



การประชุมวิชาการระดับชาติด้านสถิติ
วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 3

3 เมษายน 2569

(รูปแบบออนไลน์)

PROCEEDINGS OF THE
3rd National Conference
on Statistics, Data Science, and Insurance
(NCSDI 2026)

April 3, 2026

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 3 ประจำปี พ.ศ.2569 (The 3rd National Conference on Statistics, Data Science and Insurance: NCSDI 2026) ในวันที่ 3 เมษายน 2569 ณ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ โดยจัดขึ้นในรูปแบบออนไลน์ มีลักษณะการประชุมเป็นการนำเสนอผลงานทางวิชาการของผู้เข้าร่วมประชุมในรูปแบบบรรยาย (Oral Presentation) รูปแบบโปสเตอร์ (Poster Presentation) และการบรรยายพิเศษจากวิทยากรผู้เชี่ยวชาญเฉพาะด้าน โดยมีจุดมุ่งหมายเพื่อสร้างเครือข่ายความร่วมมือทางวิชาการด้านสถิติ วิทยาศาสตร์ข้อมูล และด้านการประกันภัย ให้มีความเข้มแข็งทางวิชาการ และส่งเสริม พัฒนางานวิจัยทางด้านสถิติ วิทยาศาสตร์ข้อมูล และด้านการประกันภัย ให้มีมาตรฐานและคุณภาพในระดับประเทศ อีกทั้งยังเป็นเวทีสำหรับการนำเสนอผลงานทางวิชาการและแลกเปลี่ยนประสบการณ์ของนักศึกษาทั้งในระดับปริญญาตรีและระดับบัณฑิตศึกษา

ในการประชุมวิชาการครั้งนี้มีนักศึกษา/นิสิตส่งผลงานเข้าร่วมทั้งหมด 41 เรื่อง โดยแบ่งเป็นการนำเสนอแบบบรรยายจำนวน 13 เรื่อง และการนำเสนอแบบโปสเตอร์จำนวน 28 เรื่อง ในนามของคณะกรรมการดำเนินงาน ขอขอบคุณผู้ทรงคุณวุฒิทุกท่านที่สละเวลาอันมีค่าในการพิจารณาและวิพากษ์ผลงาน ตลอดจนขอขอบคุณวิทยากร คณาจารย์ นักศึกษา/นิสิต และผู้เข้าร่วมประชุมวิชาการทุกท่านที่ให้การสนับสนุนและมีส่วนร่วมในกิจกรรมครั้งนี้เป็นอย่างดี นอกจากนี้ ขอขอบคุณคณะกรรมการจัดการประชุมวิชาการทุกท่านที่ให้ความร่วมมืออย่างดียิ่ง จนทำให้การประชุมวิชาการระดับชาติด้านสถิติ วิทยาศาสตร์ข้อมูล และด้านการประกันภัย ครั้งที่ 3 ประจำปี พ.ศ.2569 สำเร็จลุล่วงด้วยความเรียบร้อย

ศาสตราจารย์ ดร.ยุพาภรณ์ อารีพงษ์
ประธานคณะกรรมการดำเนินงาน

สารบัญ

	หน้า
คำนำ	i
สารบัญ	ii
วิทยากรบรรยายในงานประชุม	v
รายชื่อผู้ทรงคุณวุฒิ	vi
กำหนดการโครงการประชุมวิชาการระดับชาติ ด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 3	viii
ผลงานวิจัยที่นำเสนอแบบบรรยายห้อง Oral Presentation 1	
OP02 กล้องอัจฉริยะเพื่อลดความเสี่ยง โรคคอมพิวเตอร์ซินโดรม	1
OP03 ระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง	9
OP09 การจัดกลุ่มพฤติกรรมผู้ใช้บริการร้านเกมออนไลน์ด้วยโมเดล RFM และอัลกอริทึมเหมินส์เพื่อการส่งเสริมการตลาด	17
OP11 การพัฒนาระบบแนะนำรายวิชาเรียนรายบุคคลโดยใช้เทคนิคการวิเคราะห์กฎความสัมพันธ์ กรณีศึกษานักเรียนระดับประถมศึกษาปีที่ 5	23
ผลงานวิจัยที่นำเสนอแบบบรรยายห้อง Oral Presentation 2	
OP04 A Modified Wilson-Type Confidence Interval for Binomial Proportions with Improved Finite-Sample Performance	29
OP05 การวิเคราะห์เชิงเปรียบเทียบกลยุทธ์การลงทุนน้ำมันดิบผ่านการเรียนรู้ของเครื่อง	35
OP06 การทำนายสัดส่วนสารให้สีสำหรับการผลิตลิปสติกด้วยการเรียนรู้ของเครื่อง	42
OP07 การประยุกต์ใช้การเรียนรู้ของเครื่องในการพยากรณ์ความภักดีและการเลิกใช้บริการของผู้บริโภคสับปะรดสิ่งบ่งชี้ทางภูมิศาสตร์ (GI): กรณีศึกษาจังหวัดนครพนม	48
OP14 การพยากรณ์คาร์บอนฟุตพริ้นท์จากการใช้ไฟฟ้าและการวิเคราะห์ดัชนีความยั่งยืนฮาร์โมนิกในระบบไฟฟ้า	55
ผลงานวิจัยที่นำเสนอแบบบรรยายห้อง Oral Presentation 3	
OP01 บัญชีกำหนดความน่าจะเป็นของการผิנדชำระหนี้ของผู้ซื้อรถยนต์จากข้อมูลเชิงธุรกรรม	66
OP08 การวิเคราะห์และเปรียบเทียบวิธีการประมาณค่าเงินสำรองสินไหมทดแทนในประกันความเสี่ยงภัยทรัพย์สิน	73
OP12 ลักษณะเชิงเศรษฐกิจและสังคมของผู้เอาประกันสุขภาพในประเทศไทย	83
OP13 การเรียนรู้แบบเสริมกำลังเชิงลึกสำหรับการให้คะแนนเครดิตและการให้สินเชื่อโดยใช้วิธีการบูตสแตร็ปแบบเบส	91

สารบัญ (ต่อ)

	หน้า
ผลงานวิจัยที่นำเสนอแบบโปสเตอร์ห้อง Poster Presentation 1	
PP01 Loan Approval Prediction Using Machine Learning: A Comparative Analysis of Classification Algorithms	102
PP02 การวิเคราะห์และจำแนกภาวะการนอนหลับด้วยเทคนิคการเรียนรู้ของเครื่อง โดยใช้ปัจจัยด้านสุขภาพและรูปแบบการดำเนินชีวิต	103
PP08 การแบ่งกลุ่มลูกค้าโดยใช้แบบจำลอง RFM ร่วมกับการแบ่งกลุ่มแบบ K-Means และ DBSCAN	104
PP09 การศึกษาเปรียบเทียบประสิทธิภาพของวิธีอนุกรมเวลาและเทคนิคการเรียนรู้ของเครื่อง ในการพยากรณ์จำนวนอุบัติเหตุทางถนนในระดับภูมิภาคของประเทศไทย	105
PP10 การพยากรณ์ผลตอบแทนหุ้น S&P 500 ด้วยการเรียนรู้ของเครื่องและปัจจัยเศรษฐกิจมหภาค	106
PP17 แพลตฟอร์มการเรียนรู้และการสอบดิจิทัล สาขาเทคโนโลยีธุรกิจดิจิทัล (ต่อเนื่อง) วิทยาลัยอาชีวศึกษาชลบุรี	107
PP18 การแบ่งส่วนภาพเชื้อแก้วหูจากภาพออโตสโคปโดยใช้โมเดลการเรียนรู้เชิงลึก	108
PP19 การพัฒนาระบบแจ้งและติดตามการแก้ไขข้อบกพร่องงานก่อสร้างพร้อมแดชบอร์ด วิเคราะห์ประสิทธิภาพโครงการ	109
PP22 การพยากรณ์ปริมาณของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) ในเขตปทุมวัน กรุงเทพมหานคร ด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง	110
ผลงานวิจัยที่นำเสนอแบบโปสเตอร์ห้อง Poster Presentation 2	
PP05 การเปรียบเทียบวิธีการพยากรณ์สำหรับจำนวนการเกิดของประชากรในประเทศไทย	111
PP07 การวิเคราะห์ความชุกและปัจจัยที่ส่งผลต่อการเสียชีวิตบนถนนในประเทศไทย	112
PP11 การเปรียบเทียบประสิทธิภาพตัวแบบ ARIMA และตัวแบบการถดถอยพหุคูณ ในการพยากรณ์ยอดจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย	113
PP13 การวัดประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ ด้วยแผนภูมิ PWMA	114
PP15 การพัฒนาแผนภูมิควบคุมผสมแบบไม่อิงพารามิเตอร์ EWMA- MA SR เพื่อตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ	115
PP20 การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม NEEWMA, Modified EWMA และ EWMA ในการตรวจจับค่าเฉลี่ยของกระบวนการ	116

สารบัญ (ต่อ)

	หน้า
PP23 การพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำของเขื่อนป่าสักชลสิทธิ์และเขื่อนขุนด่านปราการชล	117
PP24 การวิเคราะห์ปัจจัยที่มีผลต่อราคาห้องพักในประเทศไทยด้วยตัวแบบการถดถอยเชิงพื้นที่	118
PP25 การพยากรณ์ค่า PM2.5 ในกรุงเทพมหานคร โดยใช้เทคนิคควอนไทล์	119
ผลงานวิจัยที่นำเสนอแบบโปสเตอร์ห้อง Poster Presentation 3	
PP29 การพัฒนาและเปรียบเทียบตัวแบบความเสี่ยงสำหรับรถยนต์ไฟฟ้าและรถยนต์สันดาป ในธุรกิจประกันภัย	120
PP03 การพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรม และภาคการขนส่งในกรุงเทพมหานคร โดยใช้วิธีบอซซ์-เจนกินส์	121
PP04 การเปรียบเทียบวิธีการพยากรณ์สำหรับปริมาณการส่งออกข้าวของประเทศไทย	122
PP06 การวิเคราะห์ปัจจัยเสี่ยงในการคืนสินค้าด้วยการเรียนรู้ของเครื่อง เพื่อใช้ในการออกแบบกรมธรรม์ประกันภัย	123
PP12 การศึกษาแบบจำลอง ARIMA เพื่อพยากรณ์ค่าสินไหมทดแทน สำหรับประกันภัยเสริมรถยนต์	124
PP14 การประมาณค่าความเสี่ยงโรคมะเร็งปอดจากปัจจัยส่วนบุคคลและมลพิษทางอากาศ เพื่อการประเมินความเสี่ยงด้านสุขภาพ	125
PP16 การพยากรณ์จำนวนผู้โดยสารรถไฟฟ้า MRT สายสีน้ำเงิน	126
PP21 กรมธรรม์ประกันภัยคุ้มครองการสืบทอดชีวิตสุนัขด้วยเทคโนโลยีการโคลนนิ่ง	127
PP26 เครื่องมือสนับสนุนการวางแผนการเงินส่วนบุคคลด้วย VBA EXCEL	128
PP27 การเปรียบเทียบตัวแบบการพยากรณ์ปริมาณการผลิตยานยนต์รวมในประเทศไทย	129

วิทยากรบรรยายในงานประชุม

	<p>รองศาสตราจารย์ ดร.วิฐุรา พึ่งพาพงศ์ ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย</p>
	<p>รองศาสตราจารย์ ดร.ภาคภูมิ มุกดาสนิท สาขาวิชาวิทยาการคอมพิวเตอร์และปัญญาประดิษฐ์ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏจันทรเกษม</p>

รายชื่อผู้ทรงคุณวุฒิ

- | | |
|---|--|
| 1. รองศาสตราจารย์ ดร.พัทธ์ชนก ศรีสุรเดชชัย | มหาวิทยาลัยธรรมศาสตร์ |
| 2. รองศาสตราจารย์ ดร.ภทวรธรรม แสงนวกิจ | มหาวิทยาลัยธรรมศาสตร์ |
| 3. รองศาสตราจารย์ ดร.ภาคภูมิ มุกดาสนิท | มหาวิทยาลัยราชภัฏจันทรเกษม |
| 4. รองศาสตราจารย์ ดร.ลวณกร มุกดาสนิท | มหาวิทยาลัยราชภัฏจันทรเกษม |
| 5. รองศาสตราจารย์ ดร.ณัฐฉิณี ดีแท้ | มหาวิทยาลัยราชภัฏพิบูลสงคราม |
| 6. รองศาสตราจารย์ ดร.ระพีณ สุนทรวัฒน์ | สถาบันเทคโนโลยีปทุมวัน |
| 7. ผู้ช่วยศาสตราจารย์ ดร.ภวัต ภักดีศรานูวัต | มหาวิทยาลัยเชียงใหม่ |
| 8. ผู้ช่วยศาสตราจารย์ ดร.ปาริชาติ ภัทรพานิชชัย | มหาวิทยาลัยเชียงใหม่ |
| 9. ผู้ช่วยศาสตราจารย์ รุจิรา จุลภักดี | มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก |
| 10. ผู้ช่วยศาสตราจารย์ ดร.พิเชฐ คุณากรวงศ์ | มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี |
| 11. ผู้ช่วยศาสตราจารย์ ดร.มธุรส ผ่านเมือง | มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี |
| 12. ผู้ช่วยศาสตราจารย์ ดร.ปิยธิดา พันธนะ | มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร |
| 13. ผู้ช่วยศาสตราจารย์ ดร.ศิริเรือง พัฒน์ช่วย | มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ |
| 14. ผู้ช่วยศาสตราจารย์ ดร.พศุภพิงศ์ เฟ็งศิริ | มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา |
| 15. ผู้ช่วยศาสตราจารย์ ดร.ธิปไตย พงษ์ศาสตร์ | มหาวิทยาลัยขอนแก่น |
| 16. รองศาสตราจารย์ ดร.วุฒิชัย ศรีโสดาพล | มหาวิทยาลัยขอนแก่น |
| 17. ผู้ช่วยศาสตราจารย์ ดร.ทศพร แดงธรรม | มหาวิทยาลัยขอนแก่น |
| 18. ผู้ช่วยศาสตราจารย์ ดร.กชพร การุณ | มหาวิทยาลัยนเรศวร |
| 19. ผู้ช่วยศาสตราจารย์ ดร.ธนพล พุกเส็ง | มหาวิทยาลัยบูรพา |
| 20. ผู้ช่วยศาสตราจารย์ ดร.ภัทรภาพร ทองน้อม | มหาวิทยาลัยบูรพา |
| 21. ผู้ช่วยศาสตราจารย์ ดร.สมบัติ ฝอยทอง | มหาวิทยาลัยบูรพา |
| 22. ผู้ช่วยศาสตราจารย์ ดร.อภิศักดิ์ ไชยโรจน์วัฒนา | มหาวิทยาลัยบูรพา |
| 23. ผู้ช่วยศาสตราจารย์ ดร.อุไรวรรณ บัวดุม | มหาวิทยาลัยบูรพา |
| 24. ผู้ช่วยศาสตราจารย์ ดร.มนชยา เจียงประดิษฐ์ | มหาวิทยาลัยมหาสารคาม |
| 25. ผู้ช่วยศาสตราจารย์ ดร.หยาดพิรุณ สุภรากรสกุล | มหาวิทยาลัยราชภัฏเพชรบูรณ์ |
| 26. ผู้ช่วยศาสตราจารย์ ดร.ศรัญญา ทองสุข | มหาวิทยาลัยราชภัฏพิบูลสงคราม |
| 27. ผู้ช่วยศาสตราจารย์ ดร.นฤมล ชูเมือง | มหาวิทยาลัยราชภัฏหมู่บ้านจอมบึง |
| 28. ผู้ช่วยศาสตราจารย์ ดร.ดิเรก บัวหลวง | มหาวิทยาลัยราชภัฏอุดรดิตถ์ |
| 29. ผู้ช่วยศาสตราจารย์ ดร.วนิดา ลิ้มมัน | มหาวิทยาลัยวลัยลักษณ์ |
| 30. อาจารย์ ดร.ปิยพล ไพจิตร | มหาวิทยาลัยศิลปากร |
| 31. อาจารย์ ดร.วรวิทย์ ยิ้มแย้ม | มหาวิทยาลัยราชภัฏเพชรบุรี |
| 32. อาจารย์ ดร.ว่าที่ร้อยเอก เฉลิมรัช นนทะภา | มหาวิทยาลัยเชียงใหม่ |
| 33. อาจารย์ ดร.สุรเดช อินทกรณ์ | มหาวิทยาลัยมหิดล |
| 34. อาจารย์ ดร.สุริยะ พิณजार | มหาวิทยาลัยเกษตรศาสตร์ |
| 35. อาจารย์ ดร.สุนิสา จันท์น้ำท่วม | มหาวิทยาลัยนเรศวร |
| 36. อาจารย์ ดร.เพียงฤทัย หนูสวัสดิ์ | มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ |
| 37. อาจารย์สมพร พิงสม | มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ |
| 38. ศาสตราจารย์ ดร.ยุพากรณ์ อารีพงษ์ | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ |
| 39. ศาสตราจารย์ ดร.สอาด นิวิศพงษ์ | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ |
| 40. ศาสตราจารย์ ดร. ดร.เสาวณิต สุขภารังษี | มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ |

กำหนดการ

โครงการประชุมวิชาการระดับชาติ ด้านสถิติ วิทยาศาสตร์ข้อมูล และการประกันภัย ครั้งที่ 3

The 3rd National Conference on Statistics, Data Science and Insurance (NCSDI 2026)

วันที่ 3 เมษายน พ.ศ. 2569

(รูปแบบออนไลน์)

เวลา	กิจกรรม
08.45 – 09.00 น.	พิธีเปิดการประชุมวิชาการ NCSDI 2026 โดย: 1) ศาสตราจารย์ ดร.บุพการณ์ อารีพงษ์ หัวหน้าภาควิชาสถิติประยุกต์ 2) รองศาสตราจารย์ ดร.เพ็ชรพุด กมลจิตรประภา คณบดีคณะวิทยาศาสตร์ประยุกต์ Join Zoom Meeting: https://zoom.us/j/6805082182?omn=97667222252 Meeting ID: 680 508 2182
09.00 – 9.30 น.	การบรรยายพิเศษ เรื่อง “Discrete-Time Survival Analysis as a Scalable Bridge Between Longitudinal EHR Data and Machine Learning” โดย รองศาสตราจารย์ ดร.วิฐรา พึ่งพาพงศ์ ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย Join Zoom Meeting: https://zoom.us/j/6805082182?omn=97667222252 Meeting ID: 680 508 2182
09.45 – 10.15 น.	การบรรยายพิเศษ เรื่อง “Transforming Biological Data into Intelligent Life Sciences: Shaping the Health of Tomorrow” โดย รองศาสตราจารย์ ดร.ภาคภูมิ มุกดาสนิท สาขาวิชาวิทยาการคอมพิวเตอร์และปัญญาประดิษฐ์ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏจันทรเกษม Join Zoom Meeting: https://zoom.us/j/6805082182?omn=97667222252 Meeting ID: 680 508 2182
10.30 – 12.00 น.	การนำเสนอผลงานวิจัยแบบบรรยาย (Oral presentation)
12.00 – 13.00 น.	พักรับประทานอาหารกลางวัน
13.00 – 15.30 น.	การนำเสนอผลงานวิจัยแบบโปสเตอร์ (Poster presentation)

หมายเหตุ: งานประชุมวิชาการฯ จะมีการบันทึกภาพและวิดีโอเพื่อนำไปใช้ประชาสัมพันธ์ผลงานในภายหลัง

ห้อง: Oral Presentation 1
เวลา: 10.30 – 11.45 น.
Chairman: ผู้ช่วยศาสตราจารย์ ดร.พีระศักดิ์ อินทรไพบุลย์
Join Zoom Meeting: <https://zoom.us/j/98378464394?pwd=HPYaqS6kVqEmkFimvr8l8a9mEshJAd.1>
Meeting ID: 983 7846 4394
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
10.30-10.45 น.	OP02	ณพัต พรหมเพ็ง	กล้องอัจฉริยะเพื่อลดความเสี่ยงโรคคอมพิวเตอร์ซินโดรม
10.45-11.00 น.	OP03	พระพาย นวมระวี	ระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง
11.00-11.15 น.	OP09	รุจิรา จุลภักดิ์	การจัดกลุ่มพฤติกรรมผู้ใช้บริการร้านเดิมเกมออนไลน์ด้วยโมเดล RFM และอัลกอริทึมเคมีนส์เพื่อการส่งเสริมการตลาด
11.15-11.30 น.	OP11	รุจิรา จุลภักดิ์	การพัฒนาระบบแนะนำรายวิชาเรียนรายบุคคลโดยใช้เทคนิคการวิเคราะห์หลักความสัมพันธ์กรณีศึกษานักเรียนระดับประถมศึกษาปีที่ 5
11.30 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 1		

ห้อง: Oral Presentation 2
เวลา: 10.30 – 11.45 น.
Chairman: รองศาสตราจารย์ ดร.ภทรวรรณ แสงนวกิจ
Join Zoom Meeting: <https://zoom.us/j/94197758728?pwd=xkOqEFcZ7b7ZhvrHUxIXz6xEXbYmpX.1>
Meeting ID: 941 9775 8728
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
10.30-10.45 น.	OP04	เฉลิมศักดิ์ มาอยู่	A Modified Wilson-Type Confidence Interval for Binomial Proportions with Improved Finite-Sample Performance
10.45-11.00 น.	OP05	บุญศรีมี แสนสวัสดิ์	การวิเคราะห์เชิงเปรียบเทียบกลยุทธ์การลงทุนน้ำมันดิบผ่านการเรียนรู้ของเครื่อง
11.00-11.15 น.	OP06	ชัยชนก รุ่งแก้ว	การทำนายสัดส่วนสารให้สีสำหรับการผลิตลิปสติกด้วยการเรียนรู้ของเครื่อง
11.15-11.30 น.	OP07	ณัฐชนนัท แก้วนิวงค์	การประยุกต์ใช้การเรียนรู้ของเครื่องในการพยากรณ์ความภักดีและการเลิกใช้บริการของผู้บริโภคสับปะรดถึงบ่งชี้ทางภูมิศาสตร์ (GI): กรณีศึกษาจังหวัดนครพนม
11.30-11.45 น.	OP14	จิรภัทร ตระกูลศักดิ์	การพยากรณ์คาร์บอนฟุตพริ้นท์จากการใช้ไฟฟ้าและการวิเคราะห์ดัชนีความยั่งยืนฮาร์โมนิกในระบบไฟฟ้า
11.45 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 2		

ห้อง: Oral Presentation 3
เวลา: 10.30 – 11.45 น.
Chairman: รองศาสตราจารย์ ดร.บุษยมาส พิมพ์พรรณชาติ
Join Zoom Meeting: <https://zoom.us/j/94003624256?pwd=2BaMbBKSNNk6XuWQwGby2320bbvYGgO.1>
Meeting ID: 940 0362 4256
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
10.30-10.45 น.	OP01	วันหยก อติเศรษฐพงศ์	ปัจจัยกำหนดความน่าจะเป็นของการผิคนัดชำระหนี้ของผู้ซื้อรถยนต์จากข้อมูลเชิงธุรกรรม
10.45-11.00 น.	OP08	ปพิชญา ชูจำ	การวิเคราะห์และเปรียบเทียบวิธีการประมาณค่าเงินสำรองสินไหมทดแทนในประกันความเสี่ยงภัยทรัพย์สิน
11.00-11.15 น.	OP12	สรพัศ วงศ์เคี่ยม	ลักษณะเชิงเศรษฐกิจและสังคมของผู้เอาประกันสุขภาพในประเทศไทย
11.15-11.30 น.	OP13	กรกนก จิตตรานนท์	การเรียนรู้แบบเสริมกำลังเชิงลึกสำหรับการให้คะแนนเครดิตและการให้สินเชื่อ โดยใช้วิธีการบูตสแตรัปแบบเบสส์
11.30 น.	ประกาศผลรางวัล Best Presentation ประจำห้อง Oral Presentation 3		

ห้อง: Poster Presentation 1
เวลา: 13.00 – 15.15 น.
Chairman: รองศาสตราจารย์ ดร.ณัฐฉินี ดีแท้
Join Zoom Meeting: <https://zoom.us/j/98778816385?pwd=KYM6L06VD5ncQDe0WbJQJRLMZ0v8sM.1>
Meeting ID: 987 7881 6385
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	PP01	ภูษิตา จิระภินโย	Loan Approval Prediction Using Machine Learning: A Comparative Analysis of Classification Algorithms
13.15-13.30 น.	PP02	วาทีณี ศรีอาวูช	การวิเคราะห์และจำแนกภาวะการนอนหลับด้วยเทคนิคการเรียนรู้ของเครื่องโดยใช้ปัจจัยด้านสุขภาพและรูปแบบการดำเนินชีวิต
13.30-13.45 น.	PP08	ปิยะเนตร อยู่ซัง	การแบ่งกลุ่มลูกค้าโดยใช้แบบจำลอง RFM ร่วมกับการแบ่งกลุ่มแบบ K-Means และ DBSCAN
13.45-14.00 น.	PP09	กมลทิพย์ พันธุ์สระคู	การศึกษาเปรียบเทียบประสิทธิภาพของวิธีอนุกรมเวลาและเทคนิคการเรียนรู้ของเครื่องในการพยากรณ์จำนวนอุบัติเหตุทางถนนในระดับภูมิภาคของประเทศไทย
14.00-14.15 น.	PP10	บัณฑิตา หง้าบุตร	การพยากรณ์ผลตอบแทนหุ้น S&P 500 ด้วยการเรียนรู้ของเครื่องและปัจจัยเศรษฐกิจมหภาค
14.15-14.30 น.	PP17	นุชจรรย์ ลุงพนธ์	แพลตฟอร์มการเรียนรู้และการสอบดิจิทัลสาขาเทคโนโลยีธุรกิจดิจิทัล (ต่อเนื่อง) วิทยาลัยอาชีวศึกษาชลบุรี
14.30-14.45 น.	PP18	ธนีสร สมรูป	การแบ่งส่วนภาพเยื่อแก้วหูจากภาพออดิโอสโคปโดยใช้โมเดลการเรียนรู้เชิงลึก
14.45-15.00 น.	PP19	ปิยวัช ชันทนิเทศน์	การพัฒนาระบบแจ้งและติดตามการแก้ไขข้อบกพร่องงานก่อสร้างพร้อมแดชบอร์ดวิเคราะห์ประสิทธิภาพโครงการ
15.00-15.15 น.	PP22	ฐิตินัย วิจิตรสาร	การพยากรณ์ปริมาณของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) ในเขตปทุมวัน กรุงเทพมหานคร ด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง
15.15 น.	ประกาศผลรางวัล Best Presentation ประจำปีห้อง Poster Presentation 1 และปิดการประชุม		

ห้อง: Poster Presentation 2
เวลา: 13.00 – 15.15 น.
Chairman: ผู้ช่วยศาสตราจารย์ ดร.ปิยธิดา พันธนะ
Join Zoom Meeting: <https://zoom.us/j/93372094020?pwd=36RcvLLVR52mK42YShkMdD3M3y2vOO.1>
Meeting ID: 933 7209 4020
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	PP05	ชญาดา ชุกะนันท์	การเปรียบเทียบวิธีการพยากรณ์สำหรับจำนวนการเกิดของประชากรในประเทศไทย
13.15-13.30 น.	PP07	จิราภรณ์ ตุ่มวงษา	การวิเคราะห์ความชุกและปัจจัยที่ส่งผลต่อการเสียชีวิตบนถนนในประเทศไทย
13.30-13.45 น.	PP11	พิมพ์รดา พ่วงพี	การเปรียบเทียบประสิทธิภาพตัวแบบ ARIMA และตัวแบบการถดถอยพหุคูณในการพยากรณ์ยอดจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย
13.45-14.00 น.	PP13	ปิยะจักษณ์ ชุมขุน	การวัดประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการด้วยแผนภูมิ PWMA
14.00-14.15 น.	PP15	ชนากานต์ สุวรรณฉวี	การพัฒนาแผนภูมิควบคุมผสมแบบไม่อิงพารามิเตอร์ EWMA- MA SR เพื่อตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ
14.15-14.30 น.	PP20	ภัทรกันย์ มีอุตสาห์	การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม NEEWMA, Modified EWMA และ EWMA ในการตรวจจับค่าเฉลี่ยของกระบวนการ
14.30-14.45 น.	PP23	ชนัญญา มาปุ๊ก	การพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำของเขื่อนป่าสักชลสิทธิ์และเขื่อนขุนด่านปราการชล
14.45-15.00 น.	PP24	วรพล จันท์กริ	การวิเคราะห์ปัจจัยที่มีผลต่อราคาห้องพักในประเทศไทยด้วยตัวแบบการถดถอยเชิงพื้นที่
15.00-15.15 น.	PP25	จิรภาส สามารธรรมย์	การพยากรณ์ค่า PM2.5 ในกรุงเทพมหานครโดยใช้เทคนิคควอนไทล์
15.15 น.	ประกาศผลรางวัล Best Presentation ประจำปีห้อง Poster Presentation 2 และปิดการประชุม		

ห้อง: Poster Presentation 3
เวลา: 13.00 – 15.30 น.
Chairman: ผู้ช่วยศาสตราจารย์ ดร.หยาดพิรุณ สุภรากรสกุล
Join Zoom Meeting: <https://zoom.us/j/93165386609?pwd=RMsRwz4NlV AmbQJoRvchClpulgUxma.1>
Meeting ID: 931 6538 6609
Passcode: 141595

เวลา	รหัส	ผู้นำส่งผลงาน	ชื่อบทความ
13.00-13.15 น.	PP29	ศศิวิมล โมคศิริ	การพัฒนาและเปรียบเทียบตัวแบบความเสี่ยงสำหรับรถยนต์ไฟฟ้าและรถยนต์สันดาปในธุรกิจประกันภัย
13.15-13.30 น.	PP03	ศุภกฤษฎ คำร้อย	การพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรมและภาคการขนส่งในกรุงเทพมหานคร โดยใช้วิธีบอกรีท-เจนกินส์
13.30-13.45 น.	PP04	กิตติยา พิมพ์คำมุล	การเปรียบเทียบวิธีการพยากรณ์สำหรับปริมาณการส่งออกข้าวของประเทศไทย
13.45-14.00 น.	PP06	กัญญาณัฐ เฟื่องเจริญ	การวิเคราะห์ปัจจัยเสี่ยงในการคินสินค้าด้วยการเรียนรู้ของเครื่องเพื่อใช้ในการออกแบบกรมธรรม์ประกันภัย
14.00-14.15 น.	PP12	จิตลาภัทร บัวแดง	การศึกษาแบบจำลอง ARIMA เพื่อพยากรณ์ค่าสินไหมทดแทนสำหรับประกันภัยเสริมรถยนต์
14.15-14.30 น.	PP14	ปาณิ ปุณณภากุล	การประมาณค่าความเสี่ยงโรคมะเร็งปอดจากปัจจัยส่วนบุคคลและมลพิษทางอากาศเพื่อการประเมินความเสี่ยงด้านสุขภาพ
14.30-14.45 น.	PP16	ขุนพล ทศนวิสุทธิ	การพยากรณ์จำนวนผู้โดยสารรถไฟฟ้า MRT สายสีน้ำเงิน
14.45-15.00 น.	PP21	ภาวิต จันทร์แสง	กรมธรรม์ประกันภัยคุ้มครองการสืบทอดชีวิตสุนัขด้วยเทคโนโลยีการโคลนนิ่ง
15.00-15.15 น.	PP26	ไชยวัฒน์ สำเภาทอง	เครื่องมือสนับสนุนการวางแผนการเงินส่วนบุคคลด้วย VBA EXCEL
15.15-15.30 น.	PP27	กิตติพันธ์ จิตอักษร	การเปรียบเทียบตัวแบบการพยากรณ์ปริมาณการผลิตยานยนต์รวมในประเทศไทย
15.30 น.	ประกาศผลรางวัล Best Presentation ประจำปีห้อง Poster Presentation 3 และปิดการประชุม		

กล้องอัจฉริยะเพื่อลดความเสี่ยงโรคคอมพิวเตอร์ซินโดรม

A Smart Camera System for Mitigating the Risk of Computer Vision Syndrome (CVS)

ณพัต พรหมเพ็ง ฌัฐวรา สุขสันต์ ศุภวิชญ์ มีสมศักดิ์ และ มธุรส ผ่านเมือง*
ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
(* mathuros_p@rmutt.ac.th)

บทคัดย่อ

โรคคอมพิวเตอร์ซินโดรม (Computer Vision Syndrome: CVS) ถือเป็นความเสี่ยงด้านสุขภาพจากการทำงานที่เพิ่มขึ้นอย่างต่อเนื่อง งานวิจัยนี้จึงนำเสนอการพัฒนา ระบบกล้องอัจฉริยะ (Smart Camera System: SCS) เพื่อใช้ในการติดตามและลดความเสี่ยง CVS แบบเรียลไทม์ โดยระบบ SCS ประยุกต์ใช้เทคโนโลยี Computer Vision ผ่านเฟรมเวิร์ก MediaPipe และ OpenCV ในการวิเคราะห์จุดสำคัญบนร่างกายและใบหน้า เพื่อประเมินพฤติกรรมเสี่ยงหลัก 3 ด้าน ได้แก่ ท่าทางคอที่ไม่เหมาะสม, การนั่งนิ่งเป็นเวลานาน, และอัตราการกระพริบตา ซึ่งการออกแบบทางเทคนิคนี้มุ่งเน้นเพื่อให้สามารถทำงานได้อย่างมีประสิทธิภาพด้วยฮาร์ดแวร์ทั่วไป

ผลการประเมินประสิทธิภาพของโมเดลโดยใช้ Confusion Matrix แสดงให้เห็นถึงความแม่นยำสูงในการจำแนกความเสี่ยง โดยโมเดลการตรวจจับการกระพริบตา มีประสิทธิภาพสูงสุดด้วยค่าความถูกต้อง (Accuracy) 0.90 ในขณะที่โมเดลการตรวจจับท่าทางศีรษะและคอ และโมเดลการตรวจจับการขยับ/การนั่งนิ่ง มีค่าความถูกต้องอยู่ที่ 0.80 นอกจากนี้ ทุกโมเดลมีค่าความแม่นยำ (Precision) เท่ากับ 1.00 ซึ่งบ่งชี้ว่าไม่มีการแจ้งเตือนผิดพลาด (False Positive) ส่งผลให้ระบบมีความน่าเชื่อถือสูงต่อประสบการณ์ผู้ใช้งาน เมื่อนำระบบที่พัฒนาขึ้นไปประเมินคุณภาพ พบว่าได้รับการยอมรับในระดับสูง โดยผลการประเมินจากผู้เชี่ยวชาญมีคะแนนเฉลี่ยรวมอยู่ในระดับดีมาก ($\bar{X} = 4.60$) และได้รับความพึงพอใจจากผู้ใช้งานกลุ่มตัวอย่างในระดับมาก ($\bar{X} = 4.34$) ผลลัพธ์เหล่านี้ยืนยันว่าระบบ SCS มีความน่าเชื่อถือทางเทคนิคและพร้อมนำไปประยุกต์ใช้เป็นเครื่องมือเชิงรุกในการส่งเสริมสุขภาพของพนักงานหน้าจอกอมพิวเตอร์

คำสำคัญ: กล้องอัจฉริยะ, โรคคอมพิวเตอร์ซินโดรม, การตรวจจับท่าทาง, การยศาสตร์

Abstract

Computer Vision Syndrome (CVS) is an increasingly prevalent occupational health risk. This research introduces a Smart Camera System (SCS) designed for real-time monitoring and mitigation of CVS risk. The SCS leverages Computer Vision technology via the MediaPipe and OpenCV frameworks to analyze facial and body landmarks, assessing three core risk behaviors: improper neck posture, prolonged static sitting, and low blink frequency. The technical design of the system focuses on high efficiency, enabling practical operation using standard, low-cost hardware.

The model performance evaluation using the Confusion Matrix demonstrated high precision in risk classification. The blink detection model achieved the highest performance with an accuracy of 0.90, while the neck posture and movement detection models both achieved an accuracy of 0.80. Notably, all models exhibited a precision of 1.00, indicating zero false positive alerts, which significantly enhances system reliability and user experience. Upon evaluating the developed system, it received high levels of acceptance. The quality assessment by experts yielded a 'very good' average score ($\bar{X} = 4.60$), and user satisfaction from the sample group was at a high level ($\bar{X} = 4.34$). These results confirm that the SCS system possesses technical reliability and is ready for application as a proactive tool to promote the well-being of computer screen users.

Keywords: Smart Camera System, Computer Vision Syndrome, Posture Detection, Ergonomics

1. บทนำ

การแพร่หลายของเทคโนโลยีดิจิทัลในช่วงทศวรรษที่ผ่านมา ประกอบกับการเปลี่ยนแปลงครั้งใหญ่สู่รูปแบบการทำงานจากที่บ้าน (Work From Home) หลังจากการระบาดของ COVID-19 ได้นำไปสู่การเพิ่มขึ้นอย่างมีนัยสำคัญของระยะเวลาการสัมผัสหน้าจอกอมพิวเตอร์ที่ยาวนานขึ้น [1] การเปลี่ยนแปลงพฤติกรรมนี้ส่งผลให้เกิดความเสี่ยงต่อภาวะสุขภาพที่เกี่ยวข้องกับการทำงาน โดยเฉพาะอย่างยิ่ง โรคออฟฟิศซินโดรม (Office Syndrome) และ โรคคอมพิวเตอร์ซินโดรม (Computer Vision Syndrome: CVS) โรคออฟฟิศซินโดรมเป็นกลุ่มอาการทางระบบโครงร่างและกล้ามเนื้อ เช่น อาการปวดเรื้อรังบริเวณคอ บ่า ไหล่ และหลัง ซึ่งเป็นผลมาจากการนั่งทำงานในท่าคงที่หรือท่าทางที่ไม่เหมาะสมเป็นเวลานาน [1] ในขณะที่ CVS เป็นกลุ่มอาการทางสายตาที่หลากหลาย เช่น อาการตาแห้ง ปวดตา และปวดศีรษะ ซึ่งเชื่อมโยงโดยตรงกับการจ้องมองจอแสดงผลดิจิทัลอย่างต่อเนื่อง ข้อมูลทางสถิติชี้ให้เห็นว่าประชากรวัยทำงานจำนวนมหาศาลต้องใช้คอมพิวเตอร์ในการปฏิบัติงาน ทำให้บุคคลเหล่านี้อยู่ในกลุ่มที่มีความเสี่ยงสูงต่อการเกิดปัญหาด้านสุขภาพจากการยศาสตร์ (Ergonomics) ที่ไม่เหมาะสมและการขาดความรู้ในการป้องกัน [2] ภาวะเหล่านี้ไม่เพียงแต่บั่นทอนคุณภาพชีวิตของผู้ใช้งานเท่านั้น แต่ยังส่งผลกระทบต่อประสิทธิภาพและประสิทธิผลในการทำงานในระดับองค์กรอีกด้วย

กลยุทธ์การบรรเทาปัญหาสุขภาพจากการทำงานหน้าจอที่ใช้อยู่ในปัจจุบันมักเป็นแบบตั้งรับ (Passive) โดยส่วนใหญ่เป็นการอาศัยคำแนะนำด้านสุขภาพทั่วไป การแจ้งเตือนตามช่วงเวลา หรือการใช้ระบบจับเวลาพักสายตา แม้ว่าแนวทางเหล่านี้จะให้การป้องกันขั้นพื้นฐาน แต่ก็ขาดความสามารถในการปรับให้เข้ากับพฤติกรรมเฉพาะบุคคล และไม่สามารถติดตามการละเมิดหลักการยศาสตร์แบบทันที (Real-time) ได้อย่างมีประสิทธิภาพ [3] ข้อจำกัดที่สำคัญคือการขาดเครื่องมือการตรวจติดตามที่เป็นวัตถุวิสัย (Objective) ต่อเนื่อง และไม่รบกวนการทำงาน (Non-intrusive) เพื่อประเมินปัจจัยเสี่ยงหลักสามประการ ได้แก่ (1) ระยะเวลาการนั่งท่าเดิม, (2) ระดับความผิดปกติของท่าทางศีรษะและคอ, และ (3) ระยะห่างระหว่างดวงตาและหน้าจอกอมพิวเตอร์ ดังนั้น จึงมีความจำเป็นเร่งด่วนในการพัฒนาเทคโนโลยีที่สามารถให้ข้อมูลป้อนกลับที่เฉพาะเจาะจงแบบเรียลไทม์ด้วยข้อมูล และเกิดขึ้นทันที เพื่อปรับปรุงพฤติกรรมสุขภาพของผู้ใช้งาน [4]

เพื่อเติมเต็มช่องว่างงานวิจัยที่กล่าวมาข้างต้น บทความนี้จึงนำเสนอระบบกล้องอัจฉริยะ (Smart Camera System: SCS) ซึ่งออกแบบมาเพื่อการติดตามเชิงรุกและลดความเสี่ยงของโรคคอมพิวเตอร์ซินโดรมและปัญหาการยศาสตร์ที่เกี่ยวข้อง ระบบ SCS ใช้เว็บแคมทั่วไปและเทคโนโลยีการวิเคราะห์ภาพคอมพิวเตอร์ (Computer Vision) ขั้นสูง เพื่อวิเคราะห์พฤติกรรมการทำงานของผู้ใช้แบบเรียลไทม์ [5]

ระบบ SCS นี้ใช้ประโยชน์จากโครงสร้าง MediaPipe ซึ่งเป็นเฟรมเวิร์กที่เชื่อถือได้สำหรับการตรวจจับท่าทางของมนุษย์ (Human Pose Detection) และการติดตามจุดสำคัญบนใบหน้า (Facial Landmark Tracking) ด้วยประสิทธิภาพสูง [6]

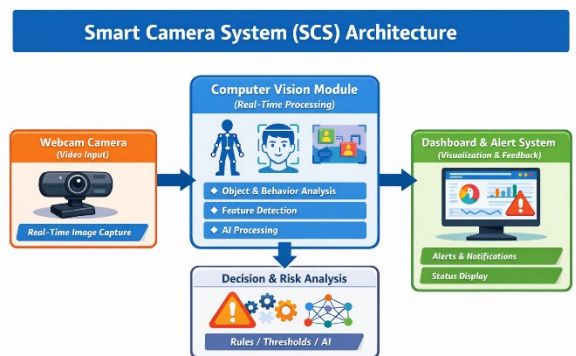
เทคโนโลยีนี้ช่วยให้ระบบสามารถตรวจจับและวิเคราะห์ตัวบ่งชี้ความเสี่ยงหลักได้อย่างแม่นยำ ได้แก่ (1) ท่าทางศีรษะและคอ (การก้มหรือยื่นศีรษะมากเกินไป), (2) ระยะเวลาการนั่ง (การตรวจวัดช่วงเวลาคงที่ที่ยาวนาน), และ (3) ระยะห่างระหว่างตาและจอ (การแจ้งเตือนเมื่อระยะห่างไม่เหมาะสม) พฤติกรรมเสี่ยงที่ตรวจจับได้จะกระตุ้นการแจ้งเตือนที่เหมาะสมและข้อมูลป้อนกลับเชิงให้ความรู้ซึ่งแสดงผลผ่านแดชบอร์ดส่วนกลาง

2. วิธีการวิจัย

ส่วนนี้จะอธิบายถึงสถาปัตยกรรมของระบบกล้องอัจฉริยะ (Smart Camera System: SCS) ที่นำเสนอ ตลอดจนระเบียบวิธีที่ใช้ในการวิเคราะห์พฤติกรรมเสี่ยงต่อโรคคอมพิวเตอร์ซินโดรม (CVS) ดังนี้

2.1 สถาปัตยกรรมของระบบกล้องอัจฉริยะ (System Architecture)

ระบบ SCS ได้รับการออกแบบให้ทำงานในลักษณะเรียลไทม์ (Real-time) โดยใช้เพียงอุปกรณ์ที่มีอยู่ทั่วไป (Off-the-shelf components) ประกอบด้วย (1) กล้องเว็บแคมสำหรับป้อนข้อมูลภาพ (2) โมดูลประมวลผลภาพ (Computer Vision Module) และ (3) ส่วนแสดงผลและแจ้งเตือน (Dashboard) ดังที่แสดงในภาพที่ 1 รวมระบบ



ภาพที่ 1: ภาพรวมระบบกล้องอัจฉริยะ (SCS)

หน้าที่หลักของระบบมีดังนี้

- 1) การรับข้อมูล (Data Acquisition) โดยรับสตรีมวิดีโอแบบต่อเนื่องจากกล้องเว็บแคมของผู้ใช้
- 2) การวิเคราะห์เชิงลึก (Deep Analysis) จากประมวลผลภาพโดยใช้เฟรมเวิร์ก MediaPipe เพื่อตรวจจับจุดสำคัญ (Landmarks) บนร่างกายและใบหน้า
- 3) การตัดสินใจความเสี่ยง (Risk Determination) จากการนำจุดสำคัญที่ได้มาคำนวณในแบบจำลองเชิงเรขาคณิต

(Geometric Models) เพื่อประเมินท่าทาง พฤติกรรมการขยับ และพฤติกรรมการกระพริบตา

4) การแจ้งเตือนและการแสดงผล (Feedback) โดยแสดงสถานะความเสี่ยงแบบเรียลไทม์ผ่านแดชบอร์ด และส่งการแจ้งเตือนเมื่อตรวจพบความเสี่ยงเกินเกณฑ์ที่กำหนด

2.2 การสกัดข้อมูลและเทคนิค โนโลยีการตรวจจับท่าทาง (Data Extraction and Pose Detection)

งานวิจัยนี้ได้ประยุกต์ใช้เทคโนโลยีการตรวจจับท่าทางมนุษย์ (Pose Detection) ซึ่งเป็นกระบวนการในการระบุและติดตามตำแหน่งของจุดสำคัญ (Keypoints) บนร่างกายและใบหน้า เพื่อนำมาวิเคราะห์ความถูกต้องของกายศาสตร์ [3] ระบบ SCS ใช้การทำงานร่วมกันระหว่าง MediaPipe และ OpenCV [4]

1) OpenCV ทำหน้าที่เป็นไลบรารีการประมวลผลภาพหลักในการจัดการการอ่านสตรีมวิดีโอจากกล้องเว็บแคม (Webcam Frame Acquisition) และการเตรียมข้อมูลภาพสำหรับการวิเคราะห์

2) MediaPipe ทำหน้าที่เป็นเฟรมเวิร์กการเรียนรู้ของเครื่อง (Machine Learning Framework) ในการสกัดจุดสำคัญ (Landmark Extraction) โดยใช้โมดูลหลักสองส่วน ได้แก่ MediaPipe Pose สำหรับตรวจจับจุดสำคัญ 33 จุดทั่วร่างกายเพื่อใช้ในการประเมินท่าทางการนั่งและการเคลื่อนไหวโดยรวม และ MediaPipe Face Mesh สำหรับตรวจจับจุดสำคัญบนใบหน้าและรอบดวงตา เพื่อใช้ในการคำนวณอัตราการกระพริบตา

ข้อมูลพิกัด (X, Y, Z) ของจุดสำคัญเหล่านี้จะถูกส่งต่อไปให้โมดูลถัดไปเพื่อประมวลผลเชิงคณิตศาสตร์และวิเคราะห์ความเสี่ยง

2.3 แบบจำลองอัลกอริทึมการจำแนกประเภทความเสี่ยง (Risk Classification Algorithms)

ระบบ SCS ใช้วิธีการจำแนกแบบอิงกฎเกณฑ์ (Rule-based Approach) โดยนำพิกัดของจุดสำคัญ (Landmarks) ที่ได้จาก MediaPipe มาคำนวณทางเรขาคณิตและเปรียบเทียบกับค่าเกณฑ์ (Threshold) ที่กำหนดไว้ โดยไม่ได้ใช้การฝึกสอนโมเดลแบบ Deep Learning ในขั้นตอนนี้ เพื่อลดภาระการประมวลผลและให้ผลลัพธ์ที่รวดเร็ว (Real-time) ระบบแบ่งการจำแนกพฤติกรรมเสี่ยงออกเป็น 3 ประเภท ดังนี้

2.3.1 โมเดลการตรวจจับท่าทางศีรษะและคอ (Neck Posture Model)

การตรวจจับท่าทางคอที่ไม่เหมาะสม (เช่น การก้มคอหรือยื่นศีรษะ) เป็นสิ่งสำคัญในการป้องกันอาการปวดคอเรื้อรัง (Office Syndrome) โดยคำนวณมุมความผิดปกติของคอ (θ_{Neck}) โดยใช้พิกัดของจุดสำคัญบริเวณหู (P_{Ear}) และจุดกึ่งกลางไหล่ ($P_{Shoulder}$) เพื่อหาแนวแกนของศีรษะเทียบกับ

แนวตั้งตรงของร่างกาย ดังเช่นงานวิจัยของ Al-Barhamtoshy et al. [7] ที่ระบุว่าวัดมุมคอ/ลำตัวสามารถตรวจจับการเคลื่อนไหวส่วนบนได้ ดังสมการ 1

$$\theta_{Next} = f(P_{Ear}, P_{Shoulder}) \quad (1)$$

การจำแนกความเสี่ยง โดยพิจารณามุม θ_{Neck} เกินเกณฑ์ที่กำหนด (เช่น $\theta_{Neck} > 20^\circ$) ติดต่อกันเป็นระยะเวลาที่กำหนด จะจัดประเภทเป็นท่าทางเสี่ยง และแจ้งเตือนให้ผู้ใช้ปรับท่าทาง

2.3.2 โมเดลการตรวจจับการขยับ/การนั่งนิ่ง (Movement Detection Model)

เพื่อป้องกันความเมื่อยล้าจากการนั่งในท่าเดิมนานเกินไป ระบบจะติดตามการเคลื่อนไหวของร่างกายส่วนบนอย่างต่อเนื่อง ระบบจะคำนวณขนาดการขยับรวม (Total Displacement Magnitude) ของจุดอ้างอิงบนลำตัว [6] (เช่น ไหล่) ภายในช่วงเวลา T โดยใช้สูตรดังสมการ 2

$$Displacement = \sum_{t=t_0}^{t_0+T} \sqrt{(X_t - X_{t-1})^2 + (Y_t - Y_{t-1})^2} \quad (2)$$

หากค่า Displacement ที่คำนวณได้มีค่าน้อยกว่าเกณฑ์ ϵ_{min} (Threshold of Movement) ติดต่อกันเป็นระยะเวลา T (เช่น 20 นาที) ระบบจะจัดประเภทเป็นไม่ขยับ และแจ้งเตือนให้ผู้ใช้พักหรือยืดเหยียดร่างกาย

2.3.3 โมเดลการตรวจจับการกระพริบตา (Blink Detection Model)

การลดความถี่ในการกระพริบตาเป็นตัวบ่งชี้ความเสี่ยงต่ออาการตาแห้งและ CVS โดยระบบใช้อัตราส่วนลักษณะตา (Eye Aspect Ratio: EAR) [8] ซึ่งคำนวณจากระยะห่างพิกัดของจุดสำคัญที่ได้จาก MediaPipe Face Mesh รอบดวงตา [4-6] โดย p คือพิกัดของจุดสำคัญรอบดวงตาดังสมการ 3

$$EAR = \frac{\|p2 - p6\| + \|p3 - p5\|}{2\|p1 - p4\|} \quad (3)$$

การจำแนกความเสี่ยง โดยระบบจะนับจำนวนการกระพริบตาเมื่อค่า EAR ลดลงต่ำกว่าเกณฑ์การหลับตา (Blink Threshold) และคำนวณอัตราการกระพริบตาด่อนาที (BPM) หาก BPM ต่ำกว่าเกณฑ์มาตรฐานทางสุขภาพ ระบบจะแจ้งเตือนให้ผู้ใช้พักสายตา

2.4 การประเมินประสิทธิภาพของโมเดล (Model Performance Evaluation)

การประเมินประสิทธิภาพของโมเดล ดำเนินการโดยใช้ชุดข้อมูลจริงจากผู้ใช้งาน และเปรียบเทียบผลลัพธ์การจำแนก

ของระบบกับข้อมูลจริง (Ground Truth) และประเมินประสิทธิภาพ โมเดล โดยใช้การวัดค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision) และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) [9] ซึ่งเป็นค่าที่ได้จากวิธีการทดสอบเพื่อหาค่าพยากรณ์ความถูกต้องของข้อมูลโดยคิดเป็นค่าร้อยละ (%) ดังสมการ ดังนี้

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

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

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

โดยที่ TP คือค่าพยากรณ์ถูกต้องเชิงบวก TN คือค่าพยากรณ์ถูกต้องเชิงลบ ส่วน FP คือค่าพยากรณ์ผิดพลาดเชิงบวก และ FN คือค่าพยากรณ์ผิดพลาดเชิงลบ

2.5 การประเมินคุณภาพของระบบโดยผู้เชี่ยวชาญและผู้ใช้งาน

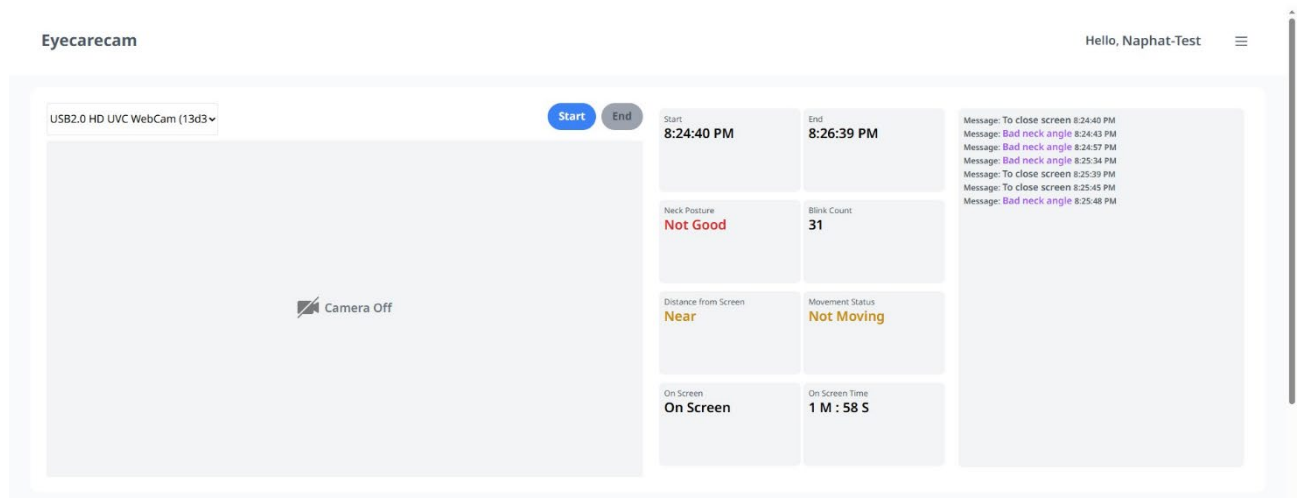
ก่อนนำไปทดลองใช้กับผู้ใช้งานและผู้เชี่ยวชาญ ระบบ Smart Camera System (SCS) ถูกนำไปพัฒนาในรูปแบบแอปพลิเคชันที่มีส่วนต่อประสานผู้ใช้งาน (User Interface) และ Dashboard (ภายใต้ชื่อ Eyecarecam) เพื่อนำเสนอผลการวิเคราะห์ความเสี่ยงและคำแนะนำแบบเรียลไทม์ โดยใช้ผลลัพธ์ของแบบจำลองที่ผ่านการประเมินความแม่นยำแล้ว การพัฒนาแอปพลิเคชันนี้จะรวมถึงฟังก์ชันการปรับเทียบท่าทาง (Calibration), การแสดงผลสถิติความเสี่ยง, และระบบแจ้งเตือนเฉพาะบุคคล ดังตัวอย่างภาพที่ 2 และภาพที่ 3

การประเมินคุณภาพของระบบ Eyecarecam ดำเนินการโดยแบ่งออกเป็น 2 กลุ่มหลัก โดยใช้เครื่องมือการประเมินแบบมาตราวัดลิเคิร์ต (Likert Scale) 5 ระดับ ได้แก่ ดีมาก (5) มาก (4) ปานกลาง (3) น้อย (2) น้อยที่สุด (1)

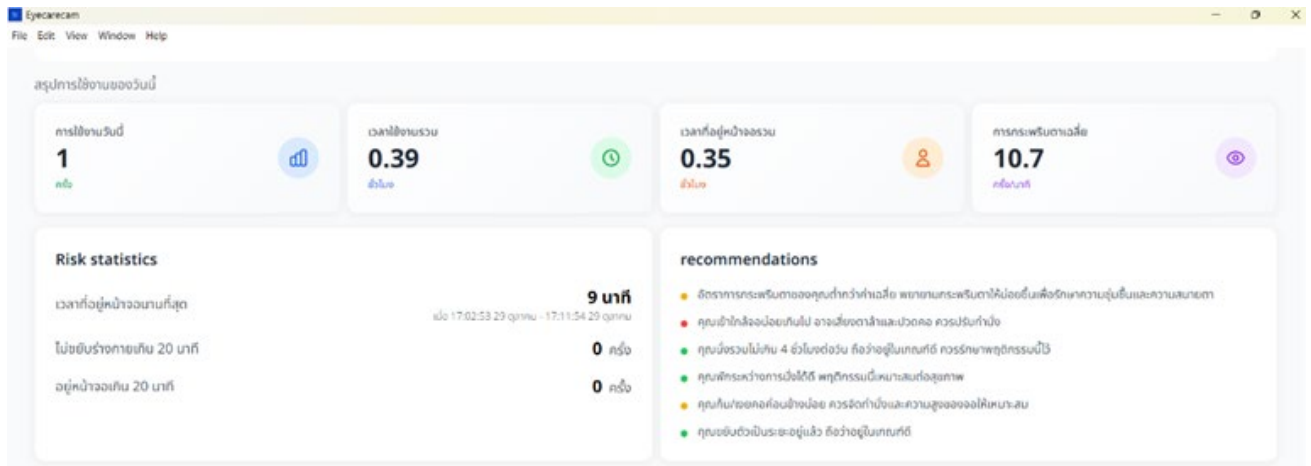
การประเมินคุณภาพโดยผู้เชี่ยวชาญ จะมุ่งเน้นไปที่ความถูกต้องทางวิชาการและเทคนิคของระบบ โดยเชิญผู้เชี่ยวชาญในสาขาที่เกี่ยวข้อง (ด้านสุขภาพ/การยศาสตร์ และด้านเทคโนโลยี/AI) จำนวน 2 ท่าน มาประเมินระบบ ตามเกณฑ์ที่กำหนดไว้ใน 5 ด้านหลัก (เช่น ประสิทธิภาพการตรวจจับ, ความถูกต้องของเนื้อหา, ความชัดเจนของการนำเสนอ)

การประเมินความพึงพอใจโดยผู้ใช้งาน จะมุ่งเน้นไปที่ประสบการณ์การใช้งานและการยอมรับระบบ (User Acceptance) โดยดำเนินการกับกลุ่มตัวอย่างที่ใช้งานคอมพิวเตอร์เป็นประจำ จำนวน 20 คน (ผู้หญิง 10 คน, ผู้ชาย 10 คน) ผู้ใช้งานจะทำการทดลองใช้แอปพลิเคชัน Eyecarecam ในสภาพแวดล้อมการทำงานจริงเป็นระยะเวลาไม่น้อยกว่า 5 ชั่วโมง ก่อนที่จะตอบแบบสอบถามเพื่อประเมินความพึงพอใจในมิติต่างๆ ได้แก่ ประโยชน์ที่รับรู้, ความง่ายในการใช้งาน, และความพึงพอใจต่อรูปแบบการแจ้งเตือน

โดยผู้ทดลองแต่ละคนจะทำการจำลองพฤติกรรมหน้าจอกอมพิวเตอร์ในระยะห่าง 50-70 เซนติเมตร บันทึกวิดีโอด้วยกล้องเว็บแคมความละเอียด 1080p ที่อัตราเฟรม (Frame Rate) 30 FPS แบ่งเป็น 3 สถานการณ์ (Session) ได้แก่ บันทึกท่าทางนั่งตัวตรง (Normal) สลับกับการก้มหรือยื่นคอผิดปกติ (Risk) บันทึกขณะนั่งทำงานปกติที่มีการขยับตัว สลับกับการนั่งนิ่งค้าง และบันทึกภาพใบหน้าขณะกระพริบตาปกติ และจงใจไม่กระพริบตา



ภาพที่ 2: หน้า User Interface



ภาพที่ 3: หน้า Dashboard

3. ผลการวิจัยและอภิปรายผล

3.1 การตั้งค่าการทดลองและชุดข้อมูล

การทดสอบประสิทธิภาพของโมเดลดำเนินการกับชุดข้อมูลที่รวบรวมจากผู้เข้าร่วมทดลองจำนวน 20 คน โดยบันทึกพฤติกรรมการทำงานหน้าจอกายใต้สภาวะที่หลากหลาย ข้อมูลที่บันทึกถูกนำไปเปรียบเทียบกับค่าจริง (Ground Truth) ซึ่งได้จากการสังเกตและกำหนดโดยผู้เชี่ยวชาญ การประเมินผลแบ่งออกเป็นสองส่วนหลัก คือ (1) การวัดค่าทางสถิติของโมเดล และ (2) การทดสอบการทำงานของระบบในสถานการณ์จริง (Real-time Test)

3.2 การประเมินประสิทธิภาพของโมเดล

การประเมินประสิทธิภาพของโมเดลตรวจจับความเสี่ยงทั้ง 3 ด้าน ใช้ตัวชี้วัดมาตรฐาน 3 ค่า คือ Precision, Recall, และ Accuracy ดังสรุปใน ตารางที่ 1

ตารางที่ 1 : ผลการประเมินประสิทธิภาพโมเดล

ค่าประสิทธิภาพ	Precision	Recall	Accuracy
การตรวจจับท่าทางศีรษะและคอ	1.00	0.78	0.80
การตรวจจับการขยับ/การนั่งนิ่ง	1.00	0.78	0.80
การตรวจจับการกระพริบตา	1.00	0.90	0.90

จากตารางที่ 1 แสดงให้เห็นว่าโมเดลมีความสามารถในการตรวจจับสูงมาก โดยเฉพาะค่า Precision ซึ่งเท่ากับ 1.00 สำหรับทุกแบบจำลอง หมายความว่า ไม่มีการแจ้งเตือนที่เป็น False Positive (FP) หรือการแจ้งเตือนความเสี่ยงโดยที่ผู้ใช้ไม่ได้กระทำการพฤติกรรมเสี่ยงจริง ซึ่งเป็นคุณสมบัติที่สำคัญอย่างยิ่งสำหรับระบบแจ้งเตือนเพื่อไม่ให้รบกวนการทำงานของผู้ใช้

3.2.1 การวิเคราะห์ผลลัพธ์ตามปัจจัยเสี่ยง

ก) การตรวจจับท่าทางศีรษะและคอ (Neck Posture Detection) พบว่าโมเดลมีความแม่นยำในการทำนายผลบวก (Precision) สูงถึง 1.00 และมีความถูกต้องโดยรวม (Accuracy) ที่ 0.80 อย่างไรก็ตาม ค่า Recall ที่ 0.78 ซึ่งให้เห็นว่าโมเดลสามารถตรวจจับพฤติกรรมที่เป็นความเสี่ยงได้ประมาณ 78% ของความเสี่ยงที่เกิดขึ้นจริงทั้งหมด โดยยังมีบางส่วนของโมเดลตรวจจับไม่พบ (False Negative)

ข) การตรวจจับการขยับ/การนั่งนิ่ง (Movement Detection) พบว่าผลการทดสอบแสดงค่า Precision ที่ 1.00 ค่า Recall ที่ 0.78 และค่า Accuracy ที่ 0.80 ซึ่งสอดคล้องกับการตรวจจับท่าทางศีรษะและคอ ผลลัพธ์นี้แสดงให้เห็นว่าแม้โมเดลจะไม่มีผลผิดพลาดในการระบุสิ่งที่ตรวจเจอ (ไม่มี False Positive) แต่ยังมีข้อจำกัดในการตรวจจับการเคลื่อนไหวบางจังหวะที่เกิดขึ้นจริง (มี False Negative จำนวน 4 ครั้ง) ซึ่งส่งผลให้ค่า Recall ไม่เต็ม 1.00

ค) การตรวจจับการกระพริบตา (Blink Detection) พบว่าพบว่ามีประสิทธิภาพสูงสุดในการทดสอบทั้ง 3 ด้าน โดยมีความแม่นยำ (Precision) ที่ 1.00 และมีความถูกต้อง (Accuracy) ที่ 0.90 อีกทั้งค่า Recall ที่ 0.90 บ่งชี้ว่าโอกาสที่ระบบจะพลาดการตรวจจับการกระพริบตาที่เกิดขึ้นจริงนั้นมีน้อยมาก (False Negative เพียง 2 ครั้ง)

3.2.2 การวิเคราะห์เชิงลึกด้วย Confusion Matrix

ตารางที่ 2 : ผลการทดสอบด้วย Confusion Matrix

ค่าประสิทธิภาพ	TP	FP	FN	TN
การตรวจจับท่าทางศีรษะและคอ	14	0	4	2
การตรวจจับการขยับ/การนั่งนิ่ง	14	0	4	2
การตรวจจับการกระพริบตา	18	0	2	0

การวิเคราะห์ค่าในตารางที่ 2 ยืนยันว่าค่า FP เป็น 0 สำหรับทุกโมเดล ซึ่งสอดคล้องกับค่า Precision = 1.00 โดยมีรายละเอียดดังนี้

ก) การตรวจจับท่าทางศีรษะและคอ และการตรวจจับการขยับ/การนั่งนิ่ง มีค่า FN (False Negative) เท่ากับ 4 ครั้ง ซึ่งหมายความว่า ใน 4 กรณี โมเดลได้จำแนกพฤติกรรมเสี่ยง (เช่น นั่งคอผิดท่า หรือนั่งนิ่งนานเกินไป) ว่าเป็นพฤติกรรมที่ถูกต้อง (True Negative) แม้ว่าค่า FN จะต่ำ แต่ก็แสดงถึงแนวโน้มของโมเดลที่อาจอนุญาตให้ท่าทางผิดพลาดผ่านไปได้อย่างน้อย ซึ่งอาจเกิดจากความคลาดเคลื่อนในการกำหนดขอบเขตของมุมมองกล้อง หรือความแปรปรวนของแสง

ข) การจับการกระพริบตา มีค่า FN เท่ากับ 2 ครั้ง และ TN เท่ากับ 0 การมีค่า FN ต่ำ แสดงให้เห็นว่า โมเดลมีความน่าเชื่อถือในการระบุการกระพริบตาที่เกิดขึ้นจริง

โดยสรุป ผลการประเมินแสดงให้เห็นว่าแบบจำลองมีความสมดุลระหว่าง Precision และ Recall ในระดับที่ดีมาก โดยเฉพาะอย่างยิ่งค่า Precision ที่ช่วยลดความรำคาญของผู้ใช้จากการแจ้งเตือนที่ผิดพลาด (False Alarms) ทำให้ระบบ SCS มีประสิทธิภาพสูงและพร้อมสำหรับการใช้งานจริง

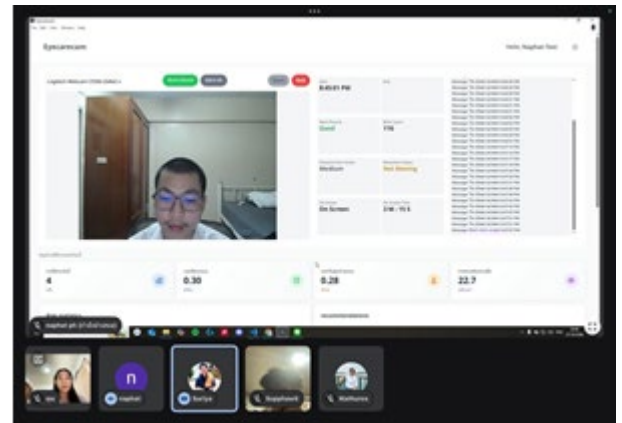
3.2.3 การตีความผลลัพธ์เชิงประสิทธิภาพ

ผลลัพธ์ที่ได้จากรายการที่ 1 (Precision = 1.00 สำหรับทุกโมเดล) เป็นข้อบ่งชี้ที่สำคัญถึงความน่าเชื่อถือของระบบในการใช้งานจริง ค่า Precision ที่สมบูรณ์แบบ หมายความว่า ระบบไม่มีการแจ้งเตือนที่เป็นบวกเท็จ (False Positive: FP=0) ซึ่งมีความสำคัญอย่างยิ่งต่อประสบการณ์ผู้ใช้ (User Experience) เนื่องจากผู้ใช้จะไม่ถูกรบกวนจากการแจ้งเตือนที่ผิดพลาด ทำให้มั่นใจได้ว่าค่าแนะนำที่ส่งไปนั้นเกิดจากพฤติกรรมเสี่ยงที่เกิดขึ้นจริง ซึ่งช่วยรักษาอัตราการปฏิบัติตาม (Compliance Rate) ของผู้ใช้ไว้ได้สูง

อย่างไรก็ตาม โมเดลการจับคอและการจับการขยับมีค่า False Negative (FN) เท่ากับ 4 ครั้ง (ตารางที่ 2) ซึ่งหมายความว่า มีพฤติกรรมเสี่ยงจริงบางส่วนที่ระบบจำแนกพลาดไปว่าเป็นพฤติกรรมปกติ แม้ว่าค่า FN ที่เกิดขึ้นจะน้อยมาก แต่ก็ยังเป็นข้อจำกัดที่ควรนำมาพิจารณาในการพัฒนาต่อไป โดยอาจมีสาเหตุมาจากความแปรปรวนของสภาพแสง หรือมุมมองของกล้องที่จำกัด ซึ่งเป็นความท้าทายที่พบได้ทั่วไปในระบบที่ใช้กล้องเว็บแคมทั่วไป [6]

3.3 ผลการทดสอบ โมเดลแบบเรียลไทม์

การทดสอบการทำงานของระบบ Smart Camera System (SCS) แบบเรียลไทม์แสดงให้เห็นว่า ระบบสามารถประมวลผลสตรีมภาพจากเว็บแคมได้อย่างต่อเนื่อง และแสดงผลการวิเคราะห์ที่ปัจจัยเสี่ยงผ่านแดชบอร์ดได้อย่างรวดเร็ว ดังนี้



ภาพที่ 4: การทดสอบโมเดลแบบ Real-time ของผู้เชี่ยวชาญ

3.3.1 ผลการประเมินคุณภาพจากผู้เชี่ยวชาญ

การประเมินคุณภาพของระบบ โดยผู้เชี่ยวชาญ พบว่า คะแนนเฉลี่ยรวม 4.60 ซึ่งอยู่ในระดับดีมาก สามารถสรุปได้ว่า ความสามารถของระบบในการตรวจจับท่าทางที่เสี่ยงต่อโรค CVS มีความถูกต้องและแม่นยำ และอัตราการตรวจจับท่าทางที่ไม่เหมาะสมอย่างครบถ้วน (Recall) นอกจากนี้ ประสิทธิภาพของโมเดล Machine Learning ในการจำแนกท่าทางที่ผิดปกติจากการเรียนรู้ และความสามารถในการทำงานร่วมกันของกล้องเว็บแคมและซอฟต์แวร์ที่พัฒนาขึ้นมานั้น ยืนยันว่าการใช้ MediaPipe ร่วมกับ OpenCV มีความเหมาะสมและมีประสิทธิภาพในการนำไปใช้งานจริง

3.3.2 ผลการประเมินความพึงพอใจของผู้ใช้งาน

การประเมินความพึงพอใจนี้มีวัตถุประสงค์เพื่อประเมินความง่ายในการใช้งาน (Ease of Use), ประโยชน์ที่ผู้ใช้รับรู้ (Perceived Usefulness), และการยอมรับ (Acceptance) ของแอปพลิเคชัน Eyecarecam ในการนำไปใช้จริงในชีวิตประจำวัน โดยผู้เข้าร่วมทดลองได้ติดตั้งและใช้งานแอปพลิเคชัน Eyecarecam ในระหว่างการทำงานหน้าจอคอมพิวเตอร์ตามปกติ หลังจากนั้น ได้มีการประเมินผลความพึงพอใจโดยใช้แบบสอบถาม ผลการประเมินพบว่า คะแนนเฉลี่ยรวมของความพึงพอใจมีค่าเท่ากับ 4.34 อยู่ในระดับมาก โดยมีรายละเอียดดังนี้

ก) ด้านการรับรู้ประโยชน์และการบรรลุเป้าหมายสุขภาพ พบว่าผู้ใช้งานรับรู้ว่าการช่วยลดพฤติกรรมเสี่ยงและปรับปรุงท่าทางได้อย่างเหมาะสม คะแนนเฉลี่ยรวมของความพึงพอใจมีค่าเท่ากับ 4.50 อยู่ในระดับดีมาก

ข) ด้านความพึงพอใจต่อ Dashboard และข้อมูล พบว่าผู้ใช้งานมีความพึงพอใจต่อการจัดวางองค์ประกอบและความสวยงามของ Dashboard ในระดับดีมาก คะแนนเฉลี่ยรวมของความพึงพอใจมีค่าเท่ากับ 4.70 ซึ่งยืนยันว่าการนำเสนอข้อมูลเชิงสถิติผ่านอินเทอร์เฟซที่ชัดเจนประสบความสำเร็จในการสื่อสารข้อมูลสุขภาพ

ค) ด้านความง่ายในการใช้งานและการยอมรับ พบว่าผู้ใช้งานส่วนใหญ่รับรู้ว่าการใช้ระบบมีความง่ายในการใช้งาน

คะแนนเฉลี่ยรวมของความพึงพอใจมีค่าเท่ากับ 4.60 อยู่ในระดับดีมาก ผลลัพธ์นี้มีความสำคัญอย่างยิ่ง เนื่องจากยืนยันว่าการออกแบบ โมเดลที่มีค่า False Positive (FP) เป็น 0 นั้นมีส่วนช่วยอย่างมากในการยอมรับระบบจากผู้ใช้งาน ซึ่งสอดคล้องกับความคาดหวังที่ว่าระบบแจ้งเตือนที่ดีต้องไม่รบกวนงานหลักของผู้ใช้

3.3.3 ความสอดคล้องกับแนวทางทางเทคนิคและการใช้งานจริง

การวิเคราะห์ท่าทางศีรษะและคอ โมเดลใช้การคำนวณมุมตามที่ระบุในส่วนระเบียบวิธีวิจัย ซึ่งสอดคล้องกับงานวิจัยของ Al-Barhamtoshy et al. [7] ที่ใช้ MediaPipe Pose ในการประเมินการเอียงของคอและลำตัว โดยใช้มุมเป็นปัจจัยกำหนดความเสี่ยง ผลลัพธ์ Accuracy ที่ 0.80 จากการวิจัยครั้งนี้ จึงสนับสนุนความถูกต้องของการใช้การวิเคราะห์เชิงมุมในการตรวจสอบการยศาสตร์ของคอ

ในส่วนความสามารถในการทำงานแบบเรียลไทม์ พบว่าระบบออกแบบมาเพื่อการทำงานบนอุปกรณ์ที่ใช้ฮาร์ดแวร์พื้นฐาน ซึ่งสอดคล้องกับงานวิจัยที่ใช้การเพิ่มประสิทธิภาพเชิง heuristic เช่น uDEAS ในงานของ Kim et al. [6] ที่พบว่าสามารถทำ 3D Pose Estimation ได้ในเวลาเพียง 0.033 วินาทีต่อเฟรมบน Single-Board Computer (SBC) โดยไม่ต้องพึ่งพา GPU ประสิทธิภาพสูง การที่ระบบ SCS สามารถทำงานได้ดีแบบเรียลไทม์ด้วย Accuracy 80% ในการจับการขยับ ยืนยันว่าการใช้การคำนวณเชิงเรขาคณิตด้วย MediaPipe นั้นเหมาะสมอย่างยิ่งสำหรับแอปพลิเคชันที่ต้องการความเร็วและต้นทุนต่ำ

3.3.4 การสนับสนุนปัจจัยเสี่ยงโรคคอมพิวเตอร์ซินโดรม (CVS)

การตรวจจับการกระพริบตา มีความแม่นยำสูง (Precision 0.90, Recall 0.90) ซึ่งยืนยันความสำคัญของการวัดตัวแปรนี้ ดังเช่นงานวิจัยของ Lapa et al. [10] ได้แสดงผลลัพธ์เชิงสำรวจอย่างชัดเจนว่า อัตราการกระพริบตาที่ลดลงมีความสัมพันธ์เชิงลบสูงกับความรุนแรงของ CVS ($r = -0.781$, $p = 0.005$) นั่นคือ ยิ่งผู้ใช้มีอัตราการกระพริบตาลดลงเท่าใด คะแนนความรุนแรงของ CVS ก็จะยิ่งสูงขึ้นเท่านั้น การที่โมเดล SCS ของเราสามารถตรวจจับการกระพริบตาได้อย่างแม่นยำ จึงทำให้ระบบเป็นเครื่องมือวินิจฉัยและแทรกแซงที่มีศักยภาพสูงในการลดความเสี่ยงตาแห้งและเมื่อยล้าทางสายตา โมเดลการจับการขยับที่ท่าคะแนนได้ค่อนข้างสมบูรณ์ (Accuracy 0.80) ช่วยให้ระบบสามารถส่งการแจ้งเตือนพักเมื่อผู้ใช้นั่งนิ่งเป็นเวลานานเกินไป ซึ่งสอดคล้องกับคำแนะนำด้านยศาสตร์ทั่วไปที่ระบุว่า การนั่งงอที่นานเกินไปเป็นสาเหตุหลักของอาการปวดสะสม

3.3.5 ข้อจำกัดและการพัฒนาในอนาคต

แม้ว่าระบบ SCS จะแสดงประสิทธิภาพที่น่าประทับใจ แต่ผลลัพธ์ที่มีค่า FN (False Negative) บ้างเล็กน้อยยังคงเป็น

ประเด็นที่ต้องปรับปรุง ซึ่งนำไปสู่การกำหนดทิศทางงานวิจัยในอนาคต ดังนี้

ก) การจัดการกับสภาพแวดล้อมที่ซับซ้อน แม้ว่าโมเดลจะมีความแข็งแกร่งเมื่อต้องเผชิญกับสิ่งกีดขวาง (Obstacles) บ้าง แต่ประสิทธิภาพยังคงอาจลดลงภายใต้สภาวะแสงที่เปลี่ยนแปลงอย่างรวดเร็ว (Rapid Lighting Changes) หรือในมุมมองที่เอียงมากเกินไป (Extreme Camera Angles) ตามที่กล่าวถึงในงานของ Thao et al. [11] และ Kim et al. [6] ที่เน้นย้ำถึงความท้าทายนี้ ดังนั้น งานในอนาคตควรมุ่งเน้นไปที่การใช้เทคนิค Deep Learning ที่ซับซ้อนยิ่งขึ้น หรือการฝึกโมเดลด้วยชุดข้อมูลที่ครอบคลุมสภาวะแวดล้อมที่หลากหลายมากขึ้น

ข) การเพิ่มการวิเคราะห์เชิงลึกโดยพัฒนาโมเดลให้สามารถวิเคราะห์ตัวแปรที่เกี่ยวข้องกับความเมื่อยล้าทางสายตาเพิ่มเติม เช่น การตรวจจับระยะห่างระหว่างตาและจอ (Distance to Screen) และการติดตามทิศทางการมอง (Gaze Estimation) จะช่วยเสริมความสมบูรณ์ของระบบให้สามารถทำนาย CVS ได้อย่างครอบคลุมมากขึ้น [11]

4. สรุปผล

งานวิจัยนี้ได้นำเสนอและพัฒนา ระบบกล้องอัจฉริยะ (Smart Camera System: SCS) ภายใต้ชื่อแอปพลิเคชัน Eyecarecam ซึ่งมีวัตถุประสงค์เพื่อติดตามและลดความเสี่ยงต่อการเกิดโรคคอมพิวเตอร์ซินโดรม (CVS) ในกลุ่มผู้ใช้งานคอมพิวเตอร์เป็นประจำ โดยใช้การวิเคราะห์ภาพคอมพิวเตอร์ (Computer Vision) บนฮาร์ดแวร์ต้นทุนต่ำ ผลการวิจัยสรุปได้ดังนี้

4.1 การพัฒนาโมเดลเชิงเทคนิค

ระบบ SCS ประสบความสำเร็จในการพัฒนาแบบจำลองการจำแนกประเภทความเสี่ยง 3 ด้านหลัก (คอ, การขยับ, การกระพริบตา) โดยใช้การคำนวณเชิงเรขาคณิตจากจุดสำคัญของร่างกายที่สกัดโดย MediaPipe/OpenCV ผลการทดสอบด้วย Confusion Matrix แสดงให้เห็นถึงประสิทธิภาพที่โดดเด่น โดยมีค่า Precision เท่ากับ 1.00 ในทุกโมเดล ซึ่งมีความสำคัญอย่างยิ่งต่อการใช้งานจริง เนื่องจากยืนยันว่าระบบสามารถ กำจัดการแจ้งเตือนที่ผิดพลาด (False Positive) ได้อย่างสมบูรณ์ ทำให้ผู้ใช้ไม่รู้สึกรำคาญหรือถูกรบกวนในการทำงาน

4.2 ประสิทธิภาพสูงสุดของการตรวจจับการกระพริบตา

โมเดลการตรวจจับการกระพริบตาแสดงประสิทธิภาพสูงสุดด้วยค่า Recall และ Accuracy ที่ 0.90 ซึ่งมีความสำคัญต่อการป้องกัน CVS โดยตรง เนื่องจากสอดคล้องกับหลักฐานทางวิชาการที่ระบุว่า อัตราการกระพริบตาที่ลดลงมีความสัมพันธ์เชิงลบสูงกับความรุนแรงของอาการตาแห้งและความเมื่อยล้าทางสายตา ทำให้ระบบ SCS มีศักยภาพสูงในการเป็นเครื่องมือแทรกแซงเชิงพฤติกรรม

4.3 การยอมรับคุณภาพของระบบจากผู้เชี่ยวชาญและผู้ใช้งาน

ผลการประเมินจากผู้เชี่ยวชาญ พบว่าคะแนนเฉลี่ยรวมอยู่ในระดับดีมาก มีค่าเฉลี่ยเท่ากับ 4.60 โดยเฉพาะความสามารถในการตรวจจับที่ละเอียดและถูกต้องตามหลักการยศาสตร์

ผลการประเมินความพึงพอใจของผู้ใช้งานโดยรวมอยู่ในระดับดีมาก มีค่าเฉลี่ยเท่ากับ 4.34 สะท้อนว่าผู้รับรู้อำนาจระบบช่วยลดพฤติกรรมเสี่ยงและไม่สร้างความรบกวน (Acceptance) ซึ่งสนับสนุนความสำเร็จของระบบในการเปลี่ยนจากการติดตามสุขภาพแบบตั้งรับไปสู่การแทรกแซงเชิงรุกที่มีความเฉพาะบุคคล

5. เอกสารอ้างอิง

- [1] จันทน์ นิลเลิศ. การนั่งตามหลักการยศาสตร์. เวชบัณฑิตศิริราช. 2560; 10(1):23-28.
- [2] ทินกร ชุณหภัทรกุล. การวิจัยและพัฒนาเว็บแอปพลิเคชันตรวจจับและแจ้งเตือนการล้ม สำหรับผู้สูงอายุด้วยมีเดียไปป์เฟรมเวิร์ค. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเซาท์อีสต์ปางกอก. 2567; 4(1):55-67.
- [3] คชากฤษ เหลี่ยมไธสง และพลาธิป ลุนคุณ. การออกแบบและประเมินองค์ประกอบของแอปพลิเคชันปรับเปลี่ยนพฤติกรรมเสี่ยงของโรคออฟฟิศซินโดรม. วารสารวิชาการการประยุกต์ใช้เทคโนโลยีสารสนเทศ. 2567; 10(2):137-150.
- [4] Bazarevsky V, Grishchenko I, Raveendran K, Zhu T, Zhang F & Grundmann M. BlazePose: On-device Real-time Body Pose tracking. Computer Vision and Pattern Recognition. 2020; arXiv:2006.10204.
- [5] Boesch G. The Complete Guide to OpenPose [document on the Internet]. 2024 [cited 2025 Dem 15]. Available from: <https://viso.ai/deep-learning/openpose/>.
- [6] Kim, J-W, Choi, J-Y, Ha, E-J & Choi, J-H. Human pose estimation using MediaPipe Pose and optimization method based on a humanoid model. Applied Sciences. 2023;13(4), 2700.
- [7] Al-Barhamtoshy HM, AlHarbi K & Rashad A. An AI Analytical Model for Human's Posture Analysis: Posture Correction with MediaPipe. 2nd International Conference on Advanced Innovations in Smart Cities (ICAISC); 09-11 February 2025, Jeddah, Saudi Arabia: IEEE, 2025.
- [8] Soukupová T, & Čech J. Eye blink detection using facial landmarks. In 21st computer vision winter workshop, Rimske Toplice, Slovenia. 2016;2(4).
- [9] Malta A, Mendes M and Farinha T. Augmented reality maintenance assistant using YOLOv5. Applied Sciences. 2021; 11(11):475.
- [10] Lapa I, Ferreira S, Mateus C, Rocha N, & Rodrigues M A. Real-Time Blink Detection as an Indicator of Computer Vision Syndrome in Real-Life Settings: An Exploratory Study. International Journal of Environmental Research and Public Health. 2023;20(5), 4569.
- [11] Thao L Q, Cuong D D, Hung V M, Vinh L T, Nghia D T, Hai D H, & Nhi N N. Eye Strain Detection During Online Learning. Intelligent Automation & Soft Computing. 2023;35(3), 3517-3529.

ระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง

Intelligent Healthcare Bed System for Bedridden Patients

พระพาย นวมระวี กนกวรรณ กิจไพบุลย์ทรัพย์ สุภัตสร ศรีโคตร และ มธุรส ผ่านเมือง*
ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
(* mathuros_p@rmutt.ac.th)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและประเมินประสิทธิภาพระบบเตียงอัจฉริยะสำหรับดูแลผู้ป่วยติดเตียง โดยประยุกต์ใช้เทคโนโลยี Internet of Things (IoT) เพื่อเฝ้าระวังสถานะการอยู่บนเตียงและการเคลื่อนไหวแบบเรียลไทม์ ขั้นตอนการดำเนินงานประกอบด้วย (1) การออกแบบโครงสร้างระบบ แบ่งเป็นส่วนรับข้อมูลจากเซนเซอร์ ส่วนประมวลผล และส่วนแสดงผล (2) การติดตั้ง Load Cell Sensor ร่วมกับ โมดูล HX711 เพื่อตรวจจับแรงกดบนเตียง และติดตั้ง PIR Motion Sensor เพื่อตรวจจับการเคลื่อนไหว (3) การพัฒนาโปรแกรมควบคุมด้วย NodeMCU ESP8266 และเชื่อมต่อข้อมูลผ่านเครือข่าย Wi-Fi ไปยังแพลตฟอร์ม Blynk และ (4) การทดสอบและประเมินประสิทธิภาพด้วย Confusion Matrix และตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall และ F1-score จากการทดสอบจำนวน 20 ครั้ง พบว่าการตรวจจับสถานะการอยู่บนเตียงมีค่า Accuracy 100%, Precision 100%, Recall 100% และ F1-score 100% ขณะที่การตรวจจับการเคลื่อนไหวมีค่า Accuracy 90%, Precision 80%, Recall 100% และ F1-score 89% นอกจากนี้ ผลการประเมินคุณภาพโดยผู้เชี่ยวชาญจำนวน 2 ท่าน มีค่าเฉลี่ยรวม 4.39 อยู่ในระดับดี และผลการประเมินจากผู้ใช้จำนวน 10 คน มีค่าเฉลี่ย 4.68 ส่วนเบี่ยงเบนมาตรฐาน 0.11 อยู่ในระดับดีมาก ระบบสามารถส่งข้อมูลและแจ้งเตือนแบบเรียลไทม์โดยมีความเสถียรของการเชื่อมต่อ ทั้งนี้สรุปได้ว่าระบบเตียงอัจฉริยะที่พัฒนาขึ้นมีประสิทธิภาพสูงและมีศักยภาพในการนำไปประยุกต์ใช้จริงเพื่อช่วยลดความเสี่ยงจากการตกเตียงและแผลกดทับ รวมถึงลดภาระการดูแลของผู้ดูแลในบริบทการดูแลระยะยาว

คำสำคัญ: ระบบเตียงอัจฉริยะ, อินเทอร์เน็ตของสรรพสิ่ง, ผู้ป่วยติดเตียง, การเฝ้าระวังแบบเรียลไทม์

Abstract

This study aimed to develop and evaluate an Intelligent Healthcare Bed System for monitoring bedridden patients using Internet of Things (IoT) technology. The system was designed to detect bed occupancy and patient movement in real time. The research methodology consisted of four main stages: (1) system architecture design integrating sensing, processing, and application layers; (2) installation of a Load Cell sensor with an HX711 amplifier to detect bed weight and a Passive Infrared (PIR) sensor to detect patient movement; (3) system implementation using NodeMCU ESP8266 for data processing and wireless transmission to the Blynk IoT platform; and (4) performance evaluation using a confusion matrix and statistical metrics including Accuracy, Precision, Recall, and F1-score. Experimental results from 20 test trials showed that bed occupancy detection achieved 100% Accuracy, 100% Precision, 100% Recall, and 100% F1-score. For movement detection, the system achieved 90% Accuracy, 80% Precision, 100% Recall, and an F1-score of 89%. Expert evaluation (n = 2) indicated an overall quality score of 4.39 (good level), while user satisfaction assessment (n = 10) yielded a mean score of 4.68 (S.D. = 0.11), representing a very good level. The system demonstrated stable real-time data transmission and effective alert notifications. Overall, the proposed smart bed system shows high performance and strong potential for practical implementation in long-term patient care settings to reduce fall risks, prevent pressure ulcers, and alleviate caregiver workload.

Keywords: Smart bed system, Internet of Things (IoT), Bedridden patients, Real-time monitoring

1. บทนำ

ผู้ป่วยติดเตียง โดยเฉพาะผู้สูงอายุและผู้ป่วยโรคเรื้อรัง เป็นกลุ่มประชากรที่ต้องการการดูแลด้านสุขภาพอย่างต่อเนื่องและรอบด้าน เนื่องจากมีข้อจำกัดด้านการเคลื่อนไหว และไม่สามารถช่วยเหลือตนเองได้ตามปกติ ภาวะการนอนอยู่ในท่าเดิมเป็นเวลานานส่งผลให้เกิดความเสี่ยงต่อปัญหาสุขภาพหลายประการ เช่น แผลกดทับ การติดเชื้อ การไหลเวียนโลหิตผิดปกติ รวมถึงความไม่สบายตัวและคุณภาพการนอนหลับที่ลดลง ซึ่งล้วนส่งผลกระทบต่อคุณภาพชีวิตของผู้ป่วยและเพิ่มภาระงานให้กับผู้ดูแลอย่างมีนัยสำคัญ [1-2] ในการดูแลผู้ป่วยติดเตียงโดยทั่วไป ผู้ดูแลมักอาศัยการตรวจสอบด้วยสายตาและการพลิกตัวผู้ป่วยตามรอบเวลาที่กำหนด ซึ่งวิธีการดังกล่าวมีข้อจำกัดด้านความถี่ ความแม่นยำ และความต่อเนื่อง โดยเฉพาะในบริบทของการดูแลผู้ป่วยที่บ้านหรือสถานดูแลระยะยาวที่มีจำนวนบุคลากรจำกัด [3]

ในช่วงทศวรรษที่ผ่านมา เทคโนโลยี Internet of Things (IoT) ได้เข้ามามีบทบาทสำคัญในการพัฒนาระบบดูแลสุขภาพอัจฉริยะ โดยเฉพาะระบบที่สามารถตรวจจับและติดตามสถานะของผู้ป่วยได้แบบเรียลไทม์ งานวิจัยหลายฉบับได้นำเสนอแนวทางการประยุกต์ใช้เซนเซอร์และอุปกรณ์อัจฉริยะร่วมกับระบบเครือข่าย เพื่อพัฒนาเตียงอัจฉริยะและระบบพยาบาลอัจฉริยะสำหรับผู้ป่วยติดเตียง [2,4] ระบบดังกล่าวสามารถตรวจจับการเคลื่อนไหว ทำการนอน และระยะเวลาที่ผู้ป่วยอยู่ในท่าเดิม ซึ่งเป็นข้อมูลสำคัญในการป้องกันแผลกดทับและลดความเสี่ยงจากภาวะแทรกซ้อนที่เกิดจากการไม่ขยับตัวเป็นเวลานาน นอกจากนี้ การผสานข้อมูลจากหลายเซนเซอร์ร่วมกับการวิเคราะห์เชิงพยากรณ์ยังช่วยให้ระบบสามารถแจ้งเตือนผู้ดูแลได้อย่างทันท่วงที ส่งผลให้การดูแลผู้ป่วยมีประสิทธิภาพมากขึ้นและลดภาระของผู้ดูแลได้อย่างเป็นรูปธรรม [5]

อย่างไรก็ตาม ระบบเตียงอัจฉริยะและระบบดูแลผู้ป่วยติดเตียงที่มีอยู่ในปัจจุบันยังคงมีข้อจำกัดหลายประการ เช่น ความซับซ้อนของโครงสร้างระบบ ต้นทุนในการพัฒนาและติดตั้งที่สูง รวมถึงการใช้อุปกรณ์สวมใส่หรืออุปกรณ์ที่อาจรบกวนความสะอาดสบายของผู้ป่วย ทำให้การนำไปใช้งานจริงในวงกว้างยังไม่แพร่หลายเท่าที่ควร [4,5] นอกจากนี้ ระบบ

บางส่วนยังขาดการประเมินประสิทธิภาพเชิงสถิติอย่างเป็นระบบ ทำให้ยากต่อการยืนยันความน่าเชื่อถือของผลลัพธ์ที่ได้จากการตรวจจับและแจ้งเตือน

ดังนั้น งานวิจัยนี้จึงมุ่งเน้นการพัฒนาและประเมิน ระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง (Intelligent Healthcare Bed System for Bedridden Patients) โดยประยุกต์ใช้เทคโนโลยี IoT เพื่อตรวจจับและแจ้งเตือนการเคลื่อนไหวของผู้ป่วยแบบเรียลไทม์ ระบบที่พัฒนาประกอบด้วย เซนเซอร์ตรวจจับการเคลื่อนไหว (Motion Sensor) และ เซนเซอร์แรงดันน้ำหนัก (Load Cell) ซึ่งเชื่อมต่อกับ NodeMCU ESP8266 และส่งข้อมูลผ่านแอปพลิเคชัน Blynk เพื่อให้ผู้ดูแลสามารถติดตามสถานะของผู้ป่วยได้อย่างต่อเนื่องและทันเวลา ประสิทธิภาพของระบบได้รับการประเมินโดยใช้ตัวชี้วัดทางสถิติ ได้แก่ Precision, Recall และ Accuracy เพื่อยืนยันความแม่นยำในการตรวจจับการอยู่บนเตียงและการเคลื่อนไหวของผู้ป่วย งานวิจัยนี้มีเป้าหมายเพื่อเสนอแนวทางการพัฒนาระบบเตียงอัจฉริยะที่มีต้นทุนต่ำ ใช้งานง่าย และสามารถนำไปประยุกต์ใช้จริงในบริบทของการดูแลผู้ป่วยติดเตียงทั้งในสถานพยาบาลและที่อยู่อาศัยได้อย่างมีประสิทธิภาพ

2. วิธีการวิจัย

การวิจัยเรื่อง ระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง (Intelligent Healthcare Bed System for Bedridden Patients) มีวัตถุประสงค์เพื่อพัฒนาและประเมินระบบตรวจจับการอยู่บนเตียงและการเคลื่อนไหวของผู้ป่วยแบบเรียลไทม์ โดยใช้เทคโนโลยี IoT ขั้นตอนการวิจัย ดังต่อไปนี้

2.1 กลุ่มตัวอย่าง

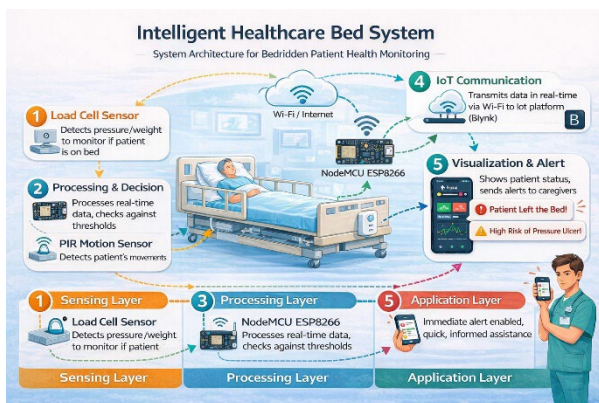
กลุ่มตัวอย่างที่ใช้ในการทดสอบระบบเป็นอาสาสมัครสุขภาพดี (Healthy Volunteers) จำนวน 10 คน แบ่งเป็นเพศชาย 5 คน และเพศหญิง 5 คน โดยดำเนินการทดสอบในสภาวะแวดล้อมควบคุม (Controlled Environment) เพื่อจำลองพฤติกรรมของผู้ป่วยติดเตียงตามสถานการณ์ที่กำหนด (Simulated Scenarios) ได้แก่ การขึ้น-ลงจากเตียง การขยับตัว และการนอนนิ่งเป็นระยะเวลานาน

ทั้งนี้ การเลือกใช้อุปกรณ์สุขภาพดีในขณะนี้ มีวัตถุประสงค์เพื่อสอบทานความถูกต้อง (Verification) ของการอ่านค่าจากเซนเซอร์และการประมวลผลของระบบในเบื้องต้น และเพื่อลดความเสี่ยงที่อาจเกิดขึ้นกับผู้ป่วยจริง โดยเน้นการประเมินความแม่นยำทางเทคนิค (Technical Accuracy) ก่อนนำไปสู่การทดสอบทางคลินิกในอนาคต

2.2 การออกแบบและพัฒนาระบบ

2.2.1 โครงสร้างระบบโดยรวม

ระบบเตียงอัจฉริยะประกอบด้วย 3 ส่วนหลัก ได้แก่ ส่วนตรวจจับข้อมูล (Sensing Layer) ส่วนประมวลผลและควบคุม (Processing Layer) และส่วนแสดงผลและแจ้งเตือน (Application Layer) โดยข้อมูลจากเซนเซอร์จะถูกส่งไปยังไมโครคอนโทรลเลอร์ NodeMCU ESP8266 เพื่อประมวลผลสถานะผู้ป่วย และส่งข้อมูลผ่านเครือข่ายอินเทอร์เน็ต ไปยังแอปพลิเคชัน Blynk สำหรับแสดงผลและแจ้งเตือนผู้ดูแลแบบเรียลไทม์ ดังภาพที่ 1




ภาพที่ 1: โครงสร้างระบบโดยรวม

2.2.2 ฮาร์ดแวร์ที่ใช้ในระบบ

Load Cell Sensor ใช้สำหรับตรวจจับแรงกดและน้ำหนักบนเตียง เพื่อนำไปใช้ระบุสถานะว่าผู้ป่วยอยู่บนเตียงหรือไม่ โดยเซนเซอร์จะทำหน้าที่แปลงแรงทางกล (mechanical stress) ที่เกิดจากน้ำหนักตัวของผู้ป่วยให้เป็นสัญญาณไฟฟ้า ซึ่งสัญญาณดังกล่าวจะถูกขยายและแปลงเป็นข้อมูลดิจิทัลผ่าน โมดูลขยายสัญญาณ HX711 ก่อนส่งไปยังไมโครคอนโทรลเลอร์เพื่อประมวลผล ผลการศึกษาก่อนหน้านี้

แสดงให้เห็นว่า การใช้ Load Cell ร่วมกับ โมดูล HX711 สามารถให้ค่าการวัดน้ำหนักที่มีความแม่นยำสูง และเหมาะสมสำหรับการประยุกต์ใช้งานด้านการดูแลสุขภาพและระบบตรวจวัดอัตโนมัติ โดยเฉพาะในงานที่ต้องการความต่อเนื่องและเสถียรของข้อมูล [6] ในงานวิจัยนี้ ได้ติดตั้ง Load Cell Sensor ไว้บริเวณใต้โครงเตียง เพื่อให้สามารถตรวจจับแรงกดจากน้ำหนักของผู้ป่วยได้โดยตรง พร้อมทั้งดำเนินการสอบเทียบค่าเซนเซอร์โดยใช้น้ำหนักมาตรฐาน (Standard Weights) ที่ทราบค่าแน่นอน (เช่น 10 kg, 20 kg และ 50 kg) วางบนตำแหน่งต่าง ๆ ของเตียงเพื่อหาค่าความคลาดเคลื่อนและปรับแก้ค่าสัมประสิทธิ์ (Calibration Factor) ในโปรแกรมควบคุม เพื่อให้ค่าน้ำหนักที่อ่านได้มีความถูกต้องแม่นยำและเป็นเชิงเส้น (Linearity) มากที่สุดก่อนเริ่มการทดลอง ดังแสดงในภาพที่ 2




ภาพที่ 2: การติดตั้ง Load Cell Sensor

PIR Motion Sensor ใช้สำหรับตรวจจับการเคลื่อนไหวของผู้ป่วย เช่น การขยับตัว การพลิกตัว หรือการลุกนั่งจากเตียง โดยทำงานบนหลักการของปรากฏการณ์ไพโรอิเล็กทริก (pyroelectricity) ซึ่งตรวจจับการเปลี่ยนแปลงของรังสีอินฟราเรดที่แผ่ออกจากร่างกายมนุษย์ งานวิจัยก่อนหน้านี้ได้ชี้ให้เห็นว่า ความไว (sensitivity) ของ PIR sensor เป็นปัจจัยสำคัญที่ส่งผลโดยตรงต่อประสิทธิภาพในการตรวจจับการเคลื่อนไหว โดยความไวของเซนเซอร์ขึ้นอยู่กับหลายปัจจัย ได้แก่ ระยะห่างระหว่างแหล่งกำเนิดความร้อนกับเซนเซอร์ อัตราการดูดกลืนรังสีอินฟราเรด และมุมรับภาพของเลนส์ Fresnel [7]

การปรับปรุงความไวของ PIR sensor จะช่วยเพิ่มความสามารถในการตรวจจับการเคลื่อนไหวขนาดเล็กหรือ

การเปลี่ยนแปลงท่าทางของผู้ป่วยได้อย่างแม่นยำมากขึ้น ซึ่งมีความสำคัญอย่างยิ่งต่อการเฝ้าระวังความเสี่ยงของการเกิดแผลกดทับและการลุกออกจากเตียง โดยไม่ได้รับการดูแล ในการวิจัยนี้ PIR Motion Sensor ถูกติดตั้งบริเวณขอบเตียงในตำแหน่งที่สามารถครอบคลุมพื้นที่การเคลื่อนไหวของผู้ป่วยได้อย่างเหมาะสม ดังแสดงในภาพที่ 3



ภาพที่ 3: การติดตั้ง PIR Motion Sensor

NodeMCU ESP8266 ทำหน้าที่เป็นหน่วยประมวลผลหลักของระบบ โดยรับข้อมูลจาก Load Cell Sensor และ PIR Motion Sensor จากนั้นทำการประมวลผลเพื่อตรวจจับสถานะและพฤติกรรมเคลื่อนไหวของผู้ป่วย และส่งข้อมูลไปยังแพลตฟอร์ม IoT ผ่านเครือข่ายไร้สาย เพื่อแสดงผลและแจ้งเตือนผู้ดูแลแบบเรียลไทม์

2.2.3 ซอฟต์แวร์และแพลตฟอร์ม

Arduino IDE ใช้สำหรับพัฒนาและอัปโหลดโปรแกรมควบคุมไปยัง NodeMCU ESP8266

Blynk Application ใช้เป็นแพลตฟอร์ม IoT สำหรับแสดงผลข้อมูลแบบเรียลไทม์และส่งการแจ้งเตือนไปยังผู้ดูแลผ่านสมาร์ตโฟน

2.3 กระบวนการทำงานของระบบ

การทำงานของระบบอาศัยการกำหนดค่า Threshold เพื่อตัดสินใจสถานะ ดังนี้

- การระบุสถานะผู้ป่วย (Occupancy Detection) โดยระบบกำหนดค่า Threshold ของน้ำหนัก ที่วัดจากน้ำหนักรวมของเตียงเปล่าและอุปกรณ์เครื่องนอน (Tare Weight) แล้วบวกค่าเพื่อความผิดพลาด (Offset) ที่ 5 กิโลกรัม เพื่อป้องกันการตรวจจับที่ผิดพลาดจากการวางสิ่งของเบา ๆ หากค่า

น้ำหนักที่อ่านได้ มีค่ามากกว่าน้ำหนักจริง ระบบจะระบุสถานะเป็นอยู่บนเตียง (Occupied)

- การตรวจจับการเคลื่อนไหว (Motion Detection) เมื่อสถานะเป็นอยู่บนเตียง ระบบจะรับค่าจาก PIR Motion Sensor หากเซนเซอร์ส่งสัญญาณ Logic High ต่อเนื่องหรือสลับไปมาภายในระยะเวลาที่กำหนด ระบบจะระบุว่ามีการเคลื่อนไหว
- ระบบจะแจ้งเตือนเมื่อ น้ำหนักลดลงต่ำกว่า Threshold (ลุกจากเตียง) หรือไม่พบสัญญาณการเคลื่อนไหวเกินระยะเวลา 2 ชั่วโมง (เสี่ยงแผลกดทับ)

2.4 การทดสอบระบบ

การทดสอบฟังก์ชันพื้นฐาน โดยทดสอบการขึ้น-ลงจากเตียง เพื่อประเมินความถูกต้องของการตรวจจับสถานะ “อยู่บนเตียง / ไม่อยู่บนเตียง” และทดสอบการขยับตัวและการนอนนิ่ง เพื่อประเมินการตอบสนองของเซนเซอร์ตรวจจับการเคลื่อนไหว

สำหรับการทดสอบระบบแจ้งเตือน ดำเนินการทดสอบการแจ้งเตือนเมื่อผู้ป่วยลุกออกจากเตียง และทดสอบการแจ้งเตือนเมื่อไม่พบการเคลื่อนไหวเกินระยะเวลาที่กำหนด

2.5 การประเมินประสิทธิภาพของระบบ

การประเมินประสิทธิภาพของระบบใช้ตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall และ F1-Score [8] ค่าทางสถิติดังกล่าวใช้เพื่อประเมินความแม่นยำ ความครบถ้วน และความสมดุลของระบบในการตรวจจับสถานะผู้ป่วยและการเคลื่อนไหว โดยกำหนดนิยามดังนี้

True Positive (TP): ระบบตรวจจับเหตุการณ์ได้ถูกต้อง

True Negative (TN): ระบบตรวจจับว่าไม่มีเหตุการณ์ได้ถูกต้อง

False Positive (FP): ระบบแจ้งเตือนผิดพลาด

False Negative (FN): ระบบไม่แจ้งเตือนเมื่อควรแจ้ง

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

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

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

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

2.5 การประเมินคุณภาพโดยผู้เชี่ยวชาญ

ระบบได้รับการประเมินคุณภาพจากผู้เชี่ยวชาญด้านระบบ IoT และด้านการพยาบาล จำนวน 2 คน โดยใช้แบบประเมินมาตราส่วนประมาณค่า 5 ระดับ (Rating Scale) ได้แก่ ดีมาก (5) มาก (4) ปานกลาง (3) น้อย (2) น้อยที่สุด (1) เพื่อประเมินด้านความถูกต้อง ความเหมาะสม และประสิทธิภาพของระบบในการใช้งานจริง

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการประเมินประสิทธิภาพเชิงเทคนิคของระบบ

การประเมินประสิทธิภาพของระบบเตียงอัจฉริยะ (Smart Bed Sense) ดำเนินการโดยใช้ Confusion Matrix เพื่อวิเคราะห์ความสามารถในการจำแนกสถานะ 2 กรณีหลัก ได้แก่ การตรวจจับสถานะการอยู่บนเตียง (Fall Prevention Function) และการตรวจจับการเคลื่อนไหวน้ำหนัก (Pressure Ulcer Prevention Function) ดังนี้

ตารางที่ 1 : ผลการทดสอบและค่าประสิทธิภาพการตรวจจับสถานะการอยู่บนเตียง (Fall Prevention Function)

ตัวชี้วัด	ค่า
จำนวนการทดสอบทั้งหมด	20
True Positive (TP)	10
True Negative (TN)	10
False Positive (FP)	0
False Negative (FN)	0
Accuracy	1.00 (100%)
Precision	1.00 (100%)
Recall	1.00 (100%)
F1-score	1.00 (100%)

จากตารางที่ 1 ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่าระบบสามารถจำแนกสถานะ “อยู่บนเตียง” และ “ไม่อยู่บนเตียง” ได้

อย่างสมบูรณ์ภายใต้เงื่อนไขการทดลอง ซึ่งแสดงถึงเสถียรภาพของ Load Cell Sensor และความแม่นยำของ threshold logic ที่ใช้ตัดสินสถานะน้ำหนัก ทั้งนี้ ฟังก์ชันการป้องกันการตกเตียงเป็นฟังก์ชันที่ต้องการความแม่นยำสูงมาก (high reliability system) ดังนั้น ค่า Recall = 1.00 จึงมีความสำคัญอย่างยิ่ง เพราะหมายความว่าระบบไม่เคยพลาดการตรวจจับกรณีผู้ป่วยลุกออกจากเตียงเลย

ตารางที่ 2 : ผลการทดสอบและค่าประสิทธิภาพการตรวจจับการเคลื่อนไหวน้ำหนัก (Pressure Ulcer Prevention Function)

ตัวชี้วัด	ค่า
จำนวนการทดสอบทั้งหมด	20
True Positive (TP)	8
True Negative (TN)	10
False Positive (FP)	2
False Negative (FN)	0
Accuracy	0.90 (90%)
Precision	0.80 (80%)
Recall	1.00 (100%)
F1-score	0.89 (89%)

จากตารางที่ 2 ค่า Recall = 1.00 แสดงว่าไม่เคยพลาดการตรวจจับการเคลื่อนไหวน้ำหนักจริง (ไม่มี False Negative) ซึ่งเป็นจุดแข็งสำคัญของระบบ เนื่องจากการพลาดตรวจจับการขยับตัวอาจนำไปสู่ความเสี่ยงของการเกิดแผลกดทับ

แม้ว่าจะมี False Positive จำนวน 2 ครั้ง (Precision = 0.80) แต่ในบริบทของการดูแลสุขภาพ False Positive มีผลกระทบต่ำกว่าการเกิด False Negative เพราะเป็นเพียงการรีเซ็ตตัวจับเวลาเตือนการพลิกตัวเท่านั้น ไม่ก่อให้เกิดอันตรายโดยตรงต่อผู้ป่วย ดังนั้นจึงสามารถกล่าวได้ว่าระบบถูกออกแบบให้เอนเอียงไปทางความปลอดภัย (Safety-oriented bias) ซึ่งเหมาะสมกับระบบเฝ้าระวังทางการแพทย์

3.2 ผลการพัฒนาและการทำงานแบบเรียลไทม์

ระบบมีโครงสร้างการทำงานแบบ IoT ที่เชื่อมต่อระหว่างเซนเซอร์ หน่วยประมวลผล และแพลตฟอร์มแสดงผลแบบ

เรียลไทม์ ดังแสดงในภาพที่ 1 ที่แสดงโครงสร้างระบบโดยรวม ซึ่งประกอบด้วย 3 ส่วนหลัก ได้แก่ (1) ส่วนรับข้อมูลจาก เซนเซอร์ (Sensing Layer) ประกอบด้วย Load Cell Sensor และ PIR Motion Sensor (2) ส่วนประมวลผลกลาง (Processing Layer) โดยใช้ NodeMCU ESP8266 และ (3) ส่วนแสดงผลและแจ้งเตือน (Application Layer) ผ่านแพลตฟอร์ม Blynk การทำงานเริ่มต้นจากการตรวจจับแรงกดบนเตียงและการเคลื่อนไหวของผู้ป่วย จากนั้นข้อมูลจะถูกส่งเข้าสู่ไมโครคอนโทรลเลอร์เพื่อประมวลผลและเปรียบเทียบกับค่าเกณฑ์ (threshold) ที่กำหนด หากพบเหตุการณ์ผิดปกติ เช่น ไม่พบแรงกดบนเตียง หรือไม่พบการเคลื่อนไหวเกินระยะเวลาที่ตั้งไว้ ระบบจะส่งสัญญาณแจ้งเตือนทันทีผ่านอินเทอร์เน็ต


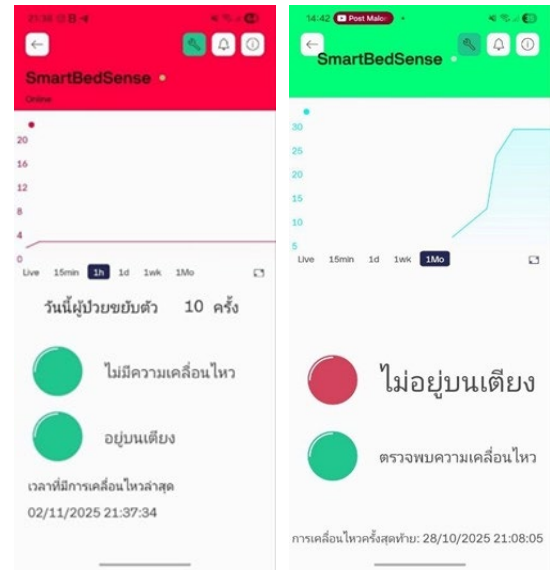


ภาพที่ 4: การเชื่อมต่อบอร์ด NodeMCU ESP8266
เข้าเซนเซอร์ Load Cell

ภาพที่ 2 และภาพที่ 4 แสดงการติดตั้ง Load Cell Sensor บริเวณใต้โครงเตียง โดยเซนเซอร์ทำหน้าที่ตรวจจับแรงกดจากน้ำหนักตัวผู้ป่วยและแปลงเป็นสัญญาณไฟฟ้า ก่อนส่งเข้าสู่ไมโครคอนโทรลเลอร์ HX711 และเข้าสู่ NodeMCU ESP8266 ผลการทดสอบพบว่า ระบบสามารถตรวจจับการมีหรือไม่มีน้ำหนักบนเตียงได้ทันทีเมื่อผู้ทดสอบขึ้นหรือลงจากเตียง โดยข้อมูลถูกอัปเดตบนแอปพลิเคชันภายในเวลาไม่เกิน 1-2 วินาที ซึ่งสะท้อนถึงความสามารถในการตอบสนองแบบเรียลไทม์ของระบบ

สำหรับการติดตั้ง PIR Motion Sensor จะติดตั้งบริเวณขอบเตียง (ภาพที่ 3) โดยเซนเซอร์จะตรวจจับการเปลี่ยนแปลงของรังสีอินฟราเรดจากการเคลื่อนไหวของผู้ป่วย เช่น การพลิกตัวหรือการลุกนั่ง เมื่อเกิดการเคลื่อนไหว ระบบจะบันทึกเหตุการณ์และรีเซ็ตตัวจับเวลาสำหรับการประเมินความเสี่ยง

แพลตฟอร์ม Blynk ที่ไม่พบการเคลื่อนไหวเกินเวลาที่กำหนด ระบบจะแจ้งเตือนผ่านแอปพลิเคชัน Blynk ทันที ดังภาพที่ 5



ภาพที่ 5: การเชื่อมต่อบอร์ด NodeMCU ESP8266 เข้า
เซนเซอร์ Load Cell

จากภาพที่ 5 การทดสอบเชิงปฏิบัติการ พบว่าการส่งข้อมูลจาก NodeMCU ESP8266 ไปยังแพลตฟอร์ม Blynk ผ่านเครือข่าย Wi-Fi มีความเสถียร และสามารถแสดงผลสถานะปัจจุบันของผู้ป่วยได้อย่างต่อเนื่อง โดยไม่มีความล่าช้าที่มีนัยสำคัญ ระบบสามารถแสดงข้อมูลในรูปแบบสถานะ (อยู่บนเตียง/ไม่อยู่บนเตียง) และแจ้งเตือนแบบ Push Notification ไปยังสมาร์ทโฟนของผู้ดูแลได้ทันทีเมื่อเกิดเหตุการณ์ผิดปกติ

ผลดังกล่าวสะท้อนให้เห็นว่า ระบบที่พัฒนาขึ้นสามารถทำงานแบบเรียลไทม์ได้จริงในสภาพแวดล้อมการทดลอง และมีศักยภาพในการประยุกต์ใช้งานในบริบทของการดูแลผู้ป่วยติดเตียง ทั้งในสถานพยาบาลและที่พักอาศัย โดยเฉพาะในด้านการลดภาระการเฝ้าระวังแบบ manual และเพิ่มความเร็วในการตอบสนองต่อเหตุการณ์ฉุกเฉิน

3.3 ผลการประเมินคุณภาพ โดยผู้เชี่ยวชาญและผลการประเมินจากกลุ่มผู้ใช้งาน

จากการประเมินคุณภาพระบบโดยผู้เชี่ยวชาญ จำนวน 2 ท่าน พบว่าระบบเตียงอัจฉริยะมีค่าเฉลี่ยรวมอยู่ในระดับดี ($\bar{X} = 4.39$) โดยผู้เชี่ยวชาญให้คะแนนสูงในด้านความรวดเร็วของการประมวลผล การแจ้งเตือนที่มีประสิทธิภาพ และความสะดวกของการเชื่อมต่อแบบไร้สาย ซึ่งสะท้อนถึงความพร้อมของระบบในเชิงวิศวกรรมและการใช้งานจริง อย่างไรก็ตาม ด้านความแม่นยำของเซนเซอร์ได้รับคะแนนต่ำกว่าด้านอื่นเล็กน้อย แสดงให้เห็นว่ายังมีโอกาสพัฒนาในเรื่องการปรับเทียบเซนเซอร์หรือการกรองสัญญาณรบกวนเพิ่มเติม ขณะเดียวกันผลการประเมินจากกลุ่มผู้ใช้งานจำนวน 10 คน พบว่าระบบได้รับความพึงพอใจในระดับดีมาก ($\bar{X} = 4.68$, S.D. = 0.11) โดยเฉพาะในประเด็นความพึงพอใจโดยรวม ความตั้งใจใช้งานต่อในอนาคต และการช่วยลดภาระงานของผู้ดูแล ซึ่งได้รับคะแนนเฉลี่ยสูงสุด ผลลัพธ์ดังกล่าวสะท้อนว่าระบบไม่เพียงมีประสิทธิภาพทางเทคนิคเท่านั้น แต่ยังสามารถได้รับการยอมรับในเชิงการใช้งาน (User Acceptance) และมีศักยภาพในการนำไปประยุกต์ใช้จริงในบริบทการดูแลสุขภาพผู้ป่วยติดเตียง ทั้งในสถานพยาบาลและการดูแลที่บ้าน โดยยังสามารถพัฒนาเพิ่มเติมเพื่อยกระดับความแม่นยำและความทนทานของระบบในระยะยาวได้อีก

3.4 อภิปรายผล

ผลการวิจัยแสดงให้เห็นว่าระบบเตียงอัจฉริยะสามารถตรวจจับสถานะการอยู่บนเตียงได้อย่างแม่นยำสูง (Accuracy 100%) และมีความไวในการตรวจจับการเคลื่อนไหวสูง (Recall 100%) ซึ่งสอดคล้องกับแนวคิดของระบบดูแลสุขภาพผู้ป่วยติดเตียงแบบ IoT ที่มุ่งเน้นการเฝ้าระวังแบบเรียลไทม์และลดความเสี่ยงต่อภาวะแทรกซ้อน [1, 4] การใช้ Load Cell ร่วมกับการตั้งค่า sampling และ threshold ที่เหมาะสมช่วยให้การจำแนกสถานะมีประสิทธิภาพ ซึ่งสอดคล้องกับข้อเสนอของ Hastawan และคณะ [6] ที่ระบุว่าการจัดการ time delay มีผลต่อความแม่นยำของข้อมูล อย่างไรก็ตาม แม้ระบบจะมี Precision 80% ในการตรวจจับการเคลื่อนไหว แต่ค่า Recall ที่สูงสะท้อนแนวทางการออกแบบเชิงความปลอดภัย (safety-

oriented design) ซึ่งเหมาะสมกับบริบทการแพทย์ และสามารถอธิบายได้จากธรรมชาติของความไวของ PIR sensor ตามที่ Verma และคณะ [7] อธิบายไว้ การพัฒนาระบบแบบไม่สวมใส่ยังสอดคล้องกับข้อเสนอของ Patel และคณะ [2] ที่ชี้ถึงข้อดีด้านความสะดวกและการยอมรับของผู้ใช้ นอกจากนี้ การสื่อสารข้อมูลผ่านแพลตฟอร์ม IoT ยังเป็นไปตามสถาปัตยกรรม sensor-cloud ที่ Alamri และคณะ [5] เสนอไว้ และสามารถต่อยอดสู่การวิเคราะห์เชิงพยากรณ์ในอนาคตตามแนวทางของ Baek [1] ได้ ทั้งนี้ เพื่อเพิ่มความเชื่อมั่นในการใช้งานจริง ควรพัฒนาระบบให้รองรับการอธิบายเหตุผลของการแจ้งเตือนอย่างโปร่งใส ตามแนวคิด explainable healthcare system ของ Khodabandehloo และคณะ [3] โดยภาพรวมระบบมีศักยภาพสูงในการประยุกต์ใช้จริง แต่ยังคงควรทดสอบในสภาพแวดล้อมทางคลินิกที่หลากหลายมากขึ้นในอนาคต

4. สรุปผลและข้อจำกัดของการวิจัย

4.1 สรุปผล

การวิจัยเรื่องระบบเตียงอัจฉริยะในการดูแลสุขภาพผู้ป่วยติดเตียง มีวัตถุประสงค์เพื่อพัฒนาและประเมินระบบตรวจจับสถานะการอยู่บนเตียงและการเคลื่อนไหวของผู้ป่วยแบบเรียลไทม์ โดยประยุกต์ใช้เทคโนโลยี Internet of Things (IoT) ร่วมกับ Load Cell Sensor, PIR Motion Sensor และ NodeMCU ESP8266 ผลการทดลองแสดงให้เห็นว่าระบบสามารถตรวจจับสถานะการอยู่บนเตียงได้อย่างแม่นยำสูง (Accuracy 100%) และมีความสามารถในการตรวจจับการเคลื่อนไหวได้ครบถ้วน (Recall 100%) แม้ว่าจะพบ False Positive บางส่วนในการตรวจจับการเคลื่อนไหว ส่งผลให้ Precision เท่ากับ 80% แต่ไม่ส่งผลกระทบต่อความปลอดภัยของผู้ป่วยโดยตรง

ระบบสามารถส่งข้อมูลและแจ้งเตือนผ่านแพลตฟอร์ม Blynk ได้แบบเรียลไทม์ โดยไม่มีความล่าช้าที่มึนขี้สำคัญ แสดงถึงความเสถียรของการสื่อสารผ่านเครือข่ายไร้สาย ผลการประเมินโดยผู้เชี่ยวชาญอยู่ในระดับดี และผลการประเมินจากผู้ใช้งานอยู่ในระดับดีมาก สะท้อนถึงทั้งประสิทธิภาพเชิงเทคนิคและการยอมรับในการใช้งานจริง

โดยสรุป ระบบเชิงอัจฉริยะที่พัฒนาขึ้นมีศักยภาพในการนำไปประยุกต์ใช้เพื่อช่วยลดความเสี่ยงจากการตกเตียงและแผลกดทับ รวมถึงลดภาระการเฝ้าระวังของผู้ดูแล อย่างไรก็ตาม ควรมีการทดสอบเพิ่มเติมในสภาพแวดล้อมทางคลินิกจริง และปรับปรุงความแม่นยำของเซนเซอร์เพื่อเพิ่มความน่าเชื่อถือในระยะยาว

4.2 ข้อจำกัดของการวิจัย

การทดสอบประสิทธิภาพของระบบดำเนินการเพียง 20 ครั้ง ซึ่งถือเป็นจำนวนที่ค่อนข้างน้อยในทางสถิติ ส่งผลให้ช่วงความเชื่อมั่น (Confidence Interval) ของค่าความถูกต้องและความแม่นยำอาจมีความกว้าง และอาจยังไม่เพียงพอที่จะยืนยันความเสถียรของระบบในทุกสถานการณ์ นอกจากนี้ การทดสอบดำเนินการในสภาวะควบคุม (Controlled Environment) โดยใช้อาสาสมัครสุขภาพดีจำลองสถานการณ์ ซึ่งอาจมีรูปแบบการเคลื่อนไหวและน้ำหนักตัวที่แตกต่างจากผู้ป่วยติดเตียงจริงที่มีภาวะกล้ามเนื้ออ่อนแรงหรือข้อติด ทำให้ผลลัพธ์อาจยังไม่สะท้อนพฤติกรรมที่ซับซ้อนในการใช้งานจริงได้อย่างครอบคลุม ดังนั้นในการวิจัยครั้งต่อไปควรเพิ่มจำนวนครั้งในการทดสอบและขยายขนาดกลุ่มตัวอย่างให้มากขึ้น และควรมีการนำระบบไปทดสอบในสภาพแวดล้อมทางคลินิกจริง พร้อมปรับปรุงอัลกอริทึมในการสอบเทียบ (Calibration) และการกำหนดค่า Threshold ให้สามารถปรับเปลี่ยนได้อัตโนมัติตามน้ำหนักของผู้ใช้งาน เพื่อลดอัตราการเกิด False Positive ในระยะยาว

5. เอกสารอ้างอิง

- [1] Baek J. Smart predictive analytics care monitoring model based on multi sensor IoT system: Management of diaper and attitude for the bedridden elderly. *Sensors International*. 2023;4:100213.
- [2] Patel S, Park H, Bonato P, Chan L, Rodgers M. A review of wearable sensors and systems with application in rehabilitation. *Journal of NeuroEngineering and Rehabilitation*. 2012;9:21.
- [3] Khodabandehloo E, Riboni D, Alimohammadi A. HealthXAI: Collaborative and explainable AI for supporting early diagnosis. *IEEE Access*. 2021;9:107527–107544.
- [4] Wudhiphan W, Suthisoontrin T, Vanijkachorn P, Visutsak P. An IoT-based multi-sensory intelligent device for bedridden elderly monitoring. *ECTI Transactions on Computer and Information Technology*. 2024;18(2):136–146.
- [5] Alamri A, Ansari WS, Hassan MM, Hossain MS, Alelaiwi A. A survey on sensor-cloud: Architecture, applications, and approaches. *International Journal of Distributed Sensor Networks*. 2013;9(2):917923.
- [6] Hastawan AF, Haryono S, Utomo AB, Hangga A, Setiyawan A, Septiana R, Hafidz CM, Triantino SB. Comparison of testing load cell sensor data sampling method based on the variation of time delay. *IOP Conference Series: Earth and Environmental Science*. 2021;700:012018.
- [7] Verma M, Kaler RS, Singh M. Sensitivity enhancement of passive infrared (PIR) sensor for motion detection. *Optik - International Journal for Light and Electron Optics*. 2021;244:167503.
- [8] Malta A, Mendes M and Farinha T. Augmented reality maintenance assistant using YOLOv5. *Applied Sciences*. 2021; 11(11):475.

การจัดกลุ่มพฤติกรรมผู้ใช้บริการร้านเติมเกมออนไลน์ด้วยโมเดล RFM และอัลกอริทึมเคมีนส์เพื่อการส่งเสริมการตลาด

Customer Segmentation for Online Game Top-up Services using RFM Model and K-Means Clustering for Marketing Promotion

ณัฐภัทร คำปล่อง¹ สุธาวรรณ แสงทองมา¹ กุลจิรา จันทนา² มณีนรัตน์ การนันท์³ และ รุจิรา จุลภักดิ์^{3*}

¹สาขาวิชาระบบสารสนเทศ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

²สาขาวิชาการบัญชี คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

³สาขาวิชาระบบสารสนเทศ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

(* Rujira_ju@rmutto.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์และจัดกลุ่มพฤติกรรมลูกค้า (Customer Segmentation) ของร้านเติมเกมออนไลน์ โดยประยุกต์ใช้เทคนิคการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ด้วยอัลกอริทึม K-Means Clustering ร่วมกับการวิเคราะห์โมเดล RFM (Recency, Frequency, Monetary) เพื่อจำแนกกลุ่มลูกค้าตามลักษณะการใช้จ่ายและพฤติกรรมการเข้าใช้งาน จากผลทดลองพบว่าการวัดผลด้วย Elbow Method แสดงจุดหักศอก (Elbow Point) ที่ชัดเจน ณ จำนวนกลุ่ม $k=3$ เป็นจุดที่ลดความแปรปรวนภายในกลุ่ม (Inertia) ได้อย่างมีประสิทธิภาพ และในขณะเดียวกันผู้วิจัยได้การวัดผลด้วย Silhouette Coefficient ซึ่งจำนวนกลุ่มที่มีจุดกระโดดของคะแนนอย่างมีนัยสำคัญที่ $k=5$ จากการวิเคราะห์เปรียบเทียบในเชิงธุรกิจและการนำไปปฏิบัติจริง ผู้วิจัยจึงเลือกจัดกลุ่มลูกค้าที่ $k=3$ เพื่อให้เหมาะสมตามแคมเปญการตลาด ซึ่งจะที่ได้ช่วยให้ธุรกิจร้านเติมเกมสามารถจำแนกกลุ่มลูกค้าเป็นกลุ่มเป้าหมายที่ชัดเจน เพื่อเพิ่มประสิทธิภาพในการรักษาลูกค้าและกระตุ้นยอดขายได้อย่างมีประสิทธิภาพ

คำสำคัญ: K-Means Clustering, การจัดกลุ่มลูกค้า, RFM Analysis, Elbow Method, Silhouette Coefficient

Abstract

This research aims to analyze and perform customer segmentation for an online game top-up store by applying Unsupervised Learning techniques. The K-Means Clustering algorithm was integrated with the RFM Model (Recency, Frequency, Monetary) to categorize customers based on their spending behavior and engagement patterns. Experimental results from the Elbow Method revealed a distinct Elbow Point at $k=3$, demonstrating an effective reduction in within-cluster variance (Inertia). Simultaneously, the Silhouette Coefficient analysis identified a significant score improvement at $k=5$. After a comparative analysis of business practicality and operational feasibility, the researcher determined that $k=3$ is the optimal number of clusters for marketing campaigns. This segmentation enables the business to clearly identify target groups, enhancing the efficiency of customer retention strategies and effectively driving sales growth.

Keywords: K-Means Clustering, Customer Segmentation, RFM Analysis, Elbow Method, Silhouette Coefficient

1. บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ปัจจุบันเกมออนไลน์ได้รับความนิยมเป็นอย่างมาก ไม่ว่าจะเป็นคนไทยหรือต่างชาติและมีแนวโน้มจะได้รับความนิยมที่สูงขึ้นอย่างต่อเนื่อง ซึ่งประเภทของเกมสโตร์ที่ได้รับความนิยม เช่น เกมสโตร์แนววางแผนกลยุทธ์การรบแบบเรียลไทม์ที่เน้นการทำงานเป็นทีม (Multiplayer Online Battle Arena), แนวเอาตัวรอด (Battle Royale), และการวางแผนรบ (Strategy Games) เป็นต้น การเล่นเกมสโตร์ถือได้ว่าเป็นการเชื่อมโยงผู้เล่นเข้าด้วยกันและทำให้เกิดสังคมออนไลน์ที่สามารถให้ทั้งความบันเทิงและฝึกทักษะ[1] จากความนิยมข้างต้นจึงมีร้านที่ให้บริการในการเล่นเกมสโตร์ในเว็บไซท์ โดยสามารถเล่นได้ 24 ชั่วโมง[2] เพิ่มความรวดเร็วและสะดวกมากยิ่งขึ้น จากความสำคัญและความน่าสนใจของร้านเกมออนไลน์ในปัจจุบัน จึงทำให้มีผู้วิจัยเกี่ยวกับเรื่องนี้อยู่หลากหลาย อาทิ

[3] ปิยนันต์ คล้ายจันทร์ ได้ทำการวิจัยเชิงสำรวจเกี่ยวกับพฤติกรรมการเล่นเกมออนไลน์ของนักศึกษา โดยเกมที่เล่นคือ VALORANT ซึ่งเป็นกลุ่มของนักศึกษาจังหวัดปทุมธานีที่กำลังศึกษาระดับนักศึกษาระดับปริญญาตรีมีอายุตั้งแต่ 18 ปีขึ้นไป จำนวน 400 คน จากผลการสำรวจพบว่า กลุ่มตัวอย่างส่วนใหญ่ที่นิยมเล่นเป็นเพศชาย สังกัดคณะสายสังคมศาสตร์ โดยมีทัศนคติโดยรวมต่อเกมออนไลน์อยู่ในระดับดีมาก ทัศนคติต่อช่องทางการจัดจำหน่ายเกมออนไลน์ในระดับมากที่สุด ทัศนคติต่อการโฆษณาและโปรโมชั่นของตัวเกมออนไลน์ในระดับมากและด้านค่าใช้จ่ายในการเล่นเกมออนไลน์ในระดับมาก

[4] อูชา บั๊กกินส์ ได้ทำการวิจัยเกี่ยวกับพฤติกรรมความคิดสื่อออนไลน์ของเยาวชนในเขตกรุงเทพมหานครกับการสร้างชุมชนเสมือนจริงในเกมออนไลน์ โดยมีวัตถุประสงค์เพื่อศึกษาพฤติกรรมสื่อสารเพื่อสร้างชุมชนเสมือนจริงในเกมออนไลน์และผลกระทบกับการดำเนินชีวิตประจำวัน ปัจจัยที่ทำให้เกิดการติดเกมออนไลน์และศึกษาลักษณะชุมชนเสมือนจริงในโลกของเกมออนไลน์ จากผลการวิจัยพบว่าการเล่นเกมเป็นการรวมตัวของผู้เล่นเพื่อไปตีศัตรู ประหลาดและมีการสื่อสารจะเป็นการสนทนาทั่วไป ซึ่งผลกระทบที่ได้รับจากการเล่นเกมนี้มีผลคือ ช่วยให้พิมพ์เร็วขึ้น เรียนรู้ภาษาอังกฤษ ผลเสียคือทำให้เสียเวลาไปกับการเล่นเกมมากเกินไป อาจส่งผลให้มีเวลาในการทบทวนบทเรียนน้อยลงรวมถึงอาจส่งผลเสียต่อสุขภาพ

[5] ชัยรัช วงศ์ชมบุญ ได้ศึกษาเกี่ยวกับพฤติกรรมกรเปิดรับและความพึงพอใจต่อการสื่อสารของเกมออนไลน์ประเภท Multiplayer Online Battle Arena โดยมีวัตถุประสงค์เพื่อศึกษาลักษณะทางประชากรศาสตร์ของผู้เล่นเกมออนไลน์ประเภท MOBA ที่มีผลต่อความพึงพอใจการสื่อสารของเกม MOBA จากผลการศึกษาพบว่ากลุ่มตัวอย่างมีความพึงพอใจต่อการสื่อสารของเกมออนไลน์ประเภท MOBA โดยรวมในระดับมากโดยมีความพึงพอใจต่อการสื่อสารถึง

การเป็นเกม Battle หรือเกมที่มีเนื้อหาในการต่อสู้กับฝั่งตรงข้ามมากที่สุด

จากการทบทวนวรรณกรรมที่เกี่ยวข้องพบว่าส่วนใหญ่จะศึกษาเกี่ยวกับพฤติกรรมและผลกระทบที่มีต่อผู้เล่นเกมสโตร์ ดังนั้นผู้วิจัยจึงสนใจศึกษาเกี่ยวกับข้อมูลพฤติกรรมการเล่นเกมออนไลน์เพื่อแบ่งกลุ่มและส่งเสริมยอดการเติมเกมให้เพิ่มมากยิ่งขึ้น

1.2 วัตถุประสงค์ของการศึกษา

1.2.1 เพื่อศึกษาพฤติกรรมของลูกค้ำที่มาใช้บริการร้านเติมเกมออนไลน์

1.2.2 เพื่อจัดกลุ่มของลูกค้ำตามพฤติกรรมการใช้งาน

1.3 ขอบเขตการศึกษา

งานวิจัยนี้มุ่งเน้นไปที่การศึกษาพฤติกรรมของลูกค้ำที่มาใช้บริการเติมเกมเพื่อนำลูกค้ำที่มีพฤติกรรมคล้ายกันมาจัดให้อยู่ในกลุ่มเดียวกัน มีขอบเขตดังต่อไปนี้

1.3.1 ด้านชุดข้อมูลที่ใช้

ชุดข้อมูลที่น่าสนใจวิเคราะห์นั้นได้รวบรวมจากร้านเติมเกมแห่งหนึ่งในเขตกรุงเทพมหานคร ตั้งแต่วันที่ 1 เดือนมกราคม พ.ศ. 2568 ถึงวันที่ 30 เดือนเมษายน พ.ศ. 2568 ซึ่งมีจำนวนทั้งสิ้น 250 ข้อมูล

1.3.2 ด้านกระบวนการ

ผู้วิจัยได้นำชุดข้อมูลมาแบ่งกลุ่มตามพฤติกรรมของการมาใช้บริการของลูกค้ำ โดยใช้เทคนิคอัลกอริทึมเคมีนส์

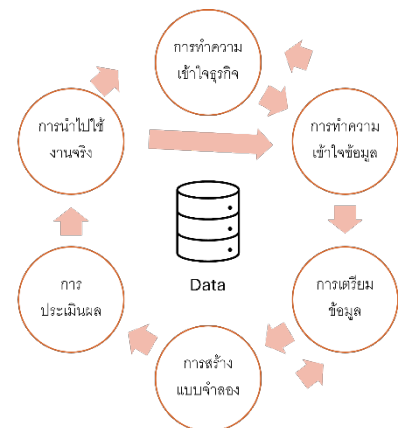
1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 เพิ่มประสิทธิภาพให้กับร้าน

1.4.2 สามารถสื่อสารได้ตรงตามกลุ่มของลูกค้ำ

2. วิธีการวิจัย

การวิจัยนี้ใช้กรอบการทำงานตามมาตรฐานของ Cross-Industry Standard Process for Data Mining: CRISP-DM [6] เพื่อวิเคราะห์ข้อมูลอย่างเป็นระบบ ซึ่ง CRISP ประกอบด้วย 6 ขั้นตอน ดังนี้ 1) การทำความเข้าใจธุรกิจ 2) การทำความเข้าใจข้อมูล 3) การเตรียมข้อมูล 4) การสร้างแบบจำลอง 5) การประเมินผล 6) การนำไปใช้งานจริง ซึ่งได้แสดงดังภาพที่ 1



ภาพที่ 1 ขั้นตอนการทำงานของ CRISP-DM

2.1 การทำความเข้าใจธุรกิจ

จากการศึกษาข้อมูลของธุรกิจเกมซึ่งธุรกิจนี้เป็นตัวกลางระหว่างลูกค้ากับค่ายเกมซึ่งรายได้ของธุรกิจนี้มาจากส่วนต่างราคา ดังนั้นวิธีจัดหาต้นทุนให้ต่ำที่สุด แล้วนำมาจำหน่ายต่อในรูปแบบการให้บริการที่เน้นความคุ้มค่าและอำนวยความสะดวกให้กับลูกค้า รวมถึงสามารถเติมเงินได้ตลอด 24 ชั่วโมง ทำให้มีความได้เปรียบคู่แข่งขั้นทางธุรกิจ การเติมเงินแต่ละครั้งอาจสร้างกำไรให้กับธุรกิจได้ไม่มากนัก แต่ธุรกิจนี้อาศัยการเติมเงินถี่และมีปริมาณมาก ดังนั้นจึงจำเป็นต้องทำความเข้าใจเกี่ยวกับพฤติกรรมของลูกค้า จากนั้นวิเคราะห์พฤติกรรมของลูกค้าที่มีลักษณะใกล้เคียงกัน มารวมไว้ในกลุ่มเดียวกัน เพื่อส่งเสริมการเติมเกมให้กับลูกค้าแต่ละกลุ่มได้อย่างเหมาะสม

2.2 การทำความเข้าใจข้อมูล

ชุดข้อมูลนี้ได้รวบรวมจากประวัติการเติมเกมจากร้านแห่งหนึ่ง ตั้งแต่วันที่ 1 เดือนมกราคม พ.ศ. 2568 ถึงวันที่ 30 เดือนเมษายน พ.ศ. 2568 ซึ่งประกอบด้วยข้อมูลดังต่อไปนี้

ตารางที่ 1: ข้อมูล Users

Attribute	Description	Data type
user_id (PK)	รหัส users	VARCHAR (10)
username	ชื่อ users	VARCHAR (100)
email / phone	อีเมลล์/ โทรศัพท์	VARCHAR (100)
tier	ระดับของ users	VARCHAR (20)

ตารางที่ 2: ข้อมูล Games

Attribute	Description	Data type
game_id (PK)	รหัสเกมส์	VARCHAR (10)
game_name	ชื่อเกมส์	VARCHAR (100)
category	ประเภทเกมส์	VARCHAR (50)

ตารางที่ 3: ข้อมูล Packages

Attribute	Description	Data type
package_id (PK)	รหัสแพ็คเกจ	VARCHAR (10)
game_id(FK)	รหัสเกมส์	VARCHAR (10)
package_name	ชื่อเกมส์	VARCHAR (100)
cost_price	ราคาคืนทุนขาย	DECIMAL (10)
sale_price	ราคาขาย	DECIMAL (10)

ตารางที่ 4: ข้อมูล Orders

Attribute	Description	Data type
order_id (PK)	รหัสออเดอร์	VARCHAR (10)
user_id (FK)	รหัส users	VARCHAR (10)
game_id (FK)	รหัสเกมส์	VARCHAR (10)
package_id (FK)	รหัสแพ็คเกจ	VARCHAR (10)
player_id	UID ของลูกค้า	VARCHAR (50)
server	ชื่อ server	VARCHAR (20)
total_price	ราคารวม	DECIMAL (10)
order_status	สถานะออเดอร์	VARCHAR (20)
order_date	วันที่ออเดอร์	DATETIME

ตารางที่ 5: ข้อมูล Payments

Attribute	Description	Data type
payment_id (PK)	รหัสชำระเงิน	VARCHAR (10)
order_id(FK)	รหัสออเดอร์	VARCHAR (10)
method	ช่องทางการชำระเงิน	VARCHAR (50)
payment_status	สถานะการชำระเงิน	VARCHAR (20)
payment_date	วันที่ชำระเงิน	DATETIME

2.3 การเตรียมข้อมูล

จากข้อมูลธุรกรรมรายวันที่ได้รวบรวมไว้ ผู้วิจัยจะเลือกข้อมูลที่มีสถานะ (order_status) success เท่านั้น และหลังจากเลือกข้อมูลเรียบร้อยแล้ว จะพบว่าข้อมูลบางส่วนขาดหายไป ซึ่งได้แสดงในตารางที่ 6 จึงจำเป็นต้องทำความสะอาดข้อมูล เพื่อให้สามารถนำไปจัดกลุ่มได้อย่างมีประสิทธิภาพ

ตารางที่ 6: ตัวอย่างข้อมูลการเติมเกมของลูกค้า

order_id	user_id	game_id	package_id	...	order_status
O001	U027	G002		...	success
O002	U022	G005	P005	...	success
O003	U003	G004	P005	...	success
O004	U039	G001	P001	...	success
O005	U024	G003	P004	...	success
...
...
O028	U022	G001	P005	...	success
O029	U084	G001		...	success
O030	U053	G005	P001	...	success
O031	U058	G003		...	success
O032	U017	G001		...	success
...
...

การทำความสะอาดข้อมูลมีขั้นตอนดังนี้

ขั้นตอนที่ 1 จัดการค่าว่างของข้อมูล

ผู้วิจัยได้ทำการแทนที่ค่าสูญหาย (Missing value) ของข้อมูลในคอลัมน์ package_id ด้วยวิธีการแทนที่ด้วยค่าฐานนิยม (Mode) ที่สูงที่สุดของลูกค้าแต่ละคน

ขั้นตอนที่ 2 กำหนดค่าที่จำเป็นต่อการวิเคราะห์ข้อมูล โดยผู้วิจัยได้หาค่าสรุปการทำธุรกรรมของลูกค้ารายบุคคล เพื่อให้สามารถแบ่งกลุ่มได้ง่ายมากยิ่งขึ้น โดยได้ใช้วิธี RFM [7] เพื่อหาค่าดังนี้ ค่า Recency (R) จำนวนเพื่อให้ทราบว่าลูกค้าเติมเงินล่าสุดเมื่อไหร่ โดยค่าที่ได้ยิ่งน้อยยิ่งดี Frequency (F) จำนวนเพื่อให้ทราบว่าลูกค้าเติมเงินบ่อยแค่ไหน โดยค่าที่ได้ยิ่งมากยิ่งดี และ Monetary (M) จำนวนเพื่อให้ทราบว่าลูกค้าได้เติมเงินรวมทั้งสิ้นเท่าไร โดยค่าที่ได้ยิ่งมากยิ่งดี ซึ่งตัวอย่างผลลัพธ์ที่แสดงดังตารางที่ 7

ตารางที่ 7: ตัวอย่างผลลัพธ์จากการคำนวณค่า RFM

user id	Recency	Frequency	Monetary
U002	0	1	300
U003	3	2	1800
U004	15	1	450
...
...
U025	3	1	35
U027	11	2	1350
U028	2	2	600
U030	3	2	450
U032	8	1	150
U034	14	1	79
U039	2	1	900
U040	14	1	1200
U042	10	1	79
U043	5	1	79

จากข้อมูลที่ได้พบว่าข้อมูลของทั้ง 3 คอลัมน์มีค่าในช่วงข้อมูลที่แตกต่างกัน เช่น คอลัมน์ Recency และคอลัมน์ Frequency มีข้อมูลอยู่ในช่วงหลักหน่วยถึงหลักสิบ แต่ในขณะที่เดียวกันข้อมูลยอดเงินที่ลูกค้าเคยเติมนั้นมีตั้งแต่ช่วงหลักสิบถึงหลักพัน ดังนั้นหากไม่ทำการปรับมาตรฐานข้อมูลก่อนนำไปใช้จะทำให้ข้อมูลความถี่ที่ลูกค้าเติมและ

ข้อมูลที่ลูกค้าเติมล่าสุดจะไม่มีผลต่อการจัดกลุ่มเลย ดังนั้นจำเป็นต้องนำข้อมูลที่นำมาทำการปรับให้อยู่ในมาตรฐานเดียวกัน

ขั้นตอนที่ 3 ปรับมาตรฐานข้อมูล

ผู้วิจัยได้ใช้วิธีการ Standard Scaler (Z-score Normalization) ในการปรับข้อมูลให้อยู่ในมาตรฐานเดียวกัน ด้วยสมการที่ 1

$$z = \frac{(x-\mu)}{\sigma} \quad (1)$$

โดยที่

x คือค่าข้อมูลเดิม

μ คือค่าเฉลี่ยของข้อมูลในแต่ละคอลัมน์

σ คือส่วนเบี่ยงเบนมาตรฐาน

หลังจากนำทำความสะอาดข้อมูลเรียบร้อยแล้วสามารถนำไปสร้างแบบจำลองได้อย่างมีประสิทธิภาพ

2.4 การสร้างแบบจำลอง

K-Means เป็นอัลกอริทึมการเรียนรู้แบบไม่มีผู้สอนที่เน้นความเร็วและประสิทธิภาพในการจัดการข้อมูลขนาดใหญ่ โดยมีหลักการทำงานที่ไม่ซับซ้อน ซึ่งขั้นตอนการทำงานของ K-Means มีดังนี้ [8]

ขั้นตอนที่ 1 กำหนดจำนวนกลุ่ม (K) ที่ต้องการ

ขั้นตอนที่ 2 สุ่มเลือกจุดข้อมูล K จุด เพื่อเป็นจุดศูนย์กลาง (Centroids)

ขั้นตอนที่ 3 คำนวณระยะห่างระหว่างข้อมูลนั้นกับจุด Centroids ทั้งหมด เพื่อเลือก Centroids ที่ใกล้ที่สุด โดยการใช้อยู่คลิด ดังสมการที่ 2

$$distance = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2)$$

โดยที่

x_i คือมิติของลูกค้าคนที่ 1

y_i คือมิติของลูกค้าคนที่ 2

ขั้นตอนที่ 4 กำหนดกลุ่มกับข้อมูล โดยพิจารณาว่าอยู่ใกล้จุด Centroids ไหมมากที่สุด ซึ่งพิจารณาได้จากสมการที่ 3

$$\arg \min_{j \in k} (Distance) \quad (3)$$

ขั้นตอนที่ 5 คำนวณค่าเฉลี่ย (Mean) ของข้อมูลแต่ละกลุ่มเพื่อกำหนดเป็น Centroids ใหม่ จากสมการที่ 4

$$Centroids_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_j \quad (4)$$

โดยที่

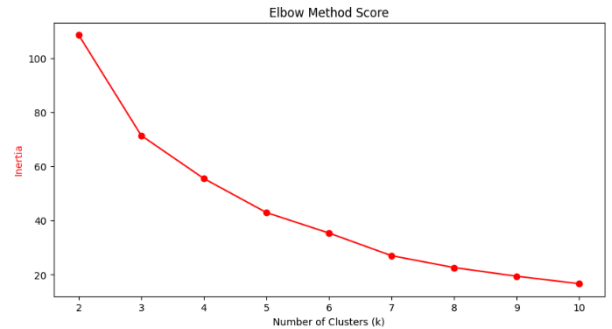
N_j คือจำนวนข้อมูลทั้งหมดของกลุ่ม j

ขั้นตอนที่ 6 ทำซ้ำขั้นตอนที่ 3 และ 5 จนกว่าค่า Centroids จะไม่เปลี่ยนแปลงถึงสิ้นสุดการทำงาน

3 ผลการวิจัยและอภิปรายผล

ผู้วิจัยได้ทำการทดลองเพื่อหาจำนวนกลุ่มที่เหมาะสม โดยกำหนดจำนวนกลุ่ม (K) ตั้งแต่ 2 กลุ่ม ไปจนถึงจำนวน 10 กลุ่มเพื่อทำการหาจำนวนกลุ่มที่เหมาะสม โดยได้ใช้วิธี Elbow Method [9] และ Silhouette Coefficient [10] ในการประเมินผลของอัลกอริทึม โดยสามารถสรุปผลได้ดังนี้

จากการประเมินผลด้วยวิธี Elbow Method เพื่อคำนวณหาจำนวนกลุ่มที่เหมาะสม โดยพิจารณาจากจำนวนข้อมูลของแต่ละกลุ่ม พบว่าหากกำหนดให้ $k=2$ ค่า Inertia หรือจำนวนลูกค้ายของแต่ละกลุ่มจะมีจำนวนสูงมากซึ่งอยู่ที่ประมาณ 108 จำนวนแสดงว่าการกระจายตัวของข้อมูลห่างจากจุดศูนย์กลางของกลุ่ม (Centroid) มากเกินไป ดังนั้นการแบ่งลูกค้ายออกเป็นแค่ 2 กลุ่มอาจไม่สามารถอธิบายพฤติกรรมลูกค้ายได้ดีพอ และจากภาพที่ 2 $k=2$ ไปจนถึง $k=3$ จะเห็นได้ว่ากราฟมีลักษณะดิ่งลงอย่างรวดเร็ว ซึ่งสะท้อนให้เห็นว่าการเพิ่มกลุ่มจาก 2 กลุ่ม เป็น 3 กลุ่มช่วยลดความแปรปรวนในกลุ่มได้ กราฟหลังจากกำหนดค่าให้กับ k ตั้งแต่ 4 เป็นต้นไปพบว่าเริ่มลาดเอียงเป็นเส้นตรงมากขึ้นเรื่อย ๆ หมายความว่า การเพิ่มจำนวนกลุ่มมากกว่า 3 ไม่ได้ช่วยให้ข้อมูลเกาะกลุ่มกัน ดังนั้นจากภาพที่ 2 สามารถสรุปได้ว่าจุดที่เหมาะสมที่สุดคือ $k=3$ เนื่องจากที่ตำแหน่ง $k=3$ มีลูกค้ายที่อยู่ภายในกลุ่มประมาณ 71 รายและเป็นจุดที่กราฟมีการเปลี่ยนทิศทางจากความชันสูงมาเป็นความชันที่น้อยลง



ภาพที่ 2: แสดงการวัดประสิทธิภาพด้วยวิธี Elbow Method

จากนั้นผู้วิจัยได้ทำการประเมินผลคุณภาพของการจัดกลุ่มว่ามีประสิทธิภาพเพียงใด ด้วยวิธี Silhouette Coefficient โดยพิจารณาจาก 2 ปัจจัยหลักคือ ความใกล้เคียงของข้อมูลที่อยู่ภายในกลุ่มเดียวกัน และความไม่ใกล้เคียงจากข้อมูลที่อยู่ต่างกลุ่มกัน ซึ่งสามารถคำนวณได้จากสมการที่ 5

$$s = \frac{(b-a)}{\max(a,b)} \quad (5)$$

โดยที่

- a แทนระยะห่างเฉลี่ยระหว่างจุดข้อมูลกับจุดในกลุ่มเดียวกัน
- b แทนระยะห่างเฉลี่ยของจุดข้อมูลกับจุดที่ใกล้ที่สุดของกลุ่มอื่น


จากการวิเคราะห์ด้วยวิธี Silhouette Coefficient เพื่อแสดงคุณภาพการแยกกลุ่มซึ่งผู้วิจัยได้สรุปผลการคำนวณในตารางที่ 8

ตารางที่ 8 : ผลการคำนวณค่า Silhouette Coefficient

จำนวนกลุ่ม	ระยะห่างระหว่างกลุ่ม
k = 2	0.3222
k = 3	0.3535
k = 4	0.3606
k = 5	0.4036
k = 6	0.4135
k = 7	0.448
k = 8	0.4558
k = 9	0.4577
k = 10	0.4650


จากตารางที่ 8 พบว่า โดยค่าระยะห่างระหว่างกลุ่มที่สูงแสดงว่าการแบ่งกลุ่มมีความชัดเจนกว่าค่าระยะห่างระหว่างกลุ่มที่มีค่าน้อย ซึ่งหมายความว่า การกำหนดค่า k ตั้งแต่ 5 ขึ้นไป ค่า

ระยะห่างระหว่างกลุ่มที่คำนวณได้จะสูงขึ้นตามลำดับ ดังภาพที่ 3



ภาพที่ 3 : การวัดประสิทธิภาพด้วยวิธี Silhouette Coefficient

จากการวิเคราะห์ระยะห่างภายในกลุ่ม (Inertia) และระหว่างกลุ่ม (Inter-cluster Distance) พบว่าการกำหนดค่า $k=3$ มีความเหมาะสมที่สุดสำหรับการแบ่งกลุ่มลูกค้าในครั้งนี้ โดยสามารถจำแนกกลุ่มเป้าหมายได้เป็น 3 ระดับ ได้แก่ กลุ่ม VIP, กลุ่มลูกค้าประจำ และกลุ่มลูกค้าاجر ในเชิงสถิติ แม้การกำหนดค่า $k=3$ จะมีค่าความแตกต่างระหว่างกลุ่มอยู่ที่ 0.3535 ซึ่งน้อยกว่าการแบ่ง 4 กลุ่ม เพียง 0.0071 และน้อยกว่าการแบ่ง 5 กลุ่ม เพียง 0.0501 แต่ความแตกต่างดังกล่าวไม่มีนัยสำคัญเพียงพอที่จะเพิ่มความซับซ้อนในการจัดการ ดังนั้น การแบ่งกลุ่มที่ $k=3$ จึงเป็นสัดส่วนที่ลงตัวที่สุดเพื่อประสิทธิภาพและความคล่องตัวในการบริหารจัดการลูกค้า



ภาพที่ 4 : การวัดประสิทธิภาพของกลุ่ม

4. เอกสารอ้างอิง

[1] ศิวภู่งู ช. สังกมเกมออนไลน์ผู้สังคมาแห่งความเป็นจริง. MCU SSR [อินเทอร์เน็ต]. 28 กุมภาพันธ์ 2020 [อ้างถึง 20 กุมภาพันธ์ 2026];6(2-01):143-58. available at: <https://so03.tci-thaijo.org/index.php/jssr/article/view/240198>

- [2] ปิติพัฒน์ ศ, พิพัฒน์สูงเนิน ป, มณีศรี เ. ปัจจัยที่มีอิทธิพลต่อความตั้งใจซื้อไอเท็มเสมือนในเกมออนไลน์ของนักศึกษา คณะวิทยาการจัดการ มหาวิทยาลัยราชภัฏอุดรธานี. MSUDRUJ [อินเทอร์เน็ต]. 1 มกราคม 2022 [อ้างถึง 20 กุมภาพันธ์ 2026];3(6):89-102. available at: <https://so08.tci-thaijo.org/index.php/MSJournal/article/view/2963>
- [3] คล้ายจันทร์ ป. พฤติกรรมการเล่นเกมออนไลน์ VALORANT ของนักศึกษาในเขตจังหวัดปทุมธานี. PANYAPIWAT JOURNAL [อินเทอร์เน็ต]. 20 ธันวาคม 2025 [อ้างถึง 13 กุมภาพันธ์ 2026];17(3):246-57.
- [4] ปีกกิ้น ส้อ. การสร้างชุมชนเสมือนจริงในเกมออนไลน์กับพฤติกรรมการติดสื่อออนไลน์ของเยาวชนในเขตกรุงเทพมหานคร. วารสารสุขุทธิปริทัศน์ [อินเทอร์เน็ต]. 10 สิงหาคม 2020.
- [5] ชัยรัช วงศ์ชมบุญ. 2560. "พฤติกรรมการเปิดรับและความพึงพอใจต่อการสื่อสารของเกมออนไลน์ประเภท MOBA (Multiplayer Online Battle Arena)." สารนิพนธ์นิเทศศาสตรมหาบัณฑิต กลุ่มวิชาการสื่อสารสื่อดิจิทัล คณะนิเทศศาสตร์ มหาวิทยาลัยศรีปทุม.
- [6] Christoph S. A Systematic Literature Review on Applying CRISP-DM Process Model, Procedia Computer Science. Thail Stat. 2021; 181(1): 526-534.
- [7] Zongxiao Wu, Cong Zang, Chia-Huei Wu, Zilin Deng, Xuefeng Shao, Wei Liu, Improving Customer Value Index and Consumption Forecasts Using a Weighted RFM Model and Machine Learning Algorithms, Journal of Global Information Management, Volume 30, Issue 3, 2022, ISSN 1062-7375, <https://doi.org/10.4018/JGIM.20220701.0a1>.
- [8] Bilal Aslam, Identifying optimistic stocks with K-means clustering algorithm, International Review of Economics & Finance, Volume 104, 2025, 104579, ISSN 1059-0560.
- [9] Natalia Rylko, Michał Stawiarz, Paweł Kurtyka, Vladimir Mityushev, Study of anisotropy in polydispersed 2D micro and nano-composites by Elbow and K-Means clustering methods, Acta Materialia, Volume 276, 2024, 120116, ISSN 1359-6454.
- [10] Peng Du, Fenglian Li, Jianli Shao, Multi-agent reinforcement learning clustering algorithm based on silhouette coefficient, Neurocomputing, Volume 596, 2024, 127901, ISSN 0925-2312.

การพัฒนาระบบแนะนำรายวิชาเรียนรายบุคคลโดยใช้เทคนิคการวิเคราะห์ กฎความสัมพันธ์ กรณีศึกษานักเรียนระดับประถมศึกษาปีที่ 5

Development of a Personalized Course Recommendation System Using Association Rule Mining: A Case Study of Grade 5 Students

ณภพร เตชะเลิศถาวรกุล¹ อิศริญา เขียวสวัสดิ์¹ เพ็ชรรัตน์ รุ่งวชิรา² สุทธิรักษ์ สุขเขมม² อัครา กิจการเจริญสิน²
และ รุจิรา จุลภักดิ์^{2*}

¹สาขาวิชาระบบสารสนเทศ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

²สาขาวิชาระบบสารสนเทศ คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

(* Rujira_ju@rmutto.ac.th)

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ 1) วิเคราะห์รูปแบบความสัมพันธ์ของจุดอ่อนในการเรียนรู้รายบทเรียนของนักเรียนชั้นประถมศึกษาปีที่ 5 2) เพื่อพัฒนาระบบแนะนำเส้นทางการเรียนรู้ส่วนบุคคล โดยใช้เทคนิคการทำเหมืองข้อมูล กลุ่มตัวอย่างที่ใช้ในการวิจัยคือนักเรียนชั้นประถมศึกษาปีที่ 5 จำนวน 48 คน เครื่องมือที่ใช้ในการวิจัยประกอบด้วย คะแนนการวัดผลสัมฤทธิ์ทางการเรียนรายจุดประสงค์จำนวน 5 กลุ่มสาระการเรียนรู้ รวม 23 บทเรียน วิเคราะห์ข้อมูลโดยใช้สถิติพื้นฐาน (ค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน) และอัลกอริทึม Apriori เพื่อสกัดกฎความสัมพันธ์ (Association Rules) จากผลการทดลองพบว่านักเรียนส่วนใหญ่มีคะแนนเฉลี่ยต่ำกว่าเกณฑ์ในบทเรียนที่ต้องใช้ทักษะการคำนวณและตรรกะ ได้แก่ บทเรียนเศษส่วน (Mean = 5.08) ทศนิยม (Mean = 4.90) และเศรษฐศาสตร์ (Mean = 5.35) ในขณะที่กลุ่มวิชาภาษาไทยและภาษาอังกฤษมีผลสัมฤทธิ์ทางการเรียนอยู่ในเกณฑ์สูงอย่างสม่ำเสมอ และจากการวิเคราะห์ด้วยอัลกอริทึม Apriori โดยมีการกำหนดค่า min support = 0.2 และ min confidence = 0.6 พบกฎความสัมพันธ์ที่มีนัยสำคัญยิ่ง ได้แก่ {เศษส่วน} → {ทศนิยม} และ {เศษส่วน} → {เศรษฐศาสตร์} โดยมีค่า Lift สูงกว่า 1.0 ซึ่งบ่งชี้ว่าจุดอ่อนในทักษะพื้นฐานทางคณิตศาสตร์ส่งผลกระทบต่อ การเรียนรู้ทั้งบทเรียนอื่นในรายวิชาเดียวกันและข้ามสาระวิชา

คำสำคัญ: อัลกอริทึม Apriori, กฎความสัมพันธ์, ระบบแนะนำการเรียนรู้, การทำเหมืองข้อมูลทางการศึกษา, เส้นทางการเรียนรู้ส่วนบุคคล

Abstract

The objectives of this research were: 1) to analyze the relationship patterns of learning weaknesses across lessons for Grade 5 students, and 2) to develop a personalized learning roadmap recommendation system using data mining techniques. The sample consisted of 48 Grade 5 students. The research instruments included achievement scores across 5 core subject areas, covering a total of 23 lessons. Data were analyzed using descriptive statistics (Mean and Standard Deviation) and the Apriori algorithm to extract association rules. The results of the experiment indicated that the majority of students performed below the criteria in lessons requiring computational and logical skills, specifically in Fractions (Mean = 5.08), Decimals (Mean = 4.90), and Economics (Mean = 5.35). In contrast, academic achievement in Thai and English subjects remained consistently high. Analysis using the Apriori algorithm, with a minimum support of 0.2 and minimum confidence of 0.6, revealed highly significant association rules, including {Fractions} → {Decimals} and {Fractions} → {Economics}. These rules yielded a Lift value greater than 1.0, indicating that weaknesses in foundational mathematical skills significantly impact learning outcomes in both related lessons within the same subject and across different subject areas.

Keywords: Apriori Algorithm, Association Rules, Personalized Learning Roadmap, Data Mining in Education, Knowledge Hierarchy

1. บทนำ

1.1. ความเป็นมาและความสำคัญของปัญหา

โรงเรียนกวดวิชามีที่มาจากจาการเป็นระบบการศึกษา กู๋ชานานที่เกดขึ้นเพื่อเติมเต็มช่องว่างของหลักสูตรในระบบ โรงเรียน และตอบสนองต่อสภาวะการแข่งขันทางการศึกษาที่สูงขึ้นในปัจจุบัน ซึ่งมีความสำคัญเนื่องจากเป็นกลไกช่วยปรับความรู้รายบุคคลและวิเคราะห์เส้นทางสู่ความสำเร็จในการสอบคัดเลือก ดังนั้นการพัฒนาแบบแผนรายวิชาเรียนโดยอิงจากผลคะแนนแยกตามเนื้อหาจึงเป็นกลยุทธ์สำคัญที่ช่วยเปลี่ยนบทบาทของโรงเรียนกวดวิชาจากการสอนแบบทั่วไปให้ไปสู่การเป็นที่ปรึกษาทางการศึกษาที่แม่นยำมากขึ้น ซึ่งจะช่วยให้นักเรียนพัฒนาตนเองได้ตรงจุด และสร้างผลสัมฤทธิ์ทางการเรียนที่มีประสิทธิภาพสูงสุดภายใต้ทรัพยากรเวลาและค่าใช้จ่ายที่จำกัดของผู้ปกครองและจากการศึกษางานวิจัยที่เกี่ยวข้องพบว่า

[1] การวิจัยนี้มุ่งสร้างกลยุทธ์บริหารโรงเรียนกวดวิชาเพื่อจัดการเรียนรู้ที่มีประสิทธิภาพ โดยพบว่าสภาพที่พึงประสงค์อยู่ในระดับมากที่สุดและมีกลยุทธ์หลัก 5 ด้าน คือ การบริหารบุคลากรอย่างยั่งยืน การสร้างความเป็นเลิศทางวิชาการ การดูแลความปลอดภัยตามมาตรฐานสากล การบริการเชิงรุก และการตลาดวิชาการแนวใหม่ ซึ่งครอบคลุมทั้งระบบการวัดผลและการจัดการเชิงรุกเพื่อตอบสนองต่อความต้องการของผู้เรียนและผู้ปกครองได้อย่างเป็นรูปธรรม

[2] ผู้วิจัยได้นำเทคโนโลยีฐานข้อมูลมาวิเคราะห์จุดอ่อนจุดแข็งรายบุคคลจึงเป็นการเปลี่ยนผ่านจากการประเมินผลแบบเดิมไปสู่การวัดผลเชิงวิเคราะห์ที่ช่วยออกแบบเส้นทางการเรียนรู้ให้ตอบโจทย์การยกระดับขีดความสามารถในการแข่งขันของผู้เรียนได้อย่างเป็นรูปธรรม ช่วยปิดช่องว่างระหว่างสภาพปัจจุบันและสภาพที่พึงประสงค์ของการบริหารวิชาการในโรงเรียนกวดวิชาให้เกิดประสิทธิภาพสูงสุดตามมาตรฐานสากล

[3] การศึกษานี้ชี้ให้เห็นว่าภาพลักษณ์องค์กรด้านชื่อเสียงและการติดต่อระหว่างบุคคลเป็นปัจจัยหลักที่มีอิทธิพลต่อการตัดสินใจใช้บริการโรงเรียนกวดวิชาของนักเรียนมัธยมปลายในเชียงใหม่ โดยเฉพาะกลุ่มสายวิทย์-คณิตที่มีผลการเรียนดี ซึ่งให้ความสำคัญกับภาพลักษณ์ด้านเอกลักษณ์ ชื่อเสียง สภาพแวดล้อม และการบริการในระดับมาก ดังนั้นการสร้าง ความเชื่อมั่นผ่านระบบการสื่อสารที่มีประสิทธิภาพและการรักษาชื่อเสียงทางวิชาการจึงเป็นกลยุทธ์สำคัญในการจูงใจนักเรียนกลุ่มเป้าหมายให้ตัดสินใจเลือกใช้บริการของสถาบัน

จากการศึกษางานวิจัยที่เกี่ยวข้อง ผู้วิจัยจึงนำเสนอแนวทางการ แนะนำรายวิชาเรียนรายบุคคล ที่บูรณาการระหว่างกลยุทธ์การบริหารวิชาการสู่ความเป็นเลิศ เทคโนโลยีการวิเคราะห์ข้อมูลเชิงลึก และการเสริมสร้างภาพลักษณ์ด้านการบริการเชิงรุกเข้าด้วยกัน โดยระบบจะช่วยประเมินเชิง

วิเคราะห์เฉพาะราย เพื่อระบุจุดอ่อนจุดแข็งของนักเรียนได้อย่างแม่นยำ


1.2. วัตถุประสงค์

วัตถุประสงค์ของการพัฒนาระบบแนะนำรายวิชาเรียนรายบุคคล โดยแบ่งออกเป็น 2 ประเด็นหลัก ดังนี้

- 1) เพื่อพัฒนาระบบฐานข้อมูลการวัดและประเมินผลเชิงวิเคราะห์ เพื่อระบุจุดแข็งและจุดอ่อนรายบุคคล
- 2) เพื่อออกแบบอัลกอริทึมการแนะนำเส้นทางการเรียนรู้เฉพาะบุคคล

1.3 กรอบแนวคิดการวิจัย

ผู้วิจัยได้กำหนดกรอบแนวคิดของการวิจัย โดยแบ่งตัวแปรต้นและตัวแปรตามไว้ดังภาพที่ 1



2. ทฤษฎีที่เกี่ยวข้อง

2.1 ทฤษฎีกฎความสัมพันธ์ (Association Rule Mining)

ทฤษฎีกฎความสัมพันธ์ (Association Rule Mining: ARM)

[4] คือการใช้กระบวนการทางสถิติและคอมพิวเตอร์เพื่อค้นหา รูปแบบที่ซ่อนอยู่ของชุดข้อมูล โดยมีจุดเริ่มต้นจากการวิเคราะห์ตะกร้าสินค้า (Market Basket Analysis) เช่น การค้นพบว่าลูกค้าที่ซื้อผ้าอ้อมมักจะซื้อเบียร์พร้อมกัน เป็นต้น ซึ่งสามารถเขียนเป็นกฎความสัมพันธ์ได้ดังนี้

$$X \rightarrow Y$$

หมายความว่า หากเกิดเหตุการณ์ X ขึ้น มีแนวโน้มที่จะเกิดเหตุการณ์ Y ตามมา ซึ่งอัลกอริทึมที่นิยมใช้ในการวิเคราะห์หากฎความสัมพันธ์ เช่น Apriori Algorithm


1) Apriori Algorithm

Apriori Algorithm คือ อัลกอริทึมที่ใช้ค้นหาชุดข้อมูลที่พบบ่อย (Frequent Itemsets) ในฐานข้อมูลขนาดใหญ่ โดยใช้หลักการที่เรียกว่า Apriori Property [5] ขั้นตอนการทำงานมีดังนี้

ขั้นตอนที่ 1 การกำหนดค่าเกณฑ์ต่ำสุด (Minimum Support) คือการกำหนดความบ่อยขั้นต่ำที่พบ

ขั้นตอนที่ 2 การสร้าง Candidate (C) และ Frequent Itemset (L) โดยที่

- C1 (Candidate1) คือการนับความถี่ของแต่ละเหตุการณ์
- L1 (Frequent) คือการเลือกเฉพาะข้อมูลที่ผ่านมาเกณฑ์ Min Support
- C2 (Candidate2) ข้อมูลที่ผ่านมาจาก L1 มาจับคู่กันเป็นคู่ๆ
- L2 (Frequent2) คัดเลือกคู่ข้อมูลที่มีค่ามากกว่า Min Support พร้อมกันที่มีค่ามากกว่า Min Support
- ทำซ้ำจนกว่าจะไม่สามารถจับคู่ที่ใหญ่ขึ้นและผ่านเกณฑ์ได้อีก



ภาพที่ 2: CRISP-DM

ขั้นตอนที่ 3 การสร้างกฎความสัมพันธ์ คือการนำ Frequent Itemsets ที่ได้จากขั้นตอนสุดท้ายมาสร้างเป็นกฎ $X \rightarrow Y$ และคำนวณค่า Confidence เพื่อตรวจสอบความน่าเชื่อถือ

2.2 โครงสร้างลำดับขั้นความรู้ (Knowledge Hierarchy)

คือการจัดระเบียบเนื้อหาการเรียนรู้อย่างเป็นระบบ โดยเรียงลำดับจากทักษะพื้นฐานที่ง่ายไปสู่ทักษะที่ซับซ้อนขึ้น โดยมีรากฐานมาจากทฤษฎีของ Robert Gagné [6] ซึ่งระบุว่า การเรียนรู้มีลักษณะเป็นลำดับขั้น (Sequential) ทักษะแต่ละอย่างมีวิชาก่อนหน้าหรือวิชาเบื้องต้น (Prerequisites) ที่ผู้เรียนต้องเชี่ยวชาญก่อน จึงจะสามารถก้าวไปสู่เนื้อหาขั้นถัดไปได้

3. วิธีการวิจัย

ผู้วิจัยได้ดำเนินการพัฒนางานวิจัยอย่างเป็นระบบตามวงจรชีวิตของวิทยาศาสตร์ข้อมูล (Data Science Lifecycle) โดยประยุกต์ใช้มาตรฐาน CRISP-DM (Cross-Industry Standard Process for Data Mining) [7] ดังภาพที่ 2 เพื่อเป็นกรอบแนวทางในการสกัดหาความสัมพันธ์จากเหมืองข้อมูล (Association Rule Mining) [8]

ผู้วิจัยได้ดำเนินการวิจัยตามขั้นตอนดังต่อไปนี้

ขั้นตอนที่ 1 การเตรียมข้อมูล (Data Preparation) ผู้วิจัยได้ทำการเก็บรวบรวมข้อมูลจากโรงเรียนกวดวิชาแห่งหนึ่ง เฉพาะนักเรียนชั้นประถมศึกษาปีที่ 5 ตั้งแต่เดือนพฤษภาคม พ.ศ. 2568 จนถึง เดือนตุลาคม พ.ศ. 2568 มีจำนวน 48 คน ซึ่งเป็นการศึกษาเบื้องต้น (preliminary study) โดยจัดเก็บข้อมูลคะแนนสอบตามจุดประสงค์การเรียนรู้ ของ 5 วิชาหลัก ได้แก่ วิชาคณิตศาสตร์ วิชาวิทยาศาสตร์ วิชาภาษาอังกฤษ วิชาภาษาไทย และวิชาสังคม ซึ่งแต่ละวิชามีจำนวนบทเรียนดังตารางที่ 1

ตารางที่ 1: รายละเอียดของบทเรียนในแต่ละรายวิชา

วิชา	จำนวน บทเรียน	รายละเอียด(ชื่อคอลัมน์)
คณิตศาสตร์	3	หน่วยที่ 1 เศษส่วน (M1) หน่วยที่ 2 ทศนิยม (M2) หน่วยที่ 3 การนำเสนอข้อมูล (M3)
วิทยาศาสตร์	3	หน่วยที่ 1 แรงเนื่องจากอากาศและน้ำ (S1) หน่วยที่ 2 เสียง (S2) หน่วยที่ 3 ลมบก ลมทะเล และลมมรสุม (S3)
ภาษาอังกฤษ	4	หน่วยที่ 1 Greeting and Leave taking (E1) หน่วยที่ 2 My school (E2) หน่วยที่ 3 my body (E3) หน่วยที่ 4 My Family (E4)
ภาษาไทย	7	หน่วยที่ 1 สื่อสารคล่องต้องรู้วิธี (T1) หน่วยที่ 2 สังข์ทอง ตอน กำเนิดพระสังข์ (T2) หน่วยที่ 3 กระจ่างวิชา (T3) หน่วยที่ 4 ภาษาพัฒนาชีวิต (T4) หน่วยที่ 5 วิชาเหมือนสินค้า (T5) หน่วยที่ 6 นิทานอ่านสนุก (T6)

วิชา	จำนวน บทเรียน	รายละเอียด(ชื่อคอลัมน์)
หน่วยที่ 7 ราชาธิราช ตอน กำเนิดมะกะโท (T7)		
สังคม	6	หน่วยที่ 1 ศาสนา ศิลธรรม จริยธรรม (SO1) หน่วยที่ 2 หน้าที่พลเมือง (SO2) หน่วยที่ 3 วัฒนธรรม และการ ดำเนินชีวิต (SO3) หน่วยที่ 4 เศรษฐศาสตร์ (SO4) หน่วยที่ 5 ภูมิศาสตร์ (SO5) หน่วยที่ 6 ประวัติศาสตร์ (SO6)

ตัวอย่างคะแนนของนักเรียนจำนวน 48 คน ที่ได้รับรวบรวมไว้ในแต่ละรายวิชา แสดงดังตารางที่ 2

ตารางที่ 2 : ตัวอย่างคะแนนของนักเรียนจำนวน 48 คน

ID	คณิต (M1-3)	วิทย์ (SI-3)	อังกฤษ (E1-4)	ไทย (TI-7)	สังคม (SO1-6)
1	9, 10, 9	10, 9, 10	9, 10, 9, 8	10, 9, 9, 10, 9, 9, 10	10, 9, 10, 9, 10, 9
2	8, 9, 8	9, 8, 9	8, 9, 9, 7	9, 8, 9, 8, 8, 9, 8	9, 9, 8, 9, 8, 9
3	4, 5, 8	8, 7, 8	9, 8, 9, 9	8, 9, 9, 8, 9, 8, 9	8, 8, 9, 5, 8, 8
4	3, 4, 7	5, 8, 6	8, 8, 7, 7	9, 8, 9, 8, 8, 9, 9	8, 9, 8, 4, 9, 8
5	7, 8, 7	8, 7, 8	8, 8, 7, 8	8, 9, 8, 9, 9, 8, 9	8, 8, 8, 7, 8, 8
...
40	2, 3, 5	4, 5, 4	5, 6, 7, 5	7, 6, 5, 7, 6, 7, 5	7, 5, 6, 4, 5, 7
...
48	2, 1, 3	3, 2, 4	4, 3, 5, 2	5, 4, 5, 4, 3, 4, 4	4, 3, 5, 2, 4, 3

ขั้นตอนที่ 2 การแปลงข้อมูลเป็นเลขฐานสอง (Data Transformation) เนื่องจากอัลกอริทึม Apriori ไม่สามารถคำนวณด้วยเลขฐาน 10 ได้ จึงจำเป็นต้องแปลงข้อมูลคะแนนให้เป็นเลขฐาน 2 เพื่อกำหนดระดับคะแนนสอบผ่านแทนด้วย 1 และสอบไม่ผ่านแทนด้วย 0 ซึ่งในโรงเรียนแห่งนี้กำหนดคะแนนการสอบผ่านอยู่ที่ 7 คะแนนจากคะแนนเต็ม 10 ดังนั้นจึงกำหนดจุดตัด (Threshold) มีค่าเท่ากับ 7 คะแนน

เมื่อนำข้อมูลมาแปลงเป็นเลขฐาน 2 เรียบร้อยแล้วแสดงดังตารางที่ 3

ตารางที่ 3: แปลงข้อมูลเป็นไบนารี

Student ID	M1_Fraction	M2_Decimals	M3_DataPresent	SO4_Eco	SO5_Geo	SO6_Hist
1	1	1	1	1	1	1
2	1	1	1	1	1	1
3	1	1	1	1	1	1
...
14	1	1	1	1	1	1
15	1	1	1	1	1	1
16	0	0	0	0	0	0
17	0	0	0	0	0	0
...
45	0	0	0	0	0	0
46	0	0	0	0	0	0
47	0	0	0	0	0	0
48	0	0	0	0	0	0

ขั้นตอนที่ 3 ค้นหา Frequent Itemsets ของชุดบทเรียนที่นักเรียนสอบตกบ่อย เนื่องจากผู้วิจัยสนใจเฉพาะหน่วยเรียนที่สอบตกบ่อย จึงถือกฎเฉพาะกรณีที่ค่าเป็น 0 แต่เนื่องจากอัลกอริทึมจะหาค่าที่เป็น 1 ดังนั้นเราจะสลับค่า 0 เป็น 1 และ 1 เป็น 0 เพื่อหาจุดอ่อนและดำเนินการดังนี้

- 1) กำหนดเกณฑ์ขั้นต่ำของความบ่อยมีค่าเท่ากับ 20 % หรือ $\text{min_support} = 0.2$ เนื่องจากเป็นค่าที่ไม่สูงและไม่ต่ำจนเกินไป สามารถคัดกรองข้อมูลที่เกิดขึ้นได้ ดังนั้นจำนวนนักเรียนมี 48 คน สามารถคำนวณได้คือ $48 \times 0.2 = 9.6$ ดังนั้นจะสนใจเฉพาะบทเรียนที่มีนักเรียนสอบตกเหมือนกันตั้งแต่ 10 คนขึ้นไปเท่านั้น
- 2) นำบทเรียนที่ผ่านเกณฑ์มาจับคู่กัน เช่น $\{M1, M2\}$ หรือ $\{M1, SO4\}$ แล้วดูว่ามีคนตก พร้อมกัน ถึง 10 คนหรือไม่ ถ้าไม่ถึงให้ตัดทิ้ง
- 3) คำนวณหาค่าค่าสนับสนุน (Support) ดังสมการที่ 1

$$\text{Support}(I) = \frac{\sigma(I)}{N} \quad (1)$$

โดยที่

$\text{Support}(I)$ แทนค่าสนับสนุนของชุดบทเรียน I

N แทนจำนวนนักเรียนทั้งหมด

$\sigma(I)$ แทน ค่าความถี่ของจำนวนนักเรียนที่สอบตก

ชุดบทเรียนเหล่านั้นพร้อมกัน

ขั้นตอนที่ 4 สร้างกฎความสัมพันธ์ (Association Rules)

หลังจากได้ชุดบทเรียนที่สอบตกบ่อยแล้ว สามารถนำ
 คู่เหล่านั้นมาสร้างเป็นกฎได้ดังนี้

$$X \rightarrow Y$$

ถ้า สอบตกบทเรียน X แล้ว มักจะสอบตกบทเรียน Y

ขั้นตอนที่ 5 กำหนดค่าความเชื่อมั่น (Confidence Filtering)

การกำหนดค่าความเชื่อมั่นเพื่อเป็นเกณฑ์ขั้นต่ำที่ใช้ในการ
 พิจารณากฎที่สร้างขึ้นมาว่ามีความน่าเชื่อถือหรือไม่ ซึ่ง
 งานวิจัยนี้ผู้วิจัยได้กำหนดค่าความเชื่อมั่นไว้ที่ 0.6
 (min_confidence = 0.6) เนื่องจากเป็นค่าความเชื่อมั่นที่เกิดขึ้น
 เกินครึ่ง ซึ่งน่าเชื่อถือกว่าการสุ่มขึ้นมาหรือการกำหนดใน
 อัตรา 50:50 ดังนั้นกฎใดที่ค่าความเชื่อมั่นน้อยกว่า 0.6 ต้อง
 ตัดทิ้ง ซึ่งคำนวณได้จากสมการที่ 2

$$Confidence(X \rightarrow Y) = \frac{Support(XUY)}{Support(X)} \quad (2)$$

ขั้นตอนที่ 6 การวิเคราะห์ค่าความสัมพันธ์เชิงลึก (Lift) คือ
 การยืนยันว่าจุดอ่อนในวิชาหนึ่ง ส่งผลต่ออีกวิชาหนึ่งอย่างมี
 นัยสำคัญจริง สามารถคำนวณได้จากสมการที่ 3 ซึ่งหาก
 ผลลัพธ์ได้มากกว่า 1 แสดงว่ากฎนั้นมีความสัมพันธ์กันอย่างมี
 นัยสำคัญจริง

$$Lift(X \rightarrow Y) = \frac{Confidence(X \rightarrow Y)}{Support(Y)} \quad (3)$$

4. ผลการวิจัยและอภิปรายผล

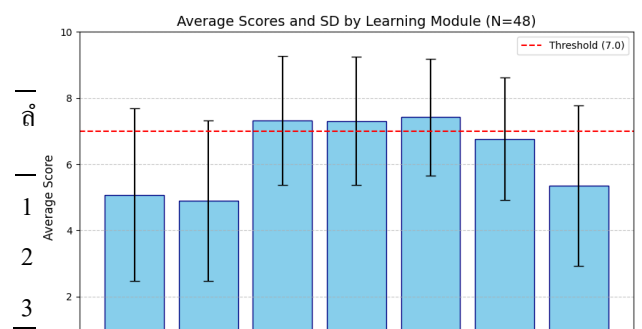
จากการคำนวณหาค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน
 ของกลุ่มรายวิชาทั้งหมด พบว่า กลุ่มรายวิชาที่มีนักเรียนสอบ
 ไม่ผ่าน (Threshold < 7) 3 อันดับแรก ได้แก่ M1 แทนชุด
 บทเรียนเศษส่วน, M2 แทนชุดบทเรียนทศนิยม และ S04
 แทนชุดบทเรียนเศรษฐศาสตร์ ซึ่งได้แสดงรายละเอียดไว้ใน
 ตารางที่ 4 และสรุปคะแนนเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน
 ไว้ดังภาพที่ 3

ตารางที่ 4: สรุปคะแนนเฉลี่ย (Mean) และส่วนเบี่ยงเบน
 มาตรฐาน (S.D.)

กลุ่มสาระการ เรียน	ID	รายชื่อบทเรียน	Mean	S.D.
คณิตศาสตร์	M1	เศษส่วน (Fraction)	5.08	2.6
	M2	ทศนิยม (Decimals)	4.9	2.43
	M3	การนำเสนอข้อมูล	7.33	1.95

กลุ่มสาระการ เรียน	ID	รายชื่อบทเรียน	Mean	S.D.
วิทยาศาสตร์	S1	แรงในชีวิตประจำวัน	7.31	1.93
	S2	เสียง	7.42	1.77
	S3	ลมฟ้าอากาศ	6.77	1.84
ภาษาอังกฤษ	E1	การทักทาย (Greeting)	7.31	1.83
	E2	โรงเรียนของเรา	7.27	1.77
	E3	ร่างกายของฉัน	7.44	1.76
	E4	ครอบครัว	7.35	1.77
ภาษาไทย	T1	การสื่อสาร (Comm)	7.33	1.83
	T2	สังคม	7.42	1.82
	T3	กระแสด (Krasae)	7.35	1.86
	T4	การพัฒนา (Dev)	7.44	1.76
	T5	สินค้าและบริการ (Goods)	7.29	1.95
	T6	นิทาน (Fable)	7.46	1.81
	T7	ราชาธิราช	7.35	1.76
สังคม	S01	ศาสนาและจริยธรรม	7.5	1.74
	S02	หน้าที่พลเมือง	7.31	1.86
	S03	วัฒนธรรมไทย	7.35	1.74
	S04	เศรษฐศาสตร์ (Econ)	5.35	2.43
	S05	ภูมิศาสตร์	7.15	1.73
	S06	ประวัติศาสตร์	7.38	1.62

และผลการวิเคราะห์กฎความสัมพันธ์ (Association Rules) ด้วย
 อัลกอริทึม Apriori ซึ่งได้กำหนดค่าให้กับ min support = 0.2
 และ min confidence = 0.6 พบว่ากฎที่ได้แสดงดังตารางที่ 5



ภาพที่ 3 : แสดงคะแนนเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน

จากตารางที่ 5 สามารถอธิบายกฎความสัมพันธ์ที่ได้ดังนี้

- **กฎข้อที่ 1: {M1} -> {M2} (Support 0.35, Confidence 0.88, Lift 1.95)** เป็นกฎความสัมพันธ์ที่แข็งแกร่งที่สุด มีค่า Confidence = 0.88 ซึ่งหมายความว่าถ้านักเรียนมี ทำคะแนนต่ำในเรื่องเศษส่วน มีโอกาสสูงถึง 88% ที่จะ

ทำคะแนนต่ำในเรื่องทัศนคติด้วย เนื่องจากสองเรื่องนี้มีพื้นฐานทางคณิตศาสตร์ที่เชื่อมโยงกัน

- **กฎข้อที่ 2: {M1} -> {SO4} (Support 0.25, Confidence 0.72)** ซึ่งให้เห็นว่าพื้นฐานคำนวณในเรื่องของเศษส่วน อาจส่งผลต่อวิชาเศรษฐศาสตร์ ซึ่งต้องใช้การคำนวณ สัดส่วนหรือตัวเลขด้วยเช่นกัน
- **กฎข้อที่ 3: {S1} -> {S3} (Support 0.21, Confidence 0.65)** ในวิชาวิทยาศาสตร์ ความเข้าใจเรื่องแรง (S1) สัมพันธ์กับเรื่องลมฟ้าอากาศ (S3) ซึ่งอาจเป็นเพราะทั้งสองบทเรียนต้องใช้ความเข้าใจเรื่องความดันหรือแรงกระทำในธรรมชาติ

ผลการวิจัยชี้ให้เห็นว่าปัญหาการเรียนรู้นักเรียน ไม่ได้เกิดขึ้นแค่หัวข้อใดหัวข้อหนึ่ง แต่มีความสัมพันธ์เชื่อมโยงกัน อย่างมีนัยสำคัญระหว่างเนื้อหาต่าง ๆ การประยุกต์ใช้เทคนิคการทำเหมืองข้อมูล (Data Mining) ด้วยอัลกอริทึม Apriori จึงเป็นเครื่องมือที่มีประสิทธิภาพในสเกลให้เห็นรูปแบบพฤติกรรมการเรียนรู้ที่ซ่อนอยู่ ซึ่งสะท้อนให้เห็นว่าประโยชน์สูงสุดของการวิเคราะห์ในครั้งนี่คือการสร้างระบบพยากรณ์ และป้องกันการล้มเหลวทางการเรียนรู้ โดยผู้สอนสามารถใช้ กฎความสัมพันธ์เพื่อระบุกลุ่มนักเรียนที่มีความเสี่ยงได้ล่วงหน้า อาทิ หากนักเรียนเริ่มมีปัญหาในการเรียนรู้บทเรียน ต้นทางอย่างเศษส่วน (M1) จะสามารถพยากรณ์ได้ทันทีว่า นักเรียนมีแนวโน้มที่จะประสบปัญหาในบทเรียนทัศนคติ (M2) และเศรษฐศาสตร์ (SO4) ตามลำดับ ข้อมูลเชิงลึกนี้ช่วยให้สถานศึกษาสามารถจัดโปรแกรมสอนซ่อมเสริมแบบ เฉพาะรายบุคคล (Individualized Remediation) ได้ อย่าง แม่นยำและทันทั่วถึง โดยไม่ต้องรอให้เกิดการสอบตกจริง นอกจากนี้ ผลการวิจัยยังเป็นแนวทางในการปรับปรุงลำดับ เนื้อหาในหลักสูตรให้มีความต่อเนื่องและเชื่อมโยงกันมากขึ้น เพื่อสร้างรากฐานความรู้ที่เข้มแข็งต่อไป

5. เอกสารอ้างอิง

- [1] ศรีวิชัย ก, เทพรบัญชากิจ จ. กลยุทธ์การบริหาร โรงเรียนกวดวิชา เพื่อการจัดการเรียนรู้ของผู้เรียน. WTU.J [อินเทอร์เน็ต]. 26 ธันวาคม 2023 [อ้างถึง 20 กุมภาพันธ์ 2026];9(3):15-28.
- [2] แผ่นทอ, กฤติยา; อุสา โห, ชญาพิมพ์; and ศิริบรรณพิทักษ์, พุทธิ (2020) "การบริหารวิชาการของโรงเรียนกวดวิชาตามแนวคิดการยกระดับขีดความสามารถในการแข่งขันของประเทศไทยในเวที โลก," Journal of Education Studies: Vol. 48: Iss. 2, Article 2. DOI: 10.58837/CHULA.EDUCU.48.2.2
- [3] Watcharaponganan S, ansuhaj N, Anek P: Corporate Images of Tutorial Schools Affecting Service-Use Decision Making of High School Students in Muang District, Chiang Mai Province. Journal of Management Science Research, Surindra Rajabhat University. 2022; 6(3) 57 – 71.
- [4] AbuBaker, M. Data Mining Applications in Understanding Electricity Consumers' Behavior: A Case Study of Tulkarm District, Palestine. Energies 2019, 12, 4287 <https://doi.org/10.3390/en12224287>
- [5] Wenbin Zhuang, Lihong Fan, Research on the Optimization of Apriori Algorithm Based On Cloud Computing and Medical Information Data, Procedia Computer Science, 2024, 247 (183-190) ,ISSN 1877-0509. <https://doi.org/10.1016/j.procs.2024.10.022>.
- [6] Joana Berger-Estilita, Robert Greif, Using Gagné's "Instructional Design" to teach clinically applicable knowledge in small groups, Trends in Anaesthesia and Critical Care, 2020, 35 (11-15), ISSN 2210-8440, <https://doi.org/10.1016/j.tacc.2020.08.002>.
- [7] Zahra Eslami, Rouzbeh Ghousi, Hossein Ghanbari, A data-driven framework for railroad accident analysis based on the CRISP-DM and association rule mining: Empirical evidence from the federal railroad administration (2020–2024), Results in Engineering, 2025, 27(106825), ISSN 25901230, <https://doi.org/10.1016/j.rineng.2025.106825>.
- [8] Agrawal, R., Imieliński, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. Proceedings of the ACM SIGMOD International Conference on Management of Data.

A Simplified Wilson-Type Confidence Interval for Binomial Proportions

Chalerm Sak Mayoo *

Department of Applied Statistics, Faculty of Science, King Mongkut's University of Technology North Bangkok, 10800,
Bangkok, Thailand
(* sab_chula@hotmail.com)

Abstract

Confidence interval estimation for a binomial proportion remains a fundamental problem in statistical inference, particularly for small and moderate sample sizes where the classical Wald interval is known to exhibit substantial undercoverage. In this study, we investigate a simplified Wilson-type confidence interval obtained by approximating the Wilson score interval and incorporating a pseudo-count adjustment in the estimator of the binomial proportion.

The resulting interval has a closed-form expression that is computationally simple while preserving the stability properties of the Wilson approach. In particular, it can be shown that the proposed interval is asymptotically equivalent to the Wilson score interval, providing theoretical justification for the pseudo-count adjustment used in practice.

The finite-sample performance of the proposed interval is evaluated through a comprehensive numerical study and compared with several widely used methods, including the Wald, Wilson, Agresti–Coull, Brown–Cai–DasGupta, and arcsine intervals. Performance is assessed in terms of average coverage probability, average expected length, and root mean square error across multiple sample sizes and nominal confidence levels.

The results indicate that the simplified Wilson-type interval maintains coverage probabilities close to the nominal level and achieves competitive interval lengths across a wide range of scenarios. These findings suggest that the proposed formulation provides a practical and computationally convenient alternative for confidence interval estimation of binomial proportions.

Keywords: binomial proportion, confidence interval, Wilson score interval, coverage probability, expected length

1. Introduction

Interval estimation for a binomial proportion is one of the most fundamental problems in statistical inference and arises in many practical applications, including medicine, epidemiology, quality control, engineering, and the social sciences. In these settings, researchers are often interested in estimating the probability of success in a Bernoulli process and quantifying the uncertainty associated with that estimate. Although the point estimator of the binomial proportion is straightforward, the construction of reliable confidence intervals remains challenging, particularly when the sample size is small or when the true proportion lies near the boundaries of the parameter space.

The most commonly used method for interval estimation of a binomial proportion is the classical Wald interval, which is derived from the normal approximation to the sampling distribution of the sample proportion [12]. Despite its simplicity and widespread use in introductory statistics, extensive research has demonstrated that the Wald interval performs poorly in many situations. In particular, it often exhibits severe undercoverage when the sample size is small or when the true proportion is close to 0 or 1 [5]. As a result, the Wald interval can lead to misleading statistical inference in practical applications.

To address these shortcomings, several alternative confidence intervals have been proposed. One of the most influential alternatives is the Wilson score interval, originally introduced by Wilson [13] by inverting the score test for the binomial parameter. The Wilson interval has been shown to

achieve substantially improved coverage properties compared with the Wald interval and is widely recommended in statistical practice [5]. Another popular alternative is the Agresti–Coull interval, which modifies the Wald interval by introducing pseudo-count adjustments to the observed data before applying the normal approximation [1]. This adjustment has been shown to substantially improve the stability of coverage probabilities while maintaining computational simplicity.

Several other approaches have also been developed to improve the finite-sample performance of binomial confidence intervals. Brown, Cai, and DasGupta [5,6] provided a comprehensive comparison of binomial interval estimators and proposed intervals based on Bayesian arguments and asymptotic expansions. Subsequent studies have further examined and compared the performance of numerous binomial confidence intervals across a wide range of scenarios [9,11]. Related theoretical developments in discrete confidence interval construction have also been studied in the statistical literature [7]. The arcsine transformation interval, originally motivated by variance-stabilizing transformations, represents another classical approach for addressing boundary problems in binomial inference [3,4].

More recently, several studies have continued to investigate improvements and comparisons of binomial confidence intervals in terms of coverage accuracy and interval length [14,15]. In addition, recent research has explored refined confidence interval procedures for discrete distributions and rare-event settings, as well as score-based interval refinements [2,8,10].

Despite the large number of available methods, the search for confidence intervals that simultaneously achieve good coverage accuracy, short expected length, and computational simplicity remains an active area of research. From a practical perspective, simple closed-form confidence intervals are particularly desirable because they can be easily implemented and interpreted in applied settings.

Motivated by these considerations, this paper investigates a simplified Wilson-type confidence interval for a binomial proportion obtained by approximating the Wilson score interval and incorporating a pseudo-count adjustment in the estimator of the proportion. The resulting formulation yields a closed-form expression that is comparable in simplicity to the classical Wald interval while retaining the stability properties associated with the Wilson approach. Furthermore, the proposed formulation provides an alternative theoretical interpretation of the pseudo-count adjustment commonly used in binomial confidence interval estimation.

The finite-sample performance of the proposed interval is evaluated through a comprehensive numerical study and compared with several widely used methods, including the Wald interval, the Wilson interval, the Agresti–Coull interval, the Brown–Cai–DasGupta interval, and the arcsine transformation interval. The comparison is conducted using three criteria: average coverage probability (ACP), average expected length (AEL), and root mean square error (RMSE) across multiple sample sizes and nominal confidence levels.

2. Research Methodology

2.1 Construction of the Simplified Wilson-Type Interval

Let $X \sim \text{Binomial}(n, p)$. The maximum likelihood estimator of p is

$$\hat{p} = \frac{X}{n}$$

The classical Wald interval is

$$\hat{p} \pm z_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$$

However, the Wald interval is known to perform poorly in finite samples [5].

2.2 Simplified Wilson-Type Approximation

The Wilson score interval can be written as

$$\frac{\hat{p} + \frac{z^2}{2n} \pm z \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z^2}{4n^2}}}{1 + \frac{z^2}{n}}$$

2.3 Proposed Confidence Interval

We introduce the stabilized estimator

$$\tilde{p} = \frac{X+2}{n+4}$$

The simplified Wilson-type confidence interval becomes

$$CI_{CS} = \tilde{p} \pm z_{1-\frac{\alpha}{2}}(n+4)^{-1} \sqrt{n\tilde{p}(1-\tilde{p}) + 1}.$$

2.4 Theoretical Properties

Lemma 1

Let $X \sim \text{Binomial}(n, p)$. The estimator

$$\tilde{p} = \frac{X+2}{n+4},$$

has expectation

$$E(\tilde{p}) = \frac{np+2}{n+4}.$$

Thus the bias is

$$\text{Bias}(\tilde{p}) = \frac{2-4p}{n+4} = O(n^{-1}).$$

Hence the estimator is consistent.

Theorem 1

The proposed simplified Wilson-type interval is asymptotically equivalent to the Wilson score interval as $n \rightarrow \infty$.

Proof As $n \rightarrow \infty$,

$$\tilde{p} = \frac{X+2}{n+4} = \frac{n}{n+4}\hat{p} + \frac{2}{n+4}.$$

Since

$$\frac{n}{n+4} \rightarrow 1 \text{ and } \frac{2}{n+4} \rightarrow 0,$$

we obtain

$$\tilde{p} \rightarrow \hat{p}.$$

Furthermore, by the central limit theorem,

$$\sqrt{n}(\hat{p} - p) \xrightarrow{d} N(0, p(1-p)).$$

Therefore,

$$\sqrt{n}(\tilde{p} - p) \xrightarrow{d} N(0, p(1-p)).$$

Consequently, the proposed interval and the Wilson interval share the same asymptotic distribution and are asymptotically equivalent up to higher-order terms.

2.5 Simulation Design

Simulation experiments were conducted using SAS software under the following parameter settings:

- Nominal confidence levels

$$1 - \alpha = 0.90, 0.95, 0.99$$
- Sample sizes

$$n = 10, 30, 50, 100, 150$$
- True binomial proportions

$$p \in \{0.0005, 0.0010, \dots, 0.9995\}$$

2.6 Evaluation Criteria

Three performance measures are considered. Coverage Probability [9]

$$C(p, n) = \sum I\{L(x) \leq p \leq U(x)\} \binom{n}{x} p^x (1-p)^{n-x}$$

Expected Length [11]

$$EL(p, n) = \sum [U(x) - L(x)] \binom{n}{x} p^x (1-p)^{n-x}$$

Root Mean Square Error [15]

$$RMSE(n) = \left[\int_0^1 \{C(p, n) - (1 - \alpha)\}^2 dp \right]^{1/2}$$

3. Research Results and Discussion

3.1 Average Coverage Probability (ACP)

Tables 1–3 report ACP for 99%, 95%, and 90% confidence levels.

Table 1: Average Coverage Probability (ACP) at 99% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.800479	0.913508	0.940234	0.962556	0.970634
Wilson	0.987532	0.988831	0.989227	0.989529	0.989673
AC	0.999539	0.996973	0.995426	0.993578	0.992724
BCD	0.814311	0.907363	0.931973	0.956323	0.966186
Arcsine	0.997827	0.996732	0.996466	0.996256	0.996181
CS	0.991234	0.990942	0.990777	0.990546	0.990428

Table 1 presents the average coverage probability (ACP) of the competing confidence interval estimators for a nominal confidence level of 99% across different sample sizes. The Wald interval shows substantial undercoverage, particularly for small sample sizes such as n=10. In contrast, the Wilson, Agresti–Coull (AC), arcsine, and CS intervals maintain coverage probabilities close to the nominal level. The AC and arcsine intervals tend to produce slightly conservative coverage probabilities, whereas the Wilson and CS intervals remain closer to the nominal level. Overall, the results indicate that the simplified Wilson-type (CS) interval achieves stable coverage performance comparable to that of the Wilson interval.

Table 2: Average Coverage Probability (ACP) at 95% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.769186	0.874891	0.900594	0.922269	0.934568
Wilson	0.954112	0.952507	0.951659	0.950997	0.950775
AC	0.986880	0.971253	0.965363	0.959519	0.955655
BCD	0.793419	0.883945	0.906380	0.925689	0.936676
Arcsine	0.982944	0.978715	0.977798	0.977060	0.976071
CS	0.946901	0.948779	0.949452	0.950040	0.949763

Table 2 reports the average coverage probability (ACP) for the competing confidence intervals at the 95% nominal confidence level. Similar to the results observed at the 99% level, the Wald interval consistently undercovers, especially for smaller sample sizes. The Wilson interval maintains coverage probabilities very close to the nominal level across all sample sizes. The AC and arcsine intervals exhibit slightly

conservative coverage behavior, while the CS interval maintains coverage probabilities that are close to the nominal level and comparable to those of the Wilson interval. These results confirm the stability of the simplified Wilson-type interval for moderate confidence levels.

Table 3: Average Coverage Probability (ACP) at 90% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.735247	0.832057	0.855527	0.875103	0.882391
Wilson	0.910472	0.905391	0.903792	0.902161	0.901655
AC	0.955498	0.928770	0.920068	0.912049	0.908655
BCD	0.759482	0.843277	0.863131	0.879774	0.886139
Arcsine	0.958757	0.951607	0.950014	0.948834	0.948436
CS	0.844296	0.872034	0.880083	0.888767	0.891986

Table 3 shows the average coverage probability (ACP) for the competing interval estimators at the 90% nominal confidence level. The Wald interval continues to demonstrate noticeable undercoverage across all sample sizes. The Wilson interval provides coverage probabilities close to the nominal level, while the AC and arcsine intervals remain slightly conservative. The CS interval produces coverage probabilities that approach the nominal level as the sample size increases, indicating improved stability for larger samples. Overall, the results demonstrate that the CS interval provides competitive coverage performance relative to the Wilson interval.

3.2 Average Expected Length (ALE)

Tables 4–6 present AEL results.

Table 4: Average Expected Length (AEL) at 99% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.552438	0.348940	0.275230	0.197360	0.161911
Wilson	0.537132	0.346537	0.274650	0.197423	0.162032
AC	0.750810	0.404411	0.304446	0.209053	0.168630
BCD	0.560176	0.348886	0.274939	0.197292	0.161926
Arcsine	0.812778	0.468743	0.362990	0.256618	0.209512
CS	0.566016	0.352405	0.277187	0.198206	0.162419

Table 4 presents the average expected length (AEL) of the competing confidence interval estimators at the 99% nominal confidence level. In general, shorter intervals are preferred provided that the coverage probability remains close to the nominal level. The Wald interval tends to produce the shortest intervals; however, this occurs at the cost of substantial undercoverage, particularly for small sample sizes. Among the methods that maintain adequate coverage, the Wilson interval generally yields the shortest expected lengths. The CS interval produces interval lengths that are slightly larger than those of the Wilson interval but remain comparable to those of the Wilson and BCD intervals. By contrast, the AC and arcsine

intervals produce noticeably wider intervals due to their more conservative coverage behavior.

Table 5: Average Expected Length (AEL) at 95% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.405364	0.255098	0.201123	0.144154	0.102653
Wilson	0.414689	0.257479	0.202403	0.144696	0.102880
AC	0.539771	0.288977	0.218224	0.150724	0.105103
BCD	0.416067	0.257375	0.202249	0.144622	0.102836
Arcsine	0.609224	0.350222	0.271027	0.191500	0.135360
CS	0.411232	0.256705	0.202081	0.144610	0.102835

Table 5 reports the average expected length (AEL) for the competing interval estimators at the 95% nominal confidence level. Similar patterns are observed across the sample sizes considered. The Wald interval consistently produces the shortest intervals but suffers from poor coverage performance. The Wilson interval maintains relatively short interval lengths while preserving good coverage properties. The CS interval exhibits expected lengths that are very close to those of the Wilson interval, indicating competitive efficiency. In contrast, the AC and arcsine intervals produce larger expected lengths, reflecting their tendency to provide more conservative coverage probabilities.

Table 6: Average Expected Length (AEL) at 90% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.325620	0.203743	0.160383	0.114803	0.094132
Wilson	0.337760	0.206208	0.161592	0.115259	0.094385
AC	0.425205	0.227131	0.171903	0.119126	0.096528
BCD	0.334455	0.205714	0.161350	0.115191	0.094360
Arcsine	0.498696	0.285775	0.220990	0.156069	0.127377
CS	0.311810	0.200175	0.158682	0.114244	0.093846

Table 6 summarizes the average expected length (AEL) of the competing confidence intervals at the 90% nominal confidence level. As in the previous cases, the Wald interval yields the shortest expected lengths but does not maintain adequate coverage. The Wilson interval continues to produce relatively short intervals while maintaining coverage close to the nominal level. The CS interval achieves expected lengths that are comparable to those of the Wilson and BCD intervals across the sample sizes considered. The AC and arcsine intervals again exhibit larger expected lengths due to their conservative nature.

3.3 Root Mean Square Error (RMSE)

Tables 7–9 summarize RMSE results.

Table 7: Root Mean Square Error (RMSE) at 99% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.304473	0.179277	0.139567	0.099125	0.081147
Wilson	0.012091	0.007186	0.005602	0.004291	0.003476
AC	0.009548	0.007106	0.005691	0.004058	0.003288
BCD	0.309536	0.256240	0.222281	0.170426	0.142757
Arcsine	0.008072	0.007364	0.007250	0.007146	0.007150
CS	0.007044	0.005091	0.004129	0.003099	0.002620

Table 7 presents the root mean square error (RMSE) of the coverage probabilities for the competing confidence interval estimators at the 99% nominal confidence level. The RMSE summarizes the overall deviation of the empirical coverage probability from the nominal level across the parameter space. Smaller RMSE values indicate that the interval estimator maintains coverage probabilities closer to the target level. The results show that the Wilson and CS intervals achieve the smallest RMSE values among the competing methods, indicating stable coverage performance across different sample sizes. In contrast, the Wald and BCD intervals exhibit substantially larger RMSE values, reflecting their instability and tendency toward undercoverage in certain regions of the parameter space.

Table 8: Root Mean Square Error (RMSE) at 95% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.286347	0.168359	0.131062	0.093128	0.066199
Wilson	0.021697	0.014073	0.011820	0.008623	0.006275
AC	0.037577	0.024016	0.018947	0.013592	0.009857
BCD	0.304537	0.222978	0.182877	0.136330	0.099407
Arcsine	0.035848	0.032894	0.032706	0.032637	0.031433
CS	0.074526	0.050062	0.038911	0.023310	0.022566

Table 8 reports the root mean square error (RMSE) for the competing interval estimators at the 95% nominal confidence level. The Wilson interval consistently produces small RMSE values, reflecting its well-known stability in maintaining coverage probabilities close to the nominal level. The CS interval also achieves relatively small RMSE values across the sample sizes considered, demonstrating competitive performance relative to the Wilson interval. In contrast, the Wald and BCD intervals produce larger RMSE values, which indicates greater variability in coverage performance. These results further confirm that the simplified Wilson-type interval provides stable and reliable coverage behavior.

Table 9: Root Mean Square Error (RMSE) at 90% Nominal Level

Interval	n=10	n=30	n=50	n=100	n=150
Wald	0.265442	0.155332	0.120768	0.085775	0.070199
Wilson	0.036106	0.023438	0.020472	0.015326	0.012769
AC	0.060705	0.037538	0.029800	0.021973	0.017970
BCD	0.294339	0.200865	0.162274	0.119108	0.096673
Arcsine	0.066804	0.062021	0.061404	0.060998	0.060703
CS	0.212716	0.138007	0.112669	0.079409	0.065614

Table 9 summarizes the root mean square error (RMSE) of the competing confidence intervals at the 90% nominal confidence level. Similar patterns are observed as in the higher confidence levels. The Wilson interval maintains relatively small RMSE values, indicating stable coverage accuracy. The CS interval also demonstrates competitive RMSE values and shows improved stability as the sample size increases. By contrast, the Wald and BCD intervals continue to exhibit larger RMSE values, reflecting their less stable coverage performance across the parameter space.

3.4 Efficiency Comparison Between Wilson and CS Intervals

The Wilson interval typically produces slightly shorter expected lengths [5]. However, the CS interval maintains comparable coverage accuracy while offering a simpler closed-form formulation. Consequently, the proposed interval provides a useful balance between statistical efficiency and computational simplicity.

3.5 Overall Performance

Overall results indicate that the proposed CS interval provides competitive performance across coverage accuracy, interval length, and RMSE.

4. Conclusions

This study investigated a simplified Wilson-type confidence interval for estimating a binomial proportion. The proposed interval is obtained by approximating the Wilson score interval and incorporating a pseudo-count adjustment into the estimator of the binomial proportion. The resulting formulation has a simple closed-form expression that closely resembles the classical Wald interval while retaining the desirable stability properties associated with the Wilson approach.

The finite-sample performance of the proposed interval was evaluated through a comprehensive numerical study and compared with several widely used binomial confidence interval estimators, including the Wald, Wilson, Agresti–Coull, Brown–Cai–DasGupta, and arcsine intervals. The comparison was conducted using three performance criteria: average coverage probability, average expected length, and root mean square error across a range of sample sizes and nominal confidence levels.

The results indicate that the proposed simplified Wilson-type interval maintains coverage probabilities close to the

nominal level and produces interval lengths comparable to those of the best-performing existing methods. In particular, the Wilson interval often yields slightly shorter expected lengths, indicating a marginal advantage in terms of interval efficiency. Nevertheless, the proposed interval achieves comparable coverage accuracy and competitive interval lengths while offering a simpler computational form.

Overall, the proposed formulation provides a practical and reliable alternative for interval estimation of binomial proportions, particularly in applications where computational simplicity and stable finite-sample performance are desirable. The results also provide additional insight into the relationship between pseudo-count adjustments and the Wilson score framework.

The proposed interval can therefore be viewed as a simplified Wilson-type approximation that provides a practical balance between statistical accuracy and computational simplicity.

Future research may extend the proposed approach to other discrete distributions, such as Poisson or negative binomial models, and further investigate higher-order coverage properties and theoretical refinements of simplified score-based intervals.

5. References

- [1] Agresti A, Coull BA. Approximate is better than exact for interval estimation of binomial proportions. *Am Stat*. 1998;52(2):119–126.
- [2] Andersson PG. A note on confidence intervals for a binomial proportion. *Statistics*. 2024.
- [3] Anscombe FJ. The transformation of Poisson, binomial and negative-binomial data. *Biometrika*. 1948;35(3–4):246–254.
- [4] Bickel PJ, Doksum KA. *Mathematical statistics: basic ideas and selected topics*. Englewood Cliffs: Prentice Hall; 1977.
- [5] Brown LD, Cai TT, DasGupta A. Interval estimation for a binomial proportion. *Stat Sci*. 2001;16(2):101–133.
- [6] Brown LD, Cai TT, DasGupta A. Confidence intervals for a binomial proportion and asymptotic expansions. *Ann Stat*. 2002;30(1):160–201.
- [7] Cai TT. One-sided confidence intervals in discrete distributions. *J Stat Plan Inference*. 2005;131(1):63–88.
- [8] McGrath O, Burke K. Binomial confidence intervals for rare events. *Am Stat*. 2024;78(2):123–134.
- [9] Pires AM, Amado C. Interval estimators for a binomial proportion: comparison of nineteen methods. *Revstat Stat J*. 2008;6(2):165–197.
- [10] Stehman SV. Confidence intervals for proportion of area estimated from stratified sampling. *Remote Sens Environ*. 2022;278.
- [11] Tian L, Liu W, Xiong C. Interval estimation of the binomial proportion: a review and some new results. *Stat Methods Med Res*. 2016;25(5):2019–2036.
- [12] Wald A. Contributions to the theory of statistical estimation and testing hypotheses. *Ann Math Stat*. 1939;10(4):299–326.
- [13] Wilson EB. Probable inference, the law of succession, and statistical inference. *J Am Stat Assoc*. 1927;22(158):209–212.

[14] Zhang Z, Zhang H. New confidence intervals for binomial proportion based on refined normal approximation. *Commun Stat Simul Comput.* 2021;50(11):3482–3498.

[15] Zhou XH, Li CM, Yang Z. Improving interval estimation of binomial proportions. *Philos Trans R Soc A.* 2008;366(1874):2405–2418.

6. Appendices

Appendix A

Explicit formulas of competing confidence intervals.

Let $X \sim \text{Binomial}(n, p)$ denote the number of successes in n Bernoulli trials with success probability p . The sample proportion is defined as

$$\hat{p} = \frac{X}{n}.$$

Let $z_{1-\alpha/2}$ denote the upper $100(1 - \alpha/2)$ percentile of the standard normal distribution.

The following subsections summarize the explicit formulas of the competing confidence intervals used in the numerical comparison.

A.1 Wald Interval

The classical Wald confidence interval [5,12] is given by

$$CI_{\text{Wald}} = \hat{p} \pm z_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}.$$

This interval is derived from the normal approximation to the sampling distribution of the sample proportion. Despite its simplicity, it is well known that the Wald interval can exhibit substantial undercoverage when the sample size is small or when the true proportion is near the boundaries of the parameter space.

A.2 Wilson Interval (Score Interval)

The Wilson score interval [5,13] is defined as

$$CI_{\text{Wilson}} = \frac{\hat{p} + \frac{z^2}{2n} \pm z \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z^2}{4n^2}}}{1 + \frac{z^2}{n}},$$

where $z = z_{1-\alpha/2}$.

This interval is obtained by inverting the score test for the binomial parameter and is widely recommended due to its improved finite-sample coverage properties.

A.3 Agresti–Coull (AC) Interval

The Agresti–Coull interval introduces a pseudo-count adjustment to stabilize the estimator of the binomial proportion. Define the adjusted estimator

$$\tilde{p}_{AC} = \frac{X + 2}{n + 4}.$$

The Agresti–Coull interval [1] is then given by

$$CI_{AC} = \tilde{p}_{AC} \pm z_{1-\alpha/2} \sqrt{\frac{\tilde{p}_{AC}(1-\tilde{p}_{AC})}{n}}.$$

This interval represents a simple modification of the Wald interval that substantially improves coverage accuracy while maintaining computational simplicity.

A.4 Brown–Cai–DasGupta (BCD) Interval

The Brown–Cai–DasGupta interval corresponds to the equal-tailed Bayesian credible interval obtained under the Jeffreys prior $\text{Beta}(1/2, 1/2)$.

Let

$$L_{BCD} = B^{-1}\left(\frac{\alpha}{2}; X + \frac{1}{2}, n - X + \frac{1}{2}\right),$$

$$U_{BCD} = B^{-1}\left(1 - \frac{\alpha}{2}; X + \frac{1}{2}, n - X + \frac{1}{2}\right),$$

where $B^{-1}(q; a, b)$ denotes the q -quantile of the Beta distribution with parameters a and b .

The BCD interval [5] is therefore

$$CI_{BCD} = (L_{BCD}, U_{BCD}).$$

This interval is closely related to Bayesian inference under the Jeffreys prior and has been shown to possess desirable coverage properties in many settings.

A.5 Arcsine Transformation Interval

The arcsine interval is based on the variance-stabilizing transformation for the binomial distribution

$$\theta = \arcsin(\sqrt{p}).$$

An approximate confidence interval [3,4] for θ is given by

$$\arcsin(\sqrt{\hat{p}}) \pm \frac{z_{1-\alpha/2}}{2\sqrt{n}}.$$

Transforming back to the original scale yields the arcsine interval

$$CI_{\text{Arc}} = \left[\sin^2\left(\arcsin(\sqrt{\hat{p}}) - \frac{z_{1-\alpha/2}}{2\sqrt{n}}\right), \sin^2\left(\arcsin(\sqrt{\hat{p}}) + \frac{z_{1-\alpha/2}}{2\sqrt{n}}\right) \right].$$

This interval arises from the variance-stabilizing transformation for the binomial distribution and has historically been used to address boundary problems in binomial inference.

การวิเคราะห์เชิงเปรียบเทียบกลยุทธ์การลงทุนน้ำมันดิบผ่านการเรียนรู้ของเครื่อง

Comparative Analysis of Crude Oil Investment Strategies Using Machine Learning

บุญรัตน์ แสนสวัสดิ์* และ ชุพากรณ์ อารีพงษ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* S6504052520075@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนากลยุทธ์การลงทุนในสัญญาซื้อขายล่วงหน้าน้ำมันดิบ WTI โดยใช้เทคนิคการพยากรณ์ราคาด้วยปัญญาประดิษฐ์ แบบจำลองที่ใช้ประกอบด้วยการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression : MLR), ต้นไม้ตัดสินใจสำหรับการถดถอย (Regression Tree), โครงข่ายประสาทเทียม (Artificial Neural Network : NN), โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network : RNN) และเทคนิคการเรียนรู้แบบรวมกลุ่ม (Ensemble Stacking Model) โดยวิเคราะห์ร่วมกับปัจจัยพื้นฐาน ปัจจัยทางเทคนิค และการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis : PCA) เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ ผลการวิเคราะห์พบว่าแบบจำลอง MLR และ RNN มีค่าความคลาดเคลื่อน (MSE, MAE และ MAPE) ต่ำที่สุด สะท้อนถึงความแม่นยำสูงและไม่เกิดปัญหาการเรียนรู้เกิน (Overfitting) ขณะที่แบบจำลอง Regression Tree และ NN แม้จะจับรูปแบบข้อมูลที่ไม่เป็นเชิงเส้นได้ดี แต่มีความผันผวนและความเสี่ยงสูงกว่า สำหรับการสร้างกลยุทธ์การลงทุนเพื่อมุ่งเน้นค่า Sharpe Ratio สูงสุด พบว่าแบบจำลอง MLR มีความเหมาะสมมากที่สุดในด้านความเสถียรและความคุ้มค่าของผลตอบแทน โดยเมื่อกำหนดเกณฑ์จุดเข้าซื้อที่ 0.05 และจุดขายที่ 0.07 แบบจำลอง MLR ให้ค่า Sharpe Ratio สูงถึง 13.67 และผลตอบแทนเฉลี่ยร้อยละ 6.99 ในชุดทดสอบ ทั้งนี้ แม้แบบจำลอง RNN จะให้ค่า Sharpe Ratio ที่สูงกว่าในบางกรณี แต่ไม่สามารถสร้างผลตอบแทนรวมที่ดีที่สุดได้

คำสำคัญ: สัญญาซื้อขายล่วงหน้าน้ำมันดิบ, การเรียนรู้ของเครื่อง, กลยุทธ์การลงทุน

Abstract

This research aims to develop investment strategies for WTI crude oil futures using AI-based price forecasting techniques. The models employed include Multiple Linear Regression (MLR), Regression Tree, Artificial Neural Network (NN), Recurrent Neural Network (RNN), and Ensemble Stacking Model. The analysis incorporates fundamental factors, technical indicators, and Principal Component Analysis (PCA) to enhance forecasting efficiency. The results indicate that the MLR and RNN models achieved the lowest error rates (MSE, MAE and MAPE), reflecting high accuracy without overfitting. While the Regression Tree and NN models effectively captured non-linear data patterns, they exhibited higher volatility and risk. In terms of strategy development focused on maximizing the Sharpe Ratio, the MLR model proved most suitable for stability and cost-effective returns. By setting a Long entry threshold at 0.05 and a Short entry threshold at 0.07, the MLR model achieved a Sharpe Ratio of 13.67 and an average return of 6.99% in the test set. Notably, although the RNN model provided a higher Sharpe Ratio in certain cases, it could not generate the best overall returns.

Keywords: Crude Oil Futures, Machine Learning, Investment Strategy

1. บทนำ

บริษัทกรุงเทพ โปรตีนสัตว์จำกัด (มหาชน) ดำเนินภารกิจหลักในการจัดหาวัตถุดิบอาหารสัตว์เพื่อจำหน่ายให้แก่บริษัท เจริญโภคภัณฑ์อาหาร จำกัด (มหาชน) หรือ ซีพีเอฟ โดยมี

กลไกการจัดหาทั้งจากแหล่งผลิตภายในประเทศและต่างประเทศ อย่างไรก็ตาม ด้วยข้อจำกัดด้านปริมาณผลผลิตในประเทศที่ไม่เพียงพอต่อความต้องการภาคอุตสาหกรรม บริษัทจึงจำเป็นต้องนำเข้าวัตถุดิบจากต่างประเทศเป็นหลัก

โดยเฉพาะจากสหรัฐอเมริกา ซึ่งเป็นผู้ผลิตสินค้าเกษตรรายใหญ่ของโลกด้วยสัดส่วนการผลิตร้อยละ 30 ของผลผลิตรวมทั่วโลก และเป็นกลไกสำคัญที่ส่งผลกระทบต่อทิศทางราคาสินค้าเกษตรในตลาดโลก

ปัจจัยสำคัญที่มีผลต่อต้นทุนการดำเนินงานของบริษัทไม่ได้จำกัดอยู่เพียงราคาสินค้าเกษตรต้นทางเท่านั้น แต่ยังรวมถึงค่าขนส่งทางเรือซึ่งเป็นช่องทางหลักในการค้าระหว่างประเทศ โดยค่าขนส่งดังกล่าวมีความผันผวนสูงตามสภาวะราคาน้ำมันดิบซึ่งเป็นเชื้อเพลิงหลักในการเดินเรือ สำหรับการนำเข้าสินค้าจากสหรัฐอเมริกา สหรัฐอเมริการายได้กำไรจากราคาน้ำมันดิบ West Texas Intermediate (WTI) เป็นเกณฑ์อ้างอิงสำคัญ โดยจากการตรวจสอบค่าความสัมพันธ์ (Correlation) พบว่าราคาน้ำมันดิบ WTI มีความสัมพันธ์กับค่าระวางเรือ (Freight) จากภูมิภาค US Gulfมายัง Northeast Asia สูงถึงร้อยละ 70 ความผันผวนของราคาน้ำมันดิบ WTI จึงส่งผลกระทบต่อโดยตรงต่อต้นทุนรวมของสินค้าเกษตรอย่างมีนัยสำคัญ

จากผลกระทบดังกล่าว ภาคธุรกิจจึงจำเป็นต้องใช้เครื่องมือทางการเงิน เช่น สัญญาซื้อขายล่วงหน้าน้ำมันดิบ (WTI Crude Oil Futures) เพื่อบริหารจัดการความเสี่ยงและสะท้อนความคาดหวังของตลาดต่อทิศทางราคาน้ำมันในอนาคต โครงการนี้จึงมุ่งเน้นการพัฒนาแบบจำลองเพื่อพยากรณ์ราคาน้ำมันดิบในรอบระยะเวลา 1 สัปดาห์ ซึ่งถือเป็นช่วงเวลาที่เหมาะสมสำหรับการวางแผนต้นทุนและการตัดสินใจเชิงกลยุทธ์ เพื่อช่วยให้บริษัทสามารถบริหารจัดการความผันผวนของราคาต้นทุนได้อย่างมีประสิทธิภาพและสร้างความได้เปรียบทางการแข่งขันในระยะยาว

ในการพยากรณ์ราคาสัญญาซื้อขายล่วงหน้าน้ำมันดิบ WTI (West Texas Intermediate) ได้เก็บรวบรวมข้อมูลที่เกี่ยวข้องจากสำนักข่าวบลูมเบิร์ก (Bloomberg) ตั้งแต่ 1 มกราคม 2016 – 1 กันยายน 2025 เป็นระยะเวลาประมาณ 9 ปี 8 เดือน (3,531 วัน) ในด้านของวงจรเศรษฐกิจ ข้อมูลชุดนี้ครอบคลุมวัฏจักรเศรษฐกิจ (Economic Cycle) ที่สำคัญ ทั้งช่วงก่อนและหลังการระบาดของ COVID-19 รวมถึงความผันผวนทางภูมิรัฐศาสตร์ ซึ่งช่วยลดปัญหาการพยากรณ์ที่จำกัดเฉพาะบางสภาวะตลาด (Regime-specific)

การแบ่งชุดข้อมูลแบ่งเป็นชุดฝึกสอน (Training Set) ช่วงวันที่ 1 มกราคม 2016 – 31 ธันวาคม 2023 ภายในชุดฝึกสอนมีการแบ่ง Validation Set ในสัดส่วน 10% เพื่อใช้ในการปรับแต่งพารามิเตอร์ (Hyperparameter Tuning) ของแบบจำลอง AI และป้องกันการเกิดปัญหาการเรียนรู้เกิน (Overfitting) และชุดทดสอบ (Test Set) ช่วงวันที่ 1 มกราคม 2024 – 1 กันยายน 2025 สำหรับประเมินประสิทธิภาพของแบบจำลองและกลยุทธ์การลงทุนในสภาวะตลาดปัจจุบัน

2. ทฤษฎีและหลักการ

2.1 ปัจจัยพื้นฐาน (Fundamental Indicator)

ราคาน้ำมันดิบ West Texas Intermediate (WTI) มิได้เป็นเพียงตัวชี้วัดด้านพลังงานของสหรัฐอเมริกาเท่านั้น แต่ยังเป็นหนึ่งในเกณฑ์มาตรฐาน (Benchmark) ที่สำคัญที่สุดของโลก

การขับเคลื่อนของราคาเกิดขึ้นจากการตอบสนองของตลาดต่อข้อมูลอุบัติใหม่ที่เกี่ยวข้องกับภาวะอุปสงค์และอุปทานทั่วโลก ในยุคปัจจุบันที่ตลาดพลังงานมีความเชื่อมโยงกันอย่างซับซ้อนผ่านระบบการค้าและการผลิตระหว่างประเทศ การวิเคราะห์ปัจจัยพื้นฐานจึงต้องครอบคลุมมิติเชิงโครงสร้าง เศรษฐกิจ กำลังการผลิต และกลไกทางการเงิน ดังนี้

2.1.1 สภาวะเศรษฐกิจมหภาคและดัชนีชี้วัดทางเศรษฐกิจ เนื่องจากน้ำมันดิบ WTI มีแหล่งกำเนิดหลักในประเทศสหรัฐอเมริกา สภาพเศรษฐกิจของสหรัฐฯ จึงส่งผลกระทบต่อโดยตรงต่อราคาน้ำมันผ่านกลไกดังต่อไปนี้

2.1.1.1 ดัชนีราคาผู้บริโภค (CPI) เป็นตัวชี้วัดอัตราเงินเฟ้อที่สะท้อนกำลังซื้อและความต้องการบริโภคพลังงานในภาคครัวเรือน ขณะที่ผลิตภัณฑ์มวลรวมในประเทศ (GDP) สะท้อนภาพรวมกิจกรรมทางเศรษฐกิจ ซึ่งการเติบโตของ GDP มักนำไปสู่ความต้องการใช้น้ำมันที่เพิ่มขึ้นในภาคการผลิตและการขนส่ง

2.1.1.2 ดัชนีตลาดหลักทรัพย์ S&P 500 ใช้เป็นตัวแทนความเชื่อมั่นของนักลงทุนและทิศทางเศรษฐกิจโดยรวม ภาวะตลาดขาขึ้นมักสัมพันธ์กับความต้องการพลังงานที่ขยายตัว

2.1.1.3 การกำหนดอัตราดอกเบี้ยของธนาคารกลางสหรัฐฯ (Fed) ส่งผลโดยตรงต่อค่าเงินดอลลาร์สหรัฐฯ (USD) เนื่องจากการซื้อขายน้ำมันเกือบทั้งหมดใช้สกุลเงินดอลลาร์ การแข็งค่าของดอลลาร์จึงทำให้ต้นทุนการนำเข้าน้ำมันในสกุลเงินท้องถิ่นของประเทศอื่นสูงขึ้น ส่งผลกดดันต่ออุปสงค์ในตลาดโลก

2.1.1.4 อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐฯ (Treasury Yield): การวิเคราะห์ส่วนต่างระหว่างผลตอบแทนระยะสั้น (2 ปี) ระยะกลาง (5 ปี) และระยะยาว (10 ปี) ช่วยให้ตลาดคาดการณ์ภาวะเงินเฟ้อและทิศทางเศรษฐกิจในอนาคต ซึ่งมีความสัมพันธ์เชิงผกผันหรือเชิงบวกกับสินทรัพย์เสี่ยง รวมถึงน้ำมันดิบ

2.1.2 ปัจจัยด้านอุปสงค์และอุปทานในตลาดพลังงาน ความสมดุลระหว่างปริมาณน้ำมันในระบบกับความต้องการใช้จริงเป็นตัวกำหนดราคาพื้นฐาน ดังนี้

2.1.2.1 ราคาน้ำมันดิบ Brent เป็นมาตรฐานอ้างอิงระดับโลกและสะท้อนสถานการณ์ภูมิรัฐศาสตร์ในตะวันออกกลาง ส่วนต่างราคาระหว่าง WTI และ Brent จึงเป็นจุดพิจารณาสำคัญในการวิเคราะห์ความได้เปรียบเชิงการค้า

2.1.2.2 ปัจจัยภายในของสหรัฐฯ เช่น ปริมาณการผลิตน้ำมันดิบรายเดือน ระดับสต็อกน้ำมันดิบคงคลัง ณ สิ้นเดือน และอัตราการใช้ประโยชน์ของโรงกลั่น (Refinery Utilization Rate) เป็นข้อมูลที่ตลาดใช้ประเมินภาวะอุปทานส่วนเกินหรือส่วนขาดอย่างใกล้ชิด

2.1.3 ภูมิรัฐศาสตร์และโครงสร้างพื้นฐานการขนส่ง ศูนย์กลางสำรองน้ำมันและระบบขนส่งหลักที่ เมืองคุชชิง (Cushing) รัฐโอคลาโฮมา ถือเป็นจุดยุทธศาสตร์สำคัญของ

น้ำมันดิบ WTI โดยราคา ณ จุดขนส่งบนเรือ (FOB Cushing) เป็นดัชนีชี้วัดต้นทุนการส่งออกที่สำคัญ นอกจากนี้ ปัญหาภูมิรัฐศาสตร์ในเส้นทางขนส่งหลักยังเป็นปัจจัยที่เพิ่มความผันผวนให้กับราคาน้ำมันอย่างมีนัยสำคัญ

2.1.4 กลไกอัตราแลกเปลี่ยนและตลาดการค้าระหว่างประเทศ

เนื่องจากสหรัฐฯ ส่งออกน้ำมันดิบ WTI ไปยังประเทศคู่ค้าสำคัญ อาทิ เนเธอร์แลนด์ แคนาดา เกาหลีใต้ อินเดีย ญี่ปุ่น และจีน อัตราแลกเปลี่ยนระหว่างดอลลาร์สหรัฐกับสกุลเงินของประเทศผู้นำเข้าจึงมีผลต่อการตัดสินใจซื้อ โดยการวิเคราะห์ความสัมพันธ์ระหว่างสกุลเงินดอลลาร์ (USD) เทียบกับกลุ่มสกุลเงินหลักและสกุลเงินคู่ค้า (อาทิ EUR, CAD, KRW, INR, JPY, CNY รวมถึง THB) ช่วยให้เห็นภาพรวมของอำนาจซื้อในตลาดโลก หากสกุลเงินของคู่ค้าอ่อนค่าลงเมื่อเทียบกับดอลลาร์ จะทำให้ต้นทุนการนำเข้าน้ำมันดิบ WTI เพิ่มขึ้น แม้ราคาตลาดโลกจะคงที่ก็ตาม

2.2 ปัจจัยเทคนิค (Technical Indicator)

วิธีศึกษาพฤติกรรมของราคาหลักทรัพย์และแนวโน้มตลาดในอดีต โดยอาศัยข้อมูลเชิงสถิติ เช่น ระดับราคา และปริมาณการซื้อขาย เพื่อคาดการณ์ทิศทางราคาในอนาคต (Market Forecasting) *ตลาดหลักทรัพย์แห่งประเทศไทย (2558)* ระบุว่าทฤษฎีการวิเคราะห์ทางเทคนิคตั้งอยู่บนสมมติฐานที่ว่า ราคาสะท้อนทุกอย่างพื้นฐาน (Price Reflects Everything) และพฤติกรรมราคามักมีการเคลื่อนไหวซ้ำตามรูปแบบเดิมในอดีต

2.2.1 ปรัชญาและแนวคิดพื้นฐาน (Foundational Philosophy)

2.2.1.1 ราคาตลาดคือผลลัพธ์สุดท้ายของการประมวลข้อมูลทางเศรษฐกิจ การเมือง และจิตวิทยาอุปสงค์-อุปทาน นักวิเคราะห์ทางเทคนิคจึงให้ความสำคัญกับ ผลลัพธ์(ราคา) มากกว่าสาเหตุ

2.2.1.2 พฤติกรรมราคามักจะเคลื่อนที่ไปตามแนวโน้มหลัก ไม่ว่าจะขึ้นขาขึ้น (Uptrend) ขาลง (Downtrend) หรือด้านข้าง (Sideways) จนกว่าจะมีแรงผลักดันใหม่ที่ทำให้แนวโน้มเปลี่ยนทิศทาง

2.2.1.3 รูปแบบราคาในอดีตสะท้อนถึงจิตวิทยาของมนุษย์ เช่น ความกลัวและความโลภ ซึ่งเป็นปัจจัยคงที่ในตลาดทุน ส่งผลให้รูปแบบกราฟและพฤติกรรมราคาเกิดซ้ำเป็นวงจร

2.2.2 เครื่องมือและตัวชี้วัดทางเทคนิค (Technical Indicators)

2.2.2.1 Stochastic Indicator

ประเมินตำแหน่งสัมพันธ์ของราคาปิดเทียบกับกรอบราคาสูงสุด-ต่ำสุดในช่วงเวลาที่กำหนด (เช่น 14 วัน) เหมาะสำหรับตลาดที่มีสภาวะแกว่งตัวออกด้านข้าง (Sideways)

$$\%K = 100 \times \frac{C-L_N}{H_N-L_N} \quad (1)$$

โดย C คือ ราคาปิดในวันปัจจุบัน

H_N คือ ราคาสูงสุดในช่วง N วันที่ผ่านมา

L_N คือ ราคาต่ำสุดในช่วง N วันที่ผ่านมา

ภาวะซื้อมากเกินไป (Overbought > 80) และภาวะขายมากเกินไป (Oversold < 20) รวมถึงการตัดกันของเส้น $\%K$ และ $\%D$ ซึ่งเป็นค่า Moving Average ของ $\%K$ เพื่อหาจุดเปลี่ยนของแนวโน้ม

2.2.2.2 ตัวชี้วัดดัชนีความแข็งแกร่งสัมพัทธ์ (Relative Strength Index : RSI)

ดัชนีความแข็งแกร่งสัมพัทธ์ พัฒนาโดย J. Welles Wilder เพื่อวัดแรงส่ง (Momentum) ของราคา โดยจำกัดค่าอยู่ในช่วง 0 ถึง 100 ช่วยแก้ปัญหาความผันผวนของข้อมูลราคาที่ผิดปกติ

$$RSI = 100 - \frac{100}{(1+RS)} \quad (2)$$

$$RS = \frac{\text{ค่าเฉลี่ยของกำไร (Average Gain)}}{\text{ค่าเฉลี่ยของขาดทุน (Average Loss)}} \quad (3)$$

2.2.2.3 ตัวชี้วัดค่าเฉลี่ยเคลื่อนที่แบบบรรจบและแยกตัว (Moving Average Convergence Divergence : MACD)

เครื่องมือวิเคราะห์แนวโน้มและแรงส่ง เกิดจากการคำนวณส่วนต่างระหว่างค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล (EMA) สองช่วงเวลา (โดยทั่วไปคือ 7 และ 14 วัน)

$$MACD = EMA(14) - EMA(7) \quad (4)$$

2.2.2.4 ตัวชี้วัดอัตราการเปลี่ยนแปลง (Rate of Change : ROC)

ใช้วัดความเร็ว หรือ อัตราการเปลี่ยนแปลง ของราคา สัญญาซื้อขายล่วงหน้าในช่วงเวลาที่กำหนด เพื่อสะท้อนแรงโมเมนตัม (Momentum) ของตลาดในช่วงนั้น ๆ

$$ROC = \frac{P_t}{P_{t-n}} - 1 \quad (5)$$

โดย P_t คือ ราคาปัจจุบัน

P_{t-n} คือ ราคา n ช่วงเวลา

2.3 การเรียนรู้ของเครื่อง (Machine Learning: ML)

2.3.1 การลดมิติข้อมูลด้วยการวิเคราะห์องค์ประกอบหลัก (PCA)

เนื่องจากชุดข้อมูลนำเข้าประกอบด้วยตัวแปรจำนวนมากที่มีความสัมพันธ์กันสูง ผู้วิจัยได้นำเทคนิค Principal Component Analysis (PCA) มาใช้เพื่อลดมิติของข้อมูลจากตัวแปรต้นทั้งหมด 29 ตัวแปร โดยกำหนดเกณฑ์การคัดเลือกองค์ประกอบหลัก (Principal Components: PCs) ให้ครอบคลุมสัดส่วนความแปรปรวนสะสม (Cumulative Variance Explained) ที่ร้อยละ 85 เพื่อรักษาข้อมูลสำคัญส่วนใหญ่ไว้ในขณะที่สามารถลดสัญญาณรบกวน (Noise) ของข้อมูลได้ ซึ่งผลจากการวิเคราะห์พบว่าจำนวน PCs ที่ถูกคัดเลือกมาใช้งานมีจำนวน 5 องค์ประกอบ ผู้วิจัยตระหนักถึงความสำคัญของปัญหา Data Leakage จึงได้กำหนดขั้นตอนการดำเนินงานให้เป็นอิสระต่อกันระหว่างชุดข้อมูลฝึกสอนและชุดทดสอบในชุดฝึกสอน (Training Set) ดำเนินการคำนวณค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน (Fit) และหาพิกัดขององค์ประกอบหลัก (PCA Fit) เฉพาะจากข้อมูลฝึกสอนเท่านั้นในชุดทดสอบ (Test Set) นำ Parameter ที่ได้จากชุดฝึกสอน (Scalers และ PCA Components) มาประยุกต์ใช้ (Transform) กับข้อมูลชุดทดสอบโดยไม่มีกรคำนวณค่าใหม่จากข้อมูลชุดทดสอบ กระบวนการนี้ช่วยยืนยันได้ว่าข้อมูลจากอนาคตในชุดทดสอบจะไม่มีส่วนเกี่ยวข้องกับการสร้างแบบจำลองในขั้นตอนการเตรียมข้อมูล ทำให้ผลการประเมินประสิทธิภาพมีความแม่นยำและน่าเชื่อถือตามหลักการทางสถิติ

2.3.2 แบบจำลองการพยากรณ์ราคา

เลือกใช้แบบจำลอง 4 ประเภทหลัก และเทคนิคการเรียนรู้แบบรวมกลุ่ม ดังนี้

2.3.2.1 การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression: MLR) เป็นเทคนิคสถิติพื้นฐานที่ใช้หาความสัมพันธ์เชิงเส้นระหว่างตัวแปรตาม (Y) และตัวแปรอิสระ (X_n) ผ่านสมการ

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (6)$$

โดยใช้สถิติทดสอบ F-test และ t-test ในการคัดเลือกตัวแปรอิสระเข้าสู่แบบจำลองด้วยวิธี Stepwise Method เพื่อให้ได้แบบจำลองที่กระชับและมีนัยสำคัญที่สุด

2.3.2.2 ต้นไม้ตัดสินใจสำหรับการถดถอย (Regression Tree) เป็นเทคนิคการเรียนรู้ที่แบ่งข้อมูลออกเป็นส่วนย่อยๆ ตามเงื่อนไขในโหนดต่างๆ (Root, Internal, Leaf Nodes) โดยใช้เกณฑ์ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ในการตัดสินใจแบ่งข้อมูล (Splitting) เพื่อหาจุดที่สามารถพยากรณ์ค่าเชิงปริมาณได้แม่นยำที่สุด

2.3.2.3 โครงข่ายประสาทเทียม (Artificial Neural Networks: NN) แบบจำลองที่จำลองการทำงานของเซลล์ประสาทมนุษย์ ประกอบด้วย Input Layer, Hidden Layer และ Output Layer โดยใช้กระบวนการ Feed Forward ในการ

พยากรณ์ และ Backpropagation ในการปรับค่าถ่วงน้ำหนัก (Weights) ผ่านฟังก์ชันกระตุ้น (Activation Function) เช่น Sigmoid, ReLU และ Linear Function เพื่อจับความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้น (Nonlinear)

2.3.2.4 โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) เป็นโครงข่ายประสาทที่ออกแบบมาเพื่อจัดการกับข้อมูลลำดับเวลา (Time Series) โดยเฉพาะ โดยข้อมูลจากสถานะก่อนหน้า (Hidden State) จะถูกวนกลับมาเป็นข้อมูลนำเข้าร่วมกับข้อมูลปัจจุบัน ทำให้แบบจำลองมีความจำระยะสั้น (Memory) และสามารถเข้าใจบริบทเชิงลำดับเวลาได้ดีกว่าโครงข่ายประสาททั่วไป แบบจำลอง RNN ที่ใช้ในงานวิจัยนี้คือ Vanilla RNN (Simple RNN) โดยมีโครงสร้างและพารามิเตอร์ที่สำคัญประกอบด้วยชั้น SimpleRNN จำนวน 64 Units โดยเลือกใช้ Linear Activation Function เพื่อให้เหมาะสมกับการพยากรณ์ค่าต่อเนื่อง (Regression Task) ของราคาน้ำมัน เลือกใช้ Adam Optimizer ในการหาค่าที่เหมาะสมที่สุด (Optimization) และใช้ Mean Squared Error เป็นฟังก์ชันสูญเสีย (Loss Function) ผู้วิจัยได้ประยุกต์ใช้เทคนิค Early Stopping โดยกำหนดค่า Patience เท่ากับ 10 รอบการเรียนรู้ เพื่อหยุดกระบวนการฝึกสอนเมื่อแบบจำลองเริ่มมีการเรียนรู้ที่คงที่ในชุดข้อมูล Validation ทั้งนี้ได้มีการใช้ PCA เพื่อลดมิติข้อมูล โดยเลือกจำนวนองค์ประกอบหลักที่รักษาความแปรปรวนไว้ได้ร้อยละ 85 (85% Variance Explained) เพื่อลดสัญญาณรบกวน (Noise) ก่อนนำเข้าสู่แบบจำลอง

2.3.2.5 เทคนิคการเรียนรู้แบบรวมกลุ่ม (Ensemble Stacking Model) เพื่อลดข้อจำกัดของแบบจำลองเชิงเดี่ยว ผู้วิจัยได้ใช้เทคนิค Stacking Model ซึ่งเป็นการนำผลลัพธ์จากการพยากรณ์ของแบบจำลองฐาน (Base Models) หลายตัวมาทำหน้าที่เป็นคุณลักษณะใหม่ (Meta-Features) เพื่อป้อนเข้าสู่แบบจำลองในระดับที่สูงขึ้น (Meta-Model) ช่วยให้ระบบสามารถเรียนรู้จากจุดแข็งของแต่ละแบบจำลองและเพิ่มความแม่นยำในการทำนายผลลัพธ์สุดท้ายได้อย่างมีนัยสำคัญ

2.4 การวัดประสิทธิภาพแบบจำลอง (Model Performance)

ในการวิเคราะห์ประสิทธิภาพของแบบจำลองการพยากรณ์ราคาน้ำมันดิบ ผู้วิจัยได้เลือกใช้ตัวชี้วัดความคลาดเคลื่อนทางสถิติที่สำคัญเพื่อประเมินความแม่นยำและความเหมาะสมของแบบจำลองแต่ละประเภท ดังนี้

2.4.1 ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error : MSE)

ตัวชี้วัดที่ใช้ประเมินความแม่นยำของแบบจำลองโดยการหาค่าเฉลี่ยของส่วนต่างระหว่างค่าจริงและค่าที่พยากรณ์ได้ยกกำลังสอง ซึ่งมีคุณสมบัติในการขยายผลกระทบของความคลาดเคลื่อนที่รุนแรง (Outliers) ให้ชัดเจนยิ่งขึ้น

$$MSE = \sum_{i=1}^n \frac{y_i - \hat{y}_i}{n} \quad (7)$$

โดย n คือ ขนาดตัวอย่าง (Sample Size)

y_i คือ ค่าจริง (Actual)

\hat{y}_i คือ ค่าพยากรณ์ (Predict)

2.4.2 ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error : MAE)

วัดขนาดเฉลี่ยของความคลาดเคลื่อน โดยไม่คำนึงถึงทิศทาง (เครื่องหมายบวกหรือลบ) สะท้อนให้เห็นถึงระยะห่างเฉลี่ยระหว่างค่าพยากรณ์และค่าจริงได้อย่างตรงไปตรงมา

$$MAE = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{n} \quad (8)$$

โดย n คือ ขนาดตัวอย่าง (Sample Size)

y_i คือ ค่าจริง (Actual)

\hat{y}_i คือ ค่าพยากรณ์ (Predict)

2.4.3 ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error : MAPE)

ดัชนีวัดประสิทธิภาพในรูปแบบของร้อยละ ช่วยให้สามารถเปรียบเทียบความแม่นยำระหว่างชุดข้อมูลที่มีหน่วยหรือขนาดที่แตกต่างกันได้อย่างชัดเจน

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (9)$$

โดย n คือ ขนาดตัวอย่าง (Sample Size)

y_i คือ ค่าจริง (Actual)

\hat{y}_i คือ ค่าพยากรณ์ (Predict)

2.5 กลยุทธ์การลงทุน (Efficiency Measurement of Strategy)

2.5.1 กลยุทธ์การเข้าสถานะการลงทุน

แนวคิดหลักของกลยุทธ์มุ่งเน้นการใช้ผลการพยากรณ์ราคาน้ำมันดิบเพื่อกำหนดทิศทางการลงทุน โดยพิจารณาจากอัตราการเปลี่ยนแปลงที่คาดการณ์ (Predicted Percentage Change)

$$\%Change = \frac{\hat{P}_t - P_t}{P_t} \quad (10)$$

โดย \hat{P}_t คือ ราคาคาดการณ์ (Predicted Price)

P_t คือ ราคาปัจจุบัน (Current Price)

ในการตัดสินใจเข้าสถานะ ผู้วิจัยได้กำหนดเกณฑ์ขีดจำกัด (Threshold) เพื่อเป็นสัญญาณในการส่งคำสั่งซื้อขาย แบ่งออกเป็น 3 กรณีดังนี้

2.5.1.1 สถานะซื้อ (Long Position) จะดำเนินการเมื่อ $\%Change > \theta_L$ (โดย θ_L คือ Long Threshold) สะท้อนถึงแนวโน้มราคาขาขึ้น

2.5.1.2 สถานะขาย (Short Position) จะดำเนินการเมื่อ $\%Change < -\theta_S$ (โดย θ_S คือ Short Threshold) สะท้อนถึงแนวโน้มราคาขาลง

2.5.1.3 สถานะถือครองเงินสด (Hold Position) หากค่าความเปลี่ยนแปลงอยู่ระหว่าง $-\theta_S$ ถึง θ_L จะไม่มีการเปิดสถานะเนื่องจากสัญญาณทิศทางราคาไม่ชัดเจน

2.5.2 การวัดประสิทธิภาพกลยุทธ์การลงทุน (Efficiency Measurement of Strategy)

เพื่อให้มั่นใจว่ากลยุทธ์ที่พัฒนาขึ้นมีความเหมาะสมในเชิงปฏิบัติ ผู้วิจัยได้ใช้ตัวชี้วัดประสิทธิภาพการลงทุน 3 ด้านหลักดังนี้

2.5.2.1 ผลขาดทุนสูงสุด (Maximum Drawdown: MDD) ใช้เพื่อวัดความเสี่ยงในกรณีที่เลวร้ายที่สุด โดยคำนวณจากเปอร์เซ็นต์การลดลงของมูลค่าพอร์ตการลงทุนที่สูงที่สุดจากจุดสูงสุดก่อนหน้า

2.5.2.2 อัตราส่วนชาร์ป (Sharpe Ratio)

ตัวชี้วัดประสิทธิภาพการลงทุนเมื่อเทียบกับความเสี่ยง เพื่อประเมินว่าผลตอบแทนที่ได้รับคุ้มค่ากับความผันผวนที่เกิดขึ้นหรือไม่

$$Sharpe Ratio = \frac{R_x - R_f}{sd_x} \quad (11)$$

โดย R_x คือ ค่าคาดหวังของผลตอบแทนจากการลงทุน

R_f คือ ผลตอบแทนที่ไม่มีความเสี่ยง

sd_x คือ ส่วนเบี่ยงเบนมาตรฐานของผลตอบแทนจากการลงทุน

2.5.2.3 ผลตอบแทนเฉลี่ย (Average Total Return)

ใช้สะท้อนประสิทธิภาพของผลตอบแทนในภาพรวมตลอดช่วงระยะเวลาการลงทุน

$$\bar{R} = \frac{\sum_{i=1}^n R_i}{n} \quad (12)$$

โดย R คือ ผลตอบแทน

n คือ ระยะเวลาที่ลงทุน

โดยตัวแบบที่ให้ผลตอบแทนเฉลี่ย (Average Total Return) สูงที่สุด และอัตราส่วนชาร์ป (Sharpe Ratio) ที่สูงที่สุด จะถือว่าเป็นตัวแบบที่ดีที่สุด

3. ผลการดำเนินงาน

3.1 การเปรียบเทียบประสิทธิภาพความแม่นยำของแบบจำลอง

จากการนำข้อมูลชุดทดสอบ (Test Dataset) เข้าสู่แบบจำลองพยากรณ์ราคา พบว่าค่าความคลาดเคลื่อนทางสถิติมีรายละเอียดดังตารางที่ 1 และ 2

ตารางที่ 1: ค่าความคลาดเคลื่อนจากแบบจำลองพื้นฐาน

แบบจำลอง	MSE	MAE	MAPE
MRL	9.22	2.45	3.52
Regression Tree	58.37	6.40	9.09
NN	23.71	4.14	5.77
RNN	9.21	2.45	3.54

ตารางที่ 2: ค่าความคลาดเคลื่อนจากเทคนิคการเรียนรู้แบบรวมกลุ่ม

แบบจำลอง	MSE	MAE	MAPE
MRL	16.62	3.22	4.54
Regression Tree	16.29	3.28	4.47
NN	10.51	2.54	3.60
RNN	18.71	3.40	4.73

จากการวิเคราะห์พบว่า แบบจำลอง RNN และ MLR แสดงประสิทธิภาพในการพยากรณ์สูงที่สุด โดยมีค่าความคลาดเคลื่อนต่ำที่สุดและใกล้เคียงกันมาก สะท้อนถึงความสามารถในการพยากรณ์ที่มีความแม่นยำและเสถียรภาพสูง ในขณะที่แบบจำลอง Regression Tree ให้ค่าความคลาดเคลื่อนสูงที่สุด บ่งชี้ว่ามีความไวต่อการเปลี่ยนแปลงของข้อมูล (Variance) สูงเกินไปจนส่งผลต่อความแม่นยำ

3.2 การเปรียบเทียบประสิทธิภาพของกลยุทธ์การลงทุน

นำผลพยากรณ์มาสร้างกลยุทธ์การลงทุนโดยใช้ค่า Sharpe Ratio เป็นเกณฑ์หลักในการคัดเลือกจุดเข้าสถานะซื้อ (Long) และขาย (Short) ที่เหมาะสมที่สุดโดยเทียบประสิทธิภาพระหว่างกลยุทธ์การซื้อและถือครอง (Buy-and-Hold Benchmark) ดังตารางที่ 3 และผลการดำเนินงานในชุดข้อมูลทดสอบแสดงได้ดังตารางที่ 4 และ 5

ตารางที่ 3 : ประสิทธิภาพกลยุทธ์การซื้อและถือครอง (Buy-and-Hold Benchmark)

กลยุทธ์	MDD (%)	Sharpe Ratio	AVG Return (%)
Buy-and-Hold	-32.93	-18.71	-1.11

ตารางที่ 4 : ประสิทธิภาพกลยุทธ์การลงทุนจากแบบจำลองพื้นฐาน

แบบจำลอง	MDD (%)	Sharpe Ratio	AVG Return (%)
MLR	0.00	13.67	6.99
Regression Tree	-56.04	-0.28	-0.32
NN	-81.67	-1.72	-1.78
RNN	0.00	23.39	5.48
Buy and Hold	-32.93	-18.71	-1.11

ตารางที่ 5 : ประสิทธิภาพกลยุทธ์การลงทุนจากเทคนิคการเรียนรู้แบบรวมกลุ่ม

แบบจำลอง	MDD (%)	Sharpe Ratio	AVG Return (%)
MLR	0.00	-0.02	-0.05
Regression Tree	-42.71	1.08	1.20
NN	-81.67	-1.72	-1.78
RNN	-52.48	1.72	1.78

จากการทดสอบประสิทธิภาพของกลยุทธ์การลงทุนในชุดข้อมูลทดสอบ (1 มกราคม 2024 – 1 กันยายน 2025) พบว่าแบบจำลองการถดถอยเชิงเส้นพหุคูณ (MLR) และโครงข่ายประสาทเทียมแบบวนซ้ำ (RNN) แสดงผลการลดลงสูงสุดของเงินทุน (Maximum Drawdown: MDD) เท่ากับร้อยละ 0.00 ซึ่งสะท้อนถึงความแม่นยำในการพยากรณ์ทิศทางราคาปิดรายสัปดาห์ได้อย่างมีประสิทธิภาพในช่วงเวลาดังกล่าวความสำเร็จนี้เป็นผลมาจากการกำหนดเกณฑ์การตัดสินใจลงทุน (Threshold) ที่เข้มงวด ทำให้แบบจำลองเลือกสถานะถือครองเงินสด (Hold Position) ในสภาวะที่สัญญาณการพยากรณ์ไม่มีความชัดเจนเพียงพอ ส่งผลให้มูลค่าสินทรัพย์สุทธิ (NAV) ของพอร์ตการลงทุนไม่มีการลดลงจากจุดสูงสุดเดิม (High-water mark) เพื่อหลีกเลี่ยงความเสี่ยงจากการผันผวนของตลาด

เมื่อเปรียบเทียบประสิทธิภาพกับกลยุทธ์การซื้อและถือครอง (Buy-and-Hold Benchmark) ซึ่งเป็นเกณฑ์มาตรฐานสากล พบว่าในช่วงเวลาเดียวกันกลยุทธ์ Buy-and-Hold ประสบผลขาดทุนเฉลี่ยร้อยละ 1.11 และมีความเสี่ยงจากการลดลงสูงสุดของเงินทุน (MDD) ถึงร้อยละ 32.93 ขณะที่แบบจำลอง MLR สามารถสร้างผลตอบแทนเฉลี่ยได้สูงถึงร้อยละ 6.99 แสดงให้เห็นถึงความสามารถในการสร้างผลกำไรที่เหนือกว่าตลาดอย่างมีนัยสำคัญ แม้แบบจำลอง RNN จะมีค่า Sharpe Ratio ที่สูงกว่า (23.39) แต่ในแง่ของผลตอบแทนรวมและความเสถียรในการใช้งานจริงแบบจำลอง MLR ถือเป็นกลยุทธ์ที่เหมาะสมที่สุด

อย่างไรก็ตาม ผู้วิจัยตระหนักถึงข้อจำกัดว่าผลลัพธ์ดังกล่าวคำนวณจากราคาปิดรายสัปดาห์ ซึ่งอาจมิได้สะท้อนถึงความผันผวนระหว่างคาบ (Intra-period fluctuation) ได้ทั้งหมด นอกจากนี้ค่าสถิติที่โดดเด่นอาจได้รับอิทธิพลจากความลำเอียงของกลุ่มตัวอย่างในระยะสั้น (Sample Bias)

3.3 การนำแบบจำลองไปใช้งานและการพยากรณ์ในอนาคต

จากการประยุกต์ใช้แบบจำลองเพื่อพยากรณ์ราคาและกำหนดกลยุทธ์สำหรับสัปดาห์วันที่ 5 กันยายน 2025 โดยใช้ข้อมูลสะสม 87 สัปดาห์ ผลการพยากรณ์มีรายละเอียดดังตาราง 6 และ 7

ตารางที่ 6 : ราคาพยากรณ์และกลยุทธ์การเข้าสถานะ ณ วันที่ 5 กันยายน 2025 จากแบบจำลองพื้นฐาน

แบบจำลอง	ราคาปัจจุบัน (USD)	ราคาพยากรณ์ (USD)	กลยุทธ์ที่แนะนำ
MLR		64.31	ถือ (Hold)
Regression Tree	64.01	66.16	ซื้อ (Long)
NN		59.81	ขาย (Short)
RNN		65.92	ซื้อ (Long)

จากการวิเคราะห์เปรียบเทียบในทุกมิติแบบจำลองการถดถอยเชิงเส้นพหุคูณ (MLR) คือเครื่องมือที่เหมาะสมที่สุดในการบริหารจัดการความเสี่ยงและกำหนดกลยุทธ์การลงทุนใน

4. สรุปผลและข้อเสนอแนะ

4.1 สรุปผลการดำเนินงาน

ผลการศึกษาชี้ให้เห็นว่า แม้เทคนิค Ensemble Learning จะมีจุดเด่นในการลดความคลาดเคลื่อนในหลายบริบท แต่สำหรับข้อมูลราคาน้ำมันดิบที่มีความผันผวนสูงและมีขนาดตัวอย่างจำกัด แบบจำลองที่มีความซับซ้อนต่ำ (Parsimonious Model) อย่างการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression: MLR) กลับแสดงให้เห็นถึงความเสถียร (Robustness) และประสิทธิภาพที่เหนือกว่า ซึ่งสอดคล้องกับหลักการทางสถิติที่ว่าแบบจำลองที่มีความซับซ้อนมากเกินไป (Over-parameterization) อาจนำไปสู่การลดทอนประสิทธิภาพเมื่อนำไปใช้กับข้อมูลที่ไม่เคยพบเห็น (Unseen Data)

ด้วยเหตุนี้ MLR จึงเป็นเครื่องมือที่เหมาะสมที่สุดในการกำหนดกลยุทธ์การลงทุนในสัญญาซื้อขายล่วงหน้าน้ำมันดิบ WTI เนื่องจากสามารถสร้างผลตอบแทนต่อความเสี่ยง (Sharpe Ratio) ที่โดดเด่นและคงเส้นคงวาอย่างไรก็ตาม ผู้วิจัยยังได้นำเทคนิค Ensemble Stacking Model มาประยุกต์ใช้เพื่อเป็นทางเลือกในการลดความพึ่งพาแบบจำลองเดี่ยว (Model Specific Risk) และเป็นการเพิ่มมิติความหลากหลายของสัญญาณการลงทุนให้ครอบคลุมสภาวะตลาดที่แตกต่างกัน

4.2 ข้อเสนอแนะ

- (1) ควรศึกษาแบบจำลองเชิงเวลา (Time Series Models) เพิ่มเติมเพื่อเพิ่มความแม่นยำในระยะยาว
- (2) ควรเปรียบเทียบกลยุทธ์เชิงรุก (Active) และเชิงรับ (Passive) ในสภาวะตลาดที่ต่างกัน
- (3) ควรประยุกต์ใช้หลักการจัดพอร์ตเชิงปริมาณ เช่น Mean-Variance Optimization เพื่อกระจายความเสี่ยงอย่างเหมาะสม

สัญญาซื้อขายล่วงหน้าน้ำมันดิบ WTI เนื่องจากให้ผลตอบแทนที่คุ้มค่าภายใต้ระดับความเสี่ยงที่ต่ำที่สุด

ตารางที่ 7 : ราคาพยากรณ์และกลยุทธ์การเข้าสถานะ ณ วันที่ 5 กันยายน 2025 จากเทคนิคการเรียนรู้แบบรวมกลุ่ม

แบบจำลอง	ราคาปัจจุบัน (USD)	ราคาพยากรณ์ (USD)	กลยุทธ์ที่แนะนำ
MLR		68.12	ซื้อ (Long)
Regression Tree	64.01	59.23	ถือ (Hold)
NN		62.29	ขาย (Short)
RNN		67.95	ซื้อ (Long)

5. กิตติกรรมประกาศ

บทความฉบับนี้สำเร็จลงได้ด้วยด้วยความช่วยเหลือและสนับสนุนจากบุคคลหลายฝ่าย ผู้จัดทำขอกราบขอบพระคุณ ศ.ดร.ยุทธพร อารีพงษ์ และคุณชญาทิน บุญมานะ สำหรับคำชี้แนะ ความรู้ และประสบการณ์อันมีค่าในการตรวจทานและแก้ไขปัญหาดลอดการดำเนินงาน ขอพระคุณ คุณภาณุ ทองจันทร์ และทีมวิเคราะห์จากบริษัทกรุงเทพ โปรดิวิส ที่กรุณาให้อิโภาสและแบ่งปันข้อมูลเชิงลึกเกี่ยวกับปัจจัยราคาน้ำมันดิบ ซึ่งเป็นรากฐานสำคัญที่ทำให้แบบจำลองมีความแม่นยำและน่าเชื่อถือยิ่งขึ้น ท้ายที่สุดนี้ขอขอบคุณครอบครัวและเพื่อนร่วมงานทุกท่านสำหรับกำลังใจและการสนับสนุนที่เป็นแรงผลักดันสำคัญให้โครงการนี้บรรลุเป้าหมายที่ตั้งไว้ ผู้จัดทำหวังเป็นอย่างยิ่งว่าผลการศึกษานี้จะเป็นประโยชน์ต่อผู้ที่สนใจและวงการวิชาการในลำดับต่อไป

6. เอกสารอ้างอิง

- [1] Alquist, R., Kilian, L., & Vigfusson, R. J. (2013). *Forecasting the price of oil*. In G. Elliott & A. Timmermann (Eds.), *Handbook of Economic Forecasting* (Vol. 2A, pp. 427–507). Elsevier.
- [2] Kilian, L., & Park, C. (2009). *The impact of oil price shocks on the U.S. stock market*. *International Economic Review*, 50(4), 1267–1287.
- [3] Solibakke, P. B. (2020). *Forecasting WTI oil price volatility density using machine learning methods*. *Energy Economics*, 86, 104666.
- [4] Zhang, S., & Zohren, S. (2021). *A machine learning approach to volatility forecasting and trading strategy optimization*. *Quantitative Finance*, 21(8), 1271–1288.

การทำนายสัดส่วนสารให้สีสำหรับการผลิตลิปสติกด้วยการเรียนรู้ของเครื่อง

A Predictive Model of Colorant Proportions in Lipstick Manufacturing Using Machine Learning

ชญชนก รุ่งแก้ว และ สุนิสา ริมเจริญ *

คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา

(66910025@go.buu.ac.th; *rsunisa@buu.ac.th)

บทคัดย่อ

งานวิจัยนี้นำเสนอการใช้ขั้นตอนวิธีการเรียนรู้ของเครื่องเพื่อทำนายสูตรตั้งต้นของสารให้สี (Color Paste) สำหรับการผลิตลิปสติกให้ใกล้เคียงสีเป้าหมายที่ลูกค้าต้องการ เพื่อลดการลองผิดลองถูกในช่วงเริ่มต้นการพัฒนาสี โดยแทนสีเป้าหมายด้วยค่าสีอ้างอิงในระบบ RGB ทั้งนี้ค่าสีดังกล่าวเป็นค่าอ้างอิงเชิงข้อมูลสำหรับการทดลองในงานวิจัย ไม่ใช่ค่าสีที่วัดจากชิ้นงานจริงในห้องปฏิบัติการ วิธีดำเนินการประกอบด้วย 1) การสร้างแบบจำลองทำนายสีเพื่อเรียนรู้ความสัมพันธ์ระหว่างสัดส่วนสารให้สี และค่าสี RGB เป้าหมายโดยใช้การถดถอยแบบ ElasticNet แยกตามช่องสี R, G และ B และ 2) การหาสูตรตั้งต้นในการผลิตโดยแก้ปัญหาค่าเหมาะที่สุด (Optimization) เพื่อค้นหาสัดส่วนของสารให้สี ที่ทำให้ค่าสีที่ทำนายจากแบบจำลองทำนายสีใกล้เคียงสีเป้าหมายที่สุด ภายใต้ข้อจำกัดการผลิต ได้แก่ สัดส่วนสารให้สีไม่ติดลบ, ผลรวมสัดส่วนสารให้สีไม่เกิน 41% และจำนวนรายการสารให้สีที่ใช้จริงไม่เกิน 7 รายการ งานวิจัยนี้ทดลองกับข้อมูลสูตรภายในของโรงงานเครื่องสำอางแห่งหนึ่งจำนวน 146 สูตร แบ่งข้อมูลเป็นชุดฝึกสอนและชุดทดสอบด้วยการแบ่งตามเจดสี ชุดฝึกสอนประกอบด้วย 116 ตัวอย่าง และชุดทดสอบประกอบด้วย 30 ตัวอย่าง จากนั้นประเมินความคลาดเคลื่อนสีในระบบ RGB ด้วยค่าความผิดพลาดตามระยะทางยูคลิด (L2_RGB), ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE_RGB) และค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE_RGB) โดยสรุปผลด้วยสถิติเชิงพรรณนา ได้แก่ ค่าเฉลี่ย (Mean), ค่ามัธยฐาน (Median) และ เปอร์เซ็นไทล์ที่ 95 (P95) ผลการทดลองบนชุดทดสอบพบว่า Mean L2_RGB = 7.41×10^{-5} , P95 L2_RGB = 4.17×10^{-4} , Mean RMSE_RGB = 4.28×10^{-6} , Median RMSE_RGB = 2.85×10^{-6} และ Mean MAE_RGB = 2.47×10^{-5}

คำสำคัญ: ลิปสติก, สารให้สี, การเรียนรู้ของเครื่อง, การถดถอยแบบ ElasticNet, การหาค่าเหมาะที่สุด

Abstract

This paper presents the use of a machine learning-based approach to predict an initial formulation of color paste that is close to a target color for lipstick manufacturing, aiming to reduce early-stage trial-and-error in color formulation development. The colors used in the experiments are represented in the RGB color space rather than laboratory-based color measurements. The methodology consists of two steps: 1) developing a model to learn the relationship between color paste proportions and target RGB values using ElasticNet Regression trained separately for the R, G, and B channels, and 2) solving an optimization problem to identify color paste proportions that make the regression models predict color closest to the target color under manufacturing constraints: non-negativity, total color paste proportion not exceeding 41%, and at most seven color paste items per formulation. The experiments used 146 internal formulations from a cosmetics factory, with a training set of 116 samples and a test set of 30 samples. The color differences in the RGB color space are evaluated using Euclidean Distance (L2_RGB), Root Mean Squared Error (RMSE_RGB), and Mean Absolute Error (MAE_RGB), summarized with descriptive statistics, including the mean, median, and 95th percentile (P95). On the test set, the results are Mean L2_RGB = 7.41×10^{-5} , P95 L2_RGB = 4.17×10^{-4} , Mean RMSE_RGB = 4.28×10^{-6} , Median RMSE_RGB = 2.85×10^{-6} and Mean MAE_RGB = 2.47×10^{-5}

Keywords: Lipstick, Color Paste, Machine Learning, ElasticNet Regression, Optimization

1. บทนำ

อุตสาหกรรมความงามและเครื่องสำอางมีการเปลี่ยนแปลงอย่างรวดเร็วตามการแข่งขันทางการตลาดและความต้องการของผู้บริโภคที่ปรับตัวตลอดเวลา โดย Grand View Research (2025) รายงานว่าลิปสติกเป็นผลิตภัณฑ์ที่ได้รับความนิยมและมีความหลากหลายสูงทั้งในด้านเฉดสี ประเภทผลิตภัณฑ์ และรูปแบบการใช้งาน ทำให้การพัฒนาสูตรจำเป็นต้องอาศัยทั้งความรู้ด้านเคมีเครื่องสำอางและการควบคุมคุณภาพตัวอย่างละเอียด เพื่อให้ได้ผลิตภัณฑ์ตรงตามมาตรฐานของแบรนด์และสามารถตอบสนองต่อความต้องการของผู้บริโภคที่เปลี่ยนแปลงอย่างรวดเร็ว

ในทางปฏิบัติ Chiou (2021) อธิบายว่าการพัฒนาสูตรลิปสติกเพื่อให้ได้สีและคุณลักษณะที่ต้องการยังต้องอาศัยประสบการณ์ของนักพัฒนาสูตร และการทดลองปรับแก้สูตรหลายรอบ ส่งผลให้กระบวนการใช้เวลานาน มีต้นทุนสูง และสิ้นเปลืองทรัพยากร นอกจากนี้ การออกแบบสูตรยังต้องพิจารณาบทบาทและปฏิสัมพันธ์ของวัตถุดิบในสูตร ความคงตัวของสูตร ตลอดจนข้อจำกัดด้านเวลาและต้นทุนในการพัฒนา

ปัจจุบัน การใช้เทคโนโลยีใหม่ ๆ เช่น ปัญญาประดิษฐ์ (Artificial Intelligence) และการเรียนรู้ของเครื่อง (Machine Learning) เริ่มเข้ามามีบทบาทสำคัญในการเพิ่มประสิทธิภาพการพัฒนาและออกแบบสูตรเพื่อลดข้อจำกัดในการทำงานแบบดั้งเดิม เช่น Kamairudin และคณะ (2015) ประยุกต์ใช้โครงข่ายประสาทเทียม (Artificial Neural Networks) เพื่อสร้างแบบจำลองทำนายจุดหลอมเหลว (Melting Point) ของสูตรลิปสติกธรรมชาติจากองค์ประกอบของส่วนผสม รวมถึง Di Guardo และคณะ (2025) ที่รายงานการประยุกต์ใช้ปัญญาประดิษฐ์ในการทำนายคุณสมบัติที่สำคัญของผลิตภัณฑ์เครื่องสำอาง เช่น ความคงตัว เนื้อสัมผัส และประสิทธิภาพของสูตร ทั้งนี้ การนำเทคนิคเหล่านี้มาช่วยทำให้กระบวนการพัฒนาสูตรมีความแม่นยำ รวดเร็ว และลดการใช้ทรัพยากรจากการทดลองซ้ำได้อย่างมีประสิทธิภาพ

จากความท้าทายดังกล่าว การประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องสามารถช่วยเพิ่มประสิทธิภาพกระบวนการพัฒนาสีได้ โดยใช้ข้อมูลสูตรในอดีตเพื่อเรียนรู้ความสัมพันธ์ระหว่างสัดส่วนของสารให้สีและค่าสีในข้อมูลแล้วนำความสัมพันธ์ดังกล่าวไปใช้เสนอสูตรตั้งต้นที่มีแนวโน้มทำให้สีเข้าใกล้เป้าหมาย ลดการลองผิดลองถูก และทำให้การออกแบบสูตรมีความเป็นระบบยิ่งขึ้น งานวิจัยนี้จึงนำเสนอการใช้เทคนิคการเรียนรู้ของเครื่องเพื่อหาสูตรตั้งต้นของสารให้สีสำหรับลิปสติกให้ได้สีใกล้เคียงเป้าหมาย โดยใช้ค่าสีอ้างอิง RGB ที่แปลงจากแพนโทน (Pantone Number) เป็นตัวแทนสีเป้าหมาย ทั้งนี้ค่าดังกล่าวเป็นค่าอ้างอิงเชิงข้อมูลไม่ใช่ค่าที่วัดจากชิ้นงานจริงในห้องปฏิบัติการ และใช้เพื่อการประเมินผลภายในกรอบของแบบจำลองที่ศึกษา

Pantone LLC อธิบายว่าการใช้มาตรฐานสี เช่น แพนโทน จะช่วยให้การสื่อสารสีมีจุดอ้างอิงที่ชัดเจนขึ้น แต่ Kobayashi

และคณะ (2017) และ Mawazi และคณะ (2022) ซึ่งชี้ให้เห็นว่าการนำมาตรฐานดังกล่าวมาใช้กับสีของลิปสติกยังมีข้อจำกัดเนื่องจากผลลัพธ์และการรับรู้สีจริงไม่ได้ขึ้นอยู่กับรหัสสีเพียงอย่างเดียว แต่ยังได้รับอิทธิพลจากคุณสมบัติของผลิตภัณฑ์ เช่น ความเข้มของสี ความสามารถในการปกปิด และลักษณะของฟิล์มสีบนริมฝีปาก รวมถึงบริบทการรับรู้ของใบหน้า ส่งผลให้สีที่เห็นบนสื่อดิจิทัลหรือชิ้นงานอ้างอิงอาจแตกต่างจากสีที่ได้เมื่อผสมสูตรและใช้งานจริง

1.1 วัตถุประสงค์ของการวิจัย

1.1.1 เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่องสำหรับคาดการณ์สัดส่วนของสารให้สีในสูตรลิปสติกจากสีเป้าหมายเพื่อใช้เป็นแนวทางเบื้องต้นในการกำหนดสูตรตั้งต้น

1.1.2 เพื่อประเมินประสิทธิภาพของแบบจำลองและแนวทางที่พัฒนาขึ้น โดยวัดความคลาดเคลื่อนสีในระบบ RGB และตรวจสอบความเป็นไปได้ของสูตรตั้งต้นภายใต้ข้อจำกัดด้านกระบวนการผลิตที่กำหนด

1.2 ขอบเขตของงานวิจัย

1.2.1 ใช้เฉดสีของลิปสติก 4 กลุ่ม ได้แก่ สีแดง, สีชมพู, สีน้ำตาล และสีส้ม

1.2.2 ข้อจำกัดการผลิต ได้แก่ สัดส่วนของสารให้สีแต่ละรายการไม่ติดลบ ($p_i \geq 0$), ผลรวมสัดส่วนสารให้สีไม่เกิน 41% ต่อสูตร ($\sum p_i \leq 41$) และจำนวนรายการที่ใช้จริงไม่เกิน 7 ($\|p\|_0 \leq 7$)

2. วิธีการวิจัย

2.1 ข้อมูลและการเตรียมข้อมูล

ข้อมูลที่ใช้ในการทดลอง คือ ข้อมูลสูตรการผลิตลิปสติกจากโรงงานเครื่องสำอางแห่งหนึ่ง จัดเก็บในไฟล์ Excel โดย “แต่ละแถวแทนหนึ่งสูตร” ประกอบด้วย 1) ข้อมูลกำกับ ได้แก่ Product Code, Product Description, Color Shades และ Pantone Number 2) ค่าสี R, G, B ซึ่งแปลงจาก Pantone Number อ้างอิงจาก Pantone Connect ด้วยแนวทางเดียวกันทั้งชุดข้อมูล และ 3) สัดส่วนของสารให้สี คือส่วนผสมที่ทำหน้าที่ให้สีในสูตรลิปสติก โดยแทนค่าเป็นสัดส่วนเชิงปริมาณของสารให้สีแต่ละรายการในสูตร

งานวิจัยนี้คัดเลือกเฉพาะข้อมูลการผลิตลิปสติกกลุ่มเฉดสีหลัก 4 กลุ่ม ได้แก่ สีแดง, สีชมพู, สีน้ำตาล และสีส้ม ทำให้ชุดข้อมูลสำหรับการทดลองมี 146 สูตร แบ่งเป็นสีแดง 58 สูตร, สีชมพู 51 สูตร, สีน้ำตาล 29 สูตร และสีส้ม 8 สูตร โดยมีสารให้สีทั้งหมด 38 รายการ ทั้งนี้ รายการสารให้สีถูกเข้ารหัสหรือวางข้อมูลเป็นรหัส (เช่น Color Paste_1, Color Paste_2, ..., Color Paste_38) เพื่อรักษาความลับทางธุรกิจ สำหรับค่าว่างที่เกิดจาก “ไม่ได้ใช้สารให้สีรายการนั้น” กำหนดค่าเป็น 0 และตรวจสอบและลบข้อมูลซ้ำด้วยคีย์ร่วมเดียวกันก่อนเข้าสู่การสร้างแบบจำลอง ตัวอย่างข้อมูลที่ใช้ในการทดลองแสดงในตารางที่ 1

ตารางที่ 1: ตัวอย่างข้อมูลที่ใช้ในการทดลองแสดง

Code	Product Description	Color Shades	Pantone Number	R	G	B	Number of Color Paste	Color Paste_1	Color Paste_2	...
30027682	Product A	Red	202 C	134	38	51	4	-	0.49	...
30027203	Product B	Pink	696 C	152	72	87	6	3.04	1.03	...
30027221	Product C	Brown	1535 C	148	69	11	5	18.37	0.71	...

2.2 นิยามตัวแปร

ให้ $\mathbf{X} \in \mathbb{R}^{m \times n}$ แทน เมทริกซ์สัดส่วนสารให้สีของสูตรการผลิตที่ใช้เป็นชุดฝึกสอน (m สูตร, n สารให้สี)

ให้ $\mathbf{y} = [R, G, B]^T$ แทน ค่าสีในระบบ RGB ของสูตรที่ใช้เป็นชุดฝึกสอน

ให้ $\hat{\mathbf{y}} = [\hat{R}, \hat{G}, \hat{B}]^T$ แทน ค่าสีที่แบบจำลองทำนาย

ให้ $\mathbf{y}^* = [R^*, G^*, B^*]^T$ แทน สีเป้าหมายที่ใช้ทดสอบแบบจำลอง

ให้ $\mathbf{p} \in \mathbb{R}^{n \times 1}$ แทน เวกเตอร์สัดส่วนของสารให้สีที่ต้องหาในขั้นตอนการหาสูตรตั้งต้น

2.3 การแบ่งชุดข้อมูล

แบ่งชุดฝึกสอนและชุดทดสอบในอัตราส่วน 80:20 ด้วยการสุ่มแบ่งแบบชั้นภูมิ (Stratified Sampling) ตามตัวแปรเฉดสีเพื่อคงสัดส่วนแต่ละกลุ่มสีให้ใกล้เคียงเดิม ได้ชุดฝึกสอน 116 ตัวอย่าง และชุดทดสอบ 30 ตัวอย่าง

2.4 การสร้างสมการแสดงความสัมพันธ์ของสัดส่วนสารให้สีด้วย ElasticNet Regression

ขั้นตอนนี้เป็นการสร้างแบบจำลองเพื่อเรียนรู้ความสัมพันธ์ขององค์ประกอบหรือสัดส่วนของสารให้สีกับค่า RGB โดยประยุกต์ใช้ ElasticNet Regression จากไลบรารี Scikit-learn แยกตามช่องสี R, G และ B ก่อนการฝึกสอน มีการเตรียมข้อมูลให้สอดคล้องกับการถดถอยแบบทำให้เป็นปกติ (Regularization) โดยทำมาตรฐาน (Standardization) ตัวแปรอิสระด้วยพารามิเตอร์จากชุดฝึกสอนใช้พารามิเตอร์การแปลงเดียวกันกับชุดทดสอบ สำหรับการตั้งค่าพารามิเตอร์ของ ElasticNet งานวิจัยคัดเลือกจากการทดลองเปรียบเทียบหลายชุดค่าบนชุดฝึกสอน โดยพิจารณาจากค่าความคลาดเคลื่อนของการทำนายสีในระบบ RGB เพื่อให้ได้สมการเชิงเส้นที่เหมาะสมสำหรับนำไปใช้ต่อในขั้นตอนการหาสูตรตั้งต้น ดังสมการ (1)

$$\hat{\mathbf{y}} = \mathbf{c} + \mathbf{A}\mathbf{p} \quad (1)$$

เมื่อ $\mathbf{c} \in \mathbb{R}^{3 \times 1}$ คือ เวกเตอร์ค่าคงที่ (Intercept) และ $\mathbf{A} \in \mathbb{R}^{3 \times n}$ คือ เมทริกซ์สัมประสิทธิ์ (Coefficients) ของสารให้สี

2.5 การหาสูตรตั้งต้น

ขั้นตอนนี้เป็นการหาค่าเหมาะสมที่สุดเพื่อหา \mathbf{p} ที่ทำให้สีที่ทำนายเข้าใกล้สีเป้าหมายมากที่สุด ดังสมการ (2)

$$\mathbf{p}^* = \arg \min_{\mathbf{p} \in \mathcal{P}} \|\mathbf{c} + \mathbf{A}\mathbf{p} - \mathbf{y}^*\|_2^2 \quad (2)$$

ภายใต้เซตคำตอบที่เป็นไปได้ (Feasible Set) ดังสมการ (3)

$$\mathcal{P} = \left\{ \mathbf{p} \in \mathbb{R}^{n \times 1} \mid p_i \geq 0 \forall i, \sum_{i=1}^n p_i \leq 41, \|\mathbf{p}\|_0 \leq 7 \right\} \quad (3)$$

เนื่องจาก $\|\mathbf{p}\|_0 \leq 7$ เป็นข้อจำกัดเชิงโครงสร้าง งานวิจัยนี้ใช้แนวทางสองขั้นตอน ได้แก่

- 1) แก้ปัญหาการหาค่าเหมาะสมที่สุด ภายใต้ข้อจำกัด $p_i \geq 0$ และ $\sum p_i \leq 41$ เพื่อได้คำตอบเบื้องต้น $\mathbf{p}^{(0)}$
- 2) เลือกสารให้สีที่มีสัดส่วนสูงสุดไม่เกิน 7 รายการจาก $\mathbf{p}^{(0)}$ แล้วทำ Re-optimization เฉพาะชุดนั้น เพื่อให้ได้ $\mathbf{p}^{(\text{final})}$

2.6 การประเมินผล

งานวิจัยนี้วัดความคลาดเคลื่อนของผลลัพธ์จากการหาสูตรตั้งต้นเมื่อคำนวณค่าสีผ่านสมการสัดส่วนสารให้สีเทียบกับสีเป้าหมาย ดังสมการ (4)-(8) ทั้งนี้ การวัดผลเป็นการวัดจากค่าความผิดพลาดที่แบบจำลองทำนายเทียบกับข้อมูลเป้าหมายที่ใช้ทดสอบไม่ใช้การผสมสีและวัดค่าสีจริงในห้องปฏิบัติการ

ความคลาดเคลื่อนรายช่องสี (Per-channel Error)

$$\Delta R = \hat{R} - R^*, \Delta G = \hat{G} - G^*, \Delta B = \hat{B} - B^* \quad (4)$$

ค่าความคลาดเคลื่อนตามระยะทางยูคลิดในระบบ RGB (Euclidean Distance in RGB)

$$L2_{RGB} = \|\hat{\mathbf{y}} - \mathbf{y}^*\|_2 = \sqrt{(\Delta R)^2 + (\Delta G)^2 + (\Delta B)^2} \quad (5)$$

ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยในระบบ RGB (Root Mean Squared Error in RGB)

$$\text{RMSE}_{RGB} = \sqrt{\frac{(\Delta R)^2 + (\Delta G)^2 + (\Delta B)^2}{3}} \quad (6)$$

ค่าความผิดพลาดสูงสุดของแต่ละช่องสี (Maximum Channel Error)

$$\text{MaxChErr} = \max(|\Delta R|, |\Delta G|, |\Delta B|) \quad (7)$$

ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ยในระบบ RGB (Mean Absolute Error in RGB)

$$\text{MAE}_{RGB} = \frac{|\Delta R| + |\Delta G| + |\Delta B|}{3} \quad (8)$$

3. ผลการวิจัยและอภิปรายผล

3.1 ผลลัพธ์จาก ElasticNet Regression สร้างสมการแสดงความสัมพันธ์ระหว่างสัดส่วนสารให้สี

งานวิจัยนี้ใช้ ElasticNet Regression ในการแยกตามช่องสี R, G และ B และใช้ชุดพารามิเตอร์ที่คัดเลือกจากการทดลองเปรียบเทียบกับชุดฝึกสอนสำหรับแต่ละช่องสี ได้แก่ R: alpha = 1.0, l1_ratio = 0.9; G: alpha = 1.0, l1_ratio = 0.1; และ B: alpha = 1.0, l1_ratio = 0.7 โดยกำหนด max_iter = 5000 และ random_state = 42 ผลลัพธ์ของ ElasticNet Regression แต่ละช่องสีให้ค่าคงที่และสัมประสิทธิ์ ดังสมการ (9)-(11)

$$\hat{R} = 185.141202 + \sum_{i=1}^{38} A_{R,i} p_i \quad (9)$$

$$\hat{G} = 61.209912 + \sum_{i=1}^{38} A_{G,i} p_i \quad (10)$$

$$\hat{B} = 91.682908 + \sum_{i=1}^{38} A_{B,i} p_i \quad (11)$$

3.2 ผลลัพธ์การหาสูตรตั้งต้น


งานวิจัยนี้ ทดลองใช้วิธีการค่าเหมาะสมที่สุด 3 วิธี พบว่า 1) การถดถอยเชิงเส้นแบบไม่มีข้อจำกัด (Unconstrained Least Squares) ให้ค่าตอบที่ใกล้เคียงกับสีเป้าหมาย แต่เกิดสัดส่วนติดลบ ซึ่งไม่สอดคล้องกับข้อจำกัดการผลิต 2) การถดถอยเชิงเส้นที่มีข้อจำกัดขอบเขต (Bound-Constrained Least Squares) สามารถกำหนดช่วงของตัวแปรได้ แต่หากไม่กำหนดข้อจำกัดให้ผลรวมสัดส่วนไม่เกิน 41% ต่อสูตร ($\sum p_i \leq 41$) อาจทำให้ผลรวมเกินเพดานที่กำหนดไว้และ 3) การหาค่าเหมาะสมที่สุดภายใต้ข้อจำกัด (Constrained Optimization) โดยกำหนดข้อจำกัด $p_i \geq 0$ และ $\sum p_i \leq 41$ รองรับข้อจำกัดหลักได้ครบถ้วนจึงเลือกเป็นวิธีหลัก และเสริมด้วยแนวทางสองขั้นตอนเพื่อรองรับ $\|p\|_0$

ตัวอย่างการทำงานของกระบวนการหาสูตรตั้งต้นสำหรับสีเป้าหมายที่มีค่า RGB (100, 120, 80) $y^* = [100, 120, 80]^T$ ผลลัพธ์ได้สูตรตั้งต้นที่ใช้สารให้สีจริง 7 รายการ และผลรวมสัดส่วนเท่ากับ 39.89% (ตารางที่ 2)

ตารางที่ 2: สรุปผลตัวอย่างการหาสูตรตั้งต้นสำหรับสีเป้าหมายที่มีค่า RGB (100, 120, 80)

สารให้สี	สัดส่วนที่แนะนำ (%)
Color Paste_1	1.02
Color Paste_2	0.58
Color Paste_3	7.08
Color Paste_4	11.88
Color Paste_5	1.69
Color Paste_6	0.11
Color Paste_7	17.54
ผลรวมสัดส่วนสารให้สี	39.89

เมื่อนำไปคำนวณผ่านสมการสารให้สีที่ได้จาก ElasticNet Regression ได้ค่าสีที่ทำนาย $\hat{y} = \mathbf{c} + \mathbf{A}p$ ใกล้เคียงสีเป้าหมาย โดยมีความคลาดเคลื่อนรายช่องสี ($\Delta R, \Delta G, \Delta B$) ในระดับทศนิยมตำแหน่งที่ 4 (ภาพที่ 1) และเมื่อปัด \hat{y} เป็นจำนวนเต็ม ทำให้ได้ค่า RGB ตรงกับสีเป้าหมาย



ภาพที่ 1: ตัวอย่างการแสดงผลสีเป้าหมายเทียบกับสีที่คำนวณได้ และค่าความคลาดเคลื่อนรายช่องสี (R, G, B)

ตารางที่ 3 แสดงค่าความคลาดเคลื่อนของสีที่คำนวณจากสมการสารให้สีที่ได้จาก ElasticNet Regression เทียบกับสีเป้าหมาย พบว่า ตัวแบบมีความแม่นยำในการหาสูตรตั้งต้นโดยพิจารณาจากค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean MAE_RGB) ในชุดทดสอบที่มีค่าเพียง 0.000025 และค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Mean RMSE_RGB) เท่ากับ 0.000043 ซึ่งแสดงให้เห็นว่าความคลาดเคลื่อนของสีที่ทำนายได้อยู่ในระดับต่ำมาก และเมื่อพิจารณาค่าความคลาดเคลื่อนในเชิงปริภูมิสี (Color Space) ผ่านค่าเฉลี่ยความผิดพลาดตามระยะทางยูคลิด (Mean L2_RGB) พบว่า ในชุดทดสอบมีความต่างของสีที่ทำนายและสีเป้าหมายเพียง 0.000074 นอกจากนี้ เมื่อวิเคราะห์ความเสถียรของตัวแบบผ่านค่าเปอร์เซ็นไทล์ที่ 95 ของ L2_RGB (P95 L2_RGB) พบว่า มีค่าเท่ากับ 0.000417 ซึ่งเป็นการยืนยันว่าข้อมูลส่วนใหญ่ (ร้อยละ 95) มีความเพี้ยนของสีอยู่ในเกณฑ์ที่ต่ำมาก สะท้อนถึงประสิทธิภาพของตัวแบบ ElasticNet Regression ในการจัดการกับความสัมพันธ์ของตัวแปรสารให้สีได้อย่างมีประสิทธิภาพ

นอกจากนี้ จากผลการทดลองยังพบว่า ผลรวมสัดส่วนสารให้สีของชุดทดสอบมีค่าเฉลี่ย 25.37 และชุดฝึกสอนมีค่าเฉลี่ย 22.79 โดยค่าสูงสุดของชุดฝึกสอนเท่ากับ 41.00 ซึ่งไม่เกินข้อจำกัดที่กำหนดไว้

ตารางที่ 3: สรุปความคลาดเคลื่อนสีของผลการหาสูตรตั้งต้นแยกตามชุดฝึกสอนและชุดทดสอบ

ตัวชี้วัดประสิทธิภาพ	ชุดฝึกสอน	ชุดทดสอบ
Mean MAE_RGB	0.006501	0.000025
Mean RMSE_RGB	0.011260	0.000043
Median RMSE_RGB	0.000044	0.000003
Mean L2_RGB	0.019504	0.000074
Mean Max Channel Error	0.018019	0.000059
P95 RMSE_RGB	0.000375	0.000241
P95 L2_RGB	0.000650	0.000417

3.3 อภิปรายผล

ผลการทดลองแสดงให้เห็นว่าวิธีการที่งานวิจัยนำเสนอ สามารถให้สูตรตั้งต้นสอดคล้องตามข้อจำกัด และให้ความคลาดเคลื่อนสีในระบบ RGB อยู่ในระดับต่ำมาก ทั้งนี้ ในชุดฝึกสอนพบความแตกต่างระหว่างค่าเฉลี่ย (Mean) และค่ามัธยฐาน (Median) อย่างชัดเจน สะท้อนการแจกแจงแบบเบ้ไปทางขวา (Right-skewed Distribution) ซึ่งบ่งชี้ว่ามีบางกรณีที่มีความคลาดเคลื่อนสูงกว่าปกติ

ความเป็นไปได้หนึ่งคือสีเป้าหมายบางจุดอาจอยู่ใกล้ขอบหรืออยู่นอกบริเวณคำตอบที่เป็นไปได้ของปัญหา ภายใต้ข้อจำกัดร่วมกัน ได้แก่ จำนวนรายการสารให้สีไม่เกิน 7 รายการ และผลรวมสัดส่วนไม่เกิน 41% ต่อสูตร ส่งผลให้ขอบเขตคำตอบที่เป็นไปได้ภายใต้ข้อจำกัดดังกล่าวแคบลง และลดความยืดหยุ่นในการเข้าถึงสีบางเฉด หรือบางกรณีอาจมีสูตรที่ให้สีใกล้เคียงได้ แต่ต้องใช้รายการสารให้สีมากกว่า เพดานที่กำหนด จึงทำให้ค่าความคลาดเคลื่อนในบางตัวอย่างสูงขึ้นเมื่อบังคับข้อจำกัดดังกล่าว ทั้งนี้ ตัวชี้วัดที่รายงานเป็นการประเมินภายใต้สมการ ElasticNet Regression เดียวกัน จึงสะท้อนความสอดคล้องภายในกรอบแบบจำลอง และยังไม่ใช้การยืนยันความแม่นยำของสีจริงหลังการผสมและการวัดสีในห้องปฏิบัติการ

ผลการทดลองของงานวิจัยนี้แสดงให้เห็นว่าตัวแบบสามารถให้สูตรตั้งต้นที่สอดคล้องกับข้อจำกัดที่กำหนด และให้ค่าความคลาดเคลื่อนสีในระบบ RGB อยู่ในระดับต่ำมาก ซึ่งสอดคล้องกับแนวคิดของ Kamairudin และคณะ (2015) ที่แสดงให้เห็นว่าการใช้แบบจำลองเชิงข้อมูลสามารถสนับสนุนการออกแบบสูตรลิปสติกและลดการพึ่งพาการทดลองแบบลองผิดลองถูกได้ แม้ว่าจะงานดังกล่าวจะใช้โครงข่ายประสาทเทียมในการสร้างแบบจำลอง ขณะที่งานวิจัยนี้ใช้ ElasticNet Regression ซึ่งเป็นแบบจำลองเชิงเส้นที่ตีความได้ง่ายกว่า และเหมาะกับการนำไปสร้างสมการสำหรับขั้นตอนการหาสูตรตั้งต้น ขณะที่ผลของงานวิจัยนี้ยังสอดคล้องกับข้อสรุปของ Di Guardo และคณะ (2025) ที่รายงานว่าการประยุกต์ใช้ปัญญาประดิษฐ์สามารถช่วยทำนายคุณสมบัติสำคัญของสูตรและเพิ่มประสิทธิภาพของกระบวนการพัฒนาสูตรได้ งานวิจัยนี้แสดงให้เห็นเพิ่มเติมว่า แม้แบบจำลองจะให้ผลการทำนายที่ดีในภาพรวม แต่ยังคงอาจเกิดค่าความคลาดเคลื่อนสูงในบางกรณีเมื่อสีเป้าหมายอยู่ใกล้ขอบเขตของคำตอบที่เป็นไปได้ภายใต้ข้อจำกัดของสูตร ซึ่งสะท้อนว่าประสิทธิภาพของตัวแบบไม่ได้ขึ้นอยู่กับตัวแบบเพียงอย่างเดียว แต่ยังขึ้นกับขอบเขตของข้อมูลและเงื่อนไขข้อจำกัดที่กำหนดไว้ด้วย

4. สรุปผล

งานวิจัยนี้นำเสนอการใช้เทคนิคการเรียนรู้ของเครื่องเพื่อหาสูตรตั้งต้นของสารให้สี ซึ่งคือสัดส่วนขององค์ประกอบทางเคมีต่าง ๆ ที่เมื่อนำมาผสมกันแล้วทำให้ได้สีลิปสติกที่มีสี RGB ตามเป้าหมายที่ต้องการ โดยใช้ ElasticNet Regression และหาสัดส่วนการผสมของวัตถุดิบด้วยการหาค่าเหมาะสม

ที่สุดภายใต้ข้อจำกัดการผลิตจริง ($p_i \geq 0, \sum p_i \leq 41, \|\mathbf{p}\|_0 \leq 7$) ผลการทดลองจาก 146 สูตร แสดงว่าวิธีการที่นำเสนอสามารถสร้างสูตรที่อยู่ในกรอบข้อจำกัดและให้ความคลาดเคลื่อนสีใน RGB ต่ำมาก โดยมีค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean MAE_RGB) เท่ากับ 0.000025 และค่าเฉลี่ยรากที่สองของความคลาดเคลื่อนกำลังสอง (Mean RMSE_RGB) เท่ากับ 0.000043 ซึ่งแสดงให้เห็นว่าตัวแบบสามารถทำนายสีได้ใกล้เคียงกับสีเป้าหมายอย่างมากภายในกรอบแบบจำลอง วิธีการที่นำเสนอนี้เหมาะสำหรับเป็น “จุดเริ่มต้น” เพื่อลดรอบการลองผิดลองถูกในงานพัฒนาสี อย่างไรก็ตาม ในการนำไปใช้งานจริงอาจพิจารณาขยายงานในอนาคตไปสู่การประเมินด้วยการทดลองผสมและวัดสีจริงในห้องปฏิบัติการ

5. เอกสารอ้างอิง

- [1] Grand View Research. Lipstick market (2025-2030): size, share & trends analysis report by product (shimmer, matte, cream, long-wearing), by applicator (tube/stick, pencil, palette, liquid), by age (under 20, 20-30, 31-50, over 50), by distribution channel, by region, and segment forecasts [document on the Internet]. San Francisco (CA): Grand View Research; [cited 2026 Jan 28]. Available from: <https://www.grandviewresearch.com/industry-analysis/lipstick-market>.
- [2] Chiou C. Challenges in cosmetic formulation [document on the Internet]. New York: New York Society of Cosmetic Chemists; 2021 Jan 14 [cited 2026 Jan 28]. Available from: <https://nyscc.org/blog/challenges-in-cosmetic-formulation/>.
- [3] Kamairudin N, Abd Gani SS, Masoumi HRF, Basri M, Hashim P, Mokhtar NM, Lane ME. Modeling of a natural lipstick formulation using an artificial neural network. RSC Adv. 2015;5(84):68632-68638. doi:10.1039/C5RA12749A.
- [4] Di Guardo A, Trovato F, Cantisani C, Dattola A, Nisticò SP, Pellacani G, Pagani A. Artificial intelligence in cosmetic formulation: predictive modeling for safety, tolerability, and regulatory perspectives. Cosmetics. 2025;12(4):157. doi:10.3390/cosmetics12040157.
- [5] Pantone LLC. Pantone color systems explained [document on the Internet]. [cited 2026 Jan 28]. Available from: <https://www.pantone.com/color-systems/pantone-color-systems-explained>.
- [6] Kobayashi Y, Matsushita S, Morikawa K. Effects of lip color on perceived lightness of human facial skin. i-Perception. 2017;8(4):2041669517717500. doi:10.1177/2041669517717500.

- [7] Mawazi SM, Azreen Redzal NAB, Othman N, Alolayan SOS. Lipsticks history, formulations, and production: a narrative review. *Cosmetics*. 2022;9(1):25. doi:10.3390/cosmetics9010025.
- [8] Scikit-learn developers. scikit-learn: machine learning in Python [document on the Internet]. [cited 2026 Jan 28]. Available from: <https://scikit-learn.org/stable/index.html>.

การประยุกต์ใช้การเรียนรู้ของเครื่องในการพยากรณ์ความภักดีและการเลิกใช้บริการของ บริโภคสิ่งบ่งชี้ทางภูมิศาสตร์ (GI): กรณีศึกษาจังหวัดนครพนม

An Application of Machine Learning for Predicting Consumer Loyalty and Churn in GI Pineapple Products: A Case Study of Nakhon Phanom Province

ณัฐชนนทร์ แก้วนิวก์ และ สราวุธ ราชมนี *

สาขาวิชานวัตกรรมการตลาดและธุรกิจอัจฉริยะ คณะวิทยาการจัดการเทคโนโลยีสารสนเทศ มหาวิทยาลัยนครพนม

(*saravut@npu.ac.th)

บทคัดย่อ

สินค้าเกษตรที่ได้รับสิ่งบ่งชี้ทางภูมิศาสตร์ (Geographical Indication: GI) มีบทบาทสำคัญต่อการสร้างมูลค่าเพิ่ม ความเชื่อมั่น และอัตลักษณ์ของพื้นที่ อย่างไรก็ตาม การรักษาความภักดีของผู้บริโภคและการป้องกันการเลิกซื้อยังคงเป็นความท้าทายสำคัญ โดยเฉพาะในบริบทของสินค้าเกษตรชุมชน งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองพยากรณ์ความภักดีและการเลิกซื้อของผู้บริโภค โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องกับข้อมูลทวิตเตอร์จากสื่อสังคมออนไลน์ กรณีศึกษาสินค้าสับปะรด GI จังหวัดนครพนม

ข้อมูลถูกวิเคราะห์ผ่านตัวชี้วัดพฤติกรรมออนไลน์ ได้แก่ คะแนนความรู้สึกเชิงบวก (Sentiment Score) อัตราการมีส่วนร่วม (Engagement Rate) และความถี่การกล่าวถึงคุณภาพและ GI จากนั้นเปรียบเทียบประสิทธิภาพของแบบจำลอง Logistic Regression, Decision Tree และ Random Forest

ผลการวิจัยพบว่าแบบจำลอง Random Forest ให้ประสิทธิภาพสูงสุด โดยมีค่าความถูกต้อง (Accuracy) เท่ากับ 0.88 ค่า Precision 0.86 ค่า Recall 0.85 และค่า F1-score เท่ากับ 0.85 อีกทั้งยังแสดงความสามารถในการจำแนกกลุ่มผู้บริโภคที่มีความภักดีและกลุ่มที่มีแนวโน้มเลิกซื้อ ได้อย่างมีประสิทธิภาพ ซึ่งสะท้อนจากค่า AUC-ROC ที่อยู่ในระดับสูง (0.94) การวิเคราะห์ความสำคัญของตัวแปรชี้ให้เห็นว่าความรู้สึกเชิงบวกและการมีส่วนร่วมบนสื่อสังคมออนไลน์เป็นปัจจัยสำคัญที่สุดต่อความภักดีของผู้บริโภค ผลการศึกษานี้สะท้อนศักยภาพของการใช้ข้อมูลโซเชียลมีเดียร่วมกับการเรียนรู้ของเครื่องในการสนับสนุนการตัดสินใจด้านการตลาดสินค้าเกษตร GI อย่างยั่งยืน

คำสำคัญ: สิ่งบ่งชี้ทางภูมิศาสตร์, ความภักดีผู้บริโภค, การเรียนรู้ของเครื่อง, การวิเคราะห์ความรู้สึก, โซเชียลมีเดีย

Abstract

Geographical Indication (GI) agricultural products contribute significantly to local economic development by enhancing product differentiation, trust, and regional identity. However, maintaining consumer loyalty and preventing customer churn remain critical challenges, particularly for community-based agricultural products. This study aims to develop a predictive model for consumer loyalty and churn by applying machine learning techniques to social media data, using GI pineapple products from Nakhon Phanom Province, Thailand, as a case study.

Secondary data were collected from social media platforms and analyzed through sentiment analysis and engagement metrics to represent online consumer behavior. Key variables included Sentiment Score, Engagement Rate, and the frequency of mentions related to product quality and GI attributes. Three machine learning models—Logistic Regression, Decision Tree, and Random Forest—were constructed and compared in terms of predictive performance.

The results indicate that the Random Forest model achieved the highest predictive performance among the compared models, with an Accuracy of 0.88, Precision of 0.86, Recall of 0.85, and an F1-score of 0.85. The model also demonstrated strong discriminative capability in distinguishing loyal consumers from those at risk of churn, as reflected by a high area under the ROC curve (AUC = 0.94). Feature importance analysis further reveals that positive sentiment and online engagement are the most influential factors in predicting consumer loyalty toward GI pineapple products.

Keywords: Geographical Indication, Consumer Loyalty, Machine Learning, Sentiment Analysis, Social Media Data

1. บทนำ

ในปัจจุบัน การทำความเข้าใจพฤติกรรมผู้บริโภคและการรักษาความสัมพันธ์ระยะยาวกับลูกค้าเป็นประเด็นสำคัญในงานด้านการตลาดและเศรษฐกิจดิจิทัล โดยเฉพาะในบริบทของสินค้าเกษตรที่มีการแข่งขันสูง งานวิจัยของ Reichheld และ Sasser (1990) พบว่า ต้นทุนการหาลูกค้าใหม่สูงกว่าการรักษาลูกค้าเดิมถึง 5-7 เท่า ส่งผลให้ความภักดีของผู้บริโภคเป็นปัจจัยเชิงกลยุทธ์ที่ช่วยลดต้นทุนการตลาดและสร้างความได้เปรียบทางการแข่งขัน

แนวคิดของ Morgan และ Hunt (1994) และ Palmatier และคณะ (2006) เกี่ยวกับการตลาดเชิงความสัมพันธ์ (Relationship Marketing) อธิบายว่า ความไว้วางใจและความผูกพันระหว่างผู้บริโภคกับผู้ผลิตเป็นกลไกหลักที่นำไปสู่ความภักดีในระยะยาว ภายใต้บริบทที่ผู้บริโภคมีข้อมูลจำกัดเกี่ยวกับคุณภาพสินค้า ทฤษฎีสัญญาณ (Signaling Theory) ตามแนวคิดของ Spence (1973) และ Connelly และคณะ (2011) อธิบายว่า ข้อมูลหรือเครื่องหมายที่ผู้ผลิตส่งถึงผู้บริโภคทำหน้าที่เป็นสัญญาณที่ช่วยลดความไม่สมมาตรของข้อมูลระหว่างผู้ขายและผู้ซื้อ โดยสัญญาณที่น่าเชื่อถือสามารถเพิ่มการรับรู้คุณค่าและความเชื่อมั่นของผู้บริโภคได้ สำหรับสินค้าเกษตร สิ่งบ่งชี้ทางภูมิศาสตร์ (Geographical Indication: GI) ทำหน้าที่เป็นสัญญาณเชิงคุณภาพที่สะท้อนแหล่งที่มา อัตลักษณ์ และมาตรฐานการผลิต ดังที่ Verbeke และคณะ (2012) และ Teuber (2011) ได้อธิบายไว้ว่า GI มีส่วนสำคัญต่อการรับรู้คุณค่า และการตัดสินใจซื้อซ้ำของผู้บริโภค นอกจากนี้ Aprile และคณะ (2012) และ Belletti และคณะ (2017) ยังชี้ให้เห็นว่าผู้บริโภคให้ความสำคัญกับสินค้าที่ได้รับการรับรอง GI เนื่องจากสะท้อนถึงคุณภาพและความน่าเชื่อถือที่เชื่อมโยงกับแหล่งผลิต

สับปะรดสิ่งบ่งชี้ทางภูมิศาสตร์ (GI) จังหวัดนครพนมมีอัตลักษณ์เฉพาะที่แตกต่างจากสับปะรดในพื้นที่อื่น ทั้งในด้านลักษณะทางกายภาพและคุณภาพทางประสาทสัมผัส โดยมีเนื้อแน่น สีเหลืองทอง รสชาติหวานฉ่ำอมเปรี้ยวพอเหมาะ และมีกลิ่นหอมเฉพาะ ซึ่งเกิดจากสภาพภูมิอากาศ ดิน และวิถีการเพาะปลูกของชุมชนท้องถิ่น อัตลักษณ์ดังกล่าว ทำให้สับปะรด GI นครพนมไม่เพียงเป็นสินค้าเกษตรทั่วไป แต่เป็น “สินค้าที่มีเรื่องราว ของพื้นที่” (place-based product) ซึ่งสามารถสร้างคุณค่าเชิงสัญลักษณ์ (symbolic value) และความแตกต่างเชิงการแข่งขันได้อย่างชัดเจน

ภายใต้กรอบทฤษฎีการตลาดเชิงความสัมพันธ์ อัตลักษณ์ท้องถิ่นดังกล่าวมีบทบาทสำคัญ ในการสร้างความผูกพันทางอารมณ์ระหว่างผู้บริโภคกับสินค้า ขณะเดียวกัน ตราสัญลักษณ์ GI ยังทำหน้าที่ตามทฤษฎีสัญญาณในการลดความไม่สมมาตรของข้อมูลและเสริมสร้างความไว้วางใจ ในกระบวนการตัดสินใจซื้อซ้ำ อัตลักษณ์ GI จึงเป็นกลไกสำคัญของการสร้างคุณค่าและความภักดีในระยะยาว

ในยุคดิจิทัลที่ข้อมูลจากสื่อสังคมออนไลน์กลายเป็นแหล่งข้อมูลสำคัญสำหรับการวิเคราะห์ พฤติกรรมผู้บริโภค Kumar และ Shah (2021) และ Chen และ Xie (2021) ชี้ให้เห็น

ว่าความรู้สึกรีวิวเชิงบวกและระดับการมีส่วนร่วมบนสื่อสังคมออนไลน์มีความสัมพันธ์โดยตรงกับความภักดีของผู้บริโภค ข้อมูลเหล่านี้สามารถนำมาประยุกต์ใช้ร่วมกับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อพัฒนาระบบพยากรณ์พฤติกรรมผู้บริโภคที่มีประสิทธิภาพ

อย่างไรก็ตาม จากการทบทวนวรรณกรรมพบว่า ยังขาดงานวิจัยที่บูรณาการแนวคิดด้านการตลาดเชิงความสัมพันธ์ ทฤษฎีสัญญาณ และคุณค่า GI ร่วมกับเทคนิคการเรียนรู้ของเครื่อง โดยเฉพาะในบริบทสินค้าเกษตร GI ของไทย นอกจากนี้การใช้ข้อมูลโซเชียลมีเดียสำหรับสินค้าประเภท “ของฝากท้องถิ่น” ซึ่งมีลักษณะเฉพาะทั้งในด้านวัฒนธรรมและอัตลักษณ์ของพื้นที่ ยังไม่มีการศึกษาอย่างเป็นระบบ

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองพยากรณ์ความภักดีและการเลิกซื้อของผู้บริโภคสินค้าเกษตร GI ด้วยเทคนิค Random Forest บนข้อมูลจากสื่อสังคมออนไลน์ กรณีศึกษาสับปะรด GI จังหวัดนครพนม ผลการศึกษาคาดว่าจะอธิบายบทบาทของความรู้สึกร่วม และการรับรู้คุณค่า GI ต่อความภักดีของผู้บริโภค รวมทั้งสนับสนุนการประยุกต์ใช้วิทยาการข้อมูลในกลยุทธ์การตลาดสินค้าเกษตรท้องถิ่น ให้สอดคล้องกับบริบทเศรษฐกิจดิจิทัลและแนวทางการพัฒนาที่ยั่งยืน

2. วิธีการวิจัย

การวิจัยนี้เป็นการศึกษาเชิงปริมาณ มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์ความภักดีและการเลิกซื้อของผู้บริโภคสับปะรดที่ได้รับสิ่งบ่งชี้ทางภูมิศาสตร์ (GI) จังหวัดนครพนม โดยใช้เทคนิคการเรียนรู้ของเครื่อง

2.1 แหล่งข้อมูลและการรวบรวมข้อมูล

ข้อมูลที่ใช้เป็นข้อมูลทุติยภูมิจากสื่อสังคมออนไลน์ ซึ่งสะท้อนพฤติกรรมและความคิดเห็นของผู้บริโภคต่อสับปะรด GI ในบริบทสินค้าของฝากและสินค้าเกษตร เก็บรวบรวมย้อนหลัง 6 เดือน (กรกฎาคม–ธันวาคม พ.ศ. 2567) จากแหล่งข้อมูลสาธารณะ ได้แก่

- (1) Facebook (เพจและกลุ่มที่เกี่ยวข้อง)
- (2) TikTok (คำบรรยายและความคิดเห็นสาธารณะ)
- (3) Marketplace ได้แก่ Shopee และ Lazada (รีวิวสินค้า)

ข้อมูลดิบจำนวน 630 รายการ ถูกคัดกรองตามเกณฑ์ ได้แก่ ตัดข้อความที่ไม่เกี่ยวข้องกับสับปะรด GI นครพนม ตัดข้อความซ้ำซ้อน และตัดข้อความที่ไม่สามารถวิเคราะห์ความรู้สึกได้ คงเหลือข้อมูลสมบูรณ์สำหรับการวิเคราะห์จำนวน 420 รายการ

2.2 การประมวลผลข้อมูลและการวิเคราะห์ความรู้สึก

การวิเคราะห์ดำเนินการด้วยภาษา Python บนแพลตฟอร์ม Google Colab โดยใช้ไลบรารีมาตรฐาน ได้แก่ Pandas, Scikit-learn และ Matplotlib ข้อมูลข้อความผ่านกระบวนการทำความสะอาด ตัดคำภาษาไทยด้วย PyThaiNLP และวิเคราะห์ความรู้สึกแบบ Lexicon-based จากนั้นแปลงเป็นคุณลักษณะ

เชิงปริมาณ ได้แก่ คะแนนความรู้สึก (Sentiment Score) อัตราการมีส่วนร่วม (Engagement Rate) และความถี่การกล่าวถึงคำสำคัญ เช่น “คุณภาพ” และ “GI”

การวิเคราะห์ความรู้สึกด้วยแนวทาง Lexicon-based มีข้อจำกัดในการตีความข้อความที่มีลักษณะประชดประชัน (Sarcasm) คำแสดง หรืออารมณ์ผสม (Mixed sentiment) ซึ่งอาจส่งผลกระทบต่อความคลาดเคลื่อนในการจำแนกคลาสในบางกรณี ทั้งนี้ ข้อจำกัดดังกล่าวถูกนำไปพิจารณาในการอภิปรายผลและข้อเสนอแนะการวิจัยในอนาคต

2.3 การกำหนดตัวแปรเป้าหมาย

ในการศึกษานี้ ตัวแปรเป้าหมาย (Target Variable) ถูกกำหนดเป็นตัวแปรทวิภาค (Binary classification) เพื่อจำแนกผู้บริโภคออกเป็น 2 กลุ่ม ได้แก่ (1) ผู้บริโภคที่มีความภักดี (Loyalty) และ (2) ผู้บริโภคที่มีแนวโน้มเลิกซื้อ (Churn) โดยอาศัยการวิเคราะห์เนื้อหาข้อความและพฤติกรรมกรรมมีส่วนร่วมบนสื่อสังคมออนไลน์ ข้อความที่สะท้อนทัศนคติเชิงบวกอย่างต่อเนื่อง มีการมีส่วนร่วมสม่ำเสมอ และไม่ปรากฏสัญญาณเชิงลบที่บ่งชี้ความไม่พึงพอใจ จะถูกจัดให้อยู่ในกลุ่มผู้บริโภคที่มีความภักดี ในขณะที่ข้อความที่แสดงความไม่พึงพอใจ การร้องเรียน หรือการระบุเจตนาที่จะไม่ซื้อซ้ำ จะถูกจัดให้อยู่ในกลุ่มผู้บริโภคที่มีแนวโน้มเลิกซื้อ

จากการตรวจสอบสัดส่วนของข้อมูล พบว่ากลุ่มผู้บริโภคที่มีความภักดีมีจำนวน 231 รายการ (ร้อยละ 55) และกลุ่มที่มีแนวโน้มเลิกซื้อมีจำนวน 189 รายการ (ร้อยละ 45) ซึ่งถือว่าข้อมูลทั้งสองกลุ่มมีสัดส่วนใกล้เคียงกัน จึงไม่เข้าข่ายปัญหาการขาดความสมดุลของข้อมูล (Class imbalance) อย่างมีนัยสำคัญ

2.4 การพัฒนาแบบจำลอง

แบบจำลองที่ใช้ในการเปรียบเทียบประกอบด้วย Logistic Regression, Decision Tree และ Random Forest พัฒนาด้วยไลบรารี scikit-learn บนภาษา Python โดยมีการกำหนดค่าพารามิเตอร์ที่สำคัญดังนี้

Logistic Regression: max_iter=1000, solver='lbfgs', C=1.0, class_weight='balanced'

Decision Tree: max_depth=5, min_samples_split=10, min_samples_leaf=5, criterion='gini', random_state=42

Random Forest: n_estimators=100, max_depth=10, min_samples_split=5, min_samples_leaf=2, max_features='sqrt', bootstrap=True, random_state=42, n_jobs=-1

การเลือกค่าพารามิเตอร์ดังกล่าวได้จากการทดลองเบื้องต้น (preliminary experiment) ร่วมกับการอ้างอิงค่ามาตรฐานที่นิยมใช้ในงานวิจัยที่มีลักษณะข้อมูลใกล้เคียงกัน

2.5 การแบ่งข้อมูลและการประเมินประสิทธิภาพ

ข้อมูลจำนวน 420 รายการถูกแบ่งออกเป็นชุดฝึกสอน (Training set) ร้อยละ 70 จำนวน 294 รายการ และชุดทดสอบ (Test set) ร้อยละ 30 จำนวน 126 รายการ ด้วยวิธี stratified

random sampling เพื่อรักษาสัดส่วนของกลุ่มผู้บริโภคที่มีความภักดีและกลุ่มที่มีแนวโน้มเลิกซื้อให้ใกล้เคียงกันในทั้งสองชุดข้อมูล การประเมินประสิทธิภาพใช้ตัวชี้วัด Accuracy, Precision, Recall และ F1-score ร่วมกับการวิเคราะห์ Confusion Matrix

2.6 การตรวจสอบความเสถียรของแบบจำลอง

แม้ว่าการแบ่งข้อมูลแบบครั้งเดียว (single 70:30 split) จะสะท้อนสถานการณ์จริงที่แบบจำลองต้องพยากรณ์ข้อมูลใหม่ แต่ผลการประเมินอาจขึ้นอยู่กับการสุ่มแบ่งข้อมูลในแต่ละครั้ง (sampling variability) งานวิจัยนี้จึงเพิ่มการตรวจสอบความเสถียรด้วยเทคนิค 5-fold cross-validation เพื่อให้ข้อมูลทุกตัวอย่างได้ถูกทดสอบและลดความเอนเอียงจากการสุ่มแบ่งข้อมูล ซึ่งพบว่าค่าประสิทธิภาพจาก cross-validation (Accuracy เฉลี่ย 0.88 ± 0.03) สอดคล้องกับผลจากชุดทดสอบ (Accuracy 0.88) แสดงให้เห็นว่าแบบจำลองมีความเสถียรสูง

2.7 ข้อจำกัดและแนวทางพัฒนาในอนาคต

แม้ว่างานวิจัยนี้จะมุ่งเน้นคุณลักษณะด้านความรู้สึก การมีส่วนร่วม และการรับรู้คุณค่า GI เป็นหลัก อย่างไรก็ตาม ในบริบทของสินค้าเกษตรและสินค้าของฝาก ปัจจัยด้านราคามักมีบทบาทสำคัญต่อการตัดสินใจซื้อซ้ำและการเลิกซื้อของผู้บริโภค งานวิจัยในอนาคตจึงควรพิจารณาเพิ่มคุณลักษณะด้านความรู้สึกเกี่ยวกับราคา (Price Sentiment) หรือการรับรู้ความคุ้มค่า เพื่อเพิ่มความแม่นยำในการพยากรณ์พฤติกรรมเลิกซื้อ (Churn)

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการวิจัย

3.1.1 สถิติเชิงพรรณนาของข้อมูล

ชุดข้อมูลที่ใช้ในการวิเคราะห์ขั้นสุดท้ายประกอบด้วย 420 รายการ ซึ่งได้จากสื่อสังคมออนไลน์เกี่ยวกับสับปะรด GI จังหวัดนครพนม ในบริบทสินค้าเกษตรและของฝาก ข้อมูลดังกล่าวผ่านการคัดกรองและทำความสะอาดแล้วเพื่อให้มีความสมบูรณ์และเหมาะสมต่อการวิเคราะห์เชิงปริมาณ

ตารางที่ 1: สถิติเชิงพรรณนาของคุณลักษณะจากข้อมูลโซเชียลมีเดีย (n = 420)

คุณลักษณะ (Feature)	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน
Sentiment Score	0.62	0.27
Engagement Rate	3.80	1.95
ความถี่คำว่า “คุณภาพ” (รายการ/ครั้ง)	1.45	1.20
ความถี่คำว่า “GI” / “สิ่งบ่งชี้ทางภูมิศาสตร์”	0.72	0.90
ความถี่การโพสต์ต่อเดือน	1.05	0.70

จากตารางที่ 1 พบว่าผู้บริโภคมักจะแสดงความรู้สึกเชิงบวกเฉลี่ยเท่ากับ 0.62 (จากช่วงคะแนน -1 ถึง 1) ซึ่งสะท้อนถึงทัศนคติเชิงบวกต่อสัปดาห์ GI จังหวัดนครพนม

ค่า Engagement Rate มีค่าเฉลี่ยเท่ากับ 3.80 และส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1.95 เมื่อพิจารณาจากค่าพิสัยของข้อมูล (ค่าต่ำสุด 0.25 สูงสุด 8.50) ค่าเฉลี่ย 3.80 อยู่ในช่วงควอไทล์ที่ 2 ถึงควอไทล์ที่ 3 (Q2 = 2.80, Q3 = 5.20) ซึ่งจัดเป็นระดับปานกลาง เมื่อเทียบกับการกระจายตัวของข้อมูล (mean \pm 1SD = 1.85 - 5.75)

3.1.2 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง

แบบจำลองทั้งสามถูกพัฒนาและประเมินผลบนแพลตฟอร์ม Google Colab โดยใช้ชุดข้อมูลทดสอบร้อยละ 30 ของข้อมูลทั้งหมด จำนวน 126 รายการ

ตารางที่ 2: ผลการประเมินประสิทธิภาพของแบบจำลอง

แบบจำลอง	Accuracy	Precision	Recall	F1-score
Logistic Regression	0.76	0.74	0.71	0.72
Decision Tree	0.80	0.78	0.77	0.77
Random Forest	0.88	0.86	0.85	0.85

หมายเหตุ: ค่าประสิทธิภาพของแบบจำลอง Random Forest ที่รายงานในตารางเป็นค่าเฉลี่ย จากกระบวนการ 5-fold cross-validation (Accuracy เฉลี่ย = 0.88, SD = \pm 0.03) เพื่อแสดงความเสถียรของแบบจำลอง ในขณะที่ Logistic Regression และ Decision Tree

รายงานผลจากการทดสอบบนชุดทดสอบ (test set) จำนวน 126 รายการ ทั้งนี้ การวิเคราะห์ Confusion Matrix ในตารางที่ 3 เป็นผลจากการทดสอบบนชุดทดสอบเดียวกันนี้ ซึ่งให้ค่า Accuracy = 0.88 (111/126) สอดคล้องกับผลจาก Cross-validation

ผลการวิเคราะห์พบว่าแบบจำลอง Random Forest ให้ค่าประสิทธิภาพสูงสุดในทุกตัวชี้วัด แสดงถึงความสามารถในการจับความสัมพันธ์ที่ไม่เป็นเชิงเส้นของข้อมูลพฤติกรรมผู้บริโภคจากโซเชียลมีเดียได้ดีกว่าแบบจำลองอื่น อีกทั้งยังมีความเสถียรสูงดังจะเห็นได้จากค่า Accuracy ที่สอดคล้องกันทั้งจากการประเมินแบบ Cross-validation และการทดสอบกับชุดข้อมูลทดสอบ

3.1.3 Confusion Matrix ของแบบจำลอง Random Forest

แบบจำลอง Random Forest พัฒนารับเข้าถูกนำมาทดสอบกับชุดข้อมูลทดสอบจำนวน 126 รายการ ซึ่งแบ่งเป็นกลุ่มผู้บริโภคที่มีความภักดี 69 รายการ และกลุ่มที่มีแนวโน้มเลิกซื้อ 57 รายการ ผลการจำแนกแสดงในตารางที่ 3

ตารางที่ 3: Confusion Matrix ของแบบจำลอง Random Forest บนชุดทดสอบ (n = 126)

แบบจำลอง	ทำนายไม่เลิกซื้อ	ทำนายเลิกซื้อ	รวม
ทำนายไม่เลิกซื้อ	60	9	69
ทำนายเลิกซื้อ	6	51	57
รวม	66	60	126

จากตารางที่ 3 พบว่าแบบจำลอง Random Forest สามารถทำนายข้อมูลทดสอบจำนวน 126 รายการ

ได้ถูกต้อง 111 รายการ (ร้อยละ 88.1) และทำนายผิดพลาด 15 รายการ (ร้อยละ 11.9)

โดยแบ่งเป็น:


- ทำนายผิดพลาดแบบ Type I (False Positive) จำนวน 9 รายการ
- ทำนายผิดพลาดแบบ Type II (False Negative) จำนวน 6 รายการ

เมื่อพิจารณาความแม่นยำในการจำแนกแต่ละคลาส พบว่า:

- กลุ่มผู้บริโภคที่มีความภักดี มีความถูกต้องในการทำนายร้อยละ 87.0 (60 จาก 69 รายการ)
- กลุ่มผู้บริโภคที่มีแนวโน้มเลิกซื้อ มีความถูกต้องในการทำนายร้อยละ 89.5 (51 จาก 57 รายการ)

3.1.4 การประเมินประสิทธิภาพด้วย AUC-ROC Curve

ผลการวิเคราะห์ด้วยค่า Area Under the Receiver Operating Characteristic Curve (AUC-ROC) พบว่า แบบจำลอง Random Forest มีค่า AUC เท่ากับ 0.94 ซึ่งจัดอยู่ในระดับสูงมาก (โดยทั่วไปค่า AUC > 0.90 ถือว่ามีความแม่นยำสูงในการจำแนก) สะท้อนว่าแบบจำลองสามารถ แยกแยะผู้บริโภคกลุ่มที่มีความภักดีและกลุ่มที่มีแนวโน้มเลิกซื้อได้ดีเยี่ยม




รูปที่ 1: เส้นโค้ง ROC ของแบบจำลอง Random Forest

3.1.5 การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance)

ตารางที่ 4: ค่าความสำคัญของตัวแปรจากแบบจำลอง Random Forest

ลำดับ	ตัวแปร (จากโซเชียลมีเดีย)	ค่าความสำคัญ
1	Sentiment Score	0.30
2	Engagement Rate	0.24
3	ความถี่การกล่าวถึง "คุณภาพ"	0.19
4	ความถี่การกล่าวถึง "GI"	0.14
5	ความถี่การโพสต์ต่อเดือน	0.13

จากตารางที่ 4 ผลการวิเคราะห์ยืนยันว่า ความรู้สึกรับรู้เชิงบวก (Sentiment Score) และการมีส่วนร่วมของผู้บริโภคบนสื่อสังคมออนไลน์ (Engagement Rate) เป็นปัจจัยสำคัญที่สุดในการพยากรณ์ความภักดีต่อสินค้า GI โดยมีค่าความสำคัญรวมกันถึงร้อยละ 54 ของความสำคัญทั้งหมด ขณะที่การกล่าวถึงคุณภาพและ GI มีบทบาทรองลงมา แต่ยังคงมีความสำคัญในการสะท้อนการรับรู้คุณค่าเชิงอัตลักษณ์ของสินค้าเกษตร GI



รูปที่ 2: ความสำคัญของตัวแปรจากแบบจำลอง Random Forest

3.2 อภิปรายผล

3.2.1 อภิปรายผลเชิงทฤษฎี

ผลการวิจัยที่พบว่าแบบจำลอง Random Forest สามารถพยากรณ์ความภักดีและการเลิกซื้อของผู้บริโภคสัปดาห์ละครั้ง GI จังหวัดนครพนมได้อย่างมีประสิทธิภาพ สอดคล้องกับแนวคิดของทฤษฎีการตลาดเชิงความสัมพันธ์ (Relationship Marketing Theory) ตามที่ Morgan และ Hunt (1994) และ Palmatier และคณะ (2006) อธิบายว่าความภักดีของผู้บริโภคเกิดจากการสะสมประสบการณ์เชิงบวก ความไว้วางใจ และความผูกพันที่เกิดจากการมีปฏิสัมพันธ์อย่างต่อเนื่องระหว่างผู้บริโภคกับสินค้าและผู้ผลิต ผลการวิเคราะห์ความสำคัญของตัวแปรที่พบว่า Sentiment Score และ Engagement Rate เป็น

ปัจจัยหลัก สะท้อนให้เห็นว่าทัศนคติเชิงบวกและการมีส่วนร่วมบนสื่อสังคมออนไลน์ทำหน้าที่เป็นกลไกสำคัญในการเสริมสร้างความสัมพันธ์เชิงคุณค่าระยะยาว ซึ่งสอดคล้องกับงานวิจัยของ Kumar และ Shah (2021) ที่ชี้ให้เห็นว่าการมีส่วนร่วมในโลกดิจิทัลเป็นหัวใจสำคัญของการตลาดเชิงความสัมพันธ์ในยุคปัจจุบัน

นอกจากนี้ การประเมินด้วยค่า AUC-ROC ที่ได้จากการวิเคราะห์ (AUC = 0.94) ยังยืนยันว่าแบบจำลอง Random Forest มีความสามารถในการจำแนกผู้บริโภคกลุ่มภักดีและกลุ่มเลิกซื้อได้ดีเยี่ยม โดยไม่ได้ขึ้นอยู่กับข้อกำหนดค่า threshold ที่แน่นอน ซึ่งสอดคล้องกับค่าประสิทธิภาพอื่นๆ ที่รายงานไว้ และสนับสนุนข้อค้นพบว่าปัจจัยด้านความรู้สึกรับรู้และการมีส่วนร่วมมีบทบาทสำคัญในการจำแนกพฤติกรรมผู้บริโภค

ในมุมมองของทฤษฎีการส่งสัญญาณ (Signaling Theory) ซึ่งพัฒนาโดย Spence (1973) และได้รับการขยายความโดย Connelly และคณะ (2011) อธิบายว่าสัญญาณที่น่าเชื่อถือสามารถลดความไม่สมมาตรของข้อมูลระหว่างผู้ซื้อและผู้ขายได้ ผลการวิจัยที่พบว่าผู้บริโภคกล่าวถึงคำว่า "คุณภาพ" และ "GI" อย่างสม่ำเสมอในข้อมูลโซเชียลมีเดีย สามารถตีความได้ว่าเป็นสัญญาณที่ผู้ผลิตและผู้จำหน่ายใช้สื่อสารไปยังผู้บริโภคเกี่ยวกับมาตรฐานสินค้า แหล่งที่มา และความน่าเชื่อถือ ในบริบทของสินค้าเกษตรซึ่งผู้บริโภคไม่สามารถประเมินคุณภาพได้โดยตรงก่อนการซื้อ สัญญาณด้าน GI จึงมีบทบาทสำคัญในการลดความไม่สมมาตรของข้อมูลและช่วยเพิ่มความมั่นใจในการตัดสินใจซื้อซ้ำ ดังที่ Verbeke และคณะ (2012) และ Teuber (2011) ได้อธิบายถึงบทบาทของการรับรองคุณภาพและสิ่งบ่งชี้ทางภูมิศาสตร์ต่อการรับรู้ของผู้บริโภค

ขณะเดียวกัน ผลการวิจัยยังสนับสนุนแนวคิดคุณค่าเชิงสิ่งบ่งชี้ทางภูมิศาสตร์ (GI Value) ตามที่ Aprile และคณะ (2012) และ Belletti และคณะ (2017) ได้นำเสนอไว้ว่า สินค้า GI ไม่ได้สร้างคุณค่าเพียงด้านเศรษฐกิจ แต่ยังสร้างคุณค่าเชิงอัตลักษณ์ ความเชื่อมั่น และความผูกพันกับพื้นที่และชุมชนแหล่งผลิต ผลที่พบว่าการรับรู้คุณค่า GI มีอิทธิพลต่อความภักดีของผู้บริโภค สะท้อนบทบาทของ GI ในฐานะเครื่องมือสร้างความแตกต่างและความไว้วางใจต่อสินค้าเกษตรของฝากจากชุมชน ซึ่งสอดคล้องกับงานวิจัยด้านการพัฒนาที่ยั่งยืนที่ชี้ว่า GI เป็นกลไกเชื่อมโยงเศรษฐกิจท้องถิ่นกับความภักดีของผู้บริโภค

ผลการศึกษาชี้ให้เห็นว่าคุณค่าในการกล่าวถึง GI มีบทบาทสำคัญต่อความภักดีของผู้บริโภคแตกต่างจากสินค้าเกษตรทั่วไป โดย GI ไม่เพียงทำหน้าที่เป็นเครื่องหมายรับรองคุณภาพ แต่ยังเป็นตัวเชื่อมโยงผู้บริโภคเข้ากับอัตลักษณ์ของพื้นที่และชุมชน ซึ่งสะท้อนให้เห็นถึงคุณค่าเชิงสัญลักษณ์ (symbolic value) ที่เกินกว่ามิติทางเศรษฐกิจ ดังที่ Belletti และคณะ (2017) ได้อธิบายไว้ในบริบทของการพัฒนาที่ยั่งยืน

3.2.2 อภิปรายผลเชิงระเบียบวิธี

ในเชิงระเบียบวิธีวิจัย การที่แบบจำลอง Random Forest ซึ่งพัฒนาโดย Breiman (2001) ให้ค่าประสิทธิภาพที่สอดคล้องกันทั้งจากการประเมินแบบ 5-fold cross-validation (Accuracy เฉลี่ย 0.88 ± 0.03) และการทดสอบกับชุดข้อมูลทดสอบ 126 รายการ (Accuracy 0.88) สะท้อนให้เห็นว่าแบบจำลองมีความเสถียรสูงและลดความเสี่ยงของปัญหา overfitting ที่มักเกิดขึ้นกับแบบจำลองที่มีความซับซ้อน การใช้เทคนิค cross-validation ร่วมกับการแบ่งข้อมูลแบบ stratified random sampling ช่วยให้การประเมินประสิทธิภาพมีความน่าเชื่อถือมากขึ้น เนื่องจากข้อมูลทุกตัวอย่างได้ถูกใช้ในการทดสอบและประเมินความสามารถในการทำนายของแบบจำลอง อีกทั้งยังช่วยลดความเอนเอียง (bias) ที่อาจเกิดจากการสุ่มแบ่งข้อมูลในแต่ละครั้ง

3.2.3 นัยเชิงปฏิบัติ

ในเชิงปฏิบัติ หากระบบวิเคราะห์ข้อมูลพบว่าคะแนน Sentiment ด้านคุณภาพหรือ GI ลดลงอย่างมีนัยสำคัญ ผู้ประกอบการสามารถนำผลลัพธ์ไปใช้เป็นระบบเตือนภัยล่วงหน้า (Real-time GI Quality Monitoring System) เพื่อเร่งตรวจสอบมาตรฐานการผลิต การสื่อสารแบรนด์ หรือประสบการณ์ของลูกค้า ซึ่งจะช่วยรักษาความน่าเชื่อถือของสินค้า GI ในระยะยาว นอกจากนี้ การทำความเข้าใจว่าปัจจัยด้านความรู้สึกและการมีส่วนร่วมบนสื่อสังคมออนไลน์เป็นตัวชี้วัดสำคัญของความภักดี สอดคล้องกับข้อเสนอของ Chen และ Xie (2021) ที่ชี้ให้เห็นว่าการวิเคราะห์ข้อมูลโซเชียลมีเดียด้วยเทคนิคการเรียนรู้ของเครื่องสามารถสนับสนุนการตัดสินใจเชิงกลยุทธ์ด้านการตลาดได้อย่างมีประสิทธิภาพ ช่วยให้ผู้ประกอบการสามารถออกแบบกลยุทธ์การตลาดที่มุ่งเน้นการสร้างปฏิสัมพันธ์เชิงบวกกับผู้บริโภคผ่านช่องทางดิจิทัลได้อย่างเหมาะสม

โดยสรุป ผลการศึกษานี้แสดงให้เห็นว่าความภักดีของผู้บริโภคสับปะรด GI จังหวัดนครพนมเกิดจากการผสมกันของความสัมพันธ์เชิงบวกและการมีปฏิสัมพันธ์อย่างต่อเนื่องตามแนวคิดการตลาดเชิงความสัมพันธ์ (Relationship Marketing) การส่งสัญญาณด้านคุณภาพและแหล่งที่มาตามทฤษฎีสัญญาณ (Signaling Theory) และคุณค่าเชิงอัตลักษณ์ของสินค้า GI (GI Value) ซึ่งสามารถนำไปใช้เป็นกรอบแนวคิดเชิงกลยุทธ์ในการพัฒนาการตลาดสินค้าเกษตรชุมชนและของฝากท้องถิ่นอย่างยั่งยืนต่อไป

4. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองสำหรับการพยากรณ์สถานะความภักดีและการเลิกซื้อของผู้บริโภคสินค้าเกษตรที่ได้รับการรับรองสิ่งบ่งชี้ทางภูมิศาสตร์ (GI) โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องกับข้อมูลพฤติกรรมการซื้อสินค้าเกษตรบนสื่อสังคมออนไลน์ในพื้นที่จังหวัดนครพนม กรณีศึกษาสินค้าสับปะรด GI นครพนม ผลการศึกษานี้สามารถสรุปสาระสำคัญได้ดังนี้

4.1 ประสิทธิภาพเชิงพยากรณ์ของแบบจำลอง

ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองพบว่า Random Forest ให้ผลการพยากรณ์ที่ดีที่สุดเมื่อเทียบกับ Logistic Regression และ Decision Tree โดยมีค่า Accuracy เท่ากับ 0.88 ค่า Precision 0.86 ค่า Recall 0.85 และค่า F1-score 0.85 ซึ่งเป็นค่าเฉลี่ยจากกระบวนการ 5-fold cross-validation แสดงให้เห็นถึงศักยภาพของแบบจำลองในการจัดการข้อมูลพฤติกรรมผู้บริโภคจากโซเชียลมีเดียซึ่งมีความหลากหลายและความสัมพันธ์เชิงซับซ้อน นอกจากนี้ การประเมินด้วยค่า AUC-ROC ที่ได้จากการวิเคราะห์ (AUC = 0.94) ยังยืนยันว่าแบบจำลองมีความสามารถในการจำแนกผู้บริโภคกลุ่มภักดีและกลุ่มเลิกซื้อได้ดีเยี่ยม สอดคล้องกับค่าประสิทธิภาพอื่นๆ ที่รายงานไว้

4.2 ปัจจัยชี้ขาดเชิงพฤติกรรมออนไลน์

การวิเคราะห์ความสำคัญของตัวแปรชี้ให้เห็นว่า Sentiment Score และ Engagement Rate เป็นปัจจัยที่มีอิทธิพลสูงสุดต่อการพยากรณ์ความภักดีของผู้บริโภค โดยมีความสำคัญรวมกันถึงร้อยละ 54 ของความสำคัญทั้งหมด สะท้อนให้เห็นว่าทัศนคติเชิงบวกและการมีส่วนร่วมอย่างต่อเนื่องบนสื่อสังคมออนไลน์เป็นตัวบ่งชี้สำคัญของความสัมพันธ์ระยะยาวระหว่างผู้บริโภคกับสินค้าเกษตร GI ขณะที่การกล่าวถึงคุณภาพและคุณค่า GI (ร้อยละ 33) ทำหน้าที่เสริมสร้างความเชื่อมั่นต่อสินค้าในเชิงอัตลักษณ์และแหล่งที่มา

4.3 นัยเชิงปฏิบัติและนวัตกรรมการดำเนินงาน

งานวิจัยนี้เสนอแนวทางการใช้ข้อมูลพฤติกรรมจริงจากโซเชียลมีเดียเป็นแหล่งข้อมูลหลัก แทนการพึ่งพาข้อมูลปฐมภูมิแบบดั้งเดิม ซึ่งช่วยลดข้อจำกัดด้านเวลาและทรัพยากรในการเก็บข้อมูล อีกทั้งยังสะท้อนพฤติกรรมผู้บริโภคในบริบทจริงได้อย่างต่อเนื่อง ผลการศึกษามีศักยภาพในการนำไปประยุกต์ใช้เป็นเครื่องมือสนับสนุนการตัดสินใจเชิงกลยุทธ์หรือระบบเฝ้าระวังความเสี่ยงด้านความภักดีของผู้บริโภค (Real-time GI Quality Monitoring System) สำหรับผู้ประกอบการสินค้าเกษตรมูลค่าเพิ่มและหน่วยงานที่เกี่ยวข้องในระดับพื้นที่

ในเชิงระเบียบวิธี การใช้เทคนิค 5-fold cross-validation ร่วมกับการแบ่งข้อมูลแบบ stratified random sampling ช่วยเพิ่มความน่าเชื่อถือของผลการวิจัย และยืนยันความเสถียรของแบบจำลอง Random Forest ในการพยากรณ์ข้อมูลใหม่

โดยสรุปงานวิจัยนี้ประสบความสำเร็จในการพัฒนาต้นแบบแบบจำลองพยากรณ์ที่มีประสิทธิภาพ และแสดงให้เห็นถึงความเหมาะสมของการบูรณาการเทคนิคการเรียนรู้ของเครื่องเข้ากับการวิเคราะห์ข้อมูลสื่อสังคมออนไลน์ เพื่อสนับสนุนการบริหารจัดการและการกำหนดนโยบายด้านสินค้าเกษตร GI ในบริบทเศรษฐกิจดิจิทัล

4.4 ข้อจำกัดและข้อเสนอแนะการวิจัยในอนาคต

งานวิจัยนี้มีข้อจำกัดจากการใช้ข้อมูลทุติยภูมิจากสื่อสังคมออนไลน์ ซึ่งอาจไม่ครอบคลุมผู้บริโภคที่ซื้อสินค้าในช่องทางออฟไลน์หรือไม่ได้แสดงความเห็นผ่านแพลตฟอร์มดิจิทัล อีกทั้งการวิเคราะห์ความรู้สึกแบบ lexicon-based มีข้อจำกัดในการตีความข้อความที่มีอารมณ์ผสม คำแสลง หรือบริบทเฉพาะของภาษาไทย

สำหรับการวิจัยในอนาคต ควรพิจารณา: (1) ผสานข้อมูลปฐมภูมิร่วมกับข้อมูลออนไลน์ (2) ประยุกต์ใช้เทคนิคการประมวลผลภาษาธรรมชาติขั้นสูง เช่น deep learning-based sentiment analysis (3) เพิ่มคุณลักษณะด้านความรู้สึกเกี่ยวกับราคา (Price Sentiment) (4) ขยายการศึกษาไปยังสินค้า GI ประเภทอื่นและพื้นที่อื่น และ (5) พัฒนาระบบเฝ้าระวังแบบเรียลไทม์เพื่อแจ้งเตือนผู้ประกอบการเมื่อพบแนวโน้มความเสี่ยงด้านความภักดีของผู้บริโภค

5. กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงได้ด้วยความช่วยเหลือ คำแนะนำจากอาจารย์ประจำสาขาวิชานวัตกรรมการตลาด และธุรกิจอัจฉริยะ มหาวิทยาลัยนครพนม ผู้วิจัยขอขอบคุณทีมงาน NCSDI 2026 สำหรับกรอบแนวทางและมาตรฐานทางวิชาการ ตลอดจนแหล่งข้อมูลอ้างอิงและชุมชนออนไลน์ที่เป็นฐานความรู้สำคัญของการศึกษาคั้งนี้

6. เอกสารอ้างอิง

- [1] Reichheld FF, Sasser WE. Zero defections: Quality comes to services. *Harvard Business Review*. 1990; 68(5): 105–111.
- [2] Morgan RM, Hunt SD. The commitment–trust theory of relationship marketing. *Journal of Marketing*. 1994; 58(3): 20–38.
- [3] Palmatier RW, Dant RP, Grewal D, Evans KR. Factors influencing the effectiveness of relationship marketing: A meta-analysis. *Journal of Marketing*. 2006; 70(4): 136–153.
- [4] Spence M. Job market signaling. *Quarterly Journal of Economics*. 1973; 87(3): 355–374.
- [5] Connelly BL, Certo ST, Ireland RD, Reutzel CR. Signaling theory: A review and assessment. *Journal of Management*. 2011; 37(1): 39–67.
- [6] Verbeke W, Pieniak Z, Guerrero L, Hersleth M. Consumers' awareness and attitudinal determinants of European Union quality label use. *Food Quality and Preference*. 2012; 27(2): 129–138.
- [7] Teuber R. Consumers' and producers' expectations towards geographical indications. *British Food Journal*. 2011; 113(7): 900–918.
- [8] Aprile MC, Caputo V, Nayga RM. Consumers' preferences and valuation for food products with geographical indication. *Journal of International Food & Agribusiness Marketing*. 2012; 24(3): 193–210.
- [9] Belletti G, Marescotti A, Touzard JM. Geographical indications, public goods, and sustainable development. *World Development*. 2017; 98: 45–57.
- [10] Kumar V, Shah D. Building customer loyalty through digital engagement: Insights from social media analytics. *Journal of the Academy of Marketing Science*. 2021; 49(5): 879–901.
- [11] Chen Y, Xie K. Social media analytics for predicting consumer loyalty: A machine learning approach. *Journal of Retailing and Consumer Services*. 2021;58:102342.
- [12] Breiman L. Random forests. *Machine Learning*. 2001; 45(1): 5–32.

การพยากรณ์คาร์บอนฟุตพริ้นท์จากการใช้ไฟฟ้าและการวิเคราะห์ ดัชนีความเพี้ยนฮาร์มอนิกในระบบไฟฟ้า

Forecasting the Carbon Footprint of Electricity Consumption and Analyzing the Harmonic Distortion Indices in Electrical Systems

จิรภัทร ตระกูลศักดิ์* และ วิภาดา ผาพันธุ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(*s6704051811029@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง Deep Learning และแบบจำลองทางสถิติในการพยากรณ์ Carbon Footprint ของโรงพยาบาล พร้อมทั้งวิเคราะห์ปัญหาคุณภาพไฟฟ้าจากค่า Total Harmonic Distortion of Current (THDi) และนำเสนอแนวทางการลงทุนเพื่อลดผลกระทบต่อสิ่งแวดล้อม

การศึกษาได้ประเมินแบบจำลอง 8 รูปแบบ ประกอบด้วย Deep Learning 5 แบบ (LSTM, GRU, BiLSTM, Stacked-LSTM, CNN-LSTM) และแบบจำลองทางสถิติ 3 แบบ (SARIMA, Exponential Smoothing, Prophet) โดยใช้ข้อมูลจริงจากโรงพยาบาล ผลการวิจัยพบว่า LSTM มีประสิทธิภาพดีที่สุดด้วยค่า RMSE 14.06 MAE 10.86 MAPE 12.66% และ R^2 เท่ากับ 0.7254 ขณะที่แบบจำลองทางสถิติทุกตัวมีค่า RMSE สูงกว่า 26.53 และให้ผลการพยากรณ์ที่ไม่ผ่านเกณฑ์ โดย LSTM มีความเหนือกว่าแบบจำลองทางสถิติที่ดีที่สุดถึง 47% ในด้าน RMSE นอกจากนี้ วิธี Stacking Ensemble ยังให้ R^2 สูงถึง 0.9892 แสดงถึงการปรับปรุงความแม่นยำ 99.84%

ด้านคุณภาพไฟฟ้า การวิเคราะห์ข้อมูล THDi จำนวน 2,107 จุดข้อมูลในระบบ 3 เฟส พบว่าค่าเฉลี่ย THDi ของทุกเฟสเกินมาตรฐาน IEEE 519-2022 ที่กำหนดไว้ 5% โดย Phase A มีค่าเฉลี่ย 6.74% Phase B 4.16% และ Phase C 6.50% อัตราการเกินมาตรฐานรวมคิดเป็น 61.7% ของการวัดทั้งหมด ที่ระดับ THDi เฉลี่ย 7% โรงพยาบาลสูญเสียพลังงานเพิ่มขึ้น 625 kWh/วัน ปลดปล่อย CO₂ เพิ่ม 321.88 กก./วัน คิดเป็นต้นทุนเพิ่ม 3,125 บาท/วัน

การวิเคราะห์ความคุ้มค่าทางเศรษฐศาสตร์พบว่าการลงทุน 4.3 ล้านบาทในระบบกรองฮาร์มอนิกจะให้ผลประหยัดสุทธิ 9.52 ล้านบาท/ปี มีระยะคืนทุนไม่ถึง 6 เดือน NPV 10 ปีเท่ากับ 60.06 ล้านบาท และ ROI 5 ปีสูงถึง 1,007% ผลการวิจัยนี้สนับสนุนให้โรงพยาบาลนำแบบจำลอง LSTM มาใช้พยากรณ์ Carbon Footprint และลงทุนในระบบปรับปรุงคุณภาพไฟฟ้าเพื่อลดต้นทุนพลังงานและผลกระทบต่อสิ่งแวดล้อมอย่างยั่งยืน

คำสำคัญ: คาร์บอนฟุตพริ้นท์, ความเพี้ยนฮาร์มอนิกรวมของกระแสไฟฟ้า (THDi), การเรียนรู้เชิงลึก, การพยากรณ์อนุกรมเวลา

Abstract

Climate change has compelled industrial organizations to accurately measure and report carbon emissions. However, organizational-level carbon footprint assessment remains complex, requiring extensive data and adherence to multiple international standards. This study proposes a novel framework leveraging Total Harmonic Distortion of current (THDi) as a predictive driver for forecasting electricity-based carbon emissions. Harmonic distortion increases transformer losses through conductor windings and magnetic cores, elevating energy consumption and carbon emissions. Five deep learning models—GRU, LSTM, BiLSTM, CNN-LSTM, and Stacked LSTM—were benchmarked against SARIMA and Prophet points from one Thai industrial establishment. Results demonstrate that GRU achieves superior performance with approximately 80% error reduction and R^2 of 0.977. A strong causal relationship between THDi and carbon emissions was One

establishment. Economic analysis indicates harmonic filtering solutions achieve payback periods under two years. The proposed framework provides near-expert-level forecasting accuracy, enabling efficient environmental compliance and supporting industrial net-zero pathways.

Keywords: Carbon Footprint, Total Harmonic Distortion (THDi), Deep Learning, Time Series Forecasting, Power Quality, GRU Model

1. บทนำ

1.1 ที่มาของปัญหาและความสำคัญการวิจัย

ปัจจุบันโรงพยาบาลเป็นสถานประกอบการที่มีการใช้พลังงานไฟฟ้าสูงอย่างต่อเนื่องตลอด 24 ชั่วโมง เนื่องจากต้องดำเนินงานระบบปรับอากาศ ระบบแสงสว่าง อุปกรณ์การแพทย์ และระบบสนับสนุนชีวิตผู้ป่วยโดยไม่สามารถหยุดพักได้ การใช้อุปกรณ์ไฟฟ้าจำนวนมากที่มีลักษณะเป็นโหลดไม่เชิงเส้น (Nonlinear Load) เช่น เครื่องปรับอากาศ ระบบอินเวอร์เตอร์ เครื่องมือแพทย์ที่ใช้วงจรอิเล็กทรอนิกส์กำลัง และระบบ UPS ก่อให้เกิดปัญหาฮาร์มอนิกส์ในระบบไฟฟ้า ซึ่งวัดได้จากค่า Total Harmonic Distortion of Current (THDi) เมื่อค่า THDi สูงเกินมาตรฐาน IEEE 519-2022 จะส่งผลให้เกิดการสูญเสียพลังงานในระบบเพิ่มขึ้น อุปกรณ์ไฟฟ้ามีอายุการใช้งานสั้นลง และที่สำคัญคือทำให้ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ (Carbon Footprint) เพิ่มขึ้นโดยไม่จำเป็น

ในขณะเดียวกัน การพยากรณ์ปริมาณ Carbon Footprint อย่างแม่นยำเป็นสิ่งจำเป็นสำหรับการวางแผนลดการปล่อยก๊าซเรือนกระจกของโรงพยาบาล แต่แบบจำลองทางสถิติแบบดั้งเดิมอาจไม่สามารถจับรูปแบบที่ซับซ้อนและไม่เชิงเส้นของข้อมูลการใช้พลังงานในสถานพยาบาลได้ จึงมีความจำเป็นต้องศึกษาเปรียบเทียบศักยภาพของแบบจำลอง Deep Learning กับแบบจำลองทางสถิติ

งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อ (1) เปรียบเทียบประสิทธิภาพแบบจำลอง Deep Learning 5 แบบและแบบจำลองทางสถิติ 3 แบบ (2) วิเคราะห์สถานการณ์คุณภาพไฟฟ้าผ่านค่า THDi ตามมาตรฐาน IEEE 519-2022 (3) ระบุสาเหตุหลักของปัญหาคุณภาพไฟฟ้าและผลกระทบต่อ Carbon Footprint และ (4) เสนอแนวทางเชิงนโยบายพร้อมการวิเคราะห์ความคุ้มค่าทางเศรษฐศาสตร์ เพื่อให้โรงพยาบาลมีเครื่องมือที่มีประสิทธิภาพในการบริหารจัดการพลังงานและลดผลกระทบต่อสิ่งแวดล้อมอย่างยั่งยืน

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 การวิจัยนี้มีวัตถุประสงค์ดังต่อไปนี้เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก กับแบบจำลองทางสถิติแบบดั้งเดิม ในการพยากรณ์คาร์บอนฟุตพริ้นท์ได้แก่

1.2.1.1 Long Short-Term Memory (LSTM),

1.2.1.2 Gated Recurrent Unit (GRU),

1.2.1.3 Bidirectional Long Short-Term Memory (BiLSTM)

1.2.1.4 Stacked Long Short-Term Memory (Stacked-LSTM)

1.2.1.5 Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM)

1.2.1.6 Seasonal Autoregressive Integrated Moving Average (SARIMA)

1.2.1.7 Prophet

1.2.2 เพื่อวิเคราะห์คุณภาพไฟฟ้า โดยเฉพาะ Total Harmonic Distortion (THDi) ในระบบไฟฟ้าของภาคโรงพยาบาลหลากหลายประเภท ครอบคลุมทั้งภาคการผลิต เครื่องใช้ไฟฟ้า ยานยนต์ เครื่องกั้นพลาสติก เครื่องกำเนิดไฟฟ้า และภาคสาธารณสุข

1.2.3 เพื่อระบุสาเหตุหลักของปัญหาคุณภาพไฟฟ้าและคาร์บอนฟุตพริ้นท์ที่เกินมาตรฐานในแต่ละภาคโรงพยาบาล

1.2.4 เพื่อพัฒนาข้อเสนอแนะเชิงนโยบายและแนวทางการปฏิบัติในการปรับปรุงคุณภาพไฟฟ้าและลดการปล่อยคาร์บอนฟุตพริ้นท์ในระดับองค์กร ระดับโรงพยาบาล และระดับประเทศ

1.2.5 เพื่อประเมินความคุ้มค่าทางเศรษฐศาสตร์ (Cost-Benefit Analysis) ของการลงทุนในการแก้ไขปัญหาคุณภาพไฟฟ้าและการพยากรณ์คาร์บอนฟุตพริ้นท์

2. ทฤษฎีที่เกี่ยวข้อง

2.1 Total Harmonic Distortion (THDi) [1-6]

$$THDi = \frac{\sqrt{\sum I_n^2}}{I_1} \times 100\% \quad (1)$$

โดยที่ I_n คือกระแสฮาร์มอนิกลำดับที่ n

I_1 คือกระแสพื้นฐาน (Fundamental Current)

2.2 มาตรฐาน IEEE 519-2014

สำหรับระบบแรงดันต่ำ (Low Voltage: 120V-69kV) ที่ $ISC/IL < 20$:

ฮาร์มอนิกแต่ละลำดับ (Individual Harmonic) ไม่เกิน 4.0%

THDi ไม่เกิน 5.0%

สำหรับระบบแรงดันต่ำ ที่ $20 \leq ISC/IL < 50$:

ฮาร์มอนิกแต่ละลำดับ ไม่เกิน 7.0%

THDi ไม่เกิน 8.0%

สำหรับระบบแรงดันต่ำ ที่ $ISC/IL \geq 50$:

ฮาร์มอนิกแต่ละลำดับ ไม่เกิน 10.0%

THDi ไม่เกิน 12.0%

2.3 Long Short-Term Memory (LSTM)

เป็นโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่ถูกออกแบบมาเพื่อแก้ปัญหาการสูญหายของข้อมูลระยะยาวในลำดับข้อมูล (vanishing gradient problem) โดยใช้กลไกประตูควบคุม (gating mechanism) ได้แก่ input gate, forget gate และ output gate เพื่อควบคุมการเก็บรักษา การลืม และการส่งผ่านข้อมูลในแต่ละช่วงเวลา โครงสร้างดังกล่าวทำให้ LSTM สามารถเรียนรู้ความสัมพันธ์ของข้อมูลในระยะยาวได้อย่างมีประสิทธิภาพ จึงถูกนำมาใช้อย่างแพร่หลายในการพยากรณ์ข้อมูลอนุกรมเวลา เช่น การพยากรณ์พลังงาน การใช้ไฟฟ้า และการปล่อยคาร์บอน

2.4 Gated Recurrent Unit (GRU)

เป็นโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่ถูกพัฒนาขึ้นเพื่อแก้ปัญหาการเรียนรู้ความสัมพันธ์ของข้อมูลลำดับเวลาในระยะยาว คล้ายกับแบบจำลอง LSTM แต่มีโครงสร้างที่ง่ายกว่า โดยใช้กลไกสองประตูหลัก ได้แก่ update gate และ reset gate เพื่อควบคุมการเก็บรักษาและการปรับปรุงข้อมูลในหน่วยความจำของเครือข่าย กล่าวคือช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพ ในขณะที่ใช้จำนวนพารามิเตอร์น้อยกว่าและใช้เวลาในการฝึกสอนน้อยกว่า LSTM ดังนั้น GRU จึงถูกนำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา เช่น การใช้พลังงานไฟฟ้า การพยากรณ์โหลดไฟฟ้า และการปล่อยคาร์บอนจากระบบพลังงานได้อย่างมีประสิทธิภาพ

2.5 Bidirectional Long Short-Term Memory (BiLSTM)

เป็นแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำที่พัฒนาจาก LSTM โดยเพิ่มความสามารถในการประมวลผลข้อมูลลำดับเวลาได้ทั้ง ทิศทางไปข้างหน้า (forward) และย้อนกลับ (backward) พร้อมกัน โครงสร้างนี้ประกอบด้วย LSTM สองชุดที่ทำงานคู่ขนานกัน โดยชุดหนึ่งประมวลผลข้อมูลจากอดีตไปสู่อนาคต และอีกชุดหนึ่งประมวลผลจาก

อนาคตย้อนกลับไปยังอดีต จากนั้นผลลัพธ์จะถูกนำมารวมกันเพื่อสร้างการทำนายที่แม่นยำยิ่งขึ้น วิธีการนี้ช่วยให้แบบจำลองสามารถเรียนรู้บริบทของข้อมูลได้ครบถ้วนทั้งก่อนหน้าและภายหลัง จึงเหมาะสำหรับการวิเคราะห์และการพยากรณ์ข้อมูลอนุกรมเวลา เช่น การพยากรณ์พลังงานไฟฟ้า การใช้ไฟฟ้า และการปล่อยคาร์บอนในระบบพลังงาน

2.6 Stacked Long Short-Term Memory (Stacked-LSTM)

เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบ LSTM ที่ประกอบด้วย หลายชั้นของ LSTM (multiple LSTM layers) ที่ถูกวางซ้อนกัน โดยผลลัพธ์จากชั้น LSTM ก่อนหน้าจะถูกส่งเป็นข้อมูลนำเข้าไปกับชั้นถัดไป โครงสร้างแบบหลายชั้นนี้ช่วยให้แบบจำลองสามารถเรียนรู้ลักษณะของข้อมูลที่มีความซับซ้อนและความสัมพันธ์เชิงลำดับในหลายระดับได้ดียิ่งขึ้น ทำให้มีประสิทธิภาพในการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลาที่มีรูปแบบซับซ้อน เช่น การพยากรณ์การใช้พลังงานไฟฟ้าและการปล่อยคาร์บอนในระบบโรงพยาบาล

2.7 Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM)

เป็นแบบจำลองการเรียนรู้เชิงลึกแบบผสมผสานที่รวมความสามารถของ Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) เข้าด้วยกัน โดยส่วนของ CNN ทำหน้าที่สกัดคุณลักษณะสำคัญของข้อมูลจากรูปแบบเชิงพื้นที่หรือรูปแบบเฉพาะของสัญญาณ ส่วน LSTM ทำหน้าที่เรียนรู้ความสัมพันธ์เชิงเวลาในข้อมูลลำดับ (time series) การผสานโครงสร้างทั้งสองช่วยให้แบบจำลองสามารถวิเคราะห์รูปแบบข้อมูลที่มีความซับซ้อนทั้งเชิงโครงสร้างและเชิงเวลาได้อย่างมีประสิทธิภาพ จึงถูกนำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา เช่น การใช้พลังงานไฟฟ้า โหลดไฟฟ้า และการปล่อยคาร์บอนในระบบพลังงาน

2.8 เมตริกซ์การประเมินประสิทธิภาพแบบจำลอง

Root Mean Square Error (RMSE)

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum (y_i - \hat{y}_i)^2}$$

Mean Absolute Error (MAE)

$$MAE = \frac{1}{n} \sum |y_i - \hat{y}_i|$$

Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{100}{n} \sum \frac{|y_i - \hat{y}_i|}{|y_i|}$$

Symmetric Mean Absolute Percentage Error (SMAPE)

$$SMAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2}$$

Coefficient of Determination (R^2)

$$R^2 = 1 - \left(\frac{SS_{res}}{SS_{tot}} \right) = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

3. ระเบียบวิธีวิจัย

3.1 ขั้นตอนการวิจัย

3.1.1 การทบทวนวรรณกรรมและกรอบแนวคิด

ได้ทำการทบทวนอย่างครอบคลุมเกี่ยวกับการพยากรณ์รอยเท้าคาร์บอน การวิเคราะห์คุณภาพพลังงาน และการประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึกสำหรับการพยากรณ์อนุกรมเวลา ฐานข้อมูลทางวิชาการ ได้แก่ IEEE Xplore, ScienceDirect, Springer และ Google Scholar ถูกนำมาใช้เพื่อสร้างกรอบแนวคิดการวิจัยและระบุช่องว่างการวิจัยที่การศึกษาครั้งนี้กล่าวถึง

3.1.2 การคัดเลือกกรณีศึกษาและการประสานงานการเข้าถึงข้อมูล

ได้เลือกสถานประกอบการตัวแทนจากภาคโรงพยาบาลหนึ่งแห่งสำหรับการศึกษาครั้งนี้ ได้มีการประสานงานกับฝ่ายบริหารและเจ้าหน้าที่ด้านพลังงานเพื่อขอรับข้อมูลการใช้พลังงานและคุณภาพไฟฟ้า พร้อมด้วยข้อตกลงการไม่เปิดเผยข้อมูล (NDA) เพื่อปกป้องข้อมูลที่มีความอ่อนไหวทางการค้า

3.1.3 การเก็บรวบรวมข้อมูล

ได้เก็บรวบรวมข้อมูลหลักสองประเภท ได้แก่ (1) ข้อมูลการใช้พลังงานไฟฟ้าต่อเดือนและการคำนวณคาร์บอนฟุตพริ้นท์ตามพลังงาน และ (2) ข้อมูลคุณภาพไฟฟ้า โดยเฉพาะอย่างยิ่งค่า Total Harmonic Distortion of Current (THDi) ที่วัดอย่างต่อเนื่องในเฟส A เฟส B และเฟส C พร้อมกับข้อมูล

ตัวประกอบกำลังและโหลดไฟฟ้า ข้อมูลทั้งหมดได้รับการตรวจสอบความถูกต้องและครบถ้วน โดยเจ้าหน้าที่ผู้รับผิดชอบในสถานประกอบการ

3.1.4 การเตรียมข้อมูลและการประมวลผลเบื้องต้น

ได้ทำการทำความสะอาดข้อมูลเพื่อจัดการกับข้อมูลที่ขาดหายไป ข้อมูลผิดปกติ และข้อมูลที่ไม่สอดคล้องกัน ได้ทำการวิเคราะห์ข้อมูลเชิงสำรวจ (EDA) เพื่อทำความเข้าใจลักษณะและรูปแบบของข้อมูล การทดสอบความนิ่งของข้อมูลดำเนินการโดยใช้การทดสอบ Augmented Dickey-Fuller (ADF) และวิเคราะห์รูปแบบตามฤดูกาลโดยใช้การแยกส่วนตามฤดูกาลและฟังก์ชันสหสัมพันธ์อัตโนมัติ (ACF)

3.1.5 การพัฒนาและการฝึกอบรมแบบจำลอง

มีการพัฒนาแบบจำลองการพยากรณ์เชิงแบบได้แก่แบบจำลองการเรียนรู้เชิงลึกห้าแบบ—LSTM, GRU, BiLSTM, Stacked-LSTM และ CNN-LSTM—และแบบจำลองทางสถิติสองแบบ—SARIMA และ Prophet การใช้งานใช้ Python ร่วมกับไลบรารี TensorFlow, Keras, Statsmodels และ Prophet ข้อมูลถูกแบ่งออกเป็นชุดฝึกอบรม (70%), ชุดตรวจสอบ (15%) และชุดทดสอบ (15%)

3.1.6 การประเมินและเปรียบเทียบประสิทธิภาพ

ประสิทธิภาพของแบบจำลองได้รับการประเมินโดยใช้เมตริก RMSE, MAE, MAPE, SMAPE และ R^2 มีการเปรียบเทียบภายในและระหว่างกลุ่มแบบจำลองและความสำคัญทางสถิติได้รับการประเมินผ่านการทดสอบสมมติฐาน

3.1.7 คุณภาพพลังงานและการวิเคราะห์ความสัมพันธ์

ข้อมูล THDi ได้รับการวิเคราะห์ตามมาตรฐาน IEEE 519-2014 เทคนิคการควบคุมกระบวนการทางสถิติ (SPC) ถูกนำมาใช้ในการสร้างแผนภูมิควบคุมและการระบุความผิดปกติ การวิเคราะห์ความสัมพันธ์และการถดถอยถูกดำเนินการเพื่อสร้างความสัมพันธ์ระหว่าง THDi การสูญเสียพลังงาน และรอยเท้าคาร์บอน

3.2 แหล่งข้อมูลและวิธีการเก็บรวบรวมข้อมูล

3.2.1 ประเภทและแหล่งที่มาของข้อมูล

การศึกษาครั้งนี้ใช้ข้อมูลทุติยภูมิที่รวบรวมจากระบบตรวจสอบพลังงานและระบบบันทึกข้อมูลถึงอำนาจความสะดวก ซึ่งแบ่งออกเป็นสองประเภทหลัก

3.2.1.1 ข้อมูลการใช้พลังงานและรอยเท้าคาร์บอน

การใช้พลังงานไฟฟ้าต่อเดือน (kWh) ได้รับความจากระบบไฟฟ้าและระบบจัดการพลังงานอาคาร (BEMS) ที่ติดตั้งในแต่ละสถานประกอบการ ครอบคลุมระยะเวลา 24 ถึง 60 เดือน ขึ้นอยู่กับความพร้อมของข้อมูล ข้อมูลรอยเท้าคาร์บอนคำนวณโดยใช้ค่าสัมประสิทธิ์การปล่อยก๊าซเรือนกระจกของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (EGAT) ที่ 0.5135 กก. CO₂e/kWh สำหรับปีงบประมาณ 2565–2566

รอยเท้าคาร์บอน (ตัน CO₂e) = การใช้พลังงาน (kWh) × ค่าสัมประสิทธิ์การปล่อยก๊าซเรือนกระจก (กก.CO₂e/kWh) ÷ 1,000 ข้อมูลเพิ่มเติมประกอบด้วยปริมาณการผลิตจากระบบบันทึกข้อมูลของโรงงาน และข้อมูลอุณหภูมิ/สภาพอากาศจากกรมอุตุนิยมวิทยาของไทย ซึ่งใช้เป็นตัวแปรภายนอกสำหรับการวิเคราะห์ปัจจัยตามฤดูกาล

3.2.1.2 ข้อมูลคุณภาพไฟฟ้า การวัดค่า THDi

ดำเนินการที่จุดเชื่อมต่อร่วม (PCC) และจุดสำคัญภายในระบบจำหน่ายไฟฟ้าภายในโดยใช้เครื่องวิเคราะห์คุณภาพไฟฟ้าความละเอียดสูง (เช่น Fluke 435 Series II, Hioki PW3198) บันทึกข้อมูลต่อเนื่อง 24 ชั่วโมงเป็นเวลา 7 ถึง 14 วันต่อสถานประกอบการ เพื่อบันทึกรูปแบบการเปลี่ยนแปลงของ THDi ในช่วงเวลาและสถานะ โหลดที่แตกต่างกัน พารามิเตอร์ที่บันทึกไว้ ได้แก่ THDi ต่อเฟส (%), กระแสเฟส (A), แรงดันเฟส (V), ตัวประกอบกำลัง (0–1), ส่วนประกอบฮาร์มอนิกแต่ละตัว (ลำดับ 1–50, %) และกำลังไฟฟ้าจริง/รีแอกทีฟ/ปรากฏ (kW/kVAR/kVA)

3.2.1.3 การตรวจสอบคุณภาพและความน่าเชื่อถือของข้อมูล

มีการใช้ขั้นตอนการตรวจสอบห้าขั้นตอน ได้แก่ (1) การตรวจสอบความถูกต้อง—เปรียบเทียบข้อมูล BEMS กับไบแรงค่าไฟฟ้าโดยมีความคลาดเคลื่อน ±3% (2) การตรวจสอบความสมบูรณ์—การประมาณค่าแบบเส้นตรงหรือ

ค่าเฉลี่ยเคลื่อนที่สำหรับข้อมูลที่ขาดหายไปน้อยกว่า 5% โดยจะขอข้อมูลเพิ่มเติมหากเกินกว่านั้น (3) การตรวจสอบความสอดคล้อง—การตรวจสอบเชิงตรรกะของความสัมพันธ์ระหว่างพลังงานกับการผลิตและ THDi กับ โหลดที่ไม่เป็นเส้นตรง (4) การตรวจจับค่าผิดปกติ—ใช้วิธี IQR และ Z-score เพื่อจำแนกค่าผิดปกติว่าเป็นข้อผิดพลาดในการบันทึกหรือเหตุการณ์จริง และ (5) การตรวจสอบการสอบเทียบเครื่องมือ—ยืนยันไบแรงการสอบเทียบที่มีอายุไม่เกินหนึ่งปีจากหน่วยงานที่ได้รับการรับรอง

3.2.2 ขนาดตัวอย่างและความเพียงพอของข้อมูล

ขนาดตัวอย่างมีความเพียงพอสำหรับการฝึกอบรมแบบจำลองการเรียนรู้เชิงลึกตามแนวทางการวิจัยที่เกี่ยวข้องสำหรับ SARIMA ข้อมูลสนับสนุนการระบุรูปแบบวัฏจักรประจำปีและการประมาณค่าพารามิเตอร์ที่น่าเชื่อถือได้อย่างเพียงพอ การวัดคุณภาพพลังงานอย่างต่อเนื่อง 7-14 วัน ครอบคลุมรูปแบบวันธรรมดา/วันหยุดสุดสัปดาห์ ชั่วโมงที่มีการใช้ไฟฟ้าสูงสุด/นอกช่วงเวลาที่มีการใช้ไฟฟ้าสูงสุด

3.2.3 การตรวจสอบคุณภาพและความน่าเชื่อถือของข้อมูล

มีการใช้ขั้นตอนการตรวจสอบห้าขั้นตอน ได้แก่ (1) การตรวจสอบความถูกต้อง—เปรียบเทียบข้อมูล BEMS กับไบแรงค่าไฟฟ้าโดยมีความคลาดเคลื่อน ±3% (2) การตรวจสอบความสมบูรณ์—การประมาณค่าแบบเส้นตรงหรือค่าเฉลี่ยเคลื่อนที่สำหรับข้อมูลที่ขาดหายไปน้อยกว่า 5% โดยจะขอข้อมูลเพิ่มเติมหากเกินกว่านั้น (3) การตรวจสอบความสอดคล้อง—การตรวจสอบเชิงตรรกะของความสัมพันธ์ระหว่างพลังงานกับการผลิตและ THDi กับ โหลดที่ไม่เป็นเส้นตรง (4) การตรวจจับค่าผิดปกติ—ใช้วิธี IQR และ Z-score เพื่อจำแนกค่าผิดปกติว่าเป็นข้อผิดพลาดในการบันทึกหรือเหตุการณ์จริง และ (5) การตรวจสอบการสอบเทียบเครื่องมือ—ยืนยันไบแรงการสอบเทียบที่มีอายุไม่เกินหนึ่งปีจากหน่วยงานที่ได้รับการรับรอง

3.3 การเตรียมข้อมูลและการประมวลผลเบื้องต้น

3.3.1 การทำความสะอาดข้อมูล

3.3.1.1 การเติมข้อมูลที่ขาดหายไป

สำหรับข้อมูลที่ขาดหายไปซึ่งคิดเป็นสัดส่วนน้อยกว่า 5% ของจำนวนข้อมูลทั้งหมด จะใช้วิธีการสามวิธีขึ้นอยู่กับความยาวของช่องว่าง ได้แก่ การประมาณค่าเชิงเส้น (Linear Interpolation) สำหรับข้อมูลที่ขาดหายไป 1-2 จุดติดต่อกัน การประมาณค่าโดยใช้ค่าเฉลี่ยเคลื่อนที่ (Moving Average Imputation) (ขนาดหน้าต่าง $k = 2-3$) สำหรับช่องว่างที่เกิน 2 จุดติดต่อกัน และการประมาณค่าโดยใช้ค่าเฉลี่ยตามฤดูกาล (Seasonal Average Imputation) สำหรับข้อมูลที่มีรูปแบบวัฏจักรที่ชัดเจน โดยใช้ค่าเฉลี่ยของช่วงเวลาที่สอดคล้องกัน จากวัฏจักรที่อยู่ติดกัน

3.3.1.2 การจัดการค่าผิดปกติ

ระบุค่าผิดปกติโดยใช้วิธีช่วงควาร์ไทล์ (Interquartile Range: IQR) โดยที่ขอบล่าง = $Q1 - 1.5 \times IQR$ และขอบบน = $Q3 + 1.5 \times IQR$ แก๊วข้อผิดพลาดในการบันทึกหรือลบบอก ในขณะที่เหตุการณ์จริง (วันหยุด การบำรุงรักษา เหตุการณ์พิเศษ) จะถูกเก็บรักษาและทำเครื่องหมายไว้ ใช้การปรับค่าขอบ (Winsorization) กับค่าผิดปกติจริงที่อาจส่งผลเสียต่อการฝึกโมเดล

3.3.1.3 การตรวจจับและแก้ไขข้อมูลซ้ำ

มีการระบุและแก้ไขข้อมูลเวลาที่ซ้ำกัน ค่าที่เหมือนกันจะคงไว้เพียงรายการเดียว ค่าที่แตกต่างกันจะได้รับการตรวจสอบกับเจ้าหน้าที่ของสถานที่เพื่อกำหนดค่าที่ถูกต้อง

3.3.2 การวิเคราะห์ข้อมูลเชิงสำรวจ

มีการคำนวณสถิติเชิงพรรณนา (ค่าเฉลี่ย มัชฐาน ส่วนเบี่ยงเบนมาตรฐาน ค่าต่ำสุด/สูงสุด ควาร์ไทล์ ค่าความเบี่ยงเบน ค่าความโค้ง) การวิเคราะห์การกระจายใช้ฮิสโตแกรม แผนภาพความหนาแน่น แผนภาพ Q-Q และการทดสอบ Shapiro-Wilk การวิเคราะห์อนุกรมเวลารวมถึงการแสดงภาพแนวโน้ม/ฤดูกาล/ความผันผวน การแยกองค์ประกอบตามฤดูกาล (แบบบวก: $y_t = T_t + S_t + R_t$; แบบคูณ: $y_t = T_t \times S_t \times R_t$) และการวิเคราะห์ ACF/PACF เพื่อระบุโครงสร้างความสัมพันธ์

การทดสอบความนิ่ง ใช้การทดสอบ Augmented Dickey-Fuller (ADF) กับแบบจำลอง

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum \delta_i \Delta y_{t-i} + \varepsilon_t$$

โดยที่ γ คือพารามิเตอร์การทดสอบหลัก ($H_0: \gamma = 0$ แสดงว่าไม่นิ่ง $H_1: \gamma < 0$ แสดงว่านิ่ง) ค่า $p < 0.05$ นำไปสู่การปฏิเสธ H_0 อนุกรมที่ไม่นิ่งจะถูกหาผลต่างก่อนการสร้างแบบจำลอง

3.3.3 การปรับค่าข้อมูลให้เป็นมาตรฐาน

เลือกใช้การปรับค่าแบบ Min-Max สำหรับโมเดลการเรียนรู้เชิงลึก โดยปรับขนาดข้อมูลให้อยู่ในช่วง $[0, 1]$

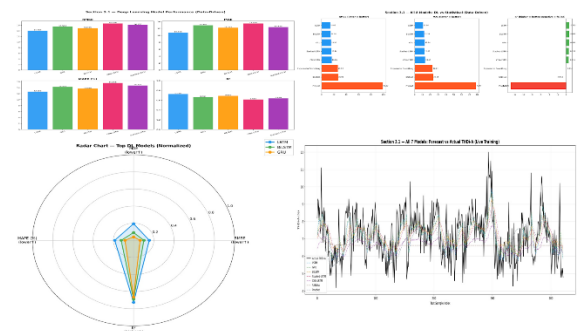
$$x_{\text{normalized}} = (x - x_{\text{min}}) / (x_{\text{max}} - x_{\text{min}})$$

ใช้การปรับค่าแบบ Z-score ($x_{\text{standardized}} = (x - \mu) / \sigma$) เป็นทางเลือกสำหรับข้อมูลที่มีการกระจายแบบปกติ พารามิเตอร์การปรับขนาดคำนวณจากชุดข้อมูลฝึกฝนเท่านั้น เพื่อป้องกันการรั่วไหลของข้อมูล

3.3.4 การสร้างชุดข้อมูล

แบ่งข้อมูลตามลำดับเวลาออกเป็นชุดฝึกฝน (70%), ชุดตรวจสอบ (15%) และชุดทดสอบ (15%) เพื่อรักษาความสัมพันธ์เชิงเวลา สำหรับแบบจำลองการเรียนรู้เชิงลึกวิธีการหน้าต่างเลื่อน (sliding window) สร้างลำดับอินพุต-เอาต์พุต: เมื่อกำหนดช่วงเวลาการมองย้อนหลัง n และช่วงเวลาการพยากรณ์ h อินพุต $X = [y_{t-n}, \dots, y_{t-1}]$ จะถูกแมปไปยังเอาต์พุต $Y = [y_t, \dots, y_{t+h-1}]$ มีการประเมินช่วงเวลาการมองย้อนหลัง 6, 12, 18 และ 24 เดือน โดยใช้ประสิทธิภาพของชุดข้อมูลตรวจสอบและวิเคราะห์ ACF

4. ผลการดำเนินงาน

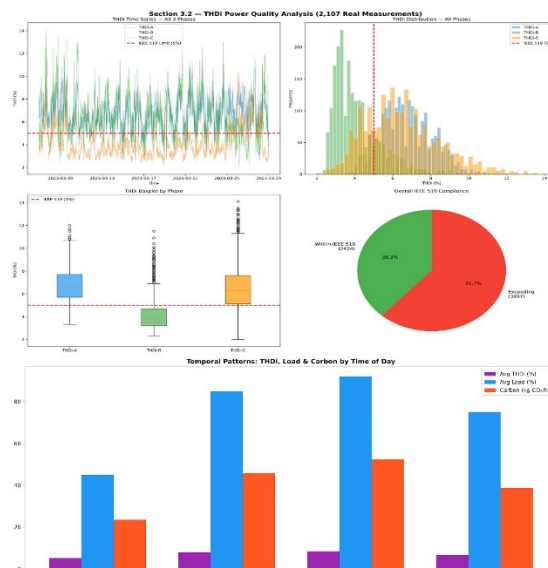


รูปภาพที่ 1 Forecasting Model Performance Comparison (8 Models)

ตาราง 1 Forecasting Model Performance Comparison (8 Models)

Model	Type	RMSE	MAE	MAPE (%)	R ²
LSTM	Deep Learning	14.06	10.86	12.66	0.7254
BiLSTM	Deep Learning	14.96	12.24	13.65	0.6895
GRU	Deep Learning	15.57	12.94	14.23	0.6636
Stacked-LSTM	Deep Learning	16.14	12.43	14.72	0.6385
CNN-LSTM	Deep Learning	16.65	13.47	15.56	0.6152
Exponential Smoothing	Traditional	26.53	22.94	24.95	0.0136
SARIMA	Traditional	26.91	23.64	24.57	-0.0147
Prophet	Traditional	99.33	78.47	78.76	-12.83

งานวิจัยนี้เปรียบเทียบประสิทธิภาพการพยากรณ์ปริมาณการปล่อยคาร์บอนในโรงงานโรงพยาบาล โดยใช้โมเดล Deep Learning 5 แบบ (LSTM, GRU, BiLSTM, Stacked-LSTM, CNN-LSTM) และ โมเดลสถิติ 3 แบบ (SARIMA, Exponential Smoothing, Prophet) ผลการทดสอบพบว่า LSTM ให้ผลดีที่สุดโดยรวม (RMSE = 14.0632, R² = 0.7254) ตามด้วย BiLSTM และ GRU ขณะที่โมเดลสถิติทั้งหมดมีประสิทธิภาพต่ำกว่าอย่างชัดเจน โดย Prophet ให้ค่า R² ติดลบ แสดงถึงความสามารถจับรูปแบบที่ซับซ้อนของข้อมูลได้ LSTM เหนือกว่าโมเดลสถิติที่ดีที่สุดถึง 47% ในค่า RMSE นอกจากนี้ วิธี Stacking Ensemble ให้ผลโดดเด่นที่สุด (RMSE = 0.0221, R² = 0.9892) ดีกว่าโมเดลเดี่ยวถึง 99.84% การทดสอบซ้ำกับชุดข้อมูล THDi ยืนยันผลในทิศทางเดียวกัน ข้อเสนอแนะคือองค์กรควรใช้ LSTM เป็นสถาปัตยกรรมหลัก และใช้ Ensemble สำหรับงานที่ต้องการความแม่นยำสูงสุด



รูปภาพที่ 2 THDi Power Quality Analysis

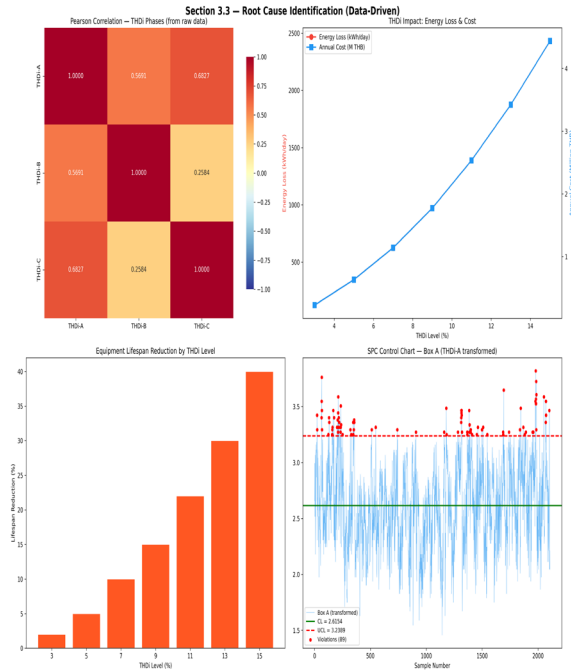
ตารางที่ 2 IEEE 519-2022 Standards

System Voltage	THDi Limit (%)	Individual Harmonic Limit (%)
< 1 kV	5	4
1-69 kV	8	7
69-138 kV	12	11
> 138 kV	15	14

งานวิจัยนี้วิเคราะห์ค่าความเพี้ยนฮาร์มอนิกรวมของกระแส (THDi) จากข้อมูลอนุกรมเวลา 2,107 จุด ในระบบไฟฟ้าสามเฟส เทียบกับมาตรฐาน IEEE 519-2022 (ขีดจำกัด 5% สำหรับระบบต่ำกว่า 1 kV) ผลพบว่าค่าเฉลี่ย THDi ทุกเฟสเกินมาตรฐาน โดยเฟส A เฉลี่ย 6.74% (เกิน 88.8% ของการวัด) เฟส B เฉลี่ย 4.16% (เกิน 20.7%) และเฟส C เฉลี่ย 6.50% (เกิน 75.4%) รวมทั้งระบบเกินมาตรฐาน 61.7% ยืนยันว่าเป็นปัญหาเชิงระบบ

การวิเคราะห์ SPC พบค่า Cpk ทุกเฟสต่ำกว่า 1.0 แสดงว่ากระบวนการไม่สามารถควบคุมได้ตามเกณฑ์ การวิเคราะห์เชิงเวลาพบว่า THDi สัมพันธ์กับโหลด โดยช่วงพีค (12:00-18:00) มีค่าเฉลี่ยสูงถึง 8.45% และปล่อย CO₂ 52.3 kg/hr นอกจากนี้ สหสัมพันธ์ระหว่างเฟสมีนัยสำคัญทางสถิติ แสดง

ว่าแหล่งกำเนิดฮาร์มอนิกส่งผลกระทบต่อพร้อมกันทุกเฟส จึงควรมุ่งแก้ไขที่ต้นเหตุเชิงระบบในช่วงโหลดสูงเป็นลำดับแรก



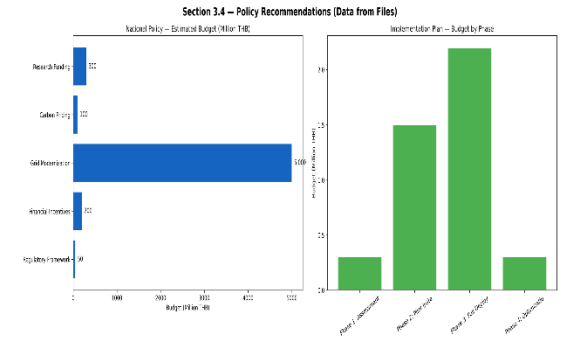
รูปภาพที่ 3 Root Cause Analysis

ตารางที่ 3 THDi Impact on Energy, CO₂ & Cost

THDi Level (%)	Additional Energy Loss (kWh/day)	Additional CO ₂ Emissions (kg/day)	Cost Impact (THB/day)	Annual Cost (Million THB)	Equipment Lifespan Reduction (%)
3	125	64.38	625	0.2280	2
5	347	178.69	1735	0.6330	5
7	625	321.88	3125	1.1410	10
9	972	500.63	4860	1.7740	15
11	1389	715.19	6945	2.5350	22
13	1875	965.63	9375	3.4220	30
15	2431	1,251.94	12155	4.4370	40

งานวิจัยนี้ระบุสาเหตุหลักของความเพี้ยนฮาร์มอนิกและการปล่อยคาร์บอนโดยใช้การวิเคราะห์สถิติหลายมิติ ผลสหสัมพันธ์ Pearson และ Spearman พบว่า THDi ทั้งสามเฟสมีความสัมพันธ์กันอย่างมีนัยสำคัญ (r สูงสุด = 0.6827 ระหว่างเฟส A-C) สอดคล้องกับการทดสอบไคสแควร์ที่ปฏิเสธสมมติฐานความเป็นอิสระทุกคู่เฟส (p < 0.05) บ่งชี้ว่าแหล่งกำเนิดฮาร์มอนิกเป็นแบบ Common-mode เช่น VFD หรือวงจรเรียงกระแสที่บัสสายหลัก มีโซุปกรณ์เฉพาะเฟส

การแปลง Box-Cox ปรับปรุงความเป็นปกติของข้อมูลได้ถึง 97.31% และแผนภูมิควบคุมยืนยันว่าทุกเฟสอยู่นอกการควบคุมทางสถิติ (จุดเกิน UCL สูงสุด 5.36%) แบบจำลองผลกระทบเชิงปริมาณแสดงว่าที่ THDi เฉลี่ย 7% สูญเสียพลังงาน 625 kWh/วัน ปล่อย CO₂ 321.88 kg/วัน คิดเป็น 3,125 บาท/วัน โดยความสัมพันธ์เป็นแบบไม่เชิงเส้น ค่าใช้จ่ายเพิ่มขึ้นเร่งตัวที่ THDi สูง ดังนั้นการแก้ไขตั้งแต่ระดับปานกลางจึงคุ้มค่ากว่าการรออนุปรณ์เสื่อมสภาพ



รูปภาพที่ 4 Multi-Tiered Policy Framework

ตารางที่ 4 Organizational Policies

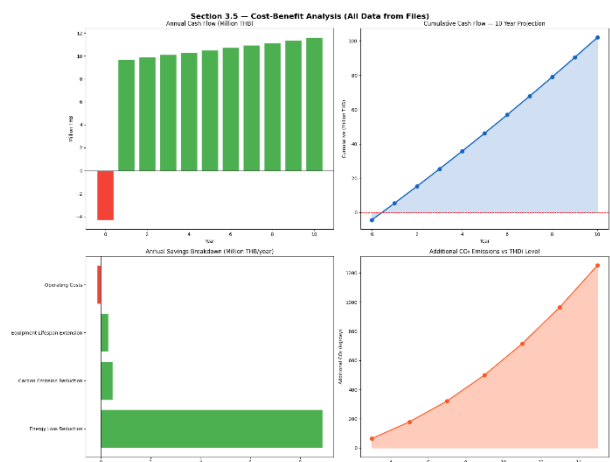
Policy Area	Recommendation	Timeline	Responsible	Priority
Power Quality Standards	Establish internal THDi limits stricter than IEEE 519	Immediate	Engineering	High
Investment Priority	Allocate budget for harmonic mitigation in CAPEX plan	FY2026 Budget	Finance	High
Monitoring Systems	Implement real-time power quality monitoring	Q2 2026	IT/Engineering	High
Training Programs	Train all electrical staff on harmonic issues	Q1-Q2 2026	HR/Engineering	Medium
Maintenance Protocols	Include power quality in preventive maintenance	Q1 2026	Maintenance	Medium

งานวิจัยนี้นำเสนอกรอบนโยบายหลายระดับบนฐานข้อมูลเชิงประจักษ์ ครอบคลุมนโยบายองค์กร 5 ด้าน

นโยบายระดับชาติ 5 ด้าน ตัวชี้วัด 6 รายการ และปัจจัยเสี่ยง 17 ประการ

ระดับองค์กร เสนอให้กำหนดค่า THDi ภายในเข้มกว่ามาตรฐาน IEEE 519 เนื่องจากค่าเฉลี่ยปัจจุบัน (4.16-6.74%) เกินขีดจำกัด 5% โดยตั้งเป้าลดต่ำกว่า 3.0% พร้อมยกระดับประสิทธิภาพพลังงานจาก 85% เป็น 92% และลดคาร์บอนจาก 1,603 เหลือต่ำกว่า 687 ตัน/ปี แผนดำเนินการ 4 ระยะใน 12 เดือน งบประมาณรวม 4.3 ล้านบาท ตั้งแต่การตรวจประเมิน ติดตั้งตัวกรองนําร่อง ขยายผลทั้งระบบ จนถึง การปรับปรุงและติดตามต่อเนื่อง

ระดับชาติ เสนองบประมาณรวม 5,650 ล้านบาท ครอบคลุมการบังคับใช้มาตรฐาน IEEE 519 มาตรการจูงใจทางภาษี การพัฒนาโครงข่ายอัจฉริยะ การเชื่อมโยงคาร์บอนเครดิต และทุนวิจัย ตั้งเป้าครอบคลุมภาคโรงพยาบาล 95%



ภายใน 5 ปี ลด CO₂ ได้ 1 ล้านตัน การบริหารความเสี่ยง 17 ประการครอบคลุมมิติเทคนิค ปฏิบัติการ และการเงิน พร้อมแผนรับมือและมาตรการฉุกเฉิน

รูปภาพที่ 5 Cost-Benefit Analysis

ตารางที่ 5 Annual Savings Breakdown

Category	Savings (THB/year)	Savings (Million THB/year)
Energy Loss Reduction	8,900,000.00	8.9000
Carbon Emission Reduction	471,642.15	0.4716
Equipment Lifespan Extension	302,343.16	0.3023
Operating Costs	-150,000.00	-0.1500
Net Annual Savings	9,523,985.31	9.5240

งานวิจัยนี้วิเคราะห์ความคุ้มค่าทางเศรษฐศาสตร์ของการลงทุนแก้ไขปัญหาฮาร์โมนิก มูลค่ารวม 4.3 ล้านบาท โดยคาดการณ์ผลตอบแทนสุทธิ 9.524 ล้านบาท/ปี แบ่งเป็นการลดการสูญเสียพลังงาน 8.900 ล้านบาท การลดคาร์บอน 0.472 ล้านบาท และการยืดอายุอุปกรณ์ 0.302 ล้านบาท หักต้นทุนดำเนินงาน 0.150 ล้านบาท ระยะคืนทุนต่ำกว่า 1 ปี กระแสเงินสดสะสม 10 ปีสูงถึง 102.07 ล้านบาท

ที่ THDi เฉลี่ย 7% โรงงานสูญเสียพลังงานเพิ่ม 625 kWh/วัน และ CO₂ ส่วนเกิน 321.88 kg/วัน คิดเป็น 3,125 บาท/วัน การลด THDi จาก 7% เหลือ 5% สามารถเก็บเกี่ยวผลประโยชน์ได้ถึง 45% เนื่องจากความสัมพันธ์แบบไม่เชิงเส้น กรณีศึกษา ระดับสากลจาก Siemens, Toyota, Intel และ Petrochemical ลิงคโพร่ ยืนยันระยะคืนทุนเฉลี่ย 2.0 ปี

ด้านการพยากรณ์ โมเดล Deep Learning (LSTM) เหนือกว่าโมเดลสถิติ 47% ในค่า RMSE สนับสนุนการลงทุนโครงสร้างพื้นฐาน GPU สำหรับงานที่ความแม่นยำส่งผลต่อการตัดสินใจทางการเงินโดยตรง

4. สรุปผล

งานวิจัยระบุข้อจำกัด 5 ประการพร้อมแนวทางแก้ไขในอนาคต ด้านขอบเขตข้อมูลจำกัดเพียงสถานประกอบการเดียว (ผลกระทบปานกลาง) เสนอขยายสู่การศึกษาหลายแห่ง ด้านการวางนัยทั่วไปของโมเดลที่ฝึกจากชุดข้อมูลเฉพาะ (ผลกระทบปานกลาง) เสนอใช้ Transfer Learning ด้านปัจจัยภายนอก เช่น สภาพอากาศและฤดูกาลยังไม่ถูกรวมในโมเดล (ผลกระทบต่ำ) เสนอขยายชุดข้อมูล ด้านข้อจำกัดเวลาที่เก็บข้อมูลเพียง 1 ปี (ผลกระทบปานกลาง) เสนอศึกษาระยะยาว และด้านวิวัฒนาการเทคโนโลยีที่เปลี่ยนแปลงรวดเร็ว (ผลกระทบต่ำ) เสนอปรับปรุงโมเดลอย่างต่อเนื่อง

ตัวชี้วัดสมรรถนะ 6 รายการกำหนดเป้าหมายชัดเจน ได้แก่ ลด THDi จาก 7.0% เหลือ 3.0% ประหยัดพลังงาน 1.8 MWh/ปี ลดต้นทุน 9.5 ล้านบาท ลดคาร์บอนจาก 1,603 เหลือ 687 ตัน (ลด 57%) เพิ่มความน่าเชื่อถืออุปกรณ์เป็น 98% และบรรลุ IEEE 519 ครบ 100% ภายใน 1 ปี ตัวชี้วัดทุกรายการมีสถานะพร้อมติดตามผลต่อเนื่อง

ตารางที่ 6 สรุปผล

Indicator	Baseline	6-Month Target	1-Year Target	Measurement	Status
THDi Reduction	7.0%	5.0%	3.0%	Continuous	Track
Energy Savings	0 kWh	0.9 MWh	1.8 MWh	Daily	Track
Cost Savings	0 THB	4.8 M THB	9.5 M THB	Monthly	Track
Carbon Reduction	1,603 tonnes	1,145 tonnes	687 tonnes	Monthly	Track
Equipment Reliability	92%	94%	98%	Quarterly	Track
IEEE Compliance	75%	90%	100%	Continuous	Track

5. เอกสารอ้างอิง

[1] IEC. IEC 61000-4-7:2002. Electromagnetic compatibility (EMC) – Part 4-7: Testing and measurement techniques – General guide on harmonics and interharmonics measurements and instrumentation. Geneva: International Electrotechnical Commission; 2002.

[2] IEEE. IEEE Std 519-2014. IEEE recommended practice and requirements for harmonic control in electric power systems. New York: Institute of Electrical and Electronics Engineers; 2014.

[3] IEEE. IEEE Std 1159-2019. IEEE recommended practice for monitoring electric power quality. New York: Institute of Electrical and Electronics Engineers; 2019.

[4] ISO. ISO 14064-1:2018. Greenhouse gases – Part 1: Specification with guidance at the organization level for quantification and reporting of greenhouse gas emissions and removals. Geneva: International Organization for Standardization; 2018.

[5] Alhussein M, Aurangzeb K, Haider SI. Hybrid CNN-LSTM model for short-term individual household load forecasting. IEEE Access. 2020;8:180544-180557.

[6] Cho K, Van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F, Schwenk H, Bengio Y. Learning phrase representations using RNN encoder-decoder for statistical machine translation. In: Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing; 2014; Doha, Qatar. p.1724-1734.

[7] Hochreiter S, Schmidhuber J. Long short-term memory. Neural Comput. 1997;9(8):1735-1780.

[8] Kim TY, Cho SB. Predicting residential energy consumption using CNN-LSTM neural networks. Energy. 2019;182:72-81.

[9] Kong WY, Dong ZY, Jia Y, Hill DJ, Xu Y, Zhang Y. Short-term residential load forecasting based on LSTM recurrent neural network. IEEE Trans Smart Grid. 2019;10(1):841-851.

[10] Livieris IE, Pintelas E, Pintelas P. A CNN-LSTM model for gold price time-series forecasting. Neural Comput Appl. 2020;32(23):17351-17360.

[11] Schuster M, Paliwal KK. Bidirectional recurrent neural networks. IEEE Trans Signal Process. 1997;45(11):2673-2681.

[12] Siami-Namini S, Tavakoli N, Siami Namin A. A comparative analysis of forecasting financial time series using ARIMA, LSTM, and BiLSTM. In: Proceedings of the 2019 IEEE International Conference on Big Data; 2019; Los Angeles, USA. p.3104-3112.

[13] Sun W, Huang C, Wu J, Zhang H. Carbon emission forecasting model based on wavelet transform and LSTM neural network. J Clean Prod. 2020;262:121400.

[14] Zhao J, Liu X, Wang Z. Bidirectional LSTM-based electricity consumption forecasting. Energy. 2017;126:123-132.

[15] Alam T, Mahmud MS, Hasan MM. Forecasting carbon dioxide emissions in Bangladesh using SARIMA model. Environ Sci Pollut Res. 2021;28(34):46915-46927.

[16] Cerqueira V, Torgo L, Mozetič I. Evaluating time series forecasting models: An empirical study on performance estimation methods. Mach Learn. 2020;109(11):1997-2028.

[17] Taylor SJ, Letham B. Forecasting at scale. Am Stat. 2018;72(1):37-45.

[18] Tong C, Li J, Lang C. An efficient deep model for day-ahead electricity load forecasting. J Parallel Distrib Comput. 2018;117:267-273.

[19] Triebe O, Hewamalage H, Pilyugina P, Laptev N, Bergmeir C, Rajagopal R. NeuralProphet: Explainable forecasting at scale. arXiv [preprint]. 2021.

[20] Emanuel AE. Power definitions and the physical mechanism of power flow. IEEE Trans Power Deliv. 2018;33(4):1977-1984.

[21] Jain S, Singh SP. A comparative analysis of passive and active power filter for harmonic mitigation in distribution systems. Electr Power Syst Res. 2020;189:106803.

[22] Kumar D, Zare F, Ghosh A. Analysis and mitigation of harmonic distortion in industrial power systems with VFD. IEEE Trans Ind Appl. 2021;57(3):2648-2657.

[23] Mohd Zin AA, Saini M, Shariati O. An analytical approach to estimate harmonic losses in distribution systems. Int J Electr Power Energy Syst. 2020;122:106184.

[2 4] Rashid M, Rashid M. Effect of harmonics on transformer loss of life. *Electr Power Compon Syst.* 2020;48(9-10):1037-1047.

[2 5] Singh B, Al-Haddad K, Chandra A. A review of active filters for power quality improvement. *IEEE Trans Ind Electron.* 1999;46(5):960-971.

[2 6] Chatthaworn R, Chaitusaney S, Yokoyama R. Harmonic distortion analysis in Thai industrial power distribution systems. *IEEJ Trans Electr Electron Eng.* 2019;14(5):703-712.

[2 7] Phuttitarn N, Kumhom P, Chamnanphrai K. Power quality assessment and harmonic mitigation in Thai healthcare facilities. *IEEE Access.* 2021;9:134521-134533.

[2 8] Silalertruksa T, Gheewala SH. Life cycle carbon footprint of food industry in Thailand. *J Clean Prod.* 2018;184:1089-1099.

[2 9] Wangpattarapong K, Maneewan S, Ketjoy N, Rakwichian W. The impact of climatic and economic factors on residential electricity consumption in Thailand. *Renew Sustain Energy Rev.* 2020;132:110110.

[3 0] Campos-Guzmán V, García-Cáscales MS, Espinosa N, Urbina A. Methods for financial assessment of renewable energy projects: A review. *Processes.* 2022;10(2):184.

[3 1] Cotfas PA, Cotfas DT, Machidon OM. Analysis of operating regimes and THD forecasting in steelmaking plant power systems using advanced neural architectures. *Mathematics.* 2025;13(22):3692.

[3 2] Karadeniz A. Advanced harmonic forecasting in offshore wind farms using hybrid deep and machine learning architecture. *IET Renew Power Gener.* 2025.

[3 3] Karmellos M, Kiprakis A, Mavrotas G. Dynamic cost-benefit analysis of digitalization in the energy industry. *Engineering.* 2024.

[3 4] Marques L, Fuinhas JA, Marques AC. From investment to net benefits: A review of guidelines and methodologies for cost-benefit analysis in the electricity sector. *Energy Res Soc Sci.* 2025.

[3 5] Paredes HMS, Brandão DI, Marafão FP. Towards technical and economic feasibility of power quality compensators. *Electr Power Syst Res.* 2022.

[3 6] Pita P, Winyuchakrit P, Limmeechokchai B. Thailand's net-zero emissions by 2050: Analysis of economy-wide impacts. *Front Energy Res.* 2023;11.

[3 7] Wang X, Zhao L, Liu Z. Practical effects of carbon emissions trading system on energy efficiency. *Sci Rep.* 2024;14.

ปัจจัยกำหนดความน่าจะเป็นของการผิดนัดชำระหนี้ของผู้ซื้อรถยนต์ จากข้อมูลเชิงธุรกรรม

Determinants of Probability of Default in Automobile Hire-Purchase Based on Transactional Data

วันหยก อติเศรษฐพงศ์ *

สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์ 12120

(* wanyok@mathstat.sci.tu.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์ปัจจัยที่กำหนดความเสี่ยงในการผิดนัดชำระหนี้ของผู้ซื้อรถยนต์ โดยใช้ข้อมูลเชิงธุรกรรมระดับรายบุคคลจากสัญญาเช่าซื้อรถยนต์จำนวน 4,990 สัญญา ที่ได้รับการอนุมัติในช่วงปี พ.ศ. 2567–2568 ข้อมูลถูกนำมาวิเคราะห์ด้วยแบบจำลองถดถอยโลจิสติกแบบถ่วงน้ำหนัก เพื่อจัดการกับปัญหาความไม่สมดุลของข้อมูล เนื่องจากกลุ่มผู้ผิดนัดมีสัดส่วนเพียงร้อยละ 4.85 ของตัวอย่างทั้งหมด การประเมินแบบจำลองใช้การแบ่งข้อมูลฝึกสอนและทดสอบแบบคงสัดส่วน (70:30) และประเมินประสิทธิภาพในการจำแนกโดยใช้เส้นโค้ง Receiver Operating Characteristic (ROC) ผลการศึกษาแสดงให้เห็นว่า ปัจจัยด้านอาชีพ อายุ การมีผู้ค้ำประกัน และวงเงินสินเชื่อมีความสัมพันธ์กับความเสี่ยงในการผิดนัดชำระหนี้อย่างมีนัยสำคัญ โดยผู้ขอสินเชื่อที่มีอาชีพมั่นคง เช่น ข้าราชการ พนักงานเอกชน และรัฐวิสาหกิจ มีความเสี่ยงต่ำกว่ากลุ่มธุรกิจส่วนตัว ขณะเดียวกันการมีผู้ค้ำประกันและการอยู่ในช่วงอายุ 31–60 ปีช่วยลดโอกาสผิดนัดชำระหนี้ในด้านเงินกู้ สัญญา พบว่าวงเงินสินเชื่อที่สูงขึ้นเพิ่มความเสี่ยงในการผิดนัดชำระหนี้ ในขณะที่การเลือกผ่อนระยะสั้นช่วยลดความเสี่ยงได้อย่างมีนัยสำคัญ ผลการประเมินแบบจำลองให้ค่าพื้นที่ใต้เส้นโค้ง (Area Under the Curve: AUC) เท่ากับ 0.597 สะท้อนว่าแบบจำลองสามารถจำแนกความเสี่ยงได้ดีกว่าการสุ่ม แต่ยังคงมีความสามารถในการจำแนกที่ค่อนข้างจำกัด งานวิจัยนี้เสนอให้ใช้แบบจำลองดังกล่าวเป็นเครื่องมือคัดกรองความเสี่ยงเบื้องต้น เพื่อสนับสนุนการบริหารความเสี่ยงด้านสินเชื่อของสถาบันการเงิน

คำสำคัญ: ความเสี่ยงด้านเครดิต, การผิดนัดชำระหนี้, สินเชื่อเช่าซื้อรถยนต์

Abstract

This study aims to analyze the determinants of default risk among automobile buyers using individual-level transactional data from 4,990 hire-purchase contracts approved between 2024 and 2025. The data was analyzed using a weighted logistic regression model to address the class imbalance problem, as the default group constituted only 4.85% of the total sample. Model evaluation employed a stratified training-testing split (70:30), and classification performance was assessed using the Receiver Operating Characteristic (ROC) curve. The empirical results indicate that occupation, age, guarantor presence, and loan amount are significantly associated with default risk. Specifically, borrowers with stable occupations—such as government officials, private sector employees, and state enterprise employees—exhibit lower risk compared to business owners. Concurrently, the presence of a guarantor and being in the 31–60 age bracket contribute to a reduction in default probability. Regarding contract terms, higher loan amounts were found to increase default risk, whereas opting for shorter installment periods significantly mitigates this risk. The model evaluation yielded an Area Under the Curve (AUC) value of 0.597, indicating a risk discrimination ability that is better than random but remains limited. This study suggests utilizing the proposed model as a preliminary risk screening tool to support credit risk management in financial institutions.

Keywords: Credit Risk, Loan Default, Automobile Hire-Purchase

1. บทนำ

สินเชื่อเพื่อการอุปโภคบริโภคเป็นกลไกพื้นฐานที่มีบทบาทสำคัญในการขับเคลื่อนกิจกรรมทางเศรษฐกิจของประเทศไทย โดยเฉพาะสินเชื่อเช่าซื้อรถยนต์และสินเชื่อที่มีทะเบียนรถเป็นประกัน ซึ่งครองสัดส่วนที่มีนัยสำคัญในพอร์ตสินเชื่อรายย่อยของทั้งธนาคารพาณิชย์และผู้ประกอบธุรกิจที่มีใช้สถาบันการเงิน (Non-bank) อย่างไรก็ตามภายใต้บริบทของความผันผวนทางเศรษฐกิจและระดับหนี้ครัวเรือนที่ยังคงอยู่ในระดับสูง ภาคสินเชื่อดังกล่าวเริ่มเผชิญกับความเสี่ยงด้านคุณภาพลูกหนี้ที่เพิ่มขึ้นอย่างต่อเนื่อง

ข้อมูลล่าสุดสะท้อนให้เห็นว่าสินเชื่อเช่าซื้อรถยนต์เป็นหนึ่งในกลุ่มที่ได้รับผลกระทบอย่างชัดเจน โดยมูลค่าหนี้ที่ไม่ก่อให้เกิดรายได้ (NPLs) ในภาคสินเชื่อยานยนต์ปรับตัวสูงขึ้นจนแตะระดับ 260,000 ล้านบาทในปี 2567 [1] สถานการณ์ดังกล่าวชี้ให้เห็นถึงความเปราะบางของความสามารถในการชำระหนี้ของผู้กู้บางส่วน ซึ่งได้รับแรงกดดันจากภาวะเศรษฐกิจที่ไม่แน่นอนและข้อจำกัดด้านรายได้ในช่วงที่ผ่านมา ความเสี่ยงในการผิดนัดชำระหนี้ที่เพิ่มสูงขึ้นนี้ทำให้สถาบันการเงินจำเป็นต้องมีเครื่องมือในการประเมินความเสี่ยงด้านเครดิตของผู้ขอสินเชื่อรายใหม่ที่มีประสิทธิภาพ

นอกจากนี้ สถิติสินเชื่อภาคครัวเรือนยังชี้ให้เห็นถึงการชะลอตัวในกลุ่มสัญญาเช่าซื้อรถยนต์และรถจักรยานยนต์อย่างมีนัยสำคัญ โดยยอดสินเชื่อคงค้างในกลุ่มดังกล่าวได้ปรับตัวลงอย่างต่อเนื่องตั้งแต่ไตรมาส 1 ปี 2567 ถึงไตรมาส 2 ปี 2568 เป็นระยะเวลา 6 ไตรมาสติดต่อกัน โดยลดลงจากประมาณ 1.76 ล้านล้านบาท เหลือเพียง 1.55 ล้านล้านบาท [2] ในขณะที่สัดส่วนหนี้ครัวเรือนต่อ GDP โดยรวมยังคงอยู่ในระดับสูงระหว่างร้อยละ 86.8 ถึง 90.7 การลดลงของสินเชื่อใหม่นี้สะท้อนให้เห็นถึงความระมัดระวังที่เพิ่มขึ้นในการอนุมัติสินเชื่อของสถาบันการเงิน ท่ามกลางความกังวลต่อคุณภาพลูกหนี้และความสามารถในการชำระคืนภายใต้ภาวะเศรษฐกิจที่ผันผวน

ถึงแม้ว่าจะมีงานวิจัยที่พยายามอธิบายการผิดนัดชำระหนี้โดยเชื่อมโยงลักษณะของผู้กู้ (เช่น อายุ อาชีพ และความมั่นคงของรายได้) กับเงื่อนไขของสัญญาสินเชื่อ (เช่น สัดส่วนวงเงินกู้ต่อมูลค่าหลักประกัน และระยะเวลาการผ่อนชำระ) อย่างไรก็ดี ข้อค้นพบเชิงประจักษ์ยังคงมีความแตกต่างกันไปตามบริบท และช่วงเวลาในการศึกษา

นอกจากนี้ งานวิจัยที่ผ่านมาในบริบทประเทศไทยส่วนใหญ่ใช้ข้อมูลในช่วงเวลาที่ผ่านมา ซึ่งอาจไม่สะท้อนพฤติกรรมชำระหนี้ระดับรายบุคคลภายใต้ภาวะเศรษฐกิจที่มีความผันผวนล่าสุด อีกทั้งยังมีข้อจำกัดในการจัดการปัญหาความไม่สมดุลของข้อมูล ซึ่งเป็นลักษณะสำคัญของข้อมูลการผิดนัดชำระหนี้ในทางปฏิบัติ ดังนั้นจึงยังขาดงานศึกษาที่ใช้ข้อมูลเชิงธุรกรรมระดับรายบุคคลในช่วงเวลาปัจจุบัน พร้อมทั้งประยุกต์ใช้วิธีการทางสถิติที่เหมาะสมกับโครงสร้างข้อมูลดังกล่าวอย่างเป็นระบบ

ดังนั้นการยกระดับประสิทธิภาพและความแม่นยำของระบบประเมินความเสี่ยงด้านเครดิต ผ่านการวิเคราะห์ปัจจัย

กำหนดพฤติกรรมชำระหนี้ในระดับรายบุคคล โดยอาศัยฐานข้อมูลเชิงประจักษ์ จึงมีความจำเป็นอย่างยิ่งต่อการบริหารจัดการความเสี่ยงในบริบททางเศรษฐกิจปัจจุบัน

งานวิจัยนี้ได้นำชุดข้อมูลธุรกรรมของผู้ได้รับอนุมัติสินเชื่อในช่วงปี พ.ศ. 2567–2568 จำนวน 4,990 ราย จากบริษัท แอคซิวเรียล บิสซิเนส โซลูชั่น จำกัด มาใช้เป็นที่ศึกษา เพื่อวิเคราะห์ปัจจัยของคุณลักษณะผู้ขอสินเชื่อและเงื่อนไขสัญญาสินเชื่อที่มีต่อความน่าจะเป็นในการผิดนัดชำระหนี้ โดยมุ่งเน้นการสร้างแบบจำลองทางสถิติที่สามารถจำแนกความเสี่ยงได้อย่างชัดเจน ซึ่งผลลัพธ์ที่ได้จะเป็นแนวทางสำคัญในการกำหนดนโยบายสินเชื่อและการประเมินมูลค่าหลักประกันที่สอดคล้องกับสถานการณ์ในปัจจุบันมากที่สุด

2. ทบทวนวรรณกรรม

ผู้วิจัยได้ศึกษางานวิจัยที่เกี่ยวข้อง เพื่อสร้างกรอบแนวคิดเรื่องปัจจัยเสี่ยงสินเชื่อเช่าซื้อรถยนต์ โดยเน้นวิเคราะห์อิทธิพลของคุณลักษณะผู้กู้และเงื่อนไขสัญญาที่มีต่อโอกาสในการผิดนัดชำระหนี้ โดยมีรายละเอียดดังนี้

งานวิจัยของนิภาพรณ์ พจนชัยธรรม [3] ได้นำเสนอการวิเคราะห์ระบบให้คะแนนสินเชื่อ เพื่อคัดเลือกรายชื่อผู้ขอสินเชื่อเช่าซื้อรถยนต์ใหม่ โดยอาศัยแบบจำลองโพรบิต (Probit Model) เพื่อประมาณความน่าจะเป็นที่ลูกหนี้จะเป็นลูกหนี้ที่มีคุณภาพ ผลการศึกษาพบว่าแบบจำลองดังกล่าวสามารถจำแนกความเสี่ยงของลูกหนี้ได้อย่างมีประสิทธิภาพ โดยตัวแปรสำคัญที่ส่งผลต่อคุณภาพลูกหนี้ ได้แก่ รายได้ อายุ ภาระหนี้ ประวัติการชำระหนี้ สถานภาพสมรส ระดับการศึกษา และลักษณะการอยู่อาศัย ทั้งนี้แบบจำลองให้ผลความแม่นยำในการพยากรณ์สูงและสะท้อนความสอดคล้องระหว่างคะแนนสินเชื่อกับคุณภาพลูกหนี้ที่เกิดขึ้นจริง

ในทำนองเดียวกัน งานวิจัยของวิภากรัตน์ พิพัฒน์ไพศาล [4] ได้ทำการศึกษาปัจจัยที่มีผลต่อการเกิดหนี้ค้างชำระในสินเชื่อเช่าซื้อรถยนต์ของบริษัทเงินทุนแห่งหนึ่ง โดยใช้แบบจำลองโพรบิตและการวิเคราะห์เชิงพรรณนา ผลการศึกษาพบว่าปัจจัยด้านเพศ อาชีพ และระดับรายได้มีความสัมพันธ์กับโอกาสในการค้างชำระหนี้ โดยผู้มีรายได้ต่ำและผู้ประกอบอาชีพรับจ้างมีแนวโน้มผิดนัดชำระหนี้สูงกว่ากลุ่มอื่น งานวิจัยนี้สะท้อนถึงบทบาทสำคัญของความมั่นคงทางรายได้ในการอธิบายพฤติกรรมชำระหนี้ของลูกหนี้เช่าซื้อ

ต่อมา งานวิจัยของรัฐวิษณุ จิรพัฒน์วงศ์ [5] ได้พัฒนาระบบคะแนนสินเชื่อสำหรับสินเชื่อเช่าซื้อรถยนต์ภายใต้นโยบายค้ำประกันรถยนต์คันแรก โดยใช้ข้อมูล Panel Data และ Random Effect Ordered Probit Model ผลการศึกษาชี้ให้เห็นว่าระบบคะแนนสินเชื่อสามารถช่วยจำแนกคุณภาพลูกหนี้ได้อย่างมีประสิทธิภาพ และให้ผลดีกว่าวิธีการพิจารณาสินเชื่อแบบดั้งเดิม ขณะที่งานของชวัญทัย ฤทธิ [6] ซึ่งศึกษาการผิดนัดชำระค่างวดในธุรกิจเช่าซื้อรถจักรยานยนต์โดยใช้แบบจำลองโลจิสติก พบว่าปัจจัยด้านเพศ อายุ อาชีพ รายได้

วงเงินสินเชื่อ ระยะเวลาผ่อนชำระ และผู้ค้ำประกัน ล้วนมีอิทธิพลต่อความน่าจะเป็นในการคิดนัดชำระหนี้

งานวิจัยที่กล่าวมาข้างต้นสนับสนุนแนวคิดว่าการใช้ระบบให้คะแนนสินเชื่อบนพื้นฐานข้อมูลเชิงประจักษ์สามารถช่วยลดความเสี่ยงในการคิดนัดชำระหนี้ และเป็นเครื่องมือสำคัญในการบริหารความเสี่ยงด้านเครดิตของธุรกิจสินเชื่อเช่าซื้อรถยนต์

3. ระเบียบวิธีวิจัย

3.1 การเตรียมข้อมูลและสถิติเชิงพรรณนา

งานวิจัยนี้ใช้ข้อมูลเชิงธุรกรรมของผู้กู้จำนวน 4,990 ราย โดยสามารถจำแนกออกเป็น 4 ด้านหลัก ได้แก่ (1) ข้อมูลของ

ผู้ขอสินเชื่อ ซึ่งประกอบด้วยเพศ อายุ อาชีพ และรายได้ต่อเดือน (2) ข้อมูลรถยนต์ ซึ่งประกอบด้วยประเภทรถยนต์ยี่ห้อ รุ่น ลักษณะรถ สี ขนาดเครื่องยนต์ และปีที่ผลิต (3) ข้อมูลการผ่อนชำระ ซึ่งประกอบด้วยอัตราดอกเบี้ย จำนวนงวดทั้งหมด ราคารถยนต์ ค่างวดต่อเดือน ยอดเงินที่ชำระแล้ว ยอดเงินคงเหลือ จำนวนงวดที่ค้างชำระ เบี้ยปรับ และจำนวนวันที่ขาดการติดต่อ (4) ข้อมูลผู้ค้ำประกัน ซึ่งประกอบด้วยอาชีพและข้อมูลสำหรับการติดต่อ

ภายหลังจากการทำความสะอาดข้อมูล ผู้วิจัยได้คัดเลือกตัวแปรที่เกี่ยวข้องกับการประเมินความเสี่ยงด้านเครดิต โดยมีรายละเอียดดังตารางที่ 1

ตารางที่ 1: รายละเอียดตัวแปรที่ใช้ในงานวิจัย

สัญลักษณ์	ชื่อตัวแปร	คำอธิบายและวิธีวัดค่า	ประเภทตัวแปร
ตัวแปรตาม (Dependent Variables)			
Y	สถานะการคิดนัดชำระหนี้	0 = ปกติ (ชำระตามเวลาหรือผิดนัดไม่เกิน 90 วัน) 1 = คิดนัดชำระหนี้ (ค้างชำระเกิน 90 วัน)	Binary (Dummy)
ตัวแปรต้น (Independent Variables)			
X_1	เพศ	0 = เพศชาย 1 = เพศหญิง	Binary (Dummy)
X_2	รายได้ต่อเดือน	รายได้รวมต่อเดือนของผู้กู้ (หน่วย: บาท)	Continuous
$X_{3, ref}$	อาชีพธุรกิจส่วนตัว	กลุ่มอ้างอิง	-
X_{31}	อาชีพรับราชการ	1 = รับราชการ 0 = อื่น ๆ	Binary (Dummy)
X_{32}	อาชีพพนักงานเอกชนหรือรัฐวิสาหกิจ	1 = พนักงานบริษัทเอกชนหรือรัฐวิสาหกิจ 0 = อื่น ๆ	Binary (Dummy)
X_{33}	อาชีพเกษตรกร หรืออาชีพอิสระ	1 = เกษตรกรหรืออาชีพอิสระ 0 = อื่น ๆ	Binary (Dummy)
X_4	การมีผู้ค้ำประกัน	1 = มีบุคคลค้ำประกัน 0 = ไม่มีบุคคลค้ำประกัน	Binary (Dummy)
X_5	ช่วงอายุ	1 = อายุ 31-60 ปี (เนื่องจากเป็นช่วง 31-60 ปี บริษัทประเมินมูลค่าสินทรัพย์ถือว่าเป็นวัยทำงานที่มีเสถียรภาพด้านรายได้และความสามารถในการชำระหนี้สูงกว่ากลุ่มอายุอื่น) 0 = นอกช่วงอายุดังกล่าว	Binary (Dummy)
X_6	อัตราดอกเบี้ย	อัตราดอกเบี้ยเงินกู้ตามสัญญา (หน่วย: ร้อยละต่อปี)	Continuous
X_7	วงเงินสินเชื่อ	ยอดเงินต้นที่ได้รับอนุมัติ (หน่วย: บาท)	Continuous
X_{81}	งวดการผ่อนชำระ: 36 งวด	1 = สัญญา 36 งวด 0 = อื่น ๆ	Binary (Dummy)
X_{82}	งวดการผ่อนชำระ: 48 งวด	1 = สัญญา 48 งวด 0 = อื่น ๆ	Binary (Dummy)
X_{83}	งวดการผ่อนชำระ: 60 งวด	1 = สัญญา 60 งวด 0 = อื่น ๆ	Binary (Dummy)
$X_{8, ref}$	งวดการผ่อนชำระ: 72 งวด	กลุ่มอ้างอิง	-
X_9	จำนวนเงินที่ชำระแล้ว	ยอดเงินสะสมที่ผู้กู้ได้ชำระคืนมาแล้ว (หน่วย: บาท)	Continuous

ตัวแปรต้นที่นำมาใช้ในการวิเคราะห์ประกอบด้วยข้อมูลของผู้ขอสินเชื่อ ได้แก่ เพศ รายได้ต่อเดือน อาชีพ การมีผู้ค้ำประกัน ช่วงอายุ ข้อมูลด้านการผ่อนชำระ ได้แก่ อัตราดอกเบี้ย วงเงิน

สินเชื่อ จำนวนงวดการผ่อนชำระ และจำนวนเงินที่ชำระแล้ว ในขณะที่ตัวแปรตามคือความน่าจะเป็นในการคิดนัดชำระหนี้ของผู้กู้ โดยถือว่าผู้กู้มีสถานะผิดนัดชำระหนี้ เมื่อมีการผิดนัด

ชำระเกิน 90 วัน และมีสถานะปกติ หากผู้ชำระหนี้ตามเวลา หรือผิดนัดชำระไม่เกิน 90 วัน โดยการจำแนกสถานะผู้กู้จาก กำหนดเวลาค้างชำระ 90 วันเป็นไปตามหลักเกณฑ์การจัดชั้น สินทรัพย์ของธนาคารแห่งประเทศไทย [7]

สถิติเชิงพรรณนาของข้อมูลทั้งหมดสามารถสรุปได้ดังนี้

ในด้านตัวแปรเชิงปริมาณ ผู้กู้มีรายได้เฉลี่ยต่อเดือนเท่ากับ 47,627.36 บาท โดยมีค่ามัธยฐานอยู่ที่ 31,955 บาท แสดงให้เห็นถึงการกระจายของรายได้ที่มีลักษณะเบ้ขวา (ผู้กู้ส่วนใหญ่ มีรายได้ต่ำกว่าค่าเฉลี่ย) อัตราดอกเบี้ยเฉลี่ยอยู่ที่ร้อยละ 13.84 ต่อปี วงเงินสินเชื่อเฉลี่ยอยู่ที่ 542,546.91 บาท ขณะที่จำนวนเงินที่ชำระแล้วเฉลี่ยอยู่ที่ 76,764.10 บาท

สำหรับลักษณะเชิงโครงสร้างของผู้กู้ พบว่าผู้กู้เพศหญิง คิดเป็นร้อยละ 56.37 ด้านอาชีพ ผู้กู้ส่วนใหญ่อยู่ในกลุ่มธุรกิจ

ส่วนตัวคิดเป็นร้อยละ 32.08 (กำหนดให้เป็นกลุ่มอ้างอิง) รองลงมาคือข้าราชการร้อยละ 26.71 พนักงานบริษัทเอกชน หรือรัฐวิสาหกิจร้อยละ 25.05 และเกษตรกรหรืออาชีพอิสระ ร้อยละ 16.15 นอกจากนี้ ผู้กู้ที่มีผู้ค้ำประกันคิดเป็นร้อยละ 16.79 และผู้กู้ที่มีอายุอยู่ในช่วง 31–60 ปีคิดเป็นร้อยละ 13.49

ในด้านโครงสร้างสัญญาสินเชื่อ พบว่าสัญญาที่มี ระยะเวลาผ่อนชำระ 72 งวดมีสัดส่วนสูงที่สุดคิดเป็นร้อยละ 41.54 (กำหนดให้เป็นกลุ่มอ้างอิง) รองลงมาคือ 60 งวดร้อยละ 27.07 และ 48 งวดร้อยละ 25.65 ขณะที่สัญญา 36 งวดมี สัดส่วนน้อยที่สุดที่ร้อยละ 5.73

สถิติเชิงพรรณนาของผู้ขอสินเชื่อเมื่อจำแนกตาม สถานะการผิดนัดชำระหนี้แสดงได้ดังตารางที่ 2

ตารางที่ 2: สถิติเชิงพรรณนา จำแนกตามสถานะการผิดนัดชำระหนี้

ตัวแปร	สถานะปกติ (4,757 ราย)	สถานะค้างชำระ (242 ราย)	p-value
เพศหญิง (%)	56.42%	55.37%	0.7984
รายได้ต่อเดือน (บาท)	47,190.72 ± 158,495.34	56,194.29 ± 79,876.85	0.1105
อาชีพ: ธุรกิจส่วนตัว (%)	31.54%	42.98%	0.0003
อาชีพ: ข้าราชการ (%)	26.85%	23.96%	0.3600
อาชีพ: เอกชน/รัฐวิสาหกิจ (%)	25.48%	16.53%	0.0022
อาชีพ: เกษตรกร/อาชีพอิสระ (%)	16.13%	16.53%	0.9413
มีผู้ค้ำประกัน (%)	17.17%	9.50%	0.0025
อายุ 31–60 ปี (%)	13.61%	11.16%	0.3215
อัตราดอกเบี้ย (%)	13.85 ± 1.98	13.75 ± 1.95	0.4568
วงเงินสินเชื่อ (บาท)	539,245.62 ± 225,670.36	607,317.67 ± 249,245.65	<0.001
งวด 36 งวด (%)	5.86%	3.31%	0.1279
งวด 48 งวด (%)	25.78%	23.14%	0.4001
งวด 60 งวด (%)	27.02%	28.10%	0.7690
งวด 72 งวด (%)	41.34%	45.45%	0.2305
ยอดชำระแล้ว (บาท)	76,402.37 ± 66,682.14	83,861.14 ± 65,255.94	0.0843

จากตารางที่ 2 พบว่าตัวแปรบางตัวมีความแตกต่าง ระหว่างกลุ่มผู้ผิดนัดและไม่ผิดนัดอย่างมีนัยสำคัญทางสถิติ โดยพิจารณาจากค่า p-value ที่น้อยกว่า 0.05 ได้แก่ วงเงิน สินเชื่อ ($p < 0.001$) การมีผู้ค้ำประกัน ($p = 0.0025$) และกลุ่ม อาชีพธุรกิจส่วนตัว ($p = 0.0003$) รวมถึงกลุ่มอาชีพเอกชน/ รัฐวิสาหกิจ ($p = 0.0022$) แสดงว่าตัวแปรเหล่านี้มี ความสัมพันธ์กับสถานะการผิดนัดชำระหนี้อย่างมีนัยสำคัญ ในขณะที่ตัวแปรอื่น เช่น เพศ รายได้ อัตราดอกเบี้ย และงวด การผ่อนชำระ ไม่พบความแตกต่างอย่างมีนัยสำคัญทางสถิติ ($p > 0.05$) ทั้งนี้ค่า p-value ในตารางคำนวณจาก independent samples t-test สำหรับตัวแปรเชิงปริมาณ และ Chi-square test สำหรับตัวแปรเชิงคุณภาพ

เนื่องจากข้อจำกัดด้านจำนวนตัวอย่างในกลุ่มผู้ผิดนัด ชำระหนี้ ซึ่งมีเพียง 242 ราย หรือร้อยละ 4.85 จากจำนวน 4,990 ราย ซึ่งแสดงถึงภาวะความไม่สมดุลของข้อมูลอย่าง ชัดเจน เพื่อขจัดปัญหาความไม่สมดุลของข้อมูล และลด โอกาสที่แบบจำลองจะเกิดอคติเอนเอียงไปทางกลุ่มผู้ไม่ผิด

นัดชำระหนี้ ผู้วิจัยได้ใช้การสุ่มตัวอย่างแบบแบ่งชั้นภูมิ (Stratified Random Sampling) ในอัตราส่วนร้อยละ 70:30 เพื่อให้มั่นใจว่าสัดส่วนของผู้ผิดนัดชำระหนี้จะถูกกระจายอยู่ ในทั้งสองชุดข้อมูลอย่างเท่าเทียมกัน นอกจากนี้ผู้วิจัยได้ทำ การปรับมาตรฐานข้อมูลในส่วนของตัวแปรเชิงปริมาณ ได้แก่ รายได้ วงเงินสินเชื่อ อัตราดอกเบี้ย และจำนวนเงินที่ชำระ แล้ว เพื่อลดความแปรปรวนและปรับให้ข้อมูลอยู่ในมาตรฐาน เดียวกัน

3.2 การสร้างแบบจำลอง

เนื่องจากตัวแปรตาม ในการศึกษาครั้งนี้คือ สถานะการผิดนัด ชำระหนี้ ซึ่งมีลักษณะเป็นข้อมูลเชิงคุณภาพแบบทวิภาค กล่าวคือ มีค่าเป็น 1 เมื่อผู้กู้ผิดนัดชำระหนี้ และมีค่าเป็น 0 เมื่อ ผู้กู้ชำระปกติ ดังนั้นในสร้างแบบจำลองพยากรณ์ ผู้วิจัย เลือกใช้การถดถอยโลจิสติกแบบถ่วงน้ำหนัก (Weighted Logistic Regression) ซึ่งเป็นเทคนิคทางสถิติที่เหมาะสม สำหรับการจำแนกข้อมูลประเภททวิภาค ที่มีปัญหาความไม่

สมมูล โดยได้กำหนดค่าถ่วงน้ำหนักของกลุ่มให้ผกผันตามความถี่ของกลุ่มข้อมูลดังนี้

$$w_0 = \frac{4,990}{2 \times 4,748} = 0.53 \text{ และ } w_1 = \frac{4,990}{2 \times 242} = 10.31 \quad (1)$$

เมื่อ w_0 แทนค่าถ่วงน้ำหนักของกลุ่มผู้ชำระหนี้ปกติ และ w_1 แทนค่าถ่วงน้ำหนักของกลุ่มผู้ผิดนัดชำระหนี้

สำหรับการวิเคราะห์ความน่าจะเป็นในการผิดนัดชำระหนี้ (Probability of Default: PD) จะพิจารณาจากสมการ

$$P(Y_i = 1 | X_i) = \pi_i = \frac{1}{1 + e^{-Z_i}} \quad (2)$$

เมื่อ P_i คือความน่าจะเป็นที่ผู้กู้จะผิดนัดชำระหนี้ และ Z_i คือฟังก์ชันถดถอยเชิงเส้นของตัวแปรอิสระ นิยามโดย

$$Z_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_9 X_{9i} + \varepsilon_i \quad (3)$$

เมื่อ β_0 คือ ค่าจุดตัดแกนตั้ง $\beta_1, \beta_2, \dots, \beta_9$ คือสัมประสิทธิ์ความถดถอยของตัวแปรอิสระ $X_{1i}, X_{2i}, \dots, X_{9i}$ คือตัวแปรอิสระของผู้กู้รายที่ i และ ε_i คือค่าคลาดเคลื่อนของตัวแปรสุ่ม และฟังก์ชัน log-likelihood ของแบบจำลองโลจิสติกสามารถเขียนได้เป็น

$$L(\beta) = \sum_{i=1}^N w_i (Y_i \log(\pi_i) + (1 - Y_i) \log(1 - \pi_i)) \quad (4)$$

เมื่อ N คือจำนวนข้อมูลทั้งหมด (เท่ากับ 4,990)

สำหรับการวิเคราะห์อิทธิพลตัวแปรอิสระที่มีต่อความน่าจะเป็นในการผิดนัดชำระหนี้ ผู้วิจัยได้ทำการแปลงค่าสัมประสิทธิ์การถดถอย (β_k) ให้เป็นค่าอัตราส่วนความน่าจะเป็น (Odds Ratio: OR) เพื่อให้สามารถอธิบายผลในเชิงปริมาณได้ชัดเจนยิ่งขึ้น โดยคำนวณจากสมการ

$$OR_k = \exp(\beta_k) \quad (5)$$

โดยมีเกณฑ์การพิจารณาทิศทางความสัมพันธ์ ดังนี้

ถ้า $OR_k > 1$ แสดงว่าตัวแปรอิสระนั้นเป็นปัจจัยเสี่ยง (กล่าวคือถ้าค่าตัวแปรนี้เพิ่มขึ้น หรือมีคุณลักษณะดังกล่าวความน่าจะเป็นที่จะผิดนัดชำระหนี้จะเพิ่มขึ้นด้วย) ในทางตรงกันข้าม ถ้า $OR_k < 1$ แสดงว่าตัวแปรอิสระนั้นเป็นปัจจัยป้องกันการผิดนัด (กล่าวคือถ้าค่าตัวแปรนี้เพิ่มขึ้นหรือมีคุณลักษณะดังกล่าวความน่าจะเป็นที่จะผิดนัดชำระหนี้จะลดลงด้วย) ส่วนกรณี $OR_k = 1$ แสดงว่าตัวแปรอิสระไม่มีผลต่อความน่าจะเป็นในการผิดนัดชำระหนี้

การพิจารณาว่าตัวแปรใดเป็นปัจจัยเสี่ยงหรือปัจจัยป้องกัน จะพิจารณาร่วมกับค่านัยสำคัญทางสถิติ (p-value < 0.05) และช่วงความเชื่อมั่น 95% ของ OR โดยหากช่วงความเชื่อมั่นล้อมค่า 1 จะไม่ถือว่ามีความสำคัญเพื่อสะท้อนถึงขนาดของผลกระทบและความไม่แน่นอนของค่าประมาณ นอกจากนี้ สำหรับตัวแปรเชิงปริมาณที่มีหน่วยเป็นเงินบาท งานวิจัยนี้รายงานค่า OR ต่อการเพิ่มขึ้นของทุก ๆ 10,000 บาทด้วย เพื่อให้การตีความมีความเหมาะสมเชิงปฏิบัติและเข้าใจได้ง่ายยิ่งขึ้น

สำหรับการทดสอบนัยสำคัญของค่า β_k ในแบบจำลองผู้วิจัยใช้สถิติ Wald test ภายใต้การประมาณค่าความคลาดเคลื่อนมาตรฐานแบบ robust ตามแนวทางของ Huber-White [8] เพื่อแก้ปัญหาความแปรปรวนของความคลาดเคลื่อนที่ไม่คงที่ และผลกระทบจากการถ่วงน้ำหนักข้อมูลในฟังก์ชัน likelihood วิธีการนี้ช่วยให้การทดสอบนัยสำคัญทางสถิติมีความน่าเชื่อถือมากขึ้น แม้ในกรณีที่ข้อมูลมีความไม่สมดุลของกลุ่มตัวอย่างอย่างชัดเจน

4. ผลการวิจัย

4.1 ผลการประมาณค่าพารามิเตอร์

ผลการประมาณค่าพารามิเตอร์ที่เกี่ยวข้องแสดงได้ดังตารางที่ 3

ตารางที่ 3: ผลการประมาณค่าพารามิเตอร์จากแบบจำลอง

ตัวแปร	Beta	Robust SE	p-value	OR	OR 2.5%	OR 97.5%	OR ต่อ 10,000 บาท*
ค่าคงที่ (Intercept)	-0.5267	0.2861	0.066	0.591	0.337	1.035	
เพศหญิง	0.0003	0.0587	0.996	1.000	0.892	1.122	
รายได้ต่อเดือน	-1.03e-07	1.92e-07	0.591	1.000	1.000	1.000	0.999
อาชีพ: ข้าราชการ	-0.2011	0.0807	0.013	0.818	0.698	0.958	
อาชีพ: เอกชน/รัฐวิสาหกิจ	-0.6746	0.0801	<0.001	0.509	0.435	0.596	
อาชีพ: เกษตรกร/อาชีพอิสระ	-0.2325	0.0865	0.007	0.793	0.669	0.939	
มีผู้ค้ำประกัน	-0.5728	0.0943	<0.001	0.564	0.469	0.678	
อายุ 31-60 ปี	-0.1948	0.0892	0.029	0.823	0.691	0.980	
อัตราดอกเบี้ย	0.0184	0.0159	0.247	1.019	0.987	1.051	
วงเงินสินเชื่อ	1.02e-06	1.62e-07	<0.001	1.000	1.000	1.000	1.010
งวด 36 งวด	-0.3508	0.1575	0.026	0.704	0.517	0.959	
งวด 48 งวด	0.0108	0.0843	0.898	1.011	0.857	1.192	
งวด 60 งวด	0.0326	0.0751	0.664	1.033	0.892	1.197	
ยอดชำระแล้ว	3.70e-07	5.03e-07	0.462	1.000	1.000	1.000	1.004

ทิศทางของความสัมพันธ์และนัยสำคัญทางสถิติของตัวแปรอิสระแต่ละตัว สามารถสรุปได้ดังนี้

ตัวแปรด้าน อาชีพ อายุ และการมีผู้ค้าประกัน มีความสัมพันธ์กับความน่าจะเป็นของการผิคนัดชำระหนี้ อย่างมีนัยสำคัญทางสถิติ ในขณะที่ตัวแปรด้านเพศและรายได้ไม่แสดงผลอย่างมีนัยสำคัญ

ในกลุ่มตัวแปรอาชีพ พบว่า ผู้กู้ที่ประกอบอาชีพข้าราชการมีโอกาสผิคนัดชำระหนี้ต่ำกว่ากลุ่มอ้างอิง (กลุ่มธุรกิจส่วนตัว) ประมาณร้อยละ 18 ($OR = 0.818, p = 0.013$) ขณะที่ผู้กู้ในภาคเอกชนและรัฐวิสาหกิจมีความเสี่ยงต่ำลงอย่างชัดเจนที่สุด โดยมีโอกาสผิคนัดชำระหนี้ลดลงประมาณร้อยละ 49 ($OR = 0.509, p < 0.001$) ส่วนกลุ่มเกษตรกรและอาชีพอิสระมีความเสี่ยงต่ำกว่ากลุ่มอ้างอิงประมาณร้อยละ 21 ($OR = 0.793, p = 0.007$) ซึ่งสอดคล้องกับผล Chi-square test ในตารางที่ 2 ที่พบความแตกต่างของสัดส่วนระหว่างกลุ่มอย่างมีนัยสำคัญทางสถิติ

ด้านลักษณะผู้ขอสินเชื่อพบว่า การมีผู้ค้าประกันช่วยลดความน่าจะเป็นของการผิคนัดชำระหนี้ อย่างมีนัยสำคัญ โดยลดความเสี่ยงลงประมาณร้อยละ 44 ($OR = 0.564, p < 0.001$) ซึ่งสอดคล้องกับผลการทดสอบ Chi-square ซึ่งแสดงให้เห็นความแตกต่างของสัดส่วนผู้ที่มีผู้ค้าประกันระหว่างกลุ่มผิคนัดและไม่ผิคนัดอย่างมีนัยสำคัญเช่นกัน ขณะเดียวกัน ผู้กู้ที่มีอายุอยู่ในช่วง 31-60 ปีมีความเสี่ยงผิคนัดชำระหนี้ต่ำกว่ากลุ่มอื่นประมาณร้อยละ 18 ($OR = 0.823, p = 0.029$) สะท้อนถึงเสถียรภาพทางรายได้ของกลุ่มวัยทำงาน


ในส่วนของตัวแปรด้านเงินออม พบว่า เงินออมเชื่อมีผลเชิงบวกต่อความเสี่ยงในการผิคนัดชำระหนี้ อย่างมีนัยสำคัญ โดยเมื่อเงินเพิ่มขึ้น 10,000 บาท โอกาสผิคนัดชำระหนี้เพิ่มขึ้นประมาณร้อยละ 1 ($OR = 1.010, p < 0.001$) และผลการทดสอบ t-test จากตารางที่ 2 แสดงให้เห็นว่าค่าเฉลี่ยเงินออมเชื่อของกลุ่มผิคนัดสูงกว่ากลุ่มไม่ผิคนัดอย่างมีนัยสำคัญทางสถิติ ในขณะที่อัตราดอกเบี้ยไม่แสดงผลอย่างมีนัยสำคัญทั้งในการทดสอบเบื้องต้นและในแบบจำลองนี้

สำหรับระยะเวลาการผ่อนชำระ พบว่า การเลือกผ่อน 36 งวดช่วยลดโอกาสผิคนัดชำระหนี้ประมาณร้อยละ 30 เมื่อเทียบกับกลุ่มอ้างอิง (72 งวด) ($OR = 0.704, p = 0.026$) ในขณะที่งวดผ่อน 48 และ 60 เดือนไม่แตกต่างจากกลุ่มอ้างอิงอย่างมีนัยสำคัญ แม้ว่าผลการทดสอบ Chi-square ไม่แสดงความแตกต่างอย่างมีนัยสำคัญในทุกช่วงงวด แต่เมื่อควบคุมผลของตัวแปรอื่นในแบบจำลองแล้ว ผลกระทบของงวด 36 เดือนยังคงมีนัยสำคัญทางสถิติ ซึ่งสะท้อนความสำคัญของการวิเคราะห์เชิงพหุในการประเมินความเสี่ยงด้านเครดิต

ดังนั้นงานวิจัยนี้จึงชี้ให้เห็นว่าปัจจัยด้านความมั่นคงของรายได้และความสามารถในการชำระหนี้มีบทบาทสำคัญมากกว่าปัจจัยด้านประชากรศาสตร์พื้นฐานในการอธิบายความเสี่ยงของการผิคนัดชำระหนี้ ทั้งนี้แม้แบบจำลองเชิงเส้นนี้จะมีข้อจำกัดในการจับความสัมพันธ์เชิงซ้อน แต่ผลลัพธ์ยังสามารถนำไปใช้เป็นเครื่องมือคัดกรองความเสี่ยงในระบบการอนุมัติสินเชื่อได้อย่างมีประสิทธิภาพ

4.2 การประเมินประสิทธิภาพของแบบจำลอง

ในการประเมินประสิทธิภาพของแบบจำลอง ผู้วิจัยจะพิจารณาจาก เส้นโค้ง ROC และค่า AUC เนื่องจากชุดข้อมูลมีลักษณะความไม่สมดุลสูง การพิจารณาค่าความถูกต้องในการทำนายเพียงอย่างเดียวอาจไม่สามารถสะท้อนประสิทธิภาพที่แท้จริงของแบบจำลองได้ ทั้งนี้ลักษณะของเส้นโค้ง ROC จะช่วยให้สามารถประเมินจุดดุลยภาพระหว่างความครอบคลุมในการตรวจจับผู้กู้ที่มีโอกาสจะค้างชำระ กับการลดความผิดพลาดในการปฏิเสธลูกค้าดี เพื่อนำไปสู่การกำหนดจุดตัดที่เหมาะสมที่สุดในเชิงธุรกิจและการบริหารความเสี่ยงได้



แผนภาพที่ 1: ROC Curve

แผนภาพที่ 1 แสดงเส้นโค้ง ROC ของแบบจำลอง ซึ่งให้ค่า AUC เท่ากับ 0.597 โดยตามเกณฑ์การประเมินของ Hosmer และคณะ [9] ค่านี้จัดอยู่ในระดับต่ำถึงพอใช้ แม้ค่า AUC จะไม่สูงมาก แต่ยังคงมีค่ามากกว่า 0.5 ซึ่งหมายถึงแบบจำลองสามารถจำแนกความเสี่ยงได้ดีกว่าการสุ่ม

ค่า AUC ดังกล่าวสะท้อนข้อจำกัดของความสามารถในการจำแนกความเสี่ยงของแบบจำลองภายใต้ข้อจำกัดของชุดข้อมูล แม้ว่าผู้วิจัยได้ใช้วิธีการถ่วงน้ำหนักเพื่อแก้ไขปัญหาค่าความไม่สมดุลของข้อมูลแล้วก็ตาม อย่างไรก็ตาม ตัวแปรอิสระที่นำมาใช้ส่วนใหญ่เป็นข้อมูลด้านประชากรศาสตร์และเงินออม ซึ่งอาจยังไม่เพียงพอในการอธิบายความซับซ้อนของพฤติกรรมผิคนัดชำระหนี้ได้อย่างครบถ้วน ส่งผลให้ความแม่นยำในการจำแนกอยู่ในระดับจำกัด

ถึงแม้ว่าความสามารถในการจำแนกจะอยู่ในระดับต่ำถึงพอใช้ ผลการวิเคราะห์ยังคงแสดงให้เห็นว่าปัจจัยสำคัญหลายตัวมีความสัมพันธ์กับความน่าจะเป็นในการผิคนัดชำระหนี้ อย่างมีนัยสำคัญทางสถิติ ดังนั้นในทางปฏิบัติ แบบจำลองนี้จึงเหมาะสมที่จะใช้เป็นเครื่องมือคัดกรองความเสี่ยงเบื้องต้นมากกว่าการใช้เป็นเครื่องมือในการตัดสินใจขั้นสุดท้าย

5. สรุปผลการศึกษา

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบการประเมินความน่าจะเป็นของการผิคนัดชำระหนี้สำหรับผู้ซื้รถยนต์ โดยใช้ข้อมูลเชิงธุรกรรมระดับรายบุคคลจากสัญญาเช่าซื้อรถยนต์จำนวน 4,990 สัญญา ที่ได้รับการอนุมัติในช่วงปี พ.ศ. 2567-2568 ซึ่งสะท้อนพฤติกรรมชำระหนี้ภายใต้บริบทเศรษฐกิจที่มีความผันผวนและระดับหนี้ครัวเรือนอยู่ใน

ระดับสูง งานวิจัยมุ่งเน้นการวิเคราะห์ปัจจัยด้านคุณลักษณะของผู้กู้และเงื่อนไขของสัญญาสินเชื่อที่ส่งผลต่อความเสี่ยงในการผิดนัดชำระหนี้ เพื่อสนับสนุนการบริหารความเสี่ยงของสถาบันการเงินและผู้ประกอบธุรกิจสินเชื่อ

แบบจำลองถดถอยโลจิสติกแบบถ่วงน้ำหนักถูกเลือกใช้เพื่อจัดการกับปัญหาความไม่สมดุลของข้อมูล เนื่องจากผู้ผิดนัดชำระหนี้มีเพียงร้อยละ 4.85 ของตัวอย่างทั้งหมด โดยกำหนดค่าน้ำหนักของคลาสแบบผกผันตามความถี่ของข้อมูล และใช้การสุ่มตัวอย่างแบบแบ่งชั้นภูมิในการแบ่งข้อมูลฝึกและทดสอบในอัตราส่วน 70:30 นอกจากนี้ยังใช้ robust standard errors แบบ Huber-White เพื่อให้การอนุมานทางสถิติมีความน่าเชื่อถือมากขึ้น

ผลการวิเคราะห์เชิงประจักษ์ชี้ให้เห็นว่า อาชีพ อายุ การมีผู้ค้ำประกัน และวงเงินสินเชื่อ เป็นปัจจัยสำคัญที่กำหนดความเสี่ยงในการผิดนัดชำระหนี้ โดยผู้กู้ที่มีอาชีพมั่นคง เช่น ข้าราชการ พนักงานเอกชน และรัฐวิสาหกิจ มีความเสี่ยงต่ำกว่ากลุ่มธุรกิจส่วนตัวอย่างมีนัยสำคัญ ขณะเดียวกัน การมีผู้ค้ำประกันและการอยู่ในช่วงอายุ 31-60 ปีช่วยลดโอกาสการผิดนัด สะท้อนถึงบทบาทของเสถียรภาพทางรายได้และความสามารถในการชำระหนี้ ส่วนเงื่อนไขของสัญญาพบว่า วงเงินสินเชื่อที่สูงขึ้นเพิ่มความเสี่ยงในการผิดนัด ในขณะที่การเลือกผ่อนระยะสั้น (36 งวด) ช่วยลดความเสี่ยงได้อย่างมีนัยสำคัญ

การประเมินประสิทธิภาพของแบบจำลองด้วย ROC curve พบว่าค่า AUC เท่ากับ 0.597 แสดงถึงความสามารถในการจำแนกความเสี่ยงได้ดีกว่าการสุ่ม แต่ยังคงอยู่ในระดับจำกัดภายใต้โครงสร้างข้อมูลที่มีความไม่สมดุลสูง

ผลการศึกษานี้สามารถใช้เป็นแนวทางสำหรับสถาบันการเงินหรือผู้ประกอบการธุรกิจสินเชื่อในการพิจารณาปรับแบบจำลองไปประยุกต์ใช้ เป็นเครื่องมือในกระบวนการอนุมัติสินเชื่อ เพื่อคัดกรองผู้ขอสินเชื่อเบื้องต้น โดยเฉพาะผู้ขอสินเชื่อที่มีคุณลักษณะด้านอาชีพที่มีความผันผวนทางรายได้ หรือไม่มีผู้ค้ำประกัน ซึ่งควรได้รับการพิจารณาเพิ่มเติมในเชิงคุณภาพก่อนการอนุมัติวงเงิน นอกจากนี้ผลการศึกษาชี้ให้เห็นว่าวงเงินสินเชื่อมีความสัมพันธ์เชิงบวกกับความเสี่ยงในการผิดนัดชำระหนี้ ดังนั้นสถาบันการเงินอาจพิจารณากำหนดวงเงินสินเชื่อหรือระยะเวลาการผ่อนชำระให้สอดคล้องกับระดับความเสี่ยงที่ประเมินได้จากแบบจำลอง เพื่อลดโอกาสการเกิดหนี้ที่ไม่ก่อให้เกิดรายได้ในอนาคต

ในด้านการพัฒนาระบบ งานวิจัยนี้ชี้ให้เห็นว่าการใช้ข้อมูลเชิงธุรกรรมร่วมกับแบบจำลองทางสถิติสามารถสนับสนุนการบริหารความเสี่ยงด้านเครดิตได้ อย่างไรก็ตามแบบจำลองเชิงเส้นยังมีข้อจำกัดในการอธิบายพฤติกรรมการผิดนัดชำระหนี้ที่มีความซับซ้อน เนื่องจากค่า AUC ไม่สูงมาก ดังนั้นการพัฒนาแนวทางการวิจัยในอนาคต อาจใช้เทคนิคการเรียนรู้ของเครื่องเข้ามาพิจารณา เพื่อเพิ่มความแม่นยำของระบบการประเมินความเสี่ยงด้านเครดิต

6. เอกสารอ้างอิง

- [1] Thai PBS. ฟอนรถไม่ไหว ไม่ต้องกลัว คีนรถถูกวิธี-รักษาเครดิต-ไม่เสียหนี้เพิ่ม [อินเทอร์เน็ต]. กรุงเทพฯ: ไทยพีบีเอส; 2568 เข้าถึงได้จาก: <https://www.thaipbs.or.th/news/content/353140>
- [2] ธนาคารแห่งประเทศไทย. เงินให้กู้ยืมแก่ภาคครัวเรือนจำแนกตามวัตถุประสงค์ [อินเทอร์เน็ต]. กรุงเทพฯ: ธนาคารแห่งประเทศไทย; 2568 เข้าถึงได้จาก: https://app.bot.or.th/BTWS_STAT/statistics/BOTWEBS/TAT.aspx?reportID=984&language=TH
- [3] นิภาพรณี พจนชัยธรรม. ปัจจัยในการคัดเลือกลูกหนี้ที่มีคุณภาพของสินเชื่อเช่าซื้อรถยนต์ใหม่ [วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ]. กรุงเทพฯ: มหาวิทยาลัยธรรมศาสตร์; 2545.
- [4] วิกิรนต์ พิษพันธ์ไพศาล. ปัจจัยที่มีผลต่อการเกิดหนี้ค้างชำระเงินกู้เช่าซื้อรถยนต์ของบริษัทเงินทุนแห่งหนึ่งในอำเภอเมืองนครสวรรค์ จังหวัดนครสวรรค์ บัณฑิตวิทยาลัย มหาวิทยาลัยเชียงใหม่: เชียงใหม่; 2548.
- [5] รัฐวิชัย จิรพัฒน์วงศ์. ระบบคะแนนสินเชื่อและคุณภาพลูกหนี้เช่าซื้อรถยนต์ที่เกิดจากนโยบายสินเชื่อรถยนต์คันแรก. *Journal of Management Science Nakhon Pathom Rajabhat University*. 2019; 6(1) 256-270.
- [6] ชวัญทัย ฤคดิ, เทอดศักดิ์ ชมโตะสุวรรณ. การวิเคราะห์ปัจจัยกำหนดการผิดนัดชำระค่าวงธุรกิจเช่าซื้อรถจักรยานยนต์: กรณีศึกษาบริษัทแห่งหนึ่งในกรุงเทพมหานคร. *วารสารวิจัยมหาวิทยาลัยขอนแก่นสาขามนุษยศาสตร์และสังคมศาสตร์ (ฉบับบัณฑิตศึกษา)*. 2022;10(1):47.
- [7] ธนาคารแห่งประเทศไทย. หลักเกณฑ์การจัดชั้นและการกักเงินสำรองของสถาบันการเงินเฉพาะกิจ. [อินเทอร์เน็ต]. กรุงเทพฯ: ธนาคารแห่งประเทศไทย; 2559 เข้าถึงได้จาก: <https://www.bot.or.th/content/dam/bot/fipcs/documents/FPG/2559/ThaiPDF/25590263.pdf>
- [8] White H. A heteroscedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. *Econometrica*. 1980;48(4):817-38.
- [9] Hosmer DW, Lemeshow S, Sturdivant RX. *Applied Logistic Regression*. 3rd ed. New York: John Wiley & Sons; 2013.

การวิเคราะห์และเปรียบเทียบวิธีการประมาณค่าเงินสำรองสินไหมทดแทนใน การประกันความเสียหายภัยทรัพย์สิน

Methodological Analysis and Comparison of Loss Reserving for Industrial All Risks Insurance

ปพิชญา ชูจำ^{1*} อุไรวรรณ เจริญกิริติกุล^{2*} มนัสยา ละอองแก้ว

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504052620083@email.kmutnb.ac.th ^{2*} uraiwan.j@sci.kmutnb.ac.th)

บทคัดย่อ

อุตสาหกรรมประกันวินาศภัยของประเทศไทยมีการขยายตัวต่อเนื่องภายใต้สภาพแวดล้อมที่มีความไม่แน่นอนจากปัจจัยทางเศรษฐกิจและภัยธรรมชาติ ส่งผลให้การบริหารจัดการเงินสำรองสินไหมทดแทนมีความสำคัญอย่างมาก โดยเฉพาะในประกันความเสียหายภัยทรัพย์สิน (Industrial All Risks : IAR) ที่มีโอกาสเกิดความสูญเสียในมูลค่าสูง การรักษาสภาพคล่องทางการเงินในธุรกิจประกันภัยจึงจำเป็นต้องได้ค่าประมาณเงินสำรองสินไหมที่เหมาะสม ซึ่งในงานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของวิธีการประมาณค่าเงินสำรองสินไหม ได้แก่ วิธีบันไดลูกโซ่ (Chain Ladder) วิธีค่าคาดหมายของอัตราส่วนค่าความเสียหาย (Expected Loss Ratio) และวิธีบอร์นฮิวเอตเตอร์-เฟอร์กูสัน (Bornhuetter-Ferguson) โดยใช้ค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) เป็นเกณฑ์การประเมินประสิทธิภาพ ข้อมูลที่ใช้ในการวิเคราะห์ประกอบด้วยข้อมูลค่าสินไหมจ่ายราย 6 เดือนตามข้อมูลอุบัติเหตุของกรมธรรม์ประกันความเสียหายภัยทรัพย์สิน ในช่วงปี ค.ศ. 2019–2025 ข้อมูลเบี้ยประกันภัยที่ถือเป็นรายได้ในช่วงปี ค.ศ. 2019–2024 ของบริษัทประกันภัยแห่งหนึ่ง และข้อมูลอัตราส่วนค่าความเสียหายของอุตสาหกรรมที่เผยแพร่โดยสำนักงานคณะกรรมการกำกับและส่งเสริมการประกอบธุรกิจประกันภัย ผลการวิจัยพบว่าวิธี Chain Ladder ให้ความแม่นยำสูงสุด โดยมีค่า MAPE เท่ากับ 7.69% รองลงมาคือวิธี Bornhuetter-Ferguson และวิธี Expected Loss Ratio ตามลำดับ โดยวิธี Chain Ladder เหมาะสมเมื่อมีข้อมูลการพัฒนาการของเคลมเพียงพอ ขณะที่วิธี Expected Loss Ratio มีความคลาดเคลื่อนสูง และวิธี Bornhuetter-Ferguson เหมาะสำหรับกรณีที่มีข้อมูลการพัฒนาการของเคลมยังไม่ครบถ้วน ผลการวิจัยสามารถนำไปใช้เป็นแนวทางในการบริหารความเสี่ยงและการประเมินเงินสำรองสินไหมของบริษัท

คำสำคัญ: เงินสำรองสินไหม, ประกันความเสียหายภัยทรัพย์สิน, วิธีบันไดลูกโซ่, วิธีค่าคาดหมายของอัตราส่วนค่าความเสียหาย, วิธีบอร์นฮิวเอตเตอร์-เฟอร์กูสัน

Abstract

The non-life insurance industry in Thailand has experienced continuous growth amid increasing uncertainty arising from economic factors and natural disasters. Consequently, the estimation of loss reserves has become critically important, particularly for Industrial All Risks insurance (IAR), which is exposed to the potential for high-severity losses. Maintaining the financial liquidity of insurance companies necessitates an appropriate estimation of loss reserves. This study aims to examine and compare the performance of loss reserving methods, namely the Chain Ladder method, the Expected Loss Ratio method, and the Bornhuetter-Ferguson method. The Mean Absolute Percentage Error (MAPE) is employed as the criterion for evaluating estimation accuracy. The data used in the analysis consist of semi-annual paid claims data based on accident year data for IAR insurance policies from 2019 to 2025, earned premium data from 2019 to 2024 of an insurance company, and industry loss ratio data published by the Office of Insurance Commission. The results found that the Chain Ladder method

provides the highest estimation accuracy, with a MAPE of 7.69%, followed by the Bornhuetter–Ferguson method and the Expected Loss Ratio method, respectively. The Chain Ladder method is most suitable when sufficient loss development data are available, whereas the Expected Loss Ratio method exhibits relatively high estimation error. In contrast, the Bornhuetter–Ferguson method is more appropriate in situations where loss development data are incomplete. The findings of this study can serve as a guideline for risk management and loss reserve assessment for insurance companies.

Keywords: Loss Reserve, Industrial All Risks Insurance, Chain Ladder method, Expected Loss Ratio method, Bornhuetter–Ferguson method

1. บทนำ

ธุรกิจประกันภัยวินาศภัยมีบทบาทสำคัญต่อระบบเศรษฐกิจและการบริหารความเสี่ยงขององค์กรและบุคคล โดยเฉพาะ ประกันความเสี่ยงภัยทรัพย์สิน (Industrial All Risks : IAR) ซึ่งให้ความคุ้มครองทรัพย์สินที่มีมูลค่าสูงและมีลักษณะความเสี่ยงซับซ้อนเกิดจากที่มีคุ้มครองความเสี่ยงภัยทุกชนิดหรือสรรพภัย ค่าสินไหมมีการยึดถือไม่สิ้นสุดการจ่ายได้ในเวลาที่สิ้นสุดสัญญาความคุ้มครอง การดำเนินธุรกิจในส่วนนี้จำเป็นต้องอาศัยวิธีการคำนวณประมาณค่าเงินสำรองสินไหม (Loss Reserving) ที่เหมาะสม เพื่อรักษาสภาพคล่องและความมั่นคงทางการเงินของบริษัทประกันภัยที่จะมีความสามารถชำระค่าหนี้สินในค่าสินไหมจากความสูญเสียที่เกิดขึ้นซึ่งถือเป็นภาระผูกพันหลักของบริษัทประกันภัย

การประมาณค่าเงินสำรองสินไหมมีความท้าทายเนื่องจากข้อมูลค่าสินไหมของประกัน IAR ไม่สามารถระบุจำนวนที่แน่นอนได้ในช่วงเริ่มต้นของกระบวนการเรียกร้องค่าสินไหม และต้องผ่านการตรวจสอบและประเมินความเสี่ยง [1,8] ส่งผลให้ประสิทธิภาพของวิธีการประมาณค่าเงินสำรองสินไหมอาจแตกต่างกันไปตามลักษณะข้อมูลในทางปฏิบัติมีการใช้วิธีการต่าง ๆ [5] ได้แก่ วิธีบันไดลูกโซ่ (Chain Ladder: CL) วิธีค่าคาดหมายของอัตราส่วนค่าความเสียหาย (Expected Loss Ratio: ELR) และวิธีบอร์นฮิวเอตเตอร์-เฟอร์กูสัน (Bornhuetter–Ferguson: BF) ซึ่งแต่ละวิธีมีสมมติฐานและข้อจำกัดที่แตกต่างกัน

ดังนั้น งานวิจัยนี้จึงเน้นศึกษาการประมาณค่าเงินสำรองสินไหมของประกัน IAR โดยใช้วิธี Chain Ladder (CL) วิธี Expected Loss Ratio (ELR) และวิธี Bornhuetter–Ferguson (BF) พร้อมทั้งเปรียบเทียบประสิทธิภาพของแต่ละวิธีด้วยเกณฑ์ค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) เพื่อเป็นแนวทางในการเลือกใช้วิธีการประมาณค่าเงินสำรองที่เหมาะสมกับลักษณะข้อมูลจริงและสามารถนำไปประยุกต์ใช้ในธุรกิจประกันภัยได้อย่างมีประสิทธิภาพ

2. ทฤษฎีและหลักการ

2.1 ประกันความเสี่ยงภัยทรัพย์สิน เป็นการประกันภัยที่พัฒนามาจากการประกันภัยอัคคีภัย (Fire Insurance) แต่มีขอบเขตความคุ้มครองที่มากกว่า โดยให้ความคุ้มครองในลักษณะแบบสรรพภัย ยกเว้นความเสียหายที่ระบุเป็นข้อยกเว้นไว้ในกรมธรรม์ ประกันประเภทนี้ส่วนใหญ่มีมูลค่า

ความเสียหายสูงและมีความผันผวนของค่าสินไหม จึงจำเป็นต้องมีการประมาณค่าเงินสำรองสินไหมอย่างเหมาะสมเพื่อรองรับความเสี่ยง [1]

2.2 การประมาณค่าเงินสำรองสินไหม (Loss Reserving)

เป็นกระบวนการสำคัญในการบริหารความมั่นคงทางการเงินของบริษัทประกันภัย โดยมีวัตถุประสงค์เพื่อเตรียมเงินสำรองสำหรับค่าสินไหมที่เกิดขึ้นแล้วแต่ยังไม่ได้จ่ายครบถ้วน หรือยังไม่ได้รับแจ้ง (Incurred But Not Reported Claims: IBNR) การประมาณค่าเงินสำรองที่แม่นยำช่วยลดความเสี่ยงด้านสภาพคล่องและสนับสนุนการตัดสินใจเชิงกลยุทธ์ขององค์กร [2,5]

2.3 การพยากรณ์ (Forecasting)

เป็นการนำข้อมูลในอดีตมาวิเคราะห์เพื่อคาดการณ์ค่าที่จะเกิดขึ้นในอนาคต ซึ่งในงานวิจัยนี้ใช้สำหรับการพยากรณ์เบี้ยประกันภัยที่ถือเป็นรายได้ (Earned Premium) โดยใช้วิธีการพยากรณ์ที่เหมาะสมกับข้อมูลที่มีแนวโน้ม (Trend) ตามลักษณะของข้อมูลอนุกรมเวลา ซึ่งผลลัพธ์จากการพยากรณ์จะนำมาใช้เป็นข้อมูลนำเข้า (Input) ในการประมาณค่าเงินสำรองสินไหมในวิธี Expected Loss Ratio และวิธี Bornhuetter–Ferguson ความแม่นยำของค่าพยากรณ์จะช่วยเพิ่มประสิทธิภาพในการประมาณค่าเงินสำรองสินไหม โดยมีทฤษฎีที่เกี่ยวข้อง [3,6,7] ดังต่อไปนี้

2.3.1 วิธีการปรับเรียบแบบเอ็กซ์โพเนนเชียลสองชั้นของบราวน์ (Double Exponential Smoothing: Brown's Method)

วิธีการนี้เหมาะสำหรับข้อมูลที่มีการเคลื่อนไหวเป็นแนวโน้มเชิงเส้น (Linear Trend) และไม่มี ความผันผวนตามฤดูกาล (Seasonal Fluctuations) นอกจากนี้ยังเหมาะสำหรับการพยากรณ์ช่วงเวลาระยะสั้นถึงระยะปานกลาง โดยข้อมูลที่ใช้ในการพยากรณ์ควรมีอย่างน้อย 5 ค่า หรือ 5 ช่วงเวลา

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (1)$$

โดยที่

Y_t คือ ค่าข้อมูลหรือค่าสังเกตได้ ณ ช่วงเวลา t

β_0, β_1 คือ ค่าพารามิเตอร์ของตัวแบบจำลอง

ε_t คือ ค่าความคลาดเคลื่อน ณ ช่วงเวลา t

สำหรับตัวแบบจำลองการพยากรณ์ สามารถจัดได้ในรูปแบบ ดังต่อไปนี้

$$\hat{Y}_{t+m} = a_t + b_t m \quad (2)$$

โดยที่

\hat{Y}_{t+m} คือ ค่าพยากรณ์ล่วงหน้าไปอีก m ช่วงเวลา
 a_t, b_t คือ ค่าประมาณของพารามิเตอร์ β_0 และ β_1 ณ
ช่วงเวลา t

เมื่อ

$$a_t = 2E'_t - E''_t \quad (3)$$

$$b_t = \left(\frac{\alpha}{1-\alpha}\right)(E'_t - E''_t) \quad (4)$$

โดยที่

$$E'_t = \alpha Y_t + (1-\alpha)E'_{t-1}$$

$$E''_t = \alpha E'_t + (1-\alpha)E''_{t-1}$$

เมื่อ

E'_t คือ ค่าที่ได้จากการปรับเรียบแบบเอ็กซ์โพเนนเชียล
แบบขั้นเดียวครั้งที่หนึ่ง ณ ช่วงเวลา t

E''_t คือ ค่าที่ได้จากการปรับเรียบแบบเอ็กซ์โพเนนเชียล
แบบขั้นเดียวครั้งที่สอง ณ ช่วงเวลา t

α คือ ค่าคงที่ของการปรับเรียบ (smoothing constant) โดย
มีค่าอยู่ในช่วง $0 < \alpha < 1$

2.3.2 วิธีการถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

เป็นวิธีการทางสถิติที่ใช้วิเคราะห์ความสัมพันธ์เชิงเส้น
ระหว่างตัวแปรอิสระ (Independent Variable) และตัวแปรตาม
(Dependent Variable) โดยมีวัตถุประสงค์เพื่ออธิบายผลของ
การเปลี่ยนแปลงตัวแปรอิสระในทีนี้คือเวลาที่ช่วงเวลามีผล
ต่อตัวแปรตาม และสามารถนำตัวแบบไปใช้ในการพยากรณ์
ค่าตัวแปรตามในอนาคต ทั้งนี้ วิธีการดังกล่าวตั้งอยู่บน
สมมติฐานว่าความสัมพันธ์เป็นเชิงเส้น และค่าความ
คลาดเคลื่อนเป็นแบบสุ่ม (random error) มีค่าเฉลี่ยเป็นศูนย์
และความแปรปรวนคงที่

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (5)$$

โดยที่ Y_t คือ ค่าตัวแปรตาม ณ ช่วงเวลา t

β_0, β_1 คือ ค่าพารามิเตอร์ของตัวแบบจำลอง

ε_t คือ ค่าความคลาดเคลื่อน ณ ช่วงเวลา t

สำหรับตัวแบบจำลองการพยากรณ์ สามารถจัดได้ใน
รูปแบบ ดังต่อไปนี้

$$\hat{Y}_t = a + bt \quad (6)$$

โดยที่ \hat{Y}_t คือ ค่าประมาณของตัวแปรตามของตัวแบบจำลอง
ณ เวลา t

a, b คือ ค่าประมาณของพารามิเตอร์ β_0 และ β_1

เมื่อค่าประมาณพารามิเตอร์คำนวณได้จากวิธีกำลังสอง
น้อยที่สุด (Least Squares Method) ดังต่อไปนี้

$$a = \bar{Y} - b\bar{t} \quad (7)$$

$$b = \frac{n \sum_{t=1}^n t Y_t - (\sum_{t=1}^n t)(\sum_{t=1}^n Y_t)}{n \sum_{t=1}^n t^2 - (\sum_{t=1}^n t)^2} \quad (8)$$

โดยที่ n คือ จำนวนข้อมูลทั้งหมด

\bar{Y} คือ ค่าเฉลี่ยของตัวแปรตาม

\bar{t} คือ ค่าเฉลี่ยของเวลา

2.3.3 วิธีการปรับเรียบแบบเอ็กซ์โพเนนเชียลสองชั้นของ โฮลท์ (Holt's Method)

เป็นวิธีที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาที่มีแนวโน้มเป็น
เชิงเส้นตรง รวมถึงเหมาะสำหรับการพยากรณ์ในช่วง
ระยะเวลาที่สั้นถึงระยะปานกลาง โดยข้อมูลที่ใช้ในการ
พยากรณ์ควรมีอย่างน้อย 5 ค่า หรือ 5 ช่วงเวลา สำหรับตัว
แบบจำลองข้อมูลอนุกรมเวลาที่ใช้ในการพยากรณ์นี้ สามารถ
แบ่งออกเป็น 2 รูปแบบ ดังต่อไปนี้

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (\text{แบบบวก}) \quad (9)$$

$$Y_t = (\beta_0 + \beta_1 t) \varepsilon_t \quad (\text{แบบคูณ}) \quad (10)$$

โดยที่ Y_t คือ ค่าข้อมูลหรือค่าสังเกตได้ ณ ช่วงเวลา t

β_0, β_1 คือ ค่าพารามิเตอร์ของตัวแบบจำลอง

ε_t คือ ค่าความคลาดเคลื่อน ณ ช่วงเวลา t

สำหรับตัวแบบจำลองการพยากรณ์ของทั้งแบบบวกและ
แบบคูณ สามารถจัดได้ในรูปแบบเดียวกัน ดังต่อไปนี้

$$\hat{Y}_{t+m} = a_t + b_t m \quad (11)$$

โดยที่ \hat{Y}_{t+m} คือ ค่าพยากรณ์ล่วงหน้าไปอีก m ช่วงเวลา

a_t, b_t คือ ค่าประมาณของพารามิเตอร์ β_0 และ β_1 ณ
ช่วงเวลา t

เมื่อ

$$a_t = \alpha Y_t + (1-\alpha)(a_{t-1} + b_{t-1}) \quad (12)$$

$$b_t = \gamma(a_t - a_{t-1}) + (1-\gamma)b_{t-1} \quad (13)$$

โดยที่ α คือ ค่าคงที่ของการปรับเรียบระหว่างข้อมูลจริงและ
ค่าพยากรณ์ โดยมีค่าอยู่ในช่วง $0 \leq \alpha \leq 1$

γ คือ ค่าคงที่ของการปรับเรียบระหว่างแนวโน้มจริงและ
แนวโน้มที่ประมาณค่า โดยมีค่าอยู่ในช่วง $0 \leq \gamma \leq 1$

2.3.4 วิธีค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average: WMA)

เป็นวิธีการที่ให้น้ำหนักกับข้อมูลในอดีตแต่ละช่วงเวลาไม่
เท่ากัน โดยให้ความสำคัญกับข้อมูลในช่วงเวลาล่าสุดมากกว่า
ข้อมูลในอดีตที่อยู่ไกลออกไป โดยทฤษฎีนี้นำมาใช้ในการ
คำนวณค่า Expected Loss Ratio เป็นค่าร้อยละ (%ELR)
สำหรับการประมาณค่าเงินสำรองสินไหมของวิธี Expected
Loss Ratio (ELR) และวิธี Bornhuetter-Ferguson (BF)

$$\hat{Y}_{t+1} = W_1 Y_t + W_2 Y_{t-1} + W_3 Y_{t-2} + \dots + W_k Y_{t-k-1} \quad (14)$$

โดยที่ \hat{Y}_{t+1} คือ ค่าที่พยากรณ์ ณ ช่วงเวลา $t+1$

Y_t คือ ค่าข้อมูลจริงหรือค่าที่สังเกตได้ ณ ช่วงเวลา t

W_i คือ ค่าน้ำหนักของข้อมูลในอดีตลำดับที่ i เมื่อ $i =$
 $1, 2, 3, \dots, k$ และผลรวมของค่าน้ำหนักทั้งหมดต้องเท่ากับ 1
กล่าวคือ $\sum_{i=1}^k W_i = 1$

2.4 วิธีการประมาณค่าเงินสำรองสินไหมทดแทน

2.4.1 วิธีบันไดลูกโซ่ (Chain Ladder Method: CL)

เป็นวิธีการประมาณค่าเงินสำรองค่าสินไหม โดยอาศัยการ
นำรูปแบบการเกิดค่าสินไหมในอดีตมาคาดการณ์ไปสู่อุณหภูมิต
วิธีการนี้จะให้ผลที่เหมาะสมก็ต่อเมื่อมีการคาดการณ์ว่า

แนวโน้มของข้อมูลในอดีตจะยังคงดำเนินต่อไปในอนาคต [4-5,9]

2.4.1.1 ขั้นตอนการคำนวณในวิธีบันไดลูกโซ่

- 1) การจัดเตรียมข้อมูล ข้อมูลค่าสินไหมจ่ายสะสม (Cumulative Loss Payments) ในอดีตจะถูกจัดเรียงในรูปแบบสามเหลี่ยมการพัฒนา (Loss Development Triangle) โดยจำแนกตามปีอุบัติเหตุ (Accident Year) และช่วงเวลาที่มีการพัฒนา (Development Period) ซึ่งหมายถึง ระยะเวลาหลังจากปีอุบัติเหตุที่ข้อมูลค่าสินไหมยังคงมีการเปลี่ยนแปลงหรือพัฒนา

ตารางที่ 2.1 แสดงการนำข้อมูลค่าสินไหมจ่ายในอดีตมาเรียงในรูปของตารางสามเหลี่ยม

ปีอุบัติเหตุ (Accident Year)	ค่าสินไหมทดแทนจ่ายสะสม (หน่วย) ตามช่วงเวลาที่มีการพัฒนา				
	ช่วงเวลาที่มีการพัฒนา (Development Period)				
	0	1	2	3	j
AY 1	C _{1,0}	C _{1,1}	C _{1,2}	C _{1,3}	C _{1,j}
AY 2	C _{2,0}	C _{2,1}	C _{2,2}	C _{2,3}	
AY 3	C _{3,0}	C _{3,1}	C _{3,2}		
AY 4	C _{4,0}	C _{4,1}	ข้อมูลค่าสินไหมจ่ายที่ยังไม่เกิดขึ้น		
AY i	C _{i,0}				

เมื่อ C_{ij} คือ ค่าสินไหมจ่ายสะสมของปีอุบัติเหตุที่ i ณ ช่วงเวลาที่มีการพัฒนาที่ j

- 2) การคำนวณปัจจัยการเปลี่ยนแปลงของมูลค่าสินไหมจ่ายตามช่วงเวลาที่มีการเปลี่ยนแปลง บนพื้นฐานของการจ่ายสะสม (Age-to-Age Paid Loss development factors based on cumulative payments) และคำนวณค่าเฉลี่ยของปัจจัยการพัฒนา (Average Loss Development Factor)

$$\text{Loss Development Factor (LDF}_{j \rightarrow j+1}) = \frac{C_{i,j+1}}{C_{i,j}} \quad (15)$$

$$\text{ค่าเฉลี่ยของปัจจัยการพัฒนา (f}_j) = \frac{1}{n_j} \sum_{i=1}^{n_j} \text{LDF}_{i,j} \quad (16)$$

เมื่อ LDF_{ij} คือ ปัจจัยการพัฒนาของปีอุบัติเหตุที่ i ในช่วงเวลาที่มีการพัฒนา j ถึง j + 1 ซึ่งใช้เป็นค่าที่ใช้สำหรับการคำนวณค่าเฉลี่ยของปัจจัยการพัฒนา

f_j คือ ค่าเฉลี่ยของปัจจัยการพัฒนา จากช่วงเวลาที่มีการพัฒนา j ถึง j + 1

n_j คือ จำนวนปีอุบัติเหตุที่มีข้อมูลครบทั้งสองช่วงเวลา

- 3) การกำหนด Tailed Factor และคำนวณ Cumulative LDF คำนวณจากการนำค่าเฉลี่ยของปัจจัยการพัฒนา ของช่วงเวลาที่มีการพัฒนาปัจจุบันคูณกับค่า Cumulative LDF ของช่วงถัดไป โดยคำนวณย้อนจากช่วงที่สมบูรณ์ (Ultimate) มายังช่วงต้นของช่วงเวลาที่มีการพัฒนา

- 4) การคำนวณมูลค่าความเสียหายสมบูรณ์ (Estimated Ultimate Loss) คำนวณได้จากค่าสินไหมจ่ายสะสมล่าสุดคูณด้วย ค่าเฉลี่ยของปัจจัยการพัฒนา ค่าสินไหมจ่ายสะสมในแต่ละช่วงปีที่มีการพัฒนาที่เหลืออยู่ โดยคูณต่อเนื่องจนถึงระยะ Ultimate
- 5) การกำหนดค่าสินไหมจ่ายสะสมจนถึงปัจจุบัน (Paid-to-Date) คือ ค่าสินไหมที่มีการจ่ายจริงสะสมจนถึงปัจจุบัน ซึ่งใช้ค่าสินไหมจ่ายสะสมล่าสุดของแต่ละปีอุบัติเหตุจากตารางสามเหลี่ยมการพัฒนา
- 6) การประมาณค่าเงินสำรองสินไหม

$$\text{Loss Reserving} = \text{Estimated Ultimate Loss} - \text{Paid-to-Date} \quad (17)$$

2.4.2 วิธีค่าคาดหมายของอัตราส่วนค่าความเสียหาย (Expected Loss Ratio Method: ELR)

เป็นวิธีการประมาณค่าเงินสำรองสินไหมโดยใช้ความสัมพันธ์ระหว่างค่า Earned Premium และค่า Expected Loss Ratio (%ELR) ในการประมาณมูลค่าความเสียหายสมบูรณ์ ดังสูตรสมการที่ (18) เพื่อเปรียบเทียบส่วนต่างกับค่าสินไหมจ่ายสะสมจนถึงปัจจุบัน [4-5] ตามขั้นตอนต่อไปนี้

2.4.2.1 ขั้นตอนการคำนวณในวิธีค่าคาดหมายของอัตราส่วนค่าความเสียหาย

- 1) การกำหนดค่า Expected Loss Ratio (%ELR) การเลือก %ELR มีหลากหลายรูปแบบ เช่น ใช้จากข้อมูลย้อนหลัง ข้อมูลนอกบริษัท ข้อมูลจากอุตสาหกรรม เป็นต้น
- 2) การกำหนดค่า Earned Premium สำหรับข้อมูลในปี ค.ศ. 2019–2024 เป็นข้อมูลจากบริษัทประกันภัย ส่วน Earned Premium สำหรับปี ค.ศ. 2025 ได้จากการพยากรณ์โดยวิธี Simple Linear Regression
- 3) การคำนวณมูลค่าความเสียหายสมบูรณ์

$$\text{Estimated Ultimate Loss} = \%ELR \times \text{Earned Premium} \quad (18)$$
- 4) การกำหนดค่าสินไหมจ่ายสะสมจนถึงปัจจุบัน (Paid-to-Date)
- 5) การประมาณค่าเงินสำรองสินไหม

$$\text{Loss Reserving} = \text{Estimated Ultimate Loss} - \text{Paid-to-Date}$$

2.4.3 วิธีบอร์นฮิวเอตเตอร์-เฟอร์กูสัน (Bornhuetter-Ferguson Method: BF)

เป็นวิธีการประมาณค่าเงินสำรองสินไหมที่ผสมผสานระหว่างข้อมูลประสบการณ์ในอดีตและข้อมูลสินไหมที่เกิดขึ้นแล้วในปัจจุบัน โดยอาศัยสมมติฐานเกี่ยวกับค่า Expected Loss Ratio (%ELR) ร่วมกับสัดส่วนของสินไหมที่คาดว่ายังไม่ถูกรายงานหรือยังไม่พัฒนาเต็มที่ ซึ่งในวิธีการนี้เป็นวิธีการที่ผสมระหว่างวิธี Chain Ladder และวิธี Expected Loss Ratio โดยการประมาณมูลค่าความเสียหายสมบูรณ์แสดงดังสูตรสมการที่ (19) [4-5]

2.4.3.1 ขั้นตอนการคำนวณในวิธีบอร์นฮิวเอตเตอร์-เฟอร์กูสัน

- 1) การกำหนดค่า Expected Loss Ratio (%ELR)
- 2) การกำหนดค่า Earned Premium
- 3) การกำหนดค่าสินไหมจ่ายสะสมจนถึงปัจจุบัน (Paid-to-Date)
- 4) การคำนวณมูลค่าความเสียหายสมบูรณ์

$$\text{Estimated Ultimate Loss} = \text{Paid-to-Date} + [(1 - 1/\text{Cumulative LDF})] \times \%ELR \times \text{Earned Premium} \quad (19)$$
 โดยที่ $\%Paid = 1/\text{Cumulative LDF}$
- 5) การประมาณค่าเงินสำรองสินไหม

$$\text{Loss Reserving} = \text{Estimated Ultimate Loss} - \text{Paid-to-Date}$$

2.5 เกณฑ์ที่ใช้ในการประเมินประสิทธิภาพ

2.5.1 วิธีค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

เป็นตัวชี้วัดที่ใช้ประเมินประสิทธิภาพของตัวแบบพยากรณ์ Earned Premium และค่าประมาณมูลค่าความเสียหายสมบูรณ์ โดยแสดงเป็นหน่วยเป็นเปอร์เซ็นต์ของความคลาดเคลื่อนระหว่างค่าที่พยากรณ์กับค่าจริง [6-7]

2.5.1.1 ขั้นตอนการคำนวณค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์

- 1) ระบุค่าที่ใช้ในการวิเคราะห์
 y_i = ค่าจริง (Actual value) สำหรับแต่ละข้อมูล i
 \hat{y}_i = ค่าที่พยากรณ์ หรือ ค่าที่วัดได้ (Forecasted/Predicted value) สำหรับแต่ละข้อมูล i
 n = จำนวนปีอุบัติเหตุทั้งหมด
- 2) การคำนวณหาค่าความคลาดเคลื่อนสัมบูรณ์ (Absolute Error)

$$\text{Absolute Error} = |y_i - \hat{y}_i| \quad (20)$$
- 3) การคำนวณหาเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error : APE)

$$\text{APE}_i = \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100 \quad (21)$$
- 4) การคำนวณหาค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \text{APE}_i \quad (22)$$

3. วิธีการดำเนินการและผลการวิจัย

ในงานวิจัยนี้เป็นการวิเคราะห์และเปรียบเทียบวิธีการประมาณค่าเงินสำรองสินไหมในประกัน IAR เพื่อเป็นแนวทางให้บริษัทประกันภัยสามารถวางแผนในการจัดสรรค่าเงินสำรองสินไหม ผลการวิเคราะห์ดังกล่าวสามารถใช้

ประกอบการพิจารณาเกี่ยวกับประสิทธิภาพและความเหมาะสมของแต่ละวิธี โดยมีวิธีการดำเนินงานและผลการวิจัยดังต่อไปนี้

3.1 ขอบเขตงานวิจัย

งานวิจัยนี้ใช้ข้อมูลค่าสินไหมจ่ายสะสม (Paid Claims) ของประกัน IAR จากบริษัทประกันภัยแห่งหนึ่ง โดยประกอบด้วยข้อมูลค่าสินไหมจ่ายสะสมราย 6 เดือน จำแนกตามปีอุบัติเหตุ ตั้งแต่วันที่ 1 มกราคม ค.ศ. 2019 ถึง 30 มิถุนายน ค.ศ. 2025 ข้อมูลเบี้ยประกันภัยที่ถือเป็นรายได้ (Earned Premium) ตั้งแต่ปี ค.ศ. 2019 ถึง ค.ศ. 2024 และข้อมูลอัตราค่าความเสียหาย (Loss Ratio) ของประกัน IAR ตั้งแต่ปี ค.ศ. 2016 ถึง ค.ศ. 2024 ซึ่งใช้เป็นข้อมูลพื้นฐานสำหรับการวิเคราะห์และประมาณค่าเงินสำรองสินไหม

3.2 วิธีการดำเนินงานวิจัย

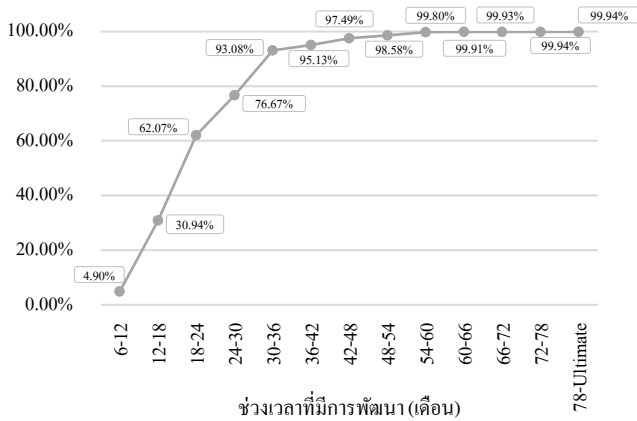
- 1) เก็บรวบรวมและจัดเตรียมข้อมูล
- 2) กำหนดตัวแบบพยากรณ์เพื่อประมาณค่า Earned Premium สำหรับปี ค.ศ. 2025
- 3) คัดเลือกตัวแบบการพยากรณ์ค่า Earned Premium ที่เหมาะสมจากค่า MAPE ต่ำที่สุด
- 4) กำหนดค่าคาดหมายของอัตราส่วนค่าความเสียหาย (%ELR) โดยใช้วิธีค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average: WMA)
- 5) กำหนดมูลค่าความเสียหายสมบูรณ์และประมาณค่าเงินสำรองค่าสินไหมโดยใช้วิธี Chain Ladder Method (CL) วิธี Expected Loss Ratio Method: (ELR) และวิธี Bornhuetter-Ferguson Method (BF)
- 6) เปรียบเทียบและคัดเลือกวิธีการประมาณค่าเงินสำรองสินไหมที่เหมาะสมจากค่า MAPE ต่ำที่สุด
- 7) สรุปผล

3.3 ผลการวิจัย

ข้อมูลค่าสินไหมจ่ายสะสม จำแนกตามปีอุบัติเหตุและช่วงเวลาที่มีการพัฒนา (หน่วย: 10,000 บาท) จัดเตรียมข้อมูลในรูปแบบตารางสามเหลี่ยมสำหรับในการวิเคราะห์การประมาณค่าเงินสำรองสินไหม ซึ่งสามารถตรวจสอบความครบถ้วนและความต่อเนื่องของข้อมูลค่าสินไหมในแต่ละปีอุบัติเหตุ และวิเคราะห์รูปแบบการเพิ่มขึ้นของค่าสินไหมตามช่วงเวลาที่มีการพัฒนา ที่เป็นขั้นตอนสำคัญก่อนนำข้อมูลไปใช้คำนวณอัตราการพัฒนา (Development Factor) ดังตารางที่ 3.1

ตารางที่ 3.1 ข้อมูลค่าสินไหมจ่ายสะสม (หน่วย : 10,000 บาท) ตามช่วงเวลาที่มีการพัฒนา

ปี อุบัติเหตุ	ค่าสินไหมจ่ายสะสม (หน่วย : 10,000 บาท) ตามช่วงเวลาที่มีการพัฒนา													
	ช่วงเวลาที่มีการพัฒนา (เดือน)													
	6	12	18	24	30	36	42	48	54	60	66	72	78	
2019	7,585	53,552	114,075	161,142	165,882	166,424	166,615	170,098	170,102	170,476	170,560	170,565	170,572	
2020	13,529	77,768	115,038	132,466	166,501	175,006	183,681	185,400	192,254	192,254	192,254			
2021	10,436	60,549	145,355	166,996	188,644	189,102	190,129	190,758	190,775					
2022	7,581	39,105	71,715	89,423	130,613	134,728	140,502							
2023	6,906	50,425	126,036	153,286	182,916									
2024	10,473	71,200	120,654											
2025	5,641													



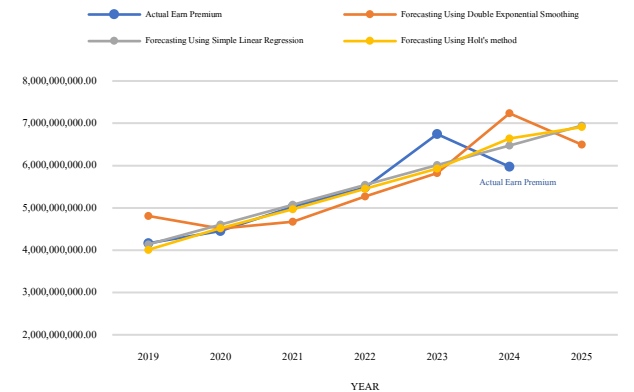
ภาพที่ 3.1 ข้อมูลร้อยละของค่าสินไหมจ่ายสะสมตามช่วงเวลาที่มีการพัฒนา

จากรูปที่ 3.1 กราฟมีลักษณะเป็นเส้นโค้งที่มีความชันสูงมากในช่วงแรก และค่อย ๆ ลดจนเป็นเส้นตรงในแนวนอนเมื่อเวลาผ่านไป แสดงว่าการจ่ายค่าสินไหมเกิดขึ้นอย่างรวดเร็วในช่วง 3 ปีแรก (36 เดือน) โดย ณ สิ้นสุดเดือนที่ 24 บริษัทได้จ่ายค่าสินไหมไปแล้วถึง 62.07% และจ่ายไปแล้วนับเป็น 93.08% ณ สิ้นสุดเดือนที่ 36 ของช่วงเวลาที่มีการพัฒนา

3.4 แนวโน้มค่าเบี้ยประกันภัยที่ถือเป็นรายได้ (Earned Premium)

ในการศึกษานี้ ทำการพยากรณ์ค่า Earned Premium สำหรับปี ค.ศ. 2025 โดยใช้ข้อมูล Earned Premium รายปี ตั้งแต่ปี ค.ศ. 2019 ถึง ค.ศ. 2024 ในการสร้างแบบจำลองพยากรณ์ โดยได้ทำการตรวจสอบความเหมาะสมและสมมติฐานของแบบจำลองก่อนการนำมาใช้ในการวิเคราะห์ เพื่อให้แบบจำลองมีความสอดคล้องกับลักษณะของข้อมูลจากการพิจารณาวิธีการพยากรณ์ที่เหมาะสมสำหรับข้อมูลอนุกรมเวลาที่มีแนวโน้ม โดยเลือกใช้ตัวแบบพยากรณ์ 3 ตัวแบบ ได้แก่ วิธีการปรับเรียบแบบเอ็กซ์โปเนนเชียลสองชั้นของบราวน์ (Double Exponential Smoothing; Brown's Method) วิธีการถดถอยเชิงเส้นอย่างง่าย (Simple Linear

Regression) และวิธีการปรับเรียบเอ็กซ์โปเนนเชียลสองเท่า (Holt's Method จากนั้นนำผลการพยากรณ์ของแต่ละแบบจำลองมาเปรียบเทียบความแม่นยำของการพยากรณ์ เพื่อคัดเลือกแบบจำลองที่ให้ผลเหมาะสมที่สุดค่าพยากรณ์ Earned Premium ที่ได้จะถูกนำไปใช้เป็นข้อมูลประกอบในการประมาณค่าเงินสำรองสินไหมด้วยวิธี Expected Loss Ratio (ELR) และวิธี Bornhuetter-Ferguson (BF) โดยผลการพยากรณ์จากแต่ละตัวแบบ แสดงดังตารางต่อไปนี้



ภาพที่ 3.2 แสดงการเปรียบเทียบค่าจริงและค่าพยากรณ์ของเบี้ยประกันภัยที่ถือเป็นรายได้

ตารางที่ 3.2 ค่าความคลาดเคลื่อน และค่าพยากรณ์เบี้ยประกันภัยที่ถือเป็นรายได้

Year	Earn Premium	Double Exponential Smoothing	APE (%)	Simple Linear Regression	APE (%)	Holt's Method	APE (%)
2019	4,163,959,327.60	4,811,006,110.78	15.54	4,137,876,379.76	0.63	4,010,192,068.79	3.69
2020	4,455,038,508.64	4,511,614,797.56	1.27	4,605,518,706.91	3.38	4,523,287,063.01	1.53
2021	5,025,166,825.32	4,670,369,348.63	7.06	5,073,161,034.06	0.96	4,970,753,220.88	1.08
2022	5,480,934,990.38	5,271,675,783.51	3.82	5,540,803,361.21	1.09	5,454,478,854.12	0.48
2023	6,743,671,110.10	5,821,181,761.64	13.68	6,008,445,688.36	10.90	5,929,940,159.08	12.07
2024	5,973,122,423.77	7,234,157,339.90	21.11	6,476,088,015.51	8.42	6,638,123,643.90	11.13
2025	-	6,492,829,691.19	-	6,943,730,342.66	-	6,909,187,368.98	-
MAPE			10.41		4.23		5.00

จากภาพที่ 3.2 พบว่า Earned Premium ค่าจริง โดยรวมแล้ว มีแนวโน้มเพิ่มขึ้น มีเพียงช่วงเวลาปลายหางของข้อมูล พบการเบี่ยงเบนจากแนวโน้มดังกล่าว ข้อมูลมีความผันผวน เมื่อพิจารณาผลการประเมินค่าความแม่นยำจากค่า MAPE พบว่าวิธีการถอดออกเชิงเส้นอย่างง่าย มีค่า MAPE ต่ำที่สุด โดยมีค่าเท่ากับ 4.23 ซึ่งเป็นวิธีที่มีความเหมาะสมกับข้อมูลมากที่สุด สำหรับใช้พยากรณ์ค่า Earned Premium ของการประกัน IAR โดยมีค่าพยากรณ์ Earned Premium ในปี 2025 เท่ากับ 6,943,730,342.66 บาท ดังแสดงผลในตารางที่ 3.2

3.5 ผลการประมาณค่าคาดหมายของอัตราส่วนค่าความเสียหาย (Expected Loss Ratio: %ELR)

ในการประมาณค่า Expected Loss Ratio (%ELR) โดยใช้ข้อมูลอัตราค่าความเสียหาย (Loss Ratio) ของประกันภัย IAR จากสำนักงานคณะกรรมการกำกับและส่งเสริมการประกอบธุรกิจประกันภัย (คปภ.) [8] ในช่วงปี ค.ศ. 2016 ถึง ค.ศ. 2024 มาคำนวณ โดยใช้ วิธีค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (WMA) โดยกำหนดอัตราส่วนถ่วงน้ำหนักเป็น 5:3:2 โดยให้น้ำหนักกับปีล่าสุดมากกว่าปีก่อน เพื่อสะท้อนแนวโน้มการเปลี่ยนแปลงตามสภาวะปัจจุบัน

ตารางที่ 3.3 ข้อมูลการประมาณค่าคาดหมายของอัตราส่วนค่าความเสียหาย (Expected Loss Ratio: %ELR)

Year	Loss Ratio	Expected Loss Ratio (%ELR)
2016	48.69%	-
2017	45.50%	-
2018	39.27%	-
2019	44.20%	43.02%
2020	48.91%	42.98%
2021	35.79%	45.57%
2022	39.87%	41.41%
2023	36.00%	40.45%
2024	39.81%	37.12%
2025	-	38.68%

จากตารางที่ 3.3 พบว่าค่า %ELR ที่คาดการณ์ในปี ค.ศ. 2019 ถึง ค.ศ. 2025 มีค่าอยู่ระหว่าง 37.12% – 45.57% โดยที่ค่า Expected Loss Ratio (%ELR) ที่ได้จะถูกนำไปใช้คำนวณการประมาณการค่าเงินสำรองสินไหมในวิธี Expected Loss Ratio (ELR) และวิธี Bornhuetter-Ferguson (BF) ต่อไป

3.6 ผลการประมาณค่าเงินสำรองสินไหมในประกันความเสี่ยงภัยทรัพย์สิน (IAR)

ในการศึกษาครั้งนี้ ได้ทำการประมาณค่าเงินสำรองสินไหมในประกัน IAR สำหรับปีอุบัติเหตุ ค.ศ. 2019 ถึง ค.ศ. 2025 ผลลัพธ์ทั้ง 3 วิธีของการประมาณค่าเงินสำรองสินไหม เพื่อเปรียบเทียบค่าประมาณของแต่ละวิธีตามปีอุบัติเหตุ แสดงดังตารางต่อไปนี้

ตารางที่ 3.4 ผลการประมาณค่าเงินสำรองสินไหม (Loss Reserving)

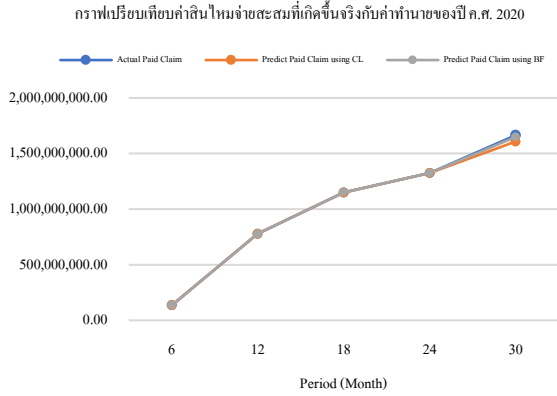
Year	Paid to Date	Reserving using Chain Ladder	Reserving using Expected Loss Ratio	Reserving using Bornhuetter-Ferguson
2019	1,707,955,844.84	1,023,431.67	85,768,247.53	1,074,248.07
2020	1,922,644,762.77	1,286,066.04	-7,721,640.37	1,753,863.54
2021	1,907,745,256.23	3,845,912.42	382,173,014.40	32,505,792.36
2022	1,405,024,381.12	36,183,191.73	864,526,593.77	110,393,872.59
2023	1,829,158,864.89	135,977,911.01	898,925,845.99	636,308,377.72
2024	1,206,539,848.82	737,209,896.44	1,010,623,463.66	1,531,028,268.61
2025	56,407,659.96	1,094,289,993.36	2,629,357,799.28	2,554,122,607.63
Total		2,009,816,402.68	5,863,653,324.26	4,867,187,030.53

จากตารางที่ 3.4 เมื่อพิจารณาค่าเงินสำรองสินไหมรวมทุกปี อุบัติเหตุ พบว่าวิธี Expected Loss Ratio (ELR) ให้ค่าประมาณเงินสำรองสินไหมรวมสูงที่สุด รองลงมาคือวิธี Bornhuetter-Ferguson (BF) และวิธี Chain Ladder (CL) ตามลำดับ ซึ่งสะท้อนถึงความแตกต่างของสมมติฐานและหลักการคำนวณของแต่ละวิธี นอกจากนี้พบว่าในปีอุบัติเหตุ 2020 วิธี ELR ให้ค่าเงินสำรองติดลบ ซึ่งอาจเกิดจาก ค่าสินไหมจ่ายสะสมจนถึงปัจจุบัน (Paid-to-Date) สูงกว่ามูลค่าความเสียหายที่คาดการณ์จากค่า Expected Loss Ratio ส่งผลให้ค่าประมาณเงินสำรองมีค่าเป็นลบ

ตารางที่ 3.5 ค่าความคลาดเคลื่อน และค่าประมาณมูลค่าความเสียหายสมบูรณ์สำหรับประกันความเสี่ยงภัยทรัพย์สิน

Year	Actual Ultimate Loss	Predict Ultimate Loss using Chain Ladder Method	Absolute Percentage Error (%)	Predict Ultimate Loss using Expected Loss Ratio	Absolute Percentage Error (%)	Predict Ultimate Loss using Bornhuetter-Ferguson	Absolute Percentage Error (%)
2019	1,705,654,470.56	1,706,677,863.24	0.06	1,791,487,703.64	5.03	1,706,728,718.63	0.06
2020	1,922,541,741.77	1,924,709,043.01	0.11	1,914,820,101.40	0.40	1,924,697,907.66	0.11
2021	1,907,580,170.86	1,947,154,525.43	2.08	2,289,918,270.63	20.04	1,954,120,923.74	2.44
2022	1,347,277,604.14	1,416,587,534.66	5.15	2,269,545,560.82	68.45	1,458,320,544.50	8.25
2023	1,532,858,843.53	2,011,796,102.94	31.02	2,728,084,710.88	77.97	2,182,319,001.52	42.14
MAPE			7.69		34.38		10.60


จากตารางที่ 3.5 ผลการประเมินประสิทธิภาพด้วยค่าเฉลี่ยร้อยละความคลาดเคลื่อนสัมบูรณ์ (MAPE) พบว่าวิธี Chain Ladder (CL) และวิธี Bornhuetter-Ferguson (BF) ให้ค่า MAPE ต่ำกว่าวิธี Expected Loss Ratio (ELR) แสดงว่าวิธีทั้งสองมีความสามารถในการประมาณค่ามูลค่าความเสียหายสมบูรณ์ (Estimated Ultimate Loss) หรือค่าความเสียหายสะสมขั้นสุดท้ายได้ใกล้เคียงกับค่าที่เกิดขึ้นจริง โดยภาพรวมมากกว่า ดังนั้น ในงานวิจัยนี้จึงเลือกใช้วิธีการคำนวณค่าเงินสำรองสินไหมด้วยวิธี Chain Ladder (CL) และวิธี Bornhuetter-Ferguson (BF) นำไปทดสอบประสิทธิภาพด้วยการทดสอบย้อนหลังกับข้อมูลในอดีต (Back Testing) ตามช่วงเวลาที่มีการพัฒนาของข้อมูล โดยวิเคราะห์ค่า MAPE จำแนกตามแต่ละช่วงเวลาที่มีการพัฒนาของแต่ละปี เพื่อศึกษาพฤติกรรมของความคลาดเคลื่อนและประเมินความเหมาะสมของแต่ละวิธีในการประมาณค่าเงินสำรองสินไหมในแต่ละช่วงเวลา โดยมีผลดังต่อไปนี้



ภาพที่ 3.3 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2020

ตารางที่ 3.6 ค่าความคลาดเคลื่อน และเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2020

Year	Development Period (Month)	Actual Paid Claim	Predict Paid Claim using CL	Predict Paid Claim using BF	APE CL Method	APE BF Method
2020	30	1,665,013,669.37	1,608,113,283.64	1,648,750,187.44	3.42	0.98




ภาพที่ 3.4 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2021

ตารางที่ 3.7 ค่าความคลาดเคลื่อน และเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2021

Year	Development Period (Month)	Actual Paid Claim	Predict Paid Claim using CL	Predict Paid Claim using BF	APE CL Method	APE BF Method
2021	24	1,669,961,262.13	1,795,459,588.45	1,780,404,455.58	7.52	6.61
2021	30	1,886,439,772.61	2,179,655,855.60	2,154,401,795.37	15.54	14.20

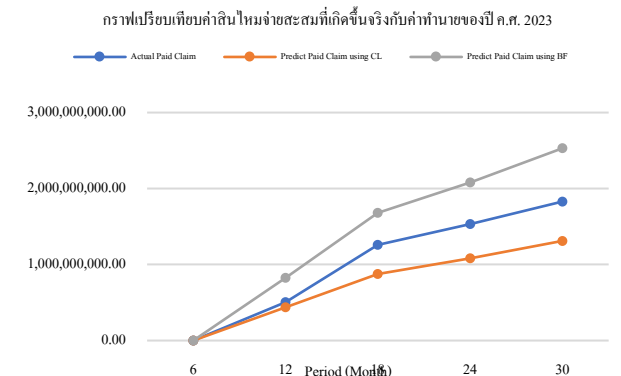
จากภาพที่ 3.3 - 3.4 และตารางที่ 3.6 - 3.7 พบว่า เมื่อพิจารณาค่าเปอร์เซ็นต์ของความคลาดเคลื่อนสัมบูรณ์ (APE) ในแต่ละช่วงเวลาที่มีการพัฒนาของปี ค.ศ. 2020 ถึง ค.ศ. 2021 พบว่าวิธี Bornhuetter-Ferguson (BF) ให้ค่าความคลาดเคลื่อนต่ำกว่าวิธี Chain Ladder (CL) ในทุกช่วงเวลาที่มีการพัฒนา เนื่องจากการใช้ข้อมูลค่า %ELR ร่วมกับข้อมูลการจ่ายจริง ทำให้ผลการประมาณมีความเสถียรและอ่อนไหวน้อยกว่าต่อความไม่สมบูรณ์ของข้อมูลในช่วงต้นของการพัฒนา ส่งผลให้วิธี Bornhuetter-Ferguson (BF) มีประสิทธิภาพมากกว่าในปีช่วงดังกล่าว



ภาพที่ 3.5 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2022

ตารางที่ 3.8 ค่าความคลาดเคลื่อน และเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2022

Year	Development Period (Month)	Actual Paid Claim	Predict Paid Claim using CL	Predict Paid Claim using BF	APE CL Method	APE BF Method
2022	18	717,146,285.59	784,579,878.02	1,215,655,355.07	9.40	69.51
2022	24	894,227,652.19	969,130,349.17	1,592,075,819.36	8.38	78.04
2022	30	1,306,131,769.39	1,176,506,925.58	1,974,681,212.44	9.92	51.19



ภาพที่ 3.6 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2023

ตารางที่ 3.9 ค่าความคลาดเคลื่อน และเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2023


Year	Development Period (Month)	Actual Paid Claim	Predict Paid Claim using CL	Predict Paid Claim using BF	APE CL Method	APE BF Method
2023	12	504,248,917.13	435,868,209.50	824,019,803.56	13.56	63.42
2023	18	1,260,358,846.83	874,495,409.57	1,680,978,884.77	30.62	33.37
2023	24	1,532,858,843.53	1,080,195,994.53	2,082,200,557.66	29.53	35.84
2023	30	1,829,158,864.89	1,311,338,634.31	2,530,450,846.80	28.31	38.34

จากภาพที่ 3.5 - 3.6 และตารางที่ 3.8 - 3.9 พบว่า เมื่อพิจารณาค่า APE ในแต่ละช่วงเวลาที่มีการพัฒนาของปี ค.ศ. 2022 ถึง ค.ศ. 2023 วิธี Chain Ladder (CL) ให้ค่าความคลาดเคลื่อนอยู่ในระดับต่ำและมีความคงที่ตลอดช่วงเวลาที่มีการพัฒนา เนื่องจากรูปแบบการพัฒนาค่าสินไหมสอดคล้องกับแนวโน้มในอดีต ส่งผลให้การประมาณค่าเงินสำรองมีความเหมาะสม ขณะที่วิธี Bornhuetter-Ferguson (BF) ให้ค่า

ความคลาดเคลื่อนสูงจากการประมาณค่าที่สูงกว่าความเป็นจริง เนื่องจากค่า %ELR ที่ใช้ไม่สอดคล้องกับประสบการณ์ความเสียหายจริงของปีดังกล่าว จึงสะท้อนว่าวิธี Chain Ladder (CL) มีประสิทธิภาพมากกว่าในช่วงปีดังกล่าว

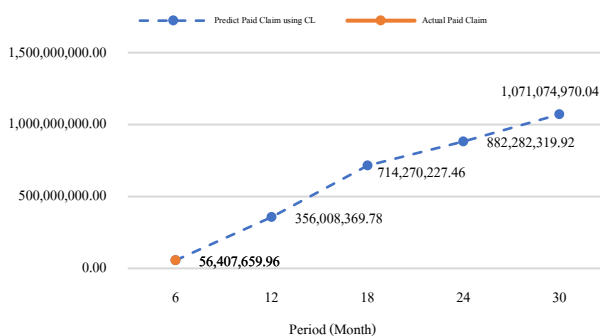
จากผลการเปรียบเทียบประสิทธิภาพของวิธี Chain Ladder (CL) และ Bornhuetter–Ferguson (BF) ในช่วงปี ค.ศ. 2020 ถึง ค.ศ. 2023 พบว่าวิธี Chain Ladder (CL) ให้ค่าประมาณที่มีความสอดคล้องกับข้อมูลจริงและมีค่า APE อยู่ในระดับต่ำอย่างสม่ำเสมอ โดยเฉพาะในช่วงปีหลังที่รูปแบบการพัฒนาค่าสินไหมมีความใกล้เคียงกับแนวโน้มในอดีต ผลดังกล่าวสะท้อนได้ว่าวิธี Chain Ladder (CL) มีความเหมาะสมในการนำมาใช้เป็นวิธีหลักสำหรับการคำนวณค่าประมาณค่าสินไหมจ่ายสะสมในอนาคตภายใต้บริบทของข้อมูลชุดนี้ ดังนั้น ในส่วนถัดไปของการวิเคราะห์จึงนำวิธี Chain Ladder (CL) มาใช้ในการทำนายค่าสินไหมจ่ายสะสมสำหรับปี ค.ศ. 2024 และ ค.ศ. 2025 เพื่อใช้ประกอบการพิจารณาแนวโน้มค่าสินไหมที่คาดว่าจะเกิดขึ้นในอนาคต โดยผลเป็นดังต่อไปนี้

กราฟเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2024



ภาพที่ 3.7 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2024

กราฟเปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2025



ภาพที่ 3.8 เปรียบเทียบค่าสินไหมจ่ายสะสมที่เกิดขึ้นจริงกับค่าทำนายของปี ค.ศ. 2025

จากภาพที่ 3.7 – 3.8 การใช้วิธี Chain Ladder (CL) ในการทำนายค่าสินไหมจ่ายสะสมสำหรับปี ค.ศ. 2024 และ ค.ศ. 2025 แสดงถึงค่าประมาณมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องตามช่วงเวลาที่มีการพัฒนา สอดคล้องกับรูปแบบการพัฒนาค่าสินไหมในอดีต โดยปี ค.ศ. 2024 มีระดับค่าสินไหมจ่าย

สะสมที่คาดการณ์สูงกว่าปี ค.ศ. 2025 อย่างชัดเจน สะท้อนถึงความแตกต่างของระดับความเสี่ยงระหว่างแต่ละปี ทั้งนี้ การที่ข้อมูลการจ่ายจริงในช่วงต้นมีค่าต่ำกว่าค่าประมาณถือเป็นลักษณะปกติของข้อมูลที่ยังพัฒนาไม่สมบูรณ์ และอยู่ภายใต้สมมติฐานของวิธี Chain Ladder (CL)

4. สรุปผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์และเปรียบเทียบวิธีการประมาณค่าเงินสำรองสินไหมในการประกันความเสี่ยงภัยทรัพย์สิน โดยใช้วิธี Chain Ladder (CL) วิธี Expected Loss Ratio (ELR) และวิธี Bornhuetter–Ferguson (BF) และประเมินประสิทธิภาพของแต่ละวิธีโดยใช้ค่า Mean Absolute Percentage Error (MAPE) ผลการศึกษาพบว่า วิธี Chain Ladder ให้ความแม่นยำในการประมาณค่าสูงที่สุด โดยมีค่า MAPE เท่ากับ 7.69% รองลงมาคือวิธี Bornhuetter–Ferguson ซึ่งมีค่า MAPE เท่ากับ 10.60% และวิธี Expected Loss Ratio มีค่า MAPE สูงที่สุด เท่ากับ 34.38% แสดงให้เห็นว่าวิธี Chain Ladder สามารถประมาณค่าเงินสำรองสินไหมได้ใกล้เคียงกับข้อมูลจริงมากที่สุดภายใต้ข้อมูลที่ใช้ในการศึกษา เมื่อพิจารณาผลการประมาณค่าเงินสำรองสินไหมรวมทุกปี อุบัติเหตุ พบว่าวิธี Expected Loss Ratio ให้ค่าเงินสำรองรวมสูงที่สุด รองลงมาคือวิธี Bornhuetter–Ferguson และวิธี Chain Ladder ตามลำดับ ซึ่งสะท้อนถึงความแตกต่างของหลักการคำนวณของแต่ละวิธี โดยวิธีที่อาศัยสมมติฐานของอัตราส่วนค่าความเสียหายและข้อมูลเบี่ยงประกันภัยจะให้ค่าประมาณเงินสำรองสูงกว่าในกรณีที่ข้อมูลค่าสินไหมยังพัฒนาไม่ครบถ้วน โดยสรุป วิธี Chain Ladder เหมาะสมสำหรับใช้เป็นวิธีหลักในการประมาณค่าเงินสำรองสินไหมเมื่อมีข้อมูลการพัฒนาค่าสินไหมที่เพียงพอ ขณะที่วิธี Bornhuetter–Ferguson เหมาะสำหรับกรณีที่ข้อมูลยังไม่สมบูรณ์ และวิธี Expected Loss Ratio สามารถใช้เป็นข้อมูลประกอบในการวิเคราะห์การประมาณค่าเงินสำรองสินไหมได้

5. ข้อเสนอแนะ

ควรพิจารณาการใช้วิธีการประมาณค่าเงินสำรองหรือแบบจำลองขั้นสูงเพิ่มเติมเพื่อประเมินความไม่แน่นอนควบคู่กับการขยายการศึกษาไปยังประกันภัยวินาศภัยประเภทอื่นและวิเคราะห์ผลกระทบของเหตุการณ์ขนาดใหญ่หรือเหตุการณ์ที่เกิดขึ้นไม่บ่อย เพื่อเพิ่มความเหมาะสมและความแม่นยำในการตั้งสำรองสินไหมทดแทน

6. เอกสารอ้างอิง

- [1] สมาคมประกันวินาศภัยไทย. คู่มือประกันวินาศภัยไทย. พิมพ์ครั้งที่ 1. กรุงเทพฯ: สมาคมประกันวินาศภัยไทย; 2564.
- [2] สำนักงานคณะกรรมการกำกับและส่งเสริมการประกอบธุรกิจประกันภัย. การคำนวณเงินสำรองค่าสินไหมทดแทน (Loss Reserving). กรุงเทพฯ: สำนักงาน

- คณะกรรมการกำกับและส่งเสริมการประกอบธุรกิจ
ประกันภัย; 2551.
- [3] ยูพาทรณ์ อารีพงษ์. เอกสารประกอบการสอนวิชาการ
พยากรณ์ทางธุรกิจ. กรุงเทพฯ: มหาวิทยาลัยเทคโนโลยี
พระจอมเกล้าพระนครเหนือ; 2567.
- [4] กัทรพงศ์ สกุลวิโรภาส. เอกสารประกอบการสอนวิชา
สถิติประกันวินาศภัย. กรุงเทพฯ: มหาวิทยาลัยเทคโนโลยี
พระจอมเกล้าพระนครเหนือ; 2567.
- [5] Brown RL, Lennox WS. Introduction to ratemaking and
loss reserving for property and casualty insurance. 4th ed.
Winsted (CT): ACTEX Publications; 2015.
- [6] Makridakis SG, Wheelwright SC, Hyndman RJ.
Forecasting: methods and applications. 3rd ed. New York:
John Wiley & Sons; 1998.
- [7] Hyndman RJ, Athanasopoulos G. Forecasting: principles
and practice [Internet]. 3rd ed. Melbourne: OTexts; 2021
[cited 2025 Aug 20]. Available from:
<https://otexts.com/fpp3/>
- [8] Office of Insurance Commission (OIC). Industry Statistic &
Data [document on the Internet]. Bangkok: Office of
Insurance Commission; [cited 2025 Aug 14]. Available
from: <https://www.oic.or.th/th/industry-statistic-data-39-2/>.
- [9] Adam FF. Claim reserving estimation by using the chain
ladder method. In: Proceedings of the 2nd International
Conference on Vocational Higher Education (ICVHE);
2017 Oct; Depok, Indonesia. Depok: Knowledge E; 2018.
1194–1198.

ลักษณะเชิงเศรษฐกิจและสังคมของผู้เอาประกันสุขภาพในประเทศไทย

Socioeconomic Profiles of Health Insurance Policyholders in Thailand

สรพัส วงศ์เคี่ยม* และ ธิฏฐิรัตน์ พิมลศรี

ภาควิชาสถิติประยุกต์ คณะสถิติประยุกต์ สถาบันบัณฑิตพัฒนบริหารศาสตร์

(*email: 6620423005@stu.nida.ac.th)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อจำแนกกลุ่มผู้เอาประกันสุขภาพในประเทศไทยตามลักษณะเศรษฐกิจและสังคมของครัวเรือน โดยใช้ข้อมูลทุติยภูมิจากการสำรวจภาวะเศรษฐกิจและสังคมของครัวเรือน พ.ศ. 2564 ของสำนักงานสถิติแห่งชาติ ศึกษาเฉพาะผู้ที่มีกรมธรรม์ประกันสุขภาพจำนวน 3,814 คน ตัวแปรนำเข้าที่ใช้ในการจำแนกกลุ่มประกอบด้วยตัวแปรเชิงปริมาณ ได้แก่ อายุ รายได้ครัวเรือน ค่าเบี้ยประกัน และค่าใช้จ่ายด้านเวชภัณฑ์ ร่วมกับตัวแปรเชิงคุณภาพ ได้แก่ เพศ สถานภาพสมรส ระดับการศึกษา และชนชั้นทางเศรษฐกิจ การวิเคราะห์ใช้การวิเคราะห์แบ่งกลุ่มแบบสองขั้นตอน และประเมินคุณภาพของการจัดกลุ่มด้วยดัชนีความสอดคล้องและการแยกจากกันของกลุ่ม

ผลการศึกษาแสดงให้เห็นว่าแบบจำลองที่เหมาะสมคือการจำแนกเป็น 3 กลุ่ม โดยใช้ตัวแปรนำเข้า 8 ตัวแปร ซึ่งให้ค่า Silhouette เป็น 0.38 ซึ่งอยู่ในระดับค่อนข้างดีและสามารถตีความเชิงประยุกต์ได้ ได้ผลการแบ่งกลุ่มเป็น 3 กลุ่มหลัก คือ กลุ่มที่ 1 กลุ่มวิชาชีพที่มีรายได้และการศึกษาสูง มีค่าเบี้ยประกันและค่าใช้จ่ายด้านสุขภาพสูง กลุ่มที่ 2 เป็นกลุ่มแรงงานภาคบริการและการผลิตที่มีรายได้และการศึกษาปานกลาง มีการเลือกความคุ้มครองในระดับสอดคล้องกับกำลังซื้อ และกลุ่มที่ 3 เป็นกลุ่มแรงงานฐานรากที่มีการศึกษาขั้นพื้นฐาน รายได้ต่ำ และมีค่าใช้จ่ายด้านประกันและเวชภัณฑ์ต่ำ โดยมีอายุเฉลี่ยสูงที่สุด ผลการศึกษาชี้ว่าปัจจัยด้านอายุ ระดับการศึกษา อาชีพ และรายได้ครัวเรือนมีบทบาทสำคัญต่อรูปแบบการเลือกประกันสุขภาพและระดับความคุ้มครองที่เลือกใช้ องค์ความรู้ที่ได้สามารถใช้เป็นข้อมูลพื้นฐานในการทำความเข้าใจโครงสร้างผู้เอาประกันสุขภาพในประเทศไทย และสนับสนุนการพัฒนาผลิตภัณฑ์ การออกแบบบริการ และแนวทางเงินโยบายให้สอดคล้องกับลักษณะของผู้เอาประกันในแต่ละกลุ่ม

คำสำคัญ: การจำแนกกลุ่มผู้เอาประกันสุขภาพ, การวิเคราะห์แบ่งกลุ่มสองขั้น, ประกันสุขภาพ

Abstract

This study aims to segment health insurance policyholders in Thailand based on household socioeconomic characteristics using secondary data from the 2021 Household Socio-Economic Survey conducted by the National Statistical Office of Thailand. The analysis focuses on 3,814 individuals holding health insurance policies. The clustering inputs include quantitative variables: age, household income, insurance premium, and expenditure on medical supplies, together with categorical variables: sex, marital status, educational attainment, and economic class. Two-step cluster analysis is employed, and clustering quality is assessed using the Silhouette measure of cohesion and separation.

The results indicate that the optimal solution consists of three clusters using eight input variables, yielding a Silhouette value of 0.38, which suggests a fairly good and interpretable clustering structure. Cluster 1 represents professional policyholders with higher income and higher education, characterized by higher premiums and higher health-related expenditures. Cluster 2 comprises service and manufacturing workers with moderate income and education, who tend to select insurance coverage at an affordable level aligned with their financial capacity. Cluster 3 includes lower-skilled policyholders with basic education and lower income, showing the lowest premium and medical-supply expenditures while having the highest average age. Overall, the findings highlight that age, education, occupation, and household income play important roles in shaping health insurance

choices and coverage levels. The resulting segmentation provides baseline evidence for understanding the structure of health insurance policyholders in Thailand and can support product development, service design, and policy directions tailored to the characteristics of each group.

Keywords: health insurance policyholder segmentation; two-step cluster analysis; health insurance

1. บทนำ

ในปัจจุบัน ค่าใช้จ่ายด้านการรักษาพยาบาลของประชาชนในประเทศไทยมีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่อง อันเป็นผลจากความก้าวหน้าทางเทคโนโลยีทางการแพทย์ การเปลี่ยนแปลงโครงสร้างประชากรเข้าสู่สังคมผู้สูงอายุ และการเพิ่มขึ้นของโรคไม่ติดต่อเรื้อรัง ปัจจัยดังกล่าวส่งผลให้ประกันสุขภาพมีบทบาทสำคัญในการช่วยบริหารความเสี่ยงด้านค่าใช้จ่ายทางการแพทย์ของประชาชน และเป็นเครื่องมือสำคัญในการเสริมสร้างความมั่นคงด้านสุขภาพในระดับครัวเรือนและระดับประเทศ อย่างไรก็ตาม ผู้เอาประกันภัยสุขภาพในประเทศไทยมีลักษณะที่แตกต่างกันอย่างหลากหลาย ทั้งในด้านประชากรศาสตร์ เศรษฐกิจ และสังคม เช่น อายุ รายได้ ระดับการศึกษา และอาชีพ ความแตกต่างดังกล่าวสะท้อนให้เห็นถึงความไม่เป็นเนื้อเดียวกันของผู้เอาประกันภัย ทั้งในด้านความสามารถในการชำระเบี้ยประกัน ความต้องการด้านความคุ้มครอง และระดับความเสี่ยงด้านสุขภาพ ส่งผลให้ผู้เอาประกันภัยแต่ละรายมีพฤติกรรมการตัดสินใจซื้อประกันสุขภาพที่แตกต่างกัน ในทางปฏิบัติ บริษัทประกันภัยในประเทศไทยจำนวนมากยังคงใช้เกณฑ์พื้นฐานบางประการในการออกแบบผลิตภัณฑ์และกำหนดเบี้ยประกัน เช่น อายุและเพศ เกณฑ์ดังกล่าวมีบทบาทสำคัญในการกำหนดโครงสร้างผลิตภัณฑ์และเบี้ยประกันในทางปฏิบัติ อย่างไรก็ตาม ในบางบริบทอาจยังมีโอกาสในการพัฒนาเพิ่มเติมเพื่อให้สามารถสะท้อนความหลากหลายของผู้เอาประกันภัยได้ดียิ่งขึ้น ซึ่งอาจช่วยสนับสนุนความเหมาะสมของการกำหนดเบี้ยประกันและการออกแบบผลิตภัณฑ์ให้สอดคล้องกับลักษณะความเสี่ยงของผู้เอาประกันภัยในระยะยาวมากขึ้น

ดังนั้น การนำเทคนิคการวิเคราะห์ข้อมูลทางสถิติมาใช้ในการจำแนกกลุ่มผู้เอาประกันภัยสุขภาพจึงมีความจำเป็น โดยเฉพาะการวิเคราะห์การจัดกลุ่มแบบสองขั้นตอน (Two-Step Cluster Analysis) ซึ่งเป็นวิธีที่ใช้ได้กับการวิเคราะห์ที่ตัวแปรที่ใช้ในการจัดกลุ่มมีทั้งเชิงปริมาณและเชิงคุณภาพ และเหมาะสมกับข้อมูลขนาดใหญ่ เทคนิคดังกล่าวช่วยให้สามารถจำแนกผู้เอาประกันภัยออกเป็นกลุ่มที่มีลักษณะคล้ายคลึงกันภายในกลุ่ม และมีความแตกต่างอย่างชัดเจนระหว่างกลุ่ม

2. วัตถุประสงค์

เพื่อจำแนกกลุ่มผู้เอาประกันภัยสุขภาพในประเทศไทยตามลักษณะเศรษฐกิจของครัวเรือน โดยใช้การวิเคราะห์การจัดกลุ่มแบบสองขั้นตอน (Two-Step Cluster Analysis)

3. การทบทวนวรรณกรรม

การวิจัยนี้ผู้วิจัยได้ค้นคว้า งานวิจัยที่เกี่ยวข้อง และมีการทบทวนวรรณกรรมโดยอาศัยแนวคิดหลายส่วนมาเป็นกรอบและแนวทางในการศึกษา โดยนำเสนอเป็นประเด็นตามหัวข้อต่อไปนี้

3.1 ปัจจัยที่มีผลต่อการจัดกลุ่มผู้ถือประกันภัย

งานศึกษาที่เกี่ยวข้องกับประกันสุขภาพในประเทศไทยสะท้อนว่าความแตกต่างของผู้เอาประกันสามารถอธิบายได้จากปัจจัยพื้นฐานด้านประชากรศาสตร์ เศรษฐกิจ และสังคม โดยเฉพาะอายุ รายได้ ระดับการศึกษา อาชีพ และภาระของครัวเรือน ซึ่งสัมพันธ์กับการตัดสินใจซื้อประกันและประเภทความคุ้มครองที่เลือก [1,2] นอกจากนี้ ปัจจัยด้านการรับรู้และทัศนคติ เช่น การรับรู้ความเสี่ยงด้านสุขภาพ ความเชื่อมั่นต่อผลิตภัณฑ์ และการรับรู้ความคุ้มค่า ยังมีความเชื่อมโยงกับความตั้งใจซื้อและการเลือกแผนประกันที่แตกต่างกัน [3] ในระดับสากล งานด้านเศรษฐศาสตร์สุขภาพชี้ว่าการเปลี่ยนแปลงทางเทคโนโลยีการแพทย์และค่าใช้จ่ายด้านสุขภาพที่เพิ่มขึ้นทำให้ความต้องการและรูปแบบการใช้บริการของประชากรมีความแตกต่างมากขึ้น [4] ขณะที่งานศึกษาพบว่าการวิเคราะห์แบ่งกลุ่มผู้เอาประกันจากข้อมูลการใช้ยาสามารถจำแนกกลุ่มความเสี่ยงต่ำ ปานกลาง และสูงได้อย่างชัดเจน [8] โดยแต่ละกลุ่มมีลักษณะด้านอายุและค่าใช้จ่ายต่างกัน

3.2 การใช้การวิเคราะห์แบ่งกลุ่มในการจัดกลุ่มผู้เอาประกันภัย

งานด้านการวิเคราะห์ข้อมูลในอุตสาหกรรมประกันภัยได้ประยุกต์ใช้การวิเคราะห์แบ่งกลุ่มเพื่อจำแนกลูกค้าหรือผู้ถือกรมธรรม์ออกเป็นกลุ่มที่มีลักษณะคล้ายกัน โดย Hanafizadeh and Paydar [5] เสนอแบบจำลองเหมืองข้อมูลที่สามารถแบ่งกลุ่มลูกค้าตามระดับความเสี่ยงและพฤติกรรมได้อย่างมีประสิทธิภาพ ส่วน Qadadeh and Abdallah [9] ใช้การวิเคราะห์แบ่งกลุ่มกับฐานข้อมูลลูกค้าประกันภัยและพบว่าสามารถแยกโปรไฟล์ลูกค้าออกเป็นหลายกลุ่มที่มีลักษณะด้านอายุและพฤติกรรมแตกต่างกัน

สำหรับประกันสุขภาพ Khairi et al. [7] ใช้การวิเคราะห์แบ่งกลุ่มกับข้อมูลผู้ถือกรมธรรม์และพบว่าผู้เอาประกันสามารถแบ่งออกเป็นกลุ่มอายุน้อยค่าใช้จ่ายต่ำ กลุ่มวัยทำงาน ค่าใช้จ่ายปานกลาง และกลุ่มอายุสูงค่าใช้จ่ายสูง ซึ่งช่วยให้เห็นโครงสร้างความแตกต่างของผู้เอาประกันภัยอย่างเป็นระบบ

นอกจากนี้ โปรแกรมวิเคราะห์ข้อมูลทางสถิติยังสนับสนุนการวิเคราะห์แบ่งกลุ่มที่รองรับตัวแปรทั้งเชิงปริมาณและเชิงจัดหมวดหมู่ได้อย่างเหมาะสม

3.3 การตรวจสอบความน่าเชื่อถือของกลุ่มและการแปลผลเป็นโปรไฟล์ผู้เอาประกันสุขภาพ

การวิเคราะห์แบ่งกลุ่มผู้เอาประกันสุขภาพจำเป็นต้องพิจารณาคุณภาพของกลุ่มที่ได้ควบคู่กับการตีความผลลัพธ์ เพื่อให้ผลการจัดกลุ่มมีความน่าเชื่อถือและสามารถนำไปใช้ประโยชน์ได้จริง แนวทางหนึ่งคือการประเมินคุณภาพของกลุ่มด้วยดัชนีที่สะท้อนความชัดเจนของโครงสร้างข้อมูล เช่น Silhouette coefficient, Calinski-Harabasz index และ Davies-Bouldin index ซึ่งช่วยตรวจสอบว่ากลุ่มที่ได้มีความแตกต่างระหว่างกลุ่มและความคล้ายคลึงภายในกลุ่มในระดับที่เหมาะสม นอกจากนี้ การตรวจสอบความเสถียรของผลการวิเคราะห์แบ่งกลุ่มผ่านการสุ่มตัวอย่างหรือการแบ่งชุดข้อมูลยังช่วยลดความเสี่ยงที่ผลการจัดกลุ่มจะเกิดจากความบังเอิญ และช่วยยืนยันความน่าเชื่อถือของแบบจำลอง เมื่อได้ผลการแบ่งกลุ่มแล้ว ขั้นตอนสำคัญคือการแปลผลลัพธ์ให้อยู่ในรูปแบบของโปรไฟล์ผู้เอาประกัน โดยการสรุปลักษณะสำคัญของแต่ละกลุ่ม เช่น ค่าเฉลี่ยรายได้ครัวเรือน ภาระพึ่งพิง รูปแบบการใช้บริการสุขภาพ หรือระดับค่าใช้จ่าย เพื่ออธิบายความแตกต่างของกลุ่มอย่างเป็นระบบ การตั้งชื่อกลุ่มในลักษณะที่เป็นกลาง เช่น กลุ่มรายได้สูงภาระพึ่งพิงต่ำ หรือกลุ่มรายได้ปานกลางภาระพึ่งพิงสูง ช่วยให้การสื่อสารผลการวิจัยมีความชัดเจนและลดการตีความเชิงคุณค่า งานศึกษาต่างประเทศที่ใช้การวิเคราะห์แบ่งกลุ่มจากข้อมูลการเรียกร้องค่าสินไหมทดแทนและข้อมูลใบสั่งยาพบว่าสามารถจำแนกผู้เอาประกันออกเป็นกลุ่มที่มีรูปแบบการใช้บริการและระดับความเสี่ยงแตกต่างกันได้อย่างชัดเจน [8] ขณะเดียวกัน การประยุกต์ใช้การวิเคราะห์แบ่งกลุ่มกับข้อมูลประกันชีวิตที่มีตัวแปรผสมยังช่วยสร้างแนวทางการตีความผลลัพธ์ในเชิงคณิตศาสตร์ ประกันภัยและสนับสนุนการสร้างโปรไฟล์ลูกค้าได้อย่างเป็นระบบ [10]

ในเชิงการนำไปใช้ ผลการแบ่งกลุ่มสามารถช่วยทำความเข้าใจความหลากหลายของผู้เอาประกันและสนับสนุนการออกแบบการสื่อสารหรือบริการที่สอดคล้องกับลักษณะของแต่ละกลุ่มได้มากขึ้น โดยไม่จำเป็นต้องมุ่งเน้นการคัดเลือกความเสี่ยงโดยตรง แนวทางดังกล่าวสอดคล้องกับงานวิจัยด้านการแบ่งกลุ่มลูกค้าในอุตสาหกรรมประกันภัยที่เน้นการใช้ข้อมูลเพื่อทำความเข้าใจโครงสร้างลูกค้าและพัฒนาการจัดการลูกค้าอย่างเหมาะสม [5,9] การผสมผสานการตรวจสอบคุณภาพของกลุ่มเข้ากับการสร้างโปรไฟล์ผู้เอาประกันจึงเป็นขั้นตอนสำคัญที่ช่วยเชื่อมโยงวิธีวิจัย ผลลัพธ์ และการนำไปใช้ประโยชน์ในบริบทของการจำแนกกลุ่มผู้เอาประกันสุขภาพในประเทศไทย

4. กรอบแนวคิดการวิจัย

การวิจัยนี้มุ่งจำแนกกลุ่มลูกค้าในธุรกิจประกันสุขภาพ โดยใช้เทคนิคการแบ่งกลุ่มแบบสองขั้น ซึ่งเหมาะสมกับข้อมูลที่ประกอบด้วยทั้งตัวแปรเชิงปริมาณและเชิงคุณภาพ ตัวแปรที่นำมาใช้ในการวิเคราะห์ ได้แก่ อายุ รายได้ครัวเรือน ค่าเบี้ยประกันสุขภาพ และค่าใช้จ่ายด้านเวชภัณฑ์ ซึ่งเป็นตัวแปรเชิงปริมาณ ร่วมกับเพศ สถานภาพสมรส ระดับการศึกษา และชนชั้นทางเศรษฐกิจ ซึ่งเป็นตัวแปรเชิงคุณภาพ ตัวแปรเหล่านี้สะท้อนลักษณะทางประชากรศาสตร์ ฐานะทางเศรษฐกิจ และพฤติกรรมการใช้จ่ายด้านสุขภาพของลูกค้าอย่างรอบด้าน การวิเคราะห์การแบ่งกลุ่มสองขั้นลูกค้าที่มีลักษณะคล้ายคลึงกันให้อยู่ในกลุ่มเดียวกัน และกำหนดจำนวนกลุ่มที่เหมาะสมตามเกณฑ์ทางสถิติ ผลลัพธ์ที่ได้คือลูกค้าแต่ละกลุ่มที่มีความแตกต่างกันอย่างชัดเจน ซึ่งสามารถนำไปอธิบายเป็นโปรไฟล์ของผู้เอาประกันสุขภาพแต่ละกลุ่มในด้านช่วงอายุ ศักยภาพทางการเงิน ระดับการใช้จ่ายด้านสุขภาพ และรูปแบบการเลือกประกันสุขภาพ

5. วิธีการวิจัย

5.1 การจัดเตรียมข้อมูล

ข้อมูลที่ใช้ในการศึกษาครั้งนี้เป็นข้อมูลทุติยภูมิจากการสำรวจภาวะเศรษฐกิจและสังคมของครัวเรือน พ.ศ. 2564 ของสำนักงานสถิติแห่งชาติ ศึกษาเฉพาะผู้มีกรมธรรม์ประกันสุขภาพ ก่อนการวิเคราะห์ผู้วิจัยได้ดำเนินการเตรียมข้อมูลโดยตรวจสอบความครบถ้วนและความเหมาะสมของตัวแปรที่ใช้ศึกษา พร้อมทั้งคัดกรองรายการข้อมูลที่มีค่าสูญหายในตัวแปรอิสระออกจากข้อมูล เพื่อให้ได้ข้อมูลที่มีความสมบูรณ์และลดความคลาดเคลื่อนที่อาจเกิดขึ้นในขั้นตอนการวิเคราะห์ จึงมีตัวอย่างทั้งสิ้น 3,814 คน

ในขั้นตอนการคัดเลือกตัวแปรอิสระพิจารณาจากทั้งลักษณะการกระจายตัวของข้อมูลและความสามารถในการจำแนกกลุ่ม โดยตัดตัวแปรที่มีลักษณะศูนย์เพื่อหรือไม่สามารถสร้างความแตกต่างระหว่างกลุ่มได้ออกจากการวิเคราะห์ เพื่อให้แบบจำลองมีประสิทธิภาพและสามารถสะท้อนโครงสร้างของข้อมูลได้อย่างเหมาะสม ตัวแปรอิสระที่ผ่านเกณฑ์การคัดเลือกถูกนำมาพิจารณาและสรุปไว้ในตารางที่ 1

5.2 การวิเคราะห์แบ่งกลุ่มแบบสองขั้น (Two-Step Cluster Analysis)

เป็นเทคนิคการวิเคราะห์กลุ่มเชิงสถิติที่พัฒนาขึ้นเพื่อใช้ในการจำแนกกลุ่มข้อมูลขนาดใหญ่ที่ประกอบด้วยทั้งตัวแปรเชิงปริมาณและตัวแปรเชิงคุณภาพในกระบวนการเดียวกัน เทคนิคนี้ได้รับความนิยมอย่างแพร่หลายในงานวิจัยด้านสังคมศาสตร์ ธุรกิจ และการตลาด รวมถึงการศึกษาด้านประกันภัย เนื่องจากสามารถจัดการกับข้อมูลที่มีลักษณะซับซ้อนและหลากหลายได้อย่างมีประสิทธิภาพ

ตาราง 1 ตัวแปรที่ใช้ในการแบ่งกลุ่ม

ลำดับ	ตัวแปรอิสระ	ประเภทข้อมูล	หน่วย
1	อายุ	เชิงปริมาณ	ปี
2	รายได้ครัวเรือน	เชิงปริมาณ	บาทต่อเดือน
3	ค่าเบี่ยงแปรผันสุขภาพ	เชิงปริมาณ	บาทต่อปี
4	ค่าใช้จ่ายด้านเวชภัณฑ์ (เวชภัณฑ์)	เชิงปริมาณ	บาทต่อเดือน
5	เพศ	เชิงคุณภาพ	
6	สถานสมรส	เชิงคุณภาพ	
7	ระดับการศึกษา	เชิงคุณภาพ	
8	ชนชั้นทางเศรษฐกิจ	เชิงคุณภาพ	

การวิเคราะห์แบ่งกลุ่มแบบสองขั้นอาศัยหลักการวัดความคล้ายคลึงของข้อมูลตามลักษณะของตัวแปร โดยตัวแปรเชิงปริมาณมีสมมติฐานการแจกแจงแบบปกติ (Normal Distribution) ขณะที่ตัวแปรเชิงคุณภาพอาศัยการแจกแจงแบบพหุนาม (Multinomial Distribution) และคำนวณระยะห่างระหว่างหน่วยข้อมูลด้วยระยะทางแบบลอการิทึมความน่าจะเป็น (Log-Likelihood Distance) ซึ่งช่วยให้สามารถผสานข้อมูลที่มีลักษณะแตกต่างกันให้อยู่ในกรอบการวิเคราะห์เดียวกันได้อย่างเหมาะสม นอกจากนี้ เทคนิคดังกล่าวยังสามารถกำหนดจำนวนกลุ่มที่เหมาะสม โดยอาศัยเกณฑ์สารสนเทศเชิงเบย์ (Bayesian Information Criterion: BIC) หรือเกณฑ์สารสนเทศของอาไคเกะ (Akaike Information Criterion: AIC) ซึ่งช่วยลดอคติจากการกำหนดจำนวนกลุ่มด้วยดุลยพินิจของผู้วิจัย

จุดเด่นสำคัญของการวิเคราะห์แบ่งกลุ่มแบบสองขั้นตอนคือความสามารถในการสร้างกลุ่มข้อมูลที่มีความหมายเชิงตีความสูง จึงเหมาะสมสำหรับการพัฒนาโปรไฟล์ของกลุ่ม (Cluster Profiling) โดยเฉพาะในงานวิจัยที่มุ่งอธิบายลักษณะของประชากรหรือลูกค้าในหลายมิติ เช่น ลักษณะทางประชากรศาสตร์ ฐานะทางเศรษฐกิจ และพฤติกรรมการใช้บริการ ในบริบทของธุรกิจประกันภัย วิธีการนี้ช่วยให้สามารถจำแนกผู้เอาประกันออกเป็นกลุ่มที่มีลักษณะความเสี่ยงและพฤติกรรมด้านการใช้ประกันแตกต่างกันอย่างมีหลักการ ซึ่งสนับสนุนการออกแบบผลิตภัณฑ์ การกำหนดเบี้ยประกัน และการบริหารความเสี่ยงได้อย่างมีประสิทธิภาพ

แม้ว่าการวิเคราะห์แบ่งกลุ่มแบบสองขั้นตอนจะมีข้อได้เปรียบด้านความยืดหยุ่นและประสิทธิภาพในการรองรับข้อมูลหลายประเภท แต่ความน่าเชื่อถือของผลลัพธ์ยังคงขึ้นอยู่กับคุณภาพของข้อมูลและความเหมาะสมของตัวแปรที่นำมาใช้ในการวิเคราะห์ ผู้วิจัยจึงจำเป็นต้องพิจารณาการคัดเลือกตัวแปรอย่างรอบคอบ ควบคู่กับการตรวจสอบคุณภาพของกลุ่มที่ได้จากการวิเคราะห์ เช่น ระดับความ

สอดคล้องภายในกลุ่ม เพื่อให้ผลการจำแนกกลุ่มมีความมั่นคง และสามารถนำไปตีความหรือประยุกต์ใช้ได้เหมาะสม

การประเมินคุณภาพของการจำแนกกลุ่มในการศึกษานี้ใช้ค่าดัชนีการวัดความสอดคล้องและการแยกจากกันของกลุ่ม (Silhouette Measure of Cohesion and Separation) ซึ่งเป็นตัวชี้วัดที่ใช้ประเมินคุณภาพของกลุ่มโดยพิจารณาทั้งความใกล้เคียงของข้อมูลภายในกลุ่มเดียวกันและระดับความแตกต่างระหว่างกลุ่มในมาตรวัดเดียว สำหรับข้อมูลแต่ละหน่วยสังเกต จะมีการคำนวณค่า Silhouette (s(i)) จะอยู่ในช่วงระหว่าง -1 ถึง 1 ซึ่งใช้สะท้อนความเหมาะสมของการจัดกลุ่มข้อมูล ค่า Silhouette โดยรวมของการจำแนกกลุ่มคำนวณจากค่าเฉลี่ยของของข้อมูลทั้งหมด ซึ่งใช้เป็นตัวชี้วัดคุณภาพของโครงสร้างคลัสเตอร์โดยรวม

ค่า Silhouette ช่วยยืนยันว่ากลุ่มที่ได้มีความสอดคล้องภายในกลุ่มและมีความแตกต่างระหว่างกลุ่มในระดับที่เหมาะสม โดยค่าที่อยู่ในช่วงปานกลางถึงสูงสะท้อนถึงผลการจำแนกกลุ่มที่มีความน่าเชื่อถือ ขณะที่ค่าต่ำอาจบ่งชี้ถึงความจำเป็นในการปรับจำนวนกลุ่มหรือทบทวนตัวแปรที่ใช้ในการวิเคราะห์ใหม่

สำหรับการวิเคราะห์โปรไฟล์ของคลัสเตอร์ภายหลังจากได้ผลการจำแนกกลุ่มจำนวน 3 กลุ่ม ผู้วิจัยได้ดำเนินการวิเคราะห์ลักษณะเฉพาะของแต่ละกลุ่มในกระบวนการสร้างโปรไฟล์กลุ่ม (Cluster Profiling) โดยพิจารณาค่าเฉลี่ยของตัวแปรเชิงปริมาณ ได้แก่ อายุ รายได้ ค่าเบี่ยงแปรผันสุขภาพ ค่าใช้จ่ายด้านสุขภาพ ควบคู่กับการวิเคราะห์สัดส่วนของตัวแปรเชิงคุณภาพ เช่น เพศ ระดับการศึกษา สถานภาพสมรส และสถานะทางเศรษฐกิจ เพื่ออธิบายลักษณะของผู้เอาประกันในแต่ละกลุ่มอย่างเป็นระบบและเอื้อต่อการตีความผลการวิจัยในบริบทของการประกันสุขภาพ

6. ผลการศึกษา

จากการวิเคราะห์ข้อมูลผู้เอาประกันสุขภาพจากครัวเรือนในประเทศไทยจำนวน 3,814 คน ด้วยการใช้การวิเคราะห์แบ่งกลุ่มสองขั้น โดยใช้ตัวแปรด้านประชากรศาสตร์ เศรษฐกิจ และพฤติกรรมสุขภาพเป็นตัวแปรนำเข้า ผู้วิจัยได้ทำการทดลองกำหนดจำนวนกลุ่มในการวิเคราะห์ไว้ที่ 3-4 กลุ่ม เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการจัดกลุ่มในหลายรูปแบบ และได้ผลตามตารางดังนี้

ตารางที่ 2 ค่าที่แสดงผลลัพธ์ในการแบ่งกลุ่มของข้อมูล

ครั้งที่	จำนวนกลุ่ม	ตัวแปร	ค่า Silhouette Measure of Cohesion and Separation	BIC	ผลวิเคราะห์การแบ่งกลุ่ม
1	4	11	0.26	34,838.00	พอใช้
2	3	9	0.31	36,417.86	พอใช้
3	3	11	0.22	39,651.64	พอใช้
4	3	8	0.38	31,580.50	ค่อนข้างดี

ผลการวิเคราะห์เบื้องต้นจากตารางที่ 2 ใช้เกณฑ์ Bayesian Information Criterion (BIC) ร่วมกับค่า Silhouette measure of cohesion and separation ในการพิจารณาจำนวนกลุ่มที่เหมาะสม โดยเริ่มจากการกำหนด 4 กลุ่มภายใต้ตัวแปรนำเข้า 11 ตัวแปร ได้แก่ อายุ รายได้ครัวเรือน ค่าเบี้ยประกันสุขภาพ ค่าใช้จ่ายด้านเวชภัณฑ์ เพศ สถานภาพสมรส ระดับการศึกษา ชนชั้นทางเศรษฐกิจ อาชีพ และค่าใช้จ่ายด้านสุขภาพในหมวดผู้ป่วยนอกและผู้ป่วยใน พบว่าค่า Silhouette เท่ากับประมาณ 0.26 อยู่ในระดับพอใช้ แสดงให้เห็นว่าสามารถจำแนกกลุ่มได้ แต่ยังมีค่าความทับซ้อนของข้อมูลระหว่างกลุ่มอยู่ เมื่อปรับจำนวนกลุ่มเหลือ 3 กลุ่ม โดยใช้ตัวแปรเดิม ค่า Silhouette ลดลงเหลือประมาณ 0.22 และค่า BIC สูงขึ้น สะท้อนว่าการใช้ตัวแปรจำนวนมากเกินไปส่งผลให้ประสิทธิภาพในการจำแนกกลุ่มลดลง ต่อมาผู้วิจัยได้ลดจำนวนตัวแปรนำเข้าเหลือ 9 ตัวแปร โดยตัดตัวแปรค่าใช้จ่ายด้านสุขภาพในหมวดผู้ป่วยนอกและผู้ป่วยในออก เหลือ อายุ รายได้ครัวเรือน ค่าเบี้ยประกันสุขภาพ ค่าใช้จ่ายด้านเวชภัณฑ์ เพศ สถานภาพสมรส ระดับการศึกษา ชนชั้นทางเศรษฐกิจ และอาชีพ ส่งผลให้ค่า Silhouette เพิ่มขึ้นเป็นประมาณ 0.31 แสดงให้เห็นว่าโครงสร้างกลุ่มมีความชัดเจนมากขึ้น และเมื่อพิจารณาปรับลดตัวแปรจาก 9 ตัวแปรเหลือ 8 ตัวแปร โดยตัดตัวแปรอาชีพออก คงเหลือ อายุ รายได้ครัวเรือน ค่าเบี้ยประกันสุขภาพ ค่าใช้จ่ายด้านเวชภัณฑ์ เพศ สถานภาพสมรส ระดับการศึกษา และชนชั้นทางเศรษฐกิจ พร้อมกำหนดจำนวนกลุ่มเท่ากับ 3 กลุ่ม พบว่าค่า Silhouette เพิ่มขึ้นเป็นประมาณ 0.38 ซึ่งเป็นค่าสูงที่สุด และมีค่า BIC ต่ำที่สุด (31,580.50) แสดงให้เห็นว่าแบบจำลองดังกล่าวมีความเหมาะสมกับข้อมูลมากที่สุด สามารถจำแนกกลุ่มได้อย่างมีประสิทธิภาพและมีโครงสร้างกลุ่มที่ชัดเจน ผู้วิจัยจึงเลือกแบบจำลองที่ใช้ตัวแปรนำเข้า 8 ตัวแปรและแบ่งข้อมูลออกเป็น 3 กลุ่มเป็นแบบจำลองสุดท้ายสำหรับการวิเคราะห์ลักษณะของกลุ่มผู้เอาประกันสุขภาพในขั้นตอนถัดไป

ตารางที่ 3 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของตัวแปรแบ่งกลุ่มจำแนกตามกลุ่ม

	กลุ่มที่ 1		กลุ่มที่ 2		กลุ่มที่ 3	
	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน
อายุ	46.94	14.719	37.61	11.223	52.46	14.077
ค่าเวชภัณฑ์	241.33	334.949	136.28	96.151	126.55	101.46
ค่าเบี้ยประกัน	1,903.21	3,679.68	700.11	694.705	660.71	769.112
รายได้ครัวเรือน	60,034.2	49,528.79	28,279.4	16,807.557	26,923.4	16,616.37

จากตารางที่ 3 และ 4 พบว่า ปัจจัยด้านเศรษฐกิจและสังคมของครัวเรือน ได้แก่ อายุ ค่าใช้จ่ายด้านสุขภาพ ค่าเบี้ยประกัน และรายได้ครัวเรือน มีค่าเฉลี่ยหรือร้อยละที่แตกต่างกันในแต่ละกลุ่ม โดยมีรายละเอียดดังนี้

กลุ่มที่ 1 ผลการจำแนกกลุ่มสะท้อนว่ากลุ่มที่ 1 เป็นกลุ่มผู้เอาประกันที่มีสถานะทางเศรษฐกิจและสังคมในระดับสูง โดยมีอายุเฉลี่ย 46.94 ปี อยู่ในช่วงวัยแรงงานตอนกลางถึงตอนปลาย และมีรายได้ครัวเรือนเฉลี่ยสูงที่สุดที่ประมาณ 60,034 บาทต่อเดือน เมื่อพิจารณาโครงสร้างอาชีพ พบว่าสมาชิกในกลุ่มส่วนใหญ่ประกอบอาชีพในระดับวิชาชีพ ผู้จัดการ และนักวิชาการ คิดเป็นสัดส่วนร้อยละ 97.14 สะท้อนถึงความมั่นคงทางอาชีพและศักยภาพในการหารายได้ที่สูง สอดคล้องกับระดับการศึกษาที่โดดเด่น โดยร้อยละ 58.73 สำเร็จการศึกษาระดับปริญญาตรีขึ้นไป รองลงมาคือระดับมัธยมศึกษาหรืออาชีวศึกษา และระดับประถมศึกษาในสัดส่วนที่น้อยกว่า

ในด้านลักษณะประชากรศาสตร์ กลุ่มนี้มีสัดส่วนเพศหญิงสูงถึงร้อยละ 73.02 และส่วนใหญ่มีสถานภาพไม่โสดคิดเป็นร้อยละ 72.84 แสดงถึงโครงสร้างครัวเรือนที่มีความมั่นคง เมื่อพิจารณาพฤติกรรมด้านการใช้ประกันสุขภาพ พบว่ากลุ่มนี้มีค่าเบี้ยประกันเฉลี่ยสูงที่สุดที่ประมาณ 1,903 บาทต่อเดือน และมีค่าใช้จ่ายด้านสุขภาพเฉลี่ยประมาณ 241 บาทต่อเดือน อย่างไรก็ตาม เมื่อพิจารณาในเชิงสัดส่วนต่อรายได้ครัวเรือน พบว่าค่าเบี้ยประกันคิดเป็นเพียงประมาณ 3.17% ของรายได้เฉลี่ย และค่าใช้จ่ายด้านสุขภาพคิดเป็นประมาณ 0.40% ซึ่งสะท้อนว่ากลุ่มนี้แม้มีค่าใช้จ่ายด้านสุขภาพในเชิงมูลค่าสูง แต่ภาระค่าใช้จ่ายเมื่อเทียบกับฐานรายได้ยังอยู่ในระดับต่ำ

โดยสรุป กลุ่มที่ 1 สามารถอธิบายได้ว่าเป็นกลุ่มแรงงานวิชาชีพที่มีระดับการศึกษาสูง รายได้ครัวเรือนสูง และมีความสามารถในการจ่ายค่าเบี้ยประกันในระดับสูง มีค่าใช้จ่ายด้านประกันและเวชภัณฑ์ในระดับสูงในเชิงมูลค่า แต่เมื่อพิจารณาเป็นสัดส่วนกับรายได้ พบว่าภาระดังกล่าวอยู่ในระดับต่ำเมื่อเทียบกับกลุ่มอื่น

กลุ่มที่ 2 ผลการจำแนกกลุ่มสะท้อนว่ากลุ่มที่ 2 เป็นกลุ่มผู้เอาประกันที่มีอายุเฉลี่ยต่ำที่สุดที่ประมาณ 37.61 ปี อยู่ในช่วงวัยแรงงานตอนต้นถึงตอนกลาง โดยมีรายได้ครัวเรือนเฉลี่ยประมาณ 28,279 บาทต่อเดือน และมีค่าเบี้ยประกันเฉลี่ยประมาณ 700 บาทต่อเดือน แสดงถึงกลุ่มผู้เอาประกันที่มี

ศักยภาพทางรายได้ในระดับปานกลางและเลือกความคุ้มครองให้สอดคล้องกับกำลังซื้อ

เมื่อพิจารณาโครงสร้างอาชีพ พบว่าสมาชิกในกลุ่มส่วนใหญ่กระจุกตัวอยู่ในอาชีพเสมียน พนักงานขาย และพนักงานให้บริการ คิดเป็นร้อยละ 56.94 รองลงมาคือผู้ปฏิบัติงานในกระบวนการผลิต ก่อสร้าง และเหมืองแร่ ร้อยละ 30.79 ขณะที่แรงงานภาคเกษตรและงานพื้นฐานมีสัดส่วนร้อยละ 12.27 และไม่พบแรงงานในกลุ่มวิชาชีพระดับผู้จัดการหรือนักวิชาการ สะท้อนลักษณะของแรงงานระดับปฏิบัติการและภาคบริการเป็นหลัก

ด้านระดับการศึกษา กลุ่มนี้มีการศึกษาส่วนใหญ่อยู่ในระดับมัธยมศึกษาหรืออาชีวศึกษา คิดเป็นร้อยละ 74.09 รองลงมาคือระดับปริญญาตรีขึ้นไป ร้อยละ 18.7 และระดับประถมศึกษาเพียงร้อยละ 7.21 แสดงถึงระดับการศึกษาที่อยู่ในช่วงปานกลางเมื่อเทียบกับกลุ่มอื่น ในด้านประชากรศาสตร์ พบว่าสัดส่วนเพศหญิงสูงกว่าชาย โดยเพศหญิงคิดเป็นร้อยละ 61.82 และเพศชายร้อยละ 38.18 อีกทั้งส่วนใหญ่มีสถานภาพไม่โสดคิดเป็นร้อยละ 62.37

ในมิติด้านเศรษฐกิจและพฤติกรรมการใช้ประกันสุขภาพ กลุ่มที่ 2 มีค่าเบี้ยประกันเฉลี่ยประมาณ 700.11 บาท และค่าใช้จ่ายด้านเวชภัณฑ์เฉลี่ยประมาณ 136.28 บาทต่อเดือน ซึ่ง

อยู่ในระดับต่ำกว่ากลุ่มวิชาชีพรายได้สูงอย่างชัดเจน สะท้อนถึงแนวโน้มการเลือกความคุ้มครองที่เน้นความเหมาะสมด้านราคาและความคุ้มค่า

โดยสรุป กลุ่มที่ 2 สามารถอธิบายได้ว่าเป็นกลุ่มแรงงานภาคบริการและการผลิตที่มีระดับการศึกษานานกลาง รายได้ครัวเรือนระดับปานกลาง และมีรูปแบบการใช้ประกันสุขภาพที่สอดคล้องกับข้อจำกัดด้านรายได้ เน้นความคุ้มค่าและความสามารถในการจ่ายมากกว่าการเลือกความคุ้มครองในระดับสูง

กลุ่มที่ 3 กลุ่มแรงงานระดับล่างและการศึกษาขั้นพื้นฐาน ผลการจำแนกกลุ่มสะท้อนว่ากลุ่มที่ 3 เป็นกลุ่มผู้เอาประกันที่มีอายุเฉลี่ยสูงที่สุดประมาณ 52.46 ปี อยู่ในช่วงวัยแรงงานตอนปลายถึงวัยสูงอายุ โดยมีรายได้ครัวเรือนเฉลี่ยประมาณ 26,923 บาทต่อเดือน ซึ่งต่ำกว่ากลุ่มที่มีฐานะทางเศรษฐกิจสูง และมีค่าเบี้ยประกันเฉลี่ยต่ำที่สุดประมาณ 661 บาทต่อเดือน สะท้อนถึงกลุ่มผู้เอาประกันที่มีข้อจำกัดด้านรายได้และเลือกความคุ้มครองในระดับพื้นฐาน

เมื่อพิจารณาโครงสร้างอาชีพ พบว่าสมาชิกส่วนใหญ่อยู่ในกลุ่มเสมียน พนักงานขาย และพนักงานให้บริการ คิดเป็น

ตารางที่ 4 ความถี่และร้อยละของตัวแปรแบ่งกลุ่มจำแนกตามกลุ่ม

	กลุ่มที่ 1		กลุ่มที่ 2		กลุ่มที่ 3		รวม	
	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ
เพศ								
ชาย	302	26.98%	619	38.18%	356	33.14%	1,277	33.5%
หญิง	817	73.02%	1002	61.82%	718	66.85%	2,537	66.5%
รวม	1,119	100%	1,621	100%	1,074	100%	3,814	100%
สถานภาพสมรส								
โสด	304	27.16%	610	37.63%	0	0%	914	24%
ไม่โสด	815	72.84%	1011	62.37%	1,074	100%	2,900	76%
รวม	1,119	100%	1,621	100%	1,074	100%	3,814	100%
ระดับการศึกษา								
ประถมศึกษา	191	17.06%	117	7.21%	1,033	96.19%	1,341	35.2%
มัธยมศึกษา/อาชีวศึกษา	271	24.21%	1,201	74.09%	41	3.81%	1,513	39.7%
ตอนต้น /อนุปริญญา								
ปริญญาตรีขึ้นไป	657	58.73%	303	18.7%	0	0%	960	25.2%
รวม	1,119	100%	1,621	100%	1,074	100%	3,814	100%

ตารางที่ 4 (ต่อ)

	กลุ่มที่ 1		กลุ่มที่ 2		กลุ่มที่ 3		รวม	
	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ	ความถี่ (คน)	ร้อยละ
ชนชั้นทางเศรษฐกิจ								
ผู้จัดการ นักวิชาการ และ ผู้ปฏิบัติงานวิชาชีพ	1,087	97.14%	0	0%	0	0%	1,087	28.5%
กลุ่มแรงงานเกษตร- ขนส่ง-งานพื้นฐาน	2	0.17%	199	12.27%	257	23.92%	458	12.01%
เสมียน พนักงานขายและ ให้บริการ	23	2.05%	923	56.94%	463	43.10%	1,409	36.94%
ผู้ปฏิบัติงานใน กระบวนการผลิต ก่อสร้าง และเหมืองแร่	7	0.64%	499	30.79%	354	32.98%	860	22.55%
รวม	1,119	100%	1,621	100%	1,074	100%	3,814	100%

ร้อยละ 43.10 รองลงมาคือผู้ปฏิบัติงานในกระบวนการผลิต
ก่อสร้าง และเหมืองแร่ ร้อยละ 32.98 และแรงงานภาคเกษตร
หรือแรงงานพื้นฐานร้อยละ 23.92 โดยไม่พบแรงงานในกลุ่ม
วิชาชีพระดับผู้จัดการหรือนักวิชาการ สะท้อนลักษณะของ
แรงงานฐานรากและแรงงานระดับล่างเป็นหลัก

ด้านการศึกษา กลุ่มนี้มีระดับการศึกษาต่ำอย่างชัดเจน โดย
ร้อยละ 96.19 สำเร็จการศึกษาระดับประถมศึกษา รองลงมา
คือระดับมัธยมศึกษาหรืออาชีวศึกษาเพียงร้อยละ 3.81 และไม่มี
พบผู้ที่สำเร็จการศึกษาระดับปริญญาตรีขึ้นไป แสดงถึง
ข้อจำกัดด้านทุนมนุษย์ของกลุ่มนี้ ในด้านลักษณะ
ประชากรศาสตร์ พบว่าสัดส่วนเพศหญิงยังคงสูง คิดเป็นร้อย
ละ 66.89 และเพศชายร้อยละ 33.14 อีกทั้งสมาชิกทั้งหมดมี
สถานภาพไม่โสด สะท้อนถึงโครงสร้างครัวเรือนที่มีภาวะ
พึ่งพิง

ในมิติด้านเศรษฐกิจและพฤติกรรมการใช้ประกันสุขภาพ
กลุ่มที่ 3 มีค่าใช้จ่ายด้านสุขภาพในระดับต่ำ โดยมีค่าเบี้ย
ประกันเฉลี่ยประมาณ 660.71 บาท และค่าใช้จ่ายด้าน
เวชภัณฑ์เฉลี่ยประมาณ 126.55 บาทต่อเดือน ซึ่งสอดคล้องกับ
ข้อจำกัดด้านรายได้และกำลังซื้อของกลุ่ม

โดยสรุป กลุ่มที่ 3 สามารถอธิบายได้ว่าเป็นกลุ่มแรงงาน
ฐานรากที่มีระดับการศึกษาต่ำ รายได้ครัวเรือนต่ำ และมี
รูปแบบการใช้ประกันสุขภาพในระดับพื้นฐาน สมาชิกส่วน
ใหญ่อยู่ในช่วงวัยที่มีความเสี่ยงด้านสุขภาพเพิ่มขึ้นในระยะ
ยาว สะท้อนกลุ่มผู้เอาประกันที่มีข้อจำกัดด้านเศรษฐกิจและม
ีความเปราะบางต่อภาวะค่าใช้จ่ายด้านสุขภาพมากกว่ากลุ่มอื่น

ผลการศึกษานี้สะท้อนให้เห็นว่า ปัจจัยด้านอายุ ระดับ
การศึกษา ลักษณะอาชีพ และรายได้ครัวเรือนมีบทบาทสำคัญ
ต่อรูปแบบการตัดสินใจเลือกซื้อประกันสุขภาพ รวมถึงระดับ

ความคุ้มครองที่ผู้เอาประกันในประเทศไทยเลือกใช้ โดย
ความแตกต่างของปัจจัยดังกล่าวนำไปสู่พฤติกรรมทางเลือก
ประกันสุขภาพที่หลากหลายระหว่างกลุ่มผู้เอาประกัน

7. อภิปรายผลและสรุปผลการศึกษา

ผลการศึกษพบว่าสามารถจำแนกผู้เอาประกันสุขภาพใน
ประเทศไทยออกเป็น 3 กลุ่มที่มีความแตกต่างด้านอายุ
การศึกษา อาชีพ และรายได้ ซึ่งมีอิทธิพลต่อพฤติกรรมกา
รเลือกประกันสุขภาพ สอดคล้องกับงานวิจัยก่อนหน้า [1-4]
โดยกลุ่มรายได้สูงเลือกความคุ้มครองสูง กลุ่มรายได้ปาน
กลางเน้นความคุ้มค่า และกลุ่มรายได้ต่ำมีข้อจำกัดในการ
เข้าถึงประกันสุขภาพ [5,9]

แบบจำลองที่ใช้ 8 ตัวแปรและ 3 กลุ่มให้ค่า Silhouette
0.38 และค่า BIC ต่ำที่สุด แสดงถึงความเหมาะสมของ
โครงสร้างกลุ่มและสอดคล้องกับงานวิจัยด้าน clustering ใน
ประกันสุขภาพ [7,10] โดยสรุป เทคนิคการวิเคราะห์แบ่งกลุ่ม
สามารถอธิบายความแตกต่างของผู้เอาประกันและสนับสนุน
การนำไปใช้เชิงนโยบายและเชิงธุรกิจได้อย่างมีประสิทธิภาพ

8. ข้อเสนอแนะในการวิจัยครั้งต่อไป

ผลการจำแนกกลุ่มผู้เอาประกันสุขภาพสามารถนำไปใช้
สนับสนุนการออกแบบผลิตภัณฑ์และบริการที่สอดคล้องกับ
ลักษณะของลูกค้าแต่ละกลุ่ม โดยกลุ่มรายได้สูงควรมุ่งเน้น
ความคุ้มครองที่ครอบคลุม กลุ่มรายได้ปานกลางควรเน้น
ความคุ้มค่า และกลุ่มรายได้ต่ำควรมีทางเลือกที่เข้าถึงได้ง่าย
นอกจากนี้ หน่วยงานที่เกี่ยวข้องสามารถนำผลการศึกษานี้ไปใช้

ในการกำหนดแนวทางเพื่อลดความเหลื่อมล้ำในการเข้าถึง
ประกันสุขภาพในระยะยาว

เอกสารอ้างอิง

- [1] ธนาพันธ์ ทองจุ่น. (2565). ปัจจัยที่ส่งผลต่อกระบวนการตัดสินใจซื้อประกันสุขภาพของผู้บริโภคในกรุงเทพมหานคร. วิทยานิพนธ์ปริญญาโท มหาวิทยาลัยธุรกิจบัณฑิตย์. <https://libdoc.dpu.ac.th/thesis/Thanapan.Thon.pdf>
- [2] สุภาพร ศรีนวล. (ม.ป.ป.). ปัจจัยที่มีผลต่อการตัดสินใจซื้อประกันสุขภาพในเขตภาคเหนือของประเทศไทย. รายงานวิจัย มหาวิทยาลัยแม่ฟ้าหลวง. <https://mfuir.mfu.ac.th/jspui/handle/123456789/1058>
- [3] วราภรณ์ มั่นพุก, & วอนชนก ไชยสุนทร. (2565). ปัจจัยที่มีอิทธิพลต่อการซื้อประกันสุขภาพของผู้บริโภคในประเทศไทย. วารสารบริหารธุรกิจและสหวิทยาการ, 9(2), 132–148. <https://so02.tci-thaijo.org/index.php/fam/article/download/255955/172255>
- [4] Chandra A, Skinner J. Technology growth and expenditure growth in health care. *J Econ Lit.* 2012;50(3):645–680.
- [5] Hanafizadeh P, Paydar NR. A data mining model for risk assessment and customer segmentation in the insurance industry. *Int J Strategic Decision Sci.* 2013;4(1):52–78.
- [6] IBM Corp. IBM SPSS Statistics for Windows. Version 26.0. Armonk (NY): IBM Corp; 2019.
- [7] Khairi FA, Farhan L, Adelaja OA. Data mining driven segmentation of health insurance policyholders using K-means clustering. *Mesopotamian J AI Healthcare.* 2025:187–196.
- [8] Momahhed SS, et al. K-means clustering of outpatient prescription claims for health insureds. *BMC Public Health.* 2023;23:788.
- [9] Qadadeh W, Abdallah S. Customers segmentation in the insurance company dataset. *Procedia Comput Sci.* 2018;144:277–290.
- [10] Yin S, Gan G, Valdez EA, Vadiveloo J. Applications of clustering with mixed type data in life insurance. *Risks.* 2021;9(3):55.
- [11] Kotler P, Keller KL. *Marketing Management.* 15th ed. Pearson; 2016.

การเรียนรู้แบบเสริมกำลังเชิงลึกสำหรับการให้คะแนนเครดิตและการให้สินเชื่อ โดยใช้วิธีการบูตสแตรป์แบบเบย์

Deep Reinforcement Learning for Credit Scoring and Underwriting via Bayesian Bootstrapping

กรกนก จิตตรานนท์* และ เสกสรร เกียรติสุไพพลย์
ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย
(*6680008326@student.chula.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและศึกษาประสิทธิภาพของตัวแทนการตัดสินใจในปัญหาการอนุมัติสินเชื่อภายใต้กรอบปัญหา Contextual bandit โดยพิจารณาจากจำนวนคุณลักษณะผู้กู้ (Feature vector) และจำนวนการคัดเลือกผู้กู้ในรอบ โดยใช้โครงข่ายประสาทเทียมในการจำลองกระบวนการให้คะแนนเครดิตและการอนุมัติสินเชื่อ งานวิจัยนี้ได้ทำการพัฒนาและเปรียบเทียบตัวแบบทั้งหมด 4 ตัวแบบ ได้แก่ ตัวแบบละโมบ (GRE), ตัวแบบละโมบเชิงลึก (GRENN), ตัวแบบการสุ่มตัวอย่างแบบทอมสัน (THS) และตัวแทนบูตสแตรป์แบบเบย์ (BBTS) ซึ่งงานวิจัยนี้ได้ทำการออกแบบการทดลองภายใต้ 6 สถานการณ์ ทำการทดลองในกรณีมิติของคุณลักษณะของผู้กู้เท่ากับ 5, 10 และ 20 มิติ และพิจารณาเลือกผู้กู้ที่ผ่านการคัดเลือกจำนวน 1 ราย และ 10 รายจากผู้กู้ทั้งหมด 100 ราย โดยในแต่ละสถานการณ์ทำการทดลองทั้งหมด 3,000 รอบ และทำซ้ำจำนวน 50 ครั้ง ผลการทดลองพบว่า ตัวแทนแบบ BBTS มีประสิทธิภาพสูงที่สุดเมื่อมีมิติของคุณลักษณะของข้อมูลเป็น 5 มิติ และเลือกอนุมัติผู้กู้ 1 ราย โดยมีผลตอบแทนสะสมเท่ากับ 181.44 ± 137.59 ขณะที่เมื่อเพิ่มการอนุมัติผู้กู้เป็น 10 รายต่อรอบ ตัวแทนแบบ THS จะมีประสิทธิภาพมากที่สุด โดยมีผลตอบแทนสะสมเท่ากับ $1,787.46 \pm 1,194.26$ และในสถานการณ์ที่มีมิติของคุณลักษณะของข้อมูลเป็น 10 มิติพบว่าตัวแทนแบบ THS มีประสิทธิภาพมากที่สุด ทั้งกรณีที่ยกอนุมัติผู้กู้ 1 รายต่อรอบ และกรณีที่ยกอนุมัติผู้กู้ 10 รายต่อรอบ มีผลตอบแทนสะสมเท่ากับ 192.40 ± 107.78 และ $2,035.54 \pm 920.23$ ตามลำดับ ส่วนในสถานการณ์ที่มีมิติของคุณลักษณะของข้อมูลเป็น 20 มิติพบว่าตัวแทนแบบ GRE ให้ประสิทธิภาพดีที่สุดในทุกสถานการณ์และมีผลตอบแทนสะสมเท่ากับ 152.94 ± 96.06 และ $1,708.94 \pm 585.40$ ตามลำดับ

คำสำคัญ: การเรียนรู้แบบเสริมกำลัง, การให้คะแนนเครดิต, วิธีการบูตสแตรป์แบบเบย์, ตัวแทน, สภาพแวดล้อม, โครงข่ายประสาทเทียม

Abstract

The purpose of this study is to develop and evaluate credit approval decision-making frameworks based on the contextual bandit problem, with a particular emphasis on the effects of borrower feature dimensionality (Feature vectors) and the number of approved borrowers per decision round. A neural network was employed to simulate the credit scoring and loan approval process. Four classes of agents were investigated, namely Greedy agent (GRE), Thompson sampling agent (THS), Deep greedy agent (GRENN), and Bayesian bootstrapping agent (BBTS). Six experimental scenarios were constructed by considering borrower feature dimensions of 5, 10, and 20 and selecting either 1 or 10 borrowers per round from a total of 100 borrowers. In each scenario, the experiments were conducted over 3,000 decision rounds and repeated 50 times. The results demonstrate that the BBTS agent performs best when the feature dimension is 5 and 1 borrower is approved per round, achieving a cumulative reward of 181.44 ± 137.59 . When the number of approved borrowers increases to 10 per round, the THS agent outperforms the other methods, with a cumulative reward of $1,787.46 \pm 1,194.26$. For the feature dimension of 10, the THS agent exhibits the best performance in both cases of approving

1 and 10 borrowers per round, yielding cumulative rewards of 192.40 ± 107.78 and $2,035.54 \pm 920.23$, respectively. When the feature dimension is further increased to 20, the GRE agent achieves the best performance in both selection settings, with cumulative rewards of 152.94 ± 96.06 and $1,708.94 \pm 585.40$, respectively.

Keywords: Reinforcement learning, Credit scoring, Bayesian bootstrapping, Agent, Environment, Neural network

1. บทนำ

การให้คะแนนเครดิต (Credit scoring) และการอนุมัติสินเชื่อ (Underwriting) เป็นองค์ประกอบที่สำคัญในการตัดสินใจทางการเงิน โดยเฉพาะอย่างยิ่งสำหรับการประเมินและการบริหารความเสี่ยงด้านเครดิต [9, 10] ดังนั้นการให้คะแนนเครดิตจึงเป็นเครื่องมือที่สำคัญสำหรับสถาบันการเงิน รวมถึงองค์กรอื่น ๆ ที่ให้บริการเกี่ยวกับสินเชื่อ โดยการให้คะแนนเครดิตมีบทบาทสำคัญในการเพิ่มผลกำไรและลดความเสี่ยงจากการผิดนัดชำระหนี้ อย่างไรก็ตามกระบวนการ การให้คะแนนเครดิตเป็นเพียงกระบวนการหนึ่ง ที่แยกออกมาจากกระบวนการพิจารณาอนุมัติสินเชื่อ ในสถานการณ์ความเป็นจริงของสถาบันการเงินต่าง ๆ จำเป็นต้องมีชุดข้อมูล เพื่อพัฒนา และปรับปรุงแบบจำลองการให้คะแนนเครดิต โดย ในช่วงแรกของการรวบรวมข้อมูลหรือระหว่างการปรับปรุงแบบจำลอง สถาบันการเงินอาจจำเป็นต้องดำเนินการอนุมัติสินเชื่อด้วยแบบจำลองที่ยังไม่แม่นยำ หรือในบางกรณีอาจจะไม่มีแบบจำลองเลย [6] การดำเนินการดังกล่าวก่อให้เกิดต้นทุนสูง เช่น การอนุมัติสินเชื่อให้กับลูกค้าที่มีความเสี่ยงสูง ซึ่งนำไปสู่อัตราการผิดนัดชำระที่สูงขึ้น และส่งผลให้เกิดการขาดทุนทางการเงิน ดังนั้นการใช่มุมมองที่ครอบคลุมกระบวนการทั้งหมดตั้งแต่การเก็บรวบรวมข้อมูล การพัฒนาแบบจำลองไปจนถึงการอนุมัติสินเชื่อ เป็นสิ่งที่จำเป็นเพื่อเพิ่มผลกำไรโดยรวมให้สูงสุด การพิจารณานี้ไม่เพียงแต่รวมรายได้จากดอกเบี้ยของสินเชื่อที่ชำระแล้ว แต่ยังรวมถึงต้นทุนจากการตัดสินใจอนุมัติสินเชื่อที่ผิดพลาดด้วย การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) ได้เสนอแนวทางที่มีศักยภาพในการแก้ปัญหาดังกล่าว [3, 4]

แนวทางสำหรับการแก้ปัญหานี้คือการใช้ Deep contextual bandits (DCB) ซึ่งเป็นตัวแบบการเรียนรู้แบบเสริมกำลังที่สามารถจัดการกับปัญหาที่มีความซับซ้อน ในกรอบงานที่ผู้ขอสินเชื่อแต่ละรายจะแสดงบริบทที่มีคุณลักษณะเฉพาะ (Feature) ซึ่งสามารถใช้ในการตัดสินใจได้ โดยตัวแทน (Agent) จะเลือกผู้ขอสินเชื่อจากกลุ่มที่มีอยู่ และปรับปรุงนโยบาย (Policy) การตัดสินใจโดยพิจารณาจากผลตอบแทน (เช่น การชำระหนี้หรือการผิดนัดชำระ) แนวทางดังกล่าวช่วยให้ตัวแทนสามารถสร้างสมดุลระหว่างการสำรวจ (Exploration) เพื่อเรียนรู้บริบทใหม่ ๆ และการแสวงประโยชน์ (Exploitation) เพื่อเพิ่มผลตอบแทนในระยะยาว [3, 10]

จากที่กล่าวมาข้างต้น งานวิจัยนี้ได้เสนอแนวทางการเรียนรู้แบบเสริมกำลังเชิงลึกที่จำลองกระบวนการให้คะแนนเครดิต และการอนุมัติสินเชื่อภายใต้สภาพแวดล้อมแบบโครงข่ายประสาทเทียม โดยคำนึงถึง

ลักษณะที่หลากหลายของผู้ขอสินเชื่อ ซึ่งได้แบ่งผู้ขอสินเชื่อออกเป็นกลุ่มจากลักษณะเฉพาะตัว (Ungeneralizable contexts) ของผู้ขอสินเชื่อจากกลุ่มต่าง ๆ ผู้ขอสินเชื่อแต่ละกลุ่มอาจมีพฤติกรรมแตกต่างกันแม้ว่าจะมีคะแนนเครดิตใกล้เคียงกัน ดังนั้นการพิจารณาอนุมัติสินเชื่อในบริบทนี้ตัวแทนจะต้องทำการตัดสินใจว่าผู้ขอสินเชื่อคนใดควรได้รับการอนุมัติสินเชื่อ โดยรางวัลที่ได้จะขึ้นอยู่กับผลลัพธ์ของสินเชื่อ เช่น รายได้จากดอกเบี้ยหากลูกค้าชำระเงินคืนหรือการสูญเสียเงินทุนหากลูกค้าผิดนัดชำระ

2. วิธีการวิจัย

2.1 การเรียนรู้แบบเสริมกำลัง (Reinforcement learning)

เป็นการเรียนรู้ของเครื่องประเภทหนึ่งที่เหมาะสมสำหรับปัญหาที่มีหลายทางเลือกในการตัดสินใจ โดยมีเป้าหมายเพื่อเลือกการกระทำที่ก่อให้เกิดผลตอบแทนสูงสุด กระบวนการเรียนรู้สามารถเปรียบเทียบได้กับการลองผิดลองถูก กล่าวคือ ในช่วงเริ่มต้นระบบยังไม่ทราบว่าควรเลือกการกระทำใด แต่เมื่อได้ทดลองกระทำ และเรียนรู้จากรางวัลที่ได้รับซ้ำ ๆ ระบบจะทำการปรับปรุงกลยุทธ์จนสามารถเลือกการกระทำที่ให้รางวัลสูงสุดได้ในที่สุด โดยการเรียนรู้แบบเสริมกำลังจะประกอบไปด้วย

2.1.1 ตัวแทน (Agent)

เป็นองค์ประกอบที่ทำหน้าที่ตัดสินใจเลือกการกระทำ (Action) และโต้ตอบกับสภาพแวดล้อม (Environment) โดยเรียนรู้จากผลลัพธ์ที่ได้รับผ่านกระบวนการลองผิดลองถูกเพื่อนำไปปรับปรุงกลยุทธ์การตัดสินใจอย่างต่อเนื่อง ตัวแทนจะรับรู้สถานะ (State) ของสภาพแวดล้อม ซึ่งสะท้อนภาพรวมของสถานการณ์ในช่วงเวลานั้น และนำสิ่งที่รับรู้มาประกอบกับข้อมูลสำคัญที่จำเป็นต่อการตัดสินใจ โดยเป้าหมายของตัวแทนคือการเลือกการกระทำที่เหมาะสมที่สุด เพื่อทำให้ผลตอบแทนสะสม (Cumulative reward) สูงที่สุดในระยะยาว [10]

ในการวิจัยนี้ได้พิจารณาใช้ตัวแทนจำนวน 4 ตัว ได้แก่ ตัวแทนแบบละโมภ, ตัวแทนแบบละโมภเชิงลึก, ตัวแทนการสุ่มตัวอย่างแบบทอมสัน, และตัวแทนบูตสแตรป์แบบเบย์

2.1.2 สภาพแวดล้อม (Environment)

สภาพแวดล้อมคือระบบที่ตัวแทนมีปฏิสัมพันธ์ด้วย โดยสภาพแวดล้อมจะตอบสนองต่อการกระทำของตัวแทนผ่านการเปลี่ยนแปลงสถานะ การสังเกตการณ์ (Observation) และการมอบค่ารางวัล (Reward) ให้แก่ตัวแทน ซึ่งกลไกดังกล่าวเป็นพื้นฐานสำคัญของกระบวนการเรียนรู้แบบเสริมกำลัง [6] ทั้งนี้ สภาพแวดล้อมสามารถจำลองเป็น

กระบวนการตัดสินใจแบบมาร์คอฟ (Markov decision process: MDP) ซึ่งประกอบด้วยชุดของสถานะ, การกระทำ, ฟังก์ชันการเปลี่ยนผ่านสถานะ และฟังก์ชันรางวัล [10] ภายในสภาพแวดล้อม ประกอบด้วยองค์ประกอบสำคัญดังต่อไปนี้

2.1.2.1 การกระทำ (Action)

การตัดสินใจที่ตัวแทนเลือกดำเนินการต่อสภาพแวดล้อมในแต่ละช่วงเวลา เมื่อดำเนินการแล้วสภาพแวดล้อมจะตอบสนองโดยเปลี่ยนสถานะและมอบค่ารางวัลให้แก่ตัวแทน [6] ในบริบทของงานวิจัยนี้การกระทำหมายถึงการคัดเลือกผู้สมัครที่ได้รับการอนุมัติสินเชื่อในแต่ละช่วงเวลา ซึ่งเป็นการตัดสินใจที่ส่งผลต่อผลตอบแทนรวมของระบบ

2.1.2.2 รางวัล (Reward)

เป็นสิ่งที่สภาพแวดล้อมส่งกลับให้แก่ตัวแทนหลังจากการกระทำถูกดำเนินการ เพื่อสะท้อนว่าผลลัพธ์ของการกระทำนั้นดี หรือ ไม่ดีต่อเป้าหมายของระบบ [6] รางวัลจึงเป็นกลไกหลักที่ขับเคลื่อนการปรับปรุงนโยบายการตัดสินใจ โดยหากนโยบายปัจจุบันนำไปสู่การได้รับรางวัลต่ำ นโยบายจะถูกปรับเปลี่ยนให้เลือกการกระทำอื่นที่มีแนวโน้มที่จะสร้างผลตอบแทนสูงกว่าในอนาคต

2.1.2.3 นโยบาย (Policy)

กลยุทธ์หรือแนวทางที่ตัวแทนใช้ในการตัดสินใจว่าจะเลือกกระทำอะไรในแต่ละสถานการณ์ โดยพิจารณาจากข้อมูลของสถานะปัจจุบันของสภาพแวดล้อม นโยบายเป็นฟังก์ชันที่เชื่อมโยงสถานะไปยังการกระทำที่ควรเลือกหรือไปยังความน่าจะเป็นของการเลือกการกระทำในแต่ละแบบ [10] นโยบายอาจมีรูปแบบไม่ซับซ้อน เช่น เลือกการกระทำที่คาดว่าจะให้ผลตอบแทนสูงที่สุดทันที หรืออาจมีความซับซ้อนมากขึ้น โดยใช้อัลกอริทึมขั้นสูงหรือโครงข่ายประสาทเทียมเพื่อช่วยตัดสินใจให้เหมาะสมกับสถานการณ์ที่เปลี่ยนแปลงอยู่ตลอดเวลา

2.1.3 การออกแบบตัวแทน (Agent design)

ในงานวิจัยนี้ได้ออกแบบตัวแทนการเรียนรู้แบบเสริมกำลังสำหรับปัญหาการรับประกันสินเชื่อ โดยกำหนดให้กระบวนการตัดสินใจดำเนินไปตามขั้นตอนมาตรฐานของระบบอนุมัติสินเชื่อจริง ซึ่งสรุปเป็นอัลกอริทึมที่ 1 (Underwriting algorithm) อัลกอริทึมดังกล่าวทำหน้าที่เป็นโครงสร้างการดำเนินงานหลักของระบบ

ALGORITHM 1: UNDERWRITING ALGORITHM

- 1: **Input** Prior distribution $N(\mu, \Sigma)$,
- 2: **Initialization** $H_0 = ()$
- 3: **for** $t = 0, 1, \dots$ **do**
- 4: **recruiting** Obtain a pool of loan applicants A
- 5: **scoring** Derive credit score s_a for each $a \in A$
- 6: **making decision** Rank $a \in A$ ascendingly by the score s_a breaking ties randomly, and let A_t be the first N members
Extend loans to each $a \in A_t$
- 7: **receiving feedback** Observe O_{t+1} the default outcomes of approved loans in A_t
- 8: **updating** $H_{t+1} \leftarrow \text{append}(H_t, A_t, O_{t+1})$
- 9: **end for**

ตัวแทนการเรียนรู้แบบเสริมกำลังแต่ละแบบจะมีวิธีการให้คะแนนเครดิตที่เป็นเอกลักษณ์ โดยจะใช้กระบวนการรับประกันสินเชื่อด้วยหลักเดียวกันที่ระบุไว้ในอัลกอริทึมที่ 1 อัลกอริทึมนี้ทำงานในรูปแบบวนซ้ำ โดยในแต่ละช่วงเวลาตัวแทนจะรวบรวมกลุ่มผู้ขอสินเชื่อ A ซึ่งขนาดของกลุ่มคือ $|A| = K$ ผู้ขอสินเชื่อแต่ละคน $a \in A$ ถูกอธิบายคุณลักษณะด้วยเวกเตอร์ข้อมูลสองชุดคือ เวกเตอร์บริบท (Context vector) และเวกเตอร์คุณลักษณะ (Feature vector)

2.1.3.1 เวกเตอร์บริบท

$$\phi_a = [\phi_{a,1}, \dots, \phi_{a,M}]^T \quad (1)$$

โดยที่ M คือจำนวนเวกเตอร์บริบท

เป็นเวกเตอร์แบบ One-hot encoding สำหรับระบุกลุ่มบริบทของผู้สมัครสินเชื่อ ทุกองค์ประกอบจะมีค่าเป็นศูนย์ ยกเว้นเพียงหนึ่งองค์ประกอบที่มีค่าเป็นหนึ่ง ซึ่งจะแสดงถึงการสังกัดกลุ่มของผู้สมัครคนนั้น ในงานวิจัยนี้ได้กำหนดค่าให้เป็น 4 กลุ่ม

2.1.3.2 เวกเตอร์คุณลักษณะ

$$x_a = [x_{a,1}, \dots, x_{a,d}]^T \quad (2)$$

โดยที่ d คือจำนวนเวกเตอร์คุณลักษณะ

เป็นเวกเตอร์ที่ใช้อธิบายคุณลักษณะทางการเงินหรือพฤติกรรมของผู้สมัครสินเชื่อ เช่น รายได้, ภาระหนี้, ประวัติการชำระหนี้ หรือข้อมูลเครดิตอื่น ๆ เวกเตอร์นี้ทำหน้าที่เป็นข้อมูลนำเข้าให้กับแบบจำลองการให้คะแนนเครดิตของตัวแทน ถูกสร้างจาก 2 ส่วนประกอบ ได้แก่ ส่วนคุณลักษณะที่สุ่มจากการแจกแจงสม่ำเสมอ (Uniform distribution) บนช่วง $[-1, 1]$ ที่มีความเป็นอิสระต่อกัน (i.i.d.) จำนวน $d-1$ มิติ กล่าวคือ

$$x_{a,i} \sim U(-1,1), \quad i = 1, 2, \dots, d-1 \quad (3)$$

และส่วนที่ 2 ถูกกำหนดให้มีค่าคงที่เท่ากับ 1 เพื่อทำหน้าที่เป็นค่าคงที่ (Intercept term) ในแบบจำลอง ในงานวิจัยนี้เราได้กำหนดค่าเวกเตอร์คุณลักษณะให้เป็น 5, 10 และ 20 มิติ

เมื่อตัวแทนได้รับข้อมูลเวกเตอร์ทั้งสองชุดของผู้สมัครแต่ละรายแล้วขั้นตอนถัดไปคือ การประเมินและให้คะแนนเครดิต (Scoring) ที่จำแนกความแตกต่างเชิงกลยุทธ์ของตัวแทนแต่ละประเภท โดยตัวแทนจะนำข้อมูลเข้าสู่ฟังก์ชันการคำนวณเฉพาะตัวเพื่อประมวลผลออกมาเป็นคะแนนความเสี่ยง s_a ภายใต้หลักเกณฑ์สำคัญคือค่าคะแนนที่ยิ่งต่ำจะสะท้อนถึงความน่าจะเป็นในการผิดนัดชำระหนี้ (Probability of default) ที่ต่ำลง เมื่อผู้สมัครทุกคนในกลุ่มได้รับการประเมินค่าคะแนนเป็นที่เรียบร้อยแล้ว ระบบจะเข้าสู่ขั้นตอนการตัดสินใจอนุมัติสินเชื่อ (Underwriting decision) โดยตัวแทนจะทำการจัดลำดับผู้สมัครทั้งหมดจากผู้ที่มีความเสี่ยงต่ำที่สุดไล่เรียงไปหาคนที่สูงที่สุด จากนั้นจะทำการคัดเลือกอนุมัติสินเชื่อให้แก่ผู้สมัครในลำดับต้นจำนวน N ราย ในขณะที่ผู้สมัครที่มีความเสี่ยงสูงกว่าเกณฑ์ดังกล่าวจะถูกปฏิเสธสินเชื่อ และคัดออกจากกระบวนการพิจารณาในรอบนั้นภายหลังจากการอนุมัติและปล่อยสินเชื่อ ตัวแทนจะสังเกตผลตอบกลับจากความเป็นจริง (Feedback observation) โดยติดตามพฤติกรรมชำระหนี้ของผู้กู้ในกลุ่มที่ได้รับเลือก A_i ว่ามีการชำระคืนตามปกติ หรือเกิดการผิดนัดชำระหนี้ขึ้น

$$O_i = \{0, 1\}^K \quad (4)$$

ข้อมูลเหล่านี้จะถูกนำเข้าสู่ขั้นตอนสุดท้ายคือ การปรับปรุงกระบวนการเรียนรู้ (Model updating) ในขั้นตอนนี้ ระบบจะบันทึกผลลัพธ์การชำระหนี้ และข้อมูลบริบทที่เกี่ยวข้องลงในฐานข้อมูลประวัติ (H_i) เพื่อนำไปคำนวณปรับปรุงค่าพารามิเตอร์ของตัวแทนผ่านกระบวนการทางสถิติ

$$H_i = (A_0, O_1, A_1, O_2, \dots, A_{i-1}, O_i) \quad (5)$$

การดำเนินการดังกล่าวส่งผลให้ตัวแทนเกิดการเรียนรู้ และมีความแม่นยำในการคาดการณ์ความเสี่ยงที่เพิ่มขึ้นอย่างต่อเนื่อง

ในงานวิจัยนี้ ตัวแทนทั้ง 4 แบบใช้ฟังก์ชันซิกมอยด์ (Sigmoid function) ในการแปลงค่าผลลัพธ์ของแบบจำลองให้อยู่ในช่วง (0, 1) เพื่อใช้เป็นค่าประมาณความน่าจะเป็นของการผิดนัดชำระหนี้ โดยฟังก์ชันซิกมอยด์มีนิยามดังนี้

$$\sigma(z) = \frac{\exp(z)}{1 + \exp(z)} \quad (6)$$

โดยที่ z คือค่าผลลัพธ์เชิงเส้น (Linear predictor) ที่คำนวณจากแบบจำลองของตัวแทนแต่ละแบบ ฟังก์ชันซิกมอยด์มีคุณสมบัติที่สำคัญคือ เมื่อ z มีค่ามาก $\sigma(z)$ จะเข้าใกล้ 1 และเมื่อ z มีค่าน้อย $\sigma(z)$ จะเข้าใกล้ 0 ดังนั้นค่าคะแนนเครดิต s_a ที่คำนวณได้จะอยู่ในช่วง (0, 1) เสมอ โดยค่าที่ต่ำแสดงถึงความน่าจะเป็นในการผิดนัดชำระหนี้ที่ต่ำ ซึ่งหมายความว่าผู้สมัครรายนั้นมีความเสี่ยงต่ำและมีโอกาสได้รับการอนุมัติสินเชื่อสูงกว่า

2.2 ตัวแทนที่ใช้ในงานวิจัย

2.2.1 ตัวแทนแบบละโมบ (Greedy agent: GRE)

ตัวแทนแบบละโมบเป็นหนึ่งในวิธีการพื้นฐานของการเรียนรู้แบบเสริมกำลัง (Reinforcement learning) โดยมีหลักการสำคัญคือการมุ่งเน้นไปที่การเพิ่มผลตอบแทนในระยะสั้นให้ได้สูงสุด [6] โดยอาศัยเพียงข้อมูลที่มีอยู่ในปัจจุบันเป็นฐานในการตัดสินใจ และไม่พิจารณาถึงความจำเป็นในการเรียนรู้ระยะยาว หรือการค้นหาข้อมูลเพิ่มเติมเพื่อปรับปรุงตัวแบบในอนาคตในบริบทของการประเมินคะแนนเครดิต และการพิจารณาสินเชื่อแบบทันท่วงทีของตัวแทนแบบละโมบคือการคัดกรอง และเลือกผู้กู้ที่มีความน่าจะเป็นสูงสุดที่จะชำระคืน โดยอ้างอิงจากประวัติข้อมูลในอดีต เพื่อให้บรรลุวัตถุประสงค์ดังกล่าว ในทางปฏิบัติ กลไกการให้คะแนนของตัวแทนแบบละโมบถูกออกแบบมาให้สะท้อนแนวคิดการแสวงหาประโยชน์ (Exploitation) โดยกระบวนการทำงานเริ่มจากการประมาณค่าพารามิเตอร์ของตัวแบบที่ดีที่สุด ณ ขณะนั้นด้วยวิธีการ Maximum a posteriori (MAP) ซึ่งเป็นการหาค่าประมาณแบบจุด (Point estimate) ที่มีความเป็นไปได้สูงสุดจากข้อมูลที่มีอยู่ H_i เมื่อได้ค่าพารามิเตอร์ดังกล่าว ตัวแทนจะนำมากำหนดเป็นคะแนนเครดิต s_a สำหรับผู้สมัครแต่ละรายผ่านสมการดังนี้

$$s_a = \frac{\exp(\phi_a^T \hat{\Theta}_i x_a)}{1 + \exp(\phi_a^T \hat{\Theta}_i x_a)} \quad (7)$$

โดยที่ $\hat{\Theta}_i$ คือค่า MAP จากข้อมูลที่มีอยู่ H_i

2.2.2 ตัวแทนแบบละโมบเชิงลึก (Greedy neural network agent: GRENN)

ตัวแทนแบบละโมบเชิงลึกเป็นการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep learning) เข้ากับกลไกการตัดสินใจแบบละโมบภายใต้กรอบการเรียนรู้แบบเสริมกำลัง [6, 11] โดยมีหลักการสำคัญคือการใช้โครงข่ายประสาทเทียม (Neural network) ที่มีความซับซ้อนมาทำหน้าที่เป็นตัวประมาณค่าฟังก์ชัน (Function approximator) แทนแบบจำลองเชิงเส้นแบบดั้งเดิม [5] เป้าหมายคือเพื่อจับรูปแบบความสัมพันธ์แบบไม่เป็นเชิงเส้น (Non-linear relationships) ระหว่างข้อมูลผู้สมัครและความเสี่ยง

กลไกการให้คะแนนของตัวแทนละโมบเชิงลึกถูกออกแบบมาให้รองรับข้อมูลที่มีมิติซับซ้อน โดยกระบวนการเริ่มจากการนำเวกเตอร์คุณลักษณะและเวกเตอร์บริบทมาเชื่อมต่อกัน (Concatenate) เป็นข้อมูลนำเข้า แล้วส่งผ่านชั้นซ่อน (Hidden layers) ของโครงข่ายประสาทเทียมแบบ Multi-layer perceptron (MLP) ผ่านฟังก์ชันกระตุ้น (Activation function) ต่าง ๆ เพื่อคำนวณออกมาเป็นคะแนนเครดิต s_a ผ่านฟังก์ชันซิกมอยด์ในขั้นสุดท้ายดังสมการ

$$s_a = \frac{1}{1 + \exp(-f(x_a, \phi_a^T, \hat{\theta}))} \quad (8)$$

โดยที่ $\hat{\theta}$ คือเมทริกซ์พารามิเตอร์ของทุกบริบท

ตัวแทนแบบ GRENN ใช้โครงข่ายประสาทเทียมแบบ Multi-layer perceptron (MLP) ในการประมาณค่าความน่าจะเป็นของการผิดนัดชำระหนี้ โดยมีสถาปัตยกรรมและ Hyperparameters ดังแสดงในตารางที่ 1

ตารางที่ 1 : Hyperparameters ของตัวแทนแบบ GRENN

พารามิเตอร์	ค่า
ชั้นนำเข้า	d+M โหนด
ชั้นซ่อนที่ 1	64 โหนด
ชั้นซ่อนที่ 2	32 โหนด
ชั้นผลลัพธ์	1 โหนด
อัตราการเรียนรู้	0.001
ฟังก์ชันความสูญเสีย	Binary cross-entropy

2.2.3 ตัวแทนการสุ่มตัวอย่างแบบทอมสัน (Thompson sampling agent: THS)

ตัวแทนแบบ THS เป็นอีกหนึ่งวิธีการในการเรียนรู้แบบเสริมกำลัง โดยมีหลักการสำคัญที่แตกต่างจากตัวแทนแบบละโมบคือการมุ่งเน้นไปที่การสร้างสมดุลระหว่างการสำรวจ และแสวงหาประโยชน์ [1] โดยไม่ได้พิจารณาเพียงแค่ค่าประมาณที่ดีที่สุดจากข้อมูลปัจจุบันเท่านั้น แต่ยังคำนึงถึงความไม่แน่นอน (Uncertainty) ของข้อมูลเพื่อเพิ่มโอกาสในการเรียนรู้ และปรับปรุงตัวแบบในระยะยาวในบริบทของการประเมินคะแนนเครดิต และการพิจารณาสินเชื่อ บทบาทสำคัญของตัวแทนแบบ THS คือการเปิดโอกาสในการค้นหาผู้กู้ที่มีศักยภาพกลุ่มใหม่ๆ ที่ตัวแบบเดิมอาจมองข้ามไป เพื่อให้บรรลุวัตถุประสงค์ดังกล่าวในทางปฏิบัติ กลไกการให้คะแนนของ THS จึงถูกออกแบบมาให้สะท้อนแนวคิดการสุ่มตัวอย่างจากความน่าจะเป็น (Probabilistic sampling) โดยกระบวนการทำงานไม่ได้ใช้ค่าพารามิเตอร์คงที่ [9] แต่เริ่มจากการสร้างการแจกแจงความน่าจะเป็นของพารามิเตอร์ (Posterior distribution) และทำการสุ่มค่าพารามิเตอร์จำลอง ($\tilde{\theta}_t$) ออกมาใช้งานในแต่ละรอบการตัดสินใจ [6]

เมื่อได้ค่าพารามิเตอร์ที่สุ่มมาได้ ($\tilde{\theta}_t$) ตัวแทนจะนำมาคำนวณเป็นคะแนนเครดิต s_a สำหรับผู้สมัครแต่ละรายผ่านฟังก์ชันดังสมการ

$$s_a = \frac{\exp(\phi_a^T \tilde{\theta}_t x_a)}{1 + \exp(\phi_a^T \tilde{\theta}_t x_a)} \quad (9)$$

โดยที่ $\tilde{\theta}_t$ คือเมทริกซ์พารามิเตอร์ของตัวแบบโลจิสติกทั้งหมดที่สุ่มมาจากการแจกแจงภายหลัง ณ เวลาที่ t

2.2.4 ตัวแทนบูตสแตรป์แบบเบย์ (Bayesian bootstrapping agent: BBTS)

ตัวแทนบูตสแตรป์แบบเบย์ เป็นอีกหนึ่งแนวทางในการประยุกต์ใช้ การสุ่มตัวอย่างแบบทอมสันที่ได้รับการพัฒนาเพื่อแก้ไขข้อจำกัดทางเทคนิคของการประมาณค่าการแจกแจงภายหลัง (Posterior approximation) ในรูปแบบดั้งเดิม โดยหลักการสำคัญของตัวแทนแบบ BBTS คือการหลีกเลี่ยงการคำนวณสูตรความน่าจะเป็นที่ซับซ้อน (เช่น การใช้ Laplace approximation ที่ต้องคำนวณ Hessian matrix) แต่ใช้วิธีการสุ่มตัวอย่างแบบถ่วงน้ำหนัก (Weighted resampling) บนข้อมูลที่มีอยู่เพื่อจำลองความไม่แน่นอนของพารามิเตอร์แทน ในบริบทของการประเมินคะแนนเครดิต และการพิจารณาสินเชื่อ บทบาทของตัวแทนแบบ BBTS คือการสร้างกลไกการสำรวจที่มีประสิทธิภาพ โดยอาศัยพื้นฐานจากข้อมูลจริงที่สังเกตได้ แทนที่จะพึ่งพาข้อสมมติฐานการแจกแจงแบบปกติ (Gaussian distribution) เพียงอย่างเดียว กลไกการทำงานเริ่มจากการนำข้อมูลประวัติการชำระหนี้ทั้งหมดมาสร้าง น้ำหนักแบบสุ่ม (Random weights) โดยใช้การแจกแจงแบบแกมมา (Gamma distribution) สำหรับข้อมูลแต่ละรายการ ซึ่งเปรียบเสมือนการจำลองชุดข้อมูลใหม่ที่มีความเป็นไปได้หลายรูปแบบ (Bootstrap replicates) จากนั้นตัวแทนจะทำการฝึกสอนตัวแบบด้วยข้อมูลที่ถ่วงน้ำหนักเหล่านี้ [8] เพื่อให้ได้ค่าพารามิเตอร์จำลอง ($\tilde{\theta}_t^{BB}$) ออกมาใช้งานเมื่อได้ค่าพารามิเตอร์จำลองจากกระบวนการบูตสแตรป์แล้วตัวแทนจะนำมาคำนวณเป็นคะแนนเครดิต s_a ผ่านฟังก์ชัน ดังสมการ

$$s_a = \frac{\exp(f(x_a, \phi_a^T, \tilde{\theta}_t^{BB}))}{1 + \exp(f(x_a, \phi_a^T, \tilde{\theta}_t^{BB}))} \quad (10)$$


โดยที่ $\tilde{\theta}_t^{BB}$ คือเมทริกซ์พารามิเตอร์ของตัวแบบโลจิสติกทั้งหมดที่สุ่มมาจาก Bayesian bootstrap ณ เวลา t

2.3 สภาพแวดล้อมที่ใช้ในงานวิจัย

การศึกษาครั้งนี้เลือกใช้สภาพแวดล้อมแบบโครงข่ายประสาทเทียม (Neural network environment) เป็นเครื่องมือในการจำลอง หรือประมาณพฤติกรรมของระบบแทนการกำหนดสมการทางคณิตศาสตร์แบบตายตัวล่วงหน้าโดยโครงข่ายประสาทเทียมทำหน้าที่เรียนรู้ความสัมพันธ์ระหว่างสถานะของสภาพแวดล้อม, การกระทำของตัวแทน และผลลัพธ์ที่เกิดขึ้นจากข้อมูลประสบการณ์ที่ตัวแทนได้ตอบกับสภาพแวดล้อม

แนวทางดังกล่าวช่วยให้สภาพแวดล้อมสามารถจับความสัมพันธ์ที่มีความซับซ้อนสูง โดยเฉพาะความสัมพันธ์แบบไม่เป็นเชิงเส้น (Non-linear relationships) ซึ่งยากต่อการอธิบายด้วยแบบจำลองการวิเคราะห์ด้วยวิธีดั้งเดิม เช่น สมการเชิงเส้น หรือแบบจำลองสถิติทั่วไป ด้วยเหตุนี้โครงข่ายประสาทเทียมจึงถูกนำมาใช้เป็นฟังก์ชันประมาณค่าเพื่อเรียนรู้กลไกภายในของสภาพแวดล้อมจากข้อมูลจริงในงานวิจัยนี้ได้ใช้โครงข่ายประสาทเทียมเพื่อจำลองระบบการ

ผิวนัดชำระของสินเชื่อ โดยใช้โครงข่ายประสาทเทียมเป็นกลไกกำเนิดความน่าจะเป็นของการผิวนัดชำระของผู้สมัครสินเชื่อ วิธีการนี้มีวัตถุประสงค์เพื่อสร้างสถานการณ์ที่โครงสร้างจริงของข้อมูล (Data-generating process) มีความซับซ้อนและไม่เป็นเชิงเส้น



ภาพที่ 1: โครงสร้างของโครงข่ายประสาทเทียม

ภาพที่ 1 แสดงโครงสร้างของโครงข่ายประสาทเทียมที่ถูกนำมาใช้เป็นแบบจำลองสภาพแวดล้อม สำหรับสร้างข้อมูลความน่าจะเป็นในการผิวนัดชำระหนี้ โดยกลไกการทำงานประกอบด้วยชั้นซ่อน (Hidden layers) จำนวน 2 ชั้น ซึ่งมีการกำหนดฟังก์ชันกระตุ้น (Activation function) และการคำนวณค่าน้ำหนักตามลำดับชั้น โดยสามารถอธิบายในรูปสมการได้ดังนี้

ชั้นซ่อนที่ 1 และ 2 ใช้ฟังก์ชันกระตุ้นแบบ Hyperbolic tangent (Tanh) สามารถเขียนได้ดังนี้

$$h_1 = \tanh(W_1 x) \quad (11)$$

$$h_2 = \tanh(W_2 h_1) \quad (12)$$

สำหรับชั้นออกติของข้อมูล ซึ่งเป็นชั้นสุดท้ายก่อนการแสดงผล จะใช้ฟังก์ชันกระตุ้นแบบ Sigmoid (σ) เพื่อปรับค่าให้อยู่ในช่วงความน่าจะเป็น (0, 1) โดยมีการกำหนดค่าอคติของข้อมูล (Bias: b) ดังสมการ

$$h_3 = \frac{1}{1 + \exp(-W_3 h_2 - b)} \quad (13)$$

โดยที่ W_1, W_2, W_3 คือ เมทริกซ์น้ำหนักที่สุ่มค่าจากการแจกแจงปกติ $N(0, 0.15)$

b คือเวกเตอร์ค่าอคติ

2.4 การวัดประสิทธิภาพ (Performance measures)

การวัดประสิทธิภาพที่ใช้ในการศึกษารุ่นนี้ ได้แก่ รางวัลสะสม และค่าเสียโอกาสสะสม

2.4.1 รางวัลสะสม (Cumulative reward)

ผลรวมของผลตอบแทนที่ตัวแทนได้รับจากการตัดสินใจปล่อยสินเชื่อตลอดช่วงเวลาการเรียนรู้ โดยรางวัลที่คาดหวัง (Expected reward) สามารถคำนวณได้ดังนี้

$$\mathbb{E}[r_t] = v(1 - p) + l(p) \quad (14)$$

โดยที่ r_t คือผลตอบแทนที่ได้รับจริงจากการเลือกผู้กู้

p คือความน่าจะเป็นที่ผู้กู้จะผิวนัดชำระหนี้

v คือผลตอบแทนเมื่อชำระหนี้คืน กำหนดไว้ที่ 0.2

l คือผลขาดทุนเมื่อผิวนัดชำระหนี้ กำหนดไว้ที่ -0.8

2.4.2 ค่าเสียโอกาสสะสม (Cumulative regret)

ตัวชี้วัดที่แสดงถึงผลต่างรวมระหว่างผลตอบแทนคาดหวังที่สูงที่สุดที่เป็นไปได้ (จากผู้กู้ที่ดีที่สุดในกลุ่ม) กับผลตอบแทนคาดหวังจากการตัดสินใจจริงของตัวแทน เพื่อสะท้อนถึงประสิทธิภาพในการเรียนรู้ของตัวแทนเทียบกับกรณีที่ดีที่สุด ค่าเสียโอกาส (Regret) สามารถคำนวณได้จาก

$$regret_t = \mathbb{E}[r_{a^*_t}] - \mathbb{E}[r_{a_t}] \quad (15)$$

โดยที่ a^*_t คือ การกระทำหรือผู้กู้ที่ดีที่สุด (Optimal action) ณ เวลา t ซึ่งเป็นผู้กู้ที่ให้ค่าผลตอบแทนคาดหวังสูงที่สุดในบรรดาทางเลือกทั้งหมดที่มีอยู่

a_t คือการกระทำหรือผู้กู้ที่ตัวแทนเลือกจริง ณ เวลา t ตามนโยบายของอัลกอริทึมในขณะนั้น

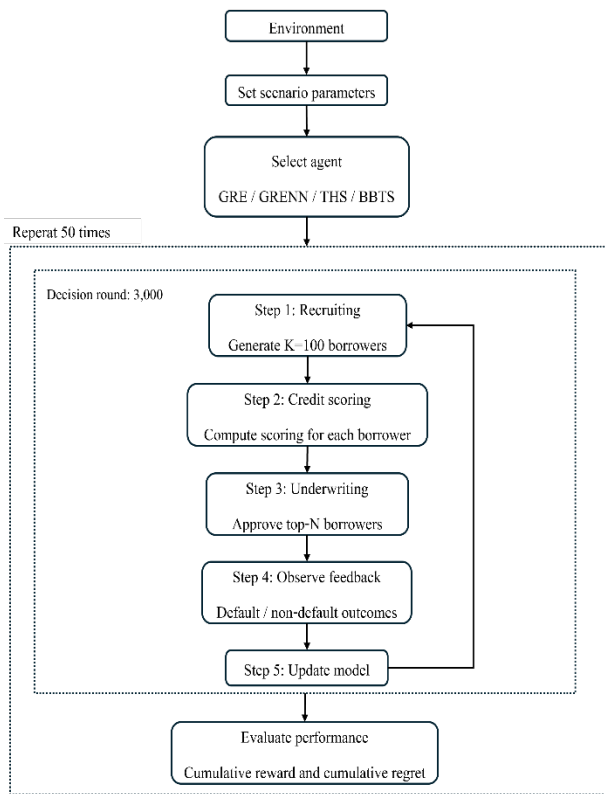
2.5 ขั้นตอนการทดลอง (Experimental design)

การทดลองในงานวิจัยนี้ได้ออกแบบเพื่อประเมินประสิทธิภาพของในการเรียนรู้แบบเสริมกำลังเชิงลึกของตัวแทนทั้ง 4 แบบ ได้แก่ ตัวแทนแบบละโมภ (GRE) ตัวแทนแบบละโมภเชิงลึก (GRENN) ตัวแทนการสุ่มตัวอย่างแบบทอมสัน (THS) และตัวแทนบูตสแตร็ปแบบเบส (BBTS) ภายใต้สภาพแวดล้อมที่จำลองพฤติกรรมลูกค้าด้วยโครงข่ายประสาทเทียม

เพื่อให้การประเมินครอบคลุมสถานการณ์ที่หลากหลาย งานวิจัยนี้ออกแบบการทดลองทั้งหมด 6 สถานการณ์ (Situations) โดยพิจารณาความซับซ้อนของคุณลักษณะของผู้สมัคร และจำนวนผู้สมัครที่ได้รับการอนุมัติในแต่ละรอบ ดังนี้

$$Situations = \{x_a = 5, 10, 20\} \times \{k = 1, 10\} \quad (16)$$


ในแต่ละสถานการณ์มีผู้สมัครสินเชื่อจำนวน 100 ราย ต่อรอบ และดำเนินการจำลอง 3,000 ช่วงเวลา (Timesteps) โดยทำการทดลองซ้ำทั้งหมด 50 ครั้ง โดยมีกรอบแนวคิดและลำดับขั้นตอนการทดลองแสดงดังภาพที่ 2



ภาพที่ 2: ลำดับขั้นตอนการทดลอง

3. ผลการวิจัยและอภิปรายผล

3.1 สถานการณ์ที่ 1: เลือกผู้ขอสินเชื่อคนเดียวด้วยจำนวนคุณลักษณะเท่ากับ 5 มิติ



ภาพที่ 3: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 1

ตารางที่ 2 : ผลการวิจัยสถานการณ์ที่ 1

Agent	Cumulative Regret	Cumulative Reward
Greedy	157.79 ± 122.43	130.20 ± 176.87
GRENN	177.01 ± 70.68	112.04 ± 127.19
THS	109.71 ± 36.89	180.54 ± 125.88
BBTS	108.46 ± 73.75	181.44 ± 137.59


จากผลการทดลองพบว่าตัวแทน BBTS ให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 108.46 ± 73.75 และผลตอบแทนสะสมสูงที่สุดเท่ากับ 181.44 ± 137.59 ซึ่งอยู่ในระดับใกล้เคียงกับ

ตัวแทนแบบ THS ที่ให้ค่าเสียโอกาสสะสมเท่ากับ 109.71 ± 36.89 และมีผลตอบแทนสะสมเท่ากับ 180.54 ± 125.88 เมื่อเปรียบเทียบกับตัวแทนทั้งหมดในกรณีที่สามารถเลือกผู้กู้ได้เพียง 1 รายต่อรอบ แสดงให้เห็นว่ากลไกการสุ่มตัวอย่างแบบทอมสันไม่ว่าจะอยู่ในรูปแบบของการประมาณ Posterior แบบ Laplace หรือการบูตสแตรัปแบบเบย์ สามารถสร้างสมดุลระหว่างการสำรวจ และการแสวงประโยชน์ได้อย่างมีประสิทธิภาพในกรณีที่ปัญหาไม่ซับซ้อนมาก และจำนวนการตัดสินใจต่อรอบมีขนาดเล็ก

ในขณะที่ตัวแทนแบบ GRE แม้จะสามารถเรียนรู้และปรับตัวได้ค่อนข้างรวดเร็วในช่วงต้นของการทดลอง แต่เนื่องจากขาดกลไกการสำรวจ ทำให้มีแนวโน้มยึดติดกับการตัดสินใจที่ดูเหมาะสมจากข้อมูลช่วงต้น และติดอยู่กับนโยบายที่ไม่เหมาะสมในบางการทดลอง ส่งผลให้ค่าเสียโอกาสสะสมมีความแปรปรวนค่อนข้างสูง โดยมีค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานเท่ากับ 157.79 ± 122.43 และให้ผลตอบแทนสะสมเฉลี่ยเพียง 130.20 ± 176.87

สำหรับตัวแทนแบบ GRENN ซึ่งใช้โครงข่ายประสาทเทียมในการประมาณความน่าจะเป็นของการผิดนัดชำระหนี้ แม้ว่าจะมีศักยภาพในการแทนความสัมพันธ์แบบไม่เป็นเชิงเส้น แต่เมื่อมีคิของคุณลักษณะมีขนาดเล็ก และโครงข่ายประสาทเทียมมีจำนวนพารามิเตอร์มากเกินไปจนเกิดความจำเป็นเมื่อเทียบกับความซับซ้อนของปัญหา ส่งผลให้การเรียนรู้ในช่วงต้นมีความไม่เสถียร และไม่สามารถใช้ประโยชน์จากโครงสร้างของข้อมูลได้อย่างเต็มที่ ทำให้เกิดค่าเสียโอกาสสะสมสูงที่สุดที่ 177.01 ± 70.68 และให้ผลตอบแทนสะสมต่ำที่สุดที่ 112.04 ± 127.19

3.2 สถานการณ์ที่ 2: เลือกผู้ขอสินเชื่อ 10 คนด้วยจำนวนคุณลักษณะเท่ากับ 5 มิติ



ภาพที่ 4: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 2

ตารางที่ 3 : ผลการวิจัยสถานการณ์ที่ 2

Agent	Cumulative Regret	Cumulative Reward
Greedy	591.41 ± 629.47	1,474.62 ± 1,348.52
GRENN	450.84 ± 273.60	1,609.54 ± 1,249.11
THS	272.06 ± 91.14	1,787.46 ± 1,194.26
BBTS	399.27 ± 371.28	1,661.82 ± 1,188.56

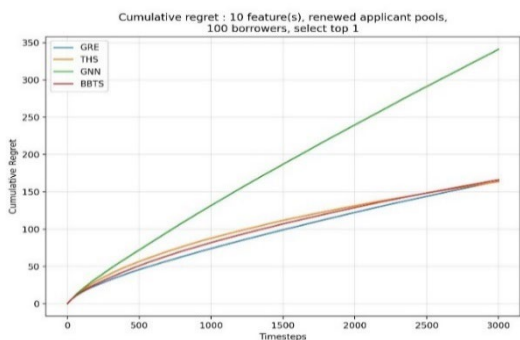
จากผลการทดลองเมื่อเพิ่มจำนวนผู้คนที่สามารถเลือกได้ต่อรอบเป็น 10 ราย พบว่าตัวแทนแบบ THS ให้ประสิทธิภาพที่ดีที่สุดอย่างชัดเจน โดยให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 272.06 ± 91.14 และให้ผลตอบแทนสะสมสูงที่สุดเท่ากับ $1,787.46 \pm 1,194.26$ เมื่อเปรียบเทียบกับตัวแทนทั้งหมด แสดงให้เห็นว่าการประมาณความไม่แน่นอนของพารามิเตอร์ผ่านการประมาณ Posterior แบบ Laplace มีบทบาทสำคัญอย่างยิ่งในกรณีที่ต้องตัดสินใจหลายรายการพร้อมกันในแต่ละรอบ

ในขณะที่ตัวแทนแบบ BBTS ให้ค่าเสียโอกาสสะสมเท่ากับ 399.27 ± 371.28 และให้ผลตอบแทนสะสมเท่ากับ $1,661.82 \pm 1,188.56$ ซึ่งแม้จะยังคงให้ผลลัพธ์ที่ดีกว่าตัวแทนแบบ GRE แต่มีความแปรปรวนของค่าเสียโอกาสสูงมากสะท้อนให้เห็นถึงความไม่เสถียรของการประมาณความไม่แน่นอนด้วยวิธีการบูตสแตรป์แบบเบส เมื่อจำนวนการตัดสินใจต่อรอบมีขนาดใหญ่

สำหรับตัวแทนแบบ GRENN ให้ค่าเสียโอกาสสะสมเท่ากับ 450.84 ± 273.60 และให้ผลตอบแทนสะสมเท่ากับ $1,609.54 \pm 1,249.11$ โดยแม้โครงข่ายประสาทเทียมจะสามารถแทนรูปแบบความสัมพันธ์ที่ซับซ้อนได้ แต่การขาดกลไกการลุ่ม หรือการประมาณค่า Posterior ทำให้พฤติกรรมการตัดสินใจยังคงเป็นแบบละโมภและมีความเสี่ยงสูงต่อการเลือกผู้ที่ไม่เหมาะสม

ในขณะที่ตัวแทนแบบ GRE ให้ค่าเสียโอกาสสะสมสูงที่สุดเท่ากับ 591.41 ± 629.47 และให้ผลตอบแทนสะสมต่ำที่สุดเท่ากับ $1,474.62 \pm 1,348.52$ ซึ่งสะท้อนให้เห็นอย่างชัดเจนว่าการขาดกลไกการสำรวจความไม่แน่นอนทำให้ตัวแทนมีแนวโน้มยึดติดกับกลุ่มผู้กู้เดิม และไม่สามารถแก้ไขนโยบายการตัดสินใจที่ไม่เหมาะสมได้เมื่อเผชิญกับความผิดพลาดในช่วงต้น

3.3 สถานการณ์ที่ 3: เลือกผู้ขอสินเชื่อคนเดียวด้วยจำนวนคุณลักษณะเท่ากับ 10 มิติ



ภาพที่ 5: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 3

ตารางที่ 4 : ผลการวิจัยสถานการณ์ที่ 3

Agent	Cumulative Regret	Cumulative Reward
Greedy	164.41 ± 126.78	188.14 ± 145.21
GRENN	341.14 ± 88.40	11.34 ± 128.74
THS	163.78 ± 39.55	192.40 ± 107.78
BBTS	166.26 ± 92.17	186.88 ± 126.51


จากผลการทดลองพบว่าตัวแทนแบบ THS ให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 163.78 ± 39.55 และให้ผลตอบแทนสะสมสูงที่สุดเท่ากับ 192.40 ± 107.78 เมื่อเปรียบเทียบกับตัวแทนทั้งหมด แสดงให้เห็นว่ากลไกการลุ่มตัวอย่างแบบทอมสัน ที่อาศัยการประมาณ Posterior ด้วยวิธี Laplace ยังคงสามารถรักษาสมดุลระหว่างการสำรวจและการแสวงประโยชน์ได้อย่างมีประสิทธิภาพ แม้ว่ามิติของคุณลักษณะจะเพิ่มขึ้นเป็น 10 มิติ ซึ่งทำให้ปัญหามีความซับซ้อนสูงขึ้น

ในขณะที่ตัวแทนแบบ BBTS และตัวแทนแบบ GRE ให้ผลลัพธ์ที่อยู่ในระดับใกล้เคียงกัน โดยตัวแทนแบบ BBTS ให้ค่าเสียโอกาสสะสมเท่ากับ 166.26 ± 92.17 และผลตอบแทนสะสมเท่ากับ 186.88 ± 126.51 ส่วนตัวแทนแบบ GRE ให้ค่าเสียโอกาสสะสมเท่ากับ 164.41 ± 126.78 และผลตอบแทนสะสมเท่ากับ 188.14 ± 145.21 ซึ่งสะท้อนว่า ในกรณีที่เลือกผู้กู้เพียง 1 รายต่อรอบ แม้จะมีมิติสูงขึ้น แต่ความรุนแรงของความผิดพลาดต่อรอบยังคงจำกัดอยู่ในระดับต่ำ ทำให้วิธีเลือกแบบละโมภ สามารถให้ผลลัพธ์ที่ได้ใกล้เคียงกับวิธีการบูตสแตรป์แบบเบส

อย่างไรก็ตาม เมื่อพิจารณาความเสถียรของผลลัพธ์จะพบว่าตัวแทนแบบ GRE มีความแปรปรวนของค่าเสียโอกาสสะสมสูงกว่าชัดเจน (ส่วนเบี่ยงเบนมาตรฐานเท่ากับ 126.78) เมื่อเทียบกับตัวแทนแบบ THS ซึ่งมีส่วนเบี่ยงเบนมาตรฐานเพียง 39.55 สะท้อนให้เห็นว่า แม้ค่าเฉลี่ยของตัวแทนแบบละโมภจะไม่ได้ด้อยกว่าอย่างชัดเจน แต่ยังคงมีความเสี่ยงที่จะติดอยู่กับนโยบายที่ไม่เหมาะสมในบางการทดลอง

สำหรับตัวแทนแบบ GRENN ซึ่งใช้โครงข่ายประสาทเทียมในการประมาณความน่าจะเป็นของการผิดนัดชำระหนี้ ให้ผลลัพธ์ด้อยกว่าวิธีอื่นอย่างชัดเจน โดยมีค่าเสียโอกาสสะสมสูงถึง 341.14 ± 88.40 และมีผลตอบแทนสะสมเพียง 11.34 ± 128.74 เท่านั้น แสดงให้เห็นว่า เมื่อมิติของคุณลักษณะมีขนาดค่อนข้างใหญ่ แต่จำนวนข้อมูลที่ได้รับในแต่ละรอบยังคงมีจำกัด โครงข่ายประสาทเทียมซึ่งมีจำนวนพารามิเตอร์สูงมีแนวโน้มเกิดความไม่เสถียรในช่วงต้นการเรียนรู้และไม่สามารถแสดงศักยภาพเหนือแบบจำลองที่ใช้การประมาณค่าความน่าจะเป็นแบบโลจิสติกได้ภายใต้กรอบการตัดสินใจแบบละโมภ

3.4 สถานการณ์ที่ 4: เลือกผู้ขอสินเชื่อ 10 คนด้วยจำนวนคุณลักษณะเท่ากับ 10 มิติ



ภาพที่ 6: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 4

ตารางที่ 5 : ผลการวิจัยสถานการณ์ที่ 4

Agent	Cumulative Regret	Cumulative Reward
Greedy	685.26 ± 504.46	1,814.06 ± 1,073.05
GRENN	840.50 ± 376.88	1,664.06 ± 956.71
THS	473.08 ± 96.92	2,035.54 ± 920.23
BBTS	540.87 ± 267.54	1,961.44 ± 945.93


จากผลการทดลองพบว่าเมื่อเพิ่มจำนวนผู้กู้ที่สามารถเลือกได้ต่อรอบเป็น 10 รายพบว่าตัวแทนแบบ THS ให้ประสิทธิภาพดีที่สุดอย่างชัดเจน โดยให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 473.08 ± 96.92 และให้ผลตอบแทนสะสมสูงที่สุดเท่ากับ $2,035.54 \pm 920.23$ เมื่อเทียบกับตัวแทนอื่นทั้งหมด

ในขณะที่ตัวแทนแบบ BBTS ให้ค่าเสียโอกาสสะสมเท่ากับ 540.87 ± 267.54 และให้ผลตอบแทนสะสมเท่ากับ $1,961.44 \pm 945.93$ ซึ่งแม้จะยังคงให้ผลลัพธ์ที่ดีในด้านค่าเฉลี่ยแต่มีความแปรปรวนของค่าเสียโอกาสค่อนข้างสูง แสดงให้เห็นถึงความไม่เสถียรของการประมาณความไม่แน่นอนด้วยวิธีการบูตสแตรัปแบบเบสในกรณีที่ต้องตัดสินใจหลายรายการพร้อมกัน

สำหรับตัวแทนแบบ GRE และตัวแทนแบบ GRENN ให้ผลลัพธ์ดีกว่าวิธีการสุ่มตัวอย่างแบบทอมสัน อย่างชัดเจน โดยตัวแทนแบบ GRE ให้ค่าเสียโอกาสสะสมสูงถึง 685.26 ± 504.46 และมีผลตอบแทนสะสมเท่ากับ $1,814.06 \pm 1,073.05$ ขณะที่ตัวแทนแบบ GRENN ให้ค่าเสียโอกาสสะสมสูงที่สุดในกลุ่มเท่ากับ 840.50 ± 376.88 และมีผลตอบแทนสะสมเพียง $1,664.06 \pm 956.71$

ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่า ความคลาดเคลื่อนในการประมาณค่าพารามิเตอร์ สามารถส่งผลกระทบต่อการจัดอันดับของผู้กู้หลายรายพร้อมกัน ซึ่งก่อให้เกิดความผิดพลาดเชิงกลุ่ม (Batch error) และส่งผลให้ค่าเสียโอกาสสะสมมีแนวโน้มเพิ่มขึ้นได้อย่างรวดเร็วขึ้นในบางการทดลอง ผลกระทบของ Batch error จะขึ้นอยู่กับระดับความซับซ้อนของข้อมูลและกลไกการตัดสินใจของตัวแทน

3.5 สถานการณ์ที่ 5: เลือกผู้ขอสินเชื่อคนเดียวด้วยจำนวนคุณลักษณะเท่ากับ 20 มิติ



ภาพที่ 7: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 5

ตารางที่ 6 : ผลการวิจัยสถานการณ์ที่ 5

Agent	Cumulative Regret	Cumulative Reward
Greedy	212.65 ± 85.02	152.94 ± 96.06
GRENN	413.53 ± 60.26	-46.44 ± 79.50
THS	262.09 ± 31.01	107.32 ± 68.97
BBTS	250.02 ± 64.50	118.68 ± 77.00


จากผลการทดลองพบว่าตัวแทนแบบ GRE ให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 212.65 ± 85.02 และให้ผลตอบแทนสะสมสูงที่สุดเท่ากับ 152.94 ± 96.06 เมื่อเปรียบเทียบกับตัวแทนทั้งหมดในกรณีที่สามารถเลือกผู้กู้ได้เพียง 1 รายต่อรอบ แสดงให้เห็นว่าเมื่อมิติของคุณลักษณะเพิ่มขึ้นเป็น 20 มิติ การอาศัยค่าประมาณแบบจุดจากแบบจำลองโลจิสติกเพียงอย่างเดียวสามารถให้ประสิทธิภาพค่าเฉลี่ยที่ดีได้ในสถานการณ์ที่ผลกระทบจากความผิดพลาดในแต่ละรอบยังมีขนาดจำกัด

ในขณะที่ตัวแทนแบบ THS ให้ค่าเสียโอกาสสะสมเท่ากับ 262.09 ± 31.01 และให้ผลตอบแทนสะสมเท่ากับ 107.32 ± 68.97 ซึ่งแม้จะดีกว่าตัวแทนแบบ GRE ในด้านค่าเฉลี่ยของผลตอบแทน แต่มีความแปรปรวนของค่าเสียโอกาสสะสมต่ำกว่าอย่างชัดเจน สะท้อนให้เห็นถึงความเสถียรของกลไกการสุ่มพารามิเตอร์จาก Posterior เมื่อเผชิญกับปัญหาที่มีมิติสูง

สำหรับตัวแทนแบบ BBTS ให้ค่าเสียโอกาสสะสมเท่ากับ 250.02 ± 64.50 และให้ผลตอบแทนสะสมเท่ากับ 118.68 ± 77.00 ซึ่งให้ผลลัพธ์อยู่ในระดับกึ่งกลางระหว่างตัวแทนแบบ GRE และตัวแทนแบบ THS โดยมีทั้งค่าเฉลี่ยและความแปรปรวนอยู่ในระดับปานกลาง

อย่างไรก็ตาม สำหรับตัวแทนแบบ GRENN ให้ผลลัพธ์ดีกว่าวิธีอื่นอย่างชัดเจน โดยมีค่าเสียโอกาสสะสมสูงถึง 413.53 ± 60.26 และมีผลตอบแทนสะสมติดลบที่ -46.44 ± 79.50 แสดงให้เห็นว่าเมื่อมิติของคุณลักษณะมีขนาดสูง โครงข่ายประสาทเทียมซึ่งมีจำนวนพารามิเตอร์มากและการเรียนรู้แบบละโมภ ไม่สามารถปรับตัวได้ดีภายใต้จำนวนข้อมูลที่จำกัดในช่วงต้นของการเรียนรู้ และมีแนวโน้มที่จะเกิดการเรียนรู้ที่ไม่เสถียรและเลือกการตัดสินใจที่ไม่เหมาะสมอย่างต่อเนื่อง

3.6 สถานการณ์ที่ 6: เลือกผู้ขอสินเชื่อ 10 คนด้วยจำนวนคุณลักษณะเท่ากับ 20 มิติ



ภาพที่ 8: ค่าเสียโอกาสสะสมของสถานการณ์ที่ 6

ตารางที่ 7 : ผลการวิจัยสถานการณ์ที่ 6

Agent	Cumulative Regret	Cumulative Reward
Greedy	770.44 ± 257.08	1,708.94 ± 585.40
GRENN	1,575.17 ± 242.66	894.82 ± 640.63
THS	849.73 ± 91.99	1,626.66 ± 525.75
BBTS	893.54 ± 177.30	1,580.26 ± 536.99

จากผลการทดลองพบว่าเมื่อเพิ่มจำนวนผู้ผู้ที่สามารถเลือกได้ต่อรอบเป็น 10 รายพบว่า พบว่าตัวแทนแบบ GRE ให้ค่าเสียโอกาสสะสมต่ำที่สุดเท่ากับ 770.44 ± 257.08 และให้ผลตอบแทนสะสมสูงที่สุดเท่ากับ $1,708.94 \pm 585.40$ เมื่อเปรียบเทียบกับตัวแทนทั้งหมด แสดงให้เห็นว่าในกรณีที่มิติของคุณลักษณะมีขนาดสูงมาก การประมาณค่าความเสี่ยงด้วยแบบจำลองแบบจุดอาจเพียงพอสำหรับการสร้างนโยบายที่ให้ผลตอบแทนในด้านค่าเฉลี่ยที่ดีได้ แม้จะต้องตัดสินใจหลายรายการพร้อมกันในแต่ละรอบ

อย่างไรก็ตาม เมื่อพิจารณาความเสถียรจะพบว่าตัวแทนแบบ THS ให้ค่าเสียโอกาสสะสมเท่ากับ 849.73 ± 91.99 และให้ผลตอบแทนสะสมเท่ากับ $1,626.66 \pm 525.75$ ซึ่งแม้จะด้อยกว่าตัวแทนแบบ GRE เล็กน้อยในค่าเฉลี่ยของผลตอบแทน แต่มีความแปรปรวนของค่าเสียโอกาสสะสมต่ำกว่ามาก สะท้อนให้เห็นว่าการสุ่มพารามิเตอร์จาก Posterior สามารถลดความเสี่ยงจากกรณีเลวร้ายในบางการทดลองได้ดีกว่า

ในขณะที่ตัวแทนแบบ BBTS ให้ค่าเสียโอกาสสะสมเท่ากับ 893.54 ± 177.30 และให้ผลตอบแทนสะสมเท่ากับ $1,580.26 \pm 536.99$ ซึ่งให้ผลลัพธ์ด้อยกว่าตัวแทนแบบ THS ทั้งในแง่ของค่าเฉลี่ยและความเสถียร แสดงให้เห็นว่าการประมาณความไม่แน่นอนด้วยวิธีการบูตสแตรป์แบบเบย์มีข้อจำกัดในบริบทที่ต้องตัดสินใจหลายรายการพร้อมกัน และมีมิติของคุณลักษณะสูง

สำหรับตัวแทนแบบ GRENN ให้ผลลัพธ์แย่ที่สุดในกลุ่มโดยมีค่าเสียโอกาสสะสมสูงถึง $1,575.17 \pm 242.66$ และมีผลตอบแทนสะสมเพียง 894.82 ± 640.63 สะท้อนให้เห็นอย่างชัดเจนว่าการใช้โครงข่ายประสาทเทียมโดยไม่มีกลไกการจัดการความไม่แน่นอน ไม่สามารถรองรับความซับซ้อนของปัญหาในกรณีที่มิติของคุณลักษณะสูงและต้องเลือกผู้ผู้หลายรายการพร้อมกันได้เป็นอย่างดี

4. สรุปผล

จากผลการทดลองแสดงให้เห็นว่า ประสิทธิภาพของตัวแทนขึ้นอยู่กับทั้งมิติของคุณลักษณะและโครงสร้างของการตัดสินใจในแต่ละรอบอย่างมีนัยสำคัญ โดยเฉพาะจำนวนการเลือกผู้ผู้ต่อรอบ ซึ่งเป็นปัจจัยที่ส่งผลต่อความรุนแรงของความผิดพลาดในการตัดสินใจโดยตรง ในกรณีที่มิติของคุณลักษณะมีขนาดเล็กถึงปานกลาง (Feature vector เท่ากับ 5 และ 10) และ โดยเฉพาะอย่างยิ่งเมื่อมีการเลือกหลายรายการพร้อมกันในแต่ละรอบ พบว่าตัวแทนแบบ THS ให้ผลการเรียนรู้ที่ดีที่สุด โดยสามารถลดค่าเสียโอกาสสะสมลงได้ต่ำที่สุดและให้ผลตอบแทนสะสมสูงที่สุดอย่างสม่ำเสมอ เนื่องจาก

แบบจำลองโลจิสติกสามารถแทนความสัมพันธ์ระหว่างคุณลักษณะกับผลลัพธ์ได้อย่างเหมาะสมในระดับความซับซ้อนดังกล่าว ส่งผลให้การประมาณค่าการแจกแจงภายหลังของพารามิเตอร์มีเสถียรภาพ และกลไกการสุ่มตัวอย่างแบบทอมสัน สามารถสร้างสมดุลระหว่างการสำรวจและการแสวงประโยชน์ได้อย่างมีประสิทธิภาพ แม้ในสถานการณ์ที่ความผิดพลาดต่อหนึ่งรอบมีผลกระทบแบบกลุ่มจากการเลือกหลายรายการพร้อมกัน

ในทางตรงกันข้าม เมื่อมิติของคุณลักษณะเพิ่มสูงขึ้น (Feature vector เท่ากับ 20) แบบจำลองโลจิสติกที่ใช้วิธีการสุ่มตัวอย่างแบบทอมสัน เริ่มเผชิญข้อจำกัดด้านความสามารถในการแทนความสัมพันธ์ที่ซับซ้อนมากขึ้น ส่งผลให้การประมาณค่าการแจกแจงภายหลังของพารามิเตอร์มีความคลาดเคลื่อน และกลไกการบูตสแตรป์แบบเบย์ไม่ก่อให้เกิดประโยชน์ในด้านค่าเฉลี่ยอย่างชัดเจนอีกต่อไป โดยเฉพาะในกรณีที่เลือกผู้ผู้เพียง 1 รายต่อรอบ พบว่าตัวแทนแบบ GRE ซึ่งอาศัยค่าประมาณแบบจุดของพารามิเตอร์ให้ผลตอบแทนเฉลี่ยสูงกว่าตัวแทนที่ใช้วิธีการสุ่มตัวอย่างแบบทอมสัน สะท้อนให้เห็นว่า ในสภาพแวดล้อมที่มีมิติสูง และข้อมูลต่อพารามิเตอร์ยังมีจำกัดการตัดสินใจจากค่าประมาณแบบจุดอาจมีความเหมาะสมมากกว่าสำหรับการใช้งานในเชิงปฏิบัติ

สำหรับตัวแทนที่ใช้โครงข่ายประสาทเทียม พบว่าในทุกระดับของมิติคุณลักษณะยังไม่สามารถแสดงศักยภาพเหนือแบบจำลองโลจิสติกได้อย่างชัดเจน และยังคงให้ผลลัพธ์ด้อยกว่าตัวแทนที่ใช้วิธีการสุ่มตัวอย่างแบบทอมสันหรือแม้แต่ตัวแทนแบบ GRE ในบางกรณี

โดยสรุปงานวิจัยนี้ชี้ให้เห็นอย่างชัดเจนว่าไม่มีตัวแทนใดที่สามารถให้ผลลัพธ์ที่ดีที่สุดในทุกสถานการณ์ ประสิทธิภาพของตัวแทนขึ้นอยู่กับทั้งมิติของคุณลักษณะ จำนวนการตัดสินใจต่อรอบ และความซับซ้อนของสภาพแวดล้อมโดยรวม ในบริบทของระบบอนุมติลินเชื่อหากข้อมูลมีมิติอยู่ในระดับต่ำถึงปานกลาง และมีการคัดเลือกผู้ผู้หลายรายการในแต่ละรอบ ตัวแทนที่ใช้วิธีการสุ่มตัวอย่างแบบทอมสัน โดยเฉพาะตัวแทนแบบ THS ยังคงเป็นทางเลือกที่มีประสิทธิภาพสูง และมีความเสถียรในการควบคุมความเสี่ยงจากการตัดสินใจผิดพลาดเชิงกลุ่ม ในกรณีที่ข้อมูลมีมิติสูงและความสัมพันธ์มีความซับซ้อนมากขึ้น การใช้ตัวแทนแบบ GRE ซึ่งอาศัยค่าประมาณแบบจุดของพารามิเตอร์ให้ผลลัพธ์ที่ดีในเชิงค่าเฉลี่ย อย่างไรก็ตามการนำแนวทางการเรียนรู้แบบเสริมกำลังเชิงลึกไปประยุกต์ใช้ในระบบอนุมติลินเชื่อจริงในอนาคต จำเป็นต้องพิจารณาอย่างรอบคอบทั้งในด้านความสามารถในการแทนความสัมพันธ์ที่ซับซ้อนของข้อมูล และกลไกการประมาณความไม่แน่นอนของพารามิเตอร์ ผลการทดลองในงานวิจัยนี้แสดงให้เห็นว่าตัวแทนทั้ง 4 ตัวแม้จะสามารถแสดงประสิทธิภาพที่ดีในบางสถานการณ์ แต่ยังมีข้อจำกัดที่ชัดเจนเมื่อเผชิญกับการเปลี่ยนแปลงของมิติข้อมูล และโครงสร้างการตัดสินใจในแต่ละรอบ จึงอาจยังไม่เพียงพอสำหรับการนำไปใช้ในการอนุมติลินเชื่อจริง

อย่างไรก็ตาม งานวิจัยนี้มีข้อจำกัดที่สำคัญคือ โครงสร้างของโครงข่ายประสาทเทียมที่ใช้จำลองสภาพแวดล้อมมีพารามิเตอร์คงที่ตลอดการทดลอง (Stationary environment) ในขณะที่พฤติกรรมการณ์คิดชำระหนี้ในความเป็นจริงมักเปลี่ยนแปลงไปตามสถานะเศรษฐกิจ นโยบายการเงิน หรือปัจจัยภายนอกอื่น ๆ (Non-stationary environment) เช่น วิกฤตเศรษฐกิจ หรือการเปลี่ยนแปลงพฤติกรรมของผู้บริโภค ซึ่งอาจส่งผลกระทบต่อโครงข่ายความสัมพันธ์ระหว่างคุณลักษณะของผู้กู้กับความน่าจะเป็นในการผิดนัดชำระหนี้อย่างมีนัยสำคัญ

นอกจากนี้ การนำไปประยุกต์ใช้ยังต้องคำนึงถึงข้อกำหนดด้านกฎระเบียบและความโปร่งใสของแบบจำลอง ซึ่งล้วนเป็นปัจจัยสำคัญต่อการยอมรับ และความน่าเชื่อถือของระบบการอนุมัติสินเชื่อที่ขับเคลื่อนด้วยปัญญาประดิษฐ์

5. เอกสารอ้างอิง

- [1] Agrawal S, Goyal N. Thompson sampling for contextual bandits with linear payoffs. In: Proceedings of the 30th International Conference on Machine Learning (ICML); 2013. p. 127–135.
- [2] Auer P. Tight confidence bounds for exploitation-exploration trade-offs. *Journal of Machine Learning Research*. 002; 3:397–422.
- [3] Chapelle O, Li L. An empirical evaluation of Thompson sampling. In: Advances in Neural Information Processing Systems (NeurIPS); 2011. p. 2249–2257.
- [4] Dumitrescu B, Feng K, Engelhardt BE. Bayesian bootstrapping for uncertainty quantification in deep learning. In: Proceedings of the 35th International Conference on Machine Learning (ICML); 2018.
- [5] Goodfellow I, Bengio Y, Courville A. *Deep Learning*. Cambridge: MIT Press; 2016.
- [6] Kiatsupaibul S, Chansiripas P, Manopanasiri P, Visantavarakul K, Wen Z. Reinforcement Learning in Credit Scoring and Underwriting.; 2025.
- [7] Osband I, Blundell C, Pritzel A, Van Roy B. Deep exploration via bootstrapped DQN. In: Advances in Neural Information Processing Systems (NeurIPS); 2016. p. 4026–4034.
- [8] Rubin DB. The Bayesian bootstrap. *The Annals of Statistics*. 1981; 9(1):130–134.
- [9] Russo D, Van Roy B, Kazerouni A, Osband I, Wen Z. A tutorial on Thompson sampling. *Foundations and Trends in Machine Learning*. 2018; 11(1):1–96.
- [10] Sutton RS, Barto AG. *Reinforcement Learning: An Introduction*. 2nd ed. Cambridge: MIT Press; 2018.
- [11] Visantavarakul K. An application of reinforcement learning to credit scoring based on the logistic Bandit framework [Master's thesis]. Bangkok: Chulalongkorn University; 2022.

Loan Approval Prediction Using Machine Learning: A Comparative Analysis of Classification Algorithms

Prasin Phuthipakorn, Nathanicha Vongsing, Phusita Jirapinyo*, and Piyachat Leelasilapasart
Department of Applied Statistics, King Mongkut's University of Technology North Bangkok
(* s6504052630135@email.kmutnb.ac.th)

Abstract

Loan approval prediction is a critical process for mitigating subjective judgment bias and minimizing loan default risks. This study utilizes a public dataset from Kaggle, consisting of 614 samples and 13 features. This research presents a comparative performance analysis of machine learning models, focusing on the baseline Logistic Regression and various Ensemble Learning techniques. The investigated models include Feature Scaling Ensemble, Logistic Regression Ensemble (LORENS), Hybrid Logit Ensemble, Logit Stacking, and Stacking Ensemble. The methodology encompasses comprehensive Feature Engineering and Data Scaling to ensure data readiness. Model evaluation is conducted using key performance metrics, including Accuracy, Precision, Recall, F1-Score, and the Area Under the Receiver Operating Characteristic Curve (AUC-ROC).

The empirical results demonstrate that the Feature Scaling Ensemble model achieves the highest performance with an accuracy of 78.75% (Precision: 0.79, Recall: 0.98, F1-Score: 0.86), followed by LORENS and the baseline Logistic Regression, both yielding an accuracy of 78.33%. Furthermore, the Hybrid Logit Ensemble exhibits superior classification capability, reaching the highest ROC value of 0.766. The analysis reveals that 'Credit History', 'Loan Amount', and 'Applicant Income' are the most influential features in predicting loan approval. In conclusion, this study highlights that implementing logistic-based ensemble models significantly enhances decision-making reliability. These findings provide valuable insights for financial institutions in establishing robust credit evaluation standards and effectively reducing business risks. Moreover, the proposed framework offers scalability for data classification tasks in other complex domains.

Keywords: Loan Approval Prediction, Machine Learning, Ensemble Learning, Logistic Regression, Feature Engineering, Financial Risk Management

การวิเคราะห์และจำแนกภาวะการนอนหลับด้วยเทคนิคการเรียนรู้ของเครื่อง โดยใช้ปัจจัยด้านสุขภาพและรูปแบบการดำเนินชีวิต

Analysis and Classification of Sleep Conditions Using Machine Learning Based on Health and Lifestyle Factors

วาทินี ศรีอาวุธ* ชีมาพร จันทร์ระ พิมพ์พิสุทธิ์ ไพโรสิงห์ และ กัลยา บุญหล้า

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยขอนแก่น

(*wathinis67@nu.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการจำแนกภาวะความผิดปกติของการนอนหลับ (Sleep Disorder) โดยใช้ข้อมูลด้านสุขภาพจากชุดข้อมูล Sleep Health and Lifestyle ซึ่งประกอบด้วยตัวแปรอิสระ ได้แก่ ระยะเวลาการนอนหลับ ระดับความเครียด ระดับกิจกรรมทางกาย และอัตราการเต้นของหัวใจ ข้อมูลถูกแบ่งออกเป็นชุดข้อมูลฝึกสอนร้อยละ 80 และชุดข้อมูลทดสอบร้อยละ 20 แบบจำลองที่นำมาใช้ในการศึกษา 5 วิธี ได้แก่ การถดถอยลอจิสติก (Logistic Regression) การวิเคราะห์จำแนกกลุ่มเชิงเส้น (Linear Discriminant Analysis) ต้นไม้ตัดสินใจ (Decision Tree) เพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbors) และการจัดกลุ่มข้อมูล (Clustering) โดยประเมินประสิทธิภาพด้วยค่าความแม่นยำ (Accuracy) และอัตราความผิดพลาดในการจำแนก (Apparent Error Rate: APER) ผลการศึกษาพบว่าแบบจำลองต้นไม้ตัดสินใจมีค่าความแม่นยำสูงสุดจากชุดข้อมูลทดสอบ รองลงมาคือแบบจำลองเพื่อนบ้านที่ใกล้ที่สุดในขณะที่การถดถอยลอจิสติกและการวิเคราะห์จำแนกกลุ่มเชิงเส้นให้ค่าความแม่นยำในระดับปานกลาง ส่วนการจัดกลุ่มข้อมูล สามารถแสดงโครงสร้างของกลุ่มคุณภาพการนอนได้อย่างชัดเจน ผลลัพธ์ที่ได้แสดงให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่องสามารถนำมาใช้ในการจำแนกภาวะความผิดปกติของการนอนหลับได้อย่างมีประสิทธิภาพ และสามารถประยุกต์ใช้เป็นแนวทางในการวิเคราะห์ข้อมูลด้านสุขภาพในอนาคต

คำสำคัญ: ความผิดปกติของการนอนหลับ, ต้นไม้ตัดสินใจ, การถดถอยลอจิสติก, การวิเคราะห์จำแนกกลุ่มเชิงเส้น, เพื่อนบ้านที่ใกล้ที่สุด

การแบ่งกลุ่มลูกค้าโดยใช้แบบจำลอง RFM ร่วมกับการแบ่งกลุ่มแบบ K-Means และ DBSCAN

Customer Segmentation using RFM Model with K-Means Clustering and DBSCAN

วชิรญาณ พิภุคศรี ธนิษฐา แสงสี* ปิยะเนตร อยู่ชัง และ มนัสยา ละอองแก้ว
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(*s6504053630082@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ในการจัดกลุ่มลูกค้า (Customer Clustering) โดยทำการเก็บรวบรวม วิเคราะห์ และประมวลผลผ่านกระบวนการมาตรฐานสำหรับการทำเหมืองข้อมูล (Cross-Industry Standard Process for Data Mining) พร้อมทั้งสร้างแบบจำลอง RFM ซึ่งเป็นเทคนิคที่ใช้ในการวิเคราะห์พฤติกรรมของลูกค้า โดยมุ่งเน้นการจำแนกกลุ่มลูกค้าที่มีลักษณะคล้ายคลึงกัน ใน 3 ด้านหลัก ได้แก่ ระยะเวลาที่นับจากวันที่ใช้บริการล่าสุด (Recency) ความถี่ของการใช้บริการ (Frequency) และมูลค่าการใช้บริการ (Monetary) งานวิจัยนี้นำข้อมูลธุรกรรม การสั่งซื้อสินค้าทางออนไลน์ ในปี ค.ศ. 2022 ถึงปี ค.ศ. 2025 จากแหล่งข้อมูล Kaggle จำนวน 10,000 รายการ ภายหลังจากคัดกรองข้อมูลเฉพาะคำสั่งซื้อที่สมบูรณ์ และรวมข้อมูลในระดับลูกค้า ทำให้มีจำนวนลูกค้าที่ไม่ซ้ำกัน 2,790 รายสำหรับการวิเคราะห์ โดยใช้การวิเคราะห์ RFM ร่วมกับการแบ่งกลุ่มแบบ K-means การแบ่งกลุ่มแบบ DBSCAN และใช้ Python เป็นเครื่องมือในการวิเคราะห์ การเปรียบเทียบประสิทธิภาพจะใช้ Silhouette Score เป็นเกณฑ์ ผลการศึกษา พบว่าการแบ่งกลุ่มแบบ K-Means ให้ค่า Silhouette Score ที่สูงกว่าแบบ DBSCAN อยู่ที่ 0.4159 และสามารถแยกลูกค้าแต่ละกลุ่มออกจากกันได้อย่างชัดเจน โดยแบ่งกลุ่มลูกค้าจำนวน 2,790 ราย ออกเป็น 3 กลุ่ม ได้แก่ กลุ่มลูกค้าที่เลิกซื้อไปแล้ว กลุ่มลูกค้าเก่าที่มีมูลค่าสูง และกลุ่มลูกค้าที่มีแนวโน้มว่าจะพัฒนาเป็นลูกค้าประจำได้ คิดเป็นสัดส่วน 57.42%, 30.90%, และ 11.68% ตามลำดับ ซึ่งสามารถนำไปประยุกต์ใช้ในการกำหนดกลยุทธ์การรักษาลูกค้า การกระตุ้นการซื้อซ้ำ และการพัฒนากลุ่มลูกค้าเป้าหมายได้อย่างมีประสิทธิภาพ

คำสำคัญ: K-means Clustering, DBSCAN, RFM Model

การศึกษาเปรียบเทียบประสิทธิภาพของวิธีอนุกรมเวลาและเทคนิคการเรียนรู้ของเครื่องในการพยากรณ์จำนวนอุบัติเหตุทางถนนในระดับภูมิภาคของประเทศไทย

A Comparative Study of the Performance of Time Series Methods and Machine Learning Techniques for Forecasting Road Traffic Accidents at the Regional Level in Thailand

กัญญาภัค อินทอม* กมลทิพย์ พันธุ์สระคู และ คลฤดี โพธิมณี

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระจอมเกล้าพระนครเหนือ
(*s6504052630011@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาหาตัวแบบการพยากรณ์ที่เหมาะสมและเปรียบเทียบประสิทธิภาพตัวแบบการพยากรณ์จำนวนการเกิดอุบัติเหตุทางถนนในระดับภูมิภาคของประเทศไทยทั้ง 6 ภูมิภาค ได้แก่ ภาคเหนือ ภาคใต้ ภาคกลาง ภาคตะวันตก ภาคตะวันออก และภาคตะวันออกเฉียงเหนือ โดยใช้ข้อมูลที่ใช้ในการวิจัยคือข้อมูลจำนวนอุบัติเหตุทางถนน ตั้งแต่เดือนมกราคม พ.ศ.2563 ถึงธันวาคม พ.ศ.2568 เป็นรายเดือนรวมทั้งสิ้น 72 เดือน โดยใช้ข้อมูลจากหน่วยงานภายใต้การกำกับดูแลของกระทรวงคมนาคม โดยแบ่งเป็น 2 ส่วน ได้แก่ ชุดข้อมูลฝึกฝน (Training dataset) ตั้งแต่เดือนมกราคม พ.ศ.2563 ถึงธันวาคม พ.ศ.2567 เป็นรายเดือนรวมทั้งสิ้น 60 เดือน และชุดข้อมูลทดสอบ (Testing dataset) ตั้งแต่เดือนมกราคม ถึงธันวาคม พ.ศ.2568 เป็นรายเดือนรวมทั้งสิ้น 12 เดือนเพื่อสร้างและประเมินตัวแบบการพยากรณ์ โดยวิธีพยากรณ์ที่ศึกษาแบ่งออกเป็น 2 กลุ่ม คือ วิธีการพยากรณ์อนุกรมเวลาทางสถิติ 6 วิธี ได้แก่ ตัวแบบการถดถอยเชิงเส้นสำหรับอนุกรมเวลา (Time Series Linear Regression: TLM) ตัวแบบการถดถอยเชิงจำนวนแบบปัวซองสำหรับอนุกรมเวลา (Time Series Poisson Regression: TPM) ตัวแบบการถดถอยเชิงจำนวนแบบทวินามลบสำหรับอนุกรมเวลา (Time Series Negative Binomial Regression: TNBM) ตัวแบบการปรับให้เรียบแบบเลขชี้กำลังทั้งแบบบวกและแบบคูณ (Additive and Multiplicative Exponential Smoothing: ASM และ MSM) และตัวแบบบ็อกซ์-เจนกินส์ (Box-Jenkins) เปรียบเทียบกับเทคนิคการเรียนรู้ของเครื่อง 3 วิธี ได้แก่ ต้นไม้ตัดสินใจ (Decision Tree: DT) ป่าสุ่ม (Random Forest: RF) และเอกซ์จีบูสต์ (Extreme Gradient Boosting: XGBoost) เปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์ ได้แก่ ค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Scaled Error: MASE) ความคลาดเคลื่อนเฉลี่ยแบบค่าสัมบูรณ์ (Mean Absolute Error: MAE) และรากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ผลการวิจัยพบว่า ตัวแบบที่เหมาะสมสำหรับการพยากรณ์จำนวนอุบัติเหตุทางถนนในประเทศไทยในระดับภูมิภาคทั้ง 6 ภูมิภาค ได้แก่ SARIMA(1,0,1)(1,1,0)₁₂, TPM, ASM, TPM, TPM และ RF ตามลำดับ

คำสำคัญ: ตัวแบบอนุกรมเวลา, ตัวแบบเชิงจำนวน, การเรียนรู้ของเครื่อง, ตัวแบบข้อมูลนับ

การพยากรณ์ผลตอบแทนหุ้น S&P 500 ด้วยการเรียนรู้ของเครื่องและปัจจัยเศรษฐกิจมหภาค

Stock Return Prediction of S&P 500

Using Machine Learning with Macroeconomic Indicators

บัญชา หงษ์บุตร* เบญญาภา พิภสวัสดิ์ สุทธิภัทร จำเริญดี และ เพ็ชรพล กมลจิตรประภา
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(*s6504051620101@email.kmutnb.ac.th)

บทคัดย่อ

ดัชนีราคาหุ้นเอสแอนด์พี 500 เป็นดัชนีที่ใช้วัดการเคลื่อนไหวของราคาหุ้นบริษัทขนาดใหญ่ในตลาดหลักทรัพย์สหรัฐอเมริกาและมักใช้เป็นตัวชี้วัดภาวะตลาดทุนและแนวโน้มกิจกรรมทางเศรษฐกิจโดยรวม งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาความสามารถในการพยากรณ์ทิศทางและการเปลี่ยนแปลงผลตอบแทนของดัชนีดังกล่าว โดยประยุกต์ใช้วิธีการเรียนรู้ของเครื่องร่วมกับตัวแปรเศรษฐกิจมหภาค ข้อมูลที่ใช้ในการศึกษารอบคลุมช่วงปี พ.ศ. 2543 ถึง พ.ศ. 2567 ประกอบด้วยข้อมูลราคาปิดรายวันของดัชนีเอสแอนด์พี 500 และตัวแปรเศรษฐกิจมหภาค ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกาอายุ 10 ปี โครงสร้างอัตราผลตอบแทน ดัชนีความผันผวนของตลาด และส่วนต่างผลตอบแทนตราสารหนี้ภาคเอกชน การศึกษานี้เปรียบเทียบประสิทธิภาพของแบบจำลอง ได้แก่ แบบจำลองการถดถอยโลจิสติก (Logistic Regression) และแบบจำลองการเรียนรู้ของเครื่อง ได้แก่ แบบจำลองป่าสุ่ม (Random Forest) แบบจำลองเอ็กซ์ตรีมกราดิเอนต์บูสตีง (Extreme Gradient Boosting: XGBoost) และแบบจำลองไลต์กราดิเอนต์บูสตีงแมชชีน (Light Gradient Boosting Machine: LightGBM) ในการพยากรณ์ทิศทางตลาดล่วงหน้า 1 เดือน โดยใช้วิธีการตรวจสอบไขว้สำหรับข้อมูลอนุกรมเวลา (Time Series Cross-Validation) และประเมินผลด้วยตัวชี้วัด ได้แก่ ค่าความถูกต้องรวม (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และ พื้นที่ใต้เส้นโค้ง (AUC) ผลการศึกษาพบว่าแบบจำลอง Random Forest มีประสิทธิภาพโดยรวมสูงสุด โดยให้ค่า Accuracy เท่ากับ 0.6255, ค่า Precision เท่ากับ 0.6310, ค่า Recall สำหรับกลุ่มที่ให้ผลตอบแทนเป็นบวกเท่ากับ 0.80 และค่า AUC เท่ากับ 0.6459 ซึ่งให้ผลการพยากรณ์ที่ดีกว่าแบบจำลอง Logistic Regression ที่ใช้เป็นแบบจำลองฐาน (Baseline Model) แสดงให้เห็นว่าวิธีการเรียนรู้ของเครื่องสามารถให้ประสิทธิภาพในการพยากรณ์ที่ดีกว่าแบบจำลอง Logistic Regression ซึ่งใช้เป็นแบบจำลองฐาน (Baseline Model) และมีค่าสูงกว่าระดับการทำนายแบบสุ่ม (Random Baseline) แสดงให้เห็นว่าแบบจำลองมีความสามารถในการจับสัญญาณทิศทางของการเคลื่อนไหวของตลาดได้ดี

คำสำคัญ: ดัชนีราคาหุ้นเอสแอนด์พี 500, การพยากรณ์ผลตอบแทนหุ้น, การเรียนรู้ของเครื่อง, ตัวชี้วัดเศรษฐกิจมหภาค, การวิเคราะห์อนุกรมเวลา

แพลตฟอร์มการเรียนรู้และการสอบดิจิทัล สาขาเทคโนโลยีธุรกิจดิจิทัล (ต่อเนื่อง)

วิทยาลัยอาชีวศึกษาชลบุรี

Digital Learning and Examination Platform, Digital Business Technology Program

(Continuing), Chonburi Vocational College

นุชจรีย์ ลุงพนธ์

สาขาวิชาเทคโนโลยีธุรกิจดิจิทัล (ต่อเนื่อง) วิทยาลัยอาชีวศึกษาชลบุรี สถาบันการอาชีวศึกษาภาคตะวันออกเฉียงเหนือ

(*nutjareelungpon096@gmail.com)

บทคัดย่อ

การศึกษาวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ (1) ศึกษาสภาพปัญหาและแนวทางการจัดการเรียนการสอนในระบบเดิม (2) พัฒนาแพลตฟอร์มการเรียนรู้และการสอบดิจิทัลสาขาวิชาเทคโนโลยีธุรกิจดิจิทัล (ต่อเนื่อง) วิทยาลัยอาชีวศึกษาชลบุรี และ (3) ประเมินความพึงพอใจของผู้ใช้งานที่มีต่อระบบที่พัฒนาขึ้น กลุ่มตัวอย่างที่ใช้ในการประเมินประสิทธิภาพ ได้แก่ นักศึกษาระดับปริญญาตรี (ต่อเนื่อง) ปีที่ 1-2 จำนวน 15 คน และอาจารย์ 6 คน จำนวน 17 คน เครื่องมือที่ใช้ในการวิจัยประกอบด้วย แพลตฟอร์มการเรียนรู้ดิจิทัล ที่พัฒนาโดยใช้ภาษา PHP และจัดการฐานข้อมูลด้วย MySQL โดยใช้เครื่องมือสนับสนุนอย่าง Visual Studio Code และ XAMPP ในการดำเนินงาน และแบบประเมินความพึงพอใจ สถิติที่ใช้ในการวิเคราะห์ข้อมูล ได้แก่ ค่าเฉลี่ย (\bar{X}) ส่วนเบี่ยงเบนมาตรฐาน (S.D.) และค่าสัมประสิทธิ์ความแปรผัน (C.V.) ไม่เกิน 15%

ผลการวิจัยพบว่า 1 ด้านการพัฒนาเครื่องมือ พบว่าวิทยาลัยขาดแพลตฟอร์มการจัดการศึกษาที่เป็นระบบและครบวงจร ส่งผลให้การบริหารจัดการหลักสูตรและการติดตามความก้าวหน้าของผู้เรียนขาดประสิทธิภาพ พบว่าวิทยาลัยขาดแพลตฟอร์มการจัดการศึกษาที่เป็นระบบและครบวงจร ส่งผลให้การบริหารจัดการหลักสูตรและการติดตามความก้าวหน้าของผู้เรียนขาดประสิทธิภาพ ผู้วิจัยจึงได้พัฒนาแพลตฟอร์มที่รองรับการใช้งาน 3 ส่วนหลัก ได้แก่ (1) ผู้ดูแลระบบ สามารถจัดการหลักสูตรและดูแลความปลอดภัยของระบบ (2) อาจารย์ สามารถจัดการเนื้อหา สร้างชุดข้อสอบ และติดตามความก้าวหน้าของผู้เรียน และ (3) นักศึกษา สามารถเข้าถึงบทเรียน ทำแบบทดสอบก่อน-หลังเรียน และตรวจสอบผลการเรียนของตนเองได้ ซึ่งช่วยลดภาระงานเอกสารและส่งเสริมการเรียนรู้ด้วยตนเอง และ 2. ด้านความพึงพอใจของผู้ใช้งาน ในภาพรวมพบว่าผู้ใช้งานมีความพึงพอใจต่อแพลตฟอร์มที่พัฒนาขึ้น ในด้านการออกแบบและประสบการณ์ผู้ใช้งาน (UX/UI) มีผลการประเมินอยู่ในระดับดี ($\bar{X}=4.27$, C.V. = 3.70%) ส่วนด้านการส่งเสริมการเรียนการสอนมีค่าเฉลี่ยเท่ากับ 3.66 (C.V. = 2.13%) และด้านประสิทธิภาพของระบบมีค่าเฉลี่ยเท่ากับ 3.50 (C.V. = 2.83%) ถือว่าอยู่ในระดับดีเช่นกัน และมีค่าสัมประสิทธิ์ความแปรผันอยู่ในเกณฑ์ที่ต่ำทุกกรณี

ข้อเสนอแนะจากการวิจัยครั้งนี้คือ ควรมีการพัฒนาเพิ่มเติมในส่วนของฟีเจอร์การบล็อกการออกจากหน้าจอขณะทำข้อสอบเพื่อป้องกันการทุจริต ผู้วิจัยได้มีการนำ Fullscreen API มาใช้ โดยระบบจะบังคับให้ทำข้อสอบเต็มหน้าจอ หากผู้สอบออกจากหน้าจอเกิน 3 ครั้ง ระบบจะส่งคำตอบทันทีและไม่อนุญาตให้ทำข้อสอบต่อ รวมถึงการเพิ่มระบบรายงานสรุปผลภาพรวม (Dashboard) และแถบแสดงความก้าวหน้า (Progress Bar) ของแต่ละหลักสูตรให้มีความละเอียดชัดเจนยิ่งขึ้น ส่งผลให้การยกระดับและพัฒนาหลักสูตรมีความเป็นระบบและมีประสิทธิภาพสูงสุดอย่างแท้จริง

คำสำคัญ: แพลตฟอร์มการเรียนรู้ดิจิทัล, ระบบสอบออนไลน์, เทคโนโลยีธุรกิจดิจิทัล, วิทยาลัยอาชีวศึกษาชลบุรี

การแบ่งส่วนภาพเยื่อแก้วหูจากภาพอโสตโคปโดยใช้โมเดลการเรียนรู้เชิงลึก

Tympanic Membrane Segmentation from Otoscope Images

Using Deep Learning

ธนีสร สมรูป* และ ชนนิกันต์ รอดมรณ

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504053620061@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก (Deep Learning) สำหรับการแบ่งส่วนเยื่อแก้วหูจากภาพถ่ายกล้องอโสตโคป (Otoscope) เพื่อสนับสนุนการวินิจฉัยโรคหูชั้นกลางอักเสบในงานทางการแพทย์ โดยทำการศึกษาเปรียบเทียบโมเดลจำนวน 4 สถาปัตยกรรม ได้แก่ U-Net, TransU-Net, TransU-Net (ResNet50) และ TransU-Net (EfficientNetB0) ชุดข้อมูลที่ใช้ประกอบด้วยภาพถ่ายเยื่อแก้วหูจำนวน 327 ภาพ โดยแบ่งการทดลองออกเป็นสองกรณี คือ การใช้ชุดข้อมูลต้นฉบับ และการใช้ชุดข้อมูลที่ผ่านกระบวนการเพิ่มปริมาณข้อมูล (Data Augmentation) ประสิทธิภาพของโมเดลถูกประเมินด้วยตัวชี้วัด Intersection over Union (IoU) และ Dice Similarity Coefficient (DSC) ผลการทดลองพบว่าการใช้เทคนิค Data Augmentation สามารถช่วยเพิ่มประสิทธิภาพของโมเดลทุกสถาปัตยกรรม โดยโมเดล TransU-Net ที่ใช้ EfficientNetB0 ร่วมกับชุดข้อมูลที่ผ่านการทำ Augmentation ให้ผลการทำนายดีที่สุด โดยมีค่า IoU เฉลี่ยร้อยละ 85.07 และค่า DSC เฉลี่ยร้อยละ 91.72 ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าสถาปัตยกรรมแบบผสมระหว่าง Convolutional Neural Network และ Transformer สามารถดึงคุณลักษณะของเยื่อแก้วหูได้อย่างมีประสิทธิภาพ และมีศักยภาพในการพัฒนาเป็นระบบช่วยวินิจฉัยทางการแพทย์ในอนาคต

คำสำคัญ: การแบ่งส่วนภาพ, เยื่อแก้วหู, การเรียนรู้เชิงลึก, TransU-Net, EfficientNetB0

การพัฒนาระบบแจ้งและติดตามการแก้ไขข้อบกพร่องงานก่อสร้างพร้อมแดชบอร์ด

วิเคราะห์ประสิทธิภาพโครงการ

Development of Construction Defect Notification and Tracking System

with Project Performance Analysis Dashboard

นาย ปิยวัช ชันธนิตเสน* และ ชนิกานต์ รอดมรณ
ภาควิชาสถิติประยุกต์ มหาวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(*s6504053620109@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบบริหารจัดการกระบวนการแจ้งและติดตามการแก้ไขข้อบกพร่อง (Corrective Action Request: CAR) ในงานก่อสร้าง รวมถึงพัฒนาแดชบอร์ดสำหรับวิเคราะห์ประสิทธิภาพโครงการของบริษัท ปรีณศิริ จำกัด (มหาชน) เนื่องจากกระบวนการทำงานเดิมประสบปัญหาความล่าช้าในการสื่อสาร ข้อมูลกระจัดกระจาย และขาดระบบติดตามสถานะงานอย่างเป็นระบบ ส่งผลให้การบริหารจัดการงานที่ล่าช้ากว่ากำหนดทำได้ยาก ในการศึกษาวิจัยได้พัฒนาระบบ “PrimCAR” ซึ่งเป็นแอปพลิเคชันสำหรับบันทึกและติดตามสถานะการแก้ไขข้อบกพร่องในงานก่อสร้าง โดยประยุกต์ใช้แพลตฟอร์มโลว์โค้ด (Low-code platform) อย่าง AppSheet ในการพัฒนาระบบหน้าบ้าน จัดเก็บข้อมูลผ่าน Google BigQuery และแสดงผลการวิเคราะห์ข้อมูลด้วย Looker Studio ระบบรองรับการทำงานของผู้ใช้งาน 3 กลุ่มหลัก ได้แก่ ฝ่ายควบคุมคุณภาพ (QC) วิศวกรโครงการ (SE) และผู้จัดการโครงการ (PM) โดยช่วยกำหนดขั้นตอนการทำงานให้มีความชัดเจน สามารถติดตามสถานะการดำเนินงานได้อย่างต่อเนื่อง และลดปัญหางานตกค้างจากการขาดการติดตาม ผลการดำเนินงานพบว่าระบบสามารถเพิ่มประสิทธิภาพในการติดตามงาน โดยสามารถจัดขั้นตอนการบันทึกข้อมูลซ้ำซ้อน (Double Data Entry) ลงได้อย่างสมบูรณ์ ลดระยะเวลาในการจัดทำรายงานสรุปข้อมูลได้มากกว่าร้อยละ 90 ผ่านการแสดงผลแบบทันที (Real-time) และสามารถทดแทนการใช้เอกสารกระดาษในกระบวนการแจ้งซ่อมได้อย่างเป็นรูปธรรม นอกจากนี้ข้อมูลที่ได้จากการใช้งานระบบยังสามารถนำมาวิเคราะห์และนำเสนอในรูปแบบแดชบอร์ด เพื่อสนับสนุนการตัดสินใจของผู้บริหารในการประเมินประสิทธิภาพโครงการ และใช้เป็นข้อมูลในการปรับปรุงคุณภาพงานก่อสร้างในระยะยาว

คำสำคัญ: การจัดการข้อบกพร่องงานก่อสร้าง, แดชบอร์ด, แพลตฟอร์มโลว์โค้ด, AppSheet, Corrective Action Request (CAR)

**การพยากรณ์ปริมาณของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5)
ในเขตปทุมวัน กรุงเทพมหานคร ด้วยวิธีการทางสถิติและการเรียนรู้ของเครื่อง
Predictive Modeling of PM2.5 Levels in Pathum Wan, Bangkok:
A Comparative Study of Statistical and Machine Learning Approaches**

กิตติพัฒน์ กัณหา ภัคพล มาเลิศ ฐิตินัย วิจิตรสาร* และสอาด นิวิศพงษ์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504052630054@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อหาวิธีการพยากรณ์ที่เหมาะสม สำหรับข้อมูลปริมาณฝุ่น PM2.5 ที่รวบรวมจาก สถานีบริเวณริมถนนพระรามสี่ แขวงปทุมวัน เขตปทุมวัน กรุงเทพมหานคร โดยใช้วิธีการพยากรณ์ทางสถิติ 3 วิธี ได้แก่ วิธีการปรับให้เรียบแบบวินเทอร์สชนิดบวก (Winter Additive), วิธีการถดถอยอนุกรมเวลา (Timeseries regression) และวิธีบ็อกซ์-เจนกินส์ (Box-Jenkins) และเทคนิคการเรียนรู้ของเครื่อง 3 วิธี ได้แก่ เทคนิคต้นไม้การตัดสินใจ (Decision Tree), เทคนิคป่าสุ่ม(Random Forest) และเทคนิคการชัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) โดยข้อมูลในการศึกษานี้เป็นข้อมูลทุติยภูมิจากเว็บไซต์ Air4thai โดยแบ่งเป็น การทำโมเดล (train set) ตั้งแต่เดือนมกราคม 2019- ธันวาคม 2024 รวมทั้งสิ้น 72 เดือน ต่อมาได้ทำการพยากรณ์ (test set) ในปี 2025 เพื่อ ประเมินความสามารถของตัวแบบที่ได้ เหนือกว่าที่ใช้ในการเปรียบเทียบตัวแบบการพยากรณ์พิจารณาจากค่าร้อยละ ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) โดยตัวแบบที่ให้ค่า MAPE ต่ำที่สุดจะเป็นตัวแบบที่เหมาะสมจากผล การศึกษาพบว่า วิธีการปรับให้เรียบแบบวินเทอร์สชนิดบวก (Winter Additive) โดยมีค่า MAPE อยู่ที่ 19.6548 เป็น วิธีการพยากรณ์ที่เหมาะสมกับข้อมูลปริมาณฝุ่น PM2.5 ในแขวงปทุมวัน เขตปทุมวัน กรุงเทพมหานครมากที่สุด โดย ให้ค่า MAPE ต่ำที่สุด ดังนั้น เทคนิคนี้จึงเป็นแนวทางที่มีประสิทธิภาพสำหรับการพยากรณ์ข้อมูลปริมาณฝุ่น PM2.5 ในแขวงปทุมวัน เขตปทุมวัน กรุงเทพมหานคร

คำสำคัญ: PM2.5 (ฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน), Time Series Forecasting (การพยากรณ์อนุกรม เวลา), Winter's Additive Method (วิธีการปรับให้เรียบแบบวินเทอร์สชนิดบวก), Box-Jenkins Method / ARIMA (วิธี บ็อกซ์-เจนกินส์), Timeseries Regression (การถดถอยอนุกรมเวลา), Machine Learning (การเรียนรู้ของเครื่อง), Random Forest (เทคนิคป่าสุ่ม), Support Vector Machine / SVM (เทคนิคชัพพอร์ตเวกเตอร์แมชชีน), Decision Tree (เทคนิคต้นไม้การตัดสินใจ)

การเปรียบเทียบวิธีการพยากรณ์สำหรับจำนวนการเกิดของประชากรในประเทศไทย

A Comparison of Forecasting Methods for the Number of Births in Thailand

ปัฐพร วีระไวทยะ ชญาดา ชูกะนันท์* มาริสา มั่นอำ และ กชพร การุณ

ภาควิชา คณิตศาสตร์ คณะ วิทยาศาสตร์ มหาวิทยาลัยนเรศวร

(*E-mail: chayadac66@nu.ac.th)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อสร้างตัวแบบที่เหมาะสมสำหรับการพยากรณ์จำนวนการเกิดของประชากรในประเทศไทย โดยใช้วิธีแยกตัวประกอบ วิธีบอซซ์-เจนกินส์ และวิธีการพยากรณ์รวม 2 วิธี ได้แก่ วิธีการให้น้ำหนักที่เท่ากันและวิธีการถ่วงน้ำหนักด้วยการผกผันของรากที่สองของผลรวมความคลาดเคลื่อนกำลังสอง ข้อมูลที่ใช้ในการพยากรณ์ได้จากเว็บไซต์ของกรมการปกครอง ตั้งแต่ เดือนมกราคม พ.ศ.2557 ถึงเดือนธันวาคม พ.ศ.2568 จำนวน 144 เดือน เพื่อเปรียบเทียบประสิทธิภาพของแต่ละวิธีในการพยากรณ์ จึงได้แบ่งข้อมูลออกเป็น 2 ชุด โดยชุดที่ 1 ตั้งแต่เดือนมกราคม พ.ศ.2557 ถึง เดือนธันวาคม พ.ศ.2567 จำนวน 132 เดือน สำหรับการสร้างตัวแบบพยากรณ์ และ ชุดที่ 2 ตั้งแต่เดือนมกราคม พ.ศ.2568 ถึง เดือนธันวาคม พ.ศ.2568 จำนวน 12 เดือน สำหรับการตรวจสอบความแม่นยำของตัวแบบพยากรณ์ โดยใช้เกณฑ์ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) และค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง (RMSE) ที่ต่ำสุดเพื่อเลือกใช้วิธีการพยากรณ์ ผลการศึกษาพบว่าวิธีการพยากรณ์รวมให้ความแม่นยำสูงกว่าวิธีการพยากรณ์แบบเดี่ยว โดยให้ค่า MAPE เท่ากับ 7.5142 และค่า RMSE เท่ากับ 2973.8656 เนื่องจากสามารถผสมผสานจุดเด่นของตัวแบบพยากรณ์หลายรูปแบบและช่วยลดอคติของตัวแบบ ส่งผลให้ค่าพยากรณ์มีความเสถียรและแม่นยำมากยิ่งขึ้น นอกจากนี้ ในช่วงการระบาดของ COVID-19 อาจส่งผลให้ข้อมูลเกิดการเปลี่ยนแปลงเชิงโครงสร้าง (structural break) ซึ่งอาจมีผลต่อความแม่นยำของการพยากรณ์ได้

คำสำคัญ: วิธีการแยกตัวประกอบ, วิธีบอซซ์-เจนกินส์, วิธีการพยากรณ์รวม, ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย, ค่ารากที่สองของค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง

การวิเคราะห์ความชุกและปัจจัยที่ส่งผลต่อการเสียชีวิตบนถนนในประเทศไทย

Prevalence and factors associated with road traffic accident fatalities in Thailand

จิราภรณ์ ตุ่มวงษา* วรรณิษา ยินดีฉัตร เพ็ชรชรัตน์ มานิต และกอบกุล รวีสวัสดิ์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(*s6504052610011@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาหาความชุกและปัจจัยที่ส่งผลต่อการเสียชีวิตจากอุบัติเหตุบนถนนในประเทศไทย โดยใช้ข้อมูลทุติยภูมิจากรายงานสถิติอุบัติเหตุบนถนนของสำนักงานปลัดกระทรวงคมนาคมระหว่างปี พ.ศ.2563 – พ.ศ.2568 โดยการวิเคราะห์การถดถอยโลจิสติกแบบทวิภาค และการทดสอบไคกำลังสอง กำหนดระดับนัยสำคัญทางสถิติที่ 0.05 และใช้โปรแกรมสำเร็จรูปทางสถิติ IBM SPSS Statistics ในการวิเคราะห์ข้อมูล ผลการศึกษาพบว่าความชุกของการเกิดอุบัติเหตุบนถนน เท่ากับ 12.9% และปัจจัยด้านบุคคล ปัจจัยด้านยานพาหนะ ปัจจัยด้านพื้นที่และปัจจัยด้านสิ่งแวดล้อม มีความสัมพันธ์กับการเสียชีวิตจากอุบัติเหตุทางถนนอย่างมีนัยสำคัญทางสถิติ จากผลการศึกษาปัจจัยที่ส่งผลต่อการเสียชีวิตจากอุบัติเหตุบนถนนในประเทศไทยโดยแบ่งเป็น ปัจจัยด้านบุคคล ปัจจัยที่มีความสัมพันธ์ ได้แก่ การไม่ให้สัญญาณชะลอหรือเลี้ยว หยุดหรือเบรกกะทันหัน และการใช้โทรศัพท์ขณะขับรถ ปัจจัยด้านยานพาหนะ ปัจจัยที่มีความสัมพันธ์ ได้แก่ รถเสียไม่แสดงเครื่องหมายหรือสัญญาณตามที่กำหนด ปัจจัยด้านพื้นที่ ปัจจัยที่มีความสัมพันธ์ ได้แก่ ถนนและผิวถนนสภาพแยะหรือชำรุด และปัจจัยด้านสิ่งแวดล้อม ปัจจัยที่มีความสัมพันธ์ ได้แก่ การมีสิ่งกีดขวางบนถนนและแสงสว่างไม่เพียงพอ โดยพิจารณาจากค่า p-value น้อยกว่า 0.001 จากงานวิจัยสรุปได้ว่าการลดการเสียชีวิตจาก อุบัติเหตุบนถนนควรให้ความสำคัญกับการปรับเปลี่ยนพฤติกรรมของผู้ใช้รถใช้ถนนควบคู่กับการพัฒนามาตรการด้านความปลอดภัยของยานพาหนะ การปรับปรุงสภาพถนน และการจัดการสิ่งแวดล้อมให้เอื้อต่อความปลอดภัย ซึ่งจะช่วยลดความสูญเสียทั้งในด้านชีวิต ทรัพย์สินและ ภาระค่าใช้จ่ายจากอุบัติเหตุทางถนนในระยะยาว

คำสำคัญ: ความชุก การวิเคราะห์การถดถอยโลจิสติกแบบทวิภาค การทดสอบไคกำลังสอง

**การเปรียบเทียบประสิทธิภาพตัวแบบ ARIMA และตัวแบบการถดถอยพหุคูณ
ในการพยากรณ์ยอดจดทะเบียนรถยนต์ไฟฟ้าในประเทศไทย
A Comparative Study of ARIMA and Multiple Regression Models
for Forecasting Electric Vehicle Registrations in Thailand**

พิมพ์รดา พ่วงพี* ภัทรพร สุวัจนน กรณิกา เทศอยู่ และ คณิดา เพ็ชรรัตน์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504052610096@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์อนุกรมเวลา 2 รูปแบบ ได้แก่แบบจำลอง ARIMA และแบบจำลองการถดถอยพหุคูณ (Multiple Regression) สำหรับการพยากรณ์จำนวนยอดจดทะเบียนรถยนต์ไฟฟ้า (EV) ในประเทศไทยโดยใช้ข้อมูลรายเดือนจำนวน 72 เดือน โดยข้อมูลถูกแบ่งเป็น 2 ส่วน ได้แก่ ชุดข้อมูลสำหรับสร้างแบบจำลอง (Training Set) ตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึง เดือนมิถุนายน พ.ศ. 2568 และชุดข้อมูลสำหรับทดสอบความแม่นยำ (Testing Set) ตั้งแต่เดือนกรกฎาคม พ.ศ. 2568 ถึง เดือนธันวาคม พ.ศ. 2568 การประเมินประสิทธิภาพของแบบจำลองพิจารณาจากค่า Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE) และ Mean Absolute Error (MAE) ผลการศึกษาพบว่า เมื่อพิจารณาจากค่า MAPE ตัวแบบจำลองการถดถอยพหุคูณ ให้ค่า MAPE ต่ำที่สุด เท่ากับ ร้อยละ 2.85 ขณะที่แบบจำลอง ARIMA มีค่า MAPE ร้อยละ 2.90 อย่างไรก็ตาม เมื่อพิจารณาจากค่า MAE และ RMSE พบว่าแบบจำลอง ARIMA ให้ค่า MAE เท่ากับ 0.039 และ RMSE เท่ากับ 0.108 ในขณะที่แบบจำลองถดถอยพหุคูณมีค่า MAE เท่ากับ 0.045 และ RMSE เท่ากับ 0.11 ดังนั้นการเลือกใช้แบบจำลองขึ้นอยู่กับวัตถุประสงค์ของการนำไปใช้งาน หากต้องการแบบจำลองที่มีความเสถียรในการพยากรณ์ แบบจำลอง ARIMA อาจมีความเหมาะสมมากกว่า ผลการวิจัยนี้สามารถนำไปใช้เป็นข้อมูลสนับสนุนในการวางแผนเชิงกลยุทธ์ด้านพลังงาน และอุตสาหกรรมยานยนต์ไฟฟ้าของประเทศไทยในอนาคต

คำสำคัญ: Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE),
ตัวแบบอาร์มา (ARIMA), การถดถอย (Regression)

การวัดประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ ด้วยแผนภูมิ PWMA

The Effectiveness of Detecting Changes in Process Mean Values Using PWMA chart

ปิยะจักษณ์ ชุมขุน* กำภูภุช ศรีวิเศษ และ ชนาธิป ทองเข้ม
คณะวิทยาศาสตร์ประยุกต์ ภาควิชาสถิติประยุกต์มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504053630031@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการระหว่างแผนภูมิควบคุม Shewhart แผนภูมิควบคุม Exponentially Weighted Moving Average: EWMA แผนภูมิควบคุม Homogeneously Weighted Moving Average : HWMA และแผนภูมิควบคุม Partitioned Weighted Moving Average : PWMA การศึกษานี้พิจารณาภายใต้สภาวะที่ข้อมูลมีการแจกแจงทั้งแบบสมมาตร ได้แก่ การแจกแจงปกติและการแจกแจงลาปลาซ และแบบไม่สมมาตร ได้แก่ การแจกแจงแบบเลขชี้กำลังและการแจกแจงแกมมา เพื่อใช้ตรวจจับการเปลี่ยนแปลงเล็กน้อยในค่าเฉลี่ยของกระบวนการ โดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length : ARL) ส่วนเบี่ยงเบนมาตรฐานของความยาวรัน (Standard Deviation of Run Length : SDRL) เป็นเกณฑ์ในการวัดประสิทธิภาพ ผลการวิจัยแสดงให้เห็นว่าแผนภูมิควบคุม PWMA มีประสิทธิภาพในการตรวจจับที่ดีกว่าแผนภูมิควบคุม Shewhart, EWMA และ HWMA ในทุกกรณีของการแจกแจงที่ทำการศึกษา โดยเฉพาะอย่างยิ่งเมื่อระดับการเปลี่ยนแปลงของค่าเฉลี่ยอยู่ในระดับเล็กน้อย ผลจากการศึกษาจึงสรุปได้ว่าแผนภูมิ PWMA เป็นแผนภูมิที่มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงได้ดีที่สุดในขอบเขตการศึกษานี้

คำสำคัญ: แผนภูมิควบคุม, การแจกแจงแบบสมมาตร, การแจกแจงแบบไม่สมมาตร, ค่าความยาวรันเฉลี่ย

การพัฒนาแผนภูมิควบคุมผสมแบบไม่อิงพารามิเตอร์ EWMA- MA SR เพื่อตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ

Development of a Non-parametric Mixed EWMA- MA SR Control Chart to Detect Changes in Process Mean

ชนากานต์ สุวรรณฉวี* นารีรัตน์ โปธิ พรรณวรินทร์ รตทอง และ เสาวณิต สุขภารังษี
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504053620036@email.kmutnb.ac.th)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมแบบไม่อิงพารามิเตอร์ โดยใช้ค่าความยาวรันเฉลี่ย (Average Run Length: ARL) เป็นเกณฑ์ในการประเมินความสามารถของแผนภูมิควบคุมในการตรวจจับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการ โดยทำการเปรียบเทียบแผนภูมิควบคุมจำนวน 5 แผนภูมิ ได้แก่ แผนภูมิควบคุม EWMA-Sign, EWMA-Sign Rank, EWMA-MA, EWMA-MA-Sign และ EWMA-MA-Sign Rank เพื่อประเมินถึงความไวและให้สัญญาณเตือนการเปลี่ยนแปลงได้รวดเร็วและแม่นยำมากที่สุด ภายใต้เงื่อนไขของการแจกแจงข้อมูล 2 ประเภท ซึ่งแบ่งออกเป็น 1) การแจกแจงแบบสมมาตร (Symmetric Distribution) ประกอบด้วย การแจกแจงปกติ (Normal Distribution) การแจกแจงโลจิสติกส์ (Logistic Distribution) และการแจกแจงลาปลาซ (Laplace Distribution) และ 2) การแจกแจงแบบไม่สมมาตร (Asymmetric Distribution) ประกอบด้วย การแจกแจงแบบเลขชี้กำลัง (Exponential Distribution) การแจกแจงแกมมา (Gamma Distribution) และการแจกแจงลอคนอร์มอล (Log-Normal Distribution) โดยพิจารณาการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการในหลายระดับ ตั้งแต่การเปลี่ยนแปลงขนาดเล็ก ปานกลาง จนถึงขนาดใหญ่ เพื่อเปรียบเทียบค่า ARL ของแต่ละแผนภูมิ ผลการวิจัยพบว่าแผนภูมิควบคุม EWMA-MA-Sign Rank มีประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการได้ดีที่สุด โดยให้ค่า ARL ต่ำที่สุดในแต่ละการเปลี่ยนแปลงของกระบวนการ ผลการศึกษาชี้ให้เห็นว่าการเลือกใช้แผนภูมิควบคุมที่เหมาะสมกับลักษณะการแจกแจงของข้อมูลมีความสำคัญอย่างยิ่งต่อการเพิ่มประสิทธิภาพในการเฝ้าระวังและควบคุมคุณภาพของกระบวนการผลิตในสภาวะแวดล้อมที่มีความไม่แน่นอนของข้อมูล

คำสำคัญ: แผนภูมิควบคุมแบบไม่อิงพารามิเตอร์, ความยาวรันเฉลี่ย (ARL), แผนภูมิควบคุม EWMA-MA-Sign Rank, การตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยกระบวนการ, การควบคุมกระบวนการเชิงสถิติ

การเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุม NEEWMA, Modified EWMA และ EWMA ในการตรวจจับค่าเฉลี่ยของกระบวนการ

The Performance of NEEWMA, Modified EWMA and EWMA Control Charts for Monitoring Process Mean

พรพิพัฒน์ กลิ่นฉือศิลป์ ภัทรภร ทรัพย์ธัญกุล ภัทรกันย์ มีอุตสาหะ* และ สุวิมล พันธุ์เยี่ยม
ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504051630026@email.kmutnb.ac.th)

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแผนภูมิควบคุมคุณภาพ 3 ประเภท ได้แก่ แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเอ็กซ์โปเนนเชียลแบบใหม่ (New Exponentially Weighted Moving Average: NEEWMA), แผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเอ็กซ์โปเนนเชียลแบบปรับปรุง (Modified Exponentially Weighted Moving Average: Modified EWMA) และแผนภูมิควบคุมค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักแบบเอ็กซ์โปเนนเชียล (Exponentially Weighted Moving Average: EWMA) ในการตรวจจับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการภายใต้สถานการณ์ที่แตกต่างกัน โดยแผนภูมิควบคุม NEEWMA ได้รับการพัฒนาต่อจากแนวคิดของแผนภูมิควบคุม EWMA เพื่อเพิ่มความสามารถในการตรวจจับการเปลี่ยนแปลงขนาดเล็กของกระบวนการผ่านการกำหนดพารามิเตอร์การถ่วงน้ำหนักหลายระดับ ในขณะที่แผนภูมิควบคุม Modified EWMA เป็นการปรับปรุงโครงสร้างของแผนภูมิควบคุม EWMA เพื่อเพิ่มประสิทธิภาพในการตรวจจับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ ขณะที่แผนภูมิควบคุม EWMA เป็นแผนภูมิควบคุมพื้นฐานที่ให้น้ำหนักกับข้อมูลล่าสุดมากกว่าข้อมูลในอดีต ในการศึกษาครั้งนี้ใช้ข้อมูลจากการจำลองโดยเทคนิคการจำลองแบบมอนติคาร์โล (Monte Carlo Simulation) โดยเลือกใช้เกณฑ์การประเมินประสิทธิภาพแผนภูมิควบคุมคือค่าความยาวรันเฉลี่ย (Average Run Length: ARL) และค่าส่วนเบี่ยงเบนมาตรฐานของความยาวรัน (Standard Deviation of Run Length: SDRL) ศึกษาในกรณีที่มีการแจกแจงแบบปกติ $X \sim N(\mu, \sigma^2)$ โดยกำหนดค่าเฉลี่ยของกระบวนการภายใต้การควบคุม $\mu_0 = 0$ และส่วนเบี่ยงเบนมาตรฐาน $\sigma = 1$ เมื่อเกิดการเปลี่ยนแปลงของกระบวนการ ค่าเฉลี่ยจะเปลี่ยนเป็น $\mu_1 = \mu_0 + \delta\sigma$ โดย δ แทนขนาดของการเปลี่ยนแปลงของกระบวนการ กำหนดขนาดตัวอย่าง $n = 10$ และกำหนดค่าความยาวรันเฉลี่ยเมื่อกระบวนการอยู่ภายใต้การควบคุม (ARL_0) เท่ากับ 370 การจำลองทำซ้ำจำนวน 10,000 ครั้ง และเมื่อกระบวนการอยู่นอกการควบคุมกำหนดค่าพารามิเตอร์ระดับการเปลี่ยนแปลงค่าเฉลี่ยของกระบวนการ (shift size) เท่ากับ 0.01, 0.02, ..., 0.1, 0.2, ..., 1.50 และ 2.0 ในการกำหนดพารามิเตอร์ของแผนภูมิควบคุม EWMA กำหนดให้ค่าพารามิเตอร์ปรับให้เรียบเอ็กซ์โปเนนเชียล (λ) เท่ากับ 0.1 สำหรับแผนภูมิควบคุม Modified EWMA กำหนดให้ค่าพารามิเตอร์ปรับให้เรียบเอ็กซ์โปเนนเชียล (λ) เท่ากับ 0.1 และสำหรับแผนภูมิควบคุม NEEWMA กำหนดให้ค่าพารามิเตอร์ปรับให้เรียบเอ็กซ์โปเนนเชียล λ_1 เท่ากับ 0.1, λ_2 เท่ากับ 0.03 และ λ_3 เท่ากับ 0.01 ผลการศึกษาพบว่า เมื่อกระบวนการออกนอกการควบคุมแผนภูมิควบคุม NEEWMA ให้ค่าความยาวรันเฉลี่ยเมื่อกระบวนการออกนอกการควบคุม (ARL_1) ต่ำที่สุด ในกรณีที่ค่าเฉลี่ยมีการเปลี่ยนแปลงขนาดเล็กถึงปานกลาง (shift size 0.01–0.20) แสดงให้เห็นว่าแผนภูมิควบคุม NEEWMA มีความไวในการตรวจจับการเปลี่ยนแปลงของค่าเฉลี่ยกระบวนการสูงกว่าแผนภูมิควบคุม EWMA และแผนภูมิควบคุม Modified EWMA เนื่องจากโครงสร้างของสถิติแผนภูมิควบคุม NEEWMA ใช้พารามิเตอร์การถ่วงน้ำหนักหลายระดับ ทำให้สามารถสะท้อนข้อมูลในอดีตได้ละเอียดมากขึ้น ขณะที่แผนภูมิควบคุม Modified EWMA มีประสิทธิภาพดีกว่าแผนภูมิควบคุม EWMA ในการตรวจจับการเปลี่ยนแปลงขนาดเล็ก (shift size 0.01–0.05) และแผนภูมิควบคุม EWMA จะมีประสิทธิภาพดีกว่าแผนภูมิควบคุม Modified EWMA ในการตรวจจับการเปลี่ยนแปลงขนาดปานกลาง (shift size 0.06–2.00)

คำสำคัญ: แผนภูมิควบคุม NEEWMA, แผนภูมิควบคุม Modified EWMA, แผนภูมิควบคุม EWMA, การจำลองแบบมอนติคาร์โล

การพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำของเขื่อนป่าสักชลสิทธิ์ และเขื่อนขุนด่านปราการชล

Forecasting Reservoir Water Volumes of Pasak Chonlasit Dam and Khun Dan Prakarnchon Dam

ขวัญจิรา จังจันทร์* ชาญญา มาปุก นิธิศ กุบ โภกกรวด และ อรไท พลเสน
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(*s6504052620041@email.kmutnb.ac.th)

บทคัดย่อ

ประเทศไทยประสบปัญหาน้ำท่วมเกือบทุกปี โดยเฉพาะในช่วงฤดูฝน ซึ่งก่อให้เกิดผลกระทบต่อชีวิตทรัพย์สิน และความมั่นคงด้านทรัพยากรน้ำของประเทศ อ่างเก็บน้ำจึงมีบทบาทสำคัญในการรองรับน้ำส่วนเกินในช่วงฤดูฝนเพื่อนำมาใช้ในช่วงฤดูแล้ง ช่วยลดความรุนแรงของน้ำหลาก และบรรเทาความเสียหายจากน้ำท่วม ซึ่งการบริหารจัดการน้ำของอ่างเก็บน้ำให้มีประสิทธิภาพนั้นจำเป็นต้องอาศัยการพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำที่มีความแม่นยำเพื่อใช้ในการวางแผนและการจัดสรรน้ำอย่างเหมาะสม งานวิจัยนี้จึงได้ศึกษาการพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำที่สำคัญของประเทศไทยประกอบด้วยอ่างเก็บน้ำของเขื่อนป่าสักชลสิทธิ์และเขื่อนขุนด่านปราการชล โดยมีวัตถุประสงค์เพื่อสร้างตัวแบบพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำของเขื่อนดังกล่าว ข้อมูลที่ใช้เป็นข้อมูลทุติยภูมิที่เก็บรวบรวมจากกรมชลประทาน กระทรวงเกษตรและสหกรณ์ ซึ่งเป็นข้อมูลรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2561 ถึงเดือนธันวาคม พ.ศ. 2568 รวมทั้งสิ้น 96 เดือน และใช้การวิเคราะห์อนุกรมเวลาด้วยตัวแบบ ARIMA (Autoregressive Integrated Moving Average) ตัวแบบ ETS (Error-Trend-Seasonality) และตัวแบบการถดถอยอนุกรมเวลา (Time Series Regression) โดยพิจารณาค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ในการเปรียบเทียบประสิทธิภาพของตัวแบบ ผลการศึกษาพบว่าตัวแบบ ARIMA เป็นตัวแบบที่มีความเหมาะสมที่สุดสำหรับการพยากรณ์ปริมาณน้ำในอ่างเก็บน้ำของเขื่อนป่าสักชลสิทธิ์และเขื่อนขุนด่านปราการชล

คำสำคัญ: ปริมาณน้ำในอ่างเก็บน้ำ, ตัวแบบ ARIMA, ตัวแบบ ETS, ตัวแบบการถดถอยอนุกรมเวลา

การวิเคราะห์ปัจจัยที่มีผลต่อราคาห้องพักในประเทศไทย ด้วยตัวแบบการถดถอยเชิงพื้นที่

An Analysis of Factors Affecting Room Prices in Thailand Using Spatial Regression Models

ไอรัก หิรัญศิริลักษณ์* วรพล จันทร์กริ ปพิชญา เตชะสร้อย และ ชนาพันธุ์ ชนาเนตร
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระจอมเกล้าพระนครเหนือ
(*s6504052610151@email.kmutnb.ac.th)

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาปัจจัยและเปรียบเทียบแบบจำลองการถดถอยสำหรับวิเคราะห์อิทธิพลเชิงพื้นที่ที่มีผลต่อความผันแปรของราคาห้องพักในประเทศไทย โดยใช้ข้อมูลทุติยภูมิจากแพลตฟอร์มออนไลน์จำนวน 714 แห่ง งานวิจัยในอดีตส่วนใหญ่มักใช้แบบจำลองการถดถอยเชิงเส้น ซึ่งตั้งอยู่บนสมมติฐานว่าหน่วยข้อมูลแต่ละหน่วยเป็นอิสระต่อกัน อย่างไรก็ตาม ข้อมูลที่พักมีการกระจายตัวตามตำแหน่งทางภูมิศาสตร์ จึงอาจก่อให้เกิดความสัมพันธ์เชิงพื้นที่ (Spatial Autocorrelation) ระหว่างพื้นที่ใกล้เคียง หากไม่พิจารณาความสัมพันธ์ดังกล่าว อาจทำให้การประมาณค่าของแบบจำลองเกิดความคลาดเคลื่อน ในการศึกษาครั้งนี้ ผู้วิจัยเริ่มต้นการวิเคราะห์ด้วยแบบจำลองการถดถอยเชิงเส้นแบบกำลังสองน้อยที่สุด (Ordinary Least Squares: OLS) เพื่อศึกษาความสัมพันธ์ระหว่างตัวแปรอิสระกับตัวแปรตาม โดยตัวแปรอิสระด้านคุณภาพ ได้แก่ คะแนนรีวิว การรับรองด้านความยั่งยืน และมาตรฐานรับรองด้านสุขอนามัย และตัวแปรอิสระด้านลักษณะ ได้แก่ ประเภทที่พัก และจำนวนรีวิว ขณะที่ตัวแปรตามคือราคาห้องพัก จากนั้นได้ทำการตรวจสอบการพึ่งพิงเชิงพื้นที่ของข้อมูลโดยใช้สถิติ Moran's I ซึ่งเป็นสถิติที่ใช้ตรวจสอบการกระจายตัวเชิงพื้นที่ของข้อมูล โดยหากพบว่าค่าดังกล่าวมีนัยสำคัญทางสถิติ ($p\text{-value} < 0.05$) แสดงว่าข้อมูลมีความสัมพันธ์เชิงพื้นที่ ผู้วิจัยจึงได้พิจารณาวิธีการสร้างเมทริกซ์น้ำหนักเชิงพื้นที่ (Spatial Weight Matrix) ที่นิยมใช้ ได้แก่ วิธีอาศัยขอบเขตพื้นที่ (Contiguity-based method) เช่น Queen Contiguity และวิธีอาศัยระยะทาง (Distance-based method) เช่น K-Nearest Neighbors (KNN) โดยในการศึกษานี้เลือกใช้วิธี KNN เนื่องจากข้อมูลอยู่ในรูปพิกัดจุดและมีการกระจุกตัวในแหล่งท่องเที่ยว โดยได้ทดลองกำหนดค่า $k = 4, 5$ และ 6 พบว่าค่า Moran's I เท่ากับ 0.066, 0.078 และ 0.058 ตามลำดับ ซึ่งค่าที่สูงที่สุดคือ 0.078 เมื่อ $k = 5$ ดังนั้นจึงเลือกใช้ $k = 5$ ในการสร้าง Spatial Weight Matrix เมื่อพบว่าข้อมูลมีการพึ่งพิงเชิงพื้นที่ ผู้วิจัยจึงทำการวิเคราะห์ด้วยแบบจำลองเชิงพื้นที่ ได้แก่ Spatial Lag Model (SLM) และ Spatial Error Model (SEM) ผลการเปรียบเทียบแบบจำลองทั้ง 3 วิธีมีค่า $R^2 = 0.264, 0.328$ และ 0.309 ตามลำดับ โดยแบบจำลอง SLM มีความเหมาะสมกับข้อมูลมากที่สุด ($R^2 = 0.328$) ซึ่งถือว่าอยู่ในระดับที่ยอมรับได้สำหรับการศึกษาด้านเศรษฐศาสตร์และการท่องเที่ยว เนื่องจากราคาที่พักอาจได้รับอิทธิพลจากปัจจัยอื่น ๆ ที่ไม่ได้รวมอยู่ในแบบจำลอง และค่า $AIC = 794.101$ ผลการวิเคราะห์พบว่าค่าสัมประสิทธิ์ของตัวแปรเชิงพื้นที่ ($\hat{\rho} = 0.338, p\text{-value} < 0.001$) ราคาห้องพักของที่พักในพื้นที่ใกล้เคียงมีอิทธิพลต่อกันอย่างมีนัยสำคัญทางสถิติ นอกจากนี้ตัวแปรด้านคุณภาพ ได้แก่ คะแนนรีวิว ($\hat{\beta} = 0.138, p\text{-value} < 0.001$), รับรองด้านความยั่งยืน ($\hat{\beta} = 0.184, p\text{-value} < 0.001$) และมาตรฐานด้านสุขอนามัย ($\hat{\beta} = 0.156, p\text{-value} < 0.001$) มีความสัมพันธ์เชิงบวกกับราคาห้องพักอย่างมีนัยสำคัญทางสถิติอย่างมาก ด้านลักษณะ ได้แก่ จำนวนรีวิว ($\hat{\beta} = 0.118, p\text{-value} < 0.001$) มีความสัมพันธ์เชิงบวกกับราคาห้องพักอย่างมีนัยสำคัญทางสถิติอย่างมาก ส่วนตัวแปรประเภทที่พัก ($\hat{\beta} = -0.062, p\text{-value} < 0.10$) มีความสัมพันธ์เชิงลบกับราคาห้องพักในระดับนัยสำคัญต่ำ

คำสำคัญ: การถดถอยเชิงพื้นที่; ราคาห้องพัก; Spatial Autocorrelation; Spatial Lag Model; Spatial Error Model

การพยากรณ์ค่า PM2.5 ในกรุงเทพมหานครโดยใช้เทคนิคควอนไทล์

Forecasting of PM2.5 Levels in Bangkok with Quantile Techniques

ศุชากริชย์ ศีลาเจริญ, ศรีมา เจริญทรัพย์, จิรภาส สามารธรรมย์ และ ชนาพันธุ์ ชนาเนตร
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504053630023@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์ความเข้มข้นของฝุ่นละอองขนาดเล็กกว่า 2.5 ไมครอน (PM2.5) ในกรุงเทพมหานคร โดยศึกษาความสัมพันธ์ของตัวแปรมลพิษทางอากาศและสร้างแบบจำลองเพื่อพยากรณ์ค่า PM2.5 จากตัวแปรที่เกี่ยวข้อง กำหนดให้ความเข้มข้นของฝุ่นละอองขนาด 10 ไมครอน (PM10) เป็นตัวแปรอิสระ และค่า PM2.5 เป็นตัวแปรตาม ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลคุณภาพอากาศในกรุงเทพมหานคร โดยใช้ข้อมูลรายเดือนตั้งแต่เดือนมีนาคม พ.ศ. 2557 ถึงเดือนธันวาคม พ.ศ. 2563 และแบ่งเป็นชุด Training set และ Test set เพื่อใช้สร้างและประเมินประสิทธิภาพของแบบจำลอง งานวิจัยนี้ประยุกต์ใช้การพยากรณ์เชิงควอนไทล์หลายวิธี ได้แก่ Quantile Random Forest (QRF), Quantile Random Forest Local (QRFL), Quantile Gradient Boosting (QGB), Quantile Gradient Boosting Local (QGBL), Quantile k-Nearest Neighbors (QKNN), Quantile k-Nearest Neighbors Local (QKNNL) และ Natural Gradient Boosting (NGBoost) การประเมิน ประสิทธิภาพของแบบจำลอง ใช้เกณฑ์ RMSE, CRPS, Bias, Coverage Probability และ Interval Width ผลการศึกษา พบว่าแบบจำลอง QRF ให้ค่า RMSE ต่ำที่สุด (≈ 6.59) และ QRF และ QRFL ให้ค่า Coverage Probability ใกล้เคียง 95% มากที่สุด ($\approx 0.94 - 0.95$) แสดงถึงความสามารถ ในการครอบคลุมค่าจริงได้ดี ขณะที่ QGB และ QGBL ให้ช่วงความเชื่อมั่นที่กว้างกว่า แสดงให้เห็นว่ามีความแปรปรวนที่มากกว่า แบบจำลอง QRF และ QGB สามารถให้ผลลัพธ์ที่ดีกว่าวิธีอื่น เนื่องจากสามารถจัดการกับ ความสัมพันธ์เชิงไม่เชิงเส้น (nonlinear relationships) และการกระจายตัวของข้อมูลที่ไม่ปกติได้อย่างมีประสิทธิภาพ ทำให้เหมาะสมกับข้อมูลมลพิษทางอากาศที่มีความผันผวนสูง ดังนั้นการใช้แบบจำลองเชิงควอนไทล์ โดยเฉพาะ QRF มีความเหมาะสมสำหรับการพยากรณ์ PM2.5 และสามารถนำไปใช้สนับสนุนการวางแผนด้านสิ่งแวดล้อมและการแจ้งเตือนคุณภาพอากาศได้อย่างมีประสิทธิภาพ

คำสำคัญ: PM2.5, PM10, คุณภาพอากาศ, การพยากรณ์เชิงควอนไทล์, Coverage Probability, interval width

การพัฒนาและเปรียบเทียบตัวแบบความเสี่ยงสำหรับรถยนต์ไฟฟ้าและ รถยนต์สันดาปในธุรกิจประกันภัย

Development and Comparison of Risk Models for Electric and Internal Combustion Vehicles in the Insurance Business

ศศิวิมล โมคศิริ และ อุไรวรรณ เจริญศิริติกุล

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(s6504052620199@email.kmutnb.ac.th, uraiwam.j@sci.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบตัวแบบความเสี่ยงสำหรับรถยนต์ไฟฟ้าและรถยนต์สันดาปในธุรกิจประกันภัย โดยศึกษาตัวแปรปัจจัยเสี่ยงที่มีผลกระทบต่อค่าต้นทุนความเสียหายในการประกันภัยสำหรับรถยนต์ไฟฟ้าและรถยนต์สันดาป และศึกษาตัวแบบจำลองที่เหมาะสมสำหรับการประมาณค่าเฉลี่ยความถี่ของการเรียกร้องค่าสินไหมทดแทนและค่าเฉลี่ยขนาดความรุนแรงของค่าสินไหมของรถยนต์ไฟฟ้าและรถยนต์สันดาป ข้อมูลที่ใช้ศึกษามาจากฐานข้อมูลของบริษัทประกันภัยแห่งหนึ่ง ในการเปรียบเทียบตัวแบบการประมาณค่าต้นทุนความเสียหายในการประกันภัยที่เหมาะสมสำหรับรถยนต์ไฟฟ้ากับรถยนต์สันดาป ใช้ข้อมูลกรมธรรม์ประกันภัยรถยนต์ไฟฟ้า BYD DOLPHIN ระหว่างกรกฎาคม พ.ศ. 2566 ถึงสิงหาคม พ.ศ. 2568 และประกันรถยนต์สันดาป HONDA JAZZ ระหว่างมกราคม พ.ศ. 2566 ถึงกรกฎาคม พ.ศ. 2568 โดยตัวแบบจำลองใช้วิธีการวิเคราะห์ข้อมูลเชิงสถิติด้วยตัวแบบเชิงเส้นน้อยทั่วไปเพื่อคาดการณ์ระดับความเสี่ยงที่จะเกิดขึ้น ผลการวิจัยพบว่าตัวแบบการถดถอยทวินามเชิงลบ เหมาะสมสำหรับการประมาณค่าเฉลี่ยความถี่ของการเรียกร้องสินไหมและตัวแบบการถดถอยลอการิทึมเหมาะสมสำหรับค่าเฉลี่ยขนาดความรุนแรงของค่าสินไหมของรถยนต์ไฟฟ้า ส่วนตัวแบบการถดถอยพหุนามเหมาะสมสำหรับค่าต้นทุนความเสียหายในการประกันภัยของรถยนต์สันดาปเท่านั้น และผลวิเคราะห์ปัจจัยเสี่ยงที่ได้จากตัวแบบที่ระดับนัยสำคัญ 0.05 ประกอบด้วยปัจจัยเสี่ยงได้แก่ปีที่มีผลบังคับใช้กรมธรรม์ ปีรถยนต์ เบี้ยประกันภัยรวมและสถานะของกรมธรรม์ เป็นปัจจัยที่มีอิทธิพลอย่างมีนัยสำคัญต่อต้นทุนความเสียหายในการประกันภัย

คำสำคัญ: ค่าเฉลี่ยความถี่ของการเรียกร้องค่าสินไหมทดแทน, ค่าเฉลี่ยขนาดความรุนแรงของค่าสินไหม, ต้นทุนความเสียหาย, ตัวแบบเชิงเส้นวางน้อยทั่วไป, ตัวแบบถดถอย

การพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรม
และภาคการขนส่งในกรุงเทพมหานครโดยใช้วิธีบ็อกซ์-เจนกินส์

Forecasting Carbon Dioxide Emissions from the Industrial and
Transportation Sectors in Bangkok Using Box–Jenkins Method

ศุภกฤษฎ คำร้อย* ศตวรรษ ฐปทอง ณัฐวดี สารแสสน และ กชพร การุณ

ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร

(*E-mail: supakithk66@nu.ac.th)

บทคัดย่อ

ปัญหาการปล่อยก๊าซคาร์บอนไดออกไซด์เป็นหนึ่งในสาเหตุสำคัญที่ส่งผลกระทบต่อการเปลี่ยนแปลงสภาพภูมิอากาศ โดยเฉพาะภาคอุตสาหกรรมและภาคการขนส่งซึ่งเป็นแหล่งกำเนิดหลักของการปล่อยก๊าซดังกล่าว การพยากรณ์ปริมาณการปล่อยก๊าซอย่างมีประสิทธิภาพจึงมีความสำคัญต่อการวางแผนและกำหนดนโยบายด้านพลังงานและสิ่งแวดล้อม การศึกษาครั้งนี้จึงมีวัตถุประสงค์เพื่อสร้างตัวแบบที่เหมาะสมสำหรับการพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรมและภาคการขนส่งในกรุงเทพมหานครโดยใช้วิธีบ็อกซ์-เจนกินส์ (Box-Jenkins Method) ซึ่งเป็นวิธีที่เหมาะสมสำหรับการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลา เนื่องจากสามารถอธิบายรูปแบบแนวโน้มและฤดูกาลของข้อมูลได้อย่างมีประสิทธิภาพ โดยใช้ข้อมูลการปล่อยก๊าซในช่วงเดือนมกราคม พ.ศ. 2562 ถึงเดือนพฤศจิกายน พ.ศ. 2568 รวมทั้งสิ้น 83 เดือน ข้อมูลถูกแบ่งออกเป็น 2 ชุด ได้แก่ ชุดที่ 1 ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ. 2567 จำนวน 72 เดือน ใช้สำหรับการสร้างตัวแบบพยากรณ์ และชุดที่ 2 ตั้งแต่เดือนมกราคม พ.ศ. 2568 ถึงเดือนพฤศจิกายน พ.ศ. 2568 จำนวน 11 เดือน ใช้สำหรับการเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์โดยวิธีร้อยละค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) และค่าคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ซึ่งตัวแบบที่มีค่า MAPE และ MSE ต่ำที่สุดจะเป็นตัวแบบที่เหมาะสมที่สุดในการพยากรณ์ ผลการศึกษาพบว่า ตัวแบบ SARIMA(1,0,0)(0,1,0)₁₂ ไม่มีพจน์ค่าคงตัว เป็นตัวแบบที่เหมาะสมที่สุดสำหรับการพยากรณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรมในกรุงเทพมหานคร โดยให้ค่า MAPE เท่ากับ 2.4984 และค่า MSE เท่ากับ 810.0537 ขณะที่ตัวแบบ SARIMA(0,0,2)(0,2,0)₁₂ ไม่มีพจน์ค่าคงตัว เป็นตัวแบบที่เหมาะสมที่สุดสำหรับภาคการขนส่ง โดยให้ค่า MAPE เท่ากับ 1.5208 และค่า MSE เท่ากับ 106.1642

คำสำคัญ: การปล่อยก๊าซคาร์บอนไดออกไซด์, วิธีบ็อกซ์-เจนกินส์, ร้อยละค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย, ค่าคลาดเคลื่อนกำลังสองเฉลี่ย

การเปรียบเทียบวิธีการพยากรณ์สำหรับปริมาณการส่งออกข้าวของประเทศไทย A Comparison of Forecasting Methods for Rice Export Volume in Thailand

กิตติยา พิมพ์มูล* ณิชฐนิชา พรหมจันทร์ สุจิตรา เกตุคณา และ กชพร การุณ
ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร
(*E-mail gittiyap66@nu.ac.th)

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีการพยากรณ์ปริมาณการส่งออกข้าวของประเทศไทยรายเดือนจากเว็บไซต์ของสำนักงานปลัดกระทรวงพาณิชย์ ตั้งแต่เดือนมกราคม พ.ศ. 2560 ถึงเดือนพฤศจิกายน พ.ศ. 2568 จำนวน 107 เดือน โดยการศึกษาเปรียบเทียบวิธีการพยากรณ์เดี่ยวจำนวน 4 วิธี ได้แก่ วิธีค่าเฉลี่ยเคลื่อนที่สองครั้ง วิธีการปรับเรียบแบบเลขชี้กำลังอย่างง่าย วิธีการปรับเรียบแบบเลขชี้กำลังสองชั้นของบราวน์ และวิธีการบ็อกซ์-เจนกินส์ รวมทั้งวิธีการพยากรณ์ร่วมที่ได้จากการนำผลของแบบจำลองเดี่ยวมารวมกัน โดยกำหนดค่าน้ำหนัก 2 วิธี ได้แก่ การกำหนดน้ำหนักที่เท่ากัน และการกำหนดน้ำหนักโดยอิงจากค่า MAPE จึงแบ่งข้อมูลออกเป็น 2 ชุด ดังนี้ ชุดที่ 1 ตั้งแต่เดือนมกราคม พ.ศ. 2560 ถึงเดือนธันวาคม พ.ศ.2567 จำนวน 96 เดือน ใช้สำหรับการสร้างตัวแบบพยากรณ์ และชุดที่ 2 ตั้งแต่เดือนมกราคม พ.ศ.2568 ถึงพฤศจิกายน พ.ศ. 2568 จำนวน 11 เดือน ใช้สำหรับเปรียบเทียบความแม่นยำของตัวแบบพยากรณ์ การประเมินความถูกต้องของแบบจำลองพยากรณ์โดยวิธีที่มีค่า MAPE ต่ำที่สุดถือว่าเป็นวิธีที่เหมาะสมที่สุด ผลการวิจัยพบว่าวิธีการพยากรณ์ร่วมให้ค่า MAPE ต่ำกว่าวิธีการพยากรณ์แบบเดี่ยว เนื่องจากความคลาดเคลื่อนจากแบบจำลองที่แตกต่างกัน เมื่อนำมารวมกันจึงช่วยลดอคติของตัวแบบและเพิ่มความเสถียรของค่าพยากรณ์ ส่งผลให้ประสิทธิภาพในการพยากรณ์ดีขึ้น โดยวิธีการให้น้ำหนักเท่ากัน และวิธีการรวมแบบอิงค่า MAPE ให้ค่า MAPE 18.925 และ 18.957 ตามลำดับ ดังนั้นวิธีการพยากรณ์ร่วมจึงเป็นวิธีที่เหมาะสมที่สุดในการพยากรณ์ปริมาณการส่งออกข้าวของประเทศไทย

คำสำคัญ: วิธีการปรับเรียบแบบเลขชี้กำลังอย่างง่าย, วิธีการปรับเรียบแบบเลขชี้กำลังสองชั้นของบราวน์, วิธีการบ็อกซ์-เจนกินส์, วิธีการพยากรณ์ร่วม, ค่าเฉลี่ยของร้อยละความคลาดเคลื่อนสัมบูรณ์

การวิเคราะห์ปัจจัยเสี่ยงในการคืนสินค้าด้วยการเรียนรู้ของเครื่อง เพื่อใช้ในการออกแบบกรมธรรม์ประกันภัย

Analysis of Risk Factors in Product Returns Using Machine Learning for Insurance Policy Design

กัญญาณัฐ เฟื่องเจริญ* วิมลศิริ วันพระ พิมชนก คิมศิริ และ นवलพรรณ ลอว์สัน
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504052620016@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อวิเคราะห์และแบ่งกลุ่มความเสี่ยงในการคืนสินค้าโดยใช้ตัวแบบการถดถอยลอจิสติก (Logistic Regression) และการเรียนรู้ของเครื่อง (Machine Learning) ได้แก่ Decision Tree, Random Forest, Gradient Boosting และ Naïve Bayes และนำผลที่ได้จากตัวแบบดังกล่าวไปใช้เป็นแนวทางในการออกแบบผลิตภัณฑ์ประกันภัยที่อิงตามระดับความเสี่ยง โดยศึกษาถึงข้อมูลธุรกรรมของบริษัทแห่งหนึ่งในปี ค.ศ. 2018 – 2019 จากแหล่งข้อมูล Kaggle จำนวน 70,052 ตัวอย่าง โดยใช้การเรียนรู้ของเครื่อง (Machine Learning) ประมวลผลด้วยโปรแกรม R โดยเกณฑ์ที่ใช้ในการเปรียบเทียบตัวแบบ ได้แก่ Accuracy, Sensitivity, Specificity, F1-score และพื้นที่ใต้โค้ง (Area Under the Curve: AUC) จากผลการศึกษาพบว่า วิธี Random Forest ให้ค่า AUC เท่ากับ 0.90 และ Accuracy เท่ากับ 85.4% ซึ่งมีประสิทธิภาพในการทำนายการคืนสินค้าในระดับที่เหมาะสมที่สุด และปัจจัยที่มีอิทธิพลต่อการคืนสินค้ามากที่สุดคือ ประเภทสินค้า โปรโมชัน และมูลค่าส่วนลด หลังจากนั้นจึงทำการแบ่งกลุ่มลูกค้าตามระดับความเสี่ยง (Risk Segmentation) โดยแบ่งออกเป็น 5 กลุ่ม โดยพิจารณาระหว่างค่าความน่าจะเป็นในการคืนสินค้าและปัจจัยเสี่ยงรายบุคคล เพื่อนำมาใช้เป็นแนวทางในการกำหนดเบี้ยประกันภัย (Premium) ตามระดับความเสี่ยงเพื่อเป็นแนวทางการเสนอความคุ้มครองให้ลูกค้า

คำสำคัญ: การคืนสินค้า การเรียนรู้ของเครื่อง การแบ่งกลุ่มความเสี่ยง เบี้ยประกันภัย Random Forest

การศึกษาแบบจำลอง ARIMA เพื่อพยากรณ์ค่าสินไหมทดแทน

สำหรับประกันภัยเสริมรถยนต์

A Study of the ARIMA Model for Forecasting Claims Amounts

in Motor Add-on Insurance

จิตลาภัทร บัวแดง* และ युพากรณ์ อารีพงษ์

ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504052636010@email.kmutnb.ac.th)

บทคัดย่อ

ประกันภัยเสริมรถยนต์ (Motor Add-on) เป็นผลิตภัณฑ์ที่รองรับความเสี่ยงที่เพิ่มเติมจากกรมธรรม์ประกันภัยรถยนต์ภาคบังคับและภาคสมัครใจ เช่น ค่าชดเชยระหว่างที่รถเข้าซ่อมในอู่ ค่าชดเชยรายได้จากการพักรักษาตัว หรือความเสียหายจากการถูกโจรกรรมทรัพย์สินภายในรถ ผลิตภัณฑ์ดังกล่าวเป็นส่วนหนึ่งของพอร์ตผลิตภัณฑ์ของบริษัทประกันภัย การบริหารและการคาดการณ์ค่าสินไหมทดแทนจึงมีความสำคัญต่อการวางแผนทางการเงิน การตั้งสำรองค่าสินไหมทดแทน และการบริหารความเสี่ยงของบริษัทประกันภัย อย่างไรก็ตาม จากการทบทวนวรรณกรรมพบว่ายังไม่มีการศึกษาที่นำแบบจำลอง ARIMA มาประยุกต์ใช้กับข้อมูลค่าสินไหมทดแทนของผลิตภัณฑ์ประกันภัยเสริมรถยนต์โดยเฉพาะ ขณะที่งานวิจัยที่เกี่ยวข้องส่วนใหญ่ใช้แบบจำลอง ARIMA ในการพยากรณ์ค่าสินไหมทดแทนของผลิตภัณฑ์อื่น ๆ ดังนั้น การศึกษานี้มีวัตถุประสงค์ 1) เพื่อสร้างแบบจำลอง ARIMA ที่เหมาะสมสำหรับการพยากรณ์ค่าสินไหมทดแทนรายเดือนของผลิตภัณฑ์ประกันภัยเสริมรถยนต์ 2) เพื่อเปรียบเทียบและประเมินประสิทธิภาพของแบบจำลองผ่านเกณฑ์การวัดแบบค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และ 3) เพื่อพยากรณ์ค่าสินไหมทดแทนรายเดือนของปี พ.ศ. 2568 สำหรับประกันภัยเสริมรถยนต์ ข้อมูลที่ใช้ในการศึกษาครั้งนี้เป็นข้อมูลทุติยภูมิจากบริษัท กรุงเทพประกันภัย จำกัด (มหาชน) โดยใช้ค่าสินไหมทดแทนรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ. 2567 รวมทั้งสิ้น 72 เดือน แบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดที่ 1 ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ. 2566 จำนวน 60 เดือน สำหรับการสร้างแบบจำลอง และชุดที่ 2 ตั้งแต่เดือนมกราคม พ.ศ. 2567 ถึงเดือนธันวาคม พ.ศ. 2567 จำนวน 12 เดือน สำหรับการทดสอบประสิทธิภาพของแบบจำลอง เกณฑ์ที่ใช้ในการวัดความแม่นยำคือ ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ผลการศึกษาพบว่า แบบจำลองที่เหมาะสมที่สุดในการพยากรณ์ค่าสินไหมทดแทนรายเดือนของปี พ.ศ. 2568 คือ ARIMA(4,2,0) เนื่องจากให้ค่า MAPE ต่ำที่สุด โดยให้ค่า MAPE เท่ากับ 14.419 ซึ่งแสดงว่าแบบจำลองมีความแม่นยำในการพยากรณ์ค่าสินไหมทดแทนอยู่ในระดับที่ดี

ข้อจำกัดแบบจำลอง ARIMA คือยังไม่ได้พิจารณาปัจจัยภายนอกที่อาจส่งผลกระทบต่อจำนวนค่าสินไหมทดแทน ดังนั้น ในการศึกษาครั้งต่อไปอาจพิจารณาใช้แบบจำลอง ARIMAX ซึ่งสามารถนำตัวแปรภายนอก เช่น ภาวะเศรษฐกิจ จำนวนกรมธรรม์ หรือเหตุการณ์พิเศษ มาร่วมวิเคราะห์กับข้อมูลอนุกรมเวลา ซึ่งอาจช่วยเพิ่มความสามารถในการอธิบายการเปลี่ยนแปลงของข้อมูลและเพิ่มความแม่นยำของการพยากรณ์ในอนาคต

คำสำคัญ: ประกันภัยเสริมรถยนต์, แบบจำลอง ARIMA, ค่าสินไหมทดแทน, ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

การประมาณค่าความเสี่ยงโรคมะเร็งปอดจากปัจจัยส่วนบุคคลและมลพิษทางอากาศ เพื่อการประเมินความเสี่ยงด้านสุขภาพ

Estimating Lung Cancer Risk from Personal Characteristics and Air Pollution Data for Health Risk Assessment

สิทธิชน ชันบรรจง ปัญจรัตน์ วงศ์กำภู ปาติน ปุณณภากุล* และ นवलพรรณ ลอว์สัน
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504052630097@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อประมาณค่าความเสี่ยงของการเกิดโรคมะเร็งปอดจากปัจจัยส่วนบุคคลและมลพิษทางอากาศเพื่อการประเมินความเสี่ยงด้านสุขภาพ ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลผู้ป่วยมะเร็งจำนวน 1,000 คน จากแหล่งข้อมูล Kaggle โดยตัวแปรที่สนใจศึกษาคือการเป็นโรคมะเร็งปอด และตัวแปรอิสระ ได้แก่ อายุ เพศ การสัมผัสมลพิษทางอากาศ การแพ้ฝุ่น ลักษณะการทำงาน ความเสี่ยงทางพันธุกรรม โรคปอดเรื้อรัง และพฤติกรรมกรรมการสูบบุหรี่ โดยใช้สถิติทดสอบไคกำลังสอง (Chi-square test) เพื่อทดสอบความสัมพันธ์ของตัวแปรต่าง ๆ และตัวแบบที่นำมาใช้ในการประมาณค่าความเสี่ยงของการเกิดโรคมะเร็งปอด ได้แก่ การถดถอยโลจิสติกแบบทวิภาค (Binary Logistic Regression), ต้นไม้ตัดสินใจ (Decision Tree) และการสุ่มป่าไม้ (Random Forest) โดยเกณฑ์ที่ใช้ในการเปรียบเทียบตัวแบบ ได้แก่ ความถูกต้อง (Accuracy), ความไวในการตรวจพบผู้ป่วย (Sensitivity), ความจำเพาะในการจำแนกผู้ป่วย (Specificity), ค่าเอฟวันสกอร์ (F1-score) และ พื้นที่ใต้เส้นโค้ง ROC (Area Under the Curve: AUC) จากผลการศึกษาพบว่าปัจจัยด้านสิ่งแวดล้อมที่มีความสำคัญสูงสุดต่อการเกิดโรคมะเร็งปอด คือ การสัมผัสมลพิษทางอากาศในช่วงดัชนีคุณภาพอากาศ (Air Quality Index: AQI) ≥ 301 ขณะที่ปัจจัยส่วนบุคคลที่มีอิทธิพลสูงสุดได้แก่ การแพ้ฝุ่น ลักษณะการทำงาน ความเสี่ยงทางพันธุกรรม โรคปอดเรื้อรัง และพฤติกรรมกรรมการสูบบุหรี่ ตามลำดับ นอกจากนี้ผลการเปรียบเทียบตัวแบบพบว่าต้นไม้ตัดสินใจให้ประสิทธิภาพสูงที่สุด โดยมีค่าความถูกต้องเท่ากับ 0.965, ค่าความไวในการตรวจพบผู้ป่วย เท่ากับ 0.986, ค่าความจำเพาะในการจำแนกผู้ป่วย เท่ากับ 0.917, ค่าเอฟวันสกอร์ เท่ากับ 0.973 และ พื้นที่ใต้เส้นโค้ง ROC เท่ากับ 0.979 เมื่อเปรียบเทียบกับ Binary Logistic Regression ที่มีค่าความถูกต้อง 0.850 และ Random Forest ที่มีค่าความถูกต้อง 0.945 จากผลที่ได้นำมาจัดทำเป็นตารางจำแนกระดับความเสี่ยง โดยพิจารณาร่วมกันระหว่างระดับมลพิษทางอากาศและจำนวนปัจจัยเสี่ยงรายบุคคล เพื่อนำมาใช้เป็นแนวทางในการกำหนดเบี้ยประกันภัยและการเสนอความคุ้มครองเพิ่มเติมตามระดับความเสี่ยง โดยเป็นการสะท้อนถึงการประยุกต์ใช้ตัวแบบจำลองในการออกแบบประกันสุขภาพเชิงสิ่งแวดล้อมแบบอิงความเสี่ยงได้

คำสำคัญ: มะเร็งปอด, มลพิษทางอากาศ, การประเมินความเสี่ยง, Decision Tree, ประกันสุขภาพ

การพยากรณ์จำนวนผู้โดยสารรถไฟฟ้า MRT สายสีน้ำเงิน

Prediction of the Number of Passengers Using the MRT Blue Line

พิศดิกร เลิศเรืองปัญญาธิ เอกขจร บารมี ขุนพล ทศนวิสุทธิ* และ คณิตา เพ็ชรรัตน์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(*s6404052630012@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษา วิเคราะห์แนวโน้มและพยากรณ์จำนวนผู้โดยสารรถไฟฟ้า MRT สายสีน้ำเงิน โดยประยุกต์ใช้แบบจำลองอนุกรมเวลาแบบการปรับเรียบแบบเลขชี้กำลัง (Exponential Smoothing) แบบจำลองการถดถอยด้วยอนุกรมเวลา (Time Series Regression) และแบบจำลองอนุกรมเวลาแบบ Box-Jenkins (ARIMA) โดยข้อมูลที่ใช้ในการศึกษานี้เป็นข้อมูลทุติยภูมิของจำนวนผู้โดยสารรถไฟฟ้า MRT สายสีน้ำเงินแบบรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ. 2567 รวมทั้งสิ้น 72 ข้อมูล โดยข้อมูลดังกล่าวได้มาจาก การรถไฟฟ้าขนส่งมวลชนแห่งประเทศไทย (MRTA) จากนั้นได้ทำการปรับข้อมูลให้อยู่ในรูปแบบรายวันเพื่อใช้ในการวิเคราะห์แบบจำลองอนุกรมเวลา และทำการคำนวณค่าพยากรณ์ (Predicted Values) และค่าคลาดเคลื่อนของแบบจำลอง (Residuals) เพื่อตรวจสอบความเหมาะสมของแบบจำลองและประเมินความแม่นยำของการพยากรณ์ โดยใช้ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เป็นเกณฑ์ในการเปรียบเทียบประสิทธิภาพของแบบจำลอง ผลการศึกษาพบว่า แบบจำลองที่เหมาะสมที่สุดคือ ARIMA(1,2,0)(0,2,0)₁₂ โดยแบบจำลองดังกล่าวมีความแม่นยำโดยมีค่า MAPE เท่ากับ 2.608 ผลการศึกษานี้สามารถนำไปใช้เป็นแนวทางในการวางแผนบริหารจัดการเดินรถไฟฟ้า MRT สายสีน้ำเงิน และการกำหนดนโยบายสาธารณะด้านคมนาคมขนส่งในอนาคตได้อย่างมีประสิทธิภาพ

คำสำคัญ: แบบจำลองอนุกรมเวลาแบบบ็อกซ์-เจนกินส์, ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย, แบบจำลองอนุกรมเวลาแบบการปรับเรียบแบบเลขชี้กำลัง, แบบจำลองการถดถอยด้วยอนุกรมเวลา

กรมธรรม์ประกันภัยคุ้มครองการสืบทอดชีวิตสุนัขด้วยเทคโนโลยีการโคลนนิ่ง

Dog Life Legacy Insurance Policy through Cloning Technology

ภาวิต จันทรแสง * พลธิป หนูมุด ภัทรพงศ์ ภัทรกวิน และ วิลาสินี ปรีระจิตร์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504052610100@email.kmutnb.ac.th)

บทคัดย่อ

ในปัจจุบัน กรมธรรม์ประกันภัยสัตว์เลี้ยงส่วนใหญ่ให้ความคุ้มครองด้านค่ารักษาพยาบาลและการชดเชยกรณีการเสียชีวิตของสัตว์เลี้ยงเป็นหลัก อย่างไรก็ตาม ความต้องการของผู้เลี้ยงสัตว์เลี้ยงบางกลุ่มได้ขยายไปสู่การสืบทอดอัตลักษณ์ทางพันธุกรรมของสัตว์เลี้ยงผ่านเทคโนโลยีการโคลนนิ่ง แม้ว่าปัจจุบันจะมีความก้าวหน้าทางเทคโนโลยีดังกล่าว แต่ยังไม่ปรากฏรูปแบบกรมธรรม์ประกันภัยที่รองรับความต้องการดังกล่าวอย่างเป็นระบบงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาและออกแบบรูปแบบกรมธรรม์ประกันภัยสำหรับการสืบทอดชีวิตสุนัขด้วยเทคโนโลยีการโคลนนิ่ง โดยประยุกต์แนวคิดการบริหารความเสี่ยงในการออกแบบผลิตภัณฑ์ประกันภัย ร่วมกับการวิเคราะห์ต้นทุนของกระบวนการโคลนนิ่ง โดยกำหนดเงื่อนไขการรับประกันเฉพาะสุนัขที่มีอายุไม่เกิน 6 ปี เพื่อให้เหมาะสมต่อการเก็บรักษาสารพันธุกรรมในระยะยาว กรมธรรม์ที่พัฒนาขึ้นในงานวิจัยนี้จึงนำเสนอรูปแบบโครงสร้างการบริหารความเสี่ยงของกรมธรรม์ประกันภัยสำหรับการสืบทอดชีวิตสุนัข Dog Life Legacy Plan ซึ่งครอบคลุมกระบวนการเก็บรักษาสารพันธุกรรม การดำเนินการโคลนนิ่ง จนถึงการดูแลลูกสุนัขหลังคลอด และต้องดำเนินการโดยสถานพยาบาลที่ได้รับใบอนุญาตตามกฎหมายที่เกี่ยวข้อง โดยค่าเบี้ยประกันภัยคำนวณตามหลักคณิตศาสตร์ประกันชีวิต โดยกำหนดเป็นเบี้ยประกันภัยแบบชั่วระยะเวลา (Term Insurance) โดยกำหนดระยะเวลาความคุ้มครองสิ้นสุดเมื่อสุนัขมีอายุครบ 7 ปี ซึ่งแปรผันตามอายุที่เริ่มทำประกันภัยและอัตรา mortality ที่จำแนกตามความหลากหลายของสายพันธุ์ผ่านการประเมินความเสี่ยงประกันภัยตามขนาดของสุนัข 4 ขนาด คือ สุนัขขนาดเล็ก สุนัขขนาดกลาง สุนัขขนาดใหญ่ และสุนัขขนาดยักษ์ นอกจากนี้งานวิจัยยังได้สร้างกลไกการวิเคราะห์ความเสี่ยงเชิงสถิติ โดยประยุกต์ใช้ตารางชีพของมนุษย์เพื่อพัฒนาตารางชีพใหม่สำหรับสุนัข ผลการศึกษาพบว่า รูปแบบกรมธรรม์ประกันภัยที่พัฒนาขึ้นสามารถกำหนดค่าเบี้ยประกันภัยที่สอดคล้องกับต้นทุนของกระบวนการโคลนนิ่ง และสามารถออกแบบเงื่อนไขระยะเวลาความคุ้มครองให้มีความยืดหยุ่นเหมาะสมกับผู้เอาประกันภัย

คำสำคัญ: ประกันภัยสัตว์เลี้ยง, เทคโนโลยีการโคลนนิ่ง, การออกแบบผลิตภัณฑ์ประกันภัย, ตารางชีพสุนัข

เครื่องมือสนับสนุนการวางแผนการเงินส่วนบุคคลด้วย VBA EXCEL

Supporting Tool for Personal Financial Planning Using VBA EXCEL

ณัฐชนน สิงห์แหลม ไชยวัฒน์ ลำภาทอง* ชีรภัทร์ บุญมี นุชรินทร์ ทิพยวรรณกร และ ศิริประภาภรณ์ โนมรัมย์
ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

(* s6504051620039@email.kmutnb.ac.th)

บทคัดย่อ

การวางแผนการเงินส่วนบุคคลจำเป็นต้องอาศัยการวิเคราะห์ข้อมูลทางการเงินจากหลายด้าน แต่โปรแกรมที่ใช้ในการคำนวณและวิเคราะห์ข้อมูลทางการเงินส่วนใหญ่มีลักษณะแยกการทำงานออกจากกันและมีวัตถุประสงค์ในการวิเคราะห์ข้อมูลทางการเงินที่แตกต่างกัน ส่งผลให้ผู้ใช้งานต้องนำเข้าข้อมูลซ้ำในหลายระบบและทำให้การวิเคราะห์ข้อมูลทางการเงินในภาพรวมเป็นไปได้ยาก รวมทั้งทำให้การดำเนินการต้องใช้เวลาเพิ่มขึ้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาโปรแกรมให้เป็นเครื่องมือสนับสนุนการวางแผนการเงินส่วนบุคคล โดยสร้างชุดคำสั่งด้วย VBA บนโปรแกรม Microsoft Excel สำหรับใช้วิเคราะห์ข้อมูลทางการเงินอย่างเป็นระบบ ผู้วิจัยได้ออกแบบโปรแกรมนี้ให้ผู้ใช้งานเข้าใจผลวิเคราะห์ทางการเงินได้ง่าย และสะดวกต่อการใช้งาน โดยไม่จำเป็นต้องมีความรู้ด้านการคำนวณทางการเงิน โดยเฉพาะ โปรแกรมนี้มีความแตกต่างจากโปรแกรมที่มีอยู่ในปัจจุบัน เนื่องจากสามารถเชื่อมโยงข้อมูลในหลายมิติทางการเงินไว้ในที่เดียวกัน และช่วยให้ผู้ใช้งานมองเห็นภาพรวมของสถานะทางการเงินของตนเองได้อย่างชัดเจนและสะดวกรวดเร็ว ทั้งในด้านการวิเคราะห์กระแสเงินสด การคำนวณความมั่งคั่งสุทธิ และการจำลองสถานการณ์การออมในอนาคต อีกทั้งยังช่วยสนับสนุนการตัดสินใจทางการเงินบนพื้นฐานของข้อมูลเฉพาะบุคคล ทำให้การวางแผนการเงินส่วนบุคคลมีประสิทธิภาพ และสามารถต่อยอดไปสู่การจัดทำแผนความมั่งคั่งส่วนบุคคลในระยะยาวได้ ผลการทดลองใช้พบว่าโปรแกรมสามารถคำนวณและประมวลผลข้อมูลได้อย่างถูกต้อง และช่วยลดระยะเวลาในการจัดทำแผนการเงินส่วนบุคคลได้อย่างชัดเจน

คำสำคัญ: การวางแผนการเงินส่วนบุคคล, VBA Excel, กระแสเงินสด, ความมั่งคั่งสุทธิ, การวิเคราะห์ข้อมูลทางการเงิน

การเปรียบเทียบตัวแบบการพยากรณ์ปริมาณการผลิตยานยนต์รวมในประเทศไทย

A Comparison of Forecasting Models for Total Automobile Production in Thailand

กิตติพันธ์ จิตอักษร* ปพนพล บุญมี และ สิริวิษณุ ชุมจินดา
ภาควิชาสถิติประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
(* s6504053620028@email.kmutnb.ac.th)

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของตัวแบบการพยากรณ์อนุกรมเวลาเชิงฤดูกาล จำนวน 3 วิธี ได้แก่ ตัวแบบ SARIMA (Seasonal Autoregressive Integrated Moving Average) การปรับเรียบแบบเอ็กซ์โปเนนเชียลของโฮลต์-วินเทอร์ (Holt-Winters Exponential Smoothing) และการแยกองค์ประกอบอนุกรมเวลาแบบบวก (Classical Additive Decomposition Method) โดยใช้ข้อมูลปริมาณการผลิตรถยนต์ในประเทศไทย ประกอบด้วยรถยนต์นั่ง และรถยนต์เพื่อการพาณิชย์ ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลรายเดือนจากสภาอุตสาหกรรมแห่งประเทศไทย ช่วงเดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2568 รวม 66 ค่า แบ่งเป็นข้อมูลสำหรับการฝึกตัวแบบตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2567 จำนวน 54 ค่า และข้อมูลสำหรับการทดสอบตั้งแต่เดือนมกราคม ถึงเดือนธันวาคม พ.ศ. 2568 จำนวน 12 ค่า เกณฑ์ที่ใช้ในการประเมินประสิทธิภาพของตัวแบบ ได้แก่ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) และค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) การวิเคราะห์ข้อมูลดำเนินการโดยใช้โปรแกรม Microsoft Excel และ RStudio ผลการศึกษาพบว่า ตัวแบบการพยากรณ์จากวิธีการแยกองค์ประกอบแบบบวกให้ค่า $MAE = 8,172.28$ $RMSE = 9,201.57$ และ $MAPE = 14.18\%$ ต่ำที่สุดเมื่อเปรียบเทียบกับตัวแบบอื่นๆ จากผลลัพธ์แสดงว่าข้อมูลปริมาณการผลิตรถยนต์มีลักษณะฤดูกาล และแนวโน้มชัดเจน โดยมีปริมาณการผลิตลดลงในช่วงเดือนเมษายน และเพิ่มขึ้นช่วงเดือนธันวาคม สามารถใช้เป็นเครื่องมือสนับสนุนการวางแผนการผลิตและการตัดสินใจเชิงกลยุทธ์ในอุตสาหกรรมยานยนต์ได้มีประสิทธิภาพ

คำสำคัญ: การพยากรณ์, ปริมาณการผลิตรถยนต์, ตัวแบบ SARIMA, การปรับเรียบแบบเอ็กซ์โปเนนเชียลของโฮลต์-วินเทอร์, การแยกองค์ประกอบ