

การวิเคราะห์สัญญาณคลื่นไฟฟ้าสมองสำหรับการเขียนในจินตนาการ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมโทรคมนาคม
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2564

ANALYSIS OF ELECTROENCEPHALOGRAM SIGNALS FOR WRITING
IMAGINATION



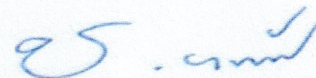
TALIT JUMPHOO

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Doctor of Philosophy in Telecommunication
Suranaree University of Technology
Academic Year 2021

การวิเคราะห์สัญญาณคลื่นไฟฟ้าสมองสำหรับการเขียนในจินตนาการ

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักศึกษานี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาตรีบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร.ชาญชัย ไทยเยี่ยม)

ประธานกรรมการ



(รศ. ดร.พีระพงษ์ อุฑารสกุล)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



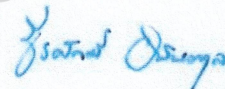
(รศ. ดร.ปิยาภรณ์ มีสวัสดิ์)

กรรมการ



(รศ. ดร.มนต์ทิพย์ภา อุฑารสกุล)

กรรมการ



(ดร.ธีรศักดิ์ อนันตกุล)

กรรมการ



(รศ. ดร.ฉัตรชัย โชติชูชาญ)

รองอธิการบดีฝ่ายวิชาการ

และประกันคุณภาพ



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

ธฤต จุมภู : การวิเคราะห์สัญญาณคลื่นไฟฟ้าสมองสำหรับการเขียนในจินตนาการ
(ANALYSIS OF ELECTROENCEPHALOGRAM SIGNALS FOR WRITING IMAGINATION)

อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.พีระพงษ์ อุซหารสกุล, 100 หน้า.

คำสำคัญ : สัญญาณคลื่นไฟฟ้าสมอง/การเชื่อมต่อระหว่างสมองและคอมพิวเตอร์/โครงข่ายประสาทเทียม

สมองเป็นอวัยวะสำคัญที่สุดของร่างกายมนุษย์เนื่องจากทำหน้าที่ควบคุมการเคลื่อนไหวของร่างกาย ถ้าหากสมองได้รับความเสียหายอาจส่งผลให้ผู้เคราะห์ร้ายบางรายต้องทนทุกข์ทรมานกับการอยู่ในภาวะที่เรียกว่า ล็อกอินซินโดรม (Locked-in Syndrome: LIS) ซึ่งเป็นภาวะที่ผู้ป่วยมีสติสัมปชัญญะครบถ้วนสามารถคิดและให้เหตุผลได้แต่ผู้ป่วยไม่สามารถขยับใบหน้าหรือแขนและขาได้เลย ยกเว้นการเคลื่อนไหวของดวงตาในแนวตั้งและการกะพริบตาเพียงเท่านั้น ถึงแม้ว่าผู้ป่วยจะได้รับผลกระทบร้ายแรงจากภาวะล็อกอินซินโดรมแต่ผู้ป่วยก็สามารถอยู่รอดได้เป็นเวลามากกว่าสิบปี ถ้าหากได้รับการดูแลสุขภาพจิตที่ดีและทำกายภาพบำบัดอย่างต่อเนื่องจากผู้ดูแล ซึ่งการจะช่วยให้ผู้ป่วยมีสุขภาพจิตที่ดีขึ้นได้ หนึ่งในส่วนประกอบที่จำเป็นต้องมีคือการสื่อสารระหว่างกันแต่ปัญหาสำคัญก็คือผู้ป่วยที่อยู่ในภาวะล็อกอินซินโดรมไม่สามารถสื่อสารได้ ถึงแม้ว่าในปัจจุบันมีหลายงานวิจัยที่พัฒนาระบบการสื่อสารโดยใช้คลื่นไฟฟ้าสมองแต่ระบบเหล่านั้นยังจำเป็นต้องมีการกระตุ้นสมองของผู้ใช้งานจากสิ่งเร้าภายนอกอย่างต่อเนื่องเพื่อสร้างการตอบสนองของสมอง ซึ่งวิธีการเหล่านี้เมื่อนำไปใช้งานจำเป็นต้องให้ผู้ใช้อ้างอิงสิ่งกระตุ้นผ่านหน้าจอคอมพิวเตอร์ตลอดเวลา ดังนั้นในงานวิจัยนี้จึงเสนอแนวทางใหม่สำหรับการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา ซึ่งหลักการก็คือการวิเคราะห์การเปลี่ยนแปลงของคลื่นไฟฟ้าสมองเมื่อจินตนาการถึงรูปแบบการเขียนตัวอักษรด้วยเทคนิคการแปลงเวฟเล็ตแบบเต็มหน่วยและใช้โครงข่ายประสาทเทียม ในการประมวลผลเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง โดยผลการวิจัยแสดงให้เห็นว่ามีความเป็นไปได้ถึง 70 เปอร์เซ็นต์ที่สามารถแยกความแตกต่างของคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบการเขียนได้ด้วยเทคนิคที่นำเสนอและนำไปสู่การพัฒนาการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลาได้ในที่สุด

สาขาวิชา วิศวกรรมโทรคมนาคม

ปีการศึกษา 2564

ลายมือชื่อนักศึกษา *Tait*

ลายมือชื่ออาจารย์ที่ปรึกษา *W. A.*

TALIT JUMPHOO : ANALYSIS OF ELECTROENCEPHALOGRAM SIGNALS FOR
WRITING IMAGINATION ADVISOR : ASSOC. PROF. PEERAPONG UTHANSAKUL,
Ph.D., 100 PP

Keyword: Electroencephalogram/Brain Computer Interfaces/Artificial Neural Networks

The brain is arguably the most important organ in the human body. It controls movement, allows us to think and feel, and enables us to have memories and feelings. Anyone who has severely injured a region of the brainstem called the pons cannot move or communicate verbally due to complete paralysis of nearly all muscles in the body except for vertical eye movements, blinking and consciousness, also known as Locked-in syndrome (LIS). If a patient receives mental health care and ongoing physical therapy from caregivers, the patient can survive for more than ten years. However, the main problem is that patients with locked-in syndrome are unable to communicate. Currently, many studies developing EEG-based communication systems, still require constant stimulation of the user's brain. These methods require the user to constantly stare at the stimulus through the computer screen. Therefore, this research proposed EEG-based communication systems without any constant external stimulation. The principle is to analyze the EEG signals when imagining the writing patterns of characters with the Discrete Wavelet Transform technique and use Artificial Neural Networks to classification EEG signals patterns. The results show that the classification accuracy of the proposed technique is about 70%, which in turn leads to a significant achievement for the development of EEG-based communication systems without any constant external stimulation.

School of Telecommunication Engineering
Academic Year 2021

Student's Signature Talit
Advisor's Signature Peerapong Uthansakul

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จลุล่วงไปได้ด้วยดีเนื่องจากความช่วยเหลือเป็นอย่างดีทั้งด้านวิชาการและการดำเนินงานวิจัยจากบุคคลและคณะบุคคลต่าง ๆ ได้แก่

รองศาสตราจารย์ ดร.พีระพงษ์ อุฑารสกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ให้โอกาสทางการศึกษา ให้คำปรึกษาและแนะแนวทางอันเป็นประโยชน์ยิ่งต่องานวิจัยแก่ผู้วิจัยมาโดยตลอด รวมทั้งช่วยตรวจทานและแก้ไขวิทยานิพนธ์เล่มนี้จนเสร็จสมบูรณ์

รองศาสตราจารย์ ดร.มนต์ทิพย์ภา อุฑารสกุล ผู้ช่วยศาสตราจารย์ ดร.วิภาวี หัตถกรรม ผู้ช่วยศาสตราจารย์ ดร. คมเดช ภาพัฒนบุรี ดร.ปธิกร อันซีน ที่ให้ความรู้ทางด้านวิชาการและให้คำปรึกษาอันเป็นประโยชน์ต่องานวิจัย

ขอขอบคุณโครงการปริญญาเอกกาญจนาภิเษกที่มอบทุนสนับสนุนตลอดระยะเวลาการศึกษา

ขอขอบคุณคุณวีรินทร์ อัจฉาญ เลขานุการสาขาวิชาวิศวกรรมโทรคมนาคม ที่ให้คำปรึกษาและจัดการด้านเอกสารตลอดระยะเวลาการศึกษา และขอบคุณพี่ เพื่อน น้องบัณฑิตศึกษาทุกท่านที่คอยให้ความช่วยเหลือและเป็นกำลังใจ

สุดท้ายนี้ผู้วิจัยขอขอบพระคุณอาจารย์ผู้สอนทุกท่านที่ประสิทธิ์ประสาทความรู้ด้านต่าง ๆ ทั้งในอดีตและปัจจุบันจนสำเร็จการศึกษาไปได้ด้วยดี

ชฤต จุมภู

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ฉ
บทที่	
1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย.....	4
1.3 สมมติฐานของการวิจัย.....	4
1.4 ขอบเขตของการวิจัย	5
1.5 วิธีดำเนินการวิจัย	5
1.6 ประโยชน์ที่คาดว่าจะได้รับ	6
2 ปรัชญาบรรณกรรมและทฤษฎีที่เกี่ยวข้อง.....	7
2.1 บทนำ.....	7
2.2 โครงสร้างและการทำงานของสมอง	7
2.2.1 การทำงานของสมองกลีบหน้า.....	8
2.2.2 การทำงานของสมองกลีบข้าง.....	8
2.2.3 การทำงานของสมองกลีบหมับ	9
2.2.4 การทำงานของสมองกลีบท้ายทอย.....	9
2.3 การเก็บข้อมูลจากสมอง.....	9
2.3.1 การเก็บข้อมูลแบบบูรณาการและแบบบูรณาการบางส่วน	10

สารบัญ (ต่อ)

หน้า

2.3.2	การเก็บข้อมูลแบบไม่รุกราน	10
2.4	รูปแบบของคลื่นไฟฟ้าสมอง	12
2.4.1	คลื่นแกมมา (Gamma Wave).....	13
2.4.2	คลื่นเบต้า (Beta Wave).....	13
2.4.3	คลื่นอัลฟา (Alpha Wave)	13
2.4.4	คลื่นธีต้า (Theta Wave)	14
2.4.5	คลื่นเดลต้า (Delta Wave)	14
2.5	การเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์.....	15
2.5.1	การเก็บข้อมูลคลื่นไฟฟ้าสมอง (Signal acquisition).....	15
2.5.2	การประมวลผลล่วงหน้า (Pre-processing).....	17
2.5.3	การวิเคราะห์คลื่นไฟฟ้าสมองเพื่อดึงคุณลักษณะเด่นของคลื่น (Feature extraction).....	19
2.5.4	การจำแนกรูปแบบของคลื่นไฟฟ้าสมอง (Classification)	25
2.6	งานวิจัยที่พัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมอง.....	31
2.7	สรุป.....	33
3	วิธีการดำเนินการวิจัย	34
3.1	บทนำ.....	34
3.2	การเก็บข้อมูลคลื่นไฟฟ้าสมองจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร	34
3.2.1	กำหนดเกณฑ์การคัดเลือกอาสาสมัคร	34
3.2.2	การเตรียมอุปกรณ์บันทึกสัญญาณคลื่นไฟฟ้าสมอง	34
3.2.3	กำหนดรูปแบบของการจินตนาการให้มีมาตรฐานเดียวกัน.....	36
3.2.4	ลดปัจจัยที่จะส่งผลกระทบต่อคลื่นไฟฟ้าสมอง	37
3.2.5	พัฒนาโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง	37
3.2.6	การเก็บข้อมูลคลื่นไฟฟ้าสมอง.....	39

สารบัญ (ต่อ)

หน้า

3.3	การวิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร.....	39
3.3.1	การจัดการข้อมูลคลื่นไฟฟ้าสมอง.....	39
3.3.2	การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมอง.....	40
3.4	การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร.....	43
3.4.1	การจัดเตรียมข้อมูลคลื่นไฟฟ้าสมอง.....	43
3.4.2	การสร้างแบบจำลองโครงข่ายเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง.....	45
3.4.3	การทดสอบแบบจำลองโครงข่ายประสาทเทียม.....	46
3.4.4	การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร.....	47
3.5	สรุป.....	48
4	ผลการวิจัยและอภิปรายผล.....	49
4.1	บทนำ.....	49
4.2	ผลการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่ายประสาทเทียมเมื่ออาสาสมัครจินตนาการถึงรูปแบบการเขียน.....	49
4.3	ผลการจำแนกคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเพื่อหาความสัมพันธ์ของย่านความถี่.....	51
4.4	ความเป็นไปได้ของระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา.....	53
4.5	สรุป.....	56

สารบัญ (ต่อ)

หน้า

5	สรุปผลการวิจัยและข้อเสนอแนะ	58
5.1	สรุปผลการวิจัย.....	58
5.2	ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต.....	59
	รายการอ้างอิง	60
ภาคผนวก		
	ภาคผนวก ก บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา	65
	ประวัติผู้เขียน	100



สารบัญตาราง

ตารางที่	หน้า
3.1	ย่านความถี่การตอบสนองของสมองที่สอดคล้องกับระดับการแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองด้วยอัลตราการสุ่มตัวอย่าง 128 เฮิรตซ์..... 41



สารบัญรูป

รูปที่		หน้า
1.1	โครงสร้างหลักของสมอง.....	1
2.1	สมองกลีบหน้า.....	8
2.2	สมองกลีบข้าง.....	8
2.3	สมองกลีบขมับ.....	9
2.4	สมองกลีบท้ายทอย.....	9
2.5	รูปแบบการเก็บข้อมูลจากสมอง.....	10
2.6	ระบบมาตรฐานนานาชาติ 10 – 20.....	12
2.7	รูปแบบของคลื่นแกมมา.....	13
2.8	รูปแบบของคลื่นเบต้า.....	13
2.9	รูปแบบของคลื่นอัลฟา.....	13
2.10	รูปแบบของคลื่นดีต้า.....	14
2.11	รูปแบบของคลื่นเดลต้า.....	14
2.12	องค์ประกอบของระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์.....	15
2.13	รูปแบบของคลื่นไฟฟ้าสมองชนิด P300.....	16
2.14	รูปแบบของคลื่นไฟฟ้าสมองที่ตอบสนองต่อสิ่งเร้าสายตาในอัตรากงที่.....	16
2.15	รูปแบบของคลื่นไฟฟ้าสมองที่ตอบสนองต่อการเคลื่อนไหวแขนข้างขวา.....	17
2.16	สิ่งประดิษฐ์ทางสรีรวิทยาที่ผสมอยู่ในคลื่นไฟฟ้าสมอง.....	18
2.17	การแปลงฟูเรียร์.....	19
2.18	การแปลงฟูเรียร์ในช่วงเวลาสั้น.....	20
2.19	การแปลงเวฟเล็ต.....	20
2.20	การแปลงเวฟเล็ตแบบต่อเนื่อง.....	21
2.21	การแปลงเวฟเล็ตแบบเต็มหน่วยระดับ 3.....	22
2.22	กระบวนการทำงานของวิธีการแบบ EMD.....	23

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.23	จุดสูงสุด(สีแดง)และจุดต่ำสุด(สีน้ำเงิน)ของแต่ละช่วงในสัญญาณต้นฉบับ $(x(t))$ 23
2.24	สัญญาณขอบบน(เส้นสีเขียว)สัญญาณขอบล่าง(เส้นสีส้ม)และสัญญาณเฉลี่ย(เส้นสีแดง) 24
2.25	สัญญาณที่มีจุดสูงสุดและต่ำสุดเพียงตำแหน่งเดียว..... 24
2.26	ตัวอย่างการแยกองค์ประกอบของสัญญาณด้วยวิธี EMD 25
2.27	โครงสร้างแบบจำลองพื้นฐานของโครงข่ายประสาทเทียม 26
2.28	โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้น..... 26
2.29	โครงสร้างภายในของโครงข่ายประสาทเทียมแบบหลายชั้น..... 27
2.30	ชนิดของฟังก์ชันกระตุ้นที่ได้รับความนิยม (Feng et al., 2019) 28
2.31	โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้นทำงานร่วมกับการแพร่ย้อนกลับ 30
2.32	รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองชนิด P300 31
2.33	รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองชนิด SSVEP (Segers, et al., 2011) 31
2.34	แป้นพิมพ์ตัวอักษรสำหรับการสื่อสารด้วยคลื่นไฟฟ้าสมอง (Hwang, Lim et al.,2012).... 32
2.35	รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองแบบ Motor Imagery..... 32
3.1	อุปกรณ์บันทึกสัญญาณแบบไร้สาย (ก) และ ตำแหน่งอิเล็กโทรดของอุปกรณ์ (ข)..... 34
3.2	การติดตั้งเครื่องบันทึกสัญญาณคลื่นไฟฟ้าสมอง 35
3.3	รูปแบบการจินตนาการถึงวงกลม 36
3.4	การจินตนาการถึงเส้นตรงในรูปแบบต่างๆ 36
3.5	ผังการทำงานของโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง 37
3.6	หน้าตาของโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง..... 38
3.7	การแสดงภาพเคลื่อนไหวของรูปแบบวงกลม..... 38
3.8	กระบวนการเก็บข้อมูลคลื่นไฟฟ้าสมอง..... 39
3.9	การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองด้วยการแปลงเวฟเล็ตแบบเต็มหน่วย... 40
3.10	การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองที่ถูกบันทึกจากอาสาสมัครด้วยการแปลงเวฟเล็ตแบบเต็มหน่วย 41
3.11	ข้อมูลคลื่นไฟฟ้าสมองที่ถูกบันทึกจากการจินตนาการ..... 43


สารบัญรูป (ต่อ)

รูปที่	หน้า
3.12	นำข้อมูลคลื่นไฟฟ้าสมองจากแต่ละช่องสัญญาณมาจัดเรียงเป็นชุดข้อมูล 43
3.13	การจัดเรียงชุดข้อมูลคลื่นไฟฟ้าสมองที่บันทึกจากการจินตนาการถึงรูปแบบของวงกลมด้วย ช่องสัญญาณ AF3..... 44
3.14	การจัดเรียงข้อมูลคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเป็น 5 ย่านความถี่ของช่องสัญญาณ F3 ในการจินตนาการแต่ละครั้ง 44
3.15	การจัดเรียงชุดข้อมูลคลื่นไฟฟ้าสมองของแต่ละย่านความถี่ตามรูปแบบการจินตนาการของ อาสาสมัครแต่ละคน 45
3.16	กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม..... 45
3.17	แบบจำลองโครงข่ายประสาทเทียมของช่องสัญญาณ AF3 46
3.18	กระบวนการทดสอบแบบจำลองโครงข่ายประสาทเทียม..... 46
3.19	ตัวอย่างการตัดสินใจว่าอาสาสมัครจินตนาการถึงรูปแบบการเขียนวงกลม 47
4.1	ผลการทดสอบความแม่นยำในการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่าย..... 49
4.2	ผลการพิจารณาช่องสัญญาณที่ให้ข้อมูลส่งออกจากแบบจำลองโครงข่ายประสาทเทียมเป็น คำตอบที่ถูกต้องอยู่เสมอ..... 50
4.3	ผลการจำแนกคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเพื่อหาความสัมพันธ์ของย่านความถี่. 52
4.4	แสดงความสัมพันธ์ที่เกิดขึ้นในกระบวนการจินตนาการ 52
4.5	ระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบของรหัสมอร์ส..... 53
4.6	รูปแบบของรหัสมอร์ส..... 54
4.7	กระบวนการทำงานของระบบการตัดสินใจเพื่อแปลความหมายของคลื่นไฟฟ้าสมองไปเป็น ตัวอักษร 55
4.8	ตัวอย่างการทำงานของระบบการสื่อสารด้วยการจินตนาการ..... 56

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา



รูปที่ 1.1 โครงสร้างหลักของสมอง

สมองเป็นอวัยวะที่สำคัญที่สุดของร่างกายมนุษย์เนื่องจากทำหน้าที่ควบคุมการเคลื่อนไหวของร่างกาย กระบวนการคิดวิเคราะห์ การเก็บความทรงจำ การแสดงอารมณ์และความรู้สึก เมื่ออธิบายด้วยลักษณะทางกายวิภาคศาสตร์โครงสร้างของสมองประกอบด้วยสามส่วนหลักได้แก่ สมองใหญ่ สมองน้อย และก้านสมอง ดังแสดงในรูปที่ 1.1 โดยแต่ละส่วนจะทำหน้าที่แตกต่างกัน สมองใหญ่เป็นส่วนที่อยู่บนสุดและมีขนาดใหญ่ที่สุด ทำหน้าที่เกี่ยวกับความคิด การมองเห็น การได้ยิน และการเรียนรู้ ในขณะที่สมองน้อยมีตำแหน่งอยู่ภายใต้สมองใหญ่ทำหน้าที่คอยประสานการเคลื่อนไหวของกล้ามเนื้อ รักษาท่าทางและความสมดุล ส่วนก้านสมองจะทำหน้าที่เป็นศูนย์กลางสำหรับการถ่ายทอดข้อมูลระหว่างสมองใหญ่และสมองน้อยไปยังไขสันหลังซึ่งสัมพันธ์กับการทำงานของอวัยวะหลายอย่าง เช่น การเคลื่อนไหวของดวงตาและปาก การแสดงออกทางสีหน้า การหายใจ การรับรู้ เป็นต้น ดังนั้น ถ้าหากสมองได้รับความเสียหายโดยเฉพาะที่ส่วนของก้านสมองผลลัพธ์ที่เกิดขึ้นอาจส่งผลให้ผู้เคราะห์ร้ายอยู่ในสภาพผัก (Vegetative state) อาการโคม่า หรือเสียชีวิตได้ (Mendoza, and Foundas 2007) ในขณะที่ผู้รอดชีวิตบางรายจะมีปัญหาอย่างน้อยหนึ่งอย่างเกี่ยวกับ การกลืน

การเคลื่อนไหว และการหายใจ หรือยิ่งไปกว่านั้นบางรายจะต้องทนทุกข์ทรมานกับการอยู่ในภาวะที่เรียกว่า ล็อกอินซินโดรม (Locked-in Syndrome: LIS) ซึ่งเป็นภาวะที่ผู้ป่วยมีสติสัมปชัญญะครบถ้วนสามารถคิดและให้เหตุผลได้แต่ผู้ป่วยไม่สามารถขยับใบหน้าหรือแขนและขาได้เลย ยกเว้นการเคลื่อนไหวของดวงตาในแนวตั้งและการกะพริบตาเพียงเท่านั้น ถึงแม้ว่าผู้ป่วยจะได้รับผลกระทบร้ายแรงจากภาวะล็อกอินซินโดรมแต่ผู้ป่วยก็สามารถอยู่รอดได้เป็นเวลามากกว่าสิบปี ถ้าหากได้รับการดูแลสุขภาพจิตที่ดีและทำกายภาพบำบัดอย่างต่อเนื่องจากผู้ดูแล (Farr, Altonji, and Harvey, 2021) ซึ่งการจะช่วยให้ผู้ป่วยมีสุขภาพจิตที่ดีขึ้นได้หนึ่งในส่วนประกอบที่จำเป็นต้องมีคือการสื่อสารระหว่างกันแต่ปัญหาสำคัญก็คือผู้ป่วยที่อยู่ในภาวะล็อกอินซินโดรมไม่สามารถสื่อสารกับผู้ดูแลได้

จากการทบทวนวรรณกรรมในช่วงไม่กี่ปีที่ผ่านมาพบว่ามีหลายความพยายามในการพัฒนาเทคโนโลยีเพื่อช่วยเหลือผู้ป่วยที่อยู่ในภาวะล็อกอินซินโดรมหนึ่งในเทคโนโลยีที่ได้รับความนิยมคือการเชื่อมต่อระหว่างผู้ป่วยกับคอมพิวเตอร์ (Patient-Computer Interfaces: PCI) ซึ่งใช้วิธีการตรวจจับสายตาของผู้ป่วยเพื่อช่วยให้ผู้ป่วยสามารถสื่อสารและเข้าถึงอินเทอร์เน็ตได้อย่างอิสระมากขึ้น งานวิจัยของ Boustany, Itani, Youssef, Chami and Abu-Faraj (2016) ได้พัฒนาระบบติดตามการมองโดยใช้กล้องจากคอมพิวเตอร์เพื่อช่วยให้ผู้ป่วยสามารถเลื่อนตัวชี้ตำแหน่งของเมาส์ไปยังคำสั่งต่างๆสำหรับควบคุมประตู, บานหน้าต่าง, ไฟส่องสว่าง, ระบบควบคุมเตียง, โทรทัศน์และเครื่องปรับอากาศด้วยตัวเอง ในลักษณะที่คล้ายกันงานวิจัยของ Vasiljevas, Šalkevičius, Gedminas and Damaševičius (2015) ได้พัฒนาระบบแป้นพิมพ์แบบเลื่อนได้เพื่อช่วยให้ผู้ป่วยสามารถสะกดคำต่างๆได้ด้วยตัวเองซึ่งหลักการทำงานคือให้ตัวอักษรแต่ละตัวเลื่อนจากขวาไปซ้ายและมีเส้นสีแดงอยู่ตรงกลางหน้าจอเสมอ ผู้ป่วยสามารถเลือกตัวอักษรที่ต้องการโดยหยุดการเคลื่อนไหวของดวงตาชั่วขณะหนึ่งหรือกะพริบตาในขณะที่ตัวอักษรนั้นอยู่ในตำแหน่งที่ตรงกับเส้นสีแดงกลางหน้าจอ ต่อมางานวิจัยของ Alva, Castellino, Deshpande, Sonawane and Lopes (2017) ได้นำเสนอระบบช่วยเหลือผู้ป่วยด้วยการแสดงภาพความต้องการต่างๆ ได้แก่ เหตุฉุกเฉิน การพักผ่อน ห้องน้ำ อาหารและเครื่องดื่ม ซึ่งระบบจะใช้วิธีการตรวจจับใบหน้าและติดตามดวงตาของผู้ป่วยเมื่อผู้ป่วยจ้องมองภาพความต้องการเป็นเวลาสองสามวินาทีระบบจะตีความว่าผู้ป่วยต้องการความช่วยเหลือในเรื่องนั้น ถึงแม้ว่าวิธีการตรวจจับสายตาจะมีแนวโน้มที่ดีที่จะสามารถช่วยเหลือผู้ป่วยได้แต่ยังคงมีข้อจำกัดหลายประการ เช่น ความเร็วต่ำ ความแม่นยำของดวงตา การตรวจจับที่ผิดพลาดจากการถูกบังด้วยเปลือกตาหรือขนตา การรบกวนจากแสงโดยรอบ เป็นต้น ดังนั้นจึงมีอีกหนึ่งเทคโนโลยีทางเลือกที่เรียกว่าการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์ (Brain-Computer

Interfaces: BCI) เข้ามาช่วยเพิ่มประสิทธิภาพในการช่วยเหลือการสื่อสารของผู้ป่วยที่อยู่ในภาวะลือคอินซินโดรม

แนวความคิดของเทคโนโลยีการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์คือการช่วยให้ผู้ป่วยมีการโต้ตอบกับสิ่งรอบตัวได้ด้วยการใช้เพียงความคิดเท่านั้น ซึ่งระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์จะประกอบไปด้วยอุปกรณ์สำหรับตรวจวัดคลื่นไฟฟ้าสมองและซอฟต์แวร์สำหรับการวิเคราะห์คลื่นเพื่อแปลความหมายให้กลายเป็นการกระทำ เช่น การส่งคำสั่งจากสมองเพื่อควบคุมอุปกรณ์ การสื่อสารทางอารมณ์หรือการสื่อสารด้วยข้อความ เป็นต้น (Al-Nafjan, Hosny, Al-Ohali and Al-Wabil, 2017) ตั้งแต่อดีตจนถึงปัจจุบันการพัฒนาเทคโนโลยีการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์สำหรับการสื่อสารจะนิยมใช้หลักการวิเคราะห์การตอบสนองของสมองสามรูปแบบ ได้แก่ 1. Event-Related Potential: ERP คือการตอบสนองของสมองที่เกิดขึ้นเนื่องจากการถูกกระตุ้นด้วยสิ่งเร้าจากภายนอก เช่น การได้ยิน (Kübler et al., 2009), การมองเห็น (Hwang et al., 2015) และการกระตุ้นด้วยการสัมผัส (Van der Waal, Severens, Geuze and Desain, 2012) เป็นต้น การกระตุ้นเหล่านี้ส่งผลต่อโครงสร้างของสมองโดยตรงทำให้เกิดการเปลี่ยนแปลงระดับแรงดันไฟฟ้าภายในสมอง ซึ่งมักจะเกิดขึ้นหลังจากถูกกระตุ้นไปแล้วเป็นช่วงเวลาประมาณ 300 มิลลิวินาที ทำให้มีชื่อเรียกว่าคลื่น P300 (P3) มีงานวิจัยหลายเรื่องที่ใช้การวิเคราะห์คลื่นดังกล่าวเพื่อสร้างระบบการสะกดคำด้วยคลื่นไฟฟ้าสมองซึ่งถูกเรียกว่า P300-speller (Brouwer and Van Erp, 2010 และ Speier, Arnold, Lu, Taira, and Pouratian, 2011) โดยมีหลักการทำงานคือการกระตุ้นสมองด้วยภาพตัวอักษรที่มีความสว่างเกิดขึ้นแบบทันทีทันใด หลังจากนั้นระบบจะทำนายว่าการตอบสนองของสมองที่เกิดขึ้นสัมพันธ์กับตัวอักษรใดและจะตีความว่าผู้ใช้ให้ความสนใจตัวอักษรนั้น 2. Steady-State Visual- Evoked Potential: SSVEP คือการตอบสนองของสมองที่เกิดขึ้นเนื่องจากการกระตุ้นทางสายตาในอัตราคงที่ ยกตัวอย่างเช่น การกระตุ้นสมองด้วยภาพที่มีการกะพริบด้วยความถี่คงที่ (Bin, Gao, Wang, Hong and Gao, 2009 และ Chen, Wang, Gao, Jung and Gao, 2014) เมื่อผู้ใช้งานจ้องมองไปที่ภาพดังกล่าวสมองจะตอบสนองด้วยการสร้างคลื่นไฟฟ้าที่มีความถี่เดียวกันกับภาพที่เป็นตัวกระตุ้นขึ้นมา เทคนิคนี้เป็นอีกหนึ่งวิธีการที่ใช้สำหรับการพัฒนาระบบการสะกดคำด้วยคลื่นไฟฟ้าสมองหรือที่เรียกว่า SSVEP-speller 3. Motor Imagery: MI คือการตอบสนองของสมองที่เกิดขึ้นเนื่องจากการจินตนาการถึงการเคลื่อนไหวของแขนหรือขา การจินตนาการดังกล่าวส่งผลให้เกิดการเปลี่ยนแปลงของแรงดันไฟฟ้าในบริเวณสมองที่ทำหน้าที่ควบคุมการส่งกระแสประสาทไปยังกล้ามเนื้อส่วนต่างๆ (Motor cortex) โดยสามารถสังเกตการตอบสนองนี้ได้จากระดับแอมพลิจูดของคลื่นไฟฟ้าสมองที่จะลดลงจากระดับปกติเมื่อเริ่มเกิดเคลื่อนไหว จากนั้น

แอมพลิจูดจะเพิ่มขึ้นจนถึงค่าสูงสุดหลังจากการเคลื่อนไหวเสร็จสิ้นและกลับสู่ระดับปกติภายในไม่กี่วินาที ด้วยปรากฏการณ์นี้งานวิจัยของ Blankertz et al. (2006) จึงได้พัฒนาระบบการสะกดคำที่ชื่อว่า Hex-o-spell โดยหลักการการทำงานคือการใช้ผู้ใช้งานจินตนาการถึงการเคลื่อนไหวของแขนหรือขาเพื่อควบคุมลูกศรให้ชี้ไปยังรูปหกเหลี่ยมที่บรรจุตัวอักษรที่ผู้ใช้งานต้องการจะสื่อสารอยู่ภายใน ในทำนองเดียวกันงานวิจัยของ Zabidi, Mansor, Khuan and Fadzal (2012) ได้พัฒนาระบบการเขียนตัวอักษรโดยไม่จำเป็นต้องใช้การขยับมือจริง ๆ เพียงแต่ให้ผู้ใช้งานจินตนาการถึงการขยับมือตามหลักการเขียนตัวอักษรเท่านั้น

อย่างไรก็ตามระบบการสื่อสารด้วยการใช้คลื่นไฟฟ้าสมองดังที่กล่าวไว้ในข้างต้นจำเป็นต้องมีการกระตุ้นสมองของผู้ใช้งานจากสิ่งเร้าภายนอกอย่างต่อเนื่องหรือต้องเกิดจากการจินตนาการถึงการเคลื่อนไหวของแขนและขาเพื่อสร้างการตอบสนองของสมอง ซึ่งวิธีการเหล่านี้เมื่อนำไปใช้งานจริงจำเป็นต้องให้ผู้ใช้งานมองสิ่งกระตุ้นผ่านหน้าจอกอมพิวเตอร์ตลอดเวลา ดังนั้นในงานวิจัยนี้จึงเสนอแนวทางใหม่สำหรับการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่จำเป็นต้องคิดถึงการเคลื่อนไหวของแขนและขาหรือใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา ซึ่งหลักการของแนวทางนี้คือการวิเคราะห์การเปลี่ยนแปลงของคลื่นไฟฟ้าสมองเมื่อจินตนาการถึงรูปแบบการเขียนตัวอักษร และใช้อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning: ML) แบบโครงข่ายประสาทเทียม (Artificial neural networks) ในการประมวลผลเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง โดยผลลัพธ์ของการจำแนกคลื่นไฟฟ้าสมองจะถูกนำไปแปลความหมายให้เป็นข้อความตามที่ผู้ใช้งานต้องการจะสื่อสาร

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 ออกแบบระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา

1.2.2 วิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

1.2.3 จำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

1.3 สมมติฐานของการวิจัย

คลื่นไฟฟ้าสมองที่เกิดขึ้นในขณะที่กำลังจินตนาการถึงรูปแบบการเขียนตัวอักษรจะเป็นคลื่นไฟฟ้าสมองที่มีความแตกต่างกันซึ่งจะทำให้สามารถจำแนกความแตกต่างได้ด้วยอัลกอริทึมการ

เรียนรู้ของเครื่องโดยจะให้ความถูกต้องในการจำแนกความแตกต่างของคลื่นไฟฟ้าสมองมากกว่า 70 เปอร์เซ็นต์

1.4 ขอบเขตของการวิจัย

1.4.1 ใช้อุปกรณ์บันทึกคลื่นไฟฟ้าสมองที่ไม่ใช่ทางการแพทย์โดยอุปกรณ์มีราคาไม่เกิน 6 หมื่นบาทและมีการส่งข้อมูลแบบไร้สายเพื่อความสะดวกในการใช้งาน

1.4.2 การเก็บข้อมูลคลื่นไฟฟ้าสมองจะดำเนินการกับอาสาสมัครที่เป็นคนปกติ สุขภาพแข็งแรงและไม่มีปัญหาทางด้านสมอง

1.4.3 การวิเคราะห์และจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร จะใช้รูปแบบการจินตนาการเฉพาะวงกลมและเส้นตรงเพียง 2 รูปแบบ

1.5 วิธีดำเนินการวิจัย

1.5.1 แนวทางการดำเนินงาน

- 1.5.1.1 สำรวจบริษัทผู้จำหน่ายและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์
- 1.5.1.2 ศึกษาทฤษฎีเกี่ยวกับโครงสร้างและระบบการทำงานของสมอง
- 1.5.1.3 ศึกษาทฤษฎีของคลื่นไฟฟ้าสมองและวิธีการบันทึกสัญญาณคลื่นไฟฟ้าสมอง
- 1.5.1.4 ศึกษาวิธีการวิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมอง
- 1.5.1.5 ศึกษาวิธีการจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง
- 1.5.1.6 ออกแบบระบบการสื่อสารด้วยการใช้คลื่นไฟฟ้าสมอง
- 1.5.1.7 วิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมองตามระบบที่ได้ออกแบบไว้
- 1.5.1.8 จำแนกความแตกต่างของคลื่นไฟฟ้าสมองตามระบบที่ได้ออกแบบไว้
- 1.5.1.9 วิเคราะห์และสรุปผลการดำเนินการวิจัย

1.5.2 เครื่องมือที่ใช้ในการวิจัย

- 1.5.2.1 อุปกรณ์บันทึกสัญญาณคลื่นไฟฟ้าสมอง
- 1.5.2.2 คอมพิวเตอร์ส่วนบุคคล
- 1.5.2.3 โปรแกรมคอมพิวเตอร์
- 1.5.2.4 ใบอนุญาตสำหรับดำเนินการวิจัยในมนุษย์

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 เป็นองค์ความรู้พื้นฐานในการพัฒนาเทคโนโลยีที่เกี่ยวข้องกับคลื่นไฟฟ้าทางร่างกาย นอกเหนือจากการพัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมอง

1.6.2 เป็นแนวทางในการพัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองสำหรับนำไปต่อยอด เพื่อช่วยเหลือผู้ป่วยที่อยู่ในภาวะลือคอินซินโดรมให้สามารถสื่อสารกับคนอื่น ๆ ได้



บทที่ 2

ปริทัศน์วรรณกรรมและทฤษฎีที่เกี่ยวข้อง

2.1 บทนำ

เนื้อหาในบทนี้จะกล่าวถึงปริทัศน์วรรณกรรมและทฤษฎีที่เกี่ยวข้องกับเทคโนโลยีการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์ที่ถูกใช้เป็นแนวทางสำหรับวิทยานิพนธ์ฉบับนี้ ส่วนแรกของบทจะอธิบายถึงโครงสร้างและการทำงานของสมอง การเก็บข้อมูลจากสมอง และรูปแบบของคลื่นไฟฟ้าสมอง ส่วนที่สองของบทจะอธิบายถึงหลักการทำงานของระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์ซึ่งจะประกอบไปด้วย การเก็บข้อมูลคลื่นไฟฟ้าสมอง (Signal acquisition) การประมวลผลล่วงหน้า (Pre-processing) การวิเคราะห์คลื่นไฟฟ้าสมองเพื่อดึงคุณลักษณะเด่นของคลื่น (Feature extraction) และการจำแนกรูปแบบของคลื่นไฟฟ้าสมอง (Classification) ส่วนสุดท้ายของบทจะกล่าวถึงงานวิจัยที่พัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมอง

2.2 โครงสร้างและการทำงานของสมอง

โครงสร้างหลักของสมองประกอบด้วยสามส่วนได้แก่ สมองน้อย ก้านสมอง และสมองใหญ่ โดยสมองน้อยมีตำแหน่งอยู่ภายใต้สมองใหญ่ทำหน้าที่คอยประสานการเคลื่อนไหวของกล้ามเนื้อ รักษาท่าทางและความสมดุล ส่วนก้านสมองจะทำหน้าที่เป็นศูนย์กลางสำหรับการถ่ายทอดข้อมูลระหว่างสมองใหญ่และสมองน้อยไปยังไขสันหลังซึ่งสัมพันธ์กับการทำงานของอวัยวะหลายอย่าง เช่น การเคลื่อนไหวของดวงตาและปาก การแสดงออกทางสีหน้า การหายใจ การรับรู้ความรู้สึก เป็นต้น ส่วนสมองใหญ่เป็นสมองที่อยู่ด้านบนสุดและมีขนาดใหญ่ที่สุดซึ่งมีส่วนประกอบอีก 4 ส่วนย่อยคือ สมองกลีบหน้า (Frontal lobe) สมองกลีบข้าง (Parietal lobe) สมองกลีบขมับ (Temporal lobe) และสมองกลีบท้ายทอย (Occipital lobe) ซึ่งมีรายละเอียดการทำงานที่แตกต่างกัน (Lezak, Howieson, Bigler and Tranel, 2012) ดังต่อไปนี้

2.2.1 การทำงานของสมองกลีบหน้า



รูปที่ 2.1 สมองกลีบหน้า

สมองกลีบหน้าเป็นส่วนที่อยู่บริเวณด้านหลังหน้าผากดังแสดงในรูปที่ 2.1 มีบทบาทหน้าที่หลายอย่างเกี่ยวกับสติปัญญา เช่น การคิดวิเคราะห์เพื่อประเมินความเหมือนหรือแตกต่างระหว่างวัตถุสองชนิด การรับรู้และความเข้าใจ การมีเหตุผล การแก้ปัญหา เป็นต้น นอกจากนี้ยังเกี่ยวข้องกับการนึกคิดเกี่ยวกับความทรงจำทั้งในระยะสั้นและระยะยาว ส่วนด้านหลังของกลีบนี้จะเป็นตำแหน่งของสมองที่มีหน้าที่ควบคุมการทำงานของกล้ามเนื้ออวัยวะทั้งหมดของร่างกาย เช่น การเคลื่อนไหวของ แขน ขา เป็นต้น ซึ่งส่วนนี้มีชื่อเรียกว่า มอเตอร์คอร์เท็กซ์ (Motor cortex)


2.2.2 การทำงานของสมองกลีบข้าง



รูปที่ 2.2 สมองกลีบข้าง

สมองกลีบข้างเป็นส่วนที่อยู่ต่อจากสมองกลีบหน้าดังแสดงในรูปที่ 2.2 มีหน้าที่ในการประมวลผลข้อมูลจากการรับรู้ทางประสาทสัมผัสที่เข้ามาจากทั่วร่างกาย ยกตัวอย่างเช่น การกินอาหาร สมองกลีบข้างจะประมวลผลภาพอาหารที่มองเห็นเพื่อแยกแยะขนาด รูปร่างและสีของอาหาร ทันทีที่จับชิ้นสมองกลีบข้างจะประมวลผลความรู้สึกของมือที่กำลังจับชิ้น และเมื่อกำลังกินอาหาร สมองกลีบข้างจะประมวลผลความรู้สึกของการรับรสและกลิ่นของอาหาร


2.2.3 การทำงานของสมองกลีบขมับ



รูปที่ 2.3 สมองกลีบขมับ

สมองกลีบขมับเป็นส่วนที่อยู่บริเวณด้านข้างของใบหูดังแสดงในรูปที่ 2.3 มีบทบาทสำคัญในการบันทึกความทรงจำระยะยาว ซึ่งช่วยให้สามารถประมวลผลความหมายของคำพูด ภาษา สิ่งที่ได้ยินและสิ่งที่มองเห็นได้ นอกจากนี้ยังเป็นส่วนที่ช่วยให้เข้าใจในอารมณ์ต่างๆ

2.2.4 การทำงานของสมองกลีบท้ายทอย



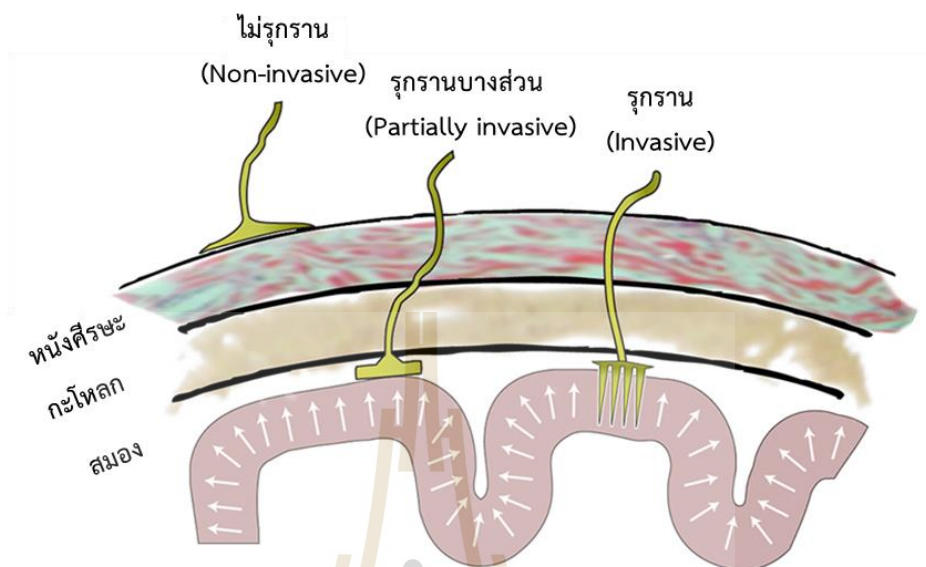
รูปที่ 2.4 สมองกลีบท้ายทอย

สมองกลีบท้ายทอยเป็นกลีบขนาดเล็กที่สุดและอยู่บริเวณด้านหลังของศีรษะดังแสดงในรูปที่ 2.4 มีหน้าที่ในการรับข้อมูลภาพจากโชนประสาทรับรู้ในรูม่านตาและส่งผ่านข้อมูลภาพไปยังพื้นที่ของสมองส่วนอื่นเพื่อประมวลผลความหมายของภาพที่มองเห็น

2.3 การเก็บข้อมูลจากสมอง

การเก็บข้อมูลจากสมองช่วยให้เข้าใจเกี่ยวกับการทำงานของสมองมนุษย์มากขึ้น ซึ่งเป็นประโยชน์ต่อการพัฒนาเทคโนโลยีเพื่อวางแผนการรักษาและเพิ่มคุณภาพชีวิตของผู้ป่วย โดยวิธีการเก็บข้อมูลจากสมองสามารถแบ่งออกเป็นสามวิธีหลัก ได้แก่ การเก็บข้อมูลแบบรุกราน (Invasive)

การเก็บข้อมูลแบบรุกรานบางส่วน (Partially invasive) และการเก็บข้อมูลแบบไม่รุกราน (Non-invasive) ดังแสดงในรูปที่ 2.5



รูปที่ 2.5 รูปแบบการเก็บข้อมูลจากสมอง

2.3.1 การเก็บข้อมูลแบบรุกรานและแบบรุกรานบางส่วน

การเก็บข้อมูลแบบรุกรานเป็นวิธีการเก็บข้อมูลด้วยการผ่าตัดเพื่อฝังแผ่นอิเล็กโทรดขนาดเล็ก (Microelectrode Arrays: MEA) เข้าไปภายในเนื้อสมองทำให้ได้รับข้อมูลสมองที่มีสัญญาณรบกวนน้อยที่สุดและมีความแม่นยำในการแปลความหมายของคลื่นไฟฟ้าสมองสูงโดยวิธีการนี้มีชื่อเรียกว่า Local field potentials หรือ LFP แต่มีข้อจำกัดในการหาพื้นที่สำหรับการฝังแผ่นอิเล็กโทรด ในลักษณะที่คล้ายกันการเก็บข้อมูลแบบรุกรานบางส่วนจะใช้การวางแผ่นอิเล็กโทรดจำนวนมากไว้บนเยื่อหุ้มสมองซึ่งวิธีการนี้มีชื่อเรียกว่า Electrocorticography หรือ ECoG โดยมีความโดดเด่นในเรื่องความละเอียดในการวัดคลื่นไฟฟ้าสมองเชิงพื้นที่และข้อมูลสมองที่เก็บได้ก็มีสัญญาณรบกวนน้อยเช่นเดียวกันกับวิธีการแบบรุกราน อย่างไรก็ตามวิธีการเก็บข้อมูลทั้งสองแบบนี้มีความเสี่ยงและอันตรายเนื่องจากมีโอกาสติดเชื้อได้ รวมไปถึงการมีแนวโน้มที่จะเกิดความล้มเหลวในความเข้ากันได้ทางชีวภาพและจำเป็นต้องถอดออกหรือเปลี่ยนใหม่หลังจากผ่านไประยะหนึ่งเนื่องจากเกิดการปฏิเสธจากร่างกาย

2.3.2 การเก็บข้อมูลแบบไม่รุกราน

เป็นวิธีการเก็บข้อมูลที่ได้รับความนิยมมากที่สุดเนื่องจากมีความปลอดภัยสูงสามารถเก็บข้อมูลสมองจากภายนอกกะโหลกศีรษะได้ โดยเทคโนโลยีที่ใช้กันทั่วไปสำหรับการเก็บข้อมูลสมองแบบไม่รุกรานมีดังนี้


Functional Magnetic Resonance Imaging หรือ fMRI เป็นวิธีการสร้างภาพการทำงานภายในสมองแบบสามมิติด้วยการตรวจวัดระดับออกซิเจนและการเปลี่ยนแปลงปริมาตรของเลือดในสมองระหว่างการกระตุ้นเซลล์ประสาทด้วยสนามแม่เหล็กไฟฟ้า วิธีการนี้อาศัยปรากฏการณ์ทางธรรมชาติของสมองนั้นคือเมื่อพื้นที่ใดของสมองเกิดการ ทำงานของระบบประสาทพื้นที่นั้นจะมีการใช้ออกซิเจนจนหมด ส่งผลให้ร่างกายต้องเติมออกซิเจนไปทดแทนทำให้ปริมาณการไหลเวียนของเลือดบริเวณนั้นเพิ่มขึ้นโดยอุปกรณ์ fMRI ให้รายละเอียดการทำงานของสมองที่สูงมากทำให้อุปกรณ์มีขนาดใหญ่จึงเหมาะสำหรับการใช้งานทางคลินิก เช่น การติดตามการรักษาโรคทางสมอง การหาตัวบ่งของโรคและการศึกษาประสิทธิภาพของยา เป็นต้น

Near-Infrared Spectroscopy หรือ NIRS เป็นวิธีการที่อาศัยปรากฏการณ์ทางธรรมชาติของสมองเหมือนกับเทคโนโลยี fMRI แต่มีหลักการทำงานที่แตกต่างกัน เทคโนโลยี NIRS จะใช้การปล่อยแสงอินฟราเรดย่านใกล้ไปยังพื้นที่ของสมอง ซึ่งแสงอินฟราเรดจะไปกระทบกับฮีโมโกลบินในเม็ดเลือดและถูกดูดซับแสงไปบางส่วนตามปริมาณการไหลเวียนของเลือดในขณะนั้นแล้วสะท้อนกลับมายังตัวรับแสง ซึ่งปริมาณแสงอินฟราเรดที่สะท้อนกลับมาสามารถแสดงถึงพื้นที่การทำงานของสมองได้ โดยอุปกรณ์ NIRS ให้รายละเอียดการทำงานของสมองที่ใกล้เคียงกับเทคโนโลยี fMRI แต่อุปกรณ์มีขนาดเล็กกว่าจึงมักถูกนำไปใช้ในทางคลินิกที่เล็กลง เช่น การวินิจฉัยแยกโรคทางจิตเวช เป็นต้น

Electroencephalogram หรือ EEG เป็นวิธีการเก็บข้อมูลสมองที่มีหลักการทำงานคือ การวัดค่าความต่างศักย์ของคลื่นไฟฟ้าสมองด้วยอิเล็กโทรดที่ติดลงบนผิวหนังของศีรษะ ซึ่งอิเล็กโทรดมักจะทำจากซิลเวอร์คลอไรด์ (AgCl) และมีเจลสำหรับนำไฟฟ้าเพื่อถ่ายโอนประจุระหว่างหนังศีรษะและอิเล็กโทรด ในการบันทึกสัญญาณ EEG การติดอิเล็กโทรดลงบนหนังศีรษะจะต้องเป็นตำแหน่งที่อ้างอิงตามระบบมาตรฐานนานาชาติ 10 – 20 (International 10–20 System) ดังแสดงในรูปที่ 2.6 โดยเป็นตำแหน่งที่มีความเกี่ยวข้องกับพื้นที่การทำงานของสมองซึ่งจะถูกกำกับด้วยตัวอักษรดังนี้

FP - Frontal Pole สมองกลีบหน้าบริเวณหน้าผาก

F - Frontal lobe สมองกลีบหน้า



รูปที่ 2.6 ระบบมาตรฐานนานาชาติ 10 - 20

T - Temporal lobe สมอกลีบขมับ

P - Parietal lobe สมอกลีบข้าง


O - Occipital lobe สมอกลีบท้ายทอย

สมอกลีบกลาง (Central, C) เป็นส่วนที่ไม่ได้อยู่ติดกับกะโหลกชั้นนอก (Cerebral Cortex) ดังนั้นจึงใช้อิเล็กโทรดตรวจวัดจากหนังศีรษะได้ไม่คืนักตำแหน่ง C จึงใช้อ้างอิงถึงในบางวัตถุประสงค์เท่านั้น ส่วนตัวเลขที่ใช้กำกับถูกแบ่งเป็นเลขคู่และเลขคี่ โดยเลขคู่ เช่น 2 4 6 8 จะใช้อ้างอิงตำแหน่งบนศีรษะซีกขวาส่วนเลขคี่ เช่น 1 3 5 7 9 จะใช้อ้างอิงตำแหน่งที่อยู่บนศีรษะซีกซ้าย และตัวอักษร Z จะใช้อ้างอิงตำแหน่งที่อยู่ในแนวแกนตรงกลางศีรษะ ด้วยความง่ายของกระบวนการเก็บข้อมูลคลื่นไฟฟ้าสมอง รวมถึงการเป็นอุปกรณ์ขนาดเล็ก ราคาไม่สูงและสามารถพกพาได้ จึงเป็นวิธีการที่ได้รับความนิยมในการนำไปประยุกต์ใช้เพื่อพัฒนาเทคโนโลยีสำหรับช่วยเหลือผู้พิการ เช่น ระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองสำหรับผู้พิการทางการพูด ระบบควบคุมการทำงานของอุปกรณ์อิเล็กทรอนิกส์ด้วยคลื่นไฟฟ้าสมองสำหรับผู้พิการทางการเคลื่อนไหว เป็นต้น

2.4 รูปแบบของคลื่นไฟฟ้าสมอง

การศึกษารูปแบบของคลื่นไฟฟ้าสมองทางด้านประสาทวิทยาพบว่าความถี่ของคลื่นไฟฟ้าสมองจะแตกต่างกันไปในแต่ละกิจกรรมของมนุษย์ ซึ่งจะครอบคลุมความถี่ในย่านต่าง ๆ ตั้งแต่ประมาณ 0.5 - 100 เฮิร์ตซ์ (Hertz) โดยรายละเอียดของย่านความถี่ที่สัมพันธ์กับกิจกรรมของร่างกายมนุษย์มีดังนี้


2.4.1 คลื่นแกมมา (Gamma Wave)



รูปที่ 2.7 รูปแบบของคลื่นแกมมา

เป็นคลื่นที่มีความถี่ประมาณ 32-100 เฮิร์ตซ์ เป็นช่วงคลื่นที่มีส่วนเกี่ยวข้องกับการประมวลผลทางความคิด การรวบรวมข้อมูลและความเข้าใจอย่างฉับพลัน การมีคลื่นแกมมาในปริมาณที่สูงกว่าคนปกติ จะมีสติปัญญา การแก้ปัญหาและการควบคุมตนเองที่ดี โดยส่วนใหญ่จะสามารถพบได้ในคนที่ฝึกสมาธิขั้นสูง


2.4.2 คลื่นเบต้า (Beta Wave)



รูปที่ 2.8 รูปแบบของคลื่นเบต้า

เป็นคลื่นที่มีความถี่ประมาณ 16-32 เฮิร์ตซ์ เป็นช่วงคลื่นในขณะที่สมองอยู่ในภาวะของการทำงานโดยเกี่ยวข้องกับการใช้ความคิด การใช้ความสนใจ การมุ่งเน้นไปที่บางสิ่งบางอย่างจากภายนอก และยังเกี่ยวข้องกับภาวะจิตใจ เช่น หากรู้สึกตื่นเต้น ตึงเครียด หรือกลัว ก็อาจส่งผลให้คลื่นเบต้าสูงขึ้นกว่าปกติได้


2.4.3 คลื่นอัลฟา (Alpha Wave)



รูปที่ 2.9 รูปแบบของคลื่นอัลฟา

เป็นคลื่นที่มีความถี่ประมาณ 8-16 เฮิร์ตซ์ เป็นช่วงคลื่นในขณะที่กล้ามเนื้อหรือร่างกายผ่อนคลาย ช่วงเวลาที่ง่วงนอน หรือการเข้าสมาธิในระดับภวังค์ที่ไม่ลึกมากคลื่นอัลฟาในช่วงปกติมีความสัมพันธ์กับอารมณ์ที่ดีและความรู้สึกสงบ การฝึกตัวเองให้อยู่ในสถานะคลื่นอัลฟาจะเป็นประโยชน์สำหรับการฝึกสมาธิและการบรรเทาความเครียดในชีวิตประจำวัน นอกจากนี้ยังเป็นประโยชน์ในการเรียนรู้ข้อมูลใหม่ๆ ปฏิบัติงานที่ซับซ้อน จิตใจที่ตื่นตัวและมุ่งมั่นก่อนที่จะมีส่วนร่วมในกิจกรรมอื่นๆ


2.4.4 คลื่นธีต้า (Theta Wave)



รูปที่ 2.10 รูปแบบของคลื่นธีต้า

เป็นคลื่นที่มีความถี่ประมาณ 4-8 เฮิร์ตซ์ เป็นช่วงคลื่นที่เกี่ยวข้องกับการผ่อนคลายอย่างลึกหรือการสนใจบางสิ่งบางอย่างด้วยการคิดในใจและการทำสมาธิอย่างลึกนอกจากนี้การเพิ่มขึ้นของคลื่นที่ต่ำยังเกี่ยวข้องกับการตอบสนองต่อการทำงานของหน่วยความจำสมอง


2.4.5 คลื่นเดลต้า (Delta Wave)



รูปที่ 2.11 รูปแบบของคลื่นเดลต้า

เป็นคลื่นที่มีความถี่ประมาณ 0.5-4 เฮิร์ตซ์ เป็นคลื่นสมองที่ช้าที่สุดและมีความเกี่ยวข้องกับนอนหลับลึกและไม่มีการฝันหรือเกิดจากการเข้าสมาธิลึก ๆ ในช่วงนี้คลื่นสมองแสดงให้เห็นว่า ร่างกายเกิดการพักผ่อนลงลึกอย่างเต็มที่เมื่อถึงเวลาที่พอเหมาะจะรู้สึกได้ถึงความสะดวกเป็นพิเศษเมื่อเปรียบเทียบกับผู้ที่นอนหลับไม่ค่อยสนิทคลื่นการลดลงของคลื่นเดลต้าจะเห็นถึงความผิดปกติขณะนอนหลับ

2.5 การเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์




รูปที่ 2.12 องค์ประกอบของระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์

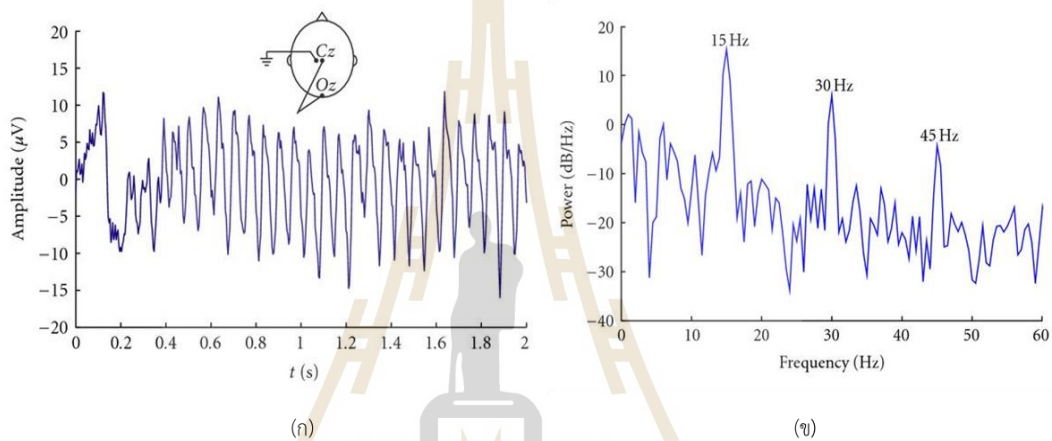
ระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์เป็นระบบที่สามารถส่งผ่านคำสั่งจากสมองไปยังคอมพิวเตอร์ได้โดยตรง ซึ่งแตกต่างจากการทำงานของสมองในรูปแบบปกติที่สมองจะต้องส่งสัญญาณผ่านเส้นประสาทเพื่อไปสั่งการกล้ามเนื้อส่วนต่างๆ ของร่างกายโดยระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์มักจะใช้รูปแบบการเก็บข้อมูลจากสมองแบบไม่รุกรากด้วยวิธีการบันทึกสัญญาณคลื่นไฟฟ้าสมอง (Electroencephalography) เนื่องจากความง่ายของกระบวนการเก็บข้อมูล อุปกรณ์มีขนาดเล็ก ราคาไม่สูง และสามารถพกพาได้สะดวก และด้วยเหตุนี้จึงทำให้ระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์จึงถูกนำไปประยุกต์ใช้เพื่อพัฒนาเทคโนโลยีสำหรับช่วยเหลือ (Assistive Technology) จำนวนมาก โดยระบบมีขั้นตอนการทำงาน 3 ขั้นตอน ได้แก่ 1. การเก็บข้อมูลจากสัญญาณคลื่นไฟฟ้าสมอง 2. การประมวลผลสัญญาณคลื่นไฟฟ้าสมองเพื่อแปลความหมายให้กลายเป็นคำสั่งในการควบคุม 3. ระบบสำหรับนำคำสั่งไปใช้งานและแสดงผลพัทธ์หรือเรียกว่าการป้อนกลับดังแสดงในรูปที่ 2.12

2.5.1 การเก็บข้อมูลคลื่นไฟฟ้าสมอง (Signal acquisition)

ในระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์การเก็บข้อมูลคลื่นไฟฟ้าสมองจะอาศัยสัญญาณทางประสาทที่สมองเกิดการตอบสนองต่อการกระตุ้นหรือการกระทำซึ่งสามารถแบ่งออกเป็น 2 กลุ่มใหญ่ดังนี้



รูปที่ 2.13 รูปแบบของคลื่นไฟฟ้าสมองชนิด P300



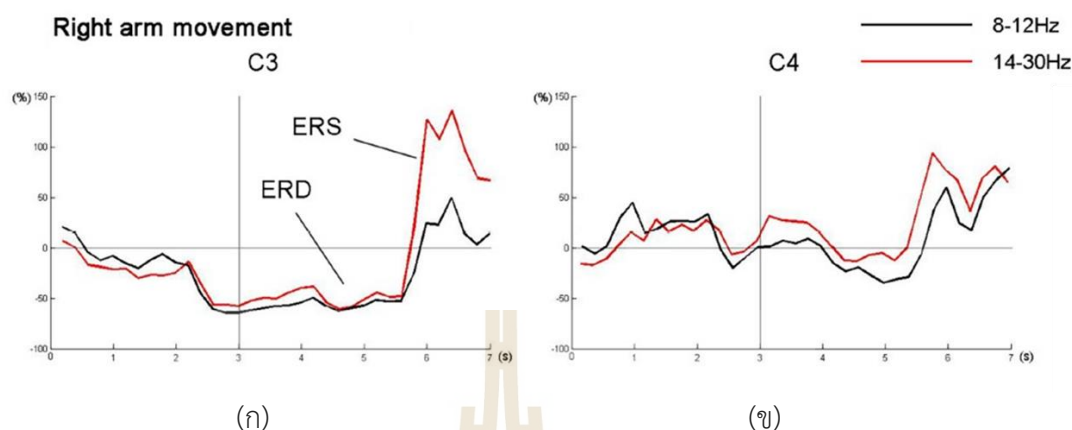
รูปที่ 2.14 รูปแบบของคลื่นไฟฟ้าสมองที่ตอบสนองต่อสิ่งเร้าสายตาในอัตราคงที่

(ก) คลื่นไฟฟ้าสมองในระหว่างการกระตุ้นทางสายตาด้วยความถี่ 15 เฮิร์ตซ์

(ข) ปริมาณความถี่ของคลื่นไฟฟ้าสมองซึ่งมีเกิดการแกว่งที่ 15 เฮิร์ตซ์ สูงที่สุด

1. การตอบสนองของสมองที่เกิดจากการถูกกระตุ้นด้วยสิ่งเร้าจากภายนอก เช่น การกระตุ้นด้วยเสียง การกระตุ้นด้วยการมองเห็น หรือการกระตุ้นด้วยการสัมผัส โดยหลักการก็คือ เมื่อสมองได้รับการกระตุ้นจากสิ่งเร้าต่าง ๆ ก็จะทำให้เกิดการเปลี่ยนแปลงของศักย์ไฟฟ้าภายในสมองที่มีความสัมพันธ์กับเหตุการณ์ภายนอกที่มากระตุ้นซึ่งเรียกการตอบสนองนี้ว่า Event-Related Potential: ERP โดยคลื่นไฟฟ้าสมองที่เกิดจากการตอบสนองแบบ ERP ที่ได้รับความนิยมในการนำมาใช้กับระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์เนื่องจากสัมพันธ์กับระดับความสนใจในสิ่งเร้าคือคลื่นที่เรียกว่า P300 หรือ P3 ซึ่งเป็นรูปแบบของคลื่นไฟฟ้าสมองจะเกิดขึ้นหลังจากได้รับการกระตุ้นจากสิ่งเร้าไปแล้วเป็นเวลาประมาณ 300 มิลลิวินาที (Sur and Sinha, 2009) ดังแสดงในรูปที่ 2.13 นอกจากนี้ยังมีการตอบสนองของสมองแบบ Steady State Visual Evoked Potentials หรือ SSVEP ซึ่งเป็นการถูกกระตุ้นทางสายตาในอัตราคงที่ เช่น การกระตุ้นด้วยภาพที่มีความถี่ 15

เอิร์ทซ์ เป็นช่วงเวลาหนึ่งคลื่นไฟฟ้าสมองจะเกิดการตอบสนองด้วยความถี่เดียวกันกับตัวกระตุ้นทางสายตานั้น (Zhu, Bieger, Garcia Molina and M. Aarts, 2010) ดังแสดงในรูปที่ 2.14



รูปที่ 2.15 รูปแบบของคลื่นไฟฟ้าสมองที่ตอบสนองต่อการเคลื่อนไหวแขนข้างขวา

(ก) การตอบสนองของคลื่นไฟฟ้าสมองที่บริเวณสมองข้างซ้าย


(ข) การตอบสนองของคลื่นไฟฟ้าสมองที่บริเวณสมองข้างขวา

2. การตอบสนองของสมองที่เกิดจากการกระทำ เช่น การเคลื่อนไหวแขนหรือขา จะทำให้เกิดการเปลี่ยนแปลงของคลื่นไฟฟ้าสมอง โดยมีหลักการก็คือเมื่อมนุษย์ต้องการที่จะเคลื่อนไหวสมองส่วนที่ทำหน้าที่ควบคุมการเคลื่อนไหวจะเริ่มส่งสัญญาณเพื่อวางแผนการเคลื่อนไหว ส่งผลให้คลื่นไฟฟ้าสมองที่ความถี่ 8-12 เอิร์ทซ์ หรือเรียกว่า Mu Rhythm ลดระดับพลังงานลง โดยจะเรียกการเปลี่ยนแปลงของคลื่นไฟฟ้าสมองนี้ว่า Event-Related De-synchronization หรือ ERD ในทางกลับกัน พลังงานของคลื่นไฟฟ้าสมองจะกลับมาสูงขึ้นอีกครั้ง หลังจากเกิดการเคลื่อนไหวร่างกายไปแล้ว ซึ่งจะพบได้ในย่านความถี่ 16-32 เอิร์ทซ์ หรือช่วงคลื่นเบต้า โดยจะเรียกการเปลี่ยนแปลงของคลื่นไฟฟ้าสมองนี้ว่า Event-Related Synchronization หรือ ERS ซึ่งจะพบการตอบสนองทั้งสองแบบนี้ได้ที่บริเวณสมองส่วนที่อยู่ด้านตรงข้ามกับแขน/ขาข้างที่ต้องการจะเคลื่อนไหว ดังแสดงในภาพที่ 2.15 และการตอบสนองของสมองแบบ ERD/ERS ไม่จำเป็นต้องเกิดการเคลื่อนไหวจริงของร่างกาย โดยที่สามารถเกิดขึ้นได้ด้วยการจินตนาการการเคลื่อนไหวหรือที่เรียกว่า Motor Imagery (Tang, Yu, Lu, Liu, and Jin, 2019)

2.5.2 การประมวลผลล่วงหน้า (Pre-processing)

การบันทึกสัญญาณคลื่นไฟฟ้าสมองโดยปกติแล้วจะไม่สมบูรณ์แบบที่สุ่มมักจะมีสัญญาณรบกวนปนเปื้อนเสมอซึ่งเรียกว่า สิ่งประดิษฐ์ (Artifacts) เป็นสัญญาณรบกวนที่เกิดขึ้นจากหลายแหล่ง เช่น ไฟบ้าน (มีความถี่ที่ 50 หรือ 60 เอิร์ทซ์) อิมพีแดนซ์ของผิวหนัง คลื่นไฟฟ้าหัวใจ (Electrocardiogram: ECG) คลื่นไฟฟ้ากล้ามเนื้อ (Electromyogram: EMG) คลื่นไฟฟ้าดวงตา (Electrooculogram: EOG) เป็นต้น โดยสิ่งประดิษฐ์ที่เกิดจากคลื่นไฟฟ้าต่างๆ ส่วนใหญ่มาจากการ

เคลื่อนไหวศีรษะ การกลืนน้ำลาย การกระพริบตาและการเคลื่อนไหวของดวงตา ซึ่งแอมพลิจูดของสิ่งประดิษฐ์บางครั้งอาจสูงกว่าแอมพลิจูดของคลื่นไฟฟ้าสมองทำให้บดบังคลื่นไฟฟ้าสมองที่แท้จริงได้ ดังแสดงในรูปที่ 2.16 ดังนั้นการลบหรือการขจัดสิ่งประดิษฐ์ให้เหลือน้อยที่สุดจึงเกิดขึ้นในขั้นตอนการประมวลผลล่วงหน้าเพื่อทำให้คลื่นไฟฟ้าสมองใกล้เคียงกับสัญญาณประสาทที่แท้จริงมากขึ้น




รูปที่ 2.16 สิ่งประดิษฐ์ทางสรีรวิทยาที่ผสมอยู่ในคลื่นไฟฟ้าสมอง

มีวิธีการจำนวนมากในการจัดการสิ่งประดิษฐ์เหล่านี้ วิธีการที่ง่ายที่สุดในการหลีกเลี่ยงการเกิดสิ่งประดิษฐ์บางอย่างโดยไม่ต้องมีการใช้เครื่องมือใดๆ คือการออกแบบการทดลองที่ครอบคลุม ยกตัวอย่างเช่น ผู้วิจัยขอให้อาสาสมัครหลีกเลี่ยงการกระพริบตาหรือขยับร่างกายในระหว่างการทดลอง นอกจากนี้ยังมีวิธีการพื้นฐานในการลบสิ่งประดิษฐ์ที่ไม่ต้องการโดยใช้ตัวกรองดิจิทัลที่ชื่อว่าตัวกรอง Butterworth เพื่อกรองความถี่ที่ต้องการ ซึ่งประกอบด้วยตัวกรองความถี่ต่ำผ่าน (Low-Pass Filter: LPF) เป็นตัวกรองที่ยอมให้สัญญาณความถี่ตั้งแต่ 0 เฮิรตซ์ จนถึงความถี่ที่กำหนดผ่านไปได้ โดยความถี่ที่สูงกว่านั้นจะถูกลดทอนไปตามลำดับ ตัวกรองความถี่สูงผ่าน (High-Pass Filter: HPF) เป็นตัวกรองที่ยอมให้สัญญาณความถี่ที่สูงกว่าความถี่ที่กำหนดผ่านไปได้ โดยที่ความถี่ที่ต่ำกว่านั้นจะถูกลดทอนไปตามลำดับ ตัวกรองแถบความถี่ผ่าน (Band-Pass Filter: BPF) เป็นตัวกรองที่ยอมให้ช่วงสัญญาณความถี่ที่กำหนดผ่านไปได้ โดยความถี่ที่ไม่ได้อยู่ในช่วงที่กำหนดจะถูกลดทอนจนหมดไปซึ่งเสมือนกับการนำตัวกรองความถี่ต่ำผ่านและตัวกรองความถี่สูงผ่านมาต่อรวมกัน และ สุดท้าย ตัวลดทอนสัญญาณช่วงความถี่ (Band Reject Filter Circuit, BRF) เป็นตัวกำจัดสัญญาณความถี่ที่ไม่ต้องการบางช่วงออกไปซึ่งเหมาะสำหรับการจัดการสิ่งประดิษฐ์จากไฟฟ้าบ้าน

2.5.3 การวิเคราะห์คลื่นไฟฟ้าสมองเพื่อดึงคุณลักษณะเด่นของคลื่น (Feature extraction)

การวิเคราะห์คลื่นไฟฟ้าสมองเพื่อหาคุณลักษณะที่เด่นชัดของคลื่นจะช่วยให้การแปลความหมายของคลื่นไฟฟ้าสมองทำได้ง่ายขึ้น วิธีการวิเคราะห์เพื่อหาคุณลักษณะที่เด่นชัดเป็นประเด็นที่ท้าทายอย่างยิ่งเนื่องจากข้อมูลที่แท้จริงของคลื่นไฟฟ้าสมองปะปนกับสัญญาณรบกวน นอกจากนี้รูปแบบของคลื่นไฟฟ้าสมองนั้นมีความไม่คงที่ (Non-stationary) โดยธรรมชาติ ซึ่งวิธีการแยกคุณลักษณะเด่นไม่กำหนดแนวทางชัดเจนขึ้นอยู่กับการนำไปประยุกต์ใช้งานในระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์แล้วได้ผลลัพธ์ที่ดี อย่างไรก็ตามมีเครื่องมือพื้นฐานที่ใช้งานอย่างแพร่หลายในการดึงข้อมูลคุณลักษณะของระบบการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์ดังนี้

การแปลงฟูเรียร์ (Fourier transform: FT)




รูปที่ 2.17 การแปลงฟูเรียร์

เป็นเทคนิคทางคณิตศาสตร์ โดยจะทำการแปลงสัญญาณจากโดเมนเวลา (Time-domain) ไปเป็นโดเมนความถี่ (Frequency-domain) หรือที่เรียกกันโดยทั่วไปว่าเป็นการหาสเปกตรัม (Spectrum) ของสัญญาณดังแสดงในรูปที่ 2.17 โดยสมการที่ใช้ในการวิเคราะห์สัญญาณด้วยการแปลงฟูเรียร์แสดงดังสมการที่ (2.1)

$$F(\omega) = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt \quad (2.1)$$

ในกรณีที่ข้อมูลมีความถี่สัญญาณหลายความถี่อยู่รวมกันเป็นจำนวนมากในเวลาเดียวกันการวิเคราะห์สัญญาณด้วยวิธีนี้นับว่ามีประโยชน์อย่างยิ่งเนื่องจากให้ค่าความแม่นยำทางความถี่สูง ถึงแม้ว่าวิธีการนี้ทำให้ทราบความถี่ที่ผสมกันภายในของสัญญาณแต่ไม่ทราบเวลาในการเกิดค่าความถี่นั้น ดังนั้นจึงเหมาะกับสัญญาณที่เป็นรายคาบ (Stationary signal) ที่มีความคงที่ของสัญญาณตลอดช่วงเวลา สำหรับกรณีที่สัญญาณไม่เป็นรายคาบ (Non-stationary signal) เช่น สัญญาณที่มีภาวะชั่วคราว สัญญาณที่มีการเปลี่ยนแปลงแบบทันทีทันใด เป็นต้น การวิเคราะห์สัญญาณเหล่านี้ อาจส่งผลให้เกิดความผิดพลาดไม่สามารถบ่งบอกข้อมูลในโดเมนเวลาได้




รูปที่ 2.18 การแปลงฟูเรียร์ในช่วงเวลาสั้น

การแปลงฟูเรียร์ในช่วงเวลาสั้น (Short-Time Fourier Transform: STFT) เป็นวิธีการที่ปรับปรุงแก้ไขข้อบกพร่องของวิธีการแปลงฟูเรียร์ โดยเป็นการวิเคราะห์ด้วยการแบ่งสัญญาณออกเป็นช่วงเวลาหนึ่งหรือเรียกว่าฟังก์ชันหน้าต่าง (Window function) และใช้การแปลงฟูเรียร์ในแต่ละช่วงเวลาฟังก์ชันหน้าต่างนี้เลื่อนไปดังแสดงในรูปที่ 2.18 สมการที่ใช้ในการวิเคราะห์สัญญาณด้วยการแปลงฟูเรียร์ในช่วงเวลาสั้นแสดงดังสมการที่ (2.2)

$$STFT(f, \tau) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-j\omega t} dt \quad (2.2)$$

เมื่อ $w(t - \tau)$ คือ Window function ที่ใช้ในการวิเคราะห์

โดยที่ตำแหน่งเวลาในการวิเคราะห์ถูกกำหนดโดยค่า τ และช่วงความถี่การวิเคราะห์กำหนดด้วยความกว้างของฟังก์ชันหน้าต่าง ผลการวิเคราะห์ด้วยฟูเรียร์ช่วงเวลาสั้นจะอยู่ในรูปของการแยกองค์ประกอบสัญญาณ ซึ่งจะสังเกตได้ว่าการแปลงฟูเรียร์ช่วงเวลาสั้น มีลักษณะของช่วงเวลาการวิเคราะห์ที่คงที่ (Fixed resolution transform) ดังนั้นการใช้ช่วงเวลาการวิเคราะห์สัญญาณที่คงที่ในการวิเคราะห์สัญญาณทุกช่วงความถี่จึงอาจไม่เหมาะสมในทางปฏิบัติ เนื่องจากสัญญาณที่มีความถี่สูงจะมีการเปลี่ยนแปลงที่รวดเร็วกว่าจึงควรจะใช้ช่วงเวลาแคบในการวิเคราะห์ ในขณะที่สัญญาณที่มีความถี่ต่ำจะมีการเปลี่ยนแปลงที่ช้าจึงควรใช้ช่วงเวลาที่กว้างกว่าในการวิเคราะห์ ด้วยเหตุผลนี้จึงได้มีการพัฒนารูปแบบการวิเคราะห์สัญญาณที่มีการปรับระดับความละเอียดในการวิเคราะห์ซึ่งเรียกว่าการแปลงเวฟเล็ต (Wavelet transform)



รูปที่ 2.19 การแปลงเวฟเล็ต

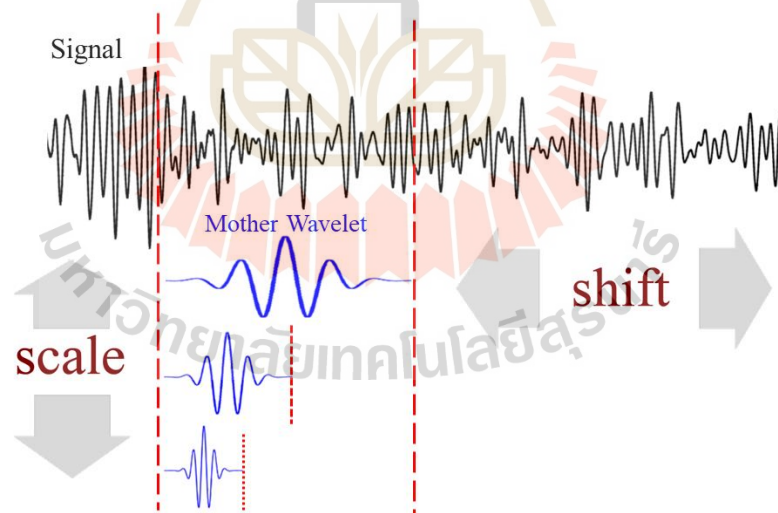
การวิเคราะห์สัญญาณด้วยวิธีการแปลงเวฟเล็ตได้รับการพัฒนาเพื่อใช้ในการแก้ปัญหาที่ไม่สามารถดำเนินการได้ในการแปลงฟูเรียร์และการแปลงฟูเรียร์ในช่วงเวลาสั้น โดยสามารถ

ปรับช่วงเวลาและความถี่ให้เหมาะสมตามความต้องการได้หากขยายช่วงเวลาของฟังก์ชันหน้าต่างให้ยาวขึ้นส่งผลให้ข้อมูลช่วงความถี่ต่ำมีความเที่ยงตรงและหากลดช่วงเวลาของฟังก์ชันหน้าต่างให้น้อยลงส่งผลให้ข้อมูลช่วงความถี่สูงมีความเที่ยงตรงเช่นกันแสดงในรูปที่ 2.19 โดยรูปแบบการแปลงเวฟเล็ตมี 2 ประเภทคือ การแปลงเวฟเล็ตแบบต่อเนื่อง (Continuous Wavelet Transform: CWT) และการแปลงเวฟเล็ตแบบเต็มหน่วย (Discrete Wavelet Transform: DWT)

การแปลงเวฟเล็ตแบบต่อเนื่องนั้นมีลักษณะการวิเคราะห์สัญญาณโดยอาศัยการปรับเปลี่ยนคุณสมบัติของเวฟเล็ตแม่ที่ใช้ในการวิเคราะห์ กล่าวคือการใช้ช่วงเวลาในการวิเคราะห์ที่แคบสำหรับการวิเคราะห์องค์ประกอบความถี่สูง และใช้ช่วงเวลาในการวิเคราะห์ที่กว้างสำหรับการวิเคราะห์องค์ประกอบความถี่ต่ำ โดยเป็นการปรับระดับความละเอียดในการวิเคราะห์อย่างต่อเนื่องตลอดการวิเคราะห์สัญญาณในทุกๆ ค่าของความถี่ตั้งสมการที่ (2.3)

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2.3)$$


- โดยที่ $f(t)$ คือ สัญญาณที่จะทำการแปลง
 $\psi(t)$ คือ เวฟเล็ตแม่ (Mother Wavelet)
 a คือ พารามิเตอร์ของการปรับขนาด (Scaling)
 b คือ พารามิเตอร์การเลื่อนตำแหน่ง (Shifting)



รูปที่ 2.20 การแปลงเวฟเล็ตแบบต่อเนื่อง

การปรับเปลี่ยนค่าพารามิเตอร์ของ a และ b ทำให้ช่วงที่มีความถี่สูงมีช่วงเวลาในการวิเคราะห์ที่แคบและในช่วงที่มีความถี่ต่ำมีช่วงเวลาที่กว้าง โดยเป็นผลรวมการคูณกันระหว่างสัญญาณในเชิงเวลากับฟังก์ชันเวฟเล็ตที่มีการปรับระดับสเกลและระดับการเลื่อนตำแหน่ง โดยเริ่มจากจุดเริ่มต้นของสัญญาณไปที่ละส่วนจนครบแล้วไล่จากสเกลต่ำสุดจนไปถึงการเพิ่มระดับสเกลขึ้นไป

จนครบทุกระดับสเกลที่ต้องการดังแสดงในรูปที่ 2.20 ทำให้ได้ค่าความถี่ที่แตกต่างกันออกไปในแต่ละระดับสเกล โดยผลจากการวิเคราะห์ที่ได้จะอยู่ในรูปของสัมประสิทธิ์เวฟเล็ต (Wavelet coefficient) ถึงแม้ว่าวิธีการนี้จะให้ค่าความแม่นยำทางด้านเวลาและความถี่สูงแต่ต้องใช้เวลาและทรัพยากรในการคำนวณความซับซ้อนสูงมาก

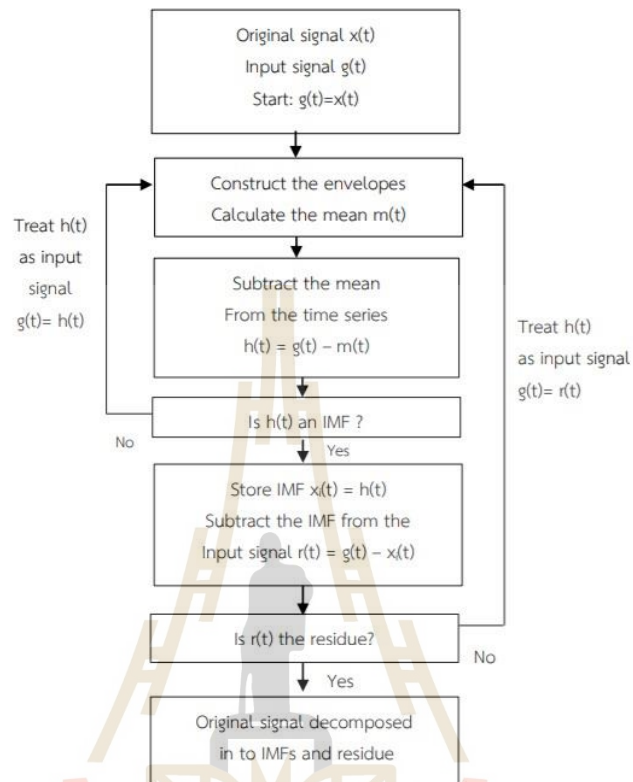


รูปที่ 2.21 การแปลงเวฟเล็ตแบบเต็มหน่วยระดับ 3

การแปลงเวฟเล็ตแบบเต็มหน่วยถูกพัฒนาขึ้นเพื่อลดความซับซ้อนและให้ข้อมูลเพียงพอสำหรับการวิเคราะห์และสังเคราะห์สัญญาณต้นฉบับ ซึ่งช่วยลดเวลาในการคำนวณลงอย่างมาก โดยมีรูปแบบการทำงานคือการปรับสเกลและการเลื่อนตำแหน่งในลักษณะเป็นช่วงๆ ที่ไม่ต่อเนื่องกัน โดยใช้การวิเคราะห์ด้วยตัวกรองสัญญาณ (Filter Bank Analysis) หลายระดับซึ่งเป็นการนำสัญญาณมาผ่านตัวกรองความถี่ต่ำแทนด้วยสัญลักษณ์ $g[n]$ และความถี่สูงแทนด้วยสัญลักษณ์ $h[n]$ เพื่อทำการแยกองค์ประกอบสัญญาณออกเป็น สัมประสิทธิ์ของส่วนที่มีความถี่ต่ำ (Approximation coefficient) และสัมประสิทธิ์ของส่วนที่มีความถี่สูง (Detail coefficient) โดยสัญญาณที่ได้มานั้นจะผ่านอัตราสุ่มลง (Down sampling) ด้วยทำให้จำนวนตัวอย่าง (Sample) ของผลลัพธ์ที่ได้ลดลงครึ่งหนึ่งจากสัญญาณต้นฉบับดังแสดงในรูปที่ 2.21

นอกจากนี้ยังมีวิธีการวิเคราะห์สัญญาณเพื่อดึงคุณลักษณะเด่นที่ชื่อว่า Empirical Mode Decomposition หรือ EMD ซึ่งเป็นวิธีการแยกองค์ประกอบของสัญญาณในโดเมนเวลา (Time-domain) โดยไม่ลดขนาดข้อมูลของสัญญาณต้นฉบับ วิธีการแบบ EMD มีการพิสูจน์แล้วว่ามีความมีประสิทธิภาพสำหรับการวิเคราะห์สัญญาณไม่คงที่ (Muñoz-Gutiérrez, Giraldo and Bueno-López, 2018; Ji, Ma, Dong and Zhang, 2019 และ Subasi, Jukic and Kevric, 2019) โดยมีหลักการว่าสัญญาณหนึ่งๆ จะประกอบด้วยสัญญาณที่มีการแกว่งไว (Fast Oscillation) และสัญญาณที่มีการแกว่งช้า (Slow Oscillation) ดังนั้นเมื่อต้องการแยกองค์ประกอบของสัญญาณจะใช้วิธีการดึงสัญญาณที่มีการแกว่งไวออกจากสัญญาณต้นฉบับทีละลำดับซึ่งเรียกว่า Intrinsic Mode functions : IMFs โดย IMFs มีเงื่อนไขในการพิจารณาดังนี้ 1) จำนวนจุดสูงสุด จุดต่ำสุด และจำนวนจุดตัดแกน


ศูนย์จะต้องมีค่าเท่ากัน หรือมีค่าต่างกันไม่เกินหนึ่ง 2) ณ จุดใดๆ ของสัญญาณค่าเฉลี่ยของขอบบน และขอบล่างจะมีค่าเท่ากับศูนย์



รูปที่ 2.22 กระบวนการทำงานของวิธีการแบบ EMD

กระบวนการทำงานของวิธีการแบบ EMD ที่ใช้สำหรับแยกองค์ประกอบจากสัญญาณต้นฉบับแสดงในรูปที่ 2.22 โดย Zeiler et al. (2010) ได้ให้รายละเอียดของขั้นตอนการทำงานดังนี้

- 1) หาจุดสูงสุดและจุดต่ำสุดตลอดช่วงของสัญญาณดังแสดงในรูปที่ 2.23




รูปที่ 2.23 จุดสูงสุด (สีแดง) และ จุดต่ำสุด (สีน้ำเงิน) ของแต่ละช่วงในสัญญาณต้นฉบับ ($x(t)$)

2) ลากเส้นเชื่อมต่อดจุดสูงสุดทั้งหมดในสัญญาณต้นฉบับและทำแบบเดียวกันกับจุดต่ำสุดดังแสดงในรูปที่ 2.24 แล้วคำนวณหาสัญญาณเฉลี่ยตามสมการที่ 2.4

$$m(t) = \frac{x_u(t) + x_l(t)}{2} \quad (2.4)$$

โดยที่ $x_u(t)$ คือ สัญญาณขอบบน

$x_l(t)$ คือ สัญญาณขอบล่าง




รูปที่ 2.24 สัญญาณขอบบน (เส้นสีเขียว) สัญญาณขอบล่าง (เส้นสีส้ม) และสัญญาณเฉลี่ย (เส้นสีแดง)

3) นำสัญญาณต้นฉบับมาลบออกด้วยสัญญาณเฉลี่ยจะได้สัญญาณผลลัพธ์ ($h(t)$)

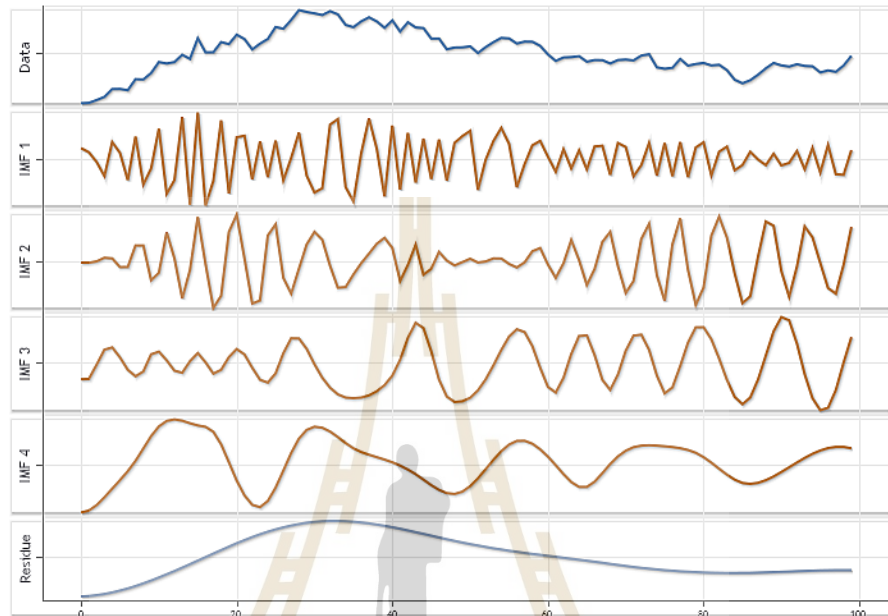
4) ตรวจสอบสัญญาณผลลัพธ์ว่าเป็นไปตามเงื่อนไขของ IMFs หรือไม่ ถ้าผลปรากฏว่าสัญญาณผลลัพธ์ที่ได้ไม่เป็น IMF ให้แทนที่สัญญาณต้นฉบับด้วยสัญญาณผลลัพธ์ ($x(t) = h(t)$) แล้วทำซ้ำกระบวนการเดิมตั้งแต่ขั้นตอนที่ 1-4 หากสัญญาณผลลัพธ์ที่ได้เป็น IMF ให้จัดเก็บสัญญาณผลลัพธ์นั้นพร้อมใส่เลขลำดับ ($h_j(t)$) , เมื่อ j คือลำดับที่สัญญาณเป็น IMF)

5) ทำการแยกองค์ประกอบในลำดับถัดไปโดยนำสัญญาณต้นฉบับลบด้วยสัญญาณผลลัพธ์ที่เป็น IMF ($h_j(t)$) จะได้สัญญาณใหม่ ($r(t)$)



รูปที่ 2.25 สัญญาณที่มีจุดสูงสุดและต่ำสุดเพียงตำแหน่งเดียว

6) ตรวจสอบสัญญาณใหม่ว่ามีจุดสูงสุดและจุดต่ำสุดเพียง 1 ตำแหน่ง ดังแสดงในรูปที่ 2.25 หรือไม่ ถ้าผลปรากฏว่าสัญญาณใหม่มีจุดสูงสุดและต่ำสุดมากกว่าหนึ่งตำแหน่งให้แทนที่สัญญาณต้นฉบับด้วยสัญญาณใหม่ ($r(t) = x(t)$) แล้วทำซ้ำกระบวนการเดิมตั้งแต่ขั้นตอนที่ 1-5 ถ้าผลปรากฏว่าสัญญาณใหม่มีจุดสูงสุดและต่ำสุดเพียงหนึ่งตำแหน่งถือว่าจบสิ้นกระบวนการ




รูปที่ 2.26 ตัวอย่างการแยกองค์ประกอบของสัญญาณด้วยวิธี EMD

ตัวอย่างการแยกองค์ประกอบของสัญญาณด้วยวิธี EMD สามารถอธิบายได้ด้วยรูปที่ 2.26 เมื่อสัญญาณต้นฉบับถูกแยกองค์ประกอบตามลำดับขั้นตอน จะได้ผลลัพธ์เป็น IMFs ซึ่งประกอบด้วย IMF1 ถึง IMF4 และส่วนที่เหลือเรียกว่า Residue โดย IMF ลำดับที่ 1 จะเป็นสัญญาณแบบแกว่งไว (มีการเปลี่ยนแปลงมากที่สุด) และ IMF ลำดับสุดท้ายจะเป็นสัญญาณแบบแกว่งช้า (มีการเปลี่ยนแปลงน้อย) และ Residue คือ สัญญาณที่มีการแกว่งช้าที่สุด (มีการเปลี่ยนแปลงน้อยที่สุด)

2.5.4 การจำแนกรูปแบบของคลื่นไฟฟ้าสมอง (Classification)

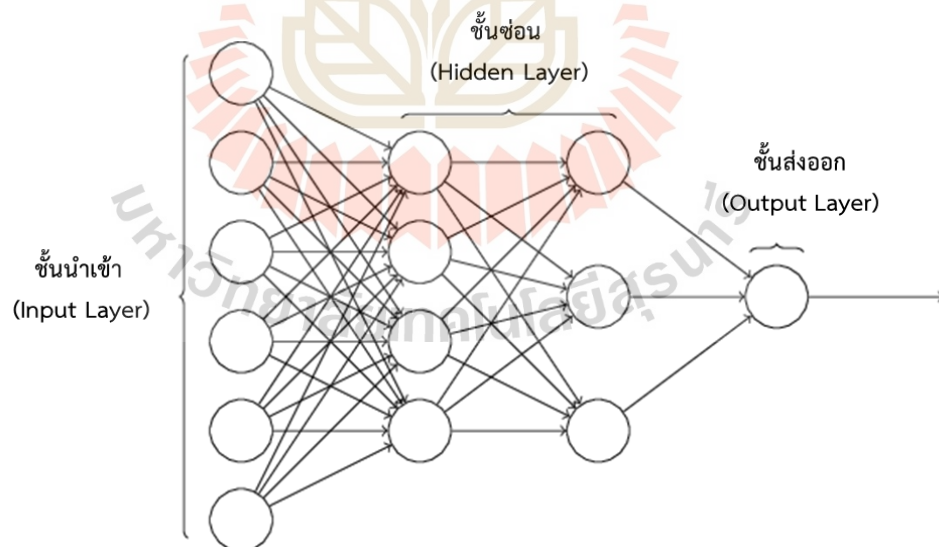
เป็นขั้นตอนการแปลความหมายของคลื่นไฟฟ้าสมองโดยใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine learning) ซึ่งเป็นเทคโนโลยีที่มีวิธีการจำแนกรูปแบบหลากหลายวิธี หนึ่งในวิธีการที่ได้รับความนิยมมากที่สุดคือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) โดยโครงข่ายประสาทเทียมเป็นโมเดลทางคณิตศาสตร์ที่จำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือที่มีความสามารถในการเรียนรู้ (Learning) การจดจำรูปแบบ (Pattern Recognition) การจัดกลุ่ม (Clustering) การจำแนกรูปแบบ (Classification) และการทำนาย (Prediction) เช่นเดียวกับความสามารถของสมองมนุษย์ ซึ่งกระบวนการทำงานพื้นฐานของโครงข่ายประสาทเทียมจะประกอบไปด้วย ข้อมูลนำเข้า ($X(n) = x_1, x_2, x_3, \dots, x_n$) คูณกับค่า

ถ่วงน้ำหนัก ($W_j = w_{1j}, w_{2j}, w_{3j}, \dots, w_{nj}$) ซึ่งผลคูณระหว่างค่าทั้งสองจะถูกนำมารวมกันและส่งเขาไปในฟังก์ชันกระตุ้น (Activation Function) หรือเรียกว่าฟังก์ชันตัดสินใจเพื่อคำนวณความเป็นไปได้ของคำตอบแล้วส่งผลลัพธ์ออกไปที่ข้อมูลส่งออกดังแสดงในภาพที่ 2.27




รูปที่ 2.27 โครงสร้างแบบจำลองพื้นฐานของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมแบบพื้นฐานมักจะใช้หาคำตอบที่ไม่ซับซ้อน เช่น คำถามแบบไบนารี (Binary) ที่ต้องการคำตอบเป็น "ใช่" หรือ "ไม่ใช่" ในขณะที่การหาคำตอบที่ซับซ้อนกว่า เช่น การจดจำรูปแบบหรือการจำแนกรูปแบบของข้อมูล โครงข่ายประสาทเทียมจะมีโครงสร้างแบบหลายชั้น (Multi-layer perceptron Neural Network) ดังแสดงในรูปที่ 2.28



รูปที่ 2.28 โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้น



รูปที่ 2.29 โครงสร้างภายในของโครงข่ายประสาทเทียมแบบหลายชั้น

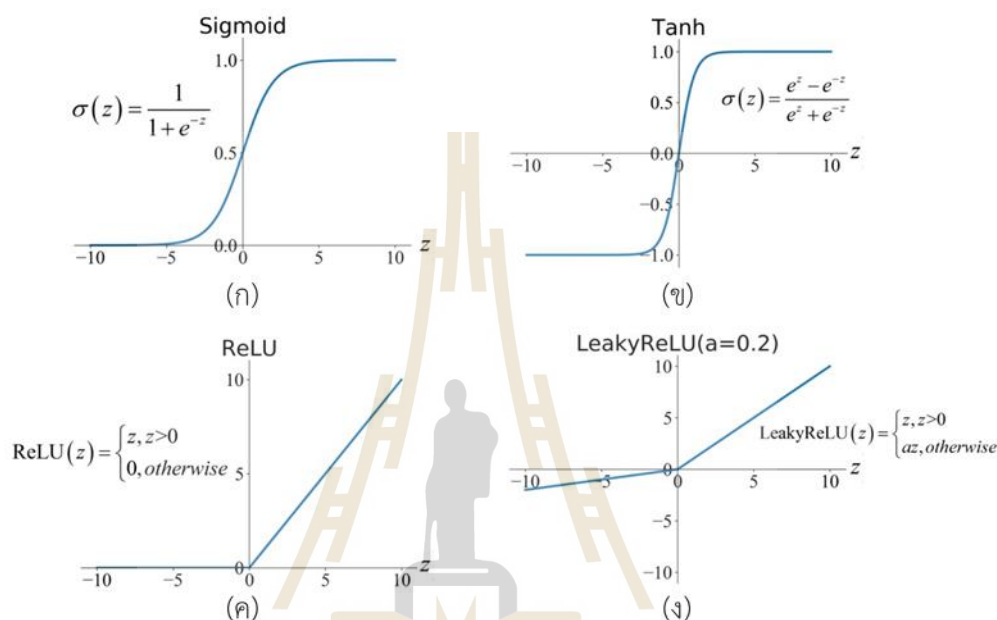
โครงข่ายประสาทเทียมแบบหลายชั้นประกอบไปด้วย 1. ชั้นนำเข้า (Input Layer) 2. ชั้นซ่อน (Hidden Layer) 3. ชั้นส่งออก (Output Layer) โดยในแต่ละชั้นจะประกอบด้วยหน่วย (Node) หรือนิวรอน (Neuron) ซึ่งจะทำหน้าที่ในการประมวลผลและเชื่อมต่อผลลัพธ์ไปยังชั้นถัดไป การเชื่อมต่อของแต่ละชั้นจะเป็นแบบถึงกันหมดจึงทำให้ข้อมูลเคลื่อนที่ไปในทิศทางเดียวคือเคลื่อนที่ไปข้างหน้าจากชั้นนำเข้าไปยังชั้นส่งออก โดยจำนวนชั้นซ่อนและหน่วยในแต่ละชั้นซ่อนจะขึ้นอยู่กับความซับซ้อนของปัญหา ส่วนจำนวนหน่วยในชั้นนำเข้าจะขึ้นกับจำนวนข้อมูลที่ต้องการให้โครงข่ายประสาทเทียมเรียนรู้ และจำนวนหน่วยในชั้นส่งออกคือผลลัพธ์ที่ต้องการจากโครงข่าย รายละเอียดภายในโครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้นแสดงในรูปที่ 2.29 และค่าผลลัพธ์จากแต่ละหน่วยจะสามารถหาได้จากสมการที่ 2.5 และ 2.6 ดังนี้

$$h_j = f \left(\sum_{n=1}^N (w_{n,j} x_n) + b_j \right) \quad (2.5)$$

$$y_k = f \left(\sum_{j=1}^J (w_{j,k} h_j) + b_k \right) \quad (2.6)$$

- โดยที่ h_j คือ ค่าผลลัพธ์ที่ได้จากการประมวลผลของหน่วยที่ j ในชั้นซ่อน
 y_k คือ ค่าผลลัพธ์ที่ได้จากการประมวลผลของหน่วยที่ k ในชั้นส่งออก
 w คือ ค่าถ่วงน้ำหนัก (Weight)
 b คือ ค่าเบี่ยงเบน (Bias)
 n คือ ลำดับของหน่วยในชั้นนำเข้ามีทั้งหมด N หน่วย
 j คือ ลำดับของหน่วยในชั้นซ่อนมีทั้งหมด J หน่วย
 k คือ ลำดับของหน่วยในชั้นส่งออกมีทั้งหมด K หน่วย
 $f(c)$ คือ ฟังก์ชันกระตุ้นหรือฟังก์ชันตัดสินใจ

ฟังก์ชันกระตุ้นเป็นฟังก์ชันในการคำนวณเพื่อทำนายค่าของผลลัพธ์ในแต่ละหน่วย รูปแบบที่นิยมมากที่สุดคือแบบที่ไม่เป็นฟังก์ชันสมการเส้นตรง (Non-linear function) เนื่องจากปัญหาในโลกความเป็นจริงมีลักษณะเป็นแบบสมการเส้นตรงน้อยมาก ฟังก์ชันกระตุ้นจะถูกนำไปใช้ใน แต่ละหน่วยของชั้นซ่อน (Hidden node) และชั้นส่งออก (Output node) ซึ่งทั้งสองหน่วยอาจจะใช้ ฟังก์ชันกระตุ้นที่เหมือนหรือต่างกันได้ โดยชนิดของฟังก์ชันกระตุ้นที่ได้รับความนิยมมีดังต่อไปนี้



รูปที่ 2.30 ชนิดของฟังก์ชันกระตุ้นที่ได้รับความนิยม (Feng et al., 2019)

(ก) Sigmoid Function

(ข) Hyperbolic Tangent Function: Tanh

(ค) Rectified Linear Units: ReLU

(ง) Leaky ReLU

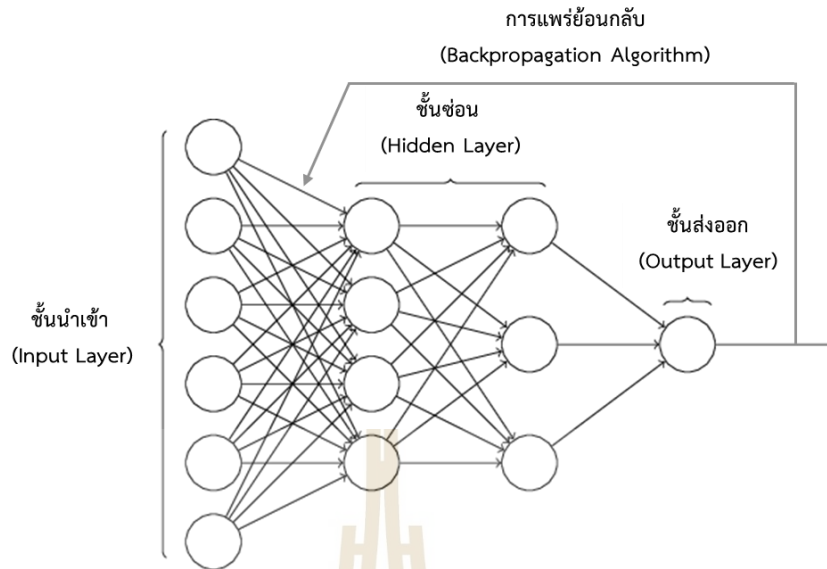
ซึ่งในแต่ละชนิดของฟังก์ชันกระตุ้นมีขอบเขตและการทำงานที่แตกต่างกันอธิบายได้ ดังนี้ Sigmoid Function เป็นฟังก์ชันทางคณิตศาสตร์ที่มีลักษณะเป็นตัวเอส “S-curve” หรือเรียกว่า “Sigmoid curve” จะมีขอบเขตอยู่ระหว่าง $[0,1]$ ดังแสดงในรูปที่ 2.30 (ก) ฟังก์ชันนี้จะใช้เมื่อ ต้องการทำนายความน่าจะเป็น (Probability) ของข้อมูล ในขณะที่ฟังก์ชันไฮเปอร์โบลิค Hyperbolic Tangent Function มีการทำงานคล้ายกับ Sigmoid Function แต่มีประสิทธิภาพดีกว่ามีขอบเขตอยู่ ระหว่าง $[-1,1]$ ดังแสดงในรูปที่ 2.30 (ข) ข้อดีของฟังก์ชันนี้คือสามารถแปลงค่าของข้อมูลนำเข้าที่มี ค่าเป็นลบมาก ๆ ให้เป็นข้อมูลส่งออกที่ติดลบได้และข้อมูลที่มีค่าเป็นศูนย์จะถูกแปลงเป็นข้อมูล ส่งออกที่มีค่าใกล้ศูนย์ ส่วน Rectified Linear Units เป็นฟังก์ชันที่นิยมใช้งานมากที่สุดในโครงข่าย

ประสาทเทียมฟังก์ชันนี้จะมีขอบเขตอยู่ระหว่าง $[0, \infty)$ ดังแสดงในรูปที่ 2.30 (ค) ซึ่งหมายความว่าถ้าข้อมูลนำเข้ามีค่ามากกว่าศูนย์ข้อมูลส่งออกจะเป็นค่าบวกและถ้าข้อมูลนำเข้ามีค่าศูนย์หรือติดลบข้อมูลส่งออกจะมีค่าเป็นศูนย์ แต่อย่างไรก็ตามการแปลงค่าของข้อมูลนำเข้าที่เป็นลบให้เป็นศูนย์ทั้งหมดนั้นจะลดความสามารถในการเรียนรู้ข้อมูลนำเข้าของโครงข่ายประสาทเทียม จึงได้มีการพัฒนาฟังก์ชัน Leaky ReLu เพื่อขยายขอบเขตออกไปเป็น $(-\infty, \infty)$ ดังแสดงในรูปที่ 2.30 (ง) การเลือกใช้ฟังก์ชันกระตุ้นสำหรับหน่วยในชั้นซ่อนและชั้นข้อมูลส่งออกไม่มีแนวทางที่กำหนดไว้ขึ้นอยู่กับปัจจัยหลายอย่าง เช่น รูปแบบของปัญหา ความเร็วในการเรียนรู้ของโครงข่ายประสาทเทียม ขอบเขตของผลลัพธ์ที่ต้องการแก้ปัญหา เป็นต้น

โครงข่ายประสาทเทียมใช้กระบวนการเรียนรู้ข้อมูลโดยการปรับค่าน้ำหนักให้เป็นค่าที่เหมาะสมที่สุดซึ่งมีอยู่ 2 ประเภทคือ

1) การเรียนรู้แบบไม่มีการสอน (Unsupervised Learning) เป็นวิธีการเรียนรู้แบบไม่มีการกำหนดป้ายกำกับ (Label) หรือประเภท (Class) ของข้อมูลให้กับโครงข่ายประสาทเทียม ซึ่งโครงข่ายประสาทเทียมจะจัดเรียงโครงสร้างด้วยตัวเองตามคุณลักษณะของข้อมูลที่ได้รับ ผลลัพธ์ของโครงข่ายประเภทนี้จะเป็นการระบุกลุ่มของข้อมูลที่ใส่เข้าไปโดยอิงจากวิธีการจัดกลุ่มซึ่งได้เรียนรู้จากข้อมูลที่โครงข่ายเคยพบมา

2) การเรียนรู้แบบมีการสอน (Supervised Learning) เป็นการเรียนรู้ที่มีการกำหนดป้ายกำกับ (Label) หรือประเภท (Class) ของข้อมูลให้กับโครงข่ายประสาทเทียม เพื่อให้โครงข่ายนำค่าผลลัพธ์ที่คำนวณได้ไปเปรียบเทียบกับความถูกต้องกับข้อมูลที่ได้เรียนรู้ ซึ่งโครงข่ายประสาทเทียมจะปรับตัวเองเพื่อให้ได้ค่าผลลัพธ์ที่ใกล้เคียงกับข้อมูลที่ได้เรียนรู้มากที่สุด วิธีการปรับตัวเองดังกล่าวคือวิธีการแบบแพร่ย้อนกลับ (Backpropagation Algorithm) แนวความคิดคือการหาค่าความผิดพลาด (Error) ที่เกิดขึ้นในแต่ละหน่วยของชั้นส่งออก โดยทำการเปรียบเทียบระหว่างค่าผลลัพธ์ที่คำนวณได้จากโครงข่ายกับค่าผลลัพธ์ที่กำหนดไว้ ซึ่งถ้าหากค่าความผิดพลาดมากกว่าค่าที่ยอมรับได้โครงข่ายประสาทเทียมจะปรับค่าถ่วงน้ำหนักใหม่ในทิศทางย้อนกลับจากชั้นส่งออกไปสู่ชั้นนำเข้าจนกว่าจะได้ค่าความผิดพลาดที่ยอมรับได้ดังแสดงในรูปที่ 2.31



รูปที่ 2.31 โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้นทำงานร่วมกับการแพร่ย้อนกลับ การหาค่าความผิดพลาดของชั้นส่งออกสามารถคำนวณได้จากสมการที่ 2.7

$$e = \frac{1}{2} \sum_{k=1}^K (y_{t,k} - y_k)^2 \quad (2.7)$$

โดยที่ e คือ ค่าความผิดพลาดของชั้นส่งออก

$y_{t,k}$ คือ ค่าผลลัพธ์ที่กำหนดให้โครงข่ายในหน่วยที่ k ของชั้นส่งออก

y_k คือ ค่าผลลัพธ์ที่ได้จากการประมวลผลของหน่วยที่ k ในชั้นส่งออก

ถ้าหากค่าความผิดพลาดที่เกิดขึ้นมีค่ามากกว่าศูนย์จะส่งผลต่อการเรียนรู้ข้อมูลของโครงข่ายประสาทเทียม ดังนั้นโครงข่ายจึงต้องปรับค่าถ่วงน้ำหนักใหม่ในทิศทางย้อนกลับจากชั้นส่งออกไปสู่ชั้นนำเข้าจนกว่าค่าความผิดพลาดจะใกล้เคียงศูนย์มากที่สุดดังสมการที่ 2.8 และ 2.9

$$w_{j,k}^{(r+1)} = w_{j,k}^{(r)} + \eta((y_{t,k} - y_k) * (y_k(1 - y_k)) * h_j) \quad (2.8)$$

$$w_{n,j}^{(r+1)} = w_{n,j}^{(r)} + \eta \left(\sum_{k=1}^K (y_{t,k} - y_k) (y_k(1 - y_k)) w_{j,k}^{(r)} * (h_j(1 - h_j)) (x_n) \right) \quad (2.9)$$

โดยที่ $w_{j,k}^{(r+1)}$ คือ ค่าน้ำหนักที่ถูกปรับระหว่างหน่วยในชั้นส่งออกกับชั้นซ่อน


$w_{n,j}^{(r+1)}$ คือ ค่าน้ำหนักที่ถูกปรับระหว่างหน่วยในชั้นซ่อนกับชั้นนำเข้า

r คือ ลำดับรอบในการปรับค่าน้ำหนัก

η คือ อัตราการเรียนรู้มีค่าอยู่ระหว่าง 0 ถึง 1


2.6 งานวิจัยที่พัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมอง

ระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองเป็นการประยุกต์จากแนวความคิดการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์โดยอาศัยการตรวจจับการตอบสนองของสมองที่เกิดจากสิ่งกระตุ้นหรือการกระทำตามที่ได้กล่าวไว้ก่อนหน้านี้ ซึ่งในปัจจุบันระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองสามารถแบ่งออกเป็น 3 ระบบ ได้แก่ P300-speller SSVEP-speller และ Motor Imagery




รูปที่ 2.32 รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองชนิด P300

Vansteensel and Jarosiewicz (2020) อธิบายว่า Farwell และ Donchin เป็นนักวิจัยกลุ่มแรกที่น่าเสนอระบบการพิมพ์ตัวอักษรด้วยการตรวจจับการตอบสนองของสมองที่เรียกว่า Event-Related Potential: ERP ชนิด P300 ซึ่งเกิดจากการจ้องมองตัวอักษรที่มีการกระพริบเป็นแถวและคอลัมน์อย่างต่อเนื่อง โดยคลื่นไฟฟ้าสมองของอักษรเป้าหมายที่ถูกจ้องมองจะมีระดับความแรงของสัญญาณสูงกว่าตำแหน่งอื่นดังแสดงในรูปที่ 2.33 ดังนั้นวิธีการสื่อสารด้วยคลื่นไฟฟ้าสมองในลักษณะนี้จึงมีชื่อเรียกว่า P300-speller และมีงานวิจัยมากกว่า 2,000 เรื่องที่พยายามปรับปรุงประสิทธิภาพของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองชนิด P300 โดยการลดสัญญาณรบกวนหรือปรับรูปแบบของสิ่งเร้าให้เกิดประโยชน์สูงสุดต่อการตอบสนองของสมอง (Kaufmann, Schulz, Grünzinger and Kübler, 2011; Sellers, Arbel and Donchin, 2012 และ Powers, Bieliaieva, Wu, and Nam, 2015)




รูปที่ 2.33 รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองชนิด SSVEP (Segers, et al., 2011)



รูปที่ 2.34 แป้นพิมพ์ตัวอักษรสำหรับการสื่อสารด้วยคลื่นไฟฟ้าสมอง (Hwang, Lim et al., 2012)

ในเวลาต่อมาได้มีการพัฒนาระบบการพิมพ์ตัวอักษรจากการตอบสนองของสมองที่เกิดจากสิ่งเร้าทางสายตาที่สั้นหรือกระพริบที่ความถี่ที่หรือเรียกว่าการตอบสนองแบบ Steady-State Visual- Evoked Potential: SSVEP ซึ่งวิธีการสื่อสารด้วยคลื่นไฟฟ้าสมองในลักษณะนี้มีชื่อเรียกว่า SSVEP-speller งานวิจัยของ Segers, et al. (2011) ได้เสนอแนวทางการสื่อสารโดยใช้วิธีการดังกล่าว ซึ่งผู้ใช้งานจะจดจ้องไปที่สิ่งเร้ารูปกล่องสี่เหลี่ยมจนกว่าจะได้กล่องที่มีตัวอักษรและสัญลักษณ์ที่ต้องการสื่อสารบรรจุอยู่ ดังแสดงในรูปที่ 2.33

Hwang, Lim, et al. (2012) ได้เสนอแนวทางการสื่อสารแบบ SSVEP ที่ผู้ใช้สามารถเลือกตัวอักษรที่ต้องการได้ด้วยการจดจ้องสิ่งเร้าเพียงครั้งเดียว โดยหลักการคือการสร้างแป้นพิมพ์ที่มีอักษรสามสิบตัว (ตัวอักษรภาษาอังกฤษ 26 ตัวและสัญลักษณ์พิเศษ 4 ตัว) โดยใช้ไดโอดเปล่งแสง (LED) จำนวน 30 ตัวกะพริบที่ความถี่ต่างกัน 0.1 Hz ดังแสดงในรูปที่ 2.34 เทคนิคนี้ช่วยให้การสื่อสารด้วยคลื่นไฟฟ้าสมองสามารถดำเนินการได้รวดเร็วขึ้น



รูปที่ 2.35 รูปแบบของระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองแบบ Motor Imagery

Blankertz et al. (2006) ได้เสนอแนวทางการพิมพ์ตัวอักษรด้วยการตรวจจับการตอบสนองของสมองที่เกิดจากการจินตนาการการเคลื่อนไหวมือและเท้า โดยตัวอักษรจะอยู่ในกล่องหกเหลี่ยมที่อยู่ติดกันหกรูปรอบวงกลมและมีลูกศรอยู่ตรงกลางวงกลม การจินตนาการถึงการเคลื่อนไหวของมือจะทำหน้าที่ควบคุมการหมุนของลูกศรในทิศทางตามเข็มนาฬิกาและการจินตนาการถึงการเคลื่อนไหว

ของเท้าจะทำหน้าที่ขยายความยาวของลูกศรออกไปจนถึงรูปหกเหลี่ยมที่มีตัวอักษรที่ต้องการจะสื่อสารบรรจุอยู่ดังแสดงในรูปที่ 2.35 ซึ่งความเร็วของการพิมพ์ตัวอักษรภายใต้แนวความคิดนี้น้อยกว่าระบบ P300-speller และ SSVEP-speller ส่งผลให้แนวทางนี้มีถูกนำไปใช้ในการพัฒนาระบบเพื่อควบคุมอุปกรณ์มากกว่าระบบการสื่อสารด้วยคลื่นไฟฟ้าสมอง (Yuan and He, 2014)

2.7 สรุป

จากเนื้อหาที่กล่าวมาข้างต้นในบทนี้ พบว่าสมองของมนุษย์มีการทำงานที่แตกต่างกันไปในแต่ละพื้นที่ ซึ่งการเก็บข้อมูลจากสมองจะช่วยให้เข้าใจเกี่ยวกับการทำงานของสมองมนุษย์มากขึ้น โดยวิธีการที่ได้รับความนิยมมากที่สุดคือการเก็บข้อมูลสมองแบบไม่รุกรานด้วยการวัดคลื่นไฟฟ้าสมอง เนื่องจากมีข้อดีหลายประการ เช่น ความปลอดภัยสูง ความง่ายของกระบวนการเก็บข้อมูล เป็นต้น โดยวิธีการใช้ประโยชน์จากข้อมูลคลื่นไฟฟ้าสมองคือการนำข้อมูลไปวิเคราะห์และทำงานร่วมกับคอมพิวเตอร์หรือเรียกว่าการเชื่อมต่อระหว่างสมองกับคอมพิวเตอร์ซึ่งมีองค์ประกอบดังนี้ 1. การเก็บข้อมูลจากสัญญาณคลื่นไฟฟ้าสมอง 2. การประมวลผลสัญญาณคลื่นไฟฟ้าสมองเพื่อแปลความหมายให้กลายเป็นคำสั่งในการควบคุม และ 3. ระบบสำหรับนำคำสั่งไปใช้งานและแสดงผลลัพธ์หรือเรียกว่าการป้อนกลับ นอกจากนี้การสำรวจปริทัศน์วรรณกรรมที่เกี่ยวข้องยังพบว่างานวิจัยที่ผ่านมาเกี่ยวกับระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองจะต้องใช้การกระตุ้นตลอดเวลา ดังนั้นผู้วิจัยจึงเสนอแนวความคิดใหม่ในการพัฒนาระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่ต้องจินตนาการถึงการเคลื่อนไหวแขนหรือขาและไม่ใช้การกระตุ้นจากสิ่งเร้าภายนอก ซึ่งจะอธิบายในบทถัดไป

บทที่ 3

วิธีการดำเนินการวิจัย

3.1 บทนำ

เนื้อหาในบทนี้จะกล่าวถึงการออกแบบระบบการสื่อสารด้วยสัญญาณคลื่นไฟฟ้าสมองโดยไม่ใช้การกระตุ้นจากสิ่งเร้าภายนอก แต่จะใช้การจินตนาการถึงองค์ประกอบของตัวอักษรที่ต้องการสื่อสารโดยตรง ซึ่งขั้นตอนในการดำเนินการวิจัยประกอบไปด้วย 3 ส่วนหลักดังนี้ 1) การเก็บข้อมูลคลื่นไฟฟ้าสมองจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร 2) การวิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร และ 3) จำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

3.2 การเก็บข้อมูลคลื่นไฟฟ้าสมองจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

3.2.1 กำหนดเกณฑ์การคัดเลือกอาสาสมัคร

- (1) มีความยินยอมเข้าร่วมการทดลองตามที่ผู้วิจัยกำหนด
- (2) ไม่ได้รับผลกระทบหรือประวัติการรักษาที่เกี่ยวกับระบบประสาทและสมอง
- (3) ไม่มีประวัติการเจ็บป่วยทางจิต การใช้ยาทางจิตเวช หรือสารเสพติดที่มีผลต่อระบบประสาท

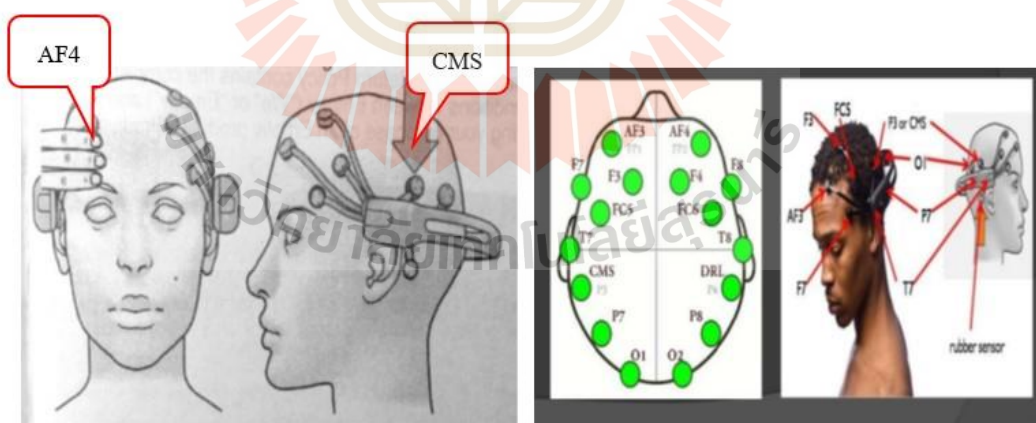
3.2.2 การเตรียมอุปกรณ์บันทึกสัญญาณคลื่นไฟฟ้าสมอง



รูปที่ 3.1 อุปกรณ์บันทึกสัญญาณแบบไร้สาย (ก) และ ตำแหน่งอิเล็กโทรดของอุปกรณ์ (ข)

ในงานวิจัยนี้ใช้อุปกรณ์บันทึกสัญญาณคลื่นไฟฟ้าสมองที่มีชื่อว่า Emotiv รุ่น EPOC+ ดังแสดงในรูปที่ 3.1(ก) และมีอิเล็กโทรดสำหรับวัดคลื่นไฟฟ้าสมองทั้งหมด 14 ตำแหน่ง ดังแสดงในรูปที่ 3.1(ข) โดยอุปกรณ์มีราคาไม่แพง มีความสะดวกในการใช้งานเนื่องจากเป็นการส่งข้อมูลแบบไร้สาย ซึ่งตัวอุปกรณ์มีข้อมูลทางเทคนิคดังนี้

- (1) Number of Channels: 14 (Plus CMS/ DRL References)
- (2) Channel Names (Int. 10-20 locations): AF3, AF4, F3, F4, F7, F8, FC5, FC6, P3 (CMS), P4 (DRL), P7, P8, T7, T8, O1, and O2
- (3) Sampling Method: Sequential Sampling, Single ADC
- (4) Sampling Rate: ~128Hz (2048Hz Internal)
- (5) Resolution: 16 Bits (14 Bits Effective) 1 LSB = 0.51 μV
- (6) Bandwidth: 0.2 - 43Hz, Digital Notch Filters at 50Hz and 60Hz
- (7) Dynamic Range (Input Referred): 8400 μV (pp)
- (8) Coupling Mode: AC coupled
- (9) Connectivity: Proprietary Wireless, 2.4 GHz Band.
- (10) Battery Type: Li-poly
- (11) Battery Life (Typical): 12 hrs.

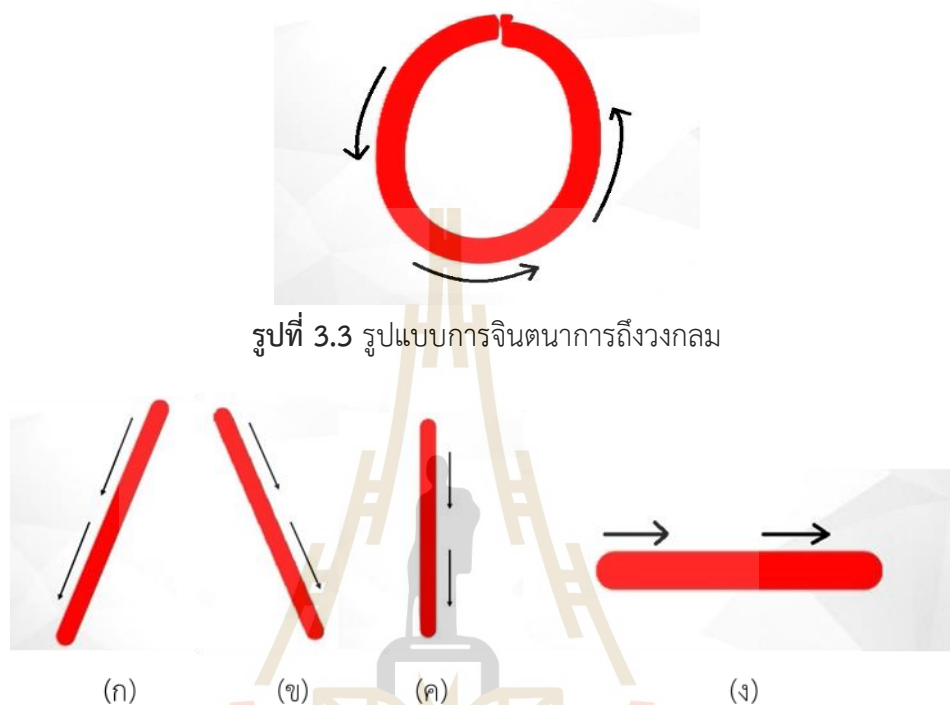


รูปที่ 3.2 การติดตั้งเครื่องบันทึกสัญญาณคลื่นไฟฟ้าสมอง

การติดตั้งอุปกรณ์บันทึกสัญญาณคลื่นไฟฟ้าสมองบนศีรษะของอาสาสมัครจะต้องปรับตำแหน่งอิเล็กโทรดให้ตรงกับตำแหน่งต่างๆ ที่กำหนดไว้ในคู่มือการใช้งาน เช่น ตำแหน่งของอิเล็กโทรด AF4 จะต้องติดตั้งอยู่ที่ระยะเหนือหางคิ้วประมาณสามนิ้วมือและตำแหน่ง CMS หรือ P3

ต้องติดตั้งอยู่บริเวณขมับดังแสดงในรูปที่ 3.2 รวมไปถึงการทำความสะอาดหนังศีรษะด้วยสาลีชุบแอลกอฮอล์ 75% เพื่อขจัดเซลล์ที่ตายแล้วออกไปและลดความต้านทานบริเวณหนังศีรษะ

3.2.3 กำหนดรูปแบบของการจินตนาการให้มีมาตรฐานเดียวกัน



รูปที่ 3.4 การจินตนาการถึงเส้นตรงในรูปแบบต่างๆ

- (ก) เส้นตรงเอียงซ้าย
- (ข) เส้นตรงเอียงขวา
- (ค) เส้นตรงแนวตั้ง
- (ง) เส้นตรงแนวนอน

เนื่องจากอาสาสมัครแต่ละคนไม่สามารถจินตนาการถึงรูปแบบการเขียนเดียวกันได้ ดังนั้นการใช้รูปแบบการเขียนที่เป็นมาตรฐานเดียวกันจึงเป็นเรื่องสำคัญเพื่อให้อาสาสมัครสามารถจินตนาการไปในทิศทางเดียวกันได้ โดยที่ตัวอักษรนั้นถูกสร้างขึ้นด้วยองค์ประกอบของเส้นต่างๆ เช่น เส้นตรง เส้นโค้ง หรือ เส้นเอียง รวมถึงในบางตัวอักษรอาจมีวงกลมด้วย ดังนั้นจึงมีมาตรฐานในการลากเส้นสำหรับแต่ละตัวอักษร ยกตัวอย่างเช่นตัวอักษรภาษาอังกฤษ I หรือตัวอักษรที่ถูกสร้างขึ้นตามแนวตั้งจะต้องลากเส้นจากบนลงล่าง ถ้าเป็นอักษรที่เขียนในแนวราบ เช่น ส่วนล่างของตัว L หรือส่วนบนของตัว T จะต้องลากเส้นจากซ้ายไปขวา ในงานวิจัยนี้จึงออกแบบภาพเคลื่อนไหวของเส้นต่างๆ ที่เป็นส่วนประกอบของตัวอักษรดังแสดงในรูปที่ 3.3 และ 3.4


3.2.4 ลดปัจจัยที่จะส่งผลกระทบต่อคลื่นไฟฟ้าสมอง

เนื่องจากคลื่นไฟฟ้าสมองเป็นคลื่นที่ไวต่อสัญญาณรบกวนอย่างมาก ดังนั้นจึงขอให้อาสาสมัครปฏิบัติตามข้อกำหนดดังนี้


- (1) อาสาสมัครแต่ละคนจะต้องมองภาพเคลื่อนไหวที่ถูกสร้างขึ้นและทำความเข้าใจในการลากเส้นของภาพเพื่อใช้ในการจินตนาการถึงรูปแบบการเขียน
- (2) ก่อนการบันทึกสัญญาณคลื่นไฟฟ้าสมองอาสาสมัครจะต้องทำสมาธิเป็นระยะเวลา 2 นาที
- (3) ในระหว่างการบันทึกสัญญาณคลื่นไฟฟ้าสมองอาสาสมัครต้องหลีกเลี่ยงการกระพริบตา การเคลื่อนไหวดวงตาและการขยับร่างกาย

นอกจากนี้เพื่อลดปัจจัยที่จะส่งผลกระทบต่อคลื่นไฟฟ้าสมองเนื่องจากความเหนื่อยล้าของสมอง การบันทึกสัญญาณคลื่นไฟฟ้าสมองจึงมีการแบ่งรอบในการบันทึกสัญญาณเพื่อให้สมองได้มีช่วงเวลาในการพัก

3.2.5 พัฒนาโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง



รูปที่ 3.5 ผังการทำงานของโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง




รูปที่ 3.6 หน้าตาของโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมอง



รูปที่ 3.7 การแสดงภาพเคลื่อนไหวของรูปแบบวงกลม

ภาพรวมกระบวนการทำงานของโปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมองแสดงในรูปที่ 3.5 ซึ่งสามารถแบ่งออกเป็น 3 ส่วนหลักดังนี้ 1) อาสาสมัครคัดเลือกรูปแบบของการจินตนาการถึงองค์ประกอบของตัวอักษร ได้แก่ วงกลม เส้นตรงเอียงซ้ายและขวา เส้นตรงแนวตั้งและเส้นตรงแนวนอนดังแสดงในรูปที่ 3.6 2) หลังจากคัดเลือกแล้วโปรแกรมจะทำการตรวจสอบระดับการทำสมาธิของอาสาสมัคร ถ้าหากไม่ผ่านเกณฑ์โปรแกรมจะให้เลือกรูปแบบการจินตนาการใหม่ แต่ถ้าหากผ่านเกณฑ์ที่กำหนดไว้โปรแกรมจะแสดงภาพเคลื่อนไหวเป็นเวลา 7 วินาที โดยมีการนับถอยหลัง 3 วินาที เพื่อให้อาสาสมัครพร้อมสำหรับการจินตนาการดังแสดงในรูปที่ 3.7 และ 3) โปรแกรมจะบันทึกคลื่นไฟฟ้าสมองของอาสาสมัครในขณะที่กำลังจินตนาการตามภาพเคลื่อนไหวที่เลือก

3.2.6 การเก็บข้อมูลคลื่นไฟฟ้าสมอง



รูปที่ 3.8 กระบวนการเก็บข้อมูลคลื่นไฟฟ้าสมอง

การเก็บข้อมูลคลื่นไฟฟ้าสมองจากอาสาสมัครจะดำเนินการด้วยขั้นตอนดังนี้ 1) อาสาสมัครสวมอุปกรณ์วัดคลื่นไฟฟ้าสมอง (Emotiv EPOC+) บนศีรษะดังแสดงในรูปที่ 3.8(ก) 2) ใช้โปรแกรมเก็บข้อมูลคลื่นไฟฟ้าสมองที่พัฒนาขึ้นโดยอาสาสมัครจะต้องทำสมาธิจนถึงเกณฑ์ที่กำหนดดังแสดงในรูปที่ 3.8(ข) เพื่อให้โปรแกรมแสดงภาพเคลื่อนไหวของรูปแบบที่ต้องจินตนาการ 3) อาสาสมัครจินตนาการตามภาพเคลื่อนไหวที่ถูกแสดงขึ้นเพื่อบันทึกสัญญาณคลื่นไฟฟ้าสมองดังแสดงในรูปที่ 3.8(ค) และ 4) หลังจากที่อาสาสมัครจินตนาการเสร็จแล้วประมาณ 30 ครั้ง อาสาสมัครต้องพักเป็นเวลา 120 วินาที เพื่อลดความเมื่อยล้าของสมองดังแสดงในรูปที่ 3.8(ง) จากนั้นอาสาสมัครจะเริ่มกระบวนการเก็บข้อมูลใหม่จนกว่าจะครบ 100 ครั้งต่อรูปแบบของการจินตนาการ โดยข้อมูลสัญญาณคลื่นไฟฟ้าสมองจะถูกจัดเก็บจากอิเล็กโทรดทั้ง 14 ตำแหน่งหรือเรียกว่า 14 ช่องสัญญาณ (AF3, AF4, F3, F4, F7, F8, FC5, FC6, P3, P4, P7, P8, T7, T8, O1 และ O2) และจะถูกนำไปวิเคราะห์ในหัวข้อถัดไป

3.3 การวิเคราะห์ความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

3.3.1 การจัดการข้อมูลคลื่นไฟฟ้าสมอง

จากการบันทึกสัญญาณคลื่นไฟฟ้าสมองที่ได้จากการจินตนาการถึงรูปแบบการเขียน จะมีการคัดเลือกสัญญาณในแต่ละช่องสัญญาณด้วยตัวตรวจจับแบบสหสัมพันธ์ (Correlation Detector) โดยการคำนวณหาค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) ตามสมการที่ 3.1 เพื่อหาสัญญาณที่มีความสัมพันธ์กันมากที่สุดในแต่ละรูปแบบการเขียน

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (3.1)$$

โดยที่ x_i คือ ลำดับข้อมูลของสัญญาณอ้างอิงมีทั้งหมด N ลำดับ

y_i คือ ลำดับข้อมูลของสัญญาณเปรียบเทียบมีทั้งหมด N ลำดับ

\bar{x} คือ ค่าเฉลี่ยของสัญญาณอ้างอิง

\bar{y} คือ ค่าเฉลี่ยของสัญญาณเปรียบเทียบ

ผลลัพธ์ของ r จะบ่งบอกระดับความสัมพันธ์เชิงเส้นโดยจะมีค่าอยู่ระหว่าง -1.0 ถึง +1.0 โดยที่ค่าที่อยู่ใกล้ -1.0 หรือ +1.0 ถือว่ามีความสัมพันธ์กันมากที่สุด ส่วน 0 หมายความว่าตัวแปรทั้งสองไม่มีความสัมพันธ์กันแม้แต่น้อยส่วนเครื่องหมาย + หรือ - บ่งบอกว่าความสัมพันธ์นั้นเป็นไปตามกันหรือตรงกันข้าม เช่น ตัวแปรหนึ่งเพิ่มค่าขึ้นอีกตัวแปรหนึ่งก็จะเพิ่มตามแต่ถ้าลดก็จะลดตามลักษณะเช่นนี้ค่า r จะเป็นบวกแต่ในกรณีที่ตัวแปรหนึ่งเพิ่มค่าแต่อีกตัวแปรลดค่าในขณะที่ตัวแปรหนึ่งลดลงอีกตัวแปรจะเพิ่มขึ้นลักษณะเช่นนี้ค่า r จะมีเครื่องหมายลบ ซึ่งในงานวิจัยนี้ต้องการค่า r ที่เป็นบวกและเข้าใกล้ 1.0 มากที่สุดและเพื่อลดความแปรปรวนของข้อมูลคลื่นไฟฟ้าสมองจึงได้มีการนำสัญญาณมา Normalization ให้มีค่าอยู่ระหว่าง -1 ถึง 1 ด้วยสมการที่ 3.2

$$Normalize(X_i) = 2 \frac{X_i - X_{min}}{X_{max} - X_{min}} - 1 \quad (3.2)$$


โดยที่ X_i คือ ลำดับข้อมูลของสัญญาณคลื่นไฟฟ้าสมองมีทั้งหมด I ลำดับ

X_{min} คือ ค่าต่ำสุดของข้อมูลในสัญญาณคลื่นไฟฟ้าสมอง


X_{max} คือ ค่ามากที่สุดของข้อมูลในสัญญาณคลื่นไฟฟ้าสมอง

3.3.2 การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมอง

ในงานวิจัยนี้จะใช้เทคนิคการแปลงเวฟเล็ตแบบเต็มหน่วยซึ่งเป็นเทคนิคที่ได้รับความนิยมในงานวิจัยเกี่ยวกับการวิเคราะห์คลื่นไฟฟ้าสมอง จากการศึกษาปริทัศน์วรรณกรรมพบว่าเวฟเล็ตแม่ที่มีความเหมาะสมสำหรับการแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองคือ Daubechies ลำดับที่สี่ (Atangana, Tchiotsop, GodpromesseKenne and Nkengfack, 2020 และ Tumari, Sudirman and Ahmad, 2013) และระดับการแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองที่มีอัตราการสุ่มตัวอย่างที่ 128 เฮิร์ตซ์ อยู่ที่ระดับ 4 ดังแสดงในภาพที่ 3.9 และ 3.10



รูปที่ 3.9 การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองด้วยการแปลงเวฟเล็ตแบบเต็มหน่วย



รูปที่ 3.10 การแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองที่ถูกบันทึกจากอาสาสมัคร ด้วยการแปลงเวฟเล็ตแบบเต็มหน่วย

จากกระบวนการแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองช่วงเวลาที่ได้รับความสัมพันธ์ที่ตรงกันกับย่านความถี่ของสมองที่เกิดจากการตอบสนองต่อกิจกรรมของมนุษย์ดังแสดงในตารางที่ 3.1

ตารางที่ 1.1 ย่านความถี่การตอบสนองของสมองที่สอดคล้องกับระดับการแยกองค์ประกอบของสัญญาณคลื่นไฟฟ้าสมองด้วยอัตราการสุ่มตัวอย่าง 128 เฮิร์ตซ์

ย่านความถี่ของสมองที่ตอบสนองต่อกิจกรรมของมนุษย์ (เฮิร์ตซ์)	ช่วงความถี่ (เฮิร์ตซ์)	ระดับการแยกองค์ประกอบ (D = Detail coefficient) (A = Approximation coefficient)
แกมม่า	32-64	ระดับที่ 1 (D1)
เบต้า	16-32	ระดับที่ 2 (D2)
อัลฟา	8-16	ระดับที่ 3 (D3)
ซีต้า	4-8	ระดับที่ 4 (D4)
เดลต้า	0-4	ระดับที่ 4 (A4)

นอกจากนี้การพิจารณาองค์ประกอบที่ถูกแยกออกมาด้วยคุณสมบัติทางสถิติอาจทำให้พบคุณลักษณะที่โดดเด่นของคลื่นไฟฟ้าสมองเพิ่มเติมได้ โดยสถิติที่ถูกเลือกใช้ในงานวิจัยนี้มีดังต่อไปนี้

1) ค่าเฉลี่ยสัมบูรณ์ในแต่ละระดับของการแยกองค์ประกอบซึ่งสามารถคำนวณได้จากสมการที่ 3.3

$$\mu_i = \frac{1}{M} \sum_{n=1}^M |C_i(n)| \quad (3.3)$$

เมื่อ $C_i(n)$ คือ ข้อมูลคลื่นไฟฟ้าสมองลำดับที่ n ของระดับการแยกองค์ประกอบที่ i โดยมีทั้งหมด M ข้อมูล

2) พลังงานเฉลี่ยของคลื่นไฟฟ้าสมองในแต่ละระดับของการแยกองค์ประกอบซึ่งสามารถคำนวณได้จากสมการที่ 3.4

$$p_i = \frac{1}{M} \sum_{n=1}^M (C_i(n))^2 \quad (3.4)$$

3) ค่าเบี่ยงเบนมาตรฐานของข้อมูลคลื่นไฟฟ้าสมองในแต่ละระดับของการแยกองค์ประกอบซึ่งสามารถคำนวณได้จากสมการที่ 3.5

$$\sigma_i = \sqrt{\frac{1}{M} \sum_{n=1}^M (C_i(n) - \mu_i)^2} \quad (3.5)$$

4) อัตราส่วนของค่าเฉลี่ยสัมบูรณ์ของข้อมูลคลื่นไฟฟ้าสมองที่มีระดับการแยกองค์ประกอบอยู่ติดกันซึ่งสามารถคำนวณได้จากสมการที่ 3.6

$$R_{ij} = \frac{\mu_i}{\mu_j} ; j = i + 1 \quad (3.6)$$

5) ความเบ้ของข้อมูลคลื่นไฟฟ้าสมองในแต่ละระดับของการแยกองค์ประกอบซึ่งสามารถคำนวณได้จากสมการที่ 3.7

$$Sk_i = \frac{1}{M} \sum_{n=1}^M \frac{(C_i(n) - \mu_i)^3}{\sigma^3} \quad (3.7)$$

6) ความโค้งของข้อมูลคลื่นไฟฟ้าสมองในแต่ละระดับของการแยกองค์ประกอบซึ่งสามารถคำนวณได้จากสมการที่ 3.8

$$Ku_i = \frac{1}{M} \sum_{n=1}^M \frac{(C_i(n) - \mu_i)^4}{\sigma^4} \quad (3.8)$$

3.4 การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร

การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองในงานวิจัยนี้จะดำเนินการด้วยการสร้างแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่ใช้วิธีการเรียนรู้แบบมีการสอนและการแพร่ย้อนกลับ ซึ่งการพัฒนาโครงข่ายประสาทเทียมจะใช้ฟังก์ชันสำเร็จรูปที่มีอยู่ในโปรแกรม MATLAB โดยมีรายละเอียดดังต่อไปนี้ 1.การจัดเตรียมข้อมูลคลื่นไฟฟ้าสมองเพื่อใช้ในการฝึกสอนโครงข่าย 2.การสร้างแบบจำลองโครงข่ายเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง และ 3.การทดสอบประสิทธิภาพของแบบจำลองโครงข่ายประสาท

3.4.1 การจัดเตรียมข้อมูลคลื่นไฟฟ้าสมอง

B	C	D	E	F	G	H	I	J	K	L	M	N	O
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
4238.974	4174.872	4200	4186.667	4170.256	4208.718	4192.82	4177.436	4189.23	4169.744	4193.846	4126.154	4175.897	4190.256
4224.615	4165.641	4194.359	4181.539	4163.077	4208.205	4189.744	4172.82	4187.179	4167.179	4187.179	4114.359	4169.744	4184.103
4241.539	4161.539	4195.897	4177.436	4160	4206.154	4192.308	4171.282	4185.128	4156.41	4189.744	4121.539	4162.051	4191.282
4220.513	4163.59	4187.692	4176.923	4166.667	4201.539	4186.667	4172.308	4181.025	4152.308	4171.282	4115.897	4158.974	4175.897
4236.923	4166.667	4192.308	4172.82	4169.23	4207.692	4193.333	4168.718	4183.077	4156.41	4177.949	4126.154	4163.077	4182.051
4232.82	4160.513	4184.103	4170.256	4166.154	4202.564	4192.82	4164.103	4183.077	4154.872	4181.539	4120.513	4158.974	4180
4217.436	4160	4180	4174.359	4160.513	4199.487	4192.308	4165.641	4178.461	4152.308	4171.795	4115.384	4159.487	4176.923
4235.897	4164.103	4186.154	4171.282	4156.41	4202.051	4195.384	4164.615	4179.487	4153.333	4180.513	4128.718	4164.615	4188.718

รูปที่ 3.11 ข้อมูลคลื่นไฟฟ้าสมองที่ถูกบันทึกจากการจินตนาการ

B	C	D	E	F	G	H	I	J	K	L	M	N	O
AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
4238.974	4174.872	4200	4186.667	4170.256	4208.718	4192.82	4177.436	4189.23	4169.744	4193.846	4126.154	4175.897	4190.256
4224.615	4165.641	4194.359	4181.539	4163.077	4208.205	4189.744	4172.82	4187.179	4167.179	4187.179	4114.359	4169.744	4184.103
4241.539	4161.539	4195.897	4177.436	4160	4206.154	4192.308	4171.282	4185.128	4156.41	4189.744	4121.539	4162.051	4191.282
4220.513	4163.59	4187.692	4176.923	4166.667	4201.539	4186.667	4172.308	4181.025	4152.308	4171.282	4115.897	4158.974	4175.897
4236.923	4166.667	4192.308	4172.82	4169.23	4207.692	4193.333	4168.718	4183.077	4156.41	4177.949	4126.154	4163.077	4182.051
4232.82	4160.513	4184.103	4170.256	4166.154	4202.564	4192.82	4164.103	4183.077	4154.872	4181.539	4120.513	4158.974	4180
4217.436	4160	4180	4174.359	4160.513	4199.487	4192.308	4165.641	4178.461	4152.308	4171.795	4115.384	4159.487	4176.923
4235.897	4164.103	4186.154	4171.282	4156.41	4202.051	4195.384	4164.615	4179.487	4153.333	4180.513	4128.718	4164.615	4188.718

จินตนาการครั้งที่	ชุดข้อมูล AF3	ชุดข้อมูล F7	ชุดข้อมูล AF4
1	AF3	F7	AF4
2	AF3	F7	AF4
3	AF3	F7	AF4
4	AF3	F7	AF4
5	AF3	F7	AF4

รูปที่ 3.12 นำข้อมูลคลื่นไฟฟ้าสมองจากแต่ละช่องสัญญาณมาจัดเรียงเป็นชุดข้อมูล

ในการบันทึกข้อมูลคลื่นไฟฟ้าสมองจากการจินตนาการหนึ่งครั้งจะได้รับข้อมูลคลื่นไฟฟ้าสมองจำนวน 14 คอลัมน์ตามชื่อตำแหน่งของอิเล็กโทรดดังแสดงในรูปที่ 3.11 ซึ่งวิธีการจัดเตรียมข้อมูลคือการนำข้อมูลที่ได้จากการจินตนาการในแต่ละครั้งมาแยกตามรายชื่อของชุดข้อมูล ยกตัวอย่างเช่น ข้อมูลคลื่นไฟฟ้าสมองจากช่องสัญญาณ AF3 จะถูกแยกมาอยู่ในชุดข้อมูลของ AF3 และข้อมูลคลื่นไฟฟ้าสมองจากช่องสัญญาณ F7 จะถูกแยกมาอยู่ในชุดข้อมูลของ F7 ซึ่งจะทำเช่นเดียวกันจนถึงชุดข้อมูล AF4 ดังแสดงในรูปที่ 3.12

รูปแบบการจินตนาการ	อาสาสมัคร				
	1	2	3	4	5
วงกลม	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3
เส้นแนวนอน	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3
เส้นแนวตั้ง	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3
เส้นเอียงขวา	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3
เส้นเอียงซ้าย	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3	ชุดข้อมูล AF3

รูปที่ 3.13 การจัดเรียงชุดข้อมูลคลื่นไฟฟ้าสมองที่บันทึกจากการจินตนาการถึงรูปแบบของวงกลมด้วยช่องสัญญาณ AF3

จากนั้นชุดข้อมูลคลื่นไฟฟ้าสมองจากแต่ละช่องสัญญาณของอาสาสมัครแต่ละคนจะถูกนำมาจัดเรียงกันตามรูปแบบการจินตนาการยกตัวอย่างเช่น ชุดข้อมูลจากช่องสัญญาณ AF3 ของอาสาสมัครทั้ง 5 คน ที่มีการจินตนาการถึงรูปแบบวงกลมมารวมเป็นชุดข้อมูลเดียวกันเรียกว่าชุดข้อมูลวงกลมดังแสดงในรูปที่ 3.13 โดยจะทำเช่นเดียวกันกับอีก 13 ช่องสัญญาณที่เหลือ

จินตนาการครั้งที่	ชุดข้อมูล F3แกมมา	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3อัลฟา	ชุดข้อมูล F3ธีต้า	ชุดข้อมูล F3เดลต้า
1	F3แกมมา	F3เบต้า	F3อัลฟา	F3ธีต้า	F3เดลต้า
2	F3แกมมา	F3เบต้า	F3อัลฟา	F3ธีต้า	F3เดลต้า
3	F3แกมมา	F3เบต้า	F3อัลฟา	F3ธีต้า	F3เดลต้า
4	F3แกมมา	F3เบต้า	F3อัลฟา	F3ธีต้า	F3เดลต้า
5	F3แกมมา	F3เบต้า	F3อัลฟา	F3ธีต้า	F3เดลต้า

รูปที่ 3.14 การจัดเรียงข้อมูลคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเป็น 5 ย่านความถี่ของช่องสัญญาณ F3 ในการจินตนาการแต่ละครั้ง

รูปแบบการจินตนาการ	อาสาสมัคร				
	1	2	3	4	5
วงกลม	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า
เส้นแนวนอน	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า	ชุดข้อมูล F3แกมม่า

(ก)

รูปแบบการจินตนาการ	อาสาสมัคร				
	1	2	3	4	5
วงกลม	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า
เส้นแนวนอน	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า	ชุดข้อมูล F3เบต้า


(ข)

รูปที่ 3.15 การจัดเรียงชุดข้อมูลคลื่นไฟฟ้าสมองของแต่ละย่านความถี่ตามรูปแบบการจินตนาการของอาสาสมัครแต่ละคน


ในทำนองเดียวกันเมื่อนำสัญญาณคลื่นไฟฟ้าสมองที่บันทึกได้จากแต่ละช่องสัญญาณไปแยกองค์ประกอบจะได้เป็นสัญญาณในย่านความถี่ แกมม่า เบต้า อัลฟา ธิต้า และเดลต้าของช่องสัญญาณนั้นๆ ยกตัวอย่างเช่น ข้อมูลคลื่นไฟฟ้าสมองที่บันทึกจากช่องสัญญาณ F3 จะถูกนำมาแยกองค์ประกอบเป็น 5 ย่านความถี่แล้วนำมาจัดเรียงต่อกันไปในแต่ละครั้งที่จินตนาการดังแสดงในรูปที่ 3.14 จากนั้นชุดข้อมูลของแต่ละย่านความถี่ของอาสาสมัครแต่ละคนจะถูกนำมาจัดเรียงกันตามรูปแบบการจินตนาการดังแสดงในรูปที่ 3.15

3.4.2 การสร้างแบบจำลองโครงข่ายเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง

การสร้างแบบจำลองโครงข่ายเพื่อจำแนกความแตกต่างของคลื่นไฟฟ้าสมองจะดำเนินการโดยการนำข้อมูลคลื่นไฟฟ้าสมองที่จัดเตรียมไว้ไปฝึกสอน (Training) ให้กับโครงข่ายเรียนรู้พร้อมกับการกำหนดเป้าหมาย (Target outputs) ที่ถูกต้องให้กับโครงข่ายประสาทเทียมดังแสดงในภาพที่ 3.15



รูปที่ 3.16 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม




รูปที่ 3.17 แบบจำลองโครงข่ายประสาทเทียมของช่องสัญญาณ AF3

ในงานวิจัยนี้จะมีการสร้างแบบจำลองโครงข่ายประสาทเทียม 2 รูปแบบดังต่อไปนี้

รูปแบบที่ 1 สร้างแบบจำลองโครงข่ายประสาทเทียมจากการฝึกสอนด้วยข้อมูลคลื่นไฟฟ้าสมองที่ผ่านการคัดเลือกสัญญาณในหัวข้อ 3.3.1 และถูกจัดเรียงข้อมูลตามกระบวนการในหัวข้อ 3.4.1 ดังแสดงในรูปที่ 3.17 โดยจะมีการสร้างแบบจำลองโครงข่ายตามจำนวนของอิเล็คโทรดที่ใช้บันทึกสัญญาณคลื่นไฟฟ้าสมองซึ่งประกอบไปด้วย แบบจำลอง AF3 แบบจำลอง AF4 แบบจำลอง F3 แบบจำลอง F4 แบบจำลอง F7 แบบจำลอง F8 แบบจำลอง FC5 แบบจำลอง FC6 แบบจำลอง P7 แบบจำลอง P8 แบบจำลอง T7 แบบจำลอง T8 แบบจำลอง O1 และแบบจำลอง O2

รูปแบบที่ 2 สร้างแบบจำลองโครงข่ายประสาทเทียมจากการฝึกสอนด้วยข้อมูลคลื่นไฟฟ้าสมองที่ถูกนำไปแยกองค์ประกอบในหัวข้อ 3.3.2 และถูกจัดเรียงข้อมูลตามกระบวนการในหัวข้อ 3.4.1 โดยจะมีการสร้างแบบจำลองโครงข่ายประสาทเทียมตามจำนวนของย่านความถี่ที่ถูกแยกองค์ประกอบออกมาซึ่งประกอบไปด้วยแบบจำลองที่ใช้ข้อมูลแอมพลิจูดในการฝึกสอน แบบจำลองที่ใช้ข้อมูลเบต้าในการฝึกสอน แบบจำลองที่ใช้ข้อมูลอัลฟาในการฝึกสอน แบบจำลองที่ใช้ข้อมูลธีต้าในการฝึกสอน และแบบจำลองที่ใช้ข้อมูลเดลต้าในการฝึกสอน

3.4.3 การทดสอบแบบจำลองโครงข่ายประสาทเทียม




รูปที่ 3.18 กระบวนการทดสอบแบบจำลองโครงข่ายประสาทเทียม

ก่อนการทดสอบแบบจำลองโครงข่ายประสาทเทียมจะต้องมีการทดสอบประสิทธิภาพของแบบจำลองก่อนโดยการใช้ชุดข้อมูลฝึกสอนเป็นข้อมูลนำเข้าแล้วดูความถูกต้องของข้อมูลส่งออกถ้าหากแบบจำลองสามารถทายประเภทของข้อมูลนำเข้าได้ถูกต้องมากกว่า 99 เปอร์เซ็นต์แบบจำลองนั้นจะถูกนำไปใช้ในการจำแนกความแตกต่างของคลื่นไฟฟ้าสมอง

ในขณะที่การทดสอบแบบจำลองโครงข่ายประสาทเทียมต้องใช้ข้อมูลคลื่นไฟฟ้าสมองชุดใหม่ที่ไม่เกี่ยวข้องกับชุดข้อมูลที่ใช้ในการฝึกสอนแบบจำลอง ซึ่งในงานวิจัยนี้จะใช้ข้อมูลคลื่นไฟฟ้าสมองของอาสาสมัครแต่ละคนจำนวน 100 ข้อมูลสำหรับการทดสอบแบบจำลองโครงข่ายประสาทเทียม

3.4.4 การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร



รูปที่ 3.19 ตัวอย่างการตัดสินใจว่าอาสาสมัครจินตนาการถึงรูปแบบการเขียนวงกลม

เงื่อนไขในการจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษรถูกกำหนดโดยผู้วิจัยซึ่งใช้กฎเสียงข้างมาก (Majority rule) ในการตัดสินใจว่าข้อมูลคลื่นไฟฟ้าสมองของอาสาสมัครจินตนาการถึงรูปแบบการเขียนใด ยกตัวอย่างเช่น เมื่ออาสาสมัครจินตนาการถึงรูปแบบการเขียนวงกลมหรือเส้นตรง ข้อมูลคลื่นไฟฟ้าสมองในแต่ละช่องสัญญาณที่บันทึกได้จะเป็นข้อมูลนำเข้าของแบบจำลองที่มีชื่อตรงกันซึ่งมีทั้งหมด 14 แบบจำลอง โดยถ้าหากข้อมูลส่งออกของแบบจำลองโครงข่ายในแต่ละช่องสัญญาณได้คำตอบที่ตรงกันมากกว่า 7 ช่องสัญญาณ ระบบจะตัดสินใจว่าอาสาสมัครจินตนาการถึงรูปแบบการเขียนของคำตอบนั้นดังแสดงในรูปที่ 3.19

3.5 สรุป

เนื้อหาในบทนี้ได้มีการนำเสนอวิธีการเก็บข้อมูลคลื่นไฟฟ้าสมองจากการจินตนาการถึงการเขียนตัวอักษร โดยใช้มาตรฐานการลากเส้นสำหรับเขียนตัวอักษรเป็นตัวกำหนดรูปแบบการจินตนาการเพื่อให้อาสาสมัครสามารถจินตนาการไปในทิศทางเดียวกันได้ รวมถึงการควบคุมปัจจัยเสี่ยงที่จะส่งผลต่อการบันทึกสัญญาณคลื่นไฟฟ้าสมองด้วยการทำสมาธิ การผ่อนคลายและการกำหนดเกณฑ์ต่างๆที่อาสาสมัครต้องทำในระหว่างการบันทึกสัญญาณ โดยการวิเคราะห์สัญญาณคลื่นไฟฟ้าสมองจะทำการแยกองค์ประกอบของสัญญาณออกมาด้วยวิธีการแปลงเวฟเล็ตแบบเต็มหน่วย ซึ่งมีความสัมพันธ์ที่ตรงกันกับย่านความถี่ของสมองที่เกิดจากการตอบสนองต่อกิจกรรมของมนุษย์ จากนั้นสร้างแบบจำลองของโครงข่ายประสาทเทียมด้วยชุดข้อมูลคลื่นไฟฟ้าสมองที่ผ่านการวิเคราะห์แล้ว โดยแบบจำลองโครงข่ายมีวัตถุประสงค์ในการจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบการเขียน




บทที่ 4

ผลการวิจัยและอภิปรายผล

4.1 บทนำ

ในบทนี้จะกล่าวถึงผลการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่ายประสาทเทียม เมื่ออาสาสมัครจินตนาการถึงรูปแบบการเขียนตามที่ได้กำหนดไว้ พร้อมทั้งอภิปรายผลกระทบที่เกิดขึ้นจากผลการจำแนกคลื่นไฟฟ้าสมอง ซึ่งนำไปสู่ระบบการสื่อสารด้วยการใช้คลื่นไฟฟ้าสมองโดยไม่ต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา


4.2 ผลการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่ายประสาทเทียมเมื่ออาสาสมัครจินตนาการถึงรูปแบบการเขียน



รูปที่ 4.1 ผลการทดสอบความแม่นยำในการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่าย

จากแบบจำลองโครงข่ายประสาทเทียมที่มีการฝึกสอนด้วยชุดข้อมูลคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบของวงกลม เส้นตรงเอียงซ้าย เส้นตรงเอียงขวา เส้นตรงแนวตั้งและเส้นตรงแนวนอน เมื่อนำแบบจำลองไปทดสอบด้วยชุดข้อมูลคลื่นไฟฟ้าสมองชุดใหม่ของอาสาสมัครแต่ละคน ผลการทดสอบพบว่าแบบจำลองให้ผลการจำแนกคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบการเขียน

วงกลมได้ดีที่สุดโดยมีความแม่นยำเฉลี่ยอยู่ที่ 70.6 ± 2.4 เปอร์เซ็นต์ ในขณะที่การจินตนาการถึงรูปแบบการเขียนเส้นตรงแนวนอน เส้นตรงแนวตั้ง เส้นตรงเอียงซ้ายและเส้นตรงเอียงขวา นั้นแบบจำลองให้ผลการจำแนกที่ใกล้เคียงกันมากแต่ผลการจำแนกที่ดีที่สุดคือเส้นตรงแนวนอน โดยมีความแม่นยำเฉลี่ยอยู่ที่ 50.6 ± 2.7 เปอร์เซ็นต์ดังแสดงในรูปที่ 4.1



รูปที่ 4.2 ผลการพิจารณาช่องสัญญาณที่ให้ข้อมูลส่งออกจากแบบจำลองโครงข่ายประสาทเทียมเป็นคำตอบที่ถูกต้องอยู่เสมอ

ตามที่ได้อธิบายไว้ในบทที่ 3 หัวข้อที่ 3.4.4 การจำแนกความแตกต่างของคลื่นไฟฟ้าสมองที่เกิดขึ้นจากการจินตนาการถึงรูปแบบการเขียนตัวอักษร จะพิจารณาจากภูเขียงข้างมาก กล่าวคือถ้าหากข้อมูลส่งออกของแบบจำลองโครงข่ายในแต่ละช่องสัญญาณได้คำตอบที่ตรงกันมากกว่า 7 ช่องสัญญาณระบบจะตัดสินใจว่าข้อมูลคลื่นไฟฟ้าสมองที่นำมาทดสอบเป็นการจินตนาการคำตอบนั้นด้วยเหตุนี้จึงมีการพิจารณาแบบจำลองของแต่ละช่องสัญญาณ (ตำแหน่งอิเล็กโทรด) ที่บ่อยครั้งจะให้ข้อมูลส่งออกเป็นคำตอบที่ถูกต้องอยู่เสมอ

ผลการพิจารณาคือแบบจำลองโครงข่ายประสาทเทียมของช่องสัญญาณ AF3 - AF4 / F3 - F4 / F7 - F8 / FC5 - FC6 และ O1 - O2 เป็นคู่ช่องสัญญาณที่บ่อยครั้งจะให้คำตอบที่ถูกต้องอยู่เสมอ โดยแบบจำลองของช่องสัญญาณ F3 - F4 มีเป็นคู่ช่องสัญญาณที่มีค่าเฉลี่ยความแม่นยำของแบบจำลองสูงสุดอยู่ที่ 71 ± 2.1 เปอร์เซ็นต์ ดังแสดงในรูปที่ 4.2


โดยจะสังเกตเห็นได้ว่าช่องสัญญาณดังกล่าวเป็นตำแหน่งที่อยู่บริเวณพื้นที่สมองส่วนหน้า จากคำอธิบายหน้าที่และการทำงานของสมองในบทที่ 2 ผลการพิจารณานี้มีความสอดคล้องกัน กล่าวคือ

พื้นที่สมองส่วนหน้ามีการทำงานที่เกี่ยวข้องกับสติปัญญา เช่น การคิดวิเคราะห์เพื่อประเมินความเหมือนหรือแตกต่างระหว่างวัตถุสองชนิด การรับรู้และความเข้าใจ เป็นต้น และยังมีความเกี่ยวข้องกับการนึกคิดเกี่ยวกับความทรงจำทั้งในระยะสั้นและระยะยาวอีกด้วย นอกจากนี้สัญญาณรบกวนที่สร้างขึ้นจากร่างกายมนุษย์ดังที่กล่าวไว้ในบทที่ 2 ยังเป็นส่วนสำคัญที่จะต้องหลีกเลี่ยง ในงานวิจัยของ Vokorokos, Adam and Madoš (2014) ได้ศึกษาคลื่นไฟฟ้าสมองที่เกิดจากการแสดงออกทางสีหน้าของนักเล่นหมากรุก ซึ่งผลการศึกษาพบว่าช่องสัญญาณ F3 และ F4 เป็นตำแหน่งที่เกิดสัญญาณการแสดงออกทางสีหน้าน้อยที่สุดในบริเวณสมองส่วนหน้า ซึ่งหมายความว่า เป็นช่องสัญญาณที่จะเกิดสัญญาณรบกวนจากร่างกายมนุษย์ได้น้อยที่สุดเช่นกัน ในขณะที่ผลการพิจารณายังสอดคล้องกับงานวิจัยของ Knoll et al. (2011) ที่แสดงให้เห็นว่าช่องสัญญาณ F3 และ F4 มีบทบาทสำคัญในการรับรู้และประมวลผลข้อมูล

ดังนั้นจากผลของการจำแนกคลื่นไฟฟ้าสมองของแบบจำลองโครงข่ายประสาทเทียมเมื่ออาสาสมัครจินตนาการถึงรูปแบบการเขียน ทำให้สามารถสรุปได้ว่ารูปแบบการจินตนาการที่ให้ความแตกต่างของคลื่นไฟฟ้าสมองมากที่สุดคือการจินตนาการถึงรูปวงกลมและการจินตนาการถึงรูปแบบของเส้นตรงเท่านั้น ยังไม่สามารถจำแนกความแตกต่างของคลื่นไฟฟ้าสมองระหว่าง เส้นตรงเอียงซ้าย เส้นตรงเอียงขวา เส้นตรงแนวตั้งและเส้นตรงแนวนอนได้ นอกจากนี้ช่องสัญญาณที่มีประสิทธิภาพสำหรับการบันทึกสัญญาณคลื่นไฟฟ้าสมองที่เกิดจากการจินตนาการถึงรูปแบบการเขียนคือช่องสัญญาณ F3 และ F4 ซึ่งผลการทดลองนี้จะถูกนำไปพิจารณาในส่วนถัดไป

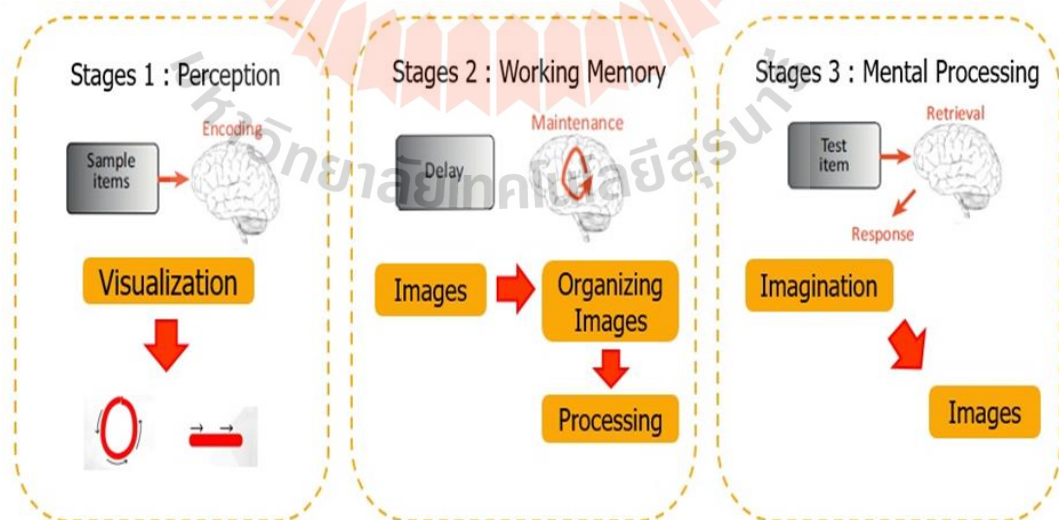
4.3 ผลการจำแนกคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเพื่อหาความสัมพันธ์ของย่านความถี่

หลังจากที่ได้รูปแบบของการจินตนาการที่ให้ความแตกต่างของคลื่นไฟฟ้าสมองมากที่สุด รวมถึงช่องสัญญาณที่มีประสิทธิภาพสำหรับบันทึกสัญญาณคลื่นไฟฟ้าสมอง ผู้วิจัยจึงนำสัญญาณคลื่นไฟฟ้าสมองที่จินตนาการถึงวงกลมและเส้นตรงโดยบันทึกจากช่องสัญญาณ F3 และ F4 มาแยกองค์ประกอบของสัญญาณด้วยการแปลงเวฟเลตแบบเต็มหน่วยและนำข้อมูลคลื่นไฟฟ้าสมองไปสร้างแบบจำลองโครงข่ายประสาทเทียมตามที่ได้กล่าวไว้ในบทที่ 3 หัวข้อที่ 3.4.2 เพื่อวัตถุประสงค์ในการหาความสัมพันธ์ที่เกิดขึ้นของย่านความถี่ผลการทดสอบแสดงในรูปที่ 4.3



รูปที่ 4.3 ผลการจำแนกคลื่นไฟฟ้าสมองที่ถูกแยกองค์ประกอบเพื่อหาความสัมพันธ์ของย่านความถี่

ซึ่งจะสังเกตได้ว่าย่านความถี่ที่แบบจำลองโครงข่ายประสาทเทียมจำแนกคลื่นไฟฟ้าสมองได้ถูกต้องที่สุดมีทั้งหมด 4 ย่านความถี่คือ แกมมา เบต้า อัลฟา และซีต้าโดยมีความแม่นยำเฉลี่ยอยู่ที่ 71.4 ± 2.3 เปอร์เซ็นต์ 69.8 ± 1.9 เปอร์เซ็นต์ 69.8 ± 2 เปอร์เซ็นต์ และ 69.4 ± 2 เปอร์เซ็นต์ตามลำดับ ซึ่งแสดงให้เห็นว่าย่านความถี่ทั้ง 4 ย่านนี้มีความสัมพันธ์กันเกิดขึ้น ในขณะที่อาสาสมัครจินตนาการถึงวงกลมหรือเส้นตรง จากการศึกษาปริทัศน์วรรณกรรมผู้วิจัยจึงได้แสดงข้อสรุปความสัมพันธ์ไว้ในรูปที่ 4.4

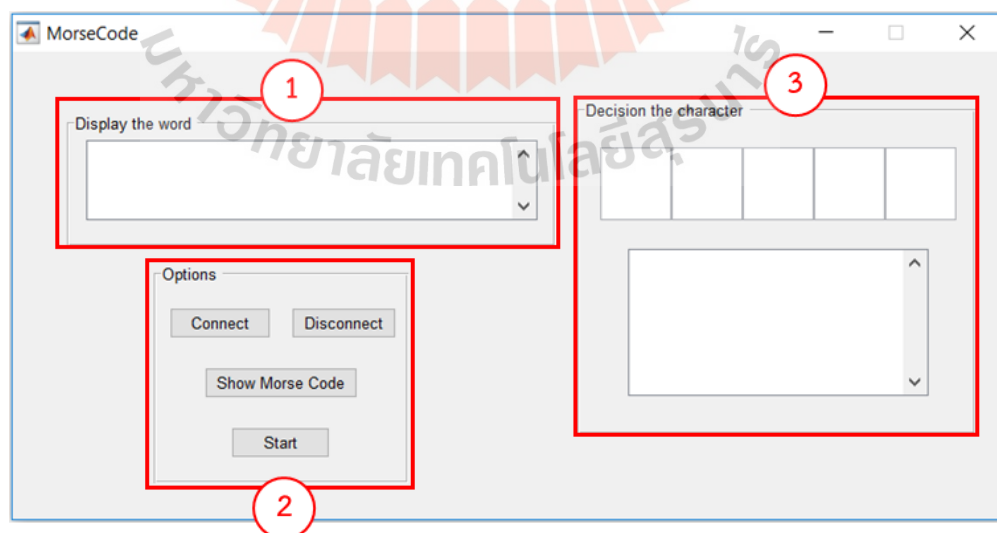


รูปที่ 4.4 แสดงความสัมพันธ์ที่เกิดขึ้นในกระบวนการจินตนาการ

ส่วนแรกคือส่วนของการรับรู้ข้อมูลที่เกิดจากการมองภาพเคลื่อนไหวของวงกลมหรือเส้นตรง กระบวนการนี้ทำให้เกิดการโฟกัสและสนใจต่อสิ่งที่ได้รับรู้จากภายนอก ส่งผลให้เกิดคลื่นเบต้า ส่วนที่สองคือกระบวนการจดจำ จัดเก็บและจัดเรียงข้อมูลที่ได้รับเพื่อนำไปประมวลผลต่อไป ส่งผลให้เกิดคลื่นแกมมา ซึ่งสอดคล้องกับงานวิจัยของ Howard et al. (2003) ที่อธิบายความสัมพันธ์ที่เกิดขึ้นระหว่างคลื่นแกมมา กับส่วนความจำการทำงาน ส่วนสุดท้ายเป็นกระบวนการนำข้อมูลที่รับรู้ไปใช้ ในงานนี้คือการจินตนาการถึงภาพเคลื่อนไหวของวงกลมหรือเส้นตรง ส่งผลให้เกิดคลื่นอัลฟาและธีต้า ซึ่งสอดคล้องกับงานวิจัยของ Sammer et al. (2003) และ Borghini, Astolfi, Vecchiato, Mattia, and Babiloni (2014). ที่แสดงความสัมพันธ์ที่เกิดขึ้นของคลื่นอัลฟาและธีต้าในขณะที่ใช้การคิดในใจ ในการทำกิจกรรมต่างๆ

4.4 ความเป็นไปได้ของระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดย ไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา

จากผลการวิจัยทั้งหมดที่ผ่านมาทำให้รู้ว่าช่องสัญญาณที่มีความเหมาะสมสำหรับใช้บันทึกสัญญาณคลื่นไฟฟ้าสมองที่เกี่ยวข้องกับการจินตนาการคือช่องสัญญาณ F3 และ F4 โดยมีรูปแบบของการจินตนาการเป็นวงกลมและเส้นตรงซึ่งสามารถพิจารณาความแตกต่างของสัญญาณได้จากการแยกองค์ประกอบของสัญญาณเป็นย่านความถี่ที่เกี่ยวข้อง ดังนั้นผู้วิจัยจึงมีแนวคิดในการสร้างระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบของรหัสสมอร์ส



รูปที่ 4.5 ระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบของรหัสสมอร์ส

ระบบการสื่อสารด้วยการจินตนาการประกอบไปด้วยส่วนประกอบดังนี้

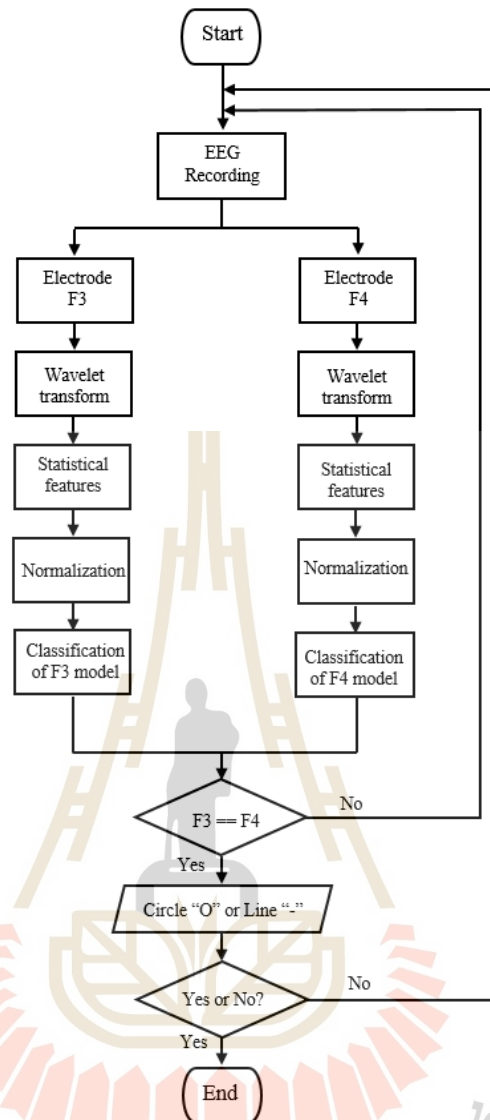
- ส่วนหน้าต่างสำหรับแสดงตัวอักษรที่ผู้ใช้ต้องการสื่อสารแสดงในรูปที่ 4.5 กรอบสี่แฉงหมายเลข 1
- ส่วนหน้าต่างสำหรับการตัดสินใจว่าเป็นตัวอักษรใดในรูปแบบของรหัสสมอร์ส แสดงในรูปที่ 4.5 กรอบสี่แฉงหมายเลข 3
- ส่วนตัวเลือกแสดงในรูปที่ 4.5 กรอบสี่แฉงหมายเลข 2

A ··	B ---	C ---
D ---	E ·	F ---
G ---	H ----	I ··
J ·---	K ---	L ----
M --	N ·-	O ---
P ----	Q ---	R ---
S ---	T -	U ---
V ----	W ---	X ----
Y ----	Z ---	

รูปที่ 4.6 รูปแบบของรหัสสมอร์ส

รายละเอียดในส่วนของตัวเลือกมีดังนี้ ปุ่ม "เชื่อมต่อ (Connect)" ใช้เพื่อเชื่อมต่อระหว่างอุปกรณ์ Emotiv EPOC+ กับคอมพิวเตอร์ผ่าน "บลูทูธ" เมื่อการเชื่อมต่อเสร็จสิ้นผู้ใช้ต้องคลิกที่ปุ่ม "เริ่ม (Start)" เพื่อเริ่มการทำงานของระบบ นอกจากนี้ผู้ใช้สามารถดูรูปแบบรหัสสมอร์สของอักษรแต่ละตัวได้โดยคลิกที่ "แสดงรหัสสมอร์ส" ดังแสดงในรูปที่ 4.6

รายละเอียดในส่วนของ "การตัดสินใจ" จะแสดงผลลัพธ์จากการจำแนกความแตกต่างของคลื่นไฟฟ้าสมองว่าเป็นการจินตนาการถึงวงกลม "O" หรือเส้นตรง "-" โดยใช้ช่องสัญญาณ F3 และ F4 ซึ่งกระบวนการทำงานของระบบการตัดสินใจเพื่อแปลความหมายของคลื่นไฟฟ้าสมองไปเป็นตัวอักษรแสดงในรูปที่ 4.7

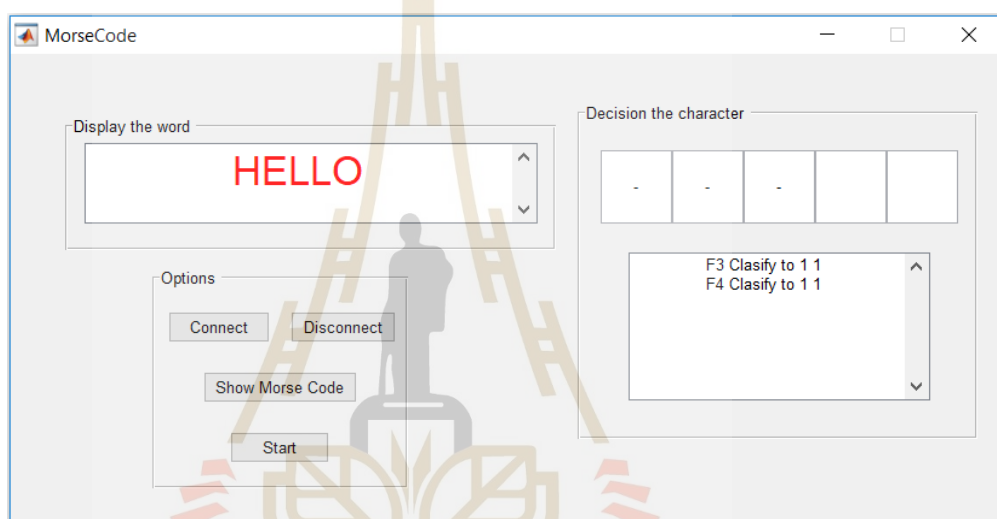


รูปที่ 4.7 กระบวนการทำงานของระบบการตัดสินใจเพื่อแปลความหมายของคลื่นไฟฟ้าสมอง
ไปเป็นตัวอักษร

ขั้นตอนแรกหลังสัญญาณคลื่นไฟฟ้าสมองที่บันทึกจากช่องสัญญาณ F3 และ F4 จะแยกองค์ประกอบของสัญญาณเป็น 4 ย่านความถี่ แกมมา เบต้า อัลฟาและธีต้าตามกระบวนการที่ได้ศึกษามา จากนั้นขั้นตอนที่สองคือการนำสัญญาณแต่ละย่านความถี่ไปคำนวณคุณสมบัติทางสถิติเพื่อลดขนาดของข้อมูลและลักษณะสำคัญของสัญญาณ ในขณะที่ขั้นตอนที่สามคือการลดความแปรปรวนของนำข้อมูลด้วยการทำให้เป็นมาตราส่วนระหว่าง ค่า -1 ถึง 1 สุดท้ายขั้นตอนที่สี่คือการนำข้อมูลคลื่นไฟฟ้าสมองที่ได้จากการจินตนาการไปเป็นข้อมูลนำเข้าของแบบจำลองโครงข่ายประสาทเทียมที่ถูกสร้างขึ้นเพื่อจำแนกวงกลม “O” หรือเส้น “-” โดยมีเงื่อนไขว่าถ้าหากคำตอบของแบบจำลองโครงข่ายประสาทเทียมจากช่องสัญญาณ F3 ไม่ตรงกับคำตอบของแบบจำลองจาก

ช่องสัญญาณ F4 ระบบจะเริ่มกระบวนการใหม่ตั้งแต่ต้นแต่ถ้าหากคำตอบตรงกันระบบจะตัดสินใจว่า ผู้ใช้กำลังจินตนาการถึงคำตอบนั้น

อย่างไรก็ตามระบบจะถามผู้ใช้งานด้วยตัวเลือกว่าคำตอบที่ระบบตัดสินใจให้ นั้น ใช่หรือไม่ใช่ กับสิ่งที่ผู้ใช้งานจินตนาการหากเป็นคำตอบ “ไม่ใช่” ผู้ใช้จะต้องกระพริบตา 3 ครั้ง เพื่อกลับไปเริ่มต้นกระบวนการใหม่ตั้งแต่การบันทึกสัญญาณคลื่นไฟฟ้าสมอง แต่ถ้าหากเลือกคำตอบว่า “ใช่” ผู้ใช้จะต้องหลับตาประมาณ 2-3 วินาที ระบบจึงจะแสดงผลในกล่องสี่เหลี่ยมเล็กๆ ในส่วนหน้าต่างการตัดสินใจ โดยเมื่อผู้ใช้งานจินตนาการจนครบรูปแบบของรหัสสมอร์ส ตัวอักษรจะไปปรากฏที่ส่วนหน้าต่างสำหรับแสดงตัวอักษร



รูปที่ 4.8 ตัวอย่างการทำงานของระบบการสื่อสารด้วยการจินตนาการ

ตัวอย่างการทำงานของระบบแสดงในรูปที่ 4.8 เมื่อผู้ต้องการสื่อสารคำว่า “HELLO” โดยจะสังเกตได้ว่าตัวอักษรตัวสุดท้ายที่เกิดขึ้นคือ “O” เมื่อพิจารณาตามรูปแบบของรหัสสมอร์สแล้ว ผู้ใช้ต้องจินตนาการถึงเส้นตรง 3 ซีด “-” ดังที่แสดงในกล่องสี่เหลี่ยมเล็กๆ ในส่วนหน้าต่างการตัดสินใจ

4.5 สรุป

จากผลการทดสอบแบบจำลองโครงข่ายประสาทเทียมที่เรียนรู้ชุดข้อมูลคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบการเขียน พบว่ารูปแบบการจินตนาการถึงการเขียนวงกลมนั้นมีความแม่นยำอยู่ที่ 70.6 ± 2.4 เปอร์เซ็นต์ ในขณะที่รูปแบบการจินตนาการถึงการเขียนเส้นตรงเอียงซ้าย เส้นตรงเอียงขวา เส้นตรงแนวตั้งและเส้นตรงแนวนอน ให้ผลที่ไม่แตกต่างกันมากแต่ผลการจำแนกที่ดีที่สุดคือเส้นตรงแนวนอนโดยมีความแม่นยำเฉลี่ยอยู่ 50.6 ± 2.7 เปอร์เซ็นต์ ในขณะที่ทดสอบแบบจำลองโครงข่ายประสาทเทียมด้วยการจินตนาการถึงรูปแบบการเขียน ผู้วิจัยได้มีการเก็บข้อมูลของ

ช่องสัญญาณที่ให้ผลการจำแนกถูกต้องอยู่เสมอด้วย ผลการพิจารณาพบว่าช่องสัญญาณ F3 - F4 มีเป็นคู่ช่องสัญญาณที่มีค่าเฉลี่ยความแม่นยำของแบบจำลองสูงสุดอยู่ที่ 71 ± 2.1 เปอร์เซ็นต์และเป็นช่องสัญญาณที่เกิดสัญญาณรบกวนจากร่างกายน้อยที่สุด ซึ่งเหมาะสำหรับการนำมาใช้ในงานวิจัยนี้ และจากการนำสัญญาณคลื่นไฟฟ้าสมองที่ได้จากการจินตนาการถึงรูปแบบการเขียนมาแยกองค์ประกอบเป็นย่านความถี่ที่ตรงกันกับย่านความถี่ของสมองที่เกิดจากการตอบสนองต่อกิจกรรมของมนุษย์แล้วนำไปสร้างแบบจำลองโครงข่ายประสาทเทียม ผลการทดสอบแบบจำลองพบว่าย่านความถี่แกมมา เบต้า อัลฟา และเซต้าเป็นย่านความถี่ที่สามารถจำแนกความแตกต่างของสัญญาณคลื่นสมองได้เนื่องจากมีความสัมพันธ์กันใน 3 กระบวนการคือ การรับรู้ข้อมูล การจัดเก็บและจัดเรียงข้อมูล และการนำข้อมูลไปใช้งาน ส่งผลให้สามารถนำแบบจำลองนี้ไปหารูปแบบที่แตกต่างกันของการจินตนาการได้ ซึ่งนำไปสู่ความเป็นไปได้ของการพัฒนาระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา



บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การสื่อสารระหว่างบุคคลเป็นสิ่งสำคัญในการดำเนินชีวิตประจำวันของมนุษย์เพื่อสร้างความสัมพันธ์ระหว่างกัน แต่การสื่อสารนี้จะไม่เกิดขึ้นกับผู้ป่วยล๊อคอินซินโดรม (Locked-in Syndrome: LIS) เนื่องจากการได้รับบาดเจ็บบริเวณสมองอย่างรุนแรงส่งผลให้ผู้ป่วยไม่สามารถขยับใบหน้า แขน และขาได้เลย ยกเว้นการเคลื่อนไหวของดวงตาในแนวตั้งและการกระพริบตาเพียงเท่านั้น แต่อย่างไรก็ตามผู้ป่วยยังคงมีสติสัมปชัญญะครบถ้วนสามารถคิดและให้เหตุผลได้ โดยในปัจจุบันมีหลายงานวิจัยที่พัฒนาระบบการสื่อสารโดยใช้คลื่นไฟฟ้าสมองเพื่อช่วยเหลือผู้ป่วยแต่ระบบเหล่านั้นยังจำเป็นต้องมีการกระตุ้นสมองของผู้ใช้งานจากสิ่งเร้าภายนอกอย่างต่อเนื่องเพื่อสร้างการตอบสนองของสมอง ซึ่งวิธีการเหล่านี้เมื่อนำไปใช้งานจำเป็นต้องให้ผู้ใช้งานมองสิ่งกระตุ้นผ่านหน้าจอกอมพิวเตอร์ตลอดเวลา ดังนั้นในงานวิจัยนี้จึงเสนอแนวทางใหม่สำหรับการสื่อสารด้วยคลื่นไฟฟ้าสมองโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลาแต่ใช้การจินตนาการถึงรูปแบบการเขียนตัวอักษรโดยตรง ซึ่งส่วนแรกของการวิจัยนี้ก็คือการหารูปแบบของการจินตนาการที่ส่งผลทำให้คลื่นไฟฟ้าสมองมีการตอบสนองที่แตกต่างกัน รวมไปถึงตำแหน่งหรือพื้นที่ของสมองที่เหมาะสมสำหรับการบันทึกสัญญาณคลื่นไฟฟ้าสมองที่เกี่ยวข้องกับการจินตนาการ โดยผลการวิจัยพบว่าตำแหน่งหรือช่องสัญญาณที่เหมาะสมและมีประสิทธิภาพคือช่องสัญญาณ F3 และ F4 และรูปแบบของการจินตนาการที่คลื่นไฟฟ้าสมองมีการตอบสนองที่แตกต่างกันคือรูปแบบการเขียนวงกลมและเส้นตรง จากผลการวิจัยนี้นำไปสู่ส่วนที่สองของการวิจัยคือการวิเคราะห์สัญญาณคลื่นไฟฟ้าสมองที่จินตนาการถึงรูปแบบการเขียนวงกลมและเส้นตรงโดยใช้การแยกองค์ประกอบของสัญญาณเป็นย่านความถี่ที่เกี่ยวข้องกับการตอบสนองของสมองที่มีต่อกิจกรรมของมนุษย์ด้วยการแปลงเวฟเล็ตแบบเต็มหน่วยและใช้โครงข่ายประสาทเทียมในการสร้างแบบจำลองโครงข่ายเพื่อพิจารณาความสัมพันธ์ที่เกิดขึ้นของย่านความถี่นี้ ซึ่งผลการวิจัยยังพบว่าคลื่นไฟฟ้าสมองที่เกิดจากการจินตนาการถึงรูปแบบการเขียนวงกลมและเส้นตรงมีการตอบสนองที่แตกต่างกันในย่านความถี่แกมมา เบต้า อัลฟาและซีต้า ด้วยผลการทดสอบนี้นำไปสู่ส่วนสุดท้ายของการวิจัยคือการพิสูจน์ความเป็นไปได้ของการพัฒนาระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอก

ตลอดเวลา โดยผลการวิจัยแสดงให้เห็นว่ามีความเป็นไปได้ถึง 70 เปอร์เซ็นต์ ที่ระบบการสื่อสารด้วยคลื่นไฟฟ้าสมองที่งานวิจัยนี้นำเสนอจะสามารถแสดงตัวอักษรจากการจินตนาการได้ถูกต้องตามความต้องการของผู้ใช้

5.2 ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต

เนื่องจากวิทยานิพนธ์ฉบับนี้เป็นการพิสูจน์ความเป็นไปได้ในการพัฒนาระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลา ซึ่งอาสาสมัครที่เข้าร่วมการทดลองเป็นผู้ที่มีสุขภาพแข็งแรง ดังนั้นการพัฒนาต่อยอดในอนาคตจำเป็นต้องใช้อาสาสมัครที่เป็นผู้ใช้งานจริงในการเข้าร่วมการทดลอง ซึ่งผู้วิจัยหวังว่าแนวคิดเกี่ยวกับการพัฒนาระบบการสื่อสารด้วยการจินตนาการถึงรูปแบบตัวอักษรโดยไม่จำเป็นต้องใช้การกระตุ้นจากสิ่งเร้าภายนอกตลอดเวลาจากวิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์แก่ผู้ที่สนใจไม่มากนักน้อย



รายการอ้างอิง

- Mendoza, J., & Foundas, A. (2007). **Clinical neuroanatomy: a neurobehavioral approach**. Springer Science & Business Media.
- Farr, E., Altonji, K., & Harvey, R. L. (2021). **Locked-In Syndrome: Practical Rehabilitation Management**. PM&R.
- Boustany, G., Itani, A. E. D., Youssef, R., Chami, O., & Abu-Faraj, Z. O. (2016, October). **Design and development of a rehabilitative eye-tracking based home automation system**. In 2016 3rd Middle East Conference on Biomedical Engineering (MECBME) (pp. 30-33). IEEE.
- Vasiljevas, M., Šalkevičius, J., Gedminas, T., & Damaševičius, R. (2015). **A prototype gaze-controlled speller for text entry**. In Proc. of the International Symposium for Young Scientists in Technology, Engineering and Mathematics (System 2015) (pp. 79-83).
- Alva M., Castellino N., Deshpande R., Sonawane K. & Lopes M. (2017). **An Image Based Eye Controlled Assistive System for Paralytic Patients**. 2nd International Conference on Communication Systems, Computing and IT Applications (CSCITA), 178 - 183.
- Al-Nafjan, A., Hosny, M., Al-Wabil, A., & Al-Ohali, Y. (2017). **Classification of human emotions from electroencephalogram (EEG) signal using deep neural network**. Int. J. Adv. Comput. Sci. Appl, 8(9), 419-425.
- Kübler, A., Furdea, A., Halder, S., Hammer, E. M., Nijboer, F., & Kotchoubey, B. (2009). **A brain-computer interface controlled auditory event-related potential (P300) spelling system for locked-in patients**. Annals of the New York Academy of Sciences, 1157(1), 90-100.

- Hwang, H. J., Ferreria, V. Y., Ulrich, D., Kilic, T., Chatziliadis, X., Blankertz, B., & Treder, M. (2015). **A gaze independent brain-computer interface based on visual stimulation through closed eyelids.** *Scientific reports*, 5(1), 1-11.
- van der Waal, M., Severens, M., Geuze, J., & Desain, P. (2012). **Introducing the tactile speller: an ERP-based brain-computer interface for communication.** *Journal of Neural Engineering*, 9(4), 045002.
- Brouwer, A. M., & Van Erp, J. B. (2010). **A tactile P300 brain-computer interface.** *Frontiers in neuroscience*, 4, 19.
- Speier, W., Arnold, C., Lu, J., Taira, R. K., & Pouratian, N. (2011). **Natural language processing with dynamic classification improves P300 speller accuracy and bit rate.** *Journal of neural engineering*, 9(1), 016004.
- Bin, G., Gao, X., Wang, Y., Hong, B., & Gao, S. (2009). VEP-based brain-computer interfaces: time, frequency, and code modulations [Research Frontier]. *IEEE Computational Intelligence Magazine*, 4(4), 22-26.
- Chen, X., Wang, Y., Gao, S., Jung, T. P., & Gao, X. (2015). Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface. *Journal of neural engineering*, 12(4), 046008.
- Blankertz, B., Dornhege, G., Lemm, S., Krauledat, M., Curio, G., & Müller, K. R. (2006). **The Berlin Brain-Computer Interface: Machine Learning Based Detection of User Specific Brain States.** *J. Univers. Comput. Sci.*, 12(6), 581-607.
- Zabidi, A., Mansor, W., Khuan, Y. L., & Fadzal, C. C. W. (2012, December). **Classification of imagined writing from EEG signals using autoregressive features.** In 2012 International Symposium on Computer Applications and Industrial Electronics (ISCAIE) (pp. 205-208). IEEE.
- Lezak, M. D., Howieson, D. B., Bigler, E. D., & Tranel, D. (2012). **Neuropsychological assessment (5th ed.).** Oxford University Press.
- Sur, S., & Sinha, V. K. (2009). **Event-related potential: An overview.** *Industrial psychiatry journal*, 18(1), 70.

- Zhu, D., Bieger, J., Garcia Molina, G., & Aarts, R. M. (2010). **A survey of stimulation methods used in SSVEP-based BCIs.** Computational intelligence and neuroscience, 2010.
- Tang, Z., Yu, H., Lu, C., Liu, P., & Jin, X. (2019). Single-trial classification of different movements on one arm based on ERD/ERS and corticomuscular coherence. *IEEE Access*, 7, 128185-128197.
- Muñoz-Gutiérrez, P. A., Giraldo, E., Bueno-López, M., & Molinas, M. (2018). **Localization of active brain sources from EEG signals using empirical mode decomposition: a comparative study.** *Frontiers in integrative neuroscience*, 12, 55.
- Ji, N., Ma, L., Dong, H., & Zhang, X. (2019). **EEG signals feature extraction based on DWT and EMD combined with approximate entropy.** *Brain sciences*, 9(8), 201.
- Subasi, A., Jukic, S., & Kevric, J. (2019). **Comparison of EMD, DWT and WPD for the localization of epileptogenic foci using Random Forest classifier.** *Measurement*, 146, 846-855.
- Zeiler, A., Faltermeier, R., Keck, I. R., Tomé, A. M., Puntonet, C. G., & Lang, E. W. (2010, July). **Empirical mode decomposition-an introduction.** In *The 2010 International Joint Conference on Neural Networks (IJCNN)* (pp. 1-8). IEEE.
- Feng, J., He, X., Teng, Q., Ren, C., Chen, H., & Li, Y. (2019). **Reconstruction of porous media from extremely limited information using conditional generative adversarial networks.** *Physical Review E*, 100(3), 033308.
- Vansteensel, M. J., & Jarosiewicz, B. (2020). **Brain-computer interfaces for communication.** In *Handbook of clinical neurology* (Vol. 168, pp. 67-85). Elsevier.
- Kaufmann, T., Schulz, S. M., Grünzinger, C., & Kübler, A. (2011). **Flashing characters with famous faces improves ERP-based brain-computer interface performance.** *Journal of neural engineering*, 8(5), 056016.


- Sellers, E. W., Arbel, Y., & Donchin, E. (2012). **12 BCIs that use P300 event-related potentials**. *Brain-computer interfaces: principles and practice*, 215.
- Powers, J. C., Bieliaieva, K., Wu, S., & Nam, C. S. (2015). **The human factors and ergonomics of P300-based brain-computer interfaces**. *Brain sciences*, 5(3), 318-356.
- Segers, H., Combaz, A., Manyakov, N. V., Chumerin, N., Vanderperren, K., Van Huffel, S., & Van Hulle, M. M. (2011). **Steady state visual evoked potential (SSVEP)-based brain spelling system with synchronous and asynchronous typing modes**. In *15th Nordic-Baltic conference on biomedical engineering and medical physics (NBC 2011)* (pp. 164-167). Springer, Berlin, Heidelberg.
- Hwang, H. J., Lim, J. H., Jung, Y. J., Choi, H., Lee, S. W., & Im, C. H. (2012). **Development of an SSVEP-based BCI spelling system adopting a QWERTY-style LED keyboard**. *Journal of neuroscience methods*, 208(1), 59-65.
- Yuan, H., & He, B. (2014). **Brain-computer interfaces using sensorimotor rhythms: current state and future perspectives**. *IEEE Transactions on Biomedical Engineering*, 61(5), 1425-1435.
- Atangana, R., Tchiotsop, D., GodpromesseKenne, L. C., & Nkengfack, D. (2020). **Suitable mother wavelet selection for EEG signals analysis: frequency bands decomposition and discriminative feature selection**. *Signal Image Process: Int J*, 11(1), 33-49.
- Tumari, S. M., Sudirman, R., & Ahmad, A. H. (2013). **Selection of a suitable wavelet for cognitive memory using electroencephalograph signal**. *Engineering*, 5(05), 15.
- Vokorokos, L., Adam, N., & Madoš, B. (2014). **Non-Invasive Brain Imaging Technique for Playing Chess with Brain-Computer Interface**. *International Journal of Computer and Information Technology*, 3(5), 877-882.
- Knoll, A., Wang, Y., Chen, F., Xu, J., Ruiz, N., Epps, J., & Zarjam, P. (2011, September). **Measuring cognitive workload with low-cost electroencephalograph**. In *Icip*

conference on human-computer interaction (pp. 568-571). Springer, Berlin, Heidelberg.

Howard, M. W., Rizzuto, D. S., Caplan, J. B., Madsen, J. R., Lisman, J., Aschenbrenner-Scheibe, R., ... & Kahana, M. J. (2003). **Gamma oscillations correlate with working memory load in humans.** *Cerebral cortex*, 13(12), 1369-1374.

Sammer, G., Blecker, C., Gebhardt, H., Bischoff, M., Stark, R., Morgen, K., & Vaitl, D. (2007). **Relationship between regional hemodynamic activity and simultaneously recorded EEG-theta associated with mental arithmetic-induced workload.** *Human brain mapping*, 28(8), 793-803.

Borghini, G., Astolfi, L., Vecchiato, G., Mattia, D., & Babiloni, F. (2014). **Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness.** *Neuroscience & Biobehavioral Reviews*, 44, 58-75.



ภาคผนวก ก
บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา

มหาวิทยาลัยเทคโนโลยีสุรนารี

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ระหว่างการศึกษา

Jumphoo, T., Uthansakul, M., & Uthansakul, P. (2017). **Analysis of Suitable Electrode Positions for Writing Imagination.** WCSE 2017, 25-27 June 2017, Beijing, China, pp. 741-745.

Jumphoo, T., Uthansakul, M., & Uthansakul, P. (2019). **Brainwave classification without the help of limb movement and any stimulus for character-writing application.** Cognitive Systems Research, 58, 375-386.

Jumphoo, T., Uthansakul, M., Duangmanee, P., Khan, N., & Uthansakul, P. (2021). **Soft Robotic Glove Controlling Using Brainwave Detection for Continuous Rehabilitation at Home.** CMC-COMPUTERS MATERIALS & CONTINUA, 66(1), 961-976.



Analysis of Suitable Electrode Positions for Writing Imagination

Talit Jumphoo¹, Monthippa Uthansakul¹ and Peerapong Uthansakul¹⁺

School of Telecommunication Engineering, Suranaree University of Technology, NakhonRatchasima,
 Thailand 30000

Abstract. The human brain has many different functions and it is so complicated that each position on human head provides the different electroencephalography signal. It is interesting to find out the suitable electrode positions for a specific brain function. In this work, the writing imagination is on focus because it is curious which brain functions such as imagination, movement, memory, language and perception play the main role on the writing imagination. This paper analyzes to find the suitable electrode positions for recording the electroencephalography signals when we imagine to write either circle or straight line by using artificial neural networks. The results reveal that the suitable electrode positions are the frontal pair of F3 and F4channels. This outcome is very helpful for studying further on writing imagination in the future application.

Keywords: Frontal lobe, Electroencephalography, Cognitive, Artificial Neural Networks.

1. Introduction

In the past, Electroencephalography (EEG) signals recorded from medical equipment was expensive and complicated. But now the development of technology can create an affordable product such as the EEG headset providing a wireless connector such as Emotiv EPOC. It is inexpensive and easy to use so it is very popular in research [1], [2], [3]. Emotiv EPOC has 14 electrodes (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, and AF4) [4]. Fig. 1 shows Emotiv's electrodes placement (Red) and the letters F, T, C, P and O stand for frontal, temporal, central, parietal, and occipital lobes, respectively. To choose a suitable electrode positions for each brain function allows a direct analysis and time saving. In [5], it is shown that the suitable electrode positions according to the brain function of emotion are T7 and T8. In another research studying the hand movement [6] [7], the suitable electrode positions are C3 and C4. In this study, the analysis of the suitable EEG electrodes for writing imagination without using arm muscle has been presented. This can be very useful for any future research that involves a writing imagination.




Fig. 1: International 10–20 system of electrode placement [5] and Emotiv's electrodes placement (Red).

⁺ Corresponding author. Tel.: +66850865588; fax: +6644224603.
 E-mail address: uthansakul@sut.ac.th

2. Methodology

2.1. Data Collection

The data was collected by researcher. He wore an Emotiv EPOC headset and performed to look the animation of circle or straight line as shown in Fig.2. Then, the researcher imagined to write either circle or straight line. The EEG data was obtained by recording from the fourteen electrodes using raw EEG and the bandwidth: 0.2 – 43 Hz, digital notch filters at 50 Hz and 60 Hz [4]. The duration of imagination is 8 seconds for each image. Fig.3 shows the process of data collection which researcher imagines writing the circle in his imagination during the experiment. In this experiment, All EEG datasets were collected from imagining to an animation of circle for 100 datasets and straight line for 100 datasets. The measured EEG datasets will be used to train the artificial neural network learning later.




Fig. 2: The image of circle and straight line for collecting the EEG signals.



Fig. 3: Researcher imagines writing the circle in his imagination during the experiment.

2.2. Learning Artificial Neural Network

The EEG datasets are measured from 14 electrodes named as AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 and AF4. The patterns of EEG signals are learnt by artificial neural network and then they will be compared between each other to find the suitable electrodes based on the correlation coefficients. The correlation coefficients provide the statistical relationships between two or more random variables and observed data values [8], [9] as shown in (1):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

The EEG datasets were normalized by scaling between 0 and 1 as shown in (2) in order to reduce variability [5], [10]:

$$\text{normalize}(X_i) = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (2)$$

Fig. 4 shows the EEG signals of electrodes F3 and F4 which have the most correlation coefficients for recoding the writing imagination of circle(above) and straight line(below). Each electrode is used as input to the learning of individual neural networks. Fig. 5 shows a model of EEG data input of the artificial neural network and vectors of two components are defined as the output targets, Circle [0 1], Line [1 0].




Fig.4: EEG signals of electrodes F3 and F4 which have the most correlation coefficients for recoding the writing imagination of circle (above) and straight line(below).




Fig.5: Input and output of artificial neural network.

2.3. Testing Artificial Neural Network

In this testing, the researchers who have no neuro disorder histories record their EEG signals in order to perform two tasks. For the first task, the researchers imagine to write a circle for 100 times and relax about 1 hour before starting the second task which is the recording of a straight line for 100 times. Then the recorded signals are used as data for testing artificial neural network.

3. Experimental Results and Discussions

Table 1 presents the classification accuracy of 14 electrodes (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 and AF4) when imagining to write a circle. The results reveal that the top-two highest average accuracies can be achieved at positions of F3 and F4 which the accuracies are 70% and 72.86%, respectively. Table 2 presents the classification accuracy of 14 electrodes when researchers imagine writing a straight line. Interestingly, it can be found that the top-two highest average accuracies are at positions of F3 and F4 which the accuracies are 68.57% and 70%, respectively. As seen from both tables, it can be seen that the electrode positions at AF3, F7, F3, F4, F8, and AF4 give the correct results more than 50% when researchers imagine writing a circle and a straight line. From these experimental results, it can be explained that the electrode positions at AF3, F7, F3, F4, F8, and AF4 are placed on frontal lobe area which acts to control concentrating, thinking (such as ideation, imagination) and problem-solving. These experimental results get along with the

area of frontal lobe which was described in Fig. 6 [11]. Note that the important problem in analysing EEG signals is that EEG signals can be generated when a muscle is shifting of the facial such as rise of brow or furrow of brow.

In [12], it was shown that the EEG signals were occurred by facial expressions in each electrode position. Remarkably, it was found that a pair of F3 and F4 channels provided the EEG signals with the minimum correlation to the facial expressions. The outcome of this work also presents the consistency with the research in [13] which a pair of F3 and F4 channels has an important role in the perception of information.

Table1: Classification accuracy of 14 electrodes when researchers imagine writing a circle.

Circle	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
Circle(%) [0 1]	65.71	68.57	70	40	47.14	42.86	64.29	62.86	58.57	44.29	48.57	72.86	61.43	67.14
Line(%) [1 0]	33.28	31.43	30	60	52.86	57.14	35.71	37.14	41.43	55.71	51.43	27.14	38.57	32.86

Table2: Classification accuracy of 14 electrodes when researchers imagine writing a straight line.

Line	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4
Circle(%) [0 1]	32.86	34.29	31.43	37.14	38.57	41.43	68.57	65.71	57.14	37.14	38.57	30	37.14	34.29
Line(%) [1 0]	67.14	65.71	68.57	62.86	61.43	58.57	31.43	33.28	42.86	62.86	61.43	70	62.86	65.71




Fig. 6: Functional areas of the Brain [11].

4. Conclusion

Among all electrode positions on frontal area, the F3 and F4 positions are the suitable electrodes to record the EEG signals for studying writing imagination. These results are considered by using the correlation coefficients in the artificial neural networks. This conclusion is very helpful to investigate the EEG signals in the future because it can save more time and provide a direct analysis on this specific problem. For future work, the authors will apply this study to send some messages by interpreting the brainwave signals.

5. Acknowledgement

This work is financially supported from the Thailand Research Fund through the Royal Golden Jubilee Ph.D. Program (Grant No. PHD/0148/2557)

6. References

- [1] D. Prince, M. Edmonds, A. Sutter, M. Cusumano, W.Lu, and V. Asari, "Brain Machine Interface Using Emotiv EPOC To Control Robai Cyton Robotic Arm," Aerospace and Electronics Conference (NAECON) - 2015, 2379-2027, 15-19 June 2015.
- [2] D. S. Benítez, S. Toscano and A. Silva, "On the use of the Emotiv EPOC neuroheadset as a low cost alternative for EEG signal acquisition ," Communications and Computing (COLCOM) – 2016, 27-29 April 2016
- [3] Vourvopoulos, Athanasios, and Fotis Liarokapis. "Brain-controlled NXT Robot: Tele-operating a robot through brain electrical activity." Games and Virtual Worlds for Serious Applications (VS-GAMES), 2011 Third International Conference on. IEEE, 2011.
- [4] Available at <https://www.emotiv.com>
- [5] Jatupaiboon, Noppadon, Setha Pan-ngum, and Pasin Israsena. "Real-time EEG-based happiness detection system." The Scientific World Journal 2013 (2013).
- [6] Upadhyay, R., et al. "Extraction and classification of Electroencephalogram signals." Computational Intelligence & Computing Research (ICCIC), 2012 IEEE International Conference on. IEEE, 2012.
- [7] Fadzal, CWNF Che Wan, W. Mansor, and L. Y. Khuan. "An analysis of EEG signal generated from grasping and writing." Computer Applications and Industrial Electronics (ICCAIE), 2011 IEEE International Conference on. IEEE, 2011.
- [8] Üstündağ, Mehmet, et al. "Denoising of weak ECG signals by using wavelet analysis and fuzzy thresholding." Network Modeling Analysis in Health Informatics and Bioinformatics 1.4 (2012): 135-140.
- [9] ÜSTÜNDAĞ, Mehmet, et al. "Performance comparison of wavelet thresholding techniques on weak ECG signal denoising." Przegląd Elektrotechniczny 89.5 (2013): 63-66.
- [10] Lin, Yuan-Pin, et al. "Support vector machine for EEG signal classification during listening to emotional music." Multimedia Signal Processing, 2008 IEEE 10th Workshop on. IEEE, 2008.
- [11] Available at <https://avinashkm-neurosurgery.blogspot.com/2013/06/my-philosophy-of-neurosurgery.html>
- [12] L. Vokorokos, N. Ádám, B. Madoš, " Non-Invasive Brain Imaging Technique for Playing Chess with Brain-Computer Interface," International Journal of Computer and Information Technology, ISSN: 2279 – 0764, Volume 03 – Issue 05, September 2014
- [13] Knoll, Y. Wang, F. Chen, J. Xu, N. Ruiz, J. Epps and P. Zarjam, "Measuring cognitive workload with low-cost electroencephalograph," In IFIP Conference on Human-Computer - (2011, September), Interaction (pp. 568-571). Springer Berlin Heidelberg.



ELSEVIER

Available online at www.sciencedirect.com**ScienceDirect**

Cognitive Systems Research 58 (2019) 375–386

**Cognitive Systems
RESEARCH**www.elsevier.com/locate/cogsys

Brainwave classification without the help of limb movement and any stimulus for character-writing application

Action editor: De-Shuang Huang

Talit Jumphoo, Monthippa Uthansakul, Peerapong Uthansakul*

*School of Telecommunication Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand*Received 29 August 2018; received in revised form 6 July 2019; accepted 2 September 2019
Available online 5 September 2019

Abstract

Recently, Brain-Computer Interfaces (BCIs) have been extensively popular for employing Electroencephalography (EEG) signals to control devices with different applications. The use of BCIs currently involves for lots of applications to help the disabilities who cannot communicate with other people, as it is an alternative way for communication by passing the need of speech. Although the applications to spell the character with BCI systems (e.g., P300-speller, SSVEP-speller, Hex-O-spell) have been already developed, but these techniques are not flexible in the real scenarios because they require the stimulus all the time or stopping the activity to focus on the limb movement in order to provide the accuracy of brain responses. In this paper, the feasibility of brainwave classification for the applications of character-writing by considering only the EEG signals without the need of stimulus unlike the literature is newly introduced. This paper adopts a classification technique named Artificial Neural Network (ANN) and focuses on two different characters; straight line and circle. From the experimental results, the suitable position of electrodes are the pair of electrodes (F3 and F4) at the frontal lobe, which provide the best result as compared to other areas due to its important role in perception, maintenance and revival of the information. The experimental results indicate that the classification accuracy of the proposed technique is about 70%, which in turn leads to a significant achievement for the development of character-writing applications.

© 2019 Elsevier B.V. All rights reserved.

Keywords: Brain-computer interfaces; Electroencephalography; Discrete wavelet transform; Artificial neural network

1. Introduction

Human communication is the necessary activity for people to exchange their information with each other as it can build a friendship or any interactions with different family members. Unfortunately, the defective people have a limitation of speaking to communicate with others or even express their feelings as their bodies are disabled e.g. deaf-mute. So far, the Brain-Computer Interface (BCI) system has been used to help those people whose brains still

work very well. The BCI concept is a direct communication between the brain and external devices through the process which the brain activity is translated into commands without the neuromuscular junction. So far, the research methods that use the BCI system for communication can be classified into three types of brain responses including Event-Related Potentials (ERPs), Steady-State Visual-Evoked Potential (SSVEP) and Motor Imagery (MI).

From the works presented in the (Brouwer & Van Erp, 2010; Ryan et al., 2010; Speier, Arnold, Lu, Taira, & Pouratian, 2011), the authors have used the brain response in a format of ERPs to generate small voltages in the brain structures when the brain responds to the specific events or

* Corresponding author.

E-mail address: uthansakul@sut.ac.th (P. Uthansakul).

stimulus e.g. P300 (P3) wave. The P300 (P3) wave is the positive deflected signal in the voltage and it usually occurs around 300 ms after the stimulations with the intensified characters. Its amplitude depends upon the attention of users during the selection of characters for communication. For example, the higher attention generates higher amplitude. This phenomenon has been studied using the BCI for communication mainly known as P300-speller.

The next format of brain response is the Steady-State Visual-Evoked Potential (SSVEP) which occurs due to the result of brain response with respect to visual stimulus (e.g. flickering stimulus) at a specific frequency ranging from 6 Hz to 100 Hz (Bin, Gao, Wang, Hong, & Gao, 2009). When the stimulus is flickering at a stable frequency, the brain generates an electrical signal at the same or integer multiple (harmonic) frequency of the visual stimulus. For this reason, it is possible to detect what the user is looking at the flickering stimulus during that frequency. For example, the screen is divided into quadrants where each quadrant contains a different subset of characters and flickers at different frequencies. When the user stares at the specific quadrant that contains the desired character, the user can communicate to one another. This technique has been widely used in BCI for communication, known as SSVEP-speller (Segers et al., 2011; Volosyak et al., 2009, 2011).

In addition to ERPs and SSVEP, there is Motor Imagery (MI) which occurs during the actual or imagined limb movement and causes the variations in neural population in the motor cortex. These variations are owing to increase (Event-Related Synchronization, ERS) or decrease (Event-Related Desynchronization, ERD) in the vital neuronal populations (Pfurtscheller, 1977, 1992). For instance, the power of Electroencephalography (EEG) decreases ERD from its normal level when the user has the limb movement (actual or imagined) and when the user is at rest without any movement then the power of EEG returns to the normal level (ERS). This phenomenon has been studied in BCI for communication as seen in many applications such as Hex-O-spell and Imagined Writing (Blankertz et al., 2007; Rohani et al., 2013; Zabidi, Mansor, Khuan, & Fadzal, 2012).

The Hex-O-spell is an application which has six hexagons around a circle (with the arrow in the center). Each hexagon contains the characters for the communication. The user can communicate by imagining the movement of the right hand for the rotation of arrow in a clockwise direction and foot movement for controlling the arrow point to the specific hexagon which contains the desired character. From literatures, a BCI for communication that uses the technique of stimulus requires a constant stimulation for generating brain responses. This is not practical for defective persons because the user has to gaze at the stimulus all the time. Similarly, the BCI for communication that uses the technique of limb movement requires stopping an activity because the movement will affect the detection of EEG signals. Whereas in this paper, we propose a

new guideline which has the possibility of imagining the desired characters for communication without the need of focusing on the limb movement and stimulation all the time.

2. Methodology

In this paper, the Emotiv EPOC neuroheadset which utilizes the Bluetooth technology to transfer the EEG raw data between the brain and computer offers a simple usability, portability and inexpensive device as shown in the Fig. 1 (Benitez, Toscano, & Silva, 2016; Prince et al., 2015; Vourvopoulos & Liarokapis, 2011). The electrode positions for the Emotiv device are placed on the key points of scalp, according to the international 10–20 systems as shown in the Fig. 1. The Emotiv device has 14 electrodes which are labeled as AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 and AF4 along with additional two extra electrodes using the Common Mode Sense (CMS) active electrode and the Driven Right Leg (DRL) passive electrode and are referred as P3 and P4. The letters F, T, C, P, and O are the abbreviation of frontal, temporal, central, parietal, and occipital lobes, respectively. The sampling rate of the Emotive device is 128 samples per second and the bandwidth is in between 0.2 and 45 Hz (Description of the emotive headset, 2019).

2.1. Data collection

In this experiment, we create the animations from a structure of characters consisting of lines (horizontal, vertical, oblique) and circle as shown in the Fig. 2. Therefore, the volunteers can imagine the characters in a similar




Fig. 1. Emotiv EPOC headset (a) and Emotiv's electrodes placement (b).




Fig. 2. Slash “/” (a); back slash “\” (b); horizontal line “-” (c); vertical line “|” (d); Circles “O” (rotating counterclockwise (e) and clockwise (f)).

way. In the EEG recording, the volunteers will conduct activities consisting of the following four steps:

1. The volunteer wears Emotiv EPOC neuroheadset on the head.
2. The volunteer focuses on the meditation for around 60 s.
3. The volunteer imagines animations that consists of slash, backslash, horizontal line, vertical line and circles (rotating counterclockwise and clockwise) 100 times per animation.
4. When the volunteer completely imagines the animation for about 30 times, then the volunteer have to rest for 120 s in order to reduce the fatigue of the brain.

The EEG signal will be converted from the continuous-time signal $s(t)$ to a discrete-time signal by substituting $t = nT$

$$s(t) = s(nT)|_{t=nT} \approx s(n) \quad (1)$$

where n is constant integer, $n = 0, \pm 1, \pm 2, \pm 3, \dots$ and T is sampling period. The discrete-time signal $s(n) = \{s(0), s(T), s(2T), \dots, s(nT)\}$ is a data sequence (or dataset) obtained from a continuous-time signal.

2.2. Feature extraction

The EEG signal is filtered using a 5th-order *sinc* filter to notch out the power line noise at 50 Hz and 60 Hz (Description of the emotive headset, 2019). The EEG signal is decomposed using the Discrete Wavelet Transform (DWT) as it is a powerful technique to analyze the non-stationary signal and can represent the signal in both time and frequency domains. The DWT decomposes a time domain signal into different frequency bands using the high-pass and low-pass filters as shown in the Fig. 3. In the low-pass filter, h_0 is its mirror version while the high-pass filter, h_1 is the discrete mother wavelet (Übeyli, 2009). The down sampled signals through the first low-pass and high-pass filters are called the first level approximation (A_1) and detail coefficients (D_1), respectively (Avcı, Hanbay, & Varol, 2007; Roth, Roesch-Ely, Bender, Weisbrod, & Kaiser, 2007). The approximation and the detail coefficients of next level are obtained using the approximation coefficient of the previous level as shown in the Fig. 3. The dominant frequency components of the signals will determine the number of decomposition levels. Wavelet function, $\psi_{j,k}(n)$ based on high-pass filter and scaling function $\varphi_{j,k}(n)$ based on low-pass filter are defined as:

$$\psi_{j,k}(n) = 2^{j/2} h_1(2^j n - k) \quad (2)$$

$$\varphi_{j,k}(n) = 2^{j/2} h_0(2^j n - k) \quad (3)$$

where $n = 0, 1, 2, \dots, M-1$, $j = 0, 1, 2, \dots, J-1$, $k = 0, 1, 2, \dots, 2^{j-1}$, J equals to $\log_2(M)$ and M is the length of the signal and chosen as 2^j (Gonzalez & Woods, 2002). The resolution j and sampling rate k specify the widths on the x-axis of functions and the positions, respectively. The amplitudes of functions are dependent on the $2^{j/2}$ value (Gonzalez & Woods, 2002). Detail coefficients $D_i(k)$ and approximation coefficients $A_i(k)$ in the i^{th} level are described as:

$$D_i = \frac{1}{\sqrt{M}} \sum_n s(n) \cdot \psi_{j,k}(n) \quad (4)$$

$$A_i = \frac{1}{\sqrt{M}} \sum_n s(n) \cdot \varphi_{j,k}(n) \quad (5)$$

For $k = 0, 1, 2, \dots, 2^{j-1}$

In this paper, we use the DWT decomposition at level 4th for all the EEG data and daubechies 4 (db4) which is commonly used in the analysis of EEG signal with DWT (Adeli, Zhou, & Dadmehr, 2003; Kar, Bhagat, & Routray, 2010; Rafiee, Rafiee, Prause, & Schoen, 2011;




Fig. 3. Decomposition of DWT implementation; h_1 is the high-pass filter, h_0 the low-pass filter.

Tumari, Sudirman, & Ahmad, 2013; Xu, Zhou, Wang, & Huang, 2009). Table 1 shows the different levels of wavelet decomposition which corresponds to the brain signal at frequency bands e.g., gamma, beta, alpha, theta, delta. Figs. 4 and 5 shows the approximated and detailed coefficients of the obtained EEG segments from the healthy volunteers who imagine the animation of a horizontal line and the circle (counterclockwise rotation), respectively.

In this work, the wavelet coefficients (detail and approximation) of the EEG signals were used as the feature vectors representing the signals. If $X\{x_1, x_2, \dots, x_N\}$ and $Y\{y_1, y_2, \dots, y_N\}$ are two adjacent sub-bands, where N represents the length of a sub-band. The feature vectors of the EEG signals can be represented using the following statistical features.

- (1) Mean of the absolute values in each sub-band.

$$\mu = \frac{1}{N} \sum_{j=1}^N |x_j| \quad (6)$$

- (2) Average power of the wavelet coefficients in each sub-band.

$$p = \sqrt{\frac{1}{N} \sum_{j=1}^N x_j^2} \quad (7)$$

- (3) Standard deviation of the wavelet coefficients in each sub-band.

$$\sigma = \sqrt{\frac{1}{N} \sum_{j=1}^N (x_j - \mu)^2} \quad (8)$$

- (4) Ratio of the absolute mean values of adjacent sub-bands.

$$R = \frac{\sum_{j=1}^N |x_j|}{\sum_{j=1}^N |y_j|} \quad (9)$$

- (5) Skewness of the wavelet coefficients in each sub-band.

$$Sk = \sqrt{\frac{1}{N} \sum_{j=1}^N \frac{(x_j - \mu)^3}{\sigma^3}} \quad (10)$$

- (6) Kurtosis of the wavelet coefficients in each sub-band.

$$Ku = \sqrt{\frac{1}{N} \sum_{j=1}^N \frac{(x_j - \mu)^4}{\sigma^4}} \quad (11)$$

Features 1–4 represent the frequency distribution of the signal and the features 5 and 6 help to exact the nonlinear behavior from the EEG signal. The feature vectors are normalized by scaling between -1 and 1 as shown in (12) to reduce the variability (Jatupaiboon, Pan-ngum, & Israsena, 2013; Lin, Wang, Wu, Jeng, & Chen, 2008):

$$\text{Normalize}(\hat{X}_i) = 2 \frac{X_i - X_{min}}{X_{max} - X_{min}} - 1 \quad (12)$$

where i is the order of the dataset (or feature vectors), X_{max} is the maximum value of dataset, X_{min} is the minimum value of dataset and \hat{X}_i is the normalized data of i^{th} order. The EEG datasets after normalization will be used to train the Artificial Neural Network (ANN) learning later on.

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

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




Fig. 4. Approximated and detailed coefficients of a sample EEG segment obtained from the imagination related to horizontal line.

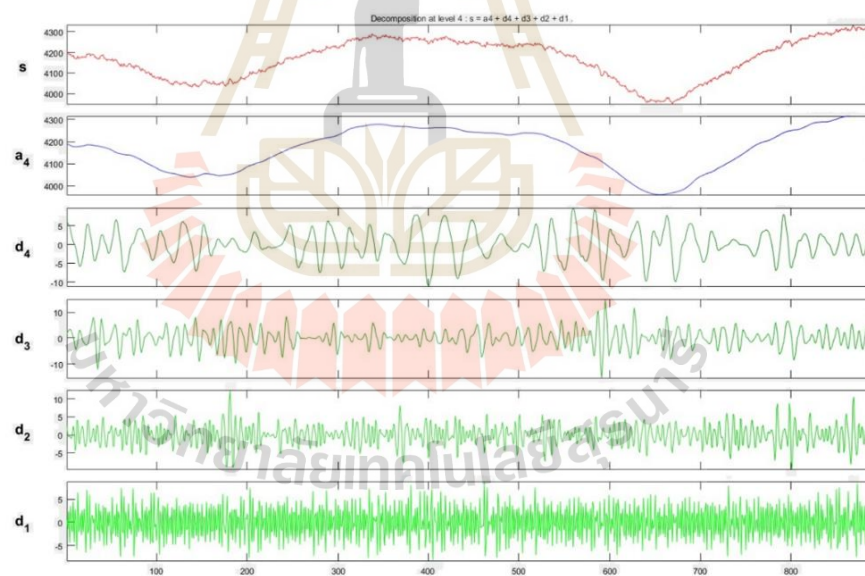


Fig. 5. Approximated and detailed coefficients of a sample EEG segment obtained from the imagination related to circle (rotating counterclockwise).

2.3. Classification

The ANN is a computing system which has inspiration from the structure of the human brain. The ANN is a highly interconnected network of a large number of processing elements called nodes or artificial neurons. The learning process in the ANN is accomplished through training algorithms and supervising learning which uses the data examples for training. Once appropriately trained, the ANN can be effectively used for solving the complex problem (El Bahy, Hosny, Mohamed, & Ibrahim, 2016; Tibdewal, Fate, Mahadevappa, & Ray, 2015). In this paper, we use the ANN model from the toolbox of MATLAB software which is designed for the pattern recognition and classification of EEG data, named the Multilayer Perceptron Neural Network (MLPNN) as shown in the Fig. 6. In the architecture of MLPNN, each neuron (j) in the hidden layer sums its input feature vectors (\hat{X}_i) after multiplying them with the strengths of the respective connection weights (w_{ji}) and computes its output (y_j) as a function of the sum:

$$y_j = f\left(\sum w_{ji}\hat{X}_i\right) \quad (13)$$

where f is the activation function that is significant to transform the weighted sum of all signals impinging onto a neuron. The activation function (f) can be a simple threshold function, or a sigmoidal, hyperbolic tangent, or radial basis function. In this paper, in the hidden layer and the output layer, the activation function (f) was the tangent-sigmoid (tansig) function. The sum of squared differences between the desired and actual values of the output neurons E is defined as:

$$E = \frac{1}{2} \sum_j (y_{dj} - y_j)^2 \quad (14)$$

where y_{dj} is the desired value of output neuron j and y_j is the actual output of that neuron. Each weight (w_{ji}) is




Fig. 6. Artificial neural network's Multi-Layer Perceptrons.

adjusted to reduce E as rapidly as possible. The adjustment of weight (w_{ji}) is dependent on the training algorithm.

The most vital feature of the ANN is the training algorithm. The MLPNN can be trained with so many algorithms and the most commonly used algorithm is the backpropagation training algorithm. The backpropagation algorithm is comparatively easy to implement because it is based on looking for the points on the surface with a minimum error using the gradient descent technique. Whereas, the issues with the backpropagation algorithm are the indefinability of the algorithm while calculating the global minimum of the error function using the gradient descent technique and the long training sessions in order to compute the acceptable weight solution. However, various techniques have been proposed in order to improve the convergence of backpropagation algorithm. The methods (Levenberg–Marquardt (LM), conjugate gradient, quasi-Newton) are the optimization methods for the training of the ANN and they have been used by the researchers in the recent years. The LM algorithm contains the best features of the steepest-descent algorithm and Gauss-Newton technique and does not get suffered with the slow convergence problem.

The LM algorithm is a least-squares estimation algorithm based on the maximum neighborhood concept. Let w be the weight vector of each signal and $E(w)$ is an error function that has to be minimized. The computation of error function having the error terms $e_j^2(w)$ for the m individual errors can be written as:

$$E(w) = \sum_{i=1}^m e_i^2(w) \quad (15)$$

where $e_i^2(w) = (y_{dj} - y_j)^2$ and y_{dj} is the desired value of output neuron j , y_j is the actual output of that neuron. The purpose of the LM algorithm is to compute the weight vector w such that $E(w)$ is minimum. Using the LM algorithm, a new weight vector for each signal w_{k+1} can be obtained from the previous weight vectors w_k as follows:

$$w_{k+1} = w_k + \delta w_k \quad (16)$$

where δw_k is defined as:

$$\delta w_k = -(J_k^T f(w_k)) (J_k^T J_k + \lambda I)^{-1} \quad (17)$$

From (17), J_k is the Jacobian of the function f at w_k , λ represents the Marquardt parameter and I is the identity matrix. The LM algorithm can be summarized as follows:

- Step 1: Error function ($E(w)$) computation
- Step 2: Assign minimum value to Marquardt parameter λ ($\lambda = 0.01$)
- Step 3: Solve (11) for δw_k and the computation of weight vectors $E(w_{k+1})$
- Step 4: If $E(w_{k+1}) \geq E(w_k)$, increase the λ and go to (Step 3)
- Step 5: If $E(w_{k+1}) < E(w_k)$, decrease the λ , update $w_k : w_k \leftarrow w_{k+1}$ and go to (Step 3).

The network performance depends upon the Mean Squared Error (MSE) value. When the MSE value between the network outputs and the targets is less than or equal to the determined value, the learning process is stopped. After the process of learning the network, we will be testing the network with the new EEG data which is obtained from the similar process in the previous EEG recording. The performance of the classifier can be measured with accuracy percentage by using the following formula:

$$\text{Accuracy (\%)} = \frac{(TP + TN)}{(TP + FN + FP + TN)} \times 100 \quad (18)$$

where *TP* (True Positive) is the number of correctly classified cases and actual correctly, *TN* (True Negative) is the number of incorrectly classified cases and actual incorrectly, *FP* (False Positive) is the number of correctly classified cases, but actual incorrectly and *FN* (False Negative) is the number of incorrectly classified cases, but actual correctly.

3. Experimental results

3.1. Offline analysis

In this paper, we have conducted experiments by employing five healthy volunteers who have no history of psychiatric problems or neuro disorders. The volunteers were guided and explained about the research objectives and their permission were taken to conduct this experiment. Each position on the human head provides different EEG signals because the human brain has different type of functions and so complicated signal. Therefore, we find out the suitable electrode positions for a specific brain function in order to reduce the number of electrode positions and time of computation. Each of the position that is the pair of electrodes i.e. AF3-AF4, F3-F4, F7-F8, FC5-FC6, P7-P8, T7-T8, and O1-O2 was considered by comparing the accuracy of classification. Fig. 7 shows the highest average accuracy for the pair of electrodes where the accuracy

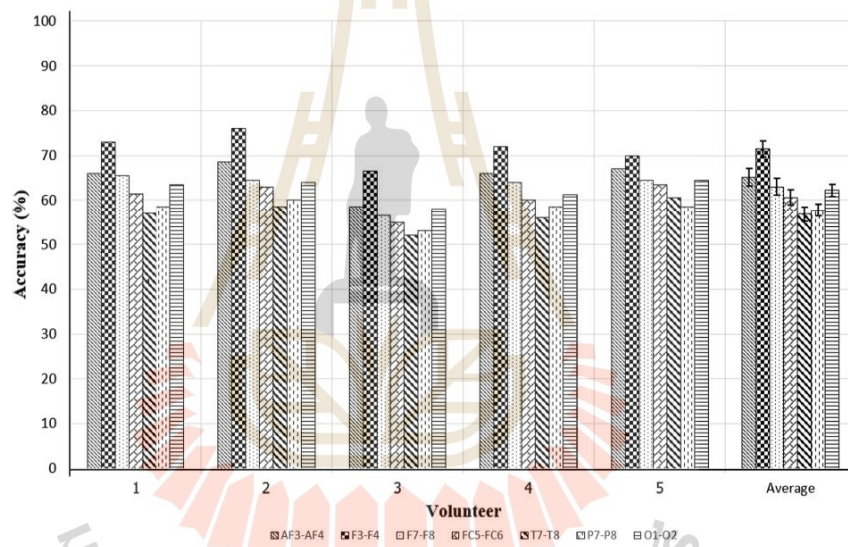


Fig. 7. Classification accuracy from the pair of electrodes.

Table 2

Classification accuracy from the imagination related to circles (rotating counterclockwise and clockwise).

The structure of character	Classification accuracy from the imagination related to character "O" (%)				
	The volunteer 1	The volunteer 2	The volunteer 3	The volunteer 4	The volunteer 5
Clockwise	72.5	72.5	64	70.5	67.5
Counterclockwise	74	75	65.5	71.5	69
Horizontal line	34.5	37	35.5	36.5	37.5
Vertical line	32.5	32.5	38	30	32
Slash	35	34	35.5	31	32
Backslash	29	31.5	35	36.5	35.5

Table 3

Classification accuracy from the imagination related to lines (horizontal, vertical, slash and backslash).

The structure of character	Classification accuracy from the imagination related to lines (horizontal “-”, vertical “ ”, slash “/” and backslash “\”) (%)				
	The volunteer 1	The volunteer 2	The volunteer 3	The volunteer 4	The volunteer 5
Clockwise	31.5	33	31.5	34.5	31.5
Counterclockwise	34	36	33	35.5	35
Horizontal line	73.5	76.5	65	72	70
Vertical line	56.5	56.5	45.5	45	52.5
Slash	55	57.5	41	41.5	43
Backslash	53.5	56.5	43	46.5	45




Fig. 8. Classification accuracy from different frequency bands.



Fig. 9. Matlab GUI for real-time character-writing system.

comes out to be $71.5 \pm 1.77\%$ at the positions of F3 and F4. Therefore, we will use the positions F3 and F4 instead of the remaining fourteen electrodes in the next operative experiments.

Subsequently, we want to find out the possibility in imagination related to the structure of character which consists of slash, backslash, horizontal line, vertical line and circles (rotating clockwise and counterclockwise). Table 2 shows the accuracy of classification when the volunteer imagines circles rotating clockwise and counterclockwise. The results reveal the average accuracy of circles between the counterclockwise and clockwise rotation of $71 \pm 1.93\%$ and $69.4 \pm 1.82\%$, respectively. Similarly, Table 3 shows the accuracy of classification when the volunteer imagines slash, backslash, horizontal line and vertical line. The results show the highest average accuracy of $71.4 \pm 2.15\%$, which is obtained from the imagination of horizontal line. Moreover, we compare the accuracy among different frequency bands which consist of gamma, beta, alpha, theta and delta obtained from the imagination of the horizontal line and counterclockwise rotating circles. The results are shown in the Fig. 8 where the average accuracies come out to be $70 \pm 1.7\%$, $69.5 \pm 1.18\%$, $69.5 \pm 1.38\%$, and $69 \pm 1.47\%$ as referred to gamma, beta, alpha and theta, respectively.

3.2. Real-time character-writing system

We implemented the real time character writing system using the Matlab GUI with the help of experimental results in the offline analysis as shown in the Fig. 9.

The GUI consists of several sections:

- Display the words
- Decision the character
- Options

A --	B ----	C ----
D ...	E .	F ...
G ---	H	I ..
J ----	K --	L
M --	N --	O ---
P ----	Q ----	R ...
S ...	T -	U ...
V	W ...	X ----
Y ----	Z ----	

Fig. 10. Morse code symbol.

The “Connect” in the options section is used to handle the connection between the Emotiv EPOC+ Headset and computer via the “Bluetooth”. Once the connection gets established, the user may proceed by clicking on the “Start”. Furthermore, the user can see the morse code pattern of each character by clicking on the “Show Morse Code” as shown in the Fig. 10.

The “Decision the character” section shows the output from the classification of brainwave to circle “O” or line “-” at the electrode positions of F3 and F4 as can be seen in the Fig. 9. The working of the character-writing system shown in the Fig. 11 is described as follows. First, the EEG signals are decomposed into 4 frequency sub-bands (i.e.

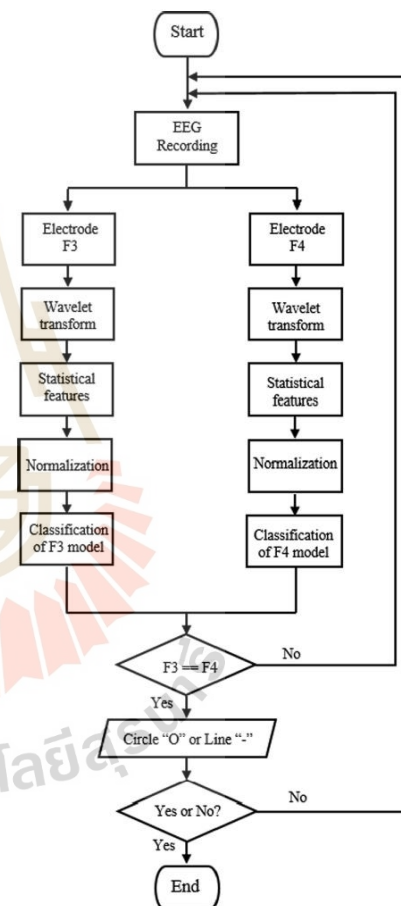


Fig. 11. Flowchart of real-time character-writing system.

Gamma, Beta, Alpha and Theta) using the wavelet transform. Second, we compute the statistical features of each sub-band. With 2 channels, there are total six feature vectors in each sub-band. Third, each feature vector is normalized by scaling between the -1 and 1 . Fourth, the normalized feature vectors are inserted into the classification model, created from the previous experiment, to classify the circle “O” or Line “-”. If the output of F3 classification model is equal to the F4 classification model, the detected character will be the circle “O” or line “-” depending upon the output values. Then, the system will question the user with the options of Yes or NO. If the user chooses No, the user will have to blink the eye in order to return to new EEG signal recording. If the user chooses Yes, the user will have to meditate around 2–3 sec to display the result. In the small square box, the circle “O” or line “-” will appear depending upon the decision of the user, who wants to display the character according to the pattern of Morse code.

The “Display the word” section shows (displays) the word that the user wants to communicate with other people following the process in the section “Decision the character”. An example shown in the section Fig. 9 presents the word “HELLO” in which the last character is “O” according to the pattern of Morse code, which contains three lines “-” as shown in the small square box.

4. Discussions

From experimental results, we can conclude that the suitable position of the electrodes comes out to be a pair of electrodes (F3 and F4) at frontal lobe and provides the best results as compared to other areas due to its important role in the perception of information and corresponds to the work presented in (Gevins & Smith, 2003; Knoll et al., 2011). Considering different frequency bands, the results show that the frequency bands are composed of

gamma, beta, alpha and theta, and have almost similar average classification accuracy. Interestingly, these frequency bands are related to the animations in which the volunteers are imagined at that specific moment. To explain these results, we divide the process into 3 parts as shown in the Fig. 12. The first part is the perception of the information by gazing at the animation in consistent with the activity of beta wave. Its activity is the usual waking rhythm of the brain associated with active thinking, active attention, and focusing the outside. The second part is the process of working memory having the role of responsible importing, sorting, and obtaining the maintenance information; consequently it causes the higher gamma wave (Fitzgibbon, Pope, Mackenzie, Clark, & Willoughby, 2004; Howard et al., 2003). The final part is the process of mental workload by retrieving the information from the working memory and uses the retrieved information in response to the imagination of the structure of character. This process causes the higher alpha and theta waves which are consistent with the works presented in (Borghini, Astolfi, Vecchiato, Mattia, & Babiloni, 2014; Lei & Roetting, 2011; Sammer et al., 2007). Therefore, we can conclude that the character-writing imagination affects the four frequency bands which are composed of gamma, beta, alpha and theta.

5. Conclusions

In this research, we have found the possibility of brain-wave classification without the help of limb movement and any stimulus for the applications of character-writing. Two obviously classified characters are “-” and “O”. Considering each pair of electrodes, we have found that the position of the electrodes (F3 and F4) at frontal lobe provides the best result as compared to other areas due to its important role in the perception, maintenance and revival of the obtained information. By comparing the accuracy of

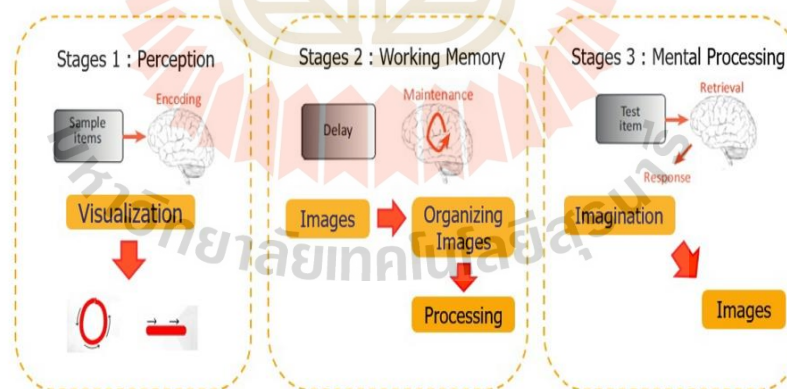


Fig. 12. The brain activity in 3 processes which are perception, maintenance and retrieval.

classification among different frequency bands, we have found that the imagination of the horizontal line and counterclockwise rotating circle affects four frequency bands which are composed of gamma, beta, alpha and theta. We can create an application to spell the character with BCI-based through the imagination with a pattern of Morse code without any focusing on the limb movement and stimulation all the time. This application uses the specific positions of the electrodes (F3 and F4) in order to record EEG signal obtained from the imagination of the horizontal line and counterclockwise rotating circle and detection with four frequency bands which are composed of gamma, beta, alpha and theta.

Declaration of Competing Interest

The authors declared that there is no conflict of interest.

Acknowledgements

This work is financially supported from the Thailand Research Fund through the Royal Golden Jubilee Ph.D. Program (Grant No. PHD/0148/2557) and obtain ethics committee approval of human research from Suranaree University of Technology (License EC-61-14 COA No. 16/2561).

References

- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of EEG records in an epileptic patient using wavelet transform. *Journal of Neuroscience Methods*, 123(1), 69–87.
- Avci, E., Hanbay, D., & Varol, A. (2007). An expert discrete wavelet adaptive network based fuzzy inference system for digital modulation recognition. *Expert Systems with Applications*, 33(3), 582–589. <https://doi.org/10.1016/j.eswa.2006.06.001>.
- Benitez, D. S., Toscano, S., & Silva, A. (2016). On the use of the Emotiv EPOC neuroheadset as a low cost alternative for EEG signal acquisition. In *2016 IEEE Colombian conference on communications and computing (COLCOM)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ColComCon.2016.7516380>.
- Bin, G., Gao, X., Wang, Y., Hong, B., & Gao, S. (2009). VEP-based brain-computer interfaces: Time, frequency, and code modulations. *IEEE Computational Intelligence Magazine*, 4(4), 22–26. <https://doi.org/10.1109/MCI.2009.934562>.
- Blankertz, B., Krauledat, M., Dornhege, G., Williamson, J., Murray-Smith, R., & Müller, K. R. (2007). A note on brain actuated spelling with the Berlin brain-computer interface. *UAHCI 2007: Universal access in human-computer interaction. Ambient interaction* (Vol. 1, pp. 759–768). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-540-73281-5_83.
- Borghini, G., Astolfi, L., Vecchiato, G., Mattia, D., & Babiloni, F. (2014). Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness. *Neuroscience & Biobehavioral Reviews*, 44, 58–75.
- Brouwer, A. M., & Van Erp, J. B. (2010). A tactile P300 brain-computer interface. *Frontiers in Neuroscience*, 4, 19. <https://doi.org/10.3389/fnins.2010.00019>.
- Description of the emotive headset (2019). <https://www.emotiv.com/product/emotiv-epoc-14-channel-mobile-eeeg/#tab-description/> (accessed 2 July 2019).
- El Bahy, M. M., Hosny, M., Mohamed, W. A., & Ibrahim, S. (2016). EEG signal classification using neural network and support vector machine in brain computer interface. *AISI 2016: Proceedings of the international conference on advanced intelligent systems and informatics 2016* (Vol. 1, pp. 246–256). Cham: Springer. https://doi.org/10.1007/978-3-319-48308-5_24.
- Fitzgibbon, S. P., Pope, K. J., Mackenzie, L., Clark, C. R., & Willoughby, J. O. (2004). Cognitive tasks augment gamma EEG power. *Clinical Neurophysiology*, 115(8), 1802–1809.
- Gevens, A., & Smith, M. E. (2003). Neurophysiological measures of cognitive workload during human-computer interaction. *Theoretical Issues in Ergonomics Science*, 4(1–2), 113–131. <https://doi.org/10.1080/14639220210159717>.
- Gonzalez, R. C., & Woods, R. E. (2002). *Digital image processing* (2nd ed.). New Jersey: Prentice Hall (Chapter 7).
- Howard, M. W., Rizzuto, D. S., Caplan, J. B., Madsen, J. R., Lisman, J., Aschenbrenner-Scheibe, R., ... Kahana, M. J. (2003). Gamma oscillations correlate with working memory load in humans. *Cerebral Cortex*, 13(12), 1369–1374.
- Jatupaiboon, N., Pan-ngum, S., & Israsena, P. (2013). Real-time EEG-based happiness detection system. *The Scientific World Journal*, 1–12. <http://www.hindawi.com/journals/tswj/2013/618649/>. <https://doi.org/10.1155/2013/618649>.
- Kar, S., Bhagat, M., & Routray, A. (2010). EEG signal analysis for the assessment and quantification of driver's fatigue. *Transportation Research Part F: Traffic Psychology and Behaviour*, 13(5), 297–306. <https://doi.org/10.1016/j.trf.2010.06.006>.
- Knoll, A., Wang, Y., Chen, F., Xu, J., Ruiz, N., Epps, J., & Zarjam, P. (2011). Measuring cognitive workload with low-cost electroencephalograph. *INTERACT 2011: Human-computer interaction – INTERACT 2011, September* (Vol. 4, pp. 568–571). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-642-23768-3_84.
- Lei, S., & Roetting, M. (2011). Influence of task combination on EEG spectrum modulation for driver workload estimation. *Human Factors*, 53(2), 168–179.
- Lin, Y. P., Wang, C. H., Wu, T. L., Jeng, S. K., & Chen, J. H. (2008). Support vector machine for EEG signal classification during listening to emotional music. In *2008 IEEE 10th workshop on multimedia signal processing* (pp. 127–130). IEEE. <https://doi.org/10.1109/MMSP.2008.4665061>.
- Pfurtscheller, G. (1977). Graphical display and statistical evaluation of event-related desynchronization (ERD). *Electroencephalography and Clinical Neurophysiology*, 43(5), 757–760.
- Pfurtscheller, G. (1992). Event-related synchronization (ERS): An electrophysiological correlate of cortical areas at rest. *Clinical Neurophysiology*, 83(1), 62–69.
- Prince, D., Edmonds, M., Sutter, A., Cusumano, M., Lu, W., & Asari, V. (2015). Brain machine interface using Emotiv EPOC to control robotic arm. In *2015 national aerospace and electronics conference (NAECON)* (pp. 263–266). IEEE. <https://doi.org/10.1109/NAECON.2015.7443080>.
- Rafiee, J., Rafiee, M. A., Prause, N., & Schoen, M. P. (2011). Wavelet basis functions in biomedical signal processing. *Expert Systems with Applications*, 38(5), 6190–6201. <https://doi.org/10.1016/j.eswa.2010.11.050>.
- Rohani, D. A., Henning, W. S., Thomsen, C. E., Kjaer, T. W., Puthusserypady, S., & Sorensen, H. B. (2013). BCI using imaginary movements: The simulator. *Computer Methods and Programs in Biomedicine*, 111(2), 300–307.
- Roth, A., Roesch-Ely, D., Bender, S., Weisbrod, M., & Kaiser, S. (2007). Increased event-related potential latency and amplitude variability in schizophrenia detected through wavelet-based single trial analysis. *International Journal of Psychophysiology*, 66(3), 244–254.
- Ryan, D. B., Frye, G. E., Townsend, G., Berry, D. R., Mesa-G, S., Gates, N. A., & Sellers, E. W. (2010). Predictive spelling with a P300-based brain-computer interface: Increasing the rate of communication. *Intl. Journal of Human-Computer Interaction*, 27(1), 69–84.

- Sammer, G., Blecker, C., Gebhardt, H., Bischoff, M., Stark, R., Morgen, K., & Vaitl, D. (2007). Relationship between regional hemodynamic activity and simultaneously recorded EEG-theta associated with mental arithmetic-induced workload. *Human Brain Mapping*, 28(8), 793–803.
- Segers, H., Combaz, A., Manyakov, N. V., Chumerin, N., Vanderperren, K., Van Huffel, S., & Van Hulle, M. M. (2011). Steady state visual evoked potential (SSVEP)-based brain spelling system with synchronous and asynchronous typing modes. *15th Nordic-Baltic conference on biomedical engineering and medical physics (NBC 2011)* (Vol. 34, pp. 164–167). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-642-21683-1_41.
- Speier, W., Arnold, C., Lu, J., Taira, R. K., & Pouratian, N. (2011). Natural language processing with dynamic classification improves P300 speller accuracy and bit rate. *Journal of Neural Engineering*, 9(1), 016004.
- Tibdewal, M. N., Fate, R. R., Mahadevappa, M., & Ray, A. (2015). Detection and classification of eye blink artifact in electroencephalogram through discrete Wavelet Transform and neural network. In *2015 international conference on pervasive computing (ICPC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/PERVASIVE.2015.7087077>.
- Tumari, S. M., Sudirman, R., & Ahmad, A. H. (2013). Selection of a suitable wavelet for cognitive memory using electroencephalograph signal. *Engineering (ENG)*, 5(5B), 15–19. <https://doi.org/10.4236/eng.2013.55B004>.
- Übeyli, E. D. (2009). Combined neural network model employing wavelet coefficients for EEG signals classification. *Digital Signal Processing*, 19(2), 297–308. <https://doi.org/10.1016/j.dsp.2008.07.004>.
- Volosyak, I., Cecotti, H., & Gräser, A. (2009). Impact of frequency selection on LCD screens for SSVEP based brain-computer interfaces. *IWANN 2009: Bio-Inspired systems: computational and ambient intelligence* (Vol. 1, pp. 706–713). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-642-02478-8_88.
- Volosyak, I., Moor, A., & Gräser, A. (2011). A dictionary-driven SSVEP speller with a modified graphical user interface. *IWANN 2011: Advances in computational intelligence* (Vol. 1, pp. 353–361). Berlin, Heidelberg: Springer. https://doi.org/10.1007/978-3-642-21501-8_44.
- Vourvopoulos, A., & Liarokapis, F. (2011). Brain-controlled NXT Robot: Tele-operating a robot through brain electrical activity. In *2011 third international conference on games and virtual worlds for serious applications, May* (pp. 140–143). IEEE. <https://doi.org/10.1109/VSGAMES.2011.27>.
- Xu, Q., Zhou, H., Wang, Y., & Huang, J. (2009). Fuzzy support vector machine for classification of EEG signals using wavelet-based features. *Medical Engineering and Physics*, 31(7), 858–865.
- Zabidi, A., Mansor, W., Khuan, Y. L., & Fadzal, C. C. W. (2012). Classification of imagined writing from EEG signals using autoregressive features. In *2012 international symposium on computer applications and industrial electronics (ISCAIE)* (pp. 205–208). IEEE. <https://doi.org/10.1109/ISCAIE.2012.6482097>.



Soft Robotic Glove Controlling Using Brainwave Detection for Continuous Rehabilitation at Home

Talit Jumphoo¹, Monthippa Uthansakul¹, Pumin Duangmanee¹, Naeem Khan² and Peerapong Uthansakul^{1,*}

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

²Faculty of Electrical and Computer Engineering, University of Engineering and Technology Peshawar, Peshawar, 25000, Pakistan

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

Received: 30 June 2020; Accepted: 14 September 2020

Abstract: The patients with brain diseases (e.g., Stroke and Amyotrophic Lateral Sclerosis (ALS)) are often affected by the injury of motor cortex, which causes a muscular weakness. For this reason, they require rehabilitation with continuous physiotherapy as these diseases can be eased within the initial stages of the symptoms. So far, the popular control system for robot-assisted rehabilitation devices is only of two types which consist of passive and active devices. However, if there is a control system that can directly detect the motor functions, it will induce neuroplasticity to facilitate early motor recovery. In this paper, the control system, which is a motor recovery system with the intent of rehabilitation, focuses on the hand organs and utilizes a brain-computer interface (BCI) technology. The final results depict that the brainwave detection for controlling pneumatic glove in real-time has an accuracy up to 82%. Moreover, the motor recovery system enables the feasibility of brainwave classification from the motor cortex with Artificial Neural Networks (ANN). The overall model performance reveals an accuracy up to 96.56% with sensitivity of 94.22% and specificity of 98.8%. Therefore, the proposed system increases the efficiency of the traditional device control system and tends to provide a better rehabilitation than the traditional physiotherapy alone.

Keywords: Rehabilitation; control system; Brain-Computer Interface (BCI); Artificial Neural Networks (ANN)

1 Introduction

The patients with brain diseases (e.g., Stroke and Amyotrophic Lateral Sclerosis (ALS)) are often affected by the injury of motor cortex, which causes a muscular weakness. This is the major cause of disability and affects the Activities of Daily Living (ADL) [1,2]. In addition, the report of World Health Organization (WHO) has shown that the stroke is the second leading cause of death worldwide. This is associated with the deaths of approximately 6 million people around the world each year [3–5]. Until now, the number of stroke patients has increased as the world population is entering an aging society [6]. The most common effect of stroke survivors is muscle weakness or partial paralysis, which is confined to



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

one side of the body and is known as hemiparesis. Likewise, ALS is one of the neurological diseases that affect nerve cells in the brain. When motor function is degraded, the patients may not be able to move some of his muscles. In no time, nerve cells begin to die, which eventually leads to a loss of motion control and then the patient becomes paralyzed [7]. However, these diseases can be alleviated in the early stages of symptoms [8–10].

Therefore, post-stroke motor recovery and ALS during the first few months are very important to initiate continued motor regeneration. Repetitive rehabilitation can stimulate motor activity to help the patient in terms of learning to regulate movement again [11,12]. However, patients can undergo physical rehabilitation in minimal time as there are no physical therapists and early rehabilitation equipment available. In addition, patients often refuse to go to rehab at hospital. As a result, the patient does not receive physical therapy continuously. Hence, robotic rehabilitation can help solve the problem, as it can record patients' real-time data for clinical follow-up to improve remote rehabilitation, alongside customizing their own in-house therapies [13–16]. Recently, researchers have come up with ideas for developing rehabilitation-assisted robots to improve the effectiveness of physical therapy [17–21]. In general, robotic rehabilitation focuses on restoring the upper and lower limbs rather than hand/finger rehabilitation, but the hands are one of the most important parts of the body as they play a fundamental role in the work. Recovering hand function can help patients in terms of ADL.

In addition, the control system of restoring robots is an important type of research. Popular control systems for restoration robots include Continuous Passive Motion (CPM), Active-Assisted Movement (AAM) and Surface electromyography (sEMG) sensors [22–25]. CPM is an automated rehabilitation system in which the patient was continually rehabilitated according to the design without any effort. CPM is used during the early stages of rehabilitation as the patient is unable to exert himself. AAM and sEMG are the rehabilitation systems in which the patient must first exert himself, and then use motion aids. Both methods are suitable for the second stage patients, allowing them to move some muscles. In addition, both passive and active control systems can be enhanced in regeneration using brain wave detection. Therefore, if there is a control system that can directly detect motor activity and increase the participation of the patient during the rehabilitation process, it can induce neural resilience to facilitate the early recovery of motor.

In this article, we present a control system named motor recovery system with the intent of rehabilitation utilizing Brain-Computer Interface (BCI) technology. The BCI is a technology that uses brainwaves to analyze and translates them into commands, and then relay to output devices for desired actions [26,27]. In BCI at non-invasive stage, the brainwaves that acquire the movement intention of users (e.g., motor imagery or execution) are decoded in real-time with the help of feature extraction. Then, the neuro-feedback system is utilized to increase the user performance by linking the intent to execute a movement [28–30]. The neuro-feedback is the measurement of brain activities to produce data for teaching self-regulation of brain function and present it with a positive or negative response to closed-loop control [31]. The active motor is intentionally trained and reproduced to stimulate the first cortical motor cortex, providing a better rehabilitation results compared to automatic (passive) movements or limb-only (active) stimulation [32–34]. In addition, physical therapy in conjunction with mindfulness is more interesting [35–37]. The experience of brain disease negatively impacts patients' mental health. Recently, researchers have revealed that meditation, along with physical therapy, is more effective than conventional physical therapy alone [38]. Therefore, the motor recovery system has two steps: The first step is to detect brain wave while the user deliberately meditates to perform robotic-assisted regenerative control. In the second step, the patient can generate some of brain waves from the motions to form a norm. Hence, the motor recovery system detects brain waves in the motor cortex area while the user is controlling the robot-assisted rehabilitation.

2 Methodology

In this paper, motor recovery systems focus on affordable, agile, and easy-to-wear solutions for rehabilitation. A commercial low-cost EEG headset was named NeuroskyMindwave and OpenBCI used in the experiment. Both headsets include dry-type electrodes that must be placed on specific scalp locations according to the 10–20 international systems as shown in Fig. 1. The EEG headset can measure different brainwave voltage fluctuations due to ionic current in brain neurons. The EEG sensor converts these voltage fluctuations into digital outputs to be sent to the device's microcontroller using wireless technology. Most observed brain waves range from 1–40 Hz. These waves are categorized into delta, theta, alpha, beta, and gamma. Delta waves (<4 Hz) are most likely to be observed during sleep. Theta wave (5–7 Hz) can be seen during meditation. Alpha waves (8–13 Hz) are the result of the brain's relaxed state. The Mu wave (8–13 Hz) is found above the motor cortex, which tends to be suppressed as each part performs voluntary muscle movement or creates the intention to perform the movement. Beta waves (14–30 Hz) are involved in the brain and active concentration. Low frequency (<22 Hz) beta waves indicate an active and focused brain, while high frequencies (>22Hz) indicate anxiety. The importance of gamma waves (>32) cannot be clearly identified [39]. The robot-assisted rehabilitation was developed for the pneumatic system, which uses soft material safely to distribute force along finger length according to the Harvard Glove [40]. Besides, the pneumatic glove provides haptic feedback to volunteers as shown in Fig. 2.




Figure 1: The international 10–20 systems for electrodes placement

2.1 Data Acquisition

The Neurosky Mindwave device's dry electrode is approximately positioned at Fp1 and has a sampling rate of 512 samples per second. In the first stage, the motor recovery system is focused on the purpose of controlling the pneumatic gloves. Usually, the intention to do something can generate brain waves involved in meditation. Therefore, the development of the system of early motor recovery uses real-time detection of meditation. The volunteers participating in the trial were 21 ± 2 years old and in good health. EEG data collection was performed in a closed room, while the volunteers sat comfortably in their chair. Volunteers put their hands on the table and watched the computer screen showing the countdown video. When the computer screen shows "Start", the volunteer rests their hands in their normal state for about

10 seconds. The volunteer then imagines closing his/her hand for approximately 10 seconds. The measured EEG data set is analyzed offline.



Figure 2: The pneumatic hand glove according to Harvard Glove 2.0

In second stage, the motor recovery system focuses on actuation for pneumatic right-hand glove control. The EEG is recorded by OpenBCI devices with five electrodes comprising C3, Cz, CP1, P3 and Pz positions. These electrode locations are related to motor activity in functional areas of the brain [41]. The sampling rate of the OpenBCI device is 250 samples per second. Healthy volunteers, right-handed and aged 21 ± 2 years participated in the experimental procedure. The EEG data retrieval was performed in a closed room, while the volunteers sat in a chair and rested their arms comfortably on the table. The volunteer is asked to meditate and watch the computer screen showing the countdown video. When the computer screen shows "Start", the volunteer turns their hands on for about 3 seconds and then turns their hands off for about 3 seconds as shown in Fig. 3. In this experiment, all EEG data sets were collected from motion and contained approximately 100 data sets. The measured EEG data sets were later used to train Artificial Neural Networks (ANN) learning.



Figure 3: The EEG data acquisition on 5 channels from volunteer

2.2 First Stage EEG Analysis

The EEG data set, measured in the first stage, is used to develop an algorithm for detecting motion-intent, which has the following processes. Detecting intentional meditation requires knowing the Baseline Parameter of Meditation (BPM) during normal conditions and can be calculated as follows:

$$BPM = \sum_{i=1}^N \frac{Meditation(i)}{N} \quad (1)$$

where the meditation is a value of meditation from EEG headset. N is the number of meditation parameters obtained in normal conditions (N = 10). Finding the Peak Value of Meditation (PVM) parameter can be calculated as follows:

$$PVM = \max(Meditation[1, 2, 3 \dots, M]) \quad (2)$$

where M is the number of meditation parameters obtained during the imagination of slowly closing hands (M = 10). The Threshold Value of Meditation (TVM) is used as a decision-making criterion in meditation detection, which can be calculated as follows:

$$TVM = \frac{(BPM + PVM)}{2} \quad (3)$$

If Meditation > TVM, Decision is "The pneumatic glove starts to fist"

If Meditation < TVM, Decision is "No action"

The development for brainwave detection algorithm of a similar BCI system is named as the assistive communication device in persons with severe disability [42].

2.3 Second Stage EEG Analysis

In the second stage, the signal processing of EEG dataset is digitally filtered using a Butterworth filter between the corresponding Mu and Beta bands, 8 to 30 Hz, as this band contains the highest data related to hand movement. Butterworth filters have a flat response to zero pulsation, which is ideal for brain wave analysis. So we filtered the frequency below 8 Hz using the high pass filter and the low pass filter to subtract the frequencies above 30 Hz using the 4th-order Butterworth Digital filters as shown in Eqs. (4) and (5) respectively.

$$HPF = \frac{s^4}{(s^2 + 0.7654s + 1)(s^2 + 1.8478s + 1)} \quad (4)$$

$$LPF = \frac{1}{(s^2 + 0.7654s + 1)(s^2 + 1.8478s + 1)} \quad (5)$$

In this study, ANN was used to classify EEG signals to identify hand movement patterns (Open hand and close hand) from the given dataset. The learning process in ANN can be done using a training algorithm named Levenberg-Marquardt. The training phase is to provide the network with sample data and adjust the weights to estimate the activation function in a better way.

In the architecture of ANN, each neuron (j) in the hidden layer sums its input feature vectors (\hat{X}_i) after multiplying by the respective connection weight strengths (w_{ij}), and computes its output (y_j) as a function of the sum:

$$y_j = f\left(\sum w_{ji} \hat{X}_i\right) \quad (6)$$

where f is the activation function that is significant to transform the weighted sum of all signals impinging onto a neuron. The activation function f can be a simple threshold function, a sigmoidal, hyperbolic tangent, or radial basis function. In this paper, for the hidden layer and the output layer, the activation function f is the tangent-sigmoid (tansig) function. The sum of squared differences between the desired and actual values of the output neurons E is defined as:

$$E = \frac{1}{2} \sum_j (y_{dj} - y_j)^2 \quad (7)$$

where y_{dj} is the desired value of output neuron j and y_j is the actual output of that neuron. Each weight (w_{ji}) is adjusted to reduce E as rapid as possible. The adjustment of weight w_{ji} is dependent on the training algorithm. The Mean Square Error (MSE) algorithm is the defined criterion for the network performance. When the MSE value between the network output and the target is less than or equal to the set value, the learning process stops.

To evaluate the performance of the ANN model, the response can be tested through a confusion matrix, Validation performance and Receiver Operating Characteristic (ROC) curves as shown in Fig. 4. A confusion matrix was computed to define the accuracy of the classification outcome as shown in Fig. 4a. By considering the results of the trained networks compared to the expected results (targets), output network, which are correctly classified according to appropriate reactions, are shown as green squares and red squares. It indicates an incorrect classification by off-base reactions. The gray squares in the lower right show the general accuracy, which can be calculated from true positives (TP), false positives (FP), false negatives (FN) and true negatives (TN) as shown in Eqs. (8)–(10).

$$\text{Accuracy (\%)} = \frac{(TP + TN)}{(TP + FN + FP + TN)} \times 100 \quad (8)$$

$$\text{Sensitivity (\%)} = \frac{TP}{(TP + FN)} \times 100 \quad (9)$$

$$\text{Specificity (\%)} = \frac{TN}{(TN + FP)} \times 100 \quad (10)$$

The validation performance is used to find the lowest MSE value for every iteration in the training process as shown in Fig. 4b. At the point of lowest MSE value, the training should be stopped, and no further iteration should be proceeded. It means that no further training is required, and we could get the wrong results if we perform the training. The ROC curve is another metrics for determining the assessment accuracy via Area Under the Curve (AUC) scores (AUC scores range between 0 and 1.0) as shown in Fig. 4c. The AUC scores of discriminations indicate the capability of the ANN to properly categorize samples. This threshold metric of segregation between both classes determines scores of AUC below 0.5 (no classification) and 1 (perfect classification). Hence, the upper left corner of the ROC figure depicts the perfect curve, which indicates the high accuracy of classification. The following scales are employed to determine the classifier accuracy: excellent = 0.9–1, good = 0.8–0.9, fair = 0.7–0.8, poor = 0.6–0.7, and fail 0.5–0.6.

2.4 Motor Recovery System

The aim of this research is to design an embedded system that can be used to classify and control pneumatic glove using the acquired EEG signals. The “STM32” is the embedded system used to fulfill

the aim of this research. The EEG data is processed through a program that we develop with the help of C++/C# programming. The result is given as an input to STM32, which is programmed to process the input data for controlling the pneumatic glove. The data processing procedure considers the conditions of Meditation >TVM or Meditation <TVM. The result of the condition generates a signal that controls the air solenoid valve connected to each finger. The system stages from the data input to device control are shown in Fig. 5. Fig. 6 shows the hardware composition which consists of 1 microcontroller, 5 air solenoid valves, 1 air pump, 8 tubes, 6 MOSFETs, 1 AC to DC power converter and 5 Pressure sensors.




Figure 4: The performance of ANN response model: (a) Confusion matrix, (b) Validation performance, (c) Receiver Operating Characteristic (ROC) curves




Figure 5: Block diagram of the motor recovery system



Figure 6: The control hardware composition

2.5 Software Development

The software of the developed motor recovery system consists of several sections which are shown in the red box in Fig. 7. The red box with number 1 on the top shows the real-time EEG signal as the user imagines it is working to close the right hand. Besides, the level of meditation is also shown in this section. The red box with number 2 on the top shows the command settings including the TVM level device connection, the air pump timing and the constant air pump waiting time. The red box with number 3 on the top shows the working status of the motor recovery system. A red circle means that the system is working. A green circle means that the system is waiting for the command. Additionally, the user can choose to inflate the air to the desired finger by clicking on the small square on the hand image.

3 Results

The pneumatic glove test with control systems developed in our study was performed on 10 normal people (mean age 21 ± 2 years), divided into 5 people to find the suitable TVMs and test the appropriate TVM pneumatic glove control. This test is based on the satisfaction score of the Likert scale technique as shown in Tab. 1. The score consists of 5 levels as follows; the range from 4.50 to 5.00, the range from 3.5 to 4.49, the range from 2.5 to 3.49, the range from 1.50 to 2.49 and the range from 1.00 to 1.49. They are referred as Very Good, Good, OK, Poor and Very Poor, respectively. The TVM calculation results show

values between 60 and 80. Hence, each volunteer performs 5 trials to find an average satisfaction score and perform 4 trials by changing the TVM from the lowest to the highest value as shown in [Tabs. 2-6](#).




Figure 7: The software display of the motor recovery system

Table 1: The satisfaction score of the Likert scale technique

Very good	Good	OK	Poor	Very poor
5	4	3	2	1

Table 2: The satisfaction score from volunteer 1 experimenting with the pneumatic glove control by changing the threshold value of meditation (TVM)

Trials	Threshold value of meditation			
	60	65	70	80
1	3	4	4	2
2	4	3	5	3
3	3	3	5	2
4	4	4	5	2
5	3	4	4	3
Average	3.4	3.6	4.6	2.4

The best satisfaction score of TVM is used as a condition for device operation. In experiments, a volunteer controls a pneumatic glove to successfully grab and release the ball. There are 10 trials in total, with a time limit of 10 seconds for each trial. The results are shown in [Tab. 7](#).

Table 3: The satisfaction score from volunteer 2 experimenting with the pneumatic glove control by changing the threshold value of meditation (TVM)

Trials	Threshold value of meditation			
	60	65	70	80
1	4	3	5	2
2	4	3	5	2
3	3	3	5	2
4	3	4	5	2
5	3	4	4	2
Average	3.4	3.4	4.8	2.0

Table 4: The satisfaction score from volunteer 3 experimenting with the pneumatic glove control by changing the threshold value of meditation (TVM)

Trials	Threshold value of meditation			
	60	65	70	80
1	4	3	4	2
2	3	3	5	2
3	3	3	5	2
4	3	4	5	2
5	3	4	5	2
Average	3.2	3.4	4.8	2.0

Table 5: The satisfaction score from volunteer 4 that trials the pneumatic glove control by changing the threshold value of meditation (TVM)

Trials	Threshold value of meditation			
	60	65	70	80
1	4	3	5	3
2	3	4	5	3
3	3	3	5	2
4	3	4	4	2
5	3	3	4	3
Average	3.2	3.4	4.6	2.6

Table 6: The satisfaction score from volunteer 5 that trials the pneumatic glove control by changing the threshold value of meditation (TVM)

Trials	Threshold value of meditation			
	60	65	70	80
1	3	3	5	2
2	4	4	5	2
3	3	4	5	3
4	4	3	4	2
5	4	4	5	3
Average	3.6	3.6	4.8	2.4

Table 7: The pneumatic glove control test with suitable Threshold Value of Meditation (TVM)

Volunteers	Trials (S = Successful, F = Fail)									
	1	2	3	4	5	6	7	8	9	10
6	S	S	S	S	F	S	S	S	S	S
7	F	F	S	S	S	S	S	S	S	S
8	S	F	S	S	S	S	S	S	F	S
9	S	S	S	S	F	S	S	S	S	F
10	F	S	F	S	S	S	S	S	S	S

Additionally, our study considers the pneumatic glove control through the brain motor cortex. The EEG data of acquisition from 5 channels (C3, Cz, CP1, P3 and Pz channel) is used to find the classification performance between open and closed hand. We divided the datasets into 70% as training set, 15% as validation set and 15% as testing set. Tab. 8 shows the ANN results of 5 channels with overall indicators including Accuracy, Sensitivity, and Specificity.

Table 8: The ANN results of 5 channels with the overall indicators

Channels	Accuracy (%)	Sensitivity (%)	Specificity (%)
C3	96.2	93	99.3
Cz	96.7	93.7	99.7
CP1	95.3	91.4	99.2
P3	96.7	93.7	99.7
Pz	97.9	99.3	96.4

At around 413 epochs of the C3 channel, the MSE validation is stable and the MSE is very low at 0.058982. It means that the training should be stopped because of receiving the best training for pattern recognition. Similarly, for other 4 channels (Cz, CP1, P3 and Pz channels) at different epochs, the best MSE validation performance is 0.05853, 0.044409, 0.049121 and 0.030337, respectively. Fig. 8 shows the ROC results of 5 channels when the AUC score is close to 1. This means that the network has given higher accuracy in hand movement classification.




Figure 8: The ROC results of the 5 channels: (a) C3 channel; (b) Cz channel; (c) CP1 channel; (d) P3 channel; (e) Pz channel

4 Discussion

The results showed that the mean satisfaction score of TVMs at 60 and 65 were 3.36, 3.48, respectively, meaning that pneumatic glove control was at an OK level. Although both TVMs can be controlled at an OK level, they can be easily performed using some basic concentration in meditation, which creates a sense of control instability. The average satisfaction score of TVM at 70 is 4.72, which means that the control is a Very Good level. Due to Very Good level, a higher concentration of meditation is required to control the pneumatic gloves as they provide stability in control. Considering the average satisfaction score of TVM at 80, the result shows a score of just 2.28. This means that controlling the pneumatic glove is at a Poor level. Since the value of TVM is high, it requires a very high concentration of intentions in meditation. Although the volunteers can successfully control the pneumatic glove, the intent of practicing a consistent high concentration is very difficult. Therefore, the satisfaction score of 5 volunteers can be concluded that the effectiveness of TVM is 70. This conclusion is used in pneumatic glove control experiments where conditions for catching and placing the ball were successful. The results showed that 82% of the volunteers were able to successfully control the pneumatic gloves. In general, the experience of brain disease negatively affects the mental health of the patient. Therefore, this success shows that meditation, along with physiotherapy, can be performed at the same time and is more effective than conventional physiotherapy alone, which is consistent with the work presented in [38].

Moreover, we have found the feasibility of the brainwave classification in the motor cortex area. Based on the results, the five-channel ANN model had an average accuracy of 96.56%, with an average sensitivity of 94.22% and a mean specificity of 98.8% in terms of Open or Close hand. The result is a possible hand movement in patients with second-stage brain disease. The ANN model then detects the corresponding brain waves as the user moves by hand. The classification results are then translated into commands and sent to the pneumatic glove control system to assist the patient in rehab. Physiotherapy with active and repetitive motor intent can stimulate the activity of the primary cortex. This approach is likely to provide better recovery results than conventional physiotherapy alone [32–34]. Although the method of the second stage works. But it is not suitable for real life use as the device is time consuming which can inconvenience the user.

5 Conclusions

In this research, we have discovered the feasibility of a motor recovery system through the aim of rehabilitation using BCI technology. In the first stage of brain disease, the patients cannot generate brain waves related to voluntary movements. Thus, the motor recovery system uses real-time brainwave detection while the user is intending to execute the movement of pneumatic glove. The results show that the volunteers were able to successfully control the pneumatic glove with 82% accuracy. Furthermore, we have found the feasibility of the motor recovery system in the second stage through the brainwave classification in the motor cortex area. Due to the second stage of brain disease, the patients can generate some brain waves related to voluntary movements. Based on the results, the five-channel ANN model had an average accuracy of 96.56% with an average sensitivity of 94.22% and a mean specificity of 98.8% in terms of Open or Close hand. Although the method of the second stage works. But it is not suitable for use in real life as the installation of the device takes time which can inconvenience the user. In the future, we will develop the motor recovery system in the second stage by reducing the number of channels for faster installations to facilitate the users.

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

Funding Statement: This work is financially supported from the Thailand Research Fund through the Royal Golden Jubilee Ph.D. Program (Grant No. PHD/0148/2557).

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

References

- [1] E. L. Miller, L. Murray, L. Richards, R. D. Zorowitz, T. Bakas *et al.*, "Comprehensive overview of nursing and interdisciplinary rehabilitation care of the stroke patient: A scientific statement from the American Heart Association," *Stroke*, vol. 41, no. 10, pp. 2402–2448, 2010.
- [2] S. Mendis, "Stroke disability and rehabilitation of stroke: World Health Organization perspective," *International Journal of Stroke*, vol. 8, no. 1, pp. 3–4, 2013.
- [3] WHO, "Global Health estimates 2016: Deaths by cause, age, sex, by country and by region, 2000–2016," in *The top 10 causes of death*, Geneva: World Health Organization, 2018. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death>.
- [4] K. Strong, C. Mathers and R. Bonita, "Preventing stroke: Saving lives around the world," *The Lancet Neurology*, vol. 6, no. 2, pp. 182–187, 2007.
- [5] A. Towfighi, B. Ovbiagele and J. L. Saver, "Therapeutic milestone: Stroke declines from the second to the third leading organ-and disease-specific cause of death in the United States," *Stroke*, vol. 41, no. 3, pp. 499–503, 2010.
- [6] United Nations, "Department of economic and social affairs population division (2019)," *World Population Ageing 2019: Highlights* (ST/ESA/SER.A/430), 2019.
- [7] M. A. del Aguila, W. T. Longstreth, V. McGuire, T. D. Koepsell and G. van Belle, "Prognosis in amyotrophic lateral sclerosis: A population-based study," *Neurology*, vol. 60, no. 5, pp. 813–819, 2013.
- [8] E. Lundström, A. Smits, A. Terént and J. Borg, "Time-course and determinants of spasticity during the first six months following first-ever stroke," *Journal of Rehabilitation Medicine*, vol. 42, no. 4, pp. 296–301, 2010.
- [9] J. Wissel, A. Manack and M. Brainin, "Toward an epidemiology of poststroke spasticity," *Neurology*, vol. 80, no. 3 Supplement 2, pp. S13–S19, 2013.
- [10] K. B. Lee, S. H. Lim, K. H. Kim, K. J. Kim, Y. R. Kim *et al.*, "Six-month functional recovery of stroke patients: A multi-time-point study," *International Journal of Rehabilitation Research*, vol. 38, no. 2, pp. 173–180, 2015.
- [11] P. Langhorne, F. Coupar and A. Pollock, "Motor recovery after stroke: A systematic review," *The Lancet Neurology*, vol. 8, no. 8, pp. 741–754, 2009.
- [12] L. H. Thomas, B. French, J. Coupe, N. McMahon, L. Connell *et al.*, "Repetitive task training for improving functional ability after stroke: A major update of a Cochrane review," *Stroke*, vol. 48, no. 4, pp. e102–e103, 2017.
- [13] J. Laut, M. Porfiri and P. Raghavan, "The present and future of robotic technology in rehabilitation," *Current Physical Medicine and Rehabilitation Reports*, vol. 4, no. 4, pp. 312–319, 2016.
- [14] S. N. Housley, K. Fitzgerald and A. J. Butler, "Telerehabilitation robotics: Overview of approaches and clinical outcomes," in *Rehabilitation Robotics*, Atlanta, GA, USA: Academic Press, pp. 333–346, 2018. <https://www.sciencedirect.com/book/9780128119952/rehabilitation-robotics>.
- [15] Y. Chena, K. T. Abel, J. T. Janeczek, Y. Chen, K. Zheng *et al.*, "Home-based technologies for stroke rehabilitation: A systematic review," *International Journal of Medical Informatics*, vol. 123, pp. 11–22, 2019.
- [16] S. C. Cramer, L. Dodakian, V. Le, J. See, R. Augsburger *et al.*, "Efficacy of home-based telerehabilitation vs in-clinic therapy for adults after stroke: A randomized clinical trial," *JAMA Neurology*, vol. 76, no. 9, pp. 1079–1087, 2019.
- [17] P. Maciejasz, J. Eschweiler, K. G. Hahn, A. J. Troy and S. Leonhardt, "A survey on robotic devices for upper limb rehabilitation," *Journal of NeuroEngineering and Rehabilitation*, vol. 11, no. 1, pp. 3, 2014.
- [18] W. Meng, Q. Liu, Z. Zhou, Q. Ai, B. Sheng *et al.*, "Recent development of mechanisms and control strategies for robot-assisted lower limb rehabilitation," *Mechatronics*, vol. 31, pp. 132–145, 2015.
- [19] T. Jumphoo, M. Uthansakul and P. Uthansakul, "Brainwave classification without the help of limb movement and any stimulus for character-writing application," *Cognitive Systems Research*, vol. 58, pp. 375–386, 2019.
- [20] Z. Yue, X. Zhang and J. Wang, "Hand rehabilitation robotics on poststroke motor recovery," *Behavioural Neurology*, vol. 2017, pp. 1–20, 2017.

- [21] I. Díaz, J. M. Catalan, F. J. Badesa, X. Justo, L. D. Lledo *et al.*, "Development of a robotic device for post-stroke home tele-rehabilitation," *Advances in Mechanical Engineering*, vol. 10, no. 1, pp. 1–8, 2018.
- [22] M. H. Rahman, C. O. Luna and M. Saad, "EMG based control of a robotic exoskeleton for shoulder and elbow motion assist," *Journal of Automation and Control Engineering*, vol. 3, no. 4, pp. 270–276, 2015.
- [23] F. Resquin, A. C. Gómez, J. G. Vargas, F. Brunetti, D. Torricelli *et al.*, "Hybrid robotic systems for upper limb rehabilitation after stroke: A review," *Medical Engineering & Physics*, vol. 38, no. 11, pp. 1279–1288, 2016.
- [24] R. Trochimeczuk, T. Hušcio, S. Grymek and D. Szalewska, "Rehabilitation device supporting active and passive upper limb exercises," *Current Science*, vol. 115, no. 5, pp. 868, 2018.
- [25] C. Y. Chu and R. M. Patterson, "Soft robotic devices for hand rehabilitation and assistance: A narrative review," *Journal of NeuroEngineering and Rehabilitation*, vol. 15, no. 1, pp. 9, 2018.
- [26] J. J. Shih, D. J. Krusienski and J. R. Wolpaw, "Brain-computer interfaces in medicine," *Mayo Clinic Proceedings*, vol. 87, no. 3, pp. 268–279, 2012.
- [27] L. F. Nicolas-Alonso and J. Gomez-Gil, "Brain computer interfaces, a review," *Sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.
- [28] A. R. C. Donati, S. Shokur, E. Morya, D. S. F. Campos, C. R. Muioli *et al.*, "Long-term training with a brain-machine interface-based gait protocol induces partial neurological recovery in paraplegic patients," *Scientific Reports*, vol. 6, pp. 1–16, 2016.
- [29] R. Sitaram, T. Ros, L. Stoeckel, S. Haller, F. Scharnowski *et al.*, "Closed-loop brain training: the science of neurofeedback," *Nature Reviews Neuroscience*, vol. 18, no. 2, pp. 86–100, 2017.
- [30] M. G. Rodriguez, J. Peters, J. Hill, B. Schölkopf, A. Gharabaghi *et al.*, "Closing the sensorimotor loop: Haptic feedback facilitates decoding of motor imagery," *Journal of Neural Engineering*, vol. 8, no. 3, pp. 1–13, 2011.
- [31] Y. Liu, S. C. H. Subramaniam, O. Sourina, E. Shah, J. Chua *et al.*, "Neurofeedback training for rifle shooters to improve cognitive ability," in *Int. Conf. on Cyberworlds*, Chester, UK, pp. 186–189, 2017.
- [32] G. I. Barsi, D. B. Popovic, I. M. Tarkka, T. Sinkjær and M. J. Grey, "Cortical excitability changes following grasping exercise augmented with electrical stimulation," *Experimental Brain Research*, vol. 191, no. 1, pp. 57–66, 2008.
- [33] N. Takeuchi and S. I. Izumi, "Rehabilitation with poststroke motor recovery: A review with a focus on neural plasticity," *Stroke Research and Treatment*, vol. 2013, no. 12, pp. 1–13, 2013.
- [34] N. M. Kersting, S. R. Kristensen, I. K. Niazi and D. Farina, "Precise temporal association between cortical potentials evoked by motor imagination and afference induces cortical plasticity," *The Journal of Physiology*, vol. 590, no. 7, pp. 1669–1682, 2012.
- [35] A. Lazaridou, P. Philbrook and A. A. Tzika, "Yoga and mindfulness as therapeutic interventions for stroke rehabilitation: A systematic review," *Evidence-Based Complementary and Alternative Medicine*, vol. 2013, no. 12, pp. 1–9, 2013.
- [36] K. M. Ulrichsen, T. Kaufmann, E. S. Dørum, K. K. Kolskár, G. Richard *et al.*, "Clinical utility of mindfulness training in the treatment of fatigue after stroke, traumatic brain injury and multiple sclerosis: A systematic literature review and meta-analysis," *Frontiers in Psychology*, vol. 7, pp. 912, 2016.
- [37] F. Pagnini, A. Marconi, A. Tagliaferri, G. M. Manzoni, R. Gatto *et al.*, "Meditation training for people with amyotrophic lateral sclerosis: A randomized clinical trial," *European Journal of Neurology*, vol. 24, no. 4, pp. 578–586, 2017.
- [38] S. John1, G. L. Khanna and P. Kotwal, "Effect of music therapy and meditation along with conventional physiotherapy management in sub-acute stroke patients," *British Journal of Sports Medicine*, vol. 44, no. Suppl 1, i14, 2010.
- [39] W. O. Tatum, "Ellen r. grass lecture: Extraordinary EEG," *The Neurodiagnostic Journal*, vol. 54, no. 1, pp. 3–21, 2014.
- [40] P. Polygerinos, K. C. Galloway, E. Savage, M. Herman, K. O'Donnell *et al.*, "Soft robotic glove for hand rehabilitation and task specific training," in *IEEE Int. Conf. on Robotics and Automation*, Seattle, WA, USA, pp. 2913–2919, 2015.

- [41] P. T. Schoenemann, "Evolution of the size and functional areas of the human brain," *Annual Review of Anthropology*, vol. 35, no. 1, pp. 379–406, 2006.
- [42] Y. Punsawad, S. Ngamrussameewong and Y. Wongsawat, "On the development of BCI and its neurofeedback training system for assistive communication device in persons with severe disability," in *Asia-Pacific Signal and Information Proc. Association Annual Summit and Conf.*, Jeju, South Korea, pp. 1–4, 2016.



ประวัติผู้เขียน

นายธฤต จุมภู เกิดเมื่อวันที่ 25 ตุลาคม พุทธศักราช 2535 ที่จังหวัดสุโขทัย โดยสำเร็จ การศึกษาระดับประถมศึกษาจากโรงเรียนอนุบาลสุโขทัย ระดับมัธยมศึกษาตอนต้นชั้นปีที่ 1-2 จาก โรงเรียนสุโขทัยวิทยาคมและระดับมัธยมศึกษาตอนต้นชั้นปีที่ 3 ที่โรงเรียนแม่สะเรียง”ปริพัตรศึกษา” จังหวัดแม่ฮ่องสอน ระดับมัธยมศึกษาตอนปลายจากโรงเรียนลำปางกัลยาณี และสำเร็จการศึกษา ระดับปริญญาตรี สาขาวิชาวิศวกรรมโทรคมนาคม สำนักวิชาวิศวกรรมศาสตร์ จากมหาวิทยาลัย เทคโนโลยีสุรนารี จังหวัดนครราชสีมา จากนั้นได้ศึกษาต่อในระดับปริญญาโทและเอกในสาขาวิชา วิศวกรรมโทรคมนาคม มหาวิทยาลัยเทคโนโลยีสุรนารี โดยขณะศึกษาได้รับทุนการศึกษาจากโครงการ ปริญญาเอกกาญจนาภิเษก รุ่นที่ 17

