

การประยุกต์ใช้โครงข่ายทรานส์ฟอร์มเมอร์สำหรับจำแนกและจดจำโรคเล็บ

เอกรัตน์ สุขสุคนธ์^{1*} บุญธิดา ชุนงาม² เอกชัย เนาวนิช³

^{1,2}สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ, สุพรรณบุรี, ประเทศไทย

³สาขาวิชาเทคโนโลยีดิจิทัลมีเดีย คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ, นนทบุรี, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : aekkarat.s@rmutsb.ac.th

รับต้นฉบับ : 13 กุมภาพันธ์ 2568; รับบทความฉบับแก้ไข : 6 มีนาคม 2568; ตอบรับบทความ : 8 สิงหาคม 2568

เผยแพร่ออนไลน์ : 26 ธันวาคม 2568

บทคัดย่อ

โรคเล็บเป็นปัญหาสำคัญในการวินิจฉัยทางการแพทย์ เนื่องจากโรคเล็บมีลักษณะที่คล้ายคลึงกัน ทำให้การวินิจฉัยต้องอาศัยผู้เชี่ยวชาญด้านโรคผิวหนัง ความผิดพลาดในการวินิจฉัยอาจนำไปสู่การรักษาที่ผิดพลาดและส่งผลกระทบต่อผู้ป่วยมีอาการแทรกซ้อนเพิ่มขึ้น งานวิจัยนี้นำเสนอการประยุกต์ใช้โครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์สำหรับจำแนกโรคเล็บ เนื่องจากโครงข่ายมีความสามารถในการเรียนรู้คุณลักษณะที่สำคัญซึ่งก่อให้เกิดโรค แนวทางนี้เป็นการส่งเสริมเพื่อเพิ่มความแม่นยำในการจำแนก การทดลองมุ่งเน้นศึกษาตัวอย่างโรคเล็บที่หลากหลาย เช่น เล็บที่เป็นโรคสะเก็ดเงิน เล็บติดเชื้อรา และเล็บปกติ โดยโครงข่ายได้รับการฝึกอบรมด้วยการปรับแต่งค่าพารามิเตอร์การเรียนรู้เพื่อเพิ่มประสิทธิภาพการทำงาน โดยประเมินด้วยค่าความแม่นยำมีผลสูงสุดจากการฝึกอบรมที่ร้อยละ 99.40 ซึ่งแสดงถึงศักยภาพในการจำแนกและจดจำโรคเล็บได้อย่างมีประสิทธิภาพ แนวทางนี้ไม่เพียงแต่ช่วยเพิ่มความแม่นยำในการวินิจฉัย แต่ยังสามารถพัฒนาระบบที่ลดภาระงานของบุคลากรทางการแพทย์ และช่วยให้การวินิจฉัยโรคเป็นไปได้อย่างรวดเร็ว ซึ่งอาจนำไปสู่การพัฒนากระบวนการวินิจฉัยอัตโนมัติที่ช่วยยกระดับคุณภาพการดูแลและรักษาในอนาคต

คำสำคัญ : ปัญญาประดิษฐ์ การเรียนรู้เชิงลึก การจำแนกและจดจำโรคเล็บ โครงข่ายทรานส์ฟอร์มเมอร์

Exploiting Transformer Network for Nail Diseases Classification and Recognition

Aekkarat Suksukont^{1*} Bunthida Chunngam² Ekachai Naowanich³

^{1*,2}*Department of Computer Engineering, Faculty of Industrial Education,
Rajamangala University of Technology Suvarnabhumi, Suphan Buri, Thailand*

³*Department of Digital Media Technology, Faculty of Science and Technology,
Rajamangala University of Technology Suvarnabhumi, Nonthaburi, Thailand*

*Corresponding Author. E-mail address: aekkarat.s@rmutsb.ac.th

Received: 13 February 2025; Revised: 6 March 2025; Accepted: 8 August 2025

Published online: 26 December 2025

Abstract

Diagnosing nail diseases is a complex task due to their similar visual characteristics, often requiring expert dermatologists for accurate assessment. Misdiagnosis can lead to ineffective treatment and prolonged patient discomfort. This study explores the use of a transformer neural network for classifying nail diseases, leveraging its ability to identify intricate patterns and subtle features that may indicate early signs of disease. The research focuses on three nail conditions: psoriasis nails, onychomycosis, and healthy. The model was trained with a carefully optimized set of hyperparameters to improve learning efficiency and classification performance. Experimental results showed that the network achieved a peak accuracy of 99.40%, demonstrating its ability to effectively distinguish between different nail conditions. This approach not only enhances classification accuracy but also has the potential to reduce the workload of healthcare professionals and speed up diagnosis. Ultimately, this advancement could contribute to the development of automated diagnostic systems, leading to improved patient care and treatment outcomes.

Keywords: Artificial intelligence, Deep learning, Nail disease classification and recognition, Transformer network

1) บทนำ

โรคเล็บเป็นปัญหาสุขภาพที่พบได้ทั่วไปและอาจส่งผลต่อคุณภาพชีวิตของผู้ป่วย โดยมีสาเหตุจากหลายปัจจัย เช่น การติดเชื้อรา การอักเสบจากแบคทีเรีย โรคผิวหนัง หรือภาวะผิดปกติของร่างกาย แม้ว่าการวินิจฉัยโรคเล็บจะต้องอาศัยความเชี่ยวชาญของแพทย์ผิวหนัง แต่เนื่องจากลักษณะของโรคมีความคล้ายคลึงกันและซับซ้อน การตรวจวินิจฉัยแบบดั้งเดิมจึงมักใช้เวลานานและมีข้อจำกัดในการเข้าถึงผู้เชี่ยวชาญ [1], [2] ในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ (artificial intelligence) และการเรียนรู้เชิงลึก (deep learning) ได้เข้ามามีบทบาทสำคัญในการแพทย์ โดยเฉพาะการนำเทคนิคการมองเห็นของคอมพิวเตอร์มาประยุกต์ใช้ในการวิเคราะห์ภาพทางการแพทย์เพื่อช่วยในการตรวจวินิจฉัยโรค การนำเทคโนโลยีเหล่านี้มาช่วยจำแนกและจดจำโรคเล็บสามารถเพิ่มความแม่นยำ ลดข้อผิดพลาด และช่วยให้แพทย์สามารถให้การวินิจฉัยได้รวดเร็วขึ้น [3], [4]

ด้วยเหตุนี้ผู้วิจัยจึงมุ่งเน้นการพัฒนาแบบจำลองการเรียนรู้เชิงลึกที่สามารถจำแนกประเภทของโรคเล็บโดยอัตโนมัติเพื่อเพิ่มความแม่นยำและประสิทธิภาพของการวินิจฉัย ซึ่งอาจนำไปสู่การลดภาระงานของแพทย์และเพิ่มโอกาสในการเข้าถึงการรักษาที่รวดเร็วและมีประสิทธิภาพยิ่งขึ้น

2) ทบทวนวรรณกรรม


ในช่วงไม่กี่ปีที่ผ่านมา เทคนิคการเรียนรู้เชิงลึกโดยเฉพาะโครงข่าย convolutional neural network (CNN) ที่มีบทบาทสำคัญในการประยุกต์ใช้สำหรับการวิเคราะห์ภาพถ่ายทางการแพทย์ [5] เนื่องจากความสามารถในการเรียนรู้ และการตรวจจับคุณลักษณะเชิงลึกได้อย่างมีประสิทธิภาพ [6] และยังได้รับการพัฒนาให้สามารถเรียนรู้องค์ประกอบจากส่วนย่อย ๆ จากความสัมพันธ์เชิงพื้นที่ของเป้าหมายนั้น ๆ ส่งผลให้มีการพัฒนาเพื่อแก้ปัญหาภาพถ่ายที่ซับซ้อน เช่น ภาพถ่ายรังสี [7] ภาพสแกน MRI [8] และภาพทางผิวหนัง [9] โดยเฉพาะการนำ CNN มาประยุกต์ใช้ในการจำแนกโรคเล็บเพื่อช่วยเพิ่มความแม่นยำและลดข้อผิดพลาดในการวินิจฉัย เช่น ใน Hariyani et al. [4] เสนอการแบ่งส่วนเส้นเลือดฝอยที่เล็บ มุ่งเน้นสัญญาณรบกวนและความแปรปรวนสูง โดยอาศัย manual, semi-automated และ automated ในการแบ่งส่วนภาพ ร่วมกับ DA-CapNet บน U-Net ที่ปรับปรุงด้วย dual attention module เพื่อช่วยให้โมเดลสามารถเรียนรู้คุณลักษณะของภาพได้ดีขึ้น ใน Yamaç et al. [10]

เสนอ ResNet101v2 ร่วมกับการถ่ายโอนการเรียนรู้เพื่อจำแนกลักษณะของโรคเล็บที่หลากหลาย เพื่อศึกษาการเรียนรู้ด้วยข้อมูลที่จำกัดและคุณภาพต่ำ ใน Muneera Begum et al. [11] เสนอ CNN โดยพัฒนาให้อยู่ในรูปแบบของเว็บแอปพลิเคชัน DermaDoc เพื่อช่วยผู้ใช้ตรวจสอบโรคและให้ข้อมูลเกี่ยวกับอาการและแนวทางการรักษาเบื้องต้น และ Shandilya et al. [12] แสดงให้เห็นถึงความสำคัญของการประยุกต์ใช้และพัฒนา อย่างไรก็ตาม การพัฒนายังคงมีข้อด้อยที่เกิดจากการทำงานของโครงข่ายสัญญาณรบกวนภาพ และความซับซ้อนของโรคเล็บ ซึ่งชี้ให้เห็นแนวทางในการพัฒนาเพื่อเพิ่มประสิทธิภาพ

งานวิจัยนี้นำเสนอการประยุกต์ใช้โครงข่ายทรานส์ฟอร์มเมอร์สำหรับจำแนกโรคเล็บ โดยโมเดลได้รับการฝึกอบรมด้วยชุดข้อมูลภาพเล็บที่ผ่านการตรวจสอบจากแพทย์ผู้เชี่ยวชาญ พร้อมทั้งดำเนินการปรับปรุงการเรียนรู้ของโครงข่ายในขณะฝึกอบรม ประสิทธิภาพของโมเดลถูกประเมินโดยค่า accuracy, precision, recall, F1 และ confusion matrix เทคนิคและวิธีที่นำเสนอเป็นการพัฒนาเพื่อเพิ่มความสามารถของโครงข่าย ให้สามารถนำไปพัฒนาควบคู่กับระบบการแพทย์ทางไกล เพื่อลดภาระงานของแพทย์และเพิ่มการเข้าถึงในการรักษา

3) วิธีดำเนินการวิจัย

งานวิจัยนี้ดำเนินการโดยรวบรวมชุดข้อมูลภาพเล็บที่ผ่านการตรวจสอบจากชุดข้อมูลออนไลน์ที่เผยแพร่ไว้สำหรับนำไปพัฒนาปัญญาประดิษฐ์ โดยนำมาปรับแต่งภาพด้วยการเสริมข้อมูล (data augmentation) เพื่อเพิ่มความหลากหลายของข้อมูล จากนั้นนำมาฝึกอบรมโครงข่ายทรานส์ฟอร์มเมอร์ โดยทำปรับเปลี่ยนพารามิเตอร์ (fine-tuning) บนชุดข้อมูลโรคเล็บ การฝึกอบรมโครงข่ายได้รับการประเมินด้วย accuracy, precision, recall, F1 และ confusion matrix พร้อมเปรียบเทียบกับโมเดลก่อนหน้า การทำงานดังกล่าวแสดงไว้ดังรูปที่ 1



รูปที่ 1 : ขั้นตอนการจำแนกและจดจำโรคเล็บ

3.1) ชุดข้อมูล (Dataset)

Nail disease [13] เป็นชุดข้อมูลที่เผยแพร่สาธารณะ ถูกพัฒนาขึ้นสำหรับการศึกษาวิจัยในการจำแนกและจดจำโรคเล็บ ประกอบด้วยสองชุดย่อย ได้แก่ ชุดเทรนนิ่ง (training set) ร้อยละ 80 และชุดทดสอบร้อยละ 20 โดยข้อมูลแต่ละชุดแบ่งออกเป็นสามประเภท ได้แก่ เล็บปกติ (healthy), โรคเชื้อรา (onychomycosis) และ โรคสะเก็ดเงิน (psoriasis) ชุดข้อมูลนี้ได้รับการจัดระเบียบเพื่อใช้ในการฝึกและทดสอบโมเดลของการเรียนรู้เชิงลึก โดยสามารถดาวน์โหลดได้จาก Kaggle เพื่อนำไปใช้ในการพัฒนาระบบวินิจฉัยโรคเล็บแบบอัตโนมัติ



(ค) โรคสะเก็ดเงิน

รูปที่ 2 : ชุดข้อมูลโรคเล็บ

3.2) โครงข่ายทรานส์ฟอร์มเมอร์ (Transformer Network)

โครงข่ายทรานส์ฟอร์มเมอร์ [14] เป็นสถาปัตยกรรมที่ใช้ self-attention mechanism ถูกออกแบบเพื่อประมวลผลข้อมูลที่เป็ลลำดับส่งผลให้โมเดลสามารถตรวจจับลักษณะเด่นของข้อมูลภาพได้โดยไม่ต้องอาศัยโครงสร้างแบบลำดับเชิงพื้นที่ หรือความสัมพันธ์ระหว่างส่วนต่างๆ ของภาพ มีการทำงานโดยใช้โครงข่ายที่แบ่งภาพออกเป็นแพตช์ ขนาด $P \times P$ และแปลงเป็นเวกเตอร์ผ่าน linear projection จากนั้น positional encoding จะถูกเพิ่มเข้าไปเพื่อรักษาข้อมูลลำดับของแพตช์ในกระบวนการ self-attention ภายใน multi-head self-attention (MHSA) ซึ่งทำหน้าที่รวมองค์ประกอบของ scaled dot-product attention เพื่อเรียนรู้ความสัมพันธ์เชิงลึกของข้อมูล ดังสมการที่ (1)

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

เมื่อ K , Q , V คือ เวกเตอร์ query, key, value ที่ได้จากการแปลงข้อมูลผ่านเมทริกซ์น้ำหนัก และ d_k คือ มิติของ key เพื่อปรับสเกลให้เหมาะสม MHSA ซึ่งจะดำเนินการไปพร้อมกันด้วย self-attention เพื่อนำข้อมูลเชิงลึกไปใช้หลังจากผ่านขั้นตอนของ feedforward network และ layer normalization โดยโมเดลจะรวมคุณลักษณะและส่งต่อไปยัง โครงข่ายประสาทเพื่อจำแนกประเภทและจดจำ

3.3) การวัดประสิทธิภาพ

ประสิทธิภาพของโมเดลสามารถใช้การคำนวณด้วย accuracy เพื่อประเมินภาพรวมของการฝึกอบรม ดังสมการที่ (2), precision เพื่อคำนวณจากสัดส่วนของ true positive (TP) ต่อผลรวมของ TP และ false positive (FP) ซึ่งใช้วัดความแม่นยำของโมเดลในการทำนายผลลัพธ์ที่เป็นบวก ดังสมการที่ (3), recall เป็นการคำนวณจากสัดส่วนของ TP ต่อผลรวมของ TP และ false negative (FN) ซึ่งใช้วัดความสามารถของโมเดลในการดึงข้อมูลที่ถูกต้อง ดังสมการที่ (4), F1 ผลทางสถิติที่ใช้วัดความแม่นยำของโมเดล ซึ่งเป็นค่าเฉลี่ยน้ำหนักระหว่าง precision และ recall ดังสมการที่ (5) ในขณะที่ confusion matrix ถูกนำมาอธิบายชุดข้อมูลที่ไม่สมดุล

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (2)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

โดยที่ TP และ true negative (TN) คือ จำนวนตัวอย่างที่จำแนกและจดจำได้ถูกต้อง FP และ FN คือ จำนวนตัวอย่างที่จำแนกและจดจำผิดพลาด

3.4) อุปกรณ์ในการทดลอง

คอมพิวเตอร์ที่ใช้ในการทดลองดำเนินการบนระบบปฏิบัติการ Windows ที่ติดตั้ง CPU Intel Core i5-12400F LGA 1700 @ 2.5 GHz พร้อมด้วย RAM ขนาด 32 GB ที่มีความเร็วสัญญาณนาฬิกา 5600 MHz และ GPU NVIDIA RTX 4070 ซึ่งมาพร้อม VRAM ขนาด 12 GB และ CUDA cores จำนวน 5888 หน่วย

NumPy และ TensorFlow เป็นเครื่องมือในการพัฒนาและทดสอบ การกำหนดค่าพารามิเตอร์สำหรับการเทรนนิ่ง และทดสอบเพื่อช่วยเพิ่มความเร็วในการประมวลผล ถูกกำหนดไว้เพื่อความเป็นมาตรฐาน ดังสรุปในตารางที่ 1


ตารางที่ 1 : พารามิเตอร์สำหรับการเทรนนิ่งโมเดล

พารามิเตอร์	ค่าของพารามิเตอร์
ขนาดข้อมูล	150×150×3
อัตราการเรียนรู้	10^{-3} , 10^{-4} , 10^{-5}
รอบของการเทรนนิ่ง	200
การเพิ่มประสิทธิภาพ	Adam

4) ผลการวิจัยและอภิปรายผล

4.1) ผลการเทรนนิ่ง (Training Results)

ผลของการเทรนนิ่ง ในรูปที่ 3 แสดงประสิทธิภาพการเรียนรู้ของโครงข่ายในขณะที่มีการเปลี่ยนแปลงอัตราการเรียนรู้ 10^{-3} , 10^{-4} และ 10^{-5} ซึ่งผลการเทรนนิ่ง พบว่า 10^{-5} ให้ประสิทธิภาพการเทรนนิ่ง สูงสุดที่ร้อยละ 99.40 และมีความเสถียรมากที่สุดในขณะที่ 10^{-4} มีความสมดุลในการเรียนรู้โดยมีผลสูงสุดที่ร้อยละ 98.28 ซึ่งเป็นผลเทียบเท่า 10^{-5} และ 10^{-3} มีผลการเรียนรู้ที่ผันผวนโดยมีผลสูงสุดที่ร้อยละ 95.71



รูปที่ 3 : ประสิทธิภาพการเทรนนิ่งโมเดล


4.2) ผลการจำแนกและจดจำ

เมื่อนำโครงข่ายไปทดสอบ โดยนำ 10^{-5} ที่ได้รับการเทรนนิ่ง สูงสุดไปทดสอบ โดยใช้ตัวชี้วัดค่า precision, recall และ F1 ผลการจำแนกโรคเล็บ ได้แก่ เล็บปกติ, โรคเชื้อรา, และ โรคสะเก็ดเงิน สรุปผลในตารางที่ 2 ผลของโรคเชื้อราได้รับผลสูงสุด


ที่ร้อยละ 88.90, 81.60 และ 85.10 ของ precision, recall และ F1 สะท้อนถึงความสมดุลในการจำแนก อย่างไรก็ตาม การจำแนกเล็บปกติและโรคสะเก็ดเงินมีผลค่อนข้างน้อยเมื่อเทียบกับการทดลองชุดอื่น ๆ โดยสามารถจำแนกได้เพียงร้อยละ 57.90, 71.00 และ 63.80 ของเล็บปกติ และมีผลที่ร้อยละ 67.80, 66.30 และ 67.00 ของโรคสะเก็ดเงิน ตามลำดับ

ตารางที่ 2 : ประสิทธิภาพการจำแนกโรคเล็บ

โรคเล็บ	Precision (%)	Recall (%)	F1 (%)
เล็บปกติ	57.90	71.00	63.80
โรคเชื้อรา	88.90	81.60	85.10
โรคสะเก็ดเงิน	67.80	66.30	67.00



รูปที่ 4 : Confusion matrix ของการจำแนกโรคเล็บ



รูปที่ 5: ผลการจดจำโรคเล็บ

ในรูปที่ 4 ผลลัพธ์ของ 10^{-5} เมื่อนำมาทดสอบเพื่อจำแนกโรคเล็บ โดย confusion matrix แสดงผลการจำแนกโรคเล็บ ผลสูงสุดที่ร้อยละ 70.97 สำหรับเล็บปกติ, ร้อยละ 81.63 สำหรับโรคเชื้อรา และร้อยละ 66.30 สำหรับโรคสะเก็ดเงิน อย่างไรก็ตาม ในการทดสอบยังมีข้อผิดพลาดที่เกิดจากความสับสนในการเรียนรู้ข้อมูล เช่น ผลการจำแนกที่ร้อยละ 29.03 ของเล็บปกติ จำแนกผิดเป็นโรคสะเก็ดเงิน หรือผลการจำแนกที่ร้อยละ 17.39 ของโรคสะเก็ดเงินถูกทำนายผิดเป็นเล็บปกติ

ในรูปที่ 5 ผลลัพธ์ของ 10^{-5} เมื่อนำมาทดสอบเพื่อจำแนกโรคเล็บ สามารถแสดงผลการจดจำได้ทั้ง เล็บปกติ, โรคเชื้อรา และโรคสะเก็ดเงิน โดยมีความแม่นยำสูงในบางภาพ เช่น ร้อยละ 100 สำหรับเล็บปกติ และร้อยละ 99.84 สำหรับโรคเชื้อราที่เล็บ อย่างไรก็ตาม ในบางกรณีมีค่าความแม่นยำต่ำ เช่น ร้อยละ 73.16 สำหรับโรคสะเก็ดเงิน ซึ่งอาจแสดงถึงความผิดพลาดในบางกรณี

4.3) การเปรียบเทียบผลการทดลอง

งานวิจัยนี้มีวัตถุประสงค์เพื่อประยุกต์ใช้โครงข่ายทรานส์ฟอร์มเมอร์สำหรับจำแนกและจดจำโรคเล็บ โดยได้รวบรวมผลการศึกษานี้ เพื่อประเมินประสิทธิภาพของวิธีที่เสนอ สรุปผลในตารางที่ 3

ตารางที่ 3 : การเปรียบเทียบประสิทธิภาพการเทรนนิ่ง (training) กับการศึกษาท่อน้ำ

บทความ	เทคนิค	เทรนนิ่ง (%)
[4]	DA-CapNet	81.00 (recall)
[10]	ResNet101v2	89.00
[12]	Hybrid Capsule CNN	99.40
[15]	Hybrid CNN	80.45
[16]	Hybrid CNN-RF	96.08
[17]	CNN	87.33
งานวิจัยนี้	เทคนิคที่นำเสนอ	99.40

ในตารางที่ 3 เปรียบเทียบประสิทธิภาพกับการศึกษาท่อน้ำ ผลลัพธ์ของเทคนิค DA-CapNet, ResNet101v2, Hybrid Capsule CNN, Hybrid CNN, CNN-RF และ CNN มีผลการฝึกอบรมที่ได้ โดยเทคนิคที่นำเสนอในงานวิจัยนี้ใช้ Transformer ซึ่งให้ผลลัพธ์ที่ดีที่สุดที่ร้อยละ 99.40 แสดงให้เห็นว่าเทคนิคที่นำเสนอมีประสิทธิภาพดีกว่าเมื่อเทียบกับวิธีอื่น ๆ

5) อภิปรายผลการทดลอง

ผลการทดลองแสดงให้เห็นว่าอัตราการเรียนรู้แตกต่างกัน ส่งผลต่อประสิทธิภาพของโครงข่ายที่เสนอ ซึ่งผลของ 10^{-5} ให้ผลลัพธ์ที่ดีที่สุดที่ร้อยละ 99.40 และมีความเสถียรมากที่สุด แสดงให้เห็นว่าอัตราการเรียนรู้ที่น้อยช่วยให้โครงข่ายเรียนรู้คุณลักษณะของข้อมูลได้ดียิ่งขึ้น เมื่อเทียบกับพารามิเตอร์อื่นๆ ทั้งนี้เมื่อสังเกต 10^{-3} มีผลลัพธ์ที่ผันผวนมากที่สุด ซึ่งบ่งชี้ว่าอัตราการเรียนรู้ที่สูงเกินไปทำให้การเรียนรู้เกิดปัญหาการเรียนรู้ที่ไม่มีเสถียรภาพ

เมื่อทดสอบกับชุดข้อมูลเพื่อจำแนกโรคเล็บพบว่า อัตราการเรียนรู้ที่ 10^{-5} สามารถจำแนกโรคเชื้อราได้ดีที่สุด โดยมีค่า precision สูงสุดที่ร้อยละ 88.90 มีผล recall สูงสุดที่ร้อยละ 81.60 และ F1 สูงสุดที่ร้อยละ 85.10 ซึ่งสะท้อนถึงความสามารถในการจำแนกที่เฉพาะในบางกรณี นอกจากนี้ เมื่อทดสอบเพื่อจดจำโรคเล็บ โมเดลสามารถจดจำเล็บปกติได้อย่างแม่นยำที่ร้อยละ 100 ในทุกตัวอย่าง สำหรับโรคเชื้อรามีความแม่นยำแตกต่างกัน ซึ่งมีผลสูงสุดที่ร้อยละ 99.84 และในบางกรณีมีผลลดลงที่ร้อยละ 75.80 ทั้งนี้ ผลการทดลองเป็นไปในแนวทางเดียวกันกับโรคสะเก็ดเงินที่มีความแม่นยำสูงและมีผลลดน้อยลงในบางกรณี อาจเกิดจากความคล้ายคลึงกันของลักษณะทางกายภาพของโรคสะท้อนถึงข้อจำกัดของโมเดลในการจำแนกและจดจำโรคบนสภาพผิวของเล็บ

แม้ว่าผลลัพธ์โดยรวมจะแสดงให้เห็นว่าโครงข่ายที่เสนอมีประสิทธิภาพสูงในการจำแนกและจดจำโรคเล็บ แต่ยังสามารถพัฒนาเพิ่มเติม โดยเฉพาะการเพิ่มชุดข้อมูลที่ครอบคลุมตัวอย่างที่มีลักษณะคล้ายคลึงกัน หรือการปรับแต่งโครงข่ายให้สามารถดึงลักษณะเฉพาะของโรคให้ดียิ่งขึ้น

6) สรุปผลการวิจัย

งานวิจัยนี้นำเสนอการประยุกต์ใช้โครงข่ายทรานส์ฟอร์มเมอร์สำหรับจำแนกและจดจำโรคเล็บ เนื่องจากข้อดีในการเรียนรู้ความสัมพันธ์เชิงพื้นที่ได้ดีและลดการสูญเสียข้อมูลที่ซับซ้อน ข้อมูลที่ใช้ทดลองประกอบด้วยโรคเล็บ ได้แก่ เล็บปกติ โรคเชื้อราที่เล็บ และโรคสะเก็ดเงิน โดยโมเดลได้รับการฝึกและปรับแต่งพารามิเตอร์เพื่อให้มีประสิทธิภาพสูงสุดสำหรับการเทรนนิ่งและทดสอบ

ผลการทดลองแสดงให้เห็นว่า วิธีที่เสนอมีประสิทธิภาพการเทรนนิ่งสูงสุดที่ร้อยละ 99.40 อีกทั้งยังสามารถจำแนกและจดจำ

โรคเล็บได้อย่างแม่นยำ ทำให้เหมาะสมสำหรับนำไปพัฒนาระบบวินิจฉัยโรคเล็บแบบอัตโนมัติ

จากผลการทดลองสรุปได้ว่า โครงข่ายทรานส์ฟอร์มเมอร์เป็นแนวทางที่มีประสิทธิภาพสูงในการจำแนกและจดจำโรคเล็บ โดยช่วยปรับปรุงความแม่นยำในการวินิจฉัย ซึ่งสามารถนำไปพัฒนาระบบเพื่อลดภาระงานของแพทย์ในอนาคต

7) ข้อเสนอแนะ

สำหรับการพัฒนาในอนาคต ควรขยายฐานข้อมูลให้ครอบคลุมโรคเล็บที่หลากหลายมากขึ้นและเพิ่มคุณภาพของข้อมูลเพื่อปรับปรุงความแม่นยำของโมเดล นอกจากนี้ควรพัฒนาโครงข่ายทรานส์ฟอร์มเมอร์ให้มีประสิทธิภาพสูงขึ้นโดยใช้เทคนิคใหม่ ๆ เช่น hybrid transformer-CNN หรือ self-supervised learning รวมถึงการพัฒนาแอปพลิเคชันสำหรับการใช้งานจริงผ่านสมาร์ตโฟนและการผสมรวมกับระบบการแพทย์ทางไกล เพื่อให้แพทย์และผู้ป่วยสามารถเข้าถึงการวินิจฉัยได้ดียิ่งขึ้น

REFERENCES

- [1] M. Umei *et al.*, "Prevalence, risk factors and potential implications of nail biting in adults with congenital heart disease," *Int. J. Cardiol.*, vol. 418, 2025, Art. no. 132652, doi: 10.1016/j.ijcard.2024.132652.
- [2] K. L. Curtis *et al.*, "Diagnosis and management of nail unit squamous cell carcinoma: A clinical review by an expert panel," *JAAD Rev.*, vol. 4, pp. 187–194, Jun. 2025, doi: 10.1016/j.jdrv.2024.12.012.
- [3] S. Das and M. Bhattacharjee, "Image-based sensing of Leukonychia for early diagnosis of anemia using a smartphone application," *IEEE Sens. Lett.*, vol. 6, no. 11, 2022, Art. no. 3502604.
- [4] Y. S. Hariyani, H. Eom, and C. Park, "DA-capnet: dual attention deep learning based on U-net for nailfold capillary segmentation," *IEEE Access*, vol. 8, pp. 10543–10553, 2020, doi: 10.1109/ACCESS.2020.2965651.
- [5] A. Prommakhot and J. Srinonchat, "Combining convolutional neural networks for fungi classification," *IEEE Access*, vol. 12, pp. 58021–58030, 2024, doi: 10.1109/ACCESS.2024.3391630.
- [6] A. Prommakhot and J. Srinonchat, "VGGNet integration for kidney tumor classification," in *Proc. 12th Int. Electr. Eng. Congr. (IEECON)*, Pattaya, Thailand, Mar. 2024, pp. 1–6.
- [7] H. Wang, H. Jia, L. Lu, and Y. Xia, "Thorax-net: An attention regularized deep neural network for classification of Thoracic diseases on chest radiography," *IEEE J. Biomed. Health Inform.*, vol. 24, no. 2, pp. 475–485, 2020.
- [8] A. P. Leynes, N. Deveshwar, S. S. Nagarajan, and P. E. Z. Larson, "Scan-specific self-supervised bayesian deep non-linear inversion for undersampled MRI reconstruction," *IEEE Trans. Med. Imaging*, vol. 43, no. 6, pp. 2358–2369, 2024.
- [9] K. Lee, T. C. Cavalcanti, S. Kim, H. M. Lew, D. H. Suh, and D. H. Lee, "Multi-task and few-shot learning-based fully automatic deep learning platform for mobile diagnosis of skin diseases," *IEEE J. Biomed. Health Inform.*, vol. 27, no. 1, pp. 176–187, 2023.
- [10] S. A. Yamaç, O. Kuyucuoglu, Ş. B. Köseoglu, and S. Ulukaya, "Deep learning-based classification of human nail diseases using color nail images," in *Proc. 45th Int. Conf. Telecommun. and Signal Process. (TSP)*, Prague, Czech Republic, Jul. 2022, pp. 196–199.
- [11] H. Muneera Begum, A. Dhivya, A. J. Krishnan, and S. D. Keerthana, "Automated detection of skin and nail disorders using convolutional neural networks," in *Proc. 5th Int. Conf. Trends Electron. Inform. (ICOEI)*, Tirunelveli, India, Jun. 2021, pp. 1309–1316.
- [12] G. Shandilya *et al.*, "Autonomous detection of nail disorders using a hybrid capsule CNN: A novel deep learning approach for early diagnosis," *BMC Med. Inform. Decis. Mak.*, vol. 24, 2024, Art. no. 414.
- [13] *Nail Disease Image Classification Dataset*, Kaggle, 2023. [Online]. Available: <https://www.kaggle.com/datasets/josephrasanjana/nail-disease-image-classification-dataset>
- [14] A. Vaswani *et al.*, "Attention is all you need," in *Proc. 31st Conf. Neural Inf. Process. Syst. (NIPS)*, Long Beach, CA, USA, Dec. 2017, pp. 5998–6008. [Online]. Available: https://papers.nips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf
- [15] R. Nijhawan, R. Verma, Ayushi, S. Bhushan, R. Dua, and A. Mittal, "An integrated deep learning framework approach for nail disease identification," in *Proc. 13th Int. Conf. Signal-Image Technol. Internet-Based Syst. (SITIS)*, Jaipur, India, Dec. 2017, pp. 197–202.
- [16] A. Kumar and K. K. Tiwari, "Disease classification in dermatology: A CNN-RF hybrid approach," in *Proc. 3rd Int. Conf. Artif. Intell. Internet Things (AllIoT)*, Vellore, India, May 2024, pp. 1–5.



- [17] S. Marulkar and B. Narain, "Nail disease prediction using a deep learning integrated framework," in *Proc. 3rd Int. Conf. Intell. Technol. (CONIT)*, Hubli, India, Jun. 2023, pp. 1–6.