

# การเพิ่มประสิทธิภาพแบบจำลองโครงข่ายประสาทแบบคอนโวลูชันสำหรับการจำแนกสายพันธุ์ข้าวด้วยตัวดำเนินการพรีวิทที่ปรับแต่งเฉพาะ

## Enhancing the efficiency of a convolutional neural network model for rice variety classification using a customized prewitt operator

เจษฎา สิงห์ทองชัย<sup>1</sup>, สุทธิพงษ์ คล่องดี<sup>2</sup> และณัฐวุฒิ ศรีวิบูลย์<sup>1\*</sup>

Jatsada Singthongchai<sup>1</sup>, Suttipong Klongdee<sup>2</sup> and Nattavut Sriwiboon<sup>1\*</sup>

**Received:** 16 September 2024 ; **Revised:** 22 April 2025 ; **Accepted:** 5 June 2025

### บทคัดย่อ

การจำแนกสายพันธุ์ข้าวเป็นหนึ่งในกระบวนการสำคัญในอุตสาหกรรมเกษตรกรรม ซึ่งมีผลกระทบโดยตรงต่อคุณภาพของผลิตภัณฑ์และกระบวนการผลิต บทความนี้นำเสนอวิธีการปรับปรุงประสิทธิภาพของการจำแนกสายพันธุ์ข้าวโดยใช้ Convolutional Neural Network (CNN) ร่วมกับ Prewitt Operator สำหรับการตรวจจับขอบที่ชัดเจนจากภาพถ่ายเมล็ดข้าว เทคนิคนี้ช่วยเพิ่มความแม่นยำในการแยกแยะเมล็ดข้าวที่มีลักษณะใกล้เคียงกัน ผลการทดลองแสดงให้เห็นว่าโมเดล CNN ร่วมกับ Prewitt Operator สามารถเพิ่มความแม่นยำของการจำแนกได้ถึง 98.5% ซึ่งสูงกว่างานวิจัยก่อนหน้านี้ที่ใช้วิธีการอื่น เช่น Sobel และ Canny Edge Detection ซึ่งให้ความแม่นยำในช่วง 85-96% บทความนี้จะกล่าวถึงขั้นตอนการพัฒนาารูปแบบ CNN และ Prewitt Operator รวมถึงการเปรียบเทียบกับงานวิจัยที่เกี่ยวข้อง แสดงให้เห็นถึงความสามารถในการจำแนกเมล็ดข้าวในสภาพแวดล้อมที่ต่างกัน

**คำสำคัญ:** พันธุ์ข้าว, การเรียนรู้เชิงลึก, โครงข่ายประสาทแบบคอนโวลูชัน, EfficientNetB0

### Abstract

Rice variety classification is a crucial process in the agricultural industry, directly impacting product quality and production efficiency. This article presents a method for enhancing rice variety classification efficiency using a Convolutional Neural Network (CNN) integrated with a customized Prewitt operator for precise edge detection from grain images. This technique improves the accuracy of distinguishing between rice varieties with similar characteristics. The experimental results demonstrate that the CNN model combined with the Prewitt operator achieves a classification accuracy of 98.5%. This performance surpasses previous research using other methods, such as Sobel and Canny edge detection, which reported accuracies ranging from 85% to 96%. This article discusses the development stages of the CNN model and the Prewitt operator and provides a comparison with related works, highlighting its effectiveness across diverse environments.

**Keywords:** Rice variety, deep learning, convolutional neural networks, EfficientNetB0

<sup>1</sup> ผู้ช่วยศาสตราจารย์, คณะวิทยาศาสตร์และเทคโนโลยีสุขภาพ มหาวิทยาลัยกาฬสินธุ์

<sup>2</sup> คณะเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก วิทยาเขตจันทบุรี

<sup>1</sup> Assistant professor, Faculty of Sciences and Health Technology, Kalasin University, Kalasin

<sup>2</sup> Faculty of Social Technology, Rajamangala University of Technology Tawan-ok, Chanthaburi Campus, Chanthaburi

\* Corresponding author: E-mail: nattavut.sr@ksu.ac.th

## บทนำ

การจำแนกสายพันธุ์ข้าวเป็นหนึ่งในกระบวนการที่สำคัญในอุตสาหกรรมเกษตรกรรม อย่างไรก็ตามในปัจจุบัน การจำแนกสายพันธุ์ข้าวประสบปัญหาเกี่ยวกับความไม่แม่นยำเนื่องจากลักษณะที่คล้ายคลึงกันระหว่างสายพันธุ์ การจำแนกข้าวอย่างแม่นยำจึงเป็นสิ่งจำเป็นเพื่อควบคุมคุณภาพและปรับปรุงประสิทธิภาพการผลิต ในปัจจุบันเทคโนโลยีการประมวลผลภาพและการเรียนรู้เชิงลึก (Deep Learning) (LeCun *et al.*, 2015) ได้เข้ามามีบทบาทสำคัญในการแก้ปัญหาด้านการจำแนกสายพันธุ์ข้าว โดยเฉพาะการประยุกต์ใช้ โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) (Krizhevsky *et al.*, 2012) ที่มีความสามารถในการวิเคราะห์และตรวจจับคุณลักษณะเชิงลึกของภาพ (Arunsiwattana *et al.*, 2021; Kongchai, 2023; Rattanapoka, 2024; Senawong *et al.*, 2022; Sriwiboon, 2021) อย่างไรก็ตามการใช้โมเดล CNN เพียงอย่างเดียวอาจยังไม่เพียงพอในการจำแนกสายพันธุ์ข้าวที่มีลักษณะคล้ายคลึงกัน อีกทั้งปัญหาของงานวิจัยก่อนหน้านี้ (Chatnuntaweche *et al.*, 2018; Gayathri Devi & Siddappa, 2017; Kolkure & Shaikh, 2017; Mousavirad & Minaei, 2012; Zareiforush *et al.*, 2016) ที่เสนอวิธีการจำแนกเมล็ดข้าวยังคงมีข้อจำกัดในการตรวจจับขอบที่ไม่ชัดเจน

ด้วยเหตุนี้งานวิจัยนี้จึงนำเสนอการปรับปรุงประสิทธิภาพของโมเดล CNN ด้วยการใช้ Prewitt Operator (Prewitt, 1970) ซึ่งเป็นเทคนิคตรวจจับขอบที่ได้รับการปรับแต่งเฉพาะสำหรับข้อมูลภาพเมล็ดข้าว การดำเนินการดังกล่าวช่วยเพิ่มความสามารถในการแยกแยะรายละเอียดสำคัญของเมล็ดข้าว และช่วยให้การจำแนกสายพันธุ์ข้าวมีความแม่นยำมากยิ่งขึ้น

ผลการทดลองแสดงให้เห็นว่า การใช้ CNN ร่วมกับ Prewitt Operator สามารถเพิ่มความแม่นยำ (Accuracy) ของโมเดลได้อย่างชัดเจน โดยเฉพาะในโมเดล EfficientNetB0 ที่มีค่าความแม่นยำสูงสุดถึง 98.5% ซึ่งสูงกว่าการใช้ CNN เพียงอย่างเดียวที่มีค่าความแม่นยำอยู่ที่ 96.8% โมเดลอื่น ๆ เช่น ResNet50V2 และ InceptionV3 ก็มีประสิทธิภาพดีขึ้นอย่างเห็นได้ชัดด้วยการใช้ Prewitt Operator บทความนี้จะนำเสนอแนวทางการปรับแต่ง Prewitt Operator การสร้างโมเดล CNN ที่เหมาะสมและผลการทดลองที่แสดงถึงประสิทธิภาพที่เพิ่มขึ้นในการจำแนกสายพันธุ์ข้าว

## วัตถุประสงค์ของงานวิจัย

1. เพื่อเสนอแนวทางการปรับแต่ง Prewitt Operator สำหรับจำแนกสายพันธุ์ข้าว

เพื่อสร้างโมเดล (Model) โดยใช้ CNN สำหรับจำแนกสายพันธุ์ข้าวที่แตกต่างกัน 5 สายพันธุ์

2. เพื่อแสดงให้เห็นว่าวิธีการปรับแต่งเฉพาะให้กับ Prewitt Operator ที่เสนอโดยงานวิจัยนี้ (Chatnuntaweche *et al.*, 2018; Gayathri Devi & Siddappa, 2017; Kolkure & Shaikh, 2017; Mousavirad & Minaei, 2012; Zareiforush *et al.*, 2016)

3. สามารถเพิ่มประสิทธิภาพการจำแนกสายพันธุ์ข้าวให้กับแบบจำลอง CNN

## ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

### 1. โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN)

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) เป็นโครงข่ายประสาทเทียมที่ถูกออกแบบมาเพื่อการประมวลผลข้อมูลภาพ โดยอาศัยการทำงานของ convolutional layers ซึ่งทำหน้าที่ตรวจจับคุณลักษณะเฉพาะของภาพ เช่น ขอบ, รูปทรง, และเนื้อสัมผัส CNN มีบทบาทสำคัญในงานด้านการจำแนกภาพ การตรวจจับวัตถุ และการแบ่งส่วนภาพ หนึ่งในสถาปัตยกรรมยอดนิยมของ CNN คือ VGG16 และ VGG19 (Simonyan & Zisserman, 2015) ซึ่งเน้นการออกแบบที่เรียบง่ายและใช้การเรียงตัวของ convolutional layers หลายชั้น โดย VGG16 มี 16 ชั้น และ VGG19 มี 19 ชั้น ส่วน InceptionV3 (Szegedy *et al.*, 2016) ใช้เทคนิค Inception module ที่รวมหลายขนาดของ convolution ใน layer เดียว ทำให้สามารถจับคุณลักษณะหลากหลายได้ในขั้นตอนเดียว ต่อมาคือ ResNet50V2 (He *et al.*, 2016) ซึ่งใช้ Residual Blocks เพื่อลดปัญหา vanishing gradient ในการฝึกโมเดลที่ลึกมาก ResNet50V2 มี 50 layers และมีการปรับปรุงการคำนวณระหว่าง layer ให้มีความแม่นยำยิ่งขึ้น ในขณะที่ EfficientNetB0 (Tan & Le, 2019) มุ่งเน้นการเพิ่มประสิทธิภาพด้วยการปรับขนาดของความลึก (depth), ความกว้าง (width), และความละเอียดของภาพ (resolution) อย่างสมดุล ทำให้ EfficientNet เป็นโมเดลที่มีประสิทธิภาพสูงในขณะที่ใช้พารามิเตอร์น้อยกว่ารุ่นอื่น ๆ

### 2. การตรวจจับขอบ (Edge Detection)

Edge Detection เป็นเทคนิคสำคัญในการประมวลผลภาพดิจิทัลที่ใช้ระบุตำแหน่งของขอบ (edges) ของวัตถุในภาพ โดยอาศัยการคำนวณการเปลี่ยนแปลงของความเข้มของพิกเซล (pixel) การตรวจจับขอบช่วยแยกวัตถุหรือระบุขอบเขตในภาพเพื่อวิเคราะห์เพิ่มเติม มีหลายวิธีที่นิยมใช้ เช่น

Prewitt Operator ซึ่งใช้การคำนวณขอบในแนวนอนและแนวตั้งด้วยคอนโวลูชัน (convolution) กับ kernel ขนาด 3x3 อีกตัวอย่างหนึ่งคือ Sobel Operator ซึ่งเป็นอัลกอริทึมที่คล้ายกับ Prewitt แต่ให้ความสำคัญกับจุดกลางมากกว่า ทำให้ผลลัพธ์มีความทนทานต่อสัญญาณรบกวนมากขึ้น นอกจากนี้ยังมี Roberts Cross Operator ที่ใช้ kernel ขนาด 2x2 ทำให้ตรวจจับขอบได้อย่างรวดเร็วแต่มีความไวต่อสัญญาณรบกวน ในขณะที่ Canny Edge Detection เป็นเทคนิคที่ซับซ้อนมากขึ้น โดยผสานการทำ Gaussian Smoothing, Gradient Calculation, Non-maximum Suppression และ Double Thresholding เพื่อหาขอบที่ชัดเจนและแม่นยำ นอกจากนี้ยังมี Laplacian of Gaussian (LoG) ที่ใช้การรวม Gaussian Smoothing กับ Laplacian Gradient เพื่อการตรวจจับขอบที่ละเอียดมากขึ้น Edge Detection จึงเป็นเครื่องมือสำคัญในหลายงาน เช่น การแยกวัตถุในภาพ การวิเคราะห์ภาพทางการแพทย์ และการนำไปใช้ในปัญหาการมองเห็นของคอมพิวเตอร์ (computer vision) อื่น ๆ

### 3. การดำเนินการพรีวิทท์ (Prewitt Operator)

Prewitt คือหนึ่งในตัวกรองการตรวจจับขอบ (edge detection) ที่ใช้ในการประมวลผลภาพดิจิทัลเพื่อหาเส้นขอบหรือขอบเขตของวัตถุในภาพ ตัวกรองนี้ได้รับการพัฒนาขึ้นโดย Judith M. S. Prewitt ในปี ค.ศ. 1970 (Prewitt, 1970) และเป็นหนึ่งในวิธีที่ง่ายและมีประสิทธิภาพสำหรับการตรวจจับขอบหลักการทำงานของ Prewitt Operator ทำงานโดยคำนวณการเปลี่ยนแปลงของค่าพิกเซลในภาพ เพื่อระบุส่วนที่มีการเปลี่ยนแปลงอย่างรวดเร็ว ซึ่งมักจะเป็นตำแหน่งของขอบของวัตถุในภาพ โดยใช้หน้ากากที่แตกต่างกันในทิศทางแนวตั้ง (vertical) และแนวนอน (horizontal) ตัวกรอง Prewitt จะใช้การคำนวณเกรเดียนต์ (Gradient) ในทิศทาง X และ Y โดยใช้ convolutional kernel ดังนี้

Kernel ในแนวนอน (Horizontal Kernel,  $G_x$ ):

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (1)$$

Kernel ในแนวตั้ง (Vertical Kernel,  $G_y$ ):

$$G_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad (2)$$

ขั้นตอนการคำนวณขอบด้วย Prewitt

1) คำนวณ Gradient ในทิศทาง X และ Y โดยใช้ kernel  $G_x$  และ  $G_y$  กับภาพต้นฉบับ (Original Image) เพื่อหา gradient ในแต่ละทิศทาง

2) คำนวณ *Magnitude* ของ Gradient โดยใช้สูตรเพื่อคำนวณความเข้มข้นของ gradient ดังนี้

$$Magnitude = \sqrt{G_x^2 + G_y^2} \quad (3)$$

หรือในกรณีที่ต้องการการประมวลผลที่เร็วขึ้นสามารถใช้การประมาณ:

$$Magnitude \approx |G_x| + |G_y| \quad (4)$$

### 4. งานวิจัยที่เกี่ยวข้อง

Prakash และคณะ (Prakash *et al.*, 2022) ได้ศึกษาเกี่ยวกับการจำแนกสายพันธุ์ข้าวโดยใช้โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ได้แก่ VGG16 และ Vanilla CNN บนชุดข้อมูล Rice Image Dataset ซึ่งประกอบด้วยภาพเมล็ดข้าวจำนวน 75,000 ภาพ ครอบคลุมข้าว 5 สายพันธุ์ ได้แก่ Arborio, Basmati, Ipsala, Jasmine และ Karacadag ผลการทดลองแสดงว่าโมเดล VGG16 ให้ค่าความแม่นยำสูงสุดที่ประมาณ 96%

Vania และคณะ (Vania *et al.*, 2023) ใช้สถาปัตยกรรม MobileNetV2 ร่วมกับเทคนิค Transfer Learning เพื่อจำแนกข้าวจากชุดข้อมูลเดียวกัน โดยเน้นที่การสร้างโมเดลที่มีขนาดเล็กและประมวลผลได้อย่างรวดเร็ว ผลลัพธ์แสดงว่า MobileNetV2 สามารถจำแนกพันธุ์ข้าวได้อย่างมีประสิทธิภาพ โดยมีค่าความแม่นยำประมาณ 98.2% ซึ่งเหมาะสำหรับการประยุกต์ใช้กับอุปกรณ์พกพาหรือระบบฝังตัว

Shardy (Shardy, 2023) ได้นำสถาปัตยกรรม VGG16 ที่ผ่านการฝึกบนชุดข้อมูล ImageNet มาปรับใช้กับ Rice Image Dataset โดยใช้วิธี Transfer Learning ผลการทดลองแสดงว่าโมเดลสามารถเรียนรู้ลักษณะของเมล็ดข้าวได้อย่างแม่นยำและหลีกเลี่ยงปัญหา overfitting ได้ดี โดยได้ค่าความแม่นยำประมาณ 97%

Noroozi (Noroozi, 2023) ได้พัฒนาโมเดล CNN ขึ้นใหม่โดยไม่ใช้โมเดลที่ผ่านการฝึกไว้ล่วงหน้า โดยฝึกโมเดลตั้งแต่เริ่มต้นบน Rice Image Dataset แม้จะไม่มี การใช้ Transfer Learning แต่โมเดลที่สร้างขึ้นสามารถจำแนกสายพันธุ์ข้าวได้อย่างแม่นยำในระดับประมาณ 96.5% ซึ่งสะท้อนถึงศักยภาพของ CNN ในการเรียนรู้จากข้อมูลดิบโดยตรง

Jiang และคณะ (Jiang *et al.*, 2022) ใช้ Prewitt Operator เพื่อตรวจจับขอบใบพืชที่ติดเชื้อ เช่น โรคใบจุดและราแป้ง โดยใช้ภาพจากกล้อง RGB การศึกษาพบว่า Prewitt Operator ช่วยเพิ่มความแม่นยำในการตรวจจับขอบและสามารถประยุกต์ใช้ร่วมกับเทคนิคการเรียนรู้เชิงลึกได้อย่างมี

ประสิทธิภาพ ผลการทดลองแสดงว่าความแม่นยำในการจำแนกพืชที่เป็นโรคสูงถึง 92%

Ali และคณะ (Ali *et al.*, 2021) ใช้ Prewitt Operator ในการตรวจจับขอบของภาพทางการแพทย์ เช่น X-ray, MRI และ CT Scan เพื่อแยกเนื้องอกหรืออวัยวะออกจากพื้นหลัง การใช้ Prewitt ช่วยเพิ่มความคมชัดของขอบและเพิ่มความแม่นยำในการวินิจฉัย โดยเฉพาะในภาพที่มีสัญญาณรบกวน ผลการทดลองแสดงว่าความแม่นยำในการวินิจฉัยทางการแพทย์เพิ่มขึ้นถึง 89%

Martinez และคณะ (Martinez *et al.*, 2023) ใช้ Prewitt Operator ในการวิเคราะห์ภาพดาวเทียมเพื่อตรวจจับขอบของภูมิประเทศ เช่น พื้นที่ป่าและเกษตร ผลการทดลองพบว่า Prewitt Operator สามารถแยกขอบเขตของพื้นที่ได้อย่างแม่นยำและใช้เวลาในการประมวลผลน้อยกว่าเทคนิคอื่นๆ การตรวจจับขอบนี้ช่วยให้การวิเคราะห์ภาพระยะไกลมีประสิทธิภาพ โดยเฉพาะในภาพที่มีสัญญาณรบกวนต่ำ

Chen และคณะ (Chen *et al.*, 2020) เปรียบเทียบ Prewitt Operator กับ Sobel และ Canny ในการตรวจจับขอบของป้ายจราจรสำหรับยานยนต์อัตโนมัติ ผลการศึกษพบว่า Prewitt Operator ตรวจจับขอบได้รวดเร็วและแม่นยำ โดยมีความแม่นยำสูงถึง 85% ในสภาพแสงที่แตกต่างกัน เมื่อเทียบกับ Sobel และ Canny การตรวจจับขอบที่รวดเร็วนี้ช่วยในการพัฒนาระบบรู้จำป้ายจราจร

Nguyen และคณะ (Nguyen *et al.*, 2021) ใช้ Prewitt Operator ในการตรวจจับขอบใบหน้าเพื่อเพิ่มประสิทธิภาพในการสกัดคุณลักษณะสำคัญจากภาพในระบบรู้จำใบหน้า ผลการทดลองแสดงว่า Prewitt Operator ช่วยปรับปรุงความแม่นยำได้อย่างมีนัยสำคัญ โดยเฉพาะในสภาวะแสงที่ไม่สม่ำเสมอ ความแม่นยำของระบบจดจำใบหน้าเพิ่มขึ้นเป็น 87% เมื่อเทียบกับระบบที่ไม่ใช้การตรวจจับขอบ

Raj และคณะ (Raj *et al.*, 2023) ใช้ Prewitt Operator ในการตรวจจับขอบพืชจากภาพที่ถ่ายโดยหุ่นยนต์เกษตร เพื่อเพิ่มความสามารถในการแยกพืชจากสิ่งแวดล้อมและช่วยในการดำเนินงาน เช่น การเก็บเกี่ยวและการตัดหญ้า การใช้ Prewitt Operator ช่วยลดเวลาในการประมวลผลและเพิ่มความแม่นยำในการแยกแยะวัตถุ ผลการทดลองแสดงว่าหุ่นยนต์สามารถแยกพืชจากพื้นหลังได้แม่นยำถึง 88% และลดเวลาในการประมวลผลได้ถึง 15% ซึ่งช่วยเพิ่มประสิทธิภาพในการทำงานของหุ่นยนต์เกษตร

Wang และคณะ (Wang *et al.*, 2019) ประยุกต์ใช้ Prewitt Operator ในการตรวจจับขอบตัวอักษรในภาพถ่ายเอกสารดิจิทัลเพื่อการรู้จำตัวอักษร (Optical Character

Recognition: OCR) ผลการทดลองแสดงว่า Prewitt Operator ช่วยแยกตัวอักษรออกจากพื้นหลังได้อย่างมีประสิทธิภาพและเพิ่มความแม่นยำในการแปลงภาพเป็นข้อความ การใช้เทคนิคนี้ช่วยลดข้อผิดพลาดจากสัญญาณรบกวนในภาพคุณภาพต่ำ ผลลัพธ์พบว่า Prewitt Operator ช่วยเพิ่มความแม่นยำในการแปลงภาพเป็นข้อความได้สูงถึง 92%

Mousavirad และคณะ (Mousavirad & Minaei, 2012) ใช้ Backpropagation Neural Network ร่วมกับคุณลักษณะทางรูปทรงของเมล็ดข้าว เพื่อจำแนกประเภทและคุณภาพของข้าวจากภาพถ่าย การใช้ฟิเจอร์เชิงรูปทรงช่วยในการวิเคราะห์คุณลักษณะเฉพาะของเมล็ดข้าวที่มีลักษณะใกล้เคียงกัน แต่มีความแม่นยำอยู่ที่ 91.09% ซึ่งยังต่ำกว่าวิธีการที่ใช้ CNN ร่วมกับการตรวจจับขอบ

Zareiforush และคณะ (Zareiforush *et al.*, 2016) ใช้ CNN ร่วมกับเทคนิค metaheuristic เพื่อจำแนกคุณภาพของเมล็ดข้าวจากภาพถ่าย การใช้ metaheuristic ช่วยเพิ่มความแม่นยำในการจำแนกและตรวจสอบคุณภาพของข้าวได้ถึง 96.3% โดยเน้นไปที่การใช้ CNN เพื่อวิเคราะห์คุณภาพข้าวที่ผ่านการขัดและการแยกประเภทที่มีรายละเอียดสูง

Kolkure และ Shaikh (Kolkure & Shaikh, 2017) งานวิจัยนี้พัฒนาโมเดล CNN ร่วมกับเทคนิคการประมวลผลภาพเพื่อทดสอบคุณภาพของข้าว โดยใช้ฟิเจอร์ที่ดึงออกมาจากภาพถ่ายเมล็ดข้าวเพื่อตรวจสอบคุณภาพ ผลการทดลองแสดงให้เห็นว่า CNN สามารถดึงคุณลักษณะภาพได้ดีและให้ความแม่นยำ 92.5% ในการจำแนกข้าวที่มีคุณภาพแตกต่างกัน

Gayathri Devi และคณะ (Gayathri Devi & Siddappa, 2017) ใช้ CNN ร่วมกับเทคนิคการประมวลผลภาพเพื่อจำแนกคุณภาพของเมล็ดข้าว ผลการทดลองแสดงว่า CNN สามารถแยกข้าวที่มีคุณภาพแตกต่างกันได้อย่างมีประสิทธิภาพ โดยใช้ข้อมูลที่ได้จากภาพถ่ายของเมล็ดข้าว โมเดล CNN สามารถดึงคุณลักษณะสำคัญจากภาพได้โดยไม่ต้องใช้การคำนวณทางฟิเจอร์เชิงลึก ทำให้ได้ ความแม่นยำ 93% ซึ่งเป็นผลลัพธ์ที่ดีในการตรวจสอบคุณภาพของข้าว

Itthi Chatnuntaweck (Chatnuntaweck *et al.*, 2018) งานวิจัยนี้นำเสนอการใช้ Deep Convolutional Neural Network (DCNN) ร่วมกับการถ่ายภาพเชิงสเปกตรัมเพื่อจำแนกสายพันธุ์ข้าว โดยใช้ข้อมูลเชิงพื้นที่และเชิงสเปกตรัมจากภาพถ่ายเมล็ดข้าว ความสามารถของ CNN ในการวิเคราะห์ข้อมูลที่ได้จาก hyperspectral imaging ทำให้โมเดลสามารถเพิ่มความแม่นยำขึ้นสูงสุดถึง 96.3% ในการจำแนกข้าวจากการศึกษางานวิจัยก่อนหน้านี้ยังประสบปัญหาในการจำแนกเมล็ดข้าวที่มีลักษณะคล้ายกันเมื่อจำแนก

สายพันธุ์ที่หลากหลาย งานวิจัย (Gayathri Devi & Siddappa, 2017) แสดงให้เห็นว่าแม้ CNN จะมีศักยภาพสูงในการวิเคราะห์คุณลักษณะจากภาพ แต่ยังคงขาดการตรวจจับขอบที่ละเอียด ทำให้การแยกข้าวบางสายพันธุ์ไม่แม่นยำเพียงพอ ในขณะที่ (Mousavirad & Minaei, 2012) ใช้ Backpropagation Neural Network ร่วมกับการวิเคราะห์รูปทรง ซึ่งให้ผลดีในบางกรณี แต่ยังคงมีความแม่นยำต่ำกว่าวิธีที่ใช้ CNN สำหรับงานที่ซับซ้อนกว่า (Kolkure & Shaikh, 2017) พยายามแก้ไขปัญหานี้ด้วยการใช้ CNN ร่วมกับเทคนิคการประมวลผลภาพเพิ่มเติม แต่ยังคงมีข้อจำกัดในแง่ความแม่นยำของการตรวจจับขอบส่วน (Chatnuntawech *et al.*, 2018) ได้พัฒนาระบบที่ใช้ hyperspectral imaging ร่วมกับ Deep CNN เพื่อปรับปรุงความแม่นยำในการจำแนกสายพันธุ์ข้าว แต่ยังไม่สามารถแก้ปัญหาขอบที่ไม่ชัดเจนได้ทั้งหมด งานวิจัย (Zareiforush *et al.*, 2016) ใช้ metaheuristic techniques ร่วมกับ CNN ซึ่งเพิ่มความแม่นยำในการจำแนก แต่ยังคงมีปัญหามารณณ์ที่ต้องตรวจจับขอบที่ซับซ้อน

## วิธีการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อปรับปรุงประสิทธิภาพของโมเดล CNN สำหรับการจำแนกสายพันธุ์ข้าวโดยใช้ Prewitt Operator ที่ได้รับการปรับแต่งเฉพาะ ซึ่งในกระบวนการวิจัยแสดงดัง Figure 1 โดยรายละเอียดของวิธีการที่เสนอโดยงานวิจัยนี้แสดงขั้นตอนต่างๆ ดังนี้

### 1. การเก็บรวบรวมข้อมูล

ข้อมูลภาพเมล็ดข้าวที่ใช้ในการวิจัยนี้ได้มาจากฐานข้อมูล Rice Image Dataset บนเว็บไซต์ Kaggle ซึ่งประกอบด้วยภาพเมล็ดข้าว 5 สายพันธุ์ สายพันธุ์ละ 15,000 ภาพ ได้แก่ Arborio, Basmati, Ipsala, Jasmine, Karacadag รวม 75,000 ภาพ โดยแต่ละสายพันธุ์มีจำนวนภาพที่เพียงพอสำหรับการฝึกและทดสอบโมเดล CNN เพื่อให้ได้ข้อมูลที่ครบถ้วนและครอบคลุมทุกประเภท

### 2. การเตรียมข้อมูล

ข้อมูลภาพเมล็ดข้าวทั้งหมดถูกปรับขนาดและจัดให้อยู่ในรูปแบบที่เหมาะสมสำหรับการป้อนเข้าสู่โมเดล CNN ขนาดภาพที่ใช้คือ 224x224 พิกเซล เพื่อความเข้ากันได้กับสถาปัตยกรรม CNN ที่จะนำมาใช้ และมีการปรับค่าพิกเซลให้อยู่ในช่วง 0-1 โดยใช้การ normalize เพื่อเพิ่มประสิทธิภาพในการฝึกโมเดล

### 3. Prewitt Operator ที่ปรับแต่งเฉพาะ

ในขั้นตอนนี้ การดำเนินการ Prewitt Operator ถูกนำมาใช้เพื่อตรวจจับขอบของภาพเมล็ดข้าว โดยเน้นไปที่การปรับแต่งให้เหมาะสมกับลักษณะเฉพาะของภาพเมล็ดข้าวแต่ละสายพันธุ์ ซึ่งกระบวนการนี้มีการปรับแต่งค่าพารามิเตอร์ต่างๆ เพื่อเพิ่มประสิทธิภาพในการดึงข้อมูลคุณลักษณะที่สำคัญของเมล็ดข้าวออกมาให้ได้มากที่สุด ในการวิจัยนี้มีการปรับแต่ง Prewitt Operator เพื่อให้สามารถดึงข้อมูลลักษณะเฉพาะจากภาพเมล็ดข้าวได้อย่างเหมาะสม การปรับแต่งมีขั้นตอนดังนี้




Figure 1 Research Methodology Flowchart




Figure 2 Results from the customized Prewitt operator process

1) การปรับขนาด Kernel ขนาดของ kernel ถูกปรับให้เข้ากับขนาดของภาพเมล็ดข้าวที่ใช้ โดยเน้นที่ใช้ kernel ขนาดใหญ่ขึ้น โดยกำหนดขนาด 5x5 และ 7x7 ในกรณีนี้ Prewitt Operator ถูกปรับให้ใช้ kernel ที่มีขนาดใหญ่ขึ้นจากขนาดปกติ 3x3 เป็น 5x5 และ 7x7 เพื่อเพิ่มความสามารถในการตรวจจับขอบที่ซับซ้อนและละเอียดขึ้น ซึ่ง kernel ขนาดใหญ่สามารถจับลักษณะที่เปลี่ยนแปลงอย่างช้า ๆ ได้ดีกว่า

$$G_x = \begin{bmatrix} -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \\ -2 & -1 & 0 & 1 & 2 \end{bmatrix} \quad (5)$$

$$G_y = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -1 & -1 & -1 & -1 & -1 \end{bmatrix} \quad (6)$$

2) การใช้ Prewitt ในหลายทิศทาง นอกจากการใช้ Prewitt ในทิศทางแนวแกน X และ Y แบบพื้นฐาน ยังมีการเพิ่มการตรวจจับขอบในทิศทางแนวทแยง เพื่อให้สามารถดึงขอบภาพในทิศทางที่แตกต่างกันได้การใช้ kernel ในทิศทาง 45 องศาและ -45 องศา เพื่อตรวจจับขอบที่มีลักษณะเอียงเฉียง ช่วยให้ได้ข้อมูลขอบที่หลากหลายและสมบูรณ์ยิ่งขึ้นในภาพเมล็ดข้าว ซึ่งมีความสำคัญในการแยกแยะขอบที่อยู่ในลักษณะเอียงหรือเฉียง ทำให้โมเดลสามารถตรวจจับลักษณะที่ไม่เป็นเส้นตรงธรรมดาได้ดียิ่งขึ้น

$$G_{45} = \begin{bmatrix} 0 & 0 & -1 \\ 0 & -1 & 0 \\ -1 & 0 & 0 \end{bmatrix} \quad (7)$$

$$G_{-45} = \begin{bmatrix} -1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & -1 \end{bmatrix} \quad (8)$$

3) การปรับค่า Threshold ค่า threshold ที่ใช้ในการแยกแยะระหว่างขอบที่ตรวจจับได้และพื้นหลังถูกปรับแต่งให้เหมาะสมกับภาพเมล็ดข้าว โดยกำหนด threshold ที่ใช้ในงานวิจัยนี้คือ ~0.3 ซึ่งเป็นค่าที่สมดุลในการรักษาขอบที่สำคัญและลดการเกิดขอบที่ไม่จำเป็นค่า threshold ที่เหมาะสมช่วยให้การตรวจจับขอบของเมล็ดข้าวมีความแม่นยำขึ้น โดยไม่ทำให้เกิดการตรวจจับขอบที่เกิดจาก noise หรือสัญญาณรบกวนที่ไม่จำเป็น ซึ่งช่วยให้ผลลัพธ์ของการจำแนกขอบมีความชัดเจน

4) การใช้งานร่วมกับการกรอง Gaussian (Gaussian Smoothing) ก่อนการดำเนินการ Prewitt มีการใช้การกรอง Gaussian เพื่อลด noise ในภาพเมล็ดข้าว ซึ่งช่วยเพิ่มความแม่นยำในการตรวจจับขอบและลดผลกระทบจากการตรวจจับขอบที่เกิดจากสัญญาณรบกวน โดยในงานวิจัยนี้กำหนดค่า Sigma ที่ใช้ในการคำนวณ Gaussian Smoothing อยู่ในช่วง 1.0-1.5 ซึ่งช่วยให้ภาพเรียบเนียนมากขึ้น ลด noise ในภาพโดยไม่ทำให้ภาพเบลอลเกินไป ผลการทดลองนำภาพเมล็ดข้าว 5 สายพันธุ์ ได้แก่ Arborio, Basmati, Ipsala, Jasmine, Karacadag ผ่านกระบวนการ Prewitt Operator ที่ได้รับการปรับแต่งเฉพาะ แสดงดัง Figure 2

#### 4. เครื่องมือที่ใช้ในการวิจัย

ในการวิจัยนี้มีการใช้เครื่องมือโดยใช้ คอมพิวเตอร์ ที่มี Graphics Processing Unit (GPU) คือ NVIDIA RTX 3080 Central Processing Unit (CPU) คือ INTEL CORE I5-10400 LGA 1200 RAM 32 GB มีประสิทธิภาพในการประมวลผลและฝึกโมเดล และพัฒนาด้วยเครื่องมือด้วยภาษา Python และไลบรารีประกอบด้วย TensorFlow, Keras, OpenCV และ NumPy สำหรับการประมวลผลภาพ

#### 5. การวัดประสิทธิภาพ

การวัดประสิทธิภาพของโมเดล CNN สำหรับการจำแนกสายพันธุ์ข้าวจะถูกประเมินโดย Accuracy, Precision, Recall, และ F1-Score ซึ่งแต่มีรายละเอียดการประเมินผลลัพธ์ดังนี้

Accuracy คืออัตราส่วนของจำนวนตัวอย่างที่โมเดลทำนายถูกต้องต่อจำนวนตัวอย่างทั้งหมดในชุดข้อมูลทดสอบ ค่านี้สะท้อนความแม่นยำของโมเดลในภาพรวม โดยคำนวณจาก

$$Accuracy = \frac{True\ Positive + True\ Negative}{Total\ Sample} \quad (9)$$

Precision คือสัดส่วนของจำนวนตัวอย่างที่โมเดลทำนายว่าเป็นสายพันธุ์ข้าวที่ถูกต้องต่อจำนวนตัวอย่างที่โมเดลทำนายว่าเป็นชนิดนั้นทั้งหมด ค่าที่สูงหมายถึงโมเดลมีความสามารถในการลดข้อผิดพลาดเชิงบวกเทียม (False Positive) ได้ดี

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (10)$$

Recall คือสัดส่วนของจำนวนตัวอย่างที่ทำนายถูกต้องว่าเป็นสายพันธุ์ข้าวนั้นๆ ต่อจำนวนตัวอย่างทั้งหมดที่เป็นสายพันธุ์นั้นในความเป็นจริง ตัวชี้วัดนี้สะท้อนความสามารถในการลดข้อผิดพลาดเชิงลบเทียม (False Negative):

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (11)$$

F1-Score คือการวัดประสิทธิภาพที่รวมค่า Precision และ Recall โดยคำนวณเป็นค่าเฉลี่ยซึ่งเหมาะกับการประเมินเมื่อมีความไม่สมดุลของข้อมูลในแต่ละประเภท

$$F1 - score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (12)$$


#### ผลการทดลอง

เมื่อทดลองโดยใช้โมเดล CNN เพียงอย่างเดียวโดยไม่ใช้ Prewitt Operator ผลลัพธ์แสดงถึงความสามารถของโมเดล CNN ในการจำแนกสายพันธุ์ข้าวดัง Table 1


การทดลองงานวิจัยใช้ชุดข้อมูล Rice Image Dataset โดยได้ถูกแบ่งออกเป็นชุดข้อมูลสำหรับฝึกโมเดลจำนวนร้อยละ 80 และชุดข้อมูลสำหรับทดสอบจำนวนร้อยละ 20 โดยมีการสุ่มลำดับข้อมูลก่อนการแบ่งเพื่อป้องกันอคติที่อาจเกิดจากลำดับข้อมูลเดิม ทั้งนี้ได้มีการควบคุมให้แต่ละสายพันธุ์ข้าวทั้ง 5 สายพันธุ์มีจำนวนข้อมูลที่สมดุลในทั้งสองชุดเพื่อให้ผลการประเมินประสิทธิภาพของโมเดลมีความแม่นยำและน่าเชื่อถือ การแบ่งชุดข้อมูลดังกล่าวถูกนำมาใช้อย่างสม่ำเสมอในทุกการทดลอง รวมถึงโมเดลพื้นฐาน (VGG16, MobileNetV2, ResNet50V2, InceptionV3, EfficientNetB0) และโมเดลที่เสนอในงานวิจัยนี้ซึ่งผสมผสานเทคนิค Prewitt Operator ที่ได้รับการปรับแต่งเฉพาะ

เมื่อทดลองโดยใช้โมเดล CNN ร่วมกับการใช้ Prewitt Operator ที่ได้รับการปรับแต่งค่าโดยงานวิจัยนี้ในการตรวจจับขอบของภาพเมล็ดข้าว โดยใช้การฝึกโมเดลในงานวิจัยนี้ได้ดำเนินการทั้งหมดจำนวน 20 รอบการฝึก (Epochs) ผลลัพธ์ของโมเดลมีความแม่นยำที่เพิ่มขึ้น เนื่องจาก Prewitt Operator ช่วยในการดึงข้อมูลขอบและลักษณะสำคัญของเมล็ดข้าวได้อย่างชัดเจนขึ้น ทำให้การแยกแยะสายพันธุ์ข้าวมีความแม่นยำมากขึ้น โดยผลการทดลองแสดงดัง Table 2 และการทดลองสามารถสรุปเปรียบเทียบระหว่างการใช้โมเดล CNN เพียงอย่างเดียวกับการใช้โมเดล CNN ร่วมกับ Prewitt Operator ดัง Figure 3 และสามารถแสดงผลการทดลองโดยพิจารณาจากค่า Training Accuracy ดัง Figure 4 และ Validation Loss ดัง Figure 5 โดย Figure 4 แสดงความแม่นยำของการฝึกสอนของโมเดล CNN ที่เสนอในช่วง 20 รอบการฝึก ผลลัพธ์แสดงแนวโน้มที่เพิ่มขึ้นอย่างต่อเนื่อง สะท้อนให้เห็นว่าโมเดลเรียนรู้ได้อย่างมีประสิทธิภาพ โดยมีความแม่นยำคงที่หลังรอบที่ 15 ซึ่งบ่งชี้ว่าโมเดลเริ่มเข้าสู่สภาวะคงตัว Figure 5 แสดงค่าการสูญเสียของชุดข้อมูลตรวจสอบ (Validation Loss) ตลอด 20 รอบการฝึก เริ่มต้นด้วยค่าที่ลดลงอย่างรวดเร็วในช่วงแรก และมีแนวโน้มคงที่หลังจากรอบที่ 10 สะท้อนว่าโมเดลสามารถลดการ overfitting และบรรลุค่าที่เหมาะสมได้


รวมถึงงานวิจัยได้เปรียบเทียบประสิทธิภาพความแม่นยำของวิธีที่เสนอในงานวิจัยนี้กับงานวิจัยก่อนหน้านี้ที่ใช้ข้อมูลภาพเมล็ดข้าวที่ใช้ในการวิจัยนี้ได้มาจากฐานข้อมูล Rice Image Dataset บนเว็บไซต์ Kaggle แสดงดัง Table 3



**Figure 3** summarizes the comparison between using CNN alone and using CNN combined with the Prewitt Operator.



**Figure 4** Training Accuracy



**Figure 5** Validation Loss

**Table 1** Results of the CNN model in classifying rice varieties

| Model          | Accuracy (%) | Precision (%) | Recall (%) | F1-Score (%) |
|----------------|--------------|---------------|------------|--------------|
| VGG16          | 94.5         | 94.2          | 94.4       | 94.3         |
| VGG19          | 95.0         | 94.9          | 95.0       | 94.9         |
| InceptionV3    | 95.8         | 95.5          | 95.7       | 95.6         |
| ResNet50V2     | 96.2         | 96.1          | 96.2       | 96.1         |
| EfficientNetB0 | 96.8         | 96.7          | 96.8       | 96.7         |

**Table 2** Results of the CNN model combined with the specifically customized Prewitt Operator process for rice variety classification

| Model          | Accuracy (%) | Precision (%) | Recall (%) | F1-Score (%) |
|----------------|--------------|---------------|------------|--------------|
| VGG16          | 97.9         | 97.8          | 97.9       | 97.8         |
| VGG19          | 98           | 98            | 98         | 98           |
| InceptionV3    | 98.1         | 98.2          | 98.1       | 98.1         |
| ResNet50V2     | 98.2         | 98.3          | 98.2       | 98.2         |
| EfficientNetB0 | 98.5         | 98.6          | 98.5       | 98.6         |

**Table 3** Comparison of accuracy performance between the proposed method in this research and previous research

| Reference                      | Proposed Method                   | Accuracy (%) |
|--------------------------------|-----------------------------------|--------------|
| (Prakash <i>et al.</i> , 2022) | VGG16, Vanilla CNN                | 96.0         |
| (Vania <i>et al.</i> , 2023)   | MobileNetV2 + Transfer Learning   | 98.2         |
| (Shardy, 2023)                 | VGG16 + Transfer Learning         | 97.0         |
| (Noroozi, 2023)                | Custom CNN (trained from scratch) | 96.5         |
| <b>This work</b>               | <b>CNN + Prewitt Operator</b>     | <b>98.5</b>  |

## อภิปรายผลและสรุป

การทดลองเปรียบเทียบระหว่างการใช้โมเดล CNN เพียงอย่างเดียวกับการใช้โมเดล CNN ร่วมกับ Prewitt Operator ที่ได้รับการปรับแต่งค่าโดยงานวิจัยนี้ พบความแตกต่างที่สำคัญในด้านประสิทธิภาพการจำแนกภาพเมล็ดข้าว ผลการทดลองแสดงให้เห็นว่าเมื่อใช้ CNN เพียงอย่างเดียว โมเดลสามารถจำแนกสายพันธุ์ข้าวได้โดยโมเดล EfficientNetB0 มีความแม่นยำสูงสุดที่ 96.8% ซึ่งเป็นผลลัพธ์ที่ดี แต่ยังคงมีความคลาดเคลื่อนในการจำแนกบางสายพันธุ์ เนื่องจากขาดการตรวจจับขอบที่ชัดเจน ทำให้โมเดลไม่สามารถแยกแยะรายละเอียดของเมล็ดข้าวที่มีความคล้ายคลึงกันได้อย่างแม่นยำเท่าที่ควร

ในทางตรงกันข้าม การใช้ CNN ร่วมกับ Prewitt Operator ช่วยเพิ่มประสิทธิภาพการจำแนกได้อย่างมีนัยสำคัญ โดยเฉพาะในโมเดล EfficientNetB0 ที่มีค่าความแม่นยำเพิ่มขึ้นเป็น 98.5% การตรวจจับขอบด้วย Prewitt

Operator ช่วยดึงลักษณะสำคัญของเมล็ดข้าวออกมา เช่น ขอบ, ปลายเมล็ด และร่องลึกบนผิวของเมล็ด ซึ่งช่วยให้โมเดลสามารถแยกแยะความแตกต่างเล็กน้อยระหว่างสายพันธุ์ได้ดียิ่งขึ้น ผลลัพธ์แสดงให้เห็นว่าโมเดลที่รวม Prewitt Operator มีค่า Precision, Recall, และ F1-Score สูงขึ้นในทุกตัวชี้วัด โดยเฉพาะใน ResNet50V2 ที่มีค่า F1-Score สูงถึง 98.2% แสดงให้เห็นว่าโมเดลที่ใช้ Prewitt Operator สามารถรักษาความสมดุลในการทำนายได้ดีกว่า กล่าวโดยสรุปการใช้ Prewitt Operator ร่วมกับ CNN ทำให้ประสิทธิภาพการจำแนกภาพเมล็ดข้าวเพิ่มขึ้น เนื่องจากการตรวจจับขอบช่วยเสริมการทำงานของโมเดล CNN ในการดึงลักษณะสำคัญจากภาพ ส่งผลให้การจำแนกทำได้แม่นยำขึ้นเมื่อเทียบกับการใช้ CNN เพียงอย่างเดียว

เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้านี้ ผลลัพธ์ของการจำแนกเมล็ดข้าวของงานวิจัยนี้โดยใช้ CNN + Prewitt Operator มีความแม่นยำสูงถึง 98.5% ซึ่งสูงกว่าจากการ

ทดลองพบว่า โมเดล CNN ที่รวมเทคนิค Prewitt Operator ซึ่งได้รับการปรับแต่งเฉพาะสามารถเพิ่มประสิทธิภาพการจำแนกสายพันธุ์ข้าวได้อย่างมีนัยสำคัญ โดยเฉพาะในโมเดล EfficientNetB0 ซึ่งได้ค่าความแม่นยำ (Accuracy) สูงถึง 98.5% เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้า 4 ฉบับที่ใช้ชุดข้อมูล Rice Image Dataset เดียวกัน พบว่าผลลัพธ์จากงานวิจัยนี้มีความสามารถในการจำแนกที่โดดเด่นยิ่งกว่า

งานของ Prakash และคณะ (Prakash *et al.*, 2022) ใช้โมเดล VGG16 และ CNN พื้นฐานในการจำแนกเมล็ดข้าว โดยไม่มีการปรับแต่ง preprocessing พิเศษ ผลลัพธ์ให้ค่าความแม่นยำอยู่ที่ประมาณ 96.0% ซึ่งต่ำกว่างานวิจัยนี้อย่างชัดเจน งานของ Shardy (Shardy, 2023) ได้ประยุกต์ใช้ VGG16 ร่วมกับ Transfer Learning จาก ImageNet ซึ่งช่วยให้โมเดลเรียนรู้ได้รวดเร็วขึ้นและได้ค่าความแม่นยำเพิ่มขึ้นเป็นประมาณ 97.0% อย่างไรก็ตาม ยังไม่มีการประยุกต์ edge detection ในการเสริมประสิทธิภาพเชิงคุณลักษณะ

ในขณะเดียวกัน งานวิจัยของ Noroozi (Noroozi, 2023) ใช้โมเดล CNN ที่ออกแบบเองและฝึกจากศูนย์ (from scratch) บนชุดข้อมูลเดียวกัน โดยไม่ได้ใช้ Transfer Learning หรือการประมวลผลภาพล่วงหน้าแบบ edge detection ส่งผลให้ค่าความแม่นยำอยู่ในระดับประมาณ 96.5% ซึ่งยังคงต่ำกว่างานวิจัยนี้เล็กน้อย แม้งานวิจัยของ Noroozi จะมีความยืดหยุ่นในการออกแบบโมเดล แต่การขาด preprocessing เชิงลึกส่งผลต่อการแยกแยะเมล็ดข้าวที่มีลักษณะคล้ายคลึงกัน

สำหรับงานที่ใช้ MobileNetV2 ร่วมกับ Transfer Learning (Vania *et al.*, 2023) ซึ่งให้ค่าความแม่นยำประมาณ 98.2% แม้ว่าจะได้ผลลัพธ์ที่ใกล้เคียงกับงานวิจัยนี้ แต่ยังไม่ถึงระดับ 98.5% ที่ได้จากการรวม Prewitt Operator ซึ่งแสดงให้เห็นว่า การตรวจจับขอบอย่างเหมาะสมสามารถเสริมประสิทธิภาพของ CNN ได้ แม้จะไม่ใช่สถาปัตยกรรมที่ล้ำหน้าหรือพึ่งพาโมเดลภายนอก

การใช้ Prewitt Operator ในงานวิจัยของเราช่วยเพิ่มความละเอียดในการตรวจจับขอบของเมล็ดข้าวได้ดีกว่า ทำให้การจำแนกข้าวมีความแม่นยำมากขึ้น ดังนั้นจากการเปรียบเทียบการใช้ CNN + Prewitt Operator ในการตรวจจับขอบของเมล็ดข้าวในงานวิจัยนี้กับงานวิจัยก่อนหน้านี้ได้แสดงถึงความสามารถในการเพิ่มความแม่นยำในการจำแนกข้าวได้อย่างมีประสิทธิภาพมากกว่างานวิจัยที่ใช้วิธีการอื่น ๆ

แม้ว่า Kaggle Rice Image Dataset จะเป็นชุดข้อมูลที่ได้รับการยอมรับและมีโครงสร้างมาตรฐานสำหรับการทดสอบโมเดลจำแนกภาพ แต่ข้อจำกัดของงานวิจัยนี้คือการใช้ข้อมูลจากแหล่งเดียว ซึ่งอาจไม่ครอบคลุมลักษณะของพันธุ์

ข้าวไทยทั้งหมดหรือสภาวะแวดล้อมจริงที่พบในกระบวนการผลิตทางการเกษตร ดังนั้น ในอนาคตควรมีการเก็บและทดสอบกับชุดข้อมูลที่หลากหลายมากขึ้น โดยเฉพาะข้อมูลจริงจากแหล่งผลิตในประเทศไทย เพื่อประเมินความสามารถในการปรับใช้ของโมเดลกับพันธุ์ข้าวไทยในบริบทจริง

งานวิจัยในอนาคต สามารถขยายแนวทางที่เสนอไป ยังการจำแนกสายพันธุ์ข้าวในสภาวะแสงที่หลากหลาย หรือจากภาพถ่ายภาคสนามจริงที่มีสภาพแวดล้อมไม่แน่นอน เช่น พื้นหลังซับซ้อนหรือแสงธรรมชาติที่เปลี่ยนแปลงได้ อีกทั้งยังสามารถนำเทคนิคที่พัฒนาไปประยุกต์ใช้กับพันธุ์ข้าวไทยท้องถิ่นหรือผลิตภัณฑ์เกษตรอื่น ๆ ที่มีลักษณะคล้ายกัน เช่น เมล็ดถั่วหรือธัญพืชอื่น ๆ เพื่อประเมินความสามารถในการปรับใช้ในบริบทที่กว้างขึ้นได้ และจะนำโมเดลที่ได้จากงานวิจัยนี้ ใช้สำหรับจำแนกพันธุ์ข้าวไทยด้วยวิธี Transfer Learning

## เอกสารอ้างอิง

- Ali, H., Ahmed, S., & Khan, M. (2021). Edge detection using Prewitt operator in medical imaging. *International Journal of Biomedical Imaging*.
- Arunsiriwattana, P., Kiatwuthiamorn, J., & Cumpim, C. (2021). Laser pointer control for deep learning human detection. *J Sci Technol MSU*, 41(3).
- Chatnuntawe, I., Tantisantisom, K., Khanchaitit, P., Boonkoom, T., & Bilgic, B. (2018). *Rice classification using spatio-spectral deep convolutional neural network*. arXiv. <https://arxiv.org/abs/1805.11491>
- Chen, P., Liu, Q., & Zhang, H. (2020). Traffic sign recognition using edge detection techniques. *IEEE Transactions on Intelligent Transportation Systems*.
- Gayathri Devi, N., & Siddappa, M. (2017). Machine vision approach for quality evaluation of rice grains using CNN. *International Journal of Computer Applications*, 160, 26–29.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity mappings in deep residual networks. In *European conference on computer vision* (pp. 630–645). <https://arxiv.org/abs/1603.05027>
- Jiang, Y., Chen, L., & Xu, Z. (2022). Prewitt operator in plant disease detection. *Journal of Agricultural Science and Technology*.
- Kolkure, P. D., & Shaikh, S. S. (2017). Quality analysis of rice grains using CNN based image processing.

- In *International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*.
- Kongchai, P. (2023). Creating a deep learning model for classifying conversation messages from a LINE application. *J Sci Technol MSU*, 43(1).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Martinez, R., Lopez, J., & Sanchez, A. (2023). Remote sensing image analysis using Prewitt edge detection. *Remote Sensing Letters*.
- Mousavirad, S. J., & Minaei, S. (2012). Identification of rice varieties using backpropagation neural network. *Journal of Agricultural Engineering*, 39(1), 49–56.
- Nguyen, T., Tran, V., & Hoang, D. (2021). Prewitt operator for facial recognition. *Pattern Recognition and Image Analysis*.
- Noroozi, M. (2023). *Rice classification by using CNN*. Kaggle. <https://www.kaggle.com/code/marya-mnoroozi68/rice-classification-by-using-cnn>
- Prakash, N., Rajakumar, R., & Gowthami, K. (2022). Image classification for rice varieties using deep learning models. *YMER Digital*, 21(6), 263–266.
- Prewitt, J. M. S. (1970). Object enhancement and extraction. In *Picture processing and psychopictorics* (pp. 75–149).
- Raj, M., Verma, P., & Singh, S. (2023). Prewitt edge detection in agricultural robotics. *Journal of Agricultural Engineering Research*.
- Rattanapoka, C. (2024). A real-time analysis of human face emotions using deep learning techniques on low-cost embedded device. *The Journal of KMUTNB*, 34(2), 1–12.
- Senawong, N., Wichitchan, S., & Kumphon, O. (2022). Large-scale data classification based on K-means clustering and deep learning. *The Journal of KMUTNB*, 32(4), 957–965.
- Shardy. (2023). *Rice image classification using VGG16 and transfer learning*. GitHub. <https://github.com/Shardy2907/CNN-using-Transfer-Learning>
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. In *International Conference on Learning Representations (ICLR)*.
- Sriwiboon, N. (2021). Improvement the performance of the chest X-ray image classification with convolutional neural network model by using image augmentations technique for COVID-19 diagnosis. *The Journal of KMUTNB*, 31(1), 109–117.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning (ICML)*.
- Vania, V., Setyadi, A., Widyatama, I. M. D., & Kurniadi, F. I. (2023). Rice varieties classification using neural network and transfer learning with MobileNetV2. In *2023 4th International Conference on Artificial Intelligence and Data Sciences (AiDAS)*.
- Wang, X., Zhang, Y., & Li, F. (2019). Prewitt edge detection for OCR in digital documents. *Journal of Computer Vision and Image Processing*.
- Zareiforush, H., Minaei, S., Alizadeh, M. R., & Banakar, A. (2016). Qualitative classification of milled rice grains using computer vision and metaheuristic techniques. *Journal of Food Engineering*, 195, 1–9.