

การพัฒนาระบบช่วยคัดกรองโรคอัลไซเมอร์ระยะเริ่มต้นจากภาพ MRI ด้วย Deep

Learning สำหรับบริบทระบบสาธารณสุขไทย

Development of a deep learning-based early Alzheimer's disease screening system using MRI for the Thai healthcare context

ธัญมัย แพงวงษ์ และ นัตตวุฒิ ศรีวิบูลย์*

Thanyamai Paengwong and Nattavut Sriwiboon *

phanyamai.pa@ksu.ac.th and nattavut.sr@ksu.ac.th *

สาขาวิชาเทคโนโลยีสารสนเทศทางการแพทย์ คณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ
มหาวิทยาลัยกาฬสินธุ์

Department of Medical Information Technology, Faculty of Science and Health Technology,
Kalasin University

Received: March 19, 2026; Revised: June 17, 2026; Accepted: June 18, 2026; Published: June 30, 2026

ABSTRACT – Thailand's transition into an aging society has increased the prevalence of Alzheimer's disease, making early-stage screening essential for improving patient outcomes. This paper proposes a deep learning-based screening system for early detection of Alzheimer's disease using magnetic resonance imaging (MRI), tailored to the context of the Thai public healthcare system. A total of 6,400 MRI images has been used and classified into four categories: Non-Demented, Very Mild Demented, Mild Demented, and Moderate Demented. Data preprocessing and augmentation techniques have been applied to enhance model performance. Four models have been evaluated, including the proposed Custom CNN, MobileNetV2, ResNet50, and VGG16. The results show that the proposed Custom CNN achieves the highest accuracy of 97.12%, with strong generalization and stable training performance. The model has also effectively reduced misclassification in early-stage categories. The proposed system demonstrates strong potential as a practical screening tool for early Alzheimer's detection in Thailand, particularly in primary healthcare settings.

KEY WORDS -- Alzheimer's Disease, Deep Learning, Magnetic Resonance Imaging (MRI), Early Screening, Thai Healthcare System

บทคัดย่อ -- ประเทศไทยได้เข้าสู่สังคมผู้สูงอายุ ส่งผลให้จำนวนผู้ป่วยโรคอัลไซเมอร์เพิ่มขึ้นอย่างต่อเนื่อง การคัดกรองโรคในระยะเริ่มต้นจึงมีความสำคัญต่อการชะลอความรุนแรงของโรค งานวิจัยนี้นำเสนอระบบช่วยคัดกรองโรคอัลไซเมอร์ระยะเริ่มต้นโดยใช้เทคนิคการเรียนรู้เชิงลึกจากภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (MRI) ซึ่งออกแบบให้เหมาะสมกับบริบทของระบบสาธารณสุขไทย งานวิจัยนี้ได้ใช้ชุดข้อมูลภาพ MRI จำนวน 6,400 ภาพ โดยแบ่งออกเป็น 4 ระดับ ได้แก่ กลุ่มปกติ กลุ่มระยะเริ่มต้นเล็กน้อย กลุ่มระยะเริ่มต้น และกลุ่มระยะปานกลาง โดยมีการเตรียมข้อมูลด้วยเทคนิคการปรับขนาดภาพ การปรับค่ามาตรฐาน และการเพิ่มข้อมูล เพื่อเพิ่มประสิทธิภาพของโมเดล จากนั้นได้ทำการเปรียบเทียบโมเดลจำนวน 4 โมเดล ได้แก่ Custom CNN ที่เสนอ, MobileNetV2, ResNet50 และ VGG16 ผลการทดลองแสดงให้เห็นว่าโมเดล Custom CNN ที่เสนอให้ความแม่นยำสูงสุดที่ 97.12% มีความสามารถในการเรียนรู้ที่มีเสถียรภาพ และลดความสับสนในการจำแนกระยะเริ่มต้นของโรคได้อย่างมีประสิทธิภาพ ระบบที่พัฒนาขึ้นมีศักยภาพในการนำไปใช้เป็นเครื่องมือช่วยคัดกรองโรคอัลไซเมอร์ในระยะเริ่มต้น โดยเฉพาะในระดับบริการสาธารณสุขปฐมภูมิของประเทศไทย

คำสำคัญ – โรคอัลไซเมอร์, การเรียนรู้เชิงลึก, ภาพ MRI, การคัดกรองระยะเริ่มต้น, ระบบสาธารณสุขไทย

1. บทนำ

ประเทศไทยได้เข้าสู่สังคมผู้สูงอายุอย่างสมบูรณ์ ซึ่งส่งผลให้จำนวนผู้ป่วยโรคไม่ติดต่อเรื้อรังเพิ่มขึ้นอย่างต่อเนื่อง [1] โดยเฉพาะ โรคอัลไซเมอร์ซึ่งเป็นโรคทางระบบประสาทที่ส่งผลกระทบต่อความจำ ความคิด และพฤติกรรมของผู้ป่วย โรคดังกล่าวไม่เพียงส่งผลกระทบต่อคุณภาพชีวิตของผู้ป่วยเท่านั้น แต่ยังสร้างภาระให้กับครอบครัวและระบบสาธารณสุขโดยรวมอย่างมีนัยสำคัญ ดังนั้น การคัดกรองและวินิจฉัยโรคในระยะเริ่มต้นจึงมีความสำคัญอย่างยิ่งในการชะลอการดำเนินของโรคและเพิ่มโอกาสในการดูแลรักษาอย่างมีประสิทธิภาพ

ในปัจจุบัน การวินิจฉัยโรคอัลไซเมอร์มักอาศัยการประเมินทางคลินิก ร่วมกับการใช้ภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (Magnetic Resonance Imaging: MRI) [2-6] ซึ่งสามารถแสดงโครงสร้างสมองและความผิดปกติที่เกี่ยวข้องกับโรคได้ อย่างไรก็ตาม การวิเคราะห์ภาพ MRI จำเป็นต้องอาศัยผู้เชี่ยวชาญเฉพาะทาง เช่น แพทย์รังสีวิทยา ซึ่งยังมีจำนวนจำกัด โดยเฉพาะในพื้นที่ชนบทหรือโรงพยาบาลระดับปฐมภูมิในประเทศไทย ส่งผลให้การเข้าถึงบริการวินิจฉัยที่มีคุณภาพยังคงมีข้อจำกัด

ในช่วงไม่กี่ปีที่ผ่านมา เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) [7] โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) [8, 9] ได้ถูกนำมาใช้ในการวิเคราะห์ภาพทางการแพทย์อย่างแพร่หลาย และสามารถให้ผลลัพธ์ที่มีความแม่นยำสูงในการจำแนกโรคจากภาพ MRI อย่างไรก็ตาม งานวิจัยส่วนใหญ่ยังมุ่งเน้นไปที่การพัฒนาโมเดลที่มีความซับซ้อนสูง [10, 11] หรือใช้เทคนิคขั้นสูง เช่น ensemble learning และ multi-dataset ซึ่งอาจไม่เหมาะสมต่อการนำไปใช้งานจริงในบริบทของระบบสาธารณสุขที่มีข้อจำกัดด้านทรัพยากร

นอกจากนี้ การจำแนกระยะเริ่มต้นของโรคอัลไซเมอร์ยังคงเป็นความท้าทายสำคัญ เนื่องจากลักษณะของภาพในแต่ละระดับมีความแตกต่างเพียงเล็กน้อย โดยเฉพาะระหว่างกลุ่ม Very Mild Demented และ Mild Demented ซึ่งอาจทำให้เกิดความสับสนในการจำแนกได้ง่าย

ด้วยเหตุนี้ งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนา ระบบช่วยคัดกรองโรคอัลไซเมอร์ระยะเริ่มต้นจากภาพ MRI โดยใช้เทคนิค Deep Learning ที่มีความแม่นยำสูง และมีโครงสร้างที่

เหมาะสมต่อการนำไปใช้งานจริงในระบบสาธารณสุขไทย โดยได้ทำการออกแบบโมเดล Custom CNN และเปรียบเทียบกับโมเดลมาตรฐาน ได้แก่ MobileNetV2 [12], ResNet50 [13] และ VGG16 [14] เพื่อประเมินประสิทธิภาพในการจำแนกโรคแบบหลายคลาส

ผลลัพธ์จากงานวิจัยนี้คาดว่าจะสามารถสนับสนุนการพัฒนาเครื่องมือช่วยคัดกรองโรคอัลไซเมอร์ในระดับปฐมภูมิ และช่วยลดภาระของบุคลากรทางการแพทย์ รวมถึงเพิ่มโอกาสในการเข้าถึงการวินิจฉัยโรคในระยะเริ่มต้นได้อย่างมีประสิทธิภาพ


2. วัสดุ อุปกรณ์ และวิธีการ

2.1 ชุดข้อมูล (Dataset)

การศึกษานี้ ได้ใช้ชุดข้อมูล Alzheimer's Disease Multiclass Images Dataset ซึ่งเป็นชุดข้อมูลสาธารณะที่ได้รับการเผยแพร่ผ่านแพลตฟอร์ม Kaggle [15] โดยชุดข้อมูลดังกล่าวประกอบด้วยภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (MRI) ที่ใช้สำหรับการจำแนกระดับความรุนแรงของโรคอัลไซเมอร์

ชุดข้อมูลนี้ประกอบด้วยภาพทั้งหมดจำนวน 6,400 ภาพ โดยแบ่งออกเป็น 4 ระดับของโรค ได้แก่ กลุ่มที่ไม่เป็นโรค (Non-Demented) จำนวน 3,200 ภาพ กลุ่มที่มีอาการระยะเริ่มต้นเล็กน้อย (Very Mild Demented) จำนวน 2,240 ภาพ กลุ่มที่มีอาการระดับเล็กน้อย (Mild Demented) จำนวน 896 ภาพ และกลุ่มที่มีอาการระดับปานกลาง (Moderate Demented) จำนวน 64 ภาพ

อย่างไรก็ตาม จากการพิจารณาการกระจายของข้อมูล พบว่าชุดข้อมูลมีลักษณะไม่สมดุล (data imbalance) อย่างชัดเจน โดยเฉพาะในกลุ่ม Moderate Demented ซึ่งมีจำนวนข้อมูลน้อยเมื่อเปรียบเทียบกับกลุ่มอื่น ๆ ปัญหาดังกล่าวอาจส่งผลกระทบต่อประสิทธิภาพของโมเดลในการเรียนรู้และการจำแนกประเภทของข้อมูลในบางกลุ่ม



รูปที่ 1. ตัวอย่างภาพ MRI จากชุดข้อมูล Alzheimer's Disease Multiclass Images Dataset ประกอบด้วย (a) Non-Demented (b) Very Mild Demented (c) Mild Demented และ (d) Moderate Demented ซึ่งแสดงระดับความรุนแรงของโรคอัลไซเมอร์ที่แตกต่างกัน

ดังแสดงในรูปที่ 1 ภาพ MRI ในแต่ละรูปย่อยแสดงระดับความรุนแรงของโรคอัลไซเมอร์ที่แตกต่างกัน โดย (a) Non-Demented แสดงลักษณะ โครงสร้างสมองปกติที่ไม่พบภาวะสมองเสื่อม (b) Very Mild Demented แสดงการเปลี่ยนแปลงของเนื้อสมองในระยะเริ่มต้นเล็กน้อย (c) Mild Demented แสดงการลดลงของปริมาตรเนื้อสมองและการเปลี่ยนแปลงของโครงสร้างสมองที่ชัดเจนมากขึ้น และ (d) Moderate Demented แสดงลักษณะการฝ่อของสมองและการขยายตัวของโพรงสมองอย่างเด่นชัด ซึ่งสะท้อนถึงความรุนแรงของโรคที่เพิ่มขึ้นตามลำดับ ภาพตัวอย่างดังกล่าวช่วยให้เห็นความแตกต่างของลักษณะทางกายวิภาคของสมองในแต่ละระยะ และเป็นข้อมูลสำคัญสำหรับการเรียนรู้ของโมเดล Deep Learning ในการจำแนกระดับของโรคอัลไซเมอร์

ดังนั้น ในการศึกษาครั้งนี้จึงได้พิจารณาแนวทางในการจัดการปัญหาความไม่สมดุลของข้อมูลร่วมกับขั้นตอนการเตรียมข้อมูล เพื่อเพิ่มความสามารถของโมเดลในการเรียนรู้ลักษณะของข้อมูลในทุกกระดับของโรคอัลไซเมอร์ได้อย่างมีประสิทธิภาพ

2.2 การเตรียมข้อมูล (Data Preprocessing)

ในการศึกษานี้ ได้ดำเนินการเตรียมข้อมูลภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (MRI) เพื่อให้เหมาะสมต่อการฝึก


โมเดล Deep Learning โดยกระบวนการเตรียมข้อมูลประกอบด้วยหลายขั้นตอน ได้แก่ การปรับขนาดภาพ การปรับค่าความเข้มของพิกเซล และการเพิ่มข้อมูล เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของโมเดล

ในขั้นตอนแรก ภาพ MRI ทั้งหมดได้ถูกปรับขนาด (image resizing) ให้มีขนาดเท่ากันที่ 224×224 พิกเซล ซึ่งเป็นขนาดมาตรฐานที่เหมาะสมสำหรับโมเดลที่ใช้เทคนิค Transfer Learning เช่น MobileNetV2, ResNet50 และ VGG16 ทั้งนี้เพื่อให้สามารถป้อนข้อมูลเข้าสู่โมเดลได้อย่างมีประสิทธิภาพ

ถัดมา ได้ดำเนินการปรับค่าพิกเซล (normalization) โดยการแปลงค่าความเข้มของพิกเซลให้อยู่ในช่วงระหว่าง 0 ถึง 1 ด้วยการหารค่าพิกเซลด้วย 255 ซึ่งช่วยให้โมเดลสามารถเรียนรู้ได้รวดเร็วและลดความแปรปรวนของข้อมูล

นอกจากนี้ ได้ใช้เทคนิคการเพิ่มข้อมูล (data augmentation) เพื่อเพิ่มความหลากหลายของชุดข้อมูล และลดปัญหาความไม่สมดุลของข้อมูล (data imbalance) โดยวิธีที่ใช้ประกอบด้วยการหมุนภาพ (rotation) การพลิกภาพ (horizontal flipping) และการซูมภาพ (zooming) ซึ่งช่วยให้โมเดลสามารถเรียนรู้ลักษณะของข้อมูลจากหลายมุมมอง

สุดท้าย ชุดข้อมูลได้ถูกแบ่งออกเป็นชุดฝึก (training set) ชุดตรวจสอบความถูกต้อง (validation set) และชุดทดสอบ (test set) ตามสัดส่วนที่เหมาะสม เพื่อใช้ในการฝึกโมเดลและประเมินประสิทธิภาพของโมเดลในขั้นตอนสุดท้าย



รูปที่ 2. กระบวนการเตรียมข้อมูลจากภาพ MRI ต้นฉบับที่ใช้ในงานวิจัยนี้ แสดงขั้นตอนการปรับขนาดภาพ (224×224 พิกเซล) การปรับค่ามาตรฐาน (0-1) และการเพิ่มข้อมูล (การพลิกภาพและการหมุนภาพ) ก่อนนำไปฝึกโมเดล Deep Learning

ดังแสดงในรูปที่ 2 กระบวนการเตรียมข้อมูลเริ่มต้นจากภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (MRI) ต้นฉบับ ซึ่งถูกนำมาประมวลผลผ่านหลายขั้นตอนเพื่อให้เหมาะสมต่อการฝึกโมเดล Deep Learning โดยในขั้นตอนแรก ภาพต้นฉบับจะถูก

ปรับขนาด (resizing) ให้มีขนาด 224×224 พิกเซล เพื่อให้สอดคล้องกับโครงสร้างของโมเดลที่ใช้ในการศึกษา จากนั้นจะมีการปรับค่าความเข้มของพิกเซล (normalization) ให้อยู่ในช่วง 0 ถึง 1 เพื่อลดความแปรปรวนของข้อมูลและเพิ่มเสถียรภาพในการเรียนรู้ของโมเดล


นอกจากนี้ ยังได้มีการใช้เทคนิคการเพิ่มข้อมูล (data augmentation) เช่น การพลิกภาพ (flipping) และการหมุนภาพ (rotation) เพื่อเพิ่มความหลากหลายของข้อมูลและช่วยลดปัญหาความไม่สมดุลของชุดข้อมูล (data imbalance) ซึ่งส่งผลให้โมเดลสามารถเรียนรู้ลักษณะของข้อมูลได้ครอบคลุมมากยิ่งขึ้น โดยชุดข้อมูลได้ถูกแบ่งออกเป็น 3 ส่วน ได้แก่ ชุดฝึก (Training Set) จำนวน 64% ชุดตรวจสอบความถูกต้อง (Validation Set) จำนวน 16% และชุดทดสอบ (Test Set) จำนวน 20% ของข้อมูลทั้งหมด โดยไม่มีการซ้ำกันของข้อมูลระหว่างแต่ละชุด เพื่อป้องกันปัญหาข้อมูลรั่วไหล (Data Leakage) และเพื่อให้การประเมินประสิทธิภาพของโมเดลมีความน่าเชื่อถือมากยิ่งขึ้น กระบวนการทั้งหมดนี้มีบทบาทสำคัญในการเตรียม

ข้อมูลให้มีคุณภาพและเหมาะสมสำหรับการนำไปใช้ในการฝึกโมเดลในขั้นตอนถัดไป

2.3 โมเดลที่ใช้ในการศึกษา (Model Architecture)

งานวิจัยนี้ได้ทำการพัฒนาและประเมินประสิทธิภาพของโมเดล Deep Learning สำหรับการจำแนกระดับของโรคอัลไซเมอร์จากภาพ MRI โดยแบ่งโมเดลออกเป็น 2 กลุ่ม ได้แก่ โมเดลที่พัฒนาขึ้น (Proposed Model) และ โมเดลพื้นฐาน (baseline models) เพื่อใช้ในการเปรียบเทียบผลลัพท์อย่างเป็นระบบ

โมเดล Custom Convolutional Neural Network (CNN) ได้ถูกออกแบบและพัฒนาขึ้นในงานวิจัยนี้เพื่อใช้เป็นโมเดลหลักในการเรียนรู้ลักษณะของข้อมูลภาพ MRI ขณะที่ MobileNetV2, ResNet50 และ VGG16 ดังแสดงในรูปที่ 3 ซึ่งเป็นโมเดลที่ได้รับการยอมรับในงานวิเคราะห์ภาพ ได้ถูกนำมาใช้เป็น baseline models เพื่อประเมินและเปรียบเทียบประสิทธิภาพของโมเดลที่พัฒนาขึ้น



รูปที่ 3. โครงสร้างโมเดลการเรียนรู้เชิงลึกที่ใช้ในงานวิจัยนี้ ได้แก่ (a) Custom CNN ที่เสนอ (b) MobileNetV2 (c) ResNet50 และ (d) VGG16 โดยแสดงกระบวนการสกัดคุณลักษณะและการจำแนกผลสำหรับการจำแนกโรคอัลไซเมอร์จากภาพ MRI

ตารางที่ 1. โครงสร้างสถาปัตยกรรมและรายละเอียดของเลเยอร์ใน โมเดล Custom CNN ที่เสนอ

Layer	Output Size	Kernel/Stride	Activation	Parameters
-------	-------------	---------------	------------	------------

Input	224×224×3	–	–	–
Conv2D-1	224×224×32	3×3 / 1	ReLU	896
MaxPooling-1	112×112×32	2×2 / 2	–	0
Conv2D-2	112×112×64	3×3 / 1	ReLU	18,496
MaxPooling-2	56×56×64	2×2 / 2	–	0
Conv2D-3	56×56×128	3×3 / 1	ReLU	73,856
MaxPooling-3	28×28×128	2×2 / 2	–	0
Flatten	100,352	–	–	0
Dense-1	128	–	ReLU	12,845,184
Dropout	128	–	–	0
Output	4	–	Softmax	516
Total Parameters				12,938,948 (~12.94M)

2.3.1 โมเดล Custom CNN ที่พัฒนาขึ้นในงานวิจัยนี้

โมเดล Custom CNN ที่พัฒนาขึ้นในงานวิจัยนี้ประกอบด้วย ชั้น Convolutional หลายระดับพร้อมกับฟังก์ชันกระตุ้น ReLU และชั้น Max Pooling เพื่อสกัดคุณลักษณะเชิงพื้นที่ของภาพ MRI อย่างมีประสิทธิภาพ จากนั้นข้อมูลจะถูกส่งต่อไปยังชั้น Fully Connected เพื่อทำการจำแนกออกเป็น 4 คลาส ได้แก่ Non-Demented, Very Mild Demented, Mild Demented และ Moderate Demented นอกจากนี้ ได้มีการใช้เทคนิค Dropout เพื่อลดปัญหา overfitting และเพิ่มความสามารถในการ generalization ของโมเดล โดยได้กำหนดค่า Dropout Rate เท่ากับ 0.5 ซึ่งหมายถึงการสุ่มปิดการทำงานของนิวรอนร้อยละ 50 ในระหว่างกระบวนการฝึก เพื่อช่วยลดปัญหา overfitting และเพิ่มความสามารถในการ generalization ของโมเดล โมเดล นี้ถูกออกแบบให้มีความสมดุลระหว่างความแม่นยำและความซับซ้อนของโครงสร้าง ดังตารางที่ 1

โมเดล Custom CNN ที่พัฒนาขึ้นในงานวิจัยนี้ประกอบด้วย หลายชั้น (layers) ที่ทำงานร่วมกันเพื่อสกัดคุณลักษณะและ จำแนกภาพ MRI ดังนี้

- Input Layer: ชั้นรับข้อมูลทำหน้าที่รับภาพ MRI ที่ผ่านการปรับขนาดเป็น 224×224×3 โดยข้อมูลจะถูกส่งเข้าสู่เครือข่ายเพื่อทำการเรียนรู้คุณลักษณะเชิงพื้นที่ของภาพ
- Convolutional Layer 1: ชั้น Convolution แรกใช้ฟิลเตอร์ขนาด 3×3 จำนวน 32 ฟิลเตอร์ เพื่อสกัด

คุณลักษณะเบื้องต้น เช่น ขอบ (edges) และพื้นผิว (textures) ของภาพ โดยใช้ฟังก์ชันกระตุ้น ReLU เพื่อเพิ่มความไม่เป็นเชิงเส้นให้กับโมเดล

- Max Pooling Layer 1: ชั้น Max Pooling ขนาด 2×2 ถูกใช้เพื่อลดขนาดของ feature map ลงครึ่งหนึ่ง (224×224 → 112×112) ช่วยลด computational cost และลด overfitting
- Convolutional Layer 2: ชั้น Convolution ที่สองเพิ่มจำนวนฟิลเตอร์เป็น 64 เพื่อสกัดคุณลักษณะที่มีความซับซ้อนมากขึ้น เช่น รูปร่างของโครงสร้างสมอง โดยยังคงใช้ kernel ขนาด 3×3 และ ReLU activation
- Max Pooling Layer 2: ลดขนาด feature map จาก 112×112 เป็น 56×56 ซึ่งช่วยให้โมเดลสามารถโฟกัสที่คุณลักษณะที่สำคัญมากขึ้น
- Convolutional Layer 3: ชั้นนี้ใช้ฟิลเตอร์จำนวน 128 เพื่อสกัดคุณลักษณะระดับลึก (high-level features) เช่น รูปแบบความผิดปกติของเนื้อสมองที่เกี่ยวข้องกับโรคอัลไซเมอร์
- Max Pooling Layer 3: ลดขนาด feature map เหลือ 28×28 ซึ่งช่วยเพิ่มประสิทธิภาพในการประมวลผล และลดจำนวนพารามิเตอร์

- Flatten Layer: ทำหน้าที่แปลงข้อมูลจากรูปแบบ 2 มิติ (feature maps) ให้เป็นเวกเตอร์ 1 มิติ เพื่อเตรียมข้อมูลเข้าสู่ชั้น Fully Connected
- Fully Connected Layer (Dense Layer): ชั้น Dense จำนวน 128 neurons ทำหน้าที่รวมคุณลักษณะที่สกัดได้จาก convolutional layers เพื่อใช้ในการจำแนกข้อมูล
- Dropout Layer: ใช้ Dropout เพื่อลด overfitting โดยสุ่มปิดบาง neurons ในระหว่างการฝึก ทำให้โมเดลมีความสามารถในการ generalization มากขึ้น
- Output Layer: ชั้นสุดท้ายใช้ Softmax activation เพื่อจำแนกภาพออกเป็น 4 คลาส ได้แก่ Non-Demented, Very Mild Demented, Mild Demented และ Moderate Demented

โมเดล Custom CNN ที่พัฒนาขึ้นมีจำนวนพารามิเตอร์รวมทั้งสิ้น 12.94 ล้านพารามิเตอร์ ซึ่งทั้งหมดเป็นพารามิเตอร์ที่สามารถปรับค่าได้ (trainable parameters) โดยส่วนใหญ่ของพารามิเตอร์อยู่ในชั้น Fully Connected ซึ่งมีบทบาทสำคัญในการจำแนกข้อมูล อย่างไรก็ตาม จำนวนพารามิเตอร์ที่สูงในชั้นนี้อาจส่งผลต่อ computational cost และความเสี่ยงของ overfitting

2.3.2 แบบจำลองพื้นฐาน (Baseline Model)

MobileNetV2 เป็นโมเดลที่มีโครงสร้างแบบ lightweight ซึ่งใช้ inverted residual blocks และ depthwise separable convolution เพื่อลดจำนวนพารามิเตอร์และเพิ่มประสิทธิภาพในการประมวลผล โมเดลนี้ได้รับการฝึกเบื้องต้นจากชุดข้อมูล ImageNet และถูกนำมาปรับใช้กับงานนี้ผ่านเทคนิค Transfer Learning โดยมีการปรับชั้น Fully Connected ให้เหมาะสมกับการจำแนกข้อมูล 4 คลาส แม้ว่า MobileNetV2 จะมีข้อดีด้านความเบาและเหมาะสมกับการใช้งานในระบบจริง เช่น โรงพยาบาลระดับจังหวัดหรือระบบ edge device แต่ข้อจำกัดคือความสามารถในการเรียนรู้คุณลักษณะเชิงลึกอาจต่ำกว่าโมเดลขนาดใหญ่ ซึ่งอาจส่งผลต่อประสิทธิภาพในการจำแนกข้อมูลที่มีความซับซ้อนสูง

ResNet50 เป็นโมเดลเชิงลึกที่ใช้แนวคิด residual learning ผ่านการเชื่อมต่อแบบ skip connection ซึ่งช่วยลดปัญหา

vanishing gradient และทำให้สามารถเรียนรู้คุณลักษณะเชิงลึกของข้อมูลได้อย่างมีประสิทธิภาพ โมเดลนี้เหมาะสำหรับการวิเคราะห์ข้อมูลภาพทางการแพทย์ที่มีความซับซ้อนสูง และถูกนำมาใช้เป็น baseline ในการเปรียบเทียบประสิทธิภาพ แม้ว่า ResNet50 จะมีความสามารถในการสกัด feature เชิงลึกได้ดี แต่มีข้อจำกัดด้านจำนวนพารามิเตอร์และ computational cost ซึ่งอาจไม่เหมาะสมกับการ deploy ในระบบจริง ดังนั้นสามารถปรับปรุงได้โดย:

VGG16 เป็นโมเดลที่มีโครงสร้างแบบลำดับขั้น (sequential architecture) โดยใช้ convolutional layers ที่มีขนาดฟิลเตอร์เล็ก (3×3) หลายชั้นในการสกัดคุณลักษณะของภาพอย่างละเอียด โมเดลนี้มีความเสถียรและให้ผลลัพธ์ที่ดีในงานจำแนกภาพหลายประเภท และถูกนำมาใช้เป็น baseline model ในการศึกษาครั้งนี้ แม้ว่า VGG16 จะให้ผลลัพธ์ที่ดีในงานนี้ แต่มีข้อจำกัดด้านจำนวนพารามิเตอร์ที่สูงมาก

เพื่อประเมินประสิทธิภาพของโมเดลที่พัฒนาขึ้นและโมเดลพื้นฐานที่เลือกใช้ในงานวิจัยนี้ โมเดลทั้งหมด ได้แก่ Custom CNN, MobileNetV2, ResNet50 และ VGG16 ได้ถูกนำไปฝึกและทดสอบภายใต้เงื่อนไขเดียวกัน โดยใช้ชุดข้อมูลภาพ MRI ที่ได้เตรียมไว้ล่วงหน้า การเปรียบเทียบประสิทธิภาพของแต่ละโมเดลจะดำเนินการโดยใช้ตัวชี้วัดมาตรฐาน ได้แก่ Accuracy, Precision, Recall และ F1-score เพื่อวิเคราะห์ความสามารถในการจำแนกระดับของโรคอัลไซเมอร์ในแต่ละคลาส โดยเฉพาะในระยะเริ่มต้นซึ่งมีความสำคัญทางคลินิก รายละเอียดของขั้นตอนการฝึกโมเดล การตั้งค่าพารามิเตอร์ และผลการทดลองเชิงเปรียบเทียบจะถูกนำเสนอในส่วนถัดไป

3. ผลการวิจัย

3.1 การตั้งค่าพารามิเตอร์ของโมเดล (Parameter Setup)

ในการฝึกโมเดล Deep Learning ในงานวิจัยนี้ ได้มีการกำหนดค่าพารามิเตอร์อย่างเป็นระบบเพื่อให้โมเดลสามารถเรียนรู้ข้อมูลภาพ MRI ได้อย่างมีประสิทธิภาพ และเพื่อให้การเปรียบเทียบผลลัพธ์ระหว่างโมเดลมีความเป็นธรรม โมเดลทั้งหมด ได้แก่ Custom CNN, MobileNetV2, ResNet50 และ VGG16 ถูกฝึกภายใต้เงื่อนไขเดียวกัน รายละเอียดของพารามิเตอร์ที่ใช้ในการฝึกโมเดลแสดงดังในตารางที่ 2

ตารางที่ 2 รายละเอียดการตั้งค่าพารามิเตอร์ที่ใช้ในการฝึก
โมเดล Deep Learning

Parameter	Value
Optimizer	Adam
Learning Rate	0.0001
Batch Size	32
Epochs	50
Loss Function	Categorical Crossentropy
Activation Function	ReLU, Softmax
Early Stopping	Applied
Validation Split	0.2

ในงานวิจัยนี้ ได้เลือกใช้ตัวปรับค่า (optimizer) แบบ Adam เนื่องจากเป็นอัลกอริทึมที่รวมข้อดีของ Momentum และ RMSProp ซึ่งช่วยให้สามารถปรับค่าพารามิเตอร์ได้อย่างมีประสิทธิภาพในปัญหาที่มีข้อมูลซับซ้อน เช่น ภาพทางการแพทย์ โดยเฉพาะ MRI ซึ่งมีลักษณะข้อมูลที่ไม่เป็นเชิงเส้น

อัตราการเรียนรู้ (learning rate) ถูกกำหนดไว้ที่ 0.0001 เพื่อควบคุมความเร็วในการปรับค่าพารามิเตอร์ โดยค่าที่ต่ำช่วยลดความเสี่ยงของการ overshooting และทำให้โมเดลสามารถเรียนรู้ feature เชิงลึกได้อย่างละเอียดมากขึ้น ซึ่งมีความสำคัญต่อการตรวจจับความผิดปกติของสมองในระยะเริ่มต้น ขนาดของ batch size ถูกตั้งค่าเป็น 32 ซึ่งเป็นค่าที่เหมาะสมสำหรับการสร้างสมดุลระหว่างความเสถียรของ gradient และประสิทธิภาพในการประมวลผล โดย batch ขนาดเล็กช่วยเพิ่ม stochasticity ในการเรียนรู้ ส่งผลให้โมเดลสามารถหลีกเลี่ยง local minima ได้ดีขึ้น จำนวนรอบการฝึก (epochs) ถูกกำหนดไว้ที่ 50 รอบ เพื่อให้โมเดลมีเวลาเพียงพอในการเรียนรู้รูปแบบของข้อมูล ขณะเดียวกันมีการใช้ validation split เท่ากับ 0.2 เพื่อแบ่งข้อมูลบางส่วนสำหรับตรวจสอบประสิทธิภาพของโมเดลระหว่างการฝึก ฟังก์ชัน loss ที่ใช้คือ categorical crossentropy ซึ่งเหมาะสมกับปัญหาการจำแนกหลายคลาส (multi-class classification) โดยใช้ร่วมกับฟังก์ชัน Softmax ในชั้นเอาต์พุต เพื่อแปลงค่าผลลัพธ์ให้เป็นความน่าจะเป็นของแต่ละคลาส

นอกจากนี้ ได้ใช้ฟังก์ชัน ReLU ในชั้นซ่อน เนื่องจากมีความสามารถในการลดปัญหา vanishing gradient และช่วยให้

โมเดลสามารถเรียนรู้ได้รวดเร็วขึ้น เพื่อป้องกันปัญหา overfitting ได้มีการใช้เทคนิค Early Stopping ซึ่งจะหยุดการฝึกโมเดลเมื่อค่าความผิดพลาดของ validation set ไม่ลดลงต่อเนื่องในช่วงเวลาที่กำหนด ทำให้โมเดลมีความสามารถในการ generalization ที่ดีขึ้น ในการฝึกโมเดล ได้มีการใช้การถ่ายโอนการเรียนรู้ (Transfer Learning) สำหรับโมเดล MobileNetV2, ResNet50 และ VGG16 โดยเริ่มจากน้ำหนักที่ผ่านการฝึกจาก ImageNet และทำการ fine-tuning ในชั้นบนสุดเพื่อให้เหมาะสมกับลักษณะข้อมูล MRI ในขณะที่โมเดล Custom CNN ถูกฝึกจากศูนย์ (training from scratch) เพื่อเปรียบเทียบประสิทธิภาพกับโมเดลที่ใช้ Transfer Learning

3.2. ตัวชี้วัดประเมินผล (Evaluation Metrics)

ในการประเมินประสิทธิภาพของโมเดล Deep Learning สำหรับการจำแนกระดับของโรคอัลไซเมอร์ในงานวิจัยนี้ ได้เลือกใช้ตัวชี้วัดมาตรฐานที่ครอบคลุมทั้งความแม่นยำโดยรวมและความสามารถในการจำแนกในแต่ละคลาส ได้แก่ Accuracy, Precision, Recall และ F1-score

ตัวชี้วัดเหล่านี้ถูกเลือกเนื่องจากสามารถสะท้อนประสิทธิภาพของโมเดลได้อย่างรอบด้าน โดยเฉพาะในกรณีที่ข้อมูลมีหลายคลาสและมีความคล้ายคลึงกันระหว่างกลุ่ม เช่น Very Mild Demented และ Non-Demented

Accuracy (ACC): ACC เป็นตัวชี้วัดความแม่นยำโดยรวมของโมเดล โดยพิจารณาสัดส่วนของจำนวนตัวอย่างที่ทำนายถูกต้องทั้งหมดเมื่อเทียบกับจำนวนตัวอย่างทั้งหมด โดย TP (True Positive) คือ จำนวนข้อมูลที่เป็น Positive และโมเดลทำนายถูกต้องว่าเป็น Positive

TN (True Negative) คือ จำนวนข้อมูลที่เป็น Negative และโมเดลทำนายถูกต้องว่าเป็น Negative

FP (False Positive) คือ จำนวนข้อมูลที่เป็น Negative แต่โมเดลทำนายผิดว่าเป็น Positive

FN (False Negative) คือ จำนวนข้อมูลที่เป็น Positive แต่โมเดลทำนายผิดว่าเป็น Negative

$$ACC = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Precision (PRE): PRE แสดงถึงความถูกต้องของการทำนายว่าเป็นคลาสนั้นจริง โดยเน้นการลดจำนวน false positive ซึ่งมีความสำคัญในบริบททางการแพทย์

$$PRE = \frac{TP}{TP + FP} \quad (2)$$

Sensitivity (SEN): SEN หรือ Recall เป็นตัววัดความสามารถของโมเดลในการตรวจจับตัวอย่างที่เป็นจริง โดยมีความสำคัญอย่างยิ่งในการตรวจคัดกรองโรค เพื่อหลีกเลี่ยงการพลาดผู้ป่วย (false negative)

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-score (F1): F1 เป็นค่าเฉลี่ยเชิงสมมูลระหว่าง Precision และ Recall ซึ่งเหมาะสำหรับกรณีที่ต้องการประเมินโมเดลในสถานการณ์ที่ข้อมูลมีความไม่สมดุล

$$F1 = 2 \cdot \frac{PRE \cdot SEN}{PRE + SEN} \quad (4)$$

3.3. ผลการทดลอง (Experimental Results)

ในการศึกษานี้ ได้ทำการประเมินประสิทธิภาพของโมเดล Deep Learning จำนวน 4 โมเดล ได้แก่ Custom CNN, MobileNetV2, ResNet50 และ VGG16 โดยใช้ชุดข้อมูล MRI ภายใต้งานฝึกเดียวกัน เพื่อให้สามารถเปรียบเทียบผลลัพธ์ได้อย่างเป็นธรรม

ผลการทดลองถูกประเมินโดยใช้ตัวชี้วัด ได้แก่ ACC, PRE, SEN และ F1

ตารางที่ 3 การเปรียบเทียบประสิทธิภาพของโมเดล Deep Learning


Model	ACC (%)	PRE (%)	Recall (%)	F1 (%)
Custom CNN (Our Proposed)	97.12	0.97	0.96	0.96
MobileNetV2	83.91	0.87	0.8	0.83

ResNet50	82.81	0.84	0.77	0.8
VGG16	90.31	0.92	0.84	0.88


จากตารางที่ 3 พบว่าโมเดล Custom CNN ที่เสนอในงานวิจัยนี้ให้ประสิทธิภาพสูงสุด โดยมีค่า ACC เท่ากับ 97.12% ซึ่งสูงกว่าโมเดล baseline ทั้งหมดอย่างมีนัยสำคัญ แสดงให้เห็นว่าโครงสร้างของโมเดลที่ออกแบบเฉพาะสำหรับข้อมูล MRI สามารถสกัดคุณลักษณะสำคัญได้ดีกว่าโมเดลทั่วไป

โมเดลที่นำเสนอมีการปรับแต่งสถาปัตยกรรมให้เหมาะสมกับลักษณะของภาพสมอง เช่น การเพิ่มจำนวนชั้น convolution และการควบคุมขนาด feature map อย่างเหมาะสม ส่งผลให้สามารถจำแนกระยะของโรคอัลไซเมอร์ได้แม่นยำมากขึ้น


ในขณะที่ VGG16 ให้ผลลัพธ์รองลงมาและ MobileNetV2 มีข้อได้เปรียบด้านความเบา แต่มีความแม่นยำต่ำกว่าอย่างชัดเจน



รูปที่ 4 กราฟความแม่นยำของชุดฝึกและชุดตรวจสอบ (training และ validation) ของโมเดลการเรียนรู้เชิงลึกทั้ง 4 โมเดล ได้แก่ (a) Custom CNN ที่เสนอ (b) MobileNetV2 (c) ResNet50 และ (d) VGG16 ซึ่งแสดงประสิทธิภาพการเรียนรู้ในแต่ละรอบการฝึก (epochs)



รูปที่ 5 กราฟค่าความสูญเสียของชุดฝึกและชุดตรวจสอบของโมเดลการเรียนรู้เชิงลึกทั้ง 4 โมเดล ได้แก่ (a) Custom CNN ที่เสนอ (b) MobileNetV2 (c) ResNet50 และ (d) VGG16 ซึ่งแสดงพฤติกรรมการลู่เข้า (convergence) ของโมเดลในระหว่างกระบวนการฝึก



รูปที่ 6 เมทริกซ์ความสับสน (confusion matrix) ของโมเดลการเรียนรู้เชิงลึกทั้ง 4 โมเดล ได้แก่ (a) Custom CNN ที่เสนอ (b) MobileNetV2 (c) ResNet50 และ (d) VGG16 ซึ่งแสดงประสิทธิภาพการจำแนกใน 4 กลุ่ม ได้แก่ กลุ่มปกติ (Non-Demented) กลุ่มระยะเริ่มต้นเล็กน้อย (Very Mild Demented) กลุ่มระยะเริ่มต้น (Mild Demented) และกลุ่มระยะปานกลาง (Moderate Demented)

ดังแสดงใน รูปที่ 4 ซึ่งเป็น Confusion matrices ของโมเดล ทั้งสี่ ได้แก่ (a) proposed Custom CNN, (b) MobileNetV2, (c) ResNet50 และ (d) VGG16 พบว่าโมเดลที่เสนอสามารถจำแนกข้อมูลได้อย่างแม่นยำสูงในทุกคลาส โดยมีค่าการทำนายถูกต้องกระจายอยู่บนแนวทแยง (diagonal) อย่างชัดเจน และมีค่าความสับสนระหว่างคลาสดำที่ต่ำสุดเมื่อเทียบกับโมเดลอื่น สำหรับโมเดล MobileNetV2 และ ResNet50 พบว่ามีความสับสนระหว่างกลุ่ม Very Mild Demented และ Mild Demented ในระดับที่สูงกว่า ซึ่งสะท้อนถึงข้อจำกัดในการสกัดคุณลักษณะเชิงลึกของข้อมูล MRI โดยเฉพาะในระยะเริ่มต้นของโรค

ในขณะที่โมเดล VGG16 สามารถจำแนกกลุ่ม Non-Demented และ Moderate Demented ได้ดี แต่ยังคงมีความคลาดเคลื่อนในกลุ่มระยะเริ่มต้นเช่นเดียวกัน

ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าโมเดล Custom CNN ที่พัฒนาขึ้นมีความสามารถในการเรียนรู้คุณลักษณะของสมองได้อย่างมีประสิทธิภาพมากกว่า โดยเฉพาะในการลดความสับสน

ระหว่างคลาสนี้ที่มีความใกล้เคียงกัน ซึ่งเป็นปัจจัยสำคัญในการคัดกรองโรคอัลไซเมอร์ในระยะเริ่มต้น

ดังแสดงในรูปที่ 5 ซึ่งแสดงกราฟค่า training และ validation accuracy ของโมเดลทั้งสี่ ได้แก่ (a) proposed Custom CNN, (b) MobileNetV2, (c) ResNet50 และ (d) VGG16 พบว่าโมเดล Custom CNN มีแนวโน้มการเรียนรู้ที่ดีที่สุด โดยค่า accuracy เพิ่มขึ้นอย่างต่อเนื่องจนถึงประมาณ 97% และมีค่า training และ validation ที่ใกล้เคียงกัน แสดงถึงความสามารถในการ generalization ที่ดีและไม่มีปัญหา overfitting อย่างมีนัยสำคัญ

สำหรับโมเดล MobileNetV2 และ ResNet50 พบว่าค่า validation accuracy มีค่าต่ำกว่า training accuracy อย่างชัดเจน ในบางช่วงของการฝึก ซึ่งสะท้อนถึงข้อจำกัดในการเรียนรู้คุณลักษณะของข้อมูล MRI และอาจเกิด underfitting หรือการเรียนรู้ที่ยังไม่เพียงพอ

ในขณะที่โมเดล VGG16 แสดงแนวโน้มการเรียนรู้ที่มีความเสถียร โดยค่า accuracy เพิ่มขึ้นอย่างสม่ำเสมอ และมี

ช่องว่างระหว่าง training และ validation ในระดับปานกลาง ซึ่งบ่งชี้ถึงสมดุลระหว่างความแม่นยำและความสามารถในการ generalization

โดยรวมแล้ว ผลลัพธ์จากรูปที่ 5 สนับสนุนว่าโมเดล Custom CNN ที่เสนอมีประสิทธิภาพสูงสุดในการเรียนรู้และจำแนกข้อมูล MRI เมื่อเปรียบเทียบกับโมเดล baseline อื่น ๆ

ดังแสดงในรูปที่ 6 ซึ่งแสดงกราฟค่า training และ validation loss ของโมเดลทั้งสี่ ได้แก่ (a) proposed Custom CNN, (b) MobileNetV2, (c) ResNet50 และ (d) VGG16 พบว่าโมเดล Custom CNN มีแนวโน้มการลดลงของค่า loss อย่างต่อเนื่องและรวดเร็ว โดยค่า training และ validation loss มีความใกล้เคียงกันตลอดกระบวนการฝึก แสดงถึงการเรียนรู้ที่มีเสถียรภาพและไม่มีปัญหา overfitting อย่างมีนัยสำคัญ

สำหรับโมเดล MobileNetV2 และ ResNet50 พบว่าค่า validation loss มีค่ามากกว่า training loss ในหลายช่วงของการฝึก และมีความผันผวนในระดับหนึ่ง ซึ่งสะท้อนถึงข้อจำกัดในการเรียนรู้คุณลักษณะของข้อมูล และอาจเกิดปัญหา overfitting หรือการเรียนรู้ที่ยังไม่สมบูรณ์

ในขณะที่โมเดล VGG16 แสดงแนวโน้มของ loss ที่ลดลงอย่างสม่ำเสมอ และมีช่องว่างระหว่าง training และ validation loss ในระดับปานกลาง ซึ่งบ่งชี้ถึงการเรียนรู้ที่มีประสิทธิภาพ แต่ยังคงมีความแตกต่างของข้อมูลระหว่าง training และ validation ผลลัพธ์จากรูปที่ 6 สนับสนุนว่าโมเดล Custom CNN ที่เสนอมีความสามารถในการเรียนรู้ข้อมูลได้ดีที่สุด โดยมีการลู่เข้า (convergence) ที่รวดเร็วและมีความเสถียรสูง เมื่อเปรียบเทียบกับโมเดล baseline อื่น ๆ

4. อภิปรายผล (Discussion)

4.1 การวิเคราะห์ผลลัพธ์ของงานวิจัยนี้

ผลการทดลองในงานวิจัยนี้แสดงให้เห็นว่าโมเดล Custom CNN ที่เสนอสามารถให้ประสิทธิภาพสูงสุด เมื่อเปรียบเทียบกับโมเดลพื้นฐาน ได้แก่ MobileNetV2, ResNet50 และ VGG16 โดยมีค่า Accuracy สูงถึง 97.12% พร้อมทั้งค่า Precision, Recall และ F1-score ที่สูงอย่างสม่ำเสมอ สะท้อนให้เห็นถึงความสามารถของโมเดลในการสกัดคุณลักษณะสำคัญจากภาพ MRI ได้อย่างมีประสิทธิภาพ

หนึ่งในปัจจัยสำคัญที่ส่งผลให้โมเดลที่เสนอมีประสิทธิภาพสูง คือการออกแบบสถาปัตยกรรมที่เหมาะสมกับลักษณะของข้อมูลภาพทางการแพทย์ โดยเฉพาะการใช้ convolutional layers หลายระดับเพื่อสกัดคุณลักษณะเชิงลึก รวมถึงการควบคุมขนาดของ feature map อย่างเหมาะสม ซึ่งช่วยลดการสูญเสียข้อมูลสำคัญในกระบวนการเรียนรู้ นอกจากนี้ การใช้เทคนิค data preprocessing และ data augmentation ยังช่วยเพิ่มความหลากหลายของข้อมูล และลดปัญหา overfitting ได้อย่างมีประสิทธิภาพ

เมื่อพิจารณาผลจาก Confusion Matrix ใน รูปที่ 6 พบว่าโมเดลที่เสนอสามารถลดความสับสนระหว่างคลาสได้ดีกว่าโมเดลอื่น โดยเฉพาะในกลุ่ม Very Mild Demented และ Mild Demented ซึ่งเป็นระยะเริ่มต้นของโรคที่มีลักษณะภาพใกล้เคียงกับกลุ่มปกติ อย่างไรก็ตาม แม้ว่าโมเดลจะมีประสิทธิภาพสูง แต่การจำแนกระยะเริ่มต้นยังคงเป็นความท้าทาย ซึ่งสอดคล้องกับงานวิจัยก่อนหน้านี้ที่รายงานว่าความแตกต่างของลักษณะสมองในระยะเริ่มต้นมีความละเอียดและตรวจจับได้ยาก

ผลจากกราฟ Training และ Validation Accuracy ดังรูปที่ 4 และ Loss ดังรูปที่ 5 แสดงให้เห็นว่าโมเดล Custom CNN มีการเรียนรู้ที่มีเสถียรภาพ โดยมีค่า training และ validation ที่ใกล้เคียงกัน และไม่มีสัญญาณของ overfitting อย่างมีนัยสำคัญ ซึ่งยืนยันถึงความสามารถในการ generalization ของโมเดล ในขณะที่โมเดล baseline บางส่วนแสดงช่องว่างระหว่าง training และ validation ซึ่งอาจสะท้อนถึงข้อจำกัดในการเรียนรู้ข้อมูลเฉพาะทาง

เมื่อเปรียบเทียบกับงานวิจัยที่ใช้โมเดล Transfer Learning เช่น VGG16 และ ResNet50 พบว่าแม้โมเดลเหล่านี้จะมีประสิทธิภาพดีในงานทั่วไป แต่การปรับใช้กับข้อมูล MRI ซึ่งมีลักษณะเฉพาะทาง อาจต้องการการปรับแต่งเพิ่มเติม ในขณะที่โมเดล Custom CNN ที่ออกแบบเฉพาะสามารถตอบสนองต่อโครงสร้างข้อมูลได้ดีกว่า

ในบริบทของระบบสาธารณสุขไทย โมเดลที่เสนอมีสักยภาพในการนำไปประยุกต์ใช้เป็นระบบช่วยคัดกรองโรคอัลไซเมอร์ในระยะเริ่มต้น โดยเฉพาะในโรงพยาบาลระดับจังหวัด หรือหน่วยบริการปฐมภูมิ ซึ่งอาจขาดผู้เชี่ยวชาญด้านรังสีวิทยา อย่างไรก็ตาม การนำไปใช้งานจริงยังจำเป็นต้องพิจารณาปัจจัยเพิ่มเติม เช่น ความหลากหลายของข้อมูลผู้ป่วยจริง และการ

ทดสอบกับชุดข้อมูลจากหลายแหล่ง (multi-center data) แม้ว่างานวิจัยนี้จะให้ผลลัพธ์ที่น่าพอใจ แต่ยังมีข้อจำกัดบางประการ ได้แก่ การใช้ข้อมูลภาพแบบ 2 มิติ (2D MRI slices) ซึ่งอาจไม่สามารถสะท้อนข้อมูลเชิงปริมาตร (3D structure) ได้อย่างครบถ้วน รวมถึงขนาดของชุดข้อมูลที่ยังจำกัดเมื่อเทียบกับการใช้งานจริง

- ในงานวิจัยต่อไป สามารถพัฒนาต่อออกได้โดย:
- การใช้ข้อมูล MRI แบบ 3 มิติ (3D CNN)
- การผสานข้อมูลทางคลินิก (multimodal learning)

- การเพิ่ม attention mechanism เพื่อเน้นบริเวณสมองที่สำคัญ
- การใช้เทคนิค self-supervised learning เพื่อเพิ่มประสิทธิภาพในการเรียนรู้

4.2 การเปรียบเทียบกับงานวิจัยก่อนหน้า

เพื่อประเมินความก้าวหน้าของโมเดลที่เสนอ งานวิจัยนี้ได้ทำการเปรียบเทียบกับงานวิจัยก่อนหน้าที่ใช้ Deep Learning สำหรับการจำแนกโรคอัลไซเมอร์จากภาพ MRI ซึ่งสามารถสรุปได้ดังตารางต่อไปนี้

ตารางที่ 4 การเปรียบเทียบผลของงานวิจัยกับงานวิจัยก่อนหน้า

Study	Year	Model	Dataset	Classes	ACC
[16]	2018	CNN	OASIS	Multi	~90%
[17]	2023	VGG16 (TL)	OASIS	Binary	92.30%
[18]	2024	Xception Ensemble	MRI	Multi	99.14%
[19]	2023	CNN Ensemble	ADNI	Multi	~95–98%
[20]	2025	TL CNN	ADNI+OASIS	Multi	97.13%
[21]	2025	CNN	MRI	Binary	87.10%
[2]	2026	VGG19	ADNI	Multi	89.80%
Our Proposed		Custom CNN	MRI	4-class	97.12%

จากตารางที่ 4 เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้า พบว่าโมเดล Deep Learning ได้ถูกนำมาใช้อย่างแพร่หลายในการจำแนกโรคอัลไซเมอร์จากภาพ MRI โดยเฉพาะโมเดล CNN และ Transfer Learning ซึ่งให้ค่าความแม่นยำอยู่ในช่วงประมาณ 87%–92% เช่น งานของ [1] และ [2] ที่ใช้ CNN และ VGG16 ตามลำดับ

ในงานวิจัยที่มีการพัฒนาโมเดลขั้นสูง เช่น ensemble learning พบว่าสามารถเพิ่มประสิทธิภาพได้อย่างมีนัยสำคัญ โดยงานของ [3] รายงานความแม่นยำสูงถึง 99.14% และงานของ [4] ให้ผลลัพธ์อยู่ในช่วง 95–98% อย่างไรก็ตาม โมเดลในกลุ่มนี้มักมีความซับซ้อนสูง และต้องใช้ทรัพยากรในการประมวลผลมาก ซึ่งอาจไม่เหมาะสมต่อการนำไปใช้งานจริงในระบบสาธารณสุข

สำหรับงานวิจัยที่ใช้การรวมข้อมูลหลายชุด (multi-dataset) เช่น [5] พบว่าสามารถเพิ่มความสามารถในการ generalization

ได้ โดยให้ค่าความแม่นยำที่ 97.13% อย่างไรก็ตาม การใช้หลาย dataset อาจมีข้อจำกัดด้านความสอดคล้องของข้อมูลและการปรับมาตรฐานข้อมูล

ในขณะเดียวกัน งานวิจัยที่ใช้โมเดลพื้นฐาน เช่น CNN และ VGG19 [6], [7] ยังมีข้อจำกัดด้านความแม่นยำ โดยเฉพาะในกรณีการจำแนกแบบหลายคลาส (multi-class classification) ซึ่งเป็นปัญหาที่มีความซับซ้อนสูงกว่าการจำแนกแบบ binary

เมื่อพิจารณาผลลัพธ์ของงานวิจัยนี้ พบว่าโมเดล Custom CNN ที่เสนอสามารถให้ค่า Accuracy เท่ากับ 97.12% ซึ่งอยู่ในระดับเดียวกับงานวิจัยขั้นสูง เช่น [3] และ [5] แต่มีข้อได้เปรียบที่สำคัญคือ โครงสร้างของโมเดลมีความเรียบง่ายกว่า และไม่ต้องใช้เทคนิค ensemble หรือ multi-dataset ที่ซับซ้อน

นอกจากนี้ โมเดลที่เสนอสามารถรองรับการจำแนกแบบ 4-class ซึ่งมีความท้าทายสูงกว่าการจำแนกแบบ binary ใน

งานวิจัย [2] และ [6] โดยเฉพาะการแยกกลุ่ม Very Mild Demented และ Mild Demented ซึ่งมีลักษณะภาพที่ใกล้เคียงกัน

โดยรวมแล้ว งานวิจัยนี้แสดงให้เห็นว่า การออกแบบโมเดลเฉพาะสำหรับข้อมูล MRI สามารถให้ประสิทธิภาพที่สูงและมีความเหมาะสมต่อการนำไปใช้งานจริงในบริบทของระบบสาธารณสุขไทย มากกว่าการใช้โมเดลทั่วไปที่พัฒนาจาก dataset ธรรมชาติ

5. สรุปผล

งานวิจัยนี้ได้พัฒนาระบบช่วยคัดกรองโรคอัลไซเมอร์ในระยะเริ่มต้นจากภาพถ่ายสมองด้วยคลื่นแม่เหล็กไฟฟ้า (MRI) โดยใช้เทคนิค Deep Learning ซึ่งมุ่งเน้นการประยุกต์ใช้ในบริบทของระบบสาธารณสุขไทย โดยได้ทำการเปรียบเทียบประสิทธิภาพของโมเดลจำนวน 4 โมเดล ได้แก่ Custom CNN (ที่เสนอ), MobileNetV2, ResNet50 และ VGG16 บนชุดข้อมูล Alzheimer's Disease Multiclass Images Dataset จำนวน 6,400 ภาพ

ผลการทดลองแสดงให้เห็นว่าโมเดล Custom CNN ที่เสนอสามารถให้ประสิทธิภาพสูงสุด โดยมีค่า ACC เท่ากับ 97.12% พร้อมทั้งค่า PRE, SEN และ F1 ที่อยู่ในระดับสูงอย่างสม่ำเสมอเมื่อเปรียบเทียบกับโมเดล baseline อื่น ๆ ซึ่งมีค่าความแม่นยำต่ำกว่าอย่างชัดเจน นอกจากนี้ โมเดลยังแสดงให้เห็นถึงความสามารถในการเรียนรู้ที่มีเสถียรภาพ และสามารถลดความสัมพันธ์ระหว่างคลาสได้อย่างมีประสิทธิภาพ โดยเฉพาะในกลุ่มระยะเริ่มต้นของโรค

เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้า พบว่าโมเดลที่เสนอสามารถให้ประสิทธิภาพในระดับเดียวกับงานวิจัยขั้นสูง แต่มีข้อได้เปรียบในด้านความเรียบง่ายของโครงสร้าง และความเหมาะสมต่อการนำไปใช้งานจริง โดยไม่จำเป็นต้องใช้เทคนิคที่มีความซับซ้อนสูง เช่น ensemble learning หรือการใช้หลายชุดข้อมูลร่วมกัน

ในเชิงการประยุกต์ใช้งาน โมเดลที่พัฒนาขึ้นมีศักยภาพในการนำไปใช้เป็นเครื่องมือช่วยคัดกรองโรคอัลไซเมอร์ในระดับบริการสุขภาพเบื้องต้น เช่น โรงพยาบาลชุมชน หรือหน่วยบริการปฐมภูมิ ซึ่งอาจช่วยสนับสนุนการตัดสินใจของบุคลากรทางการแพทย์ และลดภาระของผู้เชี่ยวชาญเฉพาะทาง

อย่างไรก็ตาม งานวิจัยนี้ยังมีข้อจำกัดบางประการ ได้แก่ การใช้ข้อมูลภาพแบบ 2 มิติ (2D MRI) และการทดสอบบนชุด

ข้อมูลเพียงแหล่งเดียว ซึ่งอาจยังไม่ครอบคลุมความหลากหลายของผู้ป่วยจริง

กิตติกรรมประกาศ

ผู้วิจัยขอขอบพระคุณคณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ มหาวิทยาลัยกาฬสินธุ์ที่เอื้อเฟื้อสถานที่ในการทำวิจัย โดยบทความวิจัยนี้เป็นผลจากการศึกษาในรายวิชาการวิเคราะห์ภาพถ่ายทางการแพทย์ หลักสูตรวิทยาศาสตรบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศทางการแพทย์ คณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ มหาวิทยาลัยกาฬสินธุ์ ประจำปีการศึกษา 2568

เอกสารอ้างอิง

- [1] สำนักงานสถิติแห่งชาติ, "รายงานสถิติประชากรประเทไทย ประจำปี 2551," สำนักงานสถิติแห่งชาติ, กรุงเทพฯ, 2551. [Online]. Available: <https://www.nso.go.th>
- [2] K. Chauhan, N. Kishore, N. Goel, and Monika, "Deep learning based multi-stage classification of Alzheimer's disease using T1-weighted MRI images," Franklin Open, vol. 15, p. 100557, 2026/06/01/ 2026, doi: <https://doi.org/10.1016/j.fraope.2026.100557>.
- [3] H. Zhu, J. Huang, K. Chen, X. Ying, and Y. Qian, "multiPI-TransBTS: A multi-path learning framework for brain tumor image segmentation based on multi-physical information," Computers in Biology and Medicine, vol. 191, p. 110148, 2025/06/01/ 2025, doi: <https://doi.org/10.1016/j.combiomed.2025.110148>.
- [4] X. Zhang et al., "Unsupervised brain MRI tumour segmentation via two-stage image synthesis," Medical Image Analysis, vol. 102, p. 103568, 2025/05/01/ 2025, doi: <https://doi.org/10.1016/j.media.2025.103568>.
- [5] V. Shevchenko et al., "A comparative machine learning study of schizophrenia biomarkers derived from functional connectivity," Scientific Reports, vol. 15, no. 1, p. 2849, 2025/01/22 2025, doi: 10.1038/s41598-024-84152-2.
- [6] V. G. Shankar, D. S. Sisodia, and P. Chandrakar, "Alzheimer's stage progression modeling using graph neural network and MRI biomarkers," Neural Computing

- and Applications, 2025/06/05 2025, doi: 10.1007/s00521-025-11353-9.
- [7] H. Schulz and S. Behnke, "Deep Learning," *KI - Künstliche Intelligenz*, vol. 26, no. 4, pp. 357-363, 2012/11/01 2012, doi: 10.1007/s13218-012-0198-z.
- [8] I. Goodfellow, Y. Bengio, and A. Courville, *Convolutional Neural Networks (CNNs)*. Cambridge, MA: MIT Press, 2016, pp. 326-359.
- [9] r. ranokphanuwat, "ระบบควบคุมโรงเรือนผักไฮโดรโปนิกส์อัตโนมัติโดยใช้เทคโนโลยี IoT และเครื่องมือการเรียนรู้เชิงลึก," *วารสารวิชาการและเทคโนโลยีสารสนเทศ*, vol. 8, no. 2, pp. 74-82, 12/25 2018, doi: 10.14456/jist.2018.8.
- [10] P. Luengvongsakorn and W. Pijitrojana, "Comparative Study of ML and DL in Optical Transceiver Failure Diagnosis," *วารสารวิชาการและเทคโนโลยีสารสนเทศ*, vol. 15, no. 2, pp. 24-36, 12/27 2025. [Online]. Available: <https://ph02.tci-thaijo.org/index.php/JIST/article/view/260843>.
- [11] ณ. หงษ์บุญมี and จ. กันยาประสิทธิ์, "การวิเคราะห์ปัญหาสุขภาพจากภาพถ่ายเล็บด้วยเทคนิคการเรียนรู้เชิงลึก," *วารสารวิชาการและเทคโนโลยีสารสนเทศ*, vol. 11, no. 2, pp. 10-20, 12/28 2021, doi: 10.14456/jist.2021.12.
- [12] M. Sandler, A. G. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4510-4520, 2018.
- [13] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [14] C. W. Chun, N. T. Yousir, S. Mohammed Abdulameer, and A. A. Hezam, "Deep Learning Approach for Predicting Prostate Cancer from MRI Images," *Journal of Soft Computing and Data Mining*, vol. 3, no. 2, pp. 1-9, 2022. [Online]. Available: <https://publisher.uthm.edu.my/ojs/index.php/jscdm/article/view/12220>.
- [15] Kaggle. Alzheimer's Disease Multiclass Images Dataset, Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/tourist55/alzheimers-dataset-4-class-of-images>
- [16] J. Islam and Y. Zhang, "Brain MRI analysis for Alzheimer's disease diagnosis using an ensemble system of deep convolutional neural networks," (in eng), *Brain Inform*, vol. 5, no. 2, p. 2, May 31 2018, doi: 10.1186/s40708-018-0080-3.
- [17] N. Raza, A. Naseer, M. Tamoor, and K. Zafar, "Alzheimer Disease Classification through Transfer Learning Approach," (in eng), *Diagnostics (Basel)*, vol. 13, no. 4, Feb 20 2023, doi: 10.3390/diagnostics13040801.
- [18] C. Mahanty et al., "Effective Alzheimer's disease detection using enhanced Xception blending with snapshot ensemble," (in eng), *Sci Rep*, vol. 14, no. 1, p. 29263, Nov 26 2024, doi: 10.1038/s41598-024-80548-2.
- [19] S. Fathi, A. Ahmadi, A. Dehnad, M. Almasi-Dooghaee, and M. Sadegh, "A Deep Learning-Based Ensemble Method for Early Diagnosis of Alzheimer's Disease using MRI Images," (in eng), *Neuroinformatics*, vol. 22, no. 1, pp. 89-105, Jan 2024, doi: 10.1007/s12021-023-09646-2.
- [20] S. B. Shahid et al., "Novel deep learning for multi-class classification of Alzheimer's in disability using MRI datasets," (in English), *Frontiers in Bioinformatics, Original Research* vol. Volume 5 - 2025, 2025-August-20 2025, doi: 10.3389/fbinf.2025.1567219.
- [21] A. Y. Bayahya, H. Banjar, O. Talabay, and S. H. Alamri, "Comparative analysis of multiple deep learning models with mitigation-driven approaches for enhanced Alzheimer's disease classification," (in eng), *Sci Rep*, vol. 15, no. 1, p. 44098, Nov 22 2025, doi: 10.1038/s41598-025-27914-w.