



ปัญหาพิเศษ

การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน
ในการจำแนกพันธุ์ ข้าวขาวดอกมะลิ 105 กข15 และ กข6

**Comparison of Convolutional Neural Network Performance for
Classification of Thai Rice Varieties: KDML105, RD15 and RD6**

นายณัฐวินท์ จินดาดวง

ภาควิชาพืชไร่นา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

DEPARTMENT OF AGRONOMY

FACULTY OF AGRICULTURE KASETSART UNIVERSITY



ใบรับรองปัญหาพิเศษ

คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

วิทยาศาสตร์บัณฑิต (วิทยาศาสตร์เกษตร)

ปริญญา

.....
วิทยาศาสตร์เกษตร

.....
พืชไร่นา

สาขา

ภาควิชา

เรื่อง การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชันในการจำแนกพันธุ์
ข้าวขาวดอกมะลิ 105 กข15 และ กข6

Comparison of Convolutional Neural Network Performance for Classification
of Thai Rice Varieties: KDML105, RD15 and RD6

นามผู้วิจัย นายณัฐวินท์ จินดาตวง

ได้รับการพิจารณาเห็นชอบโดย

อาจารย์ที่ปรึกษาปัญหาพิเศษหลัก

(..... รองศาสตราจารย์ ดำรงวุฒิ อ่อนวิมล, ปร.ด.)

อาจารย์ที่ปรึกษาปัญหาพิเศษร่วม

(..... ผู้ช่วยศาสตราจารย์ วีรชัย มัธยัสต์ถาวร, ปร.ด.)

หัวหน้าภาควิชา

(..... ผู้ช่วยศาสตราจารย์ ปาริชาติ พรหมโชติ, Ph.D.)

วันที่ 31 เดือน มีนาคม พ.ศ. 2569

ปัญหาพิเศษ

เรื่อง

การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน
ในการจำแนกพันธุ์ ข้าวขาวดอกมะลิ 105 กข15 และ กข6

Comparison of Convolutional Neural Network Performance for Classification of
Thai Rice Varieties: KDML105, RD15 and RD6

โดย

ณัฐวินท์ จินดาดวง

เสนอ

ภาควิชาพืชไร่นา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์

DEPARTMENT OF AGRONOMY

FACULTY OF AGRICULTURE KASETSART UNIVERSITY

บทคัดย่อ

ณัฐวินท์ จินดาตวง 2568 : การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน ในการจำแนกพันธุ์ข้าว ขาวดอกมะลิ 105 กข15 และ กข6. ปัญหาพิเศษปริญญาตรี สาขา วิทยาศาสตร์เกษตร ภาควิชาพืชไร่นา อาจารย์ที่ปรึกษา: รองศาสตราจารย์ ดำรงวุฒิ อ่อนวิมล, ประ.ด. 29 หน้า

ข้าวขาวดอกมะลิ 105 กข15 และ กข6 เป็นพันธุ์ข้าวที่มีความสำคัญทางเศรษฐกิจ แต่มี ลักษณะทางสรีระเมล็ดที่คล้ายคลึงกันอย่างมากจนยากต่อการจำแนกด้วยสายตา งานวิจัยนี้มี วัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน (CNN) สอง สถาปัตยกรรม ได้แก่ MobileNetV2 และ ResNet101 ในการจำแนกพันธุ์ข้าวสำคัญ โดยใช้ชุดข้อมูล ภาพถ่ายรวม 12,000 ภาพ กระบวนการดำเนินงานประกอบด้วยการเตรียมข้อมูลภาพโดยการปรับ ขนาด (Resize) เป็น 224x224 พิกเซล เพื่อให้สอดคล้องกับข้อกำหนดของสถาปัตยกรรม ข้อมูลถูก แบ่งเป็นส่วนฝึกสอนร้อยละ 70 และชุดทดสอบร้อยละ 30 เพื่อพัฒนาแบบจำลองด้วยเทคนิคการ เรียนรู้แบบถ่ายโอน (Transfer Learning) โดยเปรียบเทียบอัลกอริทึมการปรับค่าพารามิเตอร์ระหว่าง ADAM และ SGDM ผลการศึกษาพบว่า สถาปัตยกรรม ResNet101 ร่วมกับอัลกอริทึม ADAM ให้ ประสิทธิภาพสูงสุด โดยมีความแม่นยำ (Accuracy) เฉลี่ยร้อยละ 94.72 และค่า F1-score เท่ากับ 0.947 ในขณะที่ MobileNetV2 มีความแม่นยำร้อยละ 92.00 เมื่อพิจารณารายพันธุ์ พบว่าโมเดล จำแนกข้าวขาวดอกมะลิ 105 ได้แม่นยำสูงสุดถึงร้อยละ 99.50 ส่วนความสับสนส่วนใหญ่เกิดขึ้น ระหว่างพันธุ์ กข15 และ กข6 เนื่องจากความใกล้เคียงกันทางกายภาพ สรุปได้ว่า ResNet101 เป็น โมเดลที่ช่วยลดข้อผิดพลาดและระยะเวลาในการตรวจสอบ ซึ่งเป็นต้นแบบที่มีประสิทธิภาพในการ พัฒนาเทคโนโลยีควบคุมคุณภาพเมล็ดพันธุ์ในอุตสาหกรรมข้าวไทยต่อไป

คำสำคัญ: ข้าวขาวดอกมะลิ 105, กข15, กข6, การจำแนกพันธุ์ข้าว, โครงข่ายประสาทแบบคอนโวลูชัน

ณัฐวินท์ จินดาตวง

ลายมือชื่อนิติศ

ลายมือชื่ออาจารย์ที่ปรึกษาปัญหาพิเศษหลัก

30 / มี.ค. / 69

ABSTRACT

Nuttawin Jindaduang. 2026: Comparison of Convolutional Neural Network Performance for Classification of Thai Rice Varieties: KDML105, RD15 and RD6. Bachelor's special problem in Agricultural Science, Department of Agronomy. Special problem advisor: Associate Professor Damrougvudhi Onwimol, Ph.D. 39.

Khao Dawk Mali 105, RD15, and RD6 are economically significant rice varieties. However, their seeds possess highly similar physical characteristics, making manual visual classification difficult. This research aims to compare the performance of two Convolutional Neural Network (CNN) architectures, MobileNetV2 and ResNet101, for the classification of these key rice varieties using a dataset of 12,000 images. The methodology involves image preprocessing by resizing images to 224x224 pixels to comply with architectural requirements. The dataset was partitioned into a 70% training set and a 30% test set to develop models using Transfer Learning. A comparison was conducted between two optimization algorithms: ADAM and SGDM. The results indicate that the ResNet101 architecture combined with the ADAM algorithm achieved the highest performance, with an average accuracy of 94.72% and an F1-score of 0.947, while MobileNetV2 achieved an accuracy of 92.00%. Specifically, the model classified Khao Dawk Mali 105 with a peak accuracy of 99.50%. Most classification errors occurred between RD15 and RD6 due to their close physical similarities. In conclusion, utilizing ResNet101 as an automated tool can reduce human error and processing time, serving as an effective prototype for quality control technology in the Thai rice industry.

Keywords: Khao Dawk Mali 105, RD15, RD6, Rice Variety Classification, Convolutional Neural Network

Nuttawin Jindaduang

Student's signature

D. Onwimol

Special Problem Advisor's signature

30 / 03 / 26

กิตติกรรมประกาศ

ผู้วิจัยขอกราบขอบพระคุณรองศาสตราจารย์ ดำรงวุฒิ อ่อนวิมล ที่ให้ความช่วยเหลือในงานวิจัยในการทำวิทยานิพนธ์และให้คำแนะนำเล่มจนเสร็จสมบูรณ์ ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณกรมการข้าว ที่ใช้ในการทำวิจัยที่ให้ความอนุเคราะห์ตัวอย่างเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105 ข้าว กข15 และข้าว กข6 เพื่อใช้เป็นข้อมูลในการถ่ายภาพและนำมาทดสอบในงานวิจัย ซึ่งเป็นส่วนสำคัญที่ทำให้การพัฒนาระบบคัดแยกด้วยเทคโนโลยีปัญญาประดิษฐ์ในครั้งนี้สามารถดำเนินการได้อย่างสมบูรณ์

สุดท้ายนี้ ขอกราบขอบพระคุณบิดา มารดา ที่ได้ให้การสนับสนุนด้านการศึกษาและทุนทรัพย์ รวมทั้งครอบครัวและเพื่อนๆ ทุกคนที่คอยให้ความช่วยเหลือ เป็นกำลังใจ และอยู่เคียงข้างมาโดยตลอด จนกระทั่งงานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

ณัฐวินท์ จินดาดวง

มีนาคม 2569

สารบัญ

	หน้า
สารบัญ	ก
สารบัญตาราง	ข
สารบัญภาพ	ค
คำนำ	1
วัตถุประสงค์.....	2
การตรวจเอกสาร	3
อุปกรณ์และวิธีการ	13
อุปกรณ์.....	13
วิธีการ	14
สถานที่และระยะเวลาการทําวิจัย.....	17
ผลและวิจารณ์.....	18
สรุป	24
เอกสารและสิ่งอ้างอิง.....	25
ภาคผนวก	27
ประวัติการศึกษาและการทำงาน	29

สารบัญตาราง

ตารางที่	หน้า
1. ประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน และ อัลกอริทึม สำหรับปรับปรุงค่าน้ำหนัก (Optimizer) ในการจำแนกภาพถ่ายแมลงศัตรูพืช 3 พันธุ์ในการทดลอง	21

สารบัญภาพ

ภาพที่	หน้า
1. ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105	4
2. ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าว กข 15	5
3. ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าว กข 6	6
4. โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน	8
5. โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน โมเดล MobileNetV2	10
6. โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน โมเดล ResNet101	11
7. ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105 กข15 และ กข6 โดยโมเดล MobileNetV2 โดยใช้ Optimizer SDGM (ภาพบน) และ ADAM (ภาพล่าง)	19
8. ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105 กข15 และ กข6 โดยโมเดล ResNet101 โดยใช้ Optimizer ADAM (ภาพบน) และ ADAM (ภาพล่าง)	20
9. เปรียบเทียบค่า Accuracy (%) และค่า F1-Score ของโมเดล MobileNetV2 และ ResNet101 และ Optimizer ADAM (Adaptive Moment Estimation) และ SGDM (Stochastic Gradient Descent with Momentum)	21
10. Confusion Matrix จำนวนภาพที่โมเดล ResNet101 ร่วมกับ ADAM ทายถูกและผิด	23

**การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน
ในการจำแนกพันธุ์ ข้าวขาวดอกมะลิ 105 กข15 และ กข6**

**Comparison of Convolutional Neural Network Performance for Classification of
Thai Rice Varieties: KDML105, RD15 and RD6**

คำนำ

ข้าว (Rice) เป็นพืชเศรษฐกิจที่มีความสำคัญอย่างยิ่งต่อความมั่นคงทางอาหารและเศรษฐกิจของประเทศไทย โดยเฉพาะข้าวขาวดอกมะลิ 105 ซึ่งเป็นข้าวหอมที่มีชื่อเสียงระดับโลก อย่างไรก็ตาม ปัญหาที่สำคัญในกระบวนการผลิตและคัดแยกเมล็ดพันธุ์คือการปนเปื้อนของเมล็ดพันธุ์พืชอื่นที่มีลักษณะทางกายภาพคล้ายคลึงกัน เช่น ข้าวพันธุ์ กข15 และ กข6 (ภาพผนวกที่ 1 - 3) ซึ่งส่งผลกระทบต่อคุณภาพมาตรฐานและมูลค่าทางการค้าของเมล็ดพันธุ์ เนื่องจากการคัดแยกด้วยสายตามนุษย์นั้นทำได้ยากและอาจเกิดความคลาดเคลื่อนได้สูง ทางผู้วิจัยจึงเล็งเห็นถึงความสำคัญของการนำเทคโนโลยีปัญญาประดิษฐ์เข้ามาประยุกต์ใช้เพื่อยกระดับความแม่นยำในกระบวนการตรวจสอบดังกล่าว

ในปัจจุบัน โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ได้รับการยอมรับอย่างกว้างขวางว่ามีศักยภาพสูงในการเรียนรู้และสกัดลักษณะเฉพาะจากข้อมูลภาพถ่ายได้อย่างมีประสิทธิภาพ ดังนั้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของสถาปัตยกรรม CNN ในการจำแนกพันธุ์ข้าวขาวดอกมะลิ 105, กข15 และ กข6 เพื่อพัฒนาแนวทางในการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ด้วยเทคโนโลยีปัญญาประดิษฐ์ ซึ่งจะประโยชน์ต่ออุตสาหกรรมการผลิตเมล็ดพันธุ์ข้าวในอนาคต

วัตถุประสงค์

1. เพื่อรวบรวมและสร้างฐานข้อมูลภาพถ่ายสัณฐานวิทยาเมล็ดข้าว 3 พันธุ์ จำนวน 12,000 ภาพ
2. เพื่อพัฒนาแบบจำลองปัญญาประดิษฐ์ (AI Model) ในการจำแนกความแตกต่างของเมล็ดพันธุ์ข้าวที่มีพันธุกรรมใกล้เคียงได้อย่างแม่นยำ

การตรวจเอกสาร

ข้าว (*Oryza sativa* L.) จัดเป็นพืชล้มลุกตระกูลหญ้า (Poaceae) ที่มีความสำคัญอย่างยิ่งต่อเศรษฐกิจและวิถีชีวิตของประชากรในประเทศไทย โดยเฉพาะกลุ่มข้าวขาวดอกมะลิซึ่งเป็นสินค้าส่งออกที่มีมูลค่าสูง อย่างไรก็ตาม ความท้าทายสำคัญในการจัดการคุณภาพเมล็ดพันธุ์คือความคล้ายคลึงกันทางสัณฐานวิทยาของเมล็ดข้าวกลุ่มเดียวกัน โดยพันธุ์ที่นำมาศึกษาในการวิจัยครั้งนี้มีความเกี่ยวข้องกันทางพันธุกรรมอย่างใกล้ชิด (กรมการข้าว, 2560)

ลักษณะทางกายภาพและสัณฐานวิทยาของเมล็ดข้าว

เมล็ดพันธุ์ข้าวที่นำมาใช้ในการศึกษาครั้งนี้ ประกอบด้วยข้าวกลุ่มที่มีความสัมพันธ์ทางพันธุกรรมใกล้ชิดกันและมีลักษณะทางกายภาพที่คล้ายคลึงกันอย่างมากจำนวน 3 พันธุ์ ได้แก่ ข้าวพันธุ์ขาวดอกมะลิ 105, กข15 และ กข6 โดยแต่ละพันธุ์มีรายละเอียดทางสัณฐานวิทยาและขนาดของเมล็ด ดังนี้

ข้าวพันธุ์ขาวดอกมะลิ 105 (Khao Dawk Mali 105)

ข้าวขาวดอกมะลิ 105 เป็นข้าวเจ้าหอมไวต่อช่วงแสงที่เป็นต้นแบบมาตรฐานคุณภาพข้าวของประเทศไทย มีลักษณะทางสัณฐานวิทยาที่โดดเด่นคือ เมล็ดรูปร่างเรียวยาว ข้าวเปลือกสีฟาง ผิวเรียบไม่มีขน (ภาพที่ 1) และมีความเสถียรทางพันธุกรรมสูง จึงถูกนำมาใช้เป็นฐานในการพัฒนาพันธุ์ข้าวใหม่ๆ ผ่านกระบวนการชักนำให้เกิดการกลายพันธุ์เสมอ โดยลักษณะทางกายภาพด้านขนาดของเมล็ดข้าวกล้องมีความยาวเฉลี่ย 0.75 เซนติเมตร (7.5 มิลลิเมตร) ความกว้าง 0.21 เซนติเมตร (2.1 มิลลิเมตร) และความหนา 0.18 เซนติเมตร ในขณะที่เมล็ดข้าวเปลือกมีความยาวเฉลี่ย 1.06 เซนติเมตร และความกว้างเฉลี่ย 0.25 เซนติเมตร (กรมการข้าว, 2560)




ภาพที่ 1 ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105

(L = ความยาว , W = ความกว้าง)

ที่มา : (กรมการข้าว , 2560)

ข้าวพันธุ์ กข15 (RD15)

เป็นพันธุ์ข้าวเจ้าหอมไวต่อช่วงแสงที่ได้จากการชักนำให้เกิดการกลายพันธุ์จากพันธุ์ขาวดอกมะลิ 105 แม้จะมีอายุการเก็บเกี่ยวที่สั้นกว่า แต่ลักษณะทางกายภาพภายนอกยังคงคล้ายคลึงกับพันธุ์เดิมอย่างมาก (ภาพที่ 2) โดยมีทรงเมล็ดเรียวยาว ข้าวเปลือกสีฟางและมีปลายบิดงอเล็กน้อย เมล็ดข้าวสารมีความขาวใส เมื่อพิจารณาขนาดของเมล็ดพบว่า ข้าวกล้องมีความยาวเฉลี่ย 0.75 เซนติเมตร และความกว้าง 0.21 เซนติเมตร ซึ่งมีสัดส่วนเท่ากับข้าวขาวดอกมะลิ 105 ทุกประการ ส่วนระยะข้าวเปลือกมีความยาวเฉลี่ย 1.07 เซนติเมตร และความกว้าง 0.25 เซนติเมตร ความคล้ายคลึงทางมิตินี้ส่งผลให้ยากต่อการจำแนกด้วยสายตา (กรมการข้าว, 2560)



ภาพที่ 2 ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าว กข 15

(L = ความยาว , W = ความกว้าง)

ที่มา : (กรมการข้าว , 2560)

ข้าว กข6 (RD6)

เป็นข้าวเหนียวหอมที่เกิดจากการกลายพันธุ์ของข้าวขาวดอกมะลิ 105 ผ่านการฉายรังสีแกมมา มีรูปร่างเมล็ดเรียวยาวคล้ายข้าวเจ้า ข้าวเปลือกสีฟางหรือสีน้ำตาล ข้าวสารมีสีขาวขุ่น เมื่อหุงสุกจะเหนียวนุ่มและมีกลิ่นหอม ในระยะข้าวกล้องมีความยาวเฉลี่ย 7.2 มิลลิเมตร ความกว้าง 2.2 มิลลิเมตร และความหนา 1.7 มิลลิเมตร ส่วนระยะข้าวเปลือกมีความยาวเฉลี่ย 9.9 มิลลิเมตร และความกว้าง 2.7 มิลลิเมตร (ภาพที่ 3)



ภาพที่ 3 ภาพลักษณะความยาวและความกว้างของเมล็ดพันธุ์ข้าว กข 6

(L = ความยาว , W = ความกว้าง)

ที่มา : (กรมการข้าว , 2560)

ความล้มพันธ์ทางพันธุกรรมของข้าวขาวดอกมะลิ 105, กข15 และ กข6

ข้าวขาวดอกมะลิ 105 (Khao Dawk Mali 105) จัดเป็นพันธุ์ข้าวเจ้าหอมที่เป็นต้นแบบของคุณภาพข้าวไทย โดยมีความสำคัญในฐานะเป็นพันธุ์แม่หรือพันธุ์ต้นฉบับ (Parent Variety) ที่ถูกนำมาใช้ในการพัฒนาพันธุ์ข้าวใหม่ๆ ผ่านกระบวนการทางวิทยาศาสตร์ โดยเฉพาะการชักนำให้เกิดการกลายพันธุ์ (Induced Mutation) ด้วยการใช้รังสีแกมมา (Gamma Radiation) เพื่อให้ได้พันธุ์ข้าวที่มีคุณลักษณะดีขึ้นแต่ยังคงรักษาเอกลักษณ์เดิมไว้ (นริศรา และคณะ, 2555)

ในส่วน of ข้าวพันธุ์ กข15 นั้น เป็นข้าวเจ้าหอมที่ได้รับการพัฒนาจากการกลายพันธุ์ของข้าวขาวดอกมะลิ 105 โดยตรง มีจุดเด่นคือมีอายุการเก็บเกี่ยวที่สั้นกว่าเดิมประมาณ 10-20 วัน แต่ยังคงลักษณะทางกายภาพของเมล็ดและคุณภาพการหุงต้มที่ใกล้เคียงกับพันธุ์เดิมทุกประการ ในขณะที่ข้าวพันธุ์ กข6 เป็นข้าวเหนียวหอมที่เกิดจากการกลายพันธุ์ของข้าวขาวดอกมะลิ 105 เช่นกัน โดยเปลี่ยนจากข้าวเจ้าเป็นข้าวเหนียวแต่ยังคงลักษณะเมล็ดที่เรียวยาวและมีกลิ่นหอมคล้ายพันธุ์ดั้งเดิม ความใกล้ชิดทางพันธุกรรมนี้ส่งผลให้เมล็ดข้าวทั้ง 3 พันธุ์มีลักษณะคล้ายคลึงกันจนยากต่อการแยกแยะด้วยสายตา (กรมการข้าว, 2560)

การผลิตเมล็ดพันธุ์ข้าวความบริสุทธิ์ทางพันธุ์

การผลิตเมล็ดพันธุ์ข้าวให้ได้มาตรฐานคุณภาพสูง มีเป้าหมายสำคัญคือการรักษาความบริสุทธิ์ทางพันธุกรรม (Genetic Purity) โดยต้องควบคุมไม่ให้มีเมล็ดข้าวพันธุ์อื่นปะปนเกินกว่าเกณฑ์ที่กำหนดในแต่ละชั้นพันธุ์ ซึ่งประกอบด้วยเมล็ดพันธุ์คัด เมล็ดพันธุ์หลัก เมล็ดพันธุ์ขยาย และเมล็ดพันธุ์จำหน่าย กระบวนการนี้ต้องอาศัยการตรวจสอบอย่างละเอียดในทุกขั้นตอน ตั้งแต่การเตรียมแปลงปลูก การกำจัดข้าวปนในนา ไปจนถึงกระบวนการคัดทำความสะอาดหลังการเก็บเกี่ยว (กองเมล็ดพันธุ์ข้าว, 2560)


อย่างไรก็ตาม ปัญหาหลักในการตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์ข้าวกลุ่มหอมมะลิ คือความคล้ายคลึงกันของลักษณะสัณฐานวิทยาภายนอก โดยเฉพาะข้าวขาวดอกมะลิ 105, กข15 และ กข6 ที่มีขนาดมิติเมล็ดและสีเปลือกใกล้เคียงกันมาก การปนเปื้อนของพันธุ์อื่นเพียงเล็กน้อยในระหว่างกระบวนการผลิตเมล็ดพันธุ์จำหน่าย (Certified Seed) สามารถส่งผลกระทบต่อคุณภาพการหุงต้มและราคาในตลาดส่งออกอย่างมีนัยสำคัญ การคัดแยกด้วยสายตาจึงอาจมีความผิดพลาดสูง หากผู้ปฏิบัติงานขาดความเชี่ยวชาญ (หทัยรัตน์ และคณะ, 2566)

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN)

โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network: CNN) (ภาพที่ 4) เป็นสถาปัตยกรรมการเรียนรู้เชิงลึก (Deep Learning) ที่ถูกออกแบบมาโดยเฉพาะสำหรับการประมวลผลข้อมูลภาพดิจิทัล (Digital Image) จุดเด่นที่สำคัญของ CNN คือความสามารถในการสกัดคุณลักษณะ (Feature Extraction) จากภาพได้โดยอัตโนมัติ โดยไม่จำเป็นต้องอาศัยผู้เชี่ยวชาญในการกำหนดคุณลักษณะเอง (Manual Feature Engineering) โครงสร้างพื้นฐานของ CNN ประกอบด้วยชั้นการทำงานหลัก 3 ส่วน ได้แก่ ชั้นคอนโวลูชัน (Convolutional Layer) ที่ทำหน้าที่สกัดคุณลักษณะพื้นฐาน เช่น เส้นขอบ สี และพื้นผิว ชั้นพูลลิง (Pooling Layer) ที่ช่วยลดขนาดมิติของข้อมูลและรักษาคุณลักษณะที่สำคัญไว้เพื่อลดภาระการคำนวณ และชั้นเชื่อมต่อสมบูรณ์ (Fully Connected Layer) ซึ่งทำหน้าที่ประมวลผลข้อมูลทั้งหมดเพื่อจำแนกประเภท (Classification) ในขั้นตอนสุดท้าย (Goodfellow และคณะ, 2016)

เมื่อนำเทคโนโลยี CNN มาประยุกต์ใช้กับงานจำแนกประเภทเมล็ดพันธุ์ข้าว โมเดลจะสามารถเรียนรู้ความแตกต่างระดับพิกเซลที่ละเอียดอ่อน ซึ่งสายตามนุษย์อาจมองข้ามได้ โดยเฉพาะในกลุ่มข้าวที่มีความสัมพันธ์ทางพันธุกรรมใกล้เคียงกันอย่างข้าวขาวดอกมะลิ 105, ข้าว กข15 และ ข้าว กข6 ตัวแบบจะทำการเรียนรู้แพทเทิร์นของรูปทรง ความโค้งมน และมิติของเมล็ดข้าวจากชุดข้อมูลภาพถ่ายจำนวนมาก ส่งผลให้ระบบสามารถคัดแยกสิ่งเจือปนหรือจำแนกสายพันธุ์ได้อย่าง

รวดเร็ว มีความแม่นยำสูง และสามารถนำไปต่อยอดในการตรวจสอบคุณภาพระดับอุตสาหกรรมได้อย่างมีประสิทธิภาพ (วรพันธ์ และคณะ, 2562)



ภาพที่ 4 โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชัน

ที่มา : <https://shorturl.at/GrIEQ>

ส่วนประกอบหลักของโครงข่ายประสาทแบบคอนโวลูชัน

ส่วนประกอบหลักของโครงข่ายประสาทแบบคอนโวลูชัน (CNN) ทำหน้าที่สกัดคุณลักษณะของภาพและจำแนกประเภท ประกอบด้วย 4 ส่วนหลัก คือ เลเยอร์คอนโวลูชัน (Conv Layer) คึงฟิเจอร์, ฟังก์ชันการกระตุ้น (ReLU) เพิ่มความไม่เป็นเชิงเส้น, เลเยอร์พูลลิ่ง (Pooling Layer) ลดขนาดข้อมูล, และ เลเยอร์เชื่อมต่อเต็มรูปแบบ (FC Layer) ทำการจำแนกประเภทขั้นสุดท้าย (Keita, 2023)

ส่วนประกอบหลักมีรายละเอียดดังนี้:

Convolutional Layer (เลเยอร์คอนโวลูชัน): เป็นหัวใจสำคัญทำหน้าที่สกัดคุณลักษณะ (Features) เช่น ขอบ, เส้น, หรือสี จากภาพ โดยใช้ตัวกรอง (Filters หรือ Kernels) ขนาดเล็กกวาดไปทั่วภาพเพื่อสร้างแผนที่ฟิเจอร์ (Feature Map) (Keita, 2023)

Activation Layer (ReLU): เลเยอร์ ReLU (Rectified Linear Unit) จะถูกนำมาใช้หลัง Convolutional Layer เพื่อเพิ่มความไม่เป็นเชิงเส้น (Non-linearity) ให้กับโมเดล โดยจะเปลี่ยนค่าลบทั้งหมดให้เป็นศูนย์ ช่วยให้เครือข่ายเรียนรู้ความสัมพันธ์ที่ซับซ้อนได้ดีขึ้นและเร่งการฝึกฝน (Keita, 2023)


Pooling Layer (เลเยอร์พูลลิง): ทำหน้าที่ลดขนาดของแผนที่ฟีเจอร์ (Downsampling/Subsampling) เพื่อลดจำนวนพารามิเตอร์และการคำนวณ ช่วยลดปัญหาการ Overfitting และทำให้โมเดลทนทานต่อการเปลี่ยนแปลงตำแหน่งของวัตถุในภาพ วิธีที่นิยมคือ Max Pooling (Keita, 2023)

Fully Connected Layer (FC Layer): เลเยอร์เชื่อมต่อสมบูรณ์จะอยู่ช่วงท้ายสุด ทำหน้าที่นำฟีเจอร์ที่สกัดได้จากเลเยอร์ก่อนหน้าทั้งหมดมารวมกัน (Flatten) และส่งผ่านไปยังเครือข่ายประสาทเทียมแบบหนาแน่นเพื่อจำแนกประเภท (Classification) หรือทำนายผลลัพธ์ (Keita, 2023)

โครงข่ายประสาทแบบคอนโวลูชันโมเดล MobileNetV2

MobileNetV2 เป็นสถาปัตยกรรมโครงข่ายประสาทแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Network) ที่ถูกพัฒนาขึ้นโดยทีมนักวิจัยจาก Google ซึ่งออกแบบมาโดยเฉพาะสำหรับการประมวลผลบนอุปกรณ์เคลื่อนที่ (Mobile Devices) และระบบที่มีทรัพยากรการประมวลผลจำกัด จุดเด่นสำคัญที่ทำให้ MobileNetV2 มีประสิทธิภาพสูงคือการใช้เทคนิค Depthwise Separable Convolution ที่ช่วยลดจำนวนพารามิเตอร์และการคำนวณทางคณิตศาสตร์ได้อย่างมหาศาลเมื่อเทียบกับโครงข่าย CNN แบบดั้งเดิม (ภาพที่ 5) นอกจากนี้ยังมีการพัฒนาโครงสร้างแบบ Inverted Residual Blocks ร่วมกับ Linear Bottlenecks ซึ่งช่วยแก้ปัญหาการสูญเสียข้อมูลสำคัญในระหว่างกระบวนการลดมิติข้อมูล ทำให้โครงข่ายสามารถสกัดและเรียนรู้คุณลักษณะที่ซับซ้อนของภาพได้ดียิ่งขึ้นแม้ตัวโมเดลจะมีขนาดเล็กก็ตาม (Sandler และคณะ, 2018)

สำหรับการนำโมเดล MobileNetV2 มาประยุกต์ใช้ในงานจำแนกประเภทเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105, กข15 และ กข6 ถือเป็นทางเลือกที่เหมาะสมอย่างยิ่ง เนื่องจากสถาปัตยกรรมนี้มีความสามารถในการสกัดคุณลักษณะเด่น (Feature Extraction) จากภาพถ่ายเมล็ดข้าวที่มีความคล้ายคลึงทางสัณฐานวิทยาสูงได้อย่างแม่นยำ โดยใช้เวลาในการประมวลผลที่รวดเร็วและใช้หน่วยความจำน้อย การเลือกใช้โมเดลที่มีความคล่องตัวสูงนี้ จะส่งผลให้ระบบคัดแยกที่พัฒนาขึ้นมีศักยภาพในการนำไปต่อยอดเป็นแอปพลิเคชันบนสมาร์ตโฟน หรือบูรณาการเข้ากับระบบกล้องอุตสาหกรรมสำหรับการตรวจสอบความบริสุทธิ์ของเมล็ดพันธุ์แบบเรียลไทม์ (Real-time Inspection) ได้อย่างมีประสิทธิภาพ (Sandler และคณะ, 2018)



ภาพที่ 5 โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชันโมเดล MobileNetV2


ที่มา : <https://www.analyticsvidhya.com/blog/2023/12/what-is-mobilenetv2/>

โครงข่ายประสาทแบบคอนโวลูชันโมเดล ResNet101

ResNet101 (Residual Network 101-Layer) (ภาพที่ 6) เป็นสถาปัตยกรรมโครงข่ายประสาทแบบคอนโวลูชันเชิงลึกที่ถูกพัฒนาขึ้นโดยทีมนักวิจัยจาก Microsoft Research จุดเด่นสำคัญที่ทำให้โครงข่ายนี้โด่งดังและประสบความสำเร็จอย่างมากคือการแก้ปัญหาความชันของค่าความคลาดเคลื่อนที่หายไป (Vanishing Gradient Problem) ซึ่งมักเกิดขึ้นเมื่อโครงข่ายมีจำนวนชั้น (Layers) ที่ลึกมากเกินไป สถาปัตยกรรม ResNet แก้ปัญหานี้ด้วยการนำเสนอแนวคิด บล็อกส่วนตกค้าง (Residual Blocks) และ การเชื่อมต่อข้ามชั้น (Skip Connections หรือ Shortcut Connections) ซึ่งอนุญาตให้ข้อมูลสามารถส่งผ่านข้ามชั้นการเรียนรู้บางชั้นไปได้โดยตรง เทคนิคนี้ทำให้โมเดลที่มีความลึกถึง 101 ชั้นอย่าง ResNet101 สามารถเรียนรู้คุณลักษณะที่ซับซ้อนได้ลึกซึ้งยิ่งขึ้นโดยไม่สูญเสียประสิทธิภาพในระหว่างการฝึกฝน (Training) (He และคณะ, 2016)

ในบริบทของการจำแนกประเภทเมล็ดพันธุ์ข้าวที่มีความคล้ายคลึงทางพันธุกรรมและลักษณะทางสัณฐานวิทยาสูงมาก เช่น ข้าวขาวดอกมะลิ 105, ข้าว กข15 และข้าว กข6 การใช้โมเดลที่มีความลึกสูงอย่าง ResNet101 ถือเป็นเครื่องมือที่ทรงพลังอย่างยิ่ง เนื่องจากโครงข่ายสามารถสกัดคุณลักษณะ (Feature Extraction) ได้ในระดับที่ละเอียดและซับซ้อนมาก เช่น พื้นที่ผิวที่แตกต่างกันเพียงเล็กน้อย หรือความโค้งงอของปลายเมล็ด แม้ว่าสถาปัตยกรรมนี้จะต้องการทรัพยากรในการประมวลผล (Computational Cost) และเวลาในการฝึกฝนที่สูงกว่าโครงข่ายขนาดเล็ก แต่ก็แลกมาด้วยความแม่นยำ (Accuracy) และเสถียรภาพในการคัดแยกที่สูงมาก จึงเหมาะสมอย่างยิ่งในการ

นำมาใช้เป็นโมเดลอ้างอิง (Baseline Model) เพื่อเปรียบเทียบประสิทธิภาพการทำงานกับโมเดลอื่นๆ ในงานวิจัยนี้ (He และคณะ, 2016)



ภาพที่ 6 โครงสร้างการทำงานของโครงข่ายประสาทแบบคอนโวลูชันโมเดล ResNet101

(ส่วนขวาแสดงการประยุกต์ใช้แบบ Feature Pyramid Network)

ที่มา: https://www.researchgate.net/figure/a-Schematics-of-the-ResNet101-architecture-which-included-33-residual-nodes-in-total-b_fig5_338842473

อัลกอริทึมปรับค่าพารามิเตอร์ (Optimizer)

ในการฝึกฝนโครงข่ายประสาทเทียม อัลกอริทึมปรับค่าพารามิเตอร์ หรือ ออปติไมเซอร์ (Optimizer) ทำหน้าที่สำคัญในการปรับปรุงค่าน้ำหนัก (Weights) และค่าความเอนเอียง (Biases) เพื่อลดค่าฟังก์ชันความสูญเสีย (Loss Function) ให้เหลือน้อยที่สุด ซึ่งจะส่งผลให้โมเดลมีความแม่นยำเพิ่มขึ้น สำหรับการพัฒนาโมเดลจำแนกพันธุ์ข้าวในงานวิจัยนี้ ได้เลือกใช้อัลกอริทึม 2 ชนิด เพื่อทดสอบและเปรียบเทียบประสิทธิภาพ ได้แก่ Adam และ SGDM (Goodfellow และคณะ, 2016)

Adam (Adaptive Moment Estimation)

Adam เป็นอัลกอริทึมที่ได้รับความนิยมอย่างสูงในงานประมวลผลภาพ จุดเด่นคือความสามารถในการปรับอัตราการเรียนรู้ (Learning Rate) ของแต่ละพารามิเตอร์ได้แบบอัตโนมัติ โดยนำข้อดีของ AdaGrad และ RMSProp มาผสมผสานกัน ทำให้อัลกอริทึมสามารถจดจำทิศทางความชันในอดีต (Momentum) และปรับขนาดก้าวเดินได้อย่างเหมาะสม ส่งผลให้โมเดลสามารถเรียนรู้และลู่เข้าสู่จุดต่ำสุด (Convergence) ได้อย่างรวดเร็วตั้งแต่รอบการเรียนรู้ (Epoch) แรกๆ (Kingma และ Ba, 2014)

SGDM (Stochastic Gradient Descent with Momentum)

SGDM เป็นการพัฒนาต่อจากอัลกอริทึม SGD พื้นฐาน โดยเพิ่มแนวคิดของโมเมนตัม (Momentum) เข้าไป เพื่อช่วยแก้ปัญหากลิ้งตัวไปมา (Oscillation) ระหว่างการปรับค่าน้ำหนัก แนวคิดนี้เปรียบเสมือนการปล่อยลูกบอลให้กลิ้งลงจากเนินเขา ซึ่งโมเมนตัมจะช่วยสะสมความเร็วในทิศทางที่ถูกต้องและพุ่งทะลุผ่านหลุมพรางของจุดต่ำสุดท้องถิ่น (Local Minimum) ไปได้ แม้ SGDM อาจใช้เวลาในการลู่เข้าสู่เป้าหมายช้ากว่า Adam ในช่วงแรก แต่ในหลายกรณีกลับพบว่าสามารถปรับจูนโมเดลให้เข้าถึงจุดที่เหมาะสมที่สุด (Global Minimum) และให้ค่าความแม่นยำ (Accuracy) ที่เสถียรมากกว่าในระยะยาว (Goodfellow และคณะ, 2016)

อุปกรณ์และวิธีการ

อุปกรณ์

1. เมล็ดพันธุ์ที่ใช้ในการทดลอง
 - 1.1 เมล็ดพันธุ์ข้าวขาวดอกมะลิ 105
 - 1.2 เมล็ดพันธุ์ข้าวขาว 15
 - 1.3 เมล็ดพันธุ์ข้าวขาว 6
2. อุปกรณ์ที่ใช้ในการทดลอง
 - 2.1 เกล็ดมือถือมาโคร
 - 2.2 กระดาษ A4
 - 2.3 โคมไฟ
 - 2.4 โทรศัพท์มือถือรุ่น Huawei Nova 5T
 - 2.5 ถุงชিপัส
 - 2.6 คอมพิวเตอร์และซอฟต์แวร์ที่เกี่ยวข้อง
 - 2.6.1 โปรแกรม MATLAB

วิธีการ

การรวบรวมและจัดเตรียมชุดข้อมูล (Data Collection)

รวบรวมข้อมูลภาพถ่ายเมล็ดพันธุ์ข้าวจำนวน 3 พันธุ์ ซึ่งได้รับความอนุเคราะห์เมล็ดพันธุ์จากกรมการข้าว โดยทำการถ่ายภาพเมล็ดข้าวแต่ละพันธุ์ด้วยกล้องภายใต้สภาพแวดล้อมและแสงสว่างที่ควบคุม เพื่อให้ภาพถ่ายมีความสม่ำเสมอ ชุดข้อมูลทั้งหมดประกอบด้วยภาพถ่ายจำนวน 12000 ภาพ แบ่งเป็น ข้าวขาวดอกมะลิ 105 (KDML105) จำนวน 4000 ภาพ ข้าว กข15 (RD15) จำนวน 4000 ภาพ ข้าว กข6 (RD6) จำนวน 4000 ภาพ

การประมวลผลข้อมูลภาพเบื้องต้น (Image Preprocessing)

1.การปรับขนาดภาพ (Image Resizing) ปรับขนาดความกว้างและความยาวของภาพถ่ายเมล็ดข้าวทุกภาพให้มีขนาด 224 x 224 พิกเซล เพื่อให้สอดคล้องกับโครงสร้างมาตรฐานที่รับได้ของสถาปัตยกรรมโมเดลที่เลือกใช้

2.การปรับสเกลค่าพิกเซล (Image Rescaling/Normalization) ทำการปรับช่วงค่าความสว่างของพิกเซล (Pixel Value) ในแต่ละช่องสี RGB จากเดิมที่มีช่วงค่า 0-255 ให้อยู่ในสัดส่วน 0-1 (โดยการหารด้วย 255) เพื่อช่วยลดระยะเวลาในการคำนวณและเพิ่มความเสถียรในการลู่เข้าหาจุดต่ำสุด (Convergence) ของโมเดลระหว่างการฝึกฝน

การแบ่งชุดข้อมูล (Data Splitting)

1.ชุดข้อมูลสำหรับฝึกฝน (Training Set) คิดเป็นร้อยละ 70 ของข้อมูลทั้งหมด ใช้สำหรับกระบวนการเรียนรู้และปรับค่าน้ำหนัก (Weights) ภายในโครงข่าย

2.ชุดข้อมูลสำหรับตรวจสอบความแม่นยำ (Validation Set) คิดเป็นร้อยละ 30 ของข้อมูลทั้งหมด ใช้สำหรับประเมินประสิทธิภาพระหว่างการฝึกฝน เพื่อตรวจสอบปัญหาการเรียนรู้เกินพอดี (Overfitting)

การออกแบบและสร้างแบบจำลอง (Model Construction and Training)

1.MobileNetV2 สถาปัตยกรรมที่ออกแบบมาเพื่อให้มีความคล่องตัวสูง ใช้ทรัพยากรการประมวลผลต่ำ และมีความรวดเร็ว

2.ResNet101 สถาปัตยกรรมโครงข่ายเชิงลึกที่มีจำนวนชั้นมากถึง 101 ชั้น ซึ่งมีความสามารถในการสกัดคุณลักษณะที่ซับซ้อนได้อย่างแม่นยำ

การปรับพารามิเตอร์ (Hyperparameter Tuning)

ได้ทำการทดสอบเปรียบเทียบอัลกอริทึมสำหรับปรับปรุงค่าน้ำหนัก (Optimizer) จำนวน 2 ชนิด ได้แก่ Adam และ SGDM (Stochastic Gradient Descent with Momentum) เพื่อหาออปติไมเซอร์ที่เหมาะสมที่สุดสำหรับการจำแนกเมล็ดข้าวในแต่ละสถาปัตยกรรม โดยกำหนดให้ฟังก์ชันความสูญเสีย (Loss Function) เป็นแบบ Categorical Cross entropy

การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

ภายหลังสิ้นสุดกระบวนการฝึกฝนจะทำการประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองแต่ละรูปแบบ โดยพิจารณาจากมาตรวัดเชิงสถิติที่สำคัญ ดังนี้

1. ค่าความแม่นยำ (Accuracy)

เพื่อวัดสัดส่วนการทำนายพันธุ์ข้าวได้อย่างถูกต้องจากข้อมูลทั้งหมด

2. ค่าความสูญเสีย (Loss)

เพื่อวัดระดับความคลาดเคลื่อนของผลลัพธ์ที่แบบจำลองทำนายเทียบกับความเป็นจริง

การสร้างและวิเคราะห์เมทริกซ์ความสับสน (Confusion Matrix)

ในการประเมินประสิทธิภาพเชิงลึกของแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน ผู้วิจัยได้เลือกใช้เมทริกซ์ความสับสน (Confusion Matrix) เป็นเครื่องมือหลักในการวิเคราะห์ผล เนื่องจากสามารถแสดงรายละเอียดการทำนายเปรียบเทียบกับค่าความเป็นจริง (Ground Truth) ได้อย่างชัดเจน ทำให้ทราบถึงพฤติกรรมการจำแนกผิดพลาด (Misclassification) ระหว่างพันธุ์ข้าวที่มีความคล้ายคลึงกัน โดยการสร้างและวิเคราะห์เมทริกซ์ความสับสนมีขั้นตอนการดำเนินงานดังนี้ (Han และคณะ, 2011)

การประมวลผลผลลัพธ์การทดสอบ (Result Inference)

ผู้วิจัยนำชุดข้อมูลสำหรับตรวจสอบ (Validation Set) หรือชุดข้อมูลทดสอบ (Testing Set) ซึ่งผ่านการติดฉลากระบุพันธุ์ที่ถูกต้อง (Actual Class) ไว้แล้ว ป้อนเข้าสู่แบบจำลอง MobileNetV2 และ ResNet101 ที่ผ่านกระบวนการฝึกฝนเสร็จสิ้น เพื่อให้แบบจำลองทำการทำนายพันธุ์ข้าว (Predicted Class) ออกมาเป็นค่าความน่าจะเป็น แล้วเลือกคลาสที่มีค่าความน่าจะเป็นสูงสุดเป็นคำตอบสุดท้าย

การจัดทำโครงสร้างเมทริกซ์ขนาด 3x3 (Matrix Construction)

เนื่องจากการวิจัยนี้เป็นการจำแนกข้าว 3 พันธุ์ ผู้วิจัยจึงสร้างตารางเมทริกซ์ขนาด 3x3 โดยกำหนดให้แกนหนึ่งของตารางแทน "พันธุ์ข้าวที่แท้จริง (Actual Class)" และอีกแกนหนึ่งแทน "พันธุ์ข้าวที่แบบจำลองทำนายได้ (Predicted Class)" ประกอบด้วย ข้าวขาวดอกมะลิ 105, ข้าว กข15 และ ข้าว กข6 จากนั้นนำผลการเปรียบเทียบระหว่างค่าทำนายและค่าจริงของภาพข้าวทุกภาพในชุดทดสอบ มานับความถี่และเติมลงในช่องแต่ละช่องของตาราง (Han และคณะ, 2011)

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

$$Precision = \frac{TP}{TP + FP} \quad \text{_____} \quad 2$$

$$Recall = \frac{TP}{TP + FN} \quad \text{_____} \quad 3$$

$$F1 \text{ score} = 2 \times \frac{Precision * Recall}{Precision + Recall} \quad \text{_____} \quad 4$$

การแยกองค์ประกอบทางสถิติ (Statistical Component Extraction)

เพื่อนำไปสู่การคำนวณตัวชี้วัดประสิทธิภาพ จะทำการดึงค่าจากเมทริกซ์ความสับสน โดยพิจารณาแยกแบบรายคลาส (One-vs-Rest) ซึ่งข้อมูลในตารางจะถูกแบ่งออกเป็น 4 องค์ประกอบหลัก ดังนี้

True Positive (TP): จำนวนภาพที่แบบจำลองทำนายว่าเป็นพันธุ์เป้าหมายได้ถูกต้องตรงกับความเป็นจริง (ค่าที่ปรากฏในแนวทแยงมุมหลักของตาราง) (Han และคณะ, 2011)

True Negative (TN): จำนวนภาพที่แบบจำลองทำนายว่าไม่ใช่พันธุ์เป้าหมาย และความเป็นจริงก็ไม่ใช่พันธุ์เป้าหมายนั้น (Han และคณะ, 2011)

False Positive (FP): จำนวนภาพที่แบบจำลองทำนายผิดพลาดว่าเป็นพันธุ์เป้าหมาย ทั้งที่ความเป็นจริงคือพันธุ์อื่น (ความผิดพลาดประเภทที่ 1) (Han และคณะ, 2011)

False Negative (FN): จำนวนภาพที่ความเป็นจริงคือพันธุ์เป้าหมาย แต่แบบจำลองกลับทำนายผิดพลาดว่าเป็นพันธุ์อื่น (ความผิดพลาดประเภทที่ 2) (Han และคณะ, 2011)

การนำไปประยุกต์คำนวณตัวชี้วัด (Metrics Calculation)

เมื่อได้โครงสร้างตารางและค่าสถิติพื้นฐาน (TP, TN, FP, FN) ของข่าวทั้ง 3 พันธุ์อย่างครบถ้วนแล้ว จะนำค่าเหล่านี้ไปเป็นตัวแปรในสมการทางคณิตศาสตร์ เพื่อคำนวณหาตัวชี้วัดประสิทธิภาพรวมของแบบจำลอง ได้แก่ ค่าความแม่นยำ (Accuracy), ค่าความแม่นยำในการทำนาย (Precision), ค่าความระลึก (Recall) และค่าคะแนน (F1-Score) เพื่อใช้เป็นเกณฑ์มาตรฐานในการเปรียบเทียบประสิทธิภาพระหว่างโมเดลสถาปัตยกรรมต่างๆ ต่อไป (Han และคณะ, 2011)

สถานที่และระยะเวลาการทําวิจัย

1. สถานที่การทําวิจัย

ภาควิชาพีชไร่นา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร

2. ระยะเวลาการทําวิจัย

เริ่มต้นเดือนมกราคม 2569 ถึง มีนาคม 2569

ผลและวิจารณ์

ผลการประเมินประสิทธิภาพในการจำแนกภาพถ่ายเมล็ดพันธุ์ข้าว 3 พันธุ์ (ขาวดอกมะลิ 105, กข15 และ กข6) ด้วยโครงข่ายประสาทแบบคอนโวลูชัน จำนวน 2 แบบ ได้แก่ MobileNetV2 และ ResNet101 โดยโมเดลแต่ละแบบได้ถูกฝึกด้วยขั้นตอนวิธีปรับปรุงน้ำหนัก (Optimization Algorithm) จำนวน 2 แบบ คือ Stochastic Gradient Descent with Momentum (SGDM) และ Adaptive Moment Estimation (ADAM) Learning rate ที่ 0.0001

ผลการวิเคราะห์พบว่า สถาปัตยกรรมแบบ ResNet101 ให้ค่าความแม่นยำในการจำแนกเมล็ดข้าวสูงที่สุด เมื่อเทียบกับแบบ MOBILENetV2 (ตารางที่ 1) ปรากฏการณ์ดังกล่าวอาจมีสาเหตุมาจากโครงสร้างเครือข่ายของโมเดลที่มีประสิทธิภาพในการสกัดคุณลักษณะเด่น (Feature Extraction) ของเมล็ดข้าวทั้ง 3 พันธุ์ที่มีลักษณะทางกายภาพคล้ายคลึงกันได้ดีกว่า นอกจากนี้ ในส่วนของการปรับปรุงน้ำหนัก พบว่าอัลกอริทึม ADAM มีแนวโน้มที่จะให้ผลลัพธ์โดยรวมที่ดีกว่า SGDM เนื่องจาก ADAM มีกลไกการปรับอัตราการเรียนรู้แบบแปรผัน (Adaptive learning rate) ซึ่งช่วยให้การฝึกสอนโมเดลมีความรวดเร็วและมีเสถียรภาพในการเข้าสู่ผลลัพธ์ที่ดีกว่าอย่างเห็นได้ชัด (ภาพที่ 7 - 8)



ตารางที่ 1 ประสิทธิภาพของโครงข่ายประสาทแบบคอนโวลูชัน และ อัลกอริทึมสำหรับปรับปรุงน้ำหนัก (Optimizer) ในการจำแนกภาพถ่ายเมล็ดพันธุ์ข้าว 3 พันธุ์ในการทดลอง

Modal	Accuracy (%)	F1-Score
MobileNetV2+SGDM*	89	88
MobileNetV2+ADAM	92	92
ResNet101+SGDM	93	93
ResNet101+ADAM	95	95


*หมายเหตุ Stochastic Gradient Descent with Momentum (SGDM) และ Adaptive Moment Estimation (ADAM)



ภาพที่ 7 ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105 กข15 และ กข6 โดยโมเดล MobileNetV2 โดยใช้ Optimizer SDGM (ภาพบน) และ ADAM (ภาพล่าง)



ภาพที่ 8 ความแม่นยำของการประเมินความบริสุทธิ์ทางกายภาพของเมล็ดพันธุ์ข้าวขาวดอกมะลิ 105 กข15 และ กข6 โดยโมเดล ResNet101 โดยใช้ Optimizer ADAM (ภาพบน) และ ADAM (ภาพล่าง)



ภาพที่ 9 เปรียบเทียบค่า Accuracy (%) และค่า F1-Score ของโมเดล MobileNetV2 และ ResNet101 และ Optimizer ADAM (Adaptive Moment Estimation) และ SGDM (Stochastic Gradient Descent with Momentum)

จากการศึกษาและพัฒนาแบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) เพื่อจำแนกภาพถ่ายเมล็ดพันธุ์ข้าว 3 พันธุ์ ได้แก่ ข้าวขาวดอกมะลิ 105, ข้าว กข15 และข้าว กข6 โดยเปรียบเทียบประสิทธิภาพระหว่างสถาปัตยกรรม MobileNetV2 และ ResNet101 ร่วมกับการใช้อัลกอริทึมปรับค่าพารามิเตอร์ (Optimizer) 2 รูปแบบ คือ SGDM และ ADAM สามารถสรุปผลการทดลองได้ดังนี้ (ภาพที่ 9)

ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง

พบว่าสถาปัตยกรรมแบบ ResNet101 ที่ทำงานร่วมกับอัลกอริทึม ADAM มีประสิทธิภาพในการจำแนกพันธุ์ข้าวสูงที่สุด โดยให้ค่าความแม่นยำรวม (Accuracy) สูงถึงร้อยละ 95 และมีค่าเอฟวันสกอร์ (F1-Score) ที่ร้อยละ 95 รองลงมาคือสถาปัตยกรรม ResNet101 ร่วมกับ SGDM (ร้อยละ 93) และ MobileNetV2 ร่วมกับ ADAM (ร้อยละ 92) ตามลำดับ ในขณะที่สถาปัตยกรรม MobileNetV2 ที่ทำงานร่วมกับ SGDM ให้ค่าความแม่นยำต่ำที่สุดที่ร้อยละ 89 ซึ่งผลการทดลองนี้แสดงให้เห็นว่าสถาปัตยกรรม ResNet101 ที่มีความลึกของเครือข่ายมากกว่า สามารถสกัดคุณลักษณะเด่นของเมล็ดข้าวได้ดีกว่า MobileNetV2

ผลการเปรียบเทียบอัลกอริทึมปรับค่าพารามิเตอร์

การทดลองพบว่าการใช้อัลกอริทึม ADAM ร่วมกับแบบจำลองทั้งสองสถาปัตยกรรมสามารถให้ผลลัพธ์ที่มีความแม่นยำสูงกว่าการใช้อัลกอริทึม SGDM อย่างชัดเจน เนื่องจากกลไกการปรับอัตราการเรียนรู้แบบแปรผัน (Adaptive learning rate) ของ ADAM มีความเหมาะสมกับการฝึกสอนข้อมูลภาพถ่ายที่มีความซับซ้อน ทำให้แบบจำลองสามารถเข้าสู่หาผลลัพธ์ที่ดีที่สุดได้อย่างรวดเร็วและมีเสถียรภาพมากกว่า

ผลการวิเคราะห์ความผิดพลาดในการจำแนก

จากการวิเคราะห์เมทริกซ์ความสับสน (Confusion Matrix) (ภาพที่ 10) ของแบบจำลองที่ดีที่สุด (ResNet101 ร่วมกับ ADAM) พบว่าแบบจำลองสามารถคัดแยกข้าวพันธุ์ขาวดอกมะลิ 105 ได้แม่นยำที่สุด (จำแนกถูกต้อง 1,193 ภาพ จากทั้งหมด 1,200 ภาพ) อย่างไรก็ตาม ยังพบข้อจำกัดในการจำแนกระหว่างข้าวพันธุ์ กข15 และ กข6 มากที่สุด เนื่องจากลักษณะทางกายภาพภายนอกของเมล็ดข้าวทั้งสองพันธุ์อาจมีความคล้ายคลึงกัน ส่งผลให้เกิดการทำนายสับสนระหว่างกันรวมทั้งสิ้น 113 ภาพ โดยเป็นการทำนายข้าว กข15 ผิดว่าเป็น กข6 จำนวน 76 ภาพ และทำนายข้าว กข6 ผิดว่าเป็น กข15 จำนวน 37 ภาพ (ภาพที่ 10)

		Predicted Class		
		ชาวดอก มะลิ 105	กข15	กข6
Actual Class	ชาวดอก มะลิ 105	1,193	0	6
	กข15	42	1,082	76
	กข6	29	37	1,134

ภาพที่ 10 Confusion Matrix จำนวนภาพที่โมเดล ResNet101 ร่วมกับ ADAM ทายถูกและผิด

สรุป

จากฐานข้อมูลภาพถ่ายสัณฐานวิทยาเมล็ดข้าว 3 พันธุ์ จำนวน 12,000 ภาพ พบว่าแบบจำลองสถาปัตยกรรม ResNet101 ที่ทำงานร่วมกับอัลกอริทึม ADAM สามารถให้ผลลัพธ์ความแม่นยำสูงสุดถึงร้อยละ 95.00 ในการจำแนกพันธุ์เมล็ดข้าว (ข้าวดอกมะลิ 105, กข15 และ กข6) ซึ่งแสดงให้เห็นถึงศักยภาพในการนำเทคโนโลยีโครงข่ายประสาทแบบคอนโวลูชันมาพัฒนาเป็นระบบการวิเคราะห์และคัดแยกภาพถ่ายเมล็ดพันธุ์ข้าวได้อย่างมีประสิทธิภาพ ผลลัพธ์ดังกล่าวสอดคล้องกับแนวทางการประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) ในการจำแนกเมล็ดพันธุ์ข้าว โดยเฉพาะอย่างยิ่งในกรณีที่เมล็ดพันธุ์มีลักษณะทางสัณฐานวิทยาภายนอกที่คล้ายคลึงกันสูงจนยากต่อการแยกแยะด้วยตาเปล่า นอกจากนี้ ผลการวิจัยนี้ยังสามารถนำไปใช้เป็นข้อมูลพื้นฐานในการต่อยอดพัฒนาเทคโนโลยีดังกล่าว เพื่อนำไปใช้งานบนอุปกรณ์เคลื่อนที่ เช่น สมาร์ทโฟน หรือประยุกต์ใช้ร่วมกับระบบเครื่องจักรสายพานคัดแยกเมล็ดพันธุ์ในโรงสีข้าวเชิงพาณิชย์ต่อไปในอนาคต

เอกสารและสิ่งอ้างอิง

กรมการข้าว. 2560. ลักษณะประจำพันธุ์ข้าวไทย: ขาวดอกมะลิ 105. แหล่งที่มา:

https://rkb.ricethailand.go.th/web/content_page.php?code=IG2V6DR5CBCR067OJHESNEJGFLSH1, 27 มีนาคม 2569.

กรมการข้าว. 2560. ลักษณะประจำพันธุ์ข้าวไทย: กข15. แหล่งที่มา:

https://rkb.ricethailand.go.th/web/content_page.php?code=0X078F434PDM4YGXNBYLFRP1FDUE7, 27 มีนาคม 2569.

กรมการข้าว. 2560. ลักษณะประจำพันธุ์ข้าวไทย: กข6. แหล่งที่มา:

https://rkb.ricethailand.go.th/web/content_page.php?code=T4ZPWIKJ5GBO9XB8F2IVKAA861MYR, 27 มีนาคม 2569.

กรมการข้าว. 2560. ข้อมูลพันธุ์ข้าว: กข15. แหล่งที่มา: <http://webold.ricethailand.go.th/rkb3/title-index.php-file=content.php&id=115.htm>, 27 มีนาคม 2569.

กรมการข้าว. 2565. มาตรฐานการผลิตเมล็ดพันธุ์ข้าว. แหล่งที่มา:

<https://newwebs2.ricethailand.go.th/upload/doc/6691/1669275152.pdf>, 27 มีนาคม 2569.

นริศรา ชนานันต์, วัลลภ ประสิทธิ์ และ ชีระชัย ชนานันต์. 2555. การจำแนกข้าวพันธุ์ขาวดอกมะลิ 105 และพันธุ์ปรับปรุงจากพันธุ์ขาวดอกมะลิ 105 ด้วยเทคนิคแฮตอาร์เอพีดี. แหล่งที่มา:

<https://li01.tci-thaijo.org/index.php/tjst/article/view/12893>, 27 มีนาคม 2569.

วรพันธ์ กุศลภูณินันตร์, สุชาครีย์ สว่างวงษ์, กิตตินันท์ อัคระภิญโญ และปริญญ์ ภู้อย้อย. 2562. การจำแนกเมล็ดพันธุ์ข้าวไทยโดยใช้ภาพถ่ายของเมล็ดพันธุ์ข้าวด้วยวิธีการแบบ Mask R-CNN และ Transfer Learning. แหล่งที่มา:

https://op.mahidol.ac.th/ra/2019/08/20/ict_2562-03/, 27 มีนาคม 2569.

หทัยรัตน์ อุไรรงค์, กฤตพร รำจวนเกียรติ, กัญฐวุฒิ บุญมี, ธนัสสรุ ถวิลเชื้อ และ สударัตน์ ลินชัย. 2566. การตรวจสอบความบริสุทธิ์ทางพันธุกรรมของข้าวหอมมะลิไทยโดยใช้

เครื่องหมายโมเลกุล SSR. แหล่งที่มา: <https://li01.tci-thaijo.org/index.php/agritechjournal/article/view/253939>, 27 มีนาคม 2569.

Goodfellow, I., Bengio, Y. and Courville, A. 2016. Deep Learning (Chapter 9: Convolutional Networks). สำนักพิมพ์ MIT Press. แหล่งที่มา:

<https://www.deeplearningbook.org/contents/convnets.html>, 27 มีนาคม 2569.

Han, J., Kamber, M. and Pei, J. 2011. Data Mining: Concepts and Techniques (3rd ed.).

สำนักพิมพ์ Morgan Kaufmann. แหล่งที่มา:

<https://myweb.sabanciuniv.edu/rdehkharghani/files/2016/02/The-Morgan-Kaufmann-Series-in-Data-Management-Systems-Jiawei-Han-Micheline-Kamber-Jian-Pei-Data-Mining.-Concepts-and-Techniques-3rd-Edition-Morgan-Kaufmann-2011.pdf>, 28 มีนาคม 2569.

He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep Residual Learning for Image Recognition.

แหล่งที่มา: <https://arxiv.org/abs/1512.03385>, 27 มีนาคม 2569.

Keita, Z. 2023. An Introduction to Convolutional Neural Networks (CNNs). แหล่งที่มา:

<https://www.datacamp.com/tutorial/introduction-to-convolutional-neural-networks-cnns>, 27 มีนาคม 2569.

Kingma, D. P. and Ba, J. 2014. Adam: A Method for Stochastic Optimization. แหล่งที่มา:

<https://arxiv.org/abs/1412.6980>, 27 มีนาคม 2569.

National Parks Board. 2569. *Oryza sativa* L. แหล่งที่มา:

<https://www.nparks.gov.sg/florafaunaweb/flora/5/2/5218>, 27 มีนาคม 2569.

Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L.C. 2018. MobileNetV2:

Inverted Residuals and Linear Bottlenecks. แหล่งที่มา:

<https://arxiv.org/abs/1801.04381>, 27 มีนาคม 2569.

ภาพผนวก



ภาพผนวกที่ 1 เมล็ดพันธุ์ข้าวขาวดอกมะลิ 105



ภาพผนวกที่ 2 เมล็ดพันธุ์ข้าว กข15



ภาพผนวกที่ 3 เมล็ดพันธุ์ข้าว กข 6

ประวัติการศึกษาและการทำงาน

ชื่อ-นามสกุล	ณัฐวินท์ จินดาดวง
วัน เดือน ปี เกิด	7 พฤศจิกายน 2544
สถานที่เกิด	อำเภอเมือง จังหวัดชัยภูมิ
ประวัติการศึกษา	โรงเรียนวัดราชบพิตร เขตพระนคร
ตำแหน่งหน้าที่การงานปัจจุบัน	-
สถานที่ทำงานปัจจุบัน	-
ผลงานดีเด่นและรางวัลทางวิชาการ	-
ทุนการศึกษาที่ได้รับ	-