

การเปรียบเทียบประสิทธิภาพแบบจำลองการเรียนรู้เชิงลึก ประเภทโครงข่ายประสาทเทียม แบบคอนโวลูชัน สำหรับการจำแนกรูปภาพเหง้าพืชในวงศ์ขิง

อณัญญา พรหมโคตร^{1*} รัตนา อินทเกตุ² สุไพลิน พิชัย³

Received : November 21, 2024

Revised : July 3, 2025

Accepted : July 16, 2025

บทคัดย่อ

พืชสมุนไพรเป็นส่วนหนึ่งของการแพทย์แผนโบราณ มีการใช้รักษาโรค และเสริมสร้างสุขภาพมาหลายศตวรรษ แม้ว่าในปัจจุบัน ปัจจุบันพืชสมุนไพรยังคงมีบทบาทสำคัญ และมีการใช้อย่างแพร่หลาย ความท้าทายหนึ่งที่สำคัญ คือการจำแนกชนิดพืชสมุนไพร เนื่องจากพืชสมุนไพรบางชนิดมีลักษณะทางกายภาพคล้ายคลึงกันมาก อาจเกิดความผิดพลาดในกระบวนการจำแนกชนิดสมุนไพรได้ อาจส่งผลให้ผลิตภัณฑ์ที่แปรรูปจากพืชสมุนไพร ไม่มีสรรพคุณที่ต้องการ และอาจเป็นอันตรายต่อสุขภาพต่อผู้ใช้งาน การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก ประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 วิธี ได้แก่วิธี ResNet-50 วิธี VGG-19 วิธี DenseNet201 และ วิธี InceptionV3 สำหรับการจำแนกรูปภาพเหง้าสมุนไพร ในวงศ์ขิง 4 ชนิด เพื่อปรับแต่งพารามิเตอร์ให้มีความเหมาะสม และ ประเมินประสิทธิภาพของแบบจำลอง ผู้วิจัยรวบรวมข้อมูลรูปภาพสมุนไพรจำนวน 2,111 รูปภาพ และเผยแพร่สาธารณะ ในการทดลองจำแนกชนิดพืชสมุนไพร ผู้วิจัยประยุกต์ใช้วิธี Augmentation เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูลฝึกสอน หลังจากนั้น นำข้อมูลเข้าสู่กระบวนการฝึกสอน ในแบบจำลองการเรียนรู้เชิงลึก และปรับแต่งพารามิเตอร์เพื่อเพิ่มประสิทธิภาพของแบบจำลอง ผลการทดลองปรากฏว่าวิธี DenseNet201 ที่มีจำนวนรอบการฝึก 200 รอบ มีความแม่นยำสูงสุดเมื่อเปรียบเทียบกับแบบจำลองอื่น ๆ ที่ศึกษา ผลการทดลองแสดงให้เห็นว่าแบบจำลองที่พัฒนาขึ้น สามารถนำไปประยุกต์ใช้ในอุตสาหกรรมที่เกี่ยวข้องกับสมุนไพร ซึ่งจะช่วยยกระดับมาตรฐานผลิตภัณฑ์ได้อย่างมีประสิทธิภาพ

คำสำคัญ: การจำแนกรูปภาพ การจำแนกสมุนไพร การประมวลผลภาพ การเรียนรู้เชิงลึก ขมิ้นชัน
ขมิ้นอ้อย โครงข่ายประสาทเทียมแบบคอนโวลูชัน ไพล ว่านนางคำ

¹ สาขาวิชาแพทย์แผนไทย คณะทรัพยากรธรรมชาติ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน วิทยาเขตสกลนคร
อีเมล: ananya.ch@rmuti.ac.th

² สาขาวิชาแพทย์แผนไทย คณะทรัพยากรธรรมชาติ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน วิทยาเขตสกลนคร
อีเมล: rattana.in@rmuti.ac.th

³ สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเลย อีเมล: supailin.pic@lru.ac.th

* ผู้นิพนธ์หลัก อีเมล: ananya.ch@rmuti.ac.th

PERFORMANCE COMPARISON OF CONVOLUTIONAL NEURAL NETWORK-BASED
DEEP LEARNING MODELS FOR RHIZOME IMAGE CLASSIFICATION
IN THE *ZINGIBERACEAE* FAMILY

A-Nanya Promkot^{1*} Rattana Intaket² Supailin Pichai³

Abstract

Herbal plants have been an essential part of traditional medicine for centuries. They have been used to treat various ailments and promote overall health. Despite significant advances in modern medicine, herbal plants have played a crucial role and been extensively employed across numerous sectors. A major challenge in their application is the accurate identification and classification of species, as herbs within the same family often exhibit remarkably similar physical characteristics. Such similarities can cause misclassification, leading to ineffective products or potential health risks. This study evaluated and compared four convolutional neural network models including ResNet-50, VGG-19, DenseNet201, and InceptionV3 for classifying rhizome images of four species in the Zingiberaceae family: Turmeric, Zedoary, Plai, and Wild turmeric. This aimed to properly adjust their parameter and evaluated their efficiency of model. The researchers collected and publicly released a dataset of 2,111 images then applied data augmentation to increase training diversity. After that, hyperparameter tuning was performed to optimize model performance. Experimental results were demonstrated that DenseNet201 with 200 training epochs, outperformed the other models, achieving the highest classification accuracy. These findings were suggested that the proposed model has been highly suitable for practical use in herbal industries, aiding species identification, product standardization, and quality control.

Keywords: Image classification, Herbal classification, Image processing, Deep learning, Turmeric, Zedoary, Convolution neural network, Plai, Wild turmeric

¹ Department of Thai traditional medicine in The Faculty of Natural Resources, Rajamangala University of Technology Isan Sakonnakhon Campus, e-mail: ananya.ch@rmuti.ac.th

² Department of Thai traditional medicine in The Faculty of Natural Resources, Rajamangala University of Technology Isan Sakonnakhon Campus, e-mail: rattana.in@rmuti.ac.th

³ Computer science, The Faculty of Science and Technology, LoeiRajabhat University, e-mail: supailin.pic@lru.ac.th

* Corresponding author, e-mail : ananya.ch@rmuti.ac.th

บทนำ

การใช้พืชสมุนไพรและผลิตภัณฑ์สมุนไพร มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในช่วงหลายปีที่ผ่านมา มีรายงานที่ระบุว่า สารออกฤทธิ์ทางชีวภาพในพืช เช่น โพลีฟีนอลส์ เทอร์พีนอยด์ และอัลคาลอยด์ เป็นปัจจัยสำคัญที่ส่งผลต่อประโยชน์ต่อสุขภาพ พืชสมุนไพรแต่ละชนิด มีสรรพคุณและข้อจำกัดการใช้งานที่แตกต่างกัน (Sellami et al., 2018) พืชสมุนไพรบางชนิดมีลักษณะทางพฤกษศาสตร์ที่ใกล้เคียงกันมาก จนยากที่จะจำแนกชนิดพืชสมุนไพรด้วยตาเปล่าได้อย่างถูกต้อง ต้องอาศัยความรู้ความชำนาญ และประสบการณ์ ของผู้เชี่ยวชาญด้านพฤกษศาสตร์ หรือหมอพื้นบ้าน (Zhu et al., 2018) จนในบางครั้งเกิดความสับสน และมีข้อถกเถียงในการระบุชนิดของพืชสมุนไพร หากจำแนกชนิดของพืชสมุนไพรไม่ถูกต้อง ผลิตภัณฑ์ที่แปรรูปจากสมุนไพร หรือตำรับยา จะไม่สามารถรักษาโรคได้ และอาจส่งผลกระทบต่อร่างกาย เนื่องจากใช้สมุนไพรผิดชนิด หรือไม่ตรงกับอาการของโรค ดังนั้น การระบุชนิดพืชสมุนไพรจึงเป็นกระบวนการหนึ่งที่มีความสำคัญอย่างยิ่ง ส่งผลกระทบต่ออุตสาหกรรมยาสมุนไพร และประชาชนผู้ใช้งานทั่วไป พืชที่อยู่ในวงศ์ขิง (*Zingiberaceae*) เป็นหนึ่งในพืชสมุนไพรที่ใช้งานอย่างแพร่หลาย มีฤทธิ์ต้านอนุมูลอิสระ (Antioxidant activity) ฤทธิ์ต้านการอักเสบ (Anti-inflammatory activity) และ ฤทธิ์ยับยั้งการเจริญเติบโตของเซลล์เนื้องอก (Tumor cell growth inhibitory activity) (Liu et al., 2013) ซึ่งในโลกมีประมาณ 1,300 ชนิด กระจายตัวอยู่ทั่วไปในเขตร้อน โดยเฉพาะในภูมิภาคเอเชียตะวันออกเฉียงใต้ (Soumya et al., 2023) ตัวอย่างพืชอยู่ในวงศ์ขิง ที่มีความนิยมนำมาใช้ในปัจจุบัน ได้แก่ ขมิ้นชัน (Turmeric) ขมิ้นอ้อย (Zedoary) ไพล (Plai) และว่านนางคำ (Wild turmeric) โดยขมิ้นชัน และขมิ้นอ้อย เป็นพืชในสกุล *Curcuma* การจำแนกพืช 4 ชนิดด้วยการจำแนกชนิดสมุนไพรดังกล่าว ด้วยตาเปล่าหรือการดมกลิ่นเป็นสิ่งที่ทำได้ยาก เนื่องจากพืชเหล่านี้มีลักษณะทางกายภาพคล้ายคลึงกัน ทั้งสีของเหง้า กลิ่น และเนื้อสัมผัส ต้องอาศัยความรู้ และความเชี่ยวชาญเป็นพิเศษเฉพาะบุคคล

ด้วยความก้าวหน้าทางด้านเทคโนโลยีสารสนเทศ ในปัจจุบัน เทคโนโลยีการประมวลผลข้อมูลขนาดใหญ่ ได้เข้ามามีบทบาทในงานด้านวิทยาศาสตร์สุขภาพมากมาย ได้แก่ ระบบสนับสนุนการวินิจฉัยโรค (Wang et al., 2020) (Ragab et al., 2023) (Zhong et al., 2024) ระบบแนะนำโภชนาการและการดูแลสุขภาพ (Kaur et al., 2023) (Smith et al., 2022) เทคโนโลยีเหล่านี้ ช่วยสนับสนุนประสิทธิภาพ ในการให้บริการด้านสาธารณสุข ส่งผลกระทบโดยตรงต่อประชาชน การประยุกต์เทคโนโลยีการประมวลผลข้อมูลขนาดใหญ่ สำหรับการจำแนกพืชสมุนไพร เป็นสิ่งที่มีความสำคัญในเชิงเศรษฐกิจ สังคม และสุขภาพ การจำแนกพืชสมุนไพร ด้วยวิธีการเรียนรู้ของเครื่อง (Machine learning) จะช่วยลดความเสี่ยง ในการผลิตสมุนไพรที่ผิดชนิด ช่วยเพิ่มประสิทธิภาพในการผลิตสมุนไพรคุณภาพ สำหรับอุตสาหกรรมยาสมุนไพร และการใช้งานในชุมชน นอกจากนี้ ยังส่งเสริมให้ประชาชนทั่วไป สามารถใช้พืชสมุนไพรในการดูแลสุขภาพของตนเองเบื้องต้น ช่วยลดค่าใช้จ่ายในการรักษาพยาบาล และ สนับสนุนความยั่งยืน ในการใช้สมุนไพรในชีวิตประจำวัน ปัจจุบัน มีงานวิจัยมากมาย ที่เกี่ยวข้องกับการพัฒนาแบบจำลองจำแนกรูปภาพพืชสมุนไพร และผลผลิตทางการเกษตร ในช่วงต้น การวิจัยเกี่ยวกับการจำแนกรูปภาพ ผู้วิจัยใช้เทคนิคการเรียนรู้ของเครื่องแบบดั้งเดิม (traditional machine learning) ได้แก่ วิธี Random forest วิธี Support vector Machine และ วิธี โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron) มีงานวิจัยที่ผ่านมา (Aakif & Khan, 2015) ได้ทดลองจำแนกรูปภาพใบพืชที่มีรูปร่างแบบต่าง ๆ จำนวน 14 ชนิด เน้นการวิเคราะห์ลักษณะรูปร่างภายนอกของใบพืช เช่น สัดส่วน ความกลม ความยาว ความกว้าง ขอบใบ และ โครงสร้างรูปทรง โดยใช้คุณลักษณะทางสัณฐานวิทยา (morphological features) คุณลักษณะเชิงนิยามรูปทรง (shape-defining

feature) และตัวบ่งชี้ฟูเรียร์ (Fourier descriptors) ช่วยให้เราสามารถจำแนกใบพืช ที่มีรูปร่างแตกต่างกัน ได้อย่างมีประสิทธิภาพ อย่างไรก็ตาม วิธีนี้ยังมีข้อจำกัด ในการจำแนกใบพืชที่มีรูปร่างใกล้เคียงกัน แต่แตกต่างกันในแง่มุมอื่น เช่น สีของใบ ลวดลาย หรือพื้นผิวของใบ เนื่องจากไม่ได้พิจารณาคุณสมบัติเหล่านี้ ในการประมวลผลภาพ เป็นต้น อย่างไรก็ตามความต้องการจำแนกรูปภาพพืช ที่มีลักษณะรูปร่างคล้ายกัน แต่แตกต่างกันที่สีหรือผิว ยังมีความจำเป็น ซึ่งสามารถแก้ไขด้วยแบบจำลองการเรียนรู้เชิงลึก มีความสามารถในการเรียนรู้ฟีเจอร์จากรูปภาพได้อย่างครบถ้วน ทั้งรูปร่าง สี และพื้นผิวโดยไม่ต้องออกแบบฟีเจอร์ ด้วยมือ เหมาะสำหรับจำแนกรูปภาพที่มีความซับซ้อน และความคล้ายคลึงสูง ดังนั้น งานวิจัยที่เกี่ยวข้องกับการพัฒนาแบบจำลอง สำหรับจำแนกรูปภาพพืชต่างๆ จึงนิยมประยุกต์วิธีการเรียนรู้เชิงลึก ในการแก้ไขปัญหา ดังปรากฏในงานของ Zhao et al. (2022) เป็นงานวิจัยที่ใช้เทคโนโลยีประมวลผลภาพ สำหรับจำแนกรูปภาพใบพืชที่มีอาการโรคพืชด้วยวิธี DoubleGAN และงานของ Liu et al. (2020), Cap et al. (2022), Alshammari et al. (2024), Wang et al. (2021), และ Promkot (2024) มีลักษณะคล้ายกัน Tan et al. (2021) ได้รวบรวมรูปภาพทั้งสิ้น 4,067 รูปภาพ ด้วยกล้องดิจิทัล นำข้อมูลรูปภาพ มาทดสอบด้วยวิธี Random forest และ วิธี Support vector machine จากการศึกษางานวิจัยที่เกี่ยวข้อง จะเห็นได้ว่า งานวิจัยก่อนหน้านี้ ได้แสดงผลการทดลองที่น่าพอใจ แต่อย่างไรก็ตามด้วยความหลากหลายของพืชสมุนไพร การรวบรวมข้อมูลรูปภาพสมุนไพร และการปรับปรุงแบบจำลองให้มีความถูกต้องแม่นยำ สอดคล้องกับลักษณะพืชสมุนไพรแต่ละชนิดยังคงเป็นสิ่งที่มีความท้าทาย

ในปัจจุบัน การจำแนกพืชสมุนไพร ด้วยแบบจำลองการเรียนรู้ของเครื่อง หรือแบบจำลองการเรียนรู้เชิงลึก ยังคงมีข้อจำกัดด้านชุดข้อมูลสาธารณะที่สามารถนำมาใช้ในการทดลอง เพื่อรองรับการพัฒนาในงานวิจัย ในสาขานี้ งานวิจัยนี้จึงศึกษาและออกแบบวิธีการที่เหมาะสมสำหรับการจำแนกรูปภาพเหง้าสมุนไพร โดยประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึก 4 วิธี คือ 1) ResNet-50 2) VGG-19 3) DenseNet201 และ 4) InceptionV3 เนื่องจากเป็นวิธีที่ได้รับการพิสูจน์แล้วว่า มีประสิทธิภาพในการจำแนกรูปภาพ ใช้วิธี Hyperparameter เพื่อหาค่าที่ดีที่สุดของแต่ละแบบจำลอง ทั้งนี้ได้รวบรวมชุดข้อมูลรูปภาพเหง้าพืชสมุนไพร 4 ชนิด ได้แก่ ขมิ้นชัน ขมิ้นอ้อย ไพล และว่านนางคำ โดยเก็บตัวอย่างจากร้านจำหน่ายพืชสมุนไพร นำมาฝานเป็นชิ้น และถ่ายภาพด้วยกล้องดิจิทัลสมาร์ทโฟน ข้อมูลรูปภาพเหง้าสมุนไพรดังกล่าว ได้รับการเผยแพร่เพื่อให้เป็นทรัพยากรแก่คณาจารย์ นักวิจัย และผู้สนใจสำหรับการศึกษาและการพัฒนาแบบจำลองการจำแนกในงานประมวลผลภาพต่อไป

วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษา และ เปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก ประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 วิธี ได้แก่ วิธี ResNet-50 วิธี VGG-19 วิธี DenseNet201 และวิธี InceptionV3 สำหรับการจำแนกรูปภาพเหง้าสมุนไพรในวงศ์ขิง 4 ชนิด
2. เพื่อปรับแต่งพารามิเตอร์ของแบบจำลองให้มีความเหมาะสม และ ประเมินประสิทธิภาพของแบบจำลอง สำหรับใช้เป็นข้อมูลเบื้องต้น ในการนำไปใช้ในกระบวนการจำแนกสมุนไพร


วิธีดำเนินการวิจัย

1. ทฤษฎีที่เกี่ยวข้อง

หลักการและทฤษฎีของวิธีการเรียนรู้ของเครื่องที่ใช้แบบจำลองการเรียนรู้เชิงลึกในการวิเคราะห์และจดจำลักษณะภาพเพื่อการจำแนกรูปภาพโดยอัตโนมัติ มีรายละเอียดดังนี้

1.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) (Pacal et al., 2024) หรือวิธี CNN ได้รับการยอมรับอย่างแพร่หลายในการประมวลผลภาพ เนื่องจากมีโครงสร้างที่ซับซ้อนและสามารถสกัดคุณลักษณะ (Feature extraction) จากภาพได้อย่างมีประสิทธิภาพ ในภาพที่ 1 แสดงโครงสร้างการทำงานของวิธี CNN ที่ประกอบด้วยเลเยอร์หลายชั้นที่ทำงานร่วมกัน ได้แก่ 1) เลเยอร์คอนโวลูชัน (Convolutional layers) ซึ่งใช้ฟิลเตอร์ในการสกัดคุณลักษณะจากภาพ 2) เลเยอร์รวมข้อมูล (Pooling layers) เพื่อลดขนาดของข้อมูลให้เหมาะสม และ 3) เลเยอร์เชื่อมต่อแบบเต็ม (Fully connected layers) ที่ใช้สำหรับการจำแนกภาพตามกลุ่มเป้าหมาย



ภาพที่ 1 โครงสร้างการทำงานของวิธี CNN (Pacal et al., 2024)

1.1.1 เลเยอร์คอนโวลูชัน ทำหน้าที่สกัดคุณลักษณะที่สำคัญจากข้อมูลภาพที่นำเข้า โดยใช้ฟิลเตอร์หรือเคอร์เนลที่เลื่อนผ่านภาพเพื่อดึงข้อมูล เช่น ขอบ สี รูปทรง และลวดลายต่าง ๆ ฟิลเตอร์เหล่านี้ประกอบด้วยค่าน้ำหนัก (w) และอคติ (b) ที่สามารถปรับให้เหมาะสมได้ระหว่างการฝึกโมเดล พร้อมทั้งมีฟังก์ชันกระตุ้น (f) เพื่อช่วยในการคำนวณผลลัพธ์

เมื่อข้อมูลนำเข้า X ประกอบด้วย ฟิลเตอร์เท่ากับ k ในเลเยอร์คอนโวลูชัน ผลลัพธ์จากเลเยอร์คอนโวลูชัน สามารถคำนวณได้ดังสมการ (Pacal et al., 2024) ต่อไปนี้

$$y_i = \sum f(x_i * w_j + b_i), j = 1, 2, \dots, k \quad (1)$$

1.1.2 เลเยอร์รวมข้อมูล มีหน้าที่ลดขนาดของข้อมูลคุณลักษณะที่ได้จากเลเยอร์คอนโวลูชัน เพื่อลดจำนวนพารามิเตอร์และการคำนวณในเครือข่ายประสาทเทียม โดยยังคงรักษาคุณลักษณะที่สำคัญไว้ ในปัจจุบัน วิธีที่นิยมใช้มากที่สุดคือการรวมค่าสูงสุด (Max Pooling) และการรวมค่าเฉลี่ย (Average Pooling) สมการที่ (2) ได้อธิบายกระบวนการรวมค่าเฉลี่ย โดยสมมติว่าขนาดของหน้าต่างเท่ากับ $p \times p$

ซึ่งค่า $x_{i,j}$ หมายถึงค่าการกระตุ้น (activation value) ณ ตำแหน่ง (i,j) และ N หมายถึงจำนวนรายการทั้งหมดใน S

$$z = \frac{1}{N} + \sum_{(i,j) \in S}^{\infty} x_{i,j}, i, j = 1, 2, \dots, p \quad (2)$$

1.1.3 เลเยอร์เชื่อมต่อแบบเต็ม (Fully Connected Layer) ทำหน้าที่แปลงแผนที่คุณลักษณะ (feature maps) ที่สกัดได้จากเลเยอร์ก่อนหน้านี้ให้เป็นเวกเตอร์แบบหนึ่งมิติ ซึ่งเหมาะสำหรับการจำแนกหรือทำนายผลลัพธ์ โดยแต่ละโหนดในเลเยอร์นี้จะคำนวณข้อมูลนำเข้าด้วยกระบวนการเชิงเส้น จากนั้นใช้ฟังก์ชันกระตุ้น (activation function) เพื่อสร้างค่าผลลัพธ์สุดท้าย เลเยอร์เชื่อมต่อแบบเต็ม ช่วยให้เครือข่ายประสาทเทียมสามารถเรียนรู้รูปแบบที่ซับซ้อน และใช้ในการตัดสินใจขั้นสุดท้ายได้อย่างแม่นยำ โดยมีการปรับน้ำหนัก และค่าอคติในระหว่างการฝึกโมเดล เพื่อให้เกิดประสิทธิภาพสูงสุด สมการ (3) อธิบายวิธีการคำนวณของเลเยอร์เชื่อมต่อแบบเต็ม โดยที่ γ และ Z แทนเวกเตอร์ผลลัพธ์ และคุณลักษณะนำเข้า W หมายถึงน้ำหนัก และ b หมายถึง ค่าอคติของเลเยอร์เชื่อมต่อแบบเต็ม

$$\gamma = \sum_i f(wz + b) \quad (3)$$

แม้ว่าวิธี CNN เป็นโมเดลเครือข่ายประสาทเทียม ที่มีประสิทธิภาพสูงในการประมวลผลภาพ อย่างไรก็ตาม CNN ก็มีข้อจำกัดบางประการ เช่น ปัญหาการหายไปของค่าความชัน เมื่อโครงข่ายมีความลึกมาก ส่งผลประสิทธิภาพในการจำแนกรูปภาพ นอกจากนี้ยังต้องการพารามิเตอร์จำนวนมาก ส่งผลให้การฝึกแบบจำลองใช้ทรัพยากรสูง วิธี CNN ยังมีความไวต่อการเปลี่ยนแปลงของมุมมองในภาพ และมีข้อจำกัดในการจับความสัมพันธ์เชิงพื้นที่ที่อยู่ไกลกันในภาพ ดังนั้นจึงมีการพัฒนาวิธีการต่าง ๆ เช่น วิธี ResNet-50 วิธี VGG-19 วิธี DenseNet201 และ วิธี InceptionV3 เพื่อแก้ไขปัญหาที่ได้กล่าวมาข้างต้นนี้ และเพิ่มประสิทธิภาพในการประมวลผลภาพ แบบจำลองเหล่านี้เป็นแบบจำลองที่ผ่านการฝึกสอนล่วงหน้า (Pretrained models) ซึ่งได้รับการฝึกด้วยข้อมูลขนาดใหญ่ เช่น ImageNet ทำให้สามารถถ่ายโอนความรู้ไปยังแบบจำลองใหม่ได้ กระบวนการนี้ช่วยลดความต้องการข้อมูลจำนวนมากในแบบจำลองใหม่ และทำให้การฝึกสอนมีประสิทธิภาพยิ่งขึ้น (Espinoza et al., 2024)

2. งานวิจัยที่เกี่ยวข้อง

จากการศึกษางานวิจัยที่เกี่ยวข้อง พบว่างานวิจัยด้านการประมวลผลภาพด้วยวิธีการเรียนรู้เชิงลึกเป็นวิธีที่ได้รับความนิยมอย่างแพร่หลาย สำหรับงานวิจัยที่ใช้วิธีการเรียนรู้เชิงลึกสำหรับงานจำแนกรูปภาพพืชสมุนไพร มีรายละเอียดดังนี้

มีงานวิจัยที่รวบรวมข้อมูลรูปภาพสมุนไพรตามวัตถุประสงค์ของแต่ละงาน ดังปรากฏ Ji et al. (2024) ได้รวบรวมรูปภาพสมุนไพรจีน 10 ชนิด จำนวน 15,719 รูปภาพ ผู้วิจัยได้ใช้วิธี AGC มาใช้ ในกระบวนการเตรียมข้อมูล และนำมาเปรียบเทียบกับ CLAHE หลังจากนั้นนำมาเรียนรู้ด้วยวิธี GoogLeNet, วิธี ResNet-18 และ วิธี MobileNetV2 ผู้วิจัยสรุปว่าการนำวิธี AGC มาใช้ จะช่วยเพิ่มประสิทธิภาพการจำแนกรูปภาพ Wang et al. (2021) ได้ทดสอบประสิทธิภาพการจำแนกรูปภาพสมุนไพรจีน ที่หั่นเป็นชิ้นส่วนขนาดเล็ก ชนิดแห้ง ด้วยแบบจำลอง AlexNet, VGGNet, และ ResNet ร่วมกับ Fine-tuning ข้อมูลรูปภาพที่นำมาใช้ในการทดสอบเท่ากับ 72,026 รูปภาพ แบ่งเป็น 7 ชนิด แบ่งข้อมูล สำหรับฝึกสอนข้อมูล ข้อมูลสำหรับการตรวจสอบ และ ข้อมูลสำหรับการทดสอบเท่ากับ 70% 15% และ 15% ผู้วิจัยทดลอง Fine-tuning the


pre-trained model จะกระทั้งค่า epoch เท่ากับ 200 ผลการทดสอบความถูกต้องของแบบจำลอง ด้วยข้อมูลรูปภาพจำนวน 10,806 รูปภาพ ผู้วิจัยรายงานว่า แบบจำลอง ResNet based on transfer learning แสดงประสิทธิภาพสูงสุด มีค่าความถูกต้องเท่ากับ 98.17% Tan et al. (2021) รวบรวมรูปภาพสมุนไพรจีน 8 ชนิด โดยใช้กล้องดิจิทัลสมาร์ทโฟน จำนวนรูปภาพที่รวบรวมได้เท่ากับ 4,067 รูปภาพ ได้แก่ 1) Gingko 2) Ginseng 3) Barley 4) Ficus Carica 5) Jujube 6) Longan 7) Lotus Seed และ 8) Lycium ปรับรูปภาพให้มีขนาดเท่ากับ 64×64 พิกเซล หลังจากนั้นปรับรูปภาพให้อยู่ในรูปแบบ Grayscale เพื่อนำข้อมูลเข้าสู่แบบจำลองเพื่อฝึกสอนด้วยวิธี CNN ผู้วิจัยเปรียบเทียบวิธี CNN กับวิธี Random forest และวิธี Support vector machine ในการทดลองได้แบ่งข้อมูลออกเป็น 64% สำหรับฝึกสอน 16% สำหรับการตรวจสอบ และ 20% สำหรับการทดสอบ ผลการทดสอบประสิทธิภาพ การจำแนกชนิดสมุนไพรจีน วิธี CNN มีประสิทธิภาพสูงสุด เมื่อเปรียบเทียบกับวิธี Random forest และวิธี Support vector machine โดย Chen et al. (2023) ได้จำแนกสายพันธุ์สมุนไพรจีน *Fritillaria cirrhosa* จำนวน 3 สายพันธุ์ ประกอบด้วย สายพันธุ์ Songbei สายพันธุ์ Qingbei และสายพันธุ์ Lubei ด้วยวิธี ResNet34 ที่ปรับปรุงโดยการเพิ่มเลเยอร์เชื่อมต่อแบบเต็ม ขึ้นมาในตำแหน่งที่อยู่ก่อนตัวจำแนกประเภท Softmax เพื่อปรับปรุงความสามารถ ในการเรียนรู้ของแบบจำลอง ข้อมูลที่ใช้ในการทดลอง ประกอบด้วยรูปภาพสมุนไพรจีน จำนวน 3,915 รูปภาพ มีขนาด 224×224 พิกเซล โดยสุ่มเลือกรูปภาพประเภทละ 160 รูปภาพ ผู้วิจัยแสดงผลการเปรียบเทียบแบบจำลอง 3 วิธี ได้แก่วิธี ResNet18 วิธี Alexnet และ วิธี VGG16 ภายใตสภาพแวดล้อมการประมวลผลเดียวกัน พบว่ามีค่าความถูกต้องสูงสุดที่ 92.3% สูงกว่า วิธี ResNet18 วิธี Alexnet และ วิธี VGG16 ซึ่งแสดงให้เห็นถึงประสิทธิภาพ และความเหมาะสมของวิธีที่นำเสนอ ยังมีงานที่ลักษณะคล้ายกัน ดังปรากฏ Angkoso et al. (2023), Sharrab et al. (2023), Mookdarsanit and Mookdarsanit (2022), Panmuang and Rodmorn (2023), และ Islam et al. (2024) จากรายละเอียดการศึกษางานวิจัยที่ผ่านมา แสดงให้เห็นว่า ผู้วิจัยต่างพยายามปรับปรุงประสิทธิภาพการจำแนกรูปภาพด้วยวิธีการเรียนรู้เชิงลึก แต่อย่างไรก็ตาม ยังมีข้อจำกัดเกี่ยวกับชุดข้อมูลที่นำมาใช้ในกระบวนการฝึกสอน ดังนั้น จึงมีงานวิจัยที่ได้รวบรวมข้อมูลรูปภาพสมุนไพร และเผยแพร่ เพื่อนำไปใช้ประโยชน์ ในการพัฒนางานด้านประมวลผลภาพ ตัวอย่างเช่น Sharma et al. (2024) ทดลองจำแนกรูปภาพ ด้วยแบบจำลองการเรียนรู้เชิงลึก วิธี VGG19 วิธี InceptionV3 วิธี LeNet และ วิธี Resnet50 รูปภาพที่นำมาทดลองเป็นรูปภาพใบพืชจำนวน 1835 รูปภาพ จำนวน 30 ชนิด เป็นรูปภาพสาธารณะ (<https://data.mendeley.com/datasets/nnytj2v3n5/1>) ผลการทดลอง วิธี VGG-19 แสดงประสิทธิภาพสูงสุดมีค่าความถูกต้องเท่ากับ 99.85% Islam et al. (2023) ได้รวบรวมรูปภาพใบพืชสมุนไพรที่ใช้ในประเทศบังคลาเทศ และเผยแพร่ข้อมูลรูปภาพสมุนไพร โดยในเบื้องต้น รวบรวมข้อมูลรูปภาพได้จำนวน 2,029 รูปภาพ หลังจากนั้นนำมาเข้าสู่กระบวนการ Augmentation จึงมีรูปภาพจำนวนทั้งสิ้น 38,606 รูปภาพ นำข้อมูลรูปภาพดังกล่าวมาทดลองจำแนกข้อมูลด้วยแบบจำลองการเรียนรู้เชิงลึก วิธี DenseNet201 และ วิธี InceptionResNetV2 ผลการทดลองแสดงค่าความถูกต้องเท่ากับ 80.69% และ 90.09% Borkatulla et al. (2023) ได้รวบรวมรูปภาพใบพืชสมุนไพรที่ใช้ในประเทศบังคลาเทศ โดยใช้กล้องดิจิทัลสมาร์ทโฟน จำนวน 10 สายพันธุ์ สายพันธุ์ละ 500 รูปภาพ ทั้งนี้ผู้วิจัยได้ทดลองรูปภาพที่รวบรวมได้มาทดลองประมวลผลรูปภาพด้วยแบบจำลองการเรียนรู้ของเครื่อง ด้วยวิธี ImageNet pre-trained ResNet50 วิธี DenseNet201 วิธี VGG16 และ วิธี InceptionV3 ในงานวิจัยของ Sarma et al. (2023) ได้รวบรวมข้อมูลรูปภาพใบพืชสมุนไพรในรัฐอัสสัม ประเทศอินเดีย เผยแพร่ Mendeley platform นำรูปภาพเข้าสู่กระบวนการ Segmentation ด้วยวิธี U-net และในงานวิจัยของ Tian et al. (2024) ได้รวบรวมรูปภาพ

สมุนไพรจีน และ เผยแพร่เพื่อใช้สำหรับงานด้านการประมวลผลภาพ ประกอบด้วย 2 ชุดข้อมูล คือ 1) รูปภาพสมุนไพรจีน 20 ชนิด จำนวน 3,384 รูปภาพ โดยรูปภาพดังกล่าว ได้รับการอธิบายโดยผู้เชี่ยวชาญด้านการแพทย์แผนจีน 2) รวบรวมรูปภาพสมุนไพรจีน 400 รูปภาพ ด้วยกล้องสมาร์ทโฟน ผู้วิจัยได้ทดลองนำรูปภาพมาทดลองจำแนกข้อมูลรูปภาพด้วยแบบจำลอง 8 วิธี ได้แก่ วิธี VGG ResNet วิธี InceptionV3 วิธี ShuffleNetV2 วิธี SqueezeNet วิธี MobileNetV2 และวิธี MobileNetV3 ผลการทดลองพบว่าแบบจำลองการเรียนรู้ของเครื่องที่นำมาทดลอง มีความถูกต้องสูงกว่า 90% โดยวิธี MobileNetV3 มีค่าความถูกต้องสูงสุด มีค่าเท่ากับ 97.10%

3. ออกแบบการทดลอง

3.1 ข้อมูลที่ใช้ในการทดลอง

1) ข้อมูลภาพถ่ายรูปภาพสมุนไพรวงศ์จิงจำนวน 4 ชนิด ได้แก่ ขมิ้นชัน ขมิ้นอ้อย ไพล และว่านนางคำ จำนวน 2,111 รูปภาพ เผยแพร่ข้อมูลบนเว็บไซต์ Mendeley data สามารถเข้าถึงข้อมูลได้จากลิงค์ <https://data.mendeley.com/datasets/87nrnwzjkj/1>



ภาพที่ 2 กราฟแสดงข้อมูลจำนวนรูปภาพสมุนไพรจำแนกตามประเภท

2) เครื่องมือวัดและประเมินผล (Evaluation Metrics)

งานวิจัยนี้ได้กำหนดเครื่องมือที่ใช้ในการวัดและประเมินผล ดังนี้

ค่าความถูกต้อง (Accuracy) สำหรับทดสอบประสิทธิภาพในการจำแนกข้อมูลได้ถูกต้อง มีค่าสูงสุดเท่ากับ 100% ดังสมการต่อไปนี้

$$\text{Accuracy} = \left(\frac{TP+TN}{TP+TN+FP+FN} \right) \times 100 \quad (4)$$

ค่าความแม่นยำ (Precision)

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

ค่าความครบถ้วน (Recall)


$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

ค่าประสิทธิภาพโดยรวม (F-measure)

$$F - \text{measure} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

3.2 การเตรียมชุดข้อมูล

1) รวบรวมข้อมูลรูปภาพพืชสมุนไพร จำนวน 4 ชนิด ประกอบด้วย ขมิ้นชัน ขมิ้นอ้อย ไพล และ ว่านนางคำ โดยสมุนไพรที่ได้รับคัดเลือกคือสมุนไพรที่มีอายุพร้อมเก็บเกี่ยว ถ่ายรูปภาพเหง้าสมุนไพรที่ผ่าเห็นเนื้อด้านในด้วยกล้องสมาร์ทโฟน กำหนดสถานที่ถ่ายภาพอยู่ภายในอาคาร ตัวอย่างภาพถ่ายรูปภาพสมุนไพรดังแสดงในภาพที่ 3



ภาพที่ 3 ตัวอย่างภาพถ่ายรูปภาพสมุนไพรที่ใช้งานการทดลอง


2) รูปภาพที่รวบรวมได้มีจำนวน 2,111 รูปภาพ จัดกลุ่มไฟล์รูปภาพจำแนกตามประเภทของสมุนไพร รูปภาพที่ได้จากกล้องสมาร์ทโฟน เป็นไฟล์นามสกุล HEIC ผู้วิจัยแปลงไฟล์รูปภาพเป็นไฟล์นามสกุล JPG เนื่องจากในการทดลองนี้ ผู้วิจัยใช้ไลบรารี Pillow (หรือ PIL) สำหรับการประมวลผลภาพ ซึ่งไม่รองรับไฟล์ HEIC โดยตรง ดังนั้น จึงจำเป็นต้องแปลงไฟล์จาก HEIC เป็น JPG แม้ว่าการแปลงไฟล์จาก HEIC เป็น JPG อาจทำให้คุณภาพของรูปภาพลดลงเล็กน้อย แต่อย่างไรก็ตาม งานวิจัยของ Zhao et al. (2023) ได้มีการแปลงไฟล์จาก HEIC เป็น JPG สำหรับการฝึกสอน และการประเมินผล แบบจำลองการจำแนกรูปภาพ โดยไม่ได้รายงานถึงผลกระทบที่สำคัญ ต่อประสิทธิภาพการทำงานของแบบจำลอง

3) รูปภาพที่ได้จากกล้องสมาร์ทโฟน มีขนาดใหญ่ ดังแสดงในภาพที่ 4 เพื่อลดการใช้ทรัพยากรและความรวดเร็วในการประมวลผล ผู้วิจัยจึงปรับขนาดรูปภาพให้มีขนาดเท่ากับ 224x224 พิกเซล

Class 'TumericCrossCut': Image sizes – {(4032, 3024), (3024, 4032)}
 Class 'PhlaiCrossCut': Image sizes – {(4032, 3024), (3024, 4032)}
 Class 'ZedoaryCrossCut': Image sizes – {(4032, 3024), (3024, 4032)}
 Class 'WildTurmericCrossCut': Image sizes – {(4032, 3024), (3024, 4032)}

ภาพที่ 4 ขนาดรูปภาพที่รวบรวมโดยใช้กล้องดิจิทัลสมาร์ทโฟน

4) สร้างข้อมูลใหม่จากข้อมูลที่มีอยู่ เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูลฝึกสอน โดยการสร้างภาพที่มีการเปลี่ยนแปลงเล็กน้อยจากต้นฉบับ ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้ได้ดีขึ้น และลดโอกาสการเกิด Overfitting ด้วยการใช้เทคนิค Data augmentation ตัวอย่างผลลัพธ์เทคนิค Data augmentation ดังแสดงในรูปภาพที่ 5



ภาพที่ 5 ผลลัพธ์การใช้เทคนิค Augmentation

3.2 ดำเนินการทดลองจำแนกข้อมูลรูปภาพสมุนไพร

การศึกษานี้มีวัตถุประสงค์เพื่อเพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก ประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 วิธี ได้แก่ วิธี ResNet-50 วิธี VGG-19 วิธี DenseNet201 และ วิธี InceptionV3 สำหรับการจำแนกรูปภาพเหง้าสมุนไพร ในวงศ์ขิง 4 ชนิด และ เพื่อปรับแต่งพารามิเตอร์ของแบบจำลองให้มีความเหมาะสม และ ประเมินประสิทธิภาพของแบบจำลอง สำหรับใช้เป็นข้อมูลเบื้องต้น ในการนำไปใช้ในกระบวนการจำแนกสมุนไพร หลังจากขั้นตอนการเตรียมชุดข้อมูล

ให้พร้อมสำหรับนำเข้าสู่แบบจำลองการเรียนรู้เชิงลึก และทดสอบประสิทธิภาพการจำแนกรูปภาพแล้ว ผู้วิจัยดำเนินการดังนี้

1) แบ่งข้อมูลออกเป็น 70% สำหรับการฝึกสอน 20% สำหรับ การตรวจสอบ และ 10% สำหรับการทดสอบ

2) หลังจากเตรียมข้อมูลเรียบร้อยแล้วในขั้นตอนนี้จะเป็นการทดลองจำแนกข้อมูล ด้วยวิธีการเรียนรู้เชิงลึก 4 วิธี คือ 1) วิธี ResNet-50 2) วิธี VGG-19 3) วิธี DenseNet201 และ 4) วิธี InceptionV3 ซึ่ง เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ได้รับการออกแบบ เพื่อรองรับงานจำแนกรูปภาพ มีการพัฒนาเพื่อลดข้อจำกัด ที่พบในโครงข่ายเชิงลึกแบบดั้งเดิม เช่น ปัญหาการสูญเสียความชันของกราดีเอนต์ (vanishing gradients) หรือ ความซับซ้อนในการคำนวณที่สูง รายละเอียดโครงสร้างของแบบจำลองสามารถอ่านเพิ่มเติมได้ในงานของ Yao et al. (2022) มีรายละเอียด แบบจำลองที่ทดลองในงานวิจัยมีดังนี้

วิธี VGG-19 มีโครงสร้าง โครงข่ายประสาทเทียมแบบคอนโวลูชัน แบบลึกที่ประกอบด้วย 19 ชั้น โดยใช้ เลเยอร์คอนโวลูชัน ขนาด 3×3 ที่เรียงซ้อนกันหลายชั้น ตามด้วย เลเยอร์รวมข้อมูล และ เลเยอร์ เชื่อมต่อแบบเต็ม โครงสร้างดังกล่าวช่วยให้แบบจำลองสามารถเรียนรู้คุณลักษณะ (features) เชิงลึกที่ซับซ้อน ข้อจำกัดของแบบจำลองนี้ คือ มีจำนวนพารามิเตอร์สูง ส่งผลให้ความซับซ้อนในการคำนวณ สูงตามไปด้วย

วิธี ResNet-50 นำเสนอแนวคิด Residual Learning ซึ่งอาศัย shortcut connections เพื่อลดปัญหาการสูญเสียความชันของกราดีเอนต์ (vanishing gradients) ที่เกิดขึ้นในโครงข่ายที่ลึก โครงสร้าง ของแบบจำลอง ประกอบด้วย 50 ชั้น โดยแบ่งออกเป็น residual blocks ซึ่งช่วยให้การส่งผ่านข้อมูล ทำได้อย่างมีประสิทธิภาพ ส่งผลให้การเรียนรู้คุณลักษณะเป็นไปอย่างราบรื่นแม้ในโครงข่ายที่มีความลึกมาก

วิธี DenseNet201 ใช้แนวคิด Dense Connections โดยให้แต่ละเลเยอร์ เชื่อมโยง กับทุกเลเยอร์ก่อนหน้าโดยตรง ผ่านกลไก feature reuse ซึ่งช่วยลดจำนวนพารามิเตอร์ที่จำเป็นในการเรียนรู้ ส่งผลให้แบบจำลองมีประสิทธิภาพในการใช้ข้อมูลและช่วยลดการสูญเสียข้อมูลระหว่างเลเยอร์ แบบจำลองนี้ ประกอบด้วย 201 ชั้น ซึ่งช่วยปรับปรุงการไหลของข้อมูลในโครงข่ายได้ดียิ่งขึ้น

วิธี InceptionV3 ใช้โครงสร้าง โมดูล Inception (Inception Modules) ซึ่งออกแบบ ให้ใช้ เลเยอร์คอนโวลูชัน หลายขนาดภายในเลเยอร์เดียวกัน เพื่อจับคุณลักษณะจาก receptive fields ที่แตกต่างกัน ทำให้สามารถเรียนรู้ลักษณะเฉพาะของภาพได้อย่างมีประสิทธิภาพ โครงสร้างนี้ ช่วยลดจำนวนพารามิเตอร์ที่ต้องใช้ ขณะเดียวกันยังสามารถรักษาประสิทธิภาพในการประมวลผลภาพได้ดี

3) ใช้วิธี Hyperparameter เพื่อหาค่าที่ดีที่สุดของแต่ละแบบจำลอง กำหนดค่าพารามิเตอร์ ในการทดลอง รายละเอียดดังแสดงในตารางที่ 1

วิธี Hyperparameter ในกระบวนการเรียนรู้เชิงลึก ประกอบด้วยวิธีการที่หลากหลาย เช่น การค้นหาแบบกริด (Grid Search) (Liashchynskiy & Liashchynskiy, 2019) การค้นหาสุ่ม (Random Search) (Andradóttir, 2015) การลดค่าเกรเดียนต์ (Gradient Descent-Based Optimization) (Ruder, 2016) และวิธีการแบบเบย์เซียน (Bayesian Optimization) (Falkner et al., 2018) อย่างไรก็ตาม ในกรณีของแบบจำลองการเรียนรู้เชิงลึกขนาดใหญ่ พื้นที่ของค่าพารามิเตอร์เชิงไฮเปอร์ (hyperparameter space) มักมีขอบเขตที่กว้างและความซับซ้อนสูง ส่งผลให้วิธีการข้างต้น มีข้อจำกัดในด้านประสิทธิภาพและความแม่นยำ

การค้นหาแบบกริด (Liashchynskiy & Liashchynskiy, 2019) เป็นวิธีที่ทำการประเมินค่าพารามิเตอร์ทุกค่า ภายในช่วงที่กำหนด ซึ่งแม้จะสามารถระบุค่าที่เหมาะสมได้อย่างชัดเจน แต่ต้องใช้ทรัพยากรด้านเวลา และการประมวลผลสูง ขณะที่การค้นหาสุ่ม (Andradóttir, 2015) เป็นวิธีที่ช่วยลดจำนวนการทดลองได้ โดยอาศัยการสุ่มค่าพารามิเตอร์จากช่วงที่กำหนด อย่างไรก็ตาม วิธีการดังกล่าว มีข้อจำกัดด้านประสิทธิภาพ ในการประมวลผลแบบขนาน การลดค่าเกรเดียนต์ (Ruder, 2016) อาศัยสมมติฐานว่าฟังก์ชันเป้าหมาย ต้องมีลักษณะเป็นคอนเวกซ์ (convex function) เพื่อให้แน่ใจว่า กระบวนการจะลู่เข้าสู่ค่าที่ดีที่สุด (optimum) ได้สำเร็จ แต่ในทางปฏิบัติ ฟังก์ชันที่เกี่ยวข้องกับการหาค่าพารามิเตอร์ที่เหมาะสม มักมีลักษณะที่ไม่แน่นอน และ ซับซ้อนสูง สำหรับวิธีการแบบเบย์เซียน (Falkner et al., 2018) จำเป็นต้องเลือกใช้แบบจำลองตัวแทน (surrogate model) ที่เหมาะสม ซึ่งอาจไม่สามารถใช้งานได้มีประสิทธิภาพในทุกกรณีของปัญหา

ภายใต้บริบทของงานวิจัยฉบับนี้ การเลือกใช้การค้นหาสุ่ม จึงเป็นแนวทางที่เหมาะสม เนื่องจากสามารถสร้างสมดุลระหว่างความเร็ว ความเรียบง่าย และประสิทธิภาพในการใช้งานจริง เมื่อเปรียบเทียบกับวิธีการค้นหาแบบกริด อีกทั้งยังแสดงประสิทธิภาพที่ดี ในกรณีที่พารามิเตอร์บางตัวมีอิทธิพลต่อผลลัพธ์ของแบบจำลอง มากกว่าพารามิเตอร์ตัวอื่น (hyperparameter sensitivity) นอกจากนี้ การค้นหาสุ่ม มีความยืดหยุ่นในการกำหนดช่วงของค่าพารามิเตอร์ และสามารถดำเนินการทดลองจำนวนมาก ได้ภายในเวลาอันจำกัด ซึ่งช่วยเพิ่มโอกาสในการค้นหาค่าที่เหมาะสม ในสภาพแวดล้อมที่มีข้อจำกัดด้านทรัพยากร (Andradóttir, 2015)

ตารางที่ 1 รายละเอียดการกำหนดค่าพารามิเตอร์ในแบบจำลองการเรียนรู้เชิงลึก

ขั้นตอน	รายละเอียดการตั้งค่า
การตั้งค่าเริ่มต้น	seed_value = 123
Data augmentation	- ข้อมูลฝึกสอน: rotation_range=20, width_shift_range=0.2, height_shift_range=0.2, shear_range=0.2, zoom_range=0.2, horizontal_flip=True, fill_mode='nearest' - ข้อมูลตรวจสอบ และ ข้อมูลทดสอบ: rescale=1/255
โครงสร้างแบบจำลอง (Architecture)	- ชั้น Flatten - Dense (ปรับจำนวนโหนดด้วย hyperparameter tuning, ฟังก์ชันกระตุ้น relu) - ชั้นสุดท้าย Dense + softmax สำหรับการจำแนกหลายคลาส
การปรับแต่ง Hyperparameter	- การค้นหา: dense_units = [128, 256], learning_rate = [1e-2, 1e-3, 1e-4] - จำนวนครั้งการทดสอบ = 5, จำนวนรอบฝึก = 10
การฝึกสอนและประมวลผล	- epochs = 100 และ 200 - ประเมินแบบจำลองด้วย Test Loss และ Test Accuracy - แสดง Confusion Matrix แสดง metrics: accuracy, precision, recall, f1-score

การปรับแต่งพารามิเตอร์ เป็นกระบวนการที่สำคัญในการพัฒนาแบบจำลองการเรียนรู้เชิงลึก เพื่อให้ได้แบบจำลองที่มีประสิทธิภาพสูงสุด งานวิจัยนี้ได้ปรับแต่งพารามิเตอร์หลัก 2 พารามิเตอร์ คือ จำนวนโหนดในชั้น Dense (dense_units) และ อัตราการเรียนรู้ (learning_rate) ผ่านกระบวนการ Hyperparameter Tuning จาก ตารางที่ 1 การกำหนดจำนวนโหนดในชั้น Dense ที่ 128 และ 256 เป็นการเลือกค่าเพื่อทดสอบประสิทธิภาพ โดยค่า 128 เป็นค่ามาตรฐานที่มักใช้กับแบบจำลองที่ไม่ซับซ้อน เหมาะสำหรับชุดข้อมูลขนาดกลางและช่วยป้องกันการเกิด Overfitting ส่วนค่า 256 จะช่วยให้แบบจำลองสามารถจับรายละเอียดของข้อมูลได้มากขึ้น ซึ่งอาจเพิ่มความสามารถในการจำแนกได้ดีขึ้น สำหรับอัตราการเรียนรู้ที่ $1e-2$ $1e-3$ และ $1e-4$ ครอบคลุมช่วงความเร็วในการเรียนรู้จากสูงไปต่ำ เพื่อศึกษาผลกระทบของการปรับน้ำหนักในแต่ละขั้นตอน การใช้ค่าที่แตกต่างกันนี้จะช่วยเลือกอัตราการเรียนรู้ที่เหมาะสมที่สุด และปรับปรุงประสิทธิภาพของโมเดล

4) ทดลองจำแนกข้อมูลด้วยวิธีการเรียนรู้ของเครื่องดั้งเดิม 2 วิธี คือ 1) วิธี Random forest และ 2) วิธี Support vector machine

ผลการวิจัยและอภิปรายผล

งานวิจัยนี้ได้รวบรวมข้อมูลรูปภาพสมุนไพร 4 ชนิด ได้แก่ ขมิ้นชัน ขมิ้นอ้อย ไพล และว่านนางคำ ด้วยกล้องสมาร์ทโฟนในสภาพแวดล้อมที่ควบคุม จำนวน 2,111 รูปภาพและนำเข้าประมวลผลในแบบจำลองการเรียนรู้เชิงลึก 6 วิธี ผลการดำเนินการทดลองดังแสดงในตารางที่ 2 ผลลัพธ์ที่ได้จากแต่ละวิธีมีความแตกต่างกันดังนี้

วิธี ResNet-50 ในการฝึกฝน จำนวนรอบการฝึก 100 รอบ มีค่าความถูกต้อง เท่ากับ 0.81 และ ค่าประสิทธิภาพโดยรวม เท่ากับ 0.81 แสดงให้เห็นว่าแบบจำลองสามารถจำแนกรูปภาพได้ดี มีค่าความสูญเสีย เท่ากับ 0.46 และเมื่อเพิ่มจำนวนรอบการฝึกเป็น 200 รอบ ค่าความถูกต้อง และ ค่าประสิทธิภาพโดยรวม เพิ่มขึ้นเป็น 0.98 และ 0.98 ตามลำดับ ซึ่งแสดงให้เห็นว่า แบบจำลองสามารถปรับปรุงประสิทธิภาพได้ดีขึ้น เมื่อมีการฝึกฝนมากขึ้น

วิธี VGG-19 ในการฝึกฝน จำนวนรอบการฝึก 100 มีค่าความถูกต้อง เท่ากับ 0.99 และ ค่าประสิทธิภาพโดยรวม เท่ากับ 0.99 ซึ่งเป็นค่าที่สูงมาก แสดงว่าแบบจำลอง มีความสามารถในการจำแนกรูปภาพ ได้แม่นยำ และครบถ้วน และเมื่อเพิ่มจำนวนรอบการฝึกเป็น 200 รอบ ค่าความสูญเสีย เพิ่มขึ้นเล็กน้อย มีค่า 0.11 มีค่าความถูกต้อง และ ค่าประสิทธิภาพโดยรวม ยังคงอยู่ในระดับที่สูงที่ 0.98

วิธี DenseNet201 แสดงผลลัพธ์ที่ดีที่สุดในทุกๆ ด้าน ในการฝึกฝน จำนวนรอบการฝึก 100 รอบ มีค่าความถูกต้อง เท่ากับ 0.99 และ ค่าประสิทธิภาพโดยรวม เท่ากับ 0.99 โดยมีค่าความสูญเสียต่ำที่สุด เท่ากับ 0.03 เมื่อเพิ่มจำนวนรอบการฝึกเป็น 200 รอบ ค่าความถูกต้อง และ ค่าประสิทธิภาพโดยรวม เพิ่มขึ้นเป็น 1.00 ซึ่งแสดงให้เห็นถึงประสิทธิภาพในการจำแนกรูปภาพที่สูงที่สุด

วิธี InceptionV3 ในการฝึกฝน จำนวนรอบการฝึก 100 รอบ มีค่าความถูกต้อง เท่ากับ 0.99 และ ค่าประสิทธิภาพโดยรวม เท่ากับ 0.99 ซึ่งแสดงถึงผลลัพธ์ที่ดีมาก เมื่อเพิ่มจำนวนรอบการฝึกเป็น 200 รอบ ค่าความถูกต้อง และ ค่าประสิทธิภาพโดยรวม ลดลงเหลือ 0.95 และ 0.95 ตามลำดับ ซึ่งอาจเป็นผลจากการฝึกฝนมากเกินไปหรือเกิดการ overfitting กับข้อมูลบางประเภท

ในการทดสอบด้วยวิธี Random forest ได้ค่าความถูกต้อง ที่ 0.87 และ ค่าประสิทธิภาพโดยรวมที่ 0.87 ซึ่งแสดงถึงความสามารถ ในการจำแนกรูปภาพในระดับปานกลาง โดยมีความแม่นยำและความครบถ้วนที่ต่ำกว่าโมเดลการเรียนรู้เชิงลึก

วิธี Support vector machine มีค่าความถูกต้อง ที่ 0.92 และ ค่าประสิทธิภาพโดยรวม ที่ 0.92 ซึ่งแสดงให้เห็นว่ามีประสิทธิภาพดีกว่า วิธี Random forest แต่ยังคงต่ำกว่าโมเดลการเรียนรู้เชิงลึก

ตารางที่ 2 ตารางแสดงผลการทดลองจำแนกรูปภาพสมุนไพรร

รายชื่อ แบบจำลอง	รอบการ ฝึกฝน (Epoch)	ค่าความ สูญเสีย (Test loss)	ค่าความถูก ต้อง (Test Accuracy)	ค่าความ แม่นยำ Precision	ค่าความ ครบถ้วน Recall	ค่า ประสิทธิภาพ โดยรวม F-measure
ResNet-50	100	0.46	0.81	0.84	0.81	0.81
	200	0.09	0.98	0.98	0.98	0.98
VGG-19	100	0.06	0.99	0.99	0.99	0.99
	200	0.11	0.98	0.98	0.98	0.98
DenseNet201	100	0.03	0.99	0.99	0.99	0.99
	200	0.01	1.0	1.00	1.00	1.00
InceptionV3	100	0.02	0.99	0.99	0.99	0.99
	200	0.09	0.95	0.96	0.95	0.95
RF			0.87	0.88	0.87	0.87
SVM				0.92	0.92	0.92

จากตารางที่ 2 จากผลการทดลองพบว่า การจำแนกรูปภาพสมุนไพรรโดยใช้แบบจำลองการเรียนรู้เชิงลึก เช่น วิธี VGG-19 วิธี DenseNet201 และ วิธี InceptionV3 แสดงผลลัพธ์ที่มีประสิทธิภาพและความแม่นยำสูงกว่าวิธีการเรียนรู้ของเครื่องดั้งเดิม ได้แก่ วิธี Random forest และ วิธี Support vector machine

สำหรับผลการจำแนกรูปภาพโดยใช้แบบจำลองการเรียนรู้เชิงลึก พบว่าวิธี DenseNet201 ที่มีจำนวนรอบการฝึก 200 รอบ แสดงค่าความถูกต้อง สูงสุดที่ 1.00 พร้อมค่าความแม่นยำ ค่าความครบถ้วน และ ค่าประสิทธิภาพโดยรวม ที่ระดับ 1.0 การที่จำนวนรอบการฝึก 200 รอบมีประสิทธิภาพสูงกว่าการฝึกด้วย 100 รอบ อาจเกิดจาก แบบจำลองมีเวลาเพียงพอ ในการเรียนรู้รูปแบบของข้อมูล ได้ดีขึ้นในรอบการฝึกที่เพิ่มขึ้น ส่งผลให้ประสิทธิภาพของแบบจำลอง อยู่ในระดับสูงขึ้น การที่วิธี DenseNet201 มีผลลัพธ์ที่ดีที่สุด อาจเนื่องมาจากการออกแบบ ที่เน้นการเชื่อมโยงระหว่างเลเยอร์อย่างหนาแน่น (dense connections) ซึ่งช่วยให้แบบจำลอง สามารถเรียนรู้คุณลักษณะที่สำคัญ ได้ดีขึ้นจากข้อมูลรูปภาพ วิธี DenseNet201 ทุกๆ เลเยอร์จะรับข้อมูลจากทุกๆ เลเยอร์ก่อนหน้า ซึ่งทำให้ข้อมูลที่สำคัญ ถูกนำไปใช้ได้อย่างมีประสิทธิภาพ ลดปัญหาการสูญเสียข้อมูล และช่วยให้แบบจำลอง สามารถจับความสัมพันธ์ ระหว่างลักษณะของข้อมูลได้ลึกซึ้งยิ่งขึ้น นอกจากนี้ DenseNet201 ยังมีจำนวนพารามิเตอร์ที่น้อยกว่าบางแบบจำลอง เช่น ResNet-50 ซึ่งทำให้แบบจำลอง สามารถฝึกฝนได้เร็ว และมีความยืดหยุ่นมากกว่า ซึ่งสอดคล้องกับ

ผลการทดลองของ Borkatulla et al. (2023) ที่ได้รายงาน ผลการทดสอบจำแนกข้อมูลรูปภาพสมุนไพรในประเทศบังคลาเทศ วิธี DenseNet201 แสดงผลลัพธ์ที่ดีที่สุด มีค่าความถูกต้องเท่ากับ 0.97 ส่วนวิธี VGG-19 และ วิธี InceptionV3 มีผลลัพธ์ที่ใกล้เคียงกัน โดยมีค่าความถูกต้องเท่ากับ 0.98 ถึง 0.99 เมื่อรอบการฝึกอยู่ที่ 200 รอบ แสดงถึงความเหมาะสมของแบบจำลองทั้ง 3 วิธี ในการจำแนกรูปภาพสมุนไพรในลักษณะนี้ ในขณะที่ วิธี ResNet-50 แสดงความถูกต้องลดลงเล็กน้อย เมื่อเทียบกับวิธี DenseNet201 และ วิธี VGG-19 อย่างไรก็ตาม วิธี ResNet-50 ก็ยังคงแสดงผลลัพธ์ที่สูงถึง 0.98 เมื่อรอบการฝึกอยู่ที่ 200 รอบ

ผลการจำแนกโดยใช้วิธีการเรียนรู้ของเครื่องดั้งเดิม วิธี Random forest และวิธี Support vector machine มีค่าความถูกต้องที่ต่ำกว่าแบบจำลองการเรียนรู้เชิงลึก โดย วิธี Random forest มีค่าความถูกต้องเท่ากับ 0.87 และ Support vector machine มีค่าความแม่นยำ ค่าความครบถ้วน และค่าประสิทธิภาพโดยรวม ประมาณ 0.92 แม้ว่าผลลัพธ์เหล่านี้จะมีความน่าพอใจ แต่ประสิทธิภาพยังคงต่ำกว่าแบบจำลองการเรียนรู้เชิงลึก ซึ่งชี้ให้เห็นว่าการใช้แบบจำลองเชิงลึกอาจเป็นวิธีที่เหมาะสมกว่าในการจำแนกรูปภาพที่มีความซับซ้อน

สรุป

งานวิจัยนี้มีวัตถุประสงค์เพื่อ เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 วิธี ได้แก่ วิธี ResNet-50 วิธี VGG-19 วิธี DenseNet201 และ วิธี InceptionV3 สำหรับการจำแนกรูปภาพเหง้าสมุนไพร ในวงศ์ขิง 4 ชนิด ได้แก่ ขมิ้นชัน ขมิ้นอ้อย โพลและว่านนางคำ และ เพื่อปรับแต่งพารามิเตอร์ของแบบจำลองให้มีความเหมาะสม และ ประเมินประสิทธิภาพของแบบจำลอง สำหรับใช้เป็นข้อมูลเบื้องต้น ในการนำไปใช้ในกระบวนการจำแนกสมุนไพร จุดเด่นในงานวิจัยนี้คือการได้รวบรวมข้อมูลรูปภาพสมุนไพรประเภทเหง้า ที่มีลักษณะคล้ายคลึงกันมาก ทั้ง 4 ชนิด ด้วยกล้องสมาร์ทโฟน เผยแพร่สาธารณะสำหรับนักวิจัยในการนำไปใช้ในงานวิจัยด้านการประมวลผลภาพให้มีประสิทธิภาพมากขึ้น ผู้วิจัยทดลองจำแนกรูปภาพสมุนไพร ด้วยแบบจำลองการเรียนรู้เชิงลึก 4 วิธี คือ 1) ResNet-50 2) VGG-19 3) DenseNet201 และ 4) InceptionV3 และใช้วิธี Hyperparameter เพื่อหาค่าที่ดีที่สุดของแต่ละแบบจำลอง ผลการทดลองแสดงให้เห็นว่า วิธี DenseNet201 ที่มีจำนวนรอบการฝึก 200 รอบ มีความแม่นยำสูงสุดถึงเมื่อเปรียบเทียบกับแบบจำลองอื่น ๆ ที่ได้ทำการทดลอง มีความสูญเสียเท่ากับ 0.01 แสดงให้เห็นถึงศักยภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ในการจำแนกรูปภาพพืชสมุนไพรได้อย่างแม่นยำ เป็นแนวทางในการประยุกต์ใช้ในอุตสาหกรรมที่เกี่ยวข้อง เช่น การแพทย์แผนไทย อุตสาหกรรมยา อาหารเสริม และเวชสำอาง เพื่อช่วยให้กระบวนการคัดแยกวัตถุดิบสมุนไพรให้มีความแม่นยำและได้มาตรฐานมากยิ่งขึ้น ซึ่งโดยทั่วแล้ว การตรวจสอบคัดแยกพืชสมุนไพร มักดำเนินการภายใต้สภาวะแสงที่เพียงพอ เพื่อให้สามารถประเมินลักษณะ และ คุณสมบัติต่าง ๆ ของพืชสมุนไพรได้อย่างถูกต้องและแม่นยำ ในงานวิจัยนี้ ดำเนินการถ่ายภาพพืชสมุนไพร ภายใต้สภาวะแสงที่ควบคุมได้ในห้องปฏิบัติการ เพื่อลดความแปรปรวน และ เพิ่มความถูกต้องในการประเมินผล อย่างไรก็ตาม เพื่อให้การประเมินประสิทธิภาพของแบบจำลอง มีความครอบคลุมและสอดคล้อง กับการใช้งานในสถานการณ์จริง การศึกษาต่อไป ควรพิจารณาทดสอบแบบจำลอง ภายใต้สภาวะแวดล้อมที่หลากหลายมากขึ้น เช่น การถ่ายภาพในที่แสงน้อย หรือ จากมุมมองที่แตกต่างกัน การทดสอบดังกล่าว จะช่วยให้มั่นใจว่าแบบจำลองสามารถจำแนกรูปภาพ ได้อย่างถูกต้องในสภาวะที่ใกล้เคียงกับการใช้งานจริง

ข้อเสนอแนะ

งานวิจัยในอนาคต ผู้วิจัยมีแนวคิดในการจำแนกรูปภาพสมุนไพร ที่ไม่ควบคุมคุณภาพของรูปภาพ การควบคุมแสง และพื้นหลังของวัตถุ หรือรูปภาพที่ต้องการระบุหรือจำแนกมีสิ่งบดบัง และเพิ่มจำนวนชนิดพืชสมุนไพรที่นำมาใช้ในการทดลอง

เอกสารอ้างอิง

- Aakif, A., & Khan, M. F. (2015). Automatic classification of plants based on their leaves. **Biosystems Engineering**, 139, 66-75.
- Alshammari, K., Alshammari, R., Alshammari, A., & Alkhudaydi, T. (2024). An improved pear disease classification approach using cycle generative adversarial network. **Scientific Reports**, 14(1), 6680.
- Andradóttir, S. (2015). A Review of Random Search Methods. In M. C. Fu (Ed.). **Handbook of Simulation Optimization** (pp. 277-292). Springer New York.
- Angkoso, C. V., Kusumaningsih, A., & Tjahyaningtijas. (2023). **Automatic Recognition of Madurese Herbal Medicine Rhizome Images Using the Efficientnet Convolutional Neural Network**. 2023 International Conference on Information Technology and Computing (ICITCOM) (pp. 313-317), 1-2 December 2023 at Yogyakarta, Indonesia.
- Borkatulla, B., Ferdous, J., Uddin, A. H., & Mahmud, P. (2023). Bangladeshi medicinal plant dataset. **Data in Brief**, 48, 109211.
- Cap, Q. H., Uga, H., Kagiwada, S., & Iyatomi, H. (2022). LeafGAN: An Effective Data Augmentation Method for Practical Plant Disease Diagnosis. **IEEE Transactions on Automation Science and Engineering**, 19(2), 1258-1267.
- Chen, Y., Li, Y., & Zhang, S. (2023). Research on image recognition of three *Fritillaria cirrhosa* species based on deep learning. **Scientific Reports**, 13(1), 19486.
- Espinoza, S., Aguilera, C., Rojas, L., & Campos, P. G. (2024). Analysis of Fruit Images With Deep Learning: A Systematic Literature Review and Future Directions. **IEEE Access**, 12, 3837-3859.
- Falkner, S., Klein, A., & Hutter, F. (2018). **BOHB: Robust and Efficient Hyperparameter Optimization at Scale**. Proceedings of the 35th International Conference on Machine Learning, Proceedings of Machine Learning Research.
- slam, M. T., Rahman, W., Hossain, M. S., Roksana, K., Domínguez Azpíroz, I., Martínez Diaz, R., Ashraf, I., & Samad, M. A. (2024). Medicinal Plant Classification Using Particle Swarm Optimized Cascaded Network. **IEEE Access**, 12, 42465-42478.
- Islam, S., Ahmed, M. R., Islam, S., Rishad, M. M. A., Ahmed, S., Utshow, T. R., & Siam, M. I. (2023). BDMediLeaves: A leaf images dataset for Bangladeshi medicinal plants identification. **Data in Brief**, 50, 109488.

- Ji, H., Liu, X., Wang, L., Fan, L., & Liu, S. (2024). **Image Recognition of Chinese Herbal Medicine Using Adaptive Gamma Correction Based on Convolutional Neural Network**. 2024 IEEE 13th Data Driven Control and Learning Systems Conference (DDCLS) (pp.1428-1433), 17-19 May 2024 at Kaifeng, China.
- Kaur, R., Jain, M., McAdams, R. M., Sun, Y., Gupta, S., Mutharaju, R., & Singh, H. (2023). An Ontology and Rule-Based Clinical Decision Support System for Personalized Nutrition Recommendations in the Neonatal Intensive Care Unit. **IEEE Access**, 11, 142433-142446.
- Liashchynskyi, P., & Liashchynskyi, P. (2019). Grid search, random search, genetic algorithm: a big comparison for NAS. **arXiv preprint arXiv:1912.06059**.
- Liu, B., Tan, C., Li, S., He, J., & Wang, H. (2020). A Data Augmentation Method Based on Generative Adversarial Networks for Grape Leaf Disease Identification. **IEEE Access**, 8, 102188-102198.
- Liu, Y., Roy, S. S., Nebie, R. H. C., Zhang, Y., & Nair, M. G. (2013). Functional Food Quality of *Curcuma caesia*, *Curcuma zedoaria* and *Curcuma aeruginosa* Endemic to Northeastern India. **Plant Foods for Human Nutrition**, 68(1), 72-77.
- Mookdarsanit, L., & Mookdarsanit, P. (2022). Thai Herb Identification with Medicinal Properties Using Convolutional Neural Network. **Suan Sunandha Science and Technology Journal**, 6(2), 34-40.
- Pacal, I., Kunduracioglu, I., Alma, M. H., Deveci, M., Kadry, S., Nedoma, J., Slany, V., & Martinek, R. (2024). A systematic review of deep learning techniques for plant diseases. **Artificial Intelligence Review**, 57(11), 304.
- Panmuang, M., & Rodmorn, C. (2023). Herb Leaf Image Classification with Deep Convolutional Neural Networks. **Science and Technology Nakhon Sawan Rajabhat University Journal**, 15(22), 51-65.
- Promkot, A. n. (2024). Efficiency of plant diseases classification by convolutional neural network with optimization algorithm and activation function. **J ournal of Information Science and Technology**, 14(1), 34-44.
- Ragab, M., Katib, I., Sharaf, S. A., Assiri, F. Y., Hamed, D., & Al-Ghamdi, A. A. M. (2023). Self-Upgraded Cat Mouse Optimizer With Machine Learning Driven Lung Cancer Classification on Computed Tomography Imaging. **IEEE Access**, 11, 107972-107981.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. **arXiv preprint arXiv:1609.04747**.
- Sarma, P., Boruah, P. A., & Buragohain, R. (2023). MED 117: A dataset of medicinal plants mostly found in Assam with their leaf images, segmented leaf frames and name table. **Data in Brief**, 47, 108983.

- Sellami, M., Slimeni, O., Pokrywka, A., Kuvačić, G., D Hayes, L., Milic, M., & Padulo, J. (2018). Herbal medicine for sports: a review. **Journal of the International Society of Sports Nutrition**, 15(1), 14.
- Sharma, V., Chaurasia, K., & Bansal, A. (2024). **Optimizing Species Recognition in Medicinal Plants: A Comprehensive Evaluation of Deep Learning Models**. 2024 14th International Conference on Cloud Computing, Data Science & Engineering (Confluence) (pp. 738-743), 18-19 January 2024 at Noida, India.
- Sharrab, Y., Al-Fraihat, D., Tarawneh, M., & Sharieh, A. (2023). **Medicinal Plants Recognition Using Deep Learning**. 2023 International Conference on Multimedia Computing, Networking and Applications (MCNA) (pp. 116-122), 19-22 June 2023 at Valencia, Spain.
- Smith, S. P., Adam, M. T. P., Manning, G., Burrows, T., Collins, C., & Rollo, M. E. (2022). Food Volume Estimation by Integrating 3 D Image Projection and Manual Wire Mesh Transformations. **IEEE Access**, 10, 48367-48378.
- Soumya, T., Jayasree, P. R., & Manish Kumar, P. R. (2023). Zingiberaceae Plants: A Cornucopia of Promising Chemotherapeutics for Cancer Cure. In K. Arunachalam, X. Yang, & S. Puthanpura Sasidharan (Eds.). **Bioprospecting of Tropical Medicinal Plants** (pp. 427-462). Springer Nature Switzerland.
- Tan, J. W., Lim, K. M., & Lee, C. P. (2021). **Herb Classification with Convolutional Neural Network**. 2021 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET) (pp. 1-4), 13-15 September. 2021 at Kota Kinabalu, Malaysia.
- Tian, D., Zhou, C., Wang, Y., Zhang, R., & Yao, Y. (2024). NB-TCM-CHM: Image dataset of the Chinese herbal medicine fruits and its application in classification through deep learning. **Data in Brief**, 54, 110405.
- Wang, H., Tan, X., Huang, Z., Pan, B., & Tian, J. (2020). Mining incomplete clinical data for the early assessment of Kawasaki disease based on feature clustering and convolutional neural networks. **Artificial Intelligence in Medicine**, 105, 101859.
- Wang, W., Tian, W., Liao, W., Cai, B., & Li, B. (2021). **Identifying Chinese Herbal Medicine by Image with Three Deep CNNs**. Proceedings of the 5th International Conference on Control Engineering and Artificial Intelligence (pp. 1-8), 14 - 16 January 2021 at Sanya, China.
- Yao, X., Wang, X., Wang, S.-H., & Zhang, Y.-D. (2022). A comprehensive survey on convolutional neural network in medical image analysis. **Multimedia Tools and Applications**, 81(29), 41361-41405.
- Zhao, J., Almodfer, R., Wu, X., & Wang, X. (2023). A dataset of pomegranate growth stages for machine learning-based monitoring and analysis. **Data in Brief**, 50, 109468.

- Zhao, Y., Chen, Z., Gao, X., Song, W., Xiong, Q., Hu, J., & Zhang, Z. (2022). Plant Disease Detection Using Generated Leaves Based on DoubleGAN. **IEEE/ACM Transactions on Computational Biology and Bioinformatics**, 19(3), 1817-1826.
- Zhong, Y., Zhang, S., Liu, Z., Zhang, X., Mo, Z., Zhang, Y., Hu, H., Chen, W., & Qi, L. (2024). Unsupervised Fusion of Misaligned PAT and MRI Images via Mutually Reinforcing Cross-Modality Image Generation and Registration. **IEEE Transactions on Medical Imaging**, 43(5), 1702-1714.
- Zhu, H., Liu, Q., Qi, Y., Huang, X., Jiang, F., & Zhang, S. (2018). Plant identification based on very deep convolutional neural networks. **Multimedia Tools and Applications**, 77(22), 29779-29797.