




การคัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่อง  
CLASSIFICATION OF THAI MANGOES USING MACHINE LEARNING TECHNIQUES



เมธากาญจน์ ใจตระกูล

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2565

การตัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่อง



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ  
ปีการศึกษา 2565  
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

CLASSIFICATION OF THAI MANGOES USING MACHINE LEARNING TECHNIQUES



METHAKAN NGOTRAKUN

A Master's Project Submitted in Partial Fulfillment of the Requirements

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2022

Copyright of Srinakharinwirot University

สารนิพนธ์  
เรื่อง  
การคัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่อง  
ของ  
เมธากาญจน์ ใจตระกูล

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)  
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก  
(อาจารย์ ดร. เรืองศักดิ์ ตระกูลพุทธวิเศษ)

..... ประธาน  
(ผู้ช่วยศาสตราจารย์ ดร. รัตน์ชัยนันท์ ธรรมสุขจิต)

..... กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร. ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การคัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่อง
ผู้วิจัย	เมธากาญจน์ ใจตระกูล
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2565
อาจารย์ที่ปรึกษา	อาจารย์ ดร. เรืองศักดิ์ ตระกูลพุทธิรักษ์

งานวิจัยฉบับนี้มีวัตถุประสงค์เพื่อสร้างแบบจำลองการคัดแยกสายพันธุ์มะม่วงของไทยโดยใช้เทคนิคการเรียนรู้ของเครื่อง โดยใช้แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer Learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) เพื่อสร้างแบบจำลอง โดยมีการนำอัลกอริทึม Root Mean Square Propagation (RMSProp) และ Adaptive Moment Estimation (Adam) เข้ามาเพิ่มประสิทธิภาพในการเรียนรู้ของโมเดล ซึ่งชุดข้อมูลที่ใช้ประกอบด้วยภาพถ่ายมะม่วง 4 สายพันธุ์ ได้แก่ มะม่วงแก้วขมิ้น, มะม่วงเขียวเสวย, มะม่วงน้ำดอกไม้, และมะม่วงน้ำดอกไม้สีทอง รวมทั้งนำภาพมะม่วงจากต่างประเทศมาทำการทดลองในงานวิจัย ซึ่งประกอบไปด้วยจำนวนภาพมะม่วงของไทยทั้งหมด 492 ภาพ และมะม่วงสายพันธุ์ต่างประเทศจำนวน 123 ภาพ ผู้วิจัยได้เพิ่มการทดลองโมเดลด้วยการนำเทคนิคในการปรับเสริมของภาพมาใช้ร่วมกับการเรียนรู้ของโมเดล และได้เปรียบเทียบการเรียนรู้ของอัลกอริทึมของทั้งสองอัลกอริทึม ดังนั้นผู้วิจัยกำหนดให้มีการวัดค่าความถูกต้องและความแม่นยำในการจำแนกข้อมูลจาก 5 วิธีประกอบด้วยค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision), ค่าความถูกต้องของการทำนายว่าเป็นจริง (Recall) และค่าเฉลี่ยที่วัดความสามารถของแบบจำลอง (F1-Score Macro Average) และพื้นที่ใต้โค้ง (ROC) หลังจากทำการหาค่าพารามิเตอร์ที่ดีที่สุดแล้ว แม้ว่ามาจากผลการทดลองซึ่งว่าประสิทธิภาพการทำนายมีความใกล้เคียงกัน แต่แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer Learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) จากการใช้อัลกอริทึม RMSProp ดีกว่าการใช้อัลกอริทึม Adam และดีกว่าการใช้แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ที่มีการใช้อัลกอริทึม Adam ซึ่งสามารถแสดงค่าความถูกต้องในการจำแนกสายพันธุ์มะม่วงมะม่วงของไทยได้ดีกว่าร้อยละ 96

คำสำคัญ : การรู้จำของภาพ, การจัดกลุ่มของข้อมูล, การสกัดคุณลักษณะของภาพ, การเรียนรู้ของเครื่อง

Title	CLASSIFICATION OF THAI MANGOES USING MACHINE LEARNING TECHNIQUES
Author	METHAKAN NGOTRAKUN
Degree	MASTER OF SCIENCE
Academic Year	2022
Thesis Advisor	Dr. Ruangsak Trakunphutthirak

The purpose of this research is to develop a model for classifying Thai mangoes using machine learning techniques, including Convolutional Neural Network (CNN) and Transfer Learning with Visual Geometry Group (VGG16), and algorithms such as Root Mean Square Propagation (RMSProp) and Adaptive Moment Estimation (Adam) to enhance the learning performance of the model. The dataset contained 492 Thai mango images representing four varieties: Keawkramin, Khiao Sa-woey, Nam Dok Mai, and Nam Dok Mai-Srithong. In addition, this study also included 123 foreign mango images in the experiment. Additionally, the researchers applied image enhancement techniques to create the model and compared the learning performance of both algorithms. The accuracy and precision of the model were evaluated using five methods: Accuracy, Precision, Recall, and F1-Score Macro Average, as well as the Receiver Operating Characteristic (ROC). The experimental results revealed a similar prediction performance between the models. The prediction model used the VGG transfer learning technique was pre-trained with the RMSProp algorithm performed better than the prediction model, which used the Adam algorithm and the CNN model, which also employed the Adam algorithm. The VGG transfers learning model achieved an accuracy over 96% in classifying each Thai mango.

Keyword : Deep learning, Feature Extraction, Image Classification, Convolutional Neural Network, Transfer learning

## กิตติกรรมประกาศ

สารนิพนธ์สำเร็จลุล่วงได้ด้วยความสะดวกตากรุณาช่วยเหลือ และความเอาใจใส่อย่างดียิ่งตลอดจน การให้คำแนะนำ และข้อคิดเห็นที่เป็นประโยชน์อย่างยิ่งสำหรับการปรับแก้ไขข้อบกพร่องจากคณะกรรมการ ผู้ควบคุมสารนิพนธ์ ผู้วิจัยขอกราบขอบพระคุณ

อาจารย์เรืองศักดิ์ ตระกูลพุทธิรักษ์ ที่ให้ความเมตตากรุณาเป็นที่ปรึกษาและให้ความช่วยเหลือชี้ แนวทางในสิ่งที่เป็นประโยชน์ต่อการศึกษาและการทำสารนิพนธ์ด้วยความเอาใจใส่ตลอดมา รวมทั้ง ผู้ช่วย ศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ ที่กรุณาให้ข้อเสนอแนะต่างๆเพิ่มเติมแก่ผู้วิจัย ทำให้สารนิพนธ์ ฉบับนี้มีความสมบูรณ์ยิ่งขึ้น ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ขอกราบขอบพระคุณคณาจารย์และกรรมการบริหารหลักสูตรสาขาวิทยาการข้อมูล คณะ วิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒทุกท่าน ที่ได้กรุณาประสิทธิ์ประสาทความรู้ต่างๆ ให้แก่ผู้วิจัย ตลอดจนให้ความช่วยเหลือในการทำวิจัยในครั้งนี้

ขอขอบคุณนางสาวปรียาพัทตร์ สมวิฑูร ที่เป็นที่ปรึกษาและให้คำแนะนำที่ดีเสมอมาตลอดการทำ วิจัยในครั้งนี้

ขอขอบคุณพี่ๆ และเพื่อนๆ สาขาวิชาวิทยาการข้อมูล คณะวิทยาศาสตร์ รวมทั้งบุคคลอีกหลาย ท่านที่ไม่ได้กล่าวนามไว้ ณ ที่นี้ได้ให้ความช่วยเหลือและเป็นกำลังใจให้กับผู้วิจัยมาโดยตลอด

สุดท้ายนี้ ผู้วิจัยขออน้อมรำลึกคุณบิดามารดาและครูอาจารย์ ที่อบรมสั่งสอนให้ความรู้เป็น กำลังใจและให้การสนับสนุนผู้วิจัยด้วยดีตลอดมา

เมธากาญจน์ ใจตระกูล

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ .....	ฎ
บทที่ 1 บทนำ.....	1
1. ภูมิหลัง.....	1
2. ความมุ่งหมายของงานวิจัย .....	3
3. ความสำคัญของการวิจัย.....	3
4. ขอบเขตของการวิจัย.....	4
5. นิยามศัพท์เฉพาะ.....	4
6. กรอบแนวคิดในงานวิจัย .....	5
7. สมมุติฐานในการวิจัย .....	6
8. ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย .....	6
บทที่ 2 ทบทวนวรรณกรรม .....	1
1. ทฤษฎีที่เกี่ยวข้องกับงานวิจัย.....	1
1.1 แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN).....	2
1.2 แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer Learning) .....	4
1.3 อัลกอริทึมในการเพิ่มประสิทธิภาพของแบบจำลอง (Optimizer Algorithm) .....	6



1.3.1 อัลกอริทึม Root Mean Square Propagation.....	6
1.3.2 อัลกอริทึม Adaptive Moment Estimation .....	7
1.4 เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย (Confusion Matrix) .....	8
1.4.1 ความถูกต้องที่ผลลัพธ์ของแบบจำลองได้ตรงกับสิ่งที่เกิดขึ้นจริง (Accuracy) 9	
1.4.2 ค่าความแม่นยำ (Precision).....	9
1.4.3 ความถูกต้องของผลลัพธ์ของแบบจำลองที่ทำนาย (Recall) .....	9
1.4.4 ค่าเฉลี่ยในการวัดความสามารถของแบบจำลอง (F1 Score) .....	9
1.5 กราฟแสดงประสิทธิภาพของการทำนายแบบจำลอง (Receiver Operating Characteristic Curve: ROC) .....	10
2. งานวิจัยที่เกี่ยวข้อง .....	11
2.1 บทความวิจัยเรื่อง Mango Classification System Uses Image Processing Technology and Artificial Intelligence .....	11
2.2 บทความวิจัยเรื่อง Classification of Fruits using Convolutional Neural Networks .....	11
2.3 บทความวิจัยเรื่อง Detecting Mango Fruits by using Randomized Hough Transform and Backpropagation Neural Network.....	12
2.4 บทความวิจัยเรื่อง Classification and Grading of Harvested Mangoes Using Convolutional Neural Network.....	12
2.5 บทความวิจัยเรื่อง Pure-CNN: A Framework for Fruit Images Classification.....	12
2.6 บทความวิจัยเรื่อง Optimizing Convolutional Neural Network Performance by Mitigating Underfitting and Overfitting .....	13
2.7 บทความวิจัยเรื่อง Fruit Recognition and Classification with Deep Learning Support on Embedded System (Fruitnet) .....	13

2.8 บทความวิจัยเรื่อง Deep Convolutional Neural Networks for plane identification on Satellite imagery by exploiting transfer learning with a different optimizer .....	14
2.9 บทความวิจัยเรื่อง Comprehensive Study for Diabetes Identification Ability of Various Optimizers in Deep Learning Neural Network.....	14
2.10 บทความวิจัยเรื่อง Images Classification Modelling of Beef and Pork Using Convolutional Neural Network.....	15
2.11 บทความวิจัยเรื่อง IMPROVING DEEP NEURAL NETWORKS BY USING SPARSE DROPOUT STRATEGY .....	15
2.12 บทความวิจัยเรื่อง Transfer learning considering the impact of data augmentation on each layer of the source model.....	15
บทที่ 3 วิธีการดำเนินการวิจัย .....	17
1. กระบวนการในการสร้างแบบจำลอง.....	17
2. การสำรวจข้อมูล (Exploratory Data Analysis: EDA) .....	18
3. การเตรียมข้อมูล (Data Preprocessing).....	20
4. การเสริมข้อมูล (Data Augmentation).....	20
5. การสร้างแบบจำลอง (Model Creation).....	22
บทที่ 4 การทดลอง .....	25
บทที่ 5 สรุปผลการทดลอง.....	33
1. สรุปผลการวิจัย .....	33
2. ข้อเสนอแนะ .....	35
ภาคผนวก.....	36
บรรณานุกรม .....	42
ประวัติผู้เขียน.....	46

## สารบัญตาราง

	หน้า
ตาราง 1 ตลาดส่งออก 5 อันดับแรกของไทยรายสินค้า สินค้ามะม่วงกระป๋อง .....	1
ตาราง 2 ลักษณะของมะม่วงทั้ง 4 สายพันธุ์ของไทย .....	2
ตาราง 3 จำนวนข้อมูลภาพมะม่วงทั้ง 4 สายพันธุ์ของไทย และมะม่วงพันธุ์ต่างประเทศ .....	18
ตาราง 4 พารามิเตอร์ที่ใช้ในการทำการปรับเสริมข้อมูล .....	20
ตาราง 5 ไฮเปอร์พารามิเตอร์ที่ใช้ในการสร้างแบบจำลอง .....	22
ตาราง 6 ข้อมูลแบบจำลองที่ใช้ในงานวิจัย .....	23
ตาราง 7 เปรียบเทียบผลการทดลองของแบบจำลองโดยการใช้ค่าคงที่ของอัตราการเรียนรู้ที่ 0.001 .....	26
ตาราง 8 เปรียบเทียบผลการทดลองของแบบจำลองโดยการใช้ค่าคงที่ของอัตราการเรียนรู้ที่ 0.0001 .....	28
ตาราง 9 เปรียบเทียบผลการทดลองของแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16).....	30

## สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 กรอบแนวคิดในงานวิจัย .....	5
ภาพประกอบ 2 โครงร่างของแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ.....	2
ภาพประกอบ 3 โครงสร้างแบบจำลองกลุ่มภาพเรขาคณิต 16.....	5
ภาพประกอบ 4 Confusion Matrix ขนาด 2x2 .....	8
ภาพประกอบ 5 ROC Curve .....	10
ภาพประกอบ 6 แผนผังกระบวนการในการสร้างแบบจำลอง.....	17
ภาพประกอบ 7 ตัวอย่างข้อมูลภาพที่เป็นมะม่วงสายพันธุ์ของประเทศไทยทั้ง 4 สายพันธุ์ .....	19
ภาพประกอบ 8 ตัวอย่างข้อมูลภาพที่เป็นมะม่วงสายพันธุ์ของต่างประเทศ.....	19
ภาพประกอบ 9 ตัวอย่างข้อมูลภาพหลังจากใช้เทคนิคการเสริมข้อมูล.....	21
ภาพประกอบ 10 ภาพรวม Confusion Matrix ของแบบจำลองที่ใช้อัตราการเรียนรู้.....	27
ภาพประกอบ 11 ภาพรวม Confusion Matrix ของแบบจำลองที่ปรับอัตราการเรียนรู้.....	29
ภาพประกอบ 12 ตัวอย่างของการคิดแยกมะม่วงด้วยแบบจำลอง .....	32
ภาพประกอบ 13 เปรียบเทียบผลความถูกต้องและผลประสิทธิภาพของแบบจำลองจำแนกข้อมูล ด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลอง ที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้อัลกอริทึมภาพเรขาคณิต 16 (Visual Geometry Group :VGG16).....	35

## บทที่ 1

### บทนำ

#### 1. ภูมิหลัง

เนื่องจากในประเทศไทยเป็นประเทศเขตฤดูร้อนตลอดทั้งปี และอยู่ในกลุ่มประเทศอาเซียน ดังนั้นผลผลิตทางการเกษตรที่นิยมเพาะปลูกทั้งการบริโภคและจำหน่ายส่งออกไปยังต่างประเทศและเป็นที่นิยมคือ มะม่วง ซึ่งจากข้อมูลการส่งออกมะม่วงของประเทศไทยตั้งแต่ปี พ.ศ. 2560 ถึงปี 2565 ประเทศไทยมีการส่งออกมะม่วงโดยเฉลี่ยอยู่ที่ 101,046.36 ตัน หรือคิดเป็น 4,475.37 ล้านบาท (รุ่งนภา พิมมะศรี, 2565) จากข้อมูลอ้างอิงข้างต้นการส่งออกมะม่วงของไทยจึงถือว่าเป็นเศรษฐกิจหลักในภาคผลไม้ของประเทศไทยจากการผลิตมะม่วงของชาวเกษตรกร แต่กระบวนการตรวจสอบและคัดแยกสายพันธุ์ของมะม่วงยังคงเป็นระบบใช้ความสามารถของมนุษย์อาจส่งผลให้เกิดความล่าช้าและคุณภาพต่ำซึ่งอาจส่งผลกระทบต่อความต้องการของลูกค้า กระบวนการตรวจสอบ และจำแนกมะม่วงอย่างรวดเร็วนั้นจึงมีความสำคัญต่อการเก็บเกี่ยวที่ดีขึ้น นอกจากนี้ประเทศไทยมีการนำเทคโนโลยีที่ทำให้สามารถเพิ่มศักยภาพด้านการแปรรูปอาหาร ซึ่งการแปรรูปมะม่วงมีการแปรรูปที่หลากหลายวิธี เช่น มะม่วงดอง มะม่วงอบแห้ง มะม่วงกวน แยม มะม่วง และมะม่วงกระป๋อง เป็นต้น โดยการแปรรูปมะม่วงสามารถช่วยเพิ่มมูลค่าและสามารถยืดอายุการเก็บรักษาของมะม่วงได้ แต่การแปรรูปของมะม่วงขึ้นอยู่กับพันธุ์ของมะม่วงแต่ละสายพันธุ์ (Kaset GO, 2566) จากการแปรรูปมะม่วงเป็นรูปแบบมะม่วงกระป๋องนั้น พบว่าตลาดการส่งออกมะม่วงกระป๋องมีมูลค่าการส่งออกในปี 2564 อยู่ที่ 1,505.59 ล้านบาท และมีมูลค่าการส่งออกเพิ่มขึ้นเป็น 1,718.42 ล้านบาทในปี 2565 โดยตลาดการส่งออกที่สำคัญ ได้แก่ ประเทศญี่ปุ่น สหรัฐอเมริกา จีน ออสเตรเลีย และสหราชอาณาจักร ซึ่งมีข้อมูลการส่งออกตามตารางที่ 1 ดังนี้

ตาราง 1 ตลาดส่งออก 5 อันดับแรกของไทยรายสินค้า สินค้ามะม่วงกระป๋อง

ประเทศ	มูลค่า : ล้านบาท		อัตราขยายตัว (%)		สัดส่วน (%)	
	2564	2565	2564	2565	2564	2565
ญี่ปุ่น	438.76	544.9	15.4	24.19	29.14	31.71
สหรัฐอเมริกา	417.2	479.53	10.66	14.94	27.71	27.91
จีน	40.19	47.7	117.52	18.68	2.67	2.78

ตาราง 1 (ต่อ)

ประเทศ	มูลค่า : ล้านบาท		อัตราขยายตัว (%)		สัดส่วน (%)	
	2564	2565	2564	2565	2564	2565
ออสเตรเลีย	100.92	130.57	2.21	29.38	6.7	7.6
สหราชอาณาจักร	58.8	49.96	-15.76	-15.03	3.91	2.91
รวมทั้งสิ้น	1,505.59	1,718.42	21.11	14.14	100	100

ที่มา: สำนักงานปลัดกระทรวงพาณิชย์ (2566)

ดังนั้น ผู้วิจัยจึงมุ่งเน้นวิธีการในการคัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่องทั้งแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) เพื่อนำมาใช้ในการคัดแยกสายพันธุ์ของมะม่วงจากจำนวนชุดข้อมูลทั้งหมด 615 ข้อมูล โดยประกอบไปด้วยมะม่วงสายพันธุ์ของไทย ได้แก่ แก้วขมื่น เขียวเสวย น้ำดอกไม้ และน้ำดอกไม้สีทอง และมะม่วงสายพันธุ์ต่างประเทศ ซึ่งความแตกต่างของมะม่วงของไทยทั้ง 4 สายพันธุ์ (สำนักงานเกษตรและสหกรณ์, 2565) มีลักษณะตามตารางที่ 2 ดังนี้

ตาราง 2 ลักษณะของมะม่วงทั้ง 4 สายพันธุ์ของไทย

สายพันธุ์มะม่วง	รูปร่างของมะม่วง	ลักษณะของพื้นผิว
แก้วขมื่น	ผลอ้วนป้อม	ผิวสีเขียว พื้นผิวมีนวล มีจุดประ
เขียวเสวย	ผลกลมอูมยาว ก้นผลงอ เรียวมน ปลายแหลม	ผิวสีเขียวเข้ม พื้นผิวมีนวล มีจุดประ

ตาราง 2 (ต่อ)

สายพันธุ์มะม่วง	รูปร่างของมะม่วง	ลักษณะของพื้นผิว
น้ำดอกไม้	ผลกลม อุ่ม ก้นผลเรียวแหลม	ผิวสีเขียวอมเหลือง พื้นผิวมีนวล มีจุดประ
น้ำดอกไม้สีทอง	ผลกลม อุ่ม ก้นผลเรียวแหลม	ผิวสีเหลืองทอง พื้นผิวมีนวล มีจุดประ

ที่มา: สำนักงานเกษตรและสหกรณ์ (2022)

## 2. ความมุ่งหมายของงานวิจัย

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายไว้ดังนี้

2.1 เพื่อสร้างแบบจำลองการคัดแยกสายพันธุ์มะม่วงด้วยการเรียนรู้ของเครื่อง โดยใช้แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) และใช้อัลกอริทึม Adam และ RMSprop

2.2 เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองข้อมูลโครงข่ายประสาทเทียมทั้งสองแบบจำลองหลัก คือ แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) โดยใช้ภาพมะม่วงทั้ง 4 สายพันธุ์ของไทยและพันธุ์จากต่างประเทศ เพื่อดูประสิทธิภาพของแบบจำลองที่สร้างขึ้น โดยใช้การวัดค่า Precision, Recall, F1-score และ ROC เป็นต้นในการวัดความถูกต้องในการทำนายและประสิทธิภาพของแบบจำลอง

## 3. ความสำคัญของการวิจัย

จากการคัดแยกมะม่วงแบบระบบแมนนวลของเกษตรกรทำให้เกิดความล่าช้าในการส่งออกมะม่วงในปัจจุบันและไม่ตอบสนองต่อความต้องการของลูกค้า ดังนั้นการศึกษาคัดแยกสายพันธุ์มะม่วงด้วยเครื่อง โดยใช้เทคนิคการประมวลผลภาพและการแยกประเภทด้วยการเรียนรู้ของเครื่อง เป็นวิธีที่จะช่วยให้การคัดแยกสายพันธุ์มะม่วงมีความรวดเร็วและมีคุณภาพที่ดีขึ้นได้ การ

วิจัยครั้งนี้ได้ศึกษาการคัดแยกสายพันธุ์มะม่วงที่ได้รับความนิยมมากที่สุดในปัจจุบันของไทย ได้แก่ มะม่วงสายพันธุ์แก้วขมิ้น เขียวเสวย น้ำดอกไม้ และน้ำดอกไม้สีทอง

#### 4. ขอบเขตของการวิจัย

ภาพที่นำมาใช้ในงานวิจัยครั้งนี้เป็นภาพที่ได้จากการถ่ายทำมะม่วงสายพันธุ์ของไทยในขณะที่กำลังหมุนภาพ โดยฉากหลังของมะม่วงเป็นพื้นหลังสีขาว ขนาดของภาพก่อนเริ่มดำเนินขั้นตอนจัดการข้อมูล มีขนาด 6000 x 4000 พิกเซล โดยข้อมูลมาจากการเก็บรวบรวมของผู้วิจัย จึงมีภาพมะม่วงสายพันธุ์ของประเทศไทยจำนวนทั้ง 4 สายพันธุ์ ได้แก่ มะม่วงแก้วขมิ้น มะม่วงเขียวเสวย มะม่วงน้ำดอกไม้ และมะม่วงน้ำดอกไม้สีทอง และมะม่วงสายพันธุ์จำนวนทั้งหมด 492 ภาพ และภาพพันธุ์มะม่วงจากประเทศอื่นๆ จำนวน 123 ภาพ

#### 5. นิยามศัพท์เฉพาะ

ศัพท์ที่ 1 Deep Learning หมายถึงการเรียนรู้เชิงลึกของเครื่อง ที่ใช้โครงข่ายประสาทเทียมเพื่อให้คอมพิวเตอร์สามารถเรียนรู้และทำงานได้เหมือนมนุษย์

ศัพท์ที่ 2 Neural Network หมายถึงโครงข่ายประสาทเทียม หรือแบบจำลองคณิตศาสตร์ที่จำลองการทำงานของระบบประสาทเทียมในสมองมนุษย์

ศัพท์ที่ 3 Convolutional neural networks หรือเรียกว่า CNN หมายถึงการวิเคราะห์รูปภาพที่มนุษย์มองเห็น โดยจะแบ่งรูปภาพออกเป็นพื้นที่ย่อย ๆ หรือภาพจุดเล็กๆแต่ละอันเพื่อทำการวิเคราะห์เมตริกของรูปภาพ

ศัพท์ที่ 4 Transfer Learning หมายถึงเทคนิคที่ช่วยลดเวลาการเทรนแบบจำลอง Deep Learning ด้วยการนำบางส่วนจากแบบจำลองที่เทรนเรียบร้อยแล้ว กับงานที่ใกล้เคียงกัน มาใช้เป็นส่วนหนึ่งของแบบจำลองใหม่

ศัพท์ที่ 5 Data Augmentation หมายถึงเทคนิคการเพิ่มข้อมูลภาพโดยการทำการปรับแต่งหรือแปลงภาพเดิมให้เป็นรูปแบบใหม่ๆ เช่น การหมุนภาพ การเปลี่ยนขนาดของภาพ การปรับเพิ่มความหลากหลายให้กับชุดข้อมูลในการเทรนแบบจำลอง Deep Learning

ศัพท์ที่ 6 Learning Rate หมายถึงอัตราการเรียนรู้ของแบบจำลอง Deep Learning หรือ Neural Network ในการปรับค่าพารามิเตอร์ต่างๆ ในแต่ละรอบการเทรน โดยใช้ตัวแปรเป็นค่าคงที่



## 6. กรอบแนวคิดในงานวิจัย



ภาพประกอบ 1 กรอบแนวคิดในงานวิจัย

จากภาพประกอบ 1 กรอบแนวคิดของงานวิจัยของการศึกษาวิธีการเรียนรู้การคัดแยกสายพันธุ์มะม่วงของไทยด้วยเทคนิคการเรียนรู้ของเครื่อง มีการออกแบบกรอบแนวคิดจากการกำหนดขอบเขตของปัญหา การศึกษางานวิจัยที่เกี่ยวข้อง รวมทั้งการตั้งวัตถุประสงค์และขอบเขตของงานวิจัยเพื่อนำมาเป็นรูปแบบหลักของการดำเนินการวิจัย และการต่อยอดในงานวิจัย โดยหลังจากที่กำหนดขอบเขตของงานวิจัยแล้วจำเป็นต้องออกแบบงานวิจัยตั้งแต่การใช้แบบจำลอง ข้อมูลที่นำมาประกอบในงานวิจัย การออกแบบและการวิเคราะห์ข้อมูล และวิธีการเก็บรวบรวมข้อมูล เพื่อนำข้อมูลและขั้นตอนของการออกแบบการสร้างแบบจำลองไปดำเนินการวิเคราะห์ข้อมูล และการประเมินผลงานวิจัยที่ทำให้สามารถมีความเป็นไปได้ของการวัตถุประสงค์ที่ตั้งไว้ข้างต้น ดังนั้นงานวิจัยนี้จึงมีลำดับขั้นตอนการดำเนินการ ดังนี้

6.1 กำหนดปัญหา (Research Problem)

6.2 การศึกษาเอกสารที่เกี่ยวข้องกับการวิจัย (Review Related Literatures)

6.3 กำหนดวัตถุประสงค์ของการวิจัยและสมมติฐาน (Research Purposes and Research Hypotheses)

6.4 การออกแบบการวิจัย (Research Design) ประกอบไปด้วย แบบจำลองที่ใช้ในการวิจัย

- 6.5 การออกแบบรูปแบบการวิเคราะห์ข้อมูล
- 6.6 การเก็บรวบรวมข้อมูล (Data Collection)
- 6.7 การวิเคราะห์ข้อมูล (Data Analysis)
- 6.8 การประเมินผลการวิจัย (Research evaluation)
- 6.9 สรุปการวิจัย (Research summary)

## 7. สมมุติฐานในการวิจัย

ปัจจัยในการคัดแยกสายพันธุ์มะม่วงของไทยจากชุดข้อมูลการจำแนกลักษณะ และพื้นผิวของมะม่วงมีผลต่อความแม่นยำในการคัดแยกสายพันธุ์มะม่วง และประสิทธิภาพของแบบจำลองต่างๆ ที่นำมาใช้ เพื่อตอบสนองในการลดเวลาการคัดแยกสายพันธุ์

## 8. ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

1. แบบจำลองสำหรับเพื่อคัดแยกมะม่วงสายพันธุ์ของไทย
2. สามารถนำแบบจำลองไปประยุกต์ใช้กับปัญหาอื่นๆในการจำแนกวัตถุที่มีรูปร่าง สี หรือขนาดที่ใกล้เคียงกัน

อย่างไรก็ตาม ในบทที่ 1 นี้เป็นการกล่าวภาพรวมของบทวิจัยตั้งแต่ภูมิหลัง ความสำคัญ วัตถุประสงค์ และการตั้งสมมุติฐานเพื่อนำไปสู่กระบวนการวิจัยในเบื้องต้น โดยในบทที่ 2 การทบทวนวรรณกรรมจะเป็นการทบทวนวรรณกรรมในส่วนของทฤษฎีที่นำมาใช้ในงานวิจัยทั้งหมด และการทบทวนงานวิจัยที่เกี่ยวข้องเพื่อนำมาประยุกต์และปรับใช้ในงานวิจัย

## บทที่ 2

### บททวนวรรณกรรม

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาทฤษฎีต่างๆ และงานวิจัยที่เกี่ยวข้อง และได้นำเสนอตามหัวข้อดังต่อไปนี้

1. ทฤษฎีที่เกี่ยวข้องกับงานวิจัย
2. งานวิจัยที่เกี่ยวข้อง

#### 1. ทฤษฎีที่เกี่ยวข้องกับงานวิจัย

การเรียนรู้ของเครื่อง (Machine Learning) คืออัลกอริทึมที่พัฒนาการเรียนรู้ของข้อมูลต่างๆ เพื่อเป็นการเรียนรู้รูปแบบอัตโนมัติผ่านข้อมูล เพื่อทำการค้นหา การแยกแยะ การทำนายข้อมูล (Artificial Intelligence) ซึ่งหลักการทำงานของอัลกอริทึมจะทำงานโดยอาศัยการสร้างแบบจำลองทางคณิตศาสตร์จากชุดข้อมูลฝึกฝน (Training data) เพื่อนำแบบจำลองมาทดสอบกับข้อมูลทดสอบ (Test data) เพื่อใช้ในการคาดคะเน หรือหาความน่าจะเป็น หรือจุดตัดสินใจ เพื่อนำไปสู่การพัฒนากระบวนการแก้ไขปัญหาได้อย่างเหมาะสม โดยการเรียนรู้ของเครื่องสามารถแบ่งออกได้หลายประเภท ดังนี้

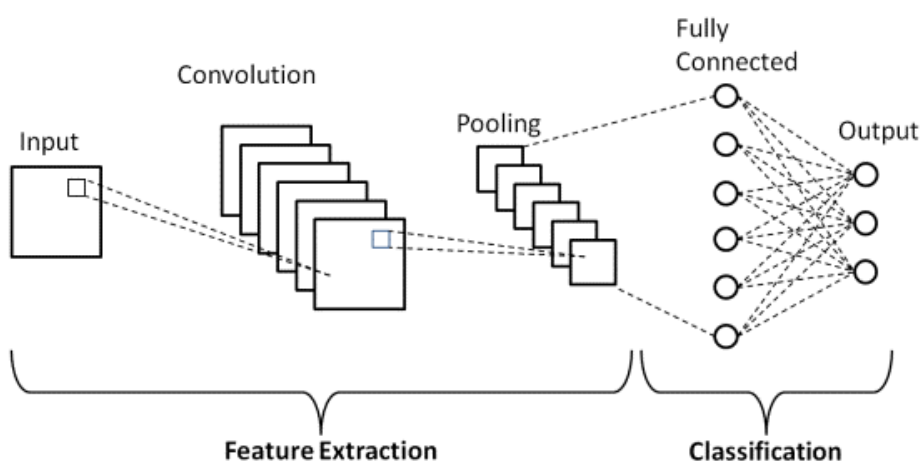
1. การเรียนรู้แบบมีผู้ฝึกสอน (Supervised Learning) คือการเรียนรู้ข้อมูลต่างๆ โดยมีผู้สอน โดยอาศัยข้อมูลในการฝึกฝน เพื่อช่วยให้สามารถเรียนรู้และคาดคะเนผลลัพธ์ต่างๆ ได้ อย่างแม่นยำมากขึ้น โดยการเรียนรู้แบบมีผู้ฝึกสอนนี้ นิยมนำมาใช้ในงานที่เกี่ยวกับการเงิน และการวิเคราะห์ผลการแข่งขันต่างๆ เป็นต้น

2. การเรียนรู้แบบไม่มีผู้ฝึกสอน (Unsupervised Learning) คือการเรียนรู้จากเครื่อง ที่ทำการเรียนรู้สิ่งต่างๆ ที่ได้รับด้วยตัวเอง โดยไม่มีการตั้งค่าเป้าหมายในแต่ละข้อมูล ซึ่งระบบจะสามารถนำไปวิเคราะห์และสร้างแบบจากข้อมูลที่ได้รับ การเรียนรู้แบบไม่มีผู้ฝึกสอนนี้ นิยมใช้กับการแนะนำสินค้าหรือผลิตภัณฑ์

3. การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) คือการเรียนรู้จากการเก็บรวบรวมข้อมูลความผิดพลาดและความถูกต้องของแบบจำลองที่ผ่านมามาตั้งแต่นั้นในอดีต เพื่อให้สามารถพัฒนาการตัดสินใจได้แม่นยำมากขึ้น โดยการเรียนรู้แบบเสริมกำลังนี้ นิยมใช้กับการพัฒนาระบบด้านต่างๆ เช่น ระบบในการจัดการข้อมูลเพื่อช่วยในการตัดสินใจเลือกอัตราส่วนของสินทรัพย์ ระบบการตัดสินใจโอกาสชนะของผู้เข้าแข่งขัน เป็นต้น

## 1.1 แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN)

แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) คือสถาปัตยกรรมเครือข่ายสำหรับการเรียนรู้เชิงลึกซึ่งเป็นการเรียนรู้โดยตรงจากข้อมูล และจากการจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นส่วนย่อยๆ โดยสามารถนำกลุ่มของส่วนย่อยๆ มาผสานกันเข้าด้วยกัน เพื่อให้สามารถจำแนกประเภทของวัตถุ หรือลักษณะของภาพนั้นๆ



ภาพประกอบ 2 โครงร่างของแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ

ที่มา: Phung & Rhee (2019)

จากภาพประกอบ 2 โครงร่างของแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการมีการแบ่งโครงสร้างการทำงานเป็นสองส่วน ได้แก่ การแยกคุณลักษณะ (Feature Extraction) และการจำแนกประเภท (Classification) โดยมีภาพอินพุต นำไปสู่การแบ่งชั้นของข้อมูลหรือเลเยอร์ (Convolutional layer) เพื่อดำเนินการทางคณิตศาสตร์และได้ข้อมูลออกมาเป็นตัวเลข จากนั้นนำข้อมูลมาซ้อนกันไปสู่การดำเนินการรวมเลเยอร์เพื่อลดขนาดของข้อมูลที่มีความซับซ้อนให้มีขนาดเล็ก (Pooling layer) จากนั้นได้นำภาพไปเรียนรู้การเชื่อมต่อกับเลเยอร์ (Fully Connected Layer) เพื่อแยกประเภทของข้อมูล

1.1.1 การแยกคุณลักษณะ (Feature Extraction) ประกอบไปด้วยการแบ่งชั้นของเลเยอร์ (Convolutional layer) และการลดขนาดของข้อมูลที่มีความซับซ้อน (Pooling layer) โดยการมีการอธิบายความหมายไว้ดังนี้

1.1.1.1 การแบ่งชั้นของเลเยอร์ (Convolutional layer) คือเลเยอร์ที่ใช้เพื่อแยกคุณสมบัติต่างๆ โดยการแบ่งชั้นหลักที่ใช้ในการทำการคอนโวลูชัน (Convolution) โดยมีการสร้าง Feature Maps หรือ Feature Extraction ของภาพนำเข้า (Input Image) โดยการใส่เคอร์เนล (Kernel) เพื่อทำการสกัดลักษณะเด่น (Features) จากภาพ และสร้างเมทริกซ์ผลลัพธ์ (Output Matrix) ที่มีขนาดเล็กลงจากภาพนำเข้า ชั้นรองมาเป็นชั้นที่ใส่ลดขนาดของภาพและย่อสเกลข้อมูลที่ได้จาก Convolutional Layer และชั้นสุดท้าย คือชั้นที่ใช้ในการประมวลผลต่อจากชั้น Convolutional Layer โดยทำหน้าที่ในการใช้ฟังก์ชันเพื่อให้มีการกระตุ้น (Activate) ค่าผลลัพธ์ของชั้น Convolutional Layer เช่น Rectified Linear Unit (ReLU) หรือซิกมอยด์ (Sigmoid) เพื่อเพิ่มความสามารถในการเรียนรู้และการแยกแยะของโมเดล

1.1.1.2 การรวมเลเยอร์เพื่อลดขนาดของข้อมูลที่มีความซับซ้อน (Pooling layer) คือ การลดขนาดของแมปคุณลักษณะที่เกี่ยวข้องเพื่อลดต้นทุนในการคำนวณ ทำได้โดยการลดการเชื่อมต่อระหว่างเลเยอร์และดำเนินการอย่างอิสระในแต่ละแผนที่คุณลักษณะ โดยมีวิธีการที่ใช้ มีการดำเนินการรวมหลายประเภท โดยทั่วไปจะสรุปคุณสมบัติที่สร้างโดยเลเยอร์การปิด (Max Pooling) ซึ่งองค์ประกอบที่ใหญ่ที่สุดจะถูกนำมาจากฟีเจอร์แมป (Feature Map) การรวมค่าเฉลี่ยจะคำนวณค่าเฉลี่ยขององค์ประกอบในส่วนรูปภาพขนาดที่กำหนดไว้ ผลรวมทั้งหมดขององค์ประกอบในส่วนที่กำหนดไว้จะถูกคำนวณในการรวบรวมระหว่างการแบ่งชั้นของเลเยอร์ และการเรียนรู้การเชื่อมต่อชั้นเลเยอร์ (Fully Connected Layer)

1.1.1.3 การเชื่อมต่อชั้นเลเยอร์ (Fully Connected Layer: FC) ประกอบด้วยน้ำหนักและความค่าเอนเอียงของเซลล์ประสาท เพื่อเชื่อมต่อเซลล์ประสาทระหว่างสองชั้นที่แตกต่างกัน ซึ่งเลเยอร์จะเป็นการกำหนดค่าก่อนการป้อนเข้า และกำหนดการสร้างเลเยอร์สุดท้ายของแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยนำภาพชุดข้อมูลเข้าไปยังเลเยอร์ที่กำหนด จากนั้นจะทำการเชื่อมข้อมูลของภาพเพื่อนำไปเข้ากระบวนการจัดหมวดหมู่ของภาพ ปกติการกำหนดและเชื่อมต่อชั้นของภาพอยู่ที่ 2-4 เลเยอร์ การเชื่อมต่อของชั้นเลเยอร์ที่มีมากกว่าชั้นเลเยอร์เดียวในแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการช่วยลดการกำกวมของมนุษย์

1.1.1.4 การออกกลางคัน (Dropout) เมื่อคุณสมบัติทั้งหมดเชื่อมต่อกับเลเยอร์ FC อาจทำให้เกิดการใส่ชุดข้อมูลการฝึกมากเกินไป Overfitting เกิดขึ้นเมื่อแบบจำลองเฉพาะทำงานได้ดีกับข้อมูลฝึกฝนทำให้เกิดผลกระทบในทางลบ หรือความบิดเบือนลงต่อประสิทธิภาพของแบบจำลองเมื่อใช้กับข้อมูลใหม่ เพื่อแก้ปัญหาข้อมูลการฝึกมากเกินไป เลเยอร์ dropout ถูกใช้โดยที่เซลล์ประสาทสองสามเซลล์ถูกทิ้งจากโครงข่ายประสาทเทียมระหว่างกระบวนการฝึก ส่งผลให้ขนาดของแบบจำลองลดลง เมื่อผ่านการ dropout อัตราาร้อยละ 30 หรือ 0.3 ของโหนดจะถูกสุ่มออกจากโครงข่ายประสาทเทียม การออกกลางคันส่งผลให้เกิดการปรับปรุงประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง เนื่องจากช่วยป้องกันการโอเวอร์ฟิตด้วยการทำให้เครือข่ายง่ายขึ้น

1.1.1.5 ฟังก์ชันการเปิดใช้งาน (Activation Functions) เป็นหนึ่งในพารามิเตอร์ที่สำคัญที่สุดของแบบจำลอง คือฟังก์ชันการเปิดใช้งานซึ่งใช้เพื่อเรียนรู้และประมาณความสัมพันธ์ที่ต่อเนื่องและความซับซ้อนระหว่างตัวแปรต่างๆ ของเครือข่าย หรือเป็นส่วนที่ตัดสินใจว่าข้อมูลใดของแบบจำลองที่ควรจะไปในทิศทางข้างหน้าและข้อมูลที่ไม่ควรอยู่ในเครือข่าย โดยมีฟังก์ชันการเปิดใช้งานที่ใช้กันทั่วไปหลายอย่าง เช่น ReLU, Softmax, tanH และฟังก์ชัน Sigmoid มีการใช้งานเฉพาะสำหรับแบบจำลองข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ โดยการจำแนกแบบไบนารี ควรใช้ฟังก์ชัน Sigmoid และ Softmax สำหรับการจำแนกประเภทหลายคลาส ซึ่งโดยทั่วไปมักนิยมใช้ Softmax เพราะเป็นฟังก์ชันการกระตุ้นในแบบจำลองซึ่งกำหนดว่าเซลล์ประสาทควรถูกกระตุ้น หรือตัดสินใจใส่ข้อมูลที่มีความสำคัญที่จะทำนายโดยใช้การดำเนินการทางคณิตศาสตร์


## 1.2 แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer Learning)

Transfer learning เป็นทฤษฎีที่ใช้แบบจำลอง Deep learning ที่ฝึกเรียบร้อยแล้วสำหรับการเรียนรู้งานอื่นๆ ซึ่งช่วยลดเวลาและค่าใช้จ่ายในการฝึกแบบจำลองใหม่ โดยการนำแบบจำลองที่ฝึกเรียบร้อยแล้วไปใช้กับงานที่ใกล้เคียงกัน เช่น การตรวจจذبวัตถุ การจำแนกภาพ หรือการแปลภาษา โดยไม่ต้องฝึกแบบจำลองใหม่ตั้งแต่ต้น ซึ่งนำไปสู่การลดเวลาและค่าใช้จ่ายในการฝึกแบบจำลองใหม่

ดังนั้นกรณีของ ImageNet dataset กับ ILSVRC แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ที่ถูกใช้ในงานวิจัย ได้ถูกฝึกด้วยชุดข้อมูลขนาดใหญ่และมีความซับซ้อน ด้วยจำนวนภาพมากกว่า 15

ล้านภาพและมีจำนวนคลาสมากกว่า 22,000 รวมถึงการแข่งขัน ILSVRC ที่มี dataset ขนาด 1 ล้านภาพที่มีความซับซ้อนเท่ากัน ดังนั้นแบบจำลองนี้จะถูกฝึกด้วยชุดข้อมูลที่จะนำมาใช้เป็นแบบจำลอง Transfer learning ในงานวิจัยอื่นๆ ที่มีลักษณะคล้ายคลึงกัน โดยจะช่วยให้ลดเวลาและค่าใช้จ่ายในการฝึกแบบจำลองใหม่ได้มากขึ้น

1.2.1 แบบจำลองกลุ่มภาพเรขาคณิต (Visual Geometry Group (VGG) คือแบบจำลองกลุ่มภาพเรขาคณิต หรือ VGG เป็นแบบจำลอง Convolutional Neural Network เป็นที่ได้รับความนิยมในการนำไปใช้งานด้านประมวลผลภาพ โดยแบบจำลองนี้ถูกพัฒนาโดย VGG (Visual Geometry Group) ซึ่งเป็นทีมวิจัยที่สังกัดกับ Oxford University แบบจำลองนี้ถูกสร้างขึ้นโดยใช้ Convolutional Layer และ Pooling Layer ตามลำดับ ซึ่งช่วยให้สามารถสกัดลักษณะเด่นของภาพได้ดีขึ้น โดย VGG16 จะประกอบด้วย 13 ชั้น Convolutional Layer และ 3 ชั้น Fully-Connected Layer ที่เชื่อมต่อกันด้วย Activation Function ชื่อ ReLU (Rectified Linear Unit) เพื่อปรับค่าความถี่ของภาพและข้อมูลรบกวน ซึ่งใช้ในการแยกประเภทภาพ ความลึกของ Convolutional Layer ใน VGG16 สูงถึง 512 ชั้น และมี Dropout ที่ช่วยลดการเกิด Overfitting ในแบบจำลองนี้ด้วย นอกจากนี้ VGG16 ยังมีการใช้ Pooling Layer แบบ Max Pooling ขนาด 2x2 พิกเซล ที่ช่วยลดขนาดของภาพ และช่วยลดพีเจอรที่ไม่จำเป็น ดังนั้น VGG16 เป็นแบบจำลอง CNN ที่มีประสิทธิภาพสูงในการจำแนกภาพ ทำให้เหมาะที่จะนำไปใช้งานด้านประมวลผลภาพที่มีความหลากหลาย และการตรวจจับวัตถุในภาพ หรือการแยกประเภทภาพต่างๆ



ภาพประกอบ 3 โครงสร้างแบบจำลองกลุ่มภาพเรขาคณิต 16

ที่มา: NVIDIA Corporation (2023)

### 1.3 อัลกอริทึมในการเพิ่มประสิทธิภาพของแบบจำลอง (Optimizer Algorithm)

อัลกอริทึมในการเพิ่มประสิทธิภาพของแบบจำลอง (Optimizer Algorithm) คือการใช้หลักคณิตศาสตร์ในการแบ่งกลุ่มตามชุดข้อมูลที่ใช้ฝึกฝนของแบบจำลอง ซึ่งมีการเลือกใช้ อัลกอริทึมเพื่อนำมาปรับค่าให้ได้ค่าที่ดีที่สุด โดยจะทำการเปลี่ยนแปลงค่าน้ำหนักของการเรียนรู้ (Weight) และค่าความเอนเอียง (Bias)

ทั้งนี้ Optimizer ในการเพิ่มประสิทธิภาพของแบบจำลองสามารถแบ่งออกเป็น 2 ประเภท คือ First Order Optimization Algorithms และ Second Order Optimization Algorithms โดย First Order Optimization Algorithms จัดอยู่ในตระกูลของ Gradient และ Second Order Optimization Algorithms จัดอยู่ในตระกูลของ Hessian

โดยการวิจัยครั้งนี้ เลือกใช้อัลกอริทึมทั้งหมด 2 แบบ คือ Root Mean Square Propagation (RMSprop) และ Adaptive Moment Estimation (Adam) โดย RMSprop จะใช้ค่าเฉลี่ยของ Gradient ในการปรับแต่งค่าการเรียนรู้ (Learning Rate) และ Adam จะใช้การปรับปรุงคล้ายกับอัลกอริทึม RMSprop แต่มีการเพิ่มค่าโมเมนตัม (Momentum) ในการปรับค่าน้ำหนักของการเรียนรู้ (Weight) และค่าความเอนเอียง (Bias) ซึ่งมีรายละเอียดต่างๆ ดังนี้

#### 1.3.1 อัลกอริทึม Root Mean Square Propagation

อัลกอริทึม Root Mean Square Propagation (RMSprop) เป็นอัลกอริทึมที่มีปรับปรุงในการเรียนรู้ของแบบจำลองเชิงลึก (Deep Learning) ซึ่งจะช่วยให้การเรียนรู้ของแบบจำลองเร็วขึ้น และเป็นอัลกอริทึมปรับปรุงในการอัปเดตพารามิเตอร์ของแบบจำลองด้วยวิธีการเปลี่ยนแปลงค่าน้ำหนักของการเรียนรู้ (Weight) และค่าความเอนเอียง (Bias) โดยมีวิธีการคำนวณดังนี้

1) คำนวณ Vector ของ "น้ำหนักแรง"  $s$  โดยใช้ EMA ของการยกกำลังสองของอนุพันธ์ คือการใช้อนุพันธ์ล่าสุดมาทำให้การเคลื่อนที่ของฟังก์ชันต้นทุน (Cost Function) และมีการใช้ EMA ของยกกำลังสองของอนุพันธ์แทน ซึ่งมีวิธีในการคำนวณ ดังนี้

สมการที่ 1 คำนวณ Vector ของ "น้ำหนักแรง"  $s$  โดยใช้ EMA ของการยกกำลังสองของอนุพันธ์:



$$\begin{aligned}
 s_{dW}^{[l]} &= \beta s_{dW}^{[l]} + (1 - \beta) dW^{[l]2} \\
 s_{db}^{[l]} &= \beta s_{db}^{[l]} + (1 - \beta) db^{[l]2}
 \end{aligned}
 \tag{1}$$

สมการที่ 2 นำค่าน้ำหนักแรง  $s_{dW}^{[l]}$  และ  $s_{db}^{[l]}$  ที่ได้ไปประกอบกับ  $dW^{[l]}$  และ  $db^{[l]}$  และถ่วงกับค่าการเรียนรู้ (Learning Rate)  $\alpha$  ดังสมการด้านล่าง แล้วจึงทำการลบออกจาก  $W^{[l]}$  และ  $b^{[l]}$

$$\begin{aligned}
 W^{[l]} &:= W^{[l]} - \alpha \left( \frac{dW^{[l]}}{\sqrt{s_{dW}^{[l]} + \epsilon}} \right) \\
 b^{[l]} &:= b^{[l]} - \alpha \left( \frac{db^{[l]}}{\sqrt{s_{db}^{[l]} + \epsilon}} \right)
 \end{aligned}
 \tag{2}$$

### 1.3.2 อัลกอริทึม Adaptive Moment Estimation

อัลกอริทึม Adaptive Moment Estimation เป็นอัลกอริทึมที่สามารถปรับค่าการเรียนรู้ (Learning Rate) ในพารามิเตอร์ของการเรียนรู้ในแต่ละครั้ง และสามารถแก้ปัญหาสำหรับพารามิเตอร์ในแต่ละครั้งได้และยังสามารถแก้ปัญหาความผิปกติ (Decaying) ของความลาดชัน (Gradients) ในแต่ละจุดของการเคลื่อนที่ และยังช่วยแก้ปัญหาการแกว่งของพารามิเตอร์ซึ่งวิธีในการคำนวณตามสมการที่ 3 ดังนี้

$$\begin{aligned}
 W_{t+1,i} &= W_{t,i} - \frac{\alpha}{\sqrt{\hat{v}_{t,i} + \epsilon}} \hat{m}_{t,i} \\
 \hat{v}_{t,i} &= \frac{v_{t,i}}{1 - \beta_2^t} \quad \hat{m}_{t,i} = \frac{m_{t,i}}{1 - \beta_1^t} \\
 m_{t,i} &= \beta_1 m_{t-1,i} + (1 - \beta_1) g_{t,i} \\
 v_{t,i} &= \beta_2 v_{t-1,i} + (1 - \beta_2) (g_{t,i})^2
 \end{aligned}
 \tag{3}$$

#### 1.4 เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย (Confusion Matrix)

เครื่องมือในการวิเคราะห์และการประเมินผลลัพธ์ของการทำนาย จากแบบจำลองสร้างขึ้นบนเครื่องคอมพิวเตอร์นั้น เป็นเครื่องมือที่มีการวัดค่าจากสิ่งให้แบบจำลองเรียนรู้ข้อมูล และการทำนายผลจากสิ่งที่เกิดขึ้นจริง

### Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

ภาพประกอบ 4 Confusion Matrix ขนาด 2x2

ที่มา: Pagon Gatchalee (2019)

จากภาพประกอบ 4 Confusion Matrix มีการจำแนกสัดส่วนของการทำนาย ดังนี้

1. สิ่งที่มีผลลัพธ์ของแบบจำลองทำนายตรงกับสิ่งที่เกิดขึ้นจริง (True Positive หรือ TP) โดยจะใช้ในกรณีการทำนายว่าเป็นจริง และสิ่งที่เกิดขึ้นเป็นจริง
2. สิ่งที่มีผลลัพธ์ของแบบจำลองทำนายได้ตรงกับสิ่งที่เกิดขึ้นจริง (True Negative หรือ TN) โดยจะใช้ในกรณีการทำนายว่าไม่เป็นจริง และสิ่งที่เกิดขึ้นไม่เป็นจริง
3. สิ่งที่มีผลลัพธ์ของแบบจำลองไม่ตรงกับสิ่งที่เกิดขึ้นจริง (False Positive หรือ FP) โดยจะใช้ในกรณีการทำนายว่าเป็นจริง แต่สิ่งที่เกิดขึ้นไม่เป็นจริง
4. สิ่งที่มีผลลัพธ์ของแบบจำลองไม่ตรงกับสิ่งที่เกิดขึ้นจริง (False Negative หรือ FN) โดยจะใช้ในกรณีการทำนายว่าไม่เป็นจริง แต่สิ่งที่เกิดขึ้นเป็นจริง

อย่างไรก็ตาม เมื่อดำเนินการคำนวณ Confusion Matrix แล้ว ยังสามารถนำไปคำนวณการประเมินประสิทธิภาพของผลลัพธ์ของแบบจำลองในรูปแบบต่างๆ เช่น ความถูกต้องของแบบจำลองที่ตรงกับความจริง (Accuracy) ค่าความแม่นยำ (Precision) ความถูกต้องของการทำนายว่าจะเป็นจริงและตรงกับความจริงเทียบกับ จำนวนครั้งของเหตุการณ์ทั้งในทำนายและเกิดขึ้นว่าเป็นจริง (Recall) และค่าเฉลี่ยที่วัดความสามารถของแบบจำลอง (F1 Score) ซึ่งจะมีการอธิบายความหมายและการคำนวณในลำดับถัดไป

#### 1.4.1 ความถูกต้องที่ผลลัพธ์ของแบบจำลองได้ตรงกับสิ่งที่เกิดขึ้นจริง (Accuracy)

ความถูกต้องที่ผลลัพธ์ของแบบจำลองได้ตรงกับสิ่งที่เกิดขึ้นจริง โดยเป็นการวัดค่าความถูกต้องของแบบจำลองโดยพิจารณารวมผลลัพธ์ของทุกคลาส ซึ่งมีวิธีการคำนวณตามสมการที่ 4 ดังนี้

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

#### 1.4.2 ค่าความแม่นยำ (Precision)

ความแม่นยำเป็นการเปรียบเทียบระหว่างผลลัพธ์ของแบบจำลองที่ทำนายได้ถูกต้องว่าเป็นจริง และเกิดขึ้นจริง (TP) กับผลลัพธ์ของแบบจำลองที่ทำนายว่าเป็นจริง แต่สิ่งที่เกิดขึ้นไม่เป็นจริง (FP) ซึ่งมีวิธีการคำนวณตามสมการที่ 5 ดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

#### 1.4.3 ความถูกต้องของผลลัพธ์ของแบบจำลองที่ทำนาย (Recall)

ความถูกต้องของผลลัพธ์ของแบบจำลองที่ทำนายว่าจะเป็นความจริง เปรียบเทียบกับ จำนวนครั้งของเหตุการณ์ที่ทำนาย และเกิดขึ้นเป็นจริง (Recall) ซึ่งมีสูตรการคำนวณตามสมการที่ 6 ดังนี้

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

#### 1.4.4 ค่าเฉลี่ยในการวัดความสามารถของแบบจำลอง (F1 Score)

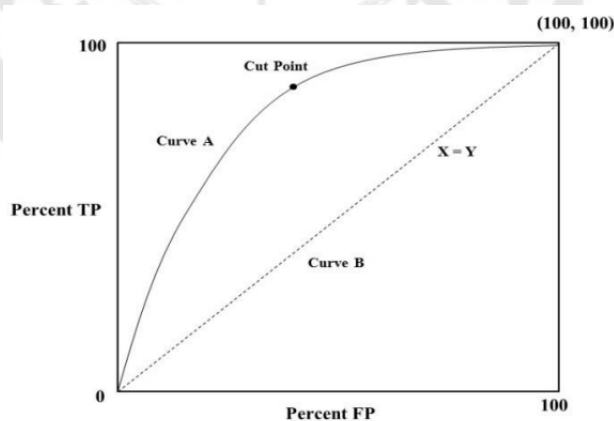
ค่าเฉลี่ยที่วัดในการวัดความสามารถของแบบจำลอง (F1 Score) เป็นค่าเฉลี่ยแบบ Harmonic Mean ระหว่างค่าความแม่นยำ (Precision) และค่าความถูกต้องของผลลัพธ์ของแบบจำลองที่ทำนาย (Recall) โดยในการสร้าง F1 Score ขึ้นมาเพื่อเป็นเมตริกเดี่ยว (Single Metric) ที่ใช้ในการวัดความสามารถของแบบจำลอง ซึ่งมีวิธีการคำนวณตามสมการที่ 7 ดังนี้

$$F1 = 2 \left( \frac{Precision * Recall}{Precision + Recall} \right) \quad (7)$$

### 1.5 กราฟแสดงประสิทธิภาพของการทำนายแบบจำลอง (Receiver Operating Characteristic Curve: ROC)

กราฟ Receiver Operating Characteristic Curve (ROC) เป็นกราฟที่ใช้ในการแสดงประสิทธิภาพของแบบจำลอง (Model) ในการจำแนกสิ่งที่ต้องการ (Positive class) และสิ่งที่ไม่ต้องการ (Negative Class) โดยเปรียบเทียบระหว่างความไวต่อการตอบสนองที่ถูกต้อง (True Positive Rate) และอัตราส่วนการตอบกลับเกินจำเป็น (False Positive Rate) ในแต่ละค่าความ Threshold ที่ใช้ตัดสินใจว่าจะแยกสิ่งที่ต้องการและไม่ต้องการด้วยกัน โดย True Positive Rate หมายถึง อัตราส่วนของตัวอย่างใน Positive Class ที่ถูกทำนายว่าเป็น Positive Class จริงๆ และ False Positive Rate หมายถึงอัตราส่วนของตัวอย่างใน Negative Class ที่ถูกทำนายว่าเป็น Positive Class โดยที่จริงๆ แล้วเป็น Negative class

ROC Curve จะทำการแสดงผลลัพธ์ด้วยเส้นโค้งที่ตั้งอยู่บนระนาบสี่เหลี่ยมขนาดหนึ่ง โดยใช้ True Positive Rate เป็นแกน y และ False Positive Rate เป็นแกน x โดยจุด (0,0) แทนการทำนายที่ไม่ถูกต้องเลย และจุด (1,1) แทนการทำนายที่ถูกต้องทั้งหมด เส้น ROC Curve ที่อยู่บนมุมซ้ายของกราฟแสดงให้เห็นว่าแบบจำลองของเราทำนายผลได้ดีกว่าการสุ่ม (Random Guessing) และเส้น ROC Curve ที่เส้นตรงที่ผ่านจุด (0,1) แสดงให้เห็นว่าแบบจำลองทำนายผลผิดกว่าการสุ่ม ตามภาพประกอบ 5



ภาพประกอบ 5 ROC Curve

ที่มา: Berrar & Flach (2012)

## 2. งานวิจัยที่เกี่ยวข้อง

### 2.1 บทความวิจัยเรื่อง Mango Classification System Uses Image Processing Technology and Artificial Intelligence

บทความกล่าวถึงเรื่อง การจำแนกประเภทมะม่วงในเวียดนามและทั่วโลก โดยการจำแนกประเภทนี้สามารถช่วยให้เกษตรกรประหยัดเวลาและต้นทุนในการคัดแยกมะม่วง โดยใช้วิธีการแบ่งกลุ่มหรือ Classification ตามสี ขนาด และปริมาณ โดยใช้ SVM และ RGB-D ในการจำแนก และทดสอบการใช้ ANN ในการจำแนกด้วยวิธีการจำแนกประเภทมะม่วงในเวียดนามและทั่วโลกโดยการใช้แรงงานโดยตรงของเกษตรกรมีปัญหาเนื่องจากการสังเกตผลไม้อาจใช้เวลานานและมีประสิทธิภาพน้อย การใช้เครื่องจักรที่ไม่เฉพาะทางให้ผลผลิตไม่สูงและต้นทุนสูง ดังนั้นการสร้างระบบที่สามารถจำแนกมะม่วงในด้านสี ปริมาตร ขนาด รูปร่าง และความหนาแน่นของผลไม้อาจเป็นเป้าหมายของการศึกษา ดังนั้น ผู้วิจัยใช้ SVM และ RGB-D ในการคัดแยกประเภทมะม่วง โดย SVM ใช้ในการคัดแยกประเภทตามสี ขนาด และปริมาณ ส่วน RGB-D ใช้ในการจำแนกตามขนาด และรูปร่าง และทดสอบการใช้ ANN ในการจำแนกด้วย โดยผลการทดสอบจากการเก็บรวบรวมค่าทางสถิติผ่านทาง SPSS software (N. D. Thong et al., 2019)

### 2.2 บทความวิจัยเรื่อง Classification of Fruits using Convolutional Neural Networks

บทความกล่าวถึงเรื่อง การจำแนกประเภทผลไม้และการตรวจจับโรคในฟาร์มเกษตรอัจฉริยะ ซึ่งในการจำแนกประเภทของผลไม้มีความสำคัญทั้งในองค์กรอุตสาหกรรมรวมถึงโรงงานซูเปอร์มาร์เก็ตและสถานที่อื่นๆ ซึ่งการจำแนกประเภทผลไม้ยังสำคัญต่อผู้ที่ต้องการรับประทานผลไม้ตามความต้องการพิเศษ เช่น ผู้ที่ต้องการรับประทานผลไม้ที่เหมาะสมกับสุขภาพ เป็นต้น โดยงานวิจัยในการจำแนกประเภทของผลไม้ มีการใช้แบบจำลอง Convolution Neural Networks (CNN) และได้ข้อมูลชุดข้อมูลที่มีผลไม้หลากหลายซึ่งมีจำนวนชุดข้อมูลทั้งหมด 90,380 ภาพ และแบ่งออกเป็น 131 ชนิดทั้งผลไม้และผัก และได้แบ่งจำนวนของชุดการฝึกฝน และการทดลองออกเป็นร้อยละ 80 และร้อยละ 20 ตามลำดับ โดยหลังจากการวิเคราะห์อย่างละเอียดด้วยการแยกตัวอย่างและการจัดกลุ่มรูปภาพ การใช้ CNN ให้ค่าความแม่นยำดีกว่าแบบจำลองอื่นๆ ผลงานของเราเน้นไปที่การจัดหมวดหมู่ผลไม้ต่างๆ แบบจำลอง CNN ให้ค่าความแม่นยำได้ถึงร้อยละ 98 (Raut et al., 2022)

### 2.3 บทความวิจัยเรื่อง Detecting Mango Fruits by using Randomized Hough Transform and Backpropagation Neural Network

บทความกล่าวถึงเรื่อง วิธีการใหม่ในการตรวจจับผลมะม่วงจากภาพ คือการใช้รูปทรงมะม่วงรูปไข่ในวิธีการตรวจจับ วิธีการนี้ขึ้นอยู่กับตัวดำเนินการประมวลผลล่วงหน้าบนภาพ ได้แก่ การแปลงเป็นภาพสีเทา การหาขอบ การคำนวณระยะห่างถึงขอบ การเปิดสัณฐานวิทยา และการแปลงเป็นภาพสีไบนารี โดยมีขั้นตอนดำเนินการประมวลผลล่วงหน้าและปรับภาพอินพุตให้เป็นมาตรฐาน จากนั้นปรับรูปร่างซึ่งอาจจะบวมมะม่วงในภาพอินพุต ขั้นตอนสุดท้ายคือการตรวจสอบภาพในแต่ละภาพ ซึ่งงานวิจัยได้ใช้โครงข่ายประสาทเทียม และมีการใช้ชุดข้อมูลจำนวน 50 ภาพที่ถ่ายด้วยดิจิตอล ใช้กล้องที่มีความละเอียด 12 ล้านพิกเซล และทุกภาพถูกแปลงเป็นขนาด 430 x 320 พิกเซล อัตราการตรวจจับสูงถึงร้อยละ 96 ในขณะที่ลดลงในกรณีที่มีความซับซ้อนกัน (Nanaa et al., 2014)

### 2.4 บทความวิจัยเรื่อง Classification and Grading of Harvested Mangoes Using Convolutional Neural Network

บทความกล่าวถึงเรื่อง การจำแนกผลไม้โดยอัตโนมัติเป็นประเภทต่างๆ ตามคุณภาพ และพันธุ์ เทคนิคการประมวลผลภาพต่างๆ และตัวแยกประเภทการเรียนรู้ของเครื่อง เช่น Support Vector Machine, ตัวแยกประเภทเพื่อนบ้านที่ใกล้ที่สุด K และเครือข่ายประสาทเทียม ใช้สำหรับระบบการจำแนกผลไม้อัตโนมัติ ส่วนนี้ประกอบด้วยกรอบทบทวนวรรณกรรมสำหรับการจำแนกและการคัดขนาดมะม่วง และตามคุณลักษณะด้านคุณภาพ เช่น สี ขนาด รูปร่าง และเนื้อสัมผัส ซึ่งมีการใช้จำนวน 2,400 ภาพ ซึ่งมีการใช้เทคนิคการเรียนรู้ของเรื่อง ได้แก่ CNN, ANN, VGG, ResNet และ Inception v3 โดยจากการทดสอบแบบจำลองต่างๆ จึงได้ค่าความแม่นยำในการจำแนกประเภทสูงถึงร้อยละ 99 ร้อยละ 97 ตามลำดับ โดยแบบจำลองที่สามารถทำงานได้ดีที่สุดคือ Inception v3 (Rizwan Iqbal & Hakim, 2022)

### 2.5 บทความวิจัยเรื่อง Pure-CNN: A Framework for Fruit Images Classification

บทความกล่าวถึงเรื่อง การจัดหมวดหมู่ภาพผลไม้โดยใช้ Pure Convolutional Neural Network (PCNN) ด้วย Global Average Pooling (GAP) พบว่าการใช้เลเยอร์ GAP สามารถแก้ปัญหาเรื่องการ Overfitting และได้ประเมินค่าความถูกต้องในการจำแนกข้อมูล จากการข้อมูลจาก Fruit-360 ประกอบไปด้วยภาพผลไม้จำนวน 81 หมวดและผลไม้ชนิดเดียวกัน หลังการทดลองได้ค่าความแม่นยำร้อยละ 98 แต่เมื่อใช้ PCNN กับชั้น GAP ทำให้สามารถจำแนกวัตถุ

และจำแนกภาพได้หลายระดับซึ่งดีกว่าการใช้เพียง PCNN เท่านั้น โดยใช้เวลาในการทำนายน้อยที่สุด 20.02 วินาที ในส่วนของ CNN และ Fully Connected Layer ให้ค่าความแม่นยำร้อยละ 97 และใช้เวลาในการคำนวณที่ 20.89 วินาที (Kausar et al., 2018)

## 2.6 บทความวิจัยเรื่อง Optimizing Convolutional Neural Network Performance by Mitigating Underfitting and Overfitting

บทความกล่าวถึงเรื่อง บทความเกี่ยวกับ การจำแนกสมาชิกในการแข่งขันซึ่งมีการเก็บภาพถ่ายจากกล้องด้วยความถี่ 30 ภาพต่อวินาที รวมเป็นชุดข้อมูลทั้งหมด 21,996 ภาพ และมีความละเอียดอยู่ที่ 224x224 พิกเซล โดยแบ่งชุดข้อมูลเป็น 2 ชุด ได้แก่ ชุดข้อมูลฝึกฝนจำนวนร้อยละ 80 และชุดข้อมูลทดสอบจำนวนร้อยละ 20 ตามลำดับ จากการเก็บรวบรวมชุดข้อมูลนั้น จึงได้ใช้แบบจำลอง Convolutional Neural Network (CNN) และใช้อัลกอริทึม Stochastic Gradient Descent (SGD) และอัลกอริทึม Root Mean Square Propagation (RMSProp) ทั้งนี้ยังมีการปรับแต่งทั้งในส่วนของอัตราค่าการเรียนรู้ของอัลกอริทึม (Learning rate) และค่ามาตรฐานของแบบจำลอง (Regularization) ได้แก่ Dropout, Batch Normalization, Weight Matrix Initialization และ Data Augmentation Method ได้เพิ่มความสามารถในการทั่วไปของแบบจำลองในสองด้านคือการปรับปรุง Underfitting และ Overfitting ของแบบจำลอง และอัตราความแม่นยำของแบบจำลองได้ถูกเพิ่มจากร้อยละ 89 เป็นร้อยละ 93 (Li et al., 2021)

## 2.7 บทความวิจัยเรื่อง Fruit Recognition and Classification with Deep Learning Support on Embedded System (Fruitnet)

บทความกล่าวถึงเรื่อง การจำแนกผลไม้โดยใช้การประมวลผลภาพ ซึ่งในการศึกษานี้ มีกระบวนการจัดหมวดหมู่ Convolutional Neural Networks (ConNN) มาทำแบบจำลองการเรียนรู้เชิงลึก แบบจำลองที่เสนอได้รับการพัฒนาบนแพลตฟอร์ม Keras เพื่อให้เกิดการศึกษาในชีวิตจริง มีการทดสอบผลไม้ 20 ชนิดในชุดข้อมูลที่ต่างกัน 2 ชุด โดยมีการแบ่งชุดข้อมูลในอัตรา ร้อยละ 80 และร้อยละ 20 ตามลำดับ โดยเป็นชุดข้อมูลมาจาก Fruit-360 และมีการใช้อัลกอริทึม ได้แก่ SGD, Adam และ RMSprop โดยผลลัพธ์ที่ออกมา นั้นอัลกอริทึมที่มีค่าความแม่นยำในการทำนายได้ดีที่สุด คืออัลกอริทึม Adam, RMSprop และ SGD ตามลำดับ (Unal et al., 2020)

## 2.8 บทความวิจัยเรื่อง Deep Convolutional Neural Networks for plane identification on Satellite imagery by exploiting transfer learning with a different optimizer

บทความกล่าวถึงเรื่อง การตรวจจับเครื่องบินจากภาพถ่ายดาวเทียม เพื่อสามารถนำไปใช้ในการจราจรทางอากาศ การตรวจสอบสนามบิน รวมทั้งประเด็นข่าวกรองด้านกลาโหม โดยใช้ Convolutional Neural Networks (CNN) เพื่อจำแนกและตรวจจับตำแหน่งของเครื่องบิน โดยมีการเก็บข้อมูลจากภาพถ่ายทางดาวเทียมแบ่งออกเป็น ชุดภาพที่มีเครื่องบินจำนวน 24,000 ภาพ ซึ่งแสดงในส่วนของลำเครื่องบิน ปีก หาง และส่วนที่บ่งบอกลักษณะเด่นของเครื่องบิน โดยชุดข้อมูลจะมีทั้งในส่วนของเครื่องบินและประกอบไปด้วยสภาพแวดล้อมอื่นๆ เช่น น้ำ พืช อาคาร เป็นต้น อีกจำนวน 23,995 ภาพ โดยแบ่งชุดข้อมูลออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลฝึกฝนร้อยละ 90 และชุดข้อมูลทดสอบร้อยละ 10 ตามลำดับ โดยการทดลองนี้ได้อัลกอริทึมเพื่อเพิ่มประสิทธิภาพ ได้แก่ Stochastic Gradient Descent (SGD), Adam Optimizer และเครื่องมือเพิ่มประสิทธิภาพ PowerSign และ AddSign โดยผลลัพธ์ที่ออกมาที่อัลกอริทึม Adam ให้ค่าความแม่นยำสูงสุดร้อยละ 92 รองลงมาเป็นอัลกอริทึม PowerSign มีค่าความแม่นยำร้อยละ 84 อัลกอริทึม SGD มีค่าความแม่นยำร้อยละ 83 และอัลกอริทึม AddSign มีค่าความแม่นยำร้อยละ 82.9 ตามลำดับ (Kamsing et al., 2019)

## 2.9 บทความวิจัยเรื่อง Comprehensive Study for Diabetes Identification Ability of Various Optimizers in Deep Learning Neural Network

บทความกล่าวถึงเรื่อง การตรวจสอบและจำแนกโรคเบาหวาน (Diabetes) ซึ่งเป็นปัญหาสุขภาพสาธารณะที่ใหญ่ในโลก โดยที่การตรวจพบโรคเบาหวานอย่างแม่นยำจึงมีความสำคัญมาก เนื่องจากโรคเบาหวานเป็นสาเหตุของอาการหัวใจขาดเลือด อัมพาต ความเสียหายที่ไต ตา และเส้นประสาท เป็นต้น ในปัจจุบันนี้ มีนักวิจัยหลายคนที่มีหวังจะใช้เทคนิค AI เพื่อช่วยจำแนกโรคเบาหวาน ในงานวิจัยนี้ได้ค้นพบว่า Deep Learning Neural Network ที่ปรับแต่งด้วยอัลกอริทึมต่างๆ เช่น Adam, SGD, RMSprop, และ Adagrad สามารถช่วยในการจำแนกโรคเบาหวานได้อย่างแม่นยำ โดยการใช้ Stratified 5-fold Cross-validation เพื่อเรียนรู้แบบจำลองจาก Pima Indian Diabetes Dataset (PIDDD) ซึ่งเป็นชุดข้อมูลที่ไม่สมดุล ผลการทดสอบแสดงว่าอัลกอริทึมที่ดีที่สุดสำหรับการจำแนกโรคเบาหวานคืออัลกอริทึม Adam และอัลกอริทึม AdaGrad มีผลลัพธ์ที่ต่ำที่สุด (Chandrasekara et al., 2021)



## 2.10 บทความวิจัยเรื่อง Images Classification Modelling of Beef and Pork Using Convolutional Neural Network

บทความกล่าวถึงเรื่อง การจำแนกเนื้อหมูและเนื้อวัว มาจากความแตกต่างระหว่างเนื้อหมูและเนื้อวัวนั้นมาจากสีและเนื้อสัมผัสของเนื้อสัตว์ งานวิจัยนี้จึงเลือก แบบจำลอง Convolutional Neural Network (CNN) เป็นวิธีการเรียนรู้เชิงลึก (Deep Learning) และมีการปรับค่า Dropout, L2 และ Max-Norm ถูกนำไปใช้กับแบบจำลองและเปรียบเทียบเพื่อให้ได้ผลการจำแนกประเภทที่ดีที่สุดและอาจทำนายข้อมูลใหม่ได้อย่างแม่นยำ จึงได้ค่าความแม่นยำร้อยละ 97 จากแบบจำลอง CNN โดยใช้ปรับค่า Dropout อยู่ที่ 0.7, ฟังก์ชันการเปิดใช้งาน ReLu และเพิ่มชั้นเลเยอร์เป็น 3 ชั้น จากการทดลองพบว่าอัตราข้อผิดพลาดของแบบจำลองอยู่ที่ร้อยละ 11.1 (Fitrianto & Sartono, 2021)

## 2.11 บทความวิจัยเรื่อง IMPROVING DEEP NEURAL NETWORKS BY USING SPARSE DROPOUT STRATEGY

บทความกล่าวถึงเรื่อง บทความกล่าวถึงเรื่อง การเสนอกลยุทธ์ในการปรับใช้การออกกลางคัน (Dropout) จากการใช้แบบจำลอง Convolutional Neural Networks (CNN) โดยมีการใช้ชุดข้อมูล TIMIT สำหรับงานการจดจำโทรศัพท์ โดยมีการปรับปรุงสำหรับโครงข่ายประสาทเทียมระดับลึกโดยปฏิบัติต่อหน่วยต่างๆ ตามผลลัพธ์ วิธีการที่เสนอนี้เรียกว่าการปรับแต่งแบบละเอียดกลางคันแบบเบาบาง การทดลองเกี่ยวกับงานการจดจำโทรศัพท์แสดงถึงวิธีที่มีการปรับปรุงประสิทธิภาพการทำงานอย่างมาก การคำนวณสำหรับการเผยแพร่ที่ใช้ในงานวิจัยคือ EQUATION  $x(l) = \text{dropout}(y(l), p)$   $2 \leq l \leq L$  และผลการทดลองเกี่ยวกับงานการจดจำโทรศัพท์หลังจากที่มีการปรับปรุงพารามิเตอร์ต่างๆ ทำให้ประสิทธิภาพของแบบจำลองในการทำนายมีเพิ่มขึ้น โดยในกลยุทธ์นี้ส่งผลให้หน่วยเอาต์พุตกระจายตัวมากขึ้นและลดอัตราข้อผิดพลาดของโทรศัพท์ การกระจายของเอาต์พุตของหน่วยที่ซ่อนอยู่แสดงให้เห็นว่าผลลัพธ์ของหน่วยที่ใช้กลยุทธ์การออกกลางคันแบบกระจายตัวมีแนวโน้มที่จะเกือบเป็นศูนย์และไม่สมดุลมากขึ้น (Zheng et al., 2014)

## 2.12 บทความวิจัยเรื่อง Transfer learning considering the impact of data augmentation on each layer of the source model

บทความกล่าวถึงเรื่อง การจัดการหมวดหมู่รูปภาพ จากแบบจำลองการเรียนรู้เชิงลึกของเครือข่ายประสาทเทียม (CNN) สำหรับการจำแนกภาพ และชุดข้อมูลที่มีความซับซ้อนและ

จำนวนมาก เพื่อให้ได้ประสิทธิภาพที่สูงที่สุดและดีที่สุด โดยจากการทดลองได้มีการปรับลดชั้นรูปแบบการเรียนรู้เชิงลึก ในการเปรียบเทียบการปรับแต่งชุดข้อมูลด้วยเทคนิคต่างๆ โดยสรุปได้ว่าการเสริมพารามิเตอร์และข้อมูลมีผลต่อสมรรถนะของแบบจำลอง และผลกระทบต่างๆ กันไปตามชั้นต่างๆ วิธีการที่เสนอให้บรรลุประสิทธิภาพที่ดีกว่าวิธีการเรียนรู้การถ่ายโอนแบบดั้งเดิม การศึกษายังระบุถึงวิธีการเสริมข้อมูลที่มีประสิทธิภาพเพิ่มขึ้นสำหรับแต่ละชั้นของแบบจำลอง (Kuroda T et al., 2022)

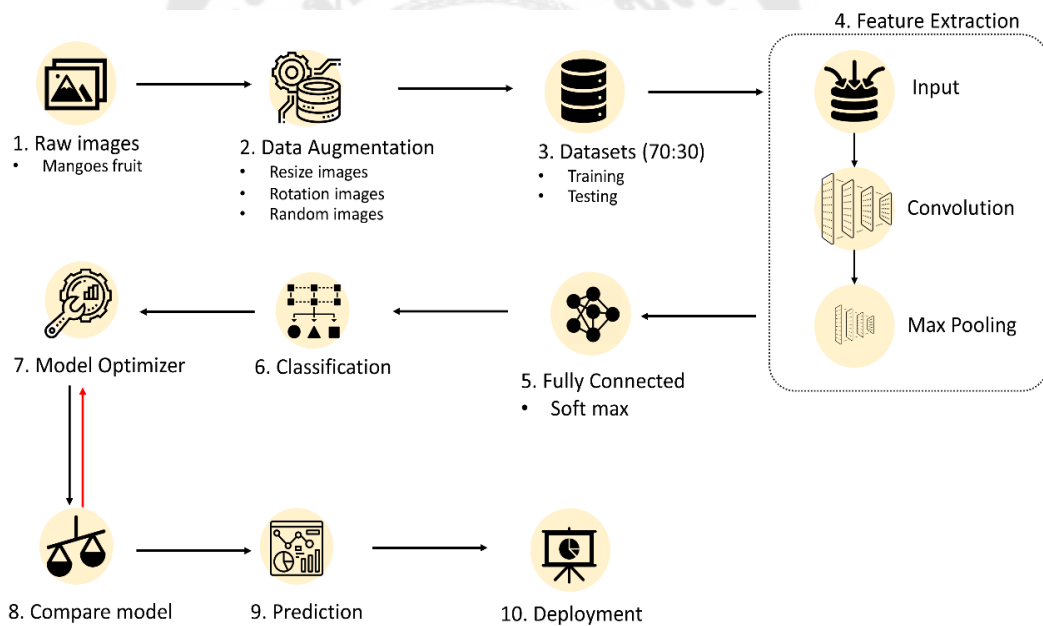
อย่างไรก็ตาม บทที่ 2 การทบทวนวรรณกรรมเป็นการทบทวนทฤษฎีที่เกี่ยวข้องกับงานวิจัย รวมทั้งงานวิจัยจากแหล่งต่างๆ เพื่อนำมาประยุกต์ใช้ และต่อยอดงานวิจัยนี้ให้เกิดประสิทธิภาพเพิ่มมากขึ้น ซึ่งวิธีการดำเนินการวิจัยอาจจะมีข้อด้อยในงานวิจัยที่เกี่ยวข้องบางส่วน โดยในบทที่ 3 ในวิธีการดำเนินการวิจัยจะกล่าวถึงภาพรวม และรายละเอียดในเรื่องกระบวนการสร้างแบบจำลอง การสำรวจข้อมูล การจัดเตรียมข้อมูล การปรับแต่งข้อมูล และการสร้างแบบจำลอง

### บทที่ 3 วิธีการดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

1. กระบวนการในการสร้างแบบจำลอง
2. การสำรวจข้อมูล
3. การเตรียมข้อมูล
4. การเสริมข้อมูล
5. การสร้างแบบจำลอง

#### 1. กระบวนการในการสร้างแบบจำลอง



ภาพประกอบ 6 แผนผังกระบวนการในการสร้างแบบจำลอง

จากภาพประกอบ 6 แผนผังกระบวนการสร้างแบบจำลอง งานวิจัยนี้เป็นงานวิจัยที่ศึกษาการแบ่งแยกพันธุ์ของมะม่วงในประเทศไทยทั้ง 4 สายพันธุ์ด้วยการเรียนรู้ของเครื่อง โดยดำเนินการตั้งแต่การเก็บรวบรวมภาพสำหรับการทำวิจัย โดยการถ่ายภาพเดี่ยวในลักษณะ 360 องศาในพื้นที่หลังสีขาวทั้งหมด จากนั้นดำเนินการสำรวจข้อมูล (Exploratory data analysis: EDA) ถึงจำนวนภาพมะม่วงทั้งหมด และนำไปสู่การดำเนินการทำความเข้าใจข้อมูล และจัดเตรียม

ข้อมูลก่อนดำเนินการทำแบบจำลอง โดยในงานวิจัยนี้ได้ดำเนินการปรับเปลี่ยนขนาดภาพจากขนาด 4,000 x 6,000 พิกเซล เป็น 100 x 100 พิกเซล และได้ดำเนินการเลือกชุดข้อมูลฝึกฝนในอัตราส่วนร้อยละ 80 และ 20 ตามลำดับ ซึ่งในการแบ่งชุดข้อมูลของทั้งสองกลุ่มนี้เป็นการแบ่งแยกภาพมะม่วงแต่ละผลออกจากกัน แล้วจึงนำไปสู่การ Feature Exaction จนถึงการจัดจำแนกข้อมูลในแต่ละพันธุ์ออก เพื่อทำแบบจำลองและสร้างการเรียนรู้ของแบบจำลอง และประเมินผลลัพธ์ของแบบจำลองด้วยการวัดประสิทธิภาพ

## 2. การสำรวจข้อมูล (Exploratory Data Analysis: EDA)

ภาพที่นำมาใช้ในงานวิจัย เป็นภาพที่มาจากการเก็บรวบรวมถ่ายภาพเดี่ยวในลักษณะ 360 องศา โดยมีพื้นหลังสีขาว ขนาดของภาพจะอยู่ที่ 4,000 x 6,000 พิกเซล ซึ่งการเก็บภาพของมะม่วงมาจากการแยกแต่ละผลของมะม่วงแต่ละสายพันธุ์ เพื่อป้องกันการเกิด Underfitting หรือการให้แบบจำลองสามารถทำนายผลเป็นจริงทั้งหมด ดังนั้นชุดข้อมูลประกอบด้วยมะม่วงของไทยทั้งหมด 4 สายพันธุ์ มีจำนวนภาพรวมทั้งหมด 492 ภาพ และมะม่วงจากสายพันธุ์ต่างประเทศจำนวน 123 ภาพ จากนั้นทำการจัดประเภทเป็น 5 ประเภทแยกตามสายพันธุ์ หรือเรียกว่า Class (Label) ซึ่งจำแนกชุดข้อมูลตามตารางที่ 3 ดังนี้

ตาราง 3 จำนวนข้อมูลภาพมะม่วงทั้ง 4 สายพันธุ์ของไทย และมะม่วงพันธุ์ต่างประเทศ

Label	Number of Training Images	Number of Test Images
Keawkramin	98	25
Khiaosawoey	98	25
Namdokmai	98	25
Namdokmai Srithong	98	25
Not Thai mangoes	98	25

จากการนำข้อมูลภาพมะม่วงของประเทศไทยทั้ง 4 สายพันธุ์ และผลไม้ชนิดอื่นๆ มาทำการสำรวจข้อมูล (Exploratory data analysis: EDA) จากการเลือกภาพมะม่วงของประเทศไทย 4

สายพันธุ์ที่ใช้ในชุดข้อมูลฝึกฝน (Training data) และมะม่วงสายพันธุ์ต่างประเทศใช้ในชุดข้อมูลทดสอบ (Testing data) ดังภาพประกอบที่ 7 และ 8



ภาพประกอบ 7 ตัวอย่างข้อมูลภาพที่เป็นมะม่วงสายพันธุ์ของประเทศไทยทั้ง 4 สายพันธุ์



ภาพประกอบ 8 ตัวอย่างข้อมูลภาพที่เป็นมะม่วงสายพันธุ์ของต่างประเทศ

### 3. การเตรียมข้อมูล (Data Preprocessing)

ในงานวิจัยนี้มีกระบวนการในการจัดเตรียมข้อมูล แบ่งออกเป็น 3 ขั้นตอน ได้แก่

3.1 ภาพมะม่วงแต่ละสายพันธุ์ของไทยจำนวน 492 ภาพ โดยประกอบด้วยมะม่วงสายพันธุ์แก้วเขียว เขียวเสวย น้ำดอกไม้ และน้ำดอกไม้สีทอง ทั้งยังได้นำภาพมะม่วงจากสายพันธุ์ต่างประเทศจำนวน 123 ภาพมาทำการทดลองแบบจำลองในครั้งนี้ ซึ่งภาพมะม่วงจะแบ่งเป็น 2 ชุด คือชุดข้อมูลฝึกฝน และชุดข้อมูลทดสอบ โดยชุดภาพทั้ง 2 ส่วนมาจากมะม่วงที่ไม่ใช่ผลเดียวกัน

3.2 การลดขนาดภาพจาก 4,000 x 6,000 พิกเซล เป็น 100 x 100 พิกเซล

3.3 การแยกภาพมะม่วงทั้ง 4 สายพันธุ์ของไทย และสายพันธุ์จากต่างประเทศ โดยสุ่มภาพแยกเป็นชุดข้อมูลการฝึกฝน (Training data) และชุดข้อมูลแบบทดสอบ (Testing data) ออกเป็นร้อยละ 80 และร้อยละ 20 ตามลำดับ

### 4. การเสริมข้อมูล (Data Augmentation)

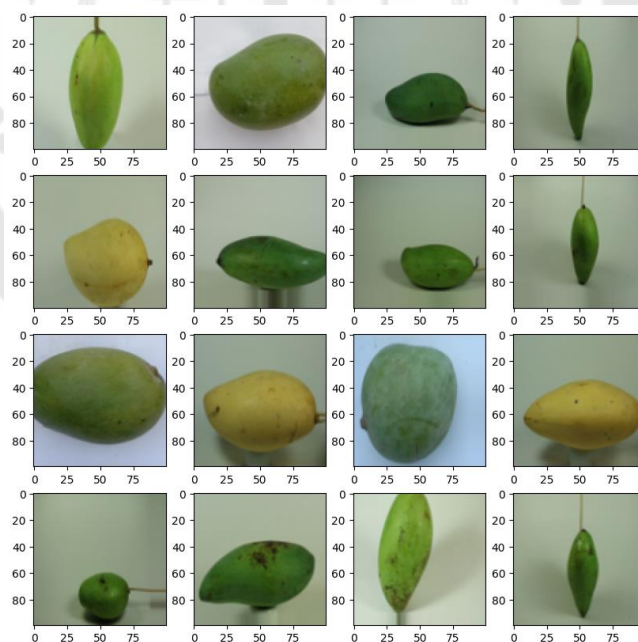
การเสริมข้อมูลของภาพ ในงานวิจัยนี้ได้ใช้เทคนิคการสุ่มการปรับขนาดของภาพชุดข้อมูลการฝึกฝน (Training Data) โดยมีการปรับเปลี่ยนภาพจากหลากหลายตัวแปร เพื่อให้แบบจำลองมีความแม่นยำมากยิ่งขึ้น ซึ่งการปรับเปลี่ยนภาพ ดังตารางที่ 4 ต่อไปนี้

ตาราง 4 พารามิเตอร์ที่ใช้ในการทำการปรับเสริมข้อมูล

Parameter	Value	Description
Rotation	0.05	การสุ่มค่าหมุนของภาพด้วยมุมที่สุ่มได้ในช่วง -0.05 ถึง +0.05 แสดงว่าภาพสามารถหมุนได้โดยไม่เกิน 0.05 หรือประมาณ 3 องศา
Zoom	0.2	การสุ่มค่าการขยายขนาดของภาพด้วยค่าสุ่มที่ไม่เกิน 0.2 แสดงว่าภาพสามารถซูมได้โดยไม่เกิน 0.2 เท่าของขนาดภาพ

ตาราง 4 (ต่อ)

Parameter	Value	Description
Width shift	0.1	การสุ้มค่าตำแหน่งของภาพแนวนอนด้วยค่าสุ้มที่ไม่เกิน 0.1 แสดงว่าภาพสามารถเลื่อนตำแหน่งได้โดยไม่เกิน 10% ของความกว้างของภาพ
Hight shift	0.1	การสุ้มค่าตำแหน่งของภาพแนวตั้งด้วยค่าสุ้มที่ไม่เกิน 0.1 แสดงว่าภาพสามารถเลื่อนตำแหน่งได้โดยไม่เกิน 10% ของความสูงของภาพ
Shear	0.05	การสุ้มค่าการเอียงภาพด้วยมุมที่สุ้มได้ในช่วง -0.05 ถึง +0.05 แสดงว่าภาพสามารถเอียงได้โดยไม่เกิน 0.05 หรือประมาณ 3 องศา



ภาพประกอบ 9 ตัวอย่างข้อมูลภาพหลังจากใช้เทคนิคการเสริมข้อมูล

## 5. การสร้างแบบจำลอง (Model Creation)

ผู้วิจัยได้สร้างแบบจำลองในการคัดแยกสายพันธุ์มะม่วงของไทยทั้งหมด 16 แบบจำลอง โดยการใช้เทคนิคการเรียนรู้ของเครื่อง ได้แก่ แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) และยังสามารถทำการปรับเปลี่ยนภาพระหว่างการเรียนรู้ของแบบจำลอง มีการกำหนดไฮเปอร์พารามิเตอร์ต่างๆ เช่น การกำหนดจำนวนรอบในการหยุดเทรนแบบจำลองหากไม่มีการปรับปรุง การนำเทคนิคการปรับเสริมข้อมูลภาพ และการกำหนดอัตราการเรียนรู้ของแบบจำลอง การกำหนดค่าเพื่อลด Overfitting ตลอดจนการนำอัลกอริทึมทั้ง Adam และ RMSprop เข้ามาใช้เพื่อให้ทิศทางการทำนายมีประสิทธิภาพเพิ่มขึ้น และได้นำการเปรียบเทียบประสิทธิภาพของเทคนิคทั้งค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความถูกต้องของการทำนายว่าเป็นจริง (Recall) ค่าเฉลี่ยที่วัดความสามารถของแบบจำลอง (F1-Score Macro Average) และพื้นที่ใต้โค้ง ROC โดยในงานวิจัยนี้ได้ทำการทดลองที่กำหนดขนาดการทดลองอยู่ที่ 128 Batch Size และกำหนดจำนวนรอบสูงสุดอยู่ที่ 500 รอบ แต่มีการกำหนดการหยุดรอบที่ไม่สามารถเรียนรู้ได้ที่ 20 รอบ รวมทั้งการปรับเสริมข้อมูลภาพ และการเปรียบเทียบอัตราการเรียนรู้ของแบบจำลอง โดยแบ่งการทดลองออกเป็นเทคนิคละ 8 แบบการทดลอง นอกจากนี้ยังมีการกำหนดไฮเปอร์พารามิเตอร์ต่างๆ ที่ใช้ในการสร้างแบบจำลองการคัดแยกมะม่วงแต่ละสายพันธุ์ตามตารางที่ 5 และการกำหนดการทดลองในแต่ละแบบจำลองตามตารางที่ 6 ดังนี้

ตาราง 5 ไฮเปอร์พารามิเตอร์ที่ใช้ในการสร้างแบบจำลอง

Hyperparameter	Value
ขนาดของภาพ (Images size)	100 x 100 pixels
จำนวนน้ำหนัก (Weight)	ImageNet เป็น Transfer learning
กำหนด Fully-Connected layer (Include top)	False คือกำหนดให้ไม่รวม Fully Connected layer



ตาราง 5 (ต่อ)

Hyperparameter	Value
รูปแบบการทำ Feature Extraction (Pooling)	Average เป็นค่าเฉลี่ยในการดึงรูปภาพ ประยุกต์ใช้ผลลัพธ์ 2 มิติ
จำนวนรอบในการทดลอง (Epochs)	กำหนดจำนวนรอบสูงสุดที่ 500 รอบ ที่มีการ กำหนดจำนวน 20 รอบหากการเทรน แบบจำลองไม่มีการปรับปรุง
ขนาดของการเทรนแบบจำลอง (Batch size)	กำหนดเป็น 128 สำหรับในการเทรน แบบจำลอง
อัตราการเรียนของแบบจำลอง (Learning rate)	กำหนดเป็นค่าคงที่ 0.001 แต่มีการทดลองโดย ปรับค่าเป็น 0.0001

ตาราง 6 ข้อมูลแบบจำลองที่ใช้ในงานวิจัย

Number of models	Deep Learning	Optimizer	Data Augmentation	Learning rate
1	CNN	Adam	No	0.001
2	CNN	Adam	Yes	0.001
3	CNN	Adam	No	0.0001
4	CNN	Adam	Yes	0.0001
5	CNN	RMSProp	No	0.001
6	CNN	RMSProp	Yes	0.001
7	CNN	RMSProp	No	0.0001
8	CNN	RMSProp	Yes	0.0001
9	VGG	Adam	No	0.001
10	VGG	Adam	Yes	0.001

ตาราง 6 (ต่อ)

Number of models	Deep Learning	Optimizer	Data Augmentation	Learning rate
11	VGG	Adam	No	0.0001
12	VGG	Adam	Yes	0.0001
13	VGG	RMSProp	No	0.001
14	VGG	RMSProp	Yes	0.001
15	VGG	RMSProp	No	0.0001
16	VGG	RMSProp	Yes	0.0001

ในงานวิจัยนี้ได้มีการทดลองปรับค่าอัตราการเรียนรู้ของทั้ง 2 แบบจำลองหลัก และพบว่า การปรับอัตราการเรียนรู้ที่ 0.0001 จะทำให้แบบจำลองมีผลลัพธ์ที่ดีที่สุด

อย่างไรก็ตาม บทที่ 3 วิธีดำเนินการวิจัยมีการกล่าวถึงชุดข้อมูลในการสร้างแบบจำลอง และการเรียนรู้ของแบบจำลอง ยังมีการนำเทคนิคต่างๆ ที่ปรับใช้กับชุดข้อมูลโดยที่แบบจำลองสามารถดำเนินการได้โดยไม่ต้องเก็บภาพเพิ่มจากการเพิ่มเทคนิคต่างๆ โดยผลของการสร้างแบบจำลองในเบื้องต้นมีค่าความแม่นยำ และประสิทธิภาพของแบบจำลอง โดยในบทที่ 4 การทดลองจะมีการกล่าวถึงการเปรียบเทียบค่าความแม่นยำ และประสิทธิภาพของแบบจำลอง รวมทั้งเวลาในการทำงานของการเทรนแบบจำลองในแต่ละการทดลอง

## บทที่ 4

### การทดลอง


จากผลการทดลองพบว่าแบบจำลองการคัดแยกสายพันธุ์มะม่วงด้วยการเรียนรู้ของเครื่อง โดยการเทคนิคประมวลผลภาพที่หลากหลายและแยกประเภทการเรียนรู้ของเครื่อง ได้แก่แบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำกลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) จากการภาพชุดข้อมูลที่ทางผู้วิจัยได้ดำเนินการรวบรวมภาพมะม่วงสายพันธุ์ของไทยจำนวน 423 ภาพ ประกอบไปด้วย มะม่วงพันธุ์แก้วขมิ้นจำนวน 123 ภาพ มะม่วงพันธุ์เขียวเสวยจำนวน 123 ภาพ มะม่วงพันธุ์น้ำดอกไม้จำนวน 123 ภาพ มะม่วงพันธุ์น้ำดอกไม้สีทองจำนวน 123 ภาพ และชุดข้อมูลภาพจากต่างประเทศจำนวน 123 ภาพ รวมทั้งหมด 615 ภาพ โดยแบ่งชุดข้อมูลออกเป็น 2 ชุดข้อมูลคือ ชุดข้อมูลฝึกฝน และชุดข้อมูลทดสอบ โดยแบ่งในอัตราร้อยละ 80 และ 20 ตามลำดับ นอกจากนี้มีการใช้การปรับเสริมข้อมูลของชุดฝึกฝนให้มีความซับซ้อนของข้อมูล รวมทั้งนำอัลกอริทึมเพื่อใช้ในการเพิ่มประสิทธิภาพของแบบจำลองทั้ง 2 อัลกอริทึม ได้แก่ RMSProp และ Adam โดยมีการใช้อัตราการเรียนรู้ของแบบจำลองที่ 0.001 และ 0.0001

จากตารางที่ 7 และภาพประกอบ 10 เป็นการแสดงผลการทดลองของการใช้อัตราการเรียนรู้ของแบบจำลองที่ 0.0001 และการเปรียบเทียบการปรับเสริมข้อมูลของภาพ โดยแบบจำลองที่มีการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ มีค่าความถูกต้องของการทำนายได้ดีที่สุดร้อยละ 91 โดยการใช้อัลกอริทึม Adam และไม่มีการปรับเสริมข้อมูลภาพ แต่เมื่อเปรียบเทียบกับแบบจำลองของการนำกลุ่มภาพเรขาคณิต 16 มีค่าความถูกต้องของการทำนายได้ดีกว่าแบบจำลองก่อนหน้าร้อยละ 96 โดยการใช้อัลกอริทึม RMSProp และแบบปรับเสริมข้อมูล โดยทั้งสองแบบจำลองนี้กล่าวมานี้ มีการเปรียบเทียบเกี่ยวกับเวลาในการประมวลผล การคัดแยกพันธุ์มะม่วงเป็นหน่วยต่อภาพต่อวินาที แบบจำลองที่มีการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ ที่มีการใช้อัลกอริทึม Adam และไม่มีการปรับเสริมข้อมูลภาพ ใช้เวลาประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.0000003469257442 วินาที และแบบจำลองของการนำกลุ่มภาพเรขาคณิต 16 ที่มีการใช้อัลกอริทึม RMSProp และมีการปรับเสริมข้อมูลภาพ ใช้เวลาประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.000004909855215 วินาที อย่างไรก็ตามแบบจำลองของการนำกลุ่มภาพเรขาคณิต 16 มีการประมวลผลต่อภาพที่นานกว่า เพราะแบบจำลองมีความซับซ้อนและใช้เวลาในการประมวลผลภาพ

มากกว่าแบบจำลองก่อนหน้า เมื่อเปรียบเทียบกับแบบจำลองกลุ่มเรขาคณิต 16 แบบจำลองมีความถูกต้องของการทำนายน้อยลงมาอยู่ร้อยละ 94 โดยเป็นการใช้อัลกอริทึม Adam และไม่มี การปรับเสริมข้อมูลภาพ ซึ่งใช้เวลาในการประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.0000003331091347 วินาที แต่เมื่อพิจารณาจากค่าประสิทธิภาพของแบบจำลองทั้งหมดมีค่าเฉลี่ยอยู่ที่ 99.6

ตาราง 7 เปรียบเทียบผลการทดลองของแบบจำลองโดยการใช้ค่าคงที่ของอัตราการเรียนรู้ที่ 0.001

Model	Algorithm	Data Augmentation	Epochs	Accuracy	ROC	Run time (sec)
1. CNN	Adam	ไม่ปรับ	274	0.91	0.993	0.0000003469257442
2. CNN	Adam	ปรับ	222	0.89	0.999	0.0000002466703814
5. CNN	RMSProp	ไม่ปรับ	73	0.83	0.994	0.000004857807202
6. CNN	RMSProp	ปรับ	157	0.89	0.999	0.000003318527072
9. VGG	Adam	ไม่ปรับ	58	0.94	0.999	0.0000003331091347
10. VGG	Adam	ปรับ	120	0.87	0.998	0.0000003393871034
13. VGG	RMSProp	ไม่ปรับ	53	0.94	0.991	0.000005463356089
14. VGG	RMSProp	ปรับ	153	0.96	0.997	0.000004909855215



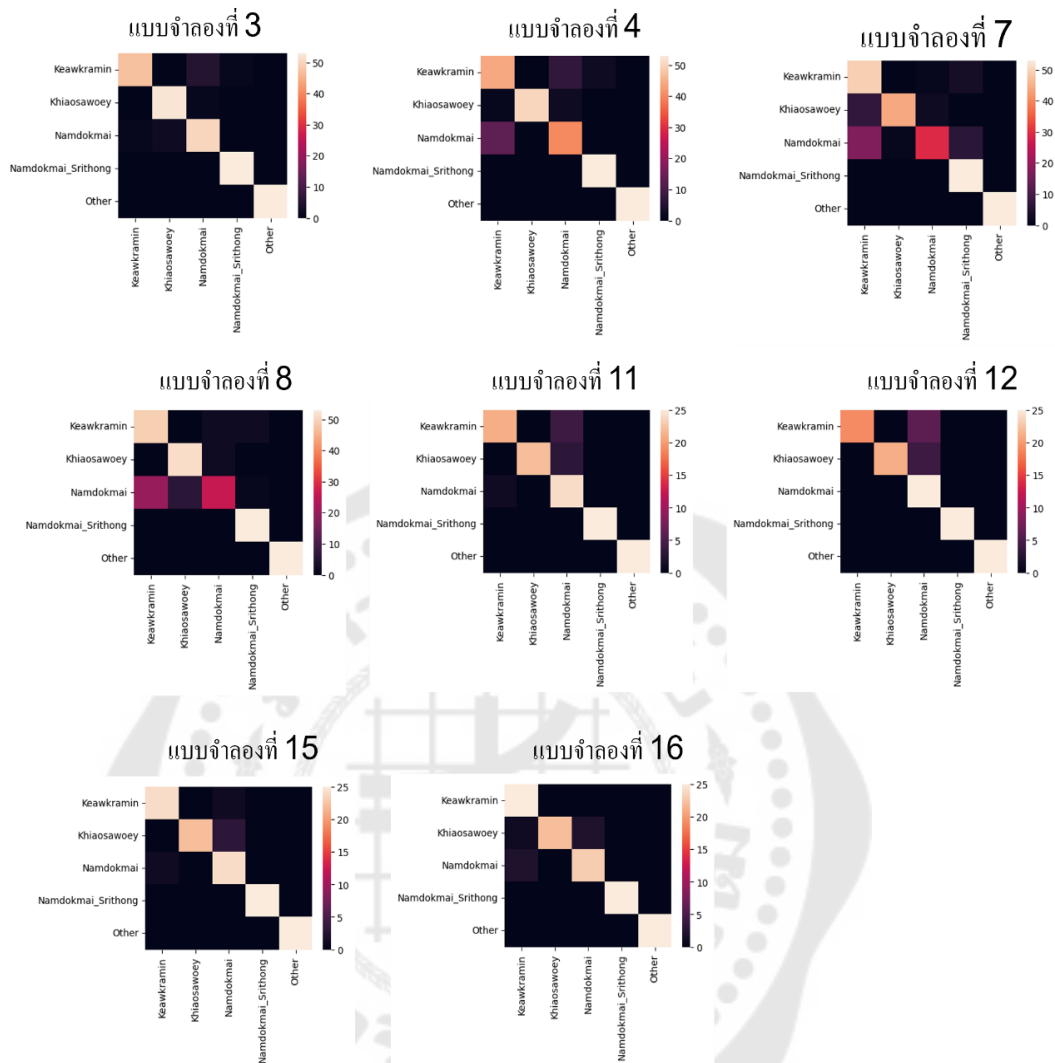
ภาพประกอบ 10 ภาพรวม Confusion Matrix ของแบบจำลองที่ใช้จัดการการเรียนรู้ของเครื่อง

และจากตารางที่ 8 และภาพประกอบ 11 เป็นการแสดงผลการทดลองของการใช้จัดการการเรียนรู้ของแบบจำลองที่ 0.0001 และการเปรียบเทียบการปรับเสริมข้อมูลของภาพ โดยแบบจำลองที่มีการใช้โครงข่ายประสาทเทียมแบบสังวัฒนา มีค่าความถูกต้องของการทำนายได้ดีที่สุดร้อยละ 96 โดยการใช้อัลกอริทึม Adam และไม่มีการปรับเสริมข้อมูลภาพ แต่เมื่อเปรียบเทียบกับแบบจำลองของการใช้กลุ่มภาพเรขาคณิต 16 มีค่าความถูกต้องของการทำนายได้ดีกว่าแบบจำลองก่อนหน้าร้อยละ 96 โดยการใช้อัลกอริทึม RMSProp และมีทั้งการแบบและไม่ปรับเสริมข้อมูล โดยทั้งสองแบบจำลองนี้กล่าวมานี้ มีการเปรียบเทียบเกี่ยวกับเวลาในการประมวลผลการตัดแยกพื้นภูมิระฆังเป็นหน่วยต่อภาพต่อวินาที แบบจำลองที่มีการใช้โครงข่ายประสาทเทียมแบบสังวัฒนา ที่มีการใช้อัลกอริทึม Adam และไม่มีการปรับเสริมข้อมูลภาพ ใช้เวลาประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.0000003578954347 วินาที และแบบจำลองของการใช้กลุ่มภาพเรขาคณิต 16 ที่มีการใช้อัลกอริทึม RMSProp และมีทั้งการแบบและไม่ปรับเสริมข้อมูลภาพใช้เวลาประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.000005029154393 วินาที และ 0.000005029154393 วินาที

ตามลำดับ อย่างไรก็ตามแบบจำลองของการใช้กลุ่มภาพเรขาคณิต 16 มีการประมวลผลต่อภาพที่นานกว่า เพราะแบบจำลองมีความซับซ้อนและใช้เวลาในการประมวลผลมากกว่าแบบจำลองก่อนหน้า เมื่อเปรียบเทียบกับแบบจำลองกลุ่มเรขาคณิต 16 แบบจำลองมีค่าความถูกต้องของการทำนายน้อยลงมาอยู่ร้อยละ 94 โดยเป็นการใช้อัลกอริทึม Adam และไม่มีการปรับเสริมข้อมูลภาพซึ่งใช้เวลาในการประมวลผลเฉลี่ยต่อภาพอยู่ที่ 0.0000003026190224 วินาที แต่เมื่อพิจารณาจากค่าประสิทธิภาพของแบบจำลองทั้งหมดมีค่าเฉลี่ยอยู่ที่ 99.6

ตาราง 8 เปรียบเทียบผลการทดลองของแบบจำลองโดยการใช้ค่าคงที่ของอัตราการเรียนรู้ที่ 0.0001

Model	Algorithm	Data Augmentation	Epochs	Accuracy	ROC	Run time (Sec)
3. CNN	Adam	ไม่ปรับ	431	0.96	0.998	0.0000003578954347
4. CNN	Adam	ปรับ	443	0.91	0.999	0.000000365511558
7. CNN	RMSProp	ไม่ปรับ	425	0.86	0.996	0.000004961527208
8. CNN	RMSProp	ปรับ	387	0.88	0.993	0.000005852301585
11. VGG	Adam	ไม่ปรับ	86	0.94	0.999	0.0000003026190224
12. VGG	Adam	ปรับ	113	0.92	0.996	0.0000003895504887
15. VGG	RMSProp	ไม่ปรับ	124	0.96	0.998	0.000005474704358
16. VGG	RMSProp	ปรับ	171	0.96	0.996	0.000005029154393



ภาพประกอบ 11 ภาพรวม Confusion Matrix ของแบบจำลองที่ปรับอัตราการเรียนรู้

หลังจากการประเมินประสิทธิภาพของแบบจำลองการคัดแยกสายพันธุ์มะม่วงด้วยการเรียนรู้ของเครื่อง โดยใช้เทคนิคการประมวลผลภาพที่หลากหลายและแยกประเภทการเรียนรู้ของเครื่องทั้งแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ด้วย Confusion Matrix แล้ว ผู้วิจัยได้วัดประสิทธิภาพของแบบจำลองทั้ง 16 แบบจำลองด้วยค่าความถูกต้อง (Accuracy), ค่า F1-Score, Macro Avg และค่าพื้นที่ใต้กราฟ (ROC) สรุปได้ว่าค่าความถูกต้องของแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ที่ไม่มีการปรับเสริมข้อมูลมีค่าใกล้เคียงกับแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียม

แบบสังวัตนาการ (Convolutional Neural Network) ที่ร้อยละ 96 แต่เมื่อเปรียบเทียบกับ การปรับ เสริมข้อมูลพบว่าแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ดีกว่าแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาท เทียมแบบสังวัตนาการ (Convolutional Neural Network) โดยมีค่าความถูกต้องร้อยละ 96, ค่า F1-Score, Macro Avg คือค่าเฉลี่ยของ Precision และ Recall ของทั้ง 5 คลาส ผลคือแบบจำลอง จำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) โดยการปรับอัตราการเรียนรู้นั้นดีกว่า แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำ ใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ที่ค่าความถูกต้องของการทำนาย ร้อยละ 96 และ 96 ตามลำดับ โดยหากเมื่อเปรียบเทียบการปรับเสริมข้อมูลของภาพของ แบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ค่าของ F1-Score และ Macro Avg ของการปรับเสริมข้อมูลมากกว่า ร้อยละ 96 และ 96 ตามลำดับ และสุดท้ายคือการวัดประสิทธิภาพด้วยพื้นที่ใต้กราฟ (ROC) โดย ทั้ง 16 แบบจำลองมีความใกล้เคียงกัน โดยแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียม แบบสังวัตนาการ (Convolutional Neural Network) มีค่าประสิทธิภาพของแบบจำลองที่ดีที่สุด คือ การปรับเสริมข้อมูล และใช้อัลกอริทึม Adam มีค่าประสิทธิภาพร้อยละ 99 และแบบจำลองที่ ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16) ที่มีการปรับและไม่ปรับเสริมข้อมูล และใช้อัลกอริทึม Adam มีค่าประสิทธิภาพของ แบบจำลองอยู่ที่ร้อยละ 99 ตามตารางที่ 9 และ ภาพประกอบ 12

ตาราง 9 เปรียบเทียบผลการทดลองของแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียม แบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16)

Models	Algorithms	Data Augmentation layers	Accuracy	F1-Score, Macro Avg	ROC
1. CNN	Adam	ไม่ปรับ	0.91	0.92	0.993
2. CNN	Adam	ปรับ	0.89	0.91	0.999



ตาราง 9 (ต่อ)

Models	Algorithms	Data Augmentation layers	Accuracy	F1-Score, Macro Avg	ROC
3. CNN	Adam	ไม่ปรับ	0.96	0.96	0.998
4. CNN	Adam	ปรับ	0.91	0.91	0.999
5. CNN	RMSProp	ไม่ปรับ	0.83	0.84	0.994
6. CNN	RMSProp	ปรับ	0.89	0.90	0.999
7. CNN	RMSProp	ไม่ปรับ	0.86	0.86	0.996
8. CNN	RMSProp	ปรับ	0.88	0.87	0.993
9. VGG	Adam	ไม่ปรับ	0.94	0.94	0.999
10. VGG	Adam	ปรับ	0.87	0.87	0.998
11. VGG	Adam	ไม่ปรับ	0.94	0.94	0.999
12. VGG	Adam	ปรับ	0.92	0.92	0.996
13. VGG	RMSProp	ไม่ปรับ	0.94	0.95	0.991
14. VGG	RMSProp	ปรับ	0.96	0.96	0.997
15. VGG	RMSProp	ไม่ปรับ	0.96	0.96	0.998
16. VGG	RMSProp	ปรับ	0.96	0.96	0.996



ภาพประกอบ 12 ตัวอย่างของการคัดแยกมะม่วงด้วยแบบจำลอง

อย่างไรก็ตาม บทที่ 4 การทดลอง มีการสรุปผลการทดลองทั้งหมด 16 ผลการทดลอง โดยมีการเปรียบเทียบผลการทดลองตามสมมติฐานในบทที่ 1 ทั้งในส่วนของคุณภาพของการทำนายการจำแนกประเภทของมะม่วงของไทยทั้ง 4 สายพันธุ์ และการเปรียบเทียบประสิทธิภาพของแบบจำลองในการทดลอง นอกจากนี้ยังได้มีการเปรียบเทียบในเรื่องของเวลาในการทดสอบแบบจำลองในแต่ละแบบจำลอง เพื่อเป็นทางเลือกตัดสินใจในการใช้งานต่อในอนาคต โดยในบทที่ 5 สรุปผลการทดลอง จะเป็นการสรุปจากผลการทดลองทั้งหมด 16 ผลการทดลองโดยดูจากค่าความแม่นยำของการจำแนกมะม่วง ประสิทธิภาพของแบบจำลอง และเวลาในการทำงานของการเทรนแบบจำลอง

## บทที่ 5

### สรุปผลการทดลอง

ในการทำวิจัยเรื่องแบบจำลองการคัดแยกสายพันธุ์มะม่วงด้วยการเรียนรู้ของเครื่อง โดยใช้เทคนิคการประมวลผลภาพที่หลากหลายและแยกประเภทการเรียนรู้ของเครื่อง ผู้วิจัยจึงได้เปรียบเทียบประสิทธิภาพของแบบจำลองเพื่อสรุปผลการทดลองโดยแบ่งหัวข้อการสรุปผลได้ดังต่อไปนี้


1. สรุปผลการวิจัย
2. ข้อเสนอแนะ

#### 1. สรุปผลการวิจัย

งานวิจัยนี้สร้างขึ้นมาจากปัญหาการคัดแยกพันธุ์มะม่วงของไทยแต่ละชนิดมีความคล้ายคลึงกันมาก และมะม่วงของไทยเป็นผลไม้ทางเศรษฐกิจที่สร้างรายได้ให้แก่ชาวเกษตรกรจึงจำเป็นต้องใช้ความแม่นยำในการคัดแยกมะม่วงแต่ละสายพันธุ์ โดยการวิจัยนี้จะช่วยให้สามารถลดเวลาในการคัดแยกสายพันธุ์ของมะม่วงจากระบบการคัดแยกมะม่วงแบบแมนนวล และยังสามารถสังเกตเห็นโอกาสในการสร้างมูลค่าเพิ่ม และการยืดอายุของมะม่วงจากการนำไปสู่ขั้นตอนการแปรรูปอาหาร จากการศึกษาข้อมูลการส่งออกมะม่วงกระป๋องถือเป็นตลาดที่มีอัตราการเติบโตอย่างต่อเนื่อง นอกจากนี้การแปรรูปมะม่วงยังสามารถนำไปแปรรูปและจำหน่ายได้อย่างหลากหลาย เช่น มะม่วงกวน มะม่วงอบแห้ง ขนมขบเคี้ยวมะม่วง แยมมะม่วง และมะม่วงกระป๋อง เป็นต้น

จากปัญหาที่กล่าวมาทั้งหมดผู้วิจัยได้ทำการสร้างแบบจำลองการคัดแยกสายพันธุ์มะม่วงด้วยการเรียนรู้ของเครื่อง โดยใช้เทคนิคการประมวลผลภาพที่หลากหลายและแยกประเภทการเรียนรู้ของเครื่อง ด้วยแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำกลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) เพื่อใช้ในการดึงลักษณะเด่นของภาพออกมา (Feature Extraction) ซึ่งส่งผลต่อมิติที่เพิ่มขึ้น และนำหลักการวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis: PCA) เพื่อลดมิติและนำเข้าแบบจำลองต่อไป หลังจากให้นำเข้าข้อมูลทดสอบ (Testing Data) เข้าแบบจำลองจำแนกข้อมูลด้วยเครื่องทั้งแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการนำกลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) รวมทั้งการใช้อัลกอริทึม Adam และ RMSProp และการปรับเสริมข้อมูลของภาพ (Data Augmentation) เพื่อทำให้การทดลองจากชุดข้อมูลมีความหลากหลายขึ้น นอกจากนี้ยังมีการปรับอัตราการเรียนรู้ของแบบจำลอง การวัดค่าความถูกต้องของการจำแนก

และวัดประสิทธิภาพ สรุปได้ว่าทั้ง 2 แบบจำลองหลักมีประสิทธิภาพของแบบจำลองการคัดแยกแยกพันธุ์มะม่วงของไทยได้ใกล้เคียงกัน โดยแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ดีกว่าแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) เนื่องจากเวลาในการประมวลผลการจำแนกข้อมูลดังตารางที่ 7 และ 8 ในเชิงของเวลาการประมวลผลการจำแนกข้อมูลนั้นมีการใช้เวลาน้อยกว่าในแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) เนื่องจากความซับซ้อนในการประมวลผลของแบบจำลองมีน้อยกว่ากัน อย่างไรก็ตามค่าความถูกต้องในการจำแนกสายพันธุ์มะม่วงของไทยทั้ง 4 สายพันธุ์ ได้แก่ มะม่วงแก้วขมิ้น มะม่วงเขียวเสวย มะม่วงน้ำดอกไม้ และมะม่วงน้ำดอกไม้สีทอง รวมทั้งหารจำแนกมะม่วงสายพันธุ์จากต่างประเทศแบบจำลองทั้ง 2 แบบจำลองมีค่าความถูกต้องที่ร้อยละ 96 เท่ากันตามตารางที่ 9 ค่า F1-Score, Macro Avg คือค่าเฉลี่ยของการทำนายทั้งความแม่นยำ (Precision) และความถูกต้องในการทำนายและการเรียกคืน (Recall) ของภาพมะม่วงทั้ง 4 สายพันธุ์ของไทย และมะม่วงสายพันธุ์จากต่างประเทศ พบว่าแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) ดีกว่าแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ที่ร้อยละ 96 ซึ่งเหตุผลที่ F1-Score และ Macro Avg มีค่าต่ำกว่าค่าความถูกต้อง (Accuracy) เพราะความแม่นยำ (Precision) และความถูกต้องในการทำนายและการเรียกคืน (Recall) ของแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ที่ทำนายกรจำแนกมะม่วงสายพันธุ์ของไทยบางชนิดค่อนข้างน้อยดังนั้นเมื่อนำมาหาค่า F1-Score และ Macro Avg โดยเฉลี่ยแล้วจะได้ค่าน้อยลง ในขณะที่ค่าความถูกต้องอาจจะได้มากกว่า แต่หากเปรียบเทียบค่าพื้นที่ใต้กราฟที่แสดงถึงประสิทธิภาพของแบบจำลอง (ROC) พบว่าแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group : VGG16) ให้ผลใกล้เคียงกับแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ที่มีร้อยละ 99.9 และร้อยละ 99.8 ตามลำดับ ตามภาพประกอบ 13



ภาพประกอบ 13 เปรียบเทียบผลความถูกต้องและผลประสิทธิภาพของแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และแบบจำลองที่ถูกฝึกฝนแล้ว (Transfer learning) ด้วยการใช้กลุ่มภาพเรขาคณิต 16 (Visual Geometry Group :VGG16)

## 2. ข้อเสนอแนะ

2.1 ในงานวิจัยนี้ได้้นำการใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) มาประยุกต์และใช้ข้อมูลจากชุดภาพมะม่วงพันธุ์ของไทยทั้ง 4 สายพันธุ์ ได้แก่ แก้วขมื่น, เขียวเสวย, น้ำดอกไม้ และน้ำดอกไม้สีทอง รวมทั้งมะม่วงจากสายพันธุ์ต่างประเทศซึ่งเป็นภาพจากหลังขาวทั้งหมดในมะม่วงทุกสายพันธุ์ ซึ่งในทางปฏิบัติแล้วมะม่วงอาจจะอยู่รวมกับผลไม้ชนิดอื่น ๆ หรือรวมกับสายพันธุ์อื่น หรืออยู่บนต้นไม้ ซึ่งงานวิจัยอนาคตอาจจะมีการนำภาพมะม่วงที่มีฉากหลังเป็นบนต้นไม้ และรวมกับมะม่วงพันธุ์อื่น ๆ หรือผลไม้ชนิดอื่น ๆ เพื่อเข้ามาสร้างแบบจำลองให้มีประสิทธิภาพและประยุกต์ใช้ในเชิงพาณิชย์ได้มากกว่านี้

2.2 นำข้อมูลจากชุดภาพมะม่วงประยุกต์ใช้กับอัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) ประเภทอื่นๆ เช่น Deep Residual Network (Resnet) และ Dense Convolutional Network เป็นต้น

2.3 สามารถเพิ่มค่าความถูกต้อง (Accuracy) ให้กับแบบจำลองได้ด้วยการเพิ่มจำนวนข้อมูลฝึกฝน (Training Data) เพิ่มขึ้น, จำลองข้อมูลการปรับเสริมข้อมูลภาพให้หลากหลายยิ่งขึ้น

2.4 นำแบบจำลองงานวิจัยนี้ทดสอบการคัดแยกสายพันธุ์ของผลไม้ชนิดอื่นๆในงานวิจัยอนาคตเพื่อทดสอบความมีประสิทธิภาพของแบบจำลอง

## ภาคผนวก

1. ข้อมูลชุดฝึกฝน (Training Set) ที่ประกอบด้วยภาพมะม่วงของไทยทั้ง 4 สายพันธุ์ และมะม่วงจากต่างประเทศจำนวน 615 ข้อมูล โดยนำมาทำ Imagenet ตามแต่ละชื่อสายพันธุ์

```
#create mango name
#mango_names=['Keawkramin','Khiaosawoey','Namdokmai','Namdokmai Srithong','Sindhri',
mango_names=['Keawkramin','Khiaosawoey','Namdokmai','Namdokmai Srithong','Other']
```

2. นำเข้าชุดข้อมูลทั้งชุดข้อมูลการฝึกฝน และชุดข้อมูลการทดลอง โดยภาพที่นำเข้ามีขนาด 100 x 100 พิกเซล

```
## Loading data and putting them into training and test sets

##locations setting for training and test datasets
train_data='Training'
test_data='Test'

##creates X_train and Y_train using file_names and folders
def get_data(path):
    data = load_files(path)
    files = np.array(data['filenames'])
    targets = np.array(data['target'])
    target_labels = np.array(data['target_names'])
    return files,targets,target_labels

X_train, Y_train, labels = get_data(train_data)
X_test, Y_test, _ = get_data(test_data)
Y_train = np_utils.to_categorical(Y_train, 5)
Y_test = np_utils.to_categorical(Y_test, 5)
```

3. นำชุดข้อมูลเข้า โดยแบ่งชุดข้อมูลออกเป็น 2 ชุดข้อมูล ได้แก่ ชุดข้อมูลที่ใช้ในการฝึกฝน และชุดข้อมูลที่ใช้ในการทดลอง ซึ่งได้แยกชุดข้อมูลในการฝึกฝนออกเป็นร้อยละ 20

```
# splitting train set into training and validation sets

X_train, X_val = train_test_split(X_train, test_size=0.2, random_state=33)
Y_train, Y_val = train_test_split(Y_train, test_size=0.2, random_state=33)
```

#### 4. นำชุดข้อมูลมาแปลงข้อมูลจากภาพเป็นตัวเลข

```
#converting images into array to start computation

def convert_image_to_array(files):
    images_as_array=[]
    for file in files:
        images_as_array.append(img_to_array(load_img(file)))
    return images_as_array

X_train = np.array(convert_image_to_array(X_train))
X_val = np.array(convert_image_to_array(X_val))
X_test = np.array(convert_image_to_array(X_test))
```

5. หลังจากที่นำภาพมาแปลงเป็นตัวเลขแล้วนั้น ในแบบจำลองมีการนำการปรับเสริมภาพจาก Keras มาใช้กับชุดข้อมูล โดยมีการสุ่มการปรับเสริมภาพตั้งแต่การหมุนภาพ การขยายภาพ และการเอียงภาพ

```
datagen = ImageDataGenerator(
    rotation_range=0.05, #Randomly rotate images in the range
    zoom_range = 0.2, # Randomly zoom image
    width_shift_range=0.1, #Randomly shift images horizontally
    height_shift_range=0.1, #Randomly shift images vertically
    shear_range=0.05 #Randomly shear images
)

datagen.fit(X_train)
```

6. ขั้นตอนถัดมาคือ การนำข้อมูลเข้าแบบจำลองจำแนกข้อมูลด้วยโครงข่ายประสาทเทียมแบบสังวัตนาการ และแบบจำลองที่ถูกฝึกฝนด้วยการใช้กลุ่มภาพเรขาคณิต 16 โดยในที่นี้จะยกตัวอย่างของการแบบจำลองที่ถูกฝึกฝนด้วยการใช้กลุ่มภาพเรขาคณิต 16

```

#importing vgg16
#Part 2 using transfer learning
#importing vgg16 architecture which is trained on Imagenet

from keras.applications.vgg16 import VGG16

t0 = time.time()

vgg_model = VGG16(input_shape=[100,100,3], weights='imagenet', include_top=False)
#We will not train the layers imported.

for layer in vgg_model.layers:
    layer.trainable = False

#summary of the imported vgg model vgg_model.summary()
vgg_model.summary()

t1 = time.time()
vggTotalComputeTime = t1-t0
print('vggTotalComputeTime : ', vggTotalComputeTime )

```

7. หลังจากนำแบบจำลองเข้ามาแล้วได้ทำการปรับไฮเปอร์พารามิเตอร์สำหรับเตรียมการทดลองการจำแนกข้อมูล

```

#adding some layers to the vgg_model imported and again fitting the model to check the performance
t0 = time.time()

transfer_learning_model = Sequential()

transfer_learning_model.add(vgg_model)

transfer_learning_model.add(Conv2D(1024, kernel_size=3, padding='same'))

transfer_learning_model.add(Activation('relu'))

transfer_learning_model.add(MaxPooling2D(pool_size=(2, 2)))
transfer_learning_model.add(Dropout(0.3))

transfer_learning_model.add(Flatten())
transfer_learning_model.add(Dense(150))
transfer_learning_model.add(Activation('relu'))
transfer_learning_model.add(Dropout(0.4))
transfer_learning_model.add(Dense(5,activation = 'softmax'))
transfer_learning_model.summary()

t1 = time.time()
vgg_transfer_learning_model_TotalComputeTime = t1-t0

print('vgg_transfer_learning_model_TotalComputeTime : ', vgg_transfer_learning_model_TotalComputeTime )

```



8. ขั้นตอนถัดมา คือนำอัลกอริทึมมาใช้กับแบบจำลอง โดยในที่นี้มีการนำอัลกอริทึม Adam และ RMSProp ทั้ง 2 อัลกอริทึมมาใช้ และมีการปรับอัตราการเรียนรู้ของแบบจำลองอยู่ที่ 0.001 และ 0.001

```
#importing ootimizers
t0 = time.time()

optimizer = Adam(learning_rate=0.0001)
transfer_learning_model.compile(loss='categorical_crossentropy',
                                optimizer=optimizer,
                                metrics=['accuracy'])
```

9. ขั้นตอนถัดไป คือการกำหนดขนาดของข้อมูลที่ใช้ในการทดลองแต่ละรอบ และการกำหนดรอบการทดลองอยู่ที่ 500 รอบ และกำหนดรอบการหยุดทดลองเมื่อผลการทดลองไม่มีการปรับปรุงอยู่ที่ 20 รอบ

```
bs = 128

es = EarlyStopping(monitor="val_loss",
                   mode="min",
                   patience=20, # number of stop test
                   verbose=1)

epochsNumber = 500

# creating a file to save the trained CNN model
checkpointer = ModelCheckpoint(filepath = 'vgg_adam_model4_.hdf5',
                                monitor='val_loss',
                                mode='min',
                                verbose = 1,
                                save_best_only = True)
```

10. ขั้นตอนถัดไป คือการวิเคราะห์การจำแนกข้อมูลด้วยแบบจำลองหลังจากที่กำหนดไฮเปอร์พารามิเตอร์เรียบร้อยแล้ว

```
VGG_Model4 = transfer_learning_model.fit(datagen.flow(X_train, Y_train, batch_size=bs),
                                         shuffle=True,
                                         epochs=epochsNumber,
                                         validation_data=(X_val, Y_val),
                                         verbose=2,
                                         callbacks = [es, checkpointer],
                                         steps_per_epoch=X_train.shape[0] // bs)
```

11. เมื่อแบบจำลองทำการวิเคราะห์ทดลองชุดข้อมูลตามรอบที่ทดลองเสร็จเรียบร้อยแล้ว ขั้นตอนถัดไป คือการจับเวลาในการประมวลผลของการแบบจำลองตั้งแต่รอบที่ 1 จนถึงรอบที่ n

```
t1 = time.time()
VGGTotalComputeTime = t1-t0
print('VGGTotalComputeTime : ', VGGTotalComputeTime )
```

12. หลังจากนั้นนำผลค่าความถูกต้องในการทดลองในแต่ละรอบมาทำการสรุปผลรวมถึงแบบจำลองนี้มีความถูกต้องรวม

```
#checking testset accuracy

score = transfer_learning_model.evaluate(X_test, Y_test)
print('Test accuracy:', score[1])
```

13. ขั้นตอนถัดไป คือหลังจากที่แบบจำลองประมวลผลเรียบร้อยแล้ว จึงได้สู่การสร้างกราฟออกมาในลักษณะ 5 x 5 ภาพ จะได้ภาพหลังการทดลองการจำแนกข้อมูลระหว่างชุดข้อมูลทดลองกับคลาสของพันธุ์มะม่วง

```
# using model to predict on test data
Y_pred = transfer_learning_model.predict(X_test)

# Lets plot the predictions of different fruits and check their original labels

fig = plt.figure(figsize=(20, 15))
for i, idx in enumerate(np.random.choice(X_test.shape[0], size=25, replace=False)):
    ax = fig.add_subplot(5, 5, i + 1, xticks=[], yticks=[])
    ax.imshow(np.squeeze(X_test[idx]))
    pred_idx = np.argmax(Y_pred[idx])
    true_idx = np.argmax(Y_test[idx])
    ax.set_title("{} ({}).format(labels[pred_idx], labels[true_idx]),
                color=("green" if pred_idx == true_idx else "red"))
```

14. ต่อมาเป็นการสร้างกราฟแสดงรอบของการทดลองซึ่งแสดงถึงทั้งในส่วนของ Loss validation และ Accuracy validation

```
#plotting the loss function and accuracy for different epochs

#VGG_model1.history.keys()
#dict_keys(['val_loss', 'val_accuracy', 'loss', 'accuracy'])
import matplotlib.pyplot as plt

fig, ax = plt.subplots(nrows=1, ncols=2, figsize=(10, 5), sharex=True)

ax[0].plot(VGG_Model4.history["loss"], label="Training", color="blue")
ax[0].plot(VGG_Model4.history["val_loss"], label="Validation", color="red")
ax[0].set_ylabel("Loss")
ax[0].set_ylim(0, 0.3 + max([max(VGG_Model4.history["loss"]), max(VGG_Model4.history["val_loss"])]))
ax[0].set_xlim(0, len(VGG_Model4.history["loss"]))

ax[1].plot(VGG_Model4.history["accuracy"], label="Training", color="blue")
ax[1].plot(VGG_Model4.history["val_accuracy"], label="Validation", color="red")
ax[1].set_xlabel("Epochs")
ax[1].set_ylabel("Accuracy")
ax[1].set_ylim(0, 1)
plt.legend(loc="best")
fig.suptitle("Model Training")
plt.savefig("Learning_Class_VGG_Adam_model4.svg", format="svg")
plt.show()
```

15. ต่อมาจะเป็นการสร้าง Heatmap ของการทดลองในแต่ละคลาส โดยให้มีการแสดงสีตั้งแต่ระดับเข้มไปจนระดับอ่อน โดยจะบ่งบอกความถูกต้องในการจำแนกข้อมูลมะม่วงแต่ละสายพันธุ์

```
#Show heatmap
from sklearn import metrics
from sklearn.metrics import accuracy_score
import seaborn as sns
from sklearn.metrics import confusion_matrix
#confusion matrix
y_pred_classes=np.argmax(Y_pred,axis=1)
y_true=np.argmax(Y_test,axis=1)
conf_mat=confusion_matrix(y_true,y_pred_classes)

#Annotate each cell with the numeric value using integer formatting:
f,ax=plt.subplots(figsize=(4,3))
sns.heatmap(conf_mat, xticklabels=mango_names, yticklabels=mango_names)
plt.show()
```

16. การแสดงผลลัพธ์ประสิทธิภาพการทำนายของแบบจำลอง

```
#Show classification_report
from sklearn.metrics import classification_report

print(classification_report(y_true, y_pred_classes, target_names = mango_names ))
```

17. กราฟแสดงผลลัพธ์ประสิทธิภาพของแบบจำลอง

```
# Compute fpr, tpr, thresholds and roc auc
fpr, tpr, thresholds = roc_curve(Y_test[:, i], Y_pred[:, i])
roc_auc = auc(fpr, tpr)

# Plot ROC curve
plt.plot(fpr, tpr, label='ROC curve (area = %0.3f)' % roc_auc)
plt.plot([0, 1], [0, 1], 'k--') # random predictions curve
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.0])
plt.xlabel('False Positive Rate or (1 - Specificity)')
plt.ylabel('True Positive Rate or (Sensitivity)')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
```

## บรรณานุกรม

- Berrar, D., & Flach, P. (2012). Caveats and pitfalls of ROC analysis in clinical microarray research (and how to avoid them). *Briefings in Bioinformatics*, 13(1), 83–97. <https://doi.org/10.1093/bib/bbr008>
- Chandrasekara, E. S. K., Kanchana, W. K. T., & Nandani, E. J. K. P. (2021). Comprehensive Study for Diabetes Identification Ability of Various Optimizers in Deep Learning Neural Network. *2021 5th SLAAI International Conference on Artificial Intelligence (SLAAI-ICAI)*, 1–6. <https://doi.org/10.1109/SLAAI-ICAI54477.2021.9664721>
- Fitrianto, A., & Sartono, B. (2021). Image Classification Modelling of Beef and Pork Using Convolutional Neural Network. *International Journal of Sciences: Basic and Applied Research (IJSBAR) International Journal of Sciences: Basic and Applied Research*, 57(2), 26–38.
- Kamsing, P., Torteeka, P., & Yooyen, S. (2019). Deep Convolutional Neural Networks for plane identification on Satellite imagery by exploiting transfer learning with a different optimizer. *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, 9788–9791. <https://doi.org/10.1109/IGARSS.2019.8899206>
- Kaset GO. (2566). การแปรรูปมะม่วง. สืบค้นจาก <https://kasetgo.com/t/topic/524353>
- Kausar, A., Sharif, M., Park, J., & Shin, D. R. (2018). Pure-CNN: A framework for fruit images classification. *Proceedings - 2018 International Conference on Computational Science and Computational Intelligence, CSCI 2018*, 404–408. <https://doi.org/10.1109/CSCI46756.2018.00082>
- Kuroda, T., & Nobuhara, H. (2022). Transfer learning considering the impact of data augmentation on each layer of the source model. *2022 Joint 12th International Conference on Soft Computing and Intelligent Systems and 23rd International Symposium on Advanced Intelligent Systems (SCIS&ISIS)*, 1–5. <https://doi.org/10.1109/SCISISIS55246.2022.10002153>

- Li, Q., Yan, M., & Xu, J. (2021). Optimizing Convolutional Neural Network Performance by Mitigating Underfitting and Overfitting. *2021 IEEE/ACIS 19th International Conference on Computer and Information Science (ICIS)*, 126–131. <https://doi.org/10.1109/ICIS51600.2021.9516868>
- N. D. Thong, N. T. T. and H. T. C. & International Conference on System Science and Engineering (ICSSE). (n.d.). *Mango Classification System Uses Image Processing Technology and Artificial Intelligence*.
- Nanaa, K., Rizon, M., Rahman, M. N. A., Ibrahim, Y., & Aziz, A. Z. A. (2014). Detecting mango fruits by using randomized hough transform and backpropagation neural network. *Proceedings of the International Conference on Information Visualisation*, 388–391. <https://doi.org/10.1109/IV.2014.54>
- NVIDIA Corporation. (2023). *DEPLOYING QUANTIZATION AWARE TRAINED MODELS IN INT8 USING TORCH-TENSORRT*. Research from [https://pytorch.org/TensorRT/\\_notebooks/vgg-qat.html](https://pytorch.org/TensorRT/_notebooks/vgg-qat.html)
- Pagon Gatchalee. (2019). *Confusion Matrix เครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำ งาน าย ใน Machine Learning*. สื่ บ คั น จ าก <https://medium.com/@pagongatchalee/confusion-matrix>
- Phung & Rhee. (2019). A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets. *Applied Sciences*, 9(21), 4500. <https://doi.org/10.3390/app9214500>
- Raut, R., Jadhav, A., Sorte, C., & Chaudhari, A. (2022). Classification of Fruits using Convolutional Neural Networks. *2022 Second International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)*, 1–4. <https://doi.org/10.1109/ICAECT54875.2022.9808070>
- Rizwan Iqbal, H. M., & Hakim, A. (2022). Classification and Grading of Harvested Mangoes Using Convolutional Neural Network. *International Journal of Fruit Science*, 22(1), 95–109. <https://doi.org/10.1080/15538362.2021.2023069>
- Unal, H. B., Vural, E., Savas, B. K., & Becerikli, Y. (2020, October 15). Fruit Recognition and Classification with Deep Learning Support on Embedded System (fruitnet).

*Proceedings - 2020 Innovations in Intelligent Systems and Applications Conference, ASYU 2020.* <https://doi.org/10.1109/ASYU50717.2020.9259881>

Zheng, H., Chen, M., Liu, W., Yang, Z., & Liang, S. (2014). Improving deep neural networks by using sparse dropout strategy. *2014 IEEE China Summit & International Conference on Signal and Information Processing (ChinaSIP)*, 21–26. <https://doi.org/10.1109/ChinaSIP.2014.6889194>

รุ่งนภา พิมมะศรี. (2565). ไทยส่งออกมะม่วงเป็นอันดับ 1 ของโลก ทำเงินปีละ 4,500 ล้านบาท แต่ยังไม่พอ ต้องหาตลาดใหม่ๆ เพิ่ม. สืบค้นจาก <https://plus.thairath.co.th/topic/money/101401>

สำนักงานปลัดกระทรวงพาณิชย์. (2566). การส่งออกของไทย มะม่วงกระป๋อง. สืบค้นจาก <https://tradereport.moc.go.th/Report/Default.aspx?Report=MenucomTopNRecode&Option=3&Lang=Th&ImExType=1&comcode=203010500>

สำนักงานเกษตรและสหกรณ์. (2565). ข้อมูลสายพันธุ์มะม่วง. สืบค้นจาก [https://www.opsmoac.go.th/angthong-article\\_prov-preview-431291791874](https://www.opsmoac.go.th/angthong-article_prov-preview-431291791874)



## ประวัติผู้เขียน

ชื่อ-สกุล

เมธากาญจน์ ใจตระกูล

สถานที่เกิด

สุพรรณบุรี

วุฒิการศึกษา

มหาวิทยาลัยศรีนครินทรวิโรฒ

