

รายงานวิจัย

Research Articles

ประสิทธิภาพของปัญญาประดิษฐ์ในการทำนายโอกาสนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุ The Efficiency of Artificial Intelligence in Predicting Hospitalization for Trauma Patients

รณชัย แก้วผดุง*

Ronnachai Keawpadung*

*กลุ่มงานเวชศาสตร์ฉุกเฉิน โรงพยาบาลน่าน จังหวัดน่าน 55000

*Emergency Medicine Department, Nan Hospital, Nan Province 55000

Corresponding author e-mail address: ronnachaikeaw@gmail.com

Received: January 23, 2024

Revised: February 27, 2025

Accepted: March 25, 2024

Abstract

Overcrowding in emergency departments presents a significant challenge at Nan Hospital. This retrospective observational study evaluated the efficiency of artificial intelligence in predicting hospital admission among accident patients. Data from accident cases recorded in the hospital's electronic database during 2022 were utilized to develop AI models using machine learning, specifically decision trees. Subsequently, data from January 1, 2023 to April 30, 2023 were employed to validate the AI model. The predictive performance of the AI was statistically assessed using a confusion matrix. The model predicted outcomes for 3,185 accident patients, achieving an overall accuracy of 92.3%, sensitivity of 89.8%, and specificity of 93.4%. Notably, for resuscitation, emergency, and semi-urgent categories, the model demonstrated 100% accuracy, while the urgency category achieved 91% accuracy. These findings indicated that AI has potential to effectively predict hospital admission for accident patients and can be used in supporting clinical decision-making and potentially mitigating emergency department overcrowding. AI-driven prediction systems could enhance patient care efficiency by enabling better resource allocation and prioritization in critical care settings.

Keywords: emergency room, artificial intelligence, trauma, hospitalization*Buddhachinaraj Med J 2025;42(1):79-90.*

บทคัดย่อ

ปัญหาความแออัดในแผนกฉุกเฉินเป็นความท้าทายสำคัญที่โรงพยาบาลน่าน การศึกษาเชิงสังเกตย้อนหลังครั้งนี้มีวัตถุประสงค์เพื่อประเมินประสิทธิภาพของปัญญาประดิษฐ์ในการทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุ โดยใช้ข้อมูลผู้ป่วยอุบัติเหตุที่บันทึกในฐานข้อมูลอิเล็กทรอนิกส์ของโรงพยาบาลในปี พ.ศ. 2565 ในการพัฒนาปัญญาประดิษฐ์ด้วยการเรียนรู้ของเครื่องประเภทต้นไม้ ตัดสินใจ และนำข้อมูลผู้ป่วยอุบัติเหตุระหว่างวันที่ 1 มกราคม พ.ศ. 2566 ถึงวันที่ 30 เมษายน พ.ศ. 2566 มาทดสอบประสิทธิภาพของโมเดลที่พัฒนา ประเมินผลการทำนายด้วยวิธีวิเคราะห์ความสับสน โมเดลสามารถทำนายผลได้ในผู้ป่วยอุบัติเหตุ 3,185 ราย โดยมีความถูกต้องโดยรวมร้อยละ 92.3 ความไวร้อยละ 89.8 และความจำเพาะร้อยละ 93.4 สำหรับผู้ป่วยบาดเจ็บวิกฤติ ผู้ป่วยบาดเจ็บรุนแรง ผู้ป่วยบาดเจ็บเล็กน้อยโมเดลสามารถทำนายได้ถูกต้องร้อยละ 100 ขณะที่ผู้ป่วยบาดเจ็บปานกลางมีความถูกต้องร้อยละ 91 สรุปได้ว่าปัญญาประดิษฐ์มีศักยภาพในการทำนายโอกาสการนอนโรงพยาบาลได้อย่างมีประสิทธิภาพและสามารถนำไปใช้สนับสนุนการดูแลผู้ป่วยเพื่อลดปัญหาความแออัดในแผนกฉุกเฉินได้

คำสำคัญ : ห้องฉุกเฉิน, ปัญญาประดิษฐ์, อุบัติเหตุ, การนอนโรงพยาบาล

พุทธชินราชเวชสาร 2568;42(1):79-90.

บทนำ

ประเทศไทยเป็นหนึ่งในประเทศที่มีอัตราการเสียชีวิตจากอุบัติเหตุสูง โดยในปี พ. ศ. 2565 จากรายงานของกระทรวงสาธารณสุขพบมีผู้เสียชีวิตจากอุบัติเหตุ 64,000 รายและจากข้อมูลบูรณาการอุบัติเหตุทางถนน พ.ศ. 2565 พบว่ามีผู้บาดเจ็บ 926,829 รายและเสียชีวิต 15,010 ราย กลุ่มอายุที่สูญเสียมากที่สุดเป็นกลุ่มเด็กและเยาวชนอายุ 10-19 ปี การจมน้ำเป็นสาเหตุการเสียชีวิตที่สำคัญของเด็กไทย โดยช่วง 10 ปีที่ผ่านมาเด็กไทยอายุต่ำกว่า 15 ปีเสียชีวิตจากการจมน้ำเฉลี่ยปีละ 779 คน¹ จากฐานข้อมูลด้านสุขภาพ พ.ศ. 2561-2562 รายงานข้อมูลป่วยนอกพบผู้ได้รับบาดเจ็บจากสาเหตุการถูกทำร้ายเฉลี่ย 198,637 ราย/ปี² ซึ่งเป็นปัญหาใหญ่ของระบบสาธารณสุขของประเทศ

สถานการณ์ของประเทศไทยในปัจจุบันห้องฉุกเฉินมีจำนวนผู้ป่วยมากขึ้นทำให้เกิดความแออัด ผู้ป่วยได้รับการรักษาล่าช้า³ โดยความแออัดในห้องฉุกเฉินส่งผลเสียต่อผู้ป่วยหลายประการ เช่น ระยะเวลารอนานขึ้น คุณภาพการดูแลลดลง เพิ่มความเสี่ยงต่อการติดเชื้อ เพิ่มความเสี่ยงต่อการเสียชีวิต โดยปัจจัยที่ทำให้เกิดความแออัดในห้องฉุกเฉิน ได้แก่ ความต้องการบริการฉุกเฉินที่เพิ่มขึ้นเนื่องจากการเติบโตของประชากร การขาดแคลนทรัพยากร การวางแผน และการประสานงาน

บริการฉุกเฉินที่ไม่ดีเพียงพอ ขั้นตอนการทำงานที่ไม่มีประสิทธิภาพ⁴ หนึ่งในวิธีการที่ใช้เพื่อจัดการลดความแออัดของผู้ป่วยในห้องฉุกเฉิน คือ การปรับปรุงประสิทธิภาพของขั้นตอนการทำงานของห้องฉุกเฉิน ซึ่งปัญญาประดิษฐ์มีบทบาทอย่างมากในห้องฉุกเฉิน⁵ หนึ่งในนั้นคือการนำปัญญาประดิษฐ์ไปใช้คาดการณ์โอกาสนอนโรงพยาบาลของผู้ป่วยเพื่อจัดเตรียมทรัพยากรในการดูแลผู้ป่วย

ผู้ป่วยอุบัติเหตุที่มารับบริการที่ห้องฉุกเฉินโรงพยาบาลน่าน พ.ศ. 2564 มีจำนวน 7,982 รายทำให้การดูแลผู้ป่วยขาดคุณภาพ เมื่อปัญญาประดิษฐ์ได้มีบทบาทในการดูแลผู้ป่วยที่ห้องฉุกเฉินผู้วิจัยจึงสร้างปัญญาประดิษฐ์เพื่อทำนายโอกาสนอนโรงพยาบาลสำหรับผู้ป่วยอุบัติเหตุเพื่อให้เจ้าหน้าที่ทราบถึงโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุ โดยใช้ข้อมูลดูแลผู้ป่วยได้อย่างมีประสิทธิภาพและเตรียมการสำหรับการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุเพื่อลดระยะเวลาที่ห้องฉุกเฉินและลดความหนาแน่นของผู้ป่วยที่ห้องฉุกเฉิน การศึกษานี้จึงมีวัตถุประสงค์เพื่อประเมินประสิทธิภาพของปัญญาประดิษฐ์ในการทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุ โดยการคาดการณ์โอกาสการเข้ารับรักษาตัวในโรงพยาบาล

ล่วงหน้าจะช่วยให้นักลากรทางการแพทย์สามารถวางแผนการดูแลผู้ป่วยได้อย่างมีประสิทธิภาพ ลดระยะเวลาในห้องฉุกเฉิน และเพิ่มประสิทธิภาพในการบริหารทรัพยากร

วัสดุและวิธีการ

การศึกษาแบบการสังเกตย้อนหลัง (retrospective observative) ครั้งนี้ประเมินประสิทธิภาพของปัญญาประดิษฐ์โดยการเรียนรู้ของเครื่อง (machine learning) แบบมีผู้สอน (supervise learning) ในรูปแบบต้นไม้แห่งการตัดสินใจ (decision tree) ที่พัฒนาจากข้อมูลของผู้ป่วยอุบัติเหตุที่มารับการรักษาที่ห้องฉุกเฉิน โรงพยาบาลน่านในการทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุที่มารับการรักษาที่ห้องฉุกเฉิน โรงพยาบาลน่านระหว่างวันที่ 1 มกราคม พ.ศ. 2566 ถึงวันที่ 30 เมษายน พ.ศ. 2566 ทั้งหมดจำนวน 3,185 ราย โดยไม่รวมผู้ป่วยที่ข้อมูลไม่ครบถ้วน, ผู้ป่วยที่เสียชีวิตก่อนมาถึงห้องฉุกเฉินและเสียชีวิตที่ห้องฉุกเฉิน, ผู้ป่วยที่ส่งต่อไปรักษาที่สถานพยาบาลอื่น และผู้ป่วยที่หลบหนีจากโรงพยาบาลหรือปฏิเสธการรักษา

ทั้งนี้ข้อมูลที่ใช้สร้างและทดสอบปัญญาประดิษฐ์มาจากข้อมูลระบบเฝ้าระวังการบาดเจ็บ (Injury surveillance) และเวชระเบียนอิเล็กทรอนิกส์จากฐานข้อมูลผู้ป่วยของโรงพยาบาลน่าน เก็บข้อมูลโดยพยาบาลที่ดูแลผู้ป่วยที่ห้องฉุกเฉินก่อนที่จะจำหน่ายออกจากห้องฉุกเฉิน ซึ่งประกอบด้วยข้อมูลดังต่อไปนี้ 1) ประเภทการบาดเจ็บ ประกอบด้วยอุบัติเหตุ ทำร้ายตนเอง ผู้อื่นทำร้าย, 2) การมาโรงพยาบาล ประกอบด้วยไม่ผ่านระบบการแพทย์ฉุกเฉิน ผ่านระบบการแพทย์ฉุกเฉิน และผ่านระบบส่งต่อระหว่างสถานพยาบาล, 3) การรักษาที่ก่อนมาโรงพยาบาล ประกอบด้วย การดูแล การหายใจ การห้ามเลือด การตามกระดูกสันหลังส่วนคอ การตามกระดูก การให้สารน้ำทางหลอดเลือดดำ โดยแบ่งเป็น 3 ประเภท คือ ได้รับการรักษา ไม่ได้รักษา และไม่มี ความจำเป็นต้องรักษา, 4) การปรึกษาแพทย์เฉพาะทาง ประกอบด้วยได้ปรึกษาแพทย์เฉพาะทางและไม่ได้ปรึกษาแพทย์เฉพาะทาง, 5) กลไกการบาดเจ็บ ประกอบด้วย การบาดเจ็บจากการกระทบกับของแข็งไม่มีคม

การบาดเจ็บที่มีแผลทะลุเข้าไปในร่างกาย การบาดเจ็บจากการกระทบกับของแข็งไม่มีคมร่วมกับการบาดเจ็บที่มีแผลทะลุเข้าไปในร่างกาย และการบาดเจ็บอื่นๆ, 6) ตำแหน่งที่บาดเจ็บ ประกอบด้วยการบาดเจ็บของศีรษะและคอ การบาดเจ็บที่ใบหน้า การบาดเจ็บที่ทรวงอก การบาดเจ็บที่ช่องท้อง การบาดเจ็บของกระดูกเชิงกรานและรยางค์ การบาดเจ็บที่ผิวหนังและอื่น ๆ โดยแบ่งความรุนแรงดังต่อไปนี้ (1) ไม่บาดเจ็บ (2) บาดเจ็บเล็กน้อย (3) บาดเจ็บปานกลาง (4) บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต (5) บาดเจ็บมากและคุกคามต่อชีวิต (6) บาดเจ็บวิกฤต ไม่แน่ใจในโอกาสรอดชีวิต (7) บาดเจ็บรุนแรงที่สุดส่วนใหญ่ไม่รอดชีวิต ส่วนประเภทการคัดแยกความรุนแรงของผู้บาดเจ็บ ประกอบด้วย ผู้ป่วยบาดเจ็บวิกฤต (resuscitation), ผู้ป่วยบาดเจ็บรุนแรง (emergency), ผู้ป่วยบาดเจ็บปานกลาง (urgency), ผู้ป่วยบาดเจ็บเล็กน้อย (semi-urgency) สำหรับประเภทการจำหน่ายออกจากห้องฉุกเฉินประกอบด้วย นอนโรงพยาบาลและจำหน่ายกลับบ้าน

ผู้วิจัยได้สร้างและทดสอบปัญญาประดิษฐ์ด้วยเครื่องมือแบบโอเพนซอร์ส (open source software) ซึ่งเป็นโปรแกรมที่เปิดให้ใช้งานอย่างเสรีและถูกต้องตามลิขสิทธิ์ โดยใช้โปรแกรม Google colab และภาษา Python (version 3.10) ใช้ไลบรารี Pandas (version: 2.0.1), Numpy (version 1.24.2), Joblib (version 1.6.1) และ Sklearn (version 1.2.2) ประกอบด้วยขั้นตอนการติดตั้งไลบรารีบนโปรแกรม Google colab แล้วนำข้อมูลที่จะใช้สร้างปัญญาประดิษฐ์ประกอบด้วยข้อมูลผู้ป่วยอุบัติเหตุที่มารับการรักษาที่โรงพยาบาลน่านระหว่างวันที่ 1 มกราคม พ.ศ. 2565 ถึงวันที่ 30 ธันวาคม พ.ศ. 2565 เข้าสู่โปรแกรม Google colab จากนั้นสร้างปัญญาประดิษฐ์โดยใช้ไลบรารี Sklearn version 1.2.2 โดยการสร้างแบ่งข้อมูลเป็น 2 ส่วน คือ ข้อมูลสำหรับใช้สอนปัญญาประดิษฐ์ร้อยละ 70 และข้อมูลใช้ทดสอบความแม่นยำระหว่างการสร้างปัญญาประดิษฐ์ร้อยละ 30 โดยแบ่งข้อมูลแบบสุ่ม เริ่มด้วยการนำข้อมูลประชากรที่ศึกษาเข้าสู่โปรแกรม Google colab จากนั้นให้ปัญญาประดิษฐ์ทำนายผลการนอนโรงพยาบาลของประชากรที่ศึกษา แล้วนำข้อมูลที่

ปัญญาประดิษฐ์ทำนายออกมาในรูปแบบไฟล์ excel เพื่อวิเคราะห์ข้อมูลทางสถิติ หลังจากตรวจสอบความถูกต้องครบถ้วนของข้อมูล นำเสนอข้อมูลส่วนบุคคล และข้อมูลทางคลินิกประกอบด้วยเพศ อายุ ประเภทการบาดเจ็บ การมาโรงพยาบาล การรักษาก่อนมาโรงพยาบาล ลักษณะการบาดเจ็บ การปรึกษาแพทย์เฉพาะทาง ประเภทการคัดแยกความรุนแรง ประเภทการจำหน่ายออกจากห้องฉุกเฉิน การทำนายประเภทการจำหน่ายออกจากห้องฉุกเฉิน แจกแจงเป็นค่าความถี่และร้อยละ เปรียบเทียบข้อมูลระหว่างกลุ่มผู้ป่วยที่ปัญญาประดิษฐ์ทำนายว่านอนโรงพยาบาลหรือจำหน่ายกลับบ้านด้วยสถิติ chi-square test จากนั้นประเมินประสิทธิภาพของปัญญาประดิษฐ์ในการทำนายโอกาสการนอนโรงพยาบาลด้วยกราฟที่ประเมินประสิทธิภาพของแบบจำลอง (Receiver operating characteristic curve) โดยใช้ค่าพื้นที่ใต้กราฟ (area under curve: AUC) และการวิเคราะห์ความสับสน โดยใช้ค่าความแม่นยำ (accuracy), ค่าความไว (sensitivity) และค่าความจำเพาะ (specificity) การวิจัยนี้ได้ผ่านการพิจารณารับรองโดยคณะกรรมการจริยธรรมการวิจัยในมนุษย์โรงพยาบาลน่าน เลขที่ 031/2566 เดือนสิงหาคม พ.ศ. 2566

ผลการศึกษา

ผู้ป่วยอุบัติเหตุที่มานำมาทดสอบประสิทธิภาพของปัญญาประดิษฐ์ 3,185 รายนั้นเมื่อให้ปัญญาประดิษฐ์ทำนายประเภทการจำหน่ายออกจากห้องฉุกเฉินพบว่า มีผู้ป่วยที่ต้องนอนโรงพยาบาล 1,005 ราย (ร้อยละ 31.6) และกลุ่มที่จำหน่ายกลับบ้าน 2,180 ราย (ร้อยละ 68.4) โดยกลุ่มที่ปัญญาประดิษฐ์ทำนายว่านอนโรงพยาบาลและกลุ่มที่ปัญญาประดิษฐ์ทำนายว่าจำหน่ายกลับบ้านนั้นเป็นเพศชาย 692 ราย (ร้อยละ 68.9) และ 1,231 ราย (ร้อยละ 56.5) ตามลำดับ ($p < 0.001$), อายุตั้งแต่ 61 ปีขึ้นไป 280 ราย (ร้อยละ 27.9) และ 450 ราย (ร้อยละ 20.7) ตามลำดับ ($p < 0.001$), โดยประเภทการบาดเจ็บจากอุบัติเหตุ 937 ราย

(ร้อยละ 93.2) และ 2,097 ราย (ร้อยละ 96.2) ตามลำดับ ($p < 0.001$), การมาโรงพยาบาลผ่านระบบส่งต่อระหว่างสถานพยาบาล 494 ราย (ร้อยละ 49.2) และ 40 ราย (ร้อยละ 1.8) ตามลำดับ ($p < 0.001$), ได้รับการรักษาด้วยการห้ามเลือด 587 ราย (ร้อยละ 58.4) และ 786 ราย (ร้อยละ 36) ตามลำดับ ($p < 0.001$), ไม่จำเป็นต้องตามกระดูกสันหลังส่วนคอ 743 ราย (ร้อยละ 73.9) และ 2,118 ราย (ร้อยละ 97.2) ตามลำดับ ($p < 0.001$), ไม่จำเป็นต้องตามกระดูก 597 ราย (ร้อยละ 59.4) และ 1,771 ราย (ร้อยละ 81.2) ตามลำดับ ($p < 0.001$), ไม่จำเป็นต้องให้สารน้ำทางหลอดเลือดดำ 560 ราย (ร้อยละ 55.7) และ 2,171 ราย (ร้อยละ 99.6) ตามลำดับ ($p < 0.001$), ลักษณะการบาดเจ็บเกิดจากการกระทบของแข็งไม่มีคม 725 ราย (ร้อยละ 72.1) และ 1,572 ราย (ร้อยละ 72.1) ตามลำดับ ($p < 0.001$), ได้ปรึกษาแพทย์เฉพาะทาง 972 ราย (ร้อยละ 96.7) และ 227 ราย (ร้อยละ 10.4) ตามลำดับ ($p < 0.001$), ได้จำหน่ายออกจากห้องฉุกเฉินโดยการนอนโรงพยาบาล 858 ราย (ร้อยละ 85.4) และ 97 ราย (ร้อยละ 4.5) ตามลำดับ ($p < 0.001$), โดยระดับความรุนแรงเป็นผู้บาดเจ็บปานกลาง 709 ราย (ร้อยละ 70.5) และ 2,152 ราย (ร้อยละ 98.7) ตามลำดับ ($p < 0.001$) ดูรายละเอียดในตารางที่ 1

จากข้อมูลประสิทธิภาพของปัญญาประดิษฐ์ผู้ป่วยทั้งหมดมีค่าความไวอยู่ที่ 89.8% (95%CI 0.812, 0.943) และค่าความจำเพาะอยู่ที่ 93.4% (95%CI 0.861, 0.971) มีค่าความแม่นยำทั้งหมด 92.3% (95%CI 0.848, 0.964) ในผู้ป่วยบาดเจ็บวิกฤติ, ผู้บาดเจ็บรุนแรง และผู้ป่วยบาดเจ็บเล็กน้อย (semi-urgency) มีค่าความแม่นยำเป็น 100% (95%CI 0.963, 1); ผู้บาดเจ็บปานกลาง มีค่าความไว 85.2% (95%CI 0.764, 0.913) มีค่าความจำเพาะ 93.3% (95%CI 0.861, 0.971) และมีค่าความแม่นยำ 91% (95%CI 0.863, 0.958) ดูรายละเอียดในตารางที่ 2 ส่วนการวัดประสิทธิภาพด้วยค่าพื้นที่ใต้กราฟ (AUC) ในผู้ป่วยทั้งหมดมีค่าพื้นที่ใต้กราฟ 0.916 (95%CI 0.904, 0.929) และผู้ป่วยบาดเจ็บ

ปานกลางมีค่าได้กราฟ 0.893 (95%CI 0.876, 0.910) แต่ไม่สามารถหาค่าพื้นที่ใต้กราฟในผู้ป่วยบาดเจ็บวิกฤติ, ผู้ป่วยบาดเจ็บรุนแรง และผู้ป่วยบาดเจ็บเล็กน้อยได้

เนื่องจากเนื่องจากค่าความไวและค่าความแม่นยำ เท่ากับศูนย์ ดังแสดงในรูปที่ 1

ตารางที่ 1 ข้อมูลส่วนบุคคลและข้อมูลทางคลินิกของผู้ป่วยอุบัติเหตุระหว่างกลุ่มที่ทำนายว่านอนโรงพยาบาลและจำหน่ายกลับบ้าน (n = 3,185)

ข้อมูลส่วนบุคคล/ข้อมูลทางคลินิก	จำนวนผู้ป่วย (ร้อยละ)		p-value ^a
	การทำนายประเภทการจำหน่ายจากห้องฉุกเฉิน		
	นอนโรงพยาบาล (n = 1,005)	จำหน่ายกลับบ้าน (n = 2,180)	
เพศ			< 0.001
ชาย	692 (68.7)	1,231 (56.5)	
หญิง	313 (31.1)	949 (43.5)	
อายุ (ปี)			< 0.001
0-15	111 (11.0)	444 (20.4)	
16-30	193 (19.2)	513 (23.5)	
31-45	184 (18.3)	365 (16.7)	
46-60	237 (23.6)	408 (18.7)	
> 60	280 (27.9)	450 (20.7)	
ประเภทการบาดเจ็บ			< 0.001
อุบัติเหตุ	937 (93.2)	2,097 (96.2)	
ทำร้ายตนเอง	31 (3.1)	5 (0.2)	
ผู้อื่นทำร้าย	37 (3.7)	78 (3.6)	
การมาโรงพยาบาล			< 0.001
ไม่ผ่านระบบ	174 (17.3)	1,821 (74.4)	
ระบบการแพทย์ฉุกเฉิน	337 (33.5)	519 (23.8)	
ระบบส่งต่อระหว่างสถานพยาบาล	494 (49.2)	40 (1.8)	
การดูแลการหายใจ			< 0.001
ได้ดูแล	172 (17.1)	16 (0.7)	
ไม่ได้ดูแล	10 (1.0)	8 (0.4)	
ไม่จำเป็น	823 (81.9)	2,156 (98.9)	
การห้ามเลือด			< 0.001
ได้ห้ามเลือด	587 (58.4)	786 (36.0)	
ไม่ได้ห้ามเลือด	50 (5.0)	392 (18.0)	
ไม่จำเป็น	368 (36.6)	1,002 (46.0)	
การตามกระดูกสันหลังส่วนคอ			< 0.001
ได้ตาม	251 (25.0)	46 (2.1)	
ไม่ได้ตาม	11 (1.1)	16 (0.7)	
ไม่จำเป็น	743 (73.9)	2,118 (97.2)	

ตารางที่ 1 ข้อมูลส่วนบุคคลและข้อมูลทางคลินิกของผู้ป่วยอุบัติเหตุระหว่างกลุ่มที่ทำนายว่านอนโรงพยาบาลและจำหน่ายกลับบ้าน (n = 3,185) (ต่อ)

ข้อมูลส่วนบุคคล/ข้อมูลทางคลินิก	จำนวนผู้ป่วย (ร้อยละ)		p-value ^a
	การทำนายประเภทการจำหน่ายจากห้องฉุกเฉิน		
	นอนโรงพยาบาล (n = 1,005)	จำหน่ายกลับบ้าน (n = 2,180)	
การตามกระดูก			< 0.001
ได้ตาม	370 (36.8)	196 (9.0)	
ไม่ได้ตาม	38 (3.8)	213 (9.8)	
ไม่จำเป็น	597 (59.4)	1,771 (81.2)	
การให้สารน้ำทางหลอดเลือดดำ			< 0.001
ได้ให้	442 (44.0)	8 (0.3)	
ไม่ได้ให้	3 (0.3)	1 (0.1)	
ไม่จำเป็น	560 (55.7)	2,171 (99.6)	
ลักษณะการบาดเจ็บ			< 0.001
บาดเจ็บจากการกระทบของแข็งไม่มีคม	725 (72.1)	1,572 (72.1)	
บาดเจ็บที่มีแผลทะลุเข้าไปในร่างกาย	95 (9.5)	354 (16.2)	
บาดเจ็บจากการกระทบของแข็งไม่มีคมร่วมกับ			
บาดเจ็บที่มีแผลทะลุเข้าไปในร่างกาย	110 (10.9)	82 (3.8)	
อื่น ๆ	75 (7.5)	172 (7.9)	
การปรึกษาแพทย์เฉพาะทาง			< 0.001
ได้ปรึกษาแพทย์เฉพาะทาง	972 (96.7)	227 (10.4)	
ไม่ได้ปรึกษาแพทย์เฉพาะทาง	33 (3.3)	1,953 (89.6)	
ประเภทการจำหน่ายออกจากห้องฉุกเฉิน			< 0.001
นอนโรงพยาบาล	858 (85.4)	97 (4.5)	
จำหน่ายกลับบ้าน	147 (14.6)	2,083 (95.5)	
การบาดเจ็บของศีรษะและคอ			< 0.001
ไม่บาดเจ็บ	715 (71.2)	2,034 (93.3)	
บาดเจ็บเล็กน้อย	23 (2.3)	123 (5.6)	
บาดเจ็บปานกลาง	170 (16.9)	22 (1.0)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	14 (1.4)	0	
บาดเจ็บมากและคุกคามต่อชีวิต	7 (7.1)	1 (0.1)	
บาดเจ็บวิกฤต ไม่แน่ใจในโอกาสรอดชีวิต	1 (1.1)	0	
การบาดเจ็บที่ใบหน้า			< 0.001
ไม่บาดเจ็บ	891 (88.7)	2,129 (97.7)	
บาดเจ็บเล็กน้อย	10 (1.0)	47 (2.2)	
บาดเจ็บปานกลาง	98 (9.6)	3 (0.1)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	6 (0.6)	0	
ไม่ทราบ/ระบุไม่ได้	0	1 (0.1)	

ตารางที่ 1 ข้อมูลส่วนบุคคลและข้อมูลทางคลินิกของผู้ป่วยอุบัติเหตุระหว่างกลุ่มที่ทำนายว่านอนโรงพยาบาลและจำหน่ายกลับบ้าน (n = 3,185)

ข้อมูลส่วนบุคคล/ข้อมูลทางคลินิก	จำนวนผู้ป่วย (ร้อยละ)		p-value ^a
	การทำนายประเภทการจำหน่ายจากห้องฉุกเฉิน		
	นอนโรงพยาบาล (n = 1,005)	จำหน่ายกลับบ้าน (n = 2,180)	
การบาดเจ็บที่ทรวงอก			
ไม่บาดเจ็บ	951 (94.6)	2,125 (97.5)	< 0.001
บาดเจ็บเล็กน้อย	0	46 (2.1)	
บาดเจ็บปานกลาง	35 (3.5)	9 (0.4)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	15 (1.5)	0	
บาดเจ็บมากและคุกคามต่อชีวิต	4 (0.4)	0	
การบาดเจ็บที่ช่องท้อง			
ไม่บาดเจ็บ	960 (95.5)	2,169 (99.5)	< 0.001
บาดเจ็บเล็กน้อย	1 (0.1)	10 (0.4)	
บาดเจ็บปานกลาง	28 (2.9)	1 (0.1)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	10 (1.0)	0	
บาดเจ็บมากและคุกคามต่อชีวิต	5 (0.5)	0	
การบาดเจ็บที่กระดูกเชิงกรานและรยางค์			
ไม่บาดเจ็บ	561 (55.8)	1,757 (80.6)	< 0.001
บาดเจ็บเล็กน้อย	11 (1.1)	223 (10.2)	
บาดเจ็บปานกลาง	329 (32.7)	167 (7.7)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	99 (9.9)	33 (1.5)	
บาดเจ็บมากและคุกคามต่อชีวิต	5 (0.5)	0	
การบาดเจ็บที่ผิวหนัง			
ไม่บาดเจ็บ	620 (61.7)	658 (30.2)	< 0.001
บาดเจ็บเล็กน้อย	302 (30.1)	1,503 (68.9)	
บาดเจ็บปานกลาง	77 (7.7)	19 (0.9)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	6 (0.5)	0	
การบาดเจ็บตำแหน่งอื่น ๆ			
ไม่บาดเจ็บ	901 (89.7)	2,032 (93.2)	< 0.001
บาดเจ็บปานกลาง	0	1 (0.1)	
บาดเจ็บมากแต่ไม่คุกคามต่อชีวิต	1 (0.1)	0	
ไม่ทราบ/ระบุไม่ได้	103 (10.2)	147 (6.7)	
ระดับความรุนแรง			
ผู้ป่วยบาดเจ็บวิกฤต	62 (6.2)	0	< 0.001
ผู้ป่วยบาดเจ็บรุนแรง	234 (23.3)	0	
ผู้ป่วยบาดเจ็บปานกลาง	709 (70.5)	2,152 (98.7)	
ผู้ป่วยบาดเจ็บเล็กน้อย	0	28 (1.3)	


^aChi-square test

ตารางที่ 2 ประสิทธิภาพของปัญญาประดิษฐ์ในผู้ป่วยอุบัติเหตุจำแนกตามระดับความรุนแรง (n = 3,185)


ประเภทผู้ป่วย	ความไว	95%CI		ความจำเพาะ	95%CI		ความแม่นยำ	95%CI	
		Lower bound	Upper bound		Lower bound	Upper bound		Lower bound	Upper bound
ผู้ป่วยทั้งหมด (n = 3,185)	89.8%	0.812	0.943	93.4%	0.861	0.971	92.3%	0.848	0.964
ผู้ป่วยบาดเจ็บวิกฤต (n = 62)	100%	0.963	1	N/A	N/A	N/A	100%	0.963	1
ผู้ป่วยบาดเจ็บรุนแรง (n = 234)	100%	0.963	1	N/A	N/A	N/A	100%	0.963	1
ผู้ป่วยบาดเจ็บปานกลาง (n = 2,861)	85.2%	0.764	0.913	93.3%	0.861	0.971	91%	0.863	0.958
ผู้ป่วยบาดเจ็บเล็กน้อย (n = 28)	N/A	N/A	N/A	100%	0.963	1	100%	0.963	1

N/A หมายถึง ไม่สามารถคำนวณค่าได้

ผู้ป่วยทั้งหมด



ผู้ป่วยบาดเจ็บปานกลาง



รูปที่ 1 การประเมินประสิทธิภาพของแบบจำลอง (ROC) ของผู้ป่วยทั้งหมดและผู้ป่วยบาดเจ็บปานกลาง

ROC curve: receiver operating characteristic curve, AUC: area under curve

วิจารณ์

เมื่อพิจารณาระเบียบวิธีวิจัยที่ใช้ในงานวิจัยนี้ผู้วิจัยได้เลือกใช้การสร้างปัญญาประดิษฐ์ประเภทการเรียนรู้ของเครื่องแบบต้นไม้แห่งการตัดสินใจเพื่อทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุที่มารับการรักษาที่โรงพยาบาลน่าน เนื่องจากปัญญาประดิษฐ์โดยการเรียนรู้ของเครื่องแบบต้นไม้แห่งการตัดสินใจมักต้องการข้อมูลจำนวนมากและคุณภาพดีเพื่อการเรียนรู้ซึ่งในงานวิจัยนี้ผู้วิจัยได้เตรียมข้อมูลจำนวนมากและคุณภาพดี อีกทั้งระเบียบวิธีวิจัยที่เหมาะสมทำให้ปัญญาประดิษฐ์ที่ต้องการการพิจารณาข้อมูลหลายมิติที่มีความซับซ้อนของข้อมูลสามารถทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุที่มารับการรักษาที่โรงพยาบาลน่านโดยมีความแม่นยำสูง

ข้อจำกัดของการใช้ปัญญาประดิษฐ์ในการทำนายโอกาสการเข้ารับการรักษาในโรงพยาบาลของผู้ป่วยอุบัติเหตุที่ห้องฉุกเฉินในงานวิจัยนี้ประกอบด้วยประเด็นสำคัญหลายประการ ได้แก่ ข้อมูลที่ใช้พัฒนาโมเดลมาจากโรงพยาบาลเพียงแห่งเดียว ซึ่งอาจจำกัดความสามารถการนำผลการทำนายไปใช้ในสถานพยาบาลอื่นที่มีบริบทและลักษณะผู้ป่วยแตกต่างกัน (generalizability) นอกจากนี้ โมเดลปัญญาประดิษฐ์ที่ใช้วิธีการเรียนรู้ของเครื่องแบบต้นไม้ตัดสินใจมีความไวต่อการเปลี่ยนแปลงของข้อมูล โดยการเปลี่ยนแปลงเพียงเล็กน้อยอาจส่งผลต่อโครงสร้างของโมเดลและลดความแม่นยำในการทำนายได้หากไม่ได้อัปเดตข้อมูลอย่างสม่ำเสมอ โมเดลอาจล้าสมัยและไม่สอดคล้องกับแนวทางการรักษาที่เปลี่ยนไป อีกทั้งยังมีความเสี่ยงจากการพึ่งพาการทำนายของปัญญาประดิษฐ์โดยขาดการพิจารณาจากดุลยพินิจของแพทย์ ซึ่งอาจก่อให้เกิดข้อผิดพลาดในการตัดสินใจทางคลินิกได้ นอกจากนี้ยังมีข้อกังวลเกี่ยวกับจริยธรรมและความเป็นส่วนตัวของข้อมูลผู้ป่วย ซึ่งจำเป็นต้องมีมาตรการคุ้มครองข้อมูลที่เหมาะสมเพื่อป้องกันการละเมิดสิทธิของผู้ป่วย

อนึ่ง จากผลการศึกษาวิจัยก่อนหน้านี้พบว่าปัจจัยเกี่ยวกับการบาดเจ็บและเสียชีวิตของผู้ป่วยอุบัติเหตุประกอบด้วย Glasgow Coma Scale (GCS), Injury Severity Score (ISS) และอัตราการหายใจ⁶

อายุ 60 ปีขึ้นไป โรคประจำตัว ความรุนแรงของการบาดเจ็บ ภาวะแทรกซ้อนของระบบไหลเวียนโลหิต การใช้จ่ายยาหลายหลอดเลือด การใช้เครื่องช่วยหายใจ ความผิดปกติของไต⁷ รวมทั้งได้สร้างปัญญาประดิษฐ์เพื่อทำนายโอกาสการนอนโรงพยาบาลของผู้ป่วยที่มาใช้บริการที่ห้องฉุกเฉินด้วยแบบจำลองหลายแบบโดยประกอบด้วยแบบจำลองชนิด neural networks มีค่าความไว 0.67 และค่าความจำเพาะ 0.78⁸ แบบจำลองชนิด logistic regression ซึ่งพบว่ามีความพื้นที่ใต้กราฟ (area under curve) ตั้งแต่ 0.8-0.86^{9-11,13-14} แบบจำลองชนิด Gradient powered decision tree พบว่าค่าพื้นที่ใต้กราฟ 0.84-0.86¹⁵ แบบจำลองชนิด Gradient boosting machine (GBM) มีค่าพื้นที่ใต้กราฟ 0.859 และมีค่าความแม่นยำ 80.31%¹⁶⁻¹⁷ แบบจำลองชนิด Gaussian NB พบว่ามีความพื้นที่ใต้กราฟ 0.806¹⁸ แบบจำลองชนิด Multivariate logistic regression พบว่าค่าพื้นที่ใต้กราฟของผู้ป่วยอายุน้อยกว่า 70 ปี คือ 0.86 ส่วนค่าพื้นที่ใต้กราฟของผู้ป่วยอายุมากกว่า 70 ปี คือ 0.77¹⁹ ทั้งนี้ ปัญญาประดิษฐ์ในแต่ละแบบจำลองมีความพื้นที่ใต้กราฟมากกว่า 0.5 ซึ่งแสดงว่าโมเดลทั้งหลายที่ทดสอบมีความแม่นยำมากกว่าการเดาสุ่มส่วนการใช้ปัญญาประดิษฐ์ทำนายการนอนโรงพยาบาลของผู้ป่วยอุบัติเหตุในการศึกษาครั้งนี้ผู้ป่วยทั้งหมดมีความพื้นที่ใต้กราฟ 0.916 และผู้ป่วยบาดเจ็บปานกลางมีความพื้นที่ใต้กราฟ 0.893 ซึ่งมีความพื้นที่ใต้กราฟสูงกว่าการศึกษาอื่น โดยอาจจะเป็นผลมาจากการศึกษานี้เป็นการศึกษาในผู้ป่วยที่ประสบอุบัติเหตุ ส่วนการศึกษาอื่นศึกษาทั้งผู้ป่วยที่ประสบอุบัติเหตุและผู้ป่วยฉุกเฉินทั่วไป โดยการทำงานวิจัยนี้ใช้โมเดลแบบต้นไม้แห่งการตัดสินใจเนื่องจากขณะทดสอบระหว่างการสร้างปัญญาประดิษฐ์โมเดลแบบต้นไม้แห่งการตัดสินใจให้มีความแม่นยำสูงที่สุด รวมทั้งการที่ปัญญาประดิษฐ์ที่สร้างขึ้นมีความแม่นยำสูงถึงร้อยละ 92.3 อาจจะเป็นเพราะการทำนายในผู้ป่วยอุบัติเหตุซึ่งต่างจากการศึกษาอื่นๆ ที่ทำนายในผู้ป่วยฉุกเฉินซึ่งรวมทั้งผู้ป่วยอุบัติเหตุและผู้ป่วยทั่วไป ส่วนผลการทำนายที่ผิดพลาดพบในผู้ป่วยที่บาดเจ็บบริเวณกระดูกเชิงกรานและกระดูกข้อมือ เป็นสัดส่วนสูงสุดเนื่องจากเป็นการบาดเจ็บในตำแหน่ง

ที่หลากหลาย รวมทั้งมีวิธีการแตกต่างกันแล้วแต่กรณี เช่น กรณีผู้ป่วยมีกระดูกข้อมือหักได้รับการรักษาโดยใส่เฝือก และจำหน่ายกลับบ้านหรือนอนโรงพยาบาลเพื่อผ่าตัด

ถึงแม้งานวิจัยนี้จะมีข้อมูลจำนวนมากแต่ข้อมูลทั้งหมดมาจากโรงพยาบาลหนึ่งแห่งเดียวทำให้ผลลัพธ์อาจไม่สามารถนำไปใช้กับบริบทของโรงพยาบาลอื่นได้ รวมทั้งหากแนวทางการรักษาเปลี่ยนแปลงอาจจะทำให้ความแม่นยำเปลี่ยนไปหากแนวทางการรักษาเปลี่ยนแปลงในบางโรค เช่น จำหน่ายผู้ป่วยจากห้องฉุกเฉินไปสังเกตอาการที่บ้านได้ในผู้ป่วย mild head injury, moderate risk ที่ผลเอกซเรย์คอมพิวเตอร์สมองปกติ รวมทั้งงานวิจัยที่ใช้ปัญญาประดิษฐ์โดยการเรียนรู้ของเครื่องแบบต้นไม้แห่งการตัดสินใจซึ่งการเปลี่ยนแปลงข้อมูลเพียงเล็กน้อยสามารถทำให้โครงสร้างของต้นไม้เปลี่ยนไปอย่างมาก ถึงแม้ว่าปัญญาประดิษฐ์ในงานวิจัยนี้จะมีผลแม่นยำสูง แต่การเพิ่มข้อมูลการฝึกสอนหรือการปรับปรุงปัญญาประดิษฐ์อาจช่วยเพิ่มความแม่นยำมากขึ้น รวมทั้งการสร้างและทดสอบปัญญาประดิษฐ์ด้วยข้อมูลใหม่ๆ อย่างสม่ำเสมอทำให้ทราบว่าความแม่นยำเปลี่ยนไปหรือไม่ รวมทั้งการนำไปใช้อาจจะต้องใช้ร่วมกับการตัดสินใจของมนุษย์ โดยปัญญาประดิษฐ์เป็นเพียงส่วนที่แนะนำเท่านั้น แต่การตัดสินใจการรักษาต้องขึ้นกับมนุษย์

อนึ่ง การประยุกต์ใช้ปัญญาประดิษฐ์ในงานวิจัยครั้งนี้มีข้อดีที่สำคัญคือ สามารถทำนายโอกาสการเข้ารับการรักษาในโรงพยาบาลของผู้ป่วยอุบัติเหตุได้อย่างแม่นยำ โดยมีความถูกต้องถึงร้อยละ 92.3 โดยเฉพาะในกลุ่มผู้ป่วยที่มีภาวะวิกฤติและรุนแรงที่มีความแม่นยำร้อยละ 100 ซึ่งช่วยสนับสนุนการตัดสินใจทางคลินิก ลดความแออัดในห้องฉุกเฉิน และเพิ่มประสิทธิภาพในการจัดสรรทรัพยากรทางการแพทย์ อย่างไรก็ตามการใช้ปัญญาประดิษฐ์ในงานวิจัยนี้ยังมีข้อจำกัดบางประการ ได้แก่ การใช้ข้อมูลจากโรงพยาบาลเพียงแห่งเดียวซึ่งอาจส่งผลต่อความแม่นยำหากนำไปใช้ในโรงพยาบาลอื่น ความไวต่อการเปลี่ยนแปลงของข้อมูลซึ่งอาจทำให้ประสิทธิภาพของปัญญาประดิษฐ์ลดลงหากไม่ได้ปรับปรุงอย่างต่อเนื่อง รวมถึงความเสี่ยงจากการพึ่งพาปัญญาประดิษฐ์โดยไม่ใช้วิจารณญาณ

ทางการแพทย์ และประเด็นด้านจริยธรรมเกี่ยวกับการคุ้มครองข้อมูลส่วนบุคคลของผู้ป่วย ดังนั้น เพื่อให้การนำปัญญาประดิษฐ์ไปใช้ในการดูแลผู้ป่วยมีประสิทธิภาพและความปลอดภัยสูงสุดควรพัฒนาและปรับปรุงโมเดลอย่างสม่ำเสมอ รวมทั้งขยายฐานข้อมูลจากหลายแหล่งและมีมาตรการในการคุ้มครองข้อมูลที่เหมาะสม

เอกสารอ้างอิง

1. Ministry of Public Health, Department of Disease Control, Ministry of Public Health. Annu Rep 2021, Division of Injury Prevention. Bangkok, Thailand: Aksorn Graphic and Design Publishing; 2021.[cited 2023 Sep 3]. Available from: URL: <https://ddc.moph.go.th/uploads/publish/1244420220310035829.pdf>
2. Strategy and Planning Division, Ministry of Public Health. Public Health Stat 2021. Nonthaburi, Thailand: Strategy and Planning Division, Ministry of Public Health; 2021.
3. Potipadcha K, Pichedboonkia P. Factors related to the length of stay of critically ill patients more than 2 hours at the emergency department, Chiangrai Prachanukroh Hospital, Thailand. J Emerg Med Serv Thai 2022;2(1):37-46.
4. Kongcheep S, Arpanantikul M, Pinyopasakul W, Sherwood G. Thai nurses' experiences of providing care in overcrowded emergency rooms in tertiary hospitals. Pac Rim Int J Nurs Res 2022;26(3):533-48.
5. Sittichanbuncha Y. Artificial intelligence (AI) and its use in healthcare and emergency medicine. J Emerg Med Serv Thai 2021; 1(1):91-104.

6. Jongaramrueng N, Tangsiricharoen S. Factors associated with the mortality rate in trauma patients in the Luntom EMS Center, Queen Savang Vadhana Memorial Hospital. *J Prapokklao Hosp Clin Med Educ Cent* 2022;39(1):53-62.
7. Lentsck MH, Oliveira RR de, Corona LP, Mathias TA de F. Risk factors for death of trauma patients admitted to an intensive care unit. *Rev Lat Am Enfermagem* [serial on the internet]. 2020 [cited 2023 Sep 3]; 28:1-12. Available from: URL: <https://www.scielo.br/j/rlae/a/rZxwfSxYGfjCGMLH7YQw7nn/?format=pdf&lang=en>
8. Lee JT, Hsieh CC, Lin CH, Lin YJ, Kao CY. Prediction of hospitalization using artificial intelligence for urgent patients in the emergency department. *Sci Rep* [serial on the internet]. 2021 [cited 2023 Sep 5]; 11(1):1-8. Available from: URL: <https://europepmc.org/article/MED/34593930#free-full-text>
9. Graham M, Parikh P, Hirpara S, McCarthy MC, Haut E, Parikh P. Predicting discharge disposition in trauma patients: Development, validation, and generalization of a model using the National Trauma Data Bank. *Am Surg* 2020;86(12):1703-9.
10. Cameron A, Rodgers K, Ireland A, Jamdar R, McKay GA. A simple tool to predict admission at the time of triage. *Emerg Med J* 2015;32(3):174-9.
11. Brink A, Alisma J, Brink HS, de Gelder J, Lucke JA, Mooijaart SP, et al. Prediction admission in the older population in the emergency department: The CLEARED tool. *Neth J Med* 2020;78(6):357-67.
12. Elvira Martínez CM, Fernández C, González Del Castillo J, González Armengol JJ, Villarroel P, Martín Sánchez FJ. Modelo predictor de ingreso hospitalario a la llegada al servicio de urgencias [Prediction model for in-hospital admission in patients arriving in the emergency department]. *An Sist Sanit Navar* 2012;35(2):207-17.
13. Parker CA, Liu N, Wu SX, Shen Y, Lam SSW, Ong MEH. Predicting hospital admission at the emergency department triage: A novel prediction model. *Am J Emerg Med* 2019;37(8):1498-504.
14. Feretzakis G, Karlis G, Loupelis E, Kalles D, Chatzikyriakou R, Trakas N, et al. Using machine learning techniques to predict hospital admission at the emergency department. *J Crit Care Med (Targu Mures)* 2022;8(2):107-16.
15. De Hond A, Raven W, Schinkelshoek L, Gaakeer M, Ter Avest E, Sir O, et al. Machine learning for developing a prediction model of hospital admission of emergency department patients: Hype or hope? *Int J Med Inform* 2021;152:104496. doi: 10.1016/j.ijmedinf.2021.104496
16. Graham B, Bond R, Quinn M, Mulvenna M. Using data mining to predict hospital admissions from the emergency department. *IEEE Access* 2018;6:10458-10469. doi: 10.1109/ACCESS.2018.2808843
17. Cusidó J, Comalrena J, Alavi H, Llunas L. Predicting hospital admissions to reduce crowding in the emergency departments. *Appl Sci* [serial on the internet]. 2022 [cited 2023 Sep 3];12(21):1-17. Available from: URL: <https://upcommons.upc.edu/handle/2117/375678>

18. Feretzakis G, Sakagianni A, Loupelis E, Karlis G, Kalles D, Tzelves L, et al. Predicting hospital admission for emergency department patients: A machine learning approach. *Stud Health Technol Inform* 2022;289:297-300. doi: 10.3233/SHTI210918
19. Lucke JA, de Gelder J, Clarijs F, Heringhaus C, de Craen AJM, Fogteloo AJ, et al. Early prediction of hospital admission for emergency department patients: A comparison between patients younger or older than 70 years. *Emerg Med J* 2018; 35(1):18-27.