การจำแนกเมล็ดพันธุ์ข้าวโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน

อนาวิล กิติธรรม[1*] และ กฤตกรณ์ ศรีวันนา[2]

บทคัดย่อ

งานวิจัยนี้นำเสนอการจำแนกชนิดพันธุ์ข้าวที่เป็นที่นิยมในจังหวัดเชียงราย จำนวนสามสายพันธุ์ ได้แก่ ข้าวปทุมธานี 1 ข้าว กข 6 และข้าวญี่ปุ่น โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน งานวิจัยนี้เก็บข้อมูลภาพเมล็ดข้าวจากกล้องมือถือ แล้วนำภาพมาประมวลผลภาพที่แตกต่างกันสามรูปแบบคือ ภาพสี ภาพเฉดเทา และภาพขาวดำ จากนั้นนำภาพเมล็ดข้าวที่ได้ไปประมวลผลด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้อัลกอริทึม เทนเซอร์โฟล์-เคราส ชนิดซีเควนเชียล ซึ่งงานวิจัยนี้เปรียบเทียบประสิทธิภาพการจำแนกเมล็ดพันธุ์ข้าวที่ใช้วิธีการเตรียมรูปภาพที่แตกต่างกันทั้งหมดสามรูปแบบคือ ภาพสี ภาพเฉดเทา และภาพขาวดำ และใช้ภาพเมล็ดข้าวทั้งหมด 600 ภาพ จากการทดลองพบว่าการเรียนรู้จากภาพเฉดเทาได้ค่าความแม่นยำมากที่สุด คือ 87.22 % และรองลงมาคือ ภาพสี และภาพขาวดำคือ 85.55 % และ 81.66 % ตามลำดับ

คำสำคัญ : โครงข่ายประสาทเทียมแบบคอนโวลูชัน การประมวลผลภาพ การจำแนกเมล็ดพันธุ์ข้าว

[1,2] สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะเทคโนโลยีดิจิทัล มหาวิทยาลัยราชภัฏเชียงราย
[*] ผู้ประสานงานหลัก e-mail: 621998033@crru.ac.th
วันที่รับบทความ 2 เมษายน 2567 วันที่แก้ไขบทความ 1 พฤษภาคม 2567 วันที่ตอบรับบทความ 15 พฤษภาคม 2567

Academic Journal of Science and Technology, Dhonburi Rajabhat University
Volume 2, Issue 1, (January-June) 2024

Rice Grain Classification Using Convolutional Neural Networks

Anawin Kititham[1*] and Kittakorn Sriwanna[2]

ABSTRACT

This research presented the classification of three popular rice varieties in Chiang Rai province, namely Pathum Thani 1 rice, RD 6 rice, and Japanese rice, using a convolutional neural network. This research collects images of rice grains from mobile cameras. The images were then processed into three different image formats: color images, grayscale images, and black and white images. Then the obtained rice grain images were processed with a convolutional neural network using TensorFlow - Keras Sequential model. This research compared the efficiency of rice seed classification using three different image preparation methods: color images, grayscale images, and black and white images, and used a total of 600 rice grain images. The experiment found that learning from grayscale images achieved the highest accuracy, which was 87.22%, followed by color images and black and white images, which were 85.55% and 81.66%, respectively.

Keywords : convolution neural network, image processing, rice classification

[1,2] Computer Engineering Program, Faculty of Digital Technology, Chiang Rai Rajabhat University
[*] Corresponding author e-mail: 621998033@crru.ac.th
Received: Apr 2, 2024 Revised: May 1, 2024 Accepted: May 15, 2024

บทนำ

ข้าวเป็นอาหารหลักและปลูกเป็นพืชเศรษฐกิจที่สำคัญในประเทศไทย ข้าวหอมมะลิเป็นพันธุ์ข้าวที่นิยม และมีความเป็นเอกลักษณ์ เนื่องจากมีคุณสมบัติที่นุ่มเมื่อหุงสุก และมีกลิ่นหอมพิเศษ ทำให้ผู้บริโภคในจังหวัดเชียงรายมีความต้องการเป็นอันดับต้น ๆ อย่างไรก็ตาม ความนิยมของข้าวหอมมะลิได้ทำให้บางผู้ค้ามีแนวโน้มในการปลอมแปลงข้าวหอมมะลิด้วยข้าวพันธุ์อื่นที่ราคาถูกและคุณภาพต่ำกว่า เพื่อเพิ่มกำไรส่งผลให้คุณภาพข้าวลดลง เพื่อรักษามาตรฐานคุณภาพและสร้างความเชื่อมั่นให้กับผู้บริโภค สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติได้กำหนดมาตรฐานข้าวหอมมะลิไทย สำหรับการส่งออก ในมาตรฐานดังกล่าว ข้าวจะต้องมีความบริสุทธิ์ไม่น้อยกว่า 95% สำหรับข้าวเปลือก และ 92% สำหรับข้าวกล้องและข้าวขาวเพื่อรักษามาตรฐาน สร้างความเชื่อมั่นให้ผู้บริโภค และยกระดับคุณภาพข้าวหอมมะลิไทย (สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ, ม.ป.ป.)

ในกระบวนการตรวจสอบมาตรฐานข้าว การเลือกสุ่มตัวอย่างข้าวและการวิเคราะห์คุณลักษณะทางกายภาพและปริมาณแอมิโลส เป็นวิธีที่สำคัญ อย่างไรก็ตาม การวิเคราะห์ด้วยวิธีนี้อาจไม่สามารถใช้ได้ในกรณีที่คุณลักษณะทางกายภาพและปริมาณแอมิโลสของข้าวมีค่าใกล้เคียงกัน วิธีตรวจสอบคุณภาพข้าวโดยใช้การตรวจสอบดีเอ็นเอจึงเป็นวิธีที่มีความแม่นยำมากกว่า อย่างไรก็ตาม วิธีดังกล่าวมีค่าใช้จ่ายที่ค่อนข้างสูง ดังนั้น การทดสอบด้วยวิธีอื่นที่ราคาถูกและให้ผลที่แม่นยำ รวมถึงการตรวจสอบได้รวดเร็วยังคงเป็นสิ่งที่จำเป็นที่จะช่วยลดภาระค่าใช้จ่ายทั้งในส่วนผู้ผลิตและผู้บริโภค (สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ, ม.ป.ป.)

ในงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อประยุกต์ใช้เทคโนโลยี การเรียนรู้ของเครื่องจักร มาช่วยในการจำแนกเมล็ดพันธุ์ข้าว โดยจะใช้ภาพถ่ายของตัวอย่างเมล็ดข้าวจำนวน สามสายพันธุ์ ประกอบด้วย ข้าวปทุมธานี 1 ข้าวกข 6 และข้าวญี่ปุ่น มาทำการประมวลผลภาพที่แตกต่างกันสามรูปแบบคือ ภาพสี ภาพเฉดเทา และภาพขาวดำ และทำการประมวลผลด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน เพื่อทดลองว่าการจำแนกวิธีใดมีประสิทธิภาพมากที่สุด

สุชาติ แย้มเม่น ณรงค์ฤทธิ์ พิมพ์คำวงศ์ และโชคชรัตน์ ฤทธิ์เย็น (2559) ให้ความหมายไพทอน (Python) คือ ภาษาโปรแกรมคอมพิวเตอร์ที่มีความนิยมในการพัฒนาซอฟต์แวร์และการเขียนโปรแกรม ถูกสร้างขึ้นโดย Guido van Rossum และเปิดตัวครั้งแรกในปี 1991 ไพทอนเป็นภาษาโปรแกรมที่อ่านง่ายและมีไวยากรณ์ที่เป็นมาตรฐานที่ช่วยให้นักพัฒนาโปรแกรมสามารถแสดงความคิดและสร้างโค้ดได้อย่างรวดเร็ว ไพทอนมีชุดคำสั่งและไลบรารีที่มากมายที่ช่วยในการแก้ปัญหาที่หลากหลายด้าน เช่นการวิเคราะห์ข้อมูล การเรียนรู้เครื่อง การพัฒนาเว็บแอปพลิเคชัน และอื่น ๆ ซึ่งทำให้ไพทอนเป็นภาษาโปรแกรมที่น่าสนใจและเหมาะสำหรับผู้ที่ต้องการทำงานในด้านการ

โปรแกรมมิ่งหลายแบบ ไพทอนยังเป็นภาษาที่พอใช้งานในหลายสาขาด้านเทคโนโลยีและวิทยาศาสตร์อื่น ๆ รวมถึงการพัฒนาเว็บแอปพลิเคชัน การเขียนสคริปต์ การทำงานทางด้านข้อมูลและการเรียนรู้ของเครื่อง (machine learning) และการประมวลผลภาพ (image processing) รวมถึงการเขียนโปรแกรมทั่วไปในหลายสาขาอื่น ๆ ด้วย

จักรินทร์ สนุกแสน และโอฬาริก สุรินต๊ะ (2562) และ Lapthanachai, Chomthong, Waijanya & Promrit (2023) อธิบายว่า โครงข่ายประสาทแบบคอนโวลูชัน (CNN) หรือ convolutional neural network (โครงข่ายประสาทเทียมแบบคอนโวลูชัน) เป็นกลไกสำคัญในการประมวลผลภาพและวิดีโอ โดยเฉพาะในงานด้านการรู้จำและการจำแนกวัตถุภายในภาพ โครงข่ายประสาทเทียมแบบ CNN ถูกออกแบบในลักษณะที่ใช้เลเยอร์แบบคอนโวลูชัน เพื่อดึงคุณลักษณะเด่นของภาพออกมา และเรียนรู้การจำแนกข้อมูลจากภาพแบบอัตโนมัติ ดังนั้นจึงเป็นโครงข่ายประสาทเทียมที่ได้รับความนิยมในการแก้ปัญหาการประมวลผลภาพและการควบคุมหุ่นยนต์ที่มีการใช้ภาพ CNN ยังเป็นส่วนสำคัญในการพัฒนาความรู้เชิงลึก (deep learning) ที่เกี่ยวข้องกับการเรียนรู้ข้อมูลจากข้อมูลที่มีโครงสร้างเชิงลึก เช่น การจดจำลายลักษณะในภาพและวิดีโอ และการตรวจจับวัตถุในเวลาจริง และอื่น ๆ นอกจากนี้ CNN ยังมีแอปพลิเคชันในการแปลภาษา ระบบแนะนำสินค้า และงานด้านการประมวลผลข้อมูลเชิงลึกด้วยความสามารถในการจดจำและจำแนกข้อมูลจากภาพและวิดีโอได้อย่างแม่นยำ (Kanoktipsatharporn, 2019)

จักรินทร์ สนุกแสน และโอฬาริก สุรินต๊ะ (2562) และ Pattana-anurak (2023) อธิบายว่า TensorFlow Library คือ โอเพ่นซอร์สไลบรารี่สำหรับการสร้างโมเดลการเรียนรู้เชิงลึกที่พัฒนาโดย Google รองรับการทำงานแบบประมวลผลร่วมกันหลาย ๆ เครื่องและสามารถใช้หน่วยประมวลผลกราฟิก (graphics processing unit; GPU) ในการประมวลผลได้ และมีอัลกอริทึมสำหรับการสร้างโครงข่ายประสาทเทียมและการเรียนรู้เชิงลึกที่หลากหลาย และมีการนำไปประยุกต์ใช้กับงานวิจัยในหลายสาขาวิชา เช่น การรู้จำเสียง การประมวลผลภาพ สร้างหุ่นยนต์ ฯลฯ โดยการทำงานของ TensorFlow จะมีการสร้างกราฟสำหรับการประมวลผล ซึ่งกราฟจะประกอบไปด้วยกลุ่มของโหนดโดยกราฟจะแสดงการไหลของการประมวลผลข้อมูล

สราวุฒิ บุญเกิดรัมย์ และณัฐวุฒิ ศรีวิบูลย์ (2563) อธิบายว่า Keras Library คือ API สำหรับการพัฒนาโครงข่ายประสาทเทียมซึ่งเขียนด้วยภาษาไพทอน สามารถทำงานโดยอาศัยไลบรารีอย่าง TensorFlow โดย Keras สามารถรองรับการสร้างโมเดล การเรียนรู้ของเครื่องในรูปแบบโครงข่ายประสาทเทียมตลอดจนการสร้างโมเดลการเรียนรู้เชิงลึกโดยมี ข้อดี คือง่ายต่อการเขียน และทำความเข้าใจ มีการทำงานแยกเป็นส่วน ๆ สามารถแยกส่วนประกอบ ต่าง ๆ ในการสร้างโมเดลอย่างเช่น Neural Layers Cost Functions Optimizers Activation Functions และ ประกอบกันเป็นโมเดล

ใหม่ได้ สามารถพัฒนาฟังก์ชันหรือคลาสต่าง ๆ เพิ่มได้ง่าย โดยการพัฒนาทั้งหมดต้องใช้ภาษาไพทอนในการพัฒนา

วิธีการประเมินประสิทธิภาพ

ภากร กัทชลี (2562) กล่าวว่า เมทริกซ์ความสับสน (confusion matrix) เป็นเครื่องมือทางสถิติที่ใช้ในการประเมินประสิทธิภาพของระบบการจำแนกและการทำนาย (classification) โดยเฉพาะในงาน machine learning และ data science โดย confusion matrix ช่วยให้เราสามารถนำความแม่นยำและประสิทธิภาพของระบบการจำแนกมาวัดและวิเคราะห์ได้อย่างชัดเจน

ตารางที่ 1 เมทริกซ์ความสับสน

Actual Values		Predictive Values: Positive	Predictive Values: Negative
	Positive	TP	FN
	Negative	FP	TN

True Positive (TP) เป็นจำนวนที่ถูก กรณีที่ระบบทำนายว่าเหตุการณ์หรือข้อมูลเป็นจริง (positive) และตรงกับความจริงที่ว่าเป็นจริง ในกรณีนี้ระบบทำนายถูกต้อง

True Negative (TN) เป็นจำนวนที่ถูก กรณีที่ระบบทำนายว่าเหตุการณ์หรือข้อมูลไม่เป็นจริง (negative) และตรงกับความจริงที่ว่าไม่เป็นจริง ในกรณีนี้ระบบทำนายถูกต้อง

False Positive (FP) เป็นจำนวนที่ผิด กรณีที่ระบบทำนายว่าเหตุการณ์หรือข้อมูลเป็นจริง (positive) แต่ความจริงแล้วไม่เป็นจริง ในกรณีนี้ระบบทำนายผิด

False Negative (FN) เป็นจำนวนที่ผิด กรณีที่ระบบทำนายว่าเหตุการณ์หรือข้อมูลไม่เป็นจริง (negative) แต่ความจริงแล้วเป็นจริง ในกรณีนี้ระบบทำนายผิด โดยสามารถใช้เมทริกซ์ความสับสนมาใช้ประเมินประสิทธิภาพความแม่นยำ (accuracy) ของโมเดลทำนาย จะคำนวณโดยนับจำนวนตัวอย่างที่ถูกจำแนกถูกต้อง (True Positive และ True Negative) และนำมาหารด้วยจำนวนทั้งหมดของตัวอย่างที่ถูกทดสอบโดยมีสูตรคำนวณดังสมการที่ 1

$$\text{Accuracy} = \frac{(TP+TN)}{TP+TN+FP+FN} \quad (1)$$

คะแนน F1 (F1-score) เป็นค่าเฉลี่ยระหว่างความแม่นยำ และความสามารถในการครอบคลุม ค่าคะแนน F1 มีความสำคัญเมื่อต้องการประเมินประสิทธิภาพของแบบจำลองในกรณีที่ความสำคัญของความแม่นยำ และความสามารถในการครอบคลุม เท่ากัน ค่าคะแนน F1 สามารถใช้เพื่อเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองที่ใช้ในงานที่ความสำคัญของ precision และ recall เท่ากันหรือใกล้เคียงกัน ค่าคะแนน F1 มีค่าระหว่าง 0 ถึง 1 โดยค่าเข้าใกล้ 1 ยิ่งแสดงประสิทธิภาพที่ดีมากขึ้น ดังสมการที่ 2

$$F1\ score = 2\frac{precision\ x\ recall}{precision + recall} \quad (2)$$

เมื่อ F1 score คือ ค่าเฉลี่ยระหว่างความแม่นยำ และความสามารถในการคลอบคลุม
precision คือ ความแม่นยำในการทำนายผล
Recall คือ ความสามารถในการครอบคลุมในการทำนายผลกลุ่ม Positive

Scikit-Learn library คือ Scikit-Learn เป็นไลบรารี สำหรับไพทอนที่ใช้ในการทำการเรียนรู้ของเครื่องและ การทำเหมืองข้อมูลอย่างมีประสิทธิภาพและเป็นที่นิยมอย่างแพร่หลายในวงการวิทยาศาสตร์ข้อมูลและการพัฒนาแอปพลิเคชันแบบ การเรียนรู้ของเครื่องในไพทอนไลบรารีนี้ถูกสร้างขึ้นโดยนักพัฒนาไพทอนชุมชน และมีความเน้นที่ความง่ายในการใช้งาน ประสิทธิภาพในการทำงาน และความยืดหยุ่นในการใช้งานหลายประเภทของแบบจำลองการเรียนรู้ของเครื่อง Scikit-Learn มีความสามารถในการรองรับการเรียนรู้แบบจดจำ และการเรียนรู้แบบไม่จดจำ รวมถึงการจัดการข้อมูล การเลือกคุณลักษณะ การประเมินแบบจำลอง และการทำความเข้าใจผลลัพธ์ของแบบจำลอง ซึ่งทำให้มันเป็นเครื่องมือที่สมบูรณ์และเหมาะสำหรับงานการพัฒนาและทดสอบแบบจำลอง การเรียนรู้ของเครื่องต่างๆ

การเรียนรู้เชิงลึก (deep learning) การเรียนรู้เชิงลึก คือการใช้โครงข่ายประสาทเทียมที่มีความลึกมากเพื่อการเรียนรู้ของเครื่อง โดยความแตกต่างสำคัญคือ การเรียนรู้เชิงลึกมีจำนวน hidden layer ที่มากกว่าในโครงข่ายประสาทเทียม (artificial neural networks; ANN) โครงข่ายประสาทเทียมนั้นจำลองการทำงานของระบบโครงข่ายประสาทในระบบประสาทของมนุษย์โดยการใช้เซลล์ประสาทเทียมในรูปแบบของโหนดเชื่อมต่อกัน และมีการปรับค่าน้ำหนักเพื่อเรียนรู้และทำนายผลลัพธ์ โดยการเรียนรู้เชิงลึก จะมีการสร้างโครงข่ายประสาทที่มีความลึกมากขึ้นโดยมีหลาย hidden layer เพื่อทำนายและประมวลผลข้อมูลอย่างอัจฉริยะในระดับลึก

เฉดสีเทา (gray scale) คือช่วงของเฉดสีเทาซึ่งแตกต่างกับภาพขาวดำที่มีเพียง 2 สี คือขาวกับดำ สีในเฉดสีเทานี้แสดงถึงความเข้มของสี (intensity) ในระดับต่าง ๆ โดยสีดำเป็นส่วนที่มี

ความเข้มของสีน้อยและสีขาวจะมีความเข้มของสีมาก จำนวนระดับของสีขึ้นอยู่กับขนาดของบิตที่ใช้เก็บค่าสี โดยทั่วไปแล้วจะเก็บข้อมูลสีประเภทนี้ด้วยข้อมูลขนาด 8 บิตหรือ 1 ไบต์ ซึ่งจะให้ความละเอียดของสีที่ 265 เฉดสี ดังภาพแสดงในรูปที่ 1

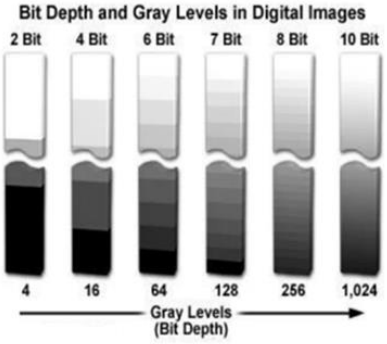

รูปที่ 1 ระดับสีของเฉดสีเทาตามขนาดข้อมูลที่เก็บค่าสี

ภาพขาวดำ การแปลงภาพเป็นภาพแบบขาวดำ (image binarization) คือ ส่วนหนึ่งของการประมวลผลภาพระดับสีเทาให้เป็นภาพขาวดำ ซึ่งแต่ละพิกเซลจะมีค่าเป็น 0 หรือ 1 เนื่องจากการประมวลผลภาพสีใช้เวลานาน และใช้พื้นที่ในการวิเคราะห์มาก ในการวิเคราะห์ภาพเอกสารจำเป็นต้องทำการแปรลงภาพขาวดำในวัตถุที่พิจารณา เช่น อักษร รูปภาพ และตาราง เป็นต้น (Sonawane, Gaikwad, Mandekar, Baradkar, & Gunjal, 2021)

Silva and Sonnadara (2013) ได้นำเสนอบทความเรื่องการจำแนกพันธุ์ข้าวด้วยการใช้โครงข่ายประสาทเทียม ซึ่งใช้พันธุ์ข้าวทั้งหมด 9 สายพันธุ์แล้วเก็บผลภาพของข้าว เพื่อนำมาพัฒนาอัลกอริทึมสำหรับการจำแนกภาพ ผลลัพธ์ แสดงให้เห็นว่าภาพพื้นผิวผิวให้ความแม่นยำมากกว่าเมื่อเทียบกับภาพแต่งสี โดยความแม่นยำทั้งหมดอยู่ที่ 92% จากโมเดลทั้งหมด

สุชาติ แย้มเม่น ณรงฤทธิ์ พิมพ์คำวงศ์ และโชคชรัตน์ ฤทธิ์เย็น (2559) ได้นำเสนอบทความเกี่ยวกับการพัฒนาวิธีการจำแนกประเภทเมล็ดข้าวขาวโดยการประยุกต์ใช้เทคนิคทางด้านการประมวลผลภาพ เช่น การหาตำแหน่งของวัตถุโดยใช้หลักการสหสัมพันธ์ การแปลงภาพระดับเทาเป็นภาพขาวดำโดยใช้ค่าขีดแบ่งอัตโนมัติ การติดป้ายส่วนประกอบเชื่อมต่อ การกรองสัญญาณรบกวนโดยใช้การเปลี่ยนรูปแบบเปิดด้วยการประมวลผลภาพองค์ประกอบโครงสร้าง การหาขอบภาพโดยวิธีแคนนี่ การหาความยาวเส้นขอบจากระยะทางคู่พิกัด และทำการหาประสิทธิภาพของโปรแกรมที่พัฒนาขึ้นด้วย (mean absolute error) และค่าความถูกต้องของการจำแนกประเภทเมล็ดข้าวขาวในหน่วยร้อยละ

Academic Journal of Science and Technology, Dhonburi Rajabhat University
Volume 2, Issue 1, (January-June) 2024

วิธีการดำเนินงานวิจัย

การออกแบบและพัฒนามีอัลกอริทึมที่ใช้สำหรับการจำแนกเมล็ดข้าวโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยมีรายละเอียดดังแสดงในรูปที่ 2

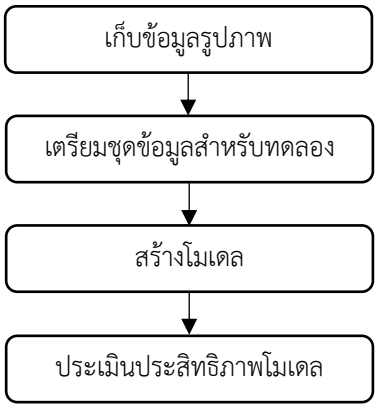

รูปที่ 2 แผนผังการดำเนินงานวิจัย

1. เก็บข้อมูลรูปภาพ ในขั้นตอนนี้ ผู้วิจัยได้ทำการเตรียม กระดาษสีดำขนาด A4 และนำเมล็ดข้าวมาวางกระจายบนกระดาษ แล้วถ่ายภาพจากกล้องมือถือบนขาตั้งกล้องที่ตั้งขนานกับพื้นซึ่งห่างจากพื้น 20 เซนติเมตร แล้วถ่ายรูปกลุ่มข้าว สายพันธุ์ข้าวปทุมธานี 1 (PTN1) กข 6 (RD6) และข้าวญี่ปุ่น (JPN) สายพันธุ์ละ 2 ภาพ รวมทั้งหมดเป็นจำนวน 6 ภาพ

2. เตรียมชุดข้อมูลสำหรับทดลอง ในขั้นตอนการเตรียมชุดข้อมูลนี้ผู้วิจัยได้นำรูปกลุ่มข้าวที่ได้จากขั้นตอนผ่านมา มาครอบตัดเป็นรูปละ 1 เมล็ด ซึ่งแต่ละภาพจะมีขนาด 256x256 พิกเซล ซึ่งครอบตัดเมล็ดข้าวสายพันธุ์ละ 200 ภาพ จึงได้จำนวนภาพเมล็ดข้าวทั้งหมด 600 ภาพ หลังจากนั้นนำภาพที่ครอบตัด 600 ภาพซึ่งเป็นภาพสีดังแสดงในรูปที่ 3 มาแปลงให้เป็นภาพเฉดเทา 600 ภาพ และภาพขาวดำ 600 ภาพ ดังแสดงในรูปที่ 4 และรูปที่ 5 ตามลำดับ

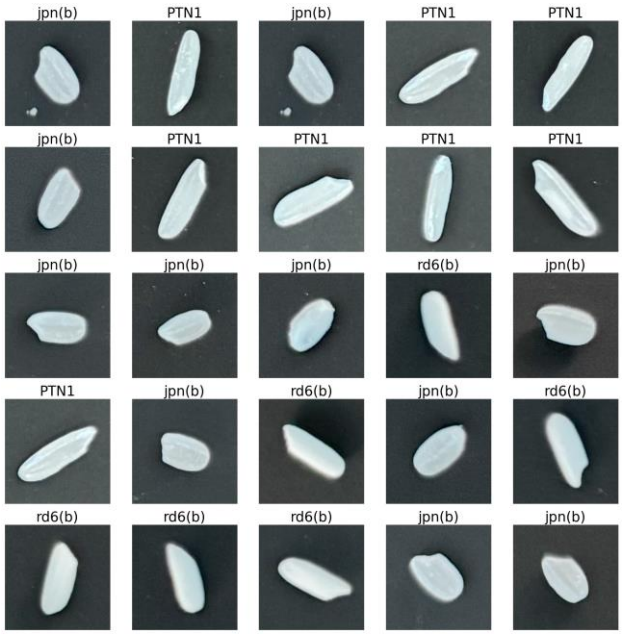

รูปที่ 3 ภาพเมล็ดพันธุ์ข้าวแบบสี

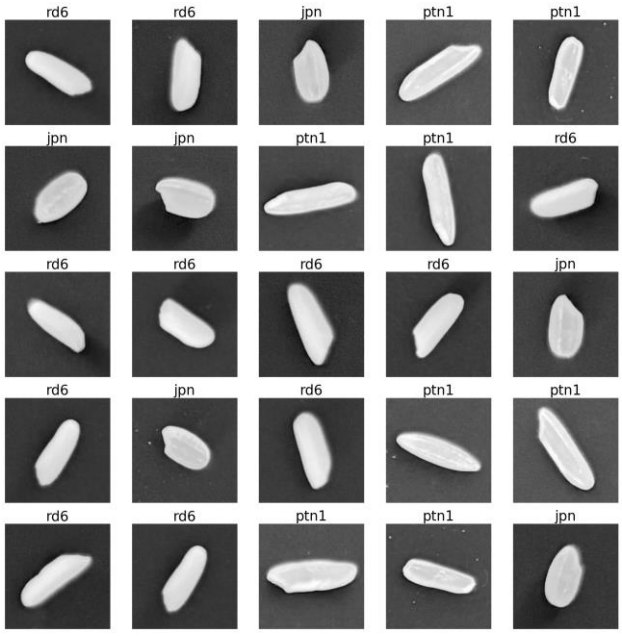

รูปที่ 4 ภาพเมล็ดพันธุ์ข้าวแบบเฉดเทา

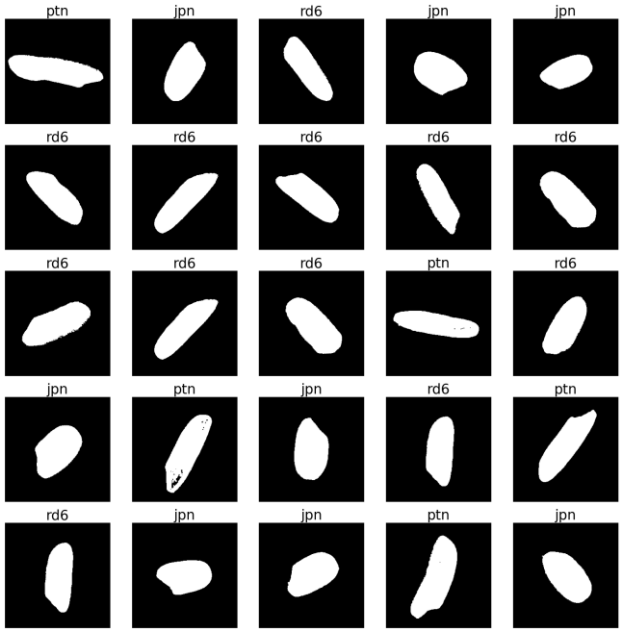

รูปที่ 5 ภาพเมล็ดพันธุ์ข้าวแบบขาวดำ

3. สร้างโมเดลจากภาพเมล็ดข้าวที่ครอบตัดแยกออกเป็นภาพละเมล็ด ในขั้นตอนนี้จะนำภาพเมล็ดข้าวมาวิเคราะห์และจำแนกชนิดของเมล็ดพันธุ์ด้วยวิธีโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยตัวอย่างภาพเมล็ดพันธุ์ข้าวทั้งหมด 600 ภาพจะถูกแบ่งออกเป็นสองชุดข้อมูล ได้แก่ ชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ โดยแบ่งด้วยอัตราส่วน 80% ต่อ 20%

ในการสร้างโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน งานวิจัยนี้ได้กำหนดค่าพารามิเตอร์ดังตารางที่ 2 และการออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันแสดงดังรูปที่ 6

ตารางที่ 2 พารามิเตอร์ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

พารามิเตอร์	**ค่าที่กำหนดไว้**
Input size (pixel)	256x256
Rescaling	1./255
Batch size	16
Epoch	5
Kernel size	3x3
Pool size	2x2

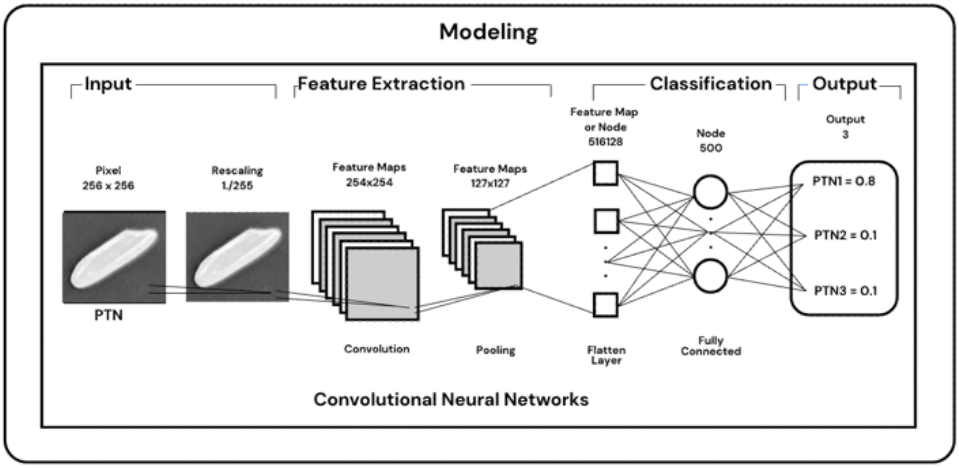

รูปที่ 6 กระบวนการสร้างโครงข่ายประสาทเทียมแบบคอนโวลูชัน

โครงข่ายประสาทเทียมแบบคอนโวลูชัน(convolution neural network; CNN) จากรูปที่ 6 ประกอบด้วย input การสกัดคุณลักษณะ (feature extraction) การจัดหมวดหมู่ (classification) และ output ซึ่งมีการกำหนดพารามิเตอร์ ดังตารางที่ 2

Input คือ การรับข้อมูลเข้ามา เป็น array 3 มิติ ขนาด 256x256 พิกเซล (256,256,3) แต่ละค่าจะมี 0 ถึง 255 หลังจากนั้นทำการตั้งค่าพารามิเตอร์ rescaling ที่ 1./255 เพื่อปรับค่าของข้อมูล ระหว่าง 0 กับ 1

Feature extraction คือ การสกัดคุณลักษณะ ประกอบด้วยขั้นตอน convolution pooling และ flatten layer ซึ่งในรูปที่ 6 มี convolution ที่กำหนด input ขนาด 256x256 kernel 3x3 ได้ feature maps ขนาด 254x254 และ pooling แบบ MaxPooling กำหนดพารามิเตอร์ขนาด 2x2 ได้ feature maps ขนาด 127x127 และนำมา flatten layer จะมีลักษณะเป็น array 1 มิติ จะได้ feature maps ขนาด 516128

Classification คือการนำข้อมูลจากขั้นตอน feature extraction นำมาประมวลผลข้อมูลโดยใช้ fully connected layer ประกอบด้วย input layer, hidden layer และ output layer ซึ่งในภาพที่ 6 input layer มีโหนดทั้งหมด 516128 โหนด เท่ากับจำนวนข้อมูล flatten layer และ hidden layer 1 ชั้น มี 500 โหนด มีการเรียนรู้รูปแบบหรือความสัมพันธ์ระหว่างข้อมูล เมื่อได้ผลลัพธ์จะส่งออกค่าไปยังชั้น output layer จำนวน 3 โหนด

Output คือขั้นตอนการนำผลลัพธ์จากขั้นตอน classification มาแสดงผล ซึ่งในรูปที่ 6 มีจำนวนผลลัพธ์ออกมา 3 ผลลัพธ์ และค่าจาก activation function ได้ผลดังนี้ [PTN1,0.8] [PTN2,0.1] [PTN3,0.1]

ในขั้นตอนการสร้างโมเดลนี้ ผู้วิจัยได้เก็บข้อมูลระยะเวลาที่ใช้ในการสร้าง ซึ่งแสดงให้เห็นว่าภาพสีใช้ระยะเวลาในการสร้างมากที่สุด และภาพขาวดำใช้ระยะเวลาในการสร้างโมเดลน้อยที่สุด ดังแสดงในรูปที่ 7

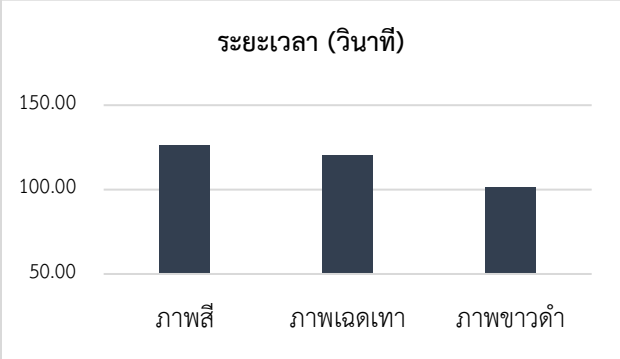

รูปที่ 7 ระยะเวลาในการเรียนรู้เพื่อสร้างโมเดล

4. ประเมินประสิทธิภาพโมเดล หลังจากได้โมเดลการจำแนกเมล็ดข้าวทั้งสามโมเดลแล้ว คือโมเดลที่ได้จากการเรียนรู้จากภาพสี จากภาพเฉดเทา และจากภาพขาวดำ ในขั้นตอนนี้จะนำโมเดลทั้งสามมาทดสอบประสิทธิภาพ โดยวัดผลจากข้อมูลทดสอบที่แยกไว้ 20% ของแต่ละโมเดล โดยวัดผลจากค่าความแม่นดังแสดงในในสมการที่ 1 และวัดผลคะแนน F1 ดังสมการที่ 2

ผลการวิจัย

จากการนำชุดข้อมูลทดสอบ 20% หรือจำนวน 180 ภาพ ของทั้งสามโมเดลมาทดสอบได้ Confusion Matrix ของแต่ละโมเดลดังแสดงในตารางที่ 3 - 5 ตาราง Confusion Matrix เหล่านี้สามารถคำนวณคะแนน F1 และความแม่นยำ ดังสรุปประสิทธิภาพของแต่ละโมเดลดังต่อไปนี้

1. การทดสอบภาพสี ข้าวปทุมธานี 1 ได้ค่าคะแนน F1 ที่ 98.24% ข้าวญี่ปุ่น ได้ค่าคะแนน F1 ที่ 67.64% ข้าว กข 6 ได้ค่าคะแนน F1 ที่ 94.54% ใช้เวลาในการเรียนรู้ 2 นาที 6 วินาที และได้ค่าความแม่นยำ 85.55% ดังแสดงในรูปที่ 8 - 9

2. การทดสอบภาพเฉดเทา ข้าวปทุมธานี 1 ได้ค่าคะแนน F1 ที่ 100% ข้าวญี่ปุ่น ได้ค่า คะแนน F1 ที่ 91.17% ข้าวกข 6 ได้ค่าคะแนน F1 ที่ 69.09% ใช้เวลาในการเรียนรู้ 2 นาที ได้ค่าความแม่นยำ 87.22%

ตารางที่ 3 Confusion Matrix ของการจำแนกพันธุ์ข้าวในภาพสี

Predicted				
	ข้าวปทุมธานี 1	56	0	1
	ข้าวญี่ปุ่น	0	46	22
	ข้าวกข 6	3	0	52
		ข้าวปทุมธานี 1	ข้าวญี่ปุ่น	ข้าวกข 6

True Positive

ตารางที่ 4 Confusion Matrix ของการจำแนกพันธุ์ข้าวในภาพเฉดเทา

Predicted				
	ข้าวปทุมธานี 1	57	0	0
	ข้าวญี่ปุ่น	0	62	6
	ข้าวกข 6	9	8	38
		ข้าวปทุมธานี 1	ข้าวญี่ปุ่น	ข้าวกข 6

True Positive

ตารางที่ 5 Confusion Matrix ของการจำแนกพันธุ์ข้าวในภาพขาวดำ

Predicted				
	ข้าวปทุมธานี 1	54	0	3
	ข้าวญี่ปุ่น	0	46	22
	ข้าวกข 6	1	7	47
		ข้าวปทุมธานี 1	ข้าวญี่ปุ่น	ข้าวกข 6

True Positive

3. การทดสอบภาพขาวดำ ข้าวปทุมธานี 1 ได้ค่าคะแนน F1 ที่ 94.73% ข้าวญี่ปุ่นได้ค่าคะแนน F1 ที่ 67.64% ข้าวกข 6 ได้ค่าคะแนน F1 ที่ 85.45% ใช้เวลาในการเรียนรู้ 1 นาที 41 วินาที และได้ค่าความแม่นยำ 81.66%

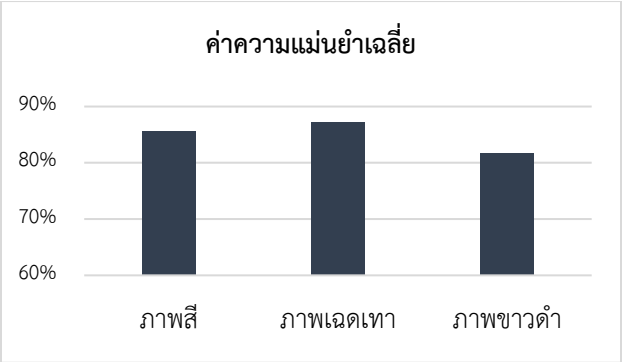

รูปที่ 8 ค่าคะแนน F1 ของการจำแนกเมล็ดพันธุ์ข้าว

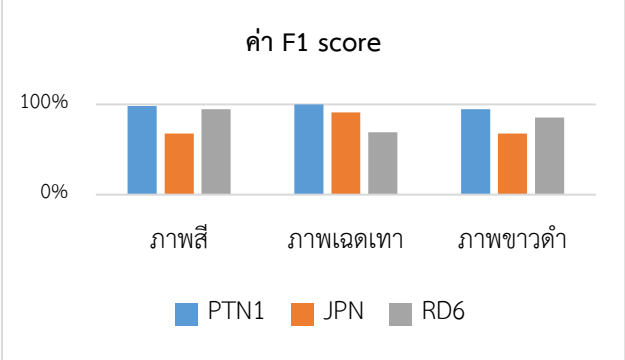

รูปที่ 9 ค่าความแม่นยำเฉลี่ยของการจำแนกเมล็ดพันธุ์ข้าว

งานวิจัยนี้นำเสนอการจำแนกพันธุ์ข้าวจากภาพเมล็ดข้าวที่ผ่านการสีข้าวแล้ว โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน และใช้ภาพเมล็ดข้าวจากข้าวสามสายพันธุ์ ได้แก่ ข้าวปทุมธานี 1 (PTN1) ข้าวกข 6 (RD6) และข้าวญี่ปุ่น (JPN) รวมทั้งหมดจำนวน 600 ภาพ โดยงานวิจัยนี้มีจุดประสงค์เพื่อเปรียบเทียบประสิทธิภาพด้านความแม่นยำและเวลา จากภาพเมล็ดข้าวสามรูปแบบ ได้แก่ ภาพสี ภาพเฉดเทา และภาพขาวดำ จากการทดลองพบว่า โมเดลที่ได้จากการเรียนรู้จากภาพเฉดเทาได้ค่าความแม่นยำเฉลี่ยมากที่สุดคือ 87.22% ใช้เวลาในการสร้างโมเดล 2 นาที อันดับที่สอง คือ ภาพสีได้ค่าความแม่นยำเฉลี่ย 85.55% ใช้เวลาในการสร้างโมเดล 2 นาที 6 วินาที และสุดท้ายคือภาพขาวดำได้ค่าความแม่นยำเฉลี่ย 81.66% ใช้เวลาในการสร้างโมเดล 1 นาที 41 วินาที

จากผลการทดลองนี้สรุปได้ว่า การเรียนรู้จากการเตรียมรูปภาพที่แตกต่างกัน 3 รูปแบบ สามารถจำแนกเมล็ดพันธุ์ข้าวได้อย่างมีประสิทธิภาพ และในงานวิจัยนี้วิธีที่มีประสิทธิภาพมากที่สุดในการจำแนกเมล็ดพันธุ์ข้าว คือ ภาพเฉดเทา และงานวิจัยในอนาคตที่ผู้วิจัยคาดว่าสามารถพัฒนาต่อไปได้ คือ การเพิ่มจำนวนข้อมูลและสายพันธุ์พร้อมกับปรับเปลี่ยนพารามิเตอร์ของโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อเพิ่มประสิทธิภาพความแม่นยำที่สูงขึ้นเนื่องจากเมล็ดพันธุ์ข้าวบางสายพันธุ์นั้นมีลักษณะทางกายภาพที่ใกล้เคียงกัน

เอกสารอ้างอิง

จักรินทร์ สนุกแสน และโอฬาริก สุรินต๊ะ. (2562). โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสำหรับการจำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ. **วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม**, 38(2), 113-124.

ภากร กัทชลี. (2562). **Confusion Matrix เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนายใน Machine learning.** ค้นเมื่อ 10 ตุลาคม 2566, จากhttps://medium.com/@pagongatchalee/confusion-matrix-เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย-ในmachine-learning-fba6e3f9508c.

สุชาติ แย้มเม่น, ณรงค์ฤทธิ์ พิมพ์คำวงศ์ และโชคชรัตน์ ฤทธิ์เย็น. (2559). การจำแนกประเภทเมล็ดข้าวขาวด้วยการ ประมวลผลภาพ. **วารสารวิชาการและวิจัย มทร.พระนคร สาขาวิทยาศาสตร์และเทคโนโลยี,** 10(1), 1-14.

สราวุฒิ บุญเกิดรัมย์ และณัฐวุฒิ ศรีวิบูลย์. (2563). การตรวจสอบคุณภาพทางกายภาพของข้าวกล้องงอกโดยใช้การประมวลผลภาพ. **วารสารวิทยาการและเทคโนโลยีสารสนเทศ.** 10(2), 101.

สำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ. (ม.ป.ป.). **มาตรฐานสินค้าเกษตร เรื่อง ข้าวหอมมะลิไทย (มกษ. 4000-2560)**.

Kanoktipsatharporn, S. (2019). **Convolutional Neural Network คืออะไร ภาษาไทย ตัวอย่างการทำงาน CNN, ConvNet กับชุดข้อมูล MNIST – ConvNet ep.1.** from https://www.bualabs.com/archives/2461/what-is-convolutional-neural-network-cnn-convnet-mnist-deep-learning-convnet-ep-1/.

Lapthanachai, N., Chomthong, A., Waijanya, S., & Promrit, N. (2023). Classification of nail abnormalities using convolutional neural network. **Journal of Applied Informatics and Technology**, 5(1), 18-35.

Pattana-anurak, A. (2023). **What is TensorFlow.** Retrieved October 10, 2023, from https://thaiconfig.com/artificial-intelligence-ai/what-is-tensorflow/.

Silva, C. S., & Sonnadara U. (2013). Classification of rice grains using neural networks. **In Conference: Institute of Physics Sri Lanka (IPSL).** March 2013. V.29.

Sonawane, V., Gaikwad, N., Mandekar, H., Baradkar, K., & Gunjal, C. (2021). Rice quality analysis and classification using image processing techniques. **International Journal of Computer Science and Mobile Computing-IJCSMC Journal,** 10(6), 79-82.