

การตรวจจับภาวะโรคซึมเศร้าจากสัญญาณคลื่นสมองด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับการเพิ่มประสิทธิภาพจากการจำแนกเฟสภายใน

MAJOR DEPRESSION DISORDER DETECTION ON EEG-BASED WITH THE CONVOLUTION NEURAL NETWORKS APPROACH IMPROVED WITH THE INTER-TRIAL PHASE CLUSTERING



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมอิเล็กทรอนิกส์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2564

KMITL-2021-EN-M-040-056

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

MAJOR DEPRESSION DISORDER DETECTION ON EEG-BASED WITH THE
CONVOLUTION NEURAL NETWORKS APPROACH IMPROVED WITH THE
INTER-TRIAL PHASE CLUSTERING



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN ELECTRONICS ENGINEERING
SCHOOL OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2021

KMITL-2021-EN-M-040-056

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2021

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่ สงวนลิขสิทธิ์ สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การตรวจจับภาวะโรคซึมเศร้าจากสัญญาณคลื่นสมองด้วย โครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับการเพิ่ม
ประสิทธิภาพจาก	การจำแนกเฟสภายใน
นักศึกษา	นายรัฐนนท์ สุวรรณธีรางกูร
รหัสประจำตัว	62601073
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมอิเล็กทรอนิกส์
พ.ศ.	2564
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผศ.ดร.ยุทธนา คิดใจเดียว

บทคัดย่อ

วิทยานิพนธ์ฉบับนี้ ได้เสนอความสามารถการเรียนรู้แบบเชิงลึก (Deep learning) สำหรับการตรวจจับความผิดปกติของสัญญาณคลื่นสมอง (Electroencephalogram ,EEG) จากผู้ป่วยภาวะซึมเศร้า โดยคุณลักษณะของ EEG จะอยู่บนพื้นฐานของการวิเคราะห์ทางเวลาและความถี่ (Time-Frequency Analysis) จากสัญญาณ EEG ซึ่งมาจากการแปลงแบบ Morlet wavelet transformation โดยผลที่ได้คือคุณลักษณะของ EEG แบบ Event-Related Potentials (ERPs) และ Inter-trial phase clustering (ITPC) ด้วยในด้านความท้าทายและซับซ้อนในการประเมินสุขภาพจิตของมนุษย์ ผู้เขียนได้เสนอโมเดลการเรียนรู้เชิงลึกที่เกิดจากการทำงานร่วมกันของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Networks, CNN) ที่มีขั้นตอนการสกัดคุณลักษณะสองชุดเพื่อใช้ในการเรียนรู้คุณลักษณะของ EEG ทั้งสองในเวลาเดียวกันเพื่อเพิ่มประสิทธิภาพในการจำแนกผู้ป่วย ซึ่งจากการรวมสองโครงข่ายเข้าด้วยกันและมีคุณลักษณะของ EEG ทั้งสองเป็นอินพุตผลลัพธ์ที่ได้คือมีความแม่นยำในการจำแนกถึง 91.67% เมื่อเปรียบเทียบกับโครงข่าย CNN ที่ใช้อินพุตเพียงคุณลักษณะเดียวคือ ERPs จะมีความแม่นยำเพียง 83.33% และผู้เขียนยังได้ทำการเปรียบเทียบกับวิธีการเรียนรู้ของเครื่อง (Machine Learning, ML) เช่น k-nearest neighbor (k-NN) ซึ่งมีความแม่นยำในการจำแนกเพียง 66.67%

Thesis	Major Depression Disorder detection on EEG-Based with the Convolution Neural Networks approach improved with the Inter-trial phase clustering
Student	Rathanon Suwanteerangkul
Student ID.	62601073
Degree	Master of Engineering
Program	Electronics Engineering
Year	2021
Thesis Advisor	Asst. Prof. Dr. Yuttana Kidjaidure

ABSTRACT

This thesis presents the ability of new architecture of deep learning to detect abnormalities in EEG (Electroencephalogram) signals of patients with depression. The EEG features are based on the Time-Frequency Analysis of EEG signals from the Morlet wavelet transformation, also known as ERPs (Event-Related Potentials) and ITPC (Inter-trial phase clustering), which is complex and challenging to assess by humans. We proposed a deep learning model that are integrating the two Convolution Neural Networks (CNNs) models to learn both EEG features at the same time to increase efficiency in classification. The result shows that the concatenation CNNs between two input's EEG features received accuracy in classification at 91.67% compared with general CNNs that use single input ERPs with accuracy only 83.33%. Also, we are comparing with a machine learning approach, such as k-NN (K-nearest neighbor), that received an accuracy of 66.67%.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี ด้วยความกรุณาจากอาจารย์ที่ปรึกษาผู้ช่วยรองศาสตราจารย์ ดร.ยุพธนา คิดใจเดียว ที่ให้ความรู้ ความช่วยเหลือ และชี้แนะแนวทางในการแก้ไขปัญหาที่เกิดขึ้นในงานวิจัยและกระบวนการวิจัย อีกทั้งยังคอยฝึกฝนให้ข้าพเจ้ามีกระบวนการ คิดวิเคราะห์ อย่างมีระบบ เป็นเหตุเป็นผล รวมถึงเปิดมุมมองใหม่ๆให้ข้าพเจ้าอยู่เสมอ ตลอดจนชี้แนะแนวทางในการดำรงชีวิตนักศึกษา ฝึกสอนให้มีความอดทน ความเอื้อเฟื้อเผื่อแผ่ หลอมรวมคุณธรรมจริยธรรม เพื่อให้ดำเนินงานอย่างนักวิจัยที่ดีในสังคม

ขอขอบคุณบิดา มารดาที่คอยสนับสนุนทั้งทุนในการเล่าเรียนและการทำงานวิจัย ตลอดจนคอยเป็นกำลังใจให้ข้าพเจ้าให้เสมอมา ขอขอบคุณคุณครูใจที่คอยอยู่เคียงข้างกันและคอยสนับสนุนตลอดการทำวิจัย ขอขอบคุณเพื่อนๆ พี่ๆ และน้องๆ ทุกคนที่ให้กำลังใจและความร่วมในการทำวิจัยเสมอมา

ขอขอบคุณห้องปฏิบัติการ B408 และภาควิชาอิเล็กทรอนิกส์ คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ที่อำนวยความสะดวก เอื้อเฟื้อสถานที่และอุปกรณ์ในการทำงานวิจัยต่างๆ

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบิดา มารดา ซึ่งเป็นที่รักและเคารพยิ่ง ครูบาอาจารย์ที่เคารพ ตลอดจนผู้มีพระคุณทุกท่าน

รัฐนนท์ สุวรรณธีรางกูร

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VIII
สารบัญรูป.....	IX
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของงานวิจัย.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา.....	2
1.3 สมมุติฐานของการศึกษา.....	2
1.4 ขอบเขตของการวิจัย.....	3
1.5 ขั้นตอนของการศึกษา.....	3
บทที่ 2 หลักการ ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 ภาวะโรคซึมเศร้า.....	5
2.2 สัญญาณไฟฟ้าคลื่นสมอง หรือ Electroencephalography (EEG).....	6
2.2.1 การวิเคราะห์สัญญาณ EEG ด้วยวิธีการ Inter-trials phase clustering.....	10
2.3 ความสัมพันธ์ระหว่างโรคซึมเศร้าและสัญญาณคลื่นสมอง EEG.....	12
2.4 กระบวนการวิเคราะห์องค์ประกอบอิสระ (Independent Component Analysis).....	14
2.5 กระบวนการแปลงสัญญาณ EEG ด้วยวิธีการ Time-frequency analysis.....	16
2.5.1 การแปลงสัญญาณ EEG ด้วยวิธี Morlet wavelet transformation.....	18
2.6 การออกแบบระบบจำแนกผู้ป่วยโรคซึมเศร้าด้วยวิธีการเรียนรู้ของเครื่อง (Machine learning) และวิธีการเรียนรู้แบบเชิงลึก (Deep learning).....	20
2.7 การลดมิติของข้อมูล (Dimension reduction).....	22

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และ IV อ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

หน้า

2.7.1 การวิเคราะห์หาค่าองค์ประกอบหลัก (Principal Component Analysis: PCA)	22
2.8 โมเดลจำแนกข้อมูลแบบการเรียนรู้ของเครื่อง	23
2.8.1 โมเดลจำแนกข้อมูลด้วยอัลกอริทึม k-Nearest Neighbors (k-NN)	23
2.8.2 โมเดลจำแนกข้อมูลด้วยอัลกอริทึม Support Vector Machine (SVM)	24
2.9 โมเดลจำแนกข้อมูลแบบการเรียนรู้เชิงลึก	26
2.9.1 โมเดลจำแนกข้อมูล Convolution Neural Networks (CNN)	26
2.10 งานวิจัยที่เกี่ยวข้องกับการสร้างโมเดลจำแนกโรคซึมเศร้าด้วยสัญญาณคลื่นสมอง	32
2.10.1 งานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้ของเครื่อง	33
2.10.2 งานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้เชิงลึก	33
บทที่ 3 การออกแบบโมเดลจำแนกโรคซึมเศร้า	34
3.1 ขั้นตอนการเตรียมประมวลผลข้อมูล (Data Preprocessing)	34
3.1.1 ขั้นตอนการวิเคราะห์สัญญาณ (Signal Processing)	35
3.1.2 ขั้นตอนการวิเคราะห์ในโดเมนเวลา-ความถี่ (Time-Frequency Analysis)	36
3.1.3 กระบวนการของโมเดลจำแนกแบบการเรียนรู้ของเครื่อง	38
3.1.3.1 ขั้นตอนการสกัดคุณลักษณะ	39
3.1.3.2 ขั้นตอนการลดมิติของข้อมูล	39
3.1.4 กระบวนการของโมเดลจำแนกแบบการเรียนรู้เชิงลึก	39
3.2 ขั้นตอนการเตรียมชุดข้อมูล	40
3.3 ขั้นตอนการสร้างโมเดลจำแนก (Classification Model)	41
3.3.1 การสร้างโมเดลจำแนก k-Nearest Neighbor (k-NN)	42
3.3.2 การสร้างโมเดลจำแนก Support Vector Machine (SVM)	42
3.3.3 การสร้างโมเดล Convolution Neural Network	42
3.3.4 การสร้างโมเดล Concatenation Convolution Neural Network	45

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และแจ้งอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
3.4 ขั้นตอนการประเมินและทดสอบประสิทธิภาพของโมเดลจำแนก	47
3.4.1 ตารางผลลัพธ์การทำนาย (Confusion Matrix).....	48
3.4.2 ค่าความแม่นยำ (Accuracy).....	48
3.4.3 ค่าความแม่นยำจำเพาะกลุ่ม (Precision).....	49
3.4.4 ค่าความไว (Recall / Sensitivity).....	49
3.4.5 ค่าความจำเพาะ (Specificity)	49
3.4.6 ค่า F1-Score.....	49
บทที่ 4 การทดลอง ผลการทดลอง และวิเคราะห์ผลการทดลอง	50
4.1 การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs	50
4.1.1 ผลการทดลองการสร้างโมเดลจำแนกแบบการเรียนรู้ของเครื่อง	51
4.1.2 ผลการทดลองการสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึก	54
4.1.3 ผลการเปรียบเทียบประสิทธิภาพของโมเดลจำแนก	57
4.2 การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs ร่วมกับ ITPC.....	58
4.2.1 ผลการทดลองสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึก Concat-CNN.....	59
4.2.2 ผลการเปรียบเทียบประสิทธิภาพของโมเดลจำแนก	62
4.3 การทดลองปรับจูนโมเดลจำแนก Concat-CNN แบบละเอียด (Fine-tuning).....	63
4.3.1 ผลการทดลองปรับจูนโมเดล Concat-CNN แบบละเอียด (Fine-Tuning).....	66
4.4 การทดลองตรวจสอบการทำนายผลจากโมเดลจำแนกด้วยอัลกอริทึม Grad-CAM.....	67
4.4.1 ผลการทดลองพล็อตค่า Gradient-weight ที่เกิดขึ้นในชั้นคอนโวลูชัน.....	67

สารบัญ (ต่อ)

	หน้า
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	70
5.1 สรุปผลการทดลอง	70
5.2 ข้อเสนอแนะ.....	71
เอกสารอ้างอิง.....	72
ภาคผนวก	75
ภาคผนวก ก. รายละเอียดของข้อมูลผู้ป่วยโรคซึมเศร้า.....	76
ภาคผนวก ข. ผลงานวิจัยที่ได้รับการตีพิมพ์	80
ประวัติผู้เขียน	86



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และ VII อ่างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
2.1 ช่วงความถี่และค่าแอมพลิจูดของสัญญาณคลื่นสมอง.....	7
2.2 ชนิดของคุณลักษณะจากสัญญาณ EEG ที่ถูกนำมาใช้ในงานวิจัย	33
3.1 ค่าพารามิเตอร์ของโมเดล CNN	44
3.2 ค่าพารามิเตอร์ของ Optimizer แต่ละชนิด	45
3.3 ค่าพารามิเตอร์ของโมเดล Concat-CNN.....	47
4.1 อัตราส่วนการกระจายของแต่ละองค์ประกอบ (Component) จาก PCA.....	51
4.2 ผลการสอนโมเดลจำแนก k-NN โดยใช้วิธี Hyperparameter Tuning	52
4.3 ผลการสอนโมเดลจำแนก SVM โดยใช้วิธี Hyperparameter Tuning	53
4.4 ผลการประเมินโมเดล CNN ด้วยข้อมูลชุดประเมินจากวิธี Hyperparameter Tuning	56
4.5 ผลการทดสอบโมเดลจำแนกทั้งหมดด้วยข้อมูลชุดทดสอบ	57
4.6 ผลการประเมินโมเดลจำแนก Concat-CNN ด้วยข้อมูลชุดประเมินจากวิธี Hyperparameter Tuning	61
4.8 ค่า learning rate ของ optimizer SGD ที่ลดลงแบบลำดับขั้นและเอกซ์โพเนนเชียล.....	65
4.9 ผลการทดสอบโมเดลจำแนกที่ผ่านการปรับจูนโมเดลแบบละเอียด	66

สารบัญรูป

รูปที่	หน้า
2.1 (a) ตำแหน่งการวางอิเล็กโทรดของ EEG ตามแบบมาตรฐาน 10/20 placement system และรูป (b) อิเล็กโทรดแบบ 64 channels.....	7
2.2 การแปลงสัญญาณคลื่นสมองเป็น Event-related potentials (ERPs).....	9
2.3 ความสัมพันธ์ของเวกเตอร์เฟสในทุกเหตุการณ์การกระตุ้น.....	11
2.4 กราฟสัญญาณ ERPs แสดงการตอบสนองของการกระตุ้นแบบ Reward (correct) และ Punishment (Incorrect) ของผู้ป่วยโรคซึมเศร้าและกลุ่มสุขภาพปกติ.....	13
2.5 กราฟสัญญาณ ERPs ในรูปแบบของ Spectrogram ทาง time-frequency domain.....	13
2.6 สัญญาณ EEG ที่ถูกการเคลื่อนที่ของร่างกายรบกวน.....	14
2.7 ตัวอย่างการตอบสนองของแต่ละช่วงความถี่ของสัญญาณ EEG.....	15
2.8 การเปรียบเทียบความละเอียดทางด้านเวลาและความถี่ของวิธี STFT และวิธี Wavelet transform.....	17
2.9 complex morlet wavelet ในรูปของโดเมนเวลาและโดเมนความถี่.....	18
2.10 ความแตกต่างของ Spectrogram จากสัญญาณต้นกำเนิด เดียวกันที่มีค่า number of cycle ต่างกัน.....	19
2.11 แผนภาพแสดงการสร้างโมเดลการเรียนรู้แบบเชิงลึก.....	21
2.12 แผนภาพแสดงการสร้างโมเดลการเรียนรู้ของเครื่อง.....	22
2.13 การลดมิติด้วยการวิเคราะห์องค์ประกอบหลัก (PCA).....	23
2.14 ตัวอย่างการจำแนกกลุ่มแบบ k-nearest neighbor.....	23
2.15 การจำแนกข้อมูลด้วยระนาบเส้นตรง.....	25
2.16 แสดงการแปลงข้อมูลให้อยู่ในมิติที่สูงกว่า.....	25
2.17 การทำงานของโมเดล CNN.....	26
2.18 การทำ Convolution เพื่อดึงคุณลักษณะของรูปภาพ.....	27
2.19 การทำ Max pooling เพื่อลดความซับซ้อน.....	27
2.20 ขั้นตอนการสอนโมเดลเรียนรู้แบบเชิงลึก (CNN).....	28
2.21 เส้นทางการหาค่าตอบของ Optimizer.....	30

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และ IX อ่างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.22 Linear activation function	31
2.23 Rectified Linear Unit (ReLU)	31
2.24 Sigmoid activation function.....	31
3.1 กระบวนการเตรียมข้อมูล (Data preprocessing)	34
3.2 สัญญาณ EEG 64 channels ที่ถูกบันทึกมาแบบต่อเนื่อง (Continuous Signal)	35
3.3 สัญญาณ Event-related potentials (ERPs).....	36
3.4 กราฟเวลา-ความถี่ของสัญญาณ ERPs.....	37
3.5 กราฟเวลา-ความถี่ของสัญญาณ ITPC.....	37
3.6 กราฟค่าสัมบูรณ์ของกำลังงาน.....	39
3.7 การจัดเรียงอินพุตในรูปของ array 3 มิติ.....	40
3.8 การแบ่งชุดข้อมูลสำหรับการสร้างโมเดล.....	41
3.9 โครงสร้างจำลองของโมเดล CNN.....	43
3.10 โครงสร้างจำลองการทำงานของโมเดล Concat-CNN.....	46
3.11 โครงสร้างจำลองของโมเดล Concat-CNN.....	46
3.12 ตารางผลลัพธ์ของการทำนาย (Confusion Matrix).....	48
4.1 กราฟแนวโน้มค่าความแม่นยำจากการสอนโมเดล.....	59
4.2 กราฟแนวโน้มค่าความสูญเสียจากการสอนโมเดล.....	59
4.3 กราฟแนวโน้มค่าความแม่นยำจากการประเมินโมเดล.....	60
4.4 กราฟแนวโน้มค่าความสูญเสียจากการประเมินโมเดล.....	60
4.5 กราฟแนวโน้มค่าความแม่นยำจากการสอนโมเดล Concat-CNN.....	59
4.6 กราฟแนวโน้มค่าความสูญเสียจากการสอนโมเดล Concat-CNN.....	59
4.7 กราฟแนวโน้มค่าความแม่นยำจากการประเมินโมเดล Concat-CNN.....	60
4.8 กราฟแนวโน้มค่าความสูญเสียจากการประเมินโมเดล Concat-CNN.....	60
4.9 Confusion Matrix ของการทำนายผลจากโมเดลจำแนก Concat-CNN.....	63

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และ X ึ่งอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของงานวิจัย

ปัจจุบันงานวิจัยด้านการวิเคราะห์สัญญาณคลื่นสมองเป็นหัวข้อที่เริ่มได้รับความสนใจเป็นวงกว้าง อันเนื่องมาจากการวิเคราะห์สัญญาณคลื่นสมองสามารถนำไปช่วยในวินิจฉัยและจำแนกโรคที่เกี่ยวข้องกับภาวะทางจิตหรือโรคทางจิตเวชได้ โดยในปัจจุบันโรคซึมเศร้า (Major Depression Disorder) ก็เป็นหนึ่งในโรคที่มีผู้ป่วยเกิดขึ้นเป็นจำนวนไม่น้อย โดยงานวิจัยด้านการวิเคราะห์สัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร่ายังอยู่ในระยะของการวิจัย โดยเฉพาะในด้านการพัฒนาเครื่องมือและอัลกอริทึมในการวินิจฉัยและจำแนกโรค เพื่อช่วยเหลือบุคลากรทางด้านโรคจิตเวชในการวินิจฉัยโรคให้เกิดประสิทธิภาพ โดยคำนึงถึงความถูกต้องและปลอดภัยของผู้ป่วย ดังนั้นในการสร้างอัลกอริทึมหรือโมเดลที่ใช้ในการจำแนกผู้ป่วยโรคซึมเศร้าจำเป็นต้องมีความแม่นยำและมีความเชื่อถือได้มากที่สุด เพื่อลดข้อผิดพลาดของการวินิจฉัยอันเป็นเหตุให้การรักษาโรคไม่เป็นไปตามที่ต้องการและอาจส่งผลเสียให้กับผู้ป่วยได้

โดยจากงานวิจัยในปัจจุบันเกี่ยวกับการใช้สัญญาณคลื่นสมองร่วมกับอัลกอริทึมหรือโมเดลในการจำแนกโรคซึมเศร้าจะสามารถแบ่งออกมาได้ทั้งหมดสามวิธีคือการประมวลผลสัญญาณ (Signal Processing) โดยวิธีนี้จะใช้การวิเคราะห์สัญญาณในโดเมนของเวลา (Time Domain Method) , การวิเคราะห์สัญญาณในโดเมนของความถี่ (Frequency Domain Method) และการวิเคราะห์สัญญาณในโดเมนเวลา-ความถี่ (Time-Frequency Domain Method) โดยในการประมวลผลสัญญาณยังคงต้องอาศัยผู้เชี่ยวชาญเพื่อตีความลักษณะของสัญญาณคลื่นสมองโดยอาจจะสิ้นเปลืองเวลาในการวิเคราะห์และอาจเกิดข้อผิดพลาดได้ วิธีที่สองคือการใช้โมเดลจำแนกแบบการเรียนรู้ของเครื่อง (Machine Learning) ร่วมกับการสกัดคุณลักษณะ (Feature Extraction) จากสัญญาณ โดยคุณลักษณะที่กล่าวถึงจะถูกสร้างขึ้นมาจากอัลกอริทึมแบบต่างๆ (Hand-crafted feature) ซึ่งยังคงต้องใช้ผู้เชี่ยวชาญในการเลือกอัลกอริทึมที่เหมาะสม นอกจากนี้ในบางอัลกอริทึมยังไม่สามารถสกัดข้อมูลที่ซับซ้อนจากสัญญาณในบางปัญหาได้ ทำให้ผู้วิจัยได้มุ่งเป้าการศึกษาไปยังวิธีที่สามซึ่งก็คือโมเดลจำแนกแบบการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถเรียนรู้ข้อมูลที่มีความซับซ้อนได้โดยปราศจากการใช้ความรู้เชิงลึกเกี่ยวกับการวิเคราะห์ทางสัญญาณและการเลือกอัลกอริทึมเพื่อสกัดคุณลักษณะมาช่วยในจำแนกโรคซึมเศร้าตามจุดประสงค์ของผู้วิจัย โดยผู้วิจัยมีความคาดการณ์ว่าโมเดลจำแนกโรคซึมเศร้าจะสามารถช่วยเหลือบุคลากรทางจิตเวชในการคัดกรองผู้ป่วยได้อย่างมี

ประสิทธิภาพ เนื่องจากมีผู้ป่วยโรคซึมเศร้าจำนวนไม่น้อยที่สามารถหลีกเลี่ยงการคัดกรองโรคที่ได้นำคำถามทางจิตวิทยาเพื่อใช้คัดกรองโรคได้

1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา

วิทยานิพนธ์เรื่องนี้ได้มุ่งเน้นศึกษาและนำอัลกอริทึมของการเรียนรู้เชิงลึก ที่มีประสิทธิภาพและเหมาะสมที่สุดเพื่อใช้ในการจำแนกผู้ป่วยโรคซึมเศร้าโดยใช้สัญญาณคลื่นสมองของผู้ป่วยเป็นอินพุต โดยปราศจากการใช้ความรู้เชิงลึกด้านจิตเวชในการวิเคราะห์เพื่อคัดกรองผู้ป่วย โดยใช้โมเดลการเรียนรู้แบบเชิงลึกที่สามารถหาคุณลักษณะของสัญญาณคลื่นสมองที่แตกต่างกันระหว่างกลุ่มผู้ป่วยโรคซึมเศร้าและกลุ่มคนที่มีสภาพทางจิตปกติด้วยวิธีการแปลงสัญญาณคลื่นสมองให้เป็นรูปภาพแบบสเปกโตรแกรม (spectrogram) เพื่อลดปัญหาในการคัดเลือกอัลกอริทึมที่ใช้สกัดคุณลักษณะของสัญญาณคลื่นสมองมาใช้งานร่วมกับวิธีการเรียนรู้ของเครื่อง โดยในกระบวนการออกแบบอัลกอริทึมการเรียนรู้แบบเชิงลึกเพื่อใช้จำแนกโรคจะมีขั้นตอนที่ประกอบด้วย ขั้นตอนการประมวลผลของสัญญาณคลื่นสมองจากมนุษย์ ขั้นตอนการแปลงสัญญาณให้เป็นรูปภาพสเปกโตรแกรม และขั้นตอนการสร้างอัลกอริทึมการเรียนรู้แบบเชิงลึกเพื่อใช้ในการคัดกรองผู้ป่วยโรคซึมเศร้าได้อย่างมีประสิทธิภาพ

1.3 สมมุติฐานของการศึกษา

จากการศึกษางานวิจัยที่ผ่านมาเกี่ยวกับการนำการเรียนรู้ของเครื่องและการเรียนรู้แบบเชิงลึกมาประยุกต์ใช้ในงานด้านการวิเคราะห์และจำแนกโรคซึมเศร้าด้วยวิธีการที่แตกต่างกันออกไป โดยพบว่าในหลายๆงานวิจัยพยายามเลือกใช้คุณลักษณะเพียงอย่างเดียวจากสัญญาณคลื่นสมองมาเป็นอินพุตสำหรับฝึกสอนโมเดลจำแนก ส่วนในงานวิจัยนี้จะนำอินพุตสองทางซึ่งมาจากสัญญาณคลื่นสมองแบบดิบโดยคาดการณ์ว่าโมเดลจำแนกแบบการเรียนรู้แบบเชิงลึกจะสามารถเรียนรู้คุณลักษณะของอินพุตทั้งสองแบบที่ส่งเพื่อใช้ฝึกสอนโมเดลจำแนก รวมถึงผู้วิจัยคาดการณ์ว่าโมเดลจำแนกจะสามารถตรวจจับความสัมพันธ์ภายในที่เกิดขึ้นระหว่างสองอินพุตที่ชั้นจำแนกของโมเดลและแสดงออกมาในรูปของประสิทธิภาพที่เพิ่มมากขึ้นในด้านการจำแนกสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าออกจากกลุ่มคนปกติทั่วไปที่คัดเลือกมาเป็นกลุ่มทดลอง อย่างไรก็ตามผู้วิจัยก็ยังพยายามสร้างโมเดลจำแนกที่มีขนาดที่เหมาะสมเพื่อให้ลดการใช้งานด้านทรัพยากรของเครื่องคอมพิวเตอร์ รวมถึงลดการใช้เวลาในการประมวลผลเพื่อฝึกสอนโมเดลจำแนกแบบการเรียนรู้เชิงลึก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.4 ขอบเขตของการวิจัย

งานศึกษาวิจัยนี้เป็นการศึกษาด้านการสร้างอัลกอริทึมที่ใช้สำหรับวิเคราะห์และจำแนกผู้ป่วยโรคซึมเศร้าโดยประยุกต์โมเดลจำแนกแบบการเรียนรู้เชิงลึกเข้ากับสัญญาณคลื่นสมองของผู้ป่วยที่มีสัญญาณจากอิเล็กโทรดหลายตำแหน่ง โดยการพัฒนาอัลกอริทึมจะมีขั้นตอนการพัฒนาซึ่งประกอบด้วย 4 ส่วนหลัก ดังนี้ 1) ใช้โปรแกรม MATLAB เพื่อประมวลผลในด้านของการวิเคราะห์สัญญาณคลื่นสมองและกำจัดสัญญาณรบกวนออกเพื่อลดความผิดพลาด 2) ขั้นตอนการแปลงสัญญาณคลื่นสมองให้เป็นรูปภาพแบบสเปกโตรแกรม 3) ขั้นตอนการสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึกโดยใช้ภาษา Python ในการพัฒนาและ 4) ขั้นตอนการประเมินประสิทธิภาพของโมเดลจำแนก ซึ่งข้อมูลสัญญาณคลื่นสมองที่ได้ใช้ในการวิเคราะห์และพัฒนาโมเดลจำแนก ได้ถูกบันทึกจากผู้เชี่ยวชาญและเครื่องมือที่มีมาตรฐานจากสถาบัน Cognitive Rhythms & Computational Lab

1.5 ขั้นตอนของการศึกษา

ขั้นตอนของการวิจัยในหัวข้อดังกล่าวจะเริ่มต้นด้วยการทบทวนและศึกษางานวิจัยที่เกี่ยวข้องกับการศึกษาสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าและงานวิจัยเกี่ยวกับการประยุกต์ใช้โมเดลจำแนกแบบการเรียนรู้เชิงลึกว่าในแต่ละวิธีนั้นมีข้อดีและข้อเสียอย่างไรเพื่อหาทางพัฒนาและปรับปรุงโครงสร้างกระบวนการต่างๆในการประมวลผลสัญญาณคลื่นสมองรวมถึงการสร้างโมเดลจำแนก จากนั้นในขั้นตอนถัดไปจะศึกษาพฤติกรรมและลักษณะของสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าว่ามีการเปลี่ยนแปลงอย่างไรในสมองของผู้ป่วยทั้งในภาวะปกติและในภาวะกระตุ้นซึ่งรวมถึงภาวะกระตุ้นที่เกิดจากการทดลอง ขั้นตอนที่สามผู้วิจัยได้ศึกษาวิธีการสกัดคุณลักษณะจากสัญญาณคลื่นสมองแบบดั้งเดิมที่ใช้กันอย่างแพร่หลาย เพื่อนำวิธีบางส่วนที่มีประโยชน์มาประยุกต์ใช้กับโมเดลจำแนกแบบการเรียนรู้แบบเชิงลึก ขั้นตอนสุดท้ายผู้วิจัยได้ศึกษาทฤษฎีของการสร้างโมเดลการเรียนรู้แบบเชิงลึก (Deep learning model) แบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) เพื่อที่จะใช้ในการจำแนกผู้ป่วยโรคซึมเศร้าผ่านอินพุตที่เป็นสัญญาณคลื่นสมองตลอดจนเสนอโครงสร้างของโมเดลการเรียนรู้เชิงลึกที่นำเทคนิคการเชื่อมต่อกันระหว่างโมเดลการเรียนรู้แบบเชิงลึกสองโมเดล (Concatenation Convolution Neural Network) ที่ส่วนของกระบวนการสกัดคุณลักษณะ โดยรายละเอียดของทฤษฎี หลักการ งานวิจัยที่เกี่ยวข้องกับการวิเคราะห์สัญญาณคลื่นสมอง การสกัดคุณลักษณะ และโมเดลการเรียนรู้แบบเชิงลึกจะแสดงในบทที่ 2 ส่วนในบทที่ 3 จะกล่าวถึงการออกแบบขั้นตอนการดำเนินการ โดยส่วนนี้จะอธิบายรายละเอียดขั้นตอนการเตรียมการข้อมูลสัญญาณคลื่นสมอง และขั้นตอนการสร้างโมเดลการเรียนรู้แบบเชิงลึกที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผู้วิจัยได้นำเสนอ ส่วนถัดมาในบทที่ 4 จะกล่าวถึงการทดลอง ผลการทดลองรวมถึงวิจารณ์ผลการทดลองที่เกิดขึ้นและผลการวิจัยทั้งหมดรวมถึงข้อเสนอแนะในด้านต่างๆจะอยู่ในส่วนสุดท้ายคือ บทที่ 5



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

หลักการ ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึง หลักการ ทฤษฎี และงานวิจัยที่เกี่ยวข้องกับการสร้างโมเดลจำแนกผู้ป่วยโรคซึมเศร้าด้วยวิธีการเรียนรู้แบบเชิงลึก รวมถึงโมเดลแบบการเรียนรู้ของเครื่อง โดยจะเริ่มจากการศึกษาทฤษฎีที่เกี่ยวข้องกับผู้ป่วยโรคซึมเศร้า การวินิจฉัยโรคซึมเศร้าด้วยวิธีต่างๆ ทฤษฎีสัญญาณคลิ่นสมองและสัญญาณที่ได้จากผู้ป่วยโรคซึมเศร้า วิธีการสกัดคุณลักษณะและการลดมิติของข้อมูลแบบต่างๆที่ใช้ร่วมกับคลิ่นสมองเพื่อใช้ในโมเดลจำแนกแบบการเรียนรู้เชิงลึก รวมถึงงานวิจัยที่เกี่ยวข้องทั้งด้านทฤษฎีของคลิ่นสมองในผู้ป่วยโรคซึมเศร้า การออกแบบโมเดลการเรียนรู้แบบเชิงลึกเพื่อใช้ในการจำแนกระหว่างผู้ป่วยและกลุ่มตัวอย่างควบคุม

2.1 ภาวะโรคซึมเศร้า

ภาวะโรคซึมเศร้า หรือ Major Depression Disorder ถือเป็นโรคทางด้านจิตเวช (Mental Disorder) ที่พบมากเป็นอันดับต้นๆของเมืองไทยและมีแนวโน้มที่เพิ่มมากขึ้นเรื่อยๆ ในอนาคต โรคซึมเศร้าสามารถเกิดได้จาก 2 สาเหตุหลักได้แก่ [1] ปัจจัยทางด้านชีวภาพ (Biological Factors) และปัจจัยด้านจิตใจหรือสภาพแวดล้อม (Personal Vulnerabilities and Environmental) โดยปัจจัยทางด้านชีวภาพที่กล่าวถึงจะเกี่ยวข้องกับสารสื่อประสาททั้งสามชนิดคือ 1.Serotonin 2.Norepinephrine และ 3.Dopamine ซึ่ง Serotonin เป็นสารที่พบว่ามีความสัมพันธ์กับภาวะโรคซึมเศร้ามากที่สุด โดยการลดลงของ serotonin สามารถกระตุ้นให้เกิดภาวะซึมเศร้า ในผู้ป่วยบางคนที่ขาดการควบคุมเกี่ยวกับการฆ่าตัวตาย (suicide impulse) จะมีความเข้มข้นของ serotonin metabolite ที่ผิดปกติ และในผู้ป่วยโรคซึมเศร้าทั่วไปจะมีระดับการหลั่ง Norepinephrine และ Dopamine ที่ลดลงเมื่อเทียบกับกลุ่มคนสุขภาพปกติที่ไม่ได้มีภาวะซึมเศร้าแต่อย่างใด นอกจากนี้ยังมีปัจจัยด้านอื่นที่เกี่ยวข้องในด้านชีวภาพเช่นผู้ป่วยโรคซึมเศร้าจะมีปริมาณของ Growth hormone ในเวลากลางคืนที่ต่ำผิดปกติ และปัจจัยด้านพันธุกรรม (genetic factor) ซึ่งจาก Family study จะพบว่าบุตรของผู้ที่เป็นโรคซึมเศร้า จะมีโอกาสป่วยเป็นโรคซึมเศร้า และ โรคไบโพล่า (Bipolar I disorder) ได้มากกว่าบุตรของกลุ่มคนสุขภาพปกติได้ถึง 1.5-2.5 เท่าและพบว่าครึ่งหนึ่งของผู้ป่วยที่เป็นโรคไบโพล่าจะมีพ่อหรือแม่คนใดคนหนึ่งป่วยเป็นโรคซึมเศร้าเช่นกัน ในปัจจุบันด้านจิตใจและสภาพแวดล้อมนอกจากความเครียดที่เกิดขึ้นจากตัวสภาพแวดล้อมหรือสังคม ลักษณะนิสัยเฉพาะของผู้ป่วยโรคซึมเศร้าบางคนจะมีแนวคิดที่ทำให้ตนเองตกอยู่ในภาวะซึมเศร้าได้ เช่นการมองตัวเองในแง่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ลบ มองแต่ความบกพร่องของตนเองในอดีตหรือมองโลกในแง่ร้ายซึ่งอาจจะเป็นผลมาจากสังคมที่ดำรงชีวิตอยู่ โดยปัจจัยทางสภาวะจิตใจ ความเครียด ความกังวลและความหวาดวิตกเหล่านี้ก็เป็นปัจจัยสนับสนุนอีกปัจจัยหนึ่งที่ทำให้เกิดการเปลี่ยนแปลงทางชีวภาพในสมองอย่างถาวรและสามารถนำไปสู่การเกิดภาวะโรคซึมเศร้า ในปัจจุบันการตรวจวินิจฉัยผู้ป่วยโรคซึมเศร้าทางการแพทย์โดยผู้เชี่ยวชาญไม่ว่าจะเป็นจิตแพทย์หรือนักจิตวิทยาจะใช้เกณฑ์การวินิจฉัยและประเมินลักษณะอาการทางคลินิกของกลุ่มโรคซึมเศร้าตามหลักของคู่มือการวินิจฉัยและสถิติสำหรับความผิดปกติทางจิตหรือ Fifth Edition of the Diagnostic and Statistical Manual of Mental Disorders (DSM-5) [2] และ Beck Depression Inventory (BDI-II) [3] โดยเป็นวิธีที่ใช้คำถามในการประเมินระดับของภาวะโรคซึมเศร้า ซึ่งทั้งสองวิธีจำเป็นต้องอาศัยประสบการณ์และความเชี่ยวชาญในการวิเคราะห์ผลที่ออกมาและยังใช้เวลานานในการประเมินอีกด้วย

เกณฑ์การระบุระดับของภาวะโรคซึมเศร้าจากแบบประเมิน Beck Depression Inventory มีเงื่อนไขดังนี้ คำถามแบบประเมินจะมีทั้งหมด 21 ข้อแบ่งออกเป็นคำถามอาการทางจิตใจและอาการทางร่างกาย โดยแต่ละคำถามจะมี 4 ตัวเลือก โดยให้ประเมินอาการที่ใกล้เคียงกับความรู้สึกมากที่สุด ใน 1 สัปดาห์ที่ผ่านมาโดยระบบคะแนนจะเรียงตั้งแต่ 0-3 เริ่มตั้งแต่อาการเพียงเล็กน้อย (คะแนน 0) ไปถึงอาการรุนแรง (คะแนน 3) ตามลำดับ ซึ่งในการแปลผลระดับความรุนแรงของภาวะโรคซึมเศร้าจะเกิดจากการนำคะแนนทั้งหมดจากคำถาม 21 ข้อมารวมคะแนนกันโดยผลการประเมินจะแบ่งออกได้เป็น 4 ระดับดังนี้


1. คะแนน 0 – 13 หมายถึง มีภาวะอารมณ์ปกติ (Minimal depression)
2. คะแนน 14 – 19 หมายถึง มีภาวะซึมเศรียรระดับต่ำ (Mild depression)
3. คะแนน 20 – 28 หมายถึง มีภาวะซึมเศรียรระดับปานกลาง (Moderate depression)
4. คะแนน 29 – 63 หมายถึง มีภาวะซึมเศรียรระดับสูง (Severe depression)

2.2 สัญญาณไฟฟ้าคลื่นสมอง หรือ Electroencephalography (EEG)

สัญญาณคลื่นสมอง หรือ EEG เป็นเครื่องมือแบบ Non-invasive ซึ่งจะไม่สร้างความบาดเจ็บให้กับผู้ทดลองโดยจะถูกใช้วัดความผันผวนของสัญญาณไฟฟ้าที่เกิดขึ้นในสมองอันเนื่องมาจากการไหลเวียนของประจุไฟฟ้าภายในเซลล์ประสาทของสมอง ซึ่งเกิดมาจากกิจกรรมต่างๆภายในสมองที่เกิดขึ้นชั่วขณะ [4] โดยการวัดสัญญาณคลื่นสมองจะถูกวัดด้วยขั้วอิเล็กโทรดจำนวนหลายจุดบริเวณหนังศีรษะของมนุษย์ในตำแหน่งต่างๆ โดยระบบของการวางอิเล็กโทรดจะมีมาตรฐานหลายรูปแบบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เช่น 10/20 (10/20 placement system) และแบบ 10/20 ที่ได้รับการปรับปรุงเป็นระบบ Modified Combinational Nomenclature (MCN) ซึ่งจะเพิ่มจำนวนอิเล็กโทรดเข้าไปในระบบโดยอ้างอิงจากแผนผัง 10/20 เพื่อเพิ่มความละเอียด (Resolution) ในการวัดสัญญาณคลื่นสมองในแต่ละส่วน



รูปที่ 2.1(a) ตำแหน่งการวางอิเล็กโทรดของ EEG ตามแบบมาตรฐาน 10/20 placement system

และ รูป (b) อิเล็กโทรดแบบ 64 channels ที่มา: [5]

โดยสัญญาณคลื่นสมองจะถูกแบ่งออกเป็นทั้งหมด 5 ช่วงความถี่ที่ตอบสนองต่อกิจกรรมในสมองที่แตกต่างกัน

ตารางที่ 2.1 ช่วงความถี่และค่าแอมพลิจูดของสัญญาณคลื่นสมอง

ความถี่	ช่วงความถี่ (Hz)	ขนาดแอมพลิจูด (μv)
เดลต้า (Delta)	0-4	20-100
ทีต้า (Theta)	4-8	10
อัลฟา (Alpha)	8-13	2-100
เบต้า (Beta)	13-22	5-10
แกมมา (Gamma)	>30	-

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยในการตีความและวิเคราะห์สัญญาณคลื่นสมอง EEG ที่เป็นสัญญาณไฟฟ้าในปัจุบันมีด้วยกันหลายวิธีการซึ่งวิธีที่ได้รับความนิยมในปัจจุบันคือ Event-related potentials (ERPs) และ Inter-trials phase clustering (ITPC) โดยสามารถวิเคราะห์ได้ทั้งในโดเมนเวลา (Time domain) โดเมนความถี่ (Frequency domain) และโดเมนเวลา-ความถี่ (Time-frequency domain) ซึ่งวิธีทั้งหมดที่กล่าวมานี้ถือว่าการสกัดคุณลักษณะของคลื่นสมอง

2.2.1 การวิเคราะห์สัญญาณ EEG ด้วยวิธีการ Event-related potentials

Event-related potentials คือวิธีการวัดการตอบสนองของสมองที่มีผลโดยตรงจากเหตุการณ์กระตุ้น (specific events or stimuli) ที่เกิดขึ้นไม่ว่าจะเกิดจากด้านระบบประสาทสัมผัส (Sensory) ระบบการรู้จำ (cognitive) และระบบของการเคลื่อนไหว (Motor) ซึ่งจะสะท้อนผลลัพธ์รวมของกิจกรรมที่เกิดขึ้นที่เซลล์ประสาทภายในสมองพร้อมๆกัน [6] ในการวัดการตอบสนองของสมองโดยผ่านเหตุการณ์การกระตุ้น (stimuli epoch) ที่สนใจเพียงครั้งเดียวจะไม่สามารถแสดงให้เห็นและสรุปข้อมูลการทำงานของสมองที่ได้จากคลื่นสมอง EEG ได้ทันที ดังนั้นเพื่อที่จะวิเคราะห์สัญญาณคลื่นสมองที่มาจากกระตุ้นในทางทดลองจำเป็นต้องสร้างเหตุการณ์เพื่อนำมาใช้กระตุ้นสมองจำนวนหลายครั้งและหาค่าเฉลี่ยของสัญญาณคลื่นสมองที่เกิดจากการกระตุ้นทั้งหมดและสุดท้ายแล้วจะเหลือเพียงสัญญาณคลื่นสมองเพียงสัญญาณเดียวที่สามารถใช้ในการตีความข้อมูลการทำงานของสมองที่มีผลขึ้นกับการกระตุ้นชนิดนั้นๆ โดยในผลลัพธ์ที่ได้จะเหลือเพียงแต่ส่วนของสัญญาณที่เกิดจากการกระตุ้นและในส่วนของสัญญาณที่เกิดขึ้นแบบสุ่มจะถูกกำจัดออกไปหลังจากสัญญาณถูกเฉลี่ยและหากมองในแง่ของการวิเคราะห์ทางสัญญาณจะพบว่าการเฉลี่ยสัญญาณ EEG จะส่งผลให้ Signal-to-noise ratio (SNR) มีค่าเพิ่มขึ้นซึ่งจะทำให้สามารถวิเคราะห์สัญญาณได้ชัดเจนขึ้น ซึ่งสัญญาณเฉลี่ยที่เป็นผลจากการกระตุ้นของแต่ละเหตุการณ์จะถูกเรียกว่า Event-related potentials และในการคำนวณหาค่าเฉลี่ยของสัญญาณคลื่นสมอง EEG จะมีสมมุติฐานในการสร้างสมการคือ

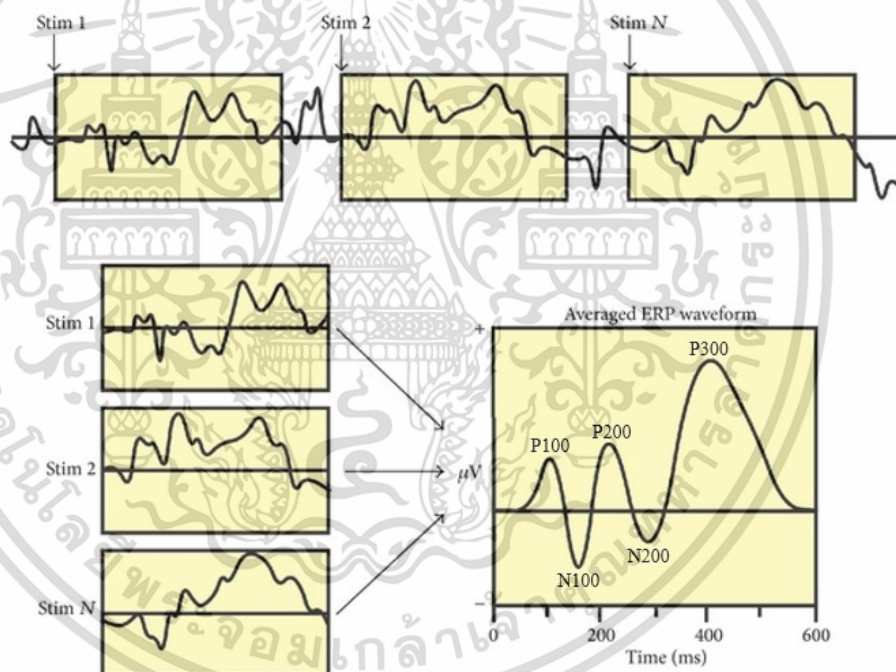
1. สัญญาณ EEG ที่นำมาคำนวณจะต้องมีลำดับของสัญญาณที่กำเนิดมาจากการเหตุการณ์กระตุ้น
2. สัญญาณรบกวนสามารถประมาณได้โดยการสุ่มแบบ Gaussian ที่มีค่าเฉลี่ยเท่ากับศูนย์และมีค่าความแปรปรวนเท่ากับ σ^2 ซึ่งจะต้องไม่มีความสัมพันธ์ระหว่างในแต่ละรอบการกระตุ้น (Epoch)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่าเฉลี่ยของสัญญาณคลื่นสมองหรือ Event-related potentials สามารถคำนวณได้จากสมการ

$$\bar{x}(t) = \frac{1}{N} \sum_{k=1}^N x(t, k) = s(t) + \frac{1}{N} \sum_{k=1}^N n(t, k) \quad (2.1)$$

กำหนดให้ $\bar{x}(t)$ คือ สัญญาณเฉลี่ยของ EEG หรือ ERPs
 $s(t)$ คือ expected value ของ $\bar{x}(t)$
 $n(t, k)$ คือ สัญญาณรบกวนที่อยู่ในแต่ละช่วงเวลาและการกระตุ้น
 N คือจำนวนของเหตุการณ์กระตุ้น (Epoch)
 t คือเวลาในแต่ละจุดของเหตุการณ์กระตุ้น



รูปที่ 2.2 การแปลงสัญญาณคลื่นสมองเป็น Event-related potentials ที่มา: [7]

ในการประเมินผลและวิเคราะห์ค่าสัญญาณ Event-related potentials จะจำแนกการวิเคราะห์ตามองค์ประกอบของสัญญาณที่เกิดขึ้นตามช่วงเวลาที่มีเหตุการณ์การกระตุ้น จากรูปที่ 2.2 จะเห็นได้ว่าสัญญาณ ERPs จะถูกแบ่งตามเวลาหลังจากการกระตุ้นเกิดขึ้น โดยในแต่ละจุดของเวลาจะมีการเปลี่ยนแปลงของแอมพลิจูดที่แตกต่างกันโดย ERPs ที่เกิดขึ้นในมนุษย์จะสามารถแบ่งได้เป็นสองประเภทหลัก คือ ช่วงสัญญาณ 100 ms หลังจากการกระตุ้นจะมีความเกี่ยวข้องกับระบบประสาทสัมผัส (Sensory) ส่วนอีกประเภทหนึ่งคือช่วงสัญญาณหลังจาก 100 ms เป็นต้นไปจะสะท้อนในเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แ่งมุมของลักษณะการตอบสนองต่อสิ่งกระตุ้นซึ่งก็คือระบบความรู้ความเข้าใจหรือการรู้จำ (Cognitive) โดยทั่วไปแล้วองค์ประกอบของสัญญาณ ERPs จะแบ่งออกได้ตามเวลาหลังจากเกิดการกระตุ้น มีดังนี้

1. ตำแหน่ง N100 คือสัญญาณที่ย้อนกลับไปทางลบที่มีขนาดใหญ่หลังจากการกระตุ้นอยู่ในช่วงเวลา 90 ถึง 200 ms โดยมีข้อสังเกตว่า N100 จะเกิดขึ้นจากสิ่งกระตุ้นที่ไม่สามารถคาดเดาได้
2. ตำแหน่ง P200 คือสัญญาณทางบวกที่อยู่ในช่วง 100 ถึง 250 ms และมีค่าแอมพลิจูดสูงสุดที่ 200 ms หลังจากเกิดการกระตุ้น ในหลายงานวิจัยจะพบว่า P200 จะมีความเกี่ยวข้องกับระบบความจำของมนุษย์ และการประมวลด้านภาษา
3. ตำแหน่ง P300 คือสัญญาณทางบวกที่อยู่ในช่วง 250 ถึง 400 ms และมีค่าแอมพลิจูดสูงสุดที่ 300 ms โดย P300 จะสะท้อนถึงกระบวนการที่เกี่ยวข้องกับการกระตุ้นแบบการประเมินหรือการจำแนกหมวดหมู่ ในการตีความสัญญาณด้วยค่าเวลาแฝง (latency) ที่เกิดขึ้นจะบอกถึงความเร็วของผลลัพธ์จากการกระตุ้นแบบการจำแนกหมวดหมู่ โดยหากมีค่าเวลาแฝงที่สั้นกว่าจะแสดงถึงประสิทธิภาพของสุขภาพจิตที่ดีกว่า ยิ่งไปกว่านั้นหากค่าแอมพลิจูดของ P300 มีค่าสูงจะบ่งบอกว่าสมองมีการตอบสนองต่อการกระตุ้นมาก ซึ่งการลดลงของค่าแอมพลิจูด P300 อย่างมีนัยยะสำคัญจะสามารถถูกพบได้ในผู้ป่วยโรคซึมเศร้าที่มีระดับความรุนแรงมาก และในผู้ป่วยที่มีความคิดที่จะฆ่าตัวตาย นอกจากนี้ในผู้ป่วยโรคไบโโพล่าก็จะพบการลดลงของแอมพลิจูดเช่นกัน

2.2.1 การวิเคราะห์สัญญาณ EEG ด้วยวิธีการ Inter-trials phase clustering

Inter-trials phase clustering คือค่าเฉลี่ยสัมบูรณ์ของเวกเตอร์เฟสที่เกิดขึ้นจากสัญญาณ Event-related potentials ณ ช่วงเวลาหนึ่งในแต่ละเหตุการณ์การกระตุ้น ที่เกิดขึ้นทั้งหมดในขอบเขตการทดลองที่เกิดถูกกำหนดไว้ [8] ซึ่งเวกเตอร์เฟสที่เกิดขึ้นในแต่ละการกระตุ้นจะถูกวางอยู่ในวงกลมหนึ่งหน่วย และมีพิกัดแบบเชิงขั้ว (Polar coordinate system) โดย ITPC จะสามารถบ่งบอกว่าในเหตุการณ์การกระตุ้นทั้งหมดที่มีลักษณะการกระตุ้นแบบเดียวกันมีความสัมพันธ์ในลักษณะเดียวกันหรือไม่ในแต่ละช่วงของเวลาและช่วงของความถี่ ซึ่งหากว่าการกระตุ้นที่เกิดขึ้นเป็นไปในทิศทางเดียวกันเวกเตอร์เฟสที่ได้ก็จะอยู่ในทิศทางเดียวกันหรือใกล้เคียงกัน โดยการคำนวณ ITPC จะสามารถหาได้จากสมการที่ 2.2

$$ITPC_{tf} = \left| \frac{1}{N} \sum_{r=1}^N e^{ik_{tfr}} \right| \quad (2.2)$$

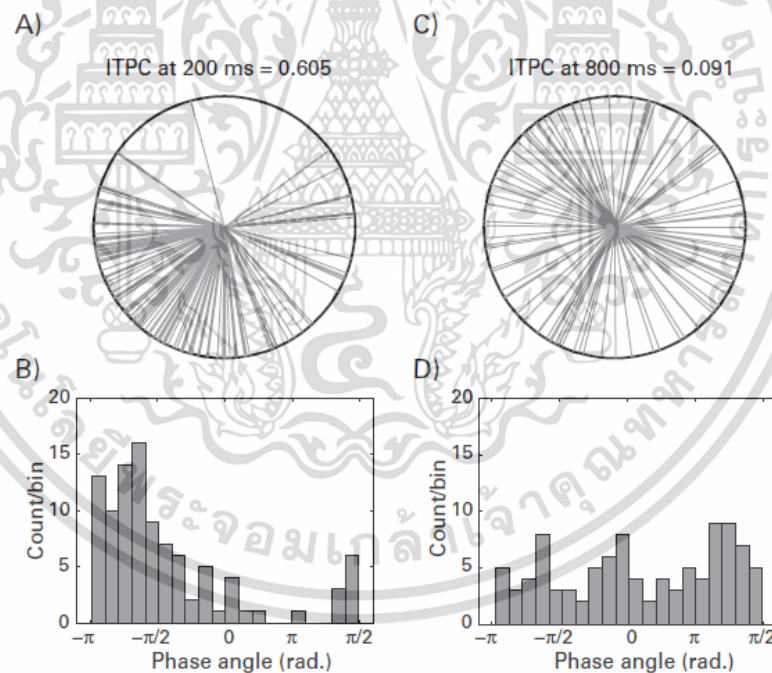
กำหนดให้ N คือจำนวนของเหตุการณ์กระตุ้น (Epoch)

k_{tfr} คือเวกเตอร์ของมุมเฟสในแต่ละจุดของสัญญาณในโดเมนเวลาความถี่

i คือจำนวนจินตภาพ

โดยค่า ITPC ที่เกิดขึ้นจากการคำนวณมีคุณสมบัติดังนี้

1. ค่า ITPC จะมีค่าอยู่ในช่วง 0 ถึง 1
2. ค่า ITPC เท่ากับ 0 จะหมายถึง ไม่มีความสัมพันธ์ที่เกิดขึ้นจากการกระตุ้นแบบเดียวกันในแต่ละช่วงเวลาและความถี่ของแต่ละเหตุการณ์
3. ค่า ITPC เท่ากับ 1 จะหมายถึงทุกๆเหตุการณ์การกระตุ้นมีความสัมพันธ์กันอย่างยิ่งยวด



รูปที่ 2.3 ความสัมพันธ์ของเวกเตอร์เฟสในทุกเหตุการณ์การกระตุ้น ที่มา: [9]

รูปที่ 2.3(A) และ รูปที่ 2.3(C) แสดงการกระจายของเวกเตอร์เฟสในระบบพิกัดเชิงขั้วที่เกิดขึ้นจากเหตุการณ์การกระตุ้นทั้งหมดโดยสังเกตได้ว่าหากเวกเตอร์เฟสมีลักษณะของทิศทางเดียวกันเช่นรูปที่ 2.3(A) จะทำให้มีค่า ITPC สูงซึ่งหมายความว่ากระตุ้นในช่วงเวลาและความถี่นั้น

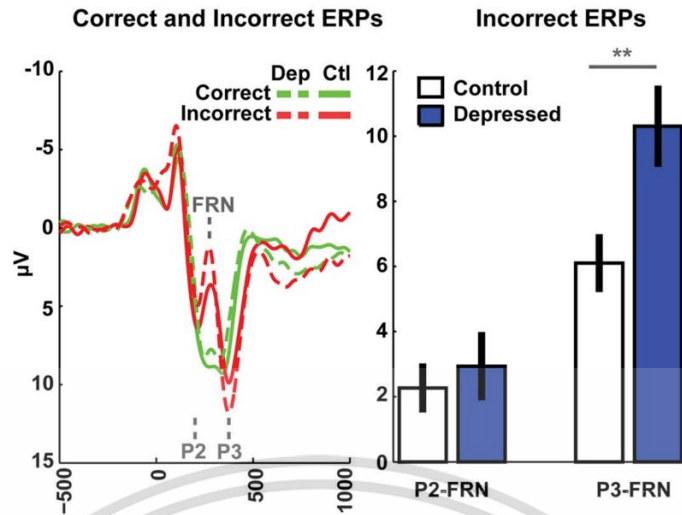
มีการตอบสนองของคลื่นสมอง EEG โกล้เคียงกันซึ่งแตกต่างกับรูปที่ 2.3(C) ที่เวกเตอร์เฟสได้กระจายเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อยู่ทั่วทั้งวงกลมหนึ่งหน่วยโดยจะสรุปได้ว่า ณ เวลาที่ 800 ms หลังจากการกระตุ้นของทุกเหตุการณ์ ไม่มีความสัมพันธ์ใดๆเกิดขึ้นเลยหรืออาจจะอนุมานได้ว่าเวกเตอร์เฟสเหล่านั้นเป็นตัวแทนของ สัญญาณรบกวน (Noise)

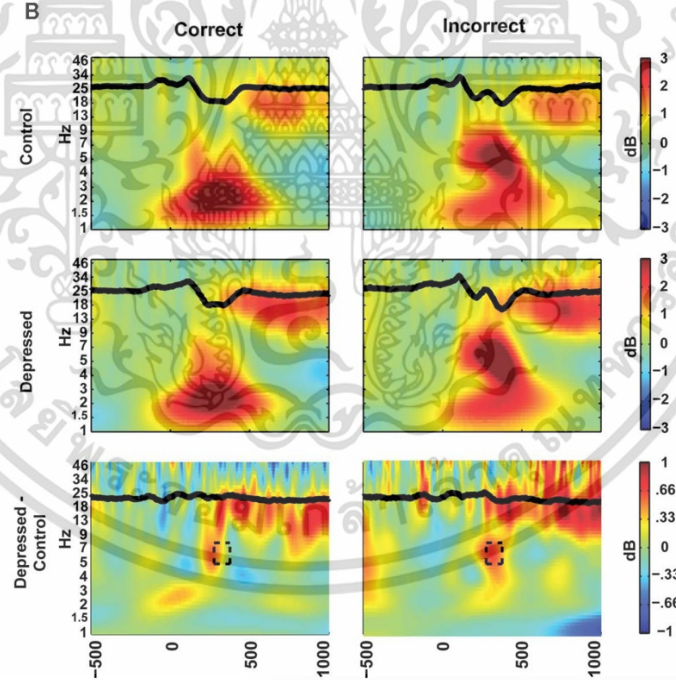
2.3 ความสัมพันธ์ระหว่างโรคซึมเศร้าและสัญญาณคลื่นสมอง EEG

ความสัมพันธ์ระหว่างโรคซึมเศร้าและสัญญาณคลื่นสมอง EEG จะเชื่อมโยงไปยังส่วนหนึ่งของสมองที่มีชื่อเรียกว่า Medial prefrontal cortex (mPFC) [10] ซึ่งเป็นส่วนที่เกี่ยวข้องกับระบบการรู้จำและพฤติกรรมของมนุษย์โดยเฉพาะอย่างยิ่งในส่วนของ Anterior cingulate cortex (ACC) ที่มีหลักฐานปรากฏไว้ว่ามีความเกี่ยวข้องกับด้านอารมณ์ของมนุษย์ และเป็นศูนย์กลางของระบบที่มีความซับซ้อนและมีการตอบสนองต่อความเครียดที่เกิดขึ้นในมนุษย์ โดยวิธีการตรวจสอบสัญญาณคลื่นสมองส่วน ACC เพื่อหาความแตกต่างกันระหว่างผู้ป่วยโรคซึมเศร้าและกลุ่มสุขภาพปกติ จะใช้วิธีการ Reinforcement learning ซึ่งเป็นการทดสอบเชิงบังคับให้เกิดการลงโทษ (Reward and Punishment) โดยในผู้ป่วยที่เคยเป็นโรคซึมเศร้าและผู้ป่วยรายปัจจุบัน จะมีการเปลี่ยนแปลงในสัญญาณคลื่นสมอง EEG เมื่อเกิดการถูกลงโทษหรือบังคับให้เกิดเหตุการณ์นั้น โดยการวัดการตอบสนองต่อการกระตุ้นแบบลงโทษที่สะท้อนการทำงานของ mPFC คือ Feedback-related negativity (FRN) ซึ่งเป็นองค์ประกอบหนึ่งของสัญญาณ ERPs โดยจะแสดงให้เห็นชัดเจนในย่านความถี่ที่ต่ำของสัญญาณ EEG ซึ่งสามารถเกิดความผิดปกติของสัญญาณ (Signal of error) เมื่อเกิดเหตุการณ์กระตุ้นแบบลงโทษและการทำให้สับสน โดยพบว่าในผู้ป่วยโรคซึมเศร้าจะมีความผิดปกติสัญญาณที่มีแอมพลิจูดขนาดใหญ่ที่ตำแหน่ง N200 และ P300 ในสัญญาณ ERPs เมื่อเทียบกับกลุ่มสุขภาพปกติ

จากรูปที่ 2.4 เป็นกราฟที่แสดงให้เห็นถึงการตอบสนองของสัญญาณ ERPs ของจุดอิเล็กโทรด FCz ที่เกิดจากการกระตุ้นแบบ Reward (correct) และ Punishment (Incorrect) โดยในผู้ป่วยโรคซึมเศร้า (Depressed) จะมีแอมพลิจูดที่บริเวณองค์ประกอบ N200 และ P300 ที่มากกว่ากลุ่มสุขภาพปกติเมื่อมีการกระตุ้นแบบลงโทษหรือการบังคับให้ตอบคำถามผิด ส่วนในรูปที่ 2.5 ซึ่งเป็นการแสดงสัญญาณ ERPs แบบ time-frequency domain จะเห็นว่าในบริเวณของสัญญาณ ERPs ในย่านความถี่ที่ต่ำหรือช่วงความถี่ที่ 4-8 Hz ผู้ป่วยโรคซึมเศร้าจะมีแอมพลิจูดที่ผิดปกติไปจากกลุ่มสุขภาพปกติ และหากมองในแง่มุมของการกระตุ้นแบบ Reward (correct) จะพบว่าค่าแอมพลิจูดที่ P300 ของผู้ป่วยโรคซึมเศร้าจะมีค่าต่ำกว่ากลุ่มสุขภาพปกติ โดยค่าการตอบสนองของการกระตุ้นชนิดนี้จะอยู่ในย่านความถี่เดลต้าหรือช่วงความถี่ที่ 0-4 Hz



รูปที่ 2.4 กราฟสัญญาณ ERPs แสดงการตอบสนองของการกระตุ้นแบบ Reward (correct) และ Punishment (Incorrect) ของผู้ป่วยโรคซึมเศร้าและกลุ่มสุขภาพปกติ ที่มา: [10]



รูปที่ 2.5 กราฟสัญญาณ ERPs ในรูปแบบของ Spectrogram ทาง time-frequency domain ที่มา: [10]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

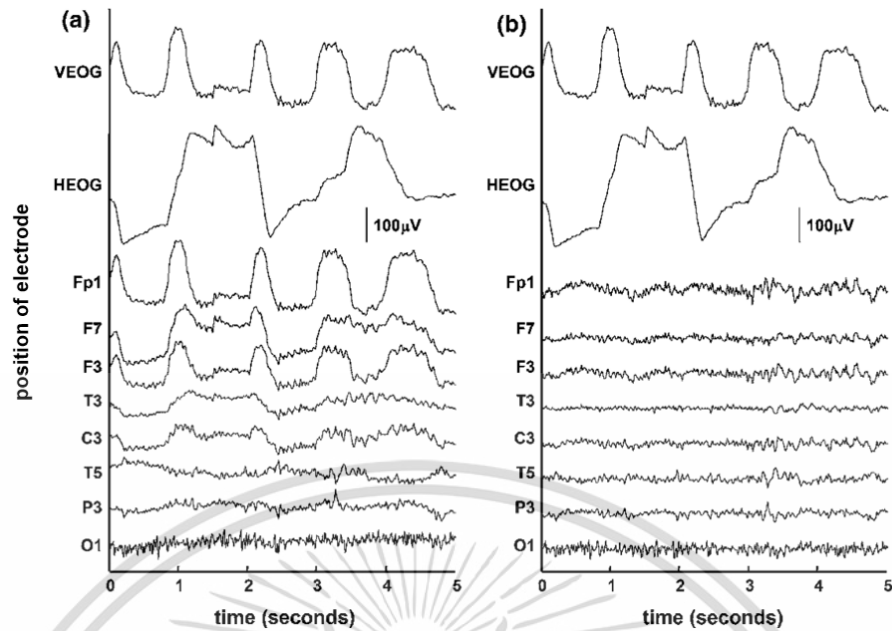
2.4 กระบวนการวิเคราะห์องค์ประกอบอิสระ (Independent Component Analysis)

การวิเคราะห์องค์ประกอบอิสระ หรือ Independent Component Analysis (ICA) คือวิธีการวิเคราะห์เพื่อแยกองค์ประกอบจากสัญญาณผสม (Mixed Signal) เพื่อหาสัญญาณอิสระที่กำเนิดจากแหล่งกำเนิดสัญญาณหลายจุด (Multivariate data) [11] ซึ่งปัญหาการปนของสัญญาณสามารถเกิดขึ้นได้ในสัญญาณคลื่นสมอง EEG ที่มีอิเล็กโทรดหลายจุดบนศีรษะและรับสัญญาณไฟฟ้าจากกิจกรรมที่เกิดขึ้นในสมองหลายแห่งพร้อมกันจากสมองแต่ละส่วน โดยปัญหานี้จะมีความคล้ายคลึงกับปัญหาที่เรียกว่า Blind source separation (BSS) หรือ Blind signal separation ซึ่งผู้วิจัยมีความต้องการเพียงแต่สัญญาณที่มาจากกระตุ้นในแต่ละจุดให้ตรงกับจุดที่อิเล็กโทรดถูกวางไว้เพื่อรับสัญญาณไฟฟ้าจากสมอง แต่ทว่าอิเล็กโทรด ณ จุดๆหนึ่งบนศีรษะสามารถที่จะรับสัญญาณจากส่วนของสมองที่อยู่ใกล้เคียงกับจุดที่สนใจได้ซึ่งทำให้เกิดปัญหาความผิดเพี้ยน (Distort) และปนเปื้อน (Contaminate) ในสัญญาณคลื่นสมอง EEG

โดยปัญหาการปนกันของสัญญาณ ในกระบวนการบันทึกสัญญาณคลื่นสมองที่มีผลกระทบต่อการบันทึกมากที่สุดก็คือสัญญาณจากขั้วอิเล็กโทรดตำแหน่ง VEOG และ HEOG โดยเป็นตำแหน่งที่อยู่บริเวณตาของมนุษย์ ซึ่งขั้วอิเล็กโทรดนี้จะใช้วัดสัญญาณไฟฟ้าจากการขยับของกล้ามเนื้อลูกตาทั้งในแนวตั้ง (VEOG) และแนวขวาง (HEOG) ที่เกิดขึ้นตลอดการทดลอง โดยสัญญาณจากขั้วทั้งสองจะมีขนาดแอมพลิจูดที่ใหญ่ซึ่งส่งผลต่ออิเล็กโทรดจุดอื่นเมื่อนำค่าสัญญาณจากคลื่นสมองไปวิเคราะห์ข้อมูล จากรูปที่ 2.6 จะแสดงตัวอย่างของสัญญาณที่ตำแหน่งทั้งสอง โดยสัญญาณรบกวนที่เกิดขึ้นจากร่างกายของมนุษย์จะถูกเรียกว่า Artifacts ซึ่งที่รูป 2.6 (a) คือชุดสัญญาณ EEG ที่ได้รับอิทธิพลจากการเคลื่อนไหวของลูกตาที่ก่อกำเนิดเป็นแอมพลิจูดขนาดใหญ่ โดยจะสังเกตเห็นได้ว่ารูปร่างของแอมพลิจูดที่ขั้ว VEOG และ HEOG ได้กระทบต่อสัญญาณที่วัดได้จากขั้วอิเล็กโทรดที่จุดอื่น และเมื่อได้วิเคราะห์องค์ประกอบอิสระของสัญญาณนี้และหาสัญญาณที่แท้จริงได้แล้วจะให้ผลของสัญญาณ EEG [12] ดังรูปที่ 2.6 (b) โดยคำนิยามของการวิเคราะห์องค์ประกอบอิสระ (ICA) ของสัญญาณผสมจะมีข้อสมมุติฐานดังนี้

1. แหล่งกำเนิดของสัญญาณจะมีอิสระแยกออกจากกัน
2. จำนวนขององค์ประกอบอิสระจะมีจำนวนเท่ากับจำนวนสัญญาณผสมที่เกิดขึ้น
3. ค่าสัญญาณในแต่ละแหล่งกำเนิดจะต้องไม่เป็นสัญญาณที่มีลักษณะการกระจายแบบเกาส์เซียน (Non-Gaussian distributions)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.6 สัญญาณ EEG ที่ถูกการเคลื่อนที่ของร่างกายรบกวน ที่มา: [13]

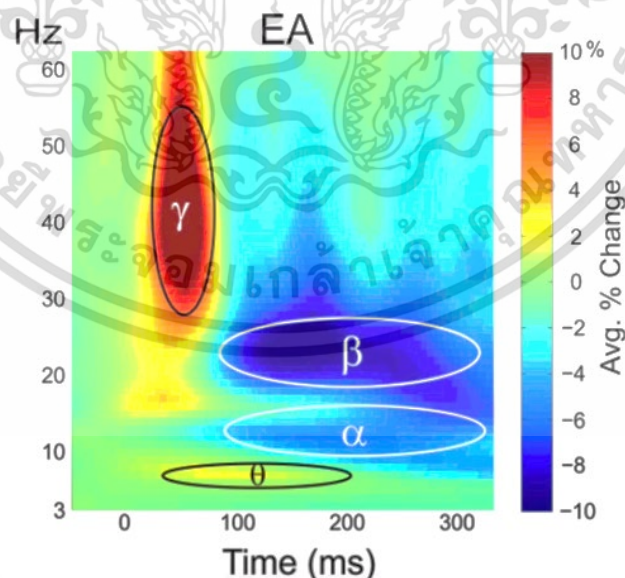
$$s = Wx \quad (2.3)$$

$$\begin{bmatrix} s_1 \\ s_2 \\ s_3 \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & w_{13} \\ w_{21} & w_{22} & w_{23} \\ w_{31} & w_{32} & w_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} \quad (2.4)$$

ข้อมูลจากสัญญาณคลื่นสมอง EEG หรือสัญญาณผสมจะถูกกำหนดให้เป็น random vector $x = (x_1, \dots, x_m)^T$ และ องค์ประกอบอิสระหรือค่าจากสัญญาณต้นกำเนิด (Independent Component) ถูกกำหนดให้เป็น random vector $s = (s_1, \dots, s_n)^T$ โดยในกระบวนการกำเนิดสัญญาณผสมมาจาก Linear transformation W จะได้สมการของการแปลงสัญญาณที่ 2.3

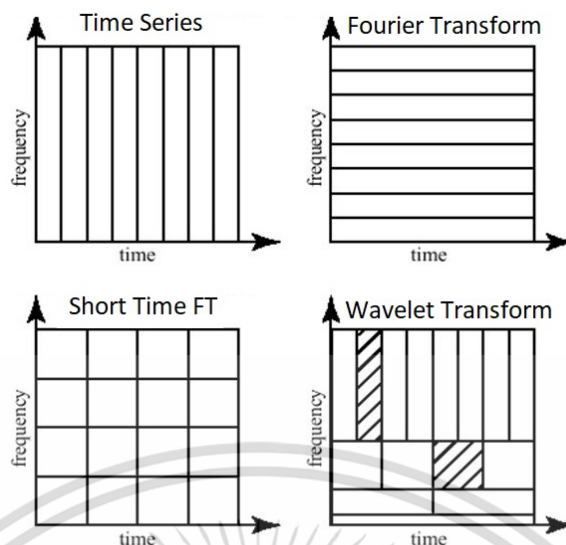
2.5 กระบวนการแปลงสัญญาณ EEG ด้วยวิธีการ Time-frequency analysis

Time-frequency analysis คือวิธีการหนึ่งในการประมวลผลทางสัญญาณ หรือ Signal processing ซึ่งวิธีการนี้จะเป็นการศึกษาสัญญาณในทั้งทางโดเมนของเวลา (Time domain) และโดเมนของความถี่ (Frequency domain) ในเวลาพร้อมกัน [14] แทนที่จะทำการวิเคราะห์เพียงแค่ในแง่ของสัญญาณเพียงแค่มิติเดียว ซึ่งผลลัพธ์ที่ได้จากการวิเคราะห์ทางเวลา-ความถี่จะออกมาในรูปแบบของกราฟ Spectrogram ที่บ่งบอกได้ทั้งค่าแอมพลิจูดของโดเมนเวลาในแต่ละช่วงความถี่ของสัญญาณๆหนึ่ง ซึ่งมีประโยชน์ในการวิเคราะห์สัญญาณคลื่นสมอง EEG ของมนุษย์เป็นอย่างมาก อันเนื่องมาจากสมองของมนุษย์จะผลิตสัญญาณ EEG ที่มีความถี่ที่แตกต่างกันออกมาตามความผันแปรของกิจกรรมที่เกิดขึ้นภายในสมองรวมไปถึงขนาดของสัญญาณที่เกิดขึ้นตามเวลาที่มาจากเหตุการณ์การกระตุ้น จากงานวิจัยเกี่ยวกับการวิเคราะห์สัญญาณ EEG ด้วยวิธีทางเวลา-ความถี่ที่ผ่านมาพบว่าได้มีการใช้การแปลงสัญญาณหลากหลายรูปแบบเช่น Short-time Fourier Transform (STFT) แต่ในความเป็นจริงของสัญญาณ EEG นั้น ในแต่ละช่วงความถี่ของสัญญาณจะมีการตอบสนองต่อเวลาที่แตกต่างกัน ดังที่แสดงในรูปที่ 2.6 จะพบว่าความถี่แต่ละช่วงจะใช้เวลาในการกำเนิดและสิ้นสุดไม่เท่ากันโดยแปรผกผันกันตามทฤษฎีของเวลาและความถี่ แต่ทว่าวิธีแปลงแบบสัญญาณให้อยู่ในรูปแบบของ spectrogram ของเวลาและความถี่แบบ STFT จะไม่สามารถที่จะปรับความละเอียดของเวลา (Time-resolution) และความละเอียดของความถี่ (Frequency-resolution) ได้ซึ่งอาจทำให้เกิดการสูญเสียข้อมูลที่สำคัญของสัญญาณ EEG ในแต่ละช่วงไปได้



รูปที่ 2.7 ตัวอย่างการตอบสนองของแต่ละช่วงความถี่ของสัญญาณ EEG ที่มา: [15]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



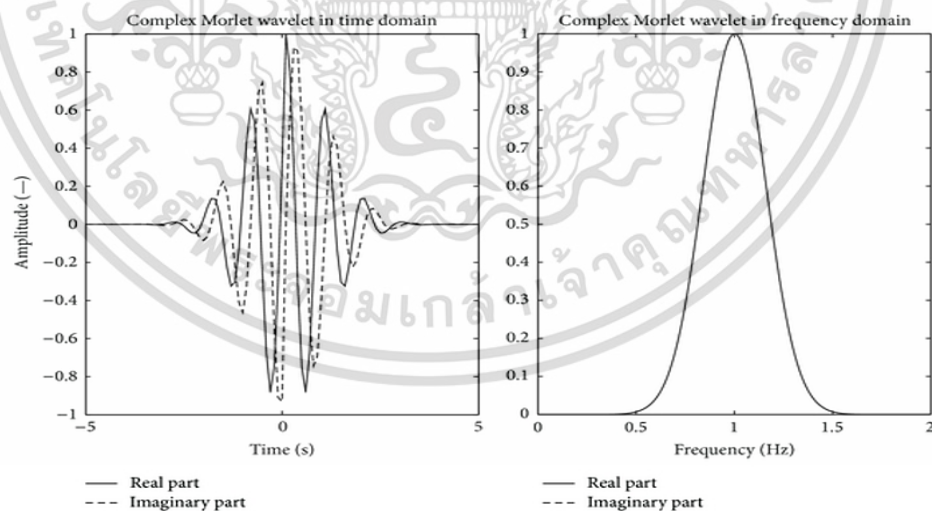
รูปที่ 2.8 การเปรียบเทียบความละเอียดทางด้านเวลาและความถี่ของวิธี STFT และวิธี Wavelet transform ที่มา: [16]

จากรูปที่ 2.8 คือการเปรียบเทียบความละเอียดทางเวลา (Time-resolution) และความละเอียดทางความถี่ (Frequency-resolution) ซึ่งจะพบว่าสัญญาณที่อยู่ในโดเมนเวลาหรือสัญญาณคลื่นสมอง EEG จะมีความละเอียดทางเวลาสูงแต่ความละเอียดทางความถี่จะเป็นศูนย์ ในทางกลับกันเมื่อแปลงสัญญาณด้วยวิธี Fourier transform เพื่อให้อยู่ในโดเมนของความถี่สัญญาณจะมีความละเอียดทางความถี่สูงแต่ไม่มีค่าใดๆจากด้านเวลาแสดงออกมาในการแปลงนี้เลย และหากสังเกตการแปลงแบบ STFT จะพบว่าในทุกๆช่วงของเวลาและความถี่จะมีขนาดที่แบ่งออกมาในแต่ละช่วงเท่ากัน แต่วิธี Wavelet Transform เป็นวิธีที่สามารถปรับความละเอียดในด้านเวลาและความถี่ได้ (Time-Frequency trade-off) โดย wavelet transform จะมีคุณสมบัติดังนี้

- สำหรับย่านความถี่ต่ำจะมีค่าความละเอียดของความถี่สูง และมีความละเอียดทางเวลาต่ำ
- สำหรับย่านความถี่สูงจะมีค่าความละเอียดของความถี่ต่ำ และมีความละเอียดทางเวลาสูง

2.5.1 การแปลงสัญญาณ EEG ด้วยวิธี Morlet wavelet transformation

Morlet wavelet คือ สัญญาณที่เกิดจากการควมรวมกันระหว่างสัญญาณไซน์ (sine wave) และเกาส์เซียน (Gaussian) โดยในทางการวิเคราะห์เวลา-ความถี่ สัญญาณไซน์จะถูกแทนที่ด้วย complex-valued sine wave และถูกเรียกว่า “Complex Morlet Wavelet (CMW)” [17] ซึ่งคุณสมบัติของ CMW เมื่อทำการคอนโวลูทกับสัญญาณที่สนใจที่อยู่ในโดเมนของเวลา ผลลัพธ์ที่ได้จากการคอนโวลูทคือสัญญาณ complex-valued ที่มีกำลังงานชั่วขณะ (Instantaneous power) และ ค่าเฟส (phase) ในแต่ละจุดเวลา โดยกระบวนการคอนโวลูทของ wavelet กับสัญญาณอาจถูกเรียกว่ากระบวนการ “Template-matching” ซึ่งเป็นการเปรียบเทียบกันระหว่างสัญญาณกับ wavelet และค่าที่ได้ในแต่ละจุดของเวลาจากการคอนโวลูทจะบ่งบอกถึงความคล้ายกันระหว่างสัญญาณที่สนใจและ wavelet ซึ่งเป็นเสมือนการสกัดข้อมูลในแต่ละจุดของความถี่และเวลาที่สนใจ โดย Complex Morlet wavelet (CMW) จะมีลักษณะในทางของโดเมนเวลาและโดเมนความถี่ตามที่แสดงในรูปที่ 2.9 ซึ่งสังเกตได้ว่าในทางโดเมนความถี่ของ CMW จะมีลักษณะเหมือน Gaussian ซึ่งทำหน้าที่คล้ายกับ Bandpass filter หรือการกรองความถี่ในส่วนที่ต้องการให้กับสัญญาณที่นำมาคอนโวลูทด้วย โดยค่าความกว้างของ Gaussian ในทางโดเมนความถี่จะถูกกำหนดด้วยค่า number of cycle



รูปที่ 2.9 complex morlet wavelet ในรูปของโดเมนเวลาและโดเมนความถี่ ที่มา: [17]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

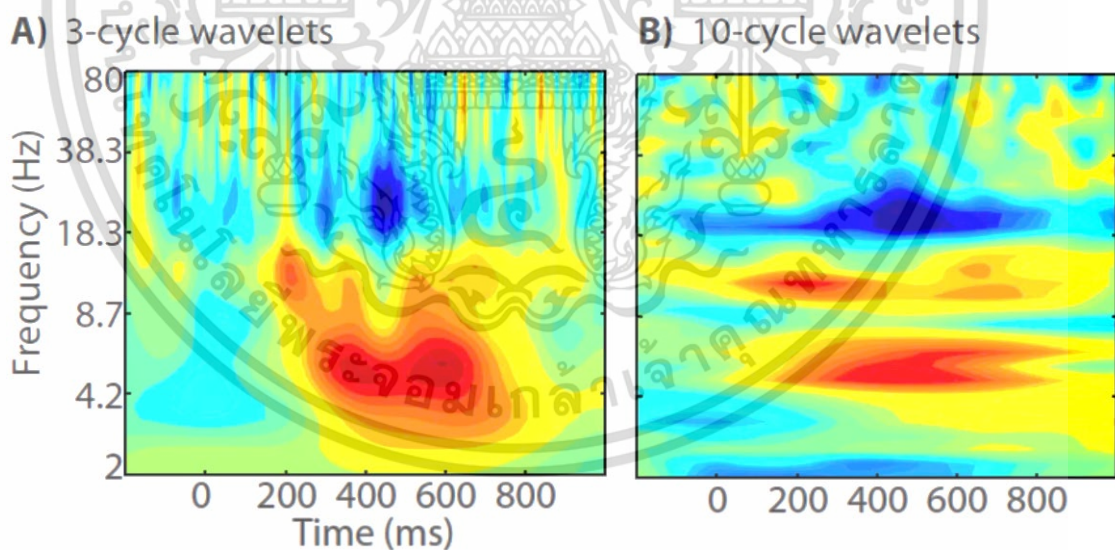
Complex Morlet wavelet (CMW) มีสมการดังนี้

$$CMW = e^{2i\pi ft} \cdot e^{\frac{-t^2}{2\sigma^2}} \quad (2.5)$$

โดยที่ t และ f คือเวลาในหน่วยวินาทีและความถี่ในหน่วย Hz ส่วน i คือค่าจินตภาพ $i = \sqrt{-1}$ และเพื่อป้องกันการเลื่อนของเฟสค่าตรงกลางของ wavelet ควรอยู่ที่เวลา $t = 0$

$$\sigma = \frac{n}{2\pi f} \quad (2.6)$$

σ คือค่าความกว้าง (Width) ของ Gaussian โดยค่า n คือค่า “number of cycles” ซึ่งเป็นตัวกำหนดความละเอียดของเวลาและความละเอียดของความถี่โดยมีลักษณะแบบ Time-frequency trade-off โดยการวิเคราะห์สัญญาณจากระบบประสาท (neurophysiology data) เช่น EEG, MEG และ LFP ช่วงของค่า n จะถูกกำหนดไว้ตั้งแต่ 2 ถึง 15 และค่าความถี่ (f) จะอยู่ในช่วง 2 H ถึง 80 Hz



รูปที่ 2.10 ความแตกต่างของ Spectrogram จากสัญญาณต้นกำเนิด

เดียวกันที่มีค่า number of cycle ต่างกัน ที่มา: [18]

จากรูปที่ 2.10 เป็นรูปที่แสดง Spectrogram ของสัญญาณ EEG ที่เกิดการกระตุ้นแตกต่างกันที่รูป 2.10 (A) ได้ปรับค่า number of cycle ของ complex morlet wavelet ไว้ที่ 3 cycle ซึ่ง

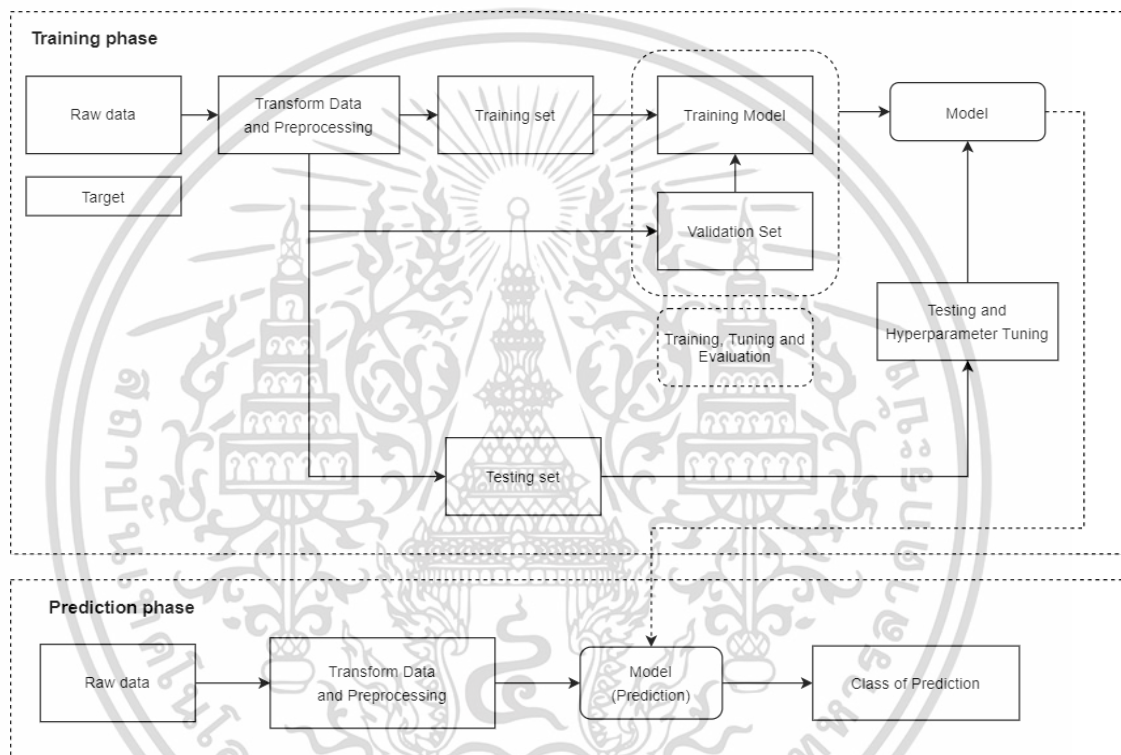
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จะสังเกตได้ว่ารูป spectrogram สามารถตรวจเจอการตอบสนองชั่วขณะเป็นเวลา 400 ms และ 600ms ที่มีขนาดของแอมพลิจูดสูงแต่ในทางกลับกัน รูปที่ 2.10 (B) ที่มีค่า n เท่ากับ 10 จะให้ลักษณะของแอมพลิจูดที่เกิดขึ้นในวงกว้าง จึงสามารถอนุมานได้ว่าที่ค่า number of cycle ต่ำ การแสดงสัญญาณในรูปของ spectrogram จะมี temporal precision หรือก็คือความละเอียดของสัญญาณแบบชั่วขณะที่ดีกว่า ซึ่งที่ค่า number of cycle สูง การแสดงสัญญาณในรูปของ spectrogram จะมี spectral precision หรือก็คือความละเอียดของสัญญาณตลอดทั้ง window ของสัญญาณที่ดีกว่า

2.6 การออกแบบระบบจำแนกผู้ป่วยโรคซึมเศร้าด้วยวิธีการเรียนรู้ของเครื่อง (Machine learning) และวิธีการเรียนรู้แบบเชิงลึก (Deep learning)

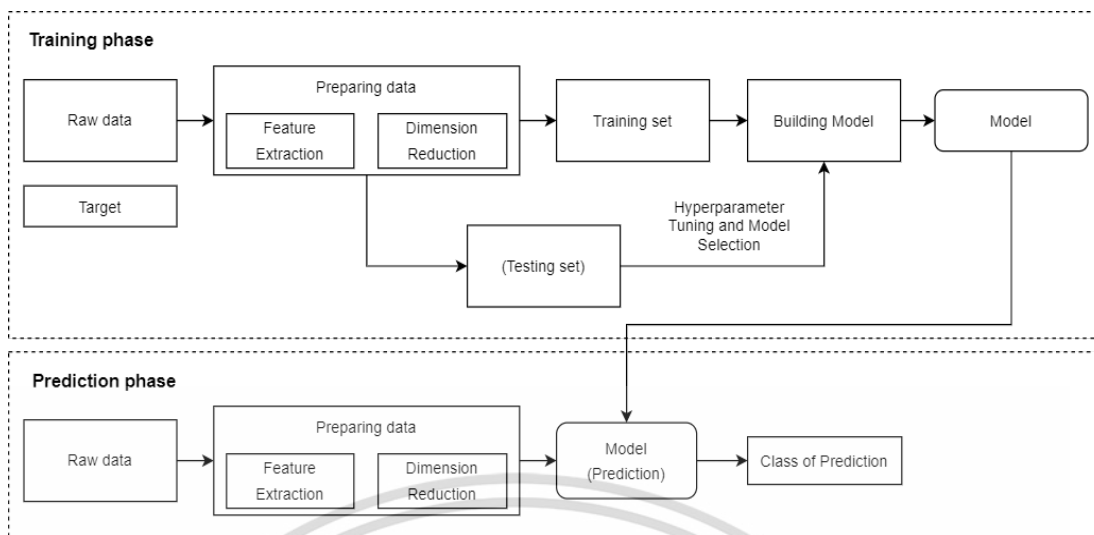
ระบบการเรียนรู้ของเครื่องแบบดั้งเดิม สามารถแบ่งออกได้เป็นสามประเภทหลักๆโดยแบ่งได้จากวิธีการสอน คือ การเรียนรู้แบบมีผู้สอน (Supervised machine learning) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised machine learning) และการเรียนรู้แบบเสริมกำลัง (Reinforcement learning) โดยการออกแบบระบบจำแนกผู้ป่วยโรคซึมเศร้า จะนำการเรียนรู้ของเครื่องแบบมีผู้สอน มาออกแบบระบบจำแนก ซึ่งในการสร้างการเรียนรู้ของเครื่องประเภทนี้จำเป็นต้องอาศัยข้อมูลที่มีการระบุกลุ่มของข้อมูลไว้ โดยการสร้างระบบจำแนกจะเริ่มต้นจากการเตรียมข้อมูลของผู้ป่วยโรคซึมเศร้า (Raw data) โดยข้อมูลจะถูกระบุกลุ่มไว้ว่าเป็นผู้ป่วยโรคซึมเศร้าหรือเป็นกลุ่มสุขภาพปกติ (Label of data) และในการสอนให้โมเดลการเรียนรู้ของเครื่องให้สามารถจำแนกความแตกต่างระหว่างสองกลุ่มข้อมูลได้ ข้อมูลทั้งหมดจะถูกแบ่งเป็น 3 ชุดได้แก่ ชุดข้อมูลสำหรับสอน (Training data) ชุดข้อมูลสำหรับประเมิน (Validation data) และชุดข้อมูลสำหรับทดสอบ (Testing data) โดยข้อมูลทั้งหมดนี้จำเป็นต้องเข้าสู่กระบวนการเตรียมข้อมูลต่างๆก่อนที่จะนำไปสอนให้กับโมเดลจำแนก เริ่มจากการนำข้อมูลผ่านกระบวนการเตรียมข้อมูล (Data preprocessing) ซึ่งรวมไปถึงกระบวนการประมวลผลทางสัญญาณ (Signal processing) เพื่อให้ข้อมูลมีความพร้อมก่อนที่จะนำไปสกัดคุณลักษณะ (Feature extraction) เพื่อหาข้อมูลเชิงลึกที่แฝงอยู่ภายในและนำไปให้โมเดลการเรียนรู้ของเครื่องได้ประมวลผล จากนั้นจะทำการลดมิติของข้อมูล (Dimension reduction) เพื่อลดความซ้ำซ้อนที่เกิดขึ้นในข้อมูล ซึ่งขั้นตอนสุดท้ายจะนำชุดข้อมูลสำหรับทดสอบมาทดสอบหาประสิทธิภาพกับโมเดลจำแนกที่ได้มา

โดยในการออกแบบโมเดลการเรียนรู้แบบเชิงลึก จะมีความคล้ายคลึงกับโมเดลการเรียนรู้ของเครื่องเพียงแต่โมเดลการเรียนรู้เชิงลึกจะไม่มีกระบวนการสกัดคุณลักษณะแยกออกมาภายนอก แต่จะรวมอยู่ในกระบวนการสอนของโมเดลการเรียนรู้แบบเชิงลึกซึ่งทำให้ผู้สร้างไม่จำเป็นต้องลดมิติของข้อมูลเพื่อลดความซับซ้อนให้กับโมเดล แต่ทว่าโมเดลสามารถที่จะเรียนรู้ความซับซ้อนเหล่านั้นได้ นอกจากนี้ในกระบวนการสอนของโมเดลการเรียนรู้แบบเชิงลึกจะใช้ข้อมูลชุดประเมิน เพื่อใช้ในการปรับ weight ให้โมเดลมีประสิทธิภาพมากที่สุด



รูปที่ 2.11 แผนภาพแสดงการสร้างโมเดลการเรียนรู้แบบเชิงลึก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.12 แผนภาพแสดงการสร้างโมเดลการเรียนรู้ของเครื่อง

2.7 การลดมิติของข้อมูล (Dimension reduction)

2.7.1 การวิเคราะห์หาค่าประกอบหลัก (Principal Component Analysis: PCA)

การวิเคราะห์หาค่าประกอบหลัก หรือ PCA คือการวิเคราะห์ข้อมูลหลายตัวแปรเพื่อหาความสัมพันธ์ของตัวแปรที่มีอยู่ทั้งหมดเพื่อลดขนาดของความซับซ้อนของข้อมูลให้ง่ายต่อการอธิบาย [19] และตีความซึ่งสามารถใช้ลดขนาดของคุณสมบัติ (Feature) ให้เล็กลงก่อนสอนให้กับโมเดลการเรียนรู้แบบเชิงลึกหรือการเรียนรู้ของเครื่องทำให้โมเดลไม่จำเป็นต้องเรียนรู้ตัวแปรที่ไม่มีความสัมพันธ์กับข้อมูลทั้งหมด หลักการวิเคราะห์หาค่าประกอบหลักเปรียบเสมือนการเปลี่ยนมุมมองของข้อมูลเพื่อให้เห็นภาพรวมทั้งหมดโดยจะไม่กระทบต่อข้อมูลจริงที่มีอยู่ PCA จะทำการสร้างตัวแปรที่เรียกว่า component โดยแต่ละ component จะไม่มีความสัมพันธ์กันเลย ในการตีความ component ตัวแรกจะมีค่า variance หรือค่าความแปรปรวนสูงที่สุดซึ่งจะสามารถอธิบายข้อมูลได้มากที่สุดและ component ที่รองลงมาจะมีค่า Variance ลดลงตามลำดับ




รูปที่ 2.13 การลดมิติด้วยการวิเคราะห์องค์ประกอบหลัก (PCA) ที่มา: [20]

2.8 โมเดลจำแนกข้อมูลแบบการเรียนรู้ของเครื่อง

2.8.1 โมเดลจำแนกข้อมูลด้วยอัลกอริทึม k-Nearest Neighbors (k-NN)

โมเดลจำแนกข้อมูลแบบ k-NN [21] เป็นอัลกอริทึมที่ใช้ในการจำแนกกลุ่มของข้อมูล (Class) หลักการของวิธีการนี้เป็นการหาระยะห่างระหว่างแต่ละตัวแปร (Attribute) โดยเริ่มจากการกำหนดค่า K ซึ่งเป็นค่าของกลุ่มตัวแปรที่ใกล้เคียงกันที่สุดและคำนวณระยะห่าง (Distance) จากข้อมูลสมมุติ (Unknown class) ระหว่างข้อมูลที่มีทั้งหมด จากนั้นเป็นกระบวนการจัดลำดับของระยะห่างเพื่อเลือกพิจารณาชุดข้อมูลที่ใกล้เคียงกันโดยจะพิจารณาตามจำนวน K ที่กำหนดไว้ โดยในการคำนวณหาระยะห่างจะมีการคำนวณหลายวิธี ได้แก่ การคำนวณระยะทางแบบ Euclidean และการคำนวณระยะทางแบบ Manhattan



รูปที่ 2.14 ตัวอย่างการจำแนกกลุ่มแบบ k nearest neighbor ที่มา: [22]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตัวอย่างรูปที่ 2.14 เป็นการแสดงการจำแนกกลุ่มข้อมูลด้วยวิธีการ k-nearest neighbor ซึ่งจะเห็นได้ว่าการเริ่มต้นของอัลกอริทึมจะป้อนข้อมูลที่สนใจลงไปในกลุ่มข้อมูลที่มีที่รู้จักชื่อกลุ่มอยู่แล้ว ดังในรูปคือ Class A และ Class B จากนั้นทำการคำนวณหาค่าระยะห่างจากข้อมูลที่ได้ที่มีอยู่ใกล้กับข้อมูลที่สนใจและเรียงลำดับว่ามีข้อมูลโดยใกล้จุดข้อมูลที่สนใจบ้าง โดยการพิจารณาจะขึ้นกับค่า K หรือจำนวนค่าเพื่อนบ้านที่ยอมรับว่าใกล้ที่สุดกับจุดข้อมูลที่สนใจ หากในบริเวณใกล้จุดสนใจมีจำนวนเพื่อนบ้านหรือ class ไหนมากที่สุด ข้อมูลนั้นจะถูกกำหนดให้อยู่ในกลุ่มนั้นด้วย โดยการคำนวณระยะทางแบบ Euclidean distance มีสมการดังนี้

$$d_{euclidean}(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2.7)$$

กำหนดให้ $d(q, p)$ คือ ระยะห่างระหว่างจุดทั้งสอง


q คือ จุดข้อมูลตำแหน่งแรก

p คือ จุดข้อมูลตำแหน่งที่สอง

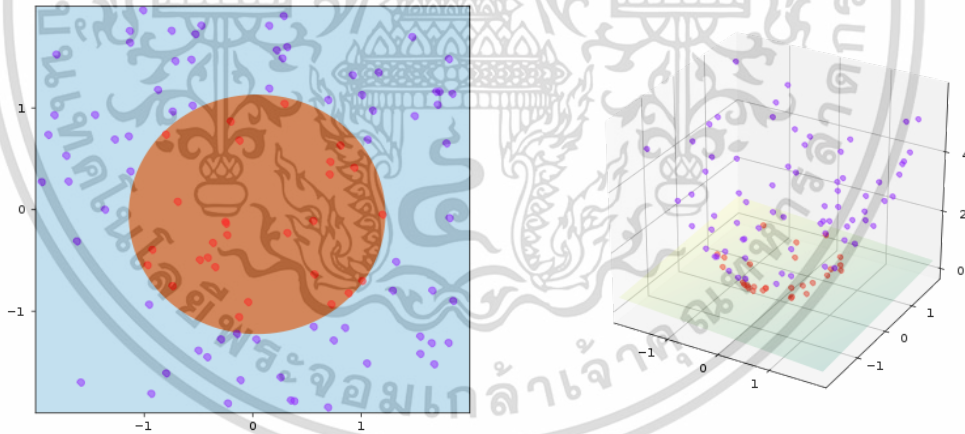
n คือ จำนวนมิติของข้อมูล

2.8.2 โมเดลจำแนกข้อมูลด้วยอัลกอริทึม Support Vector Machine (SVM)

Support Vector Machine (SVM) คืออัลกอริทึมที่มีแนวคิดการจำแนกกลุ่มของข้อมูลโดยการสร้างระนาบเส้นตรง (Hyperplane) ขึ้นมาเพื่อใช้แบ่งกลุ่มข้อมูลออกจากกัน [23] โดยโมเดลนี้จะมีประสิทธิภาพสูงกับข้อมูลที่มีความซับซ้อนรวมถึงข้อมูลที่มีคุณสมบัติ nonlinear ซึ่งใน SVM จะมีฟังก์ชัน Kernel เพื่อใช้ในการแปลง hyperplane หรือระนาบตัดสินใจให้มีรูปร่างไม่เป็นเส้นตรง โดยฟังก์ชันที่ใช้เป็น kernel ได้แก่ Polynomial, radial based function (RBF) และ Normalized polynomial kernel เป็นต้น นอกจากนี้ kernel ยังถูกใช้กับการแปลงข้อมูลจากมิติที่มีอยู่ให้ไปยังมิติที่สูงกว่าดังรูปตัวอย่างที่ 2.15 เพื่อได้มาซึ่งภาพรวมแบบใหม่ของข้อมูลและสามารถหาจุดที่ใช้จำแนกข้อมูลระหว่างกลุ่มได้ทำให้อัลกอริทึม SVM เป็นโมเดลจำแนกที่มีความยืดหยุ่นสูง โดยระนาบเส้นตรงที่ใช้แบ่งกลุ่มข้อมูลออกจากกันจะมีขอบเขตที่เรียกว่าเส้น Margin (ρ) เพื่อป้องกันข้อมูล outlier ข้ามเส้นมาโดยบังเอิญ จากรูปที่ 2.15 จะเป็นการปรับ margin ที่เรียกว่า soft margin ซึ่งเป็นการปรับขอบของเส้นแบ่งให้มีความกว้างมากที่สุดเท่าที่จะทำได้และยอมให้มีข้อมูลบางส่วนข้ามเข้ามาใน margin



รูปที่ 2.15 การจำแนกข้อมูลด้วยระนาบเส้นตรง ที่มา: [24]



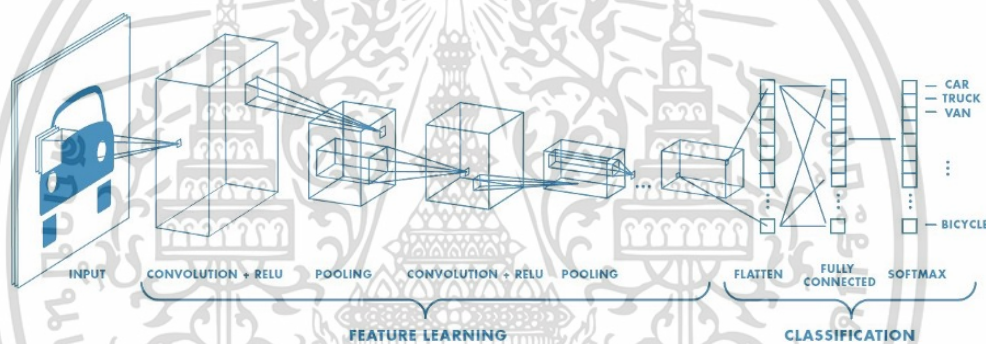
รูปที่ 2.16 แสดงการแปลงข้อมูลให้อยู่ในมิติที่สูงกว่า ที่มา: [25]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.9 โมเดลจำแนกข้อมูลแบบการเรียนรู้เชิงลึก

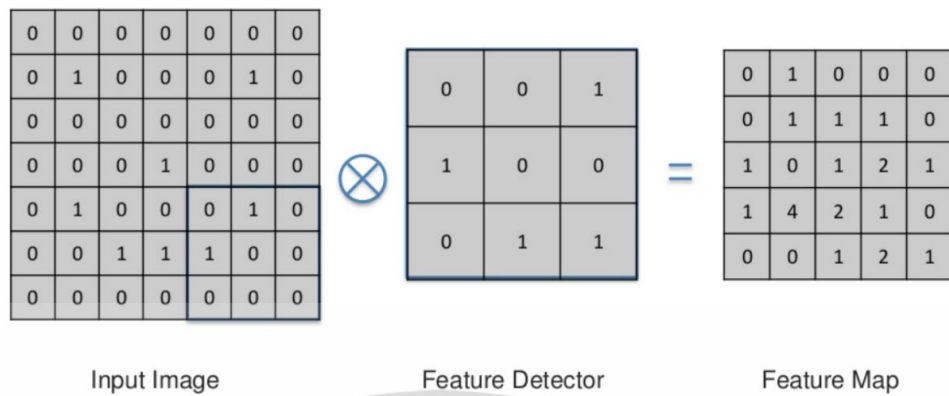
2.9.1 โมเดลจำแนกข้อมูล Convolution Neural Networks (CNN)

Convolution Neural Network หรือ CNN เป็นอัลกอริทึมการเรียนรู้แบบเชิงลึก ชนิดหนึ่งที่มีเค้าโครงมาจากโครงข่ายประสาทเทียม (Neural Network) ซึ่งถูกออกแบบมาเพื่อใช้วิเคราะห์ข้อมูลที่เป็นรูปภาพ โดยโมเดลจะเรียนรู้จากคุณลักษณะ (Feature) จากรูปร่าง ลายเส้นและสีของรูปภาพ [26] ซึ่งในโมเดลจำแนกแบบ CNN จะถูกแบ่งออกเป็นสองส่วนหลักคือ ส่วนการสกัดคุณลักษณะ (Feature Extraction) เพื่อใช้ในการดึงคุณสมบัติแฝงที่อยู่ในแต่ละรูปภาพออกมาเป็นคุณลักษณะที่เรียกว่า Feature map และส่วนที่ใช้จำแนก (Classification Layers) จะเรียนรู้คุณลักษณะที่แตกต่างกันในแต่ละรูปภาพโดยปกติแล้วขั้นที่ใช้ในการจำแนกจะใช้โครงข่ายประสาทเทียมในการเรียนรู้ความแตกต่าง ดังรูปที่ 2.17 จะแสดงให้เห็นการทำงานของ CNN



รูปที่ 2.17 การทำงานของโมเดล CNN ที่มา: [27]

องค์ประกอบสำคัญที่ใช้ในการสกัดคุณลักษณะในโมเดล CNN คือ ตัวกรอง (Filter) หรือ เคอร์เนล (kernel) โดย Filter ที่ใช้กับอินพุตที่เป็นรูปภาพปกติจะมีลักษณะเป็นตารางสองมิติที่มีขนาดพื้นที่ย่อยๆตามส่วนที่เราอยากจะพิจารณา โดยวิธีการสกัดคุณลักษณะที่เกิดขึ้นภายในโมเดล CNN จะใช้วิธี Convolution ระหว่างอินพุตกับ Filter/kernel โดยกระบวนการจะเป็นไปดังรูปที่ 2.17 ซึ่งความละเอียดของค่าคุณลักษณะจะขึ้นอยู่กับค่าการเลื่อนของ kernel ที่เรียกว่า Stride และเมื่อได้ค่าคุณลักษณะ (Feature Map) มาแล้วจะทำการลดความซับซ้อนหรือเป็นการลดมิติของข้อมูล โดยถูกเรียกว่าการ down sampling ด้วยการใช้ชั้น Pooling layer ซึ่งมีด้วยกันหลายวิธีการเช่น Max pooling, Average pooling และ Global pooling โดย max pooling จะเป็นวิธีที่นิยมที่ใช้เลือก feature ที่มีค่ามากที่สุดในแต่ละช่องของการ stride



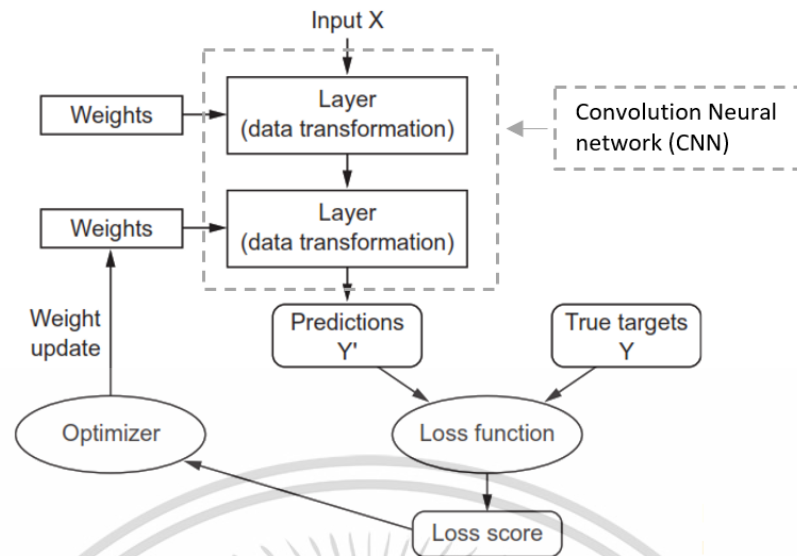
รูปที่ 2.18 การทำ Convolution เพื่อดึงคุณลักษณะของรูปภาพ ที่มา: [28]

จากรูปที่ 2.19 จะเป็นตัวอย่างในการใช้ max pooling ในการดึงค่าออกมาจาก feature map เพื่อลดความซับซ้อนที่เกิดขึ้น และเมื่อได้ Feature map ที่ผ่านการลดมิติ ขั้นตอนถัดมาคือการจัดเรียงข้อมูลในแต่ละ feature map ให้เหลือเพียงมิติเดียวโดยเรียกว่า Flatten หรือ Fully connected ก่อนนำไปให้ชั้น Classification layers เรียนรู้ feature ที่เกิดขึ้นในอินพุตที่เป็นรูปภาพ



รูปที่ 2.19 การทำ Max pooling เพื่อลดความซับซ้อน ที่มา: [28]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.20 ขั้นตอนการสอนโมเดลเรียนรู้แบบเชิงลึก


ในขั้นตอนการสอนโมเดล CNN หลังจากที่ได้สกัดองค์ประกอบที่อยู่ในรูปภาพออกมา แล้วส่งต่อให้ชั้น Classification layers ได้เรียนรู้ความแตกต่างในแต่ละ feature ที่เกิดขึ้นจากรูปภาพ โมเดลจะมีการตรวจสอบความแม่นยำเบื้องต้นด้วยทดลองทำนายกลุ่มของข้อมูล (Prediction value) และนำไปเปรียบเทียบกับกลุ่มที่มาจากข้อมูลจริง (True targets) เพื่อสังเกตว่าค่าที่ทำนายได้คลาดเคลื่อนไปจากค่าจากความเป็นจริงมากน้อยเพียงใด สามารถคำนวณจาก Loss Function (Cost Function) [29] ซึ่งค่าที่ได้จากฟังก์ชันนี้ก็คือ Error ที่เกิดจากการทำนายผล โดยทั่วไป loss function จะจำแนกได้ทั้งหมด 3 กลุ่มดังนี้

1. Regression Loss Functions
 - Mean Squared Error Loss
 - Mean Squared Logarithmic Error Loss
 - Mean Absolute Error Loss
2. Binary Classification Loss Functions
 - Binary Cross-Entropy
 - Hinge Loss
 - Squared Hinge Loss

3. Multi-Class Classification Loss Functions

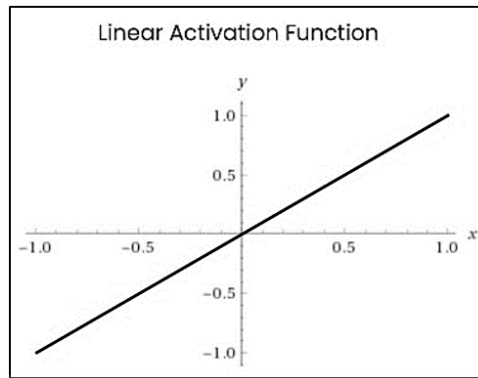
- Multi-Class Cross-Entropy Loss
- Sparse Multiclass Cross-Entropy Loss
- Fullback Leibler Divergence Loss

หลังจากที่ได้ค่าความแตกต่างระหว่างค่าที่ทำนายได้ (Predictions) และค่าจากข้อมูลจริง (Target) ซึ่งก็คือค่า Error จากนั้นกระบวนการถัดไปคือส่งค่า loss score ให้กับ Optimizer ซึ่งทำหน้าที่คำนวณค่า loss ที่เกิดขึ้นและนำไปปรับค่า weight ของโมเดลเพื่อเพิ่มความแม่นยำในแต่ละรอบของการสอนโมเดลโดยอัลกอริทึม Optimizer ที่นิยมได้แก่ตระกูลของ Gradient Descent โดยจะสามารถแบ่งออกเป็น Batch gradient descent ซึ่งจะอัปเดต weight ให้กับโมเดลครั้งเดียวต่อหนึ่งรอบการเทรน (Epoch) แต่ในความเป็นจริงแล้วการที่จะคำนวณค่า weight ทั้งหมดในคราวเดียวจำเป็นจะต้องใช้ทรัพยากรในเครื่องคอมพิวเตอร์สูงเป็นอย่างมากหากชุดข้อมูลที่ใช้ในการสอนมีขนาดใหญ่ จากนั้นมีการแก้ไขปัญหาระบบการปรับค่า weight ด้วยวิธี Stochastic Gradient Descent (SGD) โดยจะเปลี่ยนจากการอัปเดต weight ทั้งหมดในคราวเดียวเป็นการค่อยๆ อัปเดตทุกครั้ง (Iteration) หลักจากคำนวณเสร็จซึ่งเหมาะกับชุดข้อมูลที่มีขนาดใหญ่ แต่ยังคงพบกับปัญหาที่ตัว SGD อาจไม่สามารถปรับค่า weight เพื่อเพิ่มความแม่นยำให้กับโมเดลต่อไปได้เนื่องจากการคำนวณของ SGD จะเป็นการคำนวณหนึ่งครั้งแล้วอัปเดต weight ทำให้โมเดลไม่สามารถมองเห็นภาพรวมของคำตอบที่ถูกต้องของทุกๆ เpsilon ที่เกิดขึ้นใน feature จึงนำมาสู่ปัญหา Optimizer ไม่สามารถพบกับจุด Global minimum ได้และไม่ได้มาซึ่งคำตอบที่ดีที่สุดจากการปรับค่า weight และวิธีสุดท้ายคือ Mini Batch Gradient Descent โดยอัลกอริทึมนี้เป็นการรวมข้อดีของสองวิธีแรกเข้าด้วยกันโดยจากที่ต้องอัปเดต weight ทั้งหมดในคราวเดียวแล้วพบกับปัญหาเรื่องเวลาการทำงานและทรัพยากรเครื่องหรืออัปเดต weight ทีละตัวอย่างของข้อมูลซึ่งเร็วกว่าแต่อาจไม่ได้มาซึ่งคำตอบที่ดีที่สุด โดยวิธีนี้จะแบ่งชุดข้อมูลให้เป็นชุดย่อยๆ เพื่อใช้ในการคำนวณต่อการอัปเดต (mini batch) ทำให้โมเดลสามารถเห็นภาพรวมของข้อมูลมากขึ้น โดยตัวอย่างเส้นทางการหาค่าที่เหมาะสมที่สุดของ Optimizer ทั้งสามประเภทจะมีพฤติกรรมดังรูปตัวอย่างที่ 2.21 ซึ่งสังเกตได้ว่าพฤติกรรมการเดินทางของอนุภาคของแต่ละ optimizer จะแตกต่างกันตามวิธีการอัปเดตโดยวิธี SGD จะมีความกว้างของการหาค่าคำตอบมากที่สุดเนื่องมาจากการใช้ข้อมูลเพียงหนึ่งตัวอย่างต่อการอัปเดต weight ให้กับโมเดล

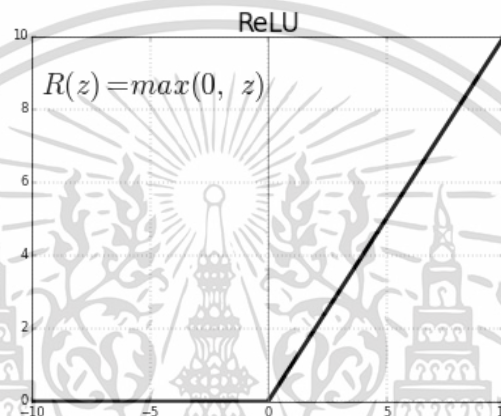


รูปที่ 2.21 เส้นทางการหาค่าตอบของ Optimizer ที่มา: [30]


ในการขั้นตอนการทำนายผลของ CNN ในส่วนสุดท้ายจะมีฟังก์ชันที่ใช้แปลงผลที่เรียกว่า Activation Function ซึ่งคือฟังก์ชันที่รับผลรวมจากการประมวลผลทั้งหมดจากทุกโหนดของโครงข่ายประสาทเทียมแล้วพิจารณาว่าค่าตอบของการทำนายควรมีค่าเป็นเท่าไรและค่าคำตอบที่ได้จะขึ้นอยู่กับชนิดของฟังก์ชันนี้ โดยการเลือก activation function จะขึ้นอยู่กับปัญหาที่โมเดลการเรียนรู้เชิงลึกต้องการแก้ไขเช่นปัญหา Regression หรือ Classification โดยปัญหา regression จะเป็นการหาค่าตอบที่อยู่เป็นการทำนายผลที่อยู่บนสมการเส้นตรง โดยจะใช้ฟังก์ชัน Linear function มาเป็นส่วนของเอาต์พุตของโมเดลโดยมีรูปร่างดังรูปที่ 2.22 และยังมีสมการ Rectified Linear Unit (ReLU) ซึ่งเป็นฟังก์ชันเส้นตรงเช่นเดียวกันดังแสดงในรูปที่ 2.23 ส่วนปัญหาด้าน Classification จะสามารถจำแนกออกเป็น Binary Classification ซึ่งเป็นการจำแนกกลุ่มสองกลุ่ม โดยมี Sigmoid function (Logistic) เป็นฟังก์ชันเอาต์พุตของโมเดล และอีกปัญหาหนึ่งคือ Multiclass Classification ซึ่งเป็นการจำแนกกลุ่มแบบหลายกลุ่มซึ่งส่วนมากจะนิยมใช้ฟังก์ชัน SoftMax function มาเป็นเอาต์พุตของฟังก์ชัน โดยรูปร่างของ Sigmoid function จะมีรูปร่างดังรูปที่ 2.24 ส่วน SoftMax function จะไม่มีรูปร่างของกราฟที่แน่นอนเนื่องจากสมการ SoftMax เป็นสมการแบบหลายตัวแปร



รูปที่ 2.22 Linear activation function ที่มา: [31]



รูปที่ 2.23 Rectified Linear Unit (ReLU) ที่มา: [31]



รูปที่ 2.24 Sigmoid activation function ที่มา: [31]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.10 งานวิจัยเกี่ยวข้องกับการสร้างโมเดลจำแนกโรคซึมเศร้าด้วยสัญญาณคลื่นสมอง

จากงานวิจัยที่เกี่ยวข้องกับการสร้างโมเดลจำแนกโรคซึมเศร้าด้วยสัญญาณคลื่นสมองที่ผ่านมา สามารถแบ่งงานวิจัยเหล่านั้นเป็น 2 กลุ่มตามประเภทของโมเดลจำแนก คือกลุ่มงานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้ของเครื่อง และกลุ่มงานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้เชิงลึก

2.10.1 งานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้ของเครื่อง

การสร้างโมเดลจำแนกที่ใช้โมเดลการเรียนรู้ของเครื่องโดยใช้ข้อมูลสัญญาณคลื่นสมองมักจะใช้จำนวนอิเล็กโทรดเพียงแค่มักไม่กี่ตำแหน่ง ในการนำมาวิเคราะห์สัญญาณและสกัดคุณลักษณะเพื่อสอนให้กับโมเดลจำแนก ตัวอย่างเช่น ในงานวิจัยของ Hanshu Cai และคณะ [32] ได้นำเสนอโมเดลจำแนกที่ใช้สัญญาณ EEG ทั้งหมด 3 อิเล็กโทรด ได้แก่ตำแหน่ง Fp1, Fp2 และ Fpz ซึ่งเป็นอิเล็กโทรดที่อยู่ในตำแหน่งของสมอง Prefrontal cortex ซึ่งเป็นศูนย์กลางของการรับรู้ทางอารมณ์ โดยในการทดลองได้เสนอวิธีการสกัดคุณลักษณะทั้งหมด 3 ประเภทคือ ค่าคุณลักษณะทางเวลา (Time Domain Feature) ค่าคุณลักษณะทางความถี่ (Frequency Domain Feature) และค่าคุณลักษณะที่ไม่เป็นเชิงเส้น (Nonlinear Feature) โดยการสกัดคุณลักษณะจะมาจากสัญญาณคลื่นสมอง EEG จากคลื่นในช่วงความถี่ต่างๆ โดยค่าคุณลักษณะทั้งหมดที่ใช้งานในงานวิจัยชิ้นนี้จะแสดงไว้ในตารางที่ 2.1 โดยมีเทคนิคการเลือกคุณลักษณะแบบ Minimal Redundancy Maximal Relevance (MRMR) เพื่อคัดเลือกคุณลักษณะที่เกี่ยวข้องมากที่สุดก่อนเข้าสู่กระบวนการสร้างโมเดลจำแนก ซึ่งโมเดลจำแนกที่ถูกใช้ในงานวิจัยนี้ได้แก่ Support Vector Machine (SVM), k-Nearest Neighbor (k-NN), Decision Tree และ Artificial Neural Network (ANN) โดยร่วมกับวิธีการแบ่งข้อมูลแบบ Cross-validation แบบ 10 fold โดยผลจากการวิจัยพบว่าโมเดลจำแนก k-NN ที่ใช้คุณลักษณะจากค่าสัมบูรณ์ของกำลังงาน (Absolute Power) ของคลื่นสมองช่วงความถี่ที่ต่ำให้ค่าความแม่นยำในการทำนายผลเฉลี่ยที่ 76.98%

ตารางที่ 2.2 ชนิดของคุณลักษณะจากสัญญาณ EEG ที่ถูกนำมาใช้ในงานวิจัย

คุณลักษณะแบบเชิงเส้น	คุณลักษณะแบบไม่เป็นเชิงเส้น
Centroid frequency	Power-Spectrum Entropy
Relative centroid frequency	Shannon Entropy
Absolute centroid frequency	Correlation Dimension
Relative power	C0-complexity
Absolute power	Kolmogorov Entropy

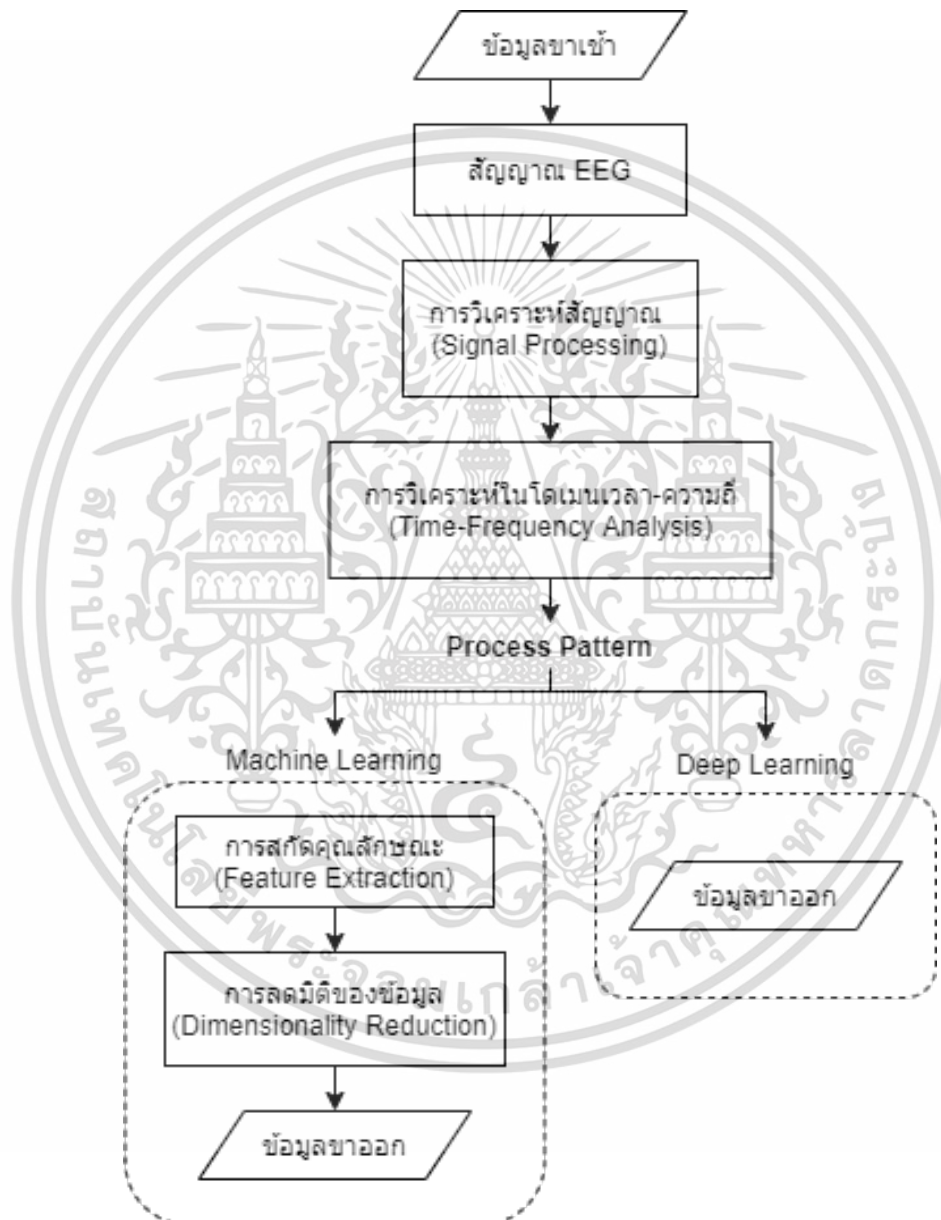
2.10.2 งานวิจัยที่ใช้โมเดลจำแนกแบบการเรียนรู้เชิงลึก

จากงานวิจัยของ Caglar Uyulan และคณะ [33] ที่ได้นำโมเดลการเรียนรู้เชิงลึกมาใช้ในการวินิจฉัยและจำแนกโรคซึมเศร้า (MDD) ใช้เทคนิคการแปลงสัญญาณ EEG จากอิเล็กโทรดทั้งหมด 19 ตำแหน่ง ที่อยู่ในรูปแบบของสัญญาณทางเวลาให้เป็นรูปภาพซึ่งเป็นตัวแทนของการกระจายของแอมพลิจูดในแต่ละช่วงเวลาของอิเล็กโทรดทุกตำแหน่งพร้อมกันหรือ Topography Maps ซึ่งจะแบ่ง topography maps ออกตามช่วงความถี่ของสัญญาณ EEG ทั้งหมด 4 ช่วง และจะถูกใช้เป็นอินพุตสำหรับการสร้างโมเดลจำแนก โดยโครงสร้างโมเดลจำแนกที่ผู้วิจัยเลือกใช้จะอยู่บนพื้นฐานของโมเดลจำแนก CNN ได้แก่ ResNet-50, MobileNet, และ Inception-v3 โดยทั้งสามโมเดลจะใช้ optimizer ชนิด SGD ที่มีค่า learning rate เท่ากับ 0.0002 และค่าโมเมนตัมเท่ากับ 0.9 และค่าลดทอนเท่ากับ 0.0005 ซึ่งจากผลการทดลองพบว่าจากการทดสอบโมเดลด้วยข้อมูลชุดทดสอบ (Testing Set) ResNet-50 ให้ค่าความแม่นยำเฉลี่ยถึง 89.47% และรองลงมาคือ MobileNet ที่มีค่าความแม่นยำเฉลี่ยที่ 84.21% โดยค่าความแม่นยำสูงสุดที่เกิดขึ้นจะได้รับมาจากการสอนโมเดลจำแนกด้วย topography maps จากช่วงความถี่เดลต้า (Delta) ของสัญญาณ EEG ซึ่งข้อดีของการสอนโมเดลด้วย topography maps จากความถี่แต่ละช่วงที่แยกออกจากกันเป็นข้อมูลคนละชุด ซึ่งจะได้โมเดลทั้งหมด 4 โมเดลตามช่วงความถี่ของสัญญาณคือ สามารถบ่งชี้ได้ว่าความถี่ช่วงไหนที่มีผลต่อการสร้างโมเดลและทดสอบโมเดลมากที่สุดและช่วยลดเวลาในการสอนโมเดลได้ แต่ข้อเสียของการแยกช่วงความถี่คือหากความถี่ทั้งสองช่วงที่อยู่ติดกันมีความสัมพันธ์ต่อเนื่องกันภายใน อาจจะทำให้วิธีนี้สูญเสียข้อมูลที่เกิดขึ้นที่ขอบของช่วงความถี่ได้

บทที่ 3

การออกแบบโมเดลจำแนกโรคซึมเศร้า

3.1 ขั้นตอนการเตรียมประมวลผลข้อมูล (Data Preprocessing)




รูปที่ 3.1 กระบวนการเตรียมข้อมูล (Data preprocessing)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.1 ขั้นตอนการวิเคราะห์สัญญาณ (Signal Processing)

จากรูปที่ 3.1 จะแสดงกระบวนการเตรียมข้อมูล (Data preprocessing) ประกอบด้วยการนำสัญญาณ EEG มาประมวลผลทางสัญญาณ เพื่อกำจัดสัญญาณรบกวน (Noise) และสัญญาณรบกวนที่มาจากร่างกาย (Artifact) ที่เกิดขึ้นในการเก็บข้อมูลสัญญาณ EEG โดยการเตรียมสัญญาณคลื่นสมอง EEG จะดำเนินการบนโปรแกรม MATLAB (EEGLAB) เริ่มจากการย้ายจุดอ้างอิง (Re-reference) ของอิเล็กโทรดมาที่จุด M1 และ M2 ซึ่งอยู่ด้านหลังใบหูของมนุษย์ จากนั้นกรองความถี่แบบ Bandpass filter ที่ความถี่ 0.5 ถึง 45 Hz เพื่อกำจัดสัญญาณรบกวนที่มาจากสายส่งไฟฟ้า (ความถี่ 50 Hz) และสัญญาณรบกวนที่ความถี่สูง จากนั้นใช้อัลกอริทึม Independent Component Analysis ในการลดสัญญาณที่มาจากร่างกายเช่นการขยับของลูกตาทั้งแนวดิ่งและแนวขวางซึ่งอยู่ที่อิเล็กโทรด HEOG และ VEOG

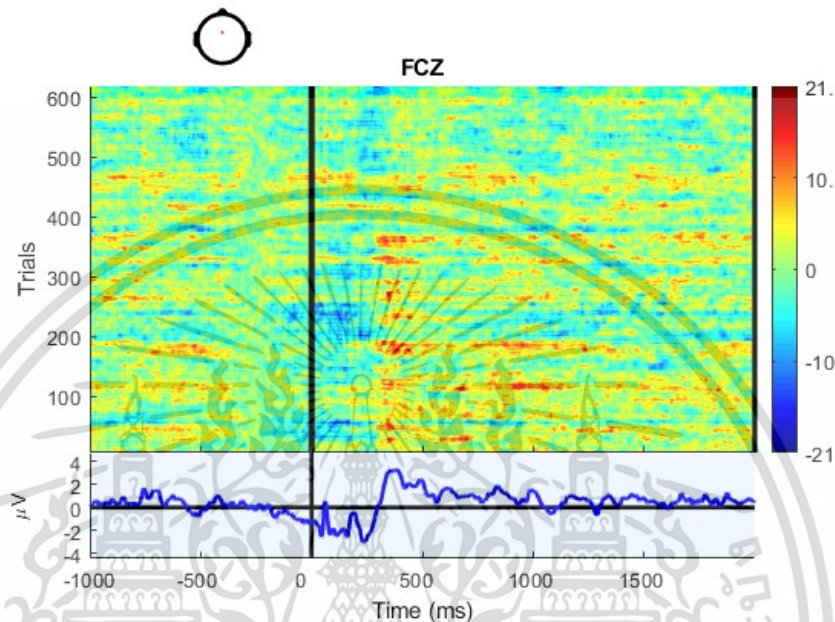
กระบวนการถัดมาจะทำการสกัดสัญญาณเฉพาะช่วงที่เกิดเหตุการณ์การกระตุ้น (Event) ในการทดลองจากสัญญาณ EEG ที่ถูกบันทึกมาแบบต่อเนื่องดังรูปที่ 3.2 แต่ถูกขึ้นด้วยขอบเขตของเหตุการณ์การกระตุ้น ให้เป็น window ของเหตุการณ์กระตุ้นโดยมีความยาวของ window ที่ -1000 ms ถึง 2000 ms และย้าย baseline ของสัญญาณมาอยู่ที่ -300 ถึง -200 ms ก่อนเกิดการกระตุ้น เพื่อให้สามารถเปรียบเทียบสัญญาณข้ามกันระหว่างตัวอย่าง



รูปที่ 3.2 สัญญาณ EEG 64 channels ที่ถูกบันทึกมาแบบต่อเนื่อง (Continuous Signal)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กระบวนการต่อไปคือการเฉลี่ยสัญญาณที่มาจากกระตุ้นทั้งหมดเพื่อหาค่า Event-related potentials ของแต่ละอิเล็กโทรดของสัญญาณ EEG โดยจะได้ค่าสัญญาณ EEG ในโดเมนเวลา (Time domain) ที่สามารถตีความแต่หาความสัมพันธ์กับเหตุการณ์การกระตุ้นได้ดังแสดงในรูปที่ 3.3 แสดงสัญญาณ ERPs ของอิเล็กโทรดที่จุด FCZ




รูปที่ 3.3 สัญญาณ Event-related potentials

3.1.2 ขั้นตอนการวิเคราะห์ในโดเมนเวลา-ความถี่ (Time-Frequency Analysis)

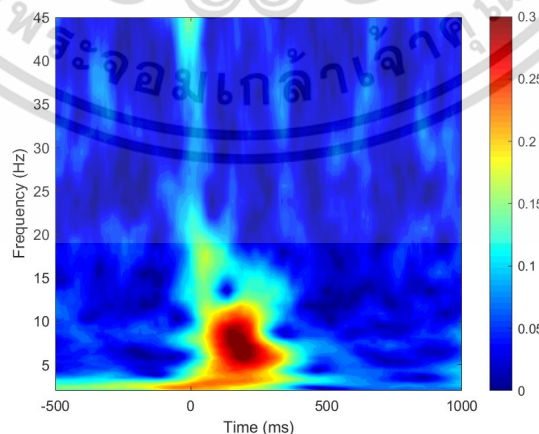
จากหัวข้อที่ 3.1.1 หลังจากการวิเคราะห์สัญญาณเพื่อลดสัญญาณรบกวนและสกัดสัญญาณเฉพาะที่เกิดเหตุการณ์กระตุ้นที่ได้ถูกเตรียมไว้ในการทดลองและแปลงสัญญาณให้อยู่ในรูปแบบของ Event-related potentials แล้วขั้นตอนถัดมาคือการแปลงสัญญาณ ERPs ที่อยู่ในโดเมนของเวลาให้กลายเป็นโดเมนเวลา-ความถี่ เพื่อให้สามารถวิเคราะห์สัญญาณในเวลาและความถี่พร้อมกันได้ จะใช้วิธี Morlet wavelet transformation ซึ่งมีสมการคือ $CMW = e^{-i2\pi t f} e^{-t^2/(2\sigma^2)}$ และกำหนดให้ความถี่ที่สนใจมีค่าตั้งแต่ 1 ถึง 45 Hz และค่า σ มีค่าตั้งแต่ 3 ถึง 10 cycle และช่วงเวลา t ที่สนใจตั้งแต่ -500 ms ก่อนการกระตุ้นถึง 1000 ms หลังการกระตุ้น โดยวิธีการแปลงจะทำได้ด้วยการ Convolution ทางความถี่ระหว่างสัญญาณ ERPs กับ CMW เริ่มต้นจากใส่การแปลง Fourier transform ให้กับสัญญาณทั้งสองและคูณกันในทางโดเมนความถี่ จากนั้นแปลงผลลัพธ์ของสัญญาณที่มาจาก การ Convolution กลับโดยใช้ Inverse Fourier transform และหาค่ากำลังงาน (power)

จากผลลัพธ์ทั้งหมดในทุกความถี่ที่กำหนดเพื่อนำมาแสดงในรูปแบบของกราฟเวลา-ความถี่ของ ERPs ดังที่แสดงตัวอย่างไว้ในรูปที่ 3.4



รูปที่ 3.4 กราฟเวลา-ความถี่ของสัญญาณ ERPs

ในส่วนของการแปลง Inter-trials phase clustering ให้อยู่ในโดเมนของเวลา-ความถี่จะมีกระบวนการเหมือนกับการแปลงของ ERPs เพียงแต่ ITPC คือค่าเฉลี่ยของเวกเตอร์เฟสใน ERPs ดังนั้นเมื่อได้ผลลัพธ์จากการ convolution ระหว่าง ERPs กับ CMW การคำนวณหาค่า ITPC ในโดเมนเวลา-ความถี่สามารถหาได้จากค่าสัมบูรณ์เฉลี่ยของเวกเตอร์เฟสในแต่ละช่วงเวลา-ความถี่ ตามที่แสดงไว้ในสมการ ITPC และผลลัพธ์ของกราฟเวลา-ความถี่ของ ITPC จะเป็นดังรูปที่ 3.5



รูปที่ 3.5 กราฟเวลา-ความถี่ของสัญญาณ ITPC


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.3 กระบวนการของโมเดลจำแนกแบบการเรียนรู้ของเครื่อง

ในการป้อนข้อมูลเพื่อสอนให้กับโมเดลการเรียนรู้ของเครื่องเพื่อให้จำแนกความแตกต่างระหว่างกลุ่มผู้ป่วยโรคซึมเศร้าและกลุ่มสุขภาพปกติ โมเดลการเรียนรู้ของเครื่อง เช่น k-NN และ SVM จะไม่เหมาะสมสำหรับอินพุตที่มีลักษณะข้อมูลที่เป็นรูปภาพ ซึ่งจากกระบวนการที่หัวข้อ 3.1.2 เป็นการแปลงสัญญาณ ERPs และ ITPC ให้เป็นรูปภาพที่อยู่ในโดเมนเวลา-ความถี่ (Time-frequency) ซึ่งในความเป็นจริง ข้อมูลรูปภาพที่เกิดขึ้นเหล่านั้นเกิดจากค่ากำลังงาน (Power) ของแต่ละช่วงเวลาและความถี่มาแสดงผลในรูปของค่าสีในรูป Spectrogram

3.1.3.1 ขั้นตอนการสกัดคุณลักษณะ (Feature Extraction)

การสกัดคุณลักษณะสำหรับโมเดลการเรียนรู้ของเครื่องจะใช้คุณลักษณะที่มีชื่อว่าค่าเฉลี่ยสัมบูรณ์ของกำลังงานหรือ Absolute mean power ซึ่งจัดว่าเป็นการสกัดคุณลักษณะในโดเมนความถี่ (Frequency domain) โดยค่าเฉลี่ยที่เกิดขึ้นจะเป็นค่าเฉลี่ยของแต่ละย่านความถี่ได้แก่ย่านความถี่เดลต้า (Delta) ที่ต้า (Theta) แอลฟา (Alpha) และบีต้า (Beta) จะมีการตอบสนองต่อเหตุการณ์การกระตุ้นที่แตกต่างกันออกไป และผู้วิจัยได้แยกค่าเฉลี่ยสัมบูรณ์ออกเป็นสองช่วงคือช่วงก่อนเกิดการกระตุ้น (Pre-stimuli) ที่เวลา -500 ms ถึง 0 ms และช่วงหลังเกิดกระตุ้น (Post-stimuli) ที่เวลา 0 ms ถึง 1000 ms เพื่อเพิ่มความละเอียด (resolution) ให้กับคุณลักษณะประเภทนี้ ซึ่งพบว่ามีการวิจัยที่ผ่านมาได้มีการนำเทคนิคการสกัดคุณลักษณะประเภทนี้มาใช้รวมกับการใช้โมเดลการเรียนรู้ของเครื่องเพื่อจำแนกสัญญาณ EEG ที่เกิดจากโรคทางจิตเภทหลายงานวิจัยด้วยกัน และผลลัพธ์ของการสกัดคุณลักษณะจะได้ทั้งหมด 8 คุณลักษณะซึ่งรวมทั้งก่อนและหลังการกระตุ้นในแต่ละจุดอิเล็กโทรดของ EEG ที่มีทั้งหมด 64 จุด จากรูปที่ 3.6 คือกราฟแสดงค่าสัมบูรณ์ของกำลังงาน (Absolute power) ซึ่งจากในกราฟจะพบว่าค่าสัมบูรณ์ของกำลังงานจะเกิดการเฉลี่ยค่ากำลังงานของความถี่ในแต่ละย่าน



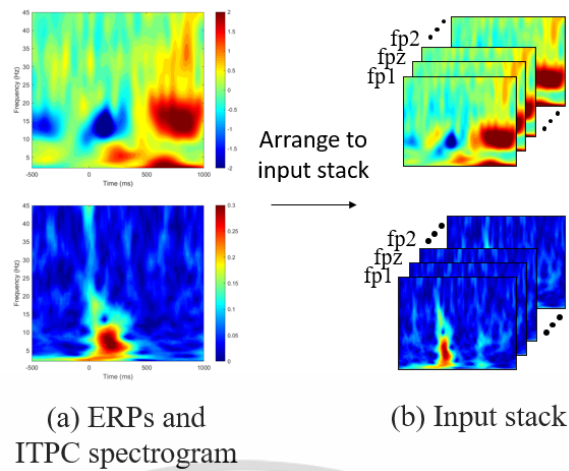
รูปที่ 3.6 กราฟค่าสัมบูรณ์ของกำลังงาน

3.1.3.2 ขั้นตอนการลดมิติของข้อมูล

หลังจากทำการสกัดคุณลักษณะจากสัญญาณ ERPs แล้วจะได้ข้อมูลจากสัญญาณทั้งหมด 8 คุณลักษณะต่ออิเล็กโทรดของ EEG 1 channel ซึ่งมีความซับซ้อนเป็นอย่างมาก จึงนำข้อมูลที่ได้นำเข้าสู่กระบวนการลดมิติของข้อมูลด้วยวิธีการหาค่าประกอบหลัก (Principle Component Analysis :PCA) เพื่อลดองค์ประกอบที่เกิดขึ้นจากค่าคุณลักษณะให้เหลือเพียง 2 ถึง 8 องค์ประกอบเพื่อเป็นตัวแทนให้กับค่าคุณลักษณะทั้งหมดที่สกัดมาได้โดยที่ไม่ได้ทำให้ข้อมูลเกิดการสูญเสีย

3.1.4 กระบวนการของโมเดลจำแนกแบบการเรียนรู้เชิงลึก


จากกระบวนการวิเคราะห์ทางเวลา-ความถี่และได้ผลลัพธ์ของ Event-related potentials และ Inter-trials phase clustering ในรูปแบบของภาพ Spectrogram ซึ่งก่อนที่จะนำข้อมูลที่ได้นำไปสอนให้กับโมเดลจำแนก CNN รูป spectrogram ที่ได้จำเป็นจะต้องลดขนาดรูปภาพให้มีขนาด 200x200 พิกเซลเพื่อลดเวลาและทรัพยากร และเนื่องจากข้อมูลของแต่ละตัวอย่างมีอิเล็กโทรดทั้งหมด 64 channel ซึ่งจะมีรูป spectrogram ทั้งหมด 64 รูปด้วยกันและเพื่อให้โมเดลจำแนก CNN ได้เรียนรู้ความสัมพันธ์ที่เกิดขึ้นทั้งหมดของแต่ละอิเล็กโทรดพร้อมกัน รูปภาพทั้งหมดจะถูกจัดเรียงใหม่ให้อยู่ในรูปของ array 3 มิติ ซึ่งผลลัพธ์ที่ได้ของรูปร่างอินพุตคือ 64x200x200 พิกเซล ผลลัพธ์ที่ได้จากการจัดเรียงข้อมูลใหม่จะเป็นไปตามรูปที่ 3.7



รูปที่ 3.7 การจัดเรียงอินพุตในรูปแบบของ array 3 มิติ

3.2 ขั้นตอนการเตรียมชุดข้อมูล

สำหรับขั้นตอนการเตรียมชุดข้อมูลเพื่อสร้างโมเดลจำแนกแบบการเรียนรู้ของเครื่องและแบบการเรียนรู้เชิงลึกเพื่อนำมาเปรียบเทียบประสิทธิภาพกันระหว่างอัลกอริทึม โดยหลังจากข้อมูลสัญญาณคลื่นสมอง EEG ได้ถูกวิเคราะห์ทางสัญญาณเพื่อแปลงให้อยู่ในรูปแบบของ ERPs เพื่อให้สามารถตีความข้อมูลจากเหตุการณ์กระตุ้นได้ ข้อมูลยังถูกเปลี่ยนอยู่ในโดเมนเวลา-ความถี่และถูกสกัดคุณลักษณะ โดยปกติแล้วในการสอนโมเดลจำแนกทั้งสองประเภทจะมีความแตกต่างกันที่จำนวนชุดข้อมูลที่ใช้ในการสอน โดยปกติแล้วโมเดลแบบการเรียนรู้ของเครื่องจะใช้ข้อมูลทั้งหมด 2 ชุดได้แก่ ชุดข้อมูลที่ใช้สำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Testing set) โดยข้อมูลชุดทดสอบจะเป็นข้อมูลที่ไม่เคยเห็นในกระบวนการการสอน แต่ในการเตรียมข้อมูลให้กับโมเดลการเรียนรู้ของเครื่องในงานวิจัยนี้จะแตกต่างจากการแบ่งข้อมูลแบบเดิมซึ่งคือการแบ่งข้อมูลเพียงสองชุด เพื่อให้สามารถเปรียบเทียบประสิทธิภาพกันระหว่างโมเดลการเรียนรู้ของเครื่องและโมเดลการเรียนรู้แบบเชิงลึกโดยผู้วิจัยจะแบ่งชุดข้อมูลทั้งหมด 3 ชุดได้ ข้อมูลที่ใช้สำหรับการสอน ข้อมูลที่ใช้สำหรับการประเมิน ในขั้นตอนการหาค่าพารามิเตอร์สำหรับแต่ละโมเดลหรือ Hyperparameter Tuning ของโมเดลการเรียนรู้ของเครื่อง และข้อมูลชุดทดสอบ และในส่วนของโมเดลการเรียนรู้เชิงลึกก็ได้มีการแบ่งข้อมูลแบบเดียวกันกับโมเดลการเรียนรู้ของเครื่อง



รูปที่ 3.8 การแบ่งชุดข้อมูลสำหรับการสร้างโมเดล

เนื่องจากกระบวนการสร้างโมเดลการเรียนรู้เชิงลึกจะมีการสอนข้อมูลแบบหลายรอบต่อข้อมูลหนึ่งชุด ดังนั้นเมื่อสอนข้อมูลให้กับโมเดลเสร็จ 1 รอบ ระบบจะดึงข้อมูลชุดประเมินมาเพื่อทดสอบประสิทธิภาพเบื้องต้นและทำการปรับค่าพารามิเตอร์ (Optimization) ให้มีความแม่นยำกับข้อมูลชุดประเมินให้มากที่สุดก่อนที่จะใช้ข้อมูลชุดทดสอบมาทดสอบการทำงาน ซึ่งจำนวนตัวอย่างของข้อมูลชุดสอนและชุดทดสอบของโมเดลทั้งสองประเภทจะมีจำนวนเท่ากันและเป็นตัวอย่างเดียวกันเพียงแต่ในโมเดลการเรียนรู้ของเครื่องจะไม่มีข้อมูลชุดประเมินมาใช้ในการปรับค่าพารามิเตอร์ ดังรูปตัวอย่างที่ 3.8

3.3 ขั้นตอนการสร้างโมเดลจำแนก (Classification Model)

ในขั้นตอนการสร้างโมเดลจำแนกผู้วิจัยจะนำภาษา Python ที่มี Library ในการพัฒนาโมเดลการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมาใช้ในการสร้างโมเดล โดย Library หลักที่นำมาใช้ได้แก่ TensorFlow, Keras และ Scikit-learn โดยการสร้างโมเดลเพื่อเปรียบเทียบจะมีทั้งหมด 4 โมเดล ได้แก่ k-Nearest-Neighbor, Support Vector Machine, Convolution Neural Network และ Concatenation Convolution Neural Network (Concat-CNN) ซึ่งเป็นโมเดลจำแนกแบบการเรียนรู้เชิงลึกที่ผู้วิจัยได้นำเสนอ ซึ่งในกระบวนการการสร้างโมเดลจะใช้กระบวนการ Hyperparameter Tuning เพื่อปรับค่าพารามิเตอร์ที่เกี่ยวข้องในแต่ละโมเดลเพื่อหาค่าที่เหมาะสมที่สุดที่ทำให้โมเดลเกิดความแม่นยำในการทำนายผลมากที่สุดของโมเดลแต่ละประเภท โดยในแต่ละรอบของการสอนโมเดล จบลง ผู้วิจัยจะบันทึกโมเดลทั้งหมดเพื่อนำมาใช้ในการกระบวนการทดสอบหาประสิทธิภาพ (Model Evaluation)

3.3.1 การสร้างโมเดลจำแนก k-Nearest Neighbor

การสร้างโมเดล k-Nearest Neighbor จะมีพารามิเตอร์ที่ผู้วิจัยสนใจมาใช้ในการปรับให้โมเดลมีประสิทธิภาพสูงขึ้นได้แก่ ค่าจำนวนเพื่อนบ้านที่ใกล้กัน หรือ ค่า n-neighbor เพื่อใช้ในการปรับความกว้างของจำนวนกลุ่มข้อมูลที่สนใจ โดยมีเกณฑ์ในการปรับตั้งแต่ค่า N เท่ากับ 1 ถึง 30 ค่าพารามิเตอร์ตัวที่สองคือวิธีการคำนวณหาระยะทางซึ่งกำหนดให้สองวิธีคือ Euclidean Distance และ Manhattan Distance ซึ่งกระบวนการประเมินโมเดลจะใช้ข้อมูลชุดประเมินมาทดสอบในแต่ละกระบวนการปรับพารามิเตอร์

3.3.2 การสร้างโมเดลจำแนก Support Vector Machine (SVM)

การสร้างโมเดล Support Vector Machine) ผู้วิจัยได้เลือกใช้ kernel ชนิด Radial basis function (RBF) ซึ่งเป็น kernel ประเภท nonlinear ที่ทำให้เส้นแบ่งระหว่างกลุ่มสามารถมีความโค้งตามข้อมูลที่เกิดขึ้นโดยจะต่างจากการใช้ระนาบเส้นตรงทำให้การจำแนกมีความยืดหยุ่นตามความซับซ้อนของข้อมูลมากขึ้น โดยพารามิเตอร์ที่ใช้ในการปรับ ได้แก่ พารามิเตอร์ C ซึ่งใช้ปรับความกว้างของเส้น margin ที่เกิดจากเส้นแบ่งระหว่างกลุ่ม และพารามิเตอร์ gamma ซึ่งใช้เพื่อปรับความโค้งของเส้นแบ่งกลุ่มที่เกิดจากฟังก์ชัน RBF โดยกำหนดให้พารามิเตอร์ C มีค่าเท่ากับ 1, 10, 100, 100 และพารามิเตอร์ gamma มีค่าเท่ากับ 1, 0.1, 0.01, 0.001, 0.0001 โดยจะประเมินโมเดลด้วยข้อมูลชุดประเมิน

3.3.3 การสร้างโมเดล Convolution Neural Network

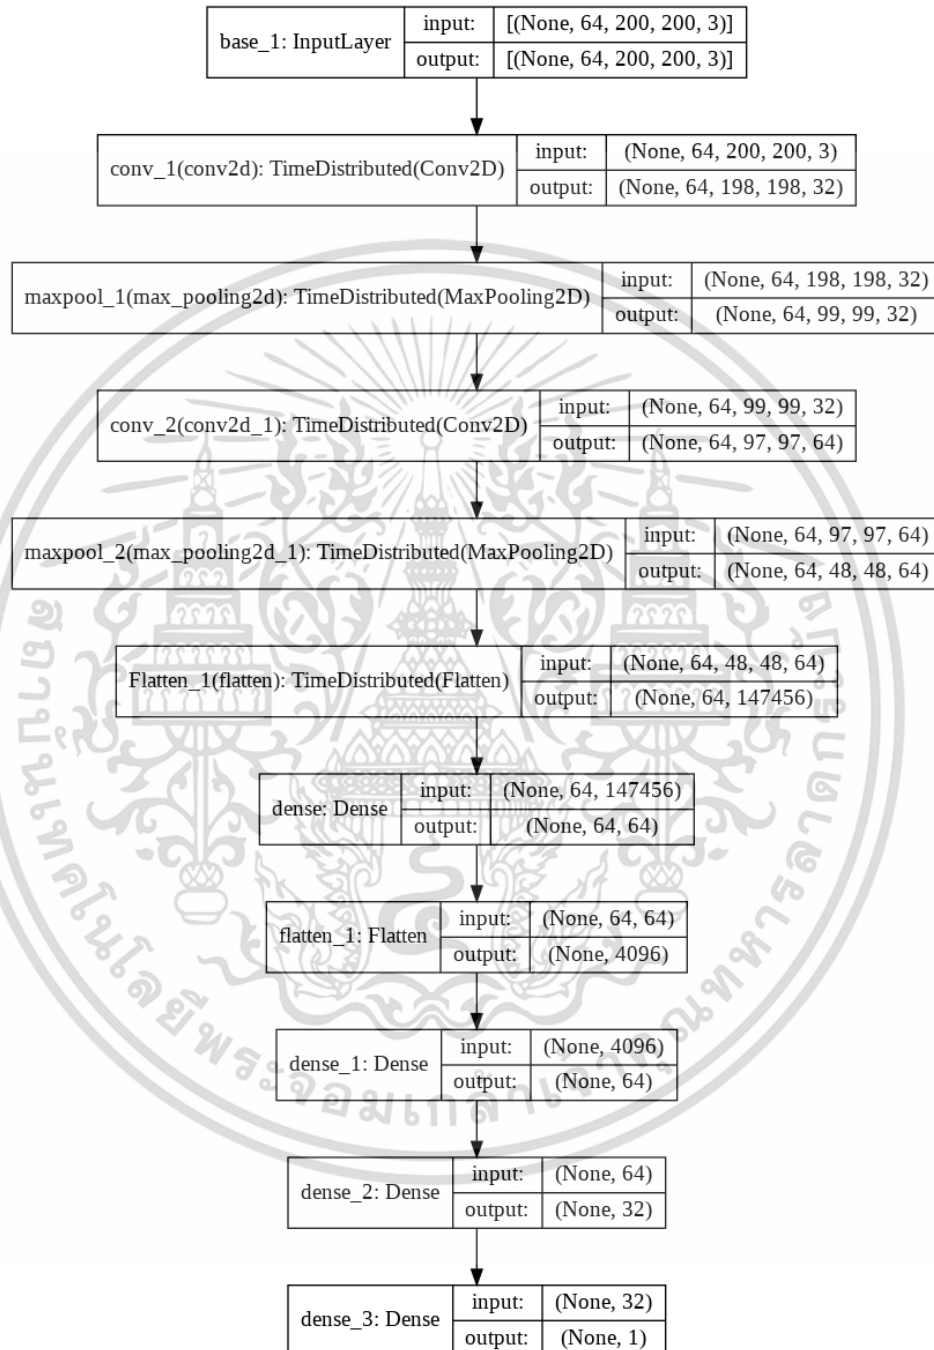
ขั้นตอนการสร้างโมเดลจำแนกแบบ CNN จะเริ่มจากการพิจารณารูปร่างของอินพุตที่เข้ามา ก่อนเป็นลำดับแรกโดยหลังจากกระบวนการวิเคราะห์สัญญาณทางเวลา-ความถี่แล้วได้ผลลัพธ์เป็นรูปของ spectrogram ของ ERPs และ ITPC ที่มีขนาดรูปภาพเท่ากับ 200x200x3 โดยมีมิติที่ 3 ของรูปภาพคือตัวแทนของค่าสี RGB โดยโครงสร้างของโมเดล CNN จะประกอบไปด้วยชั้น Convolution layers ที่ทำหน้าที่สกัดคุณลักษณะของรูปภาพ แต่เนื่องจากอินพุตที่เป็นรูปภาพของสัญญาณคลื่นสมองมีทั้งหมด 64 รูปภาพตามจำนวนของอิเล็กโทรดทำให้ต้องนำฟังก์ชันที่มีชื่อว่า Distributed เพื่อให้โมเดลสามารถรองรับหลายอินพุตได้ ชั้นถัดไปของโมเดลคือ Max pooling layers ใช้เพื่อลดมิติของข้อมูล (Down Sampling) และส่วนถัดมาคือส่วนของ Neural Network ซึ่งก่อนที่จะป้อนข้อมูลที่ เป็นคุณลักษณะของรูปภาพจากชั้นก่อนหน้านี้ที่มีมิติของข้อมูลหลายมิติ จะต้องผ่านกระบวนการเปลี่ยนมิติของข้อมูลให้เหมาะสมผ่านชั้น Flatten ซึ่งหน้าที่คือเปลี่ยนมิติของข้อมูลให้เหลือเพียงมิติเดียวที่เรียงต่อกันก่อนจะส่งต่อให้ชั้น hidden node ของ neural network ที่เรียกว่าชั้น Dense layers เพื่อเรียนรู้ความแตกต่างของแต่ละคุณลักษณะที่เกิดขึ้น และชั้นสุดท้ายจะเป็นส่วนของ

Dense layers ที่มี activation function (Sigmoid function) สำหรับหาเอาต์พุตสุดท้ายของโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยรูปที่ 3.9 จะแสดงโครงสร้างจำลองของโมเดลที่กล่าวถึง และการตั้งค่าพารามิเตอร์ของโมเดลจะเป็นไปตามตารางที่ 3.1



รูปที่ 3.9 โครงสร้างจำลองของโมเดล CNN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 ค่าพารามิเตอร์ของโมเดล CNN

ชั้นของโมเดล	ประเภทชั้น	รูปร่างของเอาต์พุต
Base_1	Input layer	(sample, 64, 200, 200, 3)
Conv_1	Convolution layer *	(sample, 64, 198, 198, 32)
Maxpool_1	Max pooling *	(sample, 64, 99, 99, 32)
Conv_2	Convolution layer *	(sample, 64, 97, 97, 64)
Maxpool_2	Max pooling *	(sample, 64, 48, 48, 64)
Flatten_1	Flatten *	(sample, 64, 147456)
Dense feature	Dense	(sample, 64, 64)
Flatten	Flatten	(sample, 4096)
Dense_1	Dense	(sample, 64)
Dense_2	Dense	(sample, 32)
Dense_3	Output layer	(sample, 1)

หมายเหตุ : * หมายถึง ชั้นของโมเดลที่มีฟังก์ชัน Distributed

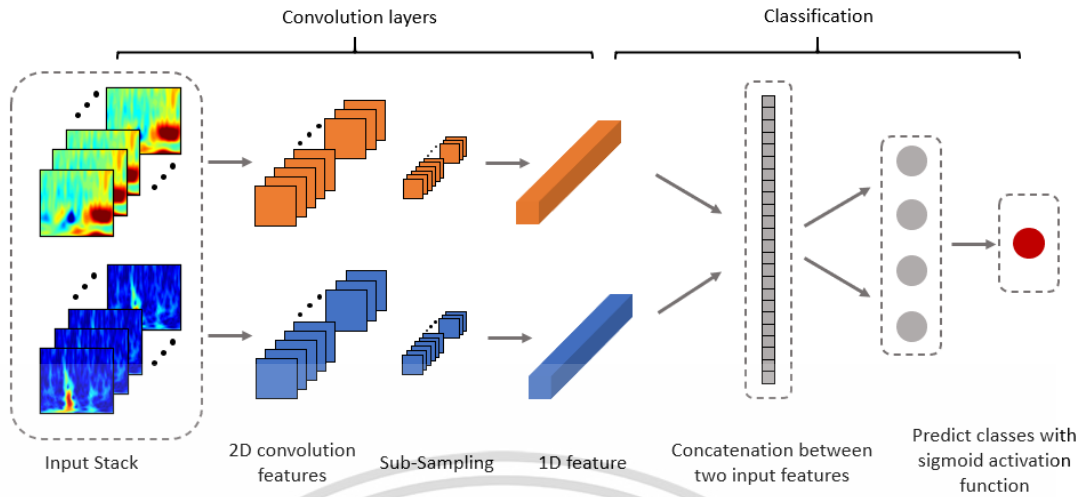
โดยกระบวนการปรับพารามิเตอร์ที่สำคัญ (Hyperparameter Tuning) ของโมเดล CNN ผู้วิจัยจะให้ความสนใจกับจำนวนของ Hidden node แต่ละตำแหน่งของโมเดลเนื่องจาก Hidden node เปรียบเสมือนหน่วยความจำของโมเดลในการเรียนรู้คุณลักษณะ โดยจากตารางที่ 3.1 ผู้วิจัยจะให้ชั้น Dense feature เป็นพารามิเตอร์หนึ่งในการปรับค่าให้เหมาะสมเนื่องจากเป็นชั้นที่รับค่ามาจากส่วนสกัดคุณลักษณะของโมเดลชั้นแรก ซึ่งจะให้มีการปรับจำนวน hidden node เท่ากับ 32, 64 และ 128 เพื่อหาค่าที่เหมาะสม และอีกพารามิเตอร์หนึ่งคือ Optimizer ของโมเดลซึ่งได้แก่ SGD, RMSprop, Adam และ Adadelta โดยพารามิเตอร์ในแต่ละ optimizer จะให้เป็นค่าเริ่มต้นของฟังก์ชันจาก Library Keras ก่อน ซึ่งจะมีค่าตามที่ตารางที่ 3.2 แสดงไว้

ตารางที่ 3.2 ค่าพารามิเตอร์ของ Optimizer แต่ละชนิด

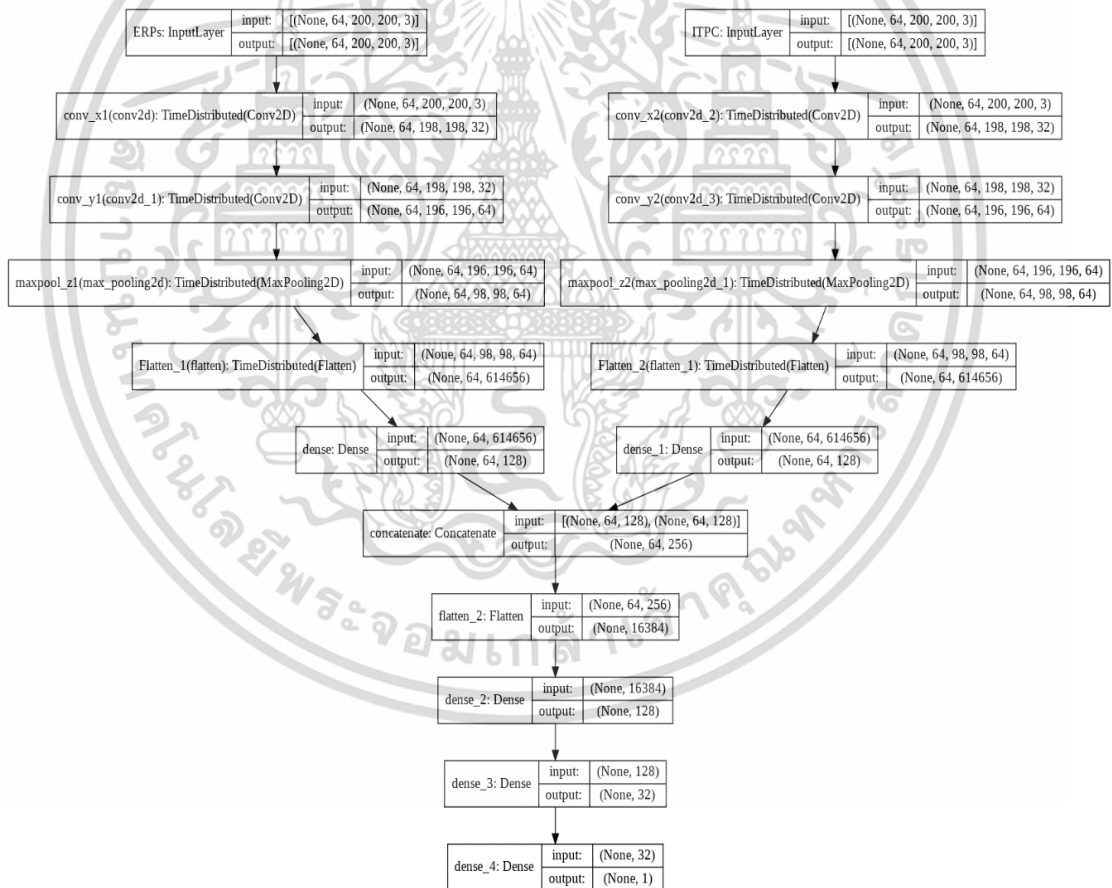
Optimizer	Learning rate	Momentum	Epsilon	rho	beta_1	beta_2
SGD	0.01	0.0	-	-	-	-
RMSprop	0.001	0.0	1e-07	0.9	-	-
Adam	0.001	-	1e-07	-	0.9	0.999
Adadelta	0.001	-	1e-07	0.95	-	-

3.3.4 การสร้างโมเดล Concatenation Convolution Neural Network

โมเดล Concat-CNN คือโมเดลที่มีอินพุตตั้งแต่สองอินพุตขึ้นไปและมีการนำค่าเอาต์พุตจากชั้น Convolution layer ซึ่งเป็นชั้นสกัดคุณลักษณะของโมเดล CNN ของแต่ละอินพุตมาควบรวมหรือต่อกันที่ชั้น Concatenate ของโมเดล เพื่อให้ชั้นจำแนก (Classification Layer) หรือส่วน Neural Network ในโมเดล CNN สามารถเรียนรู้ความสัมพันธ์ระหว่างอินพุตทั้งสองในเวลาพร้อมกัน โดยโมเดล Concat-CNN เป็นโมเดลการเรียนรู้แบบเชิงลึกที่ผู้วิจัยได้นำเสนอไว้ในงานวิจัยที่ได้รับการตีพิมพ์ [34] โดยโครงสร้างและกระบวนการทำงานของโมเดลจะเป็นไปตามที่แสดงในรูปที่ 3.10 และรูปที่ 3.11 ซึ่งอินพุตที่ป้อนให้กับโมเดล Concat-CNN ได้แก่ Event-related potentials และ Inter-trial phase clustering โดยค่าพารามิเตอร์ของในแต่ละชั้นของโมเดล Concat-CNN จะแสดงไว้ในตารางที่ 3.2 และในกระบวนการปรับค่าพารามิเตอร์ (Hyperparameter Tuning) ผู้วิจัยได้กำหนดให้ชั้น Dense_1 เป็นพารามิเตอร์ที่ต้องการปรับค่า โดยมีค่าจำนวน hidden node ตั้งแต่ 32, 64 และ 128 และ Optimizer ของโมเดลจะปรับเช่นเดียวกันกับหัวข้อ 3.3.3 ที่ได้กำหนดไว้



รูปที่ 3.10 โครงสร้างจำลองการทำงานของโมเดล Concat-CNN



รูปที่ 3.11 โครงสร้างจำลองของโมเดล Concat-CNN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.3 ค่าพารามิเตอร์ของโมเดล Concat-CNN

ชั้นของโมเดล	ประเภทชั้น	รูปร่างของเอาต์พุต (ERPs/ITPC)
Base_1	Input layer**	(sample, 64, 200, 200, 3) **
Conv_1	Convolution layer **	(sample, 64, 198, 198, 32) **
Conv_2	Convolution layer **	(sample, 64, 196, 196, 64) **
Maxpool_2	Max pooling **	(sample, 64, 98, 98, 64) **
Flatten_1	Flatten **	(sample, 64, 614656) **
Dense feature	Dense**	(sample, 64, 64)
Concatenate	Concatenate	(sample, 64, 128)
Flatten	Flatten	(sample, 8192)
Dense_1	Dense	(sample, 128)
Dense_2	Dense	(sample, 32)
Dense_3	Output layer	(sample, 1)

หมายเหตุ : ** หมายถึง ชั้นของโมเดลของทั้งสองอินพุตมีฟังก์ชัน Distributed

3.4 ขั้นตอนการประเมินและทดสอบประสิทธิภาพของโมเดลจำแนก

ขั้นตอนสำหรับการประเมินโมเดลจำแนกแบบการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกจะถูกผนวกอยู่ในกระบวนการสอนสร้างโมเดลโดยในทุกๆครั้งที่การสอนหนึ่งรอบ จบลง โมเดลจะนำข้อมูลชุดประเมินมาประเมินประสิทธิภาพเบื้องต้นเพื่อปรับพารามิเตอร์ให้เหมาะสมสำหรับการสอนรอบถัดไป โดยการประเมินประสิทธิภาพเบื้องต้นของโมเดลจะใช้ค่าความแม่นยำในการทำนายผล (Accuracy: Acc) และค่าความผิดพลาดจากค่าที่ทำนายได้กับค่าจริง (Loss) โดยใช้ข้อมูลชุดประเมินในกระบวนการนี้เพื่อเปรียบเทียบความแตกต่างกันในแต่ละรอบการสอน

กระบวนการทดสอบประสิทธิภาพของโมเดลจะเริ่มหลังจากที่การสอนโมเดลนั้นจบลงซึ่งจะนำข้อมูลชุดทดสอบ มาเพื่อทดสอบความสามารถของแต่ละโมเดลกับข้อมูลชุดที่ไม่เคยเห็นมาก่อน ซึ่งเครื่องมือที่ใช้ในการทดสอบประสิทธิภาพสำหรับโมเดลจำแนกจะประกอบด้วย ตารางผลลัพธ์การทำนาย (Confusion Matrix) ค่าความแม่นยำ (Accuracy) ค่าความแม่นยำจำเพาะกลุ่ม (Precision) ค่าความไว (Recall or Sensitivity) ค่าความจำเพาะ (Specificity) และค่า F1-score

3.4.1 ตารางผลลัพธ์การทำนาย (Confusion Matrix)

ตารางผลลัพธ์ของการทำนาย (Confusion Matrix) คือตารางที่เกิดจากการทำนายผลทั้งหมดของโมเดลจำแนก โดยในตารางจะบ่งบอกถึงความสัมพันธ์ทั้งหมดระหว่างค่าที่โมเดลทำนายได้ (Predicted Value) และค่าที่แท้จริง (Actual Value/Ground Truth) จากข้อมูลชุดทดสอบ โดยจากรูปที่ 3.11 จะสังเกตเห็นได้ว่าแกนนอนจะเป็นค่าที่แท้จริงและแกนตั้งเป็นค่าที่ทำนายได้ ซึ่งค่าที่อยู่ในตารางเป็นค่าความถี่ของการทำนายในกลุ่มที่สนใจ ซึ่งมีทั้งหมดสองกลุ่มคือ กลุ่ม Positive (1) และกลุ่ม Negative (0) โดยข้อมูลในตารางมีความหมายดังนี้

True Positive (TP) หมายถึง ค่าที่โมเดลทำนายได้กลุ่ม 1 และค่าจริงคือกลุ่ม 1

True Negative (TN) หมายถึง ค่าที่โมเดลทำนายได้กลุ่ม 0 และค่าจริงคือกลุ่ม 0

False Positive (FP) หมายถึง ค่าที่โมเดลทำนายได้กลุ่ม 1 และค่าจริงคือกลุ่ม 0

False Negative (FN) หมายถึง ค่าที่โมเดลทำนายได้กลุ่ม 0 และค่าจริงคือกลุ่ม 1

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

รูปที่ 3.12 ตารางผลลัพธ์ของการทำนาย (Confusion Matrix)

3.4.2 ค่าความแม่นยำ (Accuracy)

ค่าความแม่นยำ (Accuracy) คือค่าจากการทำนายผลลัพธ์จากโมเดลจำแนกโดยเป็นอัตราส่วนระหว่างจำนวนที่ทำนายถูกต้องและจำนวนทั้งหมดที่เข้าสู่การทำนายผล โดยมีสมการดังนี้

$$Accuracy = \left(\frac{TP+TN}{TP+FP+FN+TN} \right) \times 100\% \quad (3.1)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4.3 ค่าความแม่นยำจำเพาะกลุ่ม (Precision)

ค่าความแม่นยำจำเพาะกลุ่ม (Precision) เป็นการวัดค่าในส่วนที่โมเดลจำแนกทำนายถูกต้องในกลุ่มที่สนใจจากส่วนที่โมเดลทำนายถูกต้องทั้งหมด โดยมีสมการดังนี้

$$Precision = \left(\frac{TP}{TP+FP} \right) \times 100\% \quad (3.2)$$

3.4.4 ค่าความไว (Recall / Sensitivity)

ค่าความไว (Recall / Sensitivity) คือการวัดค่าเฉพาะกลุ่มที่สนใจว่ามีการทำนายที่ถูกต้องจากเหตุการณ์การทำนายในกลุ่มนี้ทั้งหมด โดยเป็นการวัดเพื่อป้องกันผลลบปลอม (False Negative / Type 2 error) เช่นการพบว่ามีโรคแต่ที่แท้จริงคือมีโรค ดังนั้นยิ่งค่าความไวมีค่ามากโอกาสที่ เกิดผลลบปลอมก็จะน้อยลง โดยมีสมการดังนี้

$$Recall = \left(\frac{TP}{TP+FN} \right) \times 100\% \quad (3.3)$$

3.4.5 ค่าความจำเพาะ (Specificity)

ค่าความจำเพาะ (Specificity) คือการวัดค่าเพื่อป้องกันผลบวกปลอม (False Positive / Type 1 error) เช่นการพบว่ามีโรคแต่ที่แท้จริงคือไม่มีโรค ดังนั้นยิ่งค่าความจำเพาะสูงโอกาสที่จะเกิดผลบวกปลอมก็จะน้อยลง โดยมีสมการดังนี้

$$Specificity = \left(\frac{TN}{TN+FP} \right) \times 100\% \quad (3.4)$$

3.4.6 ค่า F1-Score

ค่า F1-Score คือค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall โดยสามารถใช้ f1-score เป็นเมตริกเพื่อวัดประสิทธิภาพระหว่างโมเดล โดยมีสมการดังนี้

$$F1\ Score = \left(\frac{precision*recall}{precision+recall} \right) \times 2 \quad (3.5)$$

บทที่ 4

การทดลอง ผลการทดลอง และวิเคราะห์ผลการทดลอง

กระบวนการทดลองสร้างโมเดลสำหรับจำแนกผู้ป่วยโรคซึมเศร้าจากสัญญาณคลื่นสมอง EEG โดยใช้โมเดลการเรียนรู้ของเครื่องและโมเดลการเรียนรู้เชิงลึกจะแบ่งออกเป็น 3 การทดลอง โดยผู้วิจัยได้มุ่งเน้นเสนอในแง่มุมมองของโมเดลจำแนกแบบการเรียนรู้เชิงลึก ได้แก่ การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs ร่วมกับ ITPC และการทดลองเพิ่มประสิทธิภาพโมเดลด้วยวิธีปรับค่าพารามิเตอร์แบบละเอียด (Fine Tuning Parameter)

โดยข้อมูลสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าได้รับการสนับสนุนจากสถาบันวิจัย Cognitive Rhythms and Computational Lab ที่ University of New Mexico Department of Psychology โดยข้อมูลสัญญาณ EEG จะมีทั้งหมด 121 ตัวอย่างและทำการสุ่มเลือกจากประวัติของผู้ป่วย โดยแบ่งออกเป็นสองกลุ่มได้แก่ กลุ่มควบคุม 51 ตัวอย่างและกลุ่มผู้ป่วยโรคซึมเศร้า 47 ตัวอย่าง ซึ่งกลุ่มควบคุมจะมีค่าดัชนี BDI ต่ำกว่า 7 และกลุ่มผู้ป่วยโรคซึมเศร้าจะมีค่าดัชนี BDI สูงกว่า 13 ซึ่งในกลุ่มผู้ป่วยจะประกอบด้วยตัวอย่างที่มีประวัติประสพภาวะโรคซึมเศร้าและกลุ่มที่อยู่ในภาวะโรคซึมเศร้าในปัจจุบัน โดยได้ผ่านการคัดกรองจากระบบ DSM-IV และสามารถร่วมเป็นกลุ่มผู้ป่วยโรคซึมเศร้ากลุ่มเดียวกันได้ ซึ่งผู้วิจัยจะแบ่งข้อมูลออกเป็นสามชุดได้แก่ ข้อมูลชุดสอน 70 % ข้อมูลชุดประเมิน 20 % และข้อมูลชุดทดสอบ 10 % ตามลำดับ

4.1 การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs

จุดประสงค์การทดลอง เพื่อสร้างโมเดลจำแนกแบบการเรียนรู้ของเครื่องและโมเดลจำแนกแบบการเรียนรู้เชิงลึกเพื่อเปรียบเทียบประสิทธิภาพหรือความแม่นยำของโมเดลแต่ละประเภทในการจำแนกผู้ป่วยโรคซึมเศร้าโดยใช้อินพุตในการสอนโมเดลคือสัญญาณ ERPs ทั้งหมด 64 อิเล็กโทรด

เงื่อนไขการทดลอง

1. โมเดลการเรียนรู้ของเครื่องจะใช้วิธีการแบ่งข้อมูลแบบเดียวกับโมเดลการเรียนรู้เชิงลึก เพื่อให้สามารถเปรียบเทียบประสิทธิภาพอย่างสมอภาค และใช้ข้อมูลชุดประเมินในการทดสอบโมเดลเบื้องต้นในการปรับค่าพารามิเตอร์ของแต่ละโมเดล

2. พารามิเตอร์ของโมเดลจำแนกแต่ละประเภทจะถูกตั้งค่าไว้ตามที่กล่าวในบทที่ 3.3
3. ผลการทดสอบประสิทธิภาพของโมเดลจำแนกจะแสดงในรูปแบบของค่าความแม่นยำ ค่าความไว และค่า F1-Score โดยโมเดลการเรียนรู้แบบเชิงลึกจะแสดงกราฟของค่าความแม่นยำ (Accuracy) และกราฟของค่าการสูญเสีย (Loss) จากขั้นตอนการสอนโมเดล เพื่อสังเกตและหลีกเลี่ยงการใช้โมเดลที่เกิดเหตุการณ์ Overfitting จากการสอนโมเดล

4.1.1 ผลการทดลองการสร้างโมเดลจำแนกแบบการเรียนรู้ของเครื่อง

จากขั้นตอนการลดมิติของข้อมูลที่ผ่านการสกัดคุณลักษณะ โดยผู้วิจัยได้กำหนดให้ค่าองค์ประกอบ (Component) ของ PCA มีค่าตั้งแต่ 2 ถึง 8 องค์ประกอบโดยจะได้ผลลัพธ์ขององค์ประกอบดังตารางที่ 4.1 ซึ่งการใช้องค์ประกอบที่มีจำนวนเท่ากับ 8 สามารถอธิบายแทนข้อมูลผ่านกระบวนการสกัดคุณลักษณะได้ 86.96% และทำการนำข้อมูลที่ได้รับการแปลงมาเพื่อสอนให้กับโมเดลจำแนกแบบ k-NN และ SVM

ตารางที่ 4.1 อัตราส่วนการกระจายของแต่ละองค์ประกอบ (Component) จาก PCA

	Com_1	Com_2	Com_3	Com_4	Com_5	Com_6	Com_7	Com_8
Trial_1	0.320945	0.122591	0	0	0	0	0	0
Trial_2	0.320945	0.122592	0.100417	0	0	0	0	0
Trial_3	0.320945	0.122591	0.100417	0.087804	0	0	0	0
Trial_4	0.320944	0.122591	0.100417	0.087804	0.07448	0	0	0
Trial_5	0.320945	0.122591	0.100417	0.087804	0.074479	0.063241	0	0
Trial_6	0.320944	0.122591	0.100417	0.087804	0.074479	0.063241	0.054661	0
Trial_7	0.320945	0.122591	0.100417	0.087804	0.074479	0.063241	0.054661	0.050734

ตารางที่ 4.2 ผลการสอนโมเดลจำแนก k-NN โดยใช้วิธี Hyperparameter Tuning

Model	Neighbors	Distance type	Valid score 1	Valid score 2	Valid score 3	Mean score	SD score
KNN_1	7	Manhattan	0.5652	0.5652	0.8182	0.6495	0.1192
KNN_2	5	Manhattan	0.6087	0.5652	0.7273	0.6337	0.0685
KNN_3	5	Euclidean	0.5652	0.6087	0.7273	0.6337	0.0685
KNN_4	10	Manhattan	0.5652	0.6087	0.7273	0.6337	0.0685
KNN_5	6	Manhattan	0.6087	0.5217	0.7273	0.6192	0.0842
KNN_6	9	Manhattan	0.5217	0.6087	0.7273	0.6192	0.0842
KNN_7	7	Euclidean	0.5652	0.6522	0.6364	0.6179	0.0378
KNN_8	3	Euclidean	0.5217	0.7391	0.5909	0.6173	0.0907
KNN_9	4	Euclidean	0.5217	0.6087	0.6818	0.6041	0.0654
KNN_10	6	Euclidean	0.5652	0.5652	0.6818	0.6041	0.0550
KNN_11	3	Manhattan	0.5652	0.5217	0.6818	0.5896	0.0676
KNN_12	4	Manhattan	0.5652	0.5217	0.6818	0.5896	0.0676
KNN_13	9	Euclidean	0.4783	0.5217	0.7273	0.5758	0.1086
KNN_14	8	Manhattan	0.4783	0.5652	0.6818	0.5751	0.0834
KNN_15	2	Manhattan	0.5217	0.4783	0.6818	0.5606	0.0875
KNN_16	28	Manhattan	0.4783	0.5217	0.6818	0.5606	0.0875
KNN_17	8	Euclidean	0.5217	0.5217	0.6364	0.5599	0.0540
KNN_18	15	Manhattan	0.4783	0.5652	0.6364	0.5599	0.0647
KNN_19	2	Euclidean	0.5217	0.6087	0.5455	0.5586	0.0367
KNN_20	26	Manhattan	0.4783	0.6522	0.5455	0.5586	0.0716

จากตารางที่ 4.2 ผลการสอนโมเดลจำแนก k-NN โดยใช้วิธี Hyperparameter Tuning ซึ่งใช้ชุดข้อมูลการสอน และชุดข้อมูลประเมิน (Validation Set) โดยร่วมกับวิธี Cross validation โดยที่มี K fold เท่ากับ 3 ซึ่งผู้วิจัยจะพิจารณาประสิทธิภาพโมเดลจากค่าเฉลี่ยความแม่นยำ (Mean score) และค่าส่วนเบี่ยงเบนมาตรฐาน (SD score) โดยจากผลการทดลองพบว่าโมเดล KNN_1 มีค่าเฉลี่ยความแม่นยำเท่ากับ 64.95% แต่มีค่าส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.1192 ซึ่งโมเดล KNN_2, KNN_3 และ KNN_4 มีค่าเฉลี่ยความแม่นยำที่ 63.37% แต่มีค่าส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.0685 ซึ่งต่ำกว่าโมเดล KNN_1 ผู้วิจัยจึงนำโมเดลจำแนกทั้ง 4 โมเดลมาเข้าร่วมกับกระบวนการทดสอบประสิทธิภาพกับข้อมูลชุดทดสอบ (Test Set)


ตารางที่ 4.3 ผลการสอนโมเดลจำแนก SVM โดยใช้วิธี Hyperparameter Tuning

Model	Param C	Param Gamma	Valid score 1	Valid score 2	Valid score 3	Mean score	SD score
SVM_1	0.1	1	0.6957	0.6522	0.6957	0.6812	0.0205
SVM_2	0.1	0.1	0.5652	0.4783	0.6818	0.5751	0.0834
SVM_3	0.1	0.01	0.4783	0.5652	0.6364	0.5599	0.0647
SVM_4	0.1	0.001	0.5652	0.5217	0.5909	0.5593	0.0285
SVM_5	0.1	0.0001	0.5652	0.6522	0.4545	0.5573	0.0809
SVM_6	1	1	0.4783	0.5217	0.6364	0.5455	0.0667
SVM_7	1	0.1	0.4783	0.5652	0.5909	0.5448	0.0482
SVM_8	1	0.01	0.5217	0.5652	0.5455	0.5441	0.0178
SVM_9	1	0.001	0.4783	0.6087	0.5455	0.5441	0.0533
SVM_10	1	0.0001	0.4348	0.6522	0.5455	0.5441	0.0888
SVM_11	10	1	0.5217	0.5652	0.5455	0.5441	0.0178
SVM_12	10	0.1	0.5217	0.6087	0.5	0.5435	0.047
SVM_13	10	0.01	0.4783	0.4783	0.6364	0.531	0.0745
SVM_14	10	0.001	0.4783	0.5217	0.5909	0.5303	0.0464
SVM_15	10	0.0001	0.5217	0.5217	0.5455	0.5296	0.0112
SVM_16	100	1	0.5217	0.5652	0.5	0.529	0.0271
SVM_17	100	0.1	0.5652	0.5217	0.5	0.529	0.0271
SVM_18	100	0.01	0.5652	0.5217	0.5	0.529	0.0271
SVM_19	100	0.001	0.4783	0.6087	0.5	0.529	0.0571
SVM_20	100	0.0001	0.4348	0.4783	0.6364	0.5165	0.0866

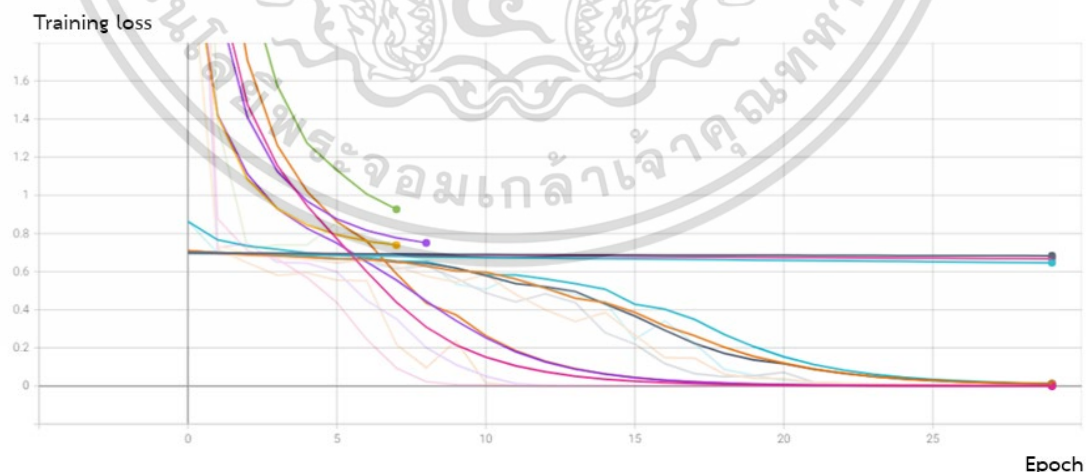
จากตารางที่ 4.3 ผลการสอนโมเดลจำแนก SVM โดยใช้วิธี Hyperparameter Tuning ซึ่งใช้ kernel แบบ radial basis function จะพบว่าโมเดลจำแนก SVM_1 ที่มีค่าพารามิเตอร์ C เท่ากับ 10 และ gamma เท่ากับ 0.0001 ให้ค่าเฉลี่ยของความแม่นยำ (Mean score) เท่ากับ 68.12% และค่าส่วนเบี่ยงเบนมาตรฐาน (SD score) เท่ากับ 0.0205 ซึ่งต่ำที่สุดจากโมเดลจำแนก SVM ทั้งหมดที่ผู้วิจัยได้สร้างขึ้นมา ดังนั้นโมเดลจำแนก SVM_1 จะเข้าสู่กระบวนการทดสอบประสิทธิภาพกับข้อมูลชุดทดสอบ (Test Set)

4.1.2 ผลการทดลองการสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึก

ผลการสอนโมเดลจำแนกแบบการเรียนรู้เชิงลึก CNN และมีอินพุตคือสัญญาณ ERPs โดยแนวโน้มของค่าความแม่นยำจากการสอน (Training accuracy) และค่าการสูญเสีย (Training loss) จะแสดงดังรูปที่ 4.1 และ 4.2 ตามลำดับ ส่วนแนวโน้มค่าความแม่นยำจากการใช้ข้อมูลชุดประเมิน (Validation accuracy) และค่าการสูญเสีย (Validation loss) จะแสดงในรูปที่ 4.3 และ 4.3 ตามลำดับ ค่าความแม่นยำและค่าการสูญเสียจากการประเมินโดยใช้ข้อมูลชุดประเมินจะถูกแสดงในตารางที่ 4.4 ซึ่งผู้วิจัยได้ทำการเลือกโมเดลจากรอบการสอน ที่มีแนวโน้มที่ดีมากที่สุดจากแนวโน้มของแต่ละโมเดลมาประเมินหาโมเดลที่มีประสิทธิภาพเบื้องต้น ก่อนจะทดสอบด้วยข้อมูลชุดทดสอบในภายหลัง




รูปที่ 4.1 กราฟแนวโน้มค่าความแม่นยำจากการสอนโมเดล



รูปที่ 4.2 กราฟแนวโน้มค่าความสูญเสียจากการสอนโมเดล


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Validation accuracy



รูปที่ 4.3 กราฟแนวโน้มค่าความแม่นยำจากการประเมินโมเดล

Validation loss



รูปที่ 4.4 กราฟแนวโน้มค่าความสูญเสียจากการประเมินโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 ผลการประเมินโมเดล CNN ด้วยข้อมูลชุดประเมินจากวิธี Hyperparameter Tuning

Model	Optimizer	Dense unit	Epoch	Valid accuracy	Valid loss
CNN_1	SGD	128	7	0.76471	0.6563
CNN_2	Adam	32	4	0.70588	0.6452
CNN_3	Adadelta	128	13	0.70588	0.6732
CNN_4	Adam	128	14	0.70588	0.8987
CNN_5	SGD	64	10	0.70588	0.6709
CNN_6	RMSprop	128	13	0.64706	0.7032
CNN_7	SGD	32	21	0.64706	0.858
CNN_8	RMSprop	64	7	0.64706	0.6657
CNN_9	Adadelta	32	16	0.58824	0.6955
CNN_10	Adadelta	64	14	0.58824	0.6585
CNN_11	Adam	64	4	0.52941	0.6925
CNN_12	RMSprop	32	2	0.47059	0.6932

จากตารางที่ 4.4 คือผลการประเมินประสิทธิภาพของโมเดลจำแนกด้วยชุดข้อมูลประเมิน โดยจากผลการทดลองโมเดล CNN_1 ที่ใช้ optimizer ชนิด SGD และมีค่า Dense unit เท่ากับ 64 จะได้ค่าความแม่นยำจากการประเมินสูงที่สุดคือ 76.47% แต่ในโมเดล CNN_2, CNN_3, CNN_4 และ CNN_5 จะมีค่าความแม่นยำที่ 70.59% เท่ากัน ดังนั้นผู้วิจัยจึงนำโมเดลทั้ง 5 เข้าสู่กระบวนการทดสอบประสิทธิภาพด้วยข้อมูลชุดทดสอบทั้งหมด

4.1.3 ผลการเปรียบเทียบประสิทธิภาพของโมเดลจำแนก

จากหัวข้อที่ 4.1.1 และ 4.1.2 ที่ผู้วิจัยได้สร้างโมเดลจำแนกชนิดการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกซึ่งมีทั้งหมด 10 โมเดลที่ผ่านเกณฑ์การประเมินเบื้องต้นด้วยข้อมูลชุดประเมิน โดยในหัวข้อนี้ผู้วิจัยจะนำโมเดลจำแนกมาเปรียบเทียบประสิทธิภาพด้วยการทำนายผลจากข้อมูลชุดทดสอบ ซึ่งผลการทดสอบที่ได้จะแสดงดังตารางที่ 4.5

ตารางที่ 4.5 ผลการทดสอบโมเดลจำแนกทั้งหมดด้วยข้อมูลชุดทดสอบ

Model	class	precision	recall/sensitivity	f1-score	accuracy
KNN_1	control	0.83	0.62	0.71	0.6667
	depression	0.5	0.75	0.6	
KNN_2	control	0.83	0.62	0.71	0.6667
	depression	0.5	0.75	0.6	
KNN_3	control	0.75	0.75	0.75	0.6667
	depression	0.5	0.5	0.5	
KNN_4	control	0.8	0.5	0.62	0.5882
	depression	0.43	0.75	0.55	
SVM_1	control	1	0.62	0.77	0.75
	depression	0.57	1	0.73	
CNN_1	control	0.88	0.88	0.88	0.83
	depression	0.75	0.75	0.75	
CNN_2	control	0.86	0.75	0.8	0.75
	depression	0.6	0.75	0.67	
CNN_3	control	0.78	0.88	0.82	0.75
	depression	0.67	0.5	0.57	
CNN_4	control	0.83	0.62	0.71	0.6667
	depression	0.5	0.75	0.6	
CNN_5	control	0.8	1	0.89	0.83
	depression	1	0.5	0.67	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.5 ที่แสดงค่าที่บ่งบอกถึงประสิทธิภาพของโมเดลจำแนกที่ผู้วิจัยสนใจทั้งโมเดลการเรียนรู้ของเครื่องและโมเดลการเรียนรู้เชิงลึก โดยจากผลการทดลองพบว่าโมเดลการเรียนรู้เชิงลึก CNN_1 มีค่าความแม่นยำจากการทำนายด้วยข้อมูลชุดทดสอบ 83.33% โดยมีค่า recall/sensitivity เฉลี่ยเท่ากับ 0.815 ซึ่งโมเดล CNN_5 ก็มีค่าความแม่นยำเท่ากับ 83.33% เช่นเดียวกันเพียงแต่มีค่า recall/ sensitivity เฉลี่ยเพียง 0.78 ซึ่งมีโอกาสทำให้เกิดผลลบปลอมจากการทำนายผลมากกว่าโมเดล CNN_1 และเมื่อเปรียบเทียบประสิทธิภาพกับโมเดลจำแนกแบบการเรียนรู้ของเครื่องที่มีค่าความแม่นยำมากที่สุดคือโมเดลจำแนก SVM_1 ที่มีความแม่นยำเพียง 75.00% ดังนั้นจึงสามารถสรุปผลการทดลองที่ 1 ได้ว่าโมเดลการเรียนรู้เชิงลึก CNN_1 ที่ได้รับอินพุตคือสัญญาณ ERPs ในรูปแบบของ spectrogram สามารถจำแนกความแตกต่างระหว่างสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าและกลุ่มควบคุมได้มีประสิทธิภาพสูงสุด

4.2 การทดลองสร้างโมเดลจำแนกโดยใช้สัญญาณ ERPs ร่วมกับ ITPC


จุดประสงค์การทดลอง เพื่อสร้างโมเดลจำแนกประเภทการเรียนรู้เชิงลึกแบบ Concatenation Convolution Neural Network ซึ่งเป็นโมเดลที่มีโครงสร้างตามที่ผู้วิจัยได้เสนอและสร้างขึ้นโดยมีอินพุตของโมเดลทั้งหมดสองอินพุตได้แก่ ERPs และ ITPC โดยมีจุดมุ่งหมายให้โมเดลในส่วนของการจำแนกสามารถเรียนรู้ความสัมพันธ์ที่มาจากคุณลักษณะของ ERPs และ ITPC เพื่อเปรียบเทียบความแม่นยำในการทำนายผลกับโมเดลการเรียนรู้ของเครื่องและโมเดลการเรียนรู้เชิงลึกแบบ CNN ที่ใช้อินพุต ERPs เพียงอินพุตเดียวโดยใช้โอเล็ก์โทรดทั้งหมด 64 อีเล็ก์โทรด โดยมีการทดลองตามหัวข้อที่ 4.1 ซึ่งโมเดล Concat-CNN จะมีโครงสร้างของโมเดลเป็นไปตามหัวข้อที่ 3.3.4

เงื่อนไขการทดลอง

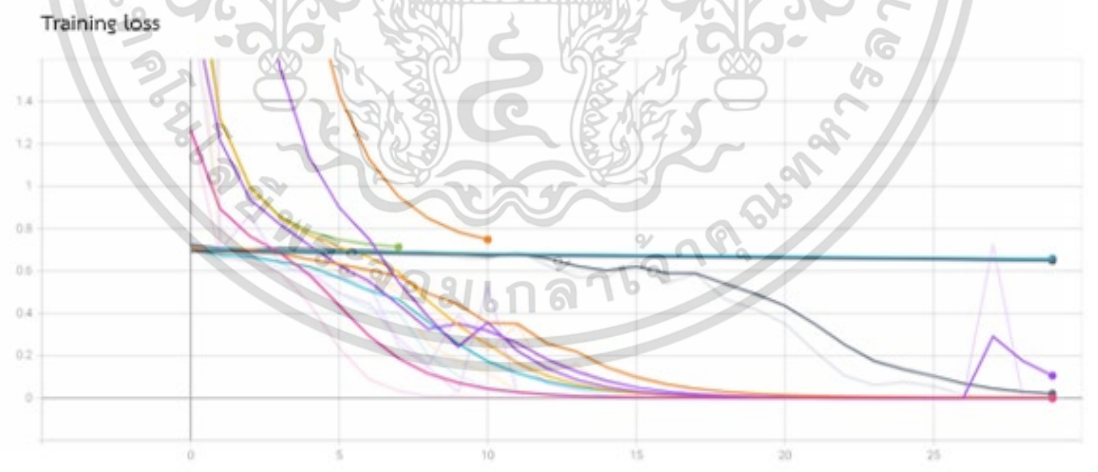
1. ข้อมูลที่ใช้สำหรับสอน ประเมิน และทดสอบโมเดลจำแนก Concat-CNN จะเป็นข้อมูลชุดเดียวกันกับการสอนโมเดลจำแนก k-NN, SVM, และ CNN แต่จะเพิ่มในส่วนของอินพุต ITPC
2. โครงสร้างของโมเดลจำแนก Concat-CNN จะมีจำนวน Convolution filter เท่ากันทั้งฝั่งอินพุต ERPs และ ITPC ดังที่แสดงไว้ในตารางที่ 3.2
3. พารามิเตอร์ที่ใช้ในการปรับค่ารวมถึงวิธีในการประเมินประสิทธิภาพของโมเดลจะใช้เงื่อนไขเดียวกันกับการทดลองที่ 1

4.2.1 ผลการทดลองสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึก Concat-CNN

จากการทดลองสร้างโมเดลจำแนกแบบการเรียนรู้เชิงลึกแบบ Concat-CNN ที่ใช้อินพุตคือสัญญาณ ERPs และ ITPC จะได้กราฟแนวโน้มของการสอนโมเดลดังรูปที่ 4.5 คล้ายกับการสร้างโมเดลจำแนก CNN แบบที่ใช้อินพุตเดียวคือ ERPs แต่ในแง่ของกราฟแนวโน้มการประเมินดังรูปที่ 4.7 จะสังเกตได้ว่าโมเดล Concat-CNN จะให้ค่าเฉลี่ยของความแม่นยำในการประเมินสูงกว่าโมเดลจำแนก CNN แบบปกติ




รูปที่ 4.5 กราฟแนวโน้มค่าความแม่นยำจากการสอนโมเดล Concat-CNN



รูปที่ 4.6 กราฟแนวโน้มค่าความสูญเสียจากการสอนโมเดล Concat-CNN


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Validation accuracy



รูปที่ 4.7 กราฟแนวโน้มค่าความแม่นยำจากการประเมินโมเดล Concat-CNN

Validation loss



รูปที่ 4.8 กราฟแนวโน้มค่าความแม่นยำจากการประเมินโมเดล Concat-CNN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.6 ผลการประเมินโมเดลจำแนก Concat-CNN ด้วยข้อมูลชุดประเมินจากวิธี

Hyperparameter Tuning

Model	Optimizer	Dense unit	Epoch	Valid accuracy	Valid loss
ConcatCNN_1	SGD	64	7	0.82353	0.5817
ConcatCNN_2	SGD	128	4	0.76471	0.6454
ConcatCNN_3	SGD	32	13	0.76471	0.6732
ConcatCNN_4	Adam	128	14	0.70588	0.6475
ConcatCNN_5	Adam	64	10	0.70588	0.6912
ConcatCNN_6	Adam	32	13	0.64706	0.6908
ConcatCNN_7	RMSprop	64	9	0.64706	0.6849
ConcatCNN_8	RMSprop	128	7	0.64706	0.6883
ConcatCNN_9	Adadelta	128	16	0.58824	0.6946
ConcatCNN_10	Adadelta	64	14	0.58824	0.6868
ConcatCNN_11	Adadelta	32	20	0.52941	0.6931
ConcatCNN_12	RMSprop	32	2	0.47059	0.7048

จากตารางที่ 4.6 ผลการประเมินโมเดลจำแนก Concat-CNN พบว่าโมเดลที่ใช้ Optimizer ชนิด SGD ที่มีค่า Dense unit เท่ากับ 64 มีความแม่นยำจากการประเมินสูงสุดที่ 82.35% ที่รอบการสอนที่ 7 ซึ่งมีค่ามากกว่าโมเดลจำแนก CNN ที่ใช้อินพุต ERPs เพียงอย่างเดียวบนการประเมินด้วยข้อมูลชุดเดียวกัน โดยผู้วิจัยจะนำโมเดล 3 อันดับแรกที่มีค่าความแม่นยำการประเมินสูงสุดและเทียบเท่ากับโมเดลจำแนก CNN_1 จากตารางที่ 4.4 มาเปรียบเทียบประสิทธิภาพกับข้อมูลชุดทดสอบในขั้นตอนถัดไป


4.2.2 ผลการเปรียบเทียบประสิทธิภาพของโมเดลจำแนก

จากผลการทดสอบประสิทธิภาพโมเดลจำแนก Concat-CNN ด้วยข้อมูลชุดทดสอบ ดังที่แสดงในตารางที่ 4.7 พบว่าโมเดล Concat-CNN_1 ที่มีค่าความแม่นยำจากการประเมินสูงสุด โมเดลให้ค่าความแม่นยำจากการทำนายด้วยข้อมูลชุดทดสอบเท่ากับ 91.67% ค่าความสูญเสียจากการทำนายเท่ากับ 0.201 โดยมีค่า recall/sensitivity เฉลี่ยเท่ากับ 0.910 ซึ่งจากผลการทำนายจะไม่มีผลลบปลอม (False Negative / Type 2 error) เกิดขึ้นซึ่งแสดงไว้ในรูปที่ 4.9 confusion matrix ของการทำนาย นอกจากนี้โมเดล Concat-CNN_2 ที่ใช้ optimizer ชนิด SGD เช่นเดียวกับโมเดล Concat-CNN_1 แต่มีจำนวน Dense unit ที่ 128 ก็มีความแม่นยำจากการทำนายผลจากข้อมูลชุดทดสอบเช่นเดียวกับโมเดลจำแนก Concat-CNN_1 ที่ 91.67% เช่นกัน

ตารางที่ 4.7 ผลการทดสอบโมเดลจำแนกด้วยข้อมูลชุดทดสอบ

Model	class	precision	recall/sensitivity	f1-score	accuracy
Concat-CNN_1	control	1.00	0.88	0.93	0.9167
	depression	0.80	1.00	0.89	
Concat-CNN_2	control	1.00	0.88	0.93	0.9167
	depression	1.00	1.00	0.89	
Concat-CNN_3	control	0.88	0.88	0.88	0.8333
	depression	0.75	0.75	0.75	
CNN_1	control	0.88	0.88	0.88	0.8333
	depression	0.75	0.75	0.75	
CNN_2	control	0.86	0.75	0.8	0.75
	depression	0.6	0.75	0.67	
CNN_3	control	0.78	0.88	0.82	0.75
	depression	0.67	0.5	0.57	
CNN_4	control	0.83	0.62	0.71	0.6667
	depression	0.5	0.75	0.6	
CNN_5	control	0.8	1	0.89	0.8333
	depression	1	0.5	0.67	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.9 Confusion Matrix ของการทำนายผลจากโมเดลจำแนก Concat-CNN

4.3 การทดลองปรับจูนโมเดลจำแนก Concat-CNN แบบละเอียด (Fine-tuning)

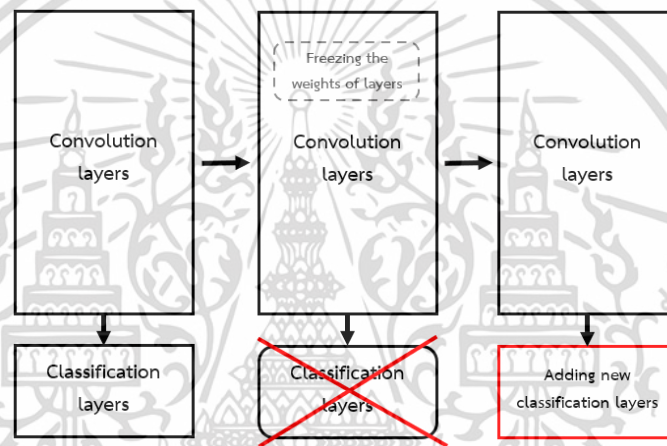
จุดประสงค์การทดลอง เพื่อนำโมเดลจำแนก Concat-CNN_1 ที่ได้รับการสอนและทดสอบประสิทธิภาพมาจากการทดลองที่ 4.2 มาปรับค่าพารามิเตอร์ในส่วนของการจำแนกหรือ Neural Network เพื่อเพิ่มประสิทธิภาพในการทำนายผลและให้ค่าความสูญเสียที่เกิดจากการทำนายมีค่าต่ำลงเพื่อให้เข้าใกล้กับคำตอบที่แท้จริง (Ground Truth) มากที่สุด

เงื่อนไขการทดลอง


1. โมเดลจำแนก Concat-CNN_1 จะเป็นโมเดลจากการทดลองที่ 4.2 ที่มีค่า weight จะการสอนโมเดลและผ่านการทดสอบประสิทธิภาพจากข้อมูลชุดทดสอบ
2. โมเดลจะถูกทำให้ค่า weight ที่ชั้น Convolution layers หรือชั้นสกัดคุณลักษณะ มีค่าคงที่และไม่สามารถเกิดการเปลี่ยนแปลงจากการสอนได้อีก (Untrainable parameter)
3. โมเดลจะถูกนำชั้น Neural Network (Classifier) หรือชั้นจำแนกที่มีค่า weight จากการสอนออกไปจากโมเดล และนำ Neural Network ชุดใหม่ที่ปราศจาก weight ที่มาจากการสอนเข้ามาเชื่อมต่อเป็นโมเดลเดียวกัน โดยกระบวนการนี้จะแสดงไว้ในรูปที่ 4.10

4. โมเดล Concat-CNN ใหม่ จะถูกเปลี่ยนจำนวน Dense unit เช่นเดียวกับกระบวนการ Hyperparameter Tuning และ optimizer ที่เลือกใช้คือ SGD เนื่องจากหลักฐานจากการทดสอบค่าความแม่นยำในการทดลองที่ 4.2 แสดงให้เห็นว่า SGD มีศักยภาพในการหาค่าตอบในชุดข้อมูลที่สอนมากที่สุด เพื่อให้โมเดลมีประสิทธิภาพมากยิ่งขึ้นผู้วิจัยจะเปลี่ยนค่าพารามิเตอร์ของ optimizer เพื่อหาค่าที่เหมาะสมกับโมเดลมากที่สุดดังแสดงในรูปที่ 4.11 และ 4.12 แผนการปรับค่า Learning rate ของ SGD แบบลดลงตามรอบการสอนแบบลำดับขั้น (Step decay) และลดลงแบบเอกซ์โพเนนเชียล (Exponential Decay)

5. ชุดข้อมูลที่ใช้ในการสอน การประเมินและการทดสอบยังคงเป็นข้อมูลชุดเดิมที่ใช้ในการทดลองที่ 4.1 และ 4.2




รูปที่ 4.10 การเตรียมโมเดลจำแนก Concat-CNN สำหรับกระบวนการปรับจูนแบบละเอียด



รูปที่ 4.11 แผนการปรับลดค่า Learning rate แบบลำดับขั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.12 แผนการปรับลดค่า Learning rate แบบเอกซ์โพเนนเชียล

ตารางที่ 4.8 ค่า learning rate ของ optimizer SGD ที่ลดลงแบบลำดับขั้นและเอกซ์โพเนนเชียล

Epoch	Step decay	Exponential decay
0	0.1	0.100000
10	0.05	0.036788
20	0.025	0.013534
30	0.0125	0.004979
40	0.00625	0.001832
50	0.003125	0.000674
60	0.001563	0.000248
70	0.000781	0.000091

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1 ผลการทดลองปรับจูนโมเดล Concat-CNN แบบละเอียด (Fine-Tuning)

จากผลการทดลองการนำโมเดลจำแนก Concat-CNN_1 มาปรับจูนละเอียดเฉพาะส่วนของการจำแนกโมเดล โดยการลดทอนค่า learning rate ตามรอบการสอนโมเดลที่มากขึ้น จะพบว่าทั้งการลดทอน learning rate แบบตามลำดับขั้นและแบบเอกซ์โพเนนเชียลจะให้ค่าความแม่นยำในทดสอบกับข้อมูลชุดทดสอบที่ 91.67% เท่ากัน เพียงแต่ค่าการสูญเสีย (loss) ในการลดทอนแบบลำดับขั้น (Step decay) จะมีค่าต่ำที่สุดซึ่งทำให้คำตอบที่ได้จากโมเดลใกล้เคียงกับคำตอบที่แท้จริงมากที่สุด

ตารางที่ 4.9 ผลการทดสอบโมเดลที่ผ่านการปรับจูนโมเดลแบบละเอียด

Model	class	precision	recall/ sensitivity	f1- score	accuracy/ loss
Concat-CNN_1	control	1.00	0.88	0.93	0.9167/0.2136
	depression	0.80	1.00	0.89	
Concat-CNN_1 (Step decay)	control	1.00	0.88	0.93	0.9167/0.1185
	depression	0.80	1.00	0.89	
Concat-CNN_1 (Expo decay)	control	1.00	0.88	0.88	0.9167/0.1824
	depression	0.80	1.00	0.89	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4 การทดลองตรวจสอบการทำนายผลจากโมเดลจำแนกด้วยอัลกอริทึม Grad-CAM

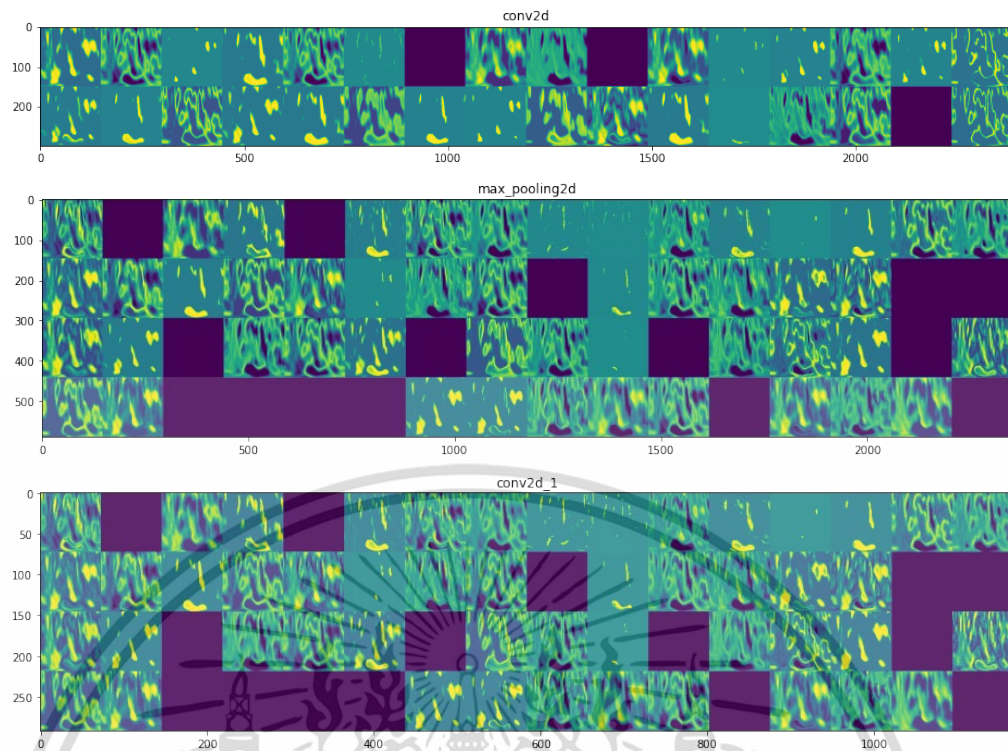
จุดประสงค์การทดลอง เพื่อนำโมเดลจำแนก Concat-CNN_1 (Step decay) มาตรวจสอบสมมุติฐานที่กำหนดไว้ว่าโมเดลจำแนกจะสามารถตรวจจับความแตกต่างของสัญญาณ ERPs และ ITPC ของผู้ป่วยโรคซึมเศร้าในรูปแบบของภาพ Spectrogram ของโดเมนเวลา-ความถี่ในจุดที่ผู้วิจัยต้องการ โดยการสร้างแผนภูมิของส่วนการสกัดคุณลักษณะจากการทำนาย (Gradient-weight Class Activation Mapping, Grad-CAM) เพื่อหาส่วนที่โมเดลสกัดคุณลักษณะจากรูป spectrogram มาเพื่อใช้ในการทำนายผลว่ามีลักษณะอย่างไร

เงื่อนไขการทดลอง


1. ผู้วิจัยจะนำค่าของ Gradient ชั้นสุดท้ายของ Convolution layers ของการสกัดคุณลักษณะจากโมเดลจำแนก Concat-CNN_1 (Step decay) ในทั้งด้านของอินพุต ERPs และ ITPC มาพล็อตในรูปแบบของ Heat map เพื่อหาส่วนที่โมเดลค้นหาจากรูป spectrogram ก่อนที่จะนำไปทำนายผลในชั้น Neural Network
2. รูป Heat map ของค่า Gradient-weight ที่แสดงออกมาจะเป็นค่าเฉลี่ยของคุณลักษณะที่เกิดขึ้นในชั้นคอนโวลูชันชั้นนั้นๆ ที่เกิดขึ้นจากการทำนายผล
3. การพล็อตค่า Gradient-weight ของกลุ่มตัวอย่างผู้วิจัยจะเลือกมาเฉพาะอิเล็กโทรดของ EEG บางส่วนเพื่อตรวจสอบเช่นอิเล็กโทรดตำแหน่ง FP1, FPZ, และ FP2 ซึ่งเกี่ยวข้องกับสมองส่วนที่ตอบสนองต่อโรคซึมเศร้ามากที่สุด

4.4.1 ผลการทดลองพล็อตค่า Gradient-weight ที่เกิดขึ้นในชั้นคอนโวลูชัน

จากผลการสำรวจชั้นคอนโวลูชันที่ผ่านการสกัดคุณลักษณะจาก spectrogram ERPs และ ITPC จะเห็นได้ว่ารูปที่ 4.13 และ 4.14 จะแสดงเอาท์พุต Feature map ของชั้นคอนโวลูชันและชั้น max pooling ที่ตอบสนองจากการทำนายผลจากข้อมูลชุดทดสอบ โดยจากการสังเกต heat map ของค่าคุณลักษณะพบว่าค่าคุณลักษณะในบางช่วงได้ถูกสกัดทอนจนไม่เหลือค่าแอมพลิจูดของ Gradient-weight อันเนื่องมาจากในกระบวนการทำนายผลจากข้อมูลตัวอย่างนั้นๆ ไม่ได้มีรูปแบบของค่าคุณลักษณะที่ตรงกับที่โมเดลได้เรียนรู้มาจากข้อมูลชุดสอน




รูปที่ 4.13 Feature map ของสัญญาณ ERPs




รูปที่ 4.14 Feature map ของสัญญาณ ITPC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.15 Heat map ของ Gradient-weight จากชั้นคอนโวลูชันที่มีอินพุตคือ ERPs



รูปที่ 4.16 Heat map ของ Gradient-weight จากชั้นคอนโวลูชันที่มีอินพุตคือ ITPC

จากการพล็อตรูป Heat map ของ Gradient-weight จากชั้นคอนโวลูชันชั้นสุดท้ายในแต่ละอินพุตทั้งฝั่ง ERPs และ ITPC จากอิเล็กโทรด EEG ที่จุด FP1, FPZ, และ FP2 ตามลำดับพบว่าจากรูปที่ 4.15 ค่าคุณลักษณะสุดท้ายที่สกัดออกมาได้ มีจุดโฟกัสสูงสุดไปยังแอมพลิจูดที่บริเวณความถี่เดลต้าและที่ต่ำโดยมีค่าองค์ประกอบ N200 และ P300 หลังจากเกิดการกระตุ้นจากการทดลอง และมีการสกัดสัญญาณรบกวนที่ไม่ต้องการในย่านความถี่อื่นเข้ามาด้วย และในส่วนของด้านอินพุต ITPC ก็จะมีการโฟกัสไปยังแอมพลิจูดที่เกิดขึ้นเช่นเดียวกัน

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการทดลอง

วิทยานิพนธ์ฉบับนี้มุ่งเน้นในการสร้างโมเดลจำแนกที่ใช้ในการจำแนกผู้ป่วยโรคซึมเศร้าด้วยสัญญาณคลื่นสมอง EEG ด้วยการใช้โมเดลจำแนกแบบ Concatenation Convolution Neural Network ซึ่งใช้อินพุตแบบสองทางมาควบรวมกันที่ชั้นสกัดคุณลักษณะ ได้แก่ สัญญาณ ERPs และ ITPC เพื่อเป็นการเพิ่มประสิทธิภาพในการจำแนกความแตกต่างระหว่างผู้ป่วยโรคซึมเศร้าและกลุ่มคนปกติ ซึ่งเป็นวิธีการสร้างโมเดลที่ผู้วิจัยได้นำเสนอไว้ในงานวิจัย โดยจากการนำความสามารถในการประมวลผลเชิงรูปภาพของโมเดลจำแนกแบบการเรียนรู้เชิงลึกเข้ามาใช้ในการจำแนกสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าพบว่าโมเดลการเรียนรู้เชิงลึกชนิด CNN มีความแม่นยำในการจำแนกที่ดีกว่าโมเดลจำแนกแบบการเรียนรู้ของเครื่องซึ่งจำเป็นต้องพึ่งพาความสามารถอัลกอริทึมที่ใช้ในการลดมิติของข้อมูลเพื่อไม่ให้ข้อมูลมีขนาดของมิติที่ใหญ่เกินความสามารถของโมเดลจำแนกจนอาจเกิดเหตุการณ์ Curse of dimensionality รวมถึงอัลกอริทึมที่ใช้ในการสกัดคุณลักษณะเพื่อสอนให้กับโมเดล โดยการเลือกอัลกอริทึมสกัดคุณลักษณะจำเป็นต้องหาอัลกอริทึมที่มีความเหมาะสมกับโมเดลจำแนกเพื่อให้เกิดประสิทธิภาพสูงสุด ซึ่งในงานวิจัยที่ผ่านมามีการใช้สัญญาณ EEG โดยใช้จำนวนจุดอิเล็กโทรดเพียงไม่กี่ตำแหน่งมาเป็นสัญญาณอินพุตให้กับโมเดลจำแนกและให้ค่าความแม่นยำในการทำนายผลได้ดีในระดับหนึ่ง แต่เมื่อมีการเพิ่มจำนวนจุดอิเล็กโทรดสำหรับอินพุตของโมเดล ก็จะทำให้พบปัญหามิติของข้อมูลสูงซึ่งส่งผลทำให้ประสิทธิภาพของโมเดลจำแนกนั้นลดลง ทำให้โมเดลจำแนก CNN มีข้อได้เปรียบโมเดลจำแนกแบบการเรียนรู้ของเครื่องซึ่งสามารถรับอินพุตหลายทางได้โดยไม่มีผลกระทบจากมิติของข้อมูล เนื่องจากอินพุตแต่ละส่วนที่เข้ามาในโมเดลจะใช้กระบวนการสกัดคุณลักษณะและลดมิติข้อมูลเป็นอิสระซึ่งกันและกันทำให้โอกาสในการสูญเสียข้อมูลที่สำคัญมีค่าต่ำกว่า

โดยจากการผลการทดลองในบทที่ 4 ในหัวข้อที่ 4.2 และ 4.3 ซึ่งเป็นการทดลองสร้างโมเดลจำแนก Concat-CNN และปรับจูนพารามิเตอร์ในโมเดลแบบละเอียด จะเห็นได้ว่าวิธีที่วิทยานิพนธ์ฉบับนี้ได้นำเสนอได้ผลลัพธ์จากการทำนายผลได้ดีกว่าโมเดลจำแนก k-NN, SVM รวมถึง CNN ที่ใช้อินพุตเพียงแค่สัญญาณ ERPs ซึ่งแตกต่างจากโมเดล Concat-CNN ที่ได้รับอินพุต ITPC โดยผู้ทดลองมีสมมุติฐานว่า ITPC ที่เป็นค่าเฉลี่ยของเวกเตอร์เฟสในแต่ละอิเล็กโทรด ซึ่งมีคุณสมบัติเพื่อใช้บอกค่าความสัมพันธ์ในอิเล็กโทรดที่มาจากผลการทดลองการกระตุ้นที่มีความเกี่ยวข้องกันมากเพียงใดจาก

เหตุการณ์การกระตุ้นทั้งหมด ซึ่งพบว่าโมเดล Concat-CNN สามารถเรียนรู้ความสัมพันธ์ที่เกิดขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภายในจากค่าคุณลักษณะที่มาจากชั้นคอนโวลูชันของอินพุตทั้งได้ และแสดงออกมาในรูปแบบของความแม่นยำจากการทำนายผลที่เพิ่มขึ้น นอกจากนี้เมื่อนำโมเดลที่ผ่านการทดสอบในการทดลองที่ 4.2 ไปเข้าสู่กระบวนการปรับจูนพารามิเตอร์แบบละเอียดที่การทดลองที่ 4.3 ซึ่งผลที่ได้แสดงให้เห็นว่า การปรับจูนแบบละเอียดยังไม่สามารถเพิ่มค่าความแม่นยำให้กับโมเดลในกระบวนการการทำนายผลได้ แต่ทำให้ค่าความสูญเสียที่เกิดขึ้นจากการทำนายมีค่าที่ต่ำลง ซึ่งมีผลทำให้ค่าความเชื่อมั่นของโมเดลจำแนกเพิ่มขึ้น

นอกจากนี้ผู้วิจัยได้นำอัลกอริทึม Gradient-weight Class Activation Mapping (Grad-CAM) ซึ่งใช้ในการตรวจสอบลักษณะที่เกิดขึ้นในชั้นคอนโวลูชันเมื่อผ่านการสกัดคุณลักษณะจากทั้งสัญญาณ ERPs และ ITPC เพื่อสังเกตว่าโมเดลจำแนกมีการตอบสนองอย่างไรต่ออินพุต โดยพบว่า ลักษณะของค่า Feature map เฉลี่ยที่ชั้นคอนโวลูชันสุดท้าย ได้มีการให้ความสำคัญไปยังบริเวณมีค่าแอมพลิจูดที่เกิดจากการกระตุ้นตามสมมุติฐานจากการสอนโมเดลที่คาดหวังไว้ ทำให้โมเดลจำแนก Concat-CNN มีคุณภาพทั้งด้านค่าความแม่นยำและความน่าเชื่อถือที่มากขึ้น

5.2 ข้อเสนอแนะ

โมเดลจำแนก Concat-CNN เป็นโมเดลที่พัฒนามาจากโมเดลจำแนก CNN โดยการเพิ่มจำนวนอินพุตทั้งในด้านจำนวนอิเล็กโทรดและอินพุตที่แสดงคุณลักษณะจำเพาะอย่าง ITPC ซึ่งจากกระบวนการสอนโมเดลจำแนกผู้วิจัยพบว่าโมเดลเกิดเหตุการณ์ Overfitting ในกระบวนการประเมินโมเดล (Validation) ที่จำนวนรอบการสอน ไม่เพียงก็รอบ อันเนื่องมาจากจำนวนตัวอย่างของข้อมูลคลื่นสมองที่มีจำกัด ทำให้เงื่อนไขนี้เป็นข้อจำกัดในการสร้างโมเดลจำแนกแบบการเรียนรู้แบบเชิงลึก เพราะการสร้างโมเดลการเรียนรู้แบบเชิงลึกจำเป็นต้องใช้จำนวนข้อมูลที่มีขนาดใหญ่เพียงพอ ผู้วิจัยจึงมีความพยายามในลดขนาดของโมเดลในทั้งส่วนของชั้นคอนโวลูชันและชั้นจำแนกที่เป็น Neural Network เพื่อให้สอดคล้องกับจำนวนข้อมูลที่มีอยู่เพื่อให้เกิดประสิทธิภาพสูงสุดและหลีกเลี่ยงปัญหา Overfitting ที่เกิดขึ้น ซึ่งปัญหานี้จำนวนข้อมูลที่ไม่เพียงพอก็ยังเป็นข้อกั่วงวลที่เกิดขึ้นในกระบวนการสร้างโมเดล โดยวิธีการแก้ไขปัญหานี้ ผู้วิจัยคาดว่าอาจสามารถใช้วิธีการสังเคราะห์ข้อมูลคลื่นสมองที่อยู่ในรูปของ Spectrogram image โดยการใช้โมเดลการเรียนรู้เชิงลึก Generative Adversarial Network (GAN) ซึ่งเป็นโมเดลที่ใช้ในสร้างรูปภาพขึ้นมาจากเงื่อนไขที่กำหนดได้ เพื่อใช้สำหรับการสอนให้โมเดลจำแนกและทดสอบด้วยข้อมูลจริงเพียงอย่างเดียวเพื่อให้ได้มาซึ่งโมเดลจำแนกที่มีประสิทธิภาพมากที่สุด

เอกสารอ้างอิง

- [1] C. Chinvararak and P. Lueboonthavatchai, "Somatic Symptoms and Its Association to Depressive Severity in Patients with Major Depressive Disorder in King Chulalongkorn Memorial Hospital," *Journal of the Psychiatric Association of Thailand*, vol. 61, pp. 293-306, 01/01 2016.
- [2] A. American Psychiatric, A. American Psychiatric, and D. S. M. T. Force, *Diagnostic and statistical manual of mental disorders : DSM-5*. Arlington, VA: American Psychiatric Association, 2013.
- [3] A. T. Beck, R. A. Steer, and G. K. Brown, *BDI-II : Beck depression inventory*. San Antonio [Tex.]: Psychological Corp., 1996.
- [4] J. S. Kumar and P. Bhuvaneshwari, "Analysis of Electroencephalography (EEG) Signals and Its Categorization–A Study," *Procedia Engineering*, vol. 38, pp. 2525-2536, 2012/01/01/ 2012.
- [5] W. contributors. (2021). *10–20 system (EEG)*. Available: [https://en.wikipedia.org/w/index.php?title=10%E2%80%9320_system_\(EEG\)&oldid=1003622197](https://en.wikipedia.org/w/index.php?title=10%E2%80%9320_system_(EEG)&oldid=1003622197)
- [6] S. Sur and V. K. Sinha, "Event-related potential: An overview," *Industrial psychiatry journal*, vol. 18, pp. 70-3, 2009.
- [7] A. Tiriak and M. Blumberg, "The Case of the Disappearing Spindle Burst," *Neural Plasticity*, vol. 2016, pp. 1-7, 03/28 2016.
- [8] R. M. van Diepen and A. Mazaheri, "The caveats of observing inter-trial phase-coherence in cognitive neuroscience," *Scientific reports*, vol. 8, pp. 1-9, 2018.
- [9] "Intertrial Phase Clustering," in *Analyzing Neural Time Series Data: Theory and Practice*, M. X. Cohen, Ed., ed: The MIT Press, 2014, p. 0.
- [10] J. F. Cavanagh, A. J. Bismark, M. J. Frank, and J. J. Allen, "Larger Error Signals in Major Depression are Associated with Better Avoidance Learning," *Front Psychol*, vol. 2, p. 331, 2011.
- [11] A. Hyvärinen, "Independent component analysis: recent advances," *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*, vol. 371, pp. 20110534-20110534, 2012.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [12] X. Jiang, G.-B. Bian, and Z. Tian, "Removal of Artifacts from EEG Signals: A Review," *Sensors (Basel, Switzerland)*, vol. 19, p. 987, 2019.
- [13] S. Romero, M. A. Mananas, and M. Barbanoj, "Ocular Reduction in EEG Signals Based on Adaptive Filtering, Regression and Blind Source Separation," *Annals of biomedical engineering*, vol. 37, pp. 176-91, 12/01 2008.
- [14] M. Murugappan, M. Rizon, R. Nagarajan, S. Yaacob, D. Hazry, and I. Zunaidi, "Time-frequency analysis of EEG signals for human emotion detection," in *4th Kuala Lumpur international conference on biomedical engineering 2008*, 2008, pp. 262-265.
- [15] T. Witzel, V. Napadow, N. Kettner, M. Vangel, M. Hämäläinen, and R. Dhond, "Differences in cortical response to acupressure and electroacupuncture stimuli," *BMC neuroscience*, vol. 12, p. 73, 07/27 2011.
- [16] A. Taspinar. (2018). *A guide for using the Wavelet Transform in Machine Learning*. Available: <https://ataspinar.com/2018/12/21/a-guide-for-using-the-wavelet-transform-in-machine-learning/>
- [17] M. X. Cohen, "A better way to define and describe Morlet wavelets for time-frequency analysis," *NeuroImage*, vol. 199, pp. 81-86, 2019.
- [18] "Morlet Wavelets and Wavelet Convolution," in *Analyzing Neural Time Series Data: Theory and Practice*, M. X. Cohen, Ed., ed: The MIT Press, 2014, p. 0.
- [19] S. Wold, K. Esbensen, and P. Geladi, "Principal component analysis," *Chemometrics and intelligent laboratory systems*, vol. 2, pp. 37-52, 1987.
- [20] K. Ruksiamza. (2020). *Principal Component Analysis : PCA*. Available: <https://kongruksiamza.medium.com/pca>
- [21] L. E. Peterson, "K-nearest neighbor," *Scholarpedia*, vol. 4, p. 1883, 2009.
- [22] S. A. Gokte. (2020). *Most Popular Distance Metrics Used in KNN and When to Use Them*. Available: <https://www.kdnuggets.com/2020/11/most-popular-distance-metrics-knn.html>
- [23] L. Wang, *Support vector machines: theory and applications* vol. 177: Springer Science & Business Media, 2005.
- [24] O. Manjrekar and M. Duduković, "Identification of flow regime in a bubble column reactor with a combination of optical probe data and machine learning technique," *Chemical Engineering Science: X*, vol. 2, p. 100023, 04/01 2019.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [25] W. contributors. (2021). *Support-vector machine*. Available: https://en.wikipedia.org/w/index.php?title=Support-vector_machine&oldid=1033188195
- [26] K. O'Shea and R. Nash, "An introduction to convolutional neural networks," *arXiv preprint arXiv:1511.08458*, 2015.
- [27] S. Saha. (2018). *A Comprehensive Guide to Convolutional Neural Networks-the ELI5 way*. Available: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [28] P. Krishnammal and S. Raja, "Convolutional Neural Network based Image Classification and Detection of Abnormalities in MRI Brain Images," *2019 International Conference on Communication and Signal Processing (ICCSP)*, pp. 0548-0553, 2019.
- [29] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning* vol. 1: MIT press Cambridge, 2016.
- [30] S. D. N. (2020). *Solving For Optimization Problems*. Available: <https://medium.com/analytics-vidhya/solving-for-optimization-problems-fee1e7ee5d22>
- [31] S. Bhattarai. (2018). *WHAT IS ACTIVATION FUNCTIONS IN NEURAL NETWORK (NN)*. Available: <https://saugatbhattarai.com.np/what-is-activation-functions-in-neural-network-nn/>
- [32] H. Cai, J. Han, Y. Chen, X. Sha, Z. Wang, B. Hu, *et al.*, "A pervasive approach to EEG-based depression detection," *Complexity*, vol. 2018, 2018.
- [33] C. Uyulan, T. T. Ergüzel, H. Unubol, M. Cebi, G. H. Sayar, M. Nezhad Asad, *et al.*, "Major depressive disorder classification based on different convolutional neural network models: Deep learning approach," *Clinical EEG and Neuroscience*, vol. 52, pp. 38-51, 2021.
- [34] S. Rathanon and K. Yuttana, "Major Depression Disorder detection on EEG-Based with the Convolution Neural Networks approach Improved with the Inter-trial phase clustering," *The 43rd Electrical Engineering Conference (EECON-43)*, pp. 314-317, 2020.



ภาคผนวก

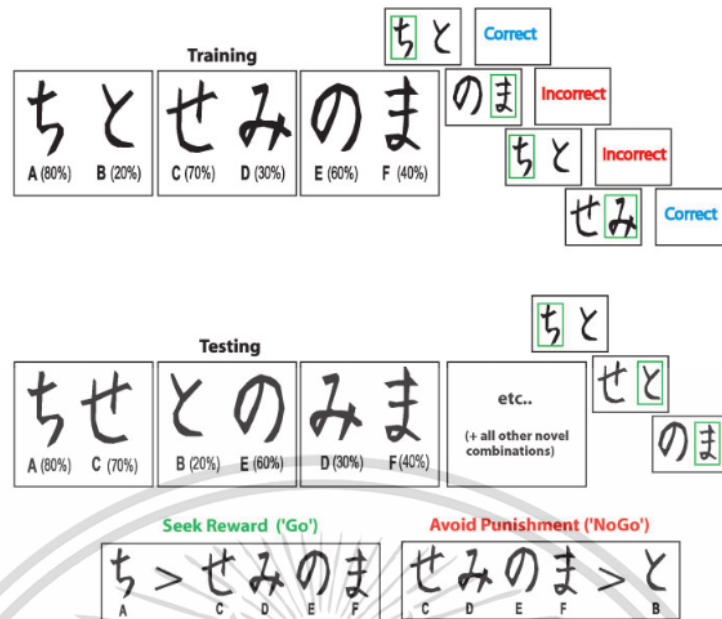
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.

รายละเอียดของข้อมูลผู้ป่วยโรคซึมเศร้า

ข้อมูลสัญญาณคลื่นสมองของผู้ป่วยโรคซึมเศร้าได้รับการสนับสนุนจากสถาบันวิจัย Cognitive Rhythms and Computational Lab ที่ University of New Mexico Department of Psychology โดยข้อมูลสัญญาณ EEG จะมีทั้งหมด 121 ตัวอย่าง โดยการเก็บตัวอย่างมาจากอาสาสมัครที่อยู่ในช่วงอายุเฉลี่ย 18.9 ปี โคนกลุ่มตัวอย่างที่มีค่าดัชนี BDI ต่ำกว่า 7 ซึ่งเป็นกลุ่มควบคุม จะต้องไม่มีประวัติรายงานเกี่ยวกับการเป็นโรคซึมเศร้า (Major Depression Disorder) ไม่มีประวัติการใช้ยารักษาที่มีการออกฤทธิ์ต่อระบบประสาท ไม่มีประวัติการเกิดอุบัติเหตุที่ศีรษะ และไม่มีการรายงานถึงอาการที่บ่งชี้ถึงโรคที่อยู่ในกลุ่มแกนที่ 1 (Axis I disorder) โดยกระบวนการเก็บข้อมูลคลื่นสมอง EEG จะใช้การสร้างเหตุการณ์การกระตุ้นที่มีชื่อเรียกว่า Reinforcement learning โดยเหตุการณ์การกระตุ้นจะสามารถจำแนกได้เป็นสองประเภทได้แก่ เหตุการณ์ที่ก่อให้เกิดการให้รางวัล (Reward/Correct) และเหตุการณ์ที่ก่อให้เกิดการลงโทษ (Punishment/Incorrect) ซึ่งในกระบวนการผู้เข้าร่วมการทดลองจะถูกสร้างให้จับคู่ตัวอักษรที่มีความน่าจะเป็นในการเฉลยคำตอบที่แตกต่างกันดังนี้คือ A/B (80%/20%), C/D (70%/30%) และ E/F (60%/40%)

โดยเหตุการณ์ที่เกิดขึ้นกับผู้เข้าร่วมการทดลองในการกระตุ้นจะมาจากการจับคู่ผสมตัวอักษรที่ต่างกัน จะอนุมานได้สองเหตุการณ์คือ เหตุการณ์การมองหารางวัลหรือคำตอบที่ถูกต้อง (seeking reward/Go learning) ซึ่งมาจากการเลือกตัวอักษร A มาก่อน C, D, E และ F เพื่อให้มีโอกาสที่ตอบถูกมากที่สุด และอีกเหตุการณ์คือ เหตุการณ์การหลีกเลี่ยงการถูกลงโทษหรือตอบผิด (NoGo learning) ซึ่งมาจากการเลือกตัวอักษร C, D, E และ F ก่อน B เนื่องจากตัวอักษร B มีโอกาสทำให้คำตอบผิดมากที่สุด โดยการทดลองทั้งหมดจะมีสองระยะคือ ระยะการสอนให้รู้จักการจับคู่และเกณฑ์การให้คำตอบ (Training phase) ซึ่งทุกครั้งที่มีจับคู่เสร็จหน้าจอก็จะแสดงผลคำตอบออกมาทันที (Feedback) และระยะทดสอบ ซึ่งจะแตกต่างจากข้อแรกคือจะไม่มีการเฉลยคำตอบหลังจากจับคู่



รูปที่ ก.1 ตัวอย่างการทดลอง Reinforcement learning

โดยผู้ป่วยโรคซึมเศร้าจะแบ่งออกเป็น 2 กลุ่มหลัก คือ ผู้ป่วยที่มีอาการอยู่ในปัจจุบัน (MDD) และผู้ที่เคยมีประวัติการป่วยเป็นโรคซึมเศร้า (Past MDD) นอกจากนี้ยังมีกลุ่มที่ค่าดัชนี BDI สูงซึ่งมีแนวโน้มบ่งชี้ว่ามีอาการของโรคซึมเศร้า (Nothing) แต่ไม่มีประวัติในการตรวจหรือรักษาโรค โดยรายละเอียดทั้งหมดจะแสดงไว้ในตารางที่ ก.1

ตารางที่ ก.1 ประวัติของกลุ่มที่เข้าเกณฑ์ป่วยเป็นโรคซึมเศร้า

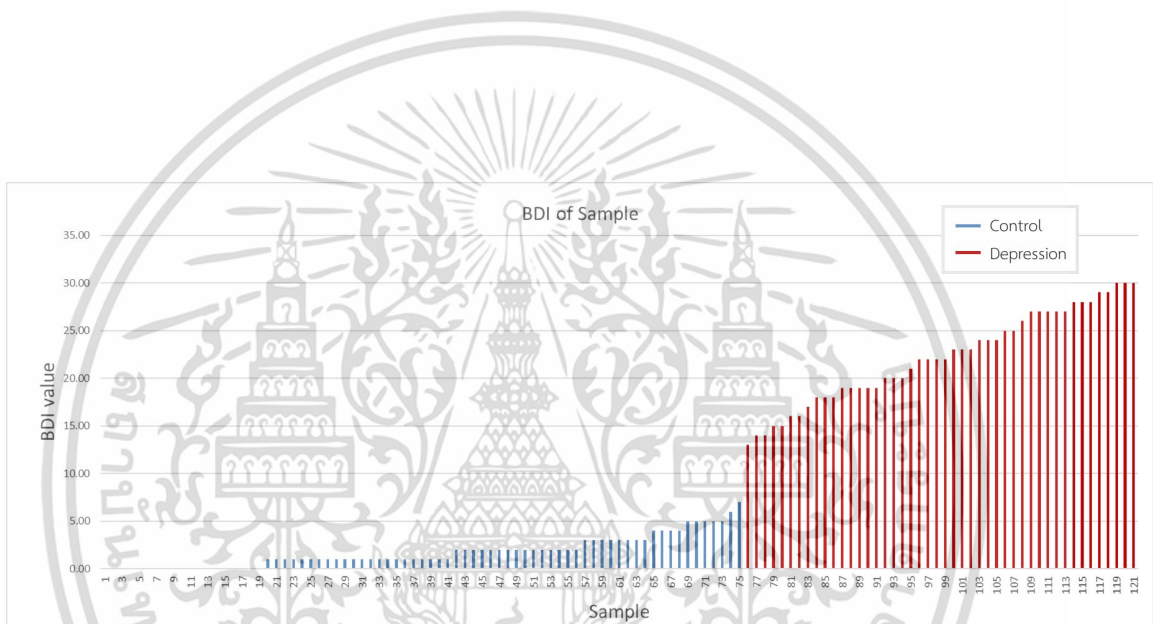
Sample No.	Sample Description	Sex	Age	BDI
1	past MDD - GAD, social Phobia - subsyndromal / unremittd Dep	Female	19	13
2	MDD	Male	18	14
3	MDD	Female	18	14
4	past MDD (mel+); past eating, current alc abuse	Female	18	15
5	Nothing	Female	18	15
6	past MDD (mel+)	Female	18	16
7	subsyndromal current	Female	19	16
8	Nothing	Female	20	17
9	MDD	Female	19	18
10	Nothing	Female	18	18
11	Nothing	Female	18	18

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sample No.	Sample Description	Sex	Age	BDI
12	past MDD: subst induced	Female	18	19
13	Spec Phobia - possibly GAD - lotsa somatic / BDD	Female	18	19
14	past MDD (mel+)	Male	24	19
15	dysthymic, Hx Alc curr cannabis	Male	18	19
16	Nothing	Female	19	19
17	past MDD - likely Narcissistic	Male	19	20
18	past MDD	Female	18	20
19	Nothing	Male	19	20
20	Nothing	Female	18	21
21	Nothing	Female	21	22
22	Nothing	Male	18	22
23	Nothing	Female	18	22
24	Nothing	Female	19	22
25	Anx: social: eat & speak	Female	18	23
26	MDD	Female	20	23
27	Nothing	Male	18	23
28	MDD	Female	19	24
29	MDD	Female	18	24
30	subsyndromal past MDE	Female	19	24
31	MDD (mel+)	Male	19	25
32	Nothing	Female	18	25
33	Nothing	Female	18	26
34	MDD; panic, OC(compulsions)	Female	19	27
35	past MDD - past Manic - past Panic (not Panic D/O)	Female	18	27
36	Nothing	Male	18	27
37	Nothing	Female	21	27
38	Nothing	Female	18	27
39	past MDD (mel+)	Female	18	28
40	past MDD	Female	20	28

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sample No.	Sample Description	Sex	Age	BDI
41	Nothing	Female	19	28
42	Nothing	Female	18	29
43	MDD: prim anhedonia	Male	20	29
44	MDD: Vague psychotic, sub dx anxiety	Male	19	30
45	past MDD	Male	19	30
46	Nothing	Female	18	30
47	Nothing	Female	18	30



รูปที่ ก.2 ค่า BDI ของกลุ่มตัวอย่าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก ข.

ผลงานวิจัยที่ได้รับการตีพิมพ์

Rathanon Suwanteerangkul, and Yuttana Kidjaidure, "Major Depression Disorder detection on EEG-Based with the Convolution Neural Networks approach Improved with the Inter-trial phase clustering," The 43rd Electrical Engineering Conference (EECON-43), 28-30 October 2020, pp. 314-317

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 43
The 43rd Electrical Engineering Conference (EECON-43)



28 - 30 ตุลาคม 2563
ณ โรงแรมท็อบแลนด์
อำเภอเมือง จังหวัดพิษณุโลก



 ไฟฟ้ากำลัง (PW)
 การประมวลผลสัญญาณดิจิทัล (DS)
 อิเล็กทรอนิกส์กำลัง (PE)
 ไฟโตนิคส์ (PH)
 ไฟฟ้าสื่อสาร (CM)
 วิศวกรรมชีวการแพทย์ (BE)
 ระบบควบคุมและการวัดคุม (CT)
 คอมพิวเตอร์และเทคโนโลยีสารสนเทศ (CP)
 อิเล็กทรอนิกส์ (EL)
 พลังงานหมุนเวียน (RE)
 ภาควิชาที่เกี่ยวข้องกับวิศวกรรมไฟฟ้า (GN)





เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Major Depression Disorder detection on EEG-Based with the Convolution Neural Networks approach improved with the Inter-trial phase clustering

Rathanon Suwanteerangkul¹ and Yuttana Kitjaidure²

¹Department of Electronics Engineering, Faculty of Engineering,
King Mongkut's Institute of Technology Ladkrabang, Thailand, 62601073@kmitl.ac.th

²Department of Electronics Engineering, Faculty of Engineering,
King Mongkut's Institute of Technology Ladkrabang, Thailand, yuttana.ki@kmitl.ac.th

Abstract

Nowadays, Major Depression Disorder is still a concern about human mental health, and there are significant challenges in the diagnosis. There are still limitations in the traditional method used to classify patients from healthy groups and required specialized personnel such as a psychiatrist or psychologist. The aim of this study is to introduce the ability of a deep learning approach to detect abnormalities in EEG (Electroencephalogram) signals of patients with depression. The EEG features are based on the Time-Frequency Analysis of EEG signals from the Morlet wavelet transformation, also known as ERPs (Event-Related Potentials) and ITPC (Inter-trial phase clustering), which is complex and challenging to assess by humans. We proposed a deep learning model that are integrating the two Convolution Neural Networks (CNNs) models to learn both EEG features at the same time to increase efficiency in classification. The result shows that the concatenation CNNs between two input's EEG features received accuracy in classification at 91.60% compared with general CNNs that use single input ERPs with accuracy only 83.33%. Also, we are comparing with a machine learning approach, such as KNN (K-nearest neighbor), that received an accuracy of 67.00%.

Keywords: Electroencephalogram (EEG), Event-Related Potentials (ERPs), Inter-Trial phase clustering (ITPC)

1. Introduction

Major depression disorder is still a grave concern for human mental health. Generally, depression is caused by brain disorders that affect thoughts, emotions, as well as physical health. In several patients who have experience with depression might have symptoms and express symptom [1] such as 1) mood symptoms, 2) somatic symptoms, 3) cognitive symptoms, 4) psychomotor slowness and 5) interpersonal symptoms that cause problems in daily life, such as Insomnia, loss of concentration, eating behavior, working, including living with others in society, and patients suffering in a critical case in depression, may cause suicide. According to the World Health Organization statistics [2], no less than 300 million patients have to live with depression. Hence, if the clinical diagnosis could diagnose the disease and treat those symptoms in an early curable stage, there could save many patients.

Presently, the diagnosis of depression symptoms needs to use a specialist in psychology such as a

psychiatrist or psychologist to convince patients in the interview of screening depression patients. The current screening tools mostly used for diagnostic criteria are the international standard criteria such as "Fifth Edition of the Diagnostic and Statistical Manual of Mental Disorders" (DSM-5) [3] and Beck depression inventory (BDI) [4]. Both of these screening tools must have collaborated with the patient because in some patient's cases they avoid in a diagnosis of depression because the nature of mental disorder fear in assistance from another person and the consequence of error diagnosis is that a patient does not receive a correct treatment procedure and might increase the level of mental disorder. According to depression detection, the accuracy in diagnosing it depends on the specialization of personal experience. On the other hand, there is an instrument that is convenient, effective, and reflects directly with brain activity and receives the physiological data in real-time called EEG.

Electroencephalography (EEG) is a noninvasive technique for measures an electrical signal from brain activities. It uses multiple of the electrode that places directly on a scalp to receive a variation of a neuron inside the brain [5]. Recording the brain signal relates to brain activity; it is based on the event set to stimulate brain activity and record it in the experimental time frame. EEG is utilized in medical practice, such as detection in abnormality of brain function, epilepsy detection, and sleep apnea assessment. Generally, an evaluation of the EEG is focused on measure response to a stimulus; the method is called Event-related potentials (ERPs) [6]; it uses an average of EEG signal of each event trial. However, using ERPs just interpretation in the aspect of the time domain in the signal analysis would not be able to observe the dynamic of magnitude in each frequency. Furthermore, receiving both magnitudes of time and frequency is using ERPs in Time-Frequency analysis for interpreting the EEG signal, so it's considered as a type of EEG features.

Moreover, there is another EEG feature in the Time-Frequency domain that correlates with a changing of EEG signal over trials called Inter-trials phase clustering (ITPC) [7], so it is represented as a distribution of vector phase relied on each frequency and each time point that stimulation is onset. So it expresses in the form of magnitude of the average vector phase that shows the interconnectivity of the EEG electrode in the overall stimulus event. The prior evidence about the investigation in ITPC [8] showed that the induction of ITPC as a condition of analysis could enhance observation between

3.2 Convolution Neural Network




Fig. 2 EEG features input stack generations

To access the ability of Convolution Neural Networks, we start with creating an input stack containing ERPs and ITPC spectrogram images that are resized to 200x200 pixels and rearranged them according to 64 EEG electrodes in each input of CNNs. Finally, an image cube of 200x200x64 is obtained as shown in Fig. 2. In this study, we proposed a CNNs architecture consisting of two separated convolution layers according to ERPs and ITPC spectrograms which are concatenated to the classification part to predict a different class as shown in Fig. 3.

To extract a feature, we use standard 2D convolution layers comprising 2D convolution filters with activation function as a rectified linear unit (ReLU) and sub-sampling to reduce the dimension of the feature following with a fully connected layer to arrange all 2D convolution features in the single dimensionality before training into a classifier in the next layers. The loss function utilizes a binary cross-entropy to obtain an error of binary classes and tuning with RMSprop optimizer with 5e-5 learning rate as shown in Table 1.

Table 1 Concatenate CNNs configuration

Layer	Layer units/Kernel Size		Output Size
	CNNs (ERPs)	CNNs (ITPC)	
Input layer	64x200x200x3	64x200x200x3	64x200x200x3
Convolution	32/3x3	32/3x3	64x198x198x32
Convolution	64/3x3	64/3x3	64x198x198x64
Maxpool	-2x2	-2x2	64x98x98x64
Flatten 2D	-	-	64x614656
Dense layer	128/-	128/-	64x128
Concatenate	-	-	64x256
Flatten 1D	fully connected	-	16384
Dense layer	128/-	-	128
Dense layer	32/-	-	32
Prediction layer	1	-	-

4. Results and Discussion

In the assessment of concatenated CNNs that we proposed, firstly a graph is performed an accuracy and loss trend; this is completely performs trends that should be in a training of deep learning. As we observe in a loss trend in Fig. 4, it is immediately overfitting around epoch 19, and after evaluating the model with a testing set, it receives an accuracy of 91.33% with a 0.317 test loss value.




Fig. 4 Accuracy and loss of concatenate CNNs model

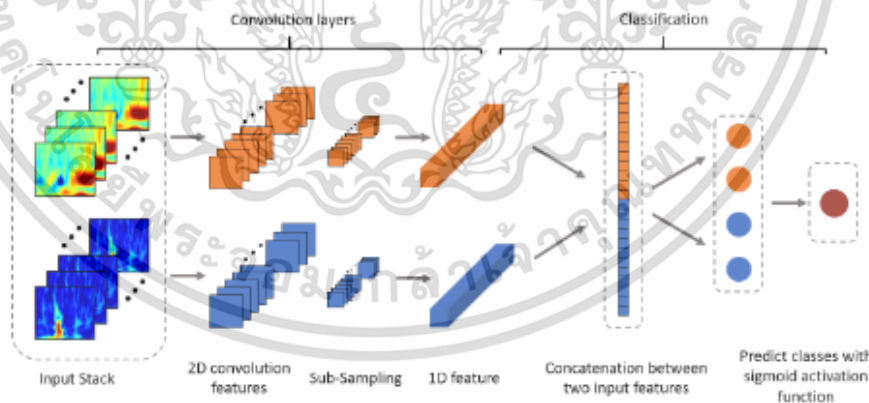


Fig.3 Workflow of Concatenate CNN model

BE-4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

the amplitude power and phase with the substantial interference of low-frequency noise in the feedback activity. However, many of the evidence show an analysis relies on the psychological statistics term for excludes a patient out of the control group by observing a response of theta power [9]. Using a machine learning to predict abnormality of EEG signal around the Prefrontal cortex region that is center of consciousness activity with conducting handcrafted feature as "Shannon Entropy," [10]. Accordingly, both of those methods require robust techniques for observing a feature from the EEG signal. Finally, we suggest the concatenation of CNN for detecting a symptom in depression disorder without using complex knowledge about the disease.

Convolution Neural Networks (CNNs) is currently an on-trend method for an image and video classification task. Structure of CNNs has comprised two-parts 1) feature extraction layers and 2) classification layers, so an advantage of CNNs is using a convolution filter to extract features from input data and compress features with partial connection for the next classification layer for learning feature in a specific problem. It has considerable evidence about the performance of CNNs in neuroscience fields [11] that substantiate whether CNNs are often successful in performance than the traditional machine learning that uses a handcrafted feature extraction part separated with a classification part. To perform representation of the EEG signals in the 2D images for the CNNs [12], it needs a method for transformation; therefore, morlet wavelet transformation is an implementation tool that is used to convert raw EEG data, especially ERPs data, to become an image to use as input stack in multi-layers CNNs to develop a classification model that can diagnose a depression symptom. To obtain better accuracy more than previous literatures we propose a multi-input stack that uses ERPs and ITPC spectrograms.

2. Materials

2.1 Dataset

This dataset is provided by "Cognitive Rhythms and Computation Labs [13]." Raw EEG signals were recorded from 121 participants containing the control group and depressed group and had consent in the experiment. EEG signal was measured by using 64 Ag/AgCl electrodes with Synamps2 system (500Hz Sampling rate, bandpass filter 0.5-100, impedances<10 kΩ). The main criteria that is used for separating participants into two groups are based on the beck depression inventory (BDI). Hence, the control group (N=75, 40 female) had stationary low BDI (<7) with no self-reported history of depression and no self-reported indicating in the possibility of Axis I disorder. The depressed group (N=46, 34 female) had stationary high BDI(>13), also required to engage criteria Structured Clinical Interview for the DSM-IV, and BDI indicating no difference between current or past MDD group so it capability of combining in a single group.

2.2 Data Preprocessing

Pre-processing of EEG signal initiated by an EEGLAB software [14] in Matlab toolbox for Re-references an electrode to mastoids. Bandpass filtered operates in frequency from 0.5 Hz to 50 Hz to eliminate an electrical noise from the powerline and high-frequency noise. Continuous EEG data are extracted in an epoch time for trials. The baseline is correcting at power magnitude from -300 to -200 ms before a stimulus for generating an ERPs and ITPC. Finally, significant artifacts were removed from the signal such as eye movement in a vertical and horizontal axis by Independent Components Analysis (ICA) and is also removed a bad trial in each electrode's channel.

3. Methods

3.1 Time-Frequency Analysis

To perform ERPs and ITPC in the form of a spectrogram image, we propose a complex morlet wavelet transformation (CMW) that calculates an EEG features in the time domain into the time-frequency domain. The process is multiplying a single trial of EEG with the CMW in the frequency domain and using the fast Fourier transform (FFT) to extract a distribution of the power spectrum in each time and frequency. The CMW algorithm is conducted by a Matlab custom equation [15, 16] between Complex sine wave and Gaussian-windowed: $e^{-i2\pi t f} e^{-t^2/(2\sigma^2)}$ while t is time, f is frequency in logarithmically spaced that frequency is change from 1 to 45 Hz, with the width of each frequency band from 3 to 10. Hence to compare a spectrogram image across the subject, a magnitude power was converted by Baseline Normalization in decibel scale (dB) at an average baseline from -300 to -200 ms pre-stimuli as shown in Fig. 1(a). In term of ITPC, it is an average in the distribution of vector phase angles at each time-frequency epoch as shown in Fig. 1(c) and Fig. 1(d), and we employ the same concept as ERPs to convert them into time-frequency spectrogram as shown in Fig. 1(b).




Fig. 1 Characteristic of EEG features in expression of time-frequency spectrogram

BE-4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

