

การประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อเพิ่มความจำเพาะในการตรวจคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว  
จากสัญญาณคลื่นไฟฟ้าหัวใจ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมชีวเวช ไม่สังกัดภาควิชา/เทียบเท่า  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2562  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Applying Deep Learning to Electrocardiogram Signals for Specificity Improvement of  
Atrial Fibrillation Screening System



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Biomedical Engineering

Common Course

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2019

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อเพิ่มความจำเพาะในการตรวจคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วจากสัญญาณคลื่นไฟฟ้าหัวใจ
โดย	น.ส.จันทน์ปภา จันท์ครบ
สาขาวิชา	วิศวกรรมชีวเวช
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	อาจารย์ ดร.ภาคภูมิ สมบูรณ์
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ศาสตราจารย์ แพทย์หญิงนิจศรี ชาญณรงค์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัย อนุวัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์  
(รองศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.อภิวัฒน์ เล็กอุทัย)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(อาจารย์ ดร.ภาคภูมิ สมบูรณ์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม  
(ศาสตราจารย์ แพทย์หญิงนิจศรี ชาญณรงค์)

..... กรรมการ  
(อาจารย์ ดร.เอกพล ช่างสุวนิช)

..... กรรมการภายนอกมหาวิทยาลัย  
(รองศาสตราจารย์ แพทย์หญิงอรอุมา ชูดีเนตร)

จันทป์ปภา จันทรศรบ : การประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อเพิ่มความจำเพาะในการตรวจคัดกรอง  
ภาวะหัวใจห้องบนสั่นพลิ้วจากสัญญาณคลื่นไฟฟ้าหัวใจ. ( Applying Deep Learning to  
Electrocardiogram Signals for Specificity Improvement of Atrial Fibrillation Screening  
System) อ.ที่ปรึกษาหลัก : อ. ดร.ภาคภูมิ สมบูรณ์, อ.ที่ปรึกษาร่วม : ศ. พญ.นิจศรี ชาญณรงค์

ภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation: AF) เป็นภาวะหัวใจเต้นผิดจังหวะที่เป็นภัยเงียบและพบได้บ่อย โดยเมื่อเกิดภาวะนี้ขึ้นทำให้มีความเสี่ยงที่จะเกิดหลอดเลือดสมองตีบตัน (Ischemic stroke) ดังนั้นการตรวจคัดกรองสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนสั่นพลิ้วจึงมีความสำคัญ ปัจจุบันมีการพัฒนาอุปกรณ์พกพาที่สามารถตรวจจับภาวะนี้ของผู้ป่วยได้อย่างต่อเนื่อง โดยอัลกอริทึมที่ใช้จะให้ค่าความไวสูงในการตรวจจับ ซึ่งจะทำให้ค่าความจำเพาะนั้นต่ำ ดังนั้นในงานวิจัยนี้ได้ทำการนำการเรียนรู้เชิงลึก (Deep learning) มาประยุกต์ใช้เพื่อเพิ่มความจำเพาะในการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว โดยมีตัวรบกวนที่สำคัญได้แก่ภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ โดยงานวิจัยนี้ได้นำเอาโครงข่ายคอนโวลูชันมาใช้แยกแยะภาวะหัวใจห้องบนสั่นพลิ้วทั้งข้อมูลภาพและข้อมูลอนุกรมเวลา ซึ่งค่าความไวและค่าความจำเพาะของโมเดลที่ฝึกจากข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจอยู่ที่ร้อยละ 84.67 และ 96.33 ตามลำดับ จากนั้นนำโมเดลที่ได้ไปใช้งานร่วมกับอุปกรณ์ตรวจคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วที่ใช้อัลกอริทึมที่มีความซับซ้อนน้อย พบว่าได้ค่าความไวและค่าความจำเพาะอยู่ที่ร้อยละ 96.97 และ 100 ตามลำดับ และโมเดลที่ทำการแยกแยะกลุ่มสัญญาณภาวะหัวใจห้องบนสั่นพลิ้วกับกลุ่มสัญญาณที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้วที่ได้จากข้อมูลอนุกรมเวลาให้ค่าความไวและค่าความจำเพาะของอยู่ที่ร้อยละ 98.33 และ 99.33 ตามลำดับ จากนั้นนำข้อมูลของกลุ่มสัญญาณที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้วมาทำการแยกประเภทได้ค่าความถูกต้องสูงสุดอยู่ที่ร้อยละ 92.33 ผลการวิจัยนี้แสดงให้เห็นว่าค่าความจำเพาะสามารถถูกปรับปรุงให้ดีขึ้นได้เมื่อนำการเรียนรู้เชิงลึกมาประยุกต์เพื่อสร้างโมเดลสำหรับการคัดแยกภาวะหัวใจห้องบนสั่นพลิ้วจากภาวะอื่น ๆ

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมชีวเวช  
ปีการศึกษา 2562

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....  
ลายมือชื่อ อ.ที่ปรึกษาร่วม .....

# # 6170351521 : MAJOR BIOMEDICAL ENGINEERING

KEYWORD: Deep learning model, Atrial fibrillation, Convolutional neural network (CNN)

Jantappapa Chanthercrob : Applying Deep Learning to Electrocardiogram Signals for Specificity Improvement of Atrial Fibrillation Screening System. Advisor: PAKPUM SOMBOON, Ph.D. Co-advisor: Prof. NIJASRI CHARNNARONG, M.D.

Atrial Fibrillation or AF is the most common cardiac arrhythmia. It is associated with increased morbidity and mortality. Since AF trends to occur the serious complications, such as ischemic stroke, early AF detection is important for improving the healthcare prevention system. Nowadays, portable ECG (Electrocardiogram) devices for continued AF detection have been developed. An algorithm of these devices must provide a high sensitivity of screening AF. Due to the high sensitivity, the specificity of the system is low. For this reason, deep learning is required to improve the specificity of this AF screening system. This study applied a convolutional neural network (CNN) to identify AF form other cardiac arrhythmias consisting of normal sinus rhythm (NSR), premature atrial contraction (PAC), and premature ventricular contraction (PVC). There are two data types of this work, ECG image data, and ECG sequence data. A CNN model trained on ECG image data gives 84.67% and 96.33% for sensitivity and specificity, respectively. The model has been compared to a low complexity algorithm designed for ECG portable devices. Accordingly, the sensitivity and specificity of the CNN model are 96.97% and 100%. For ECG sequence data, there are two groups which are AF and non-AF. The model learned ECG sequence dataset provides 98.33% of sensitivity and 99.33% of specificity. After identified the AF data, the non-AF was also distinguished. The maximum accuracy from the model trained on the non-AF dataset is 92.33%. These results indicate that applying a deep learning model can improve the specificity of the AF screening system. Besides, the trained CNN model of this study is the potential to develop for separating NSR, PAC as well as PVC.

Field of Study: Biomedical Engineering

Student's Signature .....

Academic Year: 2019

Advisor's Signature .....

Co-advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี แม้จะพบพานอุปสรรคนานับประการ ซึ่งความสำเร็จในครั้งนี้มีบุคคลมากมายที่มีส่วนสำคัญในการช่วยเหลือในการทำวิจัยกับผู้จัดทำ ผู้จัดทำรู้สึกซาบซึ้งใจเป็นอย่างยิ่งสำหรับความกรุณาเหล่านี้ จึงขอใช้เนื้อหาลงกิตติกรรมประกาศของวิทยานิพนธ์นี้เพื่อแสดงความขอบพระคุณแก่ผู้มีส่วนร่วมทั้งหลาย

ขอขอบพระคุณอาจารย์ที่ปรึกษาหลัก อ. ดร.ภาคภูมิ สมบูรณ์ ผู้อบรมสั่งสอน และแนวทางการทำวิทยานิพนธ์ คำปรึกษาอันล้ำค่าของอาจารย์ช่วยให้ผู้จัดทำได้เรียนรู้การจัดทำวิทยานิพนธ์ได้เป็นอย่างดีและมีแรงกระตุ้นที่จะฝ่าฟันอุปสรรคไปได้ นอกจากนี้ขอขอบพระคุณศ. พญ.นิจศรี ชาญณรงค์ อาจารย์ที่ปรึกษาร่วมที่ได้ให้คำชี้แนะที่มีประโยชน์แก่ผู้จัดทำ

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ ศศ. ดร.อภิวัฒน์ เล็กอุทัย ที่ได้ความรู้ความเข้าใจเกี่ยวกับสัญญาณคลื่นไฟฟ้าหัวใจซึ่งเป็นประโยชน์ในการต่อยอดสำหรับวิทยานิพนธ์นี้ อ. ดร.เอกพล ช่วงสุนิษ ผู้แนะนำผู้จัดทำเข้าสู่โลกของสายคอมพิวเตอร์ พร้อมกับให้ความรู้แนวทางเกี่ยวกับการเรียนรู้เชิงลึกและรศ. พญ.อรอุมา ชูตินेत्र ที่ให้ความกรุณาให้เกียรติเป็นคณะกรรมการวิทยานิพนธ์ และให้คำปรึกษาที่มีประโยชน์พร้อมทั้งให้กำลังใจผู้จัดทำในการทำวิทยานิพนธ์นี้

ขอขอบคุณเพื่อน ๆ พี่ ๆ หลักสูตรวิศวกรรมชีวเวชที่ให้คำแนะนำและคำปรึกษาเกี่ยวกับการเรียนในระดับปริญญาโท พร้อมทั้งเกื้อหนุนและให้กำลังใจซึ่งกันและกันเมื่อต้องเผชิญหน้ากับปัญหาต่าง ๆ

ขอขอบพระคุณเจ้าหน้าที่หลักสูตรวิศวกรรมชีวเวช โดยเฉพาะนายธนภุต สิ้นเปรมที่ได้อำนวยความสะดวกแก่ผู้จัดทำตั้งแต่การจัดการเอกสารการเรียนไปจนถึงการสอบวิทยานิพนธ์ พร้อมกับอำนวยความสะดวกแก่ผู้จัดทำในด้านอื่น ๆ ด้วย

ขอขอบพระคุณพ่อ แม่ พี่สาว น้องชาย และบุคคลอันเป็นที่รักของผู้จัดทำที่คอยรับฟังปัญหา พร้อมทั้งคอยสนับสนุนผู้จัดทำในทุก ๆ ด้าน

สุดท้ายขอขอบคุณตัวผู้จัดทำเอง เพราะวิทยานิพนธ์ฉบับนี้จะไม่สำเร็จได้ถ้าหากขาดตัวผู้จัดทำไป ขอขอบคุณที่ตนเองมีความมุ่งมั่นมาจนถึงจุดนี้ได้ และมีความเชื่อมั่นมาตลอดว่าจะสามารถทำงานนี้สำเร็จได้ด้วยดี

จันทป์ปภา จันท์ครบ

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญภาพ .....	ฉ
สารบัญตาราง.....	ช
บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ .....	5
1.3 ขอบเขตของงานวิจัย.....	5
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	5
การทบทวนวรรณกรรม .....	6
2.1 สัญญาณคลื่นไฟฟ้าหัวใจและภาวะหัวใจเต้นผิดจังหวะ.....	6
2.1.1 สัญญาณคลื่นไฟฟ้าหัวใจ.....	6
2.1.1.1 หน้าที่และโครงสร้างของหัวใจ.....	6
2.1.1.2 การเต้นของหัวใจ .....	7
2.1.2 ภาวะหัวใจเต้นผิดจังหวะ .....	9
2.1.2.1 ภาวะหัวใจห้องบนสั่นพลิ้ว.....	9
2.1.2.2 ภาวะหัวใจห้องบนเต้นก่อนจังหวะ .....	10
2.1.2.3 ภาวะหัวใจห้องล่างเต้นก่อนจังหวะ.....	10
2.2 การเรียนรู้เชิงลึก .....	11

2.2.1 ความหมายของการเรียนรู้เชิงลึก .....	11
2.2.2 ความแตกต่างของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง .....	11
2.3 โครงข่ายประสาทเทียม .....	13
2.3.1 ส่วนประกอบของโครงข่ายประสาทเทียม .....	13
2.3.2 การทำงานของโครงข่ายประสาทเทียม .....	15
2.3.2.1 การทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า .....	15
2.3.2.2 ฟังก์ชันกระตุ้น .....	16
2.3.2.3 ฟังก์ชันต้นทุน .....	17
2.3.2.4 วิธีการหาค่าที่เหมาะสม .....	17
2.3.2.5 การแพร่กระจายย้อนกลับ .....	20
2.4 โครงข่ายคอนโวลูชัน .....	20
2.4.1 ชั้นคอนโวลูชัน .....	20
2.4.2 ชั้นการรวม .....	22
2.4.3 ชั้นการเชื่อมโยงเต็มรูปแบบ .....	22
2.5 โครงข่ายคอนโวลูชันตามเวลา .....	22
2.5.1 คอนโวลูชันคอซอล .....	22
2.5.2 คอนโวลูชันไดเลต .....	23
2.5.3 การเชื่อมต่อส่วนที่เหลือ .....	23
2.6 การเรียนรู้ถ่ายโอน .....	24
2.7 การตรวจจับภาวะหัวใจเต้นผิดจังหวะด้วยการเรียนรู้เชิงลึก .....	25
ระเบียบวิธีการดำเนินงาน .....	30
3.1 ฐานข้อมูลคลื่นไฟฟ้าสัญญาณหัวใจ .....	30
3.1.1 ฐานข้อมูล PhysioNet/CinC challenge 2017 .....	30
3.1.2 ฐานข้อมูล Long Term Atrial Fibrillation Database .....	31



3.2 การประเมินโมเดลการตรวจจับภาวะหัวใจห้องบนสั้นพลิ้ว .....	32
3.2.1 คอนฟิวส์ชัน เมทริกซ์ .....	32
3.2.2 ค่าความไว .....	33
3.2.3 ค่าความจำเพาะ.....	33
3.3 การใช้โครงข่ายถ่ายโอนเพื่อจำแนกภาวะหัวใจห้องบนสั้นพลิ้วด้วยภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	33
3.3.1 การเตรียมข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ.....	33
3.3.2 การใช้การเรียนรู้ถ่ายโอนแบบโครงข่ายคอนโวลูชันเพื่อเรียนรู้ภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	36
3.3.3 การทดสอบผลต่อการเกิดไบแอสของอัตราการเต้นของหัวใจมีผลที่มีต่อค่าความไวและค่าความจำเพาะของโมเดลจำแนกภาวะหัวใจห้องบนสั้นพลิ้วด้วยภาพ .....	37
3.3.4 การกำหนดเกณฑ์ใหม่เพื่อการเปรียบเทียบผลการจำแนกที่ได้จากการเรียนรู้เชิงลึกกับอัลกอริทึมซับซ้อนน้อยสำหรับไมโครคอนโทรลเลอร์ .....	38
3.4 การเปลี่ยนจากข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจเป็นข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลา .....	39
3.4.1 การแปลงข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลาเป็นข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	39
3.4.2 ความจุของข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	39
3.4.3 ขนาดของภาพที่ใช้ในโมเดล AlexNet .....	39
3.5 การใช้โครงข่ายคอนโวลูชันตามเวลาเพื่อจำแนกภาวะหัวใจห้องบนสั้นพลิ้วด้วยสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา .....	41
3.5.1 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา.....	41
3.5.1.1 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติและภาวะหัวใจห้องบนสั้นพลิ้วที่มีขนาดความยาว 30 วินาที.....	41
3.5.1.2 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	43

3.5.1.3 การทำนายเหตุสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที .....	45
3.5.2 การประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจห้องบนสั่นพลิ้วในเชิงอนุกรมเวลา .....	45
3.5.2.1 การประยุกต์ใช้โครงข่าย LSTM กับชุดข้อมูลคลื่นไฟฟ้าหัวใจ .....	47
3.5.2.2 การหาโมเดลที่เหมาะสมกับชุดข้อมูลคลื่นไฟฟ้าหัวใจ .....	50
3.5.2.3 การปรับปรุงประสิทธิภาพของโมเดลโดยการหาข้อมูลที่ผิดปกติ .....	50
3.6 การประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	52
ผลการดำเนินงานและอภิปรายผล .....	53
4.1 ผลของการใช้โครงข่ายถ่ายโอนเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	53
4.1.1 ผลการใช้การเรียนรู้ถ่ายโอนแบบโครงข่ายคอนโวลูชันเพื่อเรียนรู้ภาพสัญญาณคลื่นไฟฟ้าหัวใจ .....	53
4.1.2 ผลการทดสอบผลต่อการเกิดไบแอสของอัตราการเต้นของหัวใจที่มีผลที่มีต่อค่าความไวและค่าความจำเพาะของโมเดลจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพ .....	54
4.1.3 ผลการจำแนกภาวะหัวใจห้องบนสั่นพลิ้วที่ได้จากการเรียนรู้เชิงลึกร่วมกับอัลกอริทึมซับซ้อนน้อยสำหรับไมโครคอนโทรลเลอร์ .....	55
4.2 ผลของการใช้โครงข่ายคอนโวลูชันตามเวลาเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา .....	56
4.2.1 ผลของการหาโมเดลที่เหมาะสมกับชุดข้อมูลคลื่นไฟฟ้าหัวใจ .....	56
4.2.2 ผลของการปรับปรุงประสิทธิภาพของโมเดลโดยการหาข้อมูลที่ผิดปกติ .....	58
4.3 ผลที่ได้จากการประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	60
4.3.1 การพิจารณาสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติ .....	62
4.3.2 การพิจารณาสัญญาณคลื่นไฟฟ้าหัวใจภาวะห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	62

4.3.2.1 ความสามารถของโมเดลในการทำนายคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้น ก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	63
4.3.2.2 ความสามารถของโมเดลในการทำนายประเภทของสัญญาณคลื่นไฟฟ้าหัวใจ	63
สรุปงานวิจัยและแนวทางการทำงานวิจัยในอนาคต .....	66
5.1 สรุปงานวิจัย.....	66
5.2 แนวทางการวิจัยในอนาคต.....	67
บรรณานุกรม.....	68
ภาคผนวก.....	73
ภาคผนวก ก ระยะเวลาในการฝึกโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีพารามิเตอร์ของโมเดลที่ ต่างกัน.....	74
ภาคผนวก ข ผลการทดสอบการเปรียบเทียบประสิทธิภาพของ 3 โมเดลที่ถูกเลือกด้วย Paired T Test.....	76
ประวัติผู้เขียน.....	78

## สารบัญญภาพ

หน้า

รูปที่ 1	ระบบการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว .....	4
รูปที่ 2	ผลการคัดแยกภาวะของหัวใจจากวิธีการทาง Rhythm-based ในหน่วยไมโครคอนโทรลเลอร์ (Microcontroller Unit: MCU) ที่อาจทำนายภาวะหัวใจห้องบนเต้นก่อน, ภาวะหัวใจห้องล่างเต้นก่อน และภาวะปกติบางส่วนเป็นภาวะหัวใจห้องบนสั่นพลิ้ว .....	4
รูปที่ 3	โครงสร้างของหัวใจประกอบด้วย ห้องหัวใจ ลิ้นหัวใจ และหลอดเลือด (ซ้าย) และการไหลเวียนของเลือดผ่านปอดและเลี้ยงร่างกาย (ขวา) [16].....	7
รูปที่ 4	ระบบการนำไฟฟ้าหัวใจ [16].....	8
รูปที่ 5	สัญญาณคลื่นไฟฟ้าหัวใจและองค์ประกอบของสัญญาณ [2].....	9
รูปที่ 6	เปรียบเทียบสัญญาณคลื่นไฟฟ้าหัวใจ: (บน) ภาวะปกติ (ล่าง) ภาวะหัวใจห้องบนสั่นพลิ้ว [2] .....	10
รูปที่ 7	สัญญาณคลื่นไฟฟ้าหัวใจของผู้ป่วย 4 คนจาก The UVa Holter database ประกอบด้วย ภาวะหัวใจเต้นปกติ (A), ภาวะหัวใจห้องบนสั่นพลิ้ว (B), ภาวะหัวใจห้องล่างเต้นก่อน (C) และภาวะหัวใจห้องบนเต้นก่อน (D) [21].....	11
รูปที่ 8	ลำดับความสัมพันธ์ของปัญญาประดิษฐ์ การเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก.....	12
รูปที่ 9	ชั้นของโครงข่ายประสาท .....	14
รูปที่ 10	โครงสร้างของนิเวรอนในโครงข่ายประสาทเทียม (ปรับจาก [22]) .....	14
รูปที่ 11	ความสัมพันธ์ของแต่ละส่วนประกอบในโครงข่ายประสาท (ปรับจากหนังสือ Deep Learning with Python [23]).....	15
รูปที่ 12	การทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า .....	16
รูปที่ 13	การทำเกรเดียนต์ เดสเซนต์ปราศจากการทำโมเมนตัม (ซ้าย) และการการทำเกรเดียนต์ เดสเซนต์ที่มีการทำโมเมนตัม (ขวา) [24] .....	18
รูปที่ 14	โครงสร้างทั่วไปของโครงข่ายคอนโวลูชัน [27] .....	21
รูปที่ 15	ตัวอย่างการทำคอนโวลูชัน.....	21
รูปที่ 16	ตัวอย่างการทำการรวมโดยใช้ค่ามากที่สุด .....	21

รูปที่ 17	ชั้นของคอนโวลูชันไดเลตและตัวประกอบไดเลตชัน [30] .....	23
รูปที่ 18	ประโยชน์สามประการที่อาจเกิดขึ้นเมื่อใช้การเรียนรู้ถ่ายโอน [32] .....	24
รูปที่ 19	ตัวอย่างการทำหมายเหตุของฐานข้อมูล LTAfDB.....	31
รูปที่ 20	รายละเอียดภาพสัญญาณคลื่นไฟฟ้าหัวใจที่แปลงได้ .....	34
รูปที่ 21	ตัวอย่างภาพของสัญญาณคลื่นไฟฟ้าหัวใจในภาวะหัวใจห้องบนสั้นพลิ้ว (ซ้าย) และภาวะหัวใจเต้นปกติ (ขวา) สำหรับให้โมเดลเรียนรู้และใช้ทดสอบแบ่งเป็น ① คลื่นไฟฟ้าหัวใจที่ใช้การกำหนดเวลา (A) ② คลื่นไฟฟ้าหัวใจระหว่าง R peak (B) ③ คลื่นไฟฟ้าหัวใจในข้อที่ 2 แต่ตัด R-S segment และ Q-R segment ออก (C) และ ④ คลื่นไฟฟ้าหัวใจในองค์ประกอบความถี่ (D) ตามลำดับ.....	35
รูปที่ 22	โครงสร้างของโครงข่ายที่โอนถ่าย: โครงข่ายที่ผ่านการฝึกแล้ว (Pretrained network) คือ AlexNet (บน) และโครงสร้างของโครงข่ายที่ใช้ในงานนี้ ประกอบด้วยชั้นขาเข้าที่รับภาพสัญญาณคลื่นไฟฟ้าหัวใจเข้ามาด้วยขนาด $227 \times 227$ พิกเซล ชั้นซ่อนที่มาจากโครงข่าย AlexNet ถัดมาเป็นชั้นการเชื่อมโยงเต็มรูปแบบใหม่ 1 ชั้น และชั้นขาออกที่จำแนกภาพเป็น 2 คลาสโดยใช้ Softmax เป็นตัวจำแนกคลาส.....	37
รูปที่ 23	กระบวนการของการตั้งข้อกำหนดใหม่เพื่อเปรียบเทียบประสิทธิภาพของโมเดลจากสองอัลกอริทึมที่ต่างกัน.....	40
รูปที่ 24	ตัวอย่างข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจที่แสดงถึงส่วนของข้อมูลที่เป็นสัญญาณ (สีดำ) และส่วนของข้อมูลที่ไม่ได้ใช้งาน (สีขาว).....	41
รูปที่ 25	ตัวอย่างการเตรียมสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติและภาวะหัวใจห้องบนสั้นพลิ้วความยาว 30 วินาที .....	42
รูปที่ 26	ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจปกติ (บน) และภาวะหัวใจห้องบนสั้นพลิ้ว (ล่าง) 30 วินาทีจากการบันทึกเดียวกัน .....	42
รูปที่ 27	ตัวอย่างการเตรียมสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะความยาว 30 วินาที .....	43
รูปที่ 28	ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนบีบตัวก่อนจังหวะ (บน) และภาวะหัวใจห้องล่างบีบตัวก่อนจังหวะ (ล่าง) 30 วินาทีจากการบันทึกเดียวกัน โดยสีฟ้าแทนคลื่นไฟฟ้าหัวใจ	

ที่เป็นภาวะหัวใจปกติ สัมพัทธ์แทนภาวะหัวใจห้องบนบีบตัวก่อนจังหวะ และสี่เหลี่ยมแทนภาวะหัวใจห้องล่างบีบตัวก่อนจังหวะ ..... 44

**รูปที่ 29** การกำกับหมายเหตุสัญญาณคลื่นไฟฟ้าหัวใจ ..... 46

**รูปที่ 30** โครงสร้างของโครงข่ายคอนโวลูชันตามเวลา ..... 48

**รูปที่ 31** โครงสร้างของ LSTM ทั้ง Uni-direction LSTM (ซ้าย) และ Bi-direction LSTM (ขวา) . 49

**รูปที่ 32** ค่าความถูกต้องและค่าต้นทุนของโมเดลแบบ Uni-direction LSTM (ซ้าย) และ Bi-direction LSTM (ขวา) จากการเรียนรู้สัญญาณคลื่นไฟฟ้าหัวใจ ..... 49

**รูปที่ 33** สัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะ (บน) และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ (ล่าง) ที่ถูกเจือปนด้วยภาวะหัวใจห้องบนสั้นพลิ้วแบบครึ่งคราว ..... 51

**รูปที่ 34** กราฟการกระจายข้อมูลของชุดข้อมูลฝึกและชุดทดสอบของการทดลองแรก: ชุดข้อมูลของภาวะหัวใจห้องบนสั้นพลิ้ว (ซ้าย) และชุดข้อมูลของภาวะหัวใจเต้นปกติ (ขวา) โดยสีฟ้าและแดงแทนจำนวนของชุดฝึกและชุดทดสอบ ตามลำดับ ..... 55

**รูปที่ 35** ค่าต้นทุนขณะโมเดลทำการเรียนรู้ด้วยจำนวนรอบการเรียนรู้สูงสุดอยู่ที่ 24 (บน) และ 36 (ล่าง) รอบ ..... 61

**รูปที่ 36** ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีที่มีจำนวนลูกที่เป็นภาวะหัวใจห้องบนเต้นก่อนจังหวะอยู่อย่างน้อยร้อยละ 20 (บน) และตัวอย่างการทำนายสัญญาณของโมเดล (ล่าง) โดยที่สีฟ้า สีส้ม และสี่เหลี่ยมคือ ภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ตามลำดับ ..... 64

**รูปที่ 37** ตัวอย่างการให้คะแนนกับโมเดลในการทายภาวะหัวใจห้องบนเต้นก่อนจังหวะ ..... 64

**รูปที่ 38** ภาพรวมของระบบและตารางคอนฟิวส์ชัน เมทริกซ์ ..... 65

## สารบัญตาราง

หน้า

ตารางที่ 1	สรุปความแตกต่างระหว่างการเรียนรู้และการเรียนรู้ของเครื่อง .....	12
ตารางที่ 2	การสรุปงานวิจัยที่เกี่ยวกับการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ .....	28
ตารางที่ 3	การสรุปข้อดีและข้อจำกัดของการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว .....	29
ตารางที่ 4	ข้อมูลของฐานข้อมูล PhysioNet/CinC challenge 2017 (ตารางข้อมูลจาก AF Classification from a Short Single Lead ECG Recording - The PhysioNet Computing in Cardiology Challenge 2017 สามารถดูได้ที่ <a href="https://physionet.org/content/challenge-2017/1.0.0/">https://physionet.org/content/challenge-2017/1.0.0/</a> ) .....	30
ตารางที่ 5	คอนฟิวส์ชัน เมทริกซ์ .....	32
ตารางที่ 6	จำนวนของชุดสัญญาณคลื่นไฟฟ้าหัวใจและจำนวนภาพคลื่นไฟฟ้าหัวใจในแต่ละชุดข้อมูล .....	35
ตารางที่ 7	สรุปจำนวนของชุดข้อมูลฝึกและชุดข้อมูลทดสอบที่ซึ่งถูกแบ่งเป็น 4 ช่วงของอัตราการเต้นของหัวใจ .....	38
ตารางที่ 8	จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจเพื่อทดสอบหาค่าที่ดีที่สุดของตัวแปร .....	50
ตารางที่ 9	จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจเพิ่มเติมสำหรับโมเดลที่มีค่าตัวแปรที่เหมาะสม ...	50
ตารางที่ 10	ชุดการบันทึกสัญญาณคลื่นไฟฟ้าหัวใจที่โมเดลมักทำนายผิด .....	51
ตารางที่ 11	จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจของกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้ว .....	52
ตารางที่ 12	ผลการทดลองโมเดลแต่ละชุดข้อมูล .....	54
ตารางที่ 13	ผลการทดลองโมเดลของชุดข้อมูลที่ใช้ช่วงความยาว 1- 5 วินาที .....	54
ตารางที่ 14	ผลประสิทธิภาพของโมเดลที่ถูกทดสอบเรียนรู้และทดสอบด้วยข้อมูลที่แบ่งช่วงของอัตราการเต้นของหัวใจ .....	55
ตารางที่ 15	ผลลัพธ์ของอัลกอริทึมที่มีความซับซ้อนน้อยจากชุดข้อมูลฝึก .....	56
ตารางที่ 16	การเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึมที่มีความซับซ้อนน้อยและอัลกอริทึมที่ใช้การเรียนรู้เชิงลึกจากการใช้ข้อมูลทดสอบชุดเดียวกัน .....	56

<b>ตารางที่ 17</b> ผลประสิทธิภาพของโมเดลที่ถูกทดสอบด้วยชุดข้อมูลกลุ่มคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนสั้นพลิ้วและกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั้นพลิ้ว.....	57
<b>ตารางที่ 18</b> ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้ทดสอบด้วยชุดข้อมูลที่มีการเพิ่มภาวะหัวใจห้องล่างเต้นก่อนจังหวะเข้าไปในกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั้นพลิ้ว.....	59
<b>ตารางที่ 19</b> ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้และทดสอบด้วยชุดข้อมูลที่มีการเอาข้อมูลที่มีการปนของภาวะหัวใจห้องบนสั้นพลิ้วออก.....	60
<b>ตารางที่ 20</b> ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้และทดสอบด้วยชุดข้อมูลที่มีการนำเอา Outliers เข้ามาอยู่ในชุดข้อมูลเรียนรู้.....	60
<b>ตารางที่ 21</b> คลาสของแต่ละข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีพร้อมกับคลาสที่ได้จากการทำนายของโมเดล .....	62
<b>ตารางที่ 22</b> ผลการทำนายของโมเดลในการทายคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะตามหัวข้อ 4.3.2.1 .....	65
<b>ตารางที่ 23</b> ผลการทำนายของโมเดลในการทายประเภทของสัญญาณคลื่นไฟฟ้าหัวใจตามหัวข้อ 4.3.2.2.....	65
<b>ตารางที่ 24</b> การสรุปงานวิจัยที่เกี่ยวกับการตรวจจับภาวะหัวใจห้องบนสั้นพลิ้วที่มีภาวะหัวใจปกติภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะปนอยู่ด้วย .....	67
<b>ตารางที่ 25</b> ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 150.....	74
<b>ตารางที่ 26</b> ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 175.....	75
<b>ตารางที่ 27</b> ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 200.....	75
<b>ตารางที่ 28</b> ค่า T value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 8 ตามลำดับ.....	76
<b>ตารางที่ 29</b> ค่า P value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 8 ตามลำดับ.....	76



**ตารางที่ 30** ค่า T value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวน  
 บล็อกส่วนที่เหลือเท่ากับ 175 และ 10 ตามลำดับ..... 76

**ตารางที่ 31** ค่า P value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวน  
 บล็อกส่วนที่เหลือเท่ากับ 175 และ 10 ตามลำดับ..... 77



## บท 1

### บทนำ

#### 1.1 ที่มาและความสำคัญ

ปัจจุบันภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation: AF) เป็นภาวะหัวใจเต้นผิดจังหวะที่พบได้บ่อยในประเทศไทย และมีจำนวนผู้ที่มีภาวะนี้เพิ่มขึ้นไปทั่วโลก [1] ความชุกของการเกิดภาวะหัวใจห้องบนสั่นพลิ้วในประเทศไทยคิดเป็นร้อยละ 0.36 ในกลุ่มประชากรอายุมากกว่า 30 ปีขึ้นไป [2] อาการป่วยที่เกี่ยวข้องกับภาวะนี้นั้นมีตั้งแต่ไม่แสดงอาการใด ๆ จนไปถึงร่างกายถูกทำให้อ่อนแอจนไม่สามารถกลับมาใช้ชีวิตตามปกติได้ ความเสี่ยงที่จะทำให้เกิดภาวะหัวใจห้องบนสั่นพลิ้วนั้นมีหลายปัจจัย เช่น ความดันโลหิตสูง เบาหวาน โรคอ้วน แต่ปัจจัยเสี่ยงที่เห็นได้อย่างชัดเจนและหลีกเลี่ยงได้ยากคือ อายุที่เพิ่มมากขึ้น [3] ตัวอย่างเช่น ความชุกของภาวะนี้ในแถบประเทศตะวันตกพบได้ร้อยละ 1-2 ของประชากรอายุ 40-50 ปี และมีจำนวนผู้ที่มีอาการเพิ่มเป็นร้อยละ 5-15 เมื่ออายุ 80 ปีขึ้นไป [2] ยิ่งไปกว่านั้นภาวะหัวใจห้องบนสั่นพลิ้วยังมีความเกี่ยวข้องกับการเกิดขึ้นของอุบัติการณ์อื่น ๆ อย่างมีนัยสำคัญได้แก่ อัตราการตายที่เพิ่มขึ้น การเข้ารับรักษาพยาบาลที่มากขึ้น คุณภาพชีวิตที่ลดลง และลดความสามารถในการออกกำลังกาย อันเนื่องมาจากผลของภาวะแทรกซ้อน เช่น หัวใจล้มเหลว (Heart failure) และโดยเฉพาะอย่างยิ่ง หลอดเลือดสมองตีบตัน (Ischemic stroke) [4] กล่าวคือเมื่อหัวใจห้องบนเกิดการสั่นพลิ้วสามารถเกิดลิ่มเลือดในหัวใจขึ้นได้ ซึ่งลิ่มเลือดนี้อาจจะถูกกระแสโลหิตพัดพาเข้าไปอุดตันหลอดเลือดในสมองได้ เป็นผลให้สมองขาดออกซิเจนจนเซลล์สมองค่อย ๆ ตายไปในที่สุด ซึ่งผู้ที่มีภาวะหัวใจห้องบนสั่นพลิ้วจะมีโอกาสเกิดหลอดเลือดสมองตีบตันได้มากกว่าบุคคลอื่น 2-7 เท่า [2] จึงเห็นได้อย่างชัดเจนว่าภาวะหัวใจห้องบนสั่นพลิ้วเป็นปัญหาทางสุขภาพที่ไม่อาจมองข้ามได้ เนื่องด้วยการเข้าสู่สังคมผู้สูงอายุจึงปฏิเสธไม่ได้ว่าการเกิดภาวะนี้อาจมีเพิ่มขึ้นอีก และบ่อยครั้งที่ภาวะหัวใจห้องบนสั่นพลิ้วมักเป็นภัยเงียบ เพราะอาการไม่ได้แสดงออกอย่างชัดเจน ดังนั้นการพัฒนาขั้นตอนวิธีในการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้วที่มีประสิทธิภาพจึงเป็นที่ต้องการเพื่อการตรวจคัดกรอง (Screening test) ทางการแพทย์

การคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วที่มีประสิทธิภาพสูงโดยที่ไม่รุกรานคือ การตรวจคลื่นไฟฟ้าหัวใจ (Electrocardiography: ECG) 12 ช่องสัญญาณ (12-lead ECG) มักทำการตรวจภายในโรงพยาบาล [5] แต่ภาวะผิดปกตินี้มักจะเกิดเพียงชั่วขณะ (Paroxysmal) และอุบัติขึ้นเมื่ออยู่นอกโรงพยาบาล ดังนั้นจึงได้มีการพัฒนาอุปกรณ์พกพา (Wearable device) เพื่อให้สามารถติดตามภาวะนี้ของคนที่ใช้ได้อย่างต่อเนื่อง [6] ซึ่งอุปกรณ์พกพาจำเป็นต้องใช้แบตเตอรี่ (Battery) เป็นแหล่งพลังงานในการทำงานของไมโครคอนโทรลเลอร์ (Microcontroller) ที่อยู่ภายในอุปกรณ์ เพื่อการประมวลผลอัลกอริทึม (Algorithm) ในการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว ดังนั้นอัลกอริทึมที่ใช้นี้จะต้องมีประสิทธิภาพเพียงพอในการตรวจจับสัญญาณและประหยัดพลังงานในการทำงานของไมโครคอนโทรลเลอร์ เพื่อให้อุปกรณ์พกพาสามารถใช้ตรวจวัดกับคนใช้ได้อย่างต่อเนื่องยาวนาน จากข้อจำกัดของความซับซ้อนในการคำนวณอัลกอริทึมจึงทำให้จำเป็นต้องเลือกให้อัลกอริทึมมีค่าความไว (Sensitivity) มากพอที่จะตรวจจับภาวะที่น่าสงสัยว่าจะเป็นภาวะหัวใจห้องบนสั่นพลิ้วทั้งหมดได้ เนื่องจากมุมมองของการคัดกรองอาการหรือ

ภาวะต่าง ๆ ทางกายภาพ ค่าความไวที่สูงนั้นมีความสำคัญเป็นอย่างมาก เพื่อว่าผู้ที่มีแนวโน้มว่าจะเป็นภาวะนั้น ๆ จะได้รับการตรวจวินิจฉัยต่อโดยแพทย์เพื่อให้ได้รับการรักษาได้ทันการณ์

การเพิ่มให้ค่าความไวมีค่าสูง ๆ นั้นส่งผลให้ค่าความจำเพาะ (Specificity) มีค่าน้อยลง ทำให้สัญญาณคลื่นไฟฟ้าหัวใจที่เป็นปกติ (Normal Sinus Rhythm: NSR) ตลอดจนภาวะหัวใจห้องบนเต้นก่อนจังหวะ (Premature Atrial Contraction: PAC) และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ (Premature Ventricular Contraction: PVC) ซึ่งเป็นตัวบ่งชี้ที่สำคัญในการตรวจคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว ยังคงปะปนอยู่ในผลที่ได้จากการคัดกรองงานวิจัยนี้จึงมุ่งเน้นไปที่การปรับปรุงค่าความจำเพาะของการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว เพื่อให้สามารถแยกแยะคลื่นไฟฟ้าหัวใจภาวะปกติ รวมถึงภาวะหัวใจห้องบน และห้องล่างเต้นก่อนจังหวะออกจากภาวะหัวใจห้องบนสั่นพลิ้วได้อย่างมีประสิทธิภาพ

ดังที่กล่าวไปในข้างต้นสัญญาณคลื่นไฟฟ้าหัวใจสามารถนำมาใช้ในการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วได้ เนื่องจากสัญญาณที่บอกได้ถึงการทำงานของหัวใจ (Heart function) และสภาวะของหัวใจ (Heart condition) ในภาวะปกติสัญญาณคลื่นไฟฟ้าหัวใจจะประกอบด้วย P-wave, QRS-complex และ T-wave ซึ่งผู้ป่วยที่มีภาวะนี้ อัตราการเต้นของหัวใจจะไม่สม่ำเสมอและ P-wave ซึ่งเกี่ยวข้องกับการทำงานของหัวใจห้องบนจะไม่ปรากฏในสัญญาณคลื่นไฟฟ้าหัวใจ จากลักษณะเฉพาะของภาวะหัวใจห้องบนสั่นพลิ้วนี้ทำให้กล่าวได้ว่ามี 2 วิธีหลักในการคัดกรองสัญญาณคือ การพิจารณาจังหวะการเต้นของหัวใจ (Rhythm-based method) และการดูรูปร่างของสัญญาณคลื่นไฟฟ้าหัวใจ (Morphology-based method)

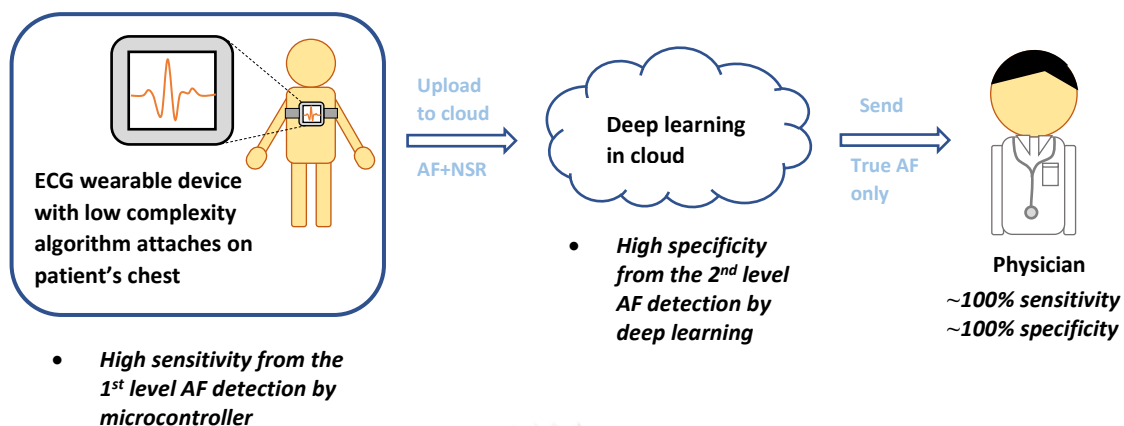
วิธีที่เป็นที่นิยมในการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้วได้แก่ การหาค่าความแปรปรวนของอัตราการเต้นของหัวใจ [7, 8] ซึ่งเกี่ยวข้องกับวิธีทาง Rhythm-based การใช้วิธีนี้ในการแยกแยะสัญญาณหัวใจภาวะปกติและภาวะหัวใจห้องบนสั่นพลิ้วนั้นได้ค่าความถูกต้องหรือค่าความไวสูง หรือสูงเฉพาะในกรณีที่ลักษณะของอัตราการเต้นของหัวใจในภาวะต่าง ๆ มีความแตกต่างกัน ดังนั้นการใช้วิธี Rhythm-based สามารถใช้ได้ดีกับภาวะหัวใจเต้นผิดปกติที่แตกต่างกันอย่างชัดเจน [9] กล่าวคือ ถ้าใช้วิธีทาง Rhythm-based อาจจะไม่สามารถแยกภาวะหัวใจเต้นผิดปกติที่มีลักษณะความแปรปรวนของอัตราการเต้นของหัวใจแบบที่ใกล้เคียงกันได้ โดยงานวิจัยนี้ได้มีความสนใจ 2 ภาวะผิดปกติคือ ภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ซึ่งทั้งสองภาวะนี้ทำให้เกิดอัตราการเต้นของหัวใจที่ไม่สม่ำเสมอเช่นเดียวกับภาวะหัวใจห้องบนสั่นพลิ้ว ดังนั้นผลการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วจากอัลกอริทึมทาง Rhythm-based ที่ใช้ในอุปกรณ์แบบพกพาอาจมีภาวะทั้งสองดังกล่าวเข้ามาปะปนอยู่ด้วยในผลการตรวจคัดกรอง

วิธีการที่จะสามารถหลีกเลี่ยงปัญหาที่เกิดขึ้นข้างต้นได้นั้นคือ การพิจารณารูปร่างของสัญญาณคลื่นไฟฟ้าหัวใจหรือวิธีทาง Morphology-based เพราะรูปร่างของแต่ละภาวะนั้นมีความแตกต่างกัน การไม่ปรากฏหรือมีลักษณะไม่ชัดเจนของ P-wave เป็นลักษณะเฉพาะของภาวะหัวใจห้องบนสั่นพลิ้ว แต่ P-wave เป็นคลื่นที่มีขนาดเล็กตรวจจับได้ยากเพราะไม่มีกฎการวิเคราะห์แยกแยะโดยกว้าง (Universal delineation rule) [10] และอีกทั้งการ

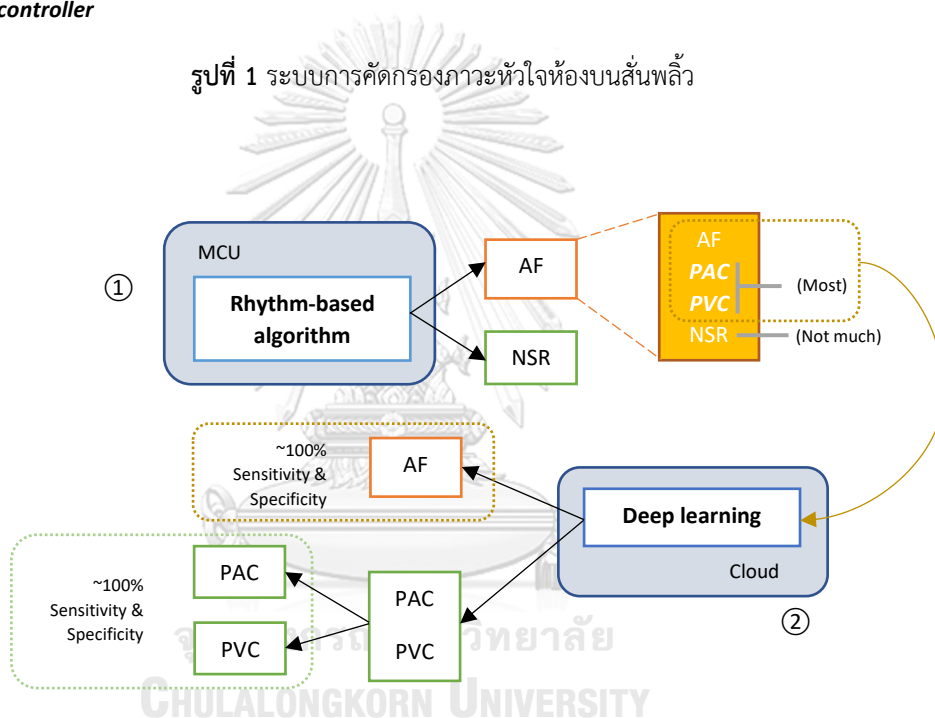
พัฒนาอัลกอริทึมให้รองรับนั้นมีความซับซ้อน วิธีนี้จึงไม่ค่อยนิยมนำมาใช้ในการแยกแยะภาวะหัวใจเต้นผิดปกตินี้ในเครื่องแบบพกพา [6]

จากการเติบโตขึ้นของการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นวิธีล่าสุดของการเรียนรู้ของเครื่อง (Machine learning) ทำให้สามารถพัฒนาระบบอัจฉริยะที่ช่วยในการตัดสินใจที่มีประสิทธิภาพมากยิ่งขึ้นในหลาย ๆ งาน เนื่องด้วยจำนวนข้อมูลทางการแพทย์ที่มีมากขึ้นบวกกับเป็นข้อมูลมีประโยชน์ในการนำมาวินิจฉัยโรค นักวิจัยจึงได้พัฒนาระบบอัจฉริยะเพื่อใช้งานทางด้านสุขภาพมากขึ้น ทั้งในเรื่องของสัญญาณและภาพทางการแพทย์ โดยเฉพาะสัญญาณคลื่นไฟฟ้าหัวใจเป็นหนึ่งในข้อมูลทางการแพทย์ที่ถูกทำการวิจัยมากที่สุด [11] การเรียนรู้เชิงลึกที่มีความสามารถในการสังเคราะห์คุณลักษณะที่สำคัญของสัญญาณคลื่นไฟฟ้าหัวใจโดยอัตโนมัติ ซึ่งเป็นคุณลักษณะสำคัญในการช่วยแยกแยะสัญญาณหัวใจในภาวะต่าง ๆ ออกจากกันได้ ตัวอย่างงานวิจัยคือ Pourbabaee, et al. [12] นำเอาโครงข่ายคอนโวลูชัน (Convolution Neural Network: CNN) ไปใช้ในการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วชนิดเกิดขึ้นชั่วคราว (Paroxysmal Atrial Fibrillation: PAF) จากข้อมูลที่มีอยู่อย่างจำกัด ถึงแม้ว่าการใช้โครงข่ายคอนโวลูชันจะเป็นโครงสร้างที่สามารถสกัดคุณลักษณะของภาพออกมาได้ดี แต่ค่าความถูกต้องที่ได้นั้นยังไม่สูงพอ ผู้เขียนอ้างว่าโมเดลโครงข่ายคอนโวลูชันของงานวิจัยนี้ไม่เหมาะกับการนำมาใช้กับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา แต่ทั้งนี้ได้มีงานวิจัยบางงานที่นำเอาโครงข่ายคอนโวลูชันไปใช้ร่วมกับโครงสร้าง Long-Short Term Memory หรือ LSTM เพื่อใช้กับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา [13] เพื่อแยกแยะภาวะหัวใจเต้นปกติ ภาวะหัวใจห้องบนเต้นก่อน และภาวะห้องล่างเต้นก่อน แต่ไม่มีการระบุค่าความไวและค่าความจำเพาะของแต่ละภาวะไว้อย่างชัดเจน นอกจากนี้ยังไม่มีการวิจัยใดที่นำเอาภาวะหัวใจห้องบนเต้นก่อน และภาวะห้องล่างเต้นก่อนมาเป็นตัวบ่งชี้เพื่อทดสอบประสิทธิภาพการทำงานของโมเดลที่สร้างขึ้นเพื่อคัดแยกภาวะหัวใจห้องบนสั่นพลิ้ว

จากที่กล่าวมาทั้งหมด จุดมุ่งหมายของงานวิจัยนี้คือการปรับปรุงความจำเพาะให้กับระบบในการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว เพื่อเพิ่มประสิทธิภาพการคัดกรองต่อจากผลการคัดกรองที่ได้จากอุปกรณ์แบบพกพา โดยนำเอาองค์ความรู้เกี่ยวกับการเรียนรู้เชิงลึกมาประยุกต์ใช้งาน ซึ่งคาดหวังว่านอกจากจะคัดกรองสัญญาณคลื่นไฟฟ้าหัวใจห้องบนเต้นสั่นพลิ้วได้อย่างมีความจำเพาะสูงเพียงพอต่อการนำไปใช้งานในทางคลินิก (ดังแสดงในรูปที่ 1) แล้วระบบที่พัฒนาขึ้นนี้อาจยังสามารถใช้ในการตรวจคัดกรองภาวะหัวใจห้องบนเต้นก่อนและภาวะห้องล่างเต้นก่อนได้อีกด้วยซึ่งเป็นดังแสดงในรูปที่ 2 โดยงานวิจัยนี้จะมุ่งเน้นไปที่การนำการเรียนรู้เชิงลึกมาใช้ เสมือนเป็นด่านคัดกรองภาวะที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้วออกก่อนส่งต่อให้กับแพทย์ และสามารถทำนายได้ถูกต้องว่าภาวะที่ป็นอยู่เป็นภาวะหัวใจห้องบนเต้นก่อนจังหวะหรือภาวะหัวใจห้องล่างเต้นก่อนจังหวะ เพื่อเพิ่มประสิทธิภาพของระบบคัดกรอง



รูปที่ 1 ระบบการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว



รูปที่ 2 ผลการคัดแยกภาวะของหัวใจจากวิธีการทาง Rhythm-based ในหน่วยไมโครคอนโทรลเลอร์ (Microcontroller Unit: MCU) ที่อาจทำนายภาวะหัวใจห้องบนเต้นก่อน, ภาวะหัวใจห้องล่างเต้นก่อน และภาวะปกติบางส่วนเป็นภาวะหัวใจห้องบนสั่นพลิ้ว

## 1.2 วัตถุประสงค์

พัฒนาระบบการตรวจจับสัญญาณคลื่นไฟฟ้าหัวใจห้องบนสั้นพลิ้วโดยนำการเรียนรู้เชิงลึกมาประยุกต์ใช้ เพื่อปรับปรุงค่าความจำเพาะของการตรวจจับภาวะหัวใจห้องบนสั้นพลิ้ว โดยมีตัวสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติ และสัญญาณคลื่นไฟฟ้าหัวใจที่ผิดปกติจากภาวะห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะเป็นตัวรบกวน

## 1.3 ขอบเขตของงานวิจัย

1.3.1 งานวิจัยนี้ได้มุ่งเน้นไปที่การสร้างโมเดลการเรียนรู้เชิงลึกเพื่อคัดกรองภาวะหัวใจห้องบนสั้นพลิ้ว โดยใช้วิธีการวิเคราะห์ทางสัญญาณวิทยา หรือ Morphology-based method ซึ่งโมเดลแรกได้ใช้ฐานข้อมูล The PhysioNet Computing in Cardiology Challenge 2017 [14] ที่เป็นสัญญาณคลื่นไฟฟ้าหัวใจแบบสั้น (ระยะเวลาระหว่าง 30 ถึง 60 วินาที) ที่ได้จากการบันทึก 1 ช่องสัญญาณ และโมเดลที่ใช้เป็น AlexNet ซึ่งเป็นโครงข่ายคอนโวลูชันนำมาใช้เป็นการเรียนรู้ถ่ายโอน (Transfer learning) และทดสอบผลต่อการเกิดไบแอส (Bias) ของอัตราการเต้นของหัวใจมีผลที่มีต่อค่าความไวและค่าความจำเพาะของโมเดล

1.3.2 สร้างโมเดลโดยใช้ฐานข้อมูล Long Term AF Database [15] เพื่อนำสัญญาณคลื่นไฟฟ้าภาวะหัวใจห้องบนเต้นก่อนจังหวะและคลื่นไฟฟ้าหัวใจภาวะห้องล่างเต้นก่อนจังหวะ มาเป็นสัญญาณรบกวนเพื่อทดสอบประสิทธิภาพการคัดแยกความผิดปกติทั้งสองนี้ออกจากภาวะหัวใจห้องบนสั้นพลิ้วของโมเดลที่พัฒนาขึ้น

1.3.3 เมื่อสามารถแยกภาวะหัวใจห้องบนสั้นพลิ้วได้แล้ว จะทำการศึกษาความเป็นไปได้ในการแยกแยะภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 ระบบที่พัฒนาขึ้นโดยใช้การเรียนรู้เชิงลึกเข้ามาช่วยนั้นจะสามารถเพิ่มประสิทธิภาพของระบบการตรวจจับสัญญาณคลื่นไฟฟ้าหัวใจห้องบนสั้นพลิ้วได้ โดยเฉพาะอย่างยิ่งค่าจำเพาะในการตรวจจับ

1.4.2 โมเดลสามารถแยกภาวะหัวใจห้องบนสั้นพลิ้วได้อย่างถูกต้อง แม้จะมีตัวรบกวนอย่างภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ และสามารถทำนายประเภทของภาวะผิดปกติของหัวใจที่มากรวนได้

1.4.3 ระบบนี้สามารถใช้เป็นระบบการดูแลสุขภาพเชิงป้องกันและช่วยคัดกรองภาวะผิดปกตินี้ได้อย่างถูกต้อง เพื่อเป็นข้อมูลให้แพทย์สามารถดำเนินการรักษาต่อไปได้อย่างมีประสิทธิภาพ

## บท 2

### การทบทวนวรรณกรรม

#### 2.1 สัญญาณคลื่นไฟฟ้าหัวใจและภาวะหัวใจเต้นผิดจังหวะ

##### 2.1.1 สัญญาณคลื่นไฟฟ้าหัวใจ

หัวใจสามารถทำงานด้วยการส่งผ่านสัญญาณทางไฟฟ้า เมื่อหัวใจทำการหดหรือคลายสัญญาณไฟฟ้านี้จะเดินทางไปทั่วทั้งร่างกาย เมื่อทำการวางขั้วอิเล็กโทรดลงบนผิวหนังบริเวณรยางค์หรือบริเวณอกของผู้ที่ต้องการตรวจวัด จะปรากฏสัญญาณหรือเส้นกราฟที่แสดงการทำงานของหัวใจตลอดเวลา เรียกว่า สัญญาณคลื่นไฟฟ้าหัวใจ (Electrocardiogram: ECG)


##### 2.1.1.1 หน้าที่และโครงสร้างของหัวใจ

หัวใจเป็นอวัยวะที่สำคัญในระบบหัวใจหลอดเลือด (Cardiovascular system) โดยหัวใจจะทำการนำส่งสารต่าง ๆ ไปทั่วทั้งร่างกาย ไม่ว่าจะเป็นการขนส่งสารอาหาร แก๊สออกซิเจน ฮอรโมน เซลล์ที่เกี่ยวข้องกับระบบภูมิคุ้มกัน ของเสีย หรือแม้แต่การช่วยกระจายความร้อนให้กับส่วนต่าง ๆ ของร่างกายผ่านเลือดที่หัวใจทำการสูบฉีด

โดยทั่วไปการไหลเวียนของเลือดในร่างกายนั้นเกิดจากการทำงานที่สัมพันธ์กันของห้องหัวใจ ลิ้นหัวใจ และหลอดเลือด ซึ่งถือได้ว่าส่วนประกอบของหัวใจในแต่ละส่วนถูกออกแบบมาโดยคำนึงถึงหน้าที่และประโยชน์การใช้งานเป็นหลักหรือที่เรียกว่า Form follows Function ซึ่งหัวใจแบ่งออกเป็น 4 ห้องด้วยกันได้แก่ หัวใจห้องบนขวา (Right atrium) หัวใจห้องบนซ้าย (Left atrium) หัวใจห้องล่างขวา (Right ventricle) และหัวใจห้องล่างซ้าย (Left ventricle) โดยหัวใจห้องบนมีหน้าที่ในการรับเลือดจากส่วนต่าง ๆ ของร่างกายและส่งต่อไปยังหัวใจห้องล่าง จากนั้นหัวใจห้องล่างจะทำการบีบเลือดออกจากหัวใจไปเลี้ยงอวัยวะอื่น ๆ โดยหัวใจห้องบนและหัวใจห้องล่างจะรองรับความดันเลือดที่แตกต่างกันคือ ความดันต่ำและความดันสูง ตามลำดับ อันเนื่องมาจากหัวใจห้องบนมีผนังของหัวใจที่บางกว่าหัวใจห้องล่าง หัวใจแต่ละห้องจะถูกกั้นด้วยลิ้นหัวใจ โดยทำหน้าที่ในการเปิดเพื่อให้เลือดไหลจากที่หนึ่งไปยังอีกที่หนึ่งและปิดเพื่อกันไม่ให้เลือดไหลย้อนกลับ สุดท้ายสิ่งที่เชื่อมต่อทั้งระบบเข้าด้วยกันคือ หลอดเลือดอาร์เตอรี (Artery) เป็นหลอดเลือดที่นำเลือดออกจากหัวใจไปสู่เนื้อเยื่อต่าง ๆ และหลอดเลือดเวน (Vein) ที่นำเลือดกลับเข้าสู่หัวใจ

วงจรไหลเวียนของเลือดแบ่งออกเป็น 2 ส่วนได้แก่ วงจรการไหลเวียนผ่านปอด (Pulmonary circulation loop) และวงจรการไหลเวียนเลี้ยงร่างกาย (Systemic circulation loop) แต่ละวงจรการไหลเวียนจะผ่านห้องหัวใจด้านขวาและห้องหัวใจด้านซ้าย ตามลำดับ โดยเริ่มจากการนำเอาเลือดที่มีปริมาณแก๊สออกซิเจนต่ำ (Deoxygenated blood) จากส่วนต่าง ๆ ของร่างกายกลับเข้าสู่หัวใจห้องบนขวาและเลือดจากหัวใจห้องล่างขวาก็จะถูกส่งไปพอกที่ปอด จากนั้นเลือดที่เข้าสู่ปอดจะทำการแลกเปลี่ยนแก๊ส ทำให้เลือดมีปริมาณแก๊สออกซิเจนที่มากพอ (Oxygenated blood) เลือดนั้นจะไหลเวียนกลับเข้าสู่หัวใจห้องบนซ้ายและส่งต่อเลือดให้กับหัวใจห้องล่างซ้ายเพื่อ

นำเลือดที่มากด้วยแก๊สออกซิเจนไปเลี้ยงเนื้อเยื่อต่าง ๆ ของร่างกายและรับเลือดที่มีปริมาณแก๊สออกซิเจนต่ำกลับเข้ามาที่หัวใจห้องบนขวาอีกครั้งวนไปเป็นวัฏจักรเช่นนี้ดังในรูปที่ 3 ซึ่งแสดงโครงสร้างของหัวใจและการไหลเวียนเลือด เนื่องจากแก๊สออกซิเจนเป็นสารที่สำคัญที่ร่างกายต้องการอยู่ตลอดเวลา จากที่กล่าวมาจะเห็นได้ว่าการทำงานที่ปกติของหัวใจนั้นมีผลต่อการได้รับแก๊สออกซิเจนที่เพียงพอต่อความต้องการของร่างกายเป็นอย่างมาก




รูปที่ 3 โครงสร้างของหัวใจประกอบด้วย ห้องหัวใจ ลิ้นหัวใจ และหลอดเลือด (ซ้าย) และการไหลเวียนของเลือดผ่านปอดและเลี้ยงร่างกาย (ขวา) [16]

#### 2.1.1.2 การเต้นของหัวใจ

การที่จะเข้าใจว่าหัวใจสามารถเต้นได้อย่างไรต้องเข้าใจพื้นฐานลักษณะของกล้ามเนื้อของหัวใจเสียก่อน กล่าวคือหัวใจมีกลุ่มเซลล์กล้ามเนื้อที่แตกต่างจากเนื้อเยื่อกล้ามเนื้ออื่น ๆ เนื้อเยื่อกล้ามเนื้อหัวใจ (Cardiac muscle tissue) นั้นจะทำงานนอกอำนาจของจิตใจ (Involuntary) แต่ละเซลล์จะทำงานร่วมกันตลอดเวลาทั้งในเชิงกายภาพและเชิงไฟฟ้า โดยแต่ละเซลล์จะทำงานประสานกันในการสร้างระดับการเปลี่ยนแปลงของแรงดัน (Pressure gradient) ภายในหัวใจได้อย่างถูกต้องแม่นยำเพื่อสูบฉีดเลือดให้กับร่างกาย

สัญญาณทางไฟฟ้าเป็นสิ่งที่คอยควบคุมจังหวะการทำงานของหัวใจ เพื่อให้หัวใจหดและคลายอย่างเป็นจังหวะ ซึ่งมีกลุ่มเซลล์กล้ามเนื้อหัวใจบางส่วนที่สามารถผลิตสัญญาณไฟฟ้าได้เอง เรียกว่า เซลล์เพซเมกเกอร์ (Pacemaker cells) กลุ่มเซลล์นี้จะทำการผลิตสัญญาณไฟฟ้าเริ่มต้นและส่งกระแสไฟฟ้าผ่านระบบลวดเชื่อมต่อภายในหัวใจหรือที่เรียกว่า ระบบการนำไฟฟ้าหัวใจ (Cardiac conducting system) แสดงในรูปที่ 4 ซึ่งทำหน้าที่นำสัญญาณไฟฟ้าจากหัวใจห้องบนสู่หัวใจห้องล่าง






รูปที่ 4 ระบบการนำไฟฟ้าหัวใจ [16]

การเต้นของหัวใจนั้นสิ่งแรกที่เกิดคือ การเกิดคลื่นกลับขั้ว (Depolarization wave) ที่ SA node (Sinoatrial node) ซึ่งเป็นเซลล์พิเศษที่ตามธรรมชาติที่อยู่บริเวณหัวใจห้องบนขวา จากนั้นสัญญาณไฟฟ้าจะแพร่กระจายไปยังเซลล์กล้ามเนื้อหัวใจห้องบนทั้งสองห้อง สัญญาณไฟฟ้าจะเดินทางต่อไปยัง AV node (Atrioventricular node) ที่บริเวณนี้สัญญาณจะถูกหน่วงไว้ ดังนั้นการบีบตัวของหัวใจห้องบนจะเสร็จสิ้นก่อนที่หัวใจห้องล่างจะหดตัว ทำให้เลือดถูกส่งไปที่หัวใจห้องล่าง จากนั้นสัญญาณไฟฟ้าเดินทางไปยัง Bundle of His, Bundle branches และ Purkinje fibers ตามระบบการนำไฟฟ้าหัวใจ เพื่อให้สัญญาณไฟฟ้าเดินทางไปยังหัวใจห้องล่างได้ และทำการกระตุ้นให้หัวใจห้องล่างบีบตัว เลือดจะถูกส่งไปเลี้ยงร่างกายต่อไปในที่สุด จากลักษณะการทำงานของหัวใจจะเห็นว่าหัวใจเป็นเหมือนปั๊ม 2 ตัวทำงานประสานกันซึ่งจำเป็นต้องมีระบบการนำไฟฟ้าหัวใจเป็นตัวเชื่อมสัญญาณไฟฟ้ากับเซลล์กล้ามเนื้อหัวใจ เพื่อให้เซลล์กล้ามเนื้อหัวใจทั้งหมดทำงานประสานกันได้อย่างมีประสิทธิภาพ

คลื่นไฟฟ้าหัวใจเกิดขึ้นในขณะที่หัวใจทำงานอยู่ โดยทั่วไปสัญญาณคลื่นไฟฟ้าหัวใจจะประกอบด้วย P-wave เป็นคลื่นขนาดเล็ก (0.25 mV) [17] เกิดจากสัญญาณไฟฟ้าเดินทางไปที่หัวใจห้องบนทำงาน หัวใจห้องบนทั้งสองห้องจะหดตัวเพื่อส่งเลือดไปยังหัวใจห้องล่าง หลังจากนั้นหัวใจห้องบนก็จะคลายตัวอย่างรวดเร็ว ตามด้วย QRS-complex ซึ่งเกิดจากหัวใจห้องล่างบีบตัว เพราะสัญญาณไฟฟ้ากระจายมายังหัวใจห้องล่างและกระตุ้นให้บีบเลือดเพื่อไปเลี้ยงร่างกาย หลังจากนั้นหัวใจห้องล่างจะคลายตัวทำให้เกิด T-wave วัฏจักรการทำงานของหัวใจจะวนไปแบบนี้เรื่อย ๆ [16] ดังในรูปที่ 5 สัญญาณคลื่นไฟฟ้าหัวใจนี้ประกอบไปด้วยข้อมูลที่สำคัญเกี่ยวกับการทำงานของหัวใจ ไม่ว่าจะเป็นการนำของกระแสไฟฟ้า สภาพของกล้ามเนื้อหัวใจ การเต้นผิดจังหวะของหัวใจ เพราะการเปลี่ยนแปลงของเวลาและรูปร่างของการเกิดสัญญาณคลื่นไฟฟ้าหัวใจนั้นสามารถถูกเปลี่ยนไปได้ตามลักษณะของพยาธิสภาพของโรคที่เกิดขึ้นได้ [18]



รูปที่ 5 สัญญาณคลื่นไฟฟ้าหัวใจและองค์ประกอบของสัญญาณ [2]

### 2.1.2 ภาวะหัวใจเต้นผิดจังหวะ

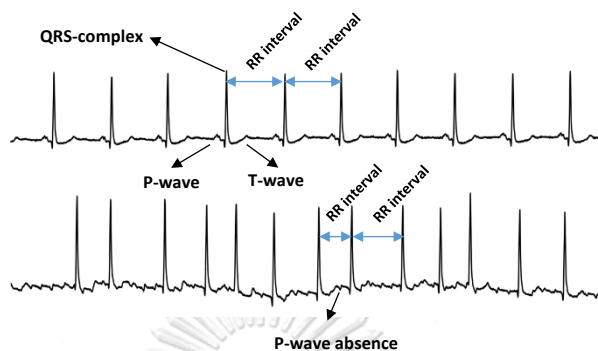
ภาวะหัวใจเต้นผิดจังหวะ (Cardiac arrhythmia) ที่งานวิจัยนี้มุ่งเน้นได้แก่ ภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation: AF) ภาวะหัวใจห้องบนเต้นก่อนจังหวะ (Premature Atrial Contraction: PAC) และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ (Premature Ventricular Contraction: PVC)

#### 2.1.2.1 ภาวะหัวใจห้องบนสั่นพลิ้ว

ภาวะหัวใจห้องบนสั่นพลิ้วเกิดจากการที่สัญญาณไฟฟ้าที่สั่งการหัวใจห้องบนกระตุ่นการทำงานแบบไม่เป็นระเบียบ การบีบตัวของกล้ามเนื้อหัวใจห้องบนเสียไป ทำให้เลือดลงไปยังหัวใจห้องล่างลดน้อยลง เป็นเหตุให้การสูบฉีดเลือดไปสู่ร่างกายจึงน้อยลงตาม อีกทั้งการขณะเกิดภาวะนี้ยังทำให้การตอบสนองของหัวใจห้องล่างทำได้ไม่ดี ส่งผลให้เกิดหัวใจวายได้ (Heart failure) นอกจากนี้อัตราการเกิดหลอดเลือดสมองตีบตัน (Ischemic stroke) ก็มากขึ้นในผู้ป่วยที่เป็นภาวะนี้ อันเนื่องมาจากการทำงานไม่สัมพันธ์กันของกล้ามเนื้อหัวใจห้องบนทำให้การไหลเวียนของเลือดในหัวใจห้องบนเป็นไปอย่างไม่เป็นระเบียบ ก่อให้เกิดลิ่มเลือด และลิ่มเลือดนี้อาจจะหลุดรอดออกไปตามระบบไหลเวียนโลหิตไปอุดตันที่หลอดเลือดที่อวัยวะสำคัญอย่างสมองได้ สุดท้ายเลือดไม่สามารถไปเลี้ยงสมองบริเวณนั้นได้ สมองจึงตายจนเกิดภาวะอัมพฤกษ์ อัมพาต หรือเสียชีวิตลงในที่สุด [2]

แม้ว่าภาวะหัวใจห้องบนสั่นพลิ้วจะมีการแสดงอาการบ้าง เช่น อาการใจสั่น หายใจติดขัด แน่นหน้าอก แต่มีรายงานว่า 1 ใน 3 ของผู้ป่วยภาวะนี้ไม่แสดงอาการเหล่านี้ ใดๆ [19] ภาวะหัวใจห้องบนสั่นพลิ้วในผู้ป่วยกลุ่มนี้ก็ยังคงไม่ถูกตรวจจับได้จนกระทั่งเกิดภาวะแทรกซ้อนที่ร้ายแรงอย่างหัวใจวายหรือหลอดเลือดสมองตีบตันเกิดขึ้น เมื่อไม่มีการตรวจพบหรือการรักษาอย่างทันท่วงที ภาวะนี้จึงนำมาสู่ความเจ็บป่วยที่ร้ายแรง อัตราการตายที่เพิ่มมากขึ้น และมีผู้ป่วยอัมพฤกษ์ อัมพาตมากขึ้น บุคคลเหล่านี้จะกลายเป็นภาระของครอบครัว และระบบสาธารณสุขของประเทศในด้านของการดูแลและเศรษฐกิจ

เอกลักษณ์ของภาวะหัวใจห้องบนสั้นพลิ้วที่ปรากฏในสัญญาณคลื่นไฟฟ้าหัวใจนั้นคือ P-wave มีลักษณะไม่ชัดเจน ไม่สม่ำเสมอ ความถี่ไม่เกิน 350 ครั้งต่อนาที เพราะหัวใจบนห้องบนสูญเสียหน้าที่การสูบฉีดเลือดไป อีกทั้งอัตราการเต้นของหัวใจหรือ RR interval ก็ไม่คงที่ [2] ดังแสดงในรูปที่ 6



รูปที่ 6 เปรียบเทียบสัญญาณคลื่นไฟฟ้าหัวใจ: (บน) ภาวะปกติ (ล่าง) ภาวะหัวใจห้องบนสั้นพลิ้ว [2]

#### 2.1.2.2 ภาวะหัวใจห้องบนเต้นก่อนจังหวะ

ภาวะหัวใจห้องบนเต้นก่อนจังหวะ คือภาวะที่สัญญาณไฟฟ้าอื่นมากระตุ้นให้หัวใจห้องบนบีบตัวก่อน โดยปกติ SA node จะเป็นตัวกำหนดจังหวะการทำงานของหัวใจทำให้หัวใจเต้นปกติ แต่ภาวะนี้มีสัญญาณอื่นมากระตุ้นก่อน SA node สั่งการ สัญญาณคลื่นไฟฟ้าหัวใจที่ได้คือ P-wave จะไปอยู่ร่วมกับ T-wave [20] ทำให้เห็น T-wave ไม่เต็มลูกหรือหายไป ดังนั้น P-wave ที่ได้จะมีรูปร่างผิดปกติด้วย


#### 2.1.2.3 ภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

ภาวะหัวใจห้องล่างเต้นก่อนจังหวะ เป็นภาวะหัวใจห้องล่างบีบตัวก่อน สาเหตุยังคงคลุมเครือแต่อาจเกิดจากโรคหัวใจทำให้เซลล์ (Cell) ของหัวใจห้องล่างทำงานผิดปกติเชิงไฟฟ้า สัญญาณที่ได้จากภาวะนี้มีหลายรูปแบบ คลื่น QRS-complex จะมีรูปร่างที่แปลกประหลาด หลังจากเกิดภาวะนี้ขึ้น การเต้นของหัวใจจะถูกหยุดไปช่วงสั้น ๆ และมีสัญญาณปกติตามมา [20]

จากการศึกษาด้านสรีรวิทยาของหัวใจ ในขณะที่หัวใจเกิดภาวะหัวใจห้องบนสั้นพลิ้วนั้น ไม่อาจเกิดภาวะหัวใจห้องบนเต้นก่อนจังหวะได้ เนื่องจากเมื่อหัวใจห้องบนเกิดการสั้นพลิ้ว ฟังก์ชันการทำงานในฐนาระบีมของหัวใจห้องบนได้สูญเสียไปแล้ว แต่อาจเกิดหัวใจห้องล่างเต้นก่อนจังหวะได้ เพราะการทำงานของหัวใจห้องล่างยังสามารถถูกกระตุ้นให้บีบตัวได้

จากรูปที่ 7 แสดงลักษณะของคลื่นไฟฟ้าหัวใจ 4 ชนิด ได้แก่ ภาวะหัวใจเต้นปกติ (A), ภาวะหัวใจห้องบนสั้นพลิ้ว (B), ภาวะหัวใจห้องล่างเต้นก่อน (C) และภาวะหัวใจห้องบนเต้นก่อน (D) [21] จะเห็นได้ว่าภาวะของหัวใจทั้ง 4 ชนิดมีรูปร่างของสัญญาณที่ต่างกัน ดังนั้นข้อมูลความผิดปกติที่ได้จากสัญญาณคลื่นไฟฟ้าหัวใจจึงมีความสำคัญ

ไม่ว่าจะเป็นจุดยอด (Peak) และขนาดความกว้าง (Width) ของสัญญาณคลื่นไฟฟ้าหัวใจก็สามารถนำมาพิจารณาชนิดของภาวะหัวใจได้ [12]



รูปที่ 7 สัญญาณคลื่นไฟฟ้าหัวใจของผู้ป่วย 4 คนจาก The UVa Holter database ประกอบด้วย ภาวะหัวใจเต้นปกติ (A), ภาวะหัวใจห้องบนสั่นพลิ้ว (B), ภาวะหัวใจห้องล่างเต้นก่อน (C) และภาวะหัวใจห้องบนเต้นก่อน (D) [21]

## 2.2 การเรียนรู้เชิงลึก


### 2.2.1 ความหมายของการเรียนรู้เชิงลึก

การเรียนรู้เชิงลึก (Deep learning) เป็นส่วนหนึ่งของการเรียนรู้ของเครื่อง (Machine learning) ซึ่งการเรียนรู้ของเครื่องนี้เป็นสาขาหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence) หรือที่นิยมเรียกกันว่า AI ดังแสดงในรูปที่ 8 โดยปัญญาประดิษฐ์คือ การสร้างให้เครื่องจักรหรือคอมพิวเตอร์มีความฉลาดคล้ายคลึงกับมนุษย์ ส่วนการเรียนรู้ของเครื่องคือ วิธีการที่ช่วยให้ปัญญาประดิษฐ์สามารถทำงานนั้น ๆ ได้ โดยผ่านการใช้อัลกอริทึมต่าง ๆ ที่ได้รับการฝึกจากชุดข้อมูลนั้น ๆ สุดท้ายการเรียนรู้เชิงลึกคือ อัลกอริทึมหนึ่งของการเรียนรู้ของเครื่องที่โครงสร้างภายในถูกออกแบบโดยได้รับแนวคิดจากการทำงานของสมองของมนุษย์

### 2.2.2 ความแตกต่างของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง

การเรียนรู้เชิงลึกนั้นมีข้อแตกต่างจากการเรียนรู้ของเครื่องอยู่ ถ้าหากต้องการสร้างเครื่องจักรที่แยกภาพชนิดต่าง ๆ การใช้การเรียนรู้ของเครื่อง ผู้ที่เตรียมข้อมูลจำเป็นต้องค้นหาคุณลักษณะ (Features) ที่แสดงถึงชุดข้อมูลนั้น ๆ ได้ดีที่สุด เพื่อให้เครื่องนำเอาคุณลักษณะที่สกัดได้ไปเรียนรู้เพื่อหารูปแบบ และทำการแบ่งประเภทของข้อมูล (Classification) ออกมาได้ถูกต้อง ดังนั้นการทำการเรียนรู้ของเครื่องจำเป็นต้องมีความรู้ความเข้าใจ

เกี่ยวกับคุณลักษณะทางวิศวกรรม (Feature engineering) ของข้อมูลชุดนั้น ๆ เป็นอย่างไรก็ตาม เป็นไปได้ยากที่จะเข้าใจหรือได้มาซึ่งคุณลักษณะที่ดีที่สุดของชุดข้อมูลที่ใช้ การเรียนรู้เชิงลึกจึงเป็นอีกหนึ่งวิธีการที่จะมาช่วยสกัดคุณลักษณะที่ดีที่สุดของข้อมูลออกมา โดยที่ผู้ใช้ไม่จำเป็นต้องไปเข้าไปแทรกแซงมากนัก แต่การได้มาซึ่งคุณลักษณะที่ดีที่สุดของข้อมูลจากการทำการเรียนรู้เชิงลึกนั้นจำเป็นต้องมีข้อมูลจำนวนมากเพื่อให้เครื่องได้เรียนรู้ แม้ว่า การเรียนรู้เชิงลึกจะทำงานได้ดีกับข้อมูลที่ไม่ได้ผ่านการสกัดคุณลักษณะ การประมวลผลที่มีประสิทธิภาพก็ต้องอาศัยฮาร์ดแวร์ (Hardware) ที่มีประสิทธิภาพมากพอเช่นกัน ซึ่งการเรียนรู้เชิงลึกต้องการหน่วยประมวลผลทางด้านกราฟิก (Graphic Processing Units: GPUs) เป็นหลักซึ่งมีราคาที่สูง และนอกจากนี้เมื่อเทียบกับการเรียนรู้ของเครื่องแล้ว การเรียนรู้เชิงลึกต้องใช้เวลาในการเรียนรู้ที่มากกว่าตั้งแต่ใช้เวลาไม่เพียงไม่กี่ชั่วโมงจนยาวนานเป็นเดือน โดยระยะเวลาที่ใช้ในการเรียนรู้จะเพิ่มขึ้นอันเนื่องมาจากจำนวนของข้อมูลที่มากขึ้นและขึ้นอยู่กับความลึกของโครงสร้างภายในของการเรียนรู้เชิงลึกด้วย



รูปที่ 8 ลำดับความสัมพันธ์ของปัญญาประดิษฐ์ การเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก

### จุฬาลงกรณ์มหาวิทยาลัย

ตารางที่ 1 สรุปความแตกต่างระหว่างการเรียนรู้และการเรียนรู้ของเครื่อง

ข้อเปรียบเทียบ	การเรียนรู้เชิงลึก	การเรียนรู้ของเครื่อง
จำนวนของชุดข้อมูลฝึก	ข้อมูลขนาดใหญ่	จำนวนน้อยถึงจำนวนปานกลาง
ความสามารถในการเลือกคุณลักษณะของชุดข้อมูล	- ผู้ใช้ไม่จำเป็นต้องสกัดคุณลักษณะที่ดีที่สุด - การเรียนรู้เชิงลึกสามารถเลือกคุณลักษณะที่ดีที่สุดให้ได้	- ผู้ใช้มีความเข้าใจและสามารถเลือกคุณลักษณะที่ดีที่สุดได้ - ต้องใช้ข้อมูลที่มีการสกัดคุณลักษณะแล้ว
ประสิทธิภาพของอุปกรณ์	ระดับอุปกรณ์ที่มีประสิทธิภาพในการคำนวณสูง	ประสิทธิภาพในการคำนวณของอุปกรณ์ไม่สูงมาก
ระยะเวลาในการฝึก	ใช้ระยะเวลานาน	ใช้ระยะเวลาสั้น

## 2.3 โครงข่ายประสาทเทียม

หากพูดถึงโครงสร้างภายในของการเรียนรู้เชิงลึกซึ่งคือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ซึ่งเป็นโครงสร้างที่ได้รับแนวคิดมาจากเครือข่ายการเชื่อมต่อกันทางชีววิทยา (Biological neural network) ของสมอง คำว่า “เชิงลึก” จากการเรียนรู้เชิงลึกนั้นหมายถึงการเชื่อมต่อกันหลาย ๆ ชั้นภายในโครงข่ายประสาทเทียม ซึ่งชั้นต่าง ๆ จะทำการสกัดคุณลักษณะของข้อมูลออกมา กระบวนการนี้จะทำโดยอัตโนมัติ โดยคุณลักษณะที่ได้ในแต่ละชั้นจะเป็นข้อมูลของชั้นถัดไป และเข้าสู่การแบ่งประเภทในที่สุด

### 2.3.1 ส่วนประกอบของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม คือ เทคนิคในการสร้างโปรแกรมคอมพิวเตอร์ขึ้นมาโดยการเรียนรู้จากข้อมูล โครงข่ายประสาทจะเป็นการเลียนแบบการเชื่อมต่อของเซลล์ประสาท (Nerve cell) ของมนุษย์ ซึ่งประกอบด้วยชั้นรับข้อมูล (Input layer) จะทำการรับข้อมูลส่งต่อไปให้ชั้นซ่อน (Hidden layer) สามารถมีได้หลายชั้น ในแต่ละชั้นซ่อนจะประกอบไปด้วยหลาย ๆ หน่วยของเซลล์ประสาท เรียกว่า นิวรอน (Neuron) ต่อจากนั้นชั้นขาออก (Output layer) จะเป็นตัวรับข้อมูลต่อและทำนายผลต่อไป โดยส่วนประกอบของโครงข่ายประสาทเทียมแสดงดังในรูปที่ 9 ทั้งนี้ชุดข้อมูลฝึกจะเข้าสู่โครงข่ายประสาทหลายครั้ง ช่วยทำให้โมเดลสามารถปรับประสิทธิภาพในการทำนายผลได้ดียิ่งขึ้น


การต่อกันของโครงข่ายประสาทโดยทั่วไป นิวรอนของชั้นก่อนหน้าจะต่อกับนิวรอนชั้นถัดไป เพื่อทำการส่งข้อมูล การต่อกันแบบทั่วถึงเรียกว่า ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully-connected layer) คือ นิวรอนทุกตัวของชั้นก่อนหน้าจะต่อกับนิวรอนทุกตัวของชั้นถัดไป การที่โมเดลสามารถทำนายผลจากข้อมูลที่เรียนรู้ได้นั้นเพราะแต่ละข้อมูลมีค่าถ่วงน้ำหนัก (Weight) ไม่เท่ากัน ซึ่งจะเป็นตัวบอกว่าข้อมูลใดในนิวรอนนั้นมีความสำคัญควรนำมาพิจารณา เมื่อข้อมูลเข้าสู่นิวรอน ข้อมูลนั้นจะถูกคูณด้วยค่าถ่วงน้ำหนัก จากนั้นบวกด้วยค่าไบแอส (Bias) ผลรวมที่ได้จะเข้าสู่ฟังก์ชันกระตุ้น (Activation function) และส่งข้อมูลที่ถูกคำนวณให้ชั้นถัดไป ดังแสดงในรูปที่ 10

$$X_{node} = [x_1, x_2, \dots, x_n] \quad (1)$$

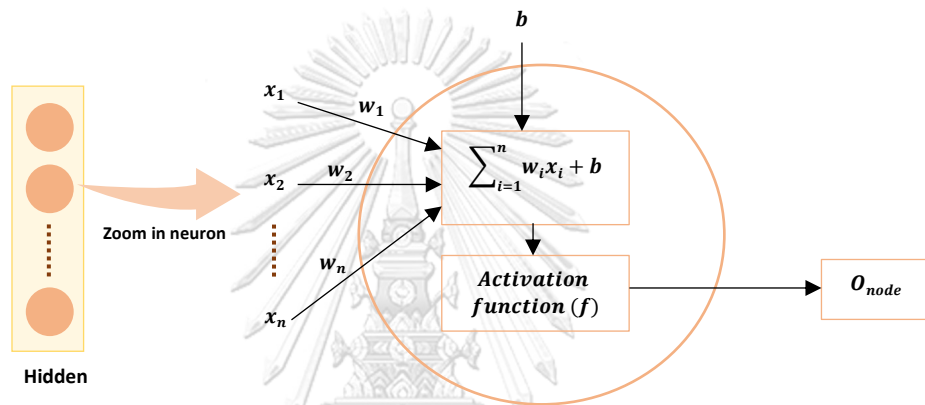
$$W_{node} = [w_1, w_2, \dots, w_n] \quad (2)$$

$$O_{node} = f(\sum_{i=1}^n w_i x_i + b) \quad (3)$$

จากสมการที่ 1  $X_{node}$  คือ เมทริกซ์ของข้อมูลขาเข้าของนิวรอนนั้น ๆ ประกอบด้วย  $[x_1, x_2, \dots, x_n]$  ส่วนสมการที่ 2 คือ  $W_{node}$  คือ เมทริกซ์ของค่าถ่วงน้ำหนักของนิวรอนนั้น ๆ ประกอบด้วย  $[w_1, w_2, \dots, w_n]$  และสมการที่ 3 แสดงการทำงานของฟังก์ชันกระตุ้นแทนด้วย  $f$  และไบแอสคือ  $b$  ส่วน  $O_{node}$  คือ ผลลัพธ์ที่ได้จาก Node หรือนิวรอนนั้น ๆ



รูปที่ 9 ชั้นของโครงข่ายประสาท



รูปที่ 10 โครงสร้างของนิวรอนในโครงข่ายประสาทเทียม (ปรับจาก [22])

จากโครงสร้างของนิวรอนในโครงข่ายประสาทเทียมที่กล่าวไปแล้วนั้น พบว่ามีตัวแปรที่นิวรอนต้องเรียนรู้คือ ค่าถ่วงน้ำหนัก เนื่องจากเมทริกซ์ของค่าถ่วงน้ำหนักของนิวรอนเป็นตัวแปรที่ไม่ทราบค่า เพราะในเบื้องต้นค่าถ่วงน้ำหนักแต่ละตัวจะถูกกำหนดอย่างสุ่ม ดังนั้นนิวรอนต้องมีกระบวนการเรียนรู้เพื่อจำแนกข้อมูลขาเข้าให้ได้ตามเป้าหมายหรือ Target ที่งาน (Task) ต้องการ โดยที่กระบวนการเรียนรู้ของนิวรอนเป็นไปตามสมการที่ 4 และ 5

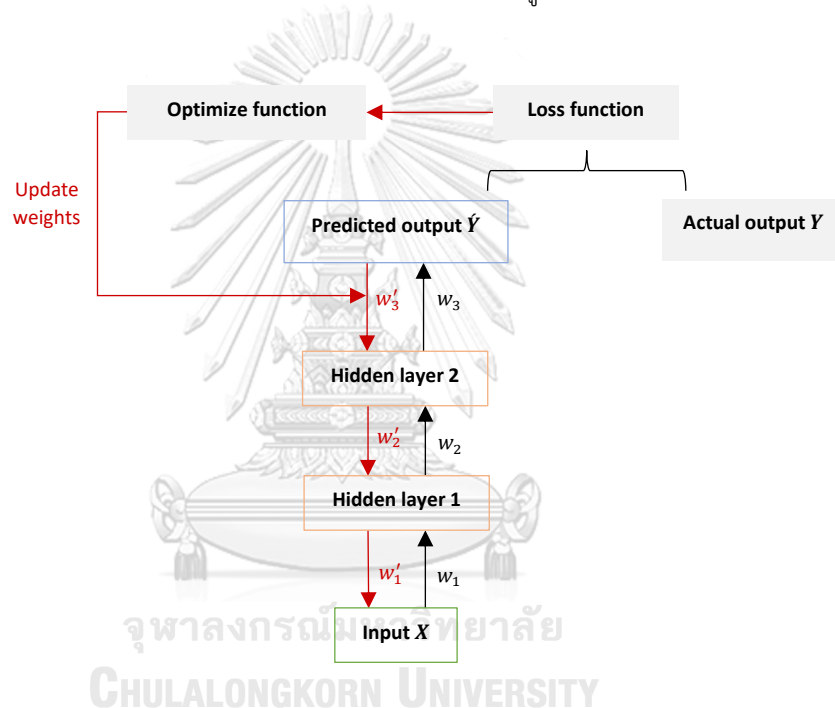
$$W_{node} \leftarrow W_{node} + \Delta W_{node} \quad (4)$$

$$\Delta W_{node} = \eta(O_{node} - T)X_{node} \quad (5)$$

โดยที่  $\eta$  คืออัตราการเรียนรู้ (Learning rate) ซึ่งเป็นไฮเปอร์พารามิเตอร์ (Hyperparameter) ตัวหนึ่งที่เป็นตัวกำหนดว่าค่าถ่วงน้ำหนักในการเรียนรู้หนึ่งรอบจะเปลี่ยนแปลงไปมากน้อยเพียงใดและ  $T$  คือเป้าหมายหรือผลลัพธ์จริงของชุดตัวอย่างนั้น

### 2.3.2 การทำงานของโครงข่ายประสาทเทียม

การทำงานของโครงข่ายประสาทจากการคำนวณไปข้างหน้า (Feed forward) เพียงอย่างเดียว ทำให้การทำนายผลที่ได้ยังไม่ถูกต้องมากนัก เพราะค่าถ่วงน้ำหนักยังไม่ถูกปรับให้อยู่ในค่าที่เหมาะสม ดังนั้นอัลกอริทึมการแพร่กระจายย้อนกลับ (Backpropagation) จึงถือกำเนิดขึ้น โดยทำการคำนวณค่าความผิดพลาด (Loss function) จากการเปรียบเทียบค่าที่ทำนายได้กับค่าตอบที่แท้จริง ซึ่งเป็นตัววัดว่า โมเดลมีประสิทธิภาพในการทำนายมากน้อยเพียงใด ยิ่งค่าความผิดพลาดน้อย โมเดลยิ่งทำนายชุดข้อมูลฝึกได้ดี ค่าความผิดพลาดจะถูกนำไปคำนวณเพื่อหาเกรเดียนต์ (Gradient of loss function) จากตัว Optimization Algorithms และทำการอัปเดต (Update) ค่าถ่วงน้ำหนัก เพื่อลดค่าความผิดพลาดลง ซึ่งหมายความว่าค่าถ่วงน้ำหนักใหม่ที่ได้ในแต่ละ node ถูกปรับให้ถูกต้องมากขึ้น การทำงานของโครงข่ายประสาทเทียมดังแสดงในรูปที่ 11



รูปที่ 11 ความสัมพันธ์ของแต่ละส่วนประกอบในโครงข่ายประสาท (ปรับจากหนังสือ Deep Learning with Python [23])

#### 2.3.2.1 การทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

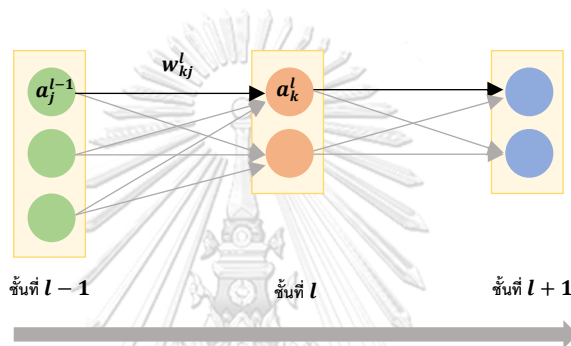
เมื่อมีการป้อนข้อมูลเข้าที่ชั้นรับข้อมูลและต่อไปยังชั้นซ่อนและสุดท้ายไปที่ชั้นขาออก ข้อมูลที่ถูกคำนวณและส่งต่อไปของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า หรือ Feedforward Neural Network จะถูกส่งผ่านไปทิศทางเดียวผ่านไปที่ละชั้น โดยนิวรอนแต่ละตัวที่อยู่ในชั้นเดียวกันจะไม่เชื่อมต่อกันเองแต่จะเชื่อมต่อกับนิวรอนชั้นถัดไป ซึ่งทำให้ข้อมูลขาออกของนิวรอนในชั้นก่อนหน้าเป็นข้อมูลขาเข้าให้กับนิวรอนชั้นถัดไป ข้อมูลขาออกของนิวรอนที่ได้รับข้อมูลจากนิวรอนของชั้นก่อนหน้าสามารถถูกคำนวณได้จากสมการ 6 และ 7



$$z_k^l = \sum_j^n w_{kj}^l a_j^{l-1} + b_k^l \quad (6)$$

$$a_k^l = f(z_k^l) \quad (7)$$

โดยกำหนดให้ชั้นของโครงข่ายประสาทชั้นก่อนหน้าคือ  $l - 1$  ซึ่งมีจำนวนนิวรอนเป็น  $j$  ถึง  $n$  และ  $a_j^{l-1}$  คือข้อมูลขาออกหรือคำตอบของนิวรอนจากชั้นก่อนหน้า ในส่วนของชั้นถัดไปหรือชั้น  $l$  มีค่าถ่วงน้ำหนัก  $w_{kj}^l$  ซึ่งมีเส้นเชื่อมมาจากนิวรอนตัวที่  $j$  ของชั้นก่อนหน้ามาที่นิวรอนตัวที่  $k$  ของชั้น  $l$  และค่าไบแอสคือ  $b_k^l$  สุดท้ายการได้มาซึ่ง  $a_k^l$  ต้องผ่าน  $f$  หรือฟังก์ชันกระตุ้นซึ่งได้อธิบายไว้ใน 2.3.1 รายละเอียดการทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าแสดงดังในรูปที่ 12



รูปที่ 12 การทำงานของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

### 2.3.2.2 ฟังก์ชันกระตุ้น

จากหัวข้อที่ 2.3.1 ที่กล่าวเกี่ยวกับโครงสร้างภายในของนิวรอนซึ่งจะมีฟังก์ชันกระตุ้นหรือ Activation function เพื่อทำให้โครงข่ายประสาทเทียมสามารถแก้ไขปัญหาต่าง ๆ ได้มากขึ้น ฟังก์ชันที่นิยมใช้มีดังนี้

(1) ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นฟังก์ชันที่สามารถหาค่าอนุพันธ์ได้ทุกจุด ซึ่งให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 สามารถคำนวณได้ตามสมการที่ 8

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (8)$$

(2) ฟังก์ชันเรกติไฟต์เชิงเส้น (Rectified Linear Unit function: ReLU) ค่าที่ได้จากฟังก์ชันนี้จะมีลักษณะเป็นไบนารี (Binary) คือได้ค่าเป็นบวกหรือเป็นศูนย์เสมอ ซึ่งฟังก์ชันจะมีลักษณะสมการดังนี้

$$f(z) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases} \quad (9)$$

(3) ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function) มักถูกใช้งานในกรณีที่ต้องการทำการแบ่งแยกประเภทของชุดข้อมูลที่มีหลายคลาส (Multiclass classification) โดยค่าที่ได้จากฟังก์ชันจะอยู่ในช่วง 0

ถึง 1 ซึ่งเป็นฟังก์ชันที่แสดงความน่าจะเป็นของการถูกทายเป็นคลาสต่าง ๆ ของตัวอย่างนั้น ๆ โดยสามารถคำนวณได้จากสมการ

$$f(z)_j = \frac{e^{z_j}}{\sum_{i=1}^K e^{z_i}} \quad (10)$$

### 2.3.2.3 ฟังก์ชันต้นทุน

ฟังก์ชันต้นทุน (Cost function หรือ Loss function) เป็นตัวบ่งบอกถึงต้นทุนของโมเดล ซึ่งเป้าหมายของโมเดลคือ การลดต้นทุนหรือการลดค่าที่ได้จากฟังก์ชันต้นทุนให้ได้มากที่สุด ซึ่งค่าที่ได้คือค่าความผิดพลาด โดยสามารถนำมาใช้เพื่อสังเกตอัตราค่าความผิดพลาดจากชุดตัวอย่างสำหรับการเรียนรู้ของโครงข่ายประสาทเทียมได้ โดยฟังก์ชันต้นทุนที่นิยมใช้ มีดังต่อไปนี้

ค่าความผิดพลาดกำลังสองเฉลี่ย (Mean Square Error: MSE) โดยคำนวณได้จากสมการที่ 11 ซึ่งสามารถหาได้จากการนำเอาค่าจริง (Target:  $t$ ) และค่าที่โมเดลทำนายได้ (Output:  $o$ ) ของแต่ละตัวอย่างฝึกมาหาผลต่าง

$$e = \frac{1}{N} \sum_{i=1}^N (o_i - t_i)^2 \approx \frac{1}{2} \sum_{i=1}^N (o_i - t_i)^2 \quad (11)$$

ค่าความผิดพลาดครอส-เอนโทรปี (Cross-entropy loss) คือการนำเอาความน่าจะเป็นมาช่วยคำนวณ ซึ่งเอนโทรปีคือความไม่แน่นอน ดังนั้นเป็นการคำนวณความน่าจะเป็นของโมเดลที่จะทำนายว่าข้อมูลฝึกนั้นเป็นอะไร โดยเทียบกับความเป็นไปได้ที่โมเดลจะตอบถูก [24]

$$e = -\frac{1}{N} \sum_{i=1}^N t_i \log(o_i) \quad (12)$$

### 2.2.3.4 วิธีการหาค่าที่เหมาะสม

การปรับเปลี่ยนค่าถ่วงน้ำหนักให้ถูกต้องเป็นเรื่องที่สำคัญเป็นอย่างยิ่งสำหรับโครงข่ายประสาทเทียม การปรับค่าน้ำหนักให้อยู่ในค่าที่เหมาะสมจะช่วยลดค่าของฟังก์ชันต้นทุนลง ทำให้โมเดลมีประสิทธิภาพในการทำนายข้อมูลได้ดียิ่งขึ้น วิธีการหาค่าที่เหมาะสม (Optimization algorithm) ที่นิยมถูกใช้งานได้แก่

(1) สโตแคสติก เกรเดียนต์ เดสเซนส์ (Stochastic Gradient Descent: SGD) วิธีนี้จะแบ่งข้อมูลฝึกเป็นชุดย่อย ๆ ซึ่งจะช่วยลดความซับซ้อนในการคำนวณ และมีการเปลี่ยนแปลงค่าถ่วงน้ำหนักบ่อยยิ่งขึ้น ช่วยให้เกิดปัญหาในกรณีที่มีค่าต่ำสุดสัมพัทธ์มาก แต่ปัญหาที่ได้คือเมื่อยิ่งลงต่ำสุดค่าต่ำสุดมากเท่าไร ค่าที่ได้ยิ่งแปรปรวนและซับซ้อนมากยิ่งขึ้น [24, 25]

---

 Stochastic Gradient Descent: SGD
 

---

กำหนดค่าเริ่มต้น อัตราการเรียนรู้เริ่มต้น ( $\eta$ ) และค่าถ่วงน้ำหนักเริ่มต้น ( $W$ )

while ค่าความผิดพลาดมากกว่าค่าที่ต้องการ

    แบ่งข้อมูลฝึกและข้อมูลเป้าหมายออกมาเป็นชุดย่อย (minibatch) เป็น  $m$  ชุด โดยที่  $\{x^1, x^2 \dots, x^m\}$  และ  $\{y^1, y^2 \dots, y^m\}$

    คำนวณเกรเดียนท์  $\frac{\partial e}{\partial w}$

    ทำการเปลี่ยนแปลงค่าถ่วงน้ำหนัก  $w_i = w_i + \eta \frac{\partial e}{\partial w_i}$

end while

คืนค่า  $W$

---

(2) โมเมนตัม (Momentum) ปัญหาของการทำเกรเดียนท์ เดสเซนส์คืออาจเกิดการลู่อับที่ค่าต่ำสุดอื่นที่ไม่ใช่ค่าต่ำสุดสัมบูรณ์ ซึ่งทำให้เกิดปัญหาที่เรียกว่า Local trap ดังแสดงในรูปที่ 13 (ขวา) โดยวิธีโมเมนตัมจะให้ความสำคัญกับทิศทางการเข้าสู่จุดต่ำที่เล็กกว่าให้ได้มากที่สุด ดังแสดงในรูปที่ 13 (ซ้าย) โดยมีกรเพิ่มพจน์เพื่อพิจารณาถึงการเปลี่ยนแปลงค่าในครั้งก่อนหน้า ดังในสมการที่ 14 และ 15 [25]

$$g(n) = \frac{\partial e(n)}{\partial w} \quad (13)$$

$$w(n+1) = w(n) + \Delta w(n) \quad (14)$$

$$\Delta w(n) = \eta g(n) + \alpha \Delta w(n-1) \quad (15)$$

กำหนดให้  $g(n)$  คือค่าเกรเดียนท์ ณ เวลา  $n$ ,  $\Delta w_i(n-1)$  คือการเปลี่ยนแปลงการเปลี่ยนแปลงค่าถ่วงน้ำหนักของครั้งก่อนหน้าและ  $\alpha$  คือค่าคงที่ที่เรียกว่าโมเมนตัม ซึ่ง  $\alpha \in [0,1]$



รูปที่ 13 การทำเกรเดียนท์ เดสเซนส์ปราศจากการทำโมเมนตัม (ซ้าย) และการการทำเกรเดียนท์ เดสเซนส์ที่มีการทำโมเมนตัม (ขวา) [24]

(3) อาร์เอ็มเอสพรอป (Root Mean Square Propagation: RMSprop) มีลักษณะคล้ายคลึงกับ โมเมนต์ตามโดยนำเอาค่าการเปลี่ยนแปลงจากครั้งก่อนหน้ามาใช้เพื่อปรับปรุงอัตราการเรียนรู้ นอกจากการใช้ค่าเกรเดียนท์แล้วยังมีการทำค่าเฉลี่ยกำลังสองของเกรเดียนท์ด้วยแสดงในสมการที่ 17 และ 18

$$g(n) = \frac{\partial e(n)}{\partial w} \quad (16)$$

$$v(n) = \rho v(n-1) + (1-\rho)g^2(n) \quad (17)$$

$$w(n+1) = w(n) - \frac{\eta}{\sqrt{v(n)+\epsilon}} g(n) \quad (18)$$

โดยที่  $g(n)$  คือค่าเกรเดียนท์ ณ เวลา  $n$

$v(n)$  คือค่าเฉลี่ยเอกโพเนนเชียลของรากที่สองของเกรเดียนท์

$\rho$  คืออัตราการใช้เกรเดียนท์ในอดีตในการเรียนรู้ซึ่งโดยทั่วไปจะมีค่าเท่ากับ **0.9** ซึ่งเป็นค่าที่เหมาะสมสำหรับอัตราการเรียนรู้เท่ากับ **0.001**

$\epsilon$  คือค่าคงที่น้อย ๆ เพื่อไม่ให้ส่วนของเศษส่วนเป็นศูนย์

(4) Adaptive Moment Estimation หรือ Adam เป็นวิธีที่สามารถปรับอัตราการเรียนรู้ได้ ทำให้อัตราการเรียนรู้ไม่ถูกลดลงมากเกินไป และช่วยลดความแปรปรวนของค่าพารามิเตอร์ ซึ่งเป็นการรวมเอา โมเมนต์ตามและอาร์เอ็มเอสพรอปมาใช้ร่วมกัน [24, 26] แสดงใน

$$g(n) = \frac{\partial e(n)}{\partial w} \quad (19)$$

$$v(n) = \rho_1 v(n-1) + (1-\rho_1)g(n) \quad (20)$$

$$s(n) = \rho_2 s(n-1) + (1-\rho_2)g^2(n) \quad (21)$$

$$w(n+1) = w(n) - \eta \frac{v(n)}{\sqrt{s(n)+\epsilon}} g(n) \quad (22)$$

โดยที่  $g(n)$  คือค่าเกรเดียนท์ ณ เวลา  $n$

$v(n)$  คือค่าเฉลี่ยเอกโพเนนเชียลของเกรเดียนท์

$s(n)$  คือค่าเฉลี่ยเอกโพเนนเชียลของรากที่สองของเกรเดียนท์

$\rho_1$  และ  $\rho_2$  คือค่าโมเมนต์อันดับที่ 1 และอันดับที่ 2 ของเกรเดียนท์ตามลำดับเป็นค่าที่อยู่ในช่วง  $[0,1)$  โดยปกติจะใช้ค่าทั้งสองที่ 0.9 และ 0.999 ตามลำดับ

$\epsilon$  คือค่าคงที่น้อย ๆ เพื่อไม่ให้ส่วนของเศษส่วนเป็นศูนย์ ค่าที่แนะนำคือ  $10^{-8}$

### 2.3.2.5 การแพร่กระจายย้อนกลับ

การแพร่กระจายย้อนกลับ (Backpropagation) เป็นวิธีที่ช่วยให้โมเดลสามารถหาค่าความผิดพลาดของนิเวรอนระหว่างชั้นได้ เนื่องจากการทำการป้อนไปข้างหน้าของโครงข่ายทำได้เพียงคำนวณค่าความผิดพลาดจากการทำนายในชั้นสุดท้ายเท่านั้น ไม่สามารถคำนวณค่าความผิดพลาดระหว่างชั้นได้โดยตรง และการเปลี่ยนแปลงค่าถ่วงน้ำหนักจากการใช้เกรเดียนต์เดสเซนท์จะใช้การคำนวณค่าความผิดพลาดเป็นหลัก ดังนั้นจึงจำเป็นต้องมีวิธีการที่นำเอาค่าความผิดพลาดมาสู่ชั้นก่อนหน้า เพื่อสังเกตค่าความผิดพลาดระหว่างชั้น

การหาค่าความผิดพลาดของนิเวรอน  $\delta_k^l$  ตัวที่  $k$  ในชั้นที่  $l$  สามารถคำนวณได้จากสมการที่ 23 จากนั้นการหา  $\frac{\partial e}{\partial a_k^l}$  ในลำดับชั้นก่อนหน้าสามารถหาได้จากการแพร่กระจายย้อนกลับ ดังในสมการที่ 24 กำหนดให้  $m$  คือจำนวนของนิเวรอนในชั้นที่  $l + 1$  สุดท้ายเมื่อคำนวณค่าความผิดพลาดระหว่างชั้นได้ ค่าความผิดพลาดเทียบกับน้ำหนักก็จะสามารถคำนวณได้จากสมการที่ 25

$$\delta_k^l = \frac{\partial e}{\partial z_k^l} = \frac{\partial e}{\partial a_k^l} f'(z_k^l) \quad (23)$$

$$\frac{\partial e}{\partial a_k^l} = \sum_{m=1}^n \frac{\partial e}{\partial z_m^{l+1}} \frac{\partial z_m^{l+1}}{\partial a_k^l} = \sum_{m=1}^n \delta_m^{l+1} w_{mk}^{l+1} \quad (24)$$


$$\frac{\partial e}{\partial w_{kj}^l} = \frac{\partial e}{\partial z_k^l} \frac{\partial z_k^l}{\partial w_{kj}^l} = \delta_k^l a_j^{l-1} \quad (25)$$

## 2.4 โครงข่ายคอนโวลูชัน

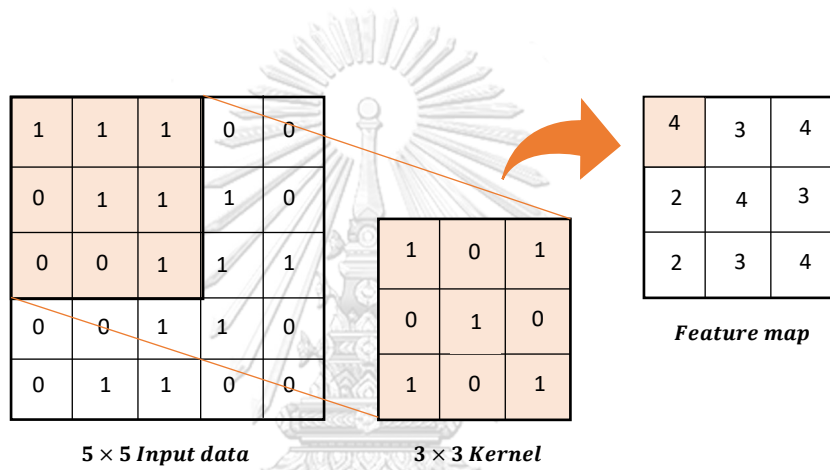
โครงข่ายคอนโวลูชัน (Convolution Neural Network: CNN) เป็นการนำเอาหน้ากาก (Mask) มาเลื่อนไปมาทั่วข้อมูล เพื่อเรียนรู้ลักษณะของข้อมูลคล้ายกับการกับการทำงานการรับรู้การมองเห็นของมนุษย์ โดยเซลล์ประสาทจะมีการตอบสนองเพียงพื้นที่เล็ก ๆ ในลานการมองเห็น (Visual field) และนำพื้นที่เล็ก ๆ มาประกอบรวมกันเพื่อให้ครอบคลุมลานการมองเห็นภาพ ทำให้รู้ว่าภาพที่มองเห็นนั้นเป็นภาพอะไร โดยรูปที่ 14 แสดงโครงสร้างทั่วไปของโครงข่ายคอนโวลูชัน

### 2.4.1 ชั้นคอนโวลูชัน

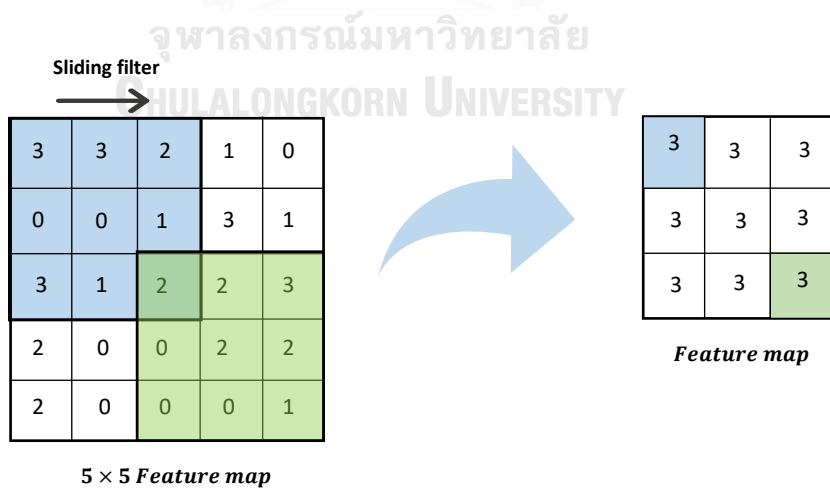
ชั้นคอนโวลูชัน (Convolutional layer) เป็นชั้นที่ทำการดึงคุณลักษณะสำคัญที่ใช้ในการรู้ของข้อมูล โดยใช้หน้ากากที่เรียกว่า ตัวกรอง (Filter) หรือเคอร์เนล (Kernel) ในขนาดที่ต่างกัน ตัวกรองนี้จะเข้าไปสู่พื้นที่ย่อย ๆ ของข้อมูล เรียกว่า ลานรับรู้ (Receptive field) ซึ่งภายในตัวกรองจะมีค่าถ่วงน้ำหนักอยู่และจะถูกใช้ในทุก ๆ การทำคอนโวลูชันกับข้อมูลขาเข้า แสดงในรูปที่ 15 จุดประสงค์หลักของการสร้างชั้นคอนโวลูชันคือ การดึงคุณลักษณะระดับสูง (High-level features) ชั้นคอนโวลูชันสามารถมีได้หลายชั้น ยิ่งเพิ่มจำนวนชั้นยิ่งทำให้คุณลักษณะระดับสูงถูกดึงออกมาได้มากขึ้น นอกจากนี้ขนาดของตัวกรองในชั้นคอนโวลูชันที่ลึกต้องมียิ่งขึ้นตาม เพื่อให้สามารถจับคุณลักษณะที่ละเอียดได้ดียิ่งขึ้น



รูปที่ 14 โครงสร้างทั่วไปของโครงข่ายคอนโวลูชัน [27]



รูปที่ 15 ตัวอย่างการทำคอนโวลูชัน



รูปที่ 16 ตัวอย่างการทำการรวมโดยใช้ค่ามากที่สุด

### 2.4.2 ชั้นการรวม

การจำแนกข้อมูลจำเป็นต้องอาศัยข้อมูลย่อย ๆ จำนวนมาก ดังนั้นจำเป็นต้องคำนวณข้อมูลในหลาย ๆ ความละเอียด ซึ่งการจะเข้าถึงความละเอียดเหล่านั้นได้จำเป็นต้องมีการย่อข้อมูลให้มีขนาดเล็กลง ชั้นการรวม (Pooling layer หรือ Subsampling layer) จึงเป็นชั้นที่ทำหน้าที่ในการลดขนาดของข้อมูลลง ให้เหลือแต่ข้อมูลที่ สำคัญ โดยสามารถทำได้โดยการเลื่อนตัวกรองไปทั่วข้อมูล จากนั้นก็ทำการเลือกตัวแทนของข้อมูลไปไว้ในเมทริกซ์ ใหม่ เช่น การรวมโดยใช้ค่ามากที่สุด (Max pooling) คือ การเลือกค่าที่มากที่สุดในตัวกรองนั้น ๆ มาเป็นตัวแทนของ ข้อมูล ดังแสดงในรูปที่ 16 เนื่องจากชั้นการรวมช่วยลดขนาดของข้อมูลลง จึงทำให้ใช้ทรัพยากรในการคำนวณ น้อยลงด้วย

### 2.4.3 ชั้นการเชื่อมโยงเต็มรูปแบบ

หลังจากที่สามารถสกัดคุณลักษณะระดับสูงได้แล้วนั้น ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully connected layer) คือขั้นสุดท้ายของโครงข่ายคอนโวลูชันนี้ ชั้นนี้จะทำการคูณผลลัพธ์ของชั้นก่อนหน้า จากนั้นทำการพิจารณาว่า คุณลักษณะระดับสูงใดที่สัมพันธ์กับคลาส (Class) นั้น ๆ มากที่สุด

## 2.5 โครงข่ายคอนโวลูชันตามเวลา

แม้ว่าหลายงานวิจัยได้นำเอาโครงข่ายคอนโวลูชันมาประยุกต์ใช้กับสัญญาณในอนุกรมเวลามากกว่า 10 ปีแล้วก็ตาม แต่ปัจจุบันโครงข่ายประสาทเทียมที่ใช้ทำนายข้อมูลในอนุกรมเวลาที่นิยมคือ โครงข่ายแบบวนซ้ำ (Recurrent Neural Network: RNN) ซึ่งโครงข่ายที่ใช้ได้ดีและเป็นที่ยอมรับคือ Long-Short Term Memory (LSTM) แต่งานวิจัย ของ Bai et al. [28] ได้มีการนำโครงข่ายคอนโวลูชันตามเวลา (Generic Temporal Convolutional Network: TCN) ซึ่งเป็นโครงข่ายคอนโวลูชันสำหรับการทำนายข้อมูลลำดับเวลาเปรียบเทียบกับโครงข่ายแบบวนซ้ำใน ฐานข้อมูลต่าง ๆ ที่มีถูกใช้เพื่อทดสอบการทำงานของโครงข่ายแบบวนซ้ำแบบต่าง ๆ ผลลัพธ์ที่ได้จากการ เปรียบเทียบของงานวิจัยชี้ให้เห็นว่าโมเดลของโครงข่ายคอนโวลูชันตามเวลานั้นให้ผลการทดสอบที่ดีกว่าโครงข่าย แบบวนซ้ำอย่าง LSTM และมีหน่วยความจำที่ยาวกว่าโครงข่ายแบบวนซ้ำเมื่อเทียบกับความยาวของข้อมูลใน อนุกรมเวลาที่เท่ากัน [28] โดยโครงสร้างของคอนโวลูชันตามเวลามีส่วนประกอบที่สำคัญดังนี้

### 2.5.1 คอนโวลูชันคอซอล

สำหรับการสร้างโมเดลในการทำนายข้อมูลในอนุกรมเวลา งานที่ต้องการจากโมเดลคือ การทำนายค่าขา ออก ณ เวลา  $t$  จากข้อมูลขาเข้า ณ ช่วงเวลา  $1$  ถึง  $t - 1$  โดยที่ข้อมูลขาออก ณ เวลา  $t$  จะไม่ขึ้นอยู่กับข้อมูล ขาเข้า ณ ช่วงเวลาอนาคตซึ่งคือ  $t$  ถึง  $T$  ซึ่งหมายความว่าต้องไม่มีการรั่วไหลของข้อมูลอนาคตไปสู่ข้อมูลในอดีต ซึ่งคอนโวลูชันคอซอล (Causal convolution) สามารถให้ใช้คำนวณเพื่อหาความน่าจะเป็นของข้อมูลขาออก ณ เวลา  $t$  จากการทำคอนโวลูชันของข้อมูลขาเข้า ณ ช่วงเวลา  $1$  ถึง  $t - 1$  [29] ดังแสดงในสมการที่ 26

$$p(o) = \prod_{t=1}^T p(o_t | x_1, \dots, x_{t-1}) \quad (26)$$


โดยที่  $o_t$  คือข้อมูลขาออกที่โมเดลทำนายได้ ณ เวลา  $t$

$x_t$  คือ ข้อมูลขาเข้า ณ เวลา  $t$

$p$  คือ ความน่าจะเป็นของการทำนาย

### 2.5.2 คอนโวลูชันไดเลต

ปัญหาของการเรียนรู้ข้อมูลในอนุกรมเวลา คือ การเรียนรู้ชุดข้อมูลที่มีขนาดที่ยาวมาก ๆ ซึ่งการใช้คอนโวลูชันคอขวดเพียงอย่างเดียวนั้นทำให้ความลึกของโครงข่ายหรือขนาดของตัวกรองจะมีขนาดใหญ่ขึ้นมาก โดยในทางปฏิบัติแล้วจะเป็นการสิ้นเปลืองทรัพยากรที่ใช้ในการคำนวณมากจนเกินไป ดังนั้นจึงมีการนำคอนโวลูชันไดเลต (Dilated convolution หรือ convolution with holes) มาใช้เพื่อเพิ่มลานการรับรู้ของโมเดล การทำคอนโวลูชันด้วยวิธีนี้จะทำการข้ามข้อมูลขาเข้าบางตัวในชั้นเดียวกันไป ซึ่งจะถูกกำหนดด้วยค่าของตัวประกอบไดเลตชัน (Dilation factor) โดยค่าตัวประกอบไดเลตชันจะทำให้ขนาดของลานการรับรู้ที่ใหญ่อขึ้นแบบเอกโพเนนเชียล และใช้พารามิเตอร์ในการทำคอนโวลูชันน้อยกว่า ตัวอย่างเช่น ตัวประกอบไดเลตชันเท่ากับ 2 ชั้นคอนโวลูชันจะทำการมองข้อมูลล่วงหน้าไป 2 ชั้นของเวลา [30] ดังแสดงในรูปที่ 17 ในชั้นที่นิเวรอนแสดงเป็นสีส้ม จะเห็นได้ว่าการทำคอนโวลูชันไดเลตเป็นการอนุญาตให้โครงข่ายทำงานกับข้อมูลอย่างหยาบได้ คล้ายกับการย่อข้อมูลในชั้นการรวม แต่ข้อมูลขาออกที่ได้จะมีขนาดเท่ากับข้อมูลขาเข้า จากรูปที่ 17 แต่ละชั้นจะมีการเพิ่มค่าของตัวประกอบไดเลตชันขึ้นเรื่อย ๆ ซึ่งทำให้โครงข่ายมีขนาดของลานการรับรู้ที่กว้างขึ้นตั้งแต่ชั้นล่าง ๆ ของโครงข่าย ในขณะที่เดียวกันก็เก็บรักษาข้อมูลขาเข้าไว้อย่างครบถ้วนและยังไม่สิ้นเปลืองทรัพยากรในการคำนวณอีกด้วย



รูปที่ 17 ชั้นของคอนโวลูชันไดเลตและตัวประกอบไดเลตชัน [30]

### 2.5.3 การเชื่อมต่อส่วนที่เหลือ


ภายในโครงข่ายคอนโวลูชันตามเวลานี้จะประกอบด้วยบล็อกที่เรียกว่า บล็อกส่วนที่เหลือ หรือ Residual block ในแต่ละบล็อกจะมีการเชื่อมต่อส่วนที่เหลือ (Residual connection) ที่จะทำให้การข้ามชั้นในบล็อก



นั้นไปหรือเป็นการสร้างทางลัด (Shortcut) ให้กับโครงข่ายซึ่งคล้ายกับโครงข่ายชื่อดังอย่าง ResNet [31] เพราะการเพิ่มลานการรับรู้ในโครงข่ายคอนโวลูชันตามเวลาจะขึ้นอยู่กับความลึกของโครงข่าย ขนาดของตัวกรอง และตัวประกอบโคเลชัน ซึ่งผลของการทำคอนโวลูชันกับข้อมูลขาเข้าในชั้นก่อนหน้าอาจไม่ถูกส่งผ่านมายังชั้นสุดท้ายได้ หมายความว่าเกรเดียนต์ที่มีค่าน้อยลงเรื่อย ๆ (Vanishing gradient) ดังนั้นการส่งผ่านค่าที่ได้จากการทำคอนโวลูชันผ่านทางลัดทำให้โครงข่ายมีความเสถียรมากขึ้น และป้องกันการเกิดการลดลงของค่าเกรเดียนต์

## 2.6 การเรียนรู้ถ่ายโอน

การเรียนรู้ถ่ายโอน (Transfer learning) มีแนวคิดมาจากการเรียนรู้ของมนุษย์ มนุษย์มีความสามารถในการใช้ความรู้หรือประสบการณ์ที่เคยสั่งสมมาเพื่อเรียนรู้สิ่งใหม่ ๆ รอบตัวได้ และเมื่อเจอสิ่งใหม่ที่มีความใกล้เคียงกับความรู้ที่มีมากเท่าไร ก็ไม่ใช่เรื่องยากที่จะสามารถเชี่ยวชาญด้านนั้น ๆ ได้ในเวลาอันรวดเร็ว การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกจึงได้นำวิธีการเรียนรู้ถ่ายโอนมาใช้เป็นหนึ่งในอัลกอริทึม โดยเป้าหมายของการเรียนรู้ถ่ายโอนคือ การพยายามถ่ายทอดความรู้ที่ได้ฝึกจากข้อมูลชุดหนึ่งไปปรับปรุงการเรียนรู้งานอีกงานหนึ่งที่มีความใกล้เคียงกันให้ดียิ่งขึ้น หมายความว่าแทนที่จะนำเอาโครงข่ายการเรียนรู้เชิงลึก (Deep learning network) ไปฝึกกับข้อมูลที่มีขนาดใหญ่มา ๆ (Scratch) ตั้งแต่ขั้นเริ่มต้น ก็นำเอาโครงข่ายที่ได้ฝึกจากงานอื่นที่มีความใกล้เคียงกันไปแล้วมาใช้ฝึกข้อมูลชุดใหม่แทน การเรียนรู้ถ่ายโอนอาจจะสามารถช่วยให้การเรียนรู้ของโครงข่ายดีขึ้น Torrey และ Shavlik [32] ได้สรุปข้อดีที่อาจเกิดขึ้นเมื่อใช้การเรียนรู้ถ่ายโอนไว้ดังนี้ คือ ทักษะการเรียนรู้เริ่มต้นสูงกว่า อัตราการเรียนรู้ขณะฝึกสูงกว่า และประสิทธิภาพของโมเดลดีกว่าเมื่อเทียบกับการไม่ใช้การเรียนรู้การถ่ายโอน ดังแสดงในรูปที่ 18



รูปที่ 18 ประโยชน์สามประการที่อาจเกิดขึ้นเมื่อใช้การเรียนรู้ถ่ายโอน [32]

ความสำเร็จของการใช้การเรียนรู้เชิงลึกนั้นขึ้นอยู่กับจำนวนของฐานข้อมูลที่ใช้ในการฝึกโมเดล ยังมีข้อมูลจำนวนมากและเป็นข้อมูลที่มีคุณภาพมากยิ่งมีผลทำให้ได้โมเดลที่ดี แต่การสร้างโมเดลจากสัญญาณคลื่นไฟฟ้าหัวใจนั้นมีปัญหาเกี่ยวกับจำนวนข้อมูลที่มีการประกอบคำอธิบาย (Annotation) นั้นมีอยู่อย่างจำกัด และนอกจากนี้ข้อมูลภาวะที่หัวใจเต้นผิดจังหวะก็ยังมีอยู่ไม่มากนัก [33] การนำเอาการเรียนรู้ถ่ายโอนมาประยุกต์ใช้ทำให้ไม่จำเป็นต้องใช้ข้อมูลจำนวนมาก ๆ และสามารถเลือกใช้โครงข่ายที่ได้มาจากประเภทงานที่ใกล้เคียงกัน เพื่อนำเอามา

เป็นตัวสกัดคุณลักษณะได้ (Feature extractor) Tajbakhsh, et al. [34] ได้นำเอาการเรียนรู้ถ่ายโอนพร้อมกับการปรับจูนโมเดล (Transfer learning with fine tuning) มาใช้ในการแยกแยะโรคจากภาพถ่ายทางการแพทย์ โดยนำโครงข่ายชื่อยืดที่ฝึกมาจากฐานข้อมูล ImageNet อย่าง AlexNet มาใช้ ซึ่งปรากฏว่าเมื่อใช้การเรียนรู้ถ่ายโอนพร้อมกับการปรับจูนช่วยให้ประสิทธิภาพของโมเดลดีขึ้นกว่าตอนที่ฝึกโมเดลจากข้อมูลชุดใหญ่ซึ่งไม่ได้ใช้การเรียนรู้ถ่ายโอน นอกจากนี้ยังมีงานการเรียนรู้ถ่ายโอนมาใช้กับสัญญาณคลื่นไฟฟ้าหัวใจ Isin และ Ozdalili [35] ได้นำเอาโครงข่าย AlexNet มาใช้กับแยกภาวะหัวใจเต้นผิดจังหวะ โดยใช้ภาพคลื่นไฟฟ้าหัวใจประเภทต่าง ๆ เป็นข้อมูลในการฝึก ผลที่ได้คือโครงข่ายที่ถูกฝึกมาจากภาพทั่วไป ก็สามารถนำมาประยุกต์ใช้กับภาพที่มีความจำเพาะเจาะจงอย่างภาพสัญญาณคลื่นไฟฟ้าหัวใจได้

## 2.7 การตรวจจับภาวะหัวใจเต้นผิดจังหวะด้วยการเรียนรู้เชิงลึก

การแยกแยะภาวะการเต้นของหัวใจทำได้ทั้งพิจารณาจังหวะการเต้นของหัวใจ (Rhythm-based method) และสัณฐานวิทยาของสัญญาณคลื่นไฟฟ้าหัวใจ (Morphology-based method)

วิธีแรกเป็นวิธีที่นิยมและใช้กันอย่างแพร่หลาย งานวิจัยของ Dash, et al. [7] ได้พัฒนาการตรวจจับภาวะหัวใจห้องบนสั้นพลั่วแบบอัตโนมัติ โดยใช้วิธีทางสถิติอย่าง Turning Points Ratio ร่วมกับการหาค่า Root Mean Square ของความแตกต่างของ RR-interval ที่ต่อเนื่องกันและใช้ Shannon Entropy เพื่อหาลักษณะสำคัญของภาวะผิดปกตินี้ ได้ค่าความไวและค่าความจำเพาะร้อยละ 94.4 และ 95.1 ตามลำดับ นอกจากนี้ยังได้มีการนำภาวะผิดปกติอื่นเข้ามาปะปนด้วย ได้ผลความไวและค่าความจำเพาะร้อยละ 90.2 และ 91.2 ตามลำดับ จะเห็นได้ว่าผลที่ได้ไม่สูงมากนักแม้ว่าจะไม่มีภาวะอื่นมาปะปนอยู่และเมื่อมีภาวะอื่น ๆ มาปะปนค่าความไวกับค่าความจำเพาะยิ่งถูกลดทอนลงไป อีกงานวิจัยที่ได้ใช้วิธีทาง Rhythm-based method เพื่อคัดแยกภาวะหัวใจห้องบนสั้นพลั่วออกจากภาวะหัวใจเต้นปกติ และนำเอาภาวะหัวใจเต้นปกติร่วมกับภาวะห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะมาใช้เพื่อทำการคัดแยกด้วยคืองานวิจัยของ Carrara et. al [21] แม้จะนำวิธีการคำนวณแบบไม่เชิงเส้นหลาย ๆ วิธีมาประยุกต์ใช้แต่สัญญาณหัวใจห้องบนสั้นพลั่วก็ยังคงถูกรบกวนด้วยภาวะอื่น ๆ เพราะภาวะการเต้นที่ผิดจังหวะทั้ง 3 ชนิดนั้นมีลักษณะของอัตราการเต้นของหัวใจที่ไม่สม่ำเสมอเหมือนกัน

จากปัญหาของ Rhythm-based method ก็ได้มีงานวิจัยอื่น ๆ พยายามใช้วิธีทาง Morphology-based method โดยการวิเคราะห์ P-wave เพื่อตรวจจับภาวะหัวใจห้องบนสั้นพลั่ว [19, 36-38] แต่ค่าความไวและค่าความจำเพาะที่ได้นั้นไม่มากอยู่ระหว่าง 73-91% และ 71-83.5% ตามลำดับ อันเนื่องมาจากการระบุตำแหน่งที่ถูกต้องแม่นยำของ P-wave นั้นทำได้ยาก อีกทั้ง P-wave เป็นคลื่นขนาดเล็กซึ่งถูกรบกวนด้วยสัญญาณรบกวนอื่น ๆ ได้ง่าย [7]

หลายสิบปีที่ผ่านมา การเรียนรู้เชิงลึก (Deep learning) ได้ถูกพัฒนาขึ้นมาอย่างมาก และถูกประยุกต์ใช้งานในหลากหลายด้าน รวมไปถึงทางด้านทางการแพทย์ด้วย ความสามารถในการรู้จำรูปแบบ (Pattern recognition) ของการเรียนรู้เชิงลึก ยิ่งส่งเสริมให้นักวิจัยนำเทคนิคของการเรียนรู้เชิงลึกมาใช้งานทางการแพทย์มากขึ้น ไม่ว่าจะเป็นสัญญาณหรือภาพทางการแพทย์ ปัจจุบันการเรียนรู้เชิงลึกได้ถูกนำมาประยุกต์ใช้กับสัญญาณทางการแพทย์

โดยเฉพาะอย่างยิ่งสำหรับการสร้างแบบจำลองคัดแยกประเภทของสัญญาณคลื่นไฟฟ้าหัวใจ (Deep learning based ECG classification models) สำหรับการแยกแยะประเภทของสัญญาณคลื่นไฟฟ้าหัวใจ สิ่งที่สำคัญเป็นอย่างมากคือ การได้มาซึ่งลักษณะเฉพาะ (Features) ที่เป็นตัวแทนข้อมูลของสัญญาณนั้น ๆ การเรียนรู้เชิงลึกสามารถเรียนรู้ลักษณะเฉพาะที่ซับซ้อนได้จากข้อมูลนั้นโดยตรง Pourbabaee, et al. [12] นำเอาโครงข่ายคอนโวลูชัน (Convolution Neural Network: CNN) มาใช้เพื่อสกัดข้อมูลสำคัญจากสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา เพื่อแยกแยะภาวะหัวใจเต้นผิดปกติและภาวะหัวใจห้องบนสั่นพลิ้วชนิดเกิดขึ้นชั่วคราว (Paroxysmal Atrial Fibrillation: PAF) ได้ค่าความถูกต้อง 91% และไม่มีการนำภาวะอื่น ๆ มาปนเพื่อทดสอบประสิทธิภาพการแยกแยะภาวะหัวใจห้องบนสั่นพลิ้ว Fan, et al. [6] ทำการออกแบบโครงข่ายคอนโวลูชันที่มีตัวกรองหลายขนาดเริ่มจากตัวกรองขนาดเล็กจนไปถึงตัวกรองที่ใหญ่ขึ้น เพื่อที่จะทำการจับลักษณะสำคัญของสัญญาณคลื่นไฟฟ้าหัวใจจากการบันทึก 1 ช่องสัญญาณในระยะเวลาของสัญญาณที่ต่างกัน งานวิจัยนี้ได้้นำเอาโมเดลไปแยกแยะภาวะหัวใจห้องบนสั่นพลิ้วโดยมีภาวะหัวใจอื่น ๆ (ไม่ได้ระบุว่าภาวะใดบ้าง) มารบกวนด้วยค่าความไวและค่าความจำเพาะที่ได้คือร้อยละ 80.26 และ 98.84 ตามลำดับ แม้ว่าค่าความจำเพาะจะสูงมากแต่ค่าความไวกลับน้อยแสดงว่ายังมีภาวะหัวใจห้องบนสั่นพลิ้วถูกหายไปเป็นภาวะอื่นอยู่จำนวนมาก นอกจากนี้โครงข่ายคอนโวลูชันได้ถูกนำมาใช้ในการสกัดและทำนายภาวะหัวใจเต้นผิดปกติหระอย่างแล้วยังมีงานวิจัยอื่นนำเอาโครงข่ายคอนโวลูชันไปใช้ร่วมกับ Long Short-Term Memory (LSTM) ซึ่งเป็นโครงข่ายที่มักใช้กับสัญญาณที่มีความต่อเนื่องทางเวลา Murugesan, et al. [13] ได้ทำการทดลองเอาโครงข่ายคอนโวลูชันและ LSTM มาใช้ร่วมกันเพื่อจำแนกคลื่นไฟฟ้าหัวใจภาวะปกติ ภาวะหัวใจห้องบนบีบตัวก่อน และภาวะหัวใจห้องล่างบีบตัวก่อน ได้ทำการสรุปไว้ว่าการใช้ทั้งสองโครงข่ายร่วมกันช่วยเพิ่มประสิทธิภาพการจำแนกภาวะหัวใจเต้นผิดปกติได้ดียิ่งขึ้น

แม้ว่าการเรียนรู้เชิงลึกจะมีความสามารถในการสกัดลักษณะที่สำคัญของข้อมูลได้ดี แต่ความรู้เกี่ยวกับธรรมชาติของสัญญาณ สรีรวิทยาของหัวใจ และความรู้ทางวิศวกรรมนั้นก็ช่วยให้สามารถเตรียมข้อมูลที่เหมาะสมก่อนที่จะนำข้อมูลเข้าสู่การเรียนรู้เชิงลึกได้ Yildirim [39] นำเอาวิธีการวิเคราะห์ทางความถี่มาใช้ คือ Wavelet transform มาเป็นชั้น (Layer) หนึ่งของการเรียนรู้เชิงลึกสำหรับสกัดคุณลักษณะของสัญญาณคลื่นไฟฟ้าหัวใจ โดยชั้น Wavelet transform จะทำการสกัดข้อมูลสัญญาณออกมาให้รูปแบบของ Wavelet sequence และนำคุณลักษณะที่ได้นี้เข้าสู่โครงข่าย LSTM เพื่อทำการเรียนรู้และทำนายผลต่อไป งานนี้แสดงให้เห็นว่าการนำวิธีการวิเคราะห์ทางความถี่มาสกัดสิ่งสำคัญของข้อมูลช่วยให้ผลการทำนายดีขึ้น Andersen, et al. [40] ทำการสกัดสัญญาณคลื่นไฟฟ้าหัวใจช่วงจาก R-peak ถึง R-peak เรียกว่า RR interval ก่อนนำข้อมูลเข้าสู่โครงข่ายคอนโวลูชันเพื่อสกัดลักษณะเฉพาะและใช้ LSTM เพื่อเรียนรู้ข้อมูลที่สกัดได้และทำการจำแนกประเภทของภาวะการเต้นของหัวใจห้องบนสั่นพลิ้วและภาวะหัวใจปกติ เพราะคลื่น P-wave ที่อยู่ระหว่าง RR interval นั้นจะไม่ปรากฏเมื่อเกิดภาวะหัวใจห้องบนสั่นพลิ้ว ค่าความไวและค่าความจำเพาะได้คือร้อยละ 98.86 และ 86.04 ตามลำดับ ผลที่ได้เป็นการเอาโมเดลไปใช้ทดสอบกับฐานข้อมูลที่มีภาวะหัวใจเต้นผิดปกติแบบอื่นปนอยู่ด้วย แม้ว่าค่าความจำเพาะจะยังคงน้อยอยู่แต่ความไวอยู่ในเกณฑ์ที่ค่อนข้างสูง

ภาวะหัวใจห้องบนเต้นสั่นพลิ้ว ภาวะหัวใจห้องบนเต้นก่อน และภาวะหัวใจห้องล่างเต้นก่อนเป็นภาวะที่ค่าความแปรปรวนของอัตราการเต้นของหัวใจอาจมีค่าที่ใกล้เคียงกันได้ แต่ก็ยังมีงานวิจัยไม่มากนักที่นำทั้งสามภาวะนี้มาใช้ในการสร้างโมเดลเพื่อแยกแต่ละภาวะออกจากกัน A. Jovic และ F. Jovic [9] ได้สร้างโมเดลเพื่อแยกภาวะหัวใจเต้นผิดปกติ 5 ชนิดด้วยกันซึ่งรวมไปถึงภาวะทั้งสามที่กล่าวไปในข้างต้นด้วย ทำการหา Alphabet entropy เพื่อสกัดคุณลักษณะและใช้ Random forest เป็นตัวแยกแยะภาวะหัวใจเต้นผิดจังหวะ (Cardiac arrhythmia classifier) ซึ่งใช้วิธีการเรียนรู้ของเครื่อง (Machine learning) ผลที่ได้คือค่าความจำเพาะนั้นสูงมาก แต่ค่าความไวต่ำ ส่วนงานของ Yao, et al. [41] ได้ออกแบบโมเดลที่แยกภาวะหัวใจเต้นผิดปกติถึง 9 ชนิดด้วยกัน รวมถึงทั้งสามภาวะนั้นด้วย ซึ่งได้ใช้โครงสร้างคอนโวลูชัน, LSTM และได้นำกลไก Attention เข้ามาด้วยซึ่งเป็นอีกหนึ่งกลไกหนึ่งของการเรียนรู้เชิงลึก เพื่อเพิ่มประสิทธิภาพของโมเดล ค่าความไวและค่าความจำเพาะนั้นมีค่าสูงมาก แต่ฐานข้อมูลที่ใช้เป็นฐานข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจที่ทำการบันทึกด้วย 12 ช่องสัญญาณ (12-lead ECG) ซึ่งแตกต่างจากงานวิจัยที่กำลังทำนี้ได้มุ่งเน้นไปที่ฐานข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจจำนวน 1 ช่องสัญญาณ

จากที่ได้กล่าวไปในข้างต้นจะเห็นได้ว่าการแยกแยะข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงอนุกรมเวลาด้วยการเรียนรู้เชิงลึกนั้น LSTM เป็นโครงข่ายประสาทเทียมที่มักถูกนำมาใช้สำหรับงานประเภทนี้ มีงานวิจัยมากมายที่พยายามพัฒนาและเปรียบเทียบสถาปัตยกรรมแบบต่าง ๆ ของโครงข่ายประสาทเทียมแบบวนซ้ำกับโครงข่าย LSTM ได้ผลสรุปว่ายังไม่มีโมเดลใดที่ให้ผลดีมากกว่า LSTM [28] ในความเป็นจริงแล้วโครงข่ายคอนโวลูชันก็เคยถูกนิยมนำมาใช้กับข้อมูลเชิงเวลา แต่ด้วยเหตุผลในด้านเทคนิคที่ทำให้สถาปัตยกรรมแบบคอนโวลูชันถูกนำมาใช้เพื่อทำนายข้อมูลเชิงเวลาน้อยลง เนื่องจากไม่ได้มีการทำเอาส่วนประกอบเชิงสถาปัตยกรรมที่สำคัญอย่างคอนโวลูชันไดเลท (Dilated convolution) และการเชื่อมต่อส่วนที่เหลือ (Residual connection) มาใช้ [28] ซึ่งต่อมาได้มีการนำโครงข่ายคอนโวลูชันตามเวลามาเปรียบเทียบประสิทธิภาพกับโครงข่ายแบบวนซ้ำชนิดต่าง ๆ ซึ่งผลที่ได้ได้กล่าวไปแล้วในหัวข้อ 2.5 และโครงข่ายคอนโวลูชันตามเวลานี้ได้ถูกนำมาใช้กับข้อมูลในอนุกรมเวลามากขึ้นด้วย เช่น โครงข่าย WaveNet ของกูเกิล (Google) ที่นำเอาสถาปัตยกรรมของโครงข่ายนี้ไปใช้เพื่อแปลงตัวอักษรไปเป็นเสียง [29] และ C. Lea, et al. [42] นำไปใช้ในงานการแบ่งส่วนและตรวจจับกิจกรรมของมนุษย์จากวิดีโอ (Action Segmentation and Detection) แต่ยังมีไม่มากนักที่นำเอาโครงข่ายคอนโวลูชันตามเวลานี้ไปใช้เพื่อแยกแยะประเภทของสัญญาณคลื่นไฟฟ้าหัวใจ งานวิจัยนี้จึงมีความสนใจที่จะนำเอาโครงข่ายนี้มาใช้ในการแยกแยะภาวะหัวใจห้องบนสั่นพลิ้ว ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ โดยงานวิจัยที่เกี่ยวข้องกับการแยกแยะภาวะหัวใจห้องบนสั่นพลิ้ว ภาวะหัวใจห้องบนเต้นก่อน และภาวะหัวใจห้องล่างเต้นก่อน แสดงในตารางที่ 2 และข้อดีและข้อจำกัดของแต่ละงานวิจัยสรุปในตารางที่ 3

จากการทบทวนวรรณกรรมของงานวิจัยที่ประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วนั้น งานวิจัยทั้งหลายได้มุ่งเน้นไปที่การพัฒนาาระบบเพื่อแยกภาวะหัวใจห้องบนสั่นพลิ้วออกจากภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะจากสัญญาณคลื่นไฟฟ้าหัวใจ 1 ช่องสัญญาณในเชิงคลินิกเพื่อกลุ่มผู้ป่วยโรคหลอดเลือดสมองเป็นประเด็นหลักเช่นงานวิจัยนี้ และอีกทั้งระบบการคัดกรองของ

งานวิจัยนี้จะถูกพัฒนาให้สามารถนำไปใช้ร่วมกับอุปกรณ์พกพาทางการแพทย์เพื่อเพิ่มประสิทธิภาพการทำงานของระบบการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว ผู้วิจัยจึงมีแนวคิดที่จะเน้นปรับปรุงค่าความจำเพาะให้สูงขึ้น เพื่อที่ว่าภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะจะไม่ถูกปะปนมากับภาวะหัวใจห้องบนสั่นพลิ้ว ทำให้การคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วนั้นเป็นไปอย่างมีประสิทธิภาพมากยิ่งขึ้น

**ตารางที่ 2** การสรุปงานวิจัยที่เกี่ยวกับการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

<i>Study</i>	<i>Arrhythmias</i>	<i>Database</i>	<i># of data (records)</i>	<i>Feature set</i>	<i>Classifier</i>	<i>Sen   Spec of each arrhythmia (%)</i>
<b>Yao et al. [41]</b>	<b>NSR, AF, I-AVB*, LBBB, RBBB, PAC, PVC, STD**, STE***</b>	The 1st China Physiologica l Signal Challenge (12-Lead)	Train: 918 NSR, 556 PVC, 672 PAC, 1098 AF Test: 394 NSR, 276 PVC, 250 PAC, 466 AF	End-to-end	CNN and LSTM	PVC: 87.32   98.39 PAC: 73.60   97.56 AF: 92.06   98.47
	<i>Preprocessing</i>	Data augmentation for reducing overfitting and normalization mean and standard deviation for converging faster.				
<i>Study</i>	<i>Arrhythmias</i>	<i>Database</i>	<i># of data (segments)</i>	<i>Feature set</i>	<i>Classifier</i>	<i>Acc   Sen   Spec of each arrhythmia (%)</i>
<b>A. Jovic, and F. Jovic [9]</b>	<b>NSR, PAC, PVC, AF, VB<sup>+</sup>, VT<sup>++</sup></b>	MIT-BIH	Train and test: 1520 NSR, 197 PAC, 437 PVC, 364 AF	Alphabe t entropy	Random forest	PVC: 83.74   95.77 PAC: 71.90   98.73 AF: 93.85   97.70
	<i>Preprocessing</i>	Transforming the ECG signal into a sequence of alphabet letters and find entropy of alphabet in order to getting features.				

\* First-degree Atrioventricular Block \*\* ST-segment depression \*\*\* ST-segment elevation <sup>+</sup> Ventricular Bigeminy <sup>++</sup> Ventricular Trigeminy

ตารางที่ 3 การสรุปข้อดีและข้อจำกัดของการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว

	วิธีการคัดกรอง	ข้อดี	ข้อจำกัด	งานวิจัย
การไม่ประยุกต์ใช้ การเรียนรู้เชิงลึก	Rhythm-based method	อัลกอริทึมง่าย ชับซ้อนน้อย ไม่ใช่ทรัพยากรในการคำนวณมาก จึงสามารถนำไปใช้ใน ไมโครคอนโทรลเลอร์ได้ และการพิจารณา R peak ของ ECG นั้นไม่ค่อยถูกรบกวนเพราะเป็นคลื่นที่มีขนาดใหญ่	ประสิทธิภาพในการคัดกรองแยกลงเมื่อทำการแยกภาวะของหัวใจที่มีลักษณะของอัตราการเต้นของหัวใจที่เหมือนหรือคล้ายกัน	[7], [9], [21]
	Morphology-based method	ทำการคัดกรองภาวะของหัวใจที่มีอัตราการเต้นของหัวใจที่คล้ายกันได้ดี เพราะพิจารณาจากรูปร่างของคลื่น	คลื่นอื่น ๆ ใน ECG มีขนาดเล็กเมื่อเทียบกับ R peak ซึ่งสามารถถูกรบกวนได้ง่ายทำให้ยากต่อการวิเคราะห์	[19, 36-38]
การประยุกต์ใช้ การเรียนรู้เชิงลึก	CNN	โครงสร้างมีความสามารถในการพิจารณาลักษณะรูปร่างของสัญญาณ ECG โดยผ่านตัวกรองขนาดต่าง ๆ กัน	ประสิทธิภาพน้อยเมื่อใช้กับสัญญาณ ECG ตามแกนเวลา	[6], [12]
	LSTM	โครงสร้างที่สามารถจำข้อมูลตามแกนเวลาที่มีขนาดยาวได้ การดูสัญญาณตามแกนเวลา ทำให้เห็นการเปลี่ยนแปลงของ ECG จากภาวะหนึ่งไปสู่อีกภาวะหนึ่งได้ดี	การเรียนรู้จากข้อมูลดิบที่ไม่ผ่านการสกัดคุณลักษณะก่อน ผลของประสิทธิภาพจะด้อยลงและหากข้อมูลเข้ามีขนาดที่ยาวมาก ๆ การเรียนรู้ของโมเดลจะไม่ดีขึ้น	[39]
	CNN และ LSTM	CNN มีความสามารถในการช่วยสกัดคุณลักษณะออกมาได้ดี เมื่อคุณลักษณะดังกล่าวเข้าสู่ LSTM ทำให้ LSTM สามารถแยกแยะข้อมูลได้ดีขึ้น	โครงสร้างที่ใช้มีความซับซ้อนมาก จึงจำเป็นต้องใช้เครื่องมือระดับสูงและระยะเวลาในการเรียนรู้เนื่องจากใช้สัญญาณทั้งหมด 12 ช่องสัญญาณ และค่าความจำเพาะอยู่ที่ประมาณร้อยละ 98	[13], [40], [41]

### บท 3

#### ระเบียบวิธีการดำเนินงาน

##### 3.1 ฐานข้อมูลคลื่นไฟฟ้าสัญญาณหัวใจ

###### 3.1.1 ฐานข้อมูล PhysioNet/CinC challenge 2017

ในเบื้องต้นจะนำฐานข้อมูล PhysioNet/CinC challenge 2017 [14] มาเป็นฐานข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ โดยฐานข้อมูลนี้ประกอบด้วยสัญญาณทั้ง 4 แบบด้วยกัน ได้แก่ คลื่นไฟฟ้าหัวใจภาวะปกติ (N) ภาวะหัวใจห้องบนสั้นพลิ้ว (A) ภาวะหัวใจเต้นผิดปกติดื่น ๆ (O) และสัญญาณรบกวน (~) โดยมีทั้งหมด 8,528 บันทึก มีความยาวของสัญญาณตั้งแต่ 9.0 – 61.0 วินาที สัญญาณคลื่นไฟฟ้าหัวใจนี้ถูกบันทึกจากเครื่องมือวัดของบริษัท AliveCor โดยทำการวัดสัญญาณโดยใช้ปลายนิ้วสัมผัสที่อิเล็กโทรดแบบแห้ง ความถี่ในการบันทึกสัญญาณ (Sampling rate) เท่ากับ 300 Hz และเป็นกรวัดแบบหนึ่งช่องสัญญาณ (Single lead ECG) และสัญญาณถูกกรองออกด้วย Band-pass filter ซึ่งอยู่ภายในอุปกรณ์วัด ตารางที่ 4 แสดงจำนวนของสัญญาณของแต่ละประเภทและระยะเวลาของสัญญาณ

งานวิจัยนี้เลือกใช้สัญญาณที่เป็นภาวะปกติกับภาวะหัวใจห้องบนสั้นพลิ้วโดยมีระยะเวลาของสัญญาณยาว 30 วินาที มาใช้ในการสร้างและทดสอบโมเดล ถึงแม้ว่าจะมีการกรองเอาสัญญาณรบกวนออกไป แต่ก็ยังคงมีสัญญาณรบกวนปนเปื้อนอยู่บ้าง เช่น สัญญาณรบกวนที่เกิดจากการเคลื่อนไหวร่างกายและนิ้วขณะวัด เป็นต้น แต่งานวิจัยนี้จะไม่ทำการประมวลผลเพื่อลดทอนสัญญาณรบกวน เนื่องจากต้องการทดสอบประสิทธิภาพของการเรียนรู้เชิงลึกของเครื่องในการคัดแยกคุณลักษณะที่สำคัญของคลื่นไฟฟ้าหัวใจที่มีสัญญาณรบกวนปนอยู่


**ตารางที่ 4** ข้อมูลของฐานข้อมูล PhysioNet/CinC challenge 2017 (ตารางข้อมูลจาก AF Classification from a Short Single Lead ECG Recording - The PhysioNet Computing in Cardiology Challenge 2017 สามารถดูได้ที่ <https://physionet.org/content/challenge-2017/1.0.0/>)

Type	# of recording	Time length (s)				
		Mean	SD	Max	Median	Min
Normal	5154	31.9	10.0	61.0	30	9.0
Atrial Fibrillation	771	31.6	12.5	60	30	10.0
Other rhythm	2557	34.1	11.8	60.9	30	9.1
Noisy	46	27.1	9.0	60	30	10.2
Total	8528	32.5	10.9	61.0	30	9.0

### 3.1.2 ฐานข้อมูล Long Term Atrial Fibrillation Database

ฐานข้อมูล Long Term Atrial Fibrillation Database (LTAfDB) [15] นี้ประกอบด้วยสัญญาณคลื่นไฟฟ้าหัวใจขนาดความยาว 24 ถึง 25 ชั่วโมง โดยมีทั้งหมด 84 บันทึก โดยบันทึกจากผู้รับการทดลองที่มีภาวะหัวใจห้องบนสั่นพลิ้วทั้งแบบเกิดภาวะหัวใจห้องบนสั่นพลิ้วเป็นครั้งคราว (Paroxysmal Atrial Fibrillation: PAF) และเกิดภาวะหัวใจห้องบนสั่นพลิ้วแบบต่อเนื่องยาวนาน (Sustained atrial fibrillation) สัญญาณคลื่นไฟฟ้าหัวใจนี้ได้ถูกบันทึกด้วยความถี่ 128 Hz และประกอบด้วย 2 ช่องสัญญาณ แต่ในงานวิจัยนี้เลือกใช้เพียง 1 ช่องสัญญาณคือ MLII (Modified Lead II)

การทำหมายเหตุ (Annotation) ประกอบด้วยสัญญาณคลื่นไฟฟ้าหัวใจของฐานข้อมูลนี้ประกอบด้วย 2 ลักษณะคือ การทำหมายเหตุจุดหัวใจเต้น (Beat annotation) และการทำหมายเหตุจังหวะของหัวใจ (Rhythm annotation) โดยการทำหมายเหตุจุดหัวใจเต้นของฐานข้อมูลนี้ประกอบด้วย จุดหัวใจเต้นปกติ (N: Normal beat) หัวใจห้องล่างเต้นก่อนจังหวะ (V: Premature ventricular contraction) หัวใจห้องบนเต้นก่อนจังหวะ (A: Premature atrial contraction) และจุดหัวใจเต้นที่ไม่สามารถแยกแยะได้ (Q: Unclassifiable beat) และการทำหมายเหตุจังหวะของหัวใจของฐานข้อมูลนี้มีดังนี้ จังหวะหัวใจเต้นปกติ (N: Normal sinus rhythm) จังหวะหัวใจห้องบนเต้นเร็ว (SVTA: Supraventricular tachyarrhythmia) จังหวะหัวใจห้องล่างเต้นเร็ว (VT: Ventricular tachycardia) จังหวะหัวใจภาวะหัวใจห้องบนสั่นพลิ้ว (AFIB: Atrial fibrillation) จังหวะหัวใจที่มีภาวะหัวใจห้องล่างบีบตัวก่อนจังหวะเกิดขึ้นคู่กับ QRS complex 1 ตัว (B: Ventricular bigeminy) จังหวะหัวใจที่มีภาวะหัวใจห้องล่างบีบตัวก่อนจังหวะเกิดขึ้นคู่กับ QRS complex 2 ตัว (T: Ventricular trigeminy) จังหวะหัวใจที่ถูกควบคุมด้วย Purkinje fibers เนื่องจากตัวควบคุมการเต้นอื่น ๆ ไม่สามารถทำงานได้ (IVR: Idioventricular rhythm) จังหวะหัวใจที่มีภาวะหัวใจห้องบนบีบตัวก่อนจังหวะเกิดขึ้นคู่กับ QRS complex 1 ตัว (AB: Atrial bigeminy) และจังหวะหัวใจเต้นช้า (SBR: Sinus bradycardia) การทำหมายเหตุจังหวะที่ระบุอยู่ในฐานข้อมูลจะเป็นเครื่องหมาย “(” และตามด้วยชื่อย่อของจังหวะหัวใจที่เกิดขึ้นได้กล่าวไปแล้ว โดยเครื่องหมาย “(” หมายถึงจุดเริ่มต้นของการเกิดจังหวะการเต้นของหัวใจชนิดนั้น ๆ เนื่องจากมีการเปลี่ยนแปลงของ ST segment และ T wave



รูปที่ 19 ตัวอย่างการทำหมายเหตุของฐานข้อมูล LTAfDB



### 3.2 การประเมินโมเดลการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้ว

#### 3.2.1 คอนฟิวส์ชัน เมทริกซ์

เมื่อโมเดลถูกสร้างขึ้นแล้ว มีความจำเป็นต้องทำการทดสอบประสิทธิภาพของโมเดล ซึ่งคอนฟิวส์ชัน เมทริกซ์ (Confusion matrix) เป็นตารางที่แสดงผลการจำแนกของโมเดลตามคลาสต่าง ๆ และสามารถนำมาคำนวณหาตัววัดประสิทธิภาพได้ จากตารางที่ 5 เป็นตัวอย่างของคอนฟิวส์ชัน เมทริกซ์ที่มีคลาสทั้งหมด 4 คลาส จะทำการเปรียบเทียบข้อมูลที่ถูกทำนายและข้อมูลจริงซึ่งอยู่ในส่วนของคอลัมน์และแถว ตามลำดับ โดยค่าในตาราง คอนฟิวส์ชัน เมทริกซ์สามารถถูกนิยามได้ 4 ค่าคือ ผลบวกจริง (True Positive: TP) ผลบวกปลอม (False Positive: FP) ผลลบปลอม (False Negative: FN) และผลลบจริง (True Negative: TN) ซึ่งแสดงการคำนวณจาก ตารางคอนฟิวส์ชัน เมทริกซ์ในสมการที่ 27-30

ผลบวกจริง คือ คนที่เป็นโรคและถูกทำนายว่าเป็นโรค (โมเดลทำนายถูกต้อง)

ผลบวกปลอม คือ คนที่ไม่เป็นโรคแต่ถูกทำนายว่าเป็นโรค (โมเดลทำนายผิด)

ผลลบปลอม คือ คนที่เป็นโรคแต่ถูกทำนายว่าไม่เป็นโรค (โมเดลทำนายผิด)

ผลลบจริง คือ คนที่ไม่เป็นโรคและถูกทำนายว่าไม่เป็นโรค (โมเดลทำนายถูกต้อง)

ตารางที่ 5 คอนฟิวส์ชัน เมทริกซ์

		Predicted class			
		A	B	C	D
Actual class	A	$\hat{Y}_{1,1}$	$\hat{Y}_{1,2}$	$\hat{Y}_{1,3}$	$\hat{Y}_{1,4}$
	B	$\hat{Y}_{2,1}$	$\hat{Y}_{2,2}$	$\hat{Y}_{2,3}$	$\hat{Y}_{2,4}$
	C	$\hat{Y}_{3,1}$	$\hat{Y}_{3,2}$	$\hat{Y}_{3,3}$	$\hat{Y}_{3,4}$
	D	$\hat{Y}_{4,1}$	$\hat{Y}_{4,2}$	$\hat{Y}_{4,3}$	$\hat{Y}_{4,4}$

$$TP_i = \hat{Y}_{i,i} \quad (27)$$

$$FP_i = \sum_{j=1}^D \hat{Y}_{j,i} \quad (\text{expect } j = i) \quad (28)$$

$$FN_i = \sum_{j=1}^D \hat{Y}_{i,j} \quad (\text{expect } j = i) \quad (29)$$

$$TN_i = \sum_{j=1}^D \sum_{k=1}^D \hat{Y}_{j,k} \quad (\text{expect } j = i \text{ or } k = i) \quad (30)$$

### 3.2.2 ค่าความไว

ในแง่มุมมองของการคัดกรองโรคทางการแพทย์ ค่าความไวเป็นค่าที่สำคัญที่ต้องคำนึงถึงเป็นอันดับแรก เนื่องจากในการคัดกรองต้องการแยกบุคคลที่มีแนวโน้มว่าจะป่วยหรือมีความผิดปกติให้ได้ทั้งหมด หลังจากนั้นจึงทำการวินิจฉัยเพิ่มเติมอย่างละเอียดอีกครั้ง ซึ่งถ้าหากผู้ป่วยไม่สามารถถูกจำแนกมาได้ตั้งแต่ขั้นแรก จะเป็นอันตรายต่อผู้ป่วยเป็นอย่างมาก อาจจะทำให้ผู้ป่วยไม่ได้รับการรักษาอย่างทันท่วงที

$$Sensitivity = \frac{TP}{TP+FN} \quad (31)$$

### 3.2.3 ค่าความจำเพาะ

ในการทดสอบประสิทธิภาพของโมเดลที่ใช้คัดกรองผู้ป่วยนั้น ถ้าค่าความจำเพาะต่ำ ผลที่ได้คือ คนปกติจะถูกทายว่าเป็นคนป่วยมากขึ้น เมื่อผลการคัดกรองนี้ไปถึงมือของแพทย์ แพทย์จำเป็นจะต้องทำงานมากขึ้นและผู้ที่ไม่ป่วยอาจจะต้องเสียเวลาและค่าตรวจเพื่อมาตรวจร่างกายที่โรงพยาบาล ด้วยเหตุนี้งานวิจัยนี้จึงต้องการเพิ่มความจำเพาะให้มากขึ้น เพื่อให้ข้อมูลการคัดกรองก่อนจะถึงมือแพทย์มีความถูกต้องและแม่นยำมากที่สุด

$$Specificity = \frac{TN}{TN+FP} \quad (32)$$

ในงานวิจัยนี้จะคำนวณตัววัดประสิทธิภาพ 2 ตัวด้วยกันคือ ความไว (Sensitivity) และความจำเพาะ (Specificity) ตามสมการที่ 31 และ 32 ตามลำดับ

## 3.3 การใช้โครงข่ายถ่ายโอนเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพสัญญาณคลื่นไฟฟ้าหัวใจ

### 3.3.1 การเตรียมข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ

การเตรียมข้อมูลทั้งชุดเรียนรู้ (Training set) และชุดทดสอบ (Testing set) ของงานวิจัยนี้ได้เตรียมข้อมูลจากฐานข้อมูลคลื่นไฟฟ้าหัวใจ PhysioNet/CinC challenge 2017 ที่ได้อธิบายไปในหัวข้อ 3.1 ข้อมูลที่ถูกเตรียมนี้เป็นข้อมูลภาพสี RGB ลักษณะของภาพที่แปลงจากสัญญาณคลื่นไฟฟ้าหัวใจคือ พื้นหลังของภาพจะเป็นสีขาว ส่วนเส้นของสัญญาณจะเป็นสีดำและความละเอียดของเส้นสัญญาณในภาพเท่ากับ 1/72 นิ้วต่อ 1 จุด ภาพแปลงได้เป็นภาพสี RGB 24 บิต (bit) ความละเอียดของภาพเท่ากับ 96 จุดต่อตารางนิ้ว เป็นภาพสี 24 บิต รูปที่ 20 แสดงรายละเอียดของภาพที่แปลงได้

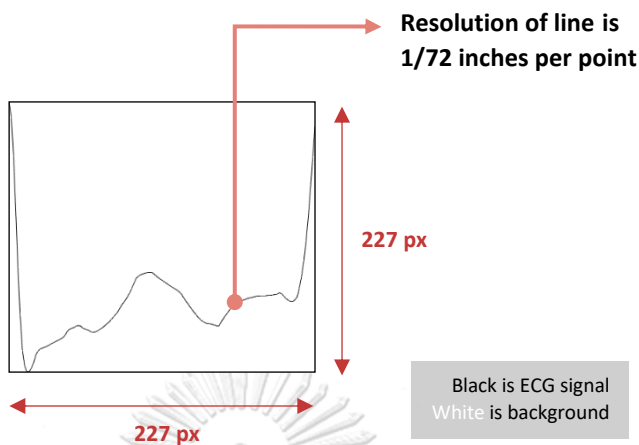
เนื่องจากต้องการทราบว่า การเตรียมข้อมูลแบบใดให้ผลดีสำหรับการทำนายชนิดของคลื่นไฟฟ้าหัวใจ ภาวะปกติและภาวะหัวใจห้องบนสั่นพลิ้วจึงได้แบ่งชุดข้อมูลเป็น 4 ชุดดังนี้

① คลื่นไฟฟ้าหัวใจที่มีช่วงความยาวของสัญญาณที่กำหนดขึ้น โดยแบ่งเป็น 1, 2, 3, 4 และ 5 วินาที ตามลำดับ

② คลื่นไฟฟ้าหัวใจระหว่าง R peak

③ คลื่นไฟฟ้าหัวใจในข้อที่ 2 แต่ตัด R-S segment และ Q-R segment ออก

④ คลื่นไฟฟ้าหัวใจในองค์ประกอบความถี่



รูปที่ 20 รายละเอียดภาพสัญญาณคลื่นไฟฟ้าหัวใจที่แปลงได้


ชุดข้อมูลในประเภทที่ ① จะทำการสุ่มตัดช่วงเวลาของสัญญาณคลื่นไฟฟ้าหัวใจตามช่วงเวลาดังกล่าวข้างต้นคือ 1, 2, 3, 4 และ 5 วินาที ตัวอย่างของข้อมูลชุดที่ 1 (ที่ใช้สัญญาณคลื่นไฟฟ้าหัวใจในช่วงเวลา 3 วินาที) ที่ถูกแปลงมาเป็นภาพ แสดงในรูปที่ 21 A โดยข้อมูลชุดนี้จะทำการสุ่มสัญญาณคลื่นไฟฟ้าหัวใจมีทั้ง 30 วินาทีมา 60 ชุด แบ่งเป็นชุดสำหรับฝึก 40 ชุดและชุดสำหรับทดสอบ 20 ชุด เมื่อสัญญาณถูกแปลงเป็นภาพ ภาพที่ได้จะถูกสุมนำมาฝึกและทดสอบโมเดลชุดละ 5 ภาพ โดยจำนวนชุดข้อมูลที่ใช้ในแต่ละโมเดลถูกรูปลงไว้ในตารางที่ 6

ชุดข้อมูลในประเภทที่ ② และ ③ โดยกระบวนการก่อนที่จะได้ข้อมูลจะต้องมีการทำการตรวจจับคลื่น QRS complex เสียก่อน โดยปัจจุบันมีหลากหลายวิธีการในการตรวจจับคลื่นนี้ เพราะเป็นคลื่นที่มีขนาดสูงสุดในคลื่นไฟฟ้าหัวใจและสามารถใช้ในการวินิจฉัยความผิดปกติต่าง ๆ ของการทำงานของหัวใจได้ โดยในงานวิจัยนี้ได้เลือกวิธีที่มีความแม่นยำและใช้งานได้ดีอย่าง Pan-Tompkins algorithm [43] เพื่อนำมาตัดช่วงคลื่นระหว่าง R peak และนำช่วงคลื่นระหว่างนั้นไปพิจารณา โดยในชุดที่ ② จะนำสัญญาณระหว่าง R peak มาใช้ แต่ในชุดที่ ③ จะนำเอา R-S segment และ Q-R segment ซึ่งเป็นส่วนหนึ่งของ QRS complex ออก ดังรูปที่ 21 B และ 21 C ตามลำดับ ส่วนจำนวนข้อมูลของชุดข้อมูลประเภทที่ ② และ ③ มีจำนวนเท่ากับชุดข้อมูลประเภทที่ ①

ในส่วนชุดข้อมูลสุดท้าย ④ จะนำสัญญาณคลื่นไฟฟ้าหัวใจความยาว 30 วินาทีมาทำการวิเคราะห์องค์ประกอบทางความถี่ คือ การแปลงฟูเรียร์แบบรวดเร็ว (Fast Fourier Transform: FFT) โดยจะใช้สัญญาณคลื่นไฟฟ้าหัวใจทั้งหมดของการบันทึก คือ สัญญาณคลื่นไฟฟ้าหัวใจมีทั้ง 30 วินาทีจะเอาทั้ง 30 วินาทีมาทำการแปลงฟูเรียร์แบบรวดเร็ว และแปลงเป็น 1 ภาพ จำนวนสัญญาณคลื่นไฟฟ้าหัวใจที่ใช้ในการเรียนรู้และทดสอบมี 200 และ 100 ข้อมูล ตามลำดับ โดยแบ่งเป็นแต่ละภาพอย่างละครึ่งหนึ่งเช่นเดียวกับชุดข้อมูลก่อนหน้า ตัวอย่างดังแสดงในรูปที่ 21 D

ตารางที่ 6 จำนวนของชุดสัญญาณคลื่นไฟฟ้าหัวใจและจำนวนภาพคลื่นไฟฟ้าหัวใจในแต่ละชุดข้อมูล

Model	Training set				Testing set			
	No. of ECG records		No. of ECG images		No. of ECG records		No. of ECG records	
	AF	NSR	AF	NSR	AF	NSR	AF	NSR
①, ②, ③	20	20	100 (20×5)	100 (20×5)	10	10	50 (10×5)	50 (10×5)
④	100	100	100	100	50	50	50	50



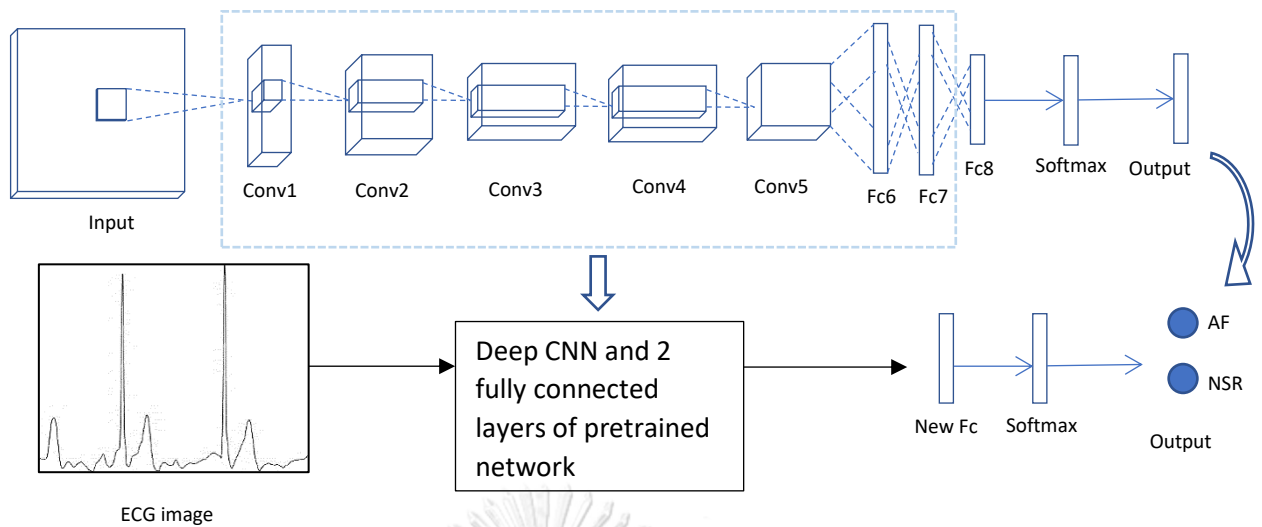
รูปที่ 21 ตัวอย่างภาพของสัญญาณคลื่นไฟฟ้าหัวใจในภาวะหัวใจห้องบนสั่นพลิ้ว (ซ้าย) และภาวะหัวใจเต้นปกติ (ขวา) สำหรับให้โมเดลเรียนรู้และใช้ทดสอบแบ่งเป็น ① คลื่นไฟฟ้าหัวใจที่ใช้การกำหนดเวลา (A) ② คลื่นไฟฟ้าหัวใจระหว่าง R peak (B) ③ คลื่นไฟฟ้าหัวใจในข้อที่ 2 แต่ตัด R-S segment และ Q-R segment ออก (C) และ ④ คลื่นไฟฟ้าหัวใจในองค์ประกอบความถี่ (D) ตามลำดับ

### 3.3.2 การใช้การเรียนรู้ถ่ายโอนแบบโครงข่ายคอนโวลูชันเพื่อเรียนรู้ภาพสัญญาณคลื่นไฟฟ้าหัวใจ

งานวิจัยนี้ได้ใช้แนวคิดของการเรียนรู้ถ่ายโอน (Transfer function) มาใช้ โดยได้เลือกใช้โครงข่ายชื่อดังอย่าง AlexNet ซึ่งเป็นโครงข่ายคอนโวลูชัน โครงข่ายนี้ได้เรียนรู้จากฐานข้อมูลภาพขนาดใหญ่ของ ImageNet ประกอบไปด้วยภาพสี RGB ที่มีความคมชัดสูงถึง 1.2 ล้านภาพ และมีประเภทของภาพมากถึง 1,000 ประเภท

โครงสร้างที่ใช้ในการถ่ายโอนนั้นจะประกอบด้วย 2 ส่วนหลัก ๆ คือ ชั้นล่าง (Lower layers) เป็นชั้นที่อยู่ใกล้กับชั้นขาเข้า และชั้นบน (Higher layers) เป็นชั้นที่อยู่ใกล้กับชั้นขาออก แสดงในรูปที่ 22 ชั้นทั้งสองจะมีการถ่ายโอนคุณลักษณะที่ต่างกัน โดยชั้นล่างจะสามารถถูกถ่ายโอนไปยังงานใหม่ ๆ ได้ดีกว่า เพราะเป็นชั้นที่ยังไม่จำเพาะเจาะจง (More general features) สามารถใช้ชั้นเหล่านี้เพื่อแยกแยะคุณลักษณะที่สำคัญของข้อมูลได้ แต่ส่วนชั้นบนนั้นจะมีความจำเพาะต่องานที่เคยทำมากกว่า (More task specific features) แต่ถ้าโมเดลได้รับการฝึกจากข้อมูลจากงานใหม่ที่มีประสิทธิภาพ ลักษณะทั่วไป (Generalization) ของชั้นบนก็สามารถถูกปรับปรุงให้ดีขึ้นและเหมาะกับงานใหม่ได้ [44]

นอกจากใช้การเรียนรู้ถ่ายโอนแล้ว งานวิจัยนี้ได้นำแนวคิดการปรับจูนละเอียด (Fine tuning) มาใช้เพื่อปรับปรุงโมเดลด้วย โดยนำเอาโครงสร้างและค่าถ่วงน้ำหนักเริ่มต้น (Initial weight) ของชั้นคอนโวลูชัน (Convolutional layer) 5 ชั้นและชั้นการเชื่อมโยงเต็มรูปแบบ (Fully connected layer) 2 ชั้นจาก AlexNet มาใช้กับภาพสัญญาณคลื่นไฟฟ้าหัวใจที่เตรียมไว้ ส่วนชั้นการเชื่อมโยงเต็มรูปแบบชั้นสุดท้ายถูกเปลี่ยนเพื่อให้เหมาะกับงานวิจัยนี้ซึ่งมีแค่ 2 คลาสแตกต่างจากงานเดิมที่มีถึง 1,000 คลาส แสดงในรูปที่ 22 โดยในส่วนของชั้นคอนโวลูชันทั้ง 5 ชั้นและชั้นการเชื่อมโยงเต็มรูปแบบอีก 2 ชั้นจะไม่มีการคงค่าถ่วงน้ำหนักค่าเดิมไว้ คือ ค่าถ่วงน้ำหนักจะถูกเปลี่ยนไปจากค่าเดิมเพื่อให้เหมาะกับงานใหม่มากขึ้น โดยกระบวนการปรับค่าถ่วงน้ำหนักจะใช้การคำนวณย้อนกลับ (Backpropagation) ดังที่เคยกล่าวไปในหัวข้อที่ 2.3.2 อย่างไรก็ตามเพื่อให้การฝึกข้อมูลเป็นไปอย่างรวดเร็ว กำหนดให้ค่าแฟคเตอร์อัตราการเรียนรู้ค่าถ่วงน้ำหนัก (Weight learning rate factor) และค่าแฟคเตอร์อัตราการเรียนรู้ค่าไบแอส (Bias learning rate factor) มีค่าเท่ากับ 10 ทั้งสองค่า และใช้อัตราการเรียนรู้ (Learning rate) 10 จากนั้นทำการฝึกโมเดลกับชุดข้อมูลฝึกทั้งหมด 12 รอบ (Epoch) เมื่อเทรนครบก็นำโมเดลไปทดสอบด้วยชุดทดสอบที่เตรียมไว้ โดยทั้งหมดนี้ใช้โปรแกรม MATLAB ในการดำเนินงาน และได้ใช้เครื่องมือที่ชื่อว่า Deep Network Designer ในการเข้าไปแก้ไขชั้นต่าง ๆ ของโครงข่าย AlexNet



**รูปที่ 22** โครงสร้างของโครงข่ายที่โอนถ่าย: โครงข่ายที่ผ่านการฝึกแล้ว (Pretrained network) คือ AlexNet (บน) และโครงสร้างของโครงข่ายที่ใช้ในงานนี้ ประกอบด้วยชั้นขาเข้าที่รับภาพสัญญาณคลื่นไฟฟ้าหัวใจเข้ามาด้วยขนาด  $227 \times 227$  พิกเซล ชั้นซ่อนที่มาจากโครงข่าย AlexNet ถัดมาเป็นชั้นการเชื่อมโยงเต็มรูปแบบใหม่ 1 ชั้น และชั้นขาออกที่จำแนกภาพเป็น 2 คลาสโดยใช้ Softmax เป็นตัวจำแนกคลาส

### 3.3.3 การทดสอบผลต่อการเกิดไบแอสของอัตราการเต้นของหัวใจมีผลที่มีต่อค่าความไว และค่าความจำเพาะของโมเดลจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพ

การทดลองที่ผ่านมายังคงมีข้อที่ต้องพิจารณาเพิ่มอยู่ สิ่งแรกคือ จำนวนของข้อมูลชุดฝึกและทดสอบ ยังคงน้อยเกินไป และอย่างที่สองคือ ไม่มีการพิจารณาถึงช่วงของอัตราการเต้นของหัวใจ แม้ว่าผลการทดลองที่แล้ว ต้องการดูความสำคัญของรูปร่างของสัญญาณคลื่นไฟฟ้าหัวใจในรูปแบบต่าง ๆ เป็นหลัก แต่ก็ปฏิเสธไม่ได้ว่าการกระจายของจำนวนข้อมูลของอัตราการเต้นของหัวใจในแต่ละช่วงนั้นก็มีความสำคัญกับการสร้างโมเดลด้วย ซึ่งการเพิ่มจำนวนข้อมูลในการฝึกและทดสอบในข้อที่หนึ่ง และการกระจายช่วงของอัตราการเต้นของหัวใจจะช่วยลดไบแอส (Bias) ที่อาจจะเกิดกับโมเดลลง และทำให้โมเดลที่ได้มีความครอบคลุม (Generalization) มากขึ้น

ในการทดลองนี้ได้ทำการเตรียมชุดข้อมูลฝึกและชุดข้อมูลทดสอบใหม่ โดยทำการเพิ่มจำนวนข้อมูลและกระจายจำนวนข้อมูลของอัตราการเต้นในแต่ละช่วงให้เท่ากันให้มากที่สุดเท่าที่เป็นไปได้ จากนั้นทำการเตรียมข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ 3 วินาที และทดสอบประสิทธิภาพของโมเดลเมื่อมีการปรับปรุงชุดข้อมูลใหม่นี้ ซึ่งในตารางที่ 7 แสดงจำนวนข้อมูลทั้งชุดฝึกและชุดทดสอบที่ใช้เพื่อสร้างโมเดลกำหนดเวลาสัญญาณคลื่นไฟฟ้าหัวใจ 3 วินาที โดยมีจำนวน 2,400 ภาพสำหรับชุดฝึกแบ่งเป็น 1,200 ภาพสำหรับภาวะหัวใจห้องบนสั่นพลิ้วและภาวะปกติอย่างละเท่า ๆ กัน (10 ภาพต่อ 1 สัญญาณคลื่นไฟฟ้าหัวใจ) และ 900 ภาพสำหรับชุดทดสอบแบ่งเป็น 450 ภาพสำหรับภาวะหัวใจห้องบนสั่นพลิ้วและภาวะปกติอย่างละเท่า ๆ กัน (15 ภาพต่อ 1 สัญญาณคลื่นไฟฟ้าหัวใจ)

ตารางที่ 7 สรุปจำนวนของชุดข้อมูลฝึกและชุดข้อมูลทดสอบที่ซึ่งถูกแบ่งเป็น 4 ช่วงของอัตราการเต้นของหัวใจ

Heart rate or HR (bpm)	Training set (records)		Testing set (records)	
	AF	NSR	AF	NSR
HR < 60	30	30	6	8
60 ≤ HR < 80	30	30	8	8
80 ≤ HR < 100	30	30	8	8
HR ≥ 100	30	30	8	6
Summation	240		60	

### 3.3.4 การกำหนดเกณฑ์ใหม่เพื่อการเปรียบเทียบผลการจำแนกที่ได้จากการเรียนรู้เชิงลึกกับอัลกอริทึมซับซ้อนน้อยสำหรับไมโครคอนโทรลเลอร์

งานวิจัยนี้มีความมุ่งมั่นในการปรับปรุงประสิทธิภาพในการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วจากการคัดกรองของอัลกอริทึมที่ฝังอยู่ในไมโครคอนโทรลเลอร์บนเครื่องตัวจับสัญญาณคลื่นไฟฟ้าหัวใจแบบพกพา โดยอัลกอริทึมที่ถูกฝังในไมโครคอนโทรลเลอร์ที่เป็นอุปกรณ์อิเล็กทรอนิกส์ชนิดหนึ่งจะเป็นอัลกอริทึมที่มีความซับซ้อนน้อย เพื่อลดการใช้พลังงานของหน่วยประมวลผลจากการทำงานของไมโครคอนโทรลเลอร์ จากการใช้อัลกอริทึมซับซ้อนน้อยนี้ทำให้ต้องเลือกประสิทธิภาพในการกรองภาวะหัวใจห้องบนสั่นพลิ้วระหว่างค่าความไวที่สูงหรือค่าความจำเพาะที่สูง ซึ่งการคัดกรองโรคในขั้นต้น ค่าความไวที่สูงนั้นเป็นสิ่งที่จำเป็นกว่า ทำให้มีสัญญาณคลื่นไฟฟ้าหัวใจในภาวะอื่น ๆ ปะปนมากับภาวะหัวใจห้องบนสั่นพลิ้วด้วย ดังนั้นงานวิจัยนี้จึงพัฒนาการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้วขั้นที่สอง เพื่อกรองส่วนที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้วออกหรือเป็นการเพิ่มค่าความจำเพาะที่ถูกลดทอนจากอัลกอริทึมก่อนหน้า

อัลกอริทึมที่มีความซับซ้อนน้อยจะเป็นอัลกอริทึมที่ทำการตรวจจับด้วยวิธีการพิจารณาจังหวะการเต้นของหัวใจ (Rhythm-based method) โดยทำการคำนวณค่า pNN50 ซึ่งเป็นการเป็นการคำนวณเพื่อหาความแปรปรวนของอัตราการเต้นของหัวใจ (Heart Rate Variability: HRV) และทำการแยกแยะสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติและภาวะหัวใจห้องบนสั่นพลิ้วออกจากกันโดยใช้เทคนิคการวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis: LDA) ซึ่งการเปรียบเทียบสองอัลกอริทึมที่ต่างกัน ทั้งสองอัลกอริทึมจำเป็นต้องใช้ชุดข้อมูลฝึกและชุดข้อมูลทดสอบเดียวกัน เนื่องจากอัลกอริทึมซับซ้อนน้อยใช้สัญญาณคลื่นไฟฟ้าหัวใจทั้ง 30 วินาทีเป็นข้อมูลในการทดสอบและทำนายออกมาว่าทั้ง 30 วินาทีนั้นเป็นภาวะใด แต่การเรียนรู้เชิงลึกที่ใช้ในงานวิจัยนี้ ข้อมูลทดสอบที่ใช้เป็นข้อมูลภาพและทำการทำนายออกมาทีละภาพว่าเป็นภาวะใด ดังนั้นการจะเปรียบเทียบทั้งสองอัลกอริทึมนี้ได้ อัลกอริทึมที่ใช้การเรียนรู้เชิงลึกจำเป็นต้องตั้งข้อกำหนดใหม่ โดยถ้าโมเดลจะทำการทายแต่ละภาพของสัญญาณคลื่นไฟฟ้าหัวใจหนึ่งและจากนั้นนำคำตอบไปเทียบกับเป้าหมายที่แท้จริง ถ้าโมเดลทายได้ถูกต้องมากกว่าทายผิดซึ่งจะนับจากจำนวนภาพ โมเดลจะได้รับ 1 คะแนนสำหรับการทายนี้ เช่น สัญญาณคลื่นไฟฟ้าหัวใจ A มี 15 ภาพ โมเดลให้คำตอบว่าเป็นภาวะปกติ 10 ภาพ และภาวะหัวใจห้องบนสั่นพลิ้ว 5 ภาพ จากนั้นนำคำตอบ

ของแต่ละภาพไปเทียบกับเป้าหมายที่แท้จริง ปรากฏว่าให้คำตอบถูก 9 ภาพ (ให้คำตอบเป็นภาวะปกติและภาวะผิดปกติได้อย่างถูกต้อง 5 และ 4 ภาพ ตามลำดับ) ดังนั้นโมเดลจะไม่ได้รับคะแนนจากการทายสัญญาณคลื่นไฟฟ้าหัวใจ A นี้ หรือแสดงว่าโมเดลให้คำตอบสัญญาณคลื่นไฟฟ้าหัวใจ A ผิด เป็นต้น หลังจากนั้นนำผลการให้คำตอบมาสร้างคอนฟิวสชัน เมทริกซ์ แล้วคำนวณค่าความไวและความจำเพาะเพื่อประเมินประสิทธิภาพของโมเดล สุดท้ายจึงนำผลที่ได้ไปเทียบกับอัลกอริทึมซบซ้อนน้อยได้

### 3.4 การเปลี่ยนจากข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจเป็นข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลา

ปัญหาของการใช้ภาพสัญญาณคลื่นไฟฟ้าหัวใจและการใช้โมเดล AlexNet สำหรับการพัฒนาระบบการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วนั้นมีดังนี้

#### 3.4.1 การแปลงข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลาเป็นข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ

จากจุดมุ่งหมายหลักของงานวิจัยนี้ต้องการนำเอาโครงข่ายการเรียนรู้เชิงลึกมาประยุกต์ใช้เพื่อคัดกรองภาวะหัวใจห้องบนสั่นพลิ้วร่วมกับอุปกรณ์วัดสัญญาณคลื่นไฟฟ้าหัวใจแบบพกพา ซึ่งอุปกรณ์ตัวนี้จะทำการวัดสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลาอยู่แล้ว ดังนั้นการแปลงข้อมูลในเชิงเวลาเป็นข้อมูลภาพจึงทำให้มีความยุ่งยากในการทำงานของระบบมากขึ้น ซึ่งอาจจะไม่สะดวกต่อการใช้งานจริง ดังนั้นการเปลี่ยนมาใช้ข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลาจึงมีความเหมาะสมในการใช้งานจริงมากกว่า


#### 3.4.2 ความจุของข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ

ข้อมูลของสัญญาณคลื่นไฟฟ้าหัวใจในภาพแทนด้วยเส้นสีดำ และที่เหลือคือส่วนของพื้นหลังที่แทนด้วยสีขาว จากรูปที่ 24 จะเห็นได้ว่า ส่วนที่เป็นสีขาวนั้นมีอยู่มากซึ่งถือว่าเป็นมีส่วนของข้อมูลที่ไม่ได้ใช้ประโยชน์ค่อนข้างมาก ซึ่งทำให้พื้นที่ให้การจัดเก็บข้อมูลนั้นถูกใช้อย่างไม่มีประสิทธิภาพเท่าที่ควร โดยข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลานั้นจะแทบจะไม่มีข้อมูลที่มิได้ใช้ประโยชน์เลย เพราะทุก ๆ จุดของข้อมูลในเชิงเวลานั้นคือตัวแทนของสัญญาณคลื่นไฟฟ้าหัวใจนั่นเอง ดังนั้นการใช้ข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงเวลาทำให้พื้นที่การจัดเก็บข้อมูลถูกใช้ไปอย่างคุ้มค่ามากกว่า

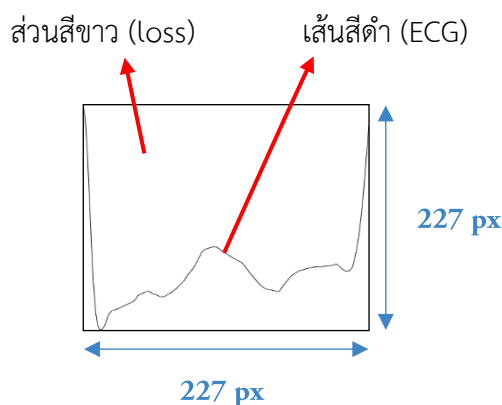
#### 3.4.3 ขนาดของภาพที่ใช้ในโมเดล AlexNet

ดังที่ได้กล่าวไปแล้วนั้นว่าโมเดล AlexNet เป็นโมเดลที่ถูกเทรนด้วยข้อมูลภาพจำนวนมาก ซึ่งขนาดของภาพที่โมเดลนี้ต้องการจะถูกกำหนดตายตัวเอาไว้ตามรูปที่ 20 ดังนั้นสัญญาณคลื่นไฟฟ้าหัวใจที่ปรากฏอยู่ในภาพจะถูกจำกัดไปด้วย ซึ่งทำให้พื้นที่ที่จะเห็นการเปลี่ยนแปลงหรือ Transition จากภาวะหนึ่งไปสู่อีกภาวะหนึ่งของสัญญาณคลื่นไฟฟ้าหัวใจได้ เช่น สัญญาณคลื่นไฟฟ้าหัวใจจากภาวะปกติสู่ภาวะหัวใจห้องบนเต้นก่อนจังหวะ เป็นต้น ซึ่งเป็นจำเป็นต้องเปลี่ยนมาใช้โครงข่ายที่มีประสิทธิภาพในการแยกแยะภาวะของหัวใจและสามารถใช้กับข้อมูลในเชิงเวลาได้ อย่างเช่น โครงข่าย LSTM โครงข่ายคอนโวลูชันตามเวลา





รูปที่ 23 กระบวนการของการตั้งข้อกำหนดใหม่เพื่อเปรียบเทียบประสิทธิภาพของโมเดลจากสองอัลกอริทึมที่ต่างกัน



รูปที่ 24 ตัวอย่างข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจที่แสดงถึงส่วนของข้อมูลที่เป็นสัญญาณ (สีดำ) และส่วนของข้อมูลที่ไม่ได้ใช้งาน (สีขาว)

### 3.5 การใช้โครงข่ายคอนโวลูชันตามเวลาเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา

#### 3.5.1 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา


เนื่องจากสัญญาณคลื่นไฟฟ้าหัวใจจากฐานข้อมูล Long Term Atrial Fibrillation Database มีความยาวมากกว่า 20 ชั่วโมง ดังนั้นไม่สามารถนำสัญญาณมาใช้ได้โดยตรงจำเป็นต้องมีการตัดสัญญาณออกเป็นขนาดย่อย ๆ เสียก่อน อีกทั้งสัญญาณคลื่นไฟฟ้าหัวใจในหนึ่งการบันทึกมีหลายประเภทของคลื่นไฟฟ้าหัวใจ ซึ่งอาจจะมีประเภทของสัญญาณที่ไม่ต้องการนำมาใช้ในโครงข่ายประสาทเทียมปนอยู่ ดังนั้นจึงต้องมีการออกแบบอัลกอริทึมเพื่อแยกข้อมูลที่ต้องการจริง ๆ ออกมาด้วย โดยการเตรียมข้อมูลในครั้งนี้ได้แบ่งประเภทของสัญญาณคลื่นไฟฟ้าหัวใจออกเป็นภาวะปกติและภาวะหัวใจห้องบนสั่นพลิ้ว 30 วินาที และภาวะหัวใจห้องล่างเต้นก่อนหรือภาวะหัวใจห้องบนเต้นก่อนที่มีจำนวนลูกมากกว่าหรือเท่ากับ 20 เปอร์เซ็นต์ของจำนวนลูกทั้งหมดของสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที

##### 3.5.1.1 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติและภาวะหัวใจห้องบนสั่นพลิ้วที่มีขนาดความยาว 30 วินาที


เนื่องจากงานวิจัยนี้มีความต้องการที่จะพัฒนาโมเดลให้สามารถนำไปประยุกต์ใช้ร่วมกับอุปกรณ์พกพาทางการแพทย์เพื่อเพิ่มประสิทธิภาพการทำงานของระบบการคัดกรองภาวะหัวใจห้องบนสั่นพลิ้ว ดังนั้นขนาดความยาวของสัญญาณคลื่นไฟฟ้าหัวใจที่จะใช้เพื่อให้โครงข่ายเรียนรู้จะมีขนาดสั้นอยู่ที่ 30 วินาที การนำเอาสัญญาณภาวะหัวใจเต้นปกติและภาวะหัวใจห้องบนสั่นพลิ้วออกจากสัญญาณที่มีความยาวกว่า 20 ชั่วโมงสามารถทำได้ดังนี้

(1) ตรวจสอบว่าแต่ละการบันทึกสัญญาณคลื่นไฟฟ้าหัวใจมีการทำหมายเหตุของจังหวะการเต้นของหัวใจเป็น “(AF)” หรือ “(N)” หรือไม่ ซึ่งตำแหน่งที่ได้จากหมายเหตุนี้จะเป็นจุดเริ่มต้นของสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที เพื่อให้แน่ใจว่าสัญญาณที่ได้เป็นภาวะที่ต้องการจริง ๆ

(2) สร้างหน้าต่างขนาด 30 วินาทีหรือ 3840 จุดสัญญาณ (คำนวณได้เทียบจากอัตราการเก็บข้อมูล 128 Hz) เพื่อตรวจสอบว่าสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีมี  
 หมายเหตุชนิดอื่นหรือไม่ โดยจากหัวข้อที่ 3.1.2 เกี่ยวกับลักษณะของการทำหมายเหตุของฐานข้อมูลทำให้ทราบว่ามีการบอกถึงจุดเริ่มต้นของจังหวะการเต้นของหัวใจผิดปกติและ  
 ผิดปกติ แต่ไม่มีการทำหมายเหตุของจังหวะการเต้นของหัวใจ ดังนั้นจุดที่เกิดภาวะหัวใจต่างกันถือเป็นจุดสิ้นสุดของภาวะก่อนหน้า



รูปที่ 25 ตัวอย่างการเตรียมสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติและภาวะหัวใจห้องบนสั้นๆ 30 วินาที



รูปที่ 26 ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจปกติ (บน) และภาวะหัวใจห้องบนสั้นๆ (ล่าง) 30 วินาทีจากการบันทึกเดียวกัน

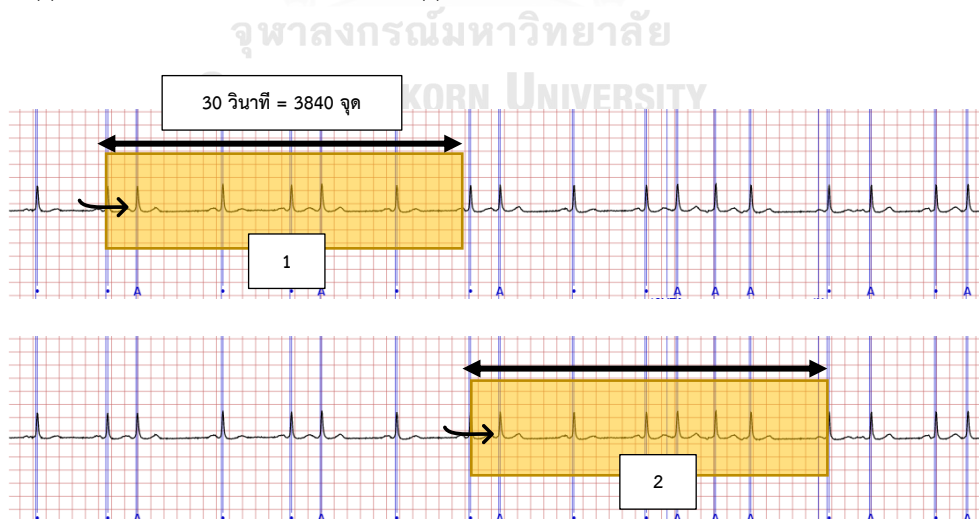
(3) ถ้าหากมีการทำหมายเหตุระบุเป็นภาวะอื่นที่ไม่ใช่ “(AF)” หรือ “(N)” จะทำการละทิ้งสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีนั้นและทำซ้ำที่ข้อ (1) ใหม่ โดยสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีที่เข้าเงื่อนไขจะจัดเก็บไว้เพื่อนำไปใช้สำหรับการเรียนรู้ของโครงข่ายต่อไป

### 3.5.1.2 การเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

(1) ตรวจสอบว่าแต่ละการบันทึกสัญญาณคลื่นไฟฟ้าหัวใจมีการทำหมายเหตุของจุดหัวใจเต้นเป็น “A” หรือ “V” หรือไม่


(2) สร้างหน้าต่างขนาด 30 วินาทีหรือ 3840 จุดสัญญาณโดยให้จุดเริ่มต้นของหน้าต่างอยู่ที่ตำแหน่งหมายเหตุจุดหัวใจก่อนที่จะเป็นตำแหน่งหมายเหตุจุดหัวใจ “A” หรือ “V” เพื่อให้มั่นใจว่าลูกคลื่นของสัญญาณไฟฟ้าหัวใจที่ถูกหมายเหตุเป็น “A” หรือ “V” นั้นมีรูปร่างของลูกคลื่นไฟฟ้าหัวใจที่สมบูรณ์ครบถ้วน จากนั้นทำการตรวจสอบว่าสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีว่ามีจำนวนของหมายเหตุจุดหัวใจเต้นที่เป็น “A” อย่างเดียวหรือ “V” อย่างเดียวรวมกันแล้วมากกว่าหรือเท่ากับ 20 เปอร์เซ็นต์หรือไม่เมื่อเทียบกับจำนวนลูกคลื่นทั้งหมดในคลื่นสัญญาณไฟฟ้าหัวใจ 30 วินาที การกำหนดตัวเลขขีดเริ่มต้น (Threshold) ที่ 20 เปอร์เซ็นต์นั้น อันเนื่องมาจากมีการยอมรับกันโดยทั่วไปว่าผู้ป่วยที่มีจำนวนลูกคลื่นที่เป็นภาวะหัวใจห้องล่างเต้นก่อนจังหวะอย่างน้อยร้อยละ 20 ของจำนวนลูกคลื่นไฟฟ้าหัวใจทั้งหมดจะมีภาวะหัวใจห้องล่างเต้นก่อนจังหวะแบบ “ความเสี่ยงสูง” (“High burden” of PVCs) [45]

(3) ถ้าหากข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีเข้าเงื่อนไขในข้อที่ (2) สัญญาณจะถูกบันทึกไว้เพื่อนำไปใช้สำหรับการเรียนรู้ของโครงข่ายต่อไป แต่ถ้าไม่เข้าเงื่อนไขจะทำการเลื่อนหน้าต่างไปยังตำแหน่งหมายเหตุจุดหัวใจก่อนที่จะเป็นตำแหน่งหมายเหตุจุดหัวใจ “A” หรือ “V” ลำดับต่อไป



รูปที่ 27 ตัวอย่างการเตรียมสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะความยาว 30 วินาที

จากรูปที่ 28 บน แสดงตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจก่อนจังหวะซึ่งมีจำนวนลูกคลื่นทั้งหมด 36 ลูก และมีจำนวนลูกที่เป็นภาวะหัวใจห้องบนบีบตัวก่อนจังหวะจำนวน 12 ลูก เทียบกับแล้วคิดเป็นร้อยละ 33.33 และรูปที่ 28 ล่าง มีจำนวนลูกคลื่นทั้งหมด 37 ลูก และมีจำนวนลูกที่เป็นภาวะหัวใจห้องกลางบีบตัวก่อนจังหวะจำนวน 8 ลูก ซึ่งคิดเป็นร้อยละ 21.62



**รูปที่ 28** ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจก่อนบีบตัวก่อนจังหวะ (บน) และภาวะหัวใจห้องกลางบีบตัวก่อนจังหวะ (ล่าง) 30 วินาทีจากการบันทึกเดียวกัน โดยตีฟ้าแทนคลื่นไฟฟ้าหัวใจที่เป็นภาวะหัวใจปกติ สีชมพูแทนภาวะหัวใจห้องบนบีบตัวก่อนจังหวะ และสีเขียวแทนภาวะหัวใจห้องกลางบีบตัวก่อนจังหวะ

### 3.5.1.3 การทำนายเหตุสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที

เนื่องจากงานวิจัยนี้ต้องการสร้างโมเดลจากสัญญาณคลื่นไฟฟ้าหัวใจในเชิงอนุกรมเวลา โดยบางข้อมูลสัญญาณ 30 วินาทีที่ถูกตัดแบ่งออกมาตามเงื่อนไขการปนกันของภาวะต่าง ๆ ตั้งแต่ 2 ภาวะขึ้นไป ซึ่งคือภาวะหัวใจเต้นปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ทำให้จำเป็นต้องทำการทำนายเหตุให้กับทุก ๆ จุดของสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที โดยใช้ 2 วิธีร่วมกันคือการใช้ฟังก์ชันจาก WFDB Toolbox สำหรับ MATLAB จาก PhysioNet และวิธีแบบแมนนวล (Manual method)

สำหรับการใช้ WFDB Toolbox สำหรับ MATLAB จาก PhysioNet ได้เลือกใช้ฟังก์ชันที่มีชื่อว่า ecgppuwave โดยฟังก์ชันตัวนี้สามารถบอกจุดเริ่มและจุดสิ้นสุดของแต่ละองค์ประกอบคลื่นในสัญญาณคลื่นไฟฟ้าหัวใจได้ ในงานวิจัยนี้ได้นำเอาฟังก์ชัน ecgppuwave มาใช้เพื่อบอกตำแหน่งจุดสิ้นสุดของ T wave เพื่อเป็นการแบ่งจุดคลื่นของสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีออกจากกัน

อย่างไรก็ตามฟังก์ชันนี้ไม่สามารถบอกตำแหน่งของจุดสิ้นสุดของ T wave ได้อย่างถูกต้องและครบถ้วน เห็นได้จากการชี้ของลูกศรสีดำ ดังแสดงในรูปที่ 29 ดังนั้นจึงมีการเขียนโปรแกรมแบบแมนนวลขึ้นมาเพื่อให้ผู้ใช้งานสามารถทำการแก้ไขหรือเพิ่มเติมตำแหน่งของจุดจบของ T wave ให้ถูกต้องมากยิ่งขึ้น โดยผู้ใช้งานสามารถเพิ่มเติมตำแหน่งที่ถูกต้องได้และทำการลบตำแหน่งที่ผิดได้เช่นกัน จากนั้นตำแหน่งจุดสิ้นสุดของ T wave จะถูกปรับให้ถูกต้อง เมื่อเสร็จสิ้นกระบวนการแล้วทุก ๆ จุดของสัญญาณคลื่นไฟฟ้าหัวใจจะถูกกำกับหมายเหตุวิธีการกำกับหมายเหตุสัญญาณคลื่นไฟฟ้าหัวใจแสดงในรูปที่ 29

### 3.5.2 การประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจห้องบนสั้นพลิ้วในเชิงอนุกรมเวลา

จากขั้นตอนการเตรียมข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจสามารถแยกประเภทของข้อมูลได้ออกเป็น 4 ประเภทได้แก่ สัญญาณภาวะหัวใจปกติ สัญญาณภาวะหัวใจห้องบนสั้นพลิ้ว สัญญาณที่มีการเจ็บบนของภาวะหัวใจห้องบนเต้นก่อนจังหวะ และสัญญาณที่มีการเจ็บบนของภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ซึ่งงานวิจัยนี้มีความมุ่งเน้นไปที่การแยกภาวะหัวใจห้องบนสั้นพลิ้วออกจากภาวะอื่น ๆ ดังนั้นข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในการทดลองนี้จะถูกแยกออกเป็น 2 กลุ่มใหญ่ด้วยกันคือ กลุ่มสัญญาณที่ไม่ใช่ภาวะหัวใจห้องบนสั้นพลิ้ว (Non-AF) ได้แก่ ภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ กับกลุ่มสัญญาณที่เป็นภาวะหัวใจห้องบนสั้นพลิ้ว (AF) โดยที่ทุก ๆ จุดของสัญญาณคลื่นไฟฟ้าหัวใจจะถูกหมายเหตุไว้ตามกลุ่มที่สัญญาณนั้นถูกจัดประเภทไว้


การประยุกต์ใช้การเรียนรู้เชิงลึกในการทดลองนี้ได้้นำโครงข่ายคอนโวลูชันตามเวลาหรือ Generic Temporal Convolutional Network (TCN) มาใช้แยกแยะภาวะหัวใจห้องบนสั้นพลิ้วออกจากภาวะอื่น ๆ ซึ่งโครงข่ายชนิดนี้มีข้อดีคือ ความสามารถในการทำงานแบบขนาน (Parallelism) ควบคุมขนาดของลานการรับรู้ได้ง่ายและยืดหยุ่น การส่งผ่านเกรเดียนต์มีความเสถียร และต้องการหน่วยความจำขณะเรียนรู้น้อย โครงข่ายนี้มีความ

### ECG data labeling method

Input: 30-second ECG segment with at least 20% of PAC or PVC

Output: All points of 30-second ECG segment are labeled.


#### Original ECG input data



The ECG data are prepared from Section 3.5.1.2

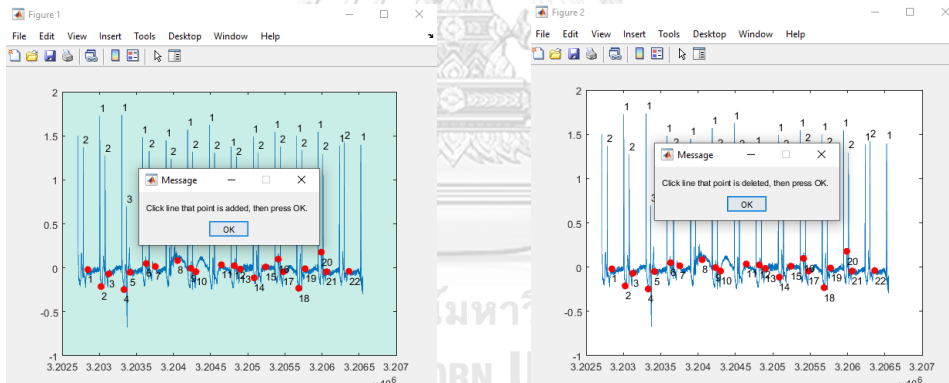
(1) Use 'ecgpuwave' function to find ending T waves of the ECG data.

Note: Red circles are the ending T wave positions

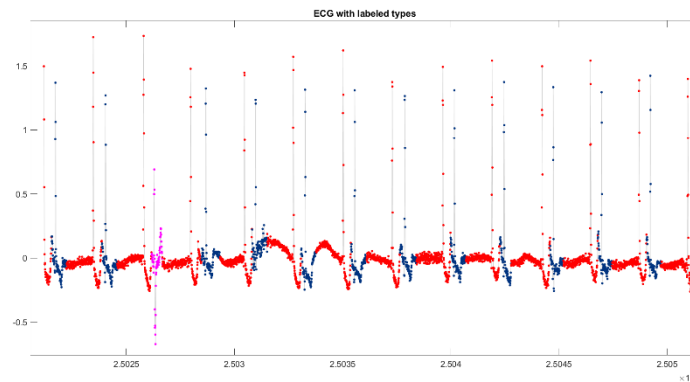


(2) Some points of automated ending T wave are not correct. In order to solving this problem, a manual labeling is required.

- Add correct position(s) by clicking on the ECG plot - Delete incorrect point(s) by clicking on the ECG plot



(3) Label each ECG wave using annotation data from LTAADB and these ending T wave positions.



Red = N, Blue = A, Pink = V

เหมือนกับโครงข่ายแบบวนซ้ำอย่าง LSTM คือสามารถนำมาใช้สร้างโมเดล Sequence-to-sequence และ Sequence-to-one ได้ซึ่งเป็นคุณสมบัติสำคัญสำหรับการทดลองที่จะทำต่อไป

ดังที่ได้กล่าวเกี่ยวกับโครงข่ายคอนโวลูชันตามเวลาไปในหัวข้อ 2.4.3 องค์ประกอบที่สำคัญคือ บล็อกส่วนที่เหลือ ซึ่งโครงข่ายที่ใช้ในการทดลองนี้จะประกอบด้วยหลายบล็อกส่วนที่เหลือมาต่อกันโดยภายในบล็อกจะประกอบด้วยคอนโวลูชันคอสโวลโตเลต (Dilated causal convolution) 2 ชั้น ฟังก์ชันกระตุ้นแบบเรกติไฟต์เชิงเส้น ใช้การนอร์มอลไลซ์เชิงชั้นแบบถ่วงน้ำหนักในส่วนของการทำนอร์มอลไลซ์เชิงชั้นในตัวกรองคอนโวลูชัน นอกจากนี้มีการทำดรอปเอาต์ (Dropout) เพื่อหลีกเลี่ยงการเกิด Over-fitting และสุดท้ายคอนโวลูชันขนาด  $1 \times 1$  เป็นการปรับขนาดของข้อมูลขาเข้าและข้อมูลขาออกให้มีขนาดเท่ากัน หลังจากนั้นค่าในบล็อกจะถูกบวกเข้าด้วยกันถูกส่งผ่านไปยังฟังก์ชันกระตุ้นแบบเรกติไฟต์ ชั้นการเชื่อมโยงเต็มรูปแบบ และสุดท้ายผ่านเข้าฟังก์ชันสูงสุดอย่างอ่อน โครงสร้างของโครงข่ายคอนโวลูชันตามเวลาแสดงดังรูปที่ 30

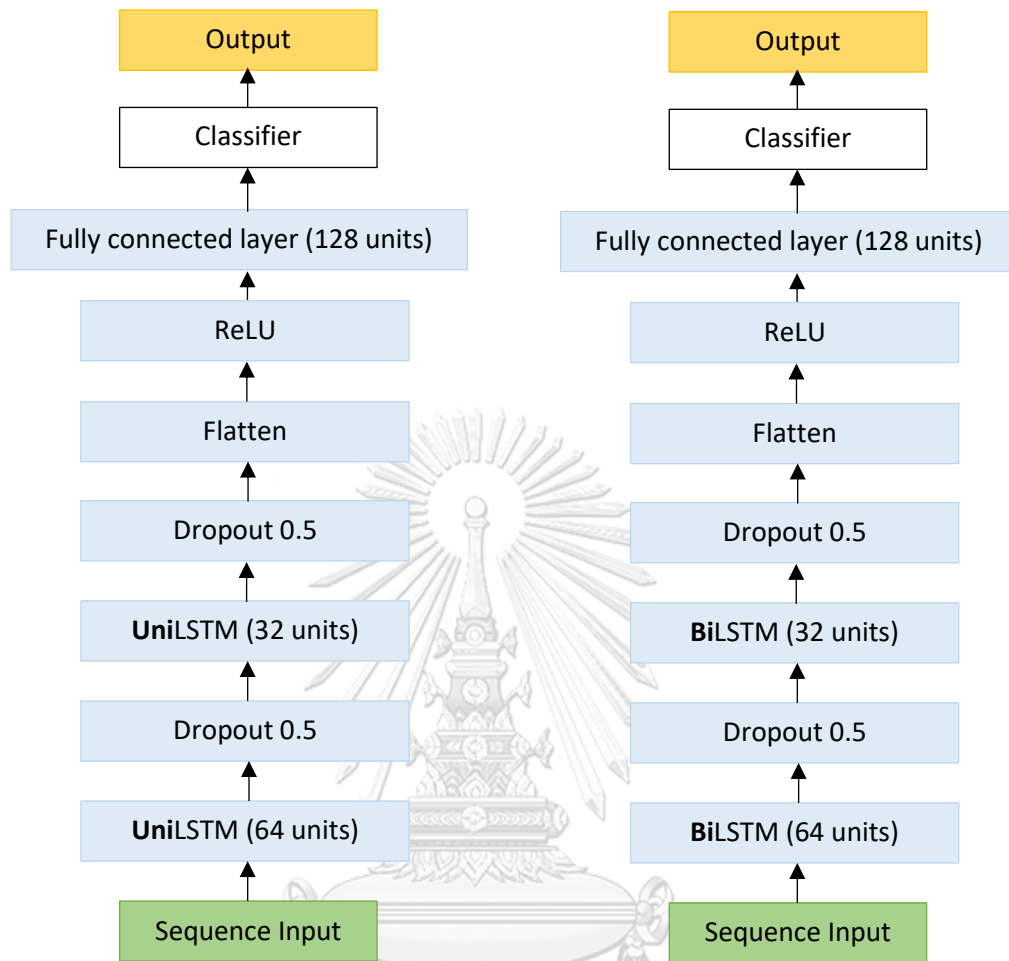
การทดลองจะมีการแปลงเปลี่ยนค่าที่สำคัญทั้งหมด 3 ตัวด้วยกันคือ จำนวนของตัวกรอง (Number of filters) {150,175,200} ขนาดของตัวกรอง (Filter size) {6,9,12,15} และจำนวนบล็อกส่วนที่เหลือ (Number of residual blocks) {6,8,10} สำหรับค่าอัตราการเรียนรู้ และค่าดรอปเอาต์จะอยู่ที่ 0.001 และ 0.05 ตามลำดับ ในขณะที่โมเดลทำการเรียนรู้ถ้าหากค่าของเกรเดียนท์มีขนาดใหญ่เกินไปจะมีการคลิปลดด้วยการใช้เรกกูลาร์ไลเซชันแบบแอลสอง (L2 Regularization) และอัปเดตค่าพารามิเตอร์ต่าง ๆ โดยใช้ Adam optimizer โดย minibatch size เท่ากับ 10 และจำนวนการเทรน (Epoch) เท่ากับ 6 รอบ โดยทุก ๆ รอบของการเทรน ชุดข้อมูลฝึกจะถูกสับเปลี่ยน (Shuffle) ทุกครั้ง โดยรายละเอียดของคุณลักษณะของเครื่องมือกับโปรแกรมที่ใช้สร้างโมเดลและระยะเวลาในการฝึกโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีพารามิเตอร์ของโมเดลที่ต่างกันแสดงไว้ในภาคผนวก ก

### 3.5.2.1 การประยุกต์ใช้โครงข่าย LSTM กับชุดข้อมูลคลื่นไฟฟ้าหัวใจ


จากการทบทวนวรรณกรรมการนำการเรียนรู้เชิงลึกมาคัดแยกสัญญาณคลื่นไฟฟ้าหัวใจเชิงอนุกรมเวลาทำให้ทราบว่า โครงข่ายที่นิยมนำมาใช้คือ LSTM และมักมีการนำเอาโครงข่าย LSTM ใช้ร่วมกับโครงข่ายคอนโวลูชันด้วย ในเบื้องต้นก่อนที่จะทำการสร้างโมเดลด้วยโครงข่ายชนิดอื่น ผู้วิจัยได้นำเอาโครงข่าย LSTM มาเรียนรู้กับข้อมูลที่ถูกรวบรวมไว้ด้วย แต่ขณะโมเดลทำการเรียนรู้ค่าความถูกต้องที่ได้จากการเทรนไม่สูงเข้าสู่จุดสูงสุด โดยค่าความถูกต้องแกว่งอยู่ที่ช่วงร้อยละ 40 ถึง 50 ซึ่งอาจจะต้องทำการลดค่าอัตราการเรียนรู้เริ่มต้นและ minibatch size โดยการลดลงของค่าอัตราการเรียนรู้เริ่มต้นและ minibatch size มีผลทำให้โมเดลสามารถเรียนรู้ได้ดียิ่งขึ้น แต่แลกมาซึ่งเวลาการเรียนรู้ที่ยาวนานขึ้น โดยโครงข่าย LSTM ที่นำมาทดสอบเป็นไปตามรูปที่ 31 ซึ่งปรับมาจาก [39] และค่าความถูกต้องและค่าต้นทุนของการเรียนรู้ของโมเดลแสดงดังในรูปที่ 32







รูปที่ 31 โครงสร้างของ LSTM ทั้ง Uni-direction LSTM (ซ้าย) และ Bi-direction LSTM (ขวา)



รูปที่ 32 ค่าความถูกต้องและค่าต้นทุนของโมเดลแบบ Uni-direction LSTM (ซ้าย) และ Bi-direction LSTM (ขวา)

จากการเรียนรู้สัญญาณคลื่นไฟฟ้าหัวใจ

### 3.5.2.2 การหาโมเดลที่เหมาะสมกับชุดข้อมูลคลื่นไฟฟ้าหัวใจ

ในขั้นแรกได้นำเอาตัวแปรต่าง ๆ คือ จำนวนของตัวกรอง ขนาดของตัวกรอง และจำนวนบล็อก ส่วนที่เหลือมาทำการทดลองเปลี่ยนเป็นค่าต่าง ๆ กันตามที่กล่าวไว้แล้วข้างต้น โดยนำตัวแปรเหล่านี้มาทำการเรียนรู้กับข้อมูลที่มีความใกล้เคียงกันมากที่สุดก่อน เนื่องจากรูปร่างและอัตราการเต้นของภาวะหัวใจห้องบนเต้นก่อนจังหวะค่อนข้างมีความคล้ายคลึงกับภาวะหัวใจห้องบนสั่นพลิ้ว สมมติฐานคือ ถ้าโมเดลและตัวแปรสามารถทำงานได้ดีกับข้อมูลชุดนี้ การใช้โมเดลพร้อมด้วยค่าตัวแปรที่ได้กับข้อมูลอื่นย่อมได้ผลที่ดีเช่นกัน ซึ่งข้อมูลประกอบด้วยภาวะต่าง ๆ ดังนี้ ภาวะหัวใจห้องบนสั่นพลิ้ว ภาวะหัวใจเต้นปกติ และภาวะหัวใจห้องบนเต้นก่อนจังหวะ โดยภาวะของหัวใจ 2 ชนิดหลังจะถูกจัดกลุ่มเป็นกลุ่มเดียวกันคือ กลุ่มของสัญญาณคลื่นไฟฟ้าหัวใจที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้ว โดยจำนวนข้อมูลที่ใช้ในการเรียนรู้แสดงในตารางที่ 8 หลังจากที่ได้โมเดลกับค่าตัวแปรที่เหมาะสมแล้ว โมเดลที่ได้จะถูกนำไปเรียนรู้กับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะเพิ่มเติม โดยนำเอาสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องล่างเต้นก่อนจังหวะมารวมอยู่ในชุดข้อมูลเรียนรู้ด้วยดังแสดงในตารางที่ 9

ตารางที่ 8 จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจเพื่อทดสอบหาค่าที่ดีที่สุดของตัวแปร

Classes	ECG Types	Training set		Testing set	
		30-second ECG segments		30-second ECG segments	
Non-AF	NSR	300		100	
	PAC	300		100	
AF	AF	600		200	
Summation		1200		400	

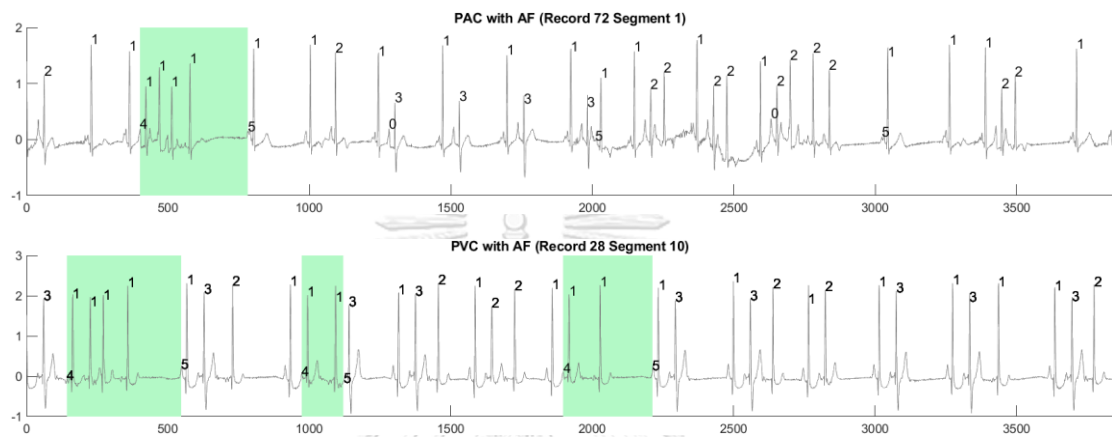
ตารางที่ 9 จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจเพิ่มเติมสำหรับโมเดลที่มีค่าตัวแปรที่เหมาะสม

Classes	ECG Types	Training set		Testing set	
		30-second ECG segments		30-second ECG segments	
Non-AF	NSR	300		100	
	PAC	300		100	
	PVC	300		100	
AF	AF	900		300	
Summation		1800		600	

### 3.5.2.3 การปรับปรุงประสิทธิภาพของโมเดลโดยการหาข้อมูลที่ผิดปกติ

การทดลองที่แล้วทำให้ถึงทราบโมเดลที่มีความเหมาะสมกับข้อมูลคลื่นไฟฟ้าหัวใจที่ได้จัดเตรียมไว้ แต่ประสิทธิภาพของโมเดลนั้นยังคงไม่ถูกปรับปรุงให้ดีขึ้นเท่าที่ควร โดยเฉพาะค่าความจำเพาะของโมเดล ซึ่งเป็นจุดประสงค์หลักของงานวิจัยนี้ที่ต้องการปรับปรุงค่าความจำเพาะให้ดีขึ้น ดังนั้นจึงได้มีการเข้าไปตรวจสอบข้อมูล

คลื่นไฟฟ้าหัวใจที่ถูกทลายผิด พบว่ามีบางข้อมูลที่เป็นภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะที่ยังถูกเจือปนด้วยสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนสั้นพลิ้ว โดยส่วนมากเป็นภาวะหัวใจห้องบนสั้นพลิ้วแบบครั้งคราวหรือ Paroxysmal Atrial Fibrillation ซึ่งไม่ได้ถูกรองออกในขั้นตอนการเตรียมข้อมูล ตัวอย่างของสัญญาณที่ถูกเจือปนแสดงดังรูปที่ 33 โดยแถบสีเขียวแสดงภาวะหัวใจห้องบนสั้นพลิ้วแบบครั้งคราว และหมายเลข 1 = N, 2 = A, 3 = V, 4 = (AF, 5 = (NSR และ 0 = ภาวะหัวใจชนิดอื่น ๆ



รูปที่ 33 สัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะ (บน) และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ (ล่าง) ที่ถูกเจือปนด้วยภาวะหัวใจห้องบนสั้นพลิ้วแบบครั้งคราว

นอกจากนี้ยังพบว่าข้อมูลที่ไม่เดลมักทลายผิดนั้นมาจากชุดการบันทึกสัญญาณคลื่นไฟฟ้าหัวใจเดียวกันซึ่งข้อมูลเหล่านี้เป็นข้อมูลที่ไม่เดลไม่ได้ผ่านการเรียนรู้มาก่อน อันเนื่องมาจากชุดข้อมูลเรียนรู้ที่ใช้งานอยู่ไม่ได้ครอบคลุมถึงข้อมูลคลื่นไฟฟ้าหัวใจในลักษณะนี้ ทำให้โมเดลไม่สามารถทำนายได้อย่างถูกต้อง ดังนั้นข้อมูลที่ถูกทลายผิดเหล่านี้จึงมีความสำคัญสำหรับการเรียนรู้ของโมเดล เพื่อให้โมเดลได้เรียนรู้ข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจที่มีความหลากหลายและครอบคลุมยิ่งขึ้น โดยชุดการบันทึกที่เป็น outlier แสดงดังในตารางที่ 10 หลังจากโมเดลได้เรียนรู้และถูกทดสอบแล้ว โมเดลที่ให้ผลทดสอบดีที่สุดจะถูกนำมาใช้ในการทดลองถัดไป

ตารางที่ 10 ชุดการบันทึกสัญญาณคลื่นไฟฟ้าหัวใจที่ไม่เดลมักทำนายผิด

Classes	ECG Types	Record Number
Non-AF	NSR	111, 119, 115
	PAC	01, 104, 115, 116
	PVC	-

### 3.6 การประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

การทดลองที่ผ่านมาได้นำเอาสัญญาณคลื่นไฟฟ้าหัวใจมาแบ่งเป็น 2 กลุ่มคือ กลุ่มของสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนสั้น และกลุ่มของสัญญาณคลื่นไฟฟ้าหัวใจที่ไม่ใช่ภาวะหัวใจห้องบนสั้น ในการทดลองนี้จะนำเอาสัญญาณกลุ่มที่ 2 มาแยกเป็นภาวะของหัวใจ 3 ชนิดด้วยกันคือ ภาวะหัวใจเต้นปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ โดยนำโครงข่ายคอนโวลูชันตามเวลามาแยกแยะสัญญาณคลื่นไฟฟ้าหัวใจทั้ง 3 ชนิดออกจากกัน ซึ่งตัวแปรของโมเดลที่ใช้คือ โมเดลที่ให้ผลดีที่สุดจากการทดลองที่แล้ว โดยข้อมูลก็นำมาใช้เทรนเป็นข้อมูลชุดเดียวกันกับการทดลองก่อนหน้า ซึ่งจำนวนของข้อมูลถูกแสดงไว้ในตารางที่ 11

ตารางที่ 11 จำนวนข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจของกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั้นพลั่ว

Classes	ECG Types	Training set	Testing set
		30-second ECG segments	30-second ECG segments
Non-AF	NSR	300	100
	PAC	300	100
	PVC	300	100
Summation		900	300

## บท 4

### ผลการดำเนินงานและอภิปรายผล

#### 4.1 ผลของการใช้โครงข่ายถ่ายโอนเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพสัญญาณคลื่นไฟฟ้าหัวใจ

##### 4.1.1 ผลการใช้การเรียนรู้ถ่ายโอนแบบโครงข่ายคอนโวลูชันเพื่อเรียนรู้ภาพสัญญาณคลื่นไฟฟ้าหัวใจ

ข้อมูลภาพที่ได้จากการเตรียมข้อมูลจากสัญญาณคลื่นไฟฟ้าหัวใจของฐานข้อมูล PhysioNet/CinC challenge 2017 โดยเป็นการบันทึกสัญญาณ 1 ช่องสัญญาณ ชุดข้อมูลฝึกและชุดข้อมูลทดสอบจะแบ่งเป็นข้อมูลภาพของภาวะหัวใจเต้นปกติและภาวะหัวใจห้องบนสั่นพลิ้ว โดยชุดข้อมูลฝึกใช้ข้อมูลภาพ 200 ภาพทั้งในสองภาวะดังกล่าว และชุดข้อมูลทดสอบใช้ข้อมูลภาพ 100 ภาพทั้งในสองภาวะเช่นกัน

ผลการทดสอบโมเดลเป็นดังแสดงในตารางที่ 12 โดยพบว่าโมเดลที่ดีที่สุดคือ โมเดลที่ได้จากการเรียนรู้ชุดข้อมูลที่ ① คือข้อมูลที่ทำการกำหนดความยาวสัญญาณคลื่นไฟฟ้าหัวใจเป็นเวลา 3 วินาทีโดยมีค่าความไวและค่าความจำเพาะเท่ากับร้อยละ 98 และ 100 ตามลำดับ โมเดลที่ตรงลงมาคือ โมเดลที่ได้รับการเรียนรู้จากชุดข้อมูลที่ ②, ③ และ ④ ตามลำดับ จากนั้นได้ทำการทดสอบโมเดลที่ได้การกำหนดเวลาของคลื่นไฟฟ้าหัวใจโดยกำหนดเวลาออกเป็น 1, 2, 4, 5 วินาทีตามลำดับเพื่อนำมาเปรียบเทียบกับ 3 วินาทีและหาโมเดลที่ดีที่สุดในการแยกแยะสัญญาณคลื่นไฟฟ้าหัวใจ โดยได้ผลการทดสอบเป็นดังแสดงในตารางที่ 13 ซึ่งพบว่าโมเดลที่ใช้สัญญาณคลื่นไฟฟ้าหัวใจ 3 วินาทียังคงเป็นโมเดลที่ได้ประสิทธิภาพในการจำแนกสูงที่สุด

จากผลการทดลองทั้งหมดจะเห็นว่า โมเดลที่ให้ผลดีที่สุดคือ โมเดลเรียนรู้ข้อมูลภาพจากชุดที่กำหนดเวลาสัญญาณคลื่นไฟฟ้าหัวใจ 3 วินาที สาเหตุที่ทำให้โมเดลนี้เป็นโมเดลที่ดีที่สุดนั้นอาจเนื่องจากว่าในเวลา 3 วินาทีรูปสัญญาณที่ได้โดยเฉลี่ยจะมีลักษณะของคลื่นไฟฟ้าหัวใจที่มีความชัดเจนและแสดงถึงรูปแบบของสัญญาณได้เหมาะสมที่สุด โดยที่ความยาว 1 และ 2 วินาทีนั้นองค์ประกอบของข้อมูลในภาพอาจมีน้อยเกินไป ซึ่งเมื่อทำการคอนโวลูชันข้อมูลในชั้นคอนโวลูชันแล้ว ลักษณะสำคัญที่ได้อาจไม่เพียงพอต่อการนำไปจำแนกสัญญาณคลื่นไฟฟ้าหัวใจทั้งสองสภาวะออกจากกันได้ ขณะเดียวกัน สัญญาณคลื่นไฟฟ้าหัวใจที่ความยาว 4 - 5 วินาที จะมีลักษณะที่ตรงข้ามกัน เนื่องจากรูปร่างของสัญญาณที่เวลาดังกล่าวมีการบีบอัดเข้าหากันมากขึ้นโดยเฉพาะในแกนเวลา ซึ่งอาจเกิดความซับซ้อนของข้อมูลมากเกินไปและทำให้มองเห็นรูปแบบของสัญญาณคลื่นไฟฟ้าหัวใจได้ค่อนข้างยากจึงทำให้ค่าทดสอบที่ได้ต่ำกว่าคลื่นไฟฟ้าหัวใจ 3 วินาที

นอกจากนี้จากผลการทดสอบทั้งหมดจะเห็นว่า การแปลงสัญญาณคลื่นไฟฟ้าหัวใจให้อยู่ในรูปแบบองค์ประกอบความถี่นั้นได้ค่าความไว และค่าความจำเพาะที่มีค่าน้อยที่สุด ทั้งนี้เนื่องจากการเตรียมข้อมูลภาพด้วยวิธีการดังกล่าวอาจยังไปเพิ่มความซับซ้อนให้กับการคัดแยกคุณลักษณะของโมเดล อีกทั้งสัญญาณคลื่นไฟฟ้าหัวใจที่

ใช้ในการเรียนรู้ของโมเดลไม่ได้ผ่านการกรองสัญญาณรบกวนออกไป อาจจะทำให้สัญญาณรบกวนมีผลมากเมื่อพิจารณาในองค์ประกอบความถี่

ตารางที่ 12 ผลการทดลองโมเดลแต่ละชุดข้อมูล

Model	Sensitivity	Specificity
①	98%	100%
②	86%	94%
③	88%	90%
④	62%	78%

ตารางที่ 13 ผลการทดลองโมเดลของชุดข้อมูลที่ใช้ช่วงความยาว 1- 5 วินาที

Model	Sensitivity	Specificity
1 วินาที	76%	88%
2 วินาที	80%	94%
3 วินาที	98%	100%
4 วินาที	94%	92%
5 วินาที	88%	94%

#### 4.1.2 ผลการทดสอบผลต่อการเกิดไบแอสของอัตราการเต้นของหัวใจมีผลที่มีต่อค่าความไวและค่าความจำเพาะของโมเดลจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยภาพ

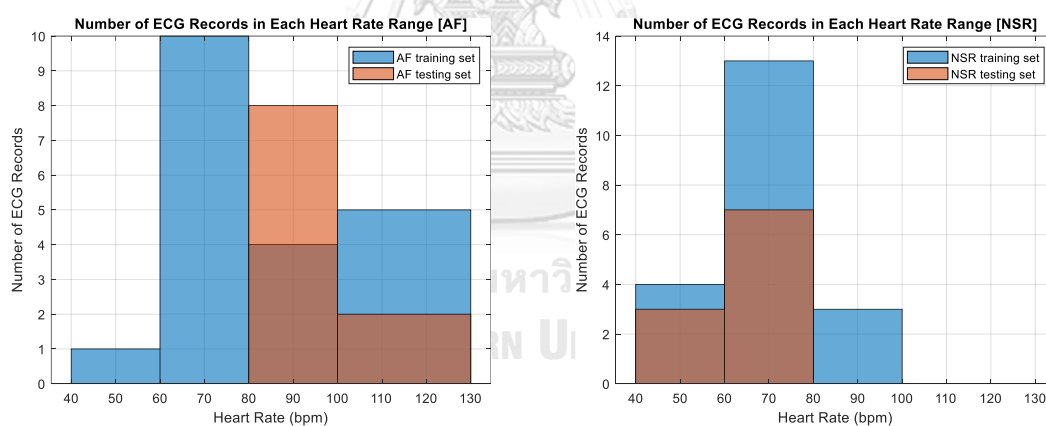
การทดลองเพิ่มจำนวนข้อมูลและการกระจายข้อมูลของแต่ละช่วงอัตราการเต้นของหัวใจให้พอกันนั้นถูกนำไปเป็นชุดข้อมูลฝึกและชุดทดสอบสำหรับการสร้างโมเดลที่กำหนดเวลาสัญญาณคลื่นไฟฟ้าหัวใจ 3 วินาที โดยโมเดลนี้เป็นโครงข่ายที่ถูกถ่ายทอดมาจากโครงข่ายชื่อดังอย่าง AlexNet ในการฝึกข้อมูลได้มีการปรับรอบการฝึก (Epoch) ของโครงข่ายลงจาก 12 เป็น 6 รอบ เพื่อลดการที่โมเดลมีความจำเพาะเจาะจงกับชุดข้อมูลฝึกมากเกินไป (Overfitting)

ผลการประเมินประสิทธิภาพของโมเดลที่ถูกเทรนด้วยชุดข้อมูลใหม่ที่แสดงในตารางที่ 14 จะเห็นว่าค่าความไวและค่าความจำเพาะที่ได้จากชุดทดสอบนั้นมีค่าน้อยลงเมื่อเทียบกับการทดลองแรก โดยได้ค่าความไวและค่าความจำเพาะเท่ากับร้อยละ 84.67 และ 96.33 ดังนั้นจึงสรุปได้ว่าโมเดลจากการทดลองแรกเกิดการไบแอสเกิดขึ้นจากการใช้จำนวนข้อมูลที่น้อยเกินไปในการเรียนรู้และการทดสอบโมเดล ซึ่งถ้าพิจารณาช่วงของอัตราการเต้นของ

หัวใจในแต่ละชุดข้อมูลของการทดลองที่แล้วจะเห็นว่า จากกราฟการกระจายของข้อมูลในแต่ละช่วงอัตราการเต้นของหัวใจที่แสดงในรูปที่ 34 ในภาวะหัวใจห้องบนสั่นพลิ้วและภาวะหัวใจเต้นปกติมีจำนวนของชุดข้อมูลฝึกและชุดข้อมูลทดสอบในช่วงอัตราการเต้นของหัวใจที่ใกล้เคียงกัน หมายความว่าโมเดลได้ถูกเทรนด้วยช่วงอัตราการเต้นของหัวใจนั้น ๆ มากอยู่แล้ว และข้อมูลที่น่ามาทดสอบก็ยังเป็นข้อมูลที่อยู่ในช่วงนั้น ๆ อีก ดังนั้นจึงเกิดไบแอสขึ้นกับโมเดล เพราะโมเดลสามารถแยกแยะออกได้ง่ายเมื่อทดสอบกับข้อมูลชุดนี้ จากการทดลองแบ่งข้อมูลให้พอ ๆ กันในแต่ละช่วงของอัตราการเต้นของหัวใจยังสามารถบอกได้ว่า อัตราการเต้นของหัวใจอาจจะส่งผลต่อการจับคุณลักษณะสำคัญบางอย่างของโมเดลด้วย

**ตารางที่ 14** ผลประสิทธิภาพของโมเดลที่ถูกทดสอบเรียนรู้และทดสอบด้วยข้อมูลที่แบ่งช่วงของอัตราการเต้นของหัวใจ

Performance classification of transferred AlexNet		
Dataset	Sensitivity	Specificity
Training data	99.83%	99.67%
Testing data	84.67%	96.33%



**รูปที่ 34** กราฟการกระจายข้อมูลของชุดข้อมูลฝึกและชุดทดสอบของการทดลองแรก: ชุดข้อมูลของภาวะหัวใจห้องบนสั่นพลิ้ว (ซ้าย) และชุดข้อมูลของภาวะหัวใจเต้นปกติ (ขวา) โดยสีฟ้าและแดงแทนจำนวนของชุดฝึกและชุดทดสอบ ตามลำดับ

#### 4.1.3 ผลการจำแนกภาวะหัวใจห้องบนสั่นพลิ้วที่ได้จากการเรียนรู้เชิงลึกร่วมกับอัลกอริทึมซัพซอนน้อยสำหรับไมโครคอนโทรลเลอร์

ในช่วงการเรียนรู้ (Training phase) ค่าขีดเริ่มต้น (Threshold value) ที่ถูกเลือกจากการสังเกตคือ -13.4 ผลที่ได้จากอัลกอริทึมที่มีความซับซ้อนน้อยนั้นคือ ร้อยละ 96.96 และ 75 สำหรับค่าความไวและค่า



ความจำเพาะ ดังแสดงในตารางที่ 15 และเมื่อเปรียบเทียบประสิทธิภาพของทั้งสองอัลกอริทึมจากชุดข้อมูลทดสอบเดียวกันจะได้ว่า สำหรับอัลกอริทึมซับซ้อนน้อยได้ค่าความไวและค่าความจำเพาะอยู่ที่ร้อยละ 100 และ 86.67 ตามลำดับ ส่วนและอัลกอริทึมที่ใช้การเรียนรู้เชิงลึกได้ค่าความไวและค่าความจำเพาะอยู่ที่ร้อยละ 96.67 และ 100 ตามลำดับ จากตารางที่ 16 จะเห็นได้ว่าค่าความไวสูงสุดร้อยละ 100 ได้จากอัลกอริทึมที่มีความซับซ้อนน้อย และค่าความจำเพาะสูงสุดร้อยละ 100 ได้จากการประยุกต์ใช้การเรียนรู้เชิงลึก จากผลที่ได้ทำให้เห็นว่าการนำการเรียนรู้เชิงลึกบนฐานของโครงข่ายคอนโวลูชันสามารถช่วยเพิ่มค่าความจำเพาะขึ้นได้

**ตารางที่ 15** ผลลัพธ์ของอัลกอริทึมที่มีความซับซ้อนน้อยจากชุดข้อมูลฝึก

<i>Performance classification of the low complexity algorithm</i>			
Dataset	Sensitivity	Specificity	Threshold value
Training data	96.96%	75%	-13.4

**ตารางที่ 16** การเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึมที่มีความซับซ้อนน้อยและอัลกอริทึมที่ใช้การเรียนรู้เชิงลึกจากการใช้ข้อมูลทดสอบชุดเดียวกัน

<i>Performance classification of the two algorithms</i>		
Algorithm	Sensitivity	Specificity
Low complexity algorithm	100%	86.67%
Transferred AlexNet	96.97%	100%

## 4.2 ผลของการใช้โครงข่ายคอนโวลูชันตามเวลาเพื่อจำแนกภาวะหัวใจห้องบนสั่นพลิ้วด้วยสัญญาณคลื่นไฟฟ้าหัวใจในอนุกรมเวลา

### 4.2.1 ผลของการหาโมเดลที่เหมาะสมกับชุดข้อมูลคลื่นไฟฟ้าหัวใจ

ผลการทดลองเพื่อหาโมเดลที่เหมาะสมนั้นแสดงในตารางที่ 17 ซึ่งมีด้วยกัน 3 โมเดลดังนี้ โมเดล [12 175 8] โมเดล [15 175 10] และโมเดล [18 175 10] โดยค่าใน [ ] ของแต่ละโมเดลคือ จำนวนของตัวกรอง ขนาดของตัวกรอง และจำนวนบล็อกส่วนที่เหลือ ตามลำดับ การเลือกโมเดลนั้นเลือกจากโมเดลที่ให้ค่าความจำเพาะที่อยู่ในเกณฑ์ดี ซึ่งโมเดล [12 175 8] ให้ค่าความไวและค่าความจำเพาะเท่ากับร้อยละ 99.50 และ 94.50 ตามลำดับ ค่าความจำเพาะที่ได้จากโมเดล [12 175 8] จะน้อยกว่าเมื่อเทียบกับอีก 2 โมเดล แต่ให้ค่าความไวที่ดีที่สุด ในส่วนค่าความไวและความจำเพาะของโมเดล [15 175 10] อยู่ที่ร้อยละ 86.50 และ 96.00 และโมเดลสุดท้าย โมเดล [18 175 10] เป็นโมเดลที่ให้ค่าความไวที่น้อยที่สุด แต่ให้ค่าความจำเพาะมากที่สุด โดยอยู่ที่ร้อยละ 77.00 และ 98.50 ตามลำดับ นอกจากนี้ได้มีการเปรียบเทียบประสิทธิภาพของโมเดลที่ถูกเลือกเป็นคู่ ๆ ด้วยวิธี Paired T Test โดยเปรียบเทียบกับโมเดลที่มีค่าจำนวนของตัวกรองกับจำนวนบล็อกส่วนที่เหลือเหมือนกัน เพื่อตรวจสอบว่าโมเดลที่ถูกเลือกดีกว่าแบบจำลองอื่นอย่างมีนัยสำคัญหรือไม่ โดยค่า T value และ P value ที่ได้ถูกแสดงในภาคผนวก ข

ตารางที่ 17 ผลประสิทธิภาพของโมเดลที่ถูกทดสอบด้วยชุดข้อมูลกลุ่มไฟฟ้าหัวใจภาวะหัวใจห้องบนสั่นพลิ้วและกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้ว

Model	Filter size	Number of residual blocks	Number of filters = 150		Number of filters = 175		Number of filters = 200	
			Sensitivity (%)	Specificity (%)	Sensitivity (%)	Specificity (%)	Sensitivity (%)	Specificity (%)
1	9	6	100.00 (Missed AF = 0)	84.50 (Missed NSR and PAC = 2, 29)	100.00 (Missed AF = 0)	82.00 (Missed NSR and PAC = 8, 28)	96.50 (Missed AF = 7)	81.50 (Missed NSR and PAC = 13, 24)
	12		100.00 (Missed AF = 0)	71.50 (Missed NSR and PAC = 24, 33)	99.50 (Missed AF = 1)	87.50 (Missed NSR and PAC = 3, 22)	99.50 (Missed AF = 1)	92.00 (Missed NSR and PAC = 6, 10)
15	95.50 (Missed AF = 9)		70.00 (Missed NSR and PAC = 0, 60)	100.00 (Missed AF = 0)	92.00 (Missed NSR and PAC = 3, 13)	94.00 (Missed AF = 12)	87.00 (Missed NSR and PAC = 6, 26)	
18	99.50 (Missed AF = 1)		76.50 (Missed NSR and PAC = 19, 28)	99.50 (Missed AF = 1)	87.00 (Missed NSR and PAC = 7, 19)	97.50 (Missed AF = 5)	92.00 (Missed NSR and PAC = 2, 14)	
9	100.00 (Missed AF = 0)		74.00 (Missed NSR and PAC = 17, 35)	99.00 (Missed AF = 2)	93.50 (Missed NSR and PAC = 2, 11)	100.00 (Missed AF = 0)	86.00 (Missed NSR and PAC = 5, 23)	
12	100.00 (Missed AF = 0)		69.50 (Missed NSR and PAC = 27, 34)	99.50 (Missed AF = 1)	94.50 (Missed NSR and PAC = 2, 9)	99.50 (Missed AF = 1)	90.50 (Missed NSR and PAC = 5, 14)	
8	15	8	99.50 (Missed AF = 1)	82.00 (Missed NSR and PAC = 8, 26)	98.50 (Missed AF = 3)	93.50 (Missed NSR and PAC = 2, 11)	100.00 (Missed AF = 0)	86.50 (Missed NSR and PAC = 7, 20)
	18		100.00 (Missed AF = 0)	89.00 (Missed NSR and PAC = 4, 18)	94.00 (Missed AF = 12)	90.50 (Missed NSR and PAC = 4, 15)	98.50 (Missed AF = 3)	93.50 (Missed NSR and PAC = 2, 11)
9	100.00 (Missed AF = 0)		90.50 (Missed NSR and PAC = 4, 15)	83.00 (Missed AF = 34)	93.50 (Missed NSR and PAC = 3, 10)	98.50 (Missed AF = 3)	93.00 (Missed NSR and PAC = 2, 12)	
12	100.00 (Missed AF = 0)		92.50 (Missed NSR and PAC = 2, 13)	98.50 (Missed AF = 3)	92.50 (Missed NSR and PAC = 2, 13)	99.50 (Missed AF = 1)	87.50 (Missed NSR and PAC = 4, 21)	
15	100.00 (Missed AF = 0)		88.00 (Missed NSR and PAC = 4, 20)	86.50 (Missed AF = 27)	96.00 (Missed NSR and PAC = 2, 6)	99.50 (Missed AF = 1)	88.00 (Missed NSR and PAC = 8, 16)	
18	99.50 (Missed AF = 1)		90.00 (Missed NSR and PAC = 2, 18)	77.00 (Missed AF = 46)	98.50 (Missed NSR and PAC = 0, 3)	99.50 (Missed AF = 1)	91.00 (Missed NSR and PAC = 3, 15)	

การทดลองเพื่อหาโมเดลที่เหมาะสมกับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจได้กำหนดตัวแปรที่สำคัญคือ จำนวนของตัวกรอง ขนาดของตัวกรอง และจำนวนบล็อกส่วนที่เหลือ จากการผลการทดลองโมเดลที่ได้มานั้นมี ขนาดของตัวกรองและจำนวนของบล็อกส่วนที่เหลือต่างกัน แต่มีจำนวนของตัวกรองเท่ากัน อย่างไรก็ตามตัวกรอง เป็นลักษณะเด่นที่สำคัญของโครงข่ายคอนโวลูชัน ซึ่งโครงข่ายนี้จะใช้ตัวกรองในการสกัดลักษณะสำคัญของข้อมูล ออกมา ดังนั้นการเพิ่มจำนวนตัวกรองให้มากขึ้น ทำให้โมเดลได้คุณลักษณะสำคัญของข้อมูลในลักษณะที่ต่างกันมาก ขึ้น และมีผลทำให้โมเดลมีประสิทธิภาพการทำงานที่ดีขึ้น [28] จากจำนวนของตัวกรองที่ได้จากการทดลองนั้นมี จำนวนไม่สูงมาก ซึ่งเป็นไปได้การใช้จำนวนตัวกรองที่มากเกินไปจนทำให้เกิด Over-fitting กับข้อมูลชุดฝึก แต่ ถ้าน้อยเกินไปคุณลักษณะสำคัญที่ได้จากข้อมูลก็น้อยตามลงไปด้วย

โครงข่ายคอนโวลูชันตามเวลานั้นมีข้อดีอย่างหนึ่งคือ สามารถปรับเปลี่ยนค่าลานการรับรู้ของโครงข่ายได้ ง่ายและยืดหยุ่น ซึ่งการเพิ่มขนาดของตัวกรองและจำนวนบล็อกส่วนที่เหลือทำให้ค่าของลานการรับรู้มีมากขึ้น ความสัมพันธ์เป็นไปตามสมการที่ 33 กำหนดให้  $R$  คือขนาดลานการรับรู้  $f$  คือขนาดของตัวกรอง และ  $k$  คือ จำนวนบล็อกส่วนที่เหลือ นอกจากนี้การเพิ่มจำนวนบล็อกส่วนที่เหลือมีผลทำให้โครงข่ายคอนโวลูชันตามเวลา มีความลึกในการเรียนรู้มากขึ้นด้วย

$$R = (f - 1)(2^k - 1) + 1 \quad (33)$$

อย่างไรก็ตามการเพิ่มค่าตัวแปรทุก ๆ ตัวให้มากขึ้นไม่ได้ให้ผลดีกับโมเดลเสมอไปซึ่งขึ้นอยู่กับลักษณะ ของข้อมูลชุดเรียนรู้ด้วย หมายความว่าเมื่อข้อมูลเข้ามีโดเมนที่แตกต่างกันย่อมมีความต้องการที่ต่างกันออกไป ด้วย ซึ่งในการเรียนรู้ข้อมูลเชิงอนุกรมเวลา โมเดลจะทำการเก็บประวัติของข้อมูลที่ได้จากการเรียนรู้เพื่อเอาไปใช้ ทำนายข้อมูลที่เข้ามาใหม่ ซึ่งชุดข้อมูลบางประเภทอาจจะต้องการขนาดของหน่วยความจำของข้อมูลที่ต่างกัน ถ้า โดเมนของข้อมูลนั้นต้องการหน่วยความจำสั้น ๆ (Short history length) แสดงว่าโมเดลต้องมีค่าของตัวกรองและ จำนวนบล็อกส่วนที่เหลือต่ำ โครงข่ายคอนโวลูชันตามเวลาอาจจะทำงานได้แย่งถ้าขนาดของลานการรับรู้เป็นค่าที่ ไม่เหมาะสม

เมื่อได้โมเดลที่เหมาะสมแล้วนำมาเอาไปเรียนรู้และทดสอบกับข้อมูลเรียนรู้ชุดใหม่ โดยเพิ่มภาวะหัวใจห้อง ล่างเต้นก่อนจังหวะเข้าไปในกลุ่มของสัญญาณคลื่นไฟฟ้าหัวใจที่ไม่ใช่ภาวะหัวใจห้องบนสั้นพลั่ว ได้ผลตามตารางที่ 18 โดยเมื่อเพิ่มจำนวนข้อมูลเข้าไปค่าความจำเพาะของโมเดล [12 175 8] มีค่าเพิ่มขึ้นเล็กน้อยและค่าความไวลดลง ในส่วนของโมเดล [15 175 10] และโมเดล [18 175 10] มีค่าความจำเพาะลดลงแต่ค่าความไวเพิ่มขึ้นมาก

#### 4.2.2 ผลของการปรับปรุงประสิทธิภาพของโมเดลโดยการหาข้อมูลที่ดีปกติ

จากผลการทดลองที่แสดงในตารางที่ 18 แสดงให้เห็นว่าค่าความจำเพาะไม่ได้ถูกทำให้ดีขึ้น แม้ว่าจะมี จำนวนของข้อมูลเพิ่มมากขึ้น เมื่อทำการตรวจสอบข้อมูลที่นำมาเรียนรู้พบว่ามีการปนของภาวะหัวใจห้องบนสั้นพลั่ว ในข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ผลการ ทดลองนำข้อมูลที่ถูกปนเปื้อนออกแสดงดังในตารางที่ 19 โดยตามที่ได้กล่าวไปแล้วว่าข้อมูลสัญญาณ คลื่นไฟฟ้า

หัวใจที่นำมาใช้มีความยาว 30 วินาทีซึ่งมีความเป็นไปได้ที่จะมีภาวะหัวใจห้องบนสั่นพลิ้วแบบครั้งคราวเข้ามาปนอยู่ โดยภาวะที่มีความเป็นไปได้ว่าจะมีการปนเปื้อนมากที่สุดคือภาวะหัวใจห้องล่างเต้นก่อนจังหวะ เพราะหัวใจห้องบนสูญเสียหน้าที่การทำงานไปเมื่อเกิดการสั่นพลิ้ว แต่หัวใจห้องล่างยังคงทำงานได้อย่างปกติ ผลจากการนำข้อมูลที่มีการปนเปื้อนด้วยภาวะหัวใจห้องบนสั่นพลิ้วออกคือ ทุก ๆ โมเดลได้ค่าความไวที่สูงขึ้น ส่วนโมเดล [12 175 8] และ [18 175 10] มีค่าความจำเพาะลดลง แต่โมเดล [15 175 10] มีค่าความจำเพาะสูงขึ้น โดยค่าความจำไวและความจำเพาะที่ได้จากโมเดล [15 175 10] มีค่าเท่ากับร้อยละ 98.00 และ 97.33 ตามลำดับ

แม้ว่าจะมีการกรองข้อมูลที่ถูกปนเปื้อนไป แต่ค่าความจำเพาะที่ได้ก็ยังคงไม่สูงมากนักซึ่งการทดลองต่อมาได้ทำการสังเกตข้อมูลที่โมเดลมักทายผิดและได้พบว่าข้อมูลเหล่านั้นมาจากชุดการบันทึกเดียวกันและได้นำเอาข้อมูลเหล่านั้นเข้าไปเป็นชุดข้อมูลสำหรับเรียนรู้แทน และทำการทดสอบโมเดลใหม่ ผลประสิทธิภาพของโมเดลเป็นไปตามแสดงในตารางที่ 20 ผลที่ได้คือค่าความจำเพาะของทุกโมเดลถูกปรับให้ดีขึ้นโดยได้ค่าความจำเพาะสูงสุดอยู่ที่ร้อยละ 99.33 จากโมเดล [12 175 8] และ [15 175 10] ซึ่งโมเดลที่ให้ผลทำนายที่ดีที่สุดทั้งค่าความไวและค่าความจำคือโมเดล [12 175 8] โดยมีค่าความไวและค่าความจำเพาะอยู่ที่ 98.33 และ 99.33 ตามลำดับ เนื่องจากข้อมูลที่ใช้ในการเรียนรู้นั้นมีอยู่อย่างจำกัด ซึ่งการวิเคราะห์ข้อมูลที่ถูกทายผิดจากการทำงานของโมเดลช่วยปรับปรุงให้โมเดลนั้นได้เห็นข้อมูลที่ยากและหลากหลายมากยิ่งขึ้น ส่งผลทำให้โมเดลมีความครอบคลุม (Generalization) และมีประสิทธิภาพในการทำนายผลดีขึ้น

**ตารางที่ 18** ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้ทดสอบด้วยชุดข้อมูลที่มีการเพิ่มภาวะหัวใจห้องล่างเต้นก่อนจังหวะเข้าไปในกลุ่มที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้ว

<i>Model</i>	<i>Filters</i>	<i>Filter size</i>	<i>Residual blocks</i>	<i>Sensitivity (%)</i>	<i>Specificity (%)</i>
1	175	12	8	96.67 (Missed AF = 10)	94.67 (Missed NSR, PAC and PVC = 13, 3, 0)
2		15	10	98.00 (Missed AF = 6)	91.67 (Missed NSR, PAC and PVC = 10, 15, 0)
3		18	10	97.33 (Missed AF = 8)	94.33 (Missed NSR, PAC and PVC = 3, 12, 3)

ตารางที่ 19 ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้และทดสอบด้วยชุดข้อมูลที่มีการเอาข้อมูลที่มีการปนของภาวะหัวใจห้องบนสั่นพลิ้วออก

Model	Filters	Filter size	Residual blocks	Sensitivity (%)	Specificity (%)
1	175	12	8	98.33 (Missed AF = 5)	92.33 (Missed NSR, PAC and PVC = 7, 16, 0)
2		15	10	98.00 (Missed AF = 6)	97.33 (Missed NSR, PAC and PVC = 2, 6, 0)
3		18	10	99.00 (Missed AF = 3)	89.67 (Missed NSR, PAC and PVC = 14, 17, 0)

ตารางที่ 20 ผลประสิทธิภาพของโมเดลที่เหมาะสมที่ถูกเรียนรู้และทดสอบด้วยชุดข้อมูลที่มีการนำเอา Outliers เข้ามาอยู่ในชุดข้อมูลเรียนรู้

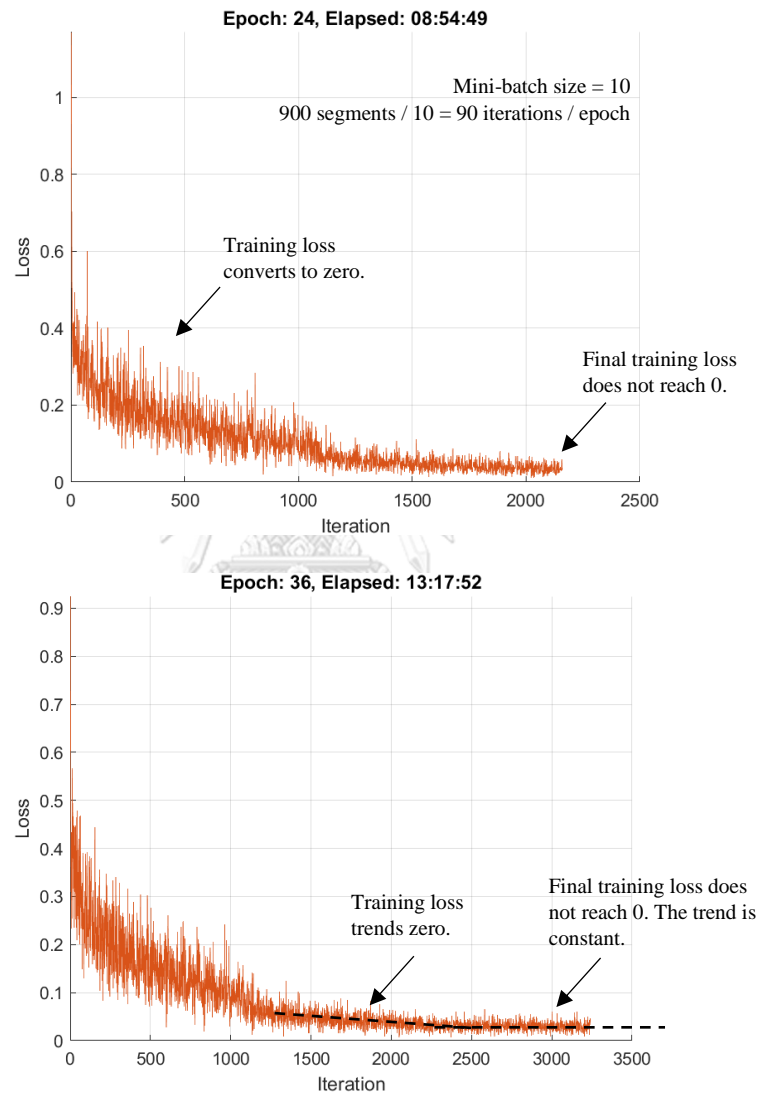
Model	Filters	Filter size	Residual blocks	Sensitivity (%)	Specificity (%)
1	175	12	8	98.33 (Missed AF = 5)	99.33 (Missed NSR, PAC and PVC = 2, 0, 0)
2		15	10	98.00 (Missed AF = 6)	99.33 (Missed NSR, PAC and PVC = 2, 0, 0)
3		18	10	99.00 (Missed AF = 3)	96.67 (Missed NSR, PAC and PVC = 3, 7, 0)

จุฬาลงกรณ์มหาวิทยาลัย

#### 4.3 ผลที่ได้จากการประยุกต์ใช้โครงข่ายคอนโวลูชันตามเวลาแยกแยะภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

จากการทดลองที่ผ่านมาข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจนั้นถูกแบ่งเป็น 2 กลุ่มคือกลุ่มสัญญาณภาวะหัวใจห้องบนสั่นพลิ้วและกลุ่มสัญญาณที่ไม่ใช่ภาวะหัวใจห้องบนสั่นพลิ้ว ซึ่งอีกหนึ่งในจุดประสงค์ของงานวิจัยนี้คือต้องการนำสัญญาณคลื่นไฟฟ้าหัวใจจากกลุ่มหลังมาแยกประเภทของสัญญาณอีกครั้ง โดยประกอบด้วยสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ โมเดลที่จะนำมาใช้ในการเรียนรู้คือ โมเดล [12 175 8] เพราะเป็นโมเดลที่ดีที่สุดที่ได้จากการทดลองที่ผ่านมา การเรียนรู้ของโมเดลในการทดลองนี้จำนวน Epoch หรือรอบการเรียนรู้ของโมเดลจะมากขึ้นเนื่องจากค่าต้นทุนขณะเทรนของโมเดลเข้าสู่ศูนย์ค่อนข้างช้า การทดลองใช้ค่าอัตราการเรียนรู้เริ่มต้นอยู่ที่ 0.001 และลดลง 10 เท่าเมื่อผ่านไป 12 epoch กำหนดจำนวน epoch สูงสุดอยู่ที่ 24 รอบ แต่เมื่อโมเดลทำการเรียนรู้เสร็จสิ้นพบว่าค่าต้นทุนยังคงมีแนวโน้มที่จะลดลงไปได้อีก ดังแสดงในรูปที่ 35 (บน) ดังนั้นจึงทำการเพิ่มจำนวน epoch สูงสุดจาก 24 รอบเป็น 36

รอบ แต่ค่าต้นทุนขณะฝึกมีแนวโน้มคงที่ ผลของการที่ค่าต้นทุนไม่ลงต่ำไปและที่ศูนย์นั้นเกิดจากการทำ dropout เอาท์ และการใช้เรกกูลาร์ไลเซชันแบบแอลสอง เนื่องจากทั้งสองวิธีนี้ช่วยลดการเกิด Over-fitting ของโมเดลลง ทำให้โมเดลไม่อิงกับชุดข้อมูลฝึกมากเกินไป โดยการทำให้เรกกูลาร์ไลเซชันมีส่วนช่วยในการพิจารณาว่าคุณลักษณะใดมีความสำคัญกับโมเดล ซึ่งช่วยลดความซับซ้อนของโมเดลที่เกิดขณะเรียนรู้กับชุดข้อมูลฝึกได้



รูปที่ 35 ค่าต้นทุนขณะโมเดลทำการเรียนรู้ด้วยจำนวนรอบการเรียนรู้สูงสุดอยู่ที่ 24 (บน) และ 36 (ล่าง) รอบ

ในส่วนของการทดสอบโมเดลจะมีความซับซ้อนขึ้นมาเล็กน้อย เนื่องจากว่าทุก ๆ จุดของข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีจะถูกกำกับด้วยเหตุเป็น 1 ใน 3 ภาวะของหัวใจที่ได้กล่าวไปแล้วข้างต้น และจากหัวข้อ 3.5.1.2 ที่กล่าวถึงการคัดข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีที่มีจำนวนลูกที่เป็นภาวะหัวใจห้องบนเต้นก่อน

จังหวะหรือภาวะหัวใจห้องล่างเต้นก่อนจังหวะปนอยู่อย่างน้อยร้อยละ 20 ของจำนวนลูกคลื่นทั้งหมดของสัญญาณคลื่นไฟฟ้าหัวใจ ดังนั้นข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีจะมีชนิดของภาวะหัวใจมากกว่าหนึ่งชนิดปะปนกันอยู่ โดยการทดสอบความสามารถของโมเดลนี้ต้องการหาวิธีการประเมินโมเดลที่นำไปประยุกต์ใช้ทางการแพทย์ได้ ซึ่งจะแบ่งพิจารณาตามตารางที่ 21

ตารางที่ 21 คลาสของแต่ละข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีพร้อมกับคลาสที่ได้จากการทำนายของโมเดล

<i>ECG type</i>	<i>Classification class</i>	<i>Prediction class</i>
NSR	NSR	NSR, PAC, PVC, PAC+PVC
PAC	PAC	PAC, no-PAC
	PAC, PAC+PVC	NSR, PAC, PVC, PAC+PVC
PVC	PVC	PVC, no-PVC
	PVC, PAC+PVC	NSR, PAC, PVC, PAC+PVC

#### 4.3.1 การพิจารณาสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติ

เนื่องจากสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติที่ถูกคัดค้านั้นจะไม่มีภาวะอื่น ๆ ปนอยู่เลย ดังนั้นการทดสอบโมเดลจะกำหนดให้คิดจากจำนวนจุดที่โมเดลทายถูกเทียบกับจำนวนจุดทั้งหมดในสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที โดยถ้าโมเดลสามารถทำนายจำนวนจุดได้ถูกต้องมากกว่าหรือเท่ากับร้อยละ 50 โมเดลจะได้รับคะแนนจากการทายถูก 1 คะแนน

$$\frac{\text{number of correct prediction point}}{\text{All ECG points}} \geq 0.5 \quad (34)$$

#### 4.3.2 การพิจารณาสัญญาณคลื่นไฟฟ้าหัวใจภาวะห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

ทั้งสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะถูกคัดเลือกจากหลักเกณฑ์เดียวกัน ดังนั้นหลักการพิจารณาความสามารถของโมเดลจึงเหมือนกัน ในที่นี้จึงจะขอยกตัวอย่างหลักการพิจารณาของภาวะหัวใจห้องบนเต้นก่อนจังหวะ


#### 4.3.2.1 ความสามารถของโมเดลในการทำนายคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อน จังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ

การพิจารณานี้มีจุดมุ่งหมายว่าโมเดลสามารถบอกได้หรือไม่ว่ามีภาวะหัวใจห้องบนเต้นก่อนจังหวะปนอยู่หรือไม่ โดยจะทำการพิจารณาไปที่เลขลูกคลื่นของสัญญาณที่ถูกหมายเหตุไว้ว่าเป็นภาวะห้องบนเต้นก่อนจังหวะ จากตัวอย่างรูปที่ 36 เป็นตัวอย่างของสัญญาณคลื่นไฟฟ้าหัวใจที่มีภาวะหัวใจห้องบนเต้นก่อนจังหวะเจือปนอยู่อย่างน้อยร้อยละ 20 ซึ่งมีจำนวนลูกของภาวะหัวใจห้องบนเต้นก่อนจังหวะอยู่ 17 ลูกจากทั้งหมด 46 ลูกคลื่น จากตัวอย่างรูปที่ 36 พิจารณาที่ลูกที่ 2 ของภาวะหัวใจห้องบนเต้นก่อนจังหวะมีจำนวนของจุดข้อมูลอยู่ 65 จุด โมเดลทายถูกทั้งหมด 55 จุด เมื่อนำมาเทียบอัตราส่วนระหว่างจำนวนจุดที่ทายถูกกับจำนวนจุดทั้งหมดที่มีอยู่ในลูกคลื่นนั้นจะมีค่าเท่ากับร้อยละ 84.32 การที่โมเดลจะได้คะแนนจากการทายในครั้งนี้นั้นโมเดลจะต้องทายได้ถูกต้องตั้งแต่ร้อยละ 50 ขึ้นไป ดังนั้นโมเดลจะได้ 1 คะแนนในครั้งนี้นี้ จากนั้นทำเช่นนี้ไปกับทุก ๆ ลูกคลื่นในสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาที โดยจากตัวอย่างโมเดลสามารถได้คะแนนจากการทายทุก ๆ ลูกคลื่นรวมเป็น 16 คะแนนจากคะแนนเต็ม 17 คะแนน โดยโมเดลจะได้คะแนนจากการทายสัญญาณ 30 วินาทีนี้ก็ต้องเมื่อโมเดลสามารถทายได้ถูกต้องตั้งแต่ร้อยละ 50 ขึ้นไป ดังนั้นเมื่อเทียบอัตราส่วนแล้วจะได้ร้อยละ 94.12 ซึ่งโมเดลจะได้คะแนนจากการทายและโมเดลสามารถทำนายได้ว่ามีภาวะหัวใจห้องบนเต้นก่อนจังหวะปนอยู่ในสัญญาณ 30 วินาทีนี้ ผลการทายของโมเดลของหัวข้อนี้แสดงไว้ในตารางที่ 22 โดยได้ค่าความถูกต้องคิดเป็นร้อยละ 92.33


#### 4.3.2.2 ความสามารถของโมเดลในการทำนายประเภทของสัญญาณคลื่นไฟฟ้าหัวใจ

จากตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจในรูปที่ 36 (บน) จะเห็นได้ว่านอกจากจะมีภาวะหัวใจเต้นปกติและภาวะหัวใจห้องบนเต้นก่อนจังหวะแล้ว ยังมีภาวะหัวใจห้องล่างเต้นก่อนจังหวะปะปนมาด้วย โดยการพิจารณาต่อไปนี้จะนำเอาทั้งภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะมาคิดด้วยด้วยกัน ซึ่งสามารถแบ่งออกเป็น 4 ประเภทของสัญญาณดังนี้ ภาวะหัวใจปกติอย่างเดียว ภาวะหัวใจห้องบนเต้นก่อนจังหวะอย่างเดียว ภาวะหัวใจห้องล่างเต้นก่อนจังหวะอย่างเดียว และมีทั้งภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะรวมอยู่ด้วยกัน หลักการให้คะแนนจะเหมือนกับในหัวข้อ 4.3.2.1 จากตัวอย่างในรูปที่ 37 สำหรับคำตอบจริงคือเป็นสัญญาณที่มีทั้งภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะ เมื่อใช้หลักเกณฑ์เดียวกับข้างต้นจะได้ว่าโมเดลสามารถทายว่ามีภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะอยู่ถูกต้องร้อยละ 94.11 และ 100 ตามลำดับ ดังนั้นคำตอบที่โมเดลทายตัวอย่างนี้คือมีทั้งภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะรวมอยู่ด้วยกันในสัญญาณ 30 วินาทีนี้ เมื่อทำการเทียบกับคำตอบจริงปรากฏว่าคำตอบที่ได้ตรงกัน ดังนั้นโมเดลได้ไป 1 คะแนนสำหรับการทายในครั้งนี้นี้ โดยผลการทายของโมเดลในหัวข้อนี้ถูกแสดงไว้ในตารางที่ 23 ได้ค่าความถูกต้องคิดเป็นร้อยละ 87.33





**รูปที่ 36** ตัวอย่างสัญญาณคลื่นไฟฟ้าหัวใจ 30 วินาทีที่มีจำนวนลูกที่เป็นภาวะหัวใจห้องบนเต้นก่อนจังหวะอยู่อย่างน้อยร้อยละ 20 (บน) และตัวอย่างการทำนายสัญญาณของโมเดล (ล่าง) โดยที่สีฟ้า สีชมพู และสีเขียวคือ ภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะ ตามลำดับ



**รูปที่ 37** ตัวอย่างการให้คะแนนกับโมเดลในการทำภาวะหัวใจห้องบนเต้นก่อนจังหวะ

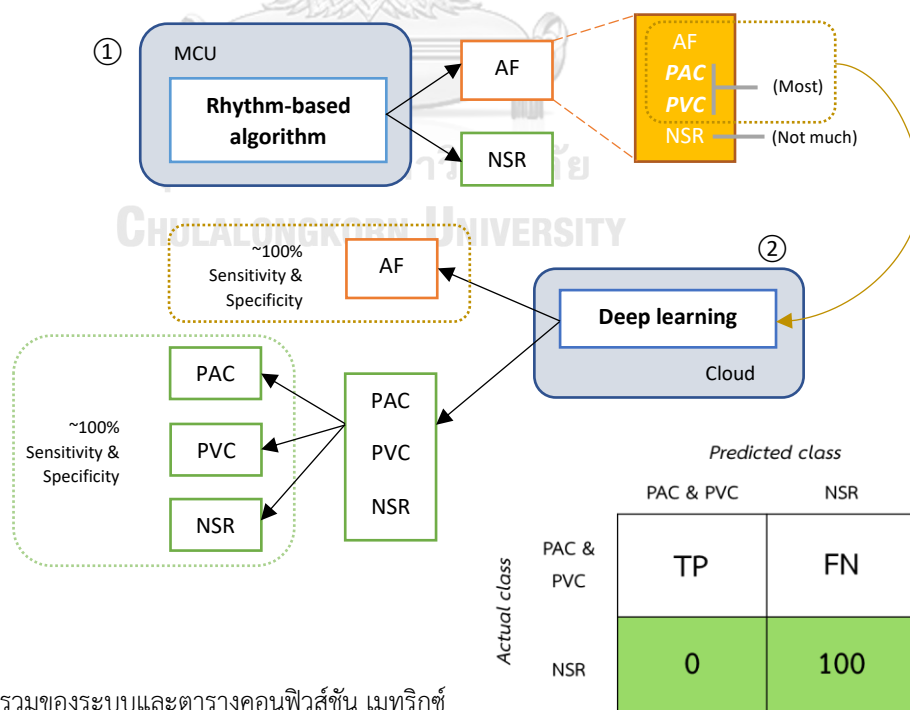
ผลการทนายของโมเดลทั้งแบบในหัวข้อ 4.3.2.1 และ 4.3.2.2 ที่ได้แสดงไว้ในตารางที่ 22 และ 23 ตามลำดับนั้น ผลที่ได้จากหลักการพิจารณาในหัวข้อ 4.3.2.1 นั้นได้ค่าความถูกต้องสูงกว่า โดยค่าความถูกต้องคิดเป็นร้อยละ 92.33 อีกวิธีหนึ่งจะให้ค่าความถูกต้องคิดเป็นร้อยละ 87.33 จะเห็นได้ว่าโครงข่ายคอนโวลูชันตามเวลาสามารถนำมาแยกสัญญาณคลื่นไฟฟ้าหัวใจภาวะปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะได้ดี โดยเฉพาะการแยกภาวะหัวใจปกติ ซึ่งโมเดลให้ค่าความจำเพาะสูงถึง 100% ดังแสดงในรูปที่ 38 ซึ่งแสดงถึงภาพรวมของงานวิจัยและตารางคอนฟิวส์ชัน เมทริกซ์ที่แสดงถึงค่าความจำเพาะของโมเดลในการแยกภาวะหัวใจปกติออกจากภาวะผิดปกติทั้งสองดังกล่าว โดยการพิจารณาความสามารถของโมเดลในการแยกภาวะทั้งสามชนิดนั้นสามารถทำได้หลายวิธีขึ้นอยู่กับการประยุกต์ใช้งานในตรวจจับภาวะทั้งสามนี้

ตารางที่ 22 ผลการทำนายของโมเดลในการทายคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะตามหัวข้อ 4.3.2.1

Classes	ECG Types	Correct Prediction
		30-second ECG segments
Non-AF	NSR	100
	PAC	84
	PVC	93
<b>Accuracy</b>		92.33%

ตารางที่ 23 ผลการทำนายของโมเดลในการทายประเภทของสัญญาณคลื่นไฟฟ้าหัวใจตามหัวข้อ 4.3.2.2

Classes	ECG Types	Correct Prediction
		30-second ECG segments
Non-AF	NSR	100
	PAC	78
	PVC	84
<b>Accuracy</b>		87.33%



รูปที่ 38 ภาพรวมของระบบและตารางคอนฟิวสชัน เมทริกซ์

## บท 5

### สรุปงานวิจัยและแนวทางการทำงานวิจัยในอนาคต

#### 5.1 สรุปงานวิจัย

การนำการเรียนรู้เชิงลึกมาประยุกต์ใช้เพื่อพัฒนาระบบการตรวจจับสัญญาณคลื่นไฟฟ้าหัวใจห้องบนสันพลิ้ว โดยมุ่งเน้นไปที่การปรับปรุงค่าความจำเพาะของการตรวจจับภาวะหัวใจห้องบนสันพลิ้ว ซึ่งมีตัวสัญญาณคลื่นไฟฟ้าหัวใจที่ผิดปกติอย่างภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะเป็นตัวรบกวนสำคัญ งานวิจัยนี้ได้ใช้วิธีการถ่ายโอนจากโครงข่ายคอนโวลูชันที่ใช้กันอย่างแพร่หลายอย่าง AlexNet เพื่อเรียนรู้และแยกแยะสัญญาณคลื่นไฟฟ้าหัวใจภาวะห้องบนสันพลิ้วและภาวะหัวใจเต้นปกติจากสัญญาณคลื่นไฟฟ้าหัวใจหนึ่งช่องสัญญาณ โดยทำการแยกแยะภาวะต่าง ๆ จากข้อมูลภาพสัญญาณคลื่นไฟฟ้าหัวใจ ผลปรากฏว่าโมเดลสามารถเรียนรู้รูปร่างลักษณะที่ต่างกันของสัญญาณได้ดี เนื่องจากได้ค่าความจำเพาะที่สูงถึงร้อยละ 96.33 และนำไปใช้ร่วมกับอัลกอริทึมซับซ้อนน้อยสำหรับไมโครคอนโทรลเลอร์ที่ใช้ตรวจจับภาวะหัวใจห้องบนสันพลิ้วด้วยวิธีทาง Rhythm-based method พบว่าสามารถเพิ่มค่าความจำเพาะของระบบทั้งหมดได้ถึงร้อยละ 100 ดังนั้นการเรียนรู้เชิงลึกสามารถนำมาใช้เพื่อวิเคราะห์รูปร่างของสัญญาณคลื่นไฟฟ้าหัวใจได้

อย่างไรก็ตามการใช้ภาพสัญญาณคลื่นไฟฟ้าหัวใจนั้นอาจจะไม่เหมาะกับการนำมาใช้ในงานจริง เพราะต้องทำการแปลงข้อมูลสัญญาณของอนุกรมเวลาเป็นข้อมูลภาพ จึงได้นำเอาโครงข่ายคอนโวลูชันตามเวลา มาประยุกต์ใช้กับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจในเชิงอนุกรมเวลาโดยเลือกใช้สัญญาณเพียงหนึ่งช่องสัญญาณเช่นกันและได้เพิ่มตัวรบกวนอย่างภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะเข้ามาทั้งในชุดข้อมูลฝึกและชุดข้อมูลทดสอบ เพราะทั้งสองภาวะมีลักษณะของอัตราการเต้นของหัวใจที่ไม่สม่ำเสมอคล้ายกับภาวะหัวใจห้องบนสันพลิ้ว ถ้าหากอาศัยอัลกอริทึมทาง Rhythm-based method เพียงอย่างเดียวอาจไม่เพียงพอที่จะแยกแยะรบกวนเหล่านี้ออกไปได้ ผลของการนำโครงข่ายตามเวลามาใช้แยกแยะสัญญาณคลื่นไฟฟ้าหัวใจห้องบนสันพลิ้วออกจากภาวะหัวใจประเภทอื่นคือ ได้ค่าความไวและค่าความจำเพาะที่ร้อยละ 98.33 และ 99.33 ตามลำดับ ซึ่งจะเห็นได้ว่าค่าความจำเพาะที่ได้นี้มีค่าสูงมาก แม้ว่าจะมีภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะมารบกวนก็ตาม นอกจากนี้ยังมีการนำเอาโครงข่ายคอนโวลูชันตามเวลาทำการแยกแยะสัญญาณคลื่นไฟฟ้าหัวใจที่ไม่ใช่ภาวะหัวใจห้องบนสันพลิ้ว ซึ่งประกอบด้วยภาวะหัวใจเต้นปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะและได้ค่าความถูกต้องสูงถึงร้อยละ 92.33 และได้ค่าความจำเพาะสูงถึงร้อยละ 100 งานวิจัยนี้แสดงให้เห็นว่าการเรียนรู้เชิงลึกเป็นวิธีที่มีประโยชน์กับวงการสัญญาณทางการแพทย์เป็นอย่างยิ่ง นอกจากจะสามารถนำมาแยกสัญญาณคลื่นไฟฟ้าหัวใจภาวะหัวใจห้องบนสันพลิ้วออกจากภาวะอื่น ๆ ได้แล้ว ยังมีความเป็นไปได้ที่จะถูกใช้ในการแยกแยะภาวะหัวใจห้องบนเต้นก่อนจังหวะและภาวะหัวใจห้องล่างเต้นก่อนจังหวะที่เป็นตัวรบกวนได้อีกด้วย การเปรียบเทียบงานวิจัยนี้กับงานวิจัยอื่นที่ทำการแยกแยะทั้ง 4 ภาวะดังตารางที่ 24

**ตารางที่ 24** การสรุปงานวิจัยที่เกี่ยวข้องกับการตรวจจับภาวะหัวใจห้องบนสั่นพลิ้วที่มีภาวะหัวใจปกติ ภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะปนอยู่ด้วย

Study	Arrhythmias	Database	Feature set	Classifier	Sen   Spec of AF (%)
Yao et. al. [41]	NSR, AF, I-AVB*, LBBB, RBBB, PAC, PVC, STD**, STE***	The 1st China Physiological Signal Challenge (12-Lead)	End-to-end	CNN and LSTM	AF: 92.06   98.47
A. Jovic, and F. Jovic [9]	NSR, PAC, PVC, AF, VB <sup>+</sup> , VT <sup>++</sup>	MIT-BIH	Alphabet entropy	Random forest	AF: 93.85   97.70
This study	NSR, PAC, PVC, AF	LTAFDB	End-to-end	TCN	AF: 98.33   99.33

\* First-degree Atrioventricular Block \*\* ST-segment depression \*\*\* ST-segment elevation <sup>+</sup> Ventricular Bigeminy <sup>++</sup> Ventricular Trigeminy

## 5.2 แนวทางการวิจัยในอนาคต

จากการใช้การเรียนรู้เชิงลึกในการสร้างโมเดลแต่ละการทดลองจะเห็นได้ว่าข้อมูลที่ใช้สำหรับการเรียนรู้ของโมเดลนั้นมีอยู่ค่อนข้างน้อย ดังนั้นควรมีการเพิ่มจำนวนข้อมูลของสัญญาณคลื่นไฟฟ้าหัวใจให้มากขึ้นในอนาคต ในงานวิจัยนี้ได้นำโครงข่ายคอนโวลูชันตามเวลามาใช้เพียงอย่างเดียวดังในหัวข้อที่ 3.5 และ 3.6 โดยจากการทำการทบทวนวรรณกรรมทำให้ทราบว่า การนำโครงข่ายชนิดอื่น ๆ มาใช้ร่วมกันอาจจะทำให้โมเดลสามารถเพิ่มขีดจำกัดในการเรียนรู้ได้มากขึ้น ตัวอย่างเช่น การนำเอา LSTM มาใช้ร่วมกัน เนื่องจากการใช้โครงข่ายคนละชนิดเสมือนกับการมองเหรียญคนละด้าน เพราะแต่ละโครงข่ายมีความสามารถในการสกัดคุณลักษณะที่สำคัญของข้อมูลต่างกันออกไป นอกจากนั้นการนำโครงข่ายอื่นมาใช้ร่วมกันแล้ว การปรับปรุงหรือการเปลี่ยนแปลงตัวแปรต่าง ๆ ของโครงข่ายคอนโวลูชันตามเวลา รวมไปถึงการนำเทคนิคการฝึกโมเดลมาประยุกต์ใช้ก็เป็นสิ่งที่ยังต้องศึกษาเพิ่มเติม เพื่อให้ได้โมเดลที่เหมาะสมกับข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจนี้มากที่สุด นอกจากนี้การตรวจจับภาวะหัวใจห้องบนเต้นก่อนจังหวะ และภาวะหัวใจห้องล่างเต้นก่อนจังหวะเป็นเพียงการตรวจจับชนิดของจุดหัวใจเต้นหรือ Beat type เท่านั้นแต่การเกิดทั้งสองภาวะนี้สามารถนำไปสู่ชนิดของจังหวะหัวใจเต้นหรือ Rhythm type อื่น ๆ ได้อีกด้วย เช่น Ventricular bigeminy, Ventricular trigeminy, Idioventricular rhythm และ Atrial bigeminy

## บรรณานุกรม

1. Fuster, V., et al., *ACC/AHA/ESC 2006 Guidelines for the Management of Patients With Atrial Fibrillation-Executive Summary. A Report of the American College of Cardiology/American Heart Association Task Force on Practice Guidelines and the European Society of Cardiology*. 2006.
2. Sitthisook., S., *Thai AF Guideline 2012*, The Heart Association of Thailand under the royal Patronage of H.M. The King, Editor. 2012: Bangkok. p. 12-17.
3. Furberg, C.D., et al., *Prevalence of atrial fibrillation in elderly subjects (the Cardiovascular Health Study)*. *The American journal of cardiology*, 1994. 74(3): p. 236-241.
4. Association, D.w.t.s.c.o.t.E.H.R., et al., *Guidelines for the management of atrial fibrillation: the Task Force for the Management of Atrial Fibrillation of the European Society of Cardiology (ESC)*. *European heart journal*, 2010. 31(19): p. 2369-2429.
5. Griffiths, K.M., et al. *Assessing the accuracy of limited lead recordings for the detection of Atrial Fibrillation*. in *Computing in Cardiology 2014*. 2014. IEEE.
6. Fan, X., et al., *Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings*. *IEEE journal of biomedical and health informatics*, 2018. 22(6): p. 1744-1753.
7. Dash, S., et al., *Automatic real time detection of atrial fibrillation*. *Annals of biomedical engineering*, 2009. 37(9): p. 1701-1709.
8. Huang, C., et al., *A novel method for detection of the transition between atrial fibrillation and sinus rhythm*. *IEEE Transactions on Biomedical Engineering*, 2010. 58(4): p. 1113-1119.
9. Jovic, A. and F. Jovic, *Classification of cardiac arrhythmias based on alphabet entropy of heart rate variability time series*. *Biomedical Signal Processing and Control*, 2017. 31: p. 217-230.
10. Panigrahy, D. and P. Sahu, *P and T wave detection and delineation of ECG signal using differential evolution (DE) optimization strategy*. *Australasian*

- physical & engineering sciences in medicine, 2018. 41(1): p. 225-241.
11. Min, S., B. Lee, and S. Yoon, *Deep learning in bioinformatics*. Briefings in bioinformatics, 2017. 18(5): p. 851-869.
  12. Pourbabaee, B., M.J. Roshtkhari, and K. Khorasani, *Deep convolutional neural networks and learning ECG features for screening paroxysmal atrial fibrillation patients*. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018. 48(12): p. 2095-2104.
  13. Murugesan, B., et al. *Ecgnnet: Deep network for arrhythmia classification*. in *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*. 2018. IEEE.
  14. Clifford, G.D., et al. *AF Classification from a short single lead ECG recording: the PhysioNet/Computing in Cardiology Challenge 2017*. in *2017 Computing in Cardiology (CinC)*. 2017. IEEE.
  15. Petrutiu, S., A.V. Sahakian, and S. Swiryn, *Abrupt changes in fibrillatory wave characteristics at the termination of paroxysmal atrial fibrillation in humans*. Europace, 2007. 9(7): p. 466-470.
  16. Marieb, E.N., *Essentials of Human Anatomy and Physiology (Eleventh edition)*. 2013: Pearson.
  17. Meek, S. and F. Morris, *Introduction. II—Basic terminology*. Bmj, 2002. 324(7335): p. 470-473.
  18. Institute for Quality and Efficiency in Health Care (IQWiG), *What is an electrocardiogram (ECG)?* 2019: Cologne, Germany.
  19. Michałkiewicz, D., et al., *Detection of patients at risk for paroxysmal atrial fibrillation (PAF) by signal averaged P wave, standard ECG and echocardiography*. Polski merkuriusz lekarski: Organ Polskiego Towarzystwa Lekarskiego, 2006. 20(115): p. 69-72.
  20. Assodiky, H., I. Syarif, and T. Badriyah, *Arrhythmia classification using long short-term memory with adaptive learning rate*. EMITTER International Journal of Engineering Technology, 2018. 6(1): p. 75-91.
  21. Carrara, M., et al., *Heart rate dynamics distinguish among atrial fibrillation, normal sinus rhythm and sinus rhythm with frequent ectopy*. Physiological

- measurement, 2015. 36(9): p. 1873.
22. Raut, G., et al. *Efficient Low-Precision CORDIC Algorithm for Hardware Implementation of Artificial Neural Network*. in *International Symposium on VLSI Design and Test*. 2019. Springer.
  23. Chollet, F., *Deep Learning with Python*. 2018, Shelter Island, New York, USA: Manning Publications Co.
  24. Ruder, S., *An overview of gradient descent optimization algorithms*. arXiv preprint arXiv:1609.04747, 2016.
  25. ปริญญา สงวนสัตย์, *Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชชีนเลิร์นนิง*. Python Edition ed. 2562, นนทบุรี: ไอทีซี พรีเมียร์. 356.
  26. Goodfellow, I., et al., *Deep learning*. Vol. 1. 2016: MIT press Cambridge.
  27. Trakoolwilaiwan, T., et al., *Convolutional neural network for high-accuracy functional near-infrared spectroscopy in a brain-computer interface: three-class classification of rest, right-, and left-hand motor execution*. *Neurophotonics*, 2017. 5(1): p. 011008.
  28. Bai, S., J.Z. Kolter, and V. Koltun, *An empirical evaluation of generic convolutional and recurrent networks for sequence modeling*. arXiv preprint arXiv:1803.01271, 2018.
  29. Oord, A.v.d., et al., *Wavenet: A generative model for raw audio*. arXiv preprint arXiv:1609.03499, 2016.
  30. Impedovo, D., et al., *TrafficWave: Generative deep learning architecture for vehicular traffic flow prediction*. *Applied Sciences*, 2019. 9(24): p. 5504.
  31. He, K., et al. *Deep residual learning for image recognition*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
  32. Shavlik, L.T.a.J., *Transfer Learning*. *Handbook of Research on Machine Learning Applications*. 2009: IGI Global.
  33. Cao, P., et al., *A novel data augmentation method to enhance deep neural networks for detection of atrial fibrillation*. *Biomedical Signal Processing and Control*, 2020. 56: p. 101675.
  34. Tajbakhsh, N., et al., *Convolutional neural networks for medical image analysis: Full training or fine tuning?* *IEEE transactions on medical imaging*, 2016. 35(5): p.

- 1299-1312.
35. Isin, A. and S. Ozdalili, *Cardiac arrhythmia detection using deep learning*. Procedia computer science, 2017. 120: p. 268-275.
  36. Fukunami, M., et al., *Detection of patients at risk for paroxysmal atrial fibrillation during sinus rhythm by P wave-triggered signal-averaged electrocardiogram*. Circulation, 1991. 83(1): p. 162-169.
  37. Opolski, G., et al., *Detection of patients at risk for recurrence of atrial fibrillation after successful electrical cardioversion by signal-averaged P-wave ECG*. International journal of cardiology, 1997. 60(2): p. 181-185.
  38. Budeus, M., et al., *Detection of atrial late potentials with P wave signal averaged electrocardiogram among patients with paroxysmal atrial fibrillation*. Zeitschrift fur Kardiologie, 2003. 92(5): p. 362-369.
  39. Yildirim, Ö., *A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification*. Computers in biology and medicine, 2018. 96: p. 189-202.
  40. Andersen, R.S., A. Peimankar, and S. Puthusserypady, *A deep learning approach for real-time detection of atrial fibrillation*. Expert Systems with Applications, 2019. 115: p. 465-473.
  41. Yao, Q., et al., *Multi-class Arrhythmia detection from 12-lead varied-length ECG using Attention-based Time-Incremental Convolutional Neural Network*. Information Fusion, 2020. 53: p. 174-182.
  42. Lea, C., et al. *Temporal convolutional networks for action segmentation and detection*. in *proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017.
  43. Pan, J. and W.J. Tompkins, *A real-time QRS detection algorithm*. IEEE transactions on biomedical engineering, 1985(3): p. 230-236.
  44. Yosinski, J., et al. *How transferable are features in deep neural networks?* in *Advances in neural information processing systems*. 2014.
  45. Yang, J., et al., *Characteristics of Unselected High -Burden Premature Ventricular Contraction Patients*. Pacing and Clinical Electrophysiology, 2014. 37(12): p. 1671-1680.





จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**



ภาคผนวก

จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ภาคผนวก ก ระยะเวลาในการฝึกโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีพารามิเตอร์ของโมเดลที่ต่างกัน

### การฝึกโมเดลโครงข่ายคอนโวลูชันตามเวลา

แต่ละโมเดลถูกเรียนรู้ด้วยหน่วยประมวลผลกลาง (CPU) โดยคุณลักษณะของหน่วยประมวลผลกลางที่ใช้มีดังนี้

(1) Intel Core i7 (6th Gen) 6500U/2.5 GHz ของอุปกรณ์แล็ปท็อป Dell Inspiron 15 5559 และโปรแกรมที่ใช้ในการสร้างและฝึกโมเดลคือ MATLAB R2019b โดยโมเดลที่ถูกฝึกด้วยอุปกรณ์นี้จะมีเครื่องหมายดอกจัน (\*) ปรากฏอยู่

(2) Intel Core i5/2.9GHz dual-core ของอุปกรณ์แล็ปท็อป 2016 MacBook Pro และโปรแกรมที่ใช้ในการสร้างและฝึกโมเดลคือ MATLAB R2020a

ระยะเวลาของการฝึกโมเดลแสดงดังตารางที่ 25, 26 และ 27 ซึ่งแบ่งตามจำนวนของตัวกรองที่ต่างกัน คือ 150, 175 และ 200 ตามลำดับ โดยรายละเอียดของข้อมูลฝึกที่ใช้นั้นได้กล่าวไปแล้วในตารางที่ 8

**ตารางที่ 25** ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 150

Model	Filter size	Number of residual blocks	Training time (HH:MM:SS)
1	9	6	01:27:54
2	12		01:42:14
3	15		01:56:13
4	18		02:14:55
5	9	8	01:56:08
6	12		02:15:40
7	15		02:36:12
8	18		02:56:56
9	9	10	02:20:08
10	12		02:39:26
11	15		03:00:17
12	18		03:21:18

ตารางที่ 26 ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 175

Model	Filter size	Number of residual blocks	Training time (HH:MM:SS)
1*	9	6	03:23:40
2*	12		03:30:42
3	15		02:33:44
4*	18		04:13:18
5	9	8	02:26:56
6*	12		04:34:40
7	15		03:24:45
8	18		03:55:08
9	9	10	02:54:51
10	12		03:27:10
11	15		04:04:56
12	18		04:28:54

ตารางที่ 27 ระยะเวลาในการเรียนรู้ของโมเดลโครงข่ายคอนโวลูชันตามเวลาที่มีจำนวนของตัวกรองเท่ากับ 200

Model	Filter size	Number of residual blocks	Training time (HH:MM:SS)
1	9	6	02:06:57
2	12		02:31:02
3	15		03:02:14
4	18		03:22:48
5	9	8	02:54:09
6	12		03:27:34
7	15		04:02:46
8	18		04:31:40
9	9	10	03:30:15
10	12		04:04:52
11	15		04:39:11
12	18		05:10:05

ภาคผนวก ข ผลการทดสอบการเปรียบเทียบประสิทธิภาพของ 3 โมเดลที่ถูกเลือกด้วย  
Paired T Test

ตารางที่ 28 ค่า T value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 8 ตามลำดับ

Models	9 175 8	12 175 8	15 175 8	18 175 8
9 175 8		-0.62	0.00	2.85*
12 175 8	-0.62		1.45	1.90*
15 175 8	0.00	1.45		1.37
18 175 8	2.85*	1.90*	1.37	

\* คือ โมเดลที่มีประสิทธิภาพดีกว่าอย่างมีนัยสำคัญ

ตารางที่ 29 ค่า P value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 8 ตามลำดับ

Models	9 175 8	12 175 8	15 175 8	18 175 8
9 175 8		0.27	0.50	0.01*
12 175 8	0.27		0.08	0.04*
15 175 8	0.50	0.08		0.09
18 175 8	0.01*	0.04*	0.09	

\* คือ โมเดลที่มีประสิทธิภาพดีกว่าอย่างมีนัยสำคัญ

จากตารางที่ 28 และ 29 โมเดล [12 175 8] เป็นโมเดลที่ถูกเลือกจากงานวิจัยนี้และเป็นโมเดลที่มีประสิทธิภาพดีกว่าอย่างมีนัยสำคัญเมื่อเทียบกับโมเดล [18 175 8] แม้ว่าโมเดล [15 175 8] จะมีประสิทธิภาพอย่างมีนัยสำคัญเช่นกัน แต่เนื่องจากค่าความไวที่ได้จากโมเดล [15 175 8] น้อยกว่าโมเดล [12 175 8] จึงทำให้ไม่ถูกเลือกมาใช้เพื่อทำการทดลองขั้นต่อไป

ตารางที่ 30 ค่า T value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 10 ตามลำดับ

Models	9 175 10	12 175 10	15 175 10	18 175 10
9 175 10		0.52	-2.03*	-2.24*
12 175 10	0.52		-2.10*	-2.56*
15 175 10	-2.03*	-2.10*		-1.75*
18 175 10	-2.24*	-2.56*	-1.75*	

\* คือ โมเดลที่มีประสิทธิภาพดีกว่าอย่างมีนัยสำคัญ

ตารางที่ 31 ค่า P value จากการทำ Paired T Test โดยแต่ละโมเดลมีจำนวนตัวกรองและจำนวนบล็อกส่วนที่เหลือเท่ากับ 175 และ 10 ตามลำดับ

Models	9 175 10	12 175 10	15 175 10	18 175 10
9 175 10		0.61	0.03*	0.02*
12 175 10	0.61		0.02*	0.01*
15 175 10	0.03*	0.02*		0.048*
18 175 10	0.02*	0.01*	0.048*	

\* คือ โมเดลที่มีประสิทธิภาพดีกว่าอย่างมีนัยสำคัญ

จากตารางที่ 30 และ 31 โมเดล [15 175 10] และ [18 175 10] เป็นโมเดลที่ถูกเลือก เนื่องจากการให้ค่าความจำเพาะที่ค่อนข้างสูง โดยเมื่อนำมาทดสอบประสิทธิภาพทางสถิติแล้วได้ผลว่า โมเดลทั้งสองเป็นโมเดลที่มีประสิทธิภาพที่ดีกว่าอย่างมีนัยสำคัญเมื่อเทียบกับโมเดลอื่น ๆ



## ประวัติผู้เขียน

ชื่อ-สกุล	จันทป์ปภา จันท์ครบ
วัน เดือน ปี เกิด	07 เมษายน 2538
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	ระดับปริญญาตรี หลักสูตรวิศวกรรมบัณฑิต สาขาวิศวกรรมชีวการแพทย์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ที่อยู่ปัจจุบัน	24 ซอยหทัยราษฎร์ 19 ถนนหทัยราษฎร์ มีนบุรี กทม. 10510



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY