

ปัจจัยทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน

โดยใช้เทคนิคเหมืองข้อมูลในบริบทโรงพยาบาลชุมชน

Predictive Factors Associated with Access to Stroke Fast-Track Services:

A Data Mining Approach in Community Hospital Settings

วีระชัย สมอมอบ¹, สุปราณี โจน์สุพร^{1*}, กริช สมกันธา², หัตถยา โพธิวงษ์³

Wirachai Samomop¹, Supranee Rojsupon¹, Krit Somkantha², Hatthaya Potiwong³

วิทยาลัยพยาบาลบรมราชชนนีนี อุดรธานี คณะพยาบาลศาสตร์ สถาบันพระบรมราชชนก¹, มหาวิทยาลัยราชภัฏอุดรธานี², โรงพยาบาลบ้านผือ³

Boromarajonani College of Nursing, Udon Thani, Faculty of Nursing, Praboromarajchanok Institute¹,

Udon Thani Rajabhat University², Banphue hospital³

(Received: 17 June 2026; Revised: 11 August 2026; Accepted: 24 August 2026)

บทคัดย่อ

การวิจัยครั้งนี้เป็นงานวิจัยเชิงวิเคราะห์แบบย้อนหลัง มีวัตถุประสงค์เพื่อวิเคราะห์ปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ภายใน 4.5 ชั่วโมง โดยประยุกต์ใช้เทคนิคเหมืองข้อมูล กลุ่มตัวอย่างคือผู้ป่วยโรคหลอดเลือดสมองที่เข้ารับการรักษาในโรงพยาบาลบ้านผือ จังหวัดอุดรธานี จำนวน 424 ราย เครื่องมือที่ใช้ในการวิจัยประกอบด้วย ฐานข้อมูลเวชระเบียนอิเล็กทรอนิกส์ และรายงานโรคหลอดเลือดสมองของโรงพยาบาล วิเคราะห์ข้อมูลโดยใช้อัลกอริทึมการเรียนรู้ของเครื่อง 3 วิธี ได้แก่ k-Nearest Neighbors (KNN), Naïve Bayes และ Random Forest ทดสอบประสิทธิภาพของแบบจำลองด้วยวิธีการทดสอบแบบไขว้ 10 ส่วน และประเมินผลด้วยค่าความแม่นยำ (Classification Accuracy: CA) ความไว (Recall) ความจำเพาะ (Specificity) และพื้นที่ใต้เส้นโค้ง ROC (AUC) ผลการวิจัยพบว่า กลุ่มตัวอย่างส่วนใหญ่เป็นเพศชาย ร้อยละ 60.14 ได้รับการวินิจฉัยเป็นโรคหลอดเลือดสมองตีบ/อุดตัน ร้อยละ 85.38 และสามารถเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนทันภายใน 4.5 ชั่วโมง ร้อยละ 51.18 เมื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง พบว่า Naïve Bayes มีประสิทธิภาพสูงที่สุด (CA = 71.7%, Recall = 71.7% Specificity = 71.9% และค่า AUC เท่ากับ 0.787) ปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ได้แก่ ชนิดของโรคหลอดเลือดสมอง ตาบลงของผู้ป่วย และระยะเวลาที่ใช้ในการเดินทางจากบ้านมายังโรงพยาบาล ผลการศึกษาชี้ให้เห็นถึงศักยภาพของเทคนิคเหมืองข้อมูลในการวิเคราะห์และทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ซึ่งสามารถนำไปใช้เป็นข้อมูลสนับสนุนการวางแผนพัฒนาระบบบริการสุขภาพ การปรับปรุงการเข้าถึงบริการในพื้นที่ห่างไกล และการตัดสินใจเชิงนโยบายด้านสุขภาพในระดับชุมชนได้อย่างเหมาะสม

คำสำคัญ: โรคหลอดเลือดสมอง, บริการช่องทางด่วน, เทคนิคเหมืองข้อมูล, การเรียนรู้ของเครื่อง

*ผู้ให้การติดต่อ (Corresponding e-mail: supraneeink@bcnu.ac.th, สุปราณี โจน์สุพร)

Abstract

This retrospective analytical study employed data mining techniques to identify key predictive factors influencing stroke fast-track service access within 4.5 hours. The study sample consisted of 424 stroke patients who received treatment at Ban Phue Hospital, Udon Thani Province, Thailand. Research instruments included electronic medical record databases, and hospital stroke reports. Data were analyzed using three machine learning algorithms: k-Nearest Neighbors (KNN), Naïve Bayes, and Random Forest. Model performance was evaluated using 10-fold cross-validation and assessed by Classification Accuracy (CA), Recall, Specificity, and the Area Under the Receiver Operating Characteristic Curve (AUC). The majority of participants were male (60.14%), with 85.38% diagnosed with ischemic stroke; notably, 51.18% accessed stroke fast-track services within the 4.5-hour window. Comparison of model performance revealed that Naïve Bayes achieved the highest predictive performance, with a Classification Accuracy of 71.7%, Recall of 71.7%, Specificity of 71.9%, and an AUC of 0.787. The most important predictors of timely access included stroke type, patient's subdistrict of residence, and travel time to the hospital. The findings demonstrate the potential of data mining techniques for analyzing and predicting access to stroke fast-track services. These findings may support healthcare service planning, improve access to care in remote areas, and inform community-level health policy decision-making.

Keywords: Stroke, Fast-track Services, Data Mining, Machine Learning

บทนำ

โรคหลอดเลือดสมอง (Stroke) เป็นภาวะฉุกเฉินทางระบบประสาทที่เกิดจากการขาดเลือดหรือเลือดออกในสมอง ส่งผลให้เนื้อเยื่อสมองตายในบริเวณที่เลือดไปเลี้ยงถูกขัดขวาง และเป็นสาเหตุสำคัญของการเสียชีวิตและความพิการทั่วโลกอย่างต่อเนื่อง องค์การอนามัยโลกรายงานว่าโรคหลอดเลือดสมองเป็นหนึ่งในสาเหตุหลักของการเสียชีวิตและความพิการ โดยในปี 2021 พบผู้ป่วยโรคหลอดเลือดสมองสะสมกว่า 93.8 ล้านคนทั่วโลก และมีผู้ป่วยรายใหม่ประมาณ 11.9 ล้านคนต่อปี ซึ่งส่วนใหญ่เกิดในประเทศรายได้ต่ำและรายได้ปานกลางที่มีทรัพยากรระบบสุขภาพจำกัด (Feigin et al., 2025) ในประเทศไทย มีผู้ป่วยโรคหลอดเลือดสมองสะสม 407,976 ราย (กระทรวงสาธารณสุข, 2569) ซึ่งส่งผลกระทบต่ออย่างรุนแรงต่อคุณภาพชีวิตของผู้ป่วยและสร้างภาระทางเศรษฐกิจแก่ครอบครัวและระบบบริการสุขภาพอย่างมหาศาล แม้ในปัจจุบันความก้าวหน้าทางการแพทย์จะสามารถพัฒนาระบบบริการช่องทางด่วนโรคหลอดเลือดสมอง (Stroke Fast-Track) เพื่อให้ผู้ป่วยได้รับยาละลายลิ่มเลือดชนิดฉีด (rt-PA) ภายในระยะเวลาทอง (Golden Period) 4.5 ชั่วโมง ตามแนวทางของ American Heart Association/American Stroke Association (AHA/ASA)

(Prabhakaran et al., 2026) แต่จากข้อมูลสถิติที่ผ่านมายังคงพบว่ามีผู้ป่วยจำนวนมากที่ไม่สามารถเข้าถึงบริการได้ตามเกณฑ์เวลาที่กำหนด

เขตสุขภาพที่ 8 มีการพัฒนาระบบบริการโรคหลอดเลือดสมองอย่างต่อเนื่อง แต่รายงานโรคหลอดเลือดสมองในปีงบประมาณ 2568 พบอัตราการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมง เพียงร้อยละ 30.90 (เขตสุขภาพที่ 8, 2569) จึงมีการส่งเสริมการเข้าถึงบริการดังกล่าว โดยการเพิ่มศักยภาพของโรงพยาบาลต่าง ๆ ในเขตสุขภาพ โดยเฉพาะโรงพยาบาลชุมชน ในจังหวัดอุดรธานี ให้มีศักยภาพในการวินิจฉัย และให้ยาละลายลิ่มเลือดชนิดฉีดได้อย่างทั่วถึง เช่น โรงพยาบาลเพ็ญ โรงพยาบาลสมเด็จพระยุพราชบ้านดุง โรงพยาบาลหนองหาน และโรงพยาบาลบ้านผือ เพื่อกระจายจุดบริการให้ครอบคลุมทุกเครือข่ายอำเภอ

ในบริบทของโรงพยาบาลบ้านผือ จังหวัดอุดรธานี ซึ่งเป็นโรงพยาบาลชุมชน ให้บริการครอบคลุมพื้นที่อำเภอบ้านผือ ซึ่งเป็นอำเภอที่มีขนาดใหญ่เป็นอันดับต้น ๆ ของจังหวัดอุดรธานี มีความซับซ้อนของพื้นที่และลักษณะประชากร การเข้าถึงบริการจึงไม่ได้ขึ้นอยู่กับปัจจัยด้านระยะทางเพียงอย่างเดียว แต่ยังมีความสัมพันธ์พหุปัจจัย ที่สลับซับซ้อน ทั้งด้านปัจจัยส่วนบุคคล เช่น เพศ (Potisopha et al., 2020) อายุ (Lee et al., 2024) ปัจจัยด้านโรคประจำตัวที่ส่งผลต่อความรุนแรงของโรค (Rakchue P. & Poonphol S., 2019) ประสบการณ์การป่วยด้วยโรคหลอดเลือดสมอง (Yoon et al., 2022) และปัจจัยเชิงระบบ เช่น ระยะทางไปโรงพยาบาล (Butdee et al., 2023) ระยะเวลาการเดินทางไปโรงพยาบาล (Tansuwannarat et al., 2021) การเข้าถึงบริการการแพทย์ฉุกเฉิน (Rakchue & Poonphol, 2019; Yoon et al., 2022) ซึ่งการวิเคราะห์ข้อมูลด้วยสถิติเชิงพรรณนาแบบดั้งเดิมมักทำได้เพียงการระบุปัจจัยเดียวที่มีผลต่อการเข้าถึงบริการ แต่ยังมีข้อจำกัดในการอธิบายรูปแบบความสัมพันธ์เชิงลึก หรือปฏิสัมพันธ์ระหว่างตัวแปรหลายตัวที่ส่งผลร่วมกันต่อการตัดสินใจเข้าสู่ระบบบริการโรคหลอดเลือดสมองแบบช่องทางด่วนได้อย่างมีประสิทธิภาพ

แม้โรงพยาบาลจะมีการจัดเก็บข้อมูลเวชระเบียนอิเล็กทรอนิกส์อย่างต่อเนื่อง แต่ส่วนใหญ่ถูกนำมาใช้เพียงการสรุปรายงานเชิงพรรณนาเท่านั้น จากการทบทวนวรรณกรรมที่ผ่านมา พบว่าการศึกษาปัจจัยที่มีผลต่อการเข้าถึงบริการหรือความล่าช้าในการรักษาของผู้ป่วยโรคหลอดเลือดสมอง ส่วนใหญ่ยังคงใช้วิธีการวิเคราะห์ด้วยสถิติเชิงพรรณนาหรือสถิติถดถอยแบบดั้งเดิม เช่น Logistic Regression (Butdee et al., 2023; Potisopha et al., 2020; Rakchue & Poonphol, 2019) ซึ่งแม้จะระบุปัจจัยเดียวได้ แต่ยังมีข้อจำกัดในการอธิบายรูปแบบความสัมพันธ์เชิงซ้อน หรือปฏิสัมพันธ์พหุปัจจัยที่ไม่เป็นเชิงเส้นระหว่างปัจจัยด้านบุคคล ปัจจัยด้านโรคประจำตัว และปัจจัยด้านระบบบริการ ปัจจุบันมีการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ผ่านเทคนิคเหมืองข้อมูล (Data Mining) ซึ่งเป็นนวัตกรรมที่มีความจำเป็นอย่างยิ่ง เนื่องจากเป็นเทคนิคที่มีประสิทธิภาพสูง (Nonsiri et al., 2023; Sutanon, 2025) ในการจำแนกประเภทข้อมูลและระบุปัจจัยทำนายสำคัญ พบการใช้ในการทำนายโอกาสเกิดโรคหลอดเลือดสมอง (Liu et al., 2023) การทำนายการวินิจฉัยโรคหลอดเลือดสมองและโรคเบาหวาน (Ngoc-Bich Le et al., 2024) การทำนายอุปสรรคการเข้าถึงบริการสุขภาพ (Chansiri et al., 2025) แต่ยังมีข้อจำกัดในการใช้วิเคราะห์ข้อมูลโดยเทคนิคเหมืองข้อมูลในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมอง ในบริบทของโรงพยาบาลชุมชน ซึ่งเทคโนโลยีในปัจจุบัน

มีโปรแกรมที่ช่วยวิเคราะห์ข้อมูล เช่น โปรแกรม XGBoost โปรแกรม LightGBM โปรแกรม Orange AI หรือโปรแกรมอื่น ๆ (Caroline & Rachmat, 2025; Wartika & Agus, 2025)


การนำข้อมูลทุติยภูมิจากระบบเวชระเบียนและฐานข้อมูลสุขภาพที่มีอยู่เดิมในโรงพยาบาลมาวิเคราะห์ด้วยเทคนิคเหมืองข้อมูล จะช่วยให้ผู้วิจัยสามารถค้นหารูปแบบความสัมพันธ์ของปัจจัยและเงื่อนไขที่เกี่ยวข้องกับการเข้าถึงบริการจริงในพื้นที่ได้อย่างแม่นยำ ซึ่งผลการศึกษาดังกล่าวจะนำไปใช้เป็นฐานข้อมูลเชิงประจักษ์ในการกำหนดกลุ่มเป้าหมายที่มีแนวโน้มไม่สามารถเข้าถึงบริการได้ทันเวลา เพื่อวางแผนการให้สุขศึกษา การเฝ้าระวัง และการส่งเสริมการรับรู้สัญญาณเตือนของโรคหลอดเลือดสมองอย่างเฉพาะเจาะจงตามลักษณะความเสี่ยงของแต่ละกลุ่มประชากร แนวทางดังกล่าวจะช่วยให้การบริหารจัดการทรัพยากรทางสุขภาพที่มีอยู่อย่างจำกัดสามารถดำเนินไปอย่างตรงจุดและมีประสิทธิภาพสูงสุด ผลจากการศึกษานี้ไม่เพียงแต่จะใช้เป็นหลักฐานเชิงประจักษ์เกี่ยวกับปัจจัยที่ส่งผลต่อการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนเท่านั้น แต่ยังเป็นต้นแบบในการใช้ข้อมูลดิจิทัลที่จัดเก็บอยู่เดิมในโรงพยาบาลมาสร้างองค์ความรู้ใหม่ เพื่อนำไปสู่การพัฒนานโยบายและปรับปรุงกระบวนการดูแลผู้ป่วยโรคหลอดเลือดสมองให้มีประสิทธิภาพสูงสุด ลดอัตราการตายและความพิการ และเพิ่มขีดความสามารถของระบบบริการสุขภาพในระดับชุมชนให้มีความเข้มแข็งและสอดคล้องกับบริบทเชิงพื้นที่ต่อไป

วัตถุประสงค์การวิจัย

1. เพื่ออธิบายลักษณะข้อมูลด้านปัจจัยส่วนบุคคล ด้านโรคประจำตัว และด้านระบบบริการของผู้ป่วยโรคหลอดเลือดสมอง โรงพยาบาลบ้านฝื่อ จังหวัดอุดรธานี
2. เพื่อวิเคราะห์ปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนด้วยเทคนิคเหมืองข้อมูล

กรอบแนวคิดการวิจัย

การวิจัยครั้งนี้มุ่งศึกษาข้อมูลด้านปัจจัยส่วนบุคคล ด้านโรคประจำตัว และด้านระบบบริการที่ส่งผลต่อการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ของผู้ป่วยโรคหลอดเลือดสมอง โรงพยาบาลบ้านฝื่อ จังหวัดอุดรธานี ดังแสดงในภาพที่ 1



ภาพที่ 1 กรอบแนวคิดการวิจัย

ระเบียบวิธีวิจัย

โครงการวิจัยนี้เป็นการวิจัยเชิงวิเคราะหย้อนหลัง (Retrospective Study) จากข้อมูลระบบเวชระเบียนอิเล็กทรอนิกส์ โปรแกรม HOSxP และรายงานโรคหลอดเลือดสมองโรงพยาบาลบ้านผือ ที่เข้ารับบริการระหว่างวันที่ 1 มกราคม 2565 ถึง 31 ธันวาคม 2568 จำนวน 631 ราย เพื่อวิเคราะห์ปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนด้วยเทคนิคเหมืองข้อมูล

ประชากรและกลุ่มตัวอย่าง

1. ประชากร คือ ผู้ป่วยโรคหลอดเลือดสมองทั้งเพศชายและหญิง อายุ 18 ปีขึ้นไป ที่เข้ารับบริการในโรงพยาบาลบ้านผือ จังหวัดอุดรธานี และมีการบันทึกข้อมูลในระบบเวชระเบียนอิเล็กทรอนิกส์ โปรแกรม HOSxP และรายงานโรคหลอดเลือดสมองโรงพยาบาลบ้านผือ ระหว่างวันที่ 1 มกราคม 2565 ถึง 31 ธันวาคม 2568 โดยได้รับการวินิจฉัยตามรหัส ICD-10 ระหว่าง I60-I69 ทั้งนี้ ในกรณีผู้ป่วยได้รับการวินิจฉัยซ้ำหลังจากระยะเวลา 28 วันขึ้นไป จะถูกนับเป็นผู้ป่วยรายใหม่อีกครั้ง

2. กลุ่มตัวอย่าง คือ ผู้ป่วยโรคหลอดเลือดสมองทั้งเพศชายและหญิง อายุ 18 ปีขึ้นไป ที่เข้ารับการรักษาโรงพยาบาลบ้านผือ จังหวัดอุดรธานี และได้รับการดูแลตามระบบบริการของโรงพยาบาลบ้านผือโดยตรง โดยไม่รวมผู้ป่วยที่ได้รับการส่งต่อมาจากโรงพยาบาลชุมชนอื่น หรือผู้ป่วยที่ได้รับการวินิจฉัยโรคหลอดเลือดสมองระหว่างการรักษาในโรงพยาบาลบ้านผือด้วยโรคอื่น รวมจำนวน 631 ราย

3.เกณฑ์คัดเข้า (Inclusion Criteria)



3.1 มีข้อมูลบันทึกในระบบ HOSxP และรายงานโรคหลอดเลือดสมองของโรงพยาบาลบ้านผือ จังหวัดอุดรธานี

3.2 ได้รับการประเมินผลการเข้ารับบริการโรคหลอดเลือดสมองแบบช่องทางด่วน

4.เกณฑ์คัดออก (Exclusion Criteria)

4.1 ข้อมูลในระบบฐานข้อมูลไม่ครบถ้วนหรือขาดข้อมูลตัวแปรสำคัญที่ใช้ในการวิเคราะห์เครื่องมือที่ใช้ในการวิจัย

เครื่องมือเก็บรวบรวมข้อมูล

1. โปรแกรมเวชระเบียนอิเล็กทรอนิกส์ ชื่อโปรแกรม โปรแกรม Hospital Operating System for Primary Care Units (HOSxP) version 3 ของโรงพยาบาลบ้านผือ จังหวัดอุดรธานี ใช้สำหรับสืบค้นและดึงข้อมูลทุติยภูมิจากเวชระเบียนผู้ป่วยโรคหลอดเลือดสมอง

2. โปรแกรมบันทึกและจัดการข้อมูล ได้แก่ โปรแกรมสำเร็จรูปแบบออนไลน์ ชื่อโปรแกรม Google Sheet ใช้เป็นเครื่องมือสำหรับบันทึกข้อมูลที่ได้จากระบบ HOSxP และรายงานโรคหลอดเลือดสมองของโรงพยาบาลบ้านผือ โดยทำหน้าที่เป็นฐานข้อมูลกลางสำหรับการตรวจสอบความถูกต้อง ความครบถ้วน การจัดรูปแบบข้อมูล และการเตรียมข้อมูล ก่อนนำเข้าวิเคราะห์ด้วยเทคนิคเหมืองข้อมูล โดยดำเนินการทวนสอบข้อมูลไขว้ระหว่าง 2 ฐานข้อมูล หากพบชุดข้อมูลที่มีการลงบันทึกไม่สมบูรณ์ ขาดตัวแปรสำคัญ หรือข้อมูลไม่ตรงกัน จะถูกคัดออกจากโครงการวิจัยตามเกณฑ์คัดออก และป้องกันความคลาดเคลื่อนในการส่งถ่ายข้อมูล โดยคณะผู้วิจัยได้กำหนดมาตรการควบคุมคุณภาพข้อมูล โดยใช้วิธีสกัดข้อมูลออกจากระบบ HOSxP ในรูปแบบไฟล์โครงสร้าง นามสกุล .csv/xlsx ผ่านชุดคำสั่ง Query Statement ที่ผ่านการตรวจสอบโดยนักวิชาการคอมพิวเตอร์เพื่อลดข้อผิดพลาดจากการคีย์ข้อมูลด้วยมือ ร่วมกับการกำหนดกฎตรวจสอบความถูกต้องของข้อมูลบน Google Sheet โดยผู้วิจัย 2 ท่านทำการสุ่มตรวจทานข้อมูล ร้อยละ 20 ของชุดข้อมูลทั้งหมด เพื่อยืนยันความถูกต้องตรงกันกับข้อมูลต้นทาง ก่อนนำเข้าสู่กระบวนการเตรียมข้อมูลเพื่อการวิเคราะห์ต่อไป

ประยุกต์ใช้การวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล 3 วิธีการ โดยจะทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) ได้แก่ วิธีการเพื่อนบ้านที่ใกล้เคียงที่สุดจำนวน K ตัว (KNN), วิธีการนาอิฟเบย์ (Naïve Bayes) และวิธีการป่าสุ่ม (Random Forest) เพื่อทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน โดยใช้ข้อมูลกลุ่มตัวอย่างผู้ป่วยโรคหลอดเลือดสมองจำนวน 631 ราย ที่เข้ารับการรักษาในโรงพยาบาลบ้านผือ จังหวัดอุดรธานี โดยเทคนิคเหมืองข้อมูลที่ใช้วิเคราะห์ มีรายละเอียดดังนี้

1.เพื่อนบ้านที่ใกล้เคียงที่สุดจำนวน K ตัว (K-Nearest Neighbor) ใช้หลักการจำแนกประเภทข้อมูลโดยอาศัยความคล้ายคลึง (Similarity) ของโหนดข้อมูลในพื้นที่หลายมิติ ข้อมูลทดสอบที่อยู่ใกล้ข้อมูลฝึกที่สุดตามจำนวน K ก็จะเป็นข้อมูลในกลุ่มนั้น ในงานวิจัยนี้ ผู้ป่วยรายใหม่จะถูกทำนายผลการเข้าถึงบริการโดยพิจารณาจากระยะห่างของปัจจัยนำเข้า เช่น ระยะทางจากบ้านไปยังโรงพยาบาล อายุ ชนิดของโรคหลอดเลือดสมอง และระยะเวลาเดินทาง เป็นต้น โดยจะทำการเปรียบเทียบกับผู้ป่วยที่มีลักษณะใกล้เคียงกันที่สุด

จำนวน K ราย วิธีการนี้สามารถเรียนรู้รูปแบบข้อมูลที่ซับซ้อนได้โดยไม่ต้องกำหนดสมมติฐานของข้อมูลล่วงหน้า วิธีการนี้สามารถคำนวณได้ดั่งสมการแบบยูคลิด (Euclidean Distance) ดังนี้

$$d(x, y) = \sqrt{\left(\sum_{i=1}^n (x_i - y_i)^2 \right)}$$

โดยที่ x และ y คือตำแหน่งของข้อมูลผู้ป่วย และ n คือจำนวนปัจจัยทำนาย ทั้งนี้ผู้วิจัยได้ทำการปรับมาตรฐานข้อมูลที่เหมาะสม เนื่องจากตัวแปรเชิงปริมาณ เช่น อายุ (ปี) และระยะทาง (กิโลเมตร) มีหน่วยวัดที่แตกต่างกัน เพื่อป้องกันไม่ใหตัวแปรที่มีค่าพิสัยสูงส่งผลกระทบต่อถ่วงน้ำหนักมากกว่าความเป็นจริง

ในการวิจัยครั้งนี้ ผู้วิจัยได้กำหนดค่าพารามิเตอร์สำหรับแบบจำลอง โดยตั้งค่าจำนวนเพื่อนบ้านที่ใกล้ที่สุด (K) เท่ากับ 7 ราย เพื่อช่วยป้องกันปัญหาการเกิดคะแนนเสียงเท่ากันในการตัดสินใจจำแนกประเภทข้อมูลที่มีลักษณะสองกลุ่ม และกำหนดฟังก์ชันน้ำหนักแบบเท่ากัน ซึ่งหมายถึง โหนดเพื่อนบ้านทั้ง 7 ราย รอบข้อมูลทดสอบจะมีค่าน้ำหนักในการลงคะแนน เพื่อจำแนกประเภทเท่ากันโดยไม่ขึ้นกับระยะห่าง (Nursikuwagus, 2025)

2. นาอิวเบย์ (Naïve Bays) เป็นโมเดลเชิงความน่าจะเป็นที่ใช้ทฤษฎีของเบย์ (Bayes' Theorem) โดยมีข้อสมมติฐานหลักคือปัจจัยทำนายแต่ละตัวมีความเป็นอิสระต่อกัน (Conditional Independence) ในบริบทของโรงพยาบาลบ้านผือ โมเดลจะคำนวณความน่าจะเป็นที่ผู้ป่วยจะเข้าถึงบริการทันเวลาหรือไม่เมื่อทราบปัจจัยสนับสนุน เช่น เป็นผู้ป่วยชนิดหลอดเลือดสมองแตก มีการใช้บริการการแพทย์ฉุกเฉิน และปัจจัยอื่น ๆ อย่างไรก็ตาม หากตัวแปรมีความสัมพันธ์กันสูง อาจส่งผลให้ประสิทธิภาพของโมเดลลดลง โดยความน่าจะเป็นของเบย์ดังแสดงในสมการ (Peretz et al., 2024)

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)}$$

$P(C|X)$ คือ ความน่าจะเป็นที่ผู้ป่วยจะเข้าถึงบริการทัน/ไม่ทัน (C) เมื่อปรากฏปัจจัย X

$P(X|C)$ คือ ความน่าจะเป็นที่พบปัจจัย X ในกลุ่มผู้ป่วยที่มีสถานะ C

$P(C)$ คือ ความน่าจะเป็นก่อนหน้า (Prior Probability) ของกลุ่มที่เข้าถึงบริการทันหรือไม่ทันจากฐานข้อมูลทั้งหมด

3. ป่าสุ่ม (Random Forest) เป็นเทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning) ที่สร้างต้นไม้ตัดสินใจจำนวนหลายต้น มาทำงานร่วมกันเพื่อเพิ่มความแม่นยำและเสถียรภาพของแบบจำลอง อัลกอริทึมจะสุ่มเลือกกลุ่มตัวอย่างผู้ป่วย และสุ่มเลือกปัจจัยนำเข้า เพื่อสร้างต้นไม้แต่ละต้น แล้วใช้การลงคะแนนเสียงข้างมาก เพื่อสรุปผลการทำนาย ทำให้มีความเสถียรและแม่นยำสูงกว่าต้นไม้ตัดสินใจต้นเดียว (Speiser et al., 2019) โดยวิธีการป่าสุ่มจะใช้เกณฑ์ที่ใช้ในการตัดสินใจเลือกปัจจัยทำนายและจุดตัดที่ดีที่สุดเพื่อแบ่งโหนดในต้นไม้แต่ละต้นดังสมการ



$$Gini(D) = 1 - \sum_{i=1}^m P_i^2$$

โดยที่ P_i คือสัดส่วนของผู้ป่วยในแต่ละคลาส (ทัน/ไม่ทัน) ที่อยู่ในโหนดนั้น ๆ เทคนิคนี้ช่วยลดปัญหาการทำนายผิดพลาดได้ดีกว่าต้นไม้ตัดสินใจเพียงต้นเดียว จุดเด่นของป่าสุ่มคือสามารถจัดการข้อมูลที่มีความซับซ้อนและมีความสัมพันธ์ไม่เป็นเชิงเส้นได้อย่างเหมาะสม มีความทนทานต่อข้อมูลรบกวน และสามารถวิเคราะห์ความสำคัญของตัวแปรได้ จึงเหมาะสำหรับการศึกษาปัจจัยทำนายในบริบทของระบบบริการสุขภาพที่มีหลายปัจจัยเกี่ยวข้องร่วมกัน

ในการวิจัยครั้งนี้ ผู้วิจัยได้กำหนดค่าพารามิเตอร์สำหรับแบบจำลองป่าสุ่ม โดยกำหนดต้นไม้ตัดสินใจเท่ากับ 8 ต้น และควบคุมการเติบโตของต้นไม้ด้วยการตั้งเงื่อนไขไม่ให้แตกโหนดย่อยหากกลุ่มข้อมูลมีขนาดเล็กกว่า 5 ราย เพื่อไม่ให้แบบจำลองเกิดปัญหาการเรียนรู้จำเพาะมากเกินไป ซึ่งช่วยเพิ่มเสถียรภาพและความสามารถในการพยากรณ์ชุดข้อมูลใหม่ได้อย่างมีประสิทธิภาพ (Nursikuwagus, 2025)

การตรวจสอบคุณภาพเครื่องมือ

สถิติที่ใช้เพื่อทดสอบแบบจำลองและแปลผลข้อมูล

1. ความแม่นยำในการจำแนกประเภท (Classification Accuracy: CA) หมายถึง สัดส่วนของจำนวนรายการที่โมเดลทำนายถูกต้องทั้งหมด ต่อจำนวนกลุ่มตัวอย่างทั้งหมด มีค่าระหว่างร้อยละ 0-100 ซึ่งค่าเข้าใกล้ 100 แสดงว่าแบบจำลองมีความถูกต้องในการพยากรณ์ภาพรวมสูง

2. ความไวในการทำนาย (Sensitivity or Recall) หมายถึง สัดส่วนของจำนวนตัวอย่างที่เป็นบวกจริง (positive cases) ที่โมเดลทำนายได้ถูกต้อง โดยเทียบกับจำนวนรายการที่เป็นบวกทั้งหมด มีค่าระหว่างร้อยละ 0-100 ซึ่งค่าเข้าใกล้ 100 แสดงว่าโมเดลมีประสิทธิภาพสูงในการตรวจจับหรือคัดกรองกลุ่มที่มาทันเวลาได้อย่างครอบคลุม

3. ค่าความจำเพาะ (Specificity) หมายถึง สัดส่วนของจำนวนตัวอย่างที่เป็นลบจริง (negative cases) ที่โมเดลทำนายได้ถูกต้อง โดยเทียบกับจำนวนเคสที่เป็นลบทั้งหมด มีค่าระหว่างร้อยละ 0-100 ซึ่งค่าเข้าใกล้ 100 แสดงว่าโมเดลมีความสามารถในการแยกแยะกลุ่มที่ไม่ทันเวลาได้อย่างแม่นยำ

4. ค่าพื้นที่ใต้เส้นโค้ง (Area Under ROC Curve: AUC) เป็นตัวชี้วัดที่มาจากกราฟ ROC (Receiver Operating Characteristic Curve) ซึ่งพล็อตค่า sensitivity (True Positive Rate) เทียบกับ false positive rate (1 - specificity) ในทุก threshold ที่เป็นไปได้ ซึ่งค่า AUC ที่เข้าใกล้ 1.0 แสดงถึงแบบจำลองมีประสิทธิภาพในการจำแนกกลุ่มเป้าหมายได้สมบูรณ์ ดังนี้ (Peretz et al., 2024; Sutanon, 2025)

AUC น้อยกว่าหรือเท่ากับ .500 หมายถึง โมเดลไม่มีความสามารถในการจำแนก

AUC อยู่ระหว่าง .500 - .700 หมายถึง โมเดลมีประสิทธิภาพในระดับพอใช้

AUC อยู่ระหว่าง .700 - .800 หมายถึง โมเดลมีประสิทธิภาพในการจำแนกระดับดี

AUC อยู่ระหว่าง .800 - .900 หมายถึง โมเดลมีประสิทธิภาพในการจำแนกระดับดีมาก

AUC ตั้งแต่ .900 ขึ้นไป หมายถึง โมเดลมีประสิทธิภาพในการจำแนกระดับยอดเยี่ยม

5. Information Gain เป็นค่าที่ใช้ในการวัดประสิทธิภาพของตัวแปรในการจำแนกข้อมูล โดยคำนวณจากค่าความไม่แน่นอนของข้อมูล (Entropy) ที่ลดลงหลังจากใช้ตัวแปรนั้น ๆ ในการแบ่งกลุ่ม ตัวแปรที่มีค่า Information Gain สูงแสดงว่าเป็นตัวแปรที่มีอิทธิพลหรือมีความสำคัญในการพยากรณ์ผลลัพธ์ตามตัวแปรตามได้ดีที่สุด

6. Information Gain Ratio เป็นดัชนีที่ปรับปรุงมาจาก Information Gain เพื่อลดความลำเอียงในการเลือกตัวแปรที่มีจำนวนกลุ่มย่อยมากเกินไป โดยนำค่า Information Gain มาหารด้วยค่าความไม่แน่นอนของตัวแปรนั้น ๆ เพื่อให้ได้ตัวแปรที่มีประสิทธิภาพในการจำแนกข้อมูลที่เหมาะสมและมีความเสถียรทางสถิติสูงที่สุด

การเก็บรวบรวมข้อมูล

ขั้นการเตรียมข้อมูล ผู้วิจัยดำเนินการยื่นหนังสืออนุญาตเก็บรวบรวมข้อมูลและขออนุญาตใช้ข้อมูลจากนายแพทย์สาธารณสุขจังหวัดอุดรธานี และผู้อำนวยการโรงพยาบาลบ้านผือ ผ่านการประสานขอใช้ข้อมูลกับเจ้าหน้าที่ศูนย์คอมพิวเตอร์ งานเวชระเบียน และผู้รับผิดชอบรายงานโรคหลอดเลือดสมอง โรงพยาบาลบ้านผือ เพื่อชี้แจงวัตถุประสงค์และขอบเขตข้อมูลที่ต้องการศึกษา คัดกรองข้อมูลของกลุ่มตัวอย่างตามรหัสการวินิจฉัยโรคหลอดเลือดสมอง จากฐานข้อมูลระบบเวชระเบียนอิเล็กทรอนิกส์ และนำรายชื่อที่ได้จากระบบ HOSxP มาทวนสอบกับทะเบียนรายงานโรคหลอดเลือดสมองโรงพยาบาลบ้านผือ เพื่อตรวจสอบความสมบูรณ์ ความซ้ำซ้อนและยืนยันความถูกต้องของข้อมูล ผู้วิจัยทำการพิทักษ์สิทธิ์กลุ่มตัวอย่างโดยในขั้นตอนการจัดการข้อมูล เจ้าหน้าที่ศูนย์คอมพิวเตอร์และงานเวชระเบียนจะเป็นผู้ดำเนินการถอดถอนและตัดข้อมูลส่วนบุคคลที่สามารถระบุตัวตน ได้แก่ ชื่อ-สกุล ที่อยู่ตามทะเบียนบ้านของกลุ่มตัวอย่างออก ฯลฯ และทำการกำหนดรหัสตัวเลขแทนตัวตนขึ้นใหม่ ก่อนส่งมอบชุดข้อมูลนิรนามให้แก่คณะผู้วิจัย และกำหนดมาตรการความปลอดภัยของข้อมูลโดยจัดเก็บไฟล์ไว้ในเครื่องคอมพิวเตอร์ที่เข้ารหัสผ่าน จำกัดสิทธิ์เฉพาะคณะผู้วิจัย

ขั้นการจัดการข้อมูลที่ไม่สมบูรณ์ จัดการข้อมูลที่ขาดหาย (Missing Values) โดยการลบแถวที่ข้อมูลไม่สมบูรณ์ทุกตัวแปร และแปลงข้อมูลให้อยู่ในรูปแบบที่โปรแกรมใช้วิเคราะห์ได้ (Data Transformation) หลังการคัดเลือกตามเกณฑ์คัดเข้า และเกณฑ์คัดออก พบว่าข้อมูล 631 ราย มีการบันทึกข้อมูลครบถ้วนทุกตัวแปร คณะผู้วิจัยจึงไม่มีการตัดแถวข้อมูลเนื่องจากค่าสูญหาย

ขั้นการจัดการความสมดุลของข้อมูลและการตัดค่าสุดโต่ง(Outliers) เนื่องจากชุดข้อมูลเริ่มต้นมีความไม่สมดุล ผู้วิจัยจึงทำการปรับสมดุลข้อมูลผ่านอัลกอริทึมการจับคู่ข้อมูล เพื่อปรับสัดส่วนกลุ่มที่เข้าถึงบริการทันและไม่ทันเวลา 4.5 ชั่วโมง ให้ใกล้เคียงกัน ร่วมกับการตัดข้อมูลที่มีค่าสุดโต่งออก ส่งผลให้เหลือชุดข้อมูลที่สมดุลเพื่อนำไปวิเคราะห์จำนวน 424 ราย โดยข้อมูลที่ถูกตัดออกคิดเป็นร้อยละ 32.81

ขั้นการวิเคราะห์ นำเข้าวิเคราะห์ข้อมูลในเทคนิคเหมืองข้อมูล 3 วิธี ได้แก่ 1) วิธีการเพื่อนบ้านที่ใกล้เคียงที่สุดจำนวน K ตัว (K-Nearest Neighbors: K-NN) 2) วิธีการนาอิวเบย์ (Naïve Bayes) และ 3) วิธีการป่าสุ่ม (Random Forest) หลังจากนั้นทำการสร้างและทดสอบแบบจำลอง (Model Training and Model Evaluation) ดังนี้ 1) ทดสอบแบบไขว้ โดยการทดสอบแบบไขว้ 10 ส่วน (10-fold cross-validation)

เพื่อลดความลำเอียงในการแบ่งข้อมูล และหาค่าเฉลี่ยความแม่นยำที่แท้จริง 2) ประเมินผล โดยประเมินค่าสถิติ ความแม่นยำในการจำแนกประเภท (Classification Accuracy: CA) ความไวในการทำนาย (Sensitivity or Recall) ค่าความจำเพาะ (Specificity) ค่าพื้นที่ใต้เส้นโค้ง (Area Under ROC Curve: AUC) และแปลผลข้อมูลโดยการอ่านค่า Information gain และ Information gain ratio ของตัวแปรแต่ละตัว

การวิเคราะห์ข้อมูล

1. ใช้สถิติเชิงพรรณนาวิเคราะห์ข้อมูลเพื่ออธิบายลักษณะทั่วไปของผู้ป่วยโรคหลอดเลือดสมอง ได้แก่ จำนวน ร้อยละ ค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน ตามระดับการวัดของตัวแปร
2. วิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล เพื่อวิเคราะห์ปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน
3. สร้างความสมดุลของข้อมูลโดยตัดส่วนที่มีค่าสุดโต่งออก เพื่อให้มีสัดส่วนใกล้เคียงกันทั้ง 2 ข้าง
4. ทดสอบและประเมินประสิทธิภาพของแบบจำลอง โดยใช้เทคนิคแบบไขว้ 10 ส่วน เพื่อลดความลำเอียงในการแบ่งข้อมูล และประเมินประสิทธิภาพของโมเดลโดยใช้ตัวชี้วัดผ่านการกำหนดค่าไฮเปอร์พารามิเตอร์ (Hyperparameters) ให้คงที่ ได้แก่ แบบจำลอง kNN กำหนด K=7, Euclidean, Uniform Weights แบบจำลอง Naïve Bayes ใช้ค่ามาตรฐานของโปรแกรม และแบบจำลอง Random Forest กำหนด Trees = 8, Split subset ≥ 5

จริยธรรมการวิจัย

โครงการวิจัยนี้ผ่านการเห็นชอบจากคณะกรรมการจริยธรรมการวิจัยในมนุษย์ วิทยาลัยพยาบาลบรมราชชนนี อุตรธานี เลขที่ COA No. 11/2569 BCNU REC 18/2569 ซึ่งกระบวนการวิจัยผู้วิจัยไม่สามารถเข้าถึงข้อมูลส่วนบุคคลที่สามารถระบุตัวตนของกลุ่มตัวอย่างได้ ซึ่งประกอบไปด้วย ชื่อ-สกุล ที่อยู่ตามทะเบียนบ้าน หรือข้อมูลอื่น ๆ โดยข้อมูลดังกล่าวจะถูกคัดออกก่อนส่งต่อข้อมูลจากเจ้าหน้าที่เวชระเบียนมายังผู้วิจัย

ผลการวิจัย

1. ลักษณะข้อมูลด้านปัจจัยส่วนบุคคล ด้านโรคประจำตัว และด้านระบบบริการ
จำนวนชุดข้อมูลทั้งหมด 631 ราย ผ่านการสร้างสมดุลของข้อมูลโดยตัดส่วนที่มีค่าสุดโต่งออกจากโปรแกรม ทำให้ข้อมูลคงเหลือก่อนการวิเคราะห์ 424 ราย ($n=424$) ดังนี้
ข้อมูลด้านปัจจัยส่วนบุคคล ส่วนใหญ่เป็นเพศชาย ร้อยละ 60.14 อยู่ในช่วงอายุ 60-69 ปี ร้อยละ 26.65 ($M=63.96$, $SD.=13.14$)
ข้อมูลด้านโรคประจำตัว พบว่ากลุ่มตัวอย่างส่วนใหญ่ปฏิเสธโรคประจำตัว ร้อยละ 58.73 กลุ่มที่มีโรคประจำตัวส่วนใหญ่เป็นโรคความดันโลหิตสูง ร้อยละ 33.96 ได้รับการวินิจฉัยเป็นโรคหลอดเลือดสมองตีบ/อุดตัน ร้อยละ 85.38 และไม่เคยได้รับการวินิจฉัยเป็นโรคหลอดเลือดสมองมาก่อน ร้อยละ 89.39
ข้อมูลด้านระบบบริการ พบว่าส่วนใหญ่มีระยะทางจากบ้านมายังโรงพยาบาลอยู่ระหว่าง 11 ถึง 20 กิโลเมตร ร้อยละ 59.91 ($M=15.68$, $SD.=7.46$) ใช้ระยะเวลาเดินทางจากบ้านมายังโรงพยาบาลอยู่ระหว่าง

ช่วง 21 ถึง 30 นาที ร้อยละ 41.75 ($M=21.78$, $SD.=7.84$) ไม่ได้ใช้บริการการแพทย์ฉุกเฉิน ร้อยละ 70.05 ผลการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนทัน ร้อยละ 51.18

2. ปัจจัยที่เกี่ยวข้องกับการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน

ผลการวิเคราะห์ลักษณะข้อมูลด้านปัจจัยส่วนบุคคล เมื่อพิจารณาด้านเพศและอายุ พบว่ากลุ่มตัวอย่างเพศชายมีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมงมากกว่าเพศหญิง (ร้อยละ 61.75 และ 38.25 ตามลำดับ) และด้านอายุ พบว่าช่วงอายุที่มีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมงมากที่สุดอยู่ในช่วงอายุ 50-59 ปี (ร้อยละ 25.81) ดังตารางที่ 1

ตารางที่ 1 ปัจจัยที่เกี่ยวข้องกับการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ด้านปัจจัยส่วนบุคคล

ลักษณะข้อมูลด้านปัจจัยส่วนบุคคล	การเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน			
	ทัน 4.5 ชั่วโมง (n=217)		ไม่ทัน 4.5 ชั่วโมง (n=207)	
	จำนวน	ร้อยละ	จำนวน	ร้อยละ
เพศ				
ชาย	134	61.75	121	58.45
หญิง	83	38.25	86	41.55
อายุ				
ต่ำกว่า 50 ปี	32	14.75	21	10.14
50-59 ปี	56	25.81	50	24.15
60-69 ปี	55	25.35	58	28.02
70-79 ปี	49	22.58	52	25.12
ตั้งแต่ 80 ปีขึ้นไป	25	11.52	26	12.56

เมื่อพิจารณาลักษณะข้อมูลด้านโรคประจำตัว กลุ่มผู้ป่วยที่เข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมง ส่วนใหญ่ปฏิเสธโรคประจำตัว (ร้อยละ 54.84) และกลุ่มที่มีโรคประจำตัวส่วนใหญ่เป็นโรคความดันโลหิตสูง (ร้อยละ 38.25) ชนิดของการวินิจฉัยโรคหลอดเลือดสมองแตกจำนวนทั้งหมดมีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมงทุกราย และกลุ่มที่มีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมงส่วนใหญ่ไม่เคยได้รับการวินิจฉัยโรคหลอดเลือดสมองมาก่อน (ร้อยละ 82.03) ดังตารางที่ 2

ตารางที่ 2 ปัจจัยที่เกี่ยวข้องกับการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ด้านโรคประจำตัว

ลักษณะข้อมูลด้านโรคประจำตัว	การเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน			
	ทัน 4.5 ชั่วโมง (n=217)		ไม่ทัน 4.5 ชั่วโมง (n=207)	
	จำนวน	ร้อยละ	จำนวน	ร้อยละ
โรคประจำตัว				
ปฏิเสธโรคประจำตัว	119	54.84	130	62.80

ลักษณะข้อมูลด้านโรคประจำตัว	การเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน			
	ทัน 4.5 ชั่วโมง (n=217)		ไม่ทัน 4.5 ชั่วโมง (n=207)	
	จำนวน	ร้อยละ	จำนวน	ร้อยละ
ความดันโลหิตสูง	83	38.25	61	14.73
เบาหวาน	52	23.96	39	9.42
ไขมันในเลือดสูง	13	5.99	0	0.00
มีโรคร่วมตั้งแต่ 2 โรคขึ้นไป	43	19.82	23	11.11
ชนิดของโรคหลอดเลือดสมอง (ครั้งปัจจุบัน)				
หลอดเลือดสมองตีบ/อุดตัน	155	71.43	207	100.00
หลอดเลือดสมองแตก	62	28.57	0	0.00
ประวัติการวินิจฉัยโรคหลอดเลือดสมอง				
เคยได้รับการวินิจฉัย	39	17.97	6	2.76
ไม่เคยได้รับการวินิจฉัย	178	82.03	201	97.24

ลักษณะข้อมูลด้านระบบบริการ เมื่อจำแนกตามตำบลที่อาศัยของกลุ่มตัวอย่างอาศัย พบว่า ผู้ป่วยที่อาศัยอยู่ในตำบลบ้านฝื่อ มีสัดส่วนการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมงสูงที่สุด (ร้อยละ 17.05) ในขณะที่ตำบลจำปาโมงพบสัดส่วนการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ไม่ทัน 4.5 ชั่วโมง สูงที่สุด (ร้อยละ 15.46) ด้านระยะทาง พบว่าผู้ป่วยที่มีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมง ส่วนใหญ่ มีระยะทางจากบ้านมายังโรงพยาบาล 11-20 กิโลเมตร (ร้อยละ 27.54) ด้านระยะเวลาการเดินทางจากบ้านมายังโรงพยาบาล พบว่าผู้ป่วยที่มีการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทัน 4.5 ชั่วโมง ส่วนใหญ่มีระยะเวลาการเดินทางจากบ้านมายังโรงพยาบาล 11-20 นาที (ร้อยละ 40.55) และแม้ผู้ป่วยโรคหลอดเลือดสมองส่วนใหญ่ไม่ได้ใช้บริการการแพทย์ฉุกเฉิน แต่ผู้ป่วยที่เข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ทันเวลา 4.5 ชั่วโมง มีสัดส่วนการใช้บริการการแพทย์ฉุกเฉินที่สูงกว่าผู้ป่วยที่เข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ไม่ทันเวลา (ร้อยละ 39.17 และ 20.29 ตามลำดับ) ดังตารางที่ 3

ตารางที่ 3 ปัจจัยที่เกี่ยวข้องกับการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ด้านระบบบริการ

ลักษณะข้อมูลด้านระบบบริการ	การเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน			
	ทัน 4.5 ชั่วโมง (n=217)		ไม่ทัน 4.5 ชั่วโมง (n=207)	
	จำนวน	ร้อยละ	จำนวน	ร้อยละ
ตำบลของผู้ป่วย				
กลางใหญ่	32	14.7	26	12.56
ข้าสาร	13	5.99	20	9.66
ตำบลของผู้ป่วย (ต่อ)				
เขื่อน	13	5.99	13	6.28

ลักษณะข้อมูลด้านระบบบริการ	การเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน			
	ทัน 4.5 ชั่วโมง (n=217)		ไม่ทัน 4.5 ชั่วโมง (n=207)	
	จำนวน	ร้อยละ	จำนวน	ร้อยละ
คำด้วง	10	4.61	3	1.45
คำบง	15	6.91	5	2.42
จำปาโมง	14	6.45	32	15.46
โนนทอง	20	9.22	22	10.63
บ้านค้อ	11	5.07	3	1.45
บ้านฝื่อ	37	17.05	24	11.59
เมืองพาน	15	6.91	18	8.70
หนองแขวง	8	3.69	13	6.28
หนองหัวคู	9	4.15	6	2.90
หายโศก	20	9.22	22	10.63
ระยะทางจากบ้านมายังโรงพยาบาล				
1-10 กิโลเมตร	48	11.59	27	13.04
11-20 กิโลเมตร	114	27.54	140	67.63
21-30 กิโลเมตร	45	10.87	37	17.87
31 กิโลเมตรขึ้นไป	10	2.42	3	1.45
ระยะเวลาที่ใช้ในการเดินทางจากบ้านมายังโรงพยาบาล				
1-10 นาที	39	17.97	24	11.59
11-20 นาที	88	40.55	65	31.40
21-30 นาที	72	33.18	105	50.72
31 นาทีขึ้นไป	18	8.29	13	6.28
การใช้บริการการแพทย์ฉุกเฉิน				
ใช่	85	39.17	42	20.29
ไม่ใช่	132	60.83	165	79.71

3. ประสิทธิภาพของแบบจำลอง

จากการทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง ทั้ง 3 อัลกอริทึม ด้วยการทดสอบแบบไขว้ 10 ส่วน เพื่อทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน พบว่าแบบจำลอง Naïve Bayes เป็นโมเดลที่มีประสิทธิภาพในการพยากรณ์สูงที่สุดในทุกมิติโดยมีค่าความแม่นยำในการจำแนกประเภทสูงถึงร้อยละ 71.70 ค่าความไวในการทำนาย ร้อยละ 71.70 ค่าความจำเพาะ ร้อยละ 71.90 และพื้นที่ใต้เส้นโค้ง ROC เท่ากับ 0.787 ดังตารางที่ 4

ตารางที่ 4 แสดงความแม่นยำของอัลกอริทึม การทดสอบความถูกต้องและความน่าเชื่อถือของโมเดล

โมเดล	ผลการทดสอบแบบไขว้ 10 ส่วน (10-fold Cross-validation)			
	CA (%)	Recall (%)	Specificity (%)	AUC
KNN	55.9	55.9	55.8	0.590
Naïve Bayes	71.7	71.7	71.9	0.787
Random Forest	68.9	68.9	69.2	0.759

ผลการจัดลำดับความสำคัญของตัวแปรพยากรณ์ที่มีอิทธิพลต่อการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน ผ่านการคำนวณค่า Information Gain และ Information Gain Ratio พบว่า ปัจจัยสำคัญที่มีอำนาจในการทำนายสูงที่สุด ได้แก่ ตำบลของผู้ป่วย ซึ่งมีค่า Information Gain สูงที่สุด เท่ากับ 0.020 แต่ดัชนี Information Gain มีข้อจำกัดด้านความลำเอียงเชิงสถิติ โดยมักให้ค่าน้ำหนักความสำคัญสูงเกินจริงในตัวแปรที่มีจำนวนกลุ่มย่อยปริมาณมาก ผู้วิจัยจึงประยุกต์ใช้ดัชนี Information Gain Ratio เพื่อเพิ่มความเสถียรเชิงสถิติในการจำแนกประเภทข้อมูล พบว่า ปัจจัยชนิดของโรคหลอดเลือดสมอง เป็นปัจจัยที่มีอำนาจในการจำแนกและทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนได้มากที่สุด (Information Gain Ratio = 0.023) ดังตารางที่ 5

ตารางที่ 5 แสดงปัจจัยสำคัญในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน

ตัวแปร	ค่า Information Gain	ค่า Information Gain Ratio
	Gain	Ratio
ตำบลของผู้ป่วย	0.020*	0.006
ชนิดของโรคหลอดเลือดสมอง	0.017	0.023**
ระยะเวลาที่ใช้ในการเดินทางจากบ้านมายังโรงพยาบาล	0.017	0.008
ระยะทางจากบ้านมายังโรงพยาบาล	0.008	0.004
โรคประจำตัว-เบาหวาน	0.006	0.007
เพศ	0.005	0.006
อายุ	0.005	0.002
โรคประจำตัว-ไขมันในเลือดสูง	0.002	0.005
การใช้บริการการแพทย์ฉุกเฉิน	0.002	0.002
โรคประจำตัว-ความดันโลหิตสูง	0.001	0.001
ประวัติการวินิจฉัยโรคหลอดเลือดสมอง	0.000	0.000

*,** หมายถึง ปัจจัยที่สำคัญที่สุดในการทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน

อภิปรายผล

ข้อมูลด้านปัจจัยส่วนบุคคล จากการศึกษาผู้ป่วยโรคหลอดเลือดสมอง จำนวน 424 ราย พบว่า กลุ่มตัวอย่างส่วนใหญ่เป็นเพศชาย ร้อยละ 60.14 และอยู่ในช่วงอายุ 60-69 ปี ซึ่งธรรมชาติของโรคหลอดเลือด

เลือดสมองจะมีความเสี่ยงเพิ่มขึ้นตามอายุ สอดคล้องกับการศึกษาของ Lee et al. (2024) ที่พบว่า อายุที่เพิ่มขึ้นร่วมกับปัจจัยทางชีวภาพและพฤติกรรมในเพศชาย มีความสัมพันธ์อย่างมีนัยสำคัญต่อการเกิดโรคหลอดเลือดสมองในกลุ่มประชากรผู้สูงอายุ ข้อมูลด้านโรคประจำตัว พบว่า ผู้ป่วยส่วนใหญ่ได้รับการวินิจฉัยเป็นโรคหลอดเลือดสมองตีบ/อุดตัน ซึ่งเป็นชนิดที่พบมากที่สุดในประเทศไทยและระดับโลก เช่นเดียวกับการศึกษาของ Feigin et al., (2025) ที่ระบุว่า ผู้ป่วยโรคหลอดเลือดสมองรายใหม่ทั่วโลกมากกว่าร้อยละ 80.00 เกิดจากภาวะสมองขาดเลือด และข้อมูลด้านระบบบริการ พบว่า ผู้ป่วยส่วนใหญ่ไม่ได้ใช้บริการการแพทย์ฉุกเฉินมากถึงร้อยละ 70.05 ซึ่งสอดคล้องกับการศึกษาของ Tansuwannarat et al. (2021) ที่ศึกษาระบบการแพทย์ฉุกเฉินในผู้ป่วยสงสัยโรคหลอดเลือดสมองในประเทศไทย และพบว่าผู้ป่วยสงสัยโรคหลอดเลือดสมองส่วนใหญ่เลือกเดินทางมาโรงพยาบาลด้วยตนเองมากกว่าการเรียกใช้บริการ 1669 เนื่องจากขาดความรู้ความเข้าใจเกี่ยวกับขั้นตอนการให้บริการฉุกเฉิน และประเมินความรุนแรงของอาการแรกรับต่ำกว่าความเป็นจริง ส่งผลให้เสียโอกาสในการได้รับการดูแลรักษาเบื้องต้นตั้งแต่อยู่บนรถพยาบาล

จากการเปรียบเทียบประสิทธิภาพของอัลกอริทึมทั้ง 3 รูปแบบ พบว่า Naïve Bayes เป็นโมเดลที่มีประสิทธิภาพสูงที่สุดในการทำนาย โดยมีค่าความแม่นยำ และความไว สูงถึงร้อยละ 71.70 รวมพื้นที่ใต้โค้งอยู่ที่ 0.787 เนื่องจาก Naïve Bayes คำนวณบนหลักความน่าจะเป็น จึงมีความทนทานสูงต่อข้อมูลทุติยภูมิทางคลินิกที่มีตัวแปรเชิงกลุ่ม ปริมาณมาก และไม่เกิดปัญหาภาวะการปรับพอดีเกิน (Overfitting) ขณะที่ Random Forest มีประสิทธิภาพลดลงเล็กน้อยจากการถูกดึงน้ำหนักในโหนดตัดสินใจโดยตัวแปรเชิงกลุ่มและปรากฏการณ์การแบ่งกลุ่มสมบูรณ์ (Perfect Separation) ซึ่งเป็นข้อจำกัดของงานวิจัยนี้ เนื่องจากผู้ป่วยชนิดหลอดเลือดสมองแตก มีการเข้าถึงบริการทัน 4.5 ชั่วโมงร้อยละ 100.00 ส่วน KNN มีประสิทธิภาพต่ำสุดเนื่องจากการคำนวณระยะทางยูคลิด ไม่เหมาะสมกับตัวแปรเชิงกลุ่มทางคลินิกเท่ากับข้อมูลตัวเลขต่อเนื่อง ผลศึกษานี้สอดคล้องกับ Nonsiri et al. (2023) ที่ชี้ว่าโมเดลจำแนกประเภทข้อมูลมีประโยชน์สูงในการช่วยคัดกรองและคัดแยกกลุ่มเสี่ยงเพื่อส่งเสริมการเข้าถึงบริการทันระยะเวลาทอง

ปัจจัยทำนายการเข้าถึงบริการโรคหลอดเลือดสมอง วิเคราะห์ผ่านค่า Information gain และ Information gain ratio พบปัจจัยสำคัญ 3 ลำดับแรกที่ทำนายการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วนได้มากที่สุด ได้แก่ ชนิดของโรคหลอดเลือดสมอง ตำบลของผู้ป่วย และระยะเวลาที่ใช้ในการเดินทาง ซึ่งสามารถอธิบายได้ดังนี้

1. ชนิดของโรคหลอดเลือดสมอง เป็นปัจจัยที่มีค่า Information gain ratio สูงที่สุด สะท้อนให้เห็นว่าลักษณะอาการแสดงของโรค ในชนิดหลอดเลือดสมองแตก มักมีอาการเฉียบพลันและรุนแรง เช่น ปวดศีรษะรุนแรง อาเจียนพุ่ง ซึม สับสน หรือหมดสติ จากภาวะสมองขาดเลือดเฉพาะที่ร่วมกับความดันในกะโหลกศีรษะสูงขึ้นอย่างรวดเร็ว (Feigin et al., 2025; Sutanon, 2025) ซึ่งแตกต่างจากโรคหลอดเลือดสมองตีบ/อุดตัน ที่อาการมักค่อยเป็นค่อยไป ส่งผลต่อการตัดสินใจมาโรงพยาบาลของผู้ป่วยและญาติ ซึ่งสอดคล้องกับผลการวิจัยของ Rakchue P. & Poonphol S. (2019) ที่พบว่าปัจจัยด้านความรุนแรงของโรคมีผลโดยตรงต่อการเข้าถึงบริการล่าช้า

2. ตำบลของผู้ป่วย และระยะเวลาที่ใช้ในการเดินทางจากบ้านมายังโรงพยาบาล เป็นปัจจัยเชิงระบบบริการที่เป็นตัวพยากรณ์สำคัญในบริบทโรงพยาบาลบ้านผือ เนื่องจากเป็นอำเภอขนาดใหญ่ที่มีความซับซ้อนของพื้นที่ ผลการวิจัยพบว่าการอาศัยอยู่ในตำบลที่ห่างไกลหรือใช้ระยะเวลาเดินทางนาน เป็นอุปสรรคสำคัญที่ทำให้ผู้ป่วยเข้าถึงบริการล่าช้ากว่าระยะเวลาทอง สอดคล้องกับการศึกษาของ Butdee et al. (2023) ที่ชี้ว่าระยะทางและเวลาเดินทางเป็นปัจจัยเชิงระบบที่ส่งผลต่อการเข้าถึงบริการทันอย่างมีนัยสำคัญ

3. ปัจจัยด้านโรคประจำตัว เป็นปัจจัยที่มีค่า Information gain ค่อนข้างต่ำ แต่ปัจจัยเหล่านี้ร่วมทำนายการเข้าถึงบริการกับชนิดของโรคหลอดเลือดสมอง ซึ่งเป็นปัจจัยทำนายหลัก โดยเฉพาะในชนิดหลอดเลือดสมองแตกที่พบเฉพาะในกลุ่มที่เข้าถึงบริการทันเวลาเท่านั้น สะท้อนว่าอาการของโรคที่รุนแรงในผู้ป่วยที่มีโรคประจำตัวเดิม อาจส่งผลต่อพฤติกรรมในการเข้ารับบริการอย่างรวดเร็วกว่า แต่ในทางกลับกันการมีโรคประจำตัวกลับเป็นปัจจัยเสี่ยงที่ทำให้มีการล่าช้าอย่างมีนัยสำคัญ (crude OR= 3.24) (Rakchue & Poonphol, 2019) อธิบายได้ว่า อาการของโรคหลอดเลือดสมองมักมีอาการคล้าย ๆ กับอาการของโรคประจำตัวเดิม เช่น อาการสับสน วิงเวียน ปวดศีรษะ ทำให้ผู้ป่วยมักจะใช้วิธีการดูแลตนเองเบื้องต้นก่อนที่จะไปพบแพทย์เมื่ออาการไม่ทุเลา

4. ปัจจัยด้านเพศและอายุ มีค่า Information gain ค่อนข้างต่ำ ซึ่งปัจจัยเหล่านี้ถือเป็นส่วนประกอบสำคัญในแบบจำลอง เนื่องจากพหุปัจจัยส่วนบุคคลมีความสัมพันธ์ที่สลับซับซ้อนต่อการตัดสินใจเข้าถึงบริการ ซึ่งสอดคล้องกับการศึกษาของ Potisopha et al. (2020) และ Lee et al. (2024) ที่อ้างถึงอิทธิพลของเพศและอายุต่อระยะเวลาเข้าถึงบริการก่อนถึงโรงพยาบาล

5. ปัจจัยการใช้บริการการแพทย์ฉุกเฉิน แม้จะมีอำนาจการทำนายน้อย ซึ่งกลุ่มตัวอย่างส่วนใหญ่ไม่ได้ใช้ระบบบริการการแพทย์ฉุกเฉิน แต่ปัจจัยนี้จะสำคัญเมื่อพิจารณาพร้อมกับตำบลของผู้ป่วยและระยะเวลาเดินทาง และกลุ่มตัวอย่างที่เข้าถึงบริการทันเวลามีสัดส่วนที่สูงกว่ากลุ่มที่เข้าถึงบริการไม่ทันเวลา แสดงให้เห็นว่าแม้ระบบการแพทย์ฉุกเฉินจะมีอิทธิพลรองในภาพรวม แต่เป็นตัวแปรสนับสนุนที่สำคัญต่อการลดระยะเวลาเดินทางสำหรับพื้นที่ห่างไกล (Tansuwannarat et al., 2021)

6. ประวัติการวินิจฉัยโรคหลอดเลือดสมอง มีค่า Information gain ต่ำมาก แสดงให้เห็นว่าประสบการณ์การเจ็บป่วยเดิมเพียงอย่างเดียว อาจไม่ได้เป็นปัจจัยหลักที่กระตุ้นให้มาโรงพยาบาลเร็วขึ้น หากไม่พิจารณาพร้อมกับปัจจัยสนับสนุนอื่น ๆ เช่น ระยะทาง หรือการรับรู้สัญญาณเตือนโรคหลอดเลือดสมอง สอดคล้องกับการศึกษาของ Yoon et al. (2022) ที่พบว่าปัจจัยประวัติการเคยป่วยมาก่อนสัมพันธ์กับการเข้ารับบริการล่าช้า อธิบายได้ว่าประสบการณ์เดิมมีผลต่อการตัดสินใจในรูปแบบที่ซับซ้อนและอาจนำไปสู่ความล่าช้าได้หากผู้ป่วยรายนั้นประเมินความรุนแรงของโรคผิดพลาด

ทั้งนี้ ข้อจำกัดของการศึกษารั้งนี้ ในประเด็นผู้ป่วยโรคหลอดเลือดสมองแตกที่เข้าถึงบริการทันเวลาทั้งหมด ก่อให้เกิดปรากฏการณ์การแบ่งกลุ่มสมบูรณ์ (Perfect Separation Effect) ซึ่งอาจทำให้แบบจำลองประเมินความสำคัญของตัวแปรนี้สูงเกินจริง ประกอบกับการใช้ข้อมูลทุติยภูมิจากโรงพยาบาลชุมชนเพียงแห่งเดียว จึงยังขาดตัวแปรเชิงพฤติกรรม และการนำไปใช้ในบริบทอื่นจำเป็นต้องปรับแก้พารามิเตอร์ให้เหมาะสม อย่างไรก็ตาม จุดเด่นของการศึกษาคือการใช้แนวคิดการแก้ปัญหาประดิษฐ์ระดับข้อมูลทุติยภูมิในระบบ



HOSxP เดิม สู่แบบจำลองทำนายเชิงคาดการณ์ที่มีประสิทธิภาพและเสถียรภาพสูง ช่วยระบุปัจจัยทำนายเชิงพื้นที่เพื่อสนับสนุนการวางแผนบริการสุขภาพเชิงรุกได้อย่างคุ้มค่า

ข้อเสนอแนะการนำผลการวิจัยไปใช้

1. ผลการวิจัยครั้งนี้สามารถนำไปเป็นข้อมูลเบื้องต้นในการวางแผนบริการเชิงรุกเพื่อเพิ่มอัตราการเข้าถึงบริการโรคหลอดเลือดสมองแบบช่องทางด่วน โดยควรเน้นส่งเสริมการใช้ระบบบริการการแพทย์ฉุกเฉินในพื้นที่ห่างไกล และจัดโปรแกรมให้สุศึกษาเรื่องสัญญาณเตือนของโรคหลอดเลือดสมองอย่างเฉพาะเจาะจงในกลุ่มเสี่ยงที่มีโรคประจำตัวเป็นโรคเรื้อรัง เพื่อลดอัตราการความพิการและเสียชีวิตในชุมชนต่อไป

2. โรงพยาบาลควรพัฒนาระบบการบันทึกข้อมูลดิจิทัลและจัดเก็บฐานข้อมูลเชิงโครงสร้างให้มีความสม่ำเสมอและเป็นมาตรฐานอย่างต่อเนื่อง เพื่อเพิ่มคุณภาพข้อมูลดิจิทัลและรองรับการนำเทคโนโลยีปัญญาประดิษฐ์มาใช้วิเคราะห์พยากรณ์สถานการณ์สุขภาพในระดับพื้นที่ได้อย่างแม่นยำยิ่งขึ้น

ข้อเสนอแนะในการวิจัยครั้งต่อไป

1. ควรมีการเพิ่มที่หลากหลายและจำนวนของตัวแปรทำนาย เช่น ตัวแปรเชิงพฤติกรรมและสังคม ที่ส่งผลต่อการตัดสินใจของผู้ป่วยและญาติ เพื่อเพิ่มความไวของแบบจำลองในการทำนายกลุ่มที่มาทันเวลาให้สูงขึ้น

2. ควรมีการศึกษาติดตามผล ภายหลังการนำแบบจำลองที่ได้จากการศึกษาครั้งนี้ไปประยุกต์ใช้ในระบบการคัดกรองหรือวางแผนเชิงรุกในชุมชน เพื่อประเมินว่าผลการศึกษามีช่วยเพิ่มอัตราการเข้าถึงบริการ และลดอัตราการความพิการของผู้ป่วยได้จริงอย่างมีนัยสำคัญหรือไม่ อย่างไร

รายการอ้างอิง

กระทรวงสาธารณสุข. (2569, 21 เมษายน). ระบบคลังข้อมูลด้านการแพทย์และสุขภาพ *Health Data*

Center (HDC) [https://hdc.moph.go.th/center/public/standard-report-](https://hdc.moph.go.th/center/public/standard-report-detail/3092c3c3250ae67155f7e134680c4152?subcatalogId=39fd60c25235db479930db85a0e97dd3)

[detail/3092c3c3250ae67155f7e134680c4152?subcatalogId=39fd](https://hdc.moph.go.th/center/public/standard-report-detail/3092c3c3250ae67155f7e134680c4152?subcatalogId=39fd60c25235db479930db85a0e97dd3)

[60c25235db479930db85a0e97dd3](https://hdc.moph.go.th/center/public/standard-report-detail/3092c3c3250ae67155f7e134680c4152?subcatalogId=39fd60c25235db479930db85a0e97dd3)

เขตสุขภาพที่ 8. (2569, 5 กุมภาพันธ์). รายงานระบบบริการโรคหลอดเลือดสมอง เขตสุขภาพที่ 8.

<https://r8way.moph.go.th/r8way/viewIVG1wVlBRPT0=>

Butdee, S., Juntasopeepun, P., Chintanawat, R., & Locsin, R. C. (2023). Prehospital delay after acute ischemic stroke among Thai older adults: A cross-sectional study. *Nurs Health Sci*, 25(1), 73-79. <https://doi.org/10.1111/nhs.12991>

Caroline, F., & Rachmat, N. (2025). Comparison of XGBoost and LightGBM Algorithms in Predicting Heart Disease. *Brilliance: Research of Artificial Intelligence*, 5, 1232-1239. <https://doi.org/10.47709/brilliance.v5i2.7505>



- Chansiri, K., McCrae, J. S., Courtney, K. O., & Cappello, D. (2025). A machine learning approach to healthcare needs and barriers using the 100% Community Survey of access to SDOH services [Original Research]. *Frontiers in Public Health, Volume 13 - 2025*. <https://doi.org/10.3389/fpubh.2025.1659322>
- Feigin, V. L., Brainin, M., Norrving, B., Martins, S. O., Pandian, J., Lindsay, P., M, F. G., & Rautalin, I. (2025). World Stroke Organization: Global Stroke Fact Sheet 2025. *Int J Stroke, 20*(2), 132-144. <https://doi.org/10.1177/17474930241308142>
- Lee, J.-E., Kityo, A., & Lee, S.-A. (2024). Lifestyle Factors, Sociodemographic Characteristics and Incident Hypertension: A Prospective Analysis of the Korean National Health Insurance Service Sample Cohort. *Journal of Personalized Medicine, 14*(9), 959.
- Liu, Y., Zhang, C., Zheng, X., Liu, Y., & He, J. (2023). Stroke prediction model based on decision tree. *WSEAS Transactions on Biology and Biomedicine, 20, 2023*, 24-27. <https://doi.org/10.37394/23208.2023.20.3>
- Ngoc-Bich Le, T.-T.-H. P., Sy-Hoang Nguyen, Nhat-Minh Nguyen, Tan-Nhu Nguyen. (2024). AI-powered Predictive Model for Stroke and Diabetes Diagnostic. *I.J. Intelligent Systems and Applications, 2024*(1), 24-40.
- Nonsiri N, M. R., Somkanta K. (2023). Data Classifying to Diagnose Diabetes Risk Using Data Mining Techniques. *The Journal of King Mongkut's University of Technology North Bangkok, 33*(2), 538-547.
- Nursikuwagus, A. (2025). CLASSIFICATION FOR DIAGNOSING STROKE USING ORANGE DATA MINING. *Journal of Mathematical Sciences and Informatics, 5*(1), 83-94.
- Peretz, O., Koren, M., & Koren, O. (2024). Naive Bayes classifier–An ensemble procedure for recall and precision enrichment. *Engineering Applications of Artificial Intelligence, 136*, 108972.
- Potisopha, W., Vuckovic, K. M., DeVon, H. A., Park, C. G., & Hershberger, P. E. (2020). Sex Differences in Prehospital Delay in Patients With Acute Stroke: A Systematic Review. *J Cardiovasc Nurs, 35*(6), E77-e88. <https://doi.org/10.1097/jcn.0000000000000715>
- Prabhakaran, S., Gonzalez, N. R., Zachrison, K. S., Adeoye, O., Alexandrov, A. W., Ansari, S. A., Chapman, S., Czap, A. L., Dumitrascu, O. M., Ishida, K., Jadhav, A. P., Johnson, B., Johnston, K. C., Khatri, P., Kimberly, W. T., Lee, V. H., Leslie-Mazwi, T. M., Mac Grory, B., Madsen, T. E., Menon, B., ... Peer Review Committee. (2026). 2026 guideline for the early management of patients with acute ischemic stroke: A guideline from the



- American Heart Association/American Stroke Association. *Stroke*. Advance online publication.
- Rakchue, P., Poonphol, S. (2019). Factor influencing Pre-hospital Delay among Acute Ischemic Stroke Patients in Rajavithi Hospital. *J Thai Stroke Soc*, 18(1), 5-13.
- Sutanon, A. (2025). Development clinical decision support system to enhance accuracy in diagnosis and treatment of stroke in emergency patients *Journal of the Thai Medical Informatics Association*, 2, 119-126.
- Tansuwannarat, P., Atiksawedparit, P., Wibulpolprasert, A., & Mankasetkit, N. (2021). Prehospital time of suspected stroke patients treated by emergency medical service: a nationwide study in Thailand. *Int J Emerg Med*, 14(1), 37.
<https://doi.org/10.1186/s12245-021-00361-w>
- Wartika, Nursikuwagus, Agus. (2025). CLASSIFICATION FOR DIAGNOSING STROKE USING ORANGE DATA MINING. *Journal of Mathematical Sciences and Informatics*, 5(1), 83-94.
- Yoon, C. W., Oh, H., Lee, J., Rha, J. H., Woo, S. I., Lee, W. K., Jung, H. Y., Ban, B., Kang, J., Kim, B. J., Kim, W. S., Yoon, C. H., Lee, H., Kim, S., Kim, S. H., Kang, E. K., Her, A. Y., Cha, J. K., Kim, D. H.,...Bae, H. J. (2022). Comparisons of Prehospital Delay and Related Factors Between Acute Ischemic Stroke and Acute Myocardial Infarction. *J Am Heart Assoc*, 11(9), e023214. <https://doi.org/10.1161/jaha.121.023214>