

Academic article

การทบทวนวรรณกรรม: การตรวจจับคลื่นสมองประเภท Sleep spindles แบบอัตโนมัติ A Review on Automatic Detection Methods of Sleep Spindles

ชินานาง พรหมแก้ว^{1,2} พรพนัช กิจอุดม^{1,2} อีสริย์ สุวรรณสมบัติ^{1,2} ธมลวรรณ ทองบุญ^{1,2}
แก้วเกล้า ถาวรวัฒนะ^{1,2} สันติธรรม พรหมอ่อน² วรณิข หินทอง¹
Shinanang Promkaew^{1,2}, Pornwanut Kitudom^{1,2}, Isaree Suwansombat^{1,2},
Thamonwan Thongbun^{1,2}, Kaewklao Thavornwattana^{1,2},
Santitham Prom-on², Woranich Hinthong^{*1}

¹วิทยาลัยแพทยศาสตร์ศรีสวางควัฒน ราชวิทยาลัยจุฬาภรณ์

²คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

¹Princess Srisavangavadhana College of Medicine, Chulabhorn Royal Academy

²Faculty of Engineering, King Mongkut's University of Technology Thonburi

*Corresponding Author, e-mail: woranich.hin@cra.ac.th

Received: 1 December 2021; Revised: 13 November 2022; Accepted: 1 December 2022

บทคัดย่อ

Sleep spindle เป็นคลื่นสมองรูปแบบหนึ่งที่เกิดขึ้นในช่วงระยะที่ 2 ของการนอนหลับแบบ NREM (Non-rapid eye movement) โดยมีหลักฐานบ่งชี้ว่าคลื่นสมองประเภทนี้มีบทบาทสำคัญในหลากหลายด้าน อาทิ มีความสำคัญในกระบวนการเปลี่ยนความทรงจำระยะสั้นเป็นความทรงจำระยะยาวของสมอง และอาจมีความสัมพันธ์กับความเสื่อมของระบบประสาท เช่น โรคอัลไซเมอร์ โรคนอนไม่หลับ เป็นต้น การตรวจจับคลื่นดังกล่าวในทางปฏิบัติทำได้โดยการประเมินจากแพทย์หรือผู้เชี่ยวชาญ ซึ่งใช้ระยะเวลานาน อีกทั้งมีโอกาสเกิดข้อผิดพลาดสูงจากความแปรปรวนของหลายปัจจัย ไม่ว่าจะเป็นความชำนาญของผู้ประเมินหรือลักษณะของคลื่น Sleep spindle ในปัจจุบันมีการศึกษาการใช้ประโยชน์จากการเรียนรู้ของเครื่อง (Machine learning) ในการตรวจจับคลื่นสมองประเภท Sleep spindle แบบอัตโนมัติ โดยคาดหวังให้สามารถทำงานได้เทียบเท่ากับการประเมินของผู้เชี่ยวชาญ และสามารถแก้ปัญหาข้างต้นได้ ทั้งนี้ การทบทวนบทความที่เกี่ยวข้องยังคงมีจำนวนไม่มากนัก บทความนี้ศึกษาและเปรียบเทียบวิธีการที่นำมาใช้ในการตรวจจับคลื่นสมองประเภท Sleep spindle แบบอัตโนมัติ โดยสรุปขั้นตอนการทำงานของการศึกษาได้เป็น การรวบรวมข้อมูล การจัดการกับข้อมูลคลื่นสมอง การเลือกคุณลักษณะ การสร้างโมเดล และการประเมินประสิทธิภาพของโมเดล โดยพบว่าการเรียนรู้ของเครื่อง (Machine learning) ถูกนำมาใช้อย่างหลากหลาย และการศึกษาที่ใช้โมเดลในกลุ่มที่เรียนรู้แบบมีผู้สอนโดยส่วนใหญ่สามารถตรวจจับ Sleep spindle ได้ตรงกับที่ผู้เชี่ยวชาญระบุ แต่ยังคงต้องการปรับปรุงประสิทธิภาพของโมเดลให้เหมาะกับข้อมูลที่หลากหลายมากยิ่งขึ้น นอกจากนี้ ในบทวิจารณ์ยังประกอบด้วยข้อเสนอแนะและความเป็นไปได้ในการศึกษาเพื่อพัฒนาต่อยอดต่อไปอีกด้วย

คำสำคัญ: การตรวจวัดคลื่นไฟฟ้าสมอง, การประมวลผลสัญญาณ, การเรียนรู้ของเครื่อง, คลื่นสมอง Sleep spindle, วิธีการตรวจจับแบบอัตโนมัติ

Abstracts

Sleep spindle is a pattern of brainwave during non-rapid eye movement (NREM) in the second stage of sleep. There are several indications that Sleep spindles might play an important role in memory consolidation, and neurodegenerative disorders such as Alzheimer's disease and

insomnia. Sleep spindle is commonly annotated by visual inspection of experts which is time consuming, and the task has risk of high error due to over-reliance on the experts' skill or variations in characteristics of Sleep spindle. Modern research aims to study machine learning to develop the efficient automatic Sleep spindle detectors, emulate human annotations, and solve the stated problems. However, there are few review articles on the subject. This article summarizes and compares the automatic detection methods of Sleep spindle. The workflow can be summarized into five steps: data collection, data preprocessing, feature extraction, modeling, and model evaluation. This article reveals the variation of Machine Learning application and study on supervised model can detect Sleep spindle equivalent to experts. Nevertheless, the model need customization to suit data diversity. In addition, the discussion includes recommendation and possibility for further studies.

Keywords: Electroencephalography (EEG), Signal Processing, Machine Learning, Sleep Spindle, Automatic Detection

บทนำ

การนอนหลับเป็นกระบวนการที่มีความสำคัญอย่างยิ่งในสิ่งมีชีวิต การนอนหลับที่เพียงพอและมีประสิทธิภาพจะส่งผลให้การทำงานของระบบต่าง ๆ ในร่างกายเจริญเติบโต รวมไปถึงกระบวนการการเรียนรู้และการจดจำดำเนินไปอย่างมีประสิทธิภาพ¹ ตามปกติร่างกายมีกลไกที่เรียกว่าวงจรการนอนหลับ (Sleep cycle) วงจรการนอนหลับจะเกิดขึ้นประมาณ 4–6 รอบ แต่ละรอบจะใช้เวลาเฉลี่ยประมาณ 90 นาที ซึ่งวงจรนี้สามารถแบ่งออกเป็น 2 ช่วง คือ ช่วงการนอนหลับแบบ Rapid eye movement (REM) และช่วงการนอนหลับแบบ Non-rapid eye movement (NREM)²

เนื่องจากมีหลักฐานว่าคุณภาพของการนอนหลับส่งผลกระทบต่อสุขภาพ³ จึงได้มีการพัฒนาระบบการวินิจฉัยหรือการตรวจวัดสุขภาพการนอนหลับ เรียกว่า Sleep study หรือ Polysomnography (PSG) ใช้เพื่อตรวจหาอาการผิดปกติที่เกิดขึ้นระหว่างการนอนหลับ โดยหนึ่งในข้อมูลที่ใช้เพื่อทำการตรวจวัดเพื่อนำมาใช้ในการวิเคราะห์ผลคือ ข้อมูลคลื่นสมอง หรือที่เรียกว่าคลื่นกระแสประสาท (Neural oscillatory) ซึ่งข้อมูลคลื่นสมองสามารถได้จากการตรวจบันทึกคลื่นสมอง (Electroencephalography: EEG) ที่แสดงผลการทำงานของคลื่นไฟฟ้าภายในสมอง โดยวิเคราะห์จากแรงกระตุ้นไฟฟ้า (Electrical impulse) ผ่านการติดขั้วไฟฟ้า (Electrode) ไว้ที่บริเวณหนังศีรษะซึ่งจะมีระบบการวางตำแหน่งขั้วไฟฟ้าที่นิยมใช้คือ ระบบ International 10–20 เป็นระบบมาตรฐานสากล⁴ โดยข้อมูลคลื่นสมองจะถูกส่งต่อมายังคอมพิวเตอร์เพื่อทำการบันทึกผล ลักษณะและรูปร่างของคลื่นสมองจาก EEG ที่เกิดขึ้นสามารถบ่งชี้การทำงานของผิดปกติของสมองได้

ในช่วงการนอนหลับแบบ NREM ระยะที่ 2 จะมีการเกิดคลื่นสมองที่เรียกว่า Sleep spindle หรือคลื่นซิกมา (Sigma wave) ซึ่งเกิดจากการทำงานของ

คลื่นกระแสประสาทที่สร้างมาจากเยื่อหุ้มนิวเคลียสในส่วนธาลามัส (Thalamic reticular nucleus: TRN) โดยมีหลักฐานว่า Sleep spindle มีความเกี่ยวข้องในกระบวนการที่หลากหลายในระบบประสาทและเป็นดัชนีชี้วัดทางชีวภาพ (Biomarker) ที่มีความสำคัญในกระบวนการเปลี่ยนความทรงจำระยะสั้นเป็นความทรงจำระยะยาว⁵ ลักษณะความถี่ ความหนาแน่น และระยะเวลาของการเกิดขึ้นของ Sleep spindle ยังสามารถบ่งชี้ถึงสุขภาพสมอง กระบวนการทำงานของเซลล์ประสาทและการเกิดขึ้นของกลุ่มโรคที่เกิดการเสื่อมของเซลล์ประสาท เช่น ภาวะถดถอยทางสมอง หรือ โรคอัลไซเมอร์ได้^{6, 7} โดยทั่วไปตำแหน่งของ Sleep spindle ใน EEG จะถูกระบุโดยผู้เชี่ยวชาญตามวิธีตรวจมาตรฐาน (Gold standard) ที่กำหนดโดยสมาคมเวชศาสตร์การนอนหลับของสหรัฐอเมริกา (American Academy of Sleep Medicine: AASM)⁸ โดยการตรวจหา Sleep spindle ด้วยการใช้สายตาของผู้เชี่ยวชาญนั้นยังคงพบปัญหาหลายประการ เช่น ใช้ระยะเวลานาน มีค่าใช้จ่ายที่สูง จำนวนผู้เชี่ยวชาญที่มีอยู่อย่างจำกัด รวมถึงความน่าเชื่อถือของตัวผู้เชี่ยวชาญ^{9, 10} นอกจากนี้ Sleep spindle ยังมีลักษณะเป็นข้อมูลที่มีความแปรปรวนสูง ซึ่งเป็นผลจากตัวแปรต่าง ๆ เช่น บริเวณต้นกำเนิดของคลื่นในสมอง ความแตกต่างระหว่างบุคคล หรืออุปกรณ์ที่ใช้ในการบันทึกผล EEG เป็นต้น ความแปรปรวนเหล่านี้จึงส่งผลให้การตรวจหา Sleep spindle เป็นไปได้ยากขึ้น

ในปัจจุบัน มีการศึกษาเพื่อพัฒนาเทคโนโลยีหรือโมเดลทางคณิตศาสตร์โดยวิธีการใช้กฎ (Rule-based approach) วิธีการเรียนรู้ของเครื่อง หรือวิธีการเรียนรู้เชิงลึก เพื่อตรวจจับ Sleep spindle แบบอัตโนมัติโดยมีหลักฐานว่าการใช้การเรียนรู้เชิงลึก ซึ่งเป็นโมเดลแบบโครงข่ายประสาทเทียมแบบ Levenberg-Marquardt (Levenberg-Marquardt artificial neural network: LM-ANN) สามารถตรวจจับ Sleep spindle ได้โดยมี

ความแม่นยำ (Accuracy) ที่ดีที่สุดถึง 100% เทียบเท่ากับความสามารถในการตรวจพบ Sleep spindle โดยผู้เชี่ยวชาญ¹¹

จากความสำคัญของ Sleep spindle ที่มีความเกี่ยวข้องกับโรคทางระบบประสาท รวมถึงความยากในการตรวจจับคลื่นจากข้อมูล EEG ทำให้มีการศึกษาด้านการตรวจจับ Sleep spindle แบบอัตโนมัติเพิ่มขึ้นเป็นจำนวนมาก เพื่อค้นหาเทคโนโลยีที่มีความสามารถทั้งด้านความแม่นยำและความรวดเร็วที่เทียบเท่ากับการประเมินของผู้เชี่ยวชาญ บทความนี้จะทำการรวบรวมสรุปและเปรียบเทียบองค์ความรู้จากผลการศึกษาเกี่ยวกับการตรวจจับ Sleep spindle แบบอัตโนมัติ และเพื่อศึกษาวิธีการที่ช่วยในการตรวจจับ Sleep spindle แบบอัตโนมัติในรูปแบบใหม่ๆ ที่จะสามารถอำนวยความสะดวกในการตรวจหา Sleep spindle ได้อย่างรวดเร็วและแม่นยำมากยิ่งขึ้น

ลักษณะพื้นฐานของคลื่น Sleep spindle


Sleep spindle ถูกค้นพบในช่วงปี 1935–1940 ซึ่งกล่าวถึงการศึกษาเกี่ยวกับคลื่น EEG ในการนอนหลับของมนุษย์ และหลังจากนั้นผู้วิจัยก็ได้พยายามทำการศึกษาค้นคว้าในองค์ความรู้ดังกล่าวเรื่อยมา อาทิ Loomis et al. กล่าวถึงข้อมูลเกี่ยวกับช่วงการนอนหลับที่สามารถพบ Sleep spindle โดยค้นพบครั้งแรกในปี 1935¹² และในปี 2003 Gennero และ Ferrara ได้กำหนดคำนิยามเรื่องความถี่และช่วงระยะเวลาเกิดของ Sleep spindle¹³ อย่างไรก็ตาม ในปัจจุบัน คลื่นสมอง Sleep spindle ยังคงไม่มีข้อกำหนดเกี่ยวกับลักษณะที่ตายตัว

Sleep spindle สามารถพบได้ในการนอนหลับช่วง NREM ระยะที่ 2 ซึ่งอาจพบร่วมกับคลื่นสมอง K-complex ได้¹⁴ คลื่นของ Sleep spindle มีรูปร่างเหมือนกระสวย มีความสมมาตร โดยค่าพลังงานของคลื่นหรือแอมพลิจูด (Amplitude) จะมีช่วงที่เพิ่มขึ้นเรื่อย ๆ (Waxing) และตามด้วยช่วงที่ค่อย ๆ ลดลง (Waning) รูปร่างดังกล่าวเกิดจากการที่ระดับพลังงานพุ่งสูงขึ้น

ฉับพลันแล้วหายไปในช่วงหนึ่ง (Transient wave หรือ Oscillation)¹⁵ โดยสามารถพบคลื่นดังกล่าวได้ในหลายบริเวณของสมอง แต่ละบริเวณจะให้ลักษณะของคลื่นที่มีความแตกต่างกันออกไป บริเวณที่พบเป็นส่วนใหญ่ คือ TC loop (Thalamocortical loop) ซึ่งประกอบด้วยสมองบริเวณทาลามัส (Thalamus) เยื่อหุ้มสมอง (Cortex) และสมองชั้นนอก (Neocortex)¹⁶ คลื่นสมอง Sleep spindle เป็นคลื่นที่มีลักษณะความถี่สูง มีช่วงความถี่อยู่ที่ 10–15 Hz¹⁷⁻¹⁹ และอาจเปลี่ยนแปลงได้โดยมีค่าคลาดเคลื่อน ± 1 Hz สามารถพบได้ในคลื่นสมองช่วงที่มีความต่างศักย์ทางไฟฟ้าต่ำกว่า 20 ไมโครโวลต์ (μV)²⁰ ระยะเวลาการเกิด Sleep spindle จะเกิดขึ้นอย่างน้อย 0.5 วินาที มากไปจนถึง 3 วินาที อย่างไรก็ตาม ช่วงระยะเวลาดังกล่าวอาจมีความไม่แน่นอน²¹ ทั้งนี้อาจขึ้นอยู่กับความแตกต่างระหว่างกลุ่มตัวอย่าง²² คลื่นสมอง Sleep spindle สามารถแบ่งออกเป็น 2 ประเภทตามความถี่และลักษณะของคลื่น ได้แก่ Slow spindle ที่มีความถี่ระหว่าง 9–12 Hz เกิดขึ้นที่บริเวณสมองส่วนหน้า (Frontal) และ Fast spindle ที่มีความถี่ระหว่าง 13–15 Hz เกิดขึ้นบริเวณสมองส่วน Centroparietal ซึ่งมีความแตกต่างกันในด้านของเวลาที่เริ่มเกิด ความถี่และบริเวณที่พบ Sleep spindle อีกทั้งยังสัมพันธ์กับเฟสที่แตกต่างกันและการสั้นของคลื่นที่ส่งผลกระทบต่อการเปลี่ยนแปลงความความทรงจำระยะสั้นเป็นความทรงจำระยะยาว²³

การตรวจจับคลื่นสมอง Sleep spindle แบบอัตโนมัติ

ขั้นตอนพื้นฐานที่ใช้ในการตรวจจับ Sleep spindle แบบอัตโนมัติประกอบด้วยขั้นตอนหลัก 5 ขั้นตอน คือ การรวบรวมข้อมูล (Data collection) การจัดการข้อมูล (Data preprocessing) การดึงคุณลักษณะสำคัญจากข้อมูล (Feature extraction) และการสร้างแบบจำลองการตรวจจับคลื่นสมอง Sleep spindle (Sleep Spindle detection modeling) (รูปที่ 1)



รูปที่ 1 แผนภาพแสดงขั้นตอนในการตรวจจับคลื่นสมอง Sleep spindle แบบอัตโนมัติ

การรวบรวมข้อมูล (Data Collection)

ข้อมูลที่น่าสนใจในการวิเคราะห์เพื่อตรวจจับ Sleep spindle ได้มาจากการผลการบันทึก EEG ในการตรวจ PSG หรือการทดลองที่เกี่ยวข้องกับการศึกษาพฤติกรรม การนอนหลับอื่น ๆ ในการศึกษาจะมีการเลือกใช้ตำแหน่งของ EEG node ของกลุ่มตัวอย่างแตกต่างกันไป ซึ่งอาจมีผลต่อการเกิดขึ้นของ Sleep spindle และลักษณะพื้นฐานของ Sleep spindle ได้ โดยหนึ่งในสิ่งที่ผู้ทำการทดลองต้องคำนึงถึงในการใช้ข้อมูล EEG คือ การพิจารณาตำแหน่งขั้วไฟฟ้าที่จะทำการทดลอง หรือการพิจารณาตำแหน่งขั้วไฟฟ้าที่จะทำการดึงข้อมูลมาใช้ ซึ่งตำแหน่งขั้วไฟฟ้าที่ AASM แนะนำให้ใช้คือ F4, C4 และ O2 เนื่องจากมีความครอบคลุมเพียงพอแล้วต่อการวิเคราะห์รูปแบบคลื่นสมอง⁸ แต่ก็สามารถใช้ข้อมูลจากตำแหน่งขั้วไฟฟ้าอื่น ๆ เพื่อศึกษาเพิ่มเติมได้ทำให้การศึกษาต่าง ๆ นั้นมีการใช้ตำแหน่งขั้วไฟฟ้าที่แตกต่างกัน โดยจะนิยมนำข้อมูล EEG จากตำแหน่งขั้วไฟฟ้าคู่ C3–C4, Fp1–Fp2, F3–F4, O1–O2 และ P3–P4 มาใช้ในการตรวจจับ Sleep spindle มากกว่าตำแหน่งขั้วไฟฟ้าคู่อื่น ๆ จากการศึกษาพบว่ามีการวิเคราะห์คลื่นสมอง Sleep spindle แบบใช้ข้อมูล EEG เพียงตำแหน่งเดียว (Single channel EEG) หรือการวิเคราะห์โดยใช้ข้อมูล EEG จากหลายตำแหน่งพร้อม ๆ กัน (Multichannel EEG) ในขณะที่แพทย์มักใช้การทำ Multichannel EEG เพื่อเพิ่มประสิทธิภาพในการตรวจจับคลื่นต่าง ๆ จากลักษณะร่วมกันของข้อมูล EEG ในทุกตำแหน่ง (Global information) โดยข้อมูลที่ถูกนำมาใช้ในการสร้างแบบจำลอง สามารถแบ่งออกเป็น 2 แหล่งดังนี้

1. ข้อมูลที่มาจากการทดลอง (Experimental data) คือ ข้อมูลที่ผู้วิจัยได้ทำการทดลองเพื่อนำข้อมูลมาใช้ในการศึกษาโดยตรง ทั้งนี้ อาจทำเพื่อความสะดวกในการกำหนดลักษณะของกลุ่มตัวอย่างหรือการควบคุมตัวแปรต่าง ๆ

2. ข้อมูลที่มาจากฐานข้อมูลสาธารณะ (Public database) คือ การดึงข้อมูลจากฐานข้อมูลกลางที่เก็บข้อมูลเกี่ยวกับพฤติกรรม การนอนหลับ ซึ่งในบางองค์กรได้เปิดให้ผู้วิจัยท่านอื่น ๆ สามารถเข้าถึงข้อมูลส่วนนี้ได้อย่างเสรี และสามารถนำข้อมูลนั้น ๆ ไปใช้ศึกษาเป็นข้อมูลสำหรับการสอนให้โมเดลเรียนรู้และใช้ในวิเคราะห์หา Sleep spindle โดยไม่จำเป็นต้องทำการทดลองด้วยตัวเอง ฐานข้อมูลสาธารณะที่นิยมใช้ มีรายละเอียด ดังนี้

ฐานข้อมูล DREAMS¹⁶ เป็นฐานข้อมูลที่รวบรวมข้อมูลจากการทำ PSG จำนวนมากเพื่อใช้สำหรับการทดสอบกับอัลกอริทึมตรวจจับคลื่นสมองแบบอัตโนมัติ (Automatic detection algorithm) นั้นรวมถึง Sleep spindle ด้วย พบว่าในหลาย ๆ งานวิจัยได้มีการนำข้อมูลบางส่วนจากฐานข้อมูล DREAMS มาใช้ทดสอบในการศึกษาด้วย²⁴⁻²⁸

ฐานข้อมูล Montreal archive of sleep studies (MASS)²⁹ เป็นฐานข้อมูลที่สร้างขึ้นด้วยจุดประสงค์เดียวกันกับฐานข้อมูล DREAM โดยเป็นฐานข้อมูลที่มาจากการศึกษา PSG ในกลุ่มตัวอย่างจำนวน 200 คน เช่นกัน ผู้วิจัยหลายท่านได้มีการนำข้อมูลบางส่วนจากฐานข้อมูล MASS มาใช้ทดสอบในการศึกษา^{24, 26-28, 30}

ฐานข้อมูล SIESTA³¹ ซึ่งถูกใช้ในการศึกษาของ Adamczyk et al.³² และฐานข้อมูล WSC1950 (Wisconsin Sleep Cohort)³³ Lacourse et al.³⁴

ซึ่งชุดข้อมูลจากฐานข้อมูลสาธารณะเหล่านี้มีขนาดของกลุ่มตัวอย่างที่ใหญ่กว่าและมีความหลากหลายมากกว่าข้อมูลที่มาจากการทดลอง จึงเหมาะสมกับผู้ที่ต้องการใช้ข้อมูลขนาดใหญ่เพื่อสร้างแบบจำลองการตรวจจับคลื่นสมอง Sleep spindle

การจัดการข้อมูล (Data Preprocessing)

ในการวิเคราะห์ข้อมูล จำเป็นต้องใช้ข้อมูลที่อยู่ในช่วงที่ถูกต้อง เหมาะสม และลดความผิดพลาดที่เกิดขึ้นในข้อมูลให้น้อยที่สุดเพื่อให้ขั้นตอนการวิเคราะห์เกิดประสิทธิภาพสูงสุด จากขั้นตอนการรวบรวมข้อมูลทีกล่าวนำมาแล้วในข้างต้น ข้อมูลที่รวบรวมมาไม่สามารถนำไปใช้ในการวิเคราะห์ข้อมูลได้ในทันที ต้องผ่านขั้นตอนการจัดการข้อมูลด้วยกระบวนการต่าง ๆ ให้ข้อมูลอยู่ในรูปแบบที่เหมาะสมกับการวิเคราะห์ข้อมูล โดยวิธีการจัดการกับข้อมูล EEG มีดังนี้

การสุ่มตัวอย่าง คือ การแปลงสัญญาณประเภทที่มีการเปลี่ยนแปลงต่อเนื่องเทียบกับเวลา (Continuous signal) ให้อยู่ในรูปสัญญาณประเภทไม่ต่อเนื่องทางเวลา (Discrete signal) ด้วยการสุ่มเลือกตัวอย่างของสัญญาณนั้น ๆ ในช่วงเวลาที่เท่ากัน (Time resolution) มีหน่วยเป็นวินาที และเรียกค่าดังกล่าวว่า ค่าอัตราสุ่มสัญญาณ (Sampling rate) เช่น ค่าอัตราสุ่มสัญญาณ 1000 Hz หมายถึง การแบ่งสัญญาณในช่วงเวลา 1 วินาทีออกเป็น 1000 จุด ซึ่งเมื่อค่าอัตราสุ่มสัญญาณยิ่งสูง สัญญาณจะยิ่งมีความละเอียดมากขึ้นโดยจากการศึกษาพบว่าค่าอัตราสุ่มสัญญาณที่นิยมใช้ในงานนี้คือ 100 Hz, 128 Hz, 200 Hz และ 500 Hz โดยค่าอัตราสุ่มสัญญาณที่นิยมใช้มากที่สุด คือ 200 Hz^{11,28,35} นอกจากนี้ อาจมีการใช้วิธีลดอัตราสุ่มตัวอย่าง (Downsampling) เพื่อลดจำนวนข้อมูลที่มีความละเอียดมากเกินไปในการสุ่มตัวอย่างเดิม โดยจากการศึกษาของ Mei et al.²⁸ มีการลดอัตราสุ่มตัวอย่างจาก 1000 Hz ไปเป็น 500 Hz ในขณะที่การศึกษาของ Duman et al.³⁵ และ Güneş et al.¹¹ ลดอัตราสุ่มตัวอย่างจาก 200 Hz ไปเป็น 128 Hz และได้มีการสุ่มตัวอย่างตามทฤษฎีไนควิสต์ (Nyquist theorem) ซึ่งกล่าวว่าการสุ่มตัวอย่างอาจไม่จำเป็นต้องใช้ค่าอัตราสุ่มสัญญาณที่สูงเสมอไป แต่สามารถทำได้ด้วยการใช้ค่าอัตราสุ่มสัญญาณที่มีค่า

เป็น 2 เท่าของความถี่ที่ต้องการ และจะทำให้สามารถรักษาข้อมูลความถี่ของสัญญาณไว้ได้ วิธีการดังกล่าวถูกใช้ในการศึกษาของ Duman et al.³⁵ เช่นกัน

การแบ่งช่วงสัญญาณ (Windowing) คือ วิธีการที่แบ่งสัญญาณทั้งหมดออกเป็นช่วงสัญญาณย่อย ๆ ที่มีความยาวเท่ากันด้วยฟังก์ชันทางคณิตศาสตร์เพื่อให้สะดวกต่อการนำมาวิเคราะห์ อีกทั้งยังใช้ทรัพยากรในการคำนวณน้อยการวิเคราะห์สัญญาณทั้งหมดในครั้งเดียว การทำ Windowing ที่พบในการศึกษาส่วนใหญ่ คือ Rectangular windowing คือ การแบ่งช่วงสัญญาณโดยข้อมูลของสัญญาณในช่วงดังกล่าวจะไม่ถูกเปลี่ยนแปลง ซึ่งพบในการศึกษาของ Huupponen et al.³⁶, Babadi et al.³⁷, และ Güneş et al.¹¹ และการทำ Hamming windowing ซึ่งถูกใช้เพื่อลดการเกิดรอยหยักของสัญญาณ (Ripple) ทำให้สามารถระบุความถี่และแอมพลิจูดของความถี่นั้น ๆ ได้แม่นยำยิ่งขึ้น ซึ่งถูกนำมาใช้ในการศึกษาของ Mei et al.²⁸, การศึกษาของ Duman et al.³⁵ และการศึกษาของ Shimada et al.³⁸ ส่วนขนาดของการทำ Windowing (Window size) อาจมีขนาดเพียงไม่กี่มิลลิวินาที (millisecond: ms) ไปจนถึงหน่วยวินาที (second: s) หากใช้ Window ที่มีขนาดใหญ่ขึ้น จะได้ความละเอียดของข้อมูลทางความถี่เพิ่มมากขึ้น แต่แลกมาด้วยความละเอียดของข้อมูลทางเวลาที่น้อยลง โดย Window ที่ใช้ในการศึกษาของ Nonclercq et al.²⁵, Shimada et al.³⁸ และ Patti et al.²⁷ มีขนาดเท่ากับ 0.5, 0.64 และ 1 วินาที ตามลำดับ และในขั้นตอนการแบ่งช่วงสัญญาณ อาจอนุญาตให้มีการซ้อนทับกันของ Window (Overlap) ซึ่งจะช่วยแก้ปัญหาการรั่วไหลของสัญญาณได้ ตัวอย่างการอนุญาตให้มีการซ้อนทับกันของ Window เช่น การศึกษาของ Nonclercq et al.²⁵ ที่ใช้ขนาดของ Window เท่ากับ 0.5 วินาที มีการอนุญาตให้เลื่อน Window ซ้อนทับกันได้ 120 มิลลิวินาที หรือในการศึกษาของ Shimada et al.³⁸ อนุญาตให้มีการซ้อนทับกัน 50% ของขนาด Window เดิม เป็นต้น

การกรองความถี่ของสัญญาณ (Signal filtering) คือ กระบวนการกรองความถี่หรือช่วงของความถี่ (Frequency band) ในบางช่วงที่ไม่ต้องการออกจากสัญญาณ ซึ่งก่อนทำการกรองสัญญาณจะต้องทำการแปลงสัญญาณจากโดเมนเวลา (Time domain) เป็นโดเมนความถี่ (Frequency domain) โดยมีวัตถุประสงค์เพื่อกรองสัญญาณให้อยู่ในเฉพาะช่วงที่สนใจ ซึ่งในการศึกษานี้คือช่วงของคลื่น Sleep spindle ในการศึกษาหนึ่ง ๆ ผู้วิจัยอาจมีการนำตัวกรองประเภทต่าง ๆ มาใช้มากกว่า 1 ประเภทตามความเหมาะสม โดยประเภทของตัวกรองความถี่ของสัญญาณสามารถแบ่งได้ ดังนี้

Low-pass filter เป็นการกรองสัญญาณที่มีความถี่ต่ำกว่าค่าที่กำหนดไว้ โดยพบว่าค่าตัวกรองที่ใช้ในการศึกษาของ Adamczyk et al.³² และ Babadi et al.³⁷ มีค่าเท่ากับ 70 Hz

High-pass filter ในการกรองสัญญาณที่มีความถี่สูงกว่าค่าที่กำหนดไว้ โดยพบว่าค่าตัวกรองที่ใช้ในการศึกษาของ Babadi et al.³⁷ และ Adamczyk et al.³² เท่ากับ 0.3 Hz และ 0.53 Hz ตามลำดับ การศึกษาของ Mei et al.²⁸ ใช้ค่าตัวกรองเท่ากับ 6 Hz เพื่อกรองคลื่นเดลต้าและคลื่น K-complex และ Nonclercq et al.²⁵ ใช้ค่าตัวกรองเท่ากับ 12.5 Hz เพื่อกรองคลื่นแอลฟา

Band-pass filter อนุญาตให้สัญญาณที่มีความถี่ภายในช่วงที่กำหนดเท่านั้นสามารถผ่านไปได้ ซึ่ง American Association of Sleep Technologists ได้กำหนดค่าตัวกรองมาตรฐานของ EEG ไว้ที่ 0.3–35 Hz³⁹ โดยพบว่าการศึกษามีการใช้ค่าตัวกรองสำหรับการตรวจจับ EEG ที่หลากหลาย เช่น 0.5–35 Hz ในการศึกษาของ Duman et al.³⁵ 0.1–50 Hz, 0.1–200 Hz ในการศึกษาของ Mei et al.²⁸ และ 0.3–300 Hz ในการศึกษาของ Kulkarni et al.³⁰ ส่วนค่าตัวกรองที่ใช้ในการศึกษาเพื่อเลือกความถี่เฉพาะช่วงคลื่น Sleep spindle มักพบว่าอยู่ในช่วงความถี่ 9–17 Hz^{24,26,28,30,32,34,36}

Finite impulse response (FIR) filter เป็นตัวกรองที่ผลลัพธ์จะขึ้นอยู่กับสัญญาณตั้งต้น ค่าตัวกรองที่ใช้ เช่น 8.7–18.5 Hz ได้ถูกใช้ในการศึกษาของ Adamczyk et al.³²

Butterworth filter เป็นตัวกรองที่เลือกเฉพาะช่วงความถี่ต่ำเช่นเดียวกับการทำงานของ Low-pass filter แต่จะให้ความราบรื่นของความถี่มากกว่า พบการใช้ตัวกรองดังกล่าวแบบ second order ในการศึกษาของ Mei et al.²⁸, fourth order ในการศึกษาของ Parekh et al.²⁴ และ eight order ที่ 10.5–16 Hz, 4–10 Hz และ 20–40 Hz ที่อยู่ในการศึกษาของ Patti et al.²⁷

Band-stop filter จะทำให้สัญญาณที่มีความถี่ภายในช่วงที่กำหนดนั้นไม่สามารถผ่านไปได้ แต่สัญญาณที่มีความถี่อยู่นอกเหนือช่วงดังกล่าวจะสามารถผ่านไปได้ เช่น การกำจัดสัญญาณในช่วงความถี่ 9–16 Hz บน EEG ในการศึกษาของ Kulkarni et al.³⁰

Notch filter ที่มีลักษณะการทำงานเหมือน Band-stop filter แต่เป็น Band-stop filter ที่มีช่วงแคบมาก ๆ กล่าวคือ จะไม่อนุญาตให้สัญญาณที่ความถี่ใดความถี่หนึ่งผ่านได้ หรือสามารถเรียกได้ว่าเป็น extreme band-stop filter ค่าตัวกรองที่ใช้ในการศึกษา เช่น 50 Hz สำหรับการกำจัดสัญญาณรบกวน ในการศึกษาของ Wei et al.⁴⁰ หรือ การกำจัดสัญญาณรบกวนที่ความถี่ 60 Hz, 120 Hz และ 180 Hz ในการศึกษาของ Mei et al.²⁸

การดึงคุณลักษณะสำคัญจากข้อมูล (Feature Extraction)

ก่อนที่จะสามารถดึงคุณลักษณะสำคัญของข้อมูลออกมา ในบางครั้งจะต้องมีการแปลงข้อมูลสัญญาณให้อยู่ในโดเมนที่ต้องการเพื่อให้ได้ลักษณะสำคัญของข้อมูล

มาใช้งาน ซึ่งวิธีการแปลงมีหลายรูปแบบ เช่น การแปลงจากโดเมนเวลาเป็นโดเมนความถี่ มีจุดประสงค์เพื่อเพิ่มข้อมูลในเชิงความถี่ประกอบการวิเคราะห์ เนื่องด้วยข้อมูลความถี่นี้เป็นหนึ่งในลักษณะสำคัญที่จะช่วยบ่งชี้ถึง Sleep spindle ได้ โดยวิธีการแปลงที่ใช้ในการตรวจจับ Sleep spindle ได้แก่ การแปลงแบบฟูเรียร์ (Fourier Transform: FT) เป็นการวิเคราะห์องค์ประกอบของสัญญาณในเชิงความถี่ ได้ผลลัพธ์เป็นข้อมูลความถี่และข้อมูลแอมพลิจูดของความถี่นั้น ๆ และเนื่องจากข้อมูล EEG เป็นข้อมูลที่ผ่านการสุ่มตัวอย่างมา ประเภทของ FT ที่ใช้ในงานนี้จึงมีพื้นฐานมาจาก Discrete Fourier Transform (DFT) ซึ่งเป็นการแปลงที่เข้ากับสัญญาณแบบไม่ต่อเนื่อง (Discrete) โดยการแปลงที่นิยมใช้คือ Fast Fourier Transform (FFT)^{11,25,27,32,36,38} และ Short-time Fourier Transform (STFT)^{35,41} นอกจากนี้ ยังมีการแปลงสัญญาณที่เกิดจากการรวมกันของสัญญาณเฉพาะหลาย ๆ สัญญาณให้อยู่ในรูปของคลื่นสัญญาณเล็ก ๆ ที่เรียกว่า “เวฟเล็ต” (Wavelet)³² โดยวิธีการ Wavelet transform (WT) เป็นการแปลงทางคณิตศาสตร์ที่ให้ผลลัพธ์คล้ายกับ STFT คือ สามารถดึงข้อมูลเวลาและความถี่ ซึ่งต่างจาก FT ที่สามารถดึงได้เพียงข้อมูลแอมพลิจูดและความถี่เท่านั้น

หลังจากแปลงข้อมูลให้อยู่ในโดเมนที่ต้องการแล้ว จึงจะสามารถนำข้อมูลมาใช้ในการขั้นตอนการดึงเฉพาะคุณลักษณะ (Feature) ที่มีความโดดเด่นหรือมีความสำคัญออกมาจากข้อมูลเพื่อนำไปใช้ในการเรียนรู้ของโมเดลต่อไป ข้อมูลที่มีคุณลักษณะเฉพาะที่ได้จากการดึงคุณลักษณะออกมาจากคลื่น EEG สามารถแบ่งออกเป็น 2 ประเภท ดังนี้

1. โดเมนเวลา (Time domain) เป็นข้อมูลการแสดงการเปลี่ยนแปลงของแอมพลิจูดเทียบกับเวลา กล่าวคือเป็นการบันทึกค่าแอมพลิจูดที่เกิดขึ้นในระบบเมื่อเวลาผ่านไป ข้อมูลโดเมนเวลาเกิดจากการวิเคราะห์ด้วยความรู้ทางคณิตศาสตร์ควบคู่กับการวิเคราะห์ลักษณะของสัญญาณ ซึ่งในหลายการศึกษาได้ทำการดึงคุณลักษณะจากข้อมูลโดเมนเวลาดังกล่าวเพื่อนำค่าที่ได้ไปใช้เป็นเกณฑ์ในการบ่งชี้ถึง Sleep spindle ที่เกิดขึ้นหรือบ่งชี้ข้อมูลอื่น ๆ ที่มีความสำคัญสำหรับการวิเคราะห์ ข้อมูลโดเมนเวลาที่มักนำมาใช้ในการวิเคราะห์ คือ ค่าทางสถิติที่คำนวณมาจากค่าแรงดันไฟฟ้าในสมองที่เกิดขึ้นในช่วงเวลาหนึ่ง ๆ โดยค่าแรงดันไฟฟ้าในสมองมักมีหน่วยเป็นไมโครโวลต์ (Microvolts: μV) และช่วงเวลาที่ใช้พิจารณามักใช้หน่วยเป็นวินาที การศึกษาของ Huupponen *et al.* มีการสร้างแผนภาพการกระจายตัวของค่าแอมพลิจูดของ Sleep spindle เพื่อนำไปหาค่าเกณฑ์ที่เหมาะสม³⁶ ส่วนในการศึกษาของ Güneş *et al.* คำนวณค่าเฉลี่ย ค่าเบี่ยงเบนมาตรฐาน ค่าแอมพลิจูดสูงสุด ค่าความเบ้ (Skewness) ค่าความโด่ง (Kurtosis) และ

ค่ารูปร่างของสัญญาณ (Shape factor) เป็นคุณลักษณะในโดเมนเวลา¹¹ และในการศึกษาของ Wei *et al.* มีการใช้ค่าเฉลี่ย ค่าสัมบูรณ์ ค่าเบี่ยงเบนมาตรฐาน และค่าเฉลี่ยกำลังสอง (Root Mean Square: RMS) ของแอมพลิจูดเป็นคุณลักษณะของโมเดล⁴⁰

2. โดเมนความถี่ (Frequency domain) เป็นการวิเคราะห์องค์ประกอบของสัญญาณในเชิงความถี่ โดยจะแสดงความสัมพันธ์ระหว่างแอมพลิจูด ตำแหน่งบนคลื่น (Phase) และความถี่ โดย 1 Hz คือความถี่ที่เท่ากับ 1 ครั้งต่อวินาที (1/s) ผู้วิจัยมักใช้ข้อมูลโดเมนความถี่ซึ่งแปลงมาจากโดเมนเวลาควบคู่กันไป เนื่องด้วยค่าความถี่คือลักษณะสำคัญที่สามารถบ่งชี้ความเป็น Sleep spindle ได้ สัญญาณในโดเมนความถี่ช่วยให้เข้าใจคุณสมบัติต่าง ๆ ของสัญญาณได้ง่ายมากยิ่งขึ้น โดยข้อมูลโดเมนความถี่ที่พบได้บ่อยครั้ง มีดังนี้

สเปกตรัมความถี่ (Frequency spectrum) เป็นผลลัพธ์ที่ได้จากแปลงโดเมนเวลาให้เป็นโดเมนความถี่ จะแสดงผลเป็นแอมพลิจูด เฟส และความถี่ ในการศึกษาของ Patti *et al.* ใช้ข้อมูลจากสเปกตรัมในการแยก Sleep spindle แบบช้าและ Sleep spindle แบบเร็ว²⁷ และในการศึกษาของ Nonclercq *et al.* มีการใช้ข้อมูลจากสเปกตรัมเป็นคุณลักษณะของโมเดล²⁵

ค่าความถี่ เป็นปริมาณที่บ่งบอกจำนวนครั้งที่เหตุการณ์เกิดขึ้นในเวลาหนึ่งของสัญญาณ มีหน่วยเป็นเฮิรตซ์ (Hertz: Hz) ในการศึกษาของ Güneş *et al.* ได้คำนวณค่าต่ำสุด ค่าสูงสุด ค่าเบี่ยงเบนมาตรฐาน และค่าเฉลี่ยของความถี่สัญญาณทั้งหมดที่ใช้ในการศึกษา¹¹

ค่า Sigma index เป็นคุณลักษณะที่สามารถบ่งบอกถึงโอกาสที่จะมี Sleep spindle ได้ โดยคำนวณมาจากสูตรที่ประกอบด้วยค่าความถี่ เช่น การที่ Sigma index มีค่าสูงจะบ่งชี้ได้ว่ามีความเป็นไปได้ที่จะมี Sleep spindle สูง³⁶

การสร้างแบบจำลองการตรวจจับคลื่นสมอง Sleep spindle (Sleep Spindle Detection Models)

วิธีการใช้กฎ หรือ Rule-based approach เป็นวิธีที่ใช้ในการตรวจจับ Sleep spindle ดั้งเดิม โดยจะคำนวณค่าที่นำมาใช้เป็นเกณฑ์ในการแบ่งประเภทของข้อมูล (Thresholding) วิธีนี้เป็นวิธีพื้นฐานที่นำไปสู่การพัฒนาโมเดลที่ใช้สำหรับการตรวจจับ Sleep spindle อัตโนมัติ ในการศึกษาของ Huupponen *et al.* ใช้การคำนวณค่า Sigma index จากข้อมูลความถี่ และค่าแอมพลิจูดของ Spindle เพื่อสร้างเป็นค่าในการแบ่งเกณฑ์ว่ามีการพบ Sleep spindle ใน EEG หรือไม่ ซึ่งให้ความจำเพาะของการทดสอบ (Specificity) เท่ากับ 97.7%³⁶ ในการศึกษาของ Adamczyk *et al.* ตรวจจับ Sleep spindle โดยใช้ค่าจากการคำนวณ Continuous wavelet transform ที่มีค่ามากกว่าค่าการเกิด Sleep spindle และค่า Sleep spindle peak ที่น้อยที่สุด

ซึ่งได้ผลค่าความไวของการทดสอบ (Sensitivity) เท่ากับ 72% และความจำเพาะของการทดสอบเท่ากับ 90%³² ในการศึกษาของ LaRocco *et al.* ใช้โมเดลที่มีชื่อว่า Spindler ซึ่งเป็นวิธีการที่ประกอบด้วย 3 ขั้นตอน คือ (1) การแสดงสัญญาณโดย Matching pursuit ด้วย Gabor atom (2) การสร้างพื้นผิวพารามิเตอร์เพื่อตรวจจับการมีอยู่ของ Sleep spindle ในสัญญาณที่สร้างขึ้นใหม่ และ (3) เลือกพารามิเตอร์ที่ดีที่สุดทำการวิเคราะห์ออกมาเพื่อตรวจจับ Sleep spindle ซึ่งได้ค่า F1 เท่ากับ 0.67–0.73²⁶ ส่วนในการศึกษาของ Parekh *et al.* ใช้วิธีการ Teager-Kaiser energy operator (TKEO) เพื่อตรวจจับ Sleep spindle โดยสร้างเกณฑ์จากวิธี Singular value thresholding (SVT) ที่คำนวณค่าคงที่หนึ่ง ๆ ด้วย Soft-threshold function หากค่าที่ได้จากการคำนวณของ TKEO มีค่ามากกว่าค่าที่ได้จากการทำ SVT จะบ่งชี้ถึงการพบ Sleep spindle ในคลื่นสัญญาณนั้น ๆ วิธีการดังกล่าวสามารถใช้ในการวิเคราะห์ข้อมูล EEG จากทั้ง Single channel หรือ Multichannel ได้ และได้ค่า F1 เฉลี่ยอยู่ที่ 0.66 ในชุดข้อมูล DREAMS และ 0.62 ในชุดข้อมูล MASS²⁴ การศึกษาของ Nonclercq *et al.* สร้างการแจกแจงปรกติแบบ 2 ตัวแปร (Bivariate normal distribution) เพื่ออธิบายถึงลักษณะของแอมพลิจูดและความถี่ของ Sleep spindle ด้วยการประมาณเกณฑ์ที่ใช้จากวิธี Maximum likelihood estimation (MLE) กล่าวคือ ทำให้ทราบได้ว่าข้อมูลควรมีการกระจายตัวอย่างไร และควรมีการกำหนดเกณฑ์ที่เหมาะสมกับชุดข้อมูลนั้น ๆ จากความน่าจะเป็นสูงสุดอย่างไร ซึ่งให้ความจำเพาะของการทดสอบเท่ากับ 94.2%²⁵ การศึกษาของ Babadi *et al.* ใช้หลักความน่าจะเป็นคำนวณจากทฤษฎีของเบย์ (Bayes' theorem) โดยนำ EEG ในแต่ละช่วงย่อย ๆ มาคำนวณ Eigenfunction และเอามาแปลงเป็นค่า Transform coefficient เพื่อนำมาคำนวณความน่าจะเป็นที่ช่วงย่อยของ EEG จะมี Sleep spindle ซึ่งให้ความจำเพาะของการทดสอบอยู่ในช่วงระหว่าง 95.54%–97.2%³⁷ และในการศึกษาของ Lacourse *et al.* ใช้หลักการคำนวณเกณฑ์แบบ A7 ซึ่งประกอบด้วยค่าที่คำนวณมาจากการวิเคราะห์สเปกตรัมกำลังให้ความแม่นยำ 74%³⁴

วิธีการตรวจจับ Sleep spindle โดยวิธีการใช้กฎเป็นวิธีการดั้งเดิมที่อาศัยสมการทางคณิตศาสตร์และเกณฑ์การคำนวณที่หลากหลาย โดยค่าที่นำมาใช้ในการคำนวณขึ้นอยู่กับความเหมาะสมของแต่ละข้อมูลและดุลยพินิจของผู้วิจัยในงานนั้น ๆ แต่เนื่องจากการตรวจจับ Sleep spindle ด้วยวิธีการใช้กฎนั้น ไม่เหมาะกับการนำมาใช้ในงานปัจจุบัน เนื่องด้วยการพัฒนาของระบบอัตโนมัติ ระบบออนไลน์ หรือระบบเรียลไทม์ เพื่อตอบสนองต่อการใช้งานดังกล่าว การเรียนรู้ของเครื่อง (Machine

learning) จึงได้เข้ามามีบทบาทสำคัญในการช่วยลดเวลาในการคำนวณ เรียนรู้การทำงานที่ซับซ้อน และช่วยลดข้อผิดพลาดที่เกิดขึ้น การเรียนรู้ของเครื่องนั้นมียุทธศาสตร์หลายประเภท โดยในการตรวจจับ Sleep spindle สามารถแบ่งประเภทของโมเดลได้ ดังนี้

โมเดลประเภทจำแนกข้อมูล (Classification)

หลักการทำงานคือการสร้างตัวจำแนกข้อมูล (Classifier) เพื่อทำนายประเภทหรือหมวดหมู่ของข้อมูล (Class) โดยในการเรียนรู้ โมเดลต้องประมวลผลข้อมูลที่ถูกระบุหมวดหมู่ไว้ก่อนแล้วหรือเรียกว่าการเรียนรู้แบบมีผู้สอน (Supervised learning) เป้าหมายการทำนายของโมเดลในงานนี้คือคลื่น EEG ที่ถูกพิจารณาจัดอยู่ในหมวดหมู่ “พบ Sleep spindle” หรือ หมวดหมู่ “ไม่พบ Sleep spindle” ในการศึกษาของ Duman *et al.* ใช้โมเดล Decision tree สร้างกฎเพื่อจำแนกข้อมูลด้วยผลการประเมินจาก 3 อัลกอริทึม ได้แก่ STFT, Multiple Signal Classification (MUSIC) และ Teager Energy Operator (TEO) หากทั้ง 3 อัลกอริทึมสามารถตรวจจับ Sleep spindle ได้ จะสามารถสรุปได้ว่าใน EEG นั้นมี Sleep spindle อยู่จริง ซึ่งให้ผลลัพธ์ความไว 96.17%³⁵ การศึกษาของ Görür *et al.* ใช้โมเดล Support vector machine (SVM) ในการแบ่งหมวดหมู่ข้อมูลออกจากกันด้วยสมการแบบเชิงเส้น (Linear) หรือ สมการแบบไม่เชิงเส้น (Nonlinear) โดยในการศึกษาได้เลือกใช้ Radial basis function (RBF) kernel เพื่อเปลี่ยนมิติ (Space) ของข้อมูลให้สามารถแบ่งแยกหมวดหมู่ออกจากกันได้ง่ายขึ้น ให้ผลลัพธ์ความแม่นยำ 94.9%–96%⁴¹ เช่นเดียวกันกับการศึกษาของ Wei *et al.* ที่ใช้โมเดล SVM เปรียบเทียบผลลัพธ์กับโมเดล Random forest ซึ่งเป็นโมเดลที่ประกอบด้วยโมเดล Decision tree หลาย ๆ โมเดลรวมกัน ให้ผลลัพธ์ความแม่นยำ 94.8%⁴⁰ ในการศึกษาของ Mei *et al.* ใช้โมเดลการถดถอยโลจิสติกส์ (Logistic regression) มีหลักการคือการคำนวณค่าความน่าจะเป็นของแต่ละหมวดหมู่จากสมการถดถอย (Regression) โดยคำนวณเกณฑ์ตั้งต้น ต่อมานำค่าดังกล่าวไปเป็นตัวจำแนกข้อมูลในโมเดลที่มาจากไลบรารีของ Python ที่มีชื่อว่า Tree-based Pipeline Optimization Tool (TPOT) ซึ่งไลบรารีดังกล่าวจะทำการเลือกโมเดลที่ดีที่สุดโดยอัตโนมัติ ไม่ว่าจะเป็น Decision tree, Random forest, eXtreme gradient boosting classifier, Logistic regression หรือ K-Nearest neighbor classifier โดยแต่ละโมเดลจะทำงานได้ดีขึ้นตามขนาดของชุดข้อมูล ยิ่งข้อมูลมากขึ้น โมเดลจะสามารถทำงานได้ดีขึ้น²⁸

โมเดลประเภทการเรียนรู้เชิงลึก (Deep neural network) เป็นโมเดลที่เลียนแบบการทำงานของระบบโครงข่ายประสาท (Neural network) ที่ซ้อนกันหลายชั้น (Layer) ของมนุษย์ โมเดลสามารถเรียนรู้การตรวจจับ

รูปแบบหรือจัดหมวดหมู่ข้อมูลด้วยการพยายามหาจุดเด่นจากข้อมูลตัวอย่างอัตโนมัติการศึกษาศึกษาของGörür *et al.* ใช้โมเดล Multilayer perceptron (MLP) เพื่อทำการจัดหมู่ โดยโมเดลมีลักษณะเป็นระบบโครงข่ายประสาทที่ส่งข้อมูลจากทุกเซลล์ประสาทเทียม (Neuron) ใน Layer ก่อนหน้าไปยังทุก Neuron ใน Layer ถัดไป โดยทำนายผลออกมาเป็นหมวดหมู่ที่พบ Sleep spindle หรือหมวดหมู่ที่ไม่พบ Sleep spindle ให้ความแม่นยำอยู่ที่ 91.7%–93.1%⁴¹ เช่นเดียวกับการศึกษาของ Güneş *et al.* ที่ใช้โมเดลโครงข่ายประสาทเทียมแบบ Levenberg-Marquardt (LM-ANN) แต่สามารถให้ความแม่นยำที่ดีที่สุดถึง 100%¹¹ อย่างไรก็ตาม พบว่าในการศึกษาได้กล่าวว่าการใช้ LM-ANN กับคุณลักษณะที่เป็นข้อมูลของโดเมนความถี่เพียงอย่างเดียวให้ผลลัพธ์ไม่ดีเท่าที่ควรโดยมีความแม่นยำอยู่ที่ 56.86%¹¹ การศึกษาของ Shimada *et al.* มีการใช้โมเดล Sleep electroencephalogram recognition neural network (SRNN) เป็นโมเดลโครงข่ายประสาทเทียมสำหรับการตรวจจับคลื่นที่มีลักษณะพิเศษใน Sleep EEG โดยเฉพาะ ซึ่งถูกพัฒนามาจากโมเดล Time-delay neural network (TDNN) ที่มีหลักการคือการค้นหารูปแบบจากการวิเคราะห์ข้อมูลความถี่ต่อเวลาแบบไม่มีลำดับ ซึ่งให้ค่า Recall ที่สูงที่สุดเมื่อเทียบกับโมเดล CNN และโมเดล TDNN³⁸ การศึกษาของ Kulkarni *et al.* มีการใช้ 2 โมเดลร่วมกันคือ โมเดลโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional neural network: CNN) มีหลักการคือการใช้ชั้นประมวลผล (Layer) ชนิดพิเศษที่เรียกว่า Convolution layer ซึ่งทำหน้าที่สกัดเอาองค์ประกอบที่ต้องการจาก EEG และโมเดล Long short-term memory (LSTM) เพื่อเรียนรู้ลำดับและค้นหารูปแบบในองค์ประกอบเหล่านั้น ซึ่งมีประสิทธิภาพของโมเดลเท่ากับ 96.08%³⁰

โมเดลประเภทแบ่งกลุ่มข้อมูล (Clustering) เป็นโมเดลที่สามารถประมวลผลได้โดยไม่ต้องใช้ข้อมูลที่ถูกกำหนดหมวดหมู่ไว้ก่อนแล้ว หรือเรียกว่าการเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) โดยโมเดลจะสามารถแบ่งข้อมูลออกเป็นกลุ่มตามลักษณะบางประการที่โมเดลจะเป็นผู้เรียนรู้เองโดยการศึกษาของPatti *et al.* ได้ใช้ Multivariate gaussian mixture model (MGMM) เป็นโมเดลที่สามารถเรียนรู้ได้เองโดยไม่ต้องกำหนดเกณฑ์ต้น เนื่องจากตัวโมเดลใช้วิธีการหาค่าคาดหวังสูงสุด (Expectation maximization: EM) เพื่อกำหนดความน่าจะเป็นไปยังกลุ่มข้อมูล 2 กลุ่ม (Cluster) โดยให้ความไวของการทดสอบอยู่ที่ 65.1%–74.1% และมีสัดส่วนผลบวกลงต่อจำนวนบริเวณ EEG ที่ผู้เชี่ยวชาญระบุมาทั้งหมดเท่ากับ 59.55%–119.7%²⁷

บางการศึกษามีการเปรียบเทียบประสิทธิภาพระหว่างโมเดล โดยการศึกษาของ Kulkarni *et al.*

มีการเปรียบเทียบระหว่างโมเดล SpindleNet, โมเดล Mcsleep³⁰ จากการศึกษาของ Parekh *et al.* และ Spindler การศึกษาของ LaRocco *et al.* ทดสอบกับข้อมูลจากฐานข้อมูล MASS พบว่า SpindleNet มีประสิทธิภาพโดยรวมดีกว่า McSleep ส่วนการเปรียบเทียบกับโมเดล Spindler พบว่ามีประสิทธิภาพใกล้เคียงกัน และในการศึกษาของ Parekh *et al.* พบว่าโมเดล McSleep ให้ผลที่ดีกว่าโมเดล DETOKS²⁴ ในบางค่าสามารถตรวจจับ Spindle ได้เร็วกว่า แต่มีความแม่นยำที่ใกล้เคียงกัน นอกจากนี้ มีการเปรียบเทียบกับโมเดลที่ต่างกันและชุดข้อมูลต่างกัน โดยในการศึกษาของ Wei *et al.* นั้นเป็นงานที่ใช้กลุ่มตัวอย่างจำนวนการมากที่สุดและได้มีความไวของการทดสอบสูงสุด⁴⁰ นอกจากนี้การศึกษาของ Mei *et al.* มีการสร้างแนวทางการเรียนรู้ของเครื่องแบบอัตโนมัติที่ให้ผลการประเมินเหมือนกับการประเมินของผู้เชี่ยวชาญท่านหนึ่งจากฐานข้อมูล DREAM²⁸

การประเมินประสิทธิภาพของโมเดล (Data Evaluation)

สำหรับวิธีการที่นำมาใช้ในการประเมินประสิทธิภาพของโมเดลนั้น ขึ้นอยู่กับประเภทของโมเดลที่นำมาใช้ในการทำนาย หากเป็นโมเดลที่เรียนรู้แบบมีผู้สอน ได้แก่ โมเดลในกลุ่มประเภทจำแนกข้อมูลและโมเดลการเรียนรู้เชิงลึก จะวัดประสิทธิภาพจากการเปรียบเทียบผลลัพธ์จริงกับผลลัพธ์ที่โมเดลทำนายว่ามีความแตกต่างกันอย่างไร โดยค่าที่นิยมใช้ในการประเมินประสิทธิภาพของโมเดล มีดังนี้

ผลบวกจริง (True positive: TP) คือ จำนวนบริเวณบนคลื่น EEG ที่ผู้เชี่ยวชาญและโมเดลระบุตรงกันว่าเป็น Sleep spindle

ผลบวกлож (True negative: TN) คือ จำนวนบริเวณบนคลื่น EEG ที่ผู้เชี่ยวชาญและโมเดลระบุตรงกันว่าเป็น Sleep spindle

ผลลบจริง (False positive: FP) คือ จำนวนบริเวณบนคลื่น EEG ที่โมเดลระบุว่าเป็น Sleep spindle แต่ผู้เชี่ยวชาญกลับระบุไว้ว่าไม่เป็น Sleep spindle

ผลลบлож (False negative: FN) คือ จำนวนบริเวณบนคลื่น EEG ที่โมเดลระบุว่าเป็น Sleep spindle แต่ผู้เชี่ยวชาญกลับระบุไว้ว่าเป็น Sleep spindle

ความแม่นยำ (Precision) คือ ค่าประเมินประสิทธิภาพว่าโมเดลทำนายผลลัพธ์ที่เป็น Sleep spindle (True positive) ได้ถูกต้องมากเพียงใด เมื่อเปรียบเทียบกับผลลัพธ์ที่โมเดลระบุว่าเป็น Sleep spindle ทั้งหมด (True positive + False positive)

ความไว (Recall หรือ Sensitivity) คือ ค่าประเมินประสิทธิภาพว่าโมเดลทำนายผลลัพธ์ที่เป็น Sleep spindle (True positive) ได้ถูกต้องมากเพียงใด เมื่อ

เปรียบเทียบกับผลลัพธ์ที่ผู้เชี่ยวชาญระบุว่าเป็น Sleep spindle ทั้งหมด (True positive + False negative)

ความจำเพาะ (Specificity) คือ ค่าประเมินประสิทธิภาพว่าโมเดลทำนายผลลัพธ์ที่ไม่เป็น Sleep spindle (True negative) ได้ถูกต้องมากเพียงใด เมื่อเปรียบเทียบกับผลลัพธ์ที่ผู้เชี่ยวชาญระบุว่าเป็น Sleep spindle ทั้งหมด (True negative + False positive)

F1-score คือ ค่าประเมินประสิทธิภาพโดยเฉลี่ยแบบฮาร์โมนิก (Harmonic mean) ของค่าความแม่นยำ (Precision) และค่าความไว (Recall)

ความถูกต้อง (Accuracy) คือ ค่าประเมินประสิทธิภาพโดยรวมของโมเดล โดยจะประเมินว่าโมเดลให้ผลลัพธ์ที่

ถูกต้อง (True positive + True negative) คิดเป็นสัดส่วนเท่าไรจากผลลัพธ์ทั้งหมด (True positive + True negative + False positive + False negative)

ส่วนโมเดลประเภทแบ่งกลุ่มข้อมูลซึ่งเป็นโมเดลที่เรียนรู้แบบไม่มีผู้สอนนั้น จะใช้การประเมินประสิทธิภาพของโมเดลที่แตกต่างจากโมเดลที่เรียนรู้แบบมีผู้สอน แต่จากการศึกษาของ Patti *et al.* ที่แม้จะใช้โมเดล Multivariate gaussian mixture model ในการแบ่งกลุ่มข้อมูล²⁷ แต่ทางผู้วิจัยได้เลือกใช้วิธีประเมินเดียวกับโมเดลที่เรียนรู้แบบมีผู้สอน โดยนำผลลัพธ์การทำนายที่ได้จากโมเดลไปเปรียบเทียบกับผลลัพธ์ที่ได้จากผู้เชี่ยวชาญ

ตารางที่ 1 แสดงตัวอย่างผลการวิจัยที่ได้จากการศึกษาการตรวจจับ Sleep spindle

โมเดล	ประสิทธิภาพของโมเดล	อ้างอิง
วิธีการใช้กฎ (Rule-based approach)		
Sigma index	ความจำเพาะ 97.7%	36
Sleep spindle peak	ความจำเพาะ 90%	32
โมเดลประเภทจำแนกข้อมูล (Classification)		
Decision tree	ความไว 96.17%	35
Random forest	ความแม่นยำ 94.8%	40
Support vector machine	ความแม่นยำ 94.9%–96%	41
โมเดลประเภทการเรียนรู้เชิงลึก (Deep neural network)		
Multilayer perceptron	ความแม่นยำ 91.7%–93.1%	41
Convolutional neural network และ Long short-term memory	ความแม่นยำ 96.08%	30
โครงข่ายประสาทเทียมแบบ Levenberg-Marquardt	ความแม่นยำ 100%	11
โมเดลประเภทแบ่งกลุ่มข้อมูล (Clustering)		
Multivariate gaussian mixture model	ความไว 65.1%–74.1%	27

อภิปรายผล (Discussion)

จากการทบทวนวรรณกรรมที่เกี่ยวข้องกับการใช้การเรียนรู้ของเครื่องเพื่อตรวจจับ Sleep spindle แบบอัตโนมัติพบว่าในแต่ละขั้นตอนของการทำงานสามารถใช้โมเดลได้หลากหลายและสามารถแบ่งกลุ่มโมเดลได้เป็น Rule-based approach, Classification, Deep Neural Network, และ Clustering^{11,27,30,32,35,36,40,41} ซึ่งการเลือกใช้โมเดลควรเลือกใช้ตามคุณลักษณะพื้นฐานของคลื่น Sleep spindle ของกลุ่มตัวอย่างว่ามีแนวโน้มหรือมีความแตกต่างจากคุณลักษณะพื้นฐานโดยทั่วไปอย่างไร ซึ่งถ้าหากมีความแตกต่างอย่างมีนัยยะสำคัญ ผู้วิจัยอาจพิจารณาปรับปรุงขั้นตอนในการวิเคราะห์ให้เหมาะสมกับกลุ่มตัวอย่างมากขึ้น และในส่วนของข้อมูลรบกวนที่อาจเป็นปัจจัยสำคัญที่ทำให้ประสิทธิภาพของโมเดลลดลง จึงมีการศึกษาเกี่ยวกับวิธีการคำนวณต่าง ๆ ที่สามารถนำมาช่วยในการตัดสัญญาณรบกวนออกได้ โดยเฉพาะสัญญาณที่ไม่ใช่คลื่นสมอง เช่น Independent component analysis (ICA) เป็นต้น^{42, 43} อย่างไรก็ตามหากสามารถสร้างโมเดลที่มีประสิทธิภาพที่น่าพึงพอใจได้แล้ว อาจพิจารณานำข้อมูลรบกวนเหล่านี้มาให้โมเดลเรียนรู้ร่วมกับข้อมูลชุดเดิมอีกครั้ง เพื่อให้โมเดลสามารถเรียนรู้ที่จะแบ่งแยกระหว่างสัญญาณจริงกับสัญญาณรบกวนได้ดียิ่งขึ้น หรือกล่าวคือ เป็นการทำให้โมเดลสามารถนำไปใช้กับข้อมูลที่หลากหลายมากขึ้น (Generalization)

ต่อมาคือการทดลองให้โมเดลเริ่มเรียนรู้จากคุณลักษณะจำนวนน้อย ๆ แล้วค่อย ๆ เพิ่มจำนวนคุณลักษณะที่ใช้และทดลองเลือกจับคู่คุณลักษณะที่แตกต่างกันเพื่อทดสอบว่าโมเดลจะให้ประสิทธิภาพที่แตกต่างกันหรือไม่ โดยพยายามเลือกคุณลักษณะที่มีความเป็นอิสระต่อกันหรือมีความซ้ำซ้อนกันน้อย กล่าวคือ ไม่เลือกคุณลักษณะใดคุณลักษณะหนึ่งที่เป็นค่าที่สามารถคำนวณได้จากอีกคุณลักษณะหนึ่ง ซึ่งการลดคุณลักษณะเหล่านี้จะช่วยเพิ่มประสิทธิภาพในการทำนายและลดระยะเวลาในการคำนวณลงไปได้⁴⁴ และถ้าหากผู้วิจัยต้องการวิเคราะห์ว่าคุณลักษณะใดสามารถบ่งชี้ถึง Sleep spindle ได้ดีที่สุด ผู้วิจัยควรวิเคราะห์เกี่ยวกับความสำคัญที่คุณลักษณะหนึ่ง ๆ ส่งผลต่อโมเดล (Feature importance) ร่วมด้วย จากนั้น อาจทดลองนำคุณลักษณะดังกล่าวไปใช้ในการแบ่งกลุ่มข้อมูลด้วยโมเดลประเภทไม่มีผู้สอนเพื่อเป็นการตรวจสอบว่าคุณลักษณะดังกล่าวสามารถใช้ในการบ่งชี้ได้จริง

ทั้งนี้ ถึงแม้ว่าจากการทบทวนวรรณกรรมจะพบว่าการทำนาย ความจำเพาะและความแม่นยำมีค่าค่อนข้างสูงถึง 90% แต่ก็ยังมีโอกาสในการทำนายตรวจจับที่ผิดพลาดได้ ดังนั้น เมื่อได้ผลการทำนายจากโมเดลแล้ว นอกจากจะประเมินประสิทธิภาพว่าโมเดลสามารถเรียนรู้และตรวจจับบริเวณที่เป็น Sleep spindle ได้ดี

เพียงใดแล้ว ควรจะพิจารณาควบคู่ไปด้วยว่าเหตุใดโมเดลจึงตอบผิด ทั้งผลบวกและผลลบลง ให้ทดลองวิเคราะห์ว่าข้อมูลลักษณะใดที่โมเดลมักจะตอบผิดหรือหากคาดการณ์ว่าไม่ได้มีสาเหตุมาจากลักษณะของข้อมูล อาจจะวิเคราะห์ในมุมมองของโมเดลว่า การทำงานของโมเดลส่วนใดที่เป็นสาเหตุหลักในการทำนายที่ผิดพลาด เป็นต้น ซึ่งการดำเนินงานดังกล่าวจะทำให้เข้าใจรูปแบบของผลลัพธ์ที่ได้มากขึ้น

สรุปผล (Conclusion)

คลื่นสมอง Sleep spindle เป็นคลื่นสมองที่มีบทบาทสำคัญในกระบวนการทางระบบประสาท วิธีการตรวจจับ Sleep spindle ได้มีการพัฒนาเพื่อให้เหมาะสมต่อการใช้งานระบบอัตโนมัติในปัจจุบัน โดยมีจุดประสงค์ของการใช้งาน คือ การประมวลผลอัตโนมัติที่มีความสามารถเทียบเท่ากับผู้เชี่ยวชาญ แต่ทำได้ในระยะเวลาที่สั้นกว่าและช่วยลดข้อผิดพลาดที่อาจเกิดขึ้นได้ การตรวจจับ Sleep spindle แบบอัตโนมัติที่ให้ประสิทธิภาพสูงที่สุดไม่ได้ขึ้นอยู่กับวิธีการที่ใช้เท่านั้น ขั้นตอนอื่น ๆ ทั้งก่อนและหลังการตรวจจับก็ถือเป็นปัจจัยสำคัญที่ช่วยเพิ่มประสิทธิภาพการในการทำงานได้ ขั้นตอนในการตรวจจับ Sleep spindle ประกอบด้วย การเก็บข้อมูลซึ่งเป็นขั้นตอนที่มีความสำคัญเป็นอย่างมาก โดยผู้วิจัยควรดึงข้อมูลมาจากแหล่งข้อมูลที่ตอบโจทย์ในการศึกษาและดึงเฉพาะข้อมูลที่ต้องการในปริมาณที่เหมาะสม ทั้งนี้ ในทางปฏิบัติการรวบรวมข้อมูลให้อยู่ในช่วงที่กำหนดโดยปราศจากข้อมูลรบกวนเป็นสิ่งที่เป็นไปได้ยาก ดังนั้นจึงต้องมีขั้นตอนการจัดการข้อมูล โดยการตรวจหา Sleep spindle มักใช้ค่าตัวกรองความถี่ของสัญญาณในการกรองช่วงสัญญาณที่มีข้อมูลรบกวนน้อยที่สุด ทั้งนี้ ค่าตัวกรองสัญญาณมีความแตกต่างกันตามดุลยพินิจของผู้วิจัย ซึ่งประเด็นเหล่านี้อาจนำไปศึกษาต่อยอดได้ว่าค่าตัวกรองความถี่ของสัญญาณหรือศึกษาว่าค่าอื่น ๆ ที่ใช้ในช่วงขั้นตอนการจัดการข้อมูลมีผลต่อการตรวจจับ Sleep spindle หรือไม่ เมื่อได้ข้อมูลในช่วงที่ต้องการขั้นตอนต่อมาเป็นการแปลงข้อมูลให้อยู่ในรูปแบบที่โมเดลสามารถเรียนรู้ได้ ซึ่งก็คือการดึงคุณลักษณะที่สำคัญของข้อมูล โดยผลลัพธ์ของคุณลักษณะที่ได้จะขึ้นอยู่กับวิธีการในการตรวจจับ Sleep spindle ที่ผู้วิจัยเลือกใช้ จากผลการศึกษาพบว่าข้อมูลทั้งโดเมนความถี่และโดเมนเวลาสามารถใช้ในการแบ่งแยก Sleep spindle ได้ไม่ต่างกัน โดยประสิทธิภาพของโมเดลอาจลดหลั่นตามความเหมาะสมระหว่างความสามารถของคุณลักษณะนั้น ๆ ในการบ่งชี้ถึง Sleep spindle กับลักษณะของโมเดลที่ใช้ และเนื่องด้วยประเภทของโมเดลหรือค่าความคมที่แตกต่างกัน ทำให้ไม่สามารถสรุปได้อย่างชัดเจนว่าวิธีการใดให้ผลดีที่สุด โดยปกติแล้วสามารถคาดหวังผลลัพธ์ที่ดีกว่าจากการเลือกใช้โมเดล

ที่ความซับซ้อนมากกว่า แต่อาจต้องแลกกับระยะเวลาที่ใช้ในการคำนวณและความสามารถในการอธิบายการทำงาน of โมเดลว่าสามารถแบ่งแยก Sleep spindle ออกจาก EEG ได้อย่างไร ในทางกลับกันการศึกษาอาจต้องยอมลดความซับซ้อนของโมเดลเพื่อให้เข้าใจในการทำงานของโมเดลมากขึ้น นอกจากนี้ Sleep spindle ถือเป็นข้อมูลที่มีความแปรปรวนสูง การเลือกใช้โมเดลที่สามารถรับมือกับข้อมูลที่มีความแปรปรวนสูงได้ดีจึงเป็นอีกทางเลือกหนึ่ง

โดยโมเดลประเภทต้นไม้อย่าง Decision tree นั้นจะถือเป็นโมเดลขั้นพื้นฐานที่สามารถเข้าใจได้ง่าย แต่มีข้อเสียคือในขั้นตอนการเรียนรู้ โมเดลอาจให้ประสิทธิภาพที่ดี แต่โมเดลกลับให้ประสิทธิภาพที่แย่งเมื่อเจอกับชุดข้อมูลทดสอบประสิทธิภาพที่ไม่เคยเรียนรู้มาก่อน ซึ่งเกิดจากการที่โมเดลไม่ได้เรียนรู้จากคุณลักษณะที่ใส่เข้าไป แต่กลับใช้วิธีจำคำตอบไปตอบแทน (Overfitting) อีกทั้งตัวโมเดลประกอบด้วยค่าพารามิเตอร์ที่ต้องปรับให้เหมาะสมสำหรับการเรียนรู้ครั้งนั้น ๆ จำนวนมาก เพื่อให้ได้ประสิทธิภาพที่ดีที่สุด ผู้วิจัยอาจต้องให้ค่าถึงประเด็นเหล่านี้ร่วมด้วย อย่างไรก็ตาม อีกหนึ่งโมเดลประเภทต้นไม้ที่สามารถคาดหวังประสิทธิภาพที่ดีได้คือ Random forest อีกทั้งยังเป็นโมเดลที่เหมาะสมสำหรับการศึกษาที่ประกอบด้วยคุณลักษณะหลายคุณลักษณะที่แตกต่างกัน และมีโอกาสรับมือกับปัญหา Overfitting ได้ดีกว่า Decision tree แต่ผลลัพธ์ที่น่าพึงพอใจเหล่านี้ มีสาเหตุมาจากการที่โมเดลมีความซับซ้อนมากขึ้นและอาจทำความเข้าใจได้ยากขึ้น ส่วนโมเดลประเภทแบ่งกลุ่มที่ยังคงคาดหวังผลลัพธ์ที่ดีได้เช่นกันคือ SVM ซึ่งเหมาะกับการศึกษาที่ประกอบด้วยหลายคุณลักษณะเช่นกัน แต่ต้องระมัดระวังเรื่องข้อมูลที่มีหน่วยแตกต่างกันมาก ๆ เพราะอาจทำให้โมเดลเรียนรู้ได้แย่งได้ และหากข้อมูลไม่ได้กระจายตัวในลักษณะที่เหมาะสม การปรับค่าพารามิเตอร์ที่ใช้ในการเรียนรู้ของโมเดล SVM ก็จะเป็นข้อที่ต้องคำนึงเช่นกัน แต่หากเป้าหมายของผู้วิจัยคือการสร้างโมเดลที่เน้นความถูกต้องหรือความแม่นยำ โดยไม่ได้เน้นวิเคราะห์ว่าโมเดลมีการตัดสินใจอย่างไร ผนวกกับทางผู้วิจัยมีชุดข้อมูลตั้งต้นขนาดใหญ่มาเพียงพอ โมเดลประเภทการเรียนรู้เชิงลึกคือโมเดลที่เหมาะสมกับงานลักษณะนี้ โดยเฉพาะโมเดลโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network: RNN) เป็นโมเดลที่ทำนายข้อมูลประเภทสัญญาณซึ่งมีลักษณะเป็นลำดับ (Sequential data) ได้ดี คาดว่าการใช้โมเดลดังกล่าวในหัวข้อการศึกษานี้จะได้รับความนิยมเพิ่มมากขึ้นในอนาคต ส่วนโมเดลที่เรียนรู้แบบไม่มีผู้สอนนั้นจะเหมาะสำหรับงานที่ต้องการค้นหาคุณลักษณะใหม่ๆ ที่สามารถบ่งชี้ Sleep spindle นอกเหนือจากคุณลักษณะที่มักนิยมใช้กัน

สุดท้ายคือการวัดค่าประสิทธิภาพของโมเดล ซึ่งสามารถเลือกประเมินได้หลายวิธี แม้ในการประเมินโดยภาพรวมมักจะใช้ความแม่นยำเป็นหลัก แต่หากผู้วิจัยมีจุดประสงค์ที่ต่างกันออกไป การประเมินที่ใช้ก็ควรจะแตกต่างกัน จากค่าประสิทธิภาพในตารางที่ 1 แสดงให้เห็นว่า โมเดลสามารถตรวจจับ Sleep spindle ได้เทียบเท่ากับผู้เชี่ยวชาญในระดับหนึ่ง โดยเฉพาะโมเดลในกลุ่มเรียนรู้แบบมีผู้สอน จะให้ค่าความแม่นยำ 90% ขึ้นไป ซึ่งมีความเป็นไปได้ที่จะนำโมเดลเหล่านี้ไปพัฒนาให้มีความแม่นยำมากขึ้นและนำไปใช้เพื่อประโยชน์ทางการแพทย์ต่อไป และในบางครั้ง การประเมินผลเปรียบเทียบว่าโมเดลหนึ่งได้ค่าดังกล่าวน้อยกว่าอีกโมเดลหนึ่งเล็กน้อยไม่ได้หมายความว่าโมเดลมีประสิทธิภาพต่ำกว่าเสมอไป เนื่องจากการประเมินเหล่านี้คือการเปรียบเทียบกับ การประเมินของผู้เชี่ยวชาญ ดังเช่นใน Kulkarni *et al.*³⁰ พบว่าค่าประสิทธิภาพที่ลดลง เหตุผลหนึ่งคือมีผลมาจากการที่โมเดลสามารถตรวจจับ Sleep spindle ในส่วนที่ผู้เชี่ยวชาญได้ทำการประเมินพลาดไป ซึ่งประเด็นเหล่านี้จะเป็นอีกทางเลือกในการวิเคราะห์ร่วมกับการพิจารณาของผู้เชี่ยวชาญในการตรวจจับ Sleep spindle ได้ อย่างไรก็ตาม ผลลัพธ์ที่โมเดลทำนายผิดไปว่าเป็น Sleep spindle อาจมีจำนวนมากกว่าผลลัพธ์ Sleep spindle ทั้งหมดที่ผู้เชี่ยวชาญระบุไว้²⁷

วิธีการที่ให้ผลลัพธ์ที่ดีที่สุดในการตรวจจับและแยกความแตกต่างของ Sleep spindle กับ EEG ขึ้นอยู่กับจุดประสงค์และความรู้ความเข้าใจพื้นฐานของผู้ใช้งานว่าต้องการศึกษาเน้นที่ผลลัพธ์ในการทำนายหรือเน้นศึกษาในลักษณะที่สามารถช่วยในการแบ่งแยก Sleep spindle ได้ ซึ่งการนำการเรียนรู้ของเครื่องมาใช้ในการพัฒนาความสามารถการตรวจจับ Sleep spindle ให้เทียบเท่ากับผู้เชี่ยวชาญในระยะเวลาที่สั้นลงอาจสามารถนำไปใช้ในการสนับสนุนการตัดสินใจของผู้เชี่ยวชาญ เพื่อสนับสนุนและเพิ่มคุณภาพในการวินิจฉัยโรคให้กับผู้ป่วยได้ต่อไปในอนาคต

กิตติกรรมประกาศ (Acknowledgements)

คณะผู้เขียนบทความ ขอขอบคุณหลักสูตรวิทยาศาสตรบัณฑิต สาขาวิชาวิทยาศาสตร์ข้อมูลสุขภาพ หลักสูตรร่วมระหว่างวิทยาลัยแพทยศาสตร์ศรีสวางควัฒนราชวิทยาลัยจุฬาภรณ์ และคณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ในการสนับสนุนการเขียนและตีพิมพ์บทความวิชาการฉบับนี้จนสำเร็จลุล่วงไปได้ด้วยดี

เอกสารอ้างอิง

1. What are Sleep Deprivation and Deficiency? [Internet]. NHLBI, NIH. [cited 2022 Nov 11].

- Available from: <https://www.nhlbi.nih.gov/health-topics/sleep-deprivation-and-deficiency>
2. Memar P, Faradji F. A Novel Multi-Class EEG-Based Sleep Stage Classification System. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2018;26(1):84-95. doi:10.1109/TNSRE.2017.2776149
 3. In Recognition of World Sleep Day, Philips Presents Its Annual Global Sleep Survey Results [Internet]. Philips. 2019 [cited 2022 Nov 11]. Available from: <https://www.philips.com/a-w/about/news/archive/standard/news/press/2019/20190307-in-recognition-of-world-sleep-day-philips-presents-its-annual-global-sleep-survey-results.html>
 4. Klem GH, Lüders HO, Jasper HH, Elger C. The Ten-twenty Electrode System of the International Federation. The International Federation of Clinical Neurophysiology. *Electroencephalogr Clin Neurophysiol Suppl*. 1999;52:3-6.
 5. Born J, Wilhelm I. System consolidation of memory during sleep. *Psychological Research*. 2012;76(2):192-203. doi:10.1007/s00426-011-0335-6
 6. Astori S, Wimmer RD, Lüthi A. Manipulating sleep spindles – expanding views on sleep, memory, and disease. *Trends in Neurosciences*. 2013;36(12):738-748. doi:10.1016/j.tins.2013.10.001
 7. Gorgoni M, Lauri G, Truglia I, et al. Parietal Fast Sleep Spindle Density Decrease in Alzheimer's Disease and Amnesic Mild Cognitive Impairment. *Neural Plasticity*. 2016;2016:e8376108. doi:10.1155/2016/8376108
 8. Iber C, Ancoli-Israel S, Chesson AL, Quan S. The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications. *Westchester, IL: American Academy of Sleep Medicine*. Published online January 1, 2007.
 9. Danker-Hopfe H, Kunz D, Gruber G, et al. Interrater reliability between scorers from eight European sleep laboratories in subjects with different sleep disorders. *Journal of Sleep Research*. 2004;13(1):63-69. doi:10.1046/j.1365-2869.2003.00375.x
 10. Wendt SL, Welinder P, Sorensen HBD, et al. Inter-expert and intra-expert reliability in sleep spindle scoring. *Clinical Neurophysiology*. 2015;126(8):1548-1556. doi:10.1016/j.clinph.2014.10.158
 11. Güneş S, Dursun M, Polat K, Yosunkaya Ş. Sleep spindles recognition system based on time and frequency domain features. *Expert Systems with Applications*. 2011;38(3):2455-2461. doi:10.1016/j.eswa.2010.08.034
 12. Loomis Alfred L., Harvey E. Newton, Hobart Garret. Potential Rhythms of the Cerebral Cortex During Sleep. *Science*. 1935;81(2111):597-598. doi:10.1126/science.81.2111.597
 13. De Gennaro L, Ferrara M. Sleep spindles: an overview. *Sleep Medicine Reviews*. 2003;7(5):423-440. doi:10.1053/smr.2002.0252
 14. Berry RB, Wagner MH. *Sleep Medicine Pearls E-Book*. Elsevier Health Sciences; 2014.
 15. Schönauer M, Pöhlchen D. Sleep spindles. *Current Biology*. 2018;28(19):R1129-R1130.
 16. Devuyst S, Dutoit T, Kerkhofs M. The DREAMS databases and assessment algorithm. *Zenodo, Genève*. Published online 2005.
 17. Purcell SM, Manoach DS, Demanuele C, et al. Characterizing sleep spindles in 11,630 individuals from the National Sleep Research Resource. *Nature Communications*. 2017;8(1):15930. doi:10.1038/ncomms15930
 18. Sitnikova E, Grubov V, Hramov AE. Slow-wave activity preceding the onset of 10–15-Hz sleep spindles and 5–9-Hz oscillations in electroencephalograms in rats with and without absence seizures. *Journal of Sleep Research*. 2020;29(6):e12927. doi:10.1111/jsr.12927
 19. Keenan S, Hirshkowitz M. Chapter 161- Sleep Stage Scoring. In: Kryger M, Roth T, Dement WC, eds. *Principles and Practice of Sleep Medicine (Sixth Edition)*. Elsevier; 2017:1567-1575. e3. doi:10.1016/B978-0-323-24288-2.00161-6
 20. Koubeissi MZ. Niedermeyer's Electroencephalography, Basic Principles, Clinical Applications, and Related Fields, 6th ed. *Archives of Neurology*. 2011;68(11):1481-1481. doi:10.1001/archneurol.2011.251

21. Warby SC, Wendt SL, Welinder P, et al. Sleep-spindle detection: crowdsourcing and evaluating performance of experts, non-experts and automated methods. *Nature Methods*. 2014;11(4):385-392. doi:10.1038/nmeth.2855
22. Werth E, Achermann P, Dijk DJ, Borbély AA. Spindle frequency activity in the sleep EEG: individual differences and topographical distribution. *Electroencephalography and Clinical Neurophysiology*. 1997;103(5):535-542. doi:10.1016/S0013-4694(97)00070-9
23. Coppieters 't Wallant D, Maquet P, Phillips C. Sleep Spindles as an Electrographic Element: Description and Automatic Detection Methods. Timofeev I, ed. *Neural Plasticity*. 2016; 2016:6783812. doi:10.1155/2016/6783812
24. Parekh A, Selesnick IW, Osorio RS, Varga AW, Rapoport DM, Ayappa I. Multichannel sleep-spindle detection using sparse low-rank optimization. *Journal of Neuroscience Methods*. 2017;288:1-16. doi:10.1016/j.jneumeth.2017.06.004
25. Nonclercq A, Urbain C, Verheulpen D, De-caestecker C, Van Bogaert P, Peigneux P. Sleep spindle detection through amplitude-frequency normal modelling. *Journal of Neuroscience Methods*. 2013;214(2):192-203. doi:10.1016/j.jneumeth.2013.01.015
26. LaRocco J, Franaszczuk PJ, Kerick S, Robbins K. Spindler: a framework for parametric analysis and detection of spindles in EEG with application to sleep spindles. *Journal of Neural Engineering*. 2018;15(6):066015. doi:10.1088/1741-2552/aadc1c
27. Patti CR, Penzel T, Cvetkovic D. Sleep spindle detection using multivariate Gaussian mixture models. *Journal of Sleep Research*. 2018; 27(4):e12614. doi:10.1111/jsr.12614
28. Mei N, Grossberg MD, Ng K, Navarro KT, Ellmore TM. Identifying sleep spindles with multichannel EEG and classification optimization. *Computers in Biology and Medicine*. 2017;89:441-453. doi:10.1016/j.combiomed.2017.08.030
29. O'Reilly C, Gosselin N, Carrier J, Nielsen T. Montreal Archive of Sleep Studies: an open-access resource for instrument benchmarking and exploratory research. *Journal of Sleep Research*. 2014;23(6):628-635. doi: 10.1111/jsr.12169
30. Kulkarni PM, Xiao Z, Robinson EJ, et al. A deep learning approach for real-time detection of sleep spindles. *Journal of Neural Engineering*. 2019;16(3):036004. doi:10.1088/1741-2552/ab0933
31. T. Penzel, M. Glos, C. Garcia, C. Schoebel, I. Fietze. The SIESTA database and the SIESTA sleep analyzer. In: 2011 *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. ; 2011:8323-8326. doi:10.1109/IEMBS.2011.6092052
32. Adamczyk M, Genzel L, Dresler M, Steiger A, Friess E. Automatic Sleep Spindle Detection and Genetic Influence Estimation Using Continuous Wavelet Transform. *Frontiers in Human Neuroscience*. 2015;9. <https://www.frontiersin.org/article/10.3389/fn-hum.2015.00624>
33. Peppard PE, Young T, Barnet JH, Palta M, Hagen EW, Hla KM. Increased Prevalence of Sleep-Disordered Breathing in Adults. *American Journal of Epidemiology*. 2013; 177(9):1006-1014. doi:10.1093/aje/kws342
34. Lacourse K, Delfrate J, Beaudry J, Peppard P, Warby SC. A sleep spindle detection algorithm that emulates human expert spindle scoring. *Journal of Neuroscience Methods*. 2019;316:3-11. doi:10.1016/j.jneumeth.2018.08.014
35. Duman F, Erdamar A, Eroglu O, Telatar Z, Yetkin S. Efficient sleep spindle detection algorithm with decision tree. *Expert Systems with Applications*. 2009;36(6):9980-9985. doi:10.1016/j.eswa.2009.01.061
36. Huupponen E, Gómez-Herrero G, Saastamoinen A, Värri A, Hasan J, Himanen SL. Development and comparison of four sleep spindle detection methods. *Artificial Intelligence in Medicine*. 2007;40(3):157-170. doi:10.1016/j.artmed.2007.04.003
37. B. Babadi, S. M. McKinney, V. Tarokh, J. M. Ellenbogen. DiBa: A Data-Driven Bayesian Algorithm for Sleep Spindle Detection. *IEEE Transactions on Biomedical Engineering*.

2012;59(2):483-493.doi:10.1109/TBME.2011.2175225

38. T. Shimada, T. Shiina, Y. Saito. Detection of characteristic waves of sleep EEG by neural network analysis. *IEEE Transactions on Bio-medical Engineering*. 2000;47(3):369-379. doi:10.1109/10.827301
39. Darien, IL. Standard polysomnography. *American Association of Sleep Technologists*. 2012.
40. L. Wei, S. Ventura, M. Lowery, et al. Random Forest-based Algorithm for Sleep Spindle Detection in Infant EEG. In: *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. ; 2020:58-61. doi:10.1109/EMBC44109.2020.9176339
41. Görür D, Halici U, Aydin H, Ongun G, Ozgen F, Leblebicioglu K. Sleep spindles detection using autoregressive modeling. In: ; 2003: 26-29.
42. Jung T-P, Makeig S, Humphries C, Lee T-W, McKeown MJ, Iragui V, et al. Removing Electroencephalographic Artifacts by Blind Source Separation. *Psychophysiology*. 2000; 37(2):163-78.
43. Jung TP, Makeig S, Westerfield M, Townsend J, Courchesne E, Sejnowski TJ. Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. *Clin Neurophysiol*. 2000;111(10): 1745-1758.doi:10.1016/s1388-2457(00)00386-2
44. Danasingh AAGS, Subramanian A alias B, Epiphany JL. Identifying redundant features using unsupervised learning for high-dimensional data. *SN Applied Sciences*. 2020;2(8):1367.doi:10.1007/s42452-020-3157-6

สัญญาอนุญาต ไฟล์ข้อมูลเสริม และ ลิขสิทธิ์

บทความเผยแพร่ในรูปแบบของบทความแบบเปิดและสามารถเข้าถึงได้อย่างเสรี (open-access) ภายใต้เงื่อนไขของสัญญาอนุญาตครีเอทีฟคอมมอนส์สากลในรูปแบบที่ต้องอ้างอิงแหล่งที่มา ห้ามใช้เพื่อการค้า และห้ามแก้ไขดัดแปลงเวอร์ชัน 4.0 (CC BY NC ND 4.0) ท่านสามารถแจกจ่ายและนำบทความไปใช้ประโยชน์เพื่อการศึกษาได้ แต่ต้องระบุการอ้างอิงถึงบทความนี้จากเว็บไซต์วารสารวิชาการราชวิทยาลัยจุฬาภรณ์ โดยการระบุข้อมูลบทความและลิงก์ URL บนเอกสารอ้างอิงของท่าน ท่านไม่สามารถนำบทความไปใช้เพื่อการพาณิชย์ใดๆ ได้เว้นแต่ได้รับอนุญาตจากบรรณาธิการวารสารวิชาการราชวิทยาลัยจุฬาภรณ์ และกรณีมีการนำบทความไปเรียบเรียงใหม่ เปลี่ยนแปลงเนื้อหา หรือเสริมเติมแต่งเนื้อหาของบทความนี้ ท่านไม่สามารถนำบทความที่ปรับแต่งไปเผยแพร่ได้ในทุกกรณี

หากมีวัสดุเอกสารข้อมูลวิจัยเสริมเพิ่มเติมใด ๆ ที่ใช้อ้างอิงในบทความท่านสามารถเข้าถึงได้บนหน้าเว็บไซต์ของวารสาร

บทความนี้เป็นลิขสิทธิ์ของราชวิทยาลัยจุฬาภรณ์ (Chulabhorn Royal Academy) พ.ศ.2566

การอ้างอิง

ชินานาง พรหมแก้ว, พรพนัช กิจอุดม, อีสริย์ สุวรรณสมบัติ, ธมลวรรณ ทองบุญ, แก้วเกล้า ถาวรวัฒนะ, สันติธรรม พรหมอ่อน และวรัณย์ หินทอง. การทบทวนวรรณกรรม: การตรวจจับคลื่นสมองประเภท Sleep spindles แบบอัตโนมัติ. *วารสารวิชาการราชวิทยาลัยจุฬาภรณ์*. 2566;5(1): 13-26. <https://he02.tci-thaijo.org/index.php/jcra/article/view/255126>

Promkaew S., Kitudom P., Suwansombat I., Thongbun T., Thavornwattana K., Prom-on S., Hinthong W. A Review on Automatic Detection Methods of Sleep Spindles. *J Chulabhorn Royal Acad*. 2023; 5(1): 13-26. <https://he02.tci-thaijo.org/index.php/jcra/article/view/255126>

Online Access

<https://he02.tci-thaijo.org/index.php/jcra/article/view/255126>

