

การจำแนกภาพโรคใบมะเขือเทศด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน  
**Image Classification of Tomato Leaf Diseases using Convolutional  
Neural Network**

นศพัชฌัน ชินปัญชรณะ

*Nutchanut Chinpanthana*

วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์

110/1-4 ถ.ประชาชื่น เขตหลักสี่ กรุงเทพฯ 10210

*College of Innovative Technology and Engineering, Dhurakij Pundit University, 110/1-4 Prachachuen rd*

*Laksi, Bangkok, 10210.*

Received: June 24, 2023; Revised: December 12, 2023; Accepted: December 20, 2023; Published: December 29, 2023

**ABSTRACT** – Tomato is one of the most important cultivated vegetable plants in the world. The continuous expanded production and consumption of tomato has grown quickly. It is considered a mainstay of many economic country. Tomato crops can be damage due to various kinds of diseases that are recently discovery of diagnosis errors or not prevented and controlled timely. The problems faced by farmers are typically unnoticed and lack knowledge in crop production. For developing an early treatment process, the identify infections of plant diseases in a rapid can help to reduce huge economical suffering. In agricultural practices is detect of disease manually on crops which is very complex, time-consuming and more tedious tasks. This paper discussing the technique base on digital image processing, which employs the convolutional neural network deep learning model to classify tomato leaf diseases. The dataset is classified into 10 classes: bacterial leaf spot, early blight, late blight, leaf mold, septoria leaf spot, two-spotted spider mite, target spot, cucumber mosaic virus, yellow leaf curl virus and fresh leaf. The approach is composed of four main phases: (1) data preprocessing, (2) generated model convolutional neural network, and (3) model evaluation and (4) deployment. The experimental results indicated that deep learning with convolutional neural network technique has the highest effectiveness in recognizing tomato leaf diseases with the total average accuracy at 87.96% at learning rate 0.001 for 100 epochs.

**KEYWORDS:** Image Classification, Tomato Leaf Diseases, Deep Learning, Convolutional Neural Networks, Image Processing

บทคัดย่อ -- มะเขือเทศเป็นพืชที่ทั่วโลกนิยมบริโภคกันอย่างแพร่หลาย ทำให้กลายเป็นพืชทางเศรษฐกิจที่สำคัญในหลายประเทศ และเมื่อมีการขยายพันธุ์เพิ่มขึ้นทำให้มะเขือเทศเกิดเป็นโรคต่างๆเพิ่มขึ้นและบางโรคก็เพิ่งถูกค้นพบ ปัญหาที่มักเกิดขึ้นคือเกษตรกรขาดความรู้ ความเชี่ยวชาญในกลุ่มโรคทำให้มีการวินิจฉัยผิดพลาดรวมทั้งไม่ได้มีการป้องกันและควบคุมโรคอย่างทันทั่วทั้งที่ทำให้เกิดปัญหาตามมา ถ้าเกษตรกรสามารถระบุการติดเชื้อโรคได้รวดเร็ว ก็จะสามารถช่วยลดปัญหาของการเกิดโรคได้ ดังนั้นจึงควรพัฒนากระบวนการดูแลพืชในระยะเริ่มต้น การระบุการติดเชื้อของโรคพืชอย่างรวดเร็วสามารถช่วยแก้ไขปัญหาก็ได้ การตรวจหาโรคใบมะเขือเทศด้วยตนเองเป็นงานที่ซับซ้อนยากลำบากและใช้เวลา ดังนั้นในงานวิจัยนี้ได้นำเสนอเทคนิคการประมวลผลภาพด้วยการเรียนรู้เชิงลึกผ่านโครงข่ายประสาทเทียมแบบคอนโวลูชัน เพื่อทำการจำแนกโรคใบมะเขือเทศแบ่งออกเป็น 10 กลุ่ม โรคใบจุดแบคทีเรีย โรคใบจุดวง โรคใบไหม้ โรคราก่ามะหะยี โรคใบจุดวงกลม โรคใบสองจุด โรคใบจุดเป่ากระสุน โรคใบด่างลิบ โรคใบหงิก

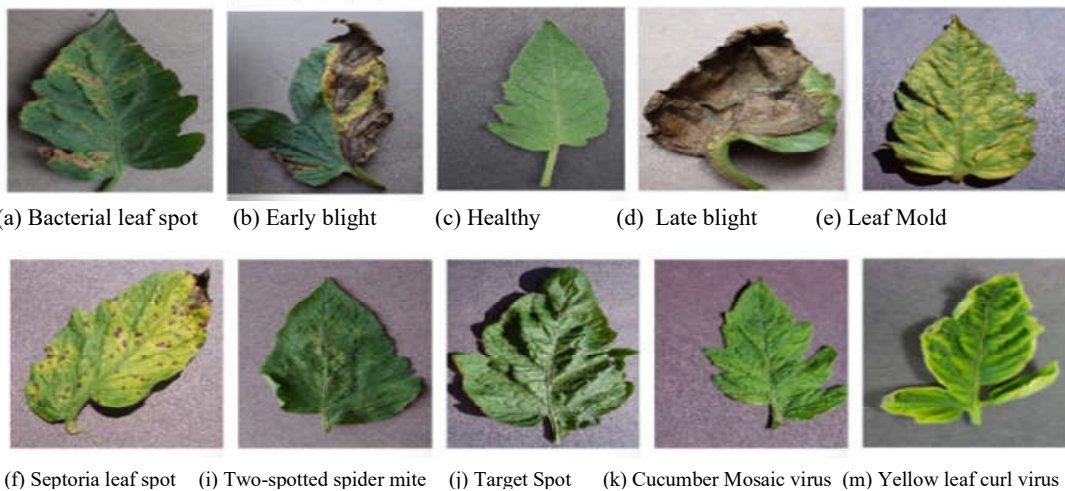
เหลือง และ ใบมะเขือเทศปกติ ประกอบด้วยขั้นตอนการทำงานดังนี้ (1) ขั้นตอนการเตรียมข้อมูล (2) การสร้างโมเดล CNN (3) การประเมินผลโมเดล และ (4) การนำโมเดลไปใช้งาน การเรียนรู้เชิงลึก ผลลัพธ์ที่ได้จากการทดลองด้วยคุณลักษณะข้อมูลผ่านกระบวนการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้ผลการทดลองที่มีประสิทธิภาพสูงสามารถจำแนกโรคใบมะเขือเทศได้ด้วยค่าความเฉลี่ยความถูกต้องรวมอยู่ที่ 87.96% ด้วยอัตราการเรียนรู้ 0.001 ที่จำนวน 100 รอบสำหรับชุดทวนทดสอบ

คำสำคัญ: การจำแนกข้อมูลภาพ, โรคใบมะเขือเทศ, การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, ประมวลผลภาพ


## 1. บทนำ

มะเขือเทศเป็นพืชที่ได้รับความนิยมในการปลูก เพราะเป็นพืชเศรษฐกิจระดับต้นๆของประเทศ การปลูกมะเขือเทศจะต้องมีสภาพภูมิประเทศที่เหมาะสม โดยเฉพาะภาคเหนือ และภาคตะวันออกเฉียงเหนือเป็นแหล่งปลูกมะเขือเทศสำคัญ ปัจจุบันการปลูกมะเขือเทศยังต้องขยายพื้นที่ปลูก และกระจายอยู่ทั่วทุกภาคของประเทศการแปรเปลี่ยนของสภาพภูมิอากาศทำให้เกิดสภาวะโลกร้อน อุณหภูมิเฉลี่ยของพื้นผิวโลกที่เพิ่มขึ้น ทำให้ส่งผลกระทบต่อสรีระวิทยาและทางกายภาพของต้นพืช ไม่ว่าจะเป็นการสังเคราะห์แสง การแบ่งเซลล์ การลำเลียงน้ำ อาหาร รวมไปถึงความผิดปกติที่เกิดขึ้นนี้อาจทำให้คุณภาพของผลผลิตลดลง พืชอ่อนแอต่อการเกิดโรคด้วยเช่นกันดังนั้นสภาพแวดล้อมที่ไม่เหมาะสมจะเป็นสาเหตุของการเกิดโรคได้ ปัจจุบันเกษตรกรที่ปลูกมะเขือเทศประสบปัญหาจากโรคเหี่ยวเหี่ยวเหี่ยวเหลือง และโรคใบจุดมะเขือเทศมีสาเหตุเกิดจากเชื้อแบคทีเรียในกลุ่มชานโทโมนาสหลายชนิด (Genus Xanthomonas) โรคนี้พบได้ในแหล่งปลูกมะเขือเทศและพริกทั่วโลก [1] โดยเฉพาะในเขตสภาพอากาศร้อนชื้น เชื้อทำให้เกิดอาการแผลจุดขนาดเล็กสีน้ำตาลที่ใบ ลำต้นและจุดแผลมีสีเหลือง

ล้อมรอบเป็นจุดแผลตายขนาดเล็กเชื่อมต่อกันลักษณะใบไหม้และใบร่วงก่อนกำหนดได้ทำให้เกิดความเสียหายอย่างมาก เกษตรกรส่วนใหญ่ควบคุมโรคเหี่ยวเหี่ยวและเหี่ยวเหลืองมะเขือเทศได้ด้วยสารเคมีถ้าระบาดในแปลงปลูก ฟันด้วยสารป้องกันกำจัดโรคพืช เช่น ไดเทนเอ็ม-45 แคปแตน แมนโคเซ็บ หรือ กูราราวิท ไธรมซี เน็บ มาเน็บ หรือใช้สารชีวภัณฑ์ เช่น เชื้อราไตรโคเดอร์มา เชื้อแบคทีเรียบาซิลลัส คอลลัมเบียด้วยสารป้องกันกำจัดโรคพืชที่สามารถกำจัดเชื้อสาเหตุที่ติดมากับเมล็ดพันธุ์ได้ เช่น แมนโคเซ็บ ไอโพรไดโอน การปลูกมะเขือเทศผสมผสานระหว่างสารเคมีและสารอินทรีย์ อีกทั้งการปลูกมะเขือเทศโดยชีววิธีด้วยแบคทีเรียปฏิบัญ จะทำให้เกษตรกรมีผลผลิตมะเขือเทศและรายได้เพิ่มขึ้น [2] แสดงให้เห็นว่าแบคทีเรียปฏิบัญสามารถป้องกันและควบคุมการระบาดของโรคเหี่ยวเหี่ยวและโรคเหี่ยวเหลืองได้อย่างมีประสิทธิภาพ และเชื่อมั่นว่าแบคทีเรียปฏิบัญสามารถใช้ในการควบคุมโรคใบมะเขือเทศได้จริง การป้องกันกำจัดศัตรูพืชด้วยการใช้สารเคมีทางการเกษตรในการควบคุมจะเกิดประสิทธิภาพถึง 80% อย่างไรก็ตามสารฆ่าแมลงเป็นสารพิษที่ก่อให้เกิดอันตรายต่อมนุษย์และสารพิษที่ตกค้างในอาหาร รวมทั้งยังทำลาย



รูปที่ 1. ภาพตัวอย่างกลุ่มการจำแนกโรคใบมะเขือเทศ



รูปที่ 2. ขั้นตอนการจำแนกโรคใบมะเขือเทศ

สภาพแวดล้อมแมลงศัตรูธรรมชาติและแมลงที่เป็นประโยชน์ในระบบนิเวศ ดังนั้นเพื่อเป็นแนวทางลดการใช้สารเคมีและความปลอดภัยของผู้บริโภคจึงจำเป็นต้องมีการพัฒนาสิ่งทดแทนการใช้สารเคมี นักวิจัยบางกลุ่มได้มีการนำเกษตรอินทรีย์เข้ามาใช้ป้องกันกำจัดแมลงศัตรูพืชแบบผสมผสาน[3] เช่น ไคโตซาน (Chitosan) เป็นสารจากธรรมชาติที่ได้จากเปลือกกุ้งหรือปู เข้ามาใช้ควบคุมศัตรูพืช และสารสกัดจากพืชเป็นหลัก เช่น สารสะเดา สารสกัดหางไหลแดง สารสกัดว่านหางจระเข้ น้ำส้มควันไม้ เป็นต้น พบว่า การฉีดพ่นแบบถูกตัวศัตรูพืช ทำให้ตายภายในเวลา 48 ชั่วโมง และสารสกัดว่านหางจระเข้ สารสกัดหางไหลแดง และน้ำส้มควันไม้สามารถยับยั้ง ชะลอการระบาดของศัตรูพืชได้ไม่แตกต่างกับการใช้สารเคมี

## 2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยครั้งนี้ได้ศึกษาประเภทของโรคในใบมะเขือเทศประกอบกับการใช้ ทฤษฎีการประมวลผลภาพร่วมกับการประยุกต์ใช้กระบวนการเรียนรู้เชิงลึกเพื่อจำแนกโรคใบมะเขือเทศ

### 2.1 โรคใบมะเขือเทศ

มะเขือเทศ เป็นพืชที่มีความสำคัญและในบางช่วงฤดูมะเขือเทศจะเจริญเติบโตช้าและยังมีแมลงมารบกวน จึงเป็นสาเหตุสำคัญทำให้เกิดโรคทางใบระบาดรุนแรง สามารถจำแนกโรคใบมะเขือเทศ [4] ไว้ดังนี้(1) โรคใบจุดแบคทีเรีย (bacterial leaf spot) (2) โรคใบจุดวง (Early blight) (3) โรคใบไหม้ (Late blight) (4) โรคคราก่ามะหี (Leaf mold) (5) โรคใบจุดวงกลม (Septoria leaf spot) (6) โรคไรสองจุด (Two-spotted spider mite) (7)โรคใบจุดเป้ากระสุน (Target spot) (8) โรคใบค่างสีบ (Cucumber mosaic virus) (9) โรคใบหงิกเหลือง (Yellow leaf curl virus) (10) ภาพใบมะเขือปกติ (Fresh leaf) [4] ดังแสดงตัวอย่างภาพในรูปที่ 1

### 2.2 การประมวลผลภาพ

สำหรับงานวิจัยนี้ข้อมูลนำเข้าเป็นภาพดิจิทัลของใบมะเขือเทศที่อยู่ในรูปแบบ 2 มิติโดยแต่ละพิกเซลถูกเก็บเป็นค่าความเข้มแสง (intensity) ดังนั้นจึงได้นำทฤษฎีการประมวลผลภาพมาใช้จำแนกประเภทข้อมูลภาพ (image classification) ด้วยการตรวจสอบความผิดปกติของใบจากคุณลักษณะพื้นฐานของภาพที่ถูกสกัดคุณลักษณะด้วยอัลกอริทึมต่างๆ ตัวอย่างเช่น สี (color) พื้นผิว (texture) รูปทรง (shape) เป็นต้น และนำคุณลักษณะเหล่านี้มาผสมผสานเพื่อให้เกิดการจำแนกขั้นสูงต่อไป

### 2.3 การเรียนรู้ของเครื่อง

ปัจจุบันการเรียนรู้ทางด้านปัญญาประดิษฐ์ถูกพัฒนาไปอย่างรวดเร็วเพื่อตอบรับกับความต้องการที่เปลี่ยนแปลงไปทำให้งานวิจัยได้มีการประยุกต์ใช้ปัญญาประดิษฐ์เข้ากับการจำแนกข้อมูลภาพให้ตรงตามความหมายของภาพที่ต้องการของผู้ใช้มากที่สุด ดังนั้นจึงได้นำการเรียนรู้เชิงลึก (Deep learning) เข้ามาใช้งานและการเพิ่มประสิทธิภาพการเรียนรู้เพื่อทำให้ผลลัพธ์ที่ดียิ่งขึ้น ด้วยการประยุกต์ใช้วิธีการเรียนรู้เชิงลึกร่วมกับโครงข่ายประสาทเทียม (Neural Networks) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) [5][6] ผลลัพธ์ที่ได้ส่วนใหญ่จะมีค่าความถูกต้องที่เพิ่มขึ้น

### 2.4 งานวิจัยที่เกี่ยวข้อง

ปัจจุบันมีงานวิจัยศึกษาการจำแนกโรคพืชด้วยคุณลักษณะทางพฤกษศาสตร์ และการจำแนกเชื้อด้วยคุณสมบัติด้านพันธุศาสตร์โมเลกุล [7] แต่อย่างไรก็ตามยังคงมีนักวิจัยพยายามจำแนกโรคมะเขือเทศจากลักษณะใบด้วยข้อมูลภาพดิจิทัลเป็นการใช้ทฤษฎีการประมวลผลภาพ เพื่อตรวจสอบลักษณะโรคบนใบมะเขือเทศจากคุณลักษณะพื้นฐานของภาพที่ถูกสกัดคุณลักษณะจากอัลกอริทึมต่างๆ ซึ่งเป็น

การใช้ความรู้ด้านพฤกษศาสตร์ของคุณลักษณะโรคในมะเขือเทศ เพื่อพิจารณาว่ามีรูปแบบอย่างไร ดังนั้นการใช้วิธีการประมวลผลภาพร่วมกับเทคโนโลยีปัญญาประดิษฐ์เพื่อสร้างความสัมพันธ์ของการเรียนรู้คุณลักษณะที่เกิดขึ้นบนใบมะเขือเทศทำให้สามารถจำแนกประเภทของโรคได้อย่างชัดเจนและมีความถูกต้องที่มากที่สุด

การพัฒนาวิธีการเพื่อให้สามารถวิเคราะห์โรคพืชแบบอัตโนมัติเป็นความต้องการของเกษตรกร ทำให้นักวิจัยได้พยายามใช้คุณลักษณะข้อมูลภาพใบมาวิเคราะห์โรคมีหลายวิธีการ เช่น Principal component analysis (PCA), Gamma correction, Noise injection, ข้อมูลสี (color enhancement), การหมุนข้อมูล (rotation) หรือการทำสเกลลิง (scaling) [8] ข้อมูลได้ถูกสกัดเพื่อนำมาเรียนรู้และวิเคราะห์โรคบนใบมะเขือเทศ และในปัจจุบันได้มีการนำโครงข่ายประสาทเทียม เข้ามาใช้ในการวิเคราะห์ รวมทั้งการใช้โมเดล CNN เข้ามาใช้งานด้วยพารามิเตอร์จำนวนมากนักวิจัย Mohanty et al. [8] ได้ใช้ GoogleNet และ AlexNet เพื่อจำแนกโรคทางใบจากฐานข้อมูลภาพใบพืช PlantVillage [9] เมื่อสรุปแล้วค่าเฉลี่ยโดยรวมของการจำแนกโรคพืชด้วย GoogleNet จะได้ค่าความถูกต้องสูงกว่า AlexNet ที่มีการใช้เรียนรู้เชิงลึกด้วยเทคนิค Convolutional Neural Network Model และกลุ่มนักวิจัย Amara et al. [10] ได้จำแนกโรคบนใบกล้วยด้วย LeNet จากคุณลักษณะของสี มีกลุ่มนักวิจัยได้ทำการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อจำแนกโรค Black rot ที่เกิดจากเชื้อรา Botryosphaeria obtuse ของใบแอปเปิ้ล จากฐานข้อมูล PlantVillage [9] และได้มีการใช้โมเดลการเรียนรู้เข้ามาวิเคราะห์โรคบนใบมะเขือเทศเพิ่มมากขึ้นผลสรุปที่ได้มีค่าความถูกต้องสูงถึง 94-95% มีกลุ่มนักวิจัยใช้โมเดล AlexNet และ VGG 19 [11][12] เข้ามาวิเคราะห์โรคมะเขือเทศสามารถวัดค่าความถูกต้องได้ถึง 97.49% เช่นเดียวกันบางกลุ่มใช้โมเดล AlexNet ในการเรียนรู้เชิงลึกเพื่อตรวจหาโรคในมะเขือเทศได้ค่าความถูกต้อง 95.75% และ Resnet-50 ได้ถูกออกแบบเพื่อตรวจหาโรคในใบมะเขือเทศถึง 1,000 โรคจากฐานข้อมูลภาพทั้งหมด 3,000 ภาพ ไม่ว่าจะพบโรค Lesion blight, โรคใบไหม้ (Late blight) หรือ โรคใบหงิกเหลือง (Yellow leaf curl virus) เมื่อมีการเปรียบเทียบและแก้ไขวิธีการ Leaky-ReLU ที่คอนเนลขนาด 11x11 ในคอนโวลูชันแรกแล้ว โมเดลสามารถทำนายโรคได้ด้วยค่าความถูกต้องถึง 98.30% แต่อย่างไรก็ตามยังไม่สามารถจำแนกโรคบนใบมะเขือเทศได้ครบ ดังนั้นในงานวิจัยนี้นำเสนอการจำแนกโรคมะเขือเทศด้วยการสกัดข้อมูลและทำการเรียนรู้เชิงลึก

ด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) ด้วยการเพิ่มฟังก์ชันสำหรับลดความผิดพลาดของการทำงานใน CNN ด้วยวิธี Rectified Linear Unit ที่มีการเปลี่ยนแปลงตลอดเวลา

### 3. วิธีการดำเนินงานวิจัย

ขั้นตอนการจำแนกโรคใบมะเขือเทศ ประกอบด้วย การนำไปใช้งาน การเตรียมข้อมูล (Data Preprocessing) การสร้างโมเดล CNN (Generated Model CNN) การประเมินผลโมเดล (Model Evaluation) และการนำโมเดลไปใช้งาน (Deployment) คือการจำแนกประเภทใบมะเขือเทศที่เป็นโรคดังแสดงในรูปที่ 2 มีรายละเอียดดังต่อไปนี้

#### 3.1 การเตรียมข้อมูล

ขั้นตอนแรกของการดำเนินงานเป็นการเตรียมข้อมูล (Data Preprocessing) เป็นการเตรียมข้อมูลภาพก่อนการประมวลผล โดยส่วนใหญ่แล้วการนำภาพเข้ามาในระบบควรเป็นภาพใบมะเขือเทศที่ชัดเจนและเต็มใบ คุณลักษณะสีภาพชัดเจนรวมทั้งไม่ควรมีสิ่งรบกวนที่ทำให้ปิดบังรูปแบบของโรค หรือการทำให้สีของรอยโรคเปลี่ยนไป สิ่งเหล่านี้อาจทำให้ยากต่อการแบ่งส่วนของรอยโรคและให้ข้อมูลที่ผิดพลาดเกี่ยวกับรูปแบบของโรคได้ เพื่อให้การนำภาพเข้าสู่กระบวนการเรียนรู้และสร้างเป็นโมเดลที่ดีได้ในขั้นตอนต่อไป ในงานวิจัยนี้ใช้ฐานข้อมูลมาตรฐาน PlantVillage [9] ที่มีภาพของใบพืชชนิดต่างๆ ตัวอย่างเช่น ใบมันฝรั่ง องุ่น แอปเปิ้ล สดอเบอร์รี่ ข้าวโพดและใบมะเขือเทศ เป็นต้นทั้งหมดรวม 50,000 ภาพ และได้คัดเลือกเฉพาะข้อมูลภาพใบมะเขือเทศที่มีบริเวณใบเด่นชัด ทั้งสี และความสว่างของภาพ รวมทั้งขนาดภาพใบที่เหมาะสมเพื่อเข้าสู่ระบบต่อไป

#### 3.2 การประมวลผลภาพ

การกรองข้อมูลภาพด้วยค่ามัธยฐาน (Median filtering) เป็นการลดสัญญาณรบกวนในรูปภาพได้ดีกว่าตัวกรองอื่น ด้วยการหาค่ากลางของค่าความเข้มสีของบริเวณโดยรอบจุดพิจารณาที่มีขนาดตัวกรองเป็น 5x5 พิกเซลและจะช่วยการปรับรายละเอียดของรูปภาพ การใช้หลายค่าแบ่ง (Multi threshold) เพื่อแบ่งส่วนภาพ (Segmentation) เป็นหลายส่วนย่อยตามระดับสี RGB (Red-Green-Blue) โดยการกำหนดค่าแบ่งตามสัดส่วนที่ถูกกำหนดสามารถเขียนสมการในการกำหนดค่าแบ่งได้ดังนี้

$$(x, y) = \begin{cases} 0, f(x, y) < T_1 \\ 1, T_1 \leq f(x, y) \leq T_2 \\ 0, f(x, y) > T_2 \end{cases} \quad (1)$$

เมื่อกำหนดให้  $f(x, y)$  แทนข้อมูลภาพนำเข้าและแทนภาพสีที่มี  $T_1$  แทนเกณฑ์ค่าแบ่งส่วนแรก และ  $T_2$  แทนเกณฑ์ค่าแบ่งส่วนที่สอง และทำการแปลงค่าของ RGB จากค่าแบ่งโดยที่  $red(x, y)$  แทนค่าพิกเซลสีแดง  $green(x, y)$  แทนค่าพิกเซลสีเขียว และ  $blue(x, y)$  แทนค่าพิกเซลสีน้ำเงิน ผลที่ได้เป็นค่าแบ่งตามความสัมพันธ์ของการแปลงค่ากลุ่มสี RGB ดังแสดงในรูปที่ 2

#### 4. การเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียม

การเรียนรู้เชิงลึก (Deep learning) เป็นวิธีการเรียนรู้แบบอัตโนมัติที่จำลองมาจากโครงข่ายประสาทของมนุษย์ที่ประกอบด้วยโหนดมาเรียงซ้อนกัน หลายชั้น เพื่อทำการเรียนรู้ข้อมูลที่รับเข้ามาและถูกสร้างเป็นรูปแบบกลายเป็น โมเดลเพื่อนำมาใช้ในการประมวลผลและตัดสินใจ ดังแสดงในรูปที่ 3

##### 4.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) [13] เป็นเพอร์เซ็ปตรอนหลายชั้น (Multi-layer Perceptron) มีโครงสร้างแบบลำดับชั้น (Hierarchical Architectures) ประกอบด้วย ชั้นนำเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นแสดงผลลัพธ์ (Output layer) ถูกออกแบบมาสำหรับการเรียนรู้ข้อมูลแบบก้ำวหน้าในรอยระดับสูงเพื่อใช้ในการจำแนกข้อมูลให้ได้ผลลัพธ์ในขั้นสุดท้าย สามารถเขียนการดำเนินงานเป็นลำดับชั้นพื้นฐานของ CNN ดังนี้ Convolution Layer ลำดับชั้นคอนโวลูชันจะทำการกรองข้อมูลแบบ 2 มิติ ระหว่าง ข้อมูลภาพ  $I$  และสร้างตัวกรอง (filter)  $W$  เพื่อแยกคุณลักษณะที่สำคัญองค์ประกอบต่างของภาพ เช่น สี ลวดลาย รูปทรง และ  $h$  เป็นข้อมูลภาพอีกชั้นที่ถูกสร้างขึ้น ให้  $CT$  แทนความสัมพันธ์ของข้อมูลเข้าและออก เมื่อตัวกรองตอบสนองจากข้อมูลเข้าที่เชื่อมต่อกับข้อมูลออกตัวเดียวกันจะถูกเชื่อมต่อกัน สามารถเขียนเป็นสมการ

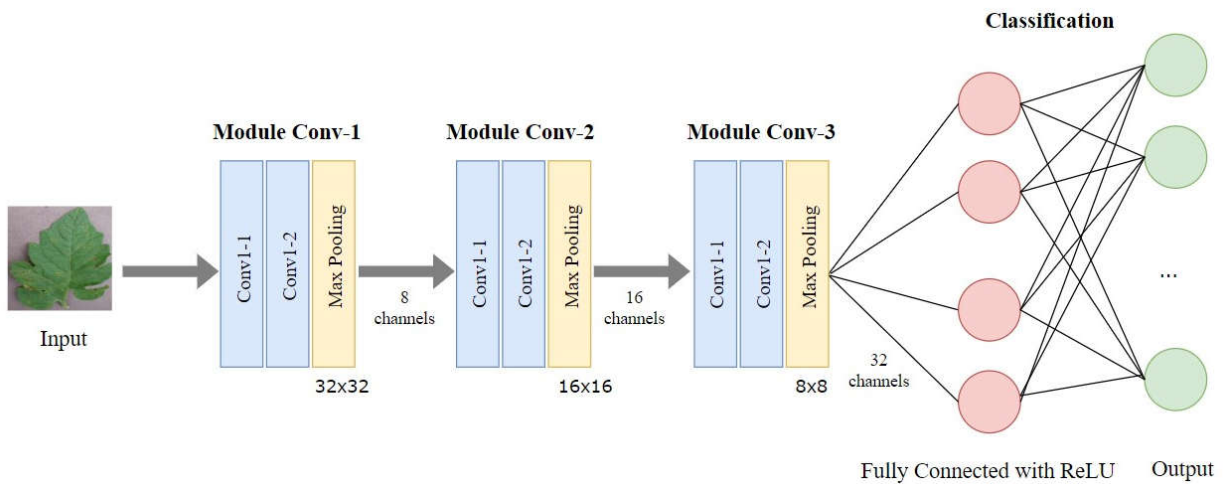
$$h_j = \sum_{i,k \in CT_{i,k,j}} (I_i * W_k) \quad (2)$$

1. Sub-sampling Layer เป็นลำดับชั้นที่ถูกสร้างขึ้นเพื่อดำเนินการ “Max-Pooling” เป็นการลดมิติของคุณลักษณะข้อมูลทั้งหมด เพื่อให้มีขนาดเล็กลงแต่ยังคงมีรายละเอียดที่สำคัญของข้อมูลไว้ เพื่อทำให้มีการคำนวณที่รวดเร็วขึ้นและแก้ไขปัญหา Overfitting

2. Fully-connected Layer เป็นลำดับชั้นที่ถูกสร้างขึ้นเพื่อรวมข้อมูลจากลำดับชั้นของ Convolution และ Pooling แล้วนำข้อมูลมาสร้างเป็นโครงข่ายประสาทเพื่อทำการเรียนรู้
  3. Output Layer เป็นลำดับชั้นข้อมูลออกที่ถูกจำแนกตามกลุ่มข้อมูลที่ถูกกำหนดไว้จากลำดับชั้น Fully-connected Layer
- โดยปกติทั่วไปขั้นตอนการเรียนรู้ของ CNN จะใช้วิธีการ Rectified Linear Unit (ReLU) เป็นฟังก์ชันกระตุ้น (Activate function) ที่ทำการแปลงเมทริกซ์ให้อยู่ในรูปแบบไม่เป็นเชิงเส้น (Non-linear) และทำการแก้ไขปัญหาคือ Gradient vanishing ด้วยการแทนค่าพิกเซลที่เป็นลบด้วยค่า 0 และปรับช่วงข้อมูลด้วยลำดับ Normalization layer (norm) เพื่อลดความผิดพลาดของทุกลำดับชั้นใน CNN ที่มีการเปลี่ยนแปลงตลอดเวลา สำหรับบางงานวิจัยใช้ขั้นตอน Back-propagation สำหรับการเรียนรู้ด้วย Max-Pooling CNN และใช้ค่าความคลาดเคลื่อนยกกำลังสอง (Sum of the Squared Error) เพื่อลดความผิดพลาด แต่อย่างไรก็ตามเนื่องจากค่าของข้อมูลโดยทั่วไปเป็นแบบไม่เป็นเชิงเส้นนั้นจะมีค่าความผิดพลาดมากวิธีการ Stochastic Gradient Descent จึงเป็นวิธีการที่เหมาะสมในการนำมาใช้สำหรับการทดลองเพื่อหลีกเลี่ยงปัญหาที่เกิดการติดขัดเมื่ออยู่ในจุดที่มีค่าต่ำสุด

##### 3.3 การเพิ่มจำนวนภาพ

การสร้างโมเดลเรียนรู้จำเป็นต้องประกอบด้วย ข้อมูลฝึกสอน (Training data) ที่มีจำนวนมากพอเพื่อสร้างเป็น โมเดลที่มีประสิทธิภาพ จากจำนวนข้อมูลภาพในฐานข้อมูลนั้นมีปริมาณภาพไม่มากนัก ทำให้ต้องมีการจำลองเพื่อเพิ่มปริมาณข้อมูลภาพสำหรับการเรียนรู้ วิธีการที่ช่วยแก้ปัญหาคือการเพิ่มจำนวนภาพที่เรียกว่า Data Augmentation [14][15] เป็นการเพิ่มจำนวนข้อมูลภาพด้วยวิธีการต่างๆ เช่น การบิดภาพ (Shear) การขยายภาพ (Zoom) การหมุนภาพ (Rotate) การเลื่อนภาพซ้ายขวา (Width Shift) การเลื่อนภาพขึ้นลง (Height Shift) 10% การกลับภาพแนวนอน (Horizontal Flip) การกลับภาพแนวตั้ง (Vertical Flip) การตัดภาพบางส่วน การปรับเปลี่ยนความสว่างภาพ รวมทั้งการลดความชัดเจนของภาพ ทำให้ภาพเพี้ยนไปจากความเป็นจริง จำนวนข้อมูลภาพที่เพิ่มขึ้นแสดงในตารางที่ 1 แสดงเป็นร้อยละของจำนวนภาพทั้งหมด 176,961 ภาพ ประกอบด้วยจำนวนภาพจริง 18,160 ภาพและภาพที่ถูก Augmentation 158,810 ภาพ โดยแสดงตัวอย่างภาพที่ถูก Augmentation ในรูปที่ 4



รูปที่ 3. ขั้นตอนโครงข่ายประสาทเทียมแบบสังวัตนาการ



รูปที่ 4. ภาพตัวอย่างใบมะเขือเทศที่ถูก Augmentation

ตารางที่ 1. จำนวนข้อมูลภาพตามประเภทโรคใบมะเขือเทศ

ชื่อโรค	จำนวนภาพ (%)	ภาพ Augmentation (%)
Bacterial_spot	1.2	6.49
Early_blight	0.6	9.49
Late_blight	1.1	6.17
Leaf_Mold	0.5	10.54
Septoria_leaf_spot	1.0	6.70
Spider_mites Two-spotted_spider_mite	0.9	8.24
Target_Spot	0.8	12.57
Tomato_Yellow_Leaf_Curl_Virus	0.2	8.27
Tomato_mosaic_virus	3.0	6.41
Fresh leaf	0.9	14.85

### 5. การวัดประสิทธิภาพและการประเมินผลการทดลอง

งานวิจัยนี้ได้นำเสนอการวัดและประเมินผลการทำงาน (Measurement and Evaluation) เป็นขั้นตอนสุดท้ายเพื่อตรวจสอบวิธีการที่ทำการทดลองมาข้างต้นว่ามีประสิทธิภาพมากหรือน้อยเพียงใดเมื่อนำมาใช้งานจริง สำหรับข้อมูลภาพใบมะเขือเทศที่ใช้ในการทดลองทั้งหมด ได้นำมาจากรฐานข้อมูลมาตรฐาน PlantVillage[9] ที่มีการเก็บข้อมูลภาพใบมะเขือเทศทั้งหมด 18,160 ภาพขนาด

256 x 256 พิกเซล เป็นชุดข้อมูลภาพใบมะเขือเทศที่ถูกคัดเลือกตามสภาพแวดล้อมรวมทั้งมีขนาดภาพใบเหมาะสม สามารถนำข้อมูลภาพมาใช้ทดลองได้ ฐานข้อมูลภาพประกอบด้วย 10 กลุ่มโรคสำคัญได้แก่ (1) โรคใบจุดแบคทีเรีย (bacterial leaf spot) (2) โรคใบจุดวง (Early blight) (3) โรคใบไหม้ (Late blight) (4) โรครากำมะหยี่ (Leaf mold) (5) โรคใบจุดวงกลม (Septoria leaf spot) (6) โรคไรสองจุด (Two-spotted spider mite) (7) โรคใบจุดเป็้ากระสุน (Target spot) (8) โรคใบค้างลิบ (Cucumber mosaic virus) (9) โรค

ใบหึงเหลือง (Yellow leaf curl virus) มาทำการทดลอง และ (10) ภาพใบมะเขือเทศปกติ (Fresh leaf tomato) ดังแสดงตัวอย่างภาพในรูปที่ 1 ข้อมูลภาพได้ถูกทำการจำลองเพื่อเพิ่มปริมาณข้อมูลภาพสำหรับการเรียนรู้ด้วยการทำ Data augmentation ประกอบด้วย การหมุน การตัดบางส่วน การปรับเปลี่ยนความสว่าง เพื่อเพิ่มจำนวนข้อมูลในการทดลอง รวมทั้งหมด 158,801 ภาพ ดังแสดงรายละเอียดการเพิ่มจำนวนภาพตามกลุ่มข้อมูลโรคในตารางที่ 1 การทดลองใช้การเรียนรู้เชิงลึกเพื่อสร้างโมเดลที่สามารถจำแนกข้อมูลได้เองโดย มีการระบุความสัมพันธ์ระหว่างชุดข้อมูล ปรับแต่งพารามิเตอร์เพื่อประเมินผลในแต่ละครั้งและสามารถปรับปรุงโมเดลเพื่อให้มีประสิทธิภาพที่ดีขึ้นเรื่อยๆ


ในงานวิจัยนี้ได้ใช้ Tensorflow เป็นโปรแกรมแพลตฟอร์มที่บริษัท Google พัฒนาด้วยภาษาไพทอน (Python) เพื่อใช้งานสำหรับการเรียนรู้เชิงลึก และใช้งานร่วมกับไลบรารี Keras ทั้งการเพิ่มจำนวนภาพด้วยการบิดเบือนรูปและการเรียนรู้โดยกำหนดค่าให้จำนวนพารามิเตอร์ของการประเมินผล โมเดล CNN แสดงรายละเอียดพารามิเตอร์ในตารางที่ 2 ข้อมูลภาพที่ถูกนำมาใช้ทดลองจะถูกเลือกแบบสุ่มแบบ 70% 15% และ 15% สำหรับ 3 ชุดข้อมูล ประกอบด้วย ชุดข้อมูลฝึกสอน (Training set) ชุดข้อมูลทดสอบ (Testing set) และ ชุดข้อมูลทวนทดสอบ (Validation set) ตามลำดับ โดยไม่มีข้อมูลทับซ้อนกันในแต่ละหมวด ทำการทดลองโดยสุ่มภาพ 10 กลุ่ม ประเมินประสิทธิภาพด้วยค่าความถูกต้อง ประกอบด้วย ค่า

ความแม่นยำ (False positive rate / Precision: Pre.) เป็นอัตราส่วนของการตรวจพบโรคที่ถูกต้องจากจำนวนกลุ่มทั้งหมด, ค่าความระลึก (True positive rate / Recall) เป็นอัตราส่วนของการตรวจพบโรคที่ถูกต้องจากจำนวนข้อมูลที่ถูกต้องทั้งหมด


งานวิจัยนี้ได้ทดลองการจำแนกโรคใน ใบมะเขือเทศแบ่งการทดลองออกเป็น 2 ชุด ด้วยอัตราการเรียนรู้ (Learning rate) 0.0001 และ 0.001 แต่ละชุดจะมีจำนวนรอบ (Epoch) ที่ 50 รอบและ 100 รอบ ดังแสดงผลการทดลองในกราฟรูปที่ 5-8 แสดงการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลฝึกสอนและชุดข้อมูลทวนทดสอบที่อัตราการเรียนรู้ 0.0001 จำนวน 50 รอบ ชุดข้อมูลฝึกสอนมีค่าความถูกต้องเฉลี่ยรวมสูงกว่าชุดข้อมูลทวนทดสอบ 85.70% , 84.14%

ตารางที่ 2. กำหนดพารามิเตอร์บนโครงข่ายประสาทเทียมแบบคอนโวลูชัน

พารามิเตอร์	ค่าอธิบาย
จำนวนคอนโวลูชัน	3
จำนวนชั้น Pooling	3
Drop out rate	1
Network weight Initialization	Uniform
Activation layer	ReLU
Learning rate	0.0001, 0.001
Epoch	50, 100
Batch size	36, 64

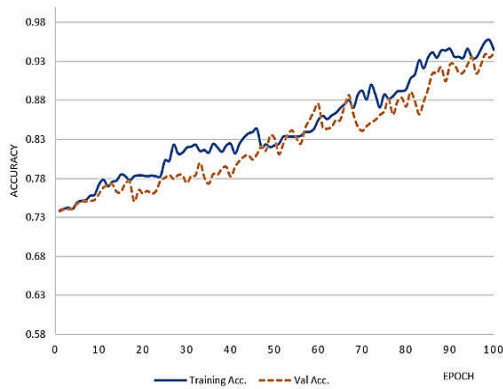


ก. กราฟแสดงค่าความถูกต้องของการเรียนรู้

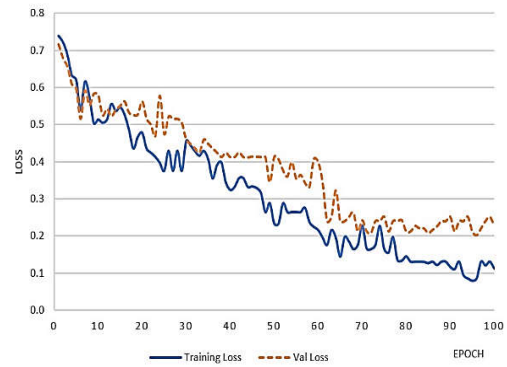


ข. กราฟแสดงอัตราการเรียนรู้ของการเรียนรู้

รูปที่ 5 ประสิทธิภาพการจำแนกโรคใบมะเขือเทศด้วย CNN , อัตราการเรียนรู้ 0.0001 ที่จำนวน 50 รอบ



ก. กราฟแสดงค่าความถูกต้องของการเรียนรู้  
รูปที่ 6 ประสิทธิภาพการจำแนกโรคใบมะเขือเทศด้วย CNN, อัตราการเรียนรู้ 0.0001 ที่จำนวน 100 รอบ




ข. กราฟแสดงอัตราการสูญเสียของการเรียนรู้




ก. กราฟแสดงค่าความถูกต้องของการเรียนรู้  
รูปที่ 7 ประสิทธิภาพการจำแนกโรคใบมะเขือเทศด้วย CNN, อัตราการเรียนรู้ 0.001 ที่จำนวน 50 รอบ



ข. กราฟแสดงอัตราการสูญเสียของการเรียนรู้

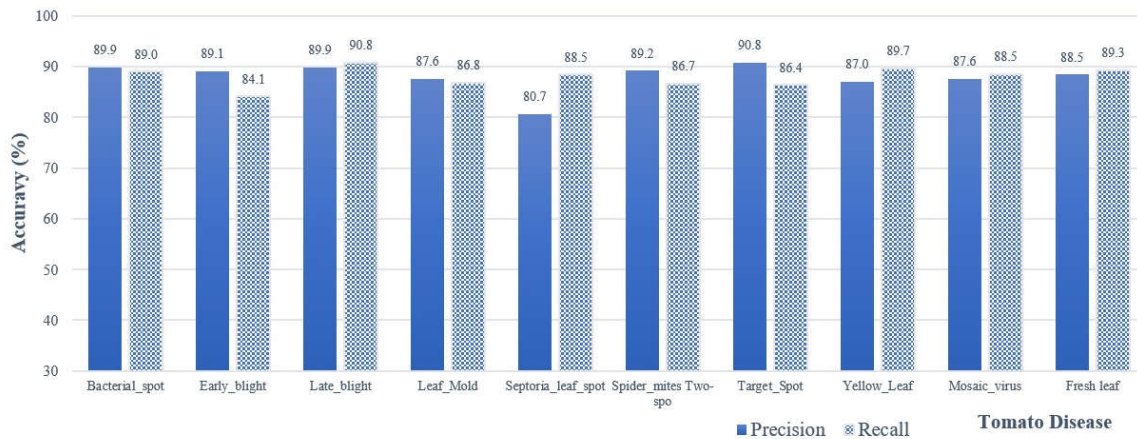


ก. กราฟค่าความถูกต้องของการเรียนรู้  
รูปที่ 8 ประสิทธิภาพการจำแนกโรคใบมะเขือเทศด้วย CNN, อัตราการเรียนรู้ 0.001 ที่จำนวน 100 รอบ



ข. กราฟอัตราการสูญเสียของการเรียนรู้





รูปที่ 9 ประสิทธิภาพการจำแนกโรคใบมะเขือเทศด้วยชุดข้อมูลทวนทดสอบ อัตราการเรียนรู้ 0.001 ที่จำนวน 100 รอบ

และในทางกลับกันอัตราของการสูญเสียของชุดข้อมูลฝึกสอนจะมีค่าต่ำกว่าชุดข้อมูลทวนทดสอบ 0.35, 0.42 ตามลำดับดังแสดงรายละเอียด และในรูปที่ 5 แสดงกราฟการเปรียบเทียบประสิทธิภาพที่อัตราการเรียนรู้ 0.0001 จำนวน 100 รอบ ค่าความถูกต้องในชุดข้อมูลฝึกสอนและชุดข้อมูลทวนทดสอบจะมีค่าความถูกต้องเฉลี่ยรวม 89.41% ในขณะที่ค่าอัตราเฉลี่ยรวมของความสูญเสียลดลงอยู่ที่ 0.29 ดังแสดงในรูปที่ 6 รายละเอียดสรุปผลการทดลองแสดงในตารางที่ 3 จากรูปที่ 7 แสดงกราฟการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลฝึกสอนและชุดข้อมูลทวนทดสอบที่อัตราการเรียนรู้ 0.001 จำนวน 50 รอบ จากกราฟแสดงให้เห็นว่าชุดข้อมูลฝึกสอนมีค่าความถูกต้องเฉลี่ยรวมสูงกว่าชุดข้อมูลทวนทดสอบ 87.84%, 86.03% ตามลำดับ และในทางกลับกันอัตราของการสูญเสียของชุดข้อมูลฝึกสอนจะมีค่าต่ำกว่าชุดข้อมูลทวนทดสอบ 0.35, 0.41 ตามลำดับ แต่เมื่อมีการเปรียบด้วยจำนวนรอบ 50 และ 100 รอบสำหรับชุดข้อมูลทวนทดสอบจะเห็นว่าอัตราเฉลี่ยรวมของค่าความถูกต้องเพิ่มขึ้นถึง 1.93% และอัตราสูญเสียลดลงถึง 0.12 ดังแสดงรายละเอียดในตารางที่ 3 และในรูปที่ 8

ตารางที่ 3. ผลการจำแนกโรคใบมะเขือเทศด้วย CNN

Learning rate	Epoch	Training Data		Validation Data	
		Average Accuracy (%)	Average Loss	Average Accuracy (%)	Average Loss
0.0001	50	85.70	0.35	84.14	0.42
	100	89.41	0.17	87.73	0.26
0.001	50	87.84	0.35	86.03	0.41
	100	89.98	0.18	87.96	0.29

จากผลการทดลองจำแนกโรคใบมะเขือเทศตามกลุ่มด้วยชุดข้อมูลทวนทดสอบ โดยกำหนดให้อัตราการเรียนรู้ 0.001 ที่จำนวน 100 รอบจากรูปที่ 9 จะเห็นว่าค่าความแม่นยำของกลุ่มโรค Target\_Spot Bacterial\_spot และ Late\_blight สูงถึง 90.8% 89.9% และ 89.9% ในขณะที่ค่าความแม่นยำของ Fresh leaf อยู่ที่ 88.5% แสดงรายละเอียดในรูป แต่อย่างไรก็ตามผลการทดลองโดยรวมจะเห็นว่าค่าเฉลี่ยความถูกต้องรวมสำหรับการจำแนกข้อมูลโรคใบมะเขือเทศในชุดทวนทดสอบจะอยู่ที่ 87.96% ด้วยอัตราการเรียนรู้ 0.001 ที่จำนวน 100 รอบ ซึ่งมีความสอดคล้องกับการทดลองในงานวิจัยก่อนหน้านี้และสามารถนำโมเดลการเรียนรู้นี้มาประยุกต์ใช้งานสำหรับการจำแนกข้อมูลต่อไป

## 6. สรุปผลการทดลอง

งานวิจัยนี้ได้ นำเสนอการจำแนกภาพโรคใบมะเขือเทศด้วยการเรียนรู้เชิงลึกโดยใช้วิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน ด้วยฟังก์ชันกระตุ้น ReLU และปรับช่วงข้อมูลด้วยลำดับ Normalization layer เพื่อลดความผิดพลาดของทุกลำดับชั้นใน CNN ที่มีการเปลี่ยนแปลงตลอดเวลา จากผลการทดลองด้วยข้อมูลภาพใบมะเขือเทศที่ถูกคัดเลือกจากฐานข้อมูลภาพมาตรฐานเพื่อจำแนก 10 กลุ่มได้แก่ โรคใบจุดแบคทีเรีย, โรคใบจุดวง, โรคใบไหม้, โรครากำมะหยี่, โรคใบจุดวงกลม, โรคไรสองจุด, โรคใบจุดเป่ากระสุน, โรคใบด่างลิบ, โรคใบหงิกเหลือง และเปรียบเทียบกับภาพใบมะเขือเทศปกติ

ผลการทดลองจะเห็นว่า มีค่าเฉลี่ยความถูกต้องของการจำแนกโรคใบมะเขือเทศสูงถึง 87.96% สำหรับการทดลองในชุดข้อมูลทวน

ทดสอบที่อัตราการเรียนรู้ 0.001 จำนวน 100 รอบ และมีอัตราการสูญเสีย 0.29 แต่อย่างไรก็ตามการทดลองนั้นยังมีข้อจำกัดของใบมะเขือเทศที่จำกัดมาก เนื่องจากข้อมูลภาพนำเข้าต้องมีความสมบูรณ์ของภาพพอสมควรจึงสามารถจำแนกได้ดี ดังนั้นยังคงเป็นสิ่งที่ต้องแก้ไขและปรับปรุงวิธีการเพื่อให้ตอบรับกับข้อมูลที่หลากหลายมากขึ้นสำหรับการทดลองต่อไป

## เอกสารอ้างอิง

- [1] Grieneisen, M.L., Aegerter, B.J., Scott Stoddard, C., Zhang, M., “Yield and fruit quality of grafted tomatoes, and their potential for soil fumigant use reduction,” A meta-analysis. *Agronomy for Sustainable Development*, vol. 38, no. 29, 2018.
- [2] Hasan, R.I., Yusuf, S.M., Alzubaidi, L., “Review of the state of the art of deep learning for plant diseases: A broad analysis and discussion,” *Plants*, vol. 9, no. 10, pp. 1–25, 2020.
- [3] Thummabenjapone, P. & Phola, S., “A highly potential fungicide to control *Stemphylium* sp., a causal agent of gray spot of tomato,” In *Proceeding The 8th National Plant Protection Conference*. pp. 383-391, 2007.
- [4] Dookie, M., Ali, O., Ramsubhag, A., and Jayaraman, J., “Flowering gene regulation in tomato plants treated with brown seaweed extracts,” *Scientia Horticulturae*. vol. 276, 2021.
- [5] Durmus, H., Gunes, E. O., and Kirci, M., “Disease detection on the leaves of the tomato plants by using deep learning”, 2017 6th international conference on agro-geoinformatics. *Agro-Geoinformatics*, pp. 1–5, 2017.
- [6] Mortazi, A.; Bagci, U., “Automatically designing CNN architectures for medical image segmentation,” In *Proceedings of the International Workshop on Machine Learning in Medical Imaging*, Granada, Spain, pp. 98–106, 2018.
- [7] Prabira Kumar Sethya, Nalini Kanta Barpandaa, Amiya Kumar Rathb, Santi Kumari Beherab, “Image Processing Techniques for Diagnosing Rice Plant Disease: A Survey,” *Procedia Computer Science*, 167, pp. 516–530, 2020.
- [8] Mohanty SP, Hughes DP, Salath M., “Using deep learning for image-based plant disease detection,” *Front Plant Sci*, vol. 7. no. 1419. 2016.
- [9] The Plant Village dataset: <https://www.kaggle.com/emmarex/plantdisease>
- [10] Amara J, Bouaziz B, Algergawy A., “A deep learning based approach for banana leaf diseases classification,” *International Journal of Creative Research Thoughts*, vol 6. Issue 2, pp. 79-88. 2017.
- [11] Rangarajan, A.K.; Purushothaman, R.; Ramesh, A. Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Comput. Sci.* 2018, 133, 1040–1047.
- [12] Sangeetha, R.; Rani, M., “Tomato Leaf Disease Prediction Using Transfer Learning,” In *Proceedings of the International Advanced Computing Conference 2020*, Panaji, India, 2020.
- [11] Too, E.C.; Yujian, L.; Njuki, S.; Yingchun, L., “A comparative study of fine-tuning deep learning models for plant disease identification,” *Comput. Electron. Agric.*, vol. 161, pp. 272–279, 2019.
- [13] Agarwal, M.; Gupta, S.K.; Biswas, K.K., “Development of Efficient CNN model for Tomato crop disease identification. Sustain,” *Comput. Inform. Syst.* vol. 28, pp. 100407–100421, 2020.
- [14] M. A. Tanner, and W. H. Wong, “The Calculation of Posterior Distributions By Data Augmentation,” *Journal Of The American Statistical Association*, vol. 82 no. 398, pp.528–540, 1987.
- [15] M. D. Bloice, C. Stocker, and A. Holzinger, “Augmentor: An Image Augmentation Library for Machine Learning,” *The Journal of Open Source Software*, vol.2. pp. 1-5, 2017.