



การเพิ่มประสิทธิภาพการจำแนกโรคจากภาพใบข้าวโพดด้วยการประมวลผลภาพ
ENHANCING MAIZE LEAF DISEASE CLASSIFICATION PERFORMANCE
USING IMAGE PROCESSING TECHNIQUES

กีระชาติ สุขสุทธิ^{1*}, รติพร จันทร์กลิ่น¹, เกตุกาญจน์ โพธิจิตติกานต์¹ และพรภัสสร อ่อนเกิด¹

¹อาจารย์, สาขาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน

*Corresponding author, E-mail: keerachart.su@rmuti.ac.th

บทคัดย่อ

การระบาดของโรคในข้าวโพดถือเป็นปัญหาสำคัญที่ส่งผลกระทบต่อผลผลิตและราคาทางการตลาดอย่างมีนัยสำคัญ การจำแนกชนิดของโรคได้อย่างถูกต้องและทันเวลาที่มีความสำคัญต่อการวางแผนจัดการของเกษตรกร ทั้งในด้านการป้องกันและการรักษา อย่างไรก็ตาม ในทางปฏิบัติ การจำแนกโรคด้วยตนเองอาจมีความคลาดเคลื่อนจากความเหนื่อยล้า หรือเนื่องจากอาการของโรคบางชนิดมีลักษณะคล้ายคลึงกัน การประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) จึงเป็นแนวทางที่สามารถลดภาระของเกษตรกรและเพิ่มความแม่นยำในการวินิจฉัยได้ แต่เนื่องจากอัลกอริทึมดั้งเดิมในบางกรณีอาจยังไม่สามารถจำแนกโรคได้อย่างมีประสิทธิภาพเพียงพอ งานวิจัยนี้จึงนำเสนอแนวทางการเพิ่มประสิทธิภาพการจำแนกโรคข้าวโพดจากภาพถ่ายใบพืช โดยประยุกต์ใช้การประมวลผลภาพในระบบสี HSV ซึ่งมีความสามารถในการแยกเฉดสีที่เกี่ยวข้องกับอาการของโรคได้อย่างแม่นยำ ร่วมกับเทคนิคการเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายและสมดุลของข้อมูลระหว่างคลาส ก่อนนำเข้าสู่กระบวนการเรียนรู้ของโมเดลโครงข่ายประสาทเทียมเชิงลึก (Deep Learning) ผลการทดลองแสดงให้เห็นว่า แนวทางที่นำเสนอสามารถเพิ่มค่าความถูกต้องเฉลี่ย (Accuracy) ในการจำแนกโรคได้ถึง 93.17% เมื่อเทียบกับวิธีดั้งเดิมซึ่งได้ค่าเท่ากับ 91.69%

คำสำคัญ: ปัญญาประดิษฐ์; การประมวลผลภาพ; การเรียนรู้เชิงลึก

Abstract

The outbreak of maize (corn) diseases poses a major challenge, significantly reducing yield and affecting market prices. Timely and accurate diagnosis is essential for effective management, including prevention and treatment. However, self-diagnosis is often unreliable due to fatigue and symptom similarity. Artificial Intelligence (AI) offers a promising solution to reduce farmer burden and improve accuracy. Nevertheless, traditional algorithms may struggle with effective classification. This research proposes an enhanced maize disease classification approach using leaf images, employing HSV color space processing (to better distinguish disease-related color shades) and Data Augmentation (to increase data diversity and balance) prior to Deep Learning model training. Experimental results demonstrate an improved average classification accuracy of 93.17%, compared to 91.69% with conventional methods.

KEYWORDS: Artificial Intelligence; Image Processing; Deep Learning.

1. บทนำ

ข้าวโพด เป็นพืชเศรษฐกิจที่สำคัญของประเทศไทยและหลายประเทศทั่วโลก เนื่องจากเป็นวัตถุดิบหลักในการผลิตอาหารสัตว์ อุตสาหกรรมแปรรูป และเป็นแหล่งพลังงานชีวมวล การเพาะปลูกข้าวโพดมีบทบาทสำคัญต่อความมั่นคงทางอาหารและเศรษฐกิจของประเทศ อย่างไรก็ตาม การเพาะปลูกข้าวโพดมักประสบปัญหาการระบาดของโรคพืชที่มีผลกระทบโดยตรงต่อปริมาณและคุณภาพของผลผลิต โดยเฉพาะโรคที่แสดงอาการบนใบ เช่น โรคราสนิม โรคใบไหม้ และโรคจุดสีน้ำตาล เป็นต้น

ในปัจจุบัน วิธีการตรวจสอบและจำแนกโรคส่วนใหญ่ยังอาศัยการสังเกตด้วยสายตาจากเกษตรกรหรือผู้เชี่ยวชาญด้านโรคพืช ซึ่งมีข้อจำกัดในเรื่องของความถูกต้อง ความรวดเร็ว รวมไปถึงความเหนื่อยล้า และอาจนำไปสู่การตัดสินใจที่ล่าช้าหรือผิดพลาด อันจะส่งผลกระทบต่อประสิทธิภาพของการจัดการโรค การใช้เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยใช้อัลกอริทึมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network : CNN) จึงได้รับความสนใจอย่างมากในงานด้านการจำแนกโรคพืชจากภาพถ่ายใบพืชเนื่องจากมีความสามารถในการเรียนรู้และจำแนกรูปแบบที่ซับซ้อนได้อย่างมีประสิทธิภาพ ดังงานวิจัยของ Muhammad Shoaib และคณะ [1] ซึ่งเสนอการใช้เทคนิคการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึกด้วยการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับเทคนิคการถ่ายโอนเพื่อเพิ่มประสิทธิภาพการระบุโรคพืช รวมไปถึงงานวิจัยของ Jha และคณะ [2] ได้เสนอการใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ปรับแต่งเองในการจำแนกโรคพืช โดยเฉพาะเมื่อนำมาใช้ร่วมกับเทคนิคการประมวลผลภาพดิจิทัล (Digital Image Processing) ดังงานวิจัยของ Barbedo [3] ที่ได้ทำบทสรุปและทบทวนเกี่ยวกับเทคนิคการประมวลผลภาพที่ใช้ในการตรวจจับและจำแนกโรคพืช รวมไปถึงงานวิจัยของ Thakur และคณะ [4] ได้เสนอเทคนิคการเรียนรู้แบบหนึ่งตัวอย่างร่วมกับการประมวลผลภาพเพื่อแก้ปัญหาข้อมูลมีจำนวนจำกัด ซึ่งการประมวลผลภาพช่วยเพิ่มความแม่นยำในการวิเคราะห์อาการของโรคที่ปรากฏบนใบพืช หนึ่งในเทคนิคที่ได้รับความนิยมในขั้นตอนการแยกและดึงคุณลักษณะของสี (Color Feature Extraction) ได้แก่ ระบบสี HSV (Hue, Saturation, Value) ซึ่งเป็นระบบสีที่สอดคล้องกับการรับรู้สีของมนุษย์ จากงานวิจัยของ Misha Paauw และคณะ [5] ได้นำเสนอเครื่องมือ ScAnalyzer ในการประยุกต์ใช้ระบบสี HSV เพื่อแยกส่วนของภาพใบพืช โดยมีวัตถุประสงค์เพื่อแยกแยะบริเวณที่แสดงอาการของโรคออกจากส่วนที่มีสภาพปกติอย่างชัดเจน อันเป็นแนวทางที่แสดงให้เห็นถึงศักยภาพของระบบสี HSV ในการประมวลผลภาพทางการแพทย์ ซึ่งสามารถจำแนกความแตกต่างของเฉดสี ความอิ่มตัวของสี และความสว่างได้อย่างมีประสิทธิภาพ จากแนวคิดดังกล่าว ผู้วิจัยจึงตั้งสมมุติฐานว่าสามารถประยุกต์ใช้ระบบสี HSV เพื่อเพิ่มประสิทธิภาพในการแยกแยะลักษณะอาการของโรคในใบข้าวโพดที่มีลักษณะสีแตกต่างกันอย่างชัดเจนได้อย่างมีประสิทธิภาพ งานวิจัยนี้จึงมุ่งเน้นไปที่การพัฒนาโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ร่วมกับการแปลงภาพจากระบบสี RGB ไปสู่ระบบสี HSV เพื่อจำแนกโรคข้าวโพดจากภาพถ่ายใบข้าวโพดโดยอัตโนมัติ ทั้งนี้เพื่อลดความคลาดเคลื่อนจากการวินิจฉัยด้วยมนุษย์ เพิ่มความรวดเร็วและความแม่นยำในการตรวจวินิจฉัยโรค และสนับสนุนการตัดสินใจในการจัดการโรคพืชได้อย่างมีประสิทธิภาพยิ่งขึ้น

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การเสริมข้อมูล (Data Augmentation)

การเสริมข้อมูล [6], [7] คือกระบวนการสร้างตัวอย่างข้อมูลใหม่จากข้อมูลที่มีอยู่เดิม เพื่อเพิ่มขนาดชุดข้อมูลและสร้างความหลากหลายให้กับข้อมูล โดยเฉพาะในงานที่เกี่ยวข้องกับการเรียนรู้เชิงลึก ซึ่งมักต้องการข้อมูลจำนวนมากเพื่อให้สามารถฝึกโมเดลได้อย่างมีประสิทธิภาพ โดยการเสริมข้อมูลจะเข้ามามีบทบาทในปัญหาข้อมูลจำกัด ลดการฝึกโมเดลมากเกินไป แก้ปัญหาข้อมูลไม่สมดุล โดยเทคนิคการเสริมข้อมูลทำได้หลายวิธี เช่น การหมุนภาพ (Rotation), การเลื่อนตำแหน่งภาพ (Translation), การซูมภาพ

(Zoom), การสะท้อนภาพ (Flipping), การเปลี่ยนแปลงความสว่างของภาพ (Brightness Adjustment) และการเพิ่มสัญญาณรบกวน (Noise Addition) ซึ่งการเสริมข้อมูลจะช่วยเพิ่มความหลากหลายของข้อมูลโดยไม่ต้องเก็บข้อมูลเพิ่ม และช่วยลดปัญหาการเกิด Overfitting ในการจำแนกรวมไปถึงการเอนเอียงของโมเดลจำแนกประเภทข้อมูล

2.2 ระบบสี HSV (Hue, Saturation, Value)

ระบบสี HSV [8], [9] หรือโมเดลสีทรงกระบอก (Cylindrical Color Model) เป็นระบบสีที่พัฒนาขึ้นโดยมีจุดมุ่งหมายเพื่อให้สอดคล้องกับกระบวนการรับรู้สีของมนุษย์มากกว่าระบบสีเชิงกายภาพอย่าง RGB (Red, Green, Blue) ซึ่งเป็นระบบสีที่อิงจากการผสมสีของแสงไฟ โดย HSV แยกองค์ประกอบของสีออกเป็นสามมิติที่เข้าใจง่าย ได้แก่ เฉดสี (Hue), ความอิ่มตัวของสี (Saturation) และความสว่าง (Value) ซึ่งช่วยอำนวยความสะดวกในกระบวนการวิเคราะห์และประมวลผลสีโดยแยกแยะองค์ประกอบของสีออกเป็น 3 มิติหลัก ได้แก่


- Hue (H): หมายถึง เฉดสี หรือประเภทของสี ซึ่งแสดงเป็นค่ามุมบนวงล้อสี (Color Wheel) ในหน่วยองศา (Degree) โดยมีค่าอยู่ในช่วง $0^\circ - 360^\circ$ เช่น แดง, เหลือง, เขียว, ฟ้า, น้ำเงิน, ม่วง

- Saturation (S): หมายถึง ความอิ่มตัวของสี หรือความบริสุทธิ์ของสี เป็นอัตราส่วนระหว่างความแตกต่างของค่าความเข้มข้นของสีที่สูงที่สุดและต่ำที่สุดเมื่อเปรียบเทียบกับค่าความเข้มข้นสูงสุด ซึ่งแสดงเป็นค่าระหว่าง 0 ถึง 1 โดยค่า $S = 0$ หมายถึง สีขาวหรือสีเทา (ไม่มีความอิ่มตัวของสี) หากค่า $S = 1$ จะหมายถึง สีที่มีความบริสุทธิ์เต็มที่

- Value (V): หมายถึง ความสว่างของสี หรือความเข้มของสีโดยรวม โดยแสดงเป็นค่าระหว่าง 0 ถึง 1 เช่นกัน ค่า $V = 0$ จะหมายถึง สีดำ (ไม่มีความสว่าง) หากค่า $V = 1$ หมายถึง สีที่สว่างที่สุดเท่าที่สามารถแสดงได้ในระบบนั้น ๆ

2.3 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network)

โครงข่ายประสาทแบบคอนโวลูชัน [10] จะจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาพาสกัน เพื่อจำแนกว่าสิ่งที่เห็นอยู่เป็นวัตถุประเภทใด การมองพื้นที่ย่อยของมนุษย์จะมีการแยกคุณลักษณะ (Feature) ของพื้นที่ย่อยนั้น โดยตัวอย่างโครงสร้างของโครงข่ายประสาทแบบคอนโวลูชัน แสดงดังรูปที่ 1




รูปที่ 1 โครงสร้างโครงข่ายประสาทแบบคอนโวลูชัน [10]

กระบวนการทำคอนโวลูชัน จะทำการเลื่อนตัวกรองนี้ไปที่ข้อมูลนำเข้า ณ ทุก ๆ ตำแหน่ง และทำการคูณค่าของแต่ละพิกเซล (Pixel) แล้วรวมผลลัพธ์ทั้งหมด เพื่อให้ได้ค่าผลรวมนั้นไปไว้ในฟังก์ชันลักษณะ (Feature Map) ที่เกิดขึ้น พื้นที่สี่เหลี่ยม (รูปที่ 2) ที่คอนโวลูชันถูกทำนี้เรียกว่า พื้นที่ที่รับสัญญาณ (Receptive Field) โดยเนื่องจากขนาดของตัวกรองทำให้พื้นที่ที่รับรู้ (Receptive Field) นั้นเป็นขนาด 3x3 แสดงขนาดตัวกรอง ดังรูปที่ 2(ก) กระบวนการกรอง ดังรูปที่ 2(ข) และผลลัพธ์จากการกรองข้อมูล ดังรูปที่ 2(ค)

การทำงานของคอนโวลูชันนั้นสามารถอธิบายด้วยสมการที่แสดงถึงการคำนวณระหว่างการเลื่อนตัวกรองและองค์ประกอบของภาพในแต่ละชั้น ดังสมการที่ 1

$$\text{output of size} = \frac{N-F+2P}{S} + 1 \quad (1)$$

- โดยที่
- N คือ ขนาดของภาพอินพุต
 - F คือ ขนาดของตัวกรองที่เลื่อนผ่านภาพเพื่อตรวจจับคุณสมบัติต่าง ๆ
 - P คือ จำนวนพิกเซลที่เสริมขอบรอบภาพ
 - S คือ จำนวนพิกเซลที่ตัวกรองเลื่อนในแต่ละครั้ง



รูปที่ 2 กระบวนการกรองข้อมูลและผลลัพธ์จากการกรองข้อมูล

การเชื่อมต่อแบบเต็ม (Fully Connected) ทำหน้าที่รวมคุณลักษณะที่ถูกดึงออกมาเพื่อสร้างการตัดสินใจสุดท้ายในระบบโครงข่ายประสาทเทียม โดยขั้นนี้จะนำข้อมูลที่ผ่านการคำนวณทั้งหมดมารวมกันเพื่อสร้างผลลัพธ์ ดังสมการที่ 2

$$H_i = \sum_{i=0}^{n-1} (x_i \cdot W_i) \quad (2)$$

- โดยที่
- H_i คือ ผลลัพธ์ที่ได้จากชั้นซ่อน (Hidden Layer) สำหรับโหนดที่ i
 - n คือ จำนวนของข้อมูลนำเข้าจากโหนดก่อนหน้า
 - x_i คือ ข้อมูลของโหนดนำเข้าที่ i
 - W_i คือ ค่าน้ำหนักที่เชื่อมโยงระหว่างข้อมูลนำเข้า x_i

ฟังก์ชันซอฟต์แมกซ์ (Softmax Function) เป็นฟังก์ชันที่แปลงผลลัพธ์จากโมเดล (Logits) เป็นค่าความน่าจะเป็นสำหรับแต่ละคลาส โดยค่าที่ได้จะรวมกันเป็น 1 ซึ่งช่วยให้การตีความผลลัพธ์และการตัดสินใจในงานการจำแนกประเภทมีประสิทธิภาพมากขึ้น

นอกจากนี้ยังช่วยในการฝึกโมเดลโดยการเปรียบเทียบค่าความน่าจะเป็นที่คาดการณ์กับค่าความจริง (Ground Truth) เพื่อปรับปรุงน้ำหนักของโมเดล ดังสมการที่ 3


$$S(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (3)$$

โดยที่	S	คือ ความน่าจะเป็นที่ตัวอย่างจะอยู่ในคลาส j ระหว่าง 0 ถึง 1
	x_i	คือ จำนวนของข้อมูลนำเข้าจากโหนดก่อนหน้า
	n	คือ จำนวนคลาสทั้งหมด
	e	คือ ฐานของลอการิทึมธรรมชาติ (Euler's number)

3. วิธีดำเนินการวิจัย

3.1 ขั้นตอนการดำเนินงาน

ในงานวิจัยนี้ ผู้วิจัยได้ดำเนินการออกแบบกระบวนการวิจัยอย่างเป็นระบบ โดยกำหนดลำดับขั้นตอนที่ชัดเจนตั้งแต่การเตรียมข้อมูล การประมวลผลเบื้องต้น การออกแบบและฝึกโมเดล ไปจนถึงการประเมินประสิทธิภาพของแบบจำลอง เพื่อให้สามารถศึกษาความสัมพันธ์ระหว่างเทคนิคการเสริมข้อมูลและการแปลงระบบสี HSV กับผลลัพธ์ของการจำแนกโรคในข้าวโพดได้อย่างเป็นรูปธรรม โดยแสดงกรอบแนวคิดการวิจัยดังรูปที่ 3



รูปที่ 3 กรอบแนวคิดการวิจัย

จากรูปที่ 3 สามารถอธิบายกรอบแนวคิดการวิจัยได้ว่า ขั้นตอนแรกคือการดำเนินการปรับปรุงความสมดุลของข้อมูลต้นฉบับ ด้วยเทคนิคการเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายและลดปัญหาการกระจายตัวของข้อมูลในแต่ละคลาส จากนั้นจึงดำเนินการประมวลผลภาพโดยการแปลงภาพจากระบบสี RGB ไปยังระบบสี HSV ซึ่งมีความสามารถในการแยกความแตกต่างของสีที่สัมพันธ์กับอาการของโรคได้อย่างมีประสิทธิภาพ ต่อมา ข้อมูลที่ผ่านการปรับปรุงแล้วจะถูกนำไปใช้ในการฝึกโมเดลด้วยอัลกอริทึมการเรียนรู้เชิงลึกจำนวนสามแบบ ได้แก่ DenseNet, ResNet50 และ VGG19 ทั้งนี้โมเดลที่ได้จากแต่ละอัลกอริทึมจะถูกนำมาทดสอบเพื่อจำแนกประเภทของโรค และทำการประเมินประสิทธิภาพของโมเดลผ่านค่าตัวชี้วัดทางสถิติเพื่อเปรียบเทียบผลลัพธ์ของแต่ละวิธีการ โดยอธิบายแต่ละขั้นตอนได้ดังต่อไปนี้

3.1.1 ลักษณะของข้อมูล

ในการวิจัยนี้ ผู้วิจัยได้ใช้ข้อมูลภาพใบข้าวโพดที่ได้รับการเผยแพร่เพื่อการทำวิจัยจากเว็บไซต์ Kaggle (Corn or Maize Leaf Disease Dataset) โดยชุดข้อมูลจะมีจำนวนภาพทั้งหมด 4188 ภาพ แต่ละภาพมีจำนวนไม่เท่ากัน โดย โรคราสนิม (Common Rust) มีจำนวน 1306 รูป โรคใบจุด (Gray Leaf Spot) มีจำนวน 574 รูป โรคใบไหม้แผลใหญ่ (Blight) จำนวน 1145 รูป และใบปกติ (Healthy) จำนวน 1162 รูป จากข้อมูลพบว่าโรคใบจุดมีจำนวนรูปภาพน้อยกว่าคลาสนอื่นเป็นจำนวนมากทำให้เกิดความไม่สมดุลกันของข้อมูลเกิดขึ้น จึงนำเทคนิคการเสริมข้อมูลเข้ามาเพื่อปรับให้ข้อมูลมีความสมดุลมากขึ้น

3.1.2 เสริมข้อมูล


เนื่องจากข้อมูลโรคใบจุดมีจำนวนข้อมูลแตกต่างจากข้อมูลโรคอื่น ๆ เป็นจำนวนมาก ส่งผลให้เกิดความไม่สมดุลของข้อมูลเกิดขึ้น ซึ่งจะส่งผลต่อประสิทธิภาพในการจำแนก ดังนั้นผู้วิจัยจึงได้เลือกใช้เทคนิคการเสริมข้อมูลเพื่อปรับข้อมูลของโรคใบจุดให้มีจำนวนใกล้เคียงกับคลาสนอื่น ๆ โดยใช้รูปภาพต้นฉบับแสดงดังรูปที่ 4(ก) ซึ่งจะเลือกใช้วิธีการหมุนภาพ (Rotation) ที่ขอบเขตการหมุนภาพที่ ± 20 องศา ผลลัพธ์การหมุนภาพแสดงดังรูปที่ 4(ข), การสะท้อนภาพ ผลลัพธ์แสดงดังรูปที่ 4(ค), การพลิกภาพแบบแนวนอน แสดงผลลัพธ์ดังรูปที่ 4(ง) และการซูมภาพ (Zoom) ที่ 0.2 แสดงดังรูปที่ 4(จ)

3.1.3 HSV

การจำแนกโรคจากภาพใบข้าวโพดในงานวิจัยนี้จะนำรูปภาพในระบบสี RGB มาประมวลผลภาพเปลี่ยนเป็นระบบสี HSV เนื่องจากระบบสี HSV สามารถสะท้อน ลักษณะการเปลี่ยนแปลงของสีใบที่เกิดจากโรคได้อย่างแม่นยำและสอดคล้องกับการรับรู้ของมนุษย์มากกว่าระบบสี RGB โดยระบบสี HSV สามารถแยกแยะสีออกจากความสว่างและความอิ่มตัวได้ชัดเจน ช่วยให้สามารถตรวจจับเจดสีของอาการโรคได้อย่างมีประสิทธิภาพ แม้ว่าสภาพแสงจะเปลี่ยนแปลง ลักษณะการแสดงอาการของโรคพืชที่มักปรากฏในรูปแบบของการเปลี่ยนแปลงเจดสีบนใบพืชมากกว่าการเปลี่ยนแปลงของโครงสร้างภาพ เช่น รูปร่างหรือลาย โดยตัวอย่างรูปภาพดั้งต้นในระบบสี RGB แสดงดังรูปที่ 5(ก) และรูปหลังการประมวลผลภาพเป็นระบบสี HSV แสดงดังรูปที่ 5(ข)



รูปที่ 4 การเสริมข้อมูลรูปใบโรคข้าวโพด



รูปที่ 5 การประมวลผลภาพด้วยระบบสี HSV

3.1.4 โครงสร้างโมเดลการเรียนรู้

ในขั้นตอนการสร้างโมเดลการเรียนรู้ ผู้วิจัยเลือกใช้อัลกอริทึมที่มีโครงสร้างพื้นฐานจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน 3 แบบในการทดลอง ได้แก่อัลกอริทึม DenseNet, ResNet50 และ VGG19 โดยมีรายละเอียดของแต่ละอัลกอริทึมที่ทดลองใช้ดังนี้

1) DenseNet (Densely Connected Convolutional Networks)

DenseNet ถูกออกแบบโดยมีแนวคิดสำคัญคือ การเชื่อมต่อทุก ๆ ชั้นภายในบล็อกเดียวกันเข้าหากันแบบโดยตรง (Direct Connections) กล่าวคือ แต่ละชั้นจะได้รับอินพุตเป็นผลลัพธ์ (Feature Maps) จากทุกชั้นก่อนหน้า และจะส่งเอาต์พุตของตนเองไปยังทุกชั้นถัดไปภายใน Dense Block นั้น ๆ โดยไม่มีการรวม (Sum) แต่ใช้การนำข้อมูลมาต่อกันในมิติ Channel (Concatenation)

2) ResNet50 (Residual Network 50)

ResNet เป็นสถาปัตยกรรมโครงข่ายคอนโวลูชันเชิงลึกซึ่งนำเสนอแนวคิด "Residual Learning" เพื่อแก้ปัญหา Gradient Vanishing และ Degradation Problem ที่มักเกิดขึ้นในโครงข่ายที่มีความลึกสูง โดย ResNet อาศัยโครงสร้าง "Residual Block" ซึ่งมีการเพิ่มทางลัด (Shortcut Connection) หรือ Identity Mapping เพื่อช่วยให้ข้อมูลและ Gradient ไหลย้อนกลับได้สะดวกขึ้น ทำให้สามารถสร้างโครงข่ายที่ลึกได้ถึงระดับหลายร้อยชั้นโดยไม่ลดทอนประสิทธิภาพ โดย ResNet50 จะประกอบด้วย 50 ชั้น (50 Layers) ซึ่งได้รับการออกแบบมาอย่างสมดุลระหว่างความลึกและความเร็วในการคำนวณ

3) VGG19

โครงข่าย VGG19 ได้รับการออกแบบมาเพื่อแก้ไขข้อจำกัดของโครงข่ายแบบดั้งเดิมที่มีโครงสร้างซับซ้อนเกินความจำเป็น โดย VGG19 นำเสนอแนวคิดการใช้ชุดของชั้นคอนโวลูชันขนาดเล็ก (3x3) หลายชั้นซ้อนกันแทนที่จะใช้ชั้นคอนโวลูชันขนาดใหญ่ ซึ่งช่วยเพิ่มความลึกของโครงข่ายได้โดยไม่เพิ่มจำนวนพารามิเตอร์มากเกินไป โดย VGG19 จะประกอบไปด้วยเลเยอร์จำนวน 19 ชั้น แบ่งออกเป็น 16 ชั้นจากกระบวนการคอนโวลูชัน และ 3 ชั้นจากกระบวนการเชื่อมต่อแบบเต็ม

4. ผลการวิจัยและอภิปรายผลการวิจัย

การทดลองในงานวิจัยนี้มีวัตถุประสงค์เพื่อประเมินประสิทธิภาพของวิธีการจำแนกโรคพืชจากภาพถ่ายใบข้าวโพดภายใต้เงื่อนไขของข้อมูลที่แตกต่างกัน โดยออกแบบชุดการทดลองทั้งหมด 2 รูปแบบ เพื่อเปรียบเทียบผลกระทบของการเสริมข้อมูลและการประมวลผลภาพในระบบสี HSV ต่อประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก (Deep Learning Algorithms) รายละเอียดของการทดลองมีดังนี้

ชุดการทดลองที่ 1: ใช้ข้อมูลต้นฉบับโดยไม่มีการปรับสมดุลของจำนวนตัวอย่างในแต่ละคลาส (Imbalanced Data) และไม่ใช้เทคนิคการเสริมข้อมูล (No Augmentation)

ชุดการทดลองที่ 2: เป็นเทคนิคที่นำเสนอในงานวิจัยนี้ โดยใช้การประมวลผลภาพผ่านการแปลงระบบสีจาก RGB ไปยัง HSV ร่วมกับการปรับข้อมูลสมดุลด้วยการเสริมข้อมูล เพื่อเสริมความสามารถในการแยกแยะที่สะท้อนอาการของโรคให้แม่นยำยิ่งขึ้น

สำหรับการจำแนกโรคจากภาพถ่ายใบพืชในแต่ละชุดการทดลอง ข้อมูลจะถูกนำเข้าสู่กระบวนการเรียนรู้ด้วยอัลกอริทึมโครงข่ายประสาทเทียมเชิงลึก 3 แบบ ได้แก่ DenseNet, ResNet-50 และ VGG19 ซึ่งเป็นโมเดลที่ได้รับการยอมรับในงานด้านการรู้จำภาพ ทั้งนี้เพื่อประเมินประสิทธิภาพเชิงเปรียบเทียบของวิธีการที่เสนอภายใต้อัลกอริทึมที่แตกต่างกัน

ในการทดลองนี้ใช้วิธีการประเมินผลแบบ 3-Fold Cross-Validation โดยแบ่งชุดข้อมูลทั้งหมดออกเป็น 3 ส่วนที่มีขนาดเท่า ๆ กัน จากนั้นดำเนินการฝึกโมเดลด้วยข้อมูลจำนวน 2 ส่วน และใช้ส่วนที่เหลืออีก 1 ส่วนสำหรับการทดสอบประสิทธิภาพของโมเดล โดยจะสลับสับเปลี่ยนชุดข้อมูลที่ใช้ในการฝึกและทดสอบจนครบทั้ง 3 ชุด (ครบทุก Fold) ผลการจำแนกจากชุดการทดลองที่ 1 ซึ่งใช้ข้อมูลต้นฉบับโดยไม่ผ่านการเสริมข้อมูล แสดงดังตารางที่ 1

ตารางที่ 1 ผลการจำแนกด้วยการใช้ข้อมูลต้นฉบับ

DenseNet			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	378	2	12	0
		ใบจุด	7	140	25	0
		ใบไหม้แผลใหญ่	18	16	299	1
ใบปกติ		0	0	0	349	
ResNet50			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	357	19	14	2
		ใบจุด	0	130	42	0
		ใบไหม้แผลใหญ่	4	29	300	1
ใบปกติ		0	1	0	348	
VGG19			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	360	18	14	0
		ใบจุด	0	148	24	0
		ใบไหม้แผลใหญ่	2	53	278	1
ใบปกติ		0	4	2	343	

จากผลการทดลองที่แสดงในตารางที่ 1 ซึ่งเป็นผลการจำแนกโรคข้าวโพดจากภาพใบพืชโดยใช้ข้อมูลต้นฉบับที่ไม่ได้ผ่านกระบวนการเสริมข้อมูล (Data Augmentation) พบว่าอัลกอริทึม DenseNet ให้ค่าความถูกต้อง (Accuracy) ในการจำแนกสูงที่สุดอยู่ที่ร้อยละ 93.50 รองลงมาคืออัลกอริทึม ResNet50 ซึ่งให้ค่าความถูกต้องอยู่ที่ร้อยละ 91.02 และอัลกอริทึม VGG19 ให้ค่าความถูกต้องอยู่ที่ร้อยละ 90.54 ตามลำดับ

สำหรับการทดลองในชุดการทดลองที่ 2 ได้ดำเนินการปรับสมดุลของข้อมูลโดยการเสริมจำนวนภาพของกลุ่มโรคใบจุดผ่านเทคนิคการเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายของข้อมูลและลดปัญหาคลาสไม่สมดุล (Class Imbalance) จากนั้นดำเนินการแปลงภาพจากระบบสี RGB ไปเป็นระบบสี HSV ซึ่งเป็นแนวทางที่นำเสนอในงานวิจัยนี้ โดยมีวัตถุประสงค์เพื่อแยกแยะสีที่เกี่ยวข้องกับอาการของโรคได้อย่างชัดเจนยิ่งขึ้น ผลลัพธ์จากการจำแนกในชุดการทดลองนี้แสดงไว้ในตารางที่ 2

ตารางที่ 2 ผลการจำแนกด้วยเทคนิคที่นำเสนอ

DenseNet			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	371	2	18	1
		ใบจุด	0	200	22	0
		ใบไหม้แผลใหญ่	3	12	318	1
		ใบปกติ	0	0	0	349
ResNet50			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	363	18	8	3
		ใบจุด	0	205	14	3
		ใบไหม้แผลใหญ่	5	41	279	9
		ใบปกติ	0	0	0	349
VGG19			ข้อมูลจริง (Actual Data)			
			ราสนิม	ใบจุด	ใบไหม้แผลใหญ่	ใบปกติ
	ข้อมูลจำแนก (Predicted)	ราสนิม	364	10	18	0
		ใบจุด	3	191	27	1
		ใบไหม้แผลใหญ่	8	27	298	1
		ใบปกติ	3	2	6	340

จากผลการทดลองที่แสดงในตารางที่ 2 เป็นผลการจำแนกโรคข้าวโพดจากภาพใบพืชโดยใช้ข้อมูลต้นฉบับนำไปเสริมข้อมูลของคลาสใบจุดพบว่าอัลกอริทึม DenseNet ให้ค่าความถูกต้อง (Accuracy) ในการจำแนกสูงที่สุดอยู่ที่ร้อยละ 95.45 รองลงมาคืออัลกอริทึม ResNet50 ซึ่งให้ค่าความถูกต้องอยู่ที่ร้อยละ 92.21 และอัลกอริทึม VGG19 ให้ค่าความถูกต้องอยู่ที่ร้อยละ 91.83 ตามลำดับ

ผลการทดลองเชิงเปรียบเทียบแสดงให้เห็นว่า วิธีการที่นำเสนอซึ่งผสมผสานระหว่างการแปลงภาพในระบบสี HSV และการเสริมข้อมูลแบบสมดุล สามารถเพิ่มความแม่นยำในการจำแนกได้สูงกว่าวิธีการแบบไม่เสริมข้อมูลอย่างมีนัยสำคัญในทุกอัลกอริทึมที่ใช้ในการทดลอง

5. สรุปผลการวิจัย

งานวิจัยนี้นำเสนอเทคนิคในการเพิ่มประสิทธิภาพของอัลกอริทึมการเรียนรู้เชิงลึกสำหรับการจำแนกโรคในข้าวโพดจากภาพถ่ายใบพืช โดยประยุกต์ใช้การเสริมข้อมูล (Data Augmentation) ร่วมกับการประมวลผลภาพผ่านการแปลงระบบสีจาก RGB ไปเป็น HSV ซึ่งมีวัตถุประสงค์เพื่อเพิ่มความหลากหลายของข้อมูลฝึกและแยกองค์ประกอบของสีที่สัมพันธ์กับอาการของโรคได้ชัดเจนยิ่งขึ้น ผลการทดลองแสดงให้เห็นว่าเทคนิคดังกล่าวส่งผลให้ประสิทธิภาพในการจำแนกโรคของโมเดลเพิ่มขึ้นในทุกอัลกอริทึมที่นำมาประเมิน โดยเฉพาะในอัลกอริทึม DenseNet ซึ่งค่าความถูกต้องในการจำแนกเพิ่มขึ้นจากร้อยละ 93.50 เป็นร้อยละ 95.45 ขณะที่ ResNet50 มีค่าความถูกต้องเพิ่มจากร้อยละ 91.02 เป็นร้อยละ 92.21 และ VGG19 เพิ่มขึ้นจากร้อยละ 90.54 เป็นร้อยละ 91.83

การยกระดับประสิทธิภาพของแบบจำลองนี้เป็นมากกว่าความก้าวหน้าทางทฤษฎี แต่ได้นำมาซึ่งศักยภาพในการประยุกต์ใช้จริง (Practical Application) ที่เป็นประโยชน์ต่อภาคเกษตรกรรมอย่างยิ่ง โดยหลักการสำคัญคือการอำนวยความสะดวกให้เกษตรกรและผู้ใช้งานทั่วไปสามารถเข้าถึงระบบการวินิจฉัยโรคพืชได้อย่างสะดวก รวดเร็ว และมีความแม่นยำสูง ณ จุดเกิดเหตุ (Point-of-Care Diagnostics) ซึ่งเป็นการลดภาระในการตรวจสอบด้วยตนเองที่อาจเกิดความคลาดเคลื่อน (Misdiagnosis) และต้องอาศัยผู้เชี่ยวชาญ ระบบนี้จึงทำหน้าที่เป็นเครื่องมือสำคัญในการสนับสนุนการตัดสินใจเชิงปฏิบัติการ (Operational Decision Support) เกี่ยวกับการใช้มาตรการป้องกันและการรักษาโรคได้อย่างทัน่วงทีและมีประสิทธิภาพสูงสุด

ผลกระทบจากการนำแนวทางนี้ไปใช้ก่อให้เกิดประโยชน์หลายมิติทั้งในด้านการเพิ่มผลิตภาพและคุณภาพผลผลิตผ่านการรักษาที่ถูกต้องแม่นยำตั้งแต่ระยะเริ่มต้น ส่งผลต่อการเพิ่มรายได้และความมั่นคงทางเศรษฐกิจของเกษตรกร นอกจากนี้ยังสนับสนุนหลักการเกษตรแม่นยำด้วยการลดการใช้สารเคมีที่ไม่จำเป็นอันนำไปสู่การลดผลกระทบเชิงลบต่อสิ่งแวดล้อมและเพิ่มความปลอดภัยของอาหาร (Food Safety) ในขณะที่ความง่ายในการเข้าถึงเทคโนโลยีนี้ยังช่วยให้เกิดความเท่าเทียมในการเข้าถึงองค์ความรู้สำหรับเกษตรกรรายย่อยในพื้นที่ห่างไกลเพื่อขับเคลื่อนการปฏิรูปภาคเกษตรกรรมสู่ยุคดิจิทัลอย่างยั่งยืน

ผลประโยชน์ทับซ้อน

ผู้เขียนขอประกาศว่าบทความนี้ไม่มีผลประโยชน์ทับซ้อน

เอกสารอ้างอิง

- [1] Choong, F. C. M., & Jan Hong, B. N. (2025). An improved convolutional neural network (CNN) for disease detection and diagnosis for multi-crop plants. *Journal of Engineering Technology and Applied Physics*, 7(1), 7–14.
- [2] Jha, S., & Zia, M. (2023). Plant disease classification using convolutional neural networks. *International Research Journal of Advanced Engineering and Science*, 8(3), 417–421.
- [3] Barbedo, J. G. A. (2023). Plant disease detection and classification techniques: A comparative study. *Journal of Big Data*, 10(1), 1–20.
- [4] Thakur, P. S., Khanna, P., Sheorey, T., & Ojha, A. (2023). A plant disease classification using one-shot learning technique with limited datasets utilizing Siamese Neural Network (SNN). *Multimedia Tools and Applications*, 82(1), 1–20.
- [5] Paauw, M., Hardeman, G., Taks, N. W., Lambalk, L., Berg, J. A., Pfeilmeier, S., & van den Burg, H. A. (2024). ScAnalyzer: An image processing tool to monitor plant disease symptoms and pathogen spread in *Arabidopsis thaliana* leaves. *Plant Methods*, 20, 80.
- [6] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.
- [7] Xu, M., Yoon, S., Fuentes, A., & Park, D. S. (2022). A comprehensive survey of image augmentation techniques for deep learning. *Pattern Recognition*, 107, 107377.

- [8] Bora, D. J., Gupta, A. K., & Khan, F. A. (2015). Comparing the performance of L*A*B* and HSV color spaces with respect to color image segmentation. *International Journal of Emerging Technology and Advanced Engineering*, 5(2), 192–199.
- [9] Hema, D., & Kannan, S. (2020). Interactive color image segmentation using HSV color space. *Science and Technology Journal*, 7(1), 1–6.
- [10] Ayeni, J. A. (2022). Convolutional Neural Network (CNN): The architecture and applications. *Applied Journal of Physical Science*, 4(4), 42–50.