

## ระบบตรวจจับภาวะหัวใจเต้นผิดจังหวะโดยใช้การเรียนรู้ของเครื่องแบบฝังตัว

### Cardiac Arrhythmia Detection System Using Embedded Machine Learning

ณัฐวิทย์ วิเชียรผลา<sup>1</sup> อภิวัฒน์ เล็กอุทัย<sup>2</sup> ธนวันต์ เตียววัฒนรัฐติกา<sup>1</sup> อารณณ์ อีรัมย์ศรี<sup>2</sup> รณพิชัย โชคสุวัฒน์สกุล<sup>3</sup> และ ภาคภูมิ สมบูรณ์<sup>1\*</sup>

<sup>1</sup>หลักสูตรวิศวกรรมชีวเวช คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

<sup>2</sup>ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

<sup>3</sup>ภาควิชาอายุรศาสตร์ คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

#### บทคัดย่อ

การตรวจภาวะหัวใจเต้นผิดจังหวะอย่างต่อเนื่องเป็นสิ่งสำคัญในการดูแลสุขภาพและการรักษาผู้ป่วย งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาระบบตรวจจับภาวะหัวใจเต้นผิดจังหวะแบบตามเวลาจริงให้สามารถใช้งานได้บนไมโครคอนโทรลเลอร์พลังงานต่ำ และนำการเรียนรู้ของเครื่องด้วยวิธี Extreme Gradient Boosting (XGBoost) มาประยุกต์ใช้ นอกจากนี้ยังมีกระบวนการคัดเลือกลักษณะเด่นจากคลื่นไฟฟ้าหัวใจที่ดีที่สุดมาใช้ในการจำแนกชนิดของความผิดปกติ โดยโมเดลดังกล่าวถูกแปลงให้อยู่ในรูปแบบที่สามารถใช้งานกับไมโครคอนโทรลเลอร์ได้ด้วยเครื่องมือ X-Cube AI และพัฒนาระบบที่สามารถรับและประมวลผลสัญญาณคลื่นไฟฟ้าหัวใจแบบเวลาจริง ขั้นตอนการทำงานเริ่มจากการตรวจจับ QRS complex การสกัดลักษณะเด่น และการจำแนกประเภทของภาวะหัวใจเต้นผิดจังหวะ การทดสอบประสิทธิภาพของระบบทำโดยการจำลองสัญญาณคลื่นไฟฟ้าหัวใจแบบเวลาจริงจากชุดข้อมูลทดสอบจำนวน 150 ตัวอย่าง ซึ่งประกอบด้วยข้อมูลคลื่นไฟฟ้าหัวใจ 3 ภาวะ ได้แก่ ภาวะหัวใจเต้นจังหวะปกติ (Normal sinus rhythm) ภาวะหัวใจเต้นก่อนเวลา (Premature Contractions) และภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation) ประเภทละ 50 ตัวอย่าง ผลการทดสอบบนอุปกรณ์ระบบฝังตัวพบว่าโมเดลมีความแม่นยำโดยรวม (Overall Accuracy) อยู่ที่ 90.67%

**คำสำคัญ:** สัญญาณคลื่นไฟฟ้าหัวใจ, ภาวะหัวใจห้องบนสั่นพลิ้ว, ภาวะหัวใจเต้นก่อนเวลา, XGBoost, ไมโครคอนโทรลเลอร์พลังงานต่ำ

#### Abstract

Continuous monitoring of cardiac arrhythmia is crucial for healthcare management and patient treatment. This research aims to develop a real-time arrhythmia detection system deployable on a low-power microcontroller and apply a machine learning model using the Extreme Gradient Boosting (XGBoost) method. Additionally, the process includes the selection of optimal features from the ECG waves to classify the type of abnormality. The model was converted into a microcontroller-compatible format using the X-Cube AI tool, and a system was developed to receive and process ECG signals in real-time. The operational workflow begins with QRS complex

detection, followed by feature extraction, and classification of the arrhythmia type. The system's performance was evaluated by simulating real-time ECG signals from a test dataset of 150 samples, which consisted of three categories: Normal Sinus Rhythm, Premature Contractions, and Atrial Fibrillation, with 50 samples for each type. The test results on the embedding system demonstrated that the model achieved an overall accuracy of 90.67%.

**Keywords:** Electrocardiogram, Atrial Fibrillation, Premature Contractions, XGBoost, Low-power Microcontroller

#### 1. บทนำ

จากสถิติผู้ป่วยในของประเทศไทยปี พ.ศ. 2566 โดยกองยุทธศาสตร์และแผนงานสำนักงานปลัดกระทรวงสาธารณสุข [1] พบว่าความผิดปกติของระบบการนำคลื่นไฟฟ้าในหัวใจและภาวะหัวใจเต้นผิดจังหวะเป็นหนึ่งใน 10 สาเหตุหลักของการเจ็บป่วย ซึ่งมีจำนวนผู้ป่วยสูงถึง 336,392 คน และติดอันดับที่ 9 ของประเทศ ซึ่งตัวเลขนี้สะท้อนถึงภาระโรคและผลกระทบที่สำคัญต่อระบบสาธารณสุขของประเทศ

ภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation) คือหนึ่งในชนิดของหัวใจเต้นผิดจังหวะที่พบบ่อย ภาวะนี้มีความสำคัญอย่างยิ่งเนื่องจากเพิ่มความเสี่ยงอย่างมีนัยสำคัญของโรคหลอดเลือดสมองหรือลิ่มเลือดอุดตัน [2] นอกจากภาวะหัวใจห้องบนสั่นพลิ้วแล้ว ภาวะหัวใจเต้นก่อนเวลา (Premature Contractions) ก็เป็นอีกภาวะหนึ่งที่พบได้บ่อยโดยเกิดจากการส่งคลื่นไฟฟ้าออกมาก่อนเวลาที่คลื่นปกติจากตัวสร้างจังหวะหลัก (Sinoatrial node) จะมาถึงซึ่งทำให้หัวใจบีบตัวเร็วเกินไป โดยจากการศึกษา [3] พบว่ามีความสัมพันธ์กับการเพิ่มความเสี่ยงของโรคสมองขาดเลือดเช่นกัน โดยเฉพาะภาวะหัวใจห้องล่างเต้นก่อนเวลา (Premature Ventricular Contraction, PVC) ในกลุ่มผู้ที่ไม่มีภาวะความดันโลหิตสูง และภาวะหัวใจห้องบนเต้นก่อนเวลา (Premature Atrial Contraction, PAC) ก็มีความสัมพันธ์กับความเสี่ยงที่เพิ่มขึ้นนี้ด้วยเช่นกัน

การตรวจวินิจฉัยภาวะหัวใจเต้นผิดจังหวะสามารถทำได้โดยการตรวจคลื่นไฟฟ้าหัวใจ (Electrocardiography, ECG) ซึ่งเป็นวิธีที่ไม่รุกรานและใช้ตรวจการทำงานของหัวใจผ่านขั้วไฟฟ้าที่ติดบนผิวหนังผู้ป่วย อย่างไรก็ตาม

\*ผู้ประสานงาน

ตามการแปลผลสัญญาณ ECG จำเป็นต้องอาศัยผู้เชี่ยวชาญ ซึ่งเป็นข้อจำกัดสำคัญสำหรับผู้ป่วยหรือบุคลากรทั่วไป


ด้วยเหตุนี้การใช้การเรียนรู้ของเครื่องจึงเป็นเครื่องมือที่เหมาะสมเนื่องจากมีศักยภาพในการวิเคราะห์ข้อมูลที่มีความซับซ้อน เช่น ECG ซึ่งมักมีรูปแบบที่หลากหลายและแตกต่างกันไปในแต่ละบุคคล ประกอบกับในปัจจุบันมีไมโครคอนโทรลเลอร์ (Microcontroller, MCU) ที่มีความสามารถมากขึ้นทำให้สามารถใช้โมเดลการเรียนรู้ของเครื่องขนาดเล็ก (TinyML) ให้สามารถทำงานบน MCU ได้

งานวิจัยนี้จึงมีเป้าหมายในการพัฒนาระบบจำแนกคลื่นไฟฟ้าหัวใจ 3 ชนิด ได้แก่ ภาวะหัวใจเต้นจังหวะปกติ (Normal sinus rhythm หรือชนิด N) ภาวะหัวใจเต้นก่อนเวลา (Premature Contractions หรือชนิด P) และภาวะหัวใจห้องบนสั่นพลิ้ว (Atrial Fibrillation หรือชนิด A) ซึ่งเป็นการตรวจจับแบบเวลาจริงด้วยไมโครคอนโทรลเลอร์ โดยใช้การเรียนรู้ของเครื่องโมเดล Extreme Gradient Boosting (XGBoost) ที่คณะผู้วิจัย [4] ได้เคยนำเสนอไว้ โดยงานวิจัยจะใช้โมเดลดังกล่าวมาเลือกลักษณะเด่นเพื่อหาหลักเกณฑ์ที่ดีที่สุดโดยวัดจากผลลัพธ์จากชุดข้อมูลทดสอบ จากนั้นจะทำการนำโมเดลเข้าไปในไมโครคอนโทรลเลอร์พลังงานต่ำเพื่อทดสอบการประมวลผลสัญญาณคลื่นไฟฟ้าหัวใจและการตรวจจับภาวะหัวใจเต้นผิดจังหวะแบบเวลาจริงเพื่อดูค่าความแม่นยำจากผลลัพธ์และสรุปผลด้วยเกณฑ์วัดผลทางสถิติ

## 2. ระเบียบวิธีวิจัยและวัสดุอุปกรณ์

ขั้นตอนวิธีการทำงานโดยรวมของระบบที่พัฒนาขึ้นเป็นดังแสดงในรูปที่ 1 โดยเริ่มจากฝั่งคอมพิวเตอร์ (PC) ซึ่งเป็นส่วนที่ใช้ในการพัฒนาและเตรียมโมเดลการเรียนรู้ของเครื่อง ขั้นตอนนี้เริ่มจากการคัดเลือกลักษณะเด่น (Feature Selection) โดยใช้โมเดล XGBoost ทดลองประมวลผลร่วมกับชุดลักษณะเด่นหลายแบบเพื่อค้นหาชุดลักษณะเด่นที่เหมาะสมที่สุด จากนั้นจึงเลือกชุดลักษณะเด่นที่ให้ค่าความแม่นยำในการตรวจจับสูงสุดมาใช้ จากนั้นการนำเข้าโมเดล (Model Deployment) ที่พัฒนาขึ้นจากฝั่งคอมพิวเตอร์ (PC) ไปยังฝั่งของไมโครคอนโทรลเลอร์พลังงานต่ำผ่านเครื่องมือ X-Cube AI (STMicroelectronics, USA)

ในการตรวจจับภาวะหัวใจเต้นผิดจังหวะแบบตามเวลาจริงโดยไมโครคอนโทรลเลอร์นั้นจะเริ่มต้นด้วยการรับสัญญาณคลื่นไฟฟ้าหัวใจแบบตามเวลาจริงที่มีความถี่ 200 Hz เป็นระยะเวลา 30 วินาทีผ่านตัวแปลงสัญญาณแอนะล็อกเป็นดิจิทัล (ADC) ของไมโครคอนโทรลเลอร์ จากนั้นสัญญาณ ECG ที่ได้รับเข้ามาจะถูกประมวลผลเพื่อตรวจจับคลื่น QRS ซึ่งหลังจากพบคลื่น QRS แล้วจะทำการสกัดลักษณะเด่น (Feature Extraction) ที่มีประสิทธิภาพสูงต่อการจำแนกภาวะผิดปกติ และส่งต่อลักษณะเด่นไปยังส่วนการจำแนกประเภท (Classification) เพื่อแยกแยะภาวะหัวใจเต้นผิดจังหวะ ในขั้นตอนนี้ระบบจะใช้โมเดลการเรียนรู้ของเครื่องที่นำเข้าผ่านเครื่องมือ X-Cube AI โดยผลลัพธ์ที่ได้จะถูกนำไปสู่ขั้นตอนสุดท้ายคือการประเมินผลลัพธ์ (Result Evaluation) เพื่อวิเคราะห์



รูปที่ 1 แผนผังแสดงขั้นตอนการทำงานของระบบที่พัฒนาขึ้น

และตรวจสอบความแม่นยำของระบบในการตรวจจับภาวะคลื่นไฟฟ้าหัวใจผิดปกติ ได้แก่ หัวใจเต้นจังหวะปกติ (N), ภาวะหัวใจเต้นก่อนเวลา (P) และภาวะหัวใจห้องบนสั่นพลิ้ว (A) โดยมีการวัดผลด้วยเกณฑ์ทางสถิติ

### 2.1 การเลือกลักษณะเด่นด้วย XGBoost

ในงานวิจัยนี้จะใช้ชุดลักษณะเด่นจำนวน 7 ตัว [4] ที่สกัดมาจากฐานข้อมูลคลื่นไฟฟ้าหัวใจ 2 ชุดข้อมูล คือ MIT-BIH Arrhythmia Database และ Long-Term AF Database [5] โดยมีจำนวนตัวอย่างสำหรับชุดข้อมูลการฝึก 16,191 ส่วนย่อย (segments) และจำนวนตัวอย่างสำหรับชุดข้อมูลการทดสอบ 2,631 ส่วนย่อย ที่ใช้อัตราการสุ่มตัวอย่าง 200 Hz และแบ่งสัญญาณคลื่นไฟฟ้าหัวใจเป็นช่วงละ 30 วินาที โดยทดสอบกับลักษณะเด่นทั้งหมดจำนวน 7 ตัว ได้แก่ 1. ค่าเฉลี่ยของ RR interval (Mean RR) 2. ค่าเฉลี่ยของความแตกต่างของ RR interval (Mean  $\Delta$ RR) 3. สัดส่วนของคู่ RR ที่มีผลต่างเกิน 20 มิลลิวินาที (pNN20) 4. ค่า Shannon Entropy ของ RR interval (ShEn RR) 5. ค่า Shannon Entropy ของความแตกต่างของ RR interval (ShEn  $\Delta$ RR) 6. ค่าสัมประสิทธิ์ Sample Entropy ของช่วงเวลา RR (COSEn RR) 7. ค่าสัมประสิทธิ์ Sample Entropy ของค่าความแตกต่างของ RR interval (COSEn  $\Delta$ RR)

เพื่อค้นหาชุดลักษณะเด่นที่ดีที่สุด จึงโดยทดสอบด้วยวิธีการจัดหมู่ (Combination) โดยใช้สมการที่ (1)

$$C(n, k) = \frac{n!}{k!(n-k)!} \quad (1)$$

โดย  $n$  คือ จำนวนลักษณะเด่นทั้งหมด  $k$  คือจำนวนลักษณะเด่นที่เลือกออกมา โดยเลือกกลุ่มลักษณะเด่นที่ไม่ซ้ำกันตั้งแต่ 3 ไปจนถึงทั้งหมด 7 ตัว โดยการคำนวณค่าของลักษณะเด่นจำนวน 7 ตัวนี้แบบตามเวลาจริงด้วยไมโครคอนโทรลเลอร์จะอธิบายในรายละเอียดในหัวข้อต่อไป

#### 2.1.1 Extreme Gradient Boosting

โมเดล XGBoost ถูกใช้ในการประมวลชุดลักษณะเด่น ซึ่งอัลกอริทึมนี้จัดอยู่ในการเรียนรู้ของเครื่องแบบมีผู้สอน (supervised learning) โดย

อาศัยข้อมูลฝึกฝนซึ่งประกอบด้วยชุดลักษณะเด่นเพื่อสร้างแบบจำลองสำหรับทำนายตัวแปรเป้าหมาย (Target Variable) ซึ่งโมเดลนี้ใช้กลุ่มของต้นไม้ตัดสินใจ (Tree Ensemble) ซึ่งเป็นการสร้างโมเดลจากการรวมผลการทำนายของต้นไม้เพื่อการจำแนกและถดถอย (Classification and Regression Trees, CART) หลายต้นเข้าด้วยกัน ในทางคณิตศาสตร์โมเดลนี้สามารถแสดงได้ในรูปแบบของสมการที่ (2)

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (2)$$

ซึ่ง  $\hat{y}_i$  คือ ค่าที่โมเดลทำนายสำหรับข้อมูลตัวที่  $i$  ตัว  $K$  คือ จำนวนต้นไม้ทั้งหมดในโมเดล  $f_k$  คือ ฟังก์ชันที่แสดงโครงสร้างและการทำนายของต้นไม้ต้นที่  $k$  ตัวแปร  $x_i$  คือ เวกเตอร์ของคุณลักษณะ (feature vector) ของข้อมูลตัวที่  $i$  ตัวแปร  $F$  คือ เซตของต้นไม้ CART ทั้งหมด สำหรับกระบวนการเรียนรู้หรือการสร้างต้นไม้แต่ละต้นจะสร้างจากฟังก์ชันวัตถุประสงค์ (Objective Function) ดังในสมการที่ (3)

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \omega(f_k) \quad (3)$$

ฟังก์ชันดังกล่าวประกอบด้วยสองส่วนดังนี้  $l(y_i, \hat{y}_i)$  คือ ค่าความสูญเสียในการฝึกฝน (Training Loss) จะวัดความแตกต่างระหว่างค่าที่โมเดลทำนาย  $\hat{y}_i$  กับค่าจริง  $y_i$  และรวมผลของข้อมูลทุกตัวตั้งแต่ตัวที่ 1 จนถึงตัวที่  $n$  เพื่อให้ได้ค่าความผิดพลาดโดยรวมของโมเดล ส่วน  $\omega(f_k)$  คือ ส่วนที่ควบคุมไม่ให้โมเดลมีความซับซ้อนมากเกินไปและรวมค่าความซับซ้อนของต้นไม้ทุกต้นตั้งแต่ต้นที่ 1 จนถึงต้นที่  $t$  เพื่อป้องกันการเกิด Overfitting ของโมเดล

## 2.1.2 การประเมินประสิทธิภาพโมเดล

ในการประเมินประสิทธิภาพของโมเดลที่พัฒนาขึ้น ใช้ค่าทางสถิติตามรูปแบบนี้ True Positive (TP) คือ จำนวนผลบวกจริง False Positive (FP) คือ จำนวนผลบวกлож FN (False Negative) คือ จำนวนผลลบлож True Negative (TN) คือ จำนวนผลลบจริง หลังจากที่ได้ค่าทางสถิติจะใช้เกณฑ์การวัดผลด้วยตัวชี้วัดนี้ ได้แก่

ความเที่ยง (Precision) ใช้วัดข้อมูลทั้งหมดที่โมเดลทำนายว่าเป็นคลาสเป้าหมาย มีข้อมูลที่ถูกต้องอยู่เท่าไร โดยคำนวณได้จากสมการที่ (4)

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

ความไว (Recall) ใช้วัดความสามารถของโมเดลว่าในบรรดาข้อมูลที่เป็นคลาสเป้าหมายจริงทั้งหมด โมเดลสามารถตรวจจับได้ไวเท่าไร โดยคำนวณได้จากสมการที่ (5)

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

F1-Score เป็นค่าเฉลี่ยฮาร์โมนิกระหว่าง Precision และ Recall ใช้ในกรณีที่ต้องการให้ความสำคัญกับทั้งสองค่าเท่าๆกัน โดยคำนวณได้จาก

สมการที่ (6)

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

โดยการประเมินเพื่อเลือกใช้คุณลักษณะเด่นที่ดีที่สุดจากชุดที่มีความแม่นยำโดยรวม (Overall Accuracy) โดยวัดสัดส่วนของจำนวนที่โมเดลสามารถทำนายได้ถูกต้องต่อจำนวนข้อมูลทั้งหมด โดยคำนวณได้จากสมการที่ (7)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

## 2.1.3 ผลลัพธ์การหาชุดลักษณะเด่นที่ดีที่สุด

ในการทดลองเพื่อค้นหาชุดลักษณะเด่นที่ดีที่สุดจากทั้งหมด 7 ตัวนั้นสามารถสร้างชุดการจัดหมู่ (Combination) ที่แตกต่างกันได้เป็นจำนวนมาก เพื่อความกระชับจึงนำเสนอเฉพาะผลลัพธ์ของชุดการจัดหมู่ที่ดีที่สุดของแต่ละชุดลักษณะเด่น โดยสรุปผลลัพธ์ไว้ดังตารางที่ 1 โดยใช้หลักเกณฑ์การตัดสินใจจากค่าความแม่นยำบนชุดข้อมูลทดสอบที่สูงที่สุด

จากข้อมูลในตารางที่ 1 พบว่า ชุดลักษณะเด่นที่ประกอบด้วย 6 ตัว คือ mean RR, mean  $\Delta$ RR, ShEn RR, ShEn  $\Delta$ RR, COSEn RR และ COSEn  $\Delta$ RR ให้ค่าความแม่นยำโดยรวมบนชุดข้อมูลทดสอบสูงที่สุด โดยมีค่าความแม่นยำบนชุดข้อมูลทดสอบสูงถึง 98.48 % แม้ว่าชุด 7 ตัวจะให้ค่าความแม่นยำสูงกว่าบนชุดข้อมูลฝึก ดังนั้นงานวิจัยนี้จึงเลือกใช้ชุดลักษณะเด่นจำนวน 6 ตัวเป็นชุดสุดท้าย เนื่องจากสะท้อนศักยภาพในการจำแนกบนข้อมูลใหม่ได้ดีกว่าและลดความเสี่ยงของการเกิด Overfitting ของโมเดล

## 2.2 การนำเข้าโมเดล

หลังจากได้โมเดลที่มีความแม่นยำเหมาะสมแล้ว ขั้นตอนต่อไปคือการนำโมเดลไปติดตั้งบนอุปกรณ์ไมโครคอนโทรลเลอร์ ในที่นี้จะใช้เครื่องมือ onnxmltools (ONNX organization, USA) เพื่อแปลงไฟล์โมเดลให้เป็นรูปแบบ ONNX (Open Neural Network Exchange) ซึ่งเป็นรูปแบบกลางที่ออกแบบมาเพื่อแลกเปลี่ยนโมเดลระหว่างแพลตฟอร์มต่างๆและเหมาะสำหรับนำไปปรับใช้ต่อบนระบบอุปกรณ์ฝังตัว

## 2.3 การเตรียมชุดข้อมูลทดสอบบนไมโครคอนโทรลเลอร์

เพื่อทดสอบประสิทธิภาพของโมเดลที่ติดตั้งบนไมโครคอนโทรลเลอร์ได้ทำการเตรียมข้อมูลสำหรับทดสอบ ECG โดยใช้ข้อมูลจาก MIT-BIH Arrhythmia Database ซึ่งผ่านขั้นตอนการเตรียมข้อมูลดังนี้คือ ข้อมูลสัญญาณคลื่นไฟฟ้าหัวใจแต่ละตัวอย่างจะถูกแปลงให้มีอัตราสุ่มตัวอย่าง (resampling) เท่ากับ 200 Hz และมีความยาวชุดละ 30 วินาที ซึ่งข้อมูลจะไม่ซ้ำกับชุดข้อมูลฝึก ได้ทำการสุ่มเลือกสัญญาณมาทั้งสิ้น 150 ตัวอย่าง โดยแบ่งเป็น 3 กลุ่มอย่างชัดเจน ได้แก่ กลุ่มหัวใจเต้นจังหวะปกติ (N) จำนวน 50 ตัวอย่าง กลุ่มภาวะหัวใจเต้นก่อนเวลา (P) จำนวน 50 ตัวอย่าง และกลุ่มภาวะหัวใจห้องบนสั่นพลิ้ว (A) จำนวน 50 ตัวอย่าง

ตารางที่ 1 ตารางสรุปผลชุดลักษณะเด่น

| ชุด<br>ลักษณะเด่น    | ชื่อ<br>ลักษณะเด่น | ค่าที่ใช้ในการประเมินในชุดข้อมูลฝึก (%)   |        |       |          |
|----------------------|--------------------|-------------------------------------------|--------|-------|----------|
|                      |                    | Precision                                 | Recall | F1    | accuracy |
|                      |                    | ค่าที่ใช้ในการประเมินในชุดข้อมูลทดสอบ (%) |        |       |          |
|                      |                    | Precision                                 | Recall | F1    | accuracy |
| 3 ตัวที่ดี<br>ที่สุด | mean $\Delta RR$   | 97.82                                     | 97.82  | 97.82 | 97.82    |
|                      | COSEn RR           | 98.06                                     | 98.02  | 98.02 | 98.02    |
|                      | COSEn $\Delta RR$  |                                           |        |       |          |
| 4 ตัวที่ดี<br>ที่สุด | mean $\Delta RR$   | 97.97                                     | 97.97  | 97.97 | 97.97    |
|                      | pNN20              |                                           |        |       |          |
|                      | ShEn RR            | 98.40                                     | 98.37  | 98.37 | 98.37    |
| 5 ตัวที่ดี<br>ที่สุด | mean RR            | 97.87                                     | 97.87  | 97.87 | 97.87    |
|                      | ShEn RR            |                                           |        |       |          |
|                      | ShEn $\Delta RR$   | 98.41                                     | 98.37  | 98.37 | 98.37    |
| 6 ตัวที่ดี<br>ที่สุด | COSEn RR           |                                           |        |       |          |
|                      | COSEn $\Delta RR$  |                                           |        |       |          |
|                      |                    |                                           |        |       |          |
| 7 ตัว                | mean RR            | 99.11                                     | 99.11  | 99.11 | 99.11    |
|                      | mean $\Delta RR$   |                                           |        |       |          |
|                      | ShEn RR            |                                           |        |       |          |
|                      | ShEn $\Delta RR$   | 98.52                                     | 98.48  | 98.48 | 98.48    |
|                      | COSEn RR           |                                           |        |       |          |
|                      | COSEn $\Delta RR$  |                                           |        |       |          |
| 7 ตัว                | mean RR            | 99.66                                     | 99.66  | 99.66 | 99.66    |
|                      | mean $\Delta RR$   |                                           |        |       |          |
|                      | pNN20              |                                           |        |       |          |
|                      | ShEn RR            | 98.23                                     | 98.17  | 98.17 | 98.17    |
|                      | ShEn $\Delta RR$   |                                           |        |       |          |
|                      | COSEn RR           |                                           |        |       |          |
|                      | COSEn $\Delta RR$  |                                           |        |       |          |

## 2.4 อัลกอริทึมตรวจจับ QRS complex

ในการตรวจจับคลื่น QRS แบบตามเวลาจริงโดยไม่โครคอนโทรลเลอร์ งานวิจัยนี้ใช้อัลกอริทึมที่อ้างอิงหลักการใช้ความชันของสัญญาณ (Steep Slope) ซึ่งถูกพัฒนาโดยคณะผู้วิจัย [6] โดยมีหลักการคือการคำนวณค่าความชันสัมบูรณ์ของสัญญาณ ECG แล้วนำไปเปรียบเทียบกับค่าเกณฑ์ (Threshold) แบบปรับตามสภาพที่เปลี่ยนแปลงไปตามลักษณะของสัญญาณที่ได้รับ อัลกอริทึมนี้มี 2 ช่วงหลักช่วงแรกคือช่วงเรียนรู้ (Learning Phase) โดยใช้ข้อมูลสัญญาณ ECG ในช่วงแรกเพื่อกำหนดค่าเกณฑ์ เพื่อใช้สำหรับช่วงที่สองซึ่งคือช่วงการตรวจจับ (Detection Phase) ที่จะตรวจจับ QRS ได้จากค่าที่เกิน ค่าเกณฑ์ที่กำหนดไว้และมีการปรับค่าเกณฑ์อย่างต่อเนื่องเพื่อใช้ตรวจจับ QRS ในสัญญาณคลื่นไฟฟ้าหัวใจลูกต่อไป

## 2.5 อัลกอริทึมสกัดลักษณะเด่น

ในส่วนนี้จะอธิบายถึงลักษณะเด่นต่างๆที่ถูกสกัดจากสัญญาณ ECG หลังผ่านกระบวนการตรวจจับ QRS complex แล้ว โดยอ้างอิงจากผลการ

ทดลองในหัวข้อ 2.1.3 ซึ่งได้คัดเลือกชุดลักษณะเด่นที่ดีที่สุดมาใช้งาน ดังรายละเอียดในหัวข้อย่อยต่อไปนี้

### 2.5.1 ลักษณะเด่นเชิงเวลา

ลักษณะเด่นในกลุ่มนี้คำนวณจากระยะเวลาของช่วงคลื่นต่างๆหลังการตรวจจับตำแหน่งของ QRS complex แบบตามเวลาจริง โดยมีพื้นฐานจากค่าหลักดังนี้ RR interval คือ ระยะเวลาระหว่าง QRS complex สองจุดติดกัน ซึ่งคำนวณจากตำแหน่งของ QRS complex ลำดับที่  $i + 1$  และ  $i$  ตามสมการที่ (8) โดย  $fs$  คือ อัตราการสุ่มตัวอย่างของสัญญาณ ECG (กำหนดไว้ที่ 200 Hz ในงานวิจัยนี้) ทำให้สามารถแปลงค่าระยะห่างระหว่างตำแหน่งให้เป็นหน่วยวินาทีได้

$$RR_i = \frac{QRS[i+1] - QRS[i]}{fs} \quad (8)$$

ค่าความแตกต่างของ RR ( $\Delta RR$ ) คือ ค่าความแตกต่างของ RR interval ที่อยู่ติดกัน ซึ่งคำนวณตามสมการที่ (9)

$$\Delta RR_i = RR_{i+1} - RR_i \quad (9)$$

จากค่าพื้นฐานทั้งสองนี้ สามารถนำมาหาค่าเฉลี่ยเพื่อใช้เป็นลักษณะเด่น mean RR และ mean  $\Delta RR$

### 2.5.2 ลักษณะเด่นเชิงเอนโทรปี

Shannon Entropy (ShEn) เป็นลักษณะเด่นวัดปริมาณความไม่แน่นอนของสัญญาณ ECG ซึ่งใช้การกระจายความน่าจะเป็นของข้อมูลซึ่งซึ่งคำนวณได้จากสมการที่ (10)

$$ShEn = - \sum_{i=1}^N p(i) \log_2 p(i) \quad (10)$$

โดยที่  $N$  คือ จำนวน bin ใน histogram ของชุดข้อมูลเวลา และ  $p(i)$  คือ ความน่าจะเป็นที่ค่าของสัญญาณจะอยู่ใน bin ที่  $i$  ซึ่งค่าของ ShEn จะสูงขึ้นเมื่อการกระจายมีความไม่แน่นอนหรือคาดเดาได้ยาก และจะต่ำลงเมื่อการกระจายสามารถคาดเดาได้ง่าย จากการคำนวณ ShEn สามารถนำค่าที่ได้ไปใช้เป็นลักษณะเด่น ShEn RR และ ShEn  $\Delta RR$

Coefficient of Sample Entropy (COSEn) เป็นลักษณะเด่นที่ใช้ในการวัดความซับซ้อนของอนุกรมเวลา ที่คำนวณโดยการปรับแก้ค่า Sample Entropy (SampEn) ด้วยค่าความคลาดเคลื่อน  $r$  และค่าเฉลี่ยของช่วงเวลา RR ดังสมการที่ (11)

$$COSEn(x) = SampEn(x) - \ln(2r) - \ln(RR_{avg}) \quad (11)$$

โดยเราสามารถหา SampEn จากความน่าจะเป็นที่ลำดับข้อมูลสองชุดซึ่งมีความคล้ายคลึงกันภายในค่าความคลาดเคลื่อน  $r$  สำหรับความยาว  $m$  จะยังคงมีความคล้ายคลึงกันเมื่อเพิ่มความยาวเป็น  $m$  โดยคำนวณจากสมการที่ (12)


$$SampEn(m, r) = - \ln\left(\frac{A}{B}\right) \quad (12)$$

ซึ่ง  $A$  คือ จำนวนคู่ของรูปแบบที่มีความยาว  $m+1$  ซึ่งมีระยะห่างระหว่างกันไม่เกินค่า  $r$  และ  $B$  คือ จำนวนคู่ของรูปแบบที่มีความยาว  $m$  ซึ่งมีระยะห่างระหว่างกันไม่เกินค่า  $r$  โดยค่า SampEn ที่ต่ำบ่งบอกถึงข้อมูลเป็นระเบียบและรูปแบบที่คาดเดาได้ที่ง่ายกว่า ในขณะที่ค่าที่สูงขึ้นแสดงถึงสัญญาณมีความซับซ้อนและคาดเดาได้ยาก

จากการคำนวณ COSEn แบบตามเวลาจริงโดยไม่โครคอนโทรลเลอร์สามารถนำค่าที่ได้ไปใช้เป็นลักษณะเด่น COSEn RR และ COSEn  $\Delta$ RR

## 2.6 อุปกรณ์และระบบที่ใช้ในการทดลอง

ในส่วนนี้จะอธิบายถึงอุปกรณ์ฮาร์ดแวร์และโครงสร้างของระบบฝังตัวที่ใช้ในการพัฒนาและทดสอบประสิทธิภาพของอัลกอริทึมวิเคราะห์สัญญาณ ECG แบบตามเวลาจริงดังแสดงในรูปที่ 2 แผนผังการออกแบบระบบฝังตัวสำหรับการประมวลผลสัญญาณ



รูปที่ 2 การออกแบบระบบฝังตัวสำหรับการประมวลผล

### 2.6.1 ตัวจำลองสัญญาณ ESP32 D32 Pro

โมดูล ESP32 D32Pro (Espressif Systems (Shanghai) Co., Ltd., China) ซึ่งมีช่อง SD Card ในตัว ทำหน้าที่อ่านข้อมูลสัญญาณ ECG ที่จัดเก็บไว้ใน SD Card และส่งข้อมูลดิจิทัลนี้ไปยังโมดูล DAC ผ่านโปรโตคอล I2C เพื่อจำลองการเกิดสัญญาณอย่างต่อเนื่อง

### 2.6.2 ตัวแปลงสัญญาณ DAC MCP4725

โมดูล MCP4725 (Microchip Technology Inc., USA) เป็นตัวแปลงสัญญาณดิจิทัลเป็นแอนะล็อก (DAC) ความละเอียด 12 บิต ทำหน้าที่รับข้อมูลดิจิทัลจาก ESP32 และแปลงเป็นสัญญาณไฟฟ้าแอนะล็อก

### 2.6.3 หน่วยประมวลผลหลัก NUCLEO-L476RG

บอร์ด NUCLEO-L476RG (STMicroelectronics, France) ทำหน้าที่เป็นหน่วยประมวลผลหลักของระบบ โดยจะรับสัญญาณแอนะล็อก ECG จากโมดูล DAC จากนั้นแปลงกลับเป็นข้อมูลดิจิทัลด้วยตัวแปลงสัญญาณแอนะล็อกเป็นดิจิทัล (ADC) ที่อยู่ภายในเพื่อนำไปประมวลผลด้วยอัลกอริทึมที่พัฒนาขึ้น หลังจากการประมวลผลบอร์ดจะส่งผลลัพธ์จากการจำแนกออกมาเป็น N (หัวใจเต้นจังหวะปกติ), P (ภาวะหัวใจเต้นก่อนเวลา)

และ A (ภาวะหัวใจห้องบนสั่นพลิ้ว) ผ่านพอร์ตอนุกรม (UART) ไปยังเครื่องคอมพิวเตอร์หรืออุปกรณ์แสดงผลภายนอกเพื่อแสดงผลลัพท์แบบตามเวลาจริง


### 2.6.4 เครื่องมือแปลงโมเดล STM32 X-Cube-AI

X-Cube-AI เป็นเครื่องมือจาก STMicroelectronics ที่ใช้สำหรับแปลงโมเดลปัญญาประดิษฐ์ (AI Model) ที่สร้างจากเฟรมเวิร์กต่างๆ เช่น TensorFlow Lite ให้กลายเป็นโค้ดภาษา C ที่สามารถทำงานได้ที่สามารถทำงานได้บนไมโครคอนโทรลเลอร์ตระกูล STM32

ซึ่งโมเดล XGBoost ที่ผ่านการฝึกสอนแล้วและถูกแปลงให้อยู่ในรูปแบบ ONNX จะถูกนำไปเข้าเครื่องมือ X-Cube-AI เพื่อแปลงให้เป็นไลบรารีภาษา C ที่ปรับแต่งมาโดยเฉพาะ ไลบรารีดังกล่าวสามารถถูกนำไปผนวกรวมกับโปรแกรมหลักผ่าน STM32CubeMX และเรียกใช้งานฟังก์ชันสำหรับประมวลผลบนไมโครคอนโทรลเลอร์ STM32L476 ได้โดยตรง หลังจากการแปลงโมเดลพบว่าไลบรารีที่ได้ใช้ทรัพยากรหน่วยความจำของไมโครคอนโทรลเลอร์ชนิด Flash และชนิด RAM เท่ากับ 270.75 KiB (26.4%) และ 1.78 KiB (1.4%) ตามลำดับ

## 3. ผลการทดลอง

รูปที่ 3 แสดง Confusion Matrix ของผลการทดสอบโมเดลบนชุดข้อมูลทดสอบจำนวนทั้งหมด 150 ตัวอย่าง



รูปที่ 3 แผนภาพ Confusion Matrix แสดงผลการทดสอบ

จากรูปที่ 3 สามารถวิเคราะห์ผลการทำงานของโมเดลในแต่ละคลาสได้ โดยในคลาส N (หัวใจเต้นจังหวะปกติ) โมเดลทายผลสัญญาณ N ทั้ง 50 ตัวอย่างได้ถูกต้องทั้งหมด ในคลาส P (ภาวะหัวใจเต้นก่อนเวลา) โมเดลสามารถทายผลถูกต้องว่าเป็นคลาส P จำนวน 37 ตัวอย่าง และทายผลผิดพลาดว่าเป็นคลาส A (ภาวะหัวใจห้องบนสั่นพลิ้ว) จำนวน 13 ตัวอย่าง ในคลาส A โมเดลสามารถทายผลถูกต้องว่าเป็นคลาส A จำนวน 49 ตัวอย่าง และทายผลผิดพลาดว่าเป็นคลาส P จำนวน 1 ตัวอย่าง ซึ่งสรุปค่า Precision, Recall, F1-score สำหรับแต่ละคลาสทั้งหมดลงในตารางที่ 2 ซึ่งนำมาคำนวณค่า Overall Accuracy ได้เท่ากับ 90.67%



ตารางที่ 2 ผลลัพธ์ทางสถิติของโมเดลในการจำแนกสัญญาณ

| คลาส | Precision (%) | Recall (%) | F1-Score (%) |
|------|---------------|------------|--------------|
| N    | 100           | 100        | 100          |
| P    | 97.36         | 74         | 84.08        |
| A    | 79.03         | 98         | 87.49        |

#### 4. อภิปราย

งานวิจัยที่ใกล้เคียงกับงานวิจัยนี้คือ [7] ซึ่งพัฒนาระบบตรวจจับภาวะหัวใจเต้นผิดจังหวะบนอุปกรณ์ฝังตัวเช่นเดียว โดยได้ทำการเปรียบเทียบงานวิจัยทั้งสองนี้ดังตารางที่ 3

ตารางที่ 3 การเปรียบเทียบประสิทธิภาพบนอุปกรณ์ฝังตัวกับงานวิจัยอื่น

| การเปรียบเทียบ                         | งานวิจัยนี้                                    | งานวิจัยอื่น [7]    |
|----------------------------------------|------------------------------------------------|---------------------|
| โมเดลการเรียนรู้ของเครื่อง             | XGBOOST                                        | VSDTLBP+SVM         |
| ไมโครคอนโทรลเลอร์                      | STM32L476RG                                    | STM32F413ZH         |
| ภาวะหัวใจเต้นผิดจังหวะที่สามารถตรวจจับ | Atrial Fibrillation และ Premature Contractions | Atrial Fibrillation |
| Dataset ที่ใช้ในการฝึกและทดสอบโมเดล    | MITBIH และ LTAF-DB                             | AFDB                |
| หน่วยความจำแบบ Flash                   | 270.75 KiB                                     | 132.86 KB           |
| ความแม่นยำ (Accuracy) ในการตรวจจับ     | 90.67%                                         | 99.45%              |

จากตารางที่ 3 งานดังกล่าว [7] ได้ใช้โมเดล SVM ด้วยความแม่นยำสูงถึง 99.45% ด้วยขนาดโมเดล 132.86 KB อย่างไรก็ตามงานวิจัยดังกล่าวมุ่งเน้นการแก้ปัญหาแบบ 2 คลาส คือ Atrial Fibrillation และ Non-Atrial Fibrillation แต่ในงานวิจัยนี้ได้จัดการกับปัญหาที่ซับซ้อนขึ้นด้วยการจำแนกแบบ 3 คลาส โดยระบบได้ให้ค่าความแม่นยำบนอุปกรณ์ฝังตัวอยู่ที่ 90.67%

ดังนั้นแม้ว่าโมเดลที่พัฒนาขึ้นในงานวิจัยนี้จะมีขนาดใหญ่กว่าที่ 270.75 KiB และมีค่าความแม่นยำที่ต่ำกว่า แต่ระบบที่พัฒนาขึ้นสามารถตรวจจับความผิดปกติได้หลากหลายกว่า ซึ่งตอบโจทย์การใช้งานในโลกจริงที่ผู้ป่วยอาจมีภาวะหัวใจเต้นผิดจังหวะได้หลายรูปแบบ แต่อย่างไรก็ดีข้อมูลคลื่นไฟฟ้าหัวใจที่นำมาใช้ของสองงานวิจัยนี้มาจากฐานข้อมูลที่แตกต่างกันจึงอาจไม่สามารถเปรียบเทียบประสิทธิภาพของระบบที่พัฒนาขึ้นทั้งสองนี้ได้อย่างแม่นยำ

#### 5. สรุป

จากการทดสอบโมเดลบนระบบฝังตัวจริง พบว่าโมเดลมีความแม่นยำโดยรวม 90.67% ซึ่งแม้ว่าจะเป็นค่าประสิทธิภาพที่สูง แต่ยังต่ำกว่าผลลัพธ์ที่ได้จากการทดสอบบนชุดข้อมูลทดสอบในคอมพิวเตอร์ที่ได้ค่าความแม่นยำ 98.48% ซึ่งอาจมีสาเหตุมาจากปัจจัยหลายประการร่วมกัน เช่น อัลกอริทึม QRS detection ที่พัฒนาขึ้นสำหรับระบบฝังตัวอาจมีความแตกต่างกันเล็กน้อยจากอัลกอริทึมในงานวิจัยต้นฉบับ จึงส่งผลทำให้การสกัดลักษณะเด่นยังมีความคลาดเคลื่อน ชุดข้อมูลที่ใช้ทดสอบบนระบบจริงมีจำนวนเพียง 150 ตัวอย่าง ซึ่งอาจไม่เป็นตัวแทนของข้อมูลทั้งหมดได้

และมีความเป็นไปได้ที่จะสรุปผลตัวอย่างสัญญาณที่มีความท้าทายในการจำแนกสูง นอกจากนี้กระบวนการแปลงสัญญาณจากดิจิทัลเป็นแอนะล็อก (DAC) และแปลงกลับเป็นดิจิทัล (ADC) ในระบบจริงย่อมมีสัญญาณรบกวนอาจส่งผลกระทบต่อประสิทธิภาพของโมเดลได้ โดยสรุปผลการทดลองนี้ยืนยันว่าโมเดลสามารถทำงานได้จริงบนระบบฝังตัว แม้ว่าประสิทธิภาพจะลดลงเมื่อเผชิญกับเงื่อนไขการทำงานและข้อจำกัดของอุปกรณ์ชนิดฝังตัวที่นำมาใช้งาน ซึ่งจะได้ทำการพัฒนาให้มีความถูกต้องในการตรวจจับคลื่นไฟฟ้าหัวใจแบบตามเวลาจริงบนไมโครคอนโทรลเลอร์พลังงานต่ำให้มีความถูกต้องเพียงพอและเหมาะต่อการใช้งานเป็นอุปกรณ์แบบสวมใส่ต่อไป

#### 6. เอกสารอ้างอิง

- [1] กองยุทธศาสตร์และแผนงาน สำนักงานปลัดกระทรวงสาธารณสุข. (2566). *สรุปรายงานการป่วย*. กรุงเทพฯ, ประเทศไทย: กระทรวงสาธารณสุข, 2566.
- [2] I. Escudero-Martinez et al., "Atrial Fibrillation and Stroke: A Review and New Insights," *Trends in Cardiovascular Medicine*, vol. 33, no. 1, pp. 23-29, 2023.
- [3] U. Ofoma et al., "Premature Cardiac Contractions and Risk of Incident Ischemic Stroke," *Journal of the American Heart Association*, vol. 1, no. 5, Art. no. e002519, 2012.
- [4] T. Tearwattanarattikol et al., "High-precision Rhythm-based Detection of Atrial Fibrillation and Frequent Premature Contractions using Extreme Gradient Boosting," *2023 15th Biomedical Engineering International Conference (BMEiCON)*, Tokyo, Japan, 2023, pp. 1-5.
- [5] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215-e220, Jun. 2000.
- [6] A. Teeramongkonrasme et al., "Performance of a QRS detector on self-collected database using a handheld two-electrode ECG," in *2017 10th Biomedical Engineering International Conference (BMEiCON)*, IEEE, 2017, pp.1-5.
- [7] M. Yazid et al., "Atrial Fibrillation Detection From Electrocardiogram Signal on Low Power Microcontroller," *IEEE Access*, vol. 12, pp. 91590-91604, 2024