

การจำแนกประเภทคลื่นไฟฟ้าสมองบนสภาพแวดล้อมแบบไม่คงที่



บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของวิทยานิพนธ์ตั้งแต่ปีการศึกษา 2554 ที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)  
เป็นแฟ้มข้อมูลของนิสิตเจ้าของวิทยานิพนธ์ ที่ส่งผ่านทางบัณฑิตวิทยาลัย

The abstract and full text of theses from the academic year 2011 in Chulalongkorn University Intellectual Repository (CUIR)  
are the thesis authors' files submitted through the University Graduate School.

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมซอฟต์แวร์ ภาควิชาวิศวกรรมคอมพิวเตอร์  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2559  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

# EEG Classification on Non-Stationary Environment

Mr. Sitthiphong Muthong



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science Program in Software Engineering

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2016

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การจำแนกประเภทคลื่นไฟฟ้าสมองบนสภาพแวดล้อมแบบไม่คงที่
โดย	นายสิทธิพงษ์ หมู่ทอง
สาขาวิชา	วิศวกรรมซอฟต์แวร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ดร. พีรพล เวทีกุล
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	รองศาสตราจารย์ ดร. มานะ ศรียุทธศักดิ์

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

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

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ  
(ผู้ช่วยศาสตราจารย์ นครทิพย์ พร้อมพูล)  
.....อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(ดร. พีรพล เวทีกุล)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม  
(รองศาสตราจารย์ ดร. มานะ ศรียุทธศักดิ์)

.....กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร. โชติรัตน์ รัตนามหัทธนะ)

.....กรรมการภายนอกมหาวิทยาลัย  
(ดร. พศิน อิศรเสนา ณ อยุธยา)

สิทธิพงษ์ หมูทอง : การจำแนกประเภทคลื่นไฟฟ้าสมองบนสภาพแวดล้อมแบบไม่คงที่ (EEG Classification on Non-Stationary Environment) อ.ที่ปรึกษาวิทยานิพนธ์หลัก: ดร. พีรพล เวทีกุล, อ.ที่ปรึกษาวิทยานิพนธ์ร่วม: รศ. ดร. มานะ ศรียุทธศักดิ์, 96 หน้า.

ในช่วงหลายปีที่ผ่านมา คลื่นไฟฟ้าสมองถูกนำมาใช้อย่างแพร่หลายในงานด้านต่าง ๆ เช่น การตรวจสอบโรคลมบ้าหมูและลมชัก การตรวจสอบการนอนหลับ การตรวจสอบความผิดปกติในการทำงานของสมอง การใช้ในการสื่อสารระหว่างบุคคลและคอมพิวเตอร์ งานวิจัยนี้ประยุกต์ใช้คลื่นไฟฟ้าสมองสำหรับการสื่อสาร โดยเฉพาะอย่างยิ่งเน้นการใช้งานกับผู้ที่มีความพิการทั้งร่างกายและไม่สามารถสื่อสารได้ด้วยวิธีการปกติเช่น พูดและขยับตัวไม่ได้ ดังนั้นเราจึงได้นำเสนอวิธีการเพื่อจำแนกประเภทการจินตนาการของผู้ป่วยเพื่อแทนคำตอบว่าใช่และไม่ใช่ ทั้งนี้มีงานวิจัยที่ได้ถูกนำเสนอมากมายแต่พบว่างานเหล่านั้นไม่ได้ให้ความสำคัญกับคุณสมบัติความไม่คงที่ของสัญญาณ จึงทำให้ประสบปัญหาความแม่นยำต่ำเมื่อนำวิธีการเหล่านั้นไปใช้งานในสภาพแวดล้อมจริง งานวิจัยนี้มุ่งแก้ปัญหาความไม่คงที่ของสัญญาณ โดยลดผลกระทบของความไม่คงที่บนข้อมูลฝึกด้วยการปรับปรุงตัวจำแนกประเภทแบบเดิมให้เป็นแบบรวมหรือแบบวางซ้อน ซึ่งตัวจำแนกประเภทที่นำเสนอถูกสร้างจากข้อมูลฝึกที่ตัดแบ่งด้วยวิธีการตรวจสอบการเปลี่ยนแปลงเพื่อแยกกลุ่มข้อมูลที่แตกต่างกันออกจากกัน ในข้อมูลทดสอบนั้นได้ปรับใช้กระบวนการปรับตัวเพื่อปรับข้อมูลทดสอบให้เข้าหาการกระจายตัวของข้อมูลฝึกให้มากที่สุด โดยวิธีการที่นำเสนอถูกประเมินบนข้อมูลการทดลองจากกลุ่มวิจัย BCI Competition ชุดข้อมูล 2b และเปรียบเทียบกับ (1) วิธีการจำแนกประเภทแบบคงที่ (2) วิธีการจำแนกประเภทปรับตัวได้พลูมินแบบต่าง ๆ (3) วิธีการที่นิยมใช้ในปัจจุบัน 3 วิธีการได้แก่ CSEM, ACSP และ PMean LDA วิธีการที่นำเสนอสามารถลดผลกระทบของความไม่คงที่ของสัญญาณทั้งบนข้อมูลฝึกที่ถูกเก็บจากหลายช่วงเวลา และความไม่คงที่ของข้อมูลทดสอบที่อยู่ต่างช่วงเวลากับข้อมูลฝึก ซึ่งผลการทดลองพบว่าวิธีการที่นำเสนอมีความแม่นยำดีกว่าทุกวิธีการที่ถูกนำมาเปรียบเทียบอย่างมีนัยสำคัญ และแม่นยำกว่าวิธีการที่ดีที่สุดประมาณ 3% โดยเฉลี่ย

ภาควิชา วิศวกรรมคอมพิวเตอร์

ลายมือชื่อนิสิต .....

สาขาวิชา วิศวกรรมซอฟต์แวร์

ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

ปีการศึกษา 2559

ลายมือชื่อ อ.ที่ปรึกษาร่วม .....

# # 5771015121 : MAJOR SOFTWARE ENGINEERING

KEYWORDS: BRAIN COMPUTER INTERFACE / BCI / EEG / MOTOR IMAGERY / ELECTROENCEPHALOGRAM / CHANGE POINT ANALYSIS / CHANGE POINT DETECTION / LINEAR DISCRIMINANT ANALYSIS (LDA) / SUPPORT VECTOR MACHINE

SITTHIPHONG MUTHONG: EEG Classification on Non-Stationary Environment.  
 ADVISOR: PEERAPON VATEEKUL, Ph.D., CO-ADVISOR: ASSOC. PROF. MANA SRIYUDTHSAK, Ph.D., 96 pp.

Over the past several years, electroencephalography (EEG) has become widely used in many domains, e.g., epilepsy and seizure testing, sleep assessment, brain dysfunction assessment and brain-computer interface. In this thesis, EEG is used as a method of communication for patients, especially those with Total Locked-in Syndrome. In this condition, the patient cannot move or communicate verbally due to a complete paralysis of nearly all voluntary muscles in the body. Therefore, we propose the classification method of the patient's imagination for representing YES/NO answer. Although there were many classification techniques, none of them considered the non-stationary characteristic of brainwaves; thus, they cannot really be employed in real-world situations due to low classification accuracy. This research aims to tackle the non-stationary issue by modifying the traditional classifier to be stacked classifiers, the proposed new classifier constructed by a group of EEG signals that partitioned based on data distribution. We also employ an adaptive process for adjusting test data to reflect train distribution closely. The experiment was conducted on the BCI Competition IV (2b) data set. Our proposed method was compared to nine baseline techniques in three groups: (1) static algorithms, (2) variants of adaptive Pool Mean algorithms, (3) the state of the art Adaptive CSP method, Corrected Sequential EM and PMean LDA. The proposed method has shown to reduce the non-stationary characteristic of EEG signal in both training and testing data. The results showed that our proposed method significantly outperform all baselines and yield 3% accuracy better than the best baseline method.

Department: Computer Engineering      Student's Signature .....

Field of Study: Software Engineering      Advisor's Signature .....

Academic Year: 2016      Co-Advisor's Signature .....

## กิตติกรรมประกาศ

ตลอดช่วงเวลาที่ได้เข้าศึกษาและจัดทำวิทยานิพนธ์เล่มนี้ ได้มีอุปสรรคต่าง ๆ เกิดขึ้น นานัปการ อันเป็นบทเรียนที่ทรงคุณค่าต่อผู้จัดทำ ซึ่งจะได้เรียนรู้ ฝึกฝน แก้ปัญหาเพื่อพัฒนาตนเองและเพิ่มพูนทักษะต่าง ๆ ที่จำเป็นสำหรับการเป็นผู้วิจัยที่ดี อย่างไรก็ตามวิทยานิพนธ์ฉบับนี้ จะไม่สามารถสำเร็จลุล่วงไปได้ด้วยดีหากขาดการสนับสนุนจากบุคคลหลาย ๆ ฝ่าย ซึ่งผู้จัดทำมีความซาบซึ้งในความกรุณาอันล้นพ้น และขอใช้เนื้อหาในกิตติกรรมประกาศเพื่อเป็นสื่อกลางในการแสดงความขอบคุณมา ณ โอกาสนี้

ประการแรก ขอขอบพระคุณ ดร.พีรพล เวทีกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้ช่วยอบรม สั่งสอน ชี้แนะแนวทางในการทำวิจัยและแก้ปัญหาที่เกิดขึ้นระหว่างการทำวิจัยด้วยดีเสมอมา ซึ่งเป็นปัจจัยหลักที่ทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปด้วยดี

ขอขอบพระคุณ รองศาสตราจารย์ ดร.มานะ ศรียุทธศักดิ์ อาจารย์ที่ปรึกษาร่วมวิทยานิพนธ์ ผู้ซึ่งเสียสละเวลาเป็นอย่างมากเพื่อให้เข้าพบและขอคำปรึกษาปัญหาเกี่ยวกับการทำวิจัย ชี้แนะแนวทางและให้แนวคิดในการทำวิจัย หากปราศจากท่านแล้ว วิทยานิพนธ์ฉบับนี้ก็ไม่สามารถสำเร็จลุล่วงไปได้ด้วยดีเช่นกัน

ขอขอบพระคุณท่านคณะกรรมการสอบวิทยานิพนธ์ ที่ให้ข้อคิดและข้อเสนอแนะต่าง ๆ อันเป็นประโยชน์อย่างยิ่งในการพัฒนาคุณภาพของวิทยานิพนธ์ฉบับนี้ ซึ่งคณะกรรมการสอบนั้น ประกอบไปด้วย ผู้ช่วยศาสตราจารย์นครทิพย์ พร้อมพูล ผู้ช่วยศาสตราจารย์ ดร.โชติรัตน์ รัตนามัทธนะ และ ดร.พศิน อิศรเสนา ณ อยุธยา

ขอบคุณเพื่อน ๆ พี่ ๆ และน้อง ๆ ในห้องปฏิบัติการ MIND Lab ทุกคนที่ช่วยทำให้การทำวิจัยมีสีสัน รวมถึงช่วยวิจารณ์ ให้แนวคิดและคำแนะนำต่าง ๆ เพื่อแก้ปัญหาที่พบเจอระหว่างการทำวิจัย

สุดท้ายที่ขาดมิได้ ขอขอบพระคุณ บิดามารดา ของผู้จัดทำที่เป็นกำลังใจและให้การสนับสนุนในทุก ๆ เรื่องด้วยดีเสมอมา

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	12
สารบัญภาพ.....	14
บทที่ 1 บทนำ.....	16
1.1 ความเป็นมาและความสำคัญของปัญหา.....	16
1.2 วัตถุประสงค์ของการวิจัย.....	17
1.3 ขอบเขตของการวิจัย.....	17
1.4 ขั้นตอนและวิธีดำเนินการวิจัย.....	17
1.5 ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย.....	18
1.6 ผลงานวิจัยที่ได้รับการตีพิมพ์.....	18
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	19
2.1 คลื่นไฟฟ้าสมอง (Brain wave).....	19
2.2 วิธีการสกัดคุณลักษณะ (Feature Extraction Techniques).....	21
2.2.1 ตัวกรองช่องสัญญาณ (Common Spatial Pattern: CSP).....	21
2.2.2 ความหนาแน่นสเปกตรัมกำลัง (Power Spectrum Density: PSD).....	22
2.2.3 การแปลงเวฟเล็ต (Wavelet Transform).....	23
2.3 วิธีการเลือกคุณลักษณะ (Feature Selection Techniques).....	25
2.3.1 สหสัมพันธ์ (Correlation).....	25
2.3.2 การทดสอบสมมติฐาน (Hypothesis Testing).....	25

2.4 การเรียนรู้ในสภาพแวดล้อมไม่คงที่ (Learning in Non-Stationary Environments).....	26
2.4.1 การเปลี่ยนแปลงของความรู้ (Knowledge Change).....	26
2.4.2 การเลื่อนของความรู้ (Knowledge Shift).....	26
2.4.2.1 ความแปรปรวนร่วมเกี่ยวเลื่อน (Covariate Shift).....	26
2.4.2.2 การปรับตัวของโดเมน (Domain Adaptation) .....	27
2.4.2.3 การถ่ายทอดการเรียนรู้ (Transfer Learning) .....	27
2.4.3 แบบจำลองปรับตัว (Adaptation Model).....	28
2.4.3.1 วิธีการแบบแอคทีฟ (Active Approach).....	28
2.4.3.2 วิธีการแบบพาสซีฟ (Passive Approach) .....	28
2.5 วิธีการจำแนกประเภท (Classification Techniques) .....	29
2.5.1 การวิเคราะห์ดิสคริมิแนนต์เชิงเส้นหรือแอลดีเอ (Linear Discriminant Analysis: LDA).....	29
2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM).....	30
2.5.3 โครงข่ายประสาทเทียม (Neural Networks).....	31
2.6 งานวิจัยที่เกี่ยวข้อง (Related Research) .....	34
2.6.1 งานวิจัยด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหว .....	34
2.6.2 งานวิจัยด้านการเพิ่มความแม่นยำของการจำแนกประเภทด้วยแบบจำลองปรับตัว ....	40
บทที่ 3 การจำแนกประเภทคลื่นไฟฟ้าสมองบนสภาพแวดล้อมแบบไม่คงที่.....	44
3.1 การเลือกช่องสัญญาณและประมวลผลขั้นต้น (Channel Selection and Data Preprocessing).....	44
3.2 การแบ่งกลุ่มข้อมูลโดยใช้การตรวจจับการเปลี่ยนแปลงของสัญญาณ (Data Partitioning based on Change Detection).....	45
3.2.1 การรวมส่วนแบ่งขนาดเล็ก (Small Partition Merging).....	47
3.2.2 การตัดแบ่งส่วนแบ่งขนาดใหญ่ (Large Partition Splitting).....	47



3.3 ตัวกรองช่องสัญญาณฟิลเตอร์แบงก์ (Filter Bank Common Spatial Pattern; FBCSP; Filter Bank CSP) .....	47
3.4 กระบวนการปรับตัว (Adaptive Process) .....	48
3.5 ตัวจำแนกประเภทแบบวางซ้อน .....	48
3.5.1 ตัวจำแนกประเภทแบบวางซ้อนอาร์แอลดีเอ (Stacked Probabilistic Regularized LDA : SPRLDA) .....	48
3.5.2 ตัวจำแนกประเภทแบบวางซ้อนเอสวิเอ็ม (Stacked SVM).....	49
บทที่ 4 การทดลองและการวิเคราะห์ผล.....	51
4.1 ข้อมูลที่ใช้ทดลองในงานวิจัย .....	51
4.2 การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation) .....	53
4.3 การเตรียมการและกระบวนการทดลอง.....	54
4.3.1 กระบวนการทดลอง.....	54
4.3.2 การออกแบบการทดลองสำหรับแบบจำลองการจำแนกประเภทที่นำเสนอ .....	55
4.3.3 วิธีการที่ใช้ในการเปรียบเทียบ (Baseline Methods).....	56
4.4 ผลการทดลองและวิเคราะห์ผลสำหรับแบบจำลองที่ขึ้นกับบุคคล .....	57
4.4.1 การวัดประสิทธิภาพด้วยการตรวจสอบสลิปส่วนตัว .....	57
4.4.2 การวัดประสิทธิภาพด้วยการแบ่งข้อมูลทดสอบ .....	59
4.5 ผลการทดลองและวิเคราะห์ผลเพื่อเปรียบเทียบระหว่างแบบจำลองที่ขึ้นกับบุคคลและแบบจำลองที่ไม่ขึ้นกับบุคคล.....	61
4.5.1 จำนวนข้อผิดพลาดที่ส่งผลกระทบต่อความแม่นยำของตัวจำแนกประเภทในแบบจำลองที่ขึ้นกับบุคคล.....	61
4.5.2 วิธีการที่นำเสนอบนแบบจำลองที่ไม่ขึ้นกับบุคคล .....	62
บทที่ 5 การพัฒนาระบบต้นแบบ.....	63
5.1 ภาพรวมของระบบ .....	63

5.2 ความต้องการของระบบ .....	64
5.2.1 ความต้องการเชิงหน้าที่ (Functional Requirements).....	64
5.2.2 ความต้องการที่ไม่ใช่หน้าที่ (Non-Functional Requirements) .....	72
5.3 โครงสร้างและการทำงานของระบบ .....	73
5.3.1 โครงสร้างของระบบต้นแบบ .....	73
5.3.2 การทำงานของส่วนการจำแนกประเภท.....	74
5.3.3 การทำงานของส่วนการฝึกสอนตัวจำแนกประเภท.....	75
5.4 การพัฒนาระบบต้นแบบ .....	75
5.4.1 เครื่องมือสนับสนุนที่ใช้งาน.....	75
5.4.2 ส่วนต่อประสานผู้ใช้ (User Interface) .....	76
5.4.2.1 ส่วนต่อประสานการจำแนกประเภท.....	77
5.4.2.2 ส่วนต่อประสานการฝึกสอนตัวจำแนกประเภท .....	78
5.4.2.3 ส่วนต่อประสานการแสดงผลลัพธ์.....	78
5.4.2.4 ส่วนต่อประสานการแสดงผลสัญญาณคลื่นไฟฟ้าสมอง.....	79
5.4.2.5 ส่วนต่อประสานการแสดงผลตอบสนองเชิงความถี่ .....	79
5.4.2.6 หน้าต่างการตั้งค่าพารามิเตอร์.....	80
5.5 การใช้งานระบบ (System Deployment).....	81
บทที่ 6 สรุปผลการวิจัยและข้อเสนอแนะ .....	82
6.1 สรุปผลการวิจัย.....	82
6.2 ข้อเสนอแนะ .....	83
6.3 งานวิจัยในอนาคต.....	83
รายการอ้างอิง .....	84
ภาคผนวก.....	90

ภาคผนวก ก. รายละเอียดชุดข้อมูล.....	91
ประวัติผู้เขียนวิทยานิพนธ์ .....	96



## สารบัญตาราง

	หน้า
ตารางที่ 2.1 งานวิจัยด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหว	38
ตารางที่ 2.2 เปรียบเทียบความแม่นยำของการนำเสนอวิธีการแบบปรับตัวได้กับวิธีการแบบคงที่ และวิธีการแบบปรับตัวได้เทียบเคียง	42
ตารางที่ 3.1 รหัสเทียมแสดงขั้นตอนการทำงานของวิธีการแบ่งส่วนแบ่งแบบเหมาะสม [54]	46
ตารางที่ 4.1 ชุดข้อมูลที่ใช้ในการจำแนกประเภทการจินตนาการเคลื่อนไหว	52
ตารางที่ 4.2 เมทริกซ์ความสับสนของข้อมูลซึ่งมี 2 คลาส	53
ตารางที่ 4.3 เปรียบเทียบความแม่นยำระหว่างวิธีการที่นำเสนอและวิธีการเปรียบเทียบ โดยใช้ วิธีการประเมินแบบการตรวจสอบสืบสวนไขว้	58
ตารางที่ 4.4 เปรียบเทียบความแม่นยำระหว่างวิธีการที่นำเสนอและวิธีการเปรียบเทียบ โดยใช้ วิธีการประเมินแบบแบ่งข้อมูลทดสอบ	60
ตารางที่ 5.1 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าหน้าต่างโปรแกรม	66
ตารางที่ 5.2 คำอธิบายยูสเคสของผู้ใช้เพื่อเรียกคืนค่าหน้าต่างโปรแกรม	66
ตารางที่ 5.3 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าสภาพแวดล้อม	66
ตารางที่ 5.4 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าการจำแนกประเภท	67
ตารางที่ 5.5 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าฝึกสอนตัวจำแนกประเภท	67
ตารางที่ 5.6 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าทางเลือกในการจำแนกประเภท	67
ตารางที่ 5.7 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าพารามิเตอร์	68
ตารางที่ 5.8 คำอธิบายยูสเคสของผู้ใช้เพื่อเรียกคืนค่าพารามิเตอร์ที่บันทึกไว้	68
ตารางที่ 5.9 คำอธิบายยูสเคสของการแสดงผลสัญญาณคลื่นไฟฟ้าสมอง	68
ตารางที่ 5.10 คำอธิบายยูสเคสของการแสดงตอบสนองเชิงความถี่ของสัญญาณ	69
ตารางที่ 5.11 คำอธิบายยูสเคสของผู้ใช้เริ่มการจำแนกประเภทสัญญาณ	69
ตารางที่ 5.12 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าแสดงผลการทำงานของทำนายเป็นค่าปริยาย	69
ตารางที่ 5.13 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าตัวอย่างข้อมูลถัดไป	70

ตารางที่ 5.14 คำอธิบายยูสเคสของผู้ใช้เพื่อฝึกสอนตัวจำแนกประเภท	70
ตารางที่ 5.15 คำอธิบายยูสเคสของผู้ใช้เพื่อลบตัวอย่างข้อมูลที่ไม่ได้คุณภาพ	70
ตารางที่ 5.16 คำอธิบายยูสเคสของผู้ใช้เพื่อเลื่อนดูข้อมูลฝึกสอน	71
ตารางที่ 5.17 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลในลักษณะยังไม่มีกรจำแนก	71
ตารางที่ 5.18 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลลัพธ์ลูกบอลขยับ	71
ตารางที่ 5.19 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลลัพธ์ YES/NO	72
ตารางที่ 5.20 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงคะแนนการจำแนกเทียบกับเวลา	72
ตารางที่ 5.21 รายการความต้องการที่ไม่ใช่หน้าที่ของระบบต้นแบบ	72



## สารบัญภาพ

	หน้า
ภาพที่ 2.1 จุดกำกับบนศีรษะในระบบ 10-20 [24].....	20
ภาพที่ 2.2 ตัวอย่างของการปรับใช้ตัวกรองช่องสัญญาณ.....	22
ภาพที่ 2.3 เวฟเล็ทแม่ชนิดต่าง ๆ [29] .....	24
ภาพที่ 2.4 ขั้นตอนวิธีการแปลงเวฟเล็ท [30].....	25
ภาพที่ 2.5 ความแปรปรวนร่วมเกี่ยวเลื่อน [34] .....	27
ภาพที่ 2.6 ระบายแบ่งเขตข้อมูลที่เหมาะสม [36].....	30
ภาพที่ 2.7 โครงข่ายประสาทเทียมหนึ่งหน่วยแบบหลายอินพุต [38].....	32
ภาพที่ 2.8 โครงข่ายประสาทเทียมหนึ่งชั้น [38].....	33
ภาพที่ 2.9 โครงข่ายประสาทเทียมแบบสามชั้น [38].....	33
ภาพที่ 3.1 กระบวนการทำงานของวิธีการที่น่าเสนอ.....	45
ภาพที่ 3.2 ตัวอย่างผลลัพธ์ของส่วนแบ่งที่ได้จากการตรวจจับการเปลี่ยนแปลง.....	46
ภาพที่ 4.1 การทดลองในหนึ่งช่วงเวลา [58].....	51
ภาพที่ 4.2 การทดลองในหนึ่งการจินตนาการ [58] .....	53
ภาพที่ 4.3 กระบวนการทดลอง.....	55
ภาพที่ 4.4 เปรียบเทียบความแม่นยำต่อจำนวนข้อมูลฝึกของแบบจำลองที่ขึ้นกับบุคคล.....	61
ภาพที่ 4.5 เปรียบเทียบความแม่นยำต่อจำนวนตัวจำแนกประเภทย่อย ที่ประกอบขึ้นเป็นตัว จำแนกประเภทแบบวางซ้อน.....	62
ภาพที่ 5.1 ภาพรวมความต้องการของระบบ .....	64
ภาพที่ 5.2 แผนภาพยูสเคสของระบบต้นแบบ.....	65
ภาพที่ 5.3 โครงสร้างของระบบต้นแบบ .....	73
ภาพที่ 5.4 แผนภาพแสดงกิจกรรมการทำงานส่วนการจำแนกประเภท .....	74
ภาพที่ 5.5 การออกแบบหน้าต่างส่วนต่อประสานของระบบต้นแบบ.....	76

ภาพที่ 5.6 หน้าต่างส่วนต่อประสานของระบบต้นแบบ.....	77
ภาพที่ 5.7 หน้าต่างย่อยการจำแนกประเภท .....	77
ภาพที่ 5.8 หน้าต่างย่อยการฝึกตัวจำแนก .....	78
ภาพที่ 5.9 หน้าต่างย่อยแสดงผลลัพธ์บอลซยับ .....	78
ภาพที่ 5.10 หน้าต่างย่อยแสดงผลลัพธ์ YES/NO .....	79
ภาพที่ 5.11 หน้าต่างย่อยแสดงคะแนนการจำแนกเทียบกับเวลา .....	79
ภาพที่ 5.12 หน้าต่างย่อยแสดงสัญญาณคลื่นไฟฟ้าสมอง .....	79
ภาพที่ 5.13 หน้าต่างย่อยแสดงผลตอบสนองเชิงความถี่.....	80
ภาพที่ 5.14 หน้าต่างย่อยแสดงการตั้งค่าพารามิเตอร์ .....	81
ภาพที่ 5.15 แผนภาพการใช้งานระบบ.....	81



## บทที่ 1

### บทนำ

#### 1.1 ความเป็นมาและความสำคัญของปัญหา

โรคแอลไอเอส (Locked-in Syndrome: LIS) [11] คือโรคที่ผู้ป่วยมีอาการอัมพาตทั้งตัว ไม่สามารถกลืนอาหารและเคลื่อนไหวร่างกายได้ ทำได้เพียงแต่หลับตา ลืมตา กลอกตาขึ้นบนและลงล่างได้เท่านั้นไม่สามารถกลอกตาไปด้านซ้ายและขวาได้ ในผู้ป่วยที่มีอาการรุนแรงและพิการอย่างสิ้นเชิง (Total Locked-in Syndrome) ผู้ป่วยจะไม่สามารถขยับตาขึ้นลงได้ อาการของโรคแอลไอเอสเกิดจากความผิดปกติของสมองส่วนท้าย (สมองส่วนบนยังใช้งานได้ปกติ) ซึ่งทำงานเป็นทางผ่านของเส้นใยประสาทของทุกส่วนของสมองผ่านจากสมองใหญ่ 2 ข้าง (Cerebral hemispheres) มาที่ก้านสมอง และที่ไขสันหลัง (Spinal cord) สาเหตุของความผิดปกติของสมองอาจมีสาเหตุมาจากโรคหลอดเลือดสมอง เช่น กลุ่มหลอดเลือดสมองแตกหรือหลอดเลือดสมองตีบ หรือเกิดจากการบาดเจ็บของสมองโดยตรง เป็นต้น เนื่องจากผู้ป่วยมีอาการอัมพาตทั้งตัว การสื่อสารในช่วงดูแลรักษาระหว่างผู้ป่วยและแพทย์รวมถึงผู้ดูแลนั้นทำได้ยากมาก ซึ่งอาจส่งผลกระทบต่อคุณภาพชีวิตและการรักษาโดยตรง หากการได้รับการสื่อสารหรือตอบสนองที่ผิดพลาด

ด้วยเหตุผลดังกล่าว งานวิจัยนี้จึงมุ่งเน้นการพัฒนาวิธีการและซอฟต์แวร์เพื่อช่วยสนับสนุนการสื่อสารระหว่างผู้ป่วยแอลไอเอสกับแพทย์และผู้ดูแล ผู้เขียนเลือกใช้อุปกรณ์การวัดคลื่นไฟฟ้าสมอง (Electroencephalography: EEG) มาใช้ในการจำแนกประเภท (Classification) สัญญาณที่เกิดจากการจินตนาการการเคลื่อนไหว ซึ่งในระหว่างการบำบัดและดูแลผู้ป่วย แพทย์จะกำหนดคำถามเพื่อการสื่อสาร และผู้ป่วยต้องคิดหรือจินตนาการเพื่อใช้แทนคำตอบที่แทนคำพูดว่า “ใช่” หรือ “ไม่ใช่” เช่นผู้ป่วยจินตนาการว่าขยับมือซ้ายแทนคำตอบว่า “ใช่” และจินตนาการว่าขยับมือขวาแทนคำตอบว่า “ไม่ใช่” เป็นต้น ในระหว่างที่ผู้ป่วยคิดนี้เองสัญญาณสมองจะถูกวัดและนำมาวิเคราะห์ด้วยวิธีการที่นำเสนอเพื่อจำแนกประเภทคำตอบ และซอฟต์แวร์ที่พัฒนาขึ้นมาจะถูกใช้เป็นส่วนต่อประสาน (User Interface: UI) เพื่อให้แพทย์และผู้ดูแลสามารถเข้าใจในสิ่งที่ผู้ป่วยตอบสนองได้

การศึกษาเกี่ยวกับการจำแนกประเภทคลื่นไฟฟ้าสมองนั้นได้รับความสนใจเป็นอย่างมาก โดยเฉพาะในบริบทของการจินตนาการการเคลื่อนไหว เริ่มประสบความสำเร็จตั้งแต่ปี ค.ศ. 1999 โดย Pfurtscheller และคณะ [12-14] ได้ประยุกต์ความรู้ด้านการรู้จำแบบ (Pattern Recognition) ในการออกแบบตัวกรองช่องสัญญาณ (Spatial Filter) เพื่อคัดเลือกตำแหน่งที่มีความเหมาะสมต่อการจำแนกประเภท วิธีการนี้เป็นต้นแบบของวิธีการสกัดคุณลักษณะ (Feature extraction) ที่ได้รับ



ความนิยมจนถึงปัจจุบัน แต่อย่างไรก็ตามวิธีการจำแนกประเภทจากงานวิจัยส่วนใหญ่ก็ไม่อาจนำไปประยุกต์ใช้ในสภาพแวดล้อมจริงได้ เนื่องด้วยไม่ได้แก้ปัญหาเรื่องความไม่คงที่ (Non-Stationary) ของคลื่นไฟฟ้าสมอง ทำให้ผลการจำแนกประเภทไม่มีความแม่นยำเพียงพอ ความไม่คงที่คือความแตกต่างของสัญญาณซึ่งเปลี่ยนแปลงในแต่ละครั้งของการทดลองหรือใช้งาน โดยการเปลี่ยนแปลงสามารถแปรผันได้จากหลายปัจจัย เช่น ความต้านทานของผิวหนัง สภาพอากาศหรืออุณหภูมิขณะนั้น เป็นต้น ซึ่งการเปลี่ยนแปลงจะขึ้นต่อการวัดสัญญาณในแต่ละครั้งที่ใช้งาน (Session dependent) และขึ้นกับตัวบุคคล (Subject dependent) นอกจากความไม่คงที่ในแง่ของความต้านทานของผิวหนังแล้ว ยังมีปัจจัยอื่น ๆ อีกมากมายที่ทำให้เกิดความไม่คงที่ของสัญญาณ เช่นสัญญาณรบกวนจากเครื่องใช้ไฟฟ้าภายในบริเวณใกล้เคียง ตำแหน่งการวัดสัญญาณที่ไม่ใช่ตำแหน่งเดิมในการติดตั้งแต่ละครั้ง ด้วยเหตุผลข้างต้นนี้เองทำให้งานวิจัยด้านการจำแนกประเภทการคิดและจินตนาการจากคลื่นไฟฟ้าสมองนั้นยังคงมีอยู่และได้รับความสนใจอย่างต่อเนื่อง ทั้งนี้เพื่อมุ่งหวังที่จะสามารถคิดค้นระบบที่สมบูรณ์แบบ และสามารถนำไปใช้ในการพัฒนาซอฟต์แวร์ในการทำนาย (Prediction Software) แบบทันเวลา (Real-time) หรือออนไลน์ (Online) ได้อย่างมีประสิทธิภาพ

## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อนำเสนอวิธีการจำแนกประเภทคลื่นไฟฟ้าสมองที่รองรับความไม่คงที่ในการใช้งานของสภาพแวดล้อม รวมถึงพัฒนาระบบต้นแบบตามวิธีการที่ได้นำเสนอ

## 1.3 ขอบเขตของการวิจัย

- 1) นำเสนอวิธีการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมองแบบสองคลาส (class)
- 2) นำเสนอวิธีการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมองที่ไม่ขึ้นกับช่วงเวลาและความไม่คงที่ของสัญญาณ (Session independent; Non-Stationary signal)
- 3) นำเสนอวิธีการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมองที่ไม่ขึ้นกับบุคคล (Subject independent; Universal model) สามารถจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมองโดยใช้แบบจำลองที่สร้างโดยใช้ข้อมูลฝึกที่ไม่ใช่ข้อมูลของคนที่ทำการทดสอบ
- 4) พัฒนาระบบต้นแบบตามวิธีการที่ได้นำเสนอ

## 1.4 ขั้นตอนและวิธีดำเนินการวิจัย

- 1) ศึกษาข้อมูลทฤษฎีและงานวิจัยที่เกี่ยวข้อง
- 2) พัฒนารูปแบบการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง และทดสอบประสิทธิภาพการทำงาน

- 3) จัดทำบทความทางวิชาการและนำเสนอบทความ
- 4) พัฒนาและทดสอบระบบต้นแบบ
- 5) สรุปผลการวิจัย และจัดทำรายงานวิทยานิพนธ์

### 1.5 ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย

- 1) ได้วิธีการจำแนกประเภทที่เหมาะสมในการใช้งานกับข้อมูลคลื่นไฟฟ้าสมองในหลายช่วงเวลา และสามารถใช้งานได้มีประสิทธิภาพกับข้อมูลที่มีความไม่คงที่
- 2) ได้วิธีการจำแนกประเภทที่เหมาะสมกับการนำไปใช้กับผู้ป่วย โดยสามารถใช้งานได้กับข้อมูลคลื่นไฟฟ้าสมองที่ไม่ขึ้นกับบุคคลได้ คือไม่ต้องใช้ข้อมูลของผู้ป่วยในการฝึกสอนตัวจำแนกประเภท รวมทั้งให้ผลลัพธ์ที่ดีเทียบเท่ากับวิธีการจำแนกประเภทที่ใช้ข้อมูลการฝึกและข้อมูลทดสอบจากคน ๆ เดียวกัน
- 3) ได้ระบบต้นแบบที่สร้างจากวิธีการที่นำเสนอ

### 1.6 ผลงานวิจัยที่ได้รับการตีพิมพ์

ส่วนหนึ่งของงานวิจัยนี้ได้รับการตีพิมพ์และนำเสนอเป็นบทความทางวิชาการแล้วหนึ่งเรื่อง และได้รับการตอบรับให้ตีพิมพ์อีกหนึ่งเรื่องดังรายละเอียดต่อไปนี้

- 1) An Adjustment Strategy On Multi-Session EEG Data for Online Left/Right Hand Imagery Classification โดยผู้แต่งคือ Sitthiphong Muthong, Peerapon Vateekul และ Mana Sriyudthsak ในการประชุมวิชาการ 2016 8th International Conference on Knowledge and Smart Technology (KST), Kantary Hill Hotel Chiangmai, Thailand (February 03-06 2016)
- 2) Stacked Probabilistic Regularized LDA on Partitioning Non-Stationary EEG Data for Left/Right Hand Imagery Classification โดยผู้แต่งคือ Sitthiphong Muthong, Peerapon Vateekul และ Mana Sriyudthsak ในการประชุมวิชาการ 2016 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES), Hotel Pullman Kuala Lumpur Bangsar, Kuala Lumpur, Malaysia (December 4-8 2016)

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 คลื่นไฟฟ้าสมอง (Brain wave)

สัญญาณคลื่นไฟฟ้าสมองเกิดจากผลของกระแสไฟฟ้าของกลุ่มเซลล์ในสมอง [15] สมองคนมีเซลล์ประสาทชนิดหนึ่งที่เรียกว่านิวรอน (Neuron) จำนวนมากมายเป็นพันล้านเซลล์ เซลล์เหล่านี้สามารถติดต่อถึงกันได้ โดยการส่งสัญญาณไฟฟ้าผ่านเยื่อเซลล์ เมื่อส่วนปลายเซลล์ประสาทส่งผ่านสัญญาณได้รับการกระตุ้นจากสารเคมีที่เรียกว่าสารสื่อประสาท (Neurotransmitter) จะปล่อยอนุภาคที่มีประจุไฟฟ้าให้เดินไปตามเนื้อเยื่อที่เรียกว่าใยประสาท (Nerve fiber) ที่เชื่อมระหว่างเซลล์ประสาท โดยกระแสไฟฟ้าปริมาณน้อย ๆ ที่เกิดขึ้นนี้ จะไปกระตุ้นเซลล์ประสาทให้ปล่อยสารสื่อประสาทต่อไปเป็นทอดๆ ซึ่งสัญญาณไฟฟ้าที่เกิดขึ้นนี้เรียกว่าคลื่นสมองหรือคลื่นไฟฟ้าสมอง

คลื่นไฟฟ้าสมองอาจจะมี ความแตกต่างได้ในแต่ละบุคคลและอายุ หรือในขณะหลับหรือตื่น โดยสามารถแยกประเภทของคลื่นไฟฟ้าสมองตามความถี่ของรอบคลื่นต่อวินาทีได้ดังนี้

1) คลื่นเดลต้า (Delta) : ความถี่ 0.1-3 เฮิร์ตซ์ (Hertz: Hz) ในผู้ใหญ่พบบริเวณสมองส่วนหน้าและเด็กพบบริเวณสมองส่วนท้าย มีแอมพลิจูด (Amplitude) สูง พบได้ในคนนอนหลับปกติ ไม่ฝัน ไม่กระพริบตา (Non-rapid eye movement sleep: Non Rem) ไม่รู้สึกตัว [16]

2) คลื่นเธต้า (Theta) : ความถี่ 4-7 เฮิร์ตซ์ พบได้ที่สมองบริเวณขมับ ในเด็กพบว่ามี ความเด่นชัดมากกว่าผู้ใหญ่ ในช่วงอายุตั้งแต่เด็กไปจนถึงวัยรุ่นพบได้ขณะง่วงนอนหรืออาการครึ่งหลับครึ่งตื่น คลื่นเธต้ามีความสัมพันธ์กับการหยั่งรู้ ความคิดริเริ่ม การรำลึก การฝัน [16]

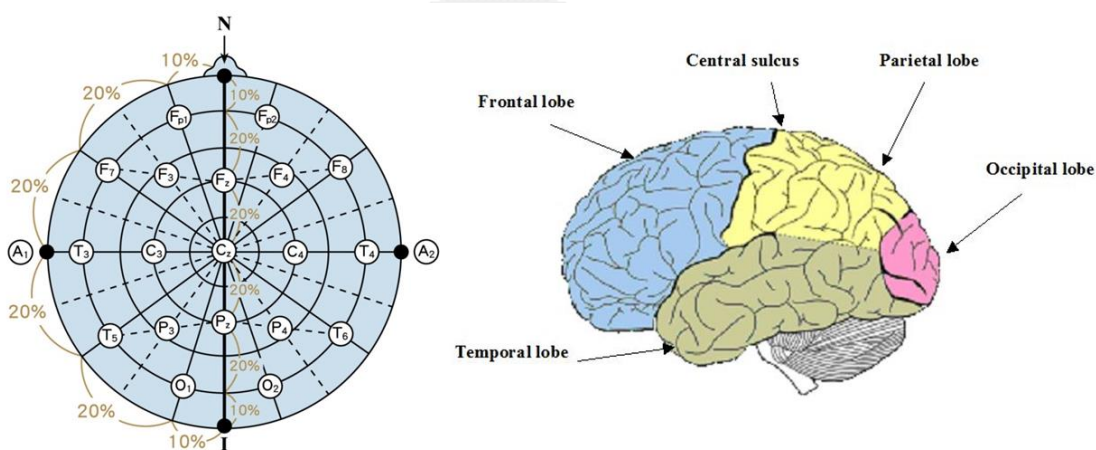
3) คลื่นอัลฟา (Alpha) : ความถี่ 8-12 เฮิร์ตซ์ พบได้เด่นชัดที่สมองกลีบท้ายทอย (occipital) เกิดขึ้นในขณะตื่น จิตใจกำลังผ่อนคลาย การหลับตาโดยไม่ได้คิดอะไร ไม่ได้มีความเหนื่อยล้าหรือ ง่วงซึม ไม่ได้ใช้ความคิดในการทำงาน ไม่ได้กำลังสนใจอะไรเป็นพิเศษ [16, 17]

4) คลื่นมิว (Mu) ความถี่ 7.5-12.5 เฮิร์ตซ์ สามารถเรียกอีกชื่อหนึ่งว่าเซนซอริมอเตอร์ริทึม (sensorimotor rhythm) ซึ่งจะมีการทำงานของนิวรอนจำนวนมากในส่วนของสมองที่ควบคุมการเคลื่อนไหว [18] พบความสัมพันธ์ของคลื่นที่บริเวณมอเตอร์คอร์เท็กซ์ (motor cortex; sensorimotor cortex) จากบริเวณหูข้างหนึ่งไปยังอีกข้างหนึ่ง คลื่นมิวเกิดขึ้นเมื่อเราทำการเคลื่อนไหวร่างกาย (motor action) หรือทำเสมือนว่ามีการเคลื่อนไหวร่างกาย (การจินตนาการ) โดยลักษณะดังกล่าวนี้จะทำให้เกิดการดีซิงโครไนเซชัน (Desynchronization; Event-Related Desynchronization; ERD) คือการที่แอมพลิจูดหรือกำลังไฟฟ้าของคลื่นลดลง

5) คลื่นเบต้า (Beta) ความถี่ 12.5–31 เฮิร์ตซ์ ลักษณะแรกพบบริเวณสมองส่วนหน้าทั้งสองด้าน มีแอมพลิจูดต่ำ และพบขณะตื่น มีความสัมพันธ์กับการตื่นตัว อาการยุ่งวุ่นวาย ความคิดวิตกกังวล การให้ความสนใจ (concentration) [19] ลักษณะที่สองพบในบริเวณมอเตอร์คอร์เท็กซ์ คลื่นเบต้าจะมีความสัมพันธ์กับการหดตัวของกล้ามเนื้อซึ่งเกิดขึ้นก่อนและระหว่างที่มีการเปลี่ยนแปลงการเคลื่อนไหว [20] คลื่นเบต้ามีความเด่นชัดเมื่อการตอบสนองต่อส่วนควบคุมมอเตอร์มีความคงที่หรือขณะเราอยู่นิ่ง ๆ และจะลดลงเมื่อมีการเคลื่อนไหวเกิดขึ้น [21] คลื่นเบต้าจะเพิ่มขึ้นหากการเคลื่อนไหวนั้นโดนต่อต้านหรือยับยั้ง [22]

6) คลื่นแกมมา (Gamma) คลื่นชนิดความถี่ช่วง 31-100 เฮิร์ตซ์ พบในบริเวณโซมาโตเซนซอรีคอร์เท็กซ์ (somatosensory cortex) มีความสัมพันธ์กับการสร้างการรับรู้ (cognition) ความเข้าใจ (perception) การรับความรู้สึก (binding senses) การประมวลผลข้อมูล การเรียนรู้ [23]

การวัดคลื่นไฟฟ้าสมองหรือเรียกย่อว่าอีอีจีคือการวัดสัญญาณไฟฟ้าบริเวณศีรษะซึ่งแพทย์ใช้เพื่อวินิจฉัยโรคและบอกตำแหน่งและความผิดปกติในการทำงานของสมอง ในทางวิศวกรรมได้มีการประยุกต์ใช้เป็นส่วนต่อประสานระหว่างมนุษย์กับคอมพิวเตอร์ (Brain-Computer Interface: BCI) โดยในการวัดสัญญาณนั้นจะมีการกำหนดตำแหน่งมาตรฐานเพื่อความเข้าใจตรงกัน เช่นในภาพที่ 2.1 แสดงตำแหน่งการวัดและชื่อเรียกตำแหน่งต่าง ๆ ของระบบ 10-20 เป็นต้น



ภาพที่ 2.1 จุดกำกับบนศีรษะในระบบ 10-20 [24]

ผู้เขียนสำรวจงานวิจัยในช่วงครึ่งปีแรกของปี 2015 เกี่ยวกับการจำแนกประเภทคลื่นไฟฟ้าสมองจำนวน 226 บทความและ 60 เอกสารการประชุมวิชาการ พบว่างานวิจัยด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหว (Motor Imagery Classification) ได้รับความสนใจเป็นอันดับที่สอง (15%) รองจากงานวิจัยด้านการจำแนกประเภทโรคลมบ้าหมูและโรคลมชัก (22%) และจากรายงานผลการศึกษาผู้ป่วยหลอดเลือดสมอง 54 คน (stroke patients) โดย Ang, et al. [25]

พบว่าสามารถตรวจจับการจินตนาการการเคลื่อนไหวเพื่อใช้ในการสื่อสารกับผู้ป่วยส่วนใหญ่ได้ ด้วยเหตุผลนี้เองผู้เขียนจึงกำหนดโปรโตคอลที่ใช้สำหรับการสื่อสารระหว่างผู้ป่วยและแพทย์รวมถึงผู้ดูแลด้วยการจินตนาการการเคลื่อนไหว และยังใช้โปรโตคอลนี้สำหรับการนำไปปรับใช้ออกแบบและพัฒนาซอฟต์แวร์

## 2.2 วิธีการสกัดคุณลักษณะ (Feature Extraction Techniques)

### 2.2.1 ตัวกรองช่องสัญญาณ (Common Spatial Pattern: CSP)

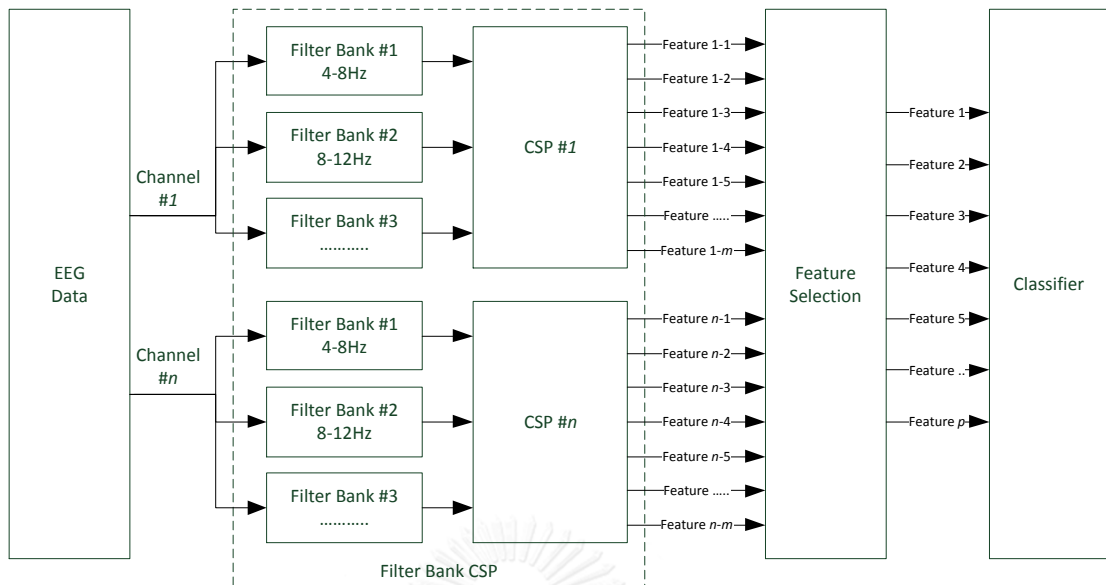
ตัวกรองช่องสัญญาณหรือซีเอสพีหรือเรียกอีกชื่อหนึ่งว่าสเปเชียลฟิลเตอร์ถูกพัฒนาขึ้นโดย Pfurtscheller และคณะ ในปี 1999 [13] ซึ่งพัฒนาต่อยอดจากบทความของ Koles และคณะในปี 1990 [26] ตัวกรองช่องสัญญาณที่ได้รับความนิยมและมีประสิทธิภาพคือตัวกรองช่องสัญญาณฟิลเตอร์แบงก์ (Filter Bank CSP) โดยคลื่นไฟฟ้าสมองแต่ละช่องสัญญาณจะถูกแบ่งย่อยตามย่านความถี่ด้วยตัวกรองแถบความถี่ผ่าน (Band-pass filter) ก่อนที่สัญญาณในทุกย่านความถี่ จะถูกใช้เป็นข้อมูลนำเข้าเพื่อหาตัวกรองช่องสัญญาณของทุก ๆ ช่องสัญญาณ (channel; electrode) สัญญาณที่ถูกแปลงหรือทำการสกัดคุณลักษณะสามารถหาได้จาก

$$Z_{b,i} = W_b^T E_{b,i} \quad (2.1)$$

โดยที่  $E_{b,i} \in R^{c \times t}$  คือคลื่นไฟฟ้าสมองวัดครั้งที่  $i$  ที่ผ่านตัวกรองแถบความถี่ผ่าน  $b$

$W_b^T \in R^{c \times c}$  คือโปรเจกชันเมทริกซ์ของตัวกรองช่องสัญญาณที่ตัวกรองความถี่ผ่าน  $b$  และ  $T$  คือทรานสโพสของเมทริกซ์

$Z_{b,i} \in R^{c \times t}$  คือสัญญาณจำนวน  $c$  ช่องสัญญาณที่ถูกการชักตัวอย่าง (sampling) จำนวน  $t$  ข้อมูล ผ่านตัวกรองช่องสัญญาณ (หรือคูณกับตัวกรองช่องสัญญาณ) โดยแต่เดิมจะเลือกวัดค่าการกระจายตัวของสัญญาณที่ถูกรองสองแถวบนสุดกับสองแถวล่างมาใช้ในการจำแนกประเภท อย่างไรก็ตามในปัจจุบันงานวิจัยส่วนใหญ่ใช้ประโยชน์ของตัวกรองช่องสัญญาณเพียงเพื่อโปรเจกชันให้เกิดความสามารถในการแยกออกจากกันได้ดี (separability) เท่านั้น โดยข้อมูลที่ออกจากตัวกรองช่องสัญญาณทั้งหมดจะไม่ถูกละทิ้ง แต่จะใช้วิธีการเลือกคุณลักษณะชนิดอื่น ๆ มาคัดเลือกคุณลักษณะที่ตีแทน ซึ่งตัวอย่างของการปรับใช้ตัวกรองช่องสัญญาณฟิลเตอร์แบงก์แสดงดังภาพที่ 2.2



ภาพที่ 2.2 ตัวอย่างของการปรับใช้ตัวกรองช่องสัญญาณ

ขั้นตอนการหาตัวกรองช่องสัญญาณสำหรับการจำแนกประเภทแบบสองค่าตอบหรือสองคลาส นั้น [27] ทำได้โดยการคำนวณหาเมทริกซ์การแปลง  $W_b$  (Transformation Matrix) ที่ทำให้การกระจายตัวของข้อมูลหรือสัญญาณสูงในทิศทางคำตอบหนึ่งและการกระจายตัวต่ำในอีกทิศทางของคำตอบตรงข้าม โดยสามารถคำนวณหาเมทริกซ์การแปลงได้จากการแก้สมการไอเก้นดีคอมโพสิชัน (Eigendecomposition) ในสมการที่ 2.2

$$\Sigma_{b,1} W_b = (\Sigma_{b,1} + \Sigma_{b,2}) W_b D_b \quad (2.2)$$

$\Sigma_{b,1}$  และ  $\Sigma_{b,2}$  คือเมทริกซ์ความแปรปรวนร่วมเกี่ยว (Covariance Matrices) ของสัญญาณที่ผ่านตัวกรองแถบความถี่ผ่านใด ๆ ซึ่งหาได้จากค่าเฉลี่ยของเมทริกซ์ความแปรปรวนร่วมเกี่ยวของชุดข้อมูลฝึกในกลุ่มคลาสเดียวกัน ตัวแปร  $D_b$  คือเมทริกซ์ทแยงที่ประกอบด้วยค่าไอเกนของ  $\Sigma_{b,1}$  โดยที่  $W_b$  สามารถคำนวณได้โดยใช้โปรแกรม แมตแล็บ (MATLAB) ด้วยคำสั่ง

$$W_b = eig(\Sigma_{b,1}, \Sigma_{b,1} + \Sigma_{b,2}) \quad (2.3)$$

### 2.2.2 ความหนาแน่นสเปกตรัมกำลัง (Power Spectrum Density: PSD)

ความหนาแน่นสเปกตรัมกำลังคือการวัดความหนาแน่นกำลังไฟฟ้าของสัญญาณบนโดเมนเวลาที่กระจายอยู่บนความถี่ต่าง ๆ โดยกำลังไฟฟ้าอาจหมายถึงกำลังไฟฟ้าจริงหรือในเชิงนามธรรมซึ่งสามารถหาได้จากค่ากำลังสองของสัญญาณ (เช่นในแง่ของการวัดคลื่นไฟฟ้าสมองที่เราอาจจะไม่รู้ความต้านของทานพิวหน่ง) โดยกำลังไฟฟ้าเฉลี่ยของสัญญาณสามารถหาได้โดยสมการที่ 2.4

$$P = \frac{1}{2T} \int_{-T}^T x^2(t) dt \quad (2.4)$$

โดยที่  $x(t)$  คือสัญญาณบนโดเมนเวลา

$T$  คือคาบเวลาของสัญญาณจาก  $[-\infty \infty]$

ในการวิเคราะห์ความถี่ของสัญญาณ สามารถหาได้ด้วยการแปลงฟูเรียร์ (Fourier Transform) จากสมการที่ 2.5

$$x(\omega) = \frac{1}{\sqrt{2\pi T}} \int_{-T}^T x(t) e^{-j\omega t} dt \quad (2.5)$$

โดยที่  $x(\omega)$  คือสัญญาณบนโดเมนความถี่ ( $\omega = 2\pi f$ )

และความหนาแน่นกำลังไฟฟ้าสามารถหาได้โดย

$$S(\omega) = E[x^2(\omega)] \quad (2.6)$$

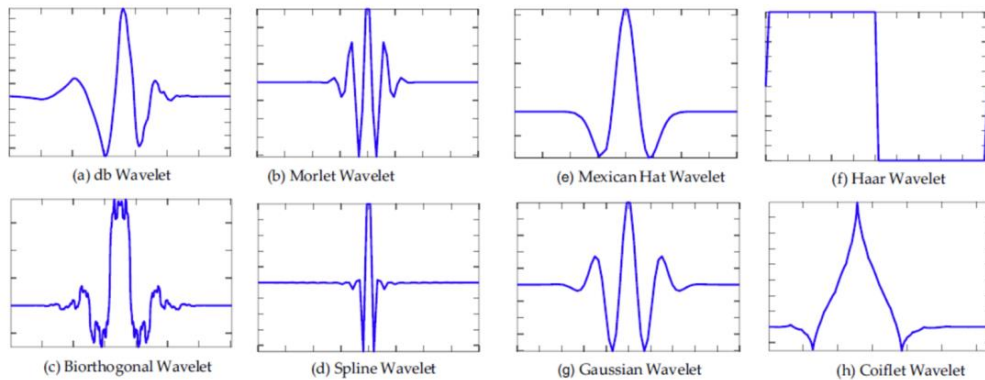
โดยที่  $E$  คือค่าคาดหวัง (expected value) หรือค่าเฉลี่ยของตัวแปรสุ่มที่สนใจ

### 2.2.3 การแปลงเวฟเล็ต (Wavelet Transform)

การแปลงเวฟเล็ตถูกพัฒนาขึ้นเพื่อแก้ไขข้อด้อยของการแปลงฟูเรียร์ซึ่งได้แก่ ใช้ได้กับสัญญาณคาบเท่านั้น มีความละเอียดน้อยเมื่อใช้กับสัญญาณความถี่สูง รวมถึงไม่สามารถอธิบายผลลัพธ์การแปลงบนโดเมนเวลาได้ การแปลงเวฟเล็ตคือการรวมสัญญาณองค์ประกอบความถี่ต่ำและองค์ประกอบความถี่สูงในระดับต่าง ๆ โดยจะมีค่าสัมประสิทธิ์เวฟเล็ตทำหน้าที่เป็นค่าน้ำหนักขององค์ประกอบความถี่แต่ละระดับ [28] ดังนั้นการอธิบายสัญญาณใด ๆ ด้วยการแปลงเวฟเล็ตก็คือการนำกลุ่มของเวฟเล็ตที่มีโครงสร้างฟังก์ชันแบบเดียวกันเป็นตัวอธิบาย โดยฟังก์ชันนี้เราเรียกว่าเวฟเล็ตแม่ (Mother Wavelet) ซึ่งคลื่นหรือสัญญาณใด ๆ จะถูกอธิบายด้วยการปรับสเกล (Scale;  $a$ ) หรือการแสดงการยืดหรือหดตัวของเวฟเล็ตแม่ ส่วนการเลื่อนตำแหน่ง (Translation or Shifting;  $b$ ) จะเป็นการแสดงตำแหน่งบนแกนเวลา โดยสามารถเขียนสมการของเวฟเล็ตได้ดังนี้

$$\psi_{a,b}(t) = \frac{1}{a} \psi\left(\frac{t-b}{a}\right) \quad (2.7)$$

ในการนำไปใช้จริงนั้นเวฟเล็ตแม่มีหลายรูปแบบขึ้นกับความเหมาะสมของสัญญาณที่นำไปปรับใช้ ซึ่งภาพที่ 2.3 แสดงเวฟเล็ตแม่ชนิดต่าง ๆ



ภาพที่ 2.3 เวฟเล็ตแม่ชนิดต่าง ๆ [29]

ในกรณีการแปลงเวฟเล็ตแบบต่อเนื่อง จะสามารถทำการแปลงสัญญาณได้ดังนี้

$$C(a, b) = \frac{1}{2T} \int_{-\infty}^{\infty} x(t) \psi_{a,b}(t) dt \quad (2.8)$$

โดยที่  $x(t)$  คือสัญญาณบนโดเมนเวลา

$\psi(t)$  คือเวฟเล็ตแม่


$a$  คือพารามิเตอร์ของการปรับสเกล (Scaling)

$b$  คือพารามิเตอร์การเลื่อนตำแหน่ง (Shifting)

ขั้นตอนวิธีการแปลงสามารถอธิบายได้โดยย่อได้ดังนี้

- 1) นำเวฟเล็ตแม่มาเปรียบเทียบกับส่วนแรกซึ่งเป็นจุดเริ่มต้นของสัญญาณในสเกลแรก
- 2) คำนวณสัมประสิทธิ์ซึ่งผลการวิเคราะห์จะแสดงความสัมพันธ์ระหว่างเวฟเล็ตแม่ในสเกลแรกซึ่งค่าสัมประสิทธิ์นี้ขึ้นอยู่กับทางเลือกใช้รูปร่างของเวฟเล็ตแม่ด้วย
- 3) เลื่อนตำแหน่งการวิเคราะห์ไปทางด้านขวาและทำขั้นตอนที่ 1 และ 2 ซ้ำ จนกระทั่งครอบคลุมช่วงสัญญาณทั้งหมดในการปรับความละเอียดครั้งแรก
- 4) เปลี่ยนอัตราการปรับความละเอียด โดยทำการขยายสเกลและทำตามขั้นตอนที่ 1-3 อีกครั้ง
- 5) ทำตามขั้นตอนที่ 1-4 อีกครั้งจนครบทุกอัตราการปรับความละเอียดจากขั้นตอนทั้งหมด ผลของการวิเคราะห์ที่ได้จะอยู่ในรูปของสัมประสิทธิ์ (coefficient) ของแต่ละค่าการปรับสเกลของทุกตำแหน่งในการเลื่อนสัญญาณ





ภาพที่ 2.4 ขั้นตอนวิธีการแปลงเวฟเล็ต [30]

## 2.3 วิธีการเลือกคุณลักษณะ (Feature Selection Techniques)

### 2.3.1 สหสัมพันธ์ (Correlation)

ค่าสหสัมพันธ์เป็นสถิติที่ใช้หาความสัมพันธ์ระหว่างตัวแปร ซึ่งค่าสหสัมพันธ์ที่คำนวณได้เรียกว่าค่าสัมประสิทธิ์สหสัมพันธ์ (correlation coefficient) มีค่าอยู่ระหว่าง -1 ถึง 1 โดยการปรับใช้เช่น การวิเคราะห์ความสัมพันธ์ของตำแหน่งช่องสัญญาณกับการจินตนาการการเคลื่อนไหวเพื่อเลือกใช้เฉพาะช่องสัญญาณที่มีความสัมพันธ์ต่อการจินตนาการ การหาความสัมพันธ์ระหว่างความถี่องค์ประกอบของสัญญาณกับการจินตนาการการเคลื่อนไหว การวิเคราะห์ผลกระทบของกาแพหรือการให้ยาบางอย่างต่อประสิทธิภาพของการจำแนกประเภทการจินตนาการการเคลื่อนไหว เป็นต้น ซึ่งสถิติสำหรับการคำนวณหาค่าสัมประสิทธิ์สหสัมพันธ์มีหลายวิธีการ การเลือกใช้ขึ้นอยู่กับเงื่อนไขหลายประการ โดยความสัมพันธ์มี 3 แบบคือสหสัมพันธ์ทางบวก (positive correlations) ซึ่งหมายความว่าเมื่อตัวแปรตัวหนึ่งเพิ่มหรือลดลงอีกตัวแปรหนึ่งก็จะเพิ่มขึ้นหรือลดลงไปด้วย สหสัมพันธ์ทางลบ (negative correlations) หมายถึงเมื่อตัวแปรตัวหนึ่งมีค่าเพิ่มขึ้นหรือลดลงอีกตัวแปรหนึ่งจะมีค่าเพิ่มหรือลดลงตรงข้ามเสมอ สหสัมพันธ์เป็นศูนย์ (zero correlations) หมายถึงตัวแปรสองตัวไม่มีความสัมพันธ์ซึ่งกันและกัน

### 2.3.2 การทดสอบสมมติฐาน (Hypothesis Testing)

การตั้งสมมติฐานทำเพื่อพิสูจน์ความแตกต่างของสองประชากร เช่นเราต้องการพิสูจน์ความแตกต่างของสองกระบวนการ (processes) หรือต้องการพิสูจน์ผลการทดลองของสองวิธีการ (treatments) ว่าตัวแปรหรือผลการทดลองที่เราสนใจมีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่ ซึ่งถ้าไม่แตกต่างเรียกว่าสมมติฐานว่าง (null hypothesis) เขียนแทนด้วย  $H_0 = H_1$  และถ้าแตกต่างกันอย่างมีนัยสำคัญเรียกว่าสมมติฐานทางเลือก (alternative hypothesis) เขียนแทนด้วย  $H_0 \neq H_1$  การนำไปประยุกต์ใช้ในการเลือกคุณลักษณะเช่น การทดสอบสมมติฐานเกี่ยวกับช่องสัญญาณที่มีความสามารถในการจำแนกประเภทสูงที่สุด (ช่องสัญญาณที่มีความแตกต่างอย่างมีนัยสำคัญระหว่าง

การจินตนาการว่า “ใช่” และ “ไม่ใช่”) นอกจากนี้ในการสรุปผลความแม่นยำของวิธีการใหม่จะต้องใช้การทดสอบสมมติฐานเพื่อทดสอบว่าวิธีการที่นำเสนอมีความแตกต่าง (แม่นยำขึ้น) อย่างมีนัยสำคัญกับวิธีอื่น ๆ หรือไม่ โดยค่าที่ใช้ตรวจสอบเราเรียกว่าค่า  $p$ -value และนิยมใช้ค่าขีดแบ่ง (threshold) ที่ 0.05 ซึ่งถ้ามากกว่าค่าดังกล่าวแสดงว่าไม่มีความแตกต่าง

## 2.4 การเรียนรู้ในสภาพแวดล้อมไม่คงที่ (Learning in Non-Stationary Environments)

### 2.4.1 การเปลี่ยนแปลงของความรู้ (Knowledge Change)


การเปลี่ยนแปลงของความรู้ [31] คือ การที่แนวความคิดหรือคอนเซ็ปต์ (Concept) ของตัวแปรที่เราสนใจที่จะทำนายนั้นเกิดการเปลี่ยนแปลง (Concept Change) ซึ่งเป็นไปได้ในสองลักษณะคือ เปลี่ยนแปลงแบบช้า ๆ ค่อยเป็นค่อยไป (Concept Drift; Gradual) หรือค่อย ๆ วิวัฒนาการการกระจายตัวเมื่อเวลาผ่านไป แบบที่สองคือการเปลี่ยนแปลงแบบเลื่อน (Concept Shift) คือมีการเปลี่ยนแปลงอย่างทันทีทันใด

### 2.4.2 การเลื่อนของความรู้ (Knowledge Shift)


การเลื่อนของความรู้ [32] คือการที่การกระจายตัวความน่าจะเป็นของข้อมูลฝึกไปยังข้อมูลทดสอบ (probability distribution) มีการเลื่อน ภายใต้วงเวลาของข้อมูลที่เกิดขึ้นอย่างต่อเนื่องกัน ซึ่งแบ่งได้เป็นสามลักษณะดังนี้

#### 2.4.2.1 ความแปรปรวนร่วมเกี่ยวเลื่อน (Covariate Shift)

ความแปรปรวนร่วมเกี่ยวเลื่อน [33] เป็นลักษณะที่การกระจายตัวของข้อมูลนำเข้าเปลี่ยนแปลงระหว่างข้อมูลฝึกไปยังข้อมูลทดสอบ ในขณะที่การกระจายตัวของคำตอบที่เกิดจากการทำนายข้อมูลนำเข้านั้นไม่มีการเปลี่ยนแปลง ซึ่งหมายถึงความสัมพันธ์ระหว่างข้อมูลนำเข้าและคำตอบที่เราต้องการที่จะทำนายนั้นคงที่ ในขณะที่การกระจายตัวของข้อมูลฝึกและข้อมูลทดสอบแตกต่างกัน ซึ่งตรงกับลักษณะของข้อมูลคลื่นไฟฟ้าสมองอันเนื่องจากข้อมูลฝึกนั้นถูกเก็บจากสภาพแวดล้อมที่ควบคุมได้ในขณะที่ข้อมูลทดสอบนั้นขึ้นกับผู้ใช้งานและลักษณะการใช้งาน ภาพที่ 2.5 แสดงความแปรปรวนร่วมเกี่ยวเลื่อนของข้อมูลที่มีการเลื่อนระหว่างข้อมูลฝึกและข้อมูลทดสอบในขณะที่ฟังก์ชันที่เกี่ยวข้องเนื่องกับการทำนายนั้นไม่มีการเปลี่ยนแปลง



(ก) การกระจายตัวของข้อมูลฝึก (เส้นต่อเนื่อง) และข้อมูลทดสอบ (เส้นประ)



(ข) ตัวอย่างข้อมูลฝึก (วงกลม) และข้อมูลทดสอบ (กากบาท) กับฟังก์ชันที่เกี่ยวข้องเนื่องกับการเรียนรู้ (เส้นต่อเนื่อง)

ภาพที่ 2.5 ความแปรปรวนร่วมเกี่ยวเนื่อง [34]

#### 2.4.2.2 การปรับตัวของโดเมน (Domain Adaptation)

การปรับตัวของโดเมนคือการที่ข้อมูลฝึกและข้อมูลทดสอบถูกสุ่มมาไม่เหมือนกัน แต่โดเมนนั้นมีความเกี่ยวข้องกัน เช่นการที่ระบบการแนะนำสินค้าสุ่มใช้ข้อมูลฝึกมาจากหนังสือ แต่กลับนำระบบนี้ไปใช้ในการทำนายผู้ใช้ที่สนใจหนังสือเล่มเป็นต้น

#### 2.4.2.3 การถ่ายทอดการเรียนรู้ (Transfer Learning)

การถ่ายทอดการเรียนรู้คือการเรียนรู้เพื่อมุ่งแก้ปัญหาเกี่ยวกับการที่ปริภูมิคุณลักษณะ (feature space) และการกระจาย (distribution) ตัวนั้นมีความแตกต่างกัน เช่นการที่ระบบการจำแนกประเภทระบบหนึ่งออกแบบมาเพื่อการทำนายโดเมนที่เราสนใจ แต่เราเรามีแค่ข้อมูลฝึกที่อยู่ในโดเมนอื่นเท่านั้น [35]

## 2.4.3 แบบจำลองปรับตัว (Adaptation Model)

### 2.4.3.1 วิธีการแบบแอคทีฟ (Active Approach)

วิธีการแบบแอคทีฟนั้นมีหลักการคือ [32] ระบบจะทำการตรวจจับการเปลี่ยนแปลงก่อนที่จะมีการปรับตัว โดยเมื่อแบบจำลองหรือระบบสามารถตรวจจับการเปลี่ยนแปลงได้ ตัวจำแนกประเภทจะทำการละทิ้งความรู้เก่า ๆ ที่ใช้ไม่ได้และปรับตัวกับสภาพแวดล้อมใหม่ วิธีการตรวจจับการเปลี่ยนแปลงที่นิยมใช้เช่น การทดสอบสมมติฐาน วิธีการแบบจุดเปลี่ยน (Change-Point Methods) วิธีการทดสอบสมมติฐานอย่างเป็นลำดับ (Sequential Hypothesis Tests) การทดสอบการตรวจจับการเปลี่ยนแปลง (Change Detection Tests) ขอบเขตโฮเอฟดิง (Hoeffding bounds) การเคลื่อนย้ายแบบเฉลี่ยเชิงเรขาคณิต (Geometric Moving Average) การเคลื่อนย้ายเฉลี่ยโดยการให้น้ำหนักเชิงเลขชี้กำลัง (Exponential Weighted Moving Average: EWMA) การทดสอบซียูซัม (Cumulative Sum Test: CUSUM) การถดถอยอัตโนมัติ (Auto Regressive) การเคลื่อนย้ายเฉลี่ยแบบการถดถอยอัตโนมัติ (Auto Regressive Moving Average) ตัวกรองคาลมาน (Kalman Filter)

เมื่อตรวจจับการเปลี่ยนแปลงได้แล้วทั้งในแง่ของการทดสอบการเปลี่ยนแปลงและการประมาณการตัวแปรที่เกี่ยวข้องเนื่องกับการเปลี่ยนแปลงของระบบ หลังจากนั้นจึงทำการปรับระบบโดยแบ่งออกเป็นสามแบบ วิธีการแรกเรียกว่าการกำหนดช่วงเวลาของข้อมูล โดยการเลื่อนช่วงเวลาให้ครอบคลุมชุดข้อมูลฝึกที่ทันสมัย ข้อมูลที่ใช้ไม่ได้ก็จะถูกละทิ้งและหลังจากนั้นชุดข้อมูลฝึกที่อยู่ในช่วงเวลาที่กำหนดก็จะถูกนำไปฝึกตัวจำแนกประเภทอีกครั้งและละทิ้งตัวจำแนกประเภทเก่าไป วิธีการแบบที่สองเรียกว่าการให้ความสำคัญ โดยวิธีการนี้จะไม่ทำการละทิ้งข้อมูลแต่จะใช้ข้อมูลทั้งหมดและทำให้ความสำคัญบนพื้นฐานของอายุของข้อมูล หรือให้ความสำคัญบนพื้นฐานของความแม่นยำในปัจจุบันของระบบ และวิธีการแบบที่สามคือวิธีการแบบสุ่มตัวอย่าง

### 2.4.3.2 วิธีการแบบพาสซีฟ (Passive Approach)

วิธีการแบบพาสซีฟนั้นหลักการคือ [32] จะทำให้แบบจำลองหรือระบบมีความทันสมัยอยู่เสมอ ด้วยการเปลี่ยนแปลงแบบจำลองแบบต่อเนื่องเมื่อได้รับข้อมูลนำเข้าใหม่เข้ามาในระบบการทำนาย โดยไม่สนใจว่าข้อมูลเหล่านั้นจะมีการดริฟหรือไม่ก็ตาม เราสามารถแบ่งแบบจำลองแบบพาสซีฟออกเป็นสองแบบดังต่อไปนี้

- 1) แบบจำลองตัวจำแนกประเภทเดี่ยว (Single Classifier Models) เช่นต้นไม้ตัดสินใจแบบเร็วที่สุด (Very-fast decision tree: VFDT) ตัวจำแนกประเภทแบบตรวจจับแนวความคิดดริฟและต้นไม้ตัดสินใจแบบเร็วที่สุด (The concept drift VFDT: CVFDT) โครงข่ายข้อมูลแบบออนไลน์ (Online information network: OLIN) การเรียนรู้ออนไลน์แบบขีดสุด (Online extreme

learning machine: ELM) โครงข่ายประสาทเทียมที่เปลี่ยนแปลงตามเวลา (Time-varying neural network)

2) แบบจำลองตัวจำแนกประเภทรวม (Ensemble Classifier Models) เช่น ขั้นตอนวิธีการรวมกระแส (Streaming ensemble algorithm: SEA) ขั้นตอนวิธีการปรับปรุงความไม่คงที่ออนไลน์ (Online Non-Stationary boosting algorithm: ONSBoost) การให้น้ำหนักแบบเสียงข้างมากเชิงพลวัต (Dynamic weighted majority: DWM)

## 2.5 วิธีการจำแนกประเภท (Classification Techniques)

### 2.5.1 การวิเคราะห์ดิสคริมิแนนต์เชิงเส้นหรือแอลดีเอ (Linear Discriminant Analysis: LDA)

การวิเคราะห์ดิสคริมิแนนต์เชิงเส้นหรือแอลดีเอมีเป้าหมายเพื่อลดมิติ (dimension) ของข้อมูล ขณะที่ยังคงไว้ซึ่งข้อมูลที่เป็นประโยชน์ต่อการจำแนกประเภทมากที่สุด สมมติว่ามีข้อมูล  $x_i$  มี  $d$  มิติ โดยมีจำนวน  $n_1$  เป็นสมาชิกของคลาส  $c_1$  และมีจำนวน  $n_2$  เป็นสมาชิกของคลาส  $c_2$  เราจะทำการหาสเกลาร์  $y$  เพื่อโปรเจกชัน  $x$  ไปยังเส้นตรงใด ๆ ( $y = w^T x$ ) ที่ทำให้เกิดความสามารถในการแยกออกจากกันสูงที่สุด (maximize separability) โดยการหาโปรเจกชันเวกเตอร์ที่ทำให้เกิดการโปรเจกชันที่ดีที่สุด จะต้องทำการกำหนดวิธีการวัดความสามารถของการแยกออกจากกัน โดยฟิชเชอร์ (Fisher) กล่าวว่าการทำให้ความแตกต่างระหว่างสมาชิกของสองคลาสใด ๆ มีค่ามากที่สุดทำได้โดยหาอัตราส่วนความแตกต่างระหว่างค่าเฉลี่ยของสมาชิกของคลาสดังกล่าวกับสแคตเตอร์ระหว่างสมาชิกของคลาส (Within-class scatter) โดยค่าสแคตเตอร์ของคลาสใด ๆ แทนด้วย  $S_i^2$  และหาได้โดย

$$S_i^2 = \sum_{y \in c_i} (y - \mu_i)^2 \quad (2.9)$$

โดยที่  $\mu_i$  คือค่าเฉลี่ยของสมาชิกของคลาสเดียวกันใด ๆ

และสแคตเตอร์ระหว่างสมาชิกของสองคลาสหาได้โดย  $S_1^2 + S_2^2$

ฟิชเชอร์แอลดีเอ (Fisher LDA) เป็นฟังก์ชันเชิงเส้นหรือโปรเจกชันฟังก์ชัน  $w^T x$  ที่ทำให้สมการเป้าหมาย  $J(w)$  ในสมการที่ 2.10 มีค่ามากที่สุด

$$J(w) = \frac{|\mu_1 - \mu_2|^2}{S_1^2 + S_2^2} \quad (2.10)$$

โดยการหา  $w$  ที่เหมาะสมที่สุด ทำได้โดยแก้สมการเป้าหมายในสมการที่ 2.11

$$J(w) = \frac{w^T S_B w}{w^T S_w w} \quad (2.11)$$

โดยที่สามารถหาค่า  $S_w, S_i, S_B$  ได้ดังนี้


$$S_w = S_1 + S_2 \quad (2.12)$$

$$S_i = \sum_{x \in c_i} (x - \mu_i)(x - \mu_i)^T \quad (2.13)$$

$$S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \quad (2.14)$$

## 2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

ซัพพอร์ตเวกเตอร์แมชชีนหรือเอสวีเอ็ม [36] เป็นหนึ่งในวิธีการจำแนกประเภทที่ได้รับความนิยมมากที่สุด ซึ่งให้ความถูกต้องและค่อนข้างแม่นยำกว่าวิธีการจำแนกประเภทอื่น ๆ หลักการของซัพพอร์ตเวกเตอร์แมชชีนก็คือ การสร้างโมเดลการจำแนกประเภทเชิงเส้นโดยหาระนาบแบ่งเขตข้อมูลที่เหมาะสม (optimal separating hyper plane) ซึ่งมีระยะห่างระหว่างคลาสมากที่สุด ตัวอย่างข้อมูลฝึกที่อยู่บริเวณขอบของการกระจายของคลาสที่เป็นบวกกับกลุ่มสมาชิกที่เป็นลบบนปริภูมิคุณลักษณะ จะถูกเรียกว่าซัพพอร์ตเวกเตอร์ (Support Vector) ดังแสดงในภาพที่ 2.6



ภาพที่ 2.6 ระบายแบ่งเขตข้อมูลที่เหมาะสม [36]

สมการที่ 2.15 แสดงสมการการหาค่าที่เหมาะสมที่สุด  $\phi(w, \xi)$  (Optimization function) ในการสร้างระนาบแบ่งเขตข้อมูล โดยที่  $w$  คือ เวกเตอร์ค่าน้ำหนักของข้อมูลนำออก และ  $c$  คือค่าคงที่ที่ใช้สำหรับกำหนดค่าความผิดพลาดในการจำแนกประเภทกลุ่มข้อมูลและค่า  $\xi_i$  (Slack variable) เป็นตัวแปรที่กำหนดขึ้นเพื่อยอมรับค่าความผิดพลาดที่คลาดเคลื่อนไปจากตำแหน่งที่เหมาะสม จากสมการจะพบว่าสมการประกอบด้วยสองพจน์หลัก โดยในพจน์แรกจะเป็นการเพิ่มระยะห่างระหว่างคลาสซึ่งต้องมีค่ามากที่สุด และพจน์ที่สองเป็นการลดข้อผิดพลาดจากการสอนให้ต่ำที่สุด

$$\phi(w, \xi) = \frac{1}{2} w^T w + c \sum_{i=1}^n \xi_i \quad (2.15)$$

ในกรณีที่ข้อมูลมีลักษณะไม่เป็นเชิงเส้น สามารถแก้ไขปัญหาดังกล่าวโดยสร้างฟังก์ชันวัดความคล้ายที่เรียกว่า เคอร์เนลฟังก์ชัน (Kernel function) ดังแสดงในสมการที่ 2.16 เพื่อให้สามารถจำแนกประเภทข้อมูลที่มีลักษณะแบบไม่เป็นเชิงเส้นได้

$$K(x_i, x_j) = \phi(x_i)\phi(x_j) \quad (2.16)$$

โดยคอร์เนลฟังก์ชันที่นิยมใช้มีอยู่ 4 ประเภท ได้แก่ คอร์เนลแบบเชิงเส้น (Linear) แบบโพลีโนเมียล (Polynomial) เกาเซียนเรเดียลเบสิสฟังก์ชัน (Gaussian Radial Basis Function: RBF) แบบซิกมอยด์ (Sigmoid)


### 2.5.3 โครงข่ายประสาทเทียม (Neural Networks)

โครงข่ายประสาทเทียม [37] เป็นการจำลองการทำงานของโครงข่ายประสาทของมนุษย์ (Biological neurons) ซึ่งประกอบด้วยส่วนของการประมวลผลที่เรียกว่านิวรอน โดยทุก ๆ นิวรอนสามารถมีข้อมูลนำเข้าได้หลายอันแต่มีข้อมูลนำออกเพียงอันเดียว ทุก ๆ ข้อมูลนำออกของทุก ๆ นิวรอนจะแยกไปเป็นข้อมูลนำเข้าของนิวรอนอื่น ๆ ภายในโครงข่าย การติดต่อกันภายในระหว่างนิวรอนนั้นไม่ใช่ลักษณะการต่อแบบธรรมดาทุก ๆ ข้อมูลนำเข้า แต่จะมีน้ำหนักเป็นตัวกำหนดกำลังของการติดต่อภายในและช่วยในการตัดสินใจการทำงานของนิวรอนในบางโครงข่ายจะถูกกำหนดไว้ตายตัวแต่บางโครงข่ายสามารถที่จะปรับแต่งได้ ซึ่งอาจจะเป็นการปรับแต่งจากภายนอกโครงข่ายหรือสามารถปรับได้ด้วยตัวเอง โครงข่ายประสาทเทียมแบบง่ายจะมีค่าข้อมูลนำเข้าเป็นสเกลาร์หนึ่งอินพุต (โดยสมมติว่าไม่มีค่าไบแอส  $b$ ) ป้อนเข้าผ่านจุดต่อและคูณกับค่าน้ำหนักสเกลาร์  $w$  ได้ผลคูณเป็นค่าสเกลาร์  $wp$  กลายเป็นค่าอินพุตที่ถูกจัดน้ำหนัก  $wp$  ส่งต่อไปยังฟังก์ชันถ่ายโอนหรือฟังก์ชันกระตุ้น  $f$  ซึ่งเกิดเป็นค่าเอาต์พุตสเกลาร์  $a$  โดยฟังก์ชันถ่ายโอน (Transfer function) มีอยู่มากมายหลายชนิดด้วยกัน เช่น ฟังก์ชันถ่ายโอนแบบจำกัดแข็ง (Hard-limit) ฟังก์ชันถ่ายโอนแบบจำกัดแข็งสมมาตร (Symmetric hard-limit) ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Linear) ฟังก์ชันถ่ายโอนแบบล็อกซิกมอยด์ (Logarithmic sigmoid) ฟังก์ชันถ่ายโอนแบบไฮเพอร์บอลิกแทนเจนต์ซิกมอยด์ หรือแทนซิกมอยด์ (Hyperbolic tangent sigmoid) และอื่น ๆ

โครงข่ายประสาทเทียมหนึ่งหน่วยแบบหลายข้อมูลนำเข้าคือโครงข่ายประสาทเทียมในรูปแบบหลายข้อมูลนำเข้าในรูปเวกเตอร์  $p = [p_1 \ p_2 \ \dots \ p_R]^T$  มีข้อมูลนำเข้า  $R$  ค่า ข้อมูลนำเข้าแต่ละตัวถูกคูณด้วยเวกเตอร์น้ำหนัก  $w = [w_{11} \ w_{12} \ \dots \ w_{1R}]$  แล้วป้อนให้กับฟังก์ชันถ่ายโอน  $f$  เป็นข้อมูลนำออก  $a$  ดังสมการ

$$n = wp + b = [w_{11}p_1 + w_{12}p_2 + \dots + w_{1R}p_R + b] \quad (2.17)$$

$$a = f(wp + b) \quad (2.18)$$



ภาพที่ 2.7 โครงข่ายประสาทเทียมหนึ่งหน่วยแบบหลายอินพุต [38]

โครงข่ายประสาทเทียมแบบเป็นชั้นในระบบงานทั่วไปจะเกี่ยวข้องกับตัวแปรมากกว่าหนึ่งตัวแปร โดยจะมีหลายหน่วยข้อมูลนำเข้า หลายสัญญาณเข้าและหลายสัญญาณออก ซึ่งทำให้สามารถนำไปประยุกต์ใช้กับระบบหลายตัวแปรได้ โครงข่ายประสาทเทียมแบบหลายข้อมูลนำเข้าและหลายข้อมูลนำออกมีชื่อทั่วไปว่าโครงข่ายประสาทเทียมแบบเป็นชั้น (Layered perceptron) โดยสามารถคำนวณได้ดังสมการต่อไปนี้

$$n_1 = [w_{11}p_1 + w_{12}p_2 + \dots + w_{1R}p_R + b_1] \quad (2.19)$$

$$n_2 = [w_{21}p_1 + w_{22}p_2 + \dots + w_{2R}p_R + b_2] \quad (2.20)$$

$$n_3 = [w_{31}p_1 + w_{32}p_2 + \dots + w_{3R}p_R + b_3] \quad (2.21)$$

$$n_S = [w_{S1}p_1 + w_{S2}p_2 + \dots + w_{SR}p_R + b_S] \quad (2.22)$$

ข้อมูลนำออกหาได้จาก

$$a_1 = f(n_1) = f(w_{11}p_1 + w_{12}p_2 + \dots + w_{1R}p_R + b_1) \quad (2.23)$$


$$a_2 = f(n_2) = f(w_{21}p_1 + w_{22}p_2 + \dots + w_{2R}p_R + b_2) \quad (2.24)$$

$$a_3 = f(n_3) = f(w_{31}p_1 + w_{32}p_2 + \dots + w_{3R}p_R + b_3) \quad (2.25)$$

$$a_S = f(n_S) = f(w_{S1}p_1 + w_{S2}p_2 + \dots + w_{SR}p_R + b_S) \quad (2.26)$$


โครงข่ายประสาทเทียมหนึ่งชั้นแสดงดังภาพที่ 2.8





ภาพที่ 2.8 โครงข่ายประสาทเทียมหนึ่งชั้น [38]

โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layered Perceptron: MLP) เป็นโครงข่ายประสาทเทียมที่นิยมใช้มากที่สุด มีความสามารถทำงานที่มีความซับซ้อนมาก ๆ ได้ อาจกล่าวได้ว่าสามารถประยุกต์ใช้ได้กับงานเกือบทุกประเภท โดยมีข้อแม้ว่าต้องมีจำนวนชั้นและจำนวนนิวรอนที่เหมาะสม ภาพที่ 2.9 แสดงโครงข่ายประสาทเทียมแบบสามชั้น



ภาพที่ 2.9 โครงข่ายประสาทเทียมแบบสามชั้น [38]

มีนักวิจัยจำนวนมากได้นำเสนอรูปแบบโครงข่ายประสาทเทียมชนิดต่าง ๆ เพื่อนำไปประยุกต์ใช้ในงานต่าง ๆ กัน ซึ่งโครงข่ายประสาทเทียมแบบต่าง ๆ มีสถาปัตยกรรมและลักษณะของนิวรอนที่แตกต่างกัน ขั้นตอนวิธีสำหรับการเรียนรู้ก็มีความแตกต่างกัน เช่น บางชนิดเรียนรู้แบบมีผู้สอน (Supervised learning) บางชนิดเป็นแบบไม่มีผู้สอน (Unsupervised learning) เป็นต้นและสำหรับการประยุกต์ใช้งานก็มีความแตกต่างกันออกไป

## 2.6 งานวิจัยที่เกี่ยวข้อง (Related Research)

ในหัวข้อนี้ผู้เขียนสำรวจงานวิจัยโดยเป็นบทความวิจัยที่ส่วนใหญ่เป็นข้อมูลย้อนหลัง 5 ปี จากงานวิจัยที่เกี่ยวกับการจำแนกประเภทการจินตนาการการเคลื่อนไหว ซึ่งจะใช้ประกอบในการอธิบายถึงเหตุผลและรายละเอียดการเลือกใช้วิธีการในแต่ละขั้นตอนย่อยต่าง ๆ เพื่อนำมาใช้ในการปรับปรุงวิธีการให้ดีขึ้นและออกแบบซอฟต์แวร์เพื่อตอบโจทย์ที่ได้กำหนดไว้

### 2.6.1 งานวิจัยด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหว

ตารางที่ 2.1 แสดงบทความด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหวในปี 2014-2015 โดยบทความทั้งหมดเป็นแบบจำลองที่ใช้ข้อมูลฝึกและข้อมูลทดสอบจากบุคคลคนเดียว ซึ่งจะเห็นว่ามีการวิจัยต่าง ๆ ที่ส่งผลต่อความแม่นยำที่แตกต่างกันและทำการเปรียบเทียบโดยตรงได้ยาก ซึ่งในการเลือกตัวแปรต่าง ๆ ที่เหมาะสมมาใช้นั้นสามารถสรุปได้ดังต่อไปนี้

1) ผู้เข้าร่วมทดลอง (participants) : พบว่าจำนวนผู้เข้าร่วมการทดลองที่ใช้ในอยู่ในช่วงตั้งแต่ 3-12 คน ยกเว้นบางการทดลองที่ใช้เพียงแค่ 1 คน และการทดลองส่วนมากจะใช้คนปกติในการทดสอบวิธีการ มีเพียงหนึ่งการทดลอง [6] เท่านั้นที่ใช้ผู้ป่วยโรคแอลเอส (ALS) 1 คน เข้าร่วมการทดลอง

2) ชุดข้อมูล (data set) : พบว่าการทดลองส่วนใหญ่เลือกใช้ชุดข้อมูลมาตรฐานเพื่อทดสอบวิธีการที่นำเสนอแทนที่จะใช้การเก็บข้อมูลเอง ซึ่งจากตารางที่ 2.1 จะเห็นว่ามีการนำชุดข้อมูลทดสอบมาตรฐานมาใช้ ทั้งนี้เหตุผลอาจสืบเนื่องมาจากความง่ายต่อการทดสอบ ทั้งในแง่ของการเตรียมการเก็บข้อมูลที่มีความยากลำบากสืบเนื่องมาจากปัจจัยหลายๆ ด้าน อีกทั้งในแง่ของการเปรียบเทียบประสิทธิภาพของผลการทดลองกับผลลัพธ์และวิธีการมาตรฐานที่ถูกตีพิมพ์ก่อนหน้านี้ซึ่งใช้ชุดข้อมูลเดียวกัน ดังนั้นผู้เขียนจึงเลือกใช้ชุดข้อมูลมาตรฐานที่ถูกเผยแพร่ไว้แล้วมาใช้ประเมินวิธีการที่พัฒนาขึ้น

3) จำนวนช่องสัญญาณ (number of channel) : พบว่าการทดลองส่วนมากใช้จำนวนช่องสัญญาณจำนวนมากด้วยเหตุผลเรื่องตำแหน่งที่ส่งผลต่อความแม่นยำของตัวจำแนกประเภทโดยตรง โดยงานวิจัยส่วนใหญ่จะทำการลดช่องสัญญาณด้วยวิธีการเลือกคุณลักษณะ ซึ่งจำนวนของคุณลักษณะที่เหมาะสมมีผลอย่างมากต่อประสิทธิภาพในการจำแนกประเภท แต่อย่างไรก็ตามงานวิจัยด้านการจินตนาการการเคลื่อนไหวนั้นมีมาอย่างยาวนานซึ่งทำให้เราทราบได้ว่า ช่องสัญญาณที่มีความสัมพันธ์สูงสุดต่อการจินตนาการการเคลื่อนไหวก็คือบริเวณกลางศีรษะที่ตำแหน่ง C3, C2, Cz, C1, C4 ซึ่งผู้วิจัยจะเลือกใช้ช่องสัญญาณน้อยที่สุดบริเวณดังกล่าวมาปรับใช้ในการออกแบบ

วิธีการและซอฟต์แวร์ โดยจำนวนของช่องสัญญาณน้อยจะส่งผลให้การออกแบบฮาร์ดแวร์ในอนาคตมีราคาประหยัดและนำไปใช้ติดตั้งให้กับผู้ป่วยได้ง่าย

4) การประมวลผลขั้นต้น (preprocessing) : พบว่าการทดลองส่วนมากใช้การประมวลผลขั้นต้นสัญญาณด้วยตัวกรองแถบความถี่ผ่านและนิยมใช้ตัวกรองบัตเตอร์เวิร์ท (Butterworth filter) มากที่สุด ซึ่งงานวิจัยที่ใช้การสกัดคุณลักษณะแบบตัวกรองช่องสัญญาณและการสกัดคุณลักษณะในโดเมนเวลาจะต้องใช้ตัวกรองแถบความถี่ผ่านก่อนเสมอเพื่อคัดเลือกเฉพาะสัญญาณความถี่ที่สนใจเท่านั้นไปใช้สำหรับการจำแนกประเภท ส่วนการสกัดคุณลักษณะโดยใช้การแปลงแปลงเวฟเล็ตและการแปลงย่านกำลังอาจไม่ต้องใช้ตัวกรองแถบความถี่ผ่านร่วมด้วยก็ได้ เพราะต้องกำหนดย่านความถี่ของสัญญาณที่ต้องการนำมาใช้ในวิธีการระหว่างการแปลงอยู่แล้ว

5) การปรับสัญญาณให้เป็นมาตรฐาน (signal calibration) : พบว่างานวิจัยส่วนใหญ่ไม่มีการปรับสัญญาณให้เป็นมาตรฐาน ซึ่งอาจเป็นเพราะว่า ผู้วิจัยเองได้ทำการควบคุมสภาพแวดล้อมให้เป็นไปอย่างที่ต้องการเพื่อลดผลกระทบของความไม่คงที่ของสัญญาณ เหตุผลอีกข้อหนึ่งอาจเป็นเพราะว่าด้วยความสามารถของวิธีการสกัดคุณลักษณะและตัวจำแนกประเภทนั้นสามารถทำการชดเชยความแม่นยำได้ในระดับหนึ่ง อย่างไรก็ตามจากรายงานการวิจัยดุษฎีนิพนธ์ของ Samek [39] พบว่าตัวกรองช่องสัญญาณซึ่งเป็นวิธีการในการสกัดคุณลักษณะที่ได้รับความนิยมมากที่สุดนั้นไม่ทนทาน (Robust) ต่อข้อมูลที่มีความไม่คงที่และข้อมูลผิดปกติ (outliers) จึงมีงานวิจัยบางส่วนนำวิธีการปรับสัญญาณมาใช้เช่นวิธีการค่าเฉลี่ยร่วมอ้างอิง (Common Average Reference: CAR) และวิธีการแปลงแซด (Z-Transform) แต่อย่างไรก็ตามวิธีการเหล่านี้ก็ไม่ได้รับความนิยมมากนักสืบเนื่องจากไม่สามารถเพิ่มความแม่นยำของการจำแนกประเภทได้อย่างเป็นที่น่าพอใจ จากเหตุผลข้างต้น ผู้เขียนจึงมุ่งวิจัยเพื่อการแก้ไขปัญหาเรื่องการเพิ่มความแม่นยำในการจำแนกประเภทที่เกิดจากความไม่คงที่ของข้อมูลที่เกิดจากการใช้งานในหลายช่วงเวลา (multiple session) และเกิดจากการใช้ข้อมูลจากบุคคลอื่นในการฝึกตัวจำแนกประเภท

6) การสกัดคุณลักษณะ (Feature extraction) : พบว่าวิธีการสกัดคุณลักษณะส่วนมากที่นักวิจัยนิยมใช้คือตัวกรองช่องสัญญาณ ซึ่งมีข้อสังเกตว่าสามารถเลือกตำแหน่งได้ดีในแง่ของการกระจายตัวของสัญญาณ อีกทั้งยังมีคุณสมบัติในการตกแต่งข้อมูลหรือขยายการกระจายตัวและหมุนแกนของข้อมูล ทำให้เกิดการกระจายเหมาะสมในทิศทางของคำตอบ ส่งผลให้เมื่อวัดการกระจายตัวเพื่อทำการจำแนกประเภทจะได้คุณลักษณะที่มีความแตกต่างอย่างเด่นชัดและมีความสามารถในการจำแนกเพิ่มมากขึ้น อย่างไรก็ตามตัวกรองช่องสัญญาณจะให้ผลดีหากจำนวนสัญญาณนำเข้าหรือจำนวนช่องสัญญาณมีมากพอสำหรับการเลือกคุณลักษณะ นอกจากตัวกรองช่องสัญญาณแล้วพบว่ามีงานวิจัยบางส่วนเลือกใช้วิธีการสกัดคุณลักษณะด้วยวิธีการแปลงเวฟเล็ตและการแปลงย่านกำลังซึ่ง

การแปลงทั้งสองวิธีการข้างต้นนั้นไม่ได้ถูกคิดค้นมาเพื่อการจำแนกประเภทคลื่นไฟฟ้าสมองโดยเฉพาะ ทำให้มีข้อด้อยต่อความไม่คงที่ของสัญญาณอย่างมาก

7) การเลือกคุณลักษณะ (Feature selection) : การเลือกจำนวนคุณลักษณะที่เหมาะสมมาใช้ในการจำแนกประเภทมีความสำคัญอย่างมากต่อความแม่นยำ เช่นจากคุณสมบัติของตัวกรองช่องสัญญาณพบว่าการเลือกคุณลักษณะจำนวนมากมาใช้ในการจำแนกประเภทไม่ทำให้เกิดผลดีซึ่ง Müller-Gerking, et al. [13] แนะนำว่าควรใช้แค่ข้อมูลที่ผ่านตัวกรองช่องสัญญาณ 2 แถวบนและ 2 แถวล่างเท่านั้น อย่างไรก็ตามจากตารางที่ 2.1 พบว่าปัจจุบันนักวิจัยนิยมใช้ตัวกรองช่องสัญญาณร่วมกับวิธีการเลือกคุณลักษณะแบบอื่นซึ่งให้ผลลัพธ์ความแม่นยำที่ดีเช่นกัน เช่นการเลือกจำนวนคุณลักษณะในบทความของ Ang, et al. [27] ซึ่งใช้วิธีการเลือกคุณลักษณะแบบเอ็มไอบีไอเอฟ (Mutual Information-based Best Individual Feature : MIBIF) และเอ็มไออาร์เอสอาร์ (Mutual Information-based Rough Set Reduction : MIRSR) นอกเหนือจากการเลือกบางคุณลักษณะจากตัวกรองช่องสัญญาณมาใช้แล้ว ยังมีวิธีการอื่น ๆ อีกที่ถูกนำมาใช้เช่น สัมประสิทธิ์สหสัมพันธ์ การวิเคราะห์องค์ประกอบย่อย และบางงานวิจัยใช้การกำหนดจำนวนคุณลักษณะด้วยข้อมูลวิจัยที่มีมาก่อน เช่น การเลือกช่องสัญญาณบริเวณตำแหน่ง C3 และ C4 มาใช้ร่วมกับสัญญาณความถี่ย่าน 8–13 เฮิร์ตซ์ (mu rhythms) และความถี่ 16–25 เฮิร์ตซ์ (beta rhythms) [40] เป็นต้น

8) รูปแบบการกระตุ้น (Stimulation Type) : พบว่านักวิจัยนิยมใช้การจินตนาการการเคลื่อนไหวร่างกายมาใช้ในการกำหนดโปรโตคอลเพื่อจุดประสงค์บางอย่าง เช่น การควบคุมคอมพิวเตอร์ การใช้ร่วมกับการบำบัดกล้ามเนื้อของผู้ป่วยที่เป็นอัมพาต การช่วยในการสื่อสาร ด้วยเหตุผลที่ดีในแง่ของประสิทธิภาพทั้งในแง่ความชัดเจนของวิธีการจินตนาการ วิธีการที่ไม่ชัดเจนยกตัวอย่างเช่น หากกำหนดให้ผู้ป่วยจินตนาการว่า “ใช่” หรือ “ไม่ใช่” ผู้ป่วยแต่ละคนนั้นอาจมีการจินตนาการร่วมกับคำตอบข้างต้นไม่เหมือนกันเช่น การจินตนาการการส่ายศีรษะร่วมกับการตอบว่าไม่ใช่ หรือการจินตนาการพูดว่าใช่ หรือการจินตนาการว่าผงกหัวแทนคำตอบว่าไม่ใช่ เป็นต้น และนักวิจัยก็พบว่าการจินตนาการเคลื่อนไหวร่างกายนั้นให้ผลดีในแง่ความแตกต่างของสัญญาณอย่างชัดเจนซึ่งส่งผลต่อความสามารถในการแบ่งแยกโดยตรง [25] ด้วยเหตุผลข้างต้นผู้เขียนจึงเลือกใช้โปรโตคอลการจินตนาการเคลื่อนไหว เช่นการจินตนาการขยับมือซ้าย ขยับมือขวา เคลื่อนไหวเท้า ลှ้า และเพดานปาก มาใช้ในการทำวิจัย

9) ตัวจำแนกประเภท (Classifier) : พบว่างานวิจัยส่วนใหญ่ใช้ตัวจำแนกประเภทแบบแอลดีเอ โคร่งข่ายประสาทเทียมและซัพพอร์ตเวกเตอร์แมชชีน Bashashati, et al. [41] ได้ใช้ข้อมูลสัญญาณสมองจากหลาย ๆ แหล่งมาใช้ร่วมกับวิธีการสกัดคุณลักษณะแบบการเวฟเล็ตและการแปลงแบบย่านกำลังเพื่อเปรียบเทียบความแม่นยำของตัวจำแนกประเภท โดยพบว่าวิธีการจำแนกประเภท

แบบการถดถอยเชิงเส้นซึ่งคล้ายคลึงกับวิธีการแอลดีเอและวิธีการโครงข่ายประสาทเทียมแบบหลายชั้นให้ความแม่นยำโดยเฉลี่ยมากที่สุดและแตกต่างอย่างมีนัยสำคัญกับวิธีการอื่น ๆ จากงานวิจัยดังกล่าวยังพบว่าในบางบุคคลเมื่อใช้ตัวจำแนกประเภทที่ดีที่สุดอาจจะให้ผลดีไม่เท่ากับตัวจำแนกประเภทอื่น ๆ ก็เป็นไปได้ ดังนั้นลักษณะของข้อมูลเป็นอีกปัจจัยหนึ่งที่ส่งผลต่อความแม่นยำของตัวจำแนกประเภทเช่นกัน ซึ่งในกระบวนการฝึกตัวจำแนกประเภทจะใช้แบบจำลองหรือตัวจำแนกประเภทที่ให้ความแม่นยำสูงบนข้อมูลตรวจสอบ (validation) ใช้กับข้อมูลทดสอบในการใช้งานจริง

10) ความแม่นยำ (accuracy) : พบว่างานวิจัยทั่วไปมีความแม่นยำอยู่ในระดับปานกลางถึงสูง (70-90%) แต่จะพบว่ามีความต้องการช่องสัญญาณจำนวนมาก ซึ่งหากนำไปประดิษฐ์เป็นอุปกรณ์พกพาจะยากต่อการติดตั้งใช้งาน รวมถึงจะทำให้อุปกรณ์ช่วยสื่อสารที่ประดิษฐ์ขึ้นนั้นมีค่าใช้จ่ายสูงตามไปด้วย ผู้เขียนจึงมุ่งเน้นการศึกษาวิจัยการจำแนกประเภทช่องสัญญาณแบบน้อยช่องสัญญาณเพื่อความง่ายต่อการใช้งานและราคาถูกลงต่อการประดิษฐ์อุปกรณ์ช่วยสื่อสาร



ตารางที่ 2.1 งานวิจัยด้านการจำแนกประเภทการจินตนาการการเคลื่อนไหว

Ref	Participant	Data Set	Channel	Preprocess	Calibrate EGG signal	Feature Extraction	Feature Selection	Motor Imagery Model	Classifier	Accuracy (%)
[1]	3	BCI III-Illa	29	Butterworth (8-30Hz)	NO	Spatial Filter Neural Network : SFN (Modify CSP)	Spatial Filter Neural Network: SFN (Modify CSP)	4 classes (left hand, right hand, foot, tongue)	Neural Network	71-80
	5	BCI III-IVa	23					2 classes (right hand, foot)		81-90
	5	JK-HH 1	29	Butterworth (7-30Hz)	NO	CSP	CSP	2 classes (right hand, foot)	(Not specify)	61-70
[2]	5	BCI III IVa	118					2 classes (right hand, foot)		71-80
	7	BCI IV-I	59					2 classes (left hand, right hand, foot)		81-90
[5]	12	Setup	32	Band pass (7-30Hz)	NO	Band Power (BP) (best score), FBCSP (2 <sup>nd</sup> score), LR (3 <sup>rd</sup> score )	Manual Selection and FBCSP	2 classes (REST, ELSE)	SVM (best score)	71-80
								2 classes (GRASP, ELSE)	LDA (2 <sup>nd</sup> score)	61-70
								3 classes (REST, GRASP, ELBOW)	LR (3 <sup>rd</sup> score )	61-70
[7]	9	BCI IV-Ila	22	Band pass (8-30Hz)	CAR	CSP	CSP	2 classes (left hand, right hand, feet, tongue)	Hybrid SVM/HMM (Hidden Markov Model)	71-80
								4 classes (left hand, right hand, feet, tongue)		61-70
[9]	5	BCI III-IVa	118	Band pass	Z-Transform	CSP	Multi-Objective Genetic Algorithms	2 classes (right hand, foot)	Bayesian Linear Discriminant Analysis (BLDA)	81-90
	1	BCI III-IVc	118					2 classes (left hand, foot)		71-80

Ref	Participant	Data Set	Channel	Preprocess	Calibrate EGG signal	Feature Extraction	Feature Selection	Motor Imagery Model	Classifier	Accuracy (%)
[3]	3	BCI III -IIa	60	Chebyshev (8-30Hz)	NO	Probabilistic CSP	Probabilistic CSP	2 classes (left hand, right hand, foot, tongue)	Fisher linear discriminant analysis (FLDA)	> 91
	5	BCI III-Iva	118					2 classes (right hand, foot)		> 91
[4]	6	Setup	10	Butterworth	NO	BP, Auto Regression (AR), Coherence Phase-Locking Value	Artificial Bee Colony	2 classes (left hand, right hand)	SVM	81-90
	1	BCI II-Ia	7	NO	NO	Wavelet Transform (Haar Wavelet)	Maximum Variance (MV) and Kolmogorov-Smirnov (KS)	2 classes (move a cursor up and down) healthy	Interval type-2 fuzzy logic systems (IT2FLS)	81-90
[6]	1	BCI II-Ib	7					2 classes (move a cursor up and down) ALS patient		61-70
	5	Setup	10	Band pass (0.5-30Hz)	NO	Continuous Wavelet Transform	Correlation of Wavelet Features	2 classes (left hand, right hand)	(Not specify)	81-90
[10]	5	BCI III-Iva	118	Band pass (1-50Hz)	NO	ERP (Time Domain), ERSP (Frequency Domain),MALS-NMF	Mixed Alternating Least Square based Nonnegative Matrix Factorization	4 classes (left hand, right hand, foot, tongue)	SVM	81-90
	1	BCI III-Ivc	118					2 classes (right hand, foot)		81-90

## 2.6.2 งานวิจัยด้านการเพิ่มความแม่นยำของการจำแนกประเภทด้วยแบบจำลองปรับตัว

ประมาณ 5 ปีที่ผ่านมางานวิจัยที่เกี่ยวกับแบบจำลองที่ปรับตัวได้เริ่มได้รับความสนใจในการปรับใช้กับคลื่นไฟฟ้าสมองมากขึ้น เนื่องจากพบว่าสามารถเพิ่มความแม่นยำของการจำแนกประเภทได้มากขึ้นเนื่องมาจากสามารถลดผลกระทบความไม่คงที่ของสัญญาณ [42] ที่เกิดจากสาเหตุสำคัญหลักสามด้าน สาเหตุแรกนั้นอาจเกิดจากช่องสัญญาณถูกถอดและติดตั้งระหว่างใช้งานหรือระหว่างช่วงเวลาใด ๆ รวมถึงความคลาดเคลื่อนของตำแหน่งการติดตั้งในแต่ละครั้ง ซึ่งส่งผลให้เกิดความแตกต่างต่อปริมาณคุณลักษณะหรืออาจเกิดจากเจลที่ใช้ในการติดตั้งขั้วช่องสัญญาณแห้งหลังจากวัดสัญญาณเป็นเวลานานทำให้ความสามารถในการนำไฟฟ้าในการวัดลดลง สาเหตุที่สองอาจเกิดจากระบบการทำนายที่ไม่มีความต่อเนื่องหรือการหยุดพักการทำนายเป็นเวลานานทำให้ไม่สามารถควบคุมสถานะกลับมาเป็นเหมือนก่อนหน้าได้ซึ่งอาจจะต้องมีการปรับระบบตลอดเวลา สาเหตุที่สามอาจเกิดจากสมาธิและความสามารถของบุคคลต่อการเรียนรู้และการทำตามโปรโตคอลที่ถูกกำหนดไว้

ด้วยเหตุผลข้างต้นผู้เขียนจึงได้ให้ความสนใจต่อการนำแบบจำลองที่ปรับตัวได้มาปรับใช้ร่วมกับวิธีการดั้งเดิม ซึ่งจากการสำรวจบทความดังตารางที่ 2.2 พบว่างานวิจัยส่วนใหญ่ประยุกต์ใช้ตัวกรองช่องสัญญาณแบบดั้งเดิมให้เป็นรูปแบบที่สามารถปรับตัวได้ [43, 44] บางงานวิจัยใช้การประยุกต์ตัวจำแนกประเภทแบบแอลดีเอให้เป็นแบบปรับตัวได้ [33, 45, 46] ซึ่งผลลัพธ์การปรับปรุงวิธีการดั้งเดิมให้สามารถปรับตัวได้ดังกล่าวสามารถช่วยเพิ่มความแม่นยำได้อย่างมีนัยสำคัญ

กลุ่มงานวิจัยแบบจำลองปรับตัวของ Masashi และคณะ [42] ได้นำเสนอวิธีการเกี่ยวกับการปรับตัวของการเลื่อนความแปรปรวนร่วมเกี่ยวซึ่งก็พบว่าสามารถเพิ่มความแม่นยำเฉลี่ยของหลาย ๆ คนได้ประมาณ 10% ซึ่งถือว่าดีขึ้นมาก

กลุ่มงานวิจัยแบบจำลองปรับตัวด้วยการประมาณการค่าตัวแปรที่เกี่ยวข้องเนื่องกับการเปลี่ยนแปลงเพื่อปรับระบบให้อยู่ในสถานะมาตรฐาน [33, 45, 47, 48] เช่นการประมาณการค่าเฉลี่ยของระบบ การประมาณการการกระจายตัว การประมาณการขนาดของคุณลักษณะ ซึ่งก็พบว่าผลลัพธ์ดีขึ้นอย่างมีนัยสำคัญ

กลุ่มงานวิจัยแบบจำลองปรับตัวโดยการนำเสนอวิธีการวางซ้อนตัวจำแนกประเภทร่วมกับวิธีการการเคลื่อนย้ายเฉลี่ยโดยการให้น้ำหนักเชิงเลขชี้กำลัง [45] ซึ่งก็รายงานผลลัพธ์ว่าให้ผลลัพธ์ที่ดีกว่าวิธีการทั่วไปและวิธีแบบปรับตัวได้บางชนิด

นอกจากนี้ยังพบว่าสองงานวิจัยสุดท้ายในตารางที่ 2.2 [44, 49] ได้มีการประยุกต์ใช้แบบจำลองปรับตัวในการจำแนกประเภทที่ไม่ขึ้นกับบุคคล ซึ่งใช้ข้อมูลฝึกของบุคคลอื่น ๆ ในการฝึกตัวจำแนกประเภทและนำมาทำการทดสอบหรือใช้จำแนกประเภทคลื่นไฟฟ้าสมองของอีกคนที่ไม่ได้มี



ส่วนเกี่ยวข้องกับข้อมูลฝึก ซึ่งแบบจำลองนี้เหมาะสมที่สุดสำหรับนำไปใช้กับผู้ป่วยแอลไอเอส จาก รายงานการวิจัยจะเห็นได้ว่าพบการปรับปรุงประสิทธิภาพอย่างมีนัยสำคัญด้วยเหตุผลที่กล่าวมาข้างต้น

จากที่กล่าวมาจะเห็นว่าแบบจำลองปรับตัวมีความสำคัญอย่างมากต่อการจำแนกประเภทคลื่นไฟฟ้าสมองแบบไม่ขึ้นกับช่วงเวลาและไม่ขึ้นกับบุคคล แต่อย่างไรก็ตามพิจารณาประเด็นดังต่อไปนี้

1) ในการจำแนกประเภทแบบน้อยช่องสัญญาณบริเวณ C3, C4, C5 (2-3 ช่องสัญญาณ) ยังไม่มีรายงานว่าตัวกรองช่องสัญญาณนั้นสามารถที่จะทำงานได้ดีที่สุดหรือไม่ เมื่อเทียบกับวิธีการสกัดคุณลักษณะชนิดอื่น ๆ เช่น การแปลงเวฟเล็ต

2) วิธีการประมาณการค่าตัวแปรที่เกี่ยวข้องเนื่องกับการเปลี่ยนแปลงเช่น ค่าเฉลี่ย ความแปรปรวนร่วม ค่าสเกล ซึ่งในการประมาณการนั้นหากพิจารณาใช้วิธีการดังต่อไปนี้

- การประมาณการค่าเฉลี่ยของคุณลักษณะของระบบด้วยวิธีการเคลื่อนย้ายเฉลี่ยโดยการให้นำหนักเชิงเลขชี้กำลัง หรือที่ผู้วิจัยเรียกว่าค่าเฉลี่ยปรับตัว (Adaptive mean) [33, 45]
- การประมาณการค่าเฉลี่ยด้วยการปรับแต่งวิธีการเคลื่อนย้ายเฉลี่ยโดยการให้นำหนักเชิงเลขชี้กำลัง ด้วยการพิจารณาค่าน้ำหนักของข้อบังคับร่วมด้วย ซึ่งให้ผลดีกว่า [47]
- การประมาณการค่าเฉลี่ยด้วยการปรับแต่งวิธีการเคลื่อนย้ายเฉลี่ยโดยการให้นำหนักเชิงเลขชี้กำลัง ด้วยการเพิ่มค่าน้ำหนักที่ได้จากการพิจารณาความน่าจะเป็นร่วมด้วย [48]

วิธีการประมาณการข้างต้นนั้นมีข้อเสียคือไม่คงทนต่อสภาวะการเปลี่ยนแปลงแบบไม่สมดุลหรือการที่ข้อมูลเกิดขึ้นด้านเดียวซ้ำ ๆ เช่นลำดับการทำนายคำตอบว่า “ใช่” 10 ครั้ง โดยไม่มีการสลับลำดับกับ “ไม่ใช่” ซึ่งเป็นไปได้ในสภาพการใช้งานจริง และพบการรายงานผลว่าระบบแบบปรับตัวประเภทนี้จะทำงานแย่ง [33] (ความแม่นยำต่ำลง) หากทำงานภายใต้สภาวะที่ระบุ

3) วิธีการแบบปรับตัวได้ส่วนใหญ่จะให้ความสำคัญกับการปรับข้อมูลทดสอบเป็นหลัก และไม่คอยได้คำนึงถึงผลกระทบของความไม่คงที่ของข้อมูลฝึกเท่าใดนัก โดยจะทำการเลือกข้อมูลที่ดีที่สุดที่มีความคงที่และมีความสามารถในการจำแนกดีที่สุดมาใช้ โดยละทิ้งข้อมูลฝึกที่เหลือทิ้งไป

ด้วยเหตุผลข้างต้นผู้เขียนจึงคิดว่า สามารถทำการขยายขอบเขตการวิจัยเพื่อทำการปรับปรุงให้ระบบการทำนายสามารถทำงานได้ดีขึ้นในสภาพการใช้งานจริง ซึ่งจะนำเสนอวิธีการในบทถัดไป

ตารางที่ 2.2 เปรียบเทียบความแม่นยำของการนำเสนอวิธีการแบบปรับตัวได้กับวิธีการแบบคงที่และวิธีการแบบปรับตัวได้เทียบเคียง

Ref. [Year]	Traditional algorithms used to build adaptive model		Baseline Model	Adaptive Model	Result Comparison
	Feature Extraction	Classifier			
[42] 2010	CSP	Linear Discriminant Analysis (LDA)	CSP with traditional LDA (e.g. no adaptation)	Covariance Shift Adaptation with LDA	Accuracy better by 10% on average
[33] 2011	CSP	LDA	CSP with traditional LDA (e.g. no adaptation)	Adaptive LDA with Pool mean, Global Covariance, Scaling	Report significantly outperform
[47] 2012	(Not specify)	LDA	Adaptive LDA with Pool mean, Global Covariance, and traditional LDA	Constrained Means Adaptive Classifier (CMAC)	Report significantly outperform
[50] 2013	CSP	LDA	CSP with traditional LDA (e.g. no adaptation)	Data Space Adaptation (DSA)	Report significantly outperform
[48] 2014	Tangent Space Mapping	LDA	Multiclass LDA (MLDA), DSA, Enhanced Bayesian LDA (EBLDA)	Multiclass Pooled Mean Linear Discriminant Analysis (MPMLDA)	Report significantly outperform
[51] 2014	Regularized CSP, Filter Bank CSP	Naive Bayesian Parzen Window (NBPW)	Tikhonov (Tik) Regularized CSP, Spatially Regularized CSP, DSA, Naive Regularization with CSP, Stationary CSP	Tensor Decomposition Model	Report significantly outperform (all)
[45] 2015	CSP	Regularized LDA (RLDA)	LDA, DSA, MPMLDA	Stack (ensemble) Regularized Linear Discriminant Analysis	Report outperform (Some Significantly better)
[43] 2015	CSP	(Not specify)	CSP	Adaptive Spatial Filters (Adaptive CSP)	Report outperform

Ref. [Year]	Traditional algorithms used to build adaptation model		Baseline Model	Adaptation Model	Comparison Result
	Feature Extraction	Classifier			
[46] 2015	CSP	LDA	14 standard results published prior	Adaptive Semi- Supervised LDA	Report significantly outperform (all)
[44] 2015	CSP	SVM	CSP, Semi- Supervised Importance Weighted Extreme Energy Ratio (SIWEER)	Adaptive Common Spatial Patterns (Adaptive CSP)	Reports improvement (Single and Multiple Subject Model)
[49] 2015	Probabilistic CSP	Bayesian	CSP, Probabilistic CSP, Bayesian Common Spatial Pattern (BCSP)	Bayesian Common Spatial Pattern (BCSP) with Indian Buffet Process (IBP)	Report significant better (Only Multiple/Inter Subject Model)

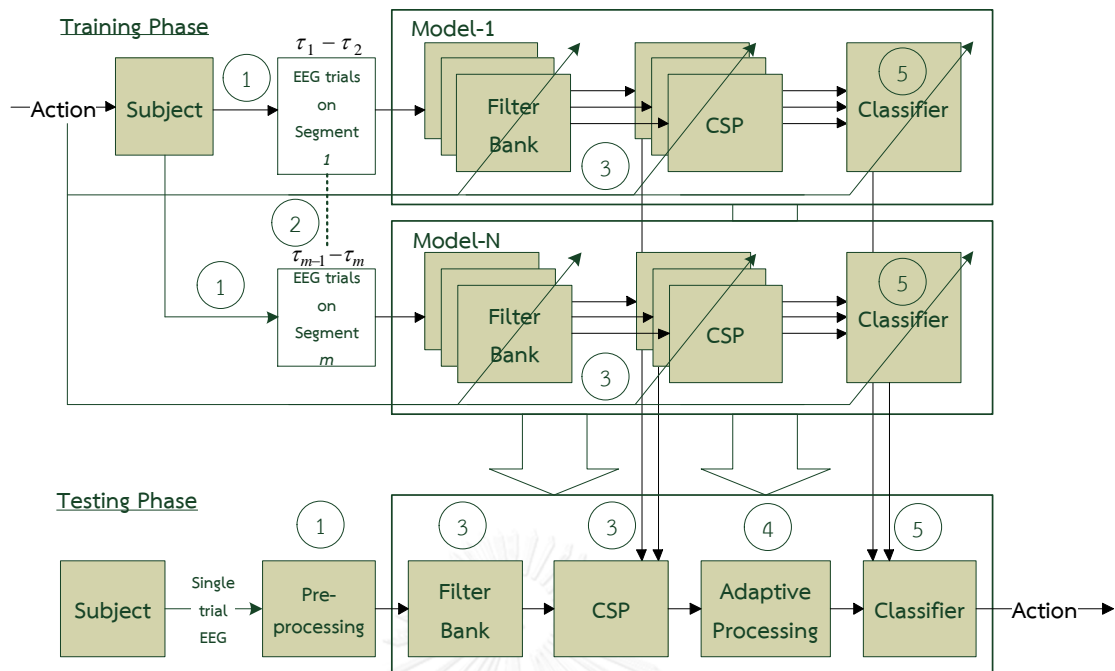
### บทที่ 3

#### การจำแนกประเภทคลื่นไฟฟ้าสมองบนสภาพแวดล้อมแบบไม่คงที่

งานวิจัยนี้นำเสนอการปรับปรุงตัวจำแนกประเภทแบบอาร์แอลดีเอ (Regularized LDA: RLDA) ในการจำแนกประเภทสัญญาณสมองแบบสองคลาส เพื่อแก้ไขปัญหาความไม่คงที่ของสัญญาณในชุดข้อมูลฝึกขนาดใหญ่ซึ่งถูกเก็บจากหลายช่วงเวลา สัญญาณคลื่นไฟฟ้าสมองที่ถูกจัดเก็บทั้งหมดจะถูกประเมินและแบ่งออกเป็นหลาย ๆ กลุ่มข้อมูลโดยใช้วิธีการตรวจจับการเปลี่ยนแปลง (Change Detection) จากนั้นตัวจำแนกประเภทจะถูกฝึกด้วยชุดข้อมูลย่อยที่ถูกแบ่งไว้และสร้างตัวจำแนกประเภทแบบรวมขึ้นจากตัวจำแนกประเภทย่อยเหล่านั้น เราเรียกตัวจำแนกประเภทแบบใหม่นี้ว่า ตัวจำแนกประเภทแบบวางซ้อน (Stacked Classifiers) ซึ่งรายละเอียดในบทนี้จะกล่าวถึงวิธีการที่นำเสนอ เริ่มจากการประมวลผลขั้นต้น (pre-processing) โดยการนำข้อมูลมาตัดแบ่งเอาเฉพาะส่วนที่สนใจคือเฉพาะช่วงการจินตนาการการเคลื่อนไหว จากนั้นนำสัญญาณไปสกัดคุณลักษณะ โดยใช้ตัวกรองช่องสัญญาณฟิลเตอร์แบงค์ ข้อมูลฝึกที่ผ่านการสกัดคุณลักษณะจะถูกทำให้ค่าเฉลี่ยของแต่ละคุณลักษณะเป็นศูนย์ก่อนนำไปฝึกตัวจำแนกประเภท ส่วนข้อมูลทดสอบนั้นจะต้องผ่านกระบวนการปรับตัว (adaptive processing) ก่อนการทำนายผลลัพธ์เพื่อลดผลกระทบของความไม่คงที่ของสัญญาณในข้อมูลทดสอบให้น้อยลง จากนั้นจึงนำข้อมูลทดสอบไปทำนายด้วยตัวจำแนกประเภทที่ได้ถูกฝึกสอนไว้ โดยกระบวนการทำงานของวิธีการที่นำเสนอแสดงดังภาพที่ 3.1 ซึ่งถูกกำกับหมายเลขไว้ในแต่ละขั้นตอนเพื่ออธิบายรายละเอียดเพิ่มเติมในหัวข้อย่อยที่ 3.1-3.5

#### 3.1 การเลือกช่องสัญญาณและประมวลผลขั้นต้น (Channel Selection and Data Preprocessing)

ดังที่ได้กล่าวมาแล้วว่างานวิจัยนี้เลือกใช้สัญญาณคลื่นไฟฟ้าสมองแบบน้อยช่องสัญญาณ และเลือกใช้บริเวณตำแหน่งที่มีความสัมพันธ์กับการจินตนาการการเคลื่อนไหวมากที่สุด [40] ดังนั้นสัญญาณบริเวณกลางศีรษะ เช่น ช่องสัญญาณ C3, Cz และ C4 จะถูกเลือกมาใช้ สัญญาณคลื่นไฟฟ้าสมองที่ถูกเลือกไว้จะถูกตัดส่วนหน้าซึ่งเป็นช่วงการเตรียมตัวออก และตัดสัญญาณส่วนหลังซึ่งเป็นการสิ้นสุดการจินตนาการออก ตัวอย่างเช่นเลือกใช้สัญญาณที่เวลาเริ่มต้น 3.5 วินาทีจนถึง 7.5 วินาที รวมวินโดว์เวลาทั้งสิ้น 4 วินาทีเป็นต้น



ภาพที่ 3.1 กระบวนการทำงานของวิธีการที่นำเสนอ

### 3.2 การแบ่งกลุ่มข้อมูลโดยใช้การตรวจจับการเปลี่ยนแปลงของสัญญาณ (Data Partitioning based on Change Detection)

การแบ่งกลุ่มข้อมูลมีเป้าหมายเพื่อจัดกลุ่มข้อมูลที่มีความคล้ายคลึงกันไว้ด้วยกัน หรือกล่าวได้ว่าเป็นจัดกลุ่มข้อมูลที่มีลักษณะการกระจายตัวเหมือนกันเข้าด้วยกัน โดยผู้เขียนใช้การแบ่งกลุ่มข้อมูลด้วยวิธีการการตรวจจับจุดเปลี่ยนแปลง (Change Point Detection) [52, 53] พิจารณาลำดับของตัวแปรสุ่ม  $y_1, y_2, \dots, y_n$ ;  $y_i = \log(\text{var}(EEG_{\text{trial}}))$  ซึ่งเกิดจากการหาค่าเฉลี่ยของลอการิทึมของการกระจายตัวของคลื่นสมองในทุก ๆ ช่องสัญญาณ (averaged log variance of EEG trials) และกำหนดให้ค่า  $\tau_1 < \tau_2 < \tau_3 < \dots < \tau_m$  แทนจุดที่เกิดการเปลี่ยนแปลงซึ่งมีจำนวนเท่ากับ  $m + 1$  จุด เราจะเรียกสมาชิกระหว่างจุดที่เกิดการเปลี่ยนแปลงว่าส่วนแบ่ง (partition; segment) ซึ่งที่ส่วนแบ่ง  $i$  จะประกอบไปด้วยสมาชิก  $y_{(\tau_{i-1}+1):\tau_i}$  วิธีการที่นิยมนำมาใช้หาจุดที่เกิดการเปลี่ยนแปลงนั้นทำได้โดยการทำฟังก์ชันเป้าหมายในสมการที่ 3.1 มีค่าน้อยที่สุด

$$\sum_{i=0}^{m+1} C(y_{(\tau_{i-1}+1):\tau_i}) + \beta f(m) \quad (3.1)$$


$C$  คือค่าฟังก์ชันต้นทุน (cost function) ที่ใช้วัดความพอดี (fit) ของจุดที่เกิดการเปลี่ยนแปลง  $\tau$  ใด ๆ พจน์  $\beta f(m)$  เรียกว่าพินาลตี (penalty) ใช้เพื่อการควบคุมปัญหาโอเวอร์ฟิตติ้ง (overfitting)

Jackson, et al. [54] ได้กล่าวถึงวิธีการการแบ่งส่วนแบ่งแบบเหมาะสม (Optimal Partitioning) ที่ทำให้ฟังก์ชันเป้าหมายมีค่าน้อยที่สุดเพื่อใช้หาจุดที่เกิดการเปลี่ยนแปลง วิธีการนี้ทำได้โดยการกำหนดให้พจน์  $f(m) = m$  จำนวนจุดที่เกิดการเปลี่ยนแปลงจะถูกควบคุมผ่านการปรับค่าคงที่  $\beta$  โดยลำดับการทำงานในการหาจุดที่เกิดการเปลี่ยนแปลงมีดังนี้

ตารางที่ 3.1 รหัสเทียมแสดงขั้นตอนการทำงานของวิธีการแบ่งส่วนแบ่งแบบเหมาะสม [54]

Algorithm Optimal Partitioning ( $y_{1:n}, C(\cdot), \beta$ )
1: Set: $n = \text{length of data}, t = 1,$
2: Set: $F(0) = -\beta, cp(0) = \text{NULL}$ and $F = F(0)$
3: While $t \leq n$ do:
4: $F(t) = \min_{\tau^*} [F(\tau^*) + C(y_{(\tau^*+1):t}) + \beta]$
5: $\tau' = \text{argmin} [F(\tau^*) + C(y_{(\tau^*+1):t}) + \beta]$
6: Set $cp(t) = (cp(\tau'), \tau')$ ;
7: Set $F = (F, F(t))$
8: $t = t + 1$
9: end While
10: Return Change Point recored in $cp(n)$ , Optimal Cost in $F$

ภาพที่ 3.2 แสดงข้อมูลตัวอย่างคลื่นไฟฟ้าสมองที่ได้จากการตรวจจับการเปลี่ยนแปลงด้วยวิธีการแบ่งส่วนแบ่งแบบเหมาะสม จะสังเกตเห็นว่าบางส่วนแบ่งนั้นเล็กเกินไปเช่น ส่วนแบ่งที่ 1, 2, 4, 5 ด้วยเหตุนี้เองจึงมีความจำเป็นที่จะต้องมีการรวมส่วนแบ่งที่มีขนาดเล็ก รวมถึงตัดแบ่งส่วนแบ่งที่มีขนาดใหญ่เกินไปเช่น ส่วนแบ่งที่ 8 เพื่อให้ได้ตัวจำแนกประเภทย่อยเพิ่มมากขึ้น โดยจะกล่าวถึงรายละเอียดวิธีการของการรวมส่วนแบ่งขนาดเล็กและการตัดแบ่งส่วนแบ่งขนาดใหญ่ในลำดับถัดไป



ภาพที่ 3.2 ตัวอย่างผลลัพธ์ของส่วนแบ่งที่ได้จากการตรวจจับการเปลี่ยนแปลง

### 3.2.1 การรวมส่วนแบ่งขนาดเล็ก (Small Partition Merging)

ในภาพที่ 3.2 เราจะสังเกตเห็นได้ว่าบางส่วนแบ่งมีสมาชิกน้อยจนไม่สามารถนำไปฝึกตัวจำแนกประเภทได้อย่างมีประสิทธิภาพ การรวมส่วนแบ่งจึงมีวัตถุประสงค์เพื่อเพิ่มจำนวนสมาชิกของข้อมูลฝึก โดยจะทำการรวมส่วนแบ่งขนาดเล็กเข้ากับส่วนแบ่งข้างเคียง ซึ่งทำได้โดยทำการวนซ้ำค้นหาส่วนแบ่งที่มีขนาดเล็กกว่าค่าขีดแบ่งส่วนแบ่งน้อยที่สุด (Minimum Partition Size: Psize) จากนั้นทำการรวมส่วนแบ่งเหล่านั้นเข้ากับส่วนแบ่งข้างเคียงที่มีระยะห่างระหว่างกลุ่มข้อมูลน้อยที่สุด ยกตัวอย่างเช่น ส่วนแบ่งที่ 4 สามารถทำการรวมเข้ากับส่วนแบ่งด้านซ้าย (ส่วนแบ่งที่ 3) เพราะมีระยะห่างน้อยกว่าส่วนแบ่งด้านขวา (ส่วนแบ่งที่ 5) การรวมส่วนแบ่งขนาดเล็กจะทำจนกระทั่งไม่มีส่วนแบ่งใด ๆ ที่มีสมาชิกน้อยกว่าค่าขีดแบ่งส่วนแบ่งน้อยที่สุด ซึ่งสุดท้ายแล้วส่วนแบ่งที่ 1, 2, 5 ก็จะต้องถูกรวมเข้ากับส่วนแบ่งที่ 3 เช่นกัน หากเรากำหนดค่า Psize อยู่ที่ 50

### 3.2.2 การตัดแบ่งส่วนแบ่งขนาดใหญ่ (Large Partition Splitting)

วิธีการนี้มีจุดประสงค์เพื่อเพิ่มตัวจำแนกประเภทย่อยให้มีจำนวนมากขึ้น โดยจะทำการแบ่งส่วนแบ่งที่มีขนาดใหญ่มากกว่าสองเท่าของค่าขีดแบ่งส่วนแบ่งน้อยที่สุด วิธีการคือทำการวนซ้ำค้นหาส่วนแบ่งที่มีขนาดใหญ่ จากนั้นตัดแบ่งข้อมูลออกเป็นหลาย ๆ กลุ่มโดยให้มีสมาชิกเท่า ๆ กัน และจำนวนสมาชิกในส่วนแบ่งทุก ๆ กลุ่มที่ถูกตัดแบ่งนั้นจะต้องไม่น้อยกว่าค่าขีดแบ่งส่วนแบ่งน้อยที่สุดหรือค่า Psize นั่นเอง

### 3.3 ตัวกรองช่องสัญญาณฟิลเตอร์แบงค์ (Filter Bank Common Spatial Pattern; FBCSP; Filter Bank CSP)

ตัวกรองช่องสัญญาณฟิลเตอร์แบงค์นั้นประกอบไปด้วย ตัวกรองความถี่ผ่านหลายย่านต่ออนุกรมกับตัวกรองช่องสัญญาณแบบดั้งเดิม สัญญาณของข้อมูลฝึกที่ผ่านตัวกรองความถี่จะถูกนำมาใช้เพื่อหาตัวกรองช่องสัญญาณ เมื่อได้ตัวกรองช่องสัญญาณของแต่ละช่องสัญญาณแล้วจึงทำการโปรเจกชันสัญญาณคลื่นไฟฟ้าสมองด้วยตัวกรองช่องสัญญาณเพื่อให้ได้คุณลักษณะที่ต้องการ ในงานวิจัยนี้เลือกใช้ตัวกรองบัตเตอร์เวิร์ทเพื่อกรองผ่านสัญญาณแถบความถี่ 1-4, 4-8,..., 36-40 เฮิรตซ์ ซึ่งครอบคลุมความถี่ที่ให้ผลการจำแนกประเภทที่ดี สัญญาณคลื่นไฟฟ้าสมองของข้อมูลฝึกและข้อมูลทดสอบจะถูกสกัดคุณลักษณะด้วยตัวกรองช่องสัญญาณเพื่อให้ได้มาซึ่งคุณลักษณะที่มีความสามารถในการแบ่งแยกสูง อย่างไรก็ตามคุณลักษณะที่ได้จากตัวกรองช่องสัญญาณนั้นไม่ได้มีประสิทธิภาพในการจำแนกดีทุกคุณลักษณะ ดังนั้นเราจะเลือกเฉพาะคุณลักษณะที่มีค่าไอเก้น (eigenvalue) สองค่าสูงสุดและสองค่าต่ำสุดต่อช่องสัญญาณเท่านั้นที่จะนำมาใช้

### 3.4 กระบวนการปรับตัว (Adaptive Process)

โดยปกติสัญญาณคลื่นไฟฟ้าสมองจะมีความไม่คงที่ ซึ่งส่งผลไปยังคุณลักษณะที่สกัดได้จากตัวกรองช่องสัญญาณด้วย คุณลักษณะที่มีความไม่คงที่นั้นจะให้ผลการจำแนกประเภทที่มีความแม่นยำต่ำ กระบวนการปรับตัวจึงถูกนำมาใช้ในการจัดปัญหาดังกล่าวโดยการลบคุณลักษณะของข้อมูลทดสอบที่เข้ามายังระบบการทำนายด้วยค่าเฉลี่ยที่ได้จากตัวประมาณการเคลื่อนย้ายเฉลี่ยโดยการให้น้ำหนักเชิงเลขชี้กำลัง (EWMA) สามารถกล่าวได้ว่า ค่าประมาณการของค่าเฉลี่ยคือผลรวมของค่าเฉลี่ย ณ เวลาการทำนายก่อนหน้านี้กับค่าของคุณลักษณะปัจจุบัน โดยที่เวลาที่เริ่มต้นการทำนายนั้นเราให้ค่าเฉลี่ยก่อนหน้านี้เท่ากับค่าเฉลี่ยของข้อมูลฝึก และการเปลี่ยนแปลงของค่าเฉลี่ยจะถูกถ่วงหรือควบคุมด้วยค่าคงที่การปรับตัว  $\eta$  การปรับตัวโดยการประมาณการค่าเฉลี่ยแบบต่อเนื่องสามารถทำได้โดยใช้สมการที่ 3.2

$$\mu(i, t) = (1 - \eta)\mu(i - 1, t) + \eta x(i, t) \quad (3.2)$$

### 3.5 ตัวจำแนกประเภทแบบวางซ้อน

#### 3.5.1 ตัวจำแนกประเภทแบบวางซ้อนอาร์แอลดีเอ (Stacked Probabilistic Regularized LDA : SPRLDA)

ตัวจำแนกประเภทแบบแอลดีเอมีสมมติฐานว่าแต่ละคลาสมีการกระจายตัวของข้อมูลแบบเกาส์เซียน (Gaussian distributions) ที่แตกต่างกัน โดยค่าพารามิเตอร์ต่าง ๆ ของตัวจำแนกประเภทนั้นจะถูกประมาณการจากข้อมูลฝึกเพื่อฝึกสอนและนำไปทำนาย  $k$  คลาสของข้อมูลทดสอบ ผลการทำนายนั้นจะอ้างอิงคลาสที่ให้ค่าความน่าจะเป็นภายหลัง (posterior probability) มากที่สุดบนข้อมูลทดสอบ กำหนดให้  $x$  แทนข้อมูลเวกเตอร์ของคุณลักษณะจำนวน  $n$  มิติ และ  $y$  คือตัวแปรตามของคลาส  $k$  โดยอ้างอิงทฤษฎีของเบย์ (Bayes' Theorem) เราสามารถคำนวณหาค่าความน่าจะเป็นภายหลังของคลาส  $k$  ใด ๆ ได้ดังต่อไปนี้

$$p(y_k|x) = \frac{p(x|y_k)p(y_k)}{p(x)} \propto p(x|y_k)p(y_k) \quad (3.3)$$

ภายใต้สมมติฐานข้อมูล  $p(y_k|x)$  มีการกระจายตัวแบบเกาส์เซียน เราจะสามารถคำนวณค่าหาดีสคริมิแนนต์ฟังก์ชันของคลาส  $k$  ใด ๆ ได้ดังนี้ [55]

$$D_k(x) = x^T \tilde{\Sigma}^{-1} \mu_k - \frac{1}{2} \mu_k^T \tilde{\Sigma}^{-1} \mu_k + \log p(y_k) \quad (3.4)$$

$$D_k(x) = \log p(x|y_k) + \log p(y_k) \quad (3.5)$$

$$D_k(x) = \log \frac{1}{(2\pi)^{n/2} |\tilde{\Sigma}|^{1/2}} e^{\left(-\frac{1}{2}(x-\mu_k)^T \tilde{\Sigma}^{-1} (x-\mu_k)\right)} + \log p(y_k) \quad (3.6)$$



โดยที่  $\Sigma = (1 - \gamma)\Sigma + \gamma \text{diag}(\Sigma)$ ,

$$\Sigma = \frac{1}{N} (X - \bar{X})(X - \bar{X})^T, \mu_k = \frac{1}{N_k} \sum_{i=1}^{N_k} x_i$$

$X$  คือเมทริกซ์ซึ่งหลักแสดงถึงตัวอย่างข้อมูลที่ถูกรวมมาใช้ ค่าผลรวมของความน่าจะเป็นภายหลังของคลาส  $k$  นั้นมีค่า 1 ดังนั้นเราจะสามารถทำให้เป็นบรรทัดฐาน (normalize) ได้ดังนี้

$$p(y_k|x) = \frac{e^{(D_k(x) - D_{\max}(x))}}{\sum_{k=1}^K e^{(D_k(x) - D_{\max}(x))}} \quad (3.7)$$

ดังที่ได้กล่าวไปข้างต้นแล้วว่าวิธีการที่นำเสนอใช้นั้นใช้การวางซ้อนของตัวจำแนกประเภทซึ่งเกิดจากข้อมูลฝึกที่ถูกแบ่งเป็นกลุ่ม ๆ ทุกตัวจำแนกประเภทย่อยใด ๆ จะให้ค่าความน่าจะเป็นภายหลังจำนวน  $k$  ค่า วิธีการรวมผลลัพธ์ของตัวการจำแนกประเภทย่อย  $M$  ตัว ทำได้โดยนำค่าความน่าจะเป็นภายหลังที่เกิดขึ้นจากตัวจำแนกประเภทแต่ละตัวมาบวกกันตามคลาส ดังสมการที่ 3.8 โดยตัวจำแนกประเภทแบบวางซ้อนของอาร์แอลดีเอจจะทำนายผลลัพธ์ตามคลาสใด ๆ ที่ให้ค่าผลรวมความน่าจะเป็นภายหลังมากที่สุด

$$\hat{p}(y_k|x) = \text{argmax} \sum_{i=1}^M p_i(y_k|x) \quad (3.8)$$

### 3.5.2 ตัวจำแนกประเภทแบบวางซ้อนเอสวีเอ็ม (Stacked SVM)

กำหนดให้  $x$  แทนข้อมูลเวกเตอร์ของคุณลักษณะจำนวน  $n$  มิติ และ  $y_j$  คือตัวแปรตามของคลาสมีค่าเท่ากับ 1 และ -1 สมการระนาบแบ่งเขตข้อมูลถูกกำหนดด้วย [56]

$$f(x) = wx + b \quad (3.9)$$

โดยที่  $w$  แทนเวกเตอร์ค่าน้ำหนักและ  $b$  คือค่าไบแอสที่เป็นค่าสเกลาร์ โดยที่ค่า  $w, b$  คือค่าที่ทำให้ขนาดของ  $|f(x)|$  ต่ำที่สุดสำหรับทุก ๆ ค่า  $x$  หรือกล่าวได้ว่า หาค่าของ  $w, b$  ที่ทำให้  $|wx + b| = 1$  ดังนั้นทุก ๆ ค่าของ  $x$  จะอยู่ภายใต้เงื่อนไข

$$y_j f(x_j) \geq 1 \quad (3.10)$$

ค่า  $x_j$  ที่ทำให้  $y_j f(x_j) = 1$  เรียกว่าซัพพอร์ตเวกเตอร์ หรือสามารถเรียกอีกอย่างหนึ่งว่าขอบเขตการตัดสินใจ (decision boundary) ดังนั้นสำหรับการจำแนกประเภทข้อมูลเวกเตอร์  $z$  ใด ๆ ค่า  $f(z)$  ก็คือระยะห่างระหว่าง  $z$  ไปยังขอบเขตการตัดสินใจหรืออาจเรียกว่าคะแนนการตัดสินใจ (decision score) และเครื่องหมายของ  $f(z)$  จะแทนคลาสของเวกเตอร์  $z$

ผู้เขียนกำหนดให้ผลรวมของค่าความน่าจะเป็นของทุก ๆ คลาสมีค่าเป็นหนึ่ง ดังนั้นสามารถทำการปรับคะแนนการตัดสินใจให้เป็นค่าความน่าจะเป็นโดยใช้วิธีการปรับขนาดของแพลตฟอร์ม (Platform Scaling) [57] ความน่าจะเป็นของตัวอย่างข้อมูลใด ๆ สามารถหาได้จาก

$$p(y = 1|z) \equiv \frac{1}{1 + e^{Af(z)+B}} \quad (3.11)$$

โดยที่  $A, B$  เป็นค่าสเกลาร์ที่ถูกเรียนรู้ด้วยวิธีการของแพลตฟอร์ม ผลการจำแนกประเภทจะเป็นคลาสบวกถ้าค่าความน่าจะเป็นมีค่ามากกว่า 0.5 และจากที่กล่าวมาแล้วว่าวิธีการที่นำเสนอใช้การวางซ้อนของตัวจำแนกประเภทย่อย ดังนั้นวิธีการรวมผลลัพธ์ของตัวจำแนกประเภทแบบวางซ้อนเอสวีเอ็มจะเหมือนกับตัวจำแนกประเภทแบบวางซ้อนอาร์แอลดีเอ ซึ่งผู้เขียนได้กล่าวถึงมาแล้วในหัวข้อก่อนหน้า




## บทที่ 4

### การทดลองและการวิเคราะห์ผล

#### 4.1 ข้อมูลที่ใช้ทดลองในงานวิจัย

งานวิจัยนี้เลือกใช้ข้อมูลการทดลองจากกลุ่มวิจัย BCI Competition โดยเลือกกลุ่มข้อมูลการกระตุ้นแบบการจินตนาการการเคลื่อนไหวชุดข้อมูล 2b [58] ข้อมูลชุดนี้เก็บจากผู้เข้าทดลองจำนวน 9 คน ทุกคนถนัดขวา ในขณะที่เข้าทำการทดลองนั้นผู้เข้าทดลองถูกจัดให้อยู่ในท่านั่งสบายบนเก้าอี้นวมและตามองไปยังจอคอมพิวเตอร์ห่างประมาณ 1 เมตรในระดับสายตา โดยจะทำการจัดเก็บข้อมูลจำนวน 5 ช่วงเวลา ใช้ 3 ช่วงเวลาสำหรับเป็นชุดข้อมูลฝึกของตัวจำแนกประเภทซึ่งเป็นแบบไม่มีผลการป้อนกลับ (feedback) และ 2 ช่วงเวลาที่เหลือสำหรับเป็นชุดข้อมูลทดสอบซึ่งเป็นแบบมีผลการป้อนกลับ (จะอธิบายรายละเอียดการป้อนกลับในลำดับถัดไป)

ในแต่ละช่วงเวลาจะประกอบไปด้วยการทดลองหลายครั้งดังแสดงในภาพที่ 4.1 ในช่วง 5 วินาที เริ่มต้นจะเป็นการวัดสัญญาณของการกระพริบตา (สัญญาณ EOG eyes open/closed) เพื่อเป็นข้อมูลเทียบเคียงสำหรับการเตรียมข้อมูลก่อนที่จะทำการจำแนกประเภท โดยอาจจะมีการตัดสัญญาณกระพริบตาออกจากข้อมูลที่ต้องการนำไปจำแนกประเภท (งานวิจัยนี้ผู้เขียนไม่ได้แยกสัญญาณที่เกิดจากการกระพริบตาออกจากสัญญาณคลื่นไฟฟ้าสมอง) สัญญาณกระพริบตาจะมีขนาดสูงกว่าปกติค่อนข้างมากและสามารถสังเกตได้ด้วยตาเปล่าอย่างชัดเจน



ภาพที่ 4.1 การทดลองในหนึ่งช่วงเวลา [58]

การเก็บข้อมูลการจินตนาการการเคลื่อนไหว จะจัดเก็บบริเวณกลางศีรษะคือช่องสัญญาณ C3, Cz และ C4 ในทางการแพทย์เรียกบริเวณนี้ว่ามอเตอร์คอร์เทกซ์ (Motor Cortex) ซึ่งจะเป็นบริเวณที่มีความสัมพันธ์กับการจินตนาการเคลื่อนไหวมากที่สุด ในชุดข้อมูลข้างต้นนี้สัญญาณจะถูกสุ่มเก็บมาด้วยความถี่ 250 เฮิร์ตซ์ สัญญาณมีขนาดประมาณ  $\pm 100 \mu V$  สำหรับชุดที่ไม่มีผลป้อนกลับ (ข้อมูลฝึก) และมีขนาดประมาณ  $\pm 50 \mu V$  ในข้อมูลที่มีผลป้อนกลับ (ข้อมูลทดสอบ) โดยหลังจากทำการทดลองเสร็จแล้ว สัญญาณจะถูกกรองผ่านแถบความถี่ 0.5-100 เฮิร์ตซ์ และ กรองตัดแถบความถี่ (Notch filter) ที่สัญญาณ 50 เฮิร์ตซ์

โปรโตคอลการกระตุ้นนั้นจะมีการจินตนาการ 2 แบบหรือ 2 คลาส คือการจินตนาการขยับมือซ้ายและการจินตนาการขยับมือขวา การเก็บข้อมูลฝึกนั้นเก็บคนละวันและข้อมูลทั้งหมดจัดเก็บเสร็จภายในสองอาทิตย์ การเก็บข้อมูลฝึกหนึ่งครั้งประกอบด้วยจินตนาการ 20 ครั้ง รวมทั้งหมด 6 รอบต่อหนึ่งช่วงเวลา โดยได้ข้อมูลฝึกมีจำนวนทั้งสิ้น 120 ข้อมูลฝึกต่อหนึ่งช่วงเวลา เก็บข้อมูลฝึกทั้งสิ้น 3 ช่วงเวลา สำหรับข้อมูลทดสอบนั้นประกอบด้วยจินตนาการ 40 ครั้งต่อการเก็บข้อมูลหนึ่งรอบ (ซ้ายและขวาอย่างละ 20 ครั้ง) และ 4 รอบต่อหนึ่งช่วงเวลา รวมทั้งสิ้น 2 ช่วงเวลา ชุดข้อมูลทั้งสิ้นสรุปได้ดังตารางที่ 4.1 โดยในวงเล็บแสดงจำนวนของข้อมูล


ตารางที่ 4.1 ชุดข้อมูลที่ใช้ในการจำแนกประเภทการจินตนาการเคลื่อนไหว

ผู้ร่วมทดลอง	ชุดข้อมูลฝึก			ชุดข้อมูลทดสอบ	
	ช่วงเวลา 1	ช่วงเวลา 2	ช่วงเวลา 3	ช่วงเวลา 4	ช่วงเวลา 5
1	B0101T (120)	B0102T (120)	B0103T (120)	B0104E (160)	B0105E (160)
2	B0201T (120)	B0202T (120)	B0203T (120)	B0204E (140)	B0205E (140)
3	B0301T (120)	B0302T (120)	B0303T (120)	B0304E (160)	B0305E (160)
4	B0401T (120)	B0402T (120)	B0403T (120)	B0404E (160)	B0405E (160)
5	B0501T (120)	B0502T (120)	B0503T (120)	B0504E (160)	B0505E (160)
6	B0601T (120)	B0602T (120)	B0603T (120)	B0604E (160)	B0605E (160)
7	B0701T (120)	B0702T (120)	B0703T (120)	B0704E (160)	B0705E (160)
8	B0801T (120)	B0802T (120)	B0803T (120)	B0804E (160)	B0805E (160)
9	B0901T (120)	B0902T (120)	B0903T (120)	B0904E (160)	B0905E (160)

การจินตนาการหนึ่งครั้งสำหรับข้อมูลฝึกนั้นเป็นไปตามโปรโตคอลในภาพที่ 4.2 รูปบน โดยเริ่มต้นหน้าจอคอมพิวเตอร์จะแสดงเครื่องหมายกากบาทกลางจอและมีสัญญาณเสียง (beep) หลังจากนั้นวินาทีที่สาม จะปรากฏลูกศรชี้ไปทางซ้ายหรือขวาเพื่อให้ผู้เข้าร่วมทดลองเตรียมตัว และเริ่มให้ผู้เข้าร่วมการทดลองจินตนาการขยับมือซ้ายหรือขยับมือขวาตามทิศทางของลูกศรเป็นเวลาต่อเนื่อง 4 วินาที โดยเมื่อเสร็จสิ้น จะมีการพัก 1-1.5 วินาทีแล้วจึงเริ่มการจินตนาการครั้งต่อไป

สำหรับการทดลองที่มีมีผลป้อนกลับ (Smiley feedback) ซึ่งแสดงดังภาพที่ 4.2 รูปล่างนั้น ในช่วงเริ่มต้นตัวป้อนกลับซึ่งก็คือรูปหน้าสีเทา (Smiley) จะอยู่ตรงกลางจอคอมพิวเตอร์ วินาทีที่ 2 จะมีเสียงสัญญาณและวินาทีที่ 3 ถึงวินาที 7 ผู้เข้าร่วมทดลองจะต้องทำการจินตนาการโดยจะต้องเคลื่อนย้ายรูปหน้าไปทางซ้ายหรือไปทางขวาตามลำดับ และตัวรูปหน้าจะปรากฏเป็นหน้ายิ้มสีเขียวหากทิศทางนั้นถูกต้อง และจะกลายเป็นรูปหน้าเสียใจสีแดงหากทิศทางผิด โดยผู้เข้าร่วมทดลองจะต้องทำให้รูปหน้ายิ้มปรากฏให้นานที่สุดเท่าที่เป็นไปได้ในระหว่างวินาที 3-7.5 และการทดลองจะ

เก็บระดับการยิ้มหรือระดับการเสียใจด้วยเช่นกัน (เพื่อวัดระดับความสามารถในการจินตนาการ) ในวินาทีที่ 7.5 หน้าจอคอมพิวเตอร์จะว่างเปล่าอีกครั้งและพักระหว่าง 1-2 วินาทีก่อนเริ่มการจินตนาการครั้งใหม่



ภาพที่ 4.2 การทดลองในหนึ่งการจินตนาการ [58]

#### 4.2 การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

ในการนำแบบจำลองไปใช้งานจริงนั้น เราจำเป็นจะต้องทราบประสิทธิภาพของแบบจำลองเสียก่อนเพื่อประเมินว่าระบบที่ออกแบบมีความน่าเชื่อถือมากน้อยเพียงใด [59] และความแม่นยำในการทำนายนั้นยอมรับได้หรือไม่ โดยทั่วไปสามารถประเมินได้โดยการดูเมทริกซ์ความสับสน (Confusion Matrix) ซึ่งเป็นตารางแบบจัตุรัสมีจำนวนแถวเท่ากับจำนวนคอลัมน์และเท่ากับจำนวนคลาส เช่นในตารางที่ 4.2 มีคลาสคำตอบอยู่ 2 ค่า คือบวก (positive) และลบ (negative) จะสร้างได้เป็นตารางขนาด 2x2 โดยข้อมูลในแนวหลัก (column) คือคลาสที่ถูกทำนาย (predicted) และข้อมูลในแนวแถว (row) คือคลาสที่เป็นผลเฉลย (actual)

ตารางที่ 4.2 เมทริกซ์ความสับสนของข้อมูลซึ่งมี 2 คลาส

Actual /Predicted	positive	negative
positive	True Positive (TP)	False Negative (FN)
negative	False Positive (FP)	True Negative (TN)

จากในตารางที่ 4.2 ค่าที่แสดงในช่องต่าง ๆ ของตารางประกอบด้วย (คลาสที่สนใจคือคลาสบวก)

- True Positive (TP) คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสซึ่งกำลังสนใจอยู่
- True Negative (TN) คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสซึ่งไม่ได้สนใจอยู่
- False Positive (FP) คือ จำนวนข้อมูลที่ทำนายผิดมาเป็นคลาสซึ่งกำลังสนใจอยู่
- False Negative (FN) คือ จำนวนข้อมูลที่ทำนายผิดมาเป็นคลาสซึ่งไม่ได้สนใจอยู่

โดยทั่วไปจะมีตัววัดที่นิยมใช้กันในงานวิจัยและการทำงานต่างๆ อยู่ 4 ค่า คือ

ความเที่ยงตรง (Precision) เป็นการวัดความแม่นยำของแบบจำลองโดยพิจารณาแยกทีละคลาส เช่น ระบบทำนายว่าคำตอบเป็นบวกถูกต้องเท่าไรหลังจากการทำนายถูกต้องทั้งหมด

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (4.1)$$

ค่ารีคอล (Recall) เป็นการวัดความถูกต้องของแบบจำลองโดยพิจารณาแยกทีละคลาส เช่น ระบบทำนายว่าคำตอบเป็นบวกถูกต้องเท่าไรจากคลาสบวกจริงทั้งหมด

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (4.2)$$


ความแม่นยำ (Accuracy) เป็นการวัดความแม่นยำของแบบจำลองโดยรวม เช่นระบบทำนายถูกกี่ครั้งจากจำนวนครั้งในการทำนายทั้งหมด

$$\text{Accuracy} = \frac{\text{True Positive} + \text{True Negative}}{\text{True Positive} + \text{False Positive} + \text{True Negative} + \text{False Negative}} \quad (4.3)$$

### 4.3 การเตรียมการและกระบวนการทดลอง

#### 4.3.1 กระบวนการทดลอง

ในกระบวนการทดลองนั้นจะทำการสร้างแบบจำลองการจำแนกประเภททั้งในส่วนองแบบจำลองที่ขึ้นกับบุคคล (ข้อมูลฝึกและข้อมูลทดสอบเป็นของคนเดียวกัน) และแบบจำลองที่ไม่ขึ้นกับบุคคลคือ (ใช้ข้อมูลของบุคคลอื่นในการฝึกตัวจำแนกประเภท) กระบวนการทดลองแสดงดังภาพที่ 4.3 ซึ่งประกอบด้วย การเตรียมข้อมูล การประมวลผลขั้นต้นโดยตัดเอาเฉพาะช่วงสัญญาณในช่วงเวลาที่มีการจินตนาการมาใช้งาน การสร้างตัวกรองช่องสัญญาณและการสกัดคุณลักษณะ กระบวนการปรับตัวและการปรับให้เป็นมาตรฐานเพื่อลดผลกระทบของความไม่คงที่ของสัญญาณ และการจำแนกประเภทแบบต่าง ๆ ทั้งวิธีการที่นำเสนอและวิธีการที่นำมาเปรียบเทียบ ขั้นตอนสุดท้ายเป็นการวัดประสิทธิภาพของแบบจำลองด้วยการประเมินแบบตรวจสอบไขว้และการแบ่งทดสอบ โดยมีรายละเอียดดังต่อไปนี้



ภาพที่ 4.3 กระบวนการทดลอง

1) การตรวจสอบแบบไขว้ (Cross Validation) [59] การวัดประสิทธิภาพด้วยวิธีนี้จะแบ่งข้อมูลออกเป็นหลาย ๆ ส่วนเช่น การตรวจสอบแบบสิบส่วนไขว้ (10-fold cross validation) โดยที่แต่ละส่วนมีจำนวนข้อมูลเท่ากัน หลังจากนั้นข้อมูลหนึ่งส่วนจะใช้เป็นตัวทดสอบประสิทธิภาพของตัวจำแนกประเภทและที่เหลือเป็นชุดข้อมูลฝึก โดยจะทำการฝึกและทดสอบวนจนครบ จำนวนข้อมูลที่แบ่งไว้ วิธีนี้วัดประสิทธิภาพโดยการหาความแม่นยำของแต่ละรอบ

2) การแบ่งทดสอบ (Split Test) [59] เป็นการแบ่งข้อมูลด้วยการสุ่มออกเป็น 2 ส่วน เช่น 70% ต่อ 30% โดยข้อมูลส่วนที่หนึ่งคือ 70% ใช้ในการสร้างตัวจำแนกประเภทและข้อมูลส่วนที่สอง 30% ใช้ในการวัดประสิทธิภาพโดยการหาความแม่นยำ

#### 4.3.2 การออกแบบการทดลองสำหรับแบบจำลองการจำแนกประเภทที่นำเสนอ

ในงานวิจัยนี้แนะนำเสนอแบบจำลอง 2 แบบ ซึ่งอยู่ภายใต้การปรับค่าขีดแบ่งส่วนแบ่งน้อยที่สุด (Minimum Partition Size: Psize) บนข้อมูลฝึก ซึ่งก็หมายถึงจำนวนข้อมูลฝึกที่น้อยที่สุดที่ถูกกำหนดไว้ โดยค่าขีดแบ่งดังต่อไปนี้  $Psize \in \{40, 45, 50, 55, 60, 65, 70, 75, 80, 85, 90, 95, 100\}$  จะถูกใช้ในการประเมินเพื่อหาค่าขีดแบ่งส่วนแบ่งที่เหมาะสมสำหรับแต่ละบุคคล โดยแบบจำลองที่แนะนำมีดังนี้

1) ตัวจำแนกประเภทแบบพูลมีนรวมส่วนแบ่ง (PMean Merge Partition) : จุดการเปลี่ยนแปลงสิบจุดถูกสร้างขึ้นภายใต้ข้อมูลฝึกคลื่นไฟฟ้าสมองที่ขึ้นกับเวลาการเก็บข้อมูล (time series data of an averaged log variance of EEG signals) ด้วยขั้นตอนวิธีการแบ่งส่วนแบ่งแบบเหมาะสม หลังจากนั้นทำการรวมส่วนแบ่งขนาดเล็กด้วยวิธีการดังที่ได้กล่าวไปแล้วในบทที่ 3 เมื่อได้

กลุ่มของข้อมูลภายใต้เงื่อนไขค่าขีดแบ่งส่วนแบ่งน้อยที่สุดแล้ว จะทำการปรับค่าเฉลี่ยของข้อมูลฝึกให้เป็นศูนย์ก่อนฝึกตัวจำแนกประเภท พจน์ที่เรียกว่าพูลมีนนั้น (PMean) คือกระบวนการปรับตัวที่ถูกใช้ในข้อมูลทดสอบก่อนที่จะมีการทำนายผลลัพธ์ด้วยตัวจำแนกประเภทแบบวางซ้อนอาร์แอลดีเอ

2) ตัวจำแนกประเภทแบบพูลมีนรวมและแบ่งส่วนแบ่ง (PMean Merge Split Partition) : แนวคิดของวิธีการนี้เหมือนกับวิธีการก่อนหน้าเพียงแต่ว่าในกรณีที่เรามีส่วนแบ่งขนาดใหญ่มา ๑ จะต้องทำการแบ่งส่วนออกเป็นส่วนแบ่งย่อย ๆ เพื่อให้ได้ตัวจำแนกประเภทย่อยเพิ่มมากขึ้น ซึ่งวิธีการแบ่งส่วนแบ่งขนาดใหญ่ได้กล่าวไปแล้วในบทที่ 3 หลังจากทำการฝึกตัวจำแนกประเภทแบบวางซ้อนด้วยข้อมูลที่ถูกแบ่งแล้ว กระบวนการปรับตัวจะถูกใช้เพื่อลดผลกระทบของความไม่คงที่ในข้อมูลทดสอบก่อนการทำนายผลลัพธ์

#### 4.3.3 วิธีการที่ใช้ในการเปรียบเทียบ (Baseline Methods)

ในการประเมินประสิทธิภาพของวิธีการที่นำเสนอ จำเป็นที่จะต้องมียุทธศาสตร์ที่ใช้ในการเปรียบเทียบ โดยวิธีการเหล่านี้ถูกฝึกด้วยข้อมูลฝึกจากสามช่วงเวลา วิธีการที่ใช้ในการเปรียบเทียบประกอบไปด้วย

1) ตัวจำแนกประเภทแบบคงที่ซีเอสพีอาร์แอลดีเอ (Static CSP-RLDA) : ตัวจำแนกประเภทแบบคงที่ซีเอสพีอาร์แอลดีเอจะถูกฝึกด้วยคุณลักษณะที่สกัดด้วยตัวกรองช่องสัญญาณแบบดั้งเดิม ทั้งนี้เพื่อนำผลลัพธ์ไปเปรียบเทียบประสิทธิภาพกับตัวกรองช่องสัญญาณฟิลเตอร์แบงก์

2) ตัวจำแนกประเภทแบบคงที่เอฟบีซีเอสพี (Static FBCSP) : ตัวจำแนกประเภทแบบอาร์แอลดีเอและซีพฟอร์ตเวกเตอร์แมชชีน จะถูกสร้างขึ้นด้วยคุณลักษณะที่สกัดด้วยตัวกรองช่องสัญญาณฟิลเตอร์แบงก์และใช้วัดความแม่นยำบนข้อมูลทดสอบเพื่อเปรียบเทียบกับวิธีการอื่น ๆ

3) ตัวจำแนกประเภทแบบพูลมีนอาร์แอลดีเอ พูลมีนเอสวีเอ็ม (PMean RLDA; PMean SVM) : ผู้เขียนทำการปรับแต่งวิธีการแบบคงที่ให้เป็นแบบปรับตัวได้จากตัวจำแนกประเภทซีพฟอร์ตเวกเตอร์แมชชีนและอาร์แอลดีเอ โดยการทำให้คุณลักษณะของข้อมูลฝึกมีค่าเฉลี่ยเป็นศูนย์ก่อนการฝึกสอนตัวจำแนกประเภท และก่อนการทำนายผล กระบวนการปรับตัวจะถูกนำมาใช้บนข้อมูลทดสอบเพื่อลดผลกระทบของความไม่คงที่ของสัญญาณในข้อมูลทดสอบ

4) ตัวจำแนกประเภทที่ได้รับการยอมรับและนิยมใช้ในปัจจุบัน : ประกอบด้วยวิธีการพูลมีนแอลดีเอ (PMean LDA) [33] ซึ่งเทียบเท่ากับวิธีการเอ็มพีเอ็มแอลดีเอ (MPMLDA) วิธีการใช้ตัวกรองช่องสัญญาณแบบปรับตัวได้ (Adaptive CSP: ACSP-LDA) [44] วิธีการซีเอสอีเอ็ม (Corrective Sequential EM : CSEM) [47] โดยวิธีการทั้งหมดนี้จะถูกสร้างขึ้นจากคุณลักษณะที่สกัดได้จากตัวกรองช่องสัญญาณฟิลเตอร์แบงก์



#### 4.4 ผลการทดลองและวิเคราะห์ผลสำหรับแบบจำลองที่ขึ้นกับบุคคล

งานวิจัยนี้ออกแบบการทดลองสองแบบ โดยการทดลองแรกจะทำการวัดประสิทธิภาพของวิธีการที่นำเสนอด้วยวิธีการตรวจสอบสืบสวนไขว้ บนข้อมูลฝึกทั้งสามช่วงเวลา การทดลองที่สองนั้นวัดประสิทธิภาพด้วยวิธีการแบ่งข้อมูลทดสอบ ซึ่งจะใช้ข้อมูลทดสอบที่จัดแยกไว้ทั้งสองช่วงเวลาในการวัดประสิทธิภาพ ตัวจำแนกประเภทนั้นจะถูกฝึกด้วยข้อมูลฝึกทั้งสามช่วงเวลา โดยรวมแล้วการทดลองที่สองถือว่ามีความไม่คงที่ของสัญญาณระหว่างข้อมูลฝึกกับข้อมูลทดสอบมากกว่าการทดลองแรก เพราะข้อมูลทดสอบใช้การเก็บข้อมูลแบบมีการป้อนกลับ ในขณะที่ข้อมูลฝึกนั้นถูกเก็บแบบไม่มีการป้อนกลับ

##### 4.4.1 การวัดประสิทธิภาพด้วยการตรวจสอบสืบสวนไขว้

ผลการทดลองแรกแสดงในตารางที่ 4.3 โดยงานวิจัยนี้ใช้การทดสอบความแตกต่างของค่ากลางของสองประชากรแบบจับคู่ (Paired Student's t-test) ระหว่างคู่ของวิธีการที่นำเสนอแบบ PMean Merge Split Partition และวิธีการอื่น ๆ เพื่อที่จะเปรียบเทียบความแตกต่างของค่าเฉลี่ยระหว่างกลุ่มประชากรสองกลุ่มว่ามีความแตกต่างอย่างมีนัยสำคัญหรือไม่ โดยค่าเฉลี่ยของความแม่นยำของทุกบุคคลที่มีความแตกต่างอย่างมีนัยสำคัญที่  $p < 0.05$  ถูกกำกับด้วย \* และค่าเฉลี่ยของความแม่นยำที่มีความแตกต่างอย่างมีนัยสำคัญ  $p < 0.01$  ถูกกำกับด้วย \*\* โดยในการทดลองแรกนี้จัดทำขึ้นภายใต้สมมติฐานของค่าขีดแบ่งส่วนแบ่งที่เหมาะสมที่สุด (หรือดีที่สุด)

พิจารณาความแม่นยำเปรียบเทียบระหว่าง FBCSP (Static RLDA) และ CSP แบบดั้งเดิม (Static CSP-RLDA) พบว่า FBCSP นั้นให้ผลลัพธ์ค่าเฉลี่ยความแม่นยำดีกว่า CSP แบบดั้งเดิมอย่างมีนัยสำคัญ ทั้งนี้สาเหตุอาจเป็นเพราะ CSP นั้นมีจำนวนคุณลักษณะที่สกัดได้น้อยเพียงแค่ 3 คุณลักษณะจึงทำให้ความแม่นยำต่ำเมื่อเทียบกับ FBCSP ซึ่งมีคุณลักษณะที่เลือกมาใช้ทั้งสิ้น 12 คุณลักษณะ พิจารณาเปรียบเทียบระหว่าง PMean RLDA และ Static RLDA พบว่าค่าเฉลี่ยความแม่นยำของ Static RLDA นั้นชนะ PMean RLDA โดย Static RLDA นั้นดีกว่าในหลาย ๆ บุคคล นอกเหนือไปกว่านั้นวิธีการแบบคงที่หรือแบบ Static ของตัวจำแนกประเภทแบบ SVM และ LDA นั้น มีประสิทธิภาพดีกว่าวิธีการแบบปรับตัว PMean เล็กน้อยประมาณ 1% ของค่าความแม่นยำเฉลี่ย ทั้งนี้สามารถสรุปได้ว่าบนชุดข้อมูลนี้วิธีการแบบคงที่นั้นดีกว่าวิธีการแบบปรับตัว ทั้งนี้อาจเนื่องมาจากข้อมูลมีความคงที่ของสัญญาณที่ค่อนข้างมากทำให้ไม่ต้องการการปรับสัญญาณเพื่อเพิ่มความแม่นยำในการจำแนกประเภท

ตารางที่ 4.3 เปรียบเทียบความแม่นยำระหว่างวิธีการทำนายเสนอและวิธีการเปรียบเทียบ โดยใช้วิธีการประเมินแบบการตรวจสอบสลับส่วนไขว้

Subject	Baseline Methods										Proposed Methods			
	Static					PMean					ACSP LDA	CSEM	PMean Merge Partition	PMean Merge Split Partition
	CSP-RLDA	RLDA	LDA	SVM	SVM	RLDA	LDA	LDA	SVM	SVM				
1	60.2±11	<b>80.7±4.2</b>	79.7±4.9	78.2±3.9	76.0±6.7	76.0±6.7	77.0±6.1	79.7±11	75.0±11	76.7±7.7	80.2±5.1			
2	56.2±7.9	67.0±7.7	67.0±7.7	65.2±8.7	64.7±8.9	65.2±9.2	66.5±7.9	67.0±7.9	59.7±7.9	67.7±7.7	<b>68.2±6.5</b>			
3	56.1±6.9	57.0±7.2	56.5±7.4	54.7±4.7	59.0±7.6	58.8±8.0	58.8±8.3	56.5±6.9	55.3±6.9	61.1±9.9	<b>63.6±7.0</b>			
4	82.0±8.1	88.5±7.2	88.0±7.4	86.8±6.6	84.9±10	85.1±10	86.1±8.2	88.5±8.1	83.2±8.1	89.7±7.3	<b>90.1±6.0</b>			
5	61.30±11	83.1±9.4	83.6±8.5	84.8±8.8	83.4±6.7	82.5±7.1	83.2±6.8	83.6±11	79.8±11	82.7±7.3	<b>84.4±6.4</b>			
6	49.5±8.2	75.6±7.6	75.1±8.2	76.2±7.7	76.3±6.7	74.8±7.5	76.9±8.1	74.8±8.2	72.2±8.2	74.1±6.3	<b>78.4±5.3</b>			
7	57.1±6.2	78.9±13	78.7±13	76.9±10	75.2±14	74.9±13	74.9±11	78.7±6.2	74.6±6.2	75.9±12	<b>78.4±11</b>			
8	63.9±15	73.5±11	72.1±12	68.9±14	71.6±12	72.1±12	69.1±12	72.1±15	65.5±15	73.2±10	<b>76.7±11</b>			
9	65.1±10	73.6±13	73.3±12	71.8±13	73.6±13	73.3±14	75.1±12	72.8±10	69.6±10	75.8±11	<b>77.1±10</b>			
Mean	<b>**61.30</b>	<b>*75.36</b>	<b>**74.93</b>	<b>**73.77</b>	<b>**73.91</b>	<b>**73.68</b>	<b>**74.21</b>	<b>*74.90</b>	<b>**70.59</b>	<b>**75.25</b>	<b>77.50</b>			
SD	9.08	9.26	9.32	9.94	8.16	8.00	8.37	9.42	9.57	8.13	7.88			
p-value	0.0001	0.0174	0.0099	0.0055	-	-	0.0011	0.0108	-	0.0011				

เปรียบเทียบวิธีการที่นำเสนอ PMean Merge Split Partition กับวิธีการอื่น ๆ พบว่าแม่นยำกว่าอย่างมีนัยสำคัญ ทั้งในแง่เปรียบเทียบกับตัวจำแนกประเภทหลาย ๆ แบบ รวมถึงตัวจำแนกประเภทแบบคงที่และแบบปรับตัวได้ นอกจากนี้วิธีการที่นำเสนอยังดีกว่าวิธีการที่นิยมใช้ในปัจจุบันคือ CSEM และ ACSP สำหรับวิธีการที่นำเสนอ PMean Merge Partition นั้นพบว่าความแม่นยำเฉลี่ยน้อยกว่าวิธีการ PMean Merge Split Partition ค่อนข้างมาก แต่อย่างไรก็ตามก็ยังคงมีประสิทธิภาพดีกว่าวิธีการที่นำมาเปรียบเทียบในทุก ๆ แบบ

#### 4.4.2 การวัดประสิทธิภาพด้วยการแบ่งข้อมูลทดสอบ

การทดลองนี้ทำขึ้นภายใต้ค่าขีดแบ่งส่วนแบ่งน้อยที่สุดที่ถูกปรับแต่ง (calibrate) ด้วยข้อมูลทดสอบเริ่มต้นจำนวน 20 ครั้ง (20 การจินตนาการแรก) ซึ่งเปรียบเทียบได้กับการปรับแต่งแบบจำลองก่อนใช้เพื่อให้เหมาะสมต่อการใช้งานจริง ค่าขีดแบ่งส่วนแบ่งน้อยที่สุดที่เหมาะสมต่อแต่ละบุคคลได้แก่ Psize  $\in$  {55-90, 55-90, 40-90, 40, 40, 60-80, 50-55, 75-95, 55-95} ตามลำดับสำหรับวิธีการ PMean Merge Split Partition และ Psize  $\in$  {55-90, 55-90, 40-90, 40, 40, 60-80, 50-55, 75-95, 55-95} สำหรับวิธีการ PMean Merge Split Partition โดยในกรณีที่ความความแม่นยำบนข้อมูลเพื่อปรับแต่งเท่ากัน (จำนวนตัวอย่างน้อยทำให้การวัดประสิทธิภาพของ Psize ทำได้ไม่ดีพอ) เราจะเลือกค่ามัธยฐานของค่าขีดแบ่งมาใช้งานเพื่อสร้างแบบจำลองที่นำเสนอ โดยผลการทดลองแสดงในตารางที่ 4.4

จากตารางที่ 4.4 จะเห็นว่าวิธีการ CSEM นั้นมีความแม่นยำของการจำแนกประเภทที่ดีภายใต้อัตราการเรียนรู้ (learning rate) ในการปรับเมทริกซ์ของค่าเฉลี่ยและค่าความแปรปรวนร่วมเกี่ยวแบบต่อเนื่องเพื่อสร้างตัวจำแนกประเภทใหม่ก่อนการทำนาย ซึ่งผู้เขียนค้นหาค่าอัตราการเรียนรู้ที่ดีที่สุดในช่วง 0.01-0.1 มาใช้งาน วิธีการ CSEM นั้นมีความแม่นยำที่ดีกว่าวิธีการ Static และมีความแม่นยำเท่า ๆ กับวิธีการแบบปรับตัวได้แบบ PMean พิจารณาเปรียบเทียบวิธีการ CSEM กับวิธีการที่นำเสนอ PMean Merge Split Partition พบว่าวิธีการที่นำเสนอนั้นดีกว่าหากแต่ไม่พบว่ามีแตกต่างอย่างมีนัยสำคัญในแง่ของค่าเฉลี่ยความแม่นยำของทุกบุคคล พิจารณาเปรียบเทียบวิธีการ PMean Merge Split Partition และวิธีการ LDA และ PMean LDA พบว่าวิธีการที่นำเสนอนั้นมีความแม่นยำกว่าอย่างมีนัยสำคัญ เปรียบเทียบวิธีการที่นำเสนอกับตัวจำแนกประเภท SVM และ PMean SVM พบว่าวิธีการที่นำเสนอนั้นมีความแม่นยำกว่าอย่างมีนัยสำคัญเช่นกัน นอกจากนี้วิธีการที่นำเสนอก็คงมีความแม่นยำกว่าตัวกรองช่องสัญญาณแบบปรับตัวได้ ACSP ที่ใช้ตัวจำแนกประเภทแบบ LDA

ตารางที่ 4.4 เปรียบเทียบความแม่นยำระหว่างวิธีการทำนายเสนอและวิธีการเปรียบเทียบ โดยใช้วิธีการประเมินแบบแบ่งข้อมูลทดสอบ

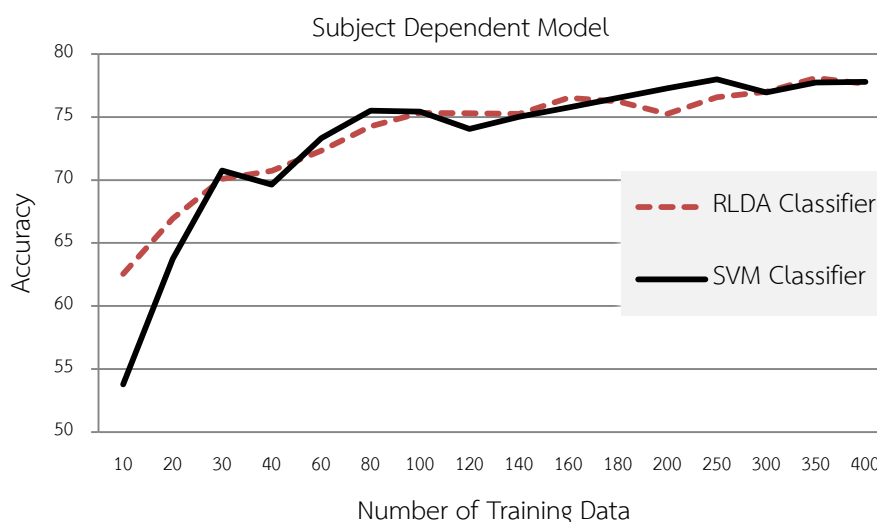
Subject	Baseline Methods											Proposed Methods	
	Static				PMean				ACSP LDA	CSEM	PMean Merge Partition	PMean Merge Split Partition	
	CSP-RLDA	RLDA	LDA	SVM	RLDA	LDA	SVM						
1	56.73	74.60	73.98	73.98	74.29	74.6	73.98	73.98	69.59	77.11	<b>79.93</b>		
2	49.10	56.27	56.27	56.63	58.06	58.06	56.98	56.27	<b>59.85</b>	59.49	57.70		
3	60.89	50.64	50.64	51.28	49.67	49.67	51.60	50.64	<b>58.97</b>	53.2	54.16		
4	64.37	90.00	90.31	92.50	95.31	95.62	95.31	90.31	93.12	96.25	<b>97.18</b>		
5	74.68	<b>100.0</b>	<b>100.0</b>	99.37	98.43	98.43	98.43	<b>100.0</b>	99.68	99.37	99.37		
6	64.06	79.68	79.68	77.50	79.68	80.00	77.18	79.68	75.31	83.75	<b>83.75</b>		
7	68.98	74.05	75.31	74.05	76.26	75.94	75.31	75.31	74.05	75.00	<b>77.84</b>		
8	85.57	83.38	83.07	83.38	86.52	86.52	<b>87.77</b>	83.38	87.14	86.52	<b>87.77</b>		
9	71.25	81.25	80.62	82.81	82.81	82.81	81.87	80.62	83.75	81.56	<b>84.68</b>		
Mean	**66.18	**76.65	**76.65	**76.83	**77.89	**77.96	**77.60	**76.68	77.94	**79.13	<b>80.26</b>		
SD	10.59	15.41	15.40	15.44	15.93	15.98	15.76	15.42	14.14	15.26			
p-value	0.0088	0.0012	0.0014	0.0013	0.0062	0.0055	0.0076	0.0014	0.1898	0.0701			

#### 4.5 ผลการทดลองและวิเคราะห์ผลเพื่อเปรียบเทียบระหว่างแบบจำลองที่ขึ้นกับบุคคลและแบบจำลองที่ไม่ขึ้นกับบุคคล

การทดลองนี้จัดทำขึ้นโดยใช้การวัดประสิทธิภาพแบบแบ่งข้อมูลทดสอบ มีจุดประสงค์เพื่อนำเสนอวิธีการจำแนกประเภทที่ไม่ขึ้นกับบุคคล ซึ่งเป็นวิธีการที่สามารถนำไปใช้จำแนกประเภทโดยไม่ต้องมีข้อมูลฝึกของผู้ป่วยหรือใช้ข้อมูลฝึกของผู้ป่วยน้อยที่สุด ซึ่งในการนำแบบจำลองไปใช้งานจริงนั้นค่อนข้างเป็นไปได้ยากที่เราจะทำการเก็บข้อมูลจำนวนมาก การทดลองจะวิเคราะห์จำนวนข้อมูลฝึกที่ส่งผลต่อความแม่นยำเฉลี่ยของทุกบุคคล เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองที่ไม่ขึ้นกับบุคคลและแบบจำลองที่ขึ้นกับบุคคล วิธีการที่นำเสนอในส่วนของแบบจำลองที่ไม่ขึ้นกับบุคคลนั้นจะทำการเปลี่ยนตัวจำแนกประเภทที่ประกอบเป็นตัวจำแนกประเภทแบบวางซ้อนจากอาร์แอลดีเอเป็นเอสวีเอ็มเพราะให้ผลลัพธ์ที่ดีกว่าในแง่ที่ไม่ได้ใช้ข้อมูลฝึกของตนเอง

##### 4.5.1 จำนวนข้อมูลฝึกที่ส่งผลความแม่นยำของตัวจำแนกประเภทในแบบจำลองที่ขึ้นกับบุคคล

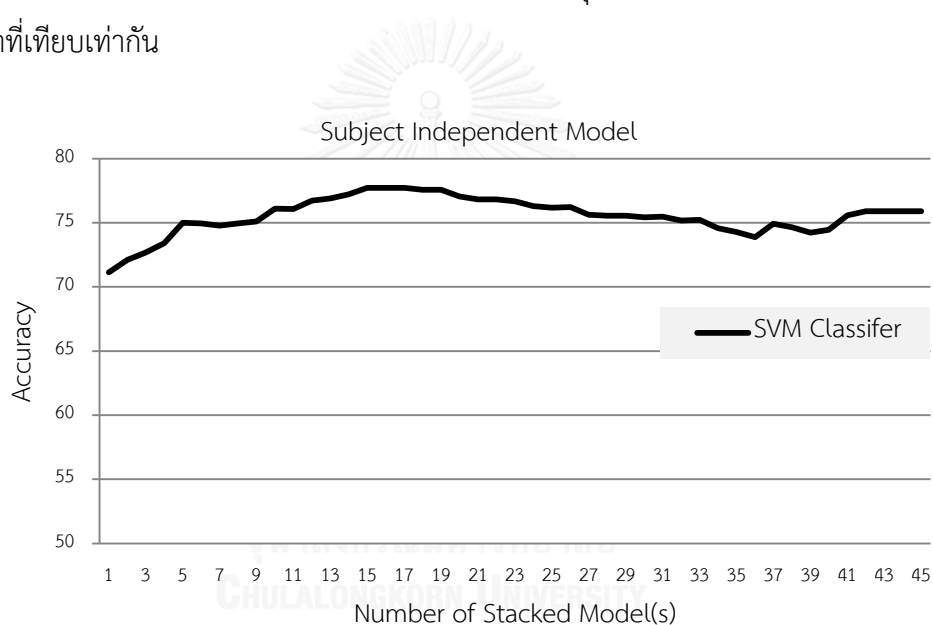
ภาพที่ 4.4 แสดงความแม่นยำเฉลี่ยทุกบุคคลต่อจำนวนข้อมูลฝึกของแบบจำลองที่ขึ้นกับบุคคล ภายใต้ข้อมูลชุดนี้จะเห็นว่าจำนวนข้อมูลฝึกส่งผลต่อความแม่นยำเป็นอย่างมาก เช่นเมื่อใช้ข้อมูลฝึกน้อย 10-20 การจินตนาการ พบว่าตัวจำแนกประเภทมีประสิทธิภาพค่อนข้างต่ำและอาร์แอลดีเอนั้นให้ผลที่ดีกว่าตัวจำแนกประเภทเอสวีเอ็ม จากกราฟพบว่าความเพียงพอของข้อมูลฝึกที่ทำให้ได้ความแม่นยำที่ใกล้เคียงกับจุดอิ่มตัวนั้นอยู่ที่ 120-140 การจินตนาการ ซึ่งจริง ๆ แล้วในการนำไปใช้งานจริงค่อนข้างทำได้ยากที่จะเก็บข้อมูลฝึกที่มีคุณภาพได้จำนวนมากเท่านี้



ภาพที่ 4.4 เปรียบเทียบความแม่นยำต่อจำนวนข้อมูลฝึกของแบบจำลองที่ขึ้นกับบุคคล

#### 4.5.2 วิธีการที่นำเสนอแบบจำลองที่ไม่ขึ้นกับบุคคล

ภาพที่ 4.5 แสดงความแม่นยำเฉลี่ยทุกบุคคลของวิธีการที่นำเสนอเทียบกับจำนวนตัวจำแนกประเภทย่อยที่ประกอบขึ้นเป็นตัวจำแนกประเภทแบบวางซ้อน โดยผลการทดลองเป็นแบบที่ไม่ขึ้นกับบุคคลคือใช้ข้อมูลของบุคคลอื่นในการฝึกตัวจำแนกประเภท วิธีการเลือกตัวจำแนกย่อยนั้นจะทำการประเมินประสิทธิภาพของตัวจำแนกย่อยทุกตัว (45 ตัว) บนข้อมูลทดสอบจำนวน 20 การจินตนาการแรก จากกราฟพบว่าบนข้อมูลชุดนี้นั้นการเลือก 15-17 ตัวจำแนกประเภทย่อยที่ดีที่สุดเพื่อประกอบเป็นตัวจำแนกประเภทแบบวางซ้อนนั้นให้ผลลัพธ์ที่ดีที่สุด เราจะเห็นว่าเมื่อเปรียบเทียบความแม่นยำของตัวจำแนกประเภทแบบวางซ้อนที่นำเสนอ (แบบจำลองที่ไม่ขึ้นกับบุคคล) ที่ประกอบขึ้นจากตัวจำแนกประเภทย่อย 15-17 ตัว เทียบกับวิธีการที่ขึ้นกับบุคคลในภาพที่ 4.4 นั้นให้ผลลัพธ์ความแม่นยำที่เทียบเท่ากัน



ภาพที่ 4.5 เปรียบเทียบความแม่นยำต่อจำนวนตัวจำแนกประเภทย่อยที่ประกอบขึ้นเป็นตัวจำแนกประเภทแบบวางซ้อน

กล่าวโดยสรุป ในการนำแบบจำลองที่ทำการออกแบบไปใช้กับผู้ป่วย การเก็บข้อมูลฝึกทำได้ยาก การจะเก็บข้อมูลฝึกให้เพียงพอจำเป็นต้องทำการจินตนาการมากกว่า 120 ครั้ง ซึ่งเป็นไปไม่ได้เลยที่จะทำกับผู้ป่วย วิธีการที่เหมาะสมสำหรับการนำไปใช้กับผู้ป่วยคือการใช้แบบจำลองที่ไม่ขึ้นกับบุคคล โดยข้อมูลฝึกอาจมาจากบุคคลปกติหลาย ๆ คน (ซึ่งอาจอยู่บนฐานข้อมูล) สัญญาณคลื่นไฟฟ้าสมองที่ใช้ฝึกตัวจำแนกประเภทควรจะถูกรวบรวมภายใต้สภาพแวดล้อมที่ถูกรวบรวมเพื่อลดผลกระทบของความไม่คงที่ของสัญญาณ เมื่อได้ข้อมูลฝึกแล้วใช้วิธีการที่นำเสนอในการฝึกตัวจำแนกประเภทเพื่อใช้กับผู้ป่วย ซึ่งวิธีการที่เสนอนั้นใช้ข้อมูลฝึกของผู้ป่วยเพียง 20 การจินตนาการเพื่อเลือกตัวจำแนกประเภทย่อยที่ดีที่สุดประกอบเป็นตัวจำแนกประเภทแบบวางซ้อน

## บทที่ 5


### การพัฒนาระบบต้นแบบ

เนื่องจากผู้ป่วยแอลไอเอสนั้นไม่สามารถเคลื่อนไหวร่างกายได้ ดังนั้นการให้ความดูแลช่วยเหลือ เพื่อให้ผู้ป่วยดำรงชีวิตได้นั้นจะครอบคลุมกรณี [11] การให้ความช่วยเหลือในทุก ๆ กิจกรรมของการดำรงชีวิต การใส่ท่อช่วยหายใจและใช้เครื่องช่วยหายใจร่วมด้วยในกรณีผู้ป่วยไม่สามารถหายใจได้เอง การฟื้นฟูสุขภาพ เช่น การทำกายภาพบำบัด เพื่อป้องกันไม่ให้เกิดภาวะแทรกซ้อน (ผลข้างเคียง) เช่น แผลกดทับ การฝึกการสื่อสารระหว่างกันทั้งผู้ดูแลและผู้ป่วย

ในบทนี้จะกล่าวถึงการพัฒนาระบบต้นแบบที่จะใช้ในการจำแนกประเภทแบบสองคำตอบจากการจินตนาการการเคลื่อนไหวเพื่อใช้ในการให้ความดูแลช่วยเหลือกับผู้ป่วย โดยระบบต้นแบบใช้ชื่อว่า “YesNo Classification : YNC” ซึ่งสามารถฝึกตัวจำแนกประเภทจากข้อมูลฝึกที่ถูกจัดเก็บ และสามารถจำแนกประเภทข้อมูลทดสอบซึ่งเก็บจากคนละช่วงเวลาได้ เนื้อหาในบทนี้ประกอบไปด้วย รายละเอียดความต้องการของระบบ โครงสร้างและการทำงานของระบบต้นแบบ การออกแบบและพัฒนาระบบต้นแบบ การพัฒนาระบบต้นแบบ

#### 5.1 ภาพรวมของระบบ

ระบบที่จัดทำขึ้นแบ่งความต้องการเชิงหน้าที่ออกเป็น 6 ด้าน และความต้องการที่ไม่ใช่หน้าที่ 1 ด้าน ซึ่งแสดงในภาพที่ 5.1 โดยความต้องการเชิงหน้าที่ประกอบไปด้วยการตั้งค่าระบบ การแสดงสัญญาณดิบของคลื่นไฟฟ้าสมอง การแสดงผลตอบสนองเชิงความถี่ การแสดงผลลัพธ์การจำแนกประเภทของสัญญาณ การจำแนกประเภทการจินตนาการการเคลื่อนไหว การฝึกสอนตัวจำแนกประเภท ส่วนความต้องการที่ไม่ใช่หน้าที่หรือความต้องการเชิงคุณภาพนั้นประกอบไปด้วยความสามารถในการจำแนกประเภทภายในเวลาที่กำหนด



ภาพที่ 5.1 ภาพรวมความต้องการของระบบ


## 5.2 ความต้องการของระบบ

ระบบต้นแบบจะถูกใช้โดยผู้ใช้ระบบ (user) โดยผู้ใช้ระบบประกอบไปด้วยผู้ใช้งาน และผู้ใช้ระบบเสมือน ซึ่งได้แก่สัญญาณคลื่นไฟฟ้าสมองที่ถูกจัดเก็บมา ฐานข้อมูลที่ใช้จัดเก็บข้อมูลฝึก ฐานข้อมูลการจัดเก็บตัวจำแนกประเภท ระบบต้นแบบจะถูกจัดทำขึ้นตามความต้องการ ซึ่งแบ่งออกเป็นความต้องการเชิงหน้าที่และความต้องการการที่ไม่ใช่หน้าที่ ซึ่งมีรายละเอียดดังต่อไปนี้

### 5.2.1 ความต้องการเชิงหน้าที่ (Functional Requirements)

ในการกำหนดความต้องการเชิงหน้าที่นั้น ผู้เขียนได้พิจารณาออกแบบลักษณะการใช้งานที่จำเป็นต่อการจำแนกประเภท ซึ่งวิธีการจำแนกประเภทนั้นจะใช้วิธีการที่นำเสนอที่ได้กล่าวไปในบทก่อนหน้า ผู้เขียนใช้ยูสเคสในภาพที่ 5.2 เพื่อประกอบกับคำอธิบายยูสเคสในตารางที่ 5.1-5.20 เพื่ออธิบายการทำงานเชิงหน้าที่ของระบบและผู้ใช้งานดังต่อไปนี้





ภาพที่ 5.2 แผนภาพยูสเคสของระบบต้นแบบ

ตารางที่ 5.1 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าหน้าต่างโปรแกรม

<b>ชื่อยูสเคส:</b> บันทึกค่าหน้าต่างโปรแกรม	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-01
<b>คำอธิบาย:</b> เป็นขั้นตอนการบันทึกการจัดลักษณะของหน้าต่างโปรแกรมเพื่อเรียกคืนค่าการจัดลักษณะได้ในภายหลัง หน้าต่างย่อยสามารถเปลี่ยนตำแหน่งและจับแยกออกจากกันได้อย่างอิสระ		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเปลี่ยนตำแหน่งของหน้าต่างย่อยหรือแยกหน้าต่างย่อยออกจากกันเพื่อดูผลลัพธ์ในหลาย ๆ หน้าต่างพร้อมกัน		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. ผู้ใช้ตรวจสอบตำแหน่งหน้าต่างที่ต้องการบันทึก</li> <li>2. กดปุ่มบันทึกสถานะของโปรแกรม</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> <p>2ก : ผู้ใช้สามารถบันทึกซ้ำได้ในกรณีต้องการเปลี่ยนตำแหน่งหน้าต่างโปรแกรมเพิ่มเติม</p>		

ตารางที่ 5.2 คำอธิบายยูสเคสของผู้ใช้เพื่อเรียกคืนค่าหน้าต่างโปรแกรม

<b>ชื่อยูสเคส:</b> เรียกคืนค่าหน้าต่างโปรแกรม	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-02
<b>คำอธิบาย:</b> เรียกคืนค่าการจัดลักษณะโปรแกรมที่ได้ถูกบันทึกไว้ การเรียกคืนนี้ออกแบบเพื่อมีวัตถุประสงค์ให้สามารถใช้ในการรวมหน้าต่างที่ถูกจับแยกออกให้รวมเข้าด้วยกัน		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการลักษณะการจัดรูปแบบที่ได้บันทึกไว้ก่อนหน้า		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. กดปุ่มเรียกคืนสถานะของโปรแกรม</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.3 คำอธิบายยูสเคสของผู้ใช้เพื่อกำหนดค่าสภาพแวดล้อม

<b>ชื่อยูสเคส:</b> ตั้งค่าสภาพแวดล้อม	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-03
<b>คำอธิบาย:</b> ตั้งค่าทั่วไปที่เกี่ยวข้องกับการใช้งานโปรแกรม		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเปลี่ยนค่าปรีายของค่าสภาพแวดล้อมให้เป็นที่ต้องการ		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. เลือกบุคคลที่จะทำการจำแนกประเภท</li> <li>2. เปลี่ยนอัตราการขยับลูกบอลแสดงผลการจำแนก</li> <li>3. เลือกโหมดการทำงานแบบ offline/online</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.4 คำอธิบายยูสเคสของผู้ใช้เพื่อตั้งค่าการจำแนกประเภท

<b>ชื่อยูสเคส:</b> ตั้งค่าการจำแนก	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-04
<b>คำอธิบาย:</b> ตั้งค่าทั่วไปที่เกี่ยวกับการจำแนกประเภท เช่นเวลาเริ่มต้น เวลารวมที่ใช้ในการจินตนาการ วินโดว์เวลาที่ใช้ในการจำแนก หมวดการทำงาน		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเปลี่ยนค่าปรีายของการจำแนกประเภท		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. ตั้งค่าเวลาเริ่มต้นของสัญญาณที่จะนำไปใช้จำแนก</li> <li>2. ตั้งค่าเวลาการเลื่อน สำหรับหมวดการจำแนกแบบเลื่อน</li> <li>3. ตั้งค่าวินโดว์เวลาที่ใช้จำแนก</li> <li>4. ตั้งค่าเวลาการจินตนาการ</li> <li>5. ตั้งค่าหมวดการทำงาน</li> <li>6. ตั้งค่าเปิดหรือปิดใช้งานระบบปรับตัวได้อัตโนมัติ</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.5 คำอธิบายยูสเคสของผู้ใช้เพื่อตั้งค่าฝึกสอนตัวจำแนกประเภท

<b>ชื่อยูสเคส:</b> ตั้งค่าฝึกสอนตัวจำแนก	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-05
<b>คำอธิบาย:</b> ตั้งค่าทั่วไปที่เกี่ยวกับการฝึกสอนตัวจำแนกประเภท เช่นเวลาเริ่มต้นที่จะนำสัญญาณไปใช้ วินโดว์เวลาที่ใช้ในการจำแนก หมวดการทำงาน		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเปลี่ยนค่าปรีายของการฝึกสอนตัวจำแนกประเภท		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. ตั้งค่าเวลาเริ่มต้นของสัญญาณที่จะนำไปใช้จำแนก</li> <li>2. ตั้งค่าวินโดว์เวลาที่ใช้จำแนก</li> <li>3. ตั้งค่าเวลาการจินตนาการ</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.6 คำอธิบายยูสเคสของผู้ใช้เพื่อตั้งค่าทางเลือกในการจำแนกประเภท

<b>ชื่อยูสเคส:</b> ตั้งค่าทางเลือกการจำแนก	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-06
<b>คำอธิบาย:</b> ตั้งค่าทั่วไปที่เกี่ยวกับการทางเลือกในการใช้ตัวจำแนกประเภท		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเปลี่ยนค่าปรีายของตัวจำแนกประเภทที่ใช้		

<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>ตั้งค่าตัวจำแนกประเภท LDA/SVM</li> <li>ตั้งค่าแบบจำลองที่ใช้ Single/Stacked</li> </ol>
<b>ขั้นตอนการทำงานทางเลือก: -</b>

ตารางที่ 5.7 คำอธิบายยูสเคสของผู้ใช้เพื่อบันทึกค่าพารามิเตอร์

<b>ชื่อยูสเคส:</b> บันทึกค่าพารามิเตอร์	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-07
<b>คำอธิบาย:</b> เป็นขั้นตอนการบันทึกค่าต่าง ๆ ที่ผู้ใช้ต้องการเปลี่ยนจากค่าปริยาย ค่าเหล่านี้บันทึกเพื่อสามารถเรียกคืนกลับมาใช้ใหม่ได้		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการจดจำค่าต่าง ๆ ที่ได้ปรับไว้และสามารถเรียกคืนกลับมาใช้ใหม่ได้		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>ปรับค่าต่าง ๆ ตามที่ต้องการ และตรวจสอบความถูกต้อง</li> <li>กดปุ่มบันทึกพารามิเตอร์</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> <p>2ก: ผู้ใช้สามารถบันทึกซ้ำได้โดยย้อนกลับไปขั้นตอนที่ และทำการบันทึกอีกครั้ง 1</p>		

ตารางที่ 5.8 คำอธิบายยูสเคสของผู้ใช้เพื่อเรียกคืนค่าพารามิเตอร์ที่บันทึกไว้

<b>ชื่อยูสเคส:</b> เรียกคืนค่าพารามิเตอร์	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC1-08
<b>คำอธิบาย:</b> เรียกคืนค่าพารามิเตอร์ต่าง ๆ ที่ได้บันทึกไว้ก่อนหน้า		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการเรียกคืนค่าต่าง ๆ ที่เคยได้บันทึกไว้		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>กดปุ่มเรียกคืนค่าพารามิเตอร์</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก: -</b>		

ตารางที่ 5.9 คำอธิบายยูสเคสของการแสดงผลสัญญาณคลื่นไฟฟ้าสมอง

<b>ชื่อยูสเคส:</b> แสดงผลสัญญาณดิบ	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC2-01
<b>คำอธิบาย:</b> แสดงสัญญาณดิบที่ระบบใช้ในการจำแนก		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>ผู้ใช้กดปุ่มเริ่มจินตนาการ</li> </ol>		

<ol style="list-style-type: none"> <li>2. ระบบทำการดึงข้อมูลสัญญาณอีอีจี</li> <li>3. ระบบแสดงผลสัญญาณดิบของทุกช่องสัญญาณ</li> </ol>
<b>ขั้นตอนการทำงานทางเลือก:</b> 3ก: ผู้ใช้สามารถเลือกดูสัญญาณคลื่นไฟฟ้าสมองในแต่ละช่องสัญญาณที่วัดได้

ตารางที่ 5.10 คำอธิบายยูสเคสของการแสดงตอบสนองเชิงความถี่ของสัญญาณ

<b>ชื่อยูสเคส:</b> แสดงผลตอบสนองเชิงความถี่	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC3-01
<b>คำอธิบาย:</b> แสดงผลตอบสนองเชิงความถี่ของสัญญาณบริเวณสมองซีกซ้ายและซีกขวา (C3, C4)		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก		
<b>ขั้นตอนการทำงานปกติ:</b>		
<ol style="list-style-type: none"> <li>1. ผู้ใช้กดปุ่มเริ่มจินตนาการ</li> <li>2. ระบบทำการดึงข้อมูลสัญญาณอีอีจี</li> <li>3. ระบบแสดงผลตอบสนองเชิงความถี่ของสมองซีกซ้ายและซีกขวา</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.11 คำอธิบายยูสเคสของผู้ใช้เริ่มการจำแนกประเภทสัญญาณ

<b>ชื่อยูสเคส:</b> เริ่มการจินตนาการ/เริ่มจำแนก	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC4-01
<b>คำอธิบาย:</b> เป็นขั้นตอนเริ่มจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการจำแนกประเภทคลื่นไฟฟ้าสมอง		
<b>ขั้นตอนการทำงานปกติ:</b>		
<ol style="list-style-type: none"> <li>1. เลือกบุคคลที่จะทำการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง</li> <li>2. ผู้ใช้ตรวจสอบค่าต่าง ๆ ของโปรแกรม</li> <li>3. กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b>		
3ก: ผู้ใช้สามารถกดปุ่ม Reset เพื่อตั้งค่าการแสดงผลเริ่มต้นก่อนการทำนายได้		

ตารางที่ 5.12 คำอธิบายยูสเคสของผู้ใช้เพื่อตั้งค่าแสดงผลการทำงานของทำนายเป็นค่าปริยาย

<b>ชื่อยูสเคส:</b> ตั้งค่าใหม่	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC4-02
<b>คำอธิบาย:</b> เป็นขั้นตอนการตั้งค่าการแสดงผลลูกบอลขยับ แสดงผล YES/NO ให้กลับมาเป็นค่ากลางหลังจากโปรแกรมได้แสดงผลการจำแนกประเภทก่อนหน้านี้		

<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการให้กลางแสดงผลลูกบอลขยับและตัวแสดงผล YES/NO เป็นค่ากลาง (ไม่ใช่ค่าที่ทำนายว่า YES หรือ NO)
<b>ขั้นตอนการทำงานปกติ:</b> 1. กดตั้งค่าใหม่ (reset)
<b>ขั้นตอนการทำงานทางเลือก:</b> -

ตารางที่ 5.13 คำอธิบายยูสเคสของผู้ใช้เพื่อจำแนกตัวอย่างข้อมูลถัดไป

<b>ชื่อยูสเคส:</b> จำแนกตัวอย่างถัดไป	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC4-03
<b>คำอธิบาย:</b> เป็นขั้นตอนเลื่อนข้อมูลการจำแนกไปยังตัวอย่างถัดไป		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการจำแนกประเภทตัวอย่างข้อมูลถัดไป		
<b>ขั้นตอนการทำงานปกติ:</b> 1. กดถัดไป (next)		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.14 คำอธิบายยูสเคสของผู้ใช้เพื่อฝึกสอนตัวจำแนกประเภท

<b>ชื่อยูสเคส:</b> ฝึกสอนตัวจำแนก	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC5-01
<b>คำอธิบาย:</b> เป็นขั้นตอนฝึกสอนตัวจำแนกประเภท		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการฝึกสอนตัวจำแนกประเภทใหม่		
<b>ขั้นตอนการทำงานปกติ:</b> 1. เลือกบุคคลที่จะทำการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง 2. เลื่อนดูตัวอย่างข้อมูลฝึกสอน 3. กดลบข้อมูลบางตัวที่มีคุณภาพต่ำ 4. กดฝึกสอนตัวจำแนกประเภท		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.15 คำอธิบายยูสเคสของผู้ใช้เพื่อลบตัวอย่างข้อมูลที่ไม่ได้คุณภาพ

<b>ชื่อยูสเคส:</b> ลบตัวอย่างข้อมูล	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC5-02
<b>คำอธิบาย:</b> เป็นขั้นตอนการลบตัวอย่างข้อมูลฝึกที่ไม่ได้คุณภาพ		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการลบบางตัวอย่างข้อมูลออกจากข้อมูลฝึก		
<b>ขั้นตอนการทำงานปกติ:</b>		

<ol style="list-style-type: none"> <li>1. กดเลื่อนดูตัวอย่างข้อมูลฝึก</li> <li>2. กดลบข้อมูลบางตัวที่มีคุณภาพต่ำ</li> </ol>
<b>ขั้นตอนการทำงานทางเลือก:</b> <ol style="list-style-type: none"> <li>1ก: ผู้ใช้ต้องดูข้อมูลสัญญาณและผลตอบสนองเชิงความถี่ประกอบเพื่อการลบข้อมูล</li> <li>2ก: ผู้ใช้สามารถย้อนกลับไปใช้ค่าปริยายได้กรณีตัวจำแนกประเภทใหม่มีความสามารถต่ำ</li> </ol>

ตารางที่ 5.16 คำอธิบายยูสเคสของผู้ใช้เพื่อเลื่อนดูข้อมูลฝึกสอน

<b>ชื่อยูสเคส:</b> เลื่อนดูตัวอย่าง	<b>ผู้กระทำหลัก:</b> ผู้ใช้	<b>รหัส:</b> YNC5-03
<b>คำอธิบาย:</b> เป็นขั้นตอนการดูข้อมูลฝึกแต่ละตัว		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการดูข้อมูลฝึก หรือลบบางตัวอย่างออกจากข้อมูลฝึก		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. กดเลื่อนดูตัวอย่างข้อมูลฝึกสอน</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> <ol style="list-style-type: none"> <li>1ก: ผู้ใช้ดูข้อมูลสัญญาณและผลตอบสนองเชิงความถี่</li> </ol>		

ตารางที่ 5.17 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลในลักษณะยังไม่มีการจำแนก

<b>ชื่อยูสเคส:</b> แสดงผลค่าเริ่มต้น	<b>ผู้กระทำหลัก:</b> โปรแกรม	<b>รหัส:</b> YNC6-01
<b>คำอธิบาย:</b> เป็นขั้นตอนการตั้งค่าการแสดงผลให้กลับไปยังค่าก่อนการจำแนก		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้ต้องการการแสดงผลแบบเป็นกลาง คือไม่ใช่ YES/NO		
<b>ขั้นตอนการทำงานปกติ:</b> <ol style="list-style-type: none"> <li>1. กดปุ่มตั้งค่าใหม่</li> <li>2. โปรแกรมตั้งค่าลูกบอลขยับไปตำแหน่งตรงกลาง และหน้าต่าง YES/NO ไม่แสดงอะไร</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก:</b> -		

ตารางที่ 5.18 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลผลลัพธ์ลูกบอลขยับ

<b>ชื่อยูสเคส:</b> แสดงผลลัพธ์ลูกบอลขยับ	<b>ผู้กระทำหลัก:</b> โปรแกรม	<b>รหัส:</b> YNC6-02
<b>คำอธิบาย:</b> เป็นขั้นตอนการแสดงระดับการขยับของลูกบอลไปด้านซ้ายหรือด้านขวา ตามระดับความเชื่อมั่นของการจำแนกประเภท ขยับออกข้าง ๆ มากแสดงว่าการจำแนกนั้นมีความมั่นใจมาก		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้เริ่มดำเนินการจินตนาการ เริ่มจำแนกประเทศตัวอย่างข้อมูล		
<b>ขั้นตอนการทำงานปกติ:</b>		

<ol style="list-style-type: none"> <li>1. เลือกบุคคลที่จะทำการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง</li> <li>2. กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก</li> <li>3. ลูกบอลขยับไปด้านซ้ายแทนคำตอบว่า YES ลูกบอลขยับไปด้านขวาแทนคำตอบว่า NO</li> </ol>
<b>ขั้นตอนการทำงานทางเลือก: -</b>

ตารางที่ 5.19 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงผลลัพธ์ YES/NO

<b>ชื่อยูสเคส:</b> แสดงผลลัพธ์ YES/NO	<b>ผู้กระทำหลัก:</b> โปรแกรม	<b>รหัส:</b> YNC4-03
<b>คำอธิบาย:</b> เป็นขั้นตอนการแสดงผลการทำนาย YES/NO		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้เริ่มต้นการจินตนาการ เริ่มจำแนกประเภทตัวอย่างข้อมูล		
<b>ขั้นตอนการทำงานปกติ:</b>		
<ol style="list-style-type: none"> <li>1. เลือกบุคคลที่จะทำการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง</li> <li>2. กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก</li> <li>3. หน้าต่างแสดงผล YES หรือ NO</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก: -</b>		

ตารางที่ 5.20 คำอธิบายยูสเคสของโปรแกรมเพื่อแสดงคะแนนการจำแนกเทียบกับเวลา

<b>ชื่อยูสเคส:</b> แสดงคะแนนการจำแนกเทียบกับเวลา	<b>ผู้กระทำหลัก:</b> โปรแกรม	<b>รหัส:</b> YNC4-03
<b>คำอธิบาย:</b> เป็นขั้นตอนการแสดงผลระดับคะแนนเทียบกับช่วงเวลาการจินตนาการ		
<b>สิ่งกระตุ้น:</b> เมื่อผู้ใช้เริ่มต้นการจินตนาการ เริ่มจำแนกประเภทตัวอย่างข้อมูล		
<b>ขั้นตอนการทำงานปกติ:</b>		
<ol style="list-style-type: none"> <li>1. เลือกบุคคลที่จะทำการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง</li> <li>2. กดปุ่มเริ่มจินตนาการ/เริ่มจำแนก</li> <li>3. หน้าต่างแสดงกราฟระดับคะแนนเทียบกับเวลาที่จินตนาการ จนถึงหยุดการจินตนาการ</li> </ol>		
<b>ขั้นตอนการทำงานทางเลือก: -</b>		

## 5.2.2 ความต้องการที่ไม่ใช่หน้าที่ (Non-Functional Requirements)

ความต้องการที่ไม่ใช่หน้าที่ หรือความต้องการเชิงคุณภาพของระบบแสดงดังตารางที่ 5.21

ตารางที่ 5.21 รายการความต้องการที่ไม่ใช่หน้าที่ของระบบต้นแบบ


รหัส	หมวดหมู่	คำอธิบาย
NFR-001	สมรรถนะ	การจำแนกประเภท 1 ครั้งใช้เวลาประมวลผลไม่เกิน 3 วินาที



## 5.3 โครงสร้างและการทำงานของระบบ

### 5.3.1 โครงสร้างของระบบต้นแบบ


โครงสร้างของระบบต้นแบบแสดงได้ดังภาพที่ 5.3 โดยระบบมีความสามารถในการทำงานสองส่วนคือส่วนของการฝึกแบบจำลองและส่วนของการจำแนกประเภทสัญญาณคลื่นไฟฟ้าสมอง ค่าต่าง ๆ ในการจำแนกและการฝึกถูกควบคุมด้วยส่วนการควบคุมหรือส่วนการตั้งค่าพารามิเตอร์ ส่วนแสดงผลถูกเชื่อมต่อเพื่อการแสดงสัญญาณ ผลตอบสองเชิงความถี่และผลลัพธ์การจำแนกประเภท



ภาพที่ 5.3 โครงสร้างของระบบต้นแบบ

### 5.3.2 การทำงานของส่วนการจำแนกประเภท

แผนภาพกิจกรรมการการทำงานส่วนการจำแนกประเภทแสดงดังภาพที่ 5.4 โดยโหมดการทำงานมีสองแบบคือ การจำแนกประเภทแบบเลื่อน (sliding window) และการจำแนกประเภทแบบคงที่ (fixed window) โดยเมื่อทำการจำแนกประเภทเสร็จแล้วจึงนำผลลัพธ์ไปแสดงยังหน้าต่างลูกบอลขยับ หน้าต่าง YES/NO และหน้าต่างคะแนนการจำแนกเทียบกับเวลา



ภาพที่ 5.4 แผนภาพแสดงกิจกรรมการการทำงานส่วนการจำแนกประเภท

### 5.3.3 การทำงานของส่วนการฝึกสอนตัวจำแนกประเภท

การทำงานของส่วนการฝึกสอนตัวจำแนกประเภท จะทำการนำข้อมูลฝึกมาสร้างตัวกรองช่องสัญญาณและสร้างตัวจำแนกประเภทที่ชนิดได้แก่ ตัวจำแนกประเภทแอลดีเอแบบเดี่ยว ตัวจำแนกประเภทแอลดีเอแบบวางซ้อน ตัวจำแนกประเภทเอสวีเอ็มแบบเดี่ยว ตัวจำแนกประเภทเอสวีเอ็มแบบวางซ้อน โดยเมื่อได้แบบจำลองทั้งหมดแล้วจึงบันทึกในฐานข้อมูลตามชื่อของบุคคล

## 5.4 การพัฒนาระบบต้นแบบ

### 5.4.1 เครื่องมือสนับสนุนที่ใช้งาน

ในการพัฒนาระบบต้นแบบนั้นมีความจำเป็นต้องอาศัยเครื่องมือต่าง ๆ ทั้งนี้เครื่องมือที่ผู้เขียนใช้นั้นประกอบด้วย ส่วนของฮาร์ดแวร์และส่วนของซอฟต์แวร์ โดยมีรายละเอียดดังต่อไปนี้

#### 1) ฮาร์ดแวร์ที่ใช้


- หน่วยประมวลผล Intel® Core™ i7 Quad-Core ความเร็ว 2.00 กิกะเฮิร์ตซ์ (GHz)
- กราฟฟิก NVIDIA® Geforce 840M
- หน่วยความจำ DDR3 ขนาด 8GB ความเร็วบัส 1333 เมกะเฮิร์ตซ์ (MHz)
- หน้าจอ FHD สูงสุด 15.6 นิ้ว (1920 x 1080) ไรต์สกรีน 16:9 ขนาด (กว้าง x หนา x สูง) 15.11" x 10.43" x 0.98" (384 มม. x 265 มม. x 25.0 มม.) ฮาร์ดดิสก์ไดรฟ์ ขนาด 1 กิกะไบต์ (GByte)

#### 2) ซอฟต์แวร์ที่ใช้

- ระบบปฏิบัติการวินโดวส์ 8.1 แบบ 64 บิต
- โปรแกรม JetBrains PyCharm Community Edition รุ่น 2016.2.3
- ไลบรารี PyQtGraph รุ่น 0.9.10
- โปรแกรมภาษาไพทอน (Python) และไลบรารี numpy, matplotlib, sklearn, cPickle, scipy, MNE, PIL MNE, PIL, emokit

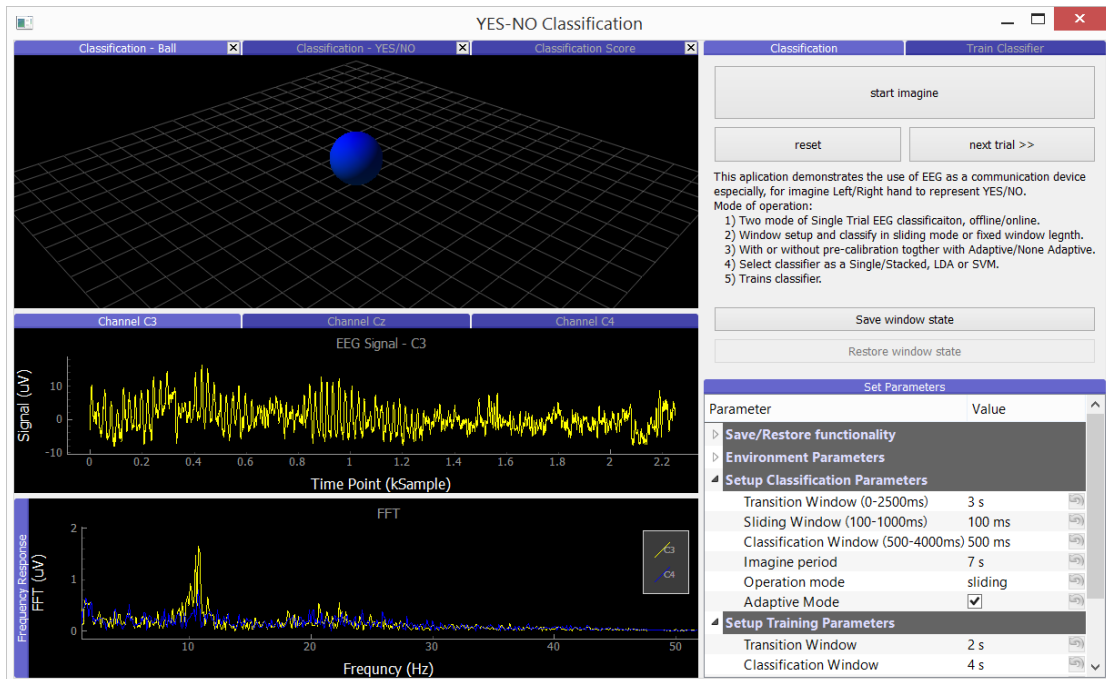
#### 5.4.2 ส่วนต่อประสานผู้ใช้ (User Interface)

การออกแบบหน้าต่างส่วนต่อประสานผู้ใช้แสดงดังภาพที่ 5.5 ซึ่งประกอบไปด้วยหน้าต่าง 6 ส่วนคือ หน้าต่างแสดงผลลัพธ์สามส่วน หน้าต่างแสดงสัญญาณคลื่นไฟฟ้าสมอง หน้าต่างแสดงผลตอบสนองเชิงความถี่ หน้าต่างการจำแนกและการฝึกตัวจำแนก และหน้าต่างที่แสดงค่าต่าง ๆ ของโปรแกรม



ภาพที่ 5.5 การออกแบบหน้าต่างส่วนต่อประสานของระบบต้นแบบ


หน้าต่างของส่วนต่อประสานที่ผู้ใช้ได้ทำการสร้างขึ้นแสดงดังภาพที่ 5.6 ซึ่งบางส่วนนั้น ออกแบบให้ซ้อนทับกันได้เพื่อประหยัดพื้นที่และเพื่อให้ได้มุมมองในการมองหน้าต่างย่อยได้กว้างขึ้น หน้าต่างย่อยประกอบไปด้วยหน้าต่างแสดงผลลัพธ์สามส่วนซึ่งวางซ้อนทับกัน หน้าต่างแสดงสัญญาณคลื่นไฟฟ้าสมองที่วางซ้อนทับกัน หน้าต่างแสดงผลตอบสนองเชิงความถี่ หน้าต่างการจำแนกและการฝึกตัวจำแนกที่วางซ้อนทับกัน และหน้าต่างสุดท้ายเป็นหน้าต่างที่แสดงค่าต่าง ๆ ของโปรแกรม ซึ่งค่าพารามิเตอร์ส่วนใหญ่ถูกกำหนดให้เป็นค่าที่แก้ไขได้ หน้าต่างย่อยทุกหน้าต่างสามารถสลับตำแหน่ง และสามารถแยกออกจากและได้อย่างอิสระ โปรแกรมสามารถจดจำตำแหน่งของหน้าต่างย่อยได้โดยกดบันทึกที่ Save window state และเรียกคืนค่าได้โดยกด Restore window state รายละเอียดเพิ่มเติมเกี่ยวกับหน้าต่างย่อยทั้งหมดมีดังนี้



ภาพที่ 5.6 หน้าต่างส่วนต่อประสานของระบบต้นแบบ

#### 5.4.2.1 ส่วนต่อประสานการจำแนกประเภท

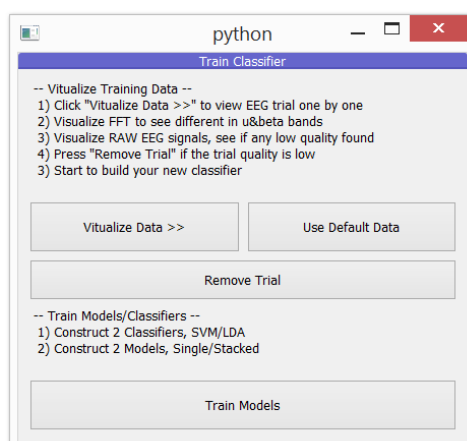
หน้าต่างการจำแนกประเภทแสดงดังภาพที่ 5.7 โดยประกอบไปด้วยปุ่ม “start imagine” เพื่อเริ่มต้นการจำแนกประเภท ปุ่ม “reset” เพื่อให้จอแสดงผลการจำแนกแสดงผลเริ่มต้นเป็นค่ากลางที่ไม่ใช่ “YES/NO” ปุ่ม “next trial >>” เพื่อเลื่อนข้อมูลทดสอบไปยังตัวอย่างถัดไป หลังจากนั้นจะเป็นคำอธิบายโปรแกรมอย่างคร่าว ๆ และตามมาด้วยปุ่ม “Save window state” เพื่อจดจำตำแหน่งการวางหน้าต่างย่อย ปุ่ม “Reset window state” เพื่อเรียกคืนค่าตำแหน่งหน้าต่างย่อย และการวางลักษณะหน้าต่างที่ได้ทำการบันทึกไว้ก่อนหน้า



ภาพที่ 5.7 หน้าต่างย่อยการจำแนกประเภท

#### 5.4.2.2 ส่วนต่อประสานการฝึกสอนตัวจำแนกประเภท

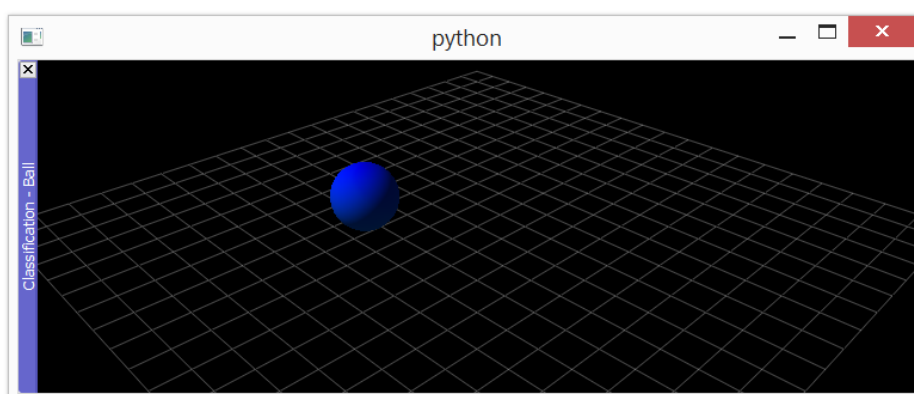
หน้าต่างการฝึกสอนตัวจำแนกประเภทแสดงดังภาพที่ 5.8 โดยประกอบไปด้วยคำอธิบายการใช้งานในหน้าต่างย่อย ปุ่ม “Visualize Data” เพื่อเรียกดูข้อมูลฝึก ปุ่ม “Use Default Data” เพื่อเรียกใช้ข้อมูลฝึกแบบเดิม ปุ่มลบตัวอย่างข้อมูล “Remove Trial” เพื่อนำข้อมูลที่ไม่ได้คุณภาพออกก่อนการฝึกตัวจำแนกประเภท และปุ่มสุดท้ายคือปุ่ม “Train Models” เพื่อฝึกตัวจำแนกประเภททั้ง LDA และ SVM และรวมถึงสองแบบจำลองทั้ง Single Classifier และ Stacked Classifier



ภาพที่ 5.8 หน้าต่างย่อยการฝึกตัวจำแนก

#### 5.4.2.3 ส่วนต่อประสานการแสดงผลลัพธ์

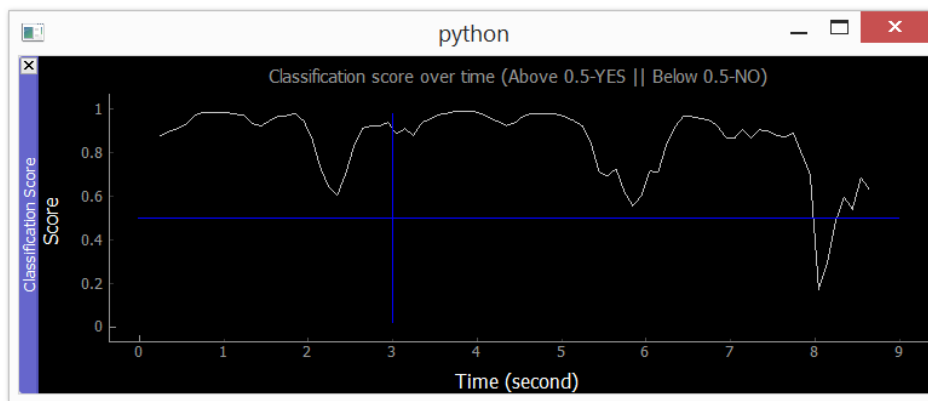
ผู้เขียนออกแบบหน้าต่างแสดงผลลัพธ์ให้แยกออกจากกันเพื่อให้ดูง่าย สะอาดตาและมีมุมมองกว้าง ซึ่งหน้าต่างแสดงผลลัพธ์การจำแนกประเภทมีอยู่สามส่วนประกอบไปด้วย หน้าต่างแสดงผลลูกบอลขยับในภาพที่ 5.9 หน้าต่างแสดงผลลัพธ์ YES/NO ในภาพที่ 5.10 และหน้าต่างแสดงคะแนนการจำแนกเทียบกับเวลาที่จินตนาการในภาพที่ 5.11 หน้าต่างสามส่วนนี้จะวางทับซ้อนกันอยู่ และผู้ใช้สามารถสลับมุมมองเพื่อเลือกหน้าต่างใด ๆ ได้ตามที่ต้องการ



ภาพที่ 5.9 หน้าต่างย่อยแสดงผลลัพธ์บอลขยับ




ภาพที่ 5.10 หน้าต่างย่อยแสดงผลลัพธ์ YES/NO



ภาพที่ 5.11 หน้าต่างย่อยแสดงคะแนนการจำแนกเทียบกับเวลา

#### 5.4.2.4 ส่วนต่อประสานการแสดงผลสัญญาณคลื่นไฟฟ้าสมอง

หน้าต่างแสดงผลสัญญาณคลื่นไฟฟ้าสมองแสดงดังภาพที่ 5.12 โดยผู้เขียนเลือกสัญญาณจากช่อง C3, Cz, C4 มาแสดงผลและทั้งสามหน้าต่างวางซ้อนทับกันโดยสามารถสลับมุมมองได้ตามที่ผู้ใช้งานต้องการ




ภาพที่ 5.12 หน้าต่างย่อยแสดงผลสัญญาณคลื่นไฟฟ้าสมอง

#### 5.4.2.5 ส่วนต่อประสานการแสดงผลตอบสนองเชิงความถี่

ผู้เขียนออกแบบให้มีการนำผลตอบสนองเชิงความถี่มาแสดงดังภาพที่ 5.13 เพื่อที่จะสามารถใช้เป็นทางเลือกในการวิเคราะห์หว่าบุคคลที่เรากำลังทำการจำแนกประเภทนั้นมีความตั้งใจต่อการ

จินตนาการมากเพียงใด และสามารถทำตามโปรโตคอลที่ได้ถูกกำหนดไว้ได้มากน้อยขนาดไหน ในทางทฤษฎีนั้นสัญญาณความถี่ย่าน 8–13 เฮิร์ตซ์ ซึ่งก็คือ mu rhythms และความถี่ 16–25 เฮิร์ตซ์ หรือ beta rhythms [40] มีความสัมพันธ์กับกิจกรรมทางสมองของบุคคลมากที่สุด ซึ่งรวมไปถึงการจินตนาการการเคลื่อนไหวด้วยเช่นกัน จะเห็นว่าความแตกต่างของสัญญาณที่ช่อง C3, C4 ที่บริเวณ 10 เฮิร์ตซ์ บ่งบอกถึงความสามารถของบุคคลในการจำแนกประเภทได้ การที่สัญญาณคลื่นไฟฟ้าสมองเกิดการ de-synchronize ที่ C4 นั้น (เส้นสีน้ำเงินในภาพที่ 5.13 ซึ่งเกิดจากสัญญาณบริเวณสมองด้านขวา) บ่งบอกอย่างคร่าว ๆ ว่าบุคคลนี้กำลังจินตนาการขยับมือซ้ายหรือจินตนาการ YES นั้นเอง

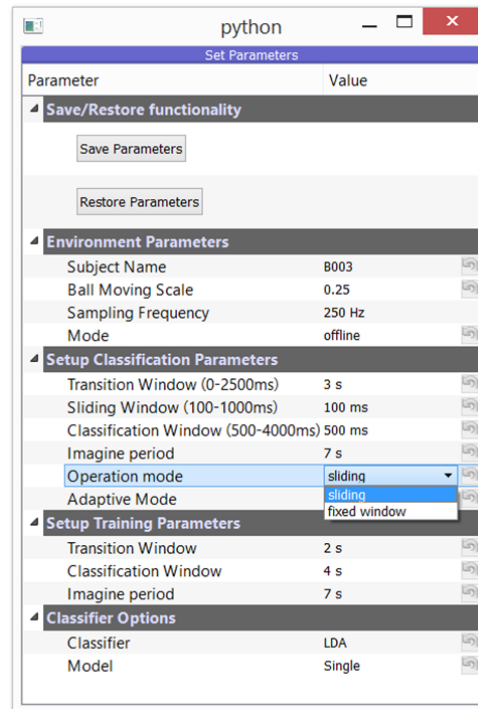


ภาพที่ 5.13 หน้าต่างย่อยแสดงผลตอบสนองเชิงความถี่

#### 5.4.2.6 หน้าต่างการตั้งค่าพารามิเตอร์

หน้าต่างการตั้งค่าพารามิเตอร์แสดงดังภาพที่ 5.14 ประกอบไปด้วยการตั้งค่า 4 ส่วนและส่วนบันทึกและคืนค่า โดยค่าต่าง ๆ เป็นค่าที่สามารถแก้ไขได้เลย โดยเมื่อแก้ไขแล้วจะส่งผลให้ค่านั้นถูกนำไปใช้ในโปรแกรมทันที ค่าพารามิเตอร์บางตัวถูกตั้งค่าให้แก้ไขไม่ได้เช่น Sampling Frequency โปรแกรมสามารถบันทึกค่าที่ตั้งไว้โดยกดที่ปุ่ม “Save Parameters” และเรียกคืนค่าครั้งล่าสุดได้ถูกบันทึกโดยกดที่ปุ่ม “Restore Parameters”






ภาพที่ 5.14 หน้าต่างย่อยแสดงการตั้งค่าพารามิเตอร์

## 5.5 การใช้งานระบบ (System Deployment)

การนำระบบต้นแบบไปใช้งานแสดงดังภาพที่ 5.15 โดยในเบื้องต้น จะต้องมีการเตรียมข้อมูลฝึก ข้อมูลทดสอบ รวมถึงตัวจำแนกประเภทและตัวกรองช่องสัญญาณไว้ในฐานข้อมูลก่อนการใช้งาน



ภาพที่ 5.15 แผนภาพการใช้งานระบบ

## บทที่ 6

### สรุปผลการวิจัยและข้อเสนอแนะ

#### 6.1 สรุปผลการวิจัย

งานวิจัยนี้มีจุดประสงค์เพื่อพัฒนาวิธีการจำแนกประเภทแบบสองค่าตอบหรือสองคลาส เพื่อใช้ในการสื่อสารแทนคำพูดว่าใช่หรือไม่ใช่โดยใช้สัญญาณคลื่นไฟฟ้าสมองเป็นตัวกลาง จุดประสงค์หลักเพื่อนำวิธีการดังกล่าวนี้ไปใช้กับผู้ป่วยที่มีความพิการและมีปัญหาในการสื่อสารด้วยวิธีการปกติ งานวิจัยใช้สัญญาณคลื่นไฟฟ้าสมองบริเวณกลางศีรษะซึ่งมีความพัวพันกับการจินตนาการการเคลื่อนไหวมากที่สุด ทั้งนี้วิธีการที่นำเสนอมุ่งแก้ปัญหาความไม่คงที่ของสัญญาณซึ่งเป็นปัญหาสำคัญในการนำแบบจำลองที่ออกแบบไปใช้ในสภาพแวดล้อมจริง วิธีการที่นำเสนอสามารถลดผลกระทบของความไม่คงที่ของสัญญาณทั้งบนข้อมูลฝึกที่ถูกเก็บจากหลายช่วงเวลา และความไม่คงที่ของข้อมูลทดสอบที่อยู่ต่างช่วงเวลากับข้อมูลฝึก วิธีการที่นำเสนอพัฒนาขึ้นจากตัวจำแนกประเภทแบบอาร์แอลดีเอ (สำหรับแบบจำลองที่ขึ้นกับบุคคล) และตัวจำแนกประเภทแบบเอสวีเอ็ม (สำหรับแบบจำลองที่ไม่ขึ้นกับบุคคล) โดยทำการวางซ้อนตัวจำแนกประเภทย่อยซึ่งถูกฝึกสอนโดยข้อมูลฝึกที่ถูกตัดแบ่งด้วยวิธีการตรวจจับการเปลี่ยนแปลงเพื่อตัดแบ่งกลุ่มข้อมูลที่แตกต่างกันออกจากกัน วิธีการที่นำเสนอถูกประเมินบนข้อมูลการทดลองจากกลุ่มวิจัย BCI Competition ชุดข้อมูล 2b และเปรียบเทียบกับวิธีการดังต่อไปนี้

- 1) วิธีการจำแนกประเภทแบบคงที่
- 2) วิธีการจำแนกประเภทแบบปรับตัวได้พลูมิน โดยพัฒนาขึ้นจากตัวจำแนกประเภทหลาย ๆ แบบ
- 3) วิธีการที่นิยมใช้ในปัจจุบัน ได้แก่วิธีการ PMean LDA วิธีการ CSEM วิธีการ ACSP

ซึ่งผลการทดลองของแบบจำลองที่ขึ้นกับบุคคลพบว่าวิธีการที่นำเสนอ ให้ความแม่นยำเฉลี่ยทุกบุคคลดีกว่าวิธีการที่ดีที่สุดที่ถูกนำมาเปรียบเทียบประมาณ 3% และพบว่าค่าเฉลี่ยความแม่นยำของวิธีการที่นำเสนอดีกว่าวิธีการที่ถูกนำมาเปรียบเทียบทุกวิธีการอย่างมีนัยสำคัญ นอกเหนือจากนั้นงานวิจัยนี้ยังนำเสนอวิธีการสำหรับแบบจำลองที่ไม่ขึ้นกับบุคคล โดยใช้ตัวจำแนกประเภทย่อยแบบเอสวีเอ็มประกอบขึ้นเป็นตัวจำแนกประเภทแบบวางซ้อน ผลการทดลองพบว่าวิธีการที่เสนอนั้นให้ความแม่นยำเทียบเท่าแบบจำลองที่ขึ้นกับบุคคล และวิธีการที่เสนอนั้นมีความเหมาะสมอย่างยิ่งที่จะนำไปใช้กับผู้ป่วย เพราะใช้ข้อฝึกของผู้ป่วยน้อยมากในการฝึกและประเมินตัวจำแนกประเภท

## 6.2 ข้อเสนอแนะ

1) วิธีการที่นำเสนอ นั้นเป็นแบบตัวจำแนกประเภทแบบวางซ้อน ซึ่งจะให้ผลลัพธ์ที่ดีขึ้นอย่างเห็นได้ชัดหากข้อมูลฝึกมีจำนวนมากเพียงพอ

2) วิธีการที่นำเสนอ ต้องการการประเมินค่าขีดแบ่งส่วนแบ่งน้อยที่สุดที่เหมาะสมต่อแต่ละบุคคล ซึ่งต้องอาศัยข้อมูลทดสอบเริ่มต้นและการปรับแต่งเพื่อหาค่าที่เหมาะสมที่สุด

3) วิธีการที่นำเสนอแบบไม่ขึ้นกับบุคคลนั้น นำตัวกรองช่องสัญญาณของบุคคลอื่นมาใช้สกัดคุณลักษณะของบุคคลที่ใช้ทดสอบ ซึ่งในบางคู่ของข้อมูลฝึกอาจจะสร้างตัวกรองช่องสัญญาณที่ไม่ดีต่อข้อมูลทดสอบ หรือทำให้เกิดความสามารถในการจำแนกของข้อมูลทดสอบลดลง ส่งผลให้ค่าความน่าจะเป็นภายหลังของคลาสที่ถูกทำนายมีค่าลดลงด้วย อย่างไรก็ตามภายใต้ตัวจำแนกประเภทแบบวางซ้อนที่นำเสนอ นั้นจะทำการรวมค่าความน่าจะเป็นภายหลังโดยคำนึงถึงความแตกต่างของค่าความน่าจะเป็นภายหลังระหว่างคลาส ทำให้ผลกระทบที่กล่าวมาจากรุ่นของข้อมูลฝึกและข้อมูลทดสอบที่ไม่เข้าคู่ นั้นส่งผลต่อความแม่นยำน้อยมาก และกล่าวได้ว่าหากเรามีข้อมูลฝึกของบุคคลอื่น ๆ จำนวนมาก ก็จะทำให้ความแม่นยำเพิ่มขึ้นด้วยสืบเนื่องมาจากความเป็นไปได้ที่จะค้นพบคู่ของข้อมูลฝึกและข้อมูลทดสอบที่มีความคล้ายคลึงของสัญญาณคลื่นไฟฟ้าสมองนั้นเพิ่มมากขึ้น

## 6.3 งานวิจัยในอนาคต

ผู้เขียนได้ทำการพัฒนาระบบต้นแบบโดยใช้วิธีการที่นำเสนอซึ่งมีรายละเอียดเป็นไปตามบทที่ 5 ระบบต้นแบบนี้ถูกออกแบบมาเพื่อรองรับการทำงานทั้งระบบแบบ offline และ online โดยระบบออนไลน์คือระบบที่สามารถเชื่อมต่อกับเครื่องวัดคลื่นไฟฟ้าสมองและทำการเก็บข้อมูล หลังจากนั้นสามารถทำการฝึกสอนตัวจำแนกประเภทที่เกิดจากข้อมูลที่เก็บ ก่อนการนำไปใช้งานจริงซึ่งก็คือการจำแนกประเภทขณะสวมเครื่องวัดคลื่นไฟฟ้าสมองนั่นเอง ผู้เขียนวางแผนที่จะพัฒนาระบบที่เหลือดังต่อไปนี้

- 1) ระบบจัดการคลังข้อมูลคลื่นไฟฟ้าสมอง
- 2) ระบบการจัดการบุคคล
- 3) ระบบการเก็บข้อมูลคลื่นไฟฟ้าสมองเพื่อการจำแนกประเภทแบบออนไลน์

ทั้งนี้เพื่อให้ระบบที่พัฒนาขึ้นสามารถนำไปใช้ได้จริงกับผู้ป่วยได้อย่างมีประสิทธิภาพ และหวังเป็นอย่างยิ่งว่าสิ่งที่พัฒนาขึ้นมาจะช่วยทำให้เป้าประสงค์ของผู้เขียนบรรลุผลได้ไม่มากนัก ซึ่งนั่นก็คือการนำสิ่งที่พัฒนาไปใช้กับผู้ป่วยได้นั่นเอง

## รายการอ้างอิง

- [1] A. Yuksel and T. Olmez, "A Neural Network-Based Optimal Spatial Filter Design Method for Motor Imagery Classification," *PLoS ONE*, vol. 10, p. e0125039, 2015.
- [2] N. Tomida, T. Tanaka, S. Ono, M. Yamagishi, and H. Higashi, "Active Data Selection for Motor Imagery EEG Classification," *Biomedical Engineering, IEEE Transactions on*, vol. 62, pp. 458-467, 2015.
- [3] W. Wu, Z. Chen, X. Gao, Y. Li, E. N. Brown, and S. Gao, "Probabilistic Common Spatial Patterns for Multichannel EEG Analysis," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 37, pp. 639-653, 2015.
- [4] W.-Y. Hsu and Y.-P. Hu, "Artificial Bee Colony Algorithm for Single-Trial Electroencephalogram Analysis," *Clinical EEG and Neuroscience*, vol. 46, pp. 119-125, 2015.
- [5] X. Yong and C. Menon, "EEG Classification of Different Imaginary Movements within the Same Limb," *PLoS ONE*, vol. 10, p. e0121896, 2015.
- [6] T. Nguyen, A. Khosravi, D. Creighton, and S. Nahavandi, "EEG signal classification for BCI applications by wavelets and interval type-2 fuzzy logic systems," *Expert Systems with Applications*, vol. 42, pp. 4370-4380, 2015.
- [7] Y. CAI, L. ZHANG, W. JIAN, and C. LI, "Hybrid SVM/HMM Classification Method for Motor Imagery Based BCI," *Journal of Computational Information Systems*, vol. 11, pp. 1259-1267, 2015.
- [8] W.-Y. Hsu, "Motor Imagery EEG Discrimination Using the Correlation of Wavelet Features," *Clinical EEG and Neuroscience*, vol. 46, pp. 94-99, 2015.
- [9] C.-Y. Kee, S. G. Ponnambalam, and C.-K. Loo, "Multi-objective genetic algorithm as channel selection method for P300 and motor imagery data set," *Neurocomputing*, vol. 161, pp. 120-131, 2015.
- [10] N. Lu and T. Yin, "Motor imagery classification via combinatory decomposition of ERP and ERSP using sparse nonnegative matrix factorization," *Journal of Neuroscience Methods*, vol. 249, pp. 41-49, 2015.

- [11] S. Tiamkao, "Locked-in syndrome:LIS [Online]," *Available from:* <http://haamor.com> [December 1, 2016], 2012.
- [12] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *Rehabilitation Engineering, IEEE Transactions on*, vol. 8, pp. 441-446, 2000.
- [13] J. Müller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, "Designing optimal spatial filters for single-trial EEG classification in a movement task," *Clinical Neurophysiology*, vol. 110, pp. 787-798, 1999.
- [14] C. Guger, G. Ramoser H Fau - Pfurtscheller, and G. Pfurtscheller, "Real-time EEG analysis with subject-specific spatial patterns for a brain-computer interface (BCI)," 20010131 DCOM- 20010405 2000.
- [15] S. Tiamkao, "Electroencephalography:EEG [Online]," *Available from:* <http://haamor.com> [December 1, 2016], 2012.
- [16] NeuroSky, "Instruction Manual, NeuroSky MindSet [Online]," *Available from:* [http://download.neurosky.com/support\\_page\\_files/MindSet/docs/mindset\\_instruction\\_manual.pdf](http://download.neurosky.com/support_page_files/MindSet/docs/mindset_instruction_manual.pdf) [December 1, 2016], 2009.
- [17] E. Niedermeyer, "Alpha rhythms as physiological and abnormal phenomena," *International Journal of Psychophysiology*, vol. 26, pp. 31-49, 1997.
- [18] N. Sheehy, "Electroencephalography: Basic Principles, Clinical Applications and Related Fields," *Journal of Neurology, Neurosurgery, and Psychiatry*, vol. 47, pp. 654-654, 1984.
- [19] J. Baumeister, T. Barthel, K. R. Geiss, and M. Weiss, "Influence of phosphatidylserine on cognitive performance and cortical activity after induced stress," *Nutritional Neuroscience*, vol. 11, pp. 103-110, 2008/06/01 2008.
- [20] S. N. Baker, "Oscillatory interactions between sensorimotor cortex and the periphery," *Current Opinion in Neurobiology*, vol. 17, pp. 649-655, 2007.
- [21] E. Lalo, T. Gilbertson, L. Doyle, V. D. Lazzaro, B. Cioni, and P. Brown, "Phasic increases in cortical beta activity are associated with alterations in sensory processing in the human," *Experimental Brain Research*, vol. 177, pp. 137-145, 2007.

- [22] Y. Zhang, Y. Chen, S. L. Bressler, and M. Ding, "Response preparation and inhibition: The role of the cortical sensorimotor beta rhythm," *Neuroscience*, vol. 156, pp. 238-246, 2008.
- [23] Mental Health Daily, "5 Types Of Brain Waves Frequencies: Gamma, Beta, Alpha, Theta, Delta [Online]," Available from: <http://mentalhealthdaily.com/2014/04/15/5-types-of-brain-waves-frequencies-gamma-beta-alpha-theta-delta> [December 1, 2016], 2014.
- [24] S.-Y. Cheng and H.-T. Hsu, "Mental Fatigue Measurement Using EEG [Online]," Available from: <http://www.intechopen.com/books/risk-management-trends/mental-fatigue-measurement-using-eeeg> [November 1, 2015], 2011.
- [25] K. K. Ang, C. Guan, K. S. G. Chua, B. T. Ang, C. W. K. Kuah, C. Wang, *et al.*, "A Large Clinical Study on the Ability of Stroke Patients to Use an EEG-Based Motor Imagery Brain-Computer Interface," *Clinical EEG and Neuroscience*, vol. 42, pp. 253-258, 2011.
- [26] Z. J. Koles, "The quantitative extraction and topographic mapping of the abnormal components in the clinical EEG," *Electroencephalography and Clinical Neurophysiology*, vol. 79, pp. 440-447, 1991.
- [27] K. K. Ang, Z. Y. Chin, C. Wang, C. Guan, and H. Zhang, "Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b," *Frontiers in Neuroscience*, vol. 6, p. 39, 2012.
- [28] "Wavelet Transform and Feature Extraction [Online]," Available from: [http://archive.lib.cmu.ac.th/full/T/2550/enel1050stt\\_ch3.pdf](http://archive.lib.cmu.ac.th/full/T/2550/enel1050stt_ch3.pdf) [November 1, 2015], 2007.
- [29] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis," *Seizure - European Journal of Epilepsy*, vol. 26, pp. 56-64, 2015.
- [30] M. Lutter, "Wavelet Based Features [Online]," Available from: <http://recognize-speech.com/feature-extraction/wavelet-based-features> [December 1, 2016], 2015.
- [31] A. Bifet, "Adaptive Learning and Mining for Data Streams and Frequent Patterns," *Doctoral Thesis*, 2009.

- [32] G. Ditzler, M. Roveri, C. Alippi, and R. Polikar, "Learning in Nonstationary Environments - a Survey," *Accepted for publication in IEEE Computational Intelligence Magazine*, 2015.
- [33] C. Vidaurre, M. Kawanabe, B. von, x, P. nau, B. Blankertz, *et al.*, "Toward Unsupervised Adaptation of LDA for Brain–Computer Interfaces," *Biomedical Engineering, IEEE Transactions on*, vol. 58, pp. 587-597, 2011.
- [34] M. Sugiyama, M. Yamada, and M. C. du Plessis, "Learning under nonstationarity: covariate shift and class-balance change," *Wiley Interdisciplinary Reviews: Computational Statistics*, vol. 5, pp. 465-477, 2013.
- [35] P. Sinno Jialin and Y. Qiang, "A Survey on Transfer Learning," *Knowledge and Data Engineering, IEEE Transactions on*, vol. 22, pp. 1345-1359, 2010.
- [36] J. Han and M. Kamber, "Data Mining: Concepts and Techniques," *Elsevier Inc.*, 2006.
- [37] "Artificial Neural Network:ANN [Online]," *Available from: <http://202.44.34.134/teacher/FileDL/phayung202255212105.pdf>* [December 1, 2016], 2015.
- [38] "Perceptron Neural Networks [Online]," *Available from: <http://www.mathworks.com/help/nnet/ug/perceptron-neural-networks.html>* [December 1, 2016], 2015.
- [39] W. Samek, "ON ROBUSTS PATIAL FILTERING OF EEG INNONSTATIONARY ENVIRONMENTS," *Doctoral Thesis*, 2014.
- [40] S. Ge, R. Wang, and D. Yu, "Classification of Four-Class Motor Imagery Employing Single-Channel Electroencephalography," *PLoS ONE*, vol. 9, p. e98019, 2014.
- [41] H. Bashashati, R. K. Ward, G. E. Birch, and A. Bashashati, "Comparing Different Classifiers in Sensory Motor Brain Computer Interfaces," *PLoS ONE*, vol. 10, p. e0129435, 2015.
- [42] L. Yan, H. Kambara, Y. Koike, and M. Sugiyama, "Application of Covariate Shift Adaptation Techniques in Brain–Computer Interfaces," *Biomedical Engineering, IEEE Transactions on*, vol. 57, pp. 1318-1324, 2010.

- [43] B. Schölkopf, J. Platt, and T. Hofmann, "Adaptive Spatial Filters with predefined Region of Interest for EEG based Brain-Computer-Interfaces," in *Advances in Neural Information Processing Systems 19: Proceedings of the 2006 Conference*, ed: MIT Press, 2007, pp. 537-544.
- [44] X. Song and S.-C. Yoon, "Improving brain-computer interface classification using adaptive common spatial patterns," *Computers in Biology and Medicine*, vol. 61, pp. 150-160, 2015.
- [45] L. F. Nicolas-Alonso, R. Corralejo, J. Gomez-Pilar, D. Alvarez, and R. Hornero, "Adaptive Stacked Generalization for Multiclass Motor Imagery-Based Brain Computer Interfaces," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 23, pp. 702-712, 2015.
- [46] L. F. Nicolas-Alonso, R. Corralejo, J. Gomez-Pilar, D. Álvarez, and R. Hornero, "Adaptive semi-supervised classification to reduce intersession non-stationarity in multiclass motor imagery-based brain-computer interfaces," *Neurocomputing*, vol. 159, pp. 186-196, 2015.
- [47] A. Llera, V. mez, and H. Kappen, "Adaptive Classification on Brain-Computer Interfaces Using Reinforcement Signals," *Neural Computation*, vol. 24, pp. 2900-2923, 2012.
- [48] A. Llera, V. mez, and H. Kappen, "Adaptive Multiclass Classification for Brain Computer Interfaces," *Neural Computation*, vol. 26, pp. 1108-1127, 2014.
- [49] H. Kang and S. Choi, "Bayesian common spatial patterns for multi-subject EEG classification," *Neural Networks*, vol. 57, pp. 39-50, 2014.
- [50] M. Arvaneh, C. Guan, K. Ang, and C. Quek, "EEG Data Space Adaptation to Reduce Intersession Nonstationarity in Brain-Computer Interface," *Neural Computation*, vol. 25, pp. 2146-2171, 2013.
- [51] L. Xinyang, G. Cuntai, Z. Haihong, A. Kai Keng, and O. Sim Heng, "Adaptation of motor imagery EEG classification model based on tensor decomposition," *Journal of Neural Engineering*, vol. 11, p. 056020, 2014.
- [52] R. Killick, P. Fearnhead, and I. A. Eckley, "Optimal Detection of Changepoints With a Linear Computational Cost," *Journal of the American Statistical Association*, vol. 107, pp. 1590-1598, 2012.



- [53] M. Lavielle, "Using penalized contrasts for the change-point problem," *Signal Processing*, vol. 85, pp. 1501-1510, 2005.
- [54] B. Jackson, J. D. Scargle, D. Barnes, S. Arabhi, A. Alt, P. Gioumouisis, *et al.*, "An algorithm for optimal partitioning of data on an interval," *IEEE Signal Processing Letters*, vol. 12, pp. 105-108, 2005.
- [55] Y. Guo, T. Hastie, and R. Tibshirani, "Regularized linear discriminant analysis and its application in microarrays," *Biostatistics*, vol. 8, pp. 86-100, January 1, 2007 2007.
- [56] T. Hastie, R. Tibshirani, and J. Friedman, "The Elements of Statistical Learning, Data Mining, Inference, and Prediction (Second Edition)," *Springer*, 2008.
- [57] J. Platt, "Advances in Large Margin Classifiers " *The MIT Press*, pp. 61-74, 2000.
- [58] M. Tangermann, K.-R. Müller, A. Aertsen, N. Birbaumer, C. Braun, C. Brunner, *et al.*, "Review of the BCI Competition IV," *Frontiers in Neuroscience*, vol. 6, p. 55, 2012.
- [59] E. Pacharawongsakda, "Model Evaluation [Online]," *Available from: <http://dataminingtrend.com/2014/data-mining-techniques/cross-validation> [November 1, 2016]*, 2014.



## ภาคผนวก ก. รายละเอียดชุดข้อมูล

รายละเอียดชุดข้อมูล BCI Competition IV Data set 2b ซึ่งได้ถูกจัดเก็บในปี 2008 โดย Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology

### BCI Competition 2008 – Graz data set B

R. Leeb<sup>1</sup>, C. Brunner<sup>1</sup>, G. R. Müller-Putz<sup>1</sup>, A. Schlögl<sup>2</sup>, and G. Pfurtscheller<sup>1</sup>

<sup>1</sup>Institute for Knowledge Discovery, Graz University of Technology, Austria

<sup>2</sup>Institute for Human-Computer Interfaces, Graz University of Technology, Austria

## Experimental paradigm

This data set consists of EEG data from 9 subjects of a study published in [1]. The subjects were right-handed, had normal or corrected-to-normal vision and were paid for participating in the experiments. All volunteers were sitting in an armchair, watching a flat screen monitor placed approximately 1 m away at eye level. For each subject 5 sessions are provided, whereby the first two sessions contain training data without feedback (screening), and the last three sessions were recorded with feedback.

Each session consists of several runs, illustrated in Figure 1. At the beginning of each session, a recording of approximately 5 minutes was performed to estimate the EOG influence. The recording was divided into 3 blocks: (1) two minutes with eyes open (looking at a fixation cross on the screen), (2) one minute with eyes closed, and (3) one minute with eye movements. The artifact block was divided into four sections (15 seconds artifacts with 5 seconds resting in between) and the subjects were instructed with a text on the monitor to perform either eye blinking, rolling, up-down or left-right movements. At the beginning and at the end of each task a low and high warning tone were presented, respectively. Note that due to technical problems no EOG block is available in session B0102T and B0504E, (see Table 1 for a list of all subjects)




Figure 1: Timing scheme of one session (for screening and feedback sessions).




Figure 2: Electrode montage of the three monopolar EOG channels.

## Data recording

Three bipolar recordings (C3, Cz, and C4) were recorded with a sampling frequency of 250 Hz. The recordings had a dynamic range of  $\pm 100 \mu\text{V}$  for the screening and  $\pm 50 \mu\text{V}$  for the feedback sessions. They were bandpass-filtered between 0.5 Hz and 100 Hz, and a notch filter at 50 Hz was enabled. The placement of the three bipolar recordings (large or small distances, more anterior or posterior) were slightly different for each subject (for more details see [1]). The electrode position Fz served as EEG ground.

In addition to the EEG channels, the electrooculogram (EOG) was recorded with three monopolar electrodes (see Figure 2, left mastoid serving as reference) using the same amplifier settings, but with a dynamic range of  $\pm 1 \text{ mV}$ . The EOG channels are provided for the subsequent application of artifact processing methods [2] and must not be used for classification.

The cue-based screening paradigm (see Figure 3a) consisted of two classes, namely the motor imagery (MI) of left hand (class 1) and right hand (class 2). Each subject participated in two screening sessions without feedback recorded on two different days within two weeks. Each session consisted of six runs with ten trials each and two classes of imagery. This resulted in 20 trials per run and 120 trials per session. Data of 120 repetitions of each MI class were available for each person in total. Prior to the first motor imagery training the subject executed and imagined different movements for each body part and selected the one which they could imagine best (e.g., squeezing a ball or pulling a brake).

Each trial started with a fixation cross and an additional short acoustic warning tone (1 kHz, 70 ms). Some seconds later a visual cue (an arrow pointing either to the left or right, according to the requested class) was presented for 1.25 seconds. Afterwards the subjects had to imagine the corresponding hand movement over a period of 4 seconds. Each trial was followed by a short break of at least 1.5 seconds. A randomized time of up to 1 second was added to the break to avoid adaptation.

For the three online feedback sessions four runs with smiley feedback were recorded (see Figure 3b), whereby each run consisted of twenty trials for each type of motor imagery. At the beginning of each trial (second 0) the




Figure 3: Timing scheme of the paradigm. (a) The first two sessions (01T, 02T) contain training data without feedback, and (b) the last three sessions (03T, 04E, 05E) with smiley feedback.

feedback (a gray smiley) was centered on the screen. At second 2, a short warning beep (1 kHz, 70 ms) was given. The cue was presented from second 3 to 7.5. Depending on the cue, the subjects were required to move the smiley towards the left or right side by imagining left or right hand movements, respectively. During the feedback period the smiley changed to green when moved in the correct direction, otherwise it became red. The distance of the smiley from the origin was set according to the integrated classification output over the past two seconds (more details see [1]). Furthermore, the classifier output was also mapped to the curvature of the mouth causing the smiley to be happy (corners of the mouth upwards) or sad (corners of the mouth downwards). At second 7.5 the screen went blank and a random interval between 1.0 and 2.0 seconds was added to the trial. The subject was instructed to keep the smiley on the correct side for as long as possible and therefore to perform the MI as long as possible.

## Data file description

All data sets are stored in the General Data Format for biomedical signals (GDF), one file per subject and session. However, only the first three sessions contain the class labels for all trials, whereas the remaining two sessions are used to test the classifier and hence to evaluate the performance. All files are listed in Table 1. The GDF files can be loaded using the open-source toolbox BioSig, available for free at <http://biosig.sourceforge.net/>. There are

ID	Training	Evaluation
1	B0101T, B0102T, B0103T	B0104E, B0105E
2	B0201T, B0202T, B0203T	<del>B0204E, B0205E</del>
3	B0301T, B0302T, B0303T	<del>B0304E, B0305E</del>
4	B0401T, B0402T, B0403T	<del>B0404E, B0405E</del>
5	B0501T, B0502T, B0503T	<del>B0504E, B0505E</del>
6	B0601T, B0602T, B0603T	<del>B0604E, B0605E</del>
7	B0701T, B0702T, B0703T	<del>B0704E, B0705E</del>
8	B0801T, B0802T, B0803T	<del>B0804E, B0805E</del>
9	B0901T, B0902T, B0903T	<del>B0904E, B0905E</del>

Table 1: List of all files contained in the data set, the striked out evaluation data sets will be provided after the deadline of the competition. The first two sessions (...01T, ...02T) contain training data without feedback, and the last three sessions (...03T, ...04E, ...05E) with smiley feedback. Note: Due to technical problems no recording for EOG estimation (eyes open, closed, eye movements) exists in session B0102T and B0504E.

versions for Octave<sup>1</sup>/MATLAB<sup>2</sup> as well as a library for C/C++.

A GDF file can be loaded with the BioSig toolbox with the following command in Octave/MATLAB (for C/C++, the corresponding function HDRTYPE\* `sopen` and `size_t sread` must be called):

```
[s, h] = sload('B0101T.gdf');
```

Note that the runs are separated by 100 missing values, which are encoded as not-a-numbers (NaN) by default. Alternatively, this behavior can be turned off and the missing values will be encoded as the negative maximum values as stored in the file with:

```
[s, h] = sload('A01T.gdf', 0, 'OVERFLOWDETECTION:OFF');
```

The workspace will then contain two variables, namely the signals `s` and a header structure `h`. The signal variable contains 6 channels (the first 3 are EEG and the last 3 are EOG signals). The header structure contains event information that describes the structure of the data over time. The following fields provide important information for the evaluation of this data set:

```
h.EVENT.TYP
h.EVENT.POS
h.EVENT.DUR
```

<sup>1</sup><http://www.gnu.org/software/octave/>

<sup>2</sup>The MathWorks, Inc., Natick, MA, USA

Event type	Description
276	0x0114 Idling EEG (eyes open)
277	0x0115 Idling EEG (eyes closed)
768	0x0300 Start of a trial
769	0x0301 Cue onset left (class 1)
770	0x0302 Cue onset right (class 2)
781	0x030D BCI feedback (continuous)
783	0x030F Cue unknown
1023	0x03FF Rejected trial
1077	0x0435 Horizontal eye movement
1078	0x0436 Vertical eye movement
1079	0x0437 Eye rotation
1081	0x0439 Eye blinks
32766	0x7FFE Start of a new run

Table 2: List of event types (the first column contains decimal values and the second hexadecimal values).

The position of an event in samples is contained in `h.EVENT.POS`. The corresponding type can be found in `h.EVENT.TYP`, and the duration of that particular event is stored in `h.EVENT.DUR`. The types used in this data set are described in Table 2 (hexadecimal values, decimal notation in parentheses). Note that the class labels (i. e., 1 and 2, corresponding to event types 769 and 770) are only provided for the training data and not for the testing data.

The trials containing artifacts as scored by experts are marked as events with the type 1023. In addition, `h.ArtifactSelection` contains a list of all trials, with 0 corresponding to a clean trial and 1 corresponding to a trial containing an artifact.

In order to view the GDF files, the viewing and scoring application SigViewer v0.2 or higher (part of BioSig) can be used.

## Evaluation

Participants should provide a continuous classification output for each sample in the form of classlabels (1, 2), including labeled trials and trials marked as artifact. A confusion matrix will then be built from all artifact-free trials for each time point. From these confusion matrices, the time course of the accuracy as well as the kappa coefficient will be obtained [3]. The algorithm used for this evaluation will be provided in BioSig. The winner is the algorithm with the largest kappa value `X.KAP00`.

Due to the fact that the evaluation data sets will not be distributed until the end of the competition, the submissions must be programs that accept

### ประวัติผู้เขียนวิทยานิพนธ์

นายสิทธิพงษ์ หมู่ทอง เกิดวันที่ 30 เดือนพฤษภาคม พ.ศ. 2529 สำเร็จการศึกษาระดับประกาศนียบัตรวิชาชีพสาขาวิชาช่างอิเล็กทรอนิกส์จากวิทยาลัย เทคนิคสุรินทร์ จากนั้นเข้าศึกษาต่อที่คณะวิศวกรรมศาสตร์มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ในปีการศึกษา 2548 และในปีการศึกษา 2552 จึงสำเร็จการศึกษาปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมไฟฟ้า และเข้าทำงานที่ บริษัท เวสเทิร์น ดิจิตอล (ประเทศไทย) จำกัด เป็นเวลา 5 ปี จึงได้เข้าศึกษาในหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิศวกรรมซอฟต์แวร์ ที่ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ปีการศึกษา 2557

