

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

## การพัฒนาเทคนิคการเรียนรู้เชิงลึกสำหรับการจำแนกโรคใบพืช Development of Deep Learning Technique for Plant Leaf Diseases Classification

เอกรัตน์ สุขสุคนธ์

นักศึกษาระดับปริญญาเอก สาขาวิชาเทคโนโลยีดิจิทัลมีเดีย คณะวิทยาศาสตร์และเทคโนโลยี  
มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

### บทคัดย่อ

การเรียนรู้เชิงลึกมีบทบาทสำคัญอย่างยิ่งในการรู้จำและจำแนกโรคใบพืช โดยสามารถให้ความแม่นยำใกล้เคียงกับการประเมินของผู้เชี่ยวชาญ อย่างไรก็ตาม การพัฒนาระบบที่มีประสิทธิภาพยังคงเผชิญกับอุปสรรคจากความซับซ้อนและความหลากหลายของลักษณะการเกิดโรคใบพืช เพื่อแก้ไขปัญหาดังกล่าว งานวิจัยนี้ได้นำเสนอสถาปัตยกรรมการเรียนรู้เชิงลึกแบบผสมผสาน และกลไกความสนใจ (attention) สำหรับการรู้จำโรคใบพืช โครงข่ายที่นำเสนอประกอบด้วยการผสมผสานบล็อก squeeze-and-excitation ร่วมกับ residual block โครงข่ายแคปซูล และโครงข่ายหน่วยความจำระยะยาวแบบสองทิศทาง (Bidirectional Long Short-Term Memory: BiLSTM) บนพื้นฐานของ Transformer นำไปสู่การเพิ่มความแม่นยำในการรู้จำโรคใบพืช โครงข่ายที่นำเสนอได้รับการประเมินบนชุดข้อมูลโรคใบข้าวโพด และชุดข้อมูลโรคใบข้าว จากผลการทดลองพบว่าโครงข่ายสามารถให้ความแม่นยำในการฝึกสอนเท่ากับร้อยละ 99.88 สำหรับ CLDD และร้อยละ 99.10 สำหรับ RLDD นอกจากนี้ การวิเคราะห์พื้นที่ใต้โค้ง AUC ของ CLDD พบว่ามีค่าสูงใกล้เคียงระดับสูงสุด โดยมีค่าเท่ากับร้อยละ 99.73, 99.96, 99.96 และ 99.98 สำหรับโรคใบไหม้ (BL) โรคราสนิม (CR) โรคจุดใบสีเทา (GL) และใบปกติ (HE) ตามลำดับ สำหรับชุดข้อมูล RLDD โครงข่ายยังคงให้ผลลัพธ์ในระดับสูง โดยมีค่า AUC เท่ากับร้อยละ 94.98, 93.70, 97.66, 84.57, 99.58 และ 98.85 สำหรับโรคใบข้าวแบคทีเรีย (BLB) โรคจุดสีน้ำตาล (BS) ใบปกติ (HE), โรคไหม้ (LB) โรคใบไหม้ขอบใบ (LS) และโรคจุดสีน้ำตาลแคบ (NBS) ตามลำดับ ผลการทดลองดังกล่าวสะท้อนให้เห็นถึงศักยภาพและประสิทธิภาพที่โดดเด่นของโครงข่ายที่นำเสนอในการประยุกต์ใช้กับการรู้จำโรคใบพืช

คำสำคัญ โรคใบพืช โครงข่ายคอนโวลูชัน การเรียนรู้เชิงลึก การจำแนก การรู้จำ

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

## 1. บทนำ

การจำแนกและการรู้จำโรคพืชได้กลายเป็นประเด็นสำคัญในภาคการเกษตรแม่นยำ เนื่องจากมีบทบาทในการปกป้องผลผลิตและคุณภาพของพืชผล รวมถึงช่วยลดความสูญเสียทางเศรษฐกิจของเกษตรกรและผู้มีส่วนเกี่ยวข้อง การตรวจพบโรคใบพืชในระยะเริ่มต้นและเชิงรุกสามารถนำไปสู่การดำเนินการแก้ไขได้อย่างทันท่วงที ส่งผลให้ลดการแพร่กระจายของโรค และช่วยให้การใช้ทรัพยากร เช่น สารเคมีป้องกันศัตรูพืชและปุ๋ย เป็นไปอย่างเหมาะสม ซึ่งเอื้อต่อการเกษตรอย่างยั่งยืน [1] อย่างไรก็ตาม การวินิจฉัยโรคใบพืชจากการสังเกตโรคใบพืชเป็นงานที่มีความซับซ้อนสูง แม้แต่เกษตรกรที่มีประสบการณ์ก็ยังประสบปัญหาในการแยกแยะโรคบางชนิด ส่งผลให้เกิดการวินิจฉัยที่คลาดเคลื่อนและการรักษาที่ล่าช้า ด้วยเหตุนี้ วิธีการดั้งเดิมที่อาศัยการสังเกตด้วยสายตามนุษย์จึงไม่เพียงพอสำหรับการเกษตรสมัยใหม่ ปัญหาดังกล่าวได้กระตุ้นให้เกิดการวิจัยและพัฒนาในด้านคอมพิวเตอร์วิทัศน์และการเรียนรู้ของเครื่อง (Machine Learning: ML) เพื่อแก้ไขข้อจำกัดเหล่านี้ [2], [3]

คอมพิวเตอร์วิทัศน์และ ML ได้รับการยอมรับว่าเป็นเครื่องมือขั้นสูงและมีประสิทธิภาพในการวินิจฉัยและระบุโรคพืช [4], [5] วิธีการ ML แบบดั้งเดิมมักประกอบด้วยกระบวนการแบ่งส่วนภาพ การสกัดคุณลักษณะ และการจำแนกประเภท [6] แม้ว่าวิธีการเหล่านี้จะสามารถเรียนรู้ข้อมูลและสกัดคุณลักษณะได้ในระดับหนึ่ง แต่ยังมีข้อจำกัดในการเรียนรู้คุณลักษณะเชิงลึก (deep features) ซึ่งส่งผลกระทบต่อประสิทธิภาพด้านการรู้จำและความสามารถในการทั่วไป (generalization) โดยเฉพาะเมื่อข้อมูลมีสัญญาณรบกวนจากพื้นหลังหรือมีรูปแบบของโรคพืชที่ซับซ้อน [7], [8]

ด้วยเหตุนี้ การพัฒนาเทคนิคการเรียนรู้เชิงลึก (Deep Learning: DL) โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) จึงได้รับการพัฒนาอย่างต่อเนื่องเพื่อเพิ่มขีดความสามารถและยกระดับผลลัพธ์ ตัวอย่างเช่น MobileNetV3Small ได้รับการปรับปรุงด้วยการผสมผสาน SE Blocks เพื่อเพิ่มความสามารถของโครงข่ายในการจับคุณลักษณะที่สำคัญจากข้อมูล พร้อมทั้งนำฟังก์ชันกระตุ้น Hard-swish มาใช้เพื่อเพิ่มประสิทธิภาพในการเรียนรู้และลดความซับซ้อน ส่งผลให้ได้โครงข่ายที่มีจำนวนพารามิเตอร์น้อยลงแต่ยังคงให้ความแม่นยำสูงในการจำแนกโรคจากใบพืช [9] ในทำนองเดียวกัน โครงข่าย ResNet ได้รับการปรับปรุงเป็น Modified ResNet และนำเทคนิคการเรียนรู้ถ่ายโอน (Transfer Learning) มาใช้เพื่อเพิ่มความสามารถของโครงข่าย ทำให้เหมาะสมต่อการตรวจจับโรคใบพืช [10]

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

นอกจากนี้ การพัฒนาอัลกอริทึม MBIRCH สำหรับการแบ่งส่วนภาพ และโครงข่ายแบบผสมผสานระหว่าง BiLSTM และ CNN สำหรับการจำแนกโรคใบพืช ได้แสดงให้เห็นถึงความก้าวหน้าอย่างมีนัยสำคัญ [11] อีกทั้งยังมีการพัฒนาโครงข่าย CNN แบบน้ำหนักเบาที่ได้รับการปรับปรุงสำหรับการจำแนกโรคพืชแบบละเอียด โดยมุ่งเน้นการแยกแยะโรคที่มีลักษณะคล้ายคลึงกัน ซึ่งผสมผสานกลไก coordinate attention เพื่อเพิ่มความสามารถของโครงข่ายในการรับรู้ตำแหน่งและบริบทของคุณลักษณะที่สำคัญในใบพืช [12] อย่างไรก็ตาม การเพิ่มจำนวนชิ้นการทำงานในโครงข่ายรู้จำโรคพืชยังคงเผชิญกับปัญหา เช่น การหายไปหรือการระเบิดของค่าเกรเดียนต์ (vanishing/exploding gradients) ซึ่งทำให้โครงข่ายเรียนรู้ได้ยากและไม่สามารถปรับค่าน้ำหนักได้อย่างมีประสิทธิภาพระหว่างการฝึกสอน นอกจากนี้ ปัญหาการเกิด overfitting ความซับซ้อนในการคำนวณ และความยั่งยืนของระบบ ยังคงเป็นอุปสรรคสำคัญที่ทำให้โครงข่ายเหล่านี้ไม่เหมาะสมต่อการประยุกต์ใช้แบบเวลาจริง

แม้ว่าโครงข่ายขนาดใหญ่ เช่น GoogLeNet [13], ResNet [14], Inception [15], EfficientNet [16] และโครงข่ายอื่น ๆ [17]–[19] จะมีบทบาทสำคัญในการยกระดับประสิทธิภาพการจำแนกและรู้จำโรคใบพืช แต่จากการทบทวนวรรณกรรมพบว่าโครงข่ายรู้จำโรคพืชในปัจจุบันยังไม่สามารถแก้ไขปัญหาการสกัดคุณลักษณะเชิงจำแนกได้อย่างมีประสิทธิภาพ การทำงานที่เชื่อถือได้ในสภาพแวดล้อมจริง และประสิทธิภาพด้านการคำนวณได้อย่างเหมาะสม ปัญหาเหล่านี้จำเป็นต้องได้รับการแก้ไขผ่านการออกแบบสถาปัตยกรรมที่มีน้ำหนักเบา สามารถชดเชยปัญหา vanishing gradients มีความทนทานต่อสัญญาณรบกวน และเพิ่มความแม่นยำและความน่าเชื่อถือของการรู้จำ [4]–[19]

ดังนั้น งานวิจัยนี้จึงนำเสนอกรอบการเรียนรู้เชิงลึกแบบผสมผสาน โดยบูรณาการตัวดำเนินการคอนโวลูชันแบบสองสาย เพื่อเรียนรู้คุณลักษณะเสริมและคุณลักษณะแบบหลายสเกลของโรคใบพืช กรอบแนวคิดดังกล่าวสนับสนุนการแทนคุณลักษณะด้วยการใช้ SE-Residual blocks สำหรับการปรับค่าน้ำหนัก, Capsule Network สำหรับการแทนความสัมพันธ์เชิงพื้นที่แบบลำดับชั้น และ BiLSTM สำหรับการเรียนรู้การพึ่งพาเชิงลำดับ และโครงข่าย Transformer Network สำหรับการปรับคุณลักษณะด้วยกลไกความสนใจ โครงข่ายที่พัฒนาขึ้นสามารถบูรณาการคุณลักษณะเชิงพื้นที่ เชิงลำดับ และเชิงบริบท เพื่อเพิ่มประสิทธิภาพในการรู้จำรูปแบบของโรคพืช ส่งผลให้โครงข่ายสามารถเรียนรู้คุณลักษณะเชิงลึกที่มีความจำแนกสูง และยกระดับสมรรถนะในการรู้จำได้อย่างมีประสิทธิภาพ

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

ในงานวิจัยนี้ได้ทำการประเมินกรอบการทดลองบนชุดข้อมูลโรคใบข้าวโพด (Corn Leaf Disease Dataset: CLDD) และชุดข้อมูลโรคใบข้าว (Rice Leaf Disease Dataset: RLDD) พร้อมทั้งเปรียบเทียบประสิทธิภาพกับแนวทางที่มีอยู่ในปัจจุบัน เพื่อพิสูจน์ศักยภาพของกรอบแนวคิดที่นำเสนอ สำหรับนำไปประยุกต์ใช้ในภาคเกษตรกรรม

## 2. วัตถุประสงค์

2.1 เพื่อออกแบบและพัฒนาโครงข่ายการเรียนรู้เชิงลึกแบบผสมผสาน สำหรับการรู้จำโรคใบพืช โดยการผสมผสาน SE-residual blocks, Capsule Network, BiLSTM และ Transformer Network

2.2 เพื่อประเมินประสิทธิภาพของโครงข่ายที่นำเสนอในการจำแนกโรคพืชบนชุดข้อมูล CLDD และ RLDD โดยใช้ตัวชี้วัด ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และค่า AUC

## 3. ขอบเขตของการวิจัย

### 3.1 ประชากร

ภาพใบพืชที่แสดงลักษณะโรคและใบปกติ ซึ่งประกอบด้วยภาพใบข้าวโพดจากชุดข้อมูล CLDD และภาพใบข้าวจากชุดข้อมูล RLDD ที่รวบรวมจากฐานข้อมูลสาธารณะ

### 3.2 กลุ่มตัวอย่าง

ภาพใบข้าวโพดและภาพใบข้าวที่มีลักษณะโรคและใบปกติ จากชุดข้อมูล CLDD จำนวน 4,188 ภาพ และชุดข้อมูล RLDD จำนวน 2,628 ภาพ โดยแบ่งข้อมูลออกเป็นร้อยละ 80 สำหรับการฝึกและตรวจสอบความถูกต้องของโครงข่าย และร้อยละ 20 สำหรับการทดสอบประสิทธิภาพของโครงข่าย

### 3.3 ตัวแปร ตัวแปรที่ใช้ได้แก่

#### 3.3.1 ตัวแปรอิสระ

โครงสร้างและองค์ประกอบของโครงข่ายการเรียนรู้เชิงลึกที่ใช้ในการรู้จำโรคใบพืช

#### 3.3.2 ตัวแปรตาม

ประสิทธิภาพของโครงข่ายในการรู้จำโรคพืชจากภาพใบพืช ซึ่งวัดจากตัวชี้วัดทางสถิติ ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และค่า AUC

### 3.4 ระยะเวลาในการวิจัย

1 ปี

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

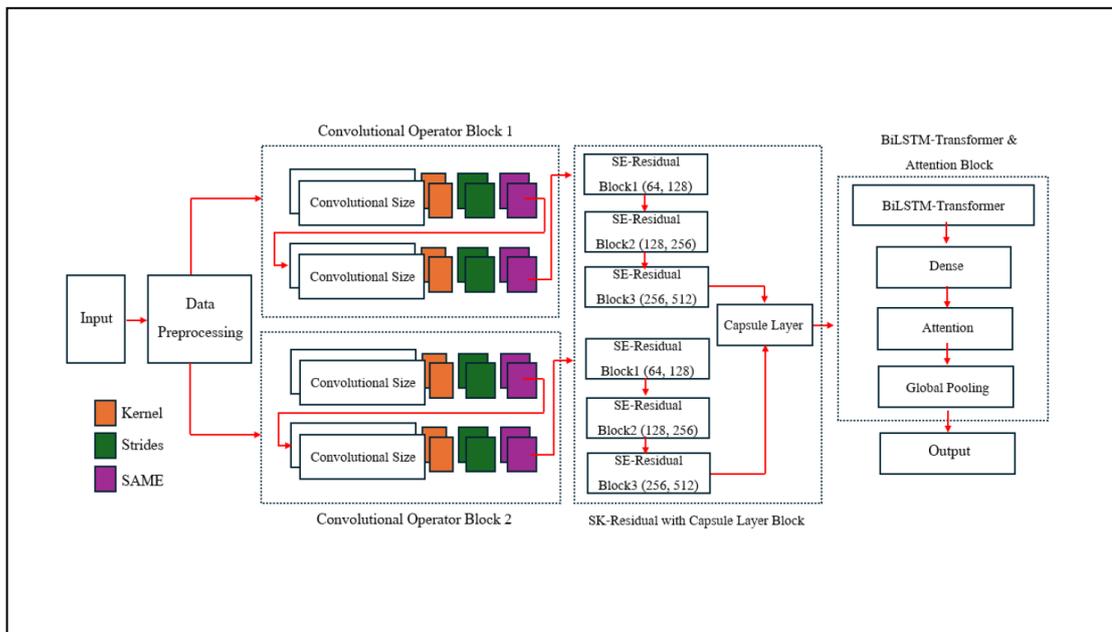
## 4. ประโยชน์ที่คาดว่าจะได้รับ

4.1 โครงข่ายการเรียนรู้เชิงลึกที่มีความแม่นยำสูงในการจำโรคใบพืช ซึ่งช่วยเพิ่มประสิทธิภาพในการวินิจฉัยโรคใบพืช

4.2 สามารถนำโครงข่ายที่พัฒนาขึ้นไปประยุกต์ใช้กับระบบเกษตรอัจฉริยะ เพื่อช่วยลดการสูญเสียผลผลิตและสนับสนุนการตัดสินใจทางการเกษตรอย่างมีประสิทธิภาพ

## 5. กรอบแนวคิดการวิจัย

โครงข่ายที่นำเสนอได้บูรณาการตัวดำเนินการคอนโวลูชันแบบสองสตรีม โดยใช้ขนาดเคอร์เนลที่แตกต่างกันเพื่อสกัดคุณลักษณะแบบหลายสเกลจากภาพโรคใบพืช บล็อก SE-Residual ถูกนำมาใช้เพื่อปรับค่าน้ำหนักของช่องสัญญาณให้เหมาะสม ขณะที่โครงข่ายแคปซูล ช่วยคงรักษาความสัมพันธ์เชิงพื้นที่ของคุณลักษณะ นอกจากนี้ โครงข่าย BiLSTM ถูกใช้เพื่อเรียนรู้การพึ่งพาเชิงลำดับ และร่วมกับกลไกความสนใจบนพื้นฐานของ Transformer Network เพื่อมุ่งเน้นคุณลักษณะที่มีความสำคัญในระดับสากล ชั้นของ Global Average Pooling ถูกใช้ในการรวมคุณลักษณะทั้งหมดเพื่อสร้างผลลัพธ์การจำขั้นสุดท้าย สถาปัตยกรรมทั้งหมดของโครงข่ายแสดงไว้ดังภาพที่ 1



ภาพที่ 1 A two-stream SE-capsule BiLSTM-transformer for plant leaf disease recognition

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

## 6. วิธีดำเนินการวิจัย

### 6.1 การรวบรวมและเตรียมข้อมูล

รวบรวมภาพโรคใบพีชจากชุดข้อมูล CLDD และชุดข้อมูล RLDD จากแหล่งข้อมูลสาธารณะ จากนั้นดำเนินการเตรียมข้อมูลภาพโดยการปรับขนาดภาพ การกรองพื้นหลัง และการแบ่งชุดข้อมูล ออกเป็นชุดฝึก ชุดตรวจสอบความถูกต้อง และชุดทดสอบ

### 6.2 การออกแบบและพัฒนาโครงข่าย

ออกแบบโครงข่ายการเรียนรู้เชิงลึกแบบผสมผสาน โดยประกอบด้วยตัวดำเนินการคอนโวลูชันแบบสองสตรีม ร่วมกับ SE-residual blocks, Capsule Network, BiLSTM และ Transformer Network เพื่อสกัดและเรียนรู้คุณลักษณะเชิงพื้นที่ เชิงลำดับ และเชิงบริบทของโรคใบพีช

### 6.3 การฝึกสอนและประเมินผลโครงข่าย

ฝึกสอนโครงข่ายด้วยชุดข้อมูลฝึก และประเมินประสิทธิภาพของโครงข่ายด้วยชุดข้อมูลทดสอบ ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และค่า AUC

## 7. ผลการวิจัย

โครงข่ายการเรียนรู้เชิงลึกแบบผสมผสานที่พัฒนาขึ้นสามารถให้ประสิทธิภาพในการรู้จำโรคใบพีชได้ในระดับสูง โดยมีความแม่นยำในการฝึกสอนร้อยละ 99.88 สำหรับชุดข้อมูล CLDD และร้อยละ 99.10 สำหรับชุดข้อมูล RLDD

ผลการประเมินด้วยตัวชี้วัดด้านความเที่ยงตรงและความครอบคลุมพบว่า ชุดข้อมูล RLDD มีค่า Precision และ Recall เท่ากับร้อยละ 100 ขณะที่ชุดข้อมูล CLDD มีค่า Precision ร้อยละ 98.85 และ Recall ร้อยละ 98.61 แสดงถึงความสามารถในการจำแนกโรคใบพีชได้อย่างถูกต้องและสม่ำเสมอ

การวิเคราะห์พื้นที่ได้โค้งแสดงให้เห็นว่าโครงข่ายมีประสิทธิภาพในการจำแนกโรคใบพีชในระดับสูง โดยชุดข้อมูล CLDD มีค่า AUC ใกล้เคียงระดับสูงสุดในทุกคลาส และชุดข้อมูล RLDD มีค่า AUC เฉลี่ยในระดับสูง สะท้อนถึงศักยภาพของโครงข่ายในการนำไปประยุกต์ใช้งานจริง

## 8. ผลการวิจัย

งานวิจัยนี้นำเสนอแนวคิดการพัฒนาโครงข่ายการเรียนรู้เชิงลึกแบบผสมผสาน โดยผสมผสาน SE-residual blocks, Capsule Network, BiLSTM และ Transformer Network เพื่อเพิ่มประสิทธิภาพในการรู้จำโรคใบพีช โครงข่ายที่นำเสนอมีผลการรู้จำ ดังต่อไปนี้

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3



ภาพที่ 2. Sample representation of CLDD recognition performance.



ภาพที่ 3. Sample representation of RLDD recognition performance.

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

จากภาพที่ 2 แสดงผลการรู้จำของชุดข้อมูล CLDD สำหรับกลุ่ม BL กลุ่ม CR กลุ่ม GL และกลุ่ม HE โดยโครงข่ายสามารถให้ความแม่นยำอยู่ในช่วงร้อยละ 99.92 ถึง 100 ในทุกกลุ่ม ผลลัพธ์ดังกล่าวสะท้อนให้เห็นถึงความสามารถของโครงข่ายในการระบุลักษณะเฉพาะของโรคใบพืชได้อย่างถูกต้อง และสามารถแยกแยะระหว่างใบพืชที่เป็นโรคและใบพืชปกติได้อย่างมีประสิทธิภาพ แม้ว่าตัวอย่างภาพจะมีความซับซ้อนและความหลากหลายสูง โครงข่ายยังคงแสดงสมรรถนะที่มีเสถียรภาพ แสดงให้เห็นถึงประสิทธิผลในการเรียนรู้และจำแนกคุณลักษณะของโรคใบพืชชนิดต่าง ๆ

จากภาพที่ 3 แสดงผลการรู้จำของชุดข้อมูล RLDD สำหรับกลุ่ม BLB กลุ่ม LB กลุ่ม BS กลุ่ม HE กลุ่ม LS และกลุ่ม NBS โดยกลุ่ม BLB แสดงความแม่นยำในการรู้จำสูงถึงร้อยละ 100 ในบางตัวอย่าง และมีค่าเฉลี่ยอยู่ในช่วงร้อยละ 98-100 แม้ว่าจะมีตัวอย่างหนึ่งที่ค่าความแม่นยำลดลงเหลือร้อยละ 90.07 แต่โดยรวมยังสะท้อนถึงความน่าเชื่อถือของโครงข่ายในการรู้จำ กลุ่ม BS ให้ค่าความแม่นยำสูงถึงร้อยละ 99.99 ในบางกรณี และส่วนใหญ่อยู่ในช่วงร้อยละ 93-99 แสดงให้เห็นถึงความสามารถในการจำแนกโรคใบพืชได้อย่างถูกต้อง สำหรับกลุ่ม HE พบว่าค่าความแม่นยำมีความแปรปรวนค่อนข้างมาก โดยอยู่ในช่วงร้อยละ 67.93 ถึง 99.67 ซึ่งสะท้อนถึงความไม่สม่ำเสมอของสมรรถนะโครงข่ายในบางกรณี ขณะที่กลุ่ม LB ให้ค่าความแม่นยำอยู่ระหว่างร้อยละ 71.63 ถึง 100 โดยพบข้อผิดพลาดเล็กน้อยในบางตัวอย่าง ส่วนกลุ่ม LS แสดงผลการรู้จำที่มีความแม่นยำสูงอย่างสม่ำเสมอ โดยหลายตัวอย่างให้ค่าร้อยละ 99.99 แสดงถึงความน่าเชื่อถือของโครงข่ายในการจำแนกโรคใบพืช และกลุ่ม NBS ให้ค่าความแม่นยำสูงสุดที่ร้อยละ 99.98 โดยมีค่าเฉลี่ยอยู่ในช่วงร้อยละ 88-99 สะท้อนถึงประสิทธิภาพของโครงข่ายในการรู้จำโรคชนิดนี้ อย่างไรก็ตาม กรณีที่โครงข่ายให้ค่าความแม่นยำต่ำในบางตัวอย่าง เช่น ร้อยละ 67.93 สำหรับกลุ่ม HE หรือร้อยละ 71.63 สำหรับกลุ่ม LB อาจมีสาเหตุมาจากความคลุมเครือหรือความซับซ้อนของข้อมูลนำเข้า ซึ่งเป็นประเด็นที่สามารถนำไปใช้ในการปรับปรุงโครงข่ายและแนวทางการเรียนรู้ในงานวิจัยในอนาคต

ผลการวิจัยแสดงให้เห็นว่าโครงข่ายมีความแม่นยำสูงในการจำแนกโรคใบพืช โดยให้ความแม่นยำร้อยละ 99.88 บนชุดข้อมูล CLDD และร้อยละ 99.10 บนชุดข้อมูล RLDD พร้อมทั้งมีค่า Precision ค่า Recall และค่า AUC อยู่ในระดับสูง สะท้อนถึงศักยภาพของแนวคิดที่เสนอในการประยุกต์ใช้กับระบบเกษตรอัจฉริยะและระบบตรวจจับโรคใบพืชในอนาคต

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

## 9. เอกสารอ้างอิง

- [1] Liu, X., Min, W., Mei, S., Wang, L., & Jiang, S. (2021). Plant disease recognition: A large-scale benchmark dataset and a visual region and loss reweighting approach. *IEEE Transactions on Image Processing*, 30, 2003–2015. <https://doi.org/10.1109/TIP.2021.3049334>
- [2] Alqahtani, Y., Nawaz, M., Nazir, T., Javed, A., Jeribi, F., & Tahir, A. (2023). An improved deep learning approach for localization and recognition of plant leaf diseases. *Expert Systems with Applications*, 230, Article 120717. <https://doi.org/10.1016/j.eswa.2023.120717>
- [3] Hari, P., & Singh, M. P. (2025). Adaptive knowledge transfer using federated deep learning for plant disease detection. *Computers and Electronics in Agriculture*, 229, Article 109720. <https://doi.org/10.1016/j.compag.2024.109720>
- [4] Polly, R., & Devi, E. A. (2024). Semantic segmentation for plant leaf disease classification and damage detection: A deep learning approach. *Smart Agricultural Technology*, 9, Article 100526. <https://doi.org/10.1016/j.atech.2024.100526>
- [5] Bouacida, I., Farou, B., Djakhdjakha, L., Seridi, H., & Kurulay, M. (2024). Innovative deep learning approach for cross-crop plant disease detection: A generalized method for identifying unhealthy leaves. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2024.03.002>
- [6] Prommakhot, A., Onshaunjit, J., Ooppakaew, W., Samseemoung, G., & Srinonchat, J. (2025). Hybrid CNN and transformer-based sequential learning techniques for plant disease classification. *IEEE Access*, 13, 122876–122887. <https://doi.org/10.1109/ACCESS.2025.3586285>
- [7] Chaturya, T., Swathi, Y., Kumar, V., Karthik, P., Nayan, A., & Yadav, A. (2023). Detection of plant disease using convolutional neural networks (CNN). In *Proceedings of the International Conference on Sustainable Computing and Data Communication Systems (ICSCDS)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICSCDS56580.2023.10105099>
- [8] Wongbongkotpaisan, J., & Phumeechanya, S. (2021). Plant leaf disease classification using local-based image augmentation and convolutional neural network. In *Proceedings of the International Conference on Electrical Engineering/Electronics, Computer,*

# สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

*Telecommunications and Information Technology (ECTI-CON)* (pp. 1–6). IEEE.  
<https://doi.org/10.1109/ECTI-CON51831.2021.9454672>

[9] Salam, A., Naznine, M., Jahan, N., Nahid, E., Nahiduzzaman, M., & Chowdhury, M. E. H. (2024). Mulberry leaf disease detection using CNN-based smart Android application. *IEEE Access*, *12*, 83575–83588. <https://doi.org/10.1109/ACCESS.2024.3407153>

[10] Zhang, C., Wu, D., Chen, J., & Yang, J. (2020). Efficient plant diseases recognition based on modified residual neural network and transfer learning. In *Proceedings of the IEEE 18th International Conference on Industrial Informatics (INDIN)* (pp. 1–6). IEEE. <https://doi.org/10.1109/INDIN45582.2020.9442151>

[11] Jayanthi, V., & Kanchana, M. (2024). Modified BIRCH and hybrid deep framework for tomato leaf disease segmentation and classification. In *Proceedings of the International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICICV62344.2024.00030>

[12] Liu, Y., Gao, G., & Zhang, Z. (2022). Crop disease recognition based on modified lightweight CNN with attention mechanism. *IEEE Access*, *10*, 112066–112075. <https://doi.org/10.1109/ACCESS.2022.3216285>

[13] Yang, L., Yu, X., Zhang, S., Long, H., Zhang, H., Xu, S., & Liao, Y. (2022). GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases. *Computers and Electronics in Agriculture*, *204*, Article 107543. <https://doi.org/10.1016/j.compag.2022.107543>

[14] Kumar, V., Arora, H., Harsh, & Sisodia, J. (2020). ResNet-based approach for detection and classification of plant leaf diseases. In *Proceedings of the International Conference on Electronics and Sustainable Communication Systems (ICESC)* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICESC48915.2020.9155585>

[15] Yu, S., Xie, L., & Huang, Q. (2023). Inception convolutional vision transformers for plant disease identification. *Internet of Things*, *21*, Article 100650. <https://doi.org/10.1016/j.iot.2022.100650>

## สัมมนาวิชาการ เทคโนโลยีดิจิทัลมีเดีย ระดับบัณฑิตศึกษา ครั้งที่ 3

- [16] Rajeena, F. P. P., A. S. U., Moustafa, M. A., & Ali, M. A. S. (2023). Detecting plant disease in corn leaf using EfficientNet architecture—An analytical approach. *Electronics*, 12(8), Article 1938. <https://doi.org/10.3390/electronics12081938>
- [17] Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311–318. <https://doi.org/10.1016/j.compag.2018.01.009>
- [18] Liu, J., & Wang, X. (2021). Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17, Article 22. <https://doi.org/10.1186/s13007-021-00722-9>
- [19] Attri, I., Awasthi, L. K., Sharma, T. P., & Rathee, P. (2023). A review of deep learning techniques used in agriculture. *Ecological Informatics*, 77, Article 102217. <https://doi.org/10.1016/j.ecoinf.2023.102217>

# Plagiarism Checking Report

Created on 2026-02-09 19:58:07 at 19:58 PM

## Submission Information

ID	SUBMISSION DATE	SUBMITTED BY	ORGANIZATION	FILENAME	STATUS	SIMILARITY INDEX
4621336	Feb 9, 2026 at 18:03 PM	aeekarat.s@rmutsb.ac.th	มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ	166490431006-เอกรัตน์ สุขสุนนท์.pdf	Completed	0.00 %

## Match Overview

NO.	TITLE	AUTHOR(S)	SOURCE	SIMILARITY INDEX
No data available in table				

*Match Details*

---

TEXT FROM SUBMITTED DOCUMENT

TEXT FROM SOURCE DOCUMENT(S)