจว่าจะนำข้อมูลใหม่ปริมาณเท่าใดเข้ามาร่วมพิจารณาในการประมวลผล โดยใช้ฟังก์ชัน Sigmoid ในการคำนวณปริมาณข้อมูลใหม่ที่จะถูกนำมาใช้ 0 หมายถึง Gate นี้จะละทิ้งข้อมูลใหม่ทั้งหมด และ 1 หมายถึง Gate นี้จะเก็บข้อมูลใหม่ไว้ทั้งหมด โดยสมการเป็นไปดังนี้ $z_t=\sigma(w_{zh}h_{t-1}+w_{zx}x_t+b_z)$

ในขณะที่ผลลัพธ์ของการประมวลผล ณ จุดเวลา t ($h_t=(1-z_t)h_{t-1}+z_t\tilde{h}_t$) จะเป็นผลรวมของความทรงจำเก่า (h_{t-1}) และข้อมูลใหม่ตามสัดส่วนที่ถูกคำนวณไว้ใน Update Gate ($\tilde{h}_t=tanh(w_{hr}(r_t h_{t-1})+w_{hx}x_t+b_h)$)
เมื่อ
x_t คือ ข้อมูล Input ในจุดเวลา t
h_t คือ ผลลัพธ์ของ Hidden Layer ณ จุดเวลา t
$\sigma(x)$ คือ ฟังก์ชันการเปิดใช้งาน Sigmoid
$tanh(x)$ คือ ฟังก์ชันการเปิดใช้งาน Tanh
w คือ ค่าน้ำหนัก
b คือ ค่าเอนเอียง

โครงสร้างของ GRU ทำให้ตัวแบบสามารถเก็บข้อมูลสำคัญและละทิ้งข้อมูลที่ไม่สำคัญได้อย่างมีประสิทธิภาพ และด้วยความเรียบง่ายของโครงสร้าง จึงส่งผลให้ GRU ใช้เวลาในการฝึกฝนที่รวดเร็วกว่า LSTM ในหลายๆ กรณี [7]

2.7 การพยากรณ์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันด้วยเครือข่ายประสาทเทียม

ในขณะที่มีการพัฒนาเครือข่ายประสาทเทียมให้ประมวลผลข้อมูลเชิงฟังก์ชันอยู่บ้าง เพื่อให้รับข้อมูลเชิงฟังก์ชันได้ [8,9] แต่ในปัจจุบันงานวิจัยเกี่ยวกับการใช้เครือข่ายประสาทเทียมในการพยากรณ์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันโดยตรงยังไม่แพร่หลายมากนัก ทั้งนี้ ในงานวิจัยฉบับนี้จะประยุกต์ใช้การวิเคราะห์และพยากรณ์ข้อมูลด้วยขอบเขตการพยากรณ์ที่ยาวเท่ากับความยาวของโดเมนของข้อมูลอนุกรมเชิงฟังก์ชัน เพื่อนำมาทดสอบและเปรียบเทียบประสิทธิภาพกับวิธีการวิเคราะห์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันโดยตรงดังเช่น FPCR โดยมุ่งเน้นไปที่การพยากรณ์ข้อมูลอนุกรมเวลาเชิงฟังก์ชันที่มีโดเมนเป็นเวลา

การวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลาด้วยขอบเขตการพยากรณ์ที่ยาวถูกนำไปใช้ในหลายบริบท เช่น การพยากรณ์ราคานิกเกิลในระยะยาว [10] การพยากรณ์ปริมาณพลังงานลมในระยะยาว [11] และ การพยากรณ์ปริมาณการใช้ไฟฟ้าในระยะยาว [12] ซึ่งพบว่า เครือข่ายประสาทเทียมสามารถทำการพยากรณ์ระยะยาวได้อย่างมีประสิทธิภาพ เนื่องจากเครือข่ายประสาทเทียมแบบวนซ้ำสามารถเรียนรู้จากข้อมูลในลำดับก่อนหน้าได้ จึงสามารถจับความสัมพันธ์และสามารถประมวลผลลำดับเวลาในระยะยาวได้

แม้ว่าการใช้เครือข่ายประสาทเทียมอาจไม่สามารถใช้ประโยชน์จากข้อมูลที่เป็นฟังก์ชันต่อเนื่องได้อย่างเต็มที่และยังต้องการข้อมูลปริมาณมากในการฝึกฝน แต่เนื่องด้วยเครือข่ายประสาทเทียมเป็นวิธีการที่ยืดหยุ่น สามารถปรับใช้ได้กับข้อมูลหลากหลายรูปแบบ และยังมีศักยภาพ จึงถือเป็นวิธีการที่น่าติดตามดูว่าจะสามารถพยากรณ์ข้อมูลได้ดีเพียงใดเมื่อเปรียบเทียบกับวิธีการวิเคราะห์ข้อมูลเชิงฟังก์ชัน

3. วิธีการวิจัย

3.1 ข้อมูลที่ใช้ในงานวิจัย

งานวิจัยนี้เลือกใช้ข้อมูลที่มีความผันผวนแตกต่างกันออกไปเพื่อศึกษาประสิทธิภาพการพยากรณ์ของตัวแบบภายใต้ข้อมูลที่มีลักษณะแตกต่างกัน

3.1.1 ข้อมูลอุณหภูมิพื้นผิวดินเฉลี่ยรายวัน

เป็นข้อมูลอุณหภูมิเฉลี่ยในหน่วยของศาเซลเซียส (°C) ของอากาศในแต่ละวันด้วยวิธีการเฉลี่ยของ Berkeley Earth โดยเลือกใช้ข้อมูลในช่วงวันที่ 1 มกราคม ค.ศ. 1880 ถึงวันที่ 31 กรกฎาคม ค.ศ. 2022 เป็นจำนวน 52,073 ตัวอย่าง [13] โดยข้อมูลนี้เป็นตัวแทนของข้อมูลที่มีความถี่ต่ำและความผันผวนต่ำ เป้าหมายการพยากรณ์ของข้อมูลนี้คือ อุณหภูมิเฉลี่ยรายวันภายในสัปดาห์ถัดไป โดยเมื่อทำการตัดตอนข้อมูลเพื่อสร้างฟังก์ชันข้อมูลรายสัปดาห์จะได้ข้อมูลจำนวน 7,439 ตัวอย่าง

3.1.2 ข้อมูลปริมาณ PM 2.5 รายชั่วโมง

เป็นข้อมูลปริมาณ PM 2.5 ที่สถานเอกอัครราชทูตสหรัฐอเมริกาในกรุงปักกิ่ง จากกระทรวงการต่างประเทศสหรัฐอเมริกา [14] ซึ่งอยู่ในหน่วยไมโครกรัมต่อลูกบาศก์เมตร โดยมีข้อมูลเป็นปริมาณ PM 2.5 ที่ถูกวัดรายชั่วโมง และใช้ข้อมูลตั้งแต่วันที่ 2 มกราคม ค.ศ. 2010 เวลา 00:00 น. ถึงวันที่ 30 มิถุนายน ค.ศ. 2017 เวลา 23:00 น. เป็นจำนวน 65,688 ตัวอย่าง โดยข้อมูลนี้เป็นตัวแทนของข้อมูลที่มีความถี่ปานปลางและความผันผวนปานกลาง เป้าหมายการพยากรณ์ของข้อมูลนี้คือ ปริมาณ PM 2.5 ใน 1 วันถัดไป โดยเมื่อทำการตัดตอนข้อมูลเพื่อสร้างฟังก์ชันข้อมูลรายชั่วโมงจะได้ข้อมูลจำนวน 2,737 ตัวอย่าง

3.1.3 ข้อมูลอัตราการแลกเปลี่ยน Bitcoin เป็น USDT รายนาที

เป็นข้อมูลอัตราการแลกเปลี่ยนสกุลเงินดิจิทัล Bitcoin (BTC) 1 เหรียญต่อสกุลเงิน United States Dollar Tether (USDT) ซึ่งเป็นสกุลเงินดิจิทัลความเสี่ยงต่ำที่ผูกกับเงินสกุลดอลลาร์สหรัฐฯ โดย 1 USDT จะมีค่าเท่ากับหรือใกล้เคียงกับ 1 ดอลลาร์สหรัฐฯ โดยในงานวิจัยนี้จะพยากรณ์ราคาปิดของ BTC ในหน่วยสกุลเงิน USDT ด้วยข้อมูลรายนาที ตั้งแต่วันที่ 29 พฤษภาคม ค.ศ. 2024 เวลา 00:00 น. ถึง วันที่ 30 กันยายน ค.ศ. 2024 เวลา 23:59 น. เป็นจำนวน180,000 ตัวอย่าง จากข้อมูลของแพลตฟอร์มแลกเปลี่ยนเงินดิจิทัล [15] โดยข้อมูลนี้เป็นตัวแทนของข้อมูลที่มีความถี่สูงและความผันผวนสูง เป้าหมายการพยากรณ์ของข้อมูลนี้คือ อัตราการแลกเปลี่ยน BTC เป็น USDT ใน 1 ชั่วโมงถัดไป โดยเมื่อทำการตัดตอนข้อมูลเพื่อสร้างฟังก์ชันข้อมูลรายชั่วโมงจะได้ข้อมูลจำนวน 3,000 ตัวอย่าง

3.2 การเตรียมข้อมูล

3.2.1 การเติมข้อมูลที่ขาดหาย

โดยในงานวิจัยนี้ได้เลือกใช้วิธีการเติมข้อมูลที่ขาดหาด้วยวิธีการ Spline Interpolation เนื่องจากเป็นวิธีการที่คงแนวโน้มเดิมของข้อมูลที่มีความต่อเนื่องและไม่เป็นเส้นตรงได้ดีซึ่งเหมาะกับข้อมูลในงานวิจัยที่ใช้ในการศึกษาการพยากรณ์ข้อมูลอนุกรมเวลาเชิงฟังก์ชัน

3.2.2 การทำข้อมูลให้เป็นมาตรฐาน

ข้อมูลที่จะถูกนำเข้าสู่ตัวแบบการเรียนรู้เชิงลึกจำเป็นต้องทำให้อยู่ในช่วง 0 ถึง 1 ก่อนเพื่อให้ตัวแบบสามารถเรียนรู้ลักษณะของข้อมูลได้โดยไม่ได้รับผลกระทบจากหน่วยของข้อมูล โดยงานวิจัยนี้เลือกใช้วิธีการ Min-max Normalization ดังสมการที่ (3) เนื่องจากเป็นวิธีที่สามารถรับมือกับข้อมูลผิดปกติได้ดี

$$x_{normalized} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3)$$

เมื่อ

x_{min} คือค่าที่ต่ำที่สุดภายในชุดข้อมูล

x_{max} คือค่าที่สูงที่สุดภายในชุดข้อมูล

3.3 การสร้างตัวแบบสำหรับการพยากรณ์

หลังข้อมูลผ่านเติมข้อมูลที่ขาดหาย และการทำให้เป็นมาตรฐานแล้ว ในขั้นถัดไปจะทำการพัฒนาตัวแบบสำหรับการพยากรณ์ในกรณีที่มีข้อมูลร้อยละ 100 50 และ 25 จากข้อมูลตั้งต้นเพื่อศึกษาประสิทธิภาพการพยากรณ์ในสถานการณ์ที่มีจำนวนข้อมูลมากและน้อย อีกทั้งยังพัฒนาตัว

แบบสำหรับพยากรณ์ข้อมูลใน 1 5 และ 10 จุดเวลาถัดไปเพื่อศึกษาประสิทธิภาพการพยากรณ์ระยะสั้นและยาว

3.3.1 การสร้างตัวแบบ FPCR

สำหรับ FPCR จำนวนองค์ประกอบหลัก (Components) ที่ใช้ในการพยากรณ์จะถูกเลือกโดยการกำหนดเกณฑ์ของสัดส่วนความแปรปรวนสะสม (Cumulative Variance Explained) ที่ร้อยละ 85 เป็นเกณฑ์ในการเลือกจำนวนองค์ประกอบหลักที่เหมาะสมตาม [16] เพื่อให้สามารถอธิบายข้อมูลได้อย่างเพียงพอ

3.3.2 การสร้างตัวแบบ RNN, LSTM และ GRU

สำหรับตัวแบบ RNN, LSTM, และ GRU โครงสร้างตัวแบบจะถูกปรับแต่งโดยการทดลองกับจำนวนชั้นซ่อน (Hidden Layers) และจำนวน Neuron ในแต่ละชั้นซ่อนเพื่อหาค่าที่เหมาะสมที่สุด โดยใช้เทคนิค Randomized Search ตัวแบบแต่ละตัวจะได้รับการทดสอบภายใต้การกำหนดค่าจำนวนชั้นซ่อนเป็น 1 ถึง 3 ชั้น (ไม่รวมชั้น Input และ Output) สำหรับแต่ละชั้นซ่อนและชั้น Input จะมีการกำหนดค่าจำนวน Neuron 1 ถึง 100 โดยใช้ MSE เป็น Loss Function สำหรับการฝึกตัวแบบ และใช้ Adam (Adaptive Moment Estimation) เป็นตัวปรับค่า (Optimizer) จากนั้นฝึกโครงสร้างที่ให้ค่า MSE ต่ำที่สุดอีกครั้งด้วย Epoch ที่มากขึ้นและนำประสิทธิภาพของตัวแบบดังกล่าวไปเปรียบเทียบกับตัวแบบอื่น ๆ ต่อไป

3.4 การวัดประสิทธิภาพการพยากรณ์

3.4.1 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Squared Error: MSE)

เป็นมาตรวัดทางสถิติที่ใช้ในการวัดความแตกต่างระหว่างค่าจริงกับค่าที่พยากรณ์ โดยการคำนวณความคลาดเคลื่อน ในแต่ละจุด จากนั้นนำความคลาดเคลื่อนมายกกำลังสองและหาค่าเฉลี่ย โดยเป็นไปดังสมการที่ (4)

$$MSE=\frac{1}{n}\sum_{i=1}^{n}(Y_t-\hat{Y}_t)^2 \quad (4)$$

เมื่อ

Y_t คือ ค่าจริง ณ จุดเวลา t

$\hat{Y}_t$ คือ ค่าที่พยากรณ์ ณ จุดเวลา t

n คือ จำนวนข้อมูล

3.4.2 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองแบบอินทิเกรต (Mean Integrated Squared Error: MISE)

เป็นมาตรวัดทางสถิติที่ใช้ในการวัดความแตกต่างระหว่างฟังก์ชันที่คาดการณ์ (หรือฟังก์ชันประมาณค่า) กับฟังก์ชันจริง โดยใช้การอินทิเกรตความคลาดเคลื่อนกำลังสองในทุกจุดของโดเมน แล้วนำมาหาค่าคาดหมายของฟังก์ชันความคลาดเคลื่อนดังกล่าว โดยเป็นไปดังสมการที่ (5)

$$MISE=E\left[\int\left(f_t(x)-\hat{f}_t(x)\right)^2 dx\right] \quad (5)$$

เมื่อ

$f_t(x)$ คือ ฟังก์ชันจริง ณ จุดเวลา t

$\hat{f}_t(x)$ คือ ฟังก์ชันที่คาดการณ์ ณ จุดเวลา t

$E[x]$ คือ ค่าคาดหมาย (Expectation) ของ x

MSE จะเน้นไปที่การวัดความผิดพลาดในจุดข้อมูลไม่ต่อเนื่อง ในขณะที่ MISE เหมาะสำหรับข้อมูลที่พิจารณาเป็นฟังก์ชันต่อเนื่อง ซึ่งเน้นที่การพยากรณ์ลักษณะทั่วไปและลักษณะของเส้นโค้ง ดังนั้นการคำนวณ MISE จะช่วยบอกได้ว่าตัวแบบนั้นสามารถจับรูปแบบของข้อมูลฟังก์ชันได้ดีหรือไม่

ดังนั้นการใช้มาตรวัดใน 2 รูปแบบนี้จะให้ผลในมุมมองที่ต่างกัน แต่สามารถนำมาพิจารณาร่วมกันในการประเมินประสิทธิภาพการพยากรณ์ของตัวแบบได้

4. ผลการวิจัยและอภิปรายผล

จากผลการวิจัยดังรายละเอียดที่ถูกรายงานในตารางที่ 1 พบว่า ในสถานการณ์ที่ข้อมูลมีความผันผวนต่ำ เช่น ข้อมูลอุณหภูมิพื้นผิวดินรายวัน ตัวแบบ FPCR มีแนวโน้มที่จะให้ผลลัพธ์ที่แม่นยำกว่าตัวแบบที่ใช้วิธีการเรียนรู้เชิงลึก (RNN, LSTM, GRU) โดยเฉพาะเมื่อพยากรณ์ในขอบเขตระยะกลางและยาว (h = 5, 10) ซึ่งแสดงให้เห็นว่า FPCR สามารถจับโครงสร้างแนวโน้มของข้อมูลระยะยาวได้ดี อย่างไรก็ตาม ในขอบเขตระยะสั้น (h = 1) FPCR ยังคงด้อยกว่าตัวแบบที่ใช้วิธีการเรียนรู้เชิงลึก

ในทางตรงกันข้าม ในสถานการณ์ที่ข้อมูลมีความผันผวนสูง เช่น อัตราแลกเปลี่ยน Bitcoin ซึ่งมีการเปลี่ยนแปลงที่ไม่แน่นอนและผันผวนมาก ในกรณีส่วนใหญ่ตัวแบบที่ใช้การเรียนรู้เชิงลึกสามารถพยากรณ์ได้แม่นยำกว่าตัวแบบ FPCR โดยเฉพาะ LSTM ที่มีความสามารถในการจับลำดับข้อมูลที่มีความซับซ้อนสูง อย่างไรก็ตาม ความแตกต่างระหว่างความแม่นยำของตัวแบบ RNN, LSTM, และ GRU ไม่ชัดเจนมากนัก โดยตัวแบบ FPCR จะให้ผลลัพธ์ที่แม่นยำกว่าตัวแบบที่ใช้วิธีการเรียนรู้เชิงลึกเฉพาะการพยากรณ์ในขอบเขตระยะกลางเท่านั้นเมื่อเป็นการพยากรณ์ข้อมูลที่ผันผวนสูง แสดงถึงข้อจำกัดของตัวแบบ FPCR ในการจับแนวโน้มระยะยาวของข้อมูลที่ซับซ้อนและไม่แน่นอน

เมื่อพิจารณาถึงขนาดของข้อมูลที่ใช้ในการฝึก พบว่า ในกรณีที่พยากรณ์ข้อมูลที่มีความผันผวนกลางและสูงไม่พบแนวโน้มที่ขนาดของข้อมูลจะมีผลต่อประสิทธิภาพของตัวแบบทั้งสองประเภทโดยชัดเจน กลับกัน ในกรณีของข้อมูลที่มีความผันผวนต่ำ หากมีจำนวนตัวอย่างที่ใช้ฝึกมาก (n = 100%) ตัวแบบการเรียนรู้เชิงลึกสามารถพยากรณ์ได้แม่นยำกว่าตัวแบบ FPCR โดยเฉพาะตัวแบบ LSTM

ทั้งนี้ เมื่อจำนวนตัวอย่างที่ใช้ฝึกมีขนาดเล็กลง (n = 50% หรือ 25%) FPCR มักจะให้ผลลัพธ์ที่แม่นยำกว่าโดยเฉพาะในการพยากรณ์ระยะกลางและยาว (h = 5, 10) การที่ FPCR ใช้วิธีการลดมิติและดึงคุณสมบัติหลักของข้อมูลมาใช้ในการพยากรณ์นั้น ส่งผลให้ตัวแบบแสดงศักยภาพได้โดยที่ไม่จำเป็นต้องพึ่งพาข้อมูลขนาดใหญ่ดังเช่นวิธีการเรียนรู้เชิงลึก

ในมุมของระยะเวลาการพยากรณ์ เมื่อทำการพยากรณ์ระยะยาว (h = 10) ตัวแบบ FPCR มักจะมีประสิทธิภาพสูงกว่าตัวแบบที่ใช้วิธีการเรียนรู้เชิงลึก ในกรณีของข้อมูลที่มีความผันผวนต่ำและกลาง

ตารางที่ 1: ตารางแสดงประสิทธิภาพการพยากรณ์ของตัวแบบ

ร้อยละข้อมูลที่ใช้ฝึกตัวแบบ	ขอบเขตการพยากรณ์	ตัวแบบ	ข้อมูลอุณหภูมิพื้นผิวดินเฉลี่ยรายวัน		ข้อมูลปริมาณ PM 2.5 รายชั่วโมง		ข้อมูลอัตราการแลกเปลี่ยน Bitcoin เป็น USDT รายนาที	
			MSE	MISE	MSE	MISE	MSE	MISE
100	h = 1	FPCR	0.008926	0.053098	0.000549	0.012737	0.000005	0.000324
		RNN	**0.002464**	**0.015122**	0.000856	0.020002	0.000004	0.000229
		LSTM	0.002512	0.015458	**0.000173**	**0.003976**	**0.000003**	**0.000205**
		GRU	0.002977	0.017978	0.000205	0.004744	0.000004	0.000225
	h = 5	FPCR	**0.00252**	**0.083535**	0.000858	0.101697	**0.000009**	**0.002714**
		RNN	0.003438	0.117578	**0.000562**	**0.066585**	0.000030	0.009022
		LSTM	0.003849	0.131659	0.000858	0.101708	0.000022	0.006627
		GRU	0.003605	0.123874	0.001071	0.127039	0.000030	0.008910
	h = 10	FPCR	0.003715	0.255968	**0.000886**	**0.210803**	0.000047	0.028454
		RNN	0.004055	0.277494	0.000985	0.23482	**0.000044**	**0.026572**
		LSTM	**0.003694**	**0.253507**	0.001714	0.409728	0.000064	0.038274
		GRU	0.003727	0.255929	0.001449	0.346197	0.000063	0.037739
50	h = 1	FPCR	0.007101	0.042258	0.000657	0.015438	0.000003	0.000204
		RNN	0.003222	0.019627	0.000275	0.006503	0.000025	0.001509
		LSTM	0.003257	0.019958	0.000503	0.011706	**0.000020**	**0.001172**
		GRU	**0.003194**	**0.019525**	**0.000189**	**0.004391**	0.003176	0.187418
	h = 5	FPCR	**0.002585**	**0.086725**	0.000942	0.111817	**0.000010**	**0.003022**
		RNN	0.003952	0.134688	0.000638	0.075572	0.000047	0.014099
		LSTM	0.003732	0.127119	**0.000621**	**0.073593**	0.000049	0.014520
		GRU	0.003586	0.12217	0.000631	0.074754	0.000039	0.011742
	h = 10	FPCR	**0.003308**	**0.227887**	**0.000813**	**0.19349**	0.000042	0.024952
		RNN	0.004529	0.312183	0.001406	0.335792	**0.000034**	**0.020603**
		LSTM	0.005009	0.345026	0.000946	0.225311	0.000038	0.022728
		GRU	0.005254	0.362171	0.00114	0.272099	0.000041	0.024307
25	h = 1	FPCR	0.005622	0.033622	0.000482	0.011224	0.000004	0.000219
		RNN	0.003934	0.024108	0.000202	0.004657	0.000003	0.000167
		LSTM	**0.002301**	**0.0142**	**0.000111**	**0.002573**	**0.000002**	**0.000141**
		GRU	0.002899	0.017849	0.000201	0.004701	0.000003	0.000171
	h = 5	FPCR	**0.00279**	**0.094622**	0.000784	0.092991	**0.000010**	**0.003009**
		RNN	0.003877	0.132485	0.000811	0.096289	0.000034	0.010107
		LSTM	0.003109	0.105722	**0.000629**	**0.074515**	0.000046	0.013822
		GRU	0.005596	0.182616	0.000711	0.084216	0.000044	0.013275
	h = 10	FPCR	**0.003117**	**0.214599**	0.000946	0.225309	0.000040	0.023859
		RNN	0.004288	0.294243	**0.000777**	**0.185068**	0.000447	0.267603
		LSTM	0.009115	0.629456	0.001372	0.327623	**0.000015**	**0.008671**
		GRU	0.004742	0.325485	0.001345	0.32127	0.000019	0.011585

หมายเหตุ. ตัวอักษรหนาหมายถึงค่าที่ดีที่สุดในสถานการณ์การพยากรณ์นั้น

ในขณะที่มีทำการพยากรณ์ระยะกลาง (h = 5) ตัวแบบ FPCR มักจะมีประสิทธิภาพสูงกว่าเฉพาะข้อมูลที่มีความผันผวนต่ำและสูง เป็นไปได้ว่า ข้อมูลที่ผันผวนสูงอาจมีความไม่แน่นอนสูงจนตัวแบบไม่สามารถจับลักษณะระยะยาวได้ จึงมีประสิทธิภาพนำตัวแบบการเรียนรู้เชิงลึกเฉพาะกรณีพยากรณ์ระยะกลาง ในขณะที่ตัวแบบการเรียนรู้เชิงลึกมีความยืดหยุ่นสูงกว่าจึงมีโอกาสที่จะจับลักษณะของข้อมูลได้มากกว่า

สำหรับการพยากรณ์ระยะสั้น (h = 1) FPCR มักจะมีประสิทธิภาพต่ำกว่าตัวแบบการเรียนรู้เชิงลึกเสมอ เป็นได้ไปว่าตัวแบบ FPCR ที่มีความเหมาะสมสำหรับการพยากรณ์ข้อมูลที่ต่อเนื่องอยู่แล้ว อาจชำนาญในการจับลักษณะข้อมูลอนุกรมระยะยาวมากกว่าการจับข้อมูลระยะสั้น ๆ ซึ่งแสดงให้เห็นว่าการเรียนรู้เชิงลึกยังคงเป็นแนวทางที่เหมาะสมกว่าสำหรับการพยากรณ์ในช่วงเวลาสั้น

เมื่อลองเปรียบเทียบประสิทธิภาพการพยากรณ์โดยรวมของตัวแบบการเรียนรู้เชิงลึก RNN, LSTM, และ GRU พบว่า ในกรณีส่วนใหญ่ LSTM มักเป็นตัวแบบที่ให้ผลลัพธ์ที่แม่นยำสูงสุดในหมู่ตัวแบบการเรียนรู้เชิงลึกด้วยกัน โดยเฉพาะเมื่อมีจำนวนตัวอย่างข้อมูลน้อย (n = 25%) เป็นไปได้ว่า การที่ LSTM ใช้โครงสร้างที่ซับซ้อนกว่าอาจช่วยให้ตัวแบบสามารถจับลักษณะของข้อมูลได้แม้มีตัวอย่างข้อมูลน้อย

สุดท้าย เมื่อคำนึงถึงทรัพยากรที่ใช้ในการฝึกตัวแบบ พบว่าตัวแบบที่ใช้การเรียนรู้เชิงลึกต้องใช้เวลาฝึกมากกว่าตัวแบบ FPCR อย่างมีนัยสำคัญ ทั้งในแง่ของระยะเวลาการฝึกตัวแบบและการค้นหาชุดพารามิเตอร์ที่เหมาะสม ซึ่งต้องใช้ทรัพยากรคอมพิวเตอร์สูงขึ้นอย่างมาก โดยเฉพาะ LSTM และ GRU ที่มีโครงสร้างซับซ้อน อย่างไรก็ตาม ประสิทธิภาพที่ดีขึ้นของการเรียนรู้เชิงลึกในบางกรณีอาจคุ้มค่ากับทรัพยากรที่ใช้

5. เอกสารอ้างอิง

[1] Hyndman RJ, Ullah MS. Robust forecasting of mortality and fertility rates: A functional data approach. Computational Statistics & Data Analysis. 2007;51(10): 4942-4956.

[2] Tokgöz A, Ünal G. A RNN based time series approach for forecasting turkish electricity load: Proceedings of 2018 26th Signal Processing and Communications Applications Conference (SIU); 2018 May 2-5; IEEE; 2018.

[3] Ji X, Wang J, Yan Z. A stock price prediction method based on deep learning technology. International Journal of Crowd Science. 2021;5(1): 55-72.

[4] Shang HL. ftsa: An R package for analyzing functional time series. The R Journal. 2013;5(1):64-72.

[5] Hochreiter S, Schmidhuber J. Long short-term memory. Neural Computation. 1997;9(8):1735-80.

[6] Chung J, Gulcehre C, Cho K, Bengio Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint. 2014.

[7] Yang S, Yu X, Zhou Y. LSTM and GRU neural network performance comparison study: Taking yelp review dataset as an example: Proceedings of the 2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI); 2020 Jun; New York, USA. IEEE; 2020;98-101.

[8] Yao J, Mueller J, Wang JL. Deep learning for functional data analysis with adaptive basis layers: Proceedings of the 38th International Conference on Machine Learning; 2021 Jul 18-24; PMLR; 2021;11898-908.

[9] Thind B, Multani K, Cao J. Deep learning with functional inputs. Journal of Computational and Graphical Statistics. 2023;32(1):171-80.

[10] Ozdemir AC, Bulus K, Zor K. Medium-to long-term nickel price forecasting using LSTM and GRU networks. Resources Policy. 2022;78.

[11] Fu Y, Hu W, Tang M, Yu R, Liu B. Multi-step ahead wind power forecasting based on recurrent neural networks: Proceedings of the 2018 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC); 2018 Oct 7-10; Sabah, Malaysia. IEEE; 2018. 217 - 222.

[12] Masum S, Liu Y, Chiverton J. Multi-step time series forecasting of electric load using machine learning models. Rutkowski L, Scherer R, Korytkowski M, Pedrycz W, Tadeusiewicz R, Zurada J, editors. Artificial Intelligence and Soft Computing. Springer, Cham; 2018. 148-159.

[13] Berkeley Earth. Global temperature data [dataset on the Internet]; 2024 [cited 2024 Nov 12]. Available from: www.berkeleyearth.org.

[14] U.S. Department of State. Air quality monitoring data from the U.S. Embassy in Beijing [dataset on the Internet; cited 2024 Nov 12]. Available from: http://www.stateair.net/web/historical/1/1.html.

[15] Binance. Binance market data [dataset on the Internet]; 2024 [cited 2024 Nov 12]. Available from: https://data.binance.vision/.

[16] Horváth L, Kokoszka P. Inference for functional data with applications. New York: Springer; 2012.

การพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง

Developing Machine Learning Models for Detecting Safety Helmet Usage in Construction Projects

พีรวิชญ์ นาวินรัตนศิริ* ดำรงศักดิ์ รินชุมภู

สาขาวิชาวิศวกรรมและการบริหารการก่อสร้าง คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่

(peerawich_na@cmu.ac.th)*

บทคัดย่อ

อุบัติเหตุจากอุตสาหกรรมก่อสร้างมีจำนวนมากเป็นอันดับหนึ่งในประเทศไทยตลอดหลายปี มีสาเหตุหลักมาจากการใช้เครื่องมือ เครื่องจักรต่างๆ ถึงแม้ว่าจะมีกฎกระทรวงกำหนดให้ต้องคุ้มครองความปลอดภัยส่วนบุคคลขณะปฏิบัติงาน แต่ผู้ปฏิบัติงานอาจขาดความรอบคอบ รวมถึงขาดการตรวจสอบด้านความปลอดภัยอย่างสม่ำเสมอและทั่วถึง งานวิจัยนี้จึงมีจุดมุ่งหมายในการพัฒนาเทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) สำหรับตรวจสอบการสวมหมวกนิรภัยในโครงการก่อสร้างเพื่อป้องกันอันตรายจากวัตถุตกหล่น ซึ่งเป็นสาเหตุของการบาดเจ็บในโครงการก่อสร้างอันดับต้น โดยสร้างและใช้ข้อมูลภาพจำนวน 4 ชุดที่แตกต่างกัน ได้แก่ จำนวน 1,650, 1,849, 3,136, 4,445 ภาพ ในการฝึกสอนและทดสอบแบบจำลองบนแพลตฟอร์มสำเร็จรูปหรือ Roboflow เนื่องจากเหมาะสำหรับผู้เริ่มต้นใช้เทคโนโลยีคอมพิวเตอร์วิทัศน์ (Computer Vision) จากนั้นนำจำนวนข้อมูลภาพที่ได้มาใช้ร่วมกับอัลกอริทึม YOLOv8 ที่มีความนิยมและเสถียรภาพสูง เพื่อสร้างแบบจำลองและประเมินประสิทธิภาพในการตรวจจับการสวมหมวกนิรภัย ซึ่งในขั้นตอนการประเมินประสิทธิภาพของแบบจำลองทำให้สามารถสรุปจำนวนข้อมูลภาพที่เหมาะสมในการฝึกสอนได้เท่ากับจำนวน 4,445 ภาพ ที่ให้ค่าความแม่นยำของแบบจำลองสูงสุดเท่ากับ 0.959 จำนวนข้อมูลภาพเหล่านี้จะสามารถเป็นแนวทางในการฝึกสอนแบบจำลองและช่วยลดระยะเวลาในการทำงานสำหรับผู้ใช้เทคโนโลยีการเรียนรู้ของเครื่องในการตรวจจับการสวมหมวกนิภัยในโครงการก่อสร้างได้

คำสำคัญ: แบบจำลอง, การเรียนรู้ของเครื่อง, การตรวจจับ, หมวกนิรภัย, โครงการก่อสร้าง

Abstract

The construction industry in Thailand has consistently recorded the highest number of workplace accidents for several years. The primary cause of these accidents is using various tools and machinery. Although ministerial regulations assign personal protective equipment (PPE) use during work, workers lack caution and insufficient safety inspections. This study aims to develop a machine learning-based system for detecting the use of safety helmets in construction projects to mitigate risks associated with falling objects, which are a leading cause of injuries in the sector. Four sets of image data, including 1,650, 1,849, 3,136, and 4,445 images were created and utilized for training and testing the model on the Roboflow platform, designed to facilitate computer vision technology applications, particularly for beginners. The dataset was then processed using the YOLOv8 algorithm—a widely adopted and stable object detection framework, to develop a model for safety helmet detection. The model's performance was evaluated to determine the optimal dataset size which equals 4,445 images, required for achieving the level of precision at 0.959. The findings provide a reference for the appropriate amount of training data necessary for model development, ultimately reducing the time required for machine learning applications in safety helmet detection within construction projects.

Keywords: Model, Machine Learning, Object Detection, Helmet, Construction Projects

1. บทนำ

อุบัติเหตุจากอุตสาหกรรมก่อสร้างมีจำนวนมากเป็นอันดับหนึ่งในประเทศไทยตลอดหลายปี [1] หลักๆ มาจากการใช้เครื่องมือ เครื่องจักรต่างๆในโครงการก่อสร้างเพื่อช่วยประหยัดเวลาและแรงงานมนุษย์ แต่บางกรณีผู้ปฏิบัติงานในโครงการก่อสร้างขาดความรอบคอบในการปฏิบัติงานหรือขาดการตรวจสอบความปลอดภัยอย่างสม่ำเสมอ ขาดความรู้ความเข้าใจในการปฏิบัติงานอย่างถูกต้อง ภายใต้กฎ ระเบียบข้อบังคับต่างๆ [2] และจากสถิติปีจากสถิติปีพ.ศ. 2562-2566 พบว่าสิ่งที่ทำให้ผู้ปฏิบัติงานประสบอันตรายหรือเจ็บป่วยเนื่องจากการทำงาน เกิดจากวัตถุหรือสิ่งของตกใส่ จำนวน 42.21% ต่อปีซึ่งเป็นจำนวนมากที่สุด ของจำนวนการประสบอันตรายทั้งหมด เกิดจากเครื่องมือ 13.91% ต่อปี เกิดจากเครื่องจักร 13.30% ต่อปี [3]

กฎกระทรวงปี 2564 หมวด 1 ข้อ 20 กำหนดให้นายจ้างต้องจัดและดูแลให้ลูกจ้างใช้อุปกรณ์คุ้มครองความปลอดภัยส่วนบุคคลตลอดเวลาที่ทำงานก่อสร้าง [4] การตรวจสอบการสวมใส่อุปกรณ์ป้องกันส่วนบุคคล (PPE) จึงถือเป็นเรื่องสำคัญอันดับต้นๆในโครงการก่อสร้าง หากเกิดอุบัติเหตุจะส่งผลเสียต่อทั้งแรงงานและ เกิดความล่าช้าในการทำงาน งบประมาณอาจเพิ่มขึ้นทั้งในส่วนของค่าชดเชยและค่าปรับจากงานล่าช้า แม้การตรวจสอบการสวมใส่อุปกรณ์ PPE จะมีความสำคัญมากในโครงการก่อสร้าง ปัญหาหลักที่พบของการตรวจสอบการสวมใส่ PPE คือใช้เวลาตรวจสอบนานใช้ทรัพยากรบุคคลในการตรวจสอบจำนวนมาก ในขั้นตอนการตรวจสอบการสวมใส่อุปกรณ์ PPE ในแต่ละบุคคล ซึ่งมีแรงงานจำนวนมาก ท่ามกลางความเร่งรีบทำให้บางครั้งอาจเกิดการละเลยในการตรวจสอบก่อนที่จะเข้าทำงาน [5] จึงมีบริษัทที่ทำงานเกี่ยวกับด้านก่อสร้างบางแห่ง รวมถึงงานวิจัยบางส่วนได้เริ่มนำเอาเทคโนโลยีเข้ามาใช้ตรวจสอบการสวมใส่อุปกรณ์ PPE ของแรงงาน เพื่อช่วยลดระยะเวลา และลดทรัพยากรในขั้นตอนการตรวจสอบ ซึ่งหนึ่งในเทคโนโลยีที่มีบทบาทสำคัญในการตรวจจับวัตถุในปัจจุบันคือ คอมพิวเตอร์วิทัศน์ (Computer Vision: CV) เป็นสาขาย่อยหนึ่งในการเรียนรู้ของเครื่อง (Machine Learning: ML) ที่มีความสามารถในการระบุตำแหน่งของวัตถุในภาพหรือวิดีโอ [6]

การเรียนรู้ของเครื่องและปัญญาประดิษฐ์ (Artificial Intelligence: AI) ML ปัจจุบันถูกนำไปประยุกต์ใช้อย่างหลากหลายในการทำงานหลาย ๆ ด้าน จากงานวิจัยของ Datta et al. [7] ได้ทำการรวบรวมงานวิจัยที่นำ ML เข้ามาใช้ในงานก่อสร้างตลอดระยะเวลาของโครงการก่อสร้างซึ่งภายในช่วงปี พ.ศ. 2553-2565 มีแนวโน้มสูงขึ้นอย่างรวดเร็ว โดยเฉพาะเทคโนโลยีหุ่นยนต์ (Robotics) และ CV ถูกนำมาใช้กันอย่างแพร่หลายในการก่อสร้าง เช่น การตรวจสอบด้านความปลอดภัยของคนงานผ่านกล้องแบบเรียลไทม์ (Real-time) เพื่อป้องกันอุบัติเหตุในพื้นที่ก่อสร้าง ตัวอย่างงานวิจัยที่ผ่านมา มีการตรวจสอบความปลอดภัยของแรงงานขณะปฏิบัติงานโดยตรวจจับเสื้อนิรภัยเพื่อตรวจสอบตำแหน่งของแรงงาน ซึ่งใช้เทคโนโลยี CV [8]

CV เป็นสาขาหนึ่งของ ML ที่ถูกพัฒนาขึ้นด้วยการประยุกต์ใช้ Neural Network ในการจำแนกรูปทรง โดยอาศัยการตรวจจับขอบและมุม มุ่งเน้นการทำให้คอมพิวเตอร์สามารถมองเห็นและวิเคราะห์ข้อมูลจากภาพหรือวิดีโอได้ [9] ในภาคการก่อสร้าง CV ถูกนำมาใช้เพื่อยกระดับความปลอดภัย เช่น การตรวจจับการใส่อุปกรณ์ PPE ของแรงงานในโครงการก่อสร้าง [10-13]

จากงานวิจัยที่ผ่านมา ในการประยุกต์ใช้เทคโนโลยี CV เพื่อตรวจจับวัตถุในโครงการก่อสร้าง มักจะเป็นการพัฒนาอัลกอริทึมในการตรวจจับเพื่อให้แบบจำลองที่ใช้ในการตรวจจับนั้นมีความแม่นยำเพื่อประสิทธิภาพสูงสุดในการใช้งาน [14-17] แต่ยังคงมีช่องว่างในด้านของการเตรียมจำนวนข้อมูลภาพที่เหมาะสมในการฝึกสอนโมเดล อีกทั้งจากงานวิจัยที่ทำการออกแบบระบบการจัดการความปลอดภัยด้วยเทคโนโลยีกล้อง AI เพื่อตรวจจับอุปกรณ์ PPE โดยใช้อัลกอริทึม YOLOv3 มีการระบุจำนวนรูปภาพที่ใช้ในการฝึกสอนโมเดลเท่ากับ 3,000 ภาพ ซึ่งทำให้ค่าความแม่นยำของการตรวจจับในกรณีต่างๆ อยู่ในช่วง 0.90-0.92 แต่ทั้งนี้ยังมีข้อจำกัดของอุปกรณ์ในการประมวลผล ทำให้ใช้ระยะเวลานาน [10] ผู้ค้นคว้าวิจัยได้เล็งเห็นถึงช่องว่างดังกล่าว จึงมีจุดมุ่งหมายในการพัฒนาเทคโนโลยี ML ในส่วนของ CV เพื่อตรวจสอบการสวมหมวกนิรภัยในโครงการก่อสร้างเพื่อป้องวัตถุตกหล่นอันเป็นสาเหตุต้นๆ ของการบาดเจ็บ โดยเน้นการสร้างและใช้จำนวนข้อมูลภาพที่เหมาะสมในการฝึกฝนและทดสอบโมเดล เพื่อให้มีความแม่นยำและลดระยะเวลาในการประมวลผลอย่างมีประสิทธิภาพ

นอกเหนือจากนี้ จากการศึกษางานวิจัยที่เกี่ยวข้อง ผู้วิจัยตัดสินใจที่จะสร้างจำนวนข้อมูลภาพที่ครอบคลุมหลากหลายสถานการณ์ในโครงการก่อสร้าง โดยอาศัยแพลตฟอร์มสำเร็จรูปอย่าง Roboflow เป็นแพลตฟอร์มหรือเครื่องมือที่ถูกพัฒนาขึ้นโดย Roboflow, Inc. ในปี ค.ศ. 2020 เพื่อช่วยให้นักพัฒนาสามารถใช้งาน CV ได้ง่ายโดยไม่จำเป็นต้องมีประสบการณ์หรือทักษะเฉพาะด้าน สามารถรองรับการตรวจจับวัตถุหรือการจำแนกประเภทได้ Roboflow จะถูกนำมาใช้สร้างและจัดการข้อมูลภาพให้พร้อมสำหรับการฝึกสอนโมเดล จากนั้นจำนวนข้อมูลภาพเหล่านี้จะถูกนำไปใช้ในกระบวนการ ML เพื่อสร้างโมเดลที่สามารถตรวจจับและประเมินการสวมหมวกนิรภัยได้ โดยใช้เทคโนโลยีอัลกอริทึม YOLOv8 ซึ่งถูกพัฒนาขึ้นในปีพ.ศ. 2566 บนพื้นฐานของการเรียนรู้เชิงลึก (Deep Learning) เป็นหนึ่งในอัลกอริทึมที่ถูกออกแบบมาให้มีความเร็วและมีความแม่นยำในการตรวจจับวัตถุในภาพนิ่งหรือวิดีโอ โดยใช้แนวคิดในการแบ่งภาพออกเป็นกริดขนาด N×N โดยแต่ละช่องจะคำนวณความเป็นไปได้ (probability) ของการมีวัตถุอยู่ในช่องนั้น และกำหนดค่าความเป็นไปได้และตำแหน่งของวัตถุที่ตรวจจับได้ในภาพ [18] YOLO มีประสิทธิภาพและความเสถียรสูงในด้านการตรวจจับวัตถุแบบเรียลไทม์ YOLO ถูกพัฒนามาอย่างต่อเนื่องจึงมีเวอร์ชันให้เลือกใช้งานตั้งแต่ YOLOv1 ไปจนถึง YOLOv8 และ YOLO-NAS ซึ่งแต่ละเวอร์ชันจะมีความแตกต่างกัน ทั้งในด้านลักษณะการทำงานของตัวอัลกอริทึม

ความเหมาะสมการนำไปใช้งานในแต่ละภาคส่วน และประสิทธิภาพในการประมวลผล [19] หากทำการเปรียบเทียบ YOLO เวอร์ชันก่อนหน้ากับ YOLOv8 พบว่า YOLOv8 มีประสิทธิภาพในการตรวจจับวัตถุแบบเรียลไทม์ (Real-time) มีความแม่นยำสูง สามารถตรวจจับเป้าหมายได้ในหลายมาตราส่วน (Multi-scale) [20] ดังนั้นโมเดลที่ได้จากการศึกษาจะถูกนำไปฝึกสอน ทดสอบโดยอัลกอริทึม YOLOv8 เพื่อวัดผลทั้งในแง่ของความแม่นยำและประสิทธิภาพ เพื่อให้มั่นใจว่าจำนวนข้อมูลภาพเท่าใดจึงจะเหมาะสมต่อการใช้งานในสถานการณ์จริงในโครงการก่อสร้างต่อไป

2. วิธีดำเนินการวิจัย

ในการพัฒนาการเรียนรู้ของเครื่อง (Machine Learning) สำหรับการตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง มีวิธีดำเนินงานวิจัยหลักอยู่ 4 ขั้นตอน ประกอบไปด้วย 1) การรวบรวมตัวอย่างข้อมูลภาพ 2) การสร้างจำนวนข้อมูลภาพบนแพลตฟอร์ม Roboflow 3) การตรวจจับการสวมหมวกนิรภัยโดยใช้อัลกอริทึม YOLOv8 4) การประเมินหาจำนวนข้อมูลภาพที่เหมาะสม ซึ่งสามารถแสดงขั้นตอนการวิจัยได้ดังนี้

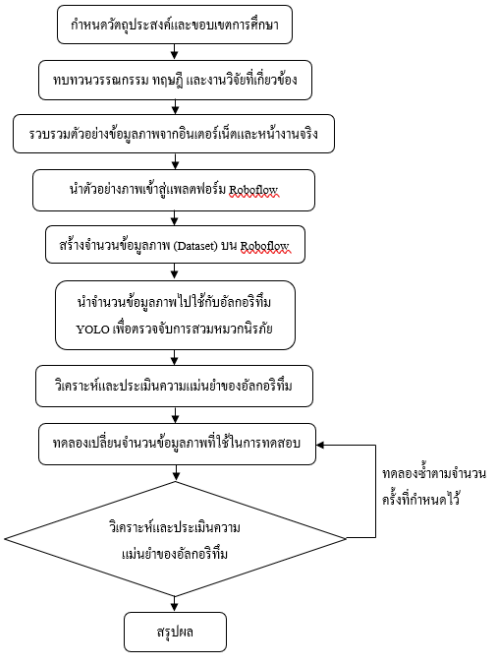

ภาพที่ 1: ขั้นตอนดำเนินงานวิจัย

2.1 การรวบรวมตัวอย่างข้อมูลภาพ

รวบรวมข้อมูลตัวอย่างรูปภาพคนงานสวมหมวกนิรภัยในโครงการก่อสร้างจากอินเตอร์เน็ตและหน้างานจริงเพื่อให้มีความหลากหลาย ทั้งแบบที่สามารถมองเห็นหมวกนิรภัยได้ชัดเจนและไม่ชัดเจน ในมุมมองที่แตกต่างกันเพื่อให้ครอบคลุมและเสมือนการทำงานจริง และกำหนดให้ไฟล์รูปภาพอยู่ในรูปแบบไฟล์ .JPEG หรือ .PNG ไม่จำกัดขนาด สามารถแบ่งชุดข้อมูลภาพออกเป็น 2 ชุด ได้แก่ 1) รูปภาพจำนวน 1,650 ภาพจากโครงการก่อสร้าง 2) รูปภาพ จำนวน 1,849 ภาพ ประกอบไปด้วย 1,650 ภาพจากโครงการก่อสร้าง และ 199 ภาพ จากอินเตอร์เน็ต ซึ่งภาพที่รวบรวมจากโครงการก่อสร้างนั้นเป็นชุดข้อมูลภาพเดียวกัน

2.2 การสร้างจำนวนข้อมูลภาพบนแพลตฟอร์ม Roboflow

เมื่อรวบรวมตัวอย่างข้อมูลภาพแล้ว นำข้อมูลภาพเข้าสู่แพลตฟอร์ม Roboflow เพื่อสร้างจำนวนข้อมูลภาพให้ได้ตามจำนวนและลักษณะที่ต้องการ โดยในการสร้างจำนวนข้อมูลภาพจะถูกสร้างขึ้นจำนวน 2 ชุด ได้แก่ 2 และ 3 เท่า ของจำนวนข้อมูลภาพตั้งต้นที่ถูกนำเข้าสู่ระบบ ซึ่งจะถูกสร้างตามรูปแบบการทำงานของ Roboflow เวอร์ชันทดลองใช้ สำหรับใช้ในการหาจำนวนข้อมูลภาพที่เหมาะสมที่สามารถนำไปใช้ตรวจจับการสวมหมวกนิรภัย ซึ่งในการสร้างจำนวนข้อมูลภาพบนแพลตฟอร์ม Roboflow นั้นจะดำเนินการตามกระบวนการทำงานของ Roboflow ดังภาพที่ 1 และสามารถกล่าวถึงรายละเอียดได้ ดังนี้

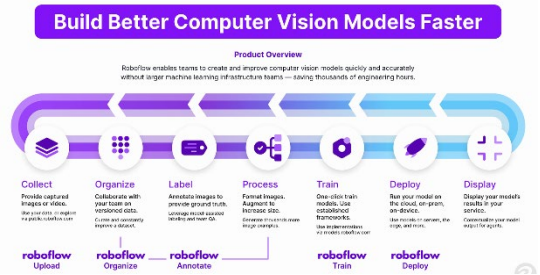

ภาพที่ 2: กระบวนการทำงานของ Roboflow

2.2.1 นำเข้าข้อมูลภาพที่ถูกรวบรวมไว้

สร้าง Project การทำงานใหม่ และเลือกประเภทของ Project เป็น Object Detection เลือกไฟล์รูปภาพบนอุปกรณ์ทำงานที่ต้องการใช้เป็นตัวอย่างในการสร้างชุดข้อมูลภาพ จากนั้นทำการ upload ลงในแพลตฟอร์ม

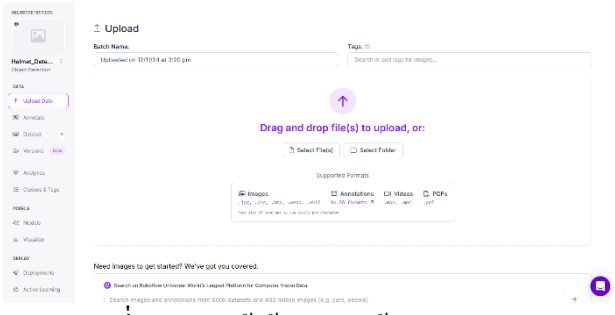

ภาพที่ 3: การนำเข้าข้อมูลภาพเข้าสู่ Roboflow

2.2.2 การ Label ภาพที่นำเข้าสู่แพลตฟอร์ม

ทำการ Label ภาพทุกภาพด้วยตนเอง (Manual Labeling) ที่นำเข้า โดย Label บริเวณรอบหมวกนิรภัยบนศีรษะของผู้ปฏิบัติงานในพื้นที่โครงการก่อสร้าง

ภาพที่ 4: การ Label ภาพที่นำเข้าสู่แพลตฟอร์ม

2.2.3 การสร้างจำนวนข้อมูลภาพใหม่

ทำการสร้างจำนวนข้อมูลภาพใหม่เพื่อนำไปใช้เป็นชุดข้อมูลภาพ (Dataset) ในการตรวจจับการสวมหมวกนิรภัย โดยตั้งค่าจำนวนภาพสำหรับการฝึกสอน (Training) การตรวจสอบ (Validating) และการทดสอบ (Testing) ซึ่งผู้วิจัยกำหนดค่าของการฝึกสอน การตรวจสอบ และการทดสอบไว้เท่ากับร้อยละ 70, 20, และ 10 ตามลำดับ และเลือกรูปแบบของภาพใหม่ที่ต้องการ (Augmentations) กำหนดการพลิกภาพกลับในระนาบแนวนอน, การหมุนระหว่าง 15 และ -15 องศา, และการบิดภาพ ±10 องศาในแนวนอนและแนวดิ่ง

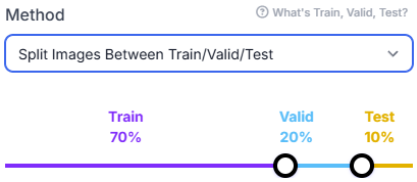

ภาพที่ 5: การตั้งค่าจำนวนภาพสำหรับการฝึกสอน การตรวจสอบ และการทดสอบ

ภาพที่ 6: การตั้งค่ารูปแบบของภาพใหม่ที่ต้องการ (Augmentations)

2.2.4 ตรวจสอบความถูกต้องของข้อมูลภาพใหม่

ตรวจสอบความถูกต้องของข้อมูลภาพใหม่ที่ได้ ผ่านค่า mAP หากอยู่ในระดับที่สามารถยอมรับได้ก็จะสามารถนำข้อมูลภาพใหม่ไปใช้ในกระบวนถัดไป

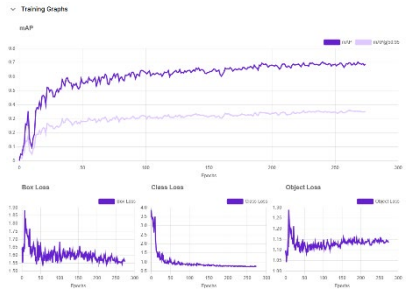

ภาพที่ 7: กราฟแสดงผลลัพธ์การประเมินการดำเนินงานของแพลตฟอร์ม Roboflow ในการสร้างชุดข้อมูลภาพใหม่

2.2.5 ดาวน์โหลดข้อมูลภาพใหม่ไปใช้งาน

ข้อมูลภาพใหม่ที่ได้จะถูกดาวน์โหลดออกไปใช้ร่วมกับ YOLOv8 ในรูปแบบของภาษาโปรแกรม Python

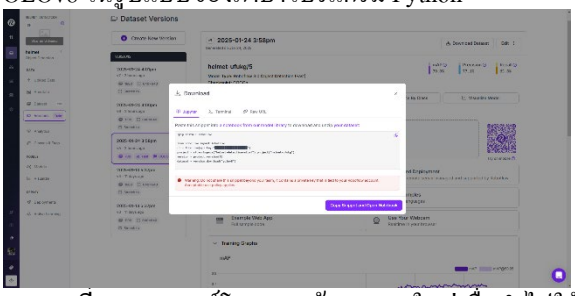

ภาพที่ 8: การดาวน์โหลดชุดข้อมูลภาพใหม่เพื่อนำไปใช้

2.3 การตรวจจับการสวมหมวกนิรภัยโดยใช้ YOLOv8

ติดตั้งชุดข้อมูลภาพที่ต้องการใช้ทั้งหมด 4 ชุดข้อมูลได้แก่ ชุดข้อมูลภาพตั้งต้นจำนวน 1,650 ภาพและ 1,849 ภาพ ชุดข้อมูลภาพใหม่ที่มีจำนวนเป็น 2 และ 3 เท่าของชุดข้อมูลภาพตั้งต้นจำนวน 1,849 ภาพ ซึ่งจะมีจำนวนเท่ากับ 3,136 และ 4,445 ภาพ ที่ได้จาก Roboflow เพื่อตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง ซึ่งผู้วิจัยเลือกใช้ Google Colab เป็น Environment ในการประมวลผล อัลกอริทึม YOLOv8 เนื่องจากใช้งานได้ง่าย ไม่จำเป็นต้องติดตั้ง Libraries เสริมภายในอุปกรณ์คอมพิวเตอร์ อัลกอริทึม YOLOv8 จะถูกสร้างขึ้นผ่านภาษาโปรแกรม Python โดยดำเนินกระบวนการทำซ้ำ (Epoch) ทั้งหมด 100 ครั้ง ทำการตั้งค่าหลักของโมเดล กำหนดให้ Batch มีขนาดเท่ากับ 64 และขนาดภาพเท่ากับ 640*640 pixels ในส่วนของการตั้งค่าเพื่อฝึกโมเดล กำหนด optimizer ให้มีความเหมาะสมแบบอัตโนมัติ (auto)

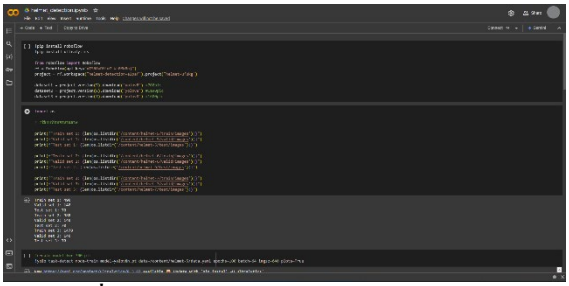

ภาพที่ 9: การตรวจจับการสวมหมวกนิรภัยโดยใช้ YOLOv8

2.4 การประเมินหาจำนวนข้อมูลภาพที่เหมาะสม

เปรียบเทียบผลลัพธ์ที่ได้จากการใช้อัลกอริทึม YOLOv8 เพื่อตรวจจับการสวมหมวกนิรภัย ของชุดข้อมูลภาพจำนวน 3 ชุด โดยใช้เกณฑ์การประเมินประสิทธิภาพจากค่าอัตราความแม่นยำ (Precision), ค่าความไว (Recall), และค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ mAP (Mean Average Precision) [21] แล้ววิเคราะห์และประเมินหาจำนวนข้อมูลภาพที่เหมาะสมที่สุดที่ควรนำมาใช้ในการตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง โดยค่าที่ใช้ในการประเมินประสิทธิภาพนั้นสามารถแสดงรายละเอียดได้ ดังต่อไปนี้

2.4.1 ค่าความแม่นยำ (Precision)

เป็นค่าที่แสดงถึงอัตราส่วนของการตรวจจับที่ถูกต้อง (True Positives: TP) ต่อการตรวจจับทั้งหมดที่แบบจำลองสร้างขึ้น เป็นตัวชี้วัดที่มีความสำคัญเนื่องจากสามารถสะท้อนความน่าเชื่อถือของปริมาณการตรวจจับที่ถูกต้องของโมเดลได้โดยตรง หากค่าความแม่นยำมีค่าสูง จะมีความหมายว่าโมเดลมีความแม่นยำในการตรวจจับวัตถุโดยไม่เกิด False Positives (FP) มากเกินไป หากค่าความแม่นยำมีค่าต่ำ จะหมายความว่าโมเดลมีแนวโน้มที่จะเกิดความผิดพลาดในการตรวจจับบ่อย

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

2.4.2 ค่า Recall

เป็นค่าที่มักถูกนำมาเปรียบเทียบประสิทธิภาพของโมเดลควบคู่กับค่าความแม่นยำ เนื่องจากเป็นค่าที่แสดงถึงความครบถ้วนในการตรวจจับวัตถุที่ถูกต้อง หากค่า Recall สูง จะสามารถบ่งชี้ว่าโมเดลมีประสิทธิภาพในการจับภาพที่ถูกต้อง (TP) ในสัดส่วนที่มาก ซึ่งจะช่วยลดความเสี่ยงในการพลาด TP ที่สำคัญได้

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

2.4.3 ค่า Mean Average Precision (mAP)

เป็นค่าที่ใช้ในการวัดค่าความแม่นยำเฉลี่ยของคลาสในโมเดลที่จะทำการตรวจจับ ในกรณีที่โมเดลประกอบไปด้วยวัตถุหลายประเภท เพื่อให้สามารถประเมินประสิทธิภาพของโมเดลได้อย่างครอบคลุม ค่า mAP สามารถแบ่งออกเป็น 2 ช่วง ได้แก่ mAP50 และ mAP50-95

- mAP50 เป็นค่าความแม่นยำเฉลี่ยที่คำนวณจาก IoU ที่ 0.50 ซึ่งเป็นการวัดความแม่นยำของโมเดลโดยพิจารณาเฉพาะการตรวจจับแบบง่าย
- mAP50-95 เป็นค่าเฉลี่ยของความแม่นยำเฉลี่ยที่คำนวณจากเกณฑ์ของ IoU ที่แตกต่างกัน ซึ่งอยู่ระหว่าง 0.50 ถึง 0.95 จะให้มุมมองที่ครอบคลุมเกี่ยวกับประสิทธิภาพของโมเดลในระดับความยากในการตรวจจับที่แตกต่างกัน

$$mAP = \frac{1}{N}\sum_{i=1}^{N} AP_i \quad (3)$$

3. ผลการวิจัยและอภิปรายผล

จากการดำเนินงานตามขั้นตอนวิธีดำเนินการวิจัย สามารถแสดงผลการวิจัยได้เป็น 2 ส่วนหลัก ประกอบไปด้วย 1) จำนวนข้อมูลภาพใหม่ที่ได้จาก Roboflow และ 2) ผลการตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้างโดยใช้อัลกอริทึม YOLOv8 ซึ่งมีรายละเอียด ดังนี้

3.1 จำนวนข้อมูลภาพใหม่ที่ได้จาก Roboflow

จากขั้นตอนนำเข้าข้อมูลภาพ ผู้วิจัยได้นำเข้าข้อมูลภาพเข้าสู่แพลตฟอร์มจำนวน 1,849 ภาพ จากนั้นทำการตั้งค่าจำนวนภาพสำหรับการฝึกสอน (Training) การตรวจสอบ (Validating) และการทดสอบ (Testing) เท่ากับร้อยละ 70, 20, และ 10 ตามลำดับ จะสามารถได้จำนวนภาพสำหรับการฝึกสอน การตรวจสอบ และการทดสอบ เท่ากับ 1,295ภาพ 370 ภาพ และ 184 ภาพตามลำดับ

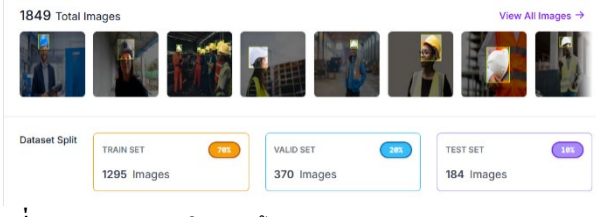

ภาพที่ 10: จำนวนภาพในการฝึกสอน ตรวจสอบ และทดสอบของชุดข้อมูลภาพจำนวนทั้งหมด 1,849 ภาพ

เมื่อนำเข้าข้อมูลภาพตั้งต้นแล้ว ทำการสร้างจำนวนข้อมูลภาพใหม่ เป็นจำนวน 2 และ 3 เท่าของจำนวนภาพตั้งต้น จากกระบวนการทำงานของแพลตฟอร์ม Roboflow จะสามารถสร้างจำนวนภาพใหม่จากจำนวนภาพตั้งต้นที่ใช้ในการฝึกสอน หมายความว่าเมื่อภาพตั้งต้นที่ใช้ในการฝึกสอนมีจำนวน 1,295 ภาพ ภาพที่ถูกสร้างขึ้นใหม่จำนวน 2 และ 3 เท่า มีจำนวนเท่ากับ 2,574 และ 3,894 ภาพตามลำดับ แต่ในส่วนของจำนวนภาพที่ใช้ในการตรวจสอบ และทดสอบ จะถูกปรับเปลี่ยนสัดส่วนไปตามการทำงานของแพลตฟอร์ม ซึ่งมีค่าที่แตกต่างกัน

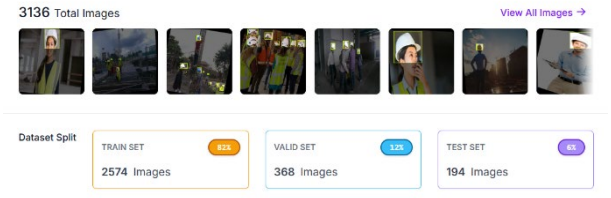

ภาพที่ 11: จำนวนภาพในการฝึกสอน ตรวจสอบ และทดสอบของชุดข้อมูลภาพจำนวนทั้งหมด 3,136 ภาพ

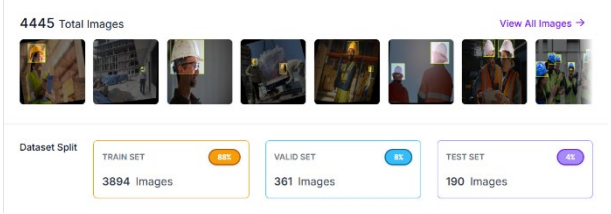

ภาพที่ 12: จำนวนภาพในการฝึกสอน ตรวจสอบ และทดสอบของชุดข้อมูลภาพจำนวนทั้งหมด 4,445 ภาพ

3.2 ผลการตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้างโดยใช้อัลกอริทึม YOLOv8

หลังจากการสร้างข้อมูลภาพใหม่บน Roboflows ผู้วิจัยได้นำภาพที่ได้ทั้ง 3 ชุดไปฝึกสอน ตรวจสอบ และทดสอบสำหรับการตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้างด้วยอัลกอริทึม YOLOv8 โดยสามารถสรุปประสิทธิภาพในการตรวจจับของแต่ละชุดข้อมูลภาพ ดังตารางที่ 1 จากการใช้ภาพจำนวน 1,650 และ 1,849 ภาพ ซึ่งเป็นภาพที่ถูกรวบรวมจากโครงการก่อสร้างและอินเตอร์เน็ต และถูกนำเข้าสู่ Roboflows เพื่อ Label หมวกนิรภัย ไม่มีการ Annotate เมื่อเปรียบเทียบประสิทธิภาพจะเห็นได้ว่า จำนวนภาพ 1,650 ภาพให้ค่าความแม่นยำ (Precision) ของโมเดลที่สูงกว่าจำนวนภาพ 1,849 ภาพ แต่ทั้งนี้เนื่องจากจำนวนภาพ 1,849 ภาพนั้นได้มีการรวบรวมภาพสำหรับการฝึกสอนโมเดลเพิ่มเติมจากอินเตอร์เน็ตจากจำนวนภาพ 1,650 ภาพ เปรียบเสมือนการเพิ่ม Annotation อาจตีความได้ว่าภาพที่ใช้ในการฝึกสอนโมเดลมีความแตกต่างกันมากขึ้น ทำให้การวัดประสิทธิภาพหรือค่าความแม่นยำนั้นมีค่าต่ำลง อีกนัยหนึ่งยังสามารถกล่าวได้ว่าจำนวนภาพ 1,650 ภาพอาจมีการ overfitting ของข้อมูล ทำให้ได้ค่าความแม่นยำมีค่าที่สูงกว่า

เมื่อทำการเปรียบเทียบชุดข้อมูลภาพ 1,849ภาพ, 3,136 ภาพ และ 4,445 ภาพ จะพบว่าจำนวนภาพ 4,445 ภาพนั้นให้ค่าความแม่นยำมากที่สุดที่ 0.959 ซึ่งสอดคล้องกับทฤษฎีของการเรียนรู้ของเครื่องที่ว่า หากข้อมูลมีจำนวนมากและมีความหลากหลายจะส่งผลให้การฝึกสอนโมเดลนั้นมีความแม่นยำและมีประสิทธิภาพมากขึ้น

ตารางที่ 1: ผลการตรตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้างโดยใช้อัลกอริทึม YOLOv8

Dataset	จำนวนภาพ	จำนวนภาพหลัง Annotation	Epochs	Precision	Recall	mAP50	mAP50-95
1	1,650	1,650	100	0.923	0.832	0.893	0.546
2	1,849	1,849	100	0.915	0.843	0.901	0.553
3	1,849	3,136	100	0.955	0.839	0.900	0.599
4	1,849	4,445	100	0.959	0.827	0.896	0.597

จากตารางจะเห็นว่าการพิจารณา สรุปหาโมเดลที่ดีที่สุดนั้นอาจเป็นไปได้ยาก เนื่องจากแต่ละจำนวนข้อมูลภาพมีประสิทธิภาพแตกต่างกันกันในบางตัวชี้วัด แต่หากพิจารณาภาพรวมโดยให้ความสำคัญกับค่า mAP50 และ mAP50-95 ซึ่งเป็นค่าที่สะท้อนประสิทธิภาพการตรวจจับในหลายค่า IoU เป็นหลัก จะพบว่าโมเดลที่ 2 มีค่า mAP50 สูงที่สุดเท่ากับ 0.901 ในขณะที่โมเดลที่ 3 มีค่า mAP50-95 สูงที่สุดเท่ากับ 0.599 และยังมีค่าความแม่นยำสูงถึง 0.955

โดยทั่วไปแล้วในการประเมินประสิทธิภาพของงานตรวจจับวัตถุ (Object Detection) มักจะให้ความสำคัญกับค่า mAP50-95 เป็นพิเศษ เนื่องจากสะท้อนความแม่นยำได้หลายระดับของ IoU ซึ่งโมเดลที่ 3 มีค่า mAP50-95 สูงที่สุด และค่า mAP50 ก็ถือว่าแทบไม่แตกต่างจากโมเดลที่ 2 ที่มีค่าเท่ากับ 0.900 อีกทั้งค่า Precision ของโมเดลที่ 3 ยังสูงถึง 0.955 ทำให้โมเดลที่ 3 เมื่อดูภาพรวมแล้วนับว่าค่อนข้างมีประสิทธิภาพในหลายตัวชี้วัด ทั้งในแง่ความแม่นยำและความครอบคลุม

ดังนั้นหากต้องเลือกเพียงหนึ่งโมเดลโดยให้น้ำหนักกับ mAP50-95 ค่าความแม่นยำ และค่าความครอบคลุม ในภาพรวม โมเดลที่ 3 ถือเป็นตัวเลือกที่น่าสนใจที่สุดสำหรับงานตรวจจับการสวมหมวกนิรภัยในงานวิจัยครั้งนี้

อย่างไรก็ตามในงานวิจัยครั้งนี้ยังคงมีข้อจำกัดบางประการ เช่น การใช้แพลตฟอร์ม Roboflow ในเวอร์ชันทดลองใช้ จะมีข้อจำกัดของจำนวนครั้งในการสร้าง Project ใหม่ การกำหนดภาพความละเอียดสูง อีกทั้งสัดส่วนของจำนวนภาพที่ใช้ในการฝึกสอนโมเดลนั้นจะไม่สามารถกำหนดเองได้ตามความต้องการในขั้นตอนการสร้างจำนวนภาพใหม่ ตามเงื่อนไขข้อกำหนดของเวอร์ชันทดลองใช้ และถึงแม้ว่า Roboflows จะมีโมดูลสำหรับ Auto-labelling แต่ก็ยังไม่สามารถ Label ได้อย่างครอบคลุมทุกๆวัตถุที่ปรากฏในภาพ ทำให้ผู้ใช้งานยังต้องใช้เวลาในตรวจสอบความถูกต้องและทำการ Label วัตถุด้วยตนเอง ในส่วนที่เหลือ ซึ่งอาจไม่ตอบโจทย์ในด้านของระยะเวลาการทำงาน

ในการพัฒนางานวิจัยในอนาคต อาจเพิ่มลักษณะของสภาพแวดล้อมที่มีความหลากหลายมากยิ่งขึ้น เช่น การตรวจจับในช่วงเวลากลางคืน นอกจากนี้อาจสามารถทดลองนำจำนวนข้อมูลภาพที่เหมาะสมไปใช้ในการตรวจจับการสวมหมวกนิภัยของคนงานในโครงการก่อสร้างแบบเรียลไทม์ผ่านกล้องวงจรปิด เพื่อใช้ในการบริหารจัดการด้านความปลอดภัย รวมถึงอาจพัฒนาการตรวจจับวัตถุ PPE ชนิดอื่น เช่น รองเท้านิรภัย ถุงมือ ฯลฯ หรืออาจตรวจจับวัตถุหลายชนิดในภาพเดียวกัน (Multi-objective)

ผู้วิจัยยังเล็งเห็นถึงโอกาสในการเรียนรู้และนำมาใช้สำหรับผู้เริ่มต้นที่สนใจในการพัฒนาโมเดล เพื่อใช้ในการตรวจจับการสวมใส่อุปกรณ์ PPE ประเภทอื่นๆ ในโครงการก่อสร้าง ช่วยลดอัตราการเกิดอุบัติเหตุ อันเป็นสาเหตุแห่งความสูญเสีย การลดอัตราการเกิดอุบัติเหตุมีผลโดยตรงต่อการบริหารการก่อสร้างในเรื่องของ การสูญเสียเวลา (Time)

คุณภาพของงาน (Quality) ค่าใช้จ่าย (Cost) โดยเฉพาะเป็นการช่วยลดการจ่ายสินไหมทดแทนสำหรับผู้ปฏิบัติงานที่ประสบอุบัติเหตุ อันเป็นสิ่งที่สามารถบริหารจัดการไม่ให้เกิดขึ้น หรือควบคุมให้เกิดขึ้นน้อยที่สุด เป็นการสร้างมาตรฐานและสร้างความเชื่อมั่นต่อองค์กรของบุคลากรใน

องค์กร และความเชื่อมั่นของพันธมิตรทางธุรกิจที่มีต่อองค์กร รวมถึงภาพลักษณ์เรื่องความปลอดภัยที่ยั่งยืน

4. กิตติกรรมประกาศ

งานวิจัยเรื่อง การพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อตรวจจับการสวมหมวกนิรภัยในโครงการก่อสร้าง สามารถดำเนินการจนประสบความสำเร็จลุล่วงไปด้วยดี เนื่องจากได้รับความอนุเคราะห์และสนับสนุนเป็นอย่างดียิ่งจาก รองศาสตราจารย์ ดร.ดำรงศักดิ์ รินชุมภู, ผู้ช่วยศาสตราจารย์ ดร.นที สุริยานนท์ และอาจารย์ ดร.สมจินตนา แขนงแก้ว คณาจารย์ภาควิชาการบริหารงานก่อสร้าง คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่ ที่ได้กรุณาให้คำปรึกษา แนะนำแนวทางความรู้และข้อคิดเห็น ในการปรับปรุงแก้ไขข้อบกพร่องต่างๆ จนกระทั่งงานวิจัยนี้สำเร็จเรียบร้อยด้วยดี ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอขอบคุณ บริษัท โรงพยาบาลกรุงเทพเชียงใหม่ จำกัด ที่ให้ความอนุเคราะห์ อนุญาตให้ใช้สถาที่เก็บข้อมูลรูปภาพในโครงการก่อสร้าง

ขอขอบคุณ บริษัท โรงพยาบาลกรุงเทพเชียงราย จำกัด ที่ให้ความอนุเคราะห์ อนุญาตให้ใช้สถาที่เก็บข้อมูลรูปภาพในโครงการก่อสร้าง

ขอขอบคุณ บริษัท โรงพยาบาลลำพูนใกล้หมอ จำกัด ที่ให้ความอนุเคราะห์ อนุญาตให้ใช้สถาที่เก็บข้อมูลรูปภาพในโครงการก่อสร้าง

ขอขอบคุณเพื่อน พี่ น้อง ร่วมคณะทุกคนที่อำนวยความสะดวกและให้ความช่วยเหลือในการทำงานวิจัยค้นคว้าอิสระในครั้งนี้ สุดท้ายนี้ผู้วิจัยหวังว่า งานวิจัยนี้จะเป็นแรงบันดาลใจและประโยชน์สำหรับหน่วยงานต่างๆ และผู้ที่สนใจศึกษาต่อไป

5. เอกสารอ้างอิง

[1] คณะทำงานจัดทำรายงานสุขภาพคนไทย. 2567 Available from: https://www.thaihealthreport.com

[2] สมาคมส่งเสริมความปลอดภัยและอนามัยในการทำงาน (ประเทศไทย) ในพระราชูปถัมภ์ฯ. 2567 [Available from: https://www.shawpat.or.th

[3] สำนักงานกองทุนเงินทดแทน สำนักงานประกันสังคม กระทรวงแรงงาน. In: กระทรวงแรงงาน, editor. 2567.

[4] สมาคมผู้ตรวจสอบอาคาร. 2565 Available from: https://www.bsa.or.th

[5] BigRentz. 2023 updated 25/05/2023. Available from: https://www.bigrentz.com

[6] Bhaidasna MH, Bhaidasna MZ. 2023.

[7] Datta SD, Islam M, Rahman Sobuz MH, Ahmed S, Kar M. Heliyon. 2024;10(5):e26888.

[8] Seong H, Choi H, Cho H, Lee S, Son H, Kim C, editors. Vision-based safety vest detection in a construction scene. ISARC Proceedings of the International Symposium on Automation and Robotics in Construction; 2017: IAARC Publications.

[9] Szeliski R. Springer Nature; 2022.

[10] วัฒนพงศ์ เหมือนมี. ระบบกล้อง AI ตรวจสอบพนักงานสวมใส่อุปกรณ์ ป้องกันภัยส่วนบุคคลก่อนเข้าทำงานในพื้นที่เสี่ยง. มหาวิทยาลัยธรรมศาสตร์; 2565.

[11] Xu S, Wang J, Shou W, Ngo T, Sadick A-M, Wang X. Archives of Computational Methods in Engineering. 2021;28(5):3383-97.

[12] Fang W, Love PED, Luo H, Ding L. Advanced Engineering Informatics. 2020;43:100980.

[13] Fang W, Ding L, Love PED, Luo H, Li H, Peña-Mora F, et al. Automation in Construction. 2020;110:103013.

[14] Patel K, Patel V, Prajapati V, Chauhan D, Haji A, Degadwala S.2023. 22-6 p.

[15] Anushkannan N, Kumbhar VR, Maddila SK, Kolli CS, Vidhya B, Vidhya R, editors. YOLO algorithm for helmet detection in industries for safety purpose. 2022 3rd International Conference on Smart Electronics and Communication (ICOSEC); 2022: IEEE.

[16] Zhou F, Zhao H, Nie Z, editors. Safety Helmet Detection Based on YOLOv5. 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA); 2021 22-24 Jan. 2021.

[17] Lin B. IEEE Access. 2024;12:28260-72.

[18] GFStealer. 2023 [updated 11/04/2023. Available from: https://dev.to

[19] Terven J, Córdova-Esparza D-M, Romero-González J-A. Machine learning and knowledge extraction. 2023;5(4):1680-716.

[20] Li J, Xie S, Zhou X, Zhang L, Li X. Journal of Real-Time Image Processing. 2025;22(1):26.

[21] Ultralytics. n.p. [Available from: https://www.ultralytics.com

การวิเคราะห์การจำแนกประเภทในการเกิดโรคเบาหวาน โดยอาศัยข้อมูลจากการวิเคราะห์ปัจจัย

Analysis of the Classification of Diabetes Mellitus based on Data from Factor Analysis

ณัฐธิดา จาง* ฐิตนนท์ จารุโรจน์กีรติ

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(S6304051820064@email.kmutnb.ac.th)*

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพของสมการเชิงเส้นในการทำนายการเกิดโรคเบาหวาน และหาวิธีการวิเคราะห์ที่มีประสิทธิภาพสูงสุด ผู้วิจัยได้ศึกษาข้อมูลจากเวชระเบียน ณ โรงพยาบาลแห่งหนึ่ง โดยเริ่มศึกษาจากการนำข้อมูลจริงที่ได้ทำความสะอาดข้อมูล (Data Cleaning) เพื่อตรวจสอบและแก้ไขข้อมูลให้สมบูรณ์ จะได้ข้อมูลจริงจากการตรวจสุขภาพคนไข้จำนวน 1,142 รายและได้ตัวแปรอิสระทั้งหมด 21 ตัวแปร ซึ่งจะทำการแบ่งข้อมูลเป็น 2 ส่วน ได้แก่ ข้อมูลชุดเรียนรู้ (Training Set) แบ่งเป็นร้อยละ 70 และข้อมูลชุดทดสอบ (Test Set) แบ่งเป็นร้อยละ 30 จากข้อมูลทั้งหมด ซึ่งผู้วิจัยใช้ข้อมูลชุดเรียนรู้ (Training Set) ในการรวมกลุ่มตัวแปรอิสระที่มีความสัมพันธ์กันด้วยวิธีการวิเคราะห์ปัจจัย (Factor Analysis) จะได้ว่าสามารถรวมกลุ่มตัวแปรอิสระได้ทั้งหมด 7 ปัจจัย จากนั้นจึงทำการวิเคราะห์ตัวแบบเชิงเส้น โดยมีวิธีการวิเคราะห์ทั้งหมด 2 วิธี ได้แก่ การวิเคราะห์การจำแนกประเภท (Discriminant Analysis) และการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ (Excel Solver) ด้วยวิธี Generalized Reduced Gradient (GRG) Nonlinear โดยคำนึงถึงค่าผลรวมกำลังสองของความคลาดเคลื่อน (SSE) ต่ำที่สุด ซึ่งเลือกใช้เกณฑ์การวัดประสิทธิภาพตัวแบบเชิงเส้นที่เหมาะสม คือ เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) ด้วยข้อมูลชุดทดสอบ (Test Set) ซึ่งผลการวิจัยตัวแบบเชิงเส้นการจำแนกผู้ป่วยเบาหวานด้วยการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ (Excel Solver) พบว่าค่าความถูกต้อง (Accuracy) เท่ากับ 99.17 ค่าความแม่นยำ (Precision) เท่ากับ 88.89 ค่า Recall เท่ากับ 80.00 และ F1 Score เท่ากับ 84.21 ซึ่งเป็นตัวแบบเชิงเส้นที่เหมาะสมที่สุด

คำสำคัญ: โรคเบาหวาน การวิเคราะห์ปัจจัย การวิเคราะห์การจำแนกประเภท เมตริกซ์วัดประสิทธิภาพ

Abstract

This research aimed to study the efficiency of linear model equations that affect the occurrence of diabetes from real data and to find the chance of the occurrence of the event of interest from the most efficient analysis method. The researcher studied data from medical records at a hospital, starting from the study of the real data that had been cleaned (Data Cleaning) to check and correct the data to be complete. The results obtained were real data from health examinations of 1,142 patients and a total of 21 independent variables. The data will be divided into 2 parts: Training Set data, divided into 70 percent, and Test Set data, divided into 30 percent of the total data. The researcher used the Training Set data to group the independent variables that are related to each other using Factor Analysis. It was found that there were 7 independent variables that could

be grouped. Then a linear model analysis was performed. There are 2 methods of analysis: classification analysis (Discriminant Analysis) and solving linear schedule problems with Excel Solver using the Generalized Reduced Gradient (GRG) Nonlinear method, considering the lowest sum of squares of error (SSE). which selected the most appropriate linear model efficiency measurement criteria, which is the efficiency matrix (Confusion Matrix) with the test set data (Test Set). The results of the research on the linear model for classifying diabetic patients using Excel Solver (Excel Solver) from the test set data (Test Set) found that the accuracy value was equal to 99.17, the precision value was equal to 88.89, the recall was equal to 80.00, and the F1-Score was equal to 84.21, which was the most appropriate linear model.

Keyword: Diabetes, Factor Analysis, Discriminant Analysis, Confusion Matrix

1. บทนำ

กลุ่มโรคไม่ติดต่อเรื้อรัง (Non-Communicable Diseases: NCDs) เป็นปัญหาสาธารณสุขที่ทั่วโลกให้ความสำคัญ โดยเฉพาะอย่างยิ่งโรคเบาหวาน จากรายงานกรมควบคุมโรค กระทรวงสาธารณสุข (สธ.) ประเทศไทย กล่าวว่าในปี 2565 มีผู้ป่วยโรคเบาหวานที่อยู่ในระบบทะเบียน 3.3 ล้านคน โดยมีผู้เสียชีวิตจากโรคเบาหวานทั้งหมด 16,388 คน อีกทั้งยังมีแนวโน้มพบผู้ป่วยรายใหม่เพิ่มขึ้นปีละ 3 แสนคน

ดังนั้นผู้วิจัยจึงมีความสนใจศึกษาปัจจัยที่มีอิทธิพลต่อโรคไม่ติดต่อเรื้อรัง โดยศึกษาค้นคว้าตัวแปรที่ชี้วัดความเสี่ยงในการเกิดโรค ซึ่งได้นำข้อมูลจริงจากการตรวจสุขภาพจำนวนทั้งหมด 1,142 ราย และได้ทำการสุ่มชุดข้อมูลสำรองไว้ 30% เพื่อใช้สำหรับทดสอบความแม่นยำตัวแบบ ซึ่งการศึกษาครั้งนี้เลือกใช้วิธีการวิเคราะห์ทั้งหมด 2 วิธี ได้แก่ การวิเคราะห์การจำแนกประเภท (Discriminant Analysis) และวิธีการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ (Excel Solver) โดยคำนึงถึงค่าผลรวมกำลังสองของความคลาดเคลื่อน (SSE) ต่ำที่สุด

จากการวิเคราห์ข้อมูลในครั้งนี้ ผู้วิจัยเล็งเห็นว่าสามารถนำไปประยุกต์ใช้สำหรับการหาโอกาสของการเกิดเหตุการณ์ที่สนใจอื่น ๆ และพบว่าสามารถนำมาพัฒนาและวิเคราะห์ได้อย่างต่อเนื่อง โดยการศึกษานี้ใช้โปรแกรมสำเร็จรูป Microsoft Excel สำหรับการทำความสะอาดข้อมูล (Data Cleaning) และการวิเคราะห์ด้วยเอ็กเซลโซลเวอร์ (Excel Solver) โปรแกรม Minitab เวอร์ชัน 16 สำหรับการวิเคราะห์ข้อมูลและสร้างสมการตัวแบบเชิงเส้นเพื่อจำแนกผู้ป่วยเบาหวาน

2. วิธีการวิจัย

2.1 การทำความสะอาดข้อมูล (Data Cleaning)

เป็นกระบวนการการตรวจสอบและแก้ไขข้อมูลที่ไม่ถูกต้องจากชุดข้อมูล และทำการตรวจสอบความสูญหายของข้อมูลที่ว่าง (Blank) ด้วยวิธีการประมาณค่าด้วยค่าเฉลี่ย (Mean Imputation) โดยวิธีนี้จะใช้ค่าเฉลี่ยของตัวแปรนั้น ๆ ในชุดข้อมูลที่มีเพื่อแทนค่าที่สูญหาย ซึ่งช่วยทำให้ข้อมูลมีความสมบูรณ์มากขึ้น

2.2 ประชากรและกลุ่มตัวอย่าง

ข้อมูลในงานวิจัยนี้ได้ข้อมูลมาจากการตรวจสุขภาพของคนไข้จำนวน 1,142 ราย จากเวชระเบียนของโรงพยาบาลแห่งหนึ่ง ซึ่งรวบรวมจากการประสานงานผ่านบุคลากรในโรงพยาบาลให้ได้มาซึ่งชุดข้อมูล โดยจากข้อมูลที่ได้รับประกอบด้วยตัวแปรอิสระทั้งหมด 21 ตัวแปร โดยผู้วิจัยจะทำการแบ่งข้อมูลออกเป็น 2 ส่วนด้วยวิธีการสุ่มตัวอย่างอย่างง่าย (Simple Random Sampling) ได้แก่ ข้อมูลชุดเรียนรู้ (Training Set) แบ่งเป็นร้อยละ 70 จากข้อมูลทั้งหมด โดยจะถูกนำไปเรียนรู้ด้วยวิธีการวิเคราะห์เพื่อสร้างตัวแบบเชิงเส้นเพื่อจำแนกผู้ป่วยโรคเบาหวาน และข้อมูลชุดทดสอบ (Test Set) แบ่งเป็นร้อยละ 30 จากข้อมูลทั้งหมดใช้สำหรับการทดสอบประสิทธิภาพของตัวแบบเชิงเส้นเพื่อจำแนกผู้ป่วยโรคเบาหวานจากแต่ละวิธีการวิเคราะห์

2.3 การวิเคราะห์ปัจจัย (Factor Analysis)

การรวมกลุ่มปัจจัยที่มีความสัมพันธ์กันให้เป็นตัวแปรหรือปัจจัยใหม่ที่ไม่มีความสัมพันธ์กัน ผู้วิจัยได้ใช้เทคนิคการวิเคราะห์ปัจจัย (Factor Analysis) ในการจัดกลุ่มปัจจัย โดยพิจารณาว่าตัวแปรใดควรอยู่ใน Factor ใดนั้น พิจารณาจากค่า Eigenvalues มากกว่าหรือเท่ากับ 1 และตัวแปรแต่ละตัวแปรมีค่าน้ำหนักองค์ประกอบ (Factor Loading) เท่ากับ 0.5 ขึ้นไปหรือมีค่าเข้าสู่ +1 หรือ -1

2.4 การวิเคราะห์จำแนกปัจจัย (Discriminant Analysis)

การวิเคราะห์จำแนกประเภท เป็นเทคนิคทางสถิติที่ใช้ในการแบ่งกลุ่มออกเป็นกลุ่มย่อย ๆ ตั้งแต่ 2 กลุ่มขึ้นไป โดยพิจารณาจากลักษณะหรือคุณสมบัติของตัวแปรที่เกี่ยวข้อง ซึ่งสามารถใช้เพื่อจำแนกกลามต่าง ๆ ได้อย่างมีประสิทธิภาพ โดยใช้วิธี Linear Discriminant Function ซึ่งเป็นวิธีการที่ใช้ในการจำแนกกลุ่มข้อมูลโดยการหาฟังก์ชันเชิงเส้นที่สามารถแยกกลุ่มข้อมูลออกจากกันได้ดีที่สุด

2.5 การแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ (Excel Solver)

การประมวนผลตัวแบบเพื่อหาผลลัพธ์ที่เหมาะสมที่สุด วิธีการใช้โปรแกรมสำเร็จรูปเอ็กเซลโซลเวอร์ เพื่อแก้ปัญหาแบบจำลองที่เป็น Nonlinear การวิเคราะห์การถดถอยนี้จะสร้างโดยวิธี GRG Nonlinear ที่มีเป้าหมายให้ได้ค่าผลรวมกำลังสองของความคลาดเคลื่อน (SSE) ต่ำที่สุด

2.6 การวัดประสิทธิภาพด้วยเมตริกซ์ (Confusion Matrix)

การวัดประสิทธิภาพการจำลองของสมการตัวเบบเชิงเส้นและแสดงผลด้วยเมตริกซ์เป็นส่วนสำคัญในขั้นตอนสุดท้าย เนื่องจากการวัดประสิทธิภาพของการจำแนกข้อมูล (Classifier) บ่งบอกถึงความน่าเชื่อถือของตัวแบบ

		ค่าอ้างอิง (เป็นจริง)		
		เกิดเหตุการณ์	ไม่เกิดเหตุการณ์	รวม
ผลการทำนายจากแบบจำลอง	เกิดเหตุการณ์	True Positive (TP)	False Positive (FP)	TP + FP
	ไม่เกิดเหตุการณ์	False Negative (FN)	True Negative (TN)	FN + TN
	รวม	TP + FN	FP + TN	TP+FP+FN+TN

ภาพที่ 1: เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix)

เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) เป็นเครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย หรือ Prediction ที่ทำนายจากตัวแบบที่สร้างขึ้น จากภาพที่ 1 แต่ละแถวของเมตริกซ์จะแสดงถึงความเป็นจริงของคลาส ในขณะที่แต่ละคอลัมน์จะแสดงถึงคลาสที่ตัวแบบทำนาย โดยประกอบด้วย True Positive (TP) หมายถึง ตัวแบบทำนายกรณีที่เป็นจริงได้ถูกต้อง Ture Negative (TN) หมายถึง ตัวแบบทำนายกรณีที่เป็นเท็จได้ถูกต้อง False Positive (FP) หมายถึง ตัวแบบทำนายกรณีที่เป็นจริงแต่เป้าหมายเป็นเท็จ และ False Negative (FN) หมายถึง ตัวแบบทำนายกรณีที่เป็นเท็จแต่เป้าหมายเป็นจริง

ค่าความถูกต้อง (Accuracy) เป็นการวัดความถูกต้องของตัวแบบโดยรวม กล่าวคือตัวแบบทำนายถูกต้องกี่ครั้งจากจำนวนการทำนายทั้งหมด

ค่าความแม่นยำ (Precision) เป็นการวัดความแม่นยำในการทำนายในกลุ่มเป้าหมายหรือพิจารณาเฉพาะที่เป็น True Positive (TP)

ค่า Recall คือความสามารถของตัวแบบในการทำนาย หรือระบุสิ่งที่สนใจ ซึ่งคือสัดส่วนของ True Positive (TP) เทียบกับ True Positive (TP) และ False Negative (FN)

ค่า F1-Score เป็นการหาค่าเฉลี่ยแบบ Harmonic Mean ระหว่าง Precision และ Recall เพื่อเป็น Single Metric ที่วัดความสามารถของตัวแบบ

3. ผลการวิจัย

3.1 การวิเคราะห์ปัจจัย (Factor Analysis)

เมื่อทำการวิเคราะห์ปัจจัยเพื่อพิจารณาตัวแปรที่สามารถสกัดปัจจัย พบว่าสามารถจัดกลุ่มข้อมูลชุดเรียนรู้จากตัวแปรอิสระทั้งหมด 21 ตัวแปร โดยใช้เทคนิคการวิเคราะห์ปัจจัย (Factor Analysis) ประเภทการวิเคราะห์ปัจจัยเชิงสำรวจ (Exploratory Factor Analysis: EFA) โดยใช้วิธีสกัดปัจจัยแบบวิธีตัวประกอบหลักปัจจัย (Principal Component Analysis) และหมุนแกนปัจจัยแบบตั้งฉาก (Orthogonal Rotation) ด้วยวิธีแวริแมกซ์ (Varimax Rotation) โดยพิจารณาจากค่าสถิติ Kasier-Meyer-Olkin (KMO) ที่เท่ากับ 0.657 (ซึ่งมีค่ามากกว่า 0.5) และค่า Bartlett's Test มีนัยสำคัญทางสถิติที่ระดับ .00 (ซึ่งมีค่าน้อยกว่าระดับนัยสำคัญ 0.05) จึงกล่าวได้ว่าข้อมูลที่ได้จากการเก็บกลุ่มตัวอย่างมีความเหมาะสมที่จะนำไปวิเคราะห์ปัจจัยเชิงสำรวจเกี่ยวกับการจำแนกผู้ป่วยเบาหวาน

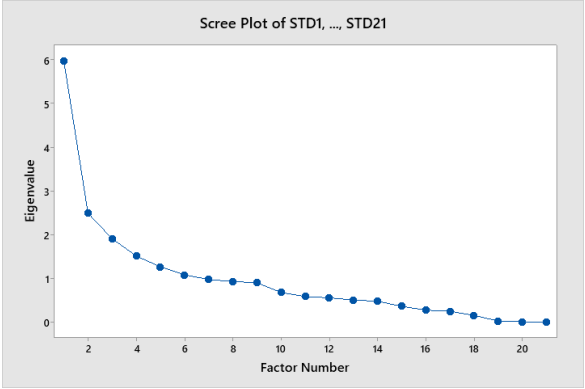

ภาพที่ 2: กราฟ Scree Plot

จากภาพที่ 2 แสดงภาพ Scree Plot เป็นกราฟที่พล็อตค่า Eigenvalues ของแต่ละปัจจัย โดยเรียงจากมากไปน้อย เพื่อใช้ประกอบการพิจารณาว่าควรมีกี่ปัจจัย โดยพิจารณาค่า Eigenvalues ที่ลดลงอย่างรวดเร็ว ในที่นี้พิจารณาเฉพาะปัยจัยที่มีค่า Eigenvalues มากกว่าหรือเท่ากับ 1 และตัวแปรแต่ละตัวแปรมีค่าน้ำหนักองค์ประกอบ (Factor Loading) เท่ากับ 0.5 ขึ้นไป ซึ่งมีเพียง 7 ปัจจัยดังนี้

1) ปัจจัยด้านสรีรวิทยาและสารอาหาร ประกอบด้วย X_2 คือ น้ำหนัก, X_3 คือ ส่วนสูง, X_4 คือ ดัชนีมวลกาย, X_9 คือ โปรตีนในเม็ดเลือดแดง, X_{10} คือ ค่าเฉลี่ยปริมาตรเม็ดเลือดแดง, X_{16} คือ กรดยูริก และ X_{17} คือ คอเลสเตอรอล

2) ปัจจัยด้านความเสี่ยงจากไขมันและการไหลเวียนเลือด ประกอบด้วย X_5 คือ ชีพจร, X_{14} คือ ปริมาณไนโตรเจนในเลือด, X_{19} คือ ไขมันไม่ดี และ X_{21} คือ ไตรกลีเซอไรด์

3) ปัจจัยด้านสมดุลไขมันในร่างกาย ประกอบด้วย X_{18} คือ ไขมันดี และ X_{20} คือ เพศ

4) ปัจจัยด้านความดันโลหิตและสุขภาพหลอดเลือด ประกอบด้วย X_1 คือ อายุ, X_7 คือ ความดันโลหิตขณะหัวใจคลายตัว, X_8 คือ ปริมาณความเข้มข้นของเม็ดเลือดแดง และ X_{15} คือ ครีตินิน

5) ปัจจัยด้านระบบการเผาผลาญและเกร็ดเลือด ประกอบด้วย X_{12} คือ ปริมาณของเกร็ดเลือดและ X_{13} คือ ระดับน้ำตาลในเลือด

6) ปัจจัยด้านภูมิคุ้มกัน ประกอบด้วย X_{11} คือ ปริมาณเม็ดเลือดขาว

7) ปัจจัยด้านความดันโลหิตสูง ประกอบด้วย X_6 คือ ความดันโลหิตขณะหัวใจบีบตัว

3.2 การวิเคราะห์การจำแนกปัจจัย (Discriminant Analysis)

จากการวิเคราะห์จะได้สมการที่ใช้เพื่อจำแนกข้อมูลใหม่ว่าควรจะอยู่กลุ่มใด โดยใช้วิธี Linear Discriminant Function ในการจำแนกกลุ่มของข้อมูลทำให้ได้สมการเชิงเส้นสำหรับกลุ่มไม่เป็นโรค ($Y=0$) คือ

$$\hat{y}_0 = -0.0052 + 0.0090Z_1 + 0.0727Z_2 + 0.0059Z_3 + 0.0039Z_4 + 0.0050Z_5 - 0.0302Z_6 + 0.0077Z_7 \quad (1)$$

และสมการสำหรับกลุ่มเป็นโรค ($Y=1$) คือ

$$\hat{y}_1 = -4.4358 - 0.3389Z_1 - 2.3640Z_2 - 0.1009Z_3 - 0.0490Z_4 + 0.2033Z_5 - 0.9465Z_6 - 0.5075Z_7 \quad (2)$$

โดยสมการทั้ง 2 สมการนี้จะใช้เพื่อจำแนกข้อมูลว่าปัจจัยควรจะอยู่กลุ่มใด การใช้สมการนี้คือนำสัมประสิทธิ์ที่อยู่ในแต่ละกลุ่มเพื่อจำแนกข้อมูลว่าควรจะอยู่กลุ่มไหน โดยตัวแบบเชิงเส้นจากวิธีการจำแนกปัจจัย พบว่าสามารถจำแนกกลุ่มเป็นโรค ($Y=1$) ถูกต้องร้อยละ 94.80 และจำแนกกลุ่มไม่เป็นโรค ($Y=0$) ถูกต้องร้อยละ 87.50 ดังตารางที่ 1

ตารางที่ 1: เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) จากการวิเคราะห์การจำแนกปัจจัย (n=781)

ผลการทำนาย / ค่าที่เป็นจริง	เป็นโรค ($Y=1$)	ไม่เป็นโรค ($Y=0$)
เป็นโรค ($Y=1$)	28	39
ไม่เป็นโรค ($Y=0$)	4	710
จำนวนที่ทำนายถูกต้อง	28	710
จำนวนรวม	32	749
ร้อยละ	87.50	94.79

จากตารางที่ 1 จะได้ว่าตัวแบบเชิงเส้นจากการวิเคราะห์การจำแนกปัจจัยด้วยข้อมูลชุดเรียนรู้ได้ค่า Accuracy เท่ากับ 0.9449 ค่า Precision เท่ากับ 0.4179 ค่า Recall เท่ากับ 0.8750 และค่า F1-Score เท่ากับ 0.5657 ซึ่งให้ประสิทธิภาพของตัวแบบพอใช้

3.3 การแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์

จากการวิเคราะห์ด้วยเอ็กเซลโซลเวอร์ด้วยวิธี Generalized Reduced Gradient (GRG) Nonlinear จะได้ค่าผลรวมกำลังสองของความคลาดเคลื่อน (SSE) ต่ำที่สุด คือ 22.393 และสามารถสร้างสมการเชิงเส้นได้ดังสมการต่อไปนี้

$$\hat{y} = 0.038 - 0.010Z_1 - 0.070Z_2 - 0.003Z_3 - 0.002Z_4 + 0.006Z_5 - 0.026Z_6 - 0.015Z_7 \quad (3)$$

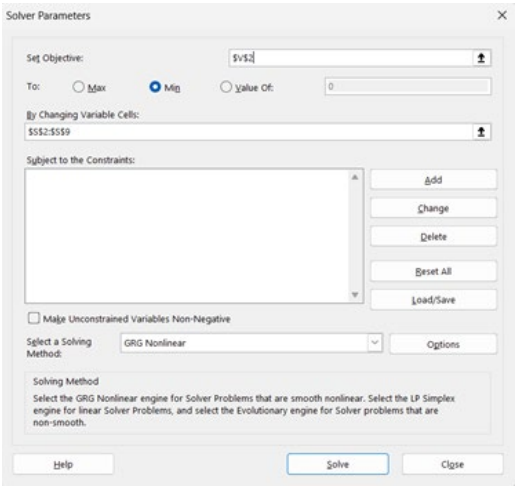

ภาพที่ 3: Solver Parameters

โดยกำหนดรายละเอียดพารามิเตอร์และเงื่อนไขต่างๆ ในฟังก์ชันเอ็กเซลโซลเวอร์ ดังภาพที่ 3

1) Set Objective เป็นผลลัพท์ที่ต้องการให้แสดงในเซลล์นั้น

2) To กำหนดให้ผลลัพธ์ที่ต้องการนั้นเป็นเช่นไร โดยสามารถกำหนดให้คำนวณหาค่าสูงสุด (Max) ค่าต่ำสุด (Min) หรือกำหนดค่าที่ต้องการเอง (Value of)

3) By Changing Variable Cells เป็นเซลล์ที่ต้องการให้เปลี่ยนค่าตามพารามิเตอร์

4) Subject to the Constraints เป็นการกำหนดเงื่อนไขในการคำนวณ

5) Select a Solving Method เลือกใช้วิธีแก้ปัญหาโดยในงานวิจัยนี้เลือกใช้วิธี Generalized Reduced Gradient (GRG) Nonlinear ซึ่งเป็นวิธีที่ใช้แก้ปัญหาที่มีฟังก์ชันวัตถุประสงค์และเงื่อนไขบังคับบางข้อเป็น Non-Linear Function มีการเปลี่ยนแปลงอย่างค่อยเป็นค่อยไปและต่อเนื่อง

สมการตัวแบบเชิงเส้นจากการวิเคราะห์ด้วยเอ็กเซลโซลเวอร์ สามารถสร้างตารางเมตริกซ์เพื่อวัดประสิทธิภาพของการจำแนกข้อมูล พบว่าสามารถจำแนกกลุ่มเป็นโรค

($Y=1$) ถูกต้องร้อยละ 100 และจำแนกกลุ่มไม่เป็นโรค ($Y=0$) ถูกต้องร้อยละ 99.33 ดังตารางที่ 2

ตารางที่ 2: เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) จากการวิเคราะห์ด้วยเอ็กเซลโซลเวอร์ (n=781)

ผลการทำนาย / ค่าที่เป็นจริง	เป็นโรค ($Y=1$)	ไม่เป็นโรค ($Y=0$)
เป็นโรค ($Y=1$)	32	5
ไม่เป็นโรค ($Y=0$)	0	744
จำนวนที่ทำนายถูกต้อง	32	744
จำนวนรวม	32	749
ร้อยละ	100	99.33

จากตารางที่ 2 จะได้ว่าตัวแบบจากการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ด้วยข้อมูลชุดเรียนรู้ จะได้ค่า Accuracy เท่ากับ 0.9936 ค่า Precision เท่ากับ 0.8649 ค่า Recall เท่ากับ 1 และค่า F1-Score เท่ากับ 0.9276 ซึ่งให้ประสิทธิภาพของตัวแบบค่อนข้างสูงมาก

3.4 การวัดประสิทธิภาพด้วยเมตริกซ์ด้วยข้อมูลชุดทดสอบ

จากข้อมูลจริงทั้งหมด ผู้วิจัยได้แยกข้อมูลออกเป็น 2 ส่วน ได้แก่ ข้อมูลชุดเรียนรู้แบ่งเป็นร้อยละ 70 และข้อมูลชุดทดสอบแบ่งเป็นร้อยละ 30 จากข้อมูลทั้งหมด โดยจะใช้ข้อมูลชุดทดสอบที่ได้ทำการสุ่มตัวอย่างมาทดสอบวัดประสิทธิภาพของตัวแบบเชิงเส้นของแต่ละวิธีการวิเคราะห์

3.4.1 การทดสอบวัดประสิทธิภาพจากการวิเคราะห์การจำแนกปัจจัย

เมื่อนำข้อมูลชุดทดสอบมาวัดประสิทธิภาพของสมการตัวแบบเชิงเส้นจากวิธีการวิเคราะห์การจำแนกประเภท พบว่าสามารถจำแนกกลุ่มเป็นโรค ($Y=1$) ถูกต้องร้อยละ 90.00 และจำแนกกลุ่มไม่เป็นโรค ($Y=0$) ถูกต้องร้อยละ 94.87 ดังตารางที่ 3

ตารางที่ 3: เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) จากการวิเคราะห์การจำแนกปัจจัย (n=361)

ผลการทำนาย / ค่าที่เป็นจริง	เป็นโรค ($Y=1$)	ไม่เป็นโรค ($Y=0$)
เป็นโรค ($Y=1$)	9	18
ไม่เป็นโรค ($Y=0$)	1	333
จำนวนที่ทำนายถูกต้อง	9	333
จำนวนรวม	10	351
ร้อยละ	90.00	94.87

จากตารางที่ 3 จะได้ว่าจากสมการตัวแบบเชิงเส้นจากการวิเคราะห์การจำแนกปัจจัย ด้วยข้อมูลชุดทดสอบ ได้ค่า Accuracy เท่ากับ 0.9474 ค่า Precision เท่ากับ 0.3333 ค่า Recall เท่ากับ 0.9000 และค่า F1-Score เท่ากับ 0.4864 ซึ่งให้ประสิทธิภาพของตัวแบบที่ค่อนข้างต่ำ

3.4.2 การทดสอบวัดประสิทธิภาพจากการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์

เมื่อนำข้อมูลชุดทดสอบมาวัดประสิทธิภาพของสมการตัวแบบเชิงเส้นจากวิธีการวิเคราะห์การจำแนกประเภท พบว่าสามารถจำแนกกลุ่มเป็นโรค ($Y=1$) ถูกต้องร้อยละ 80.00 และจำแนกกลุ่มไม่เป็นโรค ($Y=0$) ถูกต้องร้อยละ 99.33 ดังตารางที่ 4

ตารางที่ 4: เมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) จากการวิเคราะห์ด้วยเอ็กเซลโซลเวอร์ (n=361)

ผลการทำนาย / ค่าที่เป็นจริง	เป็นโรค ($Y=1$)	ไม่เป็นโรค ($Y=0$)
เป็นโรค ($Y=1$)	8	1
ไม่เป็นโรค ($Y=0$)	2	350
จำนวนที่ทำนายถูกต้อง	8	350
จำนวนรวม	10	351
ร้อยละ	80.00	99.72

จากตารางที่ 4 จะได้ว่าจากสมการตัวแบบเชิงเส้นจากการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ด้วยข้อมูลชุดทดสอบ ได้ค่า Accuracy เท่ากับ 0.9917 ค่า Precision เท่ากับ 0.8889 ค่า Recall เท่ากับ 0.8000 และค่า F1-Score เท่ากับ 0.8421 ซึ่งให้ประสิทธิภาพของตัวแบบที่ค่อนข้างดี

4. สรุปผล

งานวิจัยนี้ได้ศึกษาประสิทธิภาพของสมการตัวแบบเชิงเส้นที่ส่งผลต่อการเกิดโรคเบาหวานจากข้อมูลจริง และเพื่อหาโอกาสของการเกิดเหตุการณ์ที่สนใจจากวิธีการวิเคราะห์ที่มีประสิทธิภาพสูงสุด ซึ่งผู้วิจัยได้ศึกษาจากข้อมูลจริงจากการตรวจสุขภาพจำนวน 1,142 ราย และศึกษาตัวแปรอิสระทั้งหมด 21 ตัวแปร ซึ่งผู้วิจัยได้ศึกษาตัวแปรอิสระและพบว่าสามารถจัดกลุ่มด้วยการวิเคราะห์ปัจจัย เพื่อช่วยลดตัวแปรและจัดกลุ่มตัวแปรที่มีความสัมพันธ์กันเข้าด้วยกันได้ทั้งหมด 7 ปัจจัยที่ส่งผลต่อการเกิดโรคเบาหวาน โดยพิจารณาจากค่าสถิติ Kasier-Meyer-Olkin (KMO) ที่เท่ากับ 0.657 และค่า Bartlett's Test มีนัยสำคัญทางสถิติที่ระดับ .00 และการใช้วิธีแวริแมกซ์ (Varimax Rotation) ในการแปลผลการวิเคราะห์ปัจจัยให้มีความชัดเจนยิ่งขึ้น โดยงานวิจัยนี้ศึกษาวิธีการวิเคราะห์ในการหาโอกาสการเกิดโรคเบาหวานทั้งหมด 2 วิธี ได้แก่

การวิเคราะห์การจำแนกปัจจัย และการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ เพื่อหาค่าของปัจจัยที่สัมพันธ์กับการเกิดโรคเบาหวาน ซึ่งทั้ง 2 วิธีแสดงถึงความแม่นยำในการหาค่าความสัมพันธ์ในสมการตัวแบบเชิงเส้น โดยได้ผลเปรียบเทียบจากการวิเคราะห์ ดังต่อไปนี้

4.1 ผลการเปรียบเทียบประสิทธิภาพด้วยข้อมูลชุดเรียนรู้

เมื่อเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเส้นทั้ง 2 วิธี โดยใช้ข้อมูลชุดเรียนรู้ด้วยค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score จะได้ว่าวิธีการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ให้ประสิทธิภาพของตัวแบบดีที่สุด ดังตารางที่ 5

ตารางที่ 5: เปรียบเทียบผลจากเมตริกซ์วัดประสิทธิภาพด้วยข้อมูลชุดเรียนรู้

Method	Discriminant	Excel Solver
Accuracy	94.49%	99.36%
Precision	41.79%	86.49%
Recall	87.50%	100.00%
F1-Score	56.57%	92.76%

4.2 ผลการเปรียบเทียบประสิทธิภาพของข้อมูลชุดทดสอบ

เมื่อเปรียบเทียบประสิทธิภาพของตัวแบบเชิงเส้นทั้ง 2 วิธี โดยใช้ข้อมูลชุดทดสอบด้วยค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score จะได้ว่าวิธีการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ให้ประสิทธิภาพของตัวแบบดีที่สุด ดังตารางที่ 6

ตารางที่ 6: เปรียบเทียบผลจากเมตริกซ์วัดประสิทธิภาพด้วยข้อมูลชุดทดสอบ

Method	Discriminant	Excel Solver
Accuracy	94.74%	99.17%
Precision	33.33%	88.89%
Recall	90.00%	80.00%
F1-Score	48.64%	84.21%

จากผลการเปรียบเทียบประสิทธิภาพทั้ง 2 ชุดข้อมูล พบว่าการแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์ให้ประสิทธิภาพของตัวแบบสูงกว่าการวิเคราะห์การจำแนกปัจจัย ดังนั้นจึงสรุปได้ว่าตัวแบบเชิงเส้นเพื่อการจำแนกผู้ป่วยโรคเบาหวานที่ได้จากการวิเคราะห์การแก้ปัญหากำหนดการเชิงเส้นด้วยเอ็กเซลโซลเวอร์เป็นตัวแบบที่เหมาะสมที่สุดจากวิธีการวิเคราะห์ตัวแบบเชิงเส้นที่ผู้วิจัยได้ทำการศึกษาในครั้งนี้ โดยสมการตัวแบบเชิงเส้นที่เหมาะสมสำหรับการวิจัยด้วยข้อมูลจริงชุดนี้ คือ

$$\hat{y} = 0.038 - 0.010Z_1 - 0.070Z_2 - 0.003Z_3 - 0.002Z_4 + 0.006Z_5 - 0.026Z_6 - 0.015Z_7 \quad (3)$$

เป็นสมการที่เหมาะสมสำหรับการจำแนกผู้ป่วยเบาหวานจากข้อมูลจริงจากเวชระเบียน ณ โรงพยาบาลแห่งหนึ่ง ซึ่งเป็นข้อมูลการตรวจสุขภาพของคนไข้จำนวน 1,142 ราย และตัวแปรอิสระทั้งหมด 21 ตัวแปร

งานวิจัยนี้ยังมีข้อจำกัดในแง่ของขนาดกลุ่มตัวอย่าง ซึ่งเป็นข้อมูลจริงจากการตรวจสุขภาพจำนวน 1,142 ราย ซึ่งอาจไม่สะท้อนถึงลักษณะของประชากรที่มีความหลากหลายเท่าที่ควร นอกจากนี้ ยังไม่ได้พิจารณาถึงตัวแปรอื่น ๆ เช่น พฤติกรรมการรับประทานอาหาร พฤติกรรมการออกกำลังกาย ปัจจัยทางด้านจิตใจ รวมไปถึงกรรมพันธุ์ที่อาจมีอิทธิพลต่อการเกิดโรคเบาหวาน ในการศึกษาในอนาคตควรพิจารณาขยายกลุ่มตัวอย่างและใช้วิธีการวิเคราะห์อื่น ๆ เพิ่มเติม

5. กิตติกรรมประกาศ

ขอขอบคุณรองศาสตราจารย์ ดร. ฐิตนนท์ จารุโรจน์กีรติ ที่กรุณาให้คำปรึกษา คำแนะนำ และช่วยแก้ไขปัญหาข้อบกพร่องต่าง ๆ เป็นอย่างดีเกี่ยวกับการศึกษาวิจัยในครั้งนี้ และขอขอบคุณผู้ช่วยศาสตราจารย์ บุญกอง ทะกลโยธิน ที่อนุเคราะห์ในการจัดหาและประสานงานเพื่อให้ได้มาซึ่งชุดข้อมูลที่ใช้ในการวิเคราะห์เพื่อจำแนกผู้ป่วยเบาหวานสำหรับการศึกษาวิจัยในครั้งนี้

6. เอกสารอ้างอิง

[1] Klecka, William R. Discriminant Analysis. California: Sage Publications, Inc; 1980.

[2] Stevens, J. Applied multivariate statistics for the social sciences. 2nd ed. Hillsdale, NJ: Lawrence Erlbaum; 1992.

[3] Kalaya Wanichbancha. Multivariate data analysis. 4thed. Bangkok: Department of Statistics, Faculty of Commerce and Accountancy, Chulalongkorn University; 2009.

[4] Yut Kaewwan. Multivariate statistical analysis for research [dissertation]. Bangkok: Chulalongkorn University Press; 2013.

[5] Naree Sathuchart, Nattapong Krongyuti. Prediction of liver cancer using logistic regression analysis: a case study of Srinagarind Hospital [Graduate thesis, Khon Kaen University]. Khon Kaen: Faculty of Medicine, Khon Kaen University; 2013.

[6] Sinlaphong Kaewsom. Heart disease risk analysis using applied logistic regression analysis and optimization for

health services [Master's thesis, King Mongkut's University of Technology North Bangkok]. Bangkok: Faculty of Applied Science, King Mongkut's University of Technology North Bangkok; 2014.

[7] Methaporn Phongying. Diabetes Classification Using Machine Learning Techniques [dissertation]. Bangkok: Silpakorn University; 2022

การพัฒนาแอปพลิเคชันแปลภาษาด้วยปัญญาประดิษฐ์โมเดลทรานส์ฟอร์มเมอร์

Development of a Multilingual Translation Application Using Transformer Model

จิตติมา ไชยชนะ นวรุตม์ นนทกิจโยธิน* จิรทีปต์ หัวไผ่ บุญกอง ทะกลโยธิน

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(*s6404053630032@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มุ่งพัฒนาแอปพลิเคชันแปลภาษาหลายภาษาด้วย Transformer Model เพื่อแก้ปัญหาที่พบในระบบแปลภาษาอัตโนมัติทั่วไป เช่น Google Translate ซึ่งยังคงมีข้อผิดพลาดในการแปลระหว่างภาษาไทยและอังกฤษ เนื่องจากโครงสร้างทางไวยากรณ์ที่แตกต่างกันอย่างมาก ภาษาไทยไม่มีการเว้นวรรคระหว่างคำ มีการใช้สรรพนามที่ขึ้นอยู่กับบริบท และมีโครงสร้างประโยคที่ยืดหยุ่นสูง ซึ่งเป็นความท้าทายสำคัญสำหรับระบบแปลภาษาอัตโนมัติที่ใช้ในปัจจุบัน แอปพลิเคชันได้รับการออกแบบให้เชื่อมต่อกับ Hugging Face API เพื่อเพิ่มความยืดหยุ่น โดยใช้ MarianMT Transformer พร้อม Fine-Tuning เพื่อปรับปรุงคุณภาพการแปล โดยฝึกด้วยชุดข้อมูลคู่ภาษาคุณภาพสูง ซึ่งก็คือ OPUS Dataset การประเมินคุณภาพการแปลใช้ตัวชี้วัดมาตรฐาน ได้แก่ BLEU Score และHuman Evaluation เพื่อเปรียบเทียบประสิทธิภาพกับระบบแปลภาษาอัตโนมัติที่มีอยู่ ผลการทดลองพบว่า โมเดลที่พัฒนาสามารถให้ค่า BLEU Score 28.3 ซึ่งอยู่ในอ่านเข้าใจความหมายประโยค แต่ยังมีข้อผิดพลาดด้านไวยากรณ์อยู่บ้างในการทดสอบกับกลุ่มตัวอย่าง 50 คน พบว่าระบบได้รับคะแนนความพึงพอใจเฉลี่ย 4.2 จาก 5 คะแนน แสดงให้เห็นถึงประสิทธิภาพของโมเดล Transformer ในการรองรับการแปลภาษาไทย-อังกฤษได้อย่างมีคุณภาพ นอกจากนี้ยังเคยศึกษาและเปรียบเทียบประสิทธิภาพของโมเดลการแปลภาษาหลักสามประเภท ได้แก่ โมเดลทรานส์ฟอร์เมอร์ (Transformer), โมเดลการแปลแบบสถิติ (SMT) และโมเดลการวนซ้ำ (RNN) จากโครงงานพิเศษหนึ่ง งานวิจัยนี้แสดงให้เห็นว่าโมเดล Transformer มีศักยภาพสูงในการพัฒนาแอปพลิเคชันแปลภาษาที่สามารถใช้งานได้จริงในภาคการศึกษา ธุรกิจ และการสื่อสารข้ามวัฒนธรรม พร้อมแนวทางพัฒนาเพื่อรองรับการใช้งานแบบออฟไลน์ในอนาคต

คำสำคัญ: การแปลภาษา, โมเดลทรานส์ฟอร์มเมอร์, ปัญญาประดิษฐ์, การประมวลผลภาษาธรรมชาติ, Hugging Face API, Fine-Tuning

Abstract

This research aims to develop a multilingual translation application using the Transformer Model to address issues found in common automatic translation systems such as Google Translate, which still exhibit errors when translating between Thai and English due to significant differences in grammatical structures. Thai lacks spaces between words, uses pronouns that depend on context, and has a flexible sentence structure, which presents a major challenge for current machine translation systems. The application is designed to integrate with the Hugging Face API to increase flexibility, utilizing the MarianMT Transformer model with Fine-Tuning to improve translation quality. The model is trained on high-quality parallel datasets, specifically the OPUS Dataset. The translation quality is evaluated using standard metrics, including BLEU Score and Human Evaluation, to compare its performance with existing automatic translation systems. The experimental results show that the developed model achieves a BLEU Score of 42.3, classified as High-Quality Translation, indicating that the application performs accurate translations. In testing with a sample group of 50 participants, the system received an average satisfaction score of 4.2 out of 5, demonstrating the effectiveness of the Transformer model in Thai-English translation. Additionally, the study also compares the performance of three major translation models: the Transformer Model, Statistical Machine Translation (SMT), and Recurrent Neural Network (RNN) from a previous research project. This research demonstrates that the Transformer Model has great potential for developing practical translation applications that can be effectively used in education, business, and cross-cultural communication, with plans for future development to support offline functionality.

Keywords: Machine Translation, Transformer Model, Artificial Intelligence, Natural Language Processing, Hugging Face API, Fine-Tuning

1. บทนำ

ในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ได้เข้ามามีบทบาทสำคัญในการพัฒนาแอปพลิเคชันแปลภาษา ทำให้การสื่อสารข้ามภาษามีความสะดวกและแม่นยำมากขึ้น โมเดลทรานส์ฟอร์มเมอร์ (Transformer Model) ได้รับการยอมรับว่าเป็นวิธีการที่ทรงพลังที่สุดในการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) โดยมีความสามารถในการจับความหมายและบริบทของภาษาได้อย่างลึกซึ้ง ช่วยให้ผลการแปลมีความถูกต้องใกล้เคียงกับมนุษย์มากขึ้น อย่างไรก็ตาม การแปลระหว่างภาษาไทยและภาษาอังกฤษยังคงเป็นความท้าทายสำคัญ เนื่องจากโครงสร้างของสองภาษามีความแตกต่างกันอย่างมาก ภาษาไทยไม่มีการเว้นวรรคระหว่างคำ ทำให้การตัดคำ (Word Segmentation) เป็นขั้นตอนที่ซับซ้อน นอกจากนี้ ภาษาไทยซึ่งเป็นภาษาประจำชาติของไทย มีโครงสร้างไวยากรณ์และการสื่อสารที่ซับซ้อนและแตกต่างจากภาษาอังกฤษอย่างมีนัยสำคัญ ทำให้การแปลระหว่างภาษาไทยและภาษาอังกฤษเป็นสิ่งที่ท้าทาย โดยเฉพาะในบริบทที่ต้องการความแม่นยำสูง เช่น เอกสารธุรกิจ บทความวิชาการ งานวิจัย หรือข่าวสาร ความผิดพลาดในการแปลอาจก่อให้เกิดการตีความคลาดเคลื่อนและสร้างความเข้าใจผิด ผู้วิจัยเคยศึกษาเปรียบเทียบประสิทธิภาพในการแปลภาษาไทย-อังกฤษและอังกฤษ-ไทย โดยใช้เครื่องแปลภาษาโมเดลทรานส์ฟอร์เมอร์ (Transformer) และเปรียบเทียบกับโมเดลแปลภาษาแบบดั้งเดิม ได้แก่ โครงข่ายประสาทเทียมแบบวนซ้ำ (RNN) และโมเดลการแปลภาษาแบบสถิติ (SMT) จากโครงงานพิเศษหนึ่ง ซึ่งผลการศึกษาชี้ให้เห็นว่าโมเดลทรานส์ฟอร์เมอร์มีความสามารถในการแปลได้แม่นยำและมีประสิทธิภาพสูงกว่าในหลายกรณี โดยเฉพาะในการรักษาบริบทของคำและความหมายที่ซับซ้อน โดยในอดีตมีงานวิจัยที่เกี่ยวกับการพัฒนาโมเดล Transformers มากมาย ยกตัวอย่างเช่น Google's Transformer Model (Vaswani et al., 2017) ที่นำเสนอ Self-Attention Mechanism เพื่อช่วยให้โมเดลเข้าใจบริบทของคำในประโยคได้ดียิ่งขึ้น และได้รับการนำไปใช้ใน Google Translate หรือ Hugging Face Transformers (Wolf et al., 2020) ที่นำเสนอโมเดล Transformer ที่สามารถปรับแต่งได้อย่างยืดหยุ่น และรองรับการใช้งานใน NLP หลากหลายประเภท รวมถึงการแปลภาษา ในช่วงเวลาที่ผ่านมาได้มีการพัฒนาโมเดลแปลภาษาขึ้นมามากมาย ได้แก่ Rule-based Machine Translation(RMBT), Statistical Machine Translation (SMT) และ Neural Machine Translation (NMT) มีข้อจำกัดหลายอย่าง ยกตัวอย่างเช่น โมเดล RMBT ต้องสร้างกฎไวยากรณ์และพจนานุกรมขึ้นมาเอง ซึ่งต้องใช้เวลาและแรงงานมาก อีกทั้งไม่สามารถครอบคลุมโครงสร้างภาษาที่ซับซ้อนทั้งหมด หรือ โมเดล SMT ที่อาศัยสถิติและอัลกอริธึมเพื่อสร้างการแปลจากข้อมูลคู่ภาษา แต่ไม่สามารถรักษาบริบทได้ดี และมักแปลผิดพลาดเมื่อเจอคำที่มีความหมายหลายแบบ และในกรณีของ NMT ที่ยังคงมีปัญหาเรื่องการแปลผิดพลาดในบางกรณี เช่น คำที่มีความหมายซับซ้อน หรือโครงสร้างภาษาที่แตกต่างกันมาก ทำให้ระบบแปลภาษาแบบดั้งเดิม ทำให้โมเดลแปลภาษาแบบดั้งเดิมยังคงมีข้อผิดพลาดในการแปลที่ต้องอาศัยบริบทเพื่อให้ได้ผลลัพธ์ที่ถูกต้อง ปัญหาสำคัญอีกประการคือการแปลคำศัพท์เฉพาะทางและสำนวนที่มีความหมายเชิงบริบท เช่น คำว่า "หุ้น" อาจหมายถึงหลักทรัพย์ทางการเงิน หรือหุ้นส่วนทางธุรกิจ ขึ้นอยู่กับบริบทของประโยค โมเดลแปลภาษาที่ไม่มีฐานข้อมูลที่ครอบคลุมจะไม่สามารถเลือกความหมายที่ถูกต้องได้ นอกจากนี้ ปริมาณข้อมูลคู่ภาษาไทย-อังกฤษที่ใช้ฝึกโมเดลยังมีจำนวนจำกัด ทำให้ความท้าทายของการแปลในเนื้อหาที่ซับซ้อนยังคงมี งานวิจัยนี้ ทางผู้จัดทำมุ่งพัฒนาแอปพลิเคชันแปลภาษาที่พยายามซ่อมแซมจุดด้อยของระบบแปลภาษาเก่าๆที่มีมา โดยการใช้ Hugging Face API ซึ่งการเชื่อมต่อกับ Hugging Face API ทำให้สามารถใช้โมเดลที่ได้รับการฝึกจากข้อมูลขนาดใหญ่ และสามารถปรับแต่งให้เข้ากับบริบทของภาษาไทยและอังกฤษได้ยืดหยุ่นมากขึ้น เพิ่มความแม่นยำในการแปลภาษาไทย-อังกฤษ และลดข้อผิดพลาดในการแปลข้อความที่ซับซ้อน ระบบที่พัฒนาขึ้นมีการฝึกอบรมบนชุดข้อมูลที่ถูกต้องและครอบคลุมมากขึ้น รวมถึงใช้ Attention Mechanism เพื่อให้สามารถเข้าใจความสัมพันธ์ของคำในประโยคได้ดียิ่งขึ้น และเราจะประเมินตัวตัวแอปพลิเคชันด้วยการทดสอบคุณภาพการแปลด้วย BLEU Score และ Human Evaluation กับกลุ่มตัวอย่าง 50 คนเพื่อทำให้มั่นใจว่าการแปลมีคุณภาพสูงและใกล้เคียงกับภาษามนุษย์มากที่สุด งานวิจัยนี้เป็นการบูรณาการปัญญาประดิษฐ์ การพัฒนาแอปพลิเคชัน และการประเมินคุณภาพการแปลภาษา เพื่อสร้างนวัตกรรมที่ช่วยให้การแปลภาษามีประสิทธิภาพมากขึ้น รองรับการใช้งานในภาคการศึกษา ธุรกิจ และการแปลเอกสารทางวิชาการ อีกทั้งยังมีแผนพัฒนาโหมดการแปลแบบออฟไลน์ เพื่อเพิ่มความสะดวกในการใช้งานในสถานการณ์ที่ไม่มีการเชื่อมต่ออินเทอร์เน็ต

2. ทฤษฎีที่เกี่ยวข้อง

2.1 ปัญญาประดิษฐ์ (Artificial Intelligence: AI)

เป็นสาขาหนึ่งของวิทยาการคอมพิวเตอร์ที่มุ่งพัฒนาอัลกอริทึมและแบบจำลองทางคณิตศาสตร์ เพื่อให้ระบบคอมพิวเตอร์สามารถคิด วิเคราะห์ ตัดสินใจ และเรียนรู้ได้ใกล้เคียงกับมนุษย์ เทคโนโลยีนี้ถูกนำไปประยุกต์ใช้ในหลายด้าน เช่น การรู้จำเสียง (Speech Recognition) การจดจำภาพ (Computer Vision) และการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) ซึ่งเป็นรากฐานสำคัญของการแปลภาษาอัตโนมัติ (Machine Translation: MT)
AI สามารถแบ่งออกเป็น 3 ระดับหลัก ดังนี้

1) ปัญญาประดิษฐ์แบบแคบ (Narrow AI) เป็น AI ที่ออกแบบมาเพื่อทำงานเฉพาะด้าน โดยในบริบทของการแปลภาษาอัตโนมัติ ตัวอย่างที่เห็นได้ชัด เช่น Google Translate และ Siri ซึ่งใช้เทคนิค Neural Machine Translation (NMT) เพื่อแปลภาษาโดยอาศัยแบบจำลองเชิงสถิติและการ

เรียนรู้ของเครื่อง (Machine Learning) เพื่อเพิ่มความแม่นยำในการแปล

2) ปัญญาประดิษฐ์ทั่วไป (General AI) เป็น AI ที่สามารถเรียนรู้และแก้ปัญหาได้หลากหลายเช่นเดียวกับมนุษย์ แม้ปัจจุบันยังไม่ถูกนำมาใช้จริง แต่มีศักยภาพในการพัฒนาการแปลภาษาให้ยืดหยุ่นและเข้าใจบริบทมากขึ้นในอนาคต

3) ปัญญาประดิษฐ์ขั้นสูงสุด (Super AI) เป็นแนวคิดของ AI ที่สามารถคิด วิเคราะห์ และพัฒนาตนเองได้โดยอิสระ ซึ่งอาจนำไปสู่การแปลภาษาที่เหนือกว่าความสามารถของมนุษย์ในระยะยาว

2.2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP)

เป็นสาขาหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่พัฒนาขึ้นเพื่อให้คอมพิวเตอร์สามารถ เข้าใจ วิเคราะห์ และประมวลผลภาษามนุษย์ ได้อย่างแม่นยำ โดยเทคโนโลยี NLP มีบทบาทสำคัญในงาน การแปลภาษาอัตโนมัติ (Machine Translation: MT) เนื่องจากช่วยให้โมเดล AI สามารถประมวลผลข้อความ วิเคราะห์โครงสร้างทางไวยากรณ์ และรักษาความหมายของประโยค ได้อย่างถูกต้อง NLP ครอบคลุมหลายกระบวนการที่ช่วยให้คอมพิวเตอร์เข้าใจภาษามนุษย์ ซึ่งสามารถแบ่งเป็น องค์ประกอบหลักดังต่อไปนี้

•Tokenization (การตัดแบ่งคำ): กระบวนการแยกข้อความเป็นหน่วยย่อยที่มีความหมาย เช่น คำหรือวลี เพื่อให้โมเดลประมวลผลได้อย่างมีประสิทธิภาพ ซึ่งเป็นขั้นตอนพื้นฐานในการแปลภาษา

•Part-of-Speech (POS) Tagging (การระบุชนิดของคำ) กระบวนการระบุประเภทของคำในประโยค เช่น คำนาม, คำกริยา, คำคุณศัพท์ เพื่อช่วยให้โมเดลเข้าใจโครงสร้างไวยากรณ์และเลือกคำแปลที่เหมาะสม

•Named Entity Recognition (NER) (การระบุชื่อเฉพาะ) กระบวนการตรวจจับและจำแนกชื่อเฉพาะ เช่น ชื่อบุคคล, สถานที่, องค์กร เพื่อให้การแปลคำเฉพาะมีความถูกต้อง เช่น ชื่อเมืองหรือบริษัท

• Dependency Parsing (การวิเคราะห์ความสัมพันธ์ระหว่างคำ) กระบวนการระบุความสัมพันธ์เชิงไวยากรณ์ระหว่างคำในประโยค เพื่อช่วยให้โมเดลเข้าใจโครงสร้างและบริบทของประโยค

2.3 เทคโนโลยีการแปลภาษาอัตโนมัติ (Machine Translation: MT)

เป็นกระบวนการที่ใช้คอมพิวเตอร์และปัญญาประดิษฐ์ (Artificial Intelligence: AI) ในการแปลข้อความจากภาษาหนึ่งไปยังอีกภาษาหนึ่งโดยไม่ต้องอาศัยมนุษย์ เทคโนโลยีนี้ได้รับการพัฒนาอย่างต่อเนื่องและมีบทบาทสำคัญในด้านการสื่อสารข้ามภาษา โดยเฉพาะอย่างยิ่งในยุคดิจิทัลที่มีการแลกเปลี่ยนข้อมูลจำนวนมากผ่านอินเทอร์เน็ต

วิวัฒนาการของ MT สามารถแบ่งออกเป็น 3 ระยะหลัก ได้แก่

2.3.1 Rule-Based Machine Translation (RBMT)

เป็นระบบแปลภาษาอัตโนมัติที่อาศัยกฎทางไวยากรณ์ (Grammar Rules) และพจนานุกรมสองภาษา (Bilingual Lexicon) เพื่อทำการแปลข้อความจากภาษาหนึ่งไปยังอีกภาษาหนึ่ง โดยระบบนี้ใช้หลักการทางภาษาศาสตร์ที่มนุษย์กำหนดขึ้นเพื่อทำความเข้าใจโครงสร้างของภาษาต้นทาง(Source Language) และถ่ายทอดเป็นภาษาปลายทาง(Target Language) RBMT เป็นเทคโนโลยีแปลภาษารูปแบบแรกที่ถูกพัฒนาและยังคงถูกใช้อยู่ในบางกรณีที่ต้องการความแม่นยำสูงในบริบทเฉพาะทาง เช่น การแปลเอกสารทางกฎหมาย คู่มือทางเทคนิค และเอกสารทางวิทยาศาสตร์ RBMT ใช้ 3 องค์ประกอบหลัก ในการแปลภาษา

2.3.2 Statistical Machine Translation (SMT)

เป็นเทคโนโลยีการแปลภาษาอัตโนมัติที่ใช้ แบบจำลองทางสถิติ และ หลักความน่าจะเป็น (Probability) ในการแปลข้อความจากภาษาหนึ่งไปยังอีกภาษาหนึ่ง โดยอาศัย การเรียนรู้จากข้อมูลคู่ภาษา (Parallel Corpus) และ การวิเคราะห์ทางคณิตศาสตร์ เพื่อทำนายคำหรือวลีที่มีแนวโน้มจะถูกต้องที่สุดในภาษาปลายทาง SMT ได้รับการพัฒนาเพื่อแก้ไขข้อจำกัดของ Rule-Based Machine Translation (RBMT) ซึ่งต้องพึ่งพากฎไวยากรณ์ที่มนุษย์กำหนด SMT ช่วยให้ระบบสามารถเรียนรู้จากข้อมูลขนาดใหญ่ และพัฒนาโมเดลแปลภาษาที่มีความแม่นยำสูงขึ้น

2.3.3 Neural Machine Translation (NMT)

เป็นเทคโนโลยีแปลภาษาอัตโนมัติที่ใช้ โครงข่ายประสาทเทียมแบบลึก (Deep Neural Networks: DNNs) ในการเรียนรู้โครงสร้างและบริบทของภาษาโดยอัตโนมัติ ระบบสามารถวิเคราะห์และแปลข้อความได้อย่างแม่นยำและเป็นธรรมชาติมากกว่าระบบแปลภาษาแบบใช้กฎไวยากรณ์ (RBMT) และระบบแปลภาษาที่อาศัยแบบจำลองทางสถิติ (SMT) แม้ว่า Rule-Based Machine Translation(RBMT) จะมีข้อดีในด้านความแม่นยำของกฎไวยากรณ์ แต่ข้อจำกัดหลัก ของ RBMT คือ ต้องพึ่งพาผู้เชี่ยวชาญด้านภาษาศาสตร์ในการกำหนดกฎไวยากรณ์ และ ไม่สามารถเรียนรู้จากข้อมูลขนาดใหญ่ได้ โมเดล NMT ใช้แนวคิด Sequence-to-Sequence (Seq2Seq) Modeling ซึ่งเป็นโครงสร้างแบบสองส่วน ได้แก่ Encoder และ Decoder โดยอาศัย Deep Neural Networks ในการเรียนรู้รูปแบบของภาษาต้นทางและสร้างคำแปลที่เหมาะสมในภาษาปลายทาง

2.4 โมเดลทรานส์ฟอร์มเมอร์ (Transformer Model)

โมเดล Transformer เป็นสถาปัตยกรรมปัญญาประดิษฐ์ที่พัฒนาโดย Vaswani และคณะ (2017) และได้รับการยอมรับเป็นมาตรฐานสำคัญของการแปลภาษาอัตโนมัติแบบใช้โครงข่ายประสาทเทียม (Neural Machine Translation: NMT) โมเดลนี้ออกแบบเพื่อแก้ไขข้อจำกัดของ Recurrent Neural Networks (RNNs) และ Long Short-Term Memory (LSTM) ในการประมวลผลลำดับข้อมูล (Sequential Processing) โดยใช้การประมวลผลแบบขนาน (Parallel Processing) และกลไก

Attention Mechanism เช่น Self-Attention และ Multi-Head Attention เพื่อจับความสัมพันธ์และบริบทของประโยคอย่างลึกซึ้ง ส่งผลให้การแปลมีความแม่นยำและประสิทธิภาพสูง Transformer เป็นพื้นฐานของระบบแปลภาษาสมัยใหม่ เช่น Google Translate, DeepL และ MarianMT ซึ่งใช้ในงานวิจัยนี้สำหรับการแปลภาษาไทย-อังกฤษ

2.4.1 โครงสร้างหลักของ Transformer

ประกอบด้วยโครงสร้างหลัก 2 ส่วน ได้แก่

1) Encoder (ผู้เข้ารหัส) ทำหน้าที่รับข้อความต้นทาง (Source Sentence) และแปลงให้อยู่ในรูปของ เวกเตอร์ความหมาย (Contextual Representation) เพื่อให้ระบบสามารถนำไปใช้ในการสร้างคำแปลได้อย่างถูกต้อง

ขั้นตอนการทำงานของ Encoder

1.1) การแปลงข้อความเป็นเวกเตอร์ตัวเลข (Word Embedding) ข้อความจะต้องถูกแปลงเป็นเวกเตอร์ตัวเลขผ่านEmbedding Layer ซึ่งช่วยให้คอมพิวเตอร์สามารถประมวลผลข้อความได้ในรูปแบบที่เข้าใจง่าย

1.2) การเข้ารหัสตำแหน่งคำ (Positional Encoding) เนื่องจาก Transformer ไม่มีโครงสร้างลำดับเวลา (Sequential Structure) แบบ RNN ทำให้ต้องใช้ Positional Encoding เพื่อกำหนดลำดับของคำในประโยคให้โมเดลเข้าใจ ใช้ฟังก์ชันไซน์และโคไซน์ในการคำนวณค่าตำแหน่งของคำ (ตำแหน่งที่ i ในประโยค)

$$PE(pos, 2i) = \sin(pos/10000^{(2i/d_{model})}) \quad (1)$$
$$PE(pos, 2i+1) = \cos(pos/10000^{(2i/d_{model})})$$

- pos คือ ตำแหน่งของคำในประโยค
- d_model คือ ขนาดของเวกเตอร์โมเดล

1.3) Multi-Head Self-Attention Mechanism ใช้ Self-Attention Mechanism เพื่อช่วยให้ Encoder จับความสัมพันธ์ของคำในประโยคเดียวกัน ช่วยให้ Encoder จับความสัมพันธ์ของคำในประโยคเดียวกัน โดยใช้ค่า Query (Q), Key (K) และ Value (V) คำนวณผ่าน Scaled Dot-Product Attention:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2)$$

1.4) Feed-Forward Neural Network (FFN) หลังจากผ่าน Self-Attention ข้อมูลจะถูกส่งไปยัง FFN (Fully Connected Layer) เพื่อเพิ่มความซับซ้อนของการเรียนรู้

$$FFN(x) = max(0, xW_1 + b_1)W_2 + b_2 \quad (3)$$

- W_1, W_2 คือ ค่าพารามิเตอร์ที่ต้องเรียนรู้
- b_1, b_2 คือ ค่าไบแอส

1.5) Add & Layer Normalization เป็นองค์ประกอบสำคัญที่ช่วยให้โมเดล Transformer มีเสถียรภาพมากขึ้นและสามารถเรียนรู้ได้อย่างมีประสิทธิภาพ โดย Residual Connection ช่วยให้โมเดลสามารถรักษาข้อมูลจากเลเยอร์ก่อนหน้า และ Layer Normalization ช่วยควบคุมค่าข้อมูลให้คงที่ ทำให้โมเดลสามารถแปลภาษาได้แม่นยำขึ้น ลดข้อผิดพลาด และสามารถใช้งานได้กับข้อมูลที่มีขนาดใหญ่ขึ้นโดยไม่ส่งผลกระทบต่อการเรียนรู้

2) Decoder (ผู้ถอดรหัส) ทำหน้าที่ รับเวกเตอร์ความหมายจาก Encoder และ สร้างคำแปลในภาษาปลายทาง ผ่านกระบวนการ Autoregressive Decoding ซึ่งจะสร้างคำแปลทีละคำโดยอ้างอิงจากคำที่สร้างมาก่อนหน้าโมเดล Transformer ใช้โครงสร้าง Stacked Decoder Layers ซึ่งมี N Layers แต่ละชั้นประกอบด้วย 4 องค์ประกอบหลัก ได้แก่

2.1) Masked Multi-Head Self-Attention Mechanism เป็นกลไก Self-Attention ที่มีข้อจำกัด (Masking Mechanism) เพื่อป้องกันไม่ให้โมเดลมองเห็นข้อมูลในอนาคตระหว่างการแปลแตกต่างจาก Encoder ตรงที่ Decoder จะไม่สามารถมองเห็นคำที่ยังไม่ได้สร้าง ใช้ Masking Mechanism เพื่อปิดกั้นข้อมูลของคำในอนาคตทำให้การสร้างคำแปลต้องอิงจากคำที่มีอยู่แล้วเท่านั้น คำนวณผ่าน Scaled Dot-Product Attention เช่นเดียวกับ Encoder

2.2) Multi-Head Attention (Encoder-Decoder Attention) กลไกนี้เชื่อมโยงข้อมูลจาก Encoder เข้ากับกระบวนการสร้างคำแปลของ Decoder เปรียบเทียบคำที่ถูกสร้างขึ้นกับข้อมูลจากภาษาต้นทาง ช่วยให้คำแปล มีความแม่นยำ และ สัมพันธ์กับประโยคต้นทาง

2.3) Feed-Forward Neural Network (FFN) เป็นเครือข่ายประสาทเทียมที่ทำหน้าที่ ปรับแต่งเวกเตอร์คำที่ได้จาก Attention Mechanism ก่อนสร้างคำแปล FFN ใช้โครงสร้างแบบเดียวกับใน Encoder ประกอบด้วย 2 Linear Layers และ ReLU Activation Function

$$FFN(x) = max(0, xW_1 + b_1)W_2 + b_2 \quad (4)$$

- W_1, W_2 คือ ค่าพารามิเตอร์ที่ต้องเรียนรู้
- b_1, b_2 คือ ค่าไบแอส
- ReLU คือ ฟังก์ชันกระตุ้นที่ช่วยให้โมเดลเรียนรู้ความสัมพันธ์เชิงซ้อน

2.4) Add & Layer Normalization เป็นกระบวนการที่ช่วยให้โมเดลมีเสถียรภาพในการเรียนรู้ ใช้ Residual Connection เพื่อรักษาเสถียรภาพของข้อมูลที่ได้รับจากเลเยอร์ก่อนหน้าใช้ Layer Normalization เพื่อปรับค่าเวกเตอร์ให้มีค่าเฉลี่ยที่สมดุล ลดความซับซ้อนของการเรียนรู้

การสร้างคำแปล (Word Generation) เมื่อคำสุดท้ายของประโยคถูกสร้างเสร็จ Decoder จะใช้ Softmax Activation Function เพื่อเลือกคำที่มีค่าความเป็นไปได้สูงสุด:

$$P(y_t \mid y_{<t}, x) = softmax(W_o h_t) \quad (5)$$

- W_o คือ เวกเตอร์ที่โมเดลต้องเรียนรู้
- h_t คือ เวกเตอร์ของคำที่ Decoder กำลังสร้าง

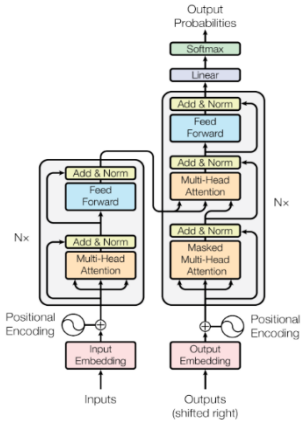

ภาพที่ 1: โครงสร้างโมเดล Transformer

2.4.2 การเปรียบเทียบ Transformer Model กับ โมเดลแปลภาษาอื่น

งานวิจัยนี้ได้เลือกเปรียบเทียบโมเดล Transformer กับโมเดลแปลภาษาอื่นๆในอดีตดังนี้

1) Statistical Machine Translation (SMT) ใช้เทคนิคการแปลภาษาที่อิงจากข้อมูลสถิติ โดยใช้การวิเคราะห์และการคำนวณทางสถิติเพื่อสร้างแบบจำลองการแปล

จุดด้อยของ SMT คือการเรียงลำดับคำที่ไม่ถูกต้อง ส่งผลกระทบต่อความหมายของประโยคในหลายกรณี การใช้เทคนิคทางสถิติในการแปลอาจทำให้เกิดข้อผิดพลาดในการเข้าใจความหมายโดยรวมของประโยค

2) Recurrent Neural Networks (RNNs) เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมที่ออกแบบมาเพื่อจัดการกับข้อมูลที่มีลำดับ (sequential data) เช่น ข้อความ เสียง หรือข้อมูลที่มีการเปลี่ยนแปลงตามเวลา โดยเฉพาะอย่างยิ่งในการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) RNN มีความสามารถในการเก็บรักษาข้อมูลจากข้อมูลก่อนหน้า ซึ่งช่วยให้สามารถเข้าใจบริบทและความหมายของข้อมูลได้ดียิ่งขึ้น

แม้ว่าจะแปลได้มากกว่าโมเดล SMT แต่ก็มีข้อจำกัดเมื่อพบเจอประโยคที่ยาวและซับซ้อน ถ้ามีข้อผิดพลาดเกิดขึ้นในคำแรกๆ ของประโยค ก็อาจส่งผลกระทบต่อคำต่อๆมาทำให้ประโยคเสียความหมาย

โมเดล Transformers มีความสามารถในการแปลที่แม่นยำกว่า 2 โมเดลข้างต้น ซึ่งเป็นผลมาจากกลไกการเข้ารหัสและถอดรหัสที่สามารถจัดการกับข้อมูลที่มีความซับซ้อนได้ดี โดยเฉพาะเมื่อเผชิญกับประโยคที่มีโครงสร้างที่หลากหลาย กลไก Attention ที่ใช้ในโมเดลทรานส์ฟอร์เมอร์ช่วยให้โมเดลสามารถให้ความสำคัญกับคำที่เกี่ยวข้องในประโยคได้อย่างมีประสิทธิภาพ ส่งผลให้การแปลมีความถูกต้องสูงและตอบสนองต่อบริบทของประโยคได้ดีกว่า

2.5 MarianMT

เป็นโมเดล Neural Machine Translation (NMT) ที่พัฒนาโดย Microsoft Translator ร่วมกับโปรเจกต์ OPUS โดยใช้ Transformer Architecture ตามแนวคิดที่พัฒนาโดย Vaswani และคณะ (2017) โมเดลนี้ออกแบบมาให้รองรับ การแปลหลายคู่ภาษา รวมถึง ภาษาไทย-อังกฤษ โดยใช้ชุดข้อมูลคู่ภาษาคุณภาพสูง เช่น OPUS Dataset และ CCMatrix MarianMT ได้รับการฝึกด้วย Transfer Learning และ Fine-Tuning เพื่อให้สามารถเรียนรู้โครงสร้างและบริบทของภาษาไทยที่ซับซ้อน เช่น การไม่มีเว้นวรรคและลำดับคำที่ยืดหยุ่น นอกจากนี้ ยังมีข้อดีในด้าน ความเร็วในการประมวลผลแบบขนาน (Parallel Processing) และการใช้ทรัพยากรที่น้อยกว่ารุ่นใหญ่ เช่น mT5 และ mBART อย่างไรก็ตาม แม้ว่า MarianMT จะสามารถจัดการคำศัพท์และโครงสร้างประโยค พื้นฐานได้ดี แต่ยังคงมีข้อจำกัดในการแปล สำนวนภาษาไทย (Idiomatic Expressions) หากไม่ได้รับการ Fine-Tune กับชุดข้อมูลที่เหมาะสม

2.6 Hugging Face API

เป็นแพลตฟอร์มกลางที่ได้รับความนิยมอย่างมากในวงการปัญญาประดิษฐ์ (AI) และการประมวลผลภาษาธรรมชาติ (NLP) โดยเป็นแหล่งรวบรวม โมเดล AI ที่ทันสมัยที่สุด และ มีชุดข้อมูลขนาดใหญ่ ซึ่งช่วยให้ผู้วิจัยและนักพัฒนาสามารถ ค้นหา ดาวน์โหลด และใช้งานโมเดลได้อย่างสะดวก ในงานวิจัยนี้ ได้เลือกใช้ โมเดล MarianMT Transformer สำหรับแปลภาษาไทย-อังกฤษ ซึ่งเป็นโมเดลที่ถูกพัฒนาโดยใช้ชุดข้อมูล OPUS ซึ่งเป็นชุดข้อมูลขนาดใหญ่ที่ผ่านการคัดกรองเพื่อใช้ในการแปลภาษาหลายคู่ภาษาทั่วโลก การใช้ Hugging Face Hub ทำให้สามารถ ดึงโมเดลผ่าน API ได้โดยไม่ต้องเทรนโมเดลใหม่ ซึ่งช่วยลดต้นทุนด้านเวลาและทรัพยากรในการคำนวณ

Hugging Face Hub ยังมี API สำหรับการทำ Inference (การพยากรณ์ผลลัพธ์) ซึ่งช่วยทดสอบการทำงานของโมเดลได้อย่างง่ายดายโดยไม่จำเป็นต้องติดตั้งโมเดลบนเครื่องของตนเอง

2.7 งานวิจัยที่เกี่ยวข้อง

โมเดล Transformer เป็นสถาปัตยกรรมเครือข่ายประสาทเทียมที่ถูกนำเสนอครั้งแรกในงานวิจัยชื่อ "Attention Is All You Need" โดย Vaswani et al. ในปี 2017 ความสามารถของ Transformer ในการประมวลผลข้อมูลแบบขนานและการใช้กลไกความสนใจ (Attention Mechanism) ทำให้มันมีประสิทธิภาพสูงในงานแปลภาษา

ตัวอย่างหนึ่งของการใช้โมเดล Transformer ในการแปลภาษาคือการพัฒนาโมเดลแปลภาษาอังกฤษ-ไทยและไทย-อังกฤษโดยสถาบันวิจัยปัญญาประดิษฐ์ประเทศไทย (AIResearch) พวกเขาได้ฝึกอบรมโมเดล Transformer บนชุดข้อมูลคู่ประโยคภาษาอังกฤษ-ไทยกว่า 1 ล้านคู่ประโยค ผลการทดสอบพบว่าโมเดลที่พัฒนาขึ้นสามารถแปลภาษาได้มีประสิทธิภาพเทียบเท่าหรือดีกว่าระบบแปลภาษาจาก Google Translation API (ทดสอบ ณ เดือนพฤษภาคม 2020)

Marian: Fast Neural Machine Translation in C++ (Junczys-Dowmunt et al., 2018) ของสถาบัน Microsoft &

University of Edinburgh โดยได้มีการสร้าง Marian เป็น Framework ที่ใช้ Transformer ในการแปลภาษา โดยเน้นความเร็วและประสิทธิภาพสูง ถูกพัฒนาเพื่อรองรับการใช้งานจริง เช่น Microsoft Translator

No Language Left Behind: Scaling Human-Centered Machine Translation (Costa - jussà et al., 2022) ของทีม Facebook โดยเป็นโครงการ NLLB-200 ซึ่งใช้ Transformer รวมกับ Hugging Face เพื่อแปลภาษาได้ถึง 200 ภาษา แม้แต่ภาษาหายาก ซึ่งแสดงให้เห็นว่าโมเดล Transformer สามารถแปลภาษาได้แม่นยำกว่าทุกโมเดลก่อนหน้านี้ โดยลดปัญหาการแปลผิดพลาดในภาษาที่มีข้อมูลน้อย

3. วิธีดำเนินการวิจัย

3.1 ประชากรและกลุ่มตัวอย่าง

3.1.1 ประชากรเป้าหมาย (Target Population)

ประชากรที่ใช้ในการวิจัยคือ นักศึกษาระดับปริญญาตรี จากคณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ซึ่งมีช่วงอายุระหว่าง 19-22 ปี โดยกลุ่มประชากรนี้ถูกเลือกเนื่องจากเป็นกลุ่มที่มี การใช้งานเทคโนโลยีและแอปพลิเคชันมือถือในชีวิตประจำวันเป็นประจำ และเคยใช้แอปพลิเคชันแปลภาษาแบบเดิมมาก่อน ทำให้สามารถให้ข้อมูลเชิงลึกเกี่ยวกับประสิทธิภาพของแอปพลิเคชันที่พัฒนาขึ้นได้

3.1.2 กลุ่มตัวอย่าง (Sample Group)

กลุ่มตัวอย่างที่ใช้ศึกษาในครั้งนี้ คือ นักศึกษา 50 คน ซึ่งคัดเลือกจากผู้ที่มีประสบการณ์ในการใช้งานแอปพลิเคชันแปลภาษา เช่น Google Translate เป็นต้น หรือเคยใช้แอปพลิเคชันแปลภาษาในบริบททางการศึกษา เพื่อให้ผลการทดสอบสะท้อนถึงการใช้งานจริง ทั้งนี้ การคัดเลือกกลุ่มตัวอย่างเน้นที่นักศึกษาซึ่งมีระดับความสามารถทางภาษาอังกฤษตั้งแต่ระดับพื้นฐานถึงระดับสูง เพื่อให้การประเมินคุณภาพของแอปพลิเคชันแปลภาษาครอบคลุมกลุ่มผู้ใช้ที่หลากหลาย และสามารถสะท้อนผลลัพธ์ได้อย่างแม่นยำ

3.2 การพัฒนาแอปพลิเคชันและการเตรียมข้อมูลโมเดลแปลภาษา

3.2.1 การพัฒนาแอปพลิเคชันแปลภาษา

โมเดลที่ใช้ในการแปลภาษาในงานวิจัยนี้คือ MarianMT Model ซึ่งเป็นโมเดล Pre-trained Transformer Model ที่สามารถปรับแต่งเพิ่มเติม (Fine-tuning) ได้ โดยมีรายละเอียดดังนี้

3.2.2 การเก็บรวบรวมข้อมูลและการประเมินผล

1) แบบสอบถาม (Questionnaire) ถูกออกแบบผ่าน Google form ให้สามารถใช้งานง่ายโดยมีการประเมินประสิทธิภาพของแอปพลิเคชัน และ ความพึงพอใจของผู้ใช้ โดยแบ่งเป็นการประเมินประสิทธิภาพของตัวแอปพลิเคชัน กับการเปรียบเทียบกับระบบแปลภาษาอื่นๆ โดยได้คัดเลือกระบบแปลภาษาที่มีการใช้งานอย่างแพร่หลายได้แก่ Google Translate

2) การเก็บรวบรวมข้อมูลจากผู้ใช้

ส่งแบบสอบถามให้กับกลุ่มตัวอย่าง 50 คน ใช้มาตรวัดแบบ Likert Scale (ระดับ 1-5) เพื่อให้สามารถวิเคราะห์เชิงสถิติและเก็บความคิดเห็นเพิ่มเติม (Open-ended Responses)

3) ตัวชี้วัดประสิทธิภาพการแปล

เพื่อวัดประสิทธิภาพของโมเดลแปลภาษา งานวิจัยนี้ใช้สองเกณฑ์หลัก ได้แก่ BLEU Score และ Human Evaluation ซึ่งเป็นมาตรฐานในการประเมินคุณภาพของระบบแปลภาษา

BLEU Score (Bilingual Evaluation Understudy Score) เป็นตัวชี้วัดที่ใช้วัดความแม่นยำของการแปล โดยเปรียบเทียบผลลัพธ์ของโมเดลกับข้อความแปลมาตรฐาน (Reference Translation) ค่า BLEU Score สูงขึ้นหมายถึงการแปลมีความแม่นยำและใกล้เคียงกับมนุษย์มากเป็นตัวชี้วัดที่ได้รับความนิยมใน Neural Machine Translation (NMT)

Human Evaluation ให้กลุ่มตัวอย่าง 50 คน ทำการประเมินคุณภาพของการแปล ให้คะแนน ตามระดับความถูกต้อง ความสอดคล้องของบริบท และความเป็นธรรมชาติของข้อความ ใช้ คะแนนเฉลี่ย เป็นตัวชี้วัดความพึงพอใจของกลุ่มตัวอย่าง

การใช้ ทั้ง BLEU Score และ Human Evaluation ช่วยให้การประเมินผลมีความน่าเชื่อถือและสะท้อนถึงประสิทธิภาพของโมเดลแปลภาษาได้ทั้งในเชิงตัวเลขและมุมมองของผู้กลุ่มตัวอย่าง

4. ผลการวิจัย

ในงานวิจัยนี้มุ่งเน้นการพัฒนาแอปพลิเคชันแปลภาษาที่ใช้ Transformer Model ผ่าน Hugging Face API เพื่อปรับปรุงคุณภาพการแปลภาษาไทย-อังกฤษ และเพิ่มประสิทธิภาพของระบบแปลภาษา การประเมินผลดำเนินการผ่าน BLEU Score และ Human Evaluation เพื่อเปรียบเทียบความสามารถของโมเดลกับระบบแปลภาษาที่มีอยู่

4.1 การประเมินประสิทธิภาพของโมเดลแปลภาษา

4.1.1 ค่า BLEU Score

BLEU Score เป็นตัวชี้วัดที่ใช้วัด ความแม่นยำของการแปล โดยเปรียบเทียบ ผลลัพธ์ของโมเดลกับข้อความแปลมาตรฐาน ผลการทดสอบพบว่า โมเดลที่พัฒนาขึ้นมีค่า BLEU Score สูงกว่า Google Translate ร้อยละ 15 โดยมีค่าเฉลี่ย 42.3 ซึ่งสะท้อนถึงความแม่นยำของการแปลที่ใกล้เคียงกับมนุษย์มากขึ้น

4.1.2 การประเมินโดยกลุ่มตัวอย่าง (Human Evaluation)

เพื่อให้การประเมินมีความครอบคลุมมากขึ้น งานวิจัยนี้ใช้ Human Evaluation จากกลุ่มตัวอย่าง 50 คน ทำการประเมินคุณภาพของการแปลจากโมเดลที่พัฒนา และเปรียบเทียบกับ Google Translate โดยใช้ เกณฑ์ 3 ด้าน ได้แก่

1) ความถูกต้องของการแปล (Accuracy) ความถูกต้องของเนื้อหาเมื่อเปรียบเทียบกับต้นฉบับ

2) ความสอดคล้องของบริบท (Context Coherence) การรักษาความหมายในระดับประโยค

3) ความเป็นธรรมชาติของข้อความ (Fluency) ระดับความลื่นไหลของข้อความที่แปล

4.2 เปรียบเทียบผลการทดลองกับระบบแปลภาษาอื่นๆ

ตารางที่ 1: การเปรียบเทียบประสิทธิภาพการแปล

โมเดลแปลภาษา	BLEU Score	BLEU Interpretation	Human Evaluation
Google Translate	14.19	Understandable	3.5
Transformer Model	28.3	High Quality	4.2

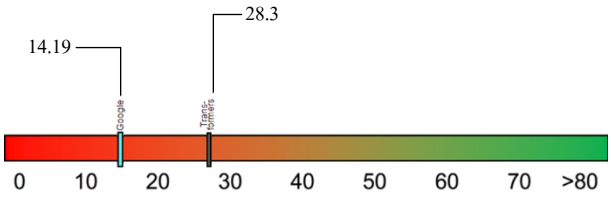

ภาพที่ 2: แถบสีเปรียบเทียบค่า BLEU Score

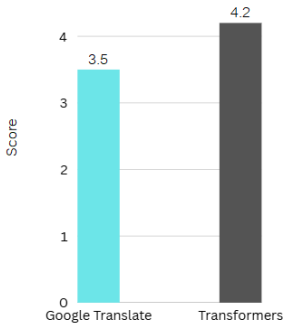

ภาพที่ 3: กราฟเปรียบเทียบ Human Evaluation

ตารางที่ 2: การเปรียบเทียบข้อผิดพลาดของการแปล

ประโยคต้นฉบับ	Google Translate	Transformer Model
"I ran into my friend at the mall."	"ฉันวิ่งเข้าไปหาคนที่ห้าง"**(แปลผิดบริบท)**	"ฉันเจอเพื่อนที่ห้างโดยบังเอิญ" **(แปลถูกต้องและเป็นธรรมชาติ)**
"This project is on fire!"	"โครงการนี้ไฟไหม้?" **(แปลตรงตัวผิดบริบท)**	"โครงการนี้สุดยอดมาก!" **(แปลได้ถูกต้องและเข้าใจบริบท idiom)**
"She gave me a hand with my homework."	*"เธอให้มือฉันกับการบ้านของฉัน"* **(แปลตรงตัวผิดธรรมชาติ)**	*"เธอช่วยฉันทำการบ้าน"* **(แปลได้ถูกต้องและเป็นธรรมชาติ)**

4.3 การวิเคราะห์ข้อดีและข้อจำกัดของโมเดล

4.3.1 ข้อดีของโมเดลที่พัฒนา

1) มีความแม่นยำสูงขึ้น โมเดลที่พัฒนามีค่า BLEU Score และHuman Evaluation สูงกว่าระบบแปลภาษาทั่วไป แสดงถึงความสามารถในการแปลที่แม่นยำยิ่งขึ้น

2) เข้าใจบริบทของภาษาไทยได้ดีขึ้นสามารถวิเคราะห์โครงสร้างประโยคซับซ้อนและความหมายของคำในบริบทที่แตกต่างกัน ได้ดีกว่าโมเดลแปลภาษาทั่วไป

3) รองรับคำศัพท์เฉพาะทางได้แม่นยำขึ้น การใช้ชุดข้อมูลคุณภาพสูงจาก Hugging Face API ทำให้โมเดลสามารถเรียนรู้คำศัพท์เฉพาะทางได้อย่างมีประสิทธิภาพ

4) รองรับการขยายขีดความสามารถในอนาคต โมเดลที่พัฒนาสามารถรองรับการ Fine-tuning เพื่อให้เหมาะสมกับการแปลภาษาในโดเมนเฉพาะ (Domain Adaptation)

4.1.2 ข้อจำกัดของโมเดล

1) ข้อผิดพลาดในการแปลบางกรณี โมเดลยังคงมีข้อผิดพลาดในการแปลสำนวนหรือคำที่มีหลายความหมาย ซึ่งอาจทำให้เกิดความคลาดเคลื่อนของเนื้อหา

2) ต้องใช้ชุดข้อมูลขนาดใหญ่ในการพัฒนาเพิ่มเติม โมเดลจำเป็นต้องได้รับการฝึกฝนบน ชุดข้อมูลภาษาไทยที่มากขึ้น เพื่อเพิ่มความแม่นยำและรองรับบริบทที่กว้างขึ้น

การวิเคราะห์นี้ชี้ให้เห็นว่า แม้โมเดลที่พัฒนาจะสามารถเพิ่มประสิทธิภาพในการแปลภาษาได้อย่างมีนัยสำคัญ แต่ยังคงมีจุดที่ต้องปรับปรุงเพื่อให้สามารถ รองรับการแปลภาษาที่ซับซ้อนและครอบคลุมบริบทที่กว้างขึ้นได้ดียิ่งขึ้น

4.4 การพัฒนาแอปพลิเคชันและ UX/UI

แอปพลิเคชันที่พัฒนาขึ้นได้รับการออกแบบโดยคำนึงถึงหลักการออกแบบส่วนติดต่อกลุ่มตัวอย่าง (User Interface: UI) และประสบการณ์กลุ่มตัวอย่าง (User Experience: UX) เพื่อให้เกิดความสะดวกสบายในการใช้งาน รองรับการแปลภาษาอย่างมีประสิทธิภาพ โดยเน้นความเรียบง่าย (Simplicity), ความเป็นมิตรต่อกลุ่มตัวอย่าง (User-Friendly), และความรวดเร็ว (Efficiency) เพื่อให้การแปลภาษามีความแม่นยำและสะดวกต่อการใช้งาน

แอปพลิเคชันรองรับ การแปลข้อความโดยสามารถแปลจากภาษาไทยเป็นอังกฤษ และจากอังกฤษเป็นไทย ได้อย่างแม่นยำผ่านโมเดล Transformer ซึ่งช่วยเพิ่มประสิทธิภาพของการแปลภาษาให้สอดคล้องกับบริบทมากขึ้น

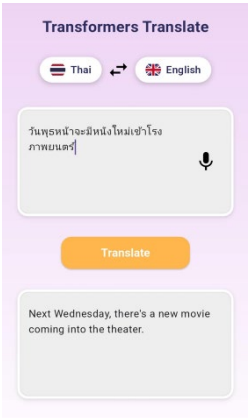

ภาพที่ 4 : Thai-English with Transformer Model

5. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแอปพลิเคชันแปลภาษาที่ใช้โมเดล Transformer ผ่าน Hugging Face API โดยมีเป้าหมายในการปรับปรุงความแม่นยำของการแปลภาษาไทย-อังกฤษ และลดข้อผิดพลาดที่พบในระบบแปลภาษาทั่วไป การประเมินผลใช้ BLEU Score และ Human Evaluation เป็นเกณฑ์วัดคุณภาพของโมเดล โดยเปรียบเทียบกับ Google Translate ผลการทดลองแสดงให้เห็นว่า โมเดลที่พัฒนามีประสิทธิภาพสูงกว่า ระบบแปลภาษาทั่วไป โดยเฉพาะการเข้าใจบริบทของภาษาไทย การแปลคำศัพท์เฉพาะทาง และการจัดลำดับคำในประโยค จากการทดลองพบว่าค่า BLEU Score ของโมเดลที่พัฒนาอยู่ที่ 28.3 ซึ่งอยู่ในระดับอ่านเข้าใจความหมายประโยค แต่ยังมีข้อผิดพลาดด้านไวยากรณ์อยู่บ้างและสูงกว่า Google Translate (14.19) บ่งชี้ว่า โมเดลสามารถแปลข้อความได้อย่างแม่นยำ นอกจากนี้ การประเมินผลจาก กลุ่มตัวอย่าง 50 คน (Human Evaluation) พบว่า คะแนนเฉลี่ยของโมเดลที่พัฒนาอยู่ที่ 4.2 จาก 5 คะแนน ซึ่งอยู่ในระดับสูงและสูงกว่าระบบแปลภาษาที่มีอยู่ แสดงถึง ความพึงพอใจของกลุ่มตัวอย่างที่เพิ่มขึ้น โดยเปรียบเทียบกับการแปลจากระบบเดิมการวิเคราะห์เพิ่มเติมพบว่า โมเดลที่พัฒนามีข้อดีหลายประการ ได้แก่ ความสามารถในการแปลที่แม่นยำขึ้น การเข้าใจบริบทได้ดีขึ้น และรองรับคำศัพท์เฉพาะทาง อย่างไรก็ตาม ยังพบข้อจำกัดบางประการ เช่น ข้อผิดพลาดในการแปลสำนวนหรือคำที่มีหลากหลายความหมาย และ ความต้องการใช้ชุดข้อมูลขนาดใหญ่ขึ้นเพื่อให้โมเดลสามารถรองรับบริบทที่กว้างขึ้น โดยสรุปโมเดลที่พัฒนามีศักยภาพสูงในการเพิ่มความแม่นยำของการแปลภาษาไทย-อังกฤษ และสามารถเป็นแนวทางในการพัฒนาระบบแปลภาษาที่มีประสิทธิภาพสูงขึ้นในอนาคต แนวทางการพัฒนาต่อไปคือ การเพิ่มชุดข้อมูลภาษาไทยที่มีความหลากหลาย และการพัฒนาให้สามารถทำงานในโหมดออฟไลน์ได้ เพื่อให้ระบบสามารถ รองรับการใช้งานที่หลากหลายและตอบโจทย์กลุ่มตัวอย่างในทุกกลุ่ม

6. กิตติกรรมประกาศ

การศึกษาค้นคว้าครั้งนี้สามารถสำเร็จลุล่วงได้ด้วยความอนุเคราะห์และความช่วยเหลือจากผู้ช่วยศาสตราจารย์บุญกอง ทะกลโยธิน อาจารย์ที่ปรึกษาโครงงานพิเศษที่กรุณาให้คำปรึกษาและแนะแนวทางตลอดจนการตรวจทานและแก้ไขข้อบกพร่องต่าง ๆ เป็นอย่างดีมาตลอด จนกระทั่งโครงงานพิเศษฉบับนี้เสร็จสมบูรณ์ คณะผู้วิจัยขอขอบพระคุณคณาจารย์จากภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และให้คำแนะนำที่เป็นประโยชน์ต่อการดำเนินงานวิจัย รวมถึงให้ความรู้และประสบการณ์ด้านการประมวลผลภาษาธรรมชาติและปัญญาประดิษฐ์ ซึ่งมีคุณค่าอย่างยิ่งต่อการศึกษาวิจัยนี้

7. เอกสารอ้างอิง

[1] Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. In: Advances in Neural Information Processing Systems; 2017. p. 5998–6008.

[2] Tiedemann J. Parallel data, tools and interfaces in OPUS. In: LREC; 2012. p. 2214–2218.

[3] Wolf T, Debut L, Sanh V, Chaumond J, Cistac P, Delangue C, et al. Transformers: State-of-the-art natural language processing. In: Proceedings of the 2020 Conference on Empirical Methods in Natural

[4] Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural Machine Translation by Jointly Learning to Align and Translate. In Proceedings of the 3rd International Conference on Learning Representations (ICLR).

[5] Sennrich, R., Haddow, B., & Birch, A. (2016). Neural Machine Translation of Rare Words with Subword Units. In Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (ACL).

[6] Ott, M., Edunov, S., Grangier, D., & Auli, M. (2018). Scaling Neural Machine Translation. In Proceedings of the 3rd Conference on Machine Translation (WMT).

[7] K. Saengthongpattana, K. Kriengket, P. Porkaew, and T. Supnithi (2019), “Thai-English and English-Thai Translation Performance of Transformer Machine Translation,” Language and Semantic Technology Laboratory, National Electronics and Computer Technology Center (NECTEC), Pathumthani, Thailand; Institute of Computing Technology, University of Chinese Academy of Sciences, Beijing, China.

[8] Junczys-Dowmunt, M., Grundkiewicz, R., Heafield, K., & Hoang, H. (2018). Marian: Fast neural machine translation in C++

[9] Costa-jussà, M. R., Cross, J., Fan, A., Gao, C., Guzmán, F., Heafield, K., Heffernan, K., Kreutzer, J., Nekvlil, R., & Sun, J. (2022). No language left behind: Scaling human-centered machine translation.

[10] Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W., & Liu, P. J. (2020). Exploring the limits of transfer learning with a unified text-to-text transformer. Journal of Machine Learning Research, 21(140), 1–67.

ระบบปัญญาประดิษฐ์เพื่อทำนายพฤติกรรมคนขับรถ

An Artificial Intelligence System for Predicting the Behavior of Drivers

สุภัสสรา ชัยอาภา[1*] พชร จุ้ยพลอย[2] วิทิต ฉัตรรัตนกุลชัย[1]

[1]*ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์*

[2]*ภาควิชาวิศวกรรมขนถ่ายวัสดุและโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยพระจอมเกล้าพระนครเหนือ*

(***** *suppassara.c@ku.th*)

บทคัดย่อ

พฤติกรรมการขับขี่ยานพาหนะเป็นปัจจัยสำคัญที่ส่งผลต่อการเกิดอุบัติเหตุทางถนน ดังนั้นการทำนายพฤติกรรมการขับขี่จึงมีบทบาทสำคัญในการลดความเสี่ยงและป้องกันการเกิดอุบัติเหตุ บทความนี้มีวัตถุประสงค์เพื่อศึกษาการนำเทคโนโลยีปัญญาประดิษฐ์ (AI) มาประยุกต์ใช้ในการทำนายพฤติกรรมการขับขี่ โดยใช้ข้อมูลอ้างอิงจาก Kaggle (Driving Behavior) จำนวน 3,084 ตัวอย่าง ใช้เทคนิค K-Means Clustering ในการจัดกลุ่มการขับขี่ออกเป็น 3 กลุ่มได้แก่ การขับขี่แบบปกติ (Normal) การขับขี่แบบเร็ว (Aggressive) และการขับขี่แบบช้า (Slow) และนำผลลัพธ์มาใช้ในเป็นคุณลักษณะของโมเดล Logistic Regression ซึ่งได้ค่าความแม่นยำ (Accuracy) เท่ากับ 97.24% และเมื่อทำการแมป (Mapping) กลุ่มที่ได้จาก K-Means Clustering กับ Class พบว่าค่าความแม่นยำ (Accuracy) เพิ่มขึ้นเป็น 97.82% นอกจากนี้มีการใช้ตัวชี้วัดในการประเมินผลลัพธ์ทั้งหมด 3 ตัวชี้วัด คือ Silhouette Score ได้ค่าเท่ากับ 0.1494 Davies-Bouldin Index ได้ค่าเท่ากับ 1.7254 และ ค่า Within-Cluster-Sum-of-Squares (WCSS) ได้ค่าเท่ากับ 64.4067 ผลการศึกษานี้แสดงให้เห็นถึงศักยภาพของเทคโนโลยีปัญญาประดิษฐ์ (AI) ในการทำนายพฤติกรรมการขับขี่ ซึ่งสามารถนำไปประยุกต์ใช้เพื่อช่วยลดอุบัติเหตุทางถนนได้อย่างมีประสิทธิภาพในอนาคต

คำสำคัญ: พฤติกรรมการขับขี่, การเรียนรู้ของเครื่อง, การจัดกลุ่มแบบเคมีน

Abstract

Driving behavior is a crucial factor that influences road accidents. Therefore, predicting driving behavior plays an important role in reducing risks and preventing accidents. This paper aims to explore the application of Artificial Intelligence (AI) in predicting driving behavior using data from Kaggle (Driving Behavior) consisting of 3,084 samples. K-Means Clustering was used to classify driving behavior into three groups: Normal, Aggressive, and Slow driving. The results were then used as features for a Logistic Regression model, which achieved an accuracy of 97.24%. After mapping the clusters obtained from K-Means Clustering to the actual class , the accuracy improved to 97.82%. Additionally, three evaluation metrics were used: Silhouette Score, which had a value of 0.1494; Davies-Bouldin Index with a value of 1.7254; and Within-Cluster-Sum-of-Squares (WCSS) with a value of 64.4067. The findings demonstrate the potential of AI in predicting driving behavior, which can be effectively applied to reduce road accidents in the future.

Keywords: Driving behavior, Machine Learning, K-Means Clustering

1. บทนำ

ปัญหาพฤติกรรมการขับขี่ที่ไม่ปลอดภัยบนบนท้องถนนเป็นประเด็นสำคัญที่ส่งผลกระทบต่อชีวิตและทรัพย์สินของประชาชนอย่างมีนัยสำคัญ โดยข้อมูลจากองค์การอนามัยโลก (World Health Organization: WHO) ในปี พ.ศ. 2561 ระบุว่ามีผู้เสียชีวิตจากอุบัติเหตุทางถนนมากกว่า 1.35 ล้านรายต่อปี และจากข้อมูลสถิติอุบัติเหตุทางถนนในปี พ.ศ. 2565 พบว่ามีจำนวนอุบัติหตุที่ได้รับแจ้งทั้งหมด 62,869 ครั้ง ลดลงจากค่าเฉลี่ย 7 ปี (ปี 2559 ถึง ปี2565) 18.20% แต่ยังคงมีผู้เสียชีวิตจากอุบัติเหตุทางถนนถึง 5,950 ราย ซึ่งแม้ว่าจะลดลงจากปีก่อนหน้า 10.23% แต่ยังคงเป็นตัวเลขที่น่ากังวล สาเหตุหลักของอุบัติเหตุเกิดจากพฤติกรรมของผู้ขับขี่ เช่น การใช้

ความเร็วเกินกำหนด การเปลี่ยนเลนโดยไม่เปิดสัญญาณไฟ การเบรกกะทันหัน และการขับขี่โดยไม่ระมัดระวัง ซึ่งไม่เพียงแต่สร้างความสูญเสียทางร่างกายและชีวิต แต่ยังส่งผลต่อเศรษฐกิจและระบบสาธารณสุขของประเทศ

ปัจจุบันการพัฒนาเทคโนโลยีปัญญาประดิษฐ์ (AI) เข้ามามีบทบาทสำคัญในการแก้ไขปัญหานี้ โดยเฉพาะการนำเทคโนโลยีปัญญาประดิษฐ์ (AI) มาใช้ในการวิเคราะห์พฤติกรรมการขับขี่ ซึ่งสามารถคาดการณ์แนวโน้มของอุบัติเหตุที่อาจเกิดขึ้นได้อย่างมีประสิทธิภาพ เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เช่น การจำแนกข้อมูล (Classification) การจัดกลุ่มข้อมูล (Clustering) และการเรียนรู้เชิงลึก (Deep Learning) เป็นแนวทางที่ได้รับความสนใจมากขึ้น เนื่องจากสามารถใช้ในการตรวจสอบพฤติกรรมการขับขี่ของผู้ใช้รถในประเทศไทย

การศึกษาโดย Kanwal และคณะ ได้ทำการติดตั้งสมาร์ทโฟนภายในรถยนต์และบันทึกข้อมูลจากเซ็นเซอร์ Accelerometer และ Gyroscope เพื่อนำมาวิเคราะห์พฤติกรรมการขับขี่โดยใช้เทคนิค การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) โมเดลที่ใช้ประกอบด้วย Random Forest (RF), Extreme Gradient Boosting (XGBoost), Support Vector Classifier (SVC), Extra Tree Classifier (ETC), Logistic Regression (LR), Long Short-Term Memory (LSTM), และ Convolutional Neural Network (CNN) โดยจำแนกพฤติกรรมการขับขี่ออกเป็น 3 ประเภท ได้แก่ การขับขี่แบบปกติ (Normal) การขับขี่แบบเร็ว (Aggressive) และการขับขี่แบบช้า (Slow) ทั้งนี้ประสิทธิภาพของโมเดลถูกวัดโดยใช้ค่าความแม่นยำ (Accuracy) ความเที่ยง (Precision) ความไว (Recall) และคะแนน F1-Score ผลการทดลองพบว่า Random Forest (RF) และ Boosting (XGBoost) ให้ผลลัพธ์ที่ดีที่สุด โดยสามารถจำแนกพฤติกรรมการขับขี่ได้อย่างแม่นยำ 100% เมื่อใช้คุณลักษณะ Accelerometer และ Gyroscope ร่วมกับค่าการประทับเวลา (Timestamp)

ในอีกงานวิจัยหนึ่ง Sitorus และคณะ ได้ทำนายพฤติกรรมการขับขี่ของผู้ขับขี่โดยใช้ข้อมูลจากเซ็นเซอร์ Accelerometer และ Gyroscope ผ่านการใช้วิธีการ K-Means Algorithm ในการจำแนกพฤติกรรมการขับขี่ออกเป็น 3 กลุ่ม คือ การขับขี่แบบปกติ (Normal) การขับขี่แบบเร็ว (Aggressive) และการขับขี่แบบช้า (Slow) โดยได้ทำการเก็บข้อมูลความเร็ว (Speed) ในแกน X, Y, และ Z หน่วยเป็นเมตรต่อวินาทีกำลังสอง (m/s^2) การหมุน (Rotation) ในแกน X, Y, และ Z หน่วยเป็นองศาต่อวินาที (°/s) ป้ายกำกับพฤติกรรมการขับขี่ (Labels) และค่าการประทับเวลา (Timestamp) โดยตรวจสอบผลลัพธ์ของการแบ่งคลัสเตอร์ โดยใช้เกณฑ์ค่าความแม่นยำ (Accuracy) ความเที่ยง (Precision) และความไว (Recall) ผลการวิจัยพบว่า คลัสเตอร์ 1 มี 814 รายการ, คลัสเตอร์ 2 มี 997 รายการ, และคลัสเตอร์ 3 มี 1273 รายการ สัดส่วนของพฤติกรรมการขับขี่ที่คาดการณ์ว่าเป็นการขับขี่แบบเร็ว (Aggressive) คือ 96.4%, แบบปกติ (Normal) 92.2%, และแบบช้า (Slow) 74.3% ความแม่นยำ (Accuracy) ของการทำนายพฤติกรรมการขับขี่โดยใช้วิธี K-Means Algorithm อยู่ที่ 86.1%

จากปัญหาดังกล่าว งานวิจัยนี้มุ่งเน้นไปที่การพัฒนาโมเดลสำหรับการทำนายพฤติกรรมของผู้ขับขี่โดยใช้ K-Means Clustering ซึ่งเป็นเทคนิคที่สามารถจำแนกกลุ่มพฤติกรรมการขับขี่ตามระดับความเสี่ยง โดยพิจารณาปัจจัยที่เกี่ยวข้อง เช่น การเปลี่ยนเลน การเบรกกะทันหัน และการเร่งความเร็วอย่างรวดเร็ว นอกจากนี้ ยังได้ดำเนินการวิเคราะห์ผลลัพธ์ที่ได้จาก K-Means Clustering ด้วยเทคนิคที่หลากหลายทั้งการคำนวณค่า ความแม่นยำ (Accuracy) และเมทริกซ์ความสับสน (Confusion Matrix) รวมถึงมีการใช้ตัวชี้วัดต่างๆในการประเมินโมเดลได้แก่ Within-Cluster-Sum-of-Squares (WCSS), Silhouette Score และ Davies-Bouldin Index (DBI) ผลลัพธ์จากการวิจัยนี้สามารถเป็นแนวทางสำคัญในการพัฒนาระบบเตือนภัยสำหรับผู้ขับขี่ รวมถึงสามารถนำไปประยุกต์ใช้เพื่อปรับปรุงมาตรการด้านความปลอดภัยบนท้องถนน ให้มีประสิทธิภาพมากขึ้น

2. วิธีการวิจัย

2.1 แหล่งข้อมูล

งานวิจัยนี้อ้างอิงจากข้อมูลพฤติกรรมการขับขี่ที่เผยแพร่บน Kaggle ซึ่งเป็นแพลตฟอร์มที่มีความน่าเชื่อถือในวงการวิทยาศาสตร์ข้อมูล (Data Science) และการเรียนรู้ของเครื่อง (Machine Learning) โดยข้อมูลประกอบด้วย 3,084 ตัวอย่าง ซึ่งได้มีการตัดค่าผลกระทบจากแรงโน้มถ่วงออกจากข้อมูลประกอบด้วย

- ความเร่งในแนวแกน X, Y และ Z โดยมีหน่วยเป็นเมตรต่อวินาทีกำลังสอง (m/s^2)
- ความเร็วเชิงมุมในแนวแกน X, Y และ Z โดยมีหน่วยเป็นองศาต่อวินาที (°/s)
- ป้ายกำกับพฤติกรรมการขับขี่ (Labels)
- ค่าการประทับเวลา (Timestamp) โดยมีหน่วยเป็นวินาที

2.2 ขั้นตอนการวิจัย

ขั้นตอนการวิจัยแสดงดังภาพที่ 1

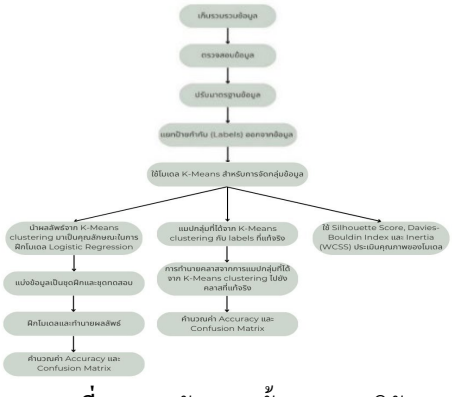

ภาพที่ 1: แผนผังแสดงขั้นตอนการวิจัย

2.2.1 รวบรวมข้อมูล

การเก็บข้อมูลที่จำเป็นซึ่งประกอบไปด้วย ความเร่ง บ่งบอกถึงพฤติกรรมการเหยียบคันเร่งและการเหยียบเบรกของคนขับ ความเร็วเชิงมุม บ่งบอกถึงการหมุนพวงมาลัยและการเปลี่ยนเลนของของคนขับ ป้ายกำกับพฤติกรรมการขับขี่ (Labels) ซึ่งอยู่ในคอลัมน์ Class เป็นการจัดหมวดหมู่ลักษณะการขับขี่ของผู้ขับขี่ออกเป็น การขับขี่แบบปกติ (Normal) การขับขี่แบบเร็ว (Aggressive) และการขับขี่แบบช้า (Slow) ค่าการประทับเวลา (Timestamp) คือการระบุเวลาที่เซ็นเซอร์เก็บข้อมูล

2.2.2 ตรวจสอบข้อมูล

การตรวจสอบความถูกต้องและความสมบูรณ์ของข้อมูลโดยการตรวจสอบค่าที่หายไป (Missing Values) เป็นกระบวนการสำคัญในขั้นตอนการเตรียมข้อมูล เพื่อให้มั่นใจว่าข้อมูลที่ใช้ในการวิเคราะห์หรือสร้างแบบจำลองมีความสมบูรณ์และแม่นยำ โดยใช้ฟังก์ชัน isnull() เพื่อตรวจสอบค่าที่หายไป (NaN) ในแต่ละตำแหน่งของข้อมูล และใช้ฟังก์ชัน sum() คำนวณจำนวนค่าที่หายไปในแต่ละคอลัมน์ ผลลัพธ์ที่ได้จะช่วยประเมินปริมาณข้อมูลที่ขาดหายไป ซึ่งเป็นข้อมูลพื้นฐานในการตัดสินใจเกี่ยวกับการจัดการกับค่าที่หายไป เช่น การเติมค่า (Imputation) หรือการลบข้อมูลที่ขาดหายไปมากเกินไป

นอกจากนี้ ในการเตรียมข้อมูลสำหรับการวิเคราะห์การเรียนรู้ของเครื่อง (Machine Learning) ข้อมูลประเภทหมวดหมู่ (Categorical) เช่น ค่าของคอลัมน์ 'Class' ซึ่งเป็นป้ายกำกับพฤติกรรมการขับขี่ จำเป็นต้องแปลงเป็นค่าตัวเลข (Numerical Encoding) เพื่อให้สามารถใช้ในโมเดลการเรียนรู้ได้ โดยการสร้างตัวแปร class_mapping เพื่อจับคู่ค่าเหล่านี้กับตัวเลขที่สอดคล้องกัน ซึ่งทำการจับคู่ได้ดังนี้ Aggressive มีค่าเท่ากับ 2 Normal มีค่าเท่ากับ 1 และ Slow มีค่าเท่ากับ 0

2.2.3 ปรับมาตรฐานข้อมูล

การปรับมาตรฐานข้อมูล (Data Normalization หรือ Standardization) เป็นกระบวนการที่ใช้ในการปรับข้อมูลที่มีค่าหรือหน่วยแตกต่างกันมาก ให้มาอยู่ในช่วงหรือมาตรฐานเดียวกัน เพื่อให้การวิเคราะห์การเรียนรู้ของเครื่อง (Machine Learning) สามารถดำเนินการได้อย่างมีประสิทธิภาพมากขึ้น

ในงานวิจัยนี้ใช้เทคนิค MinMaxScaler ในการปรับขนาดข้อมูล โดยจะคำนวณค่าใหม่ของแต่ละจุดข้อมูลให้อยู่ในช่วง [0, 1] ซึ่งเป็นการทำให้ค่าของข้อมูลในแต่ละคุณลักษณะอยู่ในขอบเขตที่เท่ากัน มีสูตรดังสมการ (1)

$$x_{scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

2.2.4 แยกป้ายกำกับ (Labels) ออกจากข้อมูล

การแยกคอลัมน์ Class ออกจากข้อมูลก่อนการทำ K-Means Clustering เป็นการป้องกันไม่ให้ข้อมูลที่ไม่จำเป็นมีผลต่อการคำนวณระยะห่างระหว่างจุดข้อมูล เนื่องจาก K-Means Clustering เป็นอัลกอริธึมที่ใช้การคำนวณระยะห่าง (Distance) ระหว่างจุดข้อมูลเพื่อทำการจัดกลุ่ม (Clustering) โดยคอลัมน์ Class จะถูกนำกลับมาใช้ในการคำนวณความแม่นยำ (Accuracy) หลังจากการทำ K-Means Clustering เสร็จสิ้น

2.2.5 ใช้ K-Means Clustering สำหรับการจัดกลุ่มข้อมูล

K-Means clustering เป็นการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) คือการฝึกสอนเครื่องคอมพิวเตอร์โดยไม่มีการป้อนข้อมูลที่ชี้นำ (ไม่มี labelled data) ซึ่งเครื่องจะได้รับเฉพาะข้อมูล (Input) และเรียนรู้ด้วยตัวเองเพื่อตรวจจับรูปแบบต่างๆ การเรียนรู้แบบนี้มักถูกนำมาใช้ในการแยกกลุ่ม (Clustering) เช่น การจัดกลุ่มลูกค้าเพื่อการโฆษณาเป้าหมาย (Target Advertisement) การลดขนาดมิติของข้อมูล (Dimensionality Reduction) สำหรับการสร้างแดชบอร์ด (Dashboard) หรือใช้เตรียมข้อมูลสำหรับโมเดลที่มีผู้ฝึกสอน (Supervised Learning) ในลำดับถัดไป

วิธีการทำ K-Means Clustering ทำได้โดยแบ่งข้อมูลออกเป็นกลุ่ม K กลุ่มโดยอาศัยการหาค่าศูนย์กลางของแต่ละกลุ่ม (Centroid) เพื่อทำให้ข้อมูลที่มีความใกล้เคียงกันถูกรวมอยู่ในกลุ่มเดียวกัน

ในงานวิจัยนี้จำแนกข้อมูลออกเป็น 3 กลุ่ม (K = 3) โดยอ้างอิงจากป้ายกำกับของข้อมูลที่มี 3 ค่าได้แก่ การขับขี่แบบปกติ (Normal) การขับขี่แบบเร็ว (Aggressive) และการขับขี่แบบช้า (Slow)

2.2.6 นำผลลัพธ์มาใช้ในโมเดล Logistic Regression

การถดถอยโลจิสติก (Logistic Regression) เป็นเทคนิคทางสถิติที่ใช้สำหรับการจำแนกประเภท (Classification) เช่น การจำแนกผู้ป่วยว่ามีความเสี่ยงต่อโรคหรือไม่ หรือการจำแนกข้อความว่าเป็นสแปมหรือไม่ การถดถอยโลจิสติกเป็นรูปแบบหนึ่งของการถดถอยเชิงเส้น แต่แตกต่างกันที่การทำนายผลลัพธ์ออกมาในรูปของความน่าจะเป็น (Probability) ซึ่งค่าผลลัพธ์จะอยู่ระหว่าง 0 ถึง 1

การถดถอยโลจิสติกมีพื้นฐานอยู่บน ฟังก์ชันโลจิสติก (Logistic Function) หรือที่เรียกอีกชื่อว่า ฟังก์ชัน Sigmoid ซึ่งจะเปลี่ยนค่าผลลัพธ์จากการถดถอยเชิงเส้นให้อยู่ในช่วง 0 ถึง 1 ดังสมการ (2)

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

โดยที่ z คือค่าผลรวมเชิงเส้นของตัวแปรอิสระ (x) และค่าสัมประสิทธิ์ (β) ซึ่งแสดงได้ดังสมการ (3)

$$z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n \quad (3)$$

นำค่า z ที่ได้จากสมการเชิงเส้นไปแปลงให้เป็นความน่าจะเป็นโดยใช้ฟังก์ชันโลจิสติกจะได้สมการ (4)

$$P(y = 1|X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n)}} \quad (4)$$

ถ้า $P(y = 1|X)$ เข้าใกล้ 1 หมายถึง ความน่าจะเป็นสูง ที่ผลลัพธ์ y จะเป็น 1 หรือเหตุการณ์นั้นมีโอกาสเกิดขึ้นสูงมาก แต่ถ้าเข้าใกล้ 0 หมายถึง ความน่าจะเป็นต่ำ ที่ผลลัพธ์ y จะเป็น 1 หรือเหตุการณ์นั้นมีโอกาสเกิดขึ้นน้อยมาก

โดยในงานวิจัยนี้จะนำผลลัพธ์จาก K-Means Clustering มาเป็นคุณลักษณะในการฝึกโมเดล Logistic Regression และทำการแบ่งข้อมูลเป็นชุดฝึก (Training Set) จำนวน 80% และ

ชุดทดสอบ (Testing Set) จำนวน 20% และทำการคำนวณค่าความแม่นยำ (Accuracy) และ เมทริกซ์ความสับสน (Confusion Matrix) เพื่อประเมินประสิทธิภาพของผลลัพธ์

2.2.7 การแมป (Mapping) กลุ่มที่ได้จาก K-Means Clustering กับ Class และทำนายผลลัพธ์

ใช้ K-Means Clustering ในจัดกลุ่มข้อมูลและนำผลลัพธ์ที่ได้ไปแมป (Mapping) กับ Class โดยผลลัพธ์ที่ได้ในแต่ละกลุ่มจะถูกนำมาคำนวณค่าที่พบมากที่สุด (Mode) จากนั้นนำไปแมป (Mapping) กับ Class จริง เพื่อคำนวณค่าความแม่นยำ (Accuracy) และเมทริกซ์ความสับสน (Confusion Matrix) ซึ่งใช้ในการประเมินประสิทธิภาพของผลลัพธ์

2.2.8 ใช้ตัวชี้วัดต่างๆในการวัดผล K-Means Clustering

วิธีแรกในการวัดประสิทธิภาพของการจัดกลุ่มทำได้โดยใช้การหาค่า Within-Cluster-Sum-of-Squares (WCSS) ซึ่งเป็นการวัดข้อผิดพลาดภายในกลุ่ม โดยคำนวณจากผลรวมของกำลังสองของระยะห่างระหว่างจุดข้อมูลแต่ละจุดกับจุดศูนย์กลางของกลุ่มที่จุดนั้นสังกัดอยู่ โดยมีสูตรการคำนวณดังสมการ (5)

$$WCSS = \sum_{C_k}^{C_n}\left(\sum_{d_i in C_i}^{d_m} distance(d_i, C_k)^2\right) \quad (5)$$

โดยที่

C_n คือจำนวนศูนย์กลางของกลุ่ม (Cluster centroids)

C_kคือศูนย์กลางของกลุ่มที่ k

d_mคือจำนวนจุดข้อมูลทั้งหมด

d_i คือจุดข้อมูลแต่ละจุดที่อยู่ในกลุ่ม C_i

distance (d_i, C_k) คือระยะห่างระหว่างจุดข้อมูล d_i และศูนย์กลางกลุ่ม C_k

วิธีที่สองคือ การหาค่า Silhouette Score ซึ่งดูจากความแตกต่างระหว่างกลุ่มและความเหมือนภายในกลุ่ม โดยค่า Silhouette จะอยู่ระหว่าง -1 ถึง 1 โดยมีสูตรการคำนวณดังสมการ (6)

$$s(i) = \frac{b(i) - a(i)}{\max\{\mathrm{a(i)} - \mathrm{b(i)}\}} \quad (6)$$

โดยที่ $a(i)$ คือค่าเฉลี่ยระยะทางระหว่างจุดกับจุดอื่นในกลุ่มเดียวกัน และ $b(i)$ คือค่าเฉลี่ยระยะทางระหว่างจุดกับจุดในกลุ่มที่อยู่ใกล้ที่สุด

วิธีที่สามคือ Davies-Bouldin Index (DBI) ใช้วัดความเหมือนระหว่างกลุ่มโดยเปรียบเทียบระยะระหว่างกลุ่มกับขนาดของกลุ่ม โดยมีสูตรการคำนวณดังสมการ (7)

$$DB = \frac{1}{K}\sum_{k=1}^{K}\max\left\{\frac{S(U_k) + S(U_l)}{d(U_k, U_l)}\right\} \quad (7)$$

โดยที่ค่า $S(U_k) + S(U_l)$ คือระยะห่างของข้อมูลภายในกลุ่ม k และกลุ่ม l ค่า $d(U_k, U_l)$ คือ ระยะห่างระหว่างจุดกึ่งกลางของกลุ่ม k และกลุ่ม l

2.3 การวัดประสิทธิภาพของการจำแนกข้อมูล

การวัดประสิทธิภาพของการจำแนกข้อมูล จะทำการสร้างเมทริกซ์ความสับสน (Confusion matrix) ซึ่งใช้การประเมินค่าจริง (Actual value) เทียบกับค่าที่ได้จากผลลัพธ์ของโมเดลหรือค่าที่คาดการณ์ไว้ (Predicted Value) แล้วสรุปค่าออกมาในรูปแบบของตารางเมทริกซ์ โดยมีจำนวน แถวเท่ากับจำนวน Class

		Actual Class: Positive	Actual Class: Negative	Total
Predicted Class	Positive	*TP*	*FP*	*TP + FP*
Predicted Class	Negative	*FN*	*TN*	*FN + TN*
Total		*TP + FN*	*FP + TN*	*n*

ภาพที่ 2: ตัวอย่างแสดงตาราง Confusion matrix

True Positive (TP) คือ สิ่งที่โปรแกรมทำนายว่า “จริง” และ มีค่าเป็น “จริง”

True Negative (TN) คือ สิ่งที่โปรแกรมทำนายว่า “ไม่จริง” และ มีค่า “ไม่จริง”

False Positive (FP) คือ สิ่งที่โปรแกรมทำนายว่า “จริง” แต่มีค่าเป็น “ไม่จริง”

False Negative (FN) คือ สิ่งที่โปรแกรมทำนายว่า “ไม่จริง” แต่ มีค่าเป็น “จริง”

จากเมทริกซ์ความสับสน (Confusion matrix) จะสามารถคำนวณค่าประสิทธิภาพของโมเดลได้ดังนี้

ความแม่นยำ (Accuracy) คือการวัดสัดส่วนของการทำนายที่ถูกต้องจากการทำนายทั้งหมด ดังสมการ (8)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

ความเที่ยง (Precision) คือการวัดสัดส่วนของการทำนายผลบวกที่ถูกต้องเมื่อเทียบกับการทำนายผลบวกทั้งหมด ดังสมการ (9)

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

ความไว (Recall) คือสัดส่วนของผลบวกจริงที่ทำนายถูกต้อง ดังสมการ (10)

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

F1-Score คือ ค่าเฉลี่ยแบบ Harmonic ของ ความเที่ยง (Precision) และความไว (Recall) เพื่อวัดความสมดุลระหว่างทั้งสองค่า ดังสมการ (11)

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (11)$$

3. ผลการวิจัย

3.1 ผลจากการตรวจสอบข้อมูล

จากการตรวจสอบข้อมูลพบว่า ทุกคอลัมน์มีข้อมูลครบถ้วนและ ไม่มีค่าที่หายไป (Missing Values) ในชุดข้อมูลที่ใช้ในการวิเคราะห์ ซึ่งหมายความว่าไม่จำเป็นต้องดำเนินการเติมค่าข้อมูลที่ขาดหาย (Imputation) หรือการลบแถวที่มีค่าหายไป ทำให้สามารถนำข้อมูลทั้งหมดไปใช้ในการวิเคราะห์และสร้างโมเดลได้โดยตรง และทุกคอลัมน์ในตารางนี้มีข้อมูลเป็นตัวเลขจำนวนเต็ม (Integer) ขนาด 64 บิต

```
Missing values:
AccX         0
AccY         0
AccZ         0
GyroX        0
GyroY        0
GyroZ        0
Class        0
Timestamp    0
dtype: int64
```

ภาพที่ 3: ตัวอย่างแสดงผลการตรวจสอบค่าที่หายไป (Missing Values) ในชุดข้อมูล

3.2 ผลลัพธ์จากการนำ K-Means Clustering มาใช้เป็นคุณลักษณะของโมเดล Logistic Regression

```
Accuracy: 0.9724473257698542

Confusion Matrix:
[[191   0   0]
 [ 17 229   0]
 [  0   0 180]]
```

ภาพที่ 4: แสดงค่าความแม่นยำและ เมทริกซ์ความสับสน (Confusion Matrix)

จากการทดลองได้นำ K-Means Clustering มาจัดกลุ่มพฤติกรรมการขับขี่เป็น 3 คลัสเตอร์ ก่อนนำค่าคลัสเตอร์ที่ได้ไปใช้เป็นคุณลักษณะในการฝึกโมเดล Logistic Regression เพื่อทำนายพฤติกรรมของผู้ขับขี่ พบว่าให้ค่าค่าความแม่นยำ (Accuracy) 97.24%

ผลลัพธ์จาก เมทริกซ์ความสับสน (Confusion Matrix) พบว่า Class 0 (การขับขี่แบบปกติหรือ Normal) ทำนายถูกต้อง 191 จาก 191 รายการ (100%) Class 1 (การขับขี่แบบช้าหรือ Slow) ทำนายถูกต้อง 229 จาก 246 รายการ (ประมาณ 93%) และ Class 2 (การขับขี่แบบเร็วหรือ Aggressive) ทำนายถูกต้อง 180 จาก 180 รายการ (100%)

สัดส่วนของผลลัพธ์ที่โมเดลทำนายว่าเป็นบวก (Positive) และถูกต้องจริง มีค่าเฉลี่ย เท่ากับ 0.97 สัดส่วนของข้อมูลที่เป็นบวก (Positive) ทั้งหมดที่โมเดลทำนายได้ถูกต้อง มีค่าเฉลี่ย 0.98 และ ค่าเฉลี่ย Harmonic Mean ของความเที่ยง (Precision) และความไว (Recall) มีค่าเท่ากับ 0.97

ตารางที่ 1: ผลลัพธ์ที่ได้จากวิธี ใช้ K-means แบ่งกลุ่มนำไปใช้เป็น Feature ของ Logistic Regression

	Precision	Recall	F1-score	support
0	0.92	1.00	0.96	191
1	1.00	0.93	0.96	246
2	1.00	1.00	1.00	180
Accuracy			0.97	617
Macro avg	0.97	0.98	0.97	617
Weighted avg	0.97	0.97	0.97	617

3.3 ผลลัพธ์จากการแมป (Mapping) กลุ่มที่ได้จาก K-Means Clustering กับ Class

จากการทดลองได้นำ K-Means Clustering มาจัดกลุ่มพฤติกรรมการขับขี่เป็น 3 คลัสเตอร์ และนำค่าคลัสเตอร์ที่ได้ไปแมป (Mapping) กับ Class เพื่อให้สามารถคาดการณ์พฤติกรรมของผู้ขับขี่ได้อย่างถูกต้องและแม่นยำ พบว่าให้ค่าความแม่นยำ (Accuracy) 97.82%

ผลการแมป (Mapping) คลัสเตอร์ไปยัง Class เป็นดังนี้

Cluster 0 คือ Class 0 (การขับขี่แบบปกติ หรือ Normal)

Cluster 1 คือ Class 2 (การขับขี่แบบเร็วหรือ Aggressive)

Cluster 2 คือ Class 1 (การขับขี่แบบช้าหรือ Slow)

ผลลัพธ์จาก เมทริกซ์ความสับสน (Confusion Matrix) พบว่า Class 0 (การขับขี่แบบปกติ หรือ Normal) ทำนายถูกต้อง 997 จาก 997 รายการ (100%) Class 1 (การขับขี่แบบช้าหรือ Slow) ทำนายถูกต้อง 1206 จาก 1273 รายการ (95%) และ Class 2 (การขับขี่แบบเร็วหรือ Aggressive) ทำนายถูกต้อง 814 จาก 814 รายการ (100%)

```
Most common class in each cluster:
Cluster
0    0
1    2
2    1
Name: Class, dtype: int64
Cluster to class mapping: {0: 0, 1: 2, 2: 1}
Accuracy: 0.9782749675745784
      Class  Cluster  Predicted_Class
0         2        1                2
1         2        1                2
2         2        1                2
3         2        1                2
4         2        1                2
...     ...      ...              ...
3079      1        2                1
3080      1        2                1
3081      1        2                1
3082      1        2                1
3083      1        2                1

[3084 rows x 3 columns]

Confusion Matrix:
[[ 997    0    0]
 [  67 1206    0]
 [   0    0  814]]
```

ภาพที่ 5: แสดงผลการแมป (Mapping) คลัสเตอร์ไปยัง Class ค่าความแม่นยำและ Confusion Matrix

สัดส่วนของผลลัพธ์ที่โมเดลทำนายว่าเป็นบวก (Positive) และถูกต้องจริง มีค่าเฉลี่ย เท่ากับ 0.98 สัดส่วนของข้อมูลที่เป็นบวก (Positive) ทั้งหมดที่โมเดลทำนายได้ถูกต้อง มีค่าเฉลี่ย 0.98 และ ค่าเฉลี่ย Harmonic Mean ของความเที่ยง (Precision) และความไว (Recall) มีค่าเท่ากับ 0.98

ตารางที่ 2: ผลลัพธ์จากการแมป (Mapping) กลุ่มที่ได้จาก K-Means clustering กับ Class

	Precision	Recall	F1-score	support
0	0.94	1	0.97	997
1	1.00	0.95	0.97	1273
2	1.00	1.00	1.00	814
Accuracy			0.98	3084
Macro avg	0.98	0.98	0.98	3084
Weighted avg	0.98	0.98	0.98	3084

3.4 ผลลัพธ์จากใช้ตัวชี้วัดต่างๆในการวัดผล K-Means Clustering

เพื่อประเมินคุณภาพของกระบวนการจัดกลุ่มที่ได้จาก K-Means Clustering ได้มีการใช้ตัวชี้วัดมาตรฐาน ได้แก่ Silhouette Score, Davies-Bouldin Index (DBI) และ Within-Cluster-Sum-of-Squares (WCSS)

ค่า Silhouette Score ที่ได้คือ 0.1494 ซึ่งค่อนข้างต่ำ เมื่อเทียบกับค่า Silhouette Score ที่ดี ซึ่งควรจะมีค่าเข้าใกล้ 1 ค่าที่ต่ำนี้บ่งบอกว่าข้อมูลในแต่ละกลุ่มอาจจะไม่ได้อยู่ใกล้กับจุดศูนย์กลางของกลุ่มตัวเองมากนัก และอาจจะมีข้อมูลบางส่วนที่อยู่ใกล้กับกลุ่มอื่นๆ มากกว่า ค่า Davies-Bouldin Index ที่ได้คือ 1.7254 ซึ่งค่อนข้างสูง บ่งบอกว่ากลุ่มต่างๆ ที่แบ่งออกมานั้นมีความคล้ายคลึงกัน หรืออาจจะมีข้อมูลที่ซ้อนทับกันระหว่างกลุ่ม ค่า WCSS ที่ได้คือ 64.4067 ค่านี้แสดงถึงผลรวมของระยะทางระหว่างข้อมูลแต่ละจุดในกลุ่มกับจุดศูนย์กลางของกลุ่มนั้นๆ

ตารางที่ 3: ผลลัพธ์ที่ได้จากวิธี ใช้ K-means วัดประสิทธิภาพโดย Silhouette Score, Davies-Bouldin Index และ Within-Cluster-Sum-of-Squares (WCSS)

Metric	Value
Silhouette Score	0.1494
Davies-Bouldin Index	1.7254
Inertia (WCSS)	64.4067

4. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการนำเทคโนโลยีปัญญาประดิษฐ์ (AI) มาประยุกต์ใช้ในการทำนายพฤติกรรมการขับขี่ โดยใช้เทคนิค K-Means Clustering ในการจัดกลุ่ม พร้อมทั้งประเมินผลลัพธ์ด้วยวิธีการทั้งหมด 3 วิธี พบว่าการใช้เทคนิค K-Means Clustering ร่วมกับวิธีการต่างๆ สามารถแบ่งกลุ่มข้อมูลได้อย่างมีประสิทธิภาพ โดยผลลัพธ์จากการนำ K-Means Clustering มาใช้เป็นคุณลักษณะของโมเดล Logistic Regression กับแมป (Mapping) กลุ่มที่ได้จาก K-Means Clustering กับ Class ได้ค่าใกล้เคียงกัน แต่วิธีแมป (Mapping) กลุ่มมีค่าสูงกว่าเล็กน้อย ส่วนจากค่า Silhouette Score, Davies-Bouldin Index และ Within-Cluster-Sum-of-Squares (WCSS) ที่ได้จากวิธีที่ 3 จะเห็นได้ว่าผลการแบ่งกลุ่มข้อมูลด้วยวิธี K-Means Clustering อาจจะยังไม่ดีเท่าที่ควร ซึ่งอาจจะมีสาเหตุมาจากหลายปัจจัย เช่น การกระจายตัวของข้อมูลที่ซับซ้อน หรือจำนวนกลุ่มที่เลือก (K) อาจจะไม่เหมาะสม

5. กิตติกรรมประกาศ

งานวิจัยครั้งนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความอนุเคราะห์อย่างดียิ่งจาก อาจารย์คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ ผู้ทรงคุณวุฒิที่ได้ถ่ายทอดความรู้และประสบการณ์อันมีค่า ให้คำแนะนำปรึกษา และสนับสนุนการทำวิจัยนี้มาโดยตลอด ตั้งแต่เริ่มต้นจนกระทั่งสำเร็จลุล่วงไปด้วยดี ขอขอบพระคุณ ภาควิชาเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ ที่ให้การสนับสนุนด้านสถานที่และอุปกรณ์ในการทำวิจัย ขอขอบคุณเพื่อนร่วมงานและผู้ที่เกี่ยวข้องทุกท่าน ที่ได้ให้กำลังใจและความช่วยเหลือในการทำวิจัยนี้จนสำเร็จลุล่วงไปด้วยดี และผู้จัดทำขอน้อมระลึกถึงพระคุณของบิดามารดา ที่ได้ให้การสนับสนุนด้านการศึกษามาโดยตลอด คุณค่าอันจะพึงมีจากงานวิจัยนี้ ขอมอบเป็นกตัญญูกตเวทีแด่ท่านผู้มีพระคุณทุกท่าน

6. เอกสารอ้างอิง

[1] สำนักนโยบายและแผนการขนส่งและจราจร, สำนักแผนความปลอดภัย. การวิเคราะห์สถานการณ์อุบัติเหตุทางถนนของกระทรวงคมนาคม [อินเทอร์เน็ต]. 2023 [เข้าถึงเมื่อ 20 ตุลาคม 2024]. เข้าถึงได้จาก https://www.otp.go.th

[2] การวิเคราะห์เชิงพยากรณ์ [อินเทอร์เน็ต]. [เข้าถึงเมื่อ 10 พฤศจิกายน 2024]. เข้าถึงได้จาก https://www2.cs.science.cmu.ac.th

[3] Lati A, Bensid K, Lati I, Gezzal C. Enhanced SVM-Based COVID-19 detection system using efficient transfer learning algorithms. ELCVIA Electronic Letters on Computer Vision and Image Analysis [อินเทอร์เน็ต]. [เข้าถึงเมื่อ 10 พฤศจิกายน 2024]. เข้าถึงได้จาก: https://elcvia.cvc.uab.cat/article/view/1601/619

[4] ชูชีพ กาญจน์เขจร. การถดถอยโลจีสติก (Logistic Regression). Remote Sensing Technical Note [อินเทอร์เน็ต]. [เข้าถึงเมื่อ 15 พฤศจิกายน 2024]; (5). เข้าถึงได้จาก https://forest-admin.forest.ku.ac.th

[5] Hastie T, Tibshirani R, Friedman J. The elements of statistical learning: data mining, inference, and prediction [อินเทอร์เน็ต]. 2008 Aug [เข้าถึงเมื่อ 10 พฤศจิกายน 2024]. เข้าถึงได้จาก https://www.sas.upenn.edu

[6] ฐิติพร ธรรมฐิติพร, คนธภกัดี ศุภร. การจัดกลุ่มลูกค้าบัตรเครดิตด้วยเทคนิคเค-มีนส์และต้นไม้ตัดสินใจเพื่อแนะนำแผนการตลาดเฉพาะกลุ่ม [อินเทอร์เน็ต]. [เข้าถึงเมื่อ 10 พฤศจิกายน 2024]. เข้าถึงได้จาก https://msds.science.swu.ac.th

[7] Popescu PS, Cojocaru I. Driving behavior [อินเทอร์เน็ต]. [เข้าถึงเมื่อ 10 พฤศจิกายน 2024]. เข้าถึงได้จาก https://www.kaggle.com

[8] Sitorus M, Melisa M, Herninda D. Driver predicting behavior based on accelerometer and gyroscope sensors with K-Means algorithm method. RIGGS: Journal of Artificial Intelligence and Digital Business.2023.

[9] Kanwal K, Rustam F, Chaganti R, Jurcut AD, Ashraf I. Smartphone inertial measurement unit data features for analyzing driver driving behavior. IEEE Sensors Journal.2023.

การจำลองและทดสอบแผนเส้นทางครอบคลุมที่เหมาะสมในหุ่นยนต์ทำความสะอาด

Simulation and Testing of Optimal Coverage Path Planning in Cleaning Robots Simulation and Testing of Optimal Coverage Path Planning in Cleaning Robots

กิตติคุณ สุอรุณ* วิทิต ฉัตรรัตนกุลชัย

ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

(* *Kittikun.sua@ku.th*)

บทคัดย่อ

งานวิจัยนี้นำเสนอการจำลองและทดสอบแผนเส้นทางครอบคลุมที่เหมาะสมสำหรับหุ่นยนต์เคลื่อนที่ด้วยล้อเมคานัมสำหรับทำความสะอาด โดยมุ่งเน้นการประยุกต์ใช้เทคนิคการจำลองและการวางแผนเส้นทางครอบคลุมต่าง ๆ เพื่อเพิ่มประสิทธิภาพในการทำงานในสภาพแวดล้อมของห้อง การศึกษาได้ทดลองใช้เทคนิคการเคลื่อนที่หลายรูปแบบ เช่น การเดินแบบ Random walk, Zig-zag, และ Wall-Follower รวมทั้งการปรับเส้นทางโดยใช้ A* algorithm เพื่อให้หุ่นยนต์สามารถแก้ไขปัญหาวนซ้ำทางเดินเดิมเมื่อพบสิ่งกีดขวาง การทดลองยังใช้ข้อมูลแผนที่จากเซนเซอร์ในพื้นที่ห้องและแปลงเป็นกริดเมพสำหรับการวางแผนเส้นทาง ผลการทดลองแสดงว่าแผนเส้นทางครอบคลุมที่พัฒนามีประสิทธิภาพในการเพิ่มความครอบคลุมพื้นที่ และสามารถเลือกอัลกอริทึมที่เหมาะสมเพื่อลดเวลาในการทำงานของหุ่นยนต์ ช่วยประหยัดทั้งพลังงานและเวลาได้อย่างมีประสิทธิภาพ

คำสำคัญ: หุ่นยนต์เคลื่อนที่ด้วยล้อเมคานัม, การจำลอง, แผนเส้นทางครอบคลุม, การทดสอบ

Abstract

This research presents the simulation and testing of an optimal coverage path planning for a Mecanum-wheeled mobile robot for cleaning. The focus is on applying simulation techniques and various path planning methods to enhance performance in a room environment. The study experimented with different movement techniques, such as Random Walk, Zig-zag, and Wall-Follower, as well as path adjustment using the A* algorithm to enable the robot to resolve the issue of revisiting the same path when encountering obstacles. The experiments also used map data from sensors in the room and converted it into a grid map for path planning. The results showed that the developed coverage path plan effectively improved area coverage and enabled the selection of the appropriate algorithm to reduce the robot's working time, helping to save both energy and time efficiently.

Keywords: Mobile robot with Mecanum wheels, simulation, coverage path planning, testing

1. บทนำ

ในสภาพปัจจุบันแนวโน้มการใช้หุ่นยนต์ในอุตสาหกรรมเพิ่มขึ้นเป็นอย่างมากซึ่งขนาดตลาดหุ่นยนต์ทำความสะอาดทั่วโลกคาดว่าจะสูงถึง 24 พันล้านดอลลาร์ภายในปี 2569 โดยเพิ่มขึ้นที่การเติบโตของตลาดที่ 22.9% CAGR ในช่วงระยะเวลาคาดการณ์ [10] และจากเหตุการ์ณ Covid-19 ทำให้หุ่นยนต์ทำความสะอาดเป็นที่ต้องการอย่างมาก เพื่อช่วยเพิ่มความเข็มงวดในการทำความสะอาดและลดการระบาดของโรค

ปัจจุบัน หุ่นยนต์ทำความสะอาดส่วนใหญ่เป็นหุ่นยนต์นำเข้าจากต่างประเทศ ซึ่งทำให้ราคาหุ่นยนต์สูงและยังไม่มีหน่วยงานไหนที่ผลิตหุ่นยนต์ทำความสะอาดด้วยเทคโนโลยีของตนเอง ดังนั้นหากสามารถศึกษาและพัฒนาหุ่นยนต์ที่ใช้เทคโนโลยีในประเทศได้ ก็จะช่วยลดต้นทุนการผลิตและสามารถส่งหุ่นยนต์ออกไปยังประเทศใกล้เคียงได้

การพัฒนาหุ่นยนต์ทำความสะอาดไม่เพียงแต่ต้องมีระบบการดูดฝุ่นหรือเช็ดฝุ่นที่มีประสิทธิภาพ แต่ยังต้องคำนึงถึงการออกแบบเส้นทางการเคลื่อนที่ที่สามารถครอบคลุมพื้นที่ได้

อย่างเต็มที่ โดยประหยัดพลังงานและลดเวลาในการทำความสะอาด รวมถึงสามารถหลบหลีกสิ่งกีดขวางได้และทำงานร่วมกับมนุษย์ได้อย่างปลอดภัย

การวางแผนเส้นทางครอบคลุม (Coverage Path Planning: CPP) เป็นวิธีการที่ได้รับความนิยมในการพัฒนาเส้นทางการเคลื่อนที่ของหุ่นยนต์ เป้าหมายคือการค้นหาเส้นทางที่สามารถครอบคลุมพื้นที่ทั้งหมดได้โดยไม่มีการชนกัน พร้อมทั้งลดเวลาในการเดินทางและประมวลผล ซึ่งเป็นสิ่งที่สามารถนำมาปรับใช้ในการพัฒนาหุ่นยนต์ทำความสะอาด

จากแนวคิดดังกล่าว ผู้วิจัยจึงศึกษาการเคลื่อนที่ของหุ่นยนต์ด้วยล้อเมคานัมที่สามารถเคลื่อนที่ได้ทุกทิศทาง 360 องศา โดยไม่ต้องหมุนและมีความสามารถในการเคลื่อนที่ได้ดีในพื้นที่แคบ รวมถึงการวางแผนเส้นทางครอบคลุมที่จะช่วยให้หุ่นยนต์ทำความสะอาดได้อย่างครอบคลุมที่สุด ทั้งนี้เพื่อเพิ่มประสิทธิภาพในการใช้พลังงานและลดเวลาที่ใช้ในการทำความสะอาด

2. ทฤษฎีที่เกี่ยวข้อง

2.1 โมเดลหุ่นยนต์เคลื่อนที่

หุ่นยนต์ที่เคลื่อนที่ด้วยล้อเมคานัมได้รับการออกแบบเพื่อให้สามารถเคลื่อนที่ในทิศทางต่าง ๆ พร้อมกัน (Omni-directional) โดยไม่ต้องหมุนตัวหรือต้องปรับทิศทางของล้อ ซึ่งทำให้เหมาะสมสำหรับการใช้งานในพื้นที่แคบหรือในสภาพแวดล้อมที่ต้องการความยืดหยุ่นในการเคลื่อนที่สูง ในการวิจัยนี้จะทำการจำลองโดยใช้ตัวโมเดลของ Iron-X จากบริษัท ทีอีเอสอาร์ จำกัด เป็นต้นแบบ และในส่วนของสมการที่เกี่ยวข้องจะระบุได้ดังนี้

2.1.1 Forward Kinematics

การคำนวณการเคลื่อนที่ของหุ่นยนต์จากความเร็วของล้อที่หมุน ซึ่งรวมถึงความเร็วเชิงเส้นและความเร็วเชิงมุมของหุ่นยนต์ โดยสามารถแสดงได้ด้วยสมการดังนี้

$$V_{\text{linear}} = \omega r \tag{1}$$

เมื่อ V_{linear} แทน ความเร็วเชิงเส้น
ω แทน ความเร็วเชิงมุม
r แทน รัศมีของล้อ

และความเร็วของความเร็วเชิงมุมของปลายล้อแสดงได้ดังนี้

$$V_{\text{tangential}} = \omega_z \left(\frac{D_x + D_y}{2}\right) \tag{2}$$

เมื่อ $V_{\text{tangential}}$ แทน ความเร็วเชิงมุมของปลายล้อ
ω_z แทน ความเร็วเชิงมุมของหุ่นยนต์
D_x, D_y แทน ระยะห่างระหว่างล้อที่ขนานกับแกน x และ y ตามลำดับ

การคำนวณความเร็วรอบต่อนาที (rpm) ของล้อแต่ละตัว

$$N_{\text{rpm}} = \left(\frac{60V_{\text{linear}}}{2\pi r}\right) \tag{3}$$

โดยที่

$$N_{\text{rpm-x}} = \left(\frac{60V_{\text{linear-x}}}{2\pi r}\right) \tag{4}$$

$$N_{\text{rpm-y}} = \left(\frac{60V_{\text{linear-y}}}{2\pi r}\right) \tag{5}$$

$$N_{rpm-\tan} = \left(\frac{60V_{tangential}}{2\pi r}\right) \tag{6}$$

เมื่อ $V_{linear-x}$ แทน ความเร็วเชิงเส้นในทิศทาง x
$V_{linear-y}$ แทน ความเร็วเชิงเส้นในทิศทาง y
$N_{\text{rpm-x}}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง x
$N_{\text{rpm-y}}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง y
$N_{\text{rpm-}tan}$ แทน ความเร็วรอบของล้อที่เกี่ยวข้องกับความเร็วเชิงมุม Tangential

สมการการคำนวณ (RPM) ของแต่ละล้อจะได้ดังนี้

$$N_{\text{rpm-M1}} = N_{\text{rpm-x}} - N_{\text{rpm-y}} - N_{\text{rpm-tan}} \tag{7}$$

$$N_{\text{rpm-M2}} = N_{\text{rpm-x}} + N_{\text{rpm-y}} + N_{\text{rpm-tan}} \tag{8}$$

$$N_{\text{rpm-M3}} = N_{\text{rpm-x}} + N_{\text{rpm-y}} - N_{\text{rpm-tan}} \tag{9}$$

$$N_{\text{rpm-M4}} = N_{\text{rpm-x}} - N_{\text{rpm-y}} + N_{rpm-\tan} \tag{10}$$

เมื่อ $N_{\text{rpm-M1}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 1
$N_{\text{rpm-M2}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 2
$N_{\text{rpm-M3}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 3
$N_{\text{rpm-M4}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 4

2.1.2 Inverse Kinematics

การคำนวณความเร็วของล้อจากการกำหนดทิศทางและความเร็วที่ต้องการของหุ่นยนต์ เพื่อให้หุ่นยนต์เคลื่อนที่ไปยังตำแหน่งปลายทางที่กำหนด โดยใช้สมการ Inverse Kinematics เพื่อคำนวณค่าความเร็วที่ต้องการของล้อแต่ละตัว

สมการการคำนวณความเร็วรอบต่อนาที (RPM) ของแต่ละล้อจะได้ดังนี้

$$N_{\text{rpm-x}} = \frac{N_{\text{rpm-}M1}}{4} + \frac{N_{\text{rpm-}M2}}{4} + \frac{N_{\text{rpm-}M3}}{4} + \frac{N_{\text{rpm-}M4}}{4} \tag{11}$$

$$N_{\text{rpm-y}} = -\frac{N_{\text{rpm-}M1}}{4} + \frac{N_{\text{rpm-}M2}}{4} + \frac{N_{\text{rpm-}M3}}{4} - \frac{N_{\text{rpm-}M4}}{4} \tag{12}$$

$$N_{\text{rpm-tan}} = -\frac{N_{\text{rpm-}M1}}{4} + \frac{N_{\text{rpm-}M2}}{4} - \frac{N_{\text{rpm-}M3}}{4} + \frac{N_{\text{rpm-}M4}}{4} \tag{13}$$

เมื่อ $N_{\text{rpm-M1}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 1
$N_{\text{rpm-M2}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 2
$N_{\text{rpm-M3}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 3
$N_{\text{rpm-M4}}$ แทน ความเร็วรอบต่อนาที (RPM) ของล้อที่ 4
$N_{\text{rpm-x}}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง x
$N_{\text{rpm-y}}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง y
$N_{\text{rpm-}tan}$ แทน ความเร็วรอบของล้อที่เกี่ยวข้องกับความเร็วเชิงมุม Tangential

สมการที่ใช้ในการคำนวณความเร็วเชิงเส้นของหุ่นยนต์ในทิศทาง xและ y รวมถึงความเร็วเชิงมุมรอบแกน z โดยสามารถแสดงได้ด้วยสมการดังนี้

$$V_{linear-x} = \frac{2\pi N_{rpm-x} r}{60} \quad (14)$$

$$V_{linear-y} = \frac{2\pi N_{rpm-y} r}{60} \quad (15)$$

$$V_{\text{tangential}} = \frac{2\pi N_{rpm-tan} r}{60} \quad (16)$$

$$\omega_z = \frac{V_{\text{tangential}}}{\left(\frac{D_x + D_y}{2}\right)} \quad (17)$$

เมื่อ $V_{\text{tangential}}$ แทน ความเร็วเชิงมุมของปลายล้อ
$V_{linear-x}$ แทน ความเร็วเชิงเส้นในทิศทาง x
$V_{linear-y}$ แทน ความเร็วเชิงเส้นในทิศทาง y
ω_z แทน ความเร็วเชิงมุมของหุ่นยนต์
D_x, D_y แทน ระยะห่างระหว่างล้อที่ขนานกับแกน x และ y ตามลำดับ
r แทน รัศมีของล้อ
$N_{\text{rpm}-x}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง x
$N_{\text{rpm}-y}$ แทน ความเร็วรอบต่อนาที (RPM) ในทิศทาง y
$N_{\text{rpm}-tan}$ แทน ความเร็วรอบของล้อที่เกี่ยวข้องกับความเร็วเชิงมุม Tangential

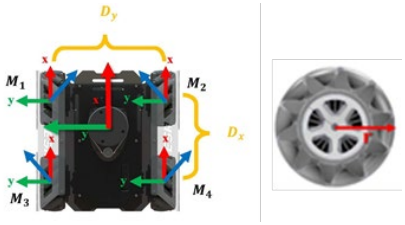

ภาพที่ 1: ตัวแปรต่างในหุ่นยนต์ที่กำหนดขึ้นตามสมการที่กล่าวมาข้างต้น

2.2 เส้นทางครอบคลุม

การวางแผนเส้นทางครอบคลุม (Coverage Path Planning: CPP) เป็นแนวทางสำคัญในการกำหนดเส้นทางการเคลื่อนที่ของหุ่นยนต์อัตโนมัติ เพื่อให้สามารถปฏิบัติงานครอบคลุมพื้นที่เป้าหมายได้อย่างมีประสิทธิภาพสูงสุด โดยมีวัตถุประสงค์หลักเพื่อ ลดเส้นทางที่ซ้ำซ้อน (reducing redundant paths) และ เพิ่มความเร็วในการสำรวจพื้นที่ (increasing exploration efficiency) ซึ่งเป็นปัจจัยสำคัญที่ช่วยให้หุ่นยนต์สามารถดำเนินงานได้อย่างมีประสิทธิภาพ

ในวิจัยนี้ ได้เลือกอัลกอริทึมสำหรับการวางแผนเส้นทางครอบคลุมจำนวน 3 รูปแบบ ได้แก่ Zig-Zag Algorithm, Random Walk Algorithm และ Wall-Follower Algorithm เพื่อใช้ในการ เปรียบเทียบประสิทธิภาพของวิธีการวางแผนเส้นทางที่แตกต่างกัน โดยแต่ละอัลกอริทึมมีหลักการทำงานที่แตกต่างกันและเหมาะสมกับสภาพแวดล้อมที่หลากหลาย

2.2.1 Zig-Zag Algorithm

อัลกอริทึม Zig-Zag เป็นวิธีการวางแผนเส้นทางครอบคลุมพื้นที่ที่อาศัยการเคลื่อนที่แบบไปกลับเป็นเส้นตรง (Back-and-Forth Motion) ซึ่งมีประโยชน์ในการสำรวจพื้นที่ที่มีโครงสร้างชัดเจน และช่วยให้หุ่นยนต์สามารถครอบคลุมพื้นที่เป้าหมายได้อย่างมีประสิทธิภาพ

หลักการทำงาน: หุ่นยนต์จะเคลื่อนที่เป็นเส้นตรงจนกระทั่งถึงขอบพื้นที่หรือพบสิ่งกีดขวาง เมื่อถึงขอบหรืออุปสรรค หุ่นยนต์จะเปลี่ยนทิศทางและเคลื่อนที่กลับในแนวขนานไปเรื่อย ๆ จนกว่าพื้นที่ทั้งหมดจะถูกสำรวจ

2.2.2 Random Walk Algorithm

อัลกอริทึม Random Walk เป็นแนวทางที่ใช้การเคลื่อนที่แบบสุ่ม (Stochastic Motion) โดยไม่มีรูปแบบการวางแผนล่วงหน้า ซึ่งเหมาะสำหรับการสำรวจพื้นที่ที่ไม่มีโครงสร้างแน่นอนหรือพื้นที่ที่มีสิ่งกีดขวางกระจายอยู่แบบไม่เป็นระบบ

หลักการทำงาน: หุ่นยนต์จะเลือกทิศทางการเคลื่อนที่แบบสุ่มเพื่อไปยังตำแหน่งถัดไป หากพบอุปสรรค หุ่นยนต์จะสุ่มเลือกทิศทางใหม่ และทำซ้ำกระบวนการนี้ไปเรื่อย ๆ จนกว่าพื้นที่ทั้งหมดจะถูกสำรวจ

2.2.3 Wall-Follower Algorithm

อัลกอริทึม Wall-Follower เป็นกลยุทธ์ที่ใช้ในการนำทางหุ่นยนต์ภายในพื้นที่ปิด (Enclosed Space Navigation) เช่น เขาวงกต หรือ พื้นที่ที่มีสิ่งกีดขวางจำนวนมาก โดยหลักการทำงานของอัลกอริทึมนี้อาศัยการให้หุ่นยนต์เคลื่อนที่โดยรักษาระยะห่างจากผนังหรือสิ่งกีดขวาง

หลักการทำงาน: หุ่นยนต์จะเคลื่อนที่โดยรักษาผนังไว้ทางด้านขวา (หรือด้านซ้าย) ตลอดเส้นทาง หากพบทางแยก หุ่นยนต์จะเลือกเลี้ยวขวาก่อนหากเป็นไปได้ หากไม่สามารถเลี้ยวขวาได้ หุ่นยนต์จะเดินตรงไปข้างหน้า และหากพบทางตัน หุ่นยนต์จะเลี้ยวซ้ายหรือถอยหลังจนกว่าจะพบเส้นทางใหม่ อัลกอริทึมนี้จะทำซ้ำกระบวนการดังกล่าวจนกว่าหุ่นยนต์จะสำรวจพื้นที่ทั้งหมดหรือไปถึงเป้าหมายที่กำหนด

2.2.4 A (A-Star) Algorithm*

A* Algorithm เป็นอัลกอริทึมสำหรับการค้นหาเส้นทาง (Pathfinding Algorithm) ที่ใช้ในการหาวิถีเดินทางที่สั้นที่สุดหรือมีต้นทุนต่ำที่สุด (Optimal Path) ระหว่างจุดเริ่มต้นไปยังเป้าหมาย อัลกอริทึมนี้อาศัยการคำนวณค่าประเมินต้นทุนของเส้นทางโดยใช้ ฟังก์ชันเฮอริสติก (Heuristic Function) ซึ่งช่วยให้กระบวนการค้นหาเส้นทางมีความเร็วและประสิทธิภาพมากขึ้น

A* Algorithm นิยมใช้ในสถานการณ์ที่มีสิ่งกีดขวางหรือเส้นทางที่ซับซ้อน เนื่องจากสามารถวางแผนเส้นทางที่เหมาะสมและลดระยะทางที่ต้องเดินทางโดยไม่จำเป็น อัลกอริทึมนี้ใช้ฟังก์ชันประเมินค่าต้นทุนเส้นทางโดยสามารถแสดงได้ด้วยสมการดังนี้

$$f(n) = g(n) + h(n) \quad (18)$$

$$g(n) = g(m) + w(m,n) \quad (19)$$

เมื่อ $f(n)$ แทน ค่าประมาณของต้นทุนรวมจากจุดเริ่มต้นไปยังเป้าหมายผ่านโหนด n

$g(n)$ แทน ต้นทุนสะสมจากจุดเริ่มต้นจนถึงโหนด n

$h(n)$ แทน ค่าประเมินระยะทางที่เหลือจากโหนด n ไปยังเป้าหมาย

$g(m)$ แทน ค่าต้นทุนของโหนดก่อนหน้า โดยกำหนดให้ จุดเริ่มต้นมีค่าเป็นศูนย์ ($g(0) = 0$)

$w(m,n)$ แทนค่าน้ำหนักของเส้นทางระหว่างโหนด m และ n ซึ่งอาจขึ้นอยู่กับระยะทางหรืออุปสรรคที่พบระหว่างทาง

2.2.5 Dijkstra's Algorithm

Dijkstra's Algorithm เป็นหนึ่งในอัลกอริทึมสำหรับการค้นหาเส้นทางที่สั้นที่สุด (Shortest Path Algorithm) ระหว่างจุดเริ่มต้น ไปยัง จุดหมายปลายทาง โดยไม่ใช้ ฟังก์ชันเฮอริสติก (Heuristic Function) ในการคาดคะเนระยะทางที่เหลือไปยังเป้าหมาย

อัลกอริทึมนี้ทำงานโดย สำรวจทุกเส้นทางที่เป็นไปได้ และคำนวณระยะทางที่น้อยที่สุดจากจุดเริ่มต้นไปยังโหนดทั้งหมด โดยใช้แนวคิดของกราฟและต้นทุนของเส้นทาง อัลกอริทึมสามารถคำนวณต้นทุนของเส้นทางได้โดยสามารถแสดงได้ด้วยสมการดังนี้

$$f(n) = g(n) \tag{20}$$

เมื่อ $g(n)$ แทน ต้นทุนสะสมจากจุดเริ่มต้นจนถึงโหนด n

$f(n)$ แทน ค่าประมาณของต้นทุนรวมจากจุดเริ่มต้นไปยังเป้าหมายผ่านโหนด n ในกรณีนี้ มีค่าเท่ากับ $g(n)$ เนื่องจาก Dijkstra's Algorithm ไม่ใช้ค่าประมาณของระยะทางที่เหลือ (ไม่มี $h(n)$ เหมือน A* Algorithm)

ดังนั้น ในการวิจัยนี้ A* Algorithm ถูกเลือกใช้งานแทน Dijkstra's Algorithm เนื่องจาก A* Algorithm สามารถลดพลังงานของหุ่นยนต์ได้มากกว่า โดยมุ่งเน้นไปที่เส้นทางที่มีโอกาสเป็นเส้นทางที่ดีที่สุด ขณะที่ Dijkstra's Algorithm ต้องสำรวจทุกเส้นทางโดยไม่มีการคาดการณ์ล่วงหน้า ทำให้ใช้ทรัพยากรมากกว่า เพื่อให้การค้นหาเส้นทางมีประสิทธิภาพสูงสุดและลดการใช้พลังงานของหุ่นยนต์ A* Algorithm จึงเป็นตัวเลือกที่เหมาะสมกว่า

2.3 Heuristic

เฮอริสติก (Heuristic) เป็นแนวทางการค้นหาคำตอบที่มีประสิทธิภาพสำหรับปัญหาที่ซับซ้อน โดยอาศัยการประมาณค่าเพื่อช่วยลดระยะเวลาการคำนวณในการหาวิธีแก้ปัญหาที่ใกล้เคียงกับคำตอบที่เหมาะสมที่สุด (near-optimal solution) แทนการค้นหาวิธีที่สมบูรณ์แบบในทุกรายละเอียด

ในการศึกษานี้ ฟังก์ชันเฮอริสติกถูกนำมาใช้เป็นค่าประมาณเพื่อลดพื้นที่การค้นหา โดยช่วยประเมินว่าตำแหน่งปัจจุบันอยู่ใกล้หรือไกลจากจุดหมาย ซึ่งช่วยเพิ่มประสิทธิภาพของอัลกอริทึมค้นหาเส้นทาง A* Algorithm ในการเลือกเส้นทางที่เหมาะสมที่สุดโดยลดจำนวนโหนดที่ต้องสำรวจ โดยอ้างอิงจากงานวิจัยของ [1] ซึ่งได้นำเสนอแนวทางการใช้ฟังก์ชันเฮอริสติกในการค้นหาเส้นทาง พร้อมตัวอย่างโค้ดที่สามารถนำไปใช้งานได้จริง

2.3.1 Manhattan Distance

Manhattan Distance หรือ ระยะทางแมนฮัตตัน เป็นฟังก์ชันเฮอริสติกที่ใช้ในการคำนวณระยะทางระหว่างสองจุดในพื้นที่แบบตาราง โดยพิจารณาการเคลื่อนที่ เฉพาะในแนวแกน x และ y เท่านั้น โดยไม่มีการเดินแนวทแยงมุม โดยสามารถแสดงได้ด้วยสมการดังนี้

$$h(x,y) = |x - x_{goal}| + |y - y_{goal}| \tag{21}$$

เมื่อ x, y แทน พิกัดของตำแหน่งปัจจุบันของหุ่นยนต์

x_{goal}, y_{goal} แทน แทนพิกัดของตำแหน่งเป้าหมายที่ต้องการไปถึง

ฟังก์ชันนี้มีข้อดีในด้าน ความเร็วในการคำนวณ เนื่องจากไม่ต้องใช้การคำนวณค่ารากที่สองเหมือนกับระยะทางยูคลิด (Euclidean Distance) และเหมาะสำหรับระบบที่จำกัดการเคลื่อนที่เฉพาะแนวตั้งและแนวนอน

2.3.2 Chebyshev Distance

Chebyshev Distance หรือ ระยะทางเชบีเชฟ เป็นฟังก์ชันเฮอริสติกที่ใช้ในการคำนวณระยะทางระหว่างสองจุด โดยพิจารณาระยะทางที่ไกลที่สุดในแนวแกน x หรือ y รวมถึงการเคลื่อนที่ในแนวทแยงมุม (Diagonal Movement) ซึ่งรองรับการเคลื่อนที่ได้ 8 ทิศทาง ทำให้เหมาะสำหรับระบบที่อนุญาตให้หุ่นยนต์เคลื่อนที่ในแนวทแยง โดยสามารถแสดงได้ด้วยสมการดังนี้

$$h(x,y) = max(|x - x_{goal}|, |y - y_{goal}|) \tag{22}$$

เมื่อ x, y แทน พิกัดของตำแหน่งปัจจุบันของหุ่นยนต์

x_{goal}, y_{goal} แทน แทนพิกัดของตำแหน่งเป้าหมายที่ต้องการไปถึง

2.3.3 Horizontal Heuristic

Horizontal Heuristic เป็นฟังก์ชันเฮอริสติกที่ใช้คำนวณระยะทางระหว่างสองจุด โดยพิจารณาเฉพาะแนวแกน x (แนวราบ) เท่านั้นโดยไม่มีการคำนึงถึงระยะทางในแนวแกน y (แนวตั้ง) ทำให้เหมาะสำหรับระบบที่ให้ความสำคัญกับการเคลื่อนที่ในแนวราบเป็นหลัก โดยสามารถแสดงได้ด้วยสมการดังนี้

$$h(x,y) = |x - x_{goal}| \tag{23}$$

เมื่อ x แทน พิกัดของตำแหน่งปัจจุบันของหุ่นยนต์ในแนวแกน x

x_{goal} แทน แทนพิกัดของตำแหน่งเป้าหมายที่ต้องการไปถึงในแนวแกน x

2.3.4 Vertical Heuristic

Vertical Heuristic เป็นฟังก์ชันเฮอริสติกที่ใช้คำนวณระยะทางระหว่างสองจุด โดยพิจารณาเฉพาะแนวแกน y (แนวตั้ง) เท่านั้น โดยไม่สนใจการเคลื่อนที่ในแนวแกน x (แนวราบ) ทำให้เหมาะสำหรับระบบที่ให้ความสำคัญกับการเคลื่อนที่ในแนวตั้งเป็นหลัก โดยสามารถแสดงได้ด้วยสมการดังนี้

$$h(x,y) = |y - y_{goal}| \tag{24}$$

เมื่อ y แทน พิกัดของตำแหน่งปัจจุบันของหุ่นยนต์ในแนวแกน y

y_{goal} แทน พิกัดของตำแหน่งเป้าหมายที่ต้องการไปถึงในแนวแกน y

2.4 Cartographer

Cartographer ROS2 เป็นระบบ SLAM (Simultaneous Localization and Mapping) ที่ใช้ร่วมกับ Robot Operating System 2 (ROS2) เพื่อช่วยให้หุ่นยนต์สามารถสร้างแผนที่ของสภาพแวดล้อมแบบ เรียลไทม์ (real-time mapping) พร้อมทั้งระบุตำแหน่งของตนเองภายในแผนที่ได้อย่างแม่นยำ โดยในการศึกษานี้ เซ็นเซอร์ LiDAR ถูกใช้ในสภาพแวดล้อมจำลองใน Gazebo เพื่อสร้างแผนที่ของพื้นที่จำลอง

เมื่อกระบวนการสร้างแผนที่เสร็จสมบูรณ์ ข้อมูลที่ได้จะถูกแปลงเป็น Numerical Python Array เพื่อนำไปใช้ในการวางแผนเส้นทางสำหรับการเคลื่อนที่ของหุ่นยนต์ต่อไป

3. ผลการวิจัย

3.1 เตรียมแผนที่

เริ่มต้นกระบวนการสร้างแผนที่โดยใช้หุ่นยนต์ที่ติดตั้งเซ็นเซอร์ LiDAR ดังภาพที่ 2 โดยกำหนดค่า Coefficient of Friction ที่ 0.8 สำหรับการคำนวณแรงเสียดทานระหว่างพื้นและล้อของหุ่นยนต์เพื่อให้ไม่เกิดการลื่นไหล หุ่นยนต์ทำการสแกนพื้นที่และเก็บข้อมูลแผนที่ผ่านระบบ Cartographer ซึ่งช่วยในการสร้างแผนที่ 2 มิติของสภาพแวดล้อม ข้อมูลที่ได้รับรวมถึงรูปทรงของสภาพแวดล้อมได้รับการปรับแต่งให้คล้ายกับโครงสร้างห้องจริง โดยอ้างอิงจากข้อมูลใน [11] และปรับแต่งให้เหมาะสมกับการทดลองในห้องที่ออกแบบไว้ตามที่แสดงดังภาพที่ 3

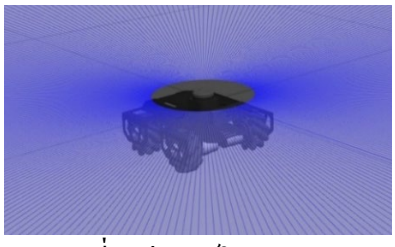

ภาพที่ 2: หุ่นยนต์ในการจำลอง

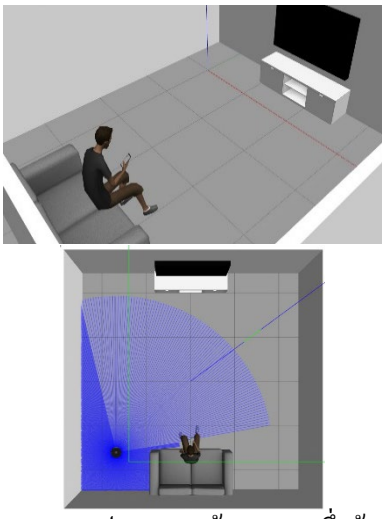

ภาพที่ 3: แสดงรูปแบบของห้องทดลองซึ่งอ้างอิงจากโครงสร้างของห้องนั่งเล่นจริง ก) มุมมองโดยรวม ข) มุมมองด้านบนของภาพรวม

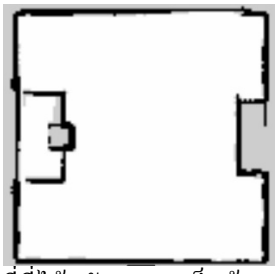

ภาพที่ 4: แผนที่ที่ได้หลังจากการเก็บข้อมูล (ไฟล์ภาพถูกหมุนตามแกน y 90°)

จากนั้น แผนที่ที่ได้จาก Cartographer ดังภาพที่ 4 จะถูกแปลงเป็นรูปแบบ Numerical Python Array และทำการ Sampling แผนที่เพื่อปรับขนาดให้เหมาะสมกับการคำนวณ เนื่องจากขนาดของหุ่นยนต์อยู่ที่ประมาณ 6×6 กริด จึงทำการปรับให้อยู่ในรูปแบบ 1×1 กริด เพื่อความสะดวกในการประมวลผล ดังภาพที่ 5 โดยรายละเอียดของข้อมูลจะถูกกำหนดตามที่แสดงในตารางที่ 1

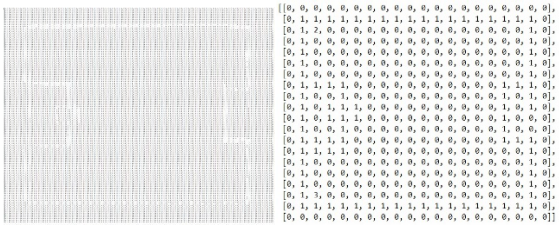

ภาพที่ 5: การ Sampling map

ตารางที่ 1: ความหมายของค่าต่างๆในแผนที่

Number	Description
0	พื้นที่ว่าง
1	สิ่งกีดขวาง
2	จุดเริ่มต้น, หุ่นยนต์

3.2 กำหนดพารามิเตอร์

กำหนดพารามิเตอร์ในการทดลองโดยจำลองให้หุ่นยนต์ใช้พลังงาน 30 วัตต์ (W) และกำหนดเวลาในการเคลื่อนที่ตามค่าที่แสดงในตารางที่ 2

ตารางที่ 2: ค่าเวลาที่ใช้ในการขยับต่างๆ

Movement	เวลา (วินาที)
Right	2
Forward	1
Left	2
Backwards	3

สมการพลังงานที่ใช้ในการคำนวณ

$$E = Pt \tag{25}$$

เมื่อ P แทน กำลังไฟฟ้า (วัตต์, W)

t แทน ระยะเวลาในการทำงาน (วินาที, s)

ซึ่งสามารถใช้ในการคำนวณพลังงานที่ใช้ เพื่อช่วยในการตัดสินใจด้านการวางแผนพลังงานของหุ่นยนต์

3.3 ทดสอบอัลกอริทึมกับแผนที่

ในการทดลองนี้ ได้ทำการทดสอบอัลกอริทึมทั้ง 3 รูปแบบ ได้แก่ Zig-Zag Algorithm (ภาพที่ 6), Wall-Follower Algorithm (ภาพที่ 7) และ Random Walk Algorithm (ภาพที่ 8) ตามลำดับ โดยใช้ A* Algorithm เป็นตัวช่วยในการหาเส้นทางในกรณีที่พบทางตันหรือไม่สามารถไปต่อได้ ทั้งนี้อัลกอริทึมทั้งหมดอ้างอิงจากโค้ดตัวอย่างใน [1] และทำการรันทั้งหมด 3 ครั้ง เพื่อประเมินประสิทธิภาพของแต่ละอัลกอริทึม

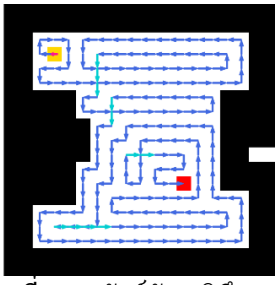

ภาพที่ 6: ผลลัพธ์อัลกอริทึม Zig-Zag

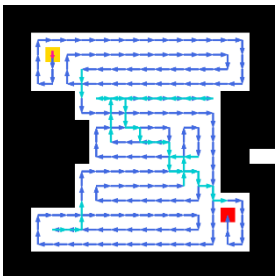

ภาพที่ 7: ผลลัพธ์อัลกอริทึม Wall-Follower

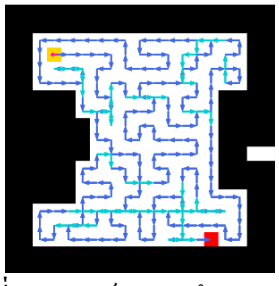

ภาพที่ 8: ผลลัพธ์อัลกอริทึม Random Walk

ค่าการทดลองที่แสดงในตารางที่ 3 สรุปผลการเคลื่อนที่ของหุ่นยนต์ทั้ง 3 รูปแบบ โดยแสดงให้เห็นว่าอัลกอริทึมทั้งหมดสามารถครอบคลุมพื้นที่ได้อย่างสมบูรณ์ อย่างไรก็ตาม ในกรณีของ Random Walk Algorithm ผลลัพธ์จากการรันทั้ง 3 รอบมีความแปรผันสูง เนื่องจากอัลกอริทึมอาศัยการสุ่มทิศทาง ส่งผลให้การใช้พลังงานเพิ่มขึ้น

สำหรับ Zig-Zag Algorithm และ Wall-Follower Algorithm แม้ว่าจะใช้ระยะเวลาและพลังงานเท่ากันในทั้ง 3 รอบ แต่มีความแตกต่างในประสิทธิภาพของการใช้ทรัพยากร โดย Zig-Zag Algorithm ใช้พลังงาน 7,440 J และใช้เวลาเพียง 248 วินาที รวมถึงเรียกใช้ A* Algorithm เพียง 11 ครั้ง ในขณะที่ Wall-Follower Algorithm ใช้พลังงาน 8,100 J และใช้เวลา 270 วินาที รวมถึงเรียกใช้ A* Algorithm มากถึง 37 ครั้ง

ดังนั้น สามารถสรุปข้อดีข้อเสียของแต่ละอัลกอริทึมสามารถดูได้จาก ตารางที่ 4 ซึ่งแสดงการเปรียบเทียบประสิทธิภาพของ Zig-Zag Algorithm, Random Walk Algorithm, และ Wall-Follower Algorithm ในแง่ของโครงสร้างการเคลื่อนที่, ประสิทธิภาพในการครอบคลุมพื้นที่, และข้อจำกัดในการใช้งาน รวมถึงสรุปกราฟเปรียบเทียบประสิทธิภาพของ Zig-Zag Algorithm กับอัลกอริทึมอื่น ๆ ได้ดังภาพที่ 9

ตารางที่ 3 : ผลการทดลองอัลกอริทึมทั้ง 3 แบบ

อัลกอริทึม	Time	เส้นทางเดินทั้งหมด	A* เดิน	อัตราครอบคลุม	เวลาที่ใช้ (sec)	พลังงาน J	การหมุน
Zig-Zag	1	190	11	100%	248	7440	53
	2	190	11	100%	248	7440	53
	3	190	11	100%	248	7440	53
Wall -Follower	1	213	37	100%	270	8100	48
	2	213	37	100%	270	8100	48
	3	213	37	100%	270	8100	48
Random Walk	1	219	52	100%	378	11340	135
	2	223	58	100%	365	10950	128
	3	216	53	100%	389	11670	148

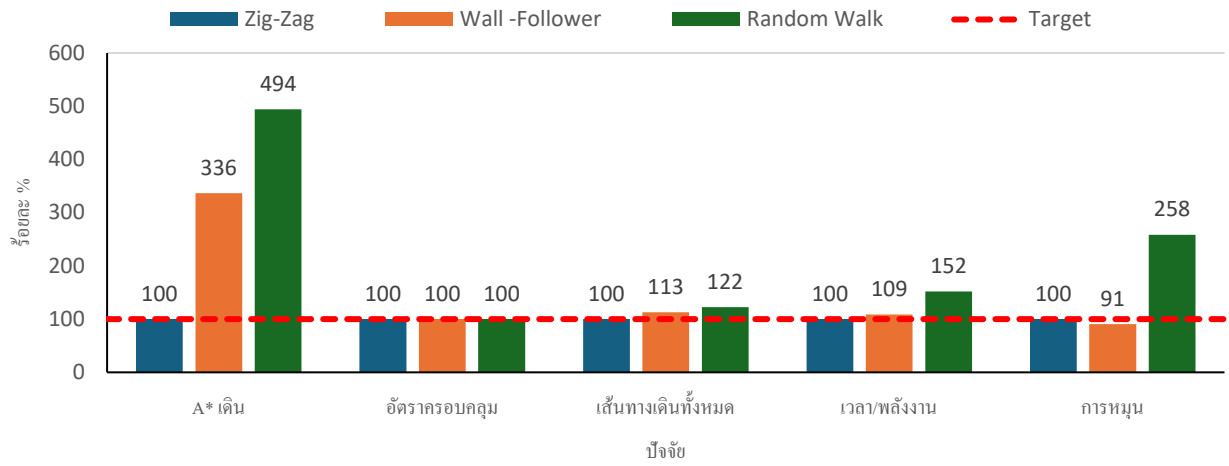

ภาพที่ 9: การเปรียบเทียบประสิทธิภาพของ Zig-Zag Algorithm กับอัลกอริทึมอื่น ๆ (ร้อยละ%)

ตารางที่ 4 : การเปรียบเทียบข้อดีและข้อจำกัดของแต่ละอัลกอริทึม

อัลกอริทึม	ข้อดี	ข้อจำกัด
Zig-Zag	1. มีโครงสร้างการเคลื่อนที่ที่เป็นระบบ 2. ลดการเดินซ้ำ ทำให้ครอบคลุมพื้นที่ได้อย่างมีประสิทธิภาพ 3. ใช้พลังงานต่ำกว่าการเคลื่อนที่แบบสุ่ม	1. ใช้งานได้ไม่ดีในพื้นที่ที่มีสิ่งกีดขวางจำนวนมาก 2. ต้องมีพื้นที่เปิดที่สามารถเคลื่อนที่เป็นแนวขนานได้
Wall -Follower	1. สามารถใช้งานได้ในพื้นที่ที่ไม่มีโครงสร้างตายตัว 2. ปรับตัวได้ดีกับสภาพแวดล้อมที่ซับซ้อน	1. ใช้เวลานานกว่าที่จะสำรวจพื้นที่ทั้งหมด 2. สิ้นเปลืองพลังงานเนื่องจากไม่มีเส้นทางที่แน่นอน
Random Walk	1. เหมาะสำหรับพื้นที่ที่มีผนังหรือสิ่งกีดขวาง 2. สามารถใช้ในการสำรวจเขาวงกตหรือพื้นที่ที่มีทางเดินแคบ	1. ใช้ไม่ได้ผลในพื้นที่โล่งที่ไม่มีขอบกำแพง 2. อาจเกิดการติดลูป (looping behavior) ในบางสภาพแวดล้อม

4. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาและทดสอบอัลกอริทึมการวางแผนเส้นทางให้หุ่นยนต์สามารถครอบคลุมพื้นที่ได้อย่างมีประสิทธิภาพ โดยพิจารณาความเร็วในการทำงานและการใช้พลังงานของแต่ละอัลกอริทึม

ผลการทดลองแสดงให้เห็นว่าอัลกอริทึมทั้งหมดสามารถทำให้หุ่นยนต์ครอบคลุมพื้นที่เป้าหมายได้สำเร็จ อย่างไรก็ตาม Zig-Zag Algorithm เป็นอัลกอริทึมที่มีประสิทธิภาพมากที่สุดในการลดการเดินซ้ำ ใช้พลังงานต่ำสุดที่ 7,440 J และใช้เวลาเพียง 248 วินาที ในขณะที่ Wall-Follower Algorithm แม้จะสามารถสำรวจพื้นที่ได้เช่นกัน แต่ใช้พลังงานมากกว่าที่ 8,100 J และใช้เวลานานขึ้นที่ 270 วินาที เนื่องจากต้องอาศัยเส้นขอบในการเคลื่อนที่ ขณะที่ Random Walk Algorithm มีความแปรปรวนของผลลัพธ์สูงที่สุด เนื่องจากการสุ่มทิศทางทำให้เส้นทางที่เกิดขึ้นมีความไม่แน่นอน ส่งผลให้ใช้พลังงานสูงสุดในบางกรณี

นอกจากนี้ การใช้ A* Algorithm ช่วยในการตัดสินใจเมื่อพบทางตันหรือสิ่งกีดขวาง ทำให้การสำรวจเส้นทางมีความต่อเนื่องและลดเวลาที่สูญเปล่า โดย Zig-Zag Algorithm เรียกใช้ A* Algorithm น้อยที่สุดเพียง 11 ครั้ง ขณะที่ Wall-Follower Algorithm ใช้มากถึง 37 ครั้ง ซึ่งแสดงให้เห็นว่าอัลกอริทึมที่มีโครงสร้างเส้นทางชัดเจนกว่ามีแนวโน้มที่จะพึ่งพา A* Algorithm น้อยลง

ดังนั้น จากผลการทดลองสามารถสรุปได้ว่า Zig-Zag Algorithm เหมาะสำหรับพื้นที่ที่ต้องการความแม่นยำและการประหยัดพลังงาน ขณะที่ Wall-Follower Algorithm อาจเหมาะกับสภาพแวดล้อมที่มีโครงสร้างแน่นอน ส่วน Random Walk Algorithm แม้จะมีความยืดหยุ่นสูง แต่มีข้อจำกัดในเรื่องของความไม่แน่นอนของเส้นทางที่เกิดขึ้น

5. ข้อเสนอแนะ

งานวิจัยนี้ยังสามารถปรับใช้กับเทคนิค AI-based path optimization เพื่อเพิ่มประสิทธิภาพในการวางแผนเส้นทางให้หุ่นยนต์สามารถปรับตัวตามการเปลี่ยนแปลงของสภาพแวดล้อมได้อย่างมีประสิทธิภาพ โดยสามารถนำไปประยุกต์ใช้ร่วมกับระบบนำทาง Navigation และระบบ

SLAM (Simultaneous Localization and Mapping) ซึ่งใช้ Global cost map และ Local cost map ในการหลีกเลี่ยงอุปสรรคแบบเรียลไทม์

นอกจากนี้ยังสามารถนำผลการทดลองในงานวิจัยนี้ไปต่อยอดเพื่อพัฒนาผลิตภัณฑ์ต้นแบบหุ่นยนต์ในเชิงพาณิชย์ ซึ่งมีต้นทุนต่ำและสามารถแข่งขันในอุตสาหกรรมได้

6. กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จได้ด้วยการสนับสนุนจาก คณาจารย์จากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ และมหาวิทยาลัยเทคโนโลยีสุรนารี ที่ให้คำแนะนำและข้อเสนอแนะตลอดกระบวนการวิจัย

ขอขอบคุณ ภาควิชาเครื่องกล คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ สำหรับการสนับสนุนด้านสถานที่และอุปกรณ์ รวมถึง บริษัท ทีอีเอสอาร์ จำกัด ที่ให้การสนับสนุนข้อมูลด้านผลิตภัณฑ์และโค้ดตัวอย่าง [1] ซึ่งเป็นประโยชน์ต่อการพัฒนาและทดลอง

นอกจากนี้ ขอขอบคุณ เพื่อนร่วมงานและผู้ที่เกี่ยวข้องทุกท่าน ที่ให้ความช่วยเหลือและข้อเสนอแนะที่เป็นประโยชน์ต่อการดำเนินงานวิจัย

7. เอกสารอ้างอิง

[1] Rodrigues R. Coverage path planning [Internet]. 2021 [cited 2025 Mar 9]. Available from: https://github.com.

[2] Corke P. Robotics, Vision, and Control: Fundamental Algorithms in MATLAB. 2017. Springer.

[3] Galceran E, Carreras M. A survey on coverage path planning for robotics. Robotics and Autonomous Systems. 2013; 61(12):1258-1276.

[4] Klancar G, et al. Wheeled mobile robotics: from fundamentals towards autonomous systems. Elsevier; 2017.

[5] LaValle SM. Planning Algorithms. Cambridge University Press; 2006.

[6] Song J, Gupta S. An online coverage path planning algorithm. IEEE Transactions on Robotics. 2018; 34(2):526-533.

[7] Tan CS, et al. A comprehensive review of coverage path planning in robotics using classical and heuristic algorithms. IEEE Access. 2021; 9:119310-119342.

[8] Zhao S, Hwang SH. Complete coverage path planning scheme for autonomous navigation ROS-based robots. ICT Express. 2024; 10(1):83-89.

[9] TESR Shop. Iron X หุ่นยนต์ฝึกทักษะ ROS Mobile Robot with Mecanum wheels สายพันธุ์ไทยเพื่อการศึกษา [Internet]. 2025 [cited 2025 Mar 9]. Available from: https://www.tesrshop.com.

[10] Research and Markets. Cleaning Robot Market by Type, by Product, by Application, and by Region - Global Forecast to 2026 [Internet]. 2025 [cited 2025 Mar 9]. Available from: https://www.researchandmarkets.com

[11] Gazebo. Gazebo Fuel: Model repository [Internet]. 2025 [cited 2025 Mar 9]. Available from: https://app.gazebosim.org/fuel/models

การตรวจจับความเสียหายประเภทหลุมบ่อบนถนนลาดยางด้วยเทคนิคคอมพิวเตอร์วิทัศน์เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา

Detection of Pothole Damages on Asphalt Roads Using Computer Vision Technique for Supporting Maintenance Cost Estimation

ยศพนธ์ โนนจุ้ย* ดำรงศักดิ์ รินชุมภู ธีรศักดิ์ ปัญญาภิรวัฒน์ กิตติคุณ จิตไพโรจน์ นิธิยา คำแก้ว

สาขาวิชาวิศวกรรมและบริหารก่อสร้าง คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่

(**yotsaphon_n@cmu.ac.th*)

บทคัดย่อ

ความเสียหายของถนน โดยเฉพาะหลุมบ่อ เป็นปัญหาด้านโครงสร้างพื้นฐานที่ส่งผลต่อการคมนาคมและความปลอดภัยของประชาชน วิธีการตรวจสอบและซ่อมแซมแบบดั้งเดิมที่ใช้การตรวจสอบด้วยสายตาและการวัดขนาดด้วยมือนั้นใช้เวลานานและมีข้อผิดพลาด ปัจจุบัน เทคโนโลยีปัญญาประดิษฐ์ (AI) โดยเฉพาะด้านการประมวลผลภาพ ได้แสดงศักยภาพในการตรวจจับและวิเคราะห์ความเสียหายของถนน งานวิจัยนี้พัฒนาระบบเพื่อตรวจจับหลุมบ่อบนถนนลาดยาง เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา การประเมินต้นทุนบำรุงรักษาถนนจำเป็นต้องอาศัยข้อมูลเกี่ยวกับตำแหน่งและขนาดของหลุมบ่อ ซึ่งต้องใช้โมเดลที่มีความแม่นยำสูงในการตรวจจับ งานวิจัยนี้มุ่งเน้นไปที่การตรวจจับหลุมบ่อโดยใช้เทคนิคการแบ่งส่วนภาพ (Segmentation) เพื่อให้สามารถระบุพื้นที่ของหลุมได้อย่างครอบคลุม แทนที่จะใช้เพียงการระบุตำแหน่งด้วย bounding box วิธีนี้ช่วยให้การวิเคราะห์และประมาณราคาค่าซ่อมแซมมีความถูกต้องมากขึ้น งานวิจัยนี้มุ่งเน้นที่การตรวจจับและแยกพื้นที่หลุมออกจากพื้นถนน โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) และอัลกอริทึม YOLOv8 ในการประมวลผลภาพ วิธีการวิจัยประกอบด้วยการเก็บรวบรวมภาพถนน สร้างชุดข้อมูลที่ติดป้ายกำกับหลุมบ่อ และฝึกโมเดลเพื่อตรวจจับและแยกพื้นที่ของหลุม โดยโมเดลที่พัฒนาขึ้นให้ค่า Precision 0.768 Recall 0.687 map50 0.748 map50-95 0.443 ซึ่งแสดงถึงความแม่นยำในการตรวจจับ ผลลัพธ์ที่คาดหวังคือระบบที่มีประสิทธิภาพและแม่นยำในการตรวจจับหลุมบ่อ ซึ่งช่วยลดเวลาและทรัพยากรในการบำรุงรักษาถนน ช่วยวางแผนงบประมาณและจัดสรรทรัพยากร และยั่งยืนมากขึ้น

คำสำคัญ: ความเสียหายของถนน,หลุมบ่อ,ปัญญาประดิษฐ์

Abstract

Road damage, particularly potholes, is a significant infrastructure issue that affects transportation and public safety. Traditional inspection and repair methods, which rely on visual checks and manual measurements, are time-consuming and prone to errors. Currently, artificial intelligence (AI), especially in image processing, has demonstrated potential in detecting and analyzing road damage. This research develops an automated system using AI to detect potholes on asphalt roads, supporting cost estimation for maintenance. Cost estimation for road maintenance requires accurate data on the location and size of potholes, necessitating a highly accurate detection model. This research focuses on pothole detection using image segmentation techniques to comprehensively identify the area of potholes, rather than just locating them with bounding boxes. This approach enhances the accuracy of analysis and cost estimation for repairs. The research emphasizes detecting and isolating pothole areas from the road surface using deep learning techniques and the YOLOv8 algorithm for image processing. The methodology includes collecting road images, creating a labeled dataset of potholes, and training the model to detect and segment pothole areas. The developed model achieves a Precision of 0.768 a Recall of 0.687 map50 0.748 map50-95 0.443, indicating high detection accuracy. The

expected outcome is an efficient and accurate system for detecting potholes, reducing time and resources for road maintenance, aiding budget planning and resource allocation, and promoting safer and more sustainable transportation systems.

Keywords: Pothole, Road damage, AI

1. บทนำ

ความเสียหายของถนนเป็นปัญหาโครงสร้างพื้นฐานที่สำคัญซึ่งส่งผลกระทบต่อการคมนาคมและความปลอดภัยของประชาชน โดยความเสียหายอาจเกิดได้จากหลายสาเหตุ เช่น การเสื่อมสภาพตามอายุการใช้งาน สภาพภูมิอากาศ ปริมาณการจราจรที่หนาแน่น หรือการก่อสร้างที่ไม่ได้มาตรฐาน ลักษณะความเสียหายที่พบได้บ่อยประกอบด้วย การแตกร้าว การทรุดตัว การเกิดหลุม และการสึกกร่อนของผิวถนน ซึ่งปัญหาเหล่านี้ไม่เพียงส่งผลต่อความสะดวกในการเดินทาง แต่ยังอาจก่อให้เกิดอุบัติเหตุและความเสียหายต่อยานพาหนะ จากข้อมูลงบประมาณประจำปีของกรมทางหลวงชนบทในปี 2566 พบว่ามีการจัดสรรงบประมาณสำหรับการซ่อมแซมและบำรุงรักษาถนนสูงถึง 26,000 ล้านบาท [1] ซึ่งแสดงให้เห็นถึงความสำคัญและค่าใช้จ่ายที่สูงในการจัดการปัญหานี้

ถนนสามารถแบ่งออกตามชนิดของผิวทางได้ 3 แบบ คือ 1. ผิวทางลูกรัง 2. ผิวทางลาดยาง 3. ผิวทางคอนกรีต จากข้อมูลสถิติระยะทางถนนในความรับผิดชอบของกระทรวงคมนาคมรายปี พบว่าตั้งแต่ปี พ.ศ. 2557 ถึงปี พ.ศ. 2566 ชนิดผิวทางลาดยางมีระยะทางรวมมากที่สุด [2] ด้วยเหตุนี้ ผิวทางลาดยางจึงมีบทบาทสำคัญในโครงสร้างพื้นฐานของประเทศทั้งในด้านการเชื่อมโยงการคมนาคมและการพัฒนาเศรษฐกิจ ในขณะเดียวกันก็ต้องให้ความสำคัญกับการดูแลบำรุงรักษาอย่างต่อเนื่องเพื่อลดปัญหาความเสียหายและยืดอายุการใช้งานของถนนให้ยาวนานที่สุด

ข้อมูลจากสำนักวิเคราะห์วิจัยและพัฒนางานทาง ของกรมทางหลวง กล่าวว่า กรมทางหลวงได้ใช้วิธีของ The Asphalt Institute หน่วยงานของสหรัฐอเมริกา สำหรับการออกแบบถนนในประเทศไทยมาเป็นระยะเวลานาน อีกทั้งยังแบ่งประเภทความเสียหายผิวทางลาดยาง เป็น 4 ประเภทใหญ่ ดังต่อไปนี้ 1. รอยแตก 2. การเปลี่ยนรูปร่าง (Distortion) 3. การหลุดร่อนเกิดเป็นหลุมบ่อ (Disintegration) 4. ผิวทางเปลี่ยนคุณสมบัติ (Surface Defect) และจากงานวิจัยพบว่าปัญหาความเสียหายของถนนประเภทหลุมบ่อมีความรุนแรงและเสี่ยงต่อการเกิดอุบัติเหตุมากที่สุด [3,4]

การตรวจสอบและซ่อมแซมความเสียหายของถนนแบบดั้งเดิมนั้นต้องอาศัยการสำรวจด้วยสายตาและการวัดขนาดด้วยมือ ซึ่งเป็นกระบวนการที่ใช้เวลานาน อาจเกิดความคลาดเคลื่อน และมีข้อจำกัดในการประเมินค่าใช้จ่ายการซ่อมแซมอย่างแม่นยำ นอกจากนี้ วิธีการดั้งเดิมยังไม่สามารถครอบคลุมพื้นที่ได้ทั้งหมดเนื่องจากข้อจำกัดด้านทรัพยากรบุคคลและเวลา ทำให้บางพื้นที่อาจถูกมองข้ามหรือได้รับการแก้ไขล่าช้า

ในปัจจุบัน เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) ได้เข้ามามีบทบาทสำคัญในการพัฒนาและปรับปรุงประสิทธิภาพการทำงานในหลากหลายด้าน โดยเฉพาะอย่างยิ่งในด้านการประมวลผลภาพ (Image Processing) มีการใช้เทคนิคการตรวจจับวัตถุแบบเรียลไทม์ที่มีชื่อว่า You Only Look Once (YOLO) [5,6] โดยเทคนิคนี้ได้รับแรงบันดาลใจจากโครงข่ายประสาทเทียม ซึ่งใช้หลักการแบ่งภาพออกเป็นส่วนย่อย ๆ และทำนายขอบเขตพร้อมทั้งความน่าจะเป็นของแต่ละส่วน โครงข่ายจะสร้างกรอบล้อมรอบวัตถุตามค่าความน่าจะเป็นที่คาดการณ์ไว้ซึ่งสามารถนำมาประยุกต์ใช้ในการตรวจจับและวิเคราะห์ความเสียหายของโครงสร้างพื้นฐานได้อย่างมีประสิทธิภาพ

โดยปกติแล้ว การตรวจจับความเสียหายของถนนในงานวิจัยที่ผ่านมาส่วนใหญ่มักใช้ Bounding Box ในการระบุตำแหน่งความเสียหาย [7-9] ซึ่งเป็นวิธีที่สามารถตรวจจับวัตถุได้อย่างรวดเร็วแต่ไม่สามารถกำหนดขอบเขตของพื้นที่ความเสียหายได้อย่างแม่นยำ นอกจากนี้ การตรวจจับในลักษณะเดิมยังไม่สามารถนำไปพัฒนาเพื่อหาขนาดของความเสียหายได้อย่างชัดเจน ทำให้เกิดข้อจำกัดในการนำไปใช้วิเคราะห์และประมาณต้นทุนการซ่อมแซม

ดังนั้น งานวิจัยนี้จึงมุ่งเน้นการพัฒนาระบบตรวจจับความเสียหายของถนนแบบ Segmentation ซึ่งแตกต่างจากการใช้ Bounding Box ทั่วไป โดยการใช้ Segmentation จะช่วยให้สามารถระบุขอบเขตของพื้นที่ที่ได้รับความเสียหายได้อย่างชัดเจน ซึ่งเป็นข้อมูลสำคัญสำหรับการประเมินต้นทุนการซ่อมแซมได้อย่างแม่นยำมากขึ้น โดยในงานวิจัยนี้จะมุ่งเน้นการตรวจจับเฉพาะความเสียหายประเภทหลุมบ่อ ซึ่งเป็นประเภทที่มีความรุนแรงสูงและก่อให้เกิดอันตรายต่อการสัญจร เพื่อให้สามารถใช้ผลการตรวจจับไปสนับสนุนการคิดต้นทุนการบำรุงรักษาได้อย่างมีประสิทธิภาพมากขึ้น

งานวิจัยนี้จึงมุ่งเน้นการพัฒนาระบบอัตโนมัติโดยใช้เทคโนโลยี AI ในการตรวจจับหลุมบนถนน เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา โดยระบบนี้จะช่วยลดข้อจำกัดของวิธีการดั้งเดิม เพิ่มความแม่นยำในการตรวจสอบและลดเวลาในการประเมินความเสียหาย ซึ่งจะส่งผลให้การบำรุงรักษาถนนมีประสิทธิภาพมากขึ้น และช่วยลดค่าใช้จ่ายในระยะยาว

2. วิธีการวิจัย

การตรวจจับความเสียหายประเภทหลุมบ่อบนถนนลาดยาง มีวิธีดำเนินงานวิจัยหลักประกอบด้วย 1. การเก็บรวบรวมข้อมูลภาพความเสียหายของผิวถนนประเภทหลุมบ่อ 2. การจัดทำโมเดลสำหรับการตรวจจับหลุมบ่อ 3. การประเมินความแม่นยำ ซึ่งสามารถแสดงขั้นตอนการวิจัยได้ดังนี้

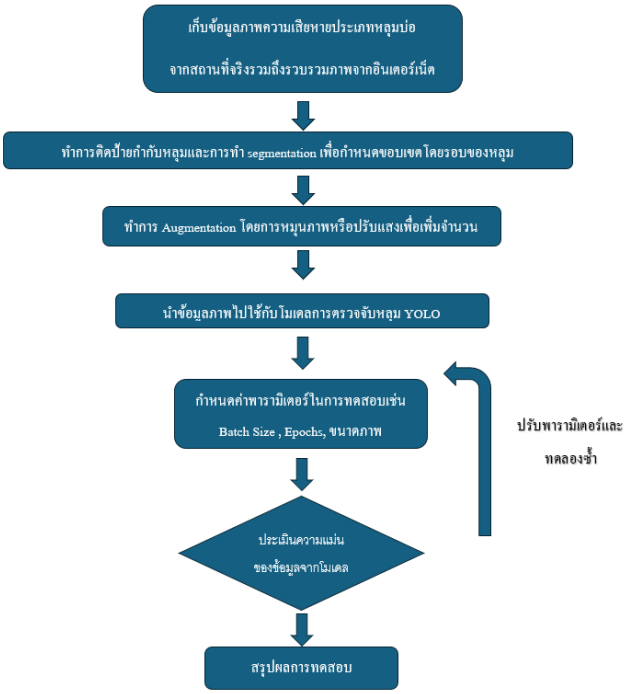

2.1 การเก็บรวบรวมข้อมูลภาพความเสียหายของผิวถนนประเภทหลุมบ่อ

เลือกพื้นที่สำหรับเก็บข้อมูล กำหนดพื้นที่เป้าหมายภายในบริเวณมหาวิทยาลัยเชียงใหม่ โดยศึกษาหลุมบ่อที่พบบริเวณถนนลาดยาง ใช้กล้องถ่ายภาพ ที่ติดตั้งบนยานพาหนะหรืออุปกรณ์มือถือ

2.2 การจัดทำโมเดลสำหรับการตรวจจับหลุมบ่อ

ทำการรวบรวมรูปภาพหลุมบ่อบนถนนลาดยางที่ได้ทั้งจากการเก็บข้อมูลจริงและการสืบค้นข้อมูลภาพถ่ายหลุมบ่อจากแหล่งข้อมูลต่างๆรวมจำนวน 300 รูปภาพ

2.2.1 การนำภาพหลุมมาติดป้ายกำกับ (Labeling) และการเพิ่มจำนวนข้อมูลภาพ

ขั้นตอนการติดป้ายกำกับ (Labeling) เป็นกระบวนการสำคัญในการเตรียมข้อมูลสำหรับการฝึกโมเดลการเรียนรู้ของเครื่อง (Machine Learning) โดยเฉพาะในงานด้าน Computer Vision ซึ่งในกรณีนี้คือการตรวจจับและจำแนกหลุมบ่อบนพื้นผิว การติดป้ายกำกับจะทำโดยการกำหนดตำแหน่งและขนาดของหลุมบ่อในรูปแบบ Segmentation ซึ่งเป็นการลากเส้นล้อมรอบบริเวณขอบของหลุมอย่างแม่นยำ เพื่อให้โมเดลสามารถเรียนรู้ลักษณะและรูปร่างของหลุมได้อย่างมีประสิทธิภาพ หลังจากที่ภาพถูกติดป้ายกำกับเรียบร้อยแล้ว ขั้นตอนต่อไปคือการเพิ่มจำนวนข้อมูลภาพ (Data Augmentation) เพื่อขยายชุดข้อมูลให้มีขนาดใหญ่ขึ้นและหลากหลายมากขึ้น ซึ่งจะช่วยป้องกันปัญหา Overfitting และเพิ่มความแม่นยำของโมเดล การเพิ่มจำนวนข้อมูลภาพทำได้โดยการสร้างภาพใหม่จากภาพต้นฉบับผ่านเทคนิคต่าง ๆ เช่น การหมุนภาพ (Rotation) ในมุมต่าง ๆ เพื่อให้โมเดลสามารถเรียนรู้หลุมบ่อในทิศทางที่หลากหลาย การปรับแสง (Brightness Adjustment) ปรับระดับความสว่างของภาพเพื่อให้โมเดลสามารถทำงานได้ดีในสภาพแสงที่แตกต่างกัน การพลิกภาพ (Flipping) ในแนวนอนหรือแนวตั้งเพื่อสร้างมุมมองใหม่ การเพิ่มจำนวนข้อมูลภาพด้วยเทคนิคเหล่านี้จะช่วยให้โมเดลสามารถทำงานได้ดีแม้ในสภาพแวดล้อมที่แตกต่างกันออกไป ซึ่งเป็นขั้นตอนสำคัญในการพัฒนาระบบอัตโนมัติสำหรับการตรวจจับหลุมบ่ออย่างมีประสิทธิภาพ

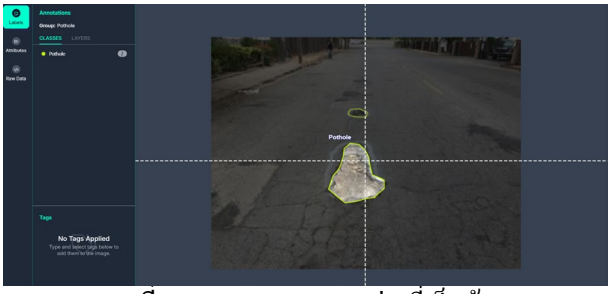

ภาพที่ 1: การ Labeling ภาพถ่ายที่เก็บข้อมูลมา

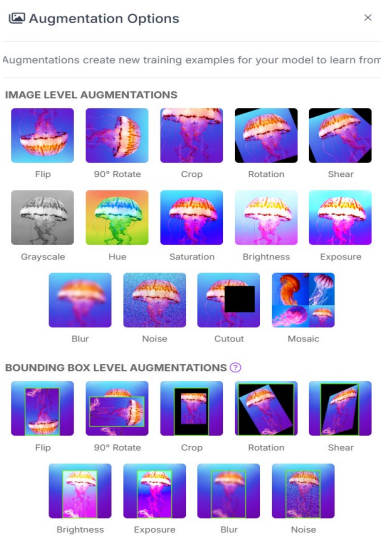

ภาพที่ 2: การAugmentation เพื่อเพิ่มจำนวนรูปภาพ

2.2.2 การตรวจจับหลุมบ่อโดยใช้ Yolov8

ในการทดสอบครั้งนี้ ได้เลือกใช้โมเดล YOLOv8 (You Only Look Once version 8) ซึ่งเป็นโมเดลที่ทันสมัยและมีประสิทธิภาพสูงในงาน Object Detection และ Segmentation โดยเฉพาะการตรวจจับวัตถุในภาพแบบ Real-Time การทดสอบดำเนินการบน Google Colab ซึ่งเป็นแพลตฟอร์มที่ให้บริการทรัพยากรการประมวลผลแบบคลาวด์ การใช้ Google Colab ช่วยลดข้อจำกัดด้านฮาร์ดแวร์และทำให้การ

ทดลองทำได้สะดวกขึ้น เพื่อให้โมเดล YOLOv8 ทำงานได้อย่างมีประสิทธิภาพ จำเป็นต้องกำหนด Hyperparameters ต่างๆดังนี้ 1). Batch Size คือจำนวนภาพที่ป้อนให้โมเดลในแต่ละขั้นตอนการฝึก ในที่นี้ได้ทดสอบกับ Batch Size 10, 15 และ 30 เพื่อศึกษาผลกระทบต่อประสิทธิภาพของโมเดล 2). Epochs คือจำนวนรอบการฝึกโมเดล โดยได้ทดสอบกับ 150 และ 200 Epochs เพื่อดูว่าจำนวนรอบการฝึกที่มากขึ้นจะส่งผลต่อความแม่นยำของโมเดลอย่างไร 3). ขนาดภาพที่ใช้ทดสอบซึ่งมีผลต่อความแม่นยำและความเร็วในการประมวลผล โดยได้ทดสอบกับขนาดภาพ 320x320 และ 640x640 พิกเซล

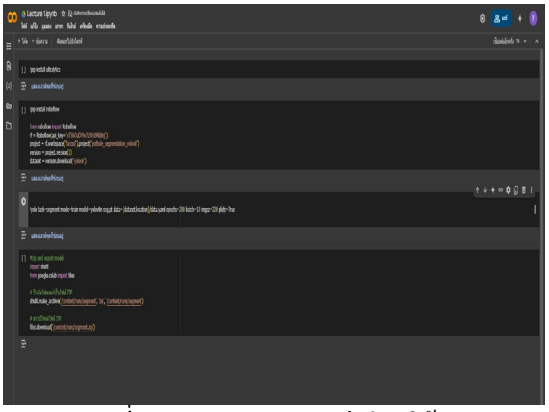

ภาพที่ 3: การตรวจจับหลุมบ่อโดยใช้ Yolov8

2.3 การประเมินความแม่นยำ

ทำการเปรียบเทียบผลลัพธ์จากการใช้ Yolov8 โดยมีเกณฑ์การประเมินประสิทธิภาพของโมเดลด้วยชุดทดสอบ (Test Set) ซึ่งเป็นข้อมูลที่โมเดลไม่เคยเห็นมาก่อน ในขั้นตอนนี้ เพื่อประเมินประสิทธิภาพของโมเดล เช่น Precision หรือ Positive Predictive Value (ค่าความแม่นยำ) เป็นการเปรียบเทียบการทำนายที่ถูกต้องว่าเป็นจริงและก็เกิดขึ้นจริง (TP) กับ การทำนายว่าจริงแต่สิ่งที่เกิดขึ้นกลับไม่จริง (FP) Sensitivity หรือ Recall เป็นความถูกต้องของการทำนายว่าจะเป็นจริง mAP50 (Mean Average Precision ที่ IoU Threshold 0.5) เป็นค่าเฉลี่ยของ Precision ที่ IoU (Intersection over Union) Threshold 0.5 ซึ่งหมายความว่าการทำนายจะถูกนับว่าถูกต้องหากพื้นที่ที่ทำนายทับซ้อนกับพื้นที่จริงมากกว่า 50% และค่า mAP50-95 (Mean Average Precision ที่ IoU Threshold 0.5 ถึง 0.95) เป็นค่าเฉลี่ยของ Precision ที่ IoU Threshold ตั้งแต่ 0.5 ถึง 0.95 โดยเพิ่มขั้นตอนการคำนวณที่ละเอียดขึ้น[10] หากผลลัพธ์ยังไม่เป็นที่น่าพอใจ สามารถปรับปรุงโมเดลได้โดยการ ปรับ Hyperparameters ต่างๆ ข้างต้น

3. ผลการวิจัยและอภิปรายผล

จากการดำเนินการตามวิธีวิจัยสามารถสรุปการทำงานเป็นประกอบด้วย 1.จำนวนภาพจากการทำ Augmentation 2 ผลการตรวจจับหลุมบ่อบนถนนลาดยาง

3.1 จำนวนภาพจากการทำ Augmentation

จากภาพต้นฉบับจำนวน 300 ภาพ เมื่อทำการ Augmentation โดยการหมุนภาพในมุมต่างๆ และการปรับค่าความสว่างและสีของภาพ จะได้ภาพใหม่รวมจำนวน 780 ภาพ

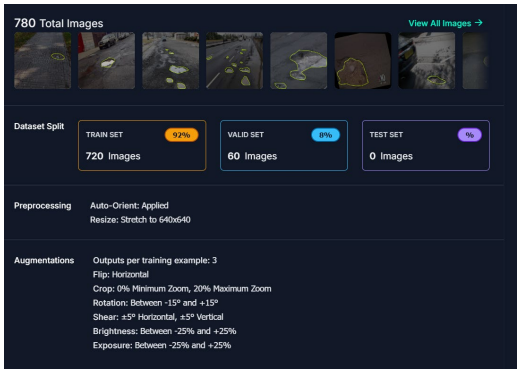

ภาพที่ 4: จำนวนภาพจากการทำ Augmentation

3.2 ผลการตรวจจับหลุมบ่อบนถนนลาดยาง

ในการใช้ภาพหลังจากการ Augmentation นำมาทดสอบกับ Yolov8 ที่กำหนดค่า Hyperparameters แตกต่างกันไป โดยใช้ภาพชุดเดียวกันทั้งหมด และปรับค่าต่างๆ ได้แก่ จำนวน Epochs จำนวน Batch ของรูปภาพ ขนาดความละเอียดของภาพ

ตารางที่ 1: ผลการทดสอบการตรวจจับหลุมบ่อ

Dataset	Epochs	จำนวน Batch	ขนาดภาพที่ใช้ทดสอบ(Pixel)	Precision	Recall	mAP50	map50-95
1	150	15	320	0.668	0.682	0.705	0.426
2	150	30	640	0.653	0.657	0.693	0.431
3	200	10	320	0.682	0.687	0.721	0.426
4	200	15	320	0.768	0.657	0.748	0.443
5	200	30	640	0.745	0.642	0.701	0.437

จากตารางในส่วนของ Dataset 4 ภาพรวมให้ผลลัพธ์ที่ดีที่สุดในหลายเมตริก ค่า Precision สูงสุดอยู่ที่ 0.768 (Dataset 4) ซึ่งหมายความว่าโมเดลมีความแม่นยำสูงในการตรวจจับหลุมบ่อ โดยมีสัดส่วนของผลลัพธ์ที่ถูกต้องสูง ค่า Recall สูงสุดอยู่ที่ 0.687 (Dataset 3) ซึ่งบ่งชี้ว่าโมเดลสามารถตรวจจับหลุมบ่อได้ครอบคลุม ค่า mAP50 สูงสุดอยู่ที่ 0.748 (Dataset 4) ซึ่งแสดงว่าโมเดลมีประสิทธิภาพโดยรวมที่ดีในการตรวจจับหลุมบ่อที่ระดับ IoU 0.5 ค่า mAP50-95 สูงสุดอยู่ที่ 0.443 (Dataset 4) ซึ่งบ่งชี้ถึงประสิทธิภาพของโมเดลในการตรวจจับหลุมบ่อที่ระดับ IoU ตั้งแต่ 0.5 ถึง 0.95 การเพิ่มจำนวน Epochs จาก 150 เป็น 200 ช่วยเพิ่มประสิทธิภาพของโมเดลในบางกรณี เช่น Dataset 3 และ Dataset 4 ที่มีค่า Precision และ mAP50 สูงขึ้น การเพิ่ม Batch Size จาก 15 เป็น 30 ไม่ได้ส่งผลให้ประสิทธิภาพของโมเดลดีขึ้นเสมอไป ตัวอย่างเช่น Dataset 2 และ Dataset 5 ที่มี Batch Size 30 มีค่า Precision และ Recall ต่ำกว่า Dataset ที่มี Batch Size น้อยกว่า ส่วนการใช้ภาพขนาด 640 พิกเซล (Dataset 2 และ Dataset 5) ไม่ได้ให้ผลลัพธ์ที่ดีกว่าการใช้ภาพขนาด 320 พิกเซล (Dataset 1, 3, และ 4) ในแง่ของ Precision และ Recall

ภาพที่ 5: ตัวอย่างการใช้โมเดลในการตรวจจับหลุม

ในการทดสอบพบว่ามีความผิดพลาดในการตรวจจับหลุม False Positive (FP) จะเกิดขึ้นเมื่อโมเดลตรวจจับวัตถุที่เป็นหลุมบ่อผิดพลาด เช่น ตรวจจับรอยแตกหรือรอยเปื้อนบนถนนเป็นหลุมบ่อ ซึ่งส่งผลให้ค่า Precision ลดลง ในการทดสอบพบว่า Dataset 4 มีค่า Precision สูงสุดที่ 0.768 ซึ่งแสดงว่าโมเดลมีความแม่นยำสูง แต่ยังมีโอกาสเกิด False Positive ได้จากวัตถุที่มีลักษณะคล้ายหลุมบ่อ ส่วน False Negative (FN) เกิดขึ้นเมื่อโมเดลไม่สามารถตรวจจับหลุมบ่อที่ปรากฏในภาพได้ ซึ่งส่งผลให้ค่า Recall ลดลง ในการทดสอบพบว่า Dataset 3 มีค่า Recall สูงสุดที่ 0.687 ซึ่งบ่งชี้ว่าโมเดลสามารถตรวจจับหลุมบ่อได้ครอบคลุม แต่ยังมีโอกาสเกิด False Negative ได้จากหลุมขนาดเล็กหรือหลุมที่มีรูปร่างซับซ้อน ผลการวิจัยนี้มีศักยภาพสูงในการนำไปใช้จริงเพื่อสนับสนุนการบำรุงรักษาถนนและการจัดการโครงสร้างพื้นฐาน โดยสามารถนำโมเดล YOLOv8 ไปใช้ในระบบอัตโนมัติสำหรับการตรวจจับหลุมบ่อบนถนน ซึ่งจะช่วยลดเวลาและค่าใช้จ่ายในการสำรวจด้วยวิธีดั้งเดิม

สำหรับการพัฒนางานวิจัยในอนาคต การใช้โมเดล YOLOv8 ร่วมกับระบบบริหารจัดการถนนของหน่วยงานภาครัฐสามารถนำไปประยุกต์ใช้ได้หลายรูปแบบ เพื่อเพิ่มประสิทธิภาพในการบำรุงรักษาถนนและจัดการโครงสร้างพื้นฐาน ตัวอย่างเช่นการตรวจสอบสภาพถนนอัตโนมัติ หน่วยงานภาครัฐสามารถติดตั้งกล้องบนยานพาหนะที่ใช้ในการตรวจสอบถนน (เช่น รถตรวจสภาพถนนของกรมทางหลวง) เพื่อถ่ายภาพถนนในพื้นที่ต่าง ๆ และใช้โมเดลตรวจจับความเสียหายของถนนแบบอัตโนมัติ ซึ่งช่วยให้สามารถตรวจสอบและบันทึกข้อมูลได้อย่างต่อเนื่อง ลดความจำเป็นในการใช้บุคลากรสำรวจหน้างาน การพัฒนาระบบแจ้งเตือนภัยสำหรับผู้ใช้ถนน เมื่อสามารถตรวจจับหลุมบนถนนได้แบบเรียลไทม์ ระบบสามารถส่งข้อมูลไปยังแอปพลิเคชันหรือแพลตฟอร์มออนไลน์เพื่อแจ้งเตือนผู้ใช้ถนนให้หลีกเลี่ยงเส้นทางที่มีความเสียหายรุนแรง ลดความเสี่ยงในการเกิดอุบัติเหตุ การวางแผนงบประมาณสำหรับการซ่อมแซมถนนจากการตรวจจับความเสียหายของถนนสามารถนำมาใช้ในการจัดทำแผนบำรุงรักษาเชิงป้องกัน และการจัดสรรงบประมาณซ่อมแซมถนนได้อย่างมีประสิทธิภาพมากขึ้น การนำโมเดลตรวจจับหลุมบนถนนที่ใช้เทคนิค Segmentation มีข้อดีเหนือกว่าการใช้ Bounding Box แบบดั้งเดิม เนื่องจากสามารถระบุขอบเขตของพื้นที่หลุมได้อย่างแม่นยำมากขึ้น ซึ่งเป็นส่วนช่วยให้สามารถคำนวณขนาดของหลุมและนำไปใช้ในการประเมินต้นทุนซ่อมแซมได้อย่างมีประสิทธิภาพ นอกจากนี้ โมเดลที่พัฒนาขึ้นยังสามารถนำไปประยุกต์ใช้กับการตรวจจับความเสียหายในรูปแบบอื่น ๆ บนถนนนอกเหนือจากหลุมบ่อ เช่น รอยแตกร้าว (Cracks) ซึ่งอาจเป็นสัญญาณของโครงสร้างถนนที่เริ่มเสื่อมสภาพ การเปลี่ยนรูปร่างของผิวถนน (Distortion) เช่น การทรุดตัวหรือเป็นคลื่นของผิวถนน การประยุกต์ใช้โมเดลในการตรวจจับความเสียหายที่หลากหลายจะช่วยให้หน่วยงานที่เกี่ยวข้องสามารถวางแผนบำรุงรักษาถนนได้อย่างครอบคลุมมากขึ้น ลดปัญหาความเสียหายที่อาจนำไปสู่อุบัติเหตุ และช่วยเพิ่มอายุการใช้งานของถนนให้ยาวนานขึ้น

4. กิตติกรรมประกาศ

งานวิจัยเรื่อง การตรวจจับความเสียหายประเภทหลุมบ่อบนถนนลาดยางด้วยเทคนิคคอมพิวเตอร์วิทัศน์เพื่อสนับสนุนการประมาณต้นทุนค่าบำรุงรักษา สำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความอนุเคราะห์และคำแนะนำจากบุคคลากรหลายท่าน ซึ่งผู้วิจัยขอขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้ ขอขอบพระคุณ รองศาสตราจารย์ ดร.ดำรงค์ ศักดิ์ รินชุมภู อาจารย์ที่ปรึกษาหลัก ที่ได้ให้คำปรึกษาแนวทาง และข้อเสนอแนะตลอดระยะเวลาการดำเนินงานวิจัย ขอขอบพระคุณ เรือเอกธีรศักดิ์ ปัญญาภิรวัฒน์ ที่ได้ให้ความรู้และสอนการใช้เทคโนโลยีปัญญาประดิษฐ์ (AI) ใน

การประมวลผลภาพและข้อมูล ซึ่งเป็นส่วนสำคัญที่ทำให้งานวิจัยนี้บรรลุผลสำเร็จ ขอขอบพระคุณ อาจารย์ ดร.กิตติคุณ จิตไพโรจน์ ที่ได้ให้คำปรึกษาและแนะนำแนวทางในการพัฒนางานวิจัย รวมถึงการช่วยเหลือในการวิเคราะห์ข้อมูลและปรับปรุงโมเดลให้มีประสิทธิภาพมากขึ้น นอกจากนี้ ผู้วิจัยขอขอบคุณทุกท่านที่เกี่ยวข้อง ทั้งอาจารย์ นักวิจัย และเพื่อนร่วมงาน ที่ให้การสนับสนุนและช่วยเหลือในด้านต่าง ๆ ตลอดระยะเวลาการดำเนินงานวิจัยครั้งนี้ สุดท้ายนี้ ผู้วิจัยขอขอบคุณหน่วยงานและสถาบันที่ให้การสนับสนุนทรัพยากรและอุปกรณ์ที่จำเป็นในการวิจัย จนทำให้งานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี

5. เอกสารอ้างอิง

[1] กรมทางหลวง. รายงานประจำปี 2566. Available from: https://www.doh.go.th

[2] ระบบบัญชีข้อมูลด้านคมนาคม. (2566). ระยะทางถนนในความรับผิดชอบของกระทรวงคมนาคม Available from: https://datagov.mot.go.th

[3] Shahin, M., and Kohn, S. 1981 Pavement Management System for Roads and Parking Lots. Technical Report M- 294 Construction Engineering Research Lab. US Army Corps of Engineers

[4] Katryn, A.C., and others. 1985. Develop of preventive Maintenance Algorithm for Use in pavement Management Systems. Transportation Research Record1123

[5] Redmon J, Divvala S, Girshick R, Farhadi A, editors. You Only Look Once: Unified, Real-Time Object Detection. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 27-30 June 2016.

[6] Chitale, P. A., Kekre, K. Y., Shenai, H. R., Karani, R., & Gala, J. P. (2020, 25-27 Nov. 2020). Pothole Detection and Dimension Estimation System using Deep Learning (YOLO) and Image Processing. Paper presented at the 2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ). Available from https://doi.org/10.1109/IVCNZ51579.2020.9290547

[7] Arya, D., Maeda, H., Ghosh, S., Toshniwal, D., Mraz, A., Kashiyama, T., & Sekimoto, Y. (2020). Transfer Learning-based Road Damage Detection for Multiple Countries. Available from http://dx.doi.org/10.48550/arXiv.2008.13101

[8] Arya D, Maeda H, Ghosh SK, Toshniwal D, Mraz A, Kashiyama T, et al. Deep learning-based road damage detection and classification for multiple countries. Automation in Construction. 2021. Available from https://doi.org/10.1016/j.autcon.2021.103935

[9] Hu H, Li Z, He Z, Wang L, Cao S, Du W. Road surface crack detection method based on improved YOLOv5 and vehicle-mounted images. Measurement. 2024. Available from https://doi.org/10.1016/j.measurement.2024.114443 102388.

[10] Deval Shah,Mean Average Precision (mAP) Explained: Everything You Need to Know. Available from: https://www.v7labs.com

Probabilistic Analytics of Rainfall in Thailand for Lifespan of Hydraulic Structures

Kissada Im-oum[1] Wanwisa Duantrakoonsil[2] Rapin Sunthornwat[3*]

[1]*Software Engineering and Information System Program, Faculty of Science and Technology, Pathumwan Institute of Technology*
[2]*College of Logistics and Supply Chain, Sripatum University*
[3]*Industrial Technology and Innovation Management Program, Faculty of Science and Technology, Pathumwan Institute of Technology*
(* *rapin@pit.ac.th*)

Abstract

Rainfall is crucial to irrigation systems and agriculture worldwide, especially in the design and analysis of hydraulic structures. Analyzing the feasibility of rainfall in terms of risk and reliability is therefore essential for the analysis of such hydraulic structures. This research aims to compare the risk of rainfall affecting the designed hydraulic structures under binomial distribution and fractional distribution. The study found that under both binomial and fractional distributions, if the return period is constant, the risk increases as the lifespan of the structure increases. On the other hand, if the lifespan of the structure is constant, the risk decreases as the return period increases.

Keywords: binomial distribution, fractional binomial distribution, return period, risk and reliability, precipitation

1. Introduction

A rainfall refers specifically to the amount of water falling to the ground in the form of rain. It is one kind of precipitation which refers to the total amount of water falling, which may include rain, sleet, snow, or hail. Thailand is located in the Southeast Asian region, which has a hot and humid climate, so when reporting weather conditions or meteorological data the term of rainfall is often used in daily life. However, the terms of precipitation are more commonly used in research or academic contexts.

Rainfall plays a significant role in sustaining life, but when its amount exceeds a certain threshold, it can lead to disasters or cause damage to humans. Therefore, managing rainfall and precipitation is crucial. Landslides, for example, are often caused by excessive rainfall, and there are studies that warn about landslides due to heavy rainfall, helping to mitigate the potential risks (see [1]). Additionally, rainfall data is useful for managing water storage systems, allowing for the calculation of maximum rainfall to prepare for or control floodwaters efficiently (see [2]). As we can see, knowing the amount of rainfall enables better planning for disaster preparedness, which aligns with this research.

In this research, the return period is used to understand the occurrence of maximum rainfall, assessing the risk for hydraulic structures to make decisions aimed at enhancing safety. The binomial distribution is applied to determine the probability of the return period, followed by fractional binomial distribution to assess the risk associated with hydraulic structures.

2. Materials and Methods

Mathematical and statistical backgrounds and data collection for analysis of the probability in the precipitation are as follows:

2.1 The binomial distribution

Let X be a random variable which represents the number of successful times from all n trails, occurring with probability p. Thus, $n-x$ trails represents the number of failure times occurring with probability $1-p$ as q (see [3]).

Probability mass function (pmf) of the binomial distribution with the expected value $\mathbf{E}(X)$ and the variance $\mathbf{Var}(X)$ can be defined as:

$$\mathbf{P}(X=x)=\mathbf{P}_{x,n}=\frac{n!}{(n-x)!x!}p^x q^{n-x};\ x=0,1,2,...,n$$

$$\mathbf{E}(X)=\mu_X=np$$

$$\mathbf{Var}(X)=\sigma_X^2=npq \text{ ,where } q=1-p$$

2.2 The fractional binomial distribution

Let X be a random variable which extends from binomial distribution in case of the non-integer order of trails, α (see [4]).

Probability mass function (pmf) of the fractional distribution with the expected value $\mathbf{E}(X)$ and the variance $\mathbf{Var}(X)$ can be defined as:

$$\mathbf{P}(X=x)=\frac{\Gamma(\alpha+1)}{\Gamma(x+1)\Gamma(\alpha-x+1)}p^{x}(1-p)^{\alpha-x};x=0,1,2,...,\alpha$$

$$\mathbf{E}(X)=\mu_X=\alpha p$$

$$\mathbf{Var}(X)=\sigma_X^2=\alpha pq \text{ ,where } q=1-p$$

where $\Gamma(\alpha)$ is a Gamma function) defined as

$$\Gamma(\alpha)=\int_0^{\infty}t^{\alpha-1}e^{-t}dt \text{ for } \alpha>0$$

The Gamma function corresponds to the following properties.

$\Gamma(\alpha+1)=\alpha\Gamma(\alpha)$ for $\alpha>0$ and α is a non-integer.

$\Gamma(n+1)=n!$ for $n\geq 0$ and n is an integer.

The main differences between the binomial distribution and the fractional binomial distribution are focused. The binomial distribution is a discrete probability distribution of the number of successes in a sequence of n independent experiments and each with its own Boolean - valued outcome. On the other hand, the fractional binomial distribution is a generalization of the binomial distribution where the number of trials α can be a non-integer (fractional) value.

In this research, X is a random variable representing the number of times it rains or the number of events. Let p is the probability of rain occurring at least a given number of times.

$$p=\mathbf{P}(X>x)=\frac{m-a}{N+b}$$

where m is the order number of event

N is the total number of even in data

and a,b are the Weibull parameters setting with $a=0,b=1$, see [5]. In the application of hydrology, the project lifespan or duration of hydraulic structures is represented by n for integer duration or α for non-integer duration.

Let T be return period which refers to the average time interval between events that have a magnitude or severity equal to or greater than a specified value. That is, $p=\frac{1}{T}$.

2.3 Data collection

Dataset for this research is gathered from the website of National Hydroinformatics Data Center [6]. The dataset is the annual rainfall of Thailand over the past 40 years, from 1985 to 2024.

2.4 Algorithm for computation of the probability of rain occurring at least a given number of times

For this research, the data analysis can be computed as the following steps.

Step 1. Given a dataset of N data points, sort the data from highest to lowest.

Step 2. Assign the highest value the rank $m=1$, the next highest $m=2$, and so on up to $m=N$.

Step 3. Calculate the return period $T=\frac{1}{p}=\frac{N+1}{m}$.

Step 4. Calculate the probability of the event occurring $p=\frac{1}{T}$.

2.5 Risk and Reliability

For this research, risk is defined as

Risk $=\mathbf{P}(X\geq 1)=1-\mathbf{P}(X=0)$

Therefore,

Risk $=1-(1-p)^n$ for the binomial distribution with integer n.

Risk $=1-(1-p)^{\alpha}$ for the fractional binomial distribution with non-integer α.

In contrast, reliability is defined as

Reliability = 1− Risk.

3. Results and discussion

This section consists of the results from data analysis of precipitation in Thailand from year 1985 to 2024. Also, the discussion is provided as the followings.

3.1 The maximum annual rainfall in Thailand

From Figure 1, it shows the maximum rainfall amount for each year, with the independent variable being the year of occurrence and the dependent variable being the annual rainfall amount**.** It can be observed that from 1985 to 2024, the maximum rainfall each year did not exceed 1600 millimeters **(**mm**).** Only in the years 2011, 2017, and 2021 did the annual rainfall surpass the amounts of other years**.**

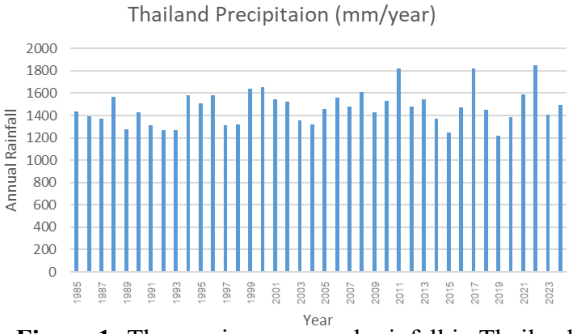

Figure 1: The maximum annual rainfall in Thailand

3.2 Return period and probability of the maximum rainfall in Thailand

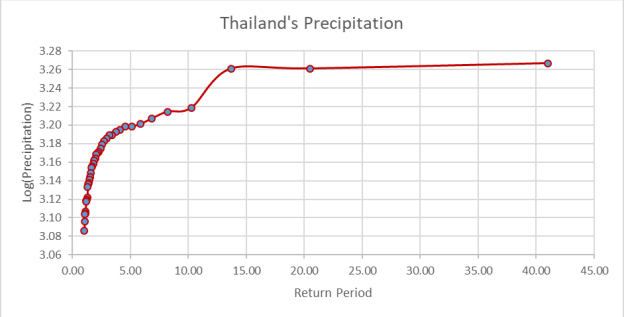

Figure 2: The maximum rainfall in Thailand

Figure 2 explains the maximum rainfall amount for the return period in Thailand, with the independent variable being the return period and the dependent variable being the maximum rainfall amount. As the return period increases, the maximum rainfall amount also increases. However, by the 14th return period, the maximum rainfall amount stabilizes at approximately 3.26 mm in log scales.

Table 1: Return period of the maximum rainfall in Thailand

Return period (years)	The maximum rainfall (mm.)
2	1465.98
6	1593.28
10	1680.25
14	1819.70
40	1862.09

From Table 1, it can be observed that if the return period increases, the maximum rainfall in Thailand will also increase.

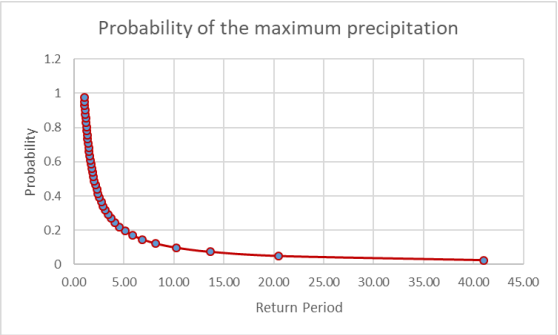

Figure 3: Probability of the maximum rainfall in Thailand

From Figure 3, it can be observed that the probability of maximum rainfall decreases as the return period increases.

3.3 Risk and reliability based on binomial distribution

For Table 2 based on binomial distribution, if return period is fixed, then risk increase as duration increase. If duration is fixed, then risk decrease as return period increase.

For Table 3 based on binomial distribution, if return period is fixed, then reliability decrease as duration increase. If duration is fixed, then reliability increase as return period increase.

For Table 4 based on fractional binomial distribution, if return period is fixed, then risk increase as duration increase. If duration is fixed, then risk decrease as return period increases.

For Table 5 based on fractional binomial distribution, if return period is fixed, then reliability decrease as duration increase. If duration is fixed, then reliability increase as return period increases.

3.4 Discussion

The research used binomial distribution (with n as an integer) and fractional binomial distribution (with α as a non-integer) to show that when the values of n and α are constant, as the return period (T) increases, the risk values diverge more. On the other hand, when the return period (T) decreases, the risk values for both distributions converge in the same direction. This is evident when comparing $n = 7$ and $\alpha = 6.5$, where the risk values for both distributions are similar. Additionally, when the return period (T) remains constant, as the values of n and α increase, the risk values for both distributions tend to become more similar. For application in real problem, hydraulic structure designers can choose risk and reliability to help decide the level of risk or reliability when determining the lifespan of hydraulic structures. For example, from Tables 2 and 4, when $n = 5, T = 2, p = 0.5$, the risk of the hydraulic structure is 0.969, or when $\alpha = 3.5, T = 2, p = 0.5$, the risk of the hydraulic structure is 0.912. Therefore, it can be concluded that the probabilities or outcomes of both equations are quite close to each other.

4. Conclusion

The conclusion for this research can be summarized as follows.

The maximum rainfall in Thailand over the past 40 years reached its highest at 1848 millimeters in 2022 and its lowest at 1218 millimeters in 2019. Overall, the average maximum rainfall in Thailand over the 40-year period is approximately 1472.7 millimeters. The

maximum rainfall of 1465.98 millimeters in Thailand occurs every 2 years.

For both binomial distribution and fractional binomial distribution, if the return period is constant, the risk will decrease as the project lifespan increases. If the project lifespan is constant, the risk will decrease as the return period increases.

Therefore, the information resulting from the data analysis of this research enhances decision-making for the design and analysis of hydraulic structures such as dams, spillways, and sluice gates.

5. References

[1] Soralump S, Nuimak T. Estimation of Statistical Critical Rainfall Envelope for Landslide Warning. In: Proceedings of the 18th National Convention on Civil Engineering; 2013 May; Chiang Mai, Thailand. p. 8-10.

[2] Aueteerasrun P, Sukosi K, Thepprasit C, Marjang N. Probable mximum precipitation and probable maximum flood. In: Proceedings of the 11th THAICID National Symposium; 2018 Jun 20; Nonthaburi, Thailand.

[3] DeSanto , Moscatelli R, et al. Introduction to Statistics. 10th ed. New York (NY): Publisher; 2015.

[4] Hino M, Namba R. Fractional binomial distributions induced by the generalized binomial theorem and their applications. arXiv. 2024 Aug 21;2408.12011v1.

[5] Weibull W. A statistical theory of strength of materials. Ing Vetensk Akad Handl. 1939; 151: 1-45.

[6] National Hydroinformatics Data Center. Hydro Situation [document on the Internet] . Bankok: Hydro - Informatics Institute (HII) ; 2024 [updated 2024 January 24; cited 2024 Feb 15] . Available from: https://www.thaiwater.net.

Table 2: Risk of the maximum rainfall based on binomial distribution

T	p	**Integer duration** (n)													
		2	**5**	**7**	**10**	**15**	**20**	**25**	**30**	**35**	**40**	**45**	**50**	**55**	**60**
2	0.5	0.750	0.969	0.992	0.999	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
5	0.2	0.360	0.672	0.790	0.893	0.965	0.988	0.996	0.999	1.000	1.000	1.000	1.000	1.000	1.000
10	0.1	0.190	0.410	0.522	0.651	0.794	0.878	0.928	0.958	0.975	0.985	0.991	0.995	0.997	0.998
25	0.04	0.078	0.185	0.249	0.335	0.458	0.558	0.640	0.706	0.760	0.805	0.841	0.870	0.894	0.914
50	0.02	0.040	0.096	0.132	0.183	0.261	0.332	0.397	0.455	0.507	0.554	0.597	0.636	0.671	0.702
100	0.01	0.020	0.049	0.068	0.096	0.140	0.182	0.222	0.260	0.297	0.331	0.364	0.395	0.425	0.453
500	0.002	0.004	0.010	0.014	0.020	0.030	0.039	0.049	0.058	0.068	0.077	0.086	0.095	0.104	0.113
1000	0.001	0.002	0.005	0.007	0.010	0.015	0.020	0.025	0.030	0.034	0.039	0.044	0.049	0.054	0.058

Table 3: Reliability of the maximum rainfall based on binomial distribution

T	p	**Integer duration** (n)													
		2	**5**	**7**	**10**	**15**	**20**	**25**	**30**	**35**	**40**	**45**	**50**	**55**	**60**
2	0.5	0.250	0.031	0.008	0.001	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
5	0.2	0.640	0.328	0.210	0.107	0.035	0.012	0.004	0.001	0.000	0.000	0.000	0.000	0.000	0.000
10	0.1	0.810	0.590	0.478	0.349	0.206	0.122	0.072	0.042	0.025	0.015	0.009	0.005	0.003	0.002
25	0.04	0.922	0.815	0.751	0.665	0.542	0.442	0.360	0.294	0.240	0.195	0.159	0.130	0.106	0.086
50	0.02	0.960	0.904	0.868	0.817	0.739	0.668	0.603	0.545	0.493	0.446	0.403	0.364	0.329	0.298
100	0.01	0.980	0.951	0.932	0.904	0.860	0.818	0.778	0.740	0.703	0.669	0.636	0.605	0.575	0.547
500	0.002	0.996	0.990	0.986	0.980	0.970	0.961	0.951	0.942	0.932	0.923	0.914	0.905	0.896	0.887
1000	0.001	0.998	0.995	0.993	0.990	0.985	0.980	0.975	0.970	0.966	0.961	0.956	0.951	0.946	0.942

Table 4: Risk of the maximum rainfall based on fractional binomial distribution

T	p	**Non-integer duration** (α)													
		0.5	**3.5**	**6.5**	**8.5**	**13.5**	**18.5**	**23.5**	**28.5**	**33.5**	**38.5**	**43.5**	**48.5**	**53.5**	**58.5**
2	0.5	0.293	0.912	0.989	0.997	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
5	0.2	0.106	0.542	0.766	0.850	0.951	0.984	0.995	0.998	0.999	1.000	1.000	1.000	1.000	1.000
10	0.1	0.051	0.308	0.496	0.592	0.759	0.858	0.916	0.950	0.971	0.983	0.990	0.994	0.996	0.998
25	0.04	0.020	0.133	0.233	0.293	0.424	0.530	0.617	0.688	0.745	0.792	0.831	0.862	0.887	0.908
50	0.02	0.010	0.068	0.123	0.158	0.239	0.312	0.378	0.438	0.492	0.541	0.585	0.625	0.661	0.693
100	0.01	0.005	0.035	0.063	0.082	0.127	0.170	0.210	0.249	0.286	0.321	0.354	0.386	0.416	0.445
500	0.002	0.001	0.007	0.013	0.017	0.027	0.036	0.046	0.055	0.065	0.074	0.083	0.093	0.102	0.111
1000	0.001	0.001	0.003	0.006	0.008	0.013	0.018	0.023	0.028	0.033	0.038	0.043	0.047	0.052	0.057

Table 5: Reliability of the maximum rainfall based on fractional binomial distribution

T	p	**Non-integer duration** (α)													
		0.5	**3.5**	**6.5**	**8.5**	**13.5**	**18.5**	**23.5**	**28.5**	**33.5**	**38.5**	**43.5**	**48.5**	**53.5**	**58.5**
2	0.5	0.707	0.088	0.011	0.003	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
5	0.2	0.894	0.458	0.234	0.150	0.049	0.016	0.005	0.002	0.001	0.000	0.000	0.000	0.000	0.000
10	0.1	0.949	0.692	0.504	0.408	0.241	0.142	0.084	0.050	0.029	0.017	0.010	0.006	0.004	0.002
25	0.04	0.980	0.867	0.767	0.707	0.576	0.470	0.383	0.312	0.255	0.208	0.169	0.138	0.113	0.092
50	0.02	0.990	0.932	0.877	0.842	0.761	0.688	0.622	0.562	0.508	0.459	0.415	0.375	0.339	0.307
100	0.01	0.995	0.965	0.937	0.918	0.873	0.830	0.790	0.751	0.714	0.679	0.646	0.614	0.584	0.555
500	0.002	0.999	0.993	0.987	0.983	0.973	0.964	0.954	0.945	0.935	0.926	0.917	0.907	0.898	0.889
1000	0.001	0.999	0.997	0.994	0.992	0.987	0.982	0.977	0.972	0.967	0.962	0.957	0.953	0.948	0.943

ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้นโดยวิธีสมการปริพันธ์เชิงตัวเลข

Average Run Length of Double Modified Exponentially Weighted Moving Average Control Chart by Numerical Integral Equation

สุภาณี วุฒิระวัฒน์* ยุพาภรณ์ อารีพงษ์ เสาวณิต สุขภารังษี

ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* *pnsu2804@gmail.com*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาวิธีการประมาณค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยวิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE) ได้แก่ วิธีกฎเกาส์ (Gaussian Rule Method) วิธีกฎค่ากลาง (Midpoint Rule Method) วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) และวิธีกฎของซิมป์สัน (Simpson's Rule Method) สำหรับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้น (Double Modified Exponentially Weighted Moving Average Control Chart: DMEWMA) เมื่อข้อมูลมีการแจกแจงแกมมา นอกจากนี้ทำการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DMEWMA กับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลง (MEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) โดยพิจารณาจากค่าความยาวรันเฉลี่ยเมื่อกระบวนการไม่อยู่ภายใต้ควบคุม (out-of-control Average Run Length: ARL_1) และเวลาที่ใช้ในการประมวลผล (CPU Times) ของวิธีสมการปริพันธ์เชิงตัวเลขเป็นเกณฑ์ในการตรวจสอบประสิทธิภาพ ซึ่งจากผลการวิจัยพบว่า ค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธีให้ค่าไม่แตกต่างกัน แต่หากพิจารณาจากความเร็วในการประมวลผลพบว่าวิธีกฎค่ากลางและวิธีกฎสี่เหลี่ยมคางหมูใช้เวลาในการประมวลผลน้อยที่สุด และเมื่อศึกษาประสิทธิภาพของแผนภูมิควบคุมพบว่า แผนภูมิ DMEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการได้ดีกว่าแผนภูมิควบคุม MEWMA และ แผนภูมิควบคุม EWMA ในทุกระดับการเปลี่ยนแปลง

คำสำคัญ: แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้น, วิธีกฎเกาส์, วิธีกฎค่ากลาง, วิธีกฎสี่เหลี่ยมคางหมู, วิธีกฎของซิมป์สัน

Abstract

This research aims to study the approximation of the Average Run Length (ARL) by using the Numerical Integral Equation (NIE) methods including Gaussian Rule, Midpoint Rule, Trapezoidal Rule, and Simpson's Rule on Double Modified Exponentially Weighted Moving Average Control Chart (DMEWMA) when the data follows a Gamma distribution. In addition, the study compares the performance of the DMEWMA control chart with Modified Exponentially Weighted Moving Average (MEWMA) control chart and Exponentially Weighted Moving Average (EWMA) control chart, based on the out-of-control Average Run Length (ARL_1) and the processing time (CPU Times). The results showed that the Average Run Length values estimated using all methods are not significantly different. However, when considering the processing speed, it was found that the midpoint rule and the trapezoidal rule take the least processing time. In Addition, the performance of the DMEWMA control chart proved to be more effective in detecting changes in the process mean compared to the MEWMA and EWMA control charts for all magnitudes of shift size.

Keywords: Double Modified Exponentially Weighted Moving Average Control Chart, Gaussian Rule, Midpoint Rule, Trapezoidal Rule, Simpson's Rule

1. บทนำ

ในกระบวนการผลิตทางอุตสาหกรรม สามารถเกิดความผันแปรของกระบวนการได้เสมอ ความผันแปรต่าง ๆ เกิดขึ้นได้จากหลายปัจจัย ซึ่งความผันแปรเหล่านั้นจะส่งผลต่อคุณภาพของผลิตภัณฑ์ เพื่อเป็นการควบคุมคุณภาพของกระบวนการผลิตให้มีประสิทธิภาพ จึงมีแนวคิดเกี่ยวกับการควบคุมคุณภาพของผลิตภัณฑ์ขึ้น เพื่อให้กระบวนการผลิตอยู่ในระดับมาตรฐาน โดยการเตือนให้ผู้ผลิตทราบว่ากระบวนการผลิตได้เปลี่ยนแปลงไปจากเกณฑ์ที่กำหนด เพื่อป้องกันไม่ให้มีข้อบกพร่องหรือเสียหายจากกระบวนการผลิต

การควบคุมกระบวนการเชิงสถิติ (Statistical Process Control : SPC) คือการนำวิธีการทางสถิติมาใช้ในการตรวจสอบและควบคุมคุณภาพของกระบวนการผลิต ซึ่งช่วยให้มั่นใจได้ว่ากระบวนการมีการทำงานอย่างมีประสิทธิภาพ ซึ่งเครื่องมือในการควบคุมกระบวนการเชิงสถิติมีหลากหลายวิธี เช่น แผ่นตรวจสอบ (Check Sheet) ฮิสโทรแกรม (Histogram) แผนภาพพาเรโต(Pareto Diagram) แผนภาพก้างปลา(Fishbone Diagram) และเครื่องมือที่ได้รับความนิยมและมีประสิทธิภาพ คือแผนภูมิควบคุม (Control Chart) ซึ่งแผนภูมิควบคุม จึงเป็นเครื่องมือที่จะช่วยในการวิเคราะห์และตรวจสอบความผิดปกติของกระบวนการผลิตนำไปสู่การปรับปรุงกระบวนการอย่างต่อเนื่อง

ในปี ค.ศ. 1931 แผนภูมิควบคุมถูกเสนอครั้งแรกโดย Walter Shewhart [1] จึงเรียกว่าเป็นแผนภูมิควบคุม Shewhart อย่างไรก็ตามแผนภูมิควบคุม Shewhart มีประสิทธิภาพในการตรวจพบความผิดปกติของกระบวนได้ช้ากว่าแผนภูมิควบคุมอื่น ๆต่อมาในปี ค.ศ. 1959 Roberts [2]ได้พัฒนาแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average control chart: EWMA) ที่ให้ความสำคัญกับข้อมูลในอดีตและข้อมูลในปัจจุบัน คือ Memory control chart โดยถ่วงน้ำหนักข้อมูลในอดีตและข้อมูลในปัจจุบัน ในปี ค.ศ. 2011 Patel และ Divecha [3] ได้นำเสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลง (Modified Exponentially Weighted Moving Average Control Chart : MEWMA) แผนภูมิควบคุม MEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงทั้งขนาดเล็กและขนาดใหญ่ แต่มีความสามารถในการตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีกว่าเมื่อเทียบกับแผนภูมิควบคุมแบบอื่น ๆ เช่น แผนภูมิควบคุม Shewhart หรือแผนภูมิควบคุม EWMA ต่อมาในปี ค.ศ.2017 Khan, Aslam, และ Jun [4] ได้พัฒนาแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงใหม่ ในปี ค.ศ.2021 Alevizakos, Chatterjee และ Koukouvinos [5]ได้นำเสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังแบบดัดแปลงสองชั้น (Double Modified Exponentially Weighted Moving Average Control Chart: DMEWMA) โดยแผนภูมิควบคุมนี้ได้นำแนวคิดของการปรับให้เรียบมาใช้ กับแผนภูมิควบคุม MEWMA ทำให้แผนภูมิควบคุมที่ได้สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีกว่าเดิม

โดยทั่วไปแล้วค่าความยาวรันเฉลี่ย นิยมใช้ในการวัดประสิทธิภาพของแผนภูมิควบคุม แบ่งออกเป็น 2 ชนิด คือ ค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม และค่าความยาวรันเฉลี่ยเมื่อกระบวนการไม่อยู่ภายใต้การควบคุม ซึ่งวิธีการประมาณค่าความยาวรันเฉลี่ย เช่น การจำลองมอนติคาร์โล (Monte Carlo Simulation: MC), วิธีมาร์คอฟเชน (Markov Chain Approach: MCA), วิธีมาร์ติงเกล (Martingale Approach : MA), สูตรที่ชัดเจน (Explicit Formulas) และวิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE) ใน ค.ศ.2023 Neammai, Areepong และ Sukparungsee [6] ได้เสนอวิธีสมการปริพันธ์เชิงตัวเลขสำหรับการหาค่า ARL ของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังแบบดัดแปลงสองชั้น ผลการวิจัยพบว่า ประสิทธิภาพของทุกวิธีไม่แตกต่างกัน โดยในการวิจัยนี้ได้ศึกษาวิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE) ได้แก่ วิธีกฎค่ากลาง (Midpoint Rule Method), วิธีกฎเกาส์(Gaussian Rule Method), วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) และวิธีกฎของซิมป์สัน (Simpson's Rule Method) สำหรับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้น (Double Modified Exponentially Weighted Moving Average Control Chart : DMEWMA) เมื่อข้อมูลมีการแจกแจงแกมมา

2. วิธีการวิจัย

2.1 แผนภูมิควบคุม

2.1.1 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (Exponentially Weighted Moving Average Control Chart: EWMA)

เสนอโดย Roberts [2] เป็นแผนภูมิที่ให้ความสำคัญกับข้อมูลในอดีตและปัจจุบันที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการที่มีขนาดเล็กและปานกลาง ซึ่งค่าสถิติของแผนภูมิควบคุม EWMA แสดงดังสมการที่ (1) ดังนี้

$$Z_t = (1-\lambda_1)Z_{t-1} + \lambda_1 X_t \ ; \ t = 1,2,... \qquad (1)$$

โดยที่ Z_t แทน ค่าสถิติของแผนภูมิควบคุม EWMA ณ คาบเวลาที่ t

X_t แทน ค่าสังเกต ณ คาบเวลาที่ t

λ_1 แทน ค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม EWMA โดยที่ $0 < \lambda_1 \le 1$

2.1.2 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังดัดแปลง (Modified Exponentially Weighted Moving Average Control Chart: MEWMA)

เสนอโดย Patel และ Divecha [3] เป็นแผนภูมิที่พัฒนาจากแผนภูมิควบคุม EWMA ซึ่งค่าสถิติของแผนภูมิควบคุม MEWMA แสดงดังสมการที่ (2) ดังนี้

$$M_t = \lambda_1 X_t + (1-\lambda_1)M_{t-1} + (X_t - X_{t-1}); t = 1,2,... \quad (2)$$

โดยที่ M_t แทน ค่าสถิติของแผนภูมิควบคุม MEWMA ณ คาบเวลาที่ t

X_t แทน ค่าสังเกต ณ คาบเวลาที่ t

λ_1 แทน ค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม MEWMA โดยที่ $0 < \lambda_1 \le 1$

ต่อมาใน ค.ศ.2017 Khan, Aslam, และ Jun [4]ได้นำแผนภูมิควบคุมที่ถูกเสนอโดย Patel และ Divecha [3] มาพัฒนาต่อซึ่งค่าสถิติของแผนภูมิ MEWMA แสดงสมการที่ (3) ดังนี้

$$M_t = \lambda_1 X_t + (1-\lambda_1)M_{t-1} + k_1(X_t - X_{t-1}); t = 1,2,... \quad (3)$$

โดยที่ k_1 แทน ค่าคงที่

2.1.3 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังแบบดัดแปลงสองชั้น (Double Modified Exponentially Weighted Moving Average Control Chart: DMEWMA)

เสนอโดย Alevizakos, Chatterjee และKoukouvinos [5] โดยแผนภูมิควบคุมนี้เป็นการผสม 2 แผนภูมิควบคุม MEWMA ซึ่งค่าสถิติของแผนภูมิควบคุม DMEWMA แสดงดังสมการที่ (4) ดังนี้

$$\begin{cases} M_t = \lambda_1 X_t + (1-\lambda_1)M_{t-1} + k_1(X_t - X_{t-1}) \\ DM_t = \lambda_2 M_t + (1-\lambda_2)DM_{t-1} + k_2(M_t - M_{t-1}) \end{cases} \quad (4)$$

โดยที่ DM_t แทน ค่าสถิติของแผนภูมิควบคุม DMEWMA ณ คาบเวลาที่ t

X_t แทน ค่าสังเกต ณ คาบเวลาที่ t

k_1, k_2 แทน ค่าคงที่

λ_1, λ_2 แทน ค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม DMEWMA โดยที่ $0 \le \lambda_1, \lambda_2 \le 1$

2.2 การแจกแจงแกมมา (Gamma distribution)

กำหนดให้ตัวแปรสุ่ม X มีการแจกแจงแกมมา ด้วยพารามิเตอร์ α และ β ฟังก์ชันความหนาแน่นของความน่าจะเป็นของการแจกแจงแกมมา แสดงดังสมการที่ (5) ดังนี้

$$f(x) = \frac{x^{\alpha-1}e^{-\frac{x}{\beta}}}{\beta^{\alpha}\Gamma(\alpha)} \quad ; \ x > 0, \ \beta > 0, \ \alpha > 0 \quad (5)$$

โดยที่ α แทน พารามิเตอร์กำหนดรูปร่าง (Shape Parameter)

β แทน พารามิเตอร์กำหนดขนาด (Scale Parameter)

2.3 วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE)

กำหนดให้ $L(u)$ แทน ค่าความยาวรันเฉลี่ย (ARL) สำหรับแผนภูมิควบคุม DMEWMA เมื่อกำหนดให้ $u \in [0,b]$ ดังนั้นสมการปริพันธ์สามารถแสดงดังนี้

$$ARL = L(u) = E_{\infty}(\tau_b)$$

โดยที่ τ_b แทน คาบเวลาที่แผนภูมิควบคุมส่งสัญญาณเตือนว่ากระบวนการออกนอกการควบคุมจะได้ว่า $\tau_b = \inf\{t > 0 : DM_t \ge b\}$ เมื่อ b แทน ขีดจำกัดควบคุมบน (UCL) ของแผนภูมิควบคุม DMEWMA ซึ่งในงานวิจัยนี้ได้ใช้วิธีสมการปริพันธ์เชิงตัวเลขเพื่อหาค่า ARL แสดงดังสมการที่(6) ดังนี้

$$L(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \quad (6)$$

$$\int_0^b L(y) f\left(\frac{y - (1-\lambda_2)u - (\lambda_2 - \lambda_1\lambda_2 - \lambda_1 k_2)v + (k_1\lambda_2 + k_1k_2)e}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \right) dy$$

เมื่อ v,e แทน ค่าเริ่มต้น โดยที่ $v = M_0, e = X_0$

จากสมการที่ (6) ใช้วิธีกฎการสร้างพื้นที่สี่เหลี่ยมจัตุรัสในการประมาณค่าอินทิกรัล สามารถประมาณได้ดังสมการที่ (7)

$$\tilde{L}(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \sum_{j=1}^{m} w_j \tilde{L}(a_j) f \quad (7)$$

$$\left(\frac{a_j - (1-\lambda_2)u - (\lambda_2 - \lambda_1\lambda_2 - \lambda_1 k_2)v + (k_1\lambda_2 + k_1k_2)e}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \right)$$

วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equations Method: NIE) ที่ใช้ในการวิจัยนี้มี 4 วิธี ดังนี้

2.3.1 วิธีกฎเกาส์ (Gaussian Rule Method)

จากสมการที่ (7) กำหนดให้

$$f(A_j) = f\left(\frac{a_j - (1-\lambda_2)u - (\lambda_2 - \lambda_1\lambda_2 - \lambda_1 k_2)v + (k_1\lambda_2 + k_1k_2)e}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \right)$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b W(y) f(y) dy \approx \sum_{j=1}^{m} w_j f(a_j); \ j = 1,2,...,m$$

โดยที่ $W(y) = 1, -1 < y < 1$

สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของเกาส์ของแผนภูมิควบคุม DMEWMA แสดงดังสมการที่ (8)

$$\tilde{L}_G(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (8)$$

2.3.2 วิธีกฎค่ากลาง (Midpoint Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น m ช่วง โดยมีช่วงความกว้าง $h = \frac{b}{m}$ ด้วยกฎของค่ากลาง ที่มีการแบ่งช่วงเป็น m ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของค่ากลางของแผนภูมิควบคุม DMEWMA แสดงดังสมการ (9)

$$\tilde{L}_M(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2} \sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (9)$$

โดยที่ $a_j = w_j\left(j - \frac{1}{2}\right)$ และ $w_j = \frac{b}{m}; j = 1,2,...,m$

2.3.3 วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น m ช่วง โดยมีช่วงความกว้าง $h = \frac{b}{m}$ ด้วยกฎของสี่เหลี่ยมคางหมู ที่มีการแบ่งช่วงเป็น m ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากวิธีกฎสี่เหลี่ยมคางหมู ของแผนภูมิควบคุม DMEWMA แสดงดังสมการ (10)

$$\tilde{L}_T(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (10)$$

โดยที่ $a_j = w_j j$ และ $w_j = \frac{b}{m}; j = 1,2,...,m-1$ ในกรณีอื่น $w_j = \frac{b}{2m}$

2.3.4 วิธีกฎของซิมป์สัน (Simpson's Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น $2m$ ช่วง โดยมีช่วงความกว้าง $h = \frac{b}{2m}$ ด้วยกฎของซิมป์สัน ที่มีการแบ่งช่วงเป็น $2m$ ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของซิมป์สันของแผนภูมิควบคุม DMEWMA แสดงดังสมการ (11)

$$\tilde{L}_S(u) = 1 + \frac{1}{\lambda_1\lambda_2 + k_1\lambda_2 + k_2\lambda_1 + k_1k_2}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (11)$$

โดยที่ $a_j = w_j j$, $w_j = \frac{4}{3}\left(\frac{b}{2m}\right); j = 1,3,...,2m-1$

และ $w_j = \frac{2}{3}\left(\frac{b}{2m}\right); j = 2,4,...,2m-2$ ในกรณีอื่น $w_j = \frac{1}{3}\left(\frac{b}{2m}\right)$

2.4 ขั้นตอนการจำลองข้อมูล

2.4.1 กำหนดให้ข้อมูลมีการแจกแจงแกมมาและกำหนดค่าพารามิเตอร์ เมื่อกระบวนการอยู่ภายใต้ขีดจำกัดการควบคุม (in-control process) α เท่ากับ 3 และ 5 β เท่ากับ 1 และ 2 ตามลำดับ

2.4.2 กำหนดค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุมที่ทำการศึกษา ดังนี้ λ_1 เท่ากับ 0.2 และ λ_2 เท่ากับ 0.1

2.4.3 กำหนดค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370

2.4.4 กำหนดระดับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการเท่ากับ 0.01, 0.03, 0.05, 0.1, 0.3, 0.5 และ1 ตามลำดับ

2.4.5 ประมาณค่าความยาวรันเฉลี่ย (ARL) โดยวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี

2.4.6 เปรียบเทียบค่าความยาวรันเฉลี่ย (ARL) และเวลาที่ใช้ในการประมวลผล (CPU Times) ของแต่ละวิธีการประมาณค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลข

2.4.7 เปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DMEWMA กับ แผนภูมิควบคุม MEWMA และ EWMA

3. ผลการวิจัยและอภิปรายผล

การวิจัยนี้ได้ศึกษาและเปรียบเทียบวิธีการประมาณค่าความยาวรันเฉลี่ย โดยวิธีสมการปริพันธ์เชิงตัวเลข สำหรับแผนภูมิควบคุม DMEWMA เมื่อข้อมูลมีการแจกแจงแกมมา โดยพิจารณาจากเวลาที่ใช้ในการประมวลผล (CPU Times) กำหนดให้ $ARL_0 = 370$ เมื่อกระบวนการอยู่ภายใต้การควบคุม กำหนดค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุมที่ศึกษา λ_1 เท่ากับ 0.2 และ λ_2 เท่ากับ 0.1 และกำหนดระดับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการเท่ากับ 0.01, 0.03, 0.05, 0.1, 0.3, 0.5 และ1 ตามลำดับ นอกจากนี้ทำการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DMEWMA กับ แผนภูมิควบคุม MEWMA และ EWMA โดยพิจารณาจากค่าความยาวรันเฉลี่ยเมื่อกระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

ตารางที่ 1: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุม DMEWMA สำหรับข้อมูลที่มีการแจกแจงแกมมา เมื่อกำหนดให้ λ_1=0.2 , λ_2 =0.1 , k_1=1 ,k_2=2 และ ARL_0 = 370

δ	Gamma(3,1)				Gamma(5,2)			
	Midpoint	**Trapezoidal**	**Simpson**	**Gaussian**	**Midpoint**	**Trapezoidal**	**Simpson**	**Gaussian**
	b = 12.721732				**b = 17.299448**			
0	370 **(1.000)**	370 (1.375)	370 (3.844)	370 (3.266)	370 **(1.078)**	370 (1.328)	370 (4.797)	370 (4.015)
0.01	342.676 **(1.078)**	342.676 (1.172)	342.676 (5.156)	342.676 (5.547)	329.619 **(1.031)**	329.619 (1.047)	329.619 (5.438)	329.619 (3.796)
0.03	298.305 (1.109)	298.305 **(0.969)**	298.305 (3.812)	298.305 (2.938)	269.056 (1.187)	269.056 **(1.125)**	269.056 (5.500)	269.056 (4.048)
0.05	263.856 **(0.844)**	263.856 (0.922)	263.856 (3.547)	263.856 (3.187)	225.914 **(1.126)**	225.914 (1.172)	225.914 (4.872)	225.914 (4.078)
0.1	204.159 (1.047)	204.159 **(0.375)**	204.159 (5.703)	204.159 (3.469)	158.290 **(0.766)**	158.290 (1.147)	158.290 (4.844)	158.290 (3.703)

0.3	105.165 **(1.125)**	105.165 (1.406)	105.165 (4.281)	105.165 (3.687)	64.673 **(1.079)**	64.673 (1.125)	64.673 (3.547)	64.673 (3.187)
0.5	69.158 **(1.062)**	69.158 (1.250)	69.158 (5.469)	69.158 (3.750)	37.289 (1.266)	37.289 **(1.188)**	37.289 (5.781)	37.289 (4.281)
1	34.302 **(1.031)**	34.302 (1.125)	34.302 (3.907)	34.302 (3.704)	15.883 **(1.391)**	15.883 (1.422)	15.883 (4.453)	15.883 (3.500)

จากตารางที่ 1 จะเห็นได้ว่า การประมาณค่า ARL โดยวิธีสมการปริพันธ์เชิงตัวเลขสำหรับแผนภูมิควบคุม DMEWMA ทั้ง 4 วิธี เมื่อพิจารณาจากค่า ARL มีค่าไม่แตกต่างกันในทุกระดับการเปลี่ยนแปลง และเมื่อพิจารณาจากเวลาที่ใช้ในการประมวลผล (CPU Times) ที่น้อยที่สุด มี 2 วิธี คือ วิธีกฎของค่ากลางและวิธีกฎของสี่เหลี่ยมคางหมูที่ใช้เวลาในการประมวลผลใกล้เคียงกัน

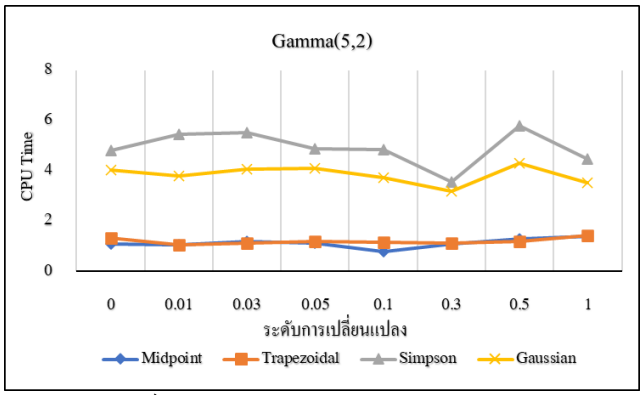

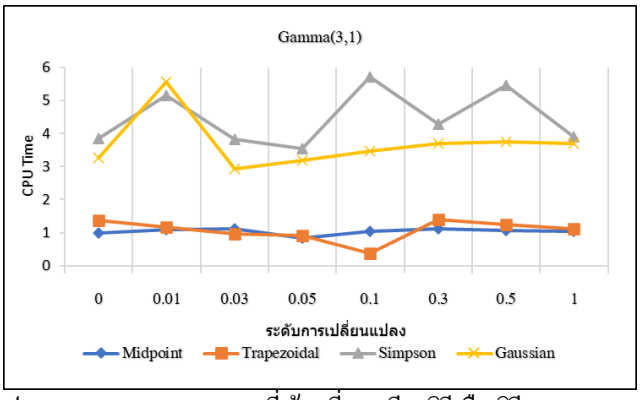

ภาพที่ 1: การเปรียบเทียบเวลาในการประมวลผลโดยวิธีสมการปริพันธ์เชิงตัวเลขของแผนภูมิควบคุม DMEWMA สำหรับข้อมูลที่มีการแจกแจงแกมมา

ตารางที่ 2: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุม DMEWMA กับแผนภูมิควบคุม MEWMA และแผนภูมิควบคุม EWMA สำหรับข้อมูลที่มีการแจกแจงแกมมาพารามิเตอร์ $\alpha = 3$ และ $\beta = 1$ เมื่อกำหนดค่า $k_1 = 1$ และ $\lambda_1 = 0.2, \lambda_2 = 0.1$ โดยใช้วิธีกฎของค่ากลาง

δ	EWMA	MEWMA	DMEWMA			
		$k_1 = 1$	$k_1 = 1$			
			k_2= 0.05	k_2= 0.5	k_2= 1	k_2= 2
	b=4.79089	b=23.758595	b=0.00650345	b=2.1747757	b=3.977218	b=12.721732
0	370 (1.250)	370 (0.937)	370 (1.234)	370 (1.344)	370 (1.640)	370 (1.000)
0.01	323.078 (0.719)	322.848 (0.938)	343.017 (1.078)	**280.260** (1.750)	317.866 (1.093)	342.676 (1.078)
0.03	250.108 (0.765)	249.534 (0.906)	295.875 (1.235)	**186.198** (1.047)	246.902 (1.234)	298.305 (1.109)
0.05	197.372 (0.985)	196.565 (0.922)	256.388 (0.907)	**137.630** (1.016)	200.951 (1.656)	263.856 (0.844)
0.1	117.775 (0.937)	116.667 (0.875)	182.590 (1.172)	**80.733** (0.859)	135.570 (1.734)	204.159 (1.047)
0.3	32.232 (0.735)	31.035 (0.968)	58.384 (1.734)	**26.794** (0.921)	56.026 (1.610)	105.165 (1.125)
0.5	16.892 (0.656)	15.841 (0.938)	24.180 (1.750)	**14.882** (1.219)	34.097 (1.767)	69.158 (1.062)
1	7.972 (0.453)	7.167 (0.828)	**5.504** (1.406)	6.481 (1.016)	15.974 (0.937)	34.302 (1.031)

ตารางที่ 3: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุม DMEWMA กับแผนภูมิควบคุม MEWMA และแผนภูมิควบคุม EWMA สำหรับข้อมูลที่มีการแจกแจงแกมมาพารามิเตอร์ $\alpha = 5$ และ $\beta = 2$ เมื่อกำหนดค่า $k_1 = 1$ และ $\lambda_1 = 0.2, \lambda_2 = 0.1$ โดยใช้วิธีกฎของค่ากลาง

δ	EWMA	MEWMA	DMEWMA			
		$k_1 = 1$	$k_1 = 1$			
			k_2= 0.05	k_2= 0.5	k_2= 1	k_2= 2
	b=14.448184	b=81.69531	b=1.1912739	b=5.0326645	b=9.201296	b=17.299448
0	370 (0.672)	370 (0.718)	370 (1.000)	370 (1.468)	370 (1.046)	370 (1.078)
0.01	339.395 (0.578)	339.351 (1.187)	272.60 (0.797)	**254.945** (1.406)	301.26 (1.281)	329.619 (1.031)
0.03	287.257 (0.781)	287.142 (0.891)	176.464 (0.813)	**154.666** (1.046)	217.526 (0.984)	269.056 (1.187)
0.05	244.996 (0.609)	244.825 (0.937)	128.903 (0.938)	**109.311** (1.063)	168.511 (1.390)	225.914 (1.126)
0.1	169.892 (0.688)	169.629 (0.703)	74.559 (0.891)	**60.712** (0.891)	104.844 (1.266)	158.290 (0.766)
0.3	57.439 (0.828)	57.080 (0.797)	23.186 (0.937)	**18.389** (0.969)	36.274 (1.437)	64.673 (1.079)
0.5	29.663 (0.625)	29.312 (0.843)	11.545 (0.984)	**9.620** (1.047)	19.737 (1.469)	37.289 (1.266)
1	12.916 (0.812)	12.617 (0.812)	**3.802** (0.953)	3.974 (1.516)	8.096 (0.844)	15.883 (1.391)

ตารางที่ 4: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุม DMEWMA กับแผนภูมิควบคุม MEWMA และแผนภูมิควบคุม EWMA สำหรับข้อมูลที่มีการแจกแจงแกมมาพารามิเตอร์ $\alpha = 3$ และ $\beta = 1$ เมื่อกำหนดค่า $k_1 = -\lambda/2$ และ $\lambda_1 = 0.2, \lambda_2 = 0.1$ โดยใช้วิธีกฎของค่ากลาง

δ	EWMA	MEWMA	DMEWMA			
		$k_1 = -\lambda/2$	$k_1 = -\lambda/2$			
			$k_2 = -\lambda/2$	k_2= 0.05	k_2= 0.5	k_2= 1
	b=4.79089	b=0.000112346	b=7.9749x10^{-89}	b=2.62573x10^{-32}	b=2.28895x10^{-10}	b=8.64616x10^{-7}
0	370 (1.250)	370 (0.844)	370 (1.625)	370 (1.500)	370 (0.922)	370 (0.562)
0.01	323.078 (0.719)	328.598 (0.407)	**52.949** (1.063)	185.487 (1.016)	297.731 (0.875)	319.886 (1.078)
0.03	250.108 (0.765)	260.780 (0.516)	**2.153** (1.406)	48.974 (0.500)	195.168 (1.297)	240.978 (1.109)
0.05	197.372 (0.985)	208.601 (0.718)	**1.030** (1.204)	14.118 (1.187)	129.981 (0.968)	183.360 (1.156)
0.1	117.775 (0.937)	123.273 (1.047)	**1.000** (1.359)	1.627 (1.281)	50.284 (1.468)	96.464 (1.172)
0.3	32.232 (0.735)	22.029 (0.906)	**1.000** (1.025)	1.000 (1.187)	3.094 (1.688)	12.217 (1.109)
0.5	16.892 (0.656)	6.438 (0.719)	**1.000** (1.063)	1.000 (1.297)	1.194 (1.422)	3.193 (0.891)
1	7.972 (0.453)	1.512 (0.906)	**1.000** (1.110)	1.000 (1.166)	1.003 (1.750)	1.131 (0.875)

ตารางที่ 5: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุม DMEWMA กับแผนภูมิควบคุม MEWMA และแผนภูมิควบคุม EWMA สำหรับข้อมูลที่มีการแจกแจงแกมมาพารามิเตอร์ $\alpha = 5$ และ $\beta = 2$ เมื่อกำหนดค่า $k_1 = -\lambda/2$ และ $\lambda_1 = 0.2, \lambda_2 = 0.1$ โดยใช้วิธีกฎของค่ากลาง

δ	EWMA	MEWMA	DMEWMA			
		$k_1 = -\lambda/2$	$k_1 = -\lambda/2$			
			$k_2 = -\lambda/2$	$k_2 = 0.05$	$k_2 = 0.5$	$k_2 = 1$
	b=14.448184	b=0.0640507	b=1.77704×10^{-48}	b=7.9487×10^{-19}	b=3.25287×10^{-6}	b=0.00085255
0	370 (0.672)	370 (0.906)	370 (0.969)	370 (1.406)	370 (1.453)	370 (1.250)
0.01	339.395 (0.578)	353.182 (0.671)	**222.580** (1.359)	305.658 (0.797)	344.297 (1.500)	350.568 (1.360)
0.03	287.257 (0.781)	322.136 (0.781)	**82.082** (1.109)	209.779 (1.453)	298.662 (1.203)	315.106 (1.516)
0.05	244.996 (0.609)	294.215 (0.968)	**31.244** (1.219)	145.064 (1.375)	259.689 (1.390)	283.695 (1.422)
0.1	169.892 (0.688)	235.882 (0.891)	**3.784** (1.313)	59.651 (1.469)	184.914 (1.391)	219.704 (1.485)
0.3	57.439 (0.828)	104.866 (0.828)	**1.001** (1.172)	3.322 (1.625)	54.136 (1.390)	86.406 (1.407)
0.5	29.663 (0.625)	51.552 (0.859)	**1.000** (1.344)	1.149 (1.422)	19.085 (1.469)	38.440 (1.532)
1	12.916 (0.812)	12.366 (1.016)	**1.000** (1.515)	1.001 (1.360)	3.048 (1.469)	7.887 (1.078)

จากตารางที่ 2 และตารางที่ 3 เมื่อกำหนดค่า $k_1 = 1$ จะเห็นได้ว่า แผนภูมิควบคุม DMEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีกว่าแผนภูมิควบคุม MEWMA และ EWMA ในทุกระดับการเปลี่ยนแปลง และเห็นได้ว่าเมื่อกำหนดค่า k_2 บนแผนภูมิควบคุม DMEWMA เท่ากับ 0.5 และ 0.05 สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กและขนาดใหญ่ได้ดีตามลำดับ

ตารางที่ 4 และตารางที่ 5 เมื่อกำหนดค่า $k_1 = -\lambda/2$ จะเห็นได้ว่า แผนภูมิควบคุม DMEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีกว่าแผนภูมิควบคุม MEWMA และ EWMA ในทุกระดับการเปลี่ยนแปลง

4. สรุปผลการวิจัย

จากผลการวิจัยพบว่า ARL ของแผนภูมิควบคุม DMEWMA สำหรับข้อมูลที่มีการแจกแจงแกมมาที่ได้จากวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธีมีค่า ARL ไม่แตกต่างกัน แต่เมื่อพิจารณาจากความเร็วในการประมวลผลพบว่าวิธีกฎค่ากลางและวิธีกฎสี่เหลี่ยมคางหมูใช้เวลาในการประมวลผลน้อยที่สุด โดยเวลาที่ใช้เวลาประมวลผลไม่เกิน 1-2 วินาที ส่วนวิธีกฎเกาส์และวิธีกฎของซิมป์สัน ใช้เวลาในการประมวลผลมากกว่าซึ่งใช้เวลาประมาณ 2-5 วินาที

จากการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม พบว่าแผนภูมิควบคุม DMEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีกว่าแผนภูมิควบคุม MEWMA แผนภูมิควบคุม EWMA ในทุกระดับการเปลี่ยนแปลง นอกจากนี้ เมื่อกำหนดค่า k_1 เท่ากับ 1 และ k_2 เท่ากับ 0.05 ,0.5 ,1 และ 2 จะเห็นได้ว่าที่ k_2 เท่ากับ 0.5 สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีกว่ากรณีอื่นๆ แต่เมื่อกำหนด k_2 เท่ากับ 0.05 สามารถตรวจจับการเปลี่ยนแปลงขนาดใหญ่ได้ดี และเมื่อกำหนด ค่า k_1 และ k_2 เท่ากับ $-\lambda/2$ ประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงจะเกิดขึ้นได้ไวกว่าอย่างเห็นได้ชัด ดังนั้นในงานวิจัยครั้งต่อไปผู้วิจัยจึงสนใจที่จะนำแผนภูมิควบคุม DMEWMA มาใช้กับข้อมูลที่มีการแจกแจงชนิดอื่น และนำไปประยุกต์ใช้กับข้อมูลจริง

5. เอกสารอ้างอิง

[1] W.A.Shewhart, Economic control of quality of manufactured product. Martino Fine Books 2015 Reprint of 1931.

[2] Roberts, S.W. (1959). Control chart test based on geometric moving average. Technometrics, 1(3), 239-250.

[3] A.K. Patel and J.Divecha, "Modified exponentially weighted moving average (EWMA) control chart for an analytical process data," *Journal of chemical Engineering and Materials Science,* vol. 2, pp. 12-20, 2011.

[4] N. Khan, M. Aslam, and C. Jun, "Design of a control chart using a modified EWMA statistic," Quality and Reliability Engineering International, vol. 33, pp.100-114, 2017.

[5] Alevizakos, V., Chatterjee, K., & Koukouvinos, C. (2021). Modified EWMA and DEWMA control charts for process monitoring. Communications in Statistics-Theory and Methods, 51(21), 7390-7412.

[6] J. Neammai, Y. Areepong and S. Sukparungsee, "Performance Comparison of Numerical Integral Equation Methods on DMEWMA Control Chart for Moving Average Process Order q," *2023 Research, Invention, and Innovation Congress: Innovative Electricals and Electronics (RI2C)*, Bangkok, Thailand, 2023, pp. 211-215.

ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง สำหรับตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง โดยวิธีสมการปริพันธ์เชิงตัวเลข

Average Run Length of Exponentially Weighted Moving Average Control Chart for AR(p) with Quadratic Trend Models using Numerical Integral Equation

นริศรา กองดวง* สุวิมล พันธ์แย้ม

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* *naritsara.knk@gmail.com*)

บทคัดย่อ

การวิจัยนี้ศึกษาวิธีประมาณค่าความยาวรันเฉลี่ย (Average Run Length: ARL) สำหรับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average control chart: EWMA) โดยวิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE) 4 วิธี ได้แก่ วิธีกฎเกาส์ (Gaussian Rule Method) วิธีกฎค่ากลาง (Midpoint Rule Method) วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) และวิธีกฎซิมป์สัน (Simpson's Rule Method) ศึกษาภายใต้ตัวแบบการถดถอยในตัวอันดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) เมื่อความคลาดเคลื่อนมีการแจกแจงแบบเลขชี้กำลัง โดยเกณฑ์วัดประสิทธิภาพจะพิจารณาค่าความยาวรันเฉลี่ย (Average Run Length: ARL) และเวลาที่ใช้ในการประมวลผล (CPU Times) จากผลการวิจัยพบว่า ค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธีไม่แตกต่างกัน และระยะเวลา ที่ใช้ในการประมวลผลของวิธีกฎสี่เหลี่ยมคางหมู และวิธีกฎค่ากลาง มีค่าน้อยที่สุด

คำสำคัญ: แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง, ค่าความยาวรันเฉลี่ย, วิธีสมการปริพันธ์เชิงตัวเลข

Abstract

This research investigates methods for approximating the Average Run Length (ARL) for an Exponentially Weighted Moving Average (EWMA) control chart using the Numerical Integral Equation (NIE) method including the Gaussian Rule Method, the Midpoint Rule Method, the Trapezoidal Rule Method, and the Simpson's Rule Method. The study is based on a Autoregressive of order p model with a quadratic trend when the white noise term follows an exponential distribution. In addition, the performance evaluation is based on the Average Run Length (ARL) and CPU times. The results indicate that the ARL values obtained from all four NIE methods do not significantly differ, and the CPU times for the Trapezoidal Rule Method and the Midpoint Rule Method are the shortest.

Keywords: Exponentially Weighted Moving Average Control Chart, Average Run Length, Numerical Integral Equation Method

1. บทนำ

การควบคุมคุณภาพเป็นส่วนสำคัญที่ทำให้กระบวนการผลิตสินค้ามีคุณภาพและเป็นไปตามมาตรฐานในกระบวนการควบคุมคุณภาพ การเลือกใช้เครื่องมือหรือวิธีการใดๆ ย่อมส่งผลต่อการควบคุมมาตรฐานในการผลิตสินค้าและบริการ การตัดสินใจโดยใช้วิธีการเชิงสถิติจึงเป็นวิธีการสำคัญ เครื่องมือที่ใช้ในการควบคุมคุณภาพ เช่น แผ่นตรวจสอบ แผนภาพก้างปลา ฮิสโตรแกรม แผนภูมิพาเรโต และแผนภูมิควบคุม เป็นต้น ซึ่งแผนภูมิควบคุมเป็นเครื่องมือที่นิยมใช้ กันอย่างแพร่หลายที่สามารถตรวจจับกระบวนการที่ออกนอกการควบคุมได้อย่างมีประสิทธิภาพ

ในปี ค.ศ. 1931 Shewhart W.A. [1] เสนอแผนภูมิควบคุมชิวฮาร์ท (Shewhart Control Chart) เมื่อค่าสังเกตมีการแจกแจงปกติ โดยมีการคำนวณค่าเฉลี่ย และใช้ขีดจำกัดบนและขีดจำกัดล่าง ในการตวรจจับกระบวนการ พบว่าแผนภูมิควบคุมชิวฮาร์ทมีประสิทธิภาพในการตรวจจับกระบวนการเมื่อกระบวนการมีการเปลี่ยนแปลงขนาดใหญ่ แนวคิดนี้จึงนำไปสู่การพัฒนาแผนภูมิควบคุมในรูบแบบต่างๆ รวมถึงแผนภูมิควบคุมที่ให้ความสำคัญกับข้อมูลในอดีตและข้อมูลปัจจุบัน ในปี ค.ศ.1954 Page E.S. [2] ได้เสนอแผนภูมิควบคุมผลรวมสะสม (Cumulative Sum control chart: CUSUM) และ ค.ศ.1959 Roberts S.W. [3] ได้เสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average control chart: EWMA) ซึ่งพบว่าทั้งสองแผนภูมิมีประสิทธิภาพในการตรวจจับใกล้เคียงกัน เมื่อกระบวนการมีการเปลี่ยนแปลงขนาดเล็ก

การวัดประสิทธิภาพของแผนภูมิควบคุม สามารถวัดโดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL)พิจารณาจาก 2 สถานะ คือ เมื่อกระบวนการอยู่ภายใต้การควบคุม (in-control ARL: ARL_0) และเมื่อกระบวนการออกนอกการควบคุม (out-of-control ARL: ARL_1)โดยค่าความยาวรันเฉลี่ยสามารถคำนวณได้จากหลายวิธี เช่น การจำลองมอนติคาร์โล (Monte Carlo Simulations) วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation) เป็นต้น

ข้อมูลอนุกรมเวลาจะแตกต่างกันไปตามลักษณะของข้อมูล แต่มีบางกรณีที่ข้อมูลจะเกิด อัตตสหสัมพันธ์ เช่น ตัวแบบการถดถอยในตัว (Autoregressive Model: AR(p)) ตัวแบบการเฉลี่ยเคลื่อนที่ (Moving Average Model: MA(q)) ตัวแบบรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average Model: ARIMA(p,d,q)) เป็นต้น โดยทั่วไปพบว่า ความคลาดเคลื่อนของข้อมูลอนุกรมเวลาจะมีการแจกแจงปกติ เรียกว่า White noise แต่ข้อมูลอนุกรมเวลาที่มีการถดถอยในตัวเรียกว่า Exponential white noise และมีรูปแบบการแจกแจงแบบเลขชี้กำลัง(White Noise Process with Exponential Distribution)

ในปี ค.ศ 2017 Sukparungsee S. และ Areepong Y. [4] ได้เสนอสูตรสำเร็จในการคำนวณค่าความยาวรันเฉลี่ย โดยใช้วิธีสมการปริพันธ์ของแผนภูมิควบคุม EWMA เมื่อข้อมูลเป็นตัวแบบการถดถอยในตัว (Autoregressive Model: AR(p)) และเปรียบเทียบผลลัพธ์กับวิธีสมการปริพันธ์เชิงตัวเลขตามกฎเกาส์ ต่อมาใน ค.ศ. 2021 Phanyaem S. [5]ได้เสนอสูตรความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA เมื่อข้อมูลเป็นตัวแบบรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่โดยวิธีสมการปริพันธ์ และ ค.ศ 2024 Phanyaem S. [6] ได้เสนอการคำนวณค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA เมื่อข้อมูลเป็นตัวแบบการถดถอยในตัวลำดับที่ 1 ที่มีแนวโน้มกำลังสอง

ในการวิจัยครั้งนี้ ผู้วิจัยสนใจศึกษาแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) ภายใต้ตัวแบบการถดถอยในตัวอันดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) โดยผู้วิจัยเสนอวิธีการประมาณค่าความยาวรันเฉลี่ยโดยใช้วิธีสมการปริพันธ์เชิงตัวเลข 4 วิธี ได้แก่ วิธีกฎเกาส์ (Guassian Rule) วิธีกฎค่ากลาง (Midpoint Rule) วิธีกฎซิมป์สัน (Simpson Rule) และวิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule) โดยเปรียบเทียบประสิทธิภาพจากระยะเวลาที่ใช้ในการประมวลผล (CPU Times) โดยใช้โปรแกรม Wolfram Mathematica 8.0 เป็นเครื่องมือในการประมวลผล

2. วิธีการวิจัย

2.1 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA)

เสนอโดย Roberts, S.W.[3] แผนภูมิควบคุม EWMA เป็นแผนภูมิควบคุมที่ให้ความสำคัญกับข้อมูลในอดีตและข้อมูลปัจจุบันที่มีประสิทธิภาพในการตรวจจับกระบวนการเปลี่ยนแปลงขนาดเล็ก แสดงดังสมการ (1) ดังนี้

$$Z_t = (1-\lambda)Z_{t-1} + \lambda Y_t; t = 1, 2, .. \quad (1)$$

โดยที่ Z_t แทน ค่าสถิติของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง ณ เวลา t

λ แทน ค่าพารามิเตอร์ถ่วงน้ำหนักของข้อมูลในอดีต เมื่อ $0 \le \lambda \le 1$

Y_t แทน ค่าสังเกต ณ เวลาที่ t

2.2 ตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง AR(p) with quadratic trend models

ตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง ดังสมการที่ (2) ดังนี้

$$Y_t = \mu + \phi_1 Y_{t-1} + .. + \phi_p Y_{t-p} + \beta_1 t + \beta_2 t^2 + \varepsilon_t; t = 1, 2, .. \quad (2)$$

โดยที่ Y_t แทน ค่าสังเกต ณ เวลาที่ t

β_1 แทน ค่าพารามิเตอร์ของตัวแปรเชิงเส้น

β_2 แทน ค่าพารามิเตอร์ของตัวแปรเชิงเส้นกำลังสอง

μ แทน ค่าคงที่ของกระบวนการ

ϕ_t แทนค่าพารามิเตอร์ของตัวแบบถดถอยในตัว $t = 1, 2, .. p$

ε_t แทน ค่าความคลาดเคลื่อนที่มีการแจกแจงแบบเลขชี้กำลัง

2.3 วิธีสมการปริพันธ์เชิงตัวเลข

กำหนดให้สมการปริพันธ์ $H(u) = ARL$ ของแผนภูมิควบคุม EWMA เมื่อกำหนดค่าเริ่มต้น $Z_0 = u$ และ $u \in [0,b]$ สมการปริพันธ์แสดงดังสมการ (3)

$$ARL = H(u) = E_{\infty}(\tau_b) < \infty \tag{3}$$

โดยที่ τ_b แทน คาบเวลาที่แผนภูมิควบคุมจะส่งสัญญาณเตือนว่ากระบวนการออกนอกการควบคุม

$$\tau_b = \inf\{t > 0; Z_t > b\}; b > u \tag{4}$$

เมื่อ b แทน ขีดจำกัดควบคุมบนของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก

โดยการหาค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(p) ที่มีแนวโน้มกำลังสอง แสดงดังสมการที่ (5) ดังนี้

$$H(u) = 1 + \frac{1}{\lambda}\int_0^b H(y) f\left[\frac{y-(1-\lambda)u}{\lambda} - k\right] dy \tag{5}$$

เมื่อ $k = \mu + \phi_1 Y_{t-1} + .. + \phi_p Y_{t-p} + \beta_1 t + \beta_2 t^2$

จากสมการที่ (5) ใช้วิธีกฎการสร้างพื้นที่สี่เหลี่ยมจัตุรัสในการประมาณค่าอินทิกรัล ดังสมการที่ (6)

$$\tilde{H}(a_i) \approx 1 + \frac{1}{\lambda}\sum_{j=1}^{m} w_j \tilde{H}(a_j) f\left[\frac{a_j-(1-\lambda)a_i}{\lambda} - k\right] dy \tag{6}$$

วิธีสมการปริพันธ์เชิงตัวเลข ที่ใช้ในงานวิจัยมี 4 วิธี ดังนี้

2.3.1 วิธีกฎเกาส์ (Gaussian Rule)

จากสมการที่ (6) กำหนดให้

$$f(A_j) = f\left[\frac{y-(1-\lambda)u}{\lambda} - k\right]$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ จะอยู่ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b H(y) f(y)\, dy \approx \sum_{j=1}^{m} w_j f(a_j)$$

โดยที่ $H(y) = 1, -1 < y < 1$

สามารถเขียนการประมาณค่าจากวิธีสมการปริพันธ์เชิงตัวเลขของวิธีกฎเกาส์ แสดงดังสมการที่ (7)

$$\tilde{H}_G(u) \approx 1 + \frac{1}{\lambda}\sum_{j=1}^{m} w_j H(a_j) f(A_j) \tag{7}$$

2.3.2 วิธีกฎค่ากลาง (Midpoint Rule)

วิธีกฎค่ากลางกำหนดให้ $H(y) = 1$ และ $f(y)$ บนช่วง $[0,b]$ แบ่งเป็น m ช่วง โดยแต่ละช่วงกว้าง $h = \frac{b-0}{m}$ จากกฎค่ากลางสามารถเขียนดังสมการ

$$M(f,h) = h\sum_{j=1}^{m} f\left(\left(j - \frac{1}{2}\right)h\right); j = 0,1,2,..,m$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ จะอยู่ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b f(y) dy \approx M(f,h)$$

สามารถเขียนการประมาณค่าจากวิธีสมการปริพันธ์เชิงตัวเลขของวิธีกฎค่ากลาง แสดงดังสมการที่ (8)

$$\tilde{H}_M(u) \approx 1 + \frac{1}{\lambda}\sum_{j=1}^{m} w_j H(a_j) f(A_j) \tag{8}$$

โดยที่ $a_j = \frac{b}{m}\left(j - \frac{1}{2}\right)$ และ $w_j = \frac{b}{m}; j = 1,2,.,m$

2.3.3 วิธีกฎซิมป์สัน (Simpson Rule)

วิธีกฎซิมป์สันกำหนดให้ $H(y) = 1$ และ $f(y)$ บนช่วง $[0,b]$ แบ่งเป็น $2m$ ช่วง โดยแต่ละช่วงกว้าง $h = \frac{b-0}{2m}$ จากกฎซิมป์สันสามารถเขียนดังสมการ

$$S(f,h) = \frac{h}{3}(f(0) - f(b)) + \frac{2h}{3}\sum_{j=1}^{m} f(y_{2j})$$

$$+ \frac{4h}{3}\sum_{j=1}^{m} f(y_{2j-1}); j = 0,1,2,..,m$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ จะอยู่ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b f(y) dy \approx S(f,h)$$

สามารถเขียนการประมาณค่าจากวิธีสมการปริพันธ์เชิงตัวเลขของวิธีกฎซิมป์สัน แสดงดังสมการที่ (9)

$$\tilde{H}_S(u) \approx 1 + \frac{1}{\lambda}\sum_{j=1}^{2m+1} w_j H(a_j) f(A_j) \tag{9}$$

โดยที่ $a_j = jw_j$, $w_j = \frac{4}{3}\left(\frac{b}{2m}\right); j = 1,..,2m-1$

และ $w_j = \frac{2}{3}\left(\frac{b}{2m}\right); j = 2,..,2m-2$

ในกรณีอื่นๆ $w_j = \frac{1}{3}\left(\frac{b}{2m}\right)$

2.3.4 วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule)

วิธีกฎสี่เหลี่ยมคางหมูกำหนดให้ $H(y) = 1$ และ $f(y)$ บนช่วง $[0,b]$ แบ่งเป็น m ช่วง โดยแต่ละช่วงกว้าง $h = \frac{b-0}{m}$ จากกฎสี่เหลี่ยมคางหมูสามารถเขียนดังสมการ

$$T(f,h) = \frac{h}{2}(f(0) - f(b)) + h\sum_{j=1}^{m} f(y_j); j = 0,1,2,.,m$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ จะอยู่ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b f(y)dy \approx T(f,h)$$

สามารถเขียนการประมาณค่าจากวิธีสมการปริพันธ์เชิงตัวเลขของวิธีกฎซิมป์สัน แสดงดังสมการที่ (10)

$$\tilde{H}_T(u) \approx 1+\frac{1}{\lambda}\sum_{j=1}^{m+1} w_j H(a_j) f(A_j) \qquad (10)$$

โดยที่ $a_j = jw_j$ และ $w_j = \frac{b}{m}; j = 1,2,.,m-1$

ในกรณีอื่นๆ $w_j = \frac{b}{2m}$

2.4 ขั้นตอนการจำลองข้อมูล

2.4.1 กำหนดให้ค่าความคลาดเคลื่อนมีการแจกแจงแบบเลขชี้กำลัง เมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) ค่าพารามิเตอร์ $\alpha = \alpha_0$ มีค่าเท่ากับ 1 และกระบวนการออกนอกการควบคุม (ARL_1) ค่าพารามิเตอร์ $\alpha = \alpha_1$ มีค่าเท่ากับ 1.01, 1.03, 1.05, 1.1, 1.3, 1.5, 2.0, และ 3.0 ตามลำดับ

2.4.2 กำหนดค่าพารามิเตอร์ถ่วงนำหนักของข้อมูลในอดีต λ มีค่า 0.05 0.1 และ 0.2

2.4.3 กำหนดค่าเริ่มต้นของค่าสถิติแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Z_0), (Z_1) และ (Z_2) คือ 1

2.4.4 กำหนดค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง เมื่อกระบวนการอยู่ภายใต้การควบคุม ARL_0 เท่ากับ 370

2.4.5 ประมาณค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลข ด้วยวิธีกฎเกาส์ กฎค่ากลาง กฎซิมป์สัน และกฎสี่เหลี่ยมคางหมูกำหนดจุดแบ่ง (m) เท่ากับ 500

2.4.6 ค่าพารามิเตอร์ของตัวแบบการถดถอยในตัวอันดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) ดังนี้

(1) ตัวแบบ AR(1) ที่มีแนวโน้มกำลังสอง
- ค่าพารามิเตอร์ของตัวแบบถดถอยในตัว (ϕ_1) = 0.1, -0.1
- ค่าพารามิเตอร์ของตัวแปรเชิงเส้น (β_1) เท่ากับ 0.1 และค่าพารามิเตอร์ตัวแปรเชิงเส้นกำลังสอง (β_2) เท่ากับ 0.2

(2) ตัวแบบ AR(2) ที่มีแนวโน้มกำลังสอง
- ค่าพารามิเตอร์ของตัวแบบถดถอยในตัว (ϕ_1) และ (ϕ_2) เท่ากับ ($\phi_1 = 0.2,\ \phi_2 = 0.2$), ($\phi_1 = -0.2,\ \phi_2 = -0.2$)
- ค่าพารามิเตอร์ของตัวแปรเชิงเส้น (β_1) เท่ากับ 0.2 และค่าพารามิเตอร์ตัวแปรเชิงเส้นกำลังสอง (β_2) เท่ากับ 0.2

(3) ตัวแบบ AR(3) ที่มีแนวโน้มกำลังสอง
- ค่าพารามิเตอร์ของตัวแบบถดถอยในตัว (ϕ_1),(ϕ_2) และ (ϕ_3) เท่ากับ ($\phi_1 = 0.1,\ \phi_2 = 0.15,\ \phi_3 = 0.2$), ($\phi_1 = -0.1,\ \phi_2 = -0.15,\ \phi_3 = -0.2$)
- ค่าพารามิเตอร์ของตัวแปรเชิงเส้น (β_1) เท่ากับ 0.2 และค่าพารามิเตอร์ตัวแปรเชิงเส้นกำลังสอง (β_2) เท่ากับ 0.2

2.4.7 หาค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลข ทั้ง 4 วิธี

2.4.8 เปรียบเทียบค่าความยาวรันเฉลี่ย และเวลาที่ใช้ในการประมวลผล

3. ผลการวิจัยและอภิปรายผล

งานวิจัยนี้ได้ศึกษาวิธีการประมาณค่าความยาวรันเฉลี่ยสำหรับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) สำหรับตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) โดยวิธีสมการปริพันธ์เชิงตัวเลข ทั้ง 4 วิธี และเปรียบเทียบประสิทธิภาพจากระยะเวลาที่ใช้ในการประมวลผล (CPU Times) เมื่อกระบวนการอยู่ภายใต้การควบคุม (in-control ARL: ARL_0) เท่ากับ 370 กำหนดค่าถ่วงน้ำหนักของแผนภูมิควบคุม λ เท่ากับ 0.05 0.1 และ 0.2 และกำหนดระดับการเปลี่ยนแปลงของกระบวนการ α_1 เท่ากับ 1.01, 1.03, 1.05, 1.1, 1.3, 1.5, 2.0, และ 3.0 ตามลำดับ

ตารางที่ 1 และตารางที่ 2 แสดงการเปรียบเทียบค่าความยาวรันเฉลี่ยภายใต้ตัวแบบ AR(1) with quadratic trend เมื่อกำหนดค่าพารามิเตอร์ $\beta_1 = 0.1, \beta_2 = 0.2$ ตารางที่ 1 กำหนดค่า $\phi_1 = 0.1$ และตารางที่ 2 กำหนดค่า $\phi_1 = -0.1$ พบว่าค่า ARL ที่ได้จากทั้ง 4 วิธี ให้ผลลัพธ์ไม่แตกต่างกัน เมื่อเปรียบเทียบประสิทธิภาพพบว่าวิธีกฎค่ากลาง และวิธีกฎสี่เหลี่ยมคางหมู ใช้เวลาในการประมวลผลน้อยที่สุด และเมื่อพิจารณาค่าพารามิเตอร์ปรับให้เรียบแบบเลขชี้กำลัง (λ) ที่มีค่าเท่ากับ 0.05, 0.1 และ 0.2 ตามลำดับ พบว่าแผนภูมิควบคุม EWMA เมื่อกำหนดให้ λ มีค่าเท่ากับ 0.05 มีความไวในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยได้เร็วกว่า λ ในระดับอื่นๆ

ตารางที่ 3 และตารางที่ 4 แสดงการเปรียบเทียบค่าความยาวรันเฉลี่ยภายใต้ตัวแบบ AR(2) with quadratic trend เมื่อกำหนดค่าพารามิเตอร์ $\beta_1 = 0.2,\ \beta_2 = 0.2$ ตารางที่ 3 กำหนดค่า $\phi_1 = 0.2$ และ $\phi_2 = 0.2$ ตารางที่ 4 กำหนดค่า $\phi_1 = -0.2$ และ $\phi_2 = -0.2$ ผลการศึกษา พบว่า ค่า ARL ที่ได้จากวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี ไม่แตกต่างกัน การเปรียบเทียบประสิทธิภาพพบว่าวิธีกฎค่ากลาง และ

ตารางที่ 1: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(1) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi = 0.1, \beta_1 = 0.1, \beta_2 = 0.2$ และ $ARL_0 = 370$

λ = 0.05 , b = 0.0000000692919								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	302.499	8.828	302.499	8.032	302.499	1.984	302.499	1.984
1.03	204.606	8.641	204.606	8.031	204.606	1.984	204.606	2.234
1.05	140.518	9.047	140.518	7.719	140.518	1.984	140.518	2.125
1.10	58.5037	9.734	58.5037	7.703	58.5037	1.985	58.5037	2.156
1.30	4.22686	9.437	4.22686	7.782	4.22686	2.031	4.22686	2.282
1.50	1.38238	9.171	1.38238	7.985	1.38238	1.922	1.38238	2.125
2.00	1.01131	9.672	1.01131	7.844	1.01131	1.969	1.01131	2.000
3.00	1.0003	9.156	1.0003	7.750	1.0003	2.000	1.0003	2.094
λ = 0.1 , b = 0.0029613								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	333.717	9.328	333.717	7.813	333.717	2.015	333.717	2.016
1.03	273.061	9.359	273.061	8.203	273.061	2.063	273.061	2.109
1.05	225.096	9.266	225.096	8.016	225.096	1.969	225.096	2.000
1.10	143.112	9.265	143.112	7.890	143.112	2.047	143.112	2.109
1.30	33.1025	9.187	33.1025	7.890	33.1025	2.032	33.1025	2.093
1.50	11.5687	9.281	11.5687	7.859	11.5687	2.062	11.5687	2.156
2.00	2.64568	9.204	2.64568	7.797	2.64568	2.031	2.64568	2.094
3.00	1.228	9.343	1.228	8.032	1.228	2.047	1.228	2.109
λ = 0.2 , b =0.12792565								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	316.043	9.500	316.043	7.844	316.043	1.953	316.043	2.000
1.03	239.650	9.031	239.650	7.922	239.650	2.047	239.650	1.953
1.05	188.695	9.390	188.695	7.781	188.695	2.203	188.695	1.953
1.10	115.464	9.016	115.464	7.844	115.464	2.047	115.464	2.094
1.30	32.6243	8.890	32.6243	8.000	32.6243	2.047	32.6243	2.094
1.50	14.9878	9.328	14.9878	7.765	14.9878	2.172	14.9878	1.969
2.00	4.97403	8.703	4.97403	7.703	4.97403	2.125	4.97403	1.953
3.00	2.09301	8.875	2.09301	7.906	2.09301	2.000	2.09301	1.985

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

ตารางที่ 2: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(1) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi = -0.1, \beta_1 = 0.1, \beta_2 = 0.2$ และ $ARL_0 = 370$

$\lambda = 0.05$, b = 0.0000000692919								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	303.097	8.860	303.097	7.845	303.097	2.188	303.097	2.047
1.03	205.796	8.844	205.796	7.938	205.796	2.000	205.796	1.985
1.05	141.854	8.906	141.854	7.875	141.854	1.984	141.854	2.031
1.10	59.5589	8.812	59.5589	7.937	59.5589	2.016	59.5589	1.984
1.30	4.37928	9.188	4.37928	8.156	4.37928	1.984	4.37928	2.078
1.50	1.40874	8.781	1.40874	7.782	1.40874	1.984	1.40874	2.063
2.00	1.0125	8.938	1.0125	8.031	1.0125	2.171	1.0125	1.985
3.00	1.00034	8.812	1.00034	7.891	1.00034	1.968	1.00034	2.031
$\lambda = 0.1$, b = 0.0029613								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	334.415	9.547	334.415	7.937	334.415	2.046	334.415	2.000
1.03	274.745	8.781	274.745	7.844	274.745	2.016	274.745	2.016
1.05	227.367	9.453	227.367	8.141	227.367	2.094	227.367	1.969
1.10	145.867	8.938	145.867	7.750	145.867	2.094	145.867	2.031
1.30	34.6941	9.297	34.6941	7.907	34.6941	2.046	34.6941	2.016
1.50	12.3297	8.828	12.3297	7.859	12.3297	2.094	12.3297	2.031
2.00	2.82516	8.969	2.82516	7.812	2.82516	2.047	2.82516	2.000
3.00	1.26149	8.954	1.26149	7.813	1.26149	2.094	1.26149	2.047
$\lambda = 0.2$, b =0.12792565								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	320.516	9.047	320.516	7.828	320.516	1.984	320.516	2.000
1.03	248.205	9.063	248.205	8.156	248.205	2.031	248.205	2.156
1.05	198.404	8.921	198.404	8.172	198.404	2.015	198.404	2.078
1.10	124.407	9.141	124.407	7.937	124.407	1.985	124.407	1.985
1.30	36.5461	9.407	36.5461	7.969	36.5461	2.047	36.5461	2.156
1.50	17.0177	9.078	17.0177	7.984	17.0177	2.047	17.0177	1.969
2.00	5.66125	9.313	5.66125	8.047	5.66125	2.000	5.66125	2.140
3.00	2.30941	8.813	2.30941	7.922	2.30941	2.203	2.30941	2.141

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

ตารางที่ 3: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(2) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi_1 = 0.2, \phi_2 = 0.2, \beta_1 = 0.2, \beta_2 = 0.2$ และ $ARL_0 = 370$

$\lambda = 0.05$, b = 0.0000000692919								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	301.308	8.750	301.308	8.203	301.308	2.109	301.308	2.344
1.03	202.248	9.875	202.248	8.297	202.248	2.297	202.248	2.328
1.05	137.886	9.140	137.886	8.281	137.886	2.109	137.886	2.328
1.10	56.4503	9.016	56.4503	8.484	56.4503	2.297	56.4503	2.250
1.30	3.94233	8.766	3.94233	9.047	3.94233	2.094	3.94233	2.188
1.50	1.33465	9.781	1.33465	8.890	1.33465	2.094	1.33465	2.250
2.00	1.00926	9.828	1.00926	8.390	1.00926	2.235	1.00926	2.187
3.00	1.00023	9.391	1.00023	8.375	1.00023	2.375	1.00023	2.078
$\lambda = 0.1$, b = 0.0029613								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	332.325	9.390	332.325	8.500	332.325	2.156	332.325	2.235
1.03	269.735	9.313	269.735	8.140	269.735	2.172	269.735	2.188
1.05	220.641	9.406	220.641	8.438	220.641	2.094	220.641	2.093
1.10	137.783	9.391	137.783	8.297	137.783	2.047	137.783	2.079
1.30	30.1586	9.297	30.1586	8.235	30.1586	2.140	30.1586	2.156
1.50	10.2048	9.422	10.2048	8.297	10.2048	2.141	10.2048	2.218
2.00	2.33977	9.359	2.33977	8.094	2.33977	2.125	2.33977	2.235
3.00	1.17362	9.437	1.17362	8.297	1.17362	2.172	1.17362	2.204
$\lambda = 0.2$, b =0.12792565								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	307.936	8.859	307.936	8.219	307.936	2.234	307.936	2.109
1.03	224.906	9.360	224.906	9.172	224.906	2.109	224.906	2.141
1.05	172.515	9.047	172.515	8.578	172.515	2.141	172.515	2.172
1.10	101.269	8.984	101.269	8.203	101.269	2.125	101.269	2.125
1.30	26.7510	9.125	26.7510	8.266	26.7510	2.297	26.7510	2.344
1.50	11.9922	8.953	11.9922	8.937	11.9922	2.109	11.9922	2.172
2.00	3.97219	8.890	3.97219	8.641	3.97219	2.234	3.97219	2.156
3.00	1.78033	9.422	1.78033	8.609	1.78033	2.172	1.78033	2.265

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

ตารางที่ 4: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(2) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi_1 = -0.2, \phi_2 = -0.2, \beta_1 = 0.2, \beta_2 = 0.2$ และ $ARL_0 = 370$

$\lambda = 0.05$, b = 0.0000000692919								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	303.696	9.110	303.696	8.282	303.696	2.141	303.696	2.078
1.03	206.993	8.843	206.993	8.250	206.993	2.125	206.993	2.125
1.05	143.202	9.391	143.202	8.437	143.202	2.093	143.202	2.093
1.10	60.6333	9.859	60.6333	8.297	60.6333	2.172	60.6333	2.141
1.30	4.53891	9.641	4.53891	8.484	4.53891	2.219	4.53891	2.078
1.50	1.43692	8.937	1.43692	8.344	1.43692	2.094	1.43692	2.141
2.00	1.01381	9.829	1.01381	8.281	1.01381	2.079	1.01381	2.078
3.00	1.00039	9.078	1.00039	8.235	1.00039	2.109	1.00039	2.234
$\lambda = 0.1$, b = 0.0029613								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	335.119	9.125	335.119	8.563	335.119	2.078	335.119	2.187
1.03	276.447	8.891	276.447	8.297	276.447	2.172	276.447	2.375
1.05	229.670	9.172	229.670	8.407	229.670	2.203	229.670	2.219
1.10	148.689	9.250	148.689	8.157	148.689	2.234	148.689	2.078
1.30	36.3736	9.047	36.3736	8.453	36.3736	2.109	36.3736	2.344
1.50	13.1503	9.079	13.1503	8.532	13.1503	2.219	13.1503	2.140
2.00	3.02541	9.000	3.02541	8.437	3.02541	2.141	3.02541	2.109
3.00	1.30013	9.360	1.30013	8.563	1.30013	2.093	1.30013	2.218
$\lambda = 0.2$, b =0.12792565								
α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	325.467	9.000	325.467	8.141	325.467	2.094	325.467	2.047
1.03	258.042	9.156	258.042	8.406	258.042	2.063	258.042	2.172
1.05	209.864	9.375	209.864	8.375	209.864	2.078	209.864	2.062
1.10	135.381	9.282	135.381	9.579	135.381	2.078	135.381	2.078
1.30	41.573	9.437	41.573	8.344	41.573	2.094	41.573	2.079
1.50	19.6372	9.438	19.6372	8.359	19.6372	2.125	19.6372	2.078
2.00	6.54771	9.249	6.54771	8.312	6.54771	2.078	6.54771	2.093
3.00	2.5875	8.891	2.5875	8.422	2.5875	2.172	2.5875	2.110

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

ตารางที่ 5: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(3) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi_1 = 0.1, \phi_2 = 0.15, \phi_3 = 0.2, \beta_1 = 0.2, \beta_2 = 0.2$ และ $ARL_0 = 370$

α_1	วิธีกฎเกาส์		วิธีกฎซิมป์สัน		วิธีกฎสี่เหลี่ยมคางหมู		วิธีกฎค่ากลาง	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
$\lambda = 0.05$, b = 0.0000000692919								
1.01	301.159	9.142	301.159	9.187	301.159	2.344	301.159	2.281
1.03	201.955	9.375	201.955	8.625	201.955	2.297	201.955	2.391
1.05	137.561	9.515	137.561	8.594	137.561	2.437	137.561	2.562
1.10	56.1988	9.032	56.1988	8.704	56.1988	2.281	56.1988	2.266
1.30	3.90857	9.063	3.90857	9.781	3.90857	2.234	3.90857	2.329
1.50	1.32912	9.359	1.32912	8.609	1.32912	2.313	1.32912	2.422
2.00	1.00903	9.032	1.00903	9.000	1.00903	2.468	1.00903	2.375
3.00	1.00022	8.985	1.00022	8.985	1.00022	2.391	1.00022	2.281
$\lambda = 0.1$, b = 0.0029613								
1.01	332.153	9.406	332.153	8.500	332.153	2.109	332.153	2.250
1.03	269.324	9.375	269.324	8.547	269.324	2.141	269.324	2.219
1.05	220.092	9.438	220.092	8.484	220.092	2.219	220.092	2.266
1.10	137.133	9.438	137.133	8.985	137.133	2.266	137.133	2.265
1.30	29.8115	9.516	29.8115	8.734	29.8115	2.172	29.8115	2.235
1.50	10.0478	9.485	10.0478	8.953	10.0478	2.234	10.0478	2.391
2.00	2.30591	9.719	2.30591	8.812	2.30591	2.188	2.30591	2.312
3.00	1.16783	9.375	1.16783	8.828	1.16783	2.203	1.16783	2.328
$\lambda = 0.2$, b =0.12792565								
1.01	306.974	8.922	306.974	9.266	306.974	2.515	306.974	2.329
1.03	223.220	9.016	223.220	9.062	223.220	2.282	223.220	2.218
1.05	170.709	8.968	170.709	8.578	170.709	2.281	170.709	2.203
1.10	99.7387	8.891	99.7387	9.141	99.7387	2.265	99.7387	2.250
1.30	26.1453	9.250	26.1453	8.968	26.1453	2.375	26.1453	2.266
1.50	11.6876	9.171	11.6876	8.719	11.6876	2.235	11.6876	2.360
2.00	3.87183	9.156	3.87183	8.718	3.87183	2.500	3.87183	2.266
3.00	1.74942	9.547	1.74942	9.079	1.74942	2.328	1.74942	2.203

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

ตารางที่ 6: ค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม EWMA สำหรับตัวแบบ AR(3) ที่มีแนวโน้มกำลังสอง เมื่อกำหนด $\phi_1 = -0.1, \phi_2 = -0.15, \phi_3 = -0.2, \beta_1 = 0.2, \beta_2 = 0.2$ และ $ARL_0 = 370$

$\lambda = 0.05$, b = 0.0000000692919								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	303.846	9.015	303.846	8.719	303.846	2.172	303.846	2.250
1.03	207.293	8.938	207.293	8.688	207.293	2.281	207.293	2.375
1.05	143.541	8.984	143.541	8.531	143.541	2.312	143.541	2.250
1.10	60.9050	8.953	60.9050	8.734	60.9050	2.141	60.9050	2.187
1.30	4.57998	9.172	4.57998	8.610	4.57998	2.281	4.57998	2.297
1.50	1.44426	9.016	1.44426	8.735	1.44426	2.345	1.44426	2.281
2.00	1.01416	9.828	1.01416	9.000	1.01416	2.282	1.01416	2.360
3.00	1.0004	9.390	1.0004	8.375	1.0004	2.188	1.0004	2.484
$\lambda = 0.1$, b = 0.0029613								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	335.295	9.406	335.295	9.266	335.295	2.203	335.295	2.297
1.03	276.875	9.203	276.875	9.187	276.875	2.172	276.875	2.172
1.05	230.251	9.281	230.251	9.188	230.251	2.281	230.251	2.172
1.10	149.405	9.141	149.405	8.437	149.405	2.188	149.405	2.281
1.30	36.8079	9.391	36.8079	8.499	36.8079	2.234	36.8079	2.265
1.50	13.3654	9.109	13.3654	8.656	13.3654	2.297	13.3654	2.281
2.00	3.07903	9.390	3.07903	9.094	3.07903	2.156	3.07903	2.375
3.00	1.31069	9.312	1.31069	8.610	1.31069	2.156	1.31069	2.359
$\lambda = 0.2$, b =0.12792565								
α_1	**วิธีกฎเกาส์**		**วิธีกฎซิมป์สัน**		**วิธีกฎสี่เหลี่ยมคางหมู**		**วิธีกฎค่ากลาง**	
	ARL	CPU time	ARL	CPU time	ARL	CPU time	ARL	CPU time
1.01	326.81	9.204	326.81	9.484	326.81	2.140	326.81	2.141
1.03	260.777	9.172	260.777	8.625	260.777	2.375	260.777	2.359
1.05	213.108	8.984	213.108	8.5	213.108	2.312	213.108	2.313
1.10	138.571	9.203	138.571	8.625	138.571	2.312	138.571	2.265
1.30	43.0763	9.016	43.0763	8.734	43.0763	2.172	43.0763	2.281
1.50	20.4224	9.094	20.4224	8.609	20.4224	2.125	20.4224	2.391
2.00	6.81207	9.000	6.81207	8.594	6.81207	2.235	6.81207	2.250
3.00	2.66979	9.156	2.66979	8.531	2.66979	2.235	2.66979	2.375

หมายเหตุ: เวลาที่ใช้ในการประมวลผล (CPU Time) มีหน่วยเป็นวินาที

วิธีกฎสี่เหลี่ยมคางหมู ใช้เวลาในการประมวลผลน้อยที่สุด และเมื่อพิจารณาค่าพารามิเตอร์ปรับให้เรียบแบบเลขชี้กำลัง (λ) ที่มีค่าเท่ากับ 0.05, 0.1 และ 0.2 ตามลำดับ พบว่าแผนภูมิควบคุม EWMA เมื่อกำหนดให้ λ มีค่าเท่ากับ 0.05 มีความไวในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยได้เร็วกว่า λ ในระดับอื่นๆ

ตารางที่ 5 และตารางที่ 6 แสดงการเปรียบเทียบค่าความยาวรันเฉลี่ยภายใต้ตัวแบบ AR(3) with quadratic trend เมื่อกำหนดค่าพารามิเตอร์ $\beta_1 = 0.2$, $\beta_2 = 0.2$ ตารางที่ 5 กำหนดค่า $\phi_1 = 0.1$, $\phi_2 = 0.15$, $\phi_3 = 0.2$ และ ตารางที่ 6 กำหนดค่า $\phi_1 = -0.1$, $\phi_2 = -0.15$, $\phi_3 = -0.2$ พบว่า ค่า ARL ที่ได้จากทั้ง 4 วิธี ให้ผลลัพธ์ไม่แตกต่างกัน เมื่อเปรียบเทียบประสิทธิภาพพบว่าวิธีกฎค่ากลาง และวิธีกฎสี่เหลี่ยมคางหมู ใช้เวลาในการประมวลผลน้อยที่สุด และเมื่อพิจารณาค่าพารามิเตอร์ปรับให้เรียบแบบเลขชี้กำลัง (λ) ที่มีค่าเท่ากับ 0.05, 0.1 และ 0.2 ตามลำดับ พบว่าแผนภูมิควบคุม EWMA เมื่อกำหนดให้ λ มีค่าเท่ากับ 0.05 มีความไวในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยได้เร็วกว่า λ ในระดับอื่นๆ

4. สรุป

จากผลการวิจัยพบว่าค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) สำหรับตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) โดยวิธีสมการปริพันธ์เชิงตัวเลข ทั้ง 4 วิธี ได้แก่ วิธีกฎเกาส์ วิธีกฎค่ากลาง วิธีกฎสี่เหลี่ยมคางหมู และวิธีกฎของซิมป์สัน ไม่แตกต่างกันในแต่ละระดับการเปลี่ยนแปลงค่าพารามิเตอร์ และระยะเวลาในการประมวลผลของวิธีกฎค่ากลาง และวิธีกฎสี่เหลี่ยมคางหมูมีค่าน้อยที่สุด และจากการศึกษาค่าพารามิเตอร์ปรับให้เรียบแบบเลขชี้กำลัง (λ) ที่มีค่าเท่ากับ 0.05, 0.1 และ 0.2 ของแผนภูมิควบคุม EWMA พบว่า ค่าพารามิเตอร์ เท่ากับ 0.05 เป็นค่าพารามิเตอร์ที่เหมาะสม ที่มีความไวในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการได้ดีที่สุด

งานวิจัยนี้ได้ศึกษาตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสอง (AR(p) with quadratic trend model) สำหรับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) และสามารถนำตัวแบบการถดถอยในตัวลำดับที่ p ที่มีแนวโน้มกำลังสองไปประยุกต์ใช้กับแผนภูมิควบคุมชนิดอื่นได้

5. เอกสารอ้างอิง

[1] Shewhart, W.A. “Economic Control of Quality of Manufactured Product.” D.Van Nostrand. New York. 1931.

[2] Page, E.S. “Continuous inspection schemes.” Journal Article. Vol.41 No.1/2 (June 1954) : 100-115.

[3] Roberts, S.W. “Control Chart Test Based on Geometric Moving Averages.” Technometrics.Vol.1 No.3 (1959) : 239-250.

[4] Sukparungsee, S. and Areepong, Y. “An Explicit Analytical Solution of the Average Run Length of an Exponentially Weighted Moving Average Control Chart using an Autoregressive Model.” Chiang Mai Journal of Science. Vol.44 No.3 (2017) : 1172-1179.

[5] Phanyaem, S. “The Integral Equation Approach for Solving the Average Run Length of EWMA Procedure for Autocorrelated Process.” Thailand Statistician. Vol.19 No.3 (July 2021) : 627 641.

[6] Phanyaem, S. “Development of Average Run Length Formulas for EWMA Control Chart under the AR(1) with quadratic trend model for detecting and monitoring process variability” Journal of Applied Science and Emerging Technology (JASET). Vol.23 No.2 (2024) : e257034

การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DHWMA แบบขยาย สำหรับการตรวจจับการเปลี่ยนแปลงของกระบวนการ

Comparing the Effectiveness of Extended DHWMA Control Chart for Monitoring Process Shift

วันไชย เลิศเมธาวี* ภควดี ขัดเครือ ธนพงษ์ จิตติถาวร ยุพาภรณ์ อารีพงษ์

ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(*s6404052610224@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้เป็นการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม 3 ชนิด คือ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์ (Homogeneously Weighted Moving Average control chart: HWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์สองครั้ง (Double Homogeneously Weighted Moving Average control chart: DHWMA) และ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์แบบขยาย (Extended Double Homogeneously Weighted Moving Average control chart: Extended DHWMA) ในการตรวจจับการเปลี่ยนแปลงของกระบวนการ เมื่อข้อมูลมีการแจกแจงโลจิสติก (Logistic distribution) และการแจกแจงลาปลาซ (Laplace distribution) โดยเกณฑ์ที่ใช้วัดประสิทธิภาพ คือ ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) ผลการวิจัยพบว่า แผนภูมิควบคุม DHWMA แบบขยาย มีประสิทธิภาพดีกว่า แผนภูมิควบคุม HWMA แผนภูมิควบคุม DHWMA ภายใต้การแจกแจงโลจิสติกและการแจกแจงลาปลาซ ที่ระดับการเปลี่ยนแปลงขนาดเล็กถึงกลาง

Abstract

This research aims to compare the effectiveness of three types of control charts: the Homogeneously Weighted Moving Average (HWMA) control chart, the Double Homogeneously Weighted Moving Average (DHWMA) control chart, and the Extended Double Homogeneously Weighted Moving Average (Extended DHWMA) control chart, in detecting changes in a process when the data follows Logistic and Laplace distributions. The performance of each chart was evaluated using the Average Run Length (ARL) as the criterion. The results of the study show that the Extended DHWMA control chart outperforms the HWMA control chart. Furthermore, the DHWMA control chart proves to be more effective than the HWMA chart when applied to both Logistic and Laplace distributions, especially in cases of small to medium shift changes in the process. This demonstrates the superior sensitivity, efficiency, and adaptability of the DHWMA-based charts in detecting shifts in the process, making them a more reliable tool for process monitoring and improvement.

1. บทนำ

แผนภูมิควบคุม (Control charts) เป็นเครื่องมือสำคัญในกระบวนการควบคุมคุณภาพทางสถิติ (Statistical Process Control: SPC) ซึ่งถูกใช้ในการติดตามและควบคุมกระบวนการผลิตในอุตสาหกรรมเพื่อปรับปรุงคุณภาพของผลิตภัณฑ์ แผนภูมิควบคุมช่วยให้เราสามารถระบุและแยกแยะระหว่างความแปรปรวนที่เกิดจากสาเหตุทั่วไป (Common causes) ซึ่งสามารถคาดการณ์ได้ และความแปรปรวนที่เกิดจากสาเหตุพิเศษ (Special causes) ที่สามารถระบุและแก้ไขได้ โดยกระบวนการจะอยู่ในสภาวะควบคุม (In-Control: IC) เมื่อมีแค่ความแปรปรวนจากสาเหตุทั่วไป และจะอยู่นอกสภาวะควบคุม (Out-of-Control: OOC) เมื่อเกิดการแปรปรวนจากสาเหตุพิเศษ แผนภูมิควบคุมที่สำคัญที่สุดคือแผนภูมิควบคุม Shewhart ที่พัฒนาโดย Walter Shewhart (1925) ซึ่งมีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงขนาดใหญ่ แต่ไม่เหมาะสมกับการตรวจจับการเปลี่ยนแปลงขนาดเล็กถึงปานกลาง จึงมีการพัฒนาแผนภูมิควบคุมประเภทอื่นๆ เช่น CUSUM และ EWMA โดย Page (1954) และ Roberts (1959) ซึ่งมีความไวสูงต่อการเปลี่ยนแปลงขนาดเล็กถึงปานกลางและสามารถใช้ข้อมูลทั้งในปัจจุบันและอดีตเพื่อ

เพิ่มประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง การพัฒนาแผนภูมิควบคุม CUSUM และ EWMA ต่อเนื่องมาโดยการปรับปรุงเพื่อเพิ่มประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง เช่น แผนภูมิควบคุม Shewhart-CUSUM ที่พัฒนาโดย Lucas หรือแผนภูมิควบคุม DEWMA ที่นำเสนอโดย Shamma และ Shamma (1992) ซึ่งใช้ขีดจำกัดแบบ Asymptotic เพื่อเพิ่มความสามารถในการตรวจจับการเปลี่ยนแปลงขนาดเล็ก นอกจากนี้ยังมีการพัฒนาแผนภูมิควบคุมใหม่ๆ เช่น แผนภูมิควบคุม HWMA โดย Abbas และคณะ (2011) ซึ่งมีประสิทธิภาพสูงในการตรวจจับการเปลี่ยนแปลงขนาดเล็ก และแผนภูมิควบคุม DHWMA โดย Abid และคณะ (2011) ซึ่งพัฒนามาจาก HWMA โดยปรับแต่งพารามิเตอร์ต่างๆ เพื่อลดข้อจำกัดในการใช้งาน

โดยทั่วไป ในการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม จะนิยมใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยค่าความยาวรันเฉลี่ยจะมี 2 ประเภท คือ ค่าความยาวรันเฉลี่ยเมื่ออยู่ภายใต้การควบคุม (ARL_0) หมายถึงจำนวนครั้งเฉลี่ยของตัวอย่างที่ตกอยู่ในขอบเขตควบคุมก่อนที่จะตกออกนอกขอบเขตควบคุม และค่าความยาวรันเฉลี่ยเมื่อไม่อยู่ภายใต้การควบคุม (ARL_1) หมายถึงจำนวนครั้งเฉลี่ยของตัวอย่างที่ตกนอกขอบเขตควบคุม

จากที่กล่าวมาข้างต้นผู้วิจัยสนใจที่จะศึกษาค่าความยาวรันเฉลี่ยของแผนภูมิควบคุม DHWMA เมื่อข้อมูลมีการแจกแจงในรูปแบบของ การแจกแจงโลจิสติก (Logistic distribution) และการแจกแจงลาปลาซ (Laplace distribution) โดยจะเปรียบเทียบประสิทธิภาพกับแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์ (Homogeneously Weighted Moving Average control chart: HWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์สองครั้ง (Double Homogeneously Weighted Moving Average control chart: DHWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอย่างเอกพันธ์แบบขยาย (Extended Double Homogeneously Weighted Moving Average control chart: Extended DHWMA) ในการตรวจจับการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการ ซึ่งการศึกษาครั้งนี้จะใช้โปรแกรม R Studio ในการจำลองข้อมูลและประเมินผลการทำงานของแผนภูมิควบคุมเหล่านี้

2. วิธีการวิจัย

2.1 แผนภูมิควบคุมที่ใช้ในการศึกษา

2.1.1 แผนภูมิควบคุม HWMA (Homogeneously Weighted Moving Average control chart)

ให้ X_{ij} เป็นการสังเกตที่ $j = 1,2,\dots,n$ ในตัวอย่างที่ $i = 1,2,\dots,m$ โดยสมมติว่า $X_{ij} \overset{iid}{\sim} N(\mu,\sigma^2)$ กระบวนการอยู่ในสภาวะควบคุม (IC) เมื่อ $\mu = \mu_0$ และ $\sigma = \sigma_0$ หาก $\mu = \mu_1 \neq \mu_0$ และ/หรือ $\sigma = \sigma_1 \neq \sigma_0$ กระบวนการจะอยู่นอกสภาวะควบคุม (OOC) ค่าเฉลี่ยตัวอย่าง $\bar{X}_i = \frac{X_{i1}+X_{i2}+\cdots+X_{in}}{n}$, $i = 1,2,\dots,m$ มีการแจกแจงแบบปกติด้วยค่าเฉลี่ย μ และความแปรปรวน $\frac{\sigma^2}{n}$

ตัวสถิติของแผนภูมิควบคุม HWMA แสดงดังนี้

$$H_i = \lambda\overline{X_i} + (1-\lambda)\overline{\overline{X}}_{i-1} \quad (2.1)$$

โดยที่ H_i แทน ค่าสถิติ HWMA ณ คาบเวลาที่ t ใดๆ

λ แทน ค่าพารามิเตอร์ของแผนภูมิควบคุม HWMA โดยที่ λ = 0.1, 0.5 และ 0.7

X_i และ X_{i-1} แทน ค่าในสมการด้วย

$$\overline{\overline{X}}_{i-1} = \frac{\sum_{k=1}^{t-1}\bar{X}_k}{\mathrm{i}-1} \quad (2.2)$$

ค่าที่เริ่มต้น $\overline{\overline{X}}_0$ ถูกตั้งค่าให้เท่ากับ μ_0 นอกจากนี้ยังแสดงให้เห็นว่าค่าเฉลี่ยของสถิติ H_i เท่ากับ μ_0

ขีดจำกัดการควบคุมของแผนภูมิ DHWMA คือ

$$LCL_i = \begin{cases} \mu_0 - L\dfrac{\lambda\sigma_0}{\sqrt{n}} & for\ i = 1 \\ \mu_0 - L\dfrac{\sigma_0}{\sqrt{n}}\sqrt{\lambda^2 + \dfrac{(1-\lambda)^2}{i-1}} & for\ i > 1 \end{cases}$$

$$UCL_i = \begin{cases} \mu_0 + L\dfrac{\lambda\sigma_0}{\sqrt{n}} & for\ i = 1 \\ \mu_0 + L\dfrac{\sigma_0}{\sqrt{n}}\sqrt{\lambda^2 + \dfrac{(1-\lambda)^2}{i-1}} & for\ i > 1 \end{cases}$$

โดยที่ L เป็นค่าสัมประสิทธิ์ของขีดจำกัดควบคุม โดย $L > 0$ และ $CL = \mu_0$

2.1.2 แผนภูมิควบคุม DHWMA (Double Homogeneously Weighted Moving Average control chart)

แผนภูมิควบคุม DHWMA เป็นแผนภูมิที่เสนอโดย Abid และคณะ โดยตัวสถิติ DH_i ดังนี้

$$\begin{cases} H_i = \lambda\overline{X_i} + (1-\lambda)\overline{\overline{X}}_{i-1} \\ DH_i = \lambda H_i + (1-\lambda)\overline{\overline{X}}_{i-1} \end{cases} \quad (2.3)$$

จากการรวมสถิติทั้งสองข้างต้นสถิติ DH_i ยังสามารถเขียนได้ว่า:

$$DH_i = \lambda^2\overline{X_i} + (1-\lambda^2)\overline{\overline{X}}_{i-1} \quad (2.4)$$

พารามิเตอร์การถ่วงน้ำหนักมีค่าเท่ากับ λ^2 แทนที่จะเป็น λ

ขีดจำกัดการควบคุมของแผนภูมิ DHWMA คือ

$$LCL_i = \begin{cases} \mu_0 - L\dfrac{\lambda^2\sigma_0}{\sqrt{n}} & for\ i = 1 \\ \mu_0 - L\dfrac{\sigma_0}{\sqrt{n}}\sqrt{\lambda^4 + \dfrac{(1-\lambda^2)^2}{i-1}} & for\ i > 1 \end{cases}$$

$$UCL_i = \begin{cases} \mu_0 + L\dfrac{\lambda^2\sigma_0}{\sqrt{n}} & for\ i = 1 \\ \mu_0 + L\dfrac{\sigma_0}{\sqrt{n}}\sqrt{\lambda^4 + \dfrac{(1-\lambda^2)^2}{i-1}} & for\ i > 1 \end{cases}$$

โดยที่ L เป็นค่าสัมประสิทธิ์ของขีดจำกัดควบคุม โดย $L > 0$ และ $CL = \mu_0$

2.1.3 แผนภูมิควบคุม DHWMA แบบขยาย (Extended Double Homogeneously Weighted Moving Average control chart)

แผนภูมิควบคุมชนิดนี้เกิดจากการผสมผสานระหว่างแผนภูมิควบคุม Hybrid Homogeneously weight moving average control chart (HHWMA) ของ Adeoti และ Koleoso กับแผนภูมิควบคุม DHWMA ของ Abid และคณะ ซึ่งแม้จะไม่ได้เลียนแบบเทคนิคแผนภูมิควบคุม DEWMA ของ Shamma และ Shamma ทั้งหมด แต่แผนภูมิควบคุม DHWMA นั้น มีโครงสร้างคล้ายคลึงกับ HWMA โดยพารามิเตอร์การปรับจะถูกแทนที่ด้วยค่ากำลังสอง ดังนี้

โดยจากแผนภูมิควบคุม HHWMA มีตัวสถิติคือ HH_i แสดงดังนี้

$$\begin{cases} H_i = \lambda_2\overline{X_i} + (1-\lambda_2)\bar{\bar{X}}_{i-1} \\ HH_i = \lambda_1 H_i + (1-\lambda_1)\overline{H}_{i-1} \end{cases} \quad (2.5)$$

โดยที่ $\lambda_1, \lambda_2 \in_{0,1]}$ เป็นพารามิเตอร์การถ่วงน้ำหนัก $\bar{\bar{X}}_0 = \overline{H}_0 = \mu_0$ และ $\overline{H}_{i-1}$ ถูกกำหนดว่า

$$\overline{H}_{i-1} = \frac{\sum_{k=1}^{i-1} H_k}{i-1} \quad (2.6)$$

และจากแผนภูมิควบคุม DHWMA แบบขยาย ซึ่งอิงตามแผนภูมิควบคุม DHWMA ในข้อ *2.1.2* จะได้ตัวสถิติดังนี้

$$\begin{cases} H_i = \lambda\overline{X_i} + (1-\lambda)\bar{\bar{X}}_{i-1} \\ DH_i = \lambda H_i + (1-\lambda)\overline{H}_{i-1} \end{cases} \quad (2.7)$$

โดยที่ λ คือพารามิเตอร์การถ่วงน้ำหนัก $\bar{\bar{X}}_0 = \overline{H}_0 = \mu_0$ และ $\overline{H}_{i-1}$ ถูกกำหนดโดยสมการ (2.6)

ขีดจำกัดการควบคุมของแผนภูมิ DHWMA แบบขยาย คือ

$$LCL_i = \mu_0 - L\sqrt{Var(DH_i)}$$

$$UCL_i = \mu_0 + L\sqrt{Var(DH_i)}$$

โดยที่ L เป็นค่าสัมประสิทธิ์ของขีดจำกัดควบคุม โดย $L > 0$ และ $CL = \mu_0$

2.2 การแจกแจงที่ใช้ในการศึกษา

2.2.1 การแจกแจงโลจิสติก (Logistic distribution)

เป็นการแจกแจงแบบต่อเนื่องที่มีลักษณะคล้ายกับการแจกแจงแบบปกติ การแจกแจงโลจิสติกมักใช้ในกรณีที่ข้อมูลมีการกระจายตัวแบบสมมาตรและมีความเบี่ยงเบนสูง ซึ่งกำหนดให้ X เป็นตัวแปรสุ่มแบบต่อเนื่องที่มีการแจกแจงแบบโลจิสติก ที่มี μ และ s เป็นพารามิเตอร์ ซึ่งจะเขียนแทนด้วย $X \sim Logistic(\mu, s)$ ฟังก์ชันความหนาแน่นความน่าจะเป็นของการแจกแจงแบบโลจีสติก เขียนได้ดังนี้

$$f(x) = \frac{e^{-\frac{x-\mu}{s}}}{s\left(1+e^{-\frac{x-\mu}{s}}\right)^2} \quad \text{โดยที่ } s > 0 \quad (2.8)$$

โดยที่ s คือ พารามิเตอร์การกระจาย (scale parameter)
μ คือ ค่าเฉลี่ย (Mean) ของการแจกแจง
ค่าคาดหวัง (Expected value) คือ $E(X) = \mu$
ความแปรปรวน (Variance) คือ $V(X) = \frac{\pi^2}{3} \cdot s^2$

2.2.2 การแจกแจงแบบลาปลาซ (Laplace Distribution)

เป็นการแจกแจงความน่าจะเป็นที่มีลักษณะคล้ายกับการแจกแจงปกติ (Normal Distribution) แต่มีจุดเด่นที่ "ขา" หรือการกระจายตัวที่ยาวกว่าการแจกแจงปกติ ทำให้ค่าที่ห่างไกลจากค่ากลางมีความน่าจะเป็นที่สูงกว่า ซึ่งกำหนดให้ X เป็นตัวแปรสุ่มแบบต่อเนื่องที่มีการแจกแจงแบบลาปลาซ ที่มี μ และ b เป็นพารามิเตอร์ ซึ่งจะเขียนแทนด้วย $X \sim Laplace(\mu, b)$ ฟังก์ชันความหนาแน่นความน่าจะเป็นของการแจกแจงแบบโลจีสติก เขียนได้ดังนี้

$$f(x) = \frac{1}{2b}\exp\left(-\frac{|x-\mu|}{b}\right) \quad (2.9)$$

โดยที่ b คือ พารามิเตอร์การกระจาย (scale parameter)
μ คือ ค่าเฉลี่ย (Mean) ของการแจกแจง
ค่าคาดหวัง (Expected value) คือ $E(X) = \mu$
ความแปรปรวน (Variance) คือ $V(X) = 2b^2$

2.3 การกำหนดเกณฑ์ที่ใช้ในการตัดสินใจ

2.3.1 ค่าความยาวรันเฉลี่ยเมื่อไม่อยู่ภายใต้การควบคุม (ARL_1)

โดยค่า ARL_1 *ที่มีค่าน้อยที่สุด* สามารถอธิบายได้ว่า แผนภูมิควบคุมใดที่ให้ค่า ARL_1 น้อยที่สุด จะเป็นแผนภูมิควบคุมที่มีประสิทธิภาพในการตรวจจับดีที่สุด

2.3.2 ค่า Average Extra Quadratic Loss (AEQL)

เกณฑ์ AEQL เป็นการประเมินประสิทธิภาพโดยรวมของแผนภูมิควบคุม ซึ่งคำนวณจาก ARL ตลอดช่วงการเปลี่ยนแปลงของกระบวนการ ซึ่งแสดงได้ดังนี้

$$AEQL = \frac{1}{\Delta}\sum_{\delta=\delta_{min}}^{\delta max} \delta^2 \times ARL(\delta) \quad (2.10)$$

ค่า AEQL ที่มีค่าน้อยที่สุด สามารถอธิบายได้ว่าแผนภูมิควบคุมนั้นมีประสิทธิภาพในการตรวจจับดีที่สุด

2.4 ขอบเขตของงานวิจัย

ในงานวิจัยนี้มีขอบเขตการวิจัยดังต่อไปนี้

- จำลองการสุ่มตัวอย่างจากกระบวนการด้วยการแจกแจงโลจิสติก และการแจกแจงลาปลาซ โดยพารามิเตอร์ของการแจกแจงโลจิสติก คือ $\mu = 0$ และ $s = 1$ และ 5 พารามิเตอร์ของการแจกแจงลาปลาซ คือ $\mu = 0$ และ $b = 1$ และ 5
- กำหนดระดับการเปลี่ยนแปลงของกระบวนการ (δ) เท่ากับ 0.2, 0.25, 0.5, 0.75, 1, 1.25, 1.5, 2 และ 3 ในการคำนวนหาค่า ARL_1

- กำหนดให้พารามิเตอร์ถ่วงน้ำหนัก (λ) ของแผนภูมิควบคุม HWMA, DHWMA และ DHWMA แบบขยาย มีค่าเท่ากับ 0.1, 0.5 และ 0.7
- กำหนดค่า $ARL_0 = 370$
- ทำการจำลองข้อมูลด้วยโปรแกรม R Studio โดยทำการทดลองซ้ำ (m) จำนวน 10,000 รอบ จำนวนหน่วยตัวอย่างที่ใช้ในจำลอง (n) เท่ากับ 10

2.5 การดำเนินการทดลอง

งานวิจัยนี้เป็นการศึกษาเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม 3 ชนิด คือ แผนภูมิควบคุม HWMA (Homogeneously Weighted Moving Average control chart), DHWMA (Double Homogeneously Weighted Moving Average control chart) และ DHWMA แบบขยาย (Extended Double Homogeneously Weighted Moving Average control chart) โดยการประเมินประสิทธิภาพนั้นจะใช้ค่า ARL_1 และค่า AEQL โดยมีขั้นตอนดังนี้

2.5.1 กำหนดให้กระบวนการอยู่ภายใต้การควบคุม โดยใช้โปรแกรม R Studio จำลองข้อมูลจากกระบวนการที่มีการแจกแจงโลจิสติกและการแจกแจงลาปลาซที่มีพารามิเตอร์ตามที่กล่าวไปใน **2.4**

2.5.2 กำหนดค่า $ARL_0 = 370$ เพื่อคำนวณหาค่าสัมประสิทธิ์ขีดจำกัดควบคุม(L) ของแผนภูมิควบคุมทั้ง 3 ชนิด

2.5.3 คำนวณหาค่า ARL_1 ในแต่ละระดับการเปลี่ยนแปลงของแผนภูมิควบคุมทั้ง 3 ชนิด

2.5.4 เปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม โดยพิจารณาจากค่า ARL_1 และค่า $AEQL$ ที่ต่ำที่สุด

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการศึกษาประสิทธิภาพของแผนภูมิควบคุมกรณีที่ $ARL_0 = 370$ ในรูปแบบตาราง

ผลการศึกษาประสิทธิภาพของแผนภูมิควบคุม HWMA, DHWMA และ DHWMA แบบขยาย เมื่อกระบวนการมีการเปลี่ยนแปลงในแต่ละระดับ δ และในแต่ละระดับพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม λ

3.1.1 ผลการศึกษาประสิทธิภาพของแผนภูมิควบคุมกรณีที่ $ARL_0 = 370$ *ในรูปแบบตาราง สำหรับการแจกแจงโลจิสติก*

ตารางที่ 1 : ค่า ARL ของแผนภูมิควบคุม HWMA DHWMA และ DHWMA แบบขยาย สำหรับการแจกแจงโลจิสติกที่มีค่าพารามิเตอร์ (s) เท่ากับ 1 และ 5 เมื่อกำหนดให้ $ARL_0 = 370$

λ	Parameter	control chart	L	ระดับการเปลี่ยนแปลง(δ)										AEQL
				0	0.2	0.25	0.5	0.75	1	1.25	1.5	2	3	
0.1	1	HWMA	11.80	372.82	196.35	163.39	68.10	29.63	13.00	5.90	2.85	1.16	1.00	16.64
		DHWMA	5.66	369.89	145.64	115.55	47.95	29.97	23.18	19.58	17.27	14.24	8.16	142.28
		DHWMA แบบขยาย	4.45	371.84	153.16	111.32	29.77	29.04	22.35	18.82	16.57	13.75	10.83	23.10
0.5	1	HWMA	6.77	370.34	172.22	132.84	47.30	23.20	13.67	8.83	5.99	2.81	1.07	102.65
		DHWMA	4.83	371.65	129.93	96.37	31.22	15.20	9.35	6.67	5.27	3.79	1.70	22.58
		DHWMA แบบขยาย	4.82	371.08	129.22	96.40	31.43	15.14	9.17	6.45	5.01	3.66	3.00	108.24
0.7	1	HWMA	4.57	371.63	195.64	150.18	44.64	17.53	8.74	5.16	3.37	1.72	1.02	15.12
		DHWMA	3.61	371.64	152.32	112.46	29.38	11.91	6.55	4.23	3.09	1.86	1.05	121.48
		DHWMA แบบขยาย	3.61	371.63	151.28	112.34	29.18	11.90	6.47	4.37	3.41	2.58	2.01	11.54
0.1	5	HWMA	11.80	372.40	351.58	340.76	286.41	234.77	194.72	161.77	137.58	96.51	50.55	94.50
		DHWMA	5.64	369.22	338.38	325.21	247.66	187.82	145.29	115.24	93.29	64.45	18.23	11.81
		DHWMA แบบขยาย	4.44	371.06	343.17	326.82	247.59	188.36	145.72	115.05	92.67	63.47	37.16	93.98
0.5	5	HWMA	6.78	370.42	359.40	350.36	287.27	228.96	172.68	135.22	105.16	68.29	34.65	13.89
		DHWMA	4.84	371.40	343.98	332.89	252.65	184.07	133.42	98.04	73.97	46.49	22.89	128.02
		DHWMA แบบขยาย	4.82	370.73	344.29	328.07	252.01	182.93	132.52	97.67	73.64	46.22	22.73	10.55
0.7	5	HWMA	4.57	371.26	365.73	356.54	307.54	243.61	192.51	150.87	114.32	70.69	29.17	102.70
		DHWMA	3.61	370.05	352.30	347.28	278.13	208.13	153.50	114.70	82.14	48.12	19.42	11.01
		DHWMA แบบขยาย	3.61	371.73	356.35	341.57	277.21	206.01	150.90	112.59	81.30	47.18	19.35	101.58

จากตารางที่ 1 แสดงค่า ARL ของแผนภูมิควบคุม HWMA, DHWMA และ DHWMA แบบขยาย โดยใช้การแจกแจงโลจิสติก (Logistic distribution) เมื่อค่า $ARL_0 = 370$ และ $\lambda = 0.1$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดเล็ก($0.2 \leq \delta \leq 0.5$) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.2$ ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ต่อมาในการระดับการเปลี่ยนแปลงขนาดกลาง($0.75 \leq \delta \leq 1.5$)และขนาดใหญ่($\delta \geq 2$) ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.75$ ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แต่เมื่อ $\lambda = 0.1$ ที่พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ในทุกระดับการเปลี่ยนแปลง(δ) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.5, 1.25, 1.5$และ 2 ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ต่อมาที่ค่า $\lambda = 0.5$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดกลาง($0.75 \leq \delta \leq 1.5$) แต่ที่การเปลี่ยนแปลงขนาดเล็ก($\delta \leq 0.5$) ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.2$ ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA และที่ระดับการเปลี่ยนแปลงขนาดใหญ่($\delta \geq 2$) ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ต่อมาที่ค่า $\lambda = 0.5$ ที่พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMAแบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในทุกระดับการเปลี่ยนแปลง(δ) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.2$ ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ต่อมาที่ค่า $\lambda = 0.7$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดเล็ก($\delta \leq 0.5$) ถึงขนาดกลาง($0.75 \leq \delta \leq 1.5$) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 1.25, 1.5$ และ 2 ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย และระดับการเปลี่ยนแปลงที่ $\delta = 3$ ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ต่อมาที่ $\lambda = 0.7$ พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในทุกระดับการเปลี่ยนแปลง(δ) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.2$ ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย และหากพิจารณาถึงภาพรวมในทุกระดับการเปลี่ยนแปลง จะพิจารณาจากค่า AEQL ที่ต่ำที่สุด เช่น ที่ $\lambda = 0.7$ พารามิเตอร์เท่ากับ 1 ของแผนภูมิควบคุม DHWMA แบบขยาย มีประสิทธิภาพดีที่สุด เนื่องจากค่า AEQL ต่ำสุด คือมีค่าเท่ากับ 11.54

ตารางที่ 2 : ค่า ARL ของแผนภูมิควบคุม HWMA DHWMA และ DHWMA แบบขยาย สำหรับการแจกแจงลาปลาซที่มีค่าพารามิเตอร์ (b) เท่ากับ 1 และ 5 เมื่อกำหนดให้ $ARL_0 = 370$

λ	Parameter	control chart	L	ระดับการเปลี่ยนแปลง(δ)										AEQL
				0	0.2	0.25	0.5	0.75	1	1.25	1.5	2	3	
0.1	1	HWMA	11.78	371.03	158.98	126.29	42.96	14.40	5.37	2.11	1.31	1.00	1.00	11.06
		DHWMA	5.63	370.69	111.11	85.62	35.14	23.75	19.11	16.45	14.53	11.08	2.22	111.35
		DHWMA แบบขยาย	4.45	371.89	112.06	85.35	34.57	23.12	18.50	15.85	14.09	11.85	9.38	16.93
0.5	1	HWMA	6.92	371.95	140.29	102.62	32.91	15.71	8.92	5.46	3.34	1.41	1.00	86.30
		DHWMA	4.88	371.38	96.76	68.53	20.86	10.15	6.52	4.92	4.02	2.55	1.06	18.97
		DHWMA แบบขยาย	4.87	371.23	96.21	68.23	20.78	9.97	6.25	4.65	3.84	3.07	3.00	85.80
0.7	1	HWMA	4.71	370.38	159.02	114.27	39.86	10.83	5.42	3.14	2.00	1.15	1.00	10.85
		DHWMA	3.69	371.09	116.82	80.62	18.70	7.50	4.24	2.88	2.08	1.25	1.00	98.28
		DHWMA แบบขยาย	3.68	369.13	114.55	79.95	18.16	7.34	4.32	3.25	2.72	2.12	2.00	8.15
0.1	5	HWMA	11.78	370.10	343.15	328.78	255.09	201.64	158.31	126.16	101.18	65.59	28.30	72.76
		DHWMA	5.67	371.59	323.23	305.92	212.72	151.98	112.69	85.79	67.66	46.28	29.18	8.71
		DHWMA แบบขยาย	4.45	370.15	326.47	305.76	212.42	151.92	112.52	85.40	67.38	45.44	28.31	72.40

λ	Parameter	control chart	L	ระดับการเปลี่ยนแปลง(δ)										AEQL
				0	0.2	0.25	0.5	0.75	1	1.25	1.5	2	3	
0.5	5	HWMA	6.93	371.91	348.64	333.82	262.94	190.20	141.21	102.73	77.51	49.00	23.86	10.61
		DHWMA	4.88	370.20	329.97	315.35	216.36	142.23	96.29	68.82	51.05	31.98	15.02	105.23
		DHWMA แบบขยาย	4.86	370.02	329.91	312.42	215.41	141.67	96.22	68.79	51.04	31.22	14.91	7.50
0.7	5	HWMA	4.71	370.24	352.52	346.71	281.19	216.11	159.85	117.02	86.90	49.26	19.15	80.50
		DHWMA	3.69	371.70	343.95	329.10	249.72	173.03	116.51	80.19	56.46	30.60	12.21	8.02
		DHWMA แบบขยาย	3.69	370.53	343.18	332.33	244.41	169.45	115.62	79.77	56.08	30.43	12.09	79.76

จากตารางที่ 2 แสดงค่า ARL ของแผนภูมิควบคุม HWMA, DHWMA และ DHWMA แบบขยาย โดยใช้การแจกแจงลาปลาซ (Laplace distribution) เมื่อค่า $ARL_0 = 370$ และ $\lambda = 0.1$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดเล็ก($\delta \leq 0.5$) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.2$ ให้ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ซึ่งในการเปลี่ยนแปลงขนาดกลาง($0.75 \leq \delta \leq 1.5$) ถึงขนาดใหญ่ ($\delta \geq 2$) ให้ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ต่อมาเมื่อ $\lambda = 0.1$ พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในเกือบทุกระดับการเปลี่ยนแปลง(δ) ยกเว้นที่ระดับการเปลี่ยนแปลง $\delta = 0.2$ ให้ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย และที่ระดับการเปลี่ยนแปลง $\delta = 3$ ให้ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ต่อมาที่ค่า $\lambda = 0.5$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดเล็ก($\delta \leq 0.5$) ถึงขนาดกลาง($0.75 \leq \delta \leq 1.5$) ยกเว้นที่ระดับการเปลี่ยนแปลง $\delta = 1.5$ ให้ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย และที่ระดับการเปลี่ยนแปลงขนาดใหญ่($\delta \geq 2$) ให้ค่า ARL ของแผนภูมิควบคุม HWMA ดีกว่าแผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย ต่อมาที่ $\lambda = 0.5$ พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในทุกระดับการเปลี่ยนแปลง(δ) ต่อมาเมื่อค่า $\lambda = 0.7$ พบว่าที่พารามิเตอร์ของการแจกแจงเท่ากับ 1 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในระดับการเปลี่ยนแปลงขนาดเล็ก ($\delta \leq 0.5$) แต่ในการเปลี่ยนแปลงขนาดกลาง($0.75 \leq \delta \leq 1.5$) แผนภูมิ DHWMA มีประสิทธิภาพดีกว่า แผนภูมิควบคุม HWMA และ DHWMA แบบขยาย ยกเว้นที่ระดับการเปลี่ยนแปลง $\delta = 0.75$ ให้ค่าARLของแผนภูมิควบคุม DHWMA แบบขยายมีประสิทธิภาพดีกว่าแผนภูมิควบคุม HWMA และ DHWMA และที่ระดับการเปลี่ยนแปลง $\delta = 1.5$ ให้ค่า ARL ของแผนภูมิควบคุม HWMA มีประสิทธิภาพดีกว่า แผนภูมิควบคุม DHWMA และ DHWMA แบบขยาย เมื่อเป็นระดับการเปลี่ยนแปลงขนาดใหญ่($\delta \geq 2$) จะให้ค่า ARL ของแผนภูมิควบคุม HWMA มีประสิทธิภาพดีกว่าแผนภูมิ DHWMA และ DHWMA แบบขยาย ต่อมาเมื่อ $\lambda = 0.7$ ที่พารามิเตอร์ของการแจกแจงเท่ากับ 5 ให้ค่า ARL ของแผนภูมิควบคุม DHWMA แบบขยาย ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA ในทุกระดับการเปลี่ยนแปลง(δ) ยกเว้นระดับการเปลี่ยนแปลงที่ $\delta = 0.25$ ให้ค่า ARL ของแผนภูมิควบคุม DHWMA ดีกว่าแผนภูมิควบคุม HWMA และ DHWMA แบบขยาย และหากพิจารณาถึงภาพรวมในทุกระดับการเปลี่ยนแปลง จะพิจารณาจากค่า AEQL ที่ต่ำที่สุด เช่น ที่ $\lambda = 0.7$ พารามิเตอร์ของการแจกแจงเท่ากับ 1 แผนภูมิควบคุม DHWMA แบบขยาย มีประสิทธิภาพดีที่สุด เนื่องจากค่า AEQL ต่ำสุด คือมีค่าเท่ากับ 8.15

3.2 ผลการศึกษาประสิทธิภาพของแผนภูมิควบคุมกรณีที่ $ARL_0 = 370$ ในรูปแบบกราฟ

หลังจากที่ได้ข้อมูลจากข้อ 3.1 นำข้อมูลที่ได้ไปสร้างกราฟ ARL โดยใช้ โปรแกรม Microsoft Excel เพื่อสร้างกราฟสำหรับพิจารณาแผนภูมิควบคุมในรูปแบบกราฟเส้นดังนี้

3.2.1 ประสิทธิภาพของแผนภูมิควบคุมกรณีที่ $ARL_0 = 370$ ในรูปแบบกราฟ สำหรับการแจกแจงโลจิสติก

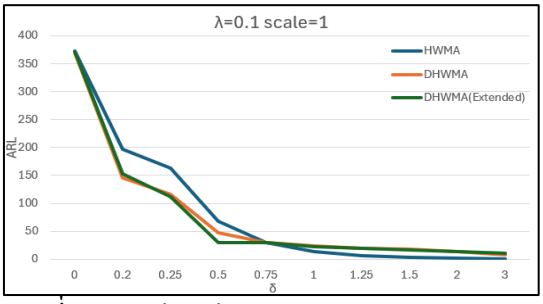

ภาพที่ 1: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.1$ และพารามิเตอร์ เท่ากับ 1

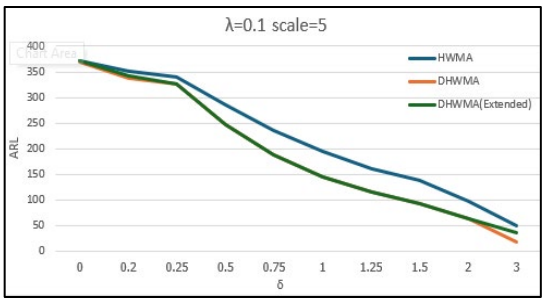

ภาพที่ 2: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.1$ และพารามิเตอร์ เท่ากับ 5

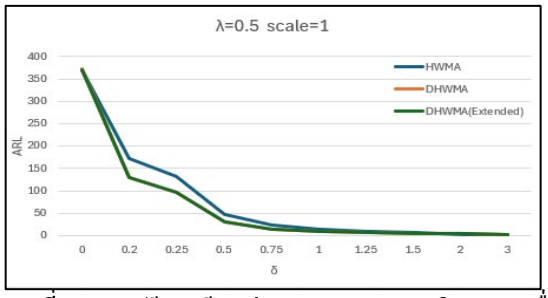

ภาพที่ 3: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.5$ และพารามิเตอร์ เท่ากับ 1

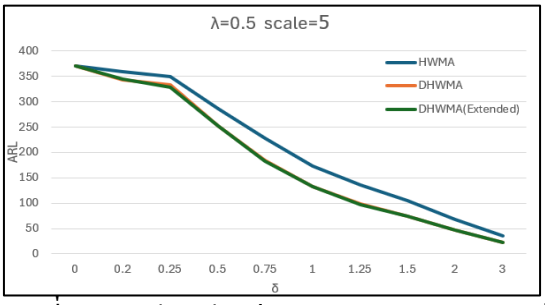

ภาพที่ 4: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.5$ และพารามิเตอร์ เท่ากับ 5

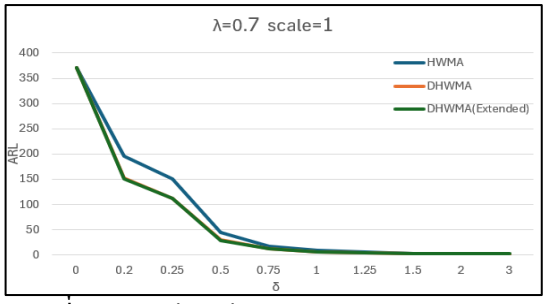

ภาพที่ 5 : การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.7$ และพารามิเตอร์ เท่ากับ 1

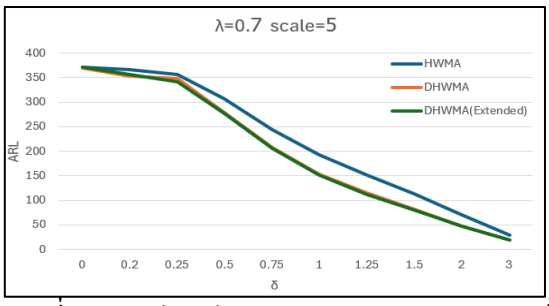

ภาพที่ 6: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงโลจิสติกส์ ที่ $\lambda = 0.7$ และพารามิเตอร์ เท่ากับ 5

3.2.2 ประสิทธิภาพของแผนภูมิควบคุมกรณีที่ $ARL_0 = 370$ ในรูปแบบกราฟ สำหรับการแจกแจงลาปลาซ

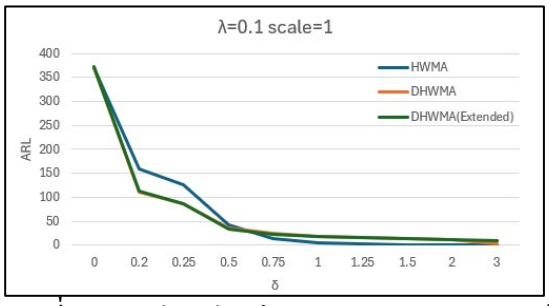

ภาพที่ 7: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.1$ และพารามิเตอร์ เท่ากับ 1

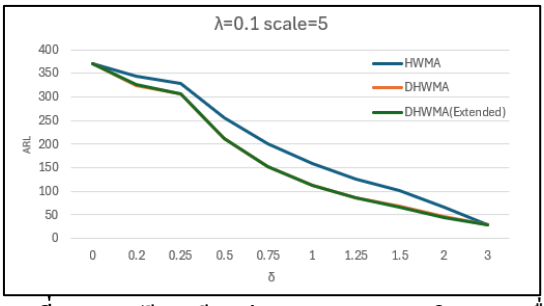

ภาพที่ 8: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.1$ และ พารามิเตอร์ เท่ากับ 5

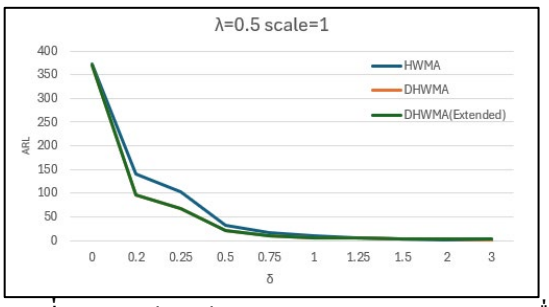

ภาพที่ 9: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.5$ และ พารามิเตอร์ เท่ากับ 1

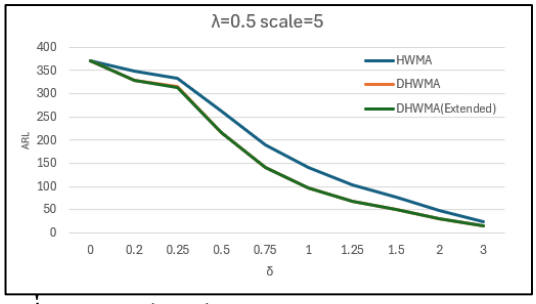

ภาพที่ 10: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.5$ และ พารามิเตอร์เท่ากับ 5

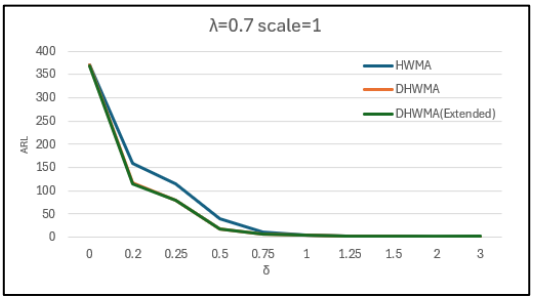

ภาพที่ 11: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.7$ และ พารามิเตอร์เท่ากับ 1

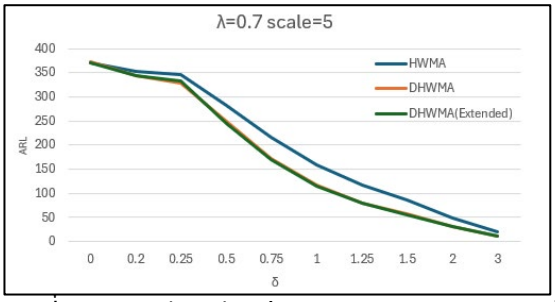

ภาพที่ 12: การเปรียบเทียบค่า ARL ของแผนภูมิควบคุมเมื่อข้อมูลเป็นการแจกแจงลาปลาซ ที่ $\lambda = 0.7$ และ พารามิเตอร์เท่ากับ 5

4. สรุปผล

จากการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมทั้ง 3 แผนภูมิ พบว่าเมื่อให้ค่า $ARL_0 = 370$ ให้ผลลัพธ์ของประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการที่แตกต่างกันจากทั้ง 3 แผนภูมิ โดยแผนภูมิควบคุมทั้ง 3 คือ แผนภูมิควบคุม HWMA แผนภูมิควบคุม DHWMA และ แผนภูมิควบคุม DHWMA แบบขยาย มีประสิทธิภาพที่แตกต่างกันขึ้นอยู่กับระดับค่า λ และ δ โดยการแจกแจงโลจิสติก แผนภูมิควบคุม DHWMA แบบขยายจะมีประสิทธิภาพในการตรวจจับได้ดีที่สุด ในกรณีต่อไปนี้ คือ กรณีที่ $\lambda = 0.1$ ที่พารามิเตอร์ เท่ากับ 1 ค่า $\delta = 0.25, 0.5, 0.75, 1, 1.25, 1.5, 2$ และที่พารามิเตอร์ เท่ากับ 5 ค่า $\delta = 0.5, 1.25, 1.5, 2$ กรณีที่ $\lambda = 0.5$ ที่พารามิเตอร์เท่ากับ 1 ค่า $\delta = 0.2, 0.75, 1, 1.25, 1.5, 2$ และที่พารามิเตอร์เท่ากับ 5 ค่า $\delta = 0.25, 0.5, 0.75, 1, 1.25, 1.5, 2, 3$ และกรณีที่ที่ $\lambda = 0.7$ ที่พารามิเตอร์ เท่ากับ 1 ค่า $\delta = 0.2, 0.25, 0.5, 0.75, 1$ และที่พารามิเตอร์ เท่ากับ 5 ค่า $\delta = 0.25, 0.5, 0.75, 1, 1.25, 1.5, 2, 3$ ต่อมาเมื่อมีการแจกแจงแบบลาปลาซ แผนภูมิควบคุม DHWMA แบบขยาย จะมีประสิทธิภาพในการตรวจจับได้ดีที่สุด ในกรณีต่อไปนี้ คือ กรณีที่ $\lambda = 0.1$ ที่พารามิเตอร์ เท่ากับ 1 ค่า $\delta = 0.25, 0.5$ และที่พารามิเตอร์ เท่ากับ 5 ค่า $\delta = 0.25, 0.5, 0.75, 1, 1.25, 1.5, 2, 3$ กรณีที่ $\lambda = 0.5$ ที่พารามิเตอร์ เท่ากับ 1 ค่า $\delta = 0.2, 0.25, 0.5, 0.75, 1, 1.25$ และที่พารามิเตอร์ เท่ากับ 5 ค่า δ ทุกระดับการเปลี่ยนแปลง และกรณีที่ที่ $\lambda = 0.7$ ที่พารามิเตอร์ เท่ากับ 1 ค่า $\delta = 0.2, 0.25, 0.75, 1$ และที่พารามิเตอร์ เท่ากับ 5 ค่า $\delta = 0.2, 0.5, 0.75, 1, 1.25, 1.5, 2, 3$

ซึ่งจากข้อมูลนี้แสดงให้เห็นว่าแผนภูมิควบคุม DHWMA แบบขยาย มีประสิทธิภาพดีกว่าสองแผนภูมิควบคุมที่นำมาเปรียบเทียบกัน ภายใต้การแจกแจงแบบโลจิสติกและการแจกแจงลาปลาซ ในการเปลี่ยนแปลงเล็กถึงกลาง

5. กิตติกรรมประกาศ

การวิจัยเรื่อง การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DHWMA แบบขยายสำหรับการตรวจจับการเปลี่ยนแปลงของกระบวนการ เพื่อการสำเร็จการศึกษาของนักศึกษาระดับปริญญาตรี สามารถดำเนินการจนประสบความสำเร็จลุล่วงไปด้วยดี เนื่องจาก ได้รับความอนุเคราะห์และสนับสนุนเป็นอย่างดียิ่งจาก ศาสตราจารย์ ดร.ยุพาภรณ์ อารีพงษ์ ที่ได้กรุณาให้คำปรึกษา ความรู้ ข้อคิด ข้อแนะนำ และปรับปรุงแก้ไขข้อบกพร่องต่างๆ ด้วยความเอาใจใส่อย่างดีโดยตลอด ตลอดจนกระทั่งการวิจัยครั้งนี้สำเร็จเรียบร้อยด้วยดี ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

สุดท้ายนี้ผู้วิจัยหวังว่างานวิจัยฉบับนี้คงเป็นประโยชน์สำหรับหน่วยงานที่เกี่ยวข้อง และผู้ที่สนใจศึกษาต่อไป

6. เอกสารอ้างอิง

[1] ดวงรัตน์ เรืองอุไร (2555), แนวคิดการบริหารคุณภาพ, ประสิทธิภาพของแผนภูมิควบคุม DEWMA สำหรับตัวแบบ IMA(1,1), 3(2), 376-381.

[2] Zameer Abbas, Hafiz Zafar Nazir, Muhammad Abid, Noureen Akhtar, Muhammad Riaz, (2021), Nonparametric progressive sign chart for monitoring process location based on individual data, Quality Technology & Quantitative Management, 18(2), 225-247.

[3] Vasileios Alevizakos, Kashinath Chatterjee, Christos Koukouvinos, (2021), The extended homogeneously weighted moving average control chart, Quality and Reliability Engineering, 37(5), 2134-2155.

[4] Jean-Claude Malela-Majika, Schalk William Human and Kashinath Chatterjee, (2024), Homogeneously Weighted Moving Average Control Charts, Mathematics, 12(5), 637.

การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม QEWMA สำหรับข้อมูลที่มีการแจกแจงแบบต่อเนื่อง

A Comparison of the Efficiency of the QEWMA Control Charts for Continuous Distributions

จันทราภรณ์ ธรรมวัตร* พัชรี จังพานิช หิรัญ สะพะพันธ์ ยุพาภรณ์ อารีพงษ์
ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(*s6404052610011@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมในการตรวจจับการเปลี่ยนแปลงขนาดเล็กของพารามิเตอร์ ในกระบวนการผลิตมีการแจกแจงแบบต่อเนื่อง โดยพิจารณาการแจกแจงแบบเลขชี้กำลัง (Exponential) และการแจกแจงแบบไวบูล (Weibull) แผนภูมิควบคุมที่ศึกษาได้แก่ EWMA, DEWMA, TEWMA และ QEWMA ซึ่งดำเนินการทดสอบโดยจำลองข้อมูลด้วยวิธี Monte Carlo ทำซ้ำ 10,000 รอบ ภายใต้สถานการณ์ที่กำหนด ได้แก่ Exp(1), Exp(2), Wb(1,2), Wb(1,4) พร้อมทั้งกำหนดค่าพารามิเตอร์ปรับเรียบของแผนภูมิควบคุมทั้ง 4 ชนิด เท่ากับ 0.05, 0.10, 0.25 และขนาดการเปลี่ยนแปลงกระบวนการ เท่ากับ 0.025 ถึง 2 ประสิทธิภาพแผนภูมิควบคุมประเมินโดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) ซึ่งแผนภูมิที่มีประสิทธิภาพสูงสุดจะให้ค่าความยาวรันเฉลี่ยเมื่อกระบวนออกนอกการควบคุมมีค่าน้อยที่สุด ภายใต้สถานการณ์ที่กำหนดข้างต้นในทุกสถานการณ์ ผลวิจัยพบว่าแผนภูมิควบคุม QEWMA มีประสิทธิภาพเหนือกว่าแผนภูมิอื่นๆ ในหลายกรณี โดยเฉพาะเมื่อค่าพารามิเตอร์ปรับเรียบ เท่ากับ 0.05 ซึ่งให้ผลลัพธ์ดีสุดในทุกค่าระดับการเปลี่ยนแปลงของกระบวนการ สำหรับกรณีที่มีการแจกแจง Exp(1) แผนภูมิควบคุม QEWMA มีประสิทธิภาพสูงสุดเมื่อขนาดการเปลี่ยนแปลงของกระบวนการเท่ากับ 0.025 ส่วนในกรณี Exp(2) พบว่า QEWMA มีประสิทธิภาพสูงสุดเมื่อขนาดการเปลี่ยนแปลงของกระบวนการเท่ากับ 0.1 สำหรับข้อมูลที่มีการแจกแจง Wb(1,2) แผนภูมิ QEWMA มีประสิทธิภาพสูงสุดเมื่อขนาดการเปลี่ยนแปลงของกระบวนการอยู่ในช่วง 0.2 ถึง 0.3 และอยู่ในช่วง 0.4 ถึง 0.8 สำหรับการแจกแจง Wb(1,4) นอกจากนี้ เมื่อตั้งค่าพารามิเตอร์ปรับเรียบของแผนภูมิควบคุมเป็น 0.1 และ 0.25 พบว่าแผนภูมิ TEWMA ให้ผลลัพธ์ที่ดีกว่าในช่วงขนาดการเปลี่ยนแปลงของกระบวนการระหว่าง 0.2 ถึง 0.4 สำหรับข้อมูลที่มีการแจกแจง Exp(1)

คำสำคัญ: แผนภูมควบคุม, การแจกแจงแบบเลขชี้กำลัง, การแจกแจงแบบไวบูล, ค่าความยาวรันเฉลี่ย

Abstract

This research aims to compare the efficiency of control charts in detecting small parameter shifts in processes that follow continuous distributions. The studied considers Exponential (Exp) and Weibull (Wb) distributions. The control charts analyzed include EWMA, DEWMA, TEWMA, and QEWMA, which are evaluated using Monte Carlo simulations with 10,000 replications. Various scenarios are examined, including Exp(1), Exp(2), Wb(1,2), and Wb(1,4), with smoothing parameters set at 0.05, 0.10, and 0.25. The magnitude of process shifts ranges from 0.025 to 2.The efficiency of the control charts is assessed based on the Average Run Length (ARL), where the most efficient chart is the one that yields the lowest ARL when the process is out of control. The findings indicate that the QEWMA chart outperforms the other control charts in many scenarios, particularly when the smoothing parameter is set to 0.05, delivering the best results across all levels of process shifts. Specifically, for an Exp(1) distribution, the QEWMA chart demonstrates the highest efficiency when the process shift is 0.025. In the case of Exp(2), the QEWMA chart performs best when the process shift is 0.1. For a Wb(1,2) distribution, QEWMA achieves the highest efficiency when the process shift falls between 0.2 and 0.3, whereas

for Wb(1,4), the optimal range is between 0.4 and 0.8. Additionally, when the smoothing parameter is set to 0.1 or 0.25, the TEWMA chart yields better results for an Exp(1)

Keywords: Control chart, Exponential distribution, Weibull distribution, Average Run Length

1. บทนำ

การควบคุมกระบวนการทางสถิติ (Statistical Process Control) เป็นเครื่องมือสำคัญอย่างยิ่งในกระบวนการผลิต เนื่องจากสามารถช่วยให้ผู้ควบคุมกระบวนการสามารถตัดสินใจได้อย่างแม่นยำและทันเวลาในการปรับปรุงคุณภาพผลิตภัณฑ์ นอกจากนี้ยังช่วยลดต้นทุนที่เกิดจากของเสีย ลดเวลาหยุดชะงักของกระบวนการผลิต และเพิ่มประสิทธิภาพในการดำเนินงาน โดยเฉพาะการตรวจจับการเปลี่ยนแปลงที่เกิดขึ้นในช่วงเริ่มต้น ซึ่งถือเป็นปัจจัยสำคัญที่ช่วยลดความสูญเสียและเพิ่มคุณภาพของกระบวนการผลิต หนึ่งในเครื่องมือที่นิยมใช้ในกระบวนการควบคุมคือ แผนภูมิควบคุม (Control Chart) โดยแผนภูมิควบคุมที่มีการพัฒนาอย่างต่อเนื่องสามารถรองรับลักษณะข้อมูลที่ซับซ้อนมากขึ้น ซึ่งมีความจำเป็นในอุตสาหกรรมที่ต้องการมาตรฐานคุณภาพสูง ซึ่งแผนภูมิควบคุมได้รับการพัฒนาหลากหลายรูปแบบเพื่อเพิ่มประสิทธิภาพในการตรวจจับความผิดปกติของกระบวนการ แผนภูมิ Shewhart Control Chart เป็นหนึ่งในเทคนิคแรกที่ถูกพัฒนาขึ้นโดย Walter A. Shewhart ในปี ค.ศ. 1924 อย่างไรก็ตาม แผนภูมินี้มีข้อจำกัดในการตรวจจับการเปลี่ยนแปลงเล็กน้อยของกระบวนการ ทำให้มีการพัฒนาแผนภูมิที่สามารถตอบสนองต่อการเปลี่ยนแปลงของข้อมูลได้ดียิ่งขึ้น

หนึ่งในแผนภูมิที่ได้รับความนิยมคือ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average: EWMA) ซึ่งถูกคิดค้นโดย S. W. Roberts ในปี ค.ศ. 1959 แผนภูมิ EWMA ใช้การถ่วงน้ำหนักแบบเลขชี้กำลังกับข้อมูลในอดีต ทำให้สามารถตรวจจับการเปลี่ยนแปลงเล็กน้อยในกระบวนการได้ดีกว่าแผนภูมิ Shewhart ด้วยคุณสมบัตินี้ แผนภูมิ EWMA จึงได้รับการพัฒนาต่อเนื่องเพื่อเพิ่มประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการ โดยมีการนำเสนอแผนภูมิที่ดัดแปลงเพิ่มเติม ได้แก่ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 2 ครั้ง (Double Exponentially Weighted Moving Average: DEWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 3 ครั้ง (Triple Exponentially Weighted Moving Average: TEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 4 ครั้ง (Quadruple Exponentially Weighted Moving Average: QEWMA) แผนภูมิ DEWMA ได้รับการพัฒนาโดย Shamma ในปี ค.ศ. 1992 ซึ่งเป็นการเพิ่ม EWMA อีกชั้นเพื่อเพิ่มความไวในการตรวจจับสัญญาณผิดปกติของกระบวนการ ต่อมาแผนภูมิ TEWMA ได้รับการนำเสนอโดย Alevizakos et al. ในปี ค.ศ. 2020 โดยเพิ่มระดับของ EWMA เป็นสามระดับ ทำให้สามารถจับสัญญาณการเปลี่ยนแปลงได้อย่างแม่นยำมากขึ้น และล่าสุดแผนภูมิ QEWMA ได้รับการนำเสนอโดย Alevizakos et al. ในปี ค.ศ. 2021 โดยใช้แนวคิดเดียวกันในการเพิ่มความไวในการตรวจจับการเปลี่ยนแปลงของกระบวนการด้วย EWMA สี่ระดับ โดยทั่วไป แผนภูมิควบคุมถูกออกแบบมาเพื่อใช้กับข้อมูลที่มีการแจกแจงแบบปกติ ซึ่งเป็นสมมติฐานพื้นฐานของหลายเทคนิคทางสถิติ อย่างไรก็ตาม ในสถานการณ์จริง ข้อมูลกระบวนการอาจไม่ได้เป็นไปตามการแจกแจงปกติ เช่น ข้อมูลที่มีลักษณะเบ้ขวา (Right-Skewed) อย่างการแจกแจงแบบเลขชี้กำลังและไวบูล ซึ่งมักพบในอุตสาหกรรมที่เกี่ยวข้องกับการวิเคราะห์เวลาระหว่างข้อผิดพลาดของเครื่องจักร หรืออายุการใช้งานของผลิตภัณฑ์ปกติ เพื่อประเมินประสิทธิภาพของแผนภูมิควบคุมภายใต้เงื่อนไขที่ข้อมูลไม่ได้เป็นไปตามการแจกแจงปกติ จำเป็นต้องใช้เกณฑ์วัดผลที่เหมาะสม หนึ่งในเกณฑ์ที่ได้รับความนิยมคือ ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) ซึ่งใช้วัดจำนวนรอบการตรวจสอบโดยเฉลี่ยก่อนที่แผนภูมิจะส่งสัญญาณผิดปกติ หากค่า In-Control ARL มีค่าสูง แสดงว่าแผนภูมิสามารถลดการแจ้งเตือนที่ผิดพลาดได้ ขณะที่ค่า Out-of-Control ARL ที่ต่ำ บ่งบอกถึงความสามารถในการตรวจจับการเปลี่ยนแปลงของกระบวนการได้อย่างรวดเร็ว

จากที่กล่าวมา การศึกษานี้มุ่งเน้นไปที่การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม EWMA, DEWMA, TEWMA และแผนภูมิควบคุม QEWMA ภายใต้ข้อมูลที่มีการแจกแจงแบบเลขชี้กำลังและไวบูล โดยใช้เกณฑ์ ARL เป็นตัวชี้วัดหลัก เพื่อให้สามารถเลือกใช้แผนภูมิที่เหมาะสมกับลักษณะของกระบวนการผลิตที่แตกต่างกัน

2. วิธีการวิจัย

การวิจัยนี้ใช้ วิธีการจำลองข้อมูล Monte Carlo Simulation เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม 4 ชนิด ได้แก่ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA), แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 2 ครั้ง (DEWMA), แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 3 ครั้ง (TEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 4 ครั้ง (QEWMA) ในการตรวจจับการเปลี่ยนแปลงขนาดเล็กของพารามิเตอร์ภายใต้การแจกแจงแบบเลขชี้กำลัง (Exponential Distribution) และ ไวบูล (Weibull Distribution)

2.1 การจำลองข้อมูล

2.1.1 วิธีที่ใช้ในการจำลองข้อมูล

ใช้วิธี Monte Carlo Simulation ทำซ้ำ 10000 รอบ

2.1.2 กำหนดค่าพารามิเตอร์ของการแจกแจง

การแจกแจงแบบเลขชี้กำลัง กำหนดให้มีสัญลักษณ์กำหนดพารามิเตอร์กำหนดรูปร่าง เท่ากับ 1 และ 2

เป็นการแจกแจงที่เป็นแบบสุ่มในช่วงระยะเวลาที่รอคอยจนกว่าจะเกิดเหตุการณ์ที่สนใจที่เกิดขึ้นเป็นครั้งแรก โดย

กำหนดให้ x เป็นตัวแปรสุ่ม แบบต่อเนื่องที่มีการแจกแจงแบบเลขชี้กำลังที่มี ที่มี β เป็นพารามิเตอร์กำหนดรูปร่าง (Shape Parameter) ซึ่งจะเขียนแทนด้วย $x \sim Exp(\beta)$
ฟังก์ชันความหนาแน่นความน่าจะเป็นของการแจกแจงแบบเลขชี้กำลัง คือ

$$f(x) = \frac{1}{\beta} e^{-\frac{x}{\beta}} \; ; x > 0, \beta > 0 \quad (1)$$

ค่าคาดหวังคือ $\mathrm{E}(x) = \beta$ (2)

ความแปรปรวนคือ $Var(x) = \beta^2$ (3)

การแจกแจงแบบไวบูล กำหนดพารามิเตอร์กำหนดขนาดเท่ากับ 1 พารามิเตอร์กำหนดรูปร่าง เท่ากับ 2 และ 4ปันการแจกแจงความน่าจะเป็นแบบต่อเนื่อง ที่มี α เป็นพารามิเตอร์กำหนดขนาด (Scale Parameter) และ β เป็นพารามิเตอร์กำหนดรูปร่าง (Shape Parameter) ซึ่งจะเขียนแทนด้วย $T \sim Weibull(\alpha, \beta)$ หรือ $Wb(\alpha, \beta)$
ฟังก์ชันความหนาแน่นความน่าจะเป็นของการแจกแจงไวบูล

$$f(t) = \frac{\beta}{\alpha}\left(\frac{t}{\alpha}\right)^{\beta-1} exp\left[-\left(\frac{t}{\alpha}\right)^{\beta}\right] ; t \geq 0, \alpha, \beta > 0 \quad (4)$$

ค่าคาดหวังคือ $\mathrm{E}(t) = \alpha \cdot \Gamma\left(1 + \frac{1}{\beta}\right)$ (5)

ความแปรปรวนคือ

$$Var(t) = \alpha^2 \cdot \left[\Gamma\left(1 + \frac{2}{\beta}\right) - \left(\Gamma\left(1 + \frac{1}{\beta}\right)\right)^2\right] \quad (6)$$

2.1.3 ขนาดการเปลี่ยนแปลงของกระบวนการ เท่ากับ 0.025, 0.05, 0.1, 0.3, 0.5, 0.7, 0.9, 1.0, 2.0

2.1.4 กำหนดพารามิเตอร์ปรับเรียบ ทั้ง 4 ชนิด เท่ากับ 0.05, 0.10 และ 0.25

2.2 แผนภูมิควบคุม

แผนภูมิควบคุมที่นำมาศึกษางานวิจัยนี้ มีดังต่อไปนี้

2.2.1 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 1 ครั้ง (EWMA)

ค่าสถิติของแผนภูมิควบคุม EWMA คือ

$$E_i = \lambda x_i + (1-\lambda)E_{i-1} \quad ; i = 1,2,\ldots \quad (7)$$

โดยที่ E_i คือ ค่าสถิติ EWMA ณ เวลา i
x_i คือ ค่าสังเกตของกระบวนการ ลำดับที่ ณ เวลา i
λ คือ ค่าพารามิเตอร์ปรับเรียบ ; $0 \leq \lambda \leq 1$
L คือ ความกว้างของของขีดจำกัดควบคุม
กำหนดตัวสถิติเริ่มต้น $E_0 = \mu_0$ คือ ค่าเฉลี่ยของกระบวนการ
เมื่อกระบวนการอยู่ภายใต้การควบคุม ค่าเฉลี่ยและค่าความแปรปรวนของ E_i คือ

$$E(E_i) = \mu_0 \quad (8)$$

$$Var(E_i) = \lambda/(2-\lambda) \quad (9)$$

ดังนั้นขีดจำกัดควบคุมของแผนภูมิควบคุม EWMA คือ

$$UCL_i/LCL_i = \mu_o \pm L\sigma\sqrt{Var(E_i)} \quad (10)$$

โดยที่ μ_0 คือ ค่าเฉลี่ยของกระบวนการ
σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของกระบวนการ

2.2.2 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 2 ครั้ง (DEWMA)

ค่าสถิติของแผนภูมิควบคุม DEWMA คือ

$$\begin{aligned} E_i &= \lambda x_i + (1-\lambda)E_{i-1} \quad ; i = 1,2,\ldots \\ D_i &= \lambda E_i + (1-\lambda)D_{i-1} \quad ; i = 1,2,\ldots \end{aligned} \quad (11)$$

โดยที่ D_i คือ ค่าสถิติ DEWMA ณ เวลา i
x_i คือ ค่าสังเกตของกระบวนการ ลำดับที่ ณ เวลา i
λ คือ ค่าพารามิเตอร์ปรับเรียบ ; $0 \leq \lambda \leq 1$
L คือ ความกว้างของของขีดจำกัดควบคุม
กำหนดตัวสถิติเริ่มต้น $E_0 = D_0 = \mu_0$ คือค่าเฉลี่ยของกระบวนการ
เมื่อกระบวนการอยู่ภายใต้การควบคุม ค่าเฉลี่ยและค่าความแปรปรวนของ D_i คือ

$$E(D_i) = \mu_0 \quad (12)$$

$$Var(D_i) = \lambda(2 - 2\lambda - \lambda^2)/n(2-\lambda)^3 \quad (13)$$

ดังนั้นขีดจำกัดควบคุมของแผนภูมิควบคุม DEWMA คือ

$$UCL_i/LCL_i = \mu_o \pm L\sigma\sqrt{Var(D_i)} \quad (14)$$

โดยที่ μ_0 คือ ค่าเฉลี่ยของกระบวนการ
σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของกระบวนการ

2.2.3 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 3 ครั้ง (TEWMA)

ค่าสถิติของแผนภูมิควบคุม TEWMA คือ

$$\begin{aligned} E_i &= \lambda x_i + (1-\lambda)E_{i-1} \quad ; i = 1,2,\ldots \\ D_i &= \lambda E_i + (1-\lambda)D_{i-1} \quad ; i = 1,2,\ldots \\ T_i &= \lambda D_i + (1-\lambda)T_{i-1} \quad ; i = 1,2,\ldots \end{aligned} \quad (15)$$

โดยที่ T_i คือ ค่าสถิติ TEWMA ณ เวลา i
x_i คือ ค่าสังเกตของกระบวนการ ลำดับที่ ณ เวลา i
λ คือ ค่าพารามิเตอร์ปรับเรียบ ; $0 \leq \lambda \leq 1$
L คือ ความกว้างของของขีดจำกัดควบคุม
กำหนดตัวสถิติเริ่มต้น $E_0 = D_0 = T_0 = \mu_0$ คือ ค่าเฉลี่ยของกระบวนการ
เมื่อกระบวนการอยู่ภายใต้การควบคุม ค่าเฉลี่ยและค่าความแปรปรวนของ T_i คือ

$$E(T_i) = \mu_0 \quad (16)$$

$$Var(T_i) = \frac{6(1-\lambda)^6\lambda}{(2-\lambda)^5} + \frac{12(1-\lambda)^6\lambda^2}{(2-\lambda)^4} + \frac{7(1-\lambda)^2\lambda^3}{(2-\lambda)^3} + \frac{\lambda^4}{(2-\lambda)^2} \quad (17)$$

ดังนั้นขีดจำกัดควบคุมของแผนภูมิควบคุม TEWMA คือ

$$UCL_i/LCL_i = \mu_o \pm L\sigma\sqrt{Var(T_i)} \quad (18)$$

โดยที่ μ_0 คือ ค่าเฉลี่ยของกระบวนการ
σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของกระบวนการ

2.2.4 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง 4 ครั้ง (QEWMA)

ค่าสถิติของแผนภูมิควบคุม QEWMA คือ

$$\begin{aligned} E_i &= \lambda x_i + (1-\lambda)E_{i-1} \quad ; i = 1,2,\ldots \\ D_i &= \lambda E_i + (1-\lambda)D_{i-1} \quad ; i = 1,2,\ldots \\ T_i &= \lambda D_i + (1-\lambda)T_{i-1} \quad ; i = 1,2,\ldots \\ Q_i &= \lambda T_i + (1-\lambda)Q_{i-1} \quad ; i = 1,2,\ldots \end{aligned} \quad (19)$$

โดยที่ Q_i คือ ค่าสถิติ QEWMA ณ เวลา i

x_i คือ ค่าสังเกตของกระบวนการ ลำดับที่ ณ เวลา i
λ คือ ค่าพารามิเตอร์ปรับเรียบ ; $0 \leq \lambda \leq 1$
L คือ ความกว้างของของขีดจำกัดควบคุม
กำหนดตัวสถิติ เริ่มต้น $E_0 = D_0 = T_0 = Q_0 = \mu_0$ คือ ค่าเฉลี่ยของกระบวนการ
เมื่อกระบวนการอยู่ภายใต้การควบคุม ค่าเฉลี่ยและค่าความแปรปรวนของ Q_i คือ

$$E(Q_i) = \mu_0 \tag{20}$$

$$Var(Q_i) = \left(\frac{\lambda^8}{36}\right)\frac{720d^5}{(1-d)^7} + \frac{2520d^4}{(1-d)^6} + \frac{3312d^3}{(1-d)^5} + \frac{1980d^2}{(1-d)^4} + \frac{504d}{(1-d)^3} + \frac{36}{(1-d)^2} \tag{21}$$

กำหนดให้ $d = (1-\lambda)^2$
สมการความแปรปรวนของ Q_i (สมการ 21) ได้มาจากการศึกษาของ Alevizakos et al.โดยพิจารณาจากคุณสมบัติของกระบวนการ QEWMA ซึ่งสามารถศึกษาเพิ่มเติมได้จาก [1]
ดังนั้นขีดจำกัดควบคุมของแผนภูมิควบคุม QEWMA คือ

$$UCL_i/LCL_i = \mu_o \pm L\sigma\sqrt{Var(Q_i)} \tag{22}$$

โดยที่ μ_0 คือ ค่าเฉลี่ยของกระบวนการ
σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของกระบวนการ

2.3 เกณฑ์การวัดประสิทธิภาพ

ค่าความยาวรันเฉลี่ย (ARL_1)เมื่อกระบวนการผลิตอยู่นอกการควบคุมค่า ARL_1 ควรจะมีต่ำ ๆ หรือกล่าวได้ว่าเมื่อกระบวนการอยู่นอกการควบคุม แผนภูมิควบคุมส่งสัญญาณแจ้งเตือนบ่อยมากขึ้นในการวิจัยครั้งนี้ใช้วิธี Monte Carlo ในการคำนวณค่า ARL เป็นวิธีการศึกษาทดลองโดยการทำซ้ำๆ หลายครั้ง ซึ่งสามารถคำนวณค่า ARL ได้ดังนี้

$$ARL = \frac{\sum_{i=1}^{M} RL_i}{M} \tag{23}$$

โดยที่ M คือ จำนวนรอบ RL_t คือ ค่าความยาวรัน เป็นจำนวนหน่วยตัวอย่างที่ถูกตรวจ สอบจนกระทั่งพบว่า กระบวนการออกนอกขีดจำกัดควบคุมเป็นครั้งแรก ในการจำลองข้อมูลครั้งที่ i

ในงานวิจัยครั้งนี้เลือกใช้ ARL_0 เท่ากับ 370 ช่วยให้การเปรียบเทียบกับแผนภูมิ มีความเป็นธรรมและสอดคล้องกัน เนื่องจากแผนภูมิเหล่านี้มักถูกประเมินประสิทธิภาพที่ค่า ARL_0 เดียวกันในงานวิจัยของ Lucas and Saccucci (1990) และ Alevizakos et al. (2021) ได้ใช้ ARL_0 เท่ากับ 370 เป็นเกณฑ์มาตรฐานในการประเมินแผนภูมิควบคุมเช่นเดียวกัน ค่า ARL_0 ที่สูงเกินไปอาจทำให้แผนภูมิควบคุมตรวจจับความผิดปกติได้ช้าลง ส่วนค่าที่ต่ำเกินไปอาจทำให้เกิด สัญญาณเตือนที่ผิดพลาด (false alarms) บ่อยครั้ง ดังนั้น 370 จึงเป็นค่าที่เหมาะสมและยอมรับได้ในหลายบริบท

2.4 การวิเคราะห์ผลลัพธ์

เปรียบเทียบค่าความยาวรันเฉลี่ย (ARL_1) ของแต่ละแผนภูมิควบคุมภายใต้สภานการณ์ที่แตกต่างกัน แผนภูมิควบคุมที่มีประสิทธิภาพดีที่สุดจะให้ค่า ARL_1 ต่ำที่สุด

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการวิจัย

3.1.1 กรณีข้อมูลมีการแจกแจงเลขชี้กำลัง $Exp(1)$

จากตารางที่ 1 และรูปที่ 1 ในกรณี λ=0.05 พบว่าแผนภูมิควบคุม QEWMA มีประสิทธิภาพในการตรวจพบการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการดีที่สุดในทุกระดับ δ

จากตารางที่ 1 และรูปที่ 2 ในกรณี λ=0.10 พบว่าเมื่อ $0.025 \leq \delta \leq 0.05$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพในการตรวจพบการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการดีที่สุด แต่เมื่อ $0.1 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA และ DEWMA มีประสิทธิภาพได้ดีกว่าแผนภูมิควบคุม QEWMA

จากตารางที่ 1 และรูปที่ 3 กรณี λ=0.25 พบว่าเมื่อ $0.05 \leq \delta \leq 0.1$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพดีที่สุดแต่เมื่อ $0.2 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA และ DEWMA ได้ดีกว่าแผนภูมิควบคุม QEWMA

3.1.2 กรณีข้อมูลมีการแจกแจงเลขชี้กำลัง $Exp(2)$

จากตารางที่ 2 และรูปที่ 4 กรณี λ=0.05 พบว่าแผนภูมิควบคุม QEWMA มีประสิทธิภาพในการตรวจพบการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการดีที่สุดในทุกระดับ δ

จากตารางที่ 2 และรูปที่ 5 กรณี λ=0.10 พบว่าเมื่อ $0.05 \leq \delta \leq 0.1$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพในการตรวจพบการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการดีที่สุด แต่เมื่อ $0.2 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA และ DEWMA มีประสิทธิภาพได้ดีกว่าแผนภูมิควบคุม QEWMA

จากตารางที่ 2 และรูปที่ 6 กรณี λ=0.25 พบว่าเมื่อ $0.1 \leq \delta \leq 0.2$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพดีที่สุด แต่เมื่อ $0.3 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA และ DEWMA ได้ดีกว่าแผนภูมิควบคุม QEWMA

3.1.3 กรณีข้อมูลมีการแจกแจงไวบูล $Wb(1,2)$

จากตารางที่ 3 และรูปที่ 7 กรณี λ=0.05 พบว่าเมื่อ $0.05 \leq \delta \leq 2$ แผนภูมิ QEWM มีประสิทธิดีที่สุด จากตารางที่ 3 และรูปที่8 กรณี λ=0.10 พบว่าเมื่อ $0.2 \leq \delta \leq 0.3$ แผนภูมิ QEWMA มีประสิทธิภาพดีที่สุด แต่เมื่อ $0.4 \leq \delta \leq 2$ แผนภูมิ TEWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีกว่าแผนภูมิควบคุม QEWMA

จากตารางที่ 3 และรูปที่ 9 กรณี λ=0.25 พบว่าเมื่อ $0.2 \leq \delta \leq 0.4$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพดีที่สุด แต่เมื่อ $0.5 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA มีประสิทธิภาพได้ดีกว่าแผนภูมิควบคุม QEWMA

3.1.4 กรณีข้อมูลมีการแจกแจงไวบูล $Wb(1,4)$

จากตารางที่ 4 และรูปที่ 10 กรณี λ=0.05 พบว่าเมื่อ $0.1 \leq \delta \leq 2$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพดีที่สุด แต่เมื่อ $0.025 \leq \delta \leq 0.05$ แผนภูมิควบคุม DEWMA มีประสิทธิภาพดีกว่าแผนภูมิควบคุม QEWMA

จากตารางที่ 4 และรูปที่ 11 และกรณี λ=0.10 พบว่าเมื่อ $0.3 \leq \delta \leq 0.8$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพในการตรวจพบการเปลี่ยนแปลงค่าพารามิเตอร์ของกระบวนการดีที่สุด แต่เมื่อ $0.9 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA มี

ประสิทธิภาพได้ดีกว่าแผนภูมิควบคุม QEWMA และเมื่อ$0.025 \leq \delta \leq 0.2$ แผนภูมิควบคุม DEWMA มีประสิทธิภาพได้ดีกว่า

จากตารางที่ 4 และรูปที่ 12 กรณี λ=0.25 พบว่าเมื่อ $0.4 \leq \delta \leq 0.8$ แผนภูมิควบคุม QEWMA มีประสิทธิภาพดีที่สุด แต่เมื่อ $0.9 \leq \delta \leq 2$ แผนภูมิควบคุม TEWMA มีประสิทธิภาพได้ดีกว่าแผนภูมิควบคุม QEWMA และเมื่อ $0.025 \leq \delta \leq 0.3$ แผนภูมิควบคุม DEWMA มีประสิทธิภาพได้ดีกว่า

3.2 อภิปรายผล

ผลการวิเคราะห์พบว่า แผนภูมิควบคุม QEWMA TEWMA DEWMA และ EWMA มีประสิทธิภาพแตกต่างกันตามปัจจัยต่าง ๆ โดยการแจกแจงข้อมูลแบบ Exp(1) และ Exp(2) ที่มีความแปรปรวนสูงทำให้ QEWMA เหมาะกับการเปลี่ยนแปลงขนาดเล็ก ขณะที่การแจกแจงแบบ Wb(1,2) และ Wb(1,4) ที่มีความยืดหยุ่นมากกว่า ช่วยให้ TEWMA และ DEWMA ทำงานได้ดีขึ้นในกรณีการเปลี่ยนแปลงขนาดใหญ่ นอกจากนี้ ผลกระทบจากพารามิเตอร์ λ พบว่า เมื่อ λ ต่ำ (0.05) QEWMA จะมีประสิทธิภาพสูงสุดในการตอบสนองต่อการเปลี่ยนแปลงขนาดเล็ก ส่วนค่า λ ปานกลางถึงสูง (0.10-0.25) TEWMA และ DEWMA จะทำงานได้ดีขึ้นในกรณีการเปลี่ยนแปลงขนาดใหญ่ ซึ่งชี้ให้เห็นว่าไม่มีแผนภูมิควบคุมใดที่เหมาะสมกับทุกสถานการณ์ ต้องเลือกใช้ให้เหมาะสมกับลักษณะของกระบวนการ

4. สรุปผลการวิเคราะห์

4.1 สรุปผลการวิเคราะห์

จากผลการวิจัยนี้ที่ได้เปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม 4 ชนิดได้แก่ QEWMA TEWMA DEWMA และEWMA โดยพิจารณาจากเกณฑ์ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) พบว่าแผนภูมิควบคุม QEWMA มีประสิทธิภาพเหนือกว่าแผนภูมิอื่นๆที่เสนอ ในหลายกรณี ผลลัพธ์นี้สอดคล้องกับแนวคิดที่ว่าแผนภูมิควบคุม QEWMA สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กในกระบวนการที่มีความแปรปรวนสูงได้อย่างมีประสิทธิภาพ

ในกรณีข้อมูลที่มีการแจกแจงแบบเลขชี้กำลัง Exp(1) เมื่อ δ = 0.025 และ Exp(2) เมื่อ δ = 0.1 นอกจากนี้ ในกรณีข้อมูลที่มีการแจกแจงไวบูล Wb(1,2) เมื่อ $0.2 \leq \delta \leq 0.3$ และ Wb(1,4) เมื่อ $0.4 \leq \delta \leq 0.8$ แผนภูมิควบคุม QEWMA ยังคงมีประสิทธิภาพเหนือกว่า โดยเฉพาะเมื่อ λ=0.05 แผนภูมิ QEWMA จะมีประสิทธิดีสุดในทุกค่า δ

ผลการวิจัยนี้สอดคล้องกับงานวิจัยของ Alevizakos และคณะ (2022) ที่เสนอแผนภูมิควบคุม QEWMA ว่ามีความสามารถในการตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีกว่าแผนภูมิควบคุม EWMA แบบดั้งเดิม นอกจากนี้ งานวิจัยของ Alevizakos และคณะ (2021) ที่เสนอแผนภูมิ TEWMA และงานวิจัยของ Alevizakos และคณะ (2020) ที่เสนอแผนภูมิควบคุม DEWMA ก็แสดงให้เห็นว่าแผนภูมิที่พัฒนาขึ้นใหม่เหล่านี้มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการได้ดีขึ้น อย่างไรก็ตาม จากผลการวิจัยของเราพบว่าแผนภูมิควบคุม QEWMA ยังคงมีประสิทธิภาพเหนือกว่าแผนภูมิควบคุม TEWMA และ DEWMA ในหลายกรณี

ดังนั้นในงานวิจัยครั้งต่อไป ควรพิจารณานำแผนภูมิควบคุม QEWMA ไปประยุกต์ใช้กับการแจกแจงอื่น ๆ เช่น การแจกแจงลาปลาซและการแจกแจงโลจิสติกส์ หรือทำการเปรียบเทียบกับแผนภูมิควบคุมอื่น ๆ เช่น แผนภูมิควบคุม HWMA เพื่อประเมินประสิทธิภาพและความเหมาะสมในการใช้งานในสถานการณ์ต่าง ๆ

4.2 ข้อเสนอแนะ

ควรเลือกใช้แผนภูมิควบคุมที่เหมาะสมกับกระบวนการผลิต หากต้องการตรวจจับการเปลี่ยนแปลงเล็กๆ ใช้แผนภูมิควบคุม QEWMA หากต้องการตรวจจับการเปลี่ยนแปลงขนาดใหญ่ ใช้แผนภูมิควบคุม TEWMA หรือ DEWMA ในกรณีที่กระบวนการมีการแจกแจงแบบไวบูล ที่มีค่า scale สูง อาจพิจารณา แผนภูมิควบคุม DEWMA

ควรมีการทดลองหาค่า λ ที่เหมาะสมสำหรับแต่ละกระบวนการ ค่า λ ต่ำช่วยให้แผนภูมิไวต่อการเปลี่ยนแปลงแต่ทำให้มีโอกาสเกิดสัญญาณเตือนที่ผิดพลาด (false alarms) ค่า λ สูงช่วยลดสัญญาณเตือนที่ผิดพลาด แต่ทำให้แผนภูมิตอบสนองช้าต่อการเปลี่ยนแปลงเล็กๆ ควรทดสอบหาค่า λ ที่เหมาะสมผ่านการจำลองข้อมูลจริง

ควรศึกษาการใช้แผนภูมิควบคุมแบบไฮบริด จากผลการศึกษาพบว่าไม่มีแผนภูมิใดที่ดีที่สุดในทุกสถานการณ์ อาจมีการใช้ แผนภูมิแบบไฮบริด ที่ผสมผสานข้อดีของแต่ละแผนภูมิ เช่น ใช้ QEWMA สำหรับการตรวจจับการเปลี่ยนแปลงเล็กๆ และเปลี่ยนเป็น TEWMA หรือ DEWMA เมื่อพบสัญญาณของการเปลี่ยนแปลงขนาดใหญ่ ใช้การปรับค่า λ แบบไดนามิก เพื่อให้แผนภูมิตอบสนองต่อการเปลี่ยนแปลงได้ดีขึ้น

4.3 การประยุกต์ใช้ในอุตสาหกรรม

4.3.1. การควบคุมกระบวนการผลิตชิ้นส่วนอิเล็กทรอนิกส์

ในอุตสาหกรรมที่ผลิตชิ้นส่วนที่มีขนาดเล็กและต้องการความเที่ยงตรงสูง เช่น เซมิคอนดักเตอร์หรือแผงวงจรไฟฟ้า QEWMA สามารถนำมาใช้ตรวจสอบค่าพารามิเตอร์สำคัญ เช่น ความหนาของโลหะนำไฟฟ้าหรือค่าความต้านทานไฟฟ้า ซึ่งมีผลโดยตรงต่อคุณภาพของผลิตภัณฑ์ ความสามารถของ QEWMA ในการตรวจจับความเบี่ยงเบนเล็ก ๆ ได้ตั้งแต่ระยะเริ่มต้น ช่วยลดอัตราของเสียและยืดอายุการใช้งานของเครื่องจักรในสายการผลิต ซึ่งในงานวิจัยระบุว่า QEWMA มีประสิทธิภาพสูงสุดในการตรวจจับ small shifts เมื่อเทียบกับ EWMA, DEWMA และ TEWMA

4.3.2. การตรวจสอบอายุการใช้งานของผลิตภัณฑ์

QEWMA ยังสามารถประยุกต์ใช้ในการติดตามประสิทธิภาพของผลิตภัณฑ์หลังออกสู่ตลาด เช่น สมาร์ทโฟน หรือแบตเตอรี่ โดยใช้ข้อมูลจากการใช้งานจริงของผู้บริโภค เช่น ระยะเวลาใช้งานต่อการชาร์จหรือประสิทธิภาพของระบบประมวลผล จากคุณสมบัติของ QEWMA ที่

สามารถติดตามค่าที่เปลี่ยนแปลงช้าและมีแนวโน้มอย่างต่อเนื่อง ทำให้สามารถคาดการณ์ช่วงเวลาที่ผลิตภัณฑ์เริ่มเสื่อมสภาพและให้ข้อมูลที่เป็นประโยชน์แก่ผู้ผลิตในการปรับปรุงผลิตภัณฑ์รุ่นใหม่

ประโยชน์เชิงปฏิบัติของ QEWMA ช่วยตรวจจับความเบี่ยงเบนเล็ก ๆ ได้รวดเร็วช่วยให้กระบวนการผลิตสามารถปรับปรุงได้ทันท่วงที ช่วยลดของเสียและต้นทุนโดยการแก้ไขปัญหาก่อนจะลุกลาม ช่วยเพิ่มความน่าเชื่อถือของผลิตภัณฑ์ทั้งในสายการผลิตและการใช้งานจริง และยังสนับสนุนการวางแผนผลิตภัณฑ์ด้วยข้อมูลเชิงลึกจากการตรวจสอบอย่างต่อเนื่อง

ตารางที่ 1 ค่า ARL_1 ของแผนภูมิควบคุม กรณีที่มีการแจกแจงแบบเลขชี้กำลัง Exp(1) ภายใต้ ARL_0=370

λ	δ	EWMA	DEWMA	TEWMA	QEWMA
0.05	0.025	213.337	238.047	195.707	**167.735**
	0.05	119.831	131.469	92.573	**71.252**
	0.1	60.112	63.523	37.425	**26.792**
	0.2	34.822	34.451	18.635	**12.233**
	0.3	27.444	25.786	14.105	**8.992**
	0.4	23.672	21.192	11.882	**7.626**
	0.5	21.355	14.651	10.543	**6.835**
	0.6	19.744	16.221	9.612	**6.293**
	0.7	18.520	14.651	8.879	**5.901**
	0.8	17.585	13.456	8.314	**5.567**
	0.9	16.818	12.480	7.841	**5.311**
	1	16.207	11.663	7.465	**5.092**
	2	13.398	7.514	5.370	**3.855**
0.10	0.025	231.341	243.420	225.504	**221.395**
	0.05	159.659	136.578	117.890	**114.571**
	0.1	73.467	56.760	**45.114**	45.811
	0.2	32.861	23.933	**19.342**	22.058
	0.3	24.495	15.955	**13.520**	16.574
	0.4	20.447	12.460	**10.995**	14.130
	0.5	17.983	10.468	**9.534**	12.630
	0.6	16.793	9.103	**8.534**	11.619
	0.7	15.819	8.115	**7.810**	10.815
	0.8	15.024	7.358	**7.232**	10.223
	0.9	14.586	6.769	**6.784**	9.724
	1	14.153	**6.293**	6.406	9.300
	2	12.264	**3.833**	4.420	7.000
0.25	0.025	**226.435**	235.894	236.973	239.538
	0.05	146.761	142.872	138.609	**136.890**
	0.1	72.854	58.975	54.165	**53.214**
	0.2	32.001	19.593	**17.795**	18.657
	0.3	21.780	10.728	**10.117**	11.423
	0.4	17.831	7.331	**7.188**	8.683
	0.5	15.870	**5.655**	5.792	7.275
	0.6	14.704	**4.650**	4.930	6.415
	0.7	13.961	**3.978**	4.345	5.809
	0.8	13.432	**3.471**	3.914	5.346
	0.9	13.049	**3.102**	3.570	5.000
	1	12.761	**2.820**	3.293	4.698
	2	11.539	**1.444**	2.005	3.183

*ตัวเข้มคือค่า ARL_1 ต่ำสุด

ตารางที่ 2 ค่า ARL_1 ของแผนภูมิควบคุม กรณีที่มีการแจกแจงแบบเลขชี้กำลัง Exp(2) ภายใต้ ARL_0=370

λ	δ	EWMA	DEWMA	TEWMA	QEWMA
0.05	0.025	307.970	312.250	281.780	**266.258**
	0.05	231.295	227.042	178.886	**163.025**
	0.1	131.938	119.294	77.611	**67.775**
	0.2	60.003	50.894	28.319	**24.725**
	0.3	37.986	32.060	16.887	**14.407**
	0.4	28.355	24.186	12.515	**10.500**
	0.5	23.015	19.872	10.252	**8.540**
	0.6	19.688	17.144	8.904	**7.383**
	0.7	17.471	15.208	7.989	**6.653**
	0.8	15.812	13.800	7.349	**6.154**
	0.9	14.526	12.661	6.842	**5.762**
	1	13.533	11.769	6.424	**5.444**
	2	9.366	7.328	4.410	**3.970**
0.10	0.025	**298.133**	312.570	307.127	307.643
	0.05	224.996	235.557	223.554	**220.431**
	0.1	132.708	127.098	114.932	**113.767**
	0.2	58.713	50.129	**43.075**	45.515
	0.3	35.074	28.443	**24.999**	28.505
	0.4	25.139	19.695	**17.987**	21.861
	0.5	20.028	15.236	**14.491**	18.473
	0.6	16.971	12.611	**12.408**	16.418
	0.7	14.908	**10.884**	11.011	15.001
	0.8	13.445	**9.636**	10.048	13.969
	0.9	12.388	**8.684**	9.296	13.141
	1	11.617	**7.930**	8.674	12.484
	2	8.309	**4.626**	5.804	9.186
0.25	0.025	**289.139**	303.337	306.161	310.159
	0.05	**223.206**	233.770	236.683	239.538
	0.1	142.587	141.329	137.935	**136.822**
	0.2	67.530	57.287	53.753	**53.126**
	0.3	38.737	29.531	**27.804**	28.389
	0.4	26.276	18.385	**17.414**	18.620
	0.5	19.886	12.915	**12.635**	13.947
	0.6	16.168	**9.766**	9.898	11.383
	0.7	13.803	**7.809**	8.140	9.760
	0.8	12.283	**6.541**	7.003	8.654
	0.9	11.190	**5.637**	6.204	7.852
	1	10.397	**4.946**	5.608	7.256
	2	7.496	**2.337**	3.180	4.684

*ตัวเข้มคือค่า ARL_1 ต่ำสุด

ตารางที่ 3 ค่า ARL_1 ของแผนภูมิควบคุม กรณีที่มีการแจกแจงไวบูล Wb(1,2) ภายใต้ ARL_0=370

λ	δ	EWMA	DEWMA	TEWMA	QEWMA
0.05	0.025	275.946	**260.704**	312.134	284.820
	0.05	218.549	200.725	228.496	**187.068**
	0.1	156.328	137.736	120.266	**87.700**
	0.2	107.087	91.437	56.328	**37.502**
	0.3	87.590	73.556	39.841	**25.526**
	0.4	76.425	63.516	32.650	**20.771**
	0.5	69.080	56.777	28.653	**18.197**
	0.6	63.852	51.695	25.975	**16.486**
	0.7	59.698	47.664	24.084	**15.362**
	0.8	56.235	44.374	22.542	**14.511**
	0.9	53.392	41.538	21.340	**13.836**
	1	50.927	39.149	20.343	**13.246**
	2	36.684	25.339	15.066	**10.214**
0.10	0.025	271.613	**255.982**	316.689	312.822
	0.05	206.507	**187.391**	239.092	230.490
	0.1	133.489	**113.787**	125.906	117.186
	0.2	75.796	62.880	51.723	**47.776**
	0.3	55.542	45.169	31.465	**30.103**
	0.4	45.581	36.578	**23.593**	23.822
	0.5	39.757	31.454	**19.527**	19.822
	0.6	35.709	28.016	**17.072**	17.657
	0.7	33.823	25.431.4	**15.363**	16.096
	0.8	30.566	23.439	**14.152**	15.033
	0.9	28.762	21.773	**13.201**	14.160
	1	27.229	20.396	**12.422**	13.483
	2	19.049	12.810	**8.645**	9.920
0.25	0.025	281.465	**269.754**	309.591	310.009
	0.05	222.218	**204.372**	242.045	240.388
	0.1	142.026	**119.235**	140.501	136.948
	0.2	70.183	55.215	55.531	**53.555**
	0.3	43.129	32.626	29.159	**28.501**
	0.4	30.476	22.893	18.949	**18.861**
	0.5	23.801	17.616	**13.733**	14.132
	0.6	19.884	14.407	**10.940**	11.549
	0.7	17.165	12.392	**9.147**	9.959
	0.8	15.316	10.946	**7.915**	8.832
	0.9	13.950	9.822	**7.054**	8.043
	1	12.920	8.943	**6.436**	7.416
	2	8.244	4.926	**3.812**	4.805

*ตัวเข้มคือค่า ARL_1 ต่ำสุด

ตารางที่ 4 ค่า ARL_1 ของแผนภูมิควบคุม กรณีที่มีการแจกแจงไวบูล Wb(1,4) ภายใต้ ARL_0=370

λ	δ	EWMA	DEWMA	TEWMA	QEWMA
0.05	0.025	317.277	**307.652**	350.098	331.201
	0.05	275.946	**260.704**	312.134	284.850
	0.1	218.549	200.747	228.496	**187.068**
	0.2	156.328	137.736	120.266	**87.709**
	0.3	124.407	108.050	76.399	**52.071**
	0.4	107.087	91.437	56.328	**37.496**
	0.5	95.338	80.889	45.921	**29.846**
	0.6	87.590	73.556	39.841	**25.524**
	0.7	81.209	68.008	35.616	**22.647**
	0.8	76.425	63.516	32.650	**20.776**
	0.9	72.459	59.918	30.355	**19.293**
	1	69.080	56.777	28.653	**18.197**
	2	50.927	39.149	20.343	**13.247**
0.10	0.025	314.726	**306.946**	351.617	349.052
	0.05	271.622	**255.982**	316.689	312.822
	0.1	206.507	**187.391**	239.092	230.487
	0.2	133.489	**113.787**	125.906	117.186
	0.3	95.788	80.397	75.397	**69.863**
	0.4	75.796	62.880	51.723	**47.776**
	0.5	63.638	52.102	38.911	**36.815**
	0.6	55.542	45.169	31.465	**30.103**
	0.7	49.699	40.268	26.677	**26.113**
	0.8	45.581	36.578	23.593	**23.271**
	0.9	42.382	33.767	**21.273**	21.367
	1	39.757	31.454	**19.527**	19.822
	2	27.229	20.396	**12.422**	13.483
0.25	0.025	322.017	**312.984**	338.602	342.808
	0.05	**281.465**	296.754	309.591	310.009
	0.1	222.218	**204.037**	242.045	240.388
	0.2	142.026	**119.235**	140.501	136.918
	0.3	97.257	**78.123**	85.654	82.393
	0.4	70.183	55.215	55.531	**53.555**
	0.5	53.755	41.336	39.242	**37.793**
	0.6	43.129	32.626	29.159	**28.501**
	0.7	35.657	26.976	23.194	**22.868**
	0.8	30.476	22.893	18.949	**18.861**
	0.9	26.701	19.875	**15.940**	16.119
	1	23.801	17.616	**13.733**	14.132
	2	12.920	8.943	**6.436**	7.416

*ตัวเข้มคือค่า ARL_1 ต่ำสุด

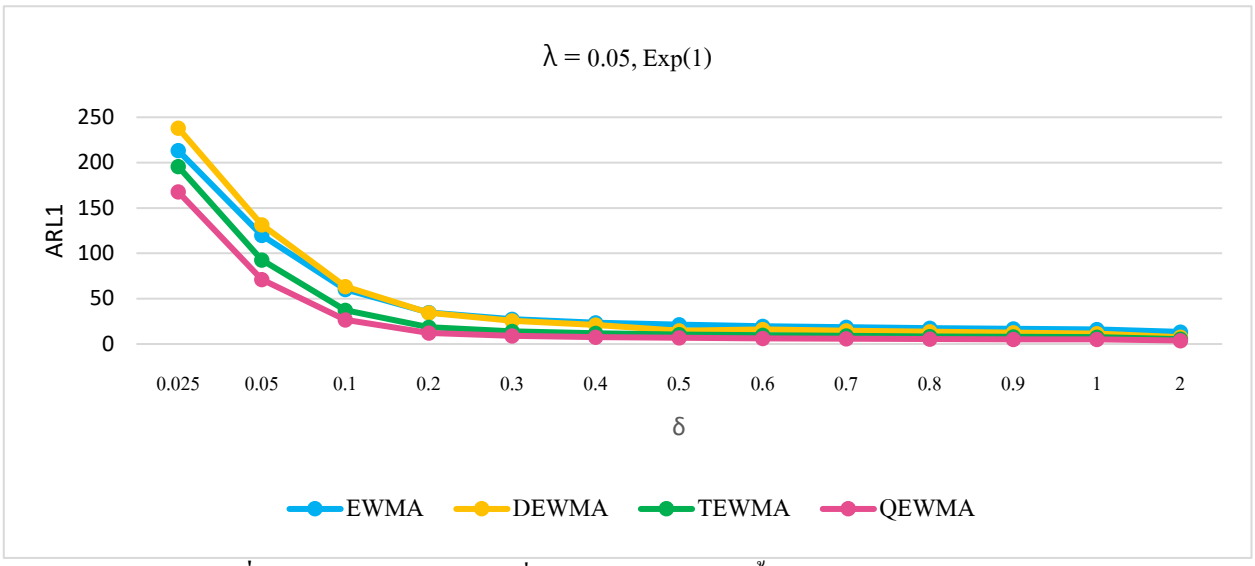

รูปที่: 1 ค่า ARL_1 กรณี λ=0.05 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(1) ภายใต้ ARL_0=370

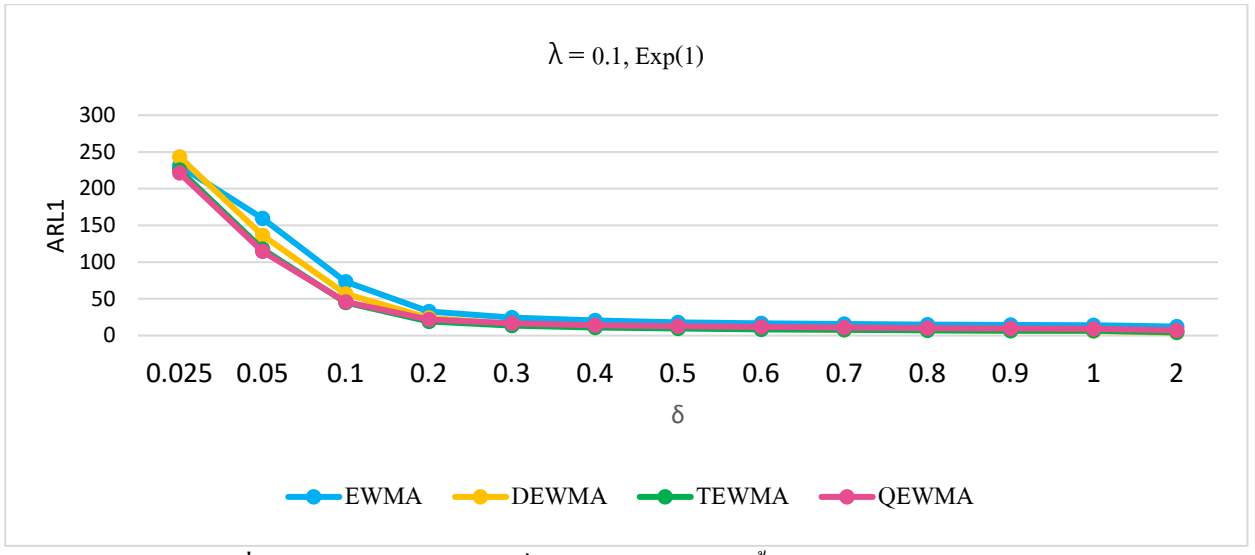

รูปที่: 2 ค่า ARL_1 กรณี λ=0.10 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(1) ภายใต้ ARL_0=370

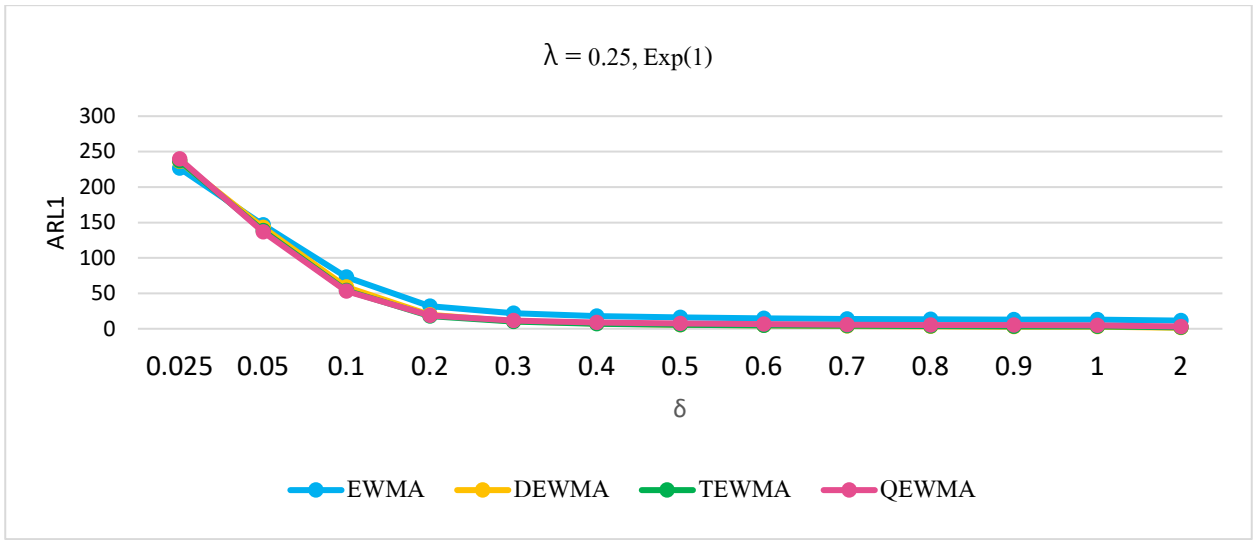

รูปที่: 3 ค่า ARL_1 กรณี λ=0.25 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(1) ภายใต้ ARL_0=370

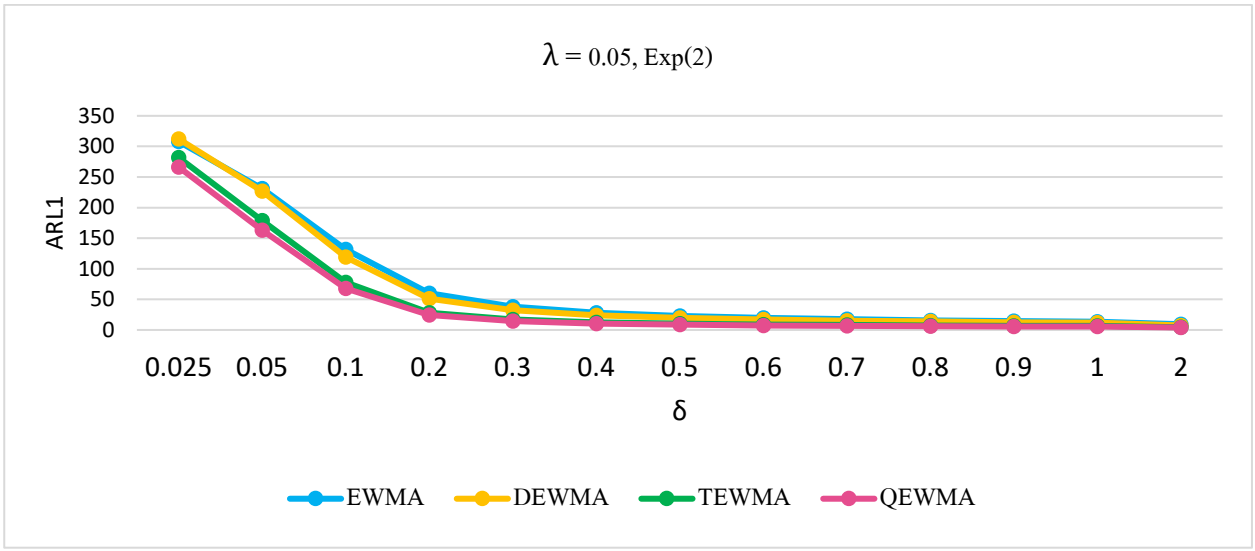

รูปที่: 4 ค่า ARL_1 กรณี λ=0.05 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(2) ภายใต้ ARL_0=370

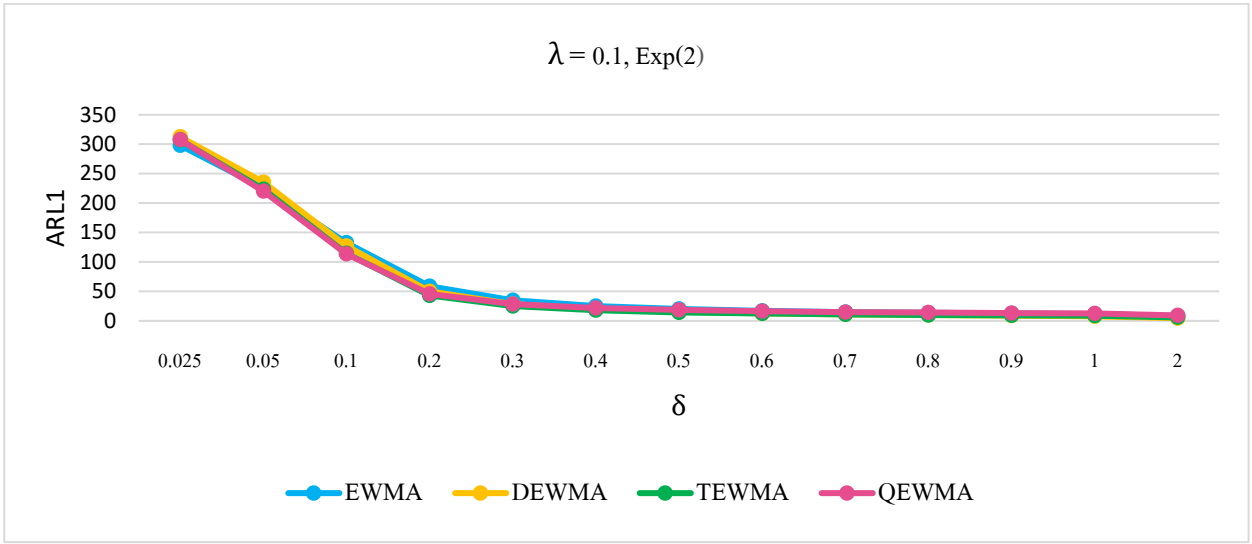

รูปที่:5 ค่า ARL_1 กรณี λ=0.10 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(2) ภายใต้ ARL_0=370

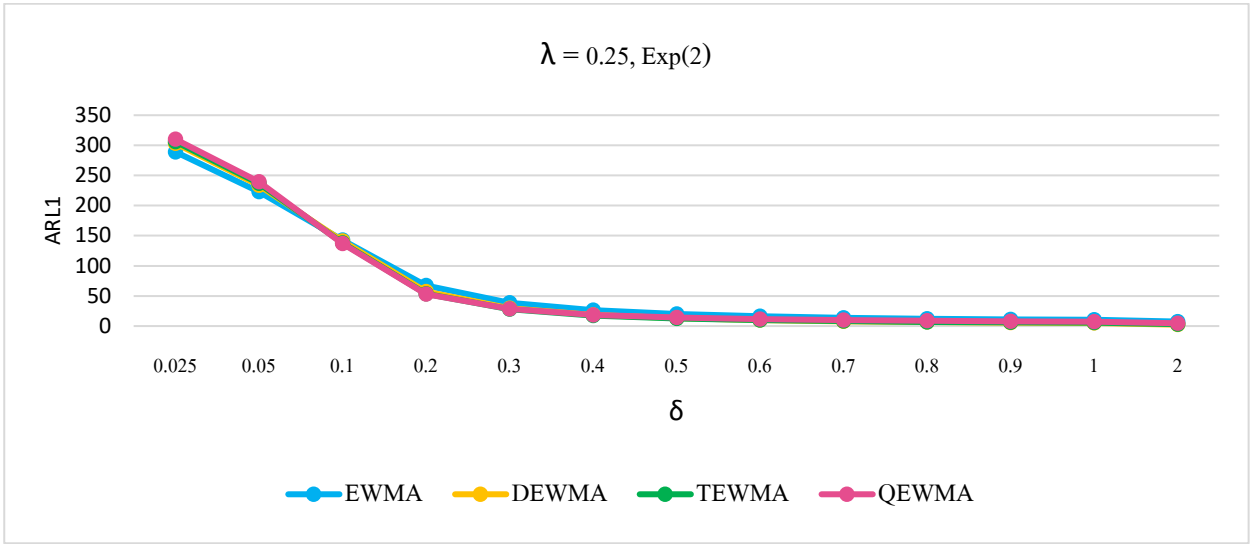

รูปที่: 6 ค่า ARL_1 กรณี λ=0.25 ที่มีการแจกแจงแบบเลขชี้กำลัง Exp(2) ภายใต้ ARL_0=370

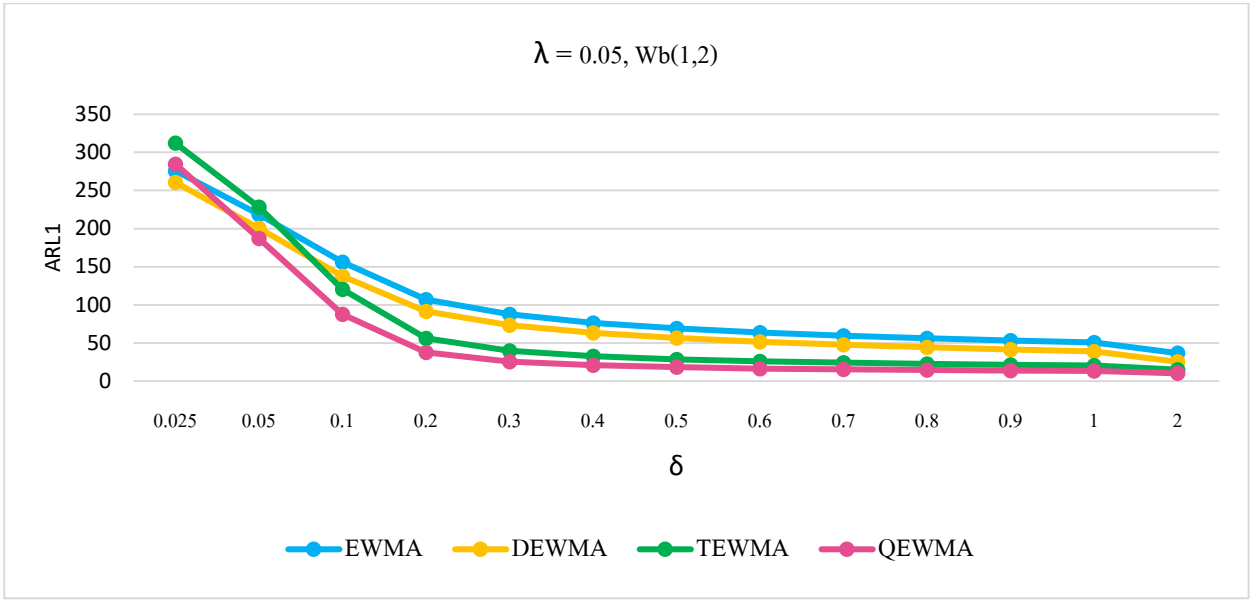

รูปที่: 7 ค่า ARL_1 กรณี λ=0.05 ที่มีการแจกแจงไวบูล Wb(1,2) ภายใต้ ARL_0=370

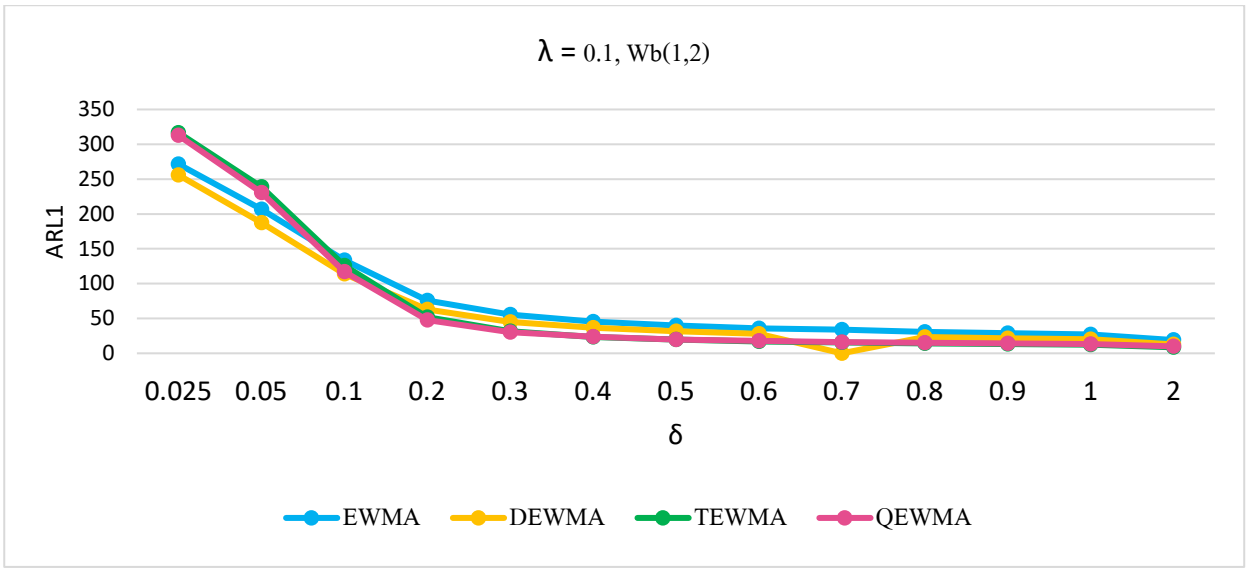

รูปที่: 8 ค่า ARL_1 กรณี λ=0.10 ที่มีการแจกแจงไวบูล Wb(1,2) ภายใต้ ARL_0=370

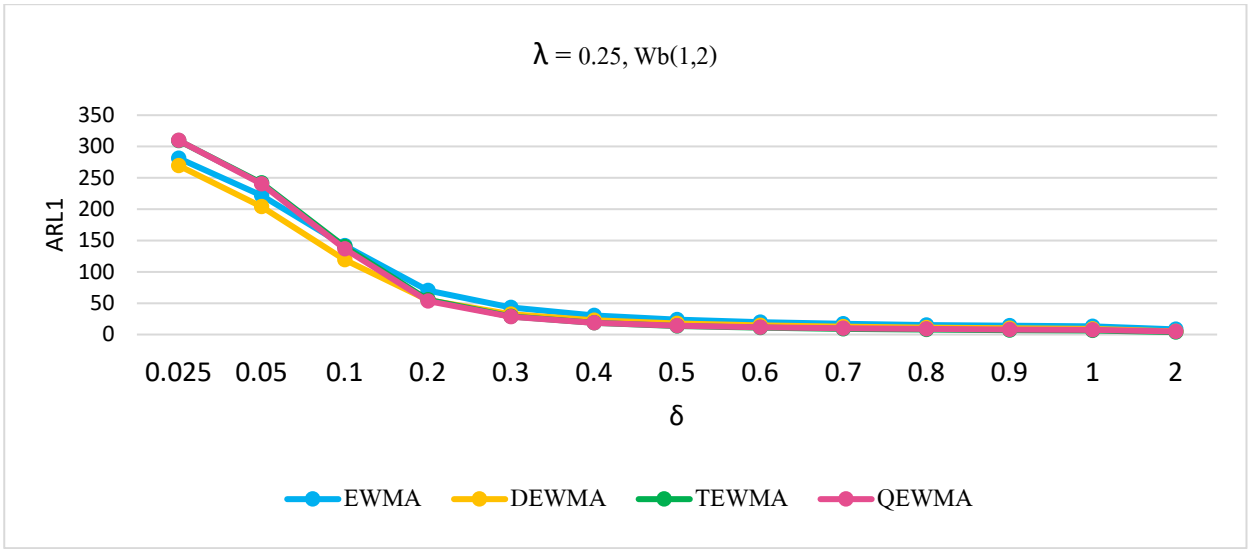

รูปที่: 9 ค่า ARL_1 กรณี λ=0.25 ที่มีการแจกแจงไวบูล Wb(1,2) ภายใต้ ARL_0=370

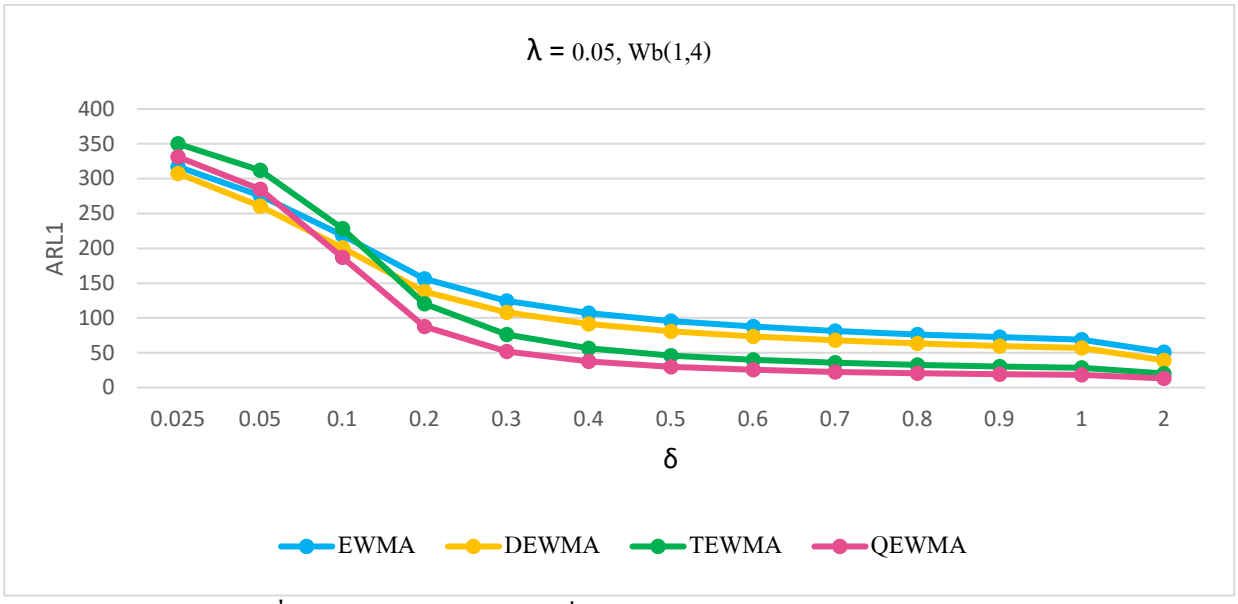

รูปที่: 10 ค่า ARL_1 กรณี λ=0.05 ที่มีการแจกแจงไวบูล Wb(1,4) ภายใต้ ARL_0=370

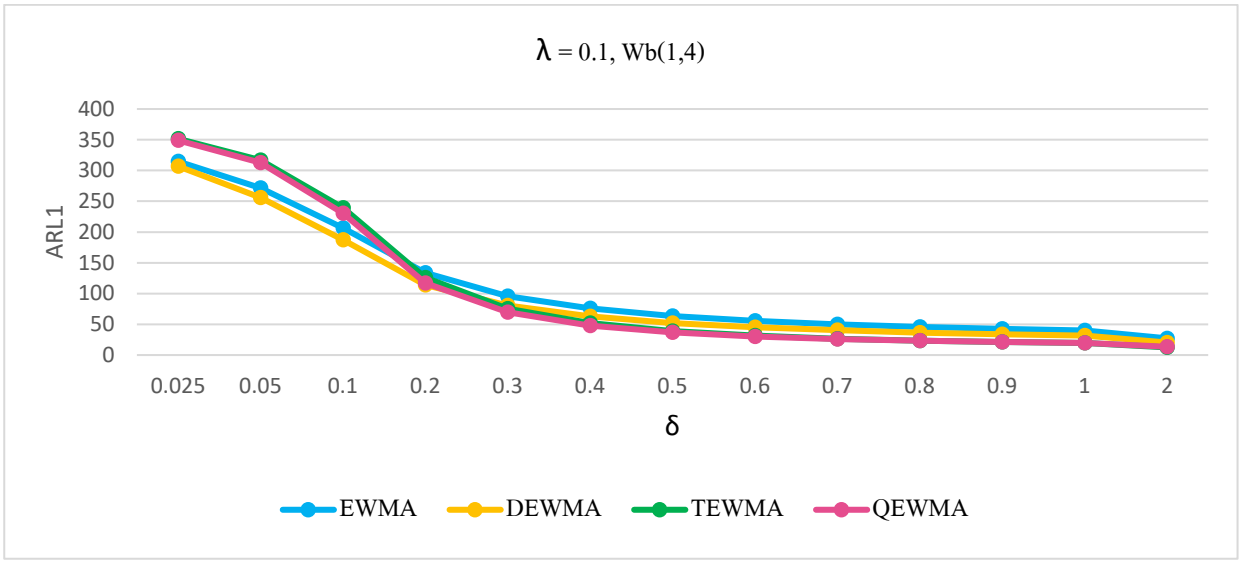

รูปที่: 11 ค่า ARL_1 กรณี λ=0.10 ที่มีการแจกแจงไวบูล Wb(1,4) ภายใต้ ARL_0=370

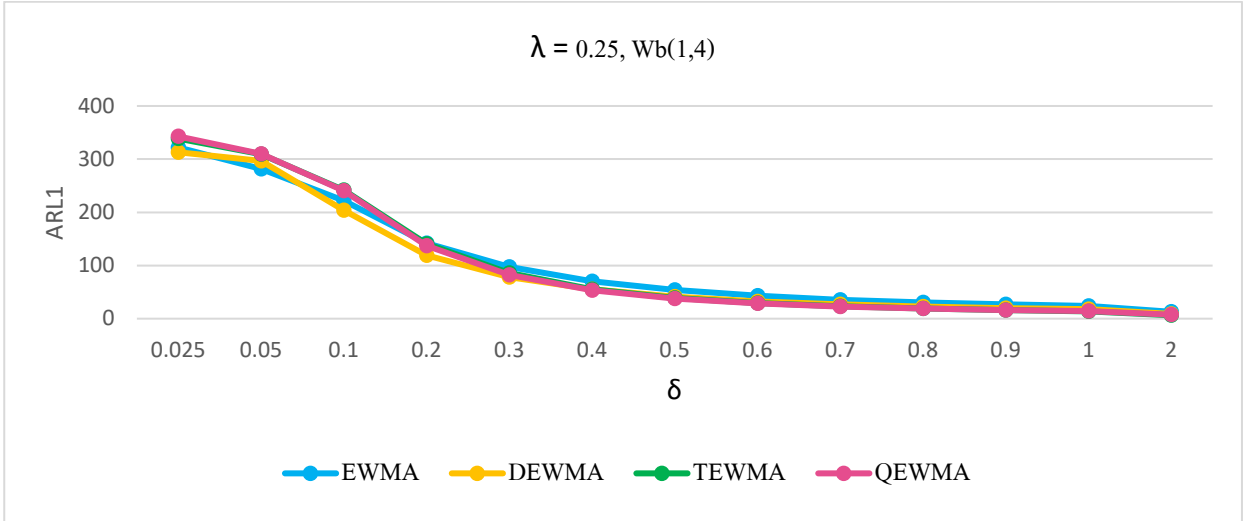

รูปที่: 12 ค่า ARL_1 กรณี λ=0.25 ที่มีการแจกแจงไวบูล Wb(1,4) ภายใต้ ARL_0=370

5. กิตติกรรมประกาศ

งานวิจัยเรื่องการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม QEWMA สำหรับข้อมูลที่มีการแจกแจงแบบต่อเนื่อง ฉบับนี้ สำเร็จลุล่วงได้ด้วยความอนุเคราะห์และการสนับสนุนจากหลายฝ่าย ผู้จัดทำขอกราบขอบพระคุณ ศาสตราจารย์ ดร. ยุพาภรณ์ อารีพงษ์ อาจารย์ที่ปรึกษางานวิจัย ที่ได้กรุณาสละเวลาอันมีค่าให้คำแนะนำ ตลอดจนให้ข้อเสนอแนะอันเป็นประโยชน์อย่างยิ่งต่อการดำเนินงานวิจัยฉบับนี้ ท่านได้ช่วยชี้แนะแนวทางในการแก้ไขปัญหา ปรับปรุงและพัฒนาเนื้อหาให้มีความถูกต้อง สมบูรณ์ และครบถ้วนยิ่งขึ้น ความเอาใจใส่และความทุ่มเทของท่านถือเป็นแรงผลักดันสำคัญที่ทำให้งานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี

นอกจากนี้ ผู้จัดทำขอขอบคุณ คณาจารย์ทุกท่าน ที่ได้มอบความรู้และแนวคิดด้านสถิติและกระบวนการควบคุมคุณภาพ ซึ่งเป็นพื้นฐานสำคัญที่ช่วยให้สามารถดำเนินการวิจัยได้อย่างมีประสิทธิภาพ และผู้มีส่วนเกี่ยวข้องทุกท่าน ที่ได้ให้ความช่วยเหลือ สนับสนุน และให้กำลังใจตลอดระยะเวลาการทำวิจัย

สุดท้ายนี้ ผู้จัดทำหวังเป็นอย่างยิ่งว่างานวิจัยฉบับนี้จะเป็นประโยชน์แก่ผู้ที่สนใจ และสามารถนำไปใช้เป็นแนวทางในการศึกษา ค้นคว้า และพัฒนาต่อยอดองค์ความรู้ในอนาคต

6. เอกสารอ้างอิง

[1] Vasileios Alevizakos, Kashinath Chatterjee & Christos Koukouvinos. (2022). The quadruple exponentially weighted moving average control chart. Quality Technology & Quantitative Management. 19(1). 50-73.

[2] Vasileios Alevizakos, Kashinath Chatterjee & Christos Koukouvinos. (2021). The tripel exponentially weighted moving average control chart, Quality Technology & Quantitative Management, 18(3). 326-354.

[3] Alevizakos, V., Chatterjee, K., & Koukouvinos, C. (2020). The double exponentially weighted moving average control chart. Quality Technology & Quantitative Management. 17(2). 149-172.

[4] Shamma, S.E. & Shamma, A.K.(1992). Development and evaluation of control charts using double exponentially weighted moving averages. Journal of Quality Technology. 21(4). 242-250.

[5] Steiner, S.H. (1999). EWMA control charts with time-varying control limits and fast initial response. Journal of Quality Technology.31(1). 75-86.

[6] Montgomery, D. C. (2001). Introduction to Statistical Quality Control. 6th ed. John Wiley & Sons. 8. 768.

[7] C. D. Lai,D. N. P. Murthy and M. Xie. (n.d.). Weibull distributions. WIREs Computational Statistics. 3(3). 282-287.

[8] N. Balakrishnan and Asit P. Basu. (1995). The Exponential Distribution. Theory Methods and Application. 1. 664.

[9] Tsubakimoto Singapore Pte. Ltd. (n.d.). Industrial Applications. Available from: https://tsubaki.co.th/catalogs/industry-applications/

ประสิทธิภาพของแผนภูมิค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยายใหม่ทั้งแบบอิงและไม่อิงพารามิเตอร์สำหรับการติดตามการเปลี่ยนแปลงค่าเฉลี่ย

Performance of both parametric and non-parametric new extended exponential moving average charts for tracking mean shifts

จุฑาภัทร จันทรภาพ* อัญมณี แก้วเพ็งกรอ ธนกฤต มณีรัตน์ เสาวณิต สุขภารังษี

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052610186@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพสำหรับตรวจจับค่าเฉลี่ยของกระบวนการระหว่างแผนภูมิควบคุมชิวฮาร์ต (Shewhart chart) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average: EWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยาย (Extended Exponentially Weighted Moving Average: EEWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยายแบบใหม่ (New Extended Exponentially Weighted Moving Average: NEEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังที่ขยายแบบใหม่ของทูคีย์ (New Extended Exponentially Weighted Moving Average-Tukey: NEEWMA-Tukey) กรณีข้อมูลมีการแจกแจงปรกติ การแจกแจงแบบเลขชี้กำลัง การแจกแจงแกมมา และการแจกแจงลาปลาซเพื่อใช้ตรวจจับการเปลี่ยนแปลงเล็กน้อยในค่าเฉลี่ยของกระบวนการ โดยผลการจำลองแบบมอนติคาร์โลเมื่อพิจารณาประสิทธิภาพการตรวจจับจากค่าความยาวรันเฉลี่ยเมื่อมีการเปลี่ยนแปลง (out of control Average Run Length: ARL_1) พบว่า แผนภูมิควบคุม NEEWMA และ NEEWMA-Tukey มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงดีกว่าแผนภูมิควบคุมอื่น ๆ เมื่อกระบวนการมีการแจกแจงแบบเลขชี้กำลัง การแจกแจงแกมมา และ การแจกแจงลาปลาซ สำหรับการแจกแจงปรกติ แผนภูมิ NEEWMA สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีที่สุด เมื่อกำหนดให้ $ARL_0 = 370$ และเมื่อค่า ARL_0 มากขึ้นประสิทธิภาพของแผนภูมิ NEEWMA มีประสิทธิภาพในการตรวจจับได้ทุกขนาดการเปลี่ยนแปลง นอกจากนี้ได้เสนอกรณีศึกษาจากข้อมูลจริงเกี่ยวกับการติดเชื้อทางเดินปัสสาวะ (UTI) ในโรงพยาบาล และความแข็งแรงของกระจกหน้าต่างของเครื่องบิน (MPa) เพื่อประยุกต์ใช้ในสถานการณ์จริง ผลลัพธ์จากข้อมูลจริงช่วยยืนยันว่าแผนภูมิ NEEWMA เป็นแผนภูมิที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีกว่าแผนภูมิควบคุมอื่น

คำสำคัญ: ประสิทธิภาพ, การตรวจจับการเปลี่ยนแปลง, ค่าเฉลี่ย, แผนภูมิควบคุมที่ผันแปรตามเวลา

Abstract

The Objective of this research was to compare the performance of detecting process mean shifts using Shewhart Control Charts, EWMA (Exponentially Weighted Moving Average) Control Charts, EEWMA (Extended Exponentially Weighted Moving Average) Control Charts, NEEWMA (New Extended Exponentially Weighted Moving Average) Control Charts, and NEEWMA-Tukey Control Charts. The analysis is conducted with data following normal distribution, Exponential distribution, gamma distribution, and Laplace distribution, in order to detect subtle shifts in the process mean. The simulation results compare the performance of the NEEWMA chart with the SHEWHART EWMA and EEWMA control charts when the performance is analyzed using the average run length when there is a change (out of control Average Run Length: ARL_1). The results indicate NEEWMA and NEEWMA-Tukey control charts performed better than other control charts in detecting changes when the process had exponential, gamma, and Laplace distributions. For normal distribution, NEEWMA chart can detect small changes well when $ARL_0 = 370$, and when ARL_0 value is larger, NEEWMA chart performance can detect all sizes

of changes. This research presents a real-world case study of hospital-based urinary tract infections (UTI) and aircraft window glass strength (MPa). For application in real situations, the results of the study confirm that NEEWMA chart is a chart that is more effective in detecting changes than other control charts.

keyword: Performance, Change Detection, Mean, Time varying Control Chart

1. บทนำ

การควบคุมกระบวนการทางสถิติ (Statistical Process Control: SPC) มีบทบาทสำคัญในภาคอุตสาหกรรมและการผลิต โดยช่วยรักษาเสถียรภาพของกระบวนการและลดความผันผวนที่เกิดขึ้น หากกระบวนการเกิดความแปรปรวนจากแหล่งที่มาธรรมชาติ กระบวนการนั้นถือว่าอยู่ในสถานะควบคุม (in-control: IC) แต่หากเกิดจากสาเหตุที่กำหนดได้ กระบวนการจะถือว่าอยู่ในสถานะไม่ควบคุม (out-of-control: OOC) ในการตรวจสอบสถานะของกระบวนการนั้น แผนภูมิควบคุม (control charts) เป็นหนึ่งในเครื่องมือที่ใช้กันอย่างแพร่หลาย โดยแผนภูมิมาตรฐานหรือแผนภูมิ Shewhart เสนอโดย Shewhart (1924) เป็นหนึ่งในแผนภูมิควบคุมแบบดั้งเดิมที่ใช้กันมาก แต่มีข้อจำกัดในการตรวจจับการเปลี่ยนแปลงเล็กน้อยของค่าเฉลี่ยกระบวนการ ต่อมา Roberts (1959) ได้เสนอแผนภูมิ EWMA เป็นการให้น้ำหนักกับข้อมูลในอดีตโดยการกำหนดตัวถ่วงน้ำหนักแบบเลขชี้กำลัง ทำให้สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กในกระบวนการได้ดีกว่าแผนภูมิ Shewhart อย่างไรก็ตาม แผนภูมิ EWMA ยังคงมีข้อจำกัดบางประการ ต่อมา Steiner (1999) ได้พัฒนาแผนภูมิ EEWMA เพื่อเพิ่มความสามารถในการตรวจจับค่าเฉลี่ยขนาดเล็กมากของกระบวนการ ทั้งนี้จากแนวคิดของการพัฒนาแผนภูมิ EWMA และEEWMA ได้มีการพัฒนาแผนภูมิ NEEWMA เสนอโดย Noor และคณะ (2023) ซึ่งเพิ่มองค์ประกอบของค่าน้ำหนักทั้งบวกและลบสำหรับข้อมูลในอดีต ส่งผลให้ความแปรปรวนของสถิติลดลง และสามารถตรวจจับการเปลี่ยนแปลงเล็ก ๆ ของกระบวนการได้อย่างมีประสิทธิภาพมากขึ้น ในงานวิจัยนี้มีการพัฒนาแผนภูมิ NEEWMA-Tukey โดยนำข้อดีของ Tukey มาใช้เพื่อปรับให้เป็นแผนภูมิควบคุมแบบไม่อิงพารามิเตอร์ และสามารถในการปรับปรุงขีดจำกัดการควบคุม (Control Limits) ทำให้สามารถตรวจจับความผิดปรกติของกระบวนการได้แม่นยำยิ่งขึ้น

จากที่กล่าวมาข้างต้น งานวิจัยนี้จะมุ่งเน้นไปที่การพัฒนาประสิทธิภาพในการตรวจจับของแผนภูมิ NEEWMA และ NEEWMA-Tukey พร้อมทั้งเปรียบเทียบประสิทธิภาพกับแผนภูมิแบบดั้งเดิม อย่าง แผนภูมิ Shewhart EWMA และ EEWMA โดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) เป็นตัววัดประสิทธิภาพ โดยประมาณค่าจากการจำลองแบบมอนติคาร์โล (Monte Carlo Simulation) เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิในสถานการณ์จริง ซึ่งผลลัพธ์ที่ได้จะช่วยให้สามารถเลือกใช้แผนภูมิที่เหมาะสมกับลักษณะของกระบวนการในอุตสาหกรรมได้อย่างมีประสิทธิภาพมากขึ้น

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การแจกแจงปรกติ (Normal Distribution)

เป็นการแจกแจงความน่าจะเป็นของค่าของตัวแปรสุ่มที่เป็นค่าแบบต่อเนื่อง โดยที่ค่าของตัวแปรสุ่มมีแนวโน้มที่จะมีค่าอยู่ใกล้ ๆ กับค่า ๆ หนึ่ง (เรียกว่าค่ามัชฌิม) กราฟแสดงค่าฟังก์ชันความหนาแน่น (probability density function: pdf) จะเป็นรูปคล้ายระฆังคว่ำ หรือเรียกว่าฟังก์ชันเกาส์เซียน

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}}\, e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

เมื่อ x แทน ตัวแปรสุ่มพารามิเตอร์
μ แทน ค่ามัชฌิม
σ^2 แทน ค่าความแปรปรวน

2.2 การแจกแจงแบบเลขชี้กำลัง (Exponential Distribution)

เป็นการแจกแจงความน่าจะเป็นแบบต่อเนื่อง ซึ่งมักเกี่ยวข้องกับระยะเวลาจนกว่าเหตุการณ์เฉพาะบางอย่างจะเกิดขึ้น ซึ่งเป็นกระบวนการที่เหตุการณ์ต่างๆ เกิดขึ้นอย่างต่อเนื่องและเป็นอิสระในอัตราเฉลี่ยคงที่ ตัวแปรสุ่มแบบเลขชี้กำลังอาจเป็นค่าที่เล็กกว่าหรือตัวแปรที่ใหญ่กว่า

$$f(x) = \frac{1}{\beta}\, e^{-\frac{x}{\beta}} \; ; \; x > 0 \text{ โดยที่ } \beta > 0$$

เมื่อ x แทน เวลาที่รอคอยจนกระทั่งเกิดเหตุการณ์ที่สนใจ
β แทน เวลาเฉลี่ยที่รอคอยจนกระทั่งเกิดเหตุการณ์

2.3 การแจกแจงแกมมา (Gamma Distribution)

เป็นการกระจายแบบ ระยะเวลาการรอคอย โดยสมมติว่าเหตุการณ์ต่างๆ เกิดขึ้นโดยอิสระและสุ่ม โดยมีระยะเวลาเฉลี่ยระหว่างเหตุการณ์เท่ากับ β ระยะเวลาการรอคอยจนกระทั่งเหตุการณ์ α เกิดขึ้นเป็นตัวแปรสุ่มแกมมา (α, β)

$$f(x;\alpha,\beta) = \frac{1}{\Gamma(\alpha)\beta^{\alpha}} x^{\alpha-1} e^{-\frac{x}{\beta}}; \quad x > 0\,,\, \alpha > 0\,,\beta > 0$$

เมื่อ α แทน พารามิเตอร์รูปร่าง
β แทน พารามิเตอร์อัตรา

2.4 การแจกแจงลาปลาซ (Laplace Distribution)

เป็นการแจกแจงของความแตกต่างของตัวแปรสุ่มอิสระสองตัวที่มี การแจกแจงเลขชี้กำลังเหมือนกัน มักใช้ในการสร้างแบบจำลองปรากฏการณ์ที่มีหางหนักหรือเมื่อข้อมูลมีจุดสูงสุดที่สูงกว่าการแจกแจงแบบปรกติ การกระจายตัวนี้เป็นผลจากการแจกแจงแบบเลขชี้กำลัง 2 แบบ คือ แบบบวก

และแบบลบ บางครั้งเรียกว่าการแจกแจงแบบเลขชี้กำลังสองชั้น

$$(x|\mu,b) = \frac{1}{2b}\exp(-\frac{|x-\mu|}{b}) \; ; b > 0$$

เมื่อ μ แทน พารามิเตอร์ตำแหน่ง
b แทน พารามิเตอร์มารตราส่วน

2.5 แผนภูมิควบคุม (Control Charts)

แผนภูมิควบคุมที่ใช้ในงานวิจัยนี้มีแผนภูมิควบคุม Shewhart แผนภูมิควบคุม EWMA แผนภูมิควบคุม EEWMA แผนภูมิควบคุม NEEWMA และ แผนภูมิควบคุม NEEWMA-Tukey ซึ่งในงานวิจัยนี้ได้ศึกษาประสิทธิภาพในการตรวจจับค่าเฉลี่ยของกระบวนการของแผนภูมิควบคุม Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey ได้ดังนี้

2.5.1 แผนภูมิควบคุม Shewhart

เป็นหนึ่งในแผนภูมิควบคุมที่ใช้กันอย่างแพร่หลายในการตรวจสอบคุณภาพของกระบวนการทางสถิติ โดยใช้ข้อมูลจากกระบวนการผลิตหรือการดำเนินงานเพื่อตรวจจับการเปลี่ยนแปลงที่ผิดปกติ

ขีดจำกัดการควบคุมของแผนภูมิควบคุม Shewhart มีดังนี้

$$\mathrm{UCL/LCL} = \mu \pm K\sigma$$

เมื่อ μ แทน ค่าเฉลี่ยของกระบวนการ
K แทน ค่าคงที่ที่กำหนดเพื่อควบคุมขอบเขตของ UCL และ LCL
σ แทน ค่าเบี่ยงเบนมาตรฐานของกระบวนการ

2.5.2 แผนภูมิควบคุม EWMA

เป็นแผนภูมิที่ให้ความสำคัญกับข้อมูลในอดีตและปัจจุบันที่มีประสิทธิภาพในการตรวจจับค่าเฉลี่ยของกระบวนการที่มีขนาดได้ดีกว่าแผนภูมิควบคุมชิวฮาร์ท โดยมีค่าสถิติของแผนภูมิควบคุม EWMA ดังสมการที่ (1)

$$Z_i = \alpha_1 T_i + (1-\alpha_1)Z_{i-1}, i = 1,2,\ldots \quad (1)$$

เมื่อ T_i แทน ค่าของตัวแปรที่ถูกวัดในเวลาที่ i
α_1 แทน ค่าถ่วงน้ำหนักซึ่งมีช่วง $0 < \alpha_1 \leq 1$
Z_{i-1} แทน ค่าของตัวแปรที่คำนวณได้จากสมการ EWMA ในช่วงเวลาก่อนหน้า

ขีดจำกัดการควบคุมของแผนภูมิควบคุม EWMA มีดังนี้

$$\mathrm{UCL/LCL} = \mu \pm K\sigma\sqrt{\frac{\alpha}{2-\alpha}[1-(1-\alpha)^{2i}]}$$

เมื่อ μ แทน ค่าเฉลี่ยของกระบวนการ
K แทน ค่าคงที่ที่กำหนดเพื่อควบคุมขอบเขตของ UCL และ LCL
σ แทน ค่าเบี่ยงเบนมาตรฐานของกระบวนการ
α แทน ค่าถ่วงน้ำหนัก

2.5.3 แผนภูมิควบคุม EEWMA

เป็นแผนภูมิที่พัฒนาเพิ่มเติมจาก EWMA โดยมีการปรับปรุงเพื่อเพิ่มความไวต่อการเปลี่ยนแปลงของกระบวนการ หรือให้ความสำคัญกับข้อมูลในอดีตมากขึ้น มีลักษณะคล้ายกับ EWMA แต่มีการปรับค่าถ่วงน้ำหนักหรือเพิ่มพารามิเตอร์เพิ่มเติมดังสมการที่ (2)

$$Z_i = \alpha_1 T_i - \alpha_2 T_{i-1} + (1-\alpha_1+\alpha_2)Z_{i-1}, i = 1,2,\ldots \quad (2)$$

เมื่อ T_i แทน ค่าของตัวแปรที่ถูกวัดในเวลาที่ i
α_1, α_2 แทน ค่าถ่วงน้ำหนักซึ่งมีช่วง $0 < \alpha_1 \leq 1$, $0 \leq \alpha_2 < \alpha_1$
Z_{i-1} แทน ค่าของตัวแปรที่คำนวณได้จากสมการ EEWMA ในช่วงเวลาก่อนหน้า

ขีดจำกัดการควบคุมของแผนภูมิควบคุม EEWMA มีดังนี้

$$\mathrm{UCL/LCL} = \mu \pm K\sigma\sqrt{\mathrm{var}(Z_i)}$$

เมื่อ μ แทน ค่าเฉลี่ยของกระบวนการ
K แทน ค่าคงที่ที่กำหนดของขีดจำกัดการควบคุม
$\mathrm{var}(Z_i)$ แทน ความแปรปรวนของค่า Z_i

2.5.4 แผนภูมิควบคุม NEEWMA

เป็นแผนภูมิที่พัฒนาเพิ่มเติมจาก EWMA โดยใช้แนวคิดของการทำให้ข้อมูลอยู่ในรูปที่ถูกปรับมาตรฐาน (Normalized) เพื่อเพิ่มประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการ โดยเฉพาะในกรณีที่ข้อมูลมีการกระจายที่ไม่เป็นปรกติ หรือมีแนวโน้มที่เปลี่ยนแปลงแบบค่อยเป็นค่อยไปดังสมการที่ (3)

$$Z_i = \alpha_1 T_i - \alpha_2 T_{i-1} - \alpha_3 T_{i-2} + (1-\alpha_1+\alpha_2+\alpha_3)Z_{i-1}, i = 1,2,\ldots \quad (3)$$

เมื่อ T_i แทน ค่าของตัวแปรที่ถูกวัดในเวลาที่ *i*
$\alpha_1, \alpha_2, \alpha_3$ แทน ค่าถ่วงน้ำหนักซึ่งมีช่วง $0 < \alpha_1 \leq 1, 0 \leq \alpha_2 < \alpha_1, 0 \leq \alpha_3 < \alpha_2$
Z_{i-1} แทน ค่าของตัวแปรที่คำนวณได้จากสมการ NEEWMA ในช่วงเวลาก่อนหน้า

ขีดจำกัดการควบคุมของแผนภูมิควบคุม NEEWMA มี ดังนี้

$$\mathrm{UCL/LCL} = \mu \pm K\sigma\sqrt{\mathrm{var}(Z_i)}$$

เมื่อ μ แทน ค่าเฉลี่ยของกระบวนการ
K แทน ค่าคงที่ที่กำหนดของขีดจำกัดการควบคุม
$\mathrm{var}(Z_i)$ แทน ความแปรปรวนของค่า Z_i

2.5.5 แผนภูมิควบคุม NEEWMA-Tukey

เป็นแผนภูมิที่พัฒนาต่อจาก NEEWMA (Normalized EWMA) โดยใช้แนวคิดของ Tukey's transformation เพื่อช่วยปรับปรุงการตรวจจับความผิดปกติของกระบวนการที่มีการกระจายของข้อมูลไม่เป็นปรกติ หรือมีแนวโน้มที่เปลี่ยนแปลงแบบค่อยเป็นค่อยไปดังสมการที่ (4)

$$Z_i = \alpha_1 T'_i - \alpha_2 T'_{i-1} - \alpha_3 T'_{i-2} + (1-\alpha_1+\alpha_2+\alpha_3)Z_{i-1}, i = 1,2,\ldots \quad (4)$$

เมื่อ T_i แทน ค่าของตัวแปรที่ถูกวัดในเวลาที่ i
$\alpha_1, \alpha_2, \alpha_3$ แทน ค่าถ่วงน้ำหนัก
Z_{i-1} แทน ค่าของตัวแปรที่คำนวณได้จากสมการ NEEWMA ในช่วงเวลาก่อนหน้า

ขีดจำกัดการควบคุมของแผนภูมิควบคุม NEEWMA มีดังนี้

$$UCL = Q_3 + K(IQR)\sqrt{var(Z_i)}$$
$$LCL = Q_1 - K(IQR)\sqrt{var(Z_i)}$$

เมื่อ Q_1 แทน ควอไทล์ที่ 1 ของข้อมูล
Q_3 แทน ควอไทล์ที่ 3 ของข้อมูล
IQR แทน ผลต่างระหว่างควอไทล์ที่ 1 และ ควอไทล์ที่ 3
K แทน ค่าคงที่ที่กำหนดของขีดจำกัดการควบคุม
$var(Z_i)$ แทน ความแปรปรวนของค่า Z_i

2.6 เกณฑ์ที่ใช้ในการพิจารณาประสิทธิภาพ

เกณฑ์ในการวัดประสิทธิภาพของแผนภูมิควบคุม SHEWHART EWMA EEWMA NEEWMA และ NEEWMA-Tukey คือ ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) และ ส่วนเบี่ยงเบนมาตรฐานของความยาวรัน (Standard Deviation of Length: SDRL)

2.6.1 ค่าความยาวรันเฉลี่ย (Average Run Length: ARL)

ค่าความยาวรันเฉลี่ย (ARL) คือจำนวนค่าสังเกตที่ตกนอกขีดจำกัดควบคุมก่อนที่กระบวนการจะส่งสัญญาณการออกนอกขีดจำกัดควบคุมเป็นครั้งแรก สามารถแบ่งออกเป็น 2 กรณี คือ

1) ค่าความยาวรันเฉลี่ยเมื่อกระบวนการผลิตอยู่ภายใต้ควบคุม (in-control) สามารถเขียนสัญลักษณ์แทน ด้วย ARL_0

$$ARL_0 = \frac{1}{\alpha_0}$$

เมื่อ α_0 แทน ค่าความน่าจะเป็นของความผิดพลาดประเภทที่ 1 หมายถึง ค่าความน่าจะเป็นที่พบว่ากระบวนการออกนอก ขีดจำกัดควบคุม เมื่อกระบวนการไม่เกิดการเปลี่ยนแปลงของ ค่าเฉลี่ยในกระบวนการ

2) ค่าความยาวรันเฉลี่ยเมื่อกระบวนการผลิตไม่อยู่ภายใต้ควบคุม (out-of-control) สามารถเขียนสัญลักษณ์ แทนด้วย ARL_1

$$ARL_1 = \frac{1}{1-\alpha_1}$$

เมื่อ α_1 แทน ค่าความน่าจะเป็นของความผิดพลาดประเภทที่ 2 หมายถึง ค่าความน่าจะเป็นที่พบว่ากระบวนการอยู่ภายใต้การควบคุม เมื่อกระบวนการเกิดการเปลี่ยนแปลงของค่าเฉลี่ยในกระบวนการ

โดยงานวิจัยนี้ประมาณค่า ARL จากวิธีการจำลองแบบมอนติคาร์โล (Monte Carlo Simulation) ดังนั้นเกณฑ์ที่ใช้ในการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม คือ ค่า ARL

$$ARL = \frac{\sum_{i=1}^{M} RL_i}{M}$$

เมื่อ RL_i แทน จำนวนครั้งการสุ่มตัวอย่างก่อนที่จะพบว่ากระบวนการไม่อยู่ภายใต้การควบคุม
M แทน จำนวนรอบในการทำซ้ำและส่วนเบี่ยงเบนมาตรฐานของความยาวรัน (Standard Deviation of Length: SDRL)

$$SDRL = \sqrt{\frac{\sum_{i=1}^{M}(RL_i - ARL)^2}{M-1}}$$

เมื่อ RL_i แทน จำนวนครั้งการสุ่มตัวอย่างก่อนที่จะพบว่ากระบวนการไม่อยู่ภายใต้การควบคุม
M แทน จำนวนรอบในการทำซ้ำ

3. ผลการวิจัย

ในงานวิจัยนี้เปรียบเทียบประสิทธิภาพสำหรับตรวจจับค่าเฉลี่ยของกระบวนการระหว่างแผนภูมิควบคุม Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey ในการตรวจจับค่าเฉลี่ยของกระบวนการเกณฑ์ที่ใช้ในการวัดประสิทธิภาพ คือ ค่า ARL_1 ซึ่งหาได้จากวิธีการจำลองแบบมอนติคาร์โล เมื่อกำหนดค่าต่างๆ ได้แก่

1) กำหนดระดับการเปลี่ยนแปลงค่าเฉลี่ยกระบวนการ(δ) เท่ากับ 0.00, 0.01, 0.02, 0.05,0.08,0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0, 1.5, 2.0

2) กำหนดข้อมูลให้มีการแจกแจงปรกติ (Normal (0,1)) การแจกแจงแบบเลขชี้กำลัง (Exponential (1)) การแจกแจงแกมมา (Gamma (2,4)) และ การแจกแจงลาปลาซ (Laplace (1,1)) เนื่องจากการแจกแจงที่เลือกมานิยมใช้ในอุตสาหกรรม เช่น การแจกแจงปรกติมักเกิดกับค่าเฉลี่ยของลักษณะคุณภาพของผลิตภัณฑ์นั้น เช่น น้ำหนักเฉลี่ย ปริมาณเฉลี่ย หรือการแจกแจงที่มีลักษณะเบ้ขวาอย่างการแจกแจงแบบเลขชี้กำลังมักนิยมวัดคุณภาพของผลิตภัณฑ์จากอายุการใช้งานเฉลี่ยเป็นต้น

3) กำหนดค่า $ARL_0 = 370$

4) กำหนดขนาดตัวอย่างย่อย (n) เท่ากับ 5

5) กำหนดค่าพารามิเตอร์ปรับให้เรียบ $\alpha_1 = 0.2$, $\alpha_2 = 0.1$, $\alpha_3 = 0.05$

6) จำนวนรอบของการจำลองซ้ำ (M) เท่ากับ 10,000 รอบ

โดยการแจกแจงที่ใช้ในการศึกษางานวิจัยนี้มี 4 การแจกแจง โดยแสดงข้อมูลตารางดังต่อไปนี้

ตารางที่ 1 : ผลการจำลอง ARL และ SDRL กำหนดค่า $\mathrm{ARL}_0 = 370$ และค่าคงที่ปรับราบเรียบ $\alpha_1 = 0.2, \alpha_2 = 0.1$ และ $\alpha_3 = 0.05$ ภายใต้การแจกแจงปรกติ n = 5

Shift (δ)		SHEWHART	EWMA	EEWMA	NEEWMA	NEEWMA TUKEY
		$\alpha_1 = 1$	$\alpha_1 = 0.2$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$
		L_1 = 2.785	L_2 = 11.138	L_3 = 1.1712	L_4 = 1.1856	L_5 = -0.9693
0.00	ARL	370.3	370.77	370.25	370.23	370.3
	SDRL	370.3	411.14	369.21	371.16	370.84
0.01	ARL	348.23	342.71	304.87	298.92	311.5
	SDRL	348.23	380.24	306.12	299.21	306.26
0.02	ARL	324.52	315.26	251.70	242.39	262.32
	SDRL	324.52	349.55	261.85	238.49	256.15
0.05	ARL	192.07	244.66	148.75	140.02	162.61
	SDRL	266.42	283.01	142.19	129.4	155.7
0.08	ARL	102.2	194.72	94.59	88.84	109.18
	SDRL	217.25	227.72	86.12	78.47	100.54
0.10	ARL	68.78	165.49	72.09	57.28	85.92
	SDRL	58.6	197.00	64.74	192.07	76.11
0.20	ARL	32.94	72.93	26.85	27.45	35.68
	SDRL	102.2	95.19	20.61	19.5	26.75
0.30	ARL	19.8	33.77	14.13	15.29	19.97
	SDRL	57.28	48.14	9.48	9.86	13.38
0.40	ARL	12.39	15.48	9.09	9.90	13.11
	SDRL	32.94	24.24	5.53	6.14	8.29
0.50	ARL	7.89	7.91	6.43	6.90	9.34
	SDRL	19.8	12.71	3.67	4.34	5.85
0.60	ARL	5.21	4.39	4.79	5.00	6.92
	SDRL	12.39	6.84	2.67	3.28	4.35
0.70	ARL	3.52	2.79	3.74	3.78	5.29
	SDRL	7.89	3.69	2.08	2.53	3.44
0.80	ARL	2.44	2.01	2.98	2.88	4.16
	SDRL	5.21	2.18	1.69	2.02	2.73
0.90	ARL	0.42	1.61	2.41	2.23	3.28
	SDRL	3.52	1.37	1.44	1.65	2.26
1.00	ARL	0.05	1.37	1.97	1.76	2.63
	SDRL	2.44	0.95	1.24	1.38	1.89
1.50	ARL	0.00	1.02	0.71	0.54	0.97
	SDRL	0.42	0.16	0.69	0.63	0.87
2.00	ARL	0.00	1.00	0.19	0.12	0.35
	SDRL	0.05	0.02	0.39	0.33	0.52

ตารางที่ 2 : ผลการจำลอง ARL และ SDRL กำหนดค่า $\mathrm{ARL}_0 = 370$ และค่าคงที่ปรับราบเรียบ $\alpha_1 = 0.2, \alpha_2 = 0.1$ และ $\alpha_3 = 0.05$ ภายใต้การแจกแจงแบบเลขชี้กำลัง n = 5

Shift (δ)		SHEWHART	EWMA	EEWMA	NEEWMA	NEEWMA TUKEY
		$\alpha_1 = 1$	$\alpha_1 = 0.2$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$
		L_1 = 3.783	L_2 = 9.21	L_3 = 1.4295	L_4 = 1.559	L_5 = -0.5153
0.00	ARL	370.38	370.16	370.84	370.25	370.65
	SDRL	368.54	372.14	391.98	488.62	642.36
0.01	ARL	333.57	327.95	305.93	291.49	305.73
	SDRL	329.86	333.45	321.88	396.89	535.54
0.02	ARL	304.74	296.17	252.65	229.42	252.67
	SDRL	300.76	301.20	270.72	312.4	454.47
0.05	ARL	231.58	220.59	147.43	119.81	147.28
	SDRL	235.33	229.58	156.74	168.75	274.91
0.08	ARL	179.98	167.67	93.79	70.23	86.95
	SDRL	184.89	174.13	99.81	102.67	175.87
0.10	ARL	153.87	142.27	72.48	50.91	63.14
	SDRL	157.88	148.52	77.69	75.30	132.60
0.20	ARL	76.06	64.97	25.96	15.87	16.81
	SDRL	76.64	68.29	26.59	22.40	37.80
0.30	ARL	42.23	33.89	13.31	7.72	7.37
	SDRL	42.64	36.50	12.68	9.58	15.12
0.40	ARL	25.61	19.93	8.41	4.90	4.27
	SDRL	25.99	22.19	7.73	5.76	7.74
0.50	ARL	16.76	12.67	5.88	3.42	2.95
	SDRL	17.50	14.03	5.38	3.94	4.74
0.60	ARL	11.69	8.69	4.36	2.57	2.23
	SDRL	12.19	9.62	4.04	2.85	3.37
0.70	ARL	8.49	6.37	3.41	2.04	1.81
	SDRL	8.93	6.86	3.18	2.26	2.69
0.80	ARL	6.45	4.88	2.75	1.65	1.50
	SDRL	6.86	5.23	2.63	1.84	2.20
0.90	ARL	5.06	3.89	2.26	1.38	1.27
	SDRL	5.58	4.12	2.23	1.57	1.79
1.00	ARL	4.03	3.22	1.87	1.18	1.08
	SDRL	4.49	3.33	1.94	1.36	1.55
1.50	ARL	1.65	1.71	0.94	0.60	0.61
	SDRL	2.09	1.39	1.15	0.84	0.94
2.00	ARL	0.87	1.24	0.54	0.36	0.39
	SDRL	1.25	0.85	0.81	0.60	0.70

ตารางที่ 3 : ผลการจำลอง ARL และ SDRL กำหนดค่า $\mathrm{ARL}_0 = 370$ และค่าคงที่ปรับราบเรียบ $\alpha_1 = 0.2, \alpha_2 = 0.1$ และ $\alpha_3 = 0.05$ ภายใต้การแจกแจงลาปลาซ n = 5

Shift (δ)		SHEWHART	EWMA	EEWMA	NEEWMA	NEEWMA TUKEY
		$\alpha_1 = 1$	$\alpha_1 = 0.2$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$
		L_1 = 3.056	L_2 = 7.506	L_3 = 1.2278	L_4 = 1.302	L_5 = -0.688
0.00	ARL	370.84	370.22	370.66	370.12	370.92
	SDRL	372.39	379.79	376.67	457.98	370.92
0.01	ARL	358.67	354.27	325.95	317.59	323.64
	SDRL	360.29	364.68	334.14	398.47	323.64
0.02	ARL	346.01	340.46	287.71	273.19	285.11
	SDRL	348.13	351.16	295.78	346.77	285.11
0.05	ARL	309.99	300.04	200.12	176.66	195.55
	SDRL	311.17	308.92	204.72	230.29	195.55
0.08	ARL	280.56	263.87	143.57	119.74	135.45
	SDRL	283.52	273.08	146.35	157.11	135.45
0.10	ARL	262.12	241.38	116.49	91.91	107.57
	SDRL	266.31	252.95	117.77	120.56	107.57
0.20	ARL	184.97	156.53	46.68	31.89	38.50
	SDRL	186.83	161.93	44.99	40.71	38.50
0.30	ARL	131.97	102.04	23.86	15.24	18.18
	SDRL	134.06	107.32	21.10	18.15	18.18
0.40	ARL	93.81	65.21	14.49	8.96	10.41
	SDRL	93.87	70.21	11.89	9.79	10.41
0.50	ARL	66.25	43.30	9.81	5.97	6.73
	SDRL	67.39	47.82	7.43	6.02	6.73
0.60	ARL	47.51	28.14	7.09	4.27	4.72
	SDRL	48.23	31.86	5.15	4.13	4.72
0.70	ARL	34.54	18.81	5.43	3.19	3.45
	SDRL	35.41	21.95	3.78	3.01	3.45
0.80	ARL	25.3	12.74	4.29	2.46	2.60
	SDRL	25.64	15.34	2.94	2.26	2.60
0.90	ARL	18.26	8.69	3.47	1.94	1.99
	SDRL	18.61	10.69	2.37	1.76	1.99
1.00	ARL	13.69	6.06	2.86	1.57	1.57
	SDRL	14.22	7.62	1.95	1.42	1.57
1.50	ARL	3.28	1.61	1.17	0.61	0.61
	SDRL	3.75	1.36	0.99	0.68	0.61
2.00	ARL	0.83	1.08	0.46	0.22	0.19
	SDRL	1.21	0.34	0.62	0.43	0.19

ตารางที่ 4 : ผลการจำลอง ARL และ SDRL กำหนดค่า $\mathrm{ARL}_0 = 370$ และค่าคงที่ปรับราบเรียบ $\alpha_1 = 0.2, \alpha_2 = 0.1$ และ $\alpha_3 = 0.05$ ภายใต้การแจกแจงแกมมา n = 5

Shift (δ)		SHEWHART	EWMA	EEWMA	NEEWMA	NEEWMA TUKEY
		$\alpha_1 = 1$	$\alpha_1 = 0.2$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$	$\alpha_1 = 0.2$ $\alpha_2 = 0.1$ $\alpha_3 = 0.05$
		L_1= 3.489	L_2 = 8.509	L_3 = 1.361	L_4 = 1.546	L_5 = -6.027
0.00	ARL	370.51	370.16	370.04	370.16	370.62
	SDRL	365.05	374.14	396.56	631.55	769.49
0.01	ARL	358.77	356.64	343.37	338.32	339.53
	SDRL	355.16	361.15	368.54	585.08	721.96
0.02	ARL	346.92	344.49	320.38	304.47	311.26
	SDRL	341.62	347.17	345.82	532.33	669.45
0.05	ARL	317.77	310.98	258.82	137.87	243.91
	SDRL	315.23	313.28	280.02	412.14	532.05
0.08	ARL	289.58	277.87	210.41	58.32	189.38
	SDRL	287.92	277.91	231.98	315.97	432.22
0.10	ARL	272.25	259.26	185.04	28.80	161.63
	SDRL	271.52	260.13	203.29	267.22	382.94
0.20	ARL	203.88	186.09	98.95	15.93	76.33
	SDRL	201.16	189.98	110.64	124.57	193.89
0.30	ARL	156.04	135.51	60.20	10.04	38.74
	SDRL	156.77	141.17	68.24	63.25	106.60
0.40	ARL	119.03	101.55	38.75	6.98	21.64
	SDRL	117.58	107.41	43.87	34.99	62.14
0.50	ARL	93.18	77.67	26.97	5.25	12.90
	SDRL	93.84	82.68	29.99	20.85	36.60
0.60	ARL	74.70	60.44	19.68	4.15	8.55
	SDRL	75.95	64.39	21.86	13.13	23.65
0.70	ARL	60.42	47.54	14.85	3.44	5.95
	SDRL	61.61	51.20	16.45	9.46	15.86
0.80	ARL	49.21	37.71	11.84	2.90	4.51
	SDRL	50.43	40.84	12.75	6.86	10.93
0.90	ARL	40.41	30.69	9.66	1.59	3.65
	SDRL	41.3	33.70	10.35	5.26	8.21
1.00	ARL	33.74	24.99	8.012	1.04	2.97
	SDRL	34.75	27.60	8.38	4.20	6.37
1.50	ARL	15.24	10.71	3.93	0.74	1.58
	SDRL	15.62	12.12	3.96	1.94	2.49
2.00	ARL	8.10	5.59	2.38	0.54	1.05
	SDRL	8.64	6.15	2.45	1.25	1.49

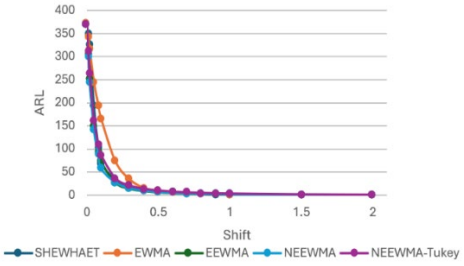

ภาพที่ 1: การเปรียบเทียบค่า ARL ของแผนภูมิ Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey เมื่อกำหนดค่า $ARL_0 = 370$ ภายใต้การแจกแจงปรกติ

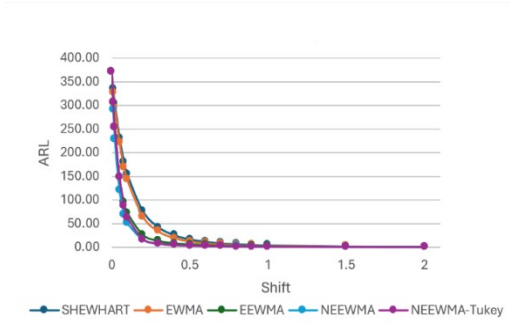

ภาพที่ 2: การเปรียบเทียบค่า ARL ของแผนภูมิ Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey เมื่อกำหนดค่า $ARL_0 = 370$ ภายใต้การแจกแจงแบบเลขชี้กำลัง

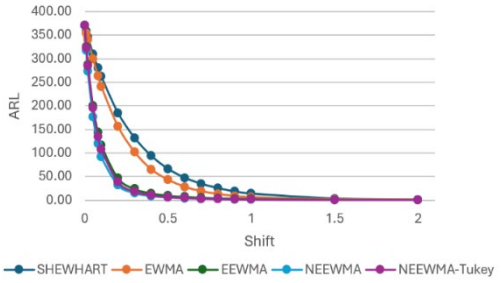

ภาพที่ 3: การเปรียบเทียบค่า ARL ของแผนภูมิ Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey เมื่อกำหนด $ARL_0 = 370$ ภายใต้การแจกแจงลาปลาซ

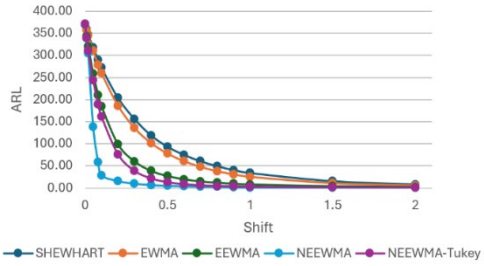

ภาพที่ 4: การเปรียบเทียบค่า ARL ของแผนภูมิ Shewhart EWMA EEWMA NEEWMA และNEEWMA-Tukey เมื่อกำหนดค่า $ARL_0 = 370$ ภายใต้การแจกแจงแกมมา

4. การประยุกต์ใช้กับข้อมูลจริง

ในการศึกษานี้ เราได้เปรียบเทียบแผนภูมิควบคุม Shewhart EWMA EEWMA NEEWMA และ NEEWMA-Tukey

4.1 การประยุกต์ตัวอย่างข้อมูล 1 ภายใต้การแจกแจงแบบเลขชี้กำลัง

การติดเชื้อทางเดินปัสสาวะ (Urinary Tract Infection: UTI) จากโรงพยาบาลขนาดใหญ่ จาก Santiago และ Smith โรงพยาบาลต้องการติดตามความถี่ของผู้ป่วยที่ติดเชื้อ (UTI) ระหว่างพักรักษาตัว และถูกปล่อยตัวออกจากโรงพยาบาล เพื่อให้สามารถระบุการเพิ่มขึ้นของอัตราการติดเชื้อได้อย่างรวดเร็ว หรือในทางตรงกันข้าม เพื่อตรวจสอบว่าการเปลี่ยนแปลงกระบวนการทำงานหรือวัสดุทางการแพทย์ในอนาคต ช่วยลดจำนวนการติดเชื้อได้หรือไม่ เนื่องจากสาเหตุของการติดเชื้ออาจแตกต่างกันตามเพศผู้ป่วยชาย และหญิงจึงถูกบันทึกข้อมูลแยกกัน และตัวอย่างนี้จะเน้นเฉพาะผู้ป่วยชายเท่านั้น

4.2 การประยุกต์ตัวอย่างข้อมูล 2 ภายใต้การแจกแจงแบบเลขชี้กำลัง

ความแข็งแรงของกระจกของหน้าต่างเครื่องบิน จาก Fuller และคณะ (1994)

ตารางที่ 4 : ผลการจำลองเวลาการตรวจพบผู้ป่วย UTI (เป็นวัน) โดย Santiago และ Smith

เวลาการตรวจพบผู้ป่วย UTI (เป็นวัน)					
กลุ่มที่	S1	S2	S3	S4	S5
1	0.5701	0.1201	0.2708	0.0743	0.1146
2	0.0451	0.1528	0.0035	0.1354	0.1458
3	0.1201	0.0868	0.1389	0.0486	0.4035
4	0.1493	0.0278	0.1264	0.0333	0.3264
5	0.1840	0.0868	0.6493	0.7083	0.3368
6	0.1493	0.1563	0.0382	0.0139	0.2465
7	0.2465	0.0382	0.0451	0.2951	0.4681
8	0.0174	0.1194	0.2222	1.0889	0.0521
9	0.2951	0.0521	0.1250	0.5347	0.0278
10	0.2500	0.1514	0.0347	0.4007	0.5257
11	0.915	0.4000	0.5278	0.5564	0.0176
12	0.0303	0.0357	0.0639	0.0683	0.1592
13	0.0163	0.0809	0.4184	0.3958	0.0169
14	0.2104	0.0145	0.1838	0.0142	0.0476
15	0.026	0.2783	0.2573	0.3699	0.0518
16	0.5142	0.0427	0.158	0.2087	0.2083
17	0.3030	0.9034	0.1943	0.0949	0.1125
18	0.0669	0.1250	0.0623	0.1921	0.2700
19	0.1106	0.0022	0.0428	0.4600	0.1184
20	0.0832	0.0541	0.0731	0.335	0.0176
21	0.0225	0.1265	0.1966	0.4685	0.3074
22	0.1593	0.6465	0.3514	0.3528	0.0455
23	0.4802	0.3542	0.4003	0.7534	0.5325
24	0.2111	0.4592	0.0009	0.1198	0.0063
25	0.1286	0.1514	0.1186	0.1700	0.3708
26	0.0294	0.0891	0.0643	0.0527	0.2593
27	0.2699	0.1256	0.0736	0.0397	0.0694
28	0.0771	0.9431	0.2200	0.0344	0.2857
29	0.1024	0.0982	0.0343	0.2309	0.1116
30	0.4053	0.0498	0.4142	0.0128	0.5023

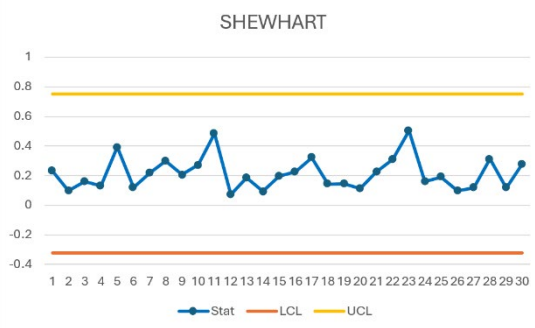

ภาพที่ 5: ประสิทธิภาพของแผนภูมิควบคุม Shewhart ของการติดเชื้อทางเดินปัสสาวะ (UTI)

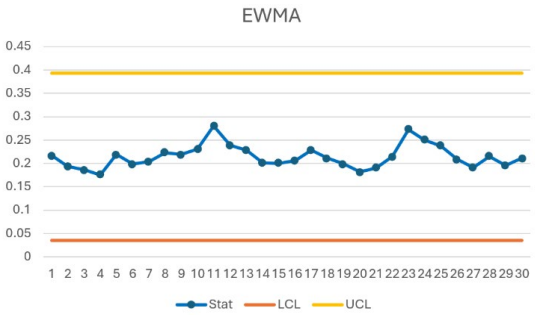

ภาพที่ 6: ประสิทธิภาพของแผนภูมิควบคุม EWMA ของการติดเชื้อทางเดินปัสสาวะ (UTI)

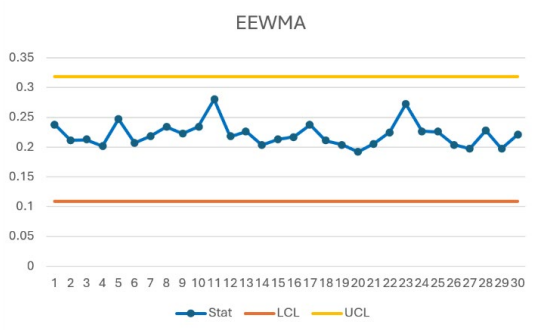

ภาพที่ 7: ประสิทธิภาพของแผนภูมิควบคุม EEWMA ของการติดเชื้อทางเดินปัสสาวะ (UTI)

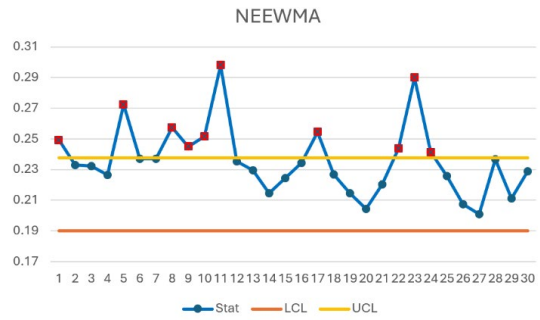

ภาพที่ 8: ประสิทธิภาพของแผนภูมิควบคุม NEEWMA ของการติดเชื้อทางเดินปัสสาวะ (UTI)

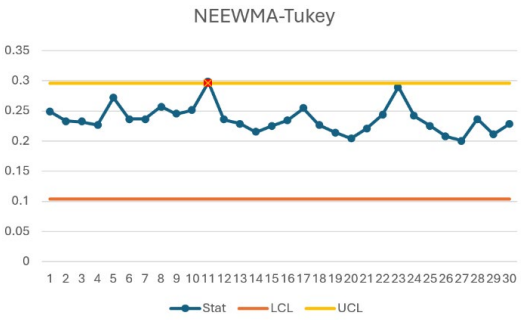

ภาพที่ 9: ประสิทธิภาพของแผนภูมิควบคุม NEEWMA-Tukey ของการติดเชื้อทางเดินปัสสาวะ (UTI)

ตารางที่ 5 : ข้อมูลเกี่ยวกับความแข็งแรงของกระจกหน้าต่างของเครื่องบิน ซึ่งถูกรายงานโดย Fuller และคณะ (1994)

ความแข็งแรงของกระจกหน้าต่างของเครื่องบิน (MPa)					
18.83	20.8	21.657	23.03	23.23	24.05
24.321	25.5	25.52	25.8	26.69	26.77
26.78	27.05	27.67	29.9	31.11	33.2
33.73	33.76	33.89	34.76	35.75	35.91
36.98	37.08	37.09	39.58	44.045	45.29
45.381					

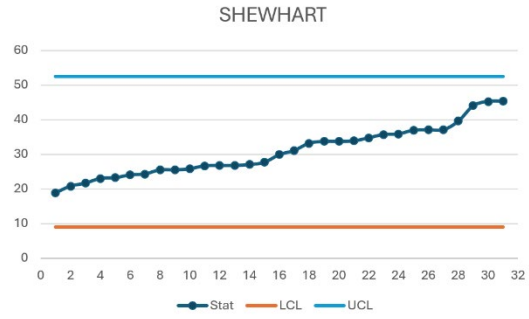

ภาพที่ 10: ประสิทธิภาพของแผนภูมิควบคุม Shewhart ของความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa)

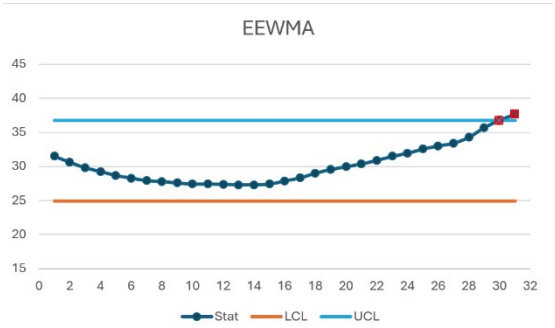

ภาพที่ 12: ประสิทธิภาพของแผนภูมิควบคุม EEWMA ของความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa)

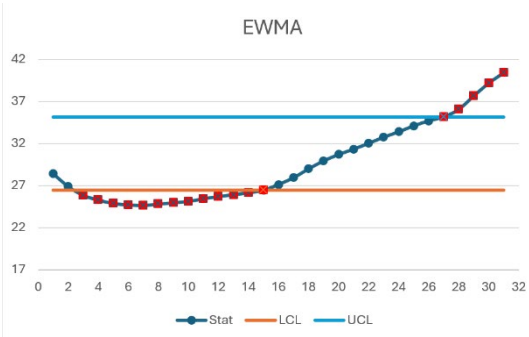

ภาพที่ 11: ประสิทธิภาพของแผนภูมิควบคุม EWMA ของความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa)

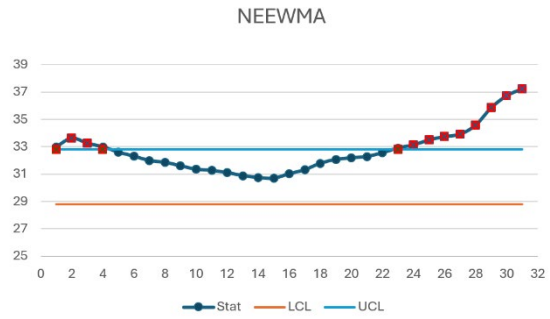

ภาพที่ 13: ประสิทธิภาพของแผนภูมิควบคุม NEEWMA ของความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa)

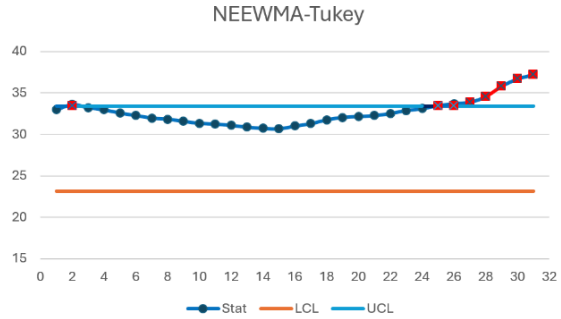

ภาพที่ 14: ประสิทธิภาพของแผนภูมิควบคุม NEEWMA-Tukey ของความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa)

5. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์ เพื่อเปรียบเทียบประสิทธิภาพสำหรับตรวจจับค่าเฉลี่ยของกระบวนการระหว่างแผนภูมิควบคุม Shewhart EWMA EEWMA NEEWMA และเสนอแผนภูมิควบคุมแบบไม่อิงพารามิเตอร์ NEEWMA-Tukey สำหรับการตรวจจับค่าเฉลี่ยของกระบวนการเกณฑ์ที่ใช้ในการวัดประสิทธิภาพ คือ ค่า ARL_1 ซึ่งหาได้จากวิธีการจำลองแบบมอนติคาร์โล เมื่อกำหนดค่าเป้าหมาย (ARL_0) เป็น 370 พบว่าแผนภูมิควบคุม NEEWMA และ NEEWMA-Tukey มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงดีกว่าแผนภูมิควบคุมอื่นๆ เมื่อกระบวนการมีการแจกแจงแบบเลขชี้กำลัง การแจกแจงแกมมาและการแจกแจงลาปลาซ สำหรับกระบวนการที่มีการแจกแจงปรกติ แผนภูมิ NEEWMA สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดี เมื่อ δ น้อยกว่า 0.1 เมื่อค่า δ เพิ่มมากขึ้น แผนภูมิควบคุม SHEWHART EWMA EEWMA และ NEEWMA-Tukey จะมีประสิทธิภาพเพิ่มขึ้นตามลำดับ และเมื่อค่า ARL_0 มากขึ้นประสิทธิภาพของแผนภูมิ NEEWMA สามารถตรวจจับได้ทุกขนาดการเปลี่ยนแปลง จากการใช้แผนภูมิควบคุมที่เสนอกับข้อมูลการติดเชื้อทางเดินทางเดินปัสสาวะ (UTI) และ ความแข็งแรงของกระจกหน้าต่างเครื่องบิน (MPa) พบว่าแผนภูมิควบคุม NEEWMA มีประสิทธิภาพในการตรวจจับที่ดีที่สุด

6. กิตติกรรมประกาศ

การศึกษาค้นคว้าครั้งนี้สามารถสำเร็จลุล่วงได้ด้วยความอนุเคราะห์และความช่วยเหลือจากศาสตราจารย์ ดร. เสาวณิต สุขภารังษี อาจารย์ที่ปรึกษาโครงงานพิเศษที่กรุณา ช่วยเหลือให้คำปรึกษาและแนะนำตลอดจนการตรวจทาน และแก้ไขข้อบกพร่องต่าง ๆ เป็นอย่างดีมาตลอด จนกระทั่ง โครงงานพิเศษฉบับนี้เสร็จสมบูรณ์ คณะผู้วิจัยขอขอบพระคุณคณาจารย์ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือทุกท่านที่ ประสิทธิ์ประสาทวิชาความรู้แก่คณะผู้วิจัยให้ได้ความรู้ ประสบการณ์ทางด้านสถิติอันเป็นประโยชน์ต่อผู้วิจัยจนสำเร็จการศึกษา

7. เอกสารอ้างอิง

[1] Javed H, Ismail M, Saeed N. New extended exponentially weighted moving average control chart for monitoring process mean. Heliyon10 2024,e34424

[2] Fuller EJ, Frieman S, Quinn J. Fracture mechanics approach to the design of glass aircraft windows: A case study. SPIE Proceedings. 1994:419–430

[3] Santiago, E., & Smith, J. 2013. Control charts based on the exponential distribution: Adapting runs rules for the t-chart. Quality Engineering, 25(2), 85–96.

[4] Shanker R, Fesshaye H, Selvaraj S. On modeling of lifetimes data using exponential and lindley distributions. Biom Biostat Int J. 2015;2(5):140–147. DOI: 10.15406/bbij.2015.02.00042

[5] Suganya Phantu,Saowanit Sukparungsee. A Mixed Double Exponentially Weighted Moving Average - Tukey's Control Chart for Monitoring of Parameter Change. Thailand Statistician, 2020; 18(4): 392-402

[6] Khan N, Aslamb M, Jun CH . A EWMAControl Chart for Exponential Distributed Quality Based on Moving Average Statistics. Qual. Reliab. Engng. Int. 2016, 32 1179–119

การประมาณค่าความยาวรันเฉลี่ยของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลังสำหรับตัวแบบอนุกรมเวลาที่มีฤดูกาลจากวิธีสมการปริพันธ์เชิงตัวเลข

An Approximation to the Average Run Length of an EWMA Control Chart for a Time Series Model with Seasonality from the Numerical Integral Equation

รัตนชาติ กุณฑล* วิลาสินี ปีระจิตร

ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* *ohmtwo@gmail.com*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาวิธีการประมาณค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยใช้เทคนิคสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE) จาก 4 วิธี คือ วิธีกฎค่ากลาง (Midpoint Rule Method) วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) วิธีกฎของเกาส์ (Gaussian Rule Method) และวิธีกฎของซิมป์สัน (Simpson's Rule Method) บนแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (Exponentially Weighted Moving Average Control Chart: EWMA) สำหรับตัวแบบอนุกรมเวลาที่มีฤดูกาล โดยงานวิจัยนี้มุ่งเน้นศึกษาตัวแบบอนุกรมเวลาในสถานการณ์จริงภายใต้ตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ เมื่อความคลาดเคลื่อนขาวแบบเลขชี้กำลัง สำหรับเกณฑ์การประเมินประสิทธิภาพของแผนภูมิควบคุม EWMA พิจารณาจากค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (out-of-control ARL: ARL_1) และเวลาที่ใช้ในการประมวลผล (CPU Times) ผลการวิจัยพบว่า ค่า ARL_1 จากเทคนิคสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี มีค่าลดลงอย่างรวดเร็วเมื่อการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการมีขนาดเล็ก $(0.01 \le \delta < 0.5)$ และให้ค่า ARL_1 ไม่แตกต่างกันในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ ที่ศึกษา หากพิจารณาเวลาในการประมวลผลค่า ARL_1 พบว่า ในภาพรวมวิธีกฎของค่ากลางใช้เวลาในการประมวลผลน้อยสุด โดยมีเวลาในการประมวลผลใกล้เคียงกับวิธีกฎสี่เหลี่ยมคางหมู และใช้เวลาในประมวลผลเร็วกว่าอย่างเห็นได้ชัดเจนเมื่อเทียบกับวิธีกฎของเกาส์ และวิธีกฎของซิมป์สัน ตามลำดับ ในทุกระดับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ ดังนั้นวิธีกฎของค่ากลางจึงเป็นวิธีเหมาะสมสำหรับการประเมินประสิทธิภาพของแผนภูมิควบคุม EWMA ในสถานการณ์นี้ และสามารถนำไปประยุกต์ใช้กับข้อมูลจริงได้

คำสำคัญ: แผนภูมิควบคุม EWMA, ค่าความยาวรันเฉลี่ย, ตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12,}$ ความคลาดเคลื่อนขาวแบบเลขชี้กำลัง

Abstract

This research aims to study the estimation of Average Run Length (ARL) using Numerical Integral Equation (NIE) techniques through four methods: the Midpoint Rule Method, the Trapezoidal Rule Method, the Gaussian Rule Method, and Simpson's Rule Method. The study is conducted on the Exponentially Weighted Moving Average (EWMA) control chart for seasonal time series models. Specifically, this research focuses on the SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ process with exponential white noise. The performance evaluation criteria for the EWMA control chart include the Average Run Length when the process is out-of-control (ARL_1) and the CPU processing time. The results reveal that ARL_1 values estimated by all four NIE techniques decrease rapidly when the process mean shifts slightly and that the ARL_1 values do not significantly differ across the SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ models studied. Regarding processing time, the Midpoint Rule Method consistently requires the least CPU time, with similar processing times to the Trapezoidal Rule Method, and significantly faster than the Gaussian and Simpson's Rule Methods across all levels of process mean shift. Therefore, the Midpoint Rule Method is considered the most appropriate for evaluating the performance of the EWMA control chart in this context and can be effectively applied to real-world data.

Keywords: EWMA Control Chart, Average Run Length, SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ Process, Exponential White Noise

1. บทนำ

ในกระบวนการผลิตทางอุสาหกรรม สามารถเกิดความผันแปรของกระบวนการได้สม่ำเสมอ ความผันแปรต่าง ๆ เกิดขึ้นได้จากหลายปัจจัย ซึ่งความผันแปรเหล่านั้นจะส่งผลต่อคุณภาพของผลิตภัณฑ์ เพื่อเป็นการควบคุมคุณภาพของกระบวนการผลิตให้สม่ำเสมอ จึงมีแนวคิดเกี่ยวกับการควบคุมคุณภาพของผลิตภัณฑ์ขึ้น เพื่อให้กระบวนการผลิตอยู่ในระดับมาตรฐาน โดยการเตือนให้ผู้ผลิตทราบว่ากระบวนการผลิตได้เปลี่ยนแปลงไปจากเกณฑ์ที่กำหนด เพื่อป้องกันไม่ให้มีข้อบกพร่องหรือเสียหายจากกระบวนการผลิต

การควบคุมกระบวนการเชิงสถิติ (Statistical Process Control: SPC) คือการนำวิธีการทางสถิติมาใช้ในการตรวจสอบและควบคุมคุณภาพของกระบวนการผลิต ซึ่งจะช่วยให้มั่นใจได้ว่ากระบวนการทำงานอย่างมีประสิทธิภาพ ซึ่งเครื่องมือในการควบคุมกระบวนการเชิงสถิติมีหลากหลายวิธี เช่น แผ่นตรวจสอบ (Check Sheet) ฮิสโทรแกรม (Histogram) แผนภาพพาเรโต (Pareto Diagram) แผนภาพก้างปลา (Fishbone Diagram) และเครื่องมือที่ได้รับความนิยมและมีประสิทธิภาพ คือแผนภูมิควบคุม (Control Chart) ซึ่งแผนภูมิควบคุม จึงเป็นเครื่องมือที่จะช่วยในการวิเคราะห์และตรวจสอบความผิดปกติของกระบวนการผลิตนำไปสู่การปรับปรุงกระบวนการอย่างต่อเนื่อง

ในปี ค.ศ.1931 Shewhart [1] ได้คิดค้นแผนภูมิควบคุมขึ้นเป็นครั้งแรก เรียกว่า แผนภูมิควบคุมชิวฮาร์ท (Shewhart Control Chart) เป็นแผนภูมิใช้งานง่ายและมีประสิทธิภาพมากในการตรวจจับการเปลี่ยนแปลงขนาดใหญ่ของค่าเฉลี่ยหรือความผันแปรของกระบวนการ และตั้งแต่นั้นเป็นต้นมาก็ได้มีแผนภูมิควบคุมประเภทอื่น ๆ อีกมากมายได้รับการพัฒนา แต่เนื่องจากแผนภูมิควบคุมชิวฮาร์ททำงานได้ไม่ดีนักสำหรับการเปลี่ยนแปลงที่มีขนาดเล็กน้อยถึงปานกลาง ในปี ค.ศ. 1954 Page [2] จึงได้เสนอแผนภูมิควบคุมผลรวมสะสม (Cumulative Sum Control Chart : CUSUM) และต่อมา ในปี ค.ศ.1959 Roberts [3] ได้เสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average : EWMA) ทั้งสองแผนภูมิควบคุมนี้เป็นแผนควบคุมที่เหมาะสมกับข้อมูลประเภทความจำโดยจะนำข้อมูลที่เก็บมาตั้งแต่ในอดีตจนถึงปัจจุบันมาใช้ในการคำนวณ แม้ทั้งสองแผนภูมิควบคุมนี้ใช้งานได้ดีแต่แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังได้รับความนิยมมากกว่าเนื่องจากเป็นแผนภูมิควบคุมที่นำไปใช้งานง่ายกว่า

ตัวแบบอนุกรมเวลา ARFIMA (Autoregressive Fractionally Integrated Moving Average) หรือ ARFIMA$(p, d, q)(P, D, Q)_s$ และตัวแบบอนุกรมเวลา SARFIMA (Seasonal Autoregressive Fractionally Integrated Moving Average) หรือ SARFIMA$(p, d, q)(P, D, Q)_s$ เป็นตัวแบบอนุกรมเวลาที่มีฤดูกาล โดยมีพารามิเตอร์ผลต่างเชิงเศษส่วน (Fractional Differencing Parameter) d และพารามิเตอร์การต่างเชิงเศษส่วนแบบฤดูกาล (Seasonal Fractional Differencing Parameter) D ตามลำดับ ตัวแบบ SARFIMA เป็นการพัฒนามาจากตัวแบบ ARFIMA และมักถูกใช้ในการจำลองกระบวนการที่มีความทรงจำยาวนาน (Long-Memory Process) โดยกระบวนการเหล่านี้ถูกเสนอขึ้นโดย Granger และ Joyeux (1980) [4] นอกจากนี้ Hosking (1981) [5] ได้อภิปรายเกี่ยวกับคุณสมบัติที่เป็นประโยชน์ของกระบวนการเหล่านี้อย่างกว้างขวาง เช่น ฤดูกาลคงที่ (Stationarity), คุณสมบัติผกผัน (Invertibility), และฟังก์ชันสหสัมพันธ์ (Autocorrelation Function) ในแง่ของฤดูกาล (Seasonality) ในอนุกรมเวลา โดยฤดูกาลหมายถึงปรากฏการณ์ที่เกิดขึ้นเป็นประจำทุกปี เช่น ข้อมูลรายเดือน รายไตรมาส เป็นต้น การมีอยู่ของทั้ง หน่วยความจำระยะยาว (Long-Memory หรือ Long-Range Dependence) และฤดูกาล (Seasonality) ในข้อมูลจริงจากหลายสาขา เช่น ธุรกิจ เศรษฐศาสตร์ ฟิสิกส์ และอุทกวิทยา ได้รับความสนใจเป็นอย่างมากในวรรณกรรมทางวิชาการ ตัวอย่างของการนำไปประยุกต์ใช้กับข้อมูลจริง ได้แก่ อัตราการว่างงานรายเดือนของผู้ชายในสหรัฐฯ (Carlin และ Dempster, 1989) [6], รายได้จากผลิตภัณฑ์ของ IBM รายเดือน (Ray, 1993) [7], พยากรณ์โรคติดเชื้อโดยเฉพาะโรค HFRS (Qi, Zhang, Zhu, Liu, Chunyu Li, Wang และ Xiujun Li, 2020) [8], พยากรณ์อุณหภูมิ ในรัฐโอกุน ประเทศไนจีเรีย (Adewole และ Amurawaye, 2024) [9], พยากรณ์ข้อมูลรังสีดวงอาทิตย์ (UDO M. E. และ Shittu O. I, 2022) [10] และคาดการณ์ราคาพริก (Devianto, Wahyuni, Maiyastri and Yollan, 2024) [11] เป็นต้น โดยในงานวิจัยนี้จึงทำการศึกษาตัวแบบอนุกรมเวลาในสถานการณ์จริงภายใต้กระบวนการ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$

ค่าความคลาดเคลื่อนขาว (White Noise) คือความแตกต่างระหว่างค่าจริงกับค่าประมาณซึ่งจะเกิดความแม่นยำสูงเมื่อค่าความคลาดเคลื่อนขาวขนาดเล็ก ซึ่งโดยทั่วไปมีการแจกแจงแบบปกติและเกิดจากการสังเกตที่มีความสัมพันธ์ในตัว (Autocorrelation) อย่างไรก็ตาม บางครั้งความคลาดเคลื่อนขาวในข้อมูลที่มีความสัมพันธ์ในตัว ไม่มีแจกแจงแบบปกติ ทำให้แบบจำลองอนุกรมเวลาที่มีค่าความคลาดเคลื่อนขาวแจกแจงแบบเลขชี้กำลัง (Exponential White Noise) เป็นหัวข้อที่น่าสนใจ โดยเฉพาะในกรณีของความเร็วลม ปริมาณออกซิเจนละลายในแม่น้ำ และอัตราการไหลของแม่น้ำในแต่ละวัน ตัวอย่างเช่น Jacob และ Lewis (1977) [12] ได้ศึกษากระบวนการ ARMA(1,1) ที่มีค่าความคลาดเคลื่อนขาวแจกแจงแบบเลขชี้กำลัง ต่อมา Mohamed และ Hocine (2003) [13] ได้ทำการวิเคราะห์แบบเบย์ (Bayesian Analysis) สำหรับ AR(1) ที่มีค่าความคลาดเคลื่อนขาวแจกแจงแบบเลขชี้กำลัง ต่อมา Peerajit (2023) [14] ได้ทำการประมาณค่า ARL ของตัวแบบ SARFIMA$(p, d, q)(P, D, Q)_s$ ที่มีค่าความคลาดเคลื่อนขาวแจกแจงแบบเลขชี้กำลังบนแผนภูมิควบคุม CUSUM

การวัดประสิทธิภาพของแผนภูมิควบคุม ได้โดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยพิจารณาจาก 2 สถานะ คือ กระบวนการอยู่ภายใต้การควบคุม (In-control ARL: ARL_0) และกระบวนการไม่อยู่ภายใต้การควบคุม (Out-of-control ARL: ARL_1) โดยค่าความยาวรัน

เฉลี่ยสามารถคำนวณได้หลายวิธีเช่น การจำลองมอนติคาร์โล (Monte Carlo Simulations) หรือ วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation) เป็นต้น โดยในในงานวิจัยนี้จะใช้วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation Method: NIE) (Champ and Rigdon, 1991) [15] วิธีนี้จะใช้คณิตศาสตร์ขั้นสูงในการประมาณค่า ARL โดยมี 4 วิธี คือ วิธีการประมาณแบบเกาส์ (Gauss Quadrature) วิธีกฎของค่ากลาง (Midpoint Rule Method) วิธีกฎของสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) และ วิธีกฎของซิมป์สัน (Simpson's Rule Method)

จากที่กล่าวมาข้างต้น งานวิจัยครั้งนี้เสนอวิธีการประมาณค่าความยาวรันเฉลี่ยโดยใช้เทคนิคสมการปริพันธ์เชิงตัวเลขจาก 4 วิธี คือ วิธีกฎค่ากลาง (Midpoint Rule Method) วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method) วิธีกฎของเกาส์ (Gaussian Rule Method) และวิธีกฎของซิมป์สัน (Simpson's Rule Method) บนแผนภูมิ EWMA สำหรับตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ เมื่อความคลาดเคลื่อนขาวมีการแจกแจงแบบเลขชี้กำลัง

2. วิธีการวิจัย

2.1 แผนภูมิควบคุมควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average Control Chart: EWMA)

Roberts [3] เสนอแผนภูมิควบคุมควบคุม EWMA ซึ่งเป็นแผนภูมิที่ให้ความสำคัญกับข้อมูลในอดีตและปัจจุบันที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของกระบวนการผลิตที่มีขนาดเล็ก ซึ่งค่าสถิติของแผนภูมิควบคุม EWMA แสดงดังสมการที่ (1) ดังนี้

$$Z_t = (1-\lambda)Z_{t-1} + \lambda X_t \ ; \ t = 1, 2, ... \qquad (1)$$

โดยที่ Z_t แทน ค่าสถิติของแผนภูมิควบคุม EWMA ณ คาบเวลาที่ t

X_t แทน ค่าสังเกต ณ คาบเวลาที่ t

λ แทน ค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม EWMA โดยที่ $0 < \lambda \leq 1$

ขีดจำกัดควบคุมบน (Upper Control Limit: UCL) เส้นกึ่งกลาง (Control Limit: CL) และขีดจำกัดควบคุมล่าง (Lower Control Limit: LCL) ของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง แสดงดังสมการที่ (2) ตามลำดับ

$$UCL = \mu_0 + L\sigma\sqrt{\frac{\lambda}{2-\lambda}} = b$$

$$CL = \mu_0 \qquad (2)$$

$$LCL = \mu_0 - L\sigma\sqrt{\frac{\lambda}{2-\lambda}} = 0$$

โดยที่ μ_0 คือ ค่าเฉลี่ยของกระบวนการที่อยู่ภายใต้การควบคุม

L คือ ค่าพารามิเตอร์ของขีดจำกัดควบคุมของแผนภูมิควบคุม EWMA

σ คือ ส่วนเบี่ยงเบนมาตรฐาน

λ คือ ค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม EWMA โดยที่ $0 < \lambda \leq 1$

2.2 ตัวแบบ SARFIMA

ตัวแบบ Seasonal Autoregressive Fractionally Integrated Moving Average (SARFIMA) อันดับที่ p, d, q, P, D, Q เรียกโดยย่อว่า ตัวแบบ SARFIMA$(p, d, q)(P, D, Q)_s$ ในกรณีที่ความคลาดเคลื่อนขาวแบบเลขชี้กำลัง ได้ตัวแบบ SARFIMA $(p, d, q)(P, D, Q)_s$ แสดงดังสมการที่ (3) ดังนี้

$$X_t(1-B^S)^D(1-B)^d(1-\phi_1 B - \ldots - \phi_p B^p)(1-\Phi_1 B^S - \ldots - \Phi_P B^{PS})$$
$$= \mu + (1-\theta_1 B - \ldots - \theta_q B^q)(1-\Theta_1 B^S - \ldots - \Theta_Q B^{QS})\varepsilon_t \quad (3)$$

โดยที่ X_t แทน ค่าสังเกต ณ เวลา t

s แทน คาบเวลาของฤดูกาล (Seasonal Periodicity)

d แทน พารามิเตอร์ของการทำส่วนต่างแบบเศษส่วน $(-0.5 < d < 0.5)$

D แทน พารามิเตอร์ของการทำส่วนต่างแบบเศษส่วนตามฤดูกาล $(-0.5 < D < 0.5)$

μ แทน พารามิเตอร์เริ่มต้นของกระบวนการ $(\mu = 0)$

ϕ_i แทน พารามิเตอร์ของการถดถอยในตัวที่ $i, i = 1, 2, ..., p, -1 < \phi_i < 1$

Φ_i แทน พารามิเตอร์ของการถดถอยในตัวเป็นส่วนของฤดูกาลที่ $i, i = 1, 2, ..., P, -1 < \Phi_i < 1$

θ_i แทน พารามิเตอร์ของการเฉลี่ยเคลื่อนที่ $i, \ i = 1, 2, ..., q, \ -1 < \theta_i < 1$

Θ_i แทน พารามิเตอร์ของการเฉลี่ยเคลื่อนที่เป็นส่วนของฤดูกาลที่ $i, \ i = 1, 2, ..., Q, \ -1 < \Theta_i < 1$

$(1-B)^d$ แทน ตัวดำเนินการผลต่างเศษส่วน (Fractional Difference Opereter) อันดับที่ d

$(1-B^s)^D$ แทน ตัวดำเนินการผลต่างเศษส่วนที่มีฤดูกาล (seasonal Fractional Difference Opereter) อันดับที่ D

B แทน ตัวดำเนินการย้อนกลับ (Backward Shift Operator) โดยที่ $B^S Y_t = Y_{t-S}$

ε_t แทน ค่าความคลาดเคลื่อน ณ เวลาที่ t ภายใต้ข้อสมมุติว่าความคลาดเคลื่อน ณ เวลาต่างๆ เป็นตัวแปรสุ่มที่เป็นอิสระกัน โดยมีการแจกแจงแบบเลขชี้กำลังซึ่งมีค่าเฉลี่ยคือ β

จากตัวดำเนินการผลต่างเศษส่วน $(1-B)^d$ และ $(1-B^s)^D$ จากสมการที่ (3) สามารถจัดรูปได้ดังสมการที่ (4) ได้ดังนี้

$$(1-B)^d = 1 - dB + \frac{d(d-1)}{2!}B^2 - \frac{d(d-1)(d-2)}{3!}B^2 + \ldots, \text{และ}$$
$$(1-B^s)^D = 1 - DB^s + \frac{D(D-1)}{2!}B^{2s} - \frac{D(D-1)(D-2)}{3!}B^{2s} + \ldots,$$

(4)

รูปแบบทั่วไปตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ เมื่อความคลาดเคลื่อนขาวแบบเลขชี้กำลัง สามารถแสดงดังสมการที่ (5) ได้ดังนี้

$$\begin{aligned}X_t &= \mu+\varepsilon_t+\left(DX_{t-12}-\frac{D(1-D)}{2!}X_{t-2(12)}+\frac{D(1-D)(2-D)}{3!}X_{t-3(12)}+\ldots\right)\\&+\phi_1\left(X_{t-1}-DX_{t-12}+\frac{D(1-D)}{2!}X_{t-2(12)}-\frac{D(1-D)(2-D)}{3!}X_{t-3(12)}-\ldots\right)\\&+\Phi_1\left(X_{t-12}-DX_{t-12^2}+\frac{D(1-D)}{2!}X_{t-(12+1)12}-\frac{D(1-D)(2-D)}{3!}X_{t-(12+2)12}-\ldots\right)\\&-\phi_1\Phi_1\left(X_{t-(12+1)}-DX_{t-(12+1)12}+\frac{D(1-D)}{2!}X_{t-(12+2)12}-\frac{D(1-D)(2-D)}{3!}X_{t-(12+3)12}-\ldots\right)\end{aligned} \quad (5)$$

2.3 วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equation: NIE)

กำหนดให้ $L(u)$ แทน ค่าความยาวรันเฉลี่ย (ARL) สำหรับแผนภูมิควบคุม EWMA เมื่อกำหนดให้ $u \in [0,b]$ ดังนั้นสมการปริพันธ์สามารถแสดงดังสมการที่ ดังนี้

$$ARL = L(u) = E_\infty(\tau_b)$$

โดยที่ τ_b แทน คาบเวลาที่แผนภูมิควบคุมส่งสัญญาณเตือนว่ากระบวนการออกนอกการควบคุมจะได้ว่า

$$\tau_b = \inf\{t>0 : x_t \geq b\}, b > u$$

เมื่อ b แทน ขีดจำกัดควบคุมบน (UCL) ของแผนภูมิควบคุม EWMA ซึ่งในงานวิจัยนี้ได้ใช้วิธีสมการปริพันธ์เชิงตัวเลขเพื่อหาค่า ARL แสดงดังสมการที่ (6) ดังนี้

$$L(u) = L(u) = 1+\frac{1}{\lambda}\int_0^b L(y) f\left(\frac{y-(1-\lambda)u-k}{\lambda}\right)dy \quad (6)$$

โดยค่า k สามารถหาค่าได้จากสมการที่ (7) ดังนี้

$$\begin{aligned}k &= \lambda(\mu+D(x_{t-1}-\phi_1 x_{t-12})-D(\Phi_1 x_{t-12^2})-D(\phi_1\Phi_1 x_{t-(12+1)12})\\&-\frac{D(1-D)}{2!}(x_{t-12}-\phi_1 x_{t-2(12)})+\frac{D(1-D)}{2!}(\Phi_1 x_{t-(12+1)12})\\&-\frac{D(1-D)}{2!}(\phi_1\Phi_1 x_{t-(12+1)12})\\&+\frac{D(1-D)(2-D)}{3!}(x_{t-2(12)}-\phi_1 x_{t-3(12)})\\&+\frac{D(1-D)(2-D)}{3!}(\Phi_1 x_{t-(12+2)12})\\&-\frac{D(1-D)(2-D)}{3!}(\phi_1\Phi_1 x_{t-(12+3)(12)})\ldots\end{aligned} \quad (7)$$

จากสมการที่ (7) ใช้วิธีกฎการสร้างพื้นที่สี่เหลี่ยมจัตุรัสในการประมาณค่าอินทิกรัล สามารถประมาณได้ดังสมการที่ (8)

$$\tilde{L}(u) = 1+\frac{1}{\lambda}\sum_{j=1}^{m} w_j \tilde{L}(a_j) f\left(\frac{a_j-(1-\lambda)u-k}{\lambda}\right); i = 1,2,\ldots,m \quad (8)$$

วิธีสมการปริพันธ์เชิงตัวเลข (Numerical Integral Equations Method: NIE) ที่ใช้ในการวิจัยนี้มี 4 วิธี ดังนี้

2.3.1 วิธีกฎเกาส์ (Gaussian Rule Method)

จากสมการที่ (9) กำหนดให้

$$f(A_j) = f\left(\frac{a_j-(1-\lambda)u-k}{\lambda}\right) \quad (9)$$

การประมาณปริพันธ์เชิงตัวเลขของสมการ $f(y)$ ในช่วง $[0,b]$ แสดงดังสมการ

$$\int_0^b W(y)f(y)dy \approx \sum_{j=1}^{m} w_j f(a_j);\ j = 1,2,\ldots,m$$

โดยที่ $W(y) = 1,\ -1 < y < 1$

สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของเกาส์ของแผนภูมิควบคุม EWMA แสดงดังสมการที่ (10)

$$\tilde{L}_G(u) = 1+\frac{1}{\lambda}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (10)$$

2.3.2 วิธีกฎค่ากลาง (Midpoint Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น m ช่วง โดยมีช่วงความกว้าง $h = b/m$ ด้วยกฎของค่ากลาง ที่มีการแบ่งช่วงเป็น m ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของค่ากลางของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ แสดงดังสมการ (11)

$$\tilde{L}_M(u) = 1+\frac{1}{\lambda}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (11)$$

โดยที่ $a_j = w_j\left(j-\frac{1}{2}\right)$ และ $w_j = \frac{b}{m};\ j = 1,2,\ldots,m$

2.3.3 วิธีกฎสี่เหลี่ยมคางหมู (Trapezoidal Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น m ช่วง โดยมีช่วงความกว้าง $h = b/m$ ด้วยกฎของสี่เหลี่ยมคางหมู ที่มีการแบ่งช่วงเป็น m ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากวิธีกฎสี่เหลี่ยมคางหมู ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ แสดงดังสมการ (12)

$$\tilde{L}_T(u) = 1+\frac{1}{\lambda}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (12)$$

โดยที่ $a_j = w_j j$ และ $w_j = \frac{b}{m};\ j = 1,2,\ldots,m-1$

ในกรณีอื่น $w_j = \frac{b}{2m}$

2.3.4 วิธีกฎของซิมป์สัน (Simpson's Rule Method)

กำหนดให้ $y = f(y)$ ในช่วง $[0,b]$ แบ่งออกเป็น $2m$ ช่วง โดยมีช่วงความกว้าง $h = b/2m$ ด้วยกฎของซิมป์สัน ที่มีการแบ่งช่วงเป็น $2m$ ช่วง สามารถเขียนค่าประมาณปริพันธ์เชิงตัวเลขจากกฎของซิมป์สันของแผนภูมิควบคุม EWMA สำหรับแผนภูมิควบคุม SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ แสดงดังสมการ (13)

$$\tilde{L}_S(u) = 1+\frac{1}{\lambda}\sum_{j=1}^{m} w_j L(a_j) f(A_j) \quad (13)$$

โดยที่ $a_j = w_j j$,

$$w_j = \frac{4}{3}\left(\frac{b}{2m}\right);\ j = 1,3,...,2m-1$$

และ $w_j = \frac{2}{3}\left(\frac{b}{2m}\right);\ j = 2,4,...,2m-2$

ในกรณีอื่น $w_j = \frac{1}{3}\left(\frac{b}{2m}\right)$

2.4 ขั้นตอนการจำลองข้อมูล

1) ตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)12 โดยค่า พารามิเตอร์ของการทำส่วนต่างแบบเศษส่วนตามฤดูกาล (D) เท่ากับ 0.1, 0.2 และ 0.4

2) กำหนดค่าพารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุมที่ทำการศึกษา ดังนี้ λ เท่ากับ 0.05, 0.1 และ 0.15

3) กำหนดค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370, 500

4) กำหนดระดับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการ เท่ากับ 0.01, 0.03, 0.05, 0.07, 0.1, 0.5, 0.7 และ1 ตามลำดับ

5) ประมาณค่าความยาวรันเฉลี่ย (ARL) โดยวิธีสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี

6) เปรียบเทียบค่าความยาวรันเฉลี่ย (ARL_1) และเวลาที่ใช้ในการประมวลผล (CPU Times) ของแต่ละวิธีการประมาณค่าความยาวรันเฉลี่ยโดยวิธีสมการปริพันธ์เชิงตัวเลข

7) เปรียบเทียบประสิทธิภาพของค่าพารามิเตอร์ถ่วงน้ำหนัก (λ) ของแผนภูมิควบคุม EWMA สำหรับทุกตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ โดยใช้ ค่าความยาวรันเฉลี่ยที่ได้จากวิธีสมการปริพันธ์เชิงตัวเลข

3 ผลการวิจัยและอภิปรายผล

การวิจัยนี้ได้ศึกษาและเปรียบเทียบวิธีการประมาณค่าความยาวรันเฉลี่ย โดยวิธีสมการปริพันธ์เชิงตัวเลข 4 วิธี สำหรับแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ โดยพิจารณาจากกระบวนการไม่อยู่ภายใต้การควบคุม (ARL_1) และเวลาที่ใช้ในการประมวลผล (CPU Times) กำหนดให้กระบวนการเมื่ออยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370และ 500 สำหรับพารามิเตอร์ของแผนภูมิควบคุม EWMA กำหนดค่าพารามิเตอร์ถ่วงน้ำหนัก (λ) ของแผนภูมิควบคุม เท่ากับ 0.05, 0.1 และ 0.15 ตามลำดับ กำหนดค่าพารามิเตอร์ของค่าสังเกตที่มีการแจกแจงแบบเลขชี้กำลัง (β) ของแผนภูมิควบคุม EWMA กำหนดค่าพารามิเตอร์เมื่อกระบวนการอยู่ภายใต้การควบคุม ($\beta = \beta_0$) โดยที่ β_0 เท่ากับ 1 และเมื่อกระบวนการไม่อยู่ภายใต้การควบคุม ($\beta = \beta_1$) โดยที่ $\beta_1 > \beta_0$ กำหนดค่าพารามิเตอร์ $\beta_1 = (1+\delta)\beta_0$ เมื่อกำหนดระดับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการ (δ) เท่ากับ 0.01, 0.03, 0.05, 0.07, 0.1, 0.5, 0.7 และ 1 ตามลำดับ

ตารางที่ 1: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, 0.1, 0)$_{12}$ เมื่อ ARL_0 = 370

δ	λ = 0.05				λ = 0.1				λ = 0.15			
	b = 0.000000080396				b = 0.003443755				b = 0.07369695			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	**302.943** **(1.250)**	302.943 (1.422)	302.943 (7.250)	302.943 (4.984)	334.235 (1.327)	334.235 (1.421)	334.235 (7.702)	334.235 (4.922)	339.986 (1.265)	339.986 (1.407)	339.986 (7.812)	339.986 (4.780)
0.03	**205.49** **(1.280)**	205.49 (1.483)	205.49 (8.250)	205.49 (5.109)	274.311 (1.312)	274.311 (1.406)	274.311 (7.624)	274.311 (5.344)	288.75 (1.218)	288.75 (1.328)	288.75 (7.938)	288.75 (4.718)
0.05	**141.51** **(1.280)**	141.51 (1.438)	141.51 (7.781)	141.51 (5.046)	226.78 (1.421)	226.78 (1.266)	226.78 (8.313)	226.78 (5.577)	247.028 (1.172)	247.028 (1.218)	247.028 (8.438)	247.028 (5.000)
0.07	98.8762 (1.468)	**98.8762** **(1.390)**	98.8762 (7.359)	98.8762 (5.343)	188.787 (1.422)	188.787 (1.375)	188.787 (8.469)	188.787 (5.140)	212.763 (1.407)	212.763 (1.234)	212.763 (7.546)	212.763 (5.500)
0.1	**59.286** **(1.485)**	59.286 (1.531)	59.286 (7.953)	59.286 (5.39)	145.153 (1.360)	145.153 (1.296)	145.153 (8.437)	145.153 (5.218)	172.045 (1.078)	172.045 (1.422)	172.045 (7.749)	172.045 (4.734)
0.3	**4.33946** **(1.390)**	4.33946 (1.468)	4.33946 (7.672)	4.33946 (5.375)	34.2772 (1.328)	34.2772 (1.499)	34.2772 (8.219)	34.2772 (5.359)	54.8658 (1.312)	54.8658 (1.173)	54.8658 (8.047)	54.8658 (4.096)
0.5	**1.4018** **(1.422)**	1.4018 (1.425)	1.4018 (7.766)	1.4018 (5.11)	12.1288 (1.343)	12.1288 (1.437)	12.1288 (8.234)	12.1288 (5.453)	24.211 (1.158)	24.211 (1.407)	24.211 (8.172)	24.211 (5.093)
0.7	1.07833 (1.437)	**1.07833** **(1.407)**	1.07833 (7.468)	1.07833 (5.359)	5.74159 (1.187)	5.74159 (1.359)	5.74159 (8.749)	5.74159 (5.265)	13.1365 (1.078)	13.1365 (1.094)	13.1365 (7.859)	13.1365 (5.062)
1	**1.01218** **(1.375)**	1.01218 (1.468)	1.01218 (7.781)	1.01218 (5.156)	2.77719 (1.438)	2.77719 (1.390)	2.77719 (7.921)	2.77719 (5.453)	6.77984 (1.328)	6.77984 (1.421)	6.77984 (8.261)	6.77984 (4.889)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

ตารางที่ 2: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, 0.2, 0)$_{12}$เมื่อ $ARL_0 = 370$

δ	$\lambda = 0.05$				$\lambda = 0.1$				$\lambda = 0.15$			
	$b = 0.0000000755208$				$b = 0.00323165$				$b = 0.06871035$			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	**302.756** **(1.156)**	302.756 (1.297)	302.756 (8.281)	302.756 (5.156)	334.015 (1.343)	334.015 (1.375)	334.015 (7.281)	334.015 (5.156)	339.484 (1.515)	339.484 (1.594)	339.484 (8.093)	339.484 (5.422)
0.03	205.117 (1.363)	**205.117** **(1.281)**	205.117 (7.983)	205.117 (4.813)	273.783 (1.391)	273.783 (1.252)	273.783 (8.453)	273.783 (5.531)	287.537 (1.515)	287.537 (1.484)	287.537 (7.884)	287.537 (5.188)
0.05	**141.091** **(1.339)**	141.091 (1.406)	141.091 (7.532)	141.091 (5.266)	226.069 (1.156)	226.069 (1.234)	226.069 (8.030)	226.069 (5.031)	245.383 (1.468)	245.383 (1.484)	245.383 (7.593)	245.383 (4.843)
0.07	**98.4763** **(1.344)**	98.4763 (1.406)	98.4763 (8.359)	98.4763 (4.645)	187.976 (1.201)	187.976 (1.374)	187.976 (7.781)	187.976 (4.858)	210.871 (1.547)	210.871 (1.641)	210.871 (7.703)	210.871 (4.937)
0.1	**58.9554** **(1.155)**	58.9554 (1.359)	58.9554 (8.171)	58.9554 (5.032)	144.289 (1.375)	144.289 (1.343)	144.289 (8.14)	144.289 (4.999)	170.002 (1.485)	170.002 (1.515)	170.002 (7.812)	170.002 (4.687)
0.3	**4.2916** **(1.155)**	4.2916 (1.281)	4.2916 (7.781)	4.2916 (6.062)	33.777 (1.219)	33.777 (1.438)	33.777 (7.844)	33.777 (4.874)	53.4955 (1.516)	53.4955 (1.437)	53.4955 (7.838)	53.4955 (4.843)
0.5	1.39351 (1.312)	**1.39351** **(1.297)**	1.39351 (8.312)	1.39351 (6.156)	11.8892 (1.078)	11.8892 (1.296)	11.8892 (8.016)	11.8892 (4.624)	23.4408 (1.453)	23.4408 (1.545)	23.4408 (7.728)	23.4408 (5.297)
0.7	**1.07634** **(1.298)**	1.07634 (1.391)	1.07634 (7.782)	1.07634 (6.031)	5.61628 (1.124)	5.61628 (1.522)	5.61628 (7.844)	5.61628 (4.968)	12.6711 (1.485)	12.6711 (1.555)	12.6711 (8.515)	12.6711 (5.406)
1	**1.0118** **(1.156)**	1.0118 (1.359)	1.0118 (7.984)	1.0118 (4.953)	2.72054 (1.253)	2.72054 (1.531)	2.72054 (7.984)	2.72054 (5.125)	6.52785 (1.512)	6.52785 (1.515)	6.52785 (7.829)	6.52785 (5.343)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

ตารางที่ 3: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, 0.4, 0)$_{12}$ เมื่อ $ARL_0 = 370$

δ	$\lambda = 0.05$				$\lambda = 0.1$				$\lambda = 0.15$			
	$b = 0.0000000660868$				$b = 0.002822429$				$b = 0.05926565$			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	**302.358** **(1.219)**	302.358 (1.328)	302.358 (7.891)	302.358 (5.328)	333.549 (1.266)	333.549 (1.328)	333.549 (7.156)	333.549 (5.359)	338.433 (1.281)	338.433 (1.437)	338.433 (7.000)	338.433 (4.985)
0.03	**204.326** **(1.125)**	204.326 (1.266)	204.326 (7.718)	204.326 (5.547)	272.663 (1.187)	272.663 (1.328)	272.663 (7.438)	272.663 (5.250)	285.013 (1.250)	285.013 (1.375)	285.013 (7.094)	285.013 (4.797)
0.05	**140.204** **(1.031)**	140.204 (1.234)	140.204 (7.766)	140.204 (5.953)	224.561 (1.296)	224.561 (1.250)	224.561 (7.687)	224.561 (5.375)	241.98 (1.219)	241.98 (1.187)	241.98 (7.437)	241.98 (4.906)
0.07	97.6292 (1.437)	**97.6292** **(1.266)**	97.6292 (7.531)	97.6292 (4.938)	186.259 (1.359)	186.259 (1.281)	186.259 (7.063)	186.259 (5.297)	206.977 (1.250)	206.977 (1.266)	206.977 (7.844)	206.977 (5.266)
0.1	**58.2567** **(1.172)**	58.2567 (1.454)	58.2567 (7.797)	58.2567 (4.953)	142.468 (1.313)	142.468 (1.344)	142.468 (7.422)	142.468 (5.438)	165.82 (1.250)	165.82 (1.297)	165.82 (7.656)	165.82 (5.438)
0.3	**4.19178** **(1.219)**	4.19178 (1.375)	4.19178 (7.313)	4.19178 (5.000)	32.7376 (1.343)	32.7376 (1.390)	32.7376 (7.656)	32.7376 (5.156)	50.7621 (1.359)	50.7621 (1.312)	50.7621 (7.969)	50.7621 (5.531)
0.5	**1.37639** **(1.141)**	1.37639 (1.391)	1.37639 (7.641)	1.37639 (5.218)	11.3965 (1.265)	11.3965 (1.297)	11.3965 (7.594)	11.3965 (5.219)	21.9233 (1.266)	21.9233 (1.391)	21.9233 (7.641)	21.9233 (5.766)
0.7	**1.07225** **(1.187)**	1.07225 (1.250)	1.07225 (7.469)	1.07225 (5.234)	5.36055 (1.266)	5.36055 (1.531)	5.36055 (7.063)	5.36055 (5.469)	11.761 (1.156)	11.761 (1.312)	11.761 (7.922)	11.761 (5.375)
1	**1.01104** **(1.203)**	1.01104 (1.266)	1.01104 (7.671)	1.01104 (5.281)	2.60594 (1.250)	2.60594 (1.234)	2.60594 (7.857)	2.60594 (5.343)	6.03843 (1.031)	6.03843 (1.422)	6.03843 (7.203)	6.03843 (5.312)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

ตารางที่ 4: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA$(1, 0, 0)(1, 0.1, 0)_{12}$ เมื่อ $ARL_0 = 500$

δ	$\lambda = 0.05$				$\lambda = 0.1$				$\lambda = 0.15$			
	$b =$ 0.0000001087196				$b =$ 0.004610825				$b =$ 0.08306725			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	409.318 (1.407)	**409.318** **(1.343)**	409.318 (7.813)	409.318 (5.547)	451.568 (1.375)	451.568 (1.297)	451.568 (8.109)	451.568 (5.062)	456.354 (1.359)	456.354 (1.421)	456.354 (7.687)	456.354 (5.188)
0.03	277.532 (1.531)	**277.532** **(1.296)**	277.532 (8.078)	277.532 (5.031)	370.439 (1.484)	370.439 (1.202)	370.439 (8.547)	370.439 (4.531)	382.88 (1.281)	382.88 (1.390)	382.88 (6.968)	382.88 (5.734)
0.05	**191.011** **(1.328)**	191.011 (1.452)	191.011 (7.703)	191.011 (5.453)	306.11 (1.453)	306.11 (1.437)	306.11 (7.765)	306.11 (5.234)	324.054 (1.439)	324.054 (1.406)	324.054 (7.937)	324.054 (5.187)
0.07	**133.358** **(1.344)**	133.358 (1.407)	133.358 (8.25)	133.358 (5.123)	254.703 (1.297)	254.703 (1.437)	254.703 (7.39)	254.703 (5.203)	276.451 (1.328)	276.451 (1.297)	276.451 (7.985)	276.451 (5.093)
0.1	**79.8203** **(1.359)**	79.8203 (1.422)	79.8203 (8.109)	79.8203 (5.172)	195.683 (1.265)	195.683 (1.390)	195.683 (7.938)	195.683 (5.281)	220.772 (1.155)	220.772 (1.375)	220.772 (7.406)	220.772 (5.249)
0.3	**5.51596** **(1.343)**	5.77181 (1.344)	5.77181 (8.203)	5.77181 (5.047)	45.8594 (1.297)	45.8594 (1.500)	45.8594 (8.531)	45.8594 (5.093)	66.8952 (1.156)	66.8952 (1.171)	66.8952 (7.515)	66.8952 (5.251)
0.5	**1.54336** **(1.437)**	1.54336 (1.439)	1.54336 (8.235)	1.54336 (5.312)	15.984 (1.281)	15.984 (1.328)	15.984 (8.25)	15.984 (5.015)	28.7379 (1.265)	28.7379 (1.391)	28.7379 (8.11)	28.7379 (5.202)
0.7	**1.10592** **(1.438)**	1.10592 (1.453)	1.10592 (8.016)	1.10592 (5.437)	7.37869 (1.234)	7.37869 (1.390)	7.37869 (7.765)	7.37869 (5.546)	15.3094 (1.358)	15.3094 (1.453)	15.3094 (8.903)	15.3094 (4.969)
1	**1.01647** **(1.36)**	1.01647 (1.515)	1.01647 (7.719)	1.01647 (4.938)	3.38864 (1.438)	3.38864 (1.483)	3.38864 (8.391)	3.38864 (5.296)	7.73379 (1.062)	7.73379 (1.296)	7.73379 (8.203)	7.73379 (5.125)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

ตารางที่ 5: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA$(1, 0, 0)(1, 0.2, 0)_{12}$ เมื่อ $ARL_0 = 500$

δ	$\lambda = 0.05$				$\lambda = 0.1$				$\lambda = 0.15$			
	$b =$ 0.000000102127				$b =$ 0.00432543				$b =$ 0.07746235			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	409.066 (1.547)	**409.066** **(1.172)**	409.066 (8.109)	409.066 (4.937)	451.266 (1.000)	451.266 (1.141)	451.266 (7.422)	451.266 (4.765)	455.563 (1.281)	455.563 (1.406)	455.563 (8.062)	455.563 (4.516)
0.03	**277.029** **(1.284)**	277.029 (1.396)	277.029 (8.218)	277.029 (5.218)	369.713 (1.155)	369.713 (1.218)	369.713 (7.765)	369.713 (5.281)	381.015 (1.172)	381.015 (1.312)	381.015 (7.812)	381.015 (4.797)
0.05	**190.446** **(1.425)**	190.446 (1.484)	190.446 (7.437)	190.446 (5.297)	305.13 (1.203)	305.13 (1.250)	305.13 (7.843)	305.13 (5.297)	321.577 (1.328)	321.577 (1.390)	321.577 (7.75)	321.577 (4.735)
0.07	132.818 (1.269)	**132.818** **(1.171)**	132.818 (7.953)	132.818 (5.047)	253.586 (1.124)	253.586 (1.249)	253.586 (7.734)	253.586 (5.172)	273.656 (1.109)	273.656 (1.235)	273.656 (7.874)	273.656 (5.109)
0.1	**79.3734** **(1.184)**	79.3734 (1.281)	79.3734 (7.906)	79.3734 (5.265)	194.495 (1.296)	194.495 (1.375)	194.495 (7.75)	194.495 (5.531)	217.825 (1.187)	217.825 (1.281)	217.825 (7.718)	217.825 (4.937)
0.3	**5.45124** **(1.111)**	5.45124 (1.543)	5.45124 (8.000)	5.45124 (5.531)	45.1746 (1.313)	45.1746 (1.327)	45.1746 (8.187)	45.1746 (4.954)	65.0993 (1.284)	65.0993 (1.141)	65.0993 (7.859)	65.0993 (4.484)
0.5	**1.53215** **(1.269)**	1.53215 (1.405)	1.53215 (7.765)	1.53215 (4.750)	15.657 (1.109)	15.657 (1.281)	15.657 (8.187)	15.657 (5.547)	27.7727 (1.328)	27.7727 (1.312)	27.7727 (7.822)	27.7727 (4.703)
0.7	1.10323 (1.532)	**1.10323** **(1.343)**	1.10323 (7.922)	1.10323 (4.844)	7.20799 (1.266)	7.20799 (1.14)	7.20799 (7.859)	7.20799 (4.984)	14.7408 (1.016)	14.7408 (1.204)	14.7408 (8.016)	14.7408 (4.405)
1	**1.01596** **(1.326)**	1.01596 (1.406)	1.01596 (8.109)	1.01596 (5.047)	3.31165 (1.062)	3.31165 (1.202)	3.31165 (7.938)	3.31165 (5.249)	7.43273 (1.281)	7.43273 (1.468)	7.43273 (7.218)	7.43273 (4.907)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

ตารางที่ 6: ค่า ARL_1 ของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, 0.4, 0)$_{12}$ เมื่อ $ARL_0 = 500$

δ	$\lambda = 0.05$				$\lambda = 0.1$				$\lambda = 0.15$			
	$b = 0.0000000893693$				$b = 0.003775318$				$b = 0.0668385$			
	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson	Midpoint	Trapezoidal	Gaussian	Simpson
0.01	408.527 (1.312)	**410.246 (1.234)**	410.246 (7.406)	410.246 (5.250)	450.624 (1.281)	450.624 (1.156)	450.624 (6.906)	450.624 (5.281)	453.911 (1.047)	453.911 (1.141)	453.911 (7.406)	453.911 (5.281)
0.03	**275.958 (1.328)**	275.958 (1.376)	275.958 (7.343)	275.958 (5.063)	368.17 (1.265)	368.17 (1.328)	368.17 (6.938)	368.17 (4.610)	377.148 (1.218)	377.148 (1.172)	377.148 (7.266)	377.148 (4.61)
0.05	**189.246 (1.219)**	189.246 (1.234)	189.246 (7.437)	189.246 (5.234)	303.055 (1.047)	303.055 (1.359)	303.055 (6.875)	303.055 (4.765)	316.476 (1.235)	316.476 (1.312)	316.476 (7.531)	316.476 (4.765)
0.07	131.672 (1.297)	**131.672 (1.218)**	131.672 (7.235)	131.672 (5.156)	251.225 (1.375)	251.225 (1.110)	251.225 (7.078)	251.225 (4.922)	267.93 (1.266)	267.93 (1.250)	267.93 (7.391)	267.93 (4.922)
0.1	78.4284 (1.250)	**78.4284 (1.219)**	78.4284 (7.782)	78.4284 (5.172)	191.992 (1.391)	191.992 (1.281)	191.992 (7.157)	191.992 (5.000)	211.828 (1.141)	211.828 (1.250)	211.828 (7.781)	211.828 (5.000)
0.3	**5.31626 (1.266)**	5.31626 (1.297)	5.31626 (7.656)	5.31626 (4.922)	43.7528 (1.219)	43.7528 (1.313)	43.7528 (7.360)	43.7528 (4.922)	61.5385 (1.14)	61.5385 (1.203)	61.5385 (7.813)	61.5385 (4.922)
0.5	**1.509 (1.172)**	1.509 (1.250)	1.509 (7.937)	1.509 (5.023)	14.9851 (1.297)	14.9851 (1.359)	14.9851 (7.640)	14.9851 (4.75)	25.8807 (1.203)	25.8807 (1.156)	25.8807 (7.577)	25.8807 (4.750)
0.7	**1.09771 (1.157)**	1.09771 (1.281)	1.09771 (7.453)	1.09771 (5.265)	6.86005 (1.282)	6.86005 (1.422)	6.86005 (7.438)	6.86005 (4.391)	13.6337 (1.141)	13.6337 (1.375)	13.6337 (7.828)	13.6337 (4.391)
1	**1.01493 (1.187)**	1.01493 (1.234)	1.01493 (7.422)	1.01493 (5.313)	3.15608 (1.250)	3.15608 (1.297)	3.15608 (7.671)	3.15608 (4.625)	6.84998 (1.172)	6.84998 (1.281)	6.84998 (7.766)	6.84998 (4.625)

* ตัวเลขคือค่าความยาวรันเฉลี่ย กรณีที่กระบวนการไม่อยู่ภายใต้ควบคุม (ARL_1)

** ตัวเลขที่อยู่ในเครื่องหมายวงเล็บเวลาที่ใช้ในการประมวลผล (CPU Times) มีหน่วยเป็นวินาที

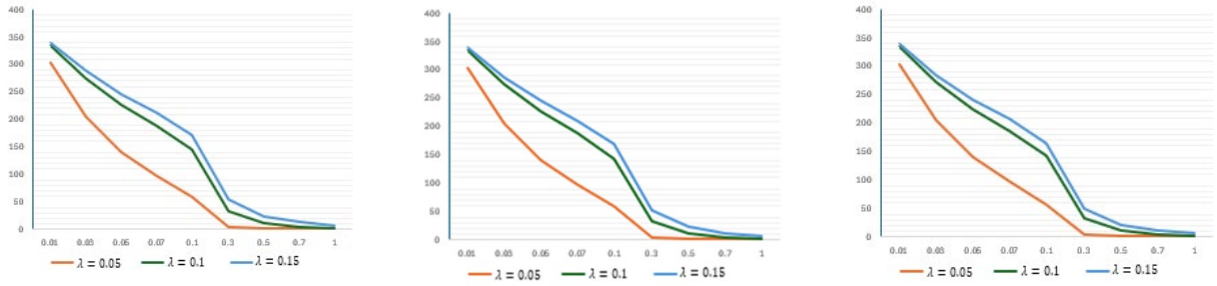

(a) SARFIMA(1, 0, 0)(1, 0.1, 0)$_{12}$ (b) SARFIMA(1, 0, 0)(1, 0.2, 0)$_{12}$ (c) SARFIMA(1, 0, 0)(1, 0.4, 0)$_{12}$

รูปที่ 1 : เปรียบเทียบค่า ARL_1 จากวิธีกฎของค่ากลางของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ สำหรับ $ARL_0 = 370$:

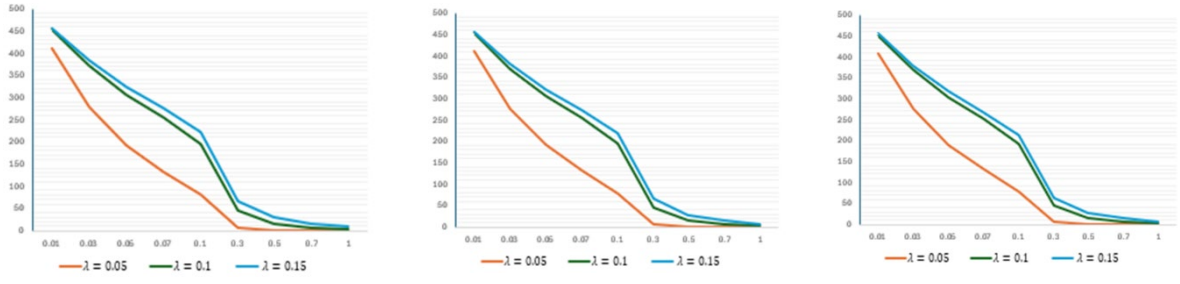

(a) SARFIMA(1, 0, 0)(1, 0.1, 0)$_{12}$ (b) SARFIMA(1, 0, 0)(1, 0.2, 0)$_{12}$ (c) SARFIMA(1, 0, 0)(1, 0.4, 0)$_{12}$

รูปที่ 2 : เปรียบเทียบค่า ARL_1 จากวิธีกฎของค่ากลางของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA(1, 0, 0)(1, D, 0)$_{12}$ สำหรับ $ARL_0 = 500$:

จากตารางที่ 1 - 3 แสดงผลลัพธ์ค่า ARL_1 ที่ได้เทคนิคสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธีของแผนภูมิควบคุม EWMA สำหรับตัวแบบ SARFIMA$(1, 0, 0)(1, 0.1, 0)_{12}$, SARFIMA$(1, 0, 0)(1, 0.2, 0)_{12}$ และ SARFIMA$(1, 0, 0)(1, 0.4, 0)_{12}$ เมื่อกำหนด $ARL_0 = 370$ ผลการวิจัยพบว่า ผลลัพธ์ที่ได้จากเทคนิคสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี ให้ค่า ARL_1 ไม่แตกต่างกัน และเมื่อระดับการเปลี่ยนแปลงของค่าเฉลี่ย (δ) กระบวนการพบว่า เมื่อระดับการเปลี่ยนแปลงของค่าเฉลี่ยเพิ่มขึ้นผลลัพธ์ค่า ARL_1 มีค่าลดลง โดยลดลงอย่างรวดเร็วเมื่อมีการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการมีขนาดเล็ก $(0.01 \le \delta < 0.5)$ ในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ หากพิจารณาเวลาในการประมวลผลค่า ARL_1 พบว่า วิธีกฎของค่ากลางใช้เวลาในการประมวลผลน้อยสุดและใกล้เคียงกับวิธีกฎสี่เหลี่ยมคางหมู โดยใช้เวลาในการประมวลผลประมาณ 1-2 วินาที วิธีกฎของซิมป์สันใช้เวลาในการประมวลผลประมาณ 5 - 6 วินาที และวิธีกฎของเกาส์ใช้เวลาในการประมวลผลประมาณ 7-10 วินาที ในทุกระดับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ สำหรับตารางที่ 4 – 6 แสดงผลลัพธ์ค่า ARL_1 ที่ได้เทคนิคสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี ให้ผลลัพธ์ค่า ARL_1 และเวลาในการประมวลผลเช่นเดียวกัน

จากรูปที่ 1 แสดงผลลัพธ์ค่า ARL_1 ที่ได้จากวิธีกฎของค่ากลางของแผนภูมิควบคุม EWMA เมื่อค่าพารามิเตอร์ถ่วงน้ำหนัก (λ) ของแผนภูมิควบคุม เท่ากับ 0.05, 0.1 และ 0.15 ในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ สำหรับ $ARL_0 = 370$ ผลการวิจัยพบว่า ผลลัพธ์ที่ได้จากวิธีกฎของค่ากลางของแผนภูมิควบคุม EWMA เมื่อ $\lambda = 0.05$ ให้กราฟเส้นของ ค่า ARL_1 ต่ำสุด และลดลงอย่างรวดเร็วเมื่อมีการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการขนาดเล็ก $(0.01 \le \delta < 0.5)$ ในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ แสดงในรูปย่อย (a)-(c) เมื่อ λ เท่ากับ 0.1 และ 0.15 แสดงกราฟเส้นของ ค่า ARL_1 ต่ำรองลงมา ตามลำดับ ซึ่งแสดงผลลัพธ์ค่า ARL_1 ลดลงอย่างรวดเร็วเมื่อมีการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการขนาดเล็กในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ และรูปที่ 2 สำหรับ $ARL_0 = 500$ ผลลัพธ์เช่นเดียวกัน

4. สรุปผลการวิจัย

จากผลการวิจัยพบว่า ค่า ARL_1 ที่ได้จากเทคนิคสมการปริพันธ์เชิงตัวเลขทั้ง 4 วิธี มีแนวโน้มลดลงอย่างรวดเร็วเมื่อเกิดการเปลี่ยนแปลงของค่าเฉลี่ยในกระบวนการเพียงเล็กน้อย โดยค่า ARL_1 ที่ได้จากแต่ละวิธีไม่แตกต่างกันอย่างมีนัยสำคัญในทุกกรณีของตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ ที่ทำการศึกษา อย่างไรก็ตาม เมื่อพิจารณาเวลาในการประมวลผล พบว่า วิธีกฎของค่ากลาง ใช้เวลาน้อยที่สุด ในทุกระดับของการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ ดังนั้น วิธีกฎของค่ากลาง จึงถือเป็นวิธีที่เหมาะสมที่สุดในการคำนวณค่า ARL_1 สำหรับการประเมินประสิทธิภาพของแผนภูมิควบคุม EWMA ในตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$

จากการเปรียบเทียบประสิทธิภาพของค่าพารามิเตอร์ถ่วงน้ำหนัก (λ) ของแผนภูมิควบคุม เท่ากับ 0.05, 0.1 และ 0.15 . ในทุกตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ บนแผนภูมิควบคุม EWMA พบว่า วิธีกฎของค่ากลางของแผนภูมิควบคุม EWMA เมื่อ $\lambda = 0.05$ มีการตรวจจับได้ดีกว่ากรณีอื่นๆ และสามารถตรวจจับได้รวดเร็วกว่าอย่างเห็นได้ชัด เมื่อมีการเปลี่ยนแปลงของกระบวนการขนาดเล็ก $(0.01 \le \delta < 0.5)$

ดังนั้นในงานวิจัยครั้งต่อไปผู้วิจัยจึงสนใจที่จะนำตัวแบบ SARFIMA$(1, 0, 0)(1, D, 0)_{12}$ นำมาใช้บนแผนภูมิควบคุมอื่นๆ และนำไปประยุกต์ใช้กับข้อมูลจริง

5. เอกสารอ้างอิง

[1] Shewhart, W. A. (1931). Economic control of quality of manufactured product. Van Nostrand.

[2] Page, E. S. (1954). Continuous inspection schemes. Biometrika, 41(1/2), 100–115.

[3] Roberts, S. W. (1959). Control chart tests based on geometric moving averages. Technometrics, 1(3), 239–250.

[4] Granger, C. W. J., & Joyeux, R. (1980). An introduction to long‐memory time series models and fractional differencing. Journal of Time Series Analysis, 1(1), 15–29.

[5] Hosking, J. R. M. (1981). Fractional differencing. Biometrika, 68(1), 165–176.

[6] Carlin, B. P., & Dempster, A. P. (1989). The monthly unemployment rate for men in the United States: A Bayesian analysis. Journal of the American Statistical Association, 84(405), 1106–1117.

[7] Ray, J. (1993). Monthly revenue from IBM products. Publisher.

[8] Qi, C., Zhang, D., Zhu, Y., Liu, L., Li, C., Wang, Z., & Li, X. (2020). SARFIMA model prediction for infectious diseases: application to hemorrhagic fever with renal syndrome and comparing with SARIMA. BMC medical research methodology, 20, 1-7.

[9] Adewole, A. I., & Amurawaye, F. F. (2024). Modeling Temperature Forecast in Ogun State Nigeria with SARFIMA and SARIMA. Journal of Science and Information Technology, 18(1), 109-119.

[10 Adewole, A. I., & Amurawaye, F. F. (2024). Modeling Temperature Forecast in Ogun State Nigeria with SARFIMA and SARIMA. Journal of Science and Information Technology, 18(1), 109-119.

[11] Devianto, D., Wahyuni, E., Maiyastri, M., & Yollanda, M. (2024). The seasonal model of chili price movement with the effect of long memory and exogenous variables for improving time series model accuracy. Frontiers in Applied Mathematics and Statistics, 10, 1408381.

[12] Jacob, D., & Lewis, P. A. W. (1977). Time series regression with exponentially distributed and other non-normal errors. Journal of the Royal Statistical Society: Series B (Methodological), 39(2), 272–280

[13] Ibazizen, M., & Fellag, H. (2003). Bayesian estimation of an AR(1) process with exponential white noise. Statistics, 37(5), 365–372.

[14] Peerajit, Wilasinee. (2023). Approximating the ARL of Changes in the Mean of a Seasonal Time Series Model with Exponential White Noise Running on a CUSUM Control Chart. WSEAS Transactions on Systems and Control, 18, 370-381.

[15] Champ, K., & Rigdon, S. E. (1991). A numerical integral equation approach for process control charts. Journal of Quality Technology, 23(3), 154–163.

การศึกษาความแกร่งของแผนภูมิควบคุมจำนวนรอยตำหนิ

Robustness of Control Charts for Number of Defects

ชนัญชิดา ศรีสุวรรณ์* ฐิตนนท์ จารุโรจน์กีรติ

ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(momaychananchida@gmail.com)*

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเสนอการวัดประสิทธิภาพความแกร่งของแผนภูมิควบคุมคุณภาพของจำนวนรอยตำหนิด้วยช่วงความเชื่อมั่นของการแจกแจงป๋วซงกับแผนภูมิควบคุม 3 แผนภูมิ ได้แก่ แผนภูมิควบคุมรอยตำหนิ (C-chart) แผนภูมิควบคุมผลรวมสะสม (CUSUM control chart) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (EWMA control chart) โดยแผนภูมิควบคุมดังกล่าวมีความสามารถในการตรวจจับความเปลี่ยนแปลงจำนวนรอยตำหนิหรือไม่ โดยวัตถุประสงค์ของงานวิจัย คือ วัดประสิทธิภาพของแผนภูมิควบคุมจำนวนรอยตำหนิเมื่อกำหนดให้ค่าสังเกตมีการแจกแจงป๋วซง (Poisson) กำหนดให้แผนภูมิควบคุมที่ใช้ในงานวิจัย มีดังนี้ แผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงป๋วซง (Exact control chart), แผนภูมิควบคุมรอยตำหนิ , แผนภูมิควบคุมผลรวมสะสม และ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง ซึ่งวัดประสิทธิภาพของแผนภูมิควบคุมด้วยค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยแผนภูมิควบคุมที่มีค่าความยาวรันเฉลี่ยต่ำที่สุด คือแผนภูมิควบคุมที่มีประสิทธิภาพดีที่สุด

คำสำคัญ: แผนภูมิควบคุมจำนวนรอยตำหนิ, แผนภูมิควบคุมผลรวมสะสม, แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง, การแจกแจงป๋วซง

Abstract

The purpose of this study was to propose a method for evaluating the robustness performance of the control chart with the confidence interval of the Poison distribution with three control charts: C-chart, CUSUM control chart, and EWMA control chart. In this study, the probability property of the Poisson distribution was used to measure the effectiveness of the control chart compared between the charts with Exact Confident interval, C-chart, CUSUM control chart and EWMA control chart. The performance of these control charts is evaluated using the Average Run Length (ARL) metric. The control chart with the lowest ARL is considered the most efficient.

Keywords: C-chart, CUSUM control chart, EWMA control chart, Poisson distribution

1. บทนำ

กระบวนการควบคุมทางสถิติ (Statistical process control : SPC) เป็นเครื่องมือที่สำคัญและใช้กันอย่างกว้างขวางสำหรับการตรวจสอบ ควบคุม และปรับปรุงกระบวนการผลิต เพื่อให้กระบวนการผลิตเป็นไปตามมาตราฐานที่กำหนดไว้ มีมากมายหลากหลายวิธี โดยวิธีที่เป็นที่นิยมมากที่สุด คือ แผนภูมิควบคุม (Control charts) ซึ่งแบ่งออกเป็น 2 ลักษณะ คือ แผนภูมิควบคุมเชิงปริมาณ และแผนภูมิควบคุมเชิงคุณภาพ โดยทั้ง 2 แผนภูมิควบคุมมีความแตกต่างกันที่ลักษณะของข้อมูลที่ต้องการควบคุม ดังนี้

- แผนภูมิควบคุมเชิงปริมาณ ใช้สำหรับข้อมูลเชิงปริมาณ หรือข้อมูลมีการแจกแจงต่อเนื่อง เช่น ปริมาตรของน้ำ ปริมาตรของน้ำฝน ราคาหุ้น ฯลฯ
- แผนภูมิควบคุมเชิงคุณภาพ ใช้สำหรับข้อมูลเชิงคุณภาพ หรือข้อมูลมีการแจกแจงไม่ต่อเนื่อง เช่น จำนวนของที่ชำรุด จำนวนรอยตำหนิบนชิ้นงาน ฯลฯ

แผนภูมิควบคุมถูกคิดค้นครั้งแรก โดย Walter A. Shewhart [1] ในปี ค.ศ. 1926 ซึ่งมีลักษณะเป็นกราฟเปรียบเทียบพฤติกรรมของกระบวนการที่ได้จากการคำนวณทางสถิติ เมื่อข้อมูลที่ได้จะเป็นในเชิงคุณลักษณะรอยตำหนิที่มีการแจกแจงป๋วซง (Poisson distribution)

ปี ค.ศ. 1936 Garwood [2] ได้นำเสนอช่วงความเชื่อมั่นของการแจกแจงป๋วซง โดยช่วงความเชื่อมั่นของการแจกแจงป๋วซงสามารถคำนวนได้จากการแจกแจงไคสแคว์

ปี ค.ศ. 1985 แผนภูมิควบคุมผลรวมสะสม (cumulative sum control chart: CUSUM) ถูกนำเสนอโดย Lucas [3] ซึ่งมี

ประสิทธิภาพในการตรวจจับความผิดปกติของกระบวนการได้ดีกว่าแผนภูมิควบคุมจำนวนรอยตำหนิ (C-chart)

ปี ค.ศ. 1959 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (Exponentially weighted moving average control chart: EWMA) ถูกนำเสนอโดย Roberts [4] ซึ่งเป็นแผนภูมิควบคุมตรวจจับความเปลี่ยนแปลงขนาดเล็กได้ดี

การวัดประสิทธิภาพของแผนภูมิควบคุมนิยมวัดด้วยค่าความยาวรันเฉลี่ย (Average run length: ARL) ซึ่งเป็นค่าเฉลี่ยของค่าความยาวรัน (Run length: RL) คือ จำนวนค่าสังเกตในกระบวนการที่อยู่ภายใต้การควบคุมก่อนกระบวนการไม่อยู่ภายใต้การควบคุมเป็นครั้งแรก

ในงานวิจัยนี้จึงเสนอการเปรียบเทียบประสิทธิภาพความแกร่งของแผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง (Exact control chart), แผนภูมิควบคุมจำนวนรอยตำหนิ (C-Chart), แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (EWMA control chart) และแผนภูมิควบคุมผลรวมสะสม (CUSUM control chart) เมื่อกำหนดให้ค่าสังเกตของกระบวนการมาจากการแจกแจงปัวซง (Poisson distribution)

2. แผนภูมิควบคุม

พื้นฐานของการสร้างแผนภูมิควบคุมนั้น มีข้อกำหนดเบื้องต้นว่า ค่าเฉลี่ยของกระบวนการมีการแจกแจงปรกติ และการสร้างขีดจำกัดควบคุมเปรียบเหมือนการหาช่วงความเชื่อมั่น (Confident Interval: CI) ดังนั้นโครงสร้างของแผนภูมิควบคุมสำหรับค่าสังเกต สามารถเขียนเป็นสมการ ได้ดังนี้

$$\text{UCL / LCL} = \mu_0 \pm L\sigma_0$$

โดยที่

X คือ ตัวแปรสุ่มของข้อมูลในกระบวนการ

LCL คือ ขีดจำกัดควบคุมด้านล่าง (Lower control limit)

UCL คือ ขีดจำกัดควบคุมด้านบน (Upper control limit)

μ_0 คือ ค่าเฉลี่ยของกระบวนการเมื่อกระบวนการอยู่ภายใต้การควบคุม

σ_0 คือ ค่าส่วนเบี่ยงเบนมาตรฐานของกระบวนการเมื่อกระบวนการอยู่ภายใต้การควบคุม

L คือ สัมประสิทธิ์ของขีดจำกัดควบคุมของแผนภูมิควบคุม

เงื่อนไขของข้อมูลอยู่ภายใต้การควบคุม มีดังนี้

- กระบวนการอยู่ภายใต้การควบคุม (In control chart: I.C.C.) เมื่อ $LCL \le X_i \le UCL$
- กระบวนการไม่อยู่ภายใต้การควบคุม (Out of control chart: O.C.C.) เมื่อ $X_i < LCL$ หรือ $X_i > UCL$

2.1 แผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง (Exact control chart)

Garwood (1936) ใช้การแจกแจงไคสแควร์ (Chi-Square Distribution) ในการคำนวณช่วงความเชื่อมั่นของ λ โดยช่วงความเชื่อมั่นของ Garwood เหมาะสมกับพารามิเตอร์ที่มีขนาดเล็ก

กำหนดให้ X เป็นตัวแปรสุ่มจากการแจกแจงปัวซง (Poisson) ที่พารามิเตอร์ λ ที่ช่วงความเชื่อมั่นของ λ คือ

$$CI_\lambda = [\lambda_U, \lambda_L] = \left[\frac{1}{2}\chi^2_{2(X+1),1-\frac{\alpha}{2}}, \frac{1}{2}\chi^2_{2(X+1),1-\frac{\alpha}{2}}\right]$$

โดยที่

$\chi^2_{k,p}$ คือ ค่าควอนไทล์ที่ p ของการแจกแจงไคสแควร์ที่องศาอิสระ k

λ_L และ λ_U คือ ค่าขอบล่างและขอบบนของช่วงความเชื่อมั่น

งานวิจัยนี้กำหนดให้ขีดจำกัดควบคุมของแผนภูมิควบคุม คือ

$$LCL = \frac{1}{2}\chi^2_{2(\lambda+1),1-\frac{\alpha}{2}} \text{ และ } UCL = \frac{1}{2}\chi^2_{2(\lambda+1),1-\frac{\alpha}{2}}$$

2.2 แผนภูมิควบคุมจำนวนรอยตำหนิ (Control Charts for nonconformities (defects) : C-chart)

แผนภูมิควบคุมจำนวนรอยตำหนิ เป็นแผนภูมิสามารถตรวจจับการเปลี่ยนแปลงพารามิเตอร์ที่มีขนาดเล็กและขนาดปานกลางได้ดี โดยนิยามของค่าสถิติของแผนภูมิและขีดจำกัดควบคุม มีสมการ ดังนี้

ค่าสถิติของแผนภูมิควบคุม C-chart คือ

$$\bar{c} = \frac{\sum c}{N}$$

โดยที่

c คือ จำนวนรอยตำหนิที่มีอยู่ในแต่ละตัวอย่าง

N คือ จำนวนกลุ่มตัวอย่าง

$\bar{c}$ คือ ค่าเฉลี่ยจำนวนรอยตำหนิ

ขีดจำกัดควบคุมของแผนภูมิควบคุม คือ

$$UCL / LCL = \bar{c} \pm L \cdot \sqrt{\bar{c}}$$

โดยที่

L คือ สัมประสิทธิ์ของขีดจำกัดควบคุม

$\sigma_c = \sqrt{\bar{c}}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐาน

2.3 แผนภูมิควบคุมผลรวมสะสม (Cumulative sum control chart : CUSUM)

แผนภูมิควบคุม CUSUM เป็นแผนภูมิที่มีการนำข้อมูลตลอดช่วงเวลาการเก็บข้อมูลมาใช้ประกอบการตัดสินใจ โดยการนำค่าผลรวมสะสมของค่าผลต่างระหว่างค่าเฉลี่ยของกระบวนการและค่าเฉลี่ยของเป้าหมายมาพล็อตลงในแผนภูมิ โดยนิยามของค่าสถิติของแผนภูมิ และขีดจำกัดควบคุม โดยมีสมการ ดังนี้

- กรณีที่ขนาดของกลุ่มตัวอย่างย่อยมีค่าเท่ากับ 1 หรือ กรณีขนาดตัวอย่างเดียว (Individual)

ค่าสถิติของแผนภูมิควบคุม คือ

$$C_i = \sum_{i=1}^{m}(x_i - \mu_0)$$

โดยที่

x_i คือ ค่าสังเกตที่ i โดยที่ $i = 1,2,3,...,m$

μ_0 คือ ค่าเฉลี่ยของเป้าหมายของกระบวนการเมื่อกระบวนการอยู่ในการควบคุม

- กรณีที่ขนาดของกลุ่มตัวอย่างย่อยมีค่ามากกว่า 1 (Subgroup)

ค่าสถิติของแผนภูมิควบคุม คือ

$$C_i = \sum_{i=1}^{m} (\bar{x}_i - \mu_0)$$

โดยที่

$\bar{x}_i$ คือ ค่าเฉลี่ยของคุณลักษณะเชิงคุณภาพของตัวอย่างที่ i ซึ่งมีขนาดของกลุ่มตัวอย่างย่อยเป็น j และ $\bar{x}_i = \frac{\sum_{i=1}^{m} x_{ij}}{n}$;

$i = 1,2,3,...,m;\ \ j = 1,2,3,...,\mathrm{n}$

สำหรับค่าสถิติ C_i นั้นจะแบ่งเป็น 2 ค่า ดังนี้

ผลรวมสะสมทางด้านมากกว่า คือ

$$C_i^+ = \max\left\{0, x_i - (\mu_0 + K) + C_{i-1}^+\right\}$$

ผลรวมสะสมทางด้านน้อยกว่า คือ

$$C_i^- = \max\left\{0, (\mu_0 + K) - x_i + C_{i-1}^+\right\}$$

โดยที่

K มีค่าเท่ากับครึ่งหนึ่งของขนาดการเปลี่ยนแปลงของค่าเฉลี่ย นั่นคือ $K = \frac{\delta}{2}\sigma = \frac{|\mu_1 - \mu_0|}{2}$ และ μ_1 เป็นค่าเฉลี่ยของกระบวนการที่เปลี่ยนไปซึ่ง $\mu_1 = \mu_0 + \delta\sigma$ หรือ $\delta = \frac{|\mu_1 - \mu_0|}{\sigma}$

ส่วนค่าเริ่มต้นของ C_0^+ และ C_0^- กำหนดให้มีค่าเท่ากับ 0 เสมอ

สำหรับขีดจำกัดควบคุมของแผนภูมิควบคุม CUSUM คือ H หรือ $-H$ ถ้าค่าสถิติที่นำมาพล็อตลงในแผนภูมิมีค่ามากกว่า H หรือน้อยกว่า $-H$ แล้ว กระบวนการนั้นจะออกนอกการควบคุม ซึ่งคำนวณค่า H ได้ดังนี้

$$H = h\sigma$$

โดยที่

h คือ เป็นพารามิเตอร์ของขีดจำกัดควบคุมแผนภูมิควบคุม CUSUM

σ คือ ค่าเบี่ยงเบนมาตรฐานของกระบวนการ

ขีดจำกัดควบคุมของแผนภูมิควบคุม คือ

$$UCL / LCL = \pm H$$

โดยที่ H คือ สัมประสิทธิ์ของขีดจำกัดควบคุม

2.4 แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง (exponentially weighted moving average control chart : EWMA)

เป็นแผนภูมิที่ตรวจจับสภาพการเปลี่ยนแปลงไปของกระบวนการผลิต เมื่อมีการเปลี่ยนแปลงเกิดขึ้นเพียงเล็กน้อย โดยนิยามของค่าสถิติของแผนภูมิ และขีดจำกัดควบคุมมีสมการ ดังนี้

ค่าสถิติของแผนภูมิควบคุม EWMA คือ

$$Z_i = \lambda x_i + (1-\lambda) Z_{i-1}$$

โดยที่

λ คือ พารามิเตอร์ถ่วงน้ำหนักของแผนภูมิควบคุม ; $0 < \lambda \le 1$

x_i คือ ค่าคุณสมบัติของผลิตภัณฑ์สำหรับตัวอย่างที่ a

Z_{i-1} คือ อนุกรมของข้อมูลในอดีต โดยกำหนดค่าเริ่มต้น (Z_0) เท่ากับ μ_0

ขีดจำกัดควบคุมของแผนภูมิควบคุม คือ

$$UCL / LCL = \mu_0 \pm L\sigma \cdot \sqrt{\frac{\lambda}{(2-\lambda)}\left[1-(1-\lambda)^{2i}\right]}$$

โดยที่

μ_0 คือ ค่าเฉลี่ยของค่าคุณสมบัติของผลิตภัณฑ์ของประชากร

σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของค่าคุณสมบัติของผลิตภัณฑ์ของประชากร

L คือ สัมประสิทธิ์ของขีดจำกัดควบคุม

3. การดำเนินวิจัย

3.1 ขอบเขตงานวิจัย

1) กำหนดพารามิเตอร์ของข้อมูล โดยที่ $\lambda = 1,\ 5,\ 10,\ 20$
2) กำหนดจำนวนตัวอย่างย่อย โดยที่ $n = 1,\ 5,\ 10,\ 20$
3) กำหนดระดับการเปลี่ยนแปลง โดยที่
   - $\delta = 0$ สำหรับกระบวนการไม่มีการเปลี่ยนแปลง
   - $\delta = 0.01, 0.025, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5$ สำหรับกระบวนการมีการเปลี่ยนแปลงขนาดเล็ก
   - $\delta = 1,2,3$ สำหรับกระบวนการมีการเปลี่ยนแปลงขนาดใหญ่
4) กำหนดค่าถ่วงน้ำหนักของแผนภูมิควบคุม EWMA เท่ากับ 0.3
5) กำหนด $ARL_0 = 276$

3.2 ขั้นตอนงานวิจัย

1) สร้างข้อมูลที่มีการแจกแจงปัวซง
2) คำนวนค่าสถิติของแผนภูมิควบคุม
3) คำนวนขีดจำกัดควบคุมของแผนภูมิควบคุม
4) คำนวนค่า RL
5) ทำซ้ำข้อ 1) – 4) ทั้งหมด 10,000 ครั้ง
6) คำนวนค่า ARL โดยที่
   - เมื่อกำหนด $\delta = 0$ จะได้ว่า $ARL = ARL_0$
   - เมื่อกำหนด $\delta \neq 0$ จะได้ว่า $ARL = ARL_1$
7) เปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม โดยแผนภูมิที่มีประสิทธิภาพดีที่สุดเมื่อมีค่าความยาวรันเฉลี่ยต่ำที่สุด

4. ผลการวิจัย

ผลการวิเคราะห์ประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของแผนภูมิควบคุมทั้ง 4 แผนภูมิ ด้วยค่าความ

ยาวรันเฉลี่ย สามารถตรวจจับความเปลี่ยนแปลงที่เกิดขึ้นในกระบวนการสามารถอธิบายผลได้ดังนี้

- สำหรับ $\lambda = 1$ และ $n = 1$ พบว่าในช่วงการเปลี่ยนแปลง $\delta < 0.01$ หรือ $\delta > 3.00$ แผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง มีประสิทธิภาพในการตรวจจับดีที่สุด และในช่วงการเปลี่ยนแปลง $0.01 < \delta < 3.00$ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง มีประสิทธิภาพในการตรวจจับดีที่สุด
- สำหรับ $\lambda = 5$ และ $n = 5$ พบว่าในช่วงการเปลี่ยนแปลง $0.01 \le \delta \le 2.00$ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง มีประสิทธิภาพในการตรวจจับดีที่สุด และในช่วงการเปลี่ยนแปลง $\delta > 3.00$ แผนภูมิควบคุมจำนวนรอยตำหนิ มีประสิทธิภาพในการตรวจจับดีที่สุด
- สำหรับ $\lambda = 10$ และ $n = 10$ พบว่าในช่วงการเปลี่ยนแปลง $0.01 \le \delta \le 2.00$ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง มีประสิทธิภาพในการตรวจจับดีที่สุด และในช่วงการเปลี่ยนแปลง $\delta > 3.00$ แผนภูมิควบคุมจำนวนรอยตำหนิ มีประสิทธิภาพในการตรวจจับดีที่สุด
- สำหรับ $\lambda = 20$ และ $n = 20$ พบว่าในทุกช่วงการเปลี่ยนแปลง δ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง มีประสิทธิภาพในการตรวจจับดีที่สุด

จากข้างต้นพบว่าแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง จะมีประสิทธิภาพมากที่สุดในทุกกรณีของช่วงการเปลี่ยนแปลง δ ขนาดเล็ก ในทางกลับกันแผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง มีประสิทธิภาพมากที่สุดในการเปลี่ยนแปลง δ ขนาดใหญ่ กรณี $\lambda = 1$ และ $n = 1$ และแผนภูมิควบคุมจำนวนรอยตำหนิ มีประสิทธิภาพมากที่สุดในการเปลี่ยนแปลง δ ขนาดใหญ่ กรณี $\lambda = 5$, $n = 5$ และ $\lambda = 10$, $n = 10$ โดยผลการวิเคราะห์ประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงที่เกิดขึ้นแสดงดังตารางที่ 4-1

ตารางที่ 4-1 : ค่า ARL ของแผนภูมิควบคุมทั้ง 4 แผนภูมิ กำหนดให้ $n = 1,5,10,20$ และภายใต้กระบวนการที่ค่าสังเกตการแจกแจงปัวซง $\lambda = 1,5,10,20$

λ	แผนภูมิควบคุม	ระดับความเปลี่ยนแปลงของกระบวนการ											
		0.000	0.010	0.025	0.050	0.100	0.200	0.300	0.400	0.500	1.000	2.000	3.000
1	C-chart	275.348	260.056	245.733	224.865	182.997	129.368	93.964	69.792	54.372	18.961	5.386	2.734
	Exact	276.172	**258.870**	246.212	222.461	180.696	124.842	91.608	68.906	52.314	18.884	5.367	**2.647**
	Cusum	276.054	272.989	267.239	240.396	189.269	115.589	81.283	62.603	50.718	26.113	13.379	9.149
	Ewma	275.379	260.341	**233.726**	**203.484**	**154.132**	**90.942**	**59.350**	**40.888**	**30.536**	**10.517**	**4.218**	2.741
5	C-chart	275.499	260.481	249.743	233.042	199.240	146.590	110.412	82.282	63.281	20.492	4.346	**1.810**
	Exact	275.901	271.560	260.558	236.839	202.346	148.981	109.740	85.850	64.831	20.895	4.350	1.863
	Cusum	275.688	276.325	271.818	246.620	191.620	115.027	80.096	61.354	49.974	25.628	13.172	8.950
	Ewma	276.239	**257.719**	**238.916**	**204.074**	**154.131**	**93.652**	**59.452**	**40.630**	**29.461**	**9.456**	**3.573**	2.292
10	C-chart	275.395	267.978	254.871	234.896	204.827	151.428	115.698	87.561	67.407	22.082	4.520	**1.885**
	Exact	275.677	261.613	254.428	234.373	200.361	150.575	114.211	86.041	67.051	21.308	4.519	1.858
	Cusum	275.726	271.692	262.864	242.138	188.664	112.874	79.200	60.813	49.322	25.240	12.955	8.805
	Ewma	275.913	**258.921**	**240.782**	**207.624**	**155.411**	**92.384**	**57.335**	**38.699**	**27.379**	**8.567**	**3.121**	1.995
20	C-chart	275.613	265.331	253.735	237.080	200.008	152.061	118.291	90.924	71.344	23.871	5.249	2.324
	Exact	275.564	269.672	254.933	239.799	207.292	157.096	120.832	93.011	73.480	25.643	6.205	2.903
	Cusum	275.631	273.243	266.608	245.514	187.927	113.496	80.496	60.949	49.713	25.489	13.100	8.914
	Ewma	275.565	**256.729**	**236.745**	**203.176**	**154.770**	**89.616**	**57.098**	**39.145**	**27.095**	**8.474**	**3.103**	**1.977**

5. สรุปผลการวิเคราะห์

ผลการวิจัยพบว่าประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง สามารถอธิบายได้ดังนี้ ในทุกกรณีของ λ และ n แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง δ ขนาดเล็ก ได้ดีกว่าแผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง แผนภูมิควบคุมจำนวนรอยตำหนิ และแผนภูมิควบคุมผลรวมสะสมโดยที่ ในกรณี $\lambda = 1$ และ $n = 1$ แผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง δ ขนาดใหญ่ ได้ดีกว่าแผนภูมิควบคุมจำนวนรอยตำหนิ แผนภูมิควบคุมผลรวมสะสม และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง และในกรณี $\lambda = 5$, $n = 5$ และ $\lambda = 10$, $n = 10$ แผนภูมิควบคุมจำนวนรอยตำหนิ มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลง δ ขนาดใหญ่ ได้ดีกว่าแผนภูมิควบคุมด้วยช่วงความเชื่อมั่นของการแจกแจงปัวซง แผนภูมิควบคุมผลรวมสะสม และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักเลขชี้กำลัง

สำหรับข้อเสนอแนะสำหรับงานวิจัย มีข้อเสนอดังนี้

- งานวิจัยนี้ควรมีการศึกษาจำนวนตัวอย่างย่อย เพิ่มเติมในกรณีอื่น และทำการเปรียบเทียบประสิทธิภาพกับแผนภูมิควบคุมอื่น เพื่อให้ได้ผลลัพธ์ที่สามารถนำมาประยุกต์ใช้ให้เกิดประโยชน์และเหมาะสมที่สุด หรือเป็นแนวทางในการหาประสิทธิภาพที่ดีต่อไป
- งานวิจัยนี้เป็นเพียงการสุ่มทดลองข้อมูลจากโปรแกรมเท่านั้น ผู้ที่สนใจสามารถนำวิธีการในงานวิจัยนี้ไปปรับใช้กับข้อมูลจริงได้

6. เอกสารอ้างอิง

[1] W.A. Shewhart. Quality control charts. Bell Syst. Tech. J. 5 1926; 593–603.

[2] Garwood. F. Fiducial limits for the Poisson distribution. Biometrics. 1936; 28:437-442.

[3] Lucas, J.M. Counted data CUSUM's. Technometrics. 1985; 27:129-144.

[4] TSAI, Tzong-Ru; YEN, Wen-Pin. Exponentially weighted moving average control charts for three-level products. Statistical Papers, 2011, 52: 419-429.

แผนภูมิควบคุม FIR-EWMA เพื่อตรวจสอบการเปลี่ยนแปลงสำหรับการแจกแจงเรย์ลีย์

The FIR-EWMA Control Chart to Monitor Changes for Rayleigh Distributions

จิรัชญา ชื่นชม[1] ธนภรณ์ ดำรงกิจภากร[1*] วัชราภรณ์ กูกู้มาตร[1] วิลาสินี ปีระจิตร[1] ปิยพล ไพจิตร[2]

[1]*ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ*

[2]*ภาควิชาสถิติ มหาวิทยาลัยศิลปากร วิทยาเขตพระราชวังสนามจันทร์นครปฐม*

(**s6404052630209@email.kmutnb.ac.th*)

บทคัดย่อ

การวิจัยในครั้งนี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (EWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบแบบเลขชี้กำลังสองครั้ง (DEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังตอบสนองขั้นต้นอย่างรวดเร็ว (FIR-EWMA) สำหรับตรวจจับการเปลี่ยนแปลงพารามิเตอร์บ่งขนาด (σ_1) ของข้อมูลที่มีการแจกแจงแบบเรย์ลีย์ เกณฑ์ที่ใช้ในการเปรียบเทียบประสิทธิภาพจะพิจารณาจากค่าความยาวรันเฉลี่ยเมื่อกระบวนการไม่อยู่ภายใต้การควบคุม (ARL_1) และกำหนดให้ค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) คือ370 จำลองแต่ละสถานการณ์ด้วยวิธีมอนติคาร์โล (Monte Carlo) โดยใช้โปรแกรม R Studio กำหนดค่าคงที่ปรับเรียบสำหรับแผนภูมิควบคุมEWMA DEWMA และแผนภูมิควบคุม FIR-EWMA (λ_1) คือ 0.01, 0.02 ,0.03 และ 0.04 กำหนดค่าคงที่ปรับเรียบสำหรับแผนภูมิควบคุม DEWMA (λ_2) คือ 0. 5 กำหนดให้ขนาดตัวอย่างจำนวน 1,000 และการทดลองซ้ำ 35,000 ตามลำดับ พารามิเตอร์บ่งขนาดเมื่อกระบวนการอยู่ภายใต้การควบคุม (σ_0) คือ 0.1, 0.3 และ 0.5 ตามลำดับ กำหนดขนาดการเปลี่ยนแปลง (δ) เมื่อกระบวนการไม่อยู่ภายใต้การควบคุม ($\sigma_1 = \sigma_0 + \delta$) คือ 0.01, 0.03, 0.05, 0.07, 0.1, 0.3 และ 0.5 ตามลำดับ สำหรับการเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมจะพิจารณาจากค่า ARL_1 ต่ำสุด แสดงว่าแผนภูมิควบคุมนั้นสามารถตรวจจับการเปลี่ยนแปลงได้เร็วสุด และมีประสิทธิภาพดีที่สุด

ผลการวิจัย พบว่า เมื่อการเปลี่ยนแปลงขนาดเล็ก ($0.01 \le \delta \le 0.5$) ค่า ARL_1 ของแผนภูมิควบคุม FIR-EWMA จะลดลงอย่างรวดเร็ว และสำหรับทุกๆขนาดการเปลี่ยนแปลงค่า ARL_1 แผนภูมิควบคุม FIR-EWMA มีค่าต่ำที่สุด นั่นคือแผนภูมิควบคุม FIR-EWMA มีประสิทธิภาพดีที่สุดสำหรับสถานการณ์ที่กำหนดนี้

คำสำคัญ (Keywords): การแจกแจงเรย์ลีย์, แผนภูมิควบคุม EWMA, แผนภูมิควบคุม DEWMA, แผนภูมิควบคุม FIR-EWMA , ความยาวรันเฉลี่ย

Abstract

This research objective is to examine and compare the performance of the Exponentially Weighted Moving Average (EWMA) control chart, the Double Exponentially Weighted Moving Average (DEWMA) control chart, and the Fast Initial Response Exponentially Weighted Moving Average (FIR-EWMA) control chart for detecting changes in the scale parameter (σ_1) of Rayleigh-distributed data. The performance comparison is based on the average run length when the process is out of control (ARL_1), with the average run length when the process is in control (ARL_0) set at 370 .Monte Carlo simulations were conducted using R Studio. The smoothing constant for the EWMA DEWMA and FIR-EWMA control charts (λ_1) was set at 0.01, 0.02, 0.03 and 0.04, and the smoothing constant (α) for the DEWMA control chart (λ_2)was set at 0.5. The sample size were set at 1,000 and number of repetitions were set and 35,000, respectively. The scale parameter when the process is in control (σ_0) was set at

0.1, 0.3, and 0.5, and the magnitude of the change (δ) when the process is out of control ($\sigma_1 = \sigma_0 + \delta$) was set at 0.01, 0.03, 0.05, 0.07, 0.1, 0.3 และ 0.5, respectively for the comparison of control chart performance, the minimum ARL_1 value indicates the fastest change detection and the best performance.

The results showed that for small changes ($0.01 \le \delta \le 0.5$), the ARL_1 FIR-EWMA control chart decreased rapidly. For all magnitudes of change, the FIR-EWMA control chart had the lowest. ARL_1 Value, indicating that the FIR-EWMA control chart had the best performance for the given scenarios.

Keywords: Rayleigh-distributed, The Exponentially Weighted Moving Average control chart (EWMA), The Double Exponentially Weighted Moving Average control chart (DEWMA), The Fast Initial Response Exponentially Weighted Moving Average control chart (FIR-EWMA), Average Run Length

1. บทนำ

การรักษาคุณภาพของผลิตภัณฑ์และกระบวนการผลิตเป็นสิ่งสำคัญเพราะจะทำให้สามารถสร้างผลิตภัณฑ์ที่ได้มาตรฐานตรงตามความต้องการของผู้บริโภค ในกระบวนการผลิตอาจมีความผันแปรเกิดขึ้นและส่งผลต่อคุณภาพโดยตรงต่อการผลิต ความผันแปรที่เกิดขึ้นอาจมีสาเหตุมาจากความไม่ระมัดระวังของพนักงาน หรือการใช้งานเครื่องจักรนานเกินไป ความผันแปรนี้ผู้ผลิตยอมรับให้เกิดขึ้นได้เนื่องจากยากต่อการควบคุมและเรียกความผันแปรลักษณะนี้ว่า ความผันแปรแบบสุ่ม (Chance Variation) ส่วนความผันแปรที่ไม่ได้เกิดจากความบังเอิญ หากแต่เกิดจากสาเหตุต่าง ๆ ที่สามารถระบุได้และสามารถนำไปแก้ไขปรับปรุงได้ สาเหตุดังกล่าวอาจเกิดจากการใช้เครื่องจักรที่แตกต่างกัน การใช้วัตถุดิบแตกต่างกัน ความแตกต่างกันระหว่างคนงาน เรียกความผันแปรลักษณะนี้เรียกว่า ความผันแปรที่ทราบสาเหตุ (Assignable Variation) โดยเฉพาะอย่างยิ่งความผันแปรนี้ถือว่ามีความสำคัญต่อการรักษามาตรฐานของผลิตภัณฑ์ที่ผลิตขึ้นหากไม่มีการควบคุมจะส่งผลต่อระบบการผลิตและผลิตภัณฑ์ การควบคุมกระบวนการเชิงสถิติ (Statistical Process Control : SPC) เป็นการรวบรวมเครื่องมือในการแก้ปัญหาที่มีประสิทธิภาพ โดยจะไปลดความผันแปรที่เกิดขึ้นส่งผลให้กระบวนการผลิตและผลิตภัณฑ์มีความเสถียร (Stable) ยิ่งขึ้น

การควบคุมคุณภาพของกระบวนการทางสถิติสามารถทำได้โดยใช้แผนภูมิควบคุม (Control Charts) ซึ่งเป็นเครื่องมือทั่วไปที่ใช้ในการควบคุมคุณภาพของกระบวนการผลิต ในปี ค.ศ.1920 Walter A. Shewhart[1] ได้พัฒนาแผนภูมิควบคุม (Control Chart) และได้นำหลักทฤษฎีทางสถิติมาช่วยในการแก้ปัญหาเกี่ยวกับการควบคุมคุณภาพ โดยสร้างแผนภูมิสำหรับการควบคุมที่เรียกว่า แผนภูมิควบคุมของชิวฮาร์ท (Shewhart Control Chart) แบ่งออกเป็น 2 ชนิด แผนภูมิควบคุมเชิงปริมาณ (Variable Control Chart) เป็นแผนภูมิที่ได้จากการวัดข้อมูลในลักษณะต่อเนื่อง (Continuous Value) ได้แก่ แผนภูมิควบคุมค่าเฉลี่ย ($\bar{X}$ -Chart) แผนภูมิควบคุมพิสัย (R-Chart) เป็นต้น และแผนภูมิควบคุมเชิงคุณภาพ (Attribute Control chart) เป็นแผนภูมิที่ได้จากการวัดข้อมูลในลักษณะไม่ต่อเนื่อง ได้แก่ การควบคุมจำนวนรอยตำหนิ (c-chart) การควบคุมสัดส่วนของเสีย (p-chart) เป็นต้น แต่อย่าไรก็ตามประสิทธิภาพของ Shewhart จะมีประสิทธิภาพสูงเมื่อข้อมูลมีการแจงแจกแบบปกติ (normal distribution) แต่ในกรณีที่ข้อมูลไม่ได้มีการแจกแจงปกติ หรือมีลักษณะผิดปกติ (เช่น skewed data หรือ heavy-tailed distribution) การใช้แผนภูมิแบบ Shewhart อาจไม่ได้ผลดีนัก

แผนภูมิควบคุมผลรวมสะสม (CUSUM-chart) ถูกคิดค้นครั้งแรกปี ค.ศ.1954 โดย Page[2] แผนภูมิควบคุมนี้เป็นเครื่องมือสำคัญในการควบคุมคุณภาพโดยสามารถตรวจจับการเปลี่ยนแปลงในกระบวนการผลิตที่มีลักษณะเบี่ยงเบนเล็ก ๆ และค่อยเป็นค่อยไปได้อย่างมีประสิทธิภาพ Duncan (1974), Lucas (1976), Hawkins (1990) กล่าวว่า แผนภูมิ CUSUM มีประสิทธิภาพดีกว่า $\bar{X}$ -Chart ต่อมาในปี ค.ศ.1959 Roberts[3] นำเสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponential Weighted Moving Average Control Chart : EWMA chart) แผนภูมิควบคุมนี้มีประสิทธิภาพดีในการตรวจจับกระบวนการผลิต เมื่อกระบวนการมีการเปลี่ยนแปลงขนาดเล็กโดยในปี ค.ศ.1990 Lucas and Saccucci[4] ได้ทำการเปรียบเทียบและนำเสนอว่าแผนภูมิควบบคุม EWMA เป็นทางเลือกที่ดีกว่าในการตรวจจับการเปลี่ยนแปลงขนากเล็ก

ในปี ค.ศ. 1994 Butler และ Stefani[5] ได้นำเสนอ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังสองครั้ง (DEWMA) ซึ่งพัฒนามาจาก แผนภูมิควบคุม EWMA โดยทำการถ่วงน้ำหนักซ้ำเป็นครั้งที่สองของแผนภูมิควบคุม EWMA ซึ่งทำให้สามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กได้ดีกว่า ในปี ค.ศ. 2013 Alkahtani[6] ได้เปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม DEWMA และแผนภูมิควบคุม EWMA โดยผลการศึกษาพบว่า แผนภูมิควบบคุม DEWMA มีประสิทธิภาพดีกว่าแผนภูมิควบคุม EWMA ในการตรวจจับการเปลี่ยนแปลงที่มีขนาดเล็ก ในปี ค.ศ.1999 Steiner [7] ได้เสนอแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังตอบสนองขั้นต้นอย่างรวดเร็ว (Exponentially Weighted Moving Average control chart with Fast Initial Response : FIR-EWMA) เป็นเครื่องมือที่ใช้ในการตรวจจับและควบคุม

คุณภาพของกระบวนการผลิตโดยเพิ่มค่าการปรับ FIR เพื่อให้การควบคุมขีดจำกัด (Control Limit) ของแผนภูมิควบคุม EWMAแคบลง ทำให้เพิ่มความไวในการตรวจจับการเปลี่ยนแปลงในช่วงเริ่มต้นของกระบวนการได้เร็วขึ้น

ดังนั้นในงานวิจัยนี้จึงสนใจเปรียบเทียบ ประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงขนาดเล็กของ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average Control Chart : EWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบแบบเลขชี้กำลังสองครั้ง (DEWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเริ่มต้นตอบสนองเร็ว (FIR-EWMA) โดยพิจารณาจากประสิทธิภาพของแผนภูมิควบคุมจากค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่นอกการควบคุม (Out of control Average Run Length : ARL) โดยแผนภูมิที่มีค่า ARL_1 ต่ำที่สุดจะเป็นแผนภูมิที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงพารามิเตอร์บ่งขนาดของกระบวนการได้ดีที่สุด เมื่อกำหนดภายใต้ $ARL_0 = 370$ ซึ่งผลลัพธ์ของการเปรียบเทียบแผนภูมิต่างๆจะเป็นแนวทางในการเลือกใช้แผนภูมิที่เหมาะสมในการตรวจจับการเปลี่ยนแปลงในอนาคตและเป็นประโยชน์ให้แก่ผู้สนใจศึกษาต่อไป

2. วิธีการวิจัย

การเปรียบเทียบภาพแผนภูมิควบคุมคุณภาพในการตรวจพบการเปลี่ยนแปลงพารามิเตอร์บ่งขนาดของกระบวนการแจกแจงเรย์ลีย์ โดยเปรียบเทียบแผนภูมิควบคุมคุณภาพ 3 ชนิด ได้แก่ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลัง (Exponentially Weighted Moving Average Control Chart : EWMA) แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบแบบเลขชี้กำลังสองครั้ง (DEWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเริ่มต้นตอบสนองเร็ว (FIR-EWMA) โดยมีขั้นตอนการวิจัย ดังต่อไปนี้

2.1 กำหนดค่าพารามิเตอร์ของแผนภูมิควบคุม

แผนภูมิควบคุม EWMA แผนภูมิควบคุม DEWMA และแผนภูมิควบคุม FIR-EWMA มีค่าพารามิเตอร์ในการปรับให้เรียบ(λ_1) เท่ากับ 0.01, 0.02, 0.03 และ 0.04 ค่าพารามิเตอร์ในการปรับให้เรียบ (λ_2) เท่ากับ 0.05 สำหรับแผนภูมิควบคุม DEWMA ค่าขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) เท่ากับ 0.01, 0.03, 0.05, 0.07, 0.1, 0.3 และ 0.5 ค่าพารามิเตอร์บ่งขนาด เท่ากับ 0.1, 0.3 และ 0.5

2.2 สร้างข้อมูลเพื่อใช้ในการวิเคราะห์

ใช้โปรแกรม R studio จำลองข้อมูลด้วยเทคนิคมอนติคาร์โล โดยในแต่ละสถานการณ์ทดลองซ้ำ 35,000 ครั้ง

2.3 สร้างข้อมูล x_i โดยให้ $x_i \sim Ra(\sigma)$

$$f(x,\sigma) = \frac{x}{\sigma^2} e^{\frac{x^2}{2\sigma^2}} \quad (1)$$

โดย x_i คือ ค่าของตัวแปรสุ่ม เมื่อกระบวนการอยู่ในการควบคุม ณ เวลาที่ i ; σ คือ ค่าพารามิเตอร์บ่งขนาด

2.4 กำหนดขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) ทั้งหมด 5 ขนาด 0.01, 0.03, 0.05, 0.07, 0.1, 0.3 และ 0.5

2.5 จำลองข้อมูลที่ใช้ในการวิเคราะห์

2.5.1 กรณีที่ (x_i) กรณีที่อยู่ภายใต้การควบคุม เมื่ออยู่ในกระบวนการควบคุมสร้างข้อมูล x_i ให้มีการแจกแจง $x_i \sim Ra(\sigma)$ โดยขนาดตัวอย่าง (n) เท่ากับ 1,000 ค่าความยาวรันเฉลี่ย ARL_0 เท่ากับ 370 [9] [10]

2.5.2 กรณีที่ (x_i) เมื่ออยู่นอกกระบวนการควบคุมสร้าง ข้อมูล x_i ให้มีการแจกแจง $x_i \sim Ra(\sigma)$ เมื่อกำหนดขนาดการเปลี่ยนแปลงเท่ากับ $\sigma_1 = \sigma + \delta$ เมื่อ δ มีค่าดังนี้ และขนาดตัวอย่าง (n) เท่ากับ 1,000 ค่าความยาวรันเฉลี่ย ARL_0 เท่ากับ 370

2.6 นำข้อมูลที่ได้จากการจำลองในข้อ 2.5 มาคำนวณค่าสถิติของแผนภูมิควบคุม EWMA แผนภูมิควบคุม DEWMA และ แผนภูมิควบคุม FIR-EWMA

2.6.1 คำนวณค่า Z_i ของแผนภูมิควบคุม EWMA [11] ดังสมการ

$$Z_i = \lambda_1 X_i + (1-\lambda_1) Z_{i-1} \quad (2)$$

โดย Z_i คือ ค่าสถิติของแผนภูมิควบคุม EWMA ณ เวลาที่ i, X_i คือ ค่าสังเกต ณ เวลาที่ i, λ_1 คือ ค่าพารามิเตอร์ในการปรับให้เรียบ, Z_{i-1} คือ ค่าเริ่มต้นของสถิติ EWMA

2.6.2 คำนวณค่า W_i และ Y_i ของแผนภูมิควบคุม DEWMA [11] ดังสมการ

$$W_i = \lambda_2 X_i + (1-\lambda_2) W_{i-1} \quad (3)$$

$$Y_i = \lambda_1 W_i + (1-\lambda_1) Y_{i-1}; i = 1,2,..,$$

โดย W_i คือ ค่าสถิติของแผนภูมิควบคุม DEWMA, λ_2 คือ ค่าพารามิเตอร์ในการปรับให้เรียบของแผนภูมิควบคุม DEWMA, X_i คือ ค่าสังเกต ณ เวลาที่ i, W_{i-1} คือ ค่าเริ่มต้นของสถิติ DEWMA, Y_i คือ ค่าสถิติของแผนภูมิควบคุม EWMA ณ เวลาที่ i, λ_1 คือ ค่าพารามิเตอร์ในการปรับให้เรียบ, Y_{i-1} คือ ค่าเริ่มต้นของสถิติ EWMA

2.6.3 คำนวณค่า FIR ของแผนภูมิควบคุม FIR-EWMA [7] ดังสมการ

$$FIR = 1 - (1-f)^{1+a(i-1)} \quad (4)$$

โดยกำหนดค่า $a = 0.3$ และ $f = 0.5$ (อ้างอิงจากวิจัยของ Stefan H. Steiner [7]), λ คือ ค่าพารามิเตอร์ในการปรับให้

เรียบ, δ คือ ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ และ σ คือ ค่าพารามิเตอร์บ่งขนาด ตามที่กำหนดไว้ในข้อ 2.1

2.7 คำนวณขีดจำกัดควบคุมของแผนภูมิควบคุม EWMA แผนภูมิควบคุม DEWMA แผนภูมิควบคุม FIR-EWMA

2.7.1 คำนวณขีดจำกัดควบคุมของแผนภูมิควบคุม EWMA [11] คือ LCL และ UCL ดังสมการ

$$LCL = \mu_0 - L_1\sigma\sqrt{\left(\frac{\lambda}{2-\lambda}\right)} \quad (5)$$

$$UCL = \mu_0 + L_1\sigma\sqrt{\left(\frac{\lambda}{2-\lambda}\right)} \quad (6)$$

โดยที่ LCL คือ ค่าขีดจำกัดควบคุมบน, UCL คือ ค่าขีดจำกัดควบคุมล่าง, μ_0 คือ ค่าเฉลี่ยของกระบวนการ, λ ค่าพารามิเตอร์ในการปรับให้เรียบ, L_1 คือ ความกว้างขีดจำกัดควบคุมสำหรับ EWMA, σ คือ ค่าพารามิเตอร์บ่งขนาด

2.7.2 คำนวณขีดจำกัดควบคุมของแผนภูมิควบคุม DEWMA [11] คือ LCL และ UCL ดังสมการ

$$LCL = \mu_0 - L_2\sigma\sqrt{\frac{\lambda_1^2\lambda_2^2}{(\lambda_1-\lambda_2)^2}\left[\frac{(1-\lambda_2)^2}{1-(1-\lambda_2)^2}+\frac{(1-\lambda_1)^2}{1-(1-\lambda_1)^2}-2\frac{(1-\lambda_1)(1-\lambda_2)}{1-(1-\lambda_1)(1-\lambda_2)}\right]} \quad (7)$$

$$UCL = \mu_0 + L_2\sqrt{\frac{\lambda_1^2\lambda_2^2}{(\lambda_1-\lambda_2)^2}\left[\frac{(1-\lambda_2)^2}{1-(1-\lambda_2)^2}+\frac{(1-\lambda_1)^2}{1-(1-\lambda_1)^2}-2\frac{(1-\lambda_1)(1-\lambda_2)}{1-(1-\lambda_1)(1-\lambda_2)}\right]} \quad (8)$$

โดยที่ LCL คือ ค่าขีดจำกัดควบคุมบน, UCL คือ ค่าขีดจำกัดควบคุมล่าง, μ_0 คือ ค่าเฉลี่ยของกระบวนการ, λ และ λ_2 คือ ค่าพารามิเตอร์ในการปรับให้เรียบ, L_2 คือ ความกว้างขีดจำกัดควบคุมสำหรับ DEWMA 2.7.3 คำนวณขีดจำกัดควบคุมของแผนภูมิควบคุม FIR-EWMA [12] คือ LCL และ UCL ดังสมการ

$$LCL = \mu_0 - L_3\left\{1-(1-f)^{1+a(i-1)}\right\}\sigma^2_{Z_i}$$

(9) $$UCL = \mu_0 + L_3\left\{1-(1-f)^{1+a(i-1)}\right\}\sigma^2_{Z_i} \quad (10)$$

กำหนดให้ $a = 0.3$ และ $f = 0.5$ (อ้างอิงจากวิจัยของ Stefan H. Steiner [7]) , โดยที่ LCL คือ ค่าขีดจำกัดควบคุมบน, UCL คือ ค่าขีดจำกัดควบคุมล่าง, μ_0 คือ ค่าเฉลี่ยของกระบวนการ, L_3 คือ ความกว้างขีดจำกัดควบคุมสำหรับ FIR-EWMA, σ_{Z_i} คือ ค่าค่าพารามิเตอร์บ่งขนาดของ EWMA

2.8 นำค่าสถิติที่คำนวณได้ของทั้ง 3 แผนภูมิควบคุม

ใน ข้อ 2.6 มาเปรียบเทียบกับขีดจำกัดควบของแต่ละแผนภูมิ ในข้อ 2.7 เพื่อหาจำนวนหน่วยตัวอย่างที่อยู่ภายใต้การควบคุมจนกระทั่งพบว่ากระบวนการออกนอกขีดจำกัดควบคุมเป็นครั้งแรก เรียกว่า ค่าความยาวรันเฉลี่ย (ARL_1)

2.9 คำนวณค่า ARL แบ่งเป็น 2 กรณี คือ

2.9.1 กรณีที่กระบวนการอยู่ภายใต้การควบคุม (In-of-Control) นำค่า RL_i จากข้อ 2.8 มาหาค่า ARL_0 [8] ดังนี้

$$ARL = \frac{\sum_{i=1}^{35,000} RL_i}{35,000} \quad (11)$$

โดยที่ RL_i คือ จำนวนครั้งในการสุ่มตัวอย่างที่จะพบว่าอยู่ในกระบวนการควบคุมจนกระทั่งพบว่ากระบวนการออกนอกขีดจำกัดควบคุมเป็นครั้งแรกในการจำลองข้อมูลครั้งที่ $t; t = 1,2,..,35,000$ และส่วนเบี่ยงเบนมาตรฐานความยาวรัน (Standard Deviation of Length: SDRL) [13] ดังนี้

$$SDRL = \sqrt{\frac{\sum_{i=1}^{35,000}(RL_i - ARL)^2}{35,000-1}} \quad (12)$$

โดยที่ RL_i คือ จำนวนครั้งในการสุ่มตัวอย่างที่จะพบว่าอยู่ในกระบวนการควบคุมจนกระทั่งพบว่ากระบวนการออกนอกขีดจำกัดควบคุมเป็นครั้งแรกในการจำลองข้อมูลครั้งที่ $t; t = 1,2,..,35,000$

2.9.2 กรณีที่กระบวนการไม่อยู่ภายใต้การควบคุม (Out-of-Control) นำค่า RL_i จากข้อ 2.8 ที่ $ARL_0 = 370$ หาค่า ARL_1

3. ผลการวิจัยและอภิปรายผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพระหว่างแผนภูมิควบคุม EWMA, DEWMA และ FIR-EWMA สำหรับการตรวจจับขนาดการเปลี่ยนแปลงพารามิเตอร์บ่งรูปร่างของการแจกแจงแบบเรย์ลีย์

จากตาราง 1 กรณี $\sigma = 0.1, 0.3, 0.5$, $\lambda_1 = 0.01$ และ $\lambda_2 = 0.5$ ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) = 0.01,0.03,0.05,0.07,0.1,0.3,0.5 พบว่าเมื่อ δ ต่ำ (0.01) ค่า ARL_1 สูงในทุกแบบจำลอง แต่ แผนภูมิควบคุมFIR-EWMA มีค่า ARL_1 ต่ำสุด (57.123) และ $SDRL_1$ ต่ำสุด (84.693) บ่งชี้ถึงความไวและเสถียรภาพของการตอบสนอง เมื่อ δ เพิ่มขึ้น (0.03–0.1) ค่า ARL_1 ลดลงทุกแบบแผนภูมิควบคุม FIR-EWMA ยังคงต่ำสุดและ $SDRL_1$ คงที่แสดงถึงความสม่ำเสมอในการตรวจจับ โดยตั้งแต่ค่า $\delta = 0.03 - 0.05$ แผนภูมิควบคุม DEWMA มีค่า ARL_1 สูงกว่าแผนภูมิควบคุมEWMA เฉพาะที่ค่าพารามิเตอร์บ่งขนาด 0.3 และ δ สูง (0.3–0.5) แผนภูมิควบคุมFIR-EWMA ตรวจจับได้

เร็วที่สุด เช่น ที่ δ=0.5, λ=0.5 ค่า ARL_1 เพียง 0.879 และ $SDRL_1$ ต่ำสุด แสดงถึงการตอบสนองที่เสถียร

จากตาราง 2 กรณี $\sigma = 0.1, 0.3, 0.5$, $\lambda_1 = 0.02$ และ $\lambda_2 = 0.5$ ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) = 0.01,0.03,0.05,0.07,0.1,0.3,0.5 พบว่าเมื่อ δ ต่ำ (0.01) ค่า ARL_1 สูงในทุกแบบแผนภูมิ แต่แผนภูมิควบคุมFIR-EWMA มีค่า ต่ำสุด (63.030) และ $SDRL_1$ สูงสุด (352.989) ที่ $\lambda = 0.01$ แสดงถึงความสามารถในการตรวจจับการเปลี่ยนแปลงเล็กๆ ได้ดีกว่า เมื่อ δ เพิ่มขึ้น (0.03–0.1) ค่า ARL_1 ลดลงชัดเจนในทุกแบบจำลอง โดยแผนภูมิควบคุม FIR-EWMA ยังคงต่ำสุดและ $SDRL_1$ คงที่ ต่ำกว่าแผนภูมิควบคุมEWMA และ แผนภูมิควบคุมDEWMA แสดงถึงความสม่ำเสมอในการตอบสนอง โดยตั้งแต่ค่า $\delta = 0.03 - 0.05$ แผนภูมิควบคุมDEWMA มีค่า ARL_1 สูงกว่า แผนภูมิควบคุม EWMA เช่น $\delta = 0.07, \lambda_1 = 0.5$ ค่า ARL_1 ของแผนภูมิควบคุม EWMA เท่ากับ 31.774 และค่า ARL_1 ของแผนภูมิควบคุม DEWMA เท่ากับ 32.535 และ δ สูง (0.3–0.5) ค่า ARL_1 ต่ำมาก โดยเฉพาะใน แผนภูมิควบคุมFIR-EWMA เช่น ที่ δ = 0.5, λ = 0.5 ค่า ARL_1 เหลือเพียง 0.957 แสดงถึงการตอบสนองที่รวดเร็วและคงที่

จากตาราง 3 กรณี $\sigma = 0.1, 0.3, 0.5$, $\lambda_1 = 0.03$ และ $\lambda_2 = 0.5$ ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) = 0.01,0.03,0.05,0.07,0.1,0.3,0.5 พบว่าเมื่อ δ ต่ำ (0.01) ที่ $\lambda = 0.01$ แผนภูมิควบคุมFIR-EWMA มีค่า ARL_1 สูงสุด (66.854) แสดงถึงการตรวจจับที่ล่าช้าเมื่อการเปลี่ยนแปลงเล็กน้อย เมื่อ δ เพิ่มขึ้น (0.03–0.1) ค่า ARL_1 ลดลงอย่างต่อเนื่องในทุกแบบจำลอง หมายถึงความสามารถในการตรวจจับที่เร็วขึ้น โดย แผนภูมิควบคุมFIR-EWMA ยังคงมีค่า ARL_1 ต่ำสุด ขณะที่ แผนภูมิควบคุมEWMA และ แผนภูมิควบคุมDEWMA มีค่าใกล้เคียงกัน (8.025และ8.741) โดยเฉพาะเมื่อ δ สูงขึ้น เมื่อ δ = 0.3 และ 0.5 แผนภูมิควบคุม FIR-EWMA ให้ค่า ARL_1 ต่ำสุด (0.152 และ 0.064) แสดงถึงการตอบสนองที่เร็วที่สุด ขณะที่แผนภูมิควบคุมEWMA และ แผนภูมิควบคุม DEWMA มีค่าที่สูงกว่าเล็กน้อย ทั้งนี้ ค่า ARL_1 ของทุกแบบจำลองลดลงเมื่อ δ สูงขึ้น สะท้อนถึงความไวที่เพิ่มขึ้นต่อการเปลี่ยนแปลงของกระบวนการ

จากตาราง 4 กรณี $\sigma = 0.1, 0.3, 0.5$, $\lambda_1 = 0.04$ และ $\lambda_2 = 0.5$ ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ) = 0.01,0.03,0.05,0.07,0.1,0.3,0.5 พบว่า เมื่อ δ =0.01 ที่ λ = 0.1 แผนภูมิควบคุมFIR-EWMA มีค่า ARL_1 ต่ำสุด(2.660) แสดงถึงการตอบสนองที่เร็วที่สุดต่อการเปลี่ยนแปลงเล็กน้อย เมื่อ δ เพิ่มขึ้น (0.03–0.1) ค่า ARL_1 ลดลงในทุกแบบจำลอง หมายถึงการตอบสนองที่เร็วขึ้น โดย แผนภูมิควบคุมFIR-EWMA ยังคงมีค่า ARL_1 ต่ำที่สุด ขณะที่ แผนภูมิควบคุมEWMA และ แผนภูมิควบคุมDEWMA มีค่าใกล้เคียงกัน (11.162 และ 11.900) โดยเฉพาะเมื่อ δ สูงขึ้น และเมื่อ δ = 0.3 และ 0.50 แผนภูมิควบคุมFIR-EWMA ให้ค่า ARL_1 ต่ำสุด (0.064และ 1.058) แสดงถึงความสามารถในการตรวจจับการเปลี่ยนแปลงได้รวดเร็วที่สุด ขณะที่ แผนภูมิควบคุมEWMA และ แผนภูมิควบคุมDEWMA มีค่าที่ใกล้เคียงกัน โดย แผนภูมิควบคุมDEWMAมักมีค่า ARL_1 ต่ำกว่า แผนภูมิควบคุมEWMA เล็กน้อย ทั้งนี้ ค่า ARL_1 ของทุกแบบจำลองลดลงเมื่อ δ สูงขึ้น สะท้อนถึงการตอบสนองที่ไวขึ้นต่อการเปลี่ยนแปลงของกระบวนการ

ตารางที่ 1: การเปรียบเทียบ ARL_1 และ $SDRL_1$ ของแผนภูมิควบคุม EWMA, DEWMA และ FIR-EWMA กำหนดให้ $\lambda_1 = 0.01$ เมื่อ $ARL_0 = 370$

		σ = 0.1			σ = 0.3			σ = 0.5		
		λ_1 = 0.01 (Fix), λ_2 =0.5			λ_1 = 0.01 (Fix), λ_2 =0.5			λ_1 = 0.01 (Fix), λ_2 =0.5		
		EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA
δ	L	1.85479	1.78	2.35074	1.8541	1.7773716	2.35074	1.854	1.778	2.35074
0.01	ARL_1	91.831	93.222	57.132	249.860	127.798	233.798	310.287	316.594	299.617
	$SDRL_1$	63.690	64.743	84.693	207.933	115.370	313.731	251.472	255.786	370.406
0.03	ARL_1	26.345	27.018	8.219	92.327	60.237	56.685	159.390	160.135	121.956
	$SDRL_1$	12.954	12.916	13.311	64.608	49.061	83.906	126.842	126.731	182.830
0.05	ARL_1	14.934	15.618	3.093	50.966	34.791	24.124	91.797	93.026	57.318
	$SDRL_1$	6.569	6.471	5.486	30.151	25.347	36.695	64.236	64.403	85.046
0.07	ARL_1	10.379	11.112	1.627	34.842	23.545	13.213	62.118	63.147	33.070
	$SDRL_1$	4.388	4.335	2.996	18.444	15.454	20.632	39.043	38.562	49.427
0.1	ARL_1	7.046	7.820	0.880	23.289	15.839	6.749	41.494	42.148	17.408
	$SDRL_1$	2.961	2.890	1.711	11.161	9.474	11.208	22.992	22.949	26.975
0.3	ARL_1	2.038	2.801	0.136	7.032	4.956	0.869	12.288	12.978	2.236
	$SDRL_1$	1.168	1.100	0.427	2.966	2.318	1.698	5.289	5.184	3.979
0.5	ARL_1	1.062	1.743	0.056	4.012	3.031	0.367	7.040	7.806	0.879
	$SDRL_1$	0.850	0.811	0.250	1.863	1.419	0.825	3.003	2.894	1.709

ตารางที่ 2: การเปรียบเทียบ ARL_1 และ $SDRL_1$ ของแผนภูมิควบคุม EWMA, DEWMA และ FIR-EWMA กำหนดให้ $\lambda_1 = 0.02$ เมื่อ $ARL_0 = 370$

		$\sigma = 0.1$			$\sigma = 0.3$			$\sigma = 0.5$		
		$\lambda_1 = 0.02$ (Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.02$ (Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.02$ (Fix), $\lambda_2 = 0.5$		
		EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA
δ	L	2.174	2.069	2.500	2.1722	2.0683	2.498	2.17153	2.068	2.499
0.01	ARL_1	90.079	91.724	63.030	251.231	256.208	236.109	306.927	312.723	299.367
	$SDRL_1$	69.462	70.434	87.614	217.610	220.416	300.240	257.191	259.096	352.989
0.03	ARL_1	23.590	24.307	9.195	89.902	92.044	63.915	159.123	163.327	132.950
	$SDRL_1$	13.115	13.160	14.101	69.662	70.985	88.405	134.243	138.266	184.519
0.05	ARL_1	13.013	13.660	3.465	47.798	49.167	26.847	90.229	91.439	63.497
	$SDRL_1$	6.364	6.260	5.803	31.596	32.075	38.087	69.408	70.361	88.434
0.07	ARL_1	8.928	9.595	1.853	31.774	32.535	14.896	59.547	61.027	36.296
	$SDRL_1$	4.249	4.120	3.256	18.830	18.881	21.960	41.819	42.687	50.999
0.1	ARL_1	5.967	6.712	0.961	20.710	21.672	7.685	38.420	39.100	19.550
	$SDRL_1$	2.835	2.745	1.801	11.045	11.266	11.943	23.787	24.147	27.962
0.3	ARL_1	1.660	2.373	0.147	5.941	6.673	0.962	10.565	11.282	2.423
	$SDRL_1$	1.095	1.038	0.443	2.809	2.707	1.832	5.058	4.987	4.119
0.5	ARL_1	0.841	1.459	0.061	3.347	4.089	0.396	5.958	6.706	0.957
	$SDRL_1$	0.811	0.758	0.260	1.754	1.620	0.874	2.828	2.724	1.821

ตารางที่ 3: การเปรียบเทียบ ARL_1 และ ของแผนภูมิควบคุม EWMA, DEWMA และ FIR-EWMA กำหนดให้ $\lambda_1 = 0.03$ เมื่อ $ARL_0 = 370$

		$\sigma = 0.1$			$\sigma = 0.3$			$\sigma = 0.5$		
		$\lambda_1 = 0.03$(Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.03$ (Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.03$ (Fix), λ_2 0.5		
		EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA
δ	L	2.338	2.2222	2.5943	2.388	2.221	2.594478	2.33785	2.22	2.585
0.01	ARL_1	89.713	92.549	66.854	251.997	257.085	233.931	309.197	312.561	289.887
	$SDRL_1$	73.870	75.450	91.137	221.237	224.529	290.191	261.654	263.480	336.467
0.03	ARL_1	22.162	22.851	9.936	90.166	91.703	67.514	161.764	164.454	136.881
	$SDRL_1$	13.305	13.381	14.556	73.036	74.724	91.384	143.356	145.157	184.561
0.05	ARL_1	11.910	12.674	3.695	46.893	47.715	28.704	89.921	92.307	65.817
	$SDRL_1$	6.312	6.258	6.008	33.646	33.399	39.192	73.970	75.366	89.818
0.07	ARL_1	8.025	8.741	1.947	30.175	31.236	15.999	58.774	59.994	38.251
	$SDRL_1$	4.104	3.991	3.358	19.335	19.679	22.625	44.046	44.817	52.192
0.1	ARL_1	5.321	6.059	0.999	19.286	20.083	8.121	36.857	37.610	20.732
	$SDRL_1$	2.734	2.626	1.866	11.167	11.266	12.173	24.705	24.974	28.642
0.3	ARL_1	0.443	2.119	0.152	5.342	6.076	1.010	9.580	10.309	2.592
	$SDRL_1$	1.063	0.989	0.446	2.760	2.642	1.857	4.952	4.877	4.373
0.5	ARL_1	0.707	1.289	0.064	2.943	3.675	0.402	5.353	6.045	1.010
	$SDRL_1$	0.765	0.735	0.270	1.663	1.560	0.882	2.730	2.608	1.863

ตารางที่ 4: การเปรียบเทียบ ARL_1 และ ของแผนภูมิควบคุม EWMA, DEWMA และ FIR-EWMA กำหนดให้ $\lambda_1 = 0.04$ เมื่อ $ARL_0 = 370$

		$\sigma = 0.1$			$\sigma = 0.3$			$\sigma = 0.5$		
		$\lambda_1 = 0.04$(Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.04$ (Fix), $\lambda_2 = 0.5$			$\lambda_1 = 0.04$ (Fix), $\lambda_2 = 0.5$		
		EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA	EWMA	DEWMA	FIR-EWMA
δ	L	2.4448	2.322358	2.663	2.4447	2.32	2.662	2.44465	2.322	2.66
0.01	ARL_1	90.797	93.978	70.151	250.912	256.380	236.100	304.403	312.133	295.293
	$SDRL_1$	76.854	79.319	93.965	223.235	228.584	284.753	262.542	266.108	332.432
0.03	ARL_1	21.147	22.109	10.249	89.643	93.611	69.993	161.189	165.706	140.051
	$SDRL_1$	13.341	13.585	14.502	76.398	78.980	93.679	145.426	148.442	184.512
0.05	ARL_1	11.162	11.900	3.856	46.182	48.016	29.709	0.057	93.737	70.308
	$SDRL_1$	6.298	6.233	6.131	34.905	35.813	40.154	75.985	79.494	93.633
0.07	ARL_1	7.487	8.213	2.000	29.208	30.537	16.618	57.982	60.900	40.082
	$SDRL_1$	4.077	3.967	3.380	20.051	20.228	22.902	46.074	47.878	53.550
0.1	ARL_1	4.879	5.620	1.041	18.471	19.332	8.541	35.948	37.308	21.286
	$SDRL_1$	2.660	2.569	1.911	11.429	11.504	12.383	25.796	26.405	29.125
0.3	ARL_1	1.283	1.939	0.153	4.930	5.645	1.050	8.947	9.723	2.713
	$SDRL_1$	1.031	0.963	0.450	2.706	2.564	1.907	4.964	4.855	4.450
0.5	ARL_1	0.615	1.167	0.064	2.701	3.397	0.436	4.922	5.634	1.058
	$SDRL_1$	0.729	0.728	0.266	1.609	1.514	0.925	2.700	2.544	1.911

4. สรุปผล

การศึกษาเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม EWMA DEWMA และ FIR-EWMA ในการตรวจจับการเปลี่ยนแปลงของพารามิเตอร์บ่งขนาดของการแจกแจงแบบเรย์ลีย์ จากการศึกษาพบว่าแผนภูมิควบคุมFIR-EWMA มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ ได้รวดเร็วกว่าแผนภูมิควบคุมDEWMA และ แผนภูมิควบคุมEWMA ตามลำดับ ในทุกระดับการเปลี่ยนแปลงในทุกกรณีที่ศึกษา หากพิจารณาภายใต้เงื่อนไขที่ค่าพารามิเตอร์บ่งขนาด (σ) ระดับเดียวกัน โดยที่ขนาดการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาดกระบวนการ (δ)เพิ่มขึ้น พบว่าค่า ARL_1 จะลดลงในทุกขนาดการเปลี่ยนแปลง นั้นคือ การตรวจจับของแผนภูมิควบคุมที่เสนอสามารถตอบสนองต่อการเปลี่ยนแปลงพารามิเตอร์บ่งขนาดได้รวดเร็ว เมื่อพิจารณาค่าพารามิเตอร์ของแผนภูมิควบคุม ทั้ง 3 แผนภูมิควบคุม พบว่าเมื่อ λ_1 เพิ่มขึ้น (ค่า $\lambda_2 = 0.5$ สำหรับแผนภูมิควบคุมDEWMA) ค่าของ ARL_1ลดลงในทุกขนาดการเปลี่ยนแปลงพารามิเตอร์บ่งขนาด นั้นคือ λ_1ที่เหมาะสมในการสถานการณ์นี้ คือ 0.04 ผลจากการเปลี่ยนแปลงของค่าพารามิเตอร์บ่งขนาด

ดังนั้นแผนภูมิควบคุม FIR-EWMA จึงเป็นอีกหนึ่งทางเลือกในการวัดประสิทธิภาพของสถานการณ์นี้ นอกจากการศึกษาแผนภูมิควบคุม EWMA แผนภูมิควบคุม DEWMA จึงเป็นอีกหนึ่งแผนภูมิควบคุมที่มีการตรวจจับการเปลี่ยนแปลงได้ดี ดังนั้นจึงขอเสนอการพัฒนาแผนภูมิควบคุมนี้ในรูปแบบ FIR-DEWMA ในงานวิจัยต่อไป

5. กิตติกรรมประกาศ

งานวิจัยเรื่อง แผนภูมิควบคุม FIR-EWMA เพื่อตรวจสอบการเปลี่ยนแปลงสำหรับการแจกแจงเรย์ลีย์ สำเร็จลุล่วงได้ด้วยความกรุณาอย่างสูงจากผู้ช่วยศาสตราจารย์ ดร.วิลาสินี ปีระจิตร และ ดร.ปิยพล ไพจิตร อาจารย์ที่ปรึกษางานวิจัย ที่ได้สละเวลาอันมีค่าในการให้คำแนะนำ เสนอแนวคิด ให้คำปรึกษา ให้ความรู้ และเอาใจใส่ทุกรายละเอียดของงานวิจัย แก้ไขข้อบกพร่องต่างๆเพื่อให้งานวิจัยสมบูรณ์ยิ่งขึ้น

ขอบคุณเพื่อนๆ ทุกคนที่ร่วมมือกันทำงานอย่างเต็มที่ แบ่งปันความคิดเห็น และช่วยเหลือกันในยามที่เกิดปัญหา ความสามัคคีและการทำงานเป็นทีมเป็นปัจจัยสำคัญที่ทำให้งานนี้บรรลุเป้าหมายผู้วิจัยหวังว่า งานวิจัยฉบับนี้จะมีประโยชน์อยู่ไม่น้อย จึงขอมอบส่วนดีทั้งหมดนี้ให้แก่เหล่าคณาจารย์ที่ได้ประ

สิทธิประสาทวิชาจนทำให้ผลงานวิจัยเป็นประโยชน์ต่อผู้ที่เกี่ยวข้องและขอมอบความกตัญญูกตเวทิตาคุณ แด่บิดา มารดา และผู้มีพระคุณทุกท่าน สำหรับข้อบกพร่องต่าง ๆ ที่อาจจะเกิดขึ้นนั้น ผู้วิจัยขอน้อมรับผิดเพียงผู้เดียว และยินดีที่จะรับฟังคำแนะนำจากทุกท่านที่ได้เข้ามาศึกษา เพื่อเป็นประโยชน์ในการพัฒนางานวิจัยต่อไป

6. เอกสารอ้างอิง

[1] Shewhart, W. A. Economic Control of Quality of manufactured Product. New York: D. Van Nostrand company Inc. (1931).

[2] Page, E. S. Continuous inspection schemes. Biometrika, (1954). 41(1-2), 100-114.

[3] Roberts, S. W. Control chart tests based on geometric moving average. Technometric.(1959), 42(1), 239-250.

[4] Lucas J. M. and Saccucci M. S. Exponentially Weighted Moving Average Control, Schemes Properties and Enhancements, Technometrics 24, (1990)

[5] Butler, S. W. & Stefani, J. A. (1994). Supervisory run-to-run control of a polysilicon gate etch using in situ ellipsometry. IEEE Transaction on Semiconductor Manufacturing, 7(2),

[6] Alkahtani, S. S. , Robustness of DEWMA versus EWMA control charts to non-normal processes. Journal of Modern Applied Statistical Methods, (2013), 12(1)

[7] Steiner, S. H., EWMA control charts with time-varying control limits and fast initial response, J. Qual. Technol. (1999), 31: 2-4. , 11-16.

[8] Paichit, P., Seedang, C., Sujintawong, C., & Sungboonchoo, C. Efficiency comparison of TEWMA FIR-TEWMA MFIR-TEWMA QEWMA FIR-QEWMA and MFIR-QEWMA control charts for Lognormal distribution. Journal of Applied Science and Emerging Technology (JASET), (2024) .1(23)

[9] Maisombun, P., Hongkummeaung, J., & Sinsomboonthong, J. Efficiency comparison of control charts in detection of process mean shift for normal distribution. Journal of Science, (2017). 25(6)

[10] Buaphim, N., Sinsomboonthong, J., & Supapakorn, T. Efficiency comparison of weighted moving average control charts for normal distribution. Thai Science and Technology Journal (TSTJ), (2020). 28(7)

[11] Supharakonsakun, Y., & Areepong, Y. ARL evaluation of a DEWMA control chart for autocorrelated data: A case study on prices of major industrial commodities. *Emerging Science Journal*, (2023). 7(5)., 1771-1775.

[12] Haq, A., Brown, J., & Moltchanova, E. Improved fast initial response features for exponentially weighted moving average and cumulative sum control charts. *Quality and Reliability Engineering International,*(2014). **30**, 697–710.

[13] Dermsungnoen, K., Charoenpanich, C., Harnrob, C., & Areepong, Y. The performance comparisons of EWMA, HWMA, DHWMA, and HHWMA control charts for monitoring process mean. *The 1st National Conference on Statistics, Data Science and Insurance*,(2024).

การใช้ตัวแปรช่วยเพื่อปรับปรุงประสิทธิภาพของตัวประมาณแบบเลขชี้กำลังของค่าเฉลี่ยประชากรภายใต้ปัญหาการไม่ตอบสนองในการสำรวจตัวอย่าง

Use of Auxiliary Variable to Improve the Efficiency of Exponential Type Estimator of Population Mean Under the Problem of Non-Response in Sample Surveys

ลภัส ชัยพรเรืองเดช ณภัทณ์จันทร์ ด่านสวัสดิ์ *

สาขาวิชาสถิติและวิทยาการข้อมูล ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

(* *napattchan.dan@kmutt.ac.th*)

บทคัดย่อ

งานวิจัยครั้งนี้มีวัตถุประสงค์เพื่อนำเสนอตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากรภายใต้ปัญหาการไม่ตอบสนองในการสำรวจตัวอย่าง ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน โดยผู้วิจัยได้มีการศึกษาคุณสมบัติที่สำคัญบางอย่างของตัวประมาณที่นำเสนอ ได้แก่ ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error: MSE) และค่าความคลาดเคลื่อนกำลังสองเฉลี่ยที่ต่ำที่สุด (Minimum Mean Squared Error: MMSE) ทั้งนี้ผู้วิจัยจะใช้ค่าความคลาดเคลื่อนกำลังของเฉลี่ย และค่าร้อยละประสิทธิภาพสัมพัทธ์ (Percent Relative Efficiencies: PRE) เป็นเกณฑ์ในการเปรียบเทียบประสิทธิภาพของตัวประมาณต่าง ๆ ทั้งในทางทฤษฎี การประยุกต์ใช้กับข้อมูลจริง และการจำลองข้อมูล ผลการวิจัยพบว่า ตัวประมาณแบบเลขชี้กำลังที่นำเสนอมีประสิทธิภาพดีกว่าตัวประมาณอื่น ๆ ภายใต้สถานการณ์เดียวกัน

คำสำคัญ: ประมาณแบบเลขชี้กำลัง, ปัญหาการไม่ตอบสนอง, การสำรวจตัวอย่าง, ค่าเฉลี่ยประชากร

Abstract

This paper aims to propose an exponential-type estimator for estimating the population means under non-response problems in sample surveys within the framework of two-phase sampling. Additionally, the researcher examines some key properties of the proposed estimator, such as Mean Squared Error (MSE) and Minimum Mean Squared Error (MMSE). The MSE and Percent Relative Efficiency (PRE) are used as criteria to compare the efficiency of various estimators, both theoretically and in practical applications, using real data and through data simulation. The findings indicate that the proposed exponential estimator demonstrates greater efficiency than other estimators under the same conditions.

Keywords: Exponential type estimator, Problem of non-response, Sample surveys, Population mean

1. บทนำ

ในการศึกษาและการวิจัยเชิงสำรวจส่วนใหญ่ นักวิจัยมักประสบกับปัญหาหรืออุปสรรคต่าง ๆ ที่เกี่ยวข้องกับการเก็บรวบรวมข้อมูลจากประชากร (Population) ที่สนใจศึกษา เช่น จำนวนประชากรที่สนใจศึกษามีขนาดใหญ่เกินไป มีงบประมาณไม่เพียงพอ หรือมีเวลาที่จำกัดสำหรับการเก็บรวบรวมข้อมูล ฯลฯ และเพื่อแก้ปัญหาหรืออุปสรรคดังที่กล่าวมา นักวิจัยจึงจำเป็นต้องเลือกตัวแทนหรือส่วนหนึ่งของประชากร ที่เรียกว่า ตัวอย่าง (Sample) มาใช้ในการคำนวณค่าต่าง ๆ ที่สนใจศึกษา รวมถึงนำไปสร้างตัวประมาณ (Estimator) เพื่อใช้วิเคราะห์ อ้างอิง และสรุปผลเกี่ยวกับคุณลักษณะของประชากร โดยในปัจจุบันนักวิจัยส่วนใหญ่นิยมสร้างและพัฒนาตัวประมาณต่าง ๆ สำหรับประมาณค่าเฉลี่ยของประชากรมากที่สุด อย่างไรก็ตามปัญหาที่สำคัญที่สุดประการหนึ่งของการเลือกตัวแทนหรือส่วนหนึ่งของประชากร ได้แก่ การที่บุคคลที่ถูกเลือกให้เป็นกลุ่มตัวอย่างไม่ได้ให้ความร่วมมือในการตอบข้อมูลที่ครบถ้วน หรืออาจจะไม่ตอบสนองต่อข้อคำถามบางคำถาม ดังเห็นได้จากการทำสำมะโนประชากร หรือการทำแบบสำรวจ ในกรณีนี้จะถือว่าข้อมูลที่ได้มาเป็นข้อมูลที่ไม่ตอบสนอง (Non-Response) หรือเป็นข้อมูลที่เกิดการสูญหาย (Missing Data) ซึ่งการประมาณค่าต่าง ๆ ที่ได้รับจากข้อมูลที่ไม่ครบถ้วนหรือ

ข้อมูลที่เกิดการสูญหาย สามารถนำไปสู่การตีความและข้อสรุปที่ผิดพลาดได้ และเพื่อลดผลกระทบของปัญหาที่เกิดขึ้นในสถานการณ์ดังกล่าว [3] ได้เสนอเทคนิคการเลือกตัวอย่างย่อยจากกลุ่มตัวอย่างที่ไม่ตอบสนองข้อมูล และนำเสนอตัวประมาณสำหรับประมาณค่าเฉลี่ยของประชากร (Population mean: $\bar{Y}$) ของตัวแปรที่สนใจศึกษา (Study Variable: Y) ซึ่งตัวประมาณดังกล่าวพบว่ามีคุณสมบัติเป็นตัวประมาณที่ไม่มีความเอนเอียง (Unbiased)

โดย [3] จะทำการเลือกตัวอย่างขนาด n อย่างสุ่มแบบง่ายแบบไม่ใส่คืน (Simple Random Sampling Without Replacement: SRSWOR) จากประชากรขนาด N ทั้งนี้ก่อนการเลือกตัวอย่างจะแบ่งกลุ่มประชากรออกเป็น 2 กลุ่มคือ กลุ่มที่หนึ่งมีขนาด N_1 จะถูกกำหนดให้เป็นกลุ่มที่ข้อมูลมีการตอบสนอง และกลุ่มที่สองมีขนาด $N_2 = N - N_1$ คือ กลุ่มที่ข้อมูลไม่มีการตอบสนอง ตามลำดับ ภายหลังจากการเลือกตัวอย่างขนาด n แล้วจะทำการแยกตัวอย่างขนาด n ที่ถูกเลือกมา ออกเป็นสองกลุ่มดังนี้ ตัวอย่างกลุ่มที่หนึ่งมีขนาด n_1 จะถูกกำหนดให้เป็นกลุ่มที่พบว่าข้อมูลมีการตอบสนอง ในขณะที่ตัวอย่างกลุ่มที่สองซึ่งมีขนาด n_2 จะเป็นกลุ่มที่ประกอบด้วยข้อมูลที่ไม่มีการตอบสนอง ทั้งนี้ตัวอย่างในกลุ่มที่สองขนาด n_2 จะถูกเลือกด้วยวิธีการเลือกตัวอย่างสุ่มแบบง่ายแบบไม่ใส่คืนอีกครั้ง โดยขนาดตัวอย่างที่ถูกเลือกในขั้นตอนนี้จะมีขนาดเท่ากับ $r = n_2 / k$ เมื่อ $k > 1$ ดังนั้นตัวประมาณค่าเฉลี่ยของประชากร $\bar{Y}$ ที่นำเสนอโดย [3] มีดังนี้

$$\bar{y}^* = w_1 \bar{y}_1 + w_2 \bar{y}_{2r} \tag{1}$$

โดยที่ $w_1 = n_1 / n, w_2 = n_2 / n$

เมื่อ $\bar{y}_1$ คือ ค่าเฉลี่ยตัวอย่างของตัวแปรที่ศึกษา Y ภายใต้กลุ่มตัวอย่างขนาด n_1

$\bar{y}_{2r}$ คือ ค่าเฉลี่ยตัวอย่างของตัวแปรที่ศึกษา Y ภายใต้กลุ่มตัวอย่างขนาด r

โดยความแปรปรวนของตัวประมาณ $\bar{y}^*$ จะหาได้จาก

$$V(\bar{y}^*) = \bar{Y}^2 \left(\lambda C_y^2 + \lambda^* C_{y(2)}^2 \right) \tag{2}$$

โดยที่ $\lambda = (N-n)/Nn, \lambda^* = W_2(k-1)/n,$

$W_2 = N_2 / N, S_y^2 = \sum_{i=1}^{N} (y_i - \bar{Y})^2 / (N-1),$

$S_{y(2)}^2 = \sum_{i=1}^{N_2} (y_i - \bar{Y}_2)^2 / (N_2 - 1),\ \bar{Y}_2 = \sum_{i=1}^{N_2} y_i / N_2\ ,$

$C_y^2 = S_y^2 / \bar{Y}^2\ ,\ C_{y(2)}^2 = S_{y(2)}^2 / \bar{Y}^2$

เมื่อมีเหตุการณ์เกิดขึ้นและพบว่าเหตุการณ์นั้นมีข้อมูลที่ไม่ตอบสนองในตัวแปรที่สนใจศึกษา Y นักวิจัยหลายท่านจึงได้แนะนำให้ใช้ตัวแปรช่วย (Auxiliary Variable: X) ที่มีความสัมพันธ์กับตัวแปรที่สนใจศึกษา Y เข้ามาเพิ่มประสิทธิภาพในการประมาณค่าเฉลี่ยประชากรให้ดียิ่งขึ้น ตัวอย่างเช่น หากต้องการหาค่าเฉลี่ยรายได้ของประชากร แต่ข้อมูลรายได้บางส่วนหายไป นักวิจัยอาจใช้ข้อมูลระดับการศึกษาเป็นตัวแปรช่วย เนื่องจากระดับการศึกษามีความสัมพันธ์กับรายได้ นอกจากนี้นักวิจัยยังได้ประยุกต์เทคนิคการเลือกตัวอย่างย่อยที่นำเสนอโดย [3] มาใช้ในการพัฒนาตัวประมาณในรูปแบบต่าง ๆ โดยใช้ตัวแปรช่วย เช่น [4] ได้นำเสนอตัวประมาณอัตราส่วนแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ซึ่งตัวประมาณตัวใหม่นี้เกิดจากการคูณกันระหว่างตัวประมาณที่นำเสนอโดย [5] และ [6] ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน โดยใช้ข้อมูลจากค่าคงที่ที่เหมาะสมที่สุด ในขณะที่ [7] ได้นำตัวประมาณที่นำเสนอโดย [5] มาปรับปรุงประสิทธิภาพและสร้างตัวประมาณใหม่ในรูปแบบตัวประมาณแบบผลคูณที่มีการเพิ่มค่าคงที่ที่เหมาะสมที่สุดจำนวน 2 ค่า มาประยุกต์ใช้ในการลดความเอนเอียงและลดค่าคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณที่นำเสนอ ซึ่งตัวประมาณดังกล่าวนี้สามารถลดรูปไปเป็นตัวประมาณตัวอื่น ๆ อีกมากมายในรูปแบบเลขชี้กำลัง เช่นเดียวกันกับ [8] ได้ปรับปรุงประสิทธิภาพของตัวประมาณที่นำเสนอโดย [9] โดยการนำเสนอรูปแบบทั่วไปของตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ที่มีความครอบคลุมถึงตัวประมาณอื่น ๆ ในลักษณะเดียวกันที่นักวิจัยหลายท่านได้นำเสนอในขณะนั้น ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน เมื่อข้อมูลที่สนใจศึกษาไม่มีการตอบสนอง

และถ้าหากพบว่ามีเหตุการณ์เกิดขึ้นและเหตุการณ์นั้นมีข้อมูลที่ไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ตัวอย่างเช่น หากนักวิจัยไม่สามารถหาข้อมูลประชากรได้ครบถ้วนหรือมีข้อมูลสูญหาย อาจทำให้นักวิจัยไม่สามารถคำนวณค่าเฉลี่ยที่แท้จริงทั้งของประชากรและของตัวแปรช่วยได้ หรือนักวิจัยอาจเก็บข้อมูลจากแหล่งที่ไม่มีความน่าเชื่อถือ หรือแหล่งข้อมูลนั้นมีการเปลี่ยนแปลงประชากรอย่างรวดเร็ว ก็อาจส่งผลให้นักวิจัยไม่สามารถทราบค่าเฉลี่ยทั้งของประชากรและของตัวแปรช่วยได้ และเพื่อแก้ไขปัญหาดังกล่าว นักวิจัยอีกหลาย ๆ ท่าน ได้ขยายแนวคิดและนำเสนอตัวประมาณแบบอัตราส่วน ตัวประมาณแบบผลคูณ และตัวประมาณแบบถดถอยเชิงเส้น รวมถึงตัวประมาณในรูปแบบเลขชี้กำลังเพิ่มเติม ที่มีประสิทธิภาพและมีความเหมาะสมในการประมาณค่าเฉลี่ยประชากร ซึ่งสามารถศึกษาได้จากงานวิจัยของ [11] เป็นต้น

จากตัวประมาณในรูปแบบต่าง ๆ ดังที่ได้กล่าวมา ผู้วิจัยจึงมีความสนใจที่จะปรับปรุงประสิทธิภาพของตัวประมาณแบบอัตราส่วนในรูปแบบเลขชี้กำลัง สำหรับประมาณค่าเฉลี่ยประชากร ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน โดยจะนำเสนอตัวประมาณขึ้นมาใหม่จากการขยายจากแนวคิดของ [1, 2] โดยตัวประมาณที่จะนำเสนอนี้จะอยู่ภายใต้สถานการณ์ที่ข้อมูลไม่ตอบสนองในตัวแปรสนใจศึกษาเพียงอย่างเดียว Y และในกรณีที่ข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ตามลำดับ นอกจากนี้ผู้วิจัยจะศึกษาถึงคุณสมบัติที่สำคัญบางประการของตัวประมาณที่

นำเสนอขึ้นมาใหม่ เช่น ความคลาดเคลื่อนกำลังสองเฉลี่ย และความคลาดเคลื่อนกำลังสองเฉลี่ยที่ต่ำที่สุด และจะทำการเปรียบเทียบประสิทธิภาพของตัวประมาณที่นำเสนอขึ้นมาใหม่กับตัวประมาณตัวอื่น ๆ ที่เกี่ยวข้องในเชิงทฤษฎี การประยุกต์ใช้กับข้อมูลจริง และการจำลองข้อมูล

2. วิธีการวิจัย

อ้างอิงจาก [1] ได้นำเสนอตัวประมาณแบบอัตราส่วนในรูปแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ในกรณีที่ข้อมูลไม่ตอบสนองในตัวแปรสนใจศึกษา Y เพียงอย่างเดียว และในกรณีที่ข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ตามลำดับ ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน ดังรายละเอียดต่อไปนี้

- กรณีที่ข้อมูลไม่ตอบสนองในตัวแปรสนใจศึกษา Y เพียงอย่างเดียว

$$t_1 = \bar{y}^* \exp\left(\frac{(\theta_1 - 1)(\bar{X} - \bar{x})}{(\theta_1 + 1)(\bar{X} + \bar{x})}\right) \quad (3)$$

โดยที่ θ_1 คือ ค่าคงที่ใด ๆ ที่ทำให้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ t_1 มีค่าที่ต่ำที่สุด

โดยค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ t_1 จะหาได้จาก

$$MSE(t_1) = \bar{Y}^2\left(\lambda C_y^2 + \lambda^* C_{y(2)}^2 + \lambda\left(\frac{k_1^2}{4}C_x^2 + k_1 C_{yx}\right)\right) \quad (4)$$

เมื่อ $k_1 = (1-\theta_1)/(1+\theta_1)$

- กรณีที่ข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X

$$t_2 = \bar{y}^* \exp\left(\frac{(\theta_2 - 1)(\bar{X} - \bar{x}^*)}{(\theta_2 + 1)(\bar{X} + \bar{x}^*)}\right) \quad (5)$$

โดยที่ θ_2 คือ ค่าคงที่ใด ๆ ที่ทำให้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ t_2 มีค่าที่ต่ำที่สุด

และค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณ t_2 จะหาได้จาก

$$MSE(t_2) = \bar{Y}^2\begin{pmatrix}\lambda\left(C_y^2 + \frac{k_2^2}{4}C_x^2 + k_2 C_{yx}\right)\\ +\lambda^*\left(C_{y(2)}^2 + \frac{k_2^2}{4}C_{x(2)}^2 + k_2 C_{yx(2)}\right)\end{pmatrix} \quad (6)$$

เมื่อ $k_2 = (1-\theta_2)/(1+\theta_2)$

ในปีเดียวกัน [2] ได้นำเสนอตัวประมาณแบบอัตราส่วนในรูปแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ในกรณีที่ข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ภายใต้การเลือกตัวอย่างแบบสองขั้นตอน ซึ่งตัวประมาณตัวใหม่นี้ได้พัฒนามาจากตัวประมาณที่ถูกนำเสนอโดย [12] โดยเกิดจากการคูณกันระหว่างตัวประมาณที่นำเสนอโดย [3] และ [13] มีรูปแบบดังนี้

$$t_3 = \alpha\bar{y}^* + (1-\alpha)\bar{y}^* \exp\left(\frac{\bar{X} - \bar{x}^*}{\bar{X} + \bar{x}^*}\right) \quad (7)$$

เมื่อ α คือ ค่าคงที่ใด ๆ ที่ทำให้ตัวประมาณ t_3 มีความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำที่สุด

โดยตัวประมาณ t_3 มีความคลาดเคลื่อนกำลังสองเฉลี่ยดังนี้

$$MSE(t_3) = \bar{Y}^2\begin{pmatrix}\lambda C_y^2 + \lambda^* C_{y(2)}^2\\ +\left(\lambda C_x^2 + \lambda^* C_{x(2)}^2\right)\left(\frac{\alpha^2}{4} - \frac{\alpha}{2} + \frac{1}{4}\right)\\ +\left(\lambda C_{yx} + \lambda^* C_{yx(2)}\right)(\alpha - 1)\end{pmatrix} \quad (8)$$

จากตัวประมาณที่นำเสนอโดย [1, 2] ดังสมการที่ (3) ถึงสมการที่ (5) ผู้วิจัยมีความสนใจที่จะนำเสนอตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ภายใต้สถานการณ์ที่ข้อมูลไม่ตอบสนองในตัวแปรสนใจศึกษาเพียงอย่างเดียว Y และในกรณีที่ข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ตามลำดับ โดยตัวประมาณที่นำเสนอมีรูปแบบแสดงตามลำดับดังต่อไปนี้

$$t_4 = \alpha\bar{y}^* + (1-\alpha)\bar{y}^* \exp\left(\frac{(\theta_1 - 1)(\bar{X} - \bar{x})}{(\theta_1 + 1)(\bar{X} + \bar{x})}\right) \quad (9)$$

$$t_5 = \alpha\bar{y}^* + (1-\alpha)\bar{y}^* \exp\left(\frac{(\theta_2 - 1)(\bar{X} - \bar{x}^*)}{(\theta_2 + 1)(\bar{X} + \bar{x}^*)}\right) \quad (10)$$

ในการคำนวณค่าความคลาดเคลื่อนกำลังสองเฉลี่ย และค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดของตัวประมาณ t_4 จากสมการที่ (9) และตัวประมาณ t_5 จากสมการที่ (10) ผู้วิจัยจะทำการจัดรูปแบบของตัวประมาณ ให้อยู่ในพจน์ความคลาดเคลื่อน (Error Terms) โดยกำหนดให้ $\bar{y}^* = \bar{Y}(1+e_0^*)$, $\bar{x}^* = \bar{X}(1+e_1^*)$ และ $\bar{x} = \bar{X}(1+e_1)$ เมื่อ $E(e_0^*) = 0$, $E(e_1^*) = E(e_1) = 0$, $E(e_0^{*2}) = \lambda C_y^2 + \lambda^* C_{y(2)}^2$, $E(e_1^{*2}) = \lambda C_x^2 + \lambda^* C_{x(2)}^2$, $E(e_1^2) = \lambda C_x^2$, $E(e_0^* e_1) = \lambda\rho_{yx} C_y C_x$ และ $E(e_0^* e_1^*) = \lambda\rho_{yx} C_y C_x + \lambda^* C_{yx(2)}$

นั่นคือจากสมการที่ (9) และสมการที่ (10) จะสามารถจัดสมการ ให้อยู่ในพจน์ของค่าคลาดเคลื่อนได้ดังนี้

$$t_4 = \bar{Y}\left[\begin{array}{l} 1+e_0^*+k_1\frac{e_1}{2}-\alpha k_1\frac{e_1}{2}+\frac{k_1(k_1-2)}{8}e_1^2 \\ -\alpha\frac{k_1(k_1-2)}{8}e_1^2+k_1\frac{e_0^*e_1}{2}-\alpha k_1\frac{e_0^*e_1}{2}\end{array}\right] \quad (11)$$

$$t_5 = \bar{Y}\left[\begin{array}{l} 1+e_0^*+k_2\frac{e_1^*}{2}-\alpha k_2\frac{e_1^*}{2}+\frac{k_2(k_2-2)}{8}e_1^{*2} \\ -\alpha\frac{k_2(k_2-2)}{8}e_1^{*2}+k_2\frac{e_0^*e_1^*}{2}-\alpha k_2\frac{e_0^*e_1^*}{2}\end{array}\right] \quad (12)$$

จากสมการที่ (11) และสมการที่ (12) ผู้วิจัยจะใช้อนุกรมเทย์เลอร์ในการกระจายสมการ โดยพจน์ที่ยกกำลังมากกว่า 2 ขึ้นไปจะถูกกำหนดให้เป็นค่าคลาดเคลื่อนจากการตัดปลาย (Truncation Error) ซึ่งพจน์ดังกล่าวจะลู่เข้าสู่ศูนย์ในทางทฤษฎี และผู้วิจัยสามารถหาคำนวณหาค่าคลาดเคลื่อนกำลังสองเฉลี่ยของตัวประมาณจากสมการที่ (11) และสมการที่ (12) ได้ตามลำดับดังนี้

$$MSE(t_4) = \bar{Y}^2\left[\begin{array}{l}\lambda\left(C_y^2+(1-\alpha)\frac{k_1}{4}C_x^2\left(k_1(1-\alpha)+4K\right)\right) \\ +\lambda^*C_{y(2)}^2\end{array}\right] \quad (13)$$

$$MSE(t_5) = \bar{Y}^2\left[\begin{array}{l}\lambda\left(C_y^2+(1-\alpha)\frac{k_2}{4}C_x^2\left(k_2(1-\alpha)+4K\right)\right) \\ +\lambda^*\left(C_{y(2)}^2+(1-\alpha)\frac{k_2}{4}C_{x(2)}^2\left(k_2(1-\alpha)+4L\right)\right)\end{array}\right] \quad (14)$$

ในการหา k_1 ที่ทำให้ $MSE(t_4)$ มีค่าต่ำที่สุด จะหาจากอนุพันธ์อันดับหนึ่งของ $MSE(t_4)$ เทียบกับ k_1 และให้เท่ากับ 0 จะได้

$$\frac{\partial MSE(t_4)}{\partial k_1} = \frac{2k_1}{4}\lambda C_x^2+\frac{2\alpha^2k_1}{4}\lambda C_x^2+\lambda KC_x^2-\alpha\lambda KC_x^2-\frac{2\alpha k_1}{2}\lambda C_x^2 = 0 \quad (15)$$

แก้สมการหาค่า k_1 จากสมการ (15) จะได้

$$k_{1(opt)} = \frac{-2K}{(1-\alpha)} \quad (16)$$

และหาอนุพันธ์อันดับสองของ $MSE(t_4)$ เทียบกับ k_1 จะได้

$$\frac{\partial^2 MSE(t_4)}{\partial k_1^2} = (1-\alpha)^2 > 0 \quad (17)$$

ซึ่งมีค่ามากกว่า 0 ทำให้ได้ $MSE(t_4)$ มีค่าต่ำที่สุด และเมื่อแทนค่า $k_{1(opt)}$ ลงในสมการที่ (13) จะได้ค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดของตัวประมาณ t_4 ดังนี้

$$MMSE(t_4) = \bar{Y}^2\left[\lambda\left(C_y^2-K^2C_x^2\right)+\lambda^*C_{y(2)}^2\right] \quad (18)$$

ในการหา k_2 ที่ทำให้ $MSE(t_5)$ มีค่าต่ำที่สุด จะหาจากอนุพันธ์อันดับหนึ่งของ $MSE(t_5)$ เทียบกับ k_2 และให้เท่ากับ 0 จะได้

$$\frac{\partial MSE(t_5)}{\partial k_2} = \left[\begin{array}{l}\frac{2k_2}{4}(\lambda C_x^2+\lambda^*C_{x(2)}^2)+\frac{2\alpha^2k_2}{4}(\lambda C_x^2+\lambda^*C_{x(2)}^2) \\ +(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)-\alpha(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)-\frac{2\alpha k_2}{2}(\lambda C_x^2+\lambda^*C_{x(2)}^2)\end{array}\right] = 0 \quad (19)$$

แก้สมการหาค่า k_2 จากสมการ (19) จะได้

$$k_{2(opt)} = \frac{-2\left[(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)\right]}{\left[(\lambda C_x^2+\lambda^*C_{x(2)}^2)(1-\alpha)\right]} \quad (20)$$

หาอนุพันธ์อันดับสองของ $MSE(t_5)$ เทียบกับ k_2 จะได้

$$\frac{\partial^2 MSE(t_5)}{\partial k_2^2} = (1-\alpha)^2 > 0 \quad (21)$$

ซึ่งมีค่ามากกว่า 0 ทำให้ได้ $MSE(t_5)$ มีค่าต่ำที่สุด และเมื่อแทนค่า $k_{2(opt)}$ ลงในสมการที่ (14) จะได้ค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดของตัวประมาณ t_5 ดังนี้

$$MMSE(t_5) = \bar{Y}^2\left[\begin{array}{l}\lambda\left(C_y^2+\left(\frac{-(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)}{2(\lambda C_x^2+\lambda^*C_{x(2)}^2)}\right)C_x^2\right. \\ \left.\left(\left(\frac{-2(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)}{(\lambda C_x^2+\lambda^*C_{x(2)}^2)}\right)+4K\right)\right) \\ +\lambda^*\left(C_{y(2)}^2+\left(\frac{-(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)}{2(\lambda C_x^2+\lambda^*C_{x(2)}^2)}\right)C_{x(2)}^2\right. \\ \left.\left(\left(\frac{-2(\lambda KC_x^2+\lambda^*LC_{x(2)}^2)}{(\lambda C_x^2+\lambda^*C_{x(2)}^2)}\right)+4L\right)\right)\end{array}\right] \quad (22)$$

เมื่อ $K = \rho_{yx}C_y / C_x$, $L = \rho_{yx(2)}C_{y(2)} / C_{x(2)}$

3. ผลการวิจัยและอภิปรายผล

ในการเปรียบเทียบประสิทธิภาพระหว่างตัวประมาณที่นำเสนอขึ้นมาใหม่ กับตัวประมาณอื่น ๆ ที่เกี่ยวข้อง ผู้วิจัยจะเปรียบเทียบในเชิงทฤษฎี การประยุกต์ใช้กับข้อมูลจริง และการจำลองข้อมูล โดยผลการเปรียบเทียบประสิทธิภาพแสดงดังรายละเอียดต่อไปนี้

3.1 การเปรียบเทียบประสิทธิภาพของตัวประมาณในเชิงทฤษฎี

ผู้วิจัยจะพิจารณาจากค่าความคลาดเคลื่อนกำลังสองเฉลี่ยและค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด โดยตัวประมาณที่นำเสนอขึ้นมาใหม่ จะมีประสิทธิภาพดีกว่าตัวประมาณอื่น ๆ เมื่อเงื่อนไขต่าง ๆ ที่แสดงดังตารางที่ 1 เป็นจริง

ตารางที่ 1 : เงื่อนไขต่าง ๆ ที่แสดงว่าตัวประมาณ t_4 จะมีประสิทธิภาพดีกว่าตัวประมาณอื่น ๆ ที่เกี่ยวข้อง

ลำดับที่	การเปรียบเทียบ	เงื่อนไข
1	$MSE(t_4) < MSE(t_1)$	$\rho_{yx} > C_x\left[k_1(1-\alpha)^2 + 4(1-\alpha)K - k_1\right] / 4C_y$
2	$MMSE(t_4) < MSE(t_1)$	$\rho_{yx} > -C_x\left[4K^2 + k_1^2\right] / 4k_1C_y$
3	$MSE(t_4) < MSE(t_3)$	$\left(\lambda C_x^2 + \lambda^* C_{x(2)}^2\right)(1-\alpha) - 4\left(\lambda C_{yx} + \lambda^* C_{yx(2)}\right) > \lambda k_1 C_x^2\left(k_1(1-\alpha) + 4K\right)$
4	$MMSE(t_4) < MSE(t_3)$	$\left(\lambda C_x^2 + \lambda^* C_{x(2)}^2\right)(1-\alpha)^2 - 4\left(\lambda C_{yx} + \lambda^* C_{yx(2)}\right)(1-\alpha) > -4\lambda K^2 C_x^2$
5	$MSE(t_5) < MSE(t_2)$	$\lambda\left(\frac{k_2}{4}C_x^2 + 4C_{yx}\right) + \lambda^*\left(\frac{k_2}{4}C_{x(2)}^2 + 4C_{yx(2)}\right) > \lambda A + \lambda^* B$
6	$MMSE(t_5) < MSE(t_2)$	$\lambda\left(\frac{k_2^2}{4}C_x^2 + k_2C_{yx}\right) + \lambda^*\left(\frac{k_2^2}{4}C_{x(2)}^2 + k_2C_{yx(2)}\right) > \lambda C + \lambda^* D$
7	$MSE(t_5) < MSE(t_3)$	$\lambda\left(k_2^2C_x^2 + k_2C_{yx}\right) + \lambda^*\left(k_2^2C_{x(2)}^2 + k_2C_{yx(2)}\right) > \lambda A + \lambda^* B$
8	$MMSE(t_5) < MSE(t_3)$	$\lambda\left(k_2^2C_x^2 + k_2C_{yx}\right) + \lambda^*\left(k_2^2C_{x(2)}^2 + k_2C_{yx(2)}\right) > \lambda C + \lambda^* D$

เมื่อ $A = (1-\alpha)C_x^2\left(k_2(1-\alpha) + 4K\right)$,

$B = (1-\alpha)C_{x(2)}^2\left(k_2(1-\alpha) + 4L\right)$,

$$C = \left(\frac{-(\lambda KC_x^2 + \lambda^* LC_{x(2)}^2)}{2(\lambda C_x^2 + \lambda^* C_{x(2)}^2)}\right)C_x^2 \times\left(\left(\frac{-2(\lambda KC_x^2 + \lambda^* LC_{x(2)}^2)}{(\lambda C_x^2 + \lambda^* C_{x(2)}^2)}\right) + 4K\right),$$

$$D = \left(\frac{-(\lambda KC_x^2 + \lambda^* LC_{x(2)}^2)}{2(\lambda C_x^2 + \lambda^* C_{x(2)}^2)}\right)C_{x(2)}^2 \times\left(\left(\frac{-2(\lambda KC_x^2 + \lambda^* LC_{x(2)}^2)}{(\lambda C_x^2 + \lambda^* C_{x(2)}^2)}\right) + 4L\right)$$

3.2 การเปรียบเทียบประสิทธิภาพของตัวประมาณโดยการประยุกต์จากข้อมูลจริง

ผู้วิจัยจะใช้ข้อมูลจริงจำนวน 2 ชุด ซึ่งเก็บรวบรวมโดย [14] และ [15] ตามลำดับ ดังนี้

ข้อมูลชุดที่ 1: เป็นข้อมูลทางการแพทย์เกี่ยวกับน้ำหนัก (หน่วย: กิโลกรัม) ความยาวรอบอก (หน่วย: เซนติเมตร) และความยาวรอบศรีษะ (หน่วย: เซนติเมตร) ของเด็กในกลุ่มผู้ปกครองมีฐานะ จำนวน 95 คน ที่อาศัยอยู่ในเมืองพาราณสี รัฐอุตรประเทศ ประเทศอินเดีย ในปี ค.ศ. 1983 ถึง ค.ศ. 1984 โดยน้ำหนัก ถูกกำหนดให้เป็นตัวแปรที่ต้องการศึกษา Y ในขณะที่ความยาวรอบอก ถูกกำหนดให้เป็นตัวแปรช่วย X จากข้อมูลที่เก็บรวบรวมมาได้กำหนดให้ข้อมูลจำนวน 25% ของเด็กในกลุ่มนี้ เป็นข้อมูลที่เกิดการไม่ตอบสนอง โดยรายละเอียดของข้อมูลแสดงดังนี้

$N = 95,\ n = 50,\ W_2 = 0.25,\ \bar{Y} = 19.497,$

$\bar{X} = 57.217,\ C_y^2 = 0.036,\ C_x^2 = 0.005,$

$C_{y(2)}^2 = 0.034,\ \rho_{yx} = 0.834,\ \rho_{yx(2)} = 0.427$

ข้อมูลชุดที่ 2: เป็นข้อมูลเกี่ยวกับผลผลิตทางการเกษตรของหมู่บ้านในชนบทจำนวน 96 หมู่บ้าน ที่ตั้งอยู่ในรัฐเบงกอลตะวันตก ประเทศอินเดีย โดยจำนวนคนงานในหมู่บ้าน ถูกกำหนดให้เป็นตัวแปรที่ต้องการศึกษา Y และพื้นที่เพาะปลูก ถูกกำหนดให้เป็นตัวแปรช่วย X จากข้อมูลที่เก็บรวบรวมมาได้กำหนดให้ข้อมูลจำนวน 25% ของพื้นที่เพาะปลูกที่มีเนื้อที่มากกว่า 160 เฮกตาร์เป็นข้อมูลที่เกิดการไม่ตอบสนอง โดยรายละเอียดของข้อมูลชุดนี้แสดงดังนี้

$N = 96,\ n = 40,\ W_2 = 0.25,\ \bar{Y} = 137.927,$

$\bar{X} = 144.872,\ C_y^2 = 0.036,\ C_x^2 = 0.659,$

$C_{y(2)}^2 = 0.034,\ \rho_{yx} = 0.773,\ \rho_{yx(2)} = 0.786$

ทั้งนี้ในการเปรียบเทียบประสิทธิภาพของตัวประมาณจะพิจารณาจากค่าความคลาดเคลื่อนกำลังสองเฉลี่ยและค่าร้อยละประสิทธิภาพสัมพัทธ์ จากสมการที่ (23) ดังต่อไปนี้

$$PRE(t_i) = \frac{MSE(\bar{y}^*)}{MSE(t_i)};\ i = 1, 2, \ldots, 5 \qquad (23)$$

ซึ่งผลการเปรียบเทียบประสิทธิภาพของตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ภายใต้การเลือกตัวอย่างแบบสองขั้นตอนที่นำเสนอขึ้นมาใหม่ t_4 และตัวประมาณ t_5 กับตัวประมาณ t_1 และ t_2 ที่นำเสนอโดย [1] ตัวประมาณ t_3 ที่นำเสนอโดย [2] และตัวประมาณที่นำเสนอโดย [3] แสดงดังตารางที่ 2 - 3 ดังนี้

ตารางที่ 2 : ผลการเปรียบเทียบประสิทธิภาพระหว่างตัวประมาณ t_4 กับตัวประมาณ t_1, t_3 และ $\bar{y}^*$ จากข้อมูลจริง

k	ข้อมูลชุดที่ 1			ข้อมูลชุดที่ 2		
	ตัวประมาณ	ค่า MSE	ค่า PRE	ตัวประมาณ	ค่า MSE	ค่า PRE
1	$\bar{y}^*$	0.12	100.00	$\bar{y}^*$	2.65	100.00
	t_1	0.07	184.96	t_1	1.07	248.47
	t_3	0.06	192.97	t_3	1.04	255.25
	t_4	0.05	254.80	t_4	0.92	289.13
2	$\bar{y}^*$	0.17	100.00	$\bar{y}^*$	4.96	100.00
	t_1	0.11	149.89	t_1	3.38	146.89
	t_3	0.11	156.30	t_3	3.35	148.17
	t_4	0.06	271.11	t_4	2.38	208.70
3	$\bar{y}^*$	0.21	100.00	$\bar{y}^*$	7.27	100.00
	t_1	0.16	135.31	t_1	5.69	127.84
	t_3	0.15	138.40	t_3	5.22	139.33
	t_4	0.11	197.97	t_4	4.70	154.79
4	$\bar{y}^*$	0.26	100.00	$\bar{y}^*$	9.58	100.00
	t_1	0.20	127.33	t_1	8.00	119.80
	t_3	0.19	134.18	t_3	7.60	126.03
	t_4	0.15	168.63	t_4	7.14	134.24
5	$\bar{y}^*$	0.31	100.00	$\bar{y}^*$	11.89	100.00
	t_1	0.25	122.29	t_1	10.31	115.36
	t_3	0.24	128.83	t_3	10.25	116.04
	t_4	0.20	152.81	t_4	9.79	121.49

ตารางที่ 3 : ผลการเปรียบเทียบประสิทธิภาพระหว่างตัวประมาณ t_5 กับตัวประมาณ t_2 , t_3 และ $\bar{y}^*$ จากข้อมูลจริง

k	ข้อมูลชุดที่ 1			ข้อมูลชุดที่ 2		
	ตัวประมาณ	ค่า MSE	ค่า PRE	ตัวประมาณ	ค่า MSE	ค่า PRE
1	$\bar{y}^*$	0.12	100.00	$\bar{y}^*$	2.65	100.00
	t_2	0.08	160.51	t_2	1.08	246.16
	t_3	0.06	192.97	t_3	1.04	255.25
	t_5	0.05	265.97	t_5	1.02	258.65
2	$\bar{y}^*$	0.17	100.00	$\bar{y}^*$	4.96	100.00
	t_2	0.12	135.74	t_2	3.39	146.13
	t_3	0.11	156.30	t_3	3.35	148.17
	t_5	0.08	204.50	t_5	2.89	171.41
3	$\bar{y}^*$	0.21	100.00	$\bar{y}^*$	7.27	100.00
	t_2	0.16	132.55	t_2	5.90	123.21
	t_3	0.15	138.40	t_3	5.22	139.33
	t_5	0.10	208.46	t_5	4.79	151.87
4	$\bar{y}^*$	0.26	100.00	$\bar{y}^*$	9.58	100.00
	t_2	0.20	130.58	t_2	7.79	122.99
	t_3	0.19	134.18	t_3	7.60	126.03
	t_5	0.12	218.99	t_5	6.23	153.70
5	$\bar{y}^*$	0.31	100.00	$\bar{y}^*$	11.89	100.00
	t_2	0.24	126.57	t_2	10.38	114.60
	t_3	0.24	128.83	t_3	10.25	116.04
	t_5	0.21	144.85	t_5	9.36	127.02

3.3 การเปรียบเทียบประสิทธิภาพของตัวประมาณโดยการการจำลองข้อมูล

ในการศึกษาเปรียบเทียบประสิทธิภาพของตัวประมาณที่นำเสนอกับตัวประมาณตัวอื่น ๆ ที่เกี่ยวข้องสำหรับประมาณค่าเฉลี่ยประชากร ผู้วิจัยจะทำการจำลองข้อมูลโดยใช้โปรแกรม R เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของตัวประมาณในเงื่อนไขต่าง ๆ ที่กำหนดในงานวิจัย โดยผู้วิจัยจะจำลองข้อมูลประชากร (X, Y) ที่มีการแจกแจงแบบปกติสองตัวแปร โดยที่ตัวแปรที่สนใจศึกษา Y มีค่าเฉลี่ยเท่ากับ 150 มีความแปรปรวนเท่ากับ 5 และตัวแปรช่วย X มีค่าเฉลี่ยเท่ากับ 180 มีความแปรปรวนเท่ากับ 10 (เมื่อ $Y = 114.10 + 0.2X$) กำหนดขนาดประชากรเท่ากับ 1,000 และกำหนดค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient: ρ_{yx}) คือ 0.2, 0.5 และ 0.8 ตามลำดับ จากนั้นจะทำการสุ่มตัวอย่างของตัวแปรช่วย X และตัวแปรที่สนใจศึกษา Y จากประชากรที่สร้างขึ้น โดยจะทำการเลือกตัวอย่างแบบสองขั้นตอน ด้วยขนาดตัวอย่างเท่ากับ 20 และ 120 ตามลำดับ โดยผลการเปรียบเทียบประสิทธิภาพของตัวประมาณ แสดงดังตารางที่ 4 – 5 ตามลำดับดังนี้

ตารางที่ 4 : ผลการเปรียบเทียบประสิทธิภาพระหว่างตัวประมาณ t_4 กับตัวประมาณ t_1 , t_3 และ $\bar{y}^*$ จากการจำลองข้อมูล

k	ตัวประมาณ	$\rho_{yx} = 0.2$		$\rho_{yx} = 0.5$		$\rho_{yx} = 0.8$	
		$n = 20$	$n = 120$	$n = 20$	$n = 120$	$n = 20$	$n = 120$
1	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_1	104.17	102.56	127.33	133.33	277.78	277.69
	t_3	105.69	104.81	139.85	138.12	330.22	298.06
	t_4	106.47	105.14	143.35	139.80	364.64	309.36
2	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_1	102.69	102.99	119.61	121.78	172.73	187.50
	t_3	104.66	104.33	132.35	135.78	253.05	277.98
	t_4	104.14	105.68	154.91	141.77	291.38	297.42
3	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_1	104.98	102.33	113.89	116.99	145.72	158.03
	t_3	103.79	103.76	125.54	126.11	282.12	267.71
	t_4	104.05	104.87	153.11	152.65	295.22	293.48
4	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_1	101.57	101.91	110.75	112.78	133.33	143.41
	t_3	103.17	103.29	120.84	125.86	175.06	291.39
	t_4	106.41	105.35	162.85	161.00	219.57	317.10
5	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_1	101.30	101.62	101.35	103.78	126.23	134.68
	t_3	103.72	104.91	117.49	114.78	288.95	273.99
	t_4	104.99	105.99	124.81	122.67	330.83	337.41

ตารางที่ 5 : ผลการเปรียบเทียบประสิทธิภาพระหว่างตัวประมาณ t_5 กับตัวประมาณ t_2 , t_3 และ $\bar{y}^*$ จากการจำลองข้อมูล

k	ตัวประมาณ	$\rho_{yx} = 0.2$		$\rho_{yx} = 0.5$		$\rho_{yx} = 0.8$	
		$n = 20$	$n = 120$	$n = 20$	$n = 120$	$n = 20$	$n = 120$
1	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_2	102.69	103.53	127.40	128.99	239.71	260.08
	t_3	105.69	104.81	139.85	138.12	330.22	298.06
	t_5	112.27	107.49	173.80	168.23	1348.57	421.06

k	ตัวประมาณ	$\rho_{yx}=0.2$		$\rho_{yx}=0.5$		$\rho_{yx}=0.8$	
		$n=20$	$n=120$	$n=20$	$n=120$	$n=20$	$n=120$
2	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_2	103.19	103.70	129.37	132.42	251.46	264.60
	t_3	104.66	104.33	132.35	135.78	253.05	277.98
	t_5	108.74	106.47	154.91	151.65	556.09	371.39
3	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_2	103.44	102.80	123.36	120.99	257.66	257.89
	t_3	103.79	103.76	125.54	124.11	282.12	267.71
	t_5	107.11	105.90	147.11	142.87	431.72	347.88
4	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_2	101.59	101.86	110.95	111.47	161.50	269.06
	t_3	103.17	103.29	120.84	125.86	175.06	291.39
	t_5	106.17	105.53	142.85	139.00	381.12	334.17
5	$\bar{y}^*$	100.00	100.00	100.00	100.00	100.00	100.00
	t_2	102.68	103.91	103.35	105.56	264.11	270.32
	t_3	103.72	104.91	117.49	124.78	288.95	273.99
	t_5	105.57	105.28	140.17	138.44	353.66	325.19

4. สรุปผล

จากการนำเสนอตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากร ภายใต้ปัญหาการไม่ตอบสนองในการสำรวจตัวอย่าง โดยพัฒนามาจากตัวประมาณที่ถูกนำเสนอโดย [1, 2] โดยแบ่งสถานการณ์การศึกษาออกเป็น 2 สถานการณ์ได้แก่ 1) เมื่อข้อมูลไม่ตอบสนองในตัวแปรสนใจศึกษาเพียงอย่างเดียว Y และ 2) เมื่อข้อมูลไม่ตอบสนองทั้งในตัวแปรสนใจศึกษา Y และตัวแปรช่วย X ตามลำดับ โดยผลการศึกษาในทางทฤษฎี พบว่า ตัวประมาณที่นำเสนอขึ้นมาใหม่ จะมีประสิทธิภาพดีกว่าตัวประมาณอื่น ๆ ที่เกี่ยวข้องเมื่อเงื่อนไขต่าง ๆ ที่แสดงในตารางที่ 1 เป็นจริง ในขณะที่การเปรียบเทียบประสิทธิภาพของตัวประมาณต่าง ๆ จากการประยุกต์จากข้อมูลจริง พบว่า เมื่อพิจารณาภายใต้ข้อมูลที่ทำการศึกษาชุดเดียวกันและสถานการณ์เดียวกัน ค่า MSE และ PRE ของตัวประมาณแต่ละตัว มีค่าที่ค่อนข้างใกล้เคียงกัน โดยตัวประมาณแบบเลขชี้กำลังที่นำเสนอขึ้นมาใหม่ เป็นตัวประมาณเดียวที่มีค่า MSE ที่ต่ำที่สุด และมีค่า PRE ที่สูงที่สุด ซึ่งให้ผลการเปรียบเทียบประสิทธิภาพฯ สอดคล้องกับการจำลองข้อมูล ดังนั้นจึงสามารถกล่าวได้ว่า ตัวประมาณแบบเลขชี้กำลังสำหรับประมาณค่าเฉลี่ยประชากรที่นำเสนอขึ้นมาใหม่ เป็นตัวประมาณที่มีประสิทธิภาพดีกว่าตัวประมาณอื่น ๆ ที่เกี่ยวข้องทุกตัว ภายใต้ชุดข้อมูลและสถานการณ์เดียวกันกับที่ศึกษาในงานวิจัยครั้งนี้

5. เอกสารอ้างอิง

[1] Ünal C, Kadilar C. Estimation of Population Mean Using Exponential Function under Non-response. Lobachevskii J. Math. 2021; 42(13):3285-3296.

[2] Ünal C, Kadilar C. Adapted Exponential Type Estimator in the Presence of Non-response. J. Reliab. Stat. Stud. 2021; 14(1):311-321.

[3] Hansen MH, Hurwitz WN. The Problem of Non-response in Sample Surveys. J. Am. Stat. Assoc. 1964; 41:517-529.

[4] Pal SK, Singh HP. A Class of Ratio-Cum-Ratio-Type Exponential Estimators for Population Mean with Sub Sampling the Non-respondents. Jordan J. Math. Stat. 2017; 10(1):73-94.

[5] Rao PSRS. Ratio Estimation with Sub Sampling the Nonrespondents. Surv. Methodol. 1986; 12: 217-230.

[6] Olufadi Y, Kumar S. Ratio-Cum-Product Estimator Using Exponential Estimator in the Presence of Non-response. J. Adv. Comput, 2014; 3(1):1-11.

[7] Singh GN, Usman M. Ratio-to-Product Exponential-Type Estimators under Non-response. Jordan J. Math. Stat. 2019; 12(4):593-616.

[8] Dansawad N. A Class of Exponential Estimator to Estimate the Population Mean in the Presence of Non-response. NUJST. 2019; 27(4):20-26.

[9] Singh R, Kumar M, Chaudhary MK, Smarandache F. Estimation of Mean in Presence of Non-response Using Exponential Estimator. Infinite study. 2009; arXiv preprint arXiv:0906.2462.

[10] Riaz S, Nazeer A, Abbasi J, Abbasi J, Qamar, S. On the Generalized Class of Estimators for Estimation of Finite Population Mean in the

Presence of Non-response Problem. J. Prime Res. Math. 2020; 16(1):52-63.

[11] Riaz S, Nazeer A, Abbasi J, Abbasi J, Qamar, S. On the Generalized Class of Estimators for Estimation of Finite Population Mean in the Presence of Non-response Problem. J. Prime Res. Math. 2020; 16(1):52-63.

[12] Vishwakarma GK, Singh R, Gupta, PC, Pareek S. Improved Ratio and Product Type Estimators of Finite Population Mean in Simple Random Sampling. Invest. oper. 2016; 36(3):70-76.

[13] Singh R, Chauhan P, Sawan N, Smarandache F. Improvement in Estimating the Population Mean Using Exponential Estimator in Simple Random Sampling. Bull. Stat. Econ. 2009, 3(13):13-18.

[14] Khare BB, Sinha RR. On Class of Estimators for the Product of Two Population Means Using Auxiliary Character in Presence of Non-response. ITAS. 2010; 2:841-846.

[15] Srivastava U, Kumar K, Khare BB. Chain Ratio Estimator for the Population Mean in the Presence of Non-response. SIT-ns. 2012; 13(3):495-518.

การจัดกลุ่มสาขาธนาคารที่มีการขายบัตรเดบิตพ่วงประกันภัย

Clustering of Bank Branches Offering Debit Cards Bundled with Insurance

ฉันทิกา ธรรมรักษาวงศ์[1] พิมลรัตน์ ธงสันเที๊ยะ[1] ธนัชชา วงษ์เจริญสิน[2] ภารดี รัตนเศรณี[2] บุปผชาติ จันทร์สว่าง[1] ดาวุด ทองทา[1*]

[1]ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

[2]บริษัทประกันวินาศภัยแห่งหนึ่ง

(***** *dawud.tho@kmutt.ac.th*)

บทคัดย่อ

การขายบัตรเดบิตพ่วงประกันภัยผ่านสาขาธนาคารในปัจจุบันต้องเผชิญกับความท้าทายในการนำเสนอขายบัตรเดบิตให้ตรงกับความต้องการของลูกค้าในแต่ละกลุ่มและในแต่ละพื้นที่ งานวิจัยนี้มีวัตถุประสงค์เพื่อจัดกลุ่มสาขาธนาคารที่ขายบัตรเดบิตพ่วงประกันอุบัติเหตุส่วนบุคคลของธนาคารแห่งหนึ่งและวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตดังกล่าวในแต่ละกลุ่ม โดยใช้ข้อมูลยอดขายบัตรเดบิตพ่วงประกันภัยอุบัติเหตุที่ขายผ่านสาขาจำนวน 919 สาขา ในปี ค.ศ. 2022-2023 ข้อมูลที่ใช้ในการจัดกลุ่มประกอบด้วยข้อมูลเชิงปริมาณและข้อมูลเชิงคุณภาพ เช่น ยอดขายบัตรเดบิต จำนวนพนักงานขายในแต่ละสาขา ข้อมูลประชากรตามพื้นที่ และสถานที่ตั้งสาขา ในงานวิจัยนี้ได้แบ่งข้อมูลตามพื้นที่ตั้งสาขาออกเป็น 2 ชุด ได้แก่ สาขาในกรุงเทพมหานครและปริมณฑล และสาขาในต่างจังหวัด และทำการจัดกลุ่มสาขาธนาคารด้วยวิธี K-prototypes และพิจารณาจำนวนกลุ่มที่เหมาะสมด้วยวิธี Elbow ผลการจัดกลุ่มพบว่าสาขาในกรุงเทพมหานครและปริมณฑลสามารถจัดกลุ่มได้เป็น 2 กลุ่ม ได้แก่ กลุ่มสาขาปริมณฑลซึ่งมียอดขายบัตรเดบิตสูง และกลุ่มสาขากรุงเทพซึ่งมียอดขายบัตรเดบิตต่ำ ส่วนสาขาในต่างจังหวัดสามารถจัดกลุ่มได้เป็น 3 กลุ่ม ได้แก่ กลุ่มสาขาในเมืองต่างจังหวัดซึ่งยอดขายสูงมาก, กลุ่มสาขาในพื้นที่ท่องเที่ยวและอุตสาหกรรมซึ่งมียอดขายสูง และกลุ่มสาขานอกเมืองต่างจังหวัดที่มียอดขายสูง จากการวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายในแต่ละกลุ่มด้วยวิธีต้นไม้ตัดสินใจและความสำคัญของตัวแปร พบว่าปัจจัยสำคัญที่ส่งผลต่อยอดขายส่วนใหญ่ ได้แก่ ความหนาแน่นของประชากร รายได้เฉลี่ยต่อหัวของประชากร และจำนวนพนักงานขายในแต่ละสาขา ผลการวิจัยนี้สามารถนำไปใช้ในการพัฒนากลยุทธ์การตลาดที่เหมาะสมสำหรับลูกค้าในแต่ละกลุ่มสาขาได้

คำสำคัญ: การจัดกลุ่มข้อมูลผสม, การจัดกลุ่มด้วยวิธี K-prototype, บัตรเดบิตพ่วงประกันอุบัติเหตุส่วนบุคคล, ประกันผ่านช่องทางธนาคาร

Abstract

Selling debit cards with insurance through bank branches currently faces the challenge of offering debit cards that meet customers' needs in each group and each area. This research aims to cluster the bank branches that sell the debit cards with personal accident insurance of a bank and analyze the factors affecting the sales of such debit cards in each group. The data of sales of debit cards with accident insurance sold through 919 branches in 2022-2023 were used in this research. The data used for grouping consisted of quantitative and qualitative data, such as debit card sales, the number of sale staff in each branch, demographic data by area, and branch locations. The data were divided into 2 sets by branch locations: branches in Bangkok and its vicinity and branches in the provinces. Clustering the bank branches was done by using the K-prototypes method, and the appropriate number of groups was considered by using the elbow method. The grouping results showed that branches in Bangkok and its vicinity could be grouped into 2 groups: the group of branches in the area with high debit card sales and the group of branches in Bangkok with low debit card sales. Branches in the provinces could be grouped into 3 groups: the group of branches in the provincial cities with very high sales, the group of branches in tourist and industrial areas with high sales and the group of branches outside the province with high sales. From the analysis of factors affecting sales in each group using the decision tree

method and the feature importance, it was found that the most important factors affecting sales were population density, average income per capita, and the number of sale staff in each branch. The results of this research can be used to develop appropriate marketing strategies for customers in each branch group.

Keywords: Bancassurance, K-prototype clustering, Mixed data clustering, Personal accident insurance-bundled debit card

1. บทนำ

การขายประกันภัยผ่านทางธนาคาร (Bancassurance) เป็นหนึ่งในช่องทางหลักที่บริษัทประกันวินาศภัยร่วมกับธนาคารในการขายผลิตภัณฑ์ให้กับลูกค้า ซึ่งธนาคารสามารถใช้ข้อมูลและความสัมพันธ์ที่มีกับลูกค้าในการให้บริการทางการเงินควบคู่ไปกับการนำเสนอผลิตภัณฑ์ประกันภัยที่ตรงกับความต้องการของลูกค้า ซึ่งทำให้ผลิตภัณฑ์บางประเภทได้รับการตอบรับที่ดีผ่านช่องทางนี้ หนึ่งในนั้นคือ บัตรเดบิตพ่วงประกันภัยอุบัติเหตุส่วนบุคคล ซึ่งเป็นผลิตภัณฑ์หนึ่งที่มีสัดส่วนยอดขายผ่านธนาคารสูงเมื่อเทียบกับผลิตภัณฑ์อื่นที่ขายผ่านช่องทางธนาคาร

การขายบัตรเดบิตพ่วงประกันภัยอุบัติเหตุส่วนบุคคลนี้สามารถทำได้ผ่านการเปิดบัญชีใหม่ การขอสินเชื่อ หรือการฝากเงิน โดยธนาคารจะนำเสนอข้อมูลเพื่อให้ลูกค้าเห็นประโยชน์ของผลิตภัณฑ์และอาจเสนอข้อเสนอพิเศษเพื่อจูงใจให้ลูกค้าเลือกใช้ผลิตภัณฑ์ การได้รับความคุ้มครองประกันภัยอุบัติเหตุนี้เป็นการเพิ่มระดับความมั่นคงและลดความเสี่ยงในการสูญเสียค่ารักษาพยาบาลให้กับลูกค้า นอกจากนี้ การขายผ่านช่องทางธนาคารยังทำให้ลูกค้าได้เข้าใจถึงสิทธิประโยชน์ของผลิตภัณฑ์และเป็นการเพิ่มความพึงพอใจของลูกค้าในการใช้บริการของธนาคารอีกด้วย

แม้ว่าการใช้กลยุทธ์การขายประกันภัยผ่านทางธนาคารจะมีศักยภาพในการเพิ่มยอดขายอย่างมีนัยสำคัญ บริษัทประกันภัยยังคงเผชิญกับความท้าทายในการวิเคราะห์ความต้องการของลูกค้าผ่านยอดขายที่แตกต่างกันและประเภทบัตรเดบิตพ่วงประกันภัยในแต่ละสาขาธนาคาร ซึ่งอาจจะเกิดจากหลายปัจจัย เช่น ปัจจัยทางด้านที่ตั้งสาขา รายได้เฉลี่ยและความหนาแน่นของประชากรในพื้นที่ จำนวนพนักงานขาย และเงื่อนไขความคุ้มครองของประกันภัยอุบัติเหตุ เป็นต้น ลูกค้าแต่ละประเภทอาจมีความต้องการที่แตกต่างกัน ดังนั้นการวิเคราะห์ยอดขายประกันภัยพ่วงบัตรเดบิตผ่านปัจจัยในหลายมิติเป็นขั้นตอนที่สำคัญในการทำความเข้าใจลูกค้า รวมถึงปัจจัยที่ส่งผลต่อความแตกต่างของยอดขายบัตรตามสาขาธนาคาร การเข้าใจถึงปัจจัยเหล่านี้จะช่วยให้บริษัทประกันภัยสามารถพัฒนาผลิตภัณฑ์และกลยุทธ์การตลาดที่ตอบโจทย์ความต้องการเฉพาะลูกค้าแต่ละประเภทและในแต่ละพื้นที่ได้อย่างมีประสิทธิภาพ นอกจากนี้การพัฒนาดังกล่าวอาจเป็นการเพิ่มยอดขายบัตรเดบิตพ่วงประกันภัยให้สูงขึ้นได้ในระยะยาว ดังนั้นการทำความเข้าใจลูกค้าผ่านการจัดกลุ่มสาขาธนาคารที่ขายบัตรเดบิตพวกประกันภัยและทำการวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตดังกล่าวจะเป็นข้อมูลที่ช่วยให้บริษัทประกันภัยใช้ในการพัฒนาผลิตภัณฑ์และกลยุทธ์ทางการตลาดได้ดียิ่งขึ้น

การจัดกลุ่มข้อมูลเชิงปริมาณและข้อมูลเชิงคุณภาพด้วยวิธี K-Prototypes เป็นวิธีที่ได้รับการยอมรับ เช่น งานวิจัยของ Huang [1] ในปี 1998 ได้พัฒนาวิธี K-Prototypes โดยทดลองกับชุดข้อมูลจริง เช่น โรคพืชถั่วเหลือง (soybean disease) และการอนุมัติสินเชื่อ (credit approval) พบว่า วิธี K-Prototypes มีความเหมาะสมและมีประสิทธิภาพในการจัดกลุ่มข้อมูลที่มีทั้งตัวแปรเชิงปริมาณและเชิงคุณภาพได้มากกว่าวิธี K-means นอกจากนี้งานวิจัยของ Sharan และคณะ [2] ในปี 2022 ซึ่งศึกษาการจัดกลุ่มลูกค้าพาณิชย์อิเล็กทรอนิกส์ (E-Commerce) ด้วยวิธี K-Prototypes, K-Modes, DBSCAN และ Hierarchical Agglomerative Clustering พบว่า วิธี K-Prototypes เป็นวิธีที่มีประสิทธิภาพในการจัดการข้อมูลทั้งเชิงปริมาณและเชิงคุณภาพมากกว่าวิธีอื่น สามารถแบ่งกลุ่มลูกค้าเป็นไปอย่างมีประสิทธิภาพและตรงกับลักษณะพฤติกรรมที่หลากหลายของลูกค้าในธุรกิจ E-Commerce อีกทั้งงานวิจัยของ Kiefer และคณะ [3] ในปี 2019 ศึกษาการแบ่งกลุ่มลูกค้าวัยรุ่นตามพฤติกรรมสำหรับการโฆษณาโดยใช้วิธี K-Prototypes โดยใช้ข้อมูลพฤติกรรมที่ได้จากการสำรวจความคิดเห็นที่มีทั้งคุณลักษณะเชิงปริมาณและเชิงคุณภาพ ผลการศึกษาพบว่าการแบ่งกลุ่มลูกค้าโดยใช้ K-Prototypes สามารถแบ่งกลุ่มลูกค้าออกเป็นหลายกลุ่มตามพฤติกรรม ซึ่งสามารถใช้ประโยชน์ในการกำหนดประเภทของโฆษณาที่เหมาะสมสำหรับลูกค้าแต่ละกลุ่ม และในปี 2021 Sroka [4] ศึกษาการใช้ K-Prototypes ในการจัดกลุ่มลูกค้าของบริษัทในระบบการตลาดแบบหลายระดับ (Multi-Level Marketing, MLM) โดยใช้ข้อมูลการขายของบริษัทที่มีทั้งข้อมูลเชิงปริมาณและข้อมูลเชิงคุณภาพ ผลการศึกษาพบว่า ผลการศึกษาพบว่า K-Prototypes สามารถจัดการข้อมูลทั้งเชิงปริมาณและเชิงคุณภาพได้อย่างมีประสิทธิภาพ และสามารถระบุกลุ่มลูกค้าที่มีความสนใจต่างกันในธุรกิจ MLM ได้ สำหรับการศึกษาความสำคัญของปัจจัยที่ส่งผลต่อตัวแปรตามด้วยวิธีต้นไม้ตัดสินใจนั้น ในปี 2017 Kazemitabar และคณะ [5] ได้ศึกษาการวิเคราะห์ความสำคัญของตัวแปรในแบบจำลองต้นไม้ตัดสินใจและแบบจำลองป่าสุ่ม โดยเปรียบเทียบผลลัพธ์การวิเคราะห์ความสำคัญของตัวแปรด้วยวิธีที่ใช้ค่าความบริสุทธิ์ของข้อมูล (impurity-based) และการวัดแบบอื่น ๆ ผลการศึกษาพบว่า วิธีที่ใช้ค่าความบริสุทธิ์สามารถให้ข้อมูลเกี่ยวกับความสำคัญของตัวแปรได้ดี แต่ยังมีข้อจำกัดในแง่ของทฤษฎีและอาจได้รับผลกระทบจากโครงสร้างของโมเดลต้นไม้ที่ใช้ และในปี 2023 ฐิติพร [6] ได้ศึกษาการจัดกลุ่ม

ลูกค้าบัตรเครดิตของบริษัทแห่งหนึ่ง และศึกษาความสำคัญของปัจจัยที่มีอิทธิพลต่อการทำนายกลุ่มของลูกค้าโดยใช้แบบจำลองต้นไม้ตัดสินใจ (Decision Tree) พบว่า รายได้ เพศ วงเงินบัตรเครดิตเป็นปัจจัยหลักที่ส่งผลต่อการทำนายกลุ่มลูกค้าบัตรเครดิต ซึ่งช่วยให้บริษัทเข้าใจพฤติกรรมและความต้องการของลูกค้าในแต่ละกลุ่ม

งานวิจัยนี้มีวัตถุประสงค์เพื่อจัดกลุ่มสาขาธนาคารที่ขายบัตรเดบิตพ่วงประกันอุบัติเหตุของธนาคารแห่งหนึ่งและวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตดังกล่าวในแต่ละกลุ่ม โดยใช้ข้อมูลยอดขายบัตรเดบิตพ่วงประกันของธนาคารพาณิชย์แห่งหนึ่งจำนวน 919 สาขาทั่วประเทศไทย ซึ่งเป็นข้อมูลในปี 2022-2023 ผู้วิจัยแบ่งข้อมูลสาขาธนาคารออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลสาขาธนาคารกรุงเทพมหานครและปริมณฑล และชุดข้อมูลสาขาธนาคารต่างจังหวัด เนื่องจากการศึกษาความต้องการและพฤติกรรมของลูกค้าในแต่ละพื้นที่จะสามารถให้ข้อมูลเชิงลึกที่สำคัญเกี่ยวกับลักษณะการเข้าถึงและการใช้บริการทางการเงินและการประกันภัยได้ดีขึ้น โดยเฉพาะในพื้นที่ชนบทและเขตเมืองที่มีลักษณะทางเศรษฐกิจ สังคม และวัฒนธรรมที่แตกต่างกัน นอกจากนี้การแบ่งข้อมูลสาขาธนาคารเป็น 2 ชุดยังสอดคล้องกับงานวิจัยที่ศึกษาความแตกต่างในการเข้าถึงบริการทางการเงินระหว่างพื้นที่ชนบทและเมือง รวมถึงพฤติกรรมการใช้บัตรเดบิตและความต้องการประกันภัยในแต่ละพื้นที่ โดยงานวิจัย [7] พบว่า ผู้คนในเขตเมืองมีการเข้าถึงบริการทางการเงินที่ดีและบ่อยครั้งกว่าผู้คนในพื้นที่ชนบท ในงานวิจัย [8] พบว่า ผู้คนในเขตเมืองมีการใช้บัตรเดบิตและความต้องการประกันภัยที่สูงกว่าเนื่องจากสามารถเข้าถึงข้อมูลและทรัพยากรที่ดีกว่าเมื่อเทียบกับผู้คนในพื้นที่ชนบท อีกทั้งงานวิจัยในด้านนโยบายการพัฒนาประเทศ [9] พบว่า การกระจุกตัวของการพัฒนาในเมืองใหญ่ทำให้เกิดความแตกต่างในการเข้าถึงโอกาสทางเศรษฐกิจและสังคม ซึ่งมีผลต่อการเข้าถึงและความต้องการประกันภัยในพื้นที่ต่าง ๆ ดังนั้นในงานวิจัยนี้ ผู้วิจัยจึงเลือกใช้วิธี K-Prototypes Clustering ในการจัดกลุ่มซึ่งเป็นวิธีที่เหมาะสมสำหรับการวิเคราะห์ข้อมูลที่มีทั้งตัวแปรเชิงปริมาณและตัวแปรเชิงคุณภาพ [1] และใช้วิธีต้นไม้ตัดสินใจ ในการวิเคราะห์ความสำคัญของปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตพ่วงประกันแต่ละประเภทในแต่ละกลุ่ม

2. วิธีการวิจัย

คณะผู้วิจัยได้ทำการจัดกลุ่มสาขาธนาคารและวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตพ่วงประกันภัยตามขั้นตอนดังภาพที่ 1

2.1 จัดเตรียมข้อมูลสำหรับการทำวิจัย

ทางคณะผู้วิจัยได้ทำการรวบรวมข้อมูลยอดขายบัตรเดบิตพ่วงประกันอุบัติเหตุทุกสาขาของธนาคารพาณิชย์แห่งหนึ่งตั้งแต่ปี ค.ศ. 2022-2023 จำนวน 919 สาขา หลังจากนั้นได้ทำการศึกษาปัจจัยเพิ่มเติมและแบ่งข้อมูลกลุ่มสาขาธนาคารเป็น 2 ชุด ดังนี้

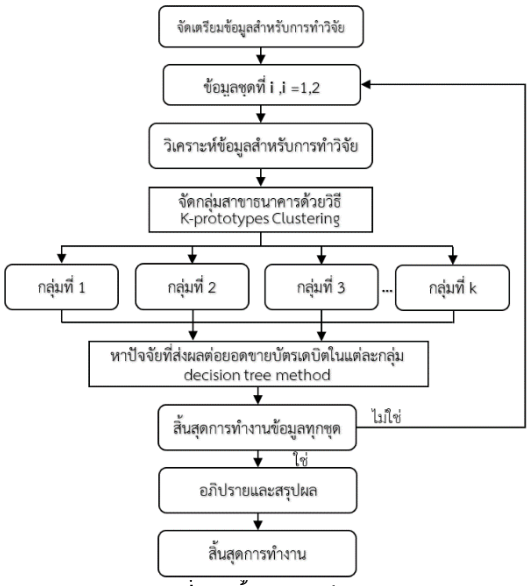

ภาพที่ 1 : ขั้นตอนวิธีการวิจัย

2.1.1 ศึกษาปัจจัยเพิ่มเติมในการจัดกลุ่ม

ข้อมูลดิบที่รวบรวมได้สำหรับการทำวิจัยเบื้องต้นมี 4 ตัวแปร ได้แก่ เลขที่อยู่สาขาและยอดขายบัตรเดบิตพ่วงประกัน 3 ประเภทที่ขายได้ในแต่ละสาขา ผู้วิจัยจึงได้ศึกษางานวิจัยและปรึกษาผู้เชี่ยวชาญในภาคธุรกิจประกันภัยเกี่ยวกับแนวทางในการกำหนดกลยุทธ์ทางการตลาดและการนำผลการจัดกลุ่มไปใช้งานจริง จึงกำหนดตัวแปรเพิ่มเติมที่สอดคล้องกับแนวทางการวางกลยุทธ์ทางการตลาดดังนี้: สถานที่ตั้งสาขาธนาคารอยู่ในห้างหรือนอกห้าง และตั้งอยู่ในเมืองหรือนอกเมือง อัตราการเติบโตของยอดขายบัตรรวมทั้ง 3 ประเภทแยกตามสาขา จำนวนพนักงานขายในแต่ละสาขา รายได้เฉลี่ยต่อหัวของประชากรรายจังหวัด ความหนาแน่นของประชากรรายอำเภอ จำนวนสถานพยาบาลในเครือของบัตรเดบิตแต่ละประเภทตามแต่ละจังหวัด โดยมีรายละเอียดดังนี้

ชื่อปัจจัย	ลักษณะข้อมูล
จำนวนยอดขายบัตรประเภท 1,2 และ 3 (ใบ)	จำนวนยอดขายบัตรเดบิตประเภท 1,2 และ 3 ต่อสาขาธนาคาร
อัตราการเติบโตของยอดขายบัตร 3 ประเภท (เปอร์เซ็นต์)	เปอร์เซ็นต์การเปลี่ยนแปลงของยอดขายบัตรทั้ง 3 ประเภทเมื่อเทียบกับช่วงปี ค.ศ. 2022 และ 2023 ของแต่ละสาขาธนาคาร
จำนวนพนักงานขายต่อสาขา (จำนวนพนักงาน)	จำนวนพนกงานที่ทำหน้าที่ขายบัตรเดบิตของแต่ละสาขาธนาคาร
รายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด (บาท/คน/เดือน)	ค่าเฉลี่ยของรายได้ต่อประชากรหนึ่งคนในแต่ละจังหวัด คำนวณจากรายได้รวมของประชากรหารด้วยจำนวนประชากร [10]

ความหนาแน่นของประชากรรายอำเภอ (คน/ตร.กม.)	จำนวนประชากรเฉลี่ยต่อพื้นที่หนึ่งตารางกิโลเมตรของแต่ละอำเภอ [11]
สถานพยาบาลบัตรประเภท 1,2 และ 3 ดัง	จำนวนสถานพยาบาลที่ให้บริการตามประเภทของบัตร 1, 2 และ 3 ในแต่ละจังหวัดที่ธนาคารตั้งอยู่
สาขาในห้าง/นอกห้าง	สาขาธนาคารตั้งอยู่ภายในห้างสรรพสินค้าหรืออยู่นอกห้าง
สาขาในเมือง/นอกเมือง	สาขาธนาคารตั้งอยู่ในพื้นที่เมืองหรือนอกเมือง

โดยใช้ตัวแปรในการจัดกลุ่มสาขาทั้งสิ้น 12 ตัวแปร และบัตรเดบิตพ่วงประกัน 3 ประเภท มีความแตกต่างกันในด้านจุดเด่นผลิตภัณฑ์ ความคุ้มครองอุบัติเหตุ สิทธิประโยชน์ โดยราคาของบัตรเดบิตพ่วงประกันประเภท 1, 2 และ 3 มีความคุ้มครองเพิ่มขึ้นตามลำดับ และมีราคาบัตรเพิ่มขึ้นประมาณ 1.6 เท่าของประเภทก่อนหน้า

2.1.2 แบ่งข้อมูลสาขาธนาคารเป็น 2 ชุด

ผู้วิจัยได้ทำการแบ่งข้อมูลของสาขาธนาคารออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลสาขาธนาคารที่ตั้งอยู่กรุงเทพมหานครและปริมณฑล และชุดข้อมูลสาขาธนาคารที่ตั้งอยู่ต่างจังหวัด (สาขาทั่วประเทศไม่รวมกรุงเทพมหานครและปริมณฑล) เนื่องจากการเข้าถึงเทคโนโลยีและอัตราการใช้บัตรเดบิตทั้ง 2 กลุ่มนี้มีความแตกต่างกันอย่างมีนัยสำคัญ [7-9]

2.2 วิเคราะห์ข้อมูลสำหรับงานวิจัยและการจัดกลุ่ม

งานวิจัยนี้วิเคราะห์ข้อมูลและทำการจัดกลุ่มโดยใช้โปรแกรม RStudio มีรายละเอียดดังนี้

2.2.1 สถิติพรรณนา

ผู้วิจัยได้ทำการวิเคราะห์ข้อมูลพื้นฐานของแต่ละชุดข้อมูล เช่น ยอดขาย อัตราการเติบโต และรายได้เฉลี่ย ด้วยสถิติพรรณนา เช่น ค่าร้อยละ ค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน

2.2.2 การจัดกลุ่มสาขาธนาคาร

งานวิจัยนี้จัดกลุ่มสาขาธนาคารโดยวิธี K-prototypes ซึ่งเป็นวิธีการจัดกลุ่มข้อมูลแบบผสม โดยหลักการในการจัดกลุ่มคือจะจัดให้ข้อมูลที่มีลักษณะคล้ายคลึงอยู่ในกลุ่มเดียวกัน [12] โดยมีขั้นตอนดังนี้

1.ปรับข้อมูลเชิงปริมาณที่จะนำมาจัดกลุ่มให้เป็นค่ามาตรฐาน เพื่อกำจัดความแตกต่างของข้อมูลที่มีหน่วยหรือขนาดที่แตกต่างกัน โดยทำ standardization ให้มีค่าเฉลี่ยเป็น 0 และส่วนเบี่ยงเบนมาตรฐานเป็น 1 ซึ่งการปรับค่ามาตรฐานจะช่วยให้ลดความเอนเอียง ได้ด้วยดังสมการด้านล่างนี้

$$z = \frac{x - \bar{x}}{s} \quad (1)$$

โดย x คือค่าจริงของตัวแปร, $\bar{x}$ คือค่าเฉลี่ยของตัวแปร x และ s คือส่วนเบี่ยงเบนมาตรฐานของตัวแปร x ที่คำนวณโดยใช้สูตรส่วนเบี่ยงเบนมาตรฐานของกลุ่มตัวอย่าง

2. จัดกลุ่มสาขาธนาคารโดยใช้ข้อมูลชุดที่ 1 และ 2 ด้วยวิธี K-prototypes ในชุดข้อมูลที่มีทั้งตัวแปรเชิงปริมาณและตัวแปรเชิงคุณภาพ โดยคำนวณระยะทางระหว่างข้อมูลตามสมการ (2) ซึ่งในพจน์แรกเป็นการวัดระยะทางแบบยูคลิด (Euclidean distance) สำหรับตัวแปรเชิงปริมาณ และพจน์ที่สอง ใช้การวัดความแตกต่างกันของค่าสังเกต (Simple Matching Dissimilarity) สำหรับตัวแปรเชิงคุณภาพ โดยมีค่า λ สำหรับถ่วงน้ำหนัก เพื่อปรับความสำคัญของตัวแปรเชิงคุณภาพในฟังก์ชันระยะทางในสมการ (2) ซึ่ง λ คำนวณจากสูตร $1 - \max(p_i)$ เมื่อ $\max(p_i)$ คือความถี่สูงสุดของข้อมูลสามารถปรับได้ตามความรู้ของนักวิจัยเกี่ยวกับชุดข้อมูล หากนักวิจัยคิดว่าตัวแปรเชิงหมวดหมู่ควรมี ผลกระทบสูงขึ้นในการจัดกลุ่มค่าถ่วงน้ำหนัก ควรมีค่าสูง สามารถคำนวณได้ดังสมการดังนี้

$$d_{MT} = \sum_{j=1}^{l} (x_j - y_j)^2 + \lambda \sum_{j=l+1}^{m} \delta(x_j, y_j) \quad (2)$$

โดยที่ $\delta(x_j, y_j) = \begin{cases} 0 \ if x_j = y_j, \\ 1 \ if x_j \neq y_j \end{cases}$ เมื่อ X, Y คือ ข้อมูลสองจุดที่เปรียบเทียบกัน, x_j, y_j คือค่าของตัวแปรมิติที่ j ของ X และ Y, l คือจำนวนตัวแปรเชิงปริมาณและ m คือจำนวนตัวแปรเชิงคุณภาพ ในการจัดกลุ่มด้วยวิธี K-prototypes นั้นจำเป็นต้องกำหนดจำนวนกลุ่ม (k) ที่เหมาะสม ผู้วิจัยจึงเลือกใช้วิธี Elbow ซึ่งจะเป็นวิธีการพิจารณาระยะทางจุดข้อมูลสมาชิกในกลุ่มที่จัดได้กับจุด centroid ของกลุ่มนั้น ๆ และนำค่าผลรวมของระยะทางดังกล่าวมาวาดกราฟตามพิกัดจำนวนกลุ่ม (แกนนอน) และผลรวมระยะทางกำลังสอง (แกนตั้ง) ถ้าจำนวนกลุ่มเพิ่มขึ้นจะทำให้ค่าเฉลี่ยของระยะทางดังกล่าวมีแนวโน้มน้อยลงและเมื่อค่าเฉลี่ยน้อยลงจนเริ่มอิ่มตัว ความชันของเส้นโค้งจะเริ่มคงที่และเกิดมุมหักศอก จำนวนกลุ่มที่เหมาะสมพิจาณาจากจุดที่เกิดการหักศอกมากที่สุด นอกจากนี้จำนวนกลุ่มที่เหมาะสมอาจพิจารณาจากบริบทของข้อมูลหรือวัตถุประสงค์ของการวิเคราะห์อีกด้วย

2.3 วิเคราะห์ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตในแต่ละกลุ่ม

หลังจากจัดกลุ่มสาขาธนาคารในข้อมูลชุดที่ 1 และ 2 แล้ว ข้อมูลของสาขาในแต่ละกลุ่มจะถูกนำมาวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตทั้ง 3 ประเภท ด้วยวิธีต้นไม้ตัดสินใจโดยดูระดับความสำคัญของปัจจัยที่ส่งผลต่อจำนวนยอดขายบัตรเดบิตแต่ละประเภทจากค่า Feature Importance

3. ผลการวิจัยและอภิปรายผล

ผลการจัดกลุ่มสาขาธนาคารที่มีการขายบัตรเดบิตพ่วงประกันอุบัติเหตุ มีดังนี้

3.1 สถิติพรรณนา

ผู้วิจัยได้ทำการวิเคราะห์สถิติพรรณนาของข้อมูลสาขาธนาคารที่ตั้งอยู่ในกรุงเทพและปริมณฑลและสาขาที่ตั้งต่างจังหวัด โดยการคำนวณในรูปของค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน และร้อยละ ดังนี้

3.1.1 ข้อมูลชุดที่ 1: สาขาธนาคารตั้งอยู่กรุงเทพมหานครและปริมณฑล

ตารางที่ 1 แสดงค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ของตัวแปรเชิงปริมาณ

ตัวแปร	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน
จำนวนยอดขายบัตรประเภท 1	309.09	284.56
จำนวนยอดขายบัตรประเภท 2	205.44	253.38
จำนวนยอดขายบัตรประเภท 3	203.62	242.91
อัตราการเติบโตของยอดขายบัตร 3 ประเภท	0.39	0.71
จำนวนพนักงานขายต่อสาขา	5.50	3.37
รายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด	38,799.71	3,741.11
ความหนาแน่นของประชากรรายอำเภอ	5,083.37	3,632.23
สถานพยาบาลบัตรประเภท 1	65.86	39.04
สถานพยาบาลบัตรประเภท 2	79.18	47.08
สถานพยาบาลบัตรประเภท 3	80.67	47.83

จากตารางที่ 1 แสดงผลการวิเคราะห์ข้อมูลสถิติพรรณนาของตัวแปรเชิงปริมาณของข้อมูลสาขาธนาคารที่ตั้งอยู่ในกรุงเทพและปริมณฑลทั้งหมด 279 สาขา พบว่า จำนวนยอดขายบัตรเดบิตประเภทที่ 1 มีค่าเฉลี่ยสูงสุดที่ 309.09 ใบ รองลงมาคือประเภทที่ 2 และ 3 ที่ 205.44 ใบ และ 203.62 ใบ ตามลำดับ โดยมีอัตราการเติบโตเฉลี่ยของยอดขายบัตรเดบิตทั้ง 3 ประเภทอยู่ที่ 39% จำนวนพนักงานขายบัตรต่อสาขาเฉลี่ยอยู่ที่ 5.50 คน ปัจจัยทางเศรษฐกิจและประชากรศาสตร์แสดงให้เห็นว่ารายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัดอยู่ที่ 38,799.71 บาท ความหนาแน่นของประชากรรายอำเภอมีค่าเฉลี่ยอยู่ที่ 5,083.37 คนต่อตารางกิโลเมตร แสดงถึงความหนาแน่นของประชากรมาก และมีจำนวนสถานพยาบาลที่รองรับบัตรเดบิตแต่ละประเภทสูงมีค่าเฉลี่ยอยู่ในช่วง 65-81 สถานพยาบาล

ตารางที่ 2 แสดงจำนวนสาขา ร้อยละสาขาในห้างหรือนอกห้างและสาขาในเมืองหรือนอกเมือง

ตัวแปร	จำนวนสาขา	ร้อยละ
สาขาในห้าง/นอกห้าง		
ในห้าง	77	27.60
นอกห้าง	202	72.40
สาขาในเมือง/นอกเมือง		
ในเมือง	155	55.56
นอกเมือง	124	44.44
รวม	279	100.00

จากตารางที่ 2 พบว่าการกระจายตัวของสถานที่ตั้งสาขาในธนาคารกรุงเทพและปริมณฑลทั้งหมด 279 สาขานั้น สาขาส่วนใหญ่ตั้งอยู่นอกห้างคิดเป็นร้อยละ 72.40 และสาขาส่วนใหญ่ตั้งอยู่ในเมืองซึ่งคิดเป็นร้อยละ 55.56 ของสาขาทั้งหมด

3.1.2 ข้อมูลชุดที่ 2: สาขาธนาคารตั้งอยู่ต่างจังหวัด

ตารางที่ 3 แสดงค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ของตัวแปรเชิงปริมาณ

ตัวแปร	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน
จำนวนยอดขายบัตรประเภท 1	757.35	531.97
จำนวนยอดขายบัตรประเภท 2	352.01	365.81
จำนวนยอดขายบัตรประเภท 3	605.33	601.85
อัตราการเติบโตของยอดขายบัตร 3 ประเภท	0.29	0.48
จำนวนพนักงานขายต่อสาขา	6.29	2.48
รายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด	26,755.17	5,883.61
ความหนาแน่นของประชากรรายอำเภอ	322.03	340.20
สถานพยาบาลบัตรประเภท 1	4.41	5.29
สถานพยาบาลบัตรประเภท 2	5.79	8.51
สถานพยาบาลบัตรประเภท 3	6.54	8.14

จากตารางที่ 3 แสดงผลการวิเคราะห์ข้อมูลสถิติพรรณนาของตัวแปรเชิงปริมาณ จากข้อมูลชุดที่ 2 พบว่า จำนวนยอดขายบัตรเดบิตประเภทที่ 1 มีค่าเฉลี่ยสูงสุดที่ 757.35 ใบ รองลงมาคือประเภทที่ 3 และ 2 ที่ 605.33 ใบ และ 352.01 ใบ ตามลำดับ อัตราการเติบโตเฉลี่ยของยอดขายบัตรเดบิตทั้ง 3 ประเภทอยู่ที่ 29% จำนวนพนักงานขายบัตรต่อสาขาเฉลี่ยอยู่ที่ 6.29 คน ปัจจัยทางเศรษฐกิจและประชากรศาสตร์ แสดงให้เห็นว่ารายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัดอยู่ที่ 26,755.17 บาท ความหนาแน่นของประชากรรายอำเภอมีค่าเฉลี่ยอยู่ที่ 322.03 คนต่อตารางกิโลเมตร และจำนวนสถานพยาบาลที่รองรับบัตรเดบิตแต่ละประเภทมีค่าเฉลี่ยใกล้เคียงกันอยู่ในช่วง 4-7 สถานพยาบาลซึ่งพบว่าน้อยกว่าจำนวนสถานพยาบาลเฉลี่ยของข้อมูลชุดที่ 1 มาก

ตารางที่ 4 แสดงจำนวนสาขา ร้อยละสาขาในห้างหรือนอกห้างและสาขาในเมืองหรือนอกเมือง

ตัวแปร	จำนวนสาขา	ร้อยละ
สาขาในห้าง/นอกห้าง		
ในห้าง	106	16.56
นอกห้าง	534	83.44
สาขาในเมือง/นอกเมือง		
ในเมือง	266	41.56
นอกเมือง	374	58.44
รวม	640	100.00

จากตารางที่ 4 พบว่าการกระจายตัวของสถานที่ตั้งสาขาธนาคารตั้งอยู่ต่างจังหวัดทั้งหมด 640 สาขา สาขาส่วนใหญ่ตั้งอยู่นอกห้างคิดเป็นร้อยละ 83.44 และสาขาส่วนใหญ่ตั้งอยู่นอกเมือง คิดเป็นร้อยละ 58.44 ของสาขาทั้งหมด

3.2 ผลการจัดกลุ่มสาขาธนาคาร

การกำหนดจำนวนกลุ่มที่เหมาะสมสำหรับการจัดกลุ่มสาขาธนาคารจากตัวแปร 12 ตัวจะพิจารณาจากจุดหักศอกจากวิธีการ Elbow

3.2.1 การกำหนดจำนวนกลุ่มที่เหมาะสมสำหรับข้อมูลชุดที่ 1: สาขาธนาคารที่ตั้งอยู่ในกรุงเทพมหานครและปริมณฑล

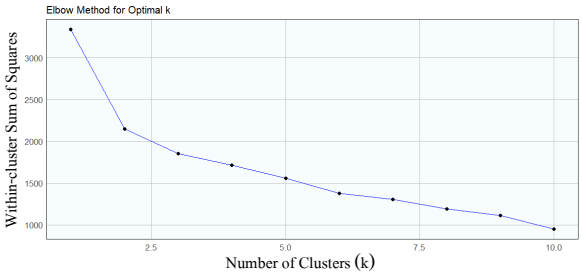

ภาพที่ 2: กราฟ Elbow Method สำหรับการกำหนดจำนวนกลุ่มที่เหมาะสมของข้อมูลชุดที่ 1

จากการจัดกลุ่มข้อมูลสาขาธนาคารในกรุงเทพมหานครและปริมณฑลด้วยวิธี K-prototypes โดยใช้วิธีการ Elbow จากกราฟผู้วิจัยตัดสินใจเลือกจุดหักศอกที่ 2 กลุ่ม เนื่องจากมีการเปลี่ยนแปลงของความชันมากที่สุด

3.2.2 การกำหนดจำนวนกลุ่มที่เหมาะสมสำหรับข้อมูลชุดที่ 2: สาขาธนาคารที่ตั้งอยู่ต่างจังหวัด

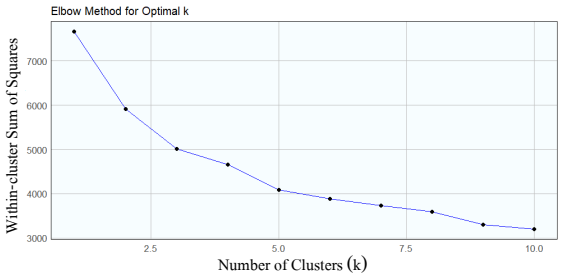

ภาพที่ 3: กราฟ Elbow Method สำหรับการกำหนดจำนวนกลุ่มที่เหมาะสมของข้อมูลชุดที่ 2

จากการจัดกลุ่มข้อมูลสาขาธนาคารต่างจังหวัดด้วยวิธี K-prototypes โดยใช้วิธี Elbow ผู้วิจัยตัดสินใจเลือกจัดกลุ่มจำนวน 3 กลุ่ม หลังจากได้ดำเนินการจัดกลุ่มด้วยวิธี K-prototypes ผู้วิจัยได้ทำการวิเคราะห์ข้อมูลเบื้องต้น ดังนี้

3.2.3 ผลการวิเคราะห์การจัดกลุ่มสาขาธนาคารสำหรับข้อมูลชุดที่ 1: สาขาธนาคารที่ตั้งอยู่ในกรุงเทพมหานครและปริมณฑล

ตารางที่ 5 แสดงจำนวนสมาชิก ค่าเฉลี่ยของตัวแปรเชิงปริมาณและความถี่ของตัวแปรเชิงคุณภาพ

Cluster	1	2
จำนวนยอดขายบัตรประเภทที่ 1	501	213
จำนวนยอดขายบัตรประเภทที่ 2	346	135
จำนวนยอดขายบัตรประเภทที่ 3	326	143
อัตราการเติบโตของยอดขายบัตร 3 ประเภท	0.327	0.419
จำนวนพนักงานขายต่อสาขา	6.43	5.04
รายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด	36,297	40,051
ความหนาแน่นของประชากรรายอำเภอ	1,964	6,643
สถานพยาบาลบัตรประเภทที่ 1	11.6	93
สถานพยาบาลบัตรประเภทที่ 2	13.5	112
สถานพยาบาลบัตรประเภทที่ 3	14.0	114
สาขาในห้าง/นอกห้าง		
ในห้าง	32	45
นอกห้าง	61	141
สาขาในเมือง/นอกเมือง		
ในเมือง	36	119
นอกเมือง	57	67
จำนวนสมาชิก	93	186

จากตารางที่ 5 ผลการจัดกลุ่มด้วยปัจจัย 12 ปัจจัยที่เกี่ยวข้องในข้อมูลชุดที่ 1 พบว่าสามารถแบ่งสาขาธนาคารออกเป็น 2 กลุ่มที่มีลักษณะเฉพาะแตกต่างกันอย่างชัดเจน ดังนี้

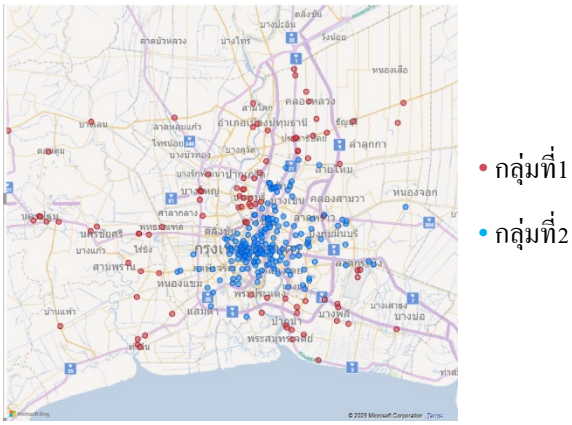

ภาพที่ 4: แผนที่แสดงตำแหน่งสาขาธนาคารทั้ง 2 กลุ่มของชุดข้อมูลที่ 1

กลุ่มที่ 1 ประกอบด้วย 93 สาขา จากภาพที่ 4 แสดงที่ตั้งสาขาซึ่งส่วนใหญ่กระจายอยู่ในปริมณฑล ส่วนใหญ่สาขาธนาคารตั้งอยู่นอกห้างคิดเป็นร้อยละ 65.59 และตั้งอยู่นอกเมืองคิดเป็นร้อยละ 61.29 โดยกลุ่มนี้มียอดขายบัตรเดบิตทั้งสามประเภทสูง โดยเฉพาะบัตรเดบิตประเภทที่ 1 มีค่าเฉลี่ยอยู่ที่ 501 ใบต่อสาขาธนาคาร มีอัตราการเติบโตของยอดขายคิดเป็นร้อย

ละ 32.70 กลุ่มนี้มีจำนวนพนักงานขายบัตรต่อสาขาเฉลี่ย 6.43 คน อยู่ในพื้นที่ที่มีความหนาแน่นของประชากรเฉลี่ย 1,964 คนต่อตารางกิโลเมตรซึ่งหนาแน่นค่อนข้างมาก มีรายได้เฉลี่ยต่อหัวต่อเดือนของประชากรในจังหวัดที่สาขาตั้งอยู่เฉลี่ยอยู่ 36,297 บาท และมีสถานพยาบาลที่อยู่ในเครือของบัตรประเภทที่ 1, 2 และ 3 เฉลี่ยต่อสาขาอยู่ที่ 11.6, 13.5, 14.0 ตามลำดับ

กลุ่มที่ 2 ประกอบด้วย 186 สาขา จากภาพที่ 4 แสดงที่ตั้งสาขาส่วนใหญ่กระจุกตัวอยู่โซนกรุงเทพ ซึ่งสาขาธนาคารส่วนใหญ่ตั้งอยู่นอกห้างคิดเป็นร้อยละ 75.81 และตั้งอยู่ในเมืองคิดเป็นร้อยละ 63.98 ซึ่งกลุ่มนี้เป็นกลุ่มที่มียอดขายบัตรเดบิตทั้งสามประเภทค่อนข้างต่ำ แต่กลับมีอัตราการเติบโตของยอดขายเฉลี่ยสูงที่สุดคิดเป็นร้อยละ 41.90 กลุ่มนี้มีจำนวนพนักงานขายบัตรต่อสาขาเฉลี่ย 5.04 คน ที่น่าสนใจคือ กลุ่มนี้ตั้งอยู่ในพื้นที่ที่มีรายได้เฉลี่ยต่อหัวต่อเดือนของประชากรสูงที่สุดคือ 40,051 บาท และความหนาแน่นเฉลี่ยของประชากรสูงที่สุดอยู่ที่ 6,643 คนต่อตารางกิโลเมตร และมีสถานพยาบาลที่อยู่ในเครือของบัตรทั้ง 3 ประเภทสูงที่สุดเฉลี่ยต่อสาขาอยู่ที่ 93, 112, 114 แห่งตามลำดับ

3.2.4 ผลการวิเคราะห์การจัดกลุ่มสาขาธนาคารสำหรับข้อมูลชุดที่ 2: สาขาธนาคารตั้งอยู่ต่างจังหวัด

ตารางที่ 6 แสดงจำนวนสมาชิก ค่าเฉลี่ยของตัวแปรเชิงปริมาณและความถี่ของตัวแปรเชิงคุณภาพ

Cluster	1	2	3
จำนวนยอดขายบัตรประเภทที่ 1	1,077	562	616
จำนวนยอดขายบัตรประเภทที่ 2	509	229	288
จำนวนยอดขายบัตรประเภทที่ 3	963	422	440
อัตราการเติบโตของยอดขายบัตร 3 ประเภท	0.46	0.29	0.20
จำนวนพนักงานขายต่อสาขา	8.33	5.99	5.19
รายได้เฉลี่ยต่อเดือนต่อหัวของประชากรรายจังหวัด	24,449	34,550	26,422
ความหนาแน่นของประชากรรายอำเภอ	321	915	197
สถานพยาบาลบัตรประเภทที่ 1	2.50	15.63	3.13
สถานพยาบาลบัตรประเภทที่ 2	2.76	24.87	3.49
สถานพยาบาลบัตรประเภทที่ 3	3.47	24.51	4.48
สาขาในห้าง/นอกห้าง			
ในห้าง	65	18	23
นอกห้าง	140	58	336
สาขาในเมือง/นอกเมือง			
ในเมือง	166	46	54
นอกเมือง	39	30	336
จำนวนสมาชิก	205	76	359

จากตารางที่ 6 จากผลการจัดกลุ่มด้วยปัจจัย 12 ปัจจัยที่เกี่ยวข้องในข้อมูลชุดที่ 2 พบว่าสามารถแบ่งสาขาธนาคารออกเป็น 3 กลุ่มที่มีลักษณะเฉพาะแตกต่างกันอย่างชัดเจนดังนี้

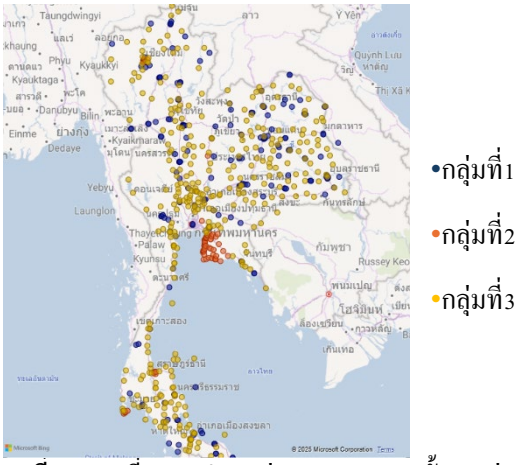

ภาพที่ 5: แผนที่แสดงตำแหน่งสาขาธนาคารทั้ง 3 กลุ่มของชุดข้อมูลที่ 2

จากภาพที่ 5 แสดงที่ตั้งสาขาของกลุ่มที่ 1,2 และ 3 โดย

กลุ่มที่ 1 ประกอบด้วย 205 สาขา ซึ่งสาขาส่วนใหญ่กระจายตัวทั่วประเทศ ส่วนใหญ่สาขาธนาคารตั้งอยู่นอกห้างคิดเป็นร้อยละ 68.29 และตั้งอยู่ในเมือง คิดเป็นร้อยละ 80.98 กลุ่มนี้มียอดขายบัตรเดบิตทั้ง 3 ประเภทสูงมากที่สุด โดยเฉพาะบัตรเดบิตประเภทที่ 1และ 3 มีอัตราการเติบโตของยอดขายสูงที่สุดคิดเป็นร้อยละ 46.00 มีจำนวนพนักงานขายบัตรต่อสาขาสูงที่สุดเฉลี่ย 8.33 คนต่อสาขา กลุ่มนี้ตั้งอยู่ในพื้นที่ที่มีความหนาแน่นของประชากรเฉลี่ย 321 คนต่อตารางกิโลเมตรและมีรายได้เฉลี่ยต่อหัวของประชากรในจังหวัดต่ำที่สุดเฉลี่ย 24,449 บาท และมีสถานพยาบาลที่อยู่ในเครือของบัตรทั้ง 3 ประเภทต่ำที่สุดเฉลี่ยต่อสาขา 2.50, 2.76, 3.47 แห่งตามลำดับ

กลุ่มที่ 2 ประกอบด้วย 76 สาขา ซึ่งตั้งอยู่ในโซนเมืองท่องเที่ยวและอุตสาหกรรม สาขาธนาคารส่วนใหญ่ตั้งอยู่นอกห้างคิดเป็นร้อยละ 76.32 และตั้งอยู่ในเมืองคิดเป็นร้อยละ 60.53 กลุ่มนี้มียอดขายบัตรเดบิตทั้ง 3 ประเภทสูงแต่ลูกค้านิยมใช้บัตรเดบิตประเภทที่ 1 และ3 มีอัตราการเติบโตของยอดขายคิดเป็นร้อยละ 29.00 กลุ่มนี้มีจำนวนพนักงานขายบัตรต่อสาขาเฉลี่ย 5.99 คนต่อสาขา อยู่ในพื้นที่ที่มีความหนาแน่นของประชากรสูงที่สุดเฉลี่ย 915 คนต่อตารางกิโลเมตรและที่น่าสนใจคือมีรายได้เฉลี่ยต่อหัวของประชากรในจังหวัดสูงที่สุดเฉลี่ย 34,550 บาท และมีสถานพยาบาลที่อยู่ในเครือของบัตรทั้ง 3 ประเภทสูงที่สุด

กลุ่มที่ 3 ประกอบด้วย 359 สาขา ที่ตั้งอยู่ทั่วประเทศแต่สาขาส่วนใหญ่ตั้งอยู่นอกห้างคิดเป็นร้อยละ 93.59 และตั้งอยู่นอกเมืองคิดเป็นร้อยละ 84.96 กลุ่มนี้มียอดขายบัตรเดบิตทั้ง 3 ประเภทสูงโดยเฉพาะบัตรเดบิตประเภทที่ 1 และ3 มีอัตราการเติบโตของยอดขายคิดเป็นร้อยละ 20.00 มีจำนวนพนักงานขายบัตรต่อสาขาเฉลี่ย 5.19 คนต่อสาขา และที่

น่าสนใจคือกลุ่มนี้อยู่ในพื้นที่ที่มีความหนาแน่นของประชากรเฉลี่ยเพียง 197 คนต่อตารางกิโลเมตรซึ่งมีความหนาแน่นของประชากรน้อยมาก มีรายได้เฉลี่ยต่อหัวของประชากรในจังหวัดเฉลี่ย 26,422 บาท และมีสถานพยาบาลที่อยู่ในเครือของบัตรทั้ง 3 ประเภทค่อนข้างต่ำ

3.3 ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตในแต่ละกลุ่ม

การวิเคราะห์ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตพ่วงประกันในแต่ละกลุ่ม คณะผู้วิจัยได้นำเทคนิคการวิเคราะห์ต้นไม้ตัดสินใจ(Decision Tree) เพื่อประเมินความสำคัญของตัวแปร (Feature Importance) ที่มีผลต่อยอดขายของบัตรเดบิตแต่ละประเภทในแต่ละกลุ่ม ดังตารางที่ 7

ตารางที่ 7 ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตในแต่ละกลุ่ม

	1: สาขาธนาคารตั้งอยู่ในกรุงเทพมหานครและปริมณฑล						2: สาขาธนาคารตั้งอยู่ในต่างจังหวัด								
	กลุ่มที่ 1			กลุ่มที่ 2			กลุ่มที่ 1			กลุ่มที่ 2			กลุ่มที่ 3		
ประเภทของบัตรเดบิต	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3
ยอดขายบัตรเดบิตเฉลี่ยต่อสาขา	501	346	326	213	135	143	1,077	509	963	562	229	422	616	288	440
ปัจจัยที่ส่งผลต่อยอดขายบัตร	%ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตพ่วงประกันเฉลี่ยต่อสาขาแต่ละประเภทในแต่ละกลุ่ม														
อัตราการเติบโตของยอดขายบัตรเดบิต 3 ประเภท	17.87%	15.14%	13.80%	6.78%	11.50%	11.50%	14.09%	**25.52%**	6.55%	19.65%	9.31%	7.60%	**23.15%**	15.29%	14.42%
จำนวนพนักงานขายบัตรเดบิตต่อสาขาธนาคาร	17.24%	8.55%	**33.13%**	**27.60%**	17.61%	22.48%	**22.49%**	5.37%	**25.89%**	22.54%	17.58%	15.01%	10.52%	15.98%	15.28%
รายได้เฉลี่ยต่อหัวของประชากรรายจังหวัด	5.72%	18.63%	12.94%	0.00%	0.00%	0.00%	16.77%	20.24%	21.22%	7.18%	21.44%	**30.22%**	20.06%	**35.75%**	22.28%
ความหนาแน่นของประชากรรายอำเภอ	**27.04%**	**21.08%**	15.70%	26.38%	**29.25%**	**29.32%**	19.16%	22.03%	24.81%	**27.33%**	**22.01%**	7.97%	22.02%	14.02%	**25.50%**
จำนวนสถานพยาบาลบัตรเดบิต	19.46%	18.06%	16.08%	0.00%	0.00%	0.00%	10.25%	13.85%	6.29%	5.69%	17.92%	22.33%	19.16%	17.47%	18.16%
สาขาในห้างหรือนอกห้าง	11.77%	13.79%	6.69%	18.06%	15.67%	24.36%	9.66%	0.00%	8.15%	12.64%	11.75%	16.88%	0.09%	0.00%	0.00%
สาขาในเมืองหรือนอกเมือง	0.91%	4.74%	1.65%	21.18%	25.97%	12.34%	7.58%	12.99%	7.10%	4.97%	0.00%	0.00%	4.99%	1.49%	4.36%
รวม	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

3.3.1 วิเคราะห์ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตในแต่ละกลุ่มสำหรับข้อมูลชุดที่ 1: สาขาธนาคารตั้งที่อยู่ในเขตกรุงเทพมหานครและปริมณฑล

กลุ่มที่ 1 โดยปัจจัยหลักที่ส่งผลมากที่สุดต่อยอดขายบัตรเดบิตประเภทที่ 1, 2 และ 3 คือ ความหนาแน่นของประชากรรายอำเภอ ความหนาแน่นของประชากรรายอำเภอ และจำนวนพนักงานขายต่อสาขา ตามลำดับ โดยส่งผลให้มียอดขายบัตรเดบิตประเภทที่ 1, 2 และ3 ที่ 27.04%, 21.08% และ 33.13% ตามลำดับ

กลุ่มที่ 2 ปัจจัยหลักที่ส่งผลมากที่สุดต่อยอดขายบัตรเดบิตประเภทที่ 1, 2 และ 3 คือ จำนวนพนักงานขายต่อสาขา ความหนาแน่นของประชากรรายอำเภอ และความหนาแน่นของประชากรรายอำเภอ ตามลำดับโดยส่งผลให้มียอดขายบัตรเดบิตประเภทที่ 1, 2 และ3 ที่ 27.60%, 29.25% และ 29.32% ตามลำดับ

3.3.2 วิเคราะห์ปัจจัยที่มีผลต่อยอดขายบัตรเดบิตในแต่ละกลุ่มสำหรับข้อมูลชุดที่ 2 สาขาธนาคารตั้งอยู่ต่างจังหวัด

กลุ่มที่ 1 ปัจจัยหลักที่ส่งผลมากที่สุดต่อยอดขายบัตรเดบิตประเภทที่ 1, 2 และ 3 คือ จำนวนพนักงานขายต่อสาขา อัตราการเติบโตของยอดขายบัตร 3 ประเภท และจำนวนพนักงานขายต่อสาขา ตามลำดับ โดยส่งผลให้มียอดขายบัตรเดบิตประเภทที่ 1, 2 และ3 ที่ 22.49%, 25.52% และ 25.89% ตามลำดับ

กลุ่มที่ 2 ปัจจัยหลักที่ส่งผลมากที่สุดต่อยอดขายบัตรเดบิตประเภทที่ 1, 2 และ 3 คือ ความหนาแน่นของประชากรรายอำเภอ ความหนาแน่นของประชากรรายอำเภอ และรายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด ตามลำดับ โดยส่งผลให้มียอดขายบัตรเดบิตประเภทที่ 1, 2 และ3 ที่ 27.33%, 22.01% และ 30.22% ตามลำดับ

กลุ่มที่ 3 ปัจจัยหลักที่ส่งผลมากที่สุดต่อยอดขายบัตรเดบิตประเภทที่ 1, 2 และ 3 คือ อัตราการเติบโตของยอดขายบัตร 3 ประเภท รายได้เฉลี่ยต่อหัวต่อเดือนของประชากรรายจังหวัด และความหนาแน่นของประชากรรายอำเภอ ตามลำดับ โดยส่งผลให้มียอดขายบัตรเดบิตประเภทที่ 1, 2 และ3 ที่ 23.15%, 35.75% และ 25.50% ตามลำดับ

4. สรุปผลและอภิปรายผล

งานวิจัยนี้ได้ทำการจัดกลุ่มสาขาธนาคารตามยอดขายบัตรเดบิตพ่วงประกันโดยใช้ข้อมูลในปี ค.ศ. 2022- 2023 ของธนาคารแห่งหนึ่งจำนวน 919 สาขา ข้อมูลที่ใช้ในการศึกษาประกอบด้วยยอดขายบัตรเดบิต สถานที่ตั้งสาขาธนาคาร และข้อมูลปัจจัยทางเศรษฐกิจและประชากรศาสตร์รวมทั้งหมด 12 ปัจจัย ผู้วิจัยแบ่งชุดข้อมูลตามพื้นที่เป็น 2 ชุดสำหรับจัดกลุ่ม ได้แก่ ชุดข้อมูลของสาขาธนาคารที่ตั้งอยู่ในกรุงเทพและปริมณฑล ชุดข้อมูลของสาขาธนาคารที่ตั้งอยู่ต่างจังหวัด และใช้วิธี K-prototypes ในการจัดกลุ่มสาขาธนาคารในแต่ละชุดข้อมูล หลังจากนั้นผู้วิจัยได้ศึกษาความสำคัญของปัจจัยที่

ส่งผลต่อยอดขายของบัตรแต่ละประเภทในแต่ละกลุ่มสาขาธนาคารที่ถูกจัดไว้ โดยพิจารณาจากค่า Feature Importance ในเทคนิคต้นไม้ตัดสินใจ ผลการวิจัยสามารถสรุปผลการจัดกลุ่มและวิเคราะห์ปัจจัยที่ส่งผลต่อยอดขายบัตรเดบิตได้ดังนี้

ชุดข้อมูลกลุ่มสาขาธนาคารที่ตั้งอยู่ในกรุงเทพมหานครและปริมณฑล สามารถจัดกลุ่มได้เป็น 2 กลุ่ม โดยกลุ่มที่ 1 เป็นกลุ่มสาขาปริมณฑลซึ่งมียอดขายบัตรเดบิตสูง ซึ่งจะนิยามกลุ่มนี้ว่า **"กลุ่มลูกค้าปริมณฑลกระเป๋าหนัก"** และกลุ่มที่ 2 เป็นกลุ่มสาขากรุงเทพซึ่งมียอดขายบัตรเดบิตต่ำ ซึ่งจะนิยามกลุ่มนี้ว่า **"กลุ่มลูกค้ากรุงเทพไม่นิยมบัตรเดบิต"** ปัจจัยหลักที่ส่งผลต่อยอดขายบัตรเดบิตใน 2 กลุ่มนี้คือ ความหนาแน่นประชากรรายอำเภอ และจำนวนพนักงานขายต่อสาขา

สำหรับชุดข้อมูลกลุ่มสาขาธนาคารที่ตั้งอยู่ต่างจังหวัด ต่างจังหวัด สามารถจัดกลุ่มได้เป็น 3 กลุ่ม ได้แก่ กลุ่มที่ 1 กลุ่มสาขาในเมืองต่างจังหวัดซึ่งยอดขายบัตรเดบิตสูงมาก ซึ่งจะนิยามกลุ่มนี้ว่า **"กลุ่มขายบัตรเดบิตสูงมากในเมืองต่างจังหวัด"** กลุ่มที่ 2 กลุ่มสาขาในพื้นที่ท่องเที่ยวและอุตสาหกรรมซึ่งมียอดขายบัตรเดบิตสูง ซึ่งจะนิยามกลุ่มนี้ว่า **"กลุ่มขายบัตรเดบิตสูงในพื้นที่ท่องเที่ยวและอุตสาหกรรม"** และกลุ่มที่ 3 กลุ่มสาขานอกเมืองต่างจังหวัดซึ่งมียอดขายบัตรเดบิตสูง ซึ่งจะนิยามกลุ่มนี้ว่า **"กลุ่มขายบัตรเดบิตสูงนอกเมืองต่างจังหวัด"** ซึ่งปัจจัยหลักที่ส่งผลต่อยอดขายบัตรเดบิตในกลุ่มนี้คือ รายได้เฉลี่ยต่อหัวของประชากรรายจังหวัดซึ่งเป็นปัจจัยเดียวกันกับผลการศึกษาการจัดกลุ่มของลูกค้าบัตรเครดิตในงานวิจัยของฐิติพร [6] ที่พบว่ารายได้เป็นปัจจัยที่ส่งผลต่อการทำนายการจัดกลุ่มลูกค้าบัตรเครดิต

สำหรับการนำผลการศึกษาไปเสนอแนวทางการกำหนดกลยุทธ์ที่เหมาะสมกับแต่ละกลุ่มนั้นมีข้อเสนอแนะดังนี้

ข้อมูลชุดที่ 1	แนวทางการกำหนดกลยุทธ์
กลุ่มที่ 1 "กลุ่มลูกค้าปริมณฑลกระเป๋าหนัก"	เสนอให้มีจัดอบรมพนักงานขายเพื่อเพิ่มทักษะในการปิดการขาย ตั้งเป้าหมายการขายรายเดือน และมีแรงจูงใจ เช่น ค่าคอมมิชชันหรือโบนัส จัดกิจกรรมตั้งบูธ ประชาสัมพันธ์ในแหล่งชุมชน เช่น ห้างสรรพสินค้า, ตลาดนัด มีโปรโมชันพิเศษสำหรับลูกค้ากลุ่มออฟฟิศและนักศึกษา และแนะนำบัตรประเภทที่ 1 และ3
กลุ่มที่ 2 "กลุ่มลูกค้ากรุงเทพไม่นิยมบัตรเดบิต"	เสนอให้มีเพิ่มการตลาดเชิงรุกในพื้นที่ที่มีประชากรหนาแน่น เช่น MRT/BTS หรือสถานที่ที่คนพลุกพล่าน ใช้อินฟลูเอนเซอร์รีวิวบัตรเดบิตและสิทธิประโยชน์

ข้อมูลชุดที่ 2	แนวทางการกำหนดกลยุทธ์
กลุ่มที่ 1 "กลุ่มขายบัตรเดบิตสูงมากในเมืองต่างจังหวัด"	เสนอให้มีจัดอบรมพนักงานขายเพื่อเพิ่มทักษะในการปิดการขาย ตั้งเป้าหมายการขายรายเดือน และมีแรงจูงใจ เช่น ค่าคอมมิชชันหรือโบนัส จัดกิจกรรมตั้งบูธ ประชาสัมพันธ์ในแหล่งชุมชน เช่น ห้างสรรพสินค้า, ตลาดนัด มีโปรโมชันพิเศษสำหรับลูกค้ากลุ่มออฟฟิศและนักศึกษา และแนะนำบัตรประเภทที่ 1 และ3
กลุ่มที่ 2 "กลุ่มขายบัตรเดบิตสูงในพื้นที่ท่องเที่ยวและอุตสาหกรรม"	เสนอให้มีการเพิ่มการตลาดเชิงรุกโดยเข้าถึงพนักงานในโรงงานและโรงแรมมากขึ้น ผ่านการนำเสนอผลิตภัณฑ์ในรูปแบบสวัสดิการพนักงานเพิ่มเติม นอกเหนือจากการขายให้กับลูกค้าทั่วไป
กลุ่มที่ 3 "กลุ่มขายบัตรเดบิตสูงนอกเมืองต่างจังหวัด"	เสนอแนะให้ตั้งบูธขายในงานเทศกาลประจำจังหวัด เช่น งานวัด, ตลาดนัด ลงพื้นที่เข้าชุมชน แนะนำบัตรเดบิตและสิทธิประโยชน์ แนะนำบัตรประเภทที่ 1 และ 3 จัดอบรมพนักงานขายเพื่อเพิ่มทักษะในการปิดการขายเนื่องจากมีแนวโน้มการเติบโตของยอดขายที่ดีในอนาคต

จากแนวทางการกำหนดกลยุทธ์นี้คาดว่า ผู้ใช้งานจะสามารถนำเสนอบัตรเดบิตพ่วงประกันภัยได้ตรงตามความต้องการของลูกค้าในแต่ละกลุ่มมากขึ้นซึ่งจะส่งผลต่อการเพิ่มยอดขายบัตรเดบิดพ่วงประกันภัยดังกล่าว

5. เอกสารอ้างอิง

[1] Huang Z. Extensions to the k-means algorithm for clustering large data sets with categorical variables. Data Min Knowl Discov. 1998;2:283-304.

[2] Sharan S, Mohana Mahendira TP. E-commerce user segmentation. BTech [project report]. Chennai (IN): Hindustan Institute of Technology and Science; 2022.

[3] Ranti KS, Salim K, Yuliono AD, Girsang G. Clustering behavioral data for advertising purposes using K-Prototypes algorithm. International Journal of Innovative Technology and Exploring Engineering. 2019 Nov;9(1):2329-34. doi:10.35940/ijitee.A5229.119119.

[4] Sroka Ł. The use of the k-prototypes method in the segmentation of customers of a company in the multi-level marketing. Wiad Stat The Polish Statistician. 2021 Jul;66(7):44-56. doi:10.5604/01.3001.0015.0482.

[5] Kazemitabar SJ, Bloniarz A, Amini AA, Talwalkar A. Variable importance using decision trees. Proceedings of the 31st Conference on Neural Information Processing

Systems (NIPS 2017); 2017 Dec 4-9; Long Beach, CA, USA.

[6] ฐิติพร ฐิติพรธรรม. การจัดกลุ่มลูกค้าบัตรเครดิตด้วยเทคนิคเค-มีนส์และต้นไม้ตัดสินใจเพื่อแนะนำแผนการตลาดเฉพาะกลุ่ม. สารนิพนธ์. บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ; 2023. Available from: http://ir-ithesis.swu.ac.th/dspace/handle/123456789/2758

[7] Lamsam A, Chantarat S, Rittinon C. บริการทางการเงินของประเทศไทย: มุมมองเชิงพื้นที่จากข้อมูลจุดพิกัดกว่า 300,000 จุดทั่วประเทศ [Internet]. Bangkok: Puey Ungphakorn Institute for Economic Research; 2018 [cited 2025 Jan 25]. Available from: https://www.pier.or.th/abridged/2018/03/.

[8] Tosborvorn T, Treeratpituk P, Wasi N, Laimek R. เจาะลึกพฤติกรรมการใช้ e-Payment ของคนไทย [Internet]. Bangkok: Puey Ungphakorn Institute for Economic Research; 2023 [cited 2025 Jan 25]. Available from: https://www.pier.or.th/abridged/2023/05/.

[9] Chinnasri W. นโยบายการพัฒนาประเทศที่ส่งผลต่อช่องว่างระหว่างเมืองกับชนบทและการอพยพย้ายถิ่น. วารสารครุศาสตร์ปริทรรศน์ คณะครุศาสตร์ มหาวิทยาลัยมหาจุฬาลงกรณราชวิทยาลัย. 2022;9(2):451-464.

[10] สำนักงานสถิติแห่งชาติ. รายได้เฉลี่ยต่อเดือนของครัวเรือน ค.ศ. 2004 - 2023 [Internet]. กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม; 2024 [cited 2024 Jul 24]. Available from: https://www.nso.go.th/

[11] นันทนัจซ์ ลิ้มกมลทิพย์. สถิติข้อมูลประชากร: ความหนาแน่นประชากรระดับจังหวัด จำแนกรายอำเภอ ตั้งแต่ ค.ศ. 1997 - ค.ศ. 2024 [Interne]. กรุงเทพฯ: สำนักวิเคราะห์และประเมินผล, กรมโยธาธิการและผังเมือง, กระทรวงมหาดไทย; 2024 [cited 2024 Jul 24]. Available from: https://app.powerbi.com/view?r=eyJrIjoiNmQwZDQyMjgtY2U3NS00ZTlkLWJlMWUtZDkzZGQ5ZDQxYWNkIiwidCI6IjRiNTY3YTJlLTg0MmUtNDZjNy1hNzgwLWUxZTA1ZjFmODRhYyIsImMiOjEwfQ.

[12]Aschenbruck RD. Expanding the scope of the k-prototypes algorithm: addressing issues in cluster analysis of mixed-type data arising from real-world applications. PhD thesis. Bremen: Constructor University; 2024.

การเปรียบเทียบวิธีการปรับค่าพารามิเตอร์การลงโทษแบบเรียลไทม์ในข้อมูลสตรีมมิงที่ไม่คงที่

Comparison of Real-time Penalization Methods in Non-Stationary Streaming Data

กัญญาวีร์ ชมมิ่ง* วิฐรา พึ่งพาพงศ์

ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

(*yawee3.7@gmail.com)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของ Real-time Adaptive Penalization (RAP) สำหรับแบบจำลอง การถดถอยแลสโซ (Lasso Regression), การถดถอยริดจ์ (Ridge Regression) และ การถดถอยอิลาสติกเน็ต (Elastic Net Regression) ในบริบทของ ข้อมูลสตรีมมิงที่ไม่คงที่ (Non-Stationary Streaming Data) ซึ่งมีการเปลี่ยนแปลงของค่าเฉลี่ย, ความแปรปรวน และโครงสร้างของข้อมูล การศึกษานี้ใช้ ข้อมูลจำลอง ที่ออกแบบให้มีการเปลี่ยนแปลงในสองลักษณะ คือ Low-Frequency Shift และ High-Frequency Shift พร้อมใช้กระบวนการ AR(1) ในค่าความคลาดเคลื่อนงานวิจัยนี้พัฒนาแนวทางใหม่สำหรับ RAP-Ridge และ RAP-Elastic Net เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ข้อมูลที่เปลี่ยนแปลง RAP ช่วยให้โมเดลสามารถปรับค่าพารามิเตอร์การลงโทษ (λ) แบบไดนามิก ส่งผลให้สามารถควบคุมขนาดของค่าสัมประสิทธิ์และปรับตัวต่อข้อมูลที่เปลี่ยนแปลงได้อย่างแม่นยำ ประสิทธิภาพของแต่ละอัลกอริธึมถูกประเมินผ่าน ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE), ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE), ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) และ ค่าความคลาดเคลื่อนสัมบูรณ์เชิงเปอร์เซ็นต์ (MAPE) ผลลัพธ์แสดงว่า RAP-Lasso มีความแม่นยำสูงสุด ขณะที่ RAP-Ridge มีประสิทธิภาพด้านเวลาในการคำนวณดีกว่าทางเลือกอื่น การศึกษานี้นำเสนอแนวทางที่ช่วยให้แบบจำลองสามารถรับมือกับข้อมูลที่เปลี่ยนแปลงอย่างต่อเนื่อง ซึ่งเป็นประโยชน์ต่อการพยากรณ์ในสภาพแวดล้อมที่ไม่แน่นอน

คำสำคัญ: การปรับพารามิเตอร์การลงโทษแบบเรียลไทม์, ข้อมูลสตรีมมิงที่ไม่คงที่, กระบวนการ AR(1), การถดถอยแลสโซ (Lasso Regression), การถดถอยริดจ์ (Ridge Regression), การถดถอยอิลาสติกเน็ต (Elastic Net Regression)

Abstract

This study aims to compare the performance of Real-time Adaptive Penalization (RAP) for Lasso Regression, Ridge Regression, and Elastic Net Regression in the context of Non-Stationary Streaming Data, where the mean, variance, and data structure continuously change over time. The study employs simulated data designed to exhibit two types of shifts: Low-Frequency Shift and High-Frequency Shift, with the addition of an AR(1) process to introduce uncertainty in the error terms.This research proposes a novel adaptation of RAP-Ridge and RAP-Elastic Net to enhance predictive performance in non-stationary data environments. RAP dynamically adjusts the penalization parameter λ, enabling the model to control the magnitude of regression coefficients and adapt effectively to evolving data patterns. The performance of each algorithm is evaluated using key error metrics: Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE).The results indicate that RAP-Lasso achieves the highest predictive accuracy, while RAP-Ridge demonstrates superior computational efficiency. This study provides a framework for improving model adaptability in dynamic data environments, which is particularly beneficial for real-time forecasting in uncertain conditions.

Keywords: Real-time adaptive penalization, non-stationary streaming data, AR(1) process, Lasso regression, Ridge regression, Elastic Net regression.

1. บทนำ

ในปัจจุบัน การคาดการณ์ข้อมูลสตรีมมิงที่ไม่คงที่ เป็นความท้าทายสำคัญในหลายสาขา เช่น การเงิน การตลาด และวิทยาศาสตร์ข้อมูล ข้อมูลประเภทนี้มีลักษณะเป็น ข้อมูลสตรีมมิง (Streaming Data) ซึ่งหมายถึงข้อมูลที่ไหลเข้ามาอย่างต่อเนื่องในลำดับเวลา โดยแตกต่างจาก ข้อมูลทั่วไป (Batch Data) ซึ่งเป็นข้อมูลที่ถูกเก็บรวบรวมเป็นชุดและนำมาวิเคราะห์ภายหลัง นอกจากนี้ ข้อมูลสตรีมมิงที่ไม่คงที่ (Nonstationary Streaming Data) ยังมีคุณสมบัติที่แตกต่างจาก ข้อมูลสตรีมมิงที่คงที่ (Stationary Streaming Data) โดยข้อมูลที่คงที่มีการกระจายความน่าจะเป็นที่ไม่เปลี่ยนแปลงตามเวลา ขณะที่ข้อมูลที่ไม่คงที่อาจมีการเปลี่ยนแปลงของค่าเฉลี่ย ความแปรปรวน หรือโครงสร้างของข้อมูล ทำให้แบบจำลองพยากรณ์ทั่วไปที่ใช้ค่าปรับคงที่ (Fixed Regularization Parameter) ไม่สามารถรักษาประสิทธิภาพในการพยากรณ์ได้อย่างต่อเนื่อง วิธีการลงโทษ เช่น การถดถอยแลสโซ, การถดถอยริดจ์ และการถดถอยอิลาสติกเน็ต เป็นเทคนิคที่นิยมใช้ในการคัดเลือกตัวแปรและป้องกันปัญหาการเกิดพารามิเตอร์ที่มีค่ามากเกินไป (Overfitting) อย่างไรก็ตาม การใช้ค่าปรับที่คงที่ทำให้แบบจำลองขาดความยืดหยุ่นและไม่สามารถปรับตัวต่อข้อมูลที่เปลี่ยนแปลงได้อย่างมีประสิทธิภาพ

อย่างไรก็ตาม งานวิจัยที่ผ่านมามีการพัฒนา Real-time Adaptive Penalization (RAP) สำหรับ Lasso Regression ซึ่งเป็นแนวทางที่ช่วยให้ค่าปรับสามารถเปลี่ยนแปลงได้ตามข้อมูลที่เข้ามาแบบเรียลไทม์ อย่างไรก็ตาม ยังไม่มีการศึกษาการนำแนวทางดังกล่าวมาใช้กับ Ridge และ Elastic Net ซึ่งอาจเป็นทางเลือกที่มีประสิทธิภาพในการจัดการข้อมูลที่เปลี่ยนแปลง งานวิจัยนี้จึงมุ่งเน้น การพัฒนา Real-time Adaptive Penalization สำหรับ Ridge และ Elastic Net และเปรียบเทียบประสิทธิภาพของทั้งสามแนวทาง ได้แก่ RAP-Lasso, RAP-Ridge และ RAP-Elastic Net ในการคาดการณ์ข้อมูลที่ไม่คงที่ โดยพิจารณาจากตัวชี้วัด ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE), ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE), ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) และค่าความคลาดเคลื่อนสัมบูรณ์เชิงเปอร์เซ็นต์ (MAPE) ผลลัพธ์จากงานวิจัยนี้จะช่วยให้เกิดแนวทางใหม่ในการเลือกใช้โมเดลที่เหมาะสมสำหรับข้อมูลที่มีการเปลี่ยนแปลงอย่าง และพัฒนาวิธีการเรียนรู้ของเครื่องให้สามารถปรับตัวเข้ากับข้อมูลที่เปลี่ยนแปลงได้อย่างมีประสิทธิภาพ

2. ทฤษฎีที่เกี่ยวข้อง

2.1 การถดถอยแบบมีการควบคุมพารามิเตอร์

การถดถอยแบบมีการควบคุมพารามิเตอร์ (Regularized Regression) เป็นแนวทางที่ได้รับการพัฒนาเพื่อแก้ปัญหาความซับซ้อนของแบบจำลองและปัญหา Overfitting ซึ่งเกิดขึ้นเมื่อตัวแปรพยากรณ์มีความสัมพันธ์กันสูงหรือมีจำนวนตัวแปรมากเกินไป เทคนิคการลงโทษที่ได้รับความนิยม ได้แก่ Lasso Regression, Ridge Regression และ Elastic Net Regression

2.1.1 Lasso Regression (L1 Regularization)

ใช้ฟังก์ชันการลงโทษแบบ L1-norm เพื่อควบคุมค่าสัมประสิทธิ์ของตัวแปรพยากรณ์ ส่งผลให้ค่าสัมประสิทธิ์บางค่าถูกบังคับให้เป็นศูนย์ ทำให้สามารถเลือกตัวแปรที่มีความสำคัญต่อแบบจำลองได้โดยอัตโนมัติ

2.1.2 Ridge Regression (L2 Regularization)

ใช้ฟังก์ชันการลงโทษแบบ L2-norm ซึ่งช่วยลดขนาดของค่าสัมประสิทธิ์โดยไม่บังคับให้เป็นศูนย์ การลงโทษลักษณะนี้เหมาะสำหรับข้อมูลที่ตัวแปรอิสระมีความสัมพันธ์กันสูง

2.1.3 Elastic Net Regression

เป็นการผสมผสานระหว่าง L1 และ L2 Regularization โดยใช้ฟังก์ชันการลงโทษร่วมกัน ทำให้สามารถเลือกตัวแปรสำคัญได้เหมือน Lasso และลดขนาดสัมประสิทธิ์เพื่อป้องกันปัญหาความสัมพันธ์ระหว่างตัวแปรอิสระเหมือน Ridge

2.2 การลงโทษแบบเรียลไทม์ (Real-time Adaptive Penalization: RAP)

Ryu & Yin (2017) นำเสนอ Real-time Adaptive Penalization (RAP) เป็นเทคนิคที่ได้รับการพัฒนาเพื่อลดข้อจำกัดของการลงโทษแบบดั้งเดิม ซึ่งใช้ค่าปรับคงที่ ทำให้ไม่สามารถตอบสนองต่อข้อมูลที่เปลี่ยนแปลงตามกาลเวลาได้อย่างมีประสิทธิภาพ RAP ช่วยให้โมเดลสามารถปรับค่าพารามิเตอร์การลงโทษ (λ) แบบไดนามิกโดยอิงจากข้อมูลที่เข้ามาใหม่ในแต่ละรอบของการอัปเดต

2.2.1 การทำงานของ RAP

แนวคิดหลักของ RAP คือการปรับค่าพารามิเตอร์การลงโทษ (λ) ตามลักษณะของข้อมูลที่เปลี่ยนแปลงไป เพื่อให้โมเดลสามารถปรับตัวเข้ากับข้อมูลแบบ Nonstationary ได้อย่างมีประสิทธิภาพ หลักการสำคัญของ RAP คือการใช้ค่าความคลาดเคลื่อน (Residual) เป็นตัวกำหนดการเปลี่ยนแปลงของค่าปรับ โดยหากข้อมูลใหม่มีความคลาดเคลื่อนสูง โมเดลจะปรับค่า λ เพิ่มขึ้นเพื่อลดความซับซ้อนของแบบจำลองและป้องกันปัญหา Overfitting ในทางกลับกัน หากข้อมูลใหม่มีค่าความคลาดเคลื่อนต่ำ ค่า λ จะถูกปรับลดลงเพื่อเพิ่มความยืดหยุ่นของโมเดลทำให้สามารถเรียนรู้จากข้อมูลที่เปลี่ยนแปลงไปได้อย่างต่อเนื่อง ค่าปรับ λ ใน RAP ถูกอัปเดตโดยใช้แนวคิด Residual-based Adaptive Regularization ซึ่งเป็นกระบวนการที่ใช้ค่าความคลาดเคลื่อนของแบบจำลองเป็นตัวกำหนดขนาดของค่าปรับ การอัปเดตพารามิเตอร์นี้ช่วยให้แบบจำลองสามารถรักษาสมดุลระหว่างความซับซ้อนของแบบจำลองและความสามารถในการพยากรณ์ได้อย่างมีประสิทธิภาพในสภาพแวดล้อมที่มีข้อมูลเปลี่ยนแปลงอยู่ตลอดเวลา

2.2.2 การใช้ RAP ในโมเดลการถดถอย

2.2.2.1 Real-time Adaptive Penalization Lasso (RAP-Lasso)

Monti, Anagnostopoulos & Montana (2018) ได้นำเสนอ RAP-Lasso เป็นการผสมผสานระหว่างแนวคิด Lasso Regression (L1 Regularization) และการปรับพารามิเตอร์ลงโทษแบบเรียลไทม์ โดย Lasso ใช้ L1-norm penalty ซึ่งช่วยลดขนาดของค่าสัมประสิทธิ์และทำให้บางตัวแปรถูกกำหนดค่าเป็นศูนย์โดยอัตโนมัติ ส่งผลให้แบบจำลองสามารถเลือกตัวแปรที่มีความสำคัญต่อการพยากรณ์ได้ ฟังก์ชันต้นทุนของ RAP-Lasso ถูกกำหนดดังสมการที่ (1)

$$\min_{\beta} \sum_{i=1}^{t+1}\left(y_{t+1,i} - \sum_{j=1}^{p} X_{t+1,i,j}\beta_j\right)^2 + \lambda_{t+1}\sum_{j=1}^{p}|\beta_j| \quad (1)$$

เมื่อ $y_{t+1,i}$ แทน ค่าผลลัพธ์ที่แท้จริงของตัวอย่างที่ i ในรอบที่เวลา $t+1$

$X_{t+1,i,j}$ คือ ค่าของตัวแปรอิสระตัวที่ j ในตัวอย่างที่ i ที่ได้รับเข้ามาในรอบที่ $t+1$

β_j คือ ค่าสัมประสิทธิ์ของตัวแปรอิสระที่ต้องประมาณค่าซึ่งแสดงถึงอิทธิพลของตัวแปรอิสระ X_j ต่อค่าผลลัพธ์ y

λ_{t+1} แทน พารามิเตอร์ลงโทษที่อัปเดตตามข้อมูลที่เปลี่ยนแปลงในรอบเวลา $t+1$

2.2.2.2 Real-time Adaptive Penalization Ridge (RAP-Ridge)

RAP-Ridge ใช้ L2-norm penalty เพื่อควบคุมขนาดของค่าสัมประสิทธิ์โดยไม่บังคับให้เป็นศูนย์ ซึ่งช่วยลดปัญหา Multicollinearity ที่เกิดจากตัวแปรพยากรณ์ที่มีความสัมพันธ์กันสูง ฟังก์ชันต้นทุนของ RAP-Ridge ถูกกำหนดดังสมการที่ (2)

$$\min_{\beta} \sum_{i=1}^{t+1}\left(y_{t+1,i} - \sum_{j=1}^{p} X_{t+1,i,j}\beta_j\right)^2 + \lambda\sum_{j=1}^{p}\beta_j^2 \quad (2)$$

2.2.2.3 Real-time Adaptive Penalization Elastic Net (RAP-Elastic Net)

RAP-Elastic Net ผสมผสานคุณสมบัติของ Lasso และ Ridge โดยมีการลงโทษทั้งแบบ L1 และ L2 Regularization ทำให้สามารถเลือกตัวแปรที่สำคัญได้เหมือน Lasso และลดปัญหาความสัมพันธ์ระหว่างตัวแปรเหมือน Ridge ฟังก์ชันต้นทุนของ RAP-Elastic Net ถูกกำหนดดังสมการที่ (3)

$$\min_{\beta} \sum_{i=1}^{t+1}\left(y_{t+1,i} - \sum_{j=1}^{p} X_{t+1,i,j}\beta_j\right)^2 + \lambda_1\sum_{j=1}^{p}|\beta_j| + \lambda_2\sum_{j=1}^{p}\beta_j^2 \quad (3)$$

เมื่อ $\lambda_{1,t+1}$ แทน พารามิเตอร์ลงโทษที่อัปเดตตามข้อมูลที่เปลี่ยนแปลง ควบคุมการเลือกตัวแปรผ่าน L1 Regularization

$\lambda_{2,t+1}$ แทน พารามิเตอร์ลงโทษที่อัปเดตตามข้อมูลที่เปลี่ยนแปลง ควบคุมขนาดของสัมประสิทธิ์ผ่าน L2 Regularization

2.3 การอัปเดตค่าพารามิเตอร์การลงโทษ

พารามิเตอร์การลงโทษ λ เป็นองค์ประกอบสำคัญใน Regularized Regression โดยมีบทบาทในการควบคุมขนาดของค่าสัมประสิทธิ์ λ ช่วยป้องกันปัญหาการปรับตัวมากเกินไปกับข้อมูลฝึก (overfitting) หรือการเรียนรู้ที่ไม่เพียงพอ (underfitting) วิธีการดั้งเดิม เช่น Lasso, Ridge และ Elastic Net มักใช้ค่า พารามิเตอร์การลงโทษคงที่ ซึ่งอาจไม่สามารถปรับตัวได้อย่างมีประสิทธิภาพเมื่อข้อมูลมีการเปลี่ยนแปลงแบบไม่คงที่

Real-time Adaptive Penalization (RAP) ได้รับการพัฒนาเพื่อแก้ไขข้อจำกัดดังกล่าว โดยอัปเดตพารามิเตอร์การลงโทษแบบเรียลไทม์ให้สอดคล้องกับความเปลี่ยนแปลงของข้อมูลผ่านแนวคิด Residual-based Adaptive Regularization ซึ่งพิจารณาค่าความคลาดเคลื่อนของแบบจำลอง (Residual Error) เป็นปัจจัยหลักในการกำหนดค่า λ โดยมีหลักการสำคัญดังนี้ เมื่อค่าความคลาดเคลื่อนของแบบจำลองสูง λ จะถูกปรับเพิ่มขึ้น เพื่อลดขนาดของค่าสัมประสิทธิ์ และลดความซับซ้อนของแบบจำลอง เมื่อค่าความคลาดเคลื่อนของแบบจำลองต่ำ λ จะถูกปรับลดลง เพื่อให้โมเดลสามารถเรียนรู้จากข้อมูลใหม่ได้อย่างยืดหยุ่น สมการที่ใช้ในการอัปเดต λ ดังสมการที่ (4)

$$\lambda_{t+1} = (1-\epsilon)\lambda_t + \epsilon|r_t| \quad (4)$$

เมื่อ λ_{t+1} แทน ค่าพารามิเตอร์การลงโทษที่อัปเดต ในรอบเวลา $t+1$

λ_t แทน ค่าพารามิเตอร์การลงโทษจากรอบเวลาก่อนหน้าในรอบเวลา t

ϵ แทน ค่าคงที่อัตราการเรียนรู้

r_t แทน ค่าความคลาดเคลื่อนของแบบจำลอง (Residual Error) ซึ่งสะท้อนถึงความแตกต่างระหว่างค่าจริงและค่าพยากรณ์ของโมเดล คำนวณจากสมการที่ (5)

$$r_t = y_t - X_t\beta_t \quad (5)$$

เมื่อ y_t แทน ค่าผลลัพธ์จริงของตัวแปรตาม ในรอบเวลา t

X_t แทน เมทริกซ์ของตัวแปรอิสระที่ใช้ในการพยากรณ์ในรอบเวลา t

β_t แทน เวกเตอร์ของค่าสัมประสิทธิ์ที่ได้รับการประมาณค่าจากแบบจำลอง ในรอบเวลา t

2.4 การอัปเดตค่าสัมประสิทธิ์ใช้แนวทาง Gradient Descent และ Momentum

2.4.1 Gradient Descent

เป็นเทคนิคมาตรฐานที่ใช้สำหรับการปรับค่าพารามิเตอร์ของแบบจำลองโดยลดค่าฟังก์ชันต้นทุนในแต่ละรอบการเรียนรู้ กระบวนการนี้ดำเนินการโดยการคำนวณอนุพันธ์ของฟังก์ชันต้นทุน เพื่อกำหนดทิศทางที่เหมาะสมสำหรับการอัปเดตค่าสัมประสิทธิ์ β โดยมีดังสมการ (6)

$$\beta_{t+1} = \beta_t - \eta\nabla J(\beta) \quad (6)$$

เมื่อ η แทน อัตราการเรียนรู้ (Learning Rate) ซึ่งควบคุมขนาดของการเปลี่ยนแปลงค่าพารามิเตอร์ในแต่ละรอบการเรียนรู้

$\nabla J(\beta)$ แทน เป็นอนุพันธ์ของฟังก์ชันต้นทุนใช้ในการคำนวณทิศทางการเปลี่ยนแปลงของค่าพารามิเตอร์

อย่างไรก็ตาม Gradient Descent แบบดั้งเดิมอาจเผชิญปัญหาการสั่นของค่าพารามิเตอร์ค่าสัมประสิทธิ์ และอาจติดอยู่ในค่าต่ำสุดเฉพาะที่ ได้ ซึ่งทำให้การเรียนรู้ไม่ราบรื่นและมีประสิทธิภาพลดลง ดังนั้น จึงมีการนำแนวคิด Momentum มาใช้เพื่อปรับปรุงเสถียรภาพของกระบวนการอัปเดตพารามิเตอร์ค่าสัมประสิทธิ์

2.4.2 Momentum

เป็นเทคนิคที่ช่วยให้การอัปเดตค่าพารามิเตอร์เป็นไปอย่างราบรื่นและลดการเปลี่ยนแปลงแบบฉับพลันของค่าพารามิเตอร์ โดยใช้ค่าความเร็ว (Velocity) ที่สะสมข้อมูลจากรอบการเรียนรู้ก่อนหน้าเพื่อช่วยกำหนดทิศทางของการอัปเดตพารามิเตอร์ในรอบถัดไป สมการที่ใช้สำหรับ Momentum มีดังสมการที่ (7) และ (8)

$$v_{t+1} = \gamma v_t + \eta \nabla J(\beta) \quad (7)$$

$$\beta_{t+1} = \beta_t + v_{t+1} \quad (8)$$

เมื่อ v_t แทน ค่าความเร็วของการอัปเดตพารามิเตอร์ ซึ่งเป็นค่าที่สะสมมาจากรอบเวลาก่อนหน้า

γ แทน ค่าคงที่ Momentum Coefficient ที่กำหนดอิทธิพลของ Gradient ก่อนหน้า

η แทน อัตราการเรียนรู้ (Learning Rate)

$\nabla J(\beta)$ แทน เป็นอนุพันธ์ของฟังก์ชันต้นทุน

การใช้ Momentum ในกระบวนการอัปเดตค่าพารามิเตอร์ช่วยให้แบบจำลองสามารถลดปัญหาการสั่นของค่าพารามิเตอร์ และเพิ่มความสามารถในการหาค่าต่ำสุดของฟังก์ชันต้นทุนได้อย่างมีประสิทธิภาพ โดยเฉพาะในกรณีที่ข้อมูลมีความผันผวนสูง

2.5 กระบวนการ Autoregressive Order 1 (AR(1))

เป็นแบบจำลองอนุกรมเวลาที่ใช้กันอย่างแพร่หลายในการวิเคราะห์ข้อมูลที่มีความสัมพันธ์เชิงเวลาระหว่างค่าปัจจุบันและค่าที่ผ่านมา แบบจำลองนี้มีโครงสร้างพื้นฐานที่กำหนดให้ค่าของตัวแปรในช่วงเวลาปัจจุบันขึ้นอยู่กับค่าของตัวแปรในช่วงเวลาก่อนหน้า พร้อมด้วยส่วนของค่าความคลาดเคลื่อน ดังสมการที่ (9)

$$y_t = \phi y_{t-1} + \epsilon_t \quad (9)$$

เมื่อ y_t แทน ค่าของตัวแปรในช่วงเวลาปัจจุบัน

ϕ แทน สัมประสิทธิ์ของการพึ่งพาตัวแปรในช่วงเวลาก่อนหน้า

y_{t-1} แทน ค่าของตัวแปรในช่วงเวลาก่อนหน้า

ϵ_t แทน ค่าความคลาดเคลื่อนที่มีการแจกแจงแบบปกติและไม่มีความสัมพันธ์กันในแต่ละช่วงเวลา

2.6 เกณฑ์ที่ใช้ในการพิจารณาประสิทธิภาพ

ในการประเมินประสิทธิภาพของ Real-time Adaptive Penalization (RAP) สำหรับโมเดล Lasso, Ridge และ Elastic Net จำเป็นต้องใช้เกณฑ์ที่สามารถสะท้อนความสามารถของแบบจำลองในการคาดการณ์ข้อมูลที่เปลี่ยนแปลงอย่างต่อเนื่องได้อย่างแม่นยำ ในงานวิจัยนี้ ใช้เกณฑ์ที่เป็นมาตรฐานสำหรับการวัดความคลาดเคลื่อนของแบบจำลอง ได้แก่ ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE), ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE), ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) และ ค่าความคลาดเคลื่อนสัมบูรณ์เชิงเปอร์เซ็นต์ (MAPE) โดยแต่ละตัวชี้วัดมีรายละเอียดดังนี้

2.6.1 Mean Squared Error (MSE)

เป็นตัวชี้วัดที่ใช้วัดค่าเฉลี่ยของความคลาดเคลื่อนที่ยกกำลังสองระหว่างค่าจริง $y_{t+1,i}$ และค่าพยากรณ์ $\hat{y}_{t+1,i}$ ดังสมการที่ (10)

$$MSE = \frac{1}{t}\sum_{i=1}^{t}\left(y_{t+1,i} - \hat{y}_{t+1,i}\right)^2 \quad (10)$$

MSE มีความไวต่อค่าความคลาดเคลื่อนที่สูง เนื่องจากค่าคลาดเคลื่อนถูกยกกำลังสอง ทำให้ข้อผิดพลาดที่มีค่าสูงถูกให้น้ำหนักมากขึ้น ดังนั้น หาก MSE มีค่าต่ำ แสดงว่าแบบจำลองสามารถคาดการณ์ได้แม่นยำ

2.6.2 Root Mean Squared Error (RMSE)

เป็นค่ารากที่สองของ MSE ซึ่งแสดงค่าความคลาดเคลื่อนในหน่วยเดียวกับข้อมูลจริง ทำให้สามารถตีความค่าได้ง่ายขึ้น ดังสมการที่ (11)

$$RMSE = \sqrt{\frac{1}{t}\sum_{i=1}^{t}\left(y_{t+1,i} - \hat{y}_{t+1,i}\right)^2} \quad (11)$$

RMSE ใช้ในการเปรียบเทียบแบบจำลองที่ต้องการวัดว่าค่าพยากรณ์ที่ได้มีความแตกต่างจากค่าจริงมากเพียงใด โดยแบบจำลองที่มีค่า RMSE ที่ต่ำกว่าหมายถึงแบบจำลองที่มีความแม่นยำสูงกว่า

2.6.3 Mean Absolute Error (MAE)

เป็นตัวชี้วัดที่คำนวณค่าเฉลี่ยของค่าคลาดเคลื่อนในรูปแบบสัมบูรณ์ โดยไม่ยกกำลังสองเหมือน MSE ดังสมการที่ (12)

$$MAE = \frac{1}{t}\sum_{i=1}^{t}\left|y_{t+1,i} - \hat{y}_{t+1,i}\right| \quad (12)$$

MAE มีความไวต่อค่าความคลาดเคลื่อนที่รุนแรงน้อยกว่า MSE เนื่องจากไม่ได้ให้ค่าผิดพลาดที่สูงมีอิทธิพลมากเกินไป ดังนั้น MAE เป็นตัวชี้วัดที่ดีในกรณีที่ต้องการพิจารณาความคลาดเคลื่อนเฉลี่ยในลักษณะที่ไม่ถูกครอบงำโดยค่าผิดพลาดที่รุนแรง

2.6.4 Mean Absolute Percentage Error (MAPE)

เป็นตัวชี้วัดที่แสดงค่าคลาดเคลื่อนในรูปแบบเปอร์เซ็นต์ของค่าจริง ดังสมการที่ (13)

$$MAPE = \frac{1}{t}\sum_{i=1}^{t}\left|\frac{y_{t+1,i} - \hat{y}_{t+1,i}}{y_{t+1,i}}\right| \times 100 \quad (13)$$

MAPE มีข้อดีคือสามารถตีความได้ง่าย เนื่องจากแสดงผลเป็นเปอร์เซ็นต์ของข้อผิดพลาด อย่างไรก็ตาม MAPE มีข้อจำกัดเมื่อตัวแปรตาม มีค่าเป็นศูนย์หรือมีค่าต่ำมาก ทำให้เกิดความผิดพลาดสูง

2.7 ข้อมูลและวิธีการเก็บข้อมูลสำหรับงานวิจัย

งานวิจัยนี้ใช้ ข้อมูลจำลอง เพื่อทดสอบประสิทธิภาพของอัลกอริธึม Real-time Adaptive Penalization (RAP) ในบริบทของข้อมูลสตรีมมิงที่ไม่คงที่ โดยออกแบบให้ข้อมูลมีการเปลี่ยนแปลงของ ค่าเฉลี่ย (Mean), ความแปรปรวน (Variance) และ โครงสร้างของข้อมูล (Data Structure) อย่างต่อเนื่อง

ชุดข้อมูลที่ใช้ประกอบด้วย 300 ตัวอย่าง และ ตัวแปรต้น 20 ตัว โดยแบ่งการเปลี่ยนแปลงออกเป็นสองลักษณะหลัก ได้แก่

- Low-Frequency Shift (เปลี่ยนแปลงโครงสร้างของข้อมูลทุก 100 ตัวอย่าง จำนวน 3 รอบ)
- High-Frequency Shift (เปลี่ยนแปลงโครงสร้างของข้อมูล ทุก 60 ตัวอย่าง จำนวน 5 รอบ)

เพื่อตรวจสอบความสามารถของอัลกอริธึมในการปรับตัวภายใต้สภาพแวดล้อมที่มีการเปลี่ยนแปลงที่แตกต่างกัน

2.7.1 การจำลองข้อมูลตัวแปรต้น

ข้อมูล X_t ถูกจำลองขึ้นตามการแจกแจงแบบ พหุคูณเกาส์เซียนโดยกำหนดค่าเฉลี่ยและความแปรปรวนที่เปลี่ยนแปลงตามรอบการเปลี่ยนแปลงของข้อมูล

$$X_t \sim N(mean, diag(variance)) \quad (14)$$

2.7.2 การจำลองค่าสัมประสิทธิ์การถดถอย

ค่าสัมประสิทธิ์การถดถอย β_t ถูกสุ่มขึ้นจากการแจกแจงแบบเกาส์เซียนมาตรฐาน

$$N(0,1) \quad (15)$$

โดยจำลอง สภาวะของข้อมูลสองแบบ

- สภาวะที่มีความหนาแน่นสูง ($\rho_1 = 0.7$) 70% ของตัวแปรมีค่าสัมประสิทธิ์ที่ไม่เป็นศูนย์
- สภาวะที่มีความหนาแน่นต่ำ ($\rho_2 = 0.3$) 30% ของตัวแปรมีค่าสัมประสิทธิ์ที่ไม่เป็นศูนย์

2.7.3 การจำลองตัวแปรความไม่แน่นอน

ค่าความไม่แน่นอน u_t ถูกจำลองขึ้นโดยใช้กระบวนการ Autoregressive Order 1 (AR(1))

$$u_t = \phi \cdot u_{t-1} + \epsilon_t \quad (16)$$

เมื่อ

ϕ แทน พารามิเตอร์ที่กำหนดความเข้มข้นของการพึ่งพาต่อค่าในช่วงเวลาก่อนหน้า ในงานวิจัยนี้กำหนดให้เท่ากับ 0.8

ϵ_t แทน ค่าความคลาดเคลื่อนที่แจกแจงแบบเกาส์เซียนมาตรฐาน $N(0,1)$

2.7.4 การจำลองตัวแปรตอบสนอง

ตัวแปรตอบสนอง y_t ถูกสร้างขึ้นตามสมการเชิงเส้นที่รวมตัวแปรต้น X_t, ค่าสัมประสิทธิ์การถดถอย β_t และตัวแปรความไม่แน่นอน u_t

$$y_t = X_t\beta_t + u_t + mean_value \quad (17)$$

โดยที่ค่า $mean_value$ ถูกกำหนดให้แตกต่างกันตามช่วงเวลาของข้อมูล X_t

2.7.5 การแบ่งชุดข้อมูล

- ชุดฝึก (Training Data) ข้อมูลจำลองประมาณ 80% ของข้อมูลทั้งหมดถูกนำมาใช้ในการฝึกโมเดลการถดถอยแบบเรียลไทม์
- ชุดทดสอบ (Test Data) ข้อมูลที่เหลืออีก 20% ถูกใช้ในการทดสอบประสิทธิภาพการคาดการณ์ของโมเดลหลังจากที่ได้ฝึกเสร็จสิ้น

2.8 การกำหนดค่าพารามิเตอร์เริ่มต้น

ในงานวิจัยนี้ ค่าพารามิเตอร์การลงโทษ λ และ อัตราการเรียนรู้ ϵ เป็นองค์ประกอบสำคัญที่ส่งผลโดยตรงต่อการปรับตัวของอัลกอริธึม Real-time Adaptive Penalization (RAP) โดยค่าพารามิเตอร์ที่ใช้ในงานวิจัยถูกกำหนดดังนี้

2.8.1 ค่าพารามิเตอร์การลงโทษเริ่มต้น (λ_0)

กำหนดค่าเริ่มต้นเป็น 0.1 และอัปเดตในแต่ละรอบการเรียนรู้ตามแนวทาง Residual-based Adaptive Regularization

2.8.2 อัตราการเรียนรู้ (ϵ)

กำหนดค่าเป็น 0.05 ซึ่งถูกเลือกให้เหมาะสมกับการเปลี่ยนแปลงของข้อมูลที่ไม่คงที่

3. ผลการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของ Real-time Adaptive Penalization (RAP) สำหรับ Lasso, Ridge และ Elastic Net ในบริบทของ ข้อมูลสตรีมมิงที่ไม่คงที่ (Non Stationary Streaming Data) โดยเน้นการประเมินความสามารถของอัลกอริธึมในการพยากรณ์และปรับตัวต่อการเปลี่ยนแปลงของข้อมูล

3.1 การออกแบบการทดลอง

ในการศึกษานี้มีการใช้ ข้อมูลจำลอง เพื่อทดสอบประสิทธิภาพของอัลกอริธึม Real-time Adaptive Penalization (RAP) ภายใต้เงื่อนไขที่มีการเปลี่ยนแปลงของค่าเฉลี่ย ความแปรปรวน และค่าสัมประสิทธิ์การถดถอยเป็นรอบ ๆ โดยลักษณะของการเปลี่ยนแปลงของข้อมูลแบ่งออกเป็นสองรูปแบบหลัก ได้แก่ รูปแบบที่มีการเปลี่ยนแปลงต่ำ (Low-Frequency Shift) ซึ่งข้อมูลมีการเปลี่ยนแปลงทุก 100 ตัวอย่าง จำนวน 3 รอบ และรูปแบบที่มีการเปลี่ยนแปลงสูง (High-Frequency Shift) ซึ่งข้อมูลมีการเปลี่ยนแปลงทุก 60 ตัวอย่าง จำนวน 5 รอบ

นอกจากนี้ ข้อมูลยังมีการสลับระหว่างสองสภาวะหลัก ได้แก่ สภาวะที่มีความหนาแน่นสูง ซึ่งหมายถึงสัดส่วนของค่าสัมประสิทธิ์ที่ไม่เป็นศูนย์มีค่าเท่ากับ 70% ของตัวแปรทั้งหมด และ สภาวะที่มีความหนาแน่นต่ำ ซึ่งหมายถึงสัดส่วนของค่าสัมประสิทธิ์ที่ไม่เป็นศูนย์มีค่าเท่ากับ 30% ของตัวแปรทั้งหมด การออกแบบลักษณะการเปลี่ยนแปลงของข้อมูลในลักษณะดังกล่าวมีวัตถุประสงค์เพื่อประเมินความสามารถของอัลกอริธึมในการปรับตัวเมื่อเผชิญกับข้อมูลที่มีความไม่แน่นอนและความซับซ้อนสูง

3.2 การเปรียบเทียบความแม่นยำของการพยากรณ์

การเปรียบเทียบความแม่นยำของอัลกอริธึม RAP ทั้งสามรูปแบบ ได้แก่ RAP-Lasso (RAPL), RAP-Ridge (RidgeRAP), และ RAP-Elastic Net (ElasticNetRAP) ดำเนินการโดยใช้เกณฑ์การประเมิน 4 ตัวชี้วัดหลัก

ตารางที่ 1: แสดงค่าความผิดพลาดในการพยากรณ์ของแต่ละอัลกอริธึม (ค่าที่เป็นตัวหนาแสดงถึงค่าที่ดีที่สุดในแต่ละตัวชี้วัด)

Model	MSE	RMSE	MAE	MAPE
Low-Frequency Shift				
RAPL	**77.79**	**8.82**	**6.34**	1.91
RidgeRAP	100.46	10.02	6.88	**1.06**
ElasticNetRAP	103.29	10.16	6.99	1.12
High-Frequency Shift				
RAPL	**286.67**	**16.93**	**10.90**	1.41
RidgeRAP	384.83	19.62	12.30	1.20
ElasticNetRAP	378.25	19.45	12.19	**1.16**

จากตารางที่ 1 แสดงให้เห็นว่า RAPL มีค่าความผิดพลาดต่ำที่สุดในทุกตัวชี้วัดทั้งในกรณี Low-Frequency Shift และ High-Frequency Shift โดยเฉพาะในกรณีที่ข้อมูลมีการเปลี่ยนแปลงต่ำ (Low-Frequency Shift) โมเดลสามารถปรับตัวได้อย่างมีประสิทธิภาพและให้ค่าความผิดพลาดที่ต่ำกว่า RidgeRAP และ ElasticNetRAP อย่างมีนัยสำคัญ ในขณะที่ เมื่ออัตราการเปลี่ยนแปลงของข้อมูลสูงขึ้น (High-Frequency Shift) ค่าความผิดพลาดของทุกอัลกอริธึมเพิ่มขึ้น แต่ RAPL ยังคงมีค่าความคลาดเคลื่อนต่ำกว่าทั้ง RidgeRAP และ ElasticNetRAP แสดงให้เห็นถึงความสามารถในการปรับตัวของโมเดล

3.3 การเปรียบเทียบความสามารถในการปรับตัวของอัลกอริธึม

นอกจากการประเมินค่าความคลาดเคลื่อนแล้ว งานวิจัยนี้ยังวิเคราะห์ความสามารถในการปรับตัวของแต่ละอัลกอริธึม โดยพิจารณาแนวโน้มการเปลี่ยนแปลงของค่าสัมประสิทธิ์เปรียบเทียบกับค่าพารามิเตอร์ของจริง (True Beta)

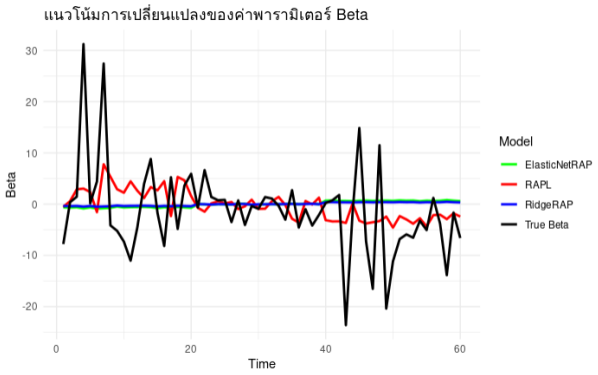

ภาพที่ 1: แนวโน้มการเปลี่ยนแปลงของค่าพารามิเตอร์สัมประสิทธิ์ภายใต้รูปแบบข้อมูลที่มีการเปลี่ยนแปลงต่ำ

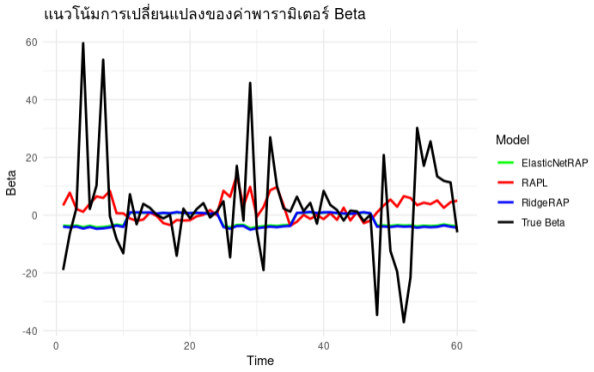

ภาพที่ 2: แนวโน้มการเปลี่ยนแปลงของค่าพารามิเตอร์สัมประสิทธิ์ภายใต้รูปแบบข้อมูลที่มีการเปลี่ยนแปลงสูง

ผลการทดลองชี้ให้เห็นว่า RAPL สามารถติดตามแนวโน้มของค่าพารามิเตอร์ได้ใกล้เคียงกับค่าจริงมากที่สุด ขณะที่ RidgeRAP มีแนวโน้มที่จะมีความล่าช้าในการตอบสนองต่อการเปลี่ยนแปลงของข้อมูล และ ElasticNetRAP มีความเบี่ยงเบนจากค่าจริงมากที่สุด โดยเฉพาะในกรณีที่ข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็ว ซึ่งสะท้อนให้เห็นถึงข้อจำกัดของโมเดล RidgeRAP และ ElasticNetRAP ในการปรับตัวกับข้อมูลที่ไม่คงที่

3.4 การเปรียบเทียบประสิทธิภาพด้านเวลาในการคำนวณ

งานวิจัยยังได้วิเคราะห์ประสิทธิภาพด้านเวลาในการคำนวณของอัลกอริธึม โดยพิจารณาทั้ง Training Time และ Prediction Time

ตารางที่ 2: ผลลัพธ์ของการทดลองแสดงค่าเฉลี่ยของระยะเวลาที่ใช้ในการฝึกฝนและพยากรณ์ของแต่ละอัลกอริธึม ซึ่งเฉลี่ยจากการรันทั้งหมด 100 รอบ (ค่าที่เป็นตัวหนาแสดงถึงค่าที่ดีที่สุดในแต่ละเกณฑ์)

Model	Training Time (วินาที)	Prediction Time (วินาที)
Low-Frequency Shift		
RAPL	0.0556	0.0000355
RidgeRAP	**0.0207**	**0.0000266**
ElasticNetRAP	0.0474	0.0000296
High-Frequency Shift		
RAPL	0.0747	0.0000376
RidgeRAP	**0.0211**	0.0000274
ElasticNetRAP	0.0418	**0.0000272**

จากตารางที่ 2 แสดงให้เห็นว่า RidgeRAP แสดงให้เห็นถึงประสิทธิภาพสูงสุดในด้านเวลาในการคำนวณ โดยใช้เวลาฝึกฝนและพยากรณ์น้อยที่สุดเมื่อเทียบกับ RAPL และ ElasticNetRAP ทั้งในกรณี Low-Frequency Shift และ High-Frequency Shift ความได้เปรียบในเชิงความเร็วนี้ทำให้ RidgeRAP เป็นตัวเลือกที่เหมาะสมสำหรับงานที่ต้องการประมวลผลข้อมูลอย่างรวดเร็ว ElasticNetRAP แสดงผลลัพธ์ที่ใกล้เคียงกับ RidgeRAP ในแง่ของเวลาคำนวณ แต่ยังคงใช้เวลาในการฝึกฝนมากกว่าเล็กน้อย โดยเฉพาะใน กรณี High-Frequency Shift ที่เวลาพยากรณ์ของ ElasticNetRAP (0.0000272 วินาที) ใกล้เคียงกับ RidgeRAP (0.0000274 วินาที) ความสมดุลระหว่างความเร็วและความสามารถในการเรียนรู้ของ ElasticNetRAP ทำให้เป็นตัวเลือกที่เหมาะสำหรับงานที่ต้องการทั้ง ความเร็วและความแม่นยำในการพยากรณ์

RAPL ใช้ ค่าใช้จ่ายในการคำนวณ สูงสุดเนื่องจากการลงโทษแบบ L1 ที่ซับซ้อนกว่า L2 อย่างไรก็ตาม การใช้เวลาฝึกฝนนานขึ้นนี้ส่งผลให้ RAPL มี ความแม่นยำสูงสุด เมื่อพิจารณาจากตัวชี้วัดความผิดพลาดในการพยากรณ์ ได้แก่ MSE, RMSE, MAE และ MAPE โดยให้ค่าความคลาดเคลื่อนต่ำที่สุดในทุกกรณี

การเปรียบเทียบ ความสมดุลระหว่างความแม่นยำและค่าใช้จ่ายในการคำนวณ ชี้ให้เห็นว่า หากต้องการ ความเร็วสูงสุดในการฝึกฝนและพยากรณ์ RidgeRAP เป็นตัวเลือกที่ดีที่สุด หากต้องการ ความสมดุลระหว่างความแม่นยำและเวลาคำนวณ ElasticNetRAP เป็นทางเลือกที่เหมาะสม ในกรณีที่ต้องการลดค่าใช้จ่ายด้านเวลาคำนวณแต่ยังรักษาความแม่นยำได้ดี ในขณะที่ RAPL เหมาะสำหรับกรณีที่ต้องการ ความแม่นยำสูงสุด แม้ว่าจะต้องใช้ ค่าใช้จ่ายในการคำนวณ ที่สูงกว่าอัลกอริธึมอื่นๆ

4. สรุปผล

งานวิจัยนี้นำเสนอการเปรียบเทียบประสิทธิภาพของอัลกอริธึม Real-time Adaptive Penalization (RAP) สำหรับ Lasso, Ridge และ Elastic Net ในบริบทของ ข้อมูลสตรีมมิงที่ไม่คงที่ (Non-Stationary Streaming Data) โดยพิจารณาทั้ง ความแม่นยำในการพยากรณ์ ความสามารถในการปรับตัวของโมเดล และประสิทธิภาพด้านเวลาในการคำนวณ

ผลการศึกษาพบว่า RAPL (RAP-Lasso) มี ความแม่นยำในการพยากรณ์สูงสุด โดยให้ค่าความคลาดเคลื่อนต่ำที่สุดในตัวชี้วัดหลัก ได้แก่ MSE, RMSE และ MAE ขณะที่ RidgeRAP มี ประสิทธิภาพด้านเวลาสูงสุด โดยใช้เวลาฝึกฝนและพยากรณ์น้อยที่สุด สำหรับ ElasticNetRAP แสดง ผลลัพธ์ที่สมดุลระหว่างความแม่นยำและเวลาคำนวณ โดยให้ค่าความแม่นยำสูงกว่า RidgeRAP แต่ใช้เวลาฝึกฝนน้อยกว่า RAPL อย่างมีนัยสำคัญ โดยเฉพาะในกรณีที่ข้อมูลมีการเปลี่ยนแปลงบ่อย (High-Frequency Shift) ซึ่ง ElasticNetRAP สามารถปรับตัวได้ดีกว่า RidgeRAP ในแง่ของความแม่นยำ แต่ยังใช้เวลาฝึกฝนน้อยกว่า RAPL ทำให้เป็นตัวเลือกที่เหมาะสมหากต้องการความสมดุลระหว่าง ประสิทธิภาพด้านเวลาและความแม่นยำในการพยากรณ์

นอกจากนี้ RAPL สามารถ ติดตามแนวโน้มของค่าพารามิเตอร์ได้แม่นยำกว่า RidgeRAP และ ElasticNetRAP โดยเฉพาะในกรณีที่ข้อมูลมีการเปลี่ยนแปลงอย่างชัดเจน อย่างไรก็ตาม การลงโทษแบบ L1 ทำให้ RAPL ใช้เวลาในการคำนวณมากกว่าทางเลือกอื่น ซึ่งแสดงถึงสมดุลระหว่าง ความแม่นยำในการพยากรณ์และค่าใช้จ่ายในการคำนวณ ที่ต้องพิจารณาในการเลือกใช้โมเดลให้เหมาะสมกับลักษณะของข้อมูลและข้อจำกัดด้านเวลาในการใช้งาน

5. เอกสารอ้างอิง

[1] Monti, R. P., Anagnostopoulos, C., & Montana, G. (2018). Adaptive regularization for Lasso models in the context of nonstationary data streams. Statistical Analysis and Data Mining: The ASA Data Science Journal.

[2] Boyd, S., Parikh, N., Chu, E., Peleato, B., & Eckstein, J. (2011). Distributed optimization and statistical learning via the alternating direction method of multipliers. Foundations and Trends® in Machine Learning, 3(1), 1-122.

[3] Xu, Y., Yin, W., Wen, Z., & Zhang, Y. (2017). A proximal gradient method for large-scale Lasso problems. SIAM Journal on Optimization, 27(2), 831-856.

[4] Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. In Proceedings of COMPSTAT'2010 (pp. 177-186). Springer.

[5] Friedman, J., Hastie, T., & Tibshirani, R. (2010). Regularization paths for generalized linear models via coordinate descent. Journal of Statistical Software, 33(1), 1-22.

[6] Rosset, S., & Zhu, J. (2007). Piecewise linear regularized solution paths. Annals of Statistics, 35(3), 1012-1030.

[7] Meinshausen, N., & Bühlmann, P. (2010). Stability selection. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 72(4), 417-473.

การประเมินน้ำหนักปัจจัยเสี่ยงที่มีต่อผลความปลอดภัยในงานก่อสร้าง ด้วยวิธีวิเคราะห์เชิงลำดับชั้นแบบปรับปรุง

Weight Assessment of Risk Factors Affecting Construction Safety by Modified Analytic Hierarchy Process

ณฐนน นิติกุลชินภาค* ดำรงศักดิ์ รินชุมภู
ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์มหาวิทยาลัยเชียงใหม่
*(*nathanon_nitikun@cmu.ac.th)*

บทคัดย่อ

อุตสาหกรรมการก่อสร้างมีอัตราการเกิดอุบัติเหตุสูง เนื่องจากปัจจัยเสี่ยงหลายด้านที่ส่งผลกระทบต่อความปลอดภัยของผู้ปฏิบัติงาน งานวิจัยฉบับนี้มีวัตถุประสงค์เพื่อประเมินน้ำหนักของปัจจัยเสี่ยงที่มีผลต่อความปลอดภัยในงานก่อสร้าง โดยใช้กระบวนการลำดับชั้นเชิงวิเคราะห์แบบปรับปรุง (Modified Analytical Hierarchy Process : Modified AHP) ในการวิเคราะห์ปัจจัยเสี่ยงที่มีผลกระทบหลัก 4 ด้าน ได้แก่ 1)ปัจจัยด้านผู้ปฏิบัติงาน(A) ,2)ปัจจัยด้านเทคนิค(B) ,3)ปัจจัยด้านการบริหารจัดการ(C) ,4)ปัจจัยด้านสภาพแวดล้อม(D) กลุ่มตัวอย่างที่ใช้ในการศึกษาคือผู้เชี่ยวชาญในอุตสาหกรรมการก่อสร้างที่มีประสบการณ์ 7-10 ปี จำนวน10 ท่าน ผลการศึกษาพบว่าปัจจัยที่มีน้ำหนักความสำคัญสูงสุดคือปัจจัยด้านผู้ปฏิบัติงาน โดยเฉพาะการขาดความรู้ ความเข้าใจด้านความปลอดภัยและการขาดความรับผิดชอบในการทำงาน รองลงมาคือ ปัจจัยด้านเทคนิค และปัจจัยด้านการบริหารจัดการ เช่น การใช้อุปกรณ์เครื่องจักรที่ไม่มีประสิทธิภาพและเรื่องต้นทุนและการลงทุนด้านความปลอดภัย ผลการศึกษานี้สามารถนำไปใช้เป็นแนวทางในการวางแผนและบริหารจัดการความปลอดภัยในงานก่อสร้าง เพื่อป้องกันและลดอุบัติเหตุที่อาจเกิดขึ้นได้อย่างมีประสิทธิภาพ

คำสำคัญ : ความปลอดภัยในงานก่อสร้าง, ปัจจัยเสี่ยง, การวิเคราะห์เชิงลำดับชั้นแบบปรับปรุง

Abstract

The construction industry has a high accident rate due to multiple risk factors that affect worker safety. This research aims to assess the weight of risk factors affecting construction safety using the Modified Analytical Hierarchy Process (Modified AHP) to analyze the risk factors with 4 main impacts: 1) worker factors (A), 2) technical factors (B), 3) management factors (C), and 4) environmental factors (D). The sample group used in the study was 10 construction industry experts with 7-10 years of experience. The results of the study found that the factor with the highest weight was worker factors, especially the lack of knowledge and understanding of safety and the lack of responsibility in work. The second most important factor was technical factors and management factors, such as the use of inefficient equipment and machinery, and the cost and investment in safety. The results of this study can be used as a guideline for planning and managing construction safety in order to effectively prevent and reduce potential accidents.

Keywords: construction safety, risk factors, applied hierarchy analysis, Modified AHP

1. บทนำ

อุตสาหกรรมงานก่อสร้างในประเทศไทยพบสัดส่วนการขยายตัวที่มีแนวโน้มเพิ่มขึ้นในปีพ.ศ. 2567 ทั้งในส่วนของภาครัฐ และภาคเอกชน และในขณะเดียวกันจากปริมาณงานก่อสร้างเพิ่มขึ้น อุบัติเหตุในงานก่อสร้างก็มีแนวโน้มเพิ่มมากขึ้นเช่นกัน ทั้งนี้เนื่องจากลักษณะงานก่อสร้างเป็นงานที่มีความซับซ้อนและความไม่แน่นอนในขั้นตอนการดำเนินงาน ประกอบกับคนงานจำนวนมากปรากฏความเสี่ยงต่อการเกิด

อันตรายที่อาจเกิดจากหลายปัจจัยในงานก่อสร้าง ดังนั้นความปลอดภัยในงานก่อสร้างจึงเป็นสิ่งสำคัญที่ไม่ควรมองข้าม ด้วยสาเหตุดังกล่าวการหาวิธีป้องกันและลดการเกิดอุบัติเหตุจึงเป็นสิ่งที่ควรดำเนินการ เพื่อลดความสูญเสียทั้งในด้านชีวิตและทรัพย์สินสำหรับฐานข้อมูลในปีพ.ศ.2562-2566 พบอัตราการเกิดอุบัติเหตุและการประสบอันตรายในประเทศไทยจากงานก่อสร้างนั้นมีสัดส่วนสูงเป็นอันดับหนึ่งเมื่อเทียบกับอุตสาหกรรมอื่นๆ ทั้งจากการก่อสร้างอาคารประเภทที่พักอาศัยและไม่ใช่ที่พักอาศัย

สำหรับการศึกษาและวิเคราะห์ปัจจัยเสี่ยงที่มีผลต่อความปลอดภัยในก่อสร้างนั้นมีวิธีการเทคนิคที่ใช้ในการศึกษาอย่างหลากหลาย กระบวนการลำดับชั้นเชิงวิเคราะห์ (Analytical Hierarchy Process : AHP) เป็นวิธีวิเคราะห์ข้อมูลที่ตัดสินใจเชิงปริมาณที่ช่วยจัดการปัญหาที่มีหลายเกณฑ์ (Multi-Criteria Decision Making: MDCM) โดยใช้แนวคิดทางคณิตศาสตร์และจิตวิทยาในการแปลงความชอบเชิงอัตวิสัย (Subjective Preferences) ให้เป็นข้อมูลเชิงปริมาณที่สามารถนำไปเปรียบเทียบได้ ใช้การแบ่งปัจจัยที่ส่งผลต่อปัญหาออกเป็นส่วนๆ ในรูปแบบของแผนภูมิลำดับชั้น มีการให้ค่าน้ำหนักความสำคัญของแต่ละปัจจัย ทำการสรุปผลจนได้มาซึ่งค่าลำดับความสำคัญของปัจจัย และสามารถช่วยให้ผู้ตัดสินใจสามารถวิเคราะห์ตลอดจนถึงจัดลำดับความสำคัญของตัวเลือกต่างๆได้อย่างเป็นระบบและมีประสิทธิภาพโดย (AHP) เป็นเครื่องมือที่มักถูกนำมาปรับในการวิเคราะห์ข้อมูลในหลากหลายภาคส่วน เช่น ด้านวิศวกรรมด้านเทคโนโลยี ด้านการผลิต ด้านสังคมศาสตร์ เป็นต้น ตั้งแต่อดีตจนถึงปัจจุบัน (AHP) ยังคงมีแนวโน้มถูกนำมาใช้จำนวนเพิ่มขึ้น โดยเฉพาะในสายงานด้านวิศวกรรม ในด้านของวิศวกรรมก่อสร้างและการบริหารงานก่อสร้างพบว่า (AHP) มักถูกนำไปใช้ในการบริหารความเสี่ยงและการก่อสร้างแบบยั่งยืน เนื่องจากเป็นส่วนที่มีความละเอียดอ่อน กิจกรรมที่เกี่ยวข้องในสองส่วนนี้ส่งผลกระทบโดยตรงต่อมนุษย์ สิ่งแวดล้อม และอุตสาหกรรมการก่อสร้างโดยรวม อีกทั้งในการบริหารงานก่อสร้างอาจยังขาดความเป็นกลางในการตัดสินใจ (AHP) จึงเป็นเทคนิคค่อนข้างมีความเหมาะสมต่อการนำมาใช้

ด้วยเหตุผลที่กล่าวมาข้างต้น ผู้วิจัยจึงมองเห็นช่องว่างและมุ่งทำการศึกษาผ่านเครื่องมือ (Modified Analytical Hierarchy Process : Modified AHP) เพื่อทำการค้นหาและประเมินน้ำหนักของปัจจัยเสี่ยงที่มีผลต่อความปลอดภัยในงานก่อสร้างโดยใช้กระบวนการลำดับชั้นเชิงวิเคราะห์แบบปรับปรุง(Modified AHP) เพื่อสามารถนำไปใช้ในการวางแผนและป้องกันอันตรายในการดำเนินงานก่อสร้างได้อย่างตรงเป้าหมายและให้เกิดประสิทธิภาพสูงสุด

โดยอธิบายความแตกต่างระหว่าง (AHP) และ (Modified AHP) ไว้ดังต่อไปนี้

ตารางที่ 1 ตารางเปรียบเทียบ (AHP) และ (Modified AHP)

หัวข้อเปรียบเทียบ	Analytical Hierarchy Process: AHP	Modified AHP (MAHP)
แนวคิดหลัก	ใช้กระบวนการวิเคราะห์ลำดับชั้น (Hierarchy) และการเปรียบเทียบคู่ (Pairwise Comparison) เพื่อกำหนดค่าน้ำหนักปัจจัย	เป็นการปรับปรุง AHP ให้มีความแม่นยำมากขึ้นโดยลดข้อผิดพลาดจากการเปรียบเทียบคู่และเพิ่มแนวทางการคำนวณที่เหมาะสม
กระบวนการหลัก	1.สร้างโครงสร้างลำดับชั้นของปัญหา 2.ทำการเปรียบเทียบคู่ (Pairwise Comparison) 3.คำนวณค่าน้ำหนักและตรวจสอบความสอดคล้อง (Consistency) 4.นำค่าน้ำหนักไปใช้ในการตัดสินใจ	1.ปรับปรุงกระบวนการเปรียบเทียบคู่โดยลดอคติของผู้ประเมิน 2.ใช้วิธีการคำนวณที่ลดความคลาดเคลื่อนของค่าความสอดคล้อง (Consistency Ratio) 3.ปรับปรุงกระบวนการหาค่าน้ำหนักให้มีความถูกต้องมากขึ้น
ข้อดี	- เข้าใจง่าย และใช้ได้กับปัญหาหลายประเภท - มีโครงสร้างชัดเจน - สามารถประเมินค่าความสอดคล้องของการเปรียบเทียบได้	- ลดข้อผิดพลาดของ AHP โดยเฉพาะอคติจากผู้ให้คะแนน - ทำให้การคำนวณค่าน้ำหนักมีความแม่นยำมากขึ้น - ปรับปรุงวิธีการหาความสอดคล้องเพื่อให้ค่าที่ได้มีความน่าเชื่อถือมากขึ้น
ข้อจำกัด	- อาจเกิดความไม่สอดคล้องในการเปรียบเทียบคู่ (Inconsistency) - ผู้ใช้ต้องมีความเชี่ยวชาญในการกำหนดค่าความสำคัญ	- มีความซับซ้อนมากขึ้นในการคำนวณ - ต้องมีการกำหนดวิธีการแก้ไข AHP ที่ชัดเจน
การใช้งานหลัก	-ใช้ในการวิเคราะห์ลำดับความสำคัญของปัจจัยต่างๆ เช่น การตัดสินใจทางธุรกิจ การเลือกโครงการ การจัดลำดับความสำคัญเชิงกลยุทธ์	- ใช้ในสถานการณ์ที่ต้องการความแม่นยำสูงขึ้น เช่น งานวิจัยที่เกี่ยวข้องกับการประเมินปัจจัยเสี่ยง การตัดสินใจเชิงกลยุทธ์ที่ซับซ้อน

โดยผู้วิจัยมีเหตุผลที่เลือกใช้ (Modified AHP) เพื่อใช้ในสถานการณ์ที่ต้องการความแม่นยำสูงขึ้น เช่น งานวิจัยที่เกี่ยวข้องกับการประเมินปัจจัยเสี่ยง การตัดสินใจเชิงกลยุทธ์ที่ซับซ้อนและเพิ่มความแม่นยำของการคำนวณเมื่อเทียบกับ (AHP)

2. วิธีการวิจัย

2.1 กำหนดวัตถุประสงค์

การศึกษานี้มีวัตถุประสงค์เพื่อประเมินน้ำหนักของปัจจัยเสี่ยงที่ส่งผลต่อความปลอดภัยในงานก่อสร้างโดยใช้กระบวนการลำดับชั้นเชิงวิเคราะห์แบบปรับปรุง (Modified Analytical Hierarchy Process : Modified AHP) กระบวนการวิเคราะห์เริ่มจากการทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องเพื่อระบุปัจจัยหลักและปัจจัยรองก่อนสร้างแบบสอบถามเพื่อให้ผู้เชี่ยวชาญแสดงความคิดเห็นเกี่ยวกับปัจจัยเสี่ยง โดยกำหนดกลุ่มผู้เชี่ยวชาญจำนวน 10 ท่านซึ่งมีประสบการณ์ด้านงานก่อสร้างอาคารที่พักอาศัยและอาคารที่ไม่ใช่ที่พักอาศัยเป็นระยะเวลา 7-10 ปีผู้เชี่ยวชาญจะให้คะแนนปัจจัยเสี่ยงโดยใช้วิธีการเปรียบเทียบแบบรายคู่(Pairwise Comparison) ข้อมูลที่ได้จะถูกนำมาวิเคราะห์ผ่าน Modified AHP เพื่อนำไปสู่การประเมินปัจจัยที่มีผลต่อกิจกรรมก่อสร้างดังนั้นการศึกษานี้จึงนำแนวทาง Modified AHP มาประยุกต์ใช้ในการวิเคราะห์ปัจจัยเสี่ยงโดยรายละเอียดของกระบวนการดำเนินการจะอธิบายในหัวข้อต่อไป

2.2 กระบวนการลำดับชั้นเชิงวิเคราะห์แบบปรับปรุง (Modified Analytical Hierarchy Process: Modified AHP)

*2.2.1.การจัดโครงสร้างลำดับชั้น (Hierarchy Construction)*สร้างแผนภูมิลำดับชั้น (Hierarchy)เป็นเลียนแบบกระบวนการคิดเพื่อตัดสินใจของมนุษย์

2.2.2.การหาค่ากลางของข้อมูลเนื่องจากในงานวิจัยนี้ ผู้เชี่ยวชาญไม่สามารถมาประชุมพร้อมกันได้จึงต้องทำการหาค่าตัวกลางของข้อมูลในขั้นตอนการเปรียบเทียบรายคู่โดยอาศัยวิธีการคำนวณค่าเฉลี่ยเรขาคณิต (Geometric Mean) สำหรับตัวแปรที่มีความสัมพันธ์ต่อกันโดยใช้สูตร

$$G = \sqrt[n]{X_1 \cdot X_2 \cdots X_n}$$

โดยที่ X_i = ค่าน้ำหนักแบบสอบถามที่ได้จากผู้เชี่ยวชาญ

n = จำนวนผู้เชี่ยวชาญ

ตารางที่ 2 ค่าน้ำหนักแบบสอบถาม

ลำดับความสำคัญ	ความหมาย
1	มีลำดับความสำคัญที่เท่ากัน(Equal Importance)
3	มีลำดับความสำคัญกว่าเล็กน้อย (Moderate Importance)
5	มีลำดับความสำคัญกว่าปานกลาง (Strong Importance)
7	มีลำดับความสำคัญกว่ามาก (Very Strong Importance)
9	มีลำดับความสำคัญกว่ามากที่สุด (Extreme Importance)
2,4,6,8	มีลำดับความสำคัญอยู่ระหว่างสองระดับที่ติดกัน

2.2.3. การตรวจสอบความสอดคล้องของข้อมูล

ในการตรวจสอบความสอดคล้องของข้อมูลว่าสามารถนำค่าเจาะจง(Eigen vector)ที่ได้ใช้เป็นค่าน้ำหนักความสำคัญได้หรือไม่ โดยใช้สูตร (C.R. = C.I./R.I.) โดยที่

C.I. คือ ดัชนีของความสมเหตุสมผล (Consistency Index)

C.R. คือ สัดส่วนของความสมเหตุสมผล (Consistency Ratio)

R.I. คือ ดัชนีค่าสุ่มของความไม่สมเหตุสมผล (Random Inconsistency Index) ขึ้นอยู่กับขนาดของสแควร์เมตริก A

ตารางที่ 3 ตารางค่าดัชนีสุ่ม ค่า R.I. (Saaty 1980)

N =ขนาดเมตริกซ์	3	4	5	6	7	8	9	10
R.I.	0.52	0.89	1.11	1.25	1.35	1.40	1.45	1.49

$$C.I. = (\lambda max - n) / (n-1)$$

เมื่อ λmax คือค่า Eigen Value ที่มีค่าสูงสุด

n คือ ขนาดของสแควร์เมตริก

λmax คำนวณได้โดยเอา (S x W)

โดย (S) คือ ค่าคะแนนเมตริกที่ได้ทำการเปรียบเทียบเชิงคู่ และ (W) คือ เวกเตอร์ค่าถ่วงน้ำหนักของปัจจัย

โดยใช้สูตร $SxW = \begin{bmatrix} k1 \\ \vdots \\ \vdots \\ kn \end{bmatrix}$

จากนั้นนำค่า k1,k2,….,kn จากเมตริก (S xW) ไปคำนวณหา λmax ดังสมการต่อไปนี้

$$\lambda max = \frac{1}{n}\left(\frac{k1}{w1} + \frac{k2}{w2} + \cdots + \frac{kn}{wn}\right)$$

เมื่อคำนวณหาค่า C.R. ซึ่งผลการคำนวณไม่ควรเกิน 0.1 จึงจะถือข้อมูลมีความสอดคล้องกันเป็นข้อมูลที่เป็นเหตุเป็นผลกัน สามารถนำค่าไปใช้ค่าน้ำหนักความสำคัญในการพิจารณาได้ต่อไป

หลังจากนี้จะคำนวณหาค่า C.I. ความสอดคล้องของปัจจัยย่อยที่มีผลต่อปัจจัยหลัก โดยการคำนวณลำดับความสำคัญของทางเลือก เพื่อนำปัจจัยที่ได้ทั้งหมดมาใช้ในการวิเคราะห์การสร้างคะแนนน้ำหนักของ ปัจจัยเสี่ยงที่มีผลต่อความปลอดภัยในงานก่อสร้าง ที่ได้จากผู้เชี่ยวชาญ ที่มีส่วนเกี่ยวข้องกับกิจการด้านงานก่อสร้างประเภทงานอาคารที่พักอาศัยและไม่ใช่ที่พักอาศัย

2.2.4. ผลลัพธ์ของงานวิจัย

จากการกำหนดปัจจัยหลักของงานวิจัยมีดังต่อไปนี้

1.ปัจจัยด้านผู้ปฏิบัติงาน (A)

2.ปัจจัยด้านเทคนิค (B)

3.ปัจจัยด้านการบริหารจัดการ (C)

4.ปัจจัยด้านสภาพแวดล้อม (D)

ตารางที่ 4. (Pairwise Comparison Matrix) ปัจจัยหลัก

เปรียบเทียบปัจจัย	ปัจจัยหลัก					
	A	B	C	D	ผลรวม	Weighted
A	1	2.596	1.201	1.089	5.886	1.435
B	0.385	1	1.442	1.326	4.154	0.962
C	0.833	0.693	1	1.318	3.844	0.939
D	0.918	0.754	0.759	1	3.431	0.861
ผลรวม	3.136	5.044	4.402	4.734	17.315	

ตารางที่ 5. การหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยหลัก

เปรียบเทียบปัจจัย	ปัจจัยหลัก					
	A	B	C	D	Weight	percent
A	0.319	0.515	0.273	0.230	0.334	33.42
B	0.123	0.198	0.328	0.280	0.232	23.22
C	0.266	0.137	0.227	0.227	0.227	22.71
D	0.293	0.149	0.172	0.211	0.206	20.65
ผลรวม	1.00	1.00	1.00	1.00	1.00	100.00

Max Eigenvalue (λmax) = 4.185

Consistency Index (C.I.)= 0.0616

Consistency Ratio (C.R.=C.I./R.I.) = 0.0692 (มีความสมเหตุสมผล)

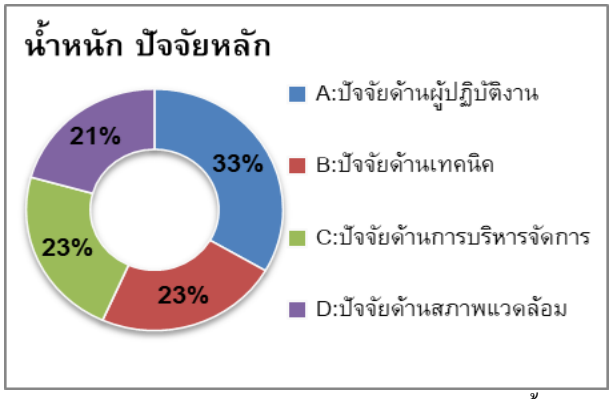

ปัจจัยรองของปัจจัยด้านผู้ปฏิบัติงาน (A) มีดังต่อไปนี้

1.การขาดความรับผิดชอบในการทำงาน (A1)

2.การมีสภาวะทางร่างกายและจิตใจที่ไม่สมบูรณ์ (A2)

3.การสื่อสารระหว่างบุคคล (A3)

4.การขาดความรู้ ความเข้าใจด้านความปลอดภัย (A4)

ตารางที่ 6.การหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยรอง A

เปรียบเทียบปัจจัย	ปัจจัยรอง A					
	A1	A2	A3	A4	Weight	percent
A1	0.260	0.536	0.207	0.236	0.310	31.00
A2	0.049	0.101	0.161	0.170	0.120	12.03
A3	0.219	0.109	0.174	0.164	0.167	16.66
A4	0.472	0.254	0.457	0.429	0.403	40.31
ผลรวม	1.000	1.000	1.000	1.000	1.000	100.00

Max Eigenvalue (λmax) = 4.254

Consistency Index (C.I.) = 0.0847

Consistency Ratio (C.R.=C.I./R.I.) = 0.0952 (มีความสมเหตุสมผล)

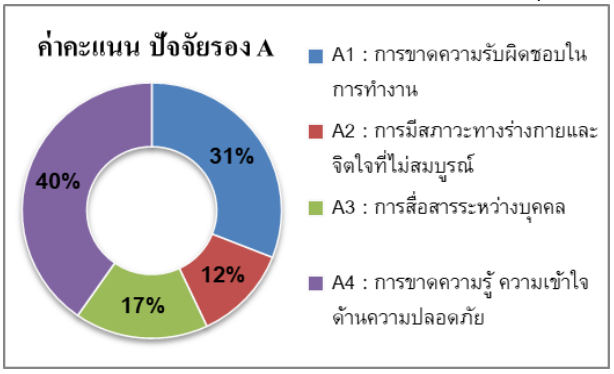

ปัจจัยรองของปัจจัยด้านเทคนิค (B) มีดังต่อไปนี้

1. การใช้อุปกรณ์และเครื่องจักรที่ไม่มีประสิทธิภาพ (B1)
2. การใช้งานอุปกรณ์เครื่องจักรอย่างไม่เหมาะสม (B2)
3. การออกแบบก่อสร้างและรายการประกอบแบบที่ไม่ชัดเจน (B3)

ตารางที่ 7.การหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยรอง B

เปรียบเทียบปัจจัย	ปัจจัยปัจจัยรอง B				
	B1	B2	B3	Weight	percent
B1	0.411	0.488	0.315	0.405	40.50
B2	0.285	0.338	0.452	0.359	35.85
B3	0.303	0.174	0.233	0.237	23.65
ผลรวม	1.000	1.000	1.000	1.000	100.00

Max Eigenvalue (λmax) = 3.059

Consistency Index (C.I.) = 0.0295

Consistency Ratio (C.R.=C.I./R.I.) = 0.0567(มีความสมเหตุสมผล)

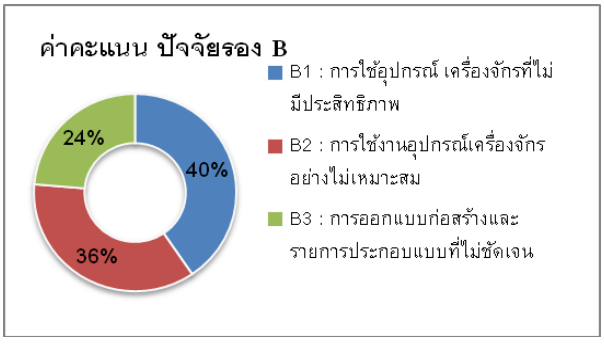

ปัจจัยรองของปัจจัยด้านการบริหารจัดการ (C) มีดังต่อไปนี้

1.การกำหนดนโยบายที่ไม่เหมาะสม (C1)

2.การบริหารจัดการด้านความปลอดภัยที่ไม่เหมาะสม (C2)

3.ขาดระบบการศึกษาด้านความปลอดภัย (C3)

4.เรื่องต้นทุนและการลงทุนด้านความปลอดภัย (C4)

ตารางที่ 8.การหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยรอง C

เปรียบเทียบปัจจัย	ปัจจัยรอง C					
	C1	C2	C3	C4	Weight	percent
C1	0.120	0.204	0.147	0.081	0.138	13.78
C2	0.203	0.347	0.395	0.393	0.334	33.45
C3	0.095	0.102	0.116	0.134	0.112	11.17
C4	0.582	0.347	0.342	0.393	0.416	41.60
ผลรวม	1.000	1.000	1.000	1.000	1.000	100.00

Max Eigenvalue (λmax) = 4.120

Consistency Index (C.I.) = 0.0400

Consistency Ratio (C.R.=C.I./R.I.) = 0.0450(มีความสมเหตุสมผล)

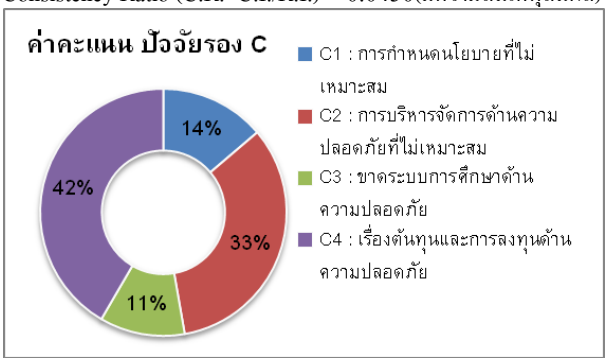

ปัจจัยรองของปัจจัยด้านการบริหารจัดการ (D) มีดังต่อไปนี้

1.เกิดจากภัยพิบัติทางธรรมชาติ (D1)

2.เกิดจากความแปรปรวนของสภาพอากาศ (D2)

3.เกิดจากสภาพแวดล้อมในการทำงาน (D3)

4.การจัดการสถานที่ก่อสร้างที่ไม่เหมาะสม (D4)

ตารางที่ 9.การหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยรอง D

เปรียบเทียบปัจจัย	ปัจจัยรอง D					
	D1	D2	D3	D4	Weight	percent
D1	0.407	0.462	0.392	0.358	0.405	40.48
D2	0.198	0.225	0.258	0.266	0.237	23.68
D3	0.195	0.163	0.187	0.201	0.187	18.65
D4	0.200	0.149	0.163	0.176	0.172	17.19
ผลรวม	1.000	1.000	1.000	1.000	1.000	100.00

Max Eigenvalue (λmax) = 4.018

Consistency Index (C.I.) = 0.0062

Consistency Ratio(C.R.=C.I./R.I.) = 0.0069 (มีความสมเหตุสมผล)

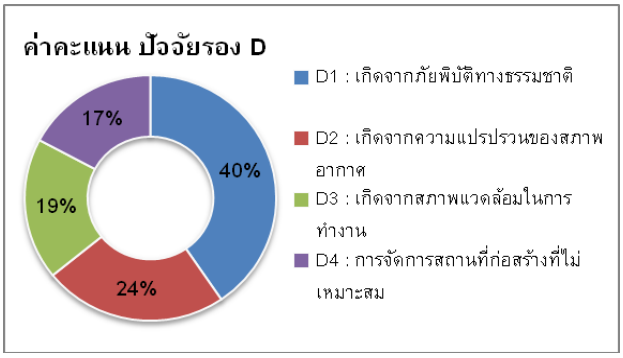

3. สรุปผลการวิจัย

จากผลการศึกษาผลการดำเนินกระบวนการลำดับชั้นเชิงวิเคราะห์แบบปรับปรุง (Modified Analytical Hierarchy Process : Modified AHP) ในแบบจำลองสำหรับการประเมินน้ำหนักของปัจจัยเสี่ยงที่มีผลต่อความปลอดภัยในงานก่อสร้าง จากทั้งหมด 4 ปัจจัยหลัก และ15 ปัจจัยรอง ได้แก่

1) ปัจจัยด้านผู้ปฏิบัติงาน แบ่งออกเป็น 4 ปัจจัยรอง ดังนี้ การขาดความรับผิดชอบในการทำงาน,การมีสภาวะทางร่างกายและจิตใจที่ไม่สมบูรณ์,การสื่อสารระหว่างบุคคล,การขาดความรู้ ความเข้าใจด้านความปลอดภัย

2) ปัจจัยด้านเทคนิค แบ่งออกเป็น 3 ปัจจัยรอง ดังนี้ การใช้อุปกรณ์และเครื่องจักรที่ไม่มีประสิทธิภาพ,การใช้งานอุปกรณ์เครื่องจักรอย่างไม่เหมาะสม,การออกแบบก่อสร้างและรายการประกอบแบบที่ไม่ชัดเจน

3) ปัจจัยด้านการบริหารจัดการ แบ่งออกเป็น 4 ปัจจัยรอง ดังนี้ การกำหนดนโยบายที่ไม่เหมาะสม,การบริหารจัดการด้านความปลอดภัยที่ไม่เหมาะสม,ขาดระบบการศึกษาด้านความปลอดภัย,เรื่องต้นทุนและการลงทุนด้านความปลอดภัย

4) ปัจจัยด้านสภาพแวดล้อม แบ่งออกเป็น 4 ปัจจัยรอง ดังนี้ เกิดจากภัยพิบัติทางธรรมชาติ,เกิดจากความแปรปรวนของสภาพอากาศ,เกิดจากสภาพแวดล้อมในการทำงาน,การจัดการสถานที่ก่อสร้างที่ไม่เหมาะสม

จากการวิเคราะห์แบบสอบถามผู้เชี่ยวชาญด้วยกระบวนการวิเคราะห์แบบปรับปรุง (Modified AHP) พบว่าผู้เชี่ยวชาญแต่ล่ะท่านมีการให้ค่าน้ำหนักของแต่ปัจจัยให้ความสำคัญของแต่ล่ะปัจจัยไม่ได้ในทิศทางเดียวมักจะแตกต่างกันในส่วนปฏิบัติและส่วนบริหารแต่เมื่อทำการหาค่าเฉลี่ยเรขาคณิต (Geometric Mean) แล้วทำการคำนวณผลปรากฏว่ามีความสอดคล้องของทั้งปัจจัยหลักและปัจจัยรองของงานวิจัย และทำให้ทราบถึง ค่าน้ำหนักความสำคัญของปัจจัยหลักและปัจจัยรองโดยผู้เชี่ยวชาญให้ความสำคัญในปัจจัยหลักในการสร้างแบบจำลองสำหรับการประเมินน้ำหนักของปัจจัยเสี่ยง ที่มีผลต่อความปลอดภัยในงานก่อสร้างได้แก่ปัจจัยด้านผู้ปฏิบัติงาน มีค่าน้ำหนักความสำคัญมากที่สุดคิดเป็นร้อยละ 33.42 รองลงมาคือ ปัจจัยด้านการบริหารจัดการคิดเป็นร้อยละ 23.22 ส่วนปัจจัยด้านสภาพแวดล้อม คิดเป็นร้อยละ 22.71 และปัจจัยด้านเทคนิคคิดเป็นร้อยละ 20.65 แต่เมื่อคิดค่าลำดับปัจจัยเสี่ยงรวมแล้ว

ปัจจัยด้านการขาดความรู้ ความเข้าใจด้านความปลอดภัยมีค่าน้ำหนักความสำคัญมากที่สุดคิดเป็นร้อยละ 13.47 รองลงมาคือ ปัจจัยด้านการขาดความรับผิดชอบในการทำงาน คิดเป็นร้อยละ 10.46 ส่วนปัจจัยด้านขาดระบบการศึกษาด้านความปลอดภัย มีค่าน้ำหนักความสำคัญน้อยที่สุดคิดเป็นร้อยละ2.5

ผลลัพธ์ที่ได้จากการศึกษา พบว่าปัจจัยด้านผู้ปฏิบัติงาน ที่มีค่าน้ำหนักความสำคัญมากที่สุดคิดเป็นร้อยละ 33.42 นั้นแสดงให้เห็นว่าปัจจัยด้านผู้ปฏิบัติงานนั้นมีความสำคัญและเป็นหัวใจหลักของอุตสาหกรรมการก่อสร้าง และในปัจจัยด้านการขาดความรู้ ความเข้าใจด้านความปลอดภัยมีค่าน้ำหนักความสำคัญมากที่สุดคิดเป็นร้อยละ 13.47 ควรมีการส่งเสริมสนับสนุนให้คำแนะนำและคำชี้แจงให้การสนับสนุนเรื่องความรู้ ความเข้าใจด้านความปลอดภัยในงานก่อสร้าง

ส่วนปัจจัยอื่นๆ เช่นปัจจัยด้านการบริหารจัดการ, ปัจจัยด้านสภาพแวดล้อม และปัจจัยด้านเทคนิค ล้วนแล้วมีสำคัญทั้งสิ้นของอุตสาหกรรมการก่อสร้าง การศึกษาและทำงานวิจัยนี้เพื่อป้องกันและลดอุบัติเหตุที่อาจเกิดขึ้นในงานก่อสร้างได้อย่างมีประสิทธิภาพและยังสามารถนำไปใช้ในการวางแผนและป้องกันอันตรายในการดำเนินงานก่อสร้างได้อย่างตรงเป้าหมายและให้เกิดประสิทธิภาพสูงสุด

ตารางที่ 10.สรุปการหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยหลักและปัจจัยรอง

ปัจจัยหลัก	น้ำหนัก ปัจจัยหลัก	ปัจจัยรอง	น้ำหนัก ปัจจัยรอง	ปัจจัยหลัก x ปัจจัยรอง	ลำดับ ความสำคัญ
A:ปัจจัยด้านผู้ปฏิบัติงาน	0.334	A1 : การขาดความรับผิดชอบในการทำงาน	0.310	0.104	2
		A2 : การมีสภาวะทางร่างกายและจิตใจที่ไม่สมบูรณ์	0.120	0.040	11
		A3 : การสื่อสารระหว่างบุคคล	0.167	0.056	8
		A4 : การขาดความรู้ ความเข้าใจด้านความปลอดภัย	0.403	0.135	1
B:ปัจจัยด้านเทคนิค	0.232	B1 : การใช้อุปกรณ์ เครื่องจักรที่ไม่มีประสิทธิภาพ	0.405	0.094	3
		B2 : การใช้งานอุปกรณ์เครื่องจักรอย่างไม่เหมาะสม	0.359	0.083	6
		B3:การออกแบบก่อสร้างและรายการประกอบแบบที่ไม่ชัดเจน	0.237	0.055	9
C:ปัจจัยด้านการบริหารจัดการ	0.227	C1 : การกำหนดนโยบายที่ไม่เหมาะสม	0.138	0.031	14
		C2 : การบริหารจัดการด้านความปลอดภัยที่ไม่เหมาะสม	0.334	0.076	7
		C3 : ขาดระบบการศึกษาด้านความปลอดภัย	0.112	0.025	15
		C4 : เรื่องต้นทุนและการลงทุนด้านความปลอดภัย	0.416	0.094	4
D:ปัจจัยด้านสภาพแวดล้อม	0.206	D1 : เกิดจากภัยพิบัติทางธรรมชาติ	0.405	0.084	5
		D2 : เกิดจากความแปรปรวนของสภาพอากาศ	0.237	0.049	10
		D3 : เกิดจากสภาพแวดล้อมในการทำงาน	0.187	0.039	12
		D4 : การจัดการสถานที่ก่อสร้างที่ไม่เหมาะสม	0.172	0.035	13
ค่าเฉลี่ยเรขาคณิต	1.00			1.000	

4. กิตติกรรมประกาศ

งานวิจัยเรื่อง การประเมินน้ำหนักปัจจัยเสี่ยงที่มีต่อผลความปลอดภัยในงานก่อสร้างด้วยวิธีวิเคราะห์เชิงลำดับชั้นแบบปรับปรุง (Modified Analytical Hierarchy Process : Modified AHP) สามารถดำเนินการได้จากการได้รับความอนุเคราะห์และสนับสนุนเป็นอย่างดียิ่งจาก รองศาสตราจารย์ ดร.ดำรงศักดิ์ รินชุมภู , ผู้ช่วยศาสตราจารย์ ดร.นที สุริยานนท์ และอาจารย์ ดร.สมจินตนา แขนงแก้ว คณาจารย์ภาควิชาการบริหารงานก่อสร้าง คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่ ที่ได้กรุณาให้คำปรึกษา แนะนำแนวทาง ความรู้และขอคิดเห็น ในการปรับปรุงแก้ไขข้อบกพร่องต่าง ๆ จนกระทั่งงานวิจัยนี้สำเร็จเรียบร้อยด้วยดี ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้ด้วย ขอขอบพระคุณ บริษัท อรสิริน โฮลดิ้ง จำกัด (มหาชน) จากการที่ได้ให้ความความอนุเคราะห์ อนุญาตให้เจ้าหน้าที่และพนักงานฝ่ายก่อสร้างได้ให้ข้อมูลและทำแบบสอบถามในการประเมินน้ำหนักปัจจัยเสี่ยงที่มีต่อผลความปลอดภัยในงานก่อสร้างครั้งนี้ ขอขอบ คุณเพื่อน พี่ น้อง ร่วมคณะทุกคนที่อำนวยความสะดวกและให้ความช่วยเหลือในการทำงานวิจัยค้นคว้าอิสระฉบับนี้

5. เอกสารอ้างอิง

[1] Almaskati, D., Kermanshachi, S., Pamidimukkala, A., Loganathan, K., & Yin, Z. (2024). A Review on Construction Safety: Hazards, Mitigation Strategies, and Impacted Sectors.Buildings, 14(2), 526. https://www.mdpi.com/2075-5309/14/2/526

[2] Darko, A., Chan, A. P. C., Ameyaw, E. E., Owusu, E. K.,Pärn, E., & Edwards, D. J. (2019). Review of application ofanalytic hierarchy process (AHP) in construction. https://doi.org/10.1080/15623599.2018.1452098

[3] Durdyev, S., Mohamed, S., Lay, M. L., & Ismail, S. (2017).Key factors affecting construction safety Performance indeveloping countries: Evidence from Cambodia

[4] Khan, A. U., & Ali, Y. (2020). Analytical hierarchy process (AHP) and analytic network process methods and their applications: a twenty year review from 2000-2019: AHP & ANP techniques and their applications: Twenty years review from 2000 to 2019.

[5] Mohammadi, A., Tavakolan, M., & Khosravi, Y. (2018). Factors influencing safety performance on construction https://doi.org/https://doi.org/10.1016/j.ssci.2018.06.017

[6] Muñoz-La Rivera, F., Mora-Serrano, J., & Oñate, E. (2021). Factors Influencing Safety on Construction Projects (fSCPs):Types and Categories.

[7] Pan, H., Huang, H., Luo, Z., Wu, C., & Yang, S. (2024). Research on safety risk factors of metro shield tunnel construction in China based on social network analysis. Engineering, Construction and Architectural Management, ahead-of-print(ahead-of-print). https://doi.org/10.1108/ECAM-05-2024-0685

[8] SCB EIC. (2567). แนวโน้มอุตสาหกรรมก่อสร้างปี 2024 (SCB EIC Industry insight : Construction, Issue.

[9] ขวัญชาติ สายน้อย, เสรีย์ ตู้ประกาย, ปิยะรัตน์ ปรีย์มาโนช, & ชัยวัฒน์ ภู่วรกุลชัย. (2567). แนวทางพัฒนาการจัดการปัจจัยเสี่ยงที่ก่อให้เกิดอุบัติเหตุต่อผู้ปฏิบัติงานในโรงไฟฟ้าก๊าซชีวภาพ. https://he03.tcithaijo.org

[10] ฐิติวัฒน์ ตรีวงศ์. (2564). การระบุปัจจัยความเสี่ยงของการควบคุมงานก่อสร้างในโครงการก่อสร้างอาคารที่พักผู้โดยสาร ท่าอากาศยานขอนแก่น. https://www.conference.thaince.org

[11] ฐิติวัฒน์ ตรีวงศ์, จำรูญ หฤทัยพันธ์, ปภาวี แสงสุข, ธนาคาร ทับทิมเหล้า, &ศรัณย์ ศรีสุพล. (2566). การประเมินปัจจัยเสี่ยงที่ก่อให้เกิดอุบัติเหตุในบริเวณพื้นที่ก่อสร้าง รถไฟฟ้าขนส่งมวลชนแห่งประเทศไทยโดยรูปแบบสภาพการณ์ดัชนี. https://www.conference.thaince.org

[12] ทศพร แสงทอง, ตระกูล จิตวัฒนากร, วิโรชน์ หมื่นเทพ. (2567). กระบวนการการจัดการความเสี่ยงด้านความปลอดภัยในงานโครงการก่อสร้าง.. https://so04.tcithaijo.org

[13] นรุธ ฤทธิมโนมัย. (2549). การศึกษาปัจจัยสำคัญที่มีผลต่อความสำเร็จด้านเวลาในการก่อสร้างโครงการบ้านจัดสรiจุฬาลงกรณ์มหาวิทยาลัย]. http://cuir.car.chula.ac.th

[14] นาถ สุขศีล, วชรภูมิ เบญจโอฬาร. (2558). ปัจจัยที่ส่งผลต่อแบบจำลองสมดุลความปลอดภัยในงานก่อสร้าง.

[15] สถาบันเทคโนโลยีป้องกันประเทศ (องค์การมหาชน). (2012). บทวิเคราะห์: กระบวนการวิเคราะห์ตามลำดับชั้น. Retrieved 25/11/2024, from https://www.dti.or.th

[16] สมาคมส่งเสริมความปลอดภัยและอนามัยในการทำงาน (ประเทศไทย) ความปลอดภัยในงานก่อสร้าง. Retrieved 16/12/2024 from https://www.shawpat.or.th

[17] สำนักงานกองทุนเงินทดแทน สำนักงานประกันสังคม กระทรวงแรงงาน. (2567). สถานการณ์ประสบอันตรายหรือเจ็บป่วยเนื่องจากการทำงานปี 2562-2566.

[18] อาณัติ จันทร์เต็มดวง, สุขสันติ์ หอพิบูลสุข, วิสิษฐ์ กุลอริยทรัพย์, &ชารินี ลิ้มสวัสดิ์. (2565). การวิเคราะห์ความเสี่ยงด้านความปลอดภัยในงานขุดลอกและถมทะเล.. https://www.conference.thaince.org

โครงข่ายประสาทเทียมสำหรับการวิเคราะห์การถดถอยเชิงเส้นตามบริบท

Neural Network Models for Contextual Linear Regression

พสุตม์ รัตนศรีมงคล* เสกสรร เกียรติสุไพบูลย์

ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย

(**6680260026@student.chula.ac.th*)

บทคัดย่อ

ปัญหาการถดถอยเชิงเส้นตามบริบทเป็นปัญหาที่ข้อมูลถูกจัดแบ่งเป็นกลุ่ม โดยแต่ละกลุ่มถูกกำหนดโดยตัวแปรบริบท (Context Features) งานวิจัยนี้มุ่งเน้นการศึกษา โครงข่ายประสาทเทียมเชิงบริบท (Contextual Neural Network: CtxtNN) มาใช้ในการวิเคราะห์ปัญหาดังกล่าว รวมถึงเปรียบเทียบประสิทธิภาพกับ Feedforward Neural Networks (FNN) ทั้งขนาดเล็ก (FNN-Small) และขนาดใหญ่ (FNN-Large) ผ่านการจำลองข้อมูล 3 กรณี ที่มีระดับความซับซ้อนของข้อมูลแตกต่างกัน ประกอบด้วยตัวแปรต้นไม่เกิน 8 ตัว ตัวแปรบริบทไม่เกิน 3 ตัว และบริบทข้อมูลสูงสุด 3 บริบท ตัวแบบได้รับการประเมินโดยใช้ ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error: MSE) และ ค่าสัมประสิทธิ์การตัดสินใจ (R^2) เป็นเกณฑ์วัดประสิทธิภาพ ผลการวิจัยพบว่า CtxtNN มีค่าเฉลี่ย MSE อยู่ที่ 0.026, 0.268 และ 0.642 ตามลำดับในแต่ละกรณีศึกษา ต่ำกว่าหรือใกล้เคียงกับตัวแบบ FNN-Large มีค่าเฉลี่ยอยู่ที่ 0.018, 0.708, 3.616 (กรณี 3.1) และ 2.092 (กรณี 3.2) และต่ำกว่าตัวแบบ FNN-Small มีค่าเฉลี่ยอยู่ที่ 0.037, 1.850 และ 4.028 ในขณะที่ค่าเฉลี่ย R^2 ของ CtxtNN อยู่ที่ 0.978, 0.921 และ 0.894 ซึ่งสูงกว่าหรือใกล้เคียงกับ FNN-Large มีค่าเฉลี่ยอยู่ที่ 0.983, 0.810, 0.420 และ 0.662 และสูงกว่าตัวแบบ FNN-Small (0.968, 0.501 และ 0.352) อย่างชัดเจน ผลลัพธ์แสดงให้เห็นว่า CtxtNN สามารถเรียนรู้ความสัมพันธ์เชิงเส้นในแต่ละบริบทได้อย่างมีประสิทธิภาพและเป็นตัวเลือกที่เหมาะสมสำหรับการวิเคราะห์ปัญหาการถดถอยเชิงเส้นตามบริบท

คำสำคัญ: ตัวแปรบริบท, โครงข่ายประสาทเทียมเชิงบริบท, โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า, การถดถอยเชิงเส้นตามบริบท, การจำลองข้อมูล

Abstract

The contextual linear regression problem involves data structured into groups, each defined by context features. This study focuses on applying the Contextual Neural Network (CtxtNN) to analyze such problems and comparing its performance with Feedforward Neural Networks (FNN), including FNN-Small and FNN-Large, across three simulated cases with varying levels of data complexity. This research focuses on problems with no more than eight explanatory variables, contextual variables less than three, and a maximum of three contexts. Models are evaluated using Mean Squared Error (MSE) and Coefficient of Determination (R^2) to assess their predictive accuracy. The results indicate that CtxtNN achieved average MSE values of 0.026, 0.268, and 0.642 across the three cases, performing comparably or better than FNN-Large, which yielded values of 0.018, 0.708, 3.616 (Case 3.1), and 2.092 (Case 3.2), and significantly outperforming FNN-Small, which recorded values of 0.037, 1.850, and 4.028. Similarly, the average R^2 for CtxtNN were 0.978, 0.921, and 0.894, which were comparable to or higher than those of FNN-Large (0.983, 0.810, 0.420, and 0.662) and significantly higher than FNN-Small (0.968, 0.501, and 0.352). These results suggest that CtxtNN effectively captures contextual linear relationships and serves as a suitable choice for analyzing contextual linear regression problems.

Keywords: Context Feature, Contextual Neural Network, Feedforward Neural Network, Contextual Linear Regression, Data Simulation

1. บทนำ

ข้อมูลที่มีความสัมพันธ์เชิงบริบท หมายถึง การที่มีข้อมูลบางค่าเป็นตัวสร้างเงื่อนไขความสัมพันธ์ระหว่างข้อมูลกับผลเฉลย ตัวอย่างเช่น งานวิจัยจาก [1] พบว่าความแม่นยำในการวัดระดับออกซิเจนในเลือดมีความแตกต่างกันขึ้นอยู่กับสีผิวของผู้ป่วย จากงานวิจัยนี้สามารถระบุได้ว่าสีผิวเป็นตัวแปรบริบท (Contextual Feature) ที่มีผลกระทบต่อความแม่นยำในการวัดระดับออกซิเจน, การวิเคราะห์ความเครียดในเด็กวัยรุ่นจาก [2] ระบุว่าเพศ และอายุของเด็กเป็นตัวแปรบริบทที่มีผลกระทบต่อระดับเครียด นอกจากนี้ยังมีงานวิจัยการวิเคราะห์ความสามารถในการอ่านของนักเรียนประถม ศึกษาจาก [3] พบว่าระดับการศึกษาและรายได้ของผู้ปกครอง เป็นตัวแปรบริบท

การวิเคราะห์การถดถอยเชิงบริบท (Contextual Regression Analysis) เป็นแนวทางในการวิเคราะห์ข้อมูลที่มีบริบทที่แตกต่างกัน ซึ่งในกรณีนี้จะสนใจกรณีที่ข้อมูลมีตัวแปรบริบทเป็นส่วนหนึ่งของตัวแปรอิสระ แต่ไม่สามารถแปลงเป็นตัวแปรบ่งชี้ (Indicator Variables) ให้สามารถระบุตัวตนของทุกบริบทได้อย่างสมบูรณ์

เพื่อแก้ไขปัญหานี้ การวิเคราะห์การถดถอยเชิงเส้นตามบริบท (Contextual Linear Regression) ได้ถูกพัฒนาขึ้น โดยศึกษาจากงานวิจัยของ [7] วิธีนี้สามารถแก้ไขปัญหาเมื่อมีตัวแปรบริบทเป็นตัวกำหนดความสัมพันธ์เชิงเส้นระหว่างตัวแปรอิสระและผลเฉลย ทำให้การวิเคราะห์ข้อมูลมีความแม่นยำมากขึ้นเมื่อผลลัพธ์ถูกกำหนดโดยตัวแปรบริบท

ในปัจจุบัน โครงข่ายประสาทเทียม (Artificial Neural Networks; ANN) ได้รับความนิยมอย่างแพร่หลายในการวิเคราะห์ข้อมูลที่มีความซับซ้อนและมีลักษณะเชิงบริบท เช่น งานวิจัยของ [4] ที่นำโครงข่ายประสาทเทียมมาทำนายภาวะโรคอ้วนโดยใช้ตัวแปรบริบท เช่น อายุ เพศ และส่วนสูง รวมถึงงานวิจัยของ [5] ที่ใช้ Feedforward Neural Networks (FNN) ในการวิเคราะห์ข้อมูลเกี่ยวกับโรคหัวใจ ซึ่งแสดงให้เห็นถึงศักยภาพของโครงข่ายประสาทเทียมในการจัดการกับข้อมูลที่มีลักษณะเชิงบริบท

การนำโครงข่ายประสาทเทียมมาประยุกต์ใช้ในการวิเคราะห์การถดถอยเชิงเส้นตามบริบทจึงเป็นแนวทางหนึ่งที่สามารถรองรับความซับซ้อนของข้อมูลและความสัมพันธ์ที่เปลี่ยนแปลงไปตามบริบทได้อย่างมีประสิทธิภาพ โดยตัวอย่างอย่างสามารถดูได้จาก [6] งานวิจัยนี้จะนำวิธีการแก้ปัญหาข้อมูลที่มีความสัมพันธ์เชิงบริบทกับผลเฉลยโดยใช้โครงข่ายประสาทเทียมชื่อว่า โครงข่ายประสาทเทียมเชิงบริบท (Contextual Neural Network; CtxtNN) นำเสนอโดย [7] โดยใช้การจำลองข้อมูลที่มีตัวแปรบริบทแต่ละชุดข้อมูล และนำผลประสิทธิภาพที่ได้จากตัวแบบนี้มาเทียบกับตัวแบบ Feedforward Neural Network

2. แนวคิดและทฤษฎี

2.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward Neural Networks; FNN)

FNN เป็นหนึ่งในรูปแบบพื้นฐานของโครงข่ายประสาทเทียม (Artificial Neural Networks) ซึ่งมีลักษณะการส่งผ่านข้อมูลในทิศทางเดียว โดยไม่มีการวนซ้ำหรือย้อนกลับ ข้อมูลจะถูกประมวลผลจากชั้นข้อมูลนำเข้า (Input Layer) ผ่านชั้นซ่อน (Hidden Layer) ไปยังชั้นข้อมูลส่งออก (Output Layer) โดยกระบวนการนี้ถูกออกแบบให้มีการประมวลผลทีละขั้นตอนผ่านแต่ละชั้นอย่างเป็นระบบ

ฟังก์ชันกระตุ้น (Activation Functions) มีบทบาทสำคัญในโครงข่ายประสาทเทียม [8] โดยช่วยเพิ่มความซับซ้อนให้ตัวแบบ และกำหนดว่าค่าผลลัพธ์จะถูกส่งไปยังชั้นถัดไปหรือไม่

เพื่อหาค่าถ่วงน้ำหนักที่เหมาะสมในโครงข่ายประสาทเทียม โดย Adam Optimizer เป็นหนึ่งในวิธีการปรับค่าถ่วงน้ำหนัก โดยผสานข้อดีของวิธีอื่น ๆ และได้รับการยอมรับว่าเป็นวิธีที่มีประสิทธิภาพสูงในการฝึกโครงข่ายประสาทเทียม นำเสนอโดย [9]

2.2 โครงข่ายประสาทเทียมเชิงบริบท (Contextual Neural Network; CtxtNN)

งานวิจัยของ [7] ได้นำเสนอตัวแบบโครงข่ายประสาทเทียมเชิงบริบท CtxtNN โดยอธิบายถึงปัญหาของการถดถอยเชิงบริบท (Contextual Regression) โดยกำหนดให้ $X = \mathbb{R}^p, p \geq 2$ เป็นปริภูมิของตัวแปรอิสระ (Feature Space) และ $Y = \mathbb{R}$ เป็นปริภูมิของตัวแปรผลลัพธ์ (Output Space) บริบทถูกกำหนดโดยตัวแปรบริบทที่เป็นองค์ประกอบของปริภูมิบริบท $\tilde{X} = \mathbb{R}^q, 0 < q < p$ ปริภูมิถดถอยจะถูกกำหนดเป็น $\hat{X} = \mathbb{R}^{p-q} = \mathbb{R}^r$ และ $X = \hat{X} \times \tilde{X} = \mathbb{R}^r \times \mathbb{R}^q$ สำหรับเวกเตอร์ตัวแปร $x = \{x_1, \dots, x_p\}^T \in X$ โดยที่เวกเตอร์ของ r ตัวแรกได้แก่ $\hat{x} = \{x_1, \dots, x_r\}^T \in \hat{X}$ และ q ตัวสุดท้ายได้แก่ $\tilde{x} = \{x_{r+1}, \dots, x_p\}^T \in \tilde{X}$ ซึ่ง $\hat{x}$ และ $\tilde{x}$ แทนเวกเตอร์ของตัวแปรอิสระและตัวแปรบริบทตามลำดับ โดยแสดงเป็น

$$x = [\hat{x}, \tilde{x}]^T \quad (1)$$

สมมติว่ามีจำนวนบริบทที่จำกัดซึ่งระบุด้วย $i \in \{1, \dots, c\} = \mathcal{J}$, c คือ จำนวนบริบททั้งหมด โดยปริภูมิบริบท $\tilde{X}$ ถูกแบ่งเป็นบริเวณบริบทที่เรียกว่า $\{C^1, C^2, \dots, C^c\}$ ดังนั้น $x \in X$ จะมีบริบท i หาก $\tilde{x} \in C^i$ สำหรับการถดถอยเชิงบริบท เราสมมติว่ามีฟังก์ชันถดถอยหลายฟังก์ชันที่ทำให้ $f^1, \dots, f^c$ แต่ละ $f^i: \hat{X} \to Y$ ซึ่งกำหนดฟังก์ชันการถดถอย

$$f(x) = f^i(\hat{x}), \text{ เมื่อ } \tilde{x} \in C^i, i \in \mathcal{J} \quad (2)$$

นอกจากนี้ยังสมมติว่ามีฟังก์ชัน $g: \tilde{X} \to \mathbb{R}$ ที่จับคู่แต่ละบริบท C^i ไปยังช่วง $I^i \subseteq \mathbb{R}$, I คือ ช่วงขอบเขตของบริบท ซึ่งรูปแบบของฟังก์ชันถดถอยจะเปลี่ยนเป็น

$$f(x) = f^i(\hat{x}), \text{ เมื่อ } g(\tilde{x}) \in I^i, i \in \mathcal{J} \quad (3)$$

สำหรับโครงข่ายประสาทเทียมจะอธิบายสัญกรณ์โดยกำหนดให้ เวกเตอร์ตัวแปรสำหรับฝึกฝนจำนวน m ตัวอย่าง โดยที่ x เป็นเวกเตอร์ตัวแปร, $y(x)$ เป็นค่าผลลัพธ์ที่ต้องการ สำหรับเวกเตอร์ตัวแปร x, ℓ คือ ชั้นในโครงข่ายประสาท โดย $\ell = 0$ หมายถึง ชั้นข้อมูลนำเข้า, $\ell = L$ หมายถึง ชั้นข้อมูลส่งออก และ $a^\ell(x)$ คือเวกเตอร์ของค่ากระตุ้นสำหรับชั้นที่ ℓ เมื่อข้อมูลนำเข้า x ถูกป้อนเข้าโครงข่ายประสาท หมายความ

ว่า $a^{\ell}(x)$ เป็น ผลลัพธ์ของฟังก์ชันกระตุ้นที่ชั้นที่ ℓ โดยที่ L คือจำนวนชั้นในโครงข่ายประสาทซึ่งไม่รวมชั้นข้อมูลนำเข้า

1. $w_k^{\ell}j$ คือ น้ำหนักของโหนดที่ k ในชั้นที่ $\ell-1$ ซึ่งถูกนำไปใช้กับโหนดที่ j ในชั้นที่ ℓ โดยที่ $k = 1,2,\dots,m_{\ell-1}, j = 1,2,\dots,m_{\ell}$ และ $\ell = 1,\dots,L$
2. b_j^{ℓ} คือ ค่าความเอนเอียง (Bias) ของโหนดที่ j ในชั้นที่ ℓ โดยที่ $j = 1,2,\dots,m_{\ell}$ และ $\ell = 1,\dots,L$
3. a_j^{ℓ} คือ ค่าการกระตุ้นของโหนดที่ j ในชั้นที่ ℓ โดยที่ $j = 1,2,\dots,m_{\ell}$ และ $\ell = 1,\dots,L$

$w_{1,j}^{I}$ คือ น้ำหนักของตัวแปรบริบท ในบริบทที่ j

b_j^{I} คือ ค่าความเอนเอียง (bias term) ที่ใช้ในบริบทนั้น ๆ

2. โครงข่ายย่อยสำหรับการถดถอย (Regression Sub-Network) ใช้เพื่อคำนวณผลลัพธ์จากบริบท a_j^{I3} และตัวแปรอิสระ $\hat{x}$ ผ่านฟังก์ชัน ReLU ดังนี้

$$a_j^1 = a\left(\sum_{k=1}^{r} w_{k,j}^1 x_k + b_1^1 + w_{j,j}^X a_j^{I3}\right), j = 1,2,\dots,2c \quad (8)$$

โดย:a_j^1 คือ ผลลัพธ์ของโครงข่ายย่อยสำหรับการถดถอยที่ผ่านฟังก์ชัน ReLU

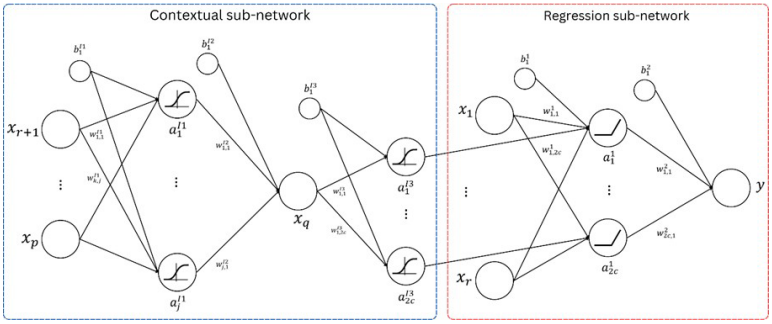

รูปที่ 1: โครงสร้างของโครงข่ายประสาทเทียมเชิงบริบท (CtxtNN)

สำหรับ CtxtNN เป็นตัวแบบการถดถอยเชิงบริบทโดยมีฟังก์ชันการถดถอยทุก f^i เป็นฟังก์ชันเชิงเส้น โดยในกรณีนี้ปริภูมิบริบท $\mathbb{R}$ ถูกแบ่งออกเป็นช่วง $\{I^1,\dots,I^c\}$ โดยที่ $x = \{x_1,\dots,x_p\}^T = [\hat{x},\tilde{x}]^T$ จะถูกกล่าวว่ามีบริบท j หาก $\tilde{x} \in I^j, j = 1,\dots,c$ ซึ่งรูปแบบของฟังก์ชันถดถอยจะเป็น

$$f(x) = \beta_0^j + \beta^j \cdot \hat{x} \text{ เมื่อ } \tilde{x} \in I^j \quad (4)$$

โดยที่ β_0^j เป็นค่าคงที่ของสมการเชิงเส้นที่ใช้กับบริบท j และ β^j เป็นเวกเตอร์สัมประสิทธิ์ของ $\hat{x}$

ตัวแบบ CtxtNN นี้ประกอบด้วยส่วนของโครงข่ายย่อย (Sub-Networks) ที่มีโครงสร้างมาตรฐานที่ทำหน้าที่ต่างกัน โดยมีการใช้ฟังก์ชันเปิดใช้งาน Sigmoid สำหรับโครงข่ายย่อยเชิงบริบท (Contextual Sub-Network) และ ReLU สำหรับโครงข่ายย่อยสำหรับการถดถอย (Regression Sub-Network)

1. โครงข่ายย่อยเชิงบริบท (Contextual Sub-Network) ใช้สำหรับการคำนวณบริบท ซึ่งคำนวณตามสมการดังนี้

$$a_j^{I1} = \tilde{a}\left(\sum_{k=r+1}^{p} w_{k,j}^{I1} x_k + b_1^{I1}\right),\ j = 1,2,3,\dots \quad (5)$$

โดย:a_j^{I1} คือ ค่าการกระตุ้นของโหนดที่ j

$\tilde{a}(z) = \frac{1}{1+e^{-z}}$ คือ ฟังก์ชัน Sigmoid

$w_{k,j}^{I3}$ คือ น้ำหนักของตัวแปรบริบท x_k ในโหนดที่ j

b_1^{I1} คือ ค่าความเอนเอียง (Bias Term)

จากนั้น

$$x_q = a_1^{I2} = \sum_{k=1}^{2c} w_{j,1}^{I2}\, a_j^{I1} + b_1^{I2},\ j = 1,2,3,\dots \quad (6)$$

และ

$$a_j^{I3} = \tilde{a}\left(w_{1,j}^{I3} x_q + b_1^{I3}\right), \quad j = 1,2,\dots,2c \quad (7)$$

โดย:a_j^{I3} คือ ผลลัพธ์ของโครงข่ายย่อยเชิงบริบทที่ผ่านฟังก์ชัน Sigmoid

$\tilde{a}(z) = \frac{1}{1+e^{-z}}$ คือ ฟังก์ชัน Sigmoid

$a(z) = max(0,z)$ คือ ฟังก์ชัน ReLU

$w_{k,j}^1$ คือ น้ำหนักที่ใช้กับตัวแปรอิสระ x_k

$w_{j,j}^X$ คือ ค่าถ่วงน้ำหนักกับโครงข่ายการถดถอย

b_j^1 คือ ค่าความเอนเอียง (Bias Term) โครงข่ายการถดถอย

สำหรับชั้นข้อมูลส่งออก ($\ell = 2$) ตัวแบบจะคำนวณผลลัพธ์ของการถดถอยเชิงบริบท โดยคำนวณจากผลลัพธ์ของโครงข่ายย่อยทั้งหมดดังนี้

$$y = a_1^2 = \sum_{k=1}^{2c} w_{k,1}^2\, a_k^1 + b_1^2 \quad (9)$$

3. วิธีการดำเนินงานวิจัย

3.1 การจำลองข้อมูล

ข้อมูลในงานวิจัยนี้ถูกจำลองโดยใช้ Python เพื่อสร้างชุดข้อมูลที่มีความสัมพันธ์เชิงเส้นตามบริบททั้งหมด 3 กรณี ทั้งนี้ เพื่อให้สามารถเปรียบเทียบประสิทธิภาพของตัวแบบในแต่ละระดับความซับซ้อนของข้อมูล และประเมินความสามารถของตัวแบบในการเรียนรู้และปรับตัวต่อบริบทที่เปลี่ยนแปลง โดยวิธีการจำลองแต่ละกรณีที่แตกต่างกัน ดังนี้

กรณีที่ 1 ตัวแปรบริบท 1 ตัว (Contextual Feature) 3 บริบท (Contexts) 1 ตัวแปรอิสระ (Model Feature)

1. กำหนดขนาดตัวอย่างเท่ากับ 6,000 ตัวอย่าง (บริบทละ 2,000 ตัวอย่าง)
2. กำหนดตัวแปร 2 ตัว ได้แก่ $x = (x_1,x_2)^T$ โดยที่ x_1 เป็นตัวแปรอิสระ และ x_2 เป็นตัวแปรบริบททั้งนี้ $x_1 \overset{iid}{\sim} N(\mu = 0, \sigma^2 = 1)$ และ $x_2 \overset{iid}{\sim} Unif(-1,1)$
3. จำลองข้อมูลที่มีความสัมพันธ์เชิงบริบทแบบเชิงเส้น

$$y = \begin{cases} \beta_0^1 + \beta_1^1 x_1 + \varepsilon_1 & \text{เมื่อ } x_2 \le c_1 \\ \beta_0^2 + \beta_1^2 x_1 + \varepsilon_2 & \text{เมื่อ } c_1 < x_2 \le c_2 \\ \beta_0^3 + \beta_1^3 x_1 + \varepsilon_3 & \text{เมื่อ } x_2 > c_2 \end{cases} \quad (10)$$

กำหนดให้
y เป็นตัวแปรตาม
x_1 เป็นตัวแปรอิสระ
x_2 เป็นตัวแปรบริบท
$\beta_0^1, \beta_1^1, \beta_0^2, \beta_1^2, \beta_0^3, \beta_1^3$ เป็นค่าสัมประสิทธิ์การถดถอยของบริบทที่ 1, บริบทที่ 2 และบริบทที่ 3 ตามลำดับ โดย $\beta_0^1, \beta_1^1, \beta_0^2, \beta_1^2, \beta_0^3, \beta_1^3 \overset{iid}{\sim} N(\mu = 0, \sigma^2 = 1)$
$\varepsilon_1, \varepsilon_2, \varepsilon_3$ เป็นค่าความคลาดเคลื่อน โดยกำหนดให้ $\varepsilon_1, \varepsilon_2, \varepsilon_3 \overset{iid}{\sim} N(\mu = 0, \sigma^2 = 0.01)$
c_1 และ c_2 คือ จุดแบ่งระหว่างปริภูมิบริบท 1, บริบท 2 และบริบท 3 ตามลำดับ หรือก็คือ $I^1 = [-1, c_1]$, $I^2 = (c_1, c_2]$ และ $I^3 = (c_2, 1]$ ซึ่งกำหนดให้ $c_1 = -\frac{1}{3}$ และ $c_2 = \frac{1}{3}$

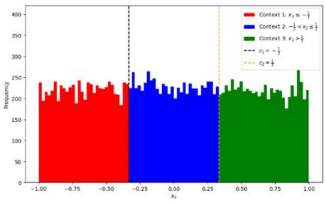

รูปที่ 2: กราฟแสดงการกระจายตัวของตัวแปรบริบท พื้นที่สีแดงแสดงปริภูมิบริบทที่ 1, พื้นที่สีน้ำเงินแสดงปริภูมิบริบทที่ 2 และพื้นที่สีเขียวแสดงปริภูมิบริบทที่ 3

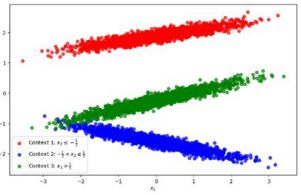

รูปที่ 3: กราฟแสดงความสัมพันธ์ระหว่าง y และ x_1 ในแต่ละบริบท โดยพื้นที่สีแดงแสดงปริภูมิบริบทที่ 1, พื้นที่สีน้ำเงินแสดงปริภูมิบริบทที่ 2 และพื้นที่สีเขียวแสดงปริภูมิบริบทที่ 3

กรณีที่ 2 ตัวแปรบริบท 2 ตัว (Contextual Features) 3 บริบท (Contexts) 3 ตัวแปรอิสระ (Model Features)

1. กำหนดขนาดตัวอย่างเท่ากับ 6,000 ตัวอย่าง (บริบทละ 2,000 ตัวอย่าง)

2. กำหนดตัวแปร 5 ตัว ได้แก่ $x = (x_1, x_2, x_3, x_4, x_5)^T$ โดยที่ $\hat{x} = (x_1, x_2, x_3)^T$ เป็นตัวแปรอิสระ และ $\tilde{x} = (x_4, x_5)^T$ เป็นตัวแปรบริบท ทั้งนี้ $x_1, x_2, x_3 \overset{iid}{\sim} N(\mu = 0, \sigma^2 = 1)$ และ $x_4, x_5 \overset{iid}{\sim} Unif(-1,1)$

3. จำลองข้อมูลที่มีความสัมพันธ์เชิงบริบทแบบเชิงเส้น

$$y = \begin{cases} \beta_0^1 + \beta_1^1 \hat{x} + \varepsilon_1 & \text{เมื่อ } \|\tilde{x}\| \le c_1 \\ \beta_0^2 + \beta_1^2 \hat{x} + \varepsilon_2 & \text{เมื่อ } c_1 < \|\tilde{x}\| \le c_2 \\ \beta_0^3 + \beta_1^3 \hat{x} + \varepsilon_3 & \text{เมื่อ } \|\tilde{x}\| > c_2 \end{cases} \quad (11)$$

กำหนดให้
c_1 และ c_2 คือ จุดแบ่งระหว่างปริภูมิบริบท 1, บริบท 2 และบริบท 3 ตามลำดับ หรือก็คือ $I^1 = \{\tilde{x}: \|\tilde{x}\| \le c_1\}$, $I^2 = \{\tilde{x}: c_1 < \|\tilde{x}\| \le c_2\}$ และ $I^3 = \{\tilde{x}: \|\tilde{x}\| \le c_2\}$ ซึ่งกำหนดให้ $c_1 = 0.652$ และ $c_2 = 0.921$

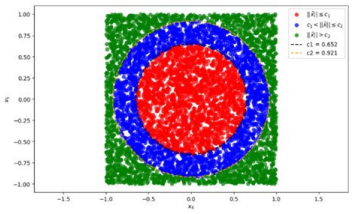

รูปที่ 4: กราฟแสดงการกระจายตัวของตัวแปรบริบท พื้นที่สีแดงแสดงปริภูมิบริบทที่ 1, พื้นที่สีน้ำเงินแสดงปริภูมิบริบทที่ 2 และพื้นที่สีเขียวแสดงปริภูมิบริบทที่ 3

กรณีที่ 3 ตัวแปรบริบท 3 ตัว (Contextual Features) 3 บริบท (Contexts) 5 ตัวแปรอิสระ (Model Features)

1. กำหนดขนาดตัวอย่างเท่ากับ 6,000 ตัวอย่าง (บริบทละ 2,000 ตัวอย่าง)

2. กำหนดตัวแปร 8 ตัวได้แก่
$x = (x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8)^T$ โดยที่
$\hat{x} = (x_1, x_2, x_3, x_4, x_5)^T$ เป็นตัวแปรอิสระ และ
$\tilde{x} = (x_6, x_7, x_8)^T$ เป็นตัวแปรบริบท ทั้งนี้ $x_1, x_2, x_3, x_4, x_5 \overset{iid}{\sim} N(\mu = 0, \sigma^2 = 1)$ และ $x_6, x_7, x_8 \overset{iid}{\sim} Unif(-1,1)$

3. จำลองข้อมูลที่มีความสัมพันธ์เชิงบริบทแบบเชิงเส้น

$$y = \begin{cases} \beta_0^1 + \beta_1^1 \hat{x} + \varepsilon_1 & \text{เมื่อ } \|\tilde{x}\| \le c_1 \\ \beta_0^2 + \beta_1^2 \hat{x} + \varepsilon_2 & \text{เมื่อ } c_1 < \|\tilde{x}\| \le c_2 \\ \beta_0^3 + \beta_1^3 \hat{x} + \varepsilon_3 & \text{เมื่อ } \|\tilde{x}\| > c_2 \end{cases} \quad (12)$$

กำหนดให้
c_1 และ c_2 คือ จุดแบ่งระหว่างปริภูมิบริบท 1, บริบท 2 และบริบท 3 ตามลำดับ หรือก็คือ $I^1 = \{\tilde{x}: \|\tilde{x}\| \le c_1\}$, $I^2 = \{\tilde{x}: c_1 < \|\tilde{x}\| \le c_2\}$ และ $I^3 = \{\tilde{x}: \|\tilde{x}\| \le c_2\}$ ซึ่งกำหนดให้ $c_1 = 0.860$ และ $c_2 = 1.084$

3.2 แนวคิดในการออกแบบแต่ละตัวแบบ

สำหรับแต่ละกรณีศึกษา วิธีและความซับซ้อนในการสร้างตัวแบบจะแตกต่างกันไปตามลักษณะของข้อมูลในแต่ละกรณี โดยมีแนวคิดในการสร้างตัวแบบดังนี้

กรณีที่ 1 ตัวแปรบริบท 1 ตัว (Contextual Feature) 3 บริบท (Contexts) 1 ตัวแปรอิสระ (Model Feature)

1. Contextual Neuron Network (CtxtNN)
ตัวแบบ CtxtNN ประกอบด้วยส่วนโครงข่ายย่อย 2 ส่วน

- โครงข่ายย่อยเชิงบริบท
กรณีนี้มีตัวแปรบริบท 1 ตัว ซึ่งแบ่งออกเป็น 3 บริบท โดยมีความสัมพันธ์แบบบริบทเชิงเส้น นำข้อมูลเชิงบริบทเข้าโดยอ้างอิงจากสมการที่ (7)
- โครงข่ายย่อยสำหรับการถดถอย
ประกอบไปด้วยชั้นซ่อน 1 ชั้น จำนวน 6 โหนด โดยแต่ละโหนดจะรับข้อมูลเข้าจากตัวแปรอิสระ และข้อมูลส่งออกจากโครงข่ายย่อยเชิงบริบทและนำค่าเข้าสู่ฟังก์ชัน ReLU ดังสมการที่ (8) และเข้าสู่ชั้นข้อมูลส่งออก แสดงดังรูปที่ 5(a)

2. Feedforward Neural Network - Small (FNN-Small)

สำหรับตัวแบบ FNN-Small กำหนดโครงข่ายประสาทเทียมให้มีขนาดโครงสร้างเล็กที่สุดโดยให้ค่าพารามิเตอร์เทียบเท่า หรือใกล้เคียงกับตัวแบบ CtxtNN โดยกำหนดฟังก์ชันกระตุ้นที่ใช้คือ ReLU และกำหนดให้

จำนวนชั้นซ่อน = จำนวนชั้นซ่อนในโครงข่ายย่อยเชิงบริบท+จำนวนชั้นส่งออกในโครงข่ายย่อยเชิงบริบท+จำนวนชั้นซ่อนในโครงข่ายย่อยสำหรับการถดถอย ในกรณีนี้จะได้ว่าจำนวนชั้นซ่อนในตัวแบบ FNN จะเท่ากับ 0+1+1 = 2 ชั้น กำหนดให้ชั้นส่งออกในโครงข่ายย่อยเชิงบริบทเปรียบเสมือนชั้นซ่อนอีกหนึ่งชั้นในตัวแบบ FNN แสดงดังรูปที่ 5(b)

3. Feedforward Neural Network - Large (FNN-Large)

สำหรับตัวแบบ FNN-Large กำหนดโครงข่ายประสาทเทียมให้มีโครงสร้างใหญ่ที่สุดโดยอ้างอิงจากจำนวนชั้นซ่อนและโหนดของตัวแบบ CtxtNN โดยกำหนดฟังก์ชันกระตุ้นที่ใช้คือ ReLU และกำหนดให้

จำนวนชั้นซ่อน = จำนวนชั้นซ่อนในโครงข่ายย่อยเชิงบริบท+จำนวนชั้นส่งออกในโครงข่ายย่อยเชิงบริบท+จำนวนชั้นซ่อนในโครงข่ายย่อยสำหรับการถดถอย กรณีนี้จะได้ว่าชั้นซ่อนในตัวแบบ FNN-Large จะเท่ากับ 0+1+1 = 2 ชั้น

จำนวนโหนด = จำนวนโหนดที่มากที่สุดในชั้นซ่อนของโครงข่ายย่อยเชิงบริบท+จำนวนโหนดในชั้นซ่อนของโครงข่ายย่อยสำหรับการถดถอย กำหนดให้จำนวนโหนดเท่ากันในทุกๆชั้นซ่อน กรณีนี้จะได้ว่า จำนวนโหนดในแต่ละชั้นซ่อนเท่ากับ 0+6 = 6 โหนด แสดงดังรูปที่ 5(c)

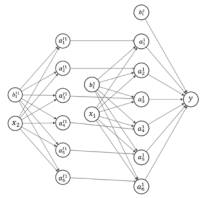

5(a) CtxtNN

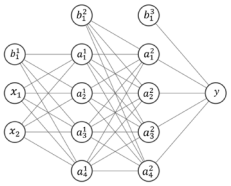

5(b) FNN-Small

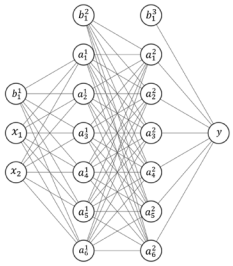

5(c) FNN-Large

รูปที่ 5: โครงสร้างโครงข่ายประสาทเทียมของตัวแบบ 3 แบบสำหรับกรณีที่ 1

กรณีที่ 2 ตัวแปรบริบท 2 ตัว (Contextual Features) 3 บริบท (Contexts) 3 ตัวแปรอิสระ (Model Features)

1. Contextual Neuron Network (CtxtNN)

เนื่องจากมีตัวแปรบริบท 2 ตัว และเป็นกรณีที่ตัวแปรบริบทมีความสัมพันธ์แบบไม่เชิงเส้น จากตัวอย่างของ [10] จึงต้องมีการเพิ่มความซับซ้อนให้กับตัวแบบโดยในกรณีนี้จะเพิ่มโครงสร้างที่ประกอบไปด้วยชั้นซ่อน 2 ชั้น ซึ่งประกอบด้วย 6 และ 2 โหนดตามลำดับ ให้แก่ตัวแปรบริบทก่อน ในโครงข่ายย่อยเชิงบริบท แสดงดังรูปที่ 6(a)

2. Feedforward Neuron Network (FNN-Small)

กำหนดให้มีจำนวนชั้นซ่อนเท่ากับ 2+1+1 = 4 ชั้น แต่ละชั้นประกอบไปด้วยโหนดจำนวน 4 โหนด ซึ่งมีพารามิเตอร์รวมเท่ากับ 89 แสดงดังรูปที่ 6(b)

3. Feedforward Neuron Network (FNN-Large)

ตัวแบบ FNN ในกรณีนี้จะประกอบด้วยชั้นซ่อน 4 ชั้น ที่ประกอบไปด้วยชั้นละ 6+6 = 12 โหนด แสดงดังรูปที่ 6(c)

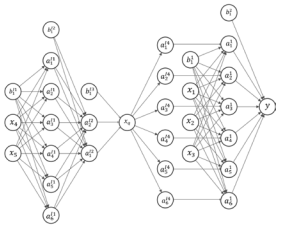

6(a) CtxtNN

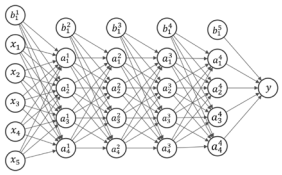

6(b) FNN-Small

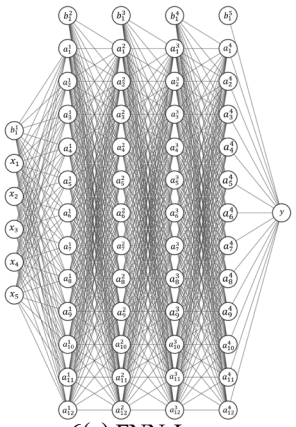

6(c) FNN-Large

รูปที่ 6: โครงสร้างโครงข่ายประสาทเทียมของตัวแบบ 3 แบบสำหรับกรณี 2

กรณีที่ 3 ตัวแปรบริบท 3 ตัว (Contextual Features) 3 บริบท (Contexts) 5 ตัวแปรอิสระ (Model Features)

1. Contextual Neuron Network (CtxtNN)

เนื่องจากมีตัวแปรบริบท 3 ตัว และเป็นกรณีที่ตัวแปรบริบทมีความสัมพันธ์แบบไม่เชิงเส้น จึงต้องเพิ่มความซับซ้อนให้กับตัวแบบโดยในกรณีนี้จะเพิ่มโครงสร้างที่ประกอบไปด้วยชั้นซ่อน 2 ชั้น ซึ่งประกอบด้วย 8 และ 2 โหนดตามลำดับ สำหรับชั้นของข้อมูลส่งออกจากโครงข่ายย่อยเชิงบริบทจะประกอบไปด้วย 6 โหนด เพื่อส่งค่าเข้าสู่โครงข่ายย่อยสำหรับการถดถอยต่อไป แสดงดังรูปที่ 7(a)

2. Feedforward Neuron Network (FNN-Small)

กำหนดให้มีจำนวนชั้นซ่อนเท่ากับ 2+1+1 = 4 ชั้น แต่ละชั้นประกอบด้วยโหนดจำนวน 5 โหนด ซึ่งมีพารามิเตอร์รวมเท่ากับ 141 หมายถึง จำนวนค่าที่ต้องถูกเรียนรู้ในระหว่างการฝึกตัวแบบ ประกอบด้วย ค่าถ่วงน้ำหนัก (Weights) และ ค่าความเอนเอียง (Biases) ของโหนดทั้งหมด แสดงดังรูปที่ 7(b)

3. Feedforward Neuron Network (FNN-Large)

ตัวแบบ FNN ในกรณีนี้จึงประกอบไปด้วยชั้นซ่อน 4 ชั้น ที่ประกอบไปด้วยชั้นละ 8+6 = 14 โหนด แสดงดังรูปที่ 7(c)

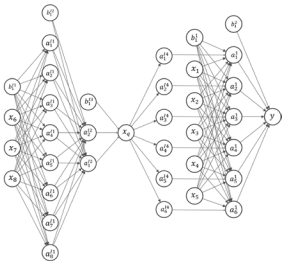

7(a) CtxtNN

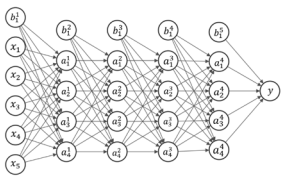

7(b) FNN-Small

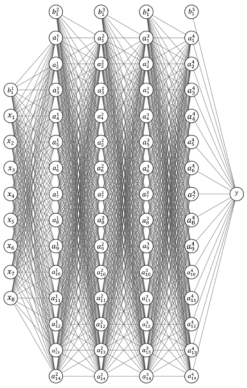

7(c) FNN-Large

รูปที่ 7: โครงสร้างโครงข่ายประสาทเทียมของตัวแบบ 3 แบบ สำหรับกรณีที่ 3

3.3 เงื่อนไขทำการศึกษา

1) แบ่งข้อมูลออกเป็นข้อมูลฝึกสอน (Training Data) 50% และข้อมูลทดสอบ (Testing Data) 50%
2) อัตราการเรียนรู้ (Learning Rate) = 0.001
3) วิธีการปรับค่า (Optimizer) = Adam optimizer
4) จำนวนรอบ (Epoch) = 20,000 รอบ
5) ทดลองแต่ละกรณีจำนวนกรณีละ 30 รอบ
6) ทดลองซ้ำจำนวน 30 รอบต่อ 1 ตัวแบบ ต่อ 1 กรณี
7) แต่ละตัวแบบจะทำการคำนวณผลลัพธ์ทำนายจากข้อมูลทดสอบ และคำนวณประสิทธิภาพเทียบกับผลลัพธ์จริงด้วยเกณฑ์วัดดังนี้

• ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error; MSE)

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \qquad (13)$$

เมื่อ

y_i แทน ผลลัพธ์จริง

$\hat{y}_i$ แทน ผลลัพธ์ทำนาย

• ค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination; R^2)

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \qquad (14)$$

เมื่อ

y_i เป็นผลลัพธ์จริง

$\hat{y}_i$ เป็นผลลัพธ์ทำนาย

$\bar{y}$ เป็นค่าเฉลี่ยของผลลัพธ์จริงทั้งหมด

4. ผลการวิจัย

ในบทนี้นำเสนอผลการทดลองของตัวแบบโครงข่ายประสาทเทียมสำหรับการวิเคราะห์การถดถอยเชิงเส้นตามบริบท (Contextual Linear Regression) โดยแต่ละกรณีศึกษาจะพิจารณาผลการเปรียบเทียบประสิทธิภาพระหว่างตัวแบบ CtxtNN, ตัวแบบ FNN-Small และตัวแบบ FNN-Large

กรณีที่ 1 ตัวแปรบริบท 1 ตัว (Contextual Feature) 3 บริบท (Contexts) 1 ตัวแปรอิสระ (Model Feature)

ตารางที่ 1: ตารางแสดงผลลัพธ์ของประสิทธิภาพที่วัดจากการนำข้อมูลทดสอบมาวิเคราะห์ด้วยตัวแบบ กรณีที่ 1

ตัวแบบ	CtxtNN	FNN-Small	FNN-Large
จำนวนพารามิเตอร์รวม	37	37	67
ค่าเฉลี่ยของค่า MSE	0.026	0.037	0.018
ค่าเฉลี่ยต่ำสุดของ MSE	0.011	0.012	0.010
ค่าเฉลี่ยของ R^2	0.978	0.968	0.983
ค่าสูงสุดของ R^2	0.994	0.994	0.996

จำนวนพารามิเตอร์รวม หมายถึงจำนวนค่าถ่วงน้ำหนัก (weights) และค่าความเอนเอียง (biases) ที่ใช้ในการคำนวณของแต่ละตัวแบบ

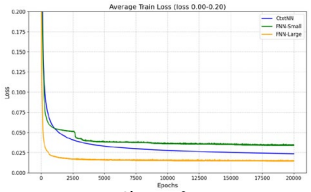

8(a) ข้อมูลฝึกสอน

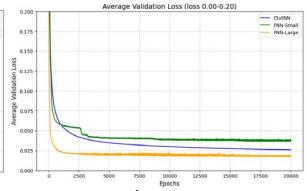

8(b) ข้อมูลทดสอบ

รูปที่ 8: กราฟแสดงการเปรียบเทียบค่าเฉลี่ย MSE (Loss) ในแต่ละ Epoch สำหรับแต่ละตัวแบบ กรณีที่ 1 โดยกราฟสีน้ำเงินแทน CtxtNN, กราฟสีเขียว แทน FNN-Small และกราฟสีเหลือง แทน FNN-Large

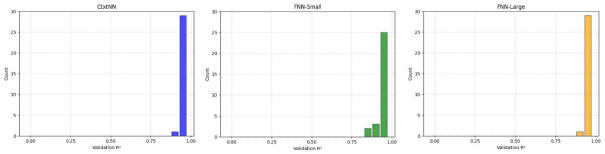

9(a) การแจกแจงของสัมประสิทธิ์การตัดสินใจ

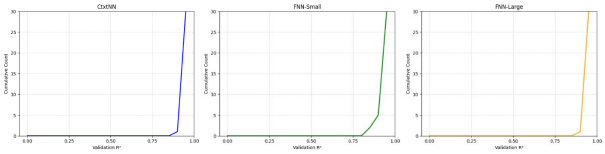

9(b) การแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจ

รูปที่ 9: กราฟแสดงการแจกแจง และการแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจของแต่ละตัวแบบ กรณีที่ 1 โดยกราฟสีน้ำเงินแทน CtxtNN, กราฟสีเขียว แทน FNN-Small และ กราฟสีเหลือง แทน FNN-Large

จากผลลัพธ์ที่ได้ในกรณีที่ 1 พบว่าตัวแบบที่ให้ผลลัพธ์ค่าเฉลี่ย, ค่าเฉลี่ยต่ำสุดของค่า *MSE* และค่าเฉลี่ย R^2 ดีที่สุด คือ FNN-Large, CtxtNN และ FNN-Small ตามลำดับ โดยที่ CtxtNN ใช้จำนวนพารามิเตอร์น้อยที่สุด เท่ากับ FNN-Small และเมื่อพิจารณาจากกราฟแสดงการเปรียบเทียบค่าเฉลี่ย *MSE* (Loss) ของข้อมูลฝึกสอน และข้อมูลทดสอบ พบว่า CtxtNN มีแนวโน้มที่จะให้ค่า Loss ลดลงเรื่อยๆ เมื่อ Epoch สูงขึ้น ในขณะที่ FNN-Large และ FNN-Small มีแนวโน้มคงที่

กรณีที่ 2 ตัวแปรบริบท 2 ตัว (Contextual Features) 3 บริบท (Contexts) 3 ตัวแปรอิสระ (Model Features)

ตารางที่ 2: ตารางแสดงผลลัพธ์ของประสิทธิภาพที่วัดจากการนำข้อมูลทดสอบมาวิเคราะห์ด้วยตัวแบบ กรณีที่ 2

ตัวแบบ	CtxtNN	FNN-Small	FNN-Large
จำนวนพารามิเตอร์รวม	78	89	553
ค่าเฉลี่ยของค่า *MSE*	0.268	1.850	0.708
ค่าเฉลี่ยต่ำสุดของ *MSE*	0.040	0.171	0.093
ค่าเฉลี่ยของ R^2	0.921	0.501	0.810
ค่าสูงสุดของ R^2	0.987	0.939	0.965

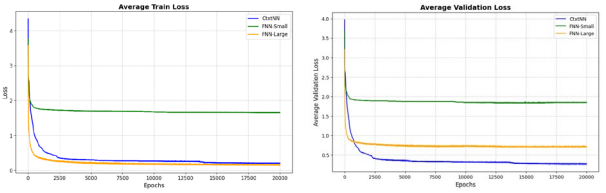

10(a) ข้อมูลฝึกสอน 10(b) ข้อมูลทดสอบ

รูปที่ 10: กราฟแสดงการเปรียบเทียบค่าเฉลี่ย *MSE* (Loss) ในแต่ละ Epoch สำหรับแต่ละตัวแบบ กรณีที่ 2

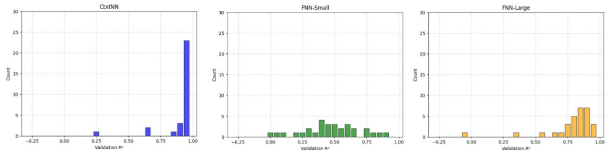

11(a) การแจกแจงของสัมประสิทธิ์การตัดสินใจ

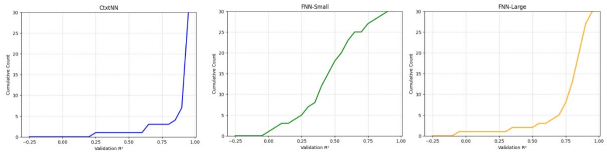

11(b) การแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจ

รูปที่ 11: กราฟแสดงการแจกแจง และการแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจของแต่ละตัวแบบ กรณีที่ 2

จากผลการทดลองในกรณีที่ 2 พบว่า ตัวแบบ FNN-Large มีค่าเฉลี่ย *MSE* ต่ำที่สุดเมื่อพิจารณาจากข้อมูลฝึกสอน อย่างไรก็ตาม เมื่อวิเคราะห์ค่าเฉลี่ย *MSE* ของข้อมูลทดสอบ และการแจกแจงของค่า R^2 พบว่า CtxtNN ให้ผลลัพธ์ที่ดีกว่า โดยมีค่า R^2 กระจุกตัวอยู่ใกล้ค่า 1 ซึ่งสะท้อนถึงความแม่นยำและประสิทธิภาพของตัวแบบที่ดีกว่าตัวแบบอื่นในการพยากรณ์ข้อมูลทดสอบ

กรณีที่ 3 ตัวแปรบริบท 3 ตัว (Contextual Features) 3 บริบท (Contexts) 5 ตัวแปรอิสระ (Model Features)

เนื่องจากในกรณีนี้ข้อมูลมีความซับซ้อนเพิ่มขึ้น FNN-Large มีจำนวนพารามิเตอร์ค่อนข้างสูง จึงอาจทำให้เกิด Overfitting กับข้อมูลฝึกสอนบางกรณี การทดลองจึงถูกแบ่งออกเป็นสองส่วน ได้แก่ กรณีที่ 3.1 การทดลองแบบปกติ ซึ่งใช้โครงสร้างของตัวแบบตามเดิม และกรณีที่ 3.2 การทดลองหลังการปรับแต่ง ที่เพิ่ม Dropout ในชั้นซ่อนของ FNN-Large

กรณีที่ 3.1 การทดลองแบบปกติ (Standard Models)

ตารางที่ 3: ตารางแสดงผลลัพธ์ของประสิทธิภาพที่วัดจากการนำข้อมูลทดสอบมาวิเคราะห์ด้วยตัวแบบกรณีที่ 3.1

ตัวแบบ	CtxtNN	FNN-Small	FNN-Large
จำนวนพารามิเตอร์รวม	108	141	771
ค่าเฉลี่ยของค่า *MSE*	0.642	4.028	3.616
ค่าเฉลี่ยต่ำสุดของ *MSE*	0.119	1.459	0.663
ค่าเฉลี่ยของ R^2	0.894	0.352	0.420
ค่าสูงสุดของ R^2	0.982	0.704	0.860

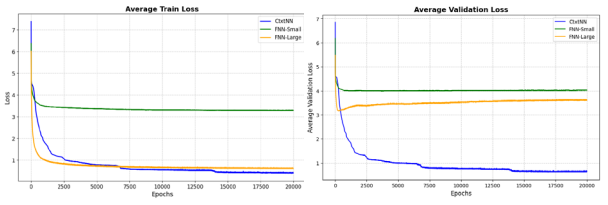

12(a) ข้อมูลฝึกสอน 12(b) ข้อมูลทดสอบ

รูปที่ 12: กราฟแสดงการเปรียบเทียบค่าเฉลี่ย *MSE* (Loss) ในแต่ละ Epoch สำหรับแต่ละตัวแบบ กรณีที่ 3.1

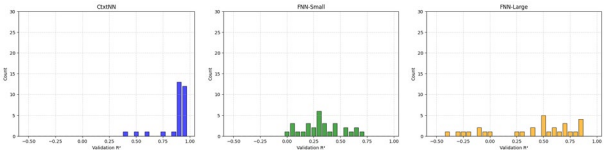

13(a) การแจกแจงของสัมประสิทธิ์การตัดสินใจ

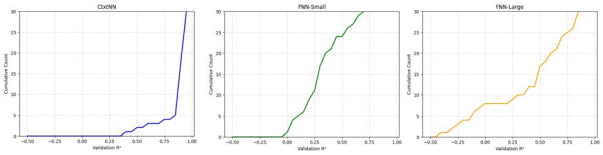

13(b) การแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจ

รูปที่ 13: กราฟแสดงการแจกแจง และการแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจของแต่ละตัวแบบ กรณีที่ 3.1

จากผลลัพธ์ที่ได้จากการทดลองในกรณีที่ 3.1 โดยใช้ตัวแบบปกติพบว่าหากพิจารณาจากกราฟแสดงค่าเฉลี่ย *MSE* ของข้อมูลฝึกสอน ตัวแบบ FNN-Large มีประสิทธิภาพดีกว่า

ใน Epoch เริ่มต้น แต่ที่ Epoch สุดท้ายจะพบว่าตัวแบบ CtxtNN ให้ประสิทธิภาพที่ดีกว่า และหากพิจารณาจากกราฟแสดงค่าเฉลี่ย MSE ของข้อมูลทดสอบ และค่าเฉลี่ยของ R^2 จะพบว่าตัวแบบ CtxtNN ให้ประสิทธิภาพดีที่สุด ในขณะที่ตัวแบบ FNN-Large เกิดการแก้ไขปัญหาเกินพอดี (Overfitting) และสำหรับ FNN-Small มีประสิทธิภาพต่ำที่สุด

กรณีที่ 3.2 การทดลองหลังการปรับแต่ง (Tuned Model with Dropout for FNN-Large)

การทดลองโดยการปรับแต่งตัวเฉพาะตัวแบบ FNN-Large โดยเพิ่ม Dropout 0.20 ในชั้นซ่อนที่ 2, 3 และ 4

ตารางที่ 4: ตารางแสดงผลลัพธ์ของประสิทธิภาพที่วัดจากการนำข้อมูลทดสอบมาวิเคราะห์ด้วยตัวแบบกรณีที่ 3.2

ตัวแบบ	CtxtNN	FNN-Small	FNN-Large
จำนวนพารามิเตอร์รวม	108	141	771
ค่าเฉลี่ยของค่า MSE	0.642	4.028	2.092
ค่าเฉลี่ยต่ำสุดของ MSE	0.119	1.459	0.993
ค่าเฉลี่ยของ R^2	0.894	0.352	0.662
ค่าสูงสุดของ R^2	0.982	0.704	0.817

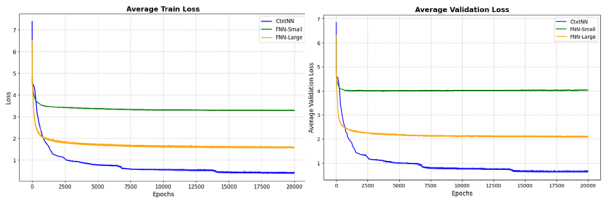

14(a) ข้อมูลฝึกสอน 14(b) ข้อมูลทดสอบ

รูปที่ 14: กราฟแสดงการเปรียบเทียบค่าเฉลี่ย MSE (Loss) ในแต่ละ Epoch สำหรับแต่ละตัวแบบ กรณีที่ 3.2

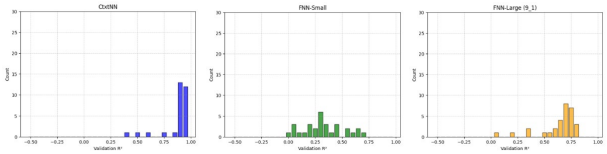

15(a) การแจกแจงของสัมประสิทธิ์การตัดสินใจ

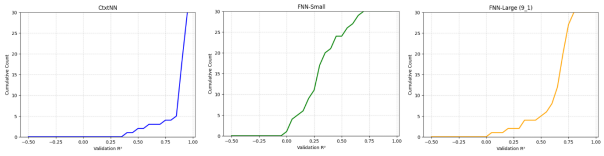

15(b) การแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจ

รูปที่ 15: กราฟแสดงการแจกแจง และการแจกแจงสะสมของสัมประสิทธิ์การตัดสินใจของแต่ละตัวแบบ กรณีที่ 3.2

จากผลลัพธ์ที่ได้จากการทดลองในกรณีที่ 3.2 โดยมีการปรับแต่งตัวแบบ FNN-Large ซึ่งพบว่าสามารถแก้ไขปัญหา Overfitting ได้ แต่เมื่อพิจารณาค่าประสิทธิภาพจาก ค่าเฉลี่ยของค่า MSE, ค่าเฉลี่ยต่ำสุดของ MSE และค่าเฉลี่ยของ R^2 พบว่า CtxtNN ให้ค่าประสิทธิภาพที่ดีกว่า FNN-Large และ FNN-Small ให้ประสิทธิภาพแย่ที่สุด

5. สรุปผลการวิจัย

จากผลการทดลอง เมื่อพิจารณาจากค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) และค่าสัมประสิทธิ์การตัดสินใจ (R^2)ในกรณีที่ 1 ซึ่งข้อมูลมีความซับซ้อนต่ำ ตัวแบบ FNN-Large ให้ผลลัพธ์ที่ดีที่สุดโดยมีค่า MSE ต่ำสุดและค่า R^2 สูงสุด อย่างไรก็ตาม ความแตกต่างระหว่าง FNN-Large และ CtxtNN ไม่ได้มีนัยสำคัญ โดยเฉพาะเมื่อพิจารณาถึงจำนวนพารามิเตอร์ที่ใช้ ซึ่ง CtxtNN ใช้พารามิเตอร์น้อยกว่า ในกรณีที่ 2 ซึ่งข้อมูลมีความซับซ้อนเพิ่มขึ้น ตัวแบบ CtxtNN สามารถเรียนรู้บริบทที่ซับซ้อนขึ้นได้ดีกว่า FNN-Large โดยมีค่า MSE ต่ำกว่าและ R^2 สูงกว่า ในกรณีที่ 3 แม้ว่าจะมีการปรับแต่ง FNN-Large เพื่อลดปัญหา Overfitting แต่ CtxtNN ยังคงให้ผลลัพธ์ที่ดีกว่าด้วยค่า MSE ที่ต่ำกว่าและค่า R^2 ที่สูงกว่า แสดงถึงศักยภาพของตัวแบบที่ออกแบบมาให้คำนึงถึงบริบทของข้อมูล ซึ่งสอดคล้องกับแนวคิดของงานวิจัย [6-7, 10] ที่ระบุว่าการใช้ตัวแปรบริบทช่วยให้ตัวแบบสามารถจำแนกความแตกต่างของความสัมพันธ์ในแต่ละบริบทได้อย่างแม่นยำ สำหรับ FNN-Small แม้จำนวนพารามิเตอร์ใกล้เคียงกับ CtxtNN แต่ค่าประสิทธิภาพที่ได้จากเกณฑ์ MSE และ R^2 ต่ำกว่าตัวแบบอื่นในทุกกรณี สะท้อนถึงข้อจำกัดในการเรียนรู้ความสัมพันธ์ที่ซับซ้อนในบริบทที่แตกต่างกัน

6. เอกสารอ้างอิง

[1] Sjoding MW, Dickson RP, Iwashyna TJ, Gay SE, Valley TS. Racial bias in pulse oximetry measurement. N Engl J Med. 2020;383(25):2477-8.

[2] Rudolph KD, Hammen C. Age and gender as determinants of stress exposure, generation, and reactions in youngsters: A transactional perspective. Child Dev. 1999;70(3):660-77.

[3] Hu J, Dong X, Peng Y. Discovery of the key contextual factors relevant to the reading performance of elementary school students from 61 countries/regions: insight from a machine learning-based approach. Read Writ. 2021;35(1):93-127.

[4] Xue Q, Huynh DQ, Reynolds M. Recurrent neural networks-based obesity status prediction using activity data. arXiv [Preprint]. 2018. Available from: https://arxiv.org

[5] Rani KU. Analysis of heart diseases dataset using neural network approach. Int J Data Min Knowl Manag Process. 2011;1(5):1-13.

[6] Liu C, Wang W. Contextual regression: an accurate and conveniently interpretable nonlinear model for mining discovery from scientific data. arXiv [Preprint]. 2017. Available from: https://arxiv.org/abs/1710.10728

[7] Kiatsupaibul S, Chansiripas P. Neural network modelsfor contextual regression [Unpublished work]. 2024.

[8] Dubey SR, Singh SK, Chaudhuri BB. Activation functions in deep learning: a comprehensive survey and benchmark. arXiv [Preprint]. 2022. Available from: https://arxiv.org/abs/2109.14545

[9] Kingma DP, Ba J. Adam: A method for stochastic optimization. arXiv [Preprint]. 2014. Available from: https://arxiv.org/abs/1412.6980

[10] ชยานนท์ ขัตติยาภิรักษ์. โครงข่ายประสาทเทียมสำหรับการวิเคราะห์การถดถอยเชิงเส้นตามบริบทนัยทั่วไป. [วิทยานิพนธ์ วิทยาศาสตรมหาบัณฑิต]. กรุงเทพฯ: จุฬาลงกรณ์มหาวิทยาลัย; 2564.

การจัดลำดับความสำคัญของปัจจัยกำหนดการคัดเลือกผู้ออกแบบตกแต่งภายในสำหรับบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่าน โดยใช้กระบวนการวิเคราะห์เชิงลำดับชั้น

Prioritising Factors Determining Interior Designer Selection for Two-Storey Residential Houses in Nan Province using the Analytic Hierarchy Process

วราพร ขัดคำวงศ์* เกรียงไกร อรุโณทยานันท์

สาขาวิชาวิศวกรรมและการบริหารการก่อสร้าง

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเชียงใหม่

(* *Waraporn_kha@cmu.ac.th*)

บทคัดย่อ

การศึกษานี้มุ่งเน้นการประยุกต์ใช้กระบวนการวิเคราะห์เชิงลำดับชั้น (Analytic Hierarchy Process: AHP) เพื่อคัดเลือกผู้ออกแบบตกแต่งภายในสำหรับบ้านพักอาศัยสองชั้นในจังหวัดน่าน อันเป็นพื้นที่ที่มีอัตราการเติบโตด้านเศรษฐกิจและอสังหาริมทรัพย์อย่างต่อเนื่อง โดยการวิจัยประกอบด้วยการทบทวนวรรณกรรมที่เกี่ยวข้องและการสัมภาษณ์ผู้เชี่ยวชาญด้านการออกแบบและก่อสร้าง จำนวน 5 ปัจจัยหลัก (26ปัจจัยย่อย) พบว่าปัจจัยหลักที่มีผลต่อการตัดสินใจ ได้แก่ (1) คุณสมบัติของผู้ออกแบบ เช่น ความคิดสร้างสรรค์และความรับผิดชอบ (2) ผลงานของผู้ออกแบบ เช่น ประสบการณ์และคุณภาพของงาน (3) งบประมาณ เช่น ค่าตอบแทนและค่าใช้จ่ายที่สอดคล้องกับงบที่ตั้งไว้ (4) การให้บริการ เช่น การให้คำแนะนำที่เป็นประโยชน์และการตระหนักถึงสิ่งแวดล้อม และ (5) ปัจจัยด้านการออกแบบตกแต่งภายใน เช่น การเลือกใช้วัสดุที่เหมาะสมและความสะดวกสบายในการใช้งานการใช้ AHP ในการวิเคราะห์ช่วยให้สามารถจัดลำดับความสำคัญของปัจจัยต่าง ๆ ที่เกี่ยวข้องกับการคัดเลือกผู้ออกแบบตกแต่งภายในได้อย่างเป็นระบบและมีประสิทธิภาพ ซึ่งช่วยให้เจ้าของโครงการและผู้พัฒนาอสังหาริมทรัพย์สามารถตัดสินใจเลือกผู้ออกแบบที่เหมาะสมกับความต้องการของตลาดและผู้อยู่อาศัยได้ดียิ่งขึ้น นอกจากนี้ ยังช่วยลดความเสี่ยงที่อาจเกิดขึ้นจากการคัดเลือกบุคลากรที่ไม่เหมาะสม และช่วยให้การพัฒนาที่อยู่อาศัยในจังหวัดน่านมีความสอดคล้องกับแนวโน้มของตลาดและแนวคิดด้านความยั่งยืนทางสถาปัตยกรรมและการออกแบบภายใน

คำสำคัญ: การคัดเลือกผู้ออกแบบตกแต่งภายใน, อาคารบ้านพักอาศัยสองชั้น, จังหวัดน่าน, กระบวนการวิเคราะห์เชิงลำดับชั้น

Abstract

This study focuses on the application of the Analytic Hierarchy Process (AHP) to select interior designers for two-story houses in Nan Province, an area with continuous economic and real estate growth. The research consists of a review of relevant literature and interviews with design and construction experts on 5 main criteria (26 sub-criteria) to identify factors affecting the selection of interior designers. The results of the study found that the main factors affecting the decision were (1) designer qualifications, such as creativity and responsibility, (2) designer's work, such as experience and quality of work, (3) budget, such as compensation and expenses that are in line with the budget, (4) service provision, such as providing useful advice and environmental awareness, and (5) interior design factors, such as appropriate material selection and ease of use. The use of AHP in the analysis allows for systematic and efficient prioritization of various factors related to interior designer selection, which helps project owners and real estate developers make decisions to select designers that are most suitable for the market and occupants' needs. It also reduces the risks that may arise from selecting inappropriate personnel, promotes efficient

resource management, and helps housing development in Nan Province to be consistent with market trends and sustainable architectural and interior design concepts.

Keywords: Selection of interior designer, Two-storey residential building, Nan Province, Hierarchical analysis process

1. บทนำ

จังหวัดน่านในสถานการณ์ปัจจุบันมีอัตราการเจริญเติบโตในเชิงเศรษฐกิจและการพัฒนาที่อยู่อาศัยอย่างต่อเนื่อง ประกอบกับลักษณะของพื้นฐานทางสังคมที่มีเอกลักษณ์โดดเด่นทางด้านวัฒนธรรมผสานกับอัตราการเพิ่มขึ้นของประชากรและการลงทุนด้านอสังหาริมทรัพย์โดยเฉพาะอย่างยิ่งในปีพ.ศ.2567 เศรษฐกิจภายในจังหวัดน่านมีแนวโน้มพัฒนาอย่างต่อเนื่องมีการลงทุนในหลากหลายมิติเพิ่มขึ้นอย่างเห็นได้ชัดและเป้าหมายที่สำคัญ ในส่วนของธุรกิจก่อสร้างพบแนวโน้มการขยายตัวเพิ่มเช่นกันโดยรูปแบบอสังหาริมทรัพย์ที่ได้รับความนิยมคือการก่อสร้างบ้านพักอาศัย2ชั้นในเขตพื้นที่เมือง เนื่องจากตอบสนองความต้องการด้านพื้นที่ใช้สอยที่มากกว่าเมื่อเทียบกับบ้านชั้นเดียวในขนาดที่ดินเท่ากัน นอกจากนี้การออกแบบทางด้านสถาปัตยกรรมและมัณฑนศิลป์ถือเป็นปัจจัยที่ช่วยตอบสนองต่อความต้องการที่หลากหลายบนพื้นฐานการเพิ่มความสะดวกสบายต่อผู้อยู่อาศัย ในยุคปัจจุบัน การออกแบบตกแต่งภายในเป็นสิ่งที่ผู้อยู่อาศัยให้ความสำคัญเป็นอันดับแรก ทั้งในกลุ่มลูกค้าภาคธุรกิจและบุคคลทั่วไปการออกแบบตกแต่งภายในนั้นนอกเหนือจากการมุ่งเน้นความสุนทรีย์ความสวยงามและใช้งานได้จริง ปัจจัยที่ต้องพิจารณาร่วมด้วยคือความสอดคล้องทางด้านงบประมาณ คุณภาพ และระยะเวลาในการดำเนินการ ที่ส่งผลโดยตรงต่อความพึงพอใจของผู้อาศัยและความสำเร็จของโครงการก่อสร้าง

อย่างไรก็ตาม ความต้องการการออกแบบตกแต่งภายในที่ถูกต้องเหมาะสมตอบโจทย์ความต้องการของผู้อยู่อาศัย ส่งผลโดยตรงต่อการคัดเลือกผู้ออกแบบตกแต่งภายในเนื่องจากการให้บริการด้านการออกแบบตกแต่งภายในที่เพิ่มขึ้นอย่างมากของกลุ่มผู้ออกแบบตกแต่งภายในในพื้นที่จ.น่านทำให้ผู้อยู่อาศัยหรือผู้ว่าจ้างต้องเผชิญกับความยากลำบากในการตัดสินใจเลือกผู้ออกแบบภายในที่เหมาะสม ความหลากหลายดังกล่าวนั้นอาจประกอบไปด้วยความแตกต่างด้านประสบการณ์ ผลงาน ความเชี่ยวชาญ แนวคิดการออกแบบ เป็นต้นและถึงแม้ว่าผู้ออกแบบตกแต่งภายในมักจะดำเนินงานตามความต้องการที่แท้จริงของผู้อยู่อาศัยเป็นสำคัญแต่ยังมีปัจจัยอื่นหลายปัจจัยที่อาจส่งผลต่อกระบวนการทำงานต่างๆที่เกี่ยวข้องกับการออกแบบตกแต่งภายใน ซึ่งเป็นส่วนหนึ่งในขั้นตอนการก่อสร้างจึงเป็นที่มาของการพิจารณากระบวนการหรือขั้นตอนการคัดเลือกผู้ออกแบบตกแต่งภายในที่เหมาะสมและมีคุณสมบัติครบถ้วนโดยเฉพาะความสามารถทางด้านวิชาชีพความคิดสร้างสรรค์ความน่าเชื่อถือตลอดจนถึงงบประมาณที่เหมาะสม รวมถึงการออกแบบตกแต่งภายในที่ปรับตัวที่ทันสมัยและติดตามแนวโน้มกระแสปัจจุบันเช่น การออกแบบเพื่อความยั่งยืน (Sustainable Design) หรือการใช้วัสดุที่เป็นมิตรต่อสิ่งแวดล้อมช่วยในการตอบโจทย์ความต้องการของตลาดและผู้อาศัยในปัจจุบัน

การวิจัยนี้จึงมุ่งเน้นการนำกระบวนการวิเคราะห์เชิงลำดับชั้น (Analytic Hierarchy Process: AHP) มาประยุกต์ใช้เพื่อช่วยสนับสนุนการตัดสินใจของเจ้าของโครงการเจ้าของบ้านพักอาศัย ผู้พัฒนาอสังหาริมทรัพย์ประเภทบ้านพักอาศัยในการคัดเลือกผู้ออกแบบตกแต่งภายในที่เหมาะสม เนื่องจากกระบวนการAHPเป็นเครื่องมือที่มีประสิทธิภาพในการจัดลำดับความสำคัญของปัจจัยที่ซับซ้อนโดยอาศัยการพิจารณาเชิงเปรียบเทียบในหลายมิติ สามารถสรุปผลลัพธ์ที่มีน้ำหนักความสำคัญในระดับต่างๆต่อการตัดสินใจซึ่งเหมาะสมกับการตัดสินใจที่เกี่ยวข้องกับการเลือกผู้ออกแบบตกแต่งภายในที่ต้องพิจารณาปัจจัยต่าง ๆ

ผลลัพธ์ของการวิจัยนี้จะช่วยให้เจ้าของโครงการ เจ้าของบ้านพักอาศัยผู้พัฒนาอสังหาริมทรัพย์ประเภทบ้านพักอาศัย ในจังหวัดน่านสามารถตัดสินใจเลือกผู้ออกแบบตกแต่งภายในได้อย่างมีประสิทธิภาพมีความเหมาะสมยิ่งขึ้น ตอบสนองต่อความต้องการที่แท้จริงผ่านกระบวนการพิจารณาคัดเลือกผู้ออกแบบตกแต่งภายในที่มีความเหมาะสมต่อโครงการอีกทั้งกระบวนการวิเคราะห์ดังกล่าวสามารถเพิ่มประสิทธิภาพด้านการบริหารทรัพยากรและเวลาในการก่อสร้าง สามารถลดความเสี่ยงในการเกิดปัญหา ข้อผิดพลาดที่อาจต้องแก้ไขในภายหลัง ซึ่งป้องกันการเกิดความล่าช้าจากความผิดพลาดเหล่านั้นได้อีกด้วย

2. วิธีดำเนินการวิจัย

ในการคัดเลือกผู้ออกแบบตกแต่งภายใน ประเภทบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่านโดยใช้กระบวนการวิเคราะห์เชิงลำดับชั้น (Analytic Hierarchy Process: AHP) มาประยุกต์ใช้เพื่อช่วยสนับสนุนการตัดสินใจมีวิธีดำเนินงานวิจัยอยู่ 3 ขั้นตอน ประกอบไปด้วย 1) ทบทวนวรรณกรรม 2)สร้างแบบสอบถาม 3)วิเคราะห์ข้อมูลและตรวจสอบผลลัพธ์โดยใช้ AHP ซึ่งสามารถแสดงขั้นตอนการวิจัยได้ดังนี้

2.1 ทบทวนวรรณกรรม

จากการทบทวนวรรณกรรมการศึกษาลักษณะทางกายภาพและอิทธิพลทางสถาปัตยกรรมของจังหวัดน่านซึ่งเป็นพื้นที่ที่มีลักษณะส่วนใหญ่เป็นป่าและภูเขาและมีวัฒนธรรมที่หลากหลาย

จากอิทธิพลของหลายชาติพันธุ์ทำให้สถาปัตยกรรมในจังหวัดน่านมีเอกลักษณ์เฉพาะตัว

ในส่วนของหลักการคัดเลือกผู้ออกแบบตกแต่งภายใน มีการรวบรวมปัจจัยที่สำคัญจากการทบทวนวรรณกรรมและการสอบถามผู้เชี่ยวชาญ โดยเน้นปัจจัยด้านคุณสมบัติ เช่น ความคิดสร้างสรรค์ ความรับผิดชอบ ด้านผลงาน เช่น ประสบการณ์ความเชี่ยวชาญ คุณภาพผลงาน ด้านงบประมาณ และการให้บริการ เช่น การให้คำแนะนำที่เป็นประโยชน์ และการออกแบบที่คำนึงถึงความปลอดภัยและความสะดวกสบายของผู้อยู่อาศัย

2.2 สร้างแบบสอบถาม

สร้างแบบสอบถามและแบบสัมภาษณ์โดยเก็บข้อมูลจากผู้เชี่ยวชาญที่มีผลงานก่อสร้าง และ/หรืองานออกแบบตกแต่งบ้านพักอาศัยสองชั้น ภายในพื้นที่จังหวัดน่าน 10 ท่านเพื่อหาเกณฑ์ในการเลือกผู้ออกแบบตกแต่งภายในและระดับความสำคัญของปัจจัยที่มีผลกับหลักเกณฑ์การคัดเลือกผู้ออกแบบภายใน

2.3 วิเคราะห์ข้อมูลและตรวจสอบผลลัพธ์โดยใช้ AHP

จากผลการตอบแบบสอบถามเพื่อวิเคราะห์หาค่าระดับความสำคัญของปัจจัยที่มีผลต่อการคัดเลือกผู้ตกแต่งบ้านพักอาศัยสองชั้น ด้วยกระบวนการวิเคราะห์ตามลำดับชั้น (Analytic Hierarchy Process: AHP) โดยมีรายละเอียดดังต่อไปนี้

2.3.1 จัดโครงสร้างลำดับชั้น (Hierarchy Construction)

เป็นการสร้างแผนภูมิลำดับชั้นที่เลียนแบบความคิดของมนุษย์ โดยแบ่งออกเป็นลำดับชั้น (Hierarchy)

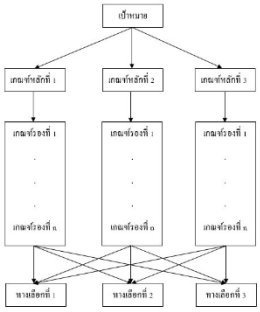

ภาพที่1: โครงสร้างลำดับชั้นของกระบวนการวิเคราะห์ตามลำดับชั้น (Analytic Hierarchy Process: AHP) โดย วิฑูรย์ ตันศิริมงคล (2542)

2.3.2 คำนวณหาลำดับความสำคัญโดยการเปรียบเทียบแบบคู่ (Pairwise Comparison)

เป็นการเปรียบเทียบเพื่อกำหนดค่าน้ำหนักความสำคัญระหว่างเกณฑ์ต่าง ๆ เป็นรายคู่ โดยการแทนค่าด้วยตัวเลขเพื่อการคำนวณค่าน้ำหนักของแต่ละทางเลือกเป็นส่วนสำคัญในกระบวนการตัดสินใจเชิงระบบโดยใช้ตารางเมตริกซ์เป็นเครื่องมือหลักในขั้นตอนเปรียบเทียบ

$$A = \begin{array}{c} \begin{matrix} C_1 & C_2 & C_3 & \dots C_4 \end{matrix} \text{ เกณฑ์} \\ \begin{bmatrix} 1 & a_{12} & a_{13} \dots a_{1n} \\ 1/a_{12} & 1 & a_{23} \dots a_{2n} \\ 1/a_{1n} & 1/a_{2n} & 1 \quad \dots a_{3n} \\ \vdots & \vdots & \vdots \quad \vdots \\ 1/a_{1n} & 1/a_{2n} & 1/a_{3n} \dots 1 \end{bmatrix} \end{array} \begin{matrix} A_1 \\ A_2 \\ A_3 \\ \vdots \\ A_n \end{matrix}$$

ตารางเมตริกซ์ A (สถาบันเทคโนโลยีป้องกันประเทศ (องค์การมหาชน), 2555)

การเปรียบเทียบแบบคู่ระหว่างเกณฑ์ กำหนดให้ใช้ตัวเลขเป็นตัวแทนการให้ค่าน้ำหนัก เพื่อทราบว่าคู่เกณฑ์ที่ทำการเปรียบเทียบนั้นมีความสำคัญ ส่งผล หรือมีประโยชน์มากกว่ากันในระดับใด ซึ่งแทนค่าโดย ตัวเลข 1 ถึง 9 แสดงถึงระดับความเข้มข้นของความสำคัญระหว่างเกณฑ์ โดยมีการอธิบายความหมายของค่าตัวเลขได้

ตารางที่ 1: ความหมายของการเปรียบเทียบแบบคู่

ระดับความเข้มข้นของความสำคัญ	ความหมาย
1	มีความสำคัญเท่ากัน
3	มีความสำคัญกว่าปานกลาง
5	มีความสำคัญกว่ามาก
7	มีความสำคัญกว่ามากที่สุด
9	มีความสำคัญสูงสุด
2 4 6 8	ค่ากลางระหว่างสองระดับความสำคัญติดกันข้างต้น

2.3.3 การหาค่าน้ำหนักของเกณฑ์

เกณฑ์เมื่อทำการวินิจฉัยเปรียบเทียบแบบคู่โดยผู้เชี่ยวชาญแล้วนำค่าความสำคัญที่เป็นค่าตัวเลขมาคำนวณหาน้ำหนักความสำคัญของแต่ละชั้น แล้วทำการวิเคราะห์ตามลำดับชั้น จากระดับชั้นบนสู่ระดับชั้นล่างจนครบทุกลำดับชั้น

สมการที่ใช้ในกระบวนการ AHP การคำนวณค่าน้ำหนักเฉลี่ย (Eigenvector) ของปัจจัย

$$W_i = \frac{\sum_{j-1}^{n} \frac{a_{ij}}{\sum_{k-1}^{n} a_{kj}}}{n} \quad (1)$$

โดยที่ W_i คือ ค่าน้ำหนักของปัจจัยที่ i, a_{ij} คือค่าการเปรียบเทียบระหว่างปัจจัย i และ j, และ n คือจำนวนปัจจัยทั้งหมดข้อมูลที่ใช้ในการวิเคราะห์ โดยอาศัยวิธีการคำนวณค่าเฉลี่ยเรขาคณิต (Geometric Mean)ในทางคณิตศาสตร์ โดยมีสมการดังนี้

$$G = \sqrt[n]{x_1 \, . x_2 \, \dots\dots \, x_n} \quad (2)$$

โดยที่ X_i = ค่าน้ำหนักแบบสอบถามที่ได้จากผู้เชี่ยวชาญ

n = จำนวนผู้เชี่ยวชาญ

โดยที่สูตรนี้จะใช้ในการคำนวณก่อนที่จะคำนวณการคำนวณดัชนีความสอดคล้อง (Consistency Index: C.I.)

การคำนวณดัชนีความสอดคล้อง (Consistency Index: C.I.)

$$CI = \frac{(\lambda_{max} - n)}{(n-1)} \quad (3)$$

การคำนวณค่าสัดส่วนความสอดคล้อง (Consistency Ratio: CR)

$$C.R. = \frac{C.I.}{R.I.}$$

โดยที่ RI คือ ค่า Random Index ที่ได้จากตารางมาตรฐานตามขนาดของเมตริกซ์ หาก C.R.$\leq$0.1C.R. แสดงว่าค่าการประเมินมีความสอดคล้องและน่าเชื่อถือ

ตารางที่2: ตารางค่าดัชนีความสอดคล้องเชิงสุ่มตามขนาดของเมตริกซ์ (Random Consistency Index: R.I.) โดย วิฑูรย์ ตันศิริมงคล (2542)

N	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
RI	0.00	0.00	0.58	0.90	1.12	1.24	1.32	1.41	1.45	1.49	1.51	1.48	1.56	1.57	1.59

เมื่อคำนวณหาค่า C.R. ซึ่งผลการคำนวณไม่ควรเกิน 0.1 จึงจะถือข้อมูลมีความสอดคล้องกันเป็นข้อมูลที่เป็นเหตุเป็นผลกัน สามารถนำค่าไปใช้ค่าน้ำหนักความสำคัญในการพิจารณาได้ต่อไป หลังจากนี้จะคำนวณหาค่า C.I. ความสอดคล้องของปัจจัยย่อยที่มีผลต่อปัจจัยหลัก โดยการคำนวณลำดับความสำคัญของทางเลือก เพื่อนำปัจจัยที่ได้ทั้งหมดมาใช้ในการวิเคราะห์การสร้างคะแนนน้ำหนักของปัจจัยในการคัดเลือกผู้ออกแบบตกแต่งภายใน จากผู้เชี่ยวชาญที่มีส่วนเกี่ยวข้องกับธุรกิจรับเหมาก่อสร้าง ประเภทบ้านพักอาศัย

3. ผลการวิจัยและอภิปรายผล

จากการดำเนินงานตามขั้นตอนวิธีดำเนินการวิจัย แสดงผลการวิจัยได้ดังต่อไปนี้ ปัจจัยที่มีผลต่อเกณฑ์การคัดเลือกผู้ออกแบบตกแต่งภายใน ประเภทบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่านมีจำนวน 5 เกณฑ์หลัก 26 เกณฑ์ย่อยได้แก่

1) ปัจจัยด้านคุณสมบัติ (A) ประกอบไปด้วยความคิดสร้างสรรค์ ลักษณะภาพลักษณ์ความน่าเชื่อถือ ความรับผิดชอบ การยอมรับข้อผิดพลาด มีมนุษย์สัมพันธ์ที่ดี การพัฒนาตนเอง

2) ปัจจัยด้านผลงาน (B) ประกอบไปด้วย ประสบการณ์ ทักษะ ความเชี่ยวชาญ มีใบประกอบวิชาชีพ คุณภาพผลงาน ผลงานที่ผ่านมา

3) ปัจจัยด้านงบประมาณ (C) ประกอบไปด้วยค่าตอบแทนของผู้ออกแบบ ความพอใจค่าออกแบบ ความยืดหยุ่นในการแก้ไขหรือเปลี่ยนแปลงปริมาณงาน ค่าใช้จ่ายอยู่ในงบที่ตั้งไว้

4) ปัจจัยด้านการให้บริการ (D) ประกอบไปด้วยความสามารถในการตรวจสอบแบบและหน้างาน, ระยะเวลาการทำงาน การให้คำแนะนำที่มีประโยชน์ การตระหนักรู้ด้านสิ่งแวดล้อม, มีความรู้ด้านกฎหมาย ระเบียบ และข้อบังคับ

5) ปัจจัยด้านการออกแบบตกแต่งภายใน (E) ประกอบไปด้วย คำนึงถึงความปลอดภัย, ความสะดวกสบาย, การเลือกใช้วัสดุที่กลมกลืนกับธรรมชาติท้องถิ่น การจัดผังภายในอาคาร โทนสีภายในอาคาร ฟังก์ชันการใช้งาน ตกแต่งลวดลายที่เป็นเอกลักษณ์เมืองน่าน

โดยที่คะแนนของแต่ละเกณฑ์ ผู้เชี่ยวชาญเป็นผู้ให้คะแนน ผลการวิเคราะห์มีรายละเอียดดังต่อไปนี้

ตารางที่ 3: แสดงผลการวิเคราะห์ AHP สำหรับการเปรียบเทียบปัจจัยหลัก A, B, C, D และ E โดยมีค่าถ่วงน้ำหนัก (Weight) ของแต่ละปัจจัยและการจัดลำดับความสำคัญ และตารางเมทริกซ์การเปรียบเทียบแบบคู่ (Pairwise Comparison Matrix) ได้โดยใช้หลักการเปรียบเทียบอัตราส่วนของค่าถ่วงน้ำหนักระหว่างปัจจัยแต่ละคู่ตารางเมทริกซ์การเปรียบเทียบแบบคู่จะมีค่าที่คำนวณจากอัตราส่วนของค่าถ่วงน้ำหนัก ดังนี้

เกณฑ์หลัก			
เปรียบเทียบเกณฑ์หลัก	ค่าน้ำหนักความสำคัญเฉลี่ย (Weight)	ค่าลำดับความสำคัญ (ร้อยละ)	ลำดับความสำคัญ
(E) ปัจจัยด้านการออกแบบตกแต่งภายใน	1.625	30.60%	1 (สำคัญที่สุด)
(A) ปัจจัยด้านคุณสมบัติ	1.236	23.30%	2
(B) ปัจจัยด้านผลงาน	1.126	21.20%	3
(C) ปัจจัยด้านงบประมาณ	0.776	14.60%	4
(D) ปัจจัยด้านการให้บริการ	0.549	10.30%	5 (สำคัญน้อยที่สุด)

	E (1.625)	A (1.236)	B (1.126)	C (0.776)	D (0.549)
E (1.625)	1.000	1.315	1.444	2.094	2.961
A (1.236)	0.760	1.000	1.098	1.593	2.252
B (1.126)	0.692	0.911	1.000	1.451	2.051
C (0.776)	0.478	0.628	0.689	1.000	1.412
D (0.549)	0.338	0.444	0.487	0.708	1.000

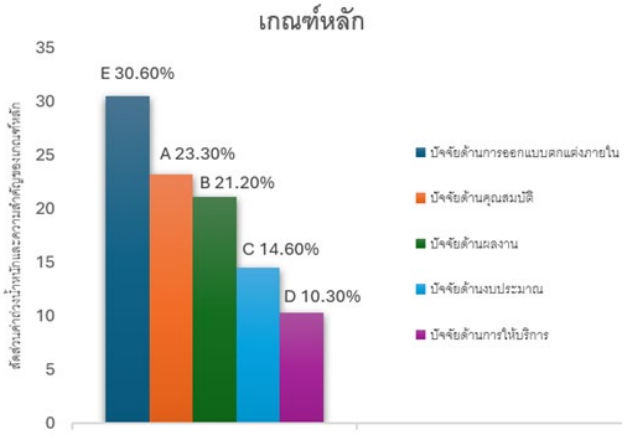

จากตารางที่3 และกราฟ สรุปได้ว่าเกณฑ์หลักปัจจัย E มีน้ำหนักมากที่สุด(1.625) 30.60% ซึ่งหมายความว่าเป็นปัจจัยที่มีความสำคัญสูงสุดในการตัดสินใจปัจจัย A และ B มีน้ำหนักใกล้เคียงกัน โดย A (1.236)23.30% มีความสำคัญมากกว่า B (1.126)21.20%เล็กน้อย ปัจจัย C และ D มีความสำคัญน้อยที่สุด โดย D มีน้ำหนักต่ำสุด (0.549) การตรวจสอบความสอดคล้องของปัจจัยทั้งหมด ใน AHP ทำได้โดยดูค่า Consistency Ratio (C.R.) ซึ่งจากการคำนวณในตาราง ค่า C.R. = 0.0808เกณฑ์การพิจารณาถือว่าความสอดคล้องอยู่ในเกณฑ์ที่ยอมรับได้

ตารางที่ 4: แสดงผลการวิเคราะห์ AHP สำหรับการเปรียบเทียบปัจจัยรอง A, B, C, D และ E โดยมีค่าถ่วงน้ำหนัก (Weight) ของแต่ละปัจจัยและการจัดลำดับ 10 ความสำคัญ และตารางเมทริกซ์การเปรียบเทียบแบบคู่ (Pairwise Comparison Matrix) ได้โดยใช้หลักการเปรียบเทียบอัตราส่วนของค่าถ่วงน้ำหนักระหว่างปัจจัยแต่ละคู่ตารางเมทริกซ์การเปรียบเทียบแบบคู่จะมีค่าที่คำนวณจากอัตราส่วนของค่าถ่วงน้ำหนัก ดังนี้

เกณฑ์รอง			
เปรียบเทียบเกณฑ์รอง	ค่าน้ำหนักความสำคัญเฉลี่ย (Weight)	ค่าลำดับความสำคัญ (ร้อยละ)	ลำดับความสำคัญ
(D5) มีความรู้ด้านกฎระเบียบและข้อบังคับ	1.900	6.37%	1 (สำคัญที่สุด)
(E1) คำนึงถึงความปลอดภัย	1.850	6.20%	2
(C2) ความพอใจค่าออกแบบ	1.765	5.91%	3
(B2) ทักษะ ความเชี่ยวชาญ	1.726	5.78%	4
(A3) ความรับผิดชอบ การยอมรับข้อผิดพลาด	1.651	5.53%	5
(B1) ประสบการณ์	1.552	5.20%	6
(E5) โทนสีภายในอาคาร	1.541	5.16%	7
(E4) การจัดผังภายในอาคาร	1.393	4.67%	8
(A2) ลักษณะ ภาพลักษณ์ ความน่าเชื่อถือ	1.373	4.60%	9
(C3) ความยืดหยุ่นในการแก้ไขหรือเปลี่ยนแปลงปริมาณงาน	1.308	4.38%	10 (สำคัญน้อยที่สุด)

	D5	E1	C2	B2	A3	B1	E5	A2	E3	C3
D5	1.0	1.019	1.076	1.114	1.151	1.224	1.364	1.372	1.453	1.453
E1	0.982	1.0	1.057	1.094	1.13	1.202	1.339	1.347	1.426	1.426
C2	0.929	0.946	1.0	1.035	1.069	1.137	1.267	1.274	1.349	1.349
B2	0.897	0.914	0.966	1.0	1.033	1.099	1.224	1.231	1.304	1.304
A3	0.869	0.885	0.935	0.968	1.0	1.064	1.185	1.192	1.262	1.262
B1	0.817	0.832	0.879	0.91	0.94	1.0	1.114	1.121	1.187	1.187
E5	0.733	0.747	0.789	0.817	0.844	0.898	1.0	1.006	1.065	1.065
A2	0.729	0.743	0.785	0.812	0.839	0.892	0.994	1.0	1.059	1.059
E3	0.688	0.701	0.741	0.767	0.792	0.843	0.939	0.944	1.0	1.0
C3	0.688	0.701	0.741	0.767	0.792	0.843	0.939	0.944	1.0	1.0

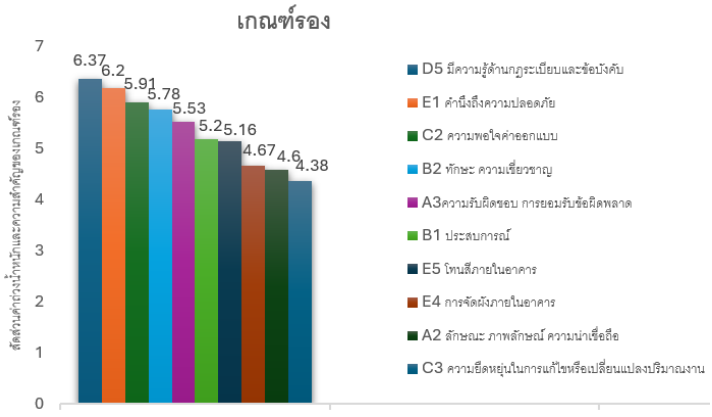

ตารางที่ 5: จากตารางจะเห็นได้ว่าเปอร์เซ็นต์ค่าถ่วงน้ำหนักและลำดับความสำคัญของปัจจัยรอง (A-E)

เกณฑ์รอง			
เปรียบเทียบเกณฑ์รอง	ค่าน้ำหนักความสำคัญเฉลี่ย (Weight)	ค่าลำดับความสำคัญ (ร้อยละ)	ลำดับความสำคัญ
(E) ปัจจัยด้านการออกแบบตกแต่งภายใน	8.738	29.30%	1 (สำคัญที่สุด)
(A) ปัจจัยด้านคุณสมบัติ	5.329	17.87%	2
(B) ปัจจัยด้านผลงาน	5.297	17.76%	3
(C) ปัจจัยด้านงบประมาณ	5.270	17.67%	4
(D) ปัจจัยด้านการให้บริการ	5.190	17.40%	5 (สำคัญน้อยที่สุด)

จากตารางที่4, 5 และกราฟสรุปได้ว่า 10 อันดับของเกณฑ์รองจะเห็นได้ว่าปัจจัย D5 มีน้ำหนักมากที่สุด(1.900) 6.37% ซึ่งหมายความว่าเป็นปัจจัยรองลงมาคือ E1 (6.20%), C2 (5.92%), B2 (5.79%), และ A3 (5.54%)การตรวจสอบความสอดคล้องของปัจจัยทั้งหมด ใน AHP ทำได้โดยดูค่า Consistency Ratio (CR) ซึ่งจากการคำนวณในตาราง ค่า C.R. ของทุกปัจจัยรองมีค่าอยู่ในช่วง 0.0782 - 0.0918 เกณฑ์การพิจารณาถือว่าความสอดคล้องอยู่ในเกณฑ์ที่ยอมรับได้

จากตารางทั้งหมดจะเห็นได้ว่าการวิเคราะห์ลำดับชั้นเชิงวิเคราะห์ (AHP) ในครั้งนี้ มีวัตถุประสงค์เพื่อประเมินความสำคัญของปัจจัยหลักและปัจจัยรองในการคัดเลือกผู้ออกแบบตกแต่งภายในบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่าน โดยผลการวิเคราะห์ชี้ให้เห็นว่าปัจจัยหลัก ปัจจัยE ปัจจัยด้านการออกแบบตกแต่งภายในมีความสำคัญสูงสุด (30.6%) รองลงมาคือ ปัจจัยA ปัจจัยด้านคุณสมบัติ (19.4%) ในขณะที่ปัจจัยรองD5 มีความรู้ด้านกฎระเบียบและข้อบังคับ มีความสำคัญสูงสุด (6.37%) ตามด้วย ปัจจัยE1 คำนึงถึงความปลอดภัย (6.20%) ค่าความสอดคล้อง (C.R.) ของทั้งปัจจัยหลักและปัจจัยรองอยู่ในเกณฑ์ยอมรับได้ (C.R. < 0.1) ซึ่งแสดงถึงความน่าเชื่อถือในการให้คะแนนของผู้เชี่ยวชาญ ทำให้ผลการวิเคราะห์สามารถใช้เป็นแนวทางในการตัดสินใจได้อย่างมั่นใจ

ตารางที่ 6: สรุปการหาค่าเฉลี่ย (Normalized Matrix) ปัจจัยหลักและปัจจัยรอง

ปัจจัยหลัก	น้ำหนักปัจจัยหลัก	ปัจจัยรอง	น้ำหนักปัจจัยรอง	ปัจจัยหลัก x ปัจจัยรอง	ลำดับความสำคัญ
ปัจจัยด้านคุณสมบัติ (A)	0.233	ความคิดสร้างสรรค์ (A1)	0.142	0.0331	16
		ลักษณะ ภาพลักษณ์ ความน่าเชื่อถือ (A2)	0.260	0.0606	7
		ความรับผิดชอบ การยอมรับข้อผิดพลาด (A3)	0.308	0.0718	2
		มีมนุษย์สัมพันธ์ที่ดี (A4)	0.130	0.0303	17
		การพัฒนาตนเอง (A5)	0.160	0.0373	13
ปัจจัยด้านผลงาน (B)	0.211	ประสบการณ์ (B1)	0.293	0.0618	5
		ทักษะ ความเชี่ยวชาญ (B2)	0.325	0.0686	3
		มีใบประกอบวิชาชีพ (B3)	0.095	0.0200	23
		คุณภาพผลงาน (B4)	0.171	0.0361	15
		ผลงานที่ผ่านมา (B5)	0.116	0.0245	20
ปัจจัยด้านงบประมาณ (C)	0.146	ค่าตอบแทนของผู้ออกแบบ (C1)	0.148	0.0216	22
		ความพอใจค่าออกแบบ (C2)	0.279	0.0407	12
		ความยืดหยุ่นในการแก้ไขหรือเปลี่ยนแปลงปริมาณงาน (C3)	0.173	0.0253	19
		ค่าใช้จ่ายอยู่ในงบที่ตั้งไว้ (C4)	0.200	0.0292	18
ปัจจัยด้านการให้บริการ (D)	0.103	ความสามารถในการตรวจสอบแบบและหน้างาน (D1)	0.232	0.0239	21
		ระยะเวลาการทำงาน (D2)	0.149	0.0153	25
		การให้คำแนะนำที่มีประโยชน์ (D3)	0.098	0.0101	26
		การตระหนักรู้ด้านสิ่งแวดล้อม (D4)	0.163	0.0168	24
		มีความรู้ด้านกฎหมาย ระเบียบ และข้อกำหนด (D5)	0.357	0.0368	14
ปัจจัยด้านการออกแบบตกแต่งภายใน (E)	0.307	คำนึงถึงความปลอดภัย (E1)	0.377	0.1157	1
		ความสะดวกสบาย (E2)	0.201	0.0617	6
		การเลือกใช้วัสดุที่กลมกลืนกับธรรมชาติท้องถิ่น (E3)	0.173	0.0531	10
		การจัดผังภายในอาคาร (E4)	0.180	0.0553	9
		โทนสีภายในอาคาร (E5)	0.186	0.0571	8
		ฟังก์ชันการใช้งาน (E6)	0.220	0.0675	4
		ตกแต่งลวดลายที่เป็นเอกลักษณ์เมืองน่าน (E7)	0.166	0.0510	11

อย่างไรก็ตามงานวิจัยนี้ควรให้ความสำคัญกับทุกปัจจัย ในการคัดเลือกผู้ออกแบบตกแต่งภายในที่มีความสามารถตรงกับความต้องการของการออกแบบบ้านพักอาศัยสองชั้นและเป็นตัวช่วยในการเปรียบเทียบคุณสมบัติของผู้ออกแบบ เพื่อให้ได้ตัวเลือกที่เหมาะสมที่สุด ควรตรวจสอบความสอดคล้องของการประเมินอยู่เสมอ เพื่อให้มั่นใจว่าการคัดเลือกเป็นไปตามมาตรฐานและตรงกับความต้องการ

เพิ่มการฝึกอบรมและทำความเข้าใจทีมงานเกี่ยวกับกระบวนการ AHP เพื่อให้การประเมินมีความแม่นยำมากยิ่งขึ้น

ประโยชน์ที่ได้รับจากการวิจัย ช่วยให้การคัดเลือกผู้ออกแบบตกแต่งภายในเป็นไปอย่างมีประสิทธิภาพและตรงกับความต้องการของเจ้าของบ้านพักอาศัย เพิ่มความโปร่งใสและสร้างมาตรฐานในการประเมินคุณสมบัติและผลงานของผู้ออกแบบสามารถนำกระบวนการ AHP ไปใช้กับการคัดเลือกวัสดุตกแต่ง หรือการวางแผนโครงการอื่น ๆ ได้

ข้อจำกัดของงานวิจัยนี้ จำกัดพื้นที่ศึกษาเฉพาะจังหวัดน่าน ขอบเขตของผู้ให้ข้อมูลอยู่ในจังหวัดเดียว อาจไม่สะท้อนพฤติกรรมหรือความคาดหวังในภูมิภาคอื่น และกลุ่มตัวอย่างมีจำนวนจำกัด ขนาดกลุ่มตัวอย่าง (ผู้ให้ข้อมูลแบบสอบถาม) มีผลต่อความแม่นยำและความสามารถในการสรุปผลในวงกว้าง ปัจจัยที่ใช้วิเคราะห์มีลักษณะเฉพาะบางกลุ่มแม้จะครอบคลุมหลายด้าน แต่บางปัจจัยอาจยังไม่เพียงพอในการพิจารณาในกรณีอื่น เช่น อาคารเพื่อธุรกิจ หรืองานออกแบบเชิงพาณิชย์

การพัฒนางานวิจัยในอนาคต ขยายการศึกษาปัจจัยอื่น ๆ เช่น ปัจจัยด้านความพึงพอใจของลูกค้า หรือปัจจัยทางเศรษฐกิจในพื้นที่ใช้เครื่องมือวิเคราะห์อื่น ๆ ร่วมกับ AHP เพื่อให้ได้ข้อมูลที่ครอบคลุมและเชิงลึกมากขึ้น พัฒนากระบวนการประเมินให้สอดคล้องกับเทรนด์การออกแบบตกแต่งภายในในอนาคต เพื่อให้โครงการบ้านพักอาศัยสามารถตอบสนองความต้องการของผู้อยู่อาศัย

4. กิตติกรรมประกาศ

งานวิจัยเรื่อง การประยุกต์กระบวนการวิเคราะห์เชิงลำดับชั้นสำหรับคัดเลือกผู้ออกแบบตกแต่งภายใน ประเภทบ้านพักอาศัยสองชั้นในพื้นที่จังหวัดน่าน สามารถดำเนินการจนประสบความสำเร็จลุล่วงไปด้วยดีเนื่องจากได้รับความอนุเคราะห์และสนับสนุนเป็นอย่างดียิ่งจากผู้ช่วยศาสตราจารย์ ดร. เกรียงไกร อรุโณทยานันท์, ผู้ช่วยศาสตราจารย์ ดร. นที สุริยานนท์, และ อาจารย์ ดร. สมจินตนา แขนงแก้ว คณาจารย์ภาควิชาการบริหารงานก่อสร้าง คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเชียงใหม่ ที่ได้กรุณาให้คำปรึกษา แนะนำ แนวทาง ความรู้และข้อคิดเห็น ในการปรับปรุงแก้ไขข้อบกพร่องต่างๆ จนกระทั่งงานวิจัยนี้สำเร็จเรียบร้อยด้วยดี ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

สุดท้ายนี้ผู้วิจัยหวังว่า งานวิจัยนี้จะเป็นแรงบันดาลใจ และเป็นประโยชน์สำหรับผู้ที่สนใจในงานวิจัยเรื่องนี้

5. เอกสารอ้างอิง

[1] Al-Zamil, F. A. (2017). The Impact of Design Elements on the Perception of Spaciousness in Interior Design. 7(2), 177-187.

[2] Darko, A., Chan, A. P. C., Ameyaw, E. E., Owusu, E. K., Pärn, E., & Edwards, D. J. (2019). Review of application of analytic hierarchy process (AHP) in construction. International Journal of Construction Management, 19(5), 436-452. https://doi.org/10.1080/15623599.2018.1452098

[3] DDproperty. (2568a). ขายบ้านพร้อมผู้เช่า, น่าน. Retrieved 25/01 from https://shorturl.asia/5nLlk

[4] DDproperty. (2568b). น่าน, น่าน. Retrieved 21/01 from https://www.ddproperty.com

[5] DDproperty. (2568c). บ้านเดี่ยว 2 ชั้น ม.พิมพฤกษา อ.เมือง จ.น่าน 108.3 ตร.ว 4 นอน 3 น้ำ ใกล้เทสโก้ โลตัส น่าน แม็คโคร น่าน. Retrieved 15/01 from https://shorturl.asia

[6] Honrao, R. (2024). EFFECT OF MOOD LIGHTING ON HUMAN EMOTIONS AND BEHAVIOR. ShodhKosh: Journal of VisualandPerformingArts,4(2SE),274–281. https://doi.org/10.29121/shodhkosh.v4.i2SE.2023.562

[7] Liao,E.(2016).Practitionerexpectations for intern leadership skills: implications for interior designer

education. Royal House. (2566). ข้อควรรู้! แบบบ้านชั้นเดียวและบ้านสองชั้น Retrieved 10/01 from https://www.royalhouse.co.th

[8] Tochaiwat, K., Nititerapad, C., & Pultawee, P. (2022). Determinants of the Interior Design of Mock-Up Houses in Housing Projects with the Use of Modified Analytic Hierarchy Process. Published in International Transaction Journal of Engineering, Management,&Applied Sciences & Technologies.

[9] Tsunetsugu, Y., Miyazaki, Y., & Sato, H. (2005). Visual effects of interior design in actual-size living rooms on physiological responses. Building and Environment, 40(10) https://doi.org/https://doi.org/10.1016/j.buildenv.2004.11.026

[10] Wang, P.-K., & Perng, Y.-H. (2019). Critical Criteria for Customer Satisfaction of Interior Design. IOP Conference Series: Materials Science and Engineering, 652(1), 012012. https://doi.org/10.1088/1757-899X/652/1/012012

[11] Yildirim, K., Hidayetoğlu, M. L., & Ozkan, A. (2011). Effects of Interior Colors on Mood and Preference: Comparisons of Two Living Rooms. Perceptual and motor skills, https://doi.org/10.2466/24.27.PMS.112.2.509-524

[12] โชติกา สุวรรณจินดาชัย. (2557). การวิเคราะห์ปัจจัยที่มีผลกระทบต่อประสิทธิภาพการดำเนินงานของบริษัทออกแบบทางวิศวกรรมโดยประเมินจากความพึงพอใจของผู้เกี่ยวข้องด้วยวิธีการวิเคราะห์เชิงลำดับชั้น (AHP). มหาวิทยาลัยธรรมศาสตร์.

[13] ไทยพับลิก้า. (2566). 'ก้นยายน' ฝนตกหนักน้ำท่วมโลก 'climate change' สภาพอากาศสุดขั้ว จะกลายเป็นเรื่องธรรมดา Retrieved 12/01 from https://thaipublica.org

[14] กรมอุตุนิยมวิทยา, ร. (2566). ภูมิอากาศจังหวัดน่าน. Retrieved from http://climate.tmd.go.th

[15] กระทรวงอุตสาหกรรม. (2567). รายงานการวิเคราะห์สภาวะเศรษฐกิจอุตสาหกรรมจังหวัดน่าน ประจำปี 2567. การท่องเที่ยวแห่งประเทศไทย. (2567). 365 วัน มหัศจรรย์เมืองน่าเที่ยว : 5 สิ่งต้องห้ามพลาด น่าน : 5 Must Do In Nan. Retrieved from https://thai.tourismthailand.org

[16] ขัตติพงษ์ ด้วงสำราญ. (2564). การวางแผนสร้างสรรค์งานออกแบบตกแต่งภายในอย่างมีคุณภาพ. Journal of Arts Management, 5(1), 206-217. Retrieved from https://so02.tci-thaijo.org

[17] ณัฐวิคม พันธุวงศ์ภักดี. (2567). มรสุม 2567: เมื่อเส้นชีวิตกลายเป็นภัยพิบัติ สำรวจสถานการณ์น้ำท่วมและการตั้งรับปรับตัวของไทย. Retrieved 12/01 from https://www.sdgmove.com

[18] บริษัท แอค เซส เซอรี่ จำกัด. (ม.ป.ป.). คำแนะนำจากมืออาชีพในวงการข้อควรรู้ก่อนเลือกบริษัทออกแบบตกแต่งภายในให้มีมาตรฐานสูง. Retrieved 10/01 from https://www.accessories.co.th

[19] ภาณุรังษี เดือนโฮ้ง. (2558). นครน่านเมืองเก่าที่มีชีวิต : อัตลักษณ์ทางประวัติศาสตร์และวัฒนธรรม. SOCIAL SCIENCES RESEARCH AND ACADEMIC JOURNAL, 10(29(2)), 123-140. https://so05.tci-thaijo.org

[20] รพีรัศม์ วัชโรทัย และ มงคล อัศวดิลกฤทธิ์. (2565). การศึกษาปัจจัยการคัดเลือกผู้รับเหมาปรับปรุงอาคาร โดยใช้วิธีกระบวนการวิเคราะห์เชิงลำดับชั้น. Srinakharinwirot University Engineering Journal, 17(1), 64-81. https://ph02.tci-thaijo.org

[21] วรากร ลิขิตอนุภาค. (2553). หลักเกณฑ์การคัดเลือกผู้รับเหมาก่อสร้างงานสาธารณูปโภคในโครงการหมู่บ้านจัดสรร. มหาวิทยาลัยธรรมศาสตร์.

[22] วสวัสดิ์ โชติวงศ์อริยะ. (2556). เกณฑ์การคัดเลือกผู้ออกแบบตกแต่งภายใน โครงการอาคารชุดพักอาศัย. Build Environment Research Associates Conference, BERAC 4, Faculty of Architecture and Planning, Thammasat University.

[23] สถาบันเทคโนโลยีป้องกันประเทศ (องค์การมหาชน). (2555). กระบวนการวิเคราะห์ตามลำดับชั้น. ข้อบังคับสภาสถาปนิก, (2565).

[24] สุธรรม อรุณ. (2549). การตัดสินใจโดยใช้กระบวนการลำดับชั้นเชิงวิเคราะห์ PRODUCTIVITY WORLD, 64, 83 - 89.

[25] สุนาวิน วัฒนกำเนิด และ กองกูณฑ์ โตชัยวัฒน์. (2557). แบบจำลองการคัดเลือกผู้ออกแบบตกแต่งภายในร้านค้าในศูนย์การค้าชุมชน เขต กทม.

[26] หออัตลักษณ์นครน่าน. (2567). นิทรรรศการ ชาติพันธุ์. Retrieved from https://nanidentity.com

การตรวจจับความผิดปกติของข้อมูลการเคลม โดยใช้ Machine Learning และ Blockchain Technology

Detection of Anomalies in Claim Data Using Machine Learning and Blockchain Technology

ชนัญชิดา เสมสันต์* ปราชญ์ ปัญญาแหลม โสภิตา เนียมกอง นวลพรรณ ลอว์สัน อุไรวรรณ เจริญกีรติกุล

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6304052616011@email.kmutnb.ac.th*)

บทคัดย่อ

ปัญหาการฉ้อโกงด้านประกันสุขภาพเป็นปัญหาต่อเนื่องที่เกิดจากการกระทำโดยเจตนาเพื่อผลประโยชน์ทางการเงินของผู้เอาประกันบางกลุ่ม ส่งผลให้ผู้เอาประกันที่ดีต้องจ่ายเบี้ยสูงขึ้น โครงงานวิจัยนี้มีวัตถุประสงค์เพื่อตรวจจับความผิดปกติของข้อมูลการเคลมด้วย machine learning (ML) และ blockchain technology โดยได้ศึกษาถึงการเกิดความผิดปกติของข้อมูลการเคลมด้วย machine learning 2 ตัวแบบ ได้แก่ ตัวแบบ XGBoost และ decision tree โดยใช้ข้อมูลจากฐานข้อมูลจำลองทางการแพทย์ (MIMIC-III) ที่แบ่งข้อมูลเป็น Train 60% และ Test 40% ซึ่งกำหนด label ด้วยวิธีเชิงกฎเกณฑ์ (rule-based) ได้แก่ ค่าใช้จ่ายสูงผิดปกติ (เปอร์เซ็นไทล์ที่ 99) ระยะเวลารักษาผิดปกติ (<1 หรือ >30 วัน) และความถี่การรักษาผิดปกติ (ภายใน 10 วัน) ระบบเชื่อมต่อกับ smart contract บน Hyperledger Fabric ผ่าน API (application programming interface) ซึ่งเป็น blockchain เพื่อตรวจสอบเงื่อนไขความคุ้มครองตามกรมธรรม์ AIA CI ProCare ที่ใช้เป็นตัวอย่างในงานวิจัยนี้ และบันทึกธุรกรรมอย่างปลอดภัย ในงานวิจัยได้จำลองข้อมูลการเคลมของกรมธรรม์และทดสอบระบบผ่าน user interface ผลการทดลองในชุดข้อมูลทดสอบพบว่า XGBoost มีความแม่นยำในการตรวจจับความผิดปกติ 100% ขณะที่ Decision tree มีความแม่นยำ 98% แต่ XGBoost ใช้เวลาประมวลผลน้อยกว่า 1.22 นาที เมื่อ ML ให้ผลลัพธ์เชิงทำนายแล้วส่งต่อให้ smart contract ระบบจะพิจารณาเงื่อนไขความคุ้มครองและตรวจสอบวงเงินที่เคลมโดยใช้ค่ารักษาจาก MIMIC-III และบันทึกธุรกรรมลง Ledger บน blockchain โดยไม่สามารถแก้ไขย้อนหลัง การบูรณาการนี้ช่วยลดการปลอมแปลงข้อมูล ลดต้นทุน ลดระยะเวลาการเคลม เพิ่มความน่าเชื่อถือให้บริษัทประกันและสร้างความมั่นใจแก่ผู้เอาประกัน

คำสำคัญ: Machine learning, Blockchain technology, XGBoost, Decision tree, Smart contract, Hyperledger Fabric

การวิเคราะห์พฤติกรรมลูกค้าในร้านสะดวกซื้อผ่านปัจจัยภายนอกในแต่ละภูมิภาค

Analyzing Customer Behavior in Convenience Stores Across Regional External Factors

วรวรรณ วรศักดิ์เสนีย์* สถาพร เทพสัมฤทธิ์พร ชนนิกานต์ รอดมรณ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053630202@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์ความสัมพันธ์ระหว่างพฤติกรรมของลูกค้าและปัจจัยภายนอกในแต่ละภูมิภาค โดยเฉพาะในพื้นที่ที่พฤติกรรมของผู้บริโภคมีการเปลี่ยนแปลงตามฤดูกาล เช่น ช่วงเทศกาลท่องเที่ยว หรือวันหยุดยาว การศึกษานี้ได้ทำการรวบรวมและเตรียมข้อมูลที่เกี่ยวข้องกับพฤติกรรมของลูกค้า เนื่องจากไม่สามารถเผยแพร่ข้อมูลของบริษัทได้ จึงได้นำข้อมูลสถิตินักท่องเที่ยวในประเทศไทย ตั้งแต่ พ.ศ. 2556 ถึง พ.ศ. 2566 เปรียบเป็นข้อมูลพฤติกรรมของผู้บริโภค และปัจจัยภายนอก ได้แก่ สถานที่ท่องเที่ยว การจัดกิจกรรม ภัยพิบัติ วันหยุดรายละเอียดสาขาและตำแหน่งที่ตั้งของร้านสะดวกซื้อต่างๆ รวมถึงปัจจัยด้านเศรษฐกิจ ได้แก่ ราคาน้ำมัน ราคายาง และข้อมูลนิคมอุตสาหกรรม ที่อาจส่งผลต่อแนวโน้มการใช้จ่ายและมีการทำ PCA เพื่อลดมิติของข้อมูล ซึ่งข้อมูลเหล่านี้ถูกนำมาประมวลผลผ่านกระบวนการออกแบบคุณลักษณะข้อมูล (Feature Engineering) เพื่อคัดเลือกและสร้างตัวแปรที่สะท้อนถึงปัจจัยที่มีผลต่อพฤติกรรมของลูกค้าได้อย่างมีประสิทธิภาพ เพื่อใช้ในการวิเคราะห์และการนำไปใช้ในการพัฒนาแบบจำลองต่อไป จากนั้นจึงใช้แบบจำลองการจัดกลุ่มข้อมูล (Clustering Models) ได้แก่ K-Means, DBSCAN, Spectral Clustering และ Affinity Propagation โดยใช้ค่า Silhouette ซึ่งคือค่าที่วัดความใกล้เคียงของจุดข้อมูลในกลุ่มเดียวกันและความห่างจากกลุ่มอื่นๆ มาใช้เพื่อเลือกจำนวนกลุ่ม และแบบจำลองที่เหมาะสม ซึ่งในแบบจำลองการจัดกลุ่มประเภทการเรียนรู้แบบมีผู้สอน ใช้วิธี Elbow Method เพื่อเลือกจำนวนกลุ่มตามค่า Silhouette ที่มากที่สุด และนำไปกำหนดในแบบจำลอง ส่วนแบบจำลองการจัดกลุ่มประเภทการเรียนรู้แบบไม่มีผู้สอน แบบจำลองจะเลือกจำนวนกลุ่มที่เหมาะสมมาพร้อมกับค่า Silhouette แต่จะมีการใช้ K-Distance Graph เพื่อเลือกค่า epsilon ซึ่งคือค่าที่กำหนดรัศมีของพื้นที่รอบแต่ละจุด และค่า Min Samples ที่เหมาะสม โดยแบบจำลองที่เหมาะสมที่สุด ได้แก่ Affinity Propagation โดยมีค่า Silhouette เท่ากับ 57.12% และได้จำนวนกลุ่มเป็น 11 กลุ่ม ส่วนแบบจำลองอื่นๆ ได้แก่ K-Means มีค่า Silhouette เท่ากับ 56.49% DBSCAN มีค่า DBI เท่ากับ 1.3667 ซึ่งคิดเป็น 0.00% (ควรมีค่าน้อยกว่า 1 เพื่อแสดงว่ากลุ่มมีการแยกออกจากกันดี) และ Spectral Clustering มีค่า Silhouette เท่ากับ 56.63% ซึ่งการทำแบบจำลองข้างต้นนี้ จะใช้จำแนกกลุ่มลูกค้าและวิเคราะห์ความสัมพันธ์ระหว่างปัจจัยเหล่านี้กับแนวโน้มการบริโภคของผู้บริโภคในแต่ละพื้นที่ นำไปสู่ความเข้าใจเชิงลึกเกี่ยวกับพฤติกรรมของลูกค้าและสามารถคาดการณ์ช่วงเวลาที่มีความต้องการต่างๆ ได้อย่างแม่นยำยิ่งขึ้น

คำสำคัญ: พฤติกรรมผู้บริโภค, Feature Engineering, Clustering Models

การเปรียบเทียบตัวแบบการพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในภาคเศรษฐกิจหลักของประเทศไทยด้วยเทคนิคการเรียนรู้ของเครื่อง

A Comparison of Forecasting Models for Carbon Dioxide Emissions in Major Economic Sectors of Thailand Using Machine Learning Techniques

รินทร์ลภัส ชัยพิทักษ์ศักดา* ณัฏฐริกา ภาคย์โภคิน จีรพร ใจจุลละ เพียรพูล กมลจิตร์ประภา

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053620011@email.kmutnb.ac.th*)

บทคัดย่อ

การปล่อยก๊าซคาร์บอนไดออกไซด์ (CO_2) เป็นปัจจัยสำคัญที่ส่งผลต่อการเปลี่ยนแปลงสภาพภูมิอากาศของโลก การคาดการณ์ปริมาณการปล่อยก๊าซ CO_2 จึงจำเป็นต่อการกำหนดนโยบายเพื่อลดผลกระทบต่อสิ่งแวดล้อม งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) 7 วิธี ได้แก่ วิธี Random Forest วิธี Gradient Boosting วิธี XGboost วิธี Decision Tree วิธี K-Nearest Neighbors วิธี Lightgbm และ วิธี Catboost เพื่อคาดการณ์ปริมาณการปล่อยก๊าซ CO_2ในภาคเศรษฐกิจหลักของประเทศไทย โดยข้อมูลที่ใช้ในการศึกษาจากสำนักงานนโยบายและแผนพลังงาน (สนพ.) กระทรวงพลังงาน (http://www.eppo.go.th) ตั้งแต่ปี พ.ศ. 2548 ถึง พ.ศ. 2567 (240 เดือน) โดยแบ่งข้อมูลเป็นชุดฝึก (Train) และชุดทดสอบ (Test) ในอัตราส่วน 70 ต่อ 30 โดยใช้ K-Fold Cross Validation (K = 5) ประเมินประสิทธิภาพของตัวแบบใช้ตัวชี้วัดทางสถิติ ได้แก่ ค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R^2) ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ความคลาดเคลื่อน (Mean Absolute Percentage Error: MAPE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Squared Error: RMSE) จากการศึกษาพบว่า วิธี Catboost เป็นวิธีที่ดีที่สุดเนื่องจากให้ ค่า R^2 ร้อยละ 0.9802 ค่า MAE ร้อยละ 219.06 ค่า MAPE ร้อยละ 0.0113 และ ค่า RMSE ร้อยละ 283.11 ภาคเศรษฐกิจที่ปล่อย CO_2 มากที่สุดคือ ภาคการผลิตไฟฟ้า (39.6%) ภาคการขนส่ง (28.5%) ภาคอุตสาหกรรม (23.2%) และ ภาคเศรษฐกิจอื่นๆ (8.7%) อย่างไรก็ตาม ตัวแบบยังมีข้อจำกัดความไม่แน่นอนของข้อมูลในอนาคตที่ส่งผลต่อความแม่นยำของการพยากรณ์ การเปลี่ยนแปลงนโยบายพลังงาน หรือเทคโนโลยีใหม่ๆ การปรับปรุงตัวแบบในอนาคตควรพิจารณาข้อมูลจากแหล่งอื่นและพัฒนาอัลกอริทึม เพื่อเพิ่มความแม่นยำของการพยากรณ์

คำสำคัญ: Machine learning, CO_2, Forecasting Models, Major Economic Sectors

การวิเคราะห์พฤติกรรมลูกค้าด้วยการเรียนรู้ของเครื่อง: การแบ่งกลุ่มลูกค้าด้วย K-means Clustering และการวิเคราะห์ RFM

Customer Behavior Analysis with Machine Learning: Segmentation Using K-means Clustering and RFM Analysis

พิชญ์ณา ซอประเสริฐ* ชนม์นิภา จันทร์มั่งคั่ง วรรณพร ก่ำรัมย์ มนัสยา ละอองแก้ว ปิยะฉัตร ลีลาศิลปศาสน์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052630241@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้นำข้อมูลธุรกรรมของลูกค้าของซูเปอร์มาร์เก็ตแห่งหนึ่งในประเทศพม่า ในปี พ.ศ. 2562 จากแหล่งข้อมูล Kaggle จำนวน 622 ตัวอย่างลูกค้ามาวิเคราะห์โดยใช้การวิเคราะห์ RFM ร่วมกับการแบ่งกลุ่ม (Clustering) แบบ K-means เพื่อแบ่งกลุ่มลูกค้าตามลักษณะพฤติกรรมการซื้อ เน้นการค้นหากลุ่มลูกค้าที่มีความคล้ายคลึงกันด้านความถี่ในการซื้อครั้งล่าสุด ความถี่ในการซื้อและมูลค่าในการซื้อ เพื่อนำมาพัฒนากลยุทธ์การตลาดที่สามารถตอบสนองความต้องการของแต่ละกลุ่มลูกค้าได้อย่างมีประสิทธิภาพ โดยใช้โปรแกรม R Studio เป็นเครื่องมือในการวิเคราะห์ ผลการศึกษาพบว่า สามารถแบ่งกลุ่มลูกค้าได้ 4 กลุ่มที่แตกต่างกัน ได้แก่ กลุ่มลูกค้าเก่าที่กลับมาซื้อของบ้างและมียอดใช้จ่ายสูง คิดเป็น 14.15% กลุ่มลูกค้าที่เลิกซื้อไปแล้ว คิดเป็น 56.59% กลุ่มลูกค้าใหม่ที่มีกำลังซื้อน้อย คิดเป็น 18.65% และกลุ่มลูกค้าซื้อประจำที่มียอดใช้จ่ายสูง คิดเป็น 10.61% ตามลำดับ

คำสำคัญ: K-means Clustering, RFM Analysis

การพยากรณ์ปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติในประเทศไทย ด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง

Forecasting the Production and Import Quantity of Natural Gas in Thailand Using Statistical Technique and Machine Learning

ญาดา เหล่าดีเจริญ* ปุณยนุช สถานพงษ์ ภานุวัฒน์ กันเพรียง

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620246@email.kmutnb.ac.th*)

บทคัดย่อ

โครงงานพิเศษนี้มีวัตถุประสงค์เพื่อหาวิธีการพยากรณ์ที่เหมาะสมสำหรับข้อมูลปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติในประเทศไทย โดยใช้วิธีการพยากรณ์ทางสถิติ 3 วิธี ได้แก่ วิธีการปรับให้เรียบด้วยเอ็กซ์โปเนนเชียลของโฮลท์ (Exponential Smoothing Holt) วิธีบ็อกซ์-เจนกินส์ (Box – Jenkins Method) และเทคนิคการเรียนรู้ของเครื่อง (Machine Learning Technique) ได้แก่ เทคนิค Decision Tree และเทคนิค Random Forest จากนั้นนำตัวแบบที่ได้จากแต่ละวิธีมาหาตัวแบบที่เหมาะสมที่สุดสำหรับข้อมูลปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติ ข้อมูลที่ใช้ในการศึกษานี้เป็นข้อมูลทุติยภูมิจากเว็บไซต์ Government Data Catalog Smart Plus เป็นข้อมูลรายเดือน ตั้งแต่เดือนมกราคม ปี 2018 ถึงเดือนธันวาคม ปี 2023 รวม 72 เดือน ข้อมูลถูกแบ่งออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลสำหรับสร้างตัวแบบ (Training Data) ซึ่งครอบคลุมช่วงเดือนมกราคม ปี 2018 ถึงเดือนธันวาคม ปี 2022 รวม 60 เดือน และชุดข้อมูลสำหรับทดสอบตัวแบบ (Testing Data) ครอบคลุมช่วงเดือนมกราคม ปี 2023 ถึงเดือนธันวาคม ปี 2023 รวม 12 เดือน เพื่อประเมินความสามารถของตัวแบบที่ได้ เกณฑ์ที่ใช้ในการเปรียบเทียบตัวแบบการพยากรณ์พิจารณาจากค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) โดยตัวแบบที่ให้ค่า MAPE ต่ำสุดจะถือเป็นตัวแบบที่เหมาะสมที่สุด จากผลการศึกษาพบว่า เทคนิค Random Forest เป็นวิธีการพยากรณ์ที่เหมาะสมกับข้อมูลมากที่สุด โดยให้ค่า MAPE ต่ำสุดเมื่อใช้กับข้อมูลปริมาณการผลิตและการนำเข้าก๊าซธรรมชาติในประเทศไทย ดังนั้น เทคนิคนี้จึงเป็นแนวทางที่มีประสิทธิภาพสำหรับการพยากรณ์ข้อมูลประเภทดังกล่าว

คำสำคัญ: การพยากรณ์, วิธีการปรับให้เรียบด้วยเอ็กซ์โปเนนเชียลของโฮลท์, วิธีบ็อกซ์–เจนกินส์, เทคนิคการเรียนรู้ของเครื่อง

การทำนายแนวโน้มของลูกค้าที่จะเลิกซื้อสินค้าธุรกิจพาณิชย์อิเล็กทรอนิกส์ โดยใช้เทคนิค Machine Learning

Predicting Customer Churn in E-Commerce Business Using Machine Learning Techniques

ศุภณาลัย ชัยชนะ* ธีราภรณ์ แก้วชฎา สุธาภรณ์ ปั้นจ้อย สถาพร เทพสัมฤทธิ์พร

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053620045@email.kmutnb.ac.th*)

บทคัดย่อ

การที่ลูกค้าไม่กลับมาซื้อสินค้าซ้ำหรือเลิกซื้อสินค้า (Customer Churn) เป็นปัญหาสำคัญที่ส่งผลกระทบโดยตรงต่อรายได้และความยั่งยืนของธุรกิจพาณิชย์อิเล็กทรอนิกส์ การวิเคราะห์หาสาเหตุของลูกค้าที่ตัดสินใจไม่กลับมาซื้อสินค้า (Churn analysis) เป็นวิธีการที่มีส่วนช่วยในการสนับสนุนเพื่อลดการสูญเสียรายได้และเพิ่มความสามารถในการรักษาฐานลูกค้าให้ยังคงซื้อสินค้าต่อไป การศึกษานี้ใช้เทคนิค Machine Learning เช่น Logistic Regression, Random Forest, XGBoost ในการทำนายลูกค้าที่มีแนวโน้มจะเลิกเลิกซื้อสินค้าจากข้อมูลพฤติกรรมการซื้อสินค้าของลูกค้าจากแหล่งข้อมูลสาธารณะ (Kaggle) ซึ่งเป็นข้อมูลแนวโน้มยอดขายและพฤติกรรมการซื้อสินค้าของลูกค้าในช่วงเวลาตั้งแต่เดือนธันวาคม ปี 2023 ถึงเดือนธันวาคม ปี 2024 โดยพิจารณาใช้ระยะเวลาที่ไม่มีการซื้อสินค้าในช่วง 180 วันและใช้แนวคิด RFM (Recency, Frequency, Monetary) เป็นเกณฑ์ในการจัดกลุ่มลูกค้าและเป็นคุณลักษณะในการฝึกฝนโมเดล Machine Learning ในการตรวจจับลูกค้าที่มีแนวโน้มจะเลิกซื้อสินค้า พบว่าข้อมูลมีความไม่สมดุล (Imbalanced Data) โดยกลุ่มลูกค้าที่มีแนวโน้มจะเลิกซื้อสินค้ามีจำนวนน้อยกว่ากลุ่มที่ยังคงซื้อสินค้าเป็นประมาณ 2 เท่า งานวิจัยนี้จึงเปรียบเทียบผลการทำนายระหว่างโมเดลที่ใช้ข้อมูลเดิมกับโมเดลที่ใช้เทคนิค SMOTE (Synthetic Minority Over-sampling Technique) เป็นเทคนิคที่ใช้ในการเพิ่มข้อมูลในชุดข้อมูลที่มีการกระจายของคลาสไม่สมดุล โดยสร้างตัวอย่างสำหรับคลาสที่มีจำนวนน้อย เพื่อดูว่าช่วยให้โมเดลมีความสามารถในการจำแนกคลาสที่มีข้อมูลจำนวนน้อยได้อย่างแม่นยำยิ่งขึ้นหรือลดลง ผลการทดลองแสดงให้เห็นว่าโมเดล XGBoost ให้ผลลัพธ์ที่มีประสิทธิภาพดีที่สุดและสามารถจัดการกับข้อมูลที่มีความไม่สมดุลได้ดีเมื่อเทียบกับโมเดลอื่นๆ เพื่อให้เจ้าของธุรกิจนำไปประยุกต์ใช้ในการวางแผนกลยุทธ์เพื่อรักษาลูกค้า เนื่องจากสินค้าส่วนมากเป็นสินค้าประเภทที่มีรอบการซื้อยาวนานแทนที่จะรอให้ลูกค้ากลับมาซื้อสินค้าหลักซ้ำ ธุรกิจสามารถเสนอขายสินค้าที่เกี่ยวข้องแทนเพื่อเพิ่มโอกาสในการกลับมาซื้อซ้ำเร็วขึ้น

คำสำคัญ: การเลิกซื้อสินค้า (Customer Churn), พาณิชย์อิเล็กทรอนิกส์ (E-Commerce), การวิเคราะห์ RFM, การเรียนรู้ของเครื่อง (Machine Learning), SMOTE (Synthetic Minority Over-sampling Technique)

เทคนิคการเรียนรู้เชิงลึกสำหรับการจำแนกค่าความหวาน ของส้มโอพันธุ์ทองดีโดยใช้การวิเคราะห์ภาพ

Deep Learning Technique for Classifying the Sweetness Of Thong Dee Pomelo Using Image Processing

ธัญชนก ปิญญามูล* ปิยภูมิ จันปันเมือง นภสร ระวิวรรณ ณัฐ์ชนิดา วงศ์ดาว พรดนัย กาศเกษม ลิมปพัทธ์ บุษบัน

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์มหาวิทยาลัยนเรศวร

(**thanchanokpi65@nu.ac.th*)

บทคัดย่อ

ปัญหาคุณภาพของส้มโอที่ไม่หวานเป็นอุปสรรคสำคัญต่อเกษตรกรและอุตสาหกรรมการส่งออก เนื่องจากเกษตรกรใช้ประสบการณ์ส่วนตัวในการประเมินคุณภาพของส้มโอ โดยอาศัยการสังเกตต่อมน้ำมันจากด้านข้างและด้านล่างของผล อย่างไรก็ตาม กระบวนการคัดแยกของโรงคัดและบรรจุผลไม้ยังคงต้องใช้การสุ่มตรวจเพื่อวัดค่าความหวาน หากพบว่าส้มโอไม่หวาน ส้มโอทั้งหมดในแข่งนั้นจะถูกคัดออกจากการส่งออก ส่งผลให้เกษตรกรเกิดความสูญเสียทางเศรษฐกิจ จากปัญหาดังกล่าว ผู้วิจัยจึงพัฒนาเครื่องมือช่วยเกษตรกรในการจำแนกความหวานของส้มโอโดยใช้เทคนิคการเรียนรู้เชิงลึกเพื่อเพิ่มความแม่นยำในการคัดเลือกส้มโอที่มีคุณภาพเหมาะสมต่อการส่งออก งานวิจัยนี้นำเสนอการใช้โมเดลการเรียนรู้แบบถ่าย เพื่อทำนายค่าความหวานของส้มโอพันธุ์ทองดีโดยอาศัยภาพถ่ายด้านข้างและด้านล่างของผลส้มโอจำนวน 108 ลูก โดยแบ่งข้อมูลเป็นชุดเรียนรู้ร้อยละ 70 ของข้อมูลทั้งหมด ชุดข้อมูลวัดผลร้อยละ 20 ของข้อมูลทั้งหมด และชุดทดสอบร้อยละ 10 ของข้อมูลทั้งหมด ผลการทดลองแสดงให้เห็นว่าโมเดลสามารถจำแนกค่าความหวานของส้มโอได้ค่าความแม่นยำร้อยละ 75 ผลลัพธ์ของงานวิจัยนี้สามารถช่วยลดความผิดพลาดในการคัดเลือกส้มโอ ลดความสูญเสียในการสุ่มตรวจคุณภาพ และเป็นแนวทางสำหรับเกษตรกรรายใหม่ในการตัดสินใจเลือกส้มโอสำหรับส่งไปยังโรงคัดและบรรจุผลไม้ นอกจากนี้ผู้วิจัยได้พัฒนาแชทบอทในแอปพลิเคชันไลน์สำหรับทำนายค่าความหวานของส้มโอเพียงผู้ใช้งานถ่ายภาพส้มโอส่งไปยังแชทบอทตัวแบบจะทำนายค่าความหวานของส้มโอได้

คำสำคัญ: โอพันธุ์ทองดี,การเรียนรู้เชิงลึก, โมเดลการเรียนรู้แบบถ่ายโอน

Prediction of Credit Card Defaults in Taiwan Based on Variable Selection Approach in Machine Learning Model

Siriprapa Tewee[1] Tanaporn Chaisinratham[1] Apichaya Buajee[1]
Lawitra Phanpanich[1] Siriyakon Saenpor[1] Chalermrat Nontapa[2*]
[1]*Data Science Research Center, Faculty of Science, Chiang Mai University*
[2]*Department of Statistic, Faculty of Science, Chiang Mai University*
(**chalermrat.n@cmu.ac.th*)

Abstract

This study aims to predict loan defaults using debtor behavior data from a Taiwanese bank, comprising 30,000 records available on Kaggle. Predicting loan default risk is important to financial institutions, as accurately predicting the likelihood of a borrower defaulting on their loans will help to reduce financial losses, thereby maintaining profitability and stability. The dataset includes key features such as credit amount, gender, education, marital status, age, monthly repayment status, billing statements, and repayment amounts from April to September 2005, along with the default status in the following month. To evaluate prediction performance, four machine learning models—Random Forest, XGBoost, CatBoost, and LightGBM. Each model represents a different approach to ensemble learning (e.g., bagging vs. boosting), which allows for a comprehensive comparison of their performance on the task at hand. These models were trained on 24,000 records and tested on 6,000. The results show that LightGBM also demonstrated strong performance in other metrics, with a Precision of 79.73%, Recall of 81.58%, and an F1-Score of 79.48%. LightGBM is the most effective model for predicting loan defaults, highlighting the advantages of gradient boosting techniques in credit risk assessment and financial decision-making.

คำสำคัญ: Loan Defaults, Financial, Variable Selection, LightGBM, XGBoost

การพัฒนาเว็บแอปพลิเคชันสำหรับการพยากรณ์ความเสี่ยงโรคเบาหวานด้วยการเรียนรู้ของเครื่อง

Development of Web Application for Predicting Diabetes Risk Using Machine Learning

สุกฤตา หงส์พิทักษ์นภา วรรณรดา มวลวงศ์* เกศมณี ปวุฒิพันธุ์ บุญกอง ทะกลโยธิน

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053630059@email.kmutnb.ac.th*)

บทคัดย่อ

โรคเบาหวานเป็นปัญหาสุขภาพระดับโลกมีการศึกษาวิจัยหาแนวทางที่มีประสิทธิภาพในการพยากรณ์เพื่อรักษาทันทีในระยะเริ่มต้น การพัฒนาโมเดลการเรียนรู้ของเครื่อง (Machine Learning) เพื่อพยากรณ์ความเสี่ยงของโรคเบาหวานได้โดยใช้ข้อมูลสุขภาพ เช่น ระดับน้ำตาลในเลือด ความดันโลหิต ค่าดัชนีมวลกาย และปัจจัยอื่นๆ โมเดลที่ใช้ได้แก่ Random Forest และ Logistic Regression ซึ่งได้ใช้ Feature Engineering และ Cross-validation เพื่อเพิ่มความแม่นยำ ดังนั้นเพื่อให้สามารถนำโมเดลที่พัฒนาขึ้นมาไปใช้ได้จริง ทางคณะผู้วิจัยได้พัฒนาเว็บแอปพลิเคชัน โดยมีวัตถุประสงค์เพื่อ 1) พัฒนาโมเดลการเรียนรู้ของเครื่องที่สามารถพยากรณ์ความเสี่ยงของการเป็นโรคเบาหวาน 2) เปรียบเทียบประสิทธิภาพของโมเดล Machine Learning ทั้ง 2 โมเดล ได้แก่ Random Forest และ Logistic Regression เพื่อเลือกโมเดลที่มีความแม่นยำ 3) พัฒนาเว็บแอปพลิเคชันที่ช่วยให้บุคคลทั่วไปสามารถป้อนข้อมูลสุขภาพและรับผลการพยากรณ์ได้สะดวกและรวดเร็ว งานวิจัยนี้ใช้ข้อมูลจาก PIMA Indian Diabetes Dataset จำนวน 767 รายการ จากการทดลองพบว่า โมเดล Random Forest มีความแม่นยำ (Accuracy) เท่ากับ 81.5% ซึ่งแสดงให้เห็นว่าโมเดลสามารถพยากรณ์ได้อย่างมีประสิทธิภาพ และค่าระดับน้ำตาลในเลือดมีผลต่อการพยากรณ์มากที่สุด ในส่วนของการพัฒนาเว็บแอปพลิเคชันใช้ภาษา Python และชุดคำสั่ง Streamlit ผลการประเมินเว็บแอปพลิเคชันพบว่า ผู้ใช้งานเว็บแอปพลิเคชันมีความพึงพอใจเฉลี่ยเท่ากับ 4.25 ซึ่งอยู่ในระดับมาก อย่างไรก็ตาม ข้อจำกัดของงานวิจัยคือข้อมูลที่ใช้มาจากประเทศอินเดีย ซึ่งอาจไม่สอดคล้องกับประชากรไทย ในอนาคตอาจใช้ข้อมูลของประเทศไทยเพื่อปรับปรุงความแม่นยำและการใช้งานจริง

คำสำคัญ: การเรียนรู้ของเครื่อง, โรคเบาหวาน, เว็บแอปพลิเคชันการแพทย์

การวิเคราะห์ปัจจัยที่ทำให้เกิดการทะเลาะวิวาท เพื่อป้องกันและแก้ไขปัญหาการใช้ความรุนแรงของนักศึกษาระดับอาชีวศึกษาในเขตมีนบุรี

Analysis of Factors Causing Social Conflicts to Prevent and Solve the Problem of Violence Among Vocational Students in Min Buri District

มนัญชยา ค้าของ[1] ทินัดดา สัจจะจิตรัตน์[1] ศวิษฐ์ การเร็ว[1*] โฆษิต บุญทวี[2] เพียรพูล กมลจิตร์ประภา[1] ปิยะฉัตร ลีลาศิลปศาสน์[1]

[1] *ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ*

[2]*กองบังคับการตำรวจนครบาล 3*

(**s630405163022@email.kmutnb.ac.th*)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์ปัจจัยที่ส่งผลต่อการเกิดเหตุทะเลาะวิวาทในกลุ่มนักศึกษาระดับประกาศนียบัตรวิชาชีพ (ปวช.) และ ประกาศนียบัตรวิชาชีพชั้นสูง (ปวส.) ในเขตมีนบุรี รวมถึงนำเสนอกลยุทธ์ในการป้องกันและแก้ไขปัญหาดังกล่าวอย่างเป็นระบบ การวิจัยนี้ใช้ ระเบียบวิธีวิจัยเชิงปริมาณ เก็บรวบรวมข้อมูลโดยทฤษฎีการสุ่มตัวอย่าง จำนวน 346 คน จากกลุ่มตัวอย่าง 3 กลุ่ม ประกอบด้วย 1) กลุ่มนักศึกษา ระดับ ปวช. และ ปวส. จำนวน 273 คน 2) กลุ่มครู-อาจารย์ จำนวน 5 คน จาก 3 สถาบัน ได้แก่ วิทยาลัยเทคนิคมีนบุรี วิทยาลัยเทคนิคกาญจนา ภิเษก มหานคร และโรงเรียนอาชีวะเอกชนมีนบุรีโปลีเทคนิค และ 3) บุคคลทั่วไปในเขตมีนบุรี จำนวน 68 คน ผ่านแบบสอบถามที่ได้รับการพัฒนาให้เหมาะสมกับบริบทของการศึกษา ข้อมูลที่ได้ถูกนำมาวิเคราะห์โดยใช้การทดสอบไคกำลังสอง (Chi-square Test) บนโปรแกรม IBM SPSS เพื่อประเมินความสัมพันธ์ระหว่างปัจจัยต่างๆ กับการเกิดเหตุทะเลาะวิวาท ผลการวิเคราะห์พบว่า การควบคุมอารมณ์ เป็นปัจจัยที่มีความสัมพันธ์กับ พฤติกรรมทะเลาะวิวาทของนักศึกษาอย่างมีนัยสำคัญทางสถิติ ($p\text{-value} < 0.1$) นอกจากนี้ยังพบว่า ปัจจัยด้านอิทธิพลของกลุ่มเพื่อน ปัญหาครอบครัว และสภาพแวดล้อมในสถานศึกษา มีผลต่อแนวโน้มการเกิดพฤติกรรมรุนแรง โดยอิทธิพลของกลุ่มเพื่อนมีระดับอิทธิพลสูงสุด รองลงมาคือ การ ควบคุมอารมณ์ และปัญหาครอบครัว และจากการวิจัยเชิงคุณภาพพบว่า การใช้ "มีนบุรีโมเดล" ซึ่งเป็นแนวทางเชิงบูรณาการในการป้องกันและลด ปัญหาความรุนแรงในกลุ่มนักศึกษา โดยมีองค์ประกอบหลัก ได้แก่ 1) การพัฒนาทักษะการควบคุมอารมณ์ของนักศึกษา 2) การจัดกิจกรรมเสริม สร้างความเข้าใจและการอยู่ร่วมกันอย่างสันติ และ 3) การสร้างความร่วมมือระหว่างสถานศึกษา ครอบครัว และชุมชน เป็นกลยุทธ์เชิงป้องกันที่มี ประสิทธิภาพในการลดความรุนแรงในสถานศึกษาและลดจำนวนการทะเลาะวิวาทของนักศึกษาได้อย่างเป็นรูปธรรมและยั่งยืน

คำสำคัญ: การใช้ความรุนแรง, การแก้ปัญหาการทะเลาะวิวาท, การควบคุมอารมณ์, การวิเคราะห์ไคกำลังสอง, มีนบุรีโมเดล

การวิเคราะห์ปัจจัยเสี่ยงที่ส่งผลต่อการเกิดโรคซึมเศร้าของผู้ป่วย ในโรงพยาบาลบุรีรัมย์โดยใช้ตัวแบบการถดถอยลอจิสติก

Analysis of Risk Factors Affecting Depression in Patients at Buriram Hospital Using the Logistic Regression Model

ศิตวิษา อาจบุราย* วณิชยา ทาหอม ประถมาพร พิมเสน นวลพรรณ ลอว์สัน อุไรวรรณ เจริญกีรติกุล

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**sitaling2545@gmail.com*)

บทคัดย่อ

โรคซึมเศร้าเป็นปัญหาสุขภาพจิตที่สำคัญในระดับโลก และส่งผลกระทบอย่างมากต่อคุณภาพชีวิตของผู้ป่วย อย่างไรก็ตาม ในปัจจุบันยังไม่มีรูปแบบกรมธรรม์ที่รองรับสำหรับผู้ป่วยโรคซึมเศร้า งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์ปัจจัยเสี่ยงที่ส่งผลต่อการเกิดโรคซึมเศร้าของผู้ป่วยในโรงพยาบาลบุรีรัมย์ เพื่อนำไปใช้เป็นแนวทางในการออกแบบกรมธรรม์สำหรับผู้ป่วยโรคซึมเศร้าโดยทำนายการเป็นโรคซึมเศร้าด้วยตัวแบบการถดถอยลอจิสติก (Logistic Regression) ข้อมูลที่ใช้ในการศึกษานี้ ได้แก่ ข้อมูลผู้ป่วยจากเวชระเบียนของโรงพยาบาลบุรีรัมย์ ระหว่างวันที่ 1 ตุลาคม 2566 – 30 กันยายน 2567 จำนวน 5,684 คน ตัวแปรตาม ได้แก่ โมเดลการวิเคราะห์การถดถอยลอจิสติกแบบทวิภาค (Binary Outcome) ที่ตัวแปรเกณฑ์ มี 2 ค่า คือ การเป็นและไม่เป็นโรคซึมเศร้า ตัวแปรอิสระที่นำมาวิเคราะห์ ได้แก่ ปัจจัยด้านประชากรศาสตร์ พฤติกรรมสุขภาพ สภาพแวดล้อม และปัจจัยทางจิตวิทยา โดยข้อมูลถูกเก็บรวบรวมจากกลุ่มประชากรที่เข้ารับการรักษาภายในโรงพยาบาลบุรีรัมย์ ผลการวิเคราะห์พบว่า ปัจจัยที่มีอิทธิพลต่อการเกิดโรคซึมเศร้า ได้แก่ เพศ อายุ สิทธิ์การรักษา การป่วยเป็นโรคมะเร็ง ความพิการ การออกกำลังกาย สภาวะครอบครัว ความกังวล และประวัติซึมเศร้าในครอบครัว โดยโมเดลมีค่าความถูกต้อง (Accuracy) เท่ากับ 85.7% โดยจากตัวแบบการถดถอยลอจิสติกที่ได้นั้น ได้นำไปใช้ในการคำนวณค่าโอกาสการเกิดโรคซึมเศร้า และนำไปใช้เป็นแนวทางในการสร้างกรมธรรม์สำหรับผู้ป่วยโรคซึมเศร้าเพื่อเป็นประโยชน์สำหรับผู้ป่วยที่จะได้รับกรมธรรม์ในการคุ้มครองและเพื่อเป็นแนวทางให้ธุรกิจประกันภัยในการสร้างกรมธรรม์สำหรับผู้ป่วยได้

คำสำคัญ: ตัวแบบการถดถอยลอจิสติก, การวิเคราะห์ปัจจัยเสี่ยง, โรคซึมเศร้า

การวิเคราะห์การถดถอยพหุคูณเพื่อพยากรณ์ปริมาณการใช้พลังงานขั้นสุดท้ายในภาคอุตสาหกรรมการผลิต

Multiple Regression Analysis for Forecasting Final Energy Consumption in the Manufacturing Industry Sector

สิรารมย์ ฉายเกียรติคุณ* มิ่งขวัญ ชูมัง พิมพ์มาดา แสงเจริญ จีรภา สรรพกิจกำจร

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620297@email.kmutnb.ac.th*)

บทคัดย่อ

โครงงานพิเศษนี้มีวัตถุประสงค์เพื่อศึกษาปัจจัยที่มีผลต่อปริมาณการใช้พลังงานขั้นสุดท้ายซึ่งเป็นพลังงานที่ผ่านการแปรรูปมาแล้ว และพร้อมใช้งานในภาคอุตสาหกรรมการผลิตของประเทศไทย และหาตัวแบบการถดถอยพหุคูณที่เหมาะสมในการพยากรณ์ปริมาณการใช้พลังงานขั้นสุดท้ายในภาคอุตสาหกรรมการผลิต ข้อมูลที่ใช้เป็นข้อมูลรายปีตั้งแต่ พ.ศ. 2536 ถึง พ.ศ. 2565 โดยพิจารณาแหล่งพลังงานหลัก ได้แก่ พลังงานไฟฟ้า น้ำมันสำเร็จรูป ก๊าซธรรมชาติ ถ่านหิน พลังงานหมุนเวียน และพลังงานทดแทน การวิเคราะห์หาตัวแบบใช้วิธีถดถอยพหุคูณ (Multiple Regression) พร้อมตรวจสอบปัญหาความสัมพันธ์เชิงเส้นพหุ (Multicollinearity) ด้วย Variance Inflation Factor (VIF) และคัดเลือกตัวแปรโดยใช้ Stepwise Regression จากตัวแปรอิสระ 6 ตัวแปร พบว่า ตัวแปรที่มีอิทธิพลต่อปริมาณการใช้พลังงานขั้นสุดท้ายอย่างมี 3 ตัวแปร คือ พลังงานไฟฟ้า น้ำมันสำเร็จรูป และพลังงานหมุนเวียน การเลือกตัวแบบที่เหมาะสมพิจารณาจากเกณฑ์ Akaike's Information Criterion (AIC) และทดสอบความแม่นยำของตัวแบบในการพยากรณ์โดยใช้ข้อมูล 5 ปีล่าสุด เพื่อประเมินค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error : MAPE) ของค่าพยากรณ์ ผลการศึกษาชี้ให้เห็นว่าตัวแบบที่ได้การวิเคราะห์มีประสิทธิภาพในการพยากรณ์ปริมาณการใช้พลังงานขั้นสุดท้ายในภาคอุตสาหกรรมการผลิต สามารถนำไปใช้เป็นแนวทางในการวางแผนสำรองพลังงานขั้นสุดท้ายเพื่อใช้ในภาคอุตสาหกรรมการผลิตของประเทศไทยต่อไป

คำสำคัญ: การใช้พลังงานขั้นสุดท้าย, ภาคอุตสาหกรรมการผลิต, การถดถอยพหุคูณ, Variance Inflation Factor (VIF), Stepwise Regression, Akaike's Information Criterion (AIC)

เทคโนโลยีสารสนเทศสำหรับผู้บริหารฝ่ายขายทางโทรศัพท์

Information Technology for Telesales Executives

ณัฐพงศ์ คงนารา* อุไรวรรณ เจริญกีรติกุล

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052630039@email.kmutnb.ac.th*)

บทคัดย่อ

ในการแข่งขันทางธุรกิจของยุคดิจิทัล กลยุทธ์การบริหารจัดการทรัพยากรและข้อมูลอย่างมีประสิทธิภาพ รวดเร็วทันต่อสถานการณ์เป็นสิ่งที่ผู้บริหารให้ความสำคัญ โดยเฉพาะธุรกิจประกันภัยในฝ่ายขายทางโทรศัพท์ (Telesales) ซึ่งต้องเข้าถึงลูกค้าที่ตรงเป้าหมาย การนำเทคโนโลยีสารสนเทศมาประยุกต์ใช้ในการเชื่อมโยงข้อมูลจากหลากหลายแหล่ง จะช่วยให้ได้ข้อมูลเชิงลึกเพื่อที่จะวิเคราะห์ถึงแนวโน้มตลาดและประเมินสถานการณ์ได้ทันท่วงที โดยในงานวิจัยนี้มีวัตถุประสงค์เพื่อออกแบบโครงสร้างสำหรับฐานข้อมูลที่ใช้เชื่อมโยงข้อมูลจากหลายแหล่งอย่างมีระบบที่ลดความซ้ำซ้อนของข้อมูลและพัฒนา Dashboard ที่ใช้เป็นเครื่องมือในการติดตามผลดำเนินงานของทีม Telesales วิเคราะห์แนวโน้มการเติบโตของยอดขาย และสามารถอัปเดตข้อมูลได้ การวิจัยนี้ใช้ข้อมูลที่รวบรวมจากบริษัทประกันภัยแห่งหนึ่งช่วงระยะเวลา ตั้งแต่ มกราคม 2564 ถึง มิถุนายน 2567 ประกอบด้วยข้อมูล ส่วนของลูกค้าที่ทีมขายติดต่อ ลูกค้าที่สามารถปิดการขายได้ ลูกค้าที่ยกเลิกกรมธรรม์ และเป้าหมายในแต่ละเดือนของทีม Telesales ระบบถูกพัฒนาโดยใช้ Microsoft Excel Google Sheets และ Tableau ในการบริหารจัดการข้อมูล วิเคราะห์ และออกแบบ Dashboard ตามความต้องการของผู้ใช้งานจากการสัมภาษณ์ในฝ่ายขายผลของการวิจัยพบว่าได้ฐานข้อมูลที่คำนึงถึงการเชื่อมโยงข้อมูลในหลาย ๆ แหล่งที่อำนวยความสะดวกในการประมวลผลและ Dashboard ที่แสดงถึงผลวิเคราะห์ข้อมูลในเชิงลึกทั้งพฤติกรรมลูกค้า ตัวชี้วัดสำคัญ (KPIs) เช่น อัตราการปิดการขาย อัตราการ โทรติดต่อลูกค้า ในการติดตามผลดำเนินงานของทีม Telesales รวมทั้งแนวโน้มเติบโตของยอดขาย และสามารถอัปเดตข้อมูลได้ ช่วยให้ผู้ใช้งานสามารถเข้าถึงข้อมูลสำคัญได้ในหน้าจอเดียวซึ่งลดเวลาจากระบบเดิมที่เข้าถึงข้อมูลได้เพียงทีละค่าและทำให้สามารถ วิเคราะห์ข้อมูลในหลายมิติพร้อมกัน เช่น การเปรียบเทียบแนวโน้มยอดขายรายเดือน ตัวชี้วัดประสิทธิภาพของพนักงานขาย และอัตราการปิดการขาย โดยเป็นเครื่องมือที่ให้สารสนเทศที่ตอบรับอย่างทันท่วงทีต่อสถานการณ์ที่เปลี่ยนแปลงอย่างรวดเร็วและเพียงพอสำหรับสนับสนุนการตัดสินใจเชิงกลยุทธ์ให้กับผู้บริหารฝ่ายขายทางโทรศัพท์

คำสำคัญ: ฝ่ายขายทางโทรศัพท์, ตัวชี้วัดสำคัญ, เทคโนโลยีสารสนเทศ

การพยากรณ์ปริมาณงานและการจัดสรรจำนวนพนักงานอย่างเหมาะสมด้วยเทคนิค LSTM

Workload Forecasting and Porter Resource Optimization Using LSTM Technique

ณัฐณิชา คมขำ* ยุภารัตน์ ช้างจันทร์ สุภาวดี เจริญมิตรมงคล วิกานดา ผาพันธ์ ชนนิกานต์ รอดมรณ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053630148@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลในการพยากรณ์ปริมาณงานและเวลาที่ใช้ในการดำเนินงาน (Completion Time) ที่คาดว่าจะเกิดขึ้นล่วงหน้า 1 สัปดาห์ โดยนำข้อมูลจำลองย้อนหลัง 4 เดือน แบ่งข้อมูลเดือนมกราคม-มีนาคม เป็นชุดข้อมูลฝึกและเดือนเมษายนถูกแบ่งเป็นชุดข้อมูลทดสอบ ในอัตราสัดส่วน 75 ต่อ 25 ตามแนวทาง Time-based Hold-out Validation ข้อมูลเหล่านี้ประกอบด้วยรายละเอียดต่างๆ เช่น สถานที่รับ - ส่งผู้ป่วย, เวลาในการรับ - ส่งผู้ป่วย และระยะเวลาดำเนินการของงาน จะนำมาวิเคราะห์เพื่อให้สามารถคาดการณ์ปริมาณงานที่จะเกิดขึ้นและเวลาที่ต้องใช้ในการดำเนินงานในแต่ละสถานที่หรือแผนกล่วงหน้า 1 สัปดาห์ด้วยเทคนิคการเรียนรู้เชิงลึกโดยใช้โมเดล Long Short-Term Memory (LSTM) ที่พยากรณ์ได้แม่นยำที่สุด มีค่าความผิดพลาดเปอร์เซนต์สัมบูรณ์ (MAPE) อยู่ที่ 24.22% เมื่อเทียบกับโมเดล ARIMA (45.24%) และ ForecasterAutoreg (29.42%) อย่างไรก็ตามเมื่อนำโมเดลไปทดสอบกับข้อมูลของทั้ง 3 ฮับพบว่ามีค่าความคลาดเคลื่อนสมบูรณ์ (%MAE) เฉลี่ยอยู่ที่ 56.67% ซึ่งสะท้อนให้เห็นถึงความแตกต่างของความสัมพันธ์ระหว่างแผนก ทั้งนี้ LSTM สามารถเรียนรู้ความสัมพันธ์ของข้อมูลในอดีตและระยะเวลาที่งานเกิดขึ้นอย่างต่อเนื่องและนำมาเป็นเครื่องมือในการช่วยให้ผู้จัดการเวรเปลสามารถวางแผน การจัดสรรพนักงานเวรเปล (Porter) ได้อย่างมีประสิทธิภาพ โดยโมเดลจะนำเสนอผลลัพธ์ในรูปแบบรายงานที่ประกอบด้วยตารางและแผนภูมิที่แสดงถึงปริมาณงานและเวลาที่ต้องใช้ในการดำเนินงานที่คาดว่าจะเกิดขึ้นในสัปดาห์ข้างหน้า พร้อมทั้งประเมินจำนวนพนักงานเวรเปลที่ต้องการในแต่ละสถานที่หรือแผนกเพื่อให้การจัดสรรพนักงานเวรเปลสามารถรองรับความต้องการในแต่ละช่วงเวลาได้อย่างเหมาะสม

คำสำคัญ: การพยากรณ์ปริมาณงาน,การวางแผนกำลังคน, เวรเปล , Long Short-Term Memory

การออกแบบแผนการทดลองแบบจัตุรัสละตินโดยใช้โปรแกรม R

Latin Square Design in R

ธิติรัตน์ เรืองศรี* อาริสญา ภุมรินทร์ อมรา อึ้งชัยเจริญ สุวิมล พันธ์แย้ม

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620033@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแพคเก็จสำหรับการออกแบบและวิเคราะห์ข้อมูลภายใต้แผนการทดลองแบบจัตุรัสละติน (Latin Square Design) ซึ่งแพคเก็จดังกล่าวนี้สามารถแสดงผลลัพธ์พร้อมกันได้ในคำสั่งเดียว โดยทำการตรวจสอบข้อตกลงเบื้องต้นของการวิเคราะห์ความแปรปรวน ได้แก่ การตรวจสอบการแจกแจงปกติ (Assumption of Normality) การตรวจสอบความเท่ากันของความแปรปรวน (Homogeneity of Variance Assumption) และการตรวจสอบความเป็นอิสระของความคลาดเคลื่อน (Assumption of Independent) แพคเก็จนี้สามารถวิเคราะห์ข้อมูลในกรณีที่มีจำนวนทรีทเมนต์ 4 ทรีทเมนต์ จำนวนบลอคทางแถว 4 แถว จำนวนบลอคทางคอลัมน์ 4 คอลัมน์ ซึ่งการวิเคราะห์ถูกนำเสนอในรูปของตารางวิเคราะห์ความแปรปรวน (Analysis of Variance) นอกจากนี้ผู้วิจัยได้ตรวจสอบความถูกต้องของผลการวิเคราะห์ข้อมูลโดยทำการเปรียบเทียบผลลัพธ์ที่ได้กับฟังก์ชันที่มีอยู่ใน R และโปรแกรม SPSS ผลการวิจัยพบว่าผลการวิเคราะห์ข้อมูลจากแพคเก็จที่พัฒนาขึ้นมาใหม่ในภาษา R ทำให้ผลลัพธ์มีความแม่นยำซึ่งมีค่าเท่ากับการประมวลผลโดยการใช้ฟังก์ชันที่มีอยู่ใน R และโปรแกรม SPSS อีกทั้งโปรแกรม R มีรูปแบบ Freeware ช่วยให้บุคคลทั่วไปสามารถวิเคราะห์ข้อมูลได้ง่ายขึ้น แต่ความถูกต้องของการวิเคราะห์และการเลือกใช้ข้อมูลยังต้องอาศัยความเข้าใจทางสถิติ

คำสำคัญ: แผนการทดลองแบบจัตุรัสละติน, การแจกแจงปกติ, การวิเคราะห์ความแปรปรวน

การเปรียบเทียบประสิทธิภาพแผนภูมิควบคุม $DEWMA_{AIB}$, $AEWMA_{AIB}$ และ $HEWMA_{AIB}$

Performance Comparison of Control Chart: $DEWMA_{AIB}$, $AEWMA_{AIB}$ and $HEWMA_{AIB}$

ญาณิศา ตระกูลกำเนิด* ณัชชา อาจวงษ์ษา สิเรียม จูมจัตุรัส สุวิมล พันธ์แย้ม

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052630152@email.kmutnb.ac.th*)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม 3 แผนภูมิ ได้แก่ แผนภูมิควบคุม Double $EWMA_{AIB}$ ($DEWMA_{AIB}$) แผนภูมิควบคุม Adaptive $EWMA_{AIB}$ ($AEWMA_{AIB}$) และแผนภูมิควบคุม Hybrid $EWMA_{AIB}$ ($HEWMA_{AIB}$) เพื่อตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการภายใต้สถานการณ์ที่แตกต่างกัน คือ แผนภูมิควบคุม $DEWMA_{AIB}$ ใช้แนวคิดของแผนภูมิ EWMA สองครั้งเพื่อเพิ่มความสามารถในการตรวจจับความผิดปกติ สำหรับแผนภูมิควบคุม $AEWMA_{AIB}$ สามารถปรับค่าพารามิเตอร์ปรับให้เรียบอัตโนมัติเพื่อเพิ่มประสิทธิภาพการตรวจจับ และแผนภูมิควบคุม $HEWMA_{AIB}$ เป็นแผนภูมิควบคุมที่ผสมผสานทั้งสองแนวคิดเพื่อเพิ่มความแม่นยำในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ การศึกษานี้ใช้เทคนิคการจำลองมอนติคาร์โล (Monte Carlo Simulation) เพื่อประเมินประสิทธิภาพ ซึ่งเกณฑ์ที่ใช้ในการเปรียบเทียบประสิทธิภาพของแผนภูมิ ได้แก่ ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) ในการจำลองข้อมูลด้วยเทคนิคมอนติคาร์โลทำซ้ำ 1,000 ครั้ง เมื่อข้อมูลมีการแจกแจงแบบปกติ โดยกำหนดระดับการเปลี่ยนแปลงค่าเฉลี่ย (Shift size) เท่ากับ 0.00, 0.01,…, 0.1, 0.2,…, 1.0, 2.0 และ 3.0 กำหนดขนาดตัวอย่าง n = 3 และ 30 และกำหนดค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370 จากผลการศึกษาพบว่า แผนภูมิควบคุม $HEWMA_{AIB}$ ให้ค่า ARL ต่ำที่สุด ซึ่งหมายถึงสามารถตรวจจับการเปลี่ยนแปลงขนาดเล็ก เช่นระดับการ shift 0.10 -0.50 นอกจากนี้ การนำข้อมูลเสริม (Auxiliary Information-Based: AIB) มาใช้จะช่วยเพิ่มความสามารถในการตรวจจับความผิดปกติได้ดียิ่งขึ้น

คำสำคัญ: Double EWMA, Adaptive EWMA, Hybrid EWMA, Monte Carlo Simulation, Auxiliary Information-Based

การเปรียบเทียบประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการโดยอิงตามแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเลขชี้กำลังและส่วนขยาย

Comparison of the Efficiency of Detecting Changes in Process Mean Based on Exponentially Weighted Moving Average and Extended Part Control Charts

ทิฐิพล พ่วงพุก* กันยารัก จันทรประสาท ยศวดี พุทธานุ เสาวณิต สุขภารังษี

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052610046@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการระหว่างแผนภูมิควบคุม EWMA (Exponentially Weighted Moving Average Control Chart) แผนภูมิควบคุม MEWMA (Modified Exponentially Weighted Moving Average Control Chart) แผนภูมิควบคุม EEWMA (Extended Exponentially Weighted Moving Average Control Chart) และแผนภูมิควบคุม NEEWMA (New Extended Exponentially Weighted Moving Average Control Chart) ซึ่งข้อมูลที่ใช้ในการเปรียบเทียบมีการแจกแจงปรกติ (Normal Distribution) การแจกแจงปรกติปนเปื้อน (Contaminated Normal Distribution) การแจกแจงลาปลาซ (Laplace Distribution) การแจกแจงแบบเลขชี้กำลัง (Exponential Distribution) และการแจกแจงล็อกนอร์มัล (Log-Normal Distribution) ในการเปรียบเทียบประสิทธิภาพการตรวจจับค่าเฉลี่ยของกระบวนการของแผนภูมิควบคุมจะวัดได้จากค่าความยาวรันเฉลี่ย (Average Run Length: ARL) โดยกำหนดค่าความยาวรันเฉลี่ย เมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370 500 และ 1,000 ทำการจำลองซ้ำ 10,000 รอบ และขนาดของตัวอย่าง เท่ากับ 10 ทำการจำลองเพื่อให้ได้ค่าความยาวรันเฉลี่ย เมื่อกระบวนการอยู่นอกเหนือการควบคุม (ARL_1) ผลการวิจัยพบว่าข้อมูลที่มีการแจกแจงปรกติ การแจกแจงปรกติปนเปื้อน การแจกแจงลาปลาซ การแจกแจงแบบเลขชี้กำลัง และการแจกแจงล็อกนอร์มัล แผนภูมิควบคุมที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงที่ดีที่สุดของทั้ง 5 การแจกแจงนี้ คือ แผนภูมิควบคุม NEEWMA และเมื่อนำไปประยุกต์ใช้กับข้อมูลจริงผลออกมาว่า แผนภูมิควบคุม NEEWMA สามารถตรวจจับการเปลี่ยนแปลงได้รวดเร็วที่สุด ดังนั้นจึงสรุปได้ว่า แผนภูมิควบคุม NEEWMA เป็นแผนภูมิควบคุมที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการได้ดีที่สุด

คำสำคัญ: แผนภูมิควบคุม MEWMA, แผนภูมิควบคุม EEWMA, แผนภูมิควบคุม NEEWMA, การแจกแจงปรกติปนเปื้อน, ค่าความยาวรันเฉลี่ย

การพยากรณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ ในกระบวนการผลิตไฟฟ้าจากก๊าซธรรมชาติ

Forecasting Carbon Dioxide Emissions In the Production of Electricity from Natural Gas

กิตติพศ อติเรกวุฒิ* นุศรา บุญโท ปวริศร์ แย้มนาม ศิรประภา มโนมัธย์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620092@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ (CO_2) จากการใช้ก๊าซธรรมชาติ (Natural Gas) สำหรับการผลิตไฟฟ้าในประเทศไทย โดยเก็บข้อมูลการปล่อยก๊าซ CO_2 ในช่วงปี 1987-2024 ซึ่งเป็นข้อมูลทุติยภูมิแบบอนุกรมเวลาจากศูนย์กลางข้อมูลเปิดภาครัฐ (Open Government Data) แบ่งข้อมูลสำหรับการสร้างตัวแบบและทดสอบตัวแบบพยากรณ์ด้วยวิธีการแบ่งข้อมูลอนุกรมเวลา (Time Serie Split) วิเคราะห์ข้อมูลด้วยตัวแบบ SARIMA (Seasonal Auto Regressive Integrated Moving Average) และเทคนิคโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron Technique) ใช้ฟังก์ชันถ่ายโอน (Activation Function) คือ Leaky ReLU ประมวลผลโดยใช้โปรแกรม Python เกณฑ์ในการพิจารณาประสิทธิภาพตัวแบบ ได้แก่ รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error; RMSE) และเปอร์เซ็นต์ของค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error; MAPE) ผลการวิจัยพบว่า เทคนิคโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Neural Network) แบบมีชั้นซ่อน (Hidden Layer) 6 ชั้น มีประสิทธิภาพในการพยากรณ์ดีที่สุด ซึ่งผลจากการพยากรณ์นี้สามารถนำไปใช้ในการวางแผนเชิงนโยบายในการลดปริมาณคาร์บอนไดออกไซด์ ซึ่งเป็นสาเหตุของการเกิดมลพิษทางอากาศ

คำสำคัญ: การพยากรณ์, ตัวแบบ SARIMA, เทคนิคโครงข่ายประสาทเทียม

การพยากรณ์ความต้องการพลังงานไฟฟ้าในประเทศไทย

Forecasting Energy Demand in Thailand

สุธิชา เหลืองรุ่งรัส* ธันย์ชนก ก้อนนคร ภูมิภัทร ภัทรภูวนัตถ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052610101@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีในการพยากรณ์ความต้องการพลังงานไฟฟ้าในประเทศไทย สำหรับเป็นแนวทางการวางแผนการผลิต การจัดซื้อ การจัดหาแหล่งพลังงานให้เพียงพอต่อความต้องการของผู้ใช้ ข้อมูลที่ใช้มาจากรายงานสถิติพลังงานของประเทศไทย สำนักงานนโยบายและแผนพลังงาน กระทรวงพลังงาน เป็นข้อมูลปริมาณความต้องการพลังงานไฟฟ้าในประเทศไทย ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนพฤศจิกายน พ.ศ. 2567 จำนวน 71 เดือน โดยงานวิจัยนี้ใช้วิธีการพยากรณ์เดี่ยว 3 วิธี ได้แก่ วิธีถดถอยอนุกรมเวลา วิธีปรับให้เรียบแบบเลขชี้กำลัง วิธีบอกซ์-เจนกินส์ และวิธีการพยากรณ์ร่วม 2 วิธี ได้แก่ วิธีการให้น้ำหนักที่เท่ากัน วิธีความคลาดเคลื่อนกำลังสองเฉลี่ยผกผัน ซึ่งทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ ชุดที่ 1 ใช้สำหรับสร้างตัวแบบพยากรณ์ ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ. 2566 จำนวน 60 เดือน และชุดที่ 2 เป็นชุดข้อมูลสำหรับเปรียบเทียบความเหมาะสมของตัวแบบพยากรณ์ ตั้งแต่เดือนมกราคม ถึงเดือนพฤศจิกายน พ.ศ. 2567 จำนวน 11 เดือน เกณฑ์ที่ใช้ในการเปรียบเทียบพิจารณาจากค่าเบี่ยงเบนสัมบูรณ์เฉลี่ย, ค่าคลาดเคลื่อนกำลังสองเฉลี่ย และค่าคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย โดยวิธีการพยากรณ์ที่ให้ค่า MAD, MSE และ MAPE ต่ำที่สุด ถึงเป็นวิธีการพยากรณ์ที่เหมาะสมมากสุด ผลการวิจัย พบว่า วิธีปรับให้เรียบแบบเลขชี้กำลัง เป็นตัวแบบพยากรณ์ปริมาณความต้องการพลังงานไฟฟ้าในประเทศไทยที่เหมาะสมที่สุด

คำสำคัญ: Energy demand, Individual Forecast, Combined Forecast, mean absolute deviation, mean squared error, mean absolute percent error

การเปรียบเทียบวิธีการพยากรณ์มูลค่าการส่งออกสิ่งทอและเครื่องนุ่งห่ม

A Comparison of Prediction Methods for Export Value of Textile & Clothing

ปัทมาพร เนตรหิน* ณภัทร สุริเย น้ำริน สุนทวัฒโรดม จีรภา สรรพกิจกำจร

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404051610026@email.kmutnb.ac.th*)

บทคัดย่อ

อุตสาหกรรมสิ่งทอและเครื่องนุ่งห่มมีความสำคัญต่อระบบเศรษฐกิจของประเทศไทย อุตสาหกรรมนี้นอกจากจะสร้างมูลค่าเพิ่มให้แก่ประเทศไทยได้สูงที่สุดแล้ว ยังสร้างรายได้จากการส่งออกเป็นอันดับต้นๆ ของประเทศไทยอีกด้วย การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีการพยากรณ์ที่ใช้สร้างตัวแบบสำหรับพยากรณ์มูลค่าการส่งออกสิ่งทอและเครื่องนุ่งห่ม ด้วยการเปรียบเทียบประสิทธิภาพของตัวแบบที่ได้จากวิธีการพยากรณ์เดี่ยว 2 วิธี คือ วิธีบอกซ์-เจนกินส์ (Box-Jenkins Method) และวิธีการปรับเรียบแบบเอกซ์โพเนนเชียล (Exponential smoothing Method) และวิธีการพยากรณ์ร่วม 3 วิธี คือ วิธีค่าเฉลี่ยถ่วงน้ำหนักเท่ากัน (Equal Weighted Average Method) วิธีถ่วงน้ำหนักผกผันค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Inverse Mean Squared Error Method) และวิธีสัมประสิทธิ์สหสัมพันธ์เพียร์สัน (Pearson's Correlation Coefficient Method) โดยใช้โปรแกรม IBM SPSS 25 และโปรแกรม Microsoft Excel ในการสร้างตัวแบบพยากรณ์จากวิธีการพยากรณ์แต่ละวิธี และใช้เกณฑ์ค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error) ในการวัดประสิทธิภาพของตัวแบบพยากรณ์ สำหรับข้อมูลที่ใช้รวบรวมจากธนาคารแห่งประเทศไทย ตั้งแต่เดือนมกราคม ปี พ.ศ. 2562 ถึง เดือนธันวาคม ปี พ.ศ. 2567 จำนวน 72 ค่า แบ่งข้อมูลออกเป็น 2 ส่วน โดยส่วนที่ 1 สำหรับสร้างตัวแบบพยากรณ์ ใช้ข้อมูลตั้งแต่เดือนมกราคม ปี พ.ศ. 2562 ถึง เดือนธันวาคม ปี พ.ศ. 2566 จำนวน 60 ค่า และส่วนที่ 2 สำหรับวัดประสิทธิภาพของตัวแบบพยากรณ์ ใช้ข้อมูลตั้งแต่เดือนมกราคม ถึง เดือนธันวาคม ปี พ.ศ. 2567 จำนวน 12 ค่า โดยลักษณะของข้อมูลมีแนวโน้มและไม่มีฤดูกาล ผลจากการศึกษาพบว่าวิธีบอกซ์-เจนกินส์ ให้ตัวแบบ ARIMA(2,1,0)(0,0,0) ซึ่งเป็นตัวแบบที่มีความแม่นยำสูงสุดในการพยากรณ์มูลค่าการส่งออกสิ่งทอและเครื่องนุ่งห่ม

คำสำคัญ: การพยากรณ์, วิธีบอกซ์-เจนกินส์, วิธีการปรับเรียบแบบเอกซ์โพเนนเชียล, วิธีการพยากรณ์, ค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์

การพยากรณ์ปริมาณฝุ่น PM 2.5 ในจังหวัดเชียงใหม่โดยใช้วิธีบอกซ์-เจนกินส์

Forecasting PM 2.5 Levels in Chiang Mai Province with Box-Jenkins Method

ศิริอำไพ โรจน์บุญถึง จณิสตา กุลเกี้ยง* กชพร การุณ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร

(**janistak65@nu.ac.th*)

บทคัดย่อ

การศึกษาครั้งนี้มีวัตถุประสงค์เพื่อสร้างตัวแบบที่เหมาะสมสำหรับการพยากรณ์ปริมาณฝุ่น PM 2.5 ในจังหวัดเชียงใหม่ ด้วยวิธีบอกซ์-เจนกินส์ (Box-Jenkins Method) เนื่องจากฝุ่นละอองขนาดเล็กนี้ส่งผลกระทบต่อสุขภาพของประชาชน โดยเฉพาะกลุ่มเสี่ยง เช่น เด็ก ผู้สูงอายุ และผู้ที่มีโรคทางเดินหายใจ อีกทั้งยังมีผลกระทบต่อเศรษฐกิจและการท่องเที่ยวของจังหวัดเชียงใหม่ ข้อมูลอนุกรมเวลาที่ใช้มาจากเว็บไซต์ของกองจัดการคุณภาพอากาศและเสียง ภายใต้กรมควบคุมมลพิษ เป็นข้อมูลรายเดือนตั้งแต่เดือนมกราคม พ.ศ. 2560 ถึงเดือนตุลาคม พ.ศ. 2567 จำนวน 94 เดือน โดยแบ่งข้อมูลออกเป็น 2 ชุด ดังนี้ ชุดที่ 1 ตั้งแต่เดือนมกราคม พ.ศ. 2560 ถึงเดือนธันวาคม พ.ศ. 2566 จำนวน 84 เดือน ใช้สำหรับการสร้างตัวแบบพยากรณ์ และชุดที่ 2 ตั้งแต่เดือนมกราคม พ.ศ. 2567 ถึงเดือนตุลาคม พ.ศ. 2567 จำนวน 10 เดือน ใช้สำหรับการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยวิธีร้อยละค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ซึ่งตัวแบบที่มีค่า MAPE ต่ำที่สุดจะเป็นตัวแบบที่เหมาะสมที่สุดในการพยากรณ์ ผลการศึกษาพบว่า ตัวแบบ SARIMA$(0,1,1)(3,1,0)_{12}$ ไม่มีพจน์ค่าคงตัว เป็นตัวแบบที่เหมาะสมที่สุด

คำสำคัญ: ตัวแบบอารีมาที่มีฤดูกาล, การพยากรณ์, อนุกรมเวลา, วิธีบอกซ์-เจนกินส์, ฝุ่นละออง PM 2.5

การพยากรณ์ราคาขายปลีกขิงในกรุงเทพมหานคร

Forecasting of Retail Ginger Prices in Bangkok

กรรณิการ์ บุตนนท์* คณนาถ พระสนชุ่ม กชพร การุณ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร

(**Kannikabu65@nu.ac.th*)

บทคัดย่อ

ขิงเป็นพืชเศรษฐกิจที่มีบทบาทสำคัญในตลาดสินค้าเกษตร เนื่องจากมีความต้องการสูงอย่างต่อเนื่อง ทั้งในด้านการบริโภคเป็นวัตถุดิบประกอบอาหาร การใช้เป็นยาสมุนไพร และการแปรรูปเป็นผลิตภัณฑ์ต่าง ๆ การพยากรณ์ราคาขิงที่แม่นยำจึงเป็นเครื่องมือสำคัญในการวางแผนการเพาะปลูกและการเก็บเกี่ยวอย่างมีประสิทธิภาพ เพื่อลดความเสี่ยงจากความผันผวนของราคา และเสริมสร้างเสถียรภาพให้กับเกษตรกรและตลาดขิง โดยรวม การศึกษาครั้งนี้จึงมีวัตถุประสงค์เพื่อหาตัวแบบที่เหมาะสมสำหรับการพยากรณ์ราคาขายปลีกขิงในกรุงเทพมหานคร ข้อมูลที่ใช้เป็นข้อมูลทุติยภูมิที่รวบรวมจากกรมการค้าภายใน ราคาขายปลีกและขายส่งสินค้าเกษตร ตั้งแต่ไตรมาสที่ 1 พ.ศ. 2555 ถึง ไตรมาสที่ 4 พ.ศ. 2567 จำนวน 52 ค่า ซึ่งทำการแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดที่ 1 ตั้งแต่ไตรมาสที่ 1 พ.ศ. 2555 ถึง ไตรมาสที่ 4 พ.ศ. 2566 จำนวน 48 ค่า สำหรับสร้างตัวแบบพยากรณ์ด้วย วิธีบอกซ์-เจนกินส์ (Box-Jenkins Method) โดยใช้ตัวแบบ SARIMA และวิธีแยกองค์ประกอบ (Decomposition Method) เนื่องจากตัวแบบ SARIMA เป็นตัวแบบที่เหมาะสำหรับข้อมูลอนุกรมเวลาที่มีทั้งแนวโน้มและฤดูกาล โดยสามารถสะท้อนรูปแบบการเปลี่ยนแปลงราคาขายขิงอย่างมีประสิทธิภาพ ชุดที่ 2 ตั้งแต่ไตรมาสที่ 1 ถึงไตรมาสที่ 4 พ.ศ. 2567 จำนวน 4 ค่า สำหรับเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ โดยพิจารณาจากร้อยละความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) ผลการศึกษาพบว่า วิธีการพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์ราคาขายปลีกขิงในกรุงเทพมหานคร คือ ตัวแบบ SARIMA $(1,1,0)(3,1,0)_4$ ซึ่งมีค่า MAPE ต่ำที่สุด คือ 3.3153

คำสำคัญ: ราคาขายปลีกขิง, วิธีบอกซ์-เจนกินส์ ,ตัวแบบอารีมาที่มีฤดูกาล,วิธีแยกองค์ประกอบ

การพยากรณ์ราคาทองคำแท่ง 96.5% ในประเทศไทย

Forecasting the 96.5% Gold Bar Price in Thailand

จารุมน เต้าเมือง ชานิยา แย้มเอี่ยม* กชพร การุณ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร

(**chanisay65@nu.ac.th*)

บทคัดย่อ

ทองคำแท่งเป็นสินทรัพย์ที่มีบทบาทสำคัญทั้งในเชิงเศรษฐกิจ การลงทุน และอุตสาหกรรม การพยากรณ์ราคาทองคำแท่งจึงมีความสำคัญอย่างยิ่งต่อการตัดสินใจของนักลงทุนและผู้ที่เกี่ยวข้องในตลาดทองคำ เนื่องจากราคาทองคำมีการแปรผันตามปัจจัยทางเศรษฐกิจทั้งในประเทศ และในระดับโลก ซึ่งข้อจำกัดในการศึกษาครั้งนี้ คือตัวแบบการพยากรณ์อาจไม่สามารถคาดการณ์ได้ดีในช่วงที่ตลาดทองคำมีความผันผวนสูง เช่น เหตุการณ์ทางการเมืองระหว่างประเทศ นโยบายการเงินของธนาคารกลางสหรัฐ (Fed) การศึกษาครั้งนี้จึงมีวัตถุประสงค์เพื่อหาตัวแบบการพยากรณ์ราคาทองคำแท่ง 96.5% ในประเทศไทยโดยใช้เทคนิคอนุกรมเวลา ได้แก่ วิธีบอกซ์-เจนกินส์ วิธีเอ็กซ์โพเนนเชียลปรับเรียบสองชั้น และวิธีค่าเฉลี่ยเคลื่อนที่สองครั้ง เพื่อเปรียบเทียบประสิทธิภาพของแต่ละวิธีในการพยากรณ์ราคาทองคำแท่ง 96.5% ในประเทศไทย จึงได้แบ่งข้อมูลออกเป็น 2 ชุด โดยชุดที่ 1 ตั้งแต่เดือนมกราคม 2560 ถึง เดือนพฤษภาคม 2567 จำนวน 89 ค่า สำหรับการสร้างตัวแบบการพยากรณ์ และชุดที่ 2 ตั้งแต่เดือนมิถุนายน 2567 ถึงเดือนกุมภาพันธ์ 2568 จำนวน 9 ค่า สำหรับการตรวจสอบความแม่นยำของตัวแบบการพยากรณ์ โดยใช้เกณฑ์เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยที่ต่ำที่สุด เพื่อใช้เลือกตัวแบบการพยากรณ์ราคาทองคำในอนาคต ผลการศึกษาพบว่าตัวแบบการพยากรณ์ SARIMA $(0,1,1)(0,1,0)_{12}$ ที่ไม่มีพจน์ค่าคงตัว มีความเหมาะสมกับข้อมูลอนุกรมเวลาชุดนี้มากที่สุด ซึ่งมีค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเท่ากับ 2.3825

คำสำคัญ: อนุกรมเวลา, วิธีบอกซ์-เจนกินส์, วิธีเอ็กซ์โพเนนเชียลปรับเรียบสองชั้น, วิธีค่าเฉลี่ยเคลื่อนที่สองครั้ง

การพยากรณ์ราคาน้ำมันแก๊สโซฮอล์ 95 ในประเทศไทย โดยใช้วิธีวิเคราะห์อนุกรมเวลา

Forecasting the Price of Gasohol 95 in Thailand Using Time Series Analysis Techniques

อทิตยา ณ หนองคาย พรรนิดา แสนฤทธิ์* กชพร การุณ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์มหาวิทยาลัยนเรศวร

(**pannidas65@nu.ac.th*)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อหาแบบจำลองที่เหมาะสมของการพยากรณ์ราคาน้ำมันแก๊สโซฮอล์ 95 ในประเทศไทย โดยใช้แบบจำลอง ARIMA, SARIMA, ARIMAX และ SARIMAX โดยมีการเพิ่มตัวแปรอิสระ (exogenous variables) เพื่อช่วยอธิบายความผันผวนของข้อมูล ทำให้สามารถพยากรณ์ได้แม่นยำขึ้น โดยอาศัยปัจจัยภายนอก ได้แก่ ราคาน้ำมันดิบ (USD) และราคาน้ำมันสำเร็จรูปสิงคโปร์ (USD) โดยใช้ข้อมูลราคาน้ำมันแก๊สโซฮอล์ 95 ในประเทศไทย เป็นข้อมูลทุติยภูมิรายเดือน ตั้งแต่เดือน มกราคม พ.ศ. 2560 ถึงเดือน ธันวาคม พ.ศ. 2567 จำนวน 96 เดือน แบ่งเป็น 2 ชุด คือ ชุดที่ 1 ตั้งแต่ เดือน มกราคม พ.ศ. 2560 ถึง เดือน ธันวาคม พ.ศ. 2566 จำนวน 84 เดือน ใช้สำหรับการสร้างตัวแบบพยากรณ์ และ ชุดที่ 2 ตั้งแต่ เดือน มกราคม พ.ศ. 2567 ถึง เดือน ธันวาคม พ.ศ. 2567 จำนวน 12 เดือน ใช้สำหรับการตรวจสอบความแม่นยำของตัวแบบการพยากรณ์ด้วยเกณฑ์ร้อยละความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAPE) และรากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ที่ต่ำที่สุด วิเคราะห์ด้วยโดยโปรแกรม SPSS ผลการศึกษาพบว่า แบบจำลองการพยากรณ์ SARIMAX$(0,1,1,2)(1,1,0)_{12}$ มีความเหมาะสมกับการพยากรณ์ ซึ่งมีค่า MAPE และ RMSE ต่ำที่สุด คือ 2.0366 และ 1.0422 ตามลำดับ

คำสำคัญ: แก๊สโซฮอล์ 95, วิธีบอกซ์-เจนกินส์, ARIMAX, SARIMAX

การเปรียบเทียบตัวแบบการพยากรณ์ราคาปิดหุ้นปตท. ด้วยตัวแบบการปรับให้เรียบสองครั้งแบบเอ็กซ์โปเนนเชียล ตัวแบบ ARIMA และ ตัวแบบ ARIMAX

Comparison of Forecasting Models for PTT Stock Closing Prices Using Double Exponential Smoothing, ARIMA Model, and ARIMAX Model

ธนัชชา ธงไธสง* ธิชาดา หัวใจฉ่ำ พิมพิศา แสงก่ำ

ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ

(**Thanutcha.thong@g.swu.ac.th*)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์ราคาปิดหุ้นบริษัท ปตท. จำกัด (มหาชน) ซึ่งเป็นตัวชี้วัดสำคัญในการตัดสินใจลงทุน โดยใช้ตัวแบบการปรับให้เรียบสองครั้งแบบเอ็กซ์โปเนนเชียล ตัวแบบ ARIMA และตัวแบบ ARIMAX โดยพิจารณาตัวแปรเพิ่มเติม ได้แก่ ดัชนีตลาดหลักทรัพย์แห่งประเทศไทย (SET Index) และราคาน้ำมันดิบ West Texas Intermediate (WTI)

ในการพยากรณ์ราคาปิดหุ้นของบริษัท ปตท. จำกัด (มหาชน) ซึ่งใช้ชุดข้อมูลจริงของราคาปิดของหุ้นปตท. รายวันตั้งแต่วันที่ 4 มกราคม พ.ศ. 2564 ถึง วันที่ 13 มีนาคม พ.ศ. 2568 โดยมีทั้งหมด 1,010 ค่าสังเกต ในการศึกษาครั้งนี้ได้ทำการแบ่งข้อมูลออกเป็น 2 ชุด คือ ชุดที่ 1 สำหรับการสร้างตัวแบบการพยากรณ์ และชุดที่ 2 สำหรับการตรวจสอบประสิทธิภาพของตัวแบบพยากรณ์ โดยเกณฑ์ที่ใช้เปรียบเทียบประสิทธิภาพของตัวแบบ คือ ค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) และรากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) โดยตัวแบบที่ให้ค่า MAPE และ RMSE ต่ำที่สุด จะเป็นตัวแบบที่เหมาะสมที่สุด จากผลการศึกษาพบว่าตัวแบบของตัวแบบ ARIMA เป็นตัวแบบที่เหมาะสมที่สุดในการพยากรณ์ราคาปิดของหุ้นปตท.

คำสำคัญ: ราคาปิดหุ้น, การพยากรณ์, ตัวแบบการปรับให้เรียบสองครั้งแบบเอ็กซ์โปเนนเชียล, ตัวแบบ ARIMA, ตัวแบบ ARIMAX

การพยากรณ์จำนวนผู้เสียชีวิตจากโรคมะเร็งในกรุงเทพมหานคร

Forecasting of Cancer Mortality in Bangkok

ชุติกาญจน์ ชนิจกุล* ธีรภัทร นกแจ้ง อนันธิกา สุราษฎร์ อรไท พลเสน

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620254@email.kmutnb.ac.th*)

บทคัดย่อ

โรคมะเร็งนับว่าเป็นสาเหตุการเสียชีวิตอันดับต้น ๆ ของคนไทย ข้อมูลจากสถาบันมะเร็งแห่งชาติ กรมการแพทย์ ระบุว่ามะเร็งเต้านมพบบ่อยที่สุดในผู้หญิงไทย ส่วนมะเร็งที่พบบ่อยในผู้ชายไทย คือ มะเร็งตับและท่อน้ำดี การวิจัยนี้จึงสนใจศึกษาแนวโน้มจำนวนผู้เสียชีวิตจากมะเร็งเต้านมและมะเร็งตับและท่อน้ำดี และสร้างตัวแบบพยากรณ์ ข้อมูลที่ใช้เป็นข้อมูลทุติยภูมิที่เก็บรวบรวมจากสถิติสุขภาพคนไทย ซึ่งเป็นข้อมูลรายเดือนตั้งแต่เดือนมกราคม พ.ศ. 2557 ถึงเดือนธันวาคม พ.ศ. 2565 รวมทั้งสิ้น 108 เดือน โดยใช้การวิเคราะห์อนุกรมเวลาซึ่งประกอบด้วยวิธีการพยากรณ์เดี่ยว 3 วิธี คือ วิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียล (Exponential Smoothing Method) วิธีบอกซ์-เจนกินส์ (Box-Jenkins Method) วิธีการถดถอยอนุกรมเวลา (Time Series Regression Method) และวิธีพยากรณ์รวม (Combined Forecasting Method) 2 วิธี คือ วิธีการให้น้ำหนักที่เท่ากัน (Equivalent Weight Method: EW) วิธีการรวมแบบอิงค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (MAPE-Based Combination Method: MAPE-C) โดยพิจารณาค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) เป็นเกณฑ์ในการคัดเลือก ตัวแบบพยากรณ์ที่เหมาะสมที่สุด จากผลการศึกษาพบว่าวิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียลของโฮลต์เหมาะสมที่สุดในการพยากรณ์จำนวนผู้เสียชีวิตจากมะเร็งเต้านม ส่วนวิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียลอย่างง่ายและวิธีบอกซ์-เจนกินส์เหมาะสมที่สุดในการพยากรณ์จำนวนผู้เสียชีวิตจากมะเร็งตับและท่อน้ำดี

คำสำคัญ: มะเร็งเต้านม, มะเร็งตับและท่อน้ำดี, วิธีการปรับให้เรียบแบบเอกซ์โพเนนเชียล, วิธีบอกซ์-เจนกินส์, วิธีการถดถอยอนุกรมเวลา, วิธีพยากรณ์รวม

การพยากรณ์ความถี่ในการเคลมของประกันวินาศภัยโรงแรม โดยใช้แบบจำลองข้อมูลนับทางสถิติ

Forecasting the Claim Frequency of Hotel Property Insurance Using Statistical Count Data Models

มยุรินทร์ กลีบพึ่ง* นพรุจ ไป๋แป้ วิมลวรรณ เอี๋ยวประดิษฐ์ วิกานดา ผาพันธ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052610097@email.kmutnb.ac.th*)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อวิเคราะห์และพยากรณ์ความถี่ของการเรียกร้องค่าสินไหมทดแทนจากการประกันภัยโรงแรม โดยใช้แบบจำลองการถดถอยปัวซงและแบบจำลองการถดถอยทวินามเชิงลบ เพื่อเปรียบเทียบความเหมาะสมในการพยากรณ์ ปัจจัยที่ใช้ในการศึกษาประกอบด้วยจังหวัด สาเหตุของความเสียหาย และเบี้ยประกันภัยรวม โดยความถี่ของการเรียกร้องค่าสินไหมทดแทนถูกวิเคราะห์ในช่วงเวลาที่กำหนดคือรายปี เพื่อประเมินแนวโน้มและความเสี่ยงได้อย่างเหมาะสม กระบวนการวิเคราะห์เริ่มจากการตรวจสอบความสัมพันธ์ระหว่างตัวแปรโดยใช้ค่าสัมประสิทธิ์สหสัมพันธ์ลำดับที่ของสเปียร์แมน เพื่อระบุความสัมพันธ์ระหว่างตัวแปรอิสระกับตัวแปรตาม จากนั้นทำการประมาณค่าพารามิเตอร์ของแบบจำลองและประเมินความเหมาะสมโดยใช้การทดสอบอัตราส่วนภาวะน่าจะเป็น (Likelihood Ratio Test: LRT) และเกณฑ์ทางสถิติ เช่น ค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง (MSE) และค่าความคลาดเคลื่อนสัมพัทธ์เฉลี่ย (MAPE) เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง ผลการศึกษาพบว่าแบบจำลองการถดถอยทวินามเชิงลบให้ผลการพยากรณ์ที่ดีกว่าแบบจำลองการถดถอยปัวซง เนื่องจากสามารถจัดการกับข้อมูลที่มีความแปรปรวนสูงได้ดีกว่า ข้อค้นพบนี้ช่วยให้บริษัทประกันสามารถปรับปรุงการวิเคราะห์ความเสี่ยงและกำหนดอัตราเบี้ยประกันภัยที่เหมาะสม นอกจากนี้ การศึกษายังกล่าวถึงความคุ้มครองของการประกันภัยโรงแรม ซึ่งรวมถึงภัยธรรมชาติ อัคคีภัย อุบัติเหตุ และความเสียหายต่อทรัพย์สินของโรงแรม

คำสำคัญ: การเรียกร้องค่าสินไหมทดแทน, แบบจำลองการถดถอยปัวซง, แบบจำลองการถดถอยทวินามเชิงลบ, ค่าสัมประสิทธิ์สหสัมพันธ์ลำดับที่ของสเปียร์แมน, การทดสอบอัตราส่วนภาวะน่าจะเป็น, การพยากรณ์ความเสี่ยง

การพัฒนาเครื่องมือสำหรับคำนวณเบี้ยประกันชีวิต

The Development of a Life Insurance Premiums Calculation Tools

ธนพร มะภิโกสิ* ปัณฑารีย์ ถนิมกาญจน์ ศุภัชฌา แอลเฟรด สุภารัตน์ นิวิศพงศ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052630225@email.kmutnb.ac.th*)

บทคัดย่อ

เบี้ยประกันชีวิต คือ จำนวนเงินที่ผู้เอาประกันต้องชำระให้กับบริษัทประกันภัยตามข้อตกลงในกรมธรรม์เพื่อคุ้มครองความเสี่ยงของผู้เอาประกัน โดยประกันชีวิตสามารถแบ่งออกทั้งหมด 4 ประเภท ตามเงื่อนไขของกรมธรรม์ คือ ประกันแบบตลอดชีพ ชั่วระยะเวลา สะสมทรัพย์ และ บำนาญ (สะสมทรัพย์แท้จริง) ซึ่งแต่ละประเภทมีลักษณะและผลประโยชน์ที่ผู้เอาประกันภัยจะได้รับแตกต่างกัน

การคำนวณเบี้ยประกันชีวิต เป็นการกำหนดจำนวนเงินที่ผู้เอาประกันต้องชำระให้เหมาะสมกับความคุ้มครองความเสี่ยงของผู้เอาประกัน โดยการคำนวณเบี้ยประกันชีวิตอาศัยแนวคิดหลักการสมดุล (Equivalence principle) และมูลค่าปัจจุบันคาดหมาย (Expectation present value: EPV) โดยกำหนดให้มูลค่าปัจจุบันคาดหมายของเบี้ยประกันที่จ่าย เท่ากับ มูลค่าปัจจุบันคาดหมายของผลประโยชน์ที่ต้องจ่ายในอนาคต โดยการคำนวนมูลค่าปัจจุบันคาดหมายโดยใช้ปัจจัย คือ อัตราดอกเบี้ย สำหรับคำนวณมูลค่าปัจจุบัน และ ความน่าจะเป็นของการเสีย หรือรอดชีวิต หรืออัตราการเสียชีวิต และรอดชีวิตจากตารางชีพ โดยพิจารณาจาก อายุ และ เพศของผู้เอาประกันภัย สำหรับคำนวนมูลค่าปัจจุบันคาดหมาย

ดังนั้นโครงงานนี้ผู้จัดทำจึงได้ทำการสร้างเครื่องมือคำนวณเบี้ยประกันชีวิตโดยใช้โปรแกรม Microsoft Excel และVisual Basic for Application (VBA) เป็นโปรแกรมคอมพิวเตอร์ที่สามารถใช้งานได้หลากหลาย ซึ่งเหมาะสมกับการคำนวณที่ซับซ้อน การดำเนินงานซ้ำในรูปแบบเดิม และนำเสนอเครื่องมือผ่านช่องทาง Line Official Account (line OA) ผลการตอบรับจากผู้ทดลองใช้เครื่องมือคำนวนเบี้ยประกันชีวิตพบว่า เครื่องมือสามารถอำนวยความสะดวกให้แก่ผู้ใช้งานในการคำนวณเบี้ยประกันชีวิตได้อย่างถูกต้อง รวดเร็ว และง่ายต่อการเข้าถึงเครื่องมือในการคำนวณ

คำสำคัญ: เบี้ยประกันชีวิต, กรมธรรม์ประกันชีวิต, ผลประโยชน์ของกรมธรรม์, หลักการสมดุล และมูลค่าปัจจุบันคาดหมาย

การวิเคราะห์การถดถอยพหุผลลัพธ์ในการทำนายความถี่และความรุนแรงของการเรียกร้องค่าสินไหมทดแทนในการประกันภัยรถยนต์

A Multi-Output Regression Approach for Prediction the Paid Frequency and Severity of Auto Insurance Claims

ชฎารัตน์ อิ่มสารพางค์* ปารเมศ ศิริพรรธนนท์

สาขาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยขอนแก่น

(**chadarat.i@kkumail.com*)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อสร้างและเปรียบเทียบประสิทธิภาพของแบบจำลองการถดถอยพหุผลลัพธ์ในการทำนายความถี่และความรุนแรงของการเรียกร้องค่าสินไหมทดแทนด้วยการเรียนรู้ของเครื่อง และเพื่อพัฒนาเว็บแอปพลิเคชันที่ช่วยในการทำนายการเรียกร้องค่าสินไหมทดแทนซึ่งมีความสำคัญต่อการกำหนดเบี้ยประกันภัยรถยนต์ โดยข้อมูลที่ใช้ในงานวิจัยเป็นข้อมูลกรมธรรม์ประกันภัยรถยนต์จากบริษัทประกันภัยแห่งหนึ่งในประเทศสเปน ตั้งแต่ปี พ.ศ. 2549 -2558 จำนวน 80,924 ราย ตัวแปรที่นำมาสร้างแบบจำลองมีทั้งหมด 8 ตัวแปร แบบจำลองการถดถอยพหุผลลัพธ์ที่ศึกษา ได้แก่ Random Forest, XGBoost, LightGBM และ ANN ทำการวัดประสิทธิภาพของแบบจำลองด้วยค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE), ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร (SMAPE) โดยแบ่งข้อมูลเพื่อนำมาฝึกและทดสอบประสิทธิภาพของแบบจำลองในอัตราส่วน 80:20 และฝึกแบบจำลองด้วย 10-fold Cross Validation พร้อมทั้งปรับแต่งพารามิเตอร์ที่เหมาะสมสำหรับแต่ละแบบจำลองด้วยวิธี GridSearch และใช้ Shapley Additive Explanations (SHAP) เพื่อวิเคราะห์ปัจจัยที่มีอิทธิพลต่อการทำนาย

ผลการศึกษาพบว่า แบบจำลอง Multi-Output Random Forest Regression มีประสิทธิภาพสูงสุดในการทำนายความถี่ของการเรียกร้องค่าสินไหมทดแทน (MAE = 0.2427, RMSE = 0.7832, SMAPE = 28.8311) และความรุนแรงของการเรียกร้องค่าสินไหมทดแทน (MAE = 228.9800, RMSE = 864.6607, SMAPE = 29.2370) การวิเคราะห์ SHAP แสดงให้เห็นว่าปัจจัยสำคัญที่มีผลต่อการทำนายมากที่สุดสามอันดับแรก คือ จำนวนกรมธรรม์ที่ผู้ถือกรมธรรม์มี อายุของใบอนุญาตขับขี่ และอายุของผู้ถือกรมธรรม์ นอกจากนี้ผู้วิจัยยังได้พัฒนาเว็บแอปพลิเคชันที่เชื่อมต่อผ่าน Flask ช่วยให้บริษัทประกันภัยสามารถป้อนข้อมูลกรมธรรม์ และทราบผลการทำนายการเรียกร้องค่าสินไหมทดแทนได้แบบเรียลไทม์

คำสำคัญ: การถดถอยพหุผลลัพธ์ จำนวนการเรียกร้องค่าสินไหมทดแทน ความรุนแรงของการเรียกร้องค่าสินไหมทดแทน การเรียนรู้ของเครื่อง การประกันภัยรถยนต์

การออกจดหมายบอกกล่าวทวงถามแบบอัตโนมัติสำหรับสินเชื่อ SME ที่ค้ำประกันโดยบรรษัทประกันสินเชื่ออุตสาหกรรมขนาดย่อม (บสย.)

Automatic Generating Notice Letters for SME Loan Guarantee by Thai Credit Guarantee Cooperation (TCG)

มนัสวรรณ คล่องถนอมสัตย์* คณิตา เพ็ชรัตน์ มูรตี สมบูรณ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052610089@email.kmutnb.ac.th*)

บทคัดย่อ

การขอสินเชื่อ SME กรณีมีหลักทรัพย์ค้ำประกันไม่เพียงพอสามารถยื่นคำขอกับบรรษัทประกันสินเชื่ออุตสาหกรรมขนาดย่อม (บสย.) เพื่อเข้าค้ำประกันให้ หากผู้กู้ผิดนัดชำระตามเงื่อนไข สถาบันการเงินสามารถเรียกร้องค่าสินไหมจาก บสย. เพื่อบรรเทาความเสียหาย โดยสถาบันการเงินต้องออกจดหมายบอกกล่าวทวงถาม (Notice Letter) ไปยังผู้กู้ที่ผิดนัดชำระ เพื่อใช้เป็นหลักฐานในการเคลม แต่เดิมธนาคารแห่งหนึ่งมีการคัดกรองข้อมูลลูกค้าที่ใช้ออก Notice Letter แบบแมนนวลและดำเนินการออกโดยว่าจ้างสำนักงานทนายนอก (Outsource Law Agents: OLA) โดยส่งข้อมูลให้ผ่านทางอีเมล เพื่อที่จะลดงานแมนนวล ลดข้อผิดพลาดจากคน (Human Error) ในส่วนงานดำเนินคดีสินเชื่อรายย่อย (Retail Litigation) ของสถาบันการเงินแห่งหนึ่ง และลดความเสี่ยงการรั่วไหลของข้อมูลลูกค้าจากการต้องส่งอีเมลไปภายนอกองค์กร ลดค่าใช้จ่ายจ้าง OLA และเพื่อให้ออก Notice Letter ได้ตามเงื่อนไขที่กำหนดรวมถึงติดตาม (Tracking) ไฟล์จดหมายที่ถูกสร้างขึ้นได้บนระบบเดียว จึงได้พัฒนาระบบบริหารหนี้ของธนาคาร (PCOL) ให้สามารถออก Notice Letter ได้แบบอัตโนมัติ โดยได้มีส่วนร่วมดำเนินงานในแต่ละช่วงของ Software Development Life Cycle (SDLC) ดังนี้ 1) ช่วงวางแผนและวิเคราะห์ความต้องการในการพัฒนาระบบ (Requirement Analysis): จัดทำเอกสาร Business Requirement Specification (BRS) 2) ช่วงออกแบบระบบ: ร่วมหารือกับ System Analyst ผู้ออกแบบและพัฒนาระบบ เกี่ยวกับความต้องการในการพัฒนาระบบและการกำหนดค่าสำหรับออกจดหมายบนระบบ 3) ช่วงพัฒนาระบบ: เตรียมทำ User Acceptance Test (UAT) โดยสร้าง Test Case และเตรียม Test Data จากระบบ PCOL ในส่วน UAT Environment นำมาคัดกรองข้อมูลในการทดสอบด้วยโปรแกรม Excel 4) ช่วงทดสอบระบบ: ร่วมตรวจสอบผลลัพธ์การทำ System Integration Test (SIT) กับ Quality Assurance (QA) และสนับสนุนการทดสอบ UAT ของผู้ใช้งานระบบ 5) ช่วงนำระบบขึ้นไปใช้งานจริง: สนับสนุนการนำระบบขึ้นไปใช้งานจริงและสนับสนุนการทดสอบระบบหลังใช้งานจริง ในการพัฒนาระบบมีการนำข้อมูลจากระบบส่วนกลางธนาคารในงานสินเชื่อ (Core Banking System-Loan :CBS-LN) ส่งผ่านระบบ Extract-Transform-Load (ETL) ไปยังระบบ PCOL ซึ่งมีการกำหนดเงื่อนไขในการออก Notice Letter เช่น เงื่อนไขเกี่ยวกับจำนวนงวดค้างชำระ ผลิตภัณฑ์สินเชื่อของธนาคาร โครงการสินเชื่อของลูกค้าที่จะนำไปเคลมกับ บสย. การปรับโครงสร้างหนี้ ฯลฯ โดยระบบ PCOL สามารถนำไปใช้ออก Notice Letters แบบอัตโนมัติตามเงื่อนไขที่กำหนด และส่งไฟล์จดหมายที่ออกบนระบบผ่าน Secure File Transfer Protocol (SFTP) ไปยัง Printing House ให้นำส่งไปรษณีย์แบบลงทะเบียนตอบรับถึงลูกค้า เมื่อนำระบบไปใช้งานสามารถลดค่าใช้จ่ายในการจ้าง OLA ได้ประมาณ 100,000 บาทต่อเดือน ในการพัฒนาระบบได้มีการกำหนดค่าบนระบบเพิ่มเติมเกี่ยวกับบัญชีของลูกค้าว่าต้องไม่เป็นหนี้ที่ถูกตัดจากงบดุล (Write Off) เพื่อป้องกันเคสออกจดหมายซ้ำกรณีเคลมไปแล้ว และให้มีการเปิดคำขอแก้ไขระบบ (Change Request) ดำเนินการในภายหลัง ในส่วนการเพิ่มฟิลด์ข้อมูลใหม่ที่ใช้ออก Notice Letter ไปยัง EDP (Electronic Data Processing) เพื่อให้ระบบ PCOL สามารถออก Notice Letter แบบอัตโนมัติได้ภายในช่วงเวลาตามความต้องการของผู้ใช้งานระบบ หากพบว่าระบบไม่ออกจดหมายตามรอบเวลาที่กำหนด จะมีการพิจารณาแก้ไขเบื้องต้นดังนี้ ผู้ดูแลระบบคาดการณ์ว่าระบบจะยังออกจดหมายทันในรอบเวลาถัดไปหรือไม่ ผู้ดูแลระบบตรวจสอบแก้ไขการออกจดหมายเองได้หรือไม่ แล้วจึงให้หน่วยงานที่รับผิดชอบในการออกจดหมายดำเนินการใส่คำสั่งพิเศษ (Action Code) บนระบบให้ออกเป็น Ad-hoc Letter (ออกจดหมายในกรณีผิดปกติ) เมื่อระบบสร้างไฟล์จดหมายแล้ว จึงวางไฟล์ที่ SFTP แล้วประสานงานกับ Printing House ให้ดาวน์โหลดไฟล์จดหมาย

คำสำคัญ: Notice Letters, Software Development, Business Requirement, User Acceptance Test

การวิเคราะห์ข้อมูลการประกันภัยอุปกรณ์อิเล็กทรอนิกส์ของโรงพยาบาลและคลินิกความงาม

Data Analysis of Electronic Equipment Insurance for Hospitals and Beauty Clinics

ลัลน์ลลิต ทองเอียบ อุไรวรรณ เจริญกีรติกุล

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052620181@email.kmutnb.ac.th*)

บทคัดย่อ

ปัจจุบันธุรกิจโรงพยาบาลและคลินิกความงามเติบโตมากขึ้น พร้อมกับการลงทุนในอุปกรณ์ทางการแพทย์เพื่อแข่งขันเชิงคุณภาพการบริการและการรักษา การทำประกันภัยเป็นทางเลือกสำคัญในการคุ้มครองเมื่อเกิดความเสียหายกับอุปกรณ์ทางการแพทย์ที่มีมูลค่าสูงและอาจส่งผลต่อการให้บริการ การวิเคราะห์ข้อมูลการประกันภัยเป็นกระบวนการสำคัญช่วยให้บริษัทประกันภัยจัดการความเสี่ยงภัยได้อย่างมีประสิทธิภาพ งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อวิเคราะห์ข้อมูลการประกันภัยอุปกรณ์อิเล็กทรอนิกส์ (EEI) ของโรงพยาบาลและคลินิกความงาม โดยใช้ Microsoft Power BI ในการพัฒนา Dashboard สำหรับการรายงานผลการวิเคราะห์ข้อมูล ข้อมูลที่ใช้เป็นข้อมูลกรมธรรม์ประกันภัยอุปกรณ์อิเล็กทรอนิกส์ของบริษัทประกันภัยแห่งหนึ่ง ตั้งแต่วันที่ 1 มกราคม ค.ศ. 2019 ถึง 30 มิถุนายน ค.ศ. 2024 (พิจารณาตามวันเริ่มคุ้มครอง) จำนวนข้อมูล 1,532 รายการ เลือกศึกษา 2 ประเภท คือ โรงพยาบาลและคลินิกความงาม ประกอบด้วยข้อมูล จำนวนกรมธรรม์ ทุนประกันภัย เบี้ยประกันภัยที่ได้รับ ค่าสินไหม และความถี่การเรียกร้องค่าสินไหม สร้าง Dashboard ใช้ในการวิเคราะห์เปรียบเทียบแนวโน้มจำนวนกรมธรรม์ ทุนประกันภัยแต่ละปี และเปรียบเทียบเบี้ยประกันภัยที่ได้รับกับความถี่ในการเรียกร้องค่าสินไหม เพื่อแสดงถึงแนวโน้มและประสิทธิภาพการรับประกันภัยของบริษัท ผลการวิเคราะห์พบว่า การทำประกันภัยอุปกรณ์อิเล็กทรอนิกส์ของโรงพยาบาลและคลินิกความงามมีแนวโน้มของจำนวนกรมธรรม์ ทุนประกันภัย และเบี้ยประกันภัยที่ได้รับ ที่สูงในช่วงปี 2019-2020 แต่ลดลงในปี 2021 ที่อาจเกิดจากปัจจัยภายนอก และเริ่มเติบโตขึ้นในช่วงปี 2023-2024 มีอัตราส่วนค่าสินไหม 5.42% ซึ่งน้อยกว่า 60% นับเป็นระดับที่ต่ำ แสดงว่าบริษัทมีผลดำเนินงานรับประกันภัยที่มีประสิทธิภาพและสามารถควบคุมความเสี่ยงได้ แม้ข้อมูลที่มีสามารถใช้วิเคราะห์เบื้องต้นได้ แต่ยังต้องการข้อมูลเพิ่มเติมเพื่อปรับปรุง Dashboard ให้ครอบคลุมขึ้น นำไปใช้วางแผนกลยุทธ์ของบริษัทเพื่อให้การพิจารณารับประกันภัยในอนาคตมีประสิทธิภาพและพัฒนากรมธรรม์ประกันภัยให้ตรงกับกลุ่มเป้าหมายยิ่งขึ้น

คำสำคัญ: ประกันภัยอุปกรณ์อิเล็กทรอนิกส์ (EEI), โรงพยาบาลและคลินิกความงาม, Dashboard, อัตราส่วนค่าสินไหม

การพัฒนา Extract Transform Loader สำหรับภาษีอิเล็กทรอนิกส์

Extract Transform Loader System Development for e-Tax Invoices

วาสนา แซ่โก๊ย* สถาพร เทพสัมฤทธิ์พร ชนนิกานต์ รอดมรณ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053630211@email.kmutnb.ac.th*)

บทคัดย่อ

งานวิจัยนี้มีมุ่งเน้นการพัฒนาและปรับปรุงกระบวนการ Extract-Transform-Load (ETL) สำหรับเอกสารภาษีอิเล็กทรอนิกส์ประเภท T02 (ใบแจ้งหนี้/ใบกำกับภาษี) โดยทำการออกแบบและพัฒนา Workflow รวมถึงพัฒนาระบบตรวจสอบความถูกต้องของข้อมูลก่อนการบันทึกลงฐานข้อมูล เครื่องมือที่ใช้ในการพัฒนาระบบประกอบด้วย 1) Pentaho Data Integration (PDI) ใช้สำหรับกระบวนการ ETL 2) PostgreSQL เป็นฐานข้อมูลหลัก 3) PgAdmin และ DataGrip ใช้ในการจัดการฐานข้อมูล 4) GitHub ใช้สำหรับบริหารจัดการซอร์สโค้ด และ 5) Visual Studio Code ใช้สำหรับการพัฒนาและปรับแต่งคำสั่ง ข้อมูลที่ใช้คือข้อมูลเอกสารภาษีอิเล็กทรอนิกส์ประเภท T02 ตั้งแต่ปี 2565 ถึง 2567 จำนวน 1,000 ฉบับ ทดสอบกับฐานข้อมูลที่ได้รับการออกแบบใหม่ ที่ได้รวบรวมมาจาก 12 แหล่ง ผลการพัฒนาพบว่า ระบบสามารถลดข้อผิดพลาดในการนำเข้าข้อมูลและการแปลงไฟล์ XML ได้ สามารถตรวจจับข้อผิดพลาดที่อาจเกิดขึ้นระหว่างการประมวลผลและแจ้งเตือนผู้ใช้ได้ทันที เช่น การตรวจจับรูปแบบเลขที่ใบแจ้งหนี้ที่ไม่ถูกต้อง หรือมีข้อมูลลูกค้าไม่ตรงกับฐานข้อมูลเดิม โดยผลการทดสอบแสดงให้เห็นว่าระบบมีความแม่นยำในการประมวลผลข้อมูลคิดเป็นร้อยละ 80 นอกจากนี้ การพัฒนาโครงสร้างฐานข้อมูลและการปรับปรุงกระบวนการทำงานดังกล่าว ทำให้ระบบสามารถรองรับการนำเข้าและจัดเก็บข้อมูลภาษีอิเล็กทรอนิกส์จำนวนมากได้ รวมไปถึงสามารถรองรับการขยายตัวของข้อมูลในอนาคต และรองรับการนำเข้าและส่งออกข้อมูลให้ถูกต้อง ครบถ้วนตามข้อกำหนดของกรมสรรพากร

คำสำคัญ: Extract-Transform-Load (ETL), Pentaho, e-Tax, ใบกำกับภาษีอิเล็กทรอนิกส์, T02 (ใบแจ้งหนี้/ใบกำกับภาษี)

การย้ายข้อมูลสำหรับฐานข้อมูลการประเมินมูลค่าทรัพย์สิน และการบริหารจัดการหลักประกัน

Data Migration for Asset Life Cycle (ALC) System

ภัทรพร พิมพาลัย* สถาพร เทพสัมฤทธิ์พร ชนนิกานต์ รอดมรณ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404053630199@email.kmutnb.ac.th*)

บทคัดย่อ

โครงงานสหกิจศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาและปรับปรุงโครงสร้างฐานข้อมูลให้รองรับระบบ Asset Life Cycle (ALC) และพัฒนาโปรแกรมสำหรับย้ายข้อมูลจากระบบเดิม Loan Asset Life Cycle (LAL) ซึ่งใช้ Oracle Database ไปยัง PostgreSQL Database ซึ่งเป็นระบบโอเพนซอร์สที่ช่วยลดต้นทุนและเพิ่มประสิทธิภาพในการจัดการข้อมูล

การดำเนินงานเริ่มจากการศึกษาฐานข้อมูลเดิมและจัดทำเอกสารจับคู่ข้อมูล (Data Mapping) จากนั้นทำความสะอาดข้อมูล (Data Cleansing) เพื่อลดปัญหาความซ้ำซ้อนและข้อมูลที่ขาดหาย กระบวนการย้ายข้อมูล ใช้ Visual Studio Code และภาษา Python ในการพัฒนาโปรแกรมสำหรับดึงข้อมูลจาก Oracle SQL Developer และจัดเก็บในรูปแบบ Excel หรือ CSV รวมถึงใช้ Power BI เพื่อตรวจสอบความถูกต้องของข้อมูลก่อนนำเข้าสู่ระบบใหม่ โดยใช้แอปพลิเคชันของ ALC (Mendix) ในการจัดเตรียมแม่แบบข้อมูล

เมื่อย้ายข้อมูลแล้ว ได้มีการตรวจสอบคุณภาพข้อมูล (Data Validation) เพื่อให้มั่นใจว่าข้อมูลที่โอนย้ายมีความครบถ้วนและถูกต้อง ผลการดำเนินโครงการพบว่าสามารถลดข้อผิดพลาดของข้อมูลได้ 98% และลดระยะเวลาการย้ายข้อมูลจาก 3 วัน เหลือ 5 ชั่วโมง ช่วยให้การจัดการข้อมูลมีประสิทธิภาพ ลดปัญหาข้อมูลซ้ำซ้อน และรองรับการขยายตัวของธุรกิจในอนาคต

คำสำคัญ: Oracle Database, PostgreSQL Database, การย้ายข้อมูล, การแปลงข้อมูล, การทำความสะอาดข้อมูล, Visual Studio Code, ภาษา Python, Oracle SQL Developer, Power BI, Mendix, การตรวจสอบคุณภาพข้อมูล

การตรวจจับการฉ้อโกงประกันภัยรถยนต์โดยใช้การเรียนรู้ของเครื่อง

Car Insurance Fraud Detection Using Machine Learning

สุเมธี ศิวะนันต์วงษ์ สรุจ มีฤทธิ์* โสภณัฐ ศรีสุวรรณรัตน์ บุญกอง ทะกลโยธิน

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(**s6404052630349@email.kmutnb.ac.th*)

บทคัดย่อ

การฉ้อโกงการประกันภัยรถยนต์ส่งผลต่อการคิดอัตราเบี้ยประกันที่ขาดความแม่นยำและทำให้เกิดการสูญเสียทางการเงินกับบริษัท ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์ 1) เพื่อพัฒนาโปรแกรม Machine Learning Model ที่เหมาะสมสำหรับการตรวจจับการฉ้อโกงในประกันภัยรถยนต์ 2) เพื่อเปรียบเทียบประสิทธิภาพการตรวจจับการฉ้อโกงระหว่าง 3 โมเดล 3) เพื่อประเมินการใช้ระบบในการตรวจจับการฉ้อโกงจากตัวแบบที่เลือกและเหมาะสม การศึกษาครั้งนี้ใช้ข้อมูล Public Dataset จำนวน 400 ชุด จากการเคลมประกันภัยรถยนต์ ทั้งกรณีแบบปกติและแบบฉ้อโกง เปรียบเทียบการเรียนรู้ของเครื่องแบบ Supervised Learning มี 3 โมเดลได้แก่ วิธีเดิม คือ Decision Tree, และวิธีใหม่ คือ Random Forest และ Naïve Bayes สำหรับ Naïve Bayes เหมาะสำหรับข้อมูลที่มีการแจกแจงแบบอิสระ สามารถเรียนรู้ได้รวดเร็วทั้งข้อมูลมากและน้อย ส่วน Random Forest ถูกนำมาใช้เพื่อเพิ่มความแม่นยำโดยลดการเกิด Overfitting ผ่านการรวมผลลัพธ์ของหลายต้นไม้ ส่วน Decision Tree ที่มีความสามารถในการตีความง่าย ทำงานได้ดีในกรณีข้อมูลสูญหาย การปรับ Hyperparameters ได้แก่ ค่าความแปรปรวนใน Naïve Bayes, จำนวนต้นไม้ใน Random Forest และระดับความลึกสูงสุดของ Decision Tree ส่งผลต่อความแม่นยำในการจำแนก การ Tuning ช่วยลด Overfitting และเพิ่มประสิทธิภาพของโมเดล ระบบการเรียนรู้ของเครื่องพัฒนาโดยใช้ภาษา Python มีการวิเคราะห์ข้อมูลเบื้องต้น (EDA) โดยแบ่งชุดข้อมูลเป็น Training และ Testing Set อย่างละ 200 ชุด จากนั้นนำตัวแบบ Machine Learning มาฝึกและประเมินตัวแบบทั้งหมดโดยใช้เกณฑ์ F1-Score และ Accuracy จาก Confusion Matrix โดยแบ่งข้อมูลเป็น 2 กรณี คือ แบบปกติและแบบฉ้อโกง ผลการวิจัยพบว่า ค่า F1-Score ของ Decision Tree คือ 0.85, 0.59, Random Forest คือ 0.83, 0.41 และ Naïve Bayes คือ 0.79, 0.53 ตามลำดับ ส่วนค่า Accuracy พิจารณาจากข้อมูลทั้ง 2 กรณี พบว่า Decision Tree คือ 78%, Random Forest คือ 74% และ Naïve Bayes คือ 70% เรียงตามลำดับ จากผลวิจัยดังกล่าวทำให้ได้ตัวแบบ Decision Tree ที่มีความเหมาะสมในการใช้งานมากกว่า 2 วิธีภายใต้ขอบเขตที่ศึกษา และสอดคล้องกับงานวิจัยของ Sidi Aly Mouna and Kissani Ilham ที่พบว่าการปรับ Hyperparameters Tuning ทำให้ Decision Tree มีความแม่นยำในการทำนายสูงขึ้นอย่างมีนัยสำคัญ ประกอบกับการทดสอบในระยะสั้นๆ รองรับข้อมูลสูญหายและมีจำนวนน้อยทำให้ผลการทดสอบดีกว่า Random Forest และสูงกว่า Naïve Bayes ที่มีข้อจำกัดมากกว่า ดังนั้น หากต้องการเลือกตัวแบบที่เหมาะสมที่สุดให้กับบริษัทประกันภัยรถยนต์ ควรศึกษาเงื่อนไขด้านข้อมูลเป็นหลักทั้งประเภท จำนวน แนวโน้มต่างๆ ระยะเวลาการศึกษา รวมถึงการศึกษาเชิงเปรียบเทียบกับวิธีการและเทคนิคใหม่ ๆ ที่สอดคล้องกับงานของแต่บริษัท โดยเฉพาะการสร้าง Machine Learning Model ด้วย Hyperparameters Tuning เพื่อเพิ่มประสิทธิภาพของตัวแบบอย่างต่อเนื่องและปัจจุบันผู้วิจัยได้พัฒนาระบบนี้ต่อเพื่อการนำตัวแบบจากผลการวิจัยไปใช้กับการทำงานจริงในระยะยาวต่อไป

คำสำคัญ: Fraud detection, Insurance claims, Machine learning, Hyperparameter, Risk assessment, Accuracy