



การประมวลผลภาพโรคต้อหิน โดยใช้เทคนิคการเรียนรู้เชิงลึก

Deep Learning-Based Image Analysis for Glaucoma Diagnosis

กัญญาณี นามเอี่ยม*

Kanyanee Nameam

ปริญญา นาโท**

Parinya Natho

Received : July 7, 2025

Revised : September 4, 2025

Accepted : October 6, 2025

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สำหรับการจำแนกโรคต้อหินจากภาพถ่ายจอประสาทตาโดยอัตโนมัติ กลุ่มตัวอย่างประกอบด้วยภาพถ่ายดวงตาจำนวน 1,000 ภาพ แบ่งเป็นกลุ่มปกติและกลุ่มที่มีภาวะต้อหิน โดยรวบรวมจากฐานข้อมูลออนไลน์และจากผู้รับบริการตรวจสุขภาพที่โรงพยาบาลราชธานี ราชนะ จังหวัดพระนครศรีอยุธยาโมเดลที่ใช้ในการวิจัยเป็นโครงสร้าง CNN แบบ 5 ชั้น ออกแบบให้เหมาะสมกับข้อมูลภาพสี พร้อมขั้นตอนการเตรียมข้อมูล ได้แก่ การปรับขนาดภาพ การแปลงเป็นภาพขาวดำ และการเสริมข้อมูล เพื่อเพิ่มความหลากหลายของชุดฝึก โดยประเมินประสิทธิภาพโมเดลด้วยเทคนิค K-Fold Cross Validation จำนวน 5 รอบ บนชุด ชุดข้อมูลสำหรับการฝึกฝนข้อมูลและชุดสำหรับการตรวจสอบ จำนวน 800 ภาพ ผลการวิจัยพบว่า ได้ค่า Accuracy อยู่ที่ 87% และเมื่อทดสอบกับชุดข้อมูลใหม่ จำนวน 200 ภาพ ผลการวิจัยพบว่าโมเดลสามารถจำแนกโรคต้อหินได้อย่างมีประสิทธิภาพ โดยมีค่าความ Accuracy เท่ากับ 94.0%, ค่า Precision เท่ากับ 93.1%, ค่า Recall เท่ากับ 95.0%, ค่า F1-Score เท่ากับ 94.0% และค่า AUC เท่ากับ 0.98 แสดงถึงความแม่นยำและความสมดุลในการจำแนกภาพระหว่างกลุ่มปกติและกลุ่มที่มีภาวะต้อหิน ซึ่งสะท้อนให้เห็นว่าประสิทธิภาพของโมเดลสามารถนำไปประยุกต์ใช้จริง โดยเฉพาะในสถานพยาบาลที่มีข้อจำกัดด้านทรัพยากรและบุคลากรเฉพาะทาง

*นักศึกษาลัทธิศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการนวัตกรรมดิจิทัล

คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

Master's Degree Student in Digital Innovation Management, Faculty of Business Administration and Information Technology, Rajamangala University of Technology Suvarnabhumi
(Corresponding Author) e-mail: 266387322001-st@rmutsb.ac.th

**อาจารย์ประจำหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการนวัตกรรมดิจิทัล

คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

Lecturer in the Master of Science Program in Digital Innovation Management, Faculty of Business Administration and Information Technology, Rajamangala University of Technology Suvarnabhumi

คำสำคัญ : การจำแนกประเภท / ต้อหิน / การเรียนรู้เชิงลึก / โครงข่ายประสาทเทียม / การประมวลผลภาพ

ABSTRACT

This research aims to develop a Convolutional Neural Network (CNN) model for the automatic classification of glaucoma from retinal fundus images. The dataset consisted of 1,000 eye images, divided into normal and glaucoma groups, collected from online databases and patients at Rajthanee Hospital, Rojana, Phra Nakhon Si Ayutthaya Province. The proposed model is a 5-layer CNN architecture designed to suit color image data. The data preprocessing steps included image resizing, grayscale conversion, and data augmentation to increase the diversity of the training dataset. Model performance was evaluated using 5-fold cross-validation on a training and validation set of 800 images. The results showed that the model achieved an accuracy of 87% during training. When tested with a new dataset of 200 images, the model demonstrated high performance, achieving an accuracy of 94.0%, precision of 93.1%, recall of 95.0%, F1-score of 94.0%, and an AUC of 0.98. These results indicate the model's strong accuracy and balance in distinguishing between normal and glaucoma images, suggesting that the developed CNN model can be effectively applied in real-world scenarios, particularly in healthcare facilities with limited resources and specialized personnel.

Keywords : Classification / Glaucoma / Deep Learning / Neural Networks / Image Processing

บทนำ

โรคต้อหิน (Glaucoma) เป็นโรคที่ส่งผลกระทบต่อการมองเห็น โดยเฉพาะในผู้ที่ไม่ได้รับการวินิจฉัยและรักษาอย่างทันที่ (Tham et al., 2014) โดยปกติมักเกิดจากความผิดปกติด้านการระบายน้ำในลูกตา ส่งผลให้ความดันในลูกตาสูงขึ้น และทำให้เส้นประสาทจอประสาทตา (Optic Nerve) เสื่อมลงหากไม่ได้รับการรักษาที่เหมาะสม แม้จะพบบ่อยในผู้สูงอายุ แต่ในบางงานวิจัยที่ศึกษาเด็กหรือวัยรุ่นซึ่งมีภาวะ Juvenile-onset glaucoma พบว่าอาจคิดเป็นประมาณ 15% ของผู้ป่วยในภาคใต้ของอินเดีย (Ehrlich et al., 2024) อย่างไรก็ตาม ในการสำรวจประชากรทั่วไป (ไม่จำกัดเฉพาะกลุ่มอายุน้อย) เช่น Chennai Glaucoma Study พบว่าในกลุ่มอายุ 40 ปีขึ้นไป มีอัตราการพบ POAG ประมาณ 1.62% ในพื้นที่ชนบท และ 3.51% ในพื้นที่เมือง (Vijaya et al., 2008; George et al., 2003)

จากการศึกษาพบว่าโรคต้อหินมีอัตราการเกิดสูงในกลุ่มผู้สูงอายุ โดยในสหรัฐอเมริกา มีอัตราการเกิดโรคต้อหินในผู้ที่มีอายุเกิน 40 ปีอยู่ที่ 2.56% (Ehrlich et al., 2024) และมีแนวโน้มที่จะเพิ่มสูงขึ้นในกลุ่มผู้สูงอายุ

แต่ก็ยังพบว่าผู้ป่วยต้อหินในกลุ่มผู้ที่อายุน้อยกว่า 40 ปี ซึ่งสามารถทำให้การวินิจฉัยและการรักษาเป็นไปอย่างทันท่วงทีในกลุ่มนี้ยังเป็นความท้าทายสำคัญแม้ว่าจะมีการพัฒนาเครื่องมือทางการแพทย์ที่ช่วยในการวินิจฉัยโรคต้อหิน แต่ยังคงพบว่าผู้ป่วยจำนวนมากไม่ได้รับการตรวจเนื่องจากขาดความตระหนักรู้หรือขาดทรัพยากรในการดูแลสุขภาพที่เพียงพอ ดังนั้น การพัฒนาเทคนิคที่สามารถวินิจฉัยโรคต้อหินได้โดยอัตโนมัติและแม่นยำ จะช่วยลดภาระของบุคลากรทางการแพทย์และเพิ่มประสิทธิภาพในการคัดกรองโรค ในประเทศไทย โรคต้อหินถือเป็นหนึ่งปัญหาสำคัญทางสาธารณสุขที่นำไปสู่การสูญเสียการมองเห็นอย่างถาวร โดยเฉพาะในกลุ่มประชากรผู้สูงอายุ การศึกษาของ (Thongthong, 2021) วิเคราะห์ข้อมูลย้อนหลังของผู้ป่วยโรคต้อหินที่เข้ารับการรักษาในโรงพยาบาลอ้างอิง พบว่า ความชุกของภาวะตาบอดจากโรคต้อหินอยู่ที่ร้อยละ 23.8 โดยมีปัจจัยเสี่ยงสำคัญได้แก่ อายุที่เพิ่มขึ้น เพศชาย โรคความดันโลหิตสูง โรคเบาหวาน ไขมันในเลือดสูง และโรคหัวใจและหลอดเลือด ซึ่งข้อมูลดังกล่าวสะท้อนให้เห็นถึงความจำเป็นในการส่งเสริมการตรวจคัดกรองและเฝ้าระวังโรคต้อหินในประชากรกลุ่มเสี่ยงอย่างต่อเนื่อง เพื่อป้องกันภาวะแทรกซ้อนรุนแรงในระยะยาว นอกจากนี้ การศึกษาจากโรงพยาบาลเชียงใหม่ประชานุเคราะห์พบว่า ผู้ป่วยที่เข้ารับการรักษาตัดต่อกระจกมีอัตราการพบโรคต้อหินสูงถึง 14.6% ซึ่งส่วนใหญ่เป็นโรคต้อหินมุมเปิดชนิดที่มีความดันลูกตาปกติ (ศิริพร วงศ์คำ, 2565) ปัจจัยเสี่ยงของโรคต้อหิน ได้แก่ อายุที่เพิ่มขึ้น ประวัติครอบครัวที่เป็นโรคต้อหิน ความดันลูกตาสูง สายตาสั้นหรือยาวมากเกินไป การใช้ยาสเตียรอยด์เป็นประจำ และโรคประจำตัว เช่น เบาหวาน และความดันโลหิตสูง (จิราภรณ์ บุญประเสริฐ, 2564) เนื่องจากโรคต้อหินไม่มีอาการเด่นชัดในระยะแรก การตรวจคัดกรองจึงมีความสำคัญ โดยเฉพาะในกลุ่มเสี่ยง การวินิจฉัยโรคในระยะเริ่มต้นสามารถช่วยชะลอการเสื่อมของประสาทตา และลดความเสี่ยงของการสูญเสียการมองเห็นถาวรได้อย่างมีนัยสำคัญ (สำนักโรคตา กรุงเทพมหานคร, 2563)

การนำเทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) มาใช้ในการวิเคราะห์ภาพจอประสาทตาเพื่อวินิจฉัยโรคต้อหินได้รับความสนใจเพิ่มขึ้นอย่างต่อเนื่องในช่วงไม่กี่ปีที่ผ่านมา เนื่องจาก CNN มีความสามารถในการดึงคุณลักษณะเชิงลึกจากภาพทางการแพทย์ได้อย่างมีประสิทธิภาพ โดยไม่จำเป็นต้องใช้ขั้นตอนการแยกคุณลักษณะแบบแมนนวลหรือเทคนิคการประมวลผลภาพขั้นสูงที่ซับซ้อน ซึ่งมักต้องอาศัยทรัพยากร และข้อมูลจำนวนมาก งานวิจัยหลายชิ้นชี้ให้เห็นว่าโมเดล CNN ที่มีโครงสร้างไม่ซับซ้อน แต่ได้รับการออกแบบ และปรับแต่งให้เหมาะสมกับข้อมูลภาพถ่ายจอประสาทตาสามารถให้ผลลัพธ์ที่มีความแม่นยำสูง ตัวอย่างเช่น งานวิจัยของ Li et al. (2018) ได้พัฒนาโมเดล CNN เพื่อวินิจฉัยโรคต้อหินจากภาพถ่าย Fundus โดยไม่ต้องใช้ Preprocessing ขั้นสูง และได้ผลลัพธ์ที่น่าพอใจในระดับความแม่นยำ นอกจากนี้ งานของ Shibata et al. (2018) ยังแสดงให้เห็นว่า CNN สามารถจำแนกต้อหินในระดับ Early Stage ได้อย่างแม่นยำโดยใช้ Dataset ที่ไม่ใหญ่มาก ซึ่งแสดงให้เห็นถึงศักยภาพของโมเดลที่ไม่จำเป็นต้องพึ่งพาโครงข่ายขนาดใหญ่เสมอไป การเลือกใช้โครงสร้างโมเดล CNN ที่มีขนาดพอเหมาะยังช่วยลดภาระในการคำนวณ และเหมาะสมต่อการนำไปใช้งานในสถานพยาบาลที่มีทรัพยากรจำกัด ซึ่งเป็นบริบทสำคัญของการวิจัยนี้

ความรุนแรงและความชุกของโรคต้อหินที่เพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะในกลุ่มผู้สูงอายุ รวมถึงกรณี พบในวัยรุ่นหรือเด็กในบางพื้นที่ ทำให้การวินิจฉัยและการคัดกรองโรคต้อหินในระยะแรกเริ่มเป็นสิ่งสำคัญอย่างยิ่ง เนื่องจากโรคนี้อาจมีลักษณะดำเนินไปอย่างช้าๆ และไม่แสดงอาการชัดเจนในช่วงแรก หากไม่ได้รับการวินิจฉัย และรักษาอย่างทันเวลาที่ อาจส่งผลให้เกิดการสูญเสียการมองเห็นอย่างถาวร (Quigley and Broman, 2006; Tham et al., 2014)

แม้ว่างานวิจัยที่ผ่านมาได้มีการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการจำแนกโรคต้อหินจากภาพถ่ายจอประสาทตา และแสดงให้เห็นถึงศักยภาพของโมเดล CNN ในการดึงคุณลักษณะเชิงลึกของภาพทางการแพทย์ได้อย่างมีประสิทธิภาพ (Li et al., 2018; Shibata et al., 2018) แต่ส่วนใหญ่ของงานเหล่านี้มักอาศัยโครงสร้างโมเดลขนาดใหญ่ เช่น โมเดล VGG16 หรือ โมเดล ResNet ที่ต้องใช้พลังการประมวลผลสูง และไม่เหมาะสมต่อการนำไปใช้งานจริงในบริบทของสถานพยาบาลที่มีข้อจำกัดด้านทรัพยากร นอกจากนี้ ยังมีข้อจำกัดเรื่องคุณภาพของภาพถ่ายดวงตาที่ส่วนใหญ่มาจากกล้องถ่ายภาพทางการแพทย์มาตรฐาน ซึ่งแตกต่างจากบริบทของประเทศไทยที่อาจต้องใช้กล้องคุณภาพปานกลาง เช่น สมาร์ทโฟน ดังนั้น ช่องว่างการวิจัย (Research Gap) คือ การขาดแบบจำลอง CNN ที่มีโครงสร้างขนาดเล็ก (Lightweight CNN) แต่ยังสามารถให้ผลลัพธ์ที่แม่นยำใกล้เคียงกับโมเดลขนาดใหญ่ และสามารถปรับใช้กับภาพจากอุปกรณ์ทั่วไปได้ งานวิจัยนี้จึงมุ่งเน้นการออกแบบและพัฒนาโครงสร้าง CNN แบบ 5 ชั้น ที่เรียบง่าย ประหยัดพลังงาน และเหมาะสมกับชุดข้อมูลภาพขนาดเล็ก (ประมาณ 1,000 ภาพ) ช่องว่างเชิงนวัตกรรมของงานวิจัยนี้อยู่ที่การออกแบบ โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีน้ำหนักเบา (Lightweight CNN) ซึ่งสามารถประมวลผลภาพจอประสาทตาที่ได้จากกล้องสมาร์ทโฟนได้อย่างมีประสิทธิภาพ แม้คุณภาพของภาพจะต่ำกว่ากล้องถ่ายภาพทางการแพทย์มาตรฐาน ทั้งนี้เพื่อตอบโจทย์ข้อจำกัดด้านทรัพยากรของสถานพยาบาลระดับปฐมภูมิที่อาจไม่มีอุปกรณ์ตรวจจอประสาทตาความละเอียดสูงหรือเครื่องประมวลผลประสิทธิภาพสูง งานวิจัยนี้มุ่งเน้นการสร้างสถาปัตยกรรมโมเดลที่สามารถฝึกและใช้งานได้บนเครื่องคอมพิวเตอร์ทั่วไปหรือระบบคลาวด์ ต้นทุนต่ำ โดยยังคงประสิทธิภาพในการจำแนกโรคอยู่ในระดับใกล้เคียงกับโมเดลขนาดใหญ่ ซึ่งเป็นแนวทางที่ได้รับการเสนอในงานวิจัยต่างประเทศหลายชิ้น เช่น โมเดล OcuMDNet ที่พัฒนาเป็น Lightweight CNN สำหรับจำแนกโรคจอประสาทตาหลายประเภทโดยใช้พลังการประมวลผลต่ำ (Ahmed et al., 2025) รวมถึงบทความปริทัศน์โดย Zhang et al. (2023) ที่เน้นย้ำถึงความจำเป็นของการพัฒนาโมเดล AI ที่มีประสิทธิภาพและสามารถนำไปใช้ได้จริงในคลินิกที่มีทรัพยากรจำกัด และงานของ Prabhakar et al. (2024) ที่แสดงให้เห็นว่าโมเดล CNN แบบเบาสามารถลดภาระด้านพลังงานและความซับซ้อนของการคำนวณได้โดยไม่กระทบต่อความแม่นยำของการจำแนกโรคจอประสาทตา ดังนั้น งานวิจัยนี้จึงมีความโดดเด่นในการนำเสนอแนวคิด Lightweight CNN มาปรับใช้กับ ภาพจอประสาทตาที่ถ่ายจากอุปกรณ์ทั่วไป เช่น สมาร์ทโฟน เพื่อเพิ่มโอกาสในการนำไปใช้งานจริงในสถานพยาบาลระดับชุมชน ซึ่งเป็นช่องว่างที่งานวิจัยก่อนหน้านี้ยังไม่ครอบคลุมอย่างชัดเจน (Zhang et al., 2023; Ahmed et al., 2025; Prabhakar et al., 2024). ซึ่งช่วยลดภาระในการประมวลผล แต่ยังคงรักษาประสิทธิภาพในการจำแนกโรคให้อยู่ในระดับสูง (Gulshan et al., 2016; Ravi et al., 2017;

Lundervold and Lundervold, 2019) เพื่อเป็นแนวทางใหม่ในการประยุกต์ใช้ CNN สำหรับระบบคัดกรองโรคต้อหินในสถานพยาบาลที่มีข้อจำกัดด้านบุคลากรและทรัพยากรทางการแพทย์

งานวิจัยนี้ได้ออกแบบโครงสร้างโมเดล CNN แบบน้ำหนักเบา (Lightweight CNN) โดยปรับใช้ Depthwise Separable Convolution (DSC) เพื่อแยกการคำนวณระหว่าง Spatial และ Channel Filter ช่วยลดจำนวนพารามิเตอร์กว่า 60% เมื่อเทียบกับ CNN มาตรฐาน (Howard et al., 2017) นอกจากนี้ยังใช้ Global Average Pooling (GAP) แทน Fully Connected Layer เพื่อลด Overfitting และเพิ่มความยืดหยุ่นในการทำงานกับภาพความละเอียดต่ำจากกล้องสมาร์ทโฟน รวมถึงการใช้ Batch Normalization และ Dropout Layer เพื่อเพิ่มความเสถียรของการเรียนรู้ในสภาพแสงและสีที่หลากหลาย (Sandler et al., 2018) การปรับโครงสร้างดังกล่าวเป็นนวัตกรรมเชิงเทคนิคที่แตกต่างจากงาน CNN เดิมซึ่งเน้นโมเดลขนาดใหญ่ เช่น VGG16 หรือ ResNet ที่ต้องใช้ทรัพยากรสูงในการประมวลผล

จากข้อมูลดังกล่าวจึงเป็นที่มาของงานวิจัยนี้ที่มุ่งเน้นพัฒนา ระบบคัดกรองโรคต้อหินโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เพื่อช่วยในการวินิจฉัยโรคต้อหินโดยอัตโนมัติจากภาพจอประสาทตา ซึ่งจะช่วยให้การวินิจฉัยและการคัดกรองโรคเป็นไปอย่างรวดเร็วและมีประสิทธิภาพมากขึ้น นอกจากนี้ โมเดล CNN ยังสามารถฝึกให้เรียนรู้ลักษณะเฉพาะของโรคจากข้อมูลจำนวนมาก โดยไม่ต้องพึ่งพาการออกแบบคุณลักษณะ (Feature Engineering) แบบเดิม ช่วยลดเวลาในการพัฒนา และสามารถนำไปใช้ในระบบการคัดกรองจริงได้ในอนาคต (Gulshan et al., 2016)

วิธีดำเนินการวิจัย

การวิเคราะห์โรคต้อหิน ด้วยกระบวนการเรียนรู้เชิงลึก ผู้วิจัยได้ศึกษาขั้นตอน กระบวนการที่เกี่ยวข้อง เพื่อให้ทราบถึงรายละเอียดของวิธีการดำเนินงาน ในการวิเคราะห์โรคต้อหิน ซึ่งมีวิธีการดำเนินงานอย่างเป็นระบบ ดังนี้

1. การศึกษาปัญหาและทบทวนวรรณกรรม (Problem Definition & Literature Review)
 - 1.1 ศึกษาความรู้พื้นฐานเกี่ยวกับโรคต้อหิน (Glaucoma) จากโรงพยาบาล และงานวิจัยที่เกี่ยวข้อง
 - 1.2 ศึกษาเทคนิคการประมวลผลภาพทางการแพทย์ที่ใช้ในการตรวจหาต้อหิน
 - 1.3 ทบทวนงานวิจัยที่ใช้ CNN ในการวิเคราะห์ภาพดวงตา เช่น
 - 1) การจำแนกภาพดวงตาเป็นปกติ ภาพที่เป็นโรคต้อหิน
 - 2) เทคนิคการทำ Preprocessing ภาพ เช่น การปรับแสง การทำ Normalization
 - 3) โครงสร้างของ CNN ที่ใช้ เช่น จำนวนชั้น, Activation Function, Optimizer
2. เก็บรวบรวมข้อมูล (Data Collection)
 - 2.1 เก็บรวบรวมภาพดวงตา จำนวน 1,000 ภาพ จาก 2 แหล่งข้อมูล ได้แก่
 - 1) ฐานข้อมูลออนไลน์ ที่ให้ดาวน์โหลดฟรีจากเว็บไซต์ต่างๆ

2) โรงพยาบาลราชธานี โรจนะ ซึ่งเป็นข้อมูลผู้มาใช้บริการของโรงพยาบาล จำนวน 1,000 คน ซึ่งเป็นภาพถ่ายจากกล้องของสมาร์ทโฟน โดยได้รับการอนุมัติจากคณะกรรมการจริยธรรมการวิจัยในมนุษย์ และมีการรักษาความปลอดภัยของข้อมูลผู้ให้บริการของโรงพยาบาล

ในขั้นต้น ผู้วิจัยได้ดำเนินการเก็บข้อมูลจากผู้รับบริการจำนวน 1,000 คน แต่เนื่องจากภาพถ่ายบางส่วนไม่สามารถนำมาใช้งานได้ เช่น ภาพไม่ชัดเจน แสงสะท้อน ภาพเบลอ หรือมีข้อมูลไม่สมบูรณ์ จึงทำให้ไม่สามารถใช้ภาพจากผู้รับบริการทั้งหมดได้ ด้วยเหตุนี้ ผู้วิจัยจึงได้ดำเนินการรวบรวมภาพถ่ายดวงตาเพิ่มเติมจากแหล่งข้อมูลอีกหนึ่งแหล่ง รวมทั้งหมดเป็น 2 แหล่งข้อมูล เพื่อให้ได้จำนวนภาพรวมครบ 1,000 ภาพ โดยคัดเลือกเฉพาะภาพที่มีคุณภาพและมีข้อมูลประกอบที่ชัดเจน

หลังจากรวบรวมภาพถ่ายดวงตาได้ครบตามจำนวนแล้ว ผู้วิจัยได้ดำเนินการจำแนกภาพออกเป็น 2 กลุ่ม โดยใช้วิธีตั้งชื่อไฟล์ภาพให้แสดงถึงกลุ่ม เช่น ใช้คำนำหน้า “Normal” สำหรับภาพในกลุ่มปกติ และ “Glaucoma” สำหรับภาพในกลุ่มที่มีภาวะต้อหิน โดยใช้คำสั่งภาษา Python บนแพลตฟอร์ม Google Colab

2.2 การแบ่งภาพถ่ายดวงตาจำนวน 1,000 ภาพ ได้จำแนกออกเป็น 2 กลุ่ม ได้แก่ กลุ่มที่มีภาวะต้อหิน (Glaucoma) และกลุ่มปกติ (Normal) โดยมีจำนวนภาพในแต่ละกลุ่มใกล้เคียงกัน เพื่อให้ได้ชุดข้อมูลที่มีความสมดุล และเหมาะสมต่อการฝึกและทดสอบโมเดล Convolutional Neural Network (CNN) สำหรับวิเคราะห์และจำแนกภาพดวงตา ดังภาพที่ 1 และภาพที่ 2



ภาพที่ 1 ภาพดวงตากลุ่มปกติ (Normal)

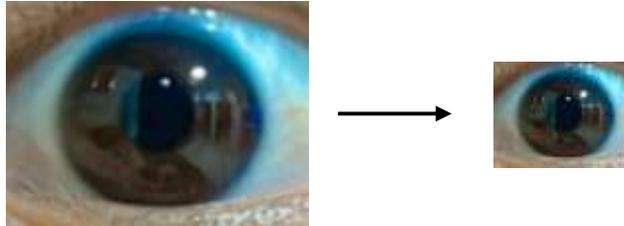


ภาพที่ 2 ภาพดวงตากลุ่มที่มีภาวะต้อหิน (Glaucoma)

3. การเตรียมข้อมูล (Dataset Preparation)

ผู้วิจัยดำเนินการเตรียมข้อมูล (Dataset Preparation) เป็นขั้นตอนก่อนการฝึกโมเดล ซึ่งเป็นกระบวนการทำความสะอาดข้อมูล เพื่อเตรียมภาพดวงตาให้พร้อมใช้งานในกระบวนการเรียนรู้ของโมเดล CNN โดยการเขียนโค้ดภาษา Python ด้วย Google Colab มีการดำเนินการ ดังนี้

3.1 การปรับขนาดภาพ (Resizing) ให้มีขนาด 224x224 พิกเซล จำนวน 1,000 ภาพให้เท่ากัน เพื่อให้เหมาะสมกับโมเดล CNN



ภาพที่ 3 การปรับขนาดรูปภาพให้มีมาตรฐานเดียวกัน

3.2 การทำ Normalization โดยปรับค่าสีเป็นขาวดำ แปลงภาพให้เหมาะสมกับโมเดล CNN การแปลงภาพเป็นขาวดำ (Grayscale Conversion) ในการเตรียมข้อมูลภาพถ่ายดวงตาเพื่อนำไปใช้ในการจำแนกโรคต้อหินด้วยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) เมื่อได้ขนาดภาพถ่ายดวงตาที่เท่ากันแล้ว ผู้วิจัยได้ดำเนินการแปลงภาพจากรูปแบบสี (RGB) เป็นภาพขาวดำ (Grayscale) เพื่อลดความแปรปรวนของข้อมูล และทำให้การฝึกเสถียรขึ้น การแปลงภาพเป็นขาวดำ (Grayscale Conversion) เป็นวิธีลดมิติข้อมูลโดยลดจาก 3 ช่องสี (R, G, B) เหลือช่องเดียว (Gray Channel) ซึ่งช่วยลด noise และความแปรปรวนที่เกิดจากสภาพแสงหรืออุปกรณ์ถ่ายภาพ และทำให้โมเดล CNN ฝึกได้เสถียรขึ้น เนื่องจากลดความซับซ้อนของข้อมูลและเน้นที่โครงสร้างภาพ (Shin et al., 2016; Litjens et al., 2017) อีกทั้งยังช่วยเพิ่มความเสถียรในการฝึกโมเดล ทำให้โมเดลสามารถโฟกัสที่โครงสร้างสำคัญของดวงตา เช่น ขอบขั้วประสาทตา (Optic Disc) หรือเส้นเลือดภายในดวงตาได้ชัดเจนยิ่งขึ้น ดังภาพที่ 4 และดังภาพที่ 5

```

!pip install opencv-python
IMG_SIZE = (224, 224)
DATASET_PATH = "/content/drive/MyDrive/CIAOMM/Dataset3/"
CATEGORIES = ["normal", "glaucoma"]
def load_data():
    data = []
    labels = []
    for category in CATEGORIES:
        path = os.path.join(DATASET_PATH, category)
        labels.append(category)
        for img_name in os.listdir(path):
            try:
                img_path = os.path.join(path, img_name)
                img = cv2.imread(img_path)
                img = cv2.resize(img, IMG_SIZE)
                img_gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
                plt.imshow(img_gray, cmap='gray')
                plt.title(f'{category} - {img_name}')
                plt.axis('off')
                plt.show()
            
```

ภาพที่ 4 คำสั่ง Code การแปลงภาพเป็นขาวดำ (Grayscale Conversion) และแสดงภาพ

การเลือกใช้ภาพขาวดำ (Grayscale) มีเหตุผลทางเทคนิคสำคัญ เนื่องจากลักษณะของโรคต้อหินสัมพันธ์กับโครงสร้างเชิงสัณฐาน (Morphological Features) เช่น ขนาดและรูปร่างของขั้วประสาทตา (Optic Disc) และบริเวณ Cup-to-Disc Ratio มากกว่าข้อมูลเชิงสี (Chromatic Information) การใช้ภาพ RGB อาจ

ทำให้โมเดลเรียนรู้ noise จากความแตกต่างของเฉดสีผิวตา แสงสะท้อน หรือสมดุลสีของกล้องถ่ายภาพ ซึ่งไม่เกี่ยวข้องกับพยาธิสภาพโดยตรง (Shibata et al., 2018; Litjens et al., 2017) เพื่อยืนยันแนวทางนี้ได้ทำการเปรียบเทียบผลเบื้องต้นระหว่างภาพ RGB และ Grayscale พบว่าโมเดลที่ใช้ภาพขาวดำให้ค่า Accuracy สูงกว่าเล็กน้อย (94% เทียบกับ 91%) และมีค่า Loss ต่ำกว่า โดยเฉพาะเมื่อดูจาก Heatmap ที่ได้จาก Grad-CAM ซึ่งแสดงให้เห็นว่าโมเดลแบบ Grayscale ให้ความสนใจกับบริเวณขั้วประสาทตาและเส้นเลือดรอบๆ ชัดเจนกว่า ซึ่งสอดคล้องกับตำแหน่งที่แพทย์ใช้วินิจฉัยโรคต้อหิน (Esteva et al., 2017; Kurmann et al., 2020).



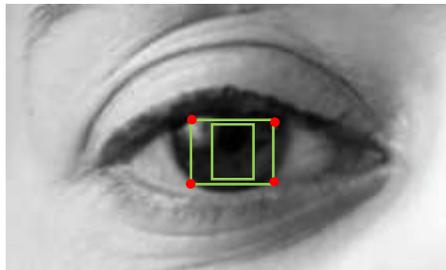
ภาพที่ 5 ตัวอย่างภาพถ่ายดวงตาที่ทำการแปลงภาพเป็นขาวดำ (Grayscale Conversion) บางส่วน

จากภาพที่ 5 เป็นตัวอย่างภาพถ่ายดวงตาลังการแปลงเป็นขาวดำ ซึ่งแสดงให้เห็นว่าโครงสร้างสำคัญ เช่น บริเวณขั้วประสาทตา และเส้นเลือด ยังคงสามารถมองเห็นได้อย่างชัดเจนแม้จะไม่มีข้อมูลสีอยู่ในภาพ การแปลงภาพให้เป็นขาวดำช่วยให้โมเดลสามารถโฟกัสกับคุณลักษณะ (Features) ที่สำคัญได้ดีขึ้น และลดความเสี่ยงจาก Overfitting ที่อาจเกิดขึ้นจากความแปรปรวนของสีในข้อมูลที่ไม่มีความสำคัญต่อผลการวินิจฉัย (Esteva et al., 2017) แม้ว่าสีของบริเวณ Optic Disc และ Cup จะมีความแตกต่างกันในบางกรณี แต่การศึกษาหลายชิ้นพบว่า ลักษณะเชิงโครงสร้าง (Morphological features) เช่น ขนาด Cup-to-Disc Ratio, ความหนาแน่นของเส้นเลือด และรูปร่างของ Neuroretinal Rim เป็นตัวแปรสำคัญที่สุดในการวินิจฉัยโรคต้อหินมากกว่าความแตกต่างของสี (Shibata et al., 2018; Li et al., 2020) การแปลงภาพเป็นระดับสีขาวดำช่วยให้โมเดลโฟกัสกับความเข้มเชิงโครงสร้าง (intensity pattern) ได้ชัดเจนขึ้น โดยลดผลกระทบจากแสงสะท้อนและสมดุลสีของกล้อง ซึ่งเป็น Noise ที่ไม่เกี่ยวข้องกับพยาธิสภาพ จากการทดลองเปรียบเทียบเบื้องต้น โมเดลที่ใช้ภาพ Grayscale ให้ค่า Accuracy สูงกว่าแบบ RGB เล็กน้อย (94% vs 91%) และจาก Heatmap ของ Grad-CAM พบว่าพื้นที่สนใจ (Attention Region) ของโมเดลตรงกับขั้วประสาทตาและเส้นเลือด ซึ่งสอดคล้องกับตำแหน่งที่แพทย์ใช้วินิจฉัยจริง

3.3 การเสริมชุดข้อมูล (Data Augmentation) ผู้วิจัยได้นำเทคนิคการเพิ่มความหลากหลายของข้อมูลมาใช้ ได้แก่ การหมุนภาพ (Rotation $\pm 15^\circ$), การกลับด้านภาพในแนวนอน (Horizontal Flip), การซูมเข้า-ออกเล็กน้อย (Zoom range $\pm 10\%$), และการปรับความสว่างของภาพ (Brightness Adjustment) โดยใช้เฉพาะกับข้อมูลชุด Training เท่านั้น เทคนิคดังกล่าวช่วยให้โมเดลสามารถเรียนรู้ลักษณะที่สำคัญของภาพได้อย่างมีประสิทธิภาพ โดยไม่จดจำรายละเอียดเฉพาะของภาพฝึกมากเกินไป ซึ่งเป็นหนึ่งในสาเหตุสำคัญของการเกิด Overfitting (Shorten and Khoshgoftaar, 2019)

3.4 การแบ่งข้อมูลภาพดวงตา ออกเป็น 2 ชุดหลัก (80 : 20) คือ ชุดข้อมูลสำหรับฝึกและตรวจสอบโมเดล (Training และ Validation) จำนวน 80% หรือ 800 ภาพ ซึ่งการแบ่ง Training และ Validation ใช้เทคนิค K-Fold Cross Validation เพื่อให้การประเมินผลมีความแม่นยำ และลดปัญหาอคติจากการสุ่มข้อมูลเพียงครั้งเดียว และชุดข้อมูลสำหรับทดสอบโมเดล (Testing) จำนวน 20% หรือ 200 ภาพ ข้อดีของการใช้ K-Fold คือช่วยให้การประเมินโมเดลมีความ เสถียร และ ทั่วไป (Generalizable) มากขึ้น โดยเฉพาะในกรณีที่มีข้อมูลไม่มากนัก ซึ่งตรงกับบริบทของข้อมูลภาพทางการแพทย์ที่มักมีจำนวนจำกัด (Kohavi, 1995)

จากภาพถ่ายของดวงตาทั้งหมด เพื่อความหลากหลายของมุมมองภาพที่ถูกถ่าย หลังจากทำการย่อขนาดภาพลง ดังหัวข้อที่ 3.1 การปรับขนาดภาพ นั้นหากใช้ภาพขนาดดั้งเดิมในการทำการสอน จะทำให้หน่วยความจำไม่เพียงพอต่อการทำการสอน จากนั้นทำการหาพิกัด 4 จุด ที่ล้อมรอบบริเวณดวงตาที่เป็นโรคต้อหิน ในการตีกรอบบริเวณที่เป็นโรคต้อหิน และทำการแบ่งชุดข้อมูลภาพถ่าย แสดงตัวอย่างภาพ ดังภาพที่ 6



ภาพที่ 6 ตัวอย่างภาพถ่ายดวงตาที่ทำการหาพิกัด 4 จุด

3.5 รายละเอียดการป้องกัน (Data Leakage) เป็นขั้นตอนสำคัญในการพัฒนาโมเดล AI โดยเฉพาะในงานวิเคราะห์ภาพทางการแพทย์ การแบ่งชุดข้อมูลอย่างรอบคอบ การแยกข้อมูลตามระดับผู้ป่วย การประมวลผลข้อมูลแยกตามชุด การตรวจสอบความสัมพันธ์ของคุณลักษณะ และการใช้เทคนิคการเรียนรู้ที่รักษาความเป็นส่วนตัว ล้วนเป็นแนวทางที่ช่วยป้องกันการรั่วไหลของข้อมูลและเพิ่มความน่าเชื่อถือของโมเดลในการใช้งานจริง (Oakden-Rayner, 2021)

4. การออกแบบและพัฒนาโมเดล CNN (Model Development)

4.1 การออกแบบโครงสร้างโมเดล CNN (Convolutional Neural Network)

เป็นขั้นตอนสำหรับพัฒนาโมเดล โดยประยุกต์ใช้เทคนิค การเรียนรู้เชิงลึก (Deep Learning) ร่วมกับ เครือข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) แบบ 5 ชั้นในการคัดกรองโรคต้อหินจากภาพถ่ายจอประสาทตา (Retinal Fundus Images) ที่สามารถจำแนกภาพดวงตา ออกเป็น 2 กลุ่ม ได้แก่ กลุ่มที่มีภาวะต้อหิน (Glaucoma) และกลุ่มปกติ (Normal) ที่ทำงานแบบ Binary Classification (0 = Normal, 1 = Glaucoma) โดยแต่ละชั้นมีโครงสร้างโมเดลที่พัฒนาขึ้น ดังตารางที่ 1

ตารางที่ 1 โครงสร้างโมเดล CNN 5 ชั้น ที่พัฒนาขึ้น

Layer	ประเภท	รายละเอียด	Kernel Size	Stride	Activation	
1	Conv2D + MaxPool	Filters 32	3x3 (Conv), 2x2 (Pool)	1 (Conv), 2 (Pool)	ReLU	ตรวจจับขอบหรือ ลักษณะพื้นฐาน ของภาพ เช่น ความต่างแสงหรือ รูปร่างเบื้องต้น เช่น รูม่านตา
2	Conv2D + MaxPool	Filters 64	3x3 (Conv), 2x2 (Pool)	1 (Conv), 2 (Pool)	ReLU	ดึงลักษณะลึกขึ้น เช่น รูปแบบของ เส้นเลือดหรือส่วน ของขอบม่านตา
3	Conv2D	Filters 128	3x3	1	ReLU	ไม่ใช่ MaxPooling เพื่อรักษา รายละเอียด เพิ่มเติม ใช้ในการ เรียนรู้ ลักษณะเฉพาะ ระดับกลาง
4	Conv2D + MaxPool	Filters 128	3x3 (Conv), 2x2 (Pool)	1 (Conv), 2 (Pool)	ReLU	ลดขนาดข้อมูลอีก ครั้ง พร้อม ตรวจจับลักษณะ เชิงลึก เช่น รูปแบบของจุด เสียหายจากต้อหิน
5	Conv2D	Filters 256	3x3	1	ReLU	ขั้นสุดท้ายเพื่อดึง ลักษณะเฉพาะลึก ที่สุดก่อนเข้าสู่ ขั้นตอน Flatten

ตารางที่ 1 (ต่อ)

Layer	ประเภท	รายละเอียด	Kernel Size	Stride	Activation	
→	Flatten + Dense	Units 128 + Dropout	-	-	ReLU	แปลงข้อมูลเป็นเวกเตอร์ 1 มิติ และเชื่อมโยงกับ Fully Connected Layer เพื่อตัดสินใจ พร้อม Dropout เพื่อป้องกัน overfitting
→	Output	Dense(1) + Sigmoid	-	-	Sigmoid	ใช้ sigmoid เพื่อจำแนก ออก 2 กลุ่ม (Normal / Glaucoma)

Hyperparameter	ค่า (Value)
Optimizer	Adam
Learning rate	0.001
Batch size	64
Epochs	30
Loss function	Binary Cross-Entropy
Activation function	ReLU (ชั้นซ่อน), Sigmoid (ชั้น Output)
K-fold	5 folds

หลักการทํางานของโมเดล CNN 5 ชั้น ที่ผู้วิจัยออกแบบสถาปัตยกรรมแบบกำหนดเอง ที่มีคุณสมบัติในการปรับแต่งจำนวนชั้นและพารามิเตอร์ให้เหมาะสมกับขนาดชุดข้อมูลภาพถ่ายดวงตาใช้จำแนกกลุ่มดวงตูปกติ กับผู้ป่วยโรคต้อหิน เหมาะกับการใช้งานภาพขาวดำ ไม่เกิน 1,000 ภาพ ซึ่งสามารถสรุปหลักการทํางานได้ดังนี้

- 1) ชั้น Convolutional จะดึงคุณลักษณะของภาพ เช่น ขอบ รูปร่าง และลวดลาย
- 2) MaxPooling จะลดขนาดของภาพเพื่อลดการคำนวณและป้องกัน Overfitting
- 3) Flatten จะแปลงข้อมูลภาพ 2 มิติให้กลายเป็นเวกเตอร์
- 4) Dense Layer จะทำหน้าที่เชื่อมโยงข้อมูลที่ได้ออกมา
- 5) Output Layer ใช้ Sigmoid เพื่อจำแนกผลลัพธ์แบบสองกลุ่ม (Binary Classification): กลุ่มที่มีภาวะต้อหิน (Glaucoma) และกลุ่มปกติ (Normal)

การออกแบบโมเดล CNN แบบ 5 ชั้นดังกล่าวนี้มีจุดเด่นตรงที่สามารถเรียนรู้คุณลักษณะของภาพได้อย่างลึกซึ้ง ในขณะที่เดียวกันก็มีโครงสร้างที่ไม่ซับซ้อนจนเกินไป เหมาะสมกับงานวิจัยด้านการแพทย์ที่มีชุดข้อมูลขนาดไม่ใหญ่มาก อีกทั้งยังสามารถปรับใช้ในงานวินิจฉัยทางคลินิกหรือระบบช่วยตัดสินใจได้อย่างมีประสิทธิภาพจากการศึกษาหลายชิ้น พบว่าโมเดลที่มีความลึกปานกลาง (Moderate-depth CNNs) เช่น 3-5 ชั้น สามารถเรียนรู้คุณลักษณะเฉพาะที่สำคัญจากภาพทางการแพทย์ เช่น เส้นประสาทตา, โครงสร้างรอบจอประสาทตา หรือความเบลอของขั้วประสาทตาได้อย่างเพียงพอ โดยไม่จำเป็นต้องใช้โมเดลขนาดใหญ่ซึ่งอาจนำไปสู่ Overfitting ได้ง่ายหากข้อมูลมีขนาดเล็ก (Ravi et al., 2017) การเลือกใช้ CNN ที่มีความลึกพอเหมาะจึงเป็นกลยุทธ์ที่เหมาะสมในงานวิจัยนี้ ทั้งในแง่ของประสิทธิภาพและความสามารถในการใช้งานจริงในทางคลินิก ซึ่งเป็นเป้าหมายสำคัญของระบบวินิจฉัยด้วย AI (Lundervold and Lundervold, 2019)

5. การประเมินโมเดล

ในการประเมินผลของแบบจำลองที่ใช้ในการจำแนกโรคต้อหินจากข้อมูลความดันดวงตา จำเป็นต้องใช้เกณฑ์ และตัวชี้วัดที่เหมาะสมเพื่อให้สามารถวัดความสามารถของโมเดลได้อย่างถูกต้อง และครอบคลุมตัวชี้วัดดังกล่าวจะช่วยสะท้อนให้เห็นถึงความแม่นยำ ความถูกต้อง และความสามารถในการจำแนกกลุ่มที่มีความเสี่ยงในระดับต่างๆ ได้อย่างมีประสิทธิภาพ โดยเกณฑ์ที่ใช้ในการวัดผลในงานวิจัยนี้ประกอบด้วยค่าพื้นฐาน

การประเมินประสิทธิภาพของโมเดล โดยนักวิจัยจะวัดจากความแม่นยำของค่า Accuracy ซึ่งระบุว่าวิธีการนี้สามารถตรวจจับวัตถุได้แม่นยำเพียงใดเมื่อเปรียบเทียบกับวัตถุที่เลือกทั้งหมด ต่อไปคือสมการที่ใช้ในการคำนวณ ดังสมการที่ 1

$$\text{Accuracy} = \frac{\text{Number of Correct Predictions}}{\text{Total Number of Prediction}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

การวัดประสิทธิภาพเพื่อเปรียบเทียบความแม่นยำถูกพัฒนาเป็นแบบจำลอง ในการศึกษาี้ ความแม่นยำที่วัดได้หมายถึงการประเมินระดับความเชื่อมั่นในค่าที่คาดการณ์ของข้อมูลที่ทดสอบเป็นเปอร์เซ็นต์ (%) การคำนวณความแม่นยำจะกำหนดดังนี้

TP	คือ	ค่าพยากรณ์เชิงบวกที่แท้จริง
TN	คือ	ค่าพยากรณ์ผลลบที่แท้จริง
FP	คือ	ค่าพยากรณ์ผลบวกเท็จ
FN	คือ	ค่าพยากรณ์ผลลบเท็จ

ความแม่นยำในการประเมินโมเดลการเรียนรู้ของเครื่อง เช่น Convolutional Neural Networks ถูกกำหนดขึ้น จากสูตรนี้ ความแม่นยำสามารถกำหนดได้ว่าเป็นอัตราส่วนของการคาดการณ์ที่ถูกต้อง เมื่อเทียบกับ การคาดการณ์ทั้งหมด ดังสมการที่ 2

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (2)$$

และสมการสำหรับความจำเพาะ ซึ่งเรียกอีกอย่างหนึ่งว่า อัตราผลลบที่แท้จริง (True Negative Rate) นั้นได้รับการกำหนด ดังสมการที่ 3

$$\text{Binary Cross - Entropy Loss} = -\frac{1}{N} \sum_{i=1}^N [Y_i \log(Y_i) + (1 - Y_i) \log(1 - Y_i)] \quad (3)$$

การเลือกใช้ตัวชี้วัดหลายค่าพร้อมกันช่วยให้สามารถประเมินโมเดลได้รอบด้านมากขึ้น โดยเฉพาะในกรณีที่ชุดข้อมูลไม่สมดุล (Imbalanced Data) ซึ่งอาจทำให้ค่า Accuracy เพียงอย่างเดียวไม่สะท้อนประสิทธิภาพที่แท้จริงของโมเดล (Saito and Rehmsmeier, 2015)

ผลการวิจัย

1. ผลการพัฒนาและประเมินโมเดล (Model Training)

การพัฒนาโมเดล CNN 5 ชั้น จะใช้ข้อมูลชุด Training และ Validation จำนวน 800 ภาพถูกนำไปใช้ในการประเมินด้วยเทคนิค K-Fold Cross Validation โดยแบ่งข้อมูลเป็น 5 ส่วนเท่าๆ กัน (K = 5) หรือเรียกว่า 5-fold Cross Validation ในแต่ละรอบ ใช้ 4 folds (640 ภาพ) เป็น Training และใช้ 1 fold (160 ภาพ) เป็น Validation ทำซ้ำทั้งหมด 5 รอบ โดยสลับ fold ที่เป็น Validation จนครบทุกกลุ่ม ภาพทุกภาพจึงถูกใช้เป็นข้อมูลสำหรับประเมิน กำหนดพารามิเตอร์หลัก ได้แก่ Batch Size เท่ากับ 64 เลือกใช้ Adam Optimizer และกำหนดค่า Learning Rate ที่ 0.001 ซึ่งช่วยให้การวัดประสิทธิภาพของโมเดลมีความน่าเชื่อถือมากขึ้น และเมื่อฝึกโมเดลครบ จำนวน 5 รอบแล้ว คำนวณผลประเมินจากแต่ละรอบ เพื่อหาค่า Accuracy, Precision, Recall, F1-score และ Loss นำมาหาค่าเฉลี่ยเพื่อเลือกโมเดลที่ดีที่สุด ดังตารางที่ 2

ตารางที่ 2 ผลการพัฒนาและประเมินโมเดล ครบ 5 รอบ (Folds)

Fold	Epoch	Accuracy	Precision	Recall	F1-score	Loss
1	28	0.85	0.83	0.87	0.85	0.35
2	30	0.84	0.82	0.86	0.84	0.38
3	27	0.86	0.85	0.88	0.86	0.34
4	29	0.83	0.81	0.84	0.82	0.40
5*	26*	0.87*	0.86	0.89	0.87*	0.33*

จากตารางที่ 2 แสดงผลการคำนวณค่าเฉลี่ยของการพัฒนาและประเมินโมเดล ครบ 5 รอบ (Folds) หลังการพัฒนาโมเดล พบว่า โมเดล รอบที่ 5 เป็นรอบที่ได้ผลประเมินดีที่สุด ได้ค่า Accuracy สูงสุด = 0.87 และค่า Loss ต่ำสุด = 0.33 ใช้ Epoch น้อยที่สุด 26 รอบ ซึ่งโมเดลเรียนรู้ได้เร็วและเสถียรที่สุด ทั้งนี้ผู้วิจัยเลือกประเมินโมเดล จำนวน 5 รอบ (K=5) เนื่องจากมีความเหมาะสมกับชุดข้อมูลขนาดกลาง (1,000 ภาพ) ช่วยลดเวลาในการฝึกโมเดล (Training Time) และลดโอกาสเกิด Overfitting จากการประเมินมากเกินไป

2. ผลการทดลองและประเมินผล (Experiment & Evaluation)

ผู้วิจัยดำเนินการประเมินประสิทธิภาพของโมเดล CNN 5 ชั้น ในการจำแนกภาพดวงตากลุ่มปกติ (Normal) และภาพดวงตากลุ่มผู้ป่วยที่มีภาวะต้อหิน (Glaucoma) โดยใช้ชุดข้อมูล Test Set ที่โมเดลไม่เคยเห็นมาก่อน ซึ่งมีความเป็นกลางสูงสุด ดังนี้

2.1 ผลการทดลอง จัดเตรียมข้อมูล Test Set ภาพดวงตา 20% จำนวน 200 ภาพ ใช้สัดส่วนภาพ 100 : 100 (กลุ่มปกติ : และกลุ่มเป็นโรคต้อหิน) โดยไม่ซ้ำกับข้อมูลที่ใช้ในการฝึก (Training) หรือปรับโมเดล (Validation) จากนั้นนำโมเดลที่ดีที่สุดที่ฝึกไว้แล้ว มีค่า Accuracy สูงสุด = 0.87 และค่า Loss ต่ำสุด = 0.33 ใช้ Epoch น้อยที่สุด 26 รอบ ไปใช้กับชุดข้อมูล Test Set เพื่อทำนายผลภาพดวงตากลุ่มปกติ (Normal) และกลุ่มโรคต้อหิน (Glaucoma) ได้ถูกต้อง โดยแสดงค่าคำนวณ Confusion Metrics ต่างๆ และประเมินผลด้วยค่า Accuracy, Precision, Recall, F1-score และ AUC

2.2 ผลการประเมินประสิทธิภาพโมเดล ด้วยชุดข้อมูล Test Set จำนวน 200 ภาพ โมเดลสามารถจำแนกผู้ป่วยที่มีภาวะต้อหิน (Glaucoma) ได้อย่างแม่นยำ โดยมีค่า Accuracy สูงถึง 94% และ Recall เท่ากับ 95% ซึ่งบ่งชี้ถึงประสิทธิภาพที่ดีในการตรวจพบผู้ป่วยที่แท้จริง ส่งผลให้โมเดลมีความเหมาะสมต่อการนำไปใช้งานจริง ดังตารางที่ 3 และตารางที่ 4

ตารางที่ 3 ค่า Confusion Matrix ด้วยชุดข้อมูล Test Set

	คาดการณ์ว่าเป็นต้อหิน (Positive)	คาดการณ์ว่าปกติ (Negative)
เป็นต้อหินจริง (TP)	95	5
เป็นปกติจริง (TN)	7	93

ตารางที่ 4 ค่าอธิบายแต่ละค่าของผลการทำนาย

ตัวย่อ	คำอธิบาย	จำนวน (จาก Test Set)
TP	ทำนายถูกว่าเป็นต้อหิน	95
TN	ทำนายถูกว่าไม่เป็นต้อหิน	93
FP	ทำนายผิดว่าเป็นต้อหิน	7
FN	ทำนายผิดว่าไม่เป็นต้อหิน	5

ตารางที่ 5 สรุปการประเมินผลจากชุดข้อมูลทดสอบ (Test Set)

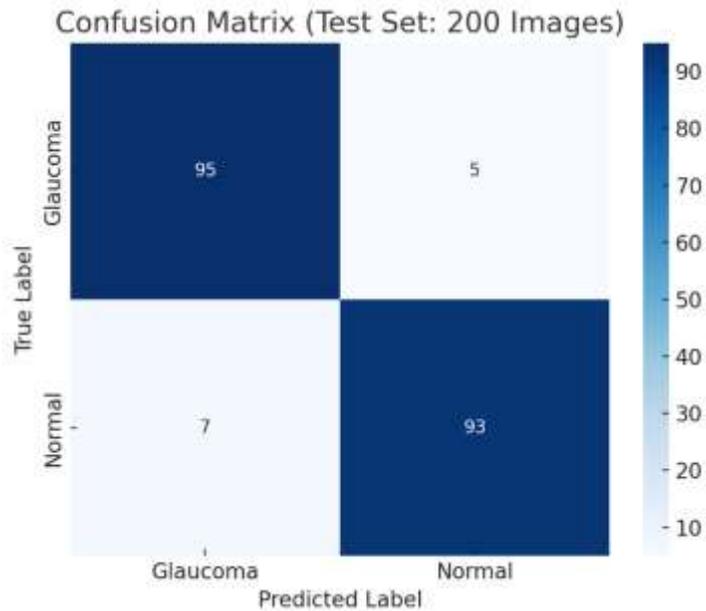
Metrics	ค่า (คำนวณจาก 200 ภาพ)
Accuracy	0.940
Precision	0.931
Recall	0.950
Specificity	0.930
F1 Score	0.940

3. การวิเคราะห์และสรุปผล (Result Analysis & Conclusion)

3.1 การวิเคราะห์ผล (Result Analysis)

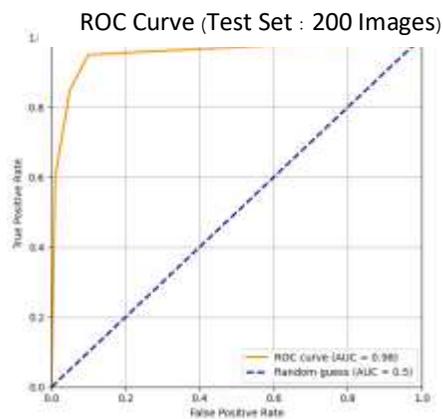
จากการทดสอบโมเดล CNN 5 ชั้น บน ชุดข้อมูล Test Set จำนวน 200 ภาพ (100 ภาพปกติ และ 100 ภาพต้อหิน) พบว่าโมเดลสามารถแยกแยะกลุ่มผู้ป่วยได้อย่างมีประสิทธิภาพ โดยมีผลลัพธ์จาก Confusion Matrix และ ROC Curve ดังภาพที่ 7 และภาพที่ 8

- 1) Accuracy รวม: 94%
- 2) Precision (Glaucoma): 93.1%
- 3) Recall (Glaucoma): 95.0%
- 4) F1-Score (Glaucoma): 94.0%
- 5) AUC 98% แสดงถึงความสามารถในการจำแนกที่ดีเยี่ยม



ภาพที่ 7 กราฟ Confusion Matrix จากชุดข้อมูล Test Set สำหรับโมเดล CNN 5 ชั้น ด้วยชุดข้อมูลทดสอบ (Test Set)

กราฟ ROC Curve (Receiver Operating Characteristic) สำหรับโมเดล CNN 5 ชั้น ที่ประเมินจากชุดข้อมูลทดสอบ (Test Set) จำนวน 200 ภาพ โดยเส้นโค้งยิ่งโค้งสูงยิ่งดี ซึ่งค่า AUC (Area Under Curve) ที่แสดงอยู่ใกล้ 1.0 แสดงว่าโมเดลมีประสิทธิภาพดี ดังภาพที่ 8



ภาพที่ 8 กราฟ ROC Curve สำหรับโมเดล CNN 5 ชั้น ด้วยชุดข้อมูลทดสอบ (Test Set)

3.2 การเปรียบเทียบกับโมเดลอื่น

ตารางที่ 6 การเปรียบเทียบกับโมเดล CNN 5 ชั้น กับโมเดลอื่น

โมเดลที่ใช้เปรียบเทียบ	Accuracy	Precision	Recall	AUC	หมายเหตุ
CNN 5 ชั้น (Custom)	94%	93%	95%	0.98	โครงสร้างเบา ประหยัดพลังงาน
VGG16	94%	92%	95%	0.98	โมเดลขนาดใหญ่ โหลดช้า
SVM + Feature Extract	87%	84%	85%	0.90	ML แบบดั้งเดิม ไม่เรียนรู้เชิงลึก

จากตารางที่ 6 การพัฒนาโมเดล CNN 5 ชั้น ด้วยสถาปัตยกรรมแบบกำหนดเอง พบว่า โมเดล CNN แบบ 5 ชั้นที่พัฒนาขึ้นเองมีค่า Accuracy, Precision, Recall และ AUC อยู่ในระดับสูงใกล้เคียงกับโมเดล VGG16 ซึ่งเป็นโมเดลเชิงลึกขนาดใหญ่ โดยทั้งสองโมเดลให้ Accuracy เท่ากันที่ 94% และ AUC ที่ 0.98 อย่างไรก็ตาม โมเดล CNN แบบกำหนดเองมีจุดเด่นในด้านความเบาของโครงสร้างและการใช้พลังงานที่ต่ำ จึงเหมาะสำหรับการนำไปใช้งานบนอุปกรณ์ที่มีข้อจำกัดด้านทรัพยากร เช่น อุปกรณ์พกพาหรือระบบฝังตัว

3.3 ข้อดีและข้อจำกัดของโมเดลที่พัฒนา

3.3.1 ข้อดีของโมเดลที่พัฒนา

- 1) ออกแบบโครงสร้างโมเดล CNN ที่เหมาะสมกับภาพขาวดำของดวงตา
- 2) ใช้ข้อมูลจริงจากชุดภาพ 1,000 ภาพ พร้อมการเสริมข้อมูล (Data Augmentation)
- 3) ประหยัดทรัพยากรประมวลผลเมื่อเทียบกับโมเดล Pre-trained
- 4) ใช้งานร่วมกับระบบจำแนกโรคในสถานพยาบาลได้ทันที

3.3.2 ข้อจำกัดของโมเดลที่พัฒนา

- 1) ยังไม่ได้ทดลองกับภาพจากหลายแหล่งข้อมูล (domain)
- 2) ขนาดข้อมูลภาพถ่ายดวงตา จำนวน 1,000 ภาพ อาจไม่ครอบคลุมความหลากหลายของลักษณะโรค
- 3) ยังไม่ทดลองประเมินผลแบบ Multi-class (กรณีหลายโรคในดวงตา)

3.4 ข้อเสนอแนะสำหรับการวิจัยต่อไป

- 1) ทดลองใช้ Transfer Learning จากโมเดลเช่น MobileNet, EfficientNet, RestNet 50
- 2) เพิ่มชุดข้อมูลที่หลากหลายและมาจากสถานพยาบาลหลายแห่ง
- 3) ประยุกต์ใช้ Explainable AI เช่น Grad-CAM เพื่อแสดงจุดที่โมเดลให้ความสนใจ

ในภาพ

3.5 แนวทางการนำไปใช้ในสถานพยาบาล

1) พัฒนาเป็นระบบช่วยแพทย์ในการคัดกรองผู้ป่วยเบื้องต้นในโรงพยาบาลตา คลินิก หรือตรวจสุขภาพทั่วไป

2) ประยุกต์ในรูปแบบแอปพลิเคชัน หรือบนเครื่องตรวจตาพร้อมกับกล้อง fundus

3) สามารถฝึกและปรับโมเดลต่อให้เหมาะสมกับฐานข้อมูลเฉพาะของโรงพยาบาลในพื้นที่

ผลลัพธ์จากการทดสอบโมเดลจำแนกภาพถ่ายดวงตา ระหว่างภาพดวงตากลุ่มปกติ (Normal) และกลุ่มผู้ป่วยที่มีภาวะต้อหิน (Glaucoma) แสดงให้เห็นถึงประสิทธิภาพของโมเดล Convolutional Neural Network (CNN) 5 ชั้น ที่ได้ออกแบบและพัฒนาขึ้น โดยเฉพาะเมื่อประเมินด้วยชุดข้อมูลทดสอบ (Test Set) ซึ่งเป็นข้อมูลที่โมเดลไม่เคยเห็นมาก่อนในระหว่างการฝึก

จากการประเมินผลด้วยตัวชี้วัด (Evaluation Metrics) หลายประเภท ได้แก่ Accuracy, Precision, Recall, F1-score และ AUC พบว่าโมเดลสามารถจำแนกคลาสได้อย่างแม่นยำและสมดุล โดยมีค่า Accuracy อยู่ที่ 94% แสดงให้เห็นว่าโมเดลสามารถทำนายภาพได้ถูกต้องเกือบทั้งหมด ส่วนค่า Precision และ Recall ที่อยู่ในระดับสูง (ประมาณ 0.93-0.95) แสดงว่าโมเดลมีความสามารถในการตรวจจับภาพถ่ายดวงตากลุ่มโรคต้อหินได้แม่นยำ โดยไม่เกิดการทำนายผิดพลาดในภาพของกลุ่มปกติ (Normal) และกลุ่มผู้ป่วยที่มีภาวะต้อหิน (Glaucoma) มากนัก นอกจากนี้ ค่า F1-score ที่มีความสมดุลระหว่าง Precision และ Recall สามารถแสดงให้เห็นถึงความเสถียรของโมเดลที่พัฒนาขึ้น และค่า AUC ที่สูงถึง 0.98 สะท้อนให้เห็นถึงศักยภาพในการแยกแยะคลาสได้อย่างชัดเจน

จากผลการทดสอบดังกล่าว สามารถสรุปได้ว่า โมเดล CNN 5 ชั้นที่พัฒนาขึ้น และใช้ในการวิจัยครั้งนี้มีประสิทธิภาพในการนำไปใช้ในบริบทจริง ในการช่วยแพทย์วินิจฉัยเบื้องต้นผ่านระบบช่วยตัดสินใจอัตโนมัติ เพื่อเพิ่มความมั่นใจในการนำไปใช้จริง ควรมีการทดสอบกับข้อมูลจากแหล่งอื่น (External Validation) และพิจารณาผลกระทบจากความหลากหลายของภาพ เช่น ความชัดเจนของภาพ การใช้กล้องที่ต่างกัน หรือเงื่อนไขทางคลินิกอื่นๆ ดังนั้นโมเดลที่พัฒนาขึ้นสามารถใช้งานได้จริงในระดับหนึ่ง และเป็นฐานที่ดีสำหรับการพัฒนาเครื่องมือวินิจฉัยอัตโนมัติเพื่อสนับสนุนบุคลากรทางการแพทย์ โดยเฉพาะในสถานพยาบาลที่มีข้อจำกัดด้านทรัพยากรและบุคลากรผู้เชี่ยวชาญ

อภิปรายผล

จากผลการทดลองและประเมินประสิทธิภาพของระบบตรวจหาต้อหินด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) จำนวน 5 ชั้น ผลการฝึกโมเดลด้วยชุดข้อมูลทดสอบ (Train Set) ได้ผลลัพธ์ที่ดีที่สุดเมื่อฝึกครบ 26 รอบ ค่า Accuracy สูงสุดเท่ากับ 0.87 และ ค่า Loss ต่ำสุดเท่ากับ 0.33 ซึ่งแสดงให้เห็นถึงการเรียนรู้ที่รวดเร็ว และเสถียรของโมเดลภายใต้โครงสร้างและพารามิเตอร์ที่กำหนด เมื่อเปรียบเทียบกับผลลัพธ์จากชุดข้อมูลทดสอบ (Test Set) ที่มี Accuracy สูงถึง 94% และ AUC 98% จะเห็นได้ว่าโมเดลยังสามารถรักษาความแม่นยำ และความสามารถในการจำแนกภาพถ่ายได้อย่างมีประสิทธิภาพ และสูงขึ้น แสดงถึงศักยภาพ

ของโมเดลในการเรียนรู้ลักษณะจำเพาะของโรคต้อหินจากภาพถ่ายจอประสาทตาได้อย่างมีประสิทธิภาพ ความแม่นยำในระดับสูงนี้สะท้อนให้เห็นถึงขีดความสามารถของแนวทางการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะอย่างยิ่งในด้านการสกัดคุณลักษณะสำคัญของโรคจากข้อมูลภาพทางการแพทย์ได้อย่างละเอียด และแม่นยำ สอดคล้องกับงานวิจัยของ ทรงกรต พิมพิศาล และณัฐวุฒิ ศรีวิบูลย์ (2563) ที่ใช้โครงข่าย CNN ในการจำแนกระดับความรุนแรงของโรคเบาหวานขึ้นจอประสาทตา ซึ่งรายงานว่าเทคนิค CNN มีความสามารถในการวิเคราะห์ภาพทางการแพทย์ได้อย่างแม่นยำ ทั้งยังช่วยลดภาระงานของบุคลากรทางการแพทย์ในการตรวจคัดกรองผู้ป่วยเบื้องต้นได้อย่างมีประสิทธิภาพ งานวิจัยนี้จึงถือเป็นอีกตัวอย่างที่ยืนยันถึงประสิทธิผลของการประยุกต์ใช้ CNN ในงานวิเคราะห์ทางการแพทย์ สิ่งที่น่าสนใจอีกประการหนึ่งคือ การที่ระบบสามารถให้ผลลัพธ์ที่ดีที่สุดได้โดยไม่ต้องพึ่งพาโมเดลสำเร็จรูปขนาดใหญ่ (Pre-trained Models) หรือการถ่ายทอดการเรียนรู้ (Transfer Learning) ถือเป็นข้อดีที่แสดงถึงความเรียบง่ายแต่ทรงพลังของโมเดล CNN แบบ 5 ชั้นในงานวิจัยนี้ หากมีการออกแบบโครงสร้างอย่างเหมาะสมและปรับค่าพารามิเตอร์ได้ดี แม้โมเดลที่มีความลึกไม่มากก็สามารถบรรลุผลลัพธ์ที่มีประสิทธิภาพสูงได้ ทั้งนี้ยังสะท้อนถึงความสำคัญของกระบวนการเตรียมข้อมูล เช่น การแปลงภาพเป็นระดับสีเทา การปรับขนาดภาพ และการจัดการข้อมูลอย่างสมดุลระหว่างกลุ่มปกติและกลุ่มที่เป็นโรค

ในมุมมองทางคลินิก ค่าความแม่นยำ 94% และค่า AUC 0.98 จากการวิเคราะห์ Heatmap ของ Grad-CAM พบว่าโมเดลให้ความสนใจกับบริเวณ Optic Cup, Neuroretinal Rim และเส้นเลือดรอบขั้วประสาทตา ซึ่งเป็นบริเวณที่มีการเปลี่ยนแปลงทางผู้ป่วยต้อหิน (Jonas et al., 2017) การโฟกัสดังกล่าวแสดงว่าโมเดลได้เรียนรู้คุณลักษณะที่เกี่ยวข้องโดยตรงกับกลไกการเกิดโรค เช่น การบางลงของ Rim และการเพิ่มของ Cup-to-Disc Ratio ซึ่งสัมพันธ์กับการสูญเสียเส้นใยประสาทตา (RNFL loss) (Medeiros and Jammal, 2022) อธิบายได้ว่าเหตุใดโมเดลจึงให้ผลลัพธ์ที่แม่นยำสูง และสามารถใช้เป็นเครื่องมือช่วยคัดกรองโรคต้อหินในระบบ tele-ophthalmology ได้อย่างมีประสิทธิภาพ ระบบสามารถทำหน้าที่เป็นเครื่องมือคัดกรองเบื้องต้น (Screening Tool) เพื่อช่วยแพทย์ระบุผู้ป่วยที่มีความเสี่ยงต่อโรคต้อหินได้อย่างมีประสิทธิภาพ โดยเฉพาะในสถานพยาบาลที่ไม่มีจักษุแพทย์ประจำ การที่โมเดลสามารถระบุบริเวณที่มีความผิดปกติได้จาก Heatmap ของ Grad-CAM ยังช่วยให้แพทย์สามารถตรวจสอบจุดสนใจของโมเดลและใช้ประกอบการตัดสินใจเชิงคลินิกได้อย่างโปร่งใส (Kurmann et al., 2020; Jammal et al., 2021) นอกจากนี้ ความสามารถของโมเดลในการเรียนรู้ลักษณะของ Cup-to-Disc Ratio และความหนาแน่นของเส้นเลือดจากภาพถ่าย fundus ยังสอดคล้องกับเกณฑ์วินิจฉัยทางคลินิก (Clinical Diagnostic Criteria) ที่ใช้ในโรงพยาบาลทั่วไป (Jonas et al., 2017) จึงมีศักยภาพสูงในการนำไปใช้งานจริงภายใต้ระบบ tele-ophthalmology หรือโปรแกรมตรวจสุขภาพตาเชิงรุก (Medeiros and Jammal, 2022).

ผลการวิจัยแสดงให้เห็นว่า โมเดล CNN ที่ออกแบบมาอย่างเหมาะสมสามารถประมวลผลและจำแนกภาพทางการแพทย์ได้อย่างแม่นยำโดยไม่ต้องพึ่งพาโมเดลขนาดใหญ่หรือซับซ้อน อีกทั้งยังแสดงศักยภาพในการนำไปพัฒนาต่อเพื่อใช้เป็นเครื่องมือช่วยวินิจฉัยโรคต้อหินในขั้นต้น ช่วยลดภาระของแพทย์ และเพิ่ม

โอกาสในการตรวจพบโรคตั้งแต่ระยะเริ่มต้น ผลลัพธ์ความแม่นยำ (Accuracy) 94% และค่า AUC 98% สูง เนื่องจากโมเดล CNN 5 ชั้นถูกออกแบบให้เหมาะสมกับลักษณะของภาพจอประสาทตา สามารถสกัดคุณลักษณะสำคัญของโรคต้อหินได้อย่างแม่นยำ อีกทั้งกระบวนการเตรียมข้อมูล เช่น การปรับขนาดภาพ การแปลงเป็นระดับสีเทา และการจัดสมมูลของข้อมูล ทำให้โมเดลเรียนรู้ได้อย่างเต็มที่ การฝึกโมเดลจนถึงจำนวนรอบที่เหมาะสม พร้อมการเลือกพารามิเตอร์ที่ดี ทำให้โมเดลมีความเสถียรและสามารถจำแนกภาพดวงตาได้อย่างมีประสิทธิภาพสูงสุด

กิตติกรรมประกาศ

ผู้วิจัยขอขอบพระคุณโรงพยาบาลราชธานี โรจนะ จังหวัดพระนครศรีอยุธยา ที่ให้ความอนุเคราะห์ข้อมูลจากผู้รับบริการตรวจสุขภาพ ระหว่างปีการศึกษา 2566-2567 เพื่อใช้ในการศึกษาวิจัยในครั้งนี้ นอกจากนี้ผู้วิจัยขอขอบพระคุณ ผศ.ดร.ปริญญา นาโท อาจารย์ที่ปรึกษาวิทยานิพนธ์ และคณาจารย์ทุกท่าน ประจำหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการนวัตกรรมดิจิทัล คณะบริหารธุรกิจและเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ ศูนย์พระนครศรีอยุธยา วาสุกกรี ที่ให้การสนับสนุนและให้คำแนะนำตลอดกระบวนการศึกษาวิจัยในทุกขั้นตอน

เอกสารอ้างอิง

- จิราภรณ์ บุญประเสริฐ. (2564). ปัจจัยเสี่ยงของโรคต้อหินในประชากรไทย. *วารสารวิจัยสุขภาพ*, 25(3), 100-110.
- ทรงกรด พิมพิศาล, และณัฐวุฒิ ศรีวิบูลย์. (2563). การจำแนกระดับความรุนแรงของโรคเบาหวานขึ้นจอประสาทตาด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน. *วารสารวิชาการเทคโนโลยีและสถิติ*, 13(1), 15-26. <https://doi.org/10.14456/jist.2020.14>
- ศิริพร วงศ์คำ. (2565). *การศึกษาการพบโรคต้อหินในผู้ป่วยหลังผ่าตัดต้อกระจกที่โรงพยาบาลเชียงใหม่ประชาชนุเคราะห์*. โรงพยาบาลเชียงใหม่ประชาชนุเคราะห์.
- สำนักโรคตา. (2563). *รายงานสถานการณ์โรคต้อหินในประเทศไทย*. สำนักโรคตา กรุงเทพมหานคร.
- Ahmed, M., Rahman, S., and Chowdhury, A. (2025). OcuMDNet: A lightweight CNN for robust multi-disease classification using fundus images. *Experimental Eye Research*, 242, 110278. <https://doi.org/10.1016/j.exer.2025.110278>
- Ehrlich, J. R., Lee, D. J., Friedman, D. S., Boland, M. V., Ramulu, P. Y., and Swenor, B. K. (2024). Prevalence of glaucoma among US adults in 2022. *JAMA Ophthalmology*, 142(11), 1046-1053. <https://doi.org/10.1001/jamaophthalmol.2024.3884>
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., and Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>
- George, R., Ve, R. S., Baskaran, M., Ramesh, S. V., Raju, P., Arvind, H., and Vijaya, L. (2003). The Chennai Glaucoma Study: Prevalence of glaucoma in a rural population. *Investigative Ophthalmology & Visual Science*, 44(10), 4262-4269. <https://doi.org/10.1167/iovs.03-0274>
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., and Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402-2410. <https://doi.org/10.1001/jama.2016.17216>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). *MobileNets: Efficient convolutional neural networks for mobile vision applications*. arXiv:1704.04861.

- Jammal, A. A., Thompson, A. C., Mariottoni, E. B., Berchuck, S. I., and Medeiros, F. A. (2021). Human-machine collaboration for glaucoma detection and visual field prediction. *Ophthalmology*, *128*(11), 1572-1574. <https://doi.org/10.1016/j.ophtha.2021.05.002>
- Jonas, J. B., Aung, T., Bourne, R. R. A., Bron, A. M., Ritch, R., and Panda-Jonas, S. (2017). Glaucoma. *The Lancet*, *390*(10108), 2183-2193. [https://doi.org/10.1016/S0140-6736\(17\)31469-1](https://doi.org/10.1016/S0140-6736(17)31469-1)
- Kurmann, T., Antoniadis, I., Wong, T. Y., and Webb, A., (2020). In-depth evaluation of saliency maps for interpreting convolutional neural network decisions in the diagnosis of glaucoma based on fundus imaging. *Investigative Ophthalmology & Visual Science*, *61*(7), 2381-2392. <https://doi.org/10.1167/iovs.61.7.2381>
- Li, Z., He, Y., Keel, S., Meng, W., Chang, R. T., and He, M. (2018). Efficacy of a deep learning system for detecting glaucomatous optic neuropathy based on color fundus photographs. *Ophthalmology*, *125*(8), 1199-1206. <https://doi.org/10.1016/j.ophtha.2018.01.023>
- Li, Z., He, Y., Keel, S., Meng, W., Chang, R. T., and He, M. (2020). A comparative study of RGB and grayscale fundus images in glaucoma detection using deep learning. *BMC Ophthalmology*, *20*(1), 245. <https://bmcophthalmol.biomedcentral.com/>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciampi, F., Ghafoorian, M., van Ginneken, B., and Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, *42*, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- Lundervold, A. S., and Lundervold, A. (2019). An overview of deep learning in medical imaging focusing on MRI. *Zeitschrift für Medizinische Physik*, *29*(2), 102-127. <https://doi.org/10.1016/j.zemedi.2018.11.002>
- Medeiros, F. A., and Jammal, A. A. (2022). Artificial intelligence and teleophthalmology: Opportunities and challenges for glaucoma care. *Current Opinion in Ophthalmology*, *33*(2), 93-99. <https://doi.org/10.1097/ICU.0000000000000822>
- Oakden-Rayner, L. (2021). Exploring data leakage in medical imaging datasets. *PMC*.
- Prabhakar, K., Sharma, N., and Gupta, R. (2024). A lightweight CNN for multiclass retinal disease detection under constrained environments. *BMC Ophthalmology*, *24*(2), 310. <https://pmc.ncbi.nlm.nih.gov/articles/PMC12387214/>

- Quigley, H. A., and Broman, A. T. (2006). The number of people with glaucoma worldwide in 2010 and 2020. *British Journal of Ophthalmology*, *90*(3), 262-267. <https://doi.org/10.1136/bjo.2005.081224>
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., and Yang, G. Z. (2017). Deep learning for health informatics. *IEEE Journal of Biomedical and Health Informatics*, *21*(1), 4-21. <https://doi.org/10.1109/JBHI.2016.2636665>
- Saito, T., and Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, *10*(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4510-4520.
- Shibata, N., Tanito, M., Mitsuhashi, K., Fujino, Y., Matsuura, M., Murata, H., and Asaoka, R. (2018). Development of a deep residual learning algorithm to screen for glaucoma from fundus photography. *Scientific Reports*, *8*, 14665. <https://doi.org/10.1038/s41598-018-33013-w>
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., and Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Transactions on Medical Imaging*, *35*(5), 1285-1298. <https://doi.org/10.1109/TMI.2016.2528162>
- Shorten, C., and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, *6*(1), 1-48. <https://doi.org/10.1186/s40537-019-0197-0>
- Tham, Y. C., Li, X., Wong, T. Y., Quigley, H. A., Aung, T., and Cheng, C. Y. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040: A systematic review and meta-analysis. *Ophthalmology*, *121*(11), 2081-2090. <https://doi.org/10.1016/j.ophtha.2014.05.013>
- Thongthong, A. (2021). Prevalence of glaucomatous blindness. *Eye South East Asia*, *16*(2), 69-77. <https://he01.tci-thaijo.org/index.php/eyesea/article/view/248101/171515>
- Vijaya, L., George, R., Baskaran, M., Arvind, H., Raju, P., Ramesh, S. V., Kumaramanickavel, G., and McCarty, C. (2008). Prevalence of primary open-angle glaucoma in an urban south Indian population and comparison with a rural population: The Chennai Glaucoma Study. *Ophthalmology*, *115*(4), 648-654. <https://doi.org/10.1016/j.ophtha.2007.04.062>

Zhang, X., Li, Y., and Wong, T. Y. (2023). Artificial intelligence in glaucoma: Opportunities, challenges, and future directions. *BioMedical Engineering Online*, 22(1), 51.

<https://doi.org/10.1186/s12938-023-01187-8>