



## บทความวิจัย

## การวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยการประมวลผลภาพและโครงข่ายประสาทเทียมแบบคอนโวลูชัน

สุภารัตน์ เทียนน้อย นพดล อ่ำดี\* และ อติศักดิ์ แสงส่องฟ้า

สาขาวิชาการจัดการเทคโนโลยีอุตสาหกรรม คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏหมู่บ้านจอมบึง

พยุ่ง มีสัจ

ภาควิชาการจัดการเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

\*ผู้นิพนธ์ประสานงาน โทรศัพท์ 0 9911 9449 9 อีเมล: noppadol.amdee@mcru.mail.go.th DOI: 10.14416/j.kmutnb.2024.06.004

รับเมื่อ 5 เมษายน 2565 แก้ไขเมื่อ 11 กรกฎาคม 2565 ตอบรับเมื่อ 23 สิงหาคม 2565 เผยแพร่ออนไลน์ 12 มิถุนายน 2567

© 2024 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

### บทคัดย่อ

งานวิจัยนี้ได้นำเสนอวิธีการนำภาพถ่ายดิจิทัลมาประยุกต์ใช้ในการเกษตรเพื่อวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยการใช้ภาพถ่ายดิจิทัล โดยมีขั้นตอนในการวิจัย 3 ขั้นตอน ดังนี้ ขั้นตอนที่ 1 ข้อมูลภาพ (Input Image) ขั้นตอนที่ 2 การฝึกฝนและเรียนรู้ (Train Image) และขั้นตอนที่ 3 การทดสอบระบบ (Test Image) ในงานวิจัยนี้ใช้ภาพถ่ายดิจิทัลจากการถ่ายด้วยสมาร์ทโฟน กล้องถ่ายภาพมีความละเอียด 12 ล้านพิกเซล โดยการนำภาพถ่ายดิจิทัลเข้าสู่ระบบที่พัฒนาขึ้นเพื่อให้ระบบได้ทำการฝึกฝนเรียนรู้ ใช้ภาพถ่ายดิจิทัลจำนวน 865 ภาพ ภาพที่นำเข้าไปในระบบมีการแบ่งภาพออกเป็น 4 คลาส ได้แก่ คลาสเต็มใบ คลาสปลายใบ คลาสกลางใบและคลาสโคนใบ และกำหนดให้เครื่องได้เรียนรู้ซ้ำ ๆ จำนวน 10 รอบ ส่วนในขั้นตอนของการทดสอบระบบ ผู้วิจัยใช้ภาพถ่ายดิจิทัลที่ไม่ได้ผ่านการประมวลผลภาพ เพื่อใช้สำหรับทดสอบความถูกต้องของระบบ ซึ่งการวิจัยพบว่า ระบบการวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยการประมวลผลภาพถ่ายดิจิทัลและโครงข่ายประสาทเทียมแบบคอนโวลูชันที่พัฒนาขึ้น สามารถวิเคราะห์ภาพถ่ายที่เป็นโรคเหี่ยวของใบสับปะรดได้ด้วยความถูกต้องสูงถึง 98.96%

**คำสำคัญ:** โรคเหี่ยว ใบสับปะรด การประมวลผลภาพ โครงข่ายประสาทเทียมแบบคอนโวลูชัน

การอ้างอิงบทความ: สุภารัตน์ เทียนน้อย, นพดล อ่ำดี, อติศักดิ์ แสงส่องฟ้า และ พยุ่ง มีสัจ, “การวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยการประมวลผลภาพและโครงข่ายประสาทเทียมแบบคอนโวลูชัน,” วารสารวิชาการพระจอมเกล้าพระนครเหนือ, ปีที่ 34, ฉบับที่ 3, หน้า 1-11, เลขที่บทความ 243-185947, ก.ค.-ก.ย. 2567.



## An Analysis of Pineapple Leaf Wilt by Image Processing and Convolutional Neural Network

Sudarat Theinnoi, Noppadol Amdee\* and Adisak Sangsongfar

Department of Industrial Technology Management, Faculty of Industrial Technology, Muban Chombueng Rajabhat University, Ratchaburi, Thailand

Payung Meesad

Department of Information Technology Management, Faculty of Information Technology Management and Digital Innovation, King Mongkut's University of Technology North Bangkok, Bangkok, Thailand

\* Corresponding Author, Tel. 0 9911 9449 9, E-mail: noppadol.amdee@mcru.mail.go.th DOI: 10.14416/j.kmutnb.2024.06.004

Received 5 April 2022; Revised 11 June 2022; Accepted 23 August 2022; Published online: 12 June 2024

© 2024 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

### Abstract

This research presented a method for applying digital photographs to agriculture for the analysis of pineapple leaf wilt by using digital photographs. There were 3 steps in the research as follows: step 1: Input Image, step 2: Train Image, and step 3: System Test. The research used digital photos taken with a smartphone that the camera had a resolution of 12 megapixels. All 865 digital photos were brought into a system developed for practicing learning. The images imported into the system were divided into 4 classes: full leaf class, tip class, mid leaf class, and base leaf class. The machine was set to learn repeatedly for 10 rounds in the process of testing the system. The researchers used unprocessed digital photographs and used them to test the correctness of the system. The research revealed an analysis of pineapple leaf wilt by digital image processing and a convolutional neural network, it was able to analyze photos with wilt of pineapple leaves with an accuracy of 98.96%.

**Keywords:** Wilt Disease, Pineapple Leaf, Image Processing, Convolutional Neural Network

Please cite this article as: S. Theinnoi, N. Amdee, A. Sangsongfar, and P. Meesad, "An analysis of pineapple leaf wilt by image processing and convolutional neural network," *The Journal of KMUTNB*, vol. 34, no. 3, pp. 1–11, ID. 243-185947, Jul.–Sep. 2024 (in Thai).

## 1. บทนำ

สับปะรดเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทยที่มีความสำคัญต่อเศรษฐกิจของประเทศไทยมาก เพราะสับปะรดเป็นผลไม้ที่เป็นวัตถุดิบสำคัญในอุตสาหกรรมผลไม้แปรรูปของไทย โดยเฉพาะอุตสาหกรรมสับปะรดกระป๋อง โดยสับปะรดได้จัดให้อยู่ในกลุ่มของสินค้าเพื่อการส่งออกทั้งในรูปของสับปะรดสด และสับปะรดแปรรูปต่าง ๆ โดยประเทศไทยมีการส่งออกสับปะรดกระป๋องในปริมาณ 290,578.34 ตัน ลดลงร้อยละ 25.44 [1] ใน พ.ศ. 2562 ได้มีการสำรวจพื้นที่พบว่า มีแหล่งปลูกสับปะรดที่สำคัญของประเทศไทยอยู่ที่จังหวัดประจวบคีรีขันธ์ จังหวัดระยอง จังหวัดราชบุรี จังหวัดเพชรบุรี จังหวัดชลบุรี จังหวัดพิษณุโลก จังหวัดอุทัยธานี จังหวัดกาญจนบุรี และจังหวัดเลย [2] และใน พ.ศ. 2563 สถานการณ์สับปะรดคาดการณ์ว่าจะมีเนื้อที่เก็บเกี่ยว 414,777 ไร่ ลดลงจากปีที่แล้ว 51,720 ไร่ ปริมาณผลผลิตมี 1.39 ล้านตัน ลดลงจากปีที่แล้ว 285,358 ตัน ผลผลิตต่อไร่ 3,362 กิโลกรัม ลดลง 239 กิโลกรัมต่อไร่ [3]

ปัญหาที่สำคัญที่ทำให้ผลผลิตลดลงและสร้างความเสียหายให้แก่เกษตรกรที่ปลูกสับปะรดทั่วประเทศคือโรคของสับปะรด ได้แก่ โรคเหี่ยว ปัจจุบันนักวิชาการทั่วโลกไม่สามารถกำจัดโรคเหี่ยวสับปะรดให้หมดไปได้แม้ว่าเราจะมียุทธศาสตร์ความรู้เชิงลึกเกี่ยวกับโรคเหี่ยวนี้มากมายนับตาม [4] จากรายงานการวิจัยเกี่ยวกับโรคของสับปะรด พบว่าการระบาดของโรคเหี่ยวในแหล่งปลูกสับปะรดใน พ.ศ. 2546 โรคนี้ระบาดรุนแรงในแปลงปลูกสับปะรดภาคตะวันตก บริเวณจังหวัดประจวบคีรีขันธ์ และเพชรบุรี และได้เข้าทำลายแปลงปลูกสับปะรดในจังหวัดชลบุรี ระยอง และตราด ซึ่งเป็นแหล่งปลูกสับปะรดเพื่อส่งโรงงานแปรรูปของภาคตะวันออก ใน พ.ศ. 2558 ผลผลิตลดลง 271 กิโลกรัมต่อไร่ หรือคิดเป็นมูลค่า 1,951.2 บาทต่อไร่ ลดลงร้อยละ 6.9 หรือ 0.132 ล้านตัน คิดเป็นมูลค่าความเสียหาย 7.2 ล้านล้านบาท ซึ่งผลผลิตที่ลดลงมีสาเหตุมาจากการประสบปัญหาโรคเหี่ยวซึ่งเป็นสาเหตุหลักที่ทำให้ผลผลิตต่อไร่ลดลง [5]

จากปัญหาที่กล่าวมาผู้วิจัยจึงมุ่งเสนอวิธีการวิเคราะห์โรคเหี่ยวจากใบของสับปะรด โดยการประยุกต์ใช้เทคโนโลยี

ทางการจำแนกร่วมกับเทคนิคการประมวลผลภาพถ่ายดิจิทัล (Image Processing) ซึ่งเป็นวิธีการที่นิยมอย่างมากในการวิเคราะห์ภาพ การจำแนกภาพ โดยมุ่งเป้าหมายความถูกต้องแม่นยำสูง ทนต่อสถานการณ์ สามารถวิเคราะห์โรคเหี่ยวอย่างถูกต้องให้แก่เกษตรกร เพื่อลดการสูญเสียผลผลิตและลดการระบาดของโรคได้ทัน ดังเช่นงานวิจัยเรื่องการประยุกต์ใช้เทคโนโลยีการประมวลผลภาพสำหรับประเมินระดับความรุนแรงของโรคข้าว [6] พบว่า โปรแกรมที่พัฒนาขึ้นสามารถทำการวิเคราะห์ระดับความรุนแรงของโรคใบขีดสีน้ำตาลได้เป็นอย่างดี

ดังนั้นในการแก้ปัญหาผลผลิตที่ตกต่ำของสับปะรดอันมีสาเหตุมาจากการเกิดโรคเหี่ยวของสับปะรด คือ การหาลักษณะของโรคเหี่ยวก่อนที่จะเกิดการระบาดของโรคมุ่งงานวิจัยหลายงานวิจัยที่กล่าวถึงการพยากรณ์การเกิดโรคในพืชชนิดอื่น ๆ โดยใช้เทคนิคการประมวลผลภาพถ่ายดิจิทัลเข้ามาประยุกต์ใช้ในงานวิจัยตัวอย่างเช่น งานวิจัยเรื่องแอปพลิเคชันวิเคราะห์โรคพืชจากใบบนแอนดรอยด์โดยใช้ซอฟต์แวร์เวกเตอร์แมชชีน [7] การวิเคราะห์โรคใบจุด โรคใบไหม้ และไม่เป็นโรค โดยใช้การเปรียบเทียบกับผลวิเคราะห์ของผู้เชี่ยวชาญ ผลการวิเคราะห์ภาพใบพืชมีความแม่นยำประมาณ 80.43% 72.31% และ 69.05% ตามลำดับสอดคล้องกับงานวิจัยเรื่องการศึกษางานวิจัยการประมวลผลภาพถ่ายดิจิทัลและการประยุกต์ใช้งานในแอปพลิเคชัน [8] งานวิจัยนี้ได้กล่าวถึงพัฒนางานของการประมวลผลภาพและการพัฒนาแอปพลิเคชันด้านการประมวลผลภาพเพื่อตอบสนองความต้องการในด้านต่าง ๆ เช่น ด้านการแพทย์ การค้นคืนข้อมูล และการรู้จำแบบ และสามารถนำไปประยุกต์ใช้งานได้อย่างมีประสิทธิภาพ ซึ่งสอดคล้องกับงานวิจัยเรื่องการศึกษาวิธีการตรวจสอบรากขาวบนผิวเนื้อยางแผ่นโดยใช้วิธีการประมวลผลภาพ [9] เป็นการประยุกต์หลักการทางด้านด้านการประมวลผลภาพถ่ายดิจิทัล มาใช้ในด้านตรวจสอบคุณภาพสินค้าทางการเกษตรที่มีปริมาณมาก ๆ และยากต่อการจำแนกแทนการใช้สายตาตามมนุษย์ที่มีความจำกัดในการทำงานนาน ๆ โดยในวิจัยพบว่า ผลการพัฒนาต้นแบบเครื่องมือในการตรวจสอบรากขาวบนผิวเนื้อยางแผ่น สามารถ

จำแนกวางแผนได้ถูกต้องร้อยละ 97.50 เป็นต้น

จากการศึกษางานวิจัยที่กล่าวมา พบว่า งานวิจัยที่ใช้เทคนิคการประมวลผลภาพถ่ายดิจิทัลเข้ามาประยุกต์ใช้ในงานวิจัยร่วมกับวิธีการต่าง ๆ แสดงให้เห็นค่าความแม่นยำที่สูง ซึ่งสอดคล้องกับงานวิจัยฉบับนี้ที่ได้ทำการวิจัยและทดสอบวิธีการทำงานของระบบ โดยมีวัตถุประสงค์เพื่อพัฒนาระบบการวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยการประมวลผลภาพและโครงข่ายประสาทแบบคอนโวลูชัน ซึ่งประโยชน์ของงานวิจัยนี้สามารถนำไปพัฒนาต่อยอดในอนาคต เช่น การนำไปประยุกต์ใช้ร่วมกับเครื่องมือตรวจสอบอัตโนมัติ เช่น การใช้โดรน เนื่องจากพื้นที่ปลูกสับปะรดมีขนาดใหญ่ การใช้คนเดินตรวจสอบเป็นไปได้ลำบาก และยังสามารถลดความสูญเสียของผลผลิตสับปะรดที่เกิดจากโรคเหี่ยวได้


## 2. วัสดุ อุปกรณ์และวิธีการวิจัย

### 2.1 ทฤษฎีที่เกี่ยวข้องกับงานวิจัย

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network; CNN) คือ ขั้นตอนวิธีการเรียนรู้เชิงลึกแบบสังวัตนาการ เป็นการวิเคราะห์รูปภาพที่มนุษย์มองเห็น โดยจะแบ่งรูปภาพออกเป็นพื้นที่ย่อย ๆ เป็น Pixel เพื่อทำการวิเคราะห์ Matrix ของรูปภาพ โดยถ้าเป็นรูปภาพสีขาวดำ จะเป็น Matrix ขนาด  $2 \times 2$  แต่ถ้าเป็นภาพสีจะเป็น Matrix ขนาด  $3 \times 3$  เป็นเทคนิคที่พัฒนาต่อยอดมาจากโครงข่ายประสาทเทียม ซึ่งเป็นการเรียนรู้ของเครื่องแบบมีการฝึกฝนหรือเรียนรู้ ประกอบด้วยชั้นหลาย ๆ ประเภท ดังนี้

1) ชั้นคอนโวลูชัน (Convolution Layer) เป็นชั้นที่ทำการหาคุณลักษณะจากกลุ่มของข้อมูลอินพุตที่อยู่ใกล้ ๆ กันโดยใช้วิธีการดอทเมทริกซ์ (Dot Matrix) กับตัวกรอง (Filter) หรือบางครั้งเรียกว่า เคอร์เนล (Kernel) โดยที่น้ำหนักของตัวกรองจะใช้ร่วมกันในทุก ๆ การทำคอนโวลูชันของข้อมูลอินพุต

2) ชั้นการรวม (Pooling Layer) ชั้นการรวมทำหน้าที่ลดขนาดของข้อมูล (Dimensionality Reduction) เพื่อให้เหลือเฉพาะข้อมูลที่สำคัญ ๆ เท่านั้น จะช่วยให้การ



รูปที่ 1 แสดงขั้นตอนวิธีการเรียนรู้เชิงลึกแบบสังวัตนาการ

เรียนรู้แบบจำลองไม่ต้องคำนวณมากเกินไป ซึ่งมักจะนำมาต่อชั้นคอนโวลูชัน โดยทั่วไปนิยมใช้การเลือกข้อมูลที่มีค่ามากที่สุด (Max Pooling) หรือค่าเฉลี่ย (Average Pooling) มาจากแต่ละช่วงของเมทริกซ์เพื่อสร้างเป็นเมทริกซ์ให้เล็กลง

3) ชั้นการเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layer) หลังจากการประกอบกันของชั้นคอนโวลูชันและชั้นการรวมจำนวนหนึ่ง เป็นชั้นที่เชื่อมโยงระหว่าง Feature Map และ Output แบบสมบูรณ์ คือ ทุก ๆ Neuron ที่อยู่ในชั้นสุดท้ายของ Feature Map จะถูกนำไปเปลี่ยนรูป (Reshape) หรือ เรียกว่า MLP ซึ่งในส่วนสุดท้ายจึงเปรียบเสมือนข้อมูลนำเข้า (Input) ไปยังโครงข่ายประสาทเทียม ดังแสดงในรูปที่ 1

### 2.2 เครื่องมือที่ใช้ในงานวิจัย

1) การวัดค่าความคลาดเคลื่อนของรากที่สองกำลังสองเฉลี่ย (Root Mean Square Error; RMSE) ดังแสดงในสมการที่ (1)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_{obs,i} - x_{model,i})^2}{N}} \quad (1)$$

เมื่อ  $x_{obs}$  คือ ค่าที่ได้จากการสังเกต

$x_{model,i}$  คือ ค่าที่ได้จากแม่แบบในเวลา  $i$

$N$  คือ จำนวนตัวอย่างทดสอบทั้งหมด

2) การหาค่าความเชื่อมั่นของเครื่องมือ ดังแสดงในสมการที่ (2)-(4)

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

โดยที่

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

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

3) การหาค่าความถูกต้อง ดังแสดงในสมการที่ (5)

$$Accuracy = \frac{(TP + TN)}{N} \quad (5)$$

เมื่อ  $N$  คือ จำนวนตัวอย่างที่ทดสอบทั้งหมด

$TP$  คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสที่

กำลังสนใจอยู่ (ทำนายว่าจริง และมีค่าเป็นจริง)

$TN$  คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสที่ไม่ได้สนใจอยู่ (ทำนายว่าไม่จริง และมีค่าไม่จริง)

### 2.3 วัสดุ อุปกรณ์ที่ใช้ในงานวิจัย


วัสดุ อุปกรณ์ และเครื่องมือที่ใช้ในการวิจัยเชิงทดลองนี้ ได้แก่ เครื่องคอมพิวเตอร์โน้ตบุ๊ก รุ่น Intel®Core™ i5-7200U CPU@ 2.50GHz 2.71GHz Ram12.0 GB 64-bit ซอฟต์แวร์ที่ใช้ในงานวิจัยนี้คือโปรแกรม Python Tensorflow, Open CV อุปกรณ์ถ่ายภาพโดยใช้สมาร์ตโฟนยี่ห้อ iPhone 11 ความละเอียดของกล้องถ่ายภาพมีความละเอียด 12 ล้านพิกเซล และภาพถ่ายใบสับประรดที่เป็นโรคเหี่ยว เป็นภาพสีแบบ RGB นามสกุลของภาพคือ .JPG จากแหล่งปลูกสับประรดอำเภอบ้านคา จังหวัดราชบุรี จำนวน 865 ภาพ

### 2.4 ขั้นตอนและวิธีการวิจัย

ในพัฒนาระบบการวิเคราะห์โรคเหี่ยวของใบสับประรดด้วยการประมวลผลภาพ ได้จัดทำขั้นตอนในภาพรวมของการดำเนินการวิจัย โดยแบ่งเป็น 3 ขั้นตอน ดังมีรายละเอียดดังรูปที่ 2

|                  |              | Positive (1) |    |
|------------------|--------------|--------------|----|
| Predicted Values | Positive (1) | TP           | FP |
|                  | Negative (0) | FN           | TN |

ตัวอย่างตาราง Confusion Matrix ขนาด 2x2



รูปที่ 2 แสดงแบบจำลองขั้นตอนการทำงานของระบบการวิเคราะห์โรคเหี่ยวของใบสับประรดจากการประมวลผลภาพและโครงข่ายประสาทเทียมแบบคอนโวลูชัน

จากรูปที่ 2 แสดงรายละเอียดขั้นตอนการทำงานของระบบการจำแนกโรคเหี่ยวของใบสับประรด โดยมี 3 ขั้นตอน ดังนี้ ขั้นตอนที่ 1 ขั้นตอนข้อมูลภาพ (Input Image) เป็นการนำภาพถ่ายเข้าสู่ระบบ ขั้นตอนที่ 2 ขั้นตอนการฝึกฝนและเรียนรู้ (Train Image) และขั้นตอนที่ 3 การทดสอบระบบ (Test Image) เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด



รูปที่ 3 ตัวอย่างภาพใบสับปะรดที่เป็นโรคเหี่ยว



รูปที่ 4 ตัวอย่างภาพถ่ายที่แสดงจากระบบ

ดังแสดงรายละเอียดของแต่ละขั้นตอนต่อไปนี้


#### ขั้นตอนที่ 1 ข้อมูลภาพ

ข้อมูลที่ใช้ในงานวิจัยนี้ใช้ภาพถ่ายใบสับปะรดที่เป็นโรคเหี่ยว จากแปลงปลูกสับปะรดในพื้นที่อำเภอบ้านคา ซึ่งเป็นแหล่งปลูกสับปะรดที่ใหญ่ที่สุดของจังหวัดราชบุรี นำมาทำการตัดใบออกจากลำต้นเพื่อทำการถ่ายภาพตั้งแต่โคนใบถึงปลายใบของสับปะรด ดังตัวอย่างรูปที่ 3

หลังจากนั้นทำการกำหนดภาพให้มีขนาดของภาพให้มีความสูง 1478 และกว้าง 240 พิกเซล โดยใช้โปรแกรมภาพที่ได้จะเป็นภาพสี RGB และระบบสีพื้นฐานในสายตามนุษย์ (HSB) คือ ลักษณะของสีสีน (H) คุณลักษณะความอิ่มตัวของสี (S) และความสว่างของสี (B) ซึ่งจะทำให้ทราบถึงระดับการเป็นโรคเหี่ยวในใบสับปะรดสามารถแยกแยะการเป็นโรคได้มากกว่าการวิเคราะห์สีเฉพาะ RGB เพียงอย่างเดียว โดยขั้นตอนนี้มีการนำภาพเข้าสู่ระบบ และทำการสกัดคุณลักษณะเพื่อแยกองค์ประกอบ เช่น ขอบ สี รูปทรง พื้นหลัง ดังแสดงในรูปที่ 4

#### ขั้นตอนที่ 2 การฝึกฝนและเรียนรู้

ขั้นตอนนี้เป็นขั้นตอนการฝึกสอนให้กับระบบที่ได้พัฒนาขึ้นได้ทำการเรียนรู้ เพราะก่อนที่ระบบคอมพิวเตอร์จะสามารถแยกแยะได้นั้นต้องมีการใส่ข้อมูลภาพถ่ายเพื่อฝึกฝนหรือเรียนรู้ให้กับระบบคอมพิวเตอร์ก่อน ในขั้นตอนนี้



รูปที่ 5 ตัวอย่างภาพถ่ายใบสับปะรดที่เป็นโรคเหี่ยว โดยแบ่งเป็น 4 คลาส


เป็นการนำภาพถ่ายเข้าสู่ระบบ เพื่อให้คอมพิวเตอร์ใช้ฝึกฝนและเรียนรู้จดจำลักษณะที่เกี่ยวข้องกับภาพที่นำเข้า โดยใช้โครงข่ายประสาทเทียมร่วมกับการประมวลผลภาพ เพื่อใช้เป็นเครื่องมือในการนำไปใช้จดจำ แยกแยะและจัดหมวดหมู่ของภาพถ่ายใบสับปะรดที่ได้รับรวบรวมมา เช่น ลักษณะของใบสับปะรด แบ่งความเข้มของสี จำแนกลักษณะอาการของโรค ภาพวัชพืช ภาพดิน ภาพอื่น ๆ ที่ไม่เกี่ยวข้องกับสับปะรดที่ติดมากับภาพถ่าย ทำการสลับพื้นหลังของภาพออก หลังจากนั้นทำการแบ่งคลาสของภาพออกเป็น 4 คลาส ได้แก่ คลาสที่ 1 ภาพเต็มใบ จำนวน 217 ภาพ คลาสที่ 2 ภาพส่วนปลายใบ จำนวน 216 ภาพ คลาสที่ 3 ภาพกลางใบ จำนวน 216 ภาพ และคลาสที่ 4 ภาพโคนใบ จำนวน 216 ภาพ ดังตัวอย่างรูปที่ 5

ในขั้นตอนนี้ผู้วิจัยได้กำหนดให้คอมพิวเตอร์เรียนรู้ซ้ำ ๆ จำนวน 10 รอบ ผลการฝึกฝนที่ได้ดังแสดงรายละเอียดในรูปที่ 6 (ก)-(ค) แสดงค่าที่สูงขึ้นในแต่ละรอบ ดังแสดงรายละเอียดในตารางที่ 1


รูปที่ 6 จะเห็นได้ว่าค่าความถูกต้องที่ได้จากการเรียนรู้และฝึกฝนซ้ำ ๆ ทำให้ระบบสามารถเรียนรู้ได้ดีขึ้นในทุก ๆ รอบ ทำให้ผลที่ได้ในแต่ละรอบสูงขึ้น เช่น ฝึกฝนรอบที่ 1 ได้ค่าความถูกต้อง (Accuracy) เพียงร้อยละ 0.1481 แต่ในรอบที่ 10 ระบบสามารถแสดงค่าความถูกต้องได้มากถึงร้อยละ 0.9630 ดังแสดงรายละเอียดในตารางที่ 1

```
Epoch 1/10
11/11 [=====]
_loss: 2.5988 - val_accuracy: 0.1481
Epoch 2/10
11/11 [=====]
_loss: 1.0326 - val_accuracy: 0.5926
Epoch 3/10
11/11 [=====]
_loss: 0.4413 - val_accuracy: 0.7778
Epoch 4/10
11/11 [=====]
_loss: 0.9606 - val_accuracy: 0.7037
Epoch 5/10
11/11 [=====]
_loss: 0.2602 - val_accuracy: 0.9259
Epoch 6/10
11/11 [=====]
_loss: 0.1737 - val_accuracy: 0.9630
Epoch 7/10
11/11 [=====]
_loss: 0.1663 - val_accuracy: 0.9259
Epoch 8/10
11/11 [=====]
_loss: 0.1982 - val_accuracy: 0.9630
Epoch 9/10
11/11 [=====]
_loss: 0.0781 - val_accuracy: 0.9630
Epoch 10/10
11/11 [=====]
_loss: 0.1329 - val_accuracy: 0.9630
```

(ก)



(ข)



(ค)

รูปที่ 6 ค่าความถูกต้องจากระบบจำนวน 10 รอบ

ตารางที่ 1 ผลการฝึกฝนเรียนรู้ของเครื่องจำนวน 10 รอบ

| การฝึกฝนเรียนรู้ (รอบ) | ความถูกต้อง (Accuracy) |
|------------------------|------------------------|
| รอบที่ 1               | 0.1481                 |
| รอบที่ 2               | 0.5926                 |
| รอบที่ 3               | 0.7778                 |
| รอบที่ 4               | 0.7037                 |
| รอบที่ 5               | 0.9259                 |
| รอบที่ 6               | 0.9630                 |
| รอบที่ 7               | 0.9259                 |
| รอบที่ 8               | 0.9630                 |
| รอบที่ 9               | 0.9630                 |
| รอบที่ 10              | 0.9630                 |

จากตารางที่ 1 จะเห็นได้ว่าค่าความถูกต้องในแต่ละรอบจะสูงขึ้น จากรอบที่ 1 ถึง 5 จะมีค่าความห่างของความถูกต้องอย่างชัดเจน ในขณะที่เดียวกันรอบที่ 5 ถึง 10 มีความห่างของค่าความถูกต้องน้อยมาก ค่าความถูกต้องหยุดนิ่งตั้งแต่รอบที่ 8 จนถึงรอบที่ 10 คือ 0.9630 จะเห็นได้ว่าถ้ามีการเพิ่มรอบให้ระบบได้มีการฝึกฝนและเรียนรู้ที่มากขึ้น ค่าความถูกต้องก็จะสูงขึ้นเช่นกัน กล่าวได้ว่าจำนวนรอบของการเรียนรู้ที่มากขึ้นส่งผลต่อค่าความถูกต้องที่มากขึ้นเช่นกัน

(ก)



Image is Image0\_Full 98.94%

(ข)



Image is Image1\_Head 98.08%

(ค)



Image is Image2\_Midem 98.96%

(ง)



Image is Image3\_Last 96.32%

รูปที่ 7 ค่าความถูกต้องที่ได้จากขั้นตอนการทดสอบ

### ขั้นตอนที่ 3 การทดสอบระบบ

โดยในขั้นตอนที่ผ่านมาได้นำภาพถ่ายใบสับปะรดที่เป็นโรคเหี่ยว จำนวน 865 ภาพ ที่ได้ทำการแบ่งส่วนภาพออกเป็นคลาส จำนวน 4 คลาสพร้อมทั้งสกัดภาพพื้นหลังออกแล้ว หลังจากนั้นเข้าสู่ขั้นตอนการฝึกสอนให้กับระบบเพื่อให้เรียนรู้ โดยให้ระบบทำการเรียนรู้จำนวน 10 รอบเพื่อให้ระบบได้ฝึกเรียนรู้ได้ดียิ่งขึ้น หลังจากนั้นเข้าสู่ขั้นตอนของการทดสอบ ซึ่งขั้นตอนนี้จะใช้ภาพถ่ายใบสับปะรดที่เป็นโรคเหี่ยวที่จัดเตรียมไว้สำหรับทดสอบที่ไม่ได้ผ่านการประมวลผลภาพ จำนวน 4 คลาส คลาสละ 10 ภาพ รวมทั้งสิ้น 40 ภาพ ผลการทดสอบระบบที่พัฒนาขึ้น ค่าความถูกต้องที่ได้จากการนำภาพที่เตรียมไว้สำหรับการทดสอบระบบที่พัฒนาขึ้นในการวิจัยครั้งนี้ ผลปรากฏดังแสดงรายละเอียดตามรูปที่ 7 แสดงค่าความถูกต้องที่ได้จากขั้นตอนการทดสอบ โดยที่รูปที่ 7 (ก) คือ ภาพของส่วนเต็มใบ มีค่าความถูกต้องร้อยละ 98.94 รูปที่ 7 (ข) คือ ภาพของ

ส่วนปลายใบ มีค่าความถูกต้องร้อยละ 98.08 รูปที่ 7 (ค) คือ ภาพของส่วนกลางใบ มีค่าความถูกต้องร้อยละ 98.96 และรูปที่ 7 (ง) คือ ภาพส่วนของโคนใบ มีค่าความถูกต้องร้อยละ 96.32

จากขั้นตอนที่กล่าวมา โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks; CNN) ซึ่งการออกแบบการเรียนรู้ในแต่ละชั้นได้มาจากการใช้การคำนวณแต่ละลำดับชั้น (Layer) ซึ่งผลลัพธ์ที่ได้จากการออกแบบระบบสรุปได้ดังตารางที่ 2

**ตารางที่ 2** สรุปการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)

| Layer (type)                   | Output Shape          | Param#   |
|--------------------------------|-----------------------|----------|
| Conv2d_3 (Conv2D)              | (none, 1472, 240, 16) | 448      |
| Max_pooling2d_3 (MaxPooling2D) | (none, 739, 120, 16)  | 0        |
| Conv2d_4 (Conv2D)              | (none, 739, 120, 32)  | 4640     |
| Max_pooling2d_4 (MaxPooling2D) | (none, 369, 60, 32)   | 0        |
| Conv2d_5 (Conv2D)              | (none, 369, 60, 64)   | 18496    |
| Max_pooling2d_5 (MaxPooling2D) | (none, 184, 30, 64)   | 0        |
| Conv2d_6 (Conv2D)              | (none, 184, 30, 128)  | 73856    |
| Max_pooling2d_6 (MaxPooling2D) | (none, 92, 15, 128)   | 0        |
| Dropout (Dropout)              | (none, 92, 15, 128)   | 0        |
| Flatten_1 (Flatten)            | (none, 176640)        | 0        |
| Dense_2 (Dense)                | (none, 128)           | 22610048 |
| Dense_3 (Dense)                | (none, 4)             | 516      |
| Total papams : 22,708,004      |                       |          |
| Trainable params : 22,708,004  |                       |          |
| Non-trainable params : 0       |                       |          |

### 3. ผลการทดลอง

ผลการทดลองการวิจัยในครั้งนี้ ผู้วิจัยมุ่งเน้นค่าความถูกต้องของการวิเคราะห์โรคเหี่ยวใบสับปะรดร่วมกับเทคนิคการประมวลผลภาพโดยใช้ภาพถ่ายดิจิทัล ซึ่งเป็นภาพถ่าย

ที่ถ่ายจากใบของสับปะรดที่เป็นโรคเหี่ยว โดยแบ่งขั้นตอนการวิจัยออกเป็น 3 ขั้นตอน โดยที่ใบสับปะรดหนึ่งใบจะได้ภาพถ่ายดิจิทัลจำนวน 4 ภาพ (4 คลาส) การฝึกฝนและเรียนรู้เป็นขั้นตอนที่มีความสำคัญอย่างยิ่ง เนื่องจากการที่เครื่องคอมพิวเตอร์จะสามารถวิเคราะห์หรือแยกประเภทของภาพได้นั้นต้องทำให้เครื่องเรียนรู้และเข้าใจก่อนว่าภาพถ่ายแต่ละชนิดคือ ส่วนใดของใบสับปะรด ซึ่งผลการฝึกฝนและเรียนรู้ของระบบจำนวน 10 รอบ จากตารางที่ 1 จะเห็นได้ว่าค่าความถูกต้องในแต่ละรอบจะสูงขึ้น จากรอบที่ 1 ถึงรอบที่ 10 มีค่าความถูกต้อง 0.9630 ในขั้นตอนของการทดสอบ นำภาพถ่ายใบสับปะรดที่เป็นโรคเหี่ยวที่ได้จัดเตรียมไว้สำหรับการนำมาทดสอบระบบ เป็นภาพถ่ายที่ไม่ได้นำเข้าสู่ขั้นตอนการฝึกฝนเรียนรู้ของเครื่อง ซึ่งใช้ภาพในแต่ละส่วนที่แตกต่างกัน จำนวน 4 คลาส ดังแสดงรายละเอียดค่าความถูกต้องในตารางที่ 3

**ตารางที่ 3** ผลการทดสอบจากภาพถ่าย จำนวน 4 คลาส

| ประเภทของภาพ (คลาส)  | ค่าความถูกต้อง (Accuracy) |
|----------------------|---------------------------|
| คลาสที่ 0 ส่วนเต็มใบ | 98.94                     |
| คลาสที่ 1 ส่วนปลายใบ | 98.08                     |
| คลาสที่ 2 ส่วนกลางใบ | 98.96                     |
| คลาสที่ 3 ส่วนโคนใบ  | 96.32                     |

ตารางที่ 3 จากการนำภาพถ่ายของแต่ละคลาสที่แตกต่างกันในแต่ละส่วน จำนวน 4 ภาพ ผลการทดสอบปรากฏว่า คลาสที่ 2 ส่วนกลางใบ มีค่าความถูกต้องสูงที่สุดคือ 98.96 ลงลงมา คือ คลาสที่ 0 ส่วนเต็มใบ มีค่าความถูกต้องอยู่ที่ 98.94 คลาสที่ 1 ส่วนปลายใบ มีค่าความถูกต้องอยู่ที่ 98.08 ส่วนคลาสที่ 3 ส่วนโคนใบ มีค่าความถูกต้องน้อยที่สุด อยู่ที่ 96.32

สำหรับค่า Precision Recall และ F1-score ของการสอนโครงข่ายแต่ละรอบนั้น แสดงในรูปที่ 8 ซึ่งเมื่อทำการสอบแบบจำลองครบทั้ง 10 รอบแล้วมีค่า 0.99 0.99 และ 0.99 ตามลำดับ

Accuracy : 98.95500000

| Report :     | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 0            | 0.99      | 1.00   | 0.99     | 10      |
| 1            | 0.99      | 0.96   | 0.97     | 10      |
| 2            | 0.99      | 1.00   | 0.99     | 10      |
| 3            | 0.99      | 1.00   | 0.99     | 10      |
| accuracy     |           |        | 0.99     | 40      |
| macro avg    | 0.99      | 0.99   | 0.99     | 40      |
| weighted avg | 0.99      | 0.99   | 0.99     | 40      |

รูปที่ 8 ค่า Precision, Recall และ F1-score

#### 4. อภิปรายผลและสรุป

งานวิจัยนี้ได้ศึกษาและพัฒนากระบวนการวิเคราะห์โรคเหี่ยวของใบสับปะรดด้วยภาพถ่ายดิจิทัล เป็นการประยุกต์ใช้เทคนิควิธีการประมวลผลภาพดิจิทัลร่วมกับโครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นเครื่องมือที่สำคัญในปัจจุบันที่สามารถนำมาประยุกต์ใช้งานได้หลากหลายด้าน ไม่ว่าจะเป็นทางด้านอุตสาหกรรม เช่น อุตสาหกรรมการผลิต การแพทย์ การขนส่ง และการเกษตร เป็นต้น เพื่อช่วยในการตรวจสอบ แยกประเภท จัดหมวดหมู่ วิเคราะห์ได้อย่างถูกต้องและมีความแม่นยำสูง จากผลการวิจัยเชิงทดลองนี้แสดงให้เห็นว่าการพัฒนาระบบการวิเคราะห์โรคเหี่ยวจากใบของสับปะรดด้วยการประมวลผลภาพและโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้พัฒนาขึ้นมาในงานวิจัยนี้ สามารถวิเคราะห์โรคเหี่ยวจากภาพถ่ายได้ ซึ่งมีค่าความถูกต้องที่สูงนั้นมีสาเหตุมาจากเป็นภาพถ่ายที่นำมาจากต้นของสับปะรดเพื่อนำเข้าห้องปฏิบัติการ ขั้นตอนการนำภาพเข้าสู่ระบบนั้นได้มีการเตรียมภาพและการแบ่งคลาสที่มีความชัดเจนมากเพื่อนำไปสู่การประมวลผลภาพในขั้นตอนการฝึกฝนเรียนรู้ของระบบ และในส่วนของการขั้นตอนของการทดสอบระบบที่มีการทำนายผิดพลาดนั้น อาจมีสาเหตุมาจากการนำภาพที่ไม่ได้ผ่านการประมวลผลภาพ มาทำการทดสอบกับระบบทำให้ระบบมีความคลาดเคลื่อนในการแยกแยะภาพในคลาสต่าง ๆ ได้ ส่วนในอนาคตควรปรับปรุงวิธีการจากห้องปฏิบัติการให้สามารถวิเคราะห์โรคเหี่ยวได้จากแปลงปลูกสับปะรดได้โดยไม่ต้องตัดใบมาวิเคราะห์และสามารถทำนายการเกิดโรคเหี่ยวได้เพื่อลดการสูญเสียจากการเกิดโรคเหี่ยวของใบสับปะรดได้

งานวิจัยนี้ได้มีการเปรียบเทียบประสิทธิภาพค่าความถูกต้องระหว่างการวิเคราะห์โรคเหี่ยวจากใบของสับปะรดด้วยการประมวลผลภาพกับการงานวิจัยอื่น ๆ ด้วยขั้นตอนวิธีการเรียนรู้เชิงลึกแบบคอนโวลูชัน (Convolutional Neural Network; CNN) ในการนำมาประยุกต์ใช้เพื่อจำแนกประเภทของข้อมูลในการวิเคราะห์โรคพืช ดังแสดงในตารางที่ 4

ตารางที่ 4 เปรียบเทียบประสิทธิภาพค่าความถูกต้องระหว่างการวิเคราะห์โรคเหี่ยวจากใบของสับปะรดด้วยการประมวลผลภาพกับการงานวิจัยอื่น ๆ ด้วยขั้นตอนวิธีการเรียนรู้เชิงลึกแบบสังวัตนาการในการจำแนกประเภทข้อมูลเพื่อการวิเคราะห์โรคพืช

| No | Algorithm                                   | Accuracy (%) |
|----|---------------------------------------------|--------------|
| 1  | MobileNet (Kamal, 2019) [10]                | 98.34        |
| 2  | AlexNet models, GPDCNN (Shanwen, 2019) [11] | 95.18        |
| 3  | DenseNets (Edna, 2019) [12]                 | 99.75        |
| 4  | AlexNet (K. Thenmozhi, 2019) [13]           | 96.75        |
| 5  | Septoria (Artzai, 2019) [14]                | 96.00        |
| 6  | Pineapple Leaf Wilt Analysis                | 98.96        |

จากตารางแสดงการเปรียบเทียบความถูกต้อง สามารถนำไปเป็นต้นแบบในงานด้านต่าง ๆ ได้อีกด้วย ซึ่งสอดคล้องกับงานวิจัยของ Too และคณะ [15] ศึกษาการเปรียบเทียบรูปแบบการเรียนรู้เชิงลึกสำหรับการจำแนกโรคพืช เป็นการใช้โครงข่ายประสาทเทียมเชิงลึก จำแนกประเภทโรคพืชด้วยภาพใบไม้ได้ค่าความถูกต้อง 99.75% ซึ่งสอดคล้องกับงานวิจัยของ Geetharamani และ Pandian [16] ระบุโรคใบพืชมโดยการใช้องค์ข่ายประสาทเทียมแบบเก่าขึ้น การฝึกฝนโดยใช้ชุดข้อมูลแบบเปิด ใช้ภาพใบพืชที่มีพื้นหลัง 39 ชนิดได้ความถูกต้อง 96.46% และยังสอดคล้องกับงานวิจัยของ Barbedo และคณะ [17] ได้ทำการวิเคราะห์โรคหลายชนิดโดยใช้ระบบการประมวลผลภาพดิจิทัล นำภาพถ่ายด้วยกล้องดิจิทัล จากพืช จำนวน 12 ชนิดที่แตกต่างกัน ได้แก่ ถั่วทั่วไป มันสำปะหลัง พืชตระกูลส้ม มะพร้าว ข้าวโพด กาแฟ ฝ้าย

อรุณ เสาวรส ถั่วเหลือง อ้อย และข้าวสาลี ทำการทดสอบกับระบบการจำแนกแบบการจำคู่กับต้นฉบับในฐานข้อมูลขนาดใหญ่ นำภาพมาฝึกฝน 70% และทดสอบ 30% พบว่าสามารถจับคู่โรคพืชกับฐานข้อมูลได้ 40–76%

### เอกสารอ้างอิง

- [1] Office of Agricultural Economics. (2023, July 28). *Pineapple yield*. [Online]. Available: <https://www.egov.go.th/th/government-agency/128/>.
- [2] Department of Internal Trade. (2022, May 15). *Pineapple yield*. [Online]. Available: <https://www.oae.go.th/view/1/> Table showing details of pineapple plant /TH-TH.
- [3] Department secretary office Department of Agricultural Extension. (2022, August 19). *Pineapple yield*. [Online]. Available: <https://doanews.doag.go.th>.
- [4] Agricultural Research Development Agency. (2020, August 19). *Pineapple yield*. [Online]. Available: <https://arda.or.th/kasetdata.php>.
- [5] Office of Industrial Economics Ministry of Industry. (2023, July 28). *Pineapple yield*. [Online]. Available: <https://www.oie.go.th/vive/1/Home/TH-TH>.
- [6] U. Lertuschatavanich and P. Suebsaiprom, "Application of image processing for assessment disease severity of rice," in *Proceedings of 51st Kasetsart University Annual Conference: Plants*, 2013, vol. 51, pp. 361–368 (in Thai).
- [7] T. Sawaengmee, S. Najaitong, N. Wangno, and K. Sunat, "Analysis of plant diseases on leaves application on android using support vector machine," in *The Thirteenth National Conference on Computing and Information Technology*, 2017, pp. 483–489 (in Thai).
- [8] N. Chinpanthana, S. Phainoun, and P. Chotsuriyasinsukh, "A study on research in digital image processing and its applications," in *National Conference Phetchabun Rajabhat University*, 2016, vol. 3, pp. 546–555 (in Thai).
- [9] S. Aunkaew, T. Khaorapapong, and M. Karnjanadecha, "A study of inspection of white mould on surface rubber sheets using image processing," *Thaksin University Journal*, vol. 10, no. 2, pp. 50–61, 2007 (in Thai).
- [10] K. KC, Z. Yin, M. Wu and Z. Wu, "Depthwise separable convolution architectures for plant disease Classification," *Computers and Electronics in Agriculture*, vol. 165, pp. 104948, 2019.
- [11] S. Zhang, S. Zhang, and C. Zhang, "Cucumber leaf disease identification with global pooling dilated convolutional neural network," *Computers and Electronics in Agriculture*, vol. 162, pp. 422–430, 2019.
- [12] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease Identification," *Computers and Electronics in Agriculture*, vol. 161, pp. 272–279, 2019.
- [13] K. Thenmozhi and U.Srinivasulu Reddy, "Crop pest classification based on deep convolutional neural network and transfer learning," *Computers and Electronics in Agriculture*, vol. 164, pp. 104906, 2019.
- [14] A. Picon, A. A. Gil, M. Seitz, A. O. Barredo, and J. Echazarra "Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild,"



- Computers and Electronics in Agriculture*, vol. 161, pp. 280–290, 2019.
- [15] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, “A comparative study of fine-tuning deep learning models for plant disease identification,” *Computers and Electronics in Agriculture*, vol. 161, pp. 272–279, 2019.
- [16] G. Geetharamani and J. A. Pandian, “Identification of plant leaf diseases using a nine-layer deep convolutional neural network,” *Computers and Electrical Engineering*, vol. 76, pp. 323–338, 2019.
- [17] J. G. A. barbedo, L. V. Koenigkan, and T. Santos, “Identifying multiple plant diseases using digital image processing,” *Biosystems Engineering*, vol. 147, pp. 104–116, 2016.