



การทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของ
เครื่อง

PREDICTION OF 72-HOUR RE-VISIT TO THE EMERGENCY DEPARTMENT USING
MACHINE LEARNING

พิชญ์พงศ์ พูลผล

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของ
เครื่อง



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

PREDICTION OF 72-HOUR RE-VISIT TO THE EMERGENCY DEPARTMENT USING
MACHINE LEARNING



PEACHAPONG POOLPOL

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของเครื่อง

ของ

พิชญ์พงศ์ พูลผล

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรพร เหล่าหะเกียรติ) (อาจารย์ ดร.สุทธิพงศ์ รัชชยพงษ์)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.วราภรณ์ วิทยานนท์)

ชื่อเรื่อง	การทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของเครื่อง
ผู้วิจัย	พิชญ์พงศ์ พูลผล
ปริญญา	วิทยาศาสตรมหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. ศิริสรรพ เหล่าหะเกียรติ

ผู้ป่วยที่มารับบริการที่แผนกฉุกเฉินที่ได้รับการอนุญาตโดยแพทย์ให้สามารถกลับบ้านได้ แต่กลับมีอาการที่รุนแรงขึ้นและต้องกลับเข้ามาใช้บริการซ้ำที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง อาจเกิดจากการประเมินของแพทย์ที่เกิดความคลาดเคลื่อน ซึ่งส่งผลกระทบต่อผลลัพธ์ของการรักษาผู้ป่วยเทียบกับการรับตัวไว้รักษาในโรงพยาบาลหรือได้รับการส่งต่อ การวิจัยนี้ทำขึ้นเพื่อประยุกต์ใช้การเรียนรู้ของเครื่องมาช่วยทำนายการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง เพื่อช่วยสนับสนุนแพทย์ประจำแผนกฉุกเฉินในการประเมินผู้ป่วยหลังได้รับอนุญาตให้สามารถกลับบ้านได้ โดยใช้ข้อมูลชุด MIMIC-IV-ED ซึ่งเป็นข้อมูลจากฐานข้อมูลเวชระเบียนของแผนกฉุกเฉินที่ Beth Israel Deaconess Medical Center เมืองบอสตัน ประเทศสหรัฐอเมริกา ระหว่างปี ค.ศ. 2011 – ค.ศ. 2019 จากเว็บไซต์ Physionet หลังจากได้มีการเตรียมข้อมูลและทำความสะอาดข้อมูลแล้ว มีจำนวนการเข้ารับบริการที่แผนกฉุกเฉินทั้งหมด 220,378 ครั้งโดยมีการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง 10,172 ครั้ง (4.61%) ใช้ตัวแปรทั้งหมด 22 ตัวแปร ประกอบด้วย เพศ เชื้อชาติ อายุ วิธีการเดินทางมาที่แผนกฉุกเฉิน ระดับการประเมินความรุนแรงและเร่งด่วน สัญญาณชีพระหว่างรักษาตัวอยู่ในแผนกฉุกเฉิน (ได้แก่ อุณหภูมิร่างกาย อัตราการเต้นของหัวใจ อัตราการหายใจ ค่าระดับความเข้มข้นของออกซิเจนในเลือด ความดันโลหิตซิสโตลิก ความดันโลหิตไดแอสโตลิก และระดับความปวด) ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน และผลการวินิจฉัย ซึ่งฝึกฝนด้วยข้อมูลทั้งแบบที่มีความไม่สมดุลของข้อมูล และข้อมูลที่ใช้วิธีการจัดการความไม่สมดุลของข้อมูล 4 วิธี คือ Random oversampling, SMOTE, Random undersampling และ Class weight เพื่อนำมาเปรียบเทียบประสิทธิภาพของแบบจำลอง 4 ประเภทหลัก ได้แก่ Logistic regression, KNN classifier, Random forest classifier และ XGBoost classifier สร้างออกมาเป็นแบบจำลองทั้งหมด 29 แบบ พบว่า ข้อมูลที่ไม่มีการจัดการความไม่สมดุลส่งผลให้แบบจำลองมีค่า Accuracy สูงถึง 0.95 แต่ค่า Recall เท่ากับ 0 ซึ่งมี AUC เท่ากับ 0.5 ไม่แตกต่างจากการทำนายแบบสุ่ม แต่เมื่อมีการจัดการความไม่สมดุลของข้อมูล แต่ละวิธีของการจัดการความไม่สมดุลของข้อมูลได้ผลดีกว่าแต่ไม่แตกต่างกัน โดยแบบจำลองที่ใช้วิธี Logistic regression ได้ค่า AUC สูงที่สุด คือเท่ากับ 0.61 ซึ่งแสดงให้เห็นว่าอาจไม่จำเป็นต้องใช้แบบจำลองที่ซับซ้อนในการทำนาย การใช้แบบจำลองทางสถิติอย่างง่ายอาจเพียงพอ แต่ทั้งนี้ค่า AUC ที่ได้จากงานวิจัยนี้ยังไม่สูงมากพอที่จะนำไปใช้ต่อ ซึ่งอาจเป็นผลมาจากจำนวนตัวแปรที่ใช้ในการทำนายมีน้อย รวมถึงข้อมูลที่นำมาใช้มีข้อมูลที่ถูกรบกวนค่อนข้างมากเนื่องจากไม่ได้ถูกออกแบบมาให้เก็บในรูปแบบมาตรฐาน ทั้งนี้จากการสร้างแบบจำลองพบว่า ตัวแปรที่มีความสำคัญ ได้แก่ การวินิจฉัย เพศ อายุ เชื้อชาติ ระดับความปวด ระยะเวลาการอยู่ในแผนกฉุกเฉิน อัตราการเต้นของหัวใจ

คำสำคัญ : แผนกฉุกเฉิน, การกลับเข้ามาใช้บริการซ้ำ, 72 ชั่วโมง

Title	PREDICTION OF 72-HOUR RE-VISIT TO THE EMERGENCY DEPARTMENT USING MACHINE LEARNING
Author	PEACHAPONG POOLPOL
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Assistant Professor Dr. Sirisup Laohakiat

Patients who are discharged from the emergency department (ED) with the approval of a physician, but experience a worsening of symptoms and require a revisit to the ED within 72 hours may face complications due to potential misjudgments in the initial assessment, affecting patient outcomes compared to hospitalization or referral. This thesis aims to develop machine learning to predict re-visits to ED within 72 hours among patients who are discharged from the ED, supporting emergency physicians in evaluating patient risks for re-visit after discharge. Utilizing the MIMIC-IV-ED dataset from Beth Israel Deaconess Medical Center in Boston, Massachusetts, USA, spanning from 2011 to 2019. This dataset, available on Physionet, contains 220,378 emergency department visits with 10,090 (4.58%) resulting in a revisit within 72 hours with a total of 22 variables, including gender, race, age, mode of arrival, acuity level, body temperature, heart rate, respiratory rate, oxygen saturation, systolic blood pressure, diastolic blood pressure, pain score, length of stay in the ED, and diagnosis. After data preparation and cleaning, the study investigates techniques for handling data imbalance, including Random Oversampling, SMOTE, Random Undersampling, and Class Weight, in order to train various models: Logistic Regression, KNN Classifier, Random Forest Classifier, and XGBoost Classifier, a total of 29 models. The findings indicate that addressing data imbalance significantly affects model learning, with accuracies reaching up to 0.95 but recall at zero, resulting in an AUC of 0.5, which is equivalent to random prediction. However, the performance of the imbalance management methods did not show any significant differences, with the Logistic Regression models achieving the highest AUC at 0.61. This suggests that complex models may not be necessary and that simple statistical models, such as Logistic Regression, could be sufficient. Nevertheless, the moderate AUC values suggest there is room for improvement, possibly due to the limited variables and the noisy nature of the data, which was not designed for standardized collection. The key predictive variables identified include diagnosis, gender, age, race, pain scores, length of stay in the ED, and heart rate.

Keyword : Emergency Department, Re-visit, 72 hours

กิตติกรรมประกาศ

ขอกราบขอบพระคุณ ผศ.ดร.ศิริสรรพ เหล่าหะเกียรติ อาจารย์ที่ปรึกษาสารนิพนธ์ด้วยความเคารพอย่างสูง ที่ได้กรุณาช่วยเหลือและแนะนำในการจัดทำสารนิพนธ์ฉบับนี้ รวมถึงกรุณาติดตาม สอบถาม และให้ความช่วยเหลือ จนสารนิพนธ์ฉบับนี้เสร็จสมบูรณ์

ขอกราบขอบพระคุณ ดร. สุทธิพงษ์ รัชชยพงษ์ และ ผศ. ดร. วราภรณ์ วิทยานนท์ ที่ได้กรุณาเป็นคณะกรรมการสอบสารนิพนธ์ฉบับนี้ และให้ข้อเสนอแนะในการปรับปรุงแก้ไขข้อบกพร่องในสารนิพนธ์ฉบับนี้จนเสร็จสมบูรณ์

ขอขอบพระคุณ นายพลวิทย์ วิสมภา Liam Feindt ผู้คอยให้คำปรึกษา ให้กำลังใจ และเป็นผู้สนับสนุนเป็นอย่างดีเสมอมา

ขอขอบพระคุณ อาจารย์ประจำหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และเพื่อนร่วมชั้นเรียน ที่คอยให้ความรู้ สนับสนุนเป็นอย่างดี

สุดท้ายนี้ขอกราบขอบพระคุณ พันจ่าอากาศเอกพีระพงศ์ พูลผล ผู้เป็นบิดา นาวาอากาศเอกพิเศษหญิง สุวรรณา พูลผล ผู้เป็นมารดา ที่อบรมเลี้ยงดู ให้การศึกษา รวมถึงนางสาว ศรัญญา พูลผล ผู้เป็นน้องสาวที่คอยให้กำลังใจในการทำสารนิพนธ์ฉบับนี้จนสำเร็จ

พีชญ์พงศ์ พูลผล

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
วัตถุประสงค์ของการวิจัย.....	2
กรอบแนวคิดการวิจัย.....	2
ประโยชน์ที่คาดว่าจะได้รับ.....	2
ข้อจำกัดในการวิจัย.....	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	4
การรับบริการที่แผนกฉุกเฉินและการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง	4
การเรียนรู้ของเครื่อง (Machine learning)	4
แบบจำลองที่ใช้ในการเรียนรู้ของเครื่อง	6
1. Logistic regression	6
2. K-neighbors Classification	7
3. Decision Tree Classification	7
4. Random Forest Classification	8
5. Extreme Gradient boosting (XGBoost) classification	9

การวัดประสิทธิภาพของแบบจำลอง.....	10
งานวิจัยที่เกี่ยวข้อง	12
บทที่ 3 วิธีดำเนินการวิจัย.....	15
รูปแบบการวิจัย	15
ประชากรที่ใช้ในการวิจัย.....	15
กลุ่มตัวอย่างที่ใช้ในการวิจัย.....	15
ชุดข้อมูล	15
กระบวนการทำงาน.....	25
การนำเข้าข้อมูล	26
การเตรียมข้อมูล	26
สรุปตัวแปรที่นำมาใช้ในงานวิจัย.....	36
การแปลงข้อมูลเป็นตัวเลข.....	36
การสเกลข้อมูล	37
การจัดการความไม่สมดุลของข้อมูล.....	37
การสร้างแบบจำลอง.....	37
การวัดประสิทธิภาพของแบบจำลอง.....	38
บทที่ 4 ผลการศึกษา	39
ผลของการสำรวจตัวแปร	39
ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง	46
ผลการแสดงค่าความสำคัญของตัวแปรแต่ละแบบจำลอง	78
บทที่ 5 สรุปผลการศึกษา อภิปรายผล และข้อเสนอแนะ	91
สรุปผลการศึกษา.....	91
อภิปรายผล	96

ข้อเสนอแนะ 99

บรรณานุกรม 101

ประวัติผู้เขียน 104



สารบัญตาราง

	หน้า
ตาราง 1 แสดงรายละเอียดของข้อมูลในตาราง edstays.....	18
ตาราง 2 แสดงรายละเอียดของข้อมูลในตาราง diagnosis.....	19
ตาราง 3 แสดงรายละเอียดของข้อมูลในตาราง medrecon.....	20
ตาราง 4 แสดงรายละเอียดของข้อมูลในตาราง pyxis.....	21
ตาราง 5 แสดงรายละเอียดของข้อมูลในตาราง triage.....	22
ตาราง 6 แสดงรายละเอียดของข้อมูลในตาราง vitalsign.....	23
ตาราง 7 แสดงรายละเอียดของข้อมูลในตาราง patient.....	24
ตาราง 8 แสดงร้อยละของวิธีการจำหน่ายผู้ป่วยจากแผนกฉุกเฉิน.....	29
ตาราง 9 แสดงร้อยละของวิธีการเดินทางมาแผนกฉุกเฉิน.....	30
ตาราง 10 แสดงค่า Minimum และ Maximum limit ของค่าสัญญาณชีพ.....	32
ตาราง 11 แสดงผลการสำรวจตัวแปร เพศ.....	39
ตาราง 12 แสดงผลการสำรวจตัวแปร อายุ.....	41
ตาราง 13 แสดงผลการสำรวจตัวแปร เชื้อชาติ.....	41
ตาราง 14 แสดงผลการสำรวจตัวแปร วิธีการเดินทางมาที่แผนกฉุกเฉิน.....	43
ตาราง 15 แสดงผลการสำรวจตัวแปร ระดับการประเมินความรุนแรงและเร่งด่วน.....	43
ตาราง 16 แสดงผลการสำรวจตัวแปร ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน.....	44
ตาราง 17 ผลประสิทธิภาพของแบบจำลองต่าง ๆ.....	75

สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 แสดงตัวอย่างการสร้างเส้นตรงที่ดีที่สุดของแบบจำลอง Logistic regression	6
ภาพประกอบ 2 แสดงตัวอย่างของการสร้างเส้นแบ่งกลุ่มโดยดูจากข้อมูลข้างเคียง	7
ภาพประกอบ 3 เมทริกซ์ความสับสน (Confusion Matrix)	10
ภาพประกอบ 4 Under Receiver Operating Characteristic curve ⁽¹¹⁾	11
ภาพประกอบ 5 แผนภาพแสดงกระบวนการทำงาน	25
ภาพประกอบ 6 แสดงการกระจายตัวของจำนวนครั้งของการเข้ารับบริการของผู้ป่วยต่อจำนวนผู้ป่วย	26
ภาพประกอบ 7 การกระจายตัวของอายุ	27
ภาพประกอบ 8 แสดงสัดส่วนของเพศในผู้ป่วยที่มารับบริการ	28
ภาพประกอบ 9 แสดงสัดส่วนของเชื้อชาติทั้งหมด	28
ภาพประกอบ 10 แสดงสัดส่วนของเชื้อชาติ เมื่อมีการรวมข้อมูล	29
ภาพประกอบ 11 แสดงสัดส่วนของวิธีการจำหน่ายผู้ป่วยจากแผนกฉุกเฉิน	30
ภาพประกอบ 12 แสดงสัดส่วนของวิธีการเดินทางมาแผนกฉุกเฉิน	30
ภาพประกอบ 13 แสดงการกระจายของระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉิน	31
ภาพประกอบ 14 แสดงวิธีการคำนวณระยะเวลาที่มารับบริการที่แผนกฉุกเฉินในครั้งถัดไปหลังจาก ถูกจำหน่ายออกจากแผนกฉุกเฉิน (Revisit gap time)	34
ภาพประกอบ 15 แผนภาพแสดงการเตรียมข้อมูล	35
ภาพประกอบ 16 แสดงผลการสำรวจตัวแปร เพศ	40
ภาพประกอบ 17 แสดงผลการสำรวจตัวแปร อายุ	40
ภาพประกอบ 18 แสดงผลการสำรวจตัวแปร เชื้อชาติ	42
ภาพประกอบ 19 แสดงผลการสำรวจตัวแปร วิธีการเดินทางมาที่แผนกฉุกเฉิน	42

ภาพประกอบ 20 แสดงผลการสำรวจตัวแปร ระดับการประเมินความรุนแรงและเร่งด่วน.....	44
ภาพประกอบ 21 แสดงผลการสำรวจตัวแปร ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน	45
ภาพประกอบ 22 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.1	46
ภาพประกอบ 23 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.2	47
ภาพประกอบ 24 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.3	48
ภาพประกอบ 25 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.4	49
ภาพประกอบ 26 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.5	50
ภาพประกอบ 27 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.6	51
ภาพประกอบ 28 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.7	52
ภาพประกอบ 29 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.8	53
ภาพประกอบ 30 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.9	54
ภาพประกอบ 31 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.10	55
ภาพประกอบ 32 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.11	56
ภาพประกอบ 33 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.12	57
ภาพประกอบ 34 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.13	58
ภาพประกอบ 35 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.14	59
ภาพประกอบ 36 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.15	60
ภาพประกอบ 37 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.1	61
ภาพประกอบ 38 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.2	62
ภาพประกอบ 39 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.3	63
ภาพประกอบ 40 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.4	64
ภาพประกอบ 41 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.1	65
ภาพประกอบ 42 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.2	66

ภาพประกอบ 43 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.3	67
ภาพประกอบ 44 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.4	68
ภาพประกอบ 45 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.5	69
ภาพประกอบ 46 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.1	70
ภาพประกอบ 47 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.2	71
ภาพประกอบ 48 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.3	72
ภาพประกอบ 49 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.4	73
ภาพประกอบ 50 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.5	74
ภาพประกอบ 51 แสดง feature importance ของแบบจำลองที่ 1.1	78
ภาพประกอบ 52 แสดง feature importance ของแบบจำลองที่ 1.2	79
ภาพประกอบ 53 แสดง feature importance ของแบบจำลองที่ 1.3	79
ภาพประกอบ 54 แสดง feature importance ของแบบจำลองที่ 1.4	80
ภาพประกอบ 55 แสดง feature importance ของแบบจำลองที่ 1.5	80
ภาพประกอบ 56 แสดง feature importance ของแบบจำลองที่ 1.6	81
ภาพประกอบ 57 แสดง feature importance ของแบบจำลองที่ 1.7	81
ภาพประกอบ 58 แสดง feature importance ของแบบจำลองที่ 1.8	82
ภาพประกอบ 59 แสดง feature importance ของแบบจำลองที่ 1.9	82
ภาพประกอบ 60 แสดง feature importance ของแบบจำลองที่ 1.10	83
ภาพประกอบ 61 แสดง feature importance ของแบบจำลองที่ 1.11	83
ภาพประกอบ 62 แสดง feature importance ของแบบจำลองที่ 1.12	84
ภาพประกอบ 63 แสดง feature importance ของแบบจำลองที่ 1.13	84
ภาพประกอบ 64 แสดง feature importance ของแบบจำลองที่ 1.14	85
ภาพประกอบ 65 แสดง feature importance ของแบบจำลองที่ 1.15	85

ภาพประกอบ 66 แสดง feature importance ของแบบจำลองที่ 3.1	86
ภาพประกอบ 67 แสดง feature importance ของแบบจำลองที่ 3.2	86
ภาพประกอบ 68 แสดง feature importance ของแบบจำลองที่ 3.3	87
ภาพประกอบ 69 แสดง feature importance ของแบบจำลองที่ 3.4	87
ภาพประกอบ 70 แสดง feature importance ของแบบจำลองที่ 3.5	88
ภาพประกอบ 71 แสดง feature importance ของแบบจำลองที่ 4.1	88
ภาพประกอบ 72 แสดง feature importance ของแบบจำลองที่ 4.2	89
ภาพประกอบ 73 แสดง feature importance ของแบบจำลองที่ 4.3	89
ภาพประกอบ 74 แสดง feature importance ของแบบจำลองที่ 4.4	90
ภาพประกอบ 75 แสดง feature importance ของแบบจำลองที่ 4.5	90
ภาพประกอบ 76 แสดงการเปรียบเทียบค่า Accuracy ในแต่ละแบบจำลอง	92
ภาพประกอบ 77 แสดงการเปรียบเทียบค่า Recall ในแต่ละแบบจำลอง	93
ภาพประกอบ 78 แสดงการเปรียบเทียบค่า AUC ในแต่ละแบบจำลอง	95
ภาพประกอบ 79 ภาพตัวอย่าง Confusion Matrix ที่มีค่า Accuracy เท่ากับ 0.95 แต่ Recall เป็น 0	96

บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา

แผนกฉุกเฉินเป็นแผนกที่เปิดให้บริการตลอด 24 ชั่วโมงในทุกวัน เพื่อให้บริการกับผู้ป่วยที่มีความต้องการเร่งด่วนในการรักษา และเป็นแผนกที่มีผู้ป่วยเข้ารับบริการจำนวนมาก ในขณะที่ทรัพยากรมีอย่างจำกัด ผู้ป่วยจำเป็นต้องได้รับการประเมินและจัดลำดับความรุนแรงเพื่อการรักษา ซึ่งอาจจะมีตั้งแต่แผลเล็กน้อย จนถึงผู้ป่วยที่ต้องได้รับการช่วยฟื้นคืนชีพอย่างเร่งด่วน แต่ทั้งนี้ มีผู้ป่วยเพียง 21.4% - 53.0% ที่มารับบริการที่แผนกฉุกเฉินแล้วได้รับการรับตัวไว้รักษาในโรงพยาบาล^(1,2) ในขณะที่ผู้ป่วยที่เหลือ จะได้รับการวินิจฉัย ให้การรักษา และอนุญาตให้ผู้ป่วยสามารถกลับบ้านได้ โดยอาจจะมีการนัดหมายเพื่อมาพบแพทย์ในการติดตามต่อไป โดยผู้ป่วยในกลุ่มนี้ที่ได้รับการอนุญาตจากแพทย์ให้สามารถกลับบ้านได้ จะต้องมีการประเมินจากแพทย์ที่ประจำแผนกฉุกเฉินแล้วว่าผู้ป่วยมีอาการคงที่ในระดับที่สามารถกลับไปรับการรักษาต่อที่บ้านได้

ทั้งนี้ มีผู้ป่วย 9% - 48% ที่เมื่อได้รับการอนุญาตให้สามารถกลับบ้านได้ แต่กลับมีอาการที่รุนแรงขึ้น และต้องกลับเข้ามารับบริการที่แผนกฉุกเฉิน⁽³⁾ โดยเฉพาะภายในระยะเวลา 72 ชั่วโมงหลังจากผู้ป่วยได้รับอนุญาตให้กลับบ้าน ที่อาจจะบ่งบอกว่าการประเมินของแพทย์ประจำแผนกฉุกเฉินนั้นอาจเกิดความคลาดเคลื่อน ผู้ป่วยอาจมีอาการที่ยังไม่คงที่เพียงพอ ทำให้ผู้ป่วยต้องกลับเข้ามารับบริการที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง ซึ่งหากมีระบบที่สามารถสนับสนุนแพทย์ประจำแผนกฉุกเฉินเพื่อร่วมประเมินผู้ป่วยและช่วยในการทำนายโอกาสในการกลับมารับการบริการที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง จะส่งผลต่อผลลัพธ์ของการรักษาของผู้ป่วยที่หากได้รับการรับตัวไว้รักษาในโรงพยาบาลหรือได้รับการส่งต่อตั้งแต่ครั้งแรกที่มาแผนกฉุกเฉิน เพื่อให้ผู้ป่วยอยู่ในการดูแลของบุคลากรทางการแพทย์และลดโอกาสที่จะอาการรุนแรงขึ้น เมื่อเปรียบเทียบกับอาการกลับไปรับการรักษาต่อที่บ้าน อีกทั้งยังส่งผลต่อการใช้ทรัพยากรบุคคลและทรัพยากรด้านสุขภาพได้อย่างมีประสิทธิภาพมากขึ้น ลดการซ้ำซ้อนในการรักษาที่อาจเกิดขึ้นเมื่อมีการกลับเข้ามารับบริการที่แผนกฉุกเฉินภายใน 72 ชั่วโมงที่แผนกฉุกเฉิน

ความซับซ้อนของข้อมูลด้านสุขภาพประกอบมีมากขึ้น รวมทั้งการให้บริการทางสุขภาพประกอบเฉพาะเจาะจงกับผู้ป่วยแต่ละราย ทำให้การใช้การเรียนรู้ของเครื่องหรือระบบปัญญาประดิษฐ์สามารถเรียนรู้และค้นหารูปแบบและความสัมพันธ์ของข้อมูลเพื่อพัฒนาแบบจำลองที่สามารถใช้เพื่อทำนายโอกาสที่ผู้ป่วยที่มีความเสี่ยงสูงที่จะกลับมารับบริการที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง

การวิจัยในครั้งนี้จัดทำขึ้นเพื่อศึกษาการประยุกต์ใช้เทคโนโลยีเรียนรู้ของเครื่อง (machine learning) เพื่อทำนายการกลับมารับบริการที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง และค้นหาปัจจัยสำคัญที่เกี่ยวข้อง เพื่อเพิ่มประสิทธิภาพและประสิทธิผลของบริการด้านสุขภาพ

วัตถุประสงค์ของการวิจัย

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายไว้ดังนี้

1. เพื่อสร้างแบบจำลองเพื่อใช้ในการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้ข้อมูลของผู้ป่วยที่มารับบริการที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของเครื่อง
2. เพื่อศึกษาว่าการสร้างแบบจำลองวิธีใด มีประสิทธิภาพมากที่สุดในการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน
3. เพื่อศึกษาว่าปัจจัยใด ที่มีผลต่อการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน

กรอบแนวคิดการวิจัย

การวิจัยนี้ศึกษาการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้การเรียนรู้ของเครื่องแบบมีผู้สอนชนิดแบ่งกลุ่ม (supervised classification model) เพื่อใช้ในการสร้างแบบจำลองในการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้ข้อมูลของผู้ป่วยที่มารับบริการที่แผนกฉุกเฉิน

ประโยชน์ที่คาดว่าจะได้รับ

1. ได้แบบจำลองที่ใช้ในการทำนายของผู้ป่วยที่มารับบริการที่แผนกฉุกเฉิน เพื่อช่วยในการสนับสนุนการตัดสินใจของแพทย์ประจำแผนกฉุกเฉินในการอนุญาตให้ผู้ป่วยสามารถกลับบ้านได้
2. ได้ทราบปัจจัยที่สำคัญที่เกี่ยวข้องกับการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน

ข้อจำกัดในการวิจัย

ข้อมูลที่นำมาใช้ในการวิจัยเป็นข้อมูลของผู้ป่วยที่มาใช้บริการที่แผนกฉุกเฉินที่เป็นข้อมูลทุติยภูมิ จากหลายสถานพยาบาล ซึ่งอาจจะมีความคลาดเคลื่อนของการบันทึกข้อมูล และลักษณะของข้อมูลที่แตกต่างกันในแต่ละสถานพยาบาล



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การรับบริการที่แผนกฉุกเฉินและการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง

การกลับเข้ามาใช้บริการซ้ำในแผนกฉุกเฉินเป็นเครื่องมือวัดหนึ่งในการบอกมาตรฐานการดูแลผู้ป่วยและประสิทธิภาพในการรักษาทางการแพทย์ ซึ่งหากมีการกลับมารับบริการซ้ำของผู้ป่วยเป็นจำนวนมากอาจจะบอกได้ว่า การดูแลรักษาทางการแพทย์อาจไม่มีประสิทธิภาพประกอบเพียงพอ⁽⁴⁾ โดยอัตราการกลับมารับบริการซ้ำที่แผนกฉุกเฉินอยู่ที่ 9% - 48% ซึ่งการกลับมารับบริการซ้ำในหลายเหตุการณ์สามารถป้องกันได้^(3, 5) โดยการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง เป็นระยะเวลาที่ยอมรับเพื่อใช้ในการประเมินคุณภาพและบริการของแผนกฉุกเฉิน^(4, 6-9)

การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่องเป็นส่วนหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence) ซึ่งเป็นการนำความรู้ หรือสิ่งที่ได้เรียนรู้ต่าง ๆ แล้วสกัดจากข้อมูลที่มี โดยอาจเป็นการเรียนรู้ที่ได้มาจากตัวอย่างที่มี แล้วนำไปใช้กับสิ่งใหม่ ๆ ที่ยังไม่เกิดขึ้น การเรียนรู้จากข้อมูลนี้เพื่อหาความสัมพันธ์ของปัจจัยบางอย่าง หรือเพื่อเรียนรู้และหารูปแบบของการเกิดขึ้นของข้อมูล เพื่อมาทำนายผลลัพธ์บางอย่าง ก่อให้เกิดการตัดสินใจที่เกิดขึ้นจากข้อมูลและสามารถนำไปใช้กับข้อมูลใหม่ ๆ ได้ ซึ่งการเรียนรู้จำเป็นต้องใส่ข้อมูลเพื่อให้โปรแกรมคอมพิวเตอร์และแบบจำลองต่าง ๆ ได้เกิดการเรียนรู้และวิเคราะห์มาเป็นโปรแกรมที่มีประสิทธิภาพ โดยการเรียนรู้นั้นจะเป็นการเรียนรู้ที่มาจากตัวอย่างต่าง ๆ ของข้อมูล เช่น ข้อมูลที่เป็นโครงสร้าง ได้แก่ ข้อมูลที่เป็นตาราง และอาจจะเป็นข้อมูลที่ไม่มีโครงสร้าง เช่น ภาพ เสียง หรือข้อความ เป็นต้น แล้วนำไปขยายเพื่อใช้ทำงานกับข้อมูลใหม่ ๆ ที่โปรแกรมหรือแบบจำลองนั้นไม่เคยพบเห็นมาก่อน โดยแบบจำลองสามารถเป็นแบบจำลองที่ใช้เพื่อการทำนาย หรืออาจจะเป็นแบบจำลองที่ใช้การได้มาซึ่งความรู้จากข้อมูล^(10, 11) ซึ่งการเรียนรู้ของเครื่องนั้นสามารถแบ่งได้ออกเป็น 4 แบบดังนี้

1. Supervised machine learning เป็นการเรียนรู้ของเครื่องแบบมีผู้สอน คือต้องมีการใส่คุณลักษณะบางอย่างที่ถูกกำหนดขึ้น เพื่อให้เครื่องได้เกิดการเรียนรู้ โดยต้องมีการติดป้ายหรือติดฉลากบอกว่าผลลัพธ์ที่ได้นั้นคืออะไรเพื่อเป็นการสอนให้เครื่องเกิดการเรียนรู้ ซึ่งใช้ในงานที่ต้องการทำนายผลลัพธ์จากข้อมูลที่ให้ไป โดยการเรียนรู้ของเครื่องแบบมีผู้สอนนั้นถือเป็นหนึ่งในประเภทที่มีการใช้งานมากที่สุดแบบหนึ่ง โดยสามารถแบ่งย่อยออกเป็น 2 ประเภทได้แก่

1.1. แบบจำลองชนิดถดถอย (regression model) เป็นแบบจำลองที่มีลักษณะของผลลัพธ์ที่เป็นข้อมูลตัวเลขแบบต่อเนื่อง (continuous data) จุดประสงค์เพื่อทำนายข้อมูลออกมาเป็นตัวเลขแบบต่อเนื่อง

1.2. แบบจำลองชนิดแบ่งกลุ่ม (classification model) เป็นแบบจำลองที่มีลักษณะของผลลัพธ์ที่เป็นข้อมูลแบบกลุ่ม (categorical data) หรือข้อมูลแบบไม่ต่อเนื่อง (discrete data) โดยมีจุดประสงค์เพื่อทำนายว่าข้อมูลนั้นจัดอยู่ในกลุ่มใด หรือมีความน่าจะเป็นว่าน่าจะถูกจัดอยู่ในกลุ่มใด และแบบจำลองชนิดแบ่งกลุ่มนี้เองยังสามารถแบ่งย่อยเป็น 2 ประเภทได้แก่

1.2.1. แบบจำลองชนิดแบ่งกลุ่มที่มีจำนวน 2 กลุ่ม (Binary classification)

1.2.2. แบบจำลองชนิดแบ่งกลุ่มที่มีจำนวนมากกว่า 2 กลุ่ม (Multiclass classification)

2. Unsupervised machine learning เป็นการเรียนรู้ของเครื่องแบบไม่มีผู้สอน คือ จะไม่มีการกำหนดลักษณะ การติดป้ายหรือติดฉลากบอกว่าผลลัพธ์ที่ได้คืออะไร จะมีเพียงแค่กลุ่มของข้อมูลชุดหนึ่ง เครื่องหรือแบบจำลองต้องเรียนรู้ด้วยตนเอง สามารถแบ่งย่อยออกได้เป็น 3 ประเภทได้แก่

2.1. การจัดกลุ่ม (clustering) เป็นการหาความเหมือนของข้อมูลย่อย ๆ ภายในข้อมูลทั้งหมด และจัดแบ่งกลุ่มความเหมือนนั้นออกเป็นกลุ่มย่อย ๆ โดยอาศัยลักษณะบางอย่าง เพื่อบอกความเหมือนกันภายในกลุ่ม และความแตกต่างจากกลุ่ม

2.2. การหาค่าที่ผิดปกติ (anomaly detection) เป็นการให้เครื่องเรียนรู้ข้อมูลเบื้องต้น และให้หาว่ามีข้อมูลกลุ่มใดหรือชุดใดที่มีความแตกต่างจากข้อมูลทั้งหมด การเรียนรู้ประเภทนี้จะไม่เน้นที่การจัดกลุ่มเพื่อแยกข้อมูลให้เป็นกลุ่มย่อย แต่จะเน้นที่ให้ข้อมูลทั้งหมดเปรียบเสมือนกลุ่มเดียวกัน แล้วมองหาข้อมูลที่มีรูปแบบความผิดปกติแตกต่างจากกลุ่ม

2.3. การวิเคราะห์หาความสัมพันธ์ (association analysis) เป็นการให้เครื่องหา กฎเพื่อดูความสัมพันธ์ระหว่างสิ่งต่าง ๆ

3. Semi-supervised machine learning เป็นการเรียนรู้ของเครื่องแบบกึ่งมีผู้สอน คือมีข้อมูลบางส่วนที่มีการติดป้ายหรือติดฉลาก ในขณะที่มีข้อมูลอีกส่วนที่ไม่มีการติดป้ายหรือฉลากไว้ เนื่องจากการติดป้ายหรือติดฉลากให้กับข้อมูลเพื่อให้ได้เป็นผลลัพธ์โดยผู้เชี่ยวชาญนั้น เป็นกิจกรรมที่ต้องมีการลงทุนที่สูง เพราะต้องใช้เวลาของมนุษย์ในการติดป้ายหรือติดฉลากให้กับ

ข้อมูลดังกล่าว ดังนั้นจะให้เครื่องมีการเรียนรู้ข้อมูลที่ไม่ครบถ้วน ซึ่งเป็นการผสมผสานกันระหว่างการเรียนรู้ของเครื่องแบบมีผู้สอนและไม่มีผู้สอน


4. Reinforcement machine learning เป็นการเรียนรู้ของเครื่องที่ดูจากผลสุดท้ายของข้อมูลเพื่อทำให้ได้รับรางวัลสูงที่สุด เป็นการลองผิดลองถูกของเครื่องเข้าไปเรื่อย ๆ เพื่อให้ได้ประสิทธิภาพประกอบดีที่สุด

โดยในงานวิจัยนี้จะเน้นหลักไปที่การใช้แบบจำลองที่ใช้ในการเรียนรู้ของเครื่องแบบมีผู้สอนชนิดแบ่งกลุ่ม (Classification model) โดยจะใช้ตัวอย่างแบบจำลองดังต่อไปนี้ คือ Logistic regression, K-neighbors Classification, Random Forests (RF) และ XGBoost classification

แบบจำลองที่ใช้ในการเรียนรู้ของเครื่อง

1. Logistic regression

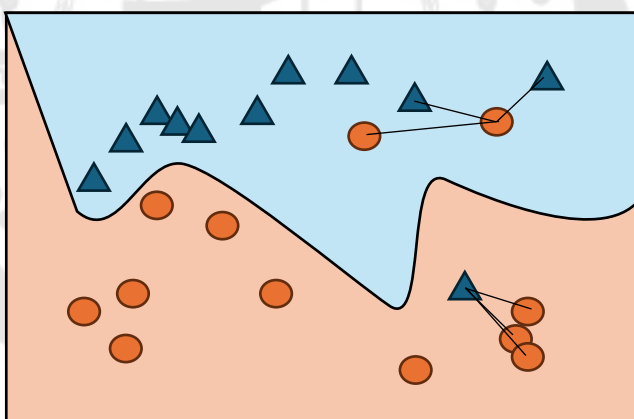
Logistic regression^(10, 11) จัดเป็นแบบจำลองทางสถิติแบบเส้นตรง โดยจะแบ่งกลุ่มในการทำนายออกเป็น 2 กลุ่ม ตามค่าความน่าจะเป็นของผลที่ทำนายได้ โดยหากมีค่ามากกว่า 0 จะจัดอยู่ในกลุ่ม +1 แต่ถ้ามีค่าน้อยกว่า 0 จะจัดอยู่ในกลุ่ม -1 โดยใช้ค่า 0 เป็นเส้นแบ่งในการตัดสินใจ (decision boundary) นั่นคือโปรแกรมคอมพิวเตอร์จะมีการเรียนรู้และพยายามหาสมการเส้นตรงที่ดีที่สุด เพื่อสร้างเป็นเส้นแบ่งในการตัดสินใจ โดยจะแปลงข้อมูลตัวแปรต่าง ๆ ให้เป็นจุด อยู่ใน feature space และดูว่าจุดดังกล่าวอยู่ในฝั่งใดของเส้นแบ่งในการตัดสินใจ โดยเลือกเส้นแบ่งในการตัดสินใจที่มีการแบ่งประเภทผิด (misclassification) น้อยที่สุดจากชุดข้อมูลทดสอบ ดังภาพประกอบ 1



ภาพประกอบ 1 แสดงตัวอย่างการสร้างเส้นตรงที่ดีที่สุดของแบบจำลอง Logistic regression

2. K-neighbors Classification

KNN Classification^(10, 11) เป็นแบบจำลองที่ไม่ได้จัดเป็นแบบจำลองเส้นตรงและไม่ใช้เส้นตรง เพราะว่ามันไม่มีการสร้างฟังก์ชัน โดยแบบจำลองนี้จะใช้ลักษณะของข้อมูลอื่น ๆ ที่อยู่ใกล้กับข้อมูลนั้น โดยต้องมีการกำหนดค่าพารามิเตอร์ K เพื่อพิจารณาจากข้อมูลใกล้เคียงจำนวน K ข้อมูล โดยการทำนายผลลัพธ์ของข้อมูลนั้น จะใช้ผลลัพธ์ข้อมูลที่อยู่ใกล้เคียงจำนวน K ข้อมูลมาใช้ในการคำนวณผลลัพธ์จากค่าเฉลี่ยของจำนวนจุดจำนวน K จุดที่อยู่ใกล้เคียง หรือคำนวณผลลัพธ์จากค่าเฉลี่ยที่มีการถ่วงน้ำหนักด้วยระยะทางระหว่างจุดนั้นกับจุดทั้ง K จุด โดยที่ยิ่งระยะทางใกล้จะมีการถ่วงน้ำหนักที่มาก ในขณะที่ระยะทางที่ไกลจะมีการถ่วงน้ำหนักที่น้อย ดังนั้นระยะทางจะแปรผกผันกับค่าถ่วงน้ำหนัก ซึ่ง KNN classification จะให้หลักการของการลงคะแนนเลือกผู้ที่มีจำนวนมากที่สุด ถ้าจุดใดอยู่ใกล้เคียงกับจุดในกลุ่มอื่นมากกว่า จะถือว่าจุดนั้นอยู่กลุ่มเดียวกัน ดังภาพประกอบ 2 โดยข้อดีของแบบจำลองแบบ KNN คือเข้าใจง่ายและมักให้ประสิทธิภาพประกอบสมเหตุสมผล แต่ข้อเสียคือ ใช้เวลานานในการทำนาย และไม่เหมาะสมกับแบบจำลองที่มีตัวแปรจำนวนมาก และตัวแปรที่มีค่าเป็น 0 เยอะ



ภาพประกอบ 2 แสดงตัวอย่างของการสร้างเส้นแบ่งกลุ่มโดยดูจากข้อมูลข้างเคียง

3. Decision Tree Classification

Decision Tree (DT) Classification^(10, 11) เป็นหนึ่งในแบบจำลองที่ได้รับความนิยมในการเรียนรู้ของเครื่อง เพราะสามารถเขียนเป็นโครงสร้างต้นไม้เป็นแผนผัง และทำให้ผู้อ่านเข้าใจได้ง่าย โดยในแบบจำลอง Decision Trees จะประกอบด้วยโหนด (node) 3 ประเภท ได้แก่ root node, internal nodes และ leaf node ซึ่งตัว leaf node จะเป็นตัวบอกกลุ่มหรือค่าผลลัพธ์ โดยโครงสร้างของต้นไม้จะเริ่มที่ราก (root nodes) โดยใช้ข้อมูลทั้งหมด จากนั้นจะแบ่งแยกข้อมูล

ออกเป็นข้อมูลย่อย ๆ ซึ่ง decision tree นี้สามารถจัดการได้กับทั้งข้อมูลที่เป็นข้อมูลต่อเนื่อง (continuous data) และข้อมูลประเภทแบ่งกลุ่ม (categorical data) ได้ สำหรับข้อมูลต่อเนื่องจะแบ่งโดยเลือกค่าในช่วงของข้อมูลมาเป็นจุดตัดเพื่อใช้ในการแยกกลุ่ม โดยเลือกจุดที่ดีที่สุด โดยการแบ่งจะมีวิธีในการพิจารณาว่าจะแบ่งวิธีใดเป็นวิธีที่ดีที่สุด เช่น การใช้ Information Gain, Gain Ratio หรือ Gini impurity index เป็นต้น และเพื่อหลีกเลี่ยงการเกิด overfitting การสร้างต้นไม้จะมีการกำหนดพารามิเตอร์เพื่อไม่ให้มีการแบ่งที่มากเกินไป โดยไม่กระทบต่อการแบ่งประเภท สำหรับแบบจำลอง decision tree classification จะใช้ลักษณะของการลงคะแนนเลือกประเภทที่มีค่ามากที่สุดในแต่ละ leaf node ให้อยู่ในประเภทนั้น ทั้งนี้ข้อเสียของการใช้ decision tree คือ เป็นแบบจำลองที่สามารถทำนายได้เฉพาะช่วงที่อยู่ใน leaf node เท่านั้น จะไม่สามารถทำนายค่าที่อยู่นอกช่วงของ training set ได้ (interpolation mode)

4. Random Forest Classification

Random Forest Classification^(12, 13) เป็นแบบจำลองที่ต่อยอดมาจาก Decision Tree เป็นหนึ่งในวิธีการสร้างแบบจำลองโดยใช้วิธี Ensemble เพื่อต้องการเพิ่มประสิทธิภาพของการทำนายของแบบจำลองแต่ละตัว โดยแบบจำลอง Random Forest นั้นเป็นวิธีหนึ่งของวิธี Bagging เพื่อลดข้อจำกัดของ Decision Tree ที่เกิด overfitting ได้ง่ายและมีความไม่คงที่ค่อนข้างสูง จึงนำมาสู่การสร้างแบบจำลอง Random Forest ที่ใช้ Decision Tree หลาย ๆ แบบจำลองในการสร้าง ทั้งนี้แบบจำลอง Decision Tree เหล่านี้ต้องอยู่บนพื้นฐานว่าแบบจำลองนั้นเป็นอิสระต่อกัน ซึ่งจะใช้กระบวนการดังต่อไปนี้เพื่อทำงานร่วมกัน ได้แก่

1. Bootstrapping เป็นวิธีในการเพิ่มปริมาณข้อมูล เพื่อนำไปใช้ในการสร้างแบบจำลอง Decision Tree ที่แตกต่างกันด้วยข้อมูลที่ใส่เข้าไปที่แตกต่างกัน ซึ่งวิธีนี้เป็นการจัดการข้อมูลในแนวตั้ง โดยจะมีการสุ่มเลือกข้อมูลและใส่ข้อมูลนั้นกลับเข้าไป เพื่อให้ได้ชุดข้อมูลใหม่ ซึ่งมีปริมาณ 67% ของชุดข้อมูลเดิม แต่เพิ่มความหลากหลายมากขึ้น การสุ่มเลือกข้อมูลใหม่นี้เพื่อนำไปสร้างเป็นชุดข้อมูลที่จะใช้ในการสร้างแบบจำลอง Decision Tree ที่แตกต่างกัน

2. Random feature selection เป็นการจัดการเพื่อให้แบบจำลองเป็นอิสระต่อกัน โดยจัดการข้อมูลในแนวนอน โดยเป็นการสุ่มเลือกตัวแปรจากตัวแปรทั้งหมด ซึ่งต้องมีการกำหนดพารามิเตอร์ max_features โดยต้องเลือกพารามิเตอร์ที่เหมาะสม ไม่มากหรือน้อยเกินไป เพื่อให้ได้เป็นข้อมูลชุดใหม่ที่มีตัวแปรที่แตกต่างกัน จากตัวแปรทั้งหมด เพื่อใช้สร้างแบบจำลอง Decision Tree ที่แตกต่างกัน

เมื่อมีการทำงานร่วมกันของทั้ง 2 กระบวนการ เพื่อใช้ในการสร้างข้อมูลชุดใหม่เพื่อใช้สร้างในแบบจำลอง Decision Tree จะทำให้แบบจำลองที่ได้มีความแตกต่างกันอย่างมาก

5. Extreme Gradient boosting (XGBoost) classification

Extreme Gradient Boosting (XGBoost) ⁽¹⁴⁻¹⁶⁾ เป็นแบบจำลองที่ใช้วิธีการสร้างแบบจำลองโดยใช้วิธี Ensemble เช่นเดียวกัน ซึ่งสามารถใช้เป็นแบบจำลองในการจำแนกประเภทหรือแบบจำลองแบบถดถอย โดยเป็นหนึ่งในแบบจำลองที่เป็นที่นิยมและมีการเลือกใช้งานมากที่สุดแบบจำลองหนึ่ง ซึ่งเลือกใช้เทคนิค Boosting แทนการใช้เทคนิค Bagging โดยหลักการของ Boosting คือ การสร้างแบบจำลองหลายแบบจำลองเพื่อทำนายแบบเรียงลำดับต่อกัน (sequential) โดยแบบจำลองที่นำมาใช้ทำนายจะใช้แบบจำลองแบบอ่อนแอ (weak predictor) คือไม่ใช่แบบจำลองที่สมบูรณ์แบบ เช่น แบบจำลอง Decision Tree ที่อาจจะมีแค่ 1-2 ลำดับ ที่น่าจะเป็นแบบจำลองที่ให้ประสิทธิภาพดีกว่าการสุ่ม เมื่อนำข้อมูลเข้าแบบจำลองครั้งแรกแล้วนั้น จะได้ผลของการทำนายมา หลังจากนั้นจึงประเมินความผิดพลาดของการทำนาย โดยมีวัตถุประสงค์เพื่อปรับปรุงฟังก์ชันสูญเสียให้มีความผิดพลาดของการทำนายน้อยที่สุด จึงมีการถ่วงน้ำหนักให้กับข้อมูลใหม่โดยดูตามความผิดพลาดที่เกิดขึ้น เพื่อจุดประสงค์ในการลดความผิดพลาดของการทำนายในแบบจำลองถัดไป หากผลของการทำนายมีความแม่นยำ ข้อมูลนั้นก็จะถูกถ่วงน้ำหนักน้อย และหากผลของการทำนายมีความผิดพลาดมากก็จะมีถ่วงน้ำหนักมากให้กับข้อมูลนั้น เพื่อนำเข้าแบบจำลองถัดไป ทำให้ข้อมูลที่มีการทำนายผิดพลาดจากแบบทดลองแรกได้มีโอกาสที่จะเกิดการเรียนรู้มากขึ้นจากแบบจำลองถัดไป และทำการถ่วงน้ำหนักด้วยวิธีการเดียวกันก่อนเข้าแบบจำลองถัด ๆ ไป โดยอ้างอิงจากผลของการทำนายในแต่ละแบบจำลองเป็นหลัก ซึ่งแบบจำลองที่ใช้เทคนิค Boosting นั้นมีหลายแบบจำลองด้วยกัน เช่น Adaboost, Gradient Boosting, LightGBM และ XGBoost

Gradient Boosting จะใช้การปรับปรุงตัวแบบจำลองที่ใช้ทำนายใหม่ เช่น การปรับค่าพารามิเตอร์ ให้ลดข้อผิดพลาดที่เกิดขึ้น จากการทำนายที่เกิดจากแบบจำลองที่ใช้ในการทำนายก่อนหน้านี้ โดยใช้ข้อมูลเดิมที่ใส่เข้าไปในแบบจำลอง และปรับตัวทำนายให้เป็นผลต่างของค่าที่ทำนายได้กับค่าจริง เพื่อให้ฟังก์ชันการสูญเสียถูกปรับให้เหมาะสมที่สุด และกำหนดอัตราการเรียนรู้ (learning rate) ให้เหมาะสมให้ข้อผิดพลาดที่เกิดขึ้นเข้าใกล้ศูนย์มากที่สุด

XGBoost นั้นเป็นการต่อยอดมาจากแบบจำลอง Gradient Boosting โดยการเพิ่ม L1 และ L2 regularization เข้าไปในโมเดล รวมทั้งปรับปรุงวิธีการใช้งานของคอมพิวเตอร์ให้มีการคำนวณแบบคู่ขนานไปทำให้ประสิทธิภาพของแบบจำลองเพิ่มสูงขึ้น ทำให้การคำนวณรวดเร็วขึ้น

อีกทั้ง XGBoost เองยังสามารถจัดการกับข้อมูลที่เป็นข้อมูลว่างได้ดีอีกด้วย จึงอาจจะไม่จำเป็นต้องมีการแทนที่ค่าว่างในข้อมูลก่อนเข้าแบบจำลอง XGBoost

การวัดประสิทธิภาพของแบบจำลอง

การวัดประสิทธิภาพของแบบจำลองแบบมีผู้สอนประเภทแบ่งกลุ่ม จะสนใจจากค่าที่ทำนายออกมาว่าเป็น True Positive (TP) , True Negative (TN), False Positive (FP) หรือ False Negative (FN) ซึ่งจะสามารถสร้างเป็น เมทริกซ์ความสับสน (Confusion Matrix) ดังแสดงในภาพประกอบ 3

		Predicted	
		Positive	Negative
Actual	Positive	True Positive (TP)	False Negative (FN)
	Negative	False Positive (FP)	True Negative (TN)

ภาพประกอบ 3 เมทริกซ์ความสับสน (Confusion Matrix)

โดยสามารถวัดได้หลายวิธีดังต่อไปนี้

1. Accuracy สามารถเขียนเป็นสมการ ดังสมการที่ 1

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

ทั้งนี้ความแม่นยำอาจจะไม่ใช่การวัดที่ดีที่สุด เนื่องจากหากเป็นเหตุการณ์ที่มีโอกาสเกิดขึ้นต่ำ ถ้ามีการทำนายเป็น Negative ทั้งหมด ก็สามารถทำให้ความแม่นยำ (Accuracy) สูงได้ จึงควรเปรียบเทียบด้วยการวัดวิธีอื่นด้วย

2. Classification error สามารถเขียนเป็นสมการ ดังสมการที่ 2

$$Classification\ Error = \frac{FP + FN}{TP + TN + FP + FN} \quad (2)$$

3. Recall หรือ True Positive Rate (TPR) สามารถเขียนเป็นสมการ ดังสมการที่ 3

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

4. ความเที่ยง (Precision) สามารถเขียนเป็นสมการ ดังสมการที่ 4

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

5. False Positive Rate (FPR) สามารถเขียนเป็นสมการ ดังสมการที่ 5


$$FPR = \frac{FP}{TN + FP} \quad (5)$$

6. F1 score สามารถเขียนเป็นสมการ ดังสมการที่ 6

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

$$= \frac{2 \times TP}{2 \times (TP + FN + FP)}$$

7. Area Under Receiver Operating Characteristic curve (AUC) เป็นการสร้างกราฟระหว่างค่า TPR (recall) และ FPR ดังภาพประกอบ 4 และคำนวณหาพื้นที่ใต้กราฟ โดยหาค่า AUC เท่ากับ 0.5 เท่ากับการทำนายแบบสุ่ม และหาค่าเข้าใกล้ 1 แสดงว่าเป็นการทำนายที่ค่อนข้างดี หากค่าเข้าใกล้ 0 แสดงว่าเป็นการทำนายที่ไม่ค่อยดี



ภาพประกอบ 4 Under Receiver Operating Characteristic curve⁽¹¹⁾

งานวิจัยที่เกี่ยวข้อง

การศึกษาของ Hsu และคณะ⁽¹⁷⁾ ทำการศึกษาในโรงพยาบาลที่ประเทศไต้หวัน เพื่อทำนายการกลับมารับบริการซ้ำที่แผนกฉุกเฉินโดยไม่ได้นัดหมายภายใน 72 ชั่วโมงในผู้ป่วยที่มีอาการปวดท้องโดยใช้การเรียนรู้ของเครื่อง โดยเลือกผู้ป่วยที่มีอายุมากกว่า 18 ปี ตั้งแต่วันที่ 1 มกราคม 2018 ถึงวันที่ 31 ธันวาคม 2019 โดยคัดออกผู้ป่วยที่มีนัดหมายกลับมารับบริการซ้ำ ผู้ป่วยที่เสียชีวิต ผู้ป่วยที่ถูกส่งต่อไปโรงพยาบาลอื่น และผู้ป่วยที่กลับบ้านโดยไม่ได้รับอนุญาตจากแพทย์ มีการเข้ารับบริการที่แผนกฉุกเฉินด้วยอาการปวดท้อง 25,151 ครั้ง และมีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง จำนวน 1,471 ครั้ง คิดเป็น 5.85% ซึ่งมีปัจจัยที่นำมาวิเคราะห์ทั้งหมด 617 ปัจจัย เช่น ข้อมูลทั่วไปของผู้ป่วย วิธีการมาโรงพยาบาล ช่วงเวลาที่ถึงโรงพยาบาล ความอาวุโสของแพทย์ ระยะเวลาการนอนในแผนกฉุกเฉิน การวินิจฉัย ความถี่ในการมาที่แผนกฉุกเฉิน ในปีก่อน ความถี่ในการถูกรักษาตัวในโรงพยาบาลในปีก่อน หรือการวินิจฉัยในสองปีก่อน โดยอัตราส่วนระหว่างผู้ป่วยที่มารับการบริการซ้ำภายใน 72 ชั่วโมง และผู้ป่วยที่ไม่ได้มารับบริการซ้ำภายใน 72 ชั่วโมง คือ 19:1 จึงใช้ one-sided selection algorithm ช่วยในการปรับอัตราส่วนเป็น 15:1 และนำข้อมูลที่อยู่ในบริเวณ Decision boundaries ออกโดยวิธี Tomek link algorithm (k=1) โดยมีแบบจำลองที่นำมาใช้ คือ logistic regression (LR), random forest (RF), extreme gradient boosting (XGB), and voting classifiers (VC) โดยที่แบบจำลอง voting classifiers จะใช้การทำนายสุดท้ายจากแบบจำลองสามชนิดก่อนหน้า และทำการฝึก ด้วย 10-fold cross-validation และจัดการความไม่เท่ากันของข้อมูลด้วย bootstrapping method เฉพาะข้อมูลที่นำมาฝึก จากการทำ voting weight ของ VC พบว่าน้ำหนักของ 1(LR):2(RF):1(XGB) ให้น้ำหนักที่ดีที่สุด ผลประสิทธิผลของแบบจำลองพบว่า ในทุกแบบจำลองให้ผลของค่า AUC มากกว่า 0.69 โดยที่ XGB และ voting classifiers มีค่า AUC ดีที่สุดคือ 0.74 แต่แบบจำลอง VC ให้ค่า F1 score ที่สูงที่สุดคือ 0.25 ซึ่งมากกว่าแบบจำลอง XGB ที่มีค่าเท่ากับ 0.07

การศึกษาของ Gao และคณะ⁽¹⁸⁾ ทำการศึกษาในโรงพยาบาลกิจการทหารผ่านศึก (Veterans Affairs hospitals) ในนิวยอร์ก ในปีงบประมาณ 2014 จาก 4 โรงพยาบาล โดยใช้ข้อมูลจากปีงบประมาณ 2013 เพื่อการทำนายการกลับมาห้องฉุกเฉินซ้ำใน 30 วัน ของปีงบประมาณ 2014 โดยมีผู้ป่วย 22,734 คนในการวิเคราะห์ และมี 4,937 คนที่กลับมาซ้ำภายใน 30 วัน คิดเป็น 22% โดยใช้ปัจจัยที่นำมาวิเคราะห์ได้แก่

1. ข้อมูลทั่วไปของผู้ป่วยเช่น อายุ เพศ สถานภาพสมรส เชื้อชาติ ระดับความพิการ ระยะเวลาที่อยู่ในหน่วยบริการทหาร

2. สถานะทางเศรษฐกิจและสังคม
3. ค่าใช้จ่ายจากการเข้าพักในโรงพยาบาลในปีก่อนหน้า
4. โรคประจำตัวหรือปัจจัยเสี่ยงของผู้ป่วย

โดยใช้แบบจำลอง logistic regression ในการวิเคราะห์และวัดผลด้วยค่า C statistic ซึ่งคล้ายกับค่า AUC และป้องกันแบบจำลองไม่ให้เกิดการเรียนรู้มากเกินไปโดยเลือกใช้เฉพาะตัวแปรที่มีค่า P-value < 0.05 จากการวิเคราะห์แบบจำลองแบบถดถอย และการทำคำนวณ shrinkage coefficient เพื่อใช้ในการพิจารณาระดับการเรียนรู้ที่มากเกินไป หลังจากนั้นทำการเข้าแบบจำลองด้วยวิธี split-sample method โดยแบ่งเป็นข้อมูลสำหรับ Train 50% และข้อมูลสำหรับการ Validate 50% และได้สร้างแบบจำลองเป็น 3 แบบ โดยมีปัจจัยที่ใช้และประสิทธิภาพของแบบจำลองดังนี้

1. แบบจำลองที่ 1 โดยใช้ข้อมูลเฉพาะ ข้อมูลทั่วไปของผู้ป่วย และสถานะทางเศรษฐกิจและสังคม มีค่า C-statistic เท่ากับ 0.568 สำหรับข้อมูลฝึก และ 0.556 สำหรับข้อมูลทดสอบ

2. แบบจำลองที่ 2 ใช้ข้อมูลจากแบบจำลองที่ 1 และค่าใช้จ่ายจากการเข้าพักในโรงพยาบาลในปีก่อนหน้า มีค่า C-statistic เท่ากับ 0.748 สำหรับข้อมูลฝึก และ 0.748 สำหรับข้อมูลทดสอบ

3. แบบจำลองที่ 3 ใช้ข้อมูลจากแบบจำลองที่ 2 และโรคประจำตัวหรือปัจจัยเสี่ยงของผู้ป่วย มีค่า C-statistic เท่ากับ 0.773 สำหรับข้อมูลฝึก และ 0.763 สำหรับข้อมูลทดสอบ

การศึกษาของ Lin และคณะ⁽¹⁹⁾ เป็นการศึกษาในแผนกฉุกเฉินของผู้ป่วยที่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมงด้วยอาการปวดท้อง โดยการเปรียบเทียบระหว่างผู้ป่วยที่มีการกลับมาใช้บริการซ้ำที่ได้รับการรักษาในโรงพยาบาล (Admission) และผู้ป่วยที่ไม่ได้รับการรักษาในโรงพยาบาล (Non-admission) โดยทำการศึกษาจากข้อมูลระหว่างวันที่ 1 มกราคม 2014 ถึงวันที่ 31 ธันวาคม 2018 โดยคัดเลือกเฉพาะผู้ป่วยที่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง ที่มีอายุมากกว่า 20 ปี โดยคัดผู้ป่วยที่ไม่ได้รับการวินิจฉัยเกี่ยวกับอาการปวดท้อง ผู้ป่วยที่มีโรคทางอุ้งเชิงกราน ผู้ป่วยที่ได้กลับบ้านโดยไม่ได้รับอนุญาตจากแพทย์ และผู้ป่วยที่ถูกส่งต่อมาจากแผนกอื่นออก โดยปัจจัยที่นำมาใช้ในการวิเคราะห์ประกอบด้วย

1. ปัจจัยที่เกี่ยวข้องกับผู้ป่วย ได้แก่ เพศ อายุ ระดับการประเมินความรุนแรงและเร่งด่วน สัญญาณชีพ (อุณหภูมิร่างกาย และอัตราการเต้นของหัวใจ), ระดับความปวด, ความดันโลหิต, ประวัติการตรวจร่างกายที่มีการกดเจ็บ โรคประจำตัว และประวัติการผ่าตัดช่องท้อง

2. ปัจจัยที่เกี่ยวข้องกับระบบ ได้แก่ ระยะเวลาการอยู่ในแผนกฉุกเฉิน จำนวนการใช้ยาแก้ปวด ประวัติการได้รับคำสั่งในการตรวจทางห้องปฏิบัติการหรือการตรวจทางรังสีวิทยา และประวัติการรับการรักษาในโรงพยาบาล

ทำการเปรียบเทียบโดยใช้ Multivariable logistic regression ในการวิเคราะห์หาปัจจัยเสี่ยงที่มีผล โดยเลือกปัจจัย 2 แบบ คือ การใส่ข้อมูลทั้งหมดที่มีนัยสำคัญทางสถิติจากการทำ univariable analysis และการเลือกปัจจัยด้วยวิธี Backward elimination และประเมินประสิทธิภาพของแบบจำลองที่ดีที่สุด ด้วย Akaike information criterion (AIC) ซึ่งค่าที่ต่ำจะเป็นแบบจำลองที่น่าสนใจ และใช้ ROC curve เพื่อศึกษาความสัมพันธ์ระหว่างปัจจัยและการเข้ารับบริการซ้ำที่ได้รับการรักษาต่อในโรงพยาบาล และใช้ Classification and regression tree (CART) เป็น Validation analysis โดยการศึกษาพบว่า มีผู้ป่วย 6,829 คนที่กลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง โดยที่มีผู้ป่วยที่เข้าเกณฑ์จำนวน 702 คน ซึ่งมี 35.5% ที่ได้รับการรักษาในโรงพยาบาลเมื่อกลับมาใช้บริการซ้ำ โดยมีปัจจัยเสี่ยงที่นำมาใช้สร้างแบบจำลองได้แก่ ระดับการประเมินความรุนแรงและเร่งด่วน การให้ยาแก้ปวดหลายตัว อายุ และการได้รับการตรวจทางห้องปฏิบัติการ โดยได้ค่า AUC เท่ากับ 0.716 ($P < 0.001$)

บทที่ 3

วิธีดำเนินการวิจัย

รูปแบบการวิจัย

การวิจัยนี้เป็นการศึกษาแบบ retrospective โดยใช้ข้อมูลทุติยภูมิ ซึ่งเป็นข้อมูลของผู้ป่วยที่เข้ารับบริการในแผนกฉุกเฉิน จากระบบฐานข้อมูลที่ได้มีการเก็บข้อมูลไว้แล้ว

ประชากรที่ใช้ในการวิจัย

ใช้ข้อมูลผู้ป่วยที่เข้ารับบริการในแผนกฉุกเฉิน ชื่อ MIMIC-IV-ED ซึ่งเป็นข้อมูลจากฐานข้อมูลเวชระเบียนของแผนกฉุกเฉินที่ Beth Israel Deaconess Medical Center เมืองบอสตัน รัฐแมสซาชูเซตส์ ประเทศสหรัฐอเมริกา ระหว่างปี ค.ศ. 2011 – ค.ศ. 2019 จากเว็บไซต์ <https://physionet.org/content/mimic-iv-ed/2.2/> โดยการได้มาซึ่งข้อมูลต้องเป็นผู้ใช้งานที่ผ่านการอบรมการวิจัยในคนของ CITI Data or Specimens Only Research และต้องเซ็นยินยอมใช้ข้อมูล sign the data use agreement for the project ก่อนจะสามารถเข้าถึงข้อมูลได้^(20, 21)

กลุ่มตัวอย่างที่ใช้ในการวิจัย

เลือกใช้ข้อมูลผู้ป่วยที่เข้ารับบริการในแผนกฉุกเฉินจากฐานข้อมูลทั้งหมดโดยไม่มี การสุ่มตัวอย่าง ซึ่งเป็นข้อมูลระหว่างปี ค.ศ. 2011 – ค.ศ. 2019 โดยมีเกณฑ์การนำเข้าและการคัดออกดังนี้

เกณฑ์นำเข้า

1. เป็นผู้ที่มีอายุตั้งแต่ 18 ปีขึ้นไป
2. เป็นผู้ที่มีประวัติการได้รับอนุญาตให้กลับบ้าน เมื่อมารับบริการที่แผนกฉุกเฉิน

เกณฑ์การคัดออก

1. เป็นผู้ที่ไม่ได้รับการรักษา จนถึงขั้นตอนที่แพทย์วินิจฉัยและตัดสินใจในการจำหน่ายผู้ป่วย เช่น ไม่รอดตรวจ หลบหนีระหว่างการรักษา ปฏิเสธการรักษา
2. เป็นผู้ที่มีประวัติได้รับอนุญาตให้รับการรักษาในโรงพยาบาล หรือส่งต่อไปยังสถานพยาบาลอื่น
3. เป็นผู้เสียชีวิตภายในแผนกฉุกเฉิน

ชุดข้อมูล

ใช้ชุดข้อมูลผู้ป่วยที่เข้ารับบริการในแผนกฉุกเฉิน จากเว็บไซต์ PhysioNet ชื่อฐานข้อมูล MIMIC-IV-ED โดยไม่มีการระบุข้อมูลส่วนบุคคล เช่น ชื่อ นามสกุล เลขประจำตัวโรงพยาบาล สถานที่ทำงาน วันเดือนปีเกิด และมีการสุ่มปีที่เข้ารับบริการในผู้ป่วยแต่ละคนให้แตกต่างกันไปจาก

วันที่มารับบริการจริง โดยข้อมูลจะระบุในช่วงปี ค.ศ. 2100 – 2200 (จากเดิมปี ค.ศ. 2011-2019) และใช้รหัสจำลองทดแทนการระบุตัวตน^(20, 21)

จากข้อมูลในฐานข้อมูล MIMIC-IV-ED ประกอบด้วย 6 ตารางดังนี้

1. edstays เป็นข้อมูลของการมารับบริการที่แผนกฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 425,087 แถว และ 9 คอลัมน์ โดยมีรายละเอียดดังตาราง 1

2. diagnosis เป็นข้อมูลของการวินิจฉัยโรคที่ลงข้อมูลโดยเจ้าหน้าที่เวชสถิติที่ได้รับการฝึกฝน (trained coders) หลังจากที่มีการจำหน่ายออกจากแผนกฉุกเฉินและใช้ในวัตถุประสงค์ในการคำนวณค่าใช้จ่าย โดยบันทึกข้อมูลด้วยระบบ ICD-9 หรือ ICD-10 (ICD = International Classification of Diseases) โดยประกอบข้อมูลทั้งหมด 899,050 แถว และ 6 คอลัมน์ โดยมีรายละเอียดดังตาราง 2

3. medrecon เป็นข้อมูลของการทำการประสานรายการยา ซึ่งเป็นรายการของยาที่ผู้ป่วยได้รับก่อนเข้ารับบริการในแผนกฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 2,987,342 แถว และ 9 คอลัมน์ โดยมีรายละเอียดดังตาราง 3

4. pyxis เป็นข้อมูลของการจ่ายยาโดยเครื่องจ่ายยาอัตโนมัติที่ใช้ในแผนกฉุกเฉิน ทั้งนี้ไม่ใช่รายการยาทุกตัวจะถูกบันทึกในตารางนี้ เนื่องจากมียาบางตัวที่ไม่ได้ถูกจ่ายด้วยเครื่องจ่ายยาอัตโนมัติ เช่น การให้สารน้ำในผู้ป่วยที่ใช้สำหรับการช่วยชีวิตฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 1,586,053 แถว และ 9 คอลัมน์ โดยมีรายละเอียดดังตาราง 4

5. triage เป็นข้อมูลของการทำการคัดกรองผู้ป่วย โดยผู้ป่วยทุกรายที่มาเข้ารับบริการที่แผนกฉุกเฉินจะต้องได้รับการประเมินภาวะทางสุขภาพ เพื่อประเมินระดับความฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 425,087 แถว และ 11 คอลัมน์ โดยมีรายละเอียดดังตาราง 5

6. vitalstays เป็นข้อมูลการวัดสัญญาณชีพขณะที่ผู้ป่วยอยู่ในแผนกฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 1,564,610 แถว และ 11 คอลัมน์ โดยมีรายละเอียดดังตารางที่ 6

เนื่องจากในฐานข้อมูล MIMIC-IV-ED ไม่มีการระบุอายุของผู้ป่วย หากต้องการคำนวณอายุของผู้ป่วย จำเป็นต้องใช้ตาราง patients ซึ่งเป็นตารางอยู่ในฐานข้อมูล MIMIC-IV ไม่ใช่ MIMIC-IV-ED และนำมาใช้เพื่อการคำนวณอายุ ของผู้ป่วย ณ วันที่มารับบริการที่แผนกฉุกเฉิน โดยประกอบข้อมูลทั้งหมด 299,712 แถว และ 6 คอลัมน์ โดยมีรายละเอียดดังตารางที่ 7 ซึ่งได้มีการปกปิดปีที่ผู้ป่วยเข้ารับบริการ โดยทำการสุ่มปีในผู้ป่วยแต่ละคน เป็นปีแบบสุ่มระหว่าง ค.ศ. 2100 - ค.ศ.2200 โดยตั้งชื่อว่า anchor_year ซึ่งระบุไว้ในตาราง patients ในฐานข้อมูล MIMIC-IV จึงต้องมีการนำข้อมูลดังกล่าว มาคำนวณหาอายุจริง ณ วันที่เข้ารับบริการ ทั้งนี้ผู้ป่วยที่มาอายุ

ตั้งแต่ 89 ปีขึ้นไป anchor_age จะถูกตั้งค่าเป็น 91 เพื่อปกปิดข้อมูลไม่ไห้สามารถระบุว่าเป็นผู้ป่วยท่านใด เนื่องจากมีผู้ป่วยจำนวนไม่มากที่มีอายุตั้งแต่ 90 ปี



ตาราง 1 แสดงรายละเอียดของข้อมูลในตาราง edstays

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลว่าง	หมายเหตุ
1 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	33258284	425,087	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล
2 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมารับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	425,087	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
3 hadm_id	ตัวบ่งชี้ ข้อมูลการรับรักษาคำในโรงพยาบาล (จะมีข้อมูล ก็ต่อเมื่อมีการรับรักษาคำในโรงพยาบาล)	float64	22595853.0	203,016	222,071	เชื่อมกับ hadm_id ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลการรับการรักษาตัวในโรงพยาบาล
4 intime	วันและเวลาที่ผู้ป่วยเข้ามาใช้บริการที่แผนกฉุกเฉิน	object	2180-05-06 19:17:00	425,087	0	
5 outtime	วันและเวลาที่ผู้ป่วยถูกจำหน่ายออกจากแผนกฉุกเฉิน	object	2180-05-06 23:30:00	425,087	0	
6 gender	เพศ	object	F	425,087	0	
7 race	เชื้อชาติ	object	WHITE	425,087	0	
8 arrival_transport	วิธีการมาเดินทางมายังแผนกฉุกเฉิน	object	AMBULANCE	425,087	899,050	
9 disposition	วิธีการจำหน่ายออกจากแผนกฉุกเฉิน	object	ADMITTED	425,087	899,050	



ตาราง 2 แสดงรายละเอียดของข้อมูลในตาราง diagnosis

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลว่าง	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมารับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	899,050	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
2 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	33258284	899,050	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV-ED
3 seq_num	ลำดับของการลงข้อมูลการวินิจฉัย (ใน 1 การรับบริการ ลงวินิจฉัยได้ 9 ครั้ง)	int64	1	899,050	0	มีค่าตั้งแต่ 1-9
4 icd_code	รหัสของการวินิจฉัย	object	V08	899,050	0	
5 icd_version	Version ของรหัส	int64	9	899,050	0	Version 9 หรือ 10
6 icd_title	ชื่อข้อมูลข้อความการวินิจฉัย	object	HYPOTENSION NOS	899,050	0	



ตาราง 3 แสดงรายละเอียดของข้อมูลในตาราง medrecon

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลซ้ำ	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมีการรับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	2,987,342	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อข้อมูลอื่น ๆ
2 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	32952584	2,987,342	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV-ED
3 charttime	วันและเวลาที่มีการบันทึกข้อมูล	object	2180-07-22 17:26:00	2,987,342	0	
4 name	ชื่อหรือคำอธิบายยา	object	albuterol sulfate	2,987,342	0	
5 gsn	Generic Sequence Number (GSN)	int64	28090	2,987,342	0	มีค่าเป็น 0 ถ้าข้อมูล GSN หายไป
6 ndc	National Drug Code (NDC)	int64	21695042308	2,987,342	0	
7 etc_rm	ลำดับของกลุ่มที่รายการยานั้นออกฤทธิ์	int64	1	2,987,342	0	ใน 1 ยาอาจจะมีการออกฤทธิ์ได้หลายประเภท ดังนั้นอาจจะมีได้หลายแถวสำหรับ 1 รายการยา
8 etccode	Code ของกลุ่มที่รายการยานั้นออกฤทธิ์ (ontology group)	float64	5970.0	2,975,614	11,728	
9 etcdescription	คำอธิบายของกลุ่มที่รายการยานั้นออกฤทธิ์	object	Asthma/COPD Therapy - Beta 2-Adrenergic Agents	2,975,614	11,728	

ตาราง 4 แสดงรายละเอียดของข้อมูลในตาราง pyxis

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลซ้ำ	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมาใช้บริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	1,586,053	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
2 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	32952584	1,586,053	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV-ED
3 charttime	วันและเวลาที่มีการบันทึกข้อมูล	object	2180-07-22 17:59:00	1,586,053	0	
4 med_rm	ลำดับของการจ่ายยา	int64	3	1,586,053	0	ในกรณีที่มีการจ่ายยาพร้อมกันหลายตัว
5 name	ชื่อหรือคำอธิบายรายการยา	object	Albuterol Inhaler	1,586,053	0	
6 gsn_rm	ลำดับของค่า GSN	int64	1	1,586,053	0	ในกรณีที่ยา 1 ตัวมีมากกว่า 1 GSN
7 gsn	Generic Sequence Number (GSN)	float64	5037.0	1,550,601	35,452	มีค่าเป็น 0 ถ้าข้อมูล GSN หายไป

ตาราง 5 แสดงรายละเอียดของข้อมูลในตาราง triage

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลว่าง	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมารับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	425,087	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
2 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	32952584	425,087	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV-ED
3 temperature	อุณหภูมิร่างกาย (หน่วยองศาฟาเรนไฮต์)	float64	97.8	401,672	23,415	
4 heartrate	อัตราการเต้นของหัวใจ	float64	87.0	407,997	17,090	
5 resprate	อัตราการหายใจ	float64	14.0	404,734	20,353	
6 o2sat	ค่าความเข้มข้นของออกซิเจนในเลือด	float64	97.0	404,491	20,596	
7 sbp	ความดันโลหิตซิสโตลิก	float64	71.0	406,796	18,291	
8 dbp	ความดันโลหิตไดแอสโตลิก	float64	43.0	405,996	19,091	
9 pain	ระดับความปวด	object	7	412,154	12,933	มีค่า 0-10 แต่สามารถลงข้อมูลเป็น free-text ได้
10 acuity	ระดับการประเมินความรุนแรงและเร่งด่วน	float64	2.0	418,100	6,987	มีค่า 1-5 1 หมายถึงรุนแรงมากที่สุด 5 หมายถึงรุนแรงน้อยที่สุด
11 chiefcomplaint	อาการนำที่นำโรงพยาบาล	object	Hypotension	425,064	23	

ตาราง 6 แสดงรายละเอียดของข้อมูลในตาราง vitalsign

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลว่าง	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมารับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	1,564,610	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
2 stay_id	ตัวบ่งชี้ ข้อมูลในแต่ละครั้งของการรับบริการที่แผนกฉุกเฉิน	int64	32952584	1,564,610	0	Primary key เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV-ED
3 chartime	วันและเวลาที่มีการบันทึกข้อมูล	object	2180-07-22 16:36:00	1,564,610	0	
4 temperature	อุณหภูมิร่างกาย (หน่วยองศาฟาเรนไฮต์)	float64	98.4	999,642	564,968	
5 heartrate	อัตราการเต้นของหัวใจ	float64	83.0	1,494,900	69,710	
6 resprate	อัตราการหายใจ	float64	24.0	1,475,217	89,393	
7 o2sat	ค่าความเข้มข้นของออกซิเจนในเลือด	float64	97.0	1,428,774	135,836	
8 sbp	ความดันโลหิตซิสโตลิก	float64	90.0	1,483,354	81,256	
9 dbp	ความดันโลหิตไดแอสโตลิก	float64	51.0	1,483,354	81,256	
10 rhythm	จังหวะการเต้นของหัวใจ	object	Sinus rhythm	59,650	1,504,960	
11 pain	ระดับความปวด	object	0	1,121,344	443,266	มีค่า 0-10 แต่สามารถลงข้อมูลเป็น free-text ได้

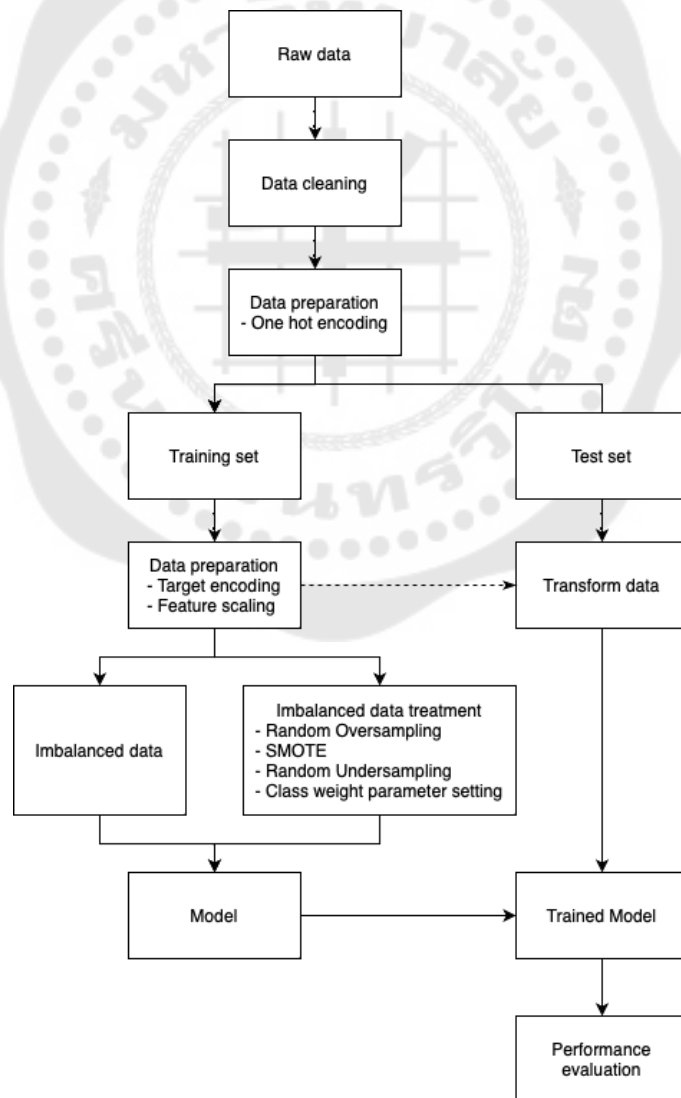
ตาราง 7 แสดงรายละเอียดของข้อมูลในตาราง patient

ชื่อคอลัมน์	ความหมาย	ประเภท	ตัวอย่างข้อมูล	จำนวนข้อมูล	จำนวนข้อมูลว่าง	หมายเหตุ
1 subject_id	ตัวบ่งชี้ ข้อมูลผู้ป่วยแต่ละคน หากมีการรับบริการหลายครั้งจะมีเพียงค่าเดียว	int64	10000032	299,712	0	เชื่อมกับตารางอื่น ๆ ในฐานข้อมูล MIMIC-IV เพื่อดูข้อมูลอื่น ๆ
2 gender	เพศ	object	F	299,712	0	
3 anchor_age	อายุ ณ ปี anchor_year	int64	52	299,712	0	ถ้ามีอายุมากกว่า 89 ปี จะถูกระบุเป็น 91 เพื่อให้ทราบอายุจริง และระบุตัวตนได้
4 anchor_year	ปี ที่ผ่านการไม่ระบุตัวตน	int64	2180	299,712	0	เป็นปีที่ไม่ระบุตัวตน อยู่ในช่วง 2100 - 2200
5 anchor_year_group	กลุ่มปี ที่เกิดเหตุการณ์ขึ้นจริง	object	2014 - 2016	299,712	0	จะเป็นช่วงของปี ณ ช่วงที่เกิดเหตุการณ์ขึ้นจริง
6 dod	วันที่เสียชีวิต	object	2180-09-09	29,076	270,636	



กระบวนการทำงาน

ในการวิจัยครั้งนี้ใช้ภาษาไพทอน (python) ในการจัดการข้อมูล และวิเคราะห์ข้อมูลในการเรียนรู้ของเครื่อง โดยมีกระบวนการทำงานของการสร้างแบบจำลองในการศึกษานี้ ดังภาพประกอบ 5 โดยเริ่มต้นจากการนำเข้าข้อมูล หลังจากนั้นผ่านกระบวนการเตรียมข้อมูล เช่น การทำความสะอาดข้อมูล การสำรวจข้อมูล การแปลงค่าจากตัวแปรต่าง ๆ ให้เหมาะสมกับการใช้งาน จากนั้นทำการแบ่งข้อมูลออกเป็น training set และ test set ด้วยอัตราส่วน 70:30 โดยข้อมูลในส่วนของการ training set จะทำการสเกลข้อมูล เพื่อนำข้อมูลเข้าทดสอบกับแบบจำลองต่าง ๆ โดยเน้นไปที่การเปรียบเทียบกระบวนการจัดการข้อมูลที่ไม่สมดุล ในแบบจำลองต่าง ๆ จากนั้นจึงนำไปใช้กับ test set เพื่อประเมินประสิทธิภาพ และเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลอง



ภาพประกอบ 5 แผนภาพแสดงกระบวนการทำงาน

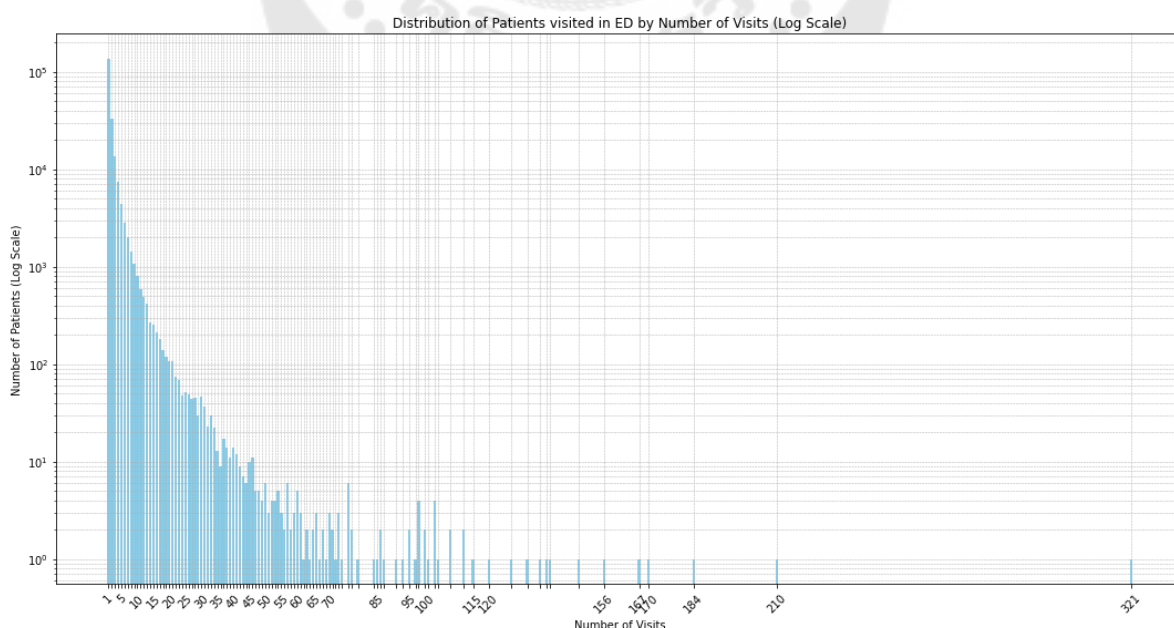
การนำเข้าข้อมูล

ในการวิจัยนี้จะมีการนำเข้าไลบรารีสำหรับการใช้งานภาษาไพทอน (python) โดยไลบรารีหลักที่ใช้ในการจัดการข้อมูล วิเคราะห์ข้อมูล และสร้างแบบจำลองได้แก่ numpy, pandas, datetime, matplotlib, sklearn, imblearn, xgboost จากนั้นจะนำเข้าข้อมูลในรูปแบบไฟล์ Comma Separated Value (*.csv) ด้วย pandas

การเตรียมข้อมูล

การเตรียมข้อมูล ได้แก่ การนำเข้าข้อมูล การสำรวจข้อมูล การทำความสะอาดข้อมูล คัดออกข้อมูลที่ซ้ำ การแปลงค่าจากตัวแปรต่าง ๆ ให้เหมาะสมกับการใช้งาน เช่น การแปลงข้อมูลประเภทแบ่งกลุ่ม เป็นตัวแปรใหม่ด้วยการทำ ordinal encoding, one-hot encoding หรือ target encoding โดยมีลำดับในการดำเนินการดังนี้ (ดังแสดงในภาพประกอบ 15)

1. นำเข้าและสำรวจตาราง edstays เนื่องจากเป็นตารางหลัก และสำรวจข้อมูล โดยมีข้อมูลผู้ป่วยที่เข้ามาใช้บริการที่แผนกฉุกเฉินมีทั้งสิ้น 425,087 ครั้ง คิดเป็นผู้ป่วยที่มารับบริการ 205,504 คน โดยมีผู้ป่วยคนเดียวกันที่มารับบริการที่แผนกฉุกเฉินมากที่สุด คือ 321 ครั้ง จำนวน 1 คน รองลงมาคือ 210 ครั้ง จำนวน 1 คน ในขณะที่มีผู้ป่วยจำนวน 135,552 คนที่มีประวัติมารับบริการที่แผนกฉุกเฉินเพียงครั้งเดียว (คิดเป็น 31.89%) ซึ่งแสดงการกระจายตัวของจำนวนครั้งของการเข้ารับบริการของผู้ป่วย 1 คน ต่อ จำนวนผู้ป่วย โดยแสดงเป็น Log scale ดังภาพประกอบ 6



ภาพประกอบ 6 แสดงการกระจายตัวของจำนวนครั้งของการเข้ารับบริการของผู้ป่วยต่อจำนวนผู้ป่วย

2. คำนวณอายุของผู้มารับบริการ เนื่องจากในฐานข้อมูล MIMIC-IV-ED มีการใช้ข้อมูลร่วมกับฐานข้อมูล MIMIC-IV ซึ่งมีความใหญ่กว่า โดยในตาราง edstays ของฐานข้อมูล MIMIC-IV-ED มี subject_id ซึ่งเป็นตัวบ่งชี้เฉพาะของผู้ป่วยแต่ละคน และมีวันที่และเวลาของการเข้ารับบริการที่แผนกฉุกเฉิน ซึ่งจำเป็นต้องเชื่อมข้อมูลจาก subject_id ในตาราง edstays และ subject_id ในตาราง patients โดย

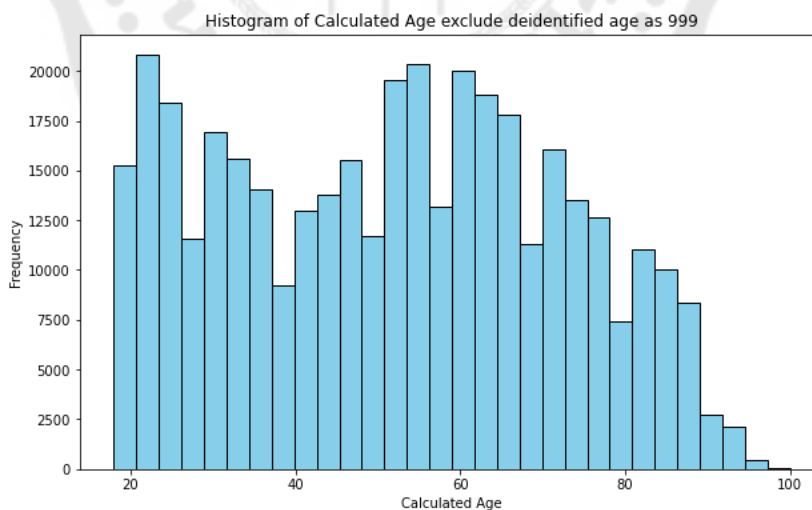
2.1. แปลงข้อมูล intime และ outtime ให้แยกเป็น ปี เดือน วัน ชั่วโมง นาที และ วินาที

2.2. นำ ปี ที่มารับบริการที่แผนกฉุกเฉินไปคำนวณอายุ ณ วันที่เข้ามาใช้บริการ จากข้อมูลปี anchor_year และอายุ anchor_age ในตาราง patients โดยตั้งชื่อว่า calculated_age

2.3. คำนวณอายุ (calculated_age) ด้วยสูตร ปีที่เข้ารับบริการในแผนกฉุกเฉิน ลบด้วย anchor_year แล้วบวก anchor_age

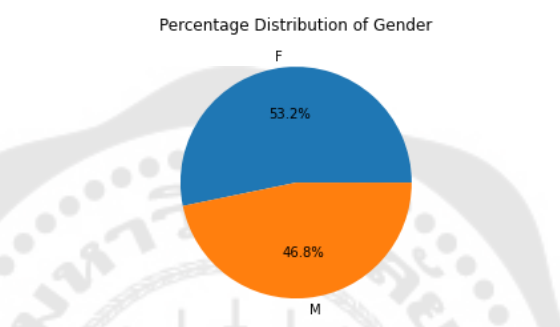
2.4. แปลงอายุที่คำนวณได้ สำหรับผู้ที่มี anchor_age เท่ากับ 91 เป็นอายุ 999 คือ ผู้ที่มารับบริการที่มีอายุมากกว่า 89 ปี

โดยมีการกระจายตัวของอายุแสดงดังภาพประกอบ 7 ทั้งนี้ผู้ป่วยที่อายุน้อยสุดคือ 18 ปี ตามเกณฑ์การคิดเข้า




ภาพประกอบ 7 การกระจายตัวของอายุ

3. ทำความสะอาดข้อมูลในตาราง edstays โดยกำจัดข้อมูลผู้ป่วยที่มีข้อมูลเพศในตาราง edstays ไม่ตรงกับเพศในตาราง patients ซึ่งกำจัดข้อมูลไปทั้งสิ้น 439 แถว คิดเป็นผู้ป่วย 77 คน และกำจัดข้อมูลผู้ป่วยที่มีเพศและ/หรือเชื้อชาติไม่ตรงกันในผู้ป่วยที่มี subject_id เดียวกัน ซึ่งกำจัดไปทั้งสิ้น 35,995 แถว คิดเป็นผู้ป่วย 6,234 คน จะเหลือข้อมูลการเข้ารับบริการที่แผนกฉุกเฉินทั้งสิ้น 388,653 ครั้ง คิดเป็นผู้ป่วย 199,193 คน โดยมีผู้ป่วยเพศหญิง 106,034 คน คิดเป็น 53.23% และเพศชาย 93,159 คน คิดเป็น 46.77% ดังแสดงในภาพประกอบ 8




ภาพประกอบ 8 แสดงสัดส่วนของเพศในผู้ป่วยที่มารับบริการ

4. ตรวจสอบและทำความสะอาดข้อมูลเกี่ยวกับเชื้อชาติ ซึ่งพบว่ามีข้อมูลที่แตกต่างกันทั้งหมด 33 ข้อมูล ดังแสดงในภาพประกอบ 9 และจากการสำรวจพบว่า 3 อันดับแรกของเชื้อชาติที่มีการบันทึกได้แก่ WHITE 58.92%, BLACK/AFRICAN AMERICAN 12.59% และ OTHER 5.44% ที่เหลือเป็นข้อมูลเชื้อชาติที่ลดหลั่นลงมา เพื่อลดการกระจายของข้อมูลที่มีปริมาณมาก ผู้วิจัยเลือกที่จะรวมข้อมูล เชื้อชาติในลำดับที่ 4 เป็นต้นไป เข้ากับข้อมูล OTHER ทำให้ ข้อมูล OTHER เพิ่มขึ้นเป็น 28.46% ดังแสดงในภาพประกอบ 10



ภาพประกอบ 9 แสดงสัดส่วนของเชื้อชาติทั้งหมด

Percentage Distribution of Race




ภาพประกอบ 10 แสดงสัดส่วนของเชื้อชาติ เมื่อมีการรวมข้อมูล

5. สํารวจข้อมูลวิธีการจําหน่ายจากแผนกฉุกเฉิน พบว่า มีผู้ป่วยที่ถูกจําหน่ายกลับบ้าน คิดเป็น 56.7% ได้รับการรักษาตัวในโรงพยาบาล 37.3% และวิธีอื่น ๆ ดังแสดงในตาราง 8 และภาพประกอบ 11

ตาราง 8 แสดงร้อยละของวิธีการจําหน่ายผู้ป่วยจากแผนกฉุกเฉิน

การจําหน่ายผู้ป่วยจากแผนกฉุกเฉิน	ร้อยละ
HOME	56.70
ADMITTED	37.34
TRANSFER	1.68
LEFT WITHOUT BEING SEEN	1.42
ELOPED	1.30
LEFT AGAINST MEDICAL ADVICE	0.44
EXPIRED	0.09
OTHER	1.04




ภาพประกอบ 11 แสดงสัดส่วนของวิธีการจำหน่ายผู้ป่วยจากแผนกฉุกเฉิน

6. สํารวจข้อมูลวิธีการเดินทางมาแผนกฉุกเฉิน โดยมีผู้ป่วย WALK IN คิดเป็น 59.10% ผู้ป่วยที่เดินทางมาด้วย AMBULANCE 36.81 และวิธีอื่น ๆ ดังแสดงในตาราง 9 และภาพประกอบ 12

ตาราง 9 แสดงร้อยละของวิธีการเดินทางมาแผนกฉุกเฉิน

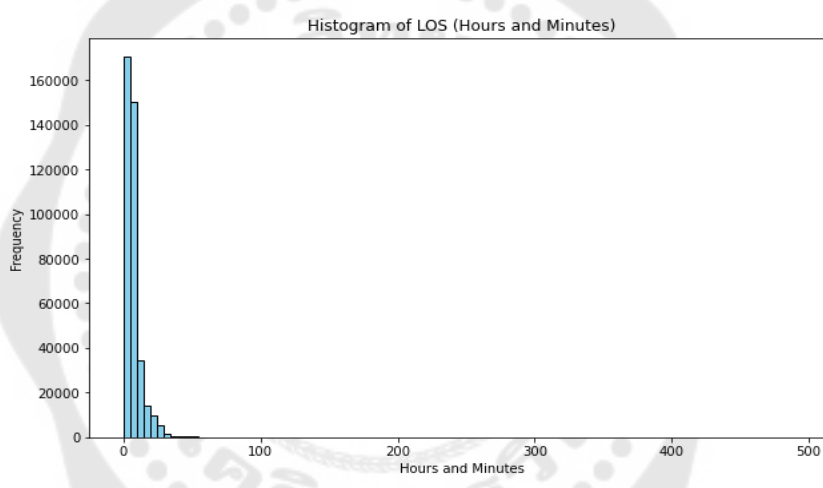
วิธีการเดินทางมาแผนกฉุกเฉิน	ร้อยละ
WALK IN	59.10
AMBULANCE	36.81
UNKNOWN	3.57
OTHER	0.30
HELICOPTER	0.22

Percentage Distribution of Arrival Transportation Mode



ภาพประกอบ 12 แสดงสัดส่วนของวิธีการเดินทางมาแผนกฉุกเฉิน

7. สร้างตัวแปร ระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉิน โดยนำวันที่และเวลาที่ผู้ป่วยถูกจำหน่ายจากแผนกฉุกเฉิน (outtime) ลบด้วยวันที่และเวลาที่ผู้ป่วยเดินทางมายังแผนกฉุกเฉิน (intime) ทั้งนี้มีข้อมูลที่คำนวณระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉิน เป็นค่าติดลบ จึงสมมติฐานว่ามีการสลับของข้อมูล outtime และ intime ผู้วิจัยได้ทำการสลับข้อมูลดังกล่าว และคำนวณระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉินอีกครั้ง ทั้งนี้มีจำนวน 48 ครั้งที่มีการบันทึกเวลาที่เดินทางมายังแผนกฉุกเฉินและเวลาจำหน่ายออกจากแผนกฉุกเฉินเป็นเวลาเดียวกัน จึงคำนวณระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉินได้เป็น ศูนย์ และจากการคำนวณพบว่า ระยะเวลาที่ผู้ป่วยมารับบริการและอยู่ในแผนกฉุกเฉิน มีค่ามัธยฐานเท่ากับ 5.45 ชั่วโมง (IQR = 4.78) หรือ 327 นาที (IQR = 287) ดังแสดงในภาพประกอบ 13



ภาพประกอบ 13 แสดงการกระจายของระยะเวลาที่ผู้ป่วยอยู่ในแผนกฉุกเฉิน

8. คัดเลือกเฉพาะการกลับมารับบริการ เมื่อได้รับการจำหน่ายให้กลับบ้าน (Disposition = HOME) ตามเกณฑ์คัดเข้า ซึ่งเหลือการรับบริการที่แผนกฉุกเฉินที่ได้รับการจำหน่ายกลับบ้านทั้งหมด 220,378 ครั้ง คิดเป็น 56.70% ของการรับบริการที่แผนกฉุกเฉินทั้งหมด (388,653 ครั้ง) เป็นผู้ป่วยจำนวน 132,873 คน คิดเป็น 66.71% ของผู้ป่วยที่มารับบริการที่แผนกฉุกเฉิน (199,193 คน)

9. นำเข้าตาราง diagnosis โดยจากข้อมูลที่มี icd_version, icd_code, icd_title ในที่นี่ได้เลือกใช้ icd_code มาเป็นตัวแทน เนื่องจากเป็น code สากลของ ICD-9 หรือ ICD-10 และมี code ที่แตกต่างกัน จากนั้นแปลงข้อมูลการลงวินิจฉัยที่ 1 code เป็น 1 แถว ตาม sequence ให้เป็น wide table โดยที่ 1 stay_id จะมีแค่ 1 แถว โดยทุก stay_id จะมี 9 คอลัมน์ของ code โดย

ที่หากการเข้ารับบริการครั้งดี มีการวินิจฉัยน้อยกว่า 9 คำวินิจฉัย ก็จะมีคอดัชนีที่เป็นลำดับหลังมีค่าเป็นค่าว่าง และแทนค่าว่างเป็น 0 เนื่องจาก 0 ไม่มี code ใน ICD-9 และ ICD-10 จึงใช้เป็นตัวแทนได้

10. นำเข้าตาราง vitalsign และจัดการข้อมูลดังนี้

10.1 ตัดคอดัชนี rhythm ออกเนื่องจากมีค่าว่าง 96%

10.2. แปลงหน่วย temperature ให้เป็นหน่วย Celsius (เนื่องจากในประเทศสหรัฐอเมริกาใช้ Fahrenheit เป็นหลัก)

10.3. แปลงค่า pain score เนื่องจาก pain score ตามหลักแล้วจะต้องลงเป็นคะแนนตัวเลขเท่านั้น แต่บางครั้งไม่สามารถลงข้อมูลได้ เลยมีการบันทึกข้อมูลเป็นข้อความ เช่น eating no pain, Pt refused จึงทำการแปลงเฉพาะข้อมูลที่เป็นตัวเลข ให้เป็นตัวเลขจริง ๆ และข้อความตัวอักษรให้แปลงเป็นค่าว่างแทน

10.4. กำหนดค่า Maximum และ Minimum ของค่าในตาราง vital sign โดยใช้ความรู้ทางการแพทย์ของผู้วิจัย เพื่อแปลงค่าที่เป็น outlier โดยไม่ใช้ outlier ตามการคำนวณจาก IQR เนื่องจากข้อมูลหลายค่า สามารถสูงและต่ำได้จริง การคำนวณ outlier อาจจะคำนวณไม่ถูกต้อง โดยมีการกำหนด ดังตาราง 10 จากนั้นแทนค่าทั้งหมดที่มากกว่า Maximum และน้อยกว่า Minimum ให้เป็นค่าว่าง

ตาราง 10 แสดงค่า Minimum และ Maximum limit ของค่าสัญญาณชีพ

ค่า Vital sign	Minimum limit	Maximum limit
Temperature (degree Celsius)	35	42
Heart rate (per minute)	20	200
Respiratory rate (per minute)	8	40
Oxygen saturation (%)	50	100
Systolic blood pressure (mmHg)	50	300
Diastolic blood pressure (mmHg)	20	150
Pain score	0	10

10.5. ลดข้อมูลในการรับบริการแต่ละครั้ง ให้เหลือเพียงค่าเดียว ด้วยการหาตัวแทนโดยใช้ค่าเฉลี่ยของแต่ละการเข้ารับบริการ ยกเว้น ค่า pain score จะแทนที่ด้วยค่ามัธยฐาน

10.6. แทนที่ค่าว่างด้วยค่าเฉลี่ยของข้อมูลทั้งหมด ยกเว้น ค่า pain score จะแทนที่ด้วยค่ามัธยฐาน

11. นำเข้าตาราง triage โดยเลือกใช้เฉพาะข้อมูล acuity level เป็นค่าตัวแทนที่ใช้ในการคัดกรองผู้ป่วยว่ามีความเร่งด่วน โดยอาศัยข้อมูลสัญญาณชีพ อาการนำ ซึ่งเป็นการประเมินโดยบุคลากรทางการแพทย์ จึงตัดข้อมูลอื่น ๆ ออก และใช้เฉพาะ acuity level จากนั้นแทนที่ค่าว่างด้วยค่ามัธยฐานของข้อมูลทั้งหมด

12. รวมข้อมูลทั้งหมดจากตาราง edstays, diagnosis, vitalsign และ triage โดยใช้ข้อมูลในตาราง edstays เป็นตารางหลัก (left join)

13. สักรวจค่าว่างในตาราง และแทนที่ค่าว่างของคอลัมน์ใน vital sign ด้วยค่าเฉลี่ยของทั้งหมด ยกเว้น ค่า pain score จะแทนที่ด้วยค่ามัธยฐาน ค่าว่างของ acuity level แทนค่าด้วยค่ามัธยฐาน และค่าว่างของการวินิจฉัยแทนที่ด้วย 0

14. สร้างตัวแปร ระยะเวลาที่มารับบริการที่แผนกฉุกเฉินในครั้งถัดไปหลังจากถูกจำหน่ายออกจากแผนกฉุกเฉิน (Revisit gap time) เนื่องจากงานวิจัยนี้จะทำการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน จึงต้องมีการสร้างตัวแปรใหม่ โดยคำนวณจากระยะเวลาที่ผู้ป่วยได้รับการจำหน่ายออกจากแผนกฉุกเฉิน (outtime of index visit) และระยะเวลาที่ผู้ป่วยกลับมาใช้บริการที่แผนกฉุกเฉินในครั้งถัดไป (intime of next visit) ว่าอยู่ภายในระยะเวลา 72 ชั่วโมงหรือไม่ โดยตัวแปรทำนายในการวิจัยนี้ คือ การกลับมาใช้บริการที่แผนกฉุกเฉินภายในระยะเวลา 72 ชั่วโมง หลังจากได้รับอนุญาตให้กลับบ้าน โดยมีการคำนวณการกลับมาใช้บริการซ้ำที่แผนกฉุกเฉินดำเนินการดังนี้ (แสดงในภาพประกอบ 14)

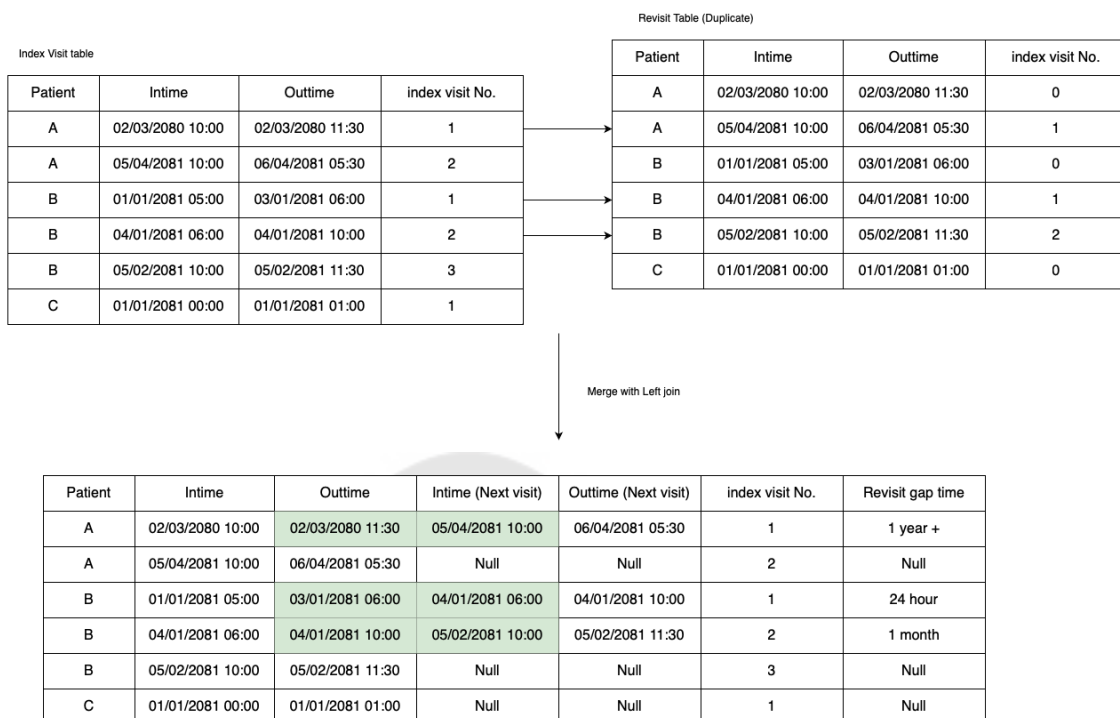
14.1. เรียงข้อมูลผู้ป่วยคนเดียวกัน ตามวันที่และเวลาที่ผู้ป่วยมาแผนกฉุกเฉิน

14.2. สร้างคอลัมน์ใหม่ เป็นครั้งที่มารับบริการที่แผนกฉุกเฉิน

14.3. คัดลอกตาราง เป็นตารางการกลับมาใช้บริการครั้งถัดไป และหักค่าครั้งที่มารับบริการที่แผนกฉุกเฉินออก หนึ่ง เพื่อบอกว่าเป็นการมารับบริการที่ต่อเนื่องจากครั้งก่อน

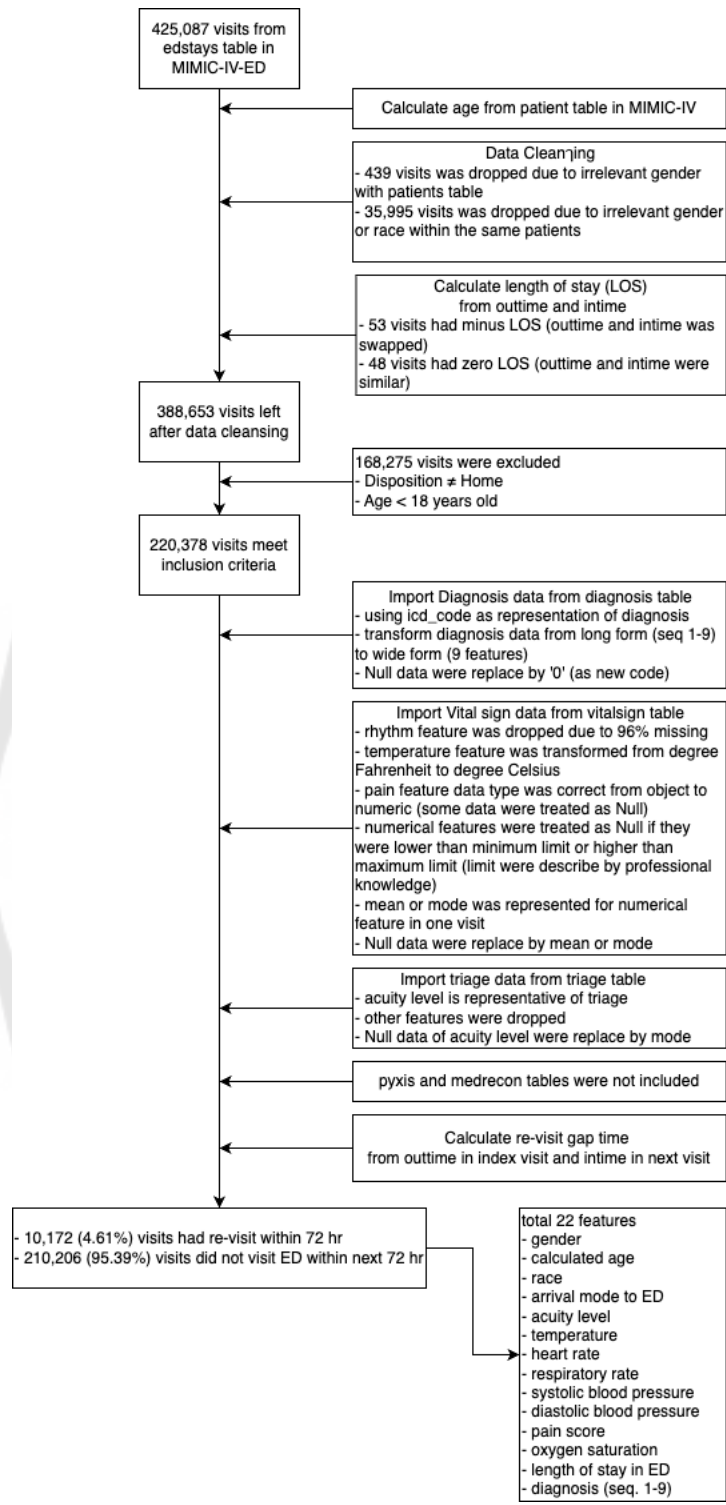
14.4. รวมตาราง โดย match ด้วยค่าครั้งที่มารับบริการที่ตรงกัน

14.5. คำนวณระยะเวลาที่ผู้ป่วยกลับมาใช้บริการซ้ำ โดยใช้ วันที่และเวลาที่มารับบริการครั้งต่อไป หักลบด้วย วันที่และเวลาที่จำหน่ายจากแผนกฉุกเฉินในครั้งนั้น



ภาพประกอบ 14 แสดงวิธีการคำนวณระยะเวลาที่มารับบริการที่แผนกฉุกเฉินในครั้งถัดไปหลังจากถูกจำหน่ายออกจากแผนกฉุกเฉิน (Revisit gap time)

15. สร้างตัวแปร การกลับมารับการรักษารักษาซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง หลังจากได้รับการจำหน่ายให้กลับบ้าน โดยคำนวณจาก revisit gap time ที่น้อยกว่าหรือเท่ากับ 72 ชั่วโมง พบว่ามีจำนวนการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง จำนวน 10,172 ครั้ง คิดเป็น 4.61% จากทั้งหมด 220,378 ครั้ง



ภาพประกอบ 15 แผนภาพแสดงการเตรียมข้อมูล

สรุปตัวแปรที่นำมาใช้ในงานวิจัย

ตัวแปรที่ใช้ในการทำนายสำหรับงานวิจัยนี้ มีทั้งหมด 22 ตัวแปร ประกอบด้วยข้อมูล ดังนี้

1. ข้อมูลส่วนบุคคล จำนวน 3 ตัวแปร ได้แก่ เพศ อายุ เชื้อชาติ
2. ข้อมูลการเดินทางมาที่แผนกฉุกเฉิน จำนวน 1 ตัวแปร
3. ข้อมูลการคัดกรองก่อนเข้ารับบริการ จำนวน 1 ตัวแปร คือ ระดับการประเมิน ความรุนแรงและเร่งด่วน

4. สัญญาณชีพระหว่างรักษาตัวอยู่ในแผนกฉุกเฉิน จำนวน 7 ตัวแปร ได้แก่ อุณหภูมิร่างกาย อัตราการเต้นของหัวใจ อัตราการหายใจ ค่าระดับความเข้มข้นของออกซิเจนในเลือด ความดันโลหิตซิสโตลิก ความดันโลหิตไดแอสโตลิก ระดับความปวด

5. ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน จำนวน 1 ตัวแปร โดยคำนวณจาก เวลาที่ผู้ป่วยเข้ารับบริการ และเวลาที่จำหน่ายผู้ป่วย

6. ผลการวินิจฉัย จำนวน 9 ตัวแปร คือ ผลการวินิจฉัยลำดับที่ 1-9

โดยในงานวิจัยครั้งนี้ได้ไม่ได้นำข้อมูลการได้รับยาในขณะที่ยังผู้ป่วยรับบริการที่แผนกฉุกเฉินจากตาราง pyxis เนื่องจากข้อมูลที่ได้มีเฉพาะข้อมูลการจ่ายยาจากเครื่องอัตโนมัติเท่านั้น ซึ่งไม่ครอบคลุมยาทั้งหมด เช่น ยาที่ได้รับการช่วยชีวิต จึงไม่นำข้อมูลการได้รับยาในขณะที่ยังผู้ป่วยรับบริการที่แผนกฉุกเฉินมาใช้ในการทำนาย และรายการยาที่ผู้ป่วยเคยได้รับ ก่อนเข้ารับบริการที่แผนกฉุกเฉิน จากตาราง medrecon เนื่องจากข้อมูลเก็บไม่สมบูรณ์

การแปลงข้อมูลเป็นตัวเลข

Nominal scale

ข้อมูลที่เป็น Nominal ในงานวิจัยนี้ได้แก่ เพศ เชื้อชาติ และ การเดินทางมาที่แผนกฉุกเฉิน สำหรับข้อมูลเพศใช้การแปลงค่า เพศหญิง เป็น 0 และเพศชายเป็น 1 ในขณะที่เชื้อชาติและการเดินทางมาที่แผนกฉุกเฉิน ซึ่งมีมากกว่า 1 กลุ่ม จึงใช้ OneHotEncoder ในการแปลงข้อมูลดังกล่าวให้เป็นตัวเลข

Ordinal scale

ข้อมูลที่เป็น Ordinal ในงานวิจัยนี้ได้แก่ ระดับความปวด และระดับการประเมิน ความรุนแรงและเร่งด่วน ซึ่งทั้ง 2 ค่า เป็น Ordinal scale ที่เป็นตัวเลขอยู่แล้ว โดยระดับความปวดมีค่า 0-10 และระดับการประเมินความรุนแรงและเร่งด่วน มีค่า 1-5 จึงไม่จำเป็นต้องใช้ OrdinalEncoder

Label

ข้อมูล Label เป็น True และ False จึงใช้ LabelEncoder เพื่อแปลงข้อมูลให้เป็น 1 และ 0 ตามลำดับ

ข้อมูลการวินิจฉัย

เนื่องจากข้อมูลการวินิจฉัยโรค มีทั้งหมด 9 คอลัมน์ และข้อมูลภายในเป็นข้อมูลที่แตกต่างกันค่อนข้างมาก จึงต้องใช้ TargetEncoder มาช่วยในการแปลงข้อมูลถ่วงน้ำหนักเป็นตัวเลข โดยอ้างอิงจากผลของ Label จึงต้องป้องกันไม่ให้เกิด Data leakage โดยแบ่งข้อมูลเป็น Training set และ Test set ก่อนจากนั้นจึงทำ Target Encoder เฉพาะข้อมูล Training set เท่านั้น

การสเกลข้อมูล

สำหรับข้อมูลที่เป็นตัวเลขทั้งหมดในงานวิจัยนี้จะใช้การสเกลข้อมูลด้วยวิธี StandardScaler สำหรับข้อมูล Training set เพื่อใช้ในการพิจารณา feature importance เนื่องจากหากข้อมูลตัวเลขมี scale ที่ไม่เท่ากัน จะทำให้ค่าความสำคัญของตัวแปร ถูกคิดถ่วงไปที่ข้อมูลที่มีค่ามาก

การจัดการความไม่สมดุลของข้อมูล

เนื่องจากข้อมูลที่นำมาศึกษา พบว่ามีการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง เพียง 4.61% ดังนั้นเพื่อไม่ให้แบบจำลองมีการเอนเอียงในการทำนาย จึงมีการจัดการความไม่สมดุลของข้อมูล โดยในงานวิจัยฉบับนี้จะใช้วิธีการจัดการ คือ Random oversampling, SMOTE, Random undersampling และ Class weight ในทุกแบบจำลอง เปรียบเทียบกับการไม่จัดการความไม่สมดุลของข้อมูล

การสร้างแบบจำลอง

ในการสร้างแบบจำลองสำหรับการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง ในงานวิจัยฉบับนี้จะเลือกใช้แบบจำลองดังนี้

1. Logistic regression
2. KNN classification
3. Random Forest classification
4. XGBoost classification

การวัดประสิทธิภาพของแบบจำลอง

ในการวัดประสิทธิภาพของแบบจำลองในงานวิจัยนี้จะทำการวัดด้วยค่า Accuracy, Recall และ AUC จากการ Validate ข้อมูลใน Test set โดยจำต้องมีการ transform Test set จากการทำ Target encoding และ Scaling ก่อน จากนั้นทำการเปรียบเทียบแบบจำลองต่าง ๆ ทั้งหมดเพื่อหาแบบจำลองที่ให้ประสิทธิภาพดีที่สุด



บทที่ 4

ผลการศึกษา

ในงานวิจัยนี้มีจุดประสงค์เพื่อสร้างแบบจำลองเพื่อใช้ในการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน โดยใช้ข้อมูลของผู้ป่วยที่มารับบริการที่แผนกฉุกเฉินโดยใช้การเรียนรู้อัตโนมัติ ซึ่งได้มีการแบ่งการแสดงผลการศึกษาดังนี้

1. ผลของการสำรวจตัวแปร
2. ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง
3. ผลการแสดงความสำคัญของตัวแปรแต่ละแบบจำลอง

ผลของการสำรวจตัวแปร

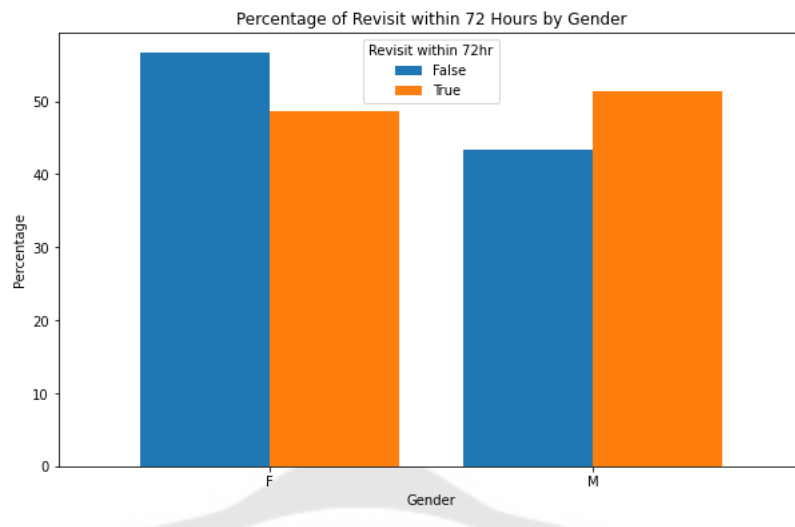
การสำรวจตัวแปร จะแยกข้อมูลเป็น 2 กลุ่ม คือ กลุ่มที่มีการกลับเข้ามาใช้บริการซ้ำภายใน 72 ชั่วโมง และกลุ่มที่ไม่ได้กลับเข้ามาใช้บริการซ้ำภายใน 72 ชั่วโมง โดยมีการสำรวจตัวแปรตามกลุ่มเฉพาะ 6 ตัวแปรหลัก ได้แก่ เพศ อายุ เชื้อชาติ วิธีการเดินทางมาที่แผนกฉุกเฉิน ระดับการประเมินความรุนแรงและเร่งด่วน และ ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน

ทั้งนี้จะไม่มีการเปรียบเทียบผลของ 16 ตัวแปร ได้แก่ สัญญาณชีพระหว่างรักษาตัวอยู่ในแผนกฉุกเฉิน จำนวน 7 ตัวแปร และ ผลการวินิจฉัย จำนวน 9 ตัวแปร

1. เพศ พบว่าในกลุ่มที่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง จะมีอัตราส่วนของเพศชายสูงกว่าเพศหญิง ในขณะที่กลุ่มที่ไม่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง มีอัตราส่วนของเพศหญิงสูงกว่าเพศชาย ดังแสดงในตาราง 11 และ ภาพประกอบ 16


ตาราง 11 แสดงผลการสำรวจตัวแปร เพศ

เพศ	กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (% , จำนวน)	ไม่กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (% , จำนวน)
ชาย	51.33% (5,221 ครั้ง)	43.35% (91,121 ครั้ง)
หญิง	47.67% (4,951 ครั้ง)	56.65% (119,085 ครั้ง)



ภาพประกอบ 16 แสดงผลการสำรวจตัวแปร เพศ

2. อายุ พบว่า ในกลุ่มที่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง มีอายุเฉลี่ย 49.48 ปี (SD = 19.19) ซึ่งสูงกว่า กลุ่มที่ไม่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง ที่มีอายุเฉลี่ย 46.81 ปี (SD = 19.84) โดยแสดงข้อมูลดังตาราง 12 และ ภาพประกอบ 7



ภาพประกอบ 17 แสดงผลการสำรวจตัวแปร อายุ


ตาราง 12 แสดงผลการสำรวจตัวแปร อายุ

อายุ	กลับมารับบริการซ้ำ ภายใน 72 ชั่วโมง (ปี) N = 10,172 ครั้ง	ไม่กลับมารับบริการซ้ำ ภายใน 72 ชั่วโมง (ปี) N = 210,206 ครั้ง
Mean (SD)	49.48 ปี (SD = 19.19)	46.81 (SD = 19.84)
Median (IQR)	51 ปี (IQR = 31)	46 ปี (IQR = 32)

3. เชื้อชาติ พบว่าการเข้ารับบริการที่แผนกฉุกเฉิน ส่วนใหญ่จะมีคนผิวขาว (WHITE) ในอัตราส่วนใกล้เคียงกัน คือ 53.42% และ 51.26% ในกลุ่มที่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง และกลุ่มที่ไม่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง ตามลำดับ ในขณะที่ในกลุ่มที่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง จะมีอัตราส่วนของคนผิวดำ (BLACK/AFRICAN AMERICAN) สูงกว่าเชื้อชาติอื่น ๆ ในขณะที่กลุ่มที่ไม่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง มีอัตราส่วนของเชื้อชาติอื่น ๆ สูงกว่าคนผิวดำ (BLACK/AFRICAN AMERICAN) ดังแสดงในตาราง 13 และ ภาพประกอบ 18

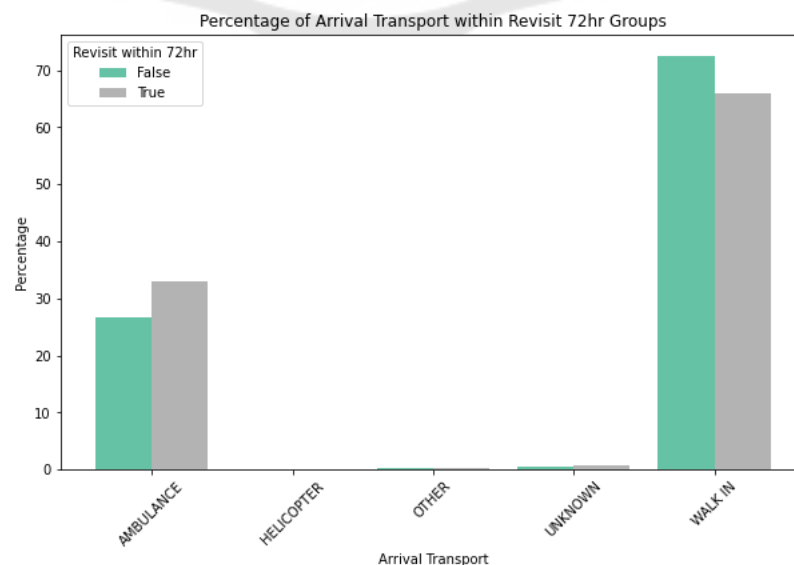
ตาราง 13 แสดงผลการสำรวจตัวแปร เชื้อชาติ

เชื้อชาติ	กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (% , จำนวน)	ไม่กลับมารับบริการซ้ำ ภายใน 72 ชั่วโมง (% , จำนวน)
คนผิวขาว	52.42% (5,434 ครั้ง)	51.26% (107,758 ครั้ง)
คนผิวดำ	25.28% (2,571 ครั้ง)	21.27% (44,703 ครั้ง)
อื่น ๆ	21.30% (2,167 ครั้ง)	27.47% (57,745 ครั้ง)



ภาพประกอบ 18 แสดงผลการสำรวจตัวแปร เชื้อชาติ

4. วิธีการเดินทางมาที่แผนกฉุกเฉิน พบว่าการเข้ารับบริการที่แผนกฉุกเฉินส่วนใหญ่จะมีเดินทางมายังแผนกฉุกเฉินด้วย 2 วิธีหลัก คือ การเดินทางมาด้วยตนเอง (WALK IN) และการเดินทางมาด้วยรถฉุกเฉิน (AMBULANCE) ซึ่งรวมกันคิดอัตราส่วนเป็นประมาณ 98-99% โดยการเดินทางมาด้วยตนเอง (WALK IN) มีอัตราส่วนสูงกว่า การเดินทางมาด้วยรถฉุกเฉิน (AMBULANCE) ในทั้ง 2 กลุ่ม ดังแสดงในตาราง 14 และ ภาพประกอบ 19



ภาพประกอบ 19 แสดงผลการสำรวจตัวแปร วิธีการเดินทางมาที่แผนกฉุกเฉิน

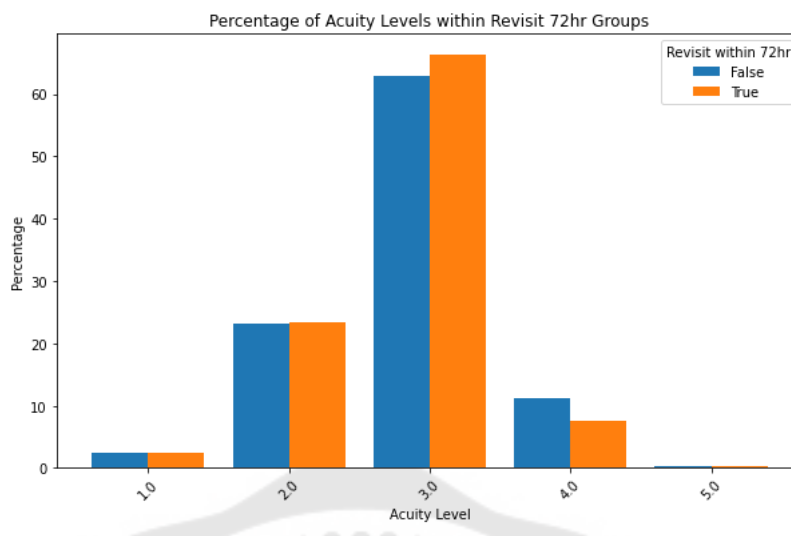
ตาราง 14 แสดงผลการสำรวจตัวแปร วิธีการเดินทางมาที่แผนกฉุกเฉิน

การเดินทางมาที่แผนกฉุกเฉิน	กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (%, จำนวน)	ไม่กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (%, จำนวน)
ด้วยตนเอง (WALK IN)	65.91% (6,704 ครั้ง)	72.59% (152,585 ครั้ง)
ด้วยรถฉุกเฉิน (AMBULANCE)	32.96% (3,353 ครั้ง)	26.64% (55,991 ครั้ง)
ด้วยเฮลิคอปเตอร์ (HELICOPTER)	0.02% (2 ครั้ง)	0.02% (41 ครั้ง)
ด้วยวิธีอื่น ๆ	0.30% (31 ครั้ง)	0.34% (711 ครั้ง)
ไม่ทราบ	0.81% (82 ครั้ง)	0.42% (878 ครั้ง)

5. ระดับการประเมินความรุนแรงและเร่งด่วน พบว่าการเข้ารับบริการที่แผนกฉุกเฉิน ส่วนใหญ่จะมีระดับความรุนแรงและเร่งด่วนอยู่ที่ ระดับ 3 รองลงมาคือระดับ 2 โดยในกลุ่มที่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมง จะมีระดับความรุนแรงของระดับ 1 และ 2 ไม่แตกต่างกัน แต่จะมีระดับ 3 ที่สูงกว่า และระดับ 4 ที่น้อยกว่า ดังแสดงในตาราง 15 และ ภาพประกอบ 20

ตาราง 15 แสดงผลการสำรวจตัวแปร ระดับการประเมินความรุนแรงและเร่งด่วน

ระดับการประเมิน	กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (%, จำนวน)	ไม่กลับมารับบริการซ้ำภายใน 72 ชั่วโมง (%, จำนวน)
ระดับ 1	2.39% (5,218 ครั้ง)	2.48% (243 ครั้ง)
ระดับ 2	23.42% (48,500 ครั้ง)	23.07% (2,382 ครั้ง)
ระดับ 3	66.35% (132,275 ครั้ง)	62.93% (6,749 ครั้ง)
ระดับ 4	7.52% (23,375 ครั้ง)	11.12% (765 ครั้ง)
ระดับ 5	0.32% (838 ครั้ง)	0.40% (33 ครั้ง)

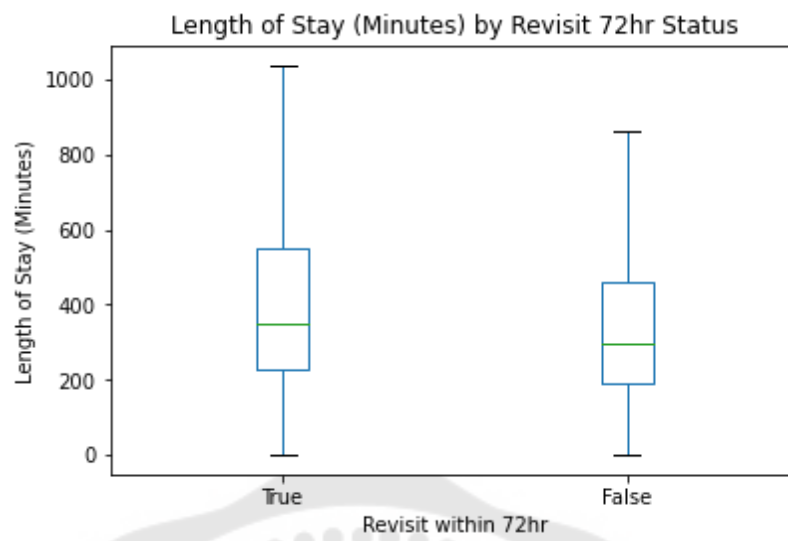


ภาพประกอบ 20 แสดงผลการสำรวจตัวแปร ระดับการประเมินความรุนแรงและเร่งด่วน

6. ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน พบว่า ในกลุ่มที่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง มีค่ามัธยฐานเท่ากับ 348 นาที (IQR = 325.35) ซึ่งสูงกว่า กลุ่มที่ไม่มีการกลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง ที่ค่ามัธยฐานเท่ากับ 295 นาที (IQR = 296) โดยแสดงข้อมูลดังตาราง 16 และ ภาพประกอบ 21

ตาราง 16 แสดงผลการสำรวจตัวแปร ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน

ระยะเวลาที่อยู่ภายใน แผนกฉุกเฉิน	กลับมาใช้บริการซ้ำภายใน 72 ชั่วโมง (ปี) N = 10,172 ครั้ง	ไม่กลับมาใช้บริการซ้ำ ภายใน 72 ชั่วโมง (ปี) N = 210,206 ครั้ง
Mean (SD)	460.76 นาที (SD = 391.30)	411.02 (SD = 403.80)
Median (IQR)	348 นาที (IQR = 325.35)	295 นาที (IQR = 296)



ภาพประกอบ 21 แสดงผลการสำรวจตัวแปร ระยะเวลาที่อยู่ภายในแผนกฉุกเฉิน

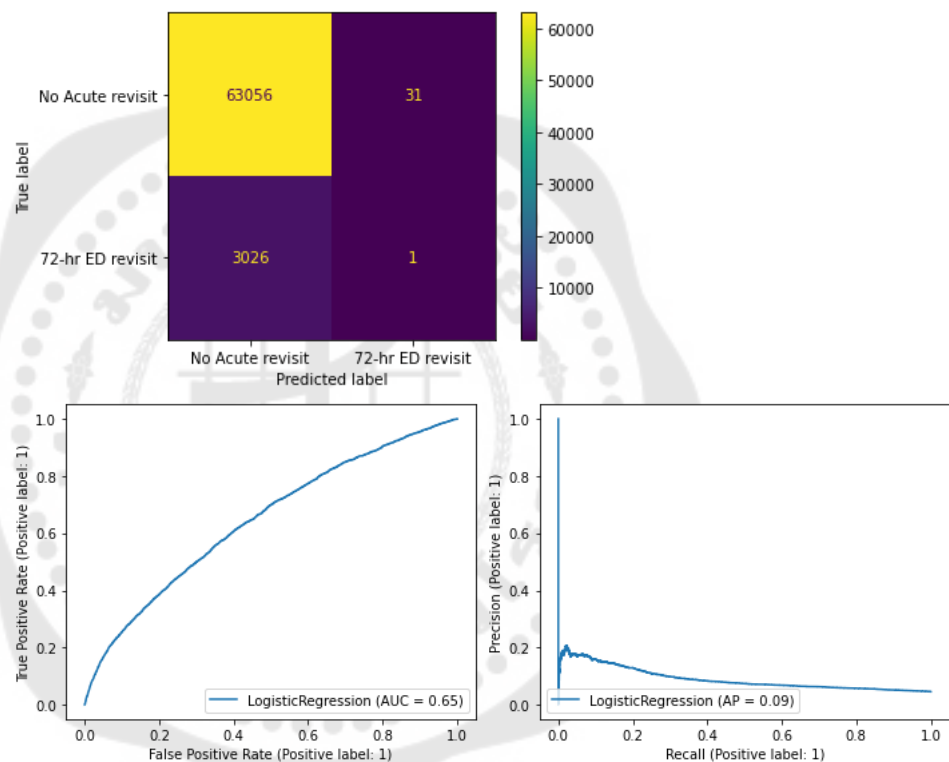


ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง

ในงานวิจัยนี้มีการสร้างแบบจำลองทั้งสิ้น 29 แบบ โดยแบ่งเป็น 4 แบบจำลองหลัก จาก การนำข้อมูลเข้าฝึก และนำมาใช้กับกลุ่มทดสอบได้ประสิทธิภาพของแบบจำลองต่าง ๆ ดังนี้

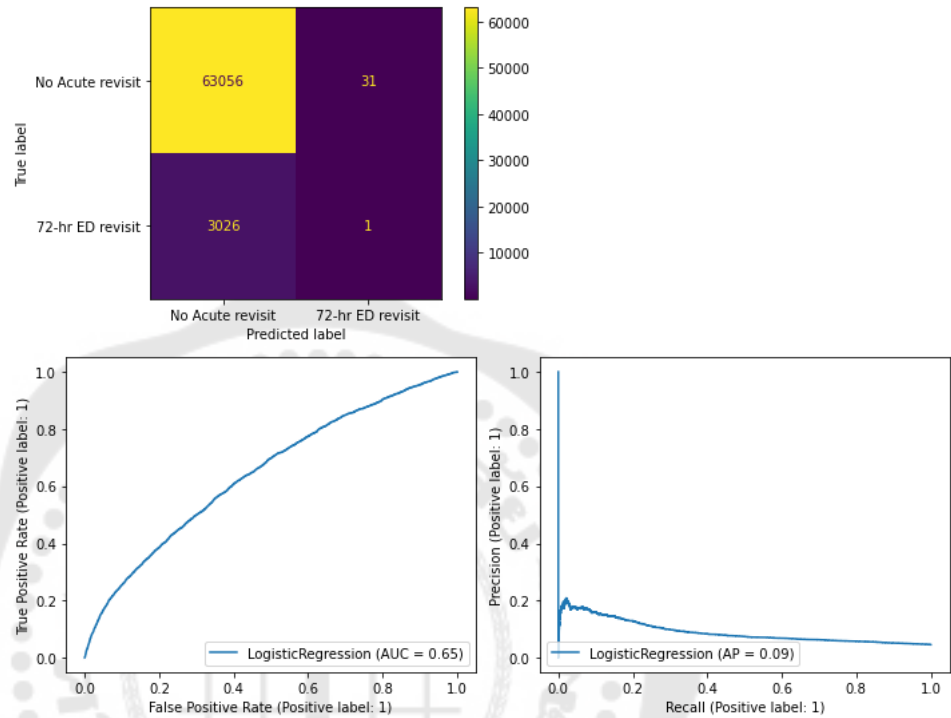
1. Logistic regression ทั้งหมด 15 แบบจำลอง

1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และ กำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 22 และตาราง 17



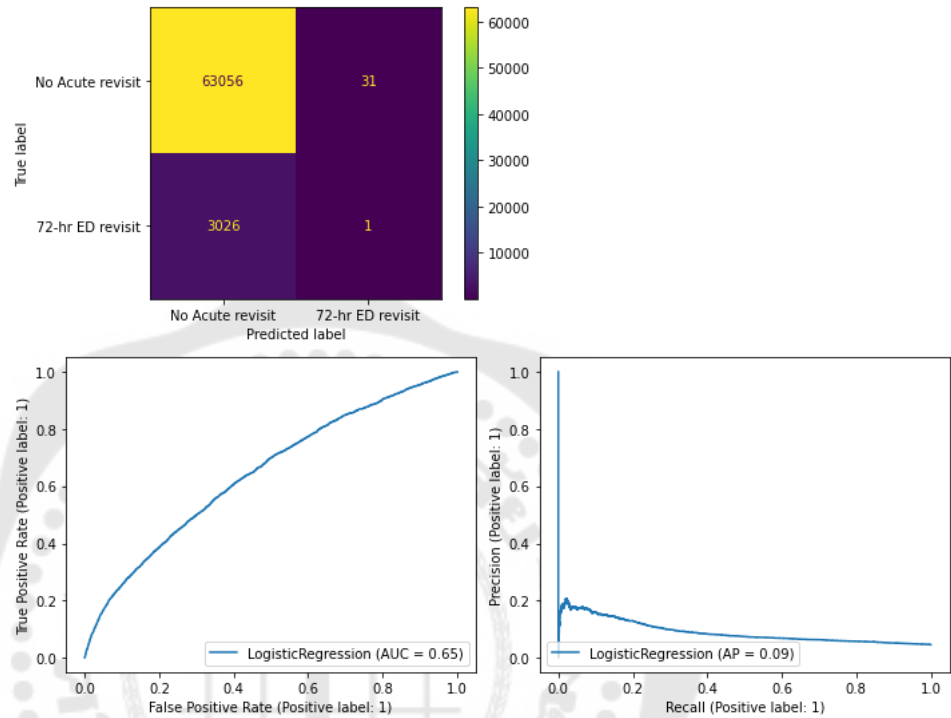
ภาพประกอบ 22 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.1

1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และ กำหนดค่า C เป็น 0.01 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 23 และตาราง 17



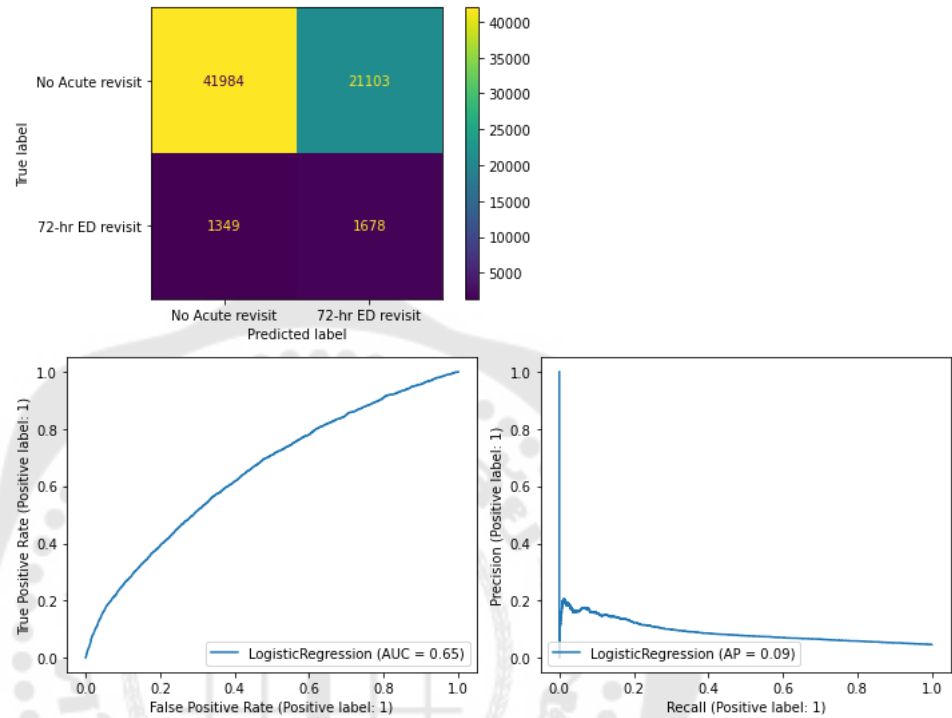
ภาพประกอบ 23 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.2

1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และ กำหนดค่า C เป็น 100 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 24 และตาราง 17



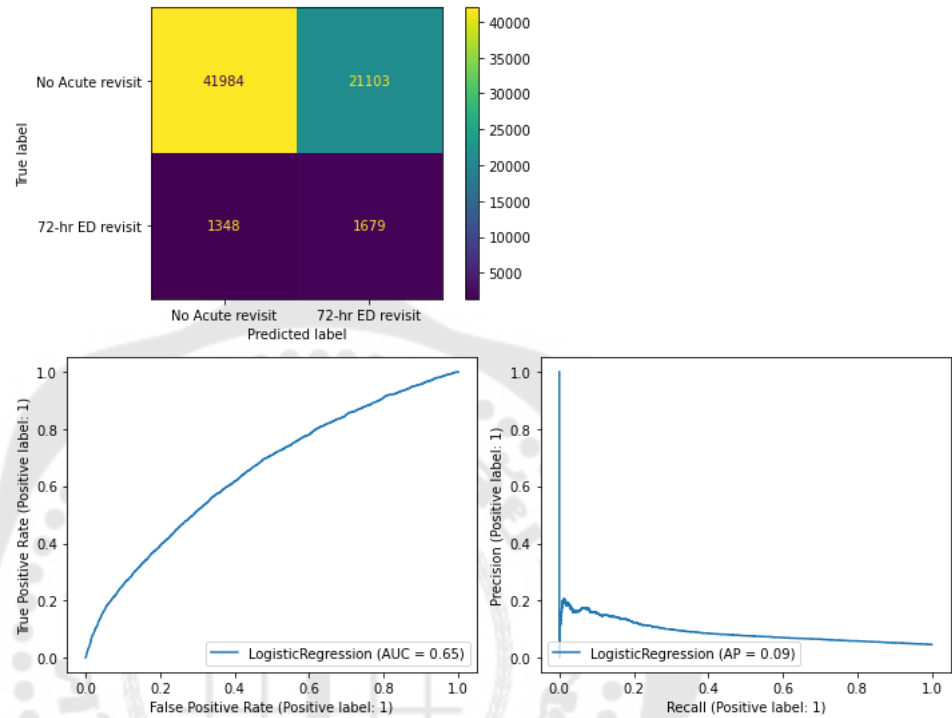
ภาพประกอบ 24 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.3

1.4. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 25 และตาราง 17



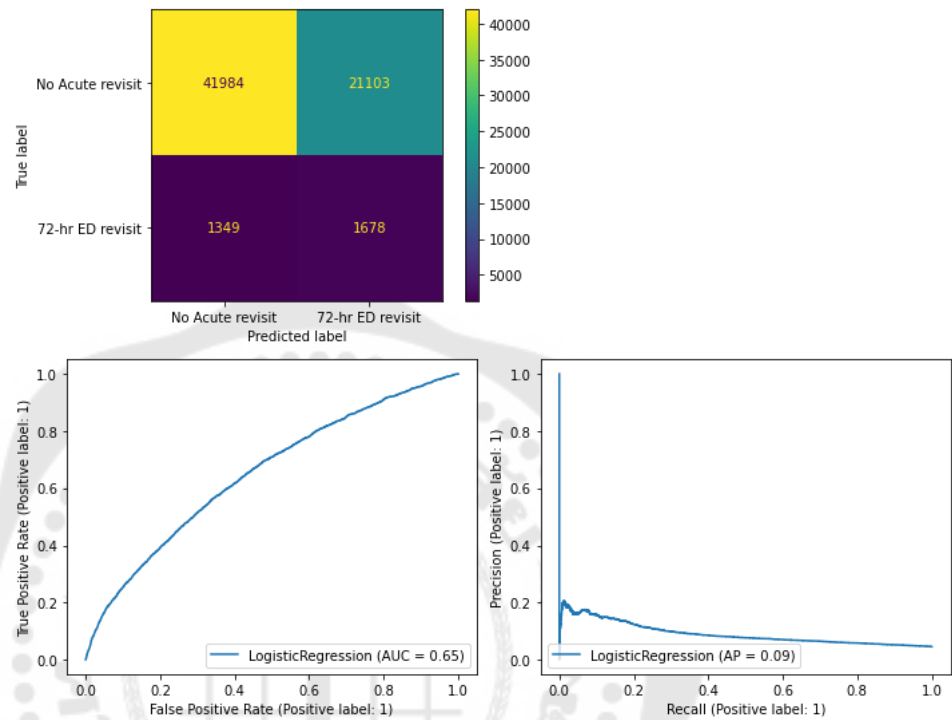
ภาพประกอบ 25 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.4

1.5. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 0.01 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 26 และตาราง 17



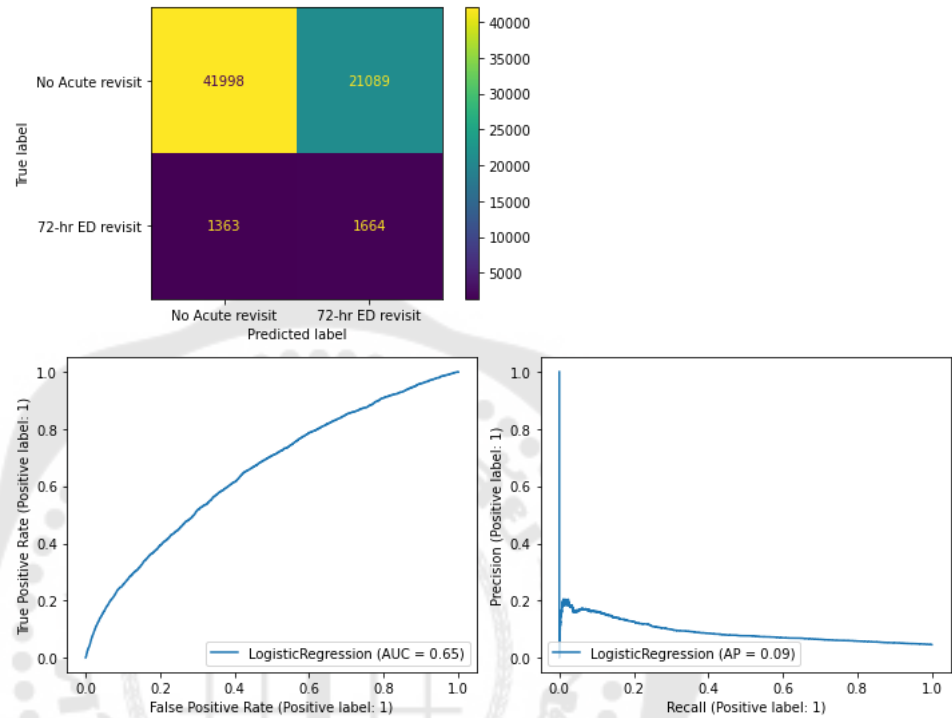
ภาพประกอบ 26 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.5

1.6. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 100 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 27 และตาราง 17



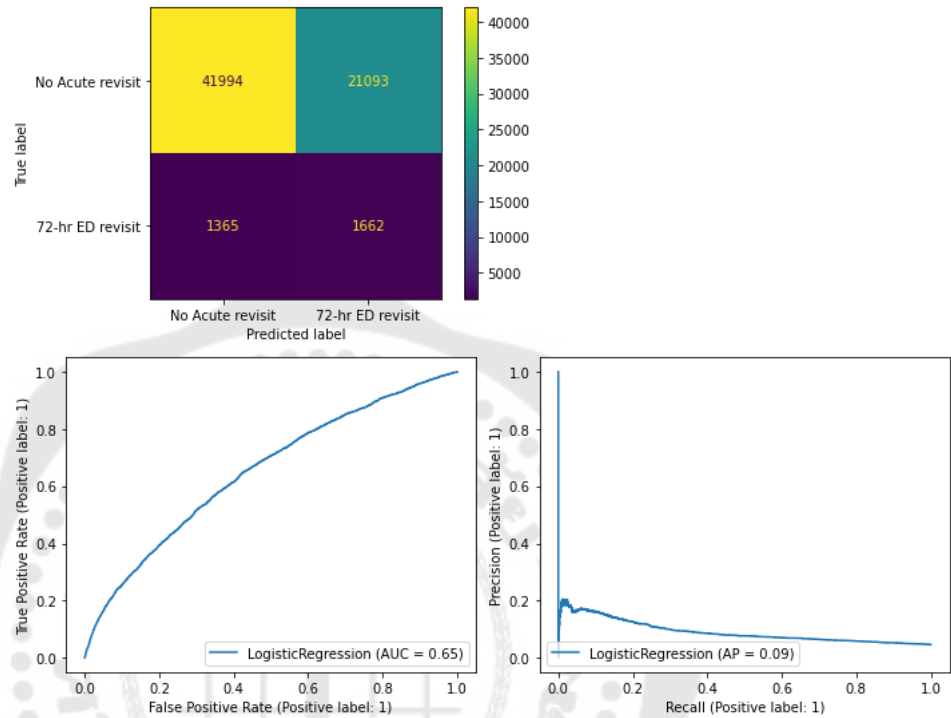
ภาพประกอบ 27 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.6

1.7. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 28 และตาราง 17



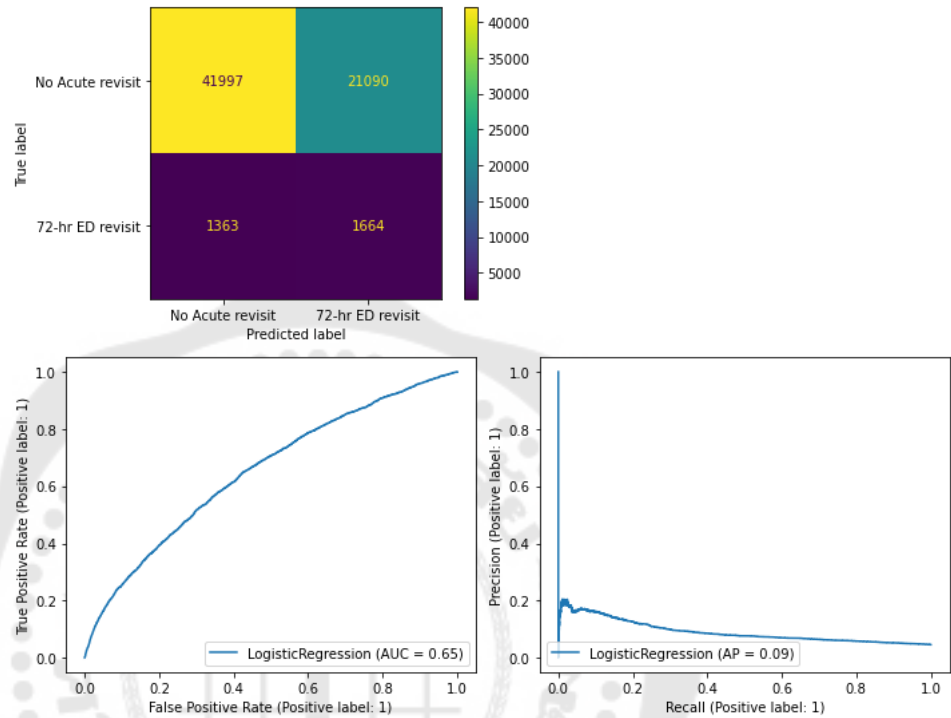
ภาพประกอบ 28 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.7

1.8. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 0.01 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 29 และ ตาราง 17



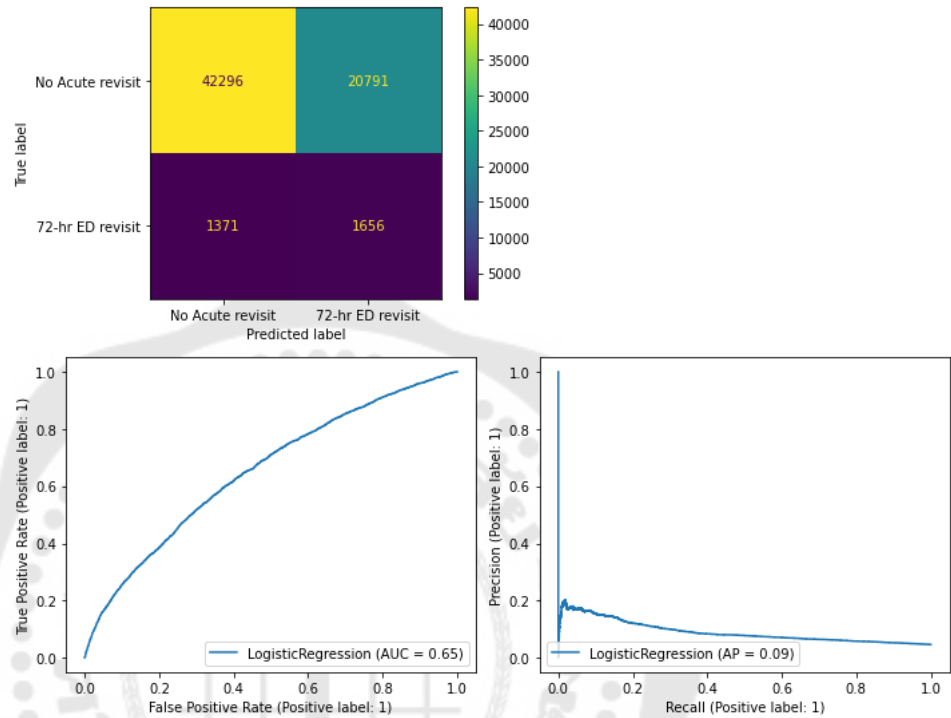
ภาพประกอบ 29 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.8

1.9. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 100 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 30 และ ตาราง 17



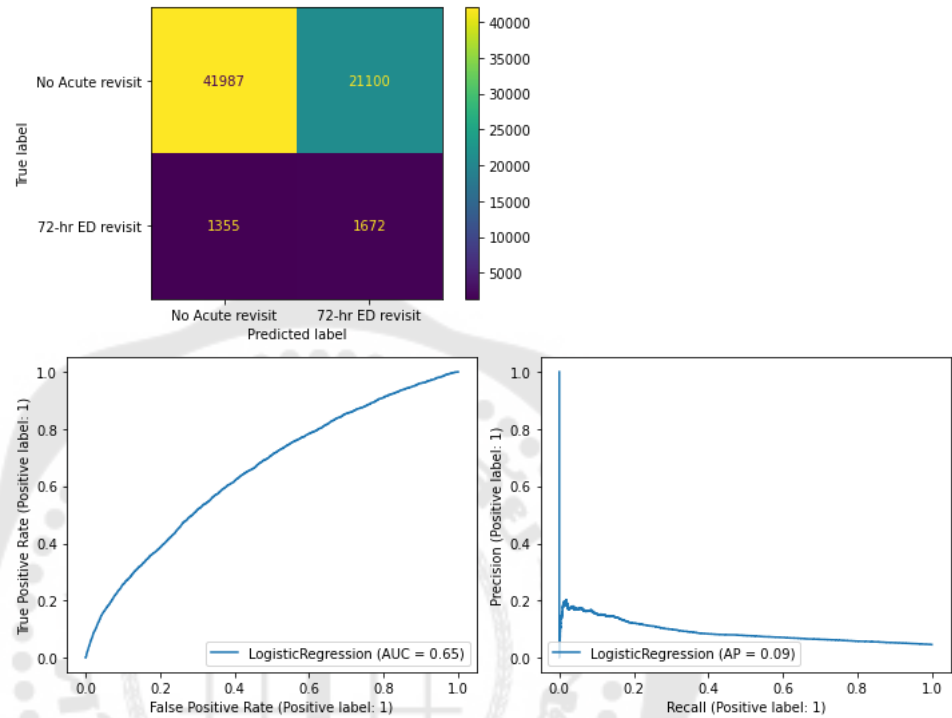
ภาพประกอบ 30 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.9

1.10. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 31 และตาราง 17



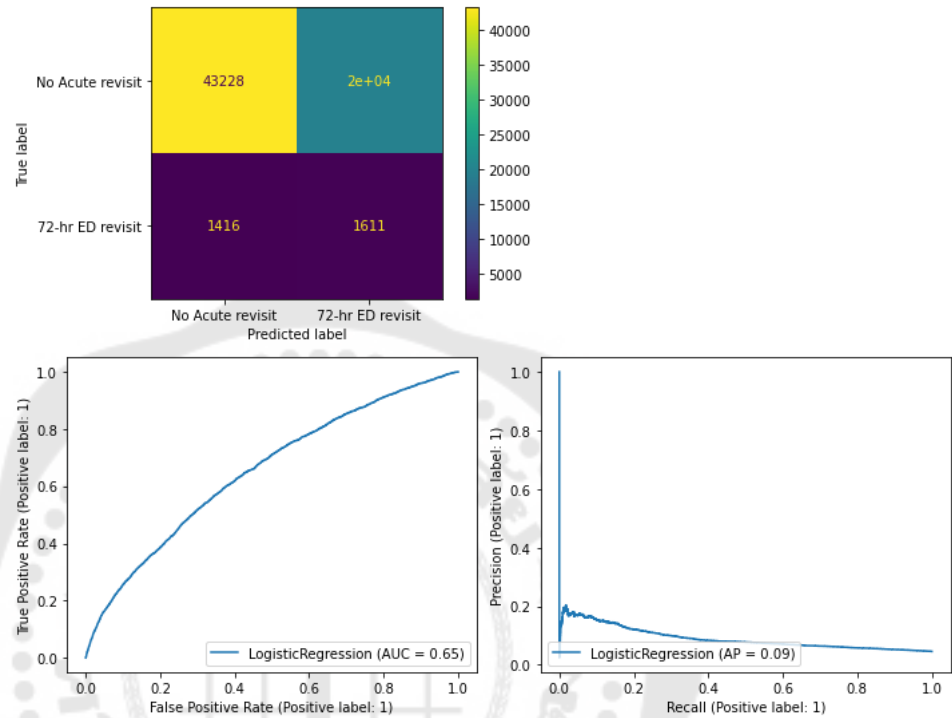
ภาพประกอบ 31 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.10

1.11. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 0.01 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 32 และตาราง 17



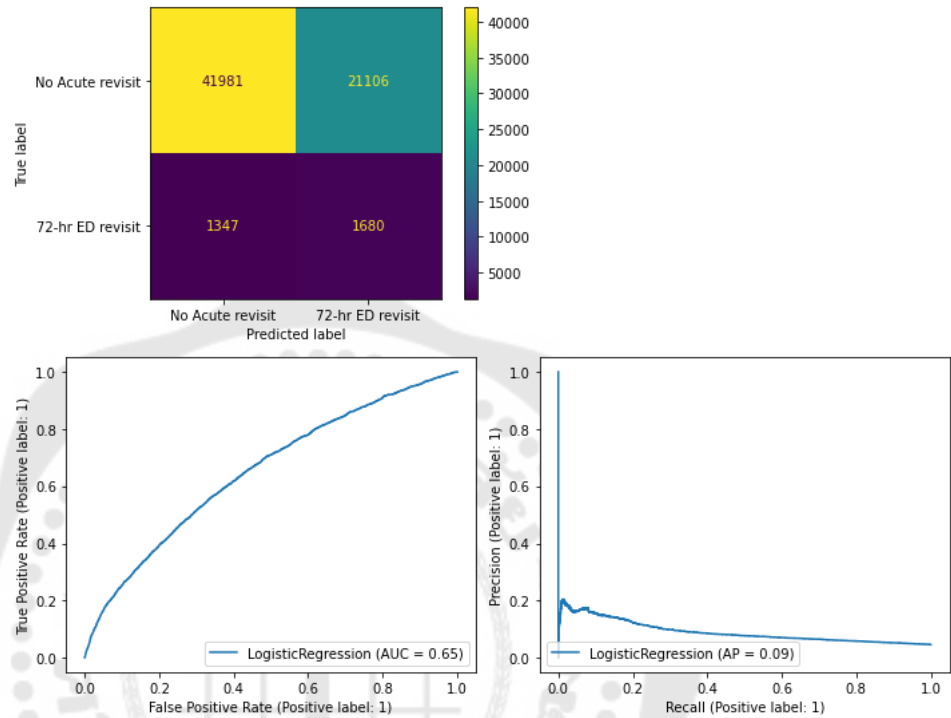
ภาพประกอบ 32 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.11

1.12. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 100 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 33 และตาราง 17



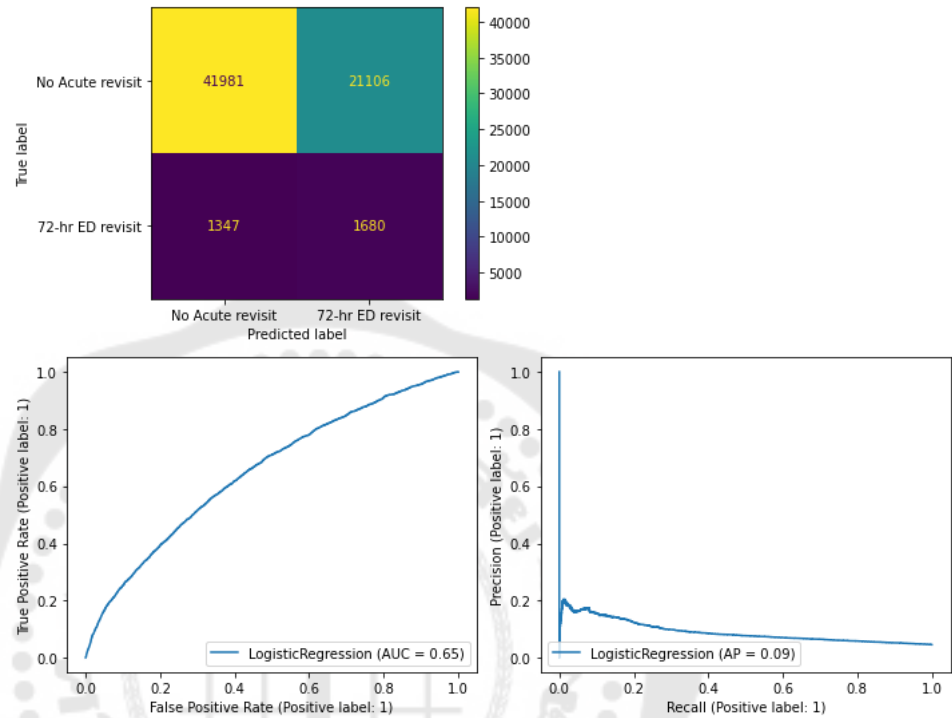
ภาพประกอบ 33 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.12

1.13. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็นค่าเริ่มต้น ($C = 1$) โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 34 และตาราง 17



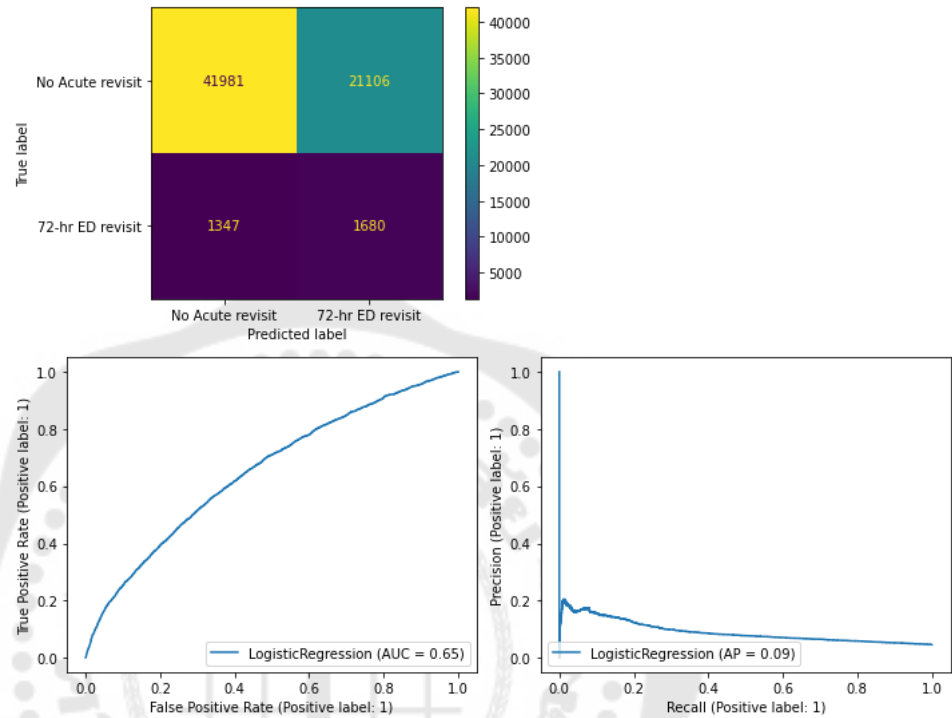
ภาพประกอบ 34 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.13

1.14. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 0.01 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดัง ภาพประกอบ 35 และตาราง 17



ภาพประกอบ 35 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.14

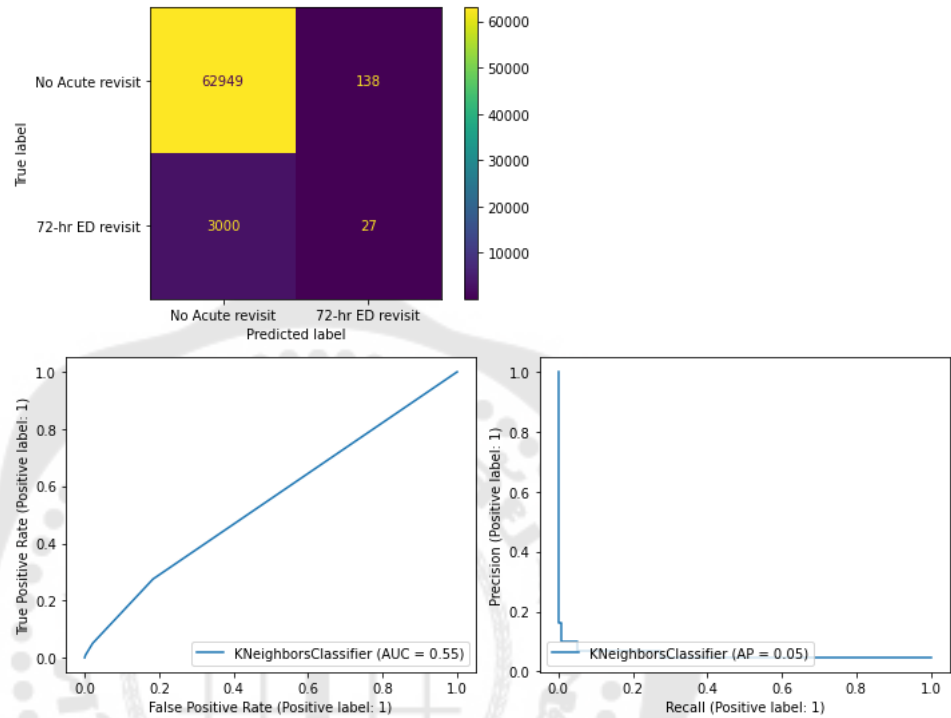
1.15. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 100 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดัง ภาพประกอบ 36 และตาราง 17



ภาพประกอบ 36 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 1.15

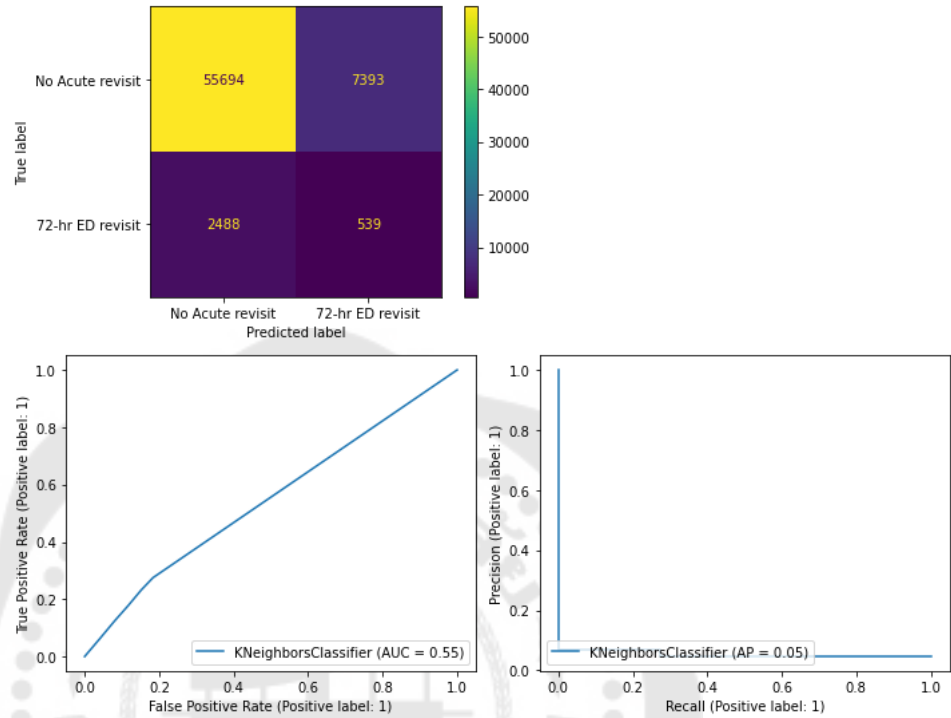
2. KNN Classification ทั้งหมด 4 แบบจำลอง

2.1. KNN Classification ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 37 และตาราง 17



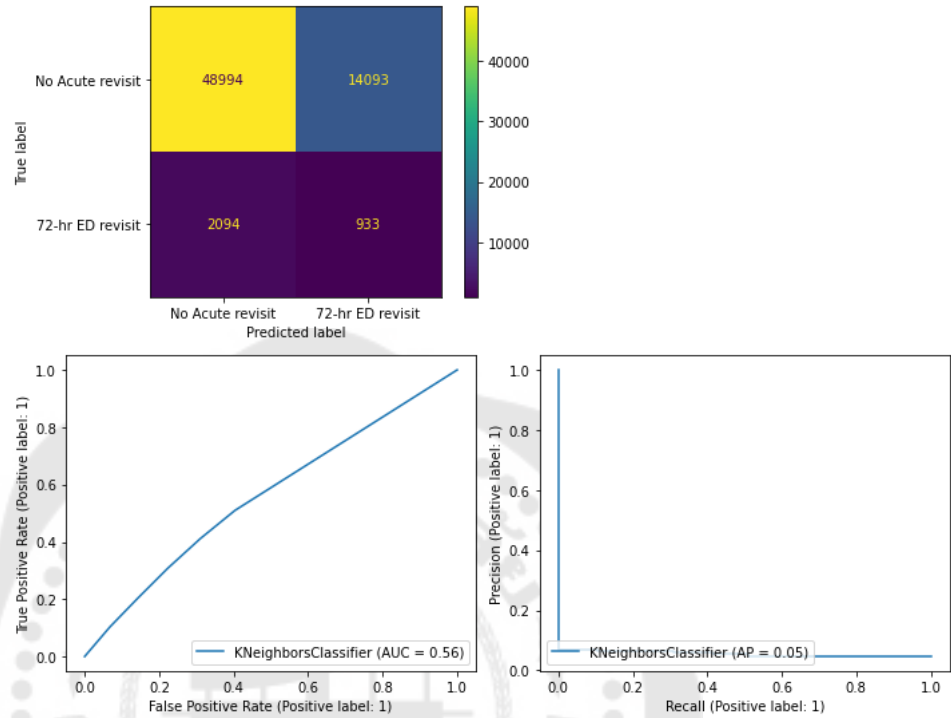
ภาพประกอบ 37 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.1

2.2. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 38 และตาราง 17



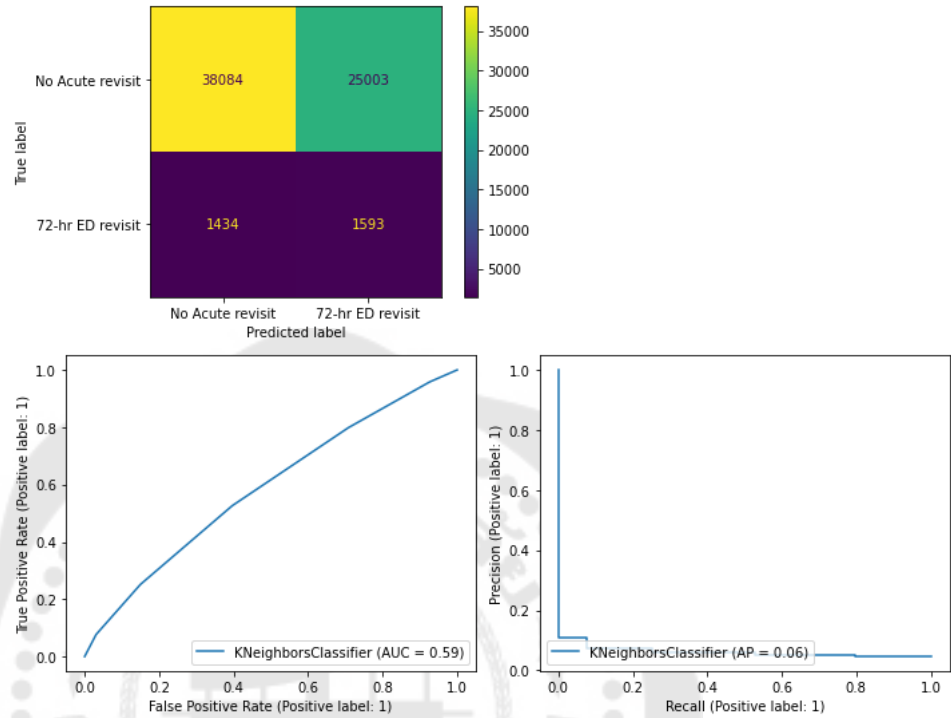
ภาพประกอบ 38 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.2

2.3. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 39 และตาราง 17



ภาพประกอบ 39 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.3

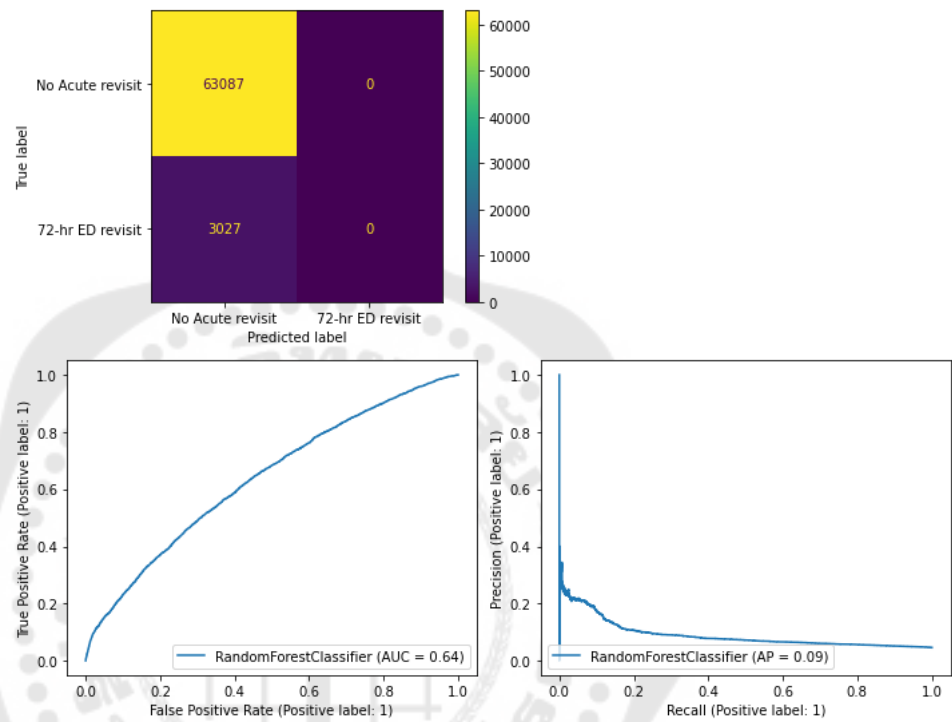
2.4. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 40 และตาราง 17



ภาพประกอบ 40 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 2.4

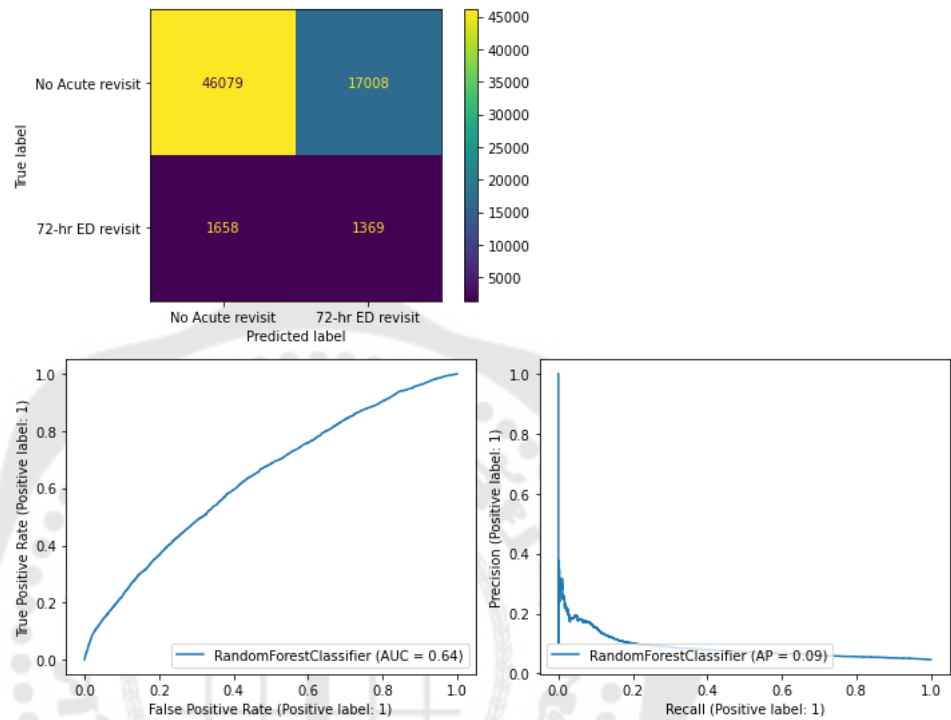
3. Random forest classifier ทั้งหมด 5 แบบจำลอง

3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด $\text{max_depth} = 2$ โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 41 และตาราง 17



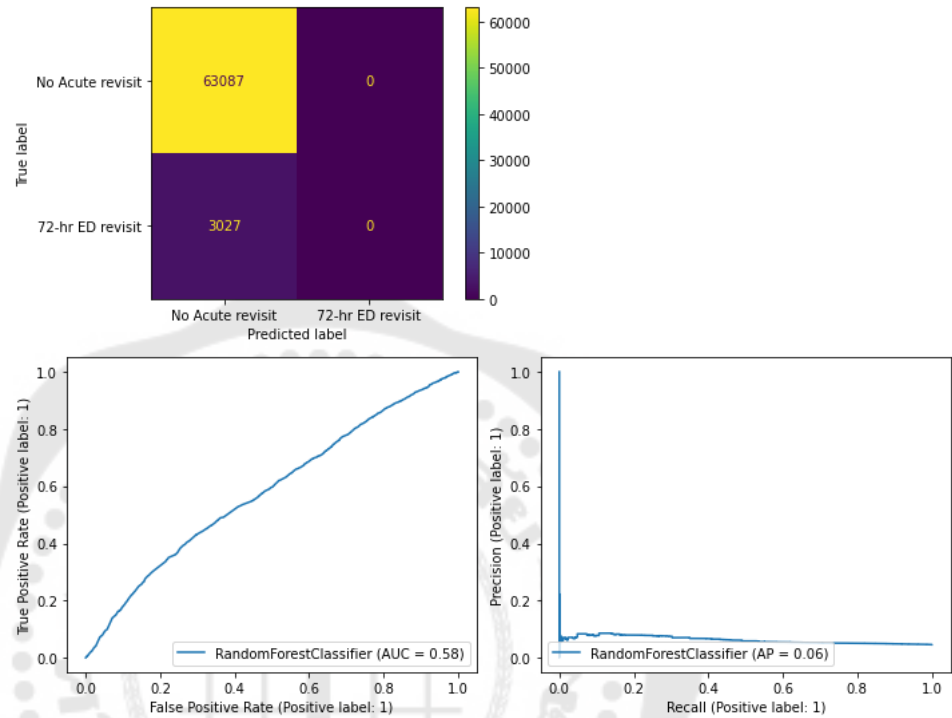
ภาพประกอบ 41 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.1

3.2. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนด $\text{max_depth} = 2$ โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 42 และตาราง 17



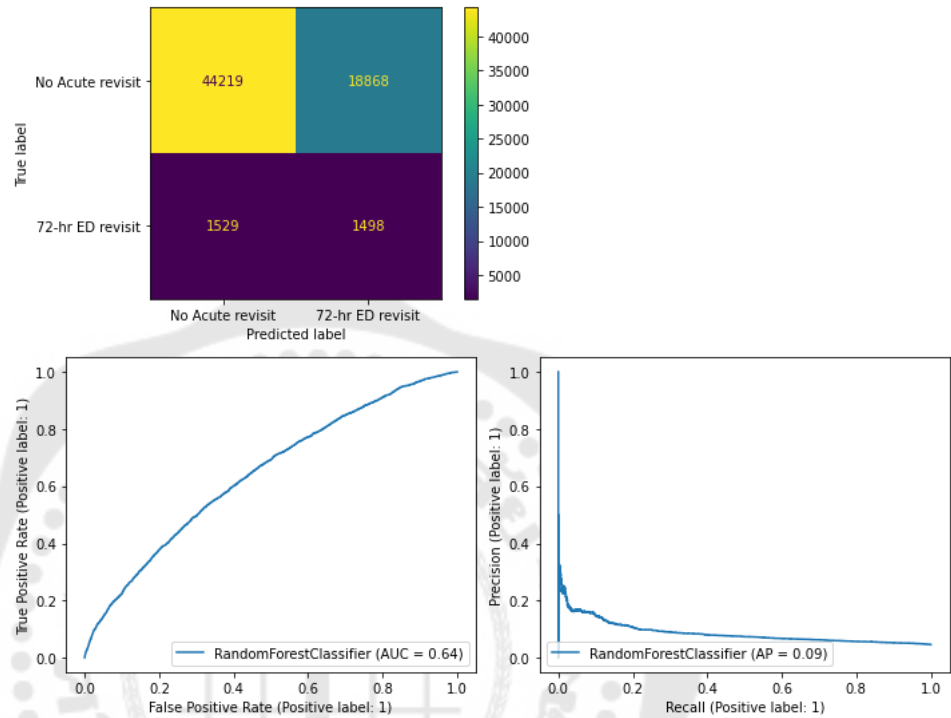
ภาพประกอบ 42 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.2

3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด $\text{max_depth} = 2$ โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 43 และตาราง 17



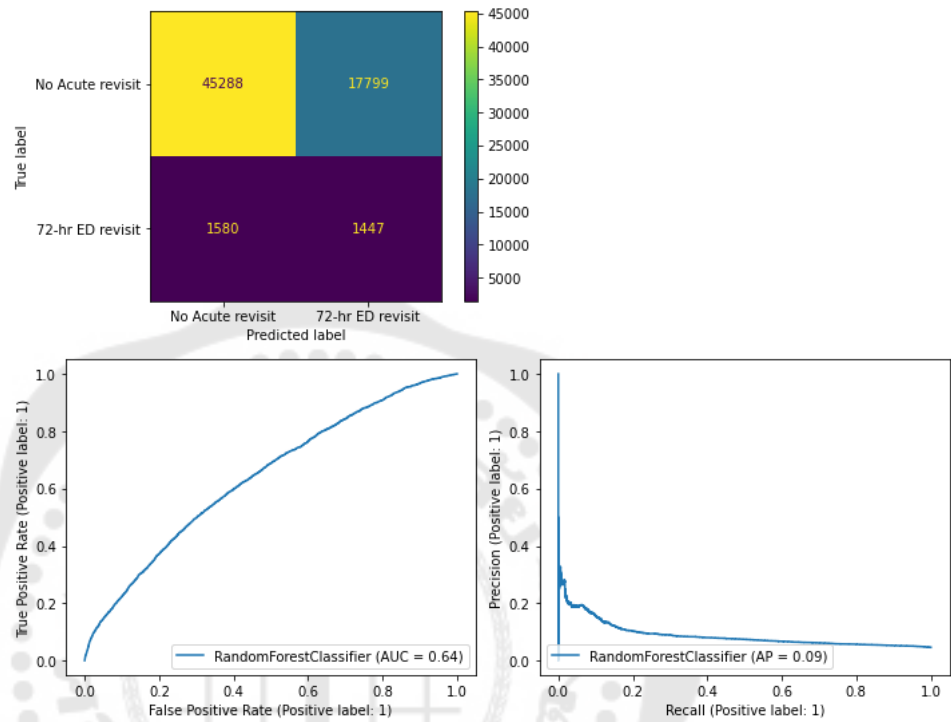
ภาพประกอบ 43 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.3

3.4. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนด $\text{max_depth} = 2$ โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 44 และตาราง 17



ภาพประกอบ 44 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.4

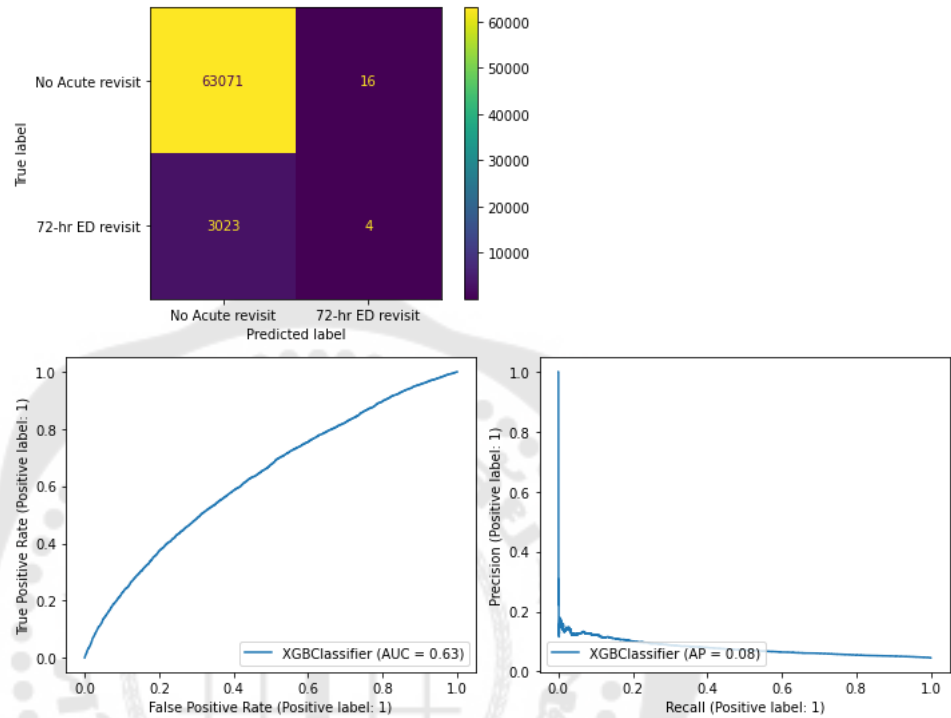
3.5. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ max_depth = 2 โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 45 และตาราง 17



ภาพประกอบ 45 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 3.5

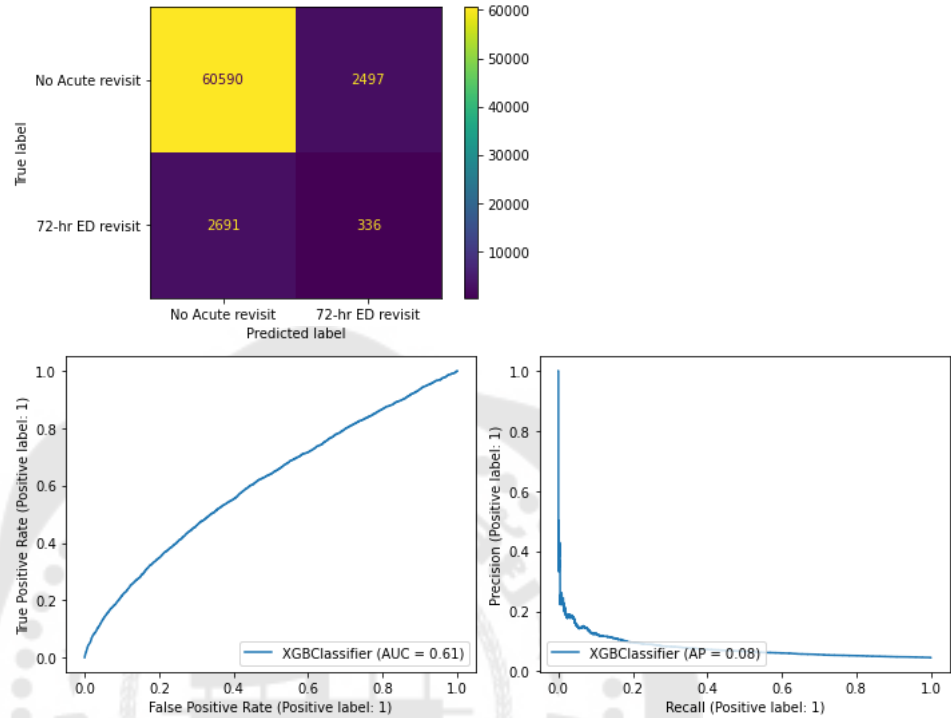
4. XGBoost classifier ทั้งหมด 5 แบบจำลอง

4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 46 และตาราง 17



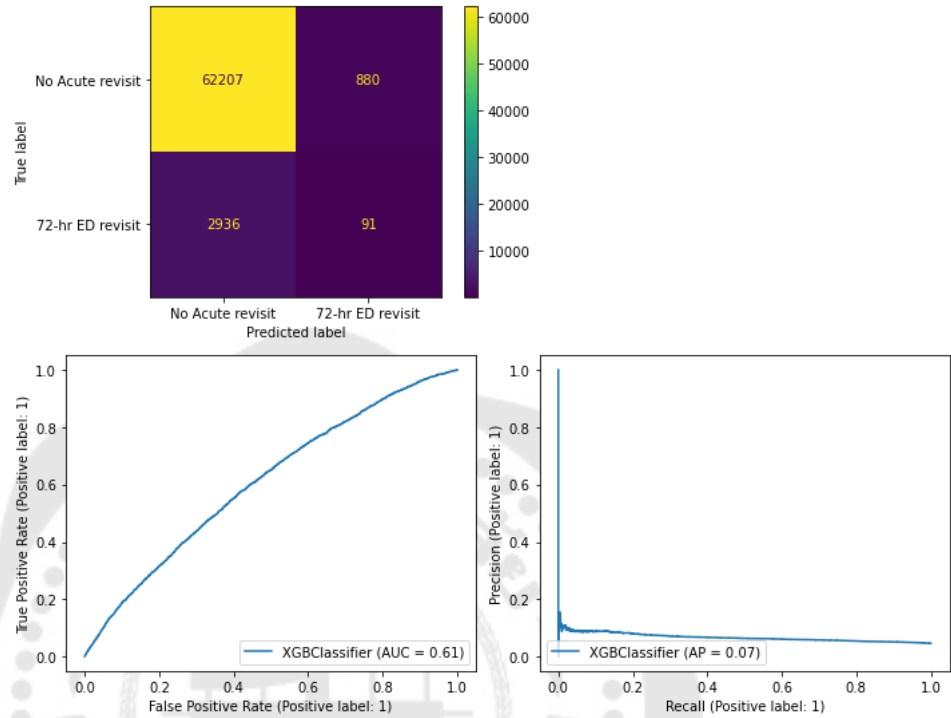
ภาพประกอบ 46 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.1

4.2. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 47 และตาราง 17



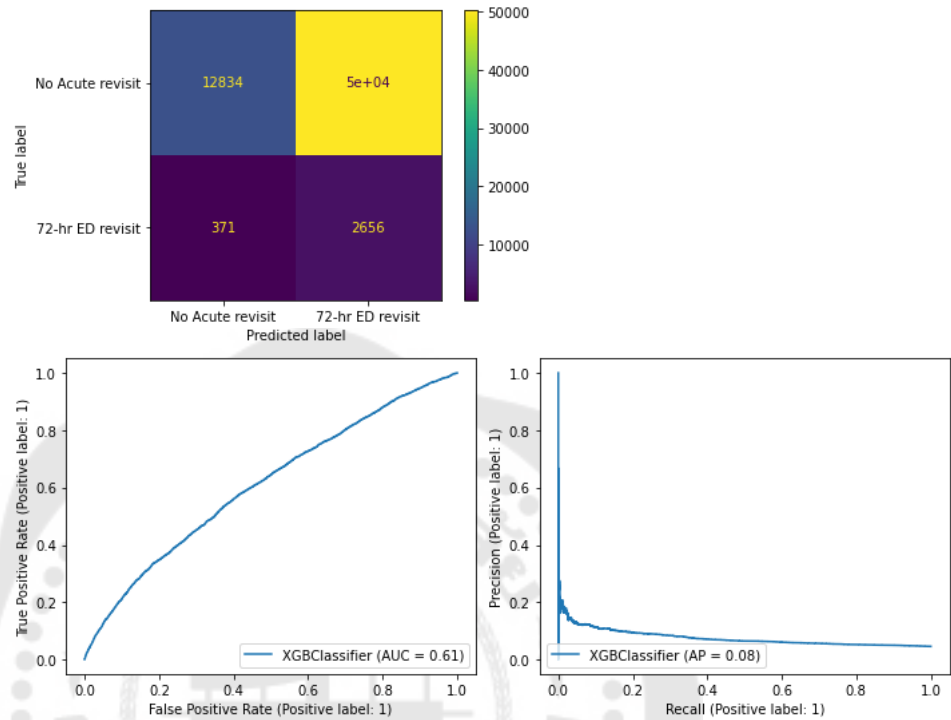
ภาพประกอบ 47 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.2

4.3. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 48 และตาราง 17



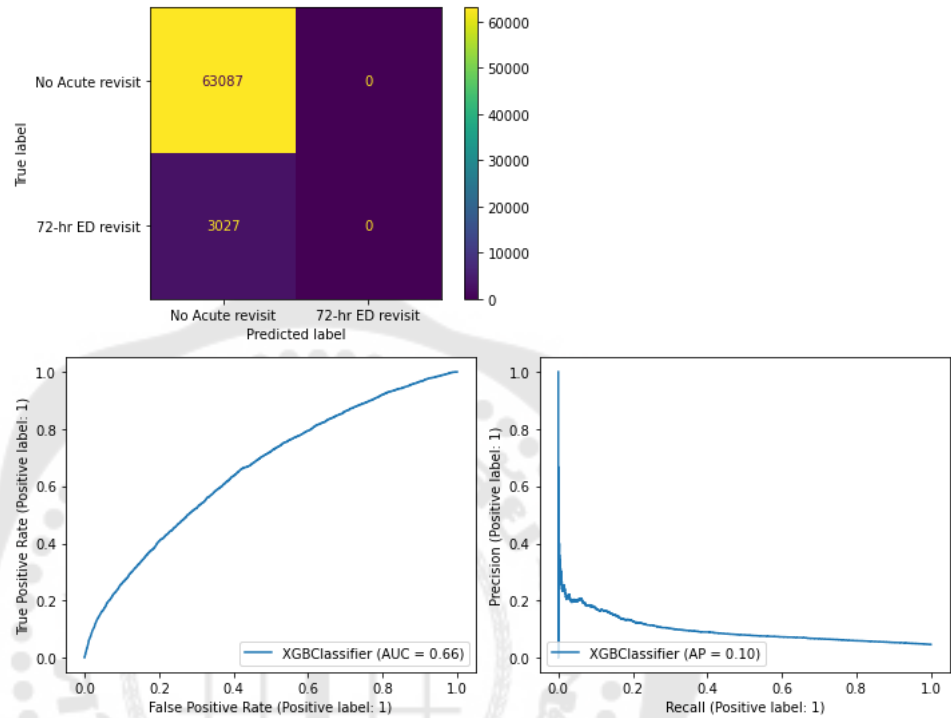
ภาพประกอบ 48 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.3

4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 49 และตาราง 17



ภาพประกอบ 49 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.4

4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด `scale_pos_weight` ให้ y สมดุล โดยแสดงผลประสิทธิภาพของแบบจำลอง ดังภาพประกอบ 50 และตาราง 17



ภาพประกอบ 50 ภาพ Confusion matrix และกราฟแสดง AUC ของแบบจำลองที่ 4.5

ตาราง 17 ผลประสิทธิภาพของแบบจำลองต่าง ๆ

แบบจำลอง	accuracy	recall score	roc_auc score
1. Logistic regression			
1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น (C = 1)	0.95	0	0.5
1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 0.01	0.95	0	0.5
1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 100	0.95	0	0.5
1.4. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็นค่าเริ่มต้น (C = 1)	0.66	0.55	0.61
1.5. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 0.01	0.66	0.55	0.61
1.6. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 100	0.66	0.55	0.61
1.7. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็นค่าเริ่มต้น (C = 1)	0.66	0.55	0.61
1.8. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 0.01	0.66	0.55	0.61
1.9. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 100	0.66	0.55	0.61

ตาราง 17 (ต่อ)

แบบจำลอง	accuracy	recall score	roc_auc score
1.10. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็นค่าเริ่มต้น (C = 1)	0.66	0.55	0.61
1.11. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 0.01	0.66	0.55	0.61
1.12. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 100	0.68	0.53	0.61
1.13. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็นค่าเริ่มต้น (C = 1)	0.66	0.56	0.61
1.14. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 0.01	0.66	0.56	0.61
1.15. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 100	0.66	0.56	0.61
2. KNN Classification			
2.1. KNN Classification ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล	0.95	0.01	0.5
2.2. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling	0.85	0.18	0.53

ตาราง 17 (ต่อ)

แบบจำลอง	accuracy	recall score	roc_auc score
2.3. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE	0.76	0.31	0.54
2.4. KNN Classification ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling	0.6	0.53	0.56
3. Random forest classifier			
3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด max_depth = 2	0.95	0	0.5
3.2. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนด max_depth = 2	0.72	0.45	0.59
3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด max_depth = 2	0.95	0	0.5
3.4. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนด max_depth = 2	0.69	0.49	0.6
3.5. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ max_depth = 2	0.71	0.48	0.6
4. XGBoost classifier			
4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล	0.95	0	0.5
4.2. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling	0.92	0.11	0.54
4.3. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE	0.94	0.03	0.51


ตาราง 17 (ต่อ)

แบบจำลอง	accuracy	recall score	roc_auc score
4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูล ด้วยวิธี Random Undersampling	0.23	0.88	0.54
4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูล ด้วยการกำหนด scale_pos_weight ให้ y สมดุล	0.95	0	0.5

ผลการแสดงค่าความสำคัญของตัวแปรแต่ละแบบจำลอง


1. Logistic regression ทั้งหมด 15 แบบจำลอง

1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 51




ภาพประกอบ 51 แสดง feature importance ของแบบจำลองที่ 1.1

1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 0.01 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 52




ภาพประกอบ 52 แสดง feature importance ของแบบจำลองที่ 1.2

1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 100 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 53




ภาพประกอบ 53 แสดง feature importance ของแบบจำลองที่ 1.3

1.4. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 54




ภาพประกอบ 54 แสดง feature importance ของแบบจำลองที่ 1.4

1.5. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 0.01 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 55




ภาพประกอบ 55 แสดง feature importance ของแบบจำลองที่ 1.5

1.6. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 100 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 56




ภาพประกอบ 56 แสดง feature importance ของแบบจำลองที่ 1.6

1.7. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 57




ภาพประกอบ 57 แสดง feature importance ของแบบจำลองที่ 1.7

1.8. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 0.01 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 58




ภาพประกอบ 58 แสดง feature importance ของแบบจำลองที่ 1.8

1.9. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 100 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 59




ภาพประกอบ 59 แสดง feature importance ของแบบจำลองที่ 1.9

1.10. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็นค่าเริ่มต้น (C = 1) แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 60




ภาพประกอบ 60 แสดง feature importance ของแบบจำลองที่ 1.10

1.11. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 0.01 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 61




ภาพประกอบ 61 แสดง feature importance ของแบบจำลองที่ 1.11

1.12. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 100 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 62




ภาพประกอบ 62 แสดง feature importance ของแบบจำลองที่ 1.12

1.13. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็นค่าเริ่มต้น (C = 1) แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 63




ภาพประกอบ 63 แสดง feature importance ของแบบจำลองที่ 1.13

1.14. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 0.01 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังกล่าวประกอบ 64



ภาพประกอบ 64 แสดง feature importance ของแบบจำลองที่ 1.14

1.15. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 100 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังกล่าวประกอบ 65

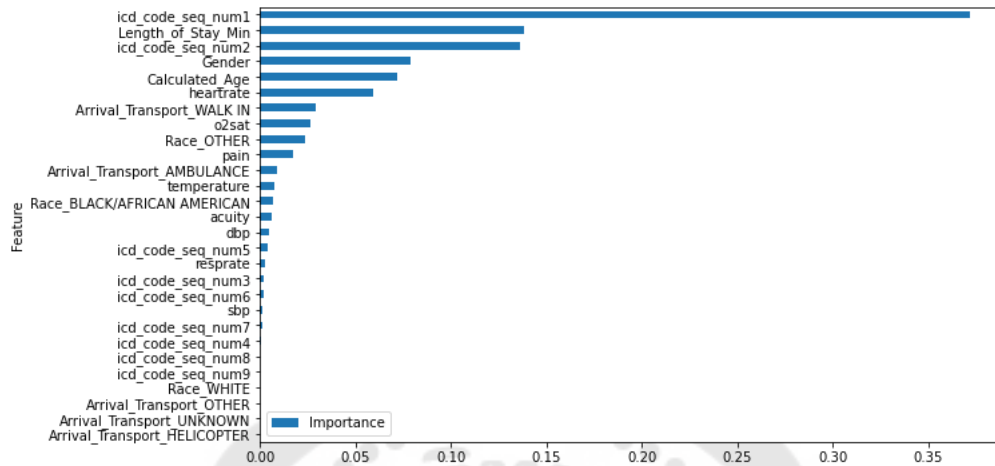


ภาพประกอบ 65 แสดง feature importance ของแบบจำลองที่ 1.15

2. KNN Classification ไม่มีพิจารณาค่าความสำคัญของตัวแปร


3. Random forest classifier ทั้งหมด 5 แบบจำลอง

3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด $\text{max_depth} = 2$ แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 66




ภาพประกอบ 66 แสดง feature importance ของแบบจำลองที่ 3.1

3.2. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนด $\text{max_depth} = 2$ แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 67




ภาพประกอบ 67 แสดง feature importance ของแบบจำลองที่ 3.2

3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด $\text{max_depth} = 2$ แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 68




ภาพประกอบ 68 แสดง feature importance ของแบบจำลองที่ 3.3

3.4. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนด max_depth = 2 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 69



ภาพประกอบ 69 แสดง feature importance ของแบบจำลองที่ 3.4


3.5. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ max_depth = 2 แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 70



ภาพประกอบ 70 แสดง feature importance ของแบบจำลองที่ 3.5


4. XGBoost classifier ทั้งหมด 5 แบบจำลอง

4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 71




ภาพประกอบ 71 แสดง feature importance ของแบบจำลองที่ 4.1

4.2. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 72




ภาพประกอบ 72 แสดง feature importance ของแบบจำลองที่ 4.2

4.3. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 73




ภาพประกอบ 73 แสดง feature importance ของแบบจำลองที่ 4.3

4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 74



ภาพประกอบ 74 แสดง feature importance ของแบบจำลองที่ 4.4

4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด scale_pos_weight ให้ y สมดุล แสดงกราฟความสำคัญของตัวแปรในแบบจำลองดังภาพประกอบ 75



ภาพประกอบ 75 แสดง feature importance ของแบบจำลองที่ 4.5

บทที่ 5

สรุปผลการศึกษา อภิปรายผล และข้อเสนอแนะ

สรุปผลการศึกษา


เมื่อพิจารณาประสิทธิภาพของแบบจำลองในการทำนายการเข้ารับบริการซ้ำภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉินในงานวิจัยนี้ด้วย ค่า Accuracy ค่า Recall และค่า AUC พบว่า

1. ค่า Accuracy

1.1. แบบจำลองที่มีค่า Accuracy สูงที่สุดคือ เท่ากับ 0.95 ได้แก่ แบบจำลองที่ 1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 100 แบบจำลองที่ 2.1. KNN Classification ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล แบบจำลองที่ 3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด $max_depth = 2$ แบบจำลองที่ 3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด $max_depth = 2$ แบบจำลองที่ 4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และแบบจำลองที่ 4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด $scale_pos_weight$ ให้ y สมดุล ดังแสดงในภาพประกอบ 76

1.2. แบบจำลองที่มีค่า Accuracy รองลงมาคือเท่ากับ 0.94 และ 0.92 ได้แก่ แบบจำลองที่ 4.3. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และแบบจำลองที่ 4.2. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling ตามลำดับ ดังแสดงในภาพประกอบ 76

1.3. แบบจำลองที่มีค่า Accuracy น้อยที่สุด เท่ากับ 0.23 คือ แบบจำลองที่ 4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling ดังแสดงในภาพประกอบ 76




ภาพประกอบ 76 แสดงการเปรียบเทียบค่า Accuracy ในแต่ละแบบจำลอง

2. ค่า Recall

2.1. แบบจำลองที่มีค่า Recall สูงที่สุด เท่ากับ 0.88 คือ แบบจำลองที่ 4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling ดังแสดงในภาพประกอบ 77

2.2. แบบจำลองที่มีค่า Recall รองลงมา มีค่าเท่ากับ 0.56 ได้แก่ แบบจำลองที่ 1.13. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.14. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 0.01 และแบบจำลองที่ 1.15. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 100 ดังแสดงในภาพประกอบ 77

2.3. แบบจำลองที่มีค่า Recall ต่ำที่สุด เท่ากับ 0 ได้แก่ แบบจำลองที่ 1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 100 แบบจำลองที่ 3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด $\text{max_depth} = 2$ แบบจำลองที่ 3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด $\text{max_depth} = 2$ แบบจำลองที่ 4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และแบบจำลองที่ 4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด scale_pos_weight ให้ y สมดุล ดังแสดงในภาพประกอบ 77



ภาพประกอบ 77 แสดงการเปรียบเทียบค่า Recall ในแต่ละแบบจำลอง


3. ค่า AUC

3.1. แบบจำลองที่มีค่า AUC สูงที่สุด เท่ากับ 0.61 ได้แก่ แบบจำลองที่ 1.4. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.5. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.6. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็น 100 แบบจำลองที่ 1.7. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.8. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.9. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนดค่า C เป็น 100 แบบจำลองที่ 1.10. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.11. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.12. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนดค่า C เป็น 100 แบบจำลองที่ 1.13. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.14. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 0.01 และแบบจำลองที่ 1.15. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ C เป็น 100

3.2. แบบจำลองที่มีค่า AUC รองลงมา เท่ากับ 0.60 ได้แก่ แบบจำลองที่ 3.4. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling และกำหนด $\text{max_depth} = 2$ และแบบจำลองที่ 3.5. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด class weight ให้ y สมดุล และ $\text{max_depth} = 2$

3.3. แบบจำลองที่มีค่า AUC น้อยที่สุด เท่ากับ 0.5 ได้แก่ แบบจำลองที่ 1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) แบบจำลองที่ 1.2. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 0.01 แบบจำลองที่ 1.3. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็น 100 แบบจำลองที่ 2.1. KNN Classification ที่ไม่มีการจัดการ

ความไม่สมดุลของข้อมูล แบบจำลองที่ 3.1. Random forest classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนด max_depth = 2 แบบจำลองที่ 3.3. Random forest classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี SMOTE และกำหนด max_depth = 2 แบบจำลองที่ 4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และแบบจำลองที่ 4.5. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยการกำหนด scale_pos_weight ให้ y สมดุล




ภาพประกอบ 78 แสดงการเปรียบเทียบค่า AUC ในแต่ละแบบจำลอง

เมื่อพิจารณาปัจจัยที่มีผลต่อการสร้างแบบจำลองในการทำนายการเข้ารับบริการซ้ำ ภายใน 72 ชั่วโมงของผู้ป่วยที่แผนกฉุกเฉิน จากแบบจำลองทั้งหมด 25 แบบจำลองที่สามารถคำนวณค่าความสำคัญสูงสุดได้ พบว่า หากพิจารณาตัวแปรที่มีความสำคัญสูงสุด 10 ลำดับ ในแต่ละแบบจำลองพบว่า การวินิจฉัยโรคลำดับที่ 1, การวินิจฉัยโรคลำดับที่ 2 และ เพศ เป็นตัวแปรที่มีความสำคัญสูงสุด 10 ลำดับ ใน 24 แบบจำลอง รองลงมาคือ อายุ และ เชื้อชาติอื่น ๆ พบว่ามี

ความสำคัญสูงสุด 10 ลำดับ ใน 23 แบบจำลอง ระดับความปวด มีความสำคัญสูงสุด 10 ลำดับ ใน 22 แบบจำลอง ระยะเวลาการอยู่ในแผนกฉุกเฉิน มีความสำคัญสูงสุด 10 ลำดับ ใน 21 แบบจำลอง และอัตราการเต้นของหัวใจ มีความสำคัญสูงสุด 10 ลำดับ ใน 20 แบบจำลอง โดยที่ตัวแปร การวินิจฉัยโรคลำดับที่ 1 มีความสำคัญสูงสุดเป็นอันดับที่ 1 ใน 20 แบบจำลอง

อภิปรายผล

เนื่องจากข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลที่มีการกลับมารับบริการซ้ำภายใน 72 ชั่วโมงที่ไม่สมดุล โดยมีข้อมูลที่มีการกลับมารับบริการซ้ำที่แผนกฉุกเฉินภายใน 72 ชั่วโมง หรือข้อมูลที่เป็น Positive เพียง 4.61% ดังนั้น จะเห็นว่าทุกแบบจำลองที่ไม่มีการจัดการความสมดุลของข้อมูล มีค่า Accuracy สูงมาก คือเท่ากับ 0.95 แต่ในขณะที่ค่า Recall ซึ่งคำนวณจาก การทำนาย True Positive มีค่าเป็น 0 นั้นหมายถึงแบบจำลองนั้นทำนายถูกเฉพาะค่า Negative ในขณะที่ค่า Positive ที่มีปริมาณน้อยนั้น ถูกทำนายเป็น Negative ทั้งหมด ดังตัวอย่างใน Confusion matrix ดังภาพประกอบ 76



ภาพประกอบ 79 ภาพตัวอย่าง Confusion Matrix ที่มีค่า Accuracy เท่ากับ 0.95 แต่ Recall เป็น 0

ดังนั้นข้อมูลที่มีความไม่สมดุลของข้อมูลทำนาย จึงไม่เหมาะสมที่จะพิจารณาประสิทธิภาพของแบบจำลองจากค่า Accuracy เพียงอย่างเดียว เพราะเมื่อพิจารณาค่า Recall แล้วมีค่าต่ำมาก เนื่องจากแบบจำลองไม่สามารถทำนายข้อมูลที่เป็น Positive ได้ถูก แต่กลับทำนายข้อมูลที่เป็น Negative ได้ถูกต้อง ดังนั้นจึงต้องมีการจัดการของความไม่สมดุลของข้อมูล โดยในการวิจัยนี้เปรียบเทียบประสิทธิภาพของแบบจำลอง จากการใช้วิธีการจัดการความไม่สมดุลของข้อมูลที่แตกต่างกัน ได้แก่ Random Oversampling, SMOTE, Random Undersampling

และใช้ความสมดุลของ Class weight ในบางแบบจำลอง ซึ่งจะเห็นว่า เมื่อมีการจัดการความไม่สมดุลของข้อมูล ในหลายแบบจำลองที่ใช้ parameter เดียวกัน พบว่ามีค่า Accuracy ลดลง และมีค่า Recall สูงขึ้น ซึ่งแสดงให้เห็นว่าแม้เป็นข้อมูลชุดเดียวกัน หากมีการทำให้ข้อมูลทำนายมีปริมาณใกล้เคียงกัน แบบจำลองที่ทำนายได้อาจจะมีประสิทธิภาพในการทำนายไม่ดีมากนัก เช่น แบบจำลองที่ 1.1. Logistic regression ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) มีค่า Accuracy เท่ากับ 0.95 และค่า Recall เท่ากับ ในขณะที่แบบจำลองที่ 1.4. Logistic regression ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Oversampling และกำหนดค่า C เป็นค่าเริ่มต้น ($C = 1$) มีค่า Accuracy เท่ากับ 0.66 และ Recall เท่ากับ 0.55 เป็นต้น ดังนั้นในการพิจารณาประสิทธิภาพของแบบจำลองชุดนี้ จึงไม่สามารถพิจารณาเฉพาะค่า Accuracy ได้ แต่ก็ไม่สามารถพิจารณาเฉพาะค่า Recall ได้เนื่องจากบางแบบจำลองอาจจะมี Recall ที่สูงมาก แต่ Accuracy อาจจะทำมาได้ด้วยเช่นกัน หมายถึงแบบจำลองสามารถทำนายกลุ่มที่ Positive ได้ดีมาก แต่ในกลุ่ม Negative ทำนายผิดเกือบทั้งหมด ยกตัวอย่างเช่น แบบจำลองที่ 4.1. XGBoost classifier ที่ไม่มีการจัดการความไม่สมดุลของข้อมูล มีค่า Recall เท่ากับ 0 และค่า Accuracy เท่ากับ 0.95 และเมื่อทำการจัดการความไม่สมดุลด้วยวิธี Random Undersampling ในแบบจำลองที่ 4.4. XGBoost classifier ที่จัดการความไม่สมดุลของข้อมูลด้วยวิธี Random Undersampling มีค่า Recall สูงถึง 0.88 แต่ค่า Accuracy มีค่าเพียง 0.23 เท่านั้น

ดังนั้นการดูประสิทธิภาพประกอบเหมาะสมกับข้อมูลชุดนี้มากที่สุด คือ การเลือกแบบจำลองโดยเลือกแบบจำลองที่มีความสมดุลของการทำนายค่า Positive ได้ถูกต้อง (True Positive) และการทำนายค่า Negative ได้ถูกต้อง (True Negative) คือการพิจารณาจาก receiver operating characteristic curve (ROC) ซึ่งเป็นกราฟที่แสดงประสิทธิภาพของการทำนายของแบบจำลองจาก decision thresholds ทั้งหมด โดยสร้างเป็นกราฟระหว่าง True Positive Rate (Recall) และ False Positive Rate (FPR) ที่แตกต่างกันของ decision thresholds และนำมาเปรียบเทียบกันด้วยค่าพื้นที่ใต้กราฟ (Area Under the curve) หรือค่า AUC (Area Under Receiver Operating Characteristic curve) โดยแบบจำลองที่ดีควรมีค่า AUC เข้าใกล้ 1 ในขณะที่ถ้าค่า AUC เท่ากับ 0.5 หมายถึงแบบจำลองนั้นทำนายได้ไม่แตกต่างจากการสุ่ม

โดยเมื่อทำการเปรียบเทียบค่า AUC จากแบบจำลองทั้งหมดที่พบว่า แบบจำลองที่ใช้วิธี Logistic Regression ที่มีการจัดการข้อมูลที่ไม่สมดุล มีค่า AUC สูงที่สุด คือเท่ากับ 0.61 เมื่อเทียบกับแบบจำลองอื่น ๆ เช่น KNN Classifier, Random Forest หรือ XGBoost ซึ่งแสดงให้เห็น

ว่า ข้อมูลบางประเภท อาจจะไม่จำเป็นต้องใช้แบบจำลองที่ซับซ้อนเพื่อสร้างแบบจำลองในการทำนาย สามารถใช้แบบจำลองที่เข้าใจง่าย ก็เพียงพอในการทำนาย โดยผลของแบบจำลองที่มีการจัดการข้อมูลที่ไม่สมดุล ในแต่ละวิธี รวมทั้งการทำ Regularization โดยการปรับค่า C พบว่าได้ค่า AUC ไม่แตกต่างกัน นั่นแสดงว่า จากแบบจำลอง Logistic regression นั้นสามารถใช้ค่า parameter ที่เป็น default และการจัดการความไม่สมดุลของข้อมูลที่ไม่ต้องซับซ้อน ก็สามารถได้ผลไม่แตกต่างกัน โดยค่า AUC ที่เท่ากับ 0.61 นั้น ถือว่ายังไม่สูงมาก แต่ก็มากกว่าการกระทำแบบสุ่ม

เมื่อเปรียบเทียบกับงานวิจัยที่ใกล้เคียงกัน พบว่างานวิจัยนี้มีค่า AUC ที่ค่อนข้างต่ำ เมื่อเปรียบเทียบกับการศึกษาของ Hsu และคณะ⁽¹⁷⁾ ซึ่งทำการศึกษาในโรงพยาบาลที่ประเทศไต้หวัน เพื่อทำนายการกลับมาเข้ารับบริการซ้ำที่แผนกฉุกเฉินโดยไม่ได้นัดหมายภายใน 72 ชั่วโมงในผู้ป่วยที่มีอาการปวดท้อง ที่ในทุกแบบจำลองให้ผลของค่า AUC มากกว่า 0.69 โดยที่ XGB และ voting classifiers มีค่า AUC ดีที่สุดคือ 0.74 อาจเกิดจากในการศึกษาของ Hsu และคณะ⁽¹⁷⁾ มีการเฉพาะเจาะจงไปผู้ป่วยที่มีอาการปวดท้อง และคัดออกผู้ป่วยที่มีการนัดหมายกลับมาซ้ำ ในขณะที่งานวิจัยนี้ไม่ได้เฉพาะเจาะจงโรคหรืออาการ ทำให้การทำนายมีประสิทธิภาพลดลง รวมทั้งในงานวิจัยนี้ไม่มีการคัดออกกลุ่มผู้ป่วยที่มีการนัดหมายกลับมาตรวจซ้ำ ซึ่งอาจทำให้แบบจำลองมีการเรียนรู้ที่คาดเคลื่อน อีกทั้งยังมีข้อมูลมาจากหลายแหล่งแม้จะเป็นข้อมูลพื้นฐานข้อมูลเดียวกันทำให้ได้ข้อมูลที่ไม่ได้มีการเก็บเป็นมาตรฐานเดียวกัน ในขณะที่การศึกษาของ Gao และคณะ⁽¹⁸⁾ ที่ทำการศึกษาในโรงพยาบาลกิจการทหารผ่านศึก เพื่อการทำนายการกลับมาที่แผนกฉุกเฉินซ้ำใน 30 วัน ซึ่งใช้แบบจำลอง Logistic regression พบว่าหากสร้างแบบจำลองที่ใช้ข้อมูลเฉพาะ ข้อมูลทั่วไปของผู้ป่วย และสถานะทางเศรษฐกิจและสังคม แบบจำลองในงานวิจัยของผู้วิจัยมีค่าสูงกว่า เนื่องจากในงานวิจัยนี้มีค่า C-statistic (เปรียบเทียบกับได้กับค่า AUC) เท่ากับ 0.556 แต่เมื่อการการเพิ่มปัจจัยอื่น ๆ ได้แก่ ค่าใช้จ่ายจากการเข้าพักในโรงพยาบาลในปีก่อนหน้า โรคประจำตัว พบว่าค่า C-statistic ค่อนข้างสูง คือ 0.763 นั่นอาจจะช่วยบ่งว่า หากงานวิจัยนี้มีการเพิ่มข้อมูลเช่น ข้อมูลโรคประจำตัว หรือการรักษาในปีที่ผ่านมา อาจจะช่วยเพิ่มประสิทธิภาพของแบบจำลองสำหรับงานวิจัยนี้ได้ แต่ทั้งนี้งานวิจัยของ Gao และคณะ เป็นการทำนายการกลับมาซ้ำใน 30 วัน ซึ่งแตกต่างจากงานวิจัยนี้ของผู้วิจัย การที่ระยะเวลาการใช้พิจารณาการกลับมาที่แผนกฉุกเฉินซ้ำนานขึ้น ส่งผลให้โอกาสที่มีข้อมูลที่เป็น Positive สูงขึ้นด้วย ในขณะที่การศึกษาของ Lin และคณะ⁽¹⁹⁾ ที่เป็นการศึกษาในแผนกฉุกเฉินของผู้ป่วยที่มีการกลับมาเข้ารับบริการซ้ำภายใน 72 ชั่วโมงด้วยอาการปวดท้อง โดยการเปรียบเทียบระหว่างผู้ป่วย

ที่มีการกลับมารับบริการซ้ำที่ได้รับการรักษาในโรงพยาบาล (Admission) และผู้ป่วยที่ไม่ได้รับการรักษาในโรงพยาบาล (Non-admission) โดยใช้ Logistic regression เช่นกัน พบว่าในงานวิจัยนี้มีค่า AUC เท่ากับ 0.716 โดยใช้ข้อมูล การคัดกรองความเร่งด่วน การให้ยาแก้ปวดหลายตัว อายุ และการได้รับการตรวจทางห้องปฏิบัติการ มาใช้ในการสร้างแบบจำลอง ซึ่งในงานวิจัยของผู้วิจัยไม่มีข้อมูลการให้ยาแก้ปวด และประวัติการตรวจทางห้องปฏิบัติการมาใช้ในการสร้างแบบจำลอง ซึ่งประวัติการตรวจทางห้องปฏิบัติการอาจจะเป็นข้อมูลที่สำคัญที่ใช้ในการทำนาย ซึ่งหากพิจารณาจาก Feature importance ในงานวิจัยนี้ การวินิจฉัยเป็นปัจจัยที่มีความสูงสุดที่มีผลต่อการสร้างแบบจำลองในการทำนาย ทั้งนี้ในการศึกษา Lin และคณะ มีการศึกษาโดยจุดประสงค์ของการทำนายที่แตกต่างกัน เนื่องจากศึกษาในเปรียบเทียบระหว่างกลุ่มที่ได้รับการรักษาในโรงพยาบาล และกลุ่มที่ไม่ได้รับการรักษาในโรงพยาบาล โดยกลับมารับบริการซ้ำภายใน 72 ชั่วโมงทั้งคู่ ทั้งนี้ข้อมูลที่นำมาใช้ในการวิจัยนี้เป็นข้อมูลที่เก็บมาหลายแหล่ง และข้อมูลไม่ได้ถูกออกแบบมาให้เก็บเป็นมาตรฐาน จึงมีโอกาสที่ข้อมูลมีการรบกวนค่อนข้างสูง การใช้แบบจำลองที่ง่ายทำให้ได้ประสิทธิภาพประกอบค่อนข้างดี ในขณะที่แบบจำลองที่ค่อนข้างซับซ้อนไม่ได้ทำให้ประสิทธิภาพการทำนายดีขึ้นมากนัก เนื่องจากข้อมูลค่อนข้างถูกรบกวนมาก

เมื่อพิจารณาเปรียบเทียบกับการศึกษาอื่น ที่ทำในลักษณะใกล้เคียงกัน งานวิจัยนี้อาจจะมีประสิทธิภาพของแบบจำลองที่ยังไม่สูงมากนัก โดยที่หากสามารถสร้างแบบจำลองที่มีค่า AUC ตั้งแต่ 0.7 ขึ้นไป จึงจะทำให้แบบจำลองนั้นได้รับการยอมรับที่มากขึ้น

ข้อเสนอแนะ

สำหรับการทำวิจัยในอนาคต เพื่อให้มีโอกาสที่ประสิทธิภาพของแบบจำลองจะมีค่าสูงขึ้น การปรับปรุงวิธีการสร้างแบบจำลองที่สามารถดำเนินการเพิ่มเติม และอาจจะส่งผลกระทบต่อประสิทธิภาพของแบบจำลอง คือ

1. การนำไปประยุกต์ใช้ต่อกับข้อมูลสุขภาพของประเทศไทย โปรแกรมสารสนเทศของโรงพยาบาล ควรนำมาตรฐานของข้อมูลสุขภาพเข้ามาใช้เพื่อให้การจัดเก็บข้อมูลทางสุขภาพเป็นมาตรฐาน และสามารถส่งต่อข้อมูลระหว่างอุปกรณ์ หรือระหว่างโรงพยาบาล ในมาตรฐานเดียวกัน เช่น HL7 (FHIR), DICOM (x-ray), LOINC (Lab) และเลือกใช้ Terminology เช่น SNOMED-CT ที่เริ่มใช้งานมากขึ้นทำให้ลดเรื่องการใช้ Free text ซึ่งค่อนข้างเป็นปัญหามากในการนำข้อมูลมาใช้ต่อ

2. หากมีการพัฒนาแบบจำลองที่สามารถนำไปใช้ต่อได้แล้วนั้น ควรจะมีการฝึกฝนแบบจำลองด้วยข้อมูลใหม่ที่อัปเดตอยู่เสมอ เพราะข้อมูลทางสุขภาพมีโอกาที่จะมีการอัปเดตและมีข้อมูลใหม่ ๆ เกิดขึ้นอยู่เสมอ เพื่อให้แบบจำลองสามารถนำไปประยุกต์ใช้กับข้อมูลที่ไม่เคยฝึกฝนมาก่อน

3. การฝึกฝนแบบจำลองด้วยการทำงานของ K-fold Cross Validation ซึ่งเป็นการฝึกแบบจำลองให้ได้เจอปริมาณข้อมูลที่มากขึ้น โดยนำข้อมูลฝึก มาแบ่งและนำมาทดสอบเพื่อให้มีการเรียนรู้และได้แบบจำลองที่มีประสิทธิภาพดีที่สุด

4. การฝึกฝนแบบจำลองด้วยการหาค่า Parameter ของแต่ละแบบจำลองที่มีประโยชน์ในการทำนายแบบที่ให้ประสิทธิภาพดีที่สุด ด้วยการทำ Grid Search Cross Validation หรือ Random Search Cross Validation ซึ่งจะช่วยหาค่า Parameter ที่ดีที่สุดของแต่ละแบบจำลอง

5. การเพิ่มปัจจัยหรือตัวแปร ที่นำมาใช้ในแบบจำลอง โดยในงานวิจัยนี้ไม่ได้นำข้อมูลที่มีอยู่ได้แก่ ประวัติยาเดิมของผู้ป่วย และประวัติยาที่ผู้ป่วยได้รับ มาใช้ในการทำนาย รวมถึงข้อมูลผลการตรวจสัญญาณชีพ ที่ในงานวิจัยนี้รวมผลการตรวจสัญญาณชีพทั้งหมด หากใช้จำนวนครั้งในการตรวจสัญญาณชีพ หรือความถี่ รวมทั้งหาข้อมูลอื่น ๆ เพิ่มเติม เช่น ประวัติการรักษาที่แผนกฉุกเฉินครั้งก่อน ประวัติโรคประจำตัว ประวัติการรักษาพยาบาลในช่วงที่ผ่านมา อาจจะช่วยเพิ่มประสิทธิภาพในการสร้างแบบจำลองได้

บรรณานุกรม

1. Pines JM. The Central Importance of Emergency Department Admission Rate Variation in Value-Based Care. *Ann Emerg Med.* 2021;78(4):484-6.
2. Smulowitz PB, O'Malley AJ, McWilliams JM, Zaborski L, Landon BE. Variation in Rates of Hospital Admission from the Emergency Department Among Medicare Patients at the Regional, Hospital, and Physician Levels. *Annals of Emergency Medicine.* 2021;78(4):474-83.
3. Benbassat J, Taragin M. Hospital readmissions as a measure of quality of health care: advantages and limitations. *Arch Intern Med.* 2000;160(8):1074-81.
4. Abualenain J, Frohna WJ, Smith M, Pipkin M, Webb C, Milzman D, Pines JM. The prevalence of quality issues and adverse outcomes among 72-hour return admissions in the emergency department. *J Emerg Med.* 2013;45(2):281-8.
5. Frankl SE, Breeling JL, Goldman L. Preventability of emergent hospital readmission. *Am J Med.* 1991;90(6):667-74.
6. Hayward J, Hagtvedt R, Ma W, Gauri A, Vester M, Holroyd BR. Predictors of Admission in Adult Unscheduled Return Visits to the Emergency Department. *West J Emerg Med.* 2018;19(6):912-8.
7. Jiménez-Puente A, Del Río-Mata J, Arjona-Huertas JL, Mora-Ordóñez B, Nieto-de Haro L, Lara-Blanquer A, et al. Causes of 72-hour return visits to hospital emergency departments. *Emergencias.* 2015;27(5):287-93.
8. Liaw SJ, Bullard MJ, Hu PM, Chen JC, Liao HC. Rates and causes of emergency department revisits within 72 hours. *J Formos Med Assoc.* 1999;98(6):422-5.
9. Wu CL, Wang FT, Chiang YC, Chiu YF, Lin TG, Fu LF, Tsai TL. Unplanned emergency department revisits within 72 hours to a secondary teaching referral hospital in Taiwan. *J Emerg Med.* 2010;38(4):512-7.
10. Alpaydin E. *Introduction to Machine Learning*: The MIT Press; 2010.
11. Müller AC, Guido S. *Introduction to machine learning with Python : a guide for data scientists.* 2017.

12. Breiman L. Random Forests. *Machine Learning*. 2001;45(1):5-32.
13. Schonlau M, Zou RY. The random forest algorithm for statistical learning. *The Stata Journal*. 2020;20(1):3-29.
14. Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*; San Francisco, California, USA: Association for Computing Machinery; 2016. p. 785–94.
15. Schonlau M. Boosted regression (boosting): An introductory tutorial and a Stata plugin. *Stata Journal*. 2005;5(3):330-54.
16. Natekin A, Knoll A. Gradient Boosting Machines, A Tutorial. *Frontiers in neurorobotics*. 2013;7:21.
17. Hsu CC, Chu CJ, Lin CH, Huang CH, Ng CJ, Lin GY, et al. A Machine Learning Model for Predicting Unscheduled 72 h Return Visits to the Emergency Department by Patients with Abdominal Pain. *Diagnostics (Basel)*. 2021;12(1).
18. Gao K, Pellerin G, Kaminsky L. Predicting 30-day emergency department revisits. *Am J Manag Care*. 2018;24(11):e358-e64.
19. Lin LT, Lin SF, Chao CC, Lin HA. Predictors of 72-h unscheduled return visits with admission in patients presenting to the emergency department with abdominal pain. *Eur J Med Res*. 2023;28(1):288.
20. Johnson A, Bulgarelli L, Pollard T, Celi LA, Mark R, Steven H. MIMIC-IV-ED (version 2.2). *PhysioNet*. 2023.
21. Goldberger A, Amaral L, Glass L, Hausdorff J, Ivanov P, Mark R, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation [Online]*. 2000;101(23):e215–e20.

ประวัติผู้เขียน

ชื่อ-สกุล

นพ.พิชญ์พงศ์ พูลผล

วุฒิการศึกษา

พ.ศ. 2556 แพทยศาสตรบัณฑิต (เกียรตินิยมอันดับ 2)

คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

พ.ศ. 2562 วิทยาศาสตรมหาบัณฑิต สาขาการวิจัยและการจัดการสุขภาพ คณะ

แพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

พ.ศ. 2562 วุฒิบัตรแสดงความรู้ความชำนาญในการประกอบ

วิชาชีพเวชกรรม สาขาเวชศาสตร์ป้องกัน แขนงเวชศาสตร์ทางทะเล

ผลงานตีพิมพ์

1. Poolpol P, Sithisarakul P, Rattananupong T, Lung function change in hyperbaric chamber inside attendants. Int Marit Health. 2019;70(2):125-131. doi: 10.5603/IMH.2019.0020.
2. Poolpol P, Sithisarakul P, Effect of Hyperbaric Environment on Pulmonary Function in Professional Divers , Royal Thai Navy Medical Journal: Vol 45 No 3 (2018): September-December 2018.