

การพัฒนาการเรียนรู้ของเครื่องแบบฝังตัวร่วมกับการเพิ่มข้อมูลด้วยโครงข่ายปฏิกิริยาแบบรู้สร้าง เพื่อตรวจจับ อาการชักเหม่อจากสัญญาณคลื่นไฟฟ้าสมอง

Development of Embedded Machine Learning with GAN-Driven Data Augmentation for EEG- Based Absence Seizure Detection

ฐาปกรณ์ โสภณพงษ์¹ อภิวัฒน์ เล็กอุทัย¹ สุรีย์ พุ่มรินทร์² อภรณ์ อีรมงคลศรี² กฤษณชัย ชมโท³ และ ภาคภูมิ สมบูรณ์¹

¹หลักสูตรวิศวกรรมชีวเวช คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

²ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

³กุมารเวชศาสตร์ คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

บทคัดย่อ

งานวิจัยนี้นำเสนอการพัฒนาแบบตรวจจับอาการชักเหม่อ (Absence Seizure) โดยใช้เทคนิคการเรียนรู้ของเครื่องแบบฝังตัวจากสัญญาณคลื่นไฟฟ้าสมอง (Electroencephalography : EEG) โดยมีเป้าหมายเพื่อให้สามารถตรวจจับอาการชักแบบตามเวลาจริงด้วยไมโครคอนโทรลเลอร์พลังงานต่ำที่เหมาะสมกับการใช้งานในรูปแบบอุปกรณ์สวมใส่หรือพกพาได้ โดยได้นำข้อมูลสัญญาณ EEG มาผ่านกระบวนการกรองสัญญาณ การแบ่งช่วง และใช้เทคนิคโครงข่ายปฏิกิริยาแบบรู้สร้าง (Generative Adversarial Network: GAN) เพื่อเพิ่มปริมาณข้อมูลทดสอบและข้อมูลในการฝึกโมเดลโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) และทำการทดสอบโมเดลที่สร้างขึ้นด้วยสัญญาณ EEG จำนวน 4 ช่องสัญญาณ (F7, F8, T5, T6) จากนั้นลดจำนวนช่องสัญญาณเหลือ 2 และ 1 ช่องสัญญาณตามลำดับ เพื่อปรับขนาดของโมเดลให้สามารถนำเข้าสู่ระบบฝังตัวได้ นอกจากนี้ได้ทดลองกับหน้าต่างของสัญญาณขาเข้าทั้งสองขนาด คือ แบบ 2 วินาทีขยับทีละ 1 วินาทีและ 1 วินาทีขยับทีละ 0.5 วินาที โดยสัญญาณมีอัตราสุ่มตัวอย่าง 200 Hz เพื่อหาการตั้งค่าที่ดีที่สุดผลการทดลองพบว่าโมเดลที่พัฒนาขึ้นโดยใช้สัญญาณจากช่อง F7 และสัญญาณจากอาการชักจำลอง 698 วินาทีเป็นชุดฝึกนั้นสามารถตรวจจับช่วงเวลาที่เกิดอาการชักได้อย่างมีประสิทธิภาพโดยให้ค่าความไว 90.3% ความจำเพาะ 89.5% และสามารถนำโมเดลที่พัฒนาเข้าสู่ระบบฝังตัวได้โดยใช้หน่วยความจำ RAM 23.44 KiB และ หน่วยความจำ Flash 7.97 KiB ซึ่งแสดงให้เห็นถึงความเป็นไปได้ในการนำโมเดล LSTM มาใช้งานจริงบนไมโครคอนโทรลเลอร์พลังงานต่ำ เพื่อพัฒนาอุปกรณ์สวมใส่สำหรับตรวจจับอาการชักแบบตามเวลาจริง

คำสำคัญ: อาการชักเหม่อ, การเรียนรู้ของเครื่องแบบฝังตัว, ไมโครคอนโทรลเลอร์พลังงานต่ำ, อุปกรณ์วัดสัญญาณคลื่นไฟฟ้าสมองแบบพกพา, โครงข่ายปฏิกิริยาแบบรู้สร้าง

Abstract

This research presents a development of a system for detecting absence seizures using embedded machine learning techniques based on electroencephalogram (EEG) signals. The goal is to achieve real-time seizure detection using low-power microcontrollers suitable for wearable or portable devices. The EEG signals were processed through filtering, segmentation, and augmented with synthetic data generated by a Generative Adversarial Network (GAN) to increase both training and testing datasets. A Long Short-Term Memory (LSTM) neural network was employed for classification. The proposed model was tested using EEG signals from four channels (F7, F8, T5, and T6), which were subsequently reduced to two channels and then to a single channel in order to minimize the model size for embedded deployment. Additionally, experiments were conducted with window sizes of 2 seconds with a 1-second stride and 1 second with a 0.5-second stride, where each 1-second signal was sampled at 200 Hz, to identify the optimal configuration. The experimental results showed that the model developed using the F7 channel together with 698 seconds of synthetic seizure data as training input achieved effective detection performance, with a sensitivity of 90.3% and a specificity of 89.5%. Furthermore, the developed model was successfully deployed on an embedded system using only 23.44 KiB of RAM and 7.97 KiB of Flash. These findings demonstrate the feasibility of implementing LSTM models on low-power microcontrollers to develop wearable devices for real-time seizure detection.

Keywords: Absence seizure, Embedded machine learning, Low-power microcontroller, Portable EEG device, Generative Adversarial Network (GAN)

1. บทนำ

โรคลมชัก (epilepsy) เกิดจากการรบกวนของกระแสประสาทในสมองที่ไม่สามารถควบคุมได้ ก่อให้เกิดการเคลื่อนไหว ความรู้สึก หรือพฤติกรรมที่อาจเปลี่ยนแปลงไปทั้งโดยรู้ตัวและไม่รู้ตัวโดยมีผู้ป่วยกว่า 50 ล้านคนทั่วโลกซึ่งทำให้โรคนี้นับเป็นหนึ่งในโรคทางระบบประสาทที่พบบ่อยที่สุด โดยผู้ป่วยโรคนี้อาจเสี่ยงต่อการเสียชีวิตก่อนวัยอันควรสูงกว่าคนทั่วไปถึง 3 เท่า [1] อาการชักแบบเหม่อ (Absence seizure) เป็นอาการชักแบบหนึ่งที่เกิดขึ้นชั่วคราว ผู้ป่วยจะ “เหม่อลอย” โดยไม่รู้ตัว ไม่ตอบสนองต่อสิ่งกระตุ้น และอาจหยุดการกระทำกลางคัน ระยะเวลาของการชักแต่ละครั้งประมาณ 5-10 วินาที [2] โดยทั่วไปเกิดในเด็กแต่สามารถเกิดได้ทุกวัย และมักไม่ถูกสังเกตเห็น ทำให้การวินิจฉัยล่าช้าและไม่สามารถดูแลผู้ป่วยได้อย่างทันท่วงที

การวินิจฉัยอาการชักแบบเหม่อจะใช้การตรวจคลื่นไฟฟ้าสมอง (Electroencephalogram: EEG) ซึ่งจะตรวจจบบรูปแบบคลื่นไฟฟ้าสมองผิดปกติ เช่น คลื่น 3 Hz spike-and-wave เป็นคลื่นที่บ่งบอกถึง EEG แบบชักเหม่อ โดยการตรวจสัญญาณคลื่นไฟฟ้าสมองในโรงพยาบาลยังมีข้อจำกัด เช่น ระยะเวลาสั้น จึงอาจตรวจพบไม่อาการ ทางเลือกหนึ่งที่น่าสนใจคือ การใช้อุปกรณ์แบบสวมใส่ (Wearable Devices) เพื่อตรวจจับอาการชักแบบเวลาจริง โดยมีงานวิจัยที่ [3-4] ได้มุ่งเน้นไปที่การตรวจจับอาการชักทั่วไปอย่างมีประสิทธิภาพด้านพลังงาน โดยใช้โมเดลขนาดเล็กประเภท CNN และ LSTM ผ่านอุปกรณ์ไมโครคอนโทรลเลอร์พลังงานต่ำ เช่น Apollo3 และ MSP430 แม้จะได้ผลลัพธ์ที่ดี แต่ก็ยังไม่ครอบคลุมการตรวจจับอาการชักเหม่อและใช้สัญญาณ EEG หลายช่อง (4 ช่อง) ในการตรวจวัด ขณะที่งานวิจัย [5] ที่สามารถตรวจจับอาการชักเหม่อได้อย่างแม่นยำโดยใช้อุปกรณ์วัด EEG แบบคาดศีรษะโดยใช้สัญญาณ EEG 1 ช่องสัญญาณ (Fp1) ร่วมกับโครงข่ายประสาทแบบคอนโวลูชัน (CNN) ที่ทำงานตามเวลาจริงได้ โดยทำงานร่วมกับสมาร์ทโฟน และยังมีงานวิจัย [6] ที่ใช้ EEG 2 ช่องสัญญาณ (F7-T7 และ F8-T8) ซึ่งแม้จะได้ความแม่นยำที่สูงแต่การประมวลผลต้องอาศัยการเชื่อมต่อกับบริการคลาวด์ และงานวิจัย [7] ได้ใช้ EEG เพียงช่องสัญญาณเดียว (Fp1-F7) และสามารถตรวจจับอาการชักเหม่อได้โดยใช้ SVM แบบออฟไลน์ใน MATLAB แต่ยังไม่ได้ทดสอบใช้งานในอุปกรณ์จริง จากงานวิจัยดังกล่าวข้างต้น [6-7] มีข้อจำกัดหากการเชื่อมต่อกับคลาวด์มีปัญหา ดังนั้นอุปกรณ์ตรวจจับที่ใช้เทคนิคการเรียนรู้ของเครื่องแบบฝังตัว (Embedded Machine Learning) มีข้อดีหลายอย่าง เช่น พลังงานต่ำ ราคาไม่แพง ประมวลผลได้ทันที โดยไม่ต้องพึ่งการเชื่อมต่อกับคลาวด์ งานวิจัย [8] ได้แสดงให้เห็นว่าการฝังโมเดลการเรียนรู้ลงบนไมโครคอนโทรลเลอร์พลังงานต่ำคือ STM32L476 สามารถใช้ตรวจจับอาการชักได้จริง โดยใช้โมเดล Random Forest และสัญญาณ


EEG 2 ช่อง (F7-T7 และ F8-T8) สำหรับการวิเคราะห์แบบเวลาจริงบนอุปกรณ์พกพา อย่างไรก็ตาม โมเดลการเรียนรู้ของเครื่องจากงานวิจัยนี้ยังมีข้อจำกัดด้านความสามารถในการเรียนรู้ความผันผวนที่เกิดขึ้นตลอดเวลา (temporal dynamics) ของสัญญาณ EEG และได้มีงานวิจัย [9] ที่นำเสนอการใช้โมเดล LSTM สำหรับตรวจจับการชักเหม่อโดยฝังลงบนไมโครคอนโทรลเลอร์ STM32L432KC พร้อมทดสอบการใช้ข้อมูล EEG ทั้งแบบ 21 ช่องและ 4 ช่อง (F7, F8, T5, T6) แต่ก็ยังมีความต้องการในการใช้ช่องสัญญาณจำนวนมากซึ่งอาจยังไม่เหมาะกับการนำไปใช้เป็นอุปกรณ์ในลักษณะพกพา

งานวิจัยนี้มีวัตถุประสงค์ในการพัฒนาระบบตรวจจับอาการชักเหม่อที่ใช้การเรียนรู้ของเครื่องแบบฝังตัว (Embedded ML) โดยใช้โมเดล LSTM ซึ่งเหมาะกับข้อมูลลำดับเวลา พร้อมทั้งใช้เทคนิคโครงข่ายปฏิปักษ์แบบรู้สร้าง (GAN) เพื่อเพิ่มข้อมูลสัญญาณ EEG เมื่ออาการชักสำหรับใช้เป็นชุดฝึกและชุดทดสอบเพื่อพัฒนาโมเดล และทำการทดลองเพื่อลดจำนวนช่อง EEG ให้เหมาะสำหรับการใช้งานเป็นอุปกรณ์แบบพกพาโดยใช้ไมโครคอนโทรลเลอร์พลังงานต่ำ สำหรับคนไข้ในโรคนี้นี้ต่อไป

2. วิธีการดำเนินงาน

2.1 การเลือกสัญญาณ EEG ที่นำมาใช้งาน

แผ่นโลหะขนาดเล็กที่เรียกว่า อิเล็กโทรด ซึ่งเชื่อมต่อกับสายนำสัญญาณ ซึ่งจะถูกติดไว้บนหนังศีรษะด้วยกาวชนิดที่สามารถลอกออกได้ โดยมีรูปแบบการติดตั้งอิเล็กโทรดตามระบบ 10/20 โดยตัวเลข 10/20 หมายถึงระยะห่างระหว่างอิเล็กโทรดคิดเป็น 10% หรือ 20% ของความยาวกะโหลกศีรษะในแนวต่างๆ ดังแสดงในรูปที่ 1





(ที่มา: <https://www.biorender.com/template/eeeg-electrode-positioning-1020-system>)

รูปที่ 1 ระบบอิเล็กโทรดแบบ 10/20 และตำแหน่งที่เลือกใช้ในงานวิจัยนี้

โดยในงานวิจัยนี้จะเลือกใช้ 4 ช่องสัญญาณคือ F7, F8, T5 และ T6 เป็นตำแหน่งที่ครอบคลุมหลายบริเวณของสมองโดยอ้างอิงจากงานวิจัย [7-9] ที่สามารถใช้จุดเหล่านี้ในการตรวจจับอาการชัก โดยจะทำการทดสอบหาจำนวนช่องสัญญาณที่น้อยที่สุดเพื่อให้เหมาะสมกับการพัฒนาเป็นอุปกรณ์แบบพกพาโดยยังรักษาความแม่นยำในการตรวจจับการชักให้เพียงพอต่อการนำไปใช้งาน

2.2 การเพิ่มสัญญาณ EEG ด้วย GAN

โครงข่ายปฏิภณแบบรู้สร้าง (Generative Adversarial Network : GAN) เป็นการใ้การเรียนรู้เชิงลึก (Deep learning) ในการเรียนรู้และจำลองข้อมูลขึ้นมาโดยมี 2 ส่วนหลักคือตัวสร้างและตัวแยกแยะทำงานควบคู่กันดังแสดงในรูปที่ 2 เพื่อให้ได้สัญญาณ EEG เทียมสำหรับการฝึกโมเดลให้มีประสิทธิภาพมากยิ่งขึ้น โดยสัญญาณ EEG ที่สร้างขึ้นด้วย GAN เทียบกับสัญญาณจริงเป็นดังแสดงในรูปที่ 3




รูปที่ 3 การเปรียบเทียบสัญญาณของอาการชัก 1 วินาทีของช่องสัญญาณ F7 ระหว่าง EEG จริงและ EEG เทียมที่สร้างขึ้นจาก GAN


จากรูปที่ 3 แสดงให้เห็นว่ารูปแบบสัญญาณของสัญญาณจริงกับสัญญาณเทียมที่สร้างขึ้นด้วย GAN มีความใกล้เคียงกันซึ่งจะสามารถนำมาใช้แทนสัญญาณจริงเพื่อให้ชุดฝึกของโมเดลการเรียนรู้ของเครื่องได้ต่อไป

2.3 การฝึกโมเดลการเรียนรู้ของเครื่อง

ฝึกโมเดลโดยใช้สัญญาณ EEG ที่มีความถี่การสุ่มตัวอย่าง 200 Hz จาก 4 ตำแหน่งอิเล็กโทรดเป็นเวลา 1,503 วินาที โดยตัดช่วงวินาทีที่ 750 ถึงวินาทีที่ 1,300 เป็นข้อมูลสำหรับทดสอบโมเดลเนื่องจากเป็นช่วงที่มีปริมาณอาการชักเหมือนและอาการปกติเท่าๆ กัน จากนั้นทำส่วนที่เหลือมาแทรกด้วยสัญญาณชักจำลองที่สร้างด้วยโมเดล GAN ดังที่แสดงในรูปที่ 4 หลังจากนั้นนำข้อมูลที่แทรกด้วย GAN เสร็จแล้วไปใช้ฝึกโมเดล 2 แบบคือ 1. ฝึกโดยใช้สัญญาณที่มีขนาดหน้าต่าง 2 วินาทีขยับทีละ 1 วินาที 2. ฝึกโดยใช้สัญญาณที่มีขนาดหน้าต่าง 1 วินาทีขยับทีละ 0.5 วินาที โมเดลที่ใช้จำแนกคือ โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) และมีโครงสร้างโมเดลดังแสดงในรูปที่ 5



รูปที่ 4 การเตรียมข้อมูลสำหรับฝึกโมเดล




รูปที่ 5 โครงสร้างโมเดล LSTM

2.4 การนำโมเดลที่พัฒนาเข้าสู่ระบบฝังตัว

2.4.1 STM32CubeIDE

เป็นโปรแกรมพัฒนาสำหรับการใช้ในการเขียนโค้ด, คอมไพล์, ดีบั๊กและแฟลชโค้ดลงไปยังไมโครคอนโทรลเลอร์ตระกูล STM32 โดยใช้งานควบคุมไปกับ X-CUBE-AI ซึ่งเป็นโปรแกรมที่ช่วยโดยแปลงโมเดลสำหรับฝังลงในไมโครคอนโทรลเลอร์เพื่อให้สามารถทำงานแบบตามเวลาจริงในระบบฝังตัว นอกจากนี้ยังช่วยในการคำนวณหน่วยความจำ RAM และ Flash ที่ใช้ได้อีกด้วย โดยโมเดลตัวอย่างที่พัฒนาและนำเข้าสู่ระบบฝังตัวจะใช้หน่วยความจำ 23.44 KiB RAM และ 7.97 KiB Flash ดังที่แสดงในรูปที่ 6




รูปที่ 6 ผลการประเมินของโมเดลจากช่องสัญญาณ F7 โดย X-CUBE-AI

2.4.2 Tera Term

เป็นโปรแกรมสำหรับสื่อสารกับอุปกรณ์อิเล็กทรอนิกส์หรือระบบฝังตัว (Embedded Systems) ใช้สำหรับตรวจสอบข้อความหรือดูผลการทำงานจากอุปกรณ์


จากรูปที่ 7 ค่าเอาต์พุตคือค่าความน่าจะเป็นที่โมเดลทำนายว่าเป็นอาการชัก ซึ่งหากมีค่ามากกว่าค่าที่กำหนดไว้ (ค่าขีดเริ่ม = 0.04) ระบบจะพิจารณาว่าเป็นสัญญาณ EEG ในช่วงที่เกิดอาการชัก



รูปที่ 7 ตัวอย่างการแสดงผลการทำงานของโมเดลผ่าน Tera Trem

2.4.3 STM32L476

เป็นชิปตระกูล STM32L4 แบบพลังงานต่ำ ใช้แกน Cortex-M4F โดยทำงานที่ความถี่สูงสุด 80 MHz และมีหน่วยความจำ Flash ขนาด 1 MB และ RAM ขนาด 128 KB โดยรองรับการใช้งานกับ X-CUBE-AI สำหรับทดสอบโมเดลการเรียนรู้ของเครื่องบนไมโครคอนโทรลเลอร์ได้ โดยมีขั้นตอนในการพัฒนาและการทำงานของเครื่องแบบฝังตัว ดังแสดงในรูปที่ 8



รูปที่ 8 flowchart การทำงานของระบบฝังตัว

3. ผลการทดลอง

หลังจากสร้างโมเดล LSTM โดยใช้สัญญาณจาก GAN ในการช่วยสร้างสัญญาณ EEG เทียมเพื่อเพิ่มปริมาณข้อมูลฝึก หลังจากนั้นนำไปทดสอบกับข้อมูลทดสอบ โดยในแต่ละโมเดลจะปรับค่าขีดเริ่มในการแยกแยะเอาต์พุตของโมเดล เพื่อให้โมเดลมีประสิทธิภาพสูงสุดในการตรวจจับการชักเหม่อ โดยตารางที่ 1 คือ ผลความแม่นยำของโมเดลใช้สัญญาณที่มีหน้าต่างขนาด 2 วินาทีขยับทีละ 1 วินาทีส่วนตารางที่ 2 สัญญาณที่มีหน้าต่างขนาด 1 วินาทีขยับทีละ 0.5 วินาทีในการฝึก

ตารางที่ 1 ความแม่นยำของโมเดลแต่ละช่องสัญญาณใช้หน้าต่างขนาด 2 วินาทีขยับทีละ 1 วินาทีในการฝึกโมเดล

โมเดล	Threshold	Sensitivity	Specificity	F1-score
F7, F8, T5, T6	0.04	87.4	86.7	76.6
F7, F8	0.005	93.3	92.3	86.0
F7, T5	0.05	92.6	90.1	83.1
F7, T6	0.1	91.1	90.3	82.6
F8, T5	0.01	90.4	89.1	80.8
F8, T6	0.03	90.4	89.3	81.1
T5, T6	0.03	85.9	86.0	75.1
F7	0.08	91.1	91.5	84.0
F8	0.03	91.1	89.1	82.0
T5	0.014	85.9	88.1	77.3
T6	0.08	87.4	89.8	80.0

ตารางที่ 2 ความแม่นยำของโมเดลแต่ละช่องสัญญาณใช้หน้าต่างขนาด 1 วินาทีที่ขยับทีละ 0.5 วินาที ในการฝึกโมเดล

โมเดล	Threshold	Sensitivity	Specificity	F1-score
F7, F8, T5, T6	0.05	89.2	92.8	85.2
F7, F8	0.01	92.0	89.0	82.6
F7, T5	0.008	90.6	89.3	82.1
F7, T6	0.003	88.2	89.8	81.3
F8, T5	0.008	86.1	85.9	76.3
F8, T6	0.001	87.2	86.4	77.3
T5, T6	0.005	84.7	83.8	73.6
F7	0.08	90.3	89.5	82.1
F8	0.01	86.1	89.4	79.7
T5	0.08	85.4	84.4	74.9
T6	0.065	86.5	84.9	75.6

ผลการทดลองที่แสดงในตารางที่ 1 และ 2 พบว่าการจะลดจำนวนอิเล็กโทรดลงไม่ส่งผลให้ความแม่นยำลดลงเท่าใดนัก โมเดลที่มีความแม่นยำสูงและใช้ช่องสัญญาณน้อยคือโมเดลที่ใช้ช่องสัญญาณ F7 โดยมีความแม่นยำ (Accuracy) 91.9% ความไว (Sensitivity) 90.3% ความจำเพาะ (Specificity) 89.5% และ F1-score 82.1%

ตารางที่ 3 ความแม่นยำของโมเดลตำแหน่ง F7 ที่ผ่านการปรับ hidden units โดยใช้หน้าต่างสัญญาณขนาด 1 วินาทีที่ขยับทีละ 0.5 วินาที ในการฝึกโมเดล

Hidden units	Threshold	Sensitivity	Specificity	F1-score
100	0.02	88.9	88.9	80.8
50	0.02	89.2	91.7	84.0
20	0.08	90.3	89.5	82.1

จากตารางที่ 3 แสดงให้เห็นว่าแม้จะปรับลด Hidden units แต่ความแม่นยำของโมเดลยังคงมีค่าไม่เปลี่ยนแปลงมากนักได้จึงใช้ Hidden units 20 เพื่อให้โมเดลมีขนาดเล็กลงเหมาะสมต่อการนำโมเดลไปใช้งานบนไมโครคอนโทรลเลอร์ได้ต่อไปเมื่อนำ model ไปฝังลงบนไมโครคอนโทรลเลอร์และทำทดสอบการตรวจจับอาการชักเหม่อจากสัญญาณ EEG ในช่องสัญญาณ F7 โดยใช้ข้อมูลสัญญาณ EEG ในช่วงเวลา 550 วินาที (test set) ในรูปแบบอาร์เรย์เข้าสู่หน่วยความจำของ STM32L4 เพื่อเป็น input ได้ผลการทดลองการตรวจจับช่วงที่เกิดการชักเหม่อมีความแม่นยำ (Accuracy) 88.9% ความไว (Sensitivity) 86.3% ความจำเพาะ (Specificity) 89.9% และ F1-score 86.7% โดยใช้หน่วยความจำ RAM 23.44 KiB และ Flash 7.97 KiB

4. สรุป

งานวิจัยนี้ได้โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) ในการตรวจจับการชักเหม่อจากสัญญาณคลื่นไฟฟ้าสมองร่วมกับการใช้โครงข่ายปฏิปักษ์แบบรู้สร้าง (GAN) ในการจำลอง

สัญญาณคลื่นไฟฟ้าสมองเพื่อเพิ่มปริมาณข้อมูลในการพัฒนาและทดสอบโมเดลการเรียนรู้ของเครื่อง โดยพบว่าโมเดลที่ใช้สัญญาณคลื่นไฟฟ้าสมองช่อง F7 ให้ความแม่นยำสูงและสามารถใช้สัญญาณจากช่องสัญญาณ F7 นี้เพียงช่องเดียวแต่ยังให้ประสิทธิภาพในการตรวจจับไม่ต่างจากการใช้สัญญาณจาก 2 หรือ 4 ช่องสัญญาณ จากนั้นได้นำโมเดลที่พัฒนาขึ้นไปฝังลงบนไมโครคอนโทรลเลอร์ชนิดพลังงานต่ำเพื่อทดสอบประสิทธิภาพในการทำงาน จากทดสอบพบว่าโมเดลบนไมโครคอนโทรลเลอร์นี้สามารถตรวจจับการชักเหม่อได้อย่างเหมาะสมโดยมีความแม่นยำ (Accuracy) 88.9%, ความไว (Sensitivity) 86.3%, ความจำเพาะ Specificity 89.9% และ F1 score 86.7% โดยใช้หน่วยความจำ RAM 23.44 KiB และ Flash 7.97 KiB ซึ่งโมเดลที่พัฒนาขึ้นนี้จะสามารถนำไปประยุกต์ใช้ในการตรวจจับอาการชักเหม่อแบบตามเวลาจริงได้ โดยคณะผู้วิจัยมีแผนงานในการนำข้อมูลจากกลุ่มคนไข้เพื่อทดสอบเพิ่มเติมและพัฒนาเป็นอุปกรณ์สวมใส่ที่ใช้กับผู้ป่วยจริงได้ในอนาคตต่อไป

กิตติกรรมประกาศ

ขอขอบพระคุณภาควิชาภูมิารเวชศาสตร์ คณะแพทยศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย และศูนย์วิจัยวิศวกรรมชีวเวช คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ที่กรุณาเอื้อเฟื้อข้อมูล อุปกรณ์ และสถานที่ในการดำเนินวิจัยนี้

เอกสารอ้างอิง

- [1] World Health Organization, "Epilepsy," Fact sheet, 2023.
- [2] Mayo Clinic. (2023). *Absence seizure – Symptoms & causes*. Mayo Foundation for Medical Education and Research.
- [3] F. Manzouri, S. M. R. Hashemi, M. Shoaran, and A. Aminifar, "A comparison of energy-efficient seizure detectors for implantable neurostimulation devices," *Frontiers in Neurology*, vol. 12, p. 792367, 2022.
- [4] M. Hugle, T. Beck, M. Hohmann, and M. Ortmanns, "Early seizure detection with an energy-efficient convolutional neural network on an implantable microcontroller," in *Proc. Int. Joint Conf. on Neural Networks (IJCNN)*, 2018, pp. 1–7.
- [5] G. Japardize et al., "Automated detection of absence seizures using a wearable electroencephalographic device: A phase 3 validation study and feasibility of automated behavioral testing," *Epilepsia*, vol. 63, no. 3, pp. 646–658, Mar. 2022.
- [6] C. Chatzichristos et al., "Multimodal detection of typical absence seizures in home environment with wearable electrodes," *Frontiers in Signal Processing*, vol. 2, p. 1014700, 2022.

- [7] T. W. Kjaer, C. M. R. Sorensen, H. H. Oturai, and T. E. Lundtorp, "Detection of paroxysms in long-term, single-channel EEG monitoring of patients with typical absence seizures," *IEEE Journal of Translational Engineering in Health and Medicine*, vol. 5, pp. 1–8, 2017.
- [8] R. Zanetti, A. Aminifar, and D. Atienza, "Robust epileptic seizure detection on wearable systems with reduced false-alarm rate," In *Proc. 42nd Annu. Int. Conf. of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2020, pp. 5970–5974.
- [9] P. Chatchavalvong, S. Pumrin, P. Somboon, and K. Chomtho, "Absence seizure detection based on embedded machine learning," In *Proc. 2024 8th Int. Conf. on Biomedical Engineering (iBioMed)*, Bandung, Indonesia, 2024, pp. 1–5.



ภาคภูมิ สมบูรณ์ อาจารย์ประจำหลักสูตร
สหสาขาวิชาวิศวกรรมชีวเวช คณะ
วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
มีความสนใจทางด้าน อุปกรณ์ทาง
การแพทย์ ไบโอเซนเซอร์และการ
ประมวลผลสัญญาณทางชีวการแพทย์



กฤษณชัย ชมโท อาจารย์ภาควิชาการ
เวชศาสตร์ คณะแพทยศาสตร์ จุฬาลงกรณ์
มหาวิทยาลัย มีความสนใจทางด้าน
ประสาทวิทยา



ฐาปกรณ์ โสภณพงษ์ นิสิตหลักสูตรสห
สาขาวิชาวิศวกรรมชีวเวช คณะ
วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย



อภิวัฒน์ เล็กอุทัย อาจารย์ประจำภาควิชา
วิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์
จุฬาลงกรณ์มหาวิทยาลัย มีความสนใจด้าน
เครื่องมือแพทย์ การวิเคราะห์และ
ประมวลผลสัญญาณทางชีวการแพทย์



สุรีย์ พุ่มรินทร์ อาจารย์ประจำภาควิชา
วิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์
จุฬาลงกรณ์มหาวิทยาลัย มีความสนใจ
ทางด้าน คอมพิวเตอร์วิทัศน์และระบบฝัง
ตัว



อาภรณ์ อีรมงคลศรี ผู้ช่วยศาสตราจารย์
ประจำภาควิชาวิศวกรรมไฟฟ้า คณะ
วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
มีความสนใจทางด้าน ตัวตรวจรู้สัญญาณ
ก๊าซเซนเซอร์ สิ่งประดิษฐ์สารกึ่งตัวนำ การ
วัดและเครื่องมือวัด