

การจำแนกภาพใบสมุนไพรด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก Herb Leaf Image Classification with Deep Convolutional Neural Networks

มธุรส ผ่านเมือง¹, ชนนิกานต์ รอดมรณ^{2*}

Mathuros Panmuang¹, Chonnikarn Rodmorn^{2*}

¹ภาควิชาเทคโนโลยีและสื่อสารการศึกษา คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

¹Department of Educational Technology and Communications, Faculty of Technical Education,
Rajamangala University of Technology Thanyaburi

²ภาควิชาสถิติประยุกต์ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

²Department of Applied Statistics, Faculty of Applied Science,
King Mongkut's University of Technology North Bangkok

บทคัดย่อ

ปัจจุบันสมุนไพรถูกนำมาใช้บรรเทารักษาอาการเจ็บป่วยแทนยาแผนปัจจุบันมากขึ้น เพราะสมุนไพรเป็นผลิตภัณฑ์ที่ได้จากธรรมชาติและก่อให้เกิดผลข้างเคียงน้อย แต่สมุนไพรบางชนิดอาจส่งผลกระทบต่อสุขภาพหากเลือกใช้ผิดชนิดเนื่องจากมีความคล้ายคลึงกัน ประกอบกับฐานข้อมูลรูปภาพของสมุนไพรจำนวนมากยังไม่มีมีการจำแนกชนิดที่ชัดเจนหรือเป็นข้อมูลที่ไม่ถูกต้อง ดังนั้นในการวิจัยครั้งนี้จึงได้ประยุกต์ใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ที่ได้ทำการปรับแต่ง และเลือกใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ในการจำแนกใบสมุนไพร ประกอบด้วย ใบฝรั่ง ใบสบู่ดำ/สบู่ขาว ใบมะนาว และใบทับทิม ซึ่งเป็นใบสมุนไพรที่มีพิษและไม่มีพิษ โดยเปรียบเทียบอัลกอริทึมในการเพิ่มประสิทธิภาพของโมเดล ประกอบด้วย AdaDelta, AdaGrad, Adam, RMSprop และ SGD พร้อมทั้งเปรียบเทียบการใช้ฟังก์ชันกระตุ้น (Activation Function) ได้แก่ ReLU, Sigmoid และTanh นอกจากนั้นยังได้ทำการปรับภาพด้วยการกลับภาพ (Flip) และการปรับความสว่างของภาพ (Brightness) เพื่อเพิ่มจำนวนภาพ ผลการทดลองพบว่า ก่อนและหลังการปรับภาพ Optimizer AdaDelta โดยใช้ฟังก์ชันกระตุ้น Tanh ให้ค่าความถูกต้อง (Accuracy) สูงสุดคือ 0.937 และ 0.954 ค่าความแม่นยำ (Precision) 0.937 และ 0.955 และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง (Recall) 0.937 และ 0.954 ดังนั้นจึงสรุปได้ว่าโมเดลที่ได้จากการวิจัยครั้งนี้สามารถนำไปประยุกต์ใช้ในการพัฒนาเว็บไซต์หรือโมบายแอปพลิเคชันเพื่อจำแนกใบสมุนไพรได้อย่างมีประสิทธิภาพ โดยจำแนกได้ถูกต้องร้อยละ 95.40

คำสำคัญ: สมุนไพร การประมวลผลภาพ การเรียนรู้เชิงลึก โครงข่ายประสาทเทียม

* Corresponding author : chonnikarn.r@sci.kmutnb.ac.th

Abstract

Herbs are now more frequently used to treat illnesses than modern medicine. As a result, in this study, herbal leaves such as guava, jatropha, lemon, and pomegranate leaves were classified using deep learning methods using a convolutional neural network, which are poisonous and non-poisonous leaves. By contrasting the activation functions of ReLU, Sigmoid, and Tanh, as well as the algorithms used to optimize the models AdaDelta, AdaGrad, Adam, RMSprop, and SGD. In order to expand the number of photos, it has also modified the image by flipping and altering the brightness. The experimental findings demonstrated that the AdaDelta optimizer utilizing the Tanh activation function provided the highest accuracy values, precision values, and recall rates, respectively, before and after image improvement, at 0.937 and 0.954, 0.937 and 0.955. Consequently, it can be stated that the model developed via this research can be used to effectively categorize herb leaves in websites or mobile applications. The classification was accurate 95.40%.

Keywords: Herb, Image Processing, Deep Learning, Neural Networks

1. บทนำ

ปัจจุบันประเทศไทยมีสมุนไพรหลากหลายชนิด บางชนิดนำมาใช้บรรเทารักษาอาการเจ็บป่วยแทนยาแผนปัจจุบัน บางชนิดรับประทานเพื่อบำรุงร่างกายให้แข็งแรง จึงทำให้สมุนไพรได้รับความสนใจและถูกนำมาใช้เพิ่มมากขึ้น เนื่องจากสมุนไพรเป็นผลิตภัณฑ์ที่ได้จากธรรมชาติและก่อให้เกิดผลข้างเคียงน้อยหรือไม่มีเลย จากที่สมุนไพรมีหลากหลายชนิดบางชนิดมีลักษณะที่คล้ายคลึงกันมาก จึงก่อให้เกิดปัญหาคือ ผู้ใช้สมุนไพรเกิดความสับสนและไม่สามารถจำแนกสมุนไพรบางชนิดออกจากกันได้ ซึ่งอาจก่อให้เกิดอันตรายต่อสุขภาพของร่างกายเมื่อใช้สมุนไพรผิดชนิดและไม่ตรงกับความต้องการหรืออาการของโรคที่มีอยู่ นอกจากนี้ปัญหาก็เกี่ยวกับข้อมูลรูปภาพของสมุนไพรในปัจจุบันที่มีอยู่เป็นจำนวนมาก ซึ่งบางข้อมูลอาจยังไม่มีมีการจำแนกชนิดที่ชัดเจนหรืออาจเป็นข้อมูลที่ผิดๆ จึงยากต่อการจำแนกด้วยตาเปล่า (กฤตชัย บุญคิวนนท์ และ รักษ์วริน วรรณศิลป์, 2558) โดยเฉพาะพืชสมุนไพรที่บางชนิดอาจจะมีพิษต่อร่างกาย เช่น มันท้าปลาหลัง หนุ่ยคา หนุ่ยไ้ใบ ขวนชม โป๊ยเซียน มะม่วงหิมพานต์ เผือก เป็นต้น และจากการจัดลำดับของศูนย์พิษวิทยารามาธิบดี (ศูนย์พิษวิทยารามาธิบดี, 2564) พบว่า มีพืชพิษที่คนไทยป่วยบ่อย 10 ชนิด ได้แก่ 1) สนุ่ดำ/สนุ่ขาว ร้อยละ 54.10 2) กลอย ร้อยละ 8.70 3) มันท้าปลาหลัง ร้อยละ 5.90 4) ลำโพงหรือมะเขือบ้า ร้อยละ 4.20 5) โพธิ์ศรี/โพธิ์ทะเล/โพธิ์ฝรั่ง ร้อยละ 4.10 6) ฟินตัน ร้อยละ 2.80 7) มะกล่ำตาหนู ร้อยละ 2.50 8) บอน ร้อยละ 2.10 9) ละหุ่ง ร้อยละ 1.40 และ 10) สาวน้อยประแป้ง ร้อยละ 1.20 นอกจากนี้ ยังมีพืชอื่น ๆ ที่ประชาชนได้รับพิษและปรึกษาเข้ามาที่ศูนย์ฯ อีก 89 ชนิด ซึ่งการแยกผู้ป่วยถูกพิษจากพืชชนิดใดนั้นเป็นเรื่องยาก เพราะบางครั้งผู้ป่วยไม่รู้หรือรู้ชื่อแต่ก็เป็นภาษาถิ่นทำให้ไม่ทราบพืชที่แท้จริง เป็นต้น

จากปัญหาดังกล่าว หากมีแนวทางที่สามารถจำแนกพืชสมุนไพรไทยได้อย่างถูกต้อง ทั้งที่มีพิษและไม่มีพิษ จะทำให้สามารถใช้ประโยชน์จากสมุนไพรไทยได้อย่างเหมาะสมหรือตรงตามสรรพคุณ และยังเป็นการใช้ประโยชน์ของสมุนไพรเพื่อสุขภาพสร้างความเข้มแข็งชุมชน ที่ใช้ต้นทุนทางทรัพยากรธรรมชาติและสิ่งแวดล้อมที่มีอยู่ อีกทั้งยังเป็นการสนับสนุนให้เกิดการใช้สมุนไพรไทยมากขึ้น เพื่อเป็นทางเลือกหนึ่งในการดูแลสุขภาพ (นเรศร์ บุญเลิศ, 2561) ดังนั้นในการวิจัยครั้งนี้ จึงได้ประยุกต์ใช้เทคนิคการประมวลผลภาพ (Image Processing) เพื่อจำแนกใบสมุนไพรด้วยการเรียนรู้ของเครื่อง (Machine Learning) ทั้งนี้เพื่อสอนให้เครื่องได้เกิดการเรียนรู้และจดจำคุณลักษณะของใบสมุนไพร ที่อาศัยศาสตร์ทางด้านสถิติ วิทยาการข้อมูล และปัญญาประดิษฐ์ หรือ AI (Artificial Intelligence) เข้ามาช่วย (Jordan & Mitchell, 2015)

ดังนั้น การวิจัยครั้งนี้ได้นำตัวอย่างใบสมุนไพรที่มีพิษและไม่มีพิษ จำนวน 4 ชนิด ได้แก่ ใบฝรั่ง ใบสบู่ดำ/สบู่ขาว ใบมะนาว และใบทับทิม โดยนำภาพมาจากเว็บไซต์ Mendeley Data (<https://data.mendeley.com/datasets/nnytj2v3n5>) (Roopashree & Anitha, 2020) ซึ่งภาพสมุนไพรทั้งหมดจะถูกนำมาเป็นตัวอย่างในการทดลองด้วยโครงข่ายประสาทแบบคอนโวลูชันพร้อมทั้งเปรียบเทียบอัลกอริทึมในการเพิ่มประสิทธิภาพของโมเดล ประกอบด้วย AdaDelta, AdaGrad, Adam, RMSprop และ SGD และเปรียบเทียบการใช้ฟังก์ชันกระตุ้นได้แก่ ReLU, Sigmoid และ Tanh ทั้งนี้เพื่อพัฒนาโมเดลให้เกิดการเรียนรู้ที่แม่นยำ และสามารถทำนายภาพใบสมุนไพรได้อย่างถูกต้อง ดังนั้นโมเดลที่ได้จากการวิจัยครั้งนี้จะสามารถนำไปพัฒนาเป็นเว็บไซต์หรือโมบายแอปพลิเคชันในการจำแนกพืชสมุนไพรได้อย่างสะดวก รวดเร็วและมีประสิทธิภาพ เนื่องจากระบบสามารถทำนายได้ว่ารูปภาพสมุนไพรนั้นเป็นประเภทใด และสามารถแยกได้ว่าสมุนไพรใดมีพิษหรือไม่มีพิษ

2. วัตถุประสงค์การวิจัย

- 1) เพื่อจำแนกภาพใบสมุนไพรด้วยโครงข่ายประสาทแบบคอนโวลูชันเชิงลึก
- 2) เพื่อเปรียบเทียบอัลกอริทึมในการเพิ่มประสิทธิภาพของโมเดล และฟังก์ชันกระตุ้น

3. งานวิจัยที่เกี่ยวข้อง

ปัจจุบันมีงานวิจัยเกี่ยวกับการเรียนรู้ของเครื่องอยู่เป็นจำนวนมาก เช่น งานวิจัยของ Panmuang et al. (2021) ที่ได้ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกในการจำแนกประเภทพันธุ์เมล็ดข้าว โดยเลือกใช้โมเดล VGG16 จำแนกพันธุ์ข้าว จำนวน 5 ชนิด ประกอบด้วย กข23, สุพรรณบุรี1, ปทุมธานี1, ชัยนาท1 และหอมมะลิ105 ผลการทดลองพบว่า สามารถจำแนกพันธุ์ข้าวได้อย่างถูกต้องร้อยละ 85.00 ในขณะที่การวิจัยของ Schwartz et al. (2019) ที่ได้นำเสนอโมเดลประสาทเชิงลึกเพื่อประมวลผลภาพ ซึ่งโมเดลสามารถเรียนรู้ในการจำแนกรายละเอียดของภาพไม่ว่าภาพจะมีแสงมากน้อยเพียงใด นอกจากนั้นงานวิจัยของ ภูมิินทร์ ตันอุตม์ และณัฐกร ขำสุวรรณ (2562) ยังได้ใช้วิธีการประมวลผลภาพในการพัฒนาเครื่องต้นแบบคัดแยกดอกดาวเรือง โดยทดสอบจากดอกดาวเรือง 100 ดอก พบว่ามีความถูกต้องที่ร้อยละ 97.20

อย่างไรก็ตาม สำหรับงานวิจัยที่ประยุกต์ใช้เทคนิคการประมวลผลภาพในการทดลองกับพืชหรือสมุนไพร พบว่า เทคนิคการประมวลผลภาพสามารถนำมาประยุกต์ใช้ได้อย่างมีประสิทธิภาพ ดังเช่นการวิจัยของ อุมารณ สายแสงจันทร์ และคณะ (2565) ที่ได้เปรียบเทียบวิธีการวิเคราะห์โรคใบมะนาวด้วยการเรียนรู้เชิงลึก โดยเลือกใช้สถาปัตยกรรม LeNet-5 VGG16 ResNet-50 และสถาปัตยกรรมที่นำเสนอบนพื้นฐานของ VGG16 ผลการวิจัยพบว่าประสิทธิภาพการวิเคราะห์ด้วย LeNet-5 มีความถูกต้องร้อยละ 78.90 ซึ่งมีประสิทธิภาพต่ำสุด ในขณะที่สถาปัตยกรรมที่นำเสนอมีความถูกต้องร้อยละ 89.06 ซึ่งมีค่าสูงสุด แต่ไม่แตกต่างกับ ResNet-50 มากนัก และงานวิจัยของ Sun et al. (2022) ที่ได้ประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการพัฒนาโมบายแอปพลิเคชัน เพื่อเพิ่มประสิทธิภาพในการจดจำสมุนไพร โดยใช้สถาปัตยกรรม ResNet-50 และ MobileNet-V2 ผลการวิจัยพบว่า small ResNeXt-101 + transfer มีค่าความถูกต้องสูงสุดคือร้อยละ 94.50

4. วิธีดำเนินการวิจัย

การเตรียมข้อมูล

ข้อมูลรูปภาพที่ถูกนำมาใช้ในการวิจัยครั้งนี้ เป็นรูปภาพที่ถูกเก็บรวบรวมข้อมูลไว้แล้วจากเว็บไซต์ ซึ่งชุดข้อมูลนี้มีวัตถุประสงค์ในการจัดเก็บเพื่อนำมาใช้ในการประมวลผลภาพ เนื่องจากพืชสมุนไพรหลายชนิด เริ่มสูญพันธุ์ การเก็บข้อมูลภาพสมุนไพรในรูปแบบดิจิทัลจึงมีความสำคัญต่อการอนุรักษ์และการนำไปใช้ประโยชน์ในด้านต่าง ๆ โดยชุดข้อมูลนี้มีภาพสมุนไพรกว่า 30 ชนิด จำนวน 1,500 ภาพ ถ่ายภาพด้วยกล้องโทรศัพท์มือถือ (Samsung s9+) จากมุมต่าง ๆ ของใบสมุนไพร ในการวิจัยครั้งนี้ผู้วิจัยเลือกมาเพียง 4 ชนิด ได้แก่ ใบฝรั่ง ใบสบู่ดำ/สบู่ขาว ใบมะนาว และใบทับทิม เนื่องจากเป็นสมุนไพรที่มีอยู่ในประเทศไทย จำนวน 720 ภาพ แบ่งออกเป็น 2 ชุดข้อมูล ได้แก่ ชุดข้อมูลฝึกสอน จำนวน 576 ภาพ และชุดข้อมูลทดสอบ จำนวน 144 ภาพ หรือคิดเป็นร้อยละ 80:20 และได้ใช้เทคนิคการขยายข้อมูล (Data Augmentation) เพื่อเพิ่มประสิทธิภาพความแม่นยำของโมเดล ประกอบด้วย การกลับภาพในแนวแกนตั้ง และการปรับความสว่างของภาพ (Brightness) จึงทำให้ได้จำนวนภาพที่ใช้สำหรับการเรียนรู้เพิ่มขึ้นรวมเป็น จำนวน 1,728 ภาพ โดย 576 ภาพมาจากภาพต้นฉบับ และอีก 1,152 ภาพ มาจากการกลับภาพ และการปรับความสว่าง หลังจากนั้นนำภาพทั้งหมดมาปรับขนาดให้เท่ากัน คือ 128x128 พิกเซล ในรูปแบบสี RGB ดังนั้นจะทำให้มี Filter จำนวน 3 ชั้น พร้อมทั้งกำหนดค่าในการจัดเก็บภาพให้อยู่ในรูปแบบของ array ที่มีค่าไม่เกิน 1 ทั้งนี้เพื่อเตรียมข้อมูลเข้าสู่ขั้นตอนการประมวลผลในลำดับต่อไป ดังแสดงตัวอย่างของข้อมูลนำเข้าได้ดังภาพที่ 1



(ก) ใบฝรั่ง



(ข) ใบสบู่ดำ/สบู่ขาว



(ค) ใบมะนาว



(ง) ใบทับทิม

ภาพที่ 1 ตัวอย่างภาพใบสมุนไพร

สำหรับการเลือกการขยายข้อมูลด้วยวิธีการกลับภาพ และปรับความสว่างของภาพ ผู้วิจัยได้กำหนดค่าพารามิเตอร์ของการกลับภาพในแนวนอน และปรับความสว่างของภาพตามระบบสี HSV ประกอบด้วย ค่าเฉดสี (Hue) ค่าความอิ่มตัว (Saturation) และค่าความสว่าง (Value) โดยกำหนดค่าความสว่างเท่ากับ 50 (โดยปกติจะมีค่าอยู่ระหว่าง 0-255) ซึ่งสามารถแสดงตัวอย่างดังภาพที่ 2



(ก) การกลับภาพ



(ข) การปรับความสว่างของภาพ

ภาพที่ 2 ตัวอย่างการกลับภาพและการปรับความสว่างของภาพ

การสร้างโมเดล

ในการวิจัยครั้งนี้ได้เลือกใช้ CNN ซึ่งผู้วิจัยได้ทำการปรับแต่งโมเดลบนพื้นฐานของ VGG16 โดยปรับปรุง Hyperparameter ซึ่งได้แก่ ขนาดของ Filter ที่ลดลง เช่น VGG16 มีขนาดของ Filter ของแต่ละชั้นคือ 64, 128, 256, 512 แต่ในการวิจัยครั้งนี้คือ 32, 64, 128 และ 256 และได้ลดจำนวนชั้น Convolution ทำให้สามารถลดขนาดของจำนวนพารามิเตอร์และเวลาลงได้ ดังภาพที่ 3

Input 128x128
Kernel 3x3, Conv2D 32 MaxPooling 2x2
Kernel 3x3, Conv2D 64 MaxPooling 2x2
Kernel 3x3, Conv2D 128 MaxPooling 2x2
Kernel 3x3, Conv2D 256 MaxPooling 2x2
FC 1024 Dropout 0.25 FC classes
Output

ภาพที่ 3 สถาปัตยกรรมที่ทำการปรับแต่งโมเดล

1) โครงสร้างของ CNN จะเหมือนกับโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แต่จะเพิ่มการคำนวณที่มีลักษณะแบบคอนโวลูชันเข้าไปในโครงข่าย ซึ่งจะทำให้มีชั้นพูลลิง (Pooling Layer) ที่ทำหน้าที่ค้นกลางระหว่างชั้นคอนโวลูชัน โดยมีไว้เพื่อลดขนาด (Downsample) ของ Feature Map ให้เล็กลง และชั้นเชื่อมโยงแบบสมบูรณ์ (Fully-Connected Layer) หรือเรียกว่าชั้นซ่อน มีหน้าที่ในการจำแนกประเภทของวัตถุ ซึ่งทุกนิวรอนที่อยู่ในชั้นนี้จะถูกเชื่อมโยงกับชั้นคอนโวลูชัน และชั้นพูลลิงอย่างสมบูรณ์ ทั้งนี้ CNN สามารถทำได้ทั้งการสกัดคุณลักษณะพิเศษของรูปภาพ และการจำแนกประเภท (จักรินทร์ สนุกแสน และ โอพาริก สุรินตะ, 2561) โดยมีสมการที่เกี่ยวข้องดังนี้

การคำนวณชั้นคอนโวลูชัน พื้นที่ส่วนย่อยจะถูกนำมาคำนวณแบบ dot product กับเคอร์เนล (Kernel) ที่มีขนาด $H \times H \times K$ โดยเคอร์เนลต้องมีขนาดเล็กกว่าขนาดของรูปภาพ และ K คือจำนวนของเคอร์เนลที่ต้องการคำนวณ ผลลัพธ์ที่ได้จากขั้นนี้เรียกว่า Feature Map ซึ่งคำนวณได้ดังนี้

$$U_{ijm} = \sum_{k=0}^{K=1} \sum_{p=0}^{H=1} \sum_{q=0}^{H=1} X_{i+p,q,k} h_{pqm} + b_{ijm} \quad (1)$$

โดยที่ X คือรูปภาพที่ใช้ในการคำนวณ ส่วน h คือเคอร์เนลขนาด $H \times H$ และ b คือ Bias

สำหรับการคำนวณในชั้นเชื่อมโยงแบบสมบูรณ์ จะเป็นการคำนวณหาค่าความน่าจะเป็น (Probability) ด้วยฟังก์ชันซอฟต์แมกซ์ (Soft Max) ดังสมการ

$$f_i(x) = \frac{\exp(x_i)}{\sum_j^n \exp(x_j)} \quad (2)$$

2) อัลกอริทึมในการเพิ่มประสิทธิภาพของโมเดล เป็นฟังก์ชันทางคณิตศาสตร์ที่อาศัยค่าพารามิเตอร์ในการเรียนรู้ เช่น ค่า Weight และ ค่า Bias ซึ่งเครื่องมือเพิ่มประสิทธิภาพช่วยให้ทราบวิธีการเปลี่ยน Weight และ Learning Rate ของ Neural Network ทั้งนี้เพื่อลดค่า Loss หรือ Error ในการวิจัยครั้งนี้ได้เลือกใช้อัลกอริทึมในการเพิ่มประสิทธิภาพ ประกอบด้วย AdaGrad, AdaDelta, Adam, RMSprop และ SGD เนื่องจากเป็นอัลกอริทึมที่นิยมใช้ใน CNN ดังรายละเอียดต่อไปนี้

AdaGrad เป็น Optimize ที่มีพารามิเตอร์โดยเฉพาะในแต่ละ Learning Rates และในแต่ละพารามิเตอร์จะมีตัวแปร cache เพิ่มขึ้นมา เพื่อทำหน้าที่ในการเก็บค่าการคำนวณผลของรวม Gradients โดยค่าที่อยู่ใน cache จะเพิ่มขึ้นเรื่อย ๆ และค่า Learning Rate จะลดลง (Mustapha el al., 2021) ดังสมการ

$$s \leftarrow s + \nabla_{\theta} J(\theta) \otimes \nabla_{\theta} J(\theta) \quad (3)$$

$$\theta \leftarrow \theta - \frac{\eta \nabla_{\theta} J(\theta)}{\sqrt{s + \beta}} \quad (4)$$

AdaDelta ถูกพัฒนาต่อยอดมาจาก AdaGrad โดย Learning Rates จะลดลงอย่างต่อเนื่องตลอดการฝึกฝน และจะไม่เก็บผลรวมทั้งหมดจากการคำนวณ Gradients ดังเช่น AdaGrad แต่จะถูกจำกัดการสะสมค่าการคำนวณของ Gradients ได้เอง (Mustapha el al., 2021) ดังสมการ

$$\Delta \theta_t \leftarrow - \frac{RMS[\Delta \theta]_{t-1}}{RMS[g]_t} g_t \quad (5)$$

$$\theta_{t-1} \leftarrow \theta_t + \Delta \theta_t \quad (6)$$

Adaptive Moment Estimation (Adam) เป็น Optimizer ที่รวมข้อดีจาก AdaGrad และ RMSprop มาพัฒนาเพื่อให้สามารถปรับ Learning Rates สำหรับพารามิเตอร์ในแต่ละครั้งได้ ทำให้สามารถแก้ปัญหา Decaying ของ Gradients ในแต่ละขั้นตอนที่ผ่านมาได้เหมือนกับ AdaDelta (Poojary & Pai, 2019) ดังสมการ

$$\begin{cases} \beta_t \leftarrow \rho_1 \beta_{t-1} + (1 - \rho_1) g_t \\ \gamma_t \leftarrow \rho_2 \gamma_{t-1} + (1 - \rho_2) g_t^2 \end{cases} \quad (7)$$

Root Mean Square Propagation (RMSprop) ถูกพัฒนาขึ้นมาเพื่อแก้ปัญหาของ AdaGrad โดยใช้ EMA (Exponentially weighted moving average) เข้ามาแทนที่ตัวแปร cache ทำให้ช่วยลดทอนความสำคัญ

ของ Gradients โดยจะใช้ค่าเฉลี่ยของ Gradients หารด้วย root ของค่าเฉลี่ย (Poojary & Pai, 2019) ดังสมการ

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{(1-\gamma)g_{t-1}^2 + \gamma g_t^2 + \epsilon}} \cdot g_t \quad (8)$$

Stochastic Gradient Descent (SGD) โดย SGD จะมีการปรับปรุงค่าพารามิเตอร์ในทุก ๆ ชุดข้อมูลฝึกฝน โดยจะปรับปรุงแค่ครั้งเดียวต่อการฝึกฝน 1 รอบ (Poojary & Pai, 2019) ดังสมการ

$$g = \frac{1}{m} \nabla_{\theta} \sum_i L(f(x^{(i)}; \theta), y^{(i)}) \quad (9)$$

$$\theta = \theta - \epsilon_k \cdot g \quad (10)$$

3) ฟังก์ชันกระตุ้น (Activation Function) หรือฟังก์ชันการถ่ายโอน (Transfer Function) เป็นฟังก์ชันที่รับผลรวมจากการประมวลทั้งหมดในทุก Input (ทุก Dendrite) ภายในนิวรอน เพื่อทำการพิจารณาและส่งต่อไปยัง Output ปัจจุบันมี Activate Function ที่นิยมใช้ในเครือข่ายประสาทเทียม ได้แก่ ReLU, Sigmoid และ Tanh (Khadim et al., 2021) ดังรายละเอียดต่อไปนี้

ReLU (Rectified Linear Unit) เป็นฟังก์ชันที่เรียบง่าย เรียกว่า Ramp Function กล่าวคือ เมื่อ Input มีค่าตั้งแต่ 0 ขึ้นไป Output จะมีค่าเท่ากับ ส่วน Input ที่น้อยกว่า 0 จะกำหนด Output เป็น 0 ตลอด ดังสมการ

$$f(x) = \text{relu}(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (11)$$

Sigmoid เป็นฟังก์ชันที่มีลักษณะเส้นโค้งรูปตัว S โดย Output มีค่าระหว่าง 0-1 ที่มาจากความน่าจะเป็น (Probability) หรือใช้เป็น Output 1=Yes, 0=No ดังสมการ

$$f(x) = \text{sigmoid}(x) = \frac{1}{1+e^{-x}} = \frac{e^x}{e^x+1} \quad (12)$$

Tanh (Hyperbolic Tangent) เป็นฟังก์ชันที่คล้ายกับ Sigmoid ต่างกันตรงที่ Output จะอยู่ในช่วง -1 และ 1 และมีจุดตัดการตัดสินใจที่ 0 ไม่ใช่ 0.5 ดังสมการ

$$f(x) = \text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (13)$$

การวัดประสิทธิภาพโมเดล

การวัดประสิทธิภาพโมเดลโดยใช้การวัดค่าความถูกต้อง ค่าความแม่นยำ และค่าอัตราการจำแนก ถูกต้องเมื่อข้อมูลเป็นจริง (อุมารณีย์ สายแสงจันทร์ และคณะ, 2565) ซึ่งเป็นค่าที่ได้จากวิธีการทดสอบเพื่อหาค่า พยากรณ์ความถูกต้องของข้อมูลโดยคิดเป็นค่าร้อยละ ดังสมการ

$$Accuracy = \frac{(TP + TN)}{(TN + FN + FP + TP)} \quad (14)$$

$$Precision = \frac{TP}{TP+FP} \quad (15)$$

$$Recall = \frac{TP}{TP+FN} \quad (16)$$

โดยที่ TP คือค่าพยากรณ์ถูกต้องเชิงบวก TN คือค่าพยากรณ์ถูกต้องเชิงลบ ส่วน FP คือค่าพยากรณ์ผิดพลาดเชิงบวก และ FN คือค่าพยากรณ์ผิดพลาดเชิงลบ

4. ผลการวิจัย

สำหรับการวิจัยในครั้งนี้ได้รวบรวมภาพถ่ายใบสมุนไพรมานำเข้าโปรแกรมการประมวลผลภาพเพื่อจำแนกใบสมุนไพรมีการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน และเปรียบเทียบประสิทธิภาพอัลกอริทึม ประกอบด้วย AdaDelta, AdaGrad, Adam, RMSprop และ SGD พร้อมทั้งเปรียบเทียบฟังก์ชันกระตุ้น ได้แก่ ReLU, Sigmoid และTanh ผลการทดลองจะแบ่งการนำเสนอออกเป็น 2 ส่วนคือ ส่วนที่ใช้ภาพก่อนการปรับภาพและหลังการปรับภาพ ได้แก่ การกลับภาพและการปรับความสว่างของภาพ โดยกำหนดค่าพารามิเตอร์ต่าง ๆ ดังนี้

- Learning Rate: 0.001
- Metric: Accuracy
- Loss Function: Cross-Entropy
- No. of Epochs: 100, 200, 300
- Training & Validation Batch Size: 32
- Total No. of Images in Train Dataset: 144 (ก่อนปรับภาพ), 432 (หลังปรับภาพ) for each class
- Total No. of Images in Validation Dataset: 36 for each class

ผลการทดลองก่อนการปรับภาพ

ผลการทดลองประสิทธิภาพของโมเดลในแต่ละ Optimizer พบว่า ค่าความถูกต้องจากฟังก์ชันกระตุ้น ReLU มีค่าสูงสุด 0.902 ซึ่งมาจาก Optimizer RMSprop ที่จำนวน epochs 200 รอบ (ตารางที่ 1) ส่วนฟังก์ชันกระตุ้น Sigmoid มีค่าสูงสุด 0.744 ซึ่งมาจาก Optimizer RMSprop ที่จำนวน epochs 100 รอบ

(ตารางที่ 2) และฟังก์ชันกระตุ้น Tanh มีค่าสูงสุด 0.937 ซึ่งมาจาก Optimizer AdaDelta ที่จำนวน epochs 200 รอบ (ตารางที่ 3)

ตารางที่ 1 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น ReLU (ก่อนปรับภาพ)

Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.465	0.293	0.465	0.645	0.525	0.645	0.687	0.807	0.687
AdaGrad	0.764	0.843	0.764	0.777	0.828	0.777	0.777	0.856	0.777
Adam	0.792	0.850	0.792	0.770	0.840	0.770	0.777	0.828	0.777
RMSprop	0.792	0.833	0.797	0.902	0.912	0.902	0.770	0.833	0.770
SGD	0.777	0.853	0.777	0.784	0.863	0.784	0.777	0.861	0.777

ตารางที่ 2 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น Sigmoid (ก่อนปรับภาพ)


Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
AdaGrad	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
Adam	0.656	0.700	0.659	0.638	0.671	0.638	0.729	0.831	0.729
RMSprop	0.744	0.824	0.743	0.743	0.786	0.743	0.729	0.791	0.729
SGD	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250

ตารางที่ 3 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น Tanh (ก่อนปรับภาพ)

Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.673	0.581	0.673	0.937	0.937	0.937	0.924	0.924	0.924
AdaGrad	0.764	0.817	0.764	0.777	0.821	0.777	0.771	0.832	0.771
Adam	0.791	0.842	0.791	0.791	0.852	0.791	0.778	0.827	0.778
RMSprop	0.770	0.836	0.770	0.784	0.850	0.784	0.785	0.843	0.785
SGD	0.784	0.860	0.784	0.784	0.840	0.784	0.785	0.834	0.785

จากตารางที่ 1 ถึง ตารางที่ 3 ประสิทธิภาพของโมเดลที่ได้จากการเปรียบเทียบในแต่ละ Optimizer พบว่า AdaDelta จากฟังก์ชันกระตุ้น Tanh มีค่าประสิทธิภาพสูงสุด โดยพิจารณาได้จากค่าความถูกต้อง

ค่าความแม่นยำ และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง ซึ่งทั้ง 3 ค่า มีค่าเท่ากันคือ 0.937 ที่จำนวน epochs 200 รอบ สามารถแสดงผลการเปรียบเทียบ Optimizer แยกตามการใช้ฟังก์ชันกระตุ้นและจำนวน epoch (100, 200, 300) ได้ดังภาพที่ 4



ภาพที่ 4 เปรียบเทียบ Optimizer แยกตามการใช้ฟังก์ชันกระตุ้นและจำนวน epoch (ก่อนปรับภาพ)

จากภาพที่ 4 ผลประเมินประสิทธิภาพการจำแนกไบสมุนไพรร พบว่า ฟังก์ชันกระตุ้น Tanh มีค่าความถูกต้องสูงสุด จาก Optimizer AdaDelta ในขณะที่ฟังก์ชันกระตุ้น Sigmoid มีค่าความถูกต้องต่ำสุด จาก Optimizer AdaDelta, AdaGrad และ SGD

ผลการทดลองหลังการปรับภาพ

ซึ่งในการทดลองหลังการปรับภาพด้วยเทคนิคการกลับภาพ และการเพิ่มความสว่าง ทำให้จำนวนภาพเพิ่มขึ้น รวมเป็นจำนวน 1,728 ภาพ โดย 576 ภาพมาจากภาพต้นฉบับ และอีก 1,152 ภาพมาจากการปรับภาพ ผลการทดลองประสิทธิภาพของโมเดล พบว่า ในแต่ละ Optimizer มีค่าความถูกต้องจากฟังก์ชันกระตุ้น ReLU มีค่าสูงสุด 0.891 ซึ่งมาจาก Optimizer RMSprop ที่จำนวน epochs 200 รอบ (ตารางที่ 4) ส่วนฟังก์ชันกระตุ้น Sigmoid มีค่าสูงสุด 0.752 ซึ่งมาจาก Optimizer Adam ที่จำนวน epochs 300 รอบ (ตารางที่ 5) และฟังก์ชันกระตุ้น Tanh มีค่าสูงสุด 0.954 ซึ่งมาจาก Optimizer AdaDelta ที่จำนวน epochs 200 รอบ (ตารางที่ 6)

ตารางที่ 4 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น ReLU (หลังปรับภาพ)

Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.512	0.384	0.512	0.622	0.614	0.622	0.781	0.717	0.781
AdaGrad	0.832	0.809	0.832	0.830	0.819	0.830	0.773	0.802	0.773
Adam	0.811	0.851	0.811	0.773	0.853	0.773	0.810	0.883	0.810
RMSprop	0.799	0.823	0.799	0.891	0.909	0.891	0.771	0.841	0.771
SGD	0.779	0.736	0.779	0.830	0.748	0.830	0.773	0.856	0.773


ตารางที่ 5 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น Sigmoid (หลังปรับภาพ)

Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
AdaGrad	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
Adam	0.453	0.612	0.453	0.611	0.662	0.611	0.752	0.781	0.755
RMSprop	0.624	0.738	0.624	0.724	0.810	0.724	0.703	0.701	0.703
SGD	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250

ตารางที่ 6 ผลการทดลองโมเดลในแต่ละ Optimizer จากฟังก์ชันกระตุ้น Tanh (หลังปรับภาพ)

Optimizer	Epochs 100			Epochs 200			Epochs 300		
	Accuracy	Precision	Recall	Accuracy	Precision	Recall	Accuracy	Precision	Recall
AdaDelta	0.917	0.917	0.917	0.921	0.921	0.921	0.954	0.955	0.954
AdaGrad	0.914	0.928	0.914	0.918	0.922	0.918	0.907	0.920	0.907
Adam	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
RMSprop	0.250	0.062	0.250	0.250	0.062	0.250	0.250	0.062	0.250
SGD	0.917	0.920	0.917	0.917	0.915	0.917	0.902	0.911	0.902

จากตารางที่ 4 ถึง ตารางที่ 6 ประสิทธิภาพของโมเดลที่ได้จากการเปรียบเทียบในแต่ละ Optimizer หลังจากการปรับภาพ พบว่า AdaDelta จากฟังก์ชันกระตุ้น Tanh มีค่าประสิทธิภาพสูงสุด โดยพิจารณาได้จาก ค่าความถูกต้อง 0.954 ค่าความแม่นยำ 0.955 และค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง 0.954 ที่จำนวน epochs 300 รอบ สามารถแสดงผลการเปรียบเทียบ Optimizer แยกตามการใช้ฟังก์ชันกระตุ้นและจำนวน epoch (100, 200, 300) ได้ดังภาพที่ 5



ภาพที่ 5 เปรียบเทียบ Optimizer แยกตามการใช้ฟังก์ชันกระตุ้นและจำนวน epoch (หลังปรับภาพ)

จากภาพที่ 5 ผลประเมินประสิทธิภาพการจำแนกใบสมุนไพรร่วมพบว่า ฟังก์ชันกระตุ้น Tanh มีค่าความถูกต้องสูงสุด จาก Optimizer AdaDelta เช่นกันกับก่อนปรับภาพ ในขณะที่ฟังก์ชันกระตุ้น Sigmoid มีค่าความถูกต้องต่ำสุด จาก Optimizer AdaDelta, AdaGrad และ SGD เช่นกันกับก่อนปรับภาพ เมื่อเปรียบเทียบผลทดลองที่ได้ทั้งก่อนปรับภาพและหลังปรับภาพพบว่า ร้อยละความถูกต้องที่หลังปรับภาพสูงกว่าก่อนปรับภาพ โดยก่อนปรับภาพร้อยละความถูกต้อง 93.70 หลังปรับภาพร้อยละความถูกต้อง 95.40

5. อภิปรายผลการวิจัยและข้อเสนอแนะ

งานวิจัยนี้มีวัตถุประสงค์เพื่อจำแนกภาพใบสมุนไพรร่วมด้วยโครงข่ายประสาทแบบคอนโวลูชันเชิงลึกและเปรียบเทียบอัลกอริทึมในการเพิ่มประสิทธิภาพของโมเดล และเปรียบเทียบฟังก์ชันกระตุ้น โดยนำตัวอย่างใบสมุนไพรมีพิษและไม่มีพิษ จำนวน 4 ชนิด ได้แก่ ใบฝรั่ง ใบสบู่ดำ/สบู่ขาว ใบมะนาว และใบทับทิม จากเว็บไซต์จำนวน 720 ภาพ โดยเพิ่มจำนวนภาพจากการกลับภาพในแนวแกนตั้ง และการปรับความสว่างของภาพ จึงทำให้ได้จำนวนภาพที่ใช้สำหรับการเรียนรู้เพิ่มขึ้นรวมเป็น 1,728 ภาพ โดย 576 ภาพมาจากภาพต้นฉบับ และอีก 1,152 ภาพ มาจากการปรับภาพ

ผลการทดลองก่อนการปรับภาพพบว่า Optimizer AdaDelta จากฟังก์ชันกระตุ้น Tanh มีค่าประสิทธิภาพสูงสุด โดยพิจารณาได้จากค่าความถูกต้อง ค่าความแม่นยำ และค่าค่าอัตราการทำนายถูกต้องเมื่อข้อมูลเป็นจริง ซึ่งทั้ง 3 ค่า มีค่าเท่ากันคือ 0.937 ที่จำนวน epochs 200 รอบ กล่าวคือโมเดลที่ผู้วิจัยได้ปรับแต่งขึ้นมาโดยใช้ภาพในการเรียนรู้ จำนวน 576 ภาพ สามารถทำนายใบสมุนไพรร่วมได้ถูกต้องร้อยละ 93.70 เมื่อทำการเพิ่มจำนวนภาพโดยการปรับภาพในแนวแกนตั้งและปรับความสว่างของภาพ ทำให้ได้ภาพในการเรียนรู้เพิ่มขึ้นรวมเป็น 1,728 ภาพ ผลการทดลองพบว่า AdaDelta จากฟังก์ชันกระตุ้น Tanh มีค่าประสิทธิภาพสูงสุดเช่นกัน

โดยพิจารณาได้จากค่าความถูกต้อง 0.954 ค่าความแม่นยำ 0.955 และค่าค่าอัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง 0.954 ที่จำนวน epochs 300 รอบ ดังนั้นจึงสรุปได้ว่าโมเดลที่ผู้วิจัยได้ปรับแต่งขึ้นโดยการเพิ่มจำนวนภาพ สามารถทำนายใบสมุนไพรมันได้ถูกต้องร้อยละ 95.40

จากผลการทดลองสามารถนำโมเดลหลังจากการปรับภาพที่ผู้วิจัยได้ปรับแต่งโดยใช้ Optimizer AdaDelta และฟังก์ชันกระตุ้น Tanh ไปประยุกต์ใช้ในการพัฒนาเว็บไซต์หรือโมบายแอปพลิเคชันเพื่อจำแนกใบสมุนไพรมันได้อย่างมีประสิทธิภาพ อย่างไรก็ตามหากเปรียบเทียบกับก่อนการปรับภาพพบว่า ค่าความถูกต้องนั้นเพิ่มขึ้น ทั้งนี้อาจเนื่องมาจากจำนวนภาพและลักษณะของภาพสร้างการเรียนรู้และจำแนกได้ถูกต้องมากขึ้นเมื่อมีการเพิ่มจำนวนภาพ นอกจากนั้นการใช้โมเดลที่ได้ปรับแต่งขึ้นจากการวิจัยครั้งนี้ ซึ่งมีจำนวนชั้นน้อยกว่าสถาปัตยกรรมอื่น ๆ ของ CNN ไม่ว่าจะเป็น VGG16 LeNet-5 หรือ ResNet-5 ทั้งนี้จึงทำให้ระยะเวลาในการประมวลผลน้อยกว่าแต่ยังคงให้ประสิทธิภาพที่สามารถนำไปประยุกต์ใช้ได้เป็นอย่างดี

สำหรับการวิจัยครั้งต่อไป ควรเพิ่มจำนวนชุดข้อมูลรูปภาพ และจำนวนภาพ พร้อมทั้งนำภาพใบสมุนไพรมันไปปรับแต่งรูปแบบต่าง ๆ เพิ่มขึ้น เช่น การหมุนรูปภาพ (Rotate) การใส่สัญญาณรบกวน (Noise) การปรับแต่งความชัด (Contrast) การเปลี่ยนสี (Recolor) การเบลอรูปภาพ (Blur) เป็นต้น ทั้งนี้เพื่อให้รูปภาพมีลักษณะแตกต่างกันออกไป และเพื่อให้โมเดลได้เกิดการเรียนรู้และจำแนกรูปภาพในลักษณะต่าง ๆ ได้มากยิ่งขึ้น นอกจากนั้นควรเลือกสถาปัตยกรรมให้หลากหลายยิ่งขึ้น เช่น LeNet-5, VGG16, ResNet-50 เป็นต้น

6. กิตติกรรมประกาศ

ขอขอบคุณทุนอุดหนุนวิจัยจากคณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

7. เอกสารอ้างอิง

- กฤตชัย บุญคิวพันธ์ และ รักษ์วริน วรณศิลป์. (2558). การพัฒนาแอปพลิเคชันด้วยเทคโนโลยีความเป็นจริงเสริม สำหรับรู้จำใบสมุนไพรมันที่บ้าน. *วารสารวิชาการแพรวกาฬสินธุ์ มหาวิทยาลัยราชภัฏกาฬสินธุ์, ฉบับพิเศษ: มหกรรมวิชาการภูมิปัญญา กลุ่มชาติพันธุ์นานาชาติลุ่มน้ำโขง ไทยลาว เวียดนาม จีน*, 9-23. https://so05.tci-thaijo.org/index.php/Praewa-ksu_Journal/article/view/90567
- จักรินทร์ สุนุกแสน และ โอฬาริก สุรินตะ. (2561). โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสำหรับการจำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ. *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม*, 38(2), 113-124. <http://olarik.it.msu.ac.th/wp-content/uploads/2019/10/001-Jakkarin-2019.pdf>
- ภูมินทร์ ต้นอุดม และ ธีรกร ขำสุวรรณ (2562). การพัฒนาเครื่องต้นแบบคัดแยกดอกดาวเรืองโดยใช้วิธีการประมวลผลภาพ. *วารสารวิชาการวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครสวรรค์*, 11(13), 79-92. <https://ph02.tci-thaijo.org/index.php/JSTNSRU/article/view/133998>
- ศูนย์พิษวิทยารามาธิบดี, คณะแพทยศาสตร์โรงพยาบาลรามาธิบดี มหาวิทยาลัยมหิดล. (2564) *สมุนไพรมัน*. <https://med.mahidol.ac.th/poisoncenter/th/pois-cov/Herbal>.

- อุมาภรณ์ สายแสงจันทร์, รพีพร ข้าของ และ อรรถพล สุวรรณษา. (2565). การเปรียบเทียบวิธีการวิเคราะห์โรคใบ
মনননননননননননননন. *วารสารวิทยาการสารสนเทศและเทคโนโลยีประยุกต์ มหาวิทยาลัยมหาสารคาม*,
4(1), 71-86. <https://li01.tci-thaijo.org/index.php/agkasetkaj/article/download/249570/173217>
- Jordan, M. I. & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects.
Science, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Khadim, E.U., Shah, S.A. & Wagan, R.A. (2021). Evaluation of activation functions in CNN model
for detection of malaria parasite using blood smear images. In *International Conference
on Innovative Computing (ICIC)*, Lahore, Pakistan, 1-6. <https://doi.org/10.1109/ICIC53490.2021.9693056>
- Mustapha, A., Mohamed, L. & Ali, K. (2021). Comparative study of optimization techniques in
deep learning: Application in the ophthalmology field. *Journal of Physics: Conference
Series*, 1743, 1-12. <https://doi.org/10.1088/1742-6596/1743/1/012002>
- Panmuang, M., Rodmorn, C. & Pinitkan, S. (2021). Image processing for classification of rice
varieties with deep convolutional neural networks. In *16th International Joint Symposium
on Artificial Intelligence and Natural Language Processing (ISAI-NLP)*, Ayutthaya, Thailand,
1-6. <https://doi.org/10.1109/ISAI-NLP54397.2021.9678184>
- Poojary, R. & Pai, A. (2019). Comparative study of model optimization techniques in fine-tuned
CNN models. In *2019 International Conference on Electrical and Computing Technologies
and Applications (ICECTA)*, Ras Al Khaimah, United Arab Emirates, 1-4. <https://doi.org/10.1109/ICECTA48151.2019.8959681>
- Roopashree, S. & Anitha, J. (2020). *Medicinal Leaf Dataset*. <https://data.mendeley.com/datasets/nnytj2v3n5>
- Schwartz, E., Giryes, R. & Bronstein, A. M. (2019). DeepISP: Toward learning an End-to-End image
processing pipeline. *IEEE Transactions on Image Processing*, 28(2), 912-923. <https://doi.org/10.1109/TIP.2018.2872858>
- Sun, X., Qian, H., Xiong, Y., Zhu, Y., Huang, Z. & Yang, F. (2022). Deep learning-enabled mobile
application for efficient and robust herb image recognition. *Scientific Reports*, 12(6579),
1-18. <https://doi.org/10.1038/s41598-022-10449-9>