

การตรวจพบคลื่นไฟฟ้าสมองของโรคลมชักด้วยการใช้
GMM, KELM และ LS-SVM



นายกษิต กกขุนทด

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์

มหาวิทยาลัยเทคโนโลยีสุรนารี

ปีการศึกษา 2563

ELECTROENCEPHALOGRAM SEIZURE DETECTION USING GMM, KELM AND LS-SVM

Kasidit Kokkhunthod



**A Thesis Submitted in Partial Fulfillment of the Requirements for
the Degree of Master of Engineering
in Telecommunication and Computer Engineering
Suranaree University of Technology
Academic Year 2020**

การตรวจพบคลื่นไฟฟ้าสมองของโรคลมชักด้วยการใช้ GMM, KELM และ LS-SVM

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักศึกษานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร.ปิยากรณ์ มีสวัสดิ์)

ประธานกรรมการ



(รศ. ดร.พีระพงษ์ อุฑารสกุล)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(ผศ. ดร.คมเดช ภาพัฒน์บุรี)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม)



(ผศ. ดร.เสริญวิทย์ ภูญาษา)

กรรมการ



(ผศ. ดร.อภิญา คีค่ายคำ)

กรรมการ



(รศ. ร.อ. ดร.กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและ

พัฒนาความเป็นสากล



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

กษิตศ กนกนท : การตรวจพบคลื่นไฟฟ้าสมองของโรคลมชักด้วยการใช้ GMM, KELM และ LS-SVM (ELECTROENCEPHALOGRAM SEIZURE DETECTION USING GMM, KELM AND LS-SVM) อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.พีระพงษ์ อุทาสกุล,
96 หน้า

โรคลมชักเป็นโรกระบบประสาทเรื้อรังที่พบได้บ่อยในประเทศไทย ถือว่าโรคนี้กำลังเป็นภัยเงียบที่สามารถเกิดได้กับทุกเพศทุกวัย การตรวจวินิจฉัยอาการชักนี้ได้จากการตรวจคลื่นไฟฟ้าสมอง เพื่อใช้ระบุชนิดของอาการชัก คลื่นไฟฟ้าสมองของมนุษย์ สามารถนำมาประยุกต์ใช้เพื่อพัฒนาทางด้านเทคโนโลยีปัจจุบันในหลายด้าน ซึ่งได้มีการนำคลื่นไฟฟ้าสมองไปใช้ในการวิเคราะห์ เพื่อใช้ร่วมกับการวินิจฉัยโรคของผู้ป่วย โดยทั่วไปสัญญาณคลื่นไฟฟ้าสมองจะต้องใช้เครื่องมือที่เป็นมาตรฐานทางการแพทย์ในการจัดเก็บสัญญาณ หลังจากนั้นนำไปให้แพทย์ที่มีความเชี่ยวชาญในการวินิจฉัย ว่าผู้ป่วยที่มีลักษณะของสัญญาณไฟฟ้าสมองที่เป็นปกติหรือผิดปกติอย่างไร แต่ก็ขึ้นอยู่กับลักษณะของคลื่นไฟฟ้าสมองว่ามีความชัดเจนมากน้อยแค่ไหนหรือแม้แต่นาฬิกาของสัญญาณมีระยะเวลาที่ทำการบันทึกว่ายาวนานแค่ไหน เพราะฉะนั้นในการวินิจฉัยจึงจำเป็นต้องใช้เวลาในการพิจารณา ที่ค่อนข้างยาวนาน ในการตรวจหาลักษณะของสัญญาณนั้นมีความผิดปกติเกิดขึ้น ในปัจจุบันเทคนิคการเรียนรู้บนระบบคอมพิวเตอร์เพื่อจำแนกลักษณะที่แตกต่าง ได้รับการประยุกต์ใช้ให้มีความสามารถในการวิเคราะห์สัญญาณคลื่นไฟฟ้าสมอง วิทยานิพนธ์ฉบับนี้นำเสนอ การนำคลื่นไฟฟ้าสมองที่เป็นมาตรฐานสากลและได้จากการบันทึกผ่านเครื่องมือที่เป็นมาตรฐาน มาทำการวิเคราะห์ด้วยการเรียนรู้ของเครื่อง เพื่อระบุรูปแบบลักษณะที่เป็นความผิดปกติ ซึ่งจะเป็นการประยุกต์ใช้ระบบในการวิเคราะห์ให้สามารถแยกแยะลักษณะสัญญาณคลื่นไฟฟ้าสมองที่มีอาการชัก โดยทำการเปรียบเทียบระหว่างการใช้วิธีการจำแนกที่แตกต่างกันในทดสอบหาความถูกต้อง และใช้เป็นแนวทางในการวิจัยงานที่เกี่ยวข้องกับการจำแนกคลื่นไฟฟ้าสมอง

สาขาวิชา วิศวกรรมโทรคมนาคม
ปีการศึกษา 2563

ลายมือชื่อนักศึกษา กษิตศ กนกนท
ลายมือชื่ออาจารย์ที่ปรึกษา ดร.พีระพงษ์ อุทาสกุล
ลายมือชื่ออาจารย์ที่ปรึกษาร่วม ดร.ปิยะเดช

KASIDIT KOKKHUNTHOD : ELECTROENCEPHALOGRAM SEIZURE
DETECTION USING GMM, KELM AND LS-SVM. THESIS ADVISOR :
ASSOC. PROF. PEERAPONG UTHANSAKUL, Ph.D., 96 PP.

EEG/MACHINE LEARNING/FEATURE EXTRACTION/STATISTICAL
TQWT/GMM/KLEM/LS-SVM

Epilepsy is a chronic neurological disease that is common in Thailand. This disease is considered a silent threat that can occur in all genders and ages. The diagnosis of seizures is based on electrocardiograms to identify the type of seizure human brain waves. It can be applied to the development of current technology in many areas. Which has been leading the brain waves to be used for analysis to be used in conjunction with the diagnosis of the patient. EEG signals require standard medical equipment to store the signal. After that, take it to a doctor who specializes in diagnosis. The patients with characteristics of normal or abnormal brain electrical signals it depends on the nature of the EEG that is very experienced and size of the signal how long the recording time. Therefore, in the diagnosis it is necessary to take time to consider relatively long in detecting the nature of the signal an abnormality occurred. At present, computer-based learning techniques to identify different traits. It has been applied to have the ability to analyze EEG signals. This thesis presents the conduction of EEG is of international standard and recorded through standard instruments, it is analyzed by machine learning. To identify the characteristic pattern that is anomaly, it will be the application of the system in the analysis to be able to distinguish the characteristics of EEG signals with seizures. The Comparisons were made between

the use of different classification methods in the validation test and used as a guide for research work related to the classification of EEG.



School of Telecommunication Engineering

Academic year 2020

Student's Signature กิตติกร มานะนา

Advisor's Signature ดร. อ. อ.

Asst. Advisor's Signature ดร. อ. อ.

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดี เนื่องจากได้รับความช่วยเหลืออย่างยิ่ง ทั้งด้านวิชาการ และด้านการดำเนินงานวิจัย จากบุคคลและกลุ่มบุคคลต่าง ๆ ได้แก่

รองศาสตราจารย์ ดร.พีระพงษ์ อุทธารสกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ และ ผู้ช่วยศาสตราจารย์ ดร.คมเดช ภาพัฒน์บุรี ที่ให้โอกาสทางการศึกษา ให้คำแนะนำและอนุเคราะห์ ให้คำปรึกษา ช่วยแก้ปัญหาและให้กำลังใจแก่ผู้วิจัยมาโดยตลอด รวมทั้งช่วยตรวจทานและแก้ไข วิทยานิพนธ์เล่มนี้จนเสร็จสมบูรณ์

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์เล่มนี้ ผู้วิจัยขอมอบให้กับบิดา มารดา ซึ่งเป็นที่รักและเคารพยิ่ง ตลอดจนคณะครูอาจารย์ที่เคารพทุกท่าน ที่ได้ประสิทธิ์ประสาทวิชา ความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ผู้วิจัยตลอดมา จนทำให้ประสบความสำเร็จในชีวิต

อีกทั้งขอขอบคุณเพื่อน พี่ ที่ให้การสนับสนุนและช่วยเหลือด้วยดีเสมอมา และขอขอบคุณ เจ้าของเอกสารและงานวิจัยทุกท่าน ที่ผู้วิจัยได้นำมาอ้างอิงในการทำวิจัย จนกระทั่งงานวิจัยฉบับนี้ สำเร็จลุล่วงไปได้ด้วยดี และขอบคุณตัวเองที่ได้ทำวิทยานิพนธ์เล่มนี้จนเสร็จสมบูรณ์

สุดท้ายนี้ผู้วิจัยหวังว่าวิทยานิพนธ์ฉบับนี้จะมีส่วนในการแก้ไขปัญหา พัฒนาและเป็น ประโยชน์ต่องานวิจัยที่เกี่ยวข้อง ไม่นานก็น้อย หากมีข้อบกพร่องประการใดผู้วิจัยก็ขออภัยไว้ ณ ที่นี้

กษิตศ กนกุนทด

มหาวิทยาลัยเทคโนโลยีสุรนารี

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ง
สารบัญ.....	จ
สารบัญตาราง	ช
สารบัญรูป	ซ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตของการวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	2
1.5 วิธีดำเนินการวิจัย	2
2 ปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	3
2.1 กล่าวนำ.....	3
2.2 ความหมายและคุณสมบัติของคลื่นไฟฟ้าสมอง.....	4
2.3 อาการของภาวะชัก.....	7
2.4 ระบบการทำงานของการเรียนรู้ของเครื่อง.....	11
2.5 เทคนิคการสกัดและจำแนกสัญญาณคลื่นไฟฟ้าสมอง	11
2.6 การทบทวนวรรณกรรม/สารสนเทศ (Information) ที่เกี่ยวข้อง	14
2.7 สรุป.....	18
3 ระเบียบวิธีวิจัย.....	19
3.1 วิธีการดำเนินงาน	19
3.2 การจัดการข้อมูล	19
3.3 การเตรียมสัญญาณ.....	21

สารบัญ (ต่อ)

หน้า

3.4	กระบวนการสกัดคุณลักษณะเด่นของสัญญาณ.....	28
3.5	การสร้างแบบจำลองข้อมูล (Model Training)	35
3.6	การแบ่งชุดข้อมูลสำหรับสร้างโมเดลฝึกฝนและทดสอบ	38
3.7	กระบวนการทดสอบ.....	39
3.8	สรุปท้ายบท.....	42
4	ผลการศึกษา และการวิเคราะห์ผล.....	43
4.1	บทนำ.....	43
4.2	ผลการจัดชุดข้อมูลก่อนนำไปเข้ากระบวนการสกัดคุณลักษณะเด่น	44
4.3	ผลสรุปขั้นตอนการสกัดคุณลักษณะเด่นของสัญญาณคลื่นไฟฟ้าสมอง	47
4.4	ผลการเก็บค่าเมื่อผ่านการสกัดคุณลักษณะเด่น	50
4.5	ผลการสร้างโมเดลการฝึกสอนจากชนิดของตัวจำแนก.....	52
4.6	ผลทดสอบการจำแนกสัญญาณคลื่นไฟฟ้าสมอง	55
4.6.1	ผลการทดสอบด้วยเทคนิค GMM	56
4.6.2	ผลการทดสอบด้วยเทคนิค KELM.....	59
4.6.3	ผลการทดสอบด้วยเทคนิค LS-SVM	61
4.7	สรุปท้ายบท.....	63
5	สรุปเนื้อหาวิทยานิพนธ์และข้อเสนอแนะในการวิจัย.....	64
5.1	สรุปผลงานวิจัย	64
5.2	สรุปเนื้อหาวิทยานิพนธ์	65
5.3	ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต.....	65
	รายการอ้างอิง	66
	ภาคผนวก	
	ภาคผนวก ก.....	68
	ภาคผนวก ข.....	72
	ประวัติผู้เขียน	97

สารบัญตาราง

ตารางที่		หน้า
2.1	คลื่นไฟฟ้าบนร่างกายมนุษย์	7
2.2	อาการนำก่อนการชัก	8
2.2	อาการนำก่อนการชัก (ต่อ).....	9
2.3	รายละเอียดของอาการชักและอาการอื่นๆ ที่เกิดร่วม	9
4.1	ผลความถูกต้องแถบย่อยชั้นที่ 1 จากการจำแนกด้วย GMM	57
4.2	ผลความถูกต้องแถบย่อยชั้นที่ 2 จากการจำแนกด้วย GMM	57
4.3	ผลความถูกต้องแถบย่อยชั้นที่ 3 จากการจำแนกด้วย GMM	57
4.4	ผลความถูกต้องแถบย่อยชั้นที่ 4 จากการจำแนกด้วย GMM	58
4.5	ผลความถูกต้องแถบย่อยชั้นที่ 5 จากการจำแนกด้วย GMM	58
4.6	ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย GMM	58
4.7	ผลความถูกต้องแถบย่อยชั้นที่ 1 จากการจำแนกด้วย KELM	59
4.8	ผลความถูกต้องแถบย่อยชั้นที่ 2 จากการจำแนกด้วย KELM	59
4.9	ผลความถูกต้องแถบย่อยชั้นที่ 3 จากการจำแนกด้วย KELM	59
4.10	ผลความถูกต้องแถบย่อยชั้นที่ 4 จากการจำแนกด้วย KELM	60
4.11	ผลความถูกต้องแถบย่อยชั้นที่ 5 จากการจำแนกด้วย KELM	60
4.12	ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย KELM	60
4.13	ผลความถูกต้องแถบย่อยชั้นที่ 1 จากการจำแนกด้วย LS-SVM	61
4.14	ผลความถูกต้องแถบย่อยชั้นที่ 2 จากการจำแนกด้วย LS-SVM	61
4.15	ผลความถูกต้องแถบย่อยชั้นที่ 3 จากการจำแนกด้วย LS-SVM	62
4.16	ผลความถูกต้องแถบย่อยชั้นที่ 4 จากการจำแนกด้วย LS-SVM	62
4.17	ผลความถูกต้องแถบย่อยชั้นที่ 5 จากการจำแนกด้วย LS-SVM	62
4.18	ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย LS-SVM	63

สารบัญรูป

รูปที่

หน้า

2.1	คลื่นเดลต้า (Delta Wave)	4
2.2	คลื่นเซต้า (Theta Wave)	5
2.3	คลื่นอัลฟา (Alpha wave).....	5
2.4	คลื่นมู (Mu Wave).....	6
2.5	คลื่นเบต้า (Beta Wave).....	6
2.6	คลื่นแกมมา (Gamma Wave).....	7
2.7	TWQT สลายสัญญาณ EEG อินพุต	12
3.1	ไฟล์ชุดข้อมูล 24 กรณี 24 โพลเคอร์.....	20
3.2	ข้อมูลเฉพาะของแต่ละกรณี.....	21
3.3	จัดกลุ่มชุดข้อมูลให้อยู่ในโพลเคอร์เดียวกัน	22
3.4	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ.....	22
3.5	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก	23
3.6	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองช่วงปกติ	24
3.7	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองช่วงที่มีการชัก.....	24
3.8	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....	25
3.9	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....	25
3.10	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติก่อนการชัก.....	26
3.11	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติขณะการชัก.....	26
3.12	ตำแหน่งของการบันทึกคลื่นไฟฟ้าสมอง.....	27
3.13	การสลายตัวระดับ J โดยใช้ TQWT.....	28
3.14	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....	30
3.15	ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ปกติในช่องสัญญาณที่ 1	30
3.16	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....	31

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.17	ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติในช่องสัญญาณที่ 131
3.18	รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่น33
3.19	รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่นโดยการหาค่าทางสถิติ 5 แบบของไฟล์สัญญาณปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....34
3.20	รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่นโดยการหาค่าทางสถิติ 5 แบบของไฟล์สัญญาณผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์.....34
3.21	ภาพแสดงการหาค่าน้ำหนักใน KELM.....37
3.22	รูปแบบการจัดชุดข้อมูลด้วยวิธี K-Fold Cross Validation38
3.23	การจัดข้อมูลสำหรับงานวิจัยนี้มี 24 กรณี39
3.24	แสดงชุดข้อมูลที่ใช้ฝึกสอนและทดสอบ40
3.25	เมทริกซ์วัดประสิทธิภาพ41
4.1	ไฟล์ข้อมูลกรณีที่ 145
4.2	จัดกลุ่มชุดข้อมูลให้อยู่ในโฟลเดอร์เดียวกัน45
4.3	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ.....46
4.4	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก.....46
4.5	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติในหนึ่งไฟล์.....48
4.6	ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ปกติในหนึ่งไฟล์.....48
4.7	ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติในหนึ่งไฟล์.....49
4.8	ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติในหนึ่งไฟล์.....51
4.9	ข้อมูลการสกัดคุณลักษณะเด่น โดยการหาค่าทางสถิติ 6 แบบของไฟล์สัญญาณ ปกติ51
4.10	ข้อมูลการสกัดคุณลักษณะเด่น โดยการหาค่าทางสถิติ 6 แบบของไฟล์สัญญาณ ผิดปกติ49
4.11	ข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย GMM จัดเก็บในสกุลไฟล์ .mat52
4.12	ตัวอย่างข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย KELM53
4.13	ข้อมูลค่าน้ำหนักสำหรับฝึกสอนด้วย KELM จากสัญญาณปกติ.....53
4.14	ข้อมูลค่าน้ำหนักสำหรับฝึกสอนด้วย KELM จากสัญญาณผิดปกติ54

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.15	ข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย LS-SVM.....54
4.16	ข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย LS-SVM.....55
4.17	การจัดข้อมูลสำหรับทดสอบการจำแนกทั้ง 24 กรณี56
ก.1	ไฟล์ชุดข้อมูล 24 กรณี 24 โฟลเดอร์70
ก.2	ข้อมูลเฉพาะของแต่ละกรณี70
ก.3	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ71
ก.4	ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก71



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

โรคลมชักเป็นโรกระบบประสาทเรื้อรังที่พบได้บ่อยในประเทศไทย ในประเทศไทย ประมาณการผู้ป่วยโรคลมชัก 500,000 คน ถือว่าโรคนี้กำลังเป็นภัยเงียบที่สามารถเกิดได้กับทุกเพศ ทุกวัย ซึ่งมีอาการเบลอ เหม่อลอย ตาค้าง วูบป๋อย โดยอาการเหล่านี้ไม่ควรมองข้าม เนื่องจากเสี่ยงต่อการเกิดโรคลมชัก ซึ่งการตรวจวินิจฉัยอาการชักนี้จะได้การตรวจคลื่นไฟฟ้าสมอง เพื่อใช้ระบุ ชนิดของอาการชัก คลื่นไฟฟ้าสมองของมนุษย์ สามารถนำมาประยุกต์ใช้เพื่อพัฒนาทางด้าน เทคโนโลยีปัจจุบันในหลายด้าน ซึ่งได้มีการนำคลื่นไฟฟ้าสมอง ไปใช้ในการวิเคราะห์ เพื่อใช้ ร่วมกับการวินิจฉัยโรคของผู้ป่วย เช่น ผู้ป่วยที่สงสัยภาวะชัก ช่วยวินิจฉัยพร้อมวางแผนในผู้ป่วยที่มีความผิดปกติที่เกี่ยวกับการนอน และ ช่วยในการเลือกยากันชักที่เหมาะสมกับผู้ป่วย เป็นต้น

โดยทั่วไปสัญญาณคลื่นไฟฟ้าสมองจะต้องใช้เครื่องมือที่เป็นมาตรฐานทางการแพทย์ในการจัดเก็บสัญญาณ หลังจากนั้นนำไปให้แพทย์ที่มีความเชี่ยวชาญในการวินิจฉัย ว่าผู้ป่วยที่มี ลักษณะของสัญญาณไฟฟ้าสมองที่เป็นปกติหรือผิดปกติอย่างไร แต่ก็ขึ้นอยู่กับลักษณะของ คลื่นไฟฟ้าสมองว่ามีความชัดเจนมากน้อยแค่ไหน หรือแม้แต่นาฬิกาของสัญญาณมีระยะเวลาที่ทำการบันทึกว่ายาวนานแค่ไหน เพราะฉะนั้นในการวินิจฉัยจึงจำเป็นต้องใช้เวลาในการพิจารณา ที่ค่อนข้างยาวนาน ในการตรวจหาลักษณะของสัญญาณนั้นมีความผิดปกติเกิดขึ้น ในปัจจุบัน เทคนิคการเรียนรู้บนระบบคอมพิวเตอร์เพื่อจำแนกลักษณะที่แตกต่าง ได้รับการประยุกต์ใช้ ให้มีความสามารถในการวิเคราะห์สัญญาณคลื่นไฟฟ้าสมอง การศึกษานี้จะนำเอาคลื่นไฟฟ้าสมองที่เป็นมาตรฐานสากลและได้จากการบันทึกผ่านเครื่องมือที่เป็นมาตรฐาน มาทำการวิเคราะห์ด้วยการ เรียนรู้ของเครื่อง เพื่อระบุรูปแบบลักษณะที่เป็นความผิดปกติ ซึ่งจะเป็นการประยุกต์ใช้ระบบ ในการวิเคราะห์ให้สามารถแยกแยะลักษณะสัญญาณคลื่นไฟฟ้าสมองที่มีอาการชัก โดยทำการ เปรียบเทียบระหว่างการใช้ในการแยกแยะ 3 ชนิด ที่แตกต่างกันในทดสอบหาความถูกต้อง

สำหรับงานวิจัยในวิทยานิพนธ์ฉบับนี้ นำเสนอการประยุกต์ใช้การเรียนรู้ของเครื่อง เพื่อใช้ ในการจำแนกลักษณะเด่นที่แตกต่าง ระหว่างสัญญาณคลื่นไฟฟ้าสมองที่ปกติกับสัญญาณ คลื่นไฟฟ้าสมองที่เกิดการชัก และทำการเปรียบเทียบเทคนิคการจำแนกสัญญาณ เพื่อทดสอบ ความสามารถในการสกัดคุณลักษณะเด่นและการจำแนกของสัญญาณ

1.2 วัตถุประสงค์

- 1.2.1 นำชุดข้อมูลคลื่นไฟฟ้าสมองมาใช้ในการวิเคราะห์ลักษณะของสัญญาณอาการชัก เพื่อใช้จำแนกลักษณะระหว่างอาการปกติและอาการชัก
- 1.2.2 ทดสอบอัลกอริทึมที่มีความสามารถในการจำแนกลักษณะสัญญาณของอาการชัก
- 1.2.3 เปรียบเทียบประสิทธิภาพอัลกอริทึมที่มีความสามารถในการจำแนกลักษณะสัญญาณของอาการชัก

1.3 ขอบเขตของการวิจัย

- 1.3.1 ศึกษาองค์ประกอบชุดข้อมูลคลื่นไฟฟ้าสมอง ที่มีมาตรฐานสำหรับใช้ในการวิเคราะห์จำแนก ลักษณะของสัญญาณที่เป็นอาการชัก
- 1.3.2 ประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning) มากกว่า 1 ชนิด
- 1.3.3 เปรียบเทียบประสิทธิภาพที่ใช้ในการจำแนกลักษณะของคลื่นไฟฟ้าสมอง ด้วยการประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning)

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1.4.1 ผลการเปรียบเทียบประสิทธิภาพที่ใช้ในการจำแนกลักษณะของคลื่นไฟฟ้าสมอง ด้วยการประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning)
- 1.4.2 จำแนกลักษณะสัญญาณคลื่นไฟฟ้าสมองที่เกิดภาวะการชักได้ถูกต้องแม่นยำ

1.5 วิธีดำเนินการวิจัย

- 1.5.1 สำนักรวพรรณวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์
- 1.5.2 ศึกษาลักษณะและตำแหน่งของบริเวณที่เกี่ยวข้องกับคลื่นไฟฟ้าสมอง
- 1.5.3 ศึกษาการใช้ระบบการเรียนรู้ของเครื่อง (Machine Learning)
- 1.5.4 ประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning)
- 1.5.5 เปรียบเทียบประสิทธิภาพที่ใช้ในการจำแนกลักษณะของคลื่นไฟฟ้าสมอง ด้วยการประยุกต์ใช้การเรียนรู้ของเครื่อง (Machine Learning)

บทที่ 2

ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.1 กล่าวนำ

ความผิดปกติทางระบบประสาทมีมากมายหลายชนิด การชักประวัติดและการตรวจร่างกาย บางครั้งไม่สามารถให้การ วินิจฉัยโรคที่แน่นอนได้ จำเป็นต้องอาศัยการตรวจพิเศษเพิ่มเติม เพื่อให้ การวินิจฉัยถูกต้องมากยิ่งขึ้น การตรวจคลื่นไฟฟ้าสมอง เป็นการตรวจพิเศษทางประสาทวิทยาชนิด หนึ่งที่สามารถบอก ตำแหน่งและลักษณะของพยาธิสภาพของสมอง ซึ่งเป็นสาเหตุ ของความ ผิดปกติทางระบบประสาทได้อย่างดี การตรวจคลื่น ไฟฟ้าสมองจำเป็นต้องเตรียมผู้ป่วยก่อนการ ตรวจ พยาบาลเป็น บุคลากรทางการแพทย์ที่สำคัญที่มีบทบาทในการเตรียมและ ให้คำแนะนำ แก่ ผู้ป่วยก่อนการตรวจคลื่นไฟฟ้าสมอง ดังนั้น จึงต้องมีความรู้พื้นฐานเกี่ยวกับการตรวจคลื่นไฟฟ้า สมองเป็นอย่างดี จึงจะสามารถให้คำแนะนำแก่ผู้ป่วยและญาติได้อย่างถูกต้อง บทความนี้ มีวัตถุประสงค์เพื่อกล่าวถึงความรู้พื้นฐาน ในการตรวจ คลื่นไฟฟ้าสมองสำหรับพยาบาล ได้แก่ ประวัติและความเป็นมา ของคลื่นไฟฟ้าสมอง แหล่งที่มาและชนิดของคลื่นไฟฟ้าสมอง ประโยชน์ ของการตรวจเครื่องตรวจคลื่นไฟฟ้าสมอง การเตรียมตัว สำหรับการตรวจคลื่นไฟฟ้าสมอง ขั้นตอน ของการตรวจคลื่นไฟฟ้า สมองโดยใช้ขั้วไฟฟ้าชนิดที่วางบนหนังศีรษะ ลักษณะคลื่นไฟฟ้า สมอง ปกติและที่ผิดปกติ และความเสี่ยงของการตรวจคลื่น ไฟฟ้าสมอง

การตรวจคลื่นไฟฟ้าสมอง (Electroencephalography: EEG) ของมนุษย์สามารถนำมา ประยุกต์ใช้เพื่อนำข้อมูลคลื่นไฟฟ้าสมองมาช่วยร่วมในการวินิจฉัยโรคทางสมองบางประเภท เพื่อเฝ้าติดตามอาการของโรคที่อาจร้ายแรงต่อผู้ป่วย ปัจจุบันคลื่นไฟฟ้าสมอง มีบทบาทในการ วินิจฉัยอาการของโรคลมชัก โดยการให้ผู้ป่วยเข้ารับการตรวจคลื่นไฟฟ้าสมอง ด้วยการบันทึก สัญญาณซึ่งจะใช้เวลาในการทำการบันทึกหลายชั่วโมง เพื่อเฝ้าติดตามว่าอาการชักจะเกิดขึ้นหรือไม่ และเมื่อทำการบันทึกเสร็จเรียบร้อยแล้ว แพทย์จะนำสัญญาณที่ได้ไปตรวจสอบหาลักษณะของ ความผิดปกติ ซึ่งในงานวิจัยนี้ศึกษาเกี่ยวกับการจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เป็น ปกติและผิดปกติที่เกิดจากอาการชักของคลื่นไฟฟ้าสมอง ในบทนี้จะกล่าวถึงทฤษฎีที่เกี่ยวข้อง กับการพัฒนาระบบอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning)


2.2 ความหมายและคุณสมบัติของคลื่นไฟฟ้าสมอง

บนร่างกายมนุษย์มีการเคลื่อนไหวเริ่มต้นเกิดมาจากการนึกคิดก่อนที่จะมีการเคลื่อนไหวมาจากสมองสั่งการ ซึ่งมีคลื่นไฟฟ้าที่ช่วยในการสั่งการการเคลื่อนไหวที่ผ่านไปยังเส้นประสาทตามบริเวณต่างๆบนร่างกายจากนั้นก็เกิดการกระตุ้นเพื่อทำให้กล้ามเนื้อทำงานหรือเคลื่อนไหว หากต้องการทราบการเคลื่อนไหวของร่างกายมนุษย์ สิ่งที่น่าสนใจในการศึกษาการเคลื่อนไหวคือ คลื่นไฟฟ้าบนตัวมนุษย์มีดังนี้

2.2.1 คลื่นไฟฟ้าสมอง (Electroencephalogram)


คลื่นสมองเป็นการตรวจจับความต่างศักย์ไฟฟ้าที่ผิวหนังบริเวณศีรษะ ความต่างศักย์นี้เกิดจากการทำงานด้วยการส่งสัญญาณไฟฟ้าระหว่างกันของเซลล์ประสาทจำนวนมากในสมองส่วนที่ใกล้กับขั้วไฟฟ้าที่เราใช้ในการวัด คลื่นสมองนี้สามารถนำมาใช้ประโยชน์ได้ทั้งทางการแพทย์และการวิจัย ในปัจจุบันยังได้มีการประยุกต์นำคลื่นสมองนี้มาใช้สั่งการอุปกรณ์อิเล็กทรอนิกส์ต่าง ๆ ได้ด้วย คลื่นสมองสามารถแบ่งเป็น 6 ประเภท ตามความถี่ของคลื่นได้ดังนี้ (Niedermeyer et al., 2004)

1. คลื่นเดลต้า (Delta wave) มีความถี่อยู่ในช่วง 0-4 เฮิรตซ์ คลื่นประเภทนี้จะปรากฏในขณะที่เราหลับลึก หรือที่เรียกว่า การนอนในช่วง Non-rapid eye movement ในขั้นที่ 3 และ 4 การหลับลึกจึงมีอีกชื่อหนึ่งว่า Slow-wave sleep




รูปที่ 2.1 คลื่นเดลต้า (Delta Wave)

2. คลื่นเซต้า (Theta wave) มีความถี่อยู่ในช่วง 4 - 7 เฮิรตซ์ จะพบคลื่นสมองประเภทนี้มากในเด็กเล็ก สำหรับในเด็กโตและวัยรุ่นผู้ใหญ่ คลื่นสมองชนิดนี้จะปรากฏเมื่อกำลังมีสมาธิครึ่งหลับครึ่งตื่น หรือในการนอนหลับที่ไม่ใช่การหลับลึกและการทำสมาธิอย่างลึก นอกจากนี้การเพิ่มขึ้นของคลื่นเซต่ายังเกี่ยวข้องกับการตอบสนองต่อการทำงานของหน่วยความจำสมอง




รูปที่ 2.2 คลื่นเซต้า (Theta Wave)

3. คลื่นอัลฟา (Alpha wave) มีความถี่อยู่ในช่วง 7.5 – 12.5 เฮิรตซ์ พบที่สมองส่วนที่เกี่ยวข้องกับการมองเห็น และจะเกิดเมื่อมีการผ่อนคลายด้วยการหลับตา และคลื่นสมองชนิดนี้จะลดลงเมื่อลืมตาหรือนอนหลับ




รูปที่ 2.3 คลื่นอัลฟา (Alpha Wave)

4. คลื่นมู (Mu wave) อยู่ในช่วงความถี่เดียวกับ คลื่นอัลฟา (Alpha wave) แต่พบที่สมองคนละส่วน โดย คลื่นมู (Mu wave) จะพบในสมองที่ควบคุมการเคลื่อนไหว และจะเด่นชัดเมื่อร่างกายไม่มีการเคลื่อนไหว และจะหายไปเมื่อมีการเคลื่อนไหวร่างกายหรือจินตนาการว่าตนเองกำลังเคลื่อนไหวร่างกาย และยังรวมถึงเมื่อกำลังมองผู้อื่นเคลื่อนไหวร่างกายอีกด้วย




รูปที่ 2.4 คลื่นมู (Mu wave)

5. คลื่นเบต้า (Beta wave) มีความถี่อยู่ในช่วง 12.5 – 30 เฮิร์ตซ์ พบได้ในขณะที่มีสติสัมปชัญญะตามปกติโดยเกี่ยวข้องกับการใช้ความคิด การใช้ความสนใจ การมุ่งเน้นไปที่บางสิ่งบางอย่างจากภายนอก และยังเกี่ยวข้องกับภาวะจิตใจเช่น หากรู้สึกตื่นเต้น ตึงเครียด หรือกลัว ก็อาจส่งผลให้คลื่นเบต้าสูงขึ้นกว่าปกติได้



รูปที่ 2.5 คลื่นเบต้า (Beta Wave)

6. คลื่นแกมมา (Gamma wave) มีความถี่อยู่ในช่วง 25 – 100 เฮิร์ตซ์เกี่ยวข้องกับการประมวลผลทางความคิด การรวบรวมข้อมูลและความเข้าใจอย่างฉับพลัน การมีคลื่นแกมมาในปริมาณที่สูงกว่าคนปกติ จะมีสติปัญญา การแก้ปัญหาและการควบคุมตนเองที่ดี โดยส่วนใหญ่จะสามารถพบได้ในคนที่ฝึกสมาธิขั้นสูง



รูปที่ 2.6 คลื่นแกมมา (Gamma Wave)

ตารางที่ 2.1 คลื่นไฟฟ้าบนร่างกายมนุษย์

คลื่นไฟฟ้า	ย่านแรงดันไฟฟ้า (มิลลิโวลต์)	ย่านความถี่ ตอบสนอง (เฮิรตซ์)
คลื่นไฟฟ้าสมอง EEG (Electroencephalography)	0.001 ถึง 0.10	0.02 ถึง 100
คลื่นไฟฟ้าหัวใจ ECG (Electrocardiogram)	0.02 ถึง 5.0	0.1 ถึง 30
คลื่นไฟฟ้ากล้ามเนื้อ EMG (Electromyography)	0.003 ถึง 5.0	2 ถึง 10,000

2.3 อาการของภาวะชัก

อาการชัก (Seizure) คือ อาการที่เกิดจากภาวะที่มีการเปลี่ยนแปลงอย่างเฉียบพลันของการทำงานของเซลล์สมองโดยมีการปลดปล่อยคลื่นไฟฟ้าที่ผิดปกติ (Epileptiform activity) ออกมาจากเซลล์สมองจำนวนมากพร้อม ๆ กัน จากสมองจุดใดจุดหนึ่งหรือทั้งหมด อาการชักเกิดได้จากหลายสาเหตุ ผู้ป่วยที่มีอาการชักไม่จำเป็นต้องเป็นโรคลมชักเสมอไป แต่อาจเป็นอาการ ชักเพียงครั้งแรกที่เกิดจากปัจจัยกระตุ้น (Provoked seizure) ผู้ป่วยที่มีอาการชักจากความเจ็บป่วยปัจจุบัน เช่น ความผิดปกติทางเมตาบอลิก จากยา หรือใช้สุงในเด็ก โดยที่ไม่ได้มีพยาธิสภาพที่สมองชัดเจน จัดเป็นการชักที่มีปัจจัยชักนำ (Provoked seizure) จึงไม่ถือว่าเป็นโรคลมชัก

ผู้ป่วยส่วนใหญ่ที่สงสัยว่ามีอาการชักมักมาพบแพทย์ในขณะที่ไม่ได้เกิดอาการ ประวัติจากผู้ป่วยหรือผู้ที่เห็นเหตุการณ์จึงเป็นสิ่งที่สำคัญเบื้องต้นในการวินิจฉัยอาการชัก ในกรณีที่ผู้ป่วยไม่รู้สติถ้าผู้เห็นเหตุการณ์บันทึกภาพจากอุปกรณ์ เช่น โทรศัพท์มือถือหรือกล้องวิดีโอ ขณะที่ผู้ป่วยเกิดอาการจะช่วยในการรับรู้ลักษณะอาการชักแก่แพทย์ได้ดียิ่งขึ้น นอกจากนี้ประวัติอื่น ๆ จะช่วยในการวินิจฉัยจำแนกชนิดและสาเหตุของโรคลมชักได้

2.3.1 อาการก่อนชัก (Preictal symptoms)

อาการนำ (Prodromes) อาจเกิดขึ้นเป็นเวลานานหลายนาที่ถึงหลายชั่วโมงก่อนมีอาการชัก และมักเป็นอาการที่ไม่มีลักษณะจำเพาะ เช่น ความรู้สึกไม่ค่อยสบาย กระสับกระส่าย ปวดศีรษะ เป็นต้น อาการเตือน (Aura) เป็นอาการแรกของอาการชัก ซึ่งผู้ป่วยสามารถบอกถึงอาการเหล่านี้ ได้ลักษณะของอาการเตือนแตกต่างกันตามตำแหน่งของสมองที่ก่อให้เกิดอาการชัก อาการเตือนมักจะเป็นในลักษณะรูปแบบเดิม (Stereotype) ผู้ป่วยบางคนมีอาการเตือนหลายแบบ แต่มักเป็นลักษณะซ้ำ ๆ เดิม (pattern) ส่วนมากระยะเวลาอาการเตือนจะไม่นานเกิน 10 นาที ระยะเวลาของอาการเตือนเป็นสิ่งสำคัญซึ่งจะสามารถใช้เป็นแนวทางเพื่อป้องกันการเกิดอุบัติเหตุที่อาจขึ้นได้ในกรณีที่อาการเตือนนั้นอาจจะดำเนินต่อไปจนเกิดเป็นอาการชักทั้งตัว เช่น เหม่อลอย ทำอะไรไม่รู้ตัว หรือเกร็งกระตุกทั่วตัว

ตารางที่ 2.2 อาการนำก่อนการชัก

อาการเตือน (aura)	ลักษณะอาการเตือน	ตำแหน่งที่ก่อให้เกิดอาการ (symptomatogenic zone)
Somatosensory	อาการชาหรือรู้สึกคล้ายมีหนามทิ่มตำในบางส่วนของร่างกาย	Contralateral somatosensory area
Visual	อาการมองเห็นที่ผิดปกติ เช่น เห็นแสงไฟกระพริบ	Contralateral primary visual area
Olfactory	การได้กลิ่นผิดปกติ เช่น กลิ่นเหม็นไหม้	Amygdala
Gustatory	การรับรสที่เปลี่ยนไป เช่น รสโลหะ รสขม	Insula
Abdominal	มีอาการจุกแน่นท้อง บางครั้งรู้สึกเหมือนมีผีเสื้อบินว่อนอยู่ในท้อง	Insula, temporal lobe

อาการเตือน (aura)	ลักษณะอาการเตือน	ตำแหน่งที่ก่อให้เกิดอาการ
Auditory	ได้ยินเสียงผิดปกติ เช่น เสียงกระดิ่ง เสียงผึ้งบิน เสียงพูด	Superior temporal gyrus
Psychic	ความผิดปกติทางอารมณ์ เช่น รู้สึกกลัว	Amygdala, basal temporal lobe
Autonomic	ใจสั่น วิงเวียน ขนลุก	Insula, basal frontal, anterior cingulate, left temporal lobe

2.3.2 อาการชัก (seizure symptom หรือ seizure semiology)

สิ่งที่ควรถามในระหว่างที่ผู้ป่วยชักคือ ลักษณะรายละเอียดของอาการชักและอาการอื่น ๆ ที่เกิดร่วมขณะชักโดยรวบรวมรายละเอียดเพื่อการวินิจฉัยแยกโรค จำแนกประเภทของโรคลมชัก และวางแผนการรักษาต่อไป

ตารางที่ 2.3 รายละเอียดของอาการชักและอาการอื่น ๆ ที่เกิดร่วม

รายละเอียดของอาการชัก	ตัวอย่างของรายละเอียด
1. ลำดับเหตุการณ์	เริ่มตั้งแต่แรกที่เห็นเหตุการณ์จนกระทั่งสิ้นสุดอาการ
2. กิจกรรมที่กำลังกระทำก่อนเกิดอาการชัก	เกิดอาการชักขณะทำกิจกรรมโดยอยู่ เช่น เกิดขณะนั่งรับประทานอาหาร
3. ระยะเวลาของอาการชัก	โดยให้เน้นถามระยะเวลาที่ชัดเจนเนื่องจากโดยมากไม่มีผู้ใดจับเวลาขณะเกิดอาการ โดยอาจถามว่านับหนึ่งถึงเท่าไรอาการจึงหยุดซึ่งจะทำให้แพทย์สามารถประมาณได้ว่านานเท่าใด
4. ช่วงเวลาไหนของวันที่เกิดอาการ	เช่น เกิดตอนกลางวัน หรือเกิดกลางคืนขณะนอนหลับ
5. จำนวนครั้งและความถี่ของอาการชัก	ควรระบุให้ชัดเจนว่าเกิดกี่ครั้งต่อวัน หรือต่อเดือน และระบุครั้งล่าสุดที่เกิดอาการ คือ วันที่เท่าไรก่อนมาพบแพทย์
6. ระดับความรู้สึกตัว	ขณะมีอาการชักยังรู้สึกตัวอยู่หรือไม่ สามารถจดจำเหตุการณ์ที่เกิดขึ้นได้ไหม และสามารถสื่อสารกับคนรอบข้างได้หรือไม่

รายละเอียดของอาการชัก	ตัวอย่างของรายละเอียด
7. การเคลื่อนไหวของร่างกายและการเคลื่อนไหวซ้ำๆ	ขณะเกิดอาการการเคลื่อนไหวของศีรษะและลำคอเอียงไปด้านใดด้านหนึ่ง พร้อมทั้งการกลอกตาขึ้นหรือมองไปทางเดียวกัน (Versive) การกระตุกสั้น ๆ ทั้งตัวเป็นวินาที (Myoclonic) การกระตุกเป็นจังหวะเป็นชุด ๆ (Clonic) อาการเกร็งของแขนและขาข้างเดียว หรือสองข้างพร้อม ๆ กัน (Asymmetric/Symmetric Tonic) การเกร็งกระตุกทั้งตัว (Tonic-Clonic) โดยมีอาการเกร็งแล้วจึงตามด้วยอาการกระตุก ผู้ป่วยบางราย อาจมีอาการเคลื่อนไหวซ้ำ ๆ เช่น กระพริบตาถี่ ๆ เคี้ยวปากหรือหยิบจับสิ่งของหรือเล่นขยี้เสื้อผ้า (Automotor)
8. ความผิดปกติทางด้านการออกเสียงและการสื่อสาร	ผู้ป่วยบางคนอาจมีความผิดปกติของการใช้ภาษา เช่น พูดไม่ชัด พูดไม่ได้ หรือมีเสียงร้องผิดปกติ
9. การเปลี่ยนแปลงทางการหายใจ	เช่น หยุดหายใจ หายใจในลักษณะที่เปลี่ยนไป หรือมีอาการตัวเขียว น้ำลายฟูมปาก
10. ความผิดปกติของระบบประสาทอัตโนมัติ	เช่น เหงื่อออกมากผิดปกติ อาเจียน หายใจผิดปกติ หัวใจเต้นผิดปกติ หวั่นไหว และ/หรือ อุจจาระราด
11. การบาดเจ็บขณะเกิดอาการ	เช่น กัดลิ้น ศีรษะกระแทกพื้น กระตุกหัก

ลักษณะของอาการชักโดยทั่วไป ได้แก่

- เกิดขึ้นทันทีทันใด (Sudden onset, paroxysm)
- เกิดขึ้นเป็นระยะเวลาสั้น ๆ ไม่เกิน 5 นาทีและหยุดเอง มีเพียงส่วนน้อยที่อาการชักจะดำเนินไปเป็นภาวะชักต่อเนื่อง (Status epilepticus)
- ส่วนใหญ่จะเกิดขึ้นเอง แต่บางครั้งอาจจะมีปัจจัยกระตุ้นให้เกิด (Precipitating factor)
- ส่วนใหญ่จะมีลักษณะเหมือนหรือคล้ายกันทุกครั้ง (Stereotype)

2.3.3 อาการหลังชัก (Postictal Symptoms)

หมายถึง อาการที่เกิดขึ้นหลังจากอาการชักจนกระทั่งผู้ป่วยกลับสู่ภาวะปกติดังเดิม ซึ่งในกรณีที่ผู้ป่วยหมดสติภายหลังจากอาการชักเกร็งกระตุกทั้งตัว หรืออาการชักที่อาจดูเหมือน

รู้ตัวแต่ไม่สามารถตอบสนองต่อคำถาม ได้เป็นปกติ นั้น ผู้ป่วยมักจะมีอาการหลังชักดังต่อไปนี้ ได้แก่ ปวดศีรษะ ชี้น หลับ สับสน หรือมีอาการทางจิต เช่น หนาว เห็นภาพหลอน ผู้ป่วยบางรายไม่สามารถสื่อสารได้อย่างปกติ เช่น ไม่เข้าใจคำถาม หรืออาจไม่สามารถพูดได้ บางราย อาจมีอาการแขนขาอ่อนแรงเป็นซีก เช่น แขนซ้ายไม่สามารถขยับได้ (Todd's paralysis) ควรถามระยะเวลาอาการหลังชักด้วยว่านานเท่าใดจนกระทั่งผู้ป่วยกลับมาเป็นปกติ

2.4 ระบบการทำงานของเครื่องเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง (Machine Learning) คือระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเองโดยปราศจากการป้อนคำสั่งของโปรแกรมเมอร์ ความก้าวหน้าในครั้งนี้นำมาพร้อมกับความคิดที่ว่าเครื่องคอมพิวเตอร์สามารถเรียนรู้ได้จากข้อมูลอย่างเดียวเพื่อที่จะผลิตผลลัพธ์ที่แม่นยำออกมาได้


การเรียนรู้ของเครื่อง ประกอบด้วยข้อมูลและเครื่องมือทางสถิติเพื่อทำนายผลลัพธ์ออกมา ผลลัพธ์ในที่นี้ถูกใช้เพื่อทำประโยชน์กับภายในองค์กรเชิงลึกต่อไป การเรียนรู้ของเครื่องเกี่ยวข้องกับอย่างมากกับ การทำเหมืองข้อมูล (Data mining) และ โมเดลการทำนายของ Bayes (Bayesian predictive models) เครื่องคอมพิวเตอร์จะรับข้อมูลเข้ามาและใช้อัลกอริทึมเพื่อหาคำตอบงานของการเรียนรู้ของเครื่องโดยทั่วไปจะเป็นการคอยสนับสนุนด้านการแนะนำ (provide a recommendation) ตัวอย่างเช่น สำหรับคนที่สมาชิกของ Netflix, ทุกคำแนะนำหนังหรือซีรีส์ต่าง ๆ ขึ้นอยู่กับข้อมูลในการเข้าชมของผู้ใช้ที่ผ่านมา บริษัทเทคโนโลยีกำลังใช้วิธีการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เพื่อปรับปรุงตามประสบการณ์ของผู้ใช้และการแนะนำส่วนบุคคลการเรียนรู้ของเครื่องยังถูกใช้กับงานหลากหลายด้าน เช่น การตรวจจับการฉ้อโกง (Fraud detection), การพยากรณ์เพื่อปรับปรุงแก้ไข (Predictive Maintenance), การเพิ่มประสิทธิภาพในการถือหุ้น (Portfolio optimization), การทำงานอัตโนมัติ และอื่น ๆ

2.5 เทคนิคการสกัดและจำแนกสัญญาณคลื่นไฟฟ้าสมอง

โดยทั่วไปแล้ว จุดข้อมูลจำนวนมากจะรวมอยู่ในการบันทึกคลื่นไฟฟ้าสมอง ข้อมูลที่ซ้ำซ้อนทำให้กระบวนการจัดหมวดหมู่ช้าลงและมักทำให้เกิดผลลัพธ์ที่ไม่ถูกต้อง เพื่อลดมิติข้อมูลและเพื่อประสิทธิภาพที่ดีขึ้น มักใช้เทคนิคการแยกคุณลักษณะในขั้นตอนนี้ จึงจะต้องมีเทคนิคในการสกัดคุณลักษณะเด่นของสัญญาณข้อมูล

2.5.1 Tunable Q-factor WT (TQWT) TQWT เป็นเทคนิคการสลายตัวของสัญญาณที่พัฒนาขึ้นใหม่ เป็นรูปแบบที่คล้ายคลึงกันของการแปลงเวฟเลตการให้เหตุผล และถูกใช้เพื่อวิเคราะห์สัญญาณ EEG TQWT ขึ้นอยู่กับพารามิเตอร์ที่เปลี่ยนแปลงได้: Q-factor (Q),

Redundancy (R) และ Decomposition level (J) สำหรับพารามิเตอร์ TQWT ค่า Q มักจะถูกตั้งค่าสูง เนื่องจากสัญญาณ EEG มีการแกว่งมากกว่า



รูปที่ 2.7 TWQT สลายสัญญาณ EEG อินพุต ($Sig[m]$) ให้เป็น $Lsig$ แบนด์ความถี่ต่ำผ่าน และ $Hsig$ แบนด์ย่อยความถี่สูงที่ระดับ J^{th}

2.5.2 Statistical feature extracted method เป็นวิธีการทางสถิติ และถูกใช้ในการแยกคุณลักษณะทางสถิติที่เป็นตัวแทน มีผลกับประสิทธิภาพของตัวแยกประเภท หากเลือกคุณลักษณะได้ไม่ดี วิธีการทางสถิติประกอบด้วยสองขั้นตอน คือ การแบ่งส่วนและการแยกคุณลักษณะทางสถิติ สัญญาณ EEG มีลักษณะไม่เชิงเส้นและไม่คงที่ ซึ่งทำให้การวิเคราะห์และการจำแนกประเภททำได้ยาก การสกัดข้อมูลด้วยค่าทางสถิติ หรือ Statistical feature extracted method วิธีการทางสถิติเป็นส่วนที่เสนอและใช้เพื่อแยกคุณลักษณะทางสถิติที่เป็นตัวแทน มีผลต่อประสิทธิภาพของลักษณะที่เด่นชัดของชุดข้อมูล หากไม่ได้เลือกคุณสมบัติไว้อย่างดี วิธีการทางสถิติประกอบด้วยสองขั้นตอนการแบ่งส่วนและการแยกคุณลักษณะทางสถิติ สัญญาณ EEG มีลักษณะไม่เป็นเชิงเส้นและไม่อยู่นิ่ง ซึ่งทำให้การวิเคราะห์และการจำแนกเป็นเรื่องยาก ซึ่งในงานวิจัยนี้จะนำคลื่นไฟฟ้าสมองที่ผ่านกระบวนการสลายแถบความถี่แล้ว มาผ่านการลดขนาดสัญญาณด้วยการสกัดข้อมูลทางสถิติ ในการสกัดข้อมูลนั้นจะใช้ข้อมูลทางสถิติ 6 ชนิดได้แก่ Maximum (Max), Variance (Var), Skewness (Sk), Kurtosis (Ku), Mean (Mean) และ Entropy (En)

2.5.2.1 Maximum คือ ค่าองค์ประกอบสูงสุดของข้อมูล

$$Max = \max(xn) \quad (2.1)$$

2.5.2.2 Variance คือ ค่าแปรปรวน ใช้เพื่อวัดการกระจายของข้อมูลคิดจากค่าเฉลี่ยของความต่างจากค่าเฉลี่ยยกกำลัง 2

$$Var = \sum_{n=1}^N (X_n - SM) \frac{2}{N-1} \quad (2.2)$$

2.5.2.3 Skewness คือ ค่าความเบ้บอกถึงการเบี่ยงเบนของข้อมูล

$$SK = \sum_{n=1}^N (X_n - SM) \frac{3}{(N-1)SD^3} \quad (2.3)$$

2.5.2.4 Kurtosis คือ ค่าความโด่งเป็นตัวชี้วัดทางสถิติที่ใช้อธิบายการกระจายตัว

$$\alpha_4 = \frac{\sum_{i=1}^m (x_i - \bar{x})^4}{m\sigma^4} \quad (2.4)$$

2.5.2.5 Mean คือ ค่าเฉลี่ยของชุดข้อมูล

$$Mean = \frac{1}{n} \sum_{n=1}^n x_n \quad (2.5)$$

2.5.2.6 Entropy คือ ปริมาณที่บอกถึงความไม่เป็นระเบียบของระบบ ซึ่งในงานวิจัยนี้จะใช้ค่า Wavelet Entropy สำหรับข้อมูลคลื่นไฟฟ้าสมอง

สมการ

$$E(s) = \sum_i E_n(S_i) \quad (2.6)$$

2.6 การทบทวนวรรณกรรม/สารสนเทศ (Information) ที่เกี่ยวข้อง

เพื่อให้เกิดความเข้าใจเกี่ยวกับการพิจารณาจำแนกคลื่นไฟฟ้าสมอง โดยใช้ข้อมูลที่เป็นมาตรฐาน ที่บันทึกค่าจากตามตำแหน่งต่าง ๆ ของสมองเพื่อศึกษาสัญญาณคลื่นไฟฟ้าสมอง หรือ EEG (Electroencephalogram) และศึกษาเทคนิคทางการจำแนกสัญญาณคลื่นไฟฟ้าสมองที่เป็นปกติ และคลื่นไฟฟ้าสมองที่มีอาการชักเกิดขึ้น หรือวิธีการจำแนกคลื่นไฟฟ้าสมองช่องสัญญาณต่าง ๆ ศึกษาทิศทางปริทัศน์วรรณกรรม และงานวิจัยที่เกี่ยวข้อง เพื่อศึกษาโครงสร้าง หลักการทำงานของคลื่นไฟฟ้าสมอง ที่มีความสัมพันธ์กันภาวะต่างๆและเทคนิคการจำแนกสัญญาณคลื่นไฟฟ้าสมอง เพื่อเป็นความรู้และใช้เป็นแนวทางในการออกแบบสำหรับงานวิจัยต่อไปนี้ ซึ่งจากการศึกษา มีปริทัศน์วรรณกรรมที่ผ่านมามีงานวิจัยที่เกี่ยวข้องดังนี้

2.6.1 งานวิจัยของ PATIDAR SHIVNARAYAN, AND TRILOCHAN PANIGRAHI. "DETECTION OF EPILEPTIC SEIZURE USING KRASKOV ENTROPY APPLIED ON TUNABLE-Q WAVELET TRANSFORM OF EEG SIGNALS."

โดยนำการจำแนกสัญญาณสัญญาณคลื่นไฟฟ้าสมอง (EEG) เป็นสัญญาณคลื่นไฟฟ้าที่ปกติแล้วจะใช้เพื่อเข้าถึงสภาพของสมอง โรคลมบ้าหมูเป็นหนึ่งในความผิดปกติของสมอง การวินิจฉัยโรคลมบ้าหมูแบบอัตโนมัติสามารถทำได้โดยการวัดและวิเคราะห์แนวโน้มที่ไม่เป็นเชิงเส้นและไม่คงที่ในสัญญาณ EEG วิธีการวินิจฉัยแบบใหม่สำหรับการวิเคราะห์และจำแนกสัญญาณ EEG ที่ไม่มีการจับกุมและการจับกุม ในโดเมนมาตราส่วนเวลา การแปลงเวฟเลต Q ที่ปรับค่าได้ (TQWT) สามารถแสดงความกระจัดกระจายในสัญญาณออสซิลเลเตอร์ได้อย่างน่าเชื่อถือ วิธีการที่นำเสนอเริ่มต้นด้วยการใช้ TQWT เพื่อกำหนดลักษณะพฤติกรรมที่ไม่คงที่และความเบาบางของสัญญาณ EEG อย่างมีประสิทธิภาพ TQWT จะแยกย่อยสัญญาณที่พิจารณาเป็นชุดสัญญาณที่จำกัดแบนด์อื่นมีค่าซึ่งเรียกว่าย่านความถี่ย่อยเพื่อการดึงคุณลักษณะที่ดีขึ้น เอนโทรปีของ Kraskov เป็นพารามิเตอร์ที่ไม่เป็นเชิงเส้นเพื่อตรวจจับแนวโน้มที่ไม่เป็นเชิงเส้นในสัญญาณภายหลังการสลายตัว เอนโทรปี Kraskov คำนวณจาก sub-band ที่เฉพาะเจาะจงเป็นคุณลักษณะชี้ขาดเพื่อแยกแยะสัญญาณ EEG จากการชักจากโรคลมชัก ต่อมา เวกเตอร์คุณลักษณะที่ได้รับจะถูกใช้เพื่อจำแนกสัญญาณ EEG ที่ไม่มีการชักและการชักโดยใช้ตัวแยกประเภทเวกเตอร์แมชชีน (LS-SVM) ที่มีกำลังสองน้อยที่สุด ขณะทำการวิเคราะห์ พบว่าค่าของคุณลักษณะตาม Krasko entropy ที่เสนอนั้นสูงกว่าอย่างมีนัยสำคัญสำหรับสัญญาณ EEG ในการยัดเมื่อเปรียบเทียบกับสัญญาณ EEG ที่ไม่มีอาการ

2.6.2 งานวิจัยของ HADI RATHAM AL GHAYA, YAN LIA, S. SIULYC AND SHAHAB ABDULLAD. "A FEATURE EXTRACTION TECHNIQUE BASED ON TUNABLE Q-FACTOR WAVELET TRANSFORM FOR BRAIN SIGNAL CLASSIFICATION."

สัญญาณคลื่นไฟฟ้าสมอง (EEG) มีความสำคัญต่อการประยุกต์ใช้การตรวจสุขภาพสมอง ลักษณะของสัญญาณ EEG นั้นซับซ้อน มีลักษณะไม่คงที่เป็นช่วง ๆ และไม่เป็นเชิงเส้น สัญญาณ EEG เป็นการรวมกันของการสั่นที่ต่อเนื่องและการเปลี่ยนแปลงชั่วคราวที่ไม่สั้นซึ่งท้าทายในการจัดการโดยใช้วิธีการเชิงเส้น

งานวิจัยนี้เสนอโครงการใหม่โดยอิงจากการแปลงเวฟเลต Q-factor ที่ปรับได้ (TQWT) และวิธีการทางสถิติเพื่อวิเคราะห์การบันทึก EEG ต่าง ๆ ประการแรก วิธีการที่เสนอจะสลายสัญญาณ EEG เป็นย่านความถี่ย่อยที่แตกต่างกันโดยใช้วิธี TQWT ซึ่งกำหนดพารามิเตอร์ด้วยปัจจัย Q และความซับซ้อน วิธีนี้ขึ้นอยู่กับการสั่นพ้องของสัญญาณ แทนที่จะเป็นความถี่หรือมาตราส่วนเช่นเดียวกับการแปลงฟูริเยร์และเวฟเลต ประการที่สอง ใช้การแยกคุณลักษณะทางสถิติบนแถบย่อยเพื่อแบ่งแต่ละแถบย่อยออกเป็น n หน้าต่าง จากนั้นแยกคุณลักษณะทางสถิติหลายรายการออกจากแต่ละหน้าต่าง สุดท้าย คุณลักษณะที่แยกออกมาจะถูกส่งต่อไปยัง bagging tree (BT) k เพื่อนบ้านที่ใกล้ที่สุด (k-NN) และ support vector machine (SVM) เป็นตัวแยกประเภทเพื่อประเมินประสิทธิภาพของเทคนิคการแยกคุณลักษณะที่เสนอ

วิธีการที่เสนอนี้ได้รับการทดสอบในฐานข้อมูล EEG สองฐานข้อมูลที่แตกต่างกัน ฐานข้อมูลมหาวิทยาลัยบอนน์และฐานข้อมูลของมหาวิทยาลัยเบอร์ลิน ผลการทดลองแสดงให้เห็นว่าอัลกอริธึมการแยกคุณลักษณะที่เสนอด้วยตัวแยกประเภท thek-NN ให้ประสิทธิภาพที่ดีที่สุดเมื่อเทียบกับตัวแยกประเภทอีกสองตัว เปรียบเทียบกับวิธีการที่มีอยู่ เพื่อประเมินผลการปฏิบัติงานต่อไป โครงร่างที่เสนอจะถูกเปรียบเทียบกับวิธีการอื่นที่มีอยู่ในแง่ของความถูกต้อง ผลการทดลองพิสูจน์ว่าวิธีการแยกคุณลักษณะตาม TQWT ที่เสนอมีสภาพที่ดีในการดึงข้อมูลการเลือกปฏิบัติจากสัญญาณสมอง

2.6.3 งานวิจัยของ GUANG-BIN HUANG, HONGMING ZHOU, XIAOJIAN DING, AND RUI ZHANG "EXTREME LEARNING MACHINE FOR REGRESSION AND MULTICLASS CLASSIFICATION."

การนำไปใช้งาน LS-SVM อย่างน้อยรองรับเวกเตอร์และ Proximal Support Vector Machine (PSVM) จึงถูกนำมาใช้กันอย่างแพร่หลายในแอปพลิเคชันการจำแนกประเภทไปนารี LS-SVM และ PSVM แบบเดิมไม่สามารถใช้ในแอปพลิเคชันการถดถอยและการจำแนกประเภทหลายคลาสได้โดยตรง แม้ว่าจะมีการเสนอตัวแปรของ LS-SVM และ PSVM เพื่อจัดการกับกรณีดังกล่าว เอกสารนี้แสดงให้เห็นว่าทั้ง LS-SVM และ PSVM สามารถทำให้ง่ายขึ้นอีก และสามารถสร้างเฟรมเวิร์กการเรียนรู้แบบรวมศูนย์ของ LS-SVM, PSVM และอัลกอริธึมการทำให้เป็นมาตรฐานอื่น ๆ ที่อ้างถึง Extreme Learning Machine (ELM) ได้ ELM ใช้งานได้กับเครือข่าย feedforward แบบซ่อนชั้นเดียว "ทั่วไป" (SLFN) แต่ไม่จำเป็นต้องปรับเลเยอร์ที่ซ่อนอยู่

(หรือที่เรียกว่าการแมปคุณลักษณะ) ใน ELM SLFN ดังกล่าวรวมถึงแต่ไม่จำกัดต่อ SVM, โครงข่ายพหุนาม และโครงข่ายประสาทฟีดฟอร์เวิร์ดทั่วไป เอกสารนี้แสดงให้เห็นดังต่อไปนี้:

- 1) ELM จัดเตรียมแพลตฟอร์มการเรียนรู้แบบรวมศูนย์ที่มีการแมปคุณลักษณะอย่างกว้างขวางและสามารถนำไปใช้ในแอปพลิเคชันการถดถอยและการจัดหมวดหมู่แบบหลายคลาสได้โดยตรง
- 2) จากมุมมองของวิธีการเพิ่มประสิทธิภาพ ELM มีข้อจำกัดในการเพิ่มประสิทธิภาพที่น้อยกว่าเมื่อเทียบกับ LS-SVM และ PSVM
- 3) ในทางทฤษฎี เมื่อเทียบกับ ELM แล้ว LS-SVM และ PSVM บรรลุโซลูชันที่ค้ำประกันประสิทธิภาพและต้องการความซับซ้อนในการคำนวณที่สูงขึ้น และ
- 4) ในทางทฤษฎี ELM สามารถประมาณฟังก์ชันเป้าหมายต่อเนื่องใด ๆ และจำแนกบริเวณที่ไม่ปะติดปะต่อกัน ตามที่ตรวจสอบโดยผลการจำลอง ELM มีแนวโน้มที่จะมีความสามารถในการปรับขนาดได้ดีกว่าและบรรลุผลที่คล้ายกัน (สำหรับการถดถอยและกรณีคลาสไบนารี) หรือดีกว่ามาก (สำหรับกรณีหลายคลาส) ที่ความเร็วการเรียนรู้ที่เร็วกว่ามาก (มากถึงหลายพันเท่า) กว่า SVM และ LS แบบเดิม -เอสวีเอ็ม

2.6.4 งานวิจัยของ YU ZHANG, YU WANG, GUOXU ZHOU, JING JIN, BEI WANG, XINGYU WANG AND ANDRZEJ CICHOCKI "MULTI-KERNEL EXTREME LEARNING MACHINE FOR EEG CLASSIFICATION IN BRAIN-COMPUTER INTERFACES."

การพัฒนาส่วนต่อประสานระหว่างสมองกับคอมพิวเตอร์โดยใช้ภาพยนต์ (motor-imagery-based brain-computer interface - BCI) คือวิธีการออกแบบตัวแยกประเภทที่ทรงพลังพร้อมความสามารถทั่วไปที่แข็งแกร่ง Extreme learning machine (ELM) เพิ่งได้รับการพิสูจน์แล้วว่าสามารถเทียบเคียงหรือมีประสิทธิภาพมากกว่า support vector machine สำหรับปัญหาการจดจำรูปแบบมากมาย ในงานวิจัยนี้ เสนอวิธีการที่ใช้ ELM แบบหลายเคอร์เนล (MKELM) สำหรับการจำแนกประเภทอิเล็กโทรเซฟาโลแกรมของภาพยนต์ (EEG) ส่วนขยายเคอร์เนลของ ELM เป็นวิธีที่ขอดีเยี่ยมในการหลีกเลี่ยงการคำนวณเอาต์พุตของเลเยอร์ที่ซ่อนอยู่และเข้ารหัสในเมทริกซ์เคอร์เนล การตรวจสอบผลกระทบของสองฟังก์ชันเคอร์เนลที่แตกต่างกัน (เช่น เคอร์เนล Gaussian และเคอร์เนลพหุนาม) ต่อประสิทธิภาพของเคอร์เนล ELM ต่อมาวิธี MKELM ได้รับการพัฒนาโดยการรวมเมลิตซ์พีชสองประเภทนี้เข้ากับกลยุทธ์การเรียนรู้หลายเคอร์เนล ซึ่งสามารถสำรวจข้อมูลเสริมจากช่องว่างคุณสมบัติไม่เชิงเส้นจำนวนมากเพื่อการจำแนก EEG ที่แข็งแกร่งยิ่งขึ้น การเปรียบเทียบการทดลองอย่างละเอียดกับชุดข้อมูล EEG สาธารณะสองชุดบ่งชี้ว่าวิธี MKELM ให้ความแม่นยำในการจำแนกประเภทที่สูงกว่าชุดข้อมูลของอัลกอริทึมอื่น ๆ ที่แข่งขันกัน ผลการทดลองยืนยันว่าเหนือกว่าของวิธีการที่ใช้ MKELM ที่เสนอสำหรับการจำแนก EEG ที่แม่นยำที่เกี่ยวข้องกับภาพยนต์ในแอปพลิเคชัน BCI วิธีการของเรายังให้แนวทาง

ที่เป็นไปได้และมีแนวโน้มทั่วไปในการตรวจสอบข้อมูลที่ซับซ้อนและไม่เชิงเส้นสำหรับการใช้งานต่างๆ ในด้านระบบผู้เชี่ยวชาญและระบบอัจฉริยะ

2.6.5 งานวิจัยของ JIUWEN CAO, JIAHUA ZHU, WENBIN HU, AND ANTON KUMMERT "EPILEPTIC SIGNAL CLASSIFICATION WITH DEEP EEG FEATURES BY STACKED CNNs."

การตรวจคลื่นไฟฟ้าสมองด้วยคลื่นไฟฟ้าสมอง (EEG) จากหนังศีรษะ (EEG) ที่ใช้ในการตรวจหาโรคลมบ้าหมู/การตรวจหาแบบไม่ชักว่าได้รับการศึกษาอย่างละเอียดถี่ถ้วนและมีการรายงานความสำเร็จที่ได้ผลในอดีต กระนั้น มีการตรวจสอบเพียงเล็กน้อยที่ง่ายให้กับการตรวจจับระยะพรีอิคทัล ซึ่งในทางปฏิบัติแล้วมีความสำคัญมากกว่าสำหรับโรคลมชักในการระมัดระวังตัวก่อนที่จะเริ่มมีอาการชัก ในบทความนี้ ได้มีการพัฒนาอัลกอริทึมการจำแนกสถานะ preictal ของโรคลมบ้าหมูและอัลกอริทึมการตรวจจับการชักตามคุณลักษณะเชิงลึกที่เรียนรู้โดยโครงข่ายประสาทเทียมแบบซ้อน (SCNN) แอมพลิจูดเฉลี่ยของแผนที่สเปกตรัม (MAS) ที่ได้จากสเปกตรัมความถี่ย่อยเฉลี่ยของ EEG แบบหลายช่องสัญญาณถูกนำมาใช้สำหรับการแทนค่า เวกเตอร์คุณสมบัติความน่าจะเป็นโดย CNN แบบเรียงซ้อนนั้นแยกออกมาในเลเยอร์ Softmax ของ CNN ซึ่งได้มีการพัฒนาฟิวชันการถ่วงน้ำหนักคุณลักษณะแบบปรับตัวและแยกแยะ (AWF) เพื่อการเพิ่มประสิทธิภาพ หลังจากการแยกชั้นลึก ได้นำ Kernel Extreme Learning Machine (KELM) มาใช้สำหรับการเรียนรู้คุณลักษณะและการจำแนกโรคลมบ้าหมู มีการทดลองกับฐานข้อมูล CHB-MIT เกณฑ์มาตรฐานและฐานข้อมูลโรคลมชักที่บันทึกไว้จริงเพื่อสาธิตประสิทธิภาพ มีการเปรียบเทียบกับวิธีการจำแนกประเภทโรคลมชักที่ล้ำสมัยเพื่อแสดงความเหนือกว่าของอัลกอริทึม SCNN+AWF ที่เสนอ

2.6.6 การสกัดลักษณะสำคัญของสัญญาณคลื่นสมองที่ได้จากการเขียนในจินตนาการ
FEATURE EXTRACTION OF BRAINWAVE SIGNALS FROM IMAGINED WRITING

การสื่อสารระหว่างสมองกับคอมพิวเตอร์เป็นเทคโนโลยีระบบการสื่อสารที่ช่วยให้สามารถส่งผ่าน ข้อความหรือคำสั่งจากสมองไปสู่โลกภายนอกได้โดยตรงด้วยการตีความหมายของสัญญาณคลื่นไฟฟ้า สมอง ซึ่งไม่ต้องผ่านเส้นทางปกติของสมองสู่ปลายทางของเส้นประสาทและกล้ามเนื้อ ทำให้การสื่อสาร ระหว่างสมองกับคอมพิวเตอร์จึงเป็นวิธีการที่ถูกคาดหวังอย่างมากในการค้นหาวิธีการสื่อสารแบบอื่น สำหรับผู้พิการที่ไม่สามารถใช้อวัยวะปกติทั่วไปในการทำงานหรือสื่อสารได้ ซึ่งการสื่อสารระหว่างสมอง กับคอมพิวเตอร์นั้นได้ถูกพัฒนาขึ้นมาหลากหลายรูปแบบหนึ่งในรูปแบบที่กำลังเป็นที่ได้รับความนิยม คือ ระบบการสะกดตัวอักษรเป็นระบบที่อนุญาตให้ผู้พิการพิมพ์อักขระแต่ละตัวหรือแม้แต่ประโยคด้วยการ ถอดรหัสการทำงานของสมอง โดยงานวิจัยส่วนใหญ่จะมุ่งเน้นไปที่สองกระบวนการคือ กระบวนการที่ใช้ สัญญาณ

รูปแบบหนึ่งที่จะปรากฏขึ้นเมื่อสมองโคจรกระตุ้นจากเหตุการณ์ที่ผิดปกติบางอย่างของสิ่งที่เห็นหรือได้ยิน เช่น การกระพริบตัวอักษรแบบทันทีทันใดหรือใช้การกระพริบแบบความถี่ที่ต่างกัน ต่อมาคือ กระบวนการที่ใช้การกระตุ้นร่วมการจินตนาการถึงการขยับแขนหรือขาเพื่อเลือกตัวอักษร แต่ทั้งสอง กระบวนการนี้ จะต้องใช้การกระตุ้นอยู่ตลอดเวลาซึ่งจะไม่สะดวกต่อการใช้งานถ้าหากจะต้องใช้ใน ชีวิตประจำวัน ดังนั้นงานวิจัยนี้จึงมีแนวคิดที่จะหาวิธีการที่จะสกัดลักษณะเฉพาะของสัญญาณคลื่นสมอง แบบไม่ใช้การกระตุ้นจากสิ่งเร้าภายนอกและไม่จินตนาการถึงการเคลื่อนไหวแขนหรือขา งานวิจัยนี้ใช้ Neural Network เพื่อแยกแยะการเขียนในจินตนาการ

2.7 สรุป

เนื้อหาในบทที่สองนี้ได้กล่าวถึงการสำรวจปริทัศน์วรรณกรรมที่ทำการสำรวจมารวมถึงความหมายและคุณสมบัติของคลื่นไฟฟ้าที่เกิดขึ้นบนร่างกายมนุษย์ อีกทั้งเพื่อให้เข้าใจถึงการเกิดอาการชักที่ถูกต้อง ตามเนื้อหาที่ได้กล่าวมาข้างต้น ในบทนี้จะเป็นพื้นฐาน สำหรับการทำความเข้าใจเกี่ยวกับการทำงาน ของสมองในแต่ละส่วน ความสัมพันธ์ระหว่างย่านความถี่กับกิจกรรมของร่างกายมนุษย์ และเทคนิคการวิเคราะห์สัญญาณคลื่นไฟฟ้าสมอง ด้วยวิธีการสกัดคุณลักษณะเด่นของสัญญาณ ที่สอดคล้องกับช่วงเวลาและความถี่ที่เหมาะสมตามความต้องการได้ รวมถึง การจำแนกสัญญาณคลื่นไฟฟ้าสมองด้วยเทคนิคการเรียนรู้ของเครื่องผ่านวิธีการจำแนกแบบชนิดต่างกัน จะทำหน้าที่จดจำรูปแบบและจำแนกสัญญาณคลื่นไฟฟ้าสมอง นอกจากนี้ การสำรวจปริทัศน์วรรณกรรมที่เกี่ยวข้อง ยังแสดงให้เห็นถึงงานวิจัยที่ผ่านมาเกี่ยวกับการสกัดคุณลักษณะเด่น ผู้วิจัยจึงเสนอแนวคิดใหม่ในการพัฒนาการสกัดคุณลักษณะเด่นที่ให้ค่าน้ำหนักได้ดีขึ้น และการลดขนาดของข้อมูลด้วยค่าทางสถิติรูปแบบต่าง ๆ เพื่อให้มีขนาดข้อมูลที่น้อยลงแต่ยังคงมีลักษณะเด่นได้ดี ซึ่งจะอธิบายในบทถัดไป

บทที่ 3

ระเบียบวิธีวิจัย

3.1 วิธีการดำเนินงาน

ในบทนี้ได้กล่าวถึงการออกแบบ และหลักการทำงานของกรรูกำลังไฟฟ้าสมอง โดยจะออกแบบการทดลองจากชุดข้อมูลที่เป็นมาตรฐานทางการแพทย์ 1.จำแนกชุดข้อมูลให้เข้าใจง่าย 2.ออกแบบกระบวนการสกัดคุณลักษณะเด่นของสัญญาณ 3.ออกแบบกระบวนการการจำแนก โดยการกระบวนการจำแนกจะใช้ชนิดการจำแนกดังนี้ 1.GMM 2.KELM 3.LS-SVM ซึ่งจะนำมาใช้ในการสร้างโมเดลการจำแนกลักษณะคลื่นไฟฟ้าสมองที่เป็นปกติและผิดปกติ หลังจากนั้นจะนำโมเดลการจำแนกที่ได้มาทดสอบกับชุดข้อมูลเพื่อทดสอบความถูกต้อง

3.2 การจัดการข้อมูล


ข้อมูลที่ใช้เป็นอินพุตจะเป็นประเภทสัญญาณคลื่นไฟฟ้าสมอง ฐานข้อมูลนี้รวบรวมที่ Children's Hospital Boston ประกอบด้วยการบันทึกคลื่นไฟฟ้าสมองจากผู้ป่วยเด็กที่มีอาการชัก ผู้ป่วยได้รับการตรวจติดตามเป็นเวลาหลายวันหลังจากถอนยาต้านอาการชัก เพื่อระบุลักษณะอาการชักและประเมินผู้ป่วยเข้ารับการรักษา

การบันทึกแบ่งออกเป็น 23 กรณีโดยรวมจากผู้ป่วย 22 คน (ชาย 5 คน อายุ 3-22 ปี และหญิง 17 คน อายุ 1.5-19 ปี) โดยชื่อไฟล์เดอร์ที่จัดเก็บข้อมูล มาจากตัวย่อของชื่อโรงพยาบาล Children's Hospital Boston เป็น chb ซึ่งแต่ละไฟล์เดอร์จัดเก็บข้อมูลของแต่ละกรณีไว้ในกรณีที่ 1 ใช้ชื่อไฟล์ chb01 และในกรณีอื่นก็แทนด้วยตัวเลขตามแต่ละกรณี (กรณี chb21 บันทึกภายหลัง 1.5 ปี จากกรณี chb01 จากผู้หญิงคนเดียวกัน) ไฟล์ SUBJECT-INFO ประกอบด้วยเพศและอายุของแต่ละกรณี (กรณี chb24 ถูกเพิ่มเข้าไปในคอลเล็กชันนี้ในเดือนธันวาคม 2010 และปัจจุบันยังไม่รวมอยู่ใน SUBJECT-INFO)

แต่ละกรณี (chb01, chb02 ฯลฯ) มีไฟล์ .edf ต่อเนื่องระหว่าง 9 ถึง 42 ไฟล์จากกรณีเดียว ข้อจำกัด ของฮาร์ดแวร์ส่งผลให้เกิดช่องว่างระหว่างไฟล์ .edf ที่มีหมายเลขติดต่อกันระหว่างที่สัญญาณไม่ได้รับการบันทึก ในกรณีส่วนใหญ่ช่องว่างจะอยู่ที่ 10 วินาทีหรือน้อยกว่า แต่บางครั้งก็มีช่องว่างที่ยาวกว่ามาก เพื่อปกป้องความเป็นส่วนตัวของอาสาสมัครข้อมูลสุขภาพที่ได้รับการป้องกัน (PHD) ทั้งหมดในไฟล์ .edf ดังเดิมจะถูกแทนที่ด้วยข้อมูลตัวแทนในไฟล์ที่ให้ไว้ที่นี่

วันที่ในไฟล์ .edf ดังเดิมถูกแทนที่ด้วยวันที่ตัวแทน แต่ความสัมพันธ์ของเวลาระหว่างไฟล์แต่ละไฟล์เป็นของแต่ละเคสจะถูกเก็บรักษาไว้ในกรณีส่วนใหญ่ไฟล์ .edf จะมีสัญญาณ EEG แบบดิจิทัลหนึ่งชั่วโมง แม้ว่าไฟล์ที่เป็นของ case chb10 จะมีความยาว 2 ชั่วโมงก็ตามและไฟล์ที่เป็นของ กรณี chb04, chb06, chb07, chb09 และ chb23 นั้นมีความยาวสี่ชั่วโมง ในบางครั้งไฟล์ที่บันทึกอาการชักจะสั้นกว่า

สัญญาณทั้งหมดถูกสุ่มตัวอย่างที่ 256 ตัวอย่างต่อวินาทีด้วยความละเอียด 16 บิต ไฟล์ส่วนใหญ่มีสัญญาณ EEG 23 สัญญาณ (24 หรือ 26 ในบางกรณี) ระบบตำแหน่งอิเล็กโทรด EEG ในบันทึกไม่มีการสัญญาณอื่น ๆ จะถูกบันทึกด้วยเช่นสัญญาณ ECG ใน 36 ไฟล์ล่าสุดที่เป็นของ กรณี chb04 และสัญญาณกระตุ้นเส้นประสาท vagal (VNS) ใน 18 ไฟล์สุดท้ายที่เป็นของ กรณี chb09 ในบางกรณีสัญญาณ "dummy" (ชื่อ "-") มากถึง 5 ตัว สลับกันระหว่างสัญญาณ EEG เพื่อให้ได้รูปแบบการแสดงผลที่อ่านง่าย สัญญาณจำลองเหล่านี้สามารถละเว้นได้ ไฟล์ RECORDS มีรายการไฟล์ 664 .edf ทั้งหมดที่รวมอยู่ในคอลเล็กชันนี้และไฟล์ RECORDS-WITH-SEIZURES จะแสดงรายการไฟล์เหล่านั้น 129 ไฟล์ที่มีอย่างน้อยหนึ่งรายการ โดยรวมแล้วบันทึกเหล่านี้รวม 198 อาการชัก (182 ในชุดเดิม 23 ราย) จุดเริ่มต้น และจุดสิ้นสุดของแต่ละครั้ง มีคำอธิบายประกอบอยู่ในไฟล์คำอธิบายประกอบ .seizure ที่มาพร้อมกับไฟล์แต่ละไฟล์ที่ระบุไว้ใน RECORDS-WITH-SEIZURES นอกจากนี้ไฟล์ชื่อ chbnn-summary.txt ยังมีข้อมูลเกี่ยวกับการติดต่อที่ใช้สำหรับการบันทึกแต่ละครั้งและเวลาที่ผ่านไปเป็นวินาทีตั้งแต่จุดเริ่มต้นของไฟล์ .edf ไปจนถึงจุดเริ่มต้นและจุดสิ้นสุดของแต่ละครั้งที่อยู่ในไฟล์ ในรูปที่ 3.1 แสดงการจัดรูปแบบไฟล์ดั้งเดิม



รูปที่ 3.1 ไฟล์ชุดข้อมูล 24 กรณี 24 โพลเดอร์


Case	Gender	Age (year)	Number of event	Duration (hour)
chb01	F	11	7	40
chb02	M	11	3	35
chb03	F	14	7	38
chb04	M	22	4	156
chb05	F	7	5	39
chb06	F	1.5	10	66
chb07	F	14.5	3	67
chb08	M	3.5	5	20
chb09	F	10	4	67
chb10	M	3	7	50
chb11	F	12	3	34
chb12	F	2	40	23
chb13	F	3	12	33
chb14	F	9	8	26
chb15	M	16	20	40
chb16	F	7	10	19
chb17	F	12	3	21
chb18	F	18	6	35
chb19	F	19	3	29
chb20	F	6	8	27
chb21	F	13	4	32
chb22	F	9	3	31
chb23	F	6	7	26
chb24	-	-	16	21

รูปที่ 3.2 ข้อมูลเฉพาะของแต่ละกรณี

ในรูปที่ 3.1 เป็นรูปที่แสดงโฟลเดอร์ทั้งหมดของการจัดเก็บข้อมูลคลื่นไฟฟ้าสมองที่มีการบันทึกของแต่ละกรณี ในรูปที่ 3.2 เป็นรูปที่แสดงข้อมูลที่เกี่ยวข้องของแต่ละกรณีที่มีการบันทึกได้แก่ เพศ อายุ จำนวนการชัก และ ข้อมูลเวลาที่มีการบันทึกไว้

3.3 การเตรียมสัญญาณ

จัดกลุ่มชุดข้อมูลในแต่ละกรณี โดยทำการแยกกลุ่มไฟล์ที่มีระบุการเกิดอาการชัก กับไฟล์ที่เป็นปกติ ออกจากกันเพื่อให้ง่ายต่อการเรียกใช้ข้อมูลในการฝึกสอน โมเดลการทดสอบ ดังรูปที่ 3.3 ได้ทำการจัดเก็บชุดข้อมูลแบบแยกชนิดของไฟล์สัญญาณปกติกับผิดปกติออกจากกัน



รูปที่ 3.3 จัดกลุ่มชุดข้อมูลให้อยู่ในโฟลเดอร์เดียวกัน

ในการแยกชนิดของสัญญาณดังรูปที่ 3.3 สามารถที่จะเขียนอัลกอริทึมให้อ่านรูปแบบการจำแนกได้ง่ายขึ้น

	chb01_01.edf	16/5/2553 10:19	EDF File
	chb01_02.edf	16/5/2553 10:19	EDF File
	chb01_05.edf	16/5/2553 10:19	EDF File
	chb01_06.edf	16/5/2553 10:19	EDF File
	chb01_07.edf	16/5/2553 10:19	EDF File
	chb01_08.edf	16/5/2553 10:19	EDF File
	chb01_09.edf	16/5/2553 10:19	EDF File
	chb01_10.edf	16/5/2553 10:19	EDF File
	chb01_11.edf	16/5/2553 10:19	EDF File
	chb01_12.edf	16/5/2553 10:19	EDF File
	chb01_13.edf	16/5/2553 10:19	EDF File
	chb01_14.edf	16/5/2553 10:19	EDF File
	chb01_17.edf	16/5/2553 10:19	EDF File
	chb01_19.edf	16/5/2553 10:19	EDF File
	chb01_20.edf	16/5/2553 10:19	EDF File
	chb01_22.edf	16/5/2553 10:19	EDF File
	chb01_23.edf	16/5/2553 10:19	EDF File
	chb01_24.edf	16/5/2553 10:19	EDF File
	chb01_25.edf	16/5/2553 10:19	EDF File
	chb01_27.edf	16/5/2553 10:19	EDF File
	chb01_29.edf	16/5/2553 10:19	EDF File

รูปที่ 3.4 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ


ในรูปที่ 3.4 แสดงการจัดเก็บไฟล์สัญญาณคลื่นไฟฟ้าสมองที่เป็นชนิดปกติ โดยจะมีการใช้การจัดลำดับด้วยหมายเลขตาม

chb01_03.edf	16/5/2553 10:19	EDF File
chb01_03.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_04.edf	16/5/2553 10:19	EDF File
chb01_04.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_15.edf	16/5/2553 10:19	EDF File
chb01_15.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_16.edf	16/5/2553 10:19	EDF File
chb01_16.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_18.edf	16/5/2553 10:19	EDF File
chb01_18.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_21.edf	16/5/2553 10:19	EDF File
chb01_21.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_26.edf	16/5/2553 10:19	EDF File
chb01_26.edf.seizures	7/6/2553 9:26	SEIZURES File


รูปที่ 3.5 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก

ในรูปที่ 3.5 แสดงการจัดเก็บไฟล์สัญญาณคลื่นไฟฟ้าสมองที่เป็นชนิดผิดปกติขณะที่มีอาการชัก โดยจะมีการใช้การจัดลำดับด้วยหมายเลขตาม และเนื่องจากไฟล์ดั้งเดิมจะมีการเพิ่มไฟล์ที่ใช้ในการระบุว่า ไฟล์ในลำดับที่เท่าไรเป็นไฟล์ที่มีสัญญาณผิดปกติอยู่ด้วย

ตัวอย่างลักษณะของคลื่นไฟฟ้าสมองจากชุดข้อมูลที่ใช้ในงานวิจัยนี้




รูปที่ 3.6 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองช่วงปกติ




รูปที่ 3.7 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองช่วงที่มีการชัก

จากรูปที่ 3.6 และ 3.7 แสดงลักษณะของสัญญาณคลื่นไฟฟ้าสมองช่วงปกติและผิดปกติ โดยการใช้การสร้างกราฟแบบเจาะจงเพื่อขยายให้เห็นถึงช่วงเวลา ที่ได้ทำการบันทึกสัญญาณได้ชัดเจน ขึ้น เมื่อเปรียบเทียบทั้งสองภาพจะเห็นถึงลักษณะของสัญญาณที่เปลี่ยนไป ซึ่งเห็นถึงความไม่คงที่ของคลื่นไฟฟ้าสมองที่มีอาการชักเกิดขึ้น




รูปที่ 3.8 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์




รูปที่ 3.9 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์

จากรูปที่ 3.8 และ 3.9 แสดงคลื่นไฟฟ้าสมองที่เป็นปกติและที่มีอาการชัก สามารถเห็นได้ถึง ความแตกต่าง แต่ด้วยสัญญาณคลื่นไฟฟ้าสมองมีความซับซ้อนของแถบความถี่บางชนิด ซึ่งทำให้ไม่สามารถมองเห็นได้จากการแสดงค่าโดยตรง รวมไปถึงขนาดของจำนวนตัวอย่างที่มีจำนวนมาก ซึ่งจำเป็นที่จะต้องใช้เวลาในการประมวลและแสดงผลออกมา จำเป็นที่จะมีกระบวนการที่ช่วยในการลดขนาดข้อมูลลง แต่ยังคงมีลักษณะเฉพาะสัญญาณนั้นอยู่

เนื่องด้วยไฟล์สัญญาณในชุดข้อมูลนี้ถูกบันทึกมีขนาดระยะเวลาที่ต่างกัน รวมไปถึงไฟล์ที่มีการระบุว่าเป็นไฟล์ที่มีอาการชักของอาสาสมัครก็เป็นไฟล์ที่บันทึกทั้งสัญญาณคลื่นไฟฟ้าสมองที่เป็นปกติและมีอาการชักอยู่ภายในไฟล์เดียวกัน



รูปที่ 3.10 กรอบสีเขียวแสดงลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติก่อนการชัก




รูปที่ 3.11 กรอบสีแดงแสดงลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติขณะการชัก

จากรูปที่ 3.10 เป็นรูปที่แสดงลักษณะของสัญญาณก่อนที่จะเกิดอาการชักในการอบสีเขียว เห็นได้ชัดว่าเป็นลักษณะสัญญาณที่ดูนิ่งเป็นปกติ มีค่าความถี่และแอมพลิจูดที่ไม่สูงโดดเด่น เมื่อเปรียบเทียบกับรูปที่ 3.11 เป็นรูปที่แสดงลักษณะของสัญญาณก่อนที่จะเกิดอาการชักในการอบสีแดง จะเห็นได้ชัดว่ามีความแตกต่างจากค่าก่อนหน้าในการอบสีเขียว ค่าในการอบสีแดงแสดงถึงความผิดปกติขณะมีอาการชัก ซึ่งมีค่าความถี่และค่าแอมพลิจูดที่ไม่คงที่

เมื่อทำการอ่านไฟล์สัญญาณคลื่นไฟฟ้าสมองที่เป็นปกติและที่มีอาการชักอยู่ในไฟล์ ดังแสดงในรูปที่ 3.10 และ 3.11 จะเห็นว่าใน 1 ไฟล์สัญญาณของแต่ละกรณี จะมีสัญญาณคลื่นไฟฟ้าสมองที่ถูกบันทึกจากบริเวณต่าง ๆ ของสมองเก็บเป็นของแต่ละช่องสัญญาณ โดยชื่อช่องสัญญาณเป็นการระบุตำแหน่งดังนี้

FP	: Front parietal	= สมองกลีบหน้าผาก
F	: Frontal lobe	= สมองกลีบหน้า
C	: Central sulcus	= ร่องกลางของสมอง
T	: Temporal lobe	= สมองกลีบขมับ
P	: Parietal lobe	= สมองกลีบข้าง
O	: Occipital lobe	= สมองกลีบท้ายทอย




รูปที่ 3.12 ตำแหน่งของการบันทึกคลื่นไฟฟ้าสมอง

3.4 กระบวนการสกัดคุณลักษณะเด่นของสัญญาณ

กระบวนการสกัดคุณลักษณะเด่นของสัญญาณ เป็นกระบวนการที่สกัดคุณลักษณะเด่นของชุดข้อมูลออกมา เพื่อใช้ข้อมูลที่สกัดออกมาได้นั้นสร้างแบบจำลอง (Model Training) สำหรับนำไปทดสอบกับชุดทดสอบ โดยขั้นตอนของการสกัดคุณลักษณะเด่นที่จะใช้ในงานวิจัยนี้จะใช้เทคนิคการสกัดคุณลักษณะเด่นชื่อว่า Tunable Q-factor Wavelet Transform (TQWT) ร่วมกับค่าทางสถิติ (Statistical)

3.4.1. Tunable Q-factor Wavelet Transform (TQWT) เป็นการแปลงคลื่นเวลาแบบไม่ต่อเนื่องซึ่งระบุปัจจัย Q โดยง่าย ซึ่งสามารถปรับได้ตามพฤติกรรมการสั่นของสัญญาณที่ใช้ การแปลงขึ้นอยู่กับปัจจัยการวัดค่าตามความเป็นจริง (ปัจจัยการขยายตัว) และดำเนินการโดยใช้ตัวกรองที่สร้างขึ้นใหม่อย่างสมบูรณ์แบบด้วยปัจจัยการสุมตัวอย่างที่มีค่าจริง มีการนำเสนอการแปลงสองรูปแบบ รูปแบบแรกถูกกำหนดสำหรับสัญญาณเวลาไม่ต่อเนื่องที่กำหนดไว้ใน Z ทั้งหมดรูปแบบที่สองถูกกำหนดสำหรับสัญญาณเวลาไม่ต่อเนื่องที่มีความยาว จำกัด และสามารถนำไปใช้กับ FFT ได้อย่างมีประสิทธิภาพ การแปลงถูกกำหนดพารามิเตอร์โดย Q -factor และอัตราการสุมตัวอย่างเกินขนาด (ซ้ำซ้อน) โดยมีอัตราการสุมตัวอย่างมากเกินไป (เช่น 3-4 ครั้งมากเกินไป) เพียงพอสำหรับฟังก์ชันการวิเคราะห์

การสกัดคุณลักษณะโดยใช้ TQWT แบบหลายขั้นตอน สามารถทำได้ง่ายโดยอาศัยการกรองย่านความถี่ซ้ำ ๆ กับสัญญาณย่านความถี่ย่อยความถี่ต่ำ TQWD ระดับ J แสดงอยู่ในรูป 3.13 ในแต่ละระดับของการสลายตัวสัญญาณอินพุต ที่มีอัตราการสุมตัวอย่างจะถูกแปลงเป็นสัญญาณย่านความถี่ต่ำและสัญญาณย่านความถี่ย่อยความถี่สูงที่มีความถี่การสุมตัวอย่าง และ βf_s ตามลำดับ โดยที่ αf_s และ βf_s เป็นพารามิเตอร์การปรับขนาด เพื่อที่จะได้รับย่านความถี่ต่ำจะใช้ตัวกรองความถี่ต่ำ $F_0(\omega)$ และอัตราการสุมสัญญาณความถี่ต่ำซึ่งแสดงเป็น LPS α ในทำนองเดียวกันแถบย่อยความถี่สูงจะได้รับโดยใช้ $F_1(\omega)$ และ HPS β LPS α และ HPS β รักษาส่วนประกอบความถี่ต่ำและความถี่สูงของสัญญาณขึ้นอยู่กับพารามิเตอร์มาตราส่วน α และ β ตามลำดับ



รูปที่ 3.13 การสลายตัวระดับ J โดยใช้ TQWT

รูปที่ 3.13 แสดงลำดับของการสลายแถบความถี่แต่ละระดับ ที่ถูกใช้ในเทคนิค TQWT TQWT ใช้ตัวกรองความถี่ต่ำและความถี่สูงต่อไปนี้

$$F_0(\omega) = \begin{cases} 1, & |\omega| < (1-\beta)\pi \\ \theta\left(\frac{\omega + (\beta-1)\pi}{\alpha + \beta - 1}\right), & (1-\beta)\pi \leq |\omega| < \alpha\pi \\ 0, & \alpha\pi \leq |\omega| \leq \pi \end{cases} \quad (3.1)$$

$$F_0(\omega) = \begin{cases} 0, & |\omega| < (1-\beta)\pi \\ \theta\left(\frac{\alpha\pi - \omega}{\alpha + \beta - 1}\right), & (1-\beta)\pi \leq |\omega| < \alpha\pi \\ 1, & \alpha\pi \leq |\omega| \leq \pi \end{cases} \quad (3.2)$$

โดยที่ในสมการข้างต้น $\theta(\omega)$ คือฟังก์ชันเสริม 2-periodic power ที่เลือกเป็นการตอบสนองความถี่ของตัวกรอง Daubechies ที่มีช่วงเวลาที่หายไปสองช่วงเวลา $\theta(\omega)$ สามารถกำหนดได้ด้วยต่อไปนี้


$$\theta(\omega) = 0.5(1 + \cos(\omega))(2 - \cos(\omega))^{1/2}, \quad |\omega| \leq \pi \quad (3.3)$$

สัญญาณอินพุตดั้งเดิมสามารถสร้างขึ้นใหม่ด้วยแถบย่อยที่เลือก โดยใช้ตัวกรองที่คล้ายกับที่ใช้ในขณะทำการแยกชิ้นส่วน พารามิเตอร์ r และ Q-factor สามารถกำหนดได้ในเงื่อนไขของพารามิเตอร์ตัวกรอง α และ β ดังต่อไปนี้

$$r = \frac{\beta}{1 - \alpha} \quad (3.4)$$


$$Q = \frac{f_c}{BW} = \frac{2 - \beta}{\beta} \quad (3.5)$$

โดยที่ f_c และ BW คือความถี่กลางและแบนด์วิดท์ของการตอบสนองความถี่ย่อย $J f_1^{(J)}$ ที่ได้รับหลังจากสร้างด้วย J-levels ของการสลายตัวของ $s[n]$




รูปที่ 3.14 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์

รูปที่ 3.14 เป็นการแสดงภาพรวม เมื่อนำสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน ตามเวลาทำการบันทึกได้จากการสุ่มตัวอย่าง 256 Hz มาแสดงอยู่ในรูปของกราฟ




รูปที่ 3.15 ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ปกติในช่องสัญญาณที่ 1

รูปที่ 3.15 เป็นการแสดงภาพสัญญาณที่เป็นปกติ เมื่อถูกสลายแถบความถี่ออกมาได้ 5 ชั้น ด้วยเทคนิค TQWT



รูปที่ 3.16 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์

รูปที่ 3.16 เป็นการแสดงภาพรวม เมื่อนำสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ตามเวลาที่ทำการบันทึกได้จากการสุ่มตัวอย่าง 256 Hz มาแสดงอยู่ในรูปของกราฟ



รูปที่ 3.17 ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติในช่องสัญญาณที่ 1

รูปที่ 3.17 เป็นการแสดงสัญญาณผิดปกติ เมื่อถูกสลายแถบความถี่ออกได้ 5 ชั้น ด้วยเทคนิค TQWT

3.4.2 การสกัดข้อมูลด้วยค่าทางสถิติ หรือ Statistical feature extracted method วิธีการทางสถิติเป็นส่วนที่เสนอและใช้เพื่อแยกคุณลักษณะทางสถิติที่เป็นตัวแทน มีผลต่อประสิทธิภาพของลักษณะที่เด่นชัดของชุดข้อมูล หากไม่ได้เลือกคุณสมบัติไว้อย่างดี วิธีการทางสถิติประกอบด้วยสองขั้นตอนการแบ่งส่วนและการแยกคุณลักษณะทางสถิติ สัญญาณ EEG มีลักษณะไม่เป็นเชิงเส้นและไม่อยู่นิ่ง ซึ่งทำให้การวิเคราะห์และการจำแนกเป็นเรื่องยาก ซึ่งในงานวิจัยนี้จะนำคลื่นไฟฟ้าสมองที่ผ่านกระบวนการสลายแถบความถี่แล้ว มาผ่านการลดขนาดสัญญาณด้วยการสกัดข้อมูลทางสถิติ ในการสกัดดังนั้นจะใช้ข้อมูลทางสถิติ 6 ชนิดได้แก่ Maximum (Max), Variance (Var), Skewness (Sk), Kurtosis (Ku), Mean (Mean) และ Entropy (En)

3.4.2.1 Maximum คือ ค่าองค์ประกอบสูงสุดของข้อมูล

$$Max = \max(xn) \quad (3.6)$$

3.4.2.2 Variance คือ ค่าแปรปรวน ใช้เพื่อวัดการกระจายของข้อมูลคิดจากค่าเฉลี่ยของความต่างจากค่าเฉลี่ยยกกำลัง 2

$$Var = \sum_{n=1}^N (X_n - SM) \frac{2}{N-1} \quad (3.7)$$

3.4.2.3 Skewness คือ ค่าความเบ้บอกถึงการเบี่ยงเบนของข้อมูล

$$SK = \sum_{n=1}^N (X_n - SM) \frac{3}{(N-1)SD^3} \quad (3.8)$$

3.4.2.4 Kurtosis คือ ค่าความโด่งเป็นตัวชี้วัดทางสถิติที่ใช้อธิบายการกระจายตัว

$$\alpha_4 = \frac{\sum_{i=1}^m (x_i - \bar{x})^4}{m\sigma^4} \quad (3.9)$$


3.4.2.5 Mean คือ ค่าเฉลี่ยของชุดข้อมูล

$$Mean = \frac{1}{n} \sum_{i=1}^n x_n \quad (3.10)$$


3.4.2.6 Entropy คือ ปริมาณ ที่บอกถึงความไม่เป็นระเบียบของระบบ ซึ่งในงานวิจัยนี้จะใช้ค่า Wavelet Entropy สำหรับข้อมูลคลื่นไฟฟ้าสมอง

$$E(s) = \sum_i E_n(S_i) \quad (3.11)$$


3.4.3 การรวมชุดข้อมูล เป็นการรวบรวมข้อมูลที่ผ่านการการสกัดคุณลักษณะเด่นจากการสลายแถบความถี่และผ่านวิธีการลดข้อมูลด้วยค่าทางสถิติแล้ว โดยข้อมูลคลื่นไฟฟ้าสมองแต่ละกรณีที่ผ่านมากระบวนการนี้แล้วจะถูกลดขนาดข้อมูลลง แต่ยังคงเก็บลักษณะเด่นของข้อมูลไว้ได้ โดยในรูปที่ 3.18 ได้แสดงส่วนที่จะทำการรวบรวมข้อมูลจากการสกัดคุณลักษณะเด่น



รูปที่ 3.18 รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่น



รูปที่ 3.19 รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่น โดยการหาค่าทางสถิติ 5 แบบของไฟล์สัญญาณปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์



รูปที่ 3.20 รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่น โดยการหาค่าทางสถิติ 5 แบบของไฟล์สัญญาณผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์

จากรูปที่ 3.19 และ 3.20 เป็นการทดลองหาค่าทางสถิติ 5 แบบ ได้แก่ ค่า Variance, Skewness, Kurtosis, Mean และ Entropy โดยใช้หาหลังจากแถบความถี่ที่หาได้ด้วยวิธี TQWT ซึ่งมีการใช้งานวิจัยที่ได้ศึกษา จึงได้นำค่าทางสถิติในงานวิจัยก่อนหน้ามาทดสอบกับชุดข้อมูลชุดนี้

ซึ่งจะเห็นความแตกต่างที่ค่า Entropy บนแถบความถี่ที่ 5 เมื่อเป็นสัญญาณปกติจะมีค่าที่ต่ำกว่าอย่างชัดเจนเทียบกับค่า Entropy บนแถบความถี่เดียวกันที่ได้จากสัญญาณผิดปกติ แต่ในส่วนของค่า Entropy บนแถบความถี่ที่ 5 จากสัญญาณผิดปกติ จะมีค่าที่เกาะกลุ่มกันซึ่งเห็นได้ชัดเจนมากกว่า

3.5 การสร้างแบบจำลองข้อมูล (Model Training)

การสร้างแบบจำลองข้อมูลที่จะนำไปใช้ในกระบวนการจำแนก ในงานวิจัยนี้จะใช้การสร้างแบบจำลองข้อมูล 3 ชนิด คือ 1. Gaussian Mixture Model (GMM) 2. Kernel Extreme Learning Machine (KELM) 3. Least-squares support-vector machine (LS-SVM) ซึ่งทั้ง 3 ชนิดนี้จะถูกใช้ในการจำแนกคลื่นไฟฟ้าสมองที่เป็นปกติและที่มีอาการชัก

3.5.1 Gaussian Mixture Model (GMM)

Gaussian Mixture Model (GMM) คือฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบพารามตริกที่แสดงเป็นผลรวมถ่วงน้ำหนักของความหนาแน่นของส่วนประกอบ Gaussian GMM มักใช้เป็นแบบจำลองพารามิเตอร์ของการแจกแจงความน่าจะเป็น ของการวัดค่าต่อเนื่องหรือคุณลักษณะต่าง ๆ ในระบบไบโอเมตริกซ์เช่นคุณสมบัติสเปกตรัมที่เกี่ยวข้องกับเส้นเสียง ในระบบจดจำผู้พูด พารามิเตอร์ GMM ประมาณจากข้อมูลการฝึกอบรมโดยใช้อัลกอริทึม Expectation-Maximization (EM) แบบวนซ้ำ หรือ การประมาณค่า Maximum A Posteriori (MAP) จากแบบจำลองก่อนที่ได้รับการฝึกฝนมาเป็นอย่างดี

แบบจำลอง GMM คือผลรวมถ่วงน้ำหนักขององค์ประกอบ M ความหนาแน่นของเกาส์เขียนตามสมการ

3.5.2 Kernel Extreme Learning Machine (KELM)

Kernel Extreme Learning Machine (KELM) ได้รับการพิสูจน์แล้วว่าเป็นอัลกอริทึม ที่มีประสิทธิภาพสำหรับงานจำแนกประเภทต่างๆและยังสามารถให้ประสิทธิภาพที่คาดหวังสำหรับการจำแนกคลื่นสมอง นี่เป็นเพราะลักษณะทั่วไปที่ดีโดยอาศัยเครื่องการเรียนรู้ขั้นสูงสุด (ELM) และข้อได้เปรียบของฟังก์ชันเคอร์เนล ในแง่ของการจัดประเภทที่มีประสิทธิภาพเพื่อทำแผนที่คุณลักษณะที่ไม่ใช่เชิงเส้น KELM ขึ้นอยู่กับ ELM ซึ่งมีการนำฟังก์ชันเคอร์เนลการแมปมาแทนที่ เลเยอร์ที่ซ่อนอยู่ของ ELM มีประสิทธิภาพสูงกว่าเมื่อเทียบกับวิธีอื่น ๆ มีลักษณะดังรูปที่

3.21

ใน KELM เราสามารถใช้ฟังก์ชันเคอร์เนลโดยตรงสำหรับการจับคู่คุณลักษณะ เคอร์เนลเมตริกซ์สามารถแสดงได้โดยใช้สมการต่อไปนี้

$$\Omega_{KELM} = HH^T \quad (3.12)$$

โดยที่ H คือเมทริกซ์เอาต์พุตของเลเยอร์ที่ซ่อนอยู่ Ω_{KELM} เป็นฟังก์ชันเคอร์เนล


$$\Omega_{KELM} = h(x_r).h(x_s) = K(x_r, x_s) \quad (3.13)$$

เนื่องจากใช้อินเวอร์สทั่วไปของ Moore – Penrose ในการคำนวณน้ำหนักเอาต์พุต ฟังก์ชันเอาต์พุตของลักษณะนามที่ใช้ KELM สามารถแสดงได้ดังต่อไปนี้

$$f(x) = \begin{bmatrix} K(x, x_1) \\ K(x, x_2) \\ \vdots \\ K(x, x_N) \end{bmatrix} \left(\frac{1}{C} + \Omega_{KELM} \right)^{-1} T \quad (3.14)$$

โดยที่ T หมายถึงเมทริกซ์เป้าหมาย (ฉลาก) คล้ายกับ SVM ฉันทคือเมทริกซ์เอกลักษณ์ C หมายถึงค่าสัมประสิทธิ์การทำให้สม่ำเสมอ สำหรับขั้นตอนการทดสอบการตัดสินใจของคลาสความปกติกับอาการชักในสัญญาณคลื่นไฟฟ้าสมอง จะขึ้นอยู่กับความแตกต่างของสองคลาสดังต่อไปนี้

$$\Lambda_{KELM}(Y) = P(t_{circle} | f(Y)) - P(t_{line} | f(Y)) \quad (3.15)$$



รูปที่ 3.21 ภาพแสดงการหาค่าน้ำหนักใน KELM

3.5.3 Least-squares support-vector machine (LS-SVM)

SVM LS-SVM เป็นหนึ่งในโมเดลแมชชีนเลิร์นนิงที่ล้ำสมัย เป็น SVM เวอร์ชันกำลังสอง น้อยที่สุดและพัฒนาขึ้นจากหลักการลดความเสี่ยงเชิงโครงสร้างและทฤษฎีการทำแผนที่เคอร์เนล หากใช้ LS-SVM ร่วมกับ SVM ความแตกต่างสองประการจะเกิดขึ้น 1.ฟังก์ชัน empirical risk ของ SVM เป็นขั้นแรกในขณะที่ LS-SVM เป็นขั้นอันดับสองของปัจจัยการคลาย 2.เงื่อนไขข้อจำกัด ของ SVM เป็นอสมการในขณะที่สมการถูกแทนที่ด้วยความเท่าเทียมกันใน LS-SVM ความแตกต่างนำไปสู่การแก้ปัญหาของ SVM และ LS-SVM ที่แตกต่างกันโดยสิ้นเชิง ปัญหาการเขียนโปรแกรมกำลังสองจำเป็นต้องได้รับการแก้ไขใน SVM ในขณะที่ LS-SVM ต้องการเพียงการแก้ชุดของ linear equations ดังนั้น LS-SVM จึงมีความเร็วในการคำนวณที่เร็วกว่า SVM

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}, x_i \in \mathbb{R}^n, y_i \in \{-1, 1\} \quad (3.16)$$

เป็นชุดการฝึกอบรมปัญหาการเพิ่มประสิทธิภาพของ LS-SVM


$$\min J(\omega, \xi) = \|\omega\|^2 / 2 + (c / 2) \sum_{i=1}^l \xi_i^2 \quad (3.17)$$

$$\text{s.t. } y_i [\phi(x_i) \cdot \omega + b] = 1 - \xi_i \quad (3.18)$$

โดยที่ $\phi(x_i)$ คือฟังก์ชันการจับคู่ที่รับผิชอบการแมปอินพุตกับพื้นที่มิติที่สูงขึ้น ω, b, C และเป็นตัววัดน้ำหนักอคติพารามิเตอร์การทำให้เป็นมาตรฐานและข้อผิดพลาดตามลำดับ

3.6 การแบ่งชุดข้อมูลสำหรับสร้างโมเดลฝึกฝนและทดสอบ

K-Fold Cross Validation คือ การแบ่งข้อมูลเป็น k ส่วนเท่า ๆ กันเพื่อสร้างและทดสอบโมเดล เพื่อใช้คำนวณค่าเฉลี่ยความถูกต้อง (accuracy) หรือ ค่าความผิดพลาด (error) ก่อนที่จะนำโมเดลไปใช้ทำนายชุดข้อมูล แบ่งข้อมูลเป็น K folds นั้นก็คือการแบ่งชุดข้อมูลเป็นชุด ๆ เพื่อใช้สำหรับการฝึกสอนและทดสอบ โดยกำหนดให้จำนวน K เป็นจำนวนชุดที่จะแบ่ง ซึ่งที่นิยมใช้กัน ในทางปฏิบัติมีสองค่าคือ $K=5$ หรือ $K=10$ โดยในงานนี้ผู้วิจัยได้จัดการแบ่งข้อมูลเป็น $K=5$ folds ดังแสดงในรูปที่ 3.22



รูปที่ 3.22 รูปแบบการจัดชุดข้อมูลด้วยวิธี K-Fold Cross Validation

จากรูปที่ 3.22 แสดงลักษณะเมื่อแบ่งข้อมูลเสร็จแล้ว ที่จำนวน $K=5$ สร้างและทดสอบโมเดลจนกว่าข้อมูลทุก fold จะถูกนำมาใช้ ถ้า $K=5$ จะต้องเทรน โมเดลทั้งหมด 5 รอบ ด้วยชุดฝึกสอน (Train folds) และทดสอบโมเดลทั้งหมด 5 รอบ ด้วยชุดทดสอบ (Validation fold)

All Data				
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
chb01	chb06	chb11	chb16	chb21
chb02	chb07	chb12	chb17	chb22
chb03	chb08	chb13	chb18	chb23
chb04	chb09	chb14	chb19	chb24
chb05	chb10	chb15	chb20	

รูปที่ 3.23 การจัดข้อมูลสำหรับงานวิจัยนี้มี 24 กรณี

จากรูปที่ 3.23 ผู้วิจัยกำหนดชุดข้อมูลแต่ละ fold ดังนี้

3.6.1 Fold 1 กำหนดให้เก็บชุดข้อมูลกรณี chb01 chb02 chb03 chb04 และ chb05

3.6.2 Fold 2 กำหนดให้เก็บชุดข้อมูลกรณี chb06 chb07 chb08 chb09 และ chb10

3.6.3 Fold 3 กำหนดให้เก็บชุดข้อมูลกรณี chb11 chb12 chb13 chb14 และ chb15


3.6.4 Fold 4 กำหนดให้เก็บชุดข้อมูลกรณี chb16 chb17 chb18 chb19 และ chb20

3.6.5 Fold 5 กำหนดให้เก็บชุดข้อมูลกรณี chb21 chb22 chb23 และ chb24

ซึ่งกระบวนการ Fold Cross Validation จะใช้เป็นการจัดกลุ่มข้อมูล ก่อนที่จะนำข้อมูลที่จัดกลุ่มแล้วไปเข้าวิธีการฝึกสอนโมเดลของชนิดการจำแนกทั้ง 3 ชนิด

3.7 กระบวนการทดสอบ

จากกระบวนการ Fold Cross Validation ที่ใช้ทำการจัดกลุ่มชุดข้อมูลสำหรับฝึกสอนโมเดล กระบวนการนี้จะถูกนำมาใช้สำหรับทำการทดสอบชุดข้อมูลเช่นกันดังนี้



รูปที่ 3.24 แสดงชุดข้อมูลที่ใช้ฝึกสอนและทดสอบ

จากรูปที่ 3.24 บอกถึงวิธีการนำกลุ่มชุดข้อมูลแต่ละ Fold ไปทำการทดสอบ ซึ่งอธิบายได้ดังนี้

ทดสอบครั้งที่ 1 คือ ใช้กลุ่มข้อมูล Fold 2 Fold 3 Fold 4 และ Fold 5 เป็นชุดข้อมูลสำหรับฝึกสอน เพื่อทดสอบกลุ่มข้อมูล Fold 1

ทดสอบครั้งที่ 2 คือ ใช้กลุ่มข้อมูล Fold 1 Fold 3 Fold 4 และ Fold 5 เป็นชุดข้อมูลสำหรับฝึกสอน เพื่อทดสอบกลุ่มข้อมูล Fold 2

ทดสอบครั้งที่ 3 คือ ใช้กลุ่มข้อมูล Fold 1 Fold 2 Fold 4 และ Fold 5 เป็นชุดข้อมูลสำหรับฝึกสอน เพื่อทดสอบกลุ่มข้อมูล Fold 3

ทดสอบครั้งที่ 4 คือ ใช้กลุ่มข้อมูล Fold 1 Fold 2 Fold 3 และ Fold 5 เป็นชุดข้อมูลสำหรับฝึกสอน เพื่อทดสอบกลุ่มข้อมูล Fold 4

ทดสอบครั้งที่ 5 คือ ใช้กลุ่มข้อมูล Fold 1 Fold 2 Fold 3 และ Fold 4 เป็นชุดข้อมูลสำหรับฝึกสอน เพื่อทดสอบกลุ่มข้อมูล Fold 5

วิธีที่ใช้หาค่าความถูกต้องโดย ตารางวัดความถูกต้องหรือเมตริกซ์วัดประสิทธิภาพ (Confusion Matrix) คือตารางที่แสดงผลลัพธ์ในการวัดที่ได้จากการฝึกฝนหรือการจำแนกข้อมูล

โดยเทียบระหว่างผลลัพธ์จริงและผลลัพธ์ในการทำนาย ดังรูปที่ 3.25 แสดงเมทริกซ์ขนาด 2x2 เป็นผลลัพธ์ที่จำแนกข้อมูล 2 คลาส คือคลาสบวก (Positive Class) และคลาสลบ (Negative Class)

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

รูปที่ 3.25 เมทริกซ์วัดประสิทธิภาพ

จากรูปที่ 3.25 ค่าที่ได้จากเมทริกซ์วัดประสิทธิภาพในกรณีที่มีข้อมูล 2 คลาส สามารถแบ่งออกเป็น 4 กรณีได้ดังนี้

True Positive (TP) คือ ผลที่ทำนายว่า “จริง” แล้วตรงกับผลลัพธ์ที่เกิดขึ้น “จริง”

True Negative (TN) คือ ผลที่ทำนายว่า “ไม่จริง” แล้วตรงกับผลลัพธ์ที่เกิดขึ้น “ไม่จริง”

False Positive (FP) คือ ผลที่ทำนายว่า “ไม่จริง” แต่ผลลัพธ์ที่เกิดขึ้น “จริง”

False Negative (FN) คือ ผลที่ทำนายว่า “จริง” แต่ผลลัพธ์ที่เกิดขึ้น “ไม่จริง”

3.7.1 ค่าความแม่นยำในการจำแนกข้อมูล (Accuracy) คือค่าความแม่นยำในการจำแนกข้อมูลว่าถูกต้องอยู่ในระดับใด ซึ่งสามารถคำนวณได้ดังสมการด้านล่างนี้

$$Accuracy (\%) = \frac{(TP + TN)}{(TP + FN + FP + TN)} \times 100 \quad (3.19)$$

3.7.2 ค่าความไว (Sensitivity) คือสัดส่วนผลบวกที่เป็นจริงสำหรับภาวะนั้น

$$Sensitivity (\%) = \frac{TP}{TP + FN} \times 100 \quad (3.20)$$

3.7.3 ความจำเพาะ (Specificity) คือสัดส่วนผลลบที่เป็นจริงสำหรับภาวะนั้น

$$Specificity (\%) = \frac{TN}{TN + FP} \times 100 \quad (3.21)$$

วิธีการหาค่าความแม่นยำ ค่าความไว และความจำเพาะ จะถูกนำมาใช้ในการทดสอบทุกชนิดของวิธีการจำแนกทั้ง 3 ชนิด เพื่อหาว่าวิธีการจำแนกชนิดไหนที่มีประสิทธิภาพในการจำแนกข้อมูลคลื่นไฟฟ้าสมองที่มีความผิดปกติได้ดี

3.8 สรุป

เนื้อหาในบทนี้ได้กล่าวถึงแนวคิด โครงสร้าง และกระบวนการทำงานของเทคนิคการจำแนกคลื่นไฟฟ้าสมองที่เป็นปกติและผิดปกติจากอาการชัก โดยใช้คลื่นไฟฟ้าสมองเป็นข้อมูลในการจำแนกความแตกต่าง ซึ่งได้มีการกล่าวถึงรูปแบบการเรียนรู้ของเครื่อง เรียนรู้เพื่อจำแนกลักษณะความแตกต่างของสัญญาณ ซึ่งเริ่มจากการใช้งานชุดข้อมูลคลื่นไฟฟ้าสมองที่เป็นมาตรฐาน รวมทั้งเทคนิคการสกัดคุณลักษณะเด่น โดยแบ่งการทำงานเป็นส่วนของการสลายแถบความถี่ข้อมูลร่วมกับการลดขนาดข้อมูล ซึ่งการสลายแถบความถี่ข้อมูลใช้วิธี TQWT และลดขนาดข้อมูลด้วย 6 ค่าทางสถิติ พร้อมเสนอวิธีการจำแนกสัญญาณที่แตกต่างกัน โดยมีวิธีการจำแนก 1. Gaussian Mixture Model (GMM) 2. Kernel Extreme Learning Machine (KELM) 3. Least-squares support-vector machine (LS-SVM) ที่เป็นชนิดการเรียนรู้ของเครื่อง (Machine - Learning) สำหรับการระบุความแตกต่าง โดยการเรียนรู้ข้อมูลที่ผ่านมาการสกัดคุณลักษณะเด่นพร้อมลดขนาดข้อมูลแล้ว และนำเสนอประสิทธิภาพของวิธีการเหล่านี้ในการจำแนกความผิดปกติของสัญญาณ

บทที่ 4

ผลการศึกษา และการวิเคราะห์ผล

4.1 บทนำ

ในบทนี้จะเป็นการนำชุดข้อมูล ทั้งคลื่นไฟฟ้าสมองที่เป็นปกติกับคลื่นไฟฟ้าสมองที่มีอาการชัก การเรียนรู้ของเครื่องแบบ GMM, KELM และ LS-SVM ซึ่งจะนำมาทดสอบการจำแนก ทั้งในเรื่องของความแม่นยำของเทคนิคที่ใช้อ้างอิงและทดสอบในเรื่องของความถูกต้องของการบอกลักษณะความแตกต่างของคลื่นไฟฟ้าสมอง โดยทั้งความแม่นยำของเทคนิคที่ใช้อ้างอิงหรือการบอกลักษณะความแตกต่าง จะต้องมีความถูกต้องพอที่สามารถรับได้ จากการที่สร้างรับรู้ข้อมูลได้รวดเร็วกว่า เพื่อใช้ในการบอกความผิดปกติคลื่นไฟฟ้าสมอง


จากการพัฒนาวิธีการจำแนกสัญญาณคลื่นไฟฟ้าสมอง การออกแบบรูปแบบการเขียนวิธีการวิเคราะห์และจำแนกสัญญาณคลื่นไฟฟ้าสมอง รวมถึงการพัฒนาวิธีการสกัดคุณลักษณะเด่นของสัญญาณ และนำข้อมูลที่ได้จากการสกัดคุณลักษณะเด่นเข้ากระบวนการเรียนรู้ของเครื่องชนิด GMM, KELM และ LS-SVM เพื่อใช้ในการเรียนรู้จำโครงสร้างข้อมูลทั้ง 2 แบบในบทที่ผ่านมาสามารถสรุปผลการดำเนินงานได้ในแต่ละขั้นตอนดังนี้

- 4.1.1 ผลการจัดชุดข้อมูลก่อนนำไปเข้ากระบวนการสกัดคุณลักษณะเด่น
- 4.1.2 ผลสรุปขั้นตอนการสกัดคุณลักษณะเด่นของสัญญาณคลื่นไฟฟ้าสมอง
- 4.1.3 ผลการเก็บค่าเมื่อผ่านการสกัดคุณลักษณะเด่น
- 4.1.4 ผลการสร้างโมเดลการฝึกสอนจากชนิดของตัวจำแนก
- 4.1.5 ผลทดสอบการจำแนกสัญญาณคลื่นไฟฟ้าสมอง
- 4.1.6 สรุปท้ายบท


หัวข้อที่ 4.2 เป็นเทคนิคการสกัดลักษณะเด่นของสัญญาณ ที่ผ่านการสลายแถบความถี่สัญญาณจากแต่ละช่องสัญญาณของแต่ละไฟล์คลื่นไฟฟ้าสมอง โดยการใช้การสลายแถบความถี่ด้วยวิธี TQWT รวมกับการใช้การหาค่าทางสถิติจากข้อมูลนั้น ซึ่งชุดข้อมูลที่นำมาใช้ในการทดลองเป็นข้อมูลที่เป็นมาตรฐาน หัวข้อที่ 4.4 และ หัวข้อที่ 4.5 เป็นเทคนิคการเรียนรู้ของเครื่องที่ใช้หลักการทำงานร่วมกันระหว่างการสกัดคุณลักษณะเฉพาะตัวของสัญญาณและ GMM, KELM และ LS-SVM ใช้ในการจำแนกสัญญาณคลื่นไฟฟ้าสมองที่เป็นปกติกับคลื่นไฟฟ้าสมองที่มีอาการชัก

4.2 ผลการจัดชุดข้อมูลก่อนนำไปเข้ากระบวนการสกัดคุณลักษณะเด่น

จากการที่ได้รับชุดข้อมูลคลื่นไฟฟ้าสมอง ทำให้ทราบถึงชนิดของไฟล์ข้อมูลว่าเป็นประเภท .edf แต่ละกรณี (chb01, chb02 ฯลฯ) มีไฟล์ .edf ต่อเนื่องระหว่าง 9 ถึง 42 ไฟล์จากกรณีเดียว ในไฟล์ .edf ดังเดิมจะถูกแทนที่ด้วยข้อมูลตัวแทนในไฟล์ที่ให้ไว้ที่นี้ วันที่ในไฟล์ .edf ดังเดิมถูกแทนที่ด้วยวันที่ตัวแทน แต่ความสัมพันธ์ของเวลาระหว่างไฟล์แต่ละไฟล์ที่เป็นของแต่ละเคสจะถูกเก็บรักษาไว้ในกรณีส่วนใหญ่ไฟล์ .edf จะมีสัญญาณ EEG แบบดิจิทัลหนึ่งชั่วโมงแม้ว่าไฟล์ที่เป็นของ case chb10 จะมีความยาว 2 ชั่วโมงก็ตามและไฟล์ที่เป็นของ case chb04, chb06, chb07, chb09 และ chb23 นั้นมีความยาวสี่ชั่วโมง ในบางครั้งไฟล์ที่บันทึกอาการชักจะสั้นกว่า เดิมในโฟลเดอร์แต่ละกรณี ไฟล์ .edf จะถูกกำกับชื่อด้วยชื่อกรณีตามด้วยตัวเลขเป็นลำดับลำดับ เพื่อความสะดวกในการเรียกใช้ไฟล์สัญญาณ จึงได้ทำการจัดเก็บข้อมูลที่เป็นปกติกับผิดปกติแยกออกจากกัน



รูปที่ 4.1 ไฟล์ข้อมูลกรณีที่ 1



รูปที่ 4.2 จัดกลุ่มชุดข้อมูลให้อยู่ในโฟลเดอร์เดียวกัน

รูปที่ 4.1 แสดงลักษณะของไฟล์ที่ได้มา เป็นเพียงการจัดตามลำดับของสัญญาณที่ได้จากการบันทึกเท่านั้น ซึ่งผู้วิจัยได้นำข้อมูลสัญญาณนี้มาจัดกลุ่มใหม่เพิ่มเติมโดยการแยกชนิดสัญญาณที่เป็นปกติและผิดปกติ ให้อยู่แยกโฟลเดอร์กัน เพื่อเป็นการจำแนกในการทำการวิเคราะห์ดังที่ได้แสดงในรูปที่ 4.2 เป็นโฟลเดอร์ ปกติ (normal) และผิดปกติ (abnormal)

chb01_01.edf	16/5/2553 10:19	EDF File
chb01_02.edf	16/5/2553 10:19	EDF File
chb01_05.edf	16/5/2553 10:19	EDF File
chb01_06.edf	16/5/2553 10:19	EDF File
chb01_07.edf	16/5/2553 10:19	EDF File
chb01_08.edf	16/5/2553 10:19	EDF File
chb01_09.edf	16/5/2553 10:19	EDF File
chb01_10.edf	16/5/2553 10:19	EDF File
chb01_11.edf	16/5/2553 10:19	EDF File
chb01_12.edf	16/5/2553 10:19	EDF File
chb01_13.edf	16/5/2553 10:19	EDF File
chb01_14.edf	16/5/2553 10:19	EDF File
chb01_17.edf	16/5/2553 10:19	EDF File
chb01_19.edf	16/5/2553 10:19	EDF File
chb01_20.edf	16/5/2553 10:19	EDF File
chb01_22.edf	16/5/2553 10:19	EDF File
chb01_23.edf	16/5/2553 10:19	EDF File
chb01_24.edf	16/5/2553 10:19	EDF File
chb01_25.edf	16/5/2553 10:19	EDF File
chb01_27.edf	16/5/2553 10:19	EDF File
chb01_29.edf	16/5/2553 10:19	EDF File

รูปที่ 4.3 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ

chb01_03.edf	16/5/2553 10:19	EDF File
chb01_03.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_04.edf	16/5/2553 10:19	EDF File
chb01_04.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_15.edf	16/5/2553 10:19	EDF File
chb01_15.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_16.edf	16/5/2553 10:19	EDF File
chb01_16.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_18.edf	16/5/2553 10:19	EDF File
chb01_18.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_21.edf	16/5/2553 10:19	EDF File
chb01_21.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_26.edf	16/5/2553 10:19	EDF File
chb01_26.edf.seizures	7/6/2553 9:26	SEIZURES File

รูปที่ 4.4 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก


รูปที่ 4.3 และ 4.4 แสดงการจัดเก็บไฟล์สัญญาณคลื่นไฟฟ้าสมองที่เป็นชนิดผิดปกติขณะมีอาการชัก โดยจะมีการใช้การจัดลำดับด้วยหมายเลขตาม และเนื่องจากไฟล์ดั้งเดิมจะมีการเพิ่มไฟล์ที่ใช้ในการระบุว่า ไฟล์ในลำดับที่เท่าไรเป็นไฟล์ที่มีสัญญาณผิดปกติอยู่ด้วย

4.3 ผลสรุปขั้นตอนการสกัดคุณลักษณะเด่นของสัญญาณคลื่นไฟฟ้าสมอง


จากการใช้คำสั่งอ่านข้อมูลไฟล์คลื่นไฟฟ้าสมองพบว่า ในแต่ละกรณีจะมีข้อมูลระยะเวลาที่ไม่เท่ากันในบางกรณี พร้อมทั้งใน 1 ไฟล์จะประกอบไปด้วยสัญญาณคลื่นไฟฟ้าสมองแต่ละช่องสัญญาณ ตามแต่ละตำแหน่งที่ทำการบันทึกมา ขั้นตอนของการสกัดคุณลักษณะเด่นจึงได้ใช้วิธีเหล่านี้ในการสกัดคุณลักษณะเด่นออกมา

4.3.1 Tunable Q-factor Wavelet Transform (TQWT) เป็นวิธีในการสลายชุดข้อมูลออกมาให้อยู่ในลักษณะเป็นแถบย่อยจากสัญญาณต้นฉบับ การสกัดคุณลักษณะโดยใช้ TQWT แบบหลายขั้นตอน สามารถทำได้อย่างง่ายดายโดยการกรอข่านความถี่ซ้ำ ๆ กับสัญญาณ ข่านความถี่ย่อยความถี่ต่ำ TQWD ระดับ J ในแต่ละระดับของการสลายตัวสัญญาณอินพุต $s[n]$ โดยค่าระดับที่นักวิจัยนใช้คือ $J = 4$ เพื่อทำการสลายแถบความถี่ให้ออกมาได้ 5 ชั้น ดังรูปที่ 4.6 ที่เป็นการสลายแถบความถี่จากไฟล์ที่เป็นสัญญาณปกติ และในรูปที่ 4.8 ที่เป็นการสลายแถบความถี่จากไฟล์ที่เป็นสัญญาณผิดปกติ

การแปลงเวฟเลตเป็นส่วนหนึ่งตามพฤติกรรมการสั่นของสัญญาณที่ใช้ ตัวอย่างเช่น เมื่อใช้เวฟเลตในการวิเคราะห์และประมวลผลสัญญาณการสั่น (คำพูด, EEG ฯลฯ) การแปลงเวฟเลตควรมี Q-factor ที่ค่อนข้างสูง ในทางกลับกัน เมื่อประมวลผลสัญญาณที่มีพฤติกรรมการสั่นเพียงเล็กน้อยหรือไม่มีเลย (เช่น เส้นสแกนจากภาพถ่าย) การแปลงเวฟเลตควรมี Q-factor ต่ำ อย่างไรก็ตาม นอกเหนือจากการแปลงเวฟเลตแบบต่อเนื่อง การแปลงเวฟเลตส่วนใหญ่ให้ความสามารถเพียงเล็กน้อยในการปรับค่า Q-factor ของเวฟเลต ไดนามิกเวฟเลตทรานส์ฟอร์มมี Q-factor ต่ำ ดังนั้นจึงเหมาะสำหรับสัญญาณที่ไม่สั่น ซึ่ง Q-factor สามารถปรับได้อย่างง่ายดาย การแปลงแสดงว่าเป็นการแปลงเวฟเลต Q ที่ปรับได้ (TQWT) จะถูกกำหนดพารามิเตอร์โดยปัจจัย Q และอัตราการสุ่มตัวอย่างมากขึ้นไป (ความซ้ำซ้อน) TQWT ได้รับการพัฒนาโดยใช้ตัวกรองตัวกรองที่มีขนาดเกินจริงในการสร้างใหม่ที่สมบูรณ์แบบ ด้วยปัจจัยการปรับขนาดตามจริง มีการนำเสนอการแปลงรูปแบบสองรูปแบบ รูปแบบแรกถูกกำหนดไว้สำหรับสัญญาณเวลาแบบไม่ต่อเนื่องที่กำหนดไว้บน Z ทั้งหมด รูปแบบที่สองถูกกำหนดไว้สำหรับสัญญาณเวลาแบบไม่ต่อเนื่องที่มีความยาวจำกัด และสามารถนำไปใช้ได้อย่างมีประสิทธิภาพด้วย FFT อัตราการสุ่มตัวอย่างมากขึ้นไปเล็กน้อยเพียงพอสำหรับฟังก์ชันการวิเคราะห์และการสังเคราะห์ของ TQWT




รูปที่ 4.5 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์




รูปที่ 4.6 ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ปกติในช่องสัญญาณที่ 1

รูปที่ 4.5 เป็นการแสดงภาพรวม เมื่อนำสัญญาณคลื่นไฟฟ้าสมองที่ปกติจากช่องสัญญาณที่ 1 ใน ตามเวลาทำการบันทึกได้จากการสุ่มตัวอย่าง 256 Hz มาแสดงอยู่ในรูปของกราฟ รูปที่ 4.6 เป็นการแสดงภาพสัญญาณปกติ เมื่อถูกสลายแถบความถี่ออกมาได้ 5 ชั้น ด้วยเทคนิค TQWT



รูปที่ 4.7 ลักษณะของสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์



รูปที่ 4.8 ลักษณะเมื่อสลายสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติในช่องสัญญาณที่ 1


รูปที่ 4.7 เป็นการแสดงภาพรวม เมื่อนำสัญญาณคลื่นไฟฟ้าสมองที่ผิดปกติจากช่องสัญญาณที่ 1 ตามเวลาที่ทำการบันทึกได้จากการสุ่มตัวอย่าง 256 Hz มาแสดงอยู่ในรูปของกราฟ รูปที่ 4.8 เป็นการแสดงภาพสัญญาณผิดปกติ เมื่อถูกสลายแถบความถี่ออกมาได้ 5 ชั้น ด้วยเทคนิค TQWT

จากการสลายแถบความถี่ด้วยวิธี TQWT ดังรูปที่ 4.6 และ 4.8 โดยในการทดลองได้ทำงานแบบแถบความถี่ออกเป็น 5 ชั้น โดยเมื่อสัญญาณได้ผ่านกระบวนการออกมาแล้วจะได้แถบความถี่ 5 ชั้น ตามที่แสดงดังรูปที่ 4.6 และ 4.8 จากสัญญาณปกติและที่มีอาการชักตามลำดับ โดยแถบความถี่จะถูกลดทอนจากสัญญาณเดิมลง ประมาณร้อยละ 30 ซึ่งจะแตกต่างกับวิธีการสลายแถบความถี่ชนิด DTW ที่ศึกษาก่อนหน้านี้โดยแถบความถี่จะลดลงจากสัญญาณเดิมร้อยละ 50 นั้นหมายความว่าวิธีการ TQWT จะยังคงเก็บแถบความถี่ที่สลายมาได้มากกว่า เพื่อให้คงคุณลักษณะเด่นของสัญญาณไว้อยู่


4.3.2 การสกัดข้อมูลด้วยค่าทางสถิติ หรือ Statistical feature extraction method วิธีการทางสถิติเป็นส่วนที่เสนอและใช้เพื่อแยกคุณลักษณะทางสถิติที่เป็นตัวแทน มีผลต่อประสิทธิภาพของลักษณะที่เด่นชัดของชุดข้อมูล หากไม่ได้เลือกคุณสมบัติไว้อย่างดี วิธีการทางสถิติประกอบด้วยสองขั้นตอนการแบ่งส่วนและการแยกคุณลักษณะทางสถิติ สัญญาณคลื่นไฟฟ้าสมอง มีลักษณะไม่เป็นเชิงเส้นและไม่อยู่นิ่ง ซึ่งทำให้การวิเคราะห์และการจำแนกเป็นเรื่องยาก ซึ่งในงานวิจัยนี้จะนำคลื่นไฟฟ้าสมองที่ผ่านกระบวนการสลายแถบความถี่แล้ว มาผ่านการลดขนาดสัญญาณด้วยการสกัดข้อมูลทางสถิติ ในการสกัดดังนั้นจะใช้ข้อมูลทางสถิติ 6 ชนิดได้แก่ Maximum (Max), Variance (Var), Skewness (Sk), Kurtosis (Ku), Mean (Mean) และ Entropy (En)

4.4 ผลการเก็บค่าเมื่อผ่านการสกัดคุณลักษณะเด่น

การเก็บค่าเมื่อผ่านการสกัดคุณลักษณะเด่นมาแล้ว มาจากการรวมค่าทางสถิติที่ผ่านกระบวนการสลายแถบความถี่ ทั้ง 5 แถบมาแล้ว และเป็นการสลายแถบความถี่จาก 20 ช่องสัญญาณ ดังนั้นจากขนาดไฟล์ 1 ช่องสัญญาณ เวลา 1 ชั่วโมง อัตราการสุ่มตัวอย่าง 256 ตัวอย่างต่อวินาที เหลือเพียง 30 ค่าต่อ 1 ช่องสัญญาณ เมื่อรวมทั้ง 20 ช่องสัญญาณจึงได้ค่า 600 ค่าต่อ 1 ไฟล์



รูปที่ 4.9 รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่นโดยการหาค่าทางสถิติ 6 แบบของไฟล์สัญญาณปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์



รูปที่ 4.10 รวบรวมข้อมูลในส่วนของการสกัดคุณลักษณะเด่นโดยการหาค่าทางสถิติ 6 แบบของไฟล์สัญญาณผิดปกติจากช่องสัญญาณที่ 1 ใน 1 ไฟล์


รูปที่ 4.9 และ 4.10 แสดงค่าที่เปรียบเทียบซึ่งได้จากกระบวนการหาค่าทางสถิติพร้อมการลดขนาดข้อมูล จะยังสามารถเห็นถึงความแตกต่างของชุดข้อมูลทั้ง 2 ชนิดได้

จะสังเกตได้ว่า เมื่อสัญญาณคลื่นไฟฟ้าสมองผ่านกระบวนการสกัดคุณลักษณะเด่นโดยผ่านการสลายแถบความถี่และหาค่าทางสถิติแล้ว พบว่ายังคงสามารถมองเห็นถึงความแตกต่างของชุดสัญญาณได้ ซึ่งก็เป็นวิธีการที่การเรียนรู้ของเครื่องจะยังคงสามารถเรียนรู้ความแตกต่างจากชุดข้อมูลได้

4.5 ผลการสร้างโมเดลการฝึกสอนจากชนิดของตัวจำแนก

กระบวนการสร้างโมเดลการฝึกสอนด้วยเทคนิคการจำแนกทั้ง 3 ชนิด คือ GMM KELM และ LS-SVM

4.5.1 ฝึกสอนด้วยเทคนิค GMM โดยจะทำการเก็บค่าน้ำหนักข้อมูลแยกแต่ละชุดทดสอบ ในรูปแบบไฟล์ .mat




รูปที่ 4.11 ข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย GMM จัดเก็บในสกุลไฟล์ .mat

จากรูปที่ 4.11 แสดงข้อมูลค่าน้ำหนักที่ได้จากการฝึกสอนด้วย GMM โดยได้ทำการฝึกสอนตามชุดการแบ่งข้อมูลแบบ 5 fold cross validation นอกจากนี้ที่จะทำการสร้างโมเดลข้อมูลทุกแถบความถี่แล้ว นักวิจัยจึงได้เพิ่มกระบวนการสร้างโมเดลเฉพาะแถบความถี่ แยกออกจากกันเพิ่มเติม

4.5.2 ฝึกสอนด้วยเทคนิค KELM โดยจะทำการเก็บค่าน้ำหนักข้อมูลพร้อมค่าที่บ่งบอกลักษณะของชุดฝึกสอน จัดเก็บอยู่ในเมตริกซ์เดียวกัน


591x601 double												
	1	2	3	4	5	6	7	8	9	10	11	12
1	0	489.2756	219.4390	0.4906	43.9035	219.4388	-1.5013e+09	475.1045	337.2768	0.2534	34.9771	337.2762
2	0	207.9817	63.9431	-0.4349	30.9034	63.9430	-3.5819e+08	270.6785	111.1306	-0.0857	23.3388	111.1304
3	0	417.3592	147.8475	0.5681	58.9260	147.8474	-9.7790e+08	446.2345	223.3436	0.1873	48.4311	223.3433
4	0	413.1870	156.7141	0.3123	43.1264	156.7139	-1.0054e+09	487.3500	241.9886	0.0972	37.2879	241.9882
5	0	374.2055	193.9034	0.2201	44.9214	193.9032	-1.3086e+09	446.5908	302.0492	0.1810	37.0784	302.0487
6	0	194.9356	105.6111	-0.3815	13.5490	105.6110	-5.9438e+08	247.3465	173.8164	-0.0177	10.7746	173.8161
7	0	446.8323	227.2350	0.8528	66.7489	227.2348	-1.6481e+09	517.9696	356.3653	0.3420	60.7401	356.3647
8	0	450.4557	228.7500	0.5201	85.0508	228.7497	-1.6944e+09	566.4898	361.6928	0.1749	87.4080	361.6922
9	0	228.0171	164.8492	-0.2966	8.2390	164.8490	-9.6151e+08	241.7045	269.5997	-0.0110	6.9494	269.5992
10	0	254.3706	153.4081	-0.3697	11.9085	153.4080	-9.1976e+08	208.1640	251.7433	-0.0029	10.2097	251.7429
11	0	161.0866	97.5781	-0.4068	13.8205	97.5780	-5.4678e+08	320.2922	157.9442	0.0249	12.7675	157.9439
12	0	151.5111	29.1618	-0.5470	48.1749	29.1618	-1.4357e+08	207.4422	45.3885	-0.0120	33.3221	45.3884
13	0	215.0122	9.1303	3.1558	449.5292	9.1303	-4.5694e+07	228.5500	12.3675	1.4846	323.0109	12.3675
14	0	198.3093	12.1304	1.0293	119.4009	12.1303	-5.4436e+07	232.9771	16.6823	0.0481	129.3026	16.6823
15	0	133.7616	10.7341	0.4634	111.8060	10.7341	-3.3629e+07	186.9356	13.7309	0.0874	98.8488	13.7309
16	0	262.8278	63.5629	-0.2731	33.3855	63.5628	-3.5361e+08	236.9812	89.6957	0.1550	27.3147	89.6955
17	0	196.9245	94.3358	-0.5322	32.8211	94.3357	-5.7270e+08	276.0340	132.6076	0.0042	29.9327	132.6074
18	0	143.0782	85.0715	-0.4150	15.5731	85.0714	-4.5359e+08	162.1682	127.2795	-0.0063	9.9121	127.2793

รูปที่ 4.12 ตัวอย่างข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย KELM



รูปที่ 4.13 ข้อมูลค่าน้ำหนักสำหรับฝึกสอนด้วย KELM จากสัญญาณปกติจาก 1 ช่องสัญญาณ

จากรูปที่ 4.12 แสดงตัวอย่างค่าน้ำหนักที่ได้จากเทคนิคการสกัดคุณลักษณะเด่นและผ่านเทคนิคการจำแนก KELM และได้แสดงค่าน้ำหนักในรูปแบบกราฟแสดงผลดังรูปที่ 4.13 ซึ่งจะแสดงให้เห็นถึง ช่วงของค่าทางสถิติ ที่มีความแตกต่างกัน แต่ยังสังเกตเห็นถึงลักษณะเฉพาะของค่าทางสถิติที่ 6 ชนิด ที่เป็นค่าจากสัญญาณแบบปกติ




รูปที่ 4.14 ข้อมูลค่าน้ำหนักสำหรับฝึกสอนด้วย KELM จากสัญญาณผิดปกติจาก 1 ช่องสัญญาณ

จากรูปที่ 4.14 แสดงให้เห็นถึง ช่วงของค่าทางสถิติ ที่มีความแตกต่างกัน แต่ยังสังเกตเห็นถึงลักษณะเฉพาะของค่าทางสถิติที่ 6 ชนิด ที่เป็นค่าจากสัญญาณแบบผิดปกติ เมื่อเปรียบเทียบกับค่าทางสถิติที่ได้จากสัญญาณแบบปกติ จะยังสามารถเห็นถึงความแตกต่างของค่าน้ำหนักได้อยู่

4.5.3 ฝึกสอนด้วยเทคนิค LS-SVM โดยจะทำการเก็บค่าน้ำหนักข้อมูล จัดเก็บแยกกันค่าที่บ่งบอกลักษณะของค่าในชุดฝึกสอน

	1	2	3	4	5	6	7	8	9	10	11	12
1	1.8061e-09	8.1002e-10	1.8110e-12	1.6206e-10	8.1002e-10	-0.0055	1.7538e-09	1.2450e-09	9.3549e-13	1.2911e-10	1.2450e-09	-0.0059
2	1.2333e-09	4.6778e-10	9.3208e-13	1.2873e-10	4.6778e-10	-0.0030	1.4547e-09	7.2232e-10	2.9017e-13	1.1130e-10	7.2232e-10	-0.0032
3	1.2109e-09	6.1580e-10	2.3110e-12	1.8089e-10	6.1580e-10	-0.0045	1.4037e-09	9.6575e-10	9.2686e-13	1.6460e-10	9.6574e-10	-0.0049
4	8.1379e-10	4.9079e-10	-1.1826e-12	3.8098e-11	4.9079e-10	-0.0029	6.6596e-10	8.0538e-10	-9.2936e-15	3.2663e-11	8.0538e-10	-0.0034
5	4.2050e-10	1.7856e-11	6.1719e-12	8.7915e-10	1.7856e-11	-8.9364e-05	4.4698e-10	2.4187e-11	2.9034e-12	6.3172e-10	2.4187e-11	-7.6321e-05
6	6.1285e-10	1.4821e-10	-6.3685e-13	7.7846e-11	1.4821e-10	-8.2453e-04	5.5258e-10	2.0915e-10	3.6138e-13	6.3691e-11	2.0915e-10	-8.0926e-04
7	5.7643e-10	2.2943e-10	-1.0043e-12	4.1211e-11	2.2943e-10	-0.0013	4.6910e-10	3.4282e-10	-6.8947e-14	3.2017e-11	3.4282e-10	-0.0014
8	6.5626e-10	2.8622e-10	-7.0898e-13	4.5839e-11	2.8622e-10	-0.0016	6.7070e-10	3.9910e-10	2.7364e-14	4.5462e-11	3.9910e-10	-0.0015
9	1.2575e-09	3.3665e-10	-6.5698e-13	1.4255e-10	3.3665e-10	-0.0021	1.8173e-09	5.0734e-10	5.1888e-13	1.9641e-10	5.0734e-10	-0.0022
10	8.1494e-10	2.4393e-11	9.0622e-12	1.3062e-09	2.4393e-11	-1.1298e-04	6.7900e-10	4.0185e-11	2.3549e-12	7.7844e-10	4.0185e-11	-1.1912e-04
11	8.9926e-10	1.9754e-11	7.6504e-12	1.6075e-09	1.9754e-11	-6.9025e-05	6.4056e-10	3.3731e-11	7.2156e-13	5.4792e-10	3.3731e-11	-7.5771e-05
12	1.1551e-09	6.8167e-11	7.4257e-12	2.0719e-09	6.8167e-11	-3.9043e-04	1.3236e-09	1.0862e-10	3.0568e-12	1.5426e-09	1.0862e-10	-3.9421e-04
13	2.1933e-09	4.2044e-10	5.8099e-12	6.2878e-10	4.2044e-10	-0.0024	1.4739e-09	5.2273e-10	3.3323e-13	1.5294e-10	5.2273e-10	-0.0018
14	1.0720e-09	2.2233e-10	7.2444e-12	4.6574e-10	2.2233e-10	-0.0015	7.8310e-10	2.1979e-10	8.0906e-13	1.6449e-10	2.1979e-10	-8.5885e-04
15	7.5775e-10	2.2480e-10	3.5755e-12	2.3043e-10	2.2480e-10	-0.0016	6.1532e-10	2.0596e-10	3.8609e-13	1.0769e-10	2.0596e-10	-8.9390e-04
16	1.3439e-09	4.3049e-11	1.9336e-11	1.8561e-09	4.3049e-11	-1.8162e-04	6.6488e-10	6.2744e-11	1.4416e-12	2.3856e-10	6.2744e-11	-1.5626e-04
17	2.2122e-09	4.6225e-10	1.8967e-11	1.3219e-09	4.6225e-10	-0.0036	1.7693e-09	3.4970e-10	3.4436e-12	9.5604e-10	3.4970e-10	-0.0016
18	1.0006e-09	3.3101e-10	1.8541e-12	7.2728e-11	3.3101e-10	-0.0020	5.1833e-10	4.6561e-10	6.8175e-14	1.6530e-11	4.6561e-10	-0.0019

รูปที่ 4.15 ข้อมูลค่าน้ำหนักจากการฝึกสอนด้วย LS-SVM



รูปที่ 4.16 ข้อมูลค่าน้ำหนักจากการเรียนรู้ด้วย LS-SVM และข้อมูลบอกลักษณะของสัญญาณที่ฝึกสอน

จากรูปที่ 4.15 แสดงตัวอย่างค่าน้ำหนักที่ได้จากเทคนิคการจำแนก LS-SVM จากรูปที่ 4.16 แสดงชุดข้อมูลที่จะถูกนำไปทำการเรียนรู้ด้วย LS-SVM มีความแตกต่างจากสองวิธีที่ผ่านมา โดยในวิธีการนี้จะเพิ่มข้อมูลประเภทของข้อมูลเข้าไปด้วย เพื่อใช้ในการจำแนกข้อมูลที่เป็นปกติและผิดปกติร่วมด้วย ชุดข้อมูลจะถูกเก็บรวมกับทั้ง 2 ประเภทในเมตริกซ์เดียวกัน วิธีการ LS-SVM จะแตกต่างจาก GMM ในส่วนที่ GMM จะแยกการเรียนรู้ระหว่างสัญญาณที่เป็นปกติกับผิดปกติ และแตกต่างจาก KELM ในส่วนที่ KELM จะไม่มีเพิ่มค่าเพื่อระบุชนิดเข้าไป

4.6 ผลทดสอบการจำแนกสัญญาณคลื่นไฟฟ้าสมอง

จากการออกแบบการทดลองการจำแนกคลื่นไฟฟ้าสมองที่เป็นปกติและผิดปกติ ด้วยการเรียนรู้ของเครื่องจากเทคนิคการจำแนก 3 รูปแบบคือ GMM KELM และ LS-SVM จะได้ลักษณะเฉพาะของสัญญาณคลื่นไฟฟ้าสมอง โดยจะนำคลื่นไฟฟ้าสมองที่ผ่านการสกัดคุณลักษณะเด่นดังกล่าวมาทำการทดสอบ เพื่อพิจารณาและจำแนกคุณสมบัติ ของสัญญาณ เพื่อทำนายความแม่นยำจากสมการ

$$Accuracy (\%) = \frac{(TP + TN)}{(TP + FN + FP + TN)} \times 100 \quad (4.1)$$

กระบวนการทดสอบได้ทำการแบ่งการทดสอบออกเป็นสองส่วนคือ 1. ในกระบวนการสกัดคุณลักษณะเด่นที่เป็นการสลายแถบความถี่ซึ่งได้แถบความถี่ย่อยออกมา 5 ชั้น โดยจะทดสอบหาค่าความถูกต้องของแต่ละชั้น 2. หาค่าความถูกต้องจากการใช้แถบความถี่ทั้ง 5 ชั้น

4.6.1 ผลการทดสอบด้วยเทคนิค GMM

ทดสอบกับชุดข้อมูล 5 ชุดข้อมูล ที่ได้จัดกลุ่มการทดลองด้วยวิธี 5 folds validation แสดงดังรูปที่ 4.17 โดยผลการทดสอบความถูกต้องแสดงดังตารางที่ 4.1-4.6

Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5
Fold 1	Fold 2	Fold 3	Fold 4	Fold 5

รูปที่ 4.17 การจัดข้อมูลสำหรับทดสอบการจำแนกทั้ง 24 กรณี

ตารางที่ 4.1 ผลความถูกต้องแบบย่อยขั้นที่ 1 จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	87.31
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	73.27
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	70.25
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	82.22
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	77.89
ความถูกต้องเฉลี่ย		78.19

ตารางที่ 4.2 ผลความถูกต้องแบบย่อยขั้นที่ 2 จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	85.79
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	73.27
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	70.89
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	82.22
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	83.16
ความถูกต้องเฉลี่ย		79.06

ตารางที่ 4.3 ผลความถูกต้องแบบย่อยขั้นที่ 3 จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	81.22
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	73.27
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	73.42
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	74.07
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	85.26
ความถูกต้องเฉลี่ย		77.45

ตารางที่ 4.4 ผลความถูกต้องแบบย่อยขั้นที่ 4 จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	80.71
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	76.24
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	73.42
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	80.74
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	83.16
ความถูกต้องเฉลี่ย		78.85

ตารางที่ 4.5 ผลความถูกต้องแบบย่อยขั้นที่ 5 จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	78.17
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	77.23
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	74.05
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	74.81
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	83.16
ความถูกต้องเฉลี่ย		77.48

ตารางที่ 4.6 ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย GMM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	86.29
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	74.26
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	70.25
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	82.22
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	85.26
ความถูกต้องเฉลี่ย		79.66

ผลการทดสอบทั้ง 5 ชั้น ด้วยเทคนิค GMM พบว่ามีความถูกต้องเฉลี่ยที่ 79.66% เมื่อเทียบก
ค่าความถูกต้องตั้งแต่ชั้นที่ 1 ถึง 5 ดังนี้ 78.19%, 79.06%, 77.45%, 78.85% และ 77.48% ตามลำดับ

ซึ่งน้อยกว่าค่าความถูกต้องเมื่อใช้ทั้ง 5 ชั้น

4.6.2 ผลการทดสอบด้วยเทคนิค KELM

ทดสอบกับชุดข้อมูล 5 ชุดข้อมูล ที่ได้จัดกลุ่มการทดลองด้วยวิธี 5 folds validation โดยผลการทดสอบความถูกต้องแสดงดังตารางที่ 4.7-4.12

ตารางที่ 4.7 ผลความถูกต้องแบบย่อยชั้นที่ 1 จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	97.63
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	97.10
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	97.54
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	97.95
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	98.36
ความถูกต้องเฉลี่ย		97.72

ตารางที่ 4.8 ผลความถูกต้องแบบย่อยชั้นที่ 2 จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	98.82
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	98.55
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	98.67
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	98.80
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	99.59
ความถูกต้องเฉลี่ย		98.89

ตารางที่ 4.9 ผลความถูกต้องแบบย่อยชั้นที่ 3 จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	77.33
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	72.96
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.57

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	75.38
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	75.46
ความถูกต้องเฉลี่ย		75.34

ตารางที่ 4.10 ผลความถูกต้องแบบย่อยขั้นที่ 4 จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	76.82
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	75.14
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.76
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	77.61
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	77.30
ความถูกต้องเฉลี่ย		76.52

ตารางที่ 4.11 ผลความถูกต้องแบบย่อยขั้นที่ 5 จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	78.34
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	74.41
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.57
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	77.26
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	75.46
ความถูกต้องเฉลี่ย		76.21

ตารางที่ 4.12 ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย KELM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	94.08
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	93.65
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	93.56
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	97.09

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	95.30
ความถูกต้องเฉลี่ย		94.74

ผลการทดสอบด้วยเทคนิค KELM พบว่ามีค่าความถูกต้องที่ 94.74% เมื่อเทียบกับค่าความถูกต้องตั้งแต่ชั้นที่ 1 ถึง 5 ดังนี้ 97.72%, 98.89%, 75.34%, 76.52% และ 76.21% ตามลำดับ เห็นได้ว่าค่าความถูกต้องของการใช้แถบความถี่บางชั้นได้แก่ ชั้นที่ 1 และ 2 ที่ถูกนำมาใช้ในการฝึกสอนชนิดของการจำแนกด้วย KELM ให้ค่าความถูกต้องสูงกว่าการใช้ทั้ง 5 ชั้น

4.6.3 ผลการทดสอบด้วยเทคนิค LS-SVM

ทดสอบกับชุดข้อมูลที่ได้จัดกลุ่ม โดยผลการทดสอบแสดงดังตารางที่ 4.13-4.18

ตารางที่ 4.13 ผลความถูกต้องแถบย่อยชั้นที่ 1 จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	81.05
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	85.19
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	73.42
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	73.27
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	87.31
ความถูกต้องเฉลี่ย		80.05

ตารางที่ 4.14 ผลความถูกต้องแถบย่อยชั้นที่ 2 จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	78.95
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	84.44
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	74.05
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	76.24
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	87.82
ความถูกต้องเฉลี่ย		80.30

ตารางที่ 4.15 ผลความถูกต้องแบบย่อยขั้นที่ 3 จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	76.84
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	84.44
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.32
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	73.27
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	89.85
ความถูกต้องเฉลี่ย		79.94

ตารางที่ 4.16 ผลความถูกต้องแบบย่อยขั้นที่ 4 จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	76.84
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	84.44
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.32
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	73.27
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	89.34
ความถูกต้องเฉลี่ย		79.84

ตารางที่ 4.17 ผลความถูกต้องแบบย่อยขั้นที่ 5 จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	75.79
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	84.44
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	75.32
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	73.27
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	89.34
ความถูกต้องเฉลี่ย		79.63

ตารางที่ 4.18 ผลความถูกต้องทั้ง 5 ชั้น จากการจำแนกด้วย LS-SVM

ชุดข้อมูลที่ใช้ทดสอบ	ชุดข้อมูลที่ใช้ฝึกสอน	ค่าความถูกต้อง
Fold 1	Fold 2, Fold 3, Fold 4, Fold 5	78.95
Fold 2	Fold 1, Fold 3, Fold 4, Fold 5	84.44
Fold 3	Fold 1, Fold 2, Fold 4, Fold 5	74.68
Fold 4	Fold 1, Fold 2, Fold 3, Fold 5	76.24
Fold 5	Fold 1, Fold 2, Fold 3, Fold 4	88.83
ความถูกต้องเฉลี่ย		80.63

ผลการทดสอบทั้ง 5 ชั้น ด้วยเทคนิค LS-SVM พบว่ามีความถูกต้องเฉลี่ยถึง 80.63% เมื่อเทียบกับค่าความถูกต้องตั้งแต่ชั้นที่ 1 ถึง 5 ดังนี้ 80.05%, 80.30%, 79.94%, 79.84% และ 79.32% ตามลำดับ ซึ่งน้อยกว่า ค่าความถูกต้องเมื่อให้ทั้ง 5 ชั้น

4.7 สรุปท้ายบท

จากการที่ได้นำเสนอผลการทดสอบการเก็บค่าตามจำนวนฝึกสอนการสุ่มตัวอย่างและสร้างแบบจำลองข้อมูล เป็นการทดสอบใช้อัลกอริทึมสำหรับจำแนกคลื่นไฟฟ้าสมองที่เป็นปกติและผิดปกติ โดยการใช้ชุดข้อมูลที่เป็นมาตรฐาน เพื่อให้การจำแนกสามารถทำงานได้อย่างเป็นมาตรฐานใช้ขั้นแรก และได้ใช้กระบวนการสกัดคุณลักษณะเด่นในการดึงค่าที่มีลักษณะเฉพาะออกมา โดยใช้ร่วมกันวิธีการหาค่าทางสถิติ เพื่อลดขนาดของข้อมูลให้เหลือน้อยลงจากเดิมในการจำแนกคลื่นไฟฟ้าสมองที่เป็นปกติและที่ผิดปกติจากชุดข้อมูล ในวิธีการนี้ได้ใช้ชนิดการจำแนกที่แตกต่างกันในการทดสอบการจำแนกคลื่นไฟฟ้าสมอง ได้แก่ GMM KELM และ LS-SVM โดยทั้งสามชนิดของการจำแนกนี้ได้จัดชุดข้อมูลในการทดสอบออกด้วยวิธีการ 5 folds cross validation ซึ่งเป็นที่นิยมในการใช้ทดสอบกระบวนการเรียนรู้ของเครื่อง ผลที่ได้พบว่ารูปแบบการจำแนกทั้งสามชนิดนั้น สามารถแยกออกจากกันได้อย่างชัดเจน แต่เนื่องจากในวิธีการสกัดคุณลักษณะเด่นข้อมูลได้ถูกลดจำนวนลง ทำให้ในการจำแนกยังไม่สามารถให้ค่าความถูกต้องที่สูงกว่านี้ได้ ซึ่งในการพัฒนานี้เป็นการพัฒนาการสกัดคุณลักษณะสัญญาณคลื่นไฟฟ้าสมองเพื่อให้สามารถนำไปใช้งานได้จริงในอนาคต ผลที่ได้จากตารางที่ 4.1 ถึง 4.3 พบว่าในการนำสัญญาณคลื่นไฟฟ้าสมองที่ได้จากการบันทึกสัญญาณที่เป็นมาตรฐานของแต่ละลักษณะกระบวนการการจำแนกทั้ง 3 ชนิดสามารถจำแนกได้มีความถูกต้องเฉลี่ยร้อยละ 84.24

บทที่ 5

สรุปเนื้อหาวิทยานิพนธ์และข้อเสนอแนะในการวิจัย

5.1 สรุปผลงานวิจัย

ปัจจุบันคลื่นไฟฟ้าสมอง มีบทบาทในการวินิจฉัยอาการของโรคลมชัก โดยการให้ผู้ป่วยเข้ารับการตรวจคลื่นไฟฟ้าสมอง ด้วยการบันทึกสัญญาณซึ่งจะใช้เวลาในการทำการบันทึกหลายชั่วโมง เพื่อเฝ้าติดตามว่าอาการชักจะเกิดขึ้นหรือไม่ และเมื่อทำการบันทึกเสร็จเรียบร้อยแล้วแพทย์จะนำสัญญาณที่ได้ไปตรวจสอบหาลักษณะของความผิดปกติ ในสัญญาณคลื่นไฟฟ้าสมองที่บันทึกได้ ในการตรวจสอบสัญญาณที่มีจำนวนตัวอย่างที่ค่อนข้างมากคือ 256 ตัวอย่างใน 1 วินาที หากไฟล์มีการบันทึก 1 ชั่วโมง ก็จะมีค่าตัวอย่างถึง 921,600 ตัวอย่างจากช่องสัญญาณเพียงช่องเดียวเท่านั้น ซึ่งใน 1 ไฟล์สัญญาณที่ทำการศึกษานี้มีช่องสัญญาณมากที่สุดถึง 24 ช่องสัญญาณ อีกทั้งสัญญาณอาการชักที่บันทึกได้อาจจะเกิดเพียงไม่กี่วินาที จึงอาจทำให้แพทย์ต้องใช้เวลาในการจำแนกไฟล์ ที่เป็นปกติมากกว่าไฟล์ที่มีความผิดปกติได้ นักวิจัยจึงได้ศึกษาการใช้งานการสกัดคุณลักษณะเด่นด้วยเทคนิคการสลายแถบความถี่แบบ TQWT กับการหาค่าทางสถิติร่วมด้วย แล้วจึงนำไปเข้ากระบวนการจำแนก 3 ชนิดคือ GMM KELM และ LS-SVM โดยกระบวนการเหล่านี้ดำเนินการบนคอมพิวเตอร์โน้ตบุ๊กที่มีประสิทธิภาพไม่ได้สูงมากนัก

การทดลองจากการเรียนรู้ของเครื่องด้วยชนิดการจำแนกทั้ง 3 ชนิด

5.1.1 การจำแนกด้วย GMM จากการใช้ 5 แถบความถี่จากการสลายแถบความถี่ TQWT ให้ค่าความถูกต้องเฉลี่ยร้อยละ 79.66

5.1.2 การจำแนกด้วย KELM จากการใช้ 5 แถบความถี่จากการสลายแถบความถี่ TQWT ให้ค่าความถูกต้องเฉลี่ยร้อยละ 94.74

5.1.3 การจำแนกด้วย LS-SVM จากการใช้ 5 แถบความถี่จากการสลายแถบความถี่ TQWT ให้ค่าความถูกต้องเฉลี่ยร้อยละ 78.32

5.2 สรุปเนื้อหาวิทยานิพนธ์

นำเสนอการพัฒนาอัลกอริทึมในการสกัดคุณลักษณะเด่นของสัญญาณคลื่นไฟฟ้าสมองในงานวิจัยนี้ใช้เทคนิคการสลายแถบความถี่ TQWT รวมกับการหาค่าทางสถิติ ร่วมกับการใช้การเรียนรู้ของเครื่องในการเรียนรู้ลักษณะพร้อมใช้ในการจำแนกความแตกต่างของสัญญาณ 2 รูปแบบ และนำเอาผลการทดลองที่ได้มาเพื่อเปรียบเทียบกับเทคนิคอื่นที่ได้ทำการศึกษา การวิจัยนี้จึงได้ศึกษาความสามารถในการจำแนกคลื่นไฟฟ้าสมองด้วยการเรียนรู้ของเครื่องจากการสกัดคุณลักษณะเด่นของสัญญาณที่พัฒนาขึ้น

5.3 ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต

จากการทดสอบจำแนกคลื่นไฟฟ้าสมองของสัญญาณขณะปกติทั่วไปกับผิดปกติจะมีลักษณะสัญญาณที่แตกต่างกัน แต่จากการศึกษาในงานวิจัยพบว่าเมื่อข้อมูลถูกลดขนาดลงจากขนาดต้นฉบับมาก จะทำให้ลักษณะเด่นของสัญญาณสูญหายไปบางส่วน จนทำให้ค่าที่นำไปสร้างแบบจำลองมีค่าใกล้เคียงกันแทนที่จะแตกต่างกัน ซึ่งเป็นข้อจำกัดมาจากการดำเนินการบนคอมพิวเตอร์ที่มีประสิทธิภาพในการประมวลผลไม่สูงมากนั่นเอง ในการพัฒนาอัลกอริทึมนี้ให้มีความถูกต้องสูงขึ้นสามารถพัฒนาได้ด้วยวิธีเหล่านี้

5.3.1 การเพิ่มกระบวนการสกัดคุณลักษณะเด่นให้ได้ค่าที่มากขึ้นกว่านี้ เพื่อเก็บลักษณะเด่นให้ได้มาและยังมีประสิทธิภาพสูง

5.3.1 ใช้อุปกรณ์คอมพิวเตอร์ที่มีประสิทธิภาพที่สูงขึ้น สำหรับทำการประมวลผลการสกัดคุณลักษณะเด่นได้

5.3.3 พัฒนาการเรียนรู้ของเครื่องด้วยเทคนิคใหม่ที่อาจถูกพัฒนาขึ้นในอนาคต


5.3.4 ศึกษาการใช้เทคนิคเดียวกันร่วมกับการใช้สัญญาณคลื่นไฟฟ้าสมองของคนไทย

โดยงานวิจัยนี้เป็นการพัฒนาอัลกอริทึมการสกัดคุณลักษณะเด่นและการจำแนกแบบคร่าวๆ บนคอมพิวเตอร์ที่มีข้อจำกัดในการประมวลผล ทำให้ค่าความถูกต้องในขั้นตอนการจำแนกบางอย่างยังไม่เป็นที่น่าพอใจ สำหรับมาใช้วิเคราะห์เพราะค่าสัญญาณที่ไม่สูงเป็นที่น่ายอมรับจากแพทย์ได้ยากกว่า หากทำการพัฒนาอัลกอริทึมให้มีความแม่นยำที่มากพอ แต่ยังสามารถดำเนินการได้บนคอมพิวเตอร์ทั่วไปได้ การออกแบบการทดลองเพิ่มเติมให้ครอบคลุมไปถึงคลื่นไฟฟ้าสมองที่มีอาการอื่นๆ เพิ่มเติม หรือรูปแบบสัญญาณใหม่ ๆ เพื่อเพิ่มประสิทธิภาพการทำงานของอัลกอริทึม ให้สามารถใช้วิธีการแบบเรียลไทม์เพื่อให้ระบบการเรียนรู้ของเครื่องตัดสินใจได้ไวและแม่นยำมากขึ้น

รายการอ้างอิง

- S. Patidar and T. Panigrahi, Detection of epileptic seizure using Kraskov entropy applied ontunable-Q wavelet transform of EEG signals, 2017 Biomedical Signal Processing and Control 34, pp. 74-78, Jan 2017
- R Sharma and RB Pachori, "Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions," 2015 Expert Systems with Applications 42.3, pp. 1106-1117, Sep 2014
- M Zhang, X Zhang, H Wang, G Xiong and W Cheng, Features Fusion Exaction and KELM With Modified Grey Wolf Optimizer for Mixture Control Chart Patterns Recognition, 2020 IEEE Access 8, pp. 42469-42480, Feb 2020
- R Panda, PS Khobragade, PD Jambhule, S. N Jengthe, P.R.Pal and T. K. Gandhi, Classification of EEG Signal Using Wavelet Transform and Support Vector Machine for Epileptic Seizure Diction, International conference on systems in medicine and biology (2010), pp. 405-408, dec 2010
- AH Shoeb and JV Guttag, Application of Machine Learning To Epileptic Seizure Detection, 2010 Proceedings of the 27th International Conference on Machine Learning (ICML-10), pp. 975-982.
- HR Al Ghayab, Y Li, S Siuly, S Abdulla and S Siuty, A Feature Extraction Technique based on Tunable Q-Factor Wavelet Transform for Brain Signal Classification, 2019 Journal of neuroscience methods 312, pp. 43-52 Nov 2018
- IW Selesnick, Wavelet Transform with Tunable Q-Factor, 2011 IEEE transactions on signal processing 59.8, pp. 3560-3575, Aug 2011

- F. E. Abd El-Samie, T. N. Alotaiby, M. I. Khalid, S. A. Alshebeili and S. A. Aldosari, A Review of EEG and MEG Epileptic Spike Detection Algorithms, IEEE Access 6 2018, pp. 60673-60688, Oct 2018
- D Wu, Z Wang, L Jiang, F Dong, X Wu, S Wang and Y Ding Automatic Epileptic Seizures Joint Detection Algorithm Based on Improved Multi-Domain Feature of cEEG and Spike Feature of aEEG, 2019 IEEE Access 7, pp. 41551-41564, Mar 2019
- K Phapatanaburi, K Kokkhunthod, L Wang, T Jumphoo, M Uthansakul, A Boonmahitthisud and P Uthansakul, 2021 CMC-Computers Materials & Continua 66.3, pp. 3029-3044



ภาคผนวก ก

ชุดข้อมูลคลื่นไฟฟ้าสมองที่ใช้ในงานวิจัย



ก.1 ชุดข้อมูล

ข้อมูลที่ใช้เป็นอินพุตจะเป็นประเภทสัญญาณคลื่นไฟฟ้าสมอง ฐานข้อมูลนี้รวบรวมที่ Children's Hospital Boston ประกอบด้วยการบันทึกคลื่นไฟฟ้าสมองจากผู้ป่วยเด็กที่มีอาการชัก ผู้ป่วยได้รับการตรวจติดตามเป็นเวลาหลายวันหลังจากถอนยาต้านอาการชัก เพื่อระบุลักษณะอาการชักและประเมินผู้ป่วยเข้ารับการผ่าตัด


การบันทึกแบ่งออกเป็น 23 กรณีโดยรวมจากผู้ป่วย 22 คน (ชาย 5 คน อายุ 3-22 ปี และหญิง 17 คน อายุ 1.5-19 ปี) (กรณี chb21 บันทึกภายหลัง 1.5 ปี จากกรณี chb01 จากผู้หญิงคนเดียว) ไฟล์ SUBJECT-INFO ประกอบด้วยเพศและอายุของแต่ละกรณี (กรณี chb24 ถูกเพิ่มเข้าไปในคอลเล็กชันนี้ในเดือนธันวาคม 2010 และปัจจุบันยังไม่รวมอยู่ใน SUBJECT-INFO)

แต่ละกรณี (chb01, chb02 ฯลฯ) มีไฟล์ .edf ต่อเนื่องระหว่าง 9 ถึง 42 ไฟล์จากกรณีเดียว ข้อจำกัด ของฮาร์ดแวร์ส่งผลให้เกิดช่องว่างระหว่างไฟล์ .edf ที่มีหมายเลขติดต่อกันระหว่างที่สัญญาณไม่ได้รับการบันทึก ในกรณีส่วนใหญ่ช่องว่างจะอยู่ที่ 10 วินาทีหรือน้อยกว่า แต่บางครั้งก็มีช่องว่างที่ยาวกว่ามาก เพื่อปกป้องความเป็นส่วนตัวของอาสาสมัครข้อมูลสุขภาพที่ได้รับการป้องกัน (PHI) ทั้งหมดในไฟล์ .edf ดั้งเดิมจะถูกแทนที่ด้วยข้อมูลตัวแทนในไฟล์ที่ให้ไว้ที่นี้ วันที่ในไฟล์ .edf ดั้งเดิมถูกแทนที่ด้วยวันที่ตัวแทน แต่ความสัมพันธ์ของเวลาระหว่างไฟล์แต่ละไฟล์ที่เป็นของแต่ละเคสจะถูกเก็บรักษาไว้

ในกรณีส่วนใหญ่ไฟล์ .edf จะมีสัญญาณ EEG แบบดิจิทัลหนึ่งชั่วโมง แม้ว่าไฟล์ที่เป็นของ case chb10 จะมีความยาว 2 ชั่วโมงก็ตามและไฟล์ที่เป็นของ case chb04, chb06, chb07, chb09 และ chb23 นั้นมีความยาวสี่ชั่วโมง ในบางครั้งไฟล์ที่บันทึกอาการชักจะสั้นกว่า

สัญญาณทั้งหมดถูกสุ่มตัวอย่างที่ 256 ตัวอย่างต่อวินาทีด้วยความละเอียด 16 บิต ไฟล์ส่วนใหญ่มีสัญญาณ EEG 23 สัญญาณ (24 หรือ 26 ในบางกรณี) ระบบตำแหน่งอิเล็กโทรด EEG ในบันทึกไม่มีการรายการสัญญาณอื่น ๆ จะถูกบันทึกด้วยเช่นสัญญาณ ECG ใน 36 ไฟล์ล่าสุดที่เป็นของ case chb04 และสัญญาณกระตุ้นเส้นประสาท vagal (VNS) ใน 18 ไฟล์สุดท้ายที่เป็นของ case chb09 ในบางกรณีสัญญาณ "dummy" (ชื่อ "-") มากถึง 5 ตัว สลับกันระหว่างสัญญาณ EEG เพื่อให้ได้รูปแบบการแสดงผลที่อ่านง่าย สัญญาณจำลองเหล่านี้สามารถละเว้นได้ ไฟล์ RECORDS มีรายการไฟล์ 664 .edf ทั้งหมดที่รวมอยู่ในคอลเล็กชันนี้และไฟล์ RECORDS-WITH-SEIZURES จะแสดงรายการไฟล์เหล่านั้น 129 ไฟล์ที่มีอย่างน้อยหนึ่งรายการ โดยรวมแล้วบันทึกเหล่านี้

รวม 198 อาการชัก (182 ในชุดเดิม 23 ราย) จุดเริ่มต้น และจุดสิ้นสุดของแต่ละครั้ง มีคำอธิบายประกอบอยู่ในไฟล์คำอธิบายประกอบ .seizure ที่มาพร้อมกับไฟล์แต่ละไฟล์ที่ระบุไว้ใน RECORDS-WITH-SEIZURES นอกจากนี้ไฟล์ชื่อ chbnn-summary.txt ยังมีข้อมูลเกี่ยวกับการติดต่อที่ใช้สำหรับการบันทึกแต่ละครั้งและเวลาที่ผ่านไปเป็นวินาทีตั้งแต่จุดเริ่มต้นของไฟล์ .edf ไปจนถึงจุดเริ่มต้นและจุดสิ้นสุดของแต่ละครั้งที่อยู่ในไฟล์



รูปที่ ก.1 ไฟล์ชุดข้อมูล 24 กรณี 24 โฟลเดอร์

Case	Gender	Age (year)	Number of event	Duration (hour)
chb01	F	11	7	40
chb02	M	11	3	35
chb03	F	14	7	38
chb04	M	22	4	156
chb05	F	7	5	39
chb06	F	1.5	10	66
chb07	F	14.5	3	67
chb08	M	3.5	5	20
chb09	F	10	4	67
chb10	M	3	7	50
chb11	F	12	3	34
chb12	F	2	40	23
chb13	F	3	12	33
chb14	F	9	8	26
chb15	M	16	20	40
chb16	F	7	10	19
chb17	F	12	3	21
chb18	F	18	6	35
chb19	F	19	3	29
chb20	F	6	8	27
chb21	F	13	4	32
chb22	F	9	3	31
chb23	F	6	7	26
chb24	-	-	16	21

รูปที่ ก.2 ข้อมูลเฉพาะของแต่ละกรณี

chb01_01.edf	16/5/2553 10:19	EDF File
chb01_02.edf	16/5/2553 10:19	EDF File
chb01_05.edf	16/5/2553 10:19	EDF File
chb01_06.edf	16/5/2553 10:19	EDF File
chb01_07.edf	16/5/2553 10:19	EDF File
chb01_08.edf	16/5/2553 10:19	EDF File
chb01_09.edf	16/5/2553 10:19	EDF File
chb01_10.edf	16/5/2553 10:19	EDF File
chb01_11.edf	16/5/2553 10:19	EDF File
chb01_12.edf	16/5/2553 10:19	EDF File
chb01_13.edf	16/5/2553 10:19	EDF File
chb01_14.edf	16/5/2553 10:19	EDF File
chb01_17.edf	16/5/2553 10:19	EDF File
chb01_19.edf	16/5/2553 10:19	EDF File
chb01_20.edf	16/5/2553 10:19	EDF File
chb01_22.edf	16/5/2553 10:19	EDF File
chb01_23.edf	16/5/2553 10:19	EDF File
chb01_24.edf	16/5/2553 10:19	EDF File
chb01_25.edf	16/5/2553 10:19	EDF File
chb01_27.edf	16/5/2553 10:19	EDF File
chb01_29.edf	16/5/2553 10:19	EDF File

รูปที่ ก.3 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองปกติ

chb01_03.edf	16/5/2553 10:19	EDF File
chb01_03.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_04.edf	16/5/2553 10:19	EDF File
chb01_04.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_15.edf	16/5/2553 10:19	EDF File
chb01_15.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_16.edf	16/5/2553 10:19	EDF File
chb01_16.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_18.edf	16/5/2553 10:19	EDF File
chb01_18.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_21.edf	16/5/2553 10:19	EDF File
chb01_21.edf.seizures	7/6/2553 9:26	SEIZURES File
chb01_26.edf	16/5/2553 10:19	EDF File
chb01_26.edf.seizures	7/6/2553 9:26	SEIZURES File

รูปที่ ก.4 ลักษณะไฟล์ของคลื่นไฟฟ้าสมองที่มีการชัก

The logo of Sakon Nakhon Rajabhat University is a large, faint watermark in the background. It features a golden-yellow triangular structure with a silhouette of a person sitting on a throne in the center. Below the triangle is a circular emblem with a red and white border. The university's name is written in Thai script around the bottom of the emblem.

ภาคผนวก ข

บทความทางวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

มหาวิทยาลัยเทคโนโลยีสุรนารี

รายชื่อบทความที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

Kasidit Kokkhunthod, Talit Jumphon1, Peerapong Uthansakul

Improving Brainwave Classification for Character-Writing Application using Single Effective EEG Channel. SUT International Virtual Conference on Science and Technology Nakhon-Ratchasima, Thailand 28th August, 2020 (IVCST).



AECXXX

(this number will be assigned after full manuscript is accepted)

Improving Brainwave Classification for Character-Writing Application using Single Effective EEG Channel

Kasidit kokkhunthod¹, Talit Jumphon¹, and Peerapong Uthansakul^{1,*}

¹ School of Telecommunication Engineering, Suranaree University of Technology,
Nakhon Ratchasima 30000, Thailand

* Corresponding Author: uthansakul@sut.ac.th

Abstract. Recent study has reported that the possibility of brainwave classification without any stimulus for character-writing application, which is flexible in the real-world application. However, the performance of the system is dependent on the pair of EEG channels at the frontal lobe, making the character detection ineffective/ambiguous due to the joint decision. In this paper, a new system is proposed to improve the performance of brainwave classification using single EEG channel to replace the pair of EEG channels. In the proposed system, artificial neural network (ANN) with discrete wavelet transform is used as brainwave classification to detect two different characters; straight line and circle. Experiments were evaluated using the volunteer-independent 5-fold cross-validation and a standard measure referred to as accuracy. From the experimental results, we can observe that using effective single EEG channel provided improved performance compared to using the pair of EEG channels because the chosen suitable EEG channel. The brainwave classification accuracy was improved from 68.20% with joint F4 and F3 channel to 74.10% with F3 channel. This indicates that brainwave classification using only F3 channel is useful for character-writing application.

Keywords: Brainwave Classification, Electroencephalogram, EEG channel, DWT, ANN.

1. Introduction

Brain-computer interface (BCI) is a system that enables people to communicate with a system or device signal. It has received increasing attention in many fields such as medical application, entertainment, and human communication [1] because a variety of brain waves derived from the BCI process can be converted into the designed commands. In this paper, we would like to study the BCI system for the communication between human brain and outside world so that the normal/defective people whose brains still work well can express their thought.

A typical BCI system for the communication [1] is controlled using different responses of electroencephalogram (EEG) signals. Broadly, different responses be grouped into three categories: the first one is based on event-related potentials (ERP) where an electrophysiological response is the direct effect of a motor event. For instance, the authors of [2] used visual P300 wave which is an ERP component to observe the brain response for spelling the characters. When the stimulations with the intensified symbol are focused by the user, the ERP response in the EEG signal will be generated. By detecting the ERP response, the system can provide the focused symbol from the which the user tries to spell the symbol. Next, the second category is based on steady-state visual evoked potential (SSVEP)

which is the response with a repetitive visual stimulus at a steady rate (i.e., flickering stimulus). For example, in [3], the SSVEP response was proposed for spelling application. In the proposed system, the brain responses the overlap of the visual stimulus, giving to a steady state signal. For this reason, when considering the steady state signal, it is possible to detect the symbol which the user is looking at the stimulus. Finally, the third one is based on motor imagery (MI) which occurs during the actual or imagined limb movement, leading to change a neural population in the motor cortex. For instance, in [4], the changed neural population in the motor cortex with event-related synchronization and event related desynchronization was studied to detect the actual or imagined limb movement. From all the mentioned types of different EEG responses, although the systems can refer to the attempt to spell the characters, they still require some stimulations and limb movements for generating brain responses. Therefore, it may not be practical because the user has to grasp the stimulus for whole time.

Unlike the above-mentioned literature, the BCI for character-writing application without the help of limb movement and any stimulus [5] was proposed. This system exploited artificial neural network (ANN) classifier with discrete wavelet transform (DWT) information to detect two different animated imaginations, straight line and circle, where the detected animation is also converted into the designed characters. The results exhibited that the proposed system showed the feasibility which does not require the help of limb movement and any stimulus, and also provided a promising performance. However, the performance of the system depends on the pair of EEG channels at the frontal lobe, making the character detection ineffective/ambiguous due to the joint decision.

To overcome the problem, motivated by [6] that brainwave classification using single efficient channel could provide a promising result for the detection of focal seizure, we propose a new simple method to improve the performance of brainwave classification using single EEG channel to replace the pair of EEG channels. We hypothesize the proposed method using single effective EEG channel can provide the improved performance for brainwave classification for character-writing application.

2. Material and Method

In this section, the data collection of brainwave classification for character-writing application is described. Moreover, DWT and ANN are also introduced as feature extraction and classifier, respectively. The details of setup/method are as follow.

2.1. Data collection

In this paper, the Emotiv EPOC neuroheadset based on Bluetooth technology is used as shown in Figure 1 (a) so that we obtain the EEG raw data between the brain and device/computer. For the EEG recording, the Emotiv device typically has 14 electrodes which referred to as AF3, AF4, F7, F3, F4, F8, FC5, FC6, T7, T8, P7, P3, P4, P8, O1 and O3. The letters of F, T, C, P, and O define the abbreviation of frontal, temporal, central, parietal, and occipital lobes, respectively. Here, the sampling rate is set to 128 samples per second and the bandwidth is in between 0.2 and 45 Hz. The data of F3 and F4 channels as shown in Figure 1 (b) are used due to the suitable electrodes for character-writing application as advised in [1].

Regarding the evaluation data used for our experiment, two characters consisting of straight line and circle characters are designed for the animation as shown in Figure 2. In this paper, five healthy volunteers where each one has to imagine 100 straight line and circle characters with 100 times were investigated for data collection as suggested in [5]. The EEG data is recorded as follow: 1) the volunteer wears Emotiv EPOC neuroheadset on the head and focuses on the meditation for around 60 s as shown in Figure 3 (a-b). 2) The volunteer is investigated by imagining straight line/circle character as seen in Figure 3 (c). 3) After the volunteer finishes to imagine animation for about 30 times, the volunteer has to rest for 120 s in order to reduce the fatigue of the brain as shown in Figure 3 (d).




Figure 1. The illustration of (a) Emotiv EPOC neuroheadset and (b) the locations of electrodes.




Figure 2. The animation of a straight line and a circle characters.




Figure 3. The procedure in the EEG data recording from (a) to (d).

2.2. DWT

DWT is popular for brainwave classification because it has the merits of scale-space analysis, multi-rate filtering, time-frequency localization. Normally, DWT can be used to expose more characteristics from the signal in both time and frequency domain precisely. This makes it become a powerful tool for brainwave classification. Here, we utilize DWT to analyze the EEG signals into various frequency bands using the high-pass and low-pass filters as shown in Figure 4. For first level, the outputs of low-pass filter is referred to as approximation (A1) coefficient, while the output of high-pass filters is referred to as detail (D1) coefficient. Next, the output signals at second level can be down-sampled by two due to Nyquist rule. For second level, we can also refer to the outputs of low and high-pass filter as A2 and D2, respectively. The same procedure with second approximation and detail coefficient can be duplicated for obtaining next approximation and detail coefficients.

In this paper, we followed the standard DWT feature as suggested in [5]. Therefore, the DWT decomposition at 4th level for all the EEG data and daubechies 4 (db4) was used for our experiment. Table 1 shows the different levels of wavelet decomposition referred to as gamma, beta, alpha, theta, and delta, respectively. Figure 5 shows the approximated and detailed coefficients at F3 channel from one of the volunteers imagining straight line and circle characters. Here, the approximated and detailed coefficients are not directly used as the input of classifier because of the problem of variable-sized

windows. Therefore, they can be represented using six following statistical features: mean, average power, standard deviation, ratio of the absolute mean values of adjacent subbands, skewness, and kurtosis. Further details of statistical features can be seen in [7].




Figure 4. The level of DWT to analyze the EEG signals into various frequency bands.

Table 1. Frequencies corresponding to different levels of decomposition with a 128 Hz sampling rate.

Decomposition level	Frequency band	Frequency range (Hz)
D1	Gamma	32-64
D2	Beta	16-32
D3	Alpha	8-16
D4	Theta	4-8
A4	Delta	0-4




Figure 5. The approximated and detailed coefficients at F3 channel.

2.3. ANN-based classifier

Because ANN can efficiently learn a non-linear function for classification and also provide a promising performance for brainwave classifier as reported in [5], we also implement ANN as classifier to calculate the posterior probability of each straight line and circle class, based on the given input feature explained in Section 2.2. Here, we follow the ANN algorithm as set in [5]. The ANN algorithm based on a feed-forward backpropagation network. The network has single hidden layer and tangent sigmoid transfer function was used to train the network. The learning rate and iterations were set to 0.001 and 1000. The

output layer consists of two neurons with SoftMax activation function for computing the probability of straight line and circle classes. The output score for a given feature is computed using following equation (1)

$$\Lambda(S) = P(\phi_l | S) - P(\phi_c | S) \quad (1)$$

where $P(\phi_l | S)$ and $P(\phi_c | S)$ are the estimations of the posterior probability of straight line and circle classes, respectively. S is a sequence of feature vectors.

Figure 6. shows the conventional and proposed ANN based brainwave classifications for character-writing application. As observed in conventional ANN-based detection, the decisions between F3 and F4 channels are jointly used to detect straight line/circle characters. This may make the detection ineffective/ambiguous if the systems based on F3 and F4 channel have different decision.

To overcome the problem, motivated by [5] that brainwave classification using single efficient channel could provide a promising result for the detection of focal seizure, two new simple methods are applied to improve the performance of brainwave classification using single EEG channel to replace the pair of EEG channels.




Figure 6. Flowchart of the decisions between F3 and F4 channels.

3. Results and discussion

In order to investigate the performance of the proposed method, the accuracy is used for evaluating a criterion measurement as given as in equation (2) [5, 8].

$$Accuracy (\%) = \frac{(TP + TN)}{(TP + FN + FP + TN)} \times 100 \quad (2)$$

where TP and TN are true positive and true negative where the model correctly classifies the positive class and the negative class, respectively. In similar way, FP and FN are false positive and false negative

From Table 2, it can be seen that brainwave classification using only F3 channel performed better than brainwave classification using only F4 channel because EEG signals derived from F3 channel provide distinct difference between straight line and circle characters, making the classification performance efficient. By comparing convention method, brainwave classification using only F4 channel performed worse than brainwave classification based on the pair of F3 and F4 because of the

conventional system has the condition of different decision as seen in Figure 6 (if the decision using F3 is not equal to the decision using F4, the final decision will be the decision of circle character). On the other hand, brainwave classification using only F3 channel could provide better performance than conventional method because the decision performance is not decreased by the decision derived from F4 channel. This indicates that brainwave classification using single effective EEG channel useful for character-writing application.

4. Conclusion

In this paper, a new system is proposed to improve the performance of brainwave classification using single EEG channel to replace the pair of EEG channels. In the proposed system, DWT and ANN were used as feature extraction and brainwave classification to detect two different characters; straight line and circle. Experiments were evaluated using the volunteer-independent 5-fold cross-validation and a standard measure referred to as accuracy. From the experimental results, it can be seen that brainwave classification using only F3 channel performed better than brainwave classification using only F4 channel because EEG signals derived from F3 channel provide distinct difference between straight line and circle characters, making the classification performance efficient. We can also observe that using effective single EEG channel provided improved performance compared to using the pair of EEG channels because the chosen suitable EEG channel. The brainwave classification accuracy was improved from 68.20% with joint F4 and F3 channel to 74.10% with F3 channel. This indicates that brainwave classification using only F3 channel is useful for character-writing application.

In future work, we have a plan to investigate phase information as feature extraction [9, 10] and magnitude and phase aware deep neural network [11] as classifier.

References

Article in Journals

- [1] Rezeika, A., Benda, M., Stawicki, P., Gembler, F., Saboor, A., Volosyak, I., Brain-Computer Interface Spellers: A Review. *Brain Sci.* 2018, 8, 57
- [2] Krusienski, D. J., Sellers, E. W., McFarland, D. J., Vaughan, T. M., and Wolpaw, J. R. (2008). Toward enhanced P300 speller performance. *Journal of neuroscience methods*, 167(1), 15-21.
- [3] Friman, O., Luth, T., Volosyak, I., and Graser, A. 2007. Spelling with steady-state visual evoked potentials. In 2007 3rd International IEEE/EMBS Conference on Neural Engineering (pp. 354-357). IEEE.
- [4] Zabidi, A., Mansor, W., Khuan, Y. L., & Fadzal, C. C. W. (2012, December). Classification of imagined writing from EEG signals using autoregressive features. In 2012 International Symposium on Computer Applications and Industrial Electronics (ISCAIE) (pp. 205-208). IEEE.
- [5] Jumphoo T., Uthansakul M., Uthansakul P. Brainwave classification without the help of limb movement and any stimulus for character-writing application. *Cogn Syst Res.* 2019 Dec 1;58:375-86.
- [6] T. Siddharth, Pranjali Gajbhiye, Rajesh Kumar Tripathy, and Ram Bilas Pachori. 2020 EEG based Detection of Focal Seizure Area using FBSE-EWT rhythm and SAE-SVM Network. *IEEE Sens. J.* 2020.
- [7] Hamad A, Houssein EH, Hassanien AE and Fahmy AA. Feature extraction of epilepsy EEG using discrete wavelet transform. In 2016 12th international computer engineering conference (ICENCO) 2016 Dec 28 (pp. 190-195). IEEE.
- [8] Alhussien M., Muhammad G., Hossain M. S. (2019). EEG pathology detection based on deep learning. *IEEE Access*, 7, 27781-27788.
- [9] Phapatanaburi K, Wang L, Nakagawa S, Iwahashi M. Replay attack detection using linear prediction analysis-based relative phase features. *IEEE Access*. 2019 Dec 17;7:183614-25.
- [10] Phapatanaburi K, Buayai P, Kupimai M and Yodrot T. Linear Prediction Residual-Based Constant-Q Cepstral Coefficients for Replay Attack Detection. In 2020 8th International Electrical Engineering Congress (iEECON) 2020 Mar 4 (pp. 1-4). IEEE.
- [11] Phapatanaburi K, Buayai P, Naktong W and Srinonchat J. Exploiting Magnitude and Phase Aware Deep Neural Network for Replay Attack Detection. *ecti transactions on electrical engineering electronics and communications*. 2020 Aug 18;2: 89-97.

Khomdet Phapatanaburi¹, Kasidit kokkhunthod, LongbiaoWang, Talit Jumphoo,
Monthippa Uthansakul, Anyaporn Boonmahitthisud and Peerapong Uthansakul
Brainwave Classification for Character-Writing Application Using EMD-Based GMM
and KELM Approaches. CMC-Computers Materials & Continua, 2021, pp. 3029-3044.



Brainwave Classification for Character-Writing Application Using EMD-Based GMM and KELM Approaches

Khomdet Phapatanaburi¹, Kasidit kokkhunthod², Longbiao Wang³, Talit Jumphoo², Monthippa Uthansakul², Anyaporn Boonmahitthisud⁴ and Peerapong Uthansakul^{2,*}

¹Department of Telecommunication Engineering, Rajamangala University of Technology Isan, Nakhon Ratchasima, 30000, Thailand

²School of Telecommunication Engineering, Suranaree University of Technology, Nakhon Ratchasima, 30000, Thailand

³Tianjin Key Laboratory of Cognitive Computing and Application, College of Intelligence and Computing, Tianjin University, Tianjin, 300350, China

⁴Department of Materials Science, Chulalongkorn University, Bangkok, 10330, Thailand

*Corresponding Author: Peerapong Uthansakul. Email: uthansakul@sut.ac.th

Received: 20 September 2020; Accepted: 18 October 2020

Abstract: A brainwave classification, which does not involve any limb movement and stimulus for character-writing applications, benefits impaired people, in terms of practical communication, because it allows users to command a device/computer directly via electroencephalogram signals. In this paper, we propose a new framework based on Empirical Mode Decomposition (EMD) features along with the Gaussian Mixture Model (GMM) and Kernel Extreme Learning Machine (KELM)-based classifiers. For this purpose, firstly, we introduce EMD to decompose EEG signals into Intrinsic Mode Functions (IMFs), which actually are used as the input features of the brainwave classification for the character-writing application. We hypothesize that EMD along with the appropriate IMF is quite powerful for the brainwave classification, in terms of character applications, because of the wavelet-like decomposition without any down sampling process. Secondly, by getting motivated with shallow learning classifiers, we can provide promising performance for the classification of binary classes, GMM and KELM, which are applied for the learning of features along with the brainwave classification. Lastly, we propose a new method by combining GMM and KELM to fuse the merits of different classifiers. Moreover, the proposed methods are validated by using the volunteer-independent 5-fold cross-validation and accuracy as a standard measurement. The experimental results showed that EMD with the proper IMF achieved better results than the conventional discrete wavelet transform (DWT) feature. Moreover, we found that the EMD feature along with the GMM/KELM-based classifier provides the average accuracy of 77.40% and 80.10%, respectively, which could perform better than the conventional methods where we use DWT along with the artificial neural network classifier in order to get the average accuracy of 80.60%. Furthermore, we obtained the improved performance by combining GMM and KELM, i.e., average accuracy of 80.60%. These outcomes exhibit the usefulness of the EMD



This work is licensed under a Creative Commons Attribution 4.0 International License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

feature combining with GMM and KELM based classifiers for the brainwave classification in terms of the Character-Writing application, which do not require any limb movement and stimulus.

Keywords: Brainwave classification; character-writing application; EMD; GMM; KELM; score combination

1 Introduction

Human communication is an essential activity of passing and interpreting information from one person to another, i.e., exchanges of opinions, emotions, ideas, or facts. Unfortunately, traditional communication is a challenging process for impaired people who does not possess speaking power along with the muscle movements. This motivates researchers to explore the alternative systems [1,2] to help defective people in terms of communication.

So far, brain-computer interface (BCI) [3,4], which enables people to communicate with a computer, has been developed to help defective people to express their thoughts. The standard concept of BCI is to convert measured brain signals into actions such as texts and emotions [5]. Moreover, scholars have explored BCI-based researches based on three types of brain responses: Event-related potentials (ERP), steady-state visual evoked potential (SSVEP) and motor imagery (MI).

An ERP brain response is an electrophysiological response based on the direct effect of motor events. Normally, auditory [6], visual [7] and tactile stimulation [8] are introduced to evoke ERP signals. When the evoked ERP response was measured/analyzed, BCI system could convert the user's intention into several actions depending on the application. For example, in [9], the authors proposed to use P300 wave being an ERP component for communication, known as P300 speller. With this speller, defective users with motor disabilities could choose alphabets based on the changed P300 wave via visual perception with the stimulus on a computer screen.

Furthermore, an SSVEP brain response is another type of visually evoked brain response, which presents natural responses in terms of human visual perception at specific frequencies (i.e., flickering stimulus [10]). When a person focuses the visual stimulus on a monitor screen at a steady flickering frequency, the electrical signals with the same frequency as the stimulus signal can be generated by the human brain. For this reason, it is believed to detect what a user is focusing on the visual stimulus such as liquid crystal display (LCD) and cathode ray tube (CRT) monitors [11]. For example, in [12], the authors presented a spelling application based on the BCI technique by using the SSVEP response. With this speller system, the 45-target characters were introduced with flickers at different frequencies and a sinusoidal stimulation approach was applied to display visual stimuli via an LCD screen. The user could select the desired character by focusing on the designed position of each character.

The final format of brain response is MI response, which is based on the mental imagination of motor behavior/movement. A conventional concept in BCI using the MI response is to convert the user's intention based on the mental imagination. For example, in [13], a MI based BCI system was introduced for communication, known as a MI-speller. With this system, the users could perform the desired mental imagination in terms of controlling the arrow point to the specific hexagon of the desired character. In all the above mentioned BCI, a constant stimulation and limb movements are needed for generating brain responses, which may lead to non-practical applications especially for defective persons. Thus, the BCI system still requires a design where it does not require any stimulation and limb movements.

brainwave classification system could provide better accuracy compared to the conventional DWT information.

- 2) We find that the GMM and KELM methods are better classifiers compared to the conventional ANN-based classifier for distinguishing between a circle and straight line characters.
- 3) The score combination of GMM and KLEM is proposed in this study. It can fuse the complementary information based on different classifiers to further improve the reliability of the detection decision.

The rest of this article is organized as follows: Section 2 introduces the proposed methodology, including data collection, feature extracted by EMD, GMM-based classifier, KELM-based classifier and the score combination of GMM and KELM. Section 3 describes the experimental setup and evaluation rule for our experiment. The performances of brainwave classification are investigated and discussed in Section 4. Finally, Section 5 summarizes the paper and describes the future work.

2 Proposed Methodology

In this section, we provide an overview of the data collection used for the experiment. In addition, the feature extraction and classifiers are described for the brainwave classification in terms of character-writing applications.

2.1 Data Collection

For the data collection, Emotiv EPOC Neuroheadset [18], as shown in Fig. 2, is used for imaging of neural activity of the lobes frontalis. The Raw EEG data were recorded from sixteen electrode positions, including AF3, AF4, F7, F3, F4, F8, FC5, FC6, T7, T8, P7, P3, P4, P8, O1 and O3 as seen in Fig. 3. The signals are sent through the Bluetooth technology and are sampled with a 128 Hz sampling rate.



Figure 2: Emotiv EPOC neuroheadset used as EEG signal acquisition hardware




Figure 3: Electrode positions of Emotiv EPOC neuroheadset

In terms of the recording data, five healthy volunteers participated in the study. Two characters, including a circle and straight line characters are used for the animation as shown in Fig. 4. We followed the process as advised in [14]. Fig. 5 shows the procedure of the data collection. The setup is as follows: 1) A volunteer first wears Emotiv EPOC neuroheadset on his/her head and keeps on the meditation for around 60 sec as illustrated in Fig. 5a. 2) The volunteer is then tested for imagining the circle/straight line characters as illustrated in Fig. 5b. 3) the volunteer will rest for 120 s after imagining the characters for about 30 times.

2.2 Feature Extraction

EMD has been proved to be effective for non-stationary time-series analysis [19], which is one of feature extraction methods that has attracted a lot of attention, in terms of the classification of brainwaves, because of its promising adaptability [20–22]. EMD can be implemented to decompose the EEG signal into different IMFs that provide underlying intra-wave modulated components in the signal. IMFs must satisfy two conditions: 1) the difference between the total number of extreme and total number of zero-crossing is zero or one 2) the mean value of the envelope defined by the local maxima and local minima is (very close) zero.




Figure 4: Two characters used for the animation: (a) Circle and (b) Straight line




Figure 5: The procedure of the data collection consisting of three parts: (a) Preparation, (b) Imagination, (c) relaxation

The steps of EMD algorithm are calculated as follows:

Step 1: Detect the maximum and minimum values of the signal $s(n)$.

Step 2: Apply the cubic spline interpolation to obtain the envelopes $e_{\max}(n)$ and $e_{\min}(n)$.

Step 3: Compute the local mean as

$$m(n) = \frac{e_{\max}(n) + e_{\min}(n)}{2} \quad (1)$$

Step 4: Subtract $m(n)$ from $s(n)$ to get the modal function $c(n)$ as

$$c(n) = s(n) - m(n) \quad (2)$$

Step 5: Acquire the residue as

$$r(n) = m(n) - c(n) \quad (3)$$

Step 6: Decide whether $r(n)$ an IMF or not based on the two basic conditions for IMFs mentioned above.

Step 7: Repeat step 1 to 6 until $r(n)$ cannot be decomposed into the IMF. Finally, the original signal is decomposed into N IMFs and the residual component as follow:

$$s(n) = \sum_{i=1}^N c_i(n) + r(n). \quad (4)$$

In this paper, the IMFs are not directly used as an input of classifier because of the problem of variable-sized windows. If M is the length of a sub-band, $X \{x_1, x_2, \dots, x_M\}$ and $Y \{y_1, y_2, \dots, y_M\}$ are two adjacent sub-bands (IMFs). The information can be defined by using six statistical features [14,22] including mean, average power, standard deviation, ratio of the absolute mean values of adjacent sub bands, skewness and kurtosis. Tab. 1 shows the details of each statistical feature.

Table 1: Six statistical features

Statistical feature names	Formula
Mean (μ)	$\mu = \frac{1}{M} \sum_{j=1}^M x_j $
Average power ($\bar{\mu}$)	$\bar{\mu} = \sqrt{\frac{1}{M} \sum_{j=1}^M x_j^2}$
Standard deviation (σ)	$\sigma = \sqrt{\frac{1}{M} \sum_{j=1}^M (x_j - \mu)^2}$
Ratio of the absolute mean values of adjacent sub bands (Ra)	$Ra = \frac{\sum_{j=1}^M x_j }{\sum_{j=1}^M y_j }$
Skewness (Sk)	$Sk = \sqrt{\frac{1}{M} \sum_{j=1}^M \frac{(x_j - \mu)^3}{\sigma^3}}$
Kurtosis (Ku)	$Ku = \sqrt{\frac{1}{M} \sum_{j=1}^M \frac{(x_j - \mu)^4}{\sigma^4}}$

2.3 Brainwave Classifiers

Although deep learning classifiers, such as deep neural network (DNN) [23], convolutional neural network (CNN) [24] and Long short-term memory (LSTM) [25], have been proved to be effective for the brainwave classification, it is well known that deep classifiers strongly depend on the training data. Moreover, we observe from [26] that deep neural network using multi layers cannot give convincing results for the binary classification. This motivates us to believe that shallow learning classifiers are more efficient than deep learning classifiers for the binary classification. In this paper, the GMM and KELM approaches are adopted for the brainwave classification. In addition to using the GMM/KELM approach alone, the combined scores of GMM and KELM are proposed to fuse the merits based on different classifiers. The details are described as follows.

2.3.1 GMM-Based Classifier

GMM has received a great amount of attention, in terms of the brainwave classification, because of the Gaussian mixture-based ability to model complicated densities. It also provides promising results for the binary classification as suggested in [27]. In this paper, the GMM is implemented to discriminate the circle from the line imagination. It can represent each class as follow:

$$P(O|\lambda) = \sum_{k=1}^{\wp} w_k g\left(O \middle| \mu_k, \sum_k\right), \quad (5)$$

$$\lambda = \left\{ w_k, \mu_k, \sum_k \right\}_{k=1}^{\wp}, \quad (6)$$

where O denotes the feature vectors augmented by six statistical features, w_k is the k^{th} mixture weight, $g(O|\mu_k, \sum_k)$ is a D -variate Gaussian density function with m and diagonal covariance matrix, $\sum$ and $\wp$ is the number of Gaussians.

For the testing phase, the decision of circle/line imagination class is computed by the logarithmic likelihood ratio as:

$$\Lambda_{GMM}(\Upsilon) = \log(\Upsilon|\lambda_{circle}) - \log(P(\Upsilon|\lambda_{line})), \quad (7)$$

where Υ is the testing feature vectors, λ_{circle} and λ_{line} define the GMMs for circle and line imagination classes, respectively.

2.3.2 KELM-Based Classifier

KELM has been proved to be an efficient algorithm for many classification tasks and can also provide an expectable performance for the brainwave classification. This is because of the good generalization, based on the original extreme learning machine (ELM) [28] and the advantage of the kernel function [29], in terms of making effective classification tasks to map nonlinear features. KELM is based on ELM where the mapping kernel function is introduced to replace the hidden layer of ELM. It achieves higher efficiency compared to other methods.

In KELM, we can directly use kernel functions for the feature mapping. Kernel matrix can be represented by using the following equation:

$$\Omega_{KELM} = HH^T \quad (8)$$

where H is the hidden layer output matrix. Ω_{KELM} is a kernel function: $\Omega_{KELM} = h(x_r) \cdot h(x_s) = K(x_r, x_s)$.

Because the Moore–Penrose generalized inverse is used to compute the output weights, the output function of the KELM-based classifier can be expressed as below:

$$f(x) = \begin{bmatrix} K(x, x_1) \\ K(x, x_2) \\ \vdots \\ K(x, x_N) \end{bmatrix} \left(\frac{1}{C} + \Omega_{KELM} \right)^{-1} T \quad (9)$$

where T denotes the target (label) matrix, similar to SVM. I is the identity matrix. C denotes the regularization coefficient.

For the testing phase, the decision of circle/line imagination classes is based on the difference of two classes as below:

$$\Lambda_{KELM}(\Upsilon) = P(t_{circle} | f(\Upsilon)) - P(t_{line} | f(\Upsilon)) \quad (10)$$

where $P(t_{circle} | f(\Upsilon))$ and $P(t_{line} | f(\Upsilon))$ are the posterior probability of circle and line imagination. In this paper, we employ the radial basis function as an effective kernel function. Further details of KELM can be found in [29].

2.3.3 Score Combination of GMM and KELM

Score combination gives a mechanism to fuse the merits of different classifiers in order to increase the decision performance. It has been adopted in many applications [16,30,31]. In this paper, the score combination is also used in our experiment. Fig. 6 shows the block diagram of score combination of GMM and KELM. To achieve the combined score, the scores of GMM and KLEM are linearly coupled by the following equation:

$$\Lambda_{COMB}(\Upsilon) = \alpha \Lambda_{GMM}(\Upsilon) + (1 - \alpha) \Lambda_{KELM}(\Upsilon) \quad (11)$$

where $\Lambda_{GMM}(\Upsilon)$ and $\Lambda_{KELM}(\Upsilon)$ are the scores of GMM and KELM model, respectively. Moreover, α is a weighing coefficient.




Figure 6: Block diagram of score combination of GMM and KELM

3 Experimental Setup and Evaluation Rule

In terms of recording the data, since previous work showed that the signals from two electrodes which are positioned at F3 and F4 are the suitable electrodes for the character-writing application as summarized in [14], the data from two these electrodes positions are used

in our experiment. Here, the evaluation data which used in the experiment follows previous studies [14,15]. Therefore, each volunteer is required to image circle characters by 100 times and straight line characters by 100 times so that we obtain 500 circle signals and 500 straight line signals to investigate the proposed methods.

In terms of the feature extracted with the help of EMD method, we used the cubic spline interpolation to interpolate maxima and minima in order to obtain the upper and lower envelope. The first 5 IMFs based on EMD was extracted by using the six statistical methods as explained in Section 2.2. Fig. 7 shows the first 5 IMFs before the statistical methods.




Figure 7: Signals of the first five IMFs/sub bands obtained through EMD method where (a) first columns are derived from circle characters and (b) second columns are derived from line characters

In the GMM-based classifier, the two GMMs for a circle and line imagination classes have 256-components. Motivated by [27], the expectation maximization algorithm along with the likelihood estimation is adopted to train these GMMs. For the KELM-based classifier, we found that high values of regularization coefficient and kernel parameter perform a similar performance compared with low values of regularization coefficient and kernel parameter because high values of regularization coefficient and kernel parameter are suitable for the high-dimensional feature space. As a result, minimum low values of regularization coefficient and kernel parameter with the best performance are selected. Here, the regularization coefficient and kernel parameter of the KELM were set to 100. For the score combination, the uniformly-weighted average as summarized in [32] is applied in this study, so the weighing coefficient is set to 0.5.

All the proposed classifier models were evaluated by using the volunteer-independent 5-fold cross-validation. In each fold, the data sets from four different volunteers were used to train

the model and the data sets from the remaining volunteers were used to evaluate the classifier model performance. From the volunteer-independent 5-fold cross-validation, 400 circle signals and 400 straight line signals were used to train the classifier model, while 100 circle signals and 100 straight line signals where the volunteer is different from the volunteers of training datasets were used to investigate the trained model. To investigate the performance of each fold, the accuracy performance is calculated as:

$$Accuracy(\%) = \frac{TC + TS}{TN} \times 100 \quad (12)$$

where TC and TS are the true circle and true straight line where the model correctly classifies the circle and straight line classes, respectively. TN is the total number of testing trials.

4 Results and Discussion

4.1 Results of EMD Using Different IMF Information

Since EMD methods using different IMF information vary the accuracy of the brainwave classification system, we need to find out the suitable IMF representation. Fig. 8 shows the results of different IMF information based on the GMM-based classifier.




Figure 8: Performance of different IMF information

As shown in Fig. 8, based on the GMM-based classifier, we can see that IMF 1 provided the best average accuracy. This is because the IMF, obtained by the first time, has a wideband frequency, which can give the difference between the line and circle character as seen in Fig. 7 (second row). Therefore, EMD with IMF 1 was used for all the next experiments.

Although our previous work reported that the pair of F3 and F4 provide the best result, some study [15] showed that by using only one position could provide promising performance for the brainwave classification. The F3 and F4 positions were investigated to find out the suitable EEG position. Fig. 9 shows the comparison of F3 and F4 positions based on the EMD-GMM-based classifier.

3040

CMC, 2021, vol.66, no.3




Figure 9: Performance of different EEG channels in terms of accuracy (%)

From Fig. 9, we can note that the F3 position significantly provided better average accuracy than the F4 position because the F3 position provided different information between the circle and line imagination signals. This leads to the obvious statistical features along with the efficient classifier. Similar trend can be found in [15]. Here, the best result with average accuracy has a high reliability for practical application. Therefore, the F3 position was used for all the next experiments.

4.2 Results of the Proposed Methods

In this subsection, the GMM, KELM-based classifier along with the fusion of GMM and KELM were compared for the brainwave classification. Fig. 10 shows the results of the KELM-based classifier along with the fusion of GMM and KELM.




Figure 10: Performance of GMM-based classifier, KELM-based classifier, the score combination of GMM and KELM in terms of accuracy (%)

As it can be seen in Fig. 10, the KELM-based classifier performed better than the GMM-based classifier because KELM has high ability to distinguish the circle and straight line characters accurately. Next, the score fusion of GMM and KELM provided an improved performance as

compared to the individual GMM and KELM-based classifiers in term of average accuracy. However, in case of the second and fourth volunteers, the score fusion can give worse performance than single classifier because the scores of two classifiers are too different to combine the decision merits. Similar trend can also be found in [33,34]. Here, the score fusion of GMM and KELM did not perform according to our expectation since the fused score of GMM and KELM provided the slightly improved performance as compared to the single KELM-based classifier. This is due to using the same input feature as summarized in [35].

4.3 Comparison with Some Previous Systems

In this subsection, our previous systems where the results of DWT feature with the ANN-based classifier was used as baseline systems [14,15] to compare the proposed system. In addition, the ANN using six statistical features extracted by EMD (IMF 1) was also used in the comparison. Tab. 2 reports the comparison of proposed systems with the referred systems.

As it can be seen in Tab. 2, we can observe that the ANN using the IMF 1 information outperformed the ANN using the DTW information (Gamma) because IMF 1 can provide more distinct representation than the DTW information. This indicates that IMF 1 is powerful for the brainwave classification in terms of the character-writing application. Next, we can find that the GMM-based classifier performs better than the ANN-based classifier. This is because the MSE function in the ANN-based classifier is non-convex function, making classifier ineffective for the brainwave classification in terms of the character-writing application. In addition, the KELM-based classifier can give the best performance in terms of individual classifiers due to the advantage of kernel mapping. Finally, the score fusion of GMM and KELM provides the best accuracy at 80.60% compared to the above mentioned systems because GMM and KELM have complementary features based on different classifiers. These outcomes show the usefulness of EMD feature with GMM and KELM-based classifiers for the brainwave classification based on the character-writing application, which do not require any limb movement and stimulus.

Table 2: Comparison with some previous systems in terms of accuracy (%)

Feature extraction method at channel	Classifier	Accuracy					
		Volunteer 1	Volunteer 2	Volunteer 3	Volunteer 4	Volunteer 5	Average
DWT at F3 = F4 (our implement set as in [14])	ANN	70.50	69.50	62.00	66.00	73.00	68.20
DWT at F3 (result in [15])	ANN	77.50	63.00	76.00	66.50	87.50	74.10
DWT at F4 (result in [15])	ANN	60.50	52.00	45.00	53.00	57.00	53.50
EMD at F3	ANN	82.00	67.00	68.50	82.00	78.50	75.60
EMD at F3 (proposed)	GMM	78.50	65.00	72.00	89.00	82.50	77.40
EMD at F3 (proposed)	KELM	84.00	71.50	80.00	80.50	84.50	80.10
EMD at F3 (Proposed)	GMM + KELM	84.50	71.00	81.00	81.00	85.50	80.60

5 Conclusions

In this paper, we proposed the brainwave classification by using EMD along with GMM and KELM for the character-writing application. For this purpose, we firstly explored the EMD method to decompose EEG signals into IMFs, which were used via statistical features as the input features of the classifiers. Secondly, the GMM and KELM methods were applied as classifiers. Finally, the score combination of GMM and KELM was proposed to fuse the merits based on different classifiers. The experimental results showed that the EMD with the proper IMF outperformed the DTW information. Furthermore, we found that by using EMD with the GMM and KELM-based classifier provided the average accuracy of 77.40% and 80.10%, respectively, which performed better than using DWT with the ANN-based classifier that gave the average accuracy of 74.10%. Moreover, the improved performance was obtained by combining the GMM and KELM at the average accuracy of 80.60%. These outcomes exhibit the usefulness of the EMD feature with GMM and KELM-based classifiers for the brainwave classification based on the character-writing application, which do not require any limb movement and stimulus.

In the future, by getting inspired by [36], we have a plan to use new neuroheadsets such as Emotiv EPOC+ and Open BCI neuroheadsets instead of EPOC neuroheadset with the aim of further improving the performance. We would also like to combine the phase feature extraction [31,37] and the neural network-based bottleneck feature extraction [38] with the proposed system in the future.

Acknowledgement: All subjects gave their informed consent for inclusion before they participated in the study. The study was conducted in accordance with the Declaration of Helsinki and the protocol was approved by the Ethics Committee of Suranaree University of Technology (License EC-61-14 COA No. 16/2561).

Funding Statement: This work is supported by the SUT research and development fund, and in part by the National Natural Science Foundation of China under Grant 61771333.

Conflicts of Interest: The authors declare that they have no conflicts of interest to report regarding the present study.

References

- [1] G. Prasad, P. Herman, D. Coyle, S. McDonough and J. Crosbie, "Applying a brain-computer interface to support motor imagery practice in people with stroke for upper limb recovery: A feasibility study," *Journal of Neuroengineering and Rehabilitation*, vol. 7, no. 1, pp. 60, 2010.
- [2] C. Brunner, N. Birbaumer, B. Blankertz, C. Guger, A. Kübler *et al.*, "BNCI Horizon 2020: Towards a roadmap for the BCI community," *Brain-Computer Interfaces*, vol. 2, no. 1, pp. 1–10, 2015.
- [3] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [4] G. E. Fabiani, D. J. McFarland, J. R. Wolpaw and G. Pfurtscheller, "Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 12, no. 3, pp. 331–338, 2004.
- [5] A. Al-Naffjan, M. Hosny, Y. Al-Othman and A. Al-Wabil, "Review and classification of emotion recognition based on EEG brain-computer interface system research: A systematic review," *Applied Sciences*, vol. 7, no. 12, pp. 1239, 2017.
- [6] G. E. Fabiani, D. J. McFarland, J. R. Wolpaw and G. Pfurtscheller, "A brain-computer interface controlled auditory event-related potential (P300) spelling system for locked-in patients," *Annals of The New York Academy of Sciences*, vol. 1157, no. 1, pp. 90–100, 2009.

- [7] H. Hwang, V. Y. Ferreria, D. Ulrich, T. Kilic, X. Chatziliadis *et al.*, "A gaze independent brain-computer interface based on visual stimulation through closed eyelids," *Scientific Reports*, vol. 5, pp. 15890, 2015.
- [8] M. Van der Waal, M. Severens, J. Geuze and P. Desain, "Introducing the tactile speller: An ERP-based brain-computer interface for communication," *Journal of Neural Engineering*, vol. 9, no. 4, pp. 045002, 2012.
- [9] L. A. Farwell and E. Donchin, "Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials," *Electroencephalography and Clinical Neurophysiology*, vol. 70, no. 70, pp. 510–523, 1988.
- [10] G. Bin, X. Gao, Y. Wang, B. Hong and S. Gao, "VEP-based brain-computer interfaces: Time, frequency and code modulations," *IEEE Computational Intelligence Magazine*, vol. 4, no. 4, pp. 22–26, 2009.
- [11] Z. Wu, Y. Lai, Y. Xia, D. Wu and D. Yao, "Stimulator selection in SSVEP-based BCI," *Medical Engineering & Physics*, vol. 30, no. 8, pp. 1079–1088, 2008.
- [12] X. Chen, Z. Chen, S. Gao and X. Gao, "A high-ITR SSVEP-based BCI speller," *Brain-Computer Interfaces*, vol. 1, no. 3–4, pp. 181–191, 2014.
- [13] B. Blankertz, G. Dornhege, M. Krauledat, M. Schroder, J. Williamson *et al.*, "The berlin brain-computer interface presents the novel mental typewriter hex-o-spell," in *3rd Int. Brain Computer Interface Workshop and Training Course*, Graz, Austria, pp. 108–109, 2006.
- [14] T. Jumphoo, M. Uthansakul and P. Uthansakul, "Brainwave classification without the help of limb movement and any stimulus for character-writing application," *Cognitive Systems Research*, vol. 58, pp. 375–386, 2019.
- [15] K. Kokkhunthod, T. Jumphoo and P. Uthansakul, "Improving brainwave classification for character-writing application using single effective EEG channel in SUT," in *Int. Virtual Conf. on Science and Technology*, Nakhon Ratchasima, Thailand, pp. 142–148, 2020.
- [16] K. Phapatanaburi, L. Wang, R. Sakagami, Z. Zhang, X. Li *et al.*, "Distant-talking accent recognition by combining GMM and DNN," *Multimedia Tools and Applications*, vol. 75, no. 9, pp. 5109–5124, 2016.
- [17] J. Cao, J. Zhu, W. Hu and A. Kummert, "Epileptic signal classification with deep EEG features by stacked CNNs," *IEEE Transactions on Cognitive and Developmental Systems*, vol. 75, no. 9, pp. 1, 2019.
- [18] L. Vokorokos, B. Madoš, N. Ádám and A. Baláz, "Data acquisition in non-invasive brain-computer interface using emotiv Epoc neuroheadset," *Acta Electrotechnica et Informatica*, vol. 12, no. 1, pp. 422, 2012.
- [19] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih *et al.*, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," in *Proc. of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, vol. 454, no. 1971, pp. 903–995, 1998.
- [20] N. Ji, L. Ma, H. Dong and X. Zhang, "EEG signals feature extraction based on DWT and EMD combined with approximate entropy," *Brain Sciences*, vol. 9, no. 8, pp. 201, 2019.
- [21] P. A. Muñoz-Gutiérrez, E. Giraldo and M. Bueno-López, "Localization of active brain sources from EEG signals using empirical mode decomposition: A comparative study," *Frontiers in Integrative Neuroscience*, vol. 19, pp. 55, 2018.
- [22] A. Subasi, S. Jukic and J. Kevric, "Comparison of EMD, DWT and WPD for the localization of epileptogenic foci using random forest classifier," *Measurement*, vol. 146, pp. 846–855, 2019.
- [23] R. K. Tripathy and U. R. Acharya, "Use of features from RR-time series and EEG signals for automated classification of sleep stages in deep neural network framework," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 4, pp. 890–902, 2018.
- [24] Z. Tang, C. Li and S. Sun, "Single-trial EEG classification of motor imagery using deep convolutional neural networks," *Optik*, vol. 130, pp. 11–18, 2017.

- [25] P. Wang, A. Jiang, X. Liu, J. Shang and L. Zhang, "LSTM-based EEG classification in motor imagery tasks," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 11, pp. 2086–2095, 2018.
- [26] K. Phapatanaburi, L. Wang, Z. Oo, W. Li, S. Nakagawa *et al.*, "Noise robust voice activity detection using joint phase and magnitude based feature enhancement," *Journal of Ambient Intelligence and Humanized Computing*, vol. 8, no. 6, pp. 845–859, 2017.
- [27] C. Hanilçi, T. Kinnunen, M. Sahidullah and A. Sizov, "Classifiers for synthetic speech detection: A comparison," in *Annual Conf. of the International Speech Communication Association*, Dresden, Germany, pp. 2087–2091, 2015.
- [28] G. B. Huang, H. Zhou, X. Ding and R. Zhang, "Extreme learning machine for regression and multiclass classification," *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 42, no. 2, pp. 513–529, 2012.
- [29] M. Zhang, X. Zhang, H. Wang, G. Xiong and W. Cheng, "Features fusion exaction and KELM with modified grey wolf optimizer for mixture control chart patterns recognition," *IEEE Access*, vol. 8, pp. 42469–42480, 2020.
- [30] S. Kundu and S. Ari, "Fusion of convolutional neural networks for P300 based character recognition," in *Proc. of 2019 Int. Conf. on Information Technology*, Quito, Ecuador, pp. 155–159, 2019.
- [31] K. Phapatanaburi, L. Wang, S. Nakagawa and M. Iwahashi, "Replay attack detection using linear prediction analysis-based relative phase features," *IEEE Access*, vol. 7, pp. 183614–183625, 2019.
- [32] M. F. Font, "Maximum-likelihood linear regression coefficients as features for speaker recognition," Ph.D. dissertation. Faculté des sciences d'Orsay, Université Paris-Saclay, Essonne, Paris, 2009.
- [33] L. Wang, S. Nakagawa, Z. Zhang, Y. Yoshida and Y. Kawakami, "Spoofing speech detection using modified relative phase information," *IEEE Journal of Selected Topics in Signal Processing*, vol. 11, no. 4, pp. 660–670, 2017.
- [34] M. R. Kamble and H. A. Patil, "Novel energy separation based instantaneous frequency features for spoof speech detection," in *IEEE 25th European Signal Processing Conf.*, Kos island, Greece, pp. 106–110, 2017.
- [35] Z. Chen, Z. Xie, W. Zhang and X. Xu, "ResNet and model fusion for automatic spoofing detection," in *Annual Conf. of the International Speech Communication Association*, Stockholm, Sweden, pp. 102–106, 2017.
- [36] P. Sawangjai, S. Hompoonsup, P. Leelaarporn, S. Kongwudhikunakorn and T. Wilaiprasitporn, "Consumer grade EEG measuring sensors as research tools: A review," *IEEE Sensors Journal*, vol. 20, no. 8, pp. 3996–4024, 2020.
- [37] Z. Oo, L. Wang, K. Phapatanaburi, M. Liu, S. Nakagawa *et al.*, "Replay attack detection with auditory filter-based relative phase features," *EURASIP Journal on Audio, Speech, and Music Processing*, vol. 2019, no. 1, pp. 130, 2019.
- [38] B. Ren, L. Wang, L. Lu, Y. Ueda and A. Kai, "Combination of bottleneck feature extraction and dereverberation for distant-talking speech recognition," *Multimedia Tools and Applications*, vol. 75, no. 9, pp. 5093–5108, 2016.

ประวัติผู้เขียน

นาย กษิดิศ กกขุนทด เกิดเมื่อวันที่ 27 กันยายน พ.ศ. 2539 เริ่มศึกษาชั้นประถมที่โรงเรียนวัดสระแก้วชั้นประถมศึกษาปีที่ 2-6 ที่โรงเรียนโรงเรียนบุญเหลือวิทยานุสรณ์ชั้นมัธยมศึกษาปีที่ 1-6 จังหวัดนครราชสีมา และสำเร็จการศึกษาระดับปริญญาตรี สาขาวิชาวิศวกรรมอิเล็กทรอนิกส์ และโทรคมนาคม คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคล อีสาน จังหวัดนครราชสีมา เมื่อปี พ.ศ.2561

ปี พ.ศ.2562 เข้าศึกษาต่อในระดับปริญญาโท สาขาวิชาวิศวกรรมโทรคมนาคม มหาวิทยาลัยเทคโนโลยีสุรนารี โดยขณะศึกษาได้รับทุนการศึกษาแก่นักศึกษาระดับบัณฑิตศึกษาที่คณาจารย์ได้รับทุนวิจัยจากแหล่งทุนภายนอกจากกองทุนสนับสนุนการวิจัยและพัฒนา (ทุน OROG) และเป็นผู้ช่วยนักวิจัยโครงการวิจัย เรื่อง โครงการพัฒนาขาเทียมสำหรับกำลังพลผู้ได้รับบาดเจ็บโดยใช้การควบคุมแขนเทียมทดด้วยชีวสัญญาณ

ผลงานวิจัย : ได้เสนอบทความเข้าร่วมในการประชุมวิชาการระดับนานาชาติ The SUT International Virtual Conference on Science and Technology (The SUT - IVCST 2020) วันที่ 28 สิงหาคม 2563 เรื่อง การปรับปรุงการจำแนกประเภทคลื่นไฟฟ้าสมองสำหรับการเขียนอักขระโดยใช้ช่องสัญญาณ EEG ช่องเดียวที่มีประสิทธิภาพ