

ปัญญาประดิษฐ์เพื่อการแปรผลการตรวจวิเคราะห์ก๊าซในหลอดเลือดแดง
สำหรับการควบคุมและปฏิบัติการเครื่องหัวใจและปอดเทียม

AI OF ARTERIAL BLOOD GAS ANALYSIS FOR CARDIOPULMONARY
BYPASS MANAGEMENT



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2567

KMITL-2024-SC-M-017-035

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

AI OF ARTERIAL BLOOD GAS ANALYSIS FOR CARDIOPULMONARY
BYPASS MANAGEMENT



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF
THE REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE
IN DATA SCIENCE AND ANALYTICS
KMITL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2024

KMITL-2024-SC-M-017-035

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2024

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	ปัญญาประดิษฐ์เพื่อการแปรผลการตรวจวิเคราะห์ก๊าซในเลือด เลือดแดงสำหรับการควบคุมและปฏิบัติการเครื่องหัวใจและ ปอดเทียม
ชื่อนักศึกษา	นางสาวเกตุศิริ ทิพย์คำ
รหัสประจำตัว	64605016
หลักสูตร	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์) ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
พ.ศ.	2567
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	รองศาสตราจารย์ ดร.ละออ บุญเกษม

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการใช้การเรียนรู้ของเครื่องเพื่อแปรผลค่าก๊าซในเลือดแดง ซึ่งโมเดลการเรียนรู้ของเครื่องที่นำมาศึกษาในงานวิจัยนี้คือ K-nearest neighbor (KNN), Random forest, XGBoost และ Deep learning แล้วเปรียบเทียบประสิทธิภาพของแต่ละโมเดลการเรียนรู้ เพื่อหาโมเดลที่มีค่าความแม่นยำ (Accuracy) สูงที่สุด โดยเก็บรวบรวมข้อมูลจากผลค่าก๊าซในเลือดในระหว่างการผ่าตัดหัวใจแบบเปิดและมีการใช้เครื่องหัวใจและปอดเทียมร่วมด้วย จำนวน 200 ตัวอย่าง นำมาดำเนินการบนโปรแกรม Rapidminer studio โดยเริ่มจากการเตรียมข้อมูลเพื่อการประมวลผล แก้ไขข้อมูลที่ไม่สมดุล หลังจากนั้นแบ่งข้อมูลสำหรับฝึกและทดสอบ (Training data and testing data) ในอัตราส่วน 70% และข้อมูลสำหรับการตรวจสอบ (Validation set) ในอัตราส่วน 30% แล้วนำข้อมูลชุดฝึกให้โมเดลเรียนรู้เพื่อสร้างโมเดล และวัดประสิทธิภาพของโมเดลด้วยค่าความแม่นยำ (Accuracy) และ ค่าความผิดพลาดสัมบูรณ์ (Absolute error) ผลการทดลองพบว่าโมเดลการเรียนรู้ที่มีประสิทธิภาพสูงที่สุดสำหรับข้อมูลชุดนี้คือ Random forest ซึ่งมีค่า ค่าความแม่นยำ (Accuracy) เท่ากับ 98.82% และค่าความผิดพลาดสัมบูรณ์ (Absolute error) เท่ากับ 0.106 +/- 0.116

คำสำคัญ : การเรียนรู้ของเครื่อง เครื่องหัวใจและปอดเทียม ผ่าตัดหัวใจแบบเปิด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Independent Study Title	AI Of Arterial Blood Gas Analysis For Cardiopulmonary Bypass Management
Student name	Kethsiri Tipcome
Student ID	64605016
Degree	Master of Science (Data Science and Analytics) KMITL Digital Analytics and Intelligence Center
Year	2024
Independent Study Advisor	Assoc.Prof. Dr. Laor Boongasame

Abstract

The aim of this study to explore the application of machine learning techniques for interpret arterial blood gas data. Employing various models such as K-nearest neighbor (KNN), Random Forest, XGBoost and Deep Learning and conducted a comparative analysis of their performances. The objective was to identify the model demonstrating the highest accuracy by gathering data from arterial blood gas during open heart surgery with cardiopulmonary bypass technique . A total of 200 samples were collected and processed through the RapidMiner Studio.

The initial steps involved data preparation, addressing data imbalances, and subsequent division into a 70% training set and a 30% validation set. The training set was then employed to facilitate model learning and construction. The model's performance was evaluated based on accuracy and absolute error values.

Upon conducting the experiment, the results revealed that the Deep Learning model exhibited the highest performance for this dataset. The accuracy of the Random Forest model was determined to be 98.82%, with an absolute error of 0.106 +/- 0.116

Keyword : Machine learning, Cardiopulmonary bypass, Open heart surgery, Arterial blood gas

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

งานวิจัยเรื่อง ปัญญาประดิษฐ์เพื่อการแปรผลการตรวจวิเคราะห์ก๊าซในหลอดเลือดแดงจากการควบคุมและปฏิบัติการเครื่องหัวใจและปอดเทียม สามารถดำเนินการจนสำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความอนุเคราะห์อย่างยิ่งจากรองศาสตราจารย์ ดร.ละออ บุญเกษม อาจารย์ที่ปรึกษาการค้นคว้าอิสระ ที่กรุณาเสียสละเวลาให้คำปรึกษา และให้ความรู้แนวคิดในการทำงานวิจัยและชี้ให้เห็นข้อบกพร่อง พร้อมแนวทางแก้ไขจนกระทั่งงานวิจัยครั้งนี้สำเร็จไปได้ด้วยดี

ขอขอบพระคุณอาจารย์นายแพทย์สุสันต์ กนกศิลป์ ศัลยแพทย์ผู้เชี่ยวชาญด้านศัลยกรรมหัวใจ หลอดเลือดและทรวงอก และหัวหน้างานศัลยกรรมหัวใจและทรวงอก ซึ่งเป็นผู้ทรงคุณวุฒิและผู้เชี่ยวชาญที่ให้ความอนุเคราะห์ให้คำแนะนำตอบคำถามและอธิบายข้อมูลเฉพาะทางเกี่ยวกับการผ่าตัดหัวใจ

ขอขอบคุณสำนักงานมาตรฐานและจริยธรรมการวิจัย ศูนย์การเรียนรู้และวิจัยเฉลิมพระเกียรติ 60 ปี เจ้าฟ้าจุฬาภรณที่ให้คำแนะนำและเสนอแนะในการเก็บข้อมูล และอนุมัติโครงการเพื่อทำการวิจัยในมนุษย์สำหรับงานวิจัยครั้งนี้

ขอขอบพระคุณเพื่อนนักศึกษาร่วมชั้นปีหลักสูตรวิทยาศาสตรมหาบัณฑิต วิทยาการข้อมูล และการวิเคราะห์ทุกท่านที่ให้คำแนะนำต่างๆที่เกี่ยวข้องกับงานวิจัยครั้งนี้

ขอขอบคุณครอบครัวที่ให้ความสนใจและคำแนะนำในการทำวิจัยครั้งนี้ อนึ่ง ผู้วิจัยหวังว่างานวิจัยทางด้านวิทยาการข้อมูลนี้จะมีประโยชน์อยู่ไม่น้อย ทั้งกับด้านการบริการทางการแพทย์และการนำวิทยาการข้อมูลมาใช้ในการวิจัยทางการแพทย์ สำหรับข้อบกพร่องต่าง ๆ ที่อาจจะเกิดขึ้นนั้น ผู้ศึกษาขออนุมัติรับและยินดีรับคำแนะนำเพื่อจะเป็นประโยชน์ในการพัฒนาการทำงานวิจัยอื่นๆในอนาคตต่อไป

เกตุศิริ ทิพย์คำ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญรูป	ช
คำย่อ/สัญลักษณ์	ณ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย	3
1.3 ขอบเขตของการวิจัย	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ	3
1.5 ข้อจำกัดในการวิจัย	3
บทที่ 2 แนวคิดทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 การทำงานของเครื่องหัวใจและปอดเทียมและระบบไหลเวียนนอกร่างกาย (Cardiopulmonary Bypass: CPB)	4
2.1.1 ส่วนประกอบของวงจรหัวใจและปอดเทียม	5
2.1.2 การจัดการระบบหัวใจและปอดเทียม	13
2.1.3 ภาวะแทรกซ้อนที่อาจเกิดขึ้นได้ (Complication)	15
2.2 การวิเคราะห์ค่า Arterial blood gas ในการรักษาและวินิจฉัย	15
2.3 การเรียนรู้ของเครื่อง (Machine learning)	19
2.4 วิธีการค้นหาเพื่อนบ้านใกล้ที่สุด k ตัว (K-Nearest Neighbors)	21
2.5 Random forest	22
2.6 eXtreme Gradient Boosting (XGBoost)	24
2.7 การเรียนรู้เชิงลึก (Deep learning)	25
2.8 การแก้ไขปัญหาชุดข้อมูลไม่สมดุลด้วยเทคนิค Synthetic Minority Over-sampling Technique (SMOTE)	27
2.9 งานวิจัยที่เกี่ยวข้องกับการใช้ปัญญาประดิษฐ์และ Machine Learning ในการวิเคราะห์และแปลผล ABG	29

สารบัญ

	หน้า
บทที่ 3 วิธีดำเนินงานวิจัย	32
3.1 การเก็บชุดข้อมูล	33
3.2 การจัดเตรียมข้อมูลเพื่อการประมวลผล	33
3.3 การสร้างโมเดล	36
3.4 วัดประสิทธิภาพของโมเดลเรียนรู้แต่ละโมเดล	39
3.5 เพิ่มประสิทธิภาพของโมเดลการเรียนรู้ให้มีความแม่นยำในการแปลผลมากขึ้น	39
3.6 เปรียบเทียบประสิทธิภาพการทำนายผลเพื่อหาโมเดลการเรียนรู้ที่ดีที่สุด	39
บทที่ 4 ผลการวิจัยและการอภิปรายผล	40
4.1 การดำเนินการจัดการข้อมูลในแต่ละ Class ให้สมดุลกันด้วยเทคนิค SMOTE	40
4.2 การกำหนดโครงสร้างและประสิทธิภาพของแต่ละโมเดล	41
4.2.1 โมเดล K-Nearest Neighbors (KNN)	41
4.2.2 โมเดล Random forest	43
4.2.3 โมเดล XGBoost	44
4.2.4 โมเดล Deep learning	46
4.3 การเปรียบเทียบประสิทธิภาพการทำนายของแต่ละโมเดลการเรียนรู้	48
4.4 การเพิ่มประสิทธิภาพของโมเดลการเรียนรู้ให้มีความแม่นยำมากขึ้น	49
4.5 ปัญหาที่พบจากการศึกษา	50
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	51
5.1 สรุปผลการวิจัย	51
5.2 ข้อเสนอแนะ	51
เอกสารอ้างอิง	53
ประวัติผู้เขียน	59
ภาคผนวก	60

สารบัญตาราง

ตารางที่	หน้า
2.1 แสดงค่าต่าง ๆ ของ ABG การแปลผล และช่วงค่าปกติ	16
2.2 แสดงความสัมพันธ์ของ Arterial blood gas กับอาการทางคลินิกต่าง ๆ	18
2.3 แสดงการสรุปผลภาพรวมของทบทวนวรรณกรรมที่เกี่ยวข้อง	30
3.1 แสดงคุณลักษณะของชุดข้อมูล	33
3.2 แสดงชนิดของตัวแปรในแต่ละ Attribute	34
3.3 แสดงจำนวนของชุดข้อมูลก่อนและหลังการปรับสมดุลด้วยเทคนิค SMOTE	35
3.4 แสดงไฮเปอร์พารามิเตอร์ในแต่ละโมเดลที่มีการปรับค่า	37
ภาคผนวก	
ก. แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล K-Nearest Neighbors (KNN)	60
ข. แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Random forest	61
ค. แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost	63
ง. แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning	68
จ. แสดงการเปรียบเทียบค่า Accuracy และ Absolute error ในแต่ละโมเดลการเรียนรู้	76
ฉ. แสดงค่าความแม่นยำเมื่อใช้ Cross validation algorithm และค่าเฉลี่ยในแต่ละโมเดลการเรียนรู้	76

สารบัญรูป

รูปที่	หน้า
2.1 วงจรหัวใจและปอดเทียม	5
2.2 หัวปั๊มชนิดต่าง ๆ	6
2.3 การใส่ท่อนำเลือดดำเพื่อระบายเลือดดำออกจากหัวใจ	7
2.4 การใส่ท่อนำเลือดแดงเพื่อนำเลือดจากเครื่องหัวใจและปอดเทียมกลับเข้าร่างกายผ่านเส้นเลือดแดงใหญ่	7
2.5 ปอดเทียม (Oxygenator)	8
2.6 สายยาง (Tubing)	9
2.7 แอ่งเก็บเลือดรูปแบบต่าง ๆ	10
2.8 ระบบการให้สารน้ำเพื่อหยุดการเต้นของหัวใจ	11
2.9 วงจรหัวใจและปอดเทียมซึ่งเป็นระบบหมุนเวียนเลือดนอกร่างกายมนุษย์	12
2.10 การจัดการระบบหัวใจและปอดเทียม ทั้งขั้นตอนการเตรียมวงจร ระหว่างการทำ Cardiopulmonary bypass (CPB) และการหย่าเครื่อง	14
2.11 ประเภทการเรียนรู้ของ Machine learning	20
2.12 หลักการของ K-Nearest Neighbors (KNN)	21
2.13 การหาระยะทาง Euclidean distance	22
2.14 หลักการของ Random forest	23
2.15 หลักการของ eXtreme Gradient Boosting (XGBoost)	24
2.16 ความแตกต่างของ Simple Neural Network และ Deep learning	26
2.17 การสกัดคุณลักษณะ (Feature Extraction) ของโมเดล Deep learning	27
2.18 เทคนิคการ Resampling สำหรับชุดข้อมูลที่ไม่สมดุล	28
2.19 เทคนิค Synthetic Minority Over-sampling Technique (SMOTE)	28
3.1 ขั้นตอนการดำเนินงานวิจัย	32
3.2 สรุปขั้นตอนการจัดเตรียมข้อมูลเพื่อการประมวลผล	36
3.3 การแบ่งข้อมูลสำหรับฝึกและทดสอบ	37
3.4 รายละเอียดการดำเนินงานวิจัย	39
4.1 จำนวนข้อมูลในแต่ละ Class จากการเก็บข้อมูลผู้ป่วย	40
4.2 จำนวนข้อมูลที่ทำให้ข้อมูลแต่ละ class สมดุลด้วยเทคนิค SMOTE	41
4.3 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์พารามิเตอร์ต่างๆ ของโมเดลการเรียนรู้ K-Nearest Neighbors (KNN)	42

สารบัญรูป

รูปที่	หน้า
4.4 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์-พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ Random forest	43
4.5 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์-พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ XGBoost	45
4.6 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์-พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ Deep learning	47
4.7 การเปรียบเทียบค่า Accuracy, Absolute error, Sensitivity และ Specificity ของแต่ละโมเดลการเรียนรู้	48
4.8 ค่า Accuracy ของแต่ละโมเดลการเรียนรู้โดยใช้ Cross validation algorithm	49
ภาคผนวก	
ก. Confusion matrix ของโมเดล K-nearest neighbors (KNN) ที่ให้ค่า Accuracy สูงที่สุด	77
ข Confusion matrix ของโมเดล Random Forest ที่ให้ค่า Accuracy สูงที่สุด	77
ค Confusion matrix ของโมเดล XGBoost ที่ให้ค่า Accuracy สูงที่สุด	77
ง Confusion matrix ของโมเดล Deep learning ที่ให้ค่า Accuracy สูงที่สุด	78

คำย่อ/สัญลักษณ์

คำย่อ/สัญลักษณ์	คำอธิบาย
ABG	Arterial blood gas หรือ ค่าก๊าซในเลือดแดง
CPB	Cardiopulmonary bypass
HLM	Heart-Lung machine หรือ เครื่องหัวใจและปอดเทียม
EEG	Electroencephalography หรือ การตรวจคลื่นไฟฟ้าสมอง
PVC	Polyvinyl Chloride หรือ วัสดุโพลีเมอร์ชนิด Polyvinyl Chloride
CVP	Central venous pressure หรือ การวัดความดันเลือดดำส่วนกลาง
SVC	Superior vena cava เป็นหลอดเลือดดำใหญ่ส่วนบน
IVC	Inferior vena cava เป็นหลอดเลือดดำใหญ่ส่วนล่าง
RA	Right Atrium หรือ หัวใจห้องบนขวา
RV	Right Ventricle หรือ หัวใจห้องล่างขวา
PA	Pulmonary Artery หรือ เส้นเลือดแดงใหญ่ที่ออกจากหัวใจไปสู่ปอด
CO ₂	ก๊าซคาร์บอนไดออกไซด์
FiO ₂	Fraction of Inspired Oxygen หรือ สัดส่วนของออกซิเจนในอากาศที่ร่างกายหายใจเข้าทั้งหมด 1 ส่วน
PaO ₂	ค่าความดันออกซิเจนที่ละลายอยู่ในกระแสเลือด
PaCO ₂	ค่าความดันออกซิเจนที่ละลายอยู่ในกระแสเลือด
pH	ค่าความสมดุลกรด-เบสในเลือด
HCO ₃	ค่าไบคาร์บอเนตในเลือดแดง
SaO ₂	ความอิ่มตัวของออกซิเจนในเลือดแดง
BE	Base excess หรือ ค่าไบคาร์บอเนตซึ่งเป็นตัวบ่งชี้เฟอร์ในเลือด
Hb	Hemoglobin หรือ ค่าระดับฮีโมโกลบิน
Hct	Hematocrit หรือ ค่าความเข้มข้นเลือด
Na	ปริมาณของโซเดียมในเลือด
K	ปริมาณของโพแทสเซียมในเลือด
Ca	ปริมาณของแคลเซียมในเลือด
CO	Carbon monoxide
methHb	Methaemoglobin หรือ ฮีโมโกลบินชนิดผิดปกติ ที่ไม่สามารถจับออกซิเจนได้
SMOTE	Synthetic Minority Oversampling Technique
KNN	K- Nearest Neighbor

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1. ความเป็นมาและความสำคัญของปัญหา

1.1 ความเป็นมา

ในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence :AI) มีความก้าวหน้าอย่างมาก เป็นเทคโนโลยีที่สามารถทำงานแทนมนุษย์ในงานที่มีความซับซ้อน มีการคำนวณหรืออัลกอริทึมที่ซับซ้อน ใช้เวลาในการวิเคราะห์มาก มีตัวแปร มีปัจจัยที่เกี่ยวข้องจำนวนมากได้ดี ซึ่งทำให้ประหยัดเวลาในการทำงาน ลดการใช้ทรัพยากร และลดความผิดพลาดที่อาจเกิดจากมนุษย์ (Human error) ได้ จะเห็นได้ว่าการนำเทคโนโลยี AI มาใช้อย่างแพร่หลายในหลายงาน เช่น ด้านการเกษตร มีนำ AI มาดูช่วงเวลาที่เหมาะสมในการเก็บเกี่ยวผลผลิต ทางด้านการลงทุน มีการนำ AI มาช่วยทำนายความน่าจะเป็นของราคาหุ้นที่สนใจลงทุน ทางด้านการเงินการธนาคาร นำมาทำนายเกี่ยวกับการทำรายการของบัตรเครดิตที่ผิดปกติซึ่งอาจเกิดจากการกระทำของมิจฉาชีพ ทางด้านงานโรงแรม นำมาดูแลตอบรับทั้งทางด้านดีและด้านที่ต้องปรับปรุงของการให้บริการแก่ลูกค้าที่มาเข้าพัก ทางด้านการแพทย์และสาธารณสุข มีการนำเทคโนโลยี AI เข้ามาช่วยวินิจฉัยภาพถ่ายเอ็กซเรย์ปอดในผู้ป่วยที่สงสัยติดเชื้อ COVID19 ในเบื้องต้นหรือ AI ช่วยวินิจฉัยคลื่นไฟฟ้าหัวใจในเบื้องต้นได้

ในด้านการแพทย์และสาธารณสุข มีการนำเทคโนโลยี AI มาใช้งานเพิ่มขึ้นอย่างเห็นได้ชัด และมีการใช้อย่างแพร่หลายมากขึ้น ยกตัวอย่างเช่นในภาวะการณระบาดของเชื้อไวรัส COVID19 ทั่วโลก มีการใช้เทคโนโลยี AI ช่วยวินิจฉัยภาพถ่ายเอ็กซเรย์ โดยให้ระบบเรียนรู้ภาพถ่ายของผู้ป่วยที่ได้รับการวินิจฉัยว่าติดเชื้อเชื้อไวรัส COVID19 แล้ว เพื่อนำไปวินิจฉัยผู้ป่วยรายใหม่ที่มีอาการคล้ายผู้ป่วยติดเชื้อไวรัส COVID19 ซึ่งช่วยจำแนกผู้ป่วยที่ติดเชื้อและไม่ติดเชื้อออกจากกันเป็นเบื้องต้น เพื่อให้ผู้ป่วยที่มีความน่าจะเป็นในการติดเชื้อมากกว่าได้รับการรักษาที่รวดเร็วขึ้น ซึ่งช่วยลดอัตราการเสียชีวิตได้ อีกทั้งยังในภาวะการณระบาดทั่วโลก ทำให้มีผู้ป่วยเป็นจำนวนมาก แต่จำนวนแพทย์มีจำกัด การนำเทคโนโลยี AI มาใช้จึงช่วยแก้ปัญหาการขาดแคลนบุคลากรเฉพาะด้านได้ นอกจากนี้เทคโนโลยี AI ยังนำมาช่วยในการรักษาผู้ป่วยในกลุ่มโรคอื่น ๆ ด้วย เช่น กลุ่มโรคหัวใจ มีการนำมาช่วยวินิจฉัยคลื่นไฟฟ้าหัวใจที่ผิดปกติในรูปแบบต่าง ๆ ได้ หรือการนำมาช่วยทำนายอัตราการเสียชีวิตในผู้ป่วยที่ได้รับการผ่าตัดหัวใจ หรือการผ่าตัดหลอดเลือดแดงขนาดใหญ่ และนำเทคโนโลยี AI มาใช้ในการทำนายอัตราการเสียชีวิตในผู้ป่วยที่ได้รับการผ่าตัดหัวใจด้วย อีกทั้งมีงานวิจัยนำเสนอการใช้เทคโนโลยี AI ในการประเมินและรักษาผู้ป่วยที่ต้องเข้ารับการผ่าตัดทั้งในช่วงก่อนผ่าตัด ระหว่างผ่าตัด หลังผ่าตัด เพื่อให้ผลการรักษามีประสิทธิภาพสูงสุด และลดภาวะแทรกซ้อนที่อาจเกิดขึ้นในระหว่างการรักษา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในระหว่างการผ่าตัดหัวใจ (Intra-operative period) หัตถการส่วนใหญ่มีการใช้เครื่องหัวใจและปอดเทียม (Heart-Lung Machine : HLM) เพื่อทดแทนการทำงานของหัวใจระหว่างการผ่าตัดเพื่อแก้ไขพยาธิสภาพของโรคนั้น ๆ ซึ่งในระหว่างการควบคุมเครื่อง Heart-Lung machine นักปฏิบัติการเครื่องหัวใจและปอดเทียม (Perfusionist) ต้องอาศัยพารามิเตอร์และค่าทางห้องปฏิบัติการหลาย ๆ ตัว ในการวิเคราะห์และแปลผล เพื่อนำไปประกอบการควบคุมและปรับตั้งการทำงานต่าง ๆ ของเครื่อง HLM เพื่อให้เหมาะสมกับสภาวะทางสรีรวิทยาของผู้ป่วยในช่วงเวลาขณะนั้น ซึ่งจะส่งผลให้การทำงานของร่างกายผู้ป่วยใกล้เคียงกับสภาวะปกติมากที่สุด

ค่าทางห้องปฏิบัติการหนึ่งที่ต้องนำมาวิเคราะห์และแปลผลเพื่อปรับตั้งและควบคุมการทำงานของเครื่อง Heart-Lung Machine คือ การตรวจวิเคราะห์ก๊าซในหลอดเลือดแดง (Arterial Blood Gas : ABG) ซึ่งเป็นการตรวจทางห้องปฏิบัติการเพื่อประเมิน ภาวะออกซิเจน (Oxygenation) การแลกเปลี่ยนก๊าซ (Gas exchange) และภาวะกรด-ด่างในร่างกาย (Acid-base status) ในการแปลผลนั้น ต้องพิจารณาพารามิเตอร์หลายตัว และต้องใช้ความเชี่ยวชาญและประสบการณ์ในการแปลผลพอสมควร ซึ่งหากมีการแปลผลผิดพลาดจะทำให้เกิดผลภาวะแทรกซ้อนหรือเหตุการณ์ไม่พึงประสงค์อื่น ๆ ที่เกิดจากการปรับตั้งเครื่อง Heart-Lung machine ไม่เหมาะสมกับสภาวะผู้ป่วยในขณะนั้นได้

1.2 ความสำคัญของปัญหา

การแปลผลค่า Arterial blood gas ต้องมีการพิจารณาพารามิเตอร์หลาย ๆ ตัวประกอบกัน และต้องอาศัยความเชี่ยวชาญในการแปลผลร่วมด้วย การแปลผล Arterial blood gas ในระหว่างการผ่าตัดหัวใจนั้นมีความสำคัญต่อการปรับตั้งการทำงานของเครื่อง Heart-Lung machine ในขณะผ่าตัดหัวใจเป็นอย่างมาก ซึ่งในระหว่างการผ่าตัดเครื่อง Heart-Lung machine ทำหน้าที่แทนหัวใจและปอดของผู้ป่วย หากมีการปรับตั้งเครื่อง Heart-Lung machine ที่ไม่สอดคล้องกับภาวะผู้ป่วยในขณะนั้น อาจทำให้เกิดภาวะแทรกซ้อนที่ไม่พึงประสงค์ต่อผู้ป่วยได้ ดังนั้นการแปลผล Arterial blood gas อย่างถูกต้องในระหว่างการผ่าตัดหัวใจจึงมีผลต่อผลต่อผู้ป่วยที่ได้รับการผ่าตัดหัวใจที่ต้องใช้เครื่อง Heart-Lung machine เป็นอย่างมาก

จากความสำคัญในการแปลผลผล Arterial blood gas ดังกล่าว ผู้วิจัยซึ่งเป็น Perfusionist จึงเห็นความสำคัญของการแปลผลที่ถูกต้องและรวดเร็ว ซึ่งในปัจจุบันเทคโนโลยี AI มีความก้าวหน้าอย่างมาก อีกทั้งเป็นเทคโนโลยีที่เข้ามาช่วยในการลด Human error และสามารถใช้งานที่มีความซับซ้อนหรืองานที่ต้องอาศัยผู้เชี่ยวชาญเฉพาะด้านได้ดี จึงทำงานวิจัยนี้เพื่อนำเทคโนโลยี AI มาใช้ในการแปลผล Arterial blood gas ในระหว่างการผ่าตัดหัวใจ เพื่อช่วยปรับตั้งการทำงานของเครื่อง HLM ให้เหมาะสมกับสภาวะผู้ป่วยในขณะนั้น ๆ ได้อย่างเหมาะสม

2. วัตถุประสงค์ของการวิจัย

2.1 เพื่อหาโมเดลการเรียนรู้ที่มีประสิทธิภาพ และเหมาะสมกับการแปรผล ผล Arterial blood gas ในระหว่างการผ่าตัดหัวใจสำหรับชุดข้อมูลที่นำมาทดลองนี้ โดยให้ค่า Accuracy ที่สูงที่สุด

2.2 นำเทคโนโลยี AI และการเรียนรู้ของเครื่อง (Machine learning) มาใช้ในการแปรผล Arterial blood gas เพื่อศึกษาแนวทางการนำข้อมูลทางห้องปฏิบัติการหรือข้อมูลทางการแพทย์อื่นๆ มาประยุกต์ให้เข้ากับงานด้านวิทยาการข้อมูลเพื่อนำไปพัฒนาการใช้ข้อมูลทางการแพทย์ที่มีอยู่

3. ขอบเขตของการวิจัย

ข้อมูลผล Arterial blood gas ของผู้ป่วยที่ได้รับการผ่าตัดหัวใจแบบเปิด (Open heart surgery) และใช้เครื่องหัวใจและปอดเทียม (Heart-Lung machine) ตั้งแต่วันที่ 1 มกราคม 2562 ถึง 31 ธันวาคม 2565 ในโรงพยาบาลจุฬารณณ์ จำนวน 200 ตัวอย่าง

4. ประโยชน์ที่คาดว่าจะได้รับ

4.1 ได้โมเดลการเรียนรู้ที่มีประสิทธิภาพในการแปรผล Arterial blood gas สำหรับชุดข้อมูลที่เก็บรวบรวมเพื่องานวิจัยนี้

4.2 ทราบแนวทางการใช้ Machine learning กับชุดข้อมูลด้านการแพทย์ที่มีอยู่

4.3 เป็นงานวิจัยเริ่มต้นในการใช้เทคโนโลยีด้านข้อมูล มาใช้ประมวลผลข้อมูลที่เกี่ยวข้องกับการควบคุมเครื่องหัวใจและปอดเทียม เพื่อพัฒนาการวิจัยที่เกี่ยวข้องในอนาคต

5. ข้อจำกัดในการวิจัย

เนื่องจากการทำวิจัยนี้เก็บข้อมูลจากในผู้ป่วยที่เข้ารับการผ่าตัดหัวใจเฉพาะที่โรงพยาบาลจุฬารณณ์เท่านั้น จึงทำให้จำนวนข้อมูลผล Arterial blood gas ที่นำมาใช้อาจมีจำนวนไม่มากพอ ซึ่งอาจมีผลต่อการเรียนรู้ของเครื่อง (Machine learning) ซึ่งผู้วิจัยได้ทำการแก้ไขปัญหานี้โดยวิธีการทางสถิติและจัดการข้อมูลให้แต่ละ Class ให้สมดุลกัน

บทที่ 2

แนวคิดทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1. การทำงานของเครื่องหัวใจและปอดเทียมและระบบไหลเวียนนอกร่างกาย (Cardiopulmonary Bypass: CPB)

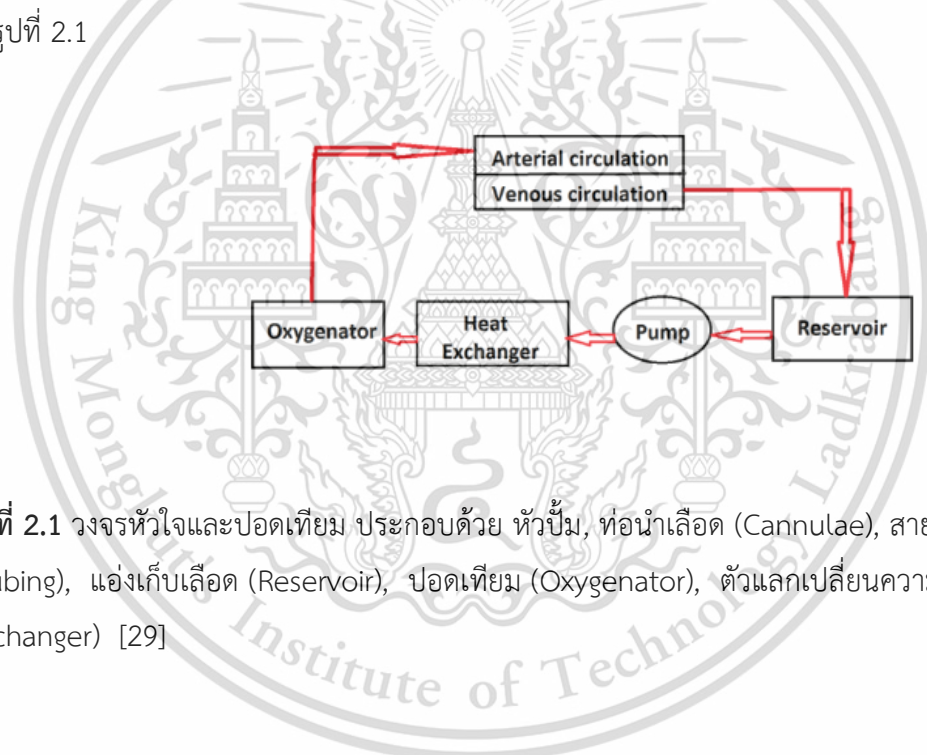
การไหลเวียนเลือดนอกร่างกายมนุษย์เพื่อช่วยให้สามารถทำการผ่าตัดเพื่อแก้ไขพยาธิสภาพที่ผิดปกติของหัวใจ ต้องอาศัยเครื่องหัวใจและปอดเทียม (Heart-Lung Machine) ซึ่งสามารถทำสำเร็จครั้งแรกโดย Dr. John Gibbon ในปี ค.ศ.1952 ที่ประเทศสหรัฐอเมริกา และในปัจจุบันมีความก้าวหน้าเพิ่มขึ้นเรื่อย ๆ โดยมีผู้สนใจค้นคว้า ศึกษาเกี่ยวกับวงจรภายนอกและอุปกรณ์เครื่องมือที่เกี่ยวข้องต่าง ๆ เพิ่มมากขึ้น เช่น

David Machin และ Chris Allsager (2006) ได้กล่าวถึง หลักการทำงานแทนหัวใจและปอดของเครื่องหัวใจและปอดเทียม (Heart-Lung machine) ในระหว่างการผ่าตัดหัวใจ ซึ่งประกอบด้วย ส่วนของปอดเทียม (Oxygenator) ซึ่งทำหน้าที่แลกเปลี่ยนก๊าซออกซิเจนและคาร์บอนไดออกไซด์ (Gas Exchange) ส่วนของการปั๊มเลือด (Blood pump) ซึ่งทำหน้าที่แทนหัวใจ รวมถึงเทคนิคการรักษาปกป้องกล้ามเนื้อหัวใจ (Myocardial protection) ในระหว่างการผ่าตัด เพื่อให้กล้ามเนื้อหัวใจได้รับบาดเจ็บน้อยที่สุดในระหว่างการผ่าตัด การลดอุณหภูมิร่างกาย (Hypothermia) ในระหว่างการผ่าตัดเพื่อลดเมตาบอลิซึมของร่างกาย สมดุลกรดเบสในร่างกายโดยใช้การวิเคราะห์ก๊าซในหลอดเลือดแดง (Arterial blood gas) และการกรองเลือด (Blood filtration) ที่สูญเสียจากการผ่าตัดนำกลับไปให้ผู้ป่วยอีกครั้งเพื่อลดการเสียเลือด [1]

Albert T Cheung, Mark Stafford-Smith และ Michele Heath (2022) ได้กล่าวถึงการปฏิบัติการและควบคุมการทำงานของเครื่องหัวใจและปอดเทียม คือ ระบบการไหลเวียนของเลือดนอกร่างกายมนุษย์ โดยเปลี่ยนเส้นทางการไหลเวียนของเลือดโดยไม่ผ่านหัวใจและปอดของผู้ป่วย ซึ่งเครื่องหัวใจและปอดเทียมประกอบด้วย หัวปั๊ม (Blood pump) สายยางนำเลือด (Tubing), ปอดเทียม (Oxygenator) และหน่วยแลกเปลี่ยนความร้อน (Heat exchange unit) ในระหว่างการใช้ทำงานของเครื่องหัวใจและปอดเทียม จะมีการติดตาม (Monitor) พารามิเตอร์ต่าง ๆ ของผู้ป่วยอย่างต่อเนื่อง เช่น ความดันในวงจร อุณหภูมิ พารามิเตอร์ของเลือด เช่น ความอิ่มตัวของออกซิเจนในเลือด ค่าการวิเคราะห์ก๊าซในเลือด ความเข้มข้นของเม็ดเลือดแดง ค่าโพแทสเซียมในเลือดรวมถึงอิเล็กโทรไลต์อื่น ๆ พารามิเตอร์ต่าง ๆ ของระบบประสาท เช่น ค่าความอิ่มตัวของออกซิเจนในหลอดเลือดสมอง (Cerebral oximetry) การวัดคลื่นไฟฟ้าสมอง (EEG) เป็นต้น ซึ่งวัตถุประสงค์ในการควบคุมและปฏิบัติการเครื่องหัวใจและปอดเทียมคือ การควบคุมและรักษาระบบสรีรวิทยาในร่างกายผู้ป่วยให้

ใกล้เคียงกับสภาวะปกติมากที่สุด รวมถึงการมีเลือดที่ได้รับการแลกเปลี่ยนก๊าซแล้วไปเลี้ยงอวัยวะต่าง ๆ ของร่างกายโดยเฉพาะอวัยวะส่วนปลายอย่างเพียงพอ[2]

Manjula Sarka และ Vishal Prabhu (2017) ได้อธิบายว่าความก้าวหน้าในการผ่าตัดหัวใจเกิดขึ้นได้จากการพัฒนาของการบายพาสหัวใจและปอด (Cardiopulmonary bypass: CPB) ซึ่งเป็นรูปแบบของระบบไหลเวียนโลหิตนอกร่างกาย ซึ่งทำหน้าที่แทนระบบหมุนเวียนโลหิตและระบบการหายใจ เพื่อช่วยให้ทำการผ่าตัดหัวใจและหลอดเลือดใหญ่ได้ การผ่าตัดหัวใจทำสำเร็จครั้งแรกในปี 1952 โดย John Gibbon โดยทำอย่างปลอดภัยด้วยวิธี CPB ภายใต้ความร่วมมือของศัลยแพทย์ วิสัญญีแพทย์ และนักปฏิบัติการเครื่องหัวใจและปอดเทียม (Perfusionist) และยังสามารถอธิบายส่วนประกอบต่าง ๆ ของวงจรหัวใจและปอดเทียม (CPB circuit) ว่าประกอบด้วย หัวปั๊ม, ท่อนำเลือด (Cannulae), สายยางนำเลือด (Tubing), แอ่งเก็บเลือด (Reservoir), ปอดเทียม (Oxygenator), ตัวแลกเปลี่ยนความร้อน (Heat exchanger) และตัวกรองที่สายเลือดแดง (Arterial filter) [3] ดังรูปที่ 2.1




รูปที่ 2.1 วงจรหัวใจและปอดเทียม ประกอบด้วย หัวปั๊ม, ท่อนำเลือด (Cannulae), สายยางนำเลือด (Tubing), แอ่งเก็บเลือด (Reservoir), ปอดเทียม (Oxygenator), ตัวแลกเปลี่ยนความร้อน (Heat exchanger) [29]

2.1.1 ส่วนประกอบของวงจรหัวใจและปอดเทียม ซึ่งจะประกอบไปด้วยเครื่องมือทางการแพทย์ที่เป็นฮาร์ดแวร์และเวชภัณฑ์ทางการแพทย์ ประกอบด้วย

2.1.1.1 หัวปั๊ม (Pump) ซึ่งเป็นส่วนที่สำคัญของเครื่องหัวใจและปอดเทียม ทำหน้าที่แทนหัวใจผู้ป่วย มี 2 ชนิด คือ

Roller Pump หัวปั๊มแบบลูกกลิ้ง ประกอบด้วยลูกกลิ้ง 2 หัวที่วางบนแกนหมุน เพื่อกดลงไปตามความยาวของสายยางเพื่อทำให้เกิดกระแสเลือดไปข้างหน้า ดังรูปที่ 2.1 ด้านซ้าย

Centrifugal pump หัวปั๊มแบบแรงเหวี่ยง ประกอบด้วยใบพัดและกรวยซ้อนกัน อยู่ภายในปลอกหุ้ม (Housing) เมื่อเกิดการหมุนอย่างรวดเร็ว จะเกิดความดันลบในฝั่งทางเข้าและความดันบวกในฝั่งทางออก ซึ่งทำให้เกิดกระแสเลือดไปข้างหน้า ดังรูปที่ 2.2 ด้านขวา




รูปที่ 2.2 หัวปั๊มชนิดต่าง ๆ

ด้านซ้าย แสดงหัวปั๊มแบบลูกกลิ้งและการทำงานโดยหัวปั๊มกดไปข้างหน้าตามความยาวของสายยาง [30]

ด้านขวา แสดงหัวปั๊มแบบแรงเหวี่ยง การหมุนอย่างรวดเร็วทำให้เกิดกระแสเลือดไปข้างหน้า [31]

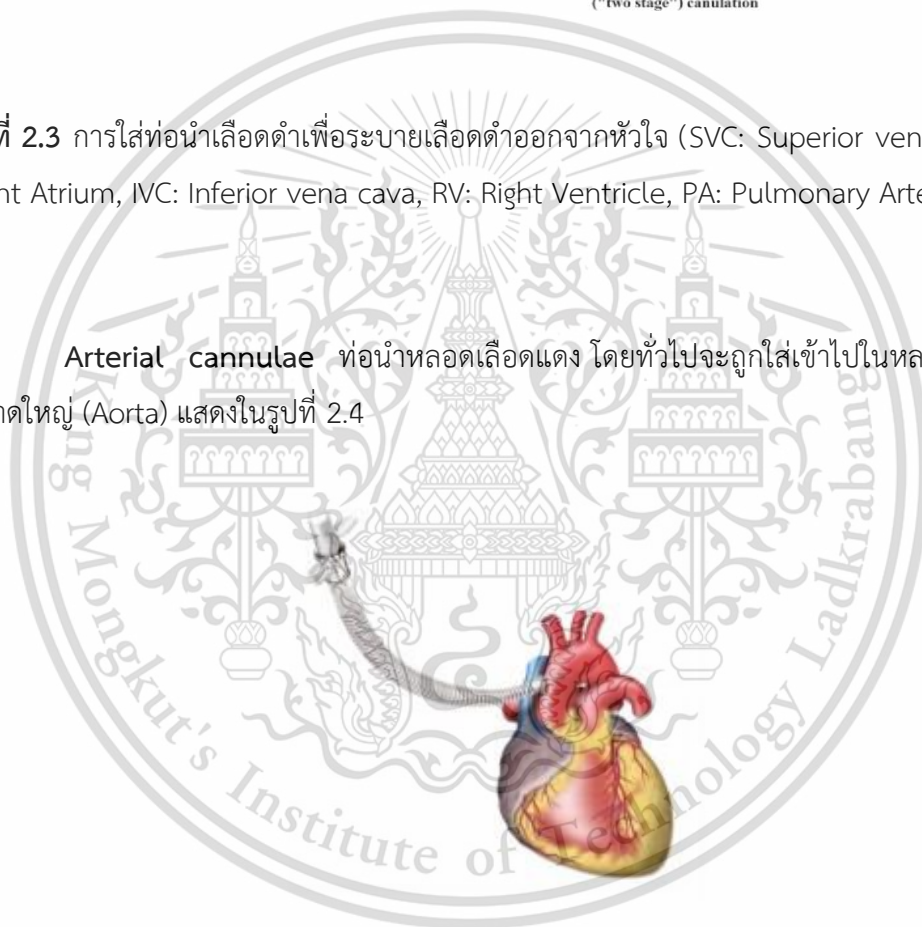
2.1.1.2 ท่อนำเลือด (Cannulae) เป็นส่วนที่เชื่อมต่อระหว่างตัวผู้ป่วยเข้ากับวงจรไปจนถึงจนเครื่องหัวใจและปอดเทียม ซึ่งทำมาจากวัสดุ Polyvinylchloride (PVC) และมีดัดลวดเสริมภายในเพื่อป้องกันการอุดตันจากการหักพับของสาย

Venous cannulae ท่อนำเลือดดำ สำหรับระบายเลือดดำออกจากหัวใจห้องขวาบน (Right atrium) หรือจากหลอดเลือดดำขนาดใหญ่ (Inferior vena cava และ Superior vena cava) [4] ซึ่งแสดงในรูปที่ 2.3



รูปที่ 2.3 การใส่ท่อ นำเลือดดำเพื่อระบายเลือดดำออกจากหัวใจ (SVC: Superior vena cava, RA: Right Atrium, IVC: Inferior vena cava, RV: Right Ventricle, PA: Pulmonary Artery) [32]

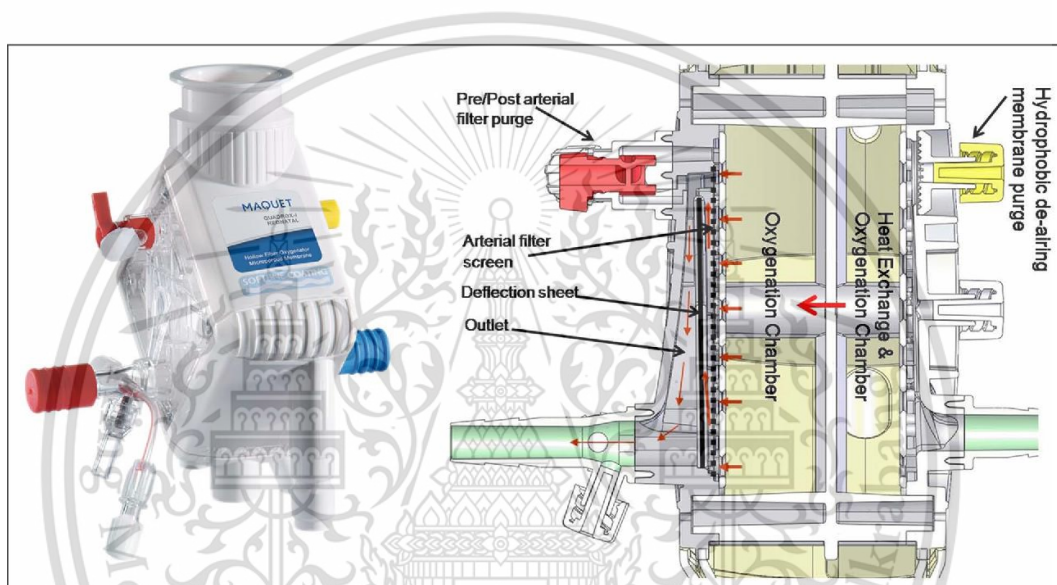
Arterial cannulae ท่อ นำหลอดเลือดแดง โดยทั่วไปจะถูกใส่เข้าไปในหลอดเลือดแดงขนาดใหญ่ (Aorta) แสดงในรูปที่ 2.4



รูปที่ 2.4 การใส่ท่อ นำเลือดแดงเพื่อนำเลือดจากเครื่องหัวใจและปอดเทียมกลับเข้าร่างกายผ่านเส้นเลือดแดงใหญ่ [33]


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.1.3 ปอดเทียม (Oxygenator) ทำหน้าที่ในการแลกเปลี่ยนก๊าซทดแทนปอดผู้ป่วย เป็นปอดเทียมชนิดเยื่อ (Membrane oxygenators) ประกอบด้วย Polypropylene fibers การแลกเปลี่ยนก๊าซเกิดจากเลือดไหลผ่านภายนอกไฟเบอร์ในขณะที่ก๊าซไหลผ่านข้างในไฟเบอร์ ดังนั้นจึงมีการแยกเฟสของเลือดกับก๊าซออกจากกัน ซึ่งทำให้เกิดภาวะฟองอากาศอุดตันในเส้นเลือด (Air embolism) ได้น้อยกว่าและมีความแม่นยำในเรื่องการควบคุมก๊าซในเลือดมากกว่า นอกจากนี้ตัวแลกเปลี่ยนความร้อน (Heat exchanger) จะถูกรวมเข้ากับปอดเทียมด้วยเพื่อการปรับอุณหภูมิเลือดและอุณหภูมิร่างกายผู้ป่วยระหว่างการผ่าตัด ดังรูปที่ 2.5



รูปที่ 2.5 ปอดเทียม (Oxygenator) ทำหน้าที่ในการแลกเปลี่ยนก๊าซทดแทนปอดผู้ป่วย [34]

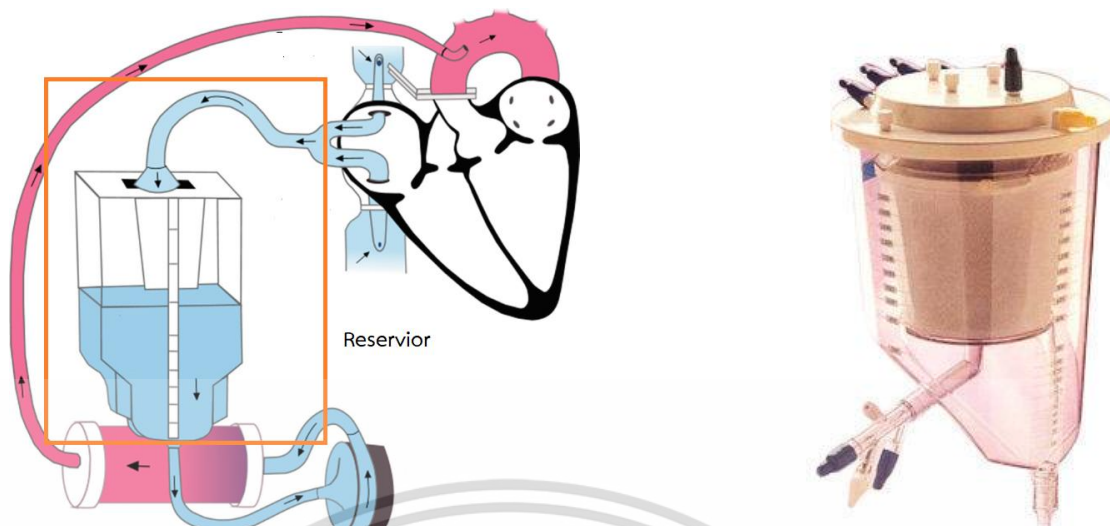
2.1.1.4 สายยาง (Tubing) ทำหน้าที่ที่คล้ายหลอดเลือดในร่างกายมนุษย์ โดยทั่วไปทำจาก PVC (Polyvinyl Chloride) เนื่องจาก PVC มีความทนทานและอัตราการสลายเม็ดเลือดที่ยอมรับได้ และมีการเติมพลาสติกชนิดอื่นในกลุ่มวัสดุทางการแพทย์ (Medical grade) เพื่อเพิ่มความยืดหยุ่น แสดงดังรูปที่ 2.6



รูปที่ 2.6 สายยาง (Tubing) ทำหน้าที่คล้ายหลอดเลือดในร่างกายมนุษย์ [35]

2.1.1.5 แอ่งเก็บเลือด (Reservoir) เป็นส่วนที่เก็บเลือดที่ระบายออกมาจากหัวใจผ่านทางท่อหลอดเลือดดำและสายยาง และรวมเลือดส่วนที่เก็บเลือดจากการดูดเลือด (Suction) ในส่วนต่าง ๆ ของการผ่าตัดกลับมารวมกันเข้าไว้ในแอ่งเก็บเลือดนี้ด้วยนอกจากนี้ยังมีส่วนตัวกรองช่วยลดการเกิดฟองอากาศและกรองลิ่มเลือดภายในแอ่งเก็บเลือดด้วย [5] ดังรูปที่ 2.7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.7 แอ่งเก็บเลือดรูปแบบต่าง ๆ

ด้านซ้าย แสดงแอ่งเก็บเลือดที่ระบายเลือดมาจากหัวใจห้องบนขวา [36]

ด้านขวา แสดงแอ่งเก็บเลือด ที่มีตัวกรองช่วยลดการเกิดฟองอากาศและกรองลิ่มเลือด [37]

2.1.1.6 ระบบการให้สารน้ำเพื่อหยุดการเต้นของหัวใจ (Cardioplegia system) [6] ในการแก้ไขพยาธิสภาพของหัวใจจำเป็นต้องมีการหยุดการเต้นของหัวใจโดยการหนีบ (Clamp) หลอดเลือดเออาร์ทา ซึ่งทำให้เกิดภาวะกล้ามเนื้อหัวใจขาดเลือด วิธีการให้สารน้ำเพื่อหยุดการเต้นของหัวใจ (Cardioplegia) เป็นวิธีการปกป้องกล้ามเนื้อหัวใจ โดยการฉีดสารน้ำเพื่อไปหยุดกลไกทางไฟฟ้าของหัวใจ ซึ่งสามารถลดความต้องการใช้ออกซิเจนของกล้ามเนื้อหัวใจได้ โดยให้ผ่านท่อนำสารหยุดการเต้นของหัวใจ (Cardioplegia cannulae) ซึ่งระบบการให้สารน้ำเพื่อหยุดการเต้นของหัวใจจะแยกหัวปั๊มออกมาหัวปั๊มเลือดแดง ดังรูปที่ 2.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



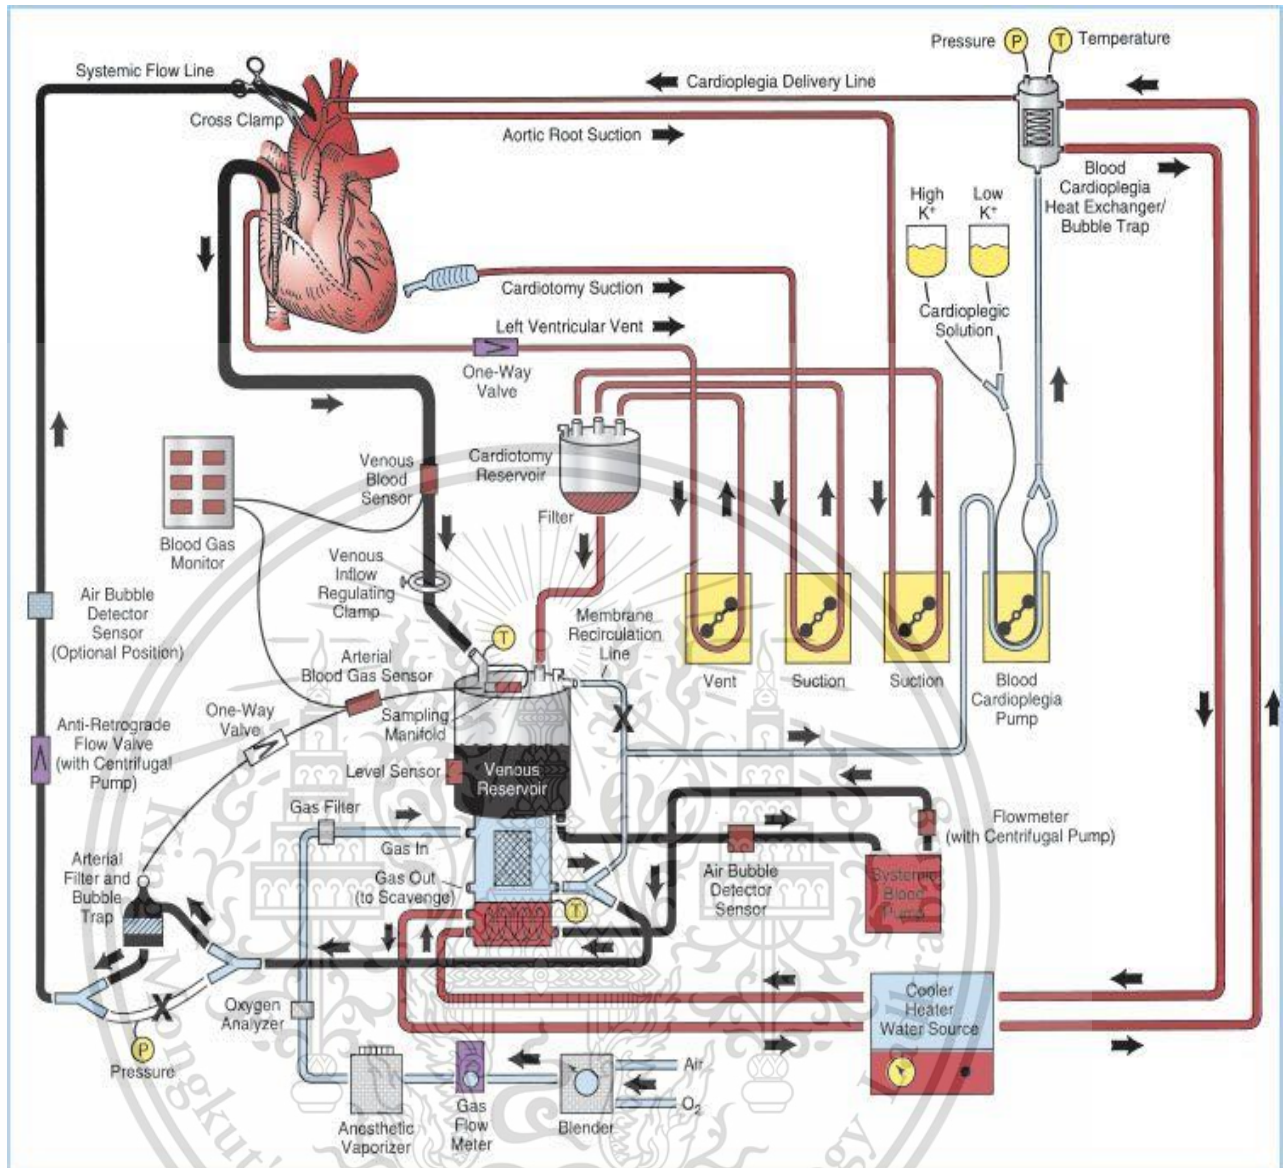
รูปที่ 2.8 ระบบการให้สารน้ำเพื่อหยุดการเต้นของหัวใจ

ด้านซ้าย วงจรการให้สารน้ำเพื่อหยุดการเต้นของหัวใจ [38]

ด้านขวา ท่อนำสารหยุดการเต้นของหัวใจ เพื่อต่อวงจรการให้สารน้ำเพื่อหยุดเข้ากับหัวใจผู้ป่วย [39]

2.1.1.7 วงจรอื่น ๆ ส่วนประกอบของวงจรอื่น ๆ ได้แก่ สายก๊าซและเครื่องผสม ก๊าซซึ่งส่งก๊าซที่ได้รับการผสมแล้วไปยังปอดเทียมในส่วนผสมที่มีการควบคุม ซึ่งการปรับตั้งเปอร์เซ็นต์ของออกซิเจน(FiO_2) จะปรับตามค่าออกซิเจนที่ละลายอยู่ในกระแสเลือด (PaO_2) และอาจมีตัวกรองที่ส่วนปลายสายเลือดแดง (Arterial filter) เพื่อกรองอนุภาคเนื้อเยื่อหรือลิ่มเลือดก่อนนำเลือดเข้าสู่ร่างกายผู้ป่วย นอกจากนี้ยังมีการเคลือบผิวด้านในของสายยางด้วยวัสดุที่หลากหลายเพื่อเพิ่มความเข้ากันได้ทางชีวภาพ กระตุ้นการอักเสบน้อยที่สุด ลดการเกิดลิ่มเลือด และลดการเกิดการเสียเลือด [7] แสดงดังรูปที่ 2.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.9 วงจรหัวใจและปอดเทียมซึ่งเป็นระบบหมุนเวียนเลือดนอกร่างกายมนุษย์ [40]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.2 การจัดการระบบหัวใจและปอดเทียม เป็นการควบคุมและปรับตั้งค่าต่าง ๆ ในระหว่างการผ่าตัดหัวใจและใช้เครื่องหัวใจและปอดเทียม เพื่อให้เหมาะสมกับผู้ป่วยแต่ละราย ซึ่งการจัดการและควบคุมระบบหัวใจและปอดเทียม ประกอบด้วยขั้นตอนต่าง ๆ ดังต่อไปนี้

2.1.2.1 การเตรียมวงจรด้วยการไล่อากาศออกจากวงจร CPB (Priming) ก่อนต่อวงจรเข้ากับร่างกายผู้ป่วย โดยใช้สารน้ำชนิดต่าง ๆ และคำนวณความต้องการกระแสเลือดต่อนาที (Cardiac output) ของผู้ป่วยแต่ละราย

2.1.2.2 การระงับความเจ็บปวดและความรู้สึก เพื่อให้ผู้ป่วยสลบและการติดตามสัญญาณชีพทั้งในระยะก่อน ระหว่างปฏิบัติการ และหลัง Cardiopulmonary bypass (CPB) ซึ่งต้องควบคุมความดันโลหิต (Arterial pressure) ให้อยู่ในเกณฑ์ที่เหมาะสมเพียงพอต่อการไปเลี้ยงอวัยวะส่วนต่าง ๆ ของร่างกาย และอาจจะติดตามเปอร์เซ็นต์ความอิ่มตัวของออกซิเจนที่สมองด้วยติดตามค่าความดันเลือดดำส่วนกลาง (Central venous pressure : CVP) เพื่อประเมินปริมาณเลือดในหลอดเลือดดำที่กลับมาที่หัวใจ ติดตามค่าความดันที่เส้นเลือดเออาร์ท่า อุณหภูมิของเลือด ในส่วนของการปรับระดับการระงับความรู้สึกและความเจ็บปวด ทำได้ด้วยการให้ยาผ่านหลอดเลือดดำ และ/หรือให้เป็นยาตามสลบก็ได้

2.1.2.3 การเริ่มการทำบายพาสหัวใจและปอดโดยเครื่องหัวใจและปอดเทียม โดยการให้ยาต้านการแข็งตัวของเลือด เนื่องจากตามกลไกการตอบสนองของร่างกายถ้ามีการสัมผัสกับสิ่งแปลกปลอมนอกหลอดเลือดจะกระตุ้นการเกิดลิ่มเลือดในระบบการไหลเวียนซึ่งเป็นอันตรายทำให้ลิ่มเลือดไปอุดตันตามอวัยวะต่าง ๆ ได้ การให้ยาต้านการแข็งตัวของเลือดจึงสามารถป้องกันการเกิดลิ่มเลือดได้

2.1.2.4 การจัดการอุณหภูมิ ซึ่งภาวะอุณหภูมิร่างกายต่ำ (Hypothermia) นิยมใช้สำหรับการทำ Cardiopulmonary bypass (CPB) ซึ่งคาดว่าช่วยลดผลกระทบที่อาจเกิดกับอวัยวะต่าง ๆ ได้ ทั้งสามารถปรับระดับการไหลของเลือดให้มีอัตราการไหลเวียนที่สูงได้ แม้จะมีการเจือจางของเลือดก็ตาม นอกจากนี้ยังสามารถลดการเกิดลิ่มเลือดได้ด้วย ซึ่งจะมีการติดตามอุณหภูมิแกนกลางของร่างกาย เช่น ในหลอดอาหาร ใน Nasopharyngeal ในกระเพาะปัสสาวะ และ ในทวารหนัก (Rectum) เป็นต้น

2.1.2.5 การจัดการภาวะกรด-เบส เป็นส่วนสำคัญในภาวะอุณหภูมิร่างกายต่ำระหว่างทำ Cardiopulmonary bypass (CPB) ก๊าซ CO₂ จะละลายในเลือดได้น้อยลงในภาวะที่อุณหภูมิร่างกายต่ำมาก ๆ (Deep hypothermia) ส่งผลให้เลือดมีความเป็นเบส (Alkalosis) เพิ่มขึ้นสำหรับภาวะเลือดเป็นกรด (Acidosis) อาจเกิดจากการเปลี่ยนก๊าซและการฉีดเลือดของระบบหัวใจและปอดเทียมไม่เพียงพอต่อความต้องการของร่างกาย โดยจะติดตามภาวะกรด-เบสของเลือดได้จากการตรวจวิเคราะห์ก๊าซในเลือดแดง (Arterial Blood Gas : ABG)

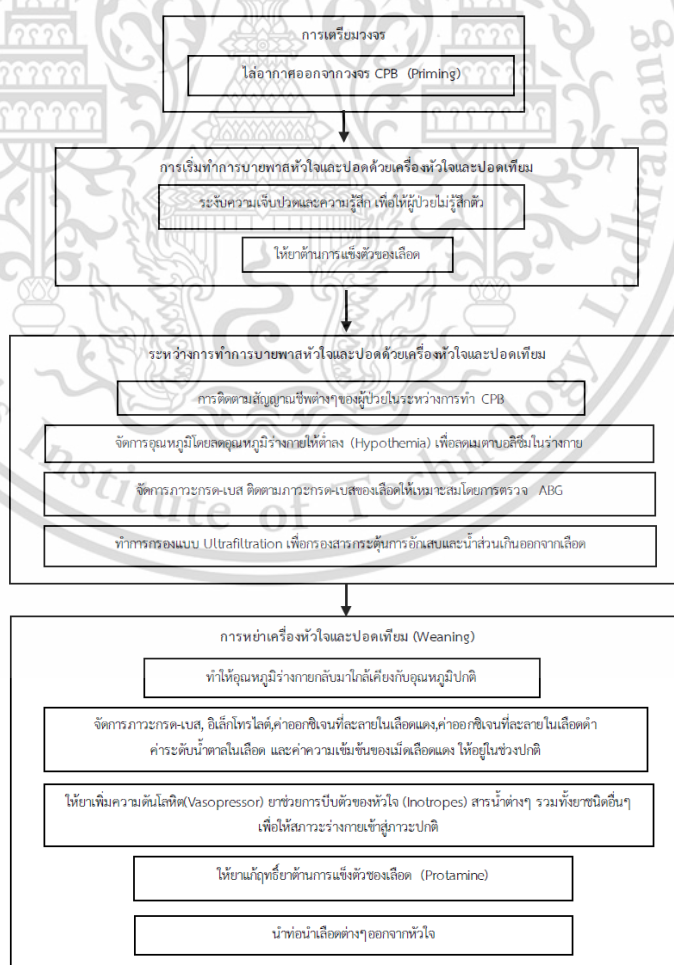
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.2.6 การกรองแบบ Ultrafiltration เป็นการกรองในระหว่างหรือหลังการทำ Cardiopulmonary bypass (CPB) เพื่อกรองสารกระตุ้นการอักเสบและน้ำส่วนเกินออกจากเลือด

2.1.2.7 การหย่าเครื่องหัวใจและปอดเทียม (Weaning) เป็นกระบวนการค่อยๆ ปรับสภาพร่างกายผู้ป่วยให้เข้าสู่ภาวะปกติ เพื่อให้หัวใจและปอดสามารถทำงานได้เองโดยไม่ต้องการทำงานของเครื่องหัวใจและปอดเทียม โดยมีขั้นตอนดังนี้

1. ปรับอุณหภูมิร่างกาย สมดุลกรด-เบส อิเล็กโทรไลต์ ค่าออกซิเจนในเลือด ระดับน้ำตาลในเลือด และความเข้มข้นเม็ดเลือดแดงให้อยู่ในระดับปกติ
2. ประเมินการทำงานของหัวใจ เช่น อัตรา จังหวะการเต้น การบีบตัวของหัวใจ
3. ให้ยาต่างๆ และสารน้ำต่างๆ เพื่อช่วยการทำงานของหัวใจ เช่น ยาเพิ่มความดันโลหิต ยาช่วยการบีบตัวของหัวใจ ส่วนประกอบของเลือด สารน้ำ เป็นต้น
4. นำท่อนำเลือดออกจากหัวใจ เพื่อให้หัวใจสามารถทำงานได้เองตามปกติ และให้ยาแก้ฤทธิ์ต้านการแข็งตัวของเลือด

การจัดการระบบหัวใจและปอดเทียมทั้งขั้นตอนการเตรียมวงจร ระหว่างการทำ Cardiopulmonary bypass (CPB) และการหย่าเครื่องแสดงในรูป 2.10



เอกสารนี้เป็นเอกสารรูปที่ 2.10 การจัดการระบบหัวใจและปอดเทียม ทั้งขั้นตอนการเตรียมวงจร ระหว่างการทำ Cardiopulmonary bypass (CPB) และการหย่าเครื่อง

เจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.3 ภาวะแทรกซ้อนที่อาจเกิดขึ้นได้ (Complication)

2.1.3.1 ภาวะแทรกซ้อนชนิด Mechanical การใส่ท่อนำเลือดเข้าไปในหลอดเลือดแดงเออร์ตาและใส่ท่อนำเลือดดำในหัวใจห้องบนขวา อาจทำให้เกิดภาวะเสียเลือดมาก ภาวะ Plaque ภายในหลอดเลือดหลุดกลายเป็นสิ่งแปลกปลอมในกระแสเลือด หรือเกิดจากตำแหน่งของท่อนำหลอดเลือดไม่เหมาะสมทำให้เกิดการฉีกขาดของผนังหลอดเลือดแดงใหญ่ (Aortic dissection) เกิดภาวะอากาศขนาดใหญ่อุดกั้นตามอวัยวะต่าง ๆ (Massive air embolism) จากการจัดการฟองอากาศในระบบที่ไม่เหมาะสม หรือภาวะแทรกซ้อนอื่น ๆ ประกอบด้วย การทำงานของปอดเทียมล้มเหลว หัวปั๊มขัดข้อง เกิดลิ่มเลือดในวงจร สายยางแตก ระบบจ่ายก๊าซล้มเหลว และระบบไฟฟ้าขัดข้อง

2.1.3.2 ภาวะแทรกซ้อนชนิด Systemic การทำ Cardiopulmonary bypass (CPB) มีผลต่อทั้งคุณภาพและปริมาณของเกร็ดเลือด ผลของการเจือจางเลือดขณะทำ ส่งผลต่อระบบการแข็งตัวของเลือด ทำให้เกิดภาวะเสียเลือดมากในระหว่างผ่าตัด กระบวนการกระตุ้นการอักเสบและภาวะความดันโลหิตต่ำ อาจทำให้เกิดการบาดเจ็บต่อการทำงานของไต ภาวะความดันโลหิตสูงเกินไปหรือการหลุดลอยของ Plaque ในหลอดเลือดอาจส่งผลให้เกิด stroke หรือ ความบกพร่องด้านความจำ การที่เลือดสัมผัสกับสิ่งแปลกปลอมจะกระตุ้นกระบวนการอักเสบ ซึ่งอาจทำให้เกิดการบาดเจ็บต่ออวัยวะต่าง ๆ ในร่างกาย ภาวะขาดเลือดในระหว่างผ่าตัดอาจทำให้บาดเจ็บต่อกล้ามเนื้อหัวใจ ส่งผลให้การทำงานของหัวใจบกพร่อง ภาวะวิกฤติทางระบบการหายใจ (Acute respiratory distress syndrome) อาจเกิดขึ้นได้ ดังนั้นการป้องกันการบาดเจ็บของปอดทั้งก่อน ระหว่างและหลังจากผ่าตัดจึงควรให้ความสำคัญ

2.2 การวิเคราะห์ค่า Arterial blood gas ในการรักษาและวินิจฉัย

การตรวจวิเคราะห์ก๊าซในเลือดแดง Arterial blood gas (ABG) เป็นมาตรฐานสำหรับการประเมินออกซิเจน การหายใจ และสถานะกรด-เบสของผู้ป่วย ซึ่งได้รับความสนใจและการศึกษาอย่างแพร่หลาย เช่น

Danny Castro Sachin M. Patil และ Michael Keenaghan (2022) ได้กล่าวว่า การวิเคราะห์ก๊าซในเลือดแดง Arterial blood gas (ABG) เป็นเครื่องมือวินิจฉัยที่ใช้กันทั่วไปในการประเมินความดันบางส่วนของก๊าซในเลือดและปริมาณกรดเบส การทำความเข้าใจและการใช้การวิเคราะห์ก๊าซในเลือดช่วยให้ผู้ให้การรักษาและผู้เกี่ยวข้องสามารถตีความความผิดปกติของระบบทางเดินหายใจ ระบบไหลเวียนโลหิต และการเผาผลาญได้ การเจาะเลือดเพื่อวิเคราะห์ Blood gas สามารถเจาะได้จากทั้งหลอดเลือดแดง หลอดเลือดดำ หรือหลอดเลือดฝอย แต่การตรวจ Blood gas ในหลอดเลือด

แดงจะสามารถบอกสถานะการอิ่มตัวของออกซิเจน (Oxygenation) จากค่า PaO₂ และสถานะการหายใจ (Ventilation) จากค่า PaCO₂ และค่าต่าง ๆ ของ Arterial blood gas[8]

การวิเคราะห์ก๊าซในเลือดแดง Arterial blood gas (ABG) เป็นมาตรฐานสำหรับการประเมินออกซิเจน การหายใจ และสถานะกรด-เบสของผู้ป่วย ค่าต่าง ๆ การแปลผล แลช่วงค่าปกติแสดงดังตารางที่ 2.1

ตารางที่ 2.1 แสดงค่าต่าง ๆ ของ ABG การแปลผล และช่วงค่าปกติ [41]

ค่าต่าง ๆ ของ ABG	การแปลผล	ความสำคัญ	ช่วงค่าปกติ
pH	เป็นการวัดความสมดุลกรด-เบสในเลือด	บ่งบอกความเข้มข้นของไฮโดรเจนไอออน (H ⁺) ในสารละลาย ถ้ามีไฮโดรเจนมากจะเป็นกรด (มีค่า pH ต่ำ) ซึ่งค่า pH ส่งผลต่อกระบวนการเผาผลาญในร่างกาย	7.35-7.45
PaO ₂	เป็นการวัดความดันแบบ partial ของออกซิเจนในเลือดแดง	เป็นออกซิเจนที่ละลายอยู่ในเลือด ซึ่งจะรวมเข้ากับฮีโมโกลบินในเซลล์เม็ดเลือดแดง ถ้าค่า PaO ₂ สูง ฮีโมโกลบินจะจับกับโมเลกุลของออกซิเจนได้อย่างรวดเร็ว	75-100 mmHg
PaCO ₂	เป็นการวัดความดันแบบ partial ของคาร์บอนไดออกไซด์ในเลือดแดง	เป็นค่าพารามิเตอร์ของระบบหายใจ บ่งบอกถึงความสามารถในการระบายอากาศของระบบการหายใจ และมีความสัมพันธ์โดยตรงกับคาร์บอนไดออกไซด์ที่ผลิตจากเซลล์	35-45 mmHg
HCO ₃	เป็นการวัดค่าไบคาร์บอเนตในเลือดแดง	เป็นพารามิเตอร์ของกระบวนการเมตาบอลิซึม เป็นองค์ประกอบของกรดหรือด่างที่ควบคุมโดยไต	22-26 mEq/L
SaO ₂	เป็นการคำนวณความอิ่มตัวของออกซิเจนในเลือดแดง	เป็นออกซิเจนที่จับกับฮีโมโกลบินในเซลล์เม็ดเลือดแดง	95-100%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Arterial blood gas มักได้รับการสั่งตรวจจากแพทย์ฉุกเฉินแพทย์วิกฤต วิชาสูญญีแพทย์ และแพทย์โรคปอด แต่อาจจำเป็นต้องใช้ในสถานการณ์รักษาอื่น ๆ ด้วย หลายโรคสามารถประเมินโดยใช้ Arterial blood gas รวมถึงกลุ่มอาการหายใจลำบากเฉียบพลัน (ARDS), ภาวะติดเชื้อรุนแรง, ช็อกจากการติดเชื้อ, ช็อกจากภาวะ Hypovolemic, ภาวะกรดในท่อไตจากเบาหวาน, ภาวะกรดในท่อไต, การหายใจล้มเหลวเฉียบพลัน, ภาวะหัวใจล้มเหลว, หัวใจหยุดเต้น, โรคหอบหืด และความผิดปกติของการเผาผลาญโดยกำเนิด

ในปี 2014 Oxford Medical Education อธิบายเกี่ยวกับ ABG ว่า ส่วนประกอบของ ABG ประกอบด้วย pH, PaO₂, PaCO₂, Base excess (BE), Bicarbonate (HCO₃), Electrolytes, Lactate, Haemoglobin (Hb), Glucose และค่าอื่น ๆ ประกอบด้วย Carbon monoxide (CO), Methaemoglobin (metHb) [9]

การชดเชยค่าความเป็นกรด-เบส (Compensate) โดยปกติค่า pH ในร่างกายมนุษย์จะถูกควบคุมและมีกลไกต่าง ๆ ในการรักษาให้อยู่ในค่าปกติ สิ่งสำคัญคือต้องสังเกตว่าร่างกายไม่วันชดเชยมากเกินไป ซึ่งการชดเชยมี 2 แบบคือ ชดเชยทางการหายใจ (Respiratory Compensation) และชดเชยทางเมตาบอลิก (Metabolic Compensation)

การแปลผลค่า ABG สามารถทำได้ ดังนี้

1. ตรวจสอบประวัติผู้ป่วยและทวนสอบผลการตรวจต่าง ๆ
2. PaO₂ มีค่าเท่าไร – สามารถประเมินได้ว่าผู้ป่วยได้รับออกซิเจนเท่าใดเมื่อได้รับก๊าซ
3. ค่า pH มีค่าเท่าไร ผู้ป่วยเป็นภาวะเลือดเป็นกรดหรือต่าง
4. PaCO₂ มีค่าเท่าไร
5. HCO₃ และเบสส่วนเกินมีค่าเท่าไร
6. ผู้ป่วยได้รับการชดเชยหรือไม่
7. ค่าอื่น ๆ มีค่าเท่าไร ตรวจสอบให้แน่ใจดูตัวเลขอื่น ๆ ทั้งหมดบนผล Arterial

blood gas

ในปี 2010 Abhishek K Verma และ Paul Roach อธิบายความสัมพันธ์ของ Arterial blood gas กับอาการทางคลินิกต่าง ๆ พร้อมอธิบายรายละเอียดความแตกต่างของความไม่สมดุล 2 ประเภทคือ ความไม่สมดุล Metabolic และความไม่สมดุล Respiratory ซึ่ง ความไม่สมดุล Metabolic แบ่งเป็น ความเป็นกรด Metabolic (Metabolic acidosis) และ ความเป็นเบส Metabolic (Metabolic alkalosis) สำหรับความไม่สมดุล Respiratory แบ่งเป็น ความเป็นกรด Respiratory (Respiratory acidosis) และ ความเป็นเบส Respiratory (Respiratory alkalosis) พร้อมทั้งอธิบายอาการแสดงที่เกิดขึ้นของภาวะต่าง ๆ รวมถึงสาเหตุส่วนใหญ่ที่ทำให้เกิดภาวะผิดปกติเหล่านั้น [10] ตารางที่ 2.2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.2 แสดงความสัมพันธ์ของ Arterial blood gas กับอาการทางคลินิกต่าง ๆ ซึ่งถ้าค่า pH ต่ำลงจะเรียกว่า acidosis หรือ ภาวะเป็นกรด, pH สูงขึ้นจะเรียกว่า alkalosis หรือภาวะเป็นเบส

	ความไม่สมดุล Metabolic		ความไม่สมดุล Respiratory	
	ความเป็นกรด Metabolic (Metabolic acidosis)	ความเป็นเบส Metabolic (Metabolic alkalosis)	ความเป็นกรด Respiratory (Respiratory acidosis)	ความเป็นเบส Respiratory (Respiratory alkalosis)
pH	↓	↑	↓	↑
PaCO ₂	N (ไม่ชดเชย) ↓ (ชดเชย)	N (ไม่ชดเชย) ↑ (ชดเชย)	↑	↓
HCO ₃	↓	↑	N (ไม่ชดเชย) ↑ (ชดเชย)	N (ไม่ชดเชย) ↓ (ชดเชย)
Base excess	↓	↑	N/↑	N/↓
อาการ แสดงทาง คลินิก	ชนิดการหายใจแบบ Kussmaul - หายใจลึกและเร็วเกินไป - ภาวะช็อคหรือ coma	Paraesthesia, tetany, อ่อนแรง	เฉื่อยเพลี่ยน : หายใจแบบ air hunger, ภาวะ สับสน เรื้อรัง : หายใจช้า , ชขาด, ออกซิเจน, ภาวะเขียว จากขาดออกซิเจน	เฉื่อยเพลี่ยน: หายใจเร็ว , paraesthesia, เวียน ศีรษะเรื้อรัง : หายใจเร็ว tetany ผมง
สาเหตุ ส่วนใหญ่	Anion gap เพิ่ม: ketoacidosis จาก เบาหวาน , lactic acidosis, สารพิษ , ได้รับ ยาเกินขนาด anion gap ปกติ: ท้องร่วง, การหลั่ง adenomas, พิษ แอมโมเนียมคลอไรด์, ไต อักเสบ, กรดไนโทอไต, ได้รับ acetazolamide	อาเจียน, การได้ยาขับ ปัสสาวะหรือสเตียรอยด์ ที่ทำให้เสียโพแทสเซียม เป็นเวลานาน โรคร Cushing, การใช้ยาไซเดียมโบ คาร์บอนเนตเกินขนาด (เช่น ยาลดกรด)	ภาวะหายใจช้า : โรคร ปอดเรื้อรังที่เกิดการคั่ง ของ CO ₂ , ได้รับยากด การหายใจ, โรครหอบหืด รุนแรง, ปอดบวมน้ำ	การหายใจเร็วเกินไปที่ เกิดจากความกังวล, ความเจ็บปวด, ไข้, ชขาด ออกซิเจน, เส้นเลือดอุด ตันที่ปอด, การตั้งครรภ์, ภาวะติดเชื้
N = อยู่ในช่วงปกติ ↑ = เพิ่มขึ้น ↓ = ลดลง				

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3 การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่อง (Machine learning) คือหนึ่งในศาสตร์ของสาขา AI (Artificial Intelligence) และ Computer Science โดยจะเน้นที่กระบวนการให้ระบบคอมพิวเตอร์สามารถเรียนรู้ได้ด้วยตนเองด้วยกระบวนการใส่ข้อมูล (Data) ร่วมกับผลลัพธ์ (Output) เข้าไปเพื่อให้ตัวโปรแกรมคอมพิวเตอร์เกิดการเรียนรู้ผ่านวิธีการทางสถิติทำให้สามารถทำนายได้ว่าหากในอนาคตมีข้อมูลในลักษณะนี้เกิดขึ้นจะส่งผลให้เกิดผลลัพธ์เหมือนกับข้อมูลที่โปรแกรมคอมพิวเตอร์ได้ทำการเรียนรู้ไปก่อนหน้านี้แล้ว ดังนั้นการเรียนรู้ของเครื่องจึงเป็นเครื่องมือชนิดหนึ่งซึ่งช่วยให้นักวิทยาศาสตร์ ข้อมูล สามารถวิเคราะห์ แก้ปัญหาและหาคำตอบจากข้อมูลจำนวนมากโดยไม่ต้องสร้างโปรแกรมใหม่ทุกครั้ง แต่จะเป็นการใส่ข้อมูลต่าง ๆ เพื่อให้คอมพิวเตอร์สามารถวิเคราะห์แทนได้เลย ซึ่งสามารถแบ่งออกได้เป็น 3 รูปแบบได้แก่

2.3.1 การเรียนรู้แบบมีผู้สอน (Supervised learning)

เป็นประเภทการเรียนรู้ของคอมพิวเตอร์โดยใส่ข้อมูล (Data) และผลลัพธ์ (Output) เพื่อให้คอมพิวเตอร์เกิดการเรียนรู้ผ่านโมเดลการเรียนรู้ เรียกข้อมูลชุดนี้ว่าชุดข้อมูลชุดฝึก (Training Dataset) และสร้างตัวแบบ (Model) การเรียนรู้ขึ้น เมื่อได้โมเดลการเรียนรู้แล้ว จึงนำข้อมูลชุดใหม่ที่คอมพิวเตอร์ไม่รู้จัก นำมาเป็นข้อมูล Input เพื่อให้โมเดลทำนายเป็นผลลัพธ์ออกมา ตัวอย่างเช่น Regression และ Classification

2.3.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning)

เป็นลักษณะของการเรียนรู้แบบที่ไม่มีการกำหนดผลลัพธ์ของข้อมูล แต่เป็นการให้ข้อมูล (Data) กับคอมพิวเตอร์ และกำหนดสิ่งที่ต้องการจากข้อมูลเหล่านั้น โดยคอมพิวเตอร์จะวิเคราะห์ จำแนกและสร้างแบบแผนจากข้อมูลที่ได้รับ เพื่อทำนายเป็นผลลัพธ์ออกมา ตัวอย่างเช่น Clustering

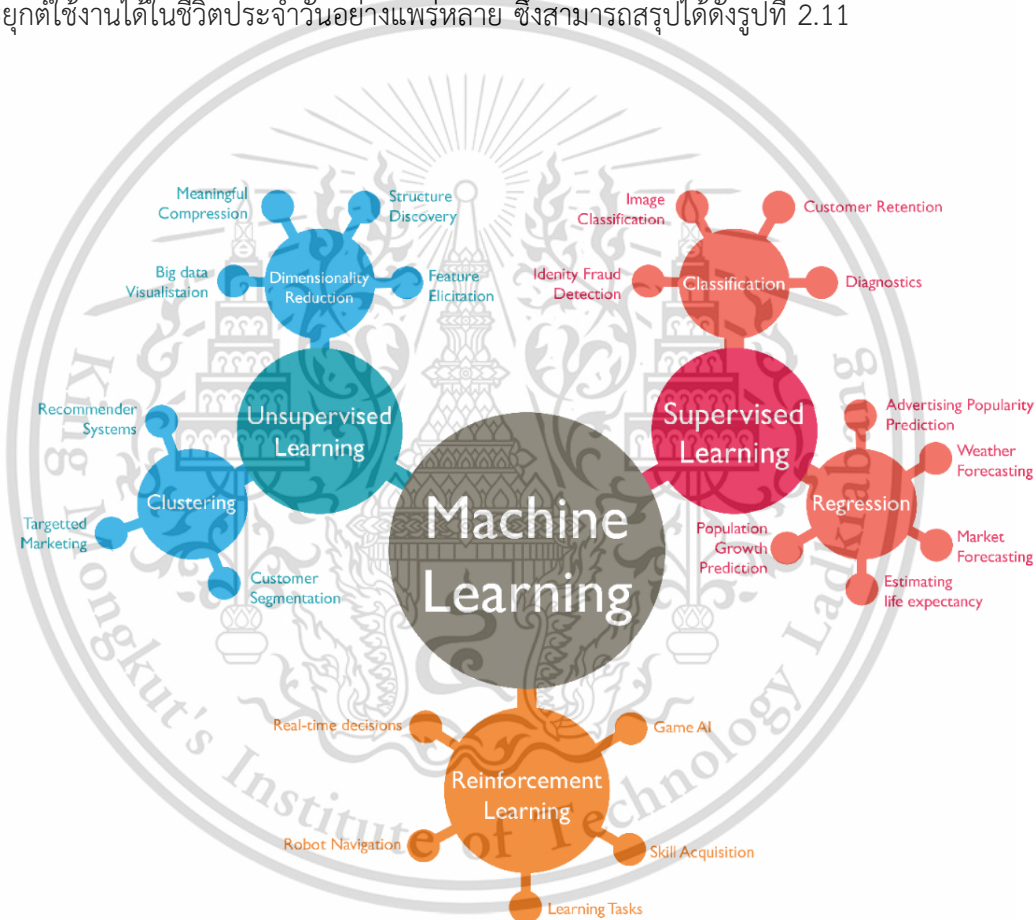
2.3.3 การเรียนแบบเสริมกำลัง (Reinforcement learning)

การเรียนรู้จากการลองผิดลองดีโดย เลือกกระทำสิ่งที่ทำให้ได้ผลลัพธ์มากที่สุด โดยเรียนรู้จากการลองผิดลองถูกจากสถานการณ์ในอดีตหรือระบบจำลอง และพยายามพัฒนาระบบการตัดสินใจของคอมพิวเตอร์ให้ดีขึ้นเรื่อย ๆ ด้วยการพยายามสร้างแบบจำลองสถานการณ์ต่าง ๆ ตัวอย่างเช่นคือ AlphaGo ที่สามารถเล่นเกมโกะให้ชนะผู้เล่นระดับโลกได้ [11,12,13]

นอกจากนี้การเรียนรู้ของเครื่องยังมีชุดข้อมูลที่เกี่ยวข้องสำหรับการสร้างโมเดลด้วย ซึ่งประกอบด้วย

1. ชุดข้อมูลสำหรับฝึก (Training dataset) เป็นชุดข้อมูลสำหรับฝึกให้คอมพิวเตอร์หรือโมเดลเรียนรู้
2. ชุดข้อมูลสำหรับตรวจสอบความถูกต้อง (Validation dataset) เป็นชุดข้อมูลสำหรับวัดประสิทธิภาพของโมเดลเมื่อมีการปรับตั้งพารามิเตอร์ในแต่ละครั้ง
3. ชุดข้อมูลสำหรับการทดสอบ (Test dataset) เป็นชุดข้อมูลสำหรับทดสอบประสิทธิภาพการทำนายผลของโมเดล ซึ่งเป็นข้อมูลที่โมเดลไม่รู้จักมาก่อน

ปัจจุบันเทคโนโลยีการเรียนรู้ของเครื่อง (Machine learning) ถูกพัฒนาและนำมาประยุกต์ใช้งานได้ในชีวิตประจำวันอย่างแพร่หลาย ซึ่งสามารถสรุปได้ดังรูปที่ 2.11




รูปที่ 2.11 ประเภทการเรียนรู้ของ Machine learning [42]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 วิธีการค้นหาเพื่อนบ้านใกล้ที่สุด k ตัว (K-Nearest Neighbors)

วิธีการค้นหาเพื่อนบ้านใกล้ที่สุด k ตัว (K-Nearest Neighbors) หรือ KNN หรือ k-NN เป็นวิธีการแบ่งกลุ่มสำหรับใช้จัดหมวดหมู่ข้อมูล (Classification) โดยอัลกอริทึม K-Nearest Neighbors (KNN) จะจำแนกประเภทข้อมูลใหม่โดยอิงถึงข้อมูลที่ใกล้ที่สุดกับข้อมูลทดสอบ เพื่อคาดเดาหรือจำแนกประเภทข้อมูลใหม่ ดังรูปที่ 2.12

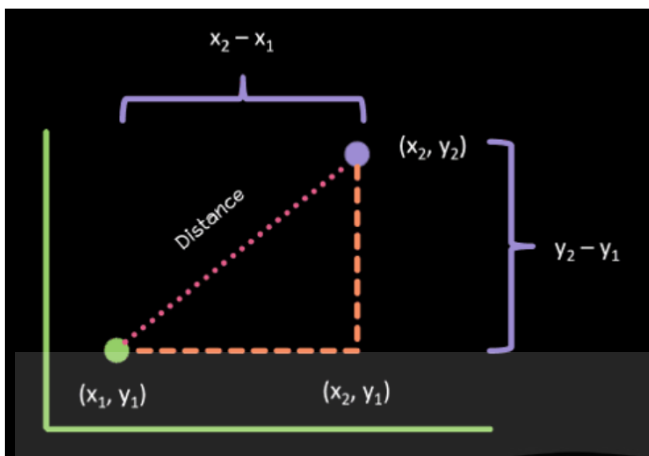


รูปที่ 2.12 หลักการของ K-Nearest Neighbors (KNN) [43]

อัลกอริทึมนี้สนับสนุนการเรียนรู้เชิงกระบวนการ (Instance-based learning) ซึ่งมีขั้นตอนการเรียนรู้ที่ไม่ซับซ้อน แต่จะใช้ข้อมูลที่มีอยู่เพื่อตัดสินใจในการจัดกลุ่มหรือจำแนกประเภทข้อมูลใหม่ โดยสามารถสรุปได้ดังนี้

1. เลือกค่า K โดยกำหนดค่า K ที่ต้องการ ซึ่งเป็นจำนวนของข้อมูลที่ใกล้ที่สุดที่จะใช้ในการตัดสินใจ ค่า K นี้มีผลต่อความถูกต้องและความสามารถในการทำนายของโมเดล

2. คำนวณระยะทาง ในกระบวนการ KNN ส่วนใหญ่ใช้ระยะทางยูคลิดีเนียน (Euclidean distance) เพื่อคำนวณระยะทางระหว่างข้อมูลทดสอบกับข้อมูลในชุดข้อมูลการฝึก ระยะทางนี้จะวัดความคล้ายคลึงของคุณสมบัติระหว่างข้อมูล โดยนิยมใช้การหาระยะทางที่เรียกว่า Euclidean Distance ในการช่วยหาว่าข้อมูลที่ต้องการใกล้กับข้อมูลประเภทไหนมากกว่า โดย Euclidean Distance มีสมการดังรูป 2.13




Formula

$$a^2 + b^2 = c^2$$

a = side of right triangle

b = side of right triangle

c = hypotenuse



เมื่อเราต้องการหาระยะทางจากจุด (x_1, y_1) ไป (x_2, y_2) โดยกำหนดให้ d แทนระยะทาง จะได้ว่า $d^2 = (x_2 - x_1)^2 + (y_2 - y_1)^2$

$$\text{ดังนั้น } d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

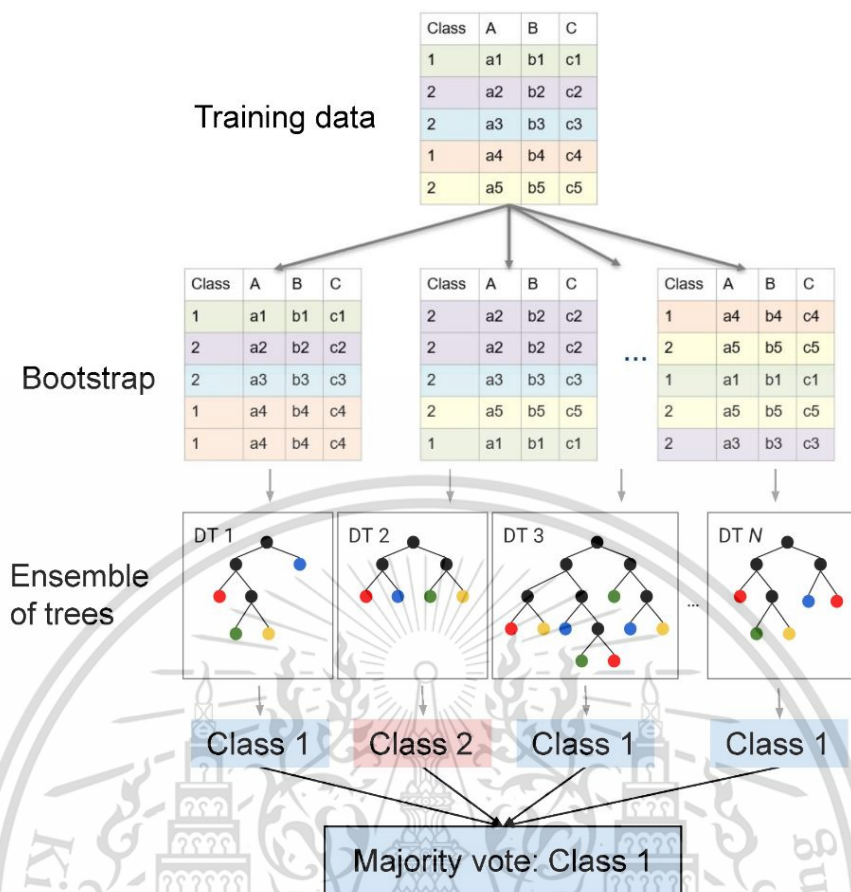
รูปที่ 2.13 การหาระยะทาง Euclidean distance [14]

3. หาข้อมูลที่ใกล้ที่สุด หลังจากคำนวณระยะทางระหว่างข้อมูลทดสอบกับข้อมูลในชุดข้อมูลการฝึกแล้ว จะเลือกข้อมูล K รายการที่มีระยะทางน้อยที่สุด
4. คำนวณผลโหวต เมื่อ ได้ข้อมูล K รายการที่ใกล้ที่สุดแล้ว จะนับจำนวนรายการในแต่ละกลุ่มหรือประเภทข้อมูล และกำหนดกลุ่มหรือประเภทข้อมูลของข้อมูลทดสอบตามจำนวนที่มากที่สุด ใน K รายการนั้น
5. ทำนายผลลัพธ์ สุดท้ายจะใช้กลุ่มหรือประเภทข้อมูลที่ได้มาจากขั้นตอนก่อนหน้านี้ในการทำนายผลลัพธ์ของข้อมูลทดสอบ [14,15]

2.5 Random forest

Random forest เป็น Machine Learning วิธีหนึ่งที่น่าิยมใช้และมีประสิทธิภาพดีกับทั้งปัญหาแบบ Regression และ Classification โดยมีหลักการทำงานที่พัฒนามาจาก Decision tree คือ แบ่งข้อมูลออกเป็นต้นไม้ตัดสินใจหลาย ๆ ต้น โดยแต่ละต้นจะได้รับคุณลักษณะ (Feature) และข้อมูล (Data) ที่ไม่เหมือนกันทั้งหมด เพื่อให้ได้ต้นไม้ที่มีความหลากหลายและมีความอิสระต่อกันมากขึ้น เพื่อให้โมเดลมีประสิทธิภาพและการทำนายผลลัพธ์สูงขึ้น ซึ่งหลักการทำงานของ Random forest แสดงดังรูปที่ 2.14

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.14 หลักการของ Random forest [44]

อัลกอริทึมของ Random forest ใช้วิธี Ensemble Learning ซึ่งคือการรวมของโมเดลการเรียนรู้ที่หลากหลาย มีความแตกต่างและมีอิสระต่อกัน เข้าด้วยกัน เพื่อเพิ่มประสิทธิภาพของโมเดล โดยจะสร้างต้นไม้ตัดสินใจหลาย ๆ ต้นโดยการใช้เทคนิค Bagging ซึ่งสามารถสุ่มเลือกข้อมูลรายการเดียวกันได้ ช่วยลด Variance ของโมเดลได้ดี เพราะการเลือกรายการข้อมูลซ้ำ ทำให้ได้โมเดลเสถียรมากกว่าและมักจะแม่นยำกว่า โดยการทำงานของ Random forest มีขั้นตอนดังนี้

1. อัลกอริทึม สุ่มเลือกคุณลักษณะ (Feature) และข้อมูล (Data) จากชุดข้อมูลทั้งหมดที่มี
2. อัลกอริทึมสร้างต้นไม้ตัดสินใจจากชุดข้อมูลตัวอย่างแต่ละชุด ด้วยเทคนิค Bagging และหาค่าทำนายเพื่อหาผลลัพธ์จากต้นไม้ตัดสินใจแต่ละต้น

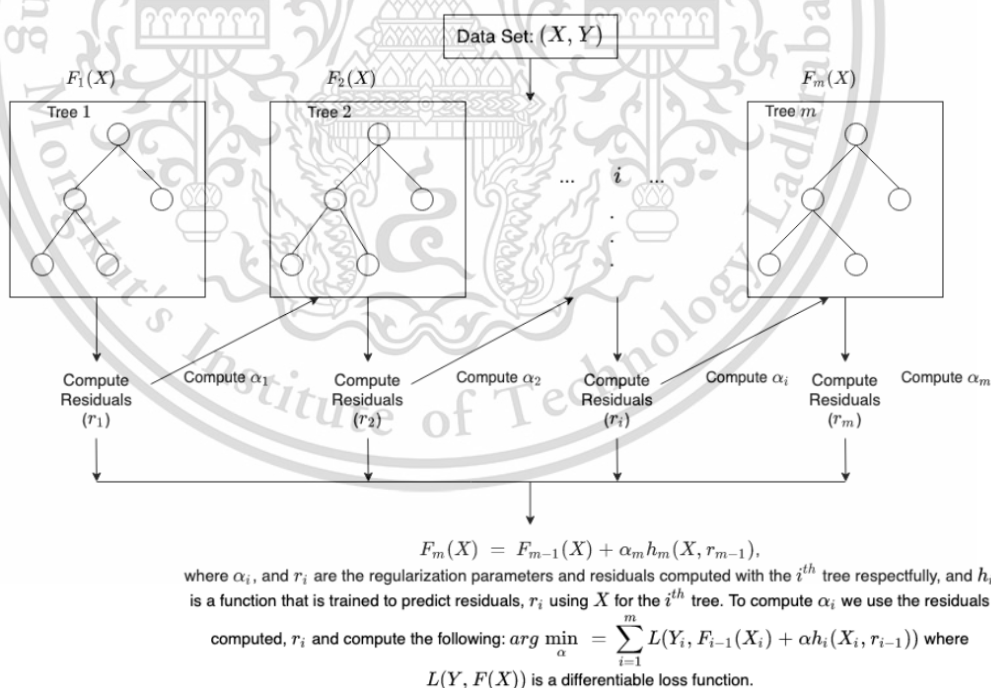
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. เลือกจำนวนต้นไม้ตัดสินใจที่ต้องการ แล้วทำซ้ำในขั้นตอนที่ 1 และ 2 เพื่อสร้างต้นไม้ตัดสินใจ

4. อัลกอริทึมหาผลลัพธ์จากค่าทำนาย สำหรับปัญหาแบบ Classification จะใช้วิธีผลโหวตมากที่สุด (Majority vote) โดยค่าทำนายของต้นไม้ตัดสินใจกลุ่ม (Class) ที่ได้รับค่าผลโหวตมากที่สุด จะถูกเลือกเป็นค่าทำนายและเป็นผลลัพธ์ของปัญหา และปัญหาแบบ Regression จะใช้วิธีคำนวณหาค่าเฉลี่ย (Mean) โดยนำค่าทำนายของทุกต้นไม้ตัดสินใจมาคำนวณหาค่าเฉลี่ยเพื่อแสดงเป็นค่าทำนายและเป็นผลลัพธ์ของปัญหา [16,17]

2.6 eXtreme Gradient Boosting (XGBoost)

eXtreme Gradient Boosting (XGBoost) เป็นเทคนิคที่พัฒนามาจาก Gradient boosting ซึ่ง XGBoost เป็นโมเดลที่นำต้นไม้ตัดสินใจมาฝึกสอนต่อกันหลาย ๆ ต้น โดยที่ต้นไม้ตัดสินใจแต่ละต้นจะเรียนรู้จากค่าความผิดพลาดของต้นก่อนหน้า ซึ่งทำให้ความแม่นยำในการทำนายจะมากขึ้นเรื่อย ๆ เมื่อมีการเรียนรู้ของต้นไม้ตัดสินใจต่อเนื่องกันจนมีความลึกมากพอ แบบจำลองจะหยุดเรียนรู้เมื่อไม่เหลือค่าความผิดพลาดจากต้นไม้ ตัดสินใจต้นก่อนหน้าให้เรียนรู้แล้วซึ่งแสดงได้ดังรูปที่ 2.15



รูปที่ 2.15 หลักการของ eXtreme Gradient Boosting (XGBoost) [45]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัลกอริทึมของ XGBoost ใช้วิธี Ensemble learning เช่นกัน โดยใช้เทคนิค Boosting คือการเรียนรู้เป็นลำดับ โดยแต่ละตัวจะแก้ไขจุดด้อยของ Classifier ตัวก่อนหน้า หลังจากนั้น Classifier ทุกตัวจะหาค่าทำนายร่วมกัน ซึ่งมีขั้นตอนดังนี้

1.อัลกอริทึม Boosting จะกำหนดน้ำหนักที่เท่ากันให้กับตัวอย่างข้อมูลแต่ละรายการ ซึ่งจะป้อนข้อมูลไปยังโมเดลแมชชีนตัวแรกที่เรียกว่าอัลกอริทึมพื้นฐาน จากนั้นอัลกอริทึมพื้นฐานจะดำเนินการทำนายสำหรับตัวอย่างข้อมูลแต่ละรายการ

2.อัลกอริทึม Boosting จะประเมินการทำนายของโมเดลและเพิ่มน้ำหนักของตัวอย่างด้วยข้อผิดพลาดที่มีนัยสำคัญมากขึ้น นอกจากนี้ยังกำหนดน้ำหนักตามประสิทธิภาพของโมเดลด้วย โดยโมเดลที่ให้ผลการทำนายที่ดีที่สุดจะมีอิทธิพลอย่างมากต่อการตัดสินใจขั้นสุดท้าย

3.อัลกอริทึมจะส่งข้อมูลถ่วงน้ำหนักไปยังต้นไม้ตัดสินใจถัดไป

4.อัลกอริทึมจะทำซ้ำขั้นตอนที่ 2 และ 3 จนกว่ากรณีตัวอย่างของข้อผิดพลาดในการฝึกฝนจะต่ำกว่าเกณฑ์ที่กำหนด

สำหรับ XGBoost นั้นมีการพัฒนาจาก Gradient boosting ซึ่งโมเดลมีความสามารถเพิ่มขึ้นคือ มีการทำ Regularization ทำให้สามารถลดการเกิด Overfit ได้ นอกจากนี้โมเดลยังสามารถจัดการกับ missing value ได้โดยอัตโนมัติ สามารถทำงานแบบขนานกับจำนวน core ของ cpu ได้ ทำให้ใช้ hardware อย่างมีประสิทธิภาพ [18,19,20]

2.7 การเรียนรู้เชิงลึก (Deep learning)


การเรียนรู้เชิงลึกเป็นรูปแบบหนึ่งของ Machine learning โดยมีวิธีการเรียนรู้แบบอัตโนมัติด้วยการเลียนแบบการทำงานของโครงข่ายประสาทของมนุษย์ (Neurons) โดยนำระบบโครงข่ายประสาท (Neural Network) มาซ้อนกันหลายชั้น (Layer) และทำการเรียนรู้ข้อมูลตัวอย่าง ซึ่งข้อมูลดังกล่าวจะถูกนำไปใช้ในการตรวจจบบรรูปแบบ (Pattern) ,คุณลักษณะ (Feature) หรือจัดหมวดหมู่ข้อมูล (Classify the Data) ซึ่ง Neuron ในโครงข่ายประสาท ถูกแบ่งเป็น 3 กลุ่มได้แก่

1. ชั้นข้อมูลนำเข้า (Input layer) จะเป็นตัวรับข้อมูล โดยแต่ละ Neuron ใน Input layer จะทำการส่งข้อมูลไปให้ Neuron ในชั้นซ่อน (hidden layer)

2. ชั้นซ่อน (Hidden layers) จะทำการเรียนรู้ข้อมูลที่ได้รับมาจาก Layer ก่อนหน้า โดยวิธีการทางคณิตศาสตร์ และส่งไปยัง Layer ชั้นถัดไป

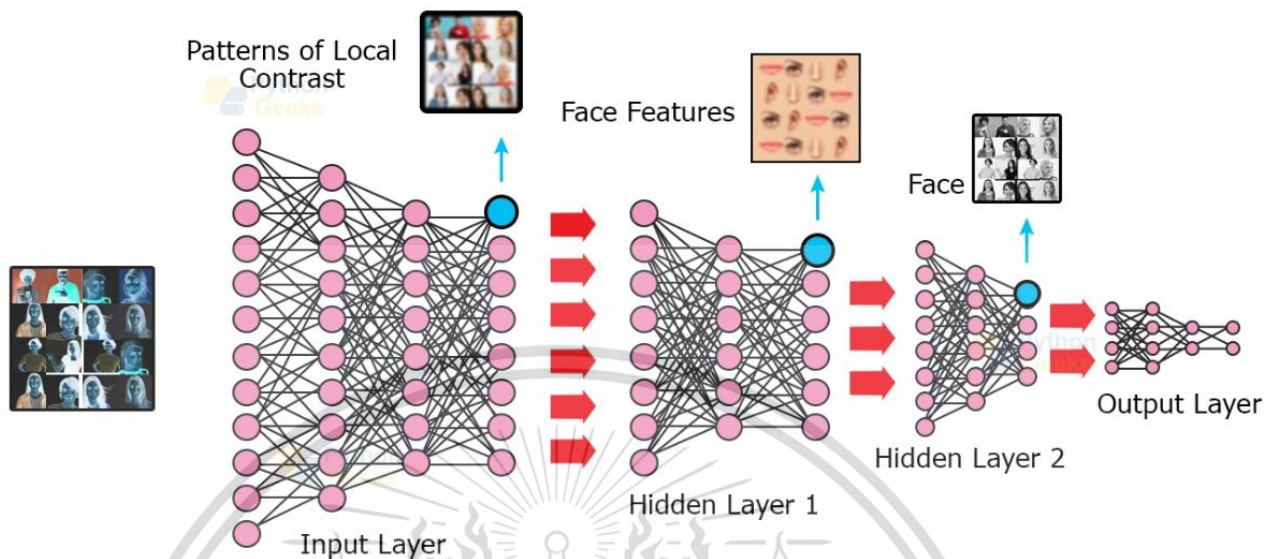
3. ชั้นข้อมูลออก (Output layer) จะให้ผลลัพธ์ของการทำนายออกมา

จากรูปที่ 2.16 จะเห็นว่า Simple Neural Network นั้นประกอบไปด้วย ชั้นข้อมูลนำเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นข้อมูลออก (Output layer) ซึ่ง Simple Neural Network มีชั้นซ่อน (Hidden layer) เพียงชั้นเดียว สำหรับ Deep learning นั้นมี Hidden layer มากกว่า 1 ชั้น



รูปที่ 2.16 ความแตกต่างของ Simple Neural Network และ Deep learning [46]

เนื่องจาก Deep learning มีจุดเด่น คือการสกัดคุณลักษณะ (Feature Extraction) หรือ การคัดแยกคุณลักษณะเด่นออกมาจากข้อมูลได้ ดังรูปที่ 2.17 และยังสามารถประมวลผลในข้อมูลที่มีความซับซ้อนได้ดี จึงนิยมนำมาประยุกต์ใช้กันอย่างแพร่หลาย เช่น งานด้านการวิเคราะห์รูปภาพ การสร้างรูปภาพขึ้นมาใหม่จากรูปภาพเดิม การจดจำใบหน้าของมนุษย์ การวิเคราะห์ภูมิศาสตร์จากภาพถ่ายทางดาวเทียม การวิเคราะห์ความน่าจะเป็นของการเป็นโรค COVID19 จากภาพถ่าย X-ray เป็นต้น [21,22,23,24]




รูปที่ 2.17 การสกัดคุณลักษณะ (Feature Extraction) ของโมเดล Deep learning [47]

2.8 การแก้ไขปัญหาชุดข้อมูลไม่สมดุลด้วยเทคนิค Synthetic Minority Over-sampling Technique (SMOTE)

บ่อยครั้งในการศึกษาทางวิทยาการข้อมูล ปัญหาที่อาจพบได้คือชุดข้อมูลที่ไม่สมดุล (Imbalance dataset) ซึ่งอาจส่งผลกระทบต่อกระบวนการทางข้อมูลในขั้นตอนต่อ ๆ ไปได้ จึงต้องมีการแก้ปัญหานี้ เทคนิคที่มักนำมาใช้อย่างกว้างขวางสำหรับการจัดการกับชุดข้อมูลที่ไม่สมดุล เรียกว่าเทคนิค Resampling ประกอบด้วยการ Remove ตัวอย่างออกจาก Majority Class (Undersampling) และ/หรือ เพิ่มตัวอย่างเพิ่มเติมจาก Minority Class (Oversampling) ดังรูปที่ 2.18


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

• Random Undersampling และ Oversampling



รูปที่ 2.18 เทคนิคการ Resampling สำหรับชุดข้อมูลที่ไม่สมดุล (Imbalance dataset) [48]

Synthetic Minority Over-sampling Technique (SMOTE) เป็นเทคนิคการ Resampling แบบ Oversampling ซึ่งเป็นวิธีสังเคราะห์หรือสร้างสมาชิกใหม่ขึ้นมาในชุดข้อมูล ซึ่งอ้างอิงจากสมาชิกหรือกลุ่มสมาชิกที่อยู่ใกล้เคียงกัน (Nearest Neighbors) เพื่อป้องกันการเกิด Over fitting [25] ดังรูปที่ 2.19



รูปที่ 2.19 เทคนิค Synthetic Minority Over-sampling Technique (SMOTE) [48]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.9 งานวิจัยที่เกี่ยวข้องกับการใช้ปัญญาประดิษฐ์และ Machine Learning ในการวิเคราะห์และแปลผล ABG

ในปัจจุบันมีการนำเทคโนโลยีด้านเทคโนโลยีสารสนเทศมาช่วยจัดการข้อมูลทางด้านการแพทย์และสาธารณสุขเพิ่มมากขึ้น เพื่อให้การวินิจฉัยมีความถูกต้องและลดเวลาในการแปลผลจากการทบทวนวรรณกรรมพบว่า มีผู้สนใจและนำเทคนิคต่าง ๆ มาใช้กับการแปลผลค่าก๊าซในเลือดแดง เช่น

Wiesław Wajs, Piotr Wais, Marcin Ochab และ Hubert Wojtowicz (2016) ทำการวิจัยโดยโมเดลจำลองโครงข่ายประสาทเทียมมาช่วยสร้างแบบจำลองการทำนายและคาดการณ์การที่ดีที่สุดของปริมาณก๊าซต่างๆในเลือดแดง ซึ่งมีการเปลี่ยนแปลงตลอดเวลาในขณะที่เข้ารับการรักษา โดยใช้พารามิเตอร์ 4 ตัว คือ pH, pO_2 , pCO_2 , HCO_3 ภายใน 72 ชั่วโมง ซึ่งมีการทำ Optimization 4 วิธี คือ Levenberga-Marquardt, Gradient descent, Back propagation และ Davidon-Fletcher-Powell ซึ่งใช้วิธี ANN และหยุดการเรียนรู้ที่ 100 epochs หรือ ค่าความคาดเคลื่อนการเรียนรู้ต่ำกว่า 10^{-7} พบว่า โมเดลจำลองโครงข่ายประสาทเทียมแบบสองชั้นมีประสิทธิภาพเหนือกว่าแบบจำลองโครงข่ายประสาทเทียมแบบสามชั้น[26]

S. Kajanan และคณะ (2022) ได้ทำการวิจัยเพื่อหาโมเดลที่มีความแม่นยำที่สุดในการวินิจฉัยและระบุชนิดของภาวะการหายใจล้มเหลวโดยใช้การแปลผล ABG ซึ่งประกอบด้วย Extreme Gradient Boosting (XGBoost), Adaptive Boosting (AdaBoost), Catboost, Random Forest, Naïve Bayes, Support Vector Machine (SVM), LightGBM, K-Nearest Neighbors (KNN), Neural Network (NN) and Decision Tree โดยเป็นข้อมูลของผู้ป่วย 700 รายในประเทศศรีลังกา มีการทำ Cross Validation 5 Folds พบว่าวิธี XGBoost เป็นโมเดลที่ทำนายได้แม่นยำที่สุด มีค่า Accuracy 98.45 % และค่าความคาดเคลื่อน 1.55 % [27]

Milad Shayan และคณะ (2020) ได้ทำการทดลองเพื่อใช้โมเดลจำลองโครงข่ายประสาทเทียมในการประมาณค่าและทำนายผล ABG โดยเก็บข้อมูลจากผู้ป่วยจากอุบัติเหตุ 2280 ราย ซึ่งส่วนใหญ่ต้องได้รับการรักษาอย่างเร่งด่วน เพื่อลดระยะเวลาการตรวจและลดค่าใช้จ่ายและไม่ต้องเจาะเลือดหลายครั้ง โดยใช้โมเดล Feed-Forward Backpropagation Neural Network (FBPNN) ด้วย 5 Input , 3 Output และ 40 Neurons พบว่า มีค่า Accuracy ที่ดี คือ 87.92% Accuracy ในการทำนายค่า ABG Accuracy ในการทำนาย pH, PCO_2 และ HCO_3 คือ 99.06%, 80.27%, 84.43% ตามลำดับ [28]

ในส่วนของงานวิจัยที่เกี่ยวข้องกับการใช้ปัญญาประดิษฐ์และ Machine learning ในการวิเคราะห์และแปลผล ABG นั้น สามารถสรุปผลภาพรวมของทบทวนวรรณกรรมที่เกี่ยวข้องได้ดังตารางที่ 2.3

ตารางที่ 2.3 แสดงการสรุปผลภาพรวมของทบทวนวรรณกรรมที่เกี่ยวข้อง

ชื่อวรรณกรรม	ผู้แต่ง	โมเดลที่ใช้	การตั้งค่าต่าง ๆ	ผลการวิจัย
Arterial Blood Gases Forecast Optimization by Artificial Neural Network Method	Wiesław Wajs, Piotr Wais, Marcin Ochab และ Hubert Wojtowicz	ANN	<i>Optimization:</i> Levenberga-Marquardt, Gradient descent, Back propagation และ Davidon-Fletcher-Powell อื่น ๆ : 100 epochs, ค่าความคาดเคลื่อนการเรียนรู้ต่ำกว่า 10^{-7}	โครงข่ายประสาทเทียมแบบสองชั้นมีประสิทธิภาพเหนือกว่าแบบจำลองโครงข่ายประสาทเทียมแบบสามชั้น
Classify the Outcome of Arterial Blood Gas Test to Detect the Respiratory Failure Using Machine Learning	S. Kajanan และคณะ	Extreme Gradient Boosting (XGBoost), Adaptive Boosting (AdaBoost), Catboost, Random Forest, Naïve Bayes, Support Vector	Cross Validation 5 Folds	XGBoost เป็นโมเดลที่ทำนายได้แม่นยำที่สุด มีค่า Accuracy 98.45 % และค่าความคาดเคลื่อน 1.55 %

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.3 แสดงการสรุปผลภาพรวมของทบทวนวรรณกรรมที่เกี่ยวข้อง (ต่อ)

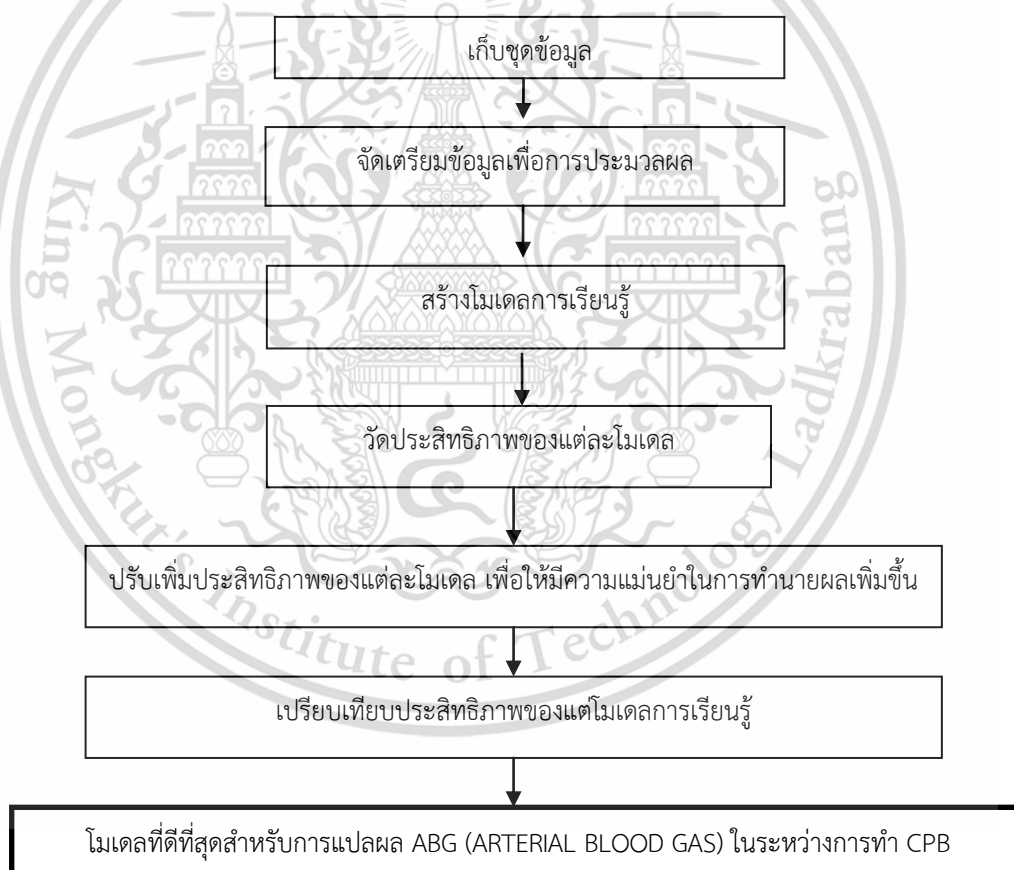
ชื่อวรรณกรรม	ผู้แต่ง	โมเดลที่ใช้	การตั้งค่าต่าง ๆ	ผลการวิจัย
		Machine (SVM), LightGBM, K- Nearest Neighbors (KNN), Neural Network (NN) and Decision Tree		
Use of artificial intelligence and neural network algorithms to predict arterial blood gas items in trauma victims	Milad Shayan และคณะ	Feed-Forward Backpropagation Neural Network (FBPNN)	5 Input , 3 Output และ 40 Neurons	ค่า Accuracy ที่ดีคือ 87.92% Accuracy ในการทำนายค่า ABG Accuracy ในการทำนาย pH, PCO2 และ HCO3 คือ 99.06%, 80.27%, 84.43% ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

วิธีดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงการดำเนินการวิจัยในการนำ AI มาใช้ในการแปลผล Arterial blood gas (ABG) ในระหว่างการผ่าตัดหัวใจ ที่มีการใช้เครื่องหัวใจและปอดเทียมร่วมด้วยในขณะผ่าตัด โดยในการศึกษานี้ นำการเรียนรู้ของเครื่อง (Machine learning) มาใช้ โดยมีขั้นตอนในการดำเนินงานวิจัย 6 ขั้นตอน คือ การเก็บชุดข้อมูล การเตรียมข้อมูลเพื่อการประมวลผล การสร้างโมเดลการเรียนรู้ วัดประสิทธิภาพของแต่ละโมเดล และปรับปรุงประสิทธิภาพของแต่ละโมเดล เพื่อให้มีความแม่นยำในการทำนายผลเพิ่มขึ้น และเปรียบเทียบประสิทธิภาพของแต่ละโมเดลการเรียนรู้ เพื่อให้ได้โมเดลที่ดีที่สุดสำหรับการแปลผล Arterial blood gas (ABG) ในระหว่างการใช้เครื่องหัวใจและปอดเทียม (Cardiopulmonary bypass - CPB) ซึ่งมีขั้นตอนดังรูปที่ 3.1



รูปที่ 3.1 ขั้นตอนการดำเนินงานวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1 การเก็บชุดข้อมูล

การเก็บชุดข้อมูล เก็บโดยการสุ่มผลตรวจ Arterial blood gas ในผู้ป่วยที่เข้ารับการผ่าตัดหัวใจและใช้เครื่องหัวใจและปอดเทียม จำนวน 200 ตัวอย่าง ตั้งแต่วันที่ 1 มกราคม 2562 – 31 ธันวาคม 2565 ในโรงพยาบาลจุฬารัตน์ ที่มีค่าผลทางห้องปฏิบัติการทั้งหมด 11 ค่า ดังตารางที่ 3.1

ตารางที่ 3.1 แสดงคุณลักษณะของชุดข้อมูล

ผลทางห้องปฏิบัติการ	คำอธิบาย	ชนิดข้อมูล
pH	ค่าบ่งบอกความเป็นกรด เบส ของก๊าซในเลือด	number
PCO ₂	ค่าความดันบางส่วน (partial pressure) ของคาร์บอนไดออกไซด์ในเลือดแดง	number
HCO ₃	ค่าไบคาร์บอเนตในเลือดแดง	number
BE (Base excess)	ค่าไบคาร์บอเนตซึ่งเป็นตัวบัพเฟอร์ในเลือด	number
PaO ₂	ค่าความดันแบบบางส่วน (partial pressure) ของออกซิเจนในเลือดแดง	number
O ₂ Sat	ความอิ่มตัวของออกซิเจนในเลือดแดง	number
Hb	ค่าระดับฮีโมโกลบิน (Hemoglobin)	number
Hct	ค่าความเข้มข้นเลือด (Hematocrit)	number
Na	ปริมาณของโซเดียมในเลือด	number
K	ปริมาณของโพแทสเซียมในเลือด	number
Ca	ปริมาณของแคลเซียมในเลือด	number

3.2 การจัดเตรียมข้อมูลเพื่อการประมวลผล

ในขั้นตอนนี้ผู้วิจัยได้ทำการแปลงข้อมูลเพื่อประมวลผล ซึ่งข้อมูลได้จากการเก็บข้อมูลแบบสุ่ม เก็บทีละตัวอย่างจากเวชระเบียนแบบบันทึกการใช้เครื่องหัวใจและปอดเทียมในผู้ป่วยที่ได้รับการเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผ่าตัดหัวใจแบบเปิด ซึ่งมีการใช้เครื่องหัวใจและปอดเทียมในขณะที่ผ่าตัด ในโรงพยาบาลจุฬารณ ตั้งแต่วันที่ 1 มกราคม 2562 – 31 ธันวาคม 2565 โดยได้รับการรับรองจริยธรรมจาก สำนักงานมาตรฐานและจริยธรรมการวิจัย ศูนย์การเรียนรู้และวิจัยเฉลิมพระเกียรติ 60 ปี เจ้าฟ้าจุฬาภรณ รัทส์โครงการวิจัยที่ EC 119/2566 ซึ่งมีขั้นตอนในการเตรียมข้อมูลดังนี้

3.2.1 เก็บข้อมูล ABG (Arterial blood gas) จากการสู่ม โดยเก็บทีละตัวอย่างจากแบบ บันทึกรการใช้เครื่องหัวใจและปอดเทียมบันทึกลงในโปรแกรม Microsoft Excel version 2010 จำนวน 200 ตัวอย่าง

3.2.2 ทำการแปลงผลทีละตัวอย่างโดยใช้วิธีการแปลงผลโดยผู้เชี่ยวชาญ ซึ่งเป็นผู้ได้รับ ใบอนุญาตประกอบวิชาชีพโรคศิลปะในสาขาที่เกี่ยวข้องไม่น้อยกว่า 5 ปี และ/หรือมีจำนวนการ ปฏิบัติงานสะสมอย่างน้อย 500 ราย ซึ่งการแปลงจะสามารถแบ่งกลุ่มได้เป็น 5 กลุ่ม (Class) คือ Metabolic acidosis , Metabolic alkalosis, Respiratory acidosis, Respiratory alkalosis และ Normal

3.2.3 แปลงชนิดของไฟล์ข้อมูลจาก xlsx เป็นชนิด csv โดยใช้โปรแกรม Microsoft excel

3.2.4 เนื่องจากปัจจุบันการตรวจทางห้องปฏิบัติการมีการพัฒนาการทดสอบโดยการตรวจ 1 ครั้งสามารถให้ผลการตรวจได้ผลหลายผลทางห้องปฏิบัติการ (Laboratory) ซึ่งทำให้ใช้เลือดน้อยกว่า และลดจำนวนครั้งในการเจาะเลือดด้วย ผู้วิจัยจึงทำการตัด Attribute ที่ไม่เกี่ยวข้องกับการแปลงผล ABG (Arterial blood gas) ออก ซึ่ง Attribute ที่มีความสำคัญสำหรับการแปลงผลประกอบด้วย pH, PCO₂, PaO₂, HCO₃, และ O₂Sat [8]

3.2.5 กำหนดชนิดของตัวแปรในแต่ละ Attribute โดยตัวแปรต่าง ๆ มีรายละเอียดดังตาราง ที่ 3.2

ตารางที่ 3.2 แสดงชนิดของตัวแปรในแต่ละ Attribute

ตัวแปร (Attribute)	ชนิดของตัวแปร
pH	ตัวแปรต้น
PCO ₂	ตัวแปรต้น
PaO ₂	ตัวแปรต้น
HCO ₃	ตัวแปรต้น
O ₂ Sat	ตัวแปรต้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.2 แสดงชนิดของตัวแปรในแต่ละ Attribute (ต่อ)

ตัวแปร (Attribute)	ชนิดของตัวแปร
Class	ตัวแปรตาม (Label)

3.2.6 สํารวจข้อมูล เพื่อหาจำนวนข้อมูลในแต่ละ Class

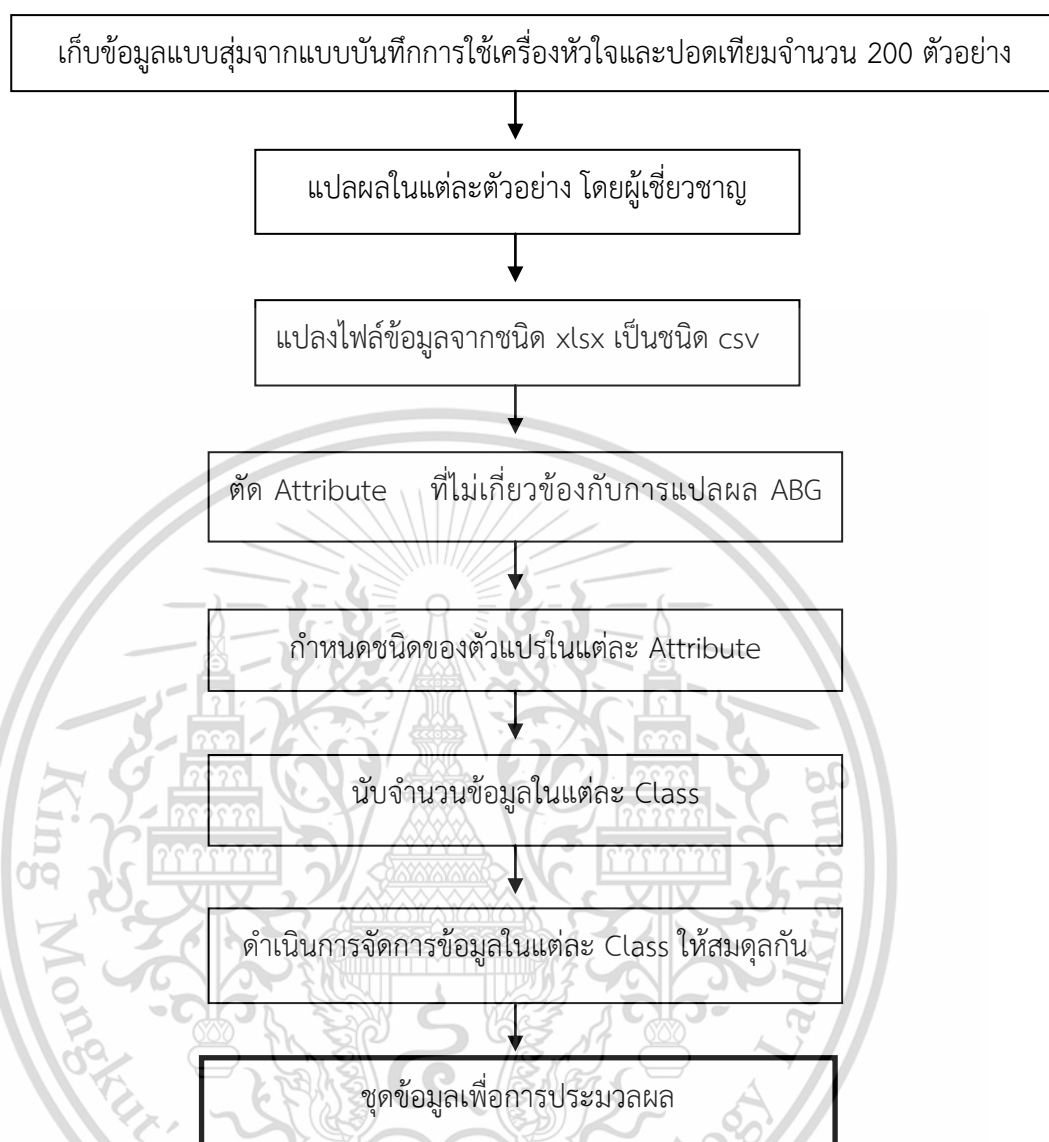
3.2.7 ดําเนินการจัดการข้อมูลในแต่ละ Class ให้สมดุล (Balance) กัน เนื่องจากข้อมูลในแต่ละ Class มีจำนวนแตกต่างกัน ผู้วิจัยต้องการแก้ปัญหาการจําแนกกลุ่มที่ไม่สมดุลโดยใช้เทคนิคการ SMOTE (Synthetic Minority Oversampling Technique) เพื่อให้ข้อมูลในแต่ละกลุ่มมีความสมดุล (Balance) กันมากขึ้น ดังตารางที่ 3.3

ตารางที่ 3.3 แสดงจำนวนของชุดข้อมูลก่อนและหลังการปรับสมดุลด้วยเทคนิค SMOTE

Class	จำนวนข้อมูลก่อนการ SMOTE	จำนวนข้อมูลหลังการ SMOTE
Metabolic acidosis	46	58
Metabolic alkalosis	34	58
Respiratory acidosis	41	58
Respiratory alkalosis	21	58
Normal	58	58
ข้อมูลทั้งหมด	200	290

3.2.8 สำหรับขั้นตอนนี้จะได้ชุดข้อมูลสำหรับการประมวลผลต่อไป โดยมีขั้นตอนโดยสรุปดังรูปที่ 3.2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.2 สรุปขั้นตอนการจัดเตรียมข้อมูลเพื่อการประมวลผล


3.3 การสร้างโมเดล

ในขั้นตอนนี้ผู้วิจัยนำข้อมูลเข้าสู่โมเดลการเรียนรู้โดยใช้งานโปรแกรม Rapidminer Studio Altair AI Studio version 2024.0 โดยจะนำข้อมูลที่จัดเตรียมไว้ เข้าสู่โมเดลการเรียนรู้ ซึ่งประกอบด้วย K-nearest neighbors (KNN), Random forest, XGBoost และ Deep learning ซึ่งในขั้นตอนการสร้างโมเดลมีขั้นตอนดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.1 การแบ่งข้อมูลสำหรับฝึกและทดสอบ

การแบ่งข้อมูลสำหรับฝึกและทดสอบแบ่งออกเป็น 2 ส่วน คือชุดข้อมูลสำหรับฝึกและทดสอบ (Training data and testing data) ในอัตราส่วน 70% และข้อมูลสำหรับการตรวจสอบ (validation set) ในอัตราส่วน 30% ซึ่งชุดข้อมูลสำหรับฝึกและทดสอบจะแบ่งเป็นอีก 2 ส่วนย่อย คือ ข้อมูลสำหรับฝึก 70% และข้อมูลทดสอบ 30% ดังรูปที่ 3.3



รูปที่ 3.3 การแบ่งข้อมูลสำหรับฝึกและทดสอบ

3.3.2 การนำข้อมูลเข้าสู่โมเดลการเรียนรู้

โมเดลการเรียนรู้เพื่อนำมาวิเคราะห์ชุดข้อมูลสำหรับงานวิจัยนี้มีทั้งหมด 4 โมเดล ประกอบด้วย K-nearest neighbors (KNN), Random forest, XGBoost และ Deep learning ซึ่งจะนำมาทำนายผลของข้อมูลเพื่อให้โมเดลการเรียนรู้สร้างโมเดลที่มีประสิทธิภาพดีที่สุด โดยในแต่ละโมเดลมีการปรับไฮเปอร์พารามิเตอร์ต่าง ๆ ดังตารางที่ 3.4

ตารางที่ 3.4 แสดงไฮเปอร์พารามิเตอร์ในแต่ละโมเดลที่มีการปรับค่า

โมเดล	ไฮเปอร์พารามิเตอร์ที่มีการปรับค่า	คำอธิบายไฮเปอร์พารามิเตอร์
K-nearest neighbors (KNN)	K	ตัวอย่างการฝึกที่มีคุณสมบัติใกล้เคียงกับตัวอย่างที่ยังไม่ทราบ Class

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.4 แสดงไฮเปอร์พารามิเตอร์ในแต่ละโมเดลที่มีการปรับค่า (ต่อ)

โมเดล	ไฮเปอร์พารามิเตอร์ที่มีการปรับค่า	คำอธิบายไฮเปอร์พารามิเตอร์
K-nearest neighbors (KNN)	Measure type	ประเภทของการวัดที่จะใช้ในการค้นหาเพื่อนบ้านที่ใกล้ที่สุด
Random forest	Number of tree	จำนวนของ Random tree ที่ต้องการสร้าง
	Criterion	เกณฑ์การเลือกแอตทริบิวต์สำหรับการแยกสำหรับการจัดกลุ่ม
	Maximal depth	ความลึกสูงสุดของ Random tree เพื่อจำกัดความลึกของแต่ละต้น
XGBoost	Booster	เทคนิคการ Boosting
	Round	รอบในการเรียนรู้
	Learning rate	อัตราการเรียนรู้
	Max depth	ความลึกสูงสุด
Deep learning	Activation	Activation function (ที่ไม่เป็นเชิงเส้น) ที่จะถูกใช้โดยเซลล์ประสาทในชั้นที่ซ่อนอยู่
	Hidden layer size	จำนวนชั้นซ่อน และจำนวนเซลล์ประสาทที่ซ่อนอยู่ในแต่ละชั้นซ่อนของโมเดล
	Epochs	จำนวนครั้งที่ชุดข้อมูลถูกประมวลผลซ้ำ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4 วัดประสิทธิภาพของโมเดลเรียนรู้แต่ละโมเดล

เมื่อนำข้อมูลที่จัดเตรียมไว้เข้าสู่โมเดลเรียนรู้ โดยแบ่งข้อมูลในอัตราส่วน ข้อมูลสำหรับฝึก 70% และสำหรับการทดสอบอีก 30% แล้ว จะวัดประสิทธิภาพตัวแบบและบันทึกค่าความแม่นยำ (Accuracy) และค่าความคาดเคลื่อนสัมบูรณ์ (Absolute error) ซึ่งในงานวิจัยนี้จะเน้นค่าความแม่นยำเป็นหลัก

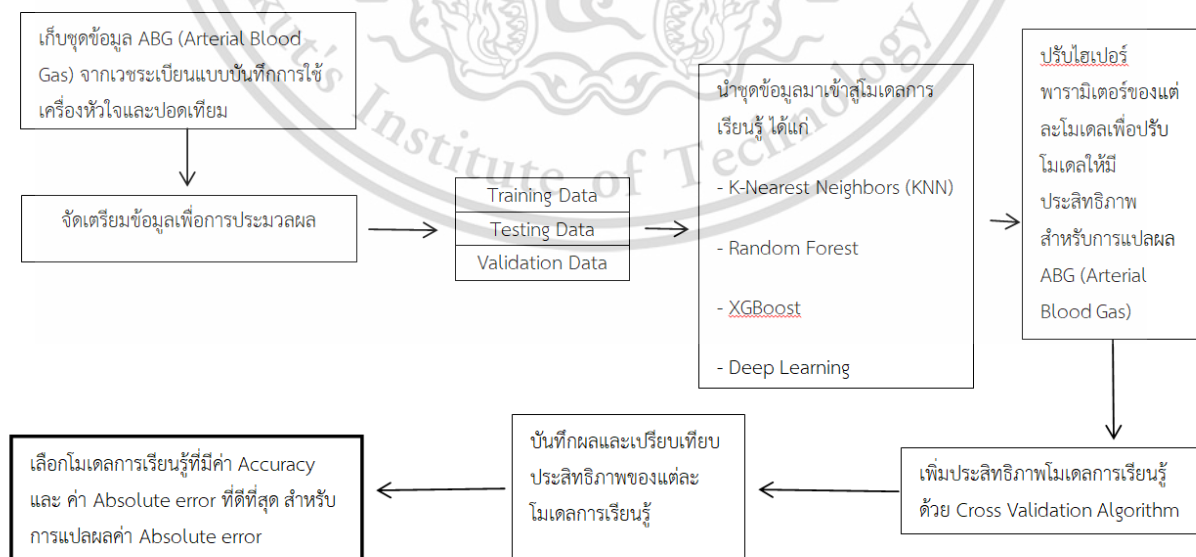
3.5 เพิ่มประสิทธิภาพของโมเดลการเรียนรู้ให้มีความแม่นยำในการแปลผลมากขึ้น

เมื่อปรับค่าไฮเปอร์พารามิเตอร์ในแต่ละโมเดล จนได้ค่าความแม่นยำที่ดีที่สุดแล้ว ผู้วิจัยจะนำโมเดลการเรียนรู้ที่ปรับแล้วนั้น มาเพิ่มประสิทธิภาพโดยการใช้ Cross validation algorithm แล้วบันทึกค่าความแม่นยำไว้ ซึ่งปรับค่า K ทั้งหมด 5 ค่า คือ K=2, K=4, K=6, K=8 และ K = 10 ตามลำดับ

3.6 เปรียบเทียบประสิทธิภาพการทำนายผลเพื่อหาโมเดลการเรียนรู้ที่ดีที่สุด

หลังจากได้ค่าต่าง ๆ ที่วัดประสิทธิภาพการทำนายผลของโมเดลการเรียนรู้แล้ว ผู้วิจัยจะนำค่าต่าง ๆ นั้นมาเปรียบเทียบกันเพื่อหาโมเดลการเรียนรู้ที่ดีที่สุดสำหรับการแปลผล ABG (Arterial blood gas) ในผู้ป่วยที่ผ่าตัดหัวใจและใช้เครื่องหัวใจและปอดเทียม

สำหรับการดำเนินงานวิจัยเพื่อนำเทคโนโลยี AI มาใช้ในการแปลผล Arterial blood gas (ABG) ในระหว่างการผ่าตัดหัวใจมีขั้นตอนโดยสรุปดังรูปที่ 3.4



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
รูปที่ 3.4 รายละเอียดการดำเนินงานวิจัย
 ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตีพิมพ์หรือเผยแพร่ข้อมูลใดๆ และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 4

ผลการวิจัยและการอภิปรายผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อนำเทคโนโลยี AI มาใช้ในการแปรผล Arterial blood gas ในระหว่างการผ่าตัดหัวใจ เพื่อช่วยปรับตั้งการทำงานของเครื่อง Heart Lung machine ให้เหมาะสมกับสถานะผู้ป่วยในขณะนั้น ในบทนี้จะกล่าวถึงประสิทธิภาพของโมเดลต่าง ๆ ที่นำมาใช้กับชุดข้อมูลจริงที่รวบรวมจากผู้ป่วย รวมถึงปัญหา และการอภิปรายผลการทดลองที่เกิดขึ้นในการวิจัยครั้งนี้

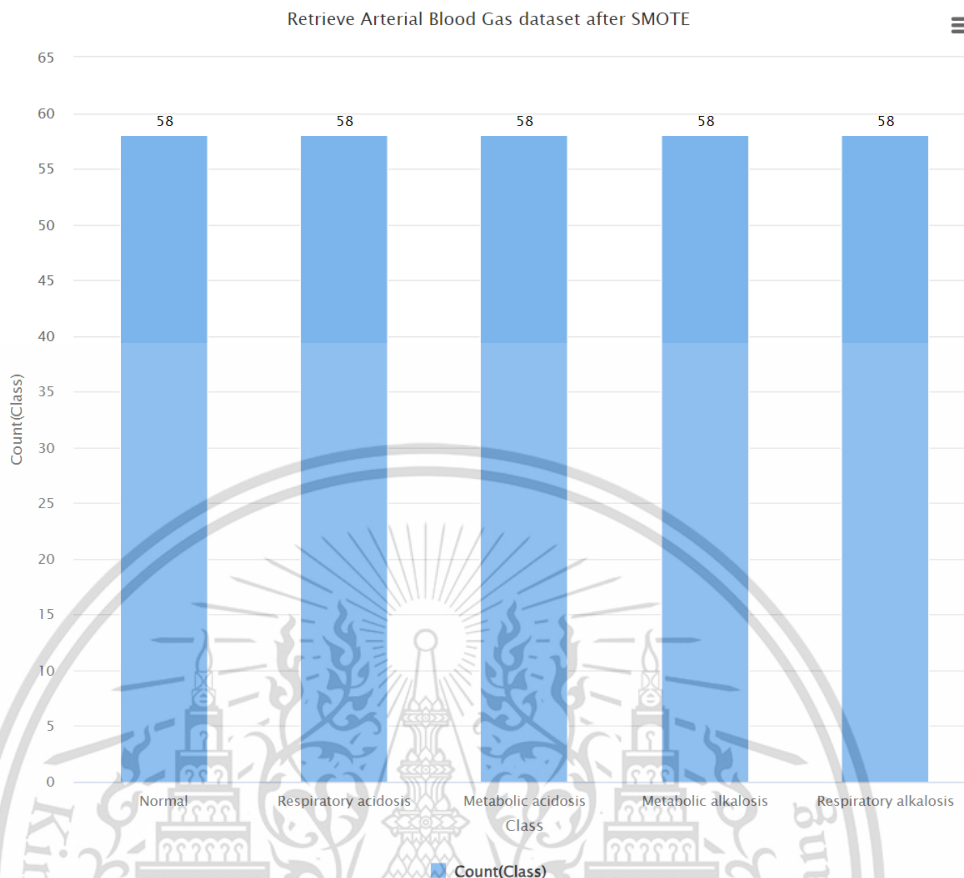
4.1 การดำเนินการจัดการข้อมูลในแต่ละ Class ให้สมดุลกันด้วยเทคนิค SMOTE

เนื่องจากข้อมูล Arterial blood gas (ABG) ที่เก็บรวบรวมมาในแต่ละ Class มีจำนวน 5 Class ซึ่งมีความแตกต่างกัน ซึ่งอาจส่งผลกระทบต่อการทำงานของโมเดลได้ ผู้วิจัยจึงแก้ปัญหาด้วยการใช้เทคนิค SMOTE เพื่อให้ข้อมูลในแต่ละ class สมดุล (Balance) กัน ซึ่งกล่าวถึงเบื้องต้นในตารางที่ 3.3 โดยแสดงดังรูปที่ 4.1 และรูปที่ 4.2



รูปที่ 4.1 จำนวนข้อมูลในแต่ละ Class จากการเก็บข้อมูลผู้ป่วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.2 จำนวนข้อมูลที่ทำให้ข้อมูลแต่ละ class สมดุลด้วยเทคนิค SMOTE

4.2 การกำหนดโครงสร้างและประสิทธิภาพของแต่ละโมเดล

จากการทดลองนำข้อมูลผ่านการจัดเตรียมเพื่อการประมวลผลแล้วเข้าสู่โมเดลการเรียนรู้เพื่อหาโมเดลที่สามารถจำแนก Class ในการแปรผล Arterial blood gas ที่มีประสิทธิภาพดีที่สุด ซึ่งโมเดลการเรียนรู้ที่ผู้วิจัยนำมาทำการทดลอง ได้แก่ K-Nearest Neighbors (KNN), Random forest, XGBoost และ Deep learning โดยในแต่ละโมเดลการเรียนรู้มีการปรับไฮเปอร์พารามิเตอร์ต่างๆ และมีผลการทดลองดังต่อไปนี้

4.2.1 โมเดล K-Nearest Neighbors (KNN)


โมเดล K-Nearest Neighbors (KNN) ผู้วิจัยได้มีการทดลองปรับค่าไฮเปอร์พารามิเตอร์ต่างๆ เพื่อให้ได้ค่า Accuracy ที่สูงที่สุด โดยมีการปรับตั้งค่าไฮเปอร์พารามิเตอร์ดังนี้

K : 2, 3, 5, 8, 10, 25

Measure type : Numeric Measure, Bregmann Divergences

Weight vote : True

จากผลการทดลองพบว่าค่า Accuracy ที่สูงที่สุดที่ทดลองจากโมเดลการเรียนรู้นี้มีค่า Accuracy เท่ากับ 85.88% และมีค่า Absolute error เท่ากับ 0.194 +/- 0.276 และมีค่า Sensitivity และค่า Specificity เท่ากับ 85.88% 96.47% ตามลำดับ ดังรูปที่ 4.3



รูปที่ 4.3 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ K-Nearest Neighbors (KNN)

จากรูปที่ 4.3 จะเห็นได้ว่าโมเดลการเรียนรู้ K-Nearest Neighbors (KNN) ที่นำมาทดลองกับชุดข้อมูล Arterial blood gas ในงานวิจัยนี้ ถ้าค่า K เพิ่มขึ้น ค่า Accuracy จะลดลง และ ค่า Absolute error ก็เพิ่มมากขึ้นด้วย จากผลการทดลองที่เกิดขึ้นนี้เนื่องจากอัลกอริทึมของโมเดล KNN เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

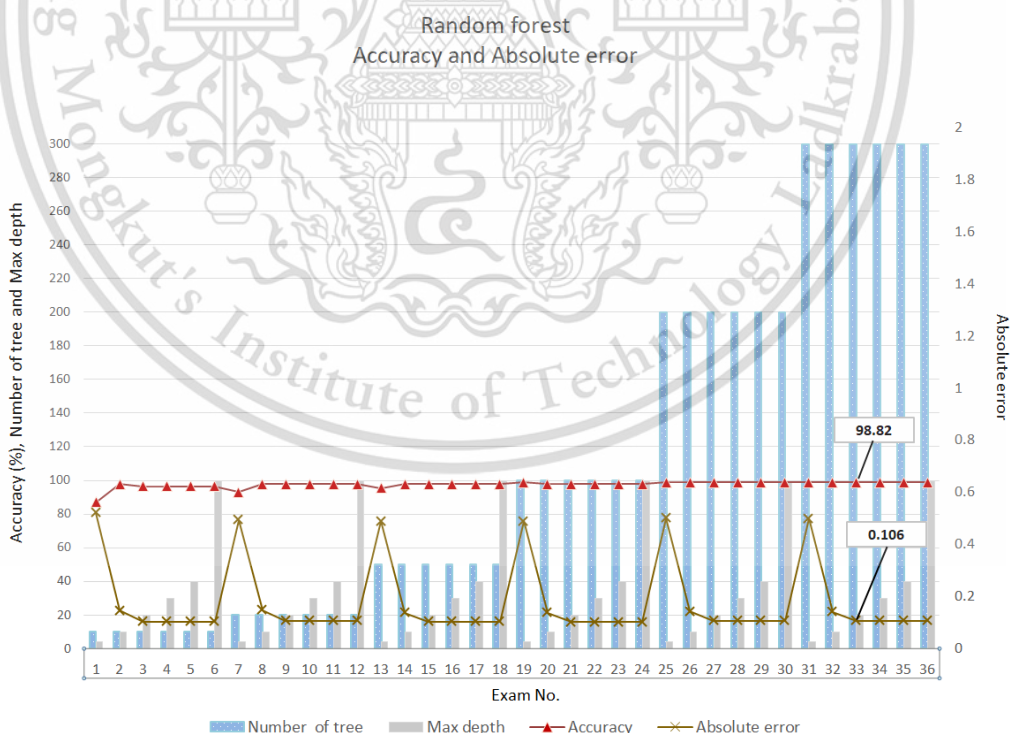
จะแบ่งกลุ่มข้อมูลโดยใช้ความคล้ายกันของข้อมูลในการจัดกลุ่ม ดังนั้นสำหรับข้อมูลชุดนี้เมื่อค่า K เพิ่มขึ้นแล้วค่า Accuracy ลดลงอาจเกิดจากชุดข้อมูลนี้มีจำนวน Class ที่ต้องการแบ่งจำนวน 5 Class ซึ่งถ้าจำนวน Class ที่ต้องการจัดกลุ่มมีมากเกินไป เมื่อค่า K เพิ่มขึ้นแล้วอาจทำให้ค่า Accuracy ลดลงได้

4.2.2 โมเดล Random forest

โมเดล Random forest ผู้วิจัยได้มีการทดลองปรับค่าไฮเปอร์พารามิเตอร์ต่างๆ เพื่อให้ได้ค่า Accuracy ที่สูงที่สุด ดังนี้

- Number of tree : 10, 20, 50, 100, 200, 300
- Criterion : Gain_ratio
- Maximal depth : 4, 10, 20, 30, 40, 100
- Apply pruning : True
- Apply prepruning : Fault
- Random split : True

จากผลการทดลองพบว่าค่า Accuracy ที่สูงที่สุดที่ทดลองจากโมเดลการเรียนรู้ี้ มีค่า Accuracy เท่ากับ 98.82% และมีค่า Absolute error เท่ากับ 0.106 +/- 0.116 และมีค่า Sensitivity และค่า Specificity เท่ากับ 98.82% และ 99.71% ตามลำดับ ดังรูปที่ 4.4



รูปที่ 4.4 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์พารามิเตอร์ต่างๆของ โมเดลการเรียนรู้ Random forest

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.4 จะเห็นได้ว่าโมเดลการเรียนรู้ Random forest นี้เมื่อปรับค่าไฮเปอร์พารามิเตอร์ต่างๆ แล้วนั้น เมื่อพิจารณา Number of tree ที่เพิ่มขึ้นในแต่ละ Max depth จะเห็นได้ว่าค่า Accuracy มีแนวโน้มเพิ่มขึ้นและค่า Absolute error มีแนวโน้มลดลง อย่างไรก็ตาม เมื่อ Number of tree เพิ่มขึ้นมากกว่า 200 ต้น ค่า Accuracy จะคงที่

ในทางกลับกัน เมื่อพิจารณา Max depth ที่เพิ่มขึ้นในแต่ละ Number of tree จะเห็นได้ว่าประสิทธิภาพของโมเดลค่อนข้างคงที่ ค่า Accuracy และ Absolute error ไม่ได้เปลี่ยนแปลงมากนัก เมื่อ Max depth เพิ่มขึ้น โมเดลที่ให้ประสิทธิภาพที่ดีที่สุดคือโมเดลที่มี Number of tree 200 ถึง 300 และมี Max depth อย่างน้อย 10 ชั้น โมเดลเหล่านี้ให้ Accuracy สูงถึง 98.82% และค่า Absolute error ต่ำที่ 0.106 ถึง 0.107

จากผลการทดลองดังกล่าว การกำหนด Number of tree = 200-300 ช่วยสร้างความหลากหลายให้กับโมเดล Random Forest แต่ละต้นไม้จะถูกสร้างจากชุดข้อมูลย่อยและคุณลักษณะที่สุ่มเลือกมา ทำให้ต้นไม้แต่ละต้นมีความแตกต่างกันและสามารถครอบคลุมรูปแบบหรือความสัมพันธ์ที่หลากหลายในข้อมูลได้ และช่วยลดความผันแปรและความเอนเอียงของโมเดล เนื่องจากข้อผิดพลาดหรือความเอนเอียงของต้นไม้แต่ละต้นจะถูกหักล้างซึ่งกันและกัน ทำให้โมเดลมีเสถียรภาพและความแม่นยำมากขึ้น นอกจากนี้ความลึกอย่างน้อย 10 ชั้นช่วยให้ต้นไม้สามารถจับความสัมพันธ์ที่ซับซ้อนข้อมูลได้ ทำให้โมเดลสามารถเรียนรู้รูปแบบที่ซับซ้อนและมีความยืดหยุ่นมากขึ้น แต่การใช้จำนวนต้นไม้ที่มากเกินไป (มากกว่า 200 ต้น) อาจไม่เพิ่มประสิทธิภาพของโมเดลการเรียนรู้ เนื่องจากโมเดลอาจเริ่มจดจำรูปแบบเฉพาะในชุดข้อมูลมากเกินไป

4.2.3 โมเดล XGBoost

โมเดล XGBoost ผู้วิจัยได้มีการทดลองปรับค่าไฮเปอร์พารามิเตอร์ต่างๆ เพื่อให้ได้ค่า Accuracy ที่สูงที่สุด ดังนี้

Booster : Tree booster

Round : 25, 50, 100, 150

Early stopping : Auto

Early stopping round : 10

Learning rate : 0.1, 0.3, 0.5, 0.8, 1.0

Min split loss : 1.0

Max depth : 2, 6, 10, 20


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sub sample : 0.1

Lambda : 0.1

Alpha : 0.0

จากผลการทดลองพบว่าค่า Accuracy ที่สูงที่สุดที่ทดลองจากโมเดลการเรียนรู้นี้มีค่า Accuracy เท่ากับ 98.82% และมีค่า Absolute error เท่ากับ 0.187 +/- 0.113 และมีค่า Sensitivity และค่า Specificity เท่ากับ 98.82% และ 99.71% ตามลำดับ ดังรูปที่ 4.5



รูปที่ 4.5 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ XGBoost

จากรูป 4.5 จะเห็นได้ว่าค่า Accuracy สูงสุดที่ 98.82% นี้เกิดขึ้นในหลายๆ รอบที่มีค่า Learning rate ค่อนข้างต่ำ (Learning rate ระหว่าง 0.1 ถึง 0.3) และค่า Accuracy จะลดลงเมื่อมี Learning rate สูงขึ้น แต่เมื่อเพิ่ม Round ค่า Accuracy ไม่เปลี่ยนแปลง และค่า Absolute error ลดลงเล็กน้อย และเมื่อเพิ่ม Max depth ไม่มีผลกับทั้งค่า Accuracy และค่า Absolute error

จากอัลกอริทึมการทำงานของโมเดลการเรียนรู้ XGBoost นี้ โมเดลจะสร้างต้นไม้การตัดสินใจมาต่อกันหลาย ๆ ต้น โดยแต่ละต้นจะเรียนรู้การทำนายผิดพลาดของต้นก่อนหน้า ซึ่งจะทำให้การเรียนรู้มีความแม่นยำเพิ่มขึ้นเรื่อยๆ จากการทดลองนี้จะเห็นว่า ค่า Accuracy สูงเกิดขึ้นในรอบที่มีค่า Learning rate ต่ำ อาจเกิดจาก Learning rate ที่ต่ำช่วยให้โมเดลค่อยๆ ปรับตัวและเรียนรู้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากข้อมูลที่ละน้อย ทำให้ได้โมเดลที่มีความแม่นยำสูง ในขณะที่ค่า Learning rate ที่สูงเกินไปอาจทำให้โมเดลเรียนรู้ข้อมูลได้รวดเร็วเกินไป และอาจข้ามจุดที่เหมาะสม จึงทำให้ Accuracy ลดลง สำหรับการเพิ่มจำนวน Round ช่วยให้มีเวลามากขึ้น ทำให้สามารถหาค่าได้แม่นยำยิ่งขึ้น ส่งผลให้ค่า Absolute error ลดลง อย่างไรก็ตาม การเพิ่ม Round มากเกินไปอาจไม่ได้ช่วยปรับปรุง Accuracy เนื่องจากโมเดลอาจเรียนรู้ได้ดีเพียงพอแล้ว และการเพิ่ม Max depth ไม่มีผลต่อค่า Accuracy และ Absolute error นั้น อาจเกิดจากชุดข้อมูลนี้อาจมีความสัมพันธ์ที่ไม่ซับซ้อนมากนัก ดังนั้นการเพิ่ม Max depth จึงไม่ได้ช่วยปรับปรุงประสิทธิภาพของโมเดล


4.2.4 โมเดล Deep learning

โมเดล Deep learning ผู้วิจัยได้มีการทดลองปรับค่าไฮเปอร์พารามิเตอร์ต่างๆ เพื่อให้ได้ค่า Accuracy ที่สูงที่สุดดังนี้

Activation	: Tanh with dropout
Hidden layer sizes	: 5, 10, 20, 50, 80, 100
Hidden layer	: 2, 3, 4
Hidden drop ratio	: 0.1
Reproducible	: True
Use local random seed	: 1992
Epochs	: 10, 20, 30, 40, 50, 80, 100, 150
Compute variable importances	: True
Adaptive rate	: True
Standardize	: True
L1	: 0.0
L2	: 0.0
Early stopping	: True

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองพบว่าค่า Accuracy ที่สูงที่สุดที่ทดลองจากโมเดลการเรียนรู้นี้ มีค่า Accuracy เท่ากับ 97.65% และมีค่า Absolute error เท่ากับ 0.078 +/- 0.145 และมีค่า Sensitivity และค่า Specificity เท่ากับ 97.65% และ 99.41% ตามลำดับ ดังรูปที่ 4.6



รูปที่ 4.6 ค่า Accuracy และ Absolute error หลังจากการปรับไฮเปอร์พารามิเตอร์ต่างๆของโมเดลการเรียนรู้ Deep learning

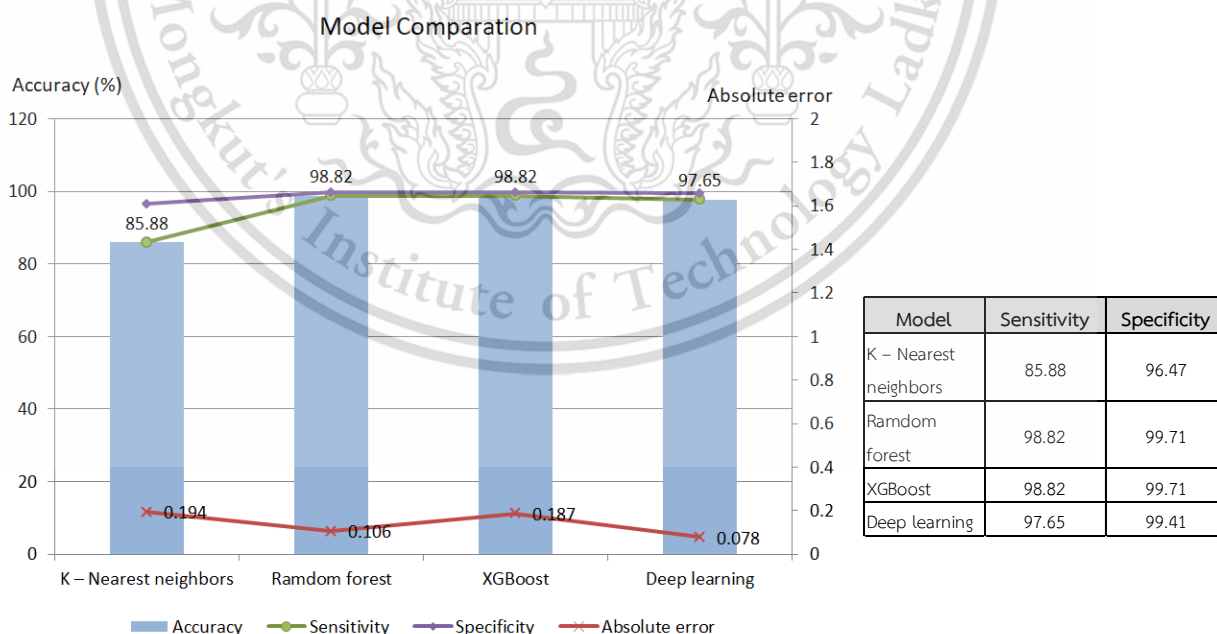
จากรูปที่ 4.6 จะพบว่าเมื่อเพิ่มจำนวน Node ต่อชั้นของแต่ละโมเดล ค่า Accuracy จะเพิ่มขึ้นและ Absolute Error จะลดลง แต่เมื่อถึงจุดหนึ่ง การเพิ่ม Node อาจไม่ช่วยให้ผลลัพธ์ดีขึ้น เช่น โมเดล 3 ชั้นซ้อนที่มี 20-50 Node ต่อชั้น ให้ค่า Accuracy ที่ค่อนข้างดีแต่เมื่อเพิ่มเป็น 80-100 Node กลับได้ค่าน้อยลง สำหรับการเพิ่มจำนวน Layer เมื่อเปรียบเทียบประสิทธิภาพของโมเดลที่จำนวน Layer ที่ 2, 3 และ 4 ชั้น พบว่าโมเดลที่มี 2 และ 3 ชั้นมักให้ค่า Accuracy สูงและค่า Absolute Error ต่ำ และการเพิ่มจำนวน Epochs มักทำให้ Accuracy เพิ่มขึ้นและ Absolute Error ลดลงในช่วงแรก แต่เมื่อถึงจุดหนึ่ง ค่า Accuracy และ Absolute error จะเริ่มคงที่

จากอัลกอริทึมของ Deep learning ที่มีแนวคิดจากระบบเซลล์ประสาทของมนุษย์ ซึ่งสามารถประมวลผลข้อมูลที่มีความซับซ้อนได้ โมเดลจะมีประสิทธิภาพเพิ่มขึ้นเรื่อยๆ เมื่อข้อมูลชุดฝึก (Training Data) มีจำนวนมากขึ้น โดยโมเดล Deep learning มักจะถูกนำมาใช้กับข้อมูลที่ซับซ้อนและมีปริมาณมาก ในการทดลองนี้เนื่องจากจำนวนข้อมูลที่นำมาฝึกการเรียนรู้ของโมเดล มีจำนวนไม่มากนัก การเพิ่มจำนวน layer ทำให้โมเดลมีความลึกมากขึ้น สามารถเรียนรู้รูปแบบและ

ความสัมพันธ์ที่ซับซ้อนในข้อมูลได้ดีขึ้น จึงให้ผลลัพธ์ที่แม่นยำกว่าโมเดลที่มีจำนวนชั้นน้อยกว่า สำหรับ Node ในแต่ละชั้น ยังมีจำนวนมาก ยิ่งทำให้โมเดลมีความสามารถในการเรียนรู้ที่สูงและยืดหยุ่นมากขึ้น แต่ทั้งจำนวน Layer และ Node ต้องดูความเหมาะสมด้วย เพราะถ้ามากเกินไปไม่เหมาะสมกับ Data set ก็อาจทำให้เกิด Over fitting ขึ้น และ Epoch คือรอบในการ Train โมเดล ยิ่งมาก โมเดลก็ยังมีโอกาสปรับค่าพารามิเตอร์ให้เข้ากับข้อมูลมากขึ้น ทำให้ผลลัพธ์ดีขึ้นในระยะแรก แต่เมื่อถึงจุดที่เหมาะสมแล้ว Epoch ที่เพิ่มขึ้นอาจไม่ช่วยเพิ่มประสิทธิภาพมากนัก เนื่องจากโมเดลเรียนรู้ได้เต็มที่แล้ว

4.3 การเปรียบเทียบประสิทธิภาพการทำนายของแต่ละโมเดลการเรียนรู้

จากการปรับไฮเปอร์พารามิเตอร์ต่างๆในแต่ละ โมเดลการเรียนรู้ซึ่งประกอบด้วย K-nearest neighbors (KNN), Random forest, XGBoost และ Deep learning และได้โมเดลที่มีค่า Accuracy สูงที่สุดแล้ว ผู้วิจัยได้นำค่า Accuracy ที่ได้มาเปรียบเทียบกันในแต่ละโมเดล พบว่า Random forest และ XGBoost มีค่า accuracy ที่เท่ากันคือ 98.82 และเมื่อนำค่า Absolute error มาเปรียบเทียบกัน พบว่า Random forest มีค่าต่ำกว่าคือ 0.106 +/- 0.116 ในขณะที่ XGBoost มีค่า 0.187 +/- 0.113 และเมื่อเทียบโมเดลการเรียนรู้ทั้ง 4 โมเดล Random forest และ XGBoost มีค่า Sensitivity และ Specificity ที่สูงสุดเท่ากันคือ 98.82 และ 99.71 ตามลำดับ ดังรูปที่ 4.7




รูปที่ 4.7 การเปรียบเทียบค่า Accuracy, Absolute error, Sensitivity และ Specificity ของแต่ละโมเดลการเรียนรู้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4 การเพิ่มประสิทธิภาพของโมเดลการเรียนรู้ให้มีความแม่นยำมากขึ้น

เมื่อทดลองปรับค่าพารามิเตอร์ต่างๆ และได้ค่าความแม่นยำที่สุดในแต่ละโมเดลการเรียนรู้แล้ว จะมีการเพิ่มประสิทธิภาพของโมเดลการเรียนรู้โดยใช้ Cross validation algorithm ซึ่งมีการปรับค่า K ทั้งหมด 5 ค่า คือ K= 2, K= 4, K= 6, K= 8 และ K = 10 แล้วนำไปหาค่าเฉลี่ย (Mean) ของค่าความแม่นยำ ซึ่งได้ผลการทดลองการเพิ่มประสิทธิภาพ พบว่าโมเดล Random forest ยังเป็นโมเดล มีค่าเฉลี่ยความแม่นยำสูงสุดคือ 96.48 % ดังรูปที่ 4.8 ในขณะที่ K – Nearest neighbors, XGBoost และ Deep learning มีค่าเฉลี่ยเท่ากับ 85.80 %, 95.73 % และ 95.52 % ตามลำดับ

Accuracy of cross validation algorithm



Model	K2 Accuracy	K4 Accuracy	K6 Accuracy	K8 Accuracy	K10 Accuracy	Mean
K – Nearest neighbors	82.07	85.16	87.27	87.25	87.24	85.80
Random forest	95.86	96.2	96.56	97.24	96.55	96.48
XGBoost	96.55	94.49	96.9	96.21	94.48	95.73
Deep learning	94.83	95.86	95.17	96.2	95.52	95.52

รูปที่ 4.8 ค่า Accuracy และค่าเฉลี่ยของแต่ละโมเดลการเรียนรู้โดยใช้ Cross validation algorithm

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.8 เมื่อนำ Cross validation algorithm มาใช้กับโมเดลการเรียนรู้พบว่า

โมเดล K-Nearest neighbors (KNN) ก่อนทำ Cross validation ค่า Accuracy ที่ดีที่สุดคือ 85.88% หลังทำ Cross validation (K=10) ค่า Accuracy เพิ่มขึ้นเป็น 87.24%

โมเดล Random Forest ก่อนทำ Cross validation ค่า Accuracy ที่ดีที่สุดคือ 98.82% หลังทำ Cross validation (K=8) ค่า Accuracy ลดลงเล็กน้อยเป็น 97.24% และยังคงเป็นโมเดลการเรียนรู้ที่ให้ค่า Accuracy สูงที่สุดในการทำ Cross validation

โมเดล XGBoost ก่อนทำ Cross validation ค่า Accuracy ที่ดีที่สุดคือ 98.82% หลังทำ Cross validation (K=2,8) ค่า Accuracy ลดลงเป็น 96.55%

โมเดล Deep Learning ก่อนทำ Cross validation ค่า Accuracy ที่ดีที่สุดคือ 97.65% หลัง cross validation (K=2) ค่า Accuracy ลดลงเป็น 95.86%

จากการทำ Cross validation จะเห็นได้ว่า ค่า accuracy ของ K-Nearest Neighbors ที่เพิ่มขึ้นหลังทำ Cross validation อาจเกิดจากเทคนิคนี้ช่วยลดปัญหา Overfitting ทำให้ได้โมเดลที่มีความสามารถในการทำนายข้อมูลใหม่ที่ดีขึ้น สำหรับโมเดลที่ซับซ้อนเช่น Random Forest, XGBoost และ Deep Learning การทำ Cross validation อาจทำให้ค่า Accuracy ลดลงเล็กน้อยเนื่องจากโมเดลเหล่านี้สามารถเรียนรู้รูปแบบที่ซับซ้อนในข้อมูลได้ดีอยู่แล้ว การทำ cross validation จึงอาจลดความสามารถในการเรียนรู้รูปแบบเหล่านั้นลงบ้าง แต่สามารถช่วยป้องกันการ Overfit และทำให้โมเดลมีประสิทธิภาพดีขึ้นในภาพรวม รวมทั้งช่วยให้ได้โมเดลที่มีความน่าเชื่อถือมากขึ้น

4.5 ปัญหาที่พบจากการศึกษา

4.5.1 การปรับค่าไฮเปอร์พารามิเตอร์

จากการทดลองในการปรับค่าไฮเปอร์พารามิเตอร์ในแต่ละโมเดลการเรียนรู้ เพื่อหาค่า Accuracy ที่ดีที่สุดนั้น พบว่าค่า Accuracy มีค่าเท่าๆกันในแต่ละโมเดลการเรียนรู้ ผู้วิจัยจึงเพิ่มการทดลองและนำค่า Absolute error มาพิจารณาร่วมด้วยเพื่อหาโมเดลเรียนรู้ที่ดีที่สุด

4.5.2. การเก็บรวบรวมข้อมูล

เนื่องจากการเก็บข้อมูลจากเอกสารแบบบันทึก ซึ่งไม่ใช่ Digital file และเป็นข้อมูลของผู้ป่วยซึ่งต้องมีความระมัดระวังในการเก็บรวบรวม อีกทั้งต้องมีการแปรผลโดยผู้เชี่ยวชาญ และต้องมีการตรวจสอบความถูกต้องของข้อมูล ในกรณีนี้อาจเกิดความผิดพลาดจากมนุษย์ (Human error) จึงทำให้การเก็บรวบรวมข้อมูลต้องมีการใช้ทรัพยากรและเวลาในการเก็บรวบรวมพอสมควร ซึ่งในการวิจัยครั้งนี้สามารถรวบรวมข้อมูลได้จำนวน 200 ตัวอย่าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้ทำการศึกษาเพื่อนำเทคโนโลยี AI มาใช้ในการแปลผล Arterial blood gas ในระหว่างการใส่เครื่องหัวใจและปอดเทียมในขณะที่ทำผ่าตัดหัวใจ โดยนำข้อมูลที่เก็บตัวอย่างมาจากแบบบันทึกการใส่เครื่องหัวใจและปอดเทียม จำนวน 200 ตัวอย่าง แล้วใช้โมเดลการเรียนรู้มาทดลองเพื่อหาโมเดลการเรียนรู้ที่ให้ค่าความแม่นยำสูงสุด จากการทดลองพบว่า

5.1.1 โมเดลการเรียนรู้ที่ให้ค่าความแม่นยำสูงสุดคือ Random forest และ XGBoost ซึ่งมีค่าความแม่นยำเท่ากับ 98.82% แต่เมื่อนำค่า Absolute error มาเปรียบเทียบกัน พบว่า Random forest มีค่าต่ำกว่าคือ 0.106 +/- 0.116 ในขณะที่ XGBoost มีค่า 0.187 +/- 0.113 ดังนั้น โมเดลที่มีค่าความแม่นยำที่สุดในการแปลผล Arterial blood gas คือ โมเดล Random forest

5.1.2 เพื่อเพิ่มประสิทธิภาพของโมเดลการเรียนรู้โดยใช้ Cross validation algorithm ซึ่งทดลองปรับค่า K เท่ากับ 2, 4, 6, 8, 10 และหาค่าเฉลี่ยของแต่ละโมเดลพบว่า โมเดลที่มีความแม่นยำมากที่สุด มีค่าเฉลี่ยความแม่นยำเท่ากับ 96.48% คือ Random forest

5.2 ข้อเสนอแนะ

ในการทำงานด้านการบริการสาธารณสุขนั้น มีการเก็บข้อมูลด้านชีวภาพต่างๆของผู้ป่วยเพื่อนำไปประกอบการวินิจฉัยและการรักษาผู้ป่วยเป็นจำนวนมาก ซึ่งในอดีตข้อมูลเหล่านี้จะถูกนำไปใช้โดยวิธีการแปลผลทีละตัวอย่าง และทำได้ในจำนวนผู้ป่วยไม่มากนัก ทำให้ใช้เวลาและทรัพยากรบุคคลผู้เชี่ยวชาญเป็นจำนวนมาก ในปัจจุบันมีการนำวิทยาการด้านข้อมูลเข้ามาใช้ในสาขาต่างๆมากขึ้น ซึ่งสามารถเพิ่มประสิทธิภาพ ลดระยะเวลา และประมวลผลข้อมูลจำนวนมากขึ้นได้ ในการวิจัยครั้งนี้ผู้วิจัยจึงมีความสนใจนำวิทยาการด้านข้อมูล โดยใช้โมเดลการเรียนรู้ต่างๆ มาประยุกต์ใช้กับข้อมูลด้านชีวภาพของผู้ป่วยที่ผู้วิจัยมีส่วนร่วมในการรักษาและการทำหัตถการนั้นๆ โดยข้อมูลที่น่ามาใช้คือผล Arterial blood gas จำนวน 200 ตัวอย่าง จากการทำวิจัยครั้งนี้มีข้อเสนอแนะดังนี้

5.2.1 เพื่อลดความผิดพลาดจากการเก็บข้อมูลโดยมนุษย์ รวมถึงลดระยะเวลาในการเก็บข้อมูล อาจจัดเก็บข้อมูลโดยวิธีขอเข้าถึงฐานข้อมูลของทางโรงพยาบาลโดยดำเนินการขอความเห็นชอบและอนุญาตจากผู้บริหารอย่างเป็นทางการ เพื่อนำข้อมูลที่เป็นไฟล์ดิจิทัลมาใช้งาน แต่ต้อง

ระมัดระวังเรื่องข้อมูลส่วนตัวของผู้ป่วยรวมถึงความปลอดภัยของข้อมูลที่นำมาใช้ด้วย เพื่อป้องกันผลกระทบที่อาจเกิดขึ้นกับผู้ป่วยได้ผู้ป่วย

5.2.2 เพื่อลดระยะเวลาในการเก็บรวบรวมข้อมูล ควรเก็บข้อมูลในรูปแบบของ Digital file ที่อยู่ในรูปแบบชนิดของไฟล์ที่พร้อมสำหรับการประมวลผล

5.2.3 ในการศึกษาครั้งต่อไป ควรเพิ่มจำนวนข้อมูลตัวอย่างที่นำมาประมวลผล เนื่องจากชุดข้อมูลที่มีขนาดเล็กเกินไปอาจทำให้เกิดการ Over fitting ได้และการเพิ่มจำนวนข้อมูลตัวอย่างสามารถเพิ่มความสามารถของโมเดลการเรียนรู้ได้อีกด้วย

5.2.4 ในขั้นตอนการแปรผลชุดข้อมูลที่เก็บรวบรวมไว้เพื่อให้โมเดลเรียนรู้ สำหรับข้อมูลที่มีปริมาณมาก ควรใช้โปรแกรมสำเร็จรูปในการแปรผลร่วมด้วย เพื่อลดระยะเวลาในการติดป้ายชื่อ (Label) ข้อมูล แต่ควรระมัดระวังและตรวจสอบความถูกต้องในการแปรผลของโปรแกรมเหล่านั้นด้วย เนื่องจากถ้ามีการแปรผลที่ไม่ถูกต้อง เมื่อนำมาประยุกต์ใช้งาน อาจส่งผลกระทบต่อผู้ป่วยได้

5.2.5 ในการเก็บรวบรวมข้อมูลผู้ป่วย ควรให้ความสำคัญกับความปลอดภัยของข้อมูลส่วนบุคคล เนื่องจากข้อมูลเหล่านี้ถือว่าเป็นข้อมูลส่วนบุคคลที่มีความเฉพาะอย่างยิ่ง และอาจเกิดการฟ้องร้องทางกฎหมายได้

5.2.6 เนื่องจากข้อมูลที่ใช้สำหรับงานวิจัยนี้เป็นข้อมูลของผู้ป่วย ซึ่งต้องปฏิบัติตามจริยธรรมการวิจัยในมนุษย์ดังนั้นในขั้นตอนการออกแบบงานวิจัย ก่อนเริ่มดำเนินการวิจัย ผู้วิจัยจึงต้องขออนุมัติโครงการ เพื่อทำวิจัยในมนุษย์กับตามระเบียบสถาบันหรือองค์กรที่เกี่ยวข้อง จึงทำให้มีขั้นตอนต่างๆเพิ่มขึ้น ดังนั้น อาจส่งผลให้ระยะเวลาในการทำวิจัยเพิ่มขึ้นได้

5.2.7 อาจจะใช้ Optimizer Operator ของโปรแกรม Rapidminer เพื่อให้การประมวลผลรวดเร็วและปรับไฮเปอร์พารามิเตอร์ได้ดีขึ้น

5.2.8 งานวิจัยนี้เป็นการเริ่มต้นใช้โมเดลการเรียนรู้ในการแปรผล Arterial blood gas ในระหว่างการใช้เครื่องหัวใจและปอดเทียมในขณะการผ่าตัดหัวใจ เนื่องจากชุดข้อมูลตัวอย่างมีขนาดเล็ก และมีการทดลองกับโมเดลการเรียนรู้เพียง 4 โมเดลเท่านั้น ในอนาคตถ้ามีการนำโมเดลการเรียนรู้อื่นๆมาประยุกต์ใช้กับผล Arterial blood gas หรือผลทางห้องปฏิบัติการอื่นๆ อาจให้ผลการทดลองที่แตกต่างจากการวิจัยนี้ ซึ่งการศึกษาวិทยาการด้านข้อมูลร่วมกับวิทยาศาสตร์ด้านสุขภาพมีความน่าสนใจและสามารถเกิดการต่อยอด พัฒนา ประยุกต์ใช้กับการให้บริการและรักษาผู้ป่วยได้อย่างมีประสิทธิภาพและปลอดภัย

เอกสารอ้างอิง

- [1] David Machin and Chris Allsager (2006). **Principles of cardiopulmonary bypass Continuing Education in Anaesthesia Critical Care & Pain**, Volume 6, Issue 5, October 2006, Pages176-181. สืบค้นเมื่อ 18 มีนาคม 2567 จาก, <https://doi.org/10.1093/bjaceaccp/mkl043>
- [2] Medi media Danist Banyan Mada Media. **Initiation of cardiopulmonary bypass**. สืบค้นเมื่อ 18 มีนาคม 2567 จาก, <https://medilib.ir/uptodate/show/115759>.
- [3] Manjula Sarka and Vishal Prabhu (2017). **Basics of cardiopulmonary bypass. Indian Journal of Anaesthesia**. 2017 Sep; 61(9): 760–767.
- [4] Prakash P Punjabi and K M Taylor (2013). **The science and practice of cardiopulmonary bypass: From cross circulation to ECMO and SIRS**. Global Cardiology Science and Practice, Volume 2013, Issue 3, Dec 2013:
- [5] Hancock, M., Pantin, E.J. (2021). **Fundamentals of Cardiopulmonary Bypass Machine Equipment and Technique**. Cardiac Anesthesia. Springer, Cham. pp 263-284. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://doi.org/10.1007/978-3-030-51755-7_13
- [6] N Colangelo, S Moriggia (2008). A cardioplegia circuit with versatility: The 'ReVerse' system. How to do it. **Perfusion** 23(4):205-207
- [7] Fastest Anesthesia & Intensive Care & Emergency Medicine Insight Engine (2016). **Cardiopulmonary Bypass: Equipment, Circuits, and Pathophysiology**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://aneskey.com/cardiopulmonary-bypass-equipment-circuits-and-pathophysiology-2/>
- [8] Castro D, Patil SM, Keenaghan M (2022) . Arterial Blood Gas.In: **StatPearls [Internet]**. Treasure Island (FL): StatPearls Publishing; 2023 Jan–. PMID: 30725604.
- [9] Oxford Medical Education (2014). **Arterial blood gas (ABG) interpretation for medical students, osces and mrcp**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://oxfordmedicaleducation.com/abgs / abg-interpretation/>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [10] Abhishek K Verma, Paul Roach (2010). The interpretation of arterial blood gases. **Australian prescriber** 2010;33:124-129
- [11] สำนักงานส่งเสริมเศรษฐกิจดิจิทัล (DEPA) (2023). **Machine Learning** สิ่งใกล้ตัวแห่งโลกยุคใหม่. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://www.depa.or.th/th/article-view/article11-2563#>
- [12] CORALINE (2023). **ความแตกต่างระหว่าง Supervised กับ Unsupervised Learning**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://www.coraline.co.th/single-post/supervised-unsupervised-learning>
- [13] สถาบันนวัตกรรมและธรรมาภิบาลข้อมูล (DIGI) (2023). **Supervised, Unsupervised, Reinforcement Learning** ต่างกันอย่างไร. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://digi.data.go.th/blog/supervised-unsupervised-reinforcement-learning/>
- [14] สถาบันนวัตกรรมและธรรมาภิบาลข้อมูล (DIGI) (2023). **สรุปให้!! วิธีการคำนวณด้วย K-Nearest Neighbors** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://digi.data.go.th/blog/what-is-k-nearest-neighbors/>
- [15] Medium (2023). **สรุป Machine Learning(EP.5) —การคำนวณเพื่อนบ้านใกล้สุด (K-nearest Neighbors)**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://kongruksiam.medium.com/สรุป-machine-learning-ep-4-เพื่อนบ้านใกล้ที่สุด-k-nearest-neighbors-787665f7c09d>
- [16] Github (2023). **Random forest**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://guopai.github.io/ml-blog10.html>
- [17] Humboldt-Universität zu Berlin. Department of Geography. (2023). **Image classification - Random Forest Learning goals** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, http://pages.cms.hu-berlin.de/EOL/geo_rs/S09_Image_classification2.html
- [18] XGBoost Document (2023). **XGBoost Tutorials** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://xgboost.readthedocs.io/en/stable/tutorials/index.html>
- [19] Github (2023). **Boosting** . สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://guopai.github.io/ml-blog11.html>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [20] Devopedia (2023). **XGBoost**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://devopedia.org/xgboost>
- [21] RBCS (Ray Bernard consulting service (2019). **Deep Learning to the Rescue** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://www.go-rbcs.com/columns/deep-learning-to-the-rescue>
- [22] ABB (2020). **Deep Learning คืออะไร**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://new.abb.com/news/detail/58004/deep-learning>
- [23] สมาคมโปรแกรมเมอร์ไทย (Thai Programmer) (2018). **Deep learning คืออะไร**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://www.thaiprogrammer.org/2018/12/deep-learning-คืออะไร/>
- [24] Bhatt, C., Kumar, I., Vijayakumar, V. (2021). **The state of the art of deep learning models in medical science and their challenges**. Multimedia Systems 27, 599–613 สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://doi.org/10.1007/s00530-020-00694->
- [25] Analytics Vidhya (2023). **10 Techniques to Solve Imbalanced Classes in Machine Learning (Updated 2023)**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <http://www.analyticsvidhya.com/blog/2020/07/10-techniques-to-deal-with-class-imbalance-in-machine-learning/>
- [26] Wiesław Wajs, Piotr Wais, Marcin Ochab , Hubert Wojtowicz (2016). **Arterial Blood Gases Forecast Optimization by Artificial Neural Network Method**. ResearchGate Chapter · May 2016 DOI: 10.1007/978-3-319-39796-2_36
- [27] S. Kajan, B. T. G. S. Kumara, K. Banujan, S. Prasanth and K. Manithepan (2022), **Classify the Outcome of Arterial Blood Gas Test to Detect the Respiratory Failure Using Machine Learning**. International Conference on Decision Aid Sciences and Applications (DASA), Chiangrai, Thailand, 2022, pp. 1139-1143, doi: 10.1109/DASA54658.2022.9765012.
- [28] Milad Shayan et al. (2020). **Systematic prediction of mortality in trauma patients based on Arterial Blood Gas**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://doi.org/10.1101/2020.05.18.20104273>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [29] Manjula Sarkar, Vishal Prabhu (2017). **Basics of cardiopulmonary bypass.** Indian J Anaesth 2017 Sep;61(9):760-767. Doi: 10.4103/ija.IJA_379_17. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://pubmed.ncbi.nlm.nih.gov/28970635/>
- [30] Dresden University of Technology, Institute of Electromechanical and Electronic Design. **Medical Device Engineering : Non-occlusive Peristaltic Pumps for Precise Transport of Demanding Media.** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://www.ifte.de/english/research/medizinische-geraetetechnik/Schlauchpumpe/index_en.html
- [31] Britannica.com. **Kinetic pumps.** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://www.britannica.com/technology/pump/Kinetic-pumps>
- [32] Prakash P Punjabi and K M Taylor (2013). **The science and practice of cardiopulmonary bypass: From cross circulation to ECMO and SIRS.** Global Cardiology Science and Practice, Volume 2013, Issue 3, Dec 2013, 32. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://www.qscience.com/content/journals/10.5339/gcsp.2013.32?crawler=true>
- [33] Livanova. **Adult cannulae Product catalog.** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://www.medicarehellas.gr/media/uploads_file/2017/11/06/p1bu8u7tnp1n96sr18t81g161gl5.pdf
- [34] RM Ginther, R. Gorney, R. Cruz (2013). **A clinical evaluation of the Maquet Quadrox-i Neonatal oxygenator with integrated arterial filter.** Perfusion 28 February 2013. DOI:10.1177/0267659113475694 Corpus ID: 20896658. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://www.semanticscholar.org/paper/A-clinical-evaluation-of-the-Maquet-Quadrox-i-with-Ginther-Gorney/a2ac291b7bd9802f8988efc5cb8f68457ebfa57d>
- [35] Braille Biomedica. **Cardioplegia tubing.** สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://www.medicaexpo.com/prod/braille-biomedica/product-106890-707129.html>

- [36] Hancock, M., Pantin, E.J. (2021). **Fundamentals of Cardiopulmonary Bypass Machine Equipment and Technique**. In: Awad, MD, MBA, A.S. (eds) *Cardiac Anesthesia*. Springer, Cham. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://doi.org/10.1007/978-3-030-51755-7_13
- [37] Supplythis.com. **Medtronic Minimax Plus Paediatric Oxygenation System**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://smartmedicalbuyer.com/collections/cardio-thoracic-surgery/products/medtronic-minimax-plus-paediatric-oxygenation-system>
- [38] Colangelo, Nicola & Moriggia, S & Kieser, Teresa & Simone, F & Vescovo, A & Palumbo, L & Denti, Paolo & Guidotti, Andrea & Blasio, A & Maisano, Francesco & Alfieri, O. (2008). **A cardioplegia circuit with versatility: The 'ReVerse' system. How to do it. Perfusion**. 23. 205-7. 10.1177/0267659108101498. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://www.researchgate.net/figure/ReVerse-circuit-with-crystalloid-cardioplegia-Clip-A-closed-Clip-B-open_fig3_23963668
- [39] Terumo cardiovascular. **Antegrade Cardioplegia Cannulae**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, www.terumocv.com/products/ProductDetail.aspx?groupID=4&familyID=88&country=1
- [40] Anesthesia Key Fastest Anesthesia & Intensive Care & Emergency Medicine Insight Engine. **Cardiopulmonary Bypass: Equipment, Circuits, and Pathophysiology**. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://aneskey.com/cardiopulmonary-bypass-equipment-circuits-and-pathophysiology-2/>
- [41] ศิริวรรณ วงศ์ประภรณ์กุล (2563). **การแปลผลการตรวจก๊าซในเลือดแดงอย่างง่าย**. วารสาร โรงพยาบาลสกลนคร ปีที่ 23 ฉบับที่ 3 กันยายน – ธันวาคม 2563 หน้า 111. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, <https://thaidj.org/index.php/jsnh/article/view/11212/9737>

- [42] Maru, Madhuri & Saket, Swarndeep. (2019). **A Novel Approach for Improving Breast Cancer Risk Prediction using Machine Learning Algorithms : A Survey**. International Journal of Scientific Research in Science, Engineering and Technology. 113-118. 10.32628/IJSRSET196634. สืบค้นเมื่อ 20 มีนาคม 2567 จาก, https://www.researchgate.net/publication/337958773_A_Novel_Approach_for_Improving_Breast_Cancer_Risk_Prediction_using_Machine_Learning_Algorithms_A_Survey
- [43] lbm.com. **What is the k-nearest neighbors (KNN) algorithm?**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://www.ibm.com/topics/knn>
- [44] Medium.com (2023) . **Understanding Random Forest**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://medium.com/@hemashreekilari9/understanding-random-forest-a87d08416280>
- [45] Devopedia.org (2022). **XGBoost**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://devopedia.org/xgboost>
- [46] Go-rbcs.com (2019). **Deep Learning to the Rescue**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://www.go-rbcs.com/columns/deep-learning-to-the-rescue>
- [47] Pythongeeks.org (2024). **Introduction to Deep Learning**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://pythongeeks.org/introduction-to-deep-learning/>
- [48] Kaggle.com . **Resampling strategies for imbalanced datasets**. สืบค้นเมื่อ 22 มีนาคม 2567 จาก, <https://www.kaggle.com/code/rafjaa/resampling-strategies-for-imbalanced-datasets/notebook>

ประวัติผู้เขียน

ชื่อ	เกตุศิริ ทิพย์คำ
วัน เดือน ปีเกิด	20 กุมภาพันธ์ 2528
ที่อยู่ปัจจุบัน	11/231 ซอยเอกมัย 12 ถนนสุขุมวิท 63 แขวงคลองตันเหนือ เขตวัฒนา จ. กรุงเทพฯ
ประวัติการศึกษา	(2546) วิทยาศาสตรบัณฑิต สาขาเทคโนโลยีหัวใจและทรวงอก เกรดเฉลี่ย 2.96
ทุนการศึกษาที่ได้รับ	ไม่มี
รางวัลที่ได้รับ	รางวัลนิสิตดีเด่นด้านกิจกรรมเสริมหลักสูตร ประจำปีการศึกษา 2548 คณะสหเวชศาสตร์ มหาวิทยาลัยนเรศวร รางวัลนิสิตดีเด่นด้านกิจกรรมเสริมหลักสูตร ประจำปีการศึกษา 2549 คณะสหเวชศาสตร์ มหาวิทยาลัยนเรศวร รางวัลโครงการภาคโปสเตอร์ดีเด่น เรื่อง เครื่องวัดอัตราการเต้นของหัวใจ อัตโนมัติ ประจำปีการศึกษา 2549 คณะสหเวชศาสตร์ มหาวิทยาลัย นเรศวร
ผลงานทางวิชาการ	ไม่มี
สมาชิกองค์กรวิชาชีพ	คณะกรรมการสมาคมนักเทคโนโลยีหัวใจและทรวงอกแห่งประเทศไทย (2560 – ปัจจุบัน)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก

ตาราง ก แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล K-Nearest Neighbors (KNN)

Exam No.	K	Measure type	Accuracy	Absolute error
1	2	NumericMeasures	75.29	0.307 +/- 0.306
2	3	NumericMeasures	69.41	0.371 +/- 0.327
3	5	NumericMeasures	56.47	0.499 +/- 0.297
4	8	NumericMeasures	49.41	0.572 +/- 0.262
5	10	NumericMeasures	45.88	0.602 +/- 0.251
6	25	NumericMeasures	36.47	0.693 +/- 0.168
7	2	BregmannDivergences	83.53	0.166 +/- 0.317
8	3	BregmannDivergences	85.88	0.194 +/- 0.276
9	5	BregmannDivergences	83.53	0.272 +/- 0.262
10	8	BregmannDivergences	80	0.361 +/- 0.264
11	10	BregmannDivergences	76.47	0.399 +/- 0.264
12	25	BregmannDivergences	65.88	0.579 +/- 0.196

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตาราง ข แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Random forest

Exam No.	Number of tree	Criterion	Max depth	Accuracy	Absolute error
1	10	Gain Ratio	4	87.06	0.521 +/- 0.099
2	10	Gain Ratio	10	97.65	0.146 +/- 0.149
3	10	Gain Ratio	20	96.47	0.103 +/- 0.157
4	10	Gain Ratio	30	96.47	0.103 +/- 0.157
5	10	Gain Ratio	40	96.47	0.103 +/- 0.157
6	10	Gain Ratio	100	96.47	0.103 +/- 0.157
7	20	Gain Ratio	4	92.94	0.493 +/- 0.096
8	20	Gain Ratio	10	97.65	0.148 +/- 0.132
9	20	Gain Ratio	20	97.65	0.107 +/- 0.140
10	20	Gain Ratio	30	97.65	0.107 +/- 0.140
11	20	Gain Ratio	40	97.65	0.107 +/- 0.140
12	20	Gain Ratio	100	97.65	0.107 +/- 0.140
13	50	Gain Ratio	4	95.29	0.488 +/- 0.081
14	50	Gain Ratio	10	97.65	0.137 +/- 0.122
15	50	Gain Ratio	20	97.65	0.104 +/- 0.130
16	50	Gain Ratio	30	97.65	0.104 +/- 0.130
17	50	Gain Ratio	40	97.65	0.104 +/- 0.130

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตาราง ข แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Random forest (ต่อ)

Exam No.	Number of tree	Criterion	Max depth	Accuracy	Absolute error
18	50	Gain Ratio	100	97.65	0.104 +/- 0.130
19	100	Gain Ratio	4	98.82	0.489 +/- 0.083
20	100	Gain Ratio	10	97.65	0.137 +/- 0.110
21	100	Gain Ratio	20	97.65	0.102 +/- 0.121
22	100	Gain Ratio	30	97.65	0.102 +/- 0.121
23	100	Gain Ratio	40	97.65	0.102 +/- 0.121
24	100	Gain Ratio	100	97.65	0.102 +/- 0.121
25	200	Gain Ratio	4	98.82	0.500 +/- 0.078
26	200	Gain Ratio	10	98.82	0.143 +/- 0.108
27	200	Gain Ratio	20	98.82	0.107 +/- 0.116
28	200	Gain Ratio	30	98.82	0.107 +/- 0.116
29	200	Gain Ratio	40	98.82	0.107 +/- 0.116
30	200	Gain Ratio	100	98.82	0.107 +/- 0.116
31	300	Gain Ratio	4	98.82	0.498 +/- 0.080
32	300	Gain Ratio	10	98.82	0.141 +/- 0.107
33	300	Gain Ratio	20	98.82	0.106 +/- 0.116
34	300	Gain Ratio	30	98.82	0.106 +/- 0.116
35	300	Gain Ratio	40	98.82	0.106 +/- 0.116
36	300	Gain Ratio	100	98.82	0.106 +/- 0.116

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตาราง ค แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost

Exam No.	Booster	Round	Learning rate	Max depth	Accuracy	Absolute error
1	Tree	25	0.1	2	98.82	0.348 +/- 0.102
2	Tree	25	0.1	6	98.82	0.348 +/- 0.102
3	Tree	25	0.1	10	98.82	0.348 +/- 0.102
4	Tree	25	0.1	20	98.82	0.348 +/- 0.102
5	Tree	25	0.3	2	98.82	0.216 +/- 0.122
6	Tree	25	0.3	6	98.82	0.216 +/- 0.122
7	Tree	25	0.3	10	98.82	0.216 +/- 0.122
8	Tree	25	0.3	20	98.82	0.216 +/- 0.122
9	Tree	25	0.5	2	96.47	0.215 +/- 0.148
10	Tree	25	0.5	6	96.47	0.215 +/- 0.148
11	Tree	25	0.5	10	96.47	0.215 +/- 0.148
12	Tree	25	0.5	20	96.47	0.215 +/- 0.148
13	Tree	25	0.8	2	94.12	0.206 +/- 0.187
14	Tree	25	0.8	6	94.12	0.206 +/- 0.187
15	Tree	25	0.8	10	94.12	0.206 +/- 0.187
16	Tree	25	0.8	20	94.12	0.206 +/- 0.187
17	Tree	25	1.0	2	92.94	0.205 +/- 0.208
18	Tree	25	1.0	6	92.94	0.205 +/- 0.208

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost (ต่อ)

Exam No.	Booster	Round	Learning rate	Max depth	Accuracy	Absolute error
19	Tree	25	1.0	10	92.94	0.205 +/- 0.208
20	Tree	25	1.0	20	92.94	0.205 +/- 0.208
21	Tree	50	0.1	2	98.82	0.261 +/- 0.114
22	Tree	50	0.1	6	98.82	0.261 +/- 0.114
23	Tree	50	0.1	10	98.82	0.261 +/- 0.114
24	Tree	50	0.1	20	98.82	0.261 +/- 0.114
25	Tree	50	0.3	2	98.82	0.189 +/- 0.115
26	Tree	50	0.3	6	98.82	0.189 +/- 0.115
27	Tree	50	0.3	10	98.82	0.189 +/- 0.115
28	Tree	50	0.3	20	98.82	0.189 +/- 0.115
29	Tree	50	0.5	2	97.65	0.184 +/- 0.136
30	Tree	50	0.5	6	97.65	0.184 +/- 0.136
31	Tree	50	0.5	10	97.65	0.184 +/- 0.136
32	Tree	50	0.5	20	97.65	0.184 +/- 0.136
33	Tree	50	0.8	2	94.12	0.206 +/- 0.187
34	Tree	50	0.8	6	94.12	0.206 +/- 0.187
35	Tree	50	0.8	10	94.12	0.206 +/- 0.187

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost (ต่อ)

Exam No.	Booster	Round	Learning rate	Max depth	Accuracy	Absolute error
36	Tree	50	0.8	20	94.12	0.206 +/- 0.187
37	Tree	50	1	2	92.94	0.205 +/- 0.208
38	Tree	50	1	6	92.94	0.205 +/- 0.208
39	Tree	50	1	10	92.94	0.205 +/- 0.208
40	Tree	50	1	20	92.94	0.205 +/- 0.208
41	Tree	100	0.1	2	98.82	0.249 +/- 0.118
42	Tree	100	0.1	6	98.82	0.249 +/- 0.118
43	Tree	100	0.1	10	98.82	0.249 +/- 0.118
44	Tree	100	0.1	20	98.82	0.249 +/- 0.118
45	Tree	100	0.3	2	98.82	0.187 +/- 0.113
46	Tree	100	0.3	6	98.82	0.187 +/- 0.113
47	Tree	100	0.3	10	98.82	0.187 +/- 0.113
48	Tree	100	0.3	20	98.82	0.187 +/- 0.113
49	Tree	100	0.5	2	97.65	0.184 +/- 0.136
50	Tree	100	0.5	6	97.65	0.184 +/- 0.136
51	Tree	100	0.5	10	97.65	0.184 +/- 0.136
52	Tree	100	0.5	20	97.65	0.184 +/- 0.136
53	Tree	100	0.8	2	94.12	0.206 +/- 0.187
54	Tree	100	0.8	6	94.12	0.206 +/- 0.187

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตาราง ค แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost (ต่อ)

Exam No.	Booster	Round	Learning rate	Max depth	Accuracy	Absolute error
55	Tree	100	0.8	10	94.12	0.206 +/- 0.187
56	Tree	100	0.8	20	94.12	0.206 +/- 0.187
57	Tree	100	1	2	92.94	0.205 +/- 0.208
58	Tree	100	1	10	92.94	0.205 +/- 0.208
59	Tree	100	1	10	92.94	0.205 +/- 0.208
60	Tree	100	1	20	92.94	0.205 +/- 0.208
61	Tree	150	0.1	2	98.82	0.249 +/- 0.118
62	Tree	150	0.1	6	98.82	0.249 +/- 0.118
63	Tree	150	0.1	10	98.82	0.249 +/- 0.118
64	Tree	150	0.1	20	98.82	0.249 +/- 0.118
65	Tree	150	0.3	2	98.82	0.187 +/- 0.113
66	Tree	150	0.3	6	98.82	0.187 +/- 0.113
67	Tree	150	0.3	10	98.82	0.187 +/- 0.113
68	Tree	150	0.3	20	98.82	0.187 +/- 0.113
69	Tree	150	0.5	2	97.65	0.184 +/- 0.136
70	Tree	150	0.5	6	97.65	0.184 +/- 0.136
71	Tree	150	0.5	10	97.65	0.184 +/- 0.136
72	Tree	150	0.5	20	97.65	0.184 +/- 0.136

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ค แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล XGBoost (ต่อ)

Exam No.	Booster	Round	Learning rate	Max depth	Accuracy	Absolute error
73	Tree	150	0.8	2	94.12	0.206 +/- 0.187
74	Tree	150	0.8	6	94.12	0.206 +/- 0.187
75	Tree	150	0.8	10	94.12	0.206 +/- 0.187
76	Tree	150	0.8	20	94.12	0.206 +/- 0.187
77	Tree	150	1	2	92.94	0.205 +/- 0.208
78	Tree	150	1	6	92.94	0.205 +/- 0.208
79	Tree	150	1	10	92.94	0.205 +/- 0.208
80	Tree	150	1	20	92.94	0.205 +/- 0.208

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning

Exam No.	Activation	Layer	Hidden layer size	Epochs	Accuracy	Absolute error
1	Tanh(dropout)	2	5	10	83.53	0.403 +/- 0.195
2	Tanh(dropout)	2	5	20	88.24	0.333 +/- 0.192
3	Tanh(dropout)	2	5	30	89.41	0.301 +/- 0.185
4	Tanh(dropout)	2	5	40	90.59	0.276 +/- 0.188
5	Tanh(dropout)	2	5	50	90.59	0.264 +/- 0.194
6	Tanh(dropout)	2	5	80	90.59	0.264 +/- 0.194
7	Tanh(dropout)	2	5	100	90.59	0.264 +/- 0.194
8	Tanh(dropout)	2	5	150	90.59	0.264 +/- 0.194
9	Tanh(dropout)	2	10	10	97.65	0.252 +/- 0.139
10	Tanh (dropout)	2	10	20	97.65	0.17 +/- 0.124
11	Tanh(dropout)	2	10	30	97.65	0.134 +/- 0.120
12	Tanh(dropout)	2	10	40	97.65	0.117 +/- 0.120
13	Tanh(dropout)	2	10	50	97.65	0.108 +/- 0.119
14	Tanh(dropout)	2	10	80	97.65	0.108 +/- 0.119
15	Tanh(dropout)	2	10	100	97.65	0.108 +/- 0.119
16	Tanh(dropout)	2	10	150	97.65	0.108 +/- 0.119
17	Tanh(dropout)	2	20	10	96.47	0.194 +/- 0.160
18	Tanh(dropout)	2	20	20	96.47	0.131 +/- 0.144

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epochs	Accuracy	Absolute error
19	Tanh(dropout)	2	20	30	96.47	0.100 +/- 0.138
20	Tanh(dropout)	2	20	40	96.47	0.083 +/- 0.131
21	Tanh(dropout)	2	20	50	96.47	0.081 +/- 0.130
22	Tanh(dropout)	2	20	80	96.47	0.081 +/- 0.130
23	Tanh(dropout)	2	20	100	96.47	0.081 +/- 0.130
24	Tanh(dropout)	2	20	150	96.47	0.081 +/- 0.130
25	Tanh(dropout)	2	50	10	95.29	0.128 +/- 0.156
26	Tanh(dropout)	2	50	20	96.47	0.088 +/- 0.146
27	Tanh(dropout)	2	50	30	97.65	0.078 +/- 0.145
28	Tanh (dropout)	2	50	40	97.65	0.078 +/- 0.145
29	Tanh(dropout)	2	50	50	97.65	0.078 +/- 0.145
30	Tanh(dropout)	2	50	80	97.65	0.078 +/- 0.145
31	Tanh(dropout)	2	50	100	97.65	0.078 +/- 0.145
32	Tanh(dropout)	2	50	150	97.65	0.078 +/- 0.145
33	Tanh(dropout)	2	80	10	92.94	0.119 +/- 0.175
34	Tanh(dropout)	2	80	20	94.12	0.103 +/- 0.167
35	Tanh(dropout)	2	80	30	94.12	0.103 +/- 0.167

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epochs	Accuracy	Absolute error
36	Tanh (dropout)	2	80	40	94.12	0.103 +/- 0.167
37	Tanh(dropout)	2	80	50	94.12	0.103 +/- 0.167
38	Tanh(dropout)	2	80	80	94.12	0.103 +/- 0.167
39	Tanh (dropout)	2	80	100	94.12	0.103 +/- 0.167
40	Tanh(dropout)	2	80	150	94.12	0.103 +/- 0.167
41	Tanh(dropout)	2	100	10	92.94	0.103 +/- 0.167
42	Tanh (dropout)	2	100	20	96.47	0.092 +/- 0.161
43	Tanh(dropout)	2	100	30	96.47	0.092 +/- 0.161
44	Tanh(dropout)	2	100	40	96.47	0.092 +/- 0.161
45	Tanh (dropout)	2	100	50	96.47	0.092 +/- 0.161
46	Tanh(dropout)	2	100	80	96.47	0.092 +/- 0.161
47	Tanh(dropout)	2	100	100	96.47	0.092 +/- 0.161
48	Tanh (dropout)	2	100	150	96.47	0.092 +/- 0.161
49	Tanh(dropout)	3	5	10	91.76	0.397 +/- 0.152
50	Tanh(dropout)	3	5	20	90.59	0.272 +/- 0.184
51	Tanh (dropout)	3	5	30	91.76	0.224 +/- 0.178
52	Tanh(dropout)	3	5	40	91.76	0.224 +/- 0.178
53	Tanh(dropout)	3	5	50	91.76	0.224 +/- 0.178
54	Tanh (dropout)	3	5	80	91.76	0.224 +/- 0.178

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epochs	Accuracy	Absolute error
55	Tanh (dropout)	3	5	100	91.76	0.224 +/- 0.178
56	Tanh(dropout)	3	5	150	91.76	0.224 +/- 0.178
57	Tanh(dropout)	3	10	10	92.94	0.267 +/- 0.163
58	Tanh (dropout)	3	10	20	95.29	0.143 +/- 0.151
59	Tanh(dropout)	3	10	30	94.12	0.140 +/- 0.155
60	Tanh(dropout)	3	10	40	94.12	0.140 +/- 0.155
61	Tanh (dropout)	3	10	50	94.12	0.140 +/- 0.155
62	Tanh(dropout)	3	10	80	94.12	0.140 +/- 0.155
63	Tanh(dropout)	3	10	100	94.12	0.140 +/- 0.155
64	Tanh (dropout)	3	10	150	94.12	0.140 +/- 0.155
65	Tanh(dropout)	3	20	10	97.65	0.131 +/- 0.138
66	Tanh(dropout)	3	20	20	97.65	0.123 +/- 0.145
67	Tanh (dropout)	3	20	30	97.65	0.123 +/- 0.145
68	Tanh(dropout)	3	20	40	97.65	0.123 +/- 0.145
69	Tanh(dropout)	3	20	50	97.65	0.123 +/- 0.145
70	Tanh (dropout)	3	20	80	97.65	0.123 +/- 0.145
71	Tanh(dropout)	3	20	100	97.65	0.123 +/- 0.145
72	Tanh(dropout)	3	20	150	97.65	0.123 +/- 0.145

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epochs	Accuracy	Absolute error
73	Tanh (dropout)	3	50	10	96.47	0.093 +/- 0.144
74	Tanh(dropout)	3	50	20	96.47	0.093 +/- 0.144
75	Tanh(dropout)	3	50	30	96.47	0.093 +/- 0.144
76	Tanh (dropout)	3	50	40	96.47	0.093 +/- 0.144
77	Tanh(dropout)	3	50	50	96.47	0.093 +/- 0.144
78	Tanh(dropout)	3	50	80	96.47	0.093 +/- 0.144
79	Tanh (dropout)	3	50	100	96.47	0.093 +/- 0.144
80	Tanh(dropout)	3	50	150	96.47	0.093 +/- 0.144
81	Tanh(dropout)	3	80	10	94.12	0.091 +/- 0.172
82	Tanh (dropout)	3	80	20	95.29	0.084 +/- 0.163
83	Tanh(dropout)	3	80	30	95.29	0.084 +/- 0.163
84	Tanh(dropout)	3	80	40	95.29	0.084 +/- 0.163
85	Tanh (dropout)	3	80	50	95.29	0.084 +/- 0.163
86	Tanh(dropout)	3	80	80	95.29	0.084 +/- 0.163
87	Tanh(dropout)	3	80	100	95.29	0.084 +/- 0.163
88	Tanh (dropout)	3	80	150	95.29	0.084 +/- 0.163
89	Tanh(dropout)	3	100	10	94.12	0.093 +/- 0.181
90	Tanh(dropout)	3	100	20	94.12	0.084 +/- 0.175
91	Tanh (dropout)	3	100	30	94.12	0.084 +/- 0.175

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epo chs	Accuracy	Absolute error
92	Tanh (dropout)	3	100	40	94.12	0.084 +/- 0.175
93	Tanh (dropout)	3	100	50	94.12	0.084 +/- 0.175
94	Tanh (dropout)	3	100	80	94.12	0.084 +/- 0.175
95	Tanh (dropout)	3	100	100	94.12	0.084 +/- 0.175
96	Tanh (dropout)	3	100	150	94.12	0.084 +/- 0.175
97	Tanh (dropout)	4	5	10	64.71	0.561 +/- 0.091
98	Tanh (dropout)	4	5	20	70.59	0.542 +/- 0.105
99	Tanh (dropout)	4	5	30	70.59	0.542 +/- 0.105
100	Tanh (dropout)	4	5	40	70.59	0.542 +/- 0.105
101	Tanh (dropout)	4	5	50	70.59	0.542 +/- 0.105
102	Tanh (dropout)	4	5	80	70.59	0.542 +/- 0.105
103	Tanh (dropout)	4	5	100	70.59	0.542 +/- 0.105
104	Tanh (dropout)	4	5	150	70.59	0.542 +/- 0.105
105	Tanh (dropout)	4	10	10	91.76	0.240 +/- 0.187
106	Tanh (dropout)	4	10	20	91.76	0.222 +/- 0.177
107	Tanh (dropout)	4	10	30	94.94	0.248 +/- 0.178
108	Tanh (dropout)	4	10	40	94.94	0.248 +/- 0.178
109	Tanh (dropout)	4	10	50	94.94	0.248 +/- 0.178
110	Tanh (dropout)	4	10	80	94.94	0.248 +/- 0.178

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epo chs	Accuracy	Absolute error
111	Tanh (dropout)	4	10	100	94.94	0.248 +/- 0.178
112	Tanh (dropout)	4	10	150	94.94	0.248 +/- 0.178
113	Tanh (dropout)	4	20	10	95.29	0.146 +/- 0.165
114	Tanh (dropout)	4	20	20	95.29	0.146 +/- 0.165
115	Tanh (dropout)	4	20	30	95.29	0.146 +/- 0.165
116	Tanh (dropout)	4	20	40	95.29	0.146 +/- 0.165
117	Tanh (dropout)	4	20	50	95.29	0.146 +/- 0.165
118	Tanh (dropout)	4	20	80	95.29	0.146 +/- 0.165
119	Tanh (dropout)	4	20	100	95.29	0.146 +/- 0.165
120	Tanh (dropout)	4	20	150	95.29	0.146 +/- 0.165
121	Tanh (dropout)	4	50	10	97.65	0.080 +/- 0.157
122	Tanh (dropout)	4	50	20	97.65	0.080 +/- 0.157
123	Tanh (dropout)	4	50	30	97.65	0.080 +/- 0.157
124	Tanh (dropout)	4	50	40	97.65	0.080 +/- 0.157
125	Tanh (dropout)	4	50	50	97.65	0.080 +/- 0.157
126	Tanh (dropout)	4	50	80	97.65	0.080 +/- 0.157
127	Tanh (dropout)	4	50	100	97.65	0.080 +/- 0.157
128	Tanh (dropout)	4	50	150	97.65	0.080 +/- 0.157
129	Tanh (dropout)	4	80	10	96.47	0.096 +/- 0.150

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ ๓ แสดงค่า Accuracy และ Absolute error จากการทดลองโมเดล Deep learning (ต่อ)

Exam No.	Activation	Layer	Hidden layer size	Epo chs	Accuracy	Absolute error
130	Tanh (dropout)	4	80	20	96.47	0.096 +/- 0.150
131	Tanh (dropout)	4	80	30	96.47	0.096 +/- 0.150
132	Tanh (dropout)	4	80	40	96.47	0.096 +/- 0.150
133	Tanh (dropout)	4	80	50	96.47	0.096 +/- 0.150
134	Tanh (dropout)	4	80	80	96.47	0.096 +/- 0.150
135	Tanh (dropout)	4	80	100	96.47	0.096 +/- 0.150
136	Tanh (dropout)	4	80	150	96.47	0.096 +/- 0.150
137	Tanh (dropout)	4	100	10	95.29	0.132 +/- 0.183
138	Tanh (dropout)	4	100	20	95.29	0.132 +/- 0.183
139	Tanh (dropout)	4	100	30	95.29	0.132 +/- 0.183
140	Tanh (dropout)	4	100	40	95.29	0.132 +/- 0.183
141	Tanh (dropout)	4	100	50	95.29	0.132 +/- 0.183
142	Tanh (dropout)	4	100	80	95.29	0.132 +/- 0.183
143	Tanh (dropout)	4	100	100	95.29	0.132 +/- 0.183
144	Tanh (dropout)	4	100	150	95.29	0.132 +/- 0.183

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ จ แสดงการเปรียบเทียบค่า Accuracy และ Absolute error ในแต่ละโมเดลการเรียนรู้

โมเดลการเรียนรู้	Accuracy	Absolute error	Sensitivity	Specificity
K – Nearest neighbors	85.88	0.194	85.88	96.47
Random forest	98.82	0.106	98.82	99.71
XGBoost	98.82	0.187	98.82	99.71
Deep learning	97.65	0.078	97.65	99.41

ตารางที่ ฉ แสดงค่าความแม่นยำเมื่อใช้ Cross validation algorithm และค่าเฉลี่ยในแต่ละโมเดลการเรียนรู้

โมเดลการเรียนรู้	K = 2 Accurac y	K = 4 Accurac y	K = 6 Accurac y	K = 8 Accurac y	K = 10 Accurac y	ค่า เฉลี่ย
K – Nearest neighbors	82.07	85.16	87.27	87.25	87.24	85.798
Random forest	95.86	96.2	96.56	97.24	96.55	96.482
XGBoost	96.55	94.49	96.9	96.21	94.48	95.726
Deep learning	94.83	95.86	95.17	96.2	95.52	95.516

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาพ Confusion matrix ของแต่ละโมเดลการเรียนรู้ต่างๆที่ให้ค่า Accuracy สูงที่สุด

accuracy: 85.88%

	true Normal	true Respiratory acidosis	true Metabolic acidosis	true Metabolic alkalosis	true Respiratory alkalosis	class precision
pred. Normal	15	1	4	2	0	68.18%
pred. Respiratory acidosis	1	14	0	0	0	93.33%
pred. Metabolic acidosis	1	2	13	0	0	81.25%
pred. Metabolic alkalosis	0	0	0	15	1	93.75%
pred. Respiratory alkalosis	0	0	0	0	16	100.00%
class recall	88.24%	82.35%	76.47%	88.24%	94.12%	

รูป ก Confusion matrix ของโมเดล K-nearest neighbors (KNN) ให้ค่า Accuracy สูงที่สุด

accuracy: 98.82%

	true Normal	true Respiratory ...	true Metabolic aci...	true Metabolic alk...	true Respiratory ...	class precision
pred. Normal	17	0	0	0	0	100.00%
pred. Respiratory...	0	17	1	0	0	94.44%
pred. Metabolic a...	0	0	16	0	0	100.00%
pred. Metabolic a...	0	0	0	17	0	100.00%
pred. Respiratory...	0	0	0	0	17	100.00%
class recall	100.00%	100.00%	94.12%	100.00%	100.00%	

รูป ข Confusion matrix ของโมเดล Random Forest ให้ค่า Accuracy สูงที่สุด

accuracy: 98.82%

	true Normal	true Respiratory ...	true Metabolic aci...	true Metabolic alk...	true Respiratory ...	class precision
pred. Normal	17	0	0	0	0	100.00%
pred. Respiratory...	0	17	1	0	0	94.44%
pred. Metabolic a...	0	0	16	0	0	100.00%
pred. Metabolic a...	0	0	0	17	0	100.00%
pred. Respiratory...	0	0	0	0	17	100.00%
class recall	100.00%	100.00%	94.12%	100.00%	100.00%	


รูป ค Confusion matrix ของโมเดล XGBooth ให้ค่า Accuracy สูงที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

accuracy: 97.65%

	true Normal	true Respiratory ...	true Metabolic aci...	true Metabolic alk...	true Respiratory ...	class precision
pred. Normal	17	0	0	0	0	100.00%
pred. Respiratory...	0	16	1	0	0	94.12%
pred. Metabolic a...	0	1	16	0	0	94.12%
pred. Metabolic a...	0	0	0	17	0	100.00%
pred. Respiratory...	0	0	0	0	17	100.00%
class recall	100.00%	94.12%	94.12%	100.00%	100.00%	

รูป ง Confusion matrix ของโมเดล Deep learning ให้ค่า Accuracy สูงที่สุด



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้