



การจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้การเรียนรู้เชิงลึก

ทรงศนีย์ หัตถิยา* ฮานิส แนนูแล และ ปรีศมน สอดส่อง

สาขาเทคโนโลยีธุรกิจดิจิทัล คณะบริหารธุรกิจ มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 09 8014 2899 อีเมล: tassanee.h@rmutsv.ac.th DOI: 10.14416/j.kmutnb.2026.06.006

รับเมื่อ 4 สิงหาคม 2568 แก้ไขเมื่อ 6 กุมภาพันธ์ 2569 ตอรับเมื่อ 10 มีนาคม 2569 เผยแพร่ออนไลน์ 16 มิถุนายน 2569

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

การวิจัยนี้ได้นำเสนอการพัฒนาตัวจำแนกเพื่อตรวจจ็ระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ซึ่งเป็นเทคนิคการจำแนกของการเรียนรู้เชิงลึก (Deep Learning) จำนวน 5 สถาปัตยกรรม ได้แก่ DenseNet121, EfficientNetB0, EfficientNetB1, MobileNetV2 และ NasNetMobile โดยใช้ข้อมูลภาพถ่ายจอประสาทตาจำนวน 5,000 ภาพจากฐานข้อมูล Kaggle ซึ่งชุดข้อมูลมีการจัดกลุ่มระยะของภาวะเบาหวานขึ้นจอประสาทตาออกเป็น 5 ระยะ โดยมีขั้นตอนในการวิจัยดังนี้ ขั้นตอนที่ 1 การเตรียมความพร้อมของข้อมูล (Data Preparation) และขั้นตอนที่ 2 การพัฒนาตัวจำแนกสำหรับตรวจจ็ระยะของภาวะเบาหวานขึ้นจอประสาทตา (Model Generation) ซึ่งขั้นตอนการพัฒนาตัวจำแนกได้กำหนดรอบในการเรียนรู้ (Epochs) จำนวน 100 รอบของแต่ละสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการ ผลการทดสอบพบว่าสถาปัตยกรรม EfficientNetB0 มีประสิทธิภาพสูงสุด โดยให้ค่าความแม่นยำในการจำแนกรูปภาพสูงถึงร้อยละ 99.25 ของชุดข้อมูลการเรียนรู้ และเมื่อนำแบบจำลองที่ได้มาทดสอบกับชุดข้อมูลทดสอบพบว่าแบบจำลองให้ค่าความแม่นยำอยู่ที่ร้อยละ 81.30 และค่า F1-score เฉลี่ยอยู่ที่ร้อยละ 81.15 นอกจากนี้แบบจำลองยังแสดงประสิทธิภาพที่ในระยะที่เป็นอันตราย โดยให้ค่าความแม่นยำ (Precision) สูงถึงร้อยละ 92.82 ในระยะที่รุนแรงที่สุด และค่าการเรียกคืน (Recall) สูงถึงร้อยละ 89.00 ในระยะรุนแรง ผลการวิจัยนี้ชี้ให้เห็นว่าตัวจำแนกที่พัฒนาขึ้นมีศักยภาพในการสนับสนุนการคัดกรองทางการแพทย์ เพื่อลดความเสี่ยงต่อการสูญเสียการมองเห็นของผู้ป่วยได้อย่างมีประสิทธิภาพ

คำสำคัญ: ภาวะเบาหวานขึ้นจอประสาทตา โครงข่ายประสาทเทียมแบบสังวัตนาการ การเรียนรู้เชิงลึก การจำแนกภาพ



Diabetic Retinopathy Stage Classification Using Deep Learning Techniques

Tassanee Hattiya*, Hanis Naelulae and Pratsamon Sodsong

Department of Digital Business Technology, Faculty of Business Administration, Rajamangala University of Technology Srivijaya, Songkhla, Thailand

* Corresponding Author, Tel. 09 8014 2899, E-mail: tassanee.h@rmutsv.ac.th DOI: 10.14416/j.kmutnb.2026.06.006

Received 4 August 2025; Revised 6 February 2026; Accepted 10 March 2026; Published online: 16 June 2026

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

This research presents the development of a classifier for detecting the stages of Diabetic Retinopathy (DR) using Convolutional Neural Networks (CNNs), a deep learning-based classification technique. Five architectures, including DenseNet121, EfficientNetB0, EfficientNetB1, MobileNetV2, and NASNetMobile, were explored. A dataset of 5,000 retinal fundus images obtained from Kaggle was categorized into five stages of Diabetic Retinopathy. The research methodology consisted of two main steps: 1) data preparation and 2) model generation. Each CNN architecture was trained for 100 epochs. The experimental results indicated that EfficientNetB0 achieved the highest performance, reaching an accuracy of 99.25% on the training dataset. When evaluated on the test dataset, the model achieved an accuracy of 81.30% and a macro-average F1-score of 81.15%. Furthermore, the model demonstrated exceptional effectiveness in identifying high-risk stages, achieving a precision of 92.82% for the most severe stage of Diabetic Retinopathy and a recall of 89.00% for the severe stage. These findings suggest that the developed classifier has significant potential to support medical screening processes and effectively reduce the risk of vision loss in diabetic patients.

Keywords: Diabetic Retinopathy, Convolutional Neural Network, Deep Learning, Image Classification


Please cite this article as: T. Hattiya, H. Naelulae, and P. Sodsong , "Diabetic retinopathy stage classification using deep learning techniques," *The Journal of KMUTNB*, vol. 36, no. 3, pp. 1–14, Jul.–Sep. 2026 (in Thai), Art. no. 263-8230, doi: 10.14416/j.kmutnb.2026.06.006.

1. บทนำ


โรคเบาหวาน (Diabetes Mellitus) เป็นโรคเรื้อรังที่กำลังเป็นปัญหาด้านสาธารณสุขที่สำคัญระดับโลก โดยสหพันธ์โรคเบาหวานนานาชาติ (International Diabetes Federation) [1] รายงานว่าใน ค.ศ. 2025 มีผู้ป่วยเบาหวานทั่วโลกมากกว่า 500 ล้านคน และตัวเลขนี้ยังคงเพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะในประเทศที่กำลังพัฒนา ซึ่งมีการเปลี่ยนแปลงวิถีชีวิตอย่างรวดเร็ว เช่น การบริโภคอาหารแปรรูป การขาดการออกกำลังกาย และภาวะน้ำหนักเกิน โรคเบาหวานไม่เพียงแต่ส่งผลกระทบต่อระดับน้ำตาลในเลือดเท่านั้น แต่ยังเป็นปัจจัยเสี่ยงสำคัญของโรคแทรกซ้อนที่เกี่ยวข้องกับระบบต่าง ๆ ในร่างกาย เช่น หัวใจ ไต และโดยเฉพาะอย่างยิ่ง “ดวงตา” หนึ่งในภาวะแทรกซ้อนที่พบบ่อยและอันตรายที่สุดของโรคเบาหวานคือ ภาวะเบาหวานขึ้นจอประสาทตา (Diabetic Retinopathy; DR) ซึ่งเป็นภาวะที่เกิดจากความเสียหายของหลอดเลือดเล็ก ๆ ที่เลี้ยงจอประสาทตาเนื่องจากระดับน้ำตาลในเลือดสูงอย่างต่อเนื่อง ทำให้เกิดการอักเสบ ความเปราะบาง และการรั่วซึมของหลอดเลือด หากไม่ได้รับการวินิจฉัยและรักษาอย่างเหมาะสมอาจนำไปสู่การเกิดของหลอดเลือดใหม่ที่ผิดปกติ ซึ่งมีแนวโน้มจะแตกได้ง่าย ส่งผลให้เกิดเลือดออกภายในจอประสาทตาและอาจเป็นสาเหตุทำให้สูญเสียการมองเห็นถาวรได้ ข้อมูลจากสมาคมเบาหวานแห่งประเทศไทยระบุว่า ผู้ป่วยเบาหวานมากกว่า 30% มีภาวะเบาหวานขึ้นจอประสาทตาในระยะใดระยะหนึ่ง โดยเฉพาะอย่างยิ่งในผู้ที่ควบคุมระดับน้ำตาลได้ไม่ดีหรือเป็นเบาหวานมานานมากกว่า 10 ปี ความยากของโรคนี้นักไม่แสดงอาการในระยะเริ่มต้น ผู้ป่วยโรคเบาหวานจึงมักไม่รู้ตัวและไม่ได้รับการตรวจคัดกรองอย่างสม่ำเสมอ ทำให้มีโอกาสสูงที่ภาวะดังกล่าวจะลุกลามจนรุนแรงก่อนเข้ารับการรักษา การตรวจคัดกรองภาวะเบาหวานขึ้นจอประสาทตาในระยะเริ่มต้นจึงเป็นสิ่งสำคัญยิ่ง โดยทั่วไปแพทย์จะใช้วิธีการถ่ายภาพจอประสาทตาโดยใช้กล้องถ่ายภาพจอประสาทตา (Fundus Camera) แล้วพิจารณาความผิดปกติของจอประสาทตาในภาพถ่ายนั้น อย่างไรก็ตามการตรวจลักษณะภาพด้วยสายตาโดยผู้เชี่ยวชาญนั้นใช้เวลาและจำกัดในด้าน

ทรัพยากรมนุษย์ โดยเฉพาะในพื้นที่ชนบทที่ขาดแคลนแพทย์เฉพาะทาง จากปัญหาที่เกิดขึ้นดังกล่าวการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์จึงถูกนำมาใช้เพื่อช่วยในการวิเคราะห์ภาพจอประสาทตา โดยเฉพาะเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) สำหรับการวิเคราะห์ภาพทางการแพทย์ ซึ่งได้รับความนิยมอย่างมากในช่วงที่ผ่านมา โดยมีการนำเสนอวิธีการสกัดคุณลักษณะจากภาพ เช่น เส้นเลือด เส้นผ่านศูนย์กลางของจุดรั้ว จุดเลือดออก เป็นต้น เพื่อนำไปสร้างตัวจำแนกสำหรับจำแนกภาพว่าอยู่ในกลุ่มผู้ป่วยเบาหวานขึ้นจอประสาทตาหรือไม่ ถึงแม้แนวทางนี้จะสามารถนำมาใช้กับข้อมูลจำนวนจำกัดได้ แต่แบบจำลองดั้งเดิมเหล่านี้มักมีข้อจำกัดในด้านประสิทธิภาพการทำงาน โดยเฉพาะเมื่อใช้กับชุดข้อมูลขนาดใหญ่ที่มีความหลากหลายของภาพสูง หรือมีลักษณะภาพที่ซับซ้อนเพื่อแก้ปัญหาดังกล่าว จึงเริ่มใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นการพัฒนาแบบจำลองการเรียนรู้ของเครื่องให้สามารถเรียนรู้คุณลักษณะของข้อมูลได้โดยอัตโนมัติ โดยไม่ต้องสกัดคุณลักษณะก่อน ซึ่งสถาปัตยกรรมที่ได้รับความนิยมสำหรับการจำแนกภาพคือ สถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Networks; CNNs) ซึ่งถูกนำมาใช้ในงานด้านการจำแนกภาพ การตรวจจับวัตถุ และงานด้านการแพทย์อย่างแพร่หลาย งานวิจัยจำนวนมากพบว่าโครงข่ายประสาทเทียมแบบสังวัตนาการสามารถเรียนรู้ลักษณะเฉพาะของภาพถ่ายจอประสาทตาได้อย่างมีประสิทธิภาพ และสามารถจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาได้แม่นยำกว่าแบบจำลองเดิม

ภาวะเบาหวานขึ้นจอประสาทตาเป็นภาวะแทรกซ้อนที่เกิดจากโรคเบาหวาน โดยมีสาเหตุมาจากระดับน้ำตาลในเลือดสูงเรื้อรัง ซึ่งส่งผลต่อการทำลายหลอดเลือดขนาดเล็กในจอประสาทตา (Retina) จอประสาทตาเป็นเนื้อเยื่อที่ทำหน้าที่รับแสงและแปลงสัญญาณแสงเป็นสัญญาณประสาทเพื่อส่งต่อไปยังสมองเพื่อประมวลผลภาพ เมื่อหลอดเลือดในจอประสาทตาถูกทำลาย จะเกิดการรั่วซึมของของเหลวและเลือด (Hemorrhage) ซึ่งทำให้เกิดจุดผิดปกติบนจอประสาทตา



รูปที่ 1 ไม่มีภาวะเบาหวานขึ้นจอประสาทตา (No DR)



รูปที่ 2 ระยะเวลา (Mild NPDR)



รูปที่ 3 ระยะปานกลาง (Moderate NPDR)


ส่งผลให้การมองเห็นผิดเพี้ยน ในกรณีที่มีโรคลูกตามจุนรุนแรงจะมีการเติบโตของหลอดเลือดใหม่ที่ผิดปกติบนผิวจอประสาทตา (Neovascularization) ซึ่งเปราะบางและอาจทำให้เกิดแผลเป็น การลอกของจอประสาทตาและนำไปสู่การสูญเสียการมองเห็นถาวรได้ [2] โรคนี้สามารถแบ่งออกเป็น 5 ระยะ ตามลักษณะความรุนแรงและการเปลี่ยนแปลงของจอประสาทตา ดังนี้

ระยะที่ 1 ไม่มีภาวะเบาหวานขึ้นจอประสาทตา (No Diabetic Retinopathy; No DR) เป็นดวงตาโดยเฉพาบริเวณจอประสาทตาไม่มีความผิดปกติใด ๆ โดยผลการตรวจพบว่าไม่มีพยาธิสภาพหรือสิ่งผิดปกติ เช่น จุดไขมันใต้ตา หลอดเลือดในจอประสาทตาไม่มีการรั่วซึมหรือบวม ไม่มีการขยายตัวหรือผิดปกติของหลอดเลือด (Micro-aneurysms) นอกจากนี้จอประสาทตายังไม่พบจุดเลือดออกหรือการสะสมของไขมันและโปรตีนรั่วซึม รวมถึงไม่มีบริเวณที่จอประสาทตาขาดเลือด (Ischemia) ซึ่งมักแสดงเป็นจุดสีขาว (Cotton-wool Spots) อีกด้วย ดังแสดงในรูปที่ 1


ระยะที่ 2 ระยะเวลา (Mild Nonproliferative Diabetic Retinopathy; Mild NPDR) ในระยะนี้มีลักษณะเฉพาะคือมีหลอดเลือดโป่งพองขนาดเล็ก ซึ่งเป็นส่วนนูนเล็ก ๆ ในหลอดเลือดของจอประสาทตาหลอดเลือดโป่งพองขนาดเล็กอาจไม่ก่อให้เกิดอาการใด ๆ แต่สามารถเป็นสัญญาณของความเสียหายในระยะเริ่มต้นของจอประสาทตาได้จุดสีแดงวงกลมจะปรากฏขึ้นที่ปลายหลอดเลือดโป่งพองขนาดเล็ก ในระยะนี้สายตาของคุณไม่ได้รับผลกระทบแต่คุณมีความเสี่ยงที่จะเกิดปัญหาในอนาคตมากขึ้น ไม่จำเป็นต้องได้รับการรักษา แต่ต้องดูแลเพื่อหยุดปัญหาไม่ให้แย่ลง ดังแสดงในรูปที่ 2

ระยะที่ 3 ระยะปานกลาง (Moderate Nonproliferative Diabetic Retinopathy; Moderate NPDR) ระยะนี้มีลักษณะเฉพาะคือมีหลอดเลือดโป่งพองขนาดเล็ก รวมถึงมีการเปลี่ยนแปลงอื่น ๆ ในหลอดเลือดของจอประสาทตา เช่น เลือดออกและสารคัดหลั่ง เลือดออกเป็นจุดเลือดเล็ก ๆ ที่รั่วออกมาจากหลอดเลือด ในขณะที่สารคัดหลั่งเป็นบริเวณเล็ก ๆ ของของเหลวที่รั่วออกมาจากหลอดเลือดระดับปานกลางอาจทำให้สูญเสียการมองเห็น เช่น การมองเห็นพร่ามัวหรือจุดดำ ในบริเวณการมองเห็น ในระยะปานกลางจุดสีแดงในหลอดเลือดจะขยายเป็นชั้นที่ลึกขึ้นและเกิดเลือดออกจากในจอประสาทตา ในระยะมีความเสี่ยงสูงที่การมองเห็นของคุณจะได้รับผลกระทบ โดยปกติจะต้องไปตรวจจอประสาทตาบ่อยขึ้น ดังแสดงในรูปที่ 3

ระยะที่ 4 ระยะรุนแรง (Severe Nonproliferative Diabetic Retinopathy; Severe NPDR) ในระยะที่โรคจอประสาทตาเสื่อมมีความรุนแรงมากขึ้นหรือเรียกว่าโรคจอประสาทตาเสื่อมแบบแพร่กระจายจะมีหลอดเลือดโป่งพอง เลือดออกและของเหลวไหลออกจำนวนมาก ส่งผลให้เกิดการสูญเสียการมองเห็นอย่างรุนแรง เช่น มองเห็นเป็นอุโมงค์



รูปที่ 4 ระยะรุนแรง (Severe NPDR)



รูปที่ 5 ระยะเจริญเติบโตของหลอดเลือดผิดปกติ (PDR)

หรือตาบอดสนิท โดยหลอดเลือดใหม่จะเติบโตบนพื้นผิวจอประสาทตาในขณะที่เดียวกันหลอดเลือดที่อุดตันทำให้เลือดไปเลี้ยงจอประสาทตาน้อยลงเกิดการขาดเลือดและส่งสัญญาณให้สร้างหลอดเลือดใหม่ พร้อมทั้งอาจเกิดเนื้อเยื่อแผลเป็น หากหลอดเลือดปิดในบริเวณจุดรับภาพทำให้มองเห็นภาพพร่ามัวมีจุดดำหรือจุดลอยปรากฏขึ้นในระยะ มีความเสี่ยงต่อการสูญเสียการมองเห็นสูงมากจะมีการเสนอการรักษาเพื่อหยุดการมองเห็นไม่ให้แย่ลง แต่ก็อาจไม่สามารถฟื้นฟูการมองเห็นที่สูญเสียไปได้ ดังแสดงในรูปที่ 4

ระยะที่ 5 ระยะเจริญเติบโตของหลอดเลือดผิดปกติ (Proliferative Diabetic Retinopathy; PDR) ในระยะขั้นสูงของโรคจอประสาทตาเสื่อม ปัจจัยการเจริญเติบโตที่หลังจากจอประสาทตาจะกระตุ้นการสร้างหลอดเลือดใหม่ที่เปราะบาง ซึ่งเติบโตบนผิวจอประสาทตาและเข้าสู่เจลวุ้นในตา หลอดเลือดเหล่านี้มีแนวโน้มรั่วซึมและเลือดออกง่าย อาจทำให้เกิดแผลเป็นและการลอกของจอประสาทตา ซึ่งนำไปสู่การสูญเสียการมองเห็นถาวรได้โดยแผลเป็นอาจดึงจอประสาทตาให้หลุดจากด้านหลังของดวงตาทำให้สูญเสียการมองเห็นทั้งด้านตรงและด้านข้างอย่างถาวร ดังแสดงในรูปที่ 5

การเรียนรู้เชิงลึกเป็นการพัฒนามาจากการเรียนรู้ของเครื่อง และปัญญาประดิษฐ์ (Artificial Intelligence) การเรียนรู้เชิงลึกเป็นความสามารถในการใช้หลักการคิด พร้อมทั้งหลักการที่เน้นการใช้ประมวลผลแบบสมองของมนุษย์ซึ่งเรียกว่าโครงข่ายประสาทเทียม (Artificial Neural Network) ซึ่งได้ถูกสร้างขึ้นโดยการนำระบบโครงข่ายประสาทเทียมมาทำการซ้อนกันจำนวนหลายชั้นพร้อมทั้ง

เรียนรู้ข้อมูลโดยการนำชุดข้อมูลสำหรับการเรียนรู้ของแบบจำลองเพิ่มเข้าไปในส่วนหนึ่งของชั้นรับข้อมูล (Input Layer) รับข้อมูลจากแหล่งต่าง ๆ [3] เช่น รูปภาพ ข้อความ หรือเสียง เพื่อส่งต่อข้อมูลไปประมวลผลที่ชั้นซ่อน (Hidden Layer) หลายชั้นที่ประมวลผลและดึงคุณลักษณะสำคัญจากข้อมูล และนำเสนอ ผลลัพธ์ของการประมวลผลที่ชั้นแสดงผล (Output Layer) ส่งผลลัพธ์ที่ได้ เช่น การจำแนกประเภท หรือการทำนาย ซึ่งในโครงสร้างของโครงข่ายประสาทเทียมระหว่างชั้นรับข้อมูล และชั้นแสดงผล ประกอบด้วยชั้นจำนวนมาก เนื่องจากในแต่ละชั้นนั้นจะช่วยเพิ่มประสิทธิภาพของแบบจำลองให้สามารถตรวจจับหรือจำแนกประเภทข้อมูลได้ถูกต้องแม่นยำมากยิ่งขึ้นและการเรียนรู้ข้อมูลของแบบจำลองสามารถแบ่งออกได้เป็น 3 ประเภท ได้แก่ การเรียนรู้แบบมีผู้ฝึกสอน (Supervised Learning) การเรียนรู้แบบไม่มีผู้ฝึกสอน (Unsupervised Learning) และการเรียนรู้แบบกึ่งผู้ฝึกสอน (Semi Supervised Learning) โดยโครงข่ายประสาทเทียมถูกนำเสนอไว้หลากหลายรูปแบบ เช่น โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network; CNN) ที่ออกแบบมาเฉพาะสำหรับการประมวลผลข้อมูลเชิงพื้นที่ เช่น ภาพและข้อมูลแบบลำดับสองมิติเพื่อดึงคุณลักษณะสำคัญจากข้อมูล โครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network; RNN) ที่ออกแบบมาเฉพาะสำหรับการจัดการกับข้อมูลลำดับ (Sequential Data) เช่น ข้อความเสียงหรือข้อมูลเวลา (Time Series) โดยมีความสามารถในการจดจำความสัมพันธ์เชิงลำดับและบริบทของข้อมูลก่อนหน้าผ่านการเชื่อมโยงผลลัพธ์ในอดีตกับการประมวลผลในปัจจุบันและ

โครงข่ายประสาทเทียมแบบสังวัตนาการย้อนกลับ (Recurrent Convolutional Neural Network) ออกแบบมาเพื่อรวมข้อดีของทั้งสองรูปแบบในการจัดการข้อมูลที่มีลักษณะเป็นเชิงพื้นที่ (Spatial) และเชิงลำดับ (Sequential) พร้อมกันเป็นต้น


สถาปัตยกรรมของโครงข่ายประสาทเทียมที่ได้รับการออกแบบมาโดยเฉพาะสำหรับกรวิเคราะห์ข้อมูลที่มีลักษณะเป็นภาพหรือมีโครงสร้างแบบ 2 มิติ เช่น ภาพถ่ายจากกล้อง ภาพเอกซเรย์หรือภาพจอประสาทตา โดยโครงข่ายประสาทเทียมแบบสังวัตนาการมีความสามารถในการเรียนรู้คุณลักษณะสำคัญ (Features) ของภาพได้โดยอัตโนมัติโดยไม่ต้องมีการสกัดคุณลักษณะด้วยมือเหมือนในเทคนิคเดิม ๆ [4] สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการประกอบด้วย 3 ชั้นหลัก (Layers) ดังแสดงในรูปที่ 6 โดยแต่ละชั้นมีหน้าที่เฉพาะในการทำงาน ดังนี้ รูปที่ 6 โครงข่ายประสาทเทียมแบบสังวัตนาการ

ชั้นที่ 1 ชั้นคอนโวลูชัน (Convolutional Layer) ชั้นนี้ทำหน้าที่สำคัญที่สุดของโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยจะใช้ฟิลเตอร์ (Filter หรือ Kernel) ที่เป็นเมทริกซ์ขนาดเล็กเคลื่อนผ่านรูปภาพ เพื่อดึงลักษณะเฉพาะ เช่น ขอบ เส้น รูปร่าง จุดสว่าง จุดมืด คุณลักษณะอื่น ๆ ของภาพ เรียกว่า แผนที่คุณลักษณะ (Feature Map)

ชั้นที่ 2 ชั้นลดขนาด (Pooling Layer) เป็นชั้นที่ใช้ลดขนาดของคุณลักษณะที่ได้จากชั้นก่อนหน้า โดยนิยมใช้ Max Pooling ซึ่งจะเลือกค่าสูงสุดในแต่ละบริเวณย่อยของรูปภาพ ช่วยลดจำนวนพารามิเตอร์และเวลาในการประมวลผลทั้งยังช่วยลดการจดจำชุดข้อมูลที่ใช้ในการเรียนรู้มากเกินไป (Overfitting)

ชั้นที่ 3 ชั้นการเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layer) ในขั้นตอนสุดท้ายของการสกัดคุณลักษณะที่ได้จากการแปลงหลายขั้นตอนจะถูกแปลงเป็นเวกเตอร์และส่งเข้าชั้นการเชื่อมโยงแบบสมบูรณ์เพื่อทำหน้าที่จำแนกภาพเข้าสู่กลุ่มที่ต้องการ

จากงานวิจัยที่เกี่ยวข้องกับการตรวจจ็บระยะของภาวะเบาหวานขึ้นจอประสาทตา (Diabetic Retinopathy) ด้วย



รูปที่ 6 โครงข่ายประสาทเทียมแบบสังวัตนาการ

เทคนิคปัญญาประดิษฐ์ได้รับความสนใจอย่างแพร่หลายในช่วงไม่กี่ปีที่ผ่านมา เนื่องจากสามารถเพิ่มทั้งความแม่นยำและความรวดเร็วในการวินิจฉัยภาพจอประสาทตาได้อย่างมีประสิทธิภาพ งานวิจัยจำนวนมากได้พัฒนาและประเมินแบบจำลองที่หลากหลายเพื่อตอบโจทย์ดังกล่าว โดยมีการนำเทคนิคจากการเรียนรู้เชิงลึก และการเรียนรู้แบบถ่ายโอน (Transfer Learning) มาประยุกต์ใช้ โดยมีงานวิจัยการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา โดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการร่วมกับเทคนิค Global Average Pooling และ Max Pooling เพื่อลดความเสี่ยงของปัญหาการจดจำชุดข้อมูลที่ใช้ในการเรียนรู้มากเกินไป (Overfitting) พร้อมทั้งเพิ่มศักยภาพในการจำแนกภาพเบื้องต้น โดยได้ผลลัพธ์ความแม่นยำอยู่ที่ 80.5 จากการทดสอบบนชุดข้อมูล Kaggle จำนวน 35,000 ภาพ [5] นอกจากนี้ยังมีงานวิจัยที่ได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของสถาปัตยกรรมต่าง ๆ ได้แก่ AlexNet, MobileNet, VGG-16, InceptionV3 และ InceptionResNetV2 จากผลการทดลองพบว่า InceptionResNetV2 มีประสิทธิภาพสูงที่สุดโดยให้ค่าความแม่นยำ (Accuracy) อยู่ที่ 63.23 จากชุดข้อมูล Kaggle จำนวน 35,126 ภาพ สะท้อนถึงความเหมาะสมของโมเดลสำหรับการนำไปใช้ในระบอบวินิจฉัยขั้นต้น [6] เช่นเดียวกันกับงานวิจัยนี้ [7] ที่ได้เน้นการเพิ่มประสิทธิภาพการจำแนกภาพจอประสาทตาที่มีภาวะเบาหวานขึ้นจอประสาทตา โดยประยุกต์ใช้เทคนิคการทำตัวอย่างข้อมูลแบบสุ่ม (Data Resampling) และ Meta-learning พร้อมเลือกใช้สถาปัตยกรรมที่มีขนาดเล็ก เช่น MobileNetV2, EfficientNetB1 และ NasNetMobile รวมถึงการประยุกต์ใช้

เทคนิคการเรียนรู้แบบกลุ่ม (Ensemble Learning) เพื่อรวมความสามารถของสถาปัตยกรรมต่าง ๆ ผลลัพธ์การทดสอบจากชุดข้อมูล Kaggle และ APTOS รวม 23,510 ภาพ แสดงค่าความแม่นยำสูงถึง 86.32 และ Arias Serrano [8] ซึ่งใช้เทคนิคการเรียนรู้แบบถ่ายโอน บนสถาปัตยกรรม AlexNet, ResNet50 และ GoogleNet สำหรับตรวจจับภาวะเบาหวานขึ้นจอประสาทตาและโรคต้อหิน (Glaucoma) แม้จะใช้ข้อมูลเพียง 4,308 ภาพ จากชุดข้อมูล APTOS, HRF และ sjchoi86-HRF แต่สถาปัตยกรรมที่ใช้สามารถให้ผลความแม่นยำในช่วง 89.70–94.30 สะท้อนถึงประสิทธิภาพการเรียนรู้แม้ในกรณีที่มีข้อมูลจำกัด นอกจากนี้บางงานวิจัยได้พัฒนาสถาปัตยกรรม EfficientNetB0 ซึ่งมีขนาดเล็กและประยุกต์ใช้การเรียนรู้แบบถ่ายโอนและการปรับจูนแบบจำลอง (Fine-tuning) เพื่อให้สามารถวิเคราะห์ภาวะเบาหวานขึ้นจอประสาทตาได้รวดเร็วและแม่นยำ โดยให้ผลความแม่นยำถึงร้อยละ 91.00 จากข้อมูลภาพ 3,200 ภาพ ใน Kaggle และ APTOS [9] และงานวิจัยต่อมา [10] ได้นำเสนอสถาปัตยกรรมใหม่ที่ชื่อว่า MAPCRI-DMPLC ซึ่งเป็นการรวมกระบวนการเตรียมความพร้อมของข้อมูล การสกัดคุณลักษณะและการจำแนกภาพไว้ในขั้นตอนเดียวกัน ส่งผลให้สามารถวินิจฉัยภาวะเบาหวานขึ้นจอประสาทตาได้อย่างแม่นยำถึงร้อยละ 92.85 จากชุดข้อมูล Kaggle จำนวน 35,126 ภาพ แสดงให้เห็นถึงศักยภาพสูงของสถาปัตยกรรมในการนำไปใช้งานจริงในระบบช่วยวินิจฉัยทางการแพทย์

จากการที่กล่าวมานั้นเห็นได้ว่าแนวโน้มงานวิจัยในปัจจุบันมุ่งเน้นไปที่การใช้สถาปัตยกรรมที่มีขนาดเล็กและมีการประยุกต์ใช้เทคนิคการเรียนรู้แบบถ่ายโอนและการผสมผสานเทคนิคหลายรูปแบบเพื่อเพิ่มประสิทธิภาพและความแม่นยำในการวิเคราะห์ภาพทางการแพทย์ซึ่งเป็นพื้นฐานที่สำคัญต่อการพัฒนาระบบช่วยบุคลากรแพทย์ในการวินิจฉัยภาวะเบาหวานขึ้นจอประสาทตาในอนาคต อย่างไรก็ตามแม้ว่างานวิจัยที่กล่าวมานั้นสามารถให้ค่าความแม่นยำได้ค่อนข้างสูง แต่ก็ยังมีข้อจำกัดความยากในการจำแนกระยะที่มีความใกล้เคียงกัน เนื่องจากบางระยะของภาวะเบาหวานขึ้นจอประสาทตามีคุณลักษณะที่แตกต่างกันเพียงเล็กน้อย และบาง

งานวิจัยใช้ชุดข้อมูลขนาดใหญ่และใช้สถาปัตยกรรมขนาดใหญ่ แต่ก็ยังให้ค่าความแม่นยำในการจำแนกระยะภาวะเบาหวานไม่สูงมาก

ด้วยเหตุนี้งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาตัวจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการเพื่อจำแนกระดับความรุนแรงของโรคตั้งแต่ระยะไม่มีอาการ ระยะเริ่มต้น ระยะปานกลาง ระยะรุนแรง และระยะเจริญเติบโตของหลอดเลือดผิดปกติ ทั้งนี้ เพื่อเพิ่มประสิทธิภาพในการวินิจฉัยผลการของแพทย์และช่วยป้องกันภาวะเบาหวานขึ้นจอประสาทตาในระยะยาว

2. วิธีการทดลอง

การดำเนินการในงานวิจัยนี้มีเป้าหมายเพื่อเปรียบเทียบประสิทธิภาพของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการในการจำแนกรูปภาพจอประสาทตาที่มีภาวะเบาหวานขึ้นจอประสาทตา โดยมีการจัดเตรียมชุดข้อมูล (Dataset Collection) ข้อมูลภาพถ่ายจอประสาทตาที่ใช้ในงานวิจัยนี้ นำมาจากแหล่งข้อมูลจาก Kaggle ซึ่งถูกจัดแบ่งออกเป็น 5 ระยะตาม ระดับความรุนแรงของโรค ได้แก่ ไม่มีอาการ ระยะแรก ระยะปานกลาง ระยะรุนแรง และระยะเจริญเติบโตของหลอดเลือดผิดปกติ (Proliferative DR) จากนั้นนำข้อมูลที่ได้จัดเตรียมมาเพิ่มจำนวนข้อมูลโดยใช้เทคนิคเพิ่มข้อมูล (Data Augmentation) เนื่องจากข้อมูลแต่ละกลุ่มมีจำนวนไม่เท่ากัน ซึ่งเครื่องมือที่ใช้สำหรับการสร้างตัวจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา คือ เครื่องคอมพิวเตอร์พกพา รุ่น 11th Gen Intel(R) Core (TM) i5-11400H @ 2.70GHz 2.69 GHz RAM 8 GB NVIDIA GeForce RTX 3050 Laptop GPU และซอฟต์แวร์ที่ใช้คือ Python 3.9, TensorFlow 2.13, Keras 2.13.1

2.1 ชุดข้อมูล

ในการวิจัยนี้ได้ใช้ข้อมูลภาพถ่ายจอประสาทตาซึ่งได้มาจากแหล่งข้อมูลบน Kaggle ซึ่งชุดข้อมูลดั้งเดิมนั้นมีจำนวนทั้งหมด 3,662 ภาพ แบ่งออกเป็น 5 ระยะ แต่เนื่องจาก


แต่ละระยะของชุดข้อมูลดั้งเดิมนั้น มีจำนวนที่ไม่สมดุลกัน ซึ่งอาจส่งผลกระทบต่อความแม่นยำในการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาได้ ผู้วิจัยจึงได้เพิ่มจำนวนชุดข้อมูล โดยมีจำนวนทั้งหมดหลังจากเพิ่มจำนวนชุดข้อมูล จำนวน 5,000 ภาพ ซึ่งได้แบ่งชุดข้อมูลเป็น 2 ส่วน โดยให้การสุ่มแยกข้อมูล (Random Split) โดยแบ่งออกเป็นชุดข้อมูลสำหรับการเรียนรู้ (Training Set) จำนวน 4,000 ภาพ คิดเป็นร้อยละ 80 และชุดข้อมูลสำหรับการทดสอบตัวจำแนก จำนวน 1,000 ภาพ คิดเป็นร้อยละ 20 โดยในชุดข้อมูลการทดสอบได้มีการกำหนดจำนวนภาพให้เท่ากัน เพื่อความสมดุลของชุดข้อมูลโดยกำหนดจำนวนภาพ 200 ภาพต่อระยะ เพื่อให้ประสิทธิภาพของตัวจำแนกมีความแม่นยำมากที่สุดโดยรายละเอียดจำนวนชุดข้อมูลแสดงไว้ดังตารางที่ 1

ตารางที่ 1 จำนวนข้อมูลที่ใช้

ระยะ	จำนวนภาพดั้งเดิมทั้งหมด	จำนวนภาพสำหรับชุดข้อมูลการเรียนรู้	จำนวนภาพสำหรับชุดข้อมูลการทดสอบ
ระยะไม่มีอาการ	1,805	995	200
ระยะเริ่มต้น	370	990	200
ระยะปานกลาง	999	991	200
ระยะรุนแรง	193	465	200
ระยะเจริญเติบโตของหลอดเลือดผิดปกติ	295	559	200
รวมทั้งหมด	3,662	4,000	1,000

2.2 การสร้างตัวจำแนก

ในการสร้างตัวจำแนก (Model Generation) เพื่อจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาในการวิจัยนี้ ผู้วิจัยได้เลือกใช้การจำแนกประเภทของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยในการวิจัยได้เลือกใช้สถาปัตยกรรมดังกล่าว ทั้ง 5 สถาปัตยกรรม ได้แก่ DenseNet121, EfficientNetB0, EfficientNetB1, MobileNetV2 และ NasNetMobile ซึ่งเป็นสถาปัตยกรรม



รูปที่ 7 กระบวนการสร้างตัวจำแนกของการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา

ที่ผ่านการเรียนรู้เบื้องต้นด้วยชุดข้อมูล ImageNet แล้ว และสามารถนำมาปรับใช้กับปัญหาเฉพาะทาง โดยกระบวนการสร้างตัวจำแนกแบ่งออกเป็น 4 ขั้นตอน ได้แก่ 1) การเก็บรวบรวมข้อมูล 2) การเตรียมข้อมูลภาพ 3) การสร้างตัวจำแนกสำหรับการตรวจจ็ระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการ และ 4) การประเมินผลตัวจำแนกที่ได้พัฒนา ดังแสดงในรูปที่ 7

จากรูปที่ 7 เป็นการแสดงขั้นตอนของกระบวนการสร้างตัวจำแนกจากรูปภาพจอประสาทตาที่มีภาวะเบาหวานขึ้นจอประสาทตา ในขั้นตอนแรกเป็นการจัดเตรียมข้อมูลภาพถ่ายจอประสาทตาซึ่งได้มาจากแหล่งข้อมูลบน Kaggle ทั้งนี้ ภาพที่ได้จะต้องผ่านการตรวจสอบความครบถ้วน ความสมบูรณ์ ก่อนนำเข้าสู่กระบวนการประมวลผล เมื่อได้ข้อมูลภาพที่พร้อมใช้งานแล้วขั้นตอนถัดไปคือ การเตรียมภาพ (Preprocessing) ซึ่งรวมถึงการปรับขนาดภาพให้มีความเหมาะสมกับสถาปัตยกรรม โดยกำหนดขนาดรูปภาพให้เท่ากัน (224 × 224) นอกจากนี้ยังมีการประยุกต์ใช้เทคนิคเพิ่มจำนวนข้อมูล เพื่อเพิ่มความหลากหลายของข้อมูลฝึกเรียนรู้ เช่น การพลิกภาพในแนวนอน การหมุนภาพ และการซูมภาพบางส่วน และส่งเสริมให้แบบจำลองสามารถเรียนรู้ลักษณะของภาพได้ดียิ่งขึ้น หลังจากนั้นเป็นขั้นตอนของการสร้างตัวจำแนกโดยการนำสถาปัตยกรรมของโครงข่ายประสาทแบบสังวัตนาการมาประยุกต์ใช้ในการตรวจจ็ ซึ่งแต่ละสถาปัตยกรรมมีโครงสร้างภายในที่แตกต่างกันส่งผลให้ประสิทธิภาพในการจำแนกประเภทของภาพแตกต่างกันไปด้วย โดยมีการกำหนดค่าพารามิเตอร์สำหรับการสร้างตัวจำแนก ดังนี้

Optimization = Adam, ค่า Learning Rate = 0.001 และ กำหนดค่า Batch Size = 32 ดังนั้นการทดลองเปรียบเทียบ จึงมีความสำคัญ เพื่อหาสถาปัตยกรรมที่เหมาะสมที่สุดกับ ชุดข้อมูลที่ใช้ในการวิจัย ขั้นตอนถัดไปคือ การสร้างตัวจำแนก สำหรับตรวจจับระยะของภาวะเบาหวานขึ้นจอประสาทตา โดยใช้ข้อมูลจากชุดฝึก ร่วมกับการตรวจสอบในระหว่างฝึก ด้วยชุดข้อมูลทดสอบ โดยมีการกำหนดพารามิเตอร์ต่าง ๆ ซึ่งช่วยป้องกันปัญหาการจดจำชุดข้อมูลที่ใช้ในการเรียนรู้ มากเกินไปและเพิ่มความเสถียรในการฝึกเรียนรู้แบบจำลอง และขั้นตอนสุดท้ายคือ การประเมินประสิทธิภาพของ ตัวจำแนกที่สร้างขึ้น โดยใช้ค่าความแม่นยำเป็นตัวชี้วัดหลัก ในการเปรียบเทียบประสิทธิภาพของแต่ละสถาปัตยกรรม ที่ได้นำไปพัฒนาตัวจำแนกสำหรับการตรวจจับระยะของ ภาวะเบาหวานขึ้นจอประสาทตา

3. ผลการทดลองและอภิปรายผลการทดลอง

3.1 การประเมินและเปรียบเทียบประสิทธิภาพของ สถาปัตยกรรม

ในการวิจัยนี้ได้ทำการประเมินประสิทธิภาพของ สถาปัตยกรรมโครงข่ายประสาทเทียมแบบสังวัตนาการ ทั้งหมด 5 สถาปัตยกรรม ได้แก่ DenseNet121, EfficientNetB0, EfficientNetB1, MobileNetV2 และ NasNetMobile โดยใช้ ค่าชี้วัดสำหรับประเมินประสิทธิภาพของตัวจำแนกที่ได้พัฒนา คือ ค่าความแม่นยำและค่าความสูญเสีย (Loss) และกำหนด จำนวนรอบการเรียนรู้ (Epochs) ที่ 100 รอบเท่ากัน เพื่อ เปรียบเทียบผลการเรียนรู้และการจำแนกรูปภาพจอประสาทตา ที่มีภาวะเบาหวานขึ้นจอประสาทตา การเปรียบเทียบผลลัพธ์ของ แต่ละสถาปัตยกรรม การทดลองแบ่งออกเป็น 2 ครั้ง ได้แก่

ตารางที่ 2 แสดงข้อมูลผลการทดลองครั้งที่ 1 ซึ่งใช้ สถาปัตยกรรมเดิมโดยยังไม่มี การปรับแต่งสำหรับการสร้างตัว จำแนกภาวะเบาหวานขึ้นจอประสาทตา จากผลการทดลอง จะเห็นว่าแบบจำลองทั้ง 5 สถาปัตยกรรม ให้ค่าความแม่นยำ ที่ค่อนข้างต่ำและมีค่าความสูญเสียสูง จึงได้ทำการทดลอง ครั้งที่ 2 โดยมีการเพิ่มชุดข้อมูลและการเพิ่มชั้น Dropout แสดงผลการทดลองดังตารางที่ 3

ตารางที่ 2 ผลการทดลองครั้งที่ 1 ไม่ใช่เทคนิคการปรับแต่ง (Baseline) ของ 5 สถาปัตยกรรม สำหรับการสร้าง ตัวจำแนกภาวะเบาหวานขึ้นจอประสาทตา

สถาปัตยกรรม	ครั้งที่ 1	
	ค่าความแม่นยำ	ค่าความสูญเสีย
DenseNet121	47.70	4.3657
EfficientNetB0	45.40	4.7523
EfficientNetB1	47.10	4.1889
MobileNetV2	38.60	5.9873
NasNetMobile	33.40	3.5804

ตารางที่ 3 ผลการทดลองครั้งที่ 2 การนำเทคนิคการเพิ่ม ข้อมูล และการลดความซับซ้อนของตัวจำแนก ด้วยการเพิ่มชั้น Dropout = 0.5 ของ 5 สถาปัตยกรรม สำหรับการสร้างตัวจำแนกภาวะ เบาหวานขึ้นจอประสาทตา

สถาปัตยกรรม	ครั้งที่ 2	
	ค่าความแม่นยำ	ค่าความสูญเสีย
DenseNet121	83.07	0.5959
EfficientNetB0	99.25	0.0239
EfficientNetB1	98.05	0.0248
MobileNetV2	86.90	1.6165
NasNetMobile	75.70	1.5220

จากผลการทดลองในตารางที่ 3 ซึ่งแสดงข้อมูลการ ทดลองครั้งที่ 2 โดยในครั้งนี้ได้มีการเรียนรู้กับชุดข้อมูล ใหม่ที่ได้เพิ่มจำนวนและการเพิ่มชั้น Dropout โดยกำหนด ค่า 0.5 ของสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบ สังวัตนาการ จำนวน 5 สถาปัตยกรรม ได้แก่ DenseNet121, EfficientNetB0, EfficientNetB1, MobileNetV2 และ NasNetMobile ในการจำแนกภาพจอประสาทตา

ผลการทดลองแสดงให้เห็นได้ว่าสถาปัตยกรรมที่ ให้ค่าความแม่นยำสูงที่สุดคือ EfficientNet โดยเฉพาะ สถาปัตยกรรม EfficientNetB0 และ EfficientNetB1 ซึ่ง ในการทดสอบครั้งที่ 1 ที่ยังไม่มีการปรับแต่งสถาปัตยกรรม



รูปที่ 8 ผลการสร้างตัวจำแนกของชุดข้อมูลการเรียนรู้สำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาของสถาปัตยกรรม EfficientNetB0

ทั้งสองให้ค่าความแม่นยำเพียงร้อยละ 45.40 และ 47.10 ตามลำดับ พร้อมกับมีค่าความสูญเสียสูงถึง 4.7523 และ 4.1889 ซึ่งแสดงให้เห็นว่าแบบจำลองที่สร้างขึ้นนั้นยังไม่สามารถสกัดคุณลักษณะที่สำคัญของภาพจอประสาทตาได้ดี แต่เมื่อได้มีการนำเทคนิคการเพิ่มจำนวนข้อมูลและการลดความซับซ้อนของตัวจำแนกด้วยการเพิ่มชั้น Dropout โดยกำหนดค่า 0.5 เข้ามาประยุกต์ใช้ในการทดสอบครั้งที่ 2 ผลลัพธ์ได้เปลี่ยนแปลงไปในทางที่ดีขึ้นอย่างเห็นได้ชัด โดยเฉพาะ EfficientNetB0 ที่ให้ค่าความแม่นยำสูงถึงร้อยละ 99.25 และ EfficientNetB1 ทำได้ร้อยละ 98.05 ในขณะที่ค่าความสูญเสียลดลงจนเหลือเพียง 0.0239 และ 0.0248 ตามลำดับ ซึ่งถือเป็นค่าความคลาดเคลื่อนที่ต่ำมากเมื่อเทียบกับสถาปัตยกรรมอื่น ๆ ในชุดการทดลองเดียวกัน โดยผลการสร้างตัวจำแนกของชุดข้อมูลการเรียนรู้สำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาของสถาปัตยกรรม EfficientNetB0 แสดงดังรูปที่ 8

ซึ่งเหตุผลหลักที่ทำให้ผลลัพธ์ในการสร้างตัวจำแนกภาวะเบาหวานขึ้นจอประสาทตาครั้งที่ 2 มีประสิทธิภาพสูงชันสามารถอธิบายได้ด้วยหลักการทำงานของ 2 เทคนิคที่นำมาใช้ เทคนิคที่ 1 คือ การเพิ่มจำนวนข้อมูล การที่ค่าความแม่นยำในครั้งที่ 1 อยู่ในระดับต่ำ สรุปลงได้ว่าเกิดจากชุดข้อมูลตั้งต้นอาจมีความหลากหลายไม่เพียงพอ ทำให้สถาปัตยกรรมไม่สามารถเรียนรู้คุณลักษณะที่สำคัญมากพอและมีโอกาสที่จะจดจำ

ข้อมูลภาพที่มีลักษณะคล้ายกันจนไม่สามารถเรียนรู้ข้อมูลใหม่ได้อย่างถูกต้อง ฉะนั้นการเพิ่มข้อมูลโดยการปรับเปลี่ยนภาพในรูปแบบต่าง ๆ เช่น การหมุนภาพ การปรับขนาด หรือการเปลี่ยนมุมมองของภาพ สามารถช่วยสร้างความหลากหลายให้กับข้อมูลและส่งผลให้สถาปัตยกรรมพยายามที่จะดึงคุณลักษณะเด่นชัดของความผิดปกติของภาพถ่ายจอประสาทตาแทนที่จะจดจำบางคุณสมบัติ ส่งผลให้ตัวจำแนกที่สร้างขึ้นนั้นสามารถจำแนกภาพถ่ายจอประสาทตาได้แม่นยำและให้ค่าความแม่นยำสูงขึ้น แต่ทั้งนี้การเพิ่มชุดข้อมูลสำหรับข้อมูลภาพถ่ายจอประสาทตามีโอกาสที่ทำให้ชุดข้อมูลนั้นมีรูปแบบที่ซ้ำกัน ต่อมาเทคนิคที่ 2 คือ การเพิ่มชั้น Dropout โดยกำหนดค่าอยู่ที่ 0.5 ซึ่งทำหน้าที่เป็นตัวลดความซับซ้อน (Regularization) ภายในโครงข่ายประสาทเทียม ในสถาปัตยกรรมที่มีความซับซ้อนสูงอย่างการเรียนรู้เชิงลึกมักเกิดปัญหาที่เซลล์ประสาทบางตัวทำงานพึ่งพากันมากเกินไป ฉะนั้นการเพิ่มชั้น Dropout นั้นจะทำการสุ่มตัดการเชื่อมต่อของเซลล์ประสาท (Node) ออกบางส่วนในระหว่างการเรียนรู้ชุดข้อมูล โดยกระบวนการนี้เป็นการบังคับให้เซลล์ประสาทที่เหลืออยู่ต้องเรียนรู้ที่จะสกัดคุณลักษณะที่สำคัญอย่างอิสระมากขึ้น ทำให้ผลลัพธ์ที่ได้คือ แบบจำลองที่มีความสามารถในการเรียนรู้รูปแบบทั่วไปได้ดีขึ้น ซึ่งแสดงออกมาผ่านค่าความสูญเสีย โดยจะเห็นได้ว่าการทดสอบครั้งที่ 2 นั้นค่าความสูญเสียมีค่าที่ลดลงเข้าใกล้ 0 อย่างเห็นได้ชัด แสดงให้เห็นว่าตัวจำแนกที่สร้างขึ้นนั้นสามารถทำนายได้ถูกต้องมากขึ้นและมีความผิดพลาดน้อยเมื่อต้องเจอกับชุดข้อมูลทดสอบที่ไม่เคยเห็นมาก่อน

นอกจากนี้เมื่อเปรียบเทียบทั้ง 5 สถาปัตยกรรมจะเห็นได้ว่าแม้ MobileNetV2 และ NasNetMobile จะมีพัฒนาการที่ดีขึ้นเช่นกันในครั้งที่ 2 แต่ยังคงมีค่าความสูญเสียที่สูงกว่า EfficientNet อย่างเห็นได้ชัด จากผลการทดลองนี้แสดงให้เห็นว่าสถาปัตยกรรมของ EfficientNet มีความเหมาะสมและมีประสิทธิภาพสูงสุดสำหรับการจำแนกภาพถ่ายจอประสาทตาชุดข้อมูลนี้ โดยสามารถดึงประสิทธิภาพจากการเพิ่มชุดข้อมูลและการเพิ่มชั้น Dropout กำหนดค่า 0.5 ออกมาใช้ได้อย่างเต็มที่

	precision	recall	f1-score	support
1 No DR	0.7500	0.8700	0.8056	200
2 Mild	0.8253	0.6850	0.7486	200
3 Moderate	0.8125	0.7150	0.7606	200
4 Proliferate_DR	0.7706	0.8900	0.8260	200
5 Severe	0.9282	0.9050	0.9165	200
accuracy			0.8130	1000
macro avg	0.8173	0.8130	0.8115	1000
weighted avg	0.8173	0.8130	0.8115	1000

รูปที่ 9 ผลลัพธ์การทดสอบกับชุดข้อมูลทดสอบ


3.2 การทดสอบแบบจำลองสำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา

ในหัวข้อนี้อธิบายถึงผลลัพธ์การทดสอบหลังจากที่ได้สร้างตัวจำแนกสำหรับจำแนกภาวะเบาหวานขึ้นจอประสาทตา โดยผลลัพธ์การทดสอบกับชุดข้อมูลทดสอบแสดงดังรูปที่ 9

จากรูปที่ 9 แสดงให้เห็นได้ว่าตัวจำแนกที่สร้างขึ้นสำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา มีประสิทธิภาพในการจำแนก โดยให้ค่าความแม่นยำสูงถึง 81.30 เมื่อนำตัวจำแนกที่สร้างขึ้นมาทดสอบกับข้อมูลทดสอบที่มีการแบ่งชุดข้อมูลสำหรับการทดสอบในแต่ละระดับความรุนแรง จำนวนละ 200 ภาพของแต่ละภาวะเบาหวานขึ้นจอประสาทตาพบว่าตัวจำแนกของการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาให้ค่า F1-score อยู่ที่ 81.15 ซึ่งแสดงให้เห็นถึงความสามารถในการจำแนกประเภทที่ครอบคลุมทุกระยะของภาวะเบาหวานขึ้นจอประสาทตา และตัวจำแนกนั้นยังให้ค่าความแม่นยำ (Precision) สูงถึง 92.82 สำหรับระยะรุนแรง และมีค่าการเรียกคืน (Recall) สูงถึง 89.00 สำหรับระยะเจริญเติบโตของหลอดเลือดผิดปกติ แสดงให้เห็นว่าตัวจำแนกที่สร้างขึ้นนั้น สามารถจำแนกได้ในระยะที่เป็นอันตราย ซึ่งเป็นส่วนสำคัญในการคัดกรองทางการแพทย์เพื่อลดความเสี่ยงต่อการสูญเสียการมองเห็นของผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตา

3.3 การทำนายและประเมินผลแบบจำลองภาวะเบาหวานขึ้นจอประสาทตา

จากผลการทดลองทั้งหมดพบว่าสถาปัตยกรรมของ EfficientNetB0 ให้ผลลัพธ์ที่ดีที่สุดในการจำแนกระยะของ



รูปที่ 10 ผลการทำนายจาก EfficientNetB0

ภาวะเบาหวานขึ้นจอประสาทตา โดยมีค่าความแม่นยำสูงสุด โดยอยู่ที่ร้อยละ 99.25 และค่าความสูญเสียที่ 0.0239 หลังการใช้ชุดข้อมูลที่มีการเพิ่มจำนวนโดยการเพิ่มข้อมูลและการเพิ่มชั้น Dropout ในสถาปัตยกรรม ซึ่งส่งผลให้สถาปัตยกรรมมีความสามารถในการเรียนรู้ลักษณะเฉพาะของภาพทางการแพทย์ได้อย่างแม่นยำและมีประสิทธิภาพเพื่อตรวจสอบประสิทธิภาพของตัวจำแนกที่ได้พัฒนา ผู้วิจัยจึงใช้สถาปัตยกรรม EfficientNetB0 ที่ผ่านการฝึกฝนแล้วนำมาทดสอบประเมินผลด้วยภาพจากชุดทดสอบ ซึ่งไม่เคยถูกใช้ในการฝึกฝนหรือการตรวจสอบก่อนหน้านี้ เพื่อทดสอบความสามารถของตัวจำแนกที่พัฒนาในการจำแนกข้อมูลที่ไม่เคยเห็นมาก่อน (Generalization) ดังแสดงในรูปที่ 10

จากผลการทดสอบที่ในรูปที่ 10 สามารถจำแนกภาพจอประสาทตาได้ อย่างถูกต้องว่าเป็น Class 5 คือ ระยะเจริญเติบโตของหลอดเลือดผิดปกติโดยตัวจำแนกที่ได้พัฒนาให้ค่าความมั่นใจ (Confidence) ในการจำแนกสูงถึงร้อยละ 99.41 ซึ่งพบว่าตัวจำแนกที่พัฒนาขึ้นมีความแม่นยำในการตัดสินใจแม้ในภาพที่ไม่เคยเห็นมาก่อน

3.4 การเปรียบเทียบผลการทดลองแบบจำลองสำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตากับงานวิจัยที่เกี่ยวข้อง

เพื่อให้เห็นถึงประสิทธิภาพของแบบจำลองที่นำเสนอในงานวิจัยนี้ ผู้วิจัยจึงได้ทำการเปรียบเทียบผลการทดลองกับงานวิจัยที่เกี่ยวข้องสำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้การเรียนรู้เชิงลึก รวมถึงการเปรียบเทียบกับผลการทดลองในงานวิจัยนี้ ดังแสดงในตารางที่ 4

ตารางที่ 4 การเปรียบเทียบผลการทดลองการสร้างแบบจำลองการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตากับงานวิจัยที่เกี่ยวข้อง

งานวิจัย	สถาปัตยกรรม	จำนวนภาพ	ค่าความแม่นยำ	ค.ศ.
[9]	MobileNetV02	3,662	97%	2022
[11]	DenseNet 121	APTOS 3,662 DDR 13,673	APTOS 98.36% DDR 79.67%	2023
[8]	AlexNet, ResNet50, GoogleNet	4,308	89.7–94.3%	2024
[12]	ResNet, GoogleNet, AlexNet, VGGNet	35,126	97.60% (VGGNet)	2024
[13]	Inception ResNetV2, VGG16, VGG19, DenseNet121 MobileNetV2, EfficientNet2L	2,631	96.61% (Inception ResNetV2), 94.20% (DenseNet121)	2025

จากผลการทดลองค่าความแม่นยำของแบบจำลองที่นำเสนอไว้ในงานวิจัยนี้ด้วยสถาปัตยกรรม Efficient-NetB0 พบว่าให้ค่าความแม่นยำที่สูงขึ้นเมื่อเปรียบเทียบกับงานวิจัยที่มีก่อนหน้า และเมื่อนำไปเปรียบเทียบกับงานวิจัยดังตารางที่ 4 จะเห็นได้ว่างานวิจัยใน ค.ศ. 2022 [9] และงานวิจัยใน ค.ศ. 2025 [13] ซึ่งใช้สถาปัตยกรรม MobileNetV02 และ InceptionResNetV2 ที่ให้ค่าความแม่นยำอยู่ที่ร้อยละ 97 และร้อยละ 96.61 ตามลำดับ พบว่างานวิจัยนี้ให้ค่าความแม่นยำที่สูงขึ้น แม้สถาปัตยกรรมในงานวิจัย [13] จะมีการทดลองสร้างแบบจำลองด้วยสถาปัตยกรรมที่หลากหลาย เช่น VGG16 และ DenseNet121

นอกจากนี้ในงานวิจัย ค.ศ. 2023 [11] ที่มีการทดลองบนชุดข้อมูล APTOS โดยใช้สถาปัตยกรรม Dense-Net121

และให้ค่าความแม่นยำได้สูงถึงร้อยละ 98.36 นั้น ผลการทดลองในงานวิจัยนี้ยังสามารถให้ค่าความแม่นยำเพิ่มขึ้นร้อยละ 0.89 ซึ่งแสดงถึงความสามารถในการสกัดคุณลักษณะของภาพถ่ายจอประสาทตา ซึ่งสอดคล้องกับงานวิจัยใน ค.ศ. 2024 [8] และ [12] โดยเฉพาะในงานวิจัยของ Jabbar [12] ที่มีการใช้จำนวนภาพ 35,126 ภาพ แต่ยังคงได้ค่าความแม่นยำอยู่ที่ 97.60 ด้วยสถาปัตยกรรม VGGNet ซึ่งการที่สถาปัตยกรรม EfficientNetB0 ในงานวิจัยนี้สามารถให้ค่าความแม่นยำที่สูงนั้น สามารถสรุปได้ว่าการเพิ่มข้อมูลโดยการปรับเปลี่ยนภาพในรูปแบบต่าง ๆ และการเพิ่มขึ้น Dropout โดยกำหนดค่า 0.5 เข้ามาประยุกต์ใช้ในงานวิจัยนี้สามารถจำแนกภาวะเบาหวานขึ้นจอประสาทตาได้อย่างแม่นยำมากยิ่งขึ้นและสามารถนำไปประยุกต์ใช้สำหรับการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาในอนาคต

4. สรุปผลการทดลอง

การจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตาโดยใช้การเรียนรู้เชิงลึกแสดงให้เห็นว่าการนำเทคนิคการเรียนรู้เชิงลึกมาประยุกต์ใช้กับงานด้านการแพทย์ โดยเฉพาะการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา มีความเป็นไปได้และให้ผลลัพธ์ที่มีประสิทธิภาพ จากการเปรียบเทียบสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสั่งต้นการ จำนวน 5 สถาปัตยกรรม พบว่า EfficientNetB0 สามารถทำงานได้อย่างมีประสิทธิภาพมากที่สุด โดยให้ความถูกต้องมากที่สุดและมีค่าความสูญเสียต่ำกว่าสถาปัตยกรรมอื่น ๆ ซึ่งเหตุผลที่ทำให้สถาปัตยกรรม EfficientNet ให้ค่าความแม่นยำสูงสุดนั้น เป็นผลจากโครงสร้างของสถาปัตยกรรมที่ถูกออกแบบโดยใช้เทคนิคการปรับขนาดแบบผสมผสาน (Compound Scaling) ซึ่งเป็นการเพิ่มมิติข้อมูล (Dimension) ของการเชื่อมต่อภายในสถาปัตยกรรม เช่น การเพิ่มความลึกของชั้น (Depth) ให้มีจำนวนที่เหมาะสมไม่ลึกจน Vanishing Gradient เล็กกลงจนทำให้น้ำหนัก (Weight) กลายเป็น 0 นอกจากนั้นความกว้าง (Width) ของจำนวนของคุณลักษณะและความละเอียดของภาพ (Resolution) ซึ่ง EfficientNet จะสร้างความสมดุล

เหล่านี้ให้แบบจำลองมีขอบเขตการเรียนรู้ที่เหมาะสมต่อการสกัดคุณสมบัติที่สำคัญ ส่งผลให้สถาปัตยกรรม EfficientNetB0 สามารถประมวลผลข้อมูลภาพทางการแพทย์ที่มีความซับซ้อนได้อย่างแม่นยำ และในงานวิจัยนี้ได้การประยุกต์ใช้เทคนิคเพิ่มเติม เช่น การเพิ่มข้อมูลด้วยการพลิก หมุน หรือซูมภาพ รวมถึงการเพิ่มชั้น Dropout เพื่อป้องกันการเรียนรู้ที่เกินจำเป็น ซึ่งล้วนมีส่วนช่วยในการเพิ่มประสิทธิภาพการทำงานของสถาปัตยกรรมต่อความหลากหลายของข้อมูลและภาพที่ไม่เคยพบมาก่อน ซึ่งปัจจัยเหล่านี้ทำให้ตัวจำแนกที่พัฒนาขึ้นสามารถลดความผิดพลาดในการทำนาย

นอกจากนี้ตัวจำแนกที่พัฒนาขึ้นสามารถนำไปประยุกต์ใช้เป็นเครื่องมือช่วยคัดกรองผู้ป่วยเบื้องต้นได้ โดยเฉพาะในพื้นที่ที่มีข้อจำกัดด้านบุคลากรและเครื่องมือทางการแพทย์ ซึ่งจะช่วยลดภาระของจักษุแพทย์และเพิ่มโอกาสให้ผู้ป่วยเข้าถึงการตรวจวินิจฉัยได้อย่างรวดเร็ว อีกทั้งผลลัพธ์จากการศึกษานี้ยังสามารถนำไปต่อยอดสู่การพัฒนาเครื่องมืออัจฉริยะในงานสุขภาพดิจิทัล และการแพทย์ทางไกลที่ตอบสนองต่อความต้องการของระบบสาธารณสุขในอนาคต อย่างไรก็ตามในงานวิจัยครั้งนี้ยังมีข้อจำกัดบางประการ โดยเฉพาะการใช้ข้อมูลจากฐานข้อมูลเดียว ซึ่งอาจไม่สะท้อนความหลากหลายของผู้ป่วยในสภาพจริงได้อย่างครอบคลุม นอกจากนี้ชุดข้อมูลที่ได้นามานั้นมีความไม่สมดุล เนื่องจากแต่ละระยะของภาวะเบาหวานขึ้นจอประสาทตานั้นมีจำนวนไม่เท่ากันและความแตกต่างของคุณภาพของภาพถ่าย ดังนั้นแนวทางการวิจัยในอนาคตควรให้ความสำคัญกับการใช้ข้อมูลจากหลายแหล่งและการเก็บข้อมูลจริงจากโรงพยาบาลเพื่อการจำแนกที่แม่นยำและสามารถนำไปใช้งานจริงได้มากยิ่งขึ้น โดยสรุปงานวิจัยนี้สามารถยืนยันถึงประสิทธิภาพของการประยุกต์ใช้สถาปัตยกรรม EfficientNetB0 ในการจำแนกระยะของภาวะเบาหวานขึ้นจอประสาทตา และให้การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกกลายเป็นอีกหนึ่งเครื่องมือสำคัญในการสนับสนุนการวินิจฉัยทางการแพทย์ในอนาคต ซึ่งจะช่วยเพิ่มประสิทธิภาพในการตรวจรักษา ลดภาระงานบุคลากรทางการแพทย์ และส่งเสริมคุณภาพชีวิตของผู้ป่วยได้อย่างยั่งยืน

เอกสารอ้างอิง

- [1] International Diabetes Federation. IDF Diabetes Atlas, 11th Edition. [Online]. (2025), Available: <https://diabetesatlas.org>.
- [2] A. Skouta, A. Elmoufidi, S. Jai-Andaloussi, and O. Ouchetto, "Deep learning for diabetic retinopathy assessments: A literature review," *Multimedia Tools and Applications*, vol. 82, no. 27, pp. 41701–41766, Apr. 2023, doi: 10.1007/s11042-023-15110-9.
- [3] K. Chung and H. Yoo, "Edge computing health model using P2P-based deep neural networks," *Peer-to-Peer Networking and Applications*, vol. 13, no. 2, pp. 694–703, 2020, doi: 10.1007/s12083-019-00738-y.
- [4] A. Ayeni, "Convolutional Neural Network (CNN): The architecture and applications," *Applied Journal of Physical Science*, vol. 4, no. 4, pp. 42–50, 2022, doi: 10.31248/AJPS2022.085
- [5] S. Pachamuthu, K. M. Umamaheswari, M. Sivaram, C. Jain, and D. Bagchi, "Classification of different stages of diabetic retinopathy using convolutional neural networks", in *2021 2nd International Conference on Computation, Automation and Knowledge Management (ICCAKM)*, 2021, pp. 59–64, doi: 10.1109/iccakm 50778.2021.9357735
- [6] I. Al-Kamachy, R. Hassanpour, and R. Choupani, "Classification of diabetic retinopathy using pre-trained deep learning models", *arXiv preprint arXiv:2403.19905*, 2024, doi: <https://doi.org/10.48550/arXiv.2403.19905>.
- [7] P. Enkvetchakul, O. Surinta, and S. Noppitak, "Effective data resampling and meta-learning convolutional neural networks for diabetic



- retinopathy recognition,” *ICIC Express Letters, Part B: Applications*, vol. 13, pp. 939–948, 2022, doi: 10.24507/icicelb.13.09.939.
- [8] I. Arias-Serrano, P. A. Vel´asquez-L´opez, L. N. Avila-Briones, F. C. Laurido-Mora, F. Villalba-Meneses, A. Tirado-Espin, J. Cruz-Varela, and D. Almeida-Gal´arraga, “Artificial intelligence based glaucoma and diabetic retinopathy detection using MATLAB—Retrained AlexNet convolutional neural network,” *F1000Research*, vol. 12, pp. 14, 2024, doi: 10.12688/f1000research.122288.2.
- [9] A.M.Pamadi, A. Ravishankar, P.A.Nithya, G. Jahnvi, and S. Kathavate, “Diabetic retinopathy detection using mobilenetv2 architecture”, in *2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)*, 2022, pp. 1–5, doi: 10.1109/icstsn 53084.2022.9761289.
- [10] D. Muthusamy and P. Palani, “Deep learning model using classification for diabetic retinopathy detection: An overview,” *Artificial Intelligence Review*, vol. 57, no. 7, pp. 185, 2024, doi: 10.1007/s10462-024-10806-2.
- [11] G. Alwakid, W. Gouda, M. Humayun, and N. Z. Jhanjhi, “Deep learning-enhanced diabetic retinopathy image classification,” *Digital Health*, vol. 9, 2023, Art. no. 20552076231194942, doi: 10.1177/20552076231194942.
- [12] A. Jabbar, S. Naseem, J. Li, T. Mahmood, M. K. Jabbar, A. Rehman, and T. Saba, “Deep transfer learning-based automated diabetic retinopathy detection using retinal fundus images in remote areas,” *International Journal of Computational Intelligence Systems*, vol. 17, no. 1, pp. 135, 2024, doi: 10.1007/s44196-024-00520-w.
- [13] S. Guefrachi, A. Echtioui, and H. Hamam, “Diabetic retinopathy detection using deep learning multistage training method,” *Arabian Journal for Science and Engineering*, vol. 50, no. 2, pp. 1079–1096, 2025, doi: 10.1007/s13369-024-09137-9.