

บทความวิจัย (Research Article)

การพัฒนาแบบจำลองการเรียนรู้ของเครื่องแบบบูสตีงเพื่อจำแนกโรคเบาหวาน
ชั้นจอประสาทตาโดยใช้คุณสมบัติซิมเล็ตเวฟเลตส์
Development of Boosting Algorithm Machine Learning Models
for Diabetic Retinopathy Classification Using Symlet Wavelets

ชัชวาลย์ ศรีมนตรี¹ และ ธารัฐ โชติพันธ์^{1*}

Chatchawarn Srimontree¹ and Tanarat Chotiphan^{1*}

¹สาขาวิชาวิทยาการคอมพิวเตอร์ คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏอุบลราชธานี

¹Department of Computer Science, Faculty of Industrial Technology, Ubon Ratchathani Rajabhat University

*Corresponding author email: tanarat.c@ubru.ac.th

วันที่รับบทความ (Received)

16 ธันวาคม 2569

วันที่ได้รับบทความฉบับแก้ไข (Revised)

6 มีนาคม 2569

วันที่ตอบรับบทความ (Accepted)

9 มีนาคม 2569

บทคัดย่อ

งานวิจัยครั้งนี้มีจุดประสงค์เพื่อ 1) พัฒนาและวัดประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่องแบบบูสตีง 2) เพื่อจำแนกภาพถ่ายจอประสาทตาซึ่งมีภาวะโรคเบาหวานชั้นจอประสาทตา ร่วมกับการสกัดคุณสมบัติเวฟเลตส์ทรานส์ฟอร์มประเภทซิมเล็ตจำนวน 10 ชั้นแบนด์ โดยแต่ละชั้นแบนด์แสดงข้อมูลเชิงสถิติได้แก่ ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน พลังงาน เอนโทรปี ความเบ้ และความโด่งทำให้ได้คุณลักษณะซิมเล็ตรวมทั้งสิ้น 60 คุณลักษณะซึ่งถูกนำไปประมวลผลร่วมกับแบบจำลองการเรียนรู้ของเครื่องแบบบูสตีงจำนวน 3 แบบจำลองได้แก่ เอ็กตรึมกราเดียนบูสตีง ไลต์จีบีเอ็ม และแคทบูสตีง โดยงานวิจัยนี้มีการประเมินประสิทธิภาพของแบบจำลองด้วย วิธีการ 10-Fold Cross Validation และตารางเมตริกซ์ความสับสน เพื่อคำนวณหาค่าความแม่นยำ ค่าความไว ค่าความจำเพาะ และประสิทธิภาพโดยรวมของระบบ เพื่อคัดเลือกแบบจำลองที่เหมาะสมที่สุดในการจำแนก ทั้งนี้จากการเปรียบเทียบประสิทธิภาพของแบบจำลองพบว่าแบบจำลองไลต์จีบีเอ็มให้ผลลัพธ์สูงสุดในเกือบทุกตัวชี้วัด โดยมีความแม่นยำร้อยละ 94.47 ความไวร้อยละ 95.24 ความจำเพาะร้อยละ 93.69 และค่าประสิทธิภาพโดยรวมของระบบร้อยละ 94.56 ซึ่งแสดงให้เห็นว่าการประยุกต์ใช้เวฟเลตส์ทรานส์ฟอร์มประเภทซิมเล็ตร่วมกับแบบจำลองการเรียนรู้ของเครื่องแบบบูสตีงสามารถเป็นทางเลือกในการวินิจฉัยโรคเบาหวานชั้นจอประสาทตา

คำสำคัญ: โรคเบาหวานชั้นจอประสาทตา, การเรียนรู้ของเครื่อง, บูสตีง, ซิมเล็ต

Abstract

This research aims to 1) develop and evaluate the performance of boosting machine learning models, and 2) classify retinal images with diabetic retinopathy using symlet wavelet transform feature extraction from 10 sub-bands. A total of 60 symlet features were obtained by extracting six statistical measures, namely mean, standard deviation, energy, entropy, skewness, and kurtosis, from each of the 10 sub-bands. The feature set was fed into three boosting machine learning algorithms, specifically XGBoost, LightGBM, and CatBoost, for classification model development and performance comparison. Model performance was assessed through 10-fold cross-validation and confusion matrix analysis to determine accuracy, sensitivity, specificity, and F1-score metrics for optimal model selection. Comparative performance evaluation demonstrated that the LightGBM model achieved the best overall performance across nearly all evaluation metrics, with an accuracy of 94.47%, sensitivity of 95.24%, specificity of 93.69%, and F1-score of 94.56%. These findings suggest that integrating symlet wavelet features with boosting-based machine learning algorithms provides a promising approach for diabetic retinopathy screening and diagnosis.

Keywords: Diabetic Retinopathy, Machine Learning, Boosting, Symlet

บทนำ

โรคเบาหวานถือเป็นโรคไม่ติดต่อชนิดเรื้อรังที่พบบ่อยและเป็นปัญหาทางด้านสาธารณสุข โดยมีแนวโน้มผู้ป่วยโรคเบาหวานเพิ่มขึ้นอย่างต่อเนื่องในทุกๆปี นอกจากนี้โรคเบาหวานยังเป็นสาเหตุของอาการแทรกซ้อนอื่นๆที่เกี่ยวกับการรักษา โดยเฉพาะอย่างยิ่งโรคเบาหวานขึ้นจอประสาทตา (Diabetic Retinopathy หรือ DR) โรคเบาหวานขึ้นจอประสาทตาเป็นหนึ่งในสาเหตุหลักของการสูญเสียการมองเห็นในผู้ใหญ่ทำงาน โดยองค์การอนามัยโลกประเมินว่าภาวะตาบอดจากโรคเบาหวานขึ้นจอประสาทตามีสัดส่วนร้อยละ 4.8 ของผู้ป่วยตาบอดทั่วโลกคิดเป็นจำนวนประมาณ 1.8 ล้านคน สอดคล้องกับการสำรวจข้อมูลในประเทศไทยซึ่งพบว่าโรคเบาหวานขึ้นจอประสาทตาเป็นสาเหตุของภาวะตาบอดร้อยละ 5.1 ซึ่งสูงกว่าค่าเฉลี่ยสากลร้อยละ 6.25 โดยประมาณ [1,2] จากเหตุปัจจัยดังกล่าวจึงมีการส่งเสริมระบบคัดกรองโรคเช่น การวางแผนทางการตรวจคัดกรองโรคและแนวปฏิบัติที่เป็นมาตรฐานเพื่อลดโอกาสการเกิดโรคเบาหวานขึ้นจอประสาทตา ซึ่งอาจนำไปสู่การสูญเสียการมองเห็น แต่เนื่องจากกระบวนการคัดกรองโรคเบาหวานขึ้นจอประสาทตาต้องใช้บุคลากรที่มีความเชี่ยวชาญสูงต้องมีการตรวจคัดกรองอย่างระมัดระวัง ทำให้ต้องใช้ทรัพยากรทางด้านเวลาส่งผลให้สามารถให้บริการแก่ผู้ป่วยได้ในจำนวนที่น้อยประกอบกับสถานพยาบาลบางแห่งอยู่ในพื้นที่ห่างไกลขาดแคลนบุคลากร ทำให้ผู้ป่วยขาดโอกาสในการตรวจคัดกรองด้วยเครื่องมือและวิธีการที่เหมาะสม จากเหตุปัจจัยดังกล่าวคณะผู้วิจัยจึงมีความประสงค์ในการวิจัยและพัฒนาเพื่อประยุกต์ใช้วิธีการเรียนรู้ของเครื่องเพื่อคัดกรองโรคเบาหวานขึ้นจอประสาทตา โดยคณะผู้วิจัยได้ทำการสังเคราะห์วรรณกรรมและงานวิจัยที่เกี่ยวข้องพบว่าคุณลักษณะเวฟเลตส์ ซึ่งถูกสกัดออกมาในรูปแบบข้อมูลเชิงตัวเลขและสถิติสามารถอธิบายคุณลักษณะของพื้นผิวจอประสาทตาได้เป็นอย่างดีและสามารถนำมาประมวลผลด้วยแบบจำลองวิธีการเรียนรู้ของเครื่องซึ่งให้ผลการจำแนกที่มีความแม่นยำสูง โดยเวฟเลตส์ทรานฟอร์มชนิดซิมเล็ตให้ผลการจำแนกที่แม่นยำมากที่สุดและสามารถเพิ่มประสิทธิภาพให้แบบจำลองได้[3] และการปรับปรุงคุณภาพของภาพก่อนการสกัดคุณลักษณะช่วยให้สกัดคุณลักษณะได้ถูกต้องและครบถ้วนส่งผลต่อความแม่นยำของแบบจำลอง[4,5,6] ทั้งนี้เมื่อเปรียบเทียบประสิทธิภาพของแบบจำลองจากงานวิจัยที่เกี่ยวข้องพบว่าแบบจำลองประเภทบูสต์มีอัตราความแม่นยำในการจำแนกที่สูงมากกว่าแบบจำลองประเภทอื่นประกอบกับมีความเร็วในการประมวลผลข้อมูล มีความแปรปรวนน้อย ลดปัญหาความไม่สมดุลของตัวจำแนก ป้องกันปัญหา

ในกรณีแบบจำลองมีความสามารถในการจำแนกข้อมูลของชุดฝึกข้อมูลได้อย่างมีประสิทธิภาพแต่มีความถูกต้องในการจำแนกข้อมูลของชุดทดสอบในอัตราที่ต่ำ (Overfitting) โดยคุณสมบัติที่โดดเด่นที่สุดคือกระบวนการสร้างแบบจำลองที่มีประสิทธิภาพสูงจากแบบจำลองที่มีประสิทธิภาพต่ำ โดยมีกระบวนการปรับปรุงประสิทธิภาพของแบบจำลองทุกวงรอบการทำงาน โดยแต่ละแบบจำลองจะเรียนรู้จากข้อผิดพลาดของแบบจำลองลำดับก่อนหน้า สามารถตีความคุณลักษณะที่มีความสำคัญต่อการจำแนกได้ง่าย มีความซับซ้อนในกระบวนการประมวลผลที่น้อยกว่า ใช้ทรัพยากรในการประมวลผลข้อมูลน้อยกว่าการใช้แบบจำลองการเรียนรู้เชิงลึกที่มีความนิยมในปัจจุบัน มีความเป็นไปได้ในการนำไปใช้จริงเหมาะแก่การนำไปประยุกต์ใช้ในสถานพยาบาลที่ห่างไกลหรือมีทรัพยากรจำกัดทั้งทางด้านบุคลากรและอุปกรณ์คอมพิวเตอร์ [11,12,13,14,15,16,17] จากการสังเคราะห์วรรณกรรมและงานวิจัยข้างต้นคณะผู้วิจัยมีความต้องการศึกษาวิจัยเพื่อพัฒนาและเปรียบเทียบประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่องแบบบูลสตริงจำนวน 3 แบบจำลองได้แก่ เอ็กตรึมกราเดียนบูลสตริงโลดจ์บีเอ็มและแคทบูลสตริง เพื่อจำแนกภาพถ่ายที่มีและไม่มีภาวะของโรคเบาหวานขึ้นจอประสาทตาโดยอาศัยคุณสมบัติซิมเล็ทซึ่งสกัดจากภาพถ่ายทางการแพทย์พร้อมกับเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 3 แบบด้วยตัวชี้วัดทางสถิติตามมาตรฐานการวิจัยซึ่งประกอบด้วยตารางเมตริกซ์ความสับสน (Confusion Matrix) ค่าความแม่นยำ (Accuracy) ค่าความไว (Sensitivity) ค่าความจำเพาะ (Specificity) และประสิทธิภาพโดยรวมของระบบ (F1-score) เพื่อคัดเลือกแบบจำลองที่เหมาะสมที่สุดสำหรับการจำแนกโรคเบาหวานขึ้นจอประสาทตา

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองในการจำแนกโรคเบาหวานขึ้นจอประสาทตาด้วยภาพถ่ายทางการแพทย์โดยใช้แบบจำลองการเรียนรู้ของเครื่องแบบบูลสตริงร่วมกับการสกัดคุณสมบัติเวฟเลตส์ทรานส์ฟอร์มประเภทซิมเล็ท
2. เพื่อเปรียบเทียบประสิทธิภาพแบบจำลองในการจำแนกโรคเบาหวานขึ้นจอประสาทตาด้วยภาพถ่ายทางการแพทย์โดยอาศัยแบบจำลอง 3 รูปแบบได้แก่ เอ็กตรึมกราเดียนบูลสตริง โลดจ์บีเอ็ม และแคทบูลสตริง

วิธีดำเนินการวิจัย

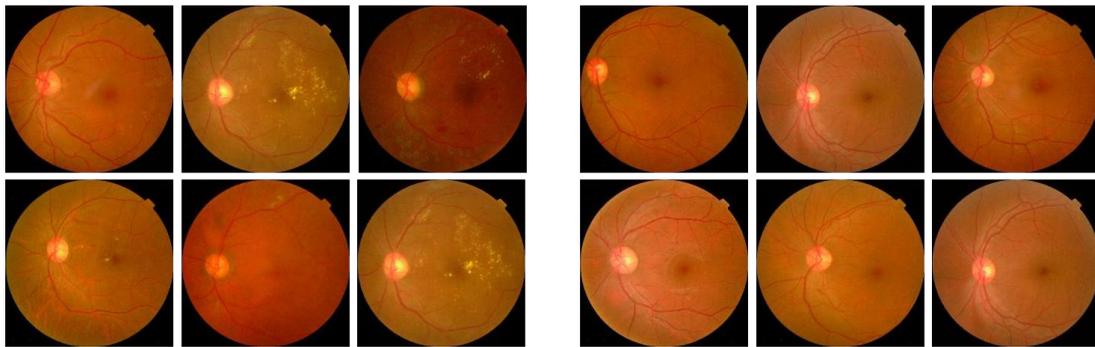
งานวิจัยนี้นำกระบวนการ CRISP-DM (Cross-Industry Standard Process for Data Mining) เป็นแนวทางในการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง เนื่องจากเป็นมาตรฐานการทำงานที่ชัดเจนเป็นระบบ นิยมใช้ในงานวิจัยและโครงการที่เกี่ยวข้องกับการเรียนรู้ของเครื่องและเหมืองข้อมูล โดยกระบวนการนี้แบ่งกระบวนการทำงานออกเป็น 6 ขั้นตอน ซึ่งมีรายละเอียดดังต่อไปนี้

การทำความเข้าใจปัญหา

ผู้ป่วยโรคเบาหวานมีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่องส่งผลให้จำนวนผู้ป่วยโรคเบาหวานขึ้นจอประสาทตามีอัตราการเกิดเพิ่มขึ้นตามไปด้วย โรคเบาหวานขึ้นจอประสาทตาเป็นสาเหตุสำคัญที่ทำให้ผู้ป่วยสูญเสียการมองเห็นหากไม่ได้รับการรักษาทันเวลา ประกอบกับการคัดกรองโรคต้องอาศัยจักษุแพทย์ผู้เชี่ยวชาญในการวินิจฉัย โดยใช้การวินิจฉัยภาพถ่ายจอประสาทตาซึ่งมีข้อจำกัดทั้งด้านบุคลากรและเวลาในการวินิจฉัย ส่งผลให้บริการผู้ป่วยได้ในจำนวนที่น้อยโดยเฉพาะในพื้นที่ห่างไกล งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่องในการจำแนกภาพถ่ายจอประสาทตา เพื่อลดภาระงานของจักษุแพทย์เพิ่มความรวดเร็วในการคัดกรองเป็นทางเลือกซึ่งช่วยให้ตรวจโรคได้รวดเร็วขึ้น แบบจำลองที่พัฒนาขึ้นคาดว่าจะประโยชน์ในการคัดกรองผู้ป่วยกลุ่มเสี่ยง เพิ่มประสิทธิภาพการให้บริการและขยายบริการไปยังพื้นที่ห่างไกลที่ขาดแคลนผู้เชี่ยวชาญ

การทำความเข้าใจข้อมูล

ข้อมูลในงานวิจัยนี้ใช้กระบวนการสกัดซิมเล็ตจากภาพถ่ายจอประสาทตาซึ่งรวบรวมและเผยแพร่เพื่อจุดประสงค์ด้านการศึกษาและวิจัยผ่านเว็บไซต์ www.researchgate.net [7] โดย Parisa Karimi Darabi จำนวนทั้งสิ้น 2,076 ภาพ แบ่งเป็นภาพถ่ายจอประสาทตาที่มีภาวะโรคเบาหวานขึ้นจอประสาทตาจำนวน 1,050 ภาพ และภาพถ่ายจอประสาทตาปกติจำนวน 1,026 ภาพ โดยแต่ละภาพเป็นไฟล์ชนิด JPEG สูง 224 พิกเซลและกว้าง 224 พิกเซล ขนาดความละเอียดที่ 72 พิกเซลต่อนิ้วและใช้โหมดสีอาร์จีบี



ภาพดวงตาที่มีภาวะเบาหวานขึ้นจอประสาทตา

ภาพดวงตาที่ไม่มีภาวะเบาหวานขึ้นจอประสาทตา

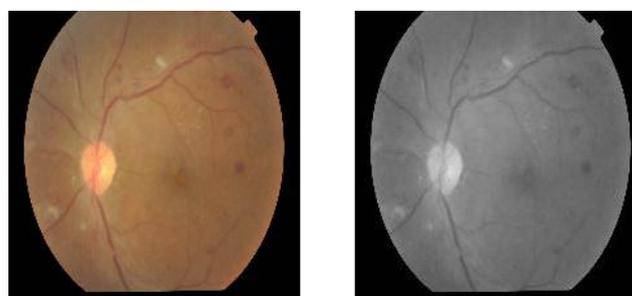
ภาพที่ 1 แสดงตัวอย่างภาพถ่ายจอประสาทตาที่มีและไม่มีภาวะโรคเบาหวานขึ้นจอประสาทตาซึ่งใช้ในงานวิจัย

การเตรียมข้อมูล

การเตรียมข้อมูลในงานวิจัยนี้ประกอบด้วยกระบวนการหลัก 2 กระบวนการคือ กระบวนการปรับปรุงคุณภาพของภาพถ่ายจอประสาทตาและกระบวนการสกัดซิมเล็ต ซึ่งประมวลผลร่วมกับภาพถ่ายจอประสาทตาที่ละภาพจนครบทุกรูปภาพ โดยกระบวนการเตรียมข้อมูลมีรายละเอียดในการดำเนินการดังนี้

1. กระบวนการปรับปรุงคุณภาพของภาพถ่ายจอประสาทตา คือกระบวนการเพิ่มรายละเอียดของรูปภาพให้มีความคมชัดช่วยให้ลักษณะเด่นบนพื้นผิวปรากฏชัดจนมากยิ่งขึ้น ส่งผลให้การสกัดคุณลักษณะของภาพมีความถูกต้องและแม่นยำ นำมาซึ่งการเรียนรู้คุณลักษณะของข้อมูลในกระบวนการสร้างแบบจำลองที่ครบถ้วนและได้แบบจำลองที่มีประสิทธิภาพในการจำแนกสูง กระบวนการดังกล่าวประกอบด้วย 3 กระบวนการย่อยดังนี้

1.1 การเปลี่ยนโหมดภาพเป็นโหมดเกรย์สเกล ส่งผลให้ภาพถ่ายมีความแตกต่างของความเข้มสี สามารถเพิ่มความชัดเจนในการตรวจจับพื้นผิวจอประสาทตาโดยเฉพาะบริเวณที่มีรอยโรคหรือเนื้อเยื่อที่ผิดปกติ ช่วยให้การแยกชั้นแบนด์ด้วยเทคนิคเวฟเลตส์ทรานสฟอร์มมีความแม่นยำส่งผลให้การสกัดคุณลักษณะมีประสิทธิภาพมากขึ้น



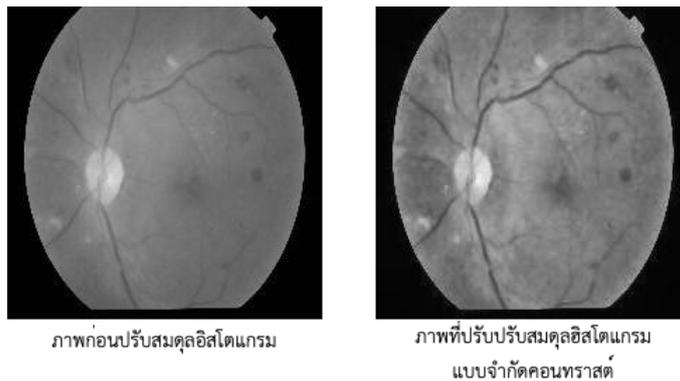
โหมดภาพปกติ

โหมดภาพเกรย์สเกล

ภาพที่ 2 แสดงการเปลี่ยนโหมดภาพให้อยู่ในลักษณะเกรย์สเกล

1.2 การลดสัญญาณรบกวนของภาพด้วยไบแลเทอร์ลฟิลเตอร์ (Bilateral Filter) เป็นวิธีการที่ได้รับความนิยมในงานวิจัย เนื่องจากใช้ทั้งตัวกรองเชิงพื้นที่ (Spatial Filter) ซึ่งพิจารณาระยะห่างทางกายภาพระหว่างพิกเซลโดยพิกเซลที่อยู่ใกล้กันจะมีน้ำหนักมากกว่าพิกเซลที่อยู่ไกล และตัวกรองช่วงความเข้มสี (Range Filter) ซึ่งพิจารณาความแตกต่างของค่าความเข้มสีระหว่างพิกเซลโดยพิกเซลที่มีความเข้มใกล้เคียงกันจะได้รับน้ำหนักมากกว่าทำให้รักษาเส้นขอบของโครงสร้างได้ดี เนื่องจากตำแหน่งของพิกเซลซึ่งอยู่คนละด้านของขอบมีค่าความเข้มสีที่ต่างกันมากจึงไม่ถูกนำมาเป็นส่วนเดียวกันทำให้สามารถลดสัญญาณรบกวนได้ดีแต่ยังคงรายละเอียดที่สำคัญเช่นขอบของเส้นเลือด รอยสสารคัดหลัง และก้อนเลือดขนาดเล็กซึ่งเป็นลักษณะเฉพาะของโรค สามารถสกัดคุณลักษณะที่มีความหมายได้แม่นยำขึ้น ลดปัญหาการเรียนรู้ที่มากจนเกินไปซึ่งเกิดจากสัญญาณรบกวนและเพิ่มประสิทธิภาพในการจำแนกโรค อย่างไรก็ตามควรปรับค่าพารามิเตอร์ให้เหมาะสมเพื่อไม่ให้สูญเสียรายละเอียดที่สำคัญตามคำแนะนำจากงานวิจัยของ Tomasi and Manduchi [4] โดยงานวิจัยนี้กำหนดค่าเส้นผ่านศูนย์กลางของพื้นที่ที่ต้องการพิจารณารอบพิกเซลเป้าหมายที่ 5 พิกเซล ($d=5$) ความแตกต่างของสีที่ 35 ($\sigma_{\text{Color}}=35$) และระยะห่างระหว่างพิกเซลที่ 35 ($\sigma_{\text{Space}}=35$)

1.3 การปรับสมดุลฮิสโตแกรมแบบจำกัดคอนทราสต์ (Contrast Limited Adaptive Histogram Equalization หรือ CLAHE) เป็นเทคนิคที่ใช้ปรับปรุงคุณภาพของภาพโดยการทำให้รายละเอียดในส่วนสว่างและมืดชัดเจนขึ้นโดยไม่สูญเสียข้อมูล ช่วยกระจายค่าความเข้มของพิกเซลให้มีความสม่ำเสมอและลดปัญหาคอนทราสต์ที่สูงเกินไปส่งผลให้การสกัดคุณลักษณะมีความแม่นยำมากขึ้นและช่วยเพิ่มประสิทธิภาพในการจำแนกข้อมูลของแบบจำลองการเรียนรู้ของเครื่อง สอดคล้องกับงานวิจัยโดย Rasta et al. [5] ซึ่งใช้ CLAHE เพื่อเพิ่มความคมชัดในภาพจอประสาทตา ผลการวิจัยแสดงให้เห็นว่ากระบวนการดังกล่าวสามารถเพิ่มความคมชัดให้แก่อวัยวะและสามารถเพิ่มความไวของแบบจำลองได้ถึงร้อยละ 5 โดยที่ความแม่นยำไม่ลดลง นอกจากนี้ยังสอดคล้องกับงานวิจัยโดย Mutawa et al. [6] ซึ่งใช้ CLAHE ปรับปรุงความสมบูรณ์ของรูปภาพให้มีความคมชัดก่อนนำไปสกัดเวฟเลตส์แบบไม่ต่อเนื่องเพื่อใช้เป็นคุณสมบัติในการจำแนกโรคเบาหวานขึ้นจอประสาทตาด้วยแบบจำลองการเรียนรู้เชิงลึก ผลการทดลองพบว่าสามารถจำแนกจอประสาทตาที่ปกติได้ดีและมีผลการวัดประสิทธิภาพแบบจำลองด้วยการวิเคราะห์กราฟพื้นที่ได้เส้นโค้งอาร์โอซีที่สูง โดยงานวิจัยนี้กำหนดค่าจำกัดการเพิ่มคอนทราสต์ที่ 2.0 ($\text{clipLimit} = 2.0$) ขนาดของกริดสำหรับแบ่งภาพที่ 8 ($\text{tileGridSize} = 8$)



ภาพที่ 3 แสดงการเปรียบเทียบภาพถ่ายจอประสาทตาก่อนและหลังการปรับปรับสมดุลฮิสโตแกรมแบบจำกัดคอนทราสต์

2. การสกัดคุณลักษณะซิมเล็ต (Symlet 4) ซึ่งเป็นเวฟเลตส์ซึ่งแต่ละซิมแบนด์ให้ข้อมูลที่ซับซ้อนน้อยและเป็นอิสระจากกันสามารถสร้างภาพต้นฉบับกลับมาได้อย่างสมบูรณ์แบบไม่สูญเสียข้อมูล มีความเร็วในการคำนวณสูงผ่านอัลกอริทึมฟาสต์เวฟเลตส์ทรานสฟอร์ม ซึ่งเหมาะสมต่อการประยุกต์ใช้ในระบบวินิจฉัยที่ต้องการผลแบบเรียลไทม์และมีความเสถียรในกระบวนการประมวลผลเชิงตัวเลข ทำให้การคำนวณมีความแม่นยำสูงโดยไม่มีปัญหาความคลาดเคลื่อนสะสม

ในการศึกษานี้ใช้การแยกย่อยแบบ 3 ระดับโดยมีซับแบนด์รวม 10 ซับแบนด์ได้แก่ ซับแบนด์ประมาณค่า (LL3) จำนวน 1 ซับแบนด์และซับแบนด์เชิงรายละเอียดได้แก่รายละเอียดในแนวตั้ง (LH1, LH2, LH3) รายละเอียดในแนวนอน (HL1, HL2, HL3) และรายละเอียดในแนวทแยง (HH1, HH2, HH3) รวมจำนวน 9 ซับแบนด์ จากนั้นสกัดค่าสถิติเชิงปริมาณจากแต่ละซับแบนด์ประกอบด้วย ค่าเฉลี่ย (Mean) ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) พลังงาน (Energy) เอนโทรปี (Entropy) ความเบ้ (Skewness) และความโด่ง (Kurtosis) ทั้งนี้จากการสกัดค่าสถิติจำนวน 6 ค่าในทุกซับแบนด์ทั้ง 10 ซับแบนด์ส่งผลให้ได้คุณลักษณะซีมเล็ทเวฟเลตส์รวมทั้งสิ้น 60 คุณลักษณะ คุณลักษณะดังกล่าวเป็นสถิติที่สามารถสะท้อนโครงสร้าง ความหนาแน่น ความผันแปรของเนื้อสัมผัส ความซับซ้อนเชิงความถี่ และรูปแบบของความแปรผันในภาพซึ่งได้รับการยอมรับอย่างแพร่หลายในประเด็นความเหมาะสมสำหรับใช้ในงานจำแนกภาพทางการแพทย์ โดยเฉพาะงานที่ต้องการตรวจหารูปแบบทางพยาธิสภาพที่ปรากฏในภาพจอประสาทตา ค่าทางสถิติเหล่านี้สามารถนำมาประยุกต์ใช้ในการอธิบายและตีความลักษณะทางพยาธิสภาพของภาพได้ โดยรายละเอียดของแต่ละคุณลักษณะมีดังต่อไปนี้

ค่าเฉลี่ย (Mean) สะท้อนถึงระดับความสว่างโดยรวมในแต่ละซับแบนด์ใช้ในการอธิบายการเปลี่ยนแปลงของสีและความหนาแน่นของเนื้อเยื่อ โดยภาวะเบาหวานขึ้นจอประสาทต้ามักทำให้เกิดพื้นที่ที่มีความสว่างผิดปกติ ยกตัวอย่างเช่น การสะสมของไขมันและโปรตีนที่รั่วซึมออกมาจากหลอดเลือดขนาดเล็กที่มีความสว่างสูง หรือเลือดออกในจอประสาทตาที่มีความสว่างต่ำ

ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) วัดความผันแปรหรือความแตกต่างของค่าพิกเซลในแต่ละซับแบนด์ โดยจอประสาทตาที่มีรอยโรคมักมีความผันแปรสูง เนื่องจากมีพื้นที่ซึ่งมีความผิดปกติปะปนกับพื้นที่ปกติในขณะที่จอประสาทตาปกติมีความสม่ำเสมอมากกว่า

พลังงาน (Energy) วัดความเข้มของสัญญาณในซับแบนด์ ค่าพลังงานสูงบ่งชี้ว่ามีโครงสร้างที่เด่นชัดในทิศทางนั้นๆ เช่น หลอดเลือดที่โดดเด่น หรือสารคัดหลั่งที่รั่วซึมออกมาจากหลอดเลือดในจอประสาทตาและสะสมในเนื้อเยื่อจอประสาทตาที่มีขอบชัดเจนซึ่งเป็นลักษณะสำคัญของภาวะเบาหวานขึ้นจอประสาทตา

เอนโทรปี (Entropy) วัดระดับความสับสนหรือความไม่เป็นระเบียบของข้อมูลในซับแบนด์ จอประสาทตาที่เป็นโรคมักมีค่าเอนโทรปีสูงเนื่องจากการกระจายตัวของรอยโรคที่ไม่สม่ำเสมอและมีความหลากหลายของลักษณะรอยโรค

ความเบ้ (Skewness) วัดความไม่สมมาตรของการกระจายตัวของค่าพิกเซล ช่วยบ่งชี้ให้เห็นพื้นที่ของรอยโรคที่มีการกระจายตัวไปในทิศทางใดทิศทางหนึ่ง

ความโด่ง (Kurtosis) วัดความแหลมของการกระจายตัวของค่าพิกเซล ใช้ตรวจหาความผิดปกติบนจอประสาทตาที่เป็นโรคซึ่งมักมีค่าความโด่งสูงเช่นจุดโป่งพองของหลอดเลือดขนาดเล็ก หรือรอยเลือดออกในจอประสาทตาขนาดเล็กที่กระจายอยู่บนพื้นผิวจอประสาทตา

การรวมคุณลักษณะเชิงสถิติทั้ง 6 ประเภทจาก 10 ซับแบนด์ ทำให้ได้คุณลักษณะที่มีความหลากหลายและครอบคลุม สามารถอธิบายลักษณะของจอประสาทตาทั้งในด้านโครงสร้าง พื้นผิว และการกระจายตัวของรอยโรคได้อย่างครอบคลุม ทั้งนี้จากงานวิจัยโดย Onjun et al. [3] ซึ่งได้เปรียบเทียบประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่องเพื่อจำแนกโรคเบาหวานขึ้นจอประสาทตาโดยคุณสมบัตินิวเวฟเลตส์ทรานสฟอร์มหลายประเภทพบว่า ซีมเลตส์มีประสิทธิภาพมากที่สุด โดยงานวิจัยนี้ใช้ภาษาไพธอนและไลบรารีที่เกี่ยวข้องในกระบวนการปรับปรุงคุณภาพของภาพถ่ายจอประสาทตาและกระบวนการสกัดซีมเล็ทได้แก่ พายเวฟเลตส์ ซายคิตอิมเมจ และโอเพนซีวีไพธอน [8,9,10]

ตารางที่ 1 แสดงตัวอย่างข้อมูลซีเอ็มแอลทีเอสที่ได้จากรูปภาพจอประสาทตา

Filename	label	LL_mean	LL_std	LL_energy	LL_entropy	LL_skewness	LL_kurtosis	LH3_mean	LH3_std	HH1_kurtosis
image1.jpg	DR	1.6380904	1.2465191	20762.033	10.1780556	-0.2019425	-0.9855628	0.000226813	0.03871111	123.38309
image2.jpg	DR	2.2330031	1.6203383	37297.812	5.8154615	-0.5372592	-1.4594787	0.000154046	0.03974638	113.77922
image3.jpg	DR	2.0782492	1.3079135	29545.81	23.5996891	-0.6137872	-0.7221148	0.000164078	0.03656798	130.96774
image4.jpg	DR	2.0015419	1.5169828	30906.293	7.49547412	-0.4219075	-1.5229849	-0.000808444	0.0791712	95.59997
image5.jpg	DR	2.173807	1.5953403	35625.684	9.8295825	-0.4431141	-1.3240011	0.000202344	0.04100434	109.89609
image6.jpg	DR	3.0620954	1.8810558	63282.523	35.0537693	-0.8035863	-0.8901322	0.000121285	0.07127795	151.81905
image7.jpg	NoDR	2.6050832	1.9281298	51470.305	18.7874393	-0.4749492	-1.4979994	-0.000223355	0.06478397	130.10301
image8.jpg	NoDR	2.3633091	1.4692249	37944.88	28.256057	-0.7051584	-0.8164132	0.000313066	0.04910117	135.5849
image9.jpg	NoDR	1.7782497	1.3880838	24935.848	31.4572532	-0.0208547	-0.6915608	0.000907717	0.12215602	44.789097
image10.jpg	NoDR	2.022906	1.527863	31489.918	22.0592919	-0.2072884	-0.9433601	-0.000228735	0.0869123	87.84205
image11.jpg	NoDR	1.2441466	0.9464966	11974.407	-9.1199261	-0.3036606	-1.3705189	0.000968922	0.0249347	85.797104

การสร้างแบบจำลอง

งานวิจัยครั้งนี้มุ่งเน้นการสร้างแบบจำลองประเภทบูสตีงซึ่งเป็นแบบจำลองในลักษณะต้นไม้ตัดสินใจหลายต้นที่สามารถปรับปรุงประสิทธิภาพของแบบจำลองตามวงรอบโดยปรับปรุงข้อผิดพลาดของแบบจำลองก่อนหน้าพร้อมทั้งทดลองเปรียบเทียบประสิทธิภาพเพื่อหาแบบจำลองที่ดีที่สุดในการจำแนกโรคเบาหวานขึ้นจอประสาทตาสอดคล้องกับงานวิจัยโดย Ganie et al. [11] ซึ่งใช้แบบจำลองที่คล้ายคลึงกับวิจัยในครั้งนี้ โดยผลการวิจัยพบว่าแบบจำลองประเภทบูสตีงมีความรวดเร็วในการประมวลผล มีความแปรปรวนน้อย สามารถลดความคลาดเคลื่อนในการจำแนก ทั้งนี้งานวิจัยครั้งนี้ประกอบด้วยแบบจำลองแบบบูสตีงจำนวน 3 แบบจำลองดังต่อไปนี้

1. แบบจำลองเอ็กตรีเมกราดิเอนบูสตีง[12] เป็นแบบจำลองการเรียนรู้ของเครื่องซึ่งทำงานโดยการสร้างต้นไม้ตัดสินใจหลายต้นแบบต่อเนื่องไต่ระดับ โดยต้นไม้ตัดสินใจแต่ละต้นที่สร้างขึ้นใหม่จะเรียนรู้จากข้อผิดพลาดของต้นไม้ตัดสินใจก่อนหน้าเพื่อเพิ่มประสิทธิภาพของแบบจำลอง แบบจำลองนี้มีคุณลักษณะที่โดดเด่นเนื่องจากมีกระบวนการควบคุมความซับซ้อนของแบบจำลองซึ่งสามารถป้องกันปัญหาโอเวอร์ฟิตติงของแบบจำลอง โดยการเพิ่มค่าการลงโทษให้กับแบบจำลองที่มีความซับซ้อนสูง ทำให้แบบจำลองไม่เกิดการเรียนรู้รายละเอียดหรือสัญญาณรบกวนที่เกิดจากข้อมูลชุดฝึกมากเกินไป และสามารถทำนายข้อมูลใหม่ได้แม่นยำขึ้น สามารถจัดการกับข้อมูลสูญหายได้ดี จากงานวิจัยโดย Yang and Yang [13] ได้ทำการวิจัยโดยรวบรวมผลการตรวจร่างกายซึ่งเป็นข้อมูลเชิงตัวเลขเพื่อประมวลผลด้วยแบบจำลองการเรียนรู้ของเครื่องพบว่าแบบจำลองเอ็กตรีเมกราดิเอนบูสตีงมีความแม่นยำสูงถึงร้อยละ 91.25 โดยการเรียนรู้เพื่อจำแนกภาพถ่ายโรคเบาหวานขึ้นจอประสาทตาครั้งนี้กำหนดค่าไฮเปอร์พารามิเตอร์โดยกำหนดจำนวนต้นไม้ตัดสินใจ 100 ต้น ($n_{estimators}=100$) ความลึกสูงสุด 4 ระดับ ($max_depth=4$) อัตราการเรียนรู้ที่ 0.1 ($learning_rate=0.1$) สัดส่วนการสุ่มตัวอย่างข้อมูลที่ 0.8 ($subsample=0.8$) สัดส่วนการสุ่มเลือกคุณลักษณะต่อต้นที่ 0.8 ($colsample_bytree=0.8$) น้ำหนักขั้นต่ำของซิลด์โหนดที่ 1 ตัวอย่าง ($min_child_weight=1$) ค่าการลดความสูญเสียขั้นต่ำสำหรับการแบ่งข้อมูลที่ 0 ($gamma=0$) การปรับค่าแบบ L1 ที่ 0 ($reg_alpha=0$) การปรับค่าแบบ L2 ที่ค่า 1 ($reg_lambda=1$) ใช้วิธีการสร้างต้นไม้แบบฮิสโตแกรม ($tree_method='hist'$) ฟังก์ชันวัดประสิทธิภาพแบบล็อกลอส ($eval_metric='logloss'$) น้ำหนักของคลาสมีการที่ปรับสมดุลอัตโนมัติ ($scale_pos_weight$) และกำหนดค่าควบคุมการสุ่มที่ 42 ($random_state=42$)

2. แบบจำลองโลตจีบีเอ็ม[14] เป็นแบบจำลองกราเดียนบูสต์ซึ่งพัฒนาขึ้นเพิ่มเติมเพื่อเพิ่มประสิทธิภาพในการประมวลผลข้อมูลขนาดใหญ่ ใช้หลักการสร้างต้นไม้ตัดสินใจหลายต้นแบบต่อเนื่องโดยแต่ละต้นจะเรียนรู้จากความผิดพลาดของต้นไม้ตัดสินใจต้นก่อนหน้า แบบจำลองโลตจีบีเอ็มมีจุดเด่นคือใช้การคัดเลือกข้อมูลที่มีความสำคัญสูงและสุ่มตัวอย่างข้อมูลที่มีความสำคัญต่ำเพียงบางตัวอย่างทำให้ลดเวลาการฝึกสอนแบบจำลองโดยไม่สูญเสียความแม่นยำมากจนเกินไป สามารถใช้เทคนิคการรวมคุณสมบัติมีลักษณะพิเศษเข้าด้วยกันเพื่อลดมิติข้อมูลและเพิ่มความเร็วในการประมวลผลและสร้างต้นไม้ตัดสินใจโดยเลือกขยายลิฟโหนดที่ช่วยลดความผิดพลาดได้มากที่สุดในแต่ละครั้งแทนกระบวนการขยายทุกลิฟโหนด ทำให้แบบจำลองเรียนรู้ได้เร็วขึ้นและใช้หน่วยความจำน้อยกว่า Rufo et al. [15] ได้ศึกษาวิจัยโดยใช้แบบจำลองโลตจีบีเอ็มเพื่อทำนายการเกิดโรคเบาหวาน จากผลการทดลองพบว่าแบบจำลองโลตจีบีเอ็มมีการใช้หน่วยความจำที่ต่ำกว่าแต่มีประสิทธิภาพการทำงานที่ดีและมีความเร็วในการประมวลผลสูงกว่าถึง 7 เท่าตัว และมีความเข้ากันได้กับชุดข้อมูลขนาดใหญ่เมื่อเปรียบเทียบกับแบบจำลองเอ็กริมกราเดียนบูสต์และมีความแม่นยำที่ดีกว่าแบบจำลองชนิดบูสต์ดั้งแบบอื่น สามารถประยุกต์ใช้เป็นแนวทางในการศึกษาและวิจัยในครั้งนี้ การวิจัยครั้งนี้กำหนดค่าไฮเปอร์พารามิเตอร์ของแบบจำลองโลตจีบีเอ็มโดยกำหนดจำนวนต้นไม้ตัดสินใจ 100 ต้น ($n_{estimators}=100$) ความลึกสูงสุด 4 ระดับ ($max_depth=4$) จำนวนลิฟโหนดสูงสุดที่ 15 โหนด ($num_leaves=15$) จำนวนตัวอย่างขั้นต่ำในลิฟโหนด 20 ตัวอย่าง ($min_child_samples=20$) อัตราการเรียนรู้ที่ 0.1 ($learning_rate=0.1$) สัดส่วนการสุ่มตัวอย่างข้อมูล 0.8 พร้อมความถี่การทำแบกกิ้งในทุกรอบ ($subsample=0.8$, $bagging_freq=1$) สัดส่วนการสุ่มเลือกคุณลักษณะของต้นไม้ตัดสินใจที่ 0.8 ($feature_fraction=0.8$) การปรับค่า L1 และ L2 เท่ากับ 0 ($reg_alpha=0$, $reg_lambda=0$) น้ำหนักคลาสแบบสมดุล ($is_unbalance=true$) และกำหนดค่าควบคุมการสุ่มที่ 42 ($random_state=42$)

3. แบบจำลองแคทบูสต์[16] เป็นแบบจำลองการเรียนรู้ของเครื่องที่พัฒนาเพิ่มเติมจากกราเดียนบูสต์โดยใช้ต้นไม้ตัดสินใจเป็นพื้นฐาน มีจุดเด่นคือสามารถจัดการข้อมูลแบบจัดกลุ่มได้โดยตรงโดยไม่ต้องแปลงเป็นค่าตัวเลขทำให้ประหยัดเวลาและรักษาคุณลักษณะดั้งเดิมของข้อมูลได้ดีกว่า Xu et al. [17] ได้ศึกษาวิจัยโดยใช้แบบจำลองแคทบูสต์เพื่อจำแนกโรคเบาหวานขึ้นจอประสาทตาโดยวิเคราะห์ตัวแปรความเสี่ยงที่นำไปสู่โรคเบาหวานขึ้นจอประสาทตา ผลการทดลองพบว่าแบบจำลองแคทบูสต์สามารถประมวลผลคุณสมบัติแบบแบ่งประเภทโดยอัตโนมัติ สามารถลดปัญหาโอเวอร์ฟิตติ้งการวิจัยเพื่อจำแนกภาพถ่ายโรคเบาหวานขึ้นจอประสาทตาครั้งนี้กำหนดค่าไฮเปอร์พารามิเตอร์ของแบบจำลองแคทบูสต์โดยกำหนดจำนวนรอบการทำซ้ำที่ 100 รอบ ($iterations=100$) ความลึกสูงสุด 4 ระดับ ($depth=4$) อัตราการเรียนรู้ที่ 0.1 ($learning_rate=0.1$) สัดส่วนการสุ่มตัวอย่างข้อมูล 0.8 ($subsample=0.8$) สัดส่วนการสุ่มเลือกคุณลักษณะของต้นไม้ตัดสินใจที่ 0.8 ($rsm=0.8$) ค่าสัมประสิทธิ์การปรับค่าแบบ L2 สำหรับลิฟโหนดเท่ากับ 3 ($l2_leaf_reg=3$) กำหนดค่าควบคุมการสุ่มที่ 42 ($random_state=42$) และปิดการแสดงผลระหว่างการฝึกสอน ($verbose=False$)

งานวิจัยนี้ใช้ภาษาไพธอนและไลบรารีในการสร้างแบบจำลองได้แก่ แพนดาส นัมพาย ซายคิทีลีน และซายพาย [18, 19, 20, 21] เป็นเครื่องมือในการพัฒนาแบบจำลอง ซึ่งไลบรารีดังกล่าวเป็นไลบรารีสำเร็จรูปที่รวบรวมกระบวนการสร้างแบบจำลองทำให้สามารถพัฒนาแบบจำลองได้สะดวกรวดเร็ว มีค่าไฮเปอร์พารามิเตอร์ที่ครบถ้วน กำหนดค่าไฮเปอร์พารามิเตอร์ได้สะดวก ลดการผิดพลาดระหว่างการพัฒนาแบบจำลอง โดยมีเวอร์ชันของแบบจำลองได้แก่ XGBoost เวอร์ชัน 1.7.0, LightGBM เวอร์ชัน 3.3.5 และ CatBoost เวอร์ชัน 1.2.0

การประเมินผล

การประเมินประสิทธิภาพแบบจำลองทั้ง 3 แบบจำลองใช้การแบ่งข้อมูลซิมเล็ตซึ่งสกัดจากภาพถ่ายจอประสาทตาเป็นชุดข้อมูลสำหรับฝึกแบบจำลอง (Training Set) จำนวน 1,660 ภาพและข้อมูลสำหรับทดสอบการจำแนกของแบบจำลอง (Testing Set) จำนวน 416 ภาพ คิดเป็นอัตราส่วนเป็นอัตราส่วนร้อยละ 80 ต่อร้อยละ 20 ตามลำดับโดยอัตราส่วนลักษณะดังกล่าวเป็นอัตราส่วนที่เป็นมาตรฐานในการประเมินประสิทธิภาพของแบบจำลองที่ได้รับการยอมรับในการประเมินประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่อง งานวิจัยนี้ใช้เทคนิค 10-Fold Cross Validation บนชุดข้อมูลสำหรับฝึกแบบจำลอง โดยกระบวนการสร้างแบบจำลองจะแบ่งชุดข้อมูลสำหรับฝึกแบบจำลองออกเป็น 10 ส่วนย่อยและใช้ข้อมูล 9 ส่วนหรือ 1,494 ภาพในการสร้างแบบจำลองและใช้ข้อมูล 1 ส่วนหรือ 166 รูปภาพในการทดสอบแบบจำลองโดยทำซ้ำเป็นจำนวน 10 รอบ ทั้งนี้การแบ่งข้อมูลดังกล่าวใช้วิธีการแบ่งข้อมูลแบบคงสัดส่วนคลาส (Stratified Split) โดยกำหนดค่าตั้งต้นการสุ่ม (Random Seed) เท่ากับ 42 เพื่อรักษาสัดส่วนของแต่ละคลาสให้เท่ากันทั้งในชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ โดยข้อมูลทั้งหมดสามารถสลับหน้าที่ในการเป็นชุดข้อมูลสำหรับฝึกและข้อมูลสำหรับทดสอบแบบจำลอง ทำให้การประเมินผลมีความเป็นมาตรฐานและสะท้อนการกระจายตัวของข้อมูลที่เกิดขึ้นจริง และแบบจำลองสามารถเรียนรู้คุณลักษณะของชุดข้อมูลเพื่อจำแนกข้อมูลได้ดียิ่งขึ้น ช่วยลดข้อผิดพลาดในการประมาณค่าและเพิ่มความน่าเชื่อถือของผลการจำแนกในกระบวนการสร้างแบบจำลอง[22] หลังจากสร้างแบบจำลองจากชุดข้อมูลสำหรับฝึกแบบจำลองเสร็จสิ้น แบบจำลองจะถูกนำไปใช้ทดสอบกับข้อมูลสำหรับทดสอบการจำแนกของแบบจำลอง เพื่อวัดผลการจำแนกด้วยตารางเมตริกซ์ความสับสนพร้อมกับประเมินประสิทธิภาพแบบจำลองด้วยตัวชี้วัดมาตรฐานประกอบด้วย ค่าความแม่นยำ ค่าความไว ค่าความจำเพาะ และค่าประสิทธิภาพโดยรวมของแบบจำลองซึ่งมีรายละเอียดดังต่อไปนี้

1. ตารางเมตริกซ์ความสับสน (Confusion Matrix) คือ ตารางที่ใช้แสดงผลการทำนายของแบบจำลองในการจำแนกประเภทโดยเปรียบเทียบระหว่างค่าจริงกับผลการจำแนกของแบบจำลอง การจำแนกในงานวิจัยนี้สามารถมีการจำแนกในรูปแบบการจำแนก 2 คลาสประกอบด้วยคลาส Positive คือภาพถ่ายจอประสาทตาที่มีภาวะโรคเบาหวานขึ้นจอประสาทตาและคลาส Negative คือภาพถ่ายจอประสาทตาปกติ ทั้งนี้การจำแนกดังกล่าวทำให้มีผลลัพธ์จากการจำแนกโดยแบบจำลองทั้งสิ้น 4 รูปแบบดังนี้

1.1 True Negative (TN) คือ แบบจำลองสามารถจำแนกได้ถูกต้องว่าเป็นภาพถ่ายจอประสาทตาปกติ

1.2 False Positive (FP) คือ การจำแนกที่ผิดพลาดเนื่องจากแบบจำลองจำแนกว่ามีภาวะของโรคแต่เป็นภาพจอประสาทตาปกติที่ไม่มีสภาวะของโรคเบาหวานขึ้นจอประสาทตา

1.3 False Negative (FN) คือ การจำแนกที่ผิดพลาดเนื่องจากแบบจำลองจำแนกว่าไม่มีภาวะของโรคแต่ภาพเป็นภาพจอประสาทตาที่มีภาวะโรคเบาหวานขึ้นจอประสาทตา

1.4 True Positive (TP) คือ แบบจำลองสามารถจำแนกได้ถูกต้องว่าเป็นภาพถ่ายจอประสาทตาที่มีภาวะโรคเบาหวานขึ้นจอประสาทตา

2. ค่าความแม่นยำ (Accuracy) คือ สัดส่วนของการจำแนกที่ถูกต้องทั้งหมดเปรียบเทียบกับจำนวนตัวอย่างทั้งหมดเป็นความสามารถของแบบจำลองในการจำแนกภาพที่มีและไม่มีภาวะโรคเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

3. ค่าความไว (Sensitivity) คือ สัดส่วนของภาพถ่ายจอประสาทตาที่มีภาวะโรคเบาหวานขึ้นจอประสาทตาซึ่งแบบจำลองสามารถจำแนกได้อย่างถูกต้อง ถือเป็นความสามารถของแบบจำลองในการจำแนกภาพถ่ายที่มีภาวะของโรคเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง

$$\text{Sensitivity} = TP / (TP + FN) \quad (2)$$

4. ค่าความจำเพาะ (Specificity) สัดส่วนภาพถ่ายจอประสาทตาที่ไม่มีภาวะโรคเบาหวานขึ้นจอประสาทตา ซึ่งแบบจำลองสามารถจำแนกได้อย่างถูกต้อง ถือเป็นความสามารถของแบบจำลองในการจำแนกภาพถ่ายที่ไม่มีภาวะของโรคเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง

$$\text{Specificity} = \text{TN} / (\text{TN} + \text{FP}) \quad (3)$$

5. ค่าประสิทธิภาพโดยรวมของระบบ (F1-score) คือ ค่าที่ใช้ประเมินประสิทธิภาพของแบบจำลองโดยวัดความสมดุลระหว่างความแม่นยำในการจำแนกภาพได้ถูกต้อง (Precision) และความครบถ้วนในการตรวจจับภาพ (Recall) ในแต่ละคลาส

$$\text{Precision (Positive)} = \text{TP} / (\text{TP} + \text{FP}) \quad (4)$$

$$\text{Recall (Positive)} = \text{TP} / (\text{TP} + \text{FN}) \quad (5)$$

$$\text{Precision (Negative)} = \text{TN} / (\text{TN} + \text{FN}) \quad (6)$$

$$\text{Recall (Negative)} = \text{TN} / (\text{TN} + \text{FP}) \quad (7)$$

$$\text{F1-measure} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (8)$$

การนำไปใช้งาน

แบบจำลองที่พัฒนาขึ้นสามารถนำไปใช้เป็นทางเลือกเพิ่มเติมสำหรับระบบคัดกรองในพื้นที่ห่างไกลหรือขาดแคลนผู้เชี่ยวชาญในการคัดกรองโรค ช่วยลดเวลาในการตรวจวินิจฉัย และเพิ่มโอกาสในการเข้าถึงบริการคัดกรองสำหรับผู้ป่วยที่เสี่ยงต่อการเป็นโรคเบาหวานขึ้นจอประสาทตา สามารถบูรณาการเข้ากับระบบการแพทย์ทางไกล เพื่อส่งผลวิเคราะห์และจัดลำดับความเร่งด่วนก่อนการวินิจฉัยโดยจักษุแพทย์ โดยใช้งานในลักษณะเป็นเครื่องมือช่วยสนับสนุนการตัดสินใจทางคลินิก

ผลการวิจัย

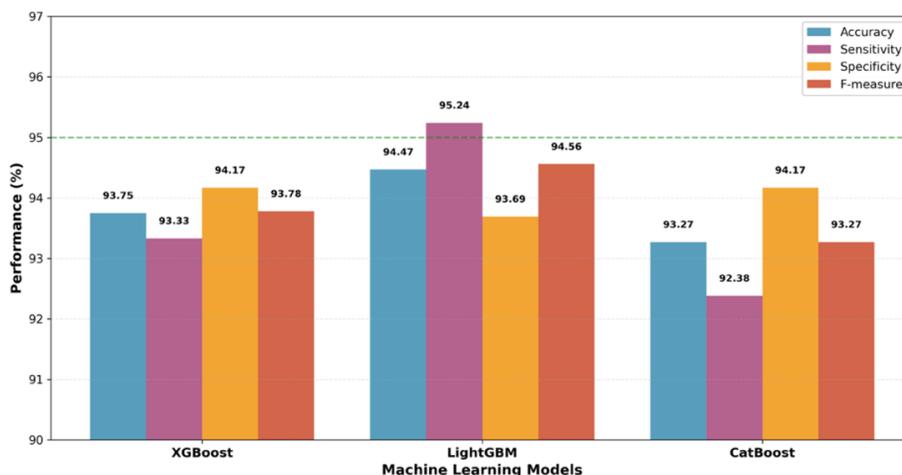
จากตารางที่ 2 แสดงตารางเมตริกซ์ความสับสนซึ่งแสดงผลการจำแนกของแบบจำลอง พบว่าแบบจำลองเอ็กซ์ตรีมกราดิเอนท์สามารถจำแนกผู้ป่วยที่ไม่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง (TN) จำนวน 194 ราย และจำแนกผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง (TP) จำนวน 196 ราย แสดงให้เห็นว่าแบบจำลองมีความคลาดเคลื่อนในการจำแนกประเภทค่อนข้างต่ำ โดยมีการวินิจฉัยเป็นผลบวกหลวง (FP) จำนวน 12 ราย ซึ่งหมายถึงผู้ป่วยที่ไม่มีภาวะเบาหวานขึ้นจอประสาทตาแต่ถูกจำแนกว่ามีภาวะของโรค และมีการวินิจฉัยลบหลวง (FN) จำนวน 14 ราย ซึ่งหมายถึงผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตาแต่ถูกจำแนกว่าไม่มีภาวะของโรค แสดงให้เห็นว่าแบบจำลองมีความสมดุลที่ดีในการจำแนกทั้งผู้ป่วยที่มีภาวะของโรคและไม่มีภาวะของโรค โดยมีอัตราความคลาดเคลื่อนทั้งสองประเภทที่ใกล้เคียงกัน แบบจำลองโลดจ์บีเอ็มสามารถจำแนกผู้ป่วยที่ไม่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง 193 ราย และจำแนกผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้องสูงสุดจำนวน 200 ราย มีค่าการวินิจฉัยบวกหลวง (FP) จำนวน 13 ราย และมีค่าการวินิจฉัยลบหลวง (FN) ต่ำที่สุดเมื่อเทียบกับแบบจำลองอื่นที่ 10 ราย ซึ่งแสดงความสามารถในการตรวจจับผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างมีประสิทธิภาพ โดยมีอัตราการผิดพลาดในการตรวจจับผู้ป่วยที่มีภาวะของโรคต่ำที่สุดมีความสำคัญอย่างยิ่งในทางคลินิก โดยเฉพาะประเด็นการป้องกันการวินิจฉัยผิดพลาดที่อาจนำไปสู่ภาวะแทรกซ้อนรุนแรง เช่นการสูญเสียการมองเห็นถาวร แบบจำลองแคทบูสต์สามารถจำแนกผู้ป่วยที่ไม่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง ที่ 194 ราย และจำแนกผู้ป่วยที่มีภาวะเบาหวานขึ้นจอประสาทตาได้อย่างถูกต้อง 194 ราย มีค่าการวินิจฉัยบวกหลวง (FP) ต่ำที่สุดเมื่อเทียบกับแบบจำลองอื่นที่ 12 ราย แต่มีค่าการวินิจฉัยลบหลวง (FN) สูงสุดจำนวน 16 ราย

ตารางที่ 2 ตารางเมตริกซ์ความสับสนแสดงผลการจำแนกของแบบจำลอง

แบบจำลอง	TN	FP	FN	TP
เอ็กซ์ตรีมกราเดียนบูสต์	194	12	14	196
โลตจีบีเอ็ม	193	13	10	200
แคทบูสต์	194	12	16	194

จากผลการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องทั้ง 3 แบบจำลองดังแสดงในตารางที่ 2 พบว่าแบบจำลองโลตจีบีเอ็มมีประสิทธิภาพในการจำแนกที่ดีที่สุด โดยมีความไวสูงสุดที่ร้อยละ 95.24 ความแม่นยำสูงสุดที่ร้อยละ 94.47 และค่าประสิทธิภาพโดยรวมของแบบจำลองที่ร้อยละ 94.56 ซึ่งสะท้อนถึงความสามารถในการตรวจจับผู้ป่วยที่เป็นโรคได้มากที่สุดโดยมีความผิดพลาดเกิดขึ้นเพียงร้อยละ 4.76 แบบจำลองที่มีประสิทธิภาพรองลงมาคือแบบจำลองเอ็กซ์ตรีมกราเดียนบูสต์แสดงความสามารถที่ระหว่างตัวชี้วัดต่างๆ โดยแบบจำลองเอ็กซ์ตรีมกราเดียนบูสต์มีความแม่นยำที่ร้อยละ 93.75 ความไวที่ร้อยละ 93.33 และความจำเพาะสูงสุดที่ร้อยละ 94.17 ซึ่งเท่ากับแบบจำลองแคทบูสต์ ทั้งนี้แบบจำลองแคทบูสต์มีความไวต่ำที่สุดที่ร้อยละ 92.38 และมีความแม่นยำต่ำที่สุดที่ร้อยละ 93.27 ซึ่งผลการตรวจจับภาพที่มีภาวะโรคเบาหวานขึ้นจอประสาทตาสูงถึงร้อยละ 7.62 คิดเป็นความแตกต่างร้อยละ 2.86 เมื่อเทียบกับแบบจำลองโลตจีบีเอ็ม ทำให้ไม่เหมาะสมสำหรับการคัดกรองโรคแม้ว่าแบบจำลองแคทบูสต์มีความจำเพาะสูงสุดที่ร้อยละ 94.17 เนื่องจากความแตกต่างของความจำเพาะระหว่างแบบจำลองทั้งหมดมีเพียงร้อยละ 0.48

จากการเปรียบเทียบประสิทธิภาพของแบบจำลองแสดงให้เห็นว่าแบบจำลองทั้งหมดมีความสามารถในการจำแนกภาพที่มีภาวะโรคได้ใกล้เคียงกันในระดับสูง แต่มีจุดเด่นที่ต่างกันว่าค่าความไวหรือความสามารถในการตรวจจับผู้ป่วยซึ่งมีความสำคัญมากกว่าการจำแนกภาพถ่ายซึ่งไม่มีภาวะของโรคหรือค่าความจำเพาะ ทั้งนี้เมื่อพิจารณาจากค่าประสิทธิภาพโดยรวมของแบบจำลองซึ่งสะท้อนถึงความสามารถระหว่างความแม่นยำในการวินิจฉัยกลุ่มที่มีภาวะของโรคและความสามารถในการตรวจจับผู้ป่วย พบว่าแบบจำลองโลตจีบีเอ็มมีค่าสูงที่สุดที่ร้อยละ 94.56 รองลงมาคือแบบจำลองเอ็กซ์ตรีมกราเดียนบูสต์ที่ร้อยละ 93.78 และแบบจำลองแคทบูสต์มีค่าต่ำสุดที่ร้อยละ 93.27 ซึ่งการจัดลำดับของค่าประสิทธิภาพโดยรวมของแบบจำลองนี้สอดคล้องกับลำดับของความแม่นยำ แสดงให้เห็นว่าทั้งสองตัวชี้วัดนี้สะท้อนประสิทธิภาพโดยรวมของแบบจำลองได้อย่างสอดคล้องกัน ดังนั้นแบบจำลองโลตจีบีเอ็มจึงเป็นแบบจำลองที่เหมาะสมที่สุดสำหรับการนำไปใช้ในการคัดกรองโรคเบาหวานขึ้นจอประสาทตาในงานวิจัยและชุดข้อมูลชุดนี้



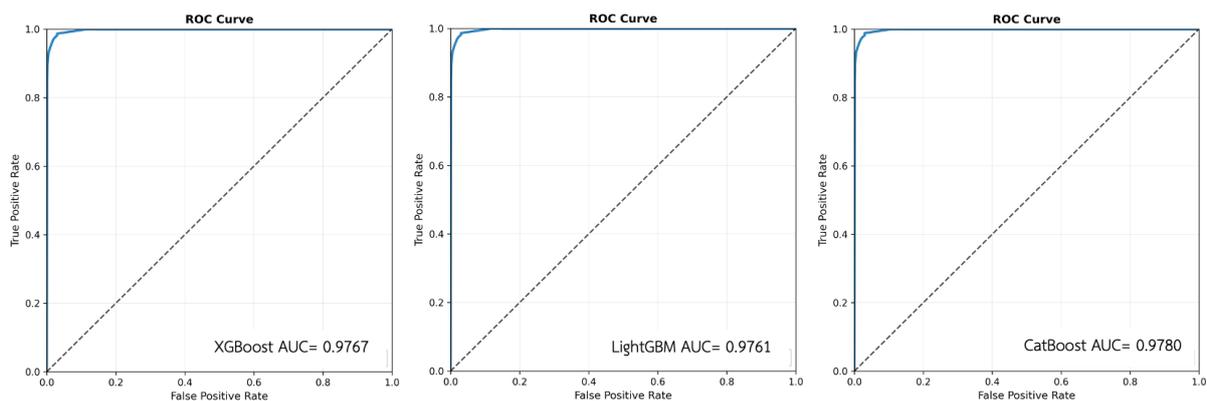
ภาพที่ 4 แสดงการเปรียบเทียบประสิทธิภาพแบบจำลองการเรียนรู้ของเครื่องแบบบูสต์

การวิเคราะห์ค่าส่วนเบี่ยงเบนมาตรฐานจากการประเมินแบบจำลองตามตัวชี้วัดซึ่งแสดงในตารางที่ 3 แสดงให้เห็นว่าแบบจำลองโลดจ์บีเอ็มมีความเสถียรสูงสุด โดยมีการกระจายตัวของผลการทดลองประสิทธิภาพน้อยที่สุดในเกือบทุกตัวชี้วัดซึ่งเป็นคุณสมบัติที่สำคัญสำหรับการนำไปประยุกต์ใช้ในทางคลินิก เนื่องจากความสามารถในการให้ผลลัพธ์ที่สม่ำเสมอเป็นทางเลือกที่เหมาะสมที่สุดสำหรับการคัดกรองโรคเบาหวานขึ้นจอประสาทตาในงานวิจัยนี้ ทั้งในแง่ของประสิทธิภาพและความน่าเชื่อถือ

ตารางที่ 3 แสดงค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานจากการประเมินแบบจำลองตามตัวชี้วัด

แบบจำลอง	ค่าความแม่นยำ	ความไว	ความจำเพาะ	ค่าประสิทธิภาพโดยรวม
เอ็กซ์ตรีมกราดิเอนบูสต์	± 0.016618	± 0.023267	± 0.014136	± 0.017246
โลดจ์บีเอ็ม	± 0.010793	± 0.016361	± 0.016878	± 0.010899
แคทบูสต์	± 0.019576	± 0.026746	± 0.017211	± 0.020285

เมื่อพิจารณาประสิทธิภาพแบบจำลองด้วยการวิเคราะห์กราฟพื้นที่ใต้เส้นโค้งอาร์โอซี (Area Under the Curve of the Receiver Operating Characteristic หรือ AUC-ROC) ตามภาพที่ 3 แสดงให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่องมีประสิทธิภาพในการจำแนกโรคเบาหวานขึ้นจอประสาทตาอยู่ในระดับดีเยี่ยม โดยมีค่าอยู่ระหว่าง 0.9761 ถึง 0.9780 ซึ่งมีความใกล้เคียงกันมาก แบบจำลองแคทบูสต์มีค่าสูงสุดที่ 0.9780 แสดงความสามารถในการจำแนกระหว่างกลุ่มที่มีภาวะของโรคและไม่มีภาวะของโรคได้ดีที่สุดโดยรวม รองลงมาคือแบบจำลองเอ็กซ์ตรีมกราดิเอนบูสต์ (0.9767) และแบบจำลองโลดจ์บีเอ็ม (0.9761) อย่างไรก็ตามการเลือกใช้แบบจำลองในทางปฏิบัติควรพิจารณาร่วมกับวัตถุประสงค์ทางคลินิก โดยแบบจำลองโลดจ์บีเอ็มที่มีค่าความไวสูงสุดจึงมีเหมาะสมกว่าในประเด็นการคัดกรองโรค แม้ว่าค่าการวิเคราะห์กราฟพื้นที่ใต้เส้นโค้งอาร์โอซีจะมีค่าน้อยกว่าก็ตาม เนื่องจากการคัดกรองโรคที่ผิดพลาดอาจนำไปสู่การสูญเสียการมองเห็นถาวร รวมถึงการคัดกรองผู้ป่วยที่มีภาวะของโรคจริงผิดพลาดมีผลกระทบรุนแรงกว่าการวินิจฉัยบวกลวง ซึ่งสามารถตรวจยืนยันเพิ่มเติมได้ในภายหลังและความแตกต่างดังกล่าวอยู่ในอัตราที่ต่ำมาก



ภาพที่ 5 แสดงการเปรียบเทียบประสิทธิภาพแบบจำลองด้วยการวิเคราะห์กราฟพื้นที่ใต้เส้นโค้งอาร์โอซี

ทั้งนี้เมื่อวิเคราะห์ค่าส่วนเบี่ยงเบนมาตรฐานของพื้นที่ใต้เส้นโค้งอาร์โอซีดังแสดงในตารางที่ 4 พบว่าทั้ง 3 แบบจำลองมีค่าส่วนเบี่ยงเบนมาตรฐานต่ำมากอยู่ในช่วง ±0.0112 ถึง ±0.0116 แสดงให้เห็นว่าทั้ง 3 แบบจำลองมีความเสถียรสูงและให้ผลการจำแนกที่สม่ำเสมอในทุกรอบ โดยแบบจำลองแคทบูสต์มีความเสถียรสูงสุดด้วยค่าส่วนเบี่ยงเบน

มาตรฐานต่ำที่สุดที่ ± 0.0112 รองลงมาคือแบบจำลองโลตส์จีบีเอ็ม (± 0.0115) และแบบจำลองเอ็กตรีมกราเดียนนุสต์ (± 0.0116) ตามลำดับ อย่างไรก็ตามความแตกต่างของค่าส่วนเบี่ยงเบนมาตรฐานระหว่างทั้งสามแบบจำลองมีเพียง 0.0004 ซึ่งถือว่าน้อยมาก สามารถสรุปได้ว่าทั้งสามแบบจำลองมีความน่าเชื่อถือและความคงที่ของประสิทธิภาพในระดับที่ใกล้เคียงกันมากสามารถนำไปประยุกต์ใช้ในการคัดกรองผู้ป่วยโดยไม่ต้องกังวลในประเด็นความแปรปรวนของผลลัพธ์

ตารางที่ 4 แสดงค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐานจากการวิเคราะห์กราฟพื้นที่ใต้เส้นโค้งอาร์โอซี

แบบจำลอง	การวิเคราะห์กราฟพื้นที่ใต้เส้นโค้งอาร์โอซี	ค่าเฉลี่ยส่วนเบี่ยงเบนมาตรฐาน
เอ็กตรีมกราเดียนนุสต์	0.9767	± 0.0116
โลตส์จีบีเอ็ม	0.9761	± 0.0115
แคทนูสต์	0.9780	± 0.0112

จากค่าความสำคัญของคุณลักษณะดังตารางที่ 3 แสดงค่าความสำคัญของคุณลักษณะ 20 อันดับแรกซึ่งมีค่าความสำคัญหรือจำนวนครั้งที่ใช้คุณลักษณะเป็นตัวจำแนกทั้งหมด 711 ครั้ง หรือคิดเป็นร้อยละ 63.9% ของค่าความสำคัญรวมทั้งหมด ยกตัวอย่างคุณลักษณะที่มีค่าความสำคัญสูงสุด 3 ลำดับแรกคือ HH1_entropy ถูกใช้ในการจำแนก 65 ครั้งคิดเป็นร้อยละ 5.84 HL1_skewness ถูกใช้ในการจำแนก 61 ครั้งคิดเป็นร้อยละ 5.48 และ LH3_entropy ถูกใช้ในการจำแนก 50 ครั้งคิดเป็นร้อยละ 4.49 เป็นต้น การจำแนกตามซับแบนด์แสดงให้เห็นว่าคุณลักษณะจากซับแบนด์แนวตั้ง (HL) ถูกคัดเลือกมาเพื่อใช้จำแนกมากที่สุดที่ 9 คุณลักษณะคิดเป็นร้อยละ 39.4 รองลงมาคือแนวนอน (LH) 5 คุณลักษณะคิดเป็นร้อยละ 26.3 และแนวทแยง (HH) 4 คุณลักษณะคิดเป็นร้อยละ 22.2 ในประเด็นการจำแนกตามประเภทคุณลักษณะพบว่าค่าความเบ้และค่าเอนโทรปีมีส่วนสูงสุดที่ 12 คุณลักษณะคิดเป็นร้อยละ 60 ซึ่งสะท้อนให้เห็นว่าแบบจำลองอาศัยลักษณะเชิงโครงสร้างพื้นผิวและรูปร่างการกระจายของสัญญาณเวฟเลตส์เป็นคุณลักษณะหลักในการจำแนก

ตารางที่ 5 แสดงค่าความสำคัญของคุณลักษณะซึ่งถูกเลือกใช้ในการจำแนก 20 ลำดับแรกของแบบจำลองโลตส์จีบีเอ็ม

ลำดับ	คุณลักษณะ	ซับแบนด์	ความสำคัญ	สัดส่วน(ร้อยละ)
1	HH1_entropy	HH1	65	5.84
2	HL1_skewness	HL1	61	5.48
3	LH3_entropy	LH3	50	4.49
4	LL3_skewness	LL3	48	4.31
5	LH3_skewness	LH3	47	4.22
6	LL3_entropy	LL3	38	3.41
7	HH3_mean	HH3	36	3.23
8	LH1_skewness	LH1	35	3.14
9	LH2_entropy	LH2	34	3.05
10	HL3_skewness	HL3	34	3.05
11	HL1_mean	HL1	31	2.79
12	HH2_mean	HH2	29	2.61
13	HH1_skewness	HH1	28	2.52
14	HL3_mean	HL3	28	2.52
15	HL1_kurtosis	HL1	28	2.52

ลำดับ	คุณลักษณะ	ซัพแบนด์	ความสำคัญ	สัดส่วน(ร้อยละ)
16	HL3_entropy	HL3	26	2.34
17	HL2_skewness	HL2	25	2.25
18	HL2_std	HL2	24	2.16
19	HL3_kurtosis	HL3	23	2.07
20	LH1_std	LH1	21	1.89

จากตารางที่ 5 แสดงคุณลักษณะที่มีความสำคัญ 20 อันดับแรกของแบบจำลองโลดจีบีเอ็มพบว่า คุณลักษณะเอนโทรปีและความเบ้มีความสำคัญต่อการจำแนก โดยคุณลักษณะ HL1_entropy มีความสำคัญสูงสุดที่ร้อยละ 5.84 โดยค่าเอนโทรปีที่สูงสะท้อนความไม่สม่ำเสมอของพื้นผิวจอประสาทตาที่เกิดจากรอยโรคเช่น จุดเลือดออกขนาดเล็ก จุดเลือดออกขนาดใหญ่และรอยสารคัดหลั่ง ซึ่งทำให้ลักษณะพื้นผิวมีความซับซ้อนและกระจายตัวที่ไม่เป็นระเบียบ โดยซัพแบนด์ HL1 และ HL1 สามารถจับการเปลี่ยนแปลงที่แตกต่างกันในบริเวณพื้นที่ใกล้เคียงกัน ค่าเอนโทรปีที่สูงบ่งบอกถึงขอบรอยโรคและความผิดปกติของหลอดเลือดในแนวนอนและทแยงได้อย่างมีประสิทธิภาพในขณะที่จอประสาทตาก็มีค่าเอนโทรปีต่ำเนื่องจากพื้นผิวสม่ำเสมอ คุณลักษณะความเบ้ในแต่ละซัพแบนด์ เช่น HL1_skewness LL3_skewness และ LH3_skewness สะท้อนความไม่สมมาตรของรอยโรค โดยความเบ้ที่เป็นบวกบ่งชี้การมีพิกเซลสว่างผิดปกติจากรอยสารคัดหลั่ง ขณะที่ความเบ้ที่เป็นลบสะท้อนพิกเซลที่มืดจากจุดเลือดออกขนาดเล็กและจุดเลือดออกขนาดใหญ่ ความเบ้ที่สูงหรือต่ำมากเกินไปแสดงให้เห็นว่ารอยโรคกระจายแบบไม่สมมาตรในหลายทิศทางซึ่งเป็นลักษณะเฉพาะของโรคเบาหวานขึ้นจอประสาทตา

อภิปรายผล

จากการวิเคราะห์ตัวชี้วัดประสิทธิภาพทั้งหมด สามารถสรุปได้ว่าแบบจำลองโลดจีบีเอ็มมีประสิทธิภาพดีที่สุดสำหรับการจำแนกโรคเบาหวานขึ้นจอประสาทตา โดยมีข้อได้เปรียบในเกือบทุกตัวชี้วัดหลัก ได้แก่ความแม่นยำสูงสุดที่ร้อยละ 94.47 ค่าความไวสูงสุดที่ร้อยละ 95.24 และมีค่าประสิทธิภาพโดยรวมของแบบจำลองที่ร้อยละ 94.56 แม้ว่าค่าความจำเพาะน้อยกว่าแบบจำลองแคทบูสต์และเอ็กตรีมกราเดียนบูสต์ที่ร้อยละ 93.69 แต่ความแตกต่างมีเพียงร้อยละ 0.48 โดยมีแบบจำลองเอ็กตรีมกราเดียนบูสต์เป็นตัวเลือกรองลงมา เนื่องจากแสดงความสมดุลที่ดีในทุกตัวชี้วัดแต่ประสิทธิภาพโดยรวมต่ำกว่าแบบจำลองโลดจีบีเอ็ม โดยเฉพาะในประเด็นค่าความไวซึ่งเป็นตัวชี้วัดที่สำคัญที่สุดในการคัดกรองโรคเบาหวานขึ้นจอประสาทตา ทั้งนี้โดยทั่วไปการเลือกใช้แบบจำลองควรให้ความสำคัญกับค่าความไว เนื่องจากความผิดพลาดในการตรวจพบภาพถ่ายที่มีภาวะของโรคมีผลกระทบร้ายแรงต่อผู้ป่วยและระบบสาธารณสุขมากกว่าการวินิจฉัยบวกลวง ซึ่งสามารถแก้ไขได้ด้วยการตรวจยืนยันเพิ่มเติมภายหลัง ดังนั้นจากเหตุผลดังกล่าวแบบจำลองโลดจีบีเอ็มจึงเป็นแบบจำลองที่เหมาะสมที่สุดในการนำไปประยุกต์ใช้ในทางคลินิกในการศึกษาวิจัยครั้งนี้ ทั้งนี้จากการเปรียบเทียบงานวิจัยที่มีวิธีการดำเนินการวิจัยใกล้เคียงกันพบว่าในภาพรวมของการใช้งานแบบจำลองแบบบูสต์มีประสิทธิภาพในการจำแนกด้วยระดับความแม่นยำที่สูงในทุกแบบจำลองสอดคล้องกับงานวิจัยโดย Ganie et al.[11] ในประเด็นการใช้งานคุณสมบัติซิมิลิตีพบสอดคล้องกับงานวิจัยโดย Onjun et al. [3] ซึ่งพบว่าซิมิลิตีเวฟเลตส์ให้ประสิทธิภาพสูงที่สุด ในการจำแนกโรคเบาหวานขึ้นจอประสาทตาเมื่อเทียบกับเวฟเลตส์ชนิดอื่น โดยให้ความแม่นยำร้อยละ 92.94 เมื่อใช้ร่วมกับโครงข่ายประสาทเทียมแบบคอนโวลูชันอย่างไรก็ตาม งานวิจัยดังกล่าวแสดงให้เห็นว่าการนำคุณลักษณะซิมิลิตีเวฟเลตส์มาใช้กับแบบจำลองโลดจีบีเอ็มสามารถเพิ่มประสิทธิภาพได้สูงถึงร้อยละ 94.47 ซึ่งงานวิจัยนี้ให้ประสิทธิภาพมากกว่าที่ร้อยละ 1.62 โดยประมาณ พร้อมกับลดความซับซ้อนของแบบจำลองและเวลาในการประมวลผล และสอดคล้องกับงานวิจัยโดย Mutawa et al. [6] ซึ่งใช้

คุณลักษณะเชิงสถิติที่สกัดจากซัพแบนด์เวฟเลตส์เพื่อจำแนกโรคเบาหวานขึ้นจอประสาทตา พบว่าแบบจำลองสามารถตรวจจับรายละเอียดทั้งในระดับหยابและระดับละเอียดของภาพจอประสาทตาได้ครบถ้วน แสดงให้เห็นว่าคุณลักษณะเวฟเลตส์เป็นคุณลักษณะเชิงสถิติที่สามารถเพิ่มประสิทธิภาพในการตรวจจับโรคเบาหวานขึ้นจอประสาทตาได้อย่างมีนัยสำคัญ ในประเด็นความเร็วด้านการประมวลผลพบว่าแบบจำลองไลต์จีพีเอ็มมีความเร็วกว่าแบบจำลองแบบบูตส์ตึงอื่นสอดคล้องกับงานวิจัยโดย Rufo et al. [15] ในประเด็นการใช้แบบจำลองไลต์จีพีเอ็มเพื่อจำแนกโรคเบาหวานขึ้นจอประสาทตาพบว่าผลการวิจัยสอดคล้องกับ Bidwai et al. [23] Bapatla and Harikiran. [24] และ Aziz et al. [25] ซึ่งประยุกต์ใช้แบบจำลองไลต์จีพีเอ็มร่วมกับข้อมูลเชิงตัวเลขเพื่อวินิจฉัยโรคทางตาด้วยภาพถ่ายทางการแพทย์ พบว่าผลการประเมินประสิทธิภาพของแบบจำลองมีความใกล้เคียงกัน ทั้งนี้เมื่อเปรียบเทียบกับงานวิจัยในปัจจุบันพบว่ามักใช้คุณลักษณะของภาพถ่ายร่วมกับแบบจำลองและกระบวนการที่ซับซ้อน การใช้ทรัพยากรและเวลาที่มากกว่าในกระบวนการพัฒนาแบบจำลอง โดยงานวิจัยนี้มุ่งเน้นการสร้างแบบจำลองแบบบูตส์ตึงซึ่งมีความรวดเร็วในการฝึกสอนและมีประสิทธิภาพการจำแนกที่สูงกว่าแบบจำลองอื่นๆ ร่วมกับการสกัดคุณลักษณะซิมเล็ตซึ่งสามารถอธิบายพื้นผิวของจอประสาทตาได้ดี นำมาซึ่งกระบวนการคัดกรองที่มีความเป็นไปได้และเหมาะสมในการนำไปประยุกต์ใช้งานจริงในสถานพยาบาลโดยเฉพาะในพื้นที่ห่างไกลที่มีข้อจำกัดด้านทรัพยากร

ทั้งนี้งานวิจัยนี้มีข้อจำกัดในประเด็นการใช้ชุดข้อมูลซึ่งมีขนาดจำกัดและมาจากแหล่งข้อมูลเดียว อาจส่งผลกระทบต่อความสามารถด้านการจำแนกที่ครอบคลุมในกรณีที่ต้องประมวลผลร่วมกับแหล่งข้อมูลอื่น การจำแนกโดยแบบจำลองการเรียนรู้ของเครื่องมีเพียง 2 รูปแบบและยังไม่จำแนกตามระดับความรุนแรงของโรค และการวิจัยครั้งนี้แม้จะมีประสิทธิภาพในการจำแนกสูงแต่ยังไม่ได้เปรียบเทียบกับวิธีการจำแนกโดยอาศัยการเรียนรู้เชิงลึกหรือวิธีการที่ซับซ้อนซึ่งเป็นที่ยอมรับในปัจจุบัน

สรุปผลการวิจัย

จากการศึกษาวิจัยพบว่าซิมเล็ตสามารถทำงานร่วมกับแบบจำลองการเรียนรู้ของเครื่องชนิดบูตส์ตึงอัลกอริทึมได้ดี และมีคุณสมบัติในการจำแนกโรคเบาหวานขึ้นจอประสาทตาด้วยภาพถ่ายทางการแพทย์ได้ดีเนื่องจากเป็นคุณลักษณะเวฟเลตส์ทรานสฟอร์มแบบไม่ต่อเนื่องที่มีความซ้ำซ้อนของข้อมูลน้อย การประมวลผลมีข้อมูลสูญหายน้อย และคำนวณได้รวดเร็วผ่านอัลกอริทึมฟาสต์เวฟเลตส์ทรานสฟอร์ม จึงเหมาะสำหรับระบบวินิจฉัยที่ต้องการทราบผลในทันที เมื่อใช้งานซิมเล็ตร่วมกับแบบจำลองไลต์จีพีเอ็มพบว่ามีการจำแนกมีประสิทธิภาพมากกว่าแบบจำลองอื่นๆ แทบทุกตัวชี้วัดและมีความเร็วในการประมวลผลสูงมาก เนื่องจากกระบวนการประมวลผลของแบบจำลองไลต์จีพีเอ็มเลือกใช้เฉพาะข้อมูลที่สำคัญในการสร้างแบบจำลอง รวมคุณลักษณะที่ไม่ซับซ้อนกันเพื่อลดมิติข้อมูล สร้างต้นไม้มัดตัดสินใจโดยเลือกข้อมูลที่ให้ผลลัพธ์ที่ดีที่สุดจากคุณสมบัติจำเพาะที่โดดเด่นซึ่งส่งเสริมกระบวนการทำงานระหว่างซิมเล็ตส์และแบบจำลองไลต์จีพีเอ็มทำให้ได้ผลการจำแนกที่มีความแม่นยำและมีความรวดเร็วในการประมวลผล จากผลการวิจัยครั้งนี้คณะผู้วิจัยมีแนวความคิดในการวิจัยต่อยอดในประเด็นการพัฒนาแบบจำลองไลต์จีพีเอ็มสู่แอปพลิเคชันทางคลินิก โดยใช้ประโยชน์จากจุดเด่นด้านความเร็วและความแม่นยำของซิมเล็ตส์และแบบจำลองไลต์จีพีเอ็ม โดยมีการออกแบบส่วนต่อประสานผู้ใช้ที่เน้นความเรียบง่ายเพื่อให้แพทย์นำเข้าภาพถ่ายและรับผลวินิจฉัยภายในระยะเวลาที่รวดเร็ว สามารถบูรณาการผลการจำแนกของแบบจำลองร่วมกับการวิเคราะห์ความสำคัญของคุณลักษณะ เพื่อเชื่อมโยงการตัดสินใจของแบบจำลองกับลักษณะพยาธิวิทยาทางคลินิก สามารถประยุกต์ใช้เป็นทางเลือกเพื่อเพิ่มการตรวจพบโรคในระยะเริ่มต้นพร้อมกับลดภาระงานของแพทย์และลดความเสี่ยงในการสูญเสียการมองเห็นของผู้ป่วย

เอกสารอ้างอิง

1. Chanlalit W. Ocular complications from diabetes mellitus. *J Med Health Sci.* 2016; 23(2): 36-45.
<https://shorturl.asia/bz4ST>
2. กรกัญจน์ จิตโสภิษฐ์. ความชุกของภาวะเบาหวานขึ้นจอประสาทตาและระดับน้ำตาลสะสมในเลือดที่สัมพันธ์กับการเกิดภาวะเบาหวานขึ้นจอประสาทตาในผู้ป่วยโรคเบาหวาน โรงพยาบาลสันป่าตอง จังหวัดเชียงใหม่. *วารสารวิชาการป้องกันควบคุมโรค สคร.2 พิษณุโลก.* 2566; 10(2): 15-25. สืบค้นจาก <https://he01.tci-thaijo.org/index.php/dpcphs/article/view/262223>
3. Onjun R, Lowmunkhong S, Kaennakham S, Phattamarut K. Diabetic retinopathy detection using a convolutional neural network enhanced by wavelet transformation pooling. In: *Proceedings of the 2024 16th International Conference on Bioinformatics and Biomedical Technology (ICBBT '24); 2024 May 24-26; Chongqing.* Association for Computing Machinery; 2024. p. 265-269.
<https://dl.acm.org/doi/10.1145/3674658.3674699>
4. Tomasi C, Manduchi R. Bilateral filtering for gray and color images. In: *Proceedings of the 6th International Conference on Computer Vision; 1998 Jan 7; Bombay.* IEEE; 1998. p. 839-846.
<https://ieeexplore.ieee.org/document/710815>
5. Rasta SH, Partovi ME, Seyedarabi H, Javadzadeh A. A comparative study on preprocessing techniques in diabetic retinopathy retinal images: illumination correction and contrast enhancement. *J Med Signals Sens.* 2015; 5(1): 40-48. Available from <https://shorturl.asia/0x8hs>
6. Mutawa AM, Al-Sabti K, Raizada S, Sruthi S. A deep learning model for detecting diabetic retinopathy stages with discrete wavelet transform. *Appl Sci.* 2024; 14(11): 4428.
<https://doi.org/10.3390/app14114428>
7. Darabi P. Diagnosis of diabetic retinopathy [dataset]. ResearchGate; 2024.
https://www.researchgate.net/publication/382264856_Diagnosis_of_Diabetic_Retinopathy
8. PyWavelets. PyWavelets: wavelet transforms in python [Internet]. Read the Docs; [cited 2025 Nov 5]. Available from: <https://pywavelets.readthedocs.io/en/latest/>
9. Scikit-Image. Scikit-image: image processing in python [Internet]. PyPI; [cited 2025 Nov 6]. Available from: <https://pypi.org/project/scikit-image>
10. OpenCV. opencv-python [Internet]. PyPI; [cited 2025 Nov 19]. Available from: <https://pypi.org/project/opencv-python/>
11. Ganie SM, Pramanik PKD, Bashir Malik M, Mallik S, Qin H. An ensemble learning approach for diabetes prediction using boosting techniques. *Front Genet.* 2023; 14: 1252159.
<https://doi.org/10.3389/fgene.2023.1252159>
12. Chen T, Guestrin C. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2016 Aug 13-17; San Francisco.* New York: ACM; 2016. p. 785-794.
<https://dl.acm.org/doi/pdf/10.1145/2939672.2939785>

13. Yang P, Yang B. Development and validation of predictive models for diabetic retinopathy using machine learning. *PLoS One*. 2025; 20(2): e0318226.
<https://doi.org/10.1371/journal.pone.0318226>
14. Ke G, Meng Q, Finley T, Wang T, Chen W, Ma W, et al. LightGBM: a highly efficient gradient boosting decision tree. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*; 2017 Dec 4; Long Beach. Red Hook, NY: Curran Associates; 2017. p. 3149-3157. <https://dl.acm.org/doi/10.5555/3294996.3295074>
15. Rufo DD, Debelee TG, Ibenthal A, Negera WG. Diagnosis of diabetes mellitus using gradient boosting machine (LightGBM). *Diagnostics*. 2021; 11(9): 1714.
<https://doi.org/10.3390/diagnostics11091714>
16. มนัสพร ตรีรุ่งโรจน์. ตัวแบบการเรียนรู้ของเครื่องอรรถิพลผสมสำหรับการวิเคราะห์การรอดชีพเวลาไม่ต่อเนื่อง [วิทยานิพนธ์ปริญญาโทศึกษาศาสตร์]. กรุงเทพฯ: คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย; 2565.
<https://digital.car.chula.ac.th/chulaetd/6671>
17. Xu W, Wang W, Ren H, Li X, Wen Y. Prediction and analysis of risk factors for diabetic retinopathy based on machine learning and interpretable models. *Heliyon*. 2024; 10(9): e29497.
<https://doi.org/10.1016/j.heliyon.2024.e29497>
18. Pandas development team. Pandas: python data analysis library [Internet]. [cited 2025 Nov 9]. Available from: <https://pandas.pydata.org>
19. NumPy. NumPy: Fundamental package for array computing in Python [Internet]. PyPI; [cited 2025 Dec 7]. Available from: <https://pypi.org/project/numpy>
20. Scikit-learn. A set of python modules for machine learning and data mining [Internet]. PyPI; [cited 2025 Dec 7]. Available from: <https://pypi.org/project/scikit-learn>
21. SciPy. SciPy: Fundamental algorithms for scientific computing in Python [Internet]. PyPI; [cited 2025 Nov 14]. Available from: <https://pypi.org/project/scipy>
22. Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: *Proceedings of the 14th International Joint Conference on Artificial Intelligence*; 1995 Aug 20; Montreal. San Francisco: Morgan Kaufmann; 1995. p.1137-1143.
<https://dl.acm.org/doi/10.5555/1643031.1643047>
23. Bidwai P, Gite S, Pradhan B, Almari A. Explainable diabetic retinopathy detection using a distributed CNN and LightGBM framework. *Comput Mater Contin*. 2025; 84(2): 2645-2676.
<https://www.techscience.com/cm/v84n2/62859>
24. Bapatla S, Harikiran J. LuNet-LightGBM: an effective hybrid approach for lesion segmentation and DR grading. *Comput Syst Sci Eng*. 2023; 46(1): 597-617. <https://doi.org/10.32604/csse.2023.034998>
25. Aziz A, Tezel NS, Kaçmaz S, Attallah Y. Early diabetic retinopathy detection from OCT images using multifractal analysis and multi-layer perceptron classification. *Diagnostics*. 2025; 15(13):
<https://doi.org/10.3390/diagnostics15131616>