วารสารแม่โจ้เทคโนโลยีสารสนเทศและนวัตกรรม มหาวิทยาลัยแม่โจ้ ปีที่ 9 ฉบับที่ 2 กรกฎาคม – ธันวาคม 2566

Received: 2 ธ.ค. 2565 **Revised:** 24 ม.ค. 2566 **Accepted:** 25 ม.ค. 2566

การเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพด

Performance Comparison of Image Classification Models for Corn Leaf Disease

ภานุวัฒน์ เมฆะ* พฤติพงศ์ มุสิกอง ณัฐภาส ผลากอง พาสน์ ปราโมกข์ชน และพยุงศักดิ์ เกษมสำราญ

สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยแม่โจ้ เชียงใหม่ 50290 ประเทศไทย

Panuwat Mekha*, Phoatipong Musikong, Nuttapas Palakong,
Part Pramokchon, and Payungsak Kasemsumran

Department of Computer Science, Faculty of Science, Maejo University,
ChiangMai, 50290, Thailand

* ผู้นิพนธ์ประสานงาน: ภานุวัฒน์ เมฆะ อีเมล : panutwat_m@mju.ac.th

Abstract

This study was to performance comparison of image classification model for corn leaf disease using Microsoft Azure tool to corn leaf disease images classification. The objective of this study was to compare the accuracy of models, size of models, and processing time of models for corn leaf disease image classification : InceptionV3, VGG16, Xception and Custom Vision which used 4 classes of corn leaf disease datasets : Leaf Blight, Corn Rust, Gray Spot Leaf, and Normal for use as a dataset of training datasets in machine learning methods to create the model and use as testing datasets to test the model of corn leaf disease image classification. From the experimental results, were found that the most performance model for corn leaf disease image classification is Custom Vision with the accuracy of model equal 98.1 percent and size of model equal 21.2 megabytes, and processing time of model equal 6.89 seconds.

Keywords : *Corn Leaf disease ; Performance Comparison ; Image Classification Model*

บทคัดย่อ

การวิจัยครั้งนี้ได้ดำเนินการการเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพดที่ใช้เครื่องมือของไมโครซอฟต์อาชัวร์ในการจำแนกประเภทภาพโรคใบข้าวโพด โดยมีวัตถุประสงค์ในการเปรียบเทียบประสิทธิภาพความแม่นยำของโมเดล ขนาดของโมเดล และเวลาที่ใช้ในการประมวลผลของโมเดลในการจำแนกภาพโรคใบข้าวโพด ได้แก่ InceptionV3, VGG16, Xception และ Custom Visionซึ่งใช้ชุดข้อมูลโรคใบข้าวโพด 4 ชนิด ได้แก่ โรคใบไหม้แผลใหญ่ โรคราสนิม โรคใบจุดสีเทา และปกติ สำหรับใช้เป็นข้อมูลชุดเรียนรู้ด้วยวิธีการเรียนรู้ด้วยเครื่องจักรเพื่อสร้างเป็นโมเดลและใช้เป็นข้อมูลชุดทดสอบโมเดลที่สร้างขึ้นในการจำแนกภาพโรคใบข้าวโพด ซึ่งจากผลการทดลองพบว่าโมเดลที่มีประสิทธิภาพในการจำแนกภาพโรคใบข้าวโพดได้ดีที่สุด คือ Custom Vision ด้วยค่าความถูกต้องของโมเดล เท่ากับร้อยละ 98.1 และมีขนาดของโมเดล เท่ากับ 21.2 เมกะไบต์ และเวลาที่ใช้ในการประมวลผลของโมเดล เท่ากับ 6.89 วินาที

คำสำคัญ : *โรคใบข้าวโพด, การเปรียบเทียบประสิทธิภาพ, โมเดลจำแนกภาพ*

1. บทนำ

ข้าวโพดนับเป็นพืชเศรษฐกิจหลักชนิดหนึ่งที่มีความสำคัญต่อประเทศ และเป็นวัตถุดิบที่สำคัญในอุตสาหกรรมอาหารคนและสัตว์ ซึ่งผลผลิตของข้าวโพดสามารถนำไปผลิตและแปรรูปเพื่อใช้อุปโภคและบริโภคภายในประเทศและเป็นสินค้าส่งออกที่สำคัญของประเทศ แต่อย่างไรก็ตามเกษตรกรผู้ปลูกข้าวโพดยังประสบปัญหาด้านการปลูกข้าวโพดที่ได้ผลผลิตที่ต่ำและคุณภาพไม่ดีเท่าที่ควร ซึ่งมีสาเหตุมาจากหลายปัจจัย เช่น พันธุ์ข้าวโพด ภูมิประเทศ ภูมิอากาศ การขาดน้ำ การขาดการบำรุงรักษาดิน แมลงศัตรูพืชและโรคพืช เป็นต้น โดยปัจจัยหลักที่ส่งผลต่อผลผลิตของข้าวโพดคือโรคระบาดของข้าวโพด เนื่องจากโรคระบาดของข้าวโพดมักจะสร้างความเสียหายที่รุนแรงและมีผลกระทบเป็นวงกว้าง หากเกษตรกรผู้ปลูกข้าวโพดไม่มีการตรวจสอบสุขภาพของต้นข้าวโพดที่มีต้นต่อมาจากโรคระบาดจะส่งผลทำให้เกษตรกรเกิดความเสียหายทั้งต้นทุนการผลผลิตและเวลาในการเพาะปลูก แต่ในทางตรงกันข้ามหากเกษตรกรสามารถวินิจฉัยลักษณะของโรคข้าวโพดได้รวดเร็วจะทำให้เกษตรกรสามารถหาทางแก้ไขและป้องกันการระบาดของโรคข้าวโพดได้ ส่งผลดีทำให้การเพาะปลูกข้าวโพดของเกษตรกรจะมีประสิทธิภาพมากขึ้นและสามารถเพิ่มศักยภาพการแข่งขันในอุตสาหกรรมข้าวโพดได้อย่างยั่งยืน

การเรียนรู้เชิงลึก (Deep Learning) เป็นวิธีการเรียนรู้ข้อมูลด้วยเครื่องจักรแบบอัตโนมัติที่เลียนแบบการทำงานของสมองมนุษย์โดยใช้โครงข่ายประสาทเทียมมาซ้อนหลายชั้น (Layer) เพื่อที่จะสามารถจำแนกข้อมูลหรือข้อมูลรูปแบบต่างๆ ได้แก่ ข้อความ รูปภาพ สายพันธุกรรม เป็นต้น (Mekha, P., & Teeyasuksaet, N. (2019)) ได้ ซึ่งเป็นกุญแจสำคัญที่ใช้ในการวิจัยครั้งนี้ ที่เป็นการนำกระบวนการเรียนรู้เชิงลึกมาวิเคราะห์สำหรับจำแนกภาพโรคใบข้าวโพด อีกทั้งในงานวิจัยนี้ได้นำเทคโนโลยีของไมโครซอฟต์เอชัวมาใช้ ซึ่งเป็นหนึ่งผู้ให้บริการทางด้านคลาวด์คอมพิวติ้ง (Cloud computing) สำหรับให้บริการหน่วยประมวลผลข้อมูลและจัดการข้อมูลต่างๆ โดยใช้โมเดลการเรียนรู้เชิงลึกของไมโครซอฟต์เอชัวที่ให้บริการในรูปแบบ Software as a Service (SaaS) สำหรับจำแนกประเภทข้อมูลด้วย Azure Custom Vision API (เอชัว คัสตอม วิชั่น เอพีไอ) ในการสร้างแบบจำลองที่สามารถกำหนดค่าในการเรียนรู้และทดสอบข้อมูลได้ด้วยตนเอง ยกตัวอย่างเช่น งานวิจัยสำหรับจำแนกภาพประเภทใบต้นยางพารา (Khoo, J. J. D., Lim, K. H., Nistah, N. N. M., & Basuki, T. A. (2021))

ดังนั้นคณะผู้วิจัยจึงมีแนวคิดที่จะพัฒนาการเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพด เพื่อช่วยให้เกษตรกรผู้ปลูกข้าวโพดสามารถวินิจฉัยลักษณะของโรคข้าวโพดชนิดต่างๆ ได้ อีกทั้งเพื่อป้องกันและแก้ไขปัญหาการระบาดของโรคข้าวโพดได้อย่างทันท่วงที โดยโรคระบาดของข้าวโพดที่พบส่วนใหญ่จะแสดงออกทางใบข้าวโพด และโรคใบข้าวโพดแต่ละชนิดจะมีความแตกต่างกัน เช่น ลักษณะอาการ เชื้อสาเหตุ การแพร่ระบาด การป้องกันและกำจัด เป็นต้น ที่ส่งผลกระทบโดยตรงต่อสุขภาพและคุณภาพผลผลิตของต้นข้าวโพด

2. วัตถุประสงค์

2.1 เพื่อพัฒนาโมเดลการจำแนกภาพสำหรับโรคใบข้าวโพดด้วยเทคโนโลยีไมโครซอฟต์เอชัวบนพื้นฐานการเรียนรู้เชิงลึก

2.2 เพื่อเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพดสำหรับช่วยให้เกษตรกรผู้ปลูกข้าวโพดสามารถวิเคราะห์และจำแนกระดับโรคข้าวโพดแต่ละชนิดได้

3. ข้อมูลและวิธีการดำเนินงาน

3.1 ชุดข้อมูล (Dataset)

ชุดข้อมูลที่ใช้ในการเรียนรู้ลักษณะของภาพโรคใบข้าวโพดทั้งหมด 4 ประเภทนี้ เป็นภาพโรคใบข้าวโพดที่มีคุณลักษณะจำเพาะและมีลักษณะที่คล้ายกันในกลุ่มของโรคใบความโพดแต่ละประเภท ดังนั้น

จึงสามารถนำชุดข้อมูลจากเว็บไซต์ https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset?resource=download นี้เป็นตัวแทนในการศึกษาโรคใบข้าวโพดที่ค่อนข้างมีผลกระทบต่อการระบาดทั้งในประเทศและต่างประเทศ ซึ่งมีการระบาดอย่างสม่ำเสมอทุกปีและระบาดเพิ่มมากขึ้นในหลายพื้นที่ โดยส่วนใหญ่จะพบว่ามีความรุนแรงกับข้าวโพดสายพันธุ์แท้ (Inbred line) หรือบางสายพันธุ์ รวมถึงข้าวโพดหวาน ข้าวโพดเทียน ข้าวโพดข้าวเหนียว เป็นต้น โดยงานวิจัยนี้มีรายละเอียดของจำนวนภาพโรคใบข้าวโพดแต่ละประเภท ดังนี้

- โรคใบไหม้แผลใหญ่ จำนวน 1,146 ภาพ
- โรคราสนิม จำนวน 1,306 ภาพ
- โรคใบจุดสีเทา จำนวน 574 ภาพ
- ปกติ จำนวน 1,162 ภาพ

3.2 ลักษณะของโรคใบข้าวโพดแต่ละประเภท

- โรคใบไหม้แผลใหญ่

เชื้อสาเหตุ : เชื้อรา Exserohilum turcicum

อาการ : อาการเริ่มแรกพบแผลขนาดเล็กสีคล้ายฟางข้าวบนใบข้าวโพด ต่อมาแผลจะขยายมีขนาดใหญ่สีเทาหรือสีน้ำตาลอ่อนยาวตามใบข้าวโพดหัวท้ายเรียวคล้ายรูปกระสวย เมื่อสภาพแวดล้อมเหมาะสม จะพบอาการแผลบนใบข้าวโพดหลายแผลต่อใบและแผลขยายรวมกันมาก ๆ ทำให้ใบข้าวโพดแห้งตาย สามารถพบอาการของแผลได้บนกาบฝัก ข้าวโพดที่เป็นโรครุนแรงจะทำให้ฝักไม่สมบูรณ์ (ข้อมูลจาก https://www.kubotasolutions.com/knowledge/corn/detail/321)

รูปที่ 1 โรคใบไหม้แผลใหญ่

- โรคราสนิม

เชื้อสาเหตุ : เชื้อรา Puccinia polysora

อาการ : ใบข้าวโพดจะเกิดเป็นจุดนูนทั้งด้านบนใบและใต้ใบ แต่จะพบด้านบนมากกว่าด้านใต้ใบ ระยะแรกจุดนูนจะมีสีน้ำตาลอ่อน ต่อมาเปลี่ยนเป็นสีน้ำตาลแดงเมื่อจุดนูนแตกมีผงสีคล้ายสนิม อาการของโรคจะพบได้แทบทุกส่วนของข้าวโพด คือ ใบ ลำต้น กาบใบ กาบฝัก (ข้อมูลจาก https://www.kubotasolutions.com/knowledge/corn/detail/321)

รูปที่ 2 โรคราสนิม

- โรคใบจุดสีเทา

เชื้อสาเหตุ : เชื้อรา Cercospora zeae-maydis

อาการ : อาการเริ่มแรกจะพบจุดเนื้อตายขนาดเล็กที่ใบข้าวโพด และจะขยายรัศมีกลายเป็นแผลรูปสี่เหลี่ยมผืนผ้ากว้างประมาณ 1/8 นิ้ว และยาวประมาณ 2-3 นิ้ว โดยมีลักษณะเป็นสีเทาถึงน้ำตาล รอยโรคมักจะมีขอบขนานที่ชัดเจนและดูทึบเมื่อส่องกับแสง แต่รอยโรคลูกผสมจะมีรูปร่างและสีแตกต่างกันมาก อาการอาจคล้ายกับโรคใบไหม้แผลใหญ่ (ข้อมูลจาก https://extension.umn.edu/corn-pest-management/gray-leaf-spot-corn)

รูปที่ 3 โรคใบจุดสีเทา

- ปกติ

ลักษณะ : ใบข้าวโพดจะมีสีเขียว โดยลักษณะของใบจะหนาและเรียบ ไม่มีรอยของโรคต่างๆ รวมถึงใบและลำต้นของข้าวโพดจะมีความสมบูรณ์

รูปที่ 4 ปกติ

3.3 โมเดลที่ใช้ในการจำแนกโรคใบข้าวโพด

- **Custom Vision**

เป็นบริการของไมโครซอฟต์เอซัว (Microsoft Azure) ที่ใช้ปัญญาประดิษฐ์ในการเรียนรู้สำหรับสร้างโมเดลในการจำแนกรูปภาพ โดยสามารถนำออกโมเดล (Export Model) ได้หลายรูปแบบ เช่น TensorFlow, CoreML, ONNX, Dockerfile, VAIDK, OpenVino เป็นต้น ซึ่งหลักการของ Custom Vison จะใช้ ResNet หรือ Residual Network เป็น Deep Convolutional Neural Networks ที่ทางไมโครซอฟต์เผยแผ่ออกสู่สาธารณชนตั้งแต่ปี 2015 และเป็นทางการในปี 2016 ที่มีการพัฒนา ResNet เพื่อปรับเพิ่มประสิทธิภาพและลดระดับของเครือข่ายที่ลึกกว่าโดยการข้ามเลเยอร์ (Layer) บางชั้นไปโดยใช้กระบวนการข้ามตัวเชื่อมต่อหรือบล็อกที่เหลือ จึงส่งผลทำให้ ResNet มีประสิทธิภาพในการจำแนกข้อมูลได้ดีขึ้นและรวดเร็วมากขึ้น ดังรูปที่ 5

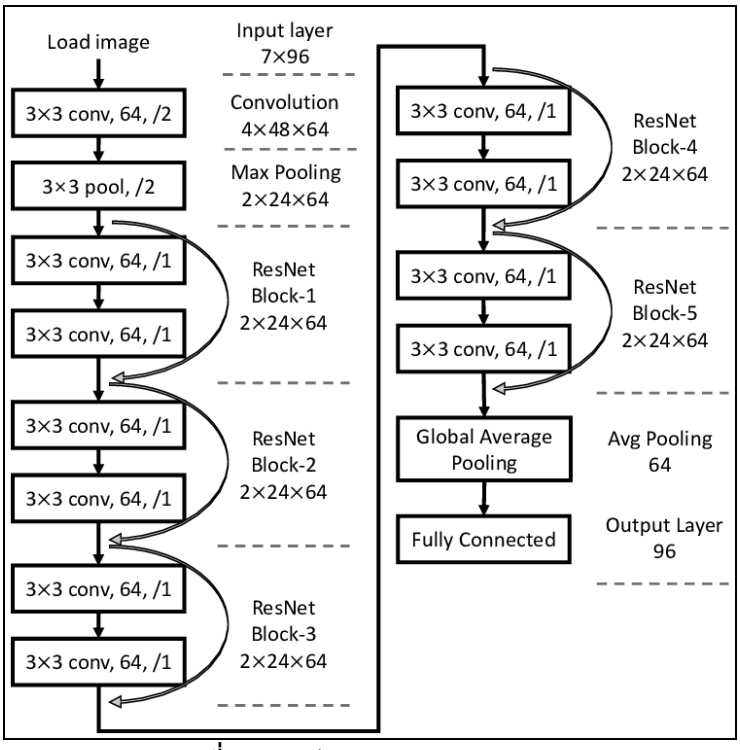

รูปที่ 5 สถาปัตยกรรมแบบ ResNet

ขั้นตอนในการสร้างโมเดลจำแนกโรคใบข้าวโพดด้วย Custom Vision

1. เข้าเว็บไซต์ https://www.customvision.ai
2. ลงทะเบียนและเข้าสู่ระบบ
3. ทำการกดที่ปุ่ม New Project
4. ตั้งค่าโปรเจค
   - 4.1. Project Types เลือก Classification
   - 4.2. Domains เลือก General (compact) [S1]
   - 4.3. Classification Types เลือก Multiclass (Single tag per image)
   - 4.4. Export Capabilities เลือก Basic platforms

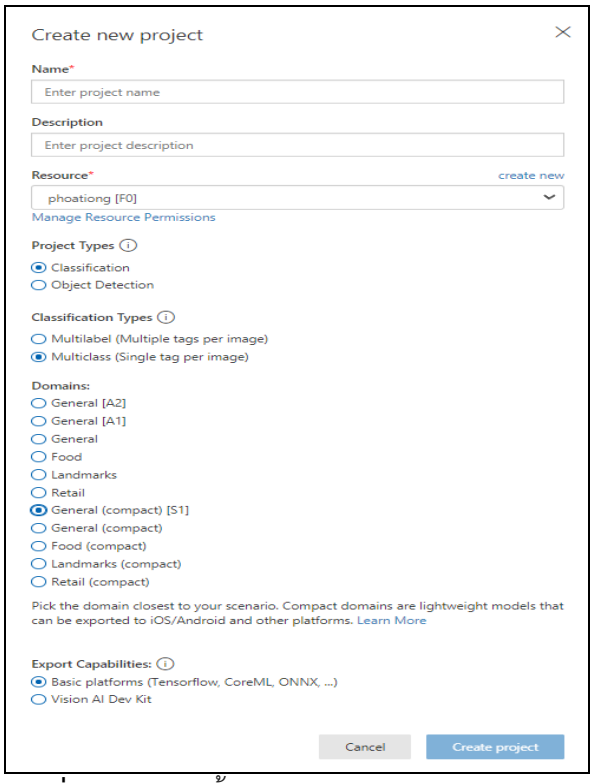

รูปที่ 6 แสดงการตั้งค่าโปรเจคบน Custom Vision

5. ดำเนินการเพิ่ม Tags โดยการกดเครื่องหมายบวก (+) และทำการตั้งชื่อ Tags ตามประเภทโรคใบข้าวโพด จากนั้นกดปุ่ม Save ทำซ้ำขั้นตอนเดิม จนได้ Tags ตามจำนวนประเภทโรคใบข้าวโพด

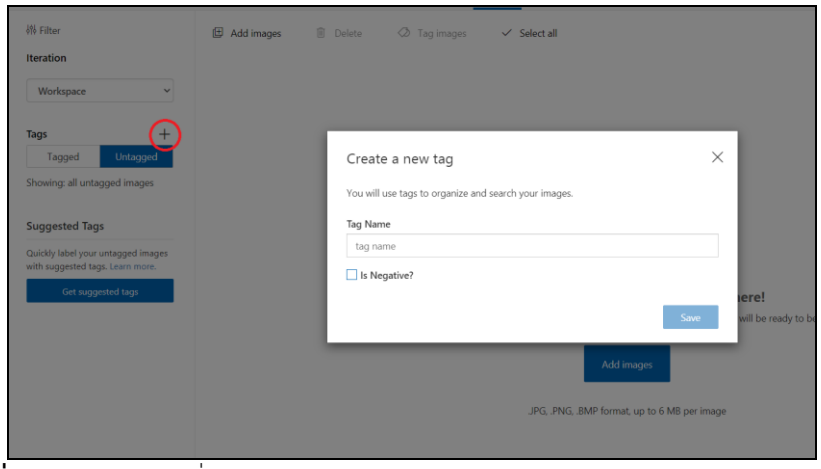

รูปที่ 7 แสดงวิธีการเพิ่ม Tags ตามประเภทโรคใบข้าวโพดบน Custom Vision

6. กดปุ่ม Images upload เพื่อเพิ่มรูปภาพโรคใบข้าวโพดแต่ละประเภท ตาม Tags ที่กำหนดไว้ สำหรับใช้ในการเรียนรู้ของเครื่อง

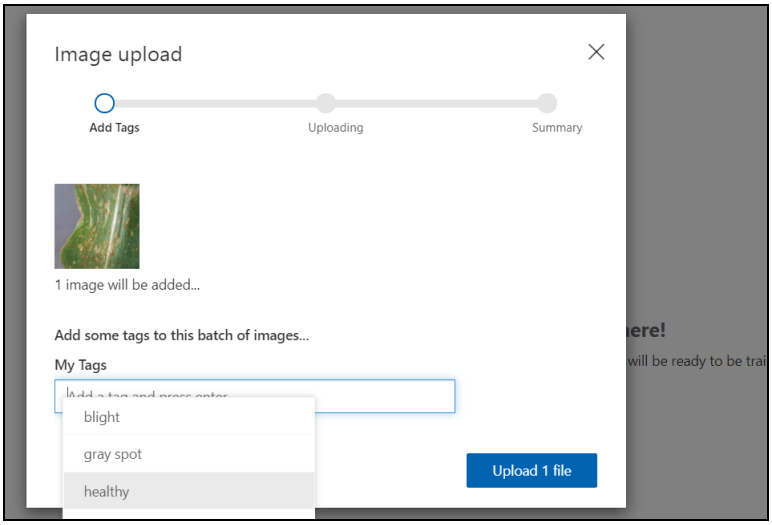

รูปที่ 8 แสดงวิธีการ Upload รูปภาพและติด Tag ให้รูปภาพบน Custom Vision

7. จากนั้นดำเนินการเลือกรูปแบบการเรียนรู้ (Training Type) โดยเลือกแบบ Advanced Training เลือกระยะเวลาที่ต้องการเรียนรู้ และกดปุ่ม Train

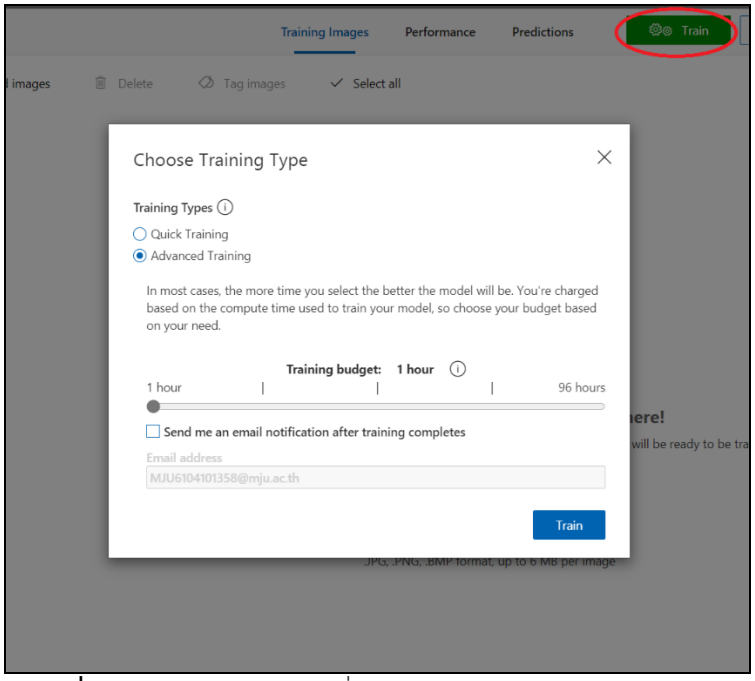

รูปที่ 9 แสดงวิธีการเรียนรู้เพื่อสร้างโมเดลบน Custom Vision

8. เมื่อดำเนินการเรียนรู้เพื่อสร้างโมเดลเสร็จแล้ว จึงเลือกแฟลตฟอร์ม (Platform) สำหรับในนำออกโมเดล ซึ่งในงานวิจัยนี้เลือกเป็น TensorFlow.js จากนั้นกดปุ่ม Download

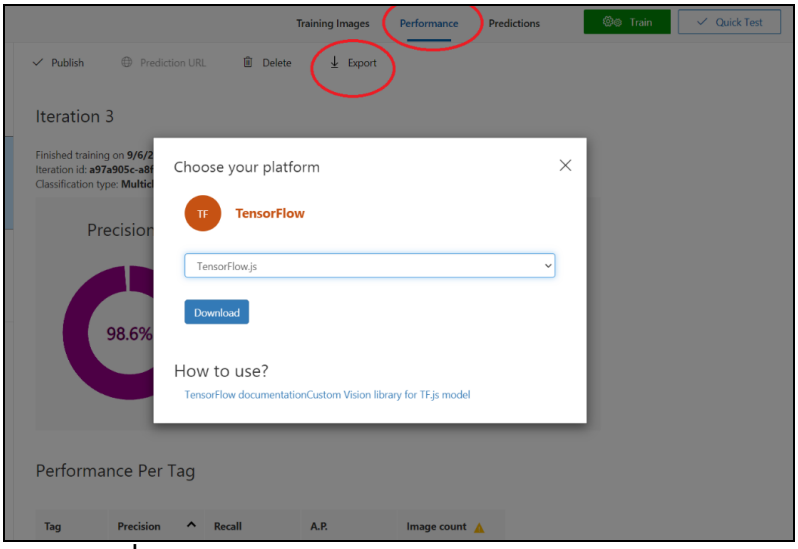

รูปที่ 10 แสดงวิธีการนำออกโมเดลจาก Custom Vision

3.4 การเปรียบเทียบประสิทธิภาพการจำแนกใบข้าวโพดกับโมเดลอื่น

คณะผู้วิจัยมีการพัฒนาโมเดลโดยการใช้เทคนิค Transfer Learning เพื่อช่วยลดเวลาในการเรียนรู้โมเดลของการเรียนรู้เชิงลึก โดยการนำโค้ดบางส่วนของโมเดลที่เรียนรู้เรียบร้อยแล้ว ซึ่งจะเรียกส่วนนี้ว่า Body มาใช้เป็นส่วนหนึ่งของโมเดลใหม่ โดยการตัดส่วนต้นของโค้ดออก (Head) และนำส่วน Head ที่สร้างใหม่มาแทนที่

- **เกณฑ์สำหรับเปรียบเทียบประสิทธิภาพการจำแนกใบข้าวโพดกับโมเดลอื่น มีดังนี้**

1. ชุดข้อมูลเรียนรู้ด้วยวิธีการเรียนรู้ด้วยเครื่องจักรเพื่อสร้างเป็นโมเดลและชุดข้อมูลทดสอบโมเดล

1.1 ชุดข้อมูลสำหรับเรียนรู้ (Training data set) 80%

1.2 ชุดข้อมูลสำหรับทดสอบ (Testing data set) 20%

2. ใช้เทคนิค Transfer Learning โดยใช้โมเดลที่นำมาเปรียบเทียบ ได้แก่ Custom Vision, InceptionV3, VGG16 และ Xception โดยแต่ละโมเดลจะมีค่าของพารามิเตอร์ต่างๆ ที่ใช้แสดงโครงสร้างของโมเดล ได้แก่ InputLayer, Functional, Flatten, Dense, Dropout เป็นต้น

3. วัดประสิทธิภาพของโมเดลที่ใช้จำแนกประเภทของโรคใบข้าวโพด ได้แก่

3.1 $$Precision = \frac{\sum_{c \subseteq C} TP_c}{\sum_{c \subseteq C}(TP_c + FP_c)} \quad (1)$$

3.2 $$Recall = \frac{\sum_{c \subseteq C} TP_c}{\sum_{c \subseteq C}(TP_c + FN_c)} \quad (2)$$

โดย c, C, TP, FP และ FN คือ ประเภทโรคใบข้าวโพดแต่ละชนิด, ประเภทโรคใบข้าวโพดทั้งหมด, True Positive, False Negative ตามลำดับ

3.3 $$F_1 = \frac{2\ x\ Precision\ x\ Recall}{Precision + Recall} \quad (3)$$

4. เปรียบเทียบ ขนาดโมเดล และความเร็วในการประมวลผลบน Node.js (Cloud function CPU 1.4 GHz Ram 1 GB)

4. ผลการทดลอง

การวัดประสิทธิภาพของโมเดลในการจำแนกภาพโรคใบข้าวโพด ทางคณะผู้วิจัยใช้ 10-fold cross validation ในการแบ่งข้อมูลเป็น 10 ส่วนเท่าๆ กันเพื่อสร้างและทดสอบโมเดล ซึ่งในงานวิจัยนี้จะดำเนินการวัดประสิทธิภาพของแต่ละโมเดลจากค่าความถูกต้อง (Accuracy) จากสมการข้อ 1-3 รวมถึงขนาด และความเร็วในการประมวลผลของแต่ละโมเดล ดังนี้

ตารางที่ 1 แสดงประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของโมเดล Custom Vision

Model : Custom Vision			
Classes	Precision	Recall	F1-score
โรคใบไหม้แผลใหญ่	0.978	0.974	0.976
โรคราสนิม	0.992	0.992	0.992
โรคใบจุดสีเทา	0.957	0.957	0.957
ปกติ	1.000	1.000	1.000
Average	0.981	0.980	0.981

ตารางที่ 2 แสดงประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของโมเดล InceptionV3

Model : InceptionV3			
Classes	Precision	Recall	F1-score
โรคใบไหม้แผลใหญ่	0.932	0.932	0.932
โรคราสนิม	1.000	0.964	0.982
โรคใบจุดสีเทา	0.884	0.900	0.871
ปกติ	1.000	1.000	1.000
Average	0.944	0.949	0.946

ตารางที่ 3 แสดงประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของโมเดล VGG16

Model : VGG16			
Classes	Precision	Recall	F1-score
โรคใบไหม้แผลใหญ่	0.917	1.000	0.957
โรคราสนิม	1.000	0.964	0.982
โรคใบจุดสีเทา	0.964	0.900	0.931
ปกติ	1.000	1.000	1.000
Average	0.970	0.966	0.967

ตารางที่ 4 แสดงประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของโมเดล Xception

Model : Xception			
Classes	Precision	Recall	F1-score
โรคใบไหม้แผลใหญ่	0.815	1.000	0.898
โรคราสนิม	0.982	0.982	0.982
โรคใบจุดสีเทา	1.000	0.667	0.800
ปกติ	1.000	1.000	1.000
Average	0.949	0.912	0.920

ตารางที่ 5 แสดงการเปรียบเทียบประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของแต่ละโมเดล

Classes	Model / F1-score			
	InceptionV3	VGG16	Xception	Custom Vision
โรคใบไหม้แผลใหญ่	0.932	0.957	0.898	0.976
โรคราสนิม	0.982	0.982	0.982	0.992
โรคใบจุดสีเทา	0.871	0.931	0.800	0.957
ปกติ	1.000	1.000	1.000	1.000
Average	0.949	0.912	0.920	0.981

ตารางที่ 6 แสดงการเปรียบเทียบประสิทธิภาพการจำแนกภาพโรคใบข้าวโพดของแต่ละโมเดล โดยพิจารณาจากขนาดและเวลาการประมวลผลของโมเดลบน Node.js (Cloud Function)

โมเดล	**ขนาด (MB)**	**ความเร็ว (วินาที)**
InceptionV3	133.0	9.294
VGG16	80.6	9.163
Xception	177.3	16.579
Custom Vision	21.2	6.890

6. สรุปผลและอภิปรายผล

จากผลการทดลองของการเปรียบเทียบประสิทธิภาพของโมเดลจำแนกภาพสำหรับโรคใบข้าวโพด จะเห็นได้ว่า โมเดลที่มีประสิทธิภาพในการจำแนกภาพโรคใบข้าวโพดได้ดีที่สุด คือ Custom Vision ซึ่งมีค่าความถูกต้องของโมเดล เท่ากับร้อยละ 98.1 และมีขนาดของโมเดล เล็กที่สุด เท่ากับ 21.2 เมกะไบต์ และเวลาที่ใช้ในการประมวลผลของโมเดล เร็วที่สุด เท่ากับ 6.89 วินาที โดยโมเดลที่มีประสิทธิภาพลำดับที่ 2 คือ InceptionV3 ซึ่งมีค่าความถูกต้องของโมเดล เท่ากับร้อยละ 94.9 แต่มีขนาดของโมเดลค่อนข้างใหญ่ เท่ากับ 133 เมกะไบต์ และเวลาที่ใช้ในการประมวลผลของโมเดล เท่ากับ 9.294 วินาที ส่วนโมเดลที่มีประสิทธิภาพลำดับที่ 3 คือ Xception ซึ่งมีค่าความถูกต้องของโมเดล เท่ากับร้อยละ 92.0 แต่มีขนาดของโมเดล ใหญ่ที่สุด เท่ากับ 177.3 เมกะไบต์ และเวลาที่ใช้ในการประมวลผลของโมเดล ช้าที่สุด เท่ากับ 16.579 วินาที ส่วนโมเดลที่มีประสิทธิภาพลำดับที่ 4 คือ VGG16 ซึ่งมีค่าความ

ถูกต้องของโมเดล เท่ากับร้อยละ 91.2 แต่มีขนาดของโมเดล เท่ากับ 80.6 เมกะไบต์ และเวลาที่ใช้ในการประมวลผลของโมเดล เท่ากับ 9.163 วินาที ดังนั้นจึงสรุปได้ว่าโมเดลที่มีประสิทธิภาพในการจำแนกภาพโรคใบข้าวโพดได้ดีที่สุด คือ Custom Vision ที่ได้ค่า F1-score จากผลเฉลี่ยของ Precision กับ Recall สูงที่สุด อีกทั้งโมเดลมีขนาดเล็กที่สุดจึงส่งผลทำให้เวลาในการประมวลผลน้อยที่สุดเช่นกัน และจากผลลัพธ์ของงานวิจัยทั้งหมดนี้จะเห็นได้ Custom Vision เป็นโมเดลที่ถูกพัฒนาขึ้นเพื่อลดความซับซ้อนของระดับชั้น (Layer) ของรูปภาพลงจึงทำให้การประมวลผลได้เร็วและโมเดลมีขนาดเล็ก รวมถึง Custom Vision มีฟังก์ชันในการเพิ่มภาพที่ไม่ได้เกี่ยวข้องกับชุดข้อมูล (Negative images) เข้าไปได้เพื่อเพิ่มประสิทธิภาพให้กับโมเดลสามารถจำแนกภาพโรคใบข้าวโพดได้ดีขึ้น

7. กิตติกรรมประกาศ

ขอขอบคุณสาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยแม่โจ้ และศูนย์วิจัยและพัฒนาเมล็ดพันธุ์พืชเชียงใหม่ ที่ให้การสนับสนุนสถานที่ทำงานวิจัยและให้ความรู้คำแนะนำเกี่ยวกับโรคใบข้าวโพด

8. เอกสารอางอิง

Codebasics. **Image classification using CNN (CIFAR10 dataset) | Deep Learning Tutorial 24 (TensorFlow & Python)**. [ระบบออนไลน์]
แหล่งที่มา https://www.youtube.com/watch?v=7HPwo4wnJeA

J, ARUN PANDIAN, GOPAL, GEETHARAMANI (2019). **Data for: Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network**. Mendeley Data, V1, doi: 10.17632/tywbtsjrjv.1

Keng Surapong. **Transfer Learning คืออะไร สอน Transfer Learning จากโมเดล MobileNet JSON ไป Retrain เทรนต่อ ภาพจากกล้อง Webcam ด้วย TensorFlow.js – tfjs ep.10**. [ระบบออนไลน์]
แหล่งที่มา https://www.bualabs.com/archives/3493/what-is-transfer-learning-build-headless-mobilenet-model-transfer-learning-machine-learning-mobilenet-json-retrain-webcam-tensorflow-js-tfjs-ep-10/

Khoo, J. J. D., Lim, K. H., Nistah, N. N. M., & Basuki, T. A. (2021, July). **Deep Learning Mobile App Based Microscopic Leaf Imaging Disease Classification with Azure Cloud Computing Service**. In 2021 International Conference on Green Energy, Computing and Sustainable Technology (GECOST) (pp. 1-6). IEEE.

Kumar, A., & Vani, M. (2019, July). **Image based tomato leaf disease detection.** In 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT) (pp. 1-6). IEEE.

Mekha, P., & Teeyasuksaet, N. (2019, January). **Deep learning algorithms for predicting breast cancer based on tumor cells.** In 2019 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT-NCON) (pp. 343-346). IEEE.

Mekha, P., & Teeyasuksaet, N. (2021, March). **Image classification of rice leaf diseases using random forest algorithm.** In 2021 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunication Engineering (pp. 165-169). IEEE.

Natthawat Phongchit. **มาทำความรู้จัก ResNet กันดีกว่า.** [ระบบออนไลน์]
แหล่งที่มา https://medium.com/@natthawatphongchit/มาทำความรู้จัก-resnet-aec3a8c10793

Piyanop Nuchanat. **13. Transfer learning รีดความสามารถของ convolutional neural network แยกหมา แยกแมว คลิปเดียวทำเป็นเลย.** [ระบบออนไลน์]
แหล่งที่มา https://www.youtube.com/watch?v=SEbWKEwl7K0&t=1055s

Sascha Dittmann. **TensorFlow.js Image Classification Made Easy**. [ระบบออนไลน์]
แหล่งที่มา https://www.youtube.com/watch?v=WFUL_oRT3nk&list=PLxs8gLPfkmIJ7_43O0z2XXk_05uqFWZ95

Singh D, Jain N, Jain P, Kayal P, Kumawat S, Batra N. **PlantDoc: a dataset for visual plant disease detection.** InProceedings of the 7th ACM IKDD CoDS and 25th COMAD 2020 Jan 5 (pp. 249-253).

Smaranjit Ghose. **Corn or Maize Leaf Disease Dataset.** [ระบบออนไลน์]
แหล่งที่มา https://www.kaggle.com/smaranjitghose/corn-or-maize-leaf-disease-dataset