

การพัฒนาแบบจำลองเชิงผสมระหว่างการเรียนรู้ของเครื่องและอนุกรมเวลาเพื่อพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉินจำแนกตามระดับความเร่งด่วน

Development of Hybrid Machine Learning and Time-Series Models for Forecasting Daily Emergency Department Patient Volumes by Triage Level

ชนาธิป ฉัตรวิไลลักษณ์¹ และ วลัยยา ร่มสายหยุด²

¹แขนงวิชาเทคโนโลยีดิจิทัล, สาขาวิชาวิทยาศาสตร์และเทคโนโลยี, มหาวิทยาลัยสุโขทัยธรรมาธิราช

บางพูด ปากเกร็ด นนทบุรี 11120, n.chanatip@hotmail.com

²แขนงวิชาเทคโนโลยีดิจิทัล, สาขาวิชาวิทยาศาสตร์และเทคโนโลยี, มหาวิทยาลัยสุโขทัยธรรมาธิราช

บางพูด ปากเกร็ด นนทบุรี 11120, walisa.rom@stou.ac.th

Chanatip Chatvelailuk¹ and Walisa Romsaiyud²

¹ Digital Technology, School of Science and Technology, Sukhothai Thammathirat Open University

Bang Phut, Pak Kret, Nonthaburi 11120, Thailand, n.chanatip@hotmail.com

² Digital Technology, School of Science and Technology, Sukhothai Thammathirat Open University

Bang Phut, Pak Kret, Nonthaburi 11120, Thailand, walisa.rom@stou.ac.th

วันที่รับบทความ 17 มิถุนายน 2568

วันแก้ไขบทความ 25 มิถุนายน 2568

วันตอบรับบทความ 19 ธันวาคม 2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อ 1) พัฒนาแบบจำลองเชิงผสมผสานระหว่างการเรียนรู้ของเครื่องและการวิเคราะห์อนุกรมเวลาสำหรับการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉิน และ 2) ประเมินประสิทธิภาพของแบบจำลองโดยใช้ตัวชี้วัดค่าความคลาดเคลื่อนของการพยากรณ์ในผู้ป่วย 6 ระดับความเร่งด่วน ได้แก่ ผู้ป่วยวิกฤต ผู้ป่วยฉุกเฉิน ผู้ป่วยเร่งด่วน ผู้ป่วยกึ่งเร่งด่วน ผู้ป่วยไม่เร่งด่วน และผู้ป่วยที่ไม่สามารถกำหนดระดับความเร่งด่วนได้ โดยใช้ข้อมูลการมารับบริการในช่วงเดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2565 รวมทั้งสิ้น 1,096 ราย ซึ่งประกอบด้วยตัวแปรด้านจำนวนผู้ป่วยและปัจจัยด้านเวลา ข้อมูลถูกแบ่งเป็นชุดฝึกและชุดทดสอบเพื่อพัฒนาและเปรียบเทียบแบบจำลอง 4 วิธี ได้แก่ การถดถอยเชิงเส้นหลายตัวแปร การถดถอยเชิงเส้นพหุนาม อาริมา และซาริมา ผลการวิจัยพบว่าแบบจำลองการถดถอยเชิงเส้นพหุนามให้ผลการพยากรณ์ที่มีความแม่นยำและเสถียรภาพโดยรวมดีที่สุด โดยมีค่า RMSE (รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย) ต่ำในทุกระดับความเร่งด่วน ได้แก่ ผู้ป่วยวิกฤตเท่ากับ 0.4699 ผู้ป่วยฉุกเฉินเท่ากับ 1.5568 ผู้ป่วยเร่งด่วนเท่ากับ 4.8947 ผู้ป่วยกึ่งเร่งด่วนเท่ากับ 5.3972 ผู้ป่วยไม่เร่งด่วนเท่ากับ 4.9101 และผู้ป่วยที่ไม่สามารถกำหนดระดับความเร่งด่วนได้เท่ากับ 0.5225 ขณะที่แบบจำลองอาริมาและซาริมาให้ผลเหมาะสมในกลุ่มข้อมูลที่มีรูปแบบเชิงเวลาค่อนข้างคงที่ แต่ยังมีค่าความคลาดเคลื่อนสูงในกลุ่มที่มีความผันผวนมาก สรุปได้ว่าแบบจำลองการถดถอยเชิงเส้นพหุนามเป็นแบบจำลองที่เหมาะสมที่สุดสำหรับบริบทข้อมูลของงานวิจัยนี้ และสามารถนำไปใช้สนับสนุนการวางแผนทรัพยากรและการบริหารจัดการในแผนกฉุกเฉินได้อย่างมีประสิทธิภาพ

คำสำคัญ: การพยากรณ์อนุกรมเวลา แผนกฉุกเฉิน การถดถอยเชิงเส้นพหุตัวแปร การถดถอยเชิงพหุนาม อาริมา ซาริมา

ABSTRACT

This research aimed to (1) develop a hybrid model integrating machine learning and time series analysis for forecasting daily patient volumes in the emergency department, and (2) evaluate the performance of the model using forecasting error metrics across six triage levels, namely critical, emergency, urgent, semi-urgent, non-urgent, and unspecified urgency. The study employed emergency department visit data collected between January 2020 and December 2022, comprising a total of 1,096 records that included patient volume variables and temporal factors. The data were divided into training and testing sets to develop and compare four forecasting models: Multiple Linear Regression, Polynomial Regression, Autoregressive Integrated Moving Average (ARIMA), and Seasonal ARIMA (SARIMA). The results showed that Polynomial Regression provided the highest overall forecasting accuracy and stability, with the lowest root mean squared error (RMSE) observed across all triage levels, including critical (RMSE = 0.4699), emergency (RMSE = 1.5568), urgent (RMSE = 4.8947), semi-urgent (RMSE = 5.3972), non-urgent (RMSE = 4.9101), and unspecified urgency (RMSE = 0.5225). In contrast, ARIMA and SARIMA models produced acceptable results for triage groups with relatively stable temporal patterns but exhibited higher forecasting errors in groups with high volatility. It can therefore be concluded that Polynomial Regression is the most appropriate model for the characteristics of the dataset used in this study and can be effectively applied to support resource planning and management in emergency departments.

KEYWORDS: Time-series forecasting, Emergency department, Multiple Linear Regression, Polynomial Regression, ARIMA, SARIMA

1. บทนำ

การบริการในแผนกฉุกเฉินของโรงพยาบาลเป็นหนึ่งในส่วนที่มีความสำคัญอย่างยิ่ง เนื่องจากเป็นจุดแรกที่ผู้ป่วยจะได้รับการรักษาในกรณีฉุกเฉิน การสามารถทำนายปริมาณผู้มารับบริการและจำแนกตามระดับความรุนแรงหรือ “Triage” จะช่วยให้โรงพยาบาลสามารถจัดสรรทรัพยากรได้อย่างเหมาะสมและเพิ่มประสิทธิภาพในการให้บริการ (คชาภรณ์ ศรีพารัตน์ และวัฒนา ชยธวัช, 2567) จากงานวิจัยในต่างประเทศพบว่า ความแออัดในแผนกฉุกเฉินเป็นปัญหาหลักที่ส่งผลให้ระยะเวลารอคอยเพิ่มสูงขึ้น และนำไปสู่การลดคุณภาพของการให้บริการ (Boyle et al., 2012) ดังนั้น จึงมีความจำเป็นอย่างยิ่งในการพัฒนาเครื่องมือที่สามารถคาดการณ์ปริมาณผู้ป่วยล่วงหน้า เพื่อรองรับความไม่แน่นอนของภาระงานในแต่ละวัน ซึ่งสอดคล้องกับแนวโน้มการบริหารจัดการแผนกฉุกเฉินในระดับสากล จากสถิติการมารับบริการในแผนกฉุกเฉินในปี พ.ศ. 2565 พบว่ามีผู้มารับบริการจำนวน 16,829 ราย โดยเป็นผู้ป่วยระดับด่วน (Urgency) ที่ต้องได้รับการรักษาภายใน 30 นาที จำนวน 6,391 ราย คิดเป็นร้อยละ 37.98 และเป็นผู้ป่วยเร่งด่วน (Emergency) ที่ต้องได้รับการรักษาภายใน 10 นาที จำนวน 1,010 ราย คิดเป็นร้อยละ 6 ของผู้มารับบริการทั้งหมด ซึ่งหากสามารถคาดการณ์จำนวนผู้มารับบริการตามระดับความรุนแรงได้อย่างแม่นยำ จะช่วยสนับสนุนการวางแผนจัดการทรัพยากรทางการแพทย์และบุคลากรให้มีความพร้อม และลดระยะเวลาในการเข้าช่วยเหลือผู้ป่วยได้อย่างทันทั่วทั้งที่ ข้อมูลดังกล่าวสะท้อนให้เห็นถึงความจำเป็นในการมีระบบคาดการณ์ที่มีประสิทธิภาพ เพื่อจัดการกับความผันผวนของจำนวนผู้ป่วยซึ่งเป็นปัญหาที่พบในแผนกฉุกเฉินของโรงพยาบาลทั่วประเทศ

ในปัจจุบันกระทรวงสาธารณสุขได้ผลักดันนโยบายโรงพยาบาลอัจฉริยะ (Smart Hospital) โดยมีแนวคิดในการนำเทคโนโลยีดิจิทัลมาประยุกต์ใช้ในการบริการทางการแพทย์ เพื่อลดขั้นตอนการปฏิบัติงานและอำนวยความสะดวกรวดเร็วให้แก่ผู้รับบริการ

(กระทรวงสาธารณสุข, 2566) ตัวอย่างการนำเทคโนโลยีดิจิทัลมาประยุกต์ใช้งาน ได้แก่ การเปรียบเทียบประสิทธิภาพในการทำนายผลการเป็นโรคเบาหวาน (สายชล สันสมบุรณ์ทอง, 2561) และการเปรียบเทียบประสิทธิภาพของแบบจำลองการทำนายความเสี่ยงโรคหัวใจและหลอดเลือดโดยใช้อัลกอริทึมเหมืองข้อมูล (นงเยาว์ ในอรุณ, 2564) นอกจากนี้ งานวิจัยในระดับสากลยังพบว่าการนำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) มาใช้ในโรงพยาบาลสามารถช่วยเพิ่มประสิทธิภาพในการคาดการณ์ภาระงานผู้ป่วย การทำนายความเสี่ยงการเสียชีวิต และการวางแผนจัดสรรทรัพยากรได้อย่างมีประสิทธิภาพ (James et al., 2013) ซึ่งสอดคล้องกับแนวทางการพัฒนาด้านสาธารณสุขของประเทศไทยที่มุ่งเน้นการเพิ่มความแม่นยำในการวางแผนและลดภาระงานของบุคลากรทางการแพทย์

จากการศึกษาการนำเทคโนโลยีสารสนเทศมาประยุกต์ใช้ในการสนับสนุนทางการแพทย์พบว่า มีหลากหลายแนวทาง รวมถึงการนำปัญญาประดิษฐ์มาประยุกต์ใช้ในการทำนายและวิเคราะห์ข้อมูลเพื่อช่วยในการวางแผน เช่น การประยุกต์เทคนิคการพยากรณ์สำหรับการวางแผนความต้องการเตียงผู้ป่วย กรณีศึกษาแผนกอายุรกรรม โรงพยาบาลศรีสะเกษ (ณัฏฐพัชร วนิชย์กุล, 2566) ซึ่งจากการศึกษางานวิจัยดังกล่าวพบว่า การวางแผนความต้องการใช้อุปกรณ์ทางการแพทย์เป็นปัจจัยสำคัญที่ส่งผลโดยตรงต่อความปลอดภัยและชีวิตของผู้ป่วย โดยการพยากรณ์จำนวนผู้ป่วยตามระดับความรุนแรงไว้ล่วงหน้าสามารถช่วยให้บุคลากรทางการแพทย์วางแผนและเตรียมอุปกรณ์เพื่อรองรับผู้ป่วยในแต่ละระดับความรุนแรงได้อย่างทันทั่วถึง นอกจากนี้ งานวิจัยในระดับสากลยังแสดงให้เห็นว่าการพยากรณ์ภาระงานในโรงพยาบาลสามารถช่วยลดต้นทุน เพิ่มประสิทธิภาพการดำเนินงาน และลดระยะเวลารอคอยของผู้ป่วยได้อย่างมีนัยสำคัญ (Montgomery et al., 2012)

ระดับความรุนแรงหรือ "Triage" เป็นการประเมินสภาพของผู้ป่วยอย่างรวดเร็ว เพื่อตัดสินความเร่งด่วนของอาการสำคัญที่เป็นปัญหาและจัดให้ได้รับการรักษาพยาบาลตามความเหมาะสม โดยหลักการประเมินอาการจะแบ่งเป็น 2 ระดับ คือ 1. Primary Triage โดยจะประเมินจากข้อมูลทางกายภาพของผู้ป่วย อาการสำคัญ และอาการที่แสดงความคุกคามต่อชีวิตเช่น หายใจหอบ หายใจหยุดเต้น เหงื่อหอบ เป็นต้น 2. Secondary Triage เป็นการประเมินผู้ป่วยอย่างละเอียดโดยรวบรวมข้อมูลจากการประเมินทางกายภาพ Vital Signs ผล Lab X-ray และผลการตรวจพิเศษอื่นๆ โดยสามารถแบ่งระจากการคัดกรองผู้ป่วยตามความเร่งด่วนได้เป็น 5 ระดับได้แก่ 1.ผู้ป่วยวิกฤต (Immediately Life-threatening หรือ Resuscitation) เป็นผู้ป่วยที่ได้รับอาการบาดเจ็บหรือมีอาการป่วยกะทันหัน ซึ่งมีภัยคุกคามต่อชีวิต ซึ่งหากไม่ได้รับการช่วยเหลือทางการแพทย์ในทันทีผู้ป่วยมีโอกาเสียชีวิตได้สูง หรือทำให้เกิดภาวะแทรกซ้อนขึ้นได้อย่างรวดเร็ว 2.ผู้ป่วยเร่งด่วน (Emergency) เป็นผู้ป่วยที่ได้รับบาดเจ็บหรือมีอาการป่วยที่มีภาวะเฉียบพลัน หรือเจ็บป่วยรุนแรงจึงจำเป็นต้องได้รับการช่วยเหลือทางการแพทย์อย่างเร่งด่วนภายใน 10 นาที มิฉะนั้นจะทำให้มีอาการบาดเจ็บหรืออาการป่วยของผู้ป่วยรุนแรงขึ้นหรือเกิดภาวะแทรกซ้อนขึ้นซึ่งส่งผลให้เสียชีวิตหรือพิการในระยะต่อมาได้ 3.ผู้ป่วยรีบด่วน (Urgency) เป็นผู้ป่วยที่ได้รับบาดเจ็บหรือมีอาการป่วยซึ่งมีภาวะเฉียบพลันไม่รุนแรง อาจรอรับการช่วยเหลือทางการแพทย์ได้ในช่วงระยะเวลา 30 นาที แต่จำเป็นต้องใช้ทรัพยากรและหากปล่อยไว้เกินเวลาอันสมควรแล้วจะทำให้มีอาการบาดเจ็บหรืออาการของผู้ป่วยฉุกเฉินนั้นรุนแรงขึ้น หรือเกิดภาวะแทรกซ้อนขึ้นได้ 4.ผู้ป่วยกึ่งรีบด่วน (Semi-urgency) เป็นผู้ป่วยที่ไม่ใช่ผู้ป่วยฉุกเฉิน ซึ่งสามารถรอรับบริการได้โดยไม่ก่อให้เกิดอาการที่รุนแรงขึ้น หรือเกิดภาวะแทรกซ้อนตามมาสามารถรอรับบริการได้ 1 ชม. 5.ผู้ป่วยไม่รีบด่วน (Non-urgency) เป็นผู้มารับบริการทางด้านสาธารณสุขหรือบริการอื่นๆ โดยไม่จำเป็นต้องใช้ทรัพยากรสามารถรอได้มากกว่า 1 ชม. (สุรัตน์ รุ่งสว่าง, 2561)

ดังนั้นในงานวิจัยนี้ขอเสนอการพัฒนาแบบจำลองการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉินโดยใช้การเรียนรู้ของเครื่อง เพื่อสนับสนุนความเชื่อมั่นในการวางแผนจัดการทรัพยากรทางการแพทย์และบุคลากรในการรับมือผู้มารับบริการตามระดับความรุนแรงของการมารับบริการ นอกจากนี้การใช้ข้อมูลเชิงสถิติควบคู่กับอัลกอริทึม Machine Learning ยังช่วยเพิ่มความแม่นยำในการวิเคราะห์แนวโน้ม ลดความคลาดเคลื่อน และสนับสนุนระบบบริการฉุกเฉินให้มีความพร้อมรับมือกับสถานการณ์ที่ไม่คาดคิด ซึ่งเป็นความสำคัญหลักของการบริหารจัดการแผนกฉุกเฉินในยุคดิจิทัล

2. วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉินโดยใช้การเรียนรู้ของเครื่อง
2. เพื่อประเมินประสิทธิภาพของแบบจำลอง โดยใช้ค่าความคลาดเคลื่อนในการวัดผลพยากรณ์ตามระดับความเร่งด่วน

3. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

3.1 การวิเคราะห์เชิงคาดการณ์ (Predictive Analysis)

เป็นกระบวนการทางสถิติและการวิเคราะห์ข้อมูลที่ใช้ข้อมูลในอดีตและข้อมูลปัจจุบันเพื่อทำนายเหตุการณ์ที่อาจเกิดขึ้นในอนาคต หรือเพื่อระบุรูปแบบและแนวโน้มที่สำคัญเพื่อนำไปใช้ประกอบการตัดสินใจเชิงกลยุทธ์ โดยเฉพาะในระบบสาธารณสุข การวิเคราะห์เชิงคาดการณ์มีบทบาทสำคัญในการวางแผนจัดสรรทรัพยากร เช่น บุคลากรทางการแพทย์ เวชภัณฑ์ อุปกรณ์ทางการแพทย์ รวมถึงการบริหารจัดการเตียงผู้ป่วยในโรงพยาบาล เพื่อให้สามารถรองรับผู้ป่วยได้อย่างเพียงพอและลดความเสี่ยงจากความแออัดในการให้บริการ ทั้งนี้ การทำนายปริมาณผู้มารับบริการจำเป็นต้องคำนึงถึงปัจจัยด้านเวลา เช่น ฤดูกาล วันหยุดนักขัตฤกษ์ หรือเหตุการณ์พิเศษ ซึ่งมีผลโดยตรงต่อจำนวนผู้ป่วยที่เข้ารับบริการ ตัวอย่างเช่น งานวิจัยด้านการพยากรณ์ภาระงานในโรงพยาบาลได้ชี้ให้เห็นว่าการนำข้อมูลเชิงเวลาวิเคราะห์ร่วมกับเทคนิคการพยากรณ์สามารถเพิ่มความแม่นยำของการทำนายได้อย่างมีนัยสำคัญ (Boyle et al., 2012) การคาดการณ์ภาระงานอย่างแม่นยำช่วยให้โรงพยาบาลสามารถวางแผนการใช้งานอุปกรณ์ทางการแพทย์ได้อย่างทันเวลาและเพียงพอต่อความต้องการจริง โดยแนวคิดดังกล่าวสอดคล้องกับงานวิจัยเรื่อง การประยุกต์เทคนิคการพยากรณ์สำหรับการวางแผนความต้องการเตียงผู้ป่วย กรณีศึกษาแผนกอายุรกรรม โรงพยาบาลศรีสะเกษ ซึ่งมุ่งพัฒนาแบบจำลองการพยากรณ์ความต้องการเตียงผู้ป่วยโดยใช้ข้อมูลทางสถิติร่วมกับเทคนิคการวิเคราะห์เชิงทำนาย (ณัฏฐพัชร วนิชย์กุล, 2566) ผลการศึกษาพบว่า การใช้ข้อมูลเชิงเวลาและการพยากรณ์เชิงสถิติสามารถช่วยเพิ่มประสิทธิภาพในการวางแผนทรัพยากรได้อย่างเหมาะสม ทำให้โรงพยาบาลสามารถเตรียมความพร้อมด้านอุปกรณ์และบุคลากรได้ดียิ่งขึ้น นอกจากนี้ แนวทางการวิเคราะห์เชิงคาดการณ์ยังถูกนำไปใช้ในหลายบริบททางการแพทย์ เช่น การทำนายจำนวนผู้ป่วยนอกในแต่ละวัน การประเมินความเสี่ยงของการเกิดโรคเรื้อรัง และการคาดการณ์ความต้องการระบบสนับสนุนทางการแพทย์ ซึ่งสะท้อนถึงศักยภาพของวิธีการนี้ในการสนับสนุนการตัดสินใจในระดับองค์กรและเพิ่มประสิทธิภาพในการให้บริการของโรงพยาบาล (Montgomery et al., 2012)

ดังนั้น การวิเคราะห์เชิงคาดการณ์จึงเป็นพื้นฐานสำคัญสำหรับงานวิจัยด้านการพยากรณ์ปริมาณผู้ป่วยในแผนกฉุกเฉินของโรงพยาบาลในครั้งนี้ โดยเฉพาะเมื่อข้อมูลมีความผันผวนสูงและมีปัจจัยด้านเวลาที่ส่งผลกระทบต่อจำนวนผู้มารับบริการ การเลือกวิธีการวิเคราะห์ที่เหมาะสมช่วยให้สามารถคาดการณ์ได้แม่นยำและสนับสนุนการวางแผนจัดการทรัพยากรของโรงพยาบาลได้อย่างมีประสิทธิภาพยิ่งขึ้น

3.2 เทคนิคการถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression)

เป็นการขยายต้นแบบจากการถดถอยเชิงเส้นเบื้องต้น (Simple Linear Regression) ให้สามารถรองรับตัวแปรอิสระหลายตัว โดยมีเป้าหมายเพื่อทำนายค่าของตัวแปรตามจากค่าของตัวแปรอิสระหลายตัว และวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรเหล่านั้น การถดถอยเชิงเส้นหลายตัวแปรเป็นเทคนิคที่ใช้ได้กับข้อมูลที่มีความสัมพันธ์เชิงเส้นระหว่างตัวแปรตามและตัวแปรอิสระหลายตัว แต่หากข้อมูลมีความสัมพันธ์ที่ซับซ้อนหรือไม่เป็นเชิงเส้น การถดถอยเชิงเส้นหลายตัวแปรอาจไม่ให้ผลลัพธ์ที่แม่นยำ และอาจต้องใช้เทคนิคการวิเคราะห์ที่ซับซ้อนขึ้น (Montgomery et al., 2012) เช่นความสัมพันธ์ระหว่างคุณภาพการให้บริการกับความพึงพอใจของผู้ป่วยในโรงพยาบาลเอกชนในประเทศอิหร่าน โดยเก็บข้อมูลจากผู้ป่วยจำนวน 969 รายผ่านแบบสอบถาม SERVPERF และวิเคราะห์ด้วยวิธี Multiple Linear Regression ผลการศึกษาพบว่า ตัวแปรคุณภาพการบริการสามารถอธิบายความแปรผันของความพึงพอใจได้ร้อยละ 45 ($R^2 = 0.45$) โดยตัวแปรที่มีผลอย่างมีนัยสำคัญ ได้แก่ กระบวนการบริการ (Process Quality), การปฏิสัมพันธ์ระหว่างผู้

ให้บริการกับผู้ป่วย (Interaction Quality) และ ค่าใช้จ่ายในการรักษา (Cost) ซึ่งแสดงให้เห็นว่าทั้งด้านประสิทธิภาพการให้บริการ และปัจจัยด้านเศรษฐกิจมีผลต่อระดับความพึงพอใจของผู้ป่วย (Zarei et al., 2015)

สมการที่ 2 การถดถอยเชิงเส้นหลายตัวแปร

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3 + \dots + \beta_nx_n + \varepsilon \quad (2)$$

โดยที่	y	คือ ตัวแปรตาม (Dependent Variable)
	$x_1, x_2, x_3, \dots, x_n$	คือ ตัวแปรต้น (Independent Variables)
	β_0	คือ ค่าคงที่ (Intercept)
	$\beta_1, \beta_2, \beta_3, \dots, \beta_n$	คือ ค่าสัมประสิทธิ์ (Coefficients) ที่โมเดลจะประมาณค่า
	ε	คือ ข้อผิดพลาด (Error Term)

3.3 เทคนิคการถดถอยเชิงเส้นพหุนาม (Polynomial Regression)

เป็นการขยายต้นแบบจากการถดถอยเชิงเส้น (Linear Regression) โดยการยกกำลังของตัวแปรอิสระเพื่อรองรับความสัมพันธ์ที่ไม่เป็นเชิงเส้นระหว่างตัวแปรตามและตัวแปรอิสระ การถดถอยเชิงเส้นพหุนามเป็นเทคนิคที่ใช้ได้กับข้อมูลที่มีความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้นระหว่างตัวแปรตามและตัวแปรอิสระ แต่หากมีการยกกำลังของตัวแปรอิสระมากเกินไป อาจทำให้เกิดปัญหาการเกินปรับ (Overfitting) ซึ่งแบบจำลองจะพยายามที่จะรองรับข้อมูลทุกจุด ทำให้ไม่สามารถทำนายข้อมูลใหม่ที่ไม่เคยเห็นมาก่อนได้ดี (James et al., 2013) เช่นงานวิจัย “การพยากรณ์อัตราผู้สูงอายุที่มีปัญหาความเครียดในจังหวัดลพบุรี” (ศุภวรรณ ศรีพรัตน์ และวัฒนา ชยรัช, 2567) โดยพัฒนาแบบจำลองการถดถอยเชิงพหุนามในการทำนายอัตราผู้สูงอายุที่มีปัญหาความเครียดเพื่อช่วยในการวางแผนจัดการการแก้ปัญหาความเครียดของผู้สูงอายุต่อไป

สมการที่ 3 การถดถอยเชิงเส้นพหุนาม

$$y = \beta^0 + \beta^1x + \beta^2x^2 + \beta^3x^3 + \dots + \beta^nx^n \quad (3)$$

โดยที่	y	คือ ตัวแปรตาม (Dependent Variable)
	X	คือ ตัวแปรต้น (Independent Variable)
	$\beta_0, \beta_1, \dots, \beta_n$	คือ ค่าสัมประสิทธิ์ (Coefficients) ที่โมเดลจะประมาณค่า
	n	คือ ระดับของพหุนาม (Degree of Polynomial)

3.4 เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average: ARIMA)

เป็นเทคนิคในการวิเคราะห์ข้อมูลอนุกรมเวลา (Time Series Analysis) ที่มักถูกใช้ในการทำนายค่าในอนาคตของข้อมูลที่มีความสัมพันธ์กับเวลา โดย ARIMA ประกอบด้วยสามส่วนหลัก ได้แก่ 1. Autoregressive (AR) ส่วนนี้เกี่ยวข้องกับการถดถอยของค่าในอดีต (lagged values) ของตัวแปรตามเอง ซึ่งเป็นการระบุว่าค่าปัจจุบันของข้อมูลมีความสัมพันธ์กับค่าในอดีตเพียงใด 2. Integrated (I) ส่วนนี้เกี่ยวข้องกับการต่าง (differencing) ของข้อมูล เพื่อทำให้ข้อมูลมีความเสถียร (stationary) ซึ่งการทำให้ข้อมูลเป็น stationary จะช่วยในการประมาณค่าสัมประสิทธิ์ของแบบจำลองให้มีประสิทธิภาพมากขึ้น 3. Moving Average (MA) ส่วนนี้

เกี่ยวข้องกับค่าคลาดเคลื่อน (error terms) ของการทำนายในอดีต ซึ่งเป็นการระบุว่าค่าคลาดเคลื่อนปัจจุบันมีความสัมพันธ์กับค่าคลาดเคลื่อนในอดีตเพียงใด (Montgomery et al., 2012) ซึ่งนิยมนำมาใช้เกี่ยวกับการพยากรณ์สภาพอากาศ เช่น “การพยากรณ์ปริมาณน้ำฝนโดยใช้เทคนิคการปรับให้เรียบ เทคนิค ARIMA และเทคนิค Support Vector Machine” (ณพฐ์ โสภีพันธ์ และคณะ, 2567) โดยนำข้อมูลจากศูนย์อุทกวิทยาและบริหารน้ำภาคตะวันออกเฉียงเหนือตอนล่าง กรมชลประทาน มาใช้ในการวิเคราะห์เปรียบเทียบประสิทธิภาพเพื่อหาวิธีที่เหมาะสมที่สุดในการพยากรณ์จาก 3 วิธีได้แก่ Winter’s Method Box-Jenkins หรือ ARIMA และ Support Vector Machine (SVM) พบว่า ARIMA เหมาะสำหรับข้อมูลอนุกรมเวลาที่มีความเสถียรและฤดูกาล

สมการที่ 4 เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \theta_q e_{t-q} + \epsilon_t \quad (4)$$

โดยที่	Y_t	คือ ค่าปัจจุบันของตัวแปรตาม
	$\phi_1, \phi_2, \dots, \phi_p$	คือ ค่าสัมประสิทธิ์ของ Autoregressive
	$\theta_1, \theta_2, \dots, \theta_q$	คือ ค่าสัมประสิทธิ์ของ Moving Average
	$e_{t-1}, e_{t-2}, \dots, e_{t-q}$	คือ ข้อผิดพลาดในช่วงเวลาที่ผ่านมา
	ϵ_t	คือ ค่าคลาดเคลื่อน (error term)

3.5 เทคนิคการพยากรณ์แบบ SARIMA (Seasonal ARIMA)

เป็นแบบจำลองที่พัฒนาต่อยอดจาก ARIMA เพื่อรองรับข้อมูลอนุกรมเวลาที่มีลักษณะเป็นวัฏจักรหรือฤดูกาล โดย SARIMA ประกอบด้วยสองส่วนหลัก ได้แก่ ส่วนไม่เป็นฤดูกาล (p, d, q) และส่วนฤดูกาล (P, D, Q, s) ซึ่ง p คือจำนวนตัวแปรอิสระจากค่าของอดีตที่ใช้มาทำนายค่าปัจจุบัน, d คือจำนวนครั้งที่ทำการหาความต่าง (differencing) เพื่อลดความไม่คงที่ของข้อมูล, และ q คือจำนวนตัวแปรจากค่าความคลาดเคลื่อนในอดีตที่ใช้มาอธิบายค่าปัจจุบัน ส่วนฤดูกาล (P, D, Q, s) มีโครงสร้างคล้ายกัน แต่ใช้กับข้อมูลที่มีรอบฤดูกาล โดยที่ P คือจำนวนค่าของตัวแปรในอดีตตามฤดูกาล, D คือจำนวนครั้งที่ทำ differencing เฉพาะส่วนฤดูกาล, Q คือจำนวนค่าความคลาดเคลื่อนตามฤดูกาล และ s คือความยาวของรอบฤดูกาล เช่น 7 วันสำหรับข้อมูลรายสัปดาห์ หรือ 12 เดือนสำหรับข้อมูลรายปี นอกจากนี้ SARIMA ยังสามารถเพิ่มตัวแปรอธิบายภายนอก (exogenous variables) เพื่อสะท้อนปัจจัยบริบท เช่น วันในสัปดาห์ (week_day) และวันหยุด (holiday) ที่มีผลต่อจำนวนผู้มารับบริการ อีกทั้งยังสามารถเสริมด้วย Fourier terms ซึ่งเป็นการใช้ฟังก์ชันไซน์ (sine) และโคไซน์ (cosine) มาแทนรูปแบบวัฏจักรที่ซับซ้อนหรือมีหลายความถี่พร้อมกัน เช่น ลวดลายรายสัปดาห์ซ้อนกับผลของวันหยุดยาว ทำให้แบบจำลองสามารถอธิบายความผันผวนและฤดูกาลที่ซับซ้อนได้อย่างมีประสิทธิภาพยิ่งขึ้น

4. วิธีดำเนินการวิจัย/ระเบียบวิธีวิจัย/Research Methodology

4.1 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้ในการวิจัยครั้งนี้ประกอบด้วย ฐานข้อมูลการมารับบริการในแผนกฉุกเฉิน ตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2565 รวมทั้งสิ้น 1,096 ระเบียบ ซึ่งเป็นข้อมูลรายวันของจำนวนผู้ป่วยแยกตามระดับความเร่งด่วน (Triage) รวมถึงข้อมูลประกอบด้านเวลา เช่น วัน เดือน วันในสัปดาห์ และสถานะวันหยุด ในการประมวลผลข้อมูลและพัฒนาแบบจำลอง โดยใช้โปรแกรม PyCharm Community Edition ซึ่งเป็นโปรแกรม สำหรับภาษา Python ที่พัฒนาโดยบริษัท JetBrains และสามารถดาวน์โหลดใช้งานได้ฟรี โปรแกรมดังกล่าวถูกใช้ในการสร้างแบบจำลองด้วยเทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Learning) การพยากรณ์เชิงอนุกรมเวลา (Time-Series Forecasting) และการประเมินประสิทธิภาพของแบบจำลองด้วยตัวชี้วัดทาง

สถิติ รวมไปถึงการพัฒนา Dashboard แบบ Interactive เพื่อแสดงผลการพยากรณ์จำนวนผู้ป่วยในแต่ละระดับความรุนแรง และช่วยให้ผู้ใช้งานสามารถนำข้อมูลที่ได้ไปสนับสนุนการวางแผนจัดสรรทรัพยากร การบริหารบุคลากร และการเตรียมพร้อมรับมือปริมาณผู้ป่วยที่คาดการณ์ในอนาคตได้อย่างมีประสิทธิภาพ

4.2 การเก็บรวบรวมข้อมูล

การเก็บรวบรวมข้อมูลจากฐานข้อมูลการมารับบริการในแผนกฉุกเฉินในโรงพยาบาลแห่งหนึ่งตั้งแต่เดือนมกราคม พ.ศ. 2563 - เดือนธันวาคม พ.ศ. 2565 จำนวน 1,096 ระเบียบ โดยข้อมูลประกอบด้วย วันที่มารับบริการ จำนวนผู้ป่วยวิกฤต (Immediately Life-threatening หรือ Resuscitation) จำนวนผู้ป่วยเร่งด่วน (Emergency) จำนวนผู้ป่วยรีบด่วน (Urgency) จำนวนผู้ป่วยกึ่งรีบด่วน (Semi-urgency) จำนวนผู้ป่วยไม่รีบด่วน (Non-urgency) ผู้ป่วยไม่ถูกระบุระดับ (Undefined) วันในสัปดาห์ และสถานะวันหยุด

การจัดประเภทผู้ป่วยในแผนกฉุกเฉินตามระบบ Triage เป็นการจัดลำดับความสำคัญของผู้ป่วยตามระดับความรุนแรงของอาการ และความจำเป็นในการได้รับการรักษาในทันที เพื่อจัดการทรัพยากรทางการแพทย์อย่างมีประสิทธิภาพ ซึ่งแบ่งออกเป็น 5 ระดับหลักได้แก่ 1.ผู้ป่วยวิกฤต (Immediately Life-threatening หรือ Resuscitation) เป็นผู้ป่วยที่ได้รับอาการบาดเจ็บหรือมีอาการป่วยกะทันหัน ซึ่งมีภัยคุกคามต่อชีวิต ซึ่งหากไม่ได้รับการช่วยเหลือทางการแพทย์ในทันทีผู้ป่วยมีโอกาเสียชีวิตได้สูง หรือทำให้เกิดภาวะแทรกซ้อนขึ้นได้อย่างรวดเร็ว 2.ผู้ป่วยเร่งด่วน (Emergency) เป็นผู้ป่วยที่ได้รับบาดเจ็บหรือมีอาการป่วยที่มีภาวะเฉียบพลัน หรือเจ็บป่วยรุนแรงจึงจำเป็นต้องได้รับการช่วยเหลือทางการแพทย์อย่างเร่งด่วนภายใน 10 นาที มิฉะนั้นจะทำให้อาการบาดเจ็บหรืออาการป่วยของผู้ป่วยรุนแรงขึ้นหรือเกิดภาวะแทรกซ้อนขึ้นซึ่งส่งผลให้เสียชีวิตหรือพิการในระยะต่อมาได้ 3.ผู้ป่วยรีบด่วน (Urgency) เป็นผู้ป่วยที่ได้รับบาดเจ็บหรือมีอาการป่วยซึ่งมีภาวะเฉียบพลันไม่รุนแรง อาจรอรับการช่วยเหลือทางการแพทย์ได้ในช่วงระยะเวลา 30 นาที แต่จำเป็นต้องใช้ทรัพยากรและหากปล่อยไว้เกินเวลาอันสมควรแล้วจะทำให้อาการบาดเจ็บหรืออาการของผู้ป่วยฉุกเฉินนั้นรุนแรงขึ้น หรือเกิดภาวะแทรกซ้อนขึ้นได้ 4.ผู้ป่วยกึ่งรีบด่วน (Semi-urgency) เป็นผู้ป่วยที่ไม่ใช่ผู้ป่วยฉุกเฉิน ซึ่งสามารถรอรับบริการได้โดยไม่ก่อให้เกิดอาการที่รุนแรงขึ้น หรือเกิดภาวะแทรกซ้อนตามมาสามารถรอรับบริการได้ 1 ชม. 5.ผู้ป่วยไม่รีบด่วน (Non-urgency) เป็นผู้มารับบริการทางด้านสาธารณสุขหรือบริการอื่นๆ โดยไม่จำเป็นต้องใช้ทรัพยากรสามารถรอได้มากกว่า 1 ชม.

4.3 การวิเคราะห์ข้อมูล

การวิจัยครั้งนี้ผู้วิจัยได้จัดข้อมูลเป็น 2 ชุด โดยที่ข้อมูลในชุดที่ 1 ใช้ข้อมูล 80 % ของข้อมูลทั้งหมดในการสร้างตัวแบบจำลอง และ ส่วนที่ 2 ใช้ข้อมูล 20 % ของข้อมูลทั้งหมดในการตรวจสอบความถูกต้องของตัวแบบ โดยข้อมูลทั้งหมดจะถูกแปลงไฟล์เป็นนามสกุล *.csv เพื่อนำมาใช้ในการวิเคราะห์แบบจำลองที่สร้างขึ้นด้วยภาษา Python ในโปรแกรม PyCharm Community โดยผู้วิจัยได้เลือกอัลกอริทึมที่เกี่ยวข้องกับการทำนายมาใช้งานดังนี้

1.เทคนิคการถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression) เป็นเทคนิคการถดถอยที่รองรับตัวแปรอิสระหลายตัว เพื่อวิเคราะห์ความสัมพันธ์เชิงเส้นและทำนายค่าตัวแปรตามจากปัจจัยหลายด้าน เช่น วันในสัปดาห์ เดือน หรือสถานะวันหยุด ซึ่งมีผลต่อจำนวนผู้ป่วยที่มารับบริการในแต่ละวัน

2.เทคนิคการถดถอยเชิงเส้นพหุนาม (Polynomial Regression) เป็นการขยายความสามารถของ เทคนิคการถดถอยเชิงเส้นหลายตัวแปร ให้รองรับความสัมพันธ์ที่ไม่เป็นเชิงเส้น โดยเพิ่มพจน์กำลังของตัวแปรอิสระทำให้โมเดลสามารถจับความแปรผันที่ซับซ้อนของข้อมูล เช่น ความผันผวนของจำนวนผู้ป่วยรายวันได้ดียิ่งขึ้น


3.เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average: ARIMA) เป็นแบบจำลองที่ใช้ความสัมพันธ์ภายในข้อมูลของตัวแบบเมื่อเวลาผ่านไป (lagged values) เพื่อทำนายค่าในอนาคต เหมาะกับข้อมูลที่มีความต่อเนื่องทางเวลา แต่ไม่มีฤดูกาลเด่นชัด

4.เทคนิคการพยากรณ์แบบ SARIMA (Seasonal ARIMA) เป็นการขยาย ARIMA เพื่อรองรับข้อมูลที่มีฤดูกาล (Seasonality) เช่น รอบสัปดาห์หรือวันหยุดราชการ ซึ่งพบได้ในข้อมูลจำนวนผู้ป่วยของแผนกฉุกเฉิน โมเดล SARIMA มีพารามิเตอร์ $(p,d,q)(P,D,Q)s$ ที่ช่วยจับทั้งความสัมพันธ์เชิงเวลาและความเป็นฤดูกาล ทำให้โมเดลนี้เป็นแบบจำลองที่ให้ความแม่นยำสูงที่สุดในงานวิจัยนี้

5.การนำผลการวิเคราะห์ข้อมูลมาประมวลผลเพื่อเปรียบเทียบประสิทธิภาพในการทำนายผลจำนวนผู้มารับบริการโดยใช้วิธีการถดถอยเชิงเส้นในการนำข้อมูลมาวิเคราะห์เปรียบเทียบว่าวิธีการไหนที่มีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (mean absolute error, MAE) และค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (mean square error, MSE) ที่มีค่าน้อยที่สุด จะทำให้มีประสิทธิภาพในการทำนายที่ดีที่สุด

4.4 การสร้างและประเมินแบบประเมิน

จากการวิเคราะห์ข้อมูลผู้มารับบริการที่นำมาวิจัยมาเข้ากระบวนการจัดเตรียมข้อมูล เพื่อนำมาสร้างแบบจำลองและประเมินประสิทธิภาพของแบบจำลองด้วยการเรียนรู้ของเครื่อง โดยมีผลลัพธ์เป็นแบบจำลองและผลการประเมินประสิทธิภาพของแบบจำลอง ดังรูปที่ 1



รูปที่ 1 ภาพรวมการทำงานของแบบจำลองการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉินโดยใช้การเรียนรู้ของเครื่อง

จากรูปที่ 1 แสดงกระบวนการทำงานของแบบจำลองการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉิน โดยเริ่มจากการนำข้อมูลผู้มารับบริการในแต่ละวันเข้าสู่กระบวนการเตรียมข้อมูล (Data Loading and Preprocessing) ซึ่งประกอบด้วยการแปลงรูปแบบวันที่ การสร้างตัวแปรที่จำเป็น เช่น วันในสัปดาห์และวันหยุดราชการ ตลอดจนการจัดรูปแบบข้อมูลให้พร้อมสำหรับนำไปใช้สร้างแบบจำลองทางสถิติและการเรียนรู้ของเครื่อง หลังจากนั้นจึงเข้าสู่ขั้นตอนการคัดเลือกแบบจำลอง (Model Selection) โดยพิจารณาอัลกอริทึมที่เหมาะสม ได้แก่ Multiple Linear Regression, Polynomial Regression, ARIMA และ SARIMA แล้วทำการฝึกสอน

แบบจำลอง (Model Training) แยกตามระดับความรุนแรงของผู้ป่วย (Triage Levels) เพื่อให้สามารถทำนายจำนวนผู้ป่วยได้อย่างเฉพาะเจาะจงมากที่สุด เมื่อได้ผลลัพธ์แล้วจึงประเมินประสิทธิภาพของแบบจำลองด้วยตัวชี้วัดความแม่นยำ ได้แก่ ค่า Mean Absolute Error (MAE), Mean Squared Error (MSE) และ Root Mean Squared Error (RMSE) เพื่อใช้ในการปรับปรุงและเลือกแบบจำลองที่ให้ค่าความคลาดเคลื่อนน้อยที่สุด แบบจำลองที่ผ่านการประเมินแล้วจะนำไปใช้งานจริงผ่านระบบแดชบอร์ด (Dashboard Deployment) เพื่อแสดงผลการพยากรณ์ปริมาณผู้มารับบริการในแต่ละวัน ซึ่งสามารถใช้เป็นข้อมูลประกอบการวางแผนทรัพยากรด้านบุคลากรและอุปกรณ์ทางการแพทย์ในแผนกฉุกเฉิน

1.การเก็บรวบรวมข้อมูล (data collection)

ทำการรวบรวมข้อมูลปัจจัยที่ส่งผลต่อการพยากรณ์ปริมาณผู้ป่วยรายวันในแผนกฉุกเฉิน โดยแบ่งตามระดับความรุนแรงของผู้ป่วย (Triage Levels) และปัจจัยภายนอก เช่น วันในสัปดาห์ และวันหยุดราชการ เพื่อใช้เป็นข้อมูลนำเข้าในการสร้างแบบจำลอง

2.นำเข้าชุดข้อมูล

กำหนดสัดส่วนการแบ่งข้อมูลสำหรับฝึกสอนและทดสอบแบบจำลองไว้ที่ 80:20 ตามลำดับ จากนั้นดำเนินการปรับรูปแบบวันที่และจัดรูปแบบข้อมูลให้อยู่ในรูปแบบที่สามารถประมวลผลผ่านแบบจำลองได้อย่างเหมาะสม

3.การทดสอบประสิทธิภาพแบบจำลอง

ทำการทดสอบแบบจำลองหลายประเภทสำหรับการพยากรณ์ปริมาณผู้ป่วย โดยนำค่าความคลาดเคลื่อน เช่น MAE, MSE และ RMSE ของแต่ละแบบจำลองมาเปรียบเทียบ เพื่อคัดเลือกแบบจำลองที่ให้ค่าความคลาดเคลื่อนน้อยที่สุด

5. ผลการวิจัยและอภิปรายผลการวิจัย

5.1 การทำนายปริมาณผู้ป่วยรายวันในแผนกฉุกเฉิน

งานวิจัยนี้ดำเนินการพยากรณ์ปริมาณผู้มารับบริการรายวันในแผนกฉุกเฉินโดยใช้ข้อมูลตั้งแต่เดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2565 รวมทั้งสิ้น 1,096 ระเบียบ โดยจำแนกผู้ป่วยตามระดับความเร่งด่วน (Triage) ออกเป็น 6 กลุ่ม ได้แก่ Undefined, Non-Urgent, Semi-Urgency, Urgent, Emergency และ Resuscitation รายละเอียดตัวแปรและคุณลักษณะของข้อมูลแสดงในตารางที่ 1 ซึ่งประกอบด้วยตัวแปรวันที่มารับบริการและจำนวนผู้ป่วยในแต่ละระดับความเร่งด่วน

ตารางที่ 1 ข้อมูลและคุณลักษณะ

ลำดับ	ชื่อคุณลักษณะ	ประเภทข้อมูล	คำอธิบาย
1	visit_date	C	วันที่มารับบริการ (วัน/เดือน/ปี)
2	Undefined	N	จำนวนผู้ป่วยไม่ถูกระบุระดับ (Undefined)
3	Non_Urgent	N	จำนวนผู้ป่วยไม่รีบด่วน (Non-urgency)
4	Semi_Urgency	N	จำนวนผู้ป่วยกึ่งรีบด่วน (Semi-urgency)
5	Urgent	N	จำนวนผู้ป่วยรีบด่วน (Urgency)
6	Emergency	N	จำนวนผู้ป่วยเร่งด่วน (Emergency)
7	Resuscitation	N	จำนวนผู้ป่วยวิกฤต (Immediately Life-threatening หรือ Resuscitation)

หมายเหตุ N = Numerical, C = Categorical

แบบจำลองที่นำมาเปรียบเทียบประกอบด้วย เทคนิคการถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression), เทคนิคการถดถอยเชิงเส้นพหุนาม (Polynomial Regression), เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average: ARIMA) และเทคนิคการพยากรณ์แบบ SARIMA (Seasonal ARIMA) โดยแบ่งข้อมูลออกเป็นชุดฝึก

และชุดทดสอบในอัตราส่วน 80:20 และประเมินประสิทธิภาพด้วยตัวชี้วัดค่าความคลาดเคลื่อน ได้แก่ MAE, MSE และ RMSE ผลการคำนวณค่าความคลาดเคลื่อนของ MLR แสดงในตารางที่ 2

ตารางที่ 2 ค่าความคลาดเคลื่อนจากการทำนายจำนวนผู้มารับบริการโดยใช้เทคนิคการถดถอยเชิงเส้นหลายตัวแปร

Triage	MAE	MSE	RMSE
Resuscitation	0.4067	0.4220	0.6496
Emergency	1.3281	2.7202	1.6493
Urgent	3.9282	24.7174	4.9717
Semi_Urgency	5.0402	43.7662	6.6156
Non_Urgent	4.0315	24.9197	4.9920
Undefine	0.2850	0.2301	0.4797

จากตารางที่ 2 พบว่า เทคนิคการถดถอยเชิงเส้นหลายตัวแปร ให้ค่าความคลาดเคลื่อนค่อนข้างสูงในหลายกลุ่ม โดยเฉพาะกลุ่ม Semi-Urgency และ Urgent ซึ่งมีลักษณะข้อมูลผันผวนสูง สะท้อนให้เห็นว่าความสัมพันธ์ระหว่างตัวแปรต้นกับตัวแปรตามไม่เป็นเชิงเส้น ทำให้แบบจำลองเชิงเส้นพื้นฐานไม่สามารถอธิบายรูปแบบข้อมูลได้อย่างครบถ้วน

5.2 การเพิ่มตัวแปรด้านเวลาและ Polynomial Regression

เพื่อเพิ่มศักยภาพในการอธิบายรูปแบบข้อมูลเชิงเวลา จึงเพิ่มตัวแปรวันในสัปดาห์และสถานะวันหยุด (ดังตารางที่ 3) เข้าเป็นตัวแปรอธิบาย และพัฒนาแบบจำลองด้วย Polynomial Regression ซึ่งมีความยืดหยุ่นในการเรียนรู้ความสัมพันธ์ไม่เป็นเชิงเส้น ผลการประเมินแสดงในตารางที่ 4

ตารางที่ 3 ด้านอนุกรมเวลา

ลำดับ	ชื่อคุณลักษณะ	ประเภทข้อมูล	คำอธิบาย
1	week_day	C	วันในสัปดาห์ (1=จันทร์, 7=อาทิตย์)
2	holiday	C	สถานะวันหยุด (1=ใช่, 0=ไม่ใช่)

หมายเหตุ N = Numerical, C = Categorical

ผลลัพธ์ชี้ให้เห็นว่า Polynomial Regression ให้ค่า MSE และ RMSE ลดลงจาก MLR ในเกือบทุกระดับความเร่งด่วน โดยเฉพาะกลุ่ม Semi-Urgency, Urgent และ Non-Urgent แสดงให้เห็นว่าโมเดลสามารถจับรูปแบบความโค้งและโครงสร้างข้อมูลที่ซับซ้อนกว่าได้อย่างมีประสิทธิภาพ กลุ่ม Undefine แม้มีค่า RMSE เพิ่มขึ้นเล็กน้อย แต่โดยรวมยังอยู่ในระดับต่ำเมื่อเทียบกับกลุ่มอื่น

ตารางที่ 4 ค่าความคลาดเคลื่อนจากการทำนายจำนวนผู้มารับบริการโดยใช้เทคนิคการถดถอยเชิงเส้นพหุนาม

Items	MAE	MSE	RMSE
Resuscitation	0.221	0.221	0.470
Emergency	1.205	2.371	1.540
Urgency	3.746	23.958	4.895
Semi-urgency	3.748	26.001	5.099
Non-urgency	3.802	23.683	4.867
Undefine	0.273	0.237	0.523

5.3 การเปรียบเทียบกับแบบจำลองอนุกรมเวลา (ARIMA และ SARIMA)

เมื่อใช้ ARIMA กับชุดข้อมูลเดียวกัน (ดังตารางที่ 5) พบว่าสามารถให้ผลการพยากรณ์ที่ดีในกลุ่มที่มีความผันผวนต่ำ เช่น Resuscitation และ Undefined อย่างไรก็ตาม ในกลุ่มที่มีความผันผวนสูง เช่น Urgent และ Semi-Urgency ค่า RMSE ยังอยู่ในระดับสูง สะท้อนว่า ARIMA มีข้อจำกัดเมื่อเผชิญข้อมูลที่ไม่นิ่งหรือมีการเปลี่ยนแปลงรวดเร็ว

ตารางที่ 5 ค่าความคลาดเคลื่อนจากการทำนายจำนวนผู้มารับบริการโดยใช้เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่


Items	MAE	MSE	RMSE
Resuscitation	0.7664	0.9368	0.9679
Emergency	1.5647	3.9661	1.9915
Urgent	4.4625	32.7507	5.7228
Semi-Urgency	4.3531	32.6188	5.7113
Non-Urgent	3.6040	20.2860	4.5040
Undefined	0.6512	0.6763	0.8224

สำหรับ SARIMA (ตารางที่ 6) ซึ่งเพิ่มโครงสร้างฤดูกาลรายสัปดาห์เข้าไป พบว่าสามารถลด RMSE ได้เล็กน้อยในบางกลุ่ม เช่น Resuscitation และ Undefined อย่างไรก็ตาม ผลลัพธ์ไม่ได้ปรับดีขึ้นอย่างสม่ำเสมอทุกกลุ่ม โดยเฉพาะ Semi-Urgency และ Non-Urgent ที่ค่า RMSE ยังสูงกว่า ARIMA ในบางช่วง นอกจากนี้ยังพบปัญหาการประมาณค่าพารามิเตอร์ไม่เสถียรในบางรูปแบบ ทำให้การพยากรณ์ไม่สม่ำเสมอเท่าที่ควร

ตารางที่ 6 ค่าความคลาดเคลื่อนจากการทำนายจำนวนผู้มารับบริการโดยใช้เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่เชิงฤดูกาล

Items	MAE	MSE	RMSE
Resuscitation	0.7508	0.8823	0.9393
Emergency	1.5884	4.0253	2.0063
Urgent	4.3248	31.1339	5.5798
Semi-Urgency	4.4357	34.0597	5.8361
Non-Urgent	3.7893	21.9736	4.6876
Undefined	0.5987	0.5339	0.7307

5.4 ความผันผวนของข้อมูลและผลต่อความแม่นยำของแบบจำลอง



รูปที่ 2 กราฟแสดงข้อมูลการมารับบริการ

จากรูปที่ 2 แสดงจำนวนผู้มารับบริการในแผนกฉุกเฉินรายวันในแต่ละระดับความรุนแรงของระบบ Triage ตั้งแต่ปี พ.ศ. 2563 ถึง พ.ศ. 2565 พบว่ากลุ่มผู้ป่วยแต่ละระดับมีรูปแบบความผันผวนของข้อมูลแตกต่างกันอย่างชัดเจน กลุ่ม Resuscitation และ Undefined มีความผันผวนของข้อมูลค่อนข้างต่ำ เนื่องจากเป็นกลุ่มที่มีปริมาณผู้ป่วยต่อวันค่อนข้างคงที่และมีจำนวนไม่มาก ขณะที่กลุ่มที่มีปริมาณผู้ป่วยสูง เช่น Semi-Urgency, Urgency และ Non-Urgent มีจำนวนผู้มารับบริการต่อวันที่แปรผันสูง ทำให้กราฟปรากฏการแกว่งตัวอย่างต่อเนื่องตลอดเวลา เพื่อประเมินระดับความผันผวนของข้อมูลในเชิงปริมาณ ผู้วิจัยได้คำนวณค่าเบี่ยงเบนมาตรฐาน (Standard Deviation; SD) ของข้อมูลในแต่ละระดับความรุนแรงโดยใช้โปรแกรม Microsoft Excel ด้วยคำสั่ง =STDEV.S() ผลลัพธ์สรุปในตารางที่ 7

ตารางที่ 7 ตารางแสดงค่าความผันผวนของข้อมูล

Items	Volatility
Resuscitation	0.553
Emergency	1.715
Urgency	5.939
Semi-urgency	8.036
Non-urgency	4.862
Undefined	0.494

จากตารางที่ 7 จะเห็นได้ว่าระดับความผันผวนของข้อมูลในแต่ละกลุ่มผู้ป่วยมีความแตกต่างกันอย่างชัดเจน โดยเฉพาะกลุ่ม Semi-urgency และ Urgency ซึ่งมีค่า Volatility สูงที่สุด สะท้อนให้เห็นว่าจำนวนผู้มารับบริการในกลุ่มดังกล่าวมีการแกว่งตัวสูงและยากต่อการคาดการณ์ ส่งผลให้การทำนายด้วยแบบจำลองทางสถิติมีความคลาดเคลื่อนมากกว่ากลุ่มอื่น ในทางกลับกัน กลุ่ม Resuscitation และ Undefined มีค่าความผันผวนต่ำ ทำให้ผลการทำนายของแบบจำลองมีแนวโน้มแม่นยำมากกว่า อย่างไรก็ตาม แม้

ระดับความผันผวนจะช่วยอธิบายความยากง่ายในการพยากรณ์ได้ดี แต่ยิ่งพบว่าจำนวนตัวอย่างในแต่ละกลุ่มไม่เท่ากัน โดยเฉพาะกลุ่ม Resuscitation และ Undefined ที่มีจำนวนข้อมูลน้อยเมื่อเทียบกับกลุ่มอื่น ทำให้แบบจำลองเกิดอคติ (Bias) ต่อกลุ่มที่มีข้อมูลมากกว่า เช่น Semi-urgency และ Non-Urgent ส่งผลให้ค่าความคลาดเคลื่อนในภาพรวมยังคงอยู่ในระดับสูง แม้จะเลือกใช้แบบจำลองที่เหมาะสมกับลักษณะของข้อมูลแล้วก็ตาม

เพื่อจัดการกับความซับซ้อนของความสัมพันธ์ระหว่างตัวแปรด้านเวลาและจำนวนผู้ป่วยในแต่ละระดับความรุนแรง ผู้วิจัยจึงประเมินประสิทธิภาพของแบบจำลองเชิงเส้นสองประเภทเพิ่มเติม ได้แก่ เทคนิคการถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression) และเทคนิคการถดถอยเชิงเส้นพหุนาม (Polynomial Regression) โดยทั้งสองโมเดลได้รับการฝึกและทดสอบภายใต้โครงสร้างข้อมูลอนุกรมเวลาเดียวกัน และใช้ตัวแปรด้านเวลา เช่น วันในสัปดาห์ วันหยุด และค่า lag ของจำนวนผู้ป่วยเป็นตัวแปรอธิบายร่วม ผลลัพธ์ของ Multiple Linear Regression แสดงในตารางที่ 8 ซึ่งพบว่าแบบจำลองให้ค่าความคลาดเคลื่อนในระดับปานกลาง โดยเฉพาะในกลุ่มผู้ป่วยที่มีความผันผวนสูง เช่น Semi-Urgency และ Urgent ส่วนผลลัพธ์ของ Polynomial Regression แสดงในตารางที่ 9 ซึ่งพบว่าแบบจำลองสามารถลดค่าความคลาดเคลื่อนในหลายระดับความรุนแรงได้ดีกว่า Multiple Linear Regression โดยเฉพาะในกลุ่มที่มีรูปแบบข้อมูลซับซ้อนหรือมีความไม่เป็นเชิงเส้น ตัวแบบสามารถเรียนรู้ความโค้งหรือรูปแบบที่ซับซ้อนมากขึ้น ส่งผลให้ความแม่นยำโดยรวมดีขึ้น สะท้อนถึงศักยภาพของแบบจำลองพหุนามในการจับรูปแบบข้อมูลที่ซับซ้อนมากกว่าแบบจำลองเชิงเส้นพื้นฐาน

ตารางที่ 8 ผลการประเมินแบบจำลอง Multiple Linear Regression (MLR)

Triage	RMSE	MAE	MSE
Emergency	2.0200	1.5811	4.0803
Non_Urgent	5.6448	4.5879	31.8636
Resuscitation	1.0527	0.7834	1.1083
Semi_Urgency	5.9275	4.4927	35.1348
Undefined	0.4313	0.2526	0.1860
Urgent	6.1720	4.7854	38.0937

ตารางที่ 9 ผลการประเมินแบบจำลอง Polynomial Regression

Triage	RMSE	MAE	MSE
Emergency	2.4057	1.8655	5.7873
Non-Urgent	4.7511	3.8690	22.5725
Resuscitation	1.6981	1.4373	2.8837
Semi-Urgency	6.0549	4.9189	36.6619
Undefined	1.1324	0.9834	1.2824
Urgent	8.5137	6.8411	72.4827

จากตารางที่ 8 และตารางที่ 9 ซึ่งเป็นผลการประเมินแบบจำลองเชิงเส้น ได้แก่ Multiple Linear Regression และ Polynomial Regression พบว่าแบบจำลองทั้งสองยังคงให้ค่าความคลาดเคลื่อนในระดับปานกลาง โดยเฉพาะในกลุ่มผู้ป่วยที่มีความผันผวนสูง เช่น Semi-Urgency และ Urgent ซึ่งทำให้แบบจำลองเชิงเส้นไม่สามารถจับความสัมพันธ์ที่ซับซ้อนของข้อมูลได้อย่างครบถ้วน แม้ Polynomial Regression จะช่วยลดความคลาดเคลื่อนได้ในบางกลุ่ม แต่ประสิทธิภาพโดยรวมยังมีความผันผวนระหว่าง


แต่ละระดับความรุนแรงของผู้ป่วย ส่วนผลลัพธ์ของ Polynomial Regression ก่อนการปรับสมมูลข้อมูลแสดงให้เห็นว่าโมเดลสามารถจับความสัมพันธ์ที่ไม่เป็นเชิงเส้นได้ดีในบางกลุ่ม โดยเฉพาะ Resuscitation และ Emergency ซึ่งมีลักษณะข้อมูลค่อนข้างคงที่และมีความผันผวนต่ำ ทำให้ค่าความคลาดเคลื่อน (RMSE) อยู่ในระดับต่ำ อย่างไรก็ตาม ในกลุ่มที่มีความผันผวนสูง เช่น Semi-Urgency และ Urgent โมเดลยังไม่สามารถอธิบายรูปแบบข้อมูลที่แปรเปลี่ยนรวดเร็วได้อย่างมีประสิทธิภาพ ส่งผลให้ค่าความคลาดเคลื่อนสูงกว่ากลุ่มอื่นอย่างชัดเจน แม้ผลลัพธ์ของกลุ่ม Emergency จะดีขึ้นเล็กน้อยเนื่องจากจำนวนข้อมูลเดิมค่อนข้างน้อย แต่ในหลายกลุ่ม เช่น Non-Urgent, Semi-Urgency และ Urgent ค่า RMSE กลับเพิ่มสูงขึ้นเมื่อเทียบกับค่าเดิม สาเหตุสำคัญคือข้อมูลสังเคราะห์ที่ถูกสร้างขึ้นไม่ได้สะท้อนโครงสร้างของข้อมูลอนุกรมเวลาที่แท้จริง โดยเฉพาะในกลุ่มที่มีความผันผวนสูง ทำให้โมเดลเรียนรู้ข้อมูลที่มีลักษณะเป็น Noise มากขึ้นและส่งผลให้ความแม่นยำลดลงแทนที่จะดีขึ้น

สำหรับแบบจำลอง ARIMA และ SARIMA ซึ่งเป็นโมเดลเชิงอนุกรมเวลา แม้จะถูกออกแบบมาเพื่อรองรับลักษณะการเกิดซ้ำ (recurrence) และฤดูกาล (seasonality) แต่ผลลัพธ์ในงานวิจัยนี้พบว่าความคลาดเคลื่อนในหลายกลุ่มกลับสูงกว่าแบบจำลองเชิงเส้น โดยเฉพาะ Semi-Urgency และ Urgent ซึ่งมีความผันผวนสูงมาก โมเดลอนุกรมเวลามีข้อจำกัดเมื่อข้อมูลมีรูปแบบฤดูกาลไม่ชัดเจน หรือมีความผันผวนสูงแบบไม่สม่ำเสมอ ทำให้ SARIMA ไม่สามารถประมาณค่าพารามิเตอร์ได้อย่างเสถียร และอาจเกิดปัญหาไม่ลู่เข้าสู่คำตอบ (Non-convergence) ส่งผลให้ค่าความคลาดเคลื่อนสูงขึ้นในบางระดับความรุนแรงของผู้ป่วย

5.5 การพัฒนา Dashboard เพื่อประยุกต์ใช้

จากผลการวิเคราะห์ทั้งหมด พบว่าแบบจำลอง Polynomial Regression ให้ผลการพยากรณ์ที่มีความแม่นยำและมีความเสถียรมากกว่าแบบจำลองอนุกรมเวลาในหลายระดับความรุนแรง โดยเฉพาะในกลุ่มที่มีความผันผวนปานกลางถึงต่ำ เช่น Resuscitation, Emergency และ Non-Urgent การใช้ข้อมูลจริงโดยไม่สร้างข้อมูลสังเคราะห์ช่วยให้โมเดลเก็บรักษาลักษณะเชิงเวลาและความต่อเนื่องของข้อมูลได้ดีกว่า ส่งผลให้ค่าความคลาดเคลื่อนต่ำกว่าและมีความเสถียรมากกว่าอย่างชัดเจน ดังนั้น งานวิจัยนี้จึงเลือกใช้ Polynomial Regression แบบไม่ปรับสมมูลข้อมูล เป็นแบบจำลองหลักสำหรับการพยากรณ์ปริมาณผู้มารับบริการรายวัน และนำผลลัพธ์ไปใช้ในการพัฒนา Dashboard เพื่อสนับสนุนการวางแผนทรัพยากรทางการแพทย์ในเดือนถัดไป ดังแสดงในรูปที่ 3

เดือนถัดไป (ค่าทำนายล่วงหน้า): 2023-01



รูปที่ 3 Dashboard แสดงข้อมูลการทำนายจำนวนผู้ป่วย

จากรูปที่ 3 จะเห็นว่าแบบจำลองสามารถประมาณแนวโน้มจำนวนผู้ป่วยในแต่ละระดับความรุนแรงได้อย่างต่อเนื่อง โดยกลุ่มผู้ป่วย Non-Urgent และ Semi-Urgency ยังคงเป็นกลุ่มที่มีจำนวนผู้มารับบริการสูงกว่ากลุ่มอื่น ซึ่งสอดคล้องกับรูปแบบข้อมูลจริงในช่วงปีที่ผ่านมา ขณะที่กลุ่ม Emergency และ Resuscitation มีปริมาณผู้ป่วยน้อยและมีความผันผวนต่ำกว่า แนวโน้มของค่าพยากรณ์สะท้อนรูปแบบรายสัปดาห์ที่พบในข้อมูลจริง เช่น ปริมาณผู้ป่วยที่มักจะเพิ่มขึ้นในช่วงต้นสัปดาห์และลดลงเล็กน้อยในช่วง

ปลายสัปดาห์ รวมถึงความผันผวนเป็นบางช่วงในกลุ่ม Urgent ซึ่งเป็นลักษณะเฉพาะของผู้ป่วยอาการเฉียบพลัน ผลการพยากรณ์ดังกล่าวสามารถช่วยให้แผนกฉุกเฉินคาดการณ์ภาระงานล่วงหน้า วางแผนจัดสรรบุคลากร เต็ม และอุปกรณ์ทางการแพทย์ได้เหมาะสมมากขึ้น และช่วยลดปัญหาความแออัดในช่วงวันที่มีความต้องการสูงได้อย่างมีประสิทธิภาพ

6. สรุปผลการวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์ปริมาณผู้มารับบริการรายวันในแผนกฉุกเฉิน โดยใช้ข้อมูลจำนวน 1,096 ระเบียบ ครอบคลุมช่วงเดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2565 ซึ่งประกอบด้วยผู้ป่วย 6 ระดับความรุนแรง ได้แก่ ผู้ป่วยวิกฤต ผู้ป่วยฉุกเฉิน ผู้ป่วยเร่งด่วน ผู้ป่วยกึ่งเร่งด่วน ผู้ป่วยไม่เร่งด่วน และผู้ป่วยที่ไม่สามารถกำหนดระดับความรุนแรงได้ รวมถึงตัวแปรด้านเวลา ได้แก่ วันในสัปดาห์ เดือน และสถานะวันหยุด เพื่อใช้ในการสร้างแบบจำลองพยากรณ์และสนับสนุนการวางแผนทรัพยากรในแผนกฉุกเฉิน โดยมีการเปรียบเทียบประสิทธิภาพของแบบจำลอง 4 ประเภท ได้แก่ เทคนิคการถดถอยเชิงเส้นหลายตัวแปร (Multiple Linear Regression), เทคนิคการถดถอยเชิงเส้นพหุนาม (Polynomial Regression), เทคนิคการถดถอยอัตโนมัติแบบผสมกับค่าเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average: ARIMA) และเทคนิคการพยากรณ์แบบ SARIMA (Seasonal ARIMA)

ผลการศึกษาพบว่า เทคนิคการถดถอยเชิงเส้นพหุนามให้ผลการพยากรณ์ที่มีความแม่นยำและเสถียรภาพโดยรวมดีที่สุด โดยเฉพาะในกลุ่มผู้ป่วยที่มีความผันผวนต่ำถึงปานกลาง เช่น ผู้ป่วยวิกฤต ผู้ป่วยฉุกเฉิน ผู้ป่วยไม่เร่งด่วน และผู้ป่วยเร่งด่วน ซึ่งสะท้อนถึงความสามารถของแบบจำลองในการจับความสัมพันธ์แบบไม่เป็นเชิงเส้นได้อย่างมีประสิทธิภาพ ขณะที่เทคนิคการถดถอยเชิงเส้นหลายตัวแปร แม้จะให้ผลในระดับยอมรับได้ แต่ยังให้ค่าความคลาดเคลื่อนสูงกว่าเทคนิคการถดถอยเชิงเส้นพหุนามในกลุ่มที่มีรูปแบบข้อมูลซับซ้อนหรือไม่เป็นเชิงเส้นอย่างชัดเจน

สำหรับแบบจำลองอนุกรมเวลาอย่าง ARIMA และ SARIMA พบว่าให้ผลการพยากรณ์ค่อนข้างดีในกลุ่มที่มีความผันผวนต่ำ เช่น ผู้ป่วยวิกฤตและผู้ป่วยที่ไม่สามารถกำหนดระดับได้ แต่มีค่าความคลาดเคลื่อนสูงในกลุ่มที่มีความผันผวนมาก เช่น ผู้ป่วยเร่งด่วน และผู้ป่วยกึ่งเร่งด่วน นอกจากนี้แบบจำลอง SARIMA ยังพบปัญหาการประมาณค่าพารามิเตอร์ไม่ลู่เข้าในบางกรณี ส่งผลให้แบบจำลองมีความไม่เสถียรและไม่สามารถให้ผลลัพธ์ที่ดีกว่าเทคนิคการถดถอยเชิงเส้นพหุนามได้อย่างสม่ำเสมอ ดังตารางที่ 10

ตารางที่ 10 ตารางเปรียบเทียบค่าความคลาดเคลื่อนกับค่าความผันผวนของข้อมูล

ระดับ Triage	MLR RMSE	Polynomial RMSE	ARIMA RMSE	SARIMA RMSE
Undefine	0.4797	0.5225	0.8224	0.7307
Non-Urgent	4.9920	4.9101	4.5040	4.6876
Semi-Urgency	6.6156	5.3972	5.7113	5.8361
Urgent	4.9717	4.8947	5.7228	5.5798
Emergency	1.6493	1.5568	1.9915	2.0063
Resuscitation	0.6496	0.4699	0.9679	0.9393

จากตารางที่ 10 แสดงการเปรียบเทียบแบบจำลองทั้งหมด พบว่าไม่สามารถระบุแบบจำลองเพียงวิธีเดียวที่เหมาะสมกับข้อมูลทุกระดับความรุนแรงได้ อย่างไรก็ตาม เทคนิคการถดถอยเชิงเส้นพหุนามแสดงศักยภาพสูงที่สุดในการพยากรณ์ข้อมูลที่มีความผันผวนและความไม่เป็นเชิงเส้นในระดับปานกลาง จึงสามารถสรุปได้ว่า Polynomial Regression เป็นแบบจำลองที่เหมาะสมที่สุด

สำหรับบริบทข้อมูลของงานวิจัยนี้ โดยผลลัพธ์สามารถนำไปใช้สนับสนุนการวางแผนทรัพยากรทางการแพทย์และการบริหารจัดการในแผนกฉุกเฉินได้อย่างมีประสิทธิภาพ

7. ข้อเสนอแนะ

7.1 การเพิ่มตัวแปรอธิบาย

งานวิจัยนี้ใช้ตัวแปรด้านเวลาเป็นหลัก ได้แก่ วัน เดือน วันในสัปดาห์ และสถานะวันหยุด ซึ่งสามารถสะท้อนรูปแบบเชิงเวลาได้ในระดับหนึ่ง อย่างไรก็ตาม ในอนาคตควรพิจารณาเพิ่มตัวแปรภายนอกที่อาจมีผลต่อจำนวนผู้ป่วย เช่น สภาพอากาศ อุณหภูมิ ฤดูกาล การระบาดของโรค หรือเหตุการณ์พิเศษ เพื่อเพิ่มความแม่นยำของแบบจำลอง โดยเฉพาะในกลุ่มที่มีความผันผวนสูง เช่น ผู้ป่วยเร่งด่วนและผู้ป่วยกึ่งเร่งด่วน

7.2 การพัฒนาแบบจำลองที่รองรับความผันผวนของข้อมูล

จากผลการศึกษาพบว่าความผันผวนของข้อมูลเป็นปัจจัยสำคัญที่มีผลต่อความแม่นยำของการพยากรณ์ ดังนั้น ควรพิจารณาเทคนิคการสร้างแบบจำลองที่สามารถรองรับความแปรปรวนของข้อมูลได้ดียิ่งขึ้น เช่น การใช้แบบจำลองเชิงความน่าจะเป็น (Probabilistic Models), การถดถอยเชิงควอนไทล์ (Quantile Regression) หรือการวิเคราะห์ความแปรปรวนไม่คงที่ (Heteroscedasticity Modeling) เพื่อให้การพยากรณ์มีความยืดหยุ่นและสะท้อนความไม่แน่นอนของข้อมูลได้ดียิ่งขึ้น

7.3 การประยุกต์ใช้แบบจำลองเชิงลึก (Deep Learning)

แม้แบบจำลองที่ใช้ในงานวิจัยนี้สามารถให้ผลลัพธ์ในระดับที่น่าพอใจ แต่ยังมีข้อจำกัดในการรองรับรูปแบบข้อมูลที่มีความซับซ้อนและผันผวนสูง โดยเฉพาะในกลุ่มข้อมูลที่มีลักษณะไม่สม่ำเสมอ ดังนั้น การประยุกต์ใช้แบบจำลองเชิงลึก เช่น LSTM, GRU หรือ Transformer สำหรับข้อมูลอนุกรมเวลา ควบคู่กับการพัฒนาแบบจำลองเชิงผสมผสาน (Hybrid Models) เช่น SARIMA-LSTM หรือ CNN-LSTM อาจช่วยเพิ่มประสิทธิภาพการพยากรณ์ได้ อย่างไรก็ตาม การใช้งานเทคนิคดังกล่าวจำเป็นต้องพิจารณาความพร้อมของข้อมูลและทรัพยากรคอมพิวเตอร์ให้เหมาะสมกับบริบทของโรงพยาบาล

8. กิตติกรรมประกาศ

ข้าพเจ้าขอขอบคุณมหาวิทยาลัยสุโขทัยธรรมาธิราช รวมทั้งคณาจารย์ในแขนงวิชาเทคโนโลยีดิจิทัล ที่ได้มอบองค์ความรู้ เครื่องมือ และแนวทางในการทำวิจัยอย่างเป็นระบบ อันเป็นพื้นฐานสำคัญที่ช่วยให้ข้าพเจ้าสามารถดำเนินการศึกษาค้นคว้าในครั้งนี้ได้อย่างถูกต้องและครบถ้วน

ข้าพเจ้าขอขอบคุณหน่วยงานด้านสาธารณสุขที่ได้อนุญาตให้นำข้อมูลทางสถิติที่เกี่ยวข้องมาใช้ในการวิเคราะห์และพัฒนาแบบจำลอง โดยข้อมูลทั้งหมดได้ผ่านการปกปิดข้อมูลส่วนบุคคล (de-identification) และดำเนินการตามหลักจริยธรรมในการใช้ข้อมูลอย่างเคร่งครัด เพื่อให้มั่นใจว่าข้อมูลที่ใช้ไม่สามารถระบุตัวบุคคลได้

9. เอกสารอ้างอิง

- กระทรวงสาธารณสุข. (2566). คู่มือการประเมินโรงพยาบาลอัจฉริยะ (พิมพ์ครั้งที่ 4). กรุงเทพมหานคร: กระทรวงสาธารณสุข.
- คชาภรณ์ ศรีพารัตน์, และวัฒนา ชยธวัช. (2567). การพยากรณ์อัตราผู้สูงอายุที่มีปัญหาความเครียดในจังหวัดลพบุรี. วารสารสถาบันจิตเวชศาสตร์สมเด็จพระยา, 18(2), 30–38.
- ณพฐ์ โสภีพันธ์. (2564). การประเมินมูลค่าความเสี่ยงในการลงทุนในทองคำโดยใช้แบบจำลอง ARIMA-GARCH. วารสารวิจัยวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครราชสีมา, 6(2), 45–55.

ณพฐ์ โสภีพันธ์, นฤเบศ ลาภยิ่งยง, ชนิษฐา ชมภูวิเศษ, วิวรรณ กาญจนวจิ, สุภาวดี สุวธิรรมา, และนิภาดา จรัสเอี่ยม. (2567). การพยากรณ์ปริมาณน้ำฝนโดยใช้เทคนิคการปรับให้เรียบ เทคนิค ARIMA และเทคนิค Support Vector Machine. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครราชสีมา, 9(1), 34–45.

ณัฐพัชร์ วณิชย์กุล. (2566). การประยุกต์เทคนิคการพยากรณ์สำหรับการวางแผนความต้องการเตียงผู้ป่วย: กรณีศึกษาแผนกอายุรกรรม โรงพยาบาลศรีสะเกษ. วารสารสหศาสตร์ศรีปทุม ชลบุรี, 9(2), 45–60.

นงเยาว์ ในอรุณ. (2564). การเปรียบเทียบประสิทธิภาพของแบบจำลองการทำนายความเสี่ยงโรคหัวใจและหลอดเลือดโดยใช้อัลกอริธึมเหมือนข้อมูล. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม, 40(2), 45–55.

พรทิพา วิเศษสุรอรธ. (2564). ระบบวิเคราะห์ข้อมูลอนุกรมเวลาด้วยเทคนิคทางสถิติและการเรียนรู้ของเครื่อง. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ, มหาวิทยาลัยธุรกิจบัณฑิต.

สายชล สันสมบุรณ์ทอง. (2561). การเปรียบเทียบประสิทธิภาพในการทำนายผลการเป็นโรคเบาหวาน. วารสารวิทยาศาสตร์และเทคโนโลยี, 26(2), 12–18.

สุรัตน์ รุ่งสว่าง. (2561). พยาบาลคัดแยกประเภทผู้ป่วย: จากกระบวนการหลักสู่การปฏิบัติ. วารสารวิชาการสุขภาพภาคเหนือ, 5(2), 45–55.

Boyle, J., Jessup, M., Crilly, J., Green, D., Lind, J., Wallis, M., & Fitzgerald, G. (2012). Predicting emergency department crowding using time-series analysis. *American Journal of Emergency Medicine*, 176(6), 540–548.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning*. New York, NY: Springer.

Lawrance, A. J. (2013). Exploratory graphics for financial time series volatility. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 62(5), 669–686.

Montgomery, D. C., Peck, E. A., & Vining, G. G. (2012). *Introduction to linear regression analysis* (5th ed.). Hoboken, NJ: Wiley.

Sakchan, L., & Boonlueo, N. (2021). Studying characteristics of Huay Saneng and predicting water levels by comparison with regression models. *Information Technology Journal*, 17(2), 34–45.

Zarei, E., Daneshkohan, A., Pouragha, B., Marzban, S., & Arab, M. (2015). An empirical study of the impact of service quality on patient satisfaction in private hospitals. *Global Journal of Health Science*, 7(1), 1–9.

ประวัติผู้เขียนบทความ



นาย ชนาธิป ฉัตรวิไลลักษณ์

แขนงวิชาเทคโนโลยีดิจิทัล, สาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช

บางพูด ปากเกร็ด นนทบุรี 11120

ที่อยู่ 80/5 ม.3 ต.ห้วยถั่วเหนือ อ.หนองบัว จ.นครสวรรค์ 60110

โทรศัพท์ 0894398647

E-mail n.chanatip@hotmail.com

งานวิจัยที่สนใจ เกี่ยวกับปัญญาประดิษฐ์(AI) และการเรียนรู้ของเครื่อง(Machine Learning)



รองศาสตราจารย์ ดร.วณิชยา ร่มสายหยุด

แขนงวิชาเทคโนโลยีดิจิทัล, สาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช

บางพูด ปากเกร็ด นนทบุรี 11120

โทรศัพท์ 025048191-3

E-mail walisa.rom@stou.ac.th

งานวิจัยที่สนใจ เกี่ยวกับปัญญาประดิษฐ์(AI) และการเรียนรู้ของเครื่อง(Machine Learning)