

การจำแนกพันธุ์อย่างพาราด้วยการเรียนรู้เชิงลึก

ธีรภัทร ร่มรื่นสุขารมย์

TNII

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

บัณฑิตศึกษา สาขาเทคโนโลยีสารสนเทศ

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

ปีการศึกษา 2568

HEVEA CLONE IDENTIFICATION USING DEEP LEARNING

Thiraphat Romruensukharom

TNII

A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science Program in Information Technology

Graduate Studies

Thai-Nichi Institute of Technology

Academic Year 2025

หัวข้อวิทยานิพนธ์

โดย

สาขาวิชา

อาจารย์ที่ปรึกษาวิทยานิพนธ์

การจำแนกพันธุ์อย่างพาราด้วยการเรียนรู้เชิงลึก

ธีรภัทร รมรื่นสุขารมย์

เทคโนโลยีสารสนเทศ

ดร.ศรายุทธ นนท์ศิริ

บัณฑิตศึกษา สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

..... รองอธิการบดีฝ่ายวิชาการ

(รองศาสตราจารย์ ดร.วรากร ศรีเชวงทรัพย์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ

(รองศาสตราจารย์ ดร.อรรณพ หมั่นสกุล)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ฐิติพร เลิศรัตน์เดชากุล)

..... กรรมการ

(ดร.ภาสกร อภิรักษ์วรพินิต)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์

(ดร.ศรายุทธ นนท์ศิริ)

ธีรภัทร รมรินสุขารมย์ : การจำแนกพันธุ์ยางพาราด้วยการเรียนรู้เชิงลึก อาจารย์ที่ปรึกษา :  
ดร.ศรายุทธ นนท์ศิริ, 141 หน้า.

ยางพาราเป็นหนึ่งในพืชเศรษฐกิจที่มีความสำคัญของประเทศไทยและมีสถิติมูลค่าผลผลิตยางพาราเป็นอันดับหนึ่งของโลกอย่างต่อเนื่อง การแนะนำให้เกษตรกรปลูกยางพันธุ์ดีจะทำให้เกษตรกรได้รับผลผลิตต่อไร่สูงขึ้น แต่เนื่องจากยางพาราเป็นพืชยืนต้นที่มีพันธุ์กรรมแบบเฮเทอโรไซกัส ทำให้ต้นที่ได้จากการขยายพันธุ์ด้วยเมล็ด (Seedling) จากต้นพันธุ์เดียวกันมีพันธุ์กรรมและผลผลิตแตกต่างกัน ไม่เหมือนต้นที่ขยายพันธุ์ด้วยการติดตา (Clone) ที่มีลักษณะทางพันธุ์กรรมเหมือนกันและมีความสม่ำเสมอ ใบเป็นลักษณะที่เหมาะสมสำหรับการจำแนกสายพันธุ์ แต่เนื่องจากรูปร่างของใบมีความแตกต่างกันน้อย และพันธุ์ยางหลายพันธุ์มีรูปร่างใบคล้ายคลึงกัน จึงจำเป็นต้องอาศัยผู้เชี่ยวชาญที่มีประสบการณ์สูงจึงจะจำแนกพันธุ์ยางได้ถูกต้อง อีกทั้งบุคลากรที่สามารถจำแนกพันธุ์ได้ถูกต้องมีน้อย งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาตัวแบบจำแนกพันธุ์ยางพาราที่สามารถนำไปใช้ในการจำแนกสายพันธุ์ได้อย่างถูกต้องด้วยการเรียนรู้เชิงลึก ดำเนินการค้นหาไฮเปอร์พารามิเตอร์และขนาดชุดข้อมูลที่เหมาะสมผ่านการตรวจสอบความถูกต้องแบบไขว้ พร้อมทั้งเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทประดิษฐ์เชิงลึก 13 สถาปัตยกรรม ได้แก่ VGG16, ResNet50, InceptionV3, MobileNet, Xception, DenseNet201, NASNetLarge, MobileNetV2, EfficientNetB7, RegNetX064, RegNetY064, ResNetRS50 และ ConvNeXtBase จากการศึกษาการทดลองย่อยการจำแนกระหว่างต้นที่ขยายพันธุ์ด้วยการติดตาและต้นที่ขยายพันธุ์ด้วยเมล็ด พบว่า การเพิ่มประสิทธิภาพการฝึกสอนโดยอาศัย ConvNeXtBase เป็นตัวสกัดคุณลักษณะด้วยไฮเปอร์พารามิเตอร์แบบ S1 ให้ความแม่นยำสูงถึง 97.82% บนชุดข้อมูลขนาด E3 และมีประสิทธิภาพในการจำแนกข้อมูลได้ดีกว่าตัวแบบอื่น ๆ ที่ค่าเกณฑ์ที่แตกต่างกัน เช่นเดียวกับการทดลองหลัก การจำแนกพันธุ์ยางพาราที่นิยมปลูกในประเทศไทย 6 สายพันธุ์ แสดงให้เห็นว่าการฝึกสอนตัวแบบโดยใช้การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะโดยอาศัยสถาปัตยกรรม ConvNeXtBase สามารถจำแนกพันธุ์ยางพาราจากลักษณะใบได้อย่างมีประสิทธิภาพ

บัณฑิตศึกษา

สาขาวิชา เทคโนโลยีสารสนเทศ

ปีการศึกษา 2568

ลายมือชื่อนักศึกษา.....

ลายมือชื่ออาจารย์ที่ปรึกษา.....

THIRAPHAT ROMRUENSUKHAROM : HEVEA CLONE IDENTIFICATION USING DEEP LEARNING. ADVISOR : DR. SARAYUT NONSIRI, 141 PP.

*Hevea brasiliensis* Muell. Arg is one of the important economic trees. Thailand has been the world's largest producer and exporter of natural rubber. Para rubber is a highly heterozygous perennial plant. A rubber tree grown from seed (seedlings) exhibits the disadvantage of lacking genetic uniformity. Unlike a clone, which is propagated by bud graft technique from a single tree, seedlings possess identical genetic constitution and have the uniformity among them. The leaf shape of seedlings is highly variable, while the leaf shape of clones is slightly variable. It also appears in similar characteristics to other clones. The objective of the research was to develop *H. brasiliensis* clone identification model. The study conducted a performance comparison of thirteen deep neural networks including VGG16, ResNet50, InceptionV3, MobileNet, Xception, DenseNet201, NASNetLarge, MobileNetV2, EfficientNetB7, RegNetX064, RegNetY064, ResNetRS50 and ConvNeXtBase. The appropriate hyperparameters were found through k-fold cross validation. The models were trained using transfer learning technique with FEA. Various augmentation techniques were applied, in order to improve the performance. The results of the pilot study revealed that retraining the improved model on low resolution images by implementing ConvNeXtBase as feature extractor with S1 achieved highest accuracy 97.82% on a quarter of dataset (E3). This outperformed the classification performance across all thresholds as well as the results of the full research. It was indicated that training the model with FEA by implementing ConvNeXtBase as feature extractor is the effective approach for developing high performance Hevea clone identification model.

Graduate Studies

Student's Signature.....

Field of Study Information Technology

Advisor's Signature.....

Academic Year 2025

## กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลุล่วงได้ด้วยความกรุณาอย่างยิ่งจาก ดร.ศรายุทธ นนท์ศิริ อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ได้สละเวลาในการให้คำแนะนำและการสนับสนุน ตั้งแต่การวางแผนการวิจัย การดำเนินการทดลอง การทบทวนทฤษฎีที่เกี่ยวข้อง ตลอดจนการแก้ไขปัญหาและข้อบกพร่องต่าง ๆ ขอขอบพระคุณคณะกรรมการควบคุมการสอบวิทยานิพนธ์ทุกท่านที่ได้กรุณาให้คำแนะนำในการแก้ไขวิทยานิพนธ์ให้มีความสมบูรณ์มากยิ่งขึ้น

ท้ายที่สุดนี้ ข้าพเจ้าขอกราบขอบพระคุณครอบครัว ผู้ซึ่งให้กำลังใจและสนับสนุนการศึกษาเล่าเรียนตลอดจนการทำวิทยานิพนธ์ฉบับนี้จนเสร็จสมบูรณ์

ธีรภัทร ร่มรื่นสุขารมย์



## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฅ
สารบัญรูป.....	ฉ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 นิยามศัพท์เฉพาะ.....	3
2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 พันธุ์ยางพารา (Hevea Clones).....	4
2.2 การพัฒนาโปรแกรมแบบดั้งเดิม (Traditional Programming).....	10
2.3 การเรียนรู้ของเครื่อง (Machine Learning).....	10
2.4 เซลล์ประสาท (Biological Neuron).....	12
2.5 โครงข่ายประสาท (Biological Neural Network).....	13
2.6 เซลล์ประสาทประดิษฐ์ (Artificial Neuron).....	14
2.7 โครงข่ายประสาทประดิษฐ์ (Artificial Neural Network : ANN).....	16
2.8 โครงข่ายประสาทประดิษฐ์คอนโวลูชัน (Convolutional Neural Network : CNN).....	17
2.9 การเรียนรู้เชิงลึก (Deep Learning : DL).....	18
2.10 การถ่ายโอนความรู้ (Transfer Learning).....	20
2.11 ตัวแบบพื้นฐาน (Pre-trained Model).....	23
2.12 งานวิจัยที่เกี่ยวข้อง (Related Research).....	33

## สารบัญ (ต่อ)

บทที่	หน้า
3 วิธีการดำเนินงาน .....	66
3.1 การเก็บข้อมูล (Data Acquisition).....	66
3.2 การทำความเข้าใจข้อมูล (Data Understanding).....	68
3.3 การเตรียมข้อมูล (Data Preparation).....	68
3.4 การสร้างตัวแบบ (Modeling) .....	73
3.5 การประเมินผล (Evaluation) .....	74
3.6 การเตรียมการทดลอง (Experimental Setup).....	77
4 ผลการวิเคราะห์ข้อมูล.....	87
4.1 ผลการทดลองย่อย (Pilot Study).....	87
4.2 ผลการทดลองหลัก (Full Research).....	102
5 บทสรุป ข้อเสนอแนะ บทวิจารณ์.....	124
บรรณานุกรม.....	126
ภาคผนวก.....	138
ประวัติย่อผู้วิจัย.....	141

## สารบัญตาราง

ตารางที่	หน้า
2.1 รูปทรงใบยางพารา.....	7
2.2 เกณฑ์ที่ใช้ในการจำแนกพันธุ์จากลักษณะใบ .....	8
2.3 ฟังก์ชันกระตุ้น (Activation Function) พื้นฐาน .....	15
2.4 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง .....	44
2.5 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรด้วยวิธีการเรียนรู้ของเครื่อง .....	47
2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ ของเครื่อง .....	51
2.7 การเปรียบเทียบงานวิจัยการสกัดคุณลักษณะใบยางพารา .....	64
2.8 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์ยางพาราจากลักษณะใบด้วยวิธีการเรียนรู้ ของเครื่อง .....	65
3.1 อุปกรณ์ที่ใช้ในการเก็บข้อมูล .....	66
3.2 ข้อมูลภาพใบยางพาราชุดทดลองย่อย .....	67
3.3 ชุดข้อมูลภาพใบยางพาราชุดทดลองหลัก .....	67
3.4 การปรับลดขนาดภาพ.....	68
3.5 ตัวแบบพื้นฐานที่ใช้ในการทดลอง.....	73
3.6 คอนฟิวชันเมทริกซ์ .....	74
3.7 การแบ่งข้อมูลชุดทดลองย่อย.....	80
3.8 การแบ่งข้อมูลชุดทดลองย่อยสำหรับการทดลองการตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation) .....	80
3.9 การแบ่งข้อมูลชุดทดลองหลัก .....	81
3.10 สถาปัตยกรรมของตัวแบบและไฮเปอร์พารามิเตอร์สำหรับการทดลองย่อย.....	85
3.11 สถาปัตยกรรมของตัวแบบและไฮเปอร์พารามิเตอร์สำหรับการทดลองหลัก.....	86
4.1 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E1.....	87
4.2 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E2.....	88
4.3 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E3.....	88

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.4 ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2.....	89
4.5 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2 .....	90
4.6 ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3.....	93
4.7 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3 .....	94
4.8 การแบ่งข้อมูลชุดเพิ่มประสิทธิภาพการทดลองย่อย .....	98
4.9 ผลการเพิ่มประสิทธิภาพตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลขนาด E2.....	99
4.10 ผลการเพิ่มประสิทธิภาพตัวแบบด้วยชุดข้อมูลขนาด E3 .....	100
4.11 ผลการฝึกสอนตัวแบบการทดลองหลัก.....	102
4.12 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก.....	103
4.13 การแบ่งชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก.....	107
4.14 ผลการเพิ่มประสิทธิภาพตัวแบบการทดลองหลัก .....	108
4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก .....	109
4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก .....	114
4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วน ความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก.....	119

TNI

THAI - NICHI INSTITUTE OF TECHNOLOGY

## สารบัญรูป

รูปที่	หน้า
2.1 ไบย่อย่างพารา .....	6
2.2 รูปทรงไบอย่างพารา .....	7
2.3 การพัฒนาโปรแกรมแบบดั้งเดิม .....	10
2.4 การเรียนรู้ของเครื่อง .....	10
2.5 โครงสร้างเซลล์ประสาท .....	12
2.6 โครงข่ายประสาท .....	13
2.7 โครงสร้างเซลล์ประสาทประดิษฐ์ .....	14
2.8 โครงข่ายประสาทประดิษฐ์ .....	16
2.9 ตัวกรองคอนโวลูชัน .....	17
2.10 การคูณเมทริกซ์ .....	17
2.11 การเรียนรู้เชิงลึก .....	18
2.12 การพหุลีค่าเฉลี่ย .....	19
2.13 การพหุลีค่าสูงสุด .....	19
2.14 การถ่ายโอนความรู้ .....	20
2.15 การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะ .....	21
2.16 การถ่ายโอนความรู้ด้วยการปรับแต่งตัวแบบพื้นฐาน .....	21
2.17 รูปแบบการปรับแต่งตัวแบบพื้นฐาน .....	22
2.18 แนวคิดตัวแบบกลุ่ม VGG .....	23
2.19 แนวคิดตัวแบบกลุ่ม ResNet .....	24
2.20 แนวคิดตัวแบบกลุ่ม Inception .....	25
2.21 แนวคิดตัวแบบกลุ่ม MobileNet .....	26
2.22 แนวคิดตัวแบบกลุ่ม Xception .....	27
2.23 แนวคิดตัวแบบกลุ่ม DenseNet .....	28
2.24 แนวคิดตัวแบบกลุ่ม NASNet .....	29
2.25 แนวคิดตัวแบบกลุ่ม EfficientNet .....	30
2.26 แนวคิดตัวแบบกลุ่ม RegNet .....	31
2.27 แนวคิดตัวแบบกลุ่ม ConvNeXt .....	32

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.1 ขั้นตอนการดำเนินงาน.....	66
3.2 การเสริมข้อมูลแบบดั้งเดิม .....	69
3.3 ตัวอย่างรูปจากการเสริมข้อมูลแบบดั้งเดิม .....	69
3.4 การเสริมข้อมูลเฉพาะงาน.....	70
3.5 ตัวอย่างรูปจากการปรับมุมกล้อง.....	70
3.6 ตัวอย่างรูปจากการเสริมข้อมูลเฉพาะงาน .....	71
3.7 ตัวอย่างรูปจากการเสริมข้อมูลเชิงคุณสมบัติของรูป.....	72
3.8 แผนภาพขั้นตอนการทดลอง .....	77
3.9 แผนภาพขั้นตอนการทดลองย่อย .....	78
3.10 แผนภาพขั้นตอนการทดลองหลัก.....	79
3.11 การปรับลดเซลล์ประสาทประดิษฐ์ .....	82
3.12 การแบ่งชุดข้อมูลตรวจสอบความถูกต้องแบบไขว้.....	83
3.13 การตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation).....	83
4.1 แผนภาพการจำแนกข้อมูลที่ค่าเกณฑ์ (Threshold) ที่แตกต่างกัน.....	98
4.2 การเรียนรู้ของตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลเพิ่มประสิทธิภาพขนาด E2 .....	99
4.3 การเรียนรู้ของตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลเพิ่มประสิทธิภาพขนาด E3 .....	100
4.4 แผนภาพคอนฟิวชันเมตริกซ์ของตัวแบบ ConvNeXtBase ที่ผ่านการเพิ่มประสิทธิภาพด้วยชุดข้อมูลขนาด E2 (ซ้าย) และชุดข้อมูลขนาด E3 (ขวา).....	101

## บทที่ 1

### บทนำ

#### 1.1 ที่มาและความสำคัญ

ยางพารา (*Hevea brasiliensis* Muell. Arg.) เป็นหนึ่งในพืชเศรษฐกิจที่มีความสำคัญของประเทศไทยและมีสถิติมูลค่าผลผลิตยางพาราเป็นอันดับหนึ่งของโลกอย่างต่อเนื่อง จากรายงานสถิติการเกษตรของประเทศไทยปี 2567 พบว่า ประเทศไทยมีผลผลิตยางพาราสูงถึง 4,789,042 ตัน มูลค่าของผลผลิต 330,157 ล้านบาท [1] และยังคงมีแนวโน้มเพิ่มสูงขึ้น เมื่อยางพาราถูกนำมาใช้ประโยชน์ในอุตสาหกรรมจึงทำให้เกษตรกรหันมาปลูกยางพาราเพิ่มมากขึ้น สถาบันวิจัยยางกรมวิชาการเกษตรได้ทำการศึกษาวิจัยเพื่อปรับปรุงพันธุ์ยางให้ได้ผลผลิตสูงขึ้น และได้มีประกาศกระทรวงเกษตรและสหกรณ์เรื่อง กำหนดต้นยางพันธุ์ดี พ.ศ. 2556 [2] เพื่อแนะนำให้เกษตรกรปลูกแบ่งเป็น 3 ชั้น พันธุ์ยางชั้น 1 เป็นพันธุ์ยางที่ผ่านการทดลองและศึกษาลักษณะต่าง ๆ อย่างละเอียด จึงแนะนำให้ปลูกโดยไม่จำกัดเนื้อที่ปลูก ส่วนพันธุ์ยางชั้น 2 และ 3 ยังมีข้อจำกัด จึงแนะนำให้ปลูกได้ไม่เกินร้อยละ 30 และ 20 ของเนื้อที่ปลูกยางที่ถือครองตามลำดับ การแนะนำให้เกษตรกรปลูกยางพันธุ์ดีจะทำให้เกษตรกรได้รับผลผลิตต่อไร่สูงขึ้น

อย่างไรก็ตาม เนื่องจากยางพาราเป็นพืชยืนต้น (Perennial Tree) ที่ใช้ระยะเวลาในการปลูกและเก็บเกี่ยวผลผลิตไม่น้อยกว่า 20 ปี และเป็นพืชที่มีพันธุกรรมแบบเฮเทอโรไซกัส (Heterozygous) [3][4] การผสมภายในสายพันธุ์ (Inbreeding) ส่งผลให้ลูกที่ได้มีลักษณะด้อยลง (Inbreeding Depression) และเกิดความหลากหลายทางพันธุกรรม [5] ต้นที่ได้จากการขยายพันธุ์ด้วยเมล็ด (Seedling) จากต้นพันธุ์เดียวกันจะมีพันธุกรรมแตกต่างกัน และผลผลิตที่ได้ลดต่ำลง ดังนั้นจึงต้องใช้วิธีการขยายพันธุ์ด้วยการติดตา (Clone) นอกจากนี้ พันธุ์ยางที่ได้รับการปรับปรุงพันธุ์ในปัจจุบันยังมีฐานพันธุกรรมแคบ พันธุ์ยางที่เกิดขึ้นใหม่จึงมีลักษณะใกล้เคียงกันมากขึ้น การศึกษาลักษณะที่จะนำมาใช้ในการตรวจจำแนกพันธุ์ยาง และการคัดเลือกพันธุ์ที่ถูกต้องเหมาะสมกับสภาพแวดล้อมพื้นที่ปลูกจึงมีความซับซ้อนตามไปด้วย โดยการจำแนกพันธุ์ยางพาราสามารถทำได้ด้วยเทคนิคทางชีวโมเลกุล (Molecular Markers) [6] ซึ่งเป็นวิธีการที่มีประสิทธิภาพ และแม่นยำแต่ยังคงมีข้อจำกัดในด้านค่าใช้จ่าย และระยะเวลาในการตรวจสอบ [7] โดยทั่วไปจึงมักจำแนกสายพันธุ์จากลักษณะภายนอก (Phenotype) และต้องอาศัยการสังเกตลักษณะส่วนใหญ่ตั้งแต่ ฉัตรใบ ใบ ก้านใบ เปลือก ตา สีนํ้ายาง ลำต้น ทรงพุ่ม กิ่ง เมล็ด นอกจากนี้ยังมีดอกซึ่งเป็นลักษณะที่มีให้เห็นเพียงบางฤดูกาลเท่านั้น อีกทั้งต้นพันธุ์ที่เกษตรกรใช้ปลูกในปัจจุบัน คือ ต้นยางชำถุงพันธุ์ดีที่ผ่านการติดตามาแล้ว จึงทำให้เกิดความจำเป็นในการตรวจสอบความถูกต้องของต้นพันธุ์ตั้งแต่ในแปลงขยายพันธุ์เพื่อให้เกษตรกรได้รับพันธุ์ยางที่ถูกต้อง

ดังนั้น ลักษณะที่สามารถนำมาใช้ในการจำแนกพันธุ์ได้นั้นถูกจำกัดลงไปอีก ใบ (Leaf) จึงเป็นลักษณะที่เหมาะสมในการจำแนกสายพันธุ์ [8] โดยมักพิจารณาจากรูปทรงใบ (Leaf Shape) เนื่องจากเป็นลักษณะทางสัณฐานวิทยา (Morphological Characteristics) ที่มีความแตกต่างชัดเจน สามารถสังเกตได้ง่ายและรวดเร็ว แต่ด้วยความหลากหลายทางพันธุกรรมส่งผลให้รูปทรงใบมีความผันแปร การจำแนกพันธุ์อย่างพาราให้ได้ถูกต้องแม่นยำนั้น จำเป็นต้องอาศัยผู้เชี่ยวชาญที่มีประสบการณ์จึงจะจำแนกพันธุ์ที่ถูกต้อง การสั่งสมประสบการณ์ต้องอาศัยระยะเวลาผ่านกระบวนการฝึกอบรมจึงทำให้บุคลากรที่สามารถจำแนกพันธุ์ได้ถูกต้องมีน้อย

ด้วยเหตุนี้ผู้วิจัยจึงมีความสนใจที่จะศึกษาการจำแนกพันธุ์อย่างพาราโดยทำการวิเคราะห์ความแตกต่างทางสายพันธุ์จากรูปทรงใบด้วยวิธีการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถรู้จำรูปแบบในงานที่จำเป็นต้องอาศัยประสบการณ์ และความชำนาญได้เป็นอย่างดีเพื่อสร้างตัวแบบจำแนกพันธุ์อย่างพาราที่สามารถนำไปใช้ในการจำแนกสายพันธุ์ได้อย่างถูกต้อง และเป็นเครื่องมือช่วยฝึกสอนบุคลากรให้มีความเชี่ยวชาญมากยิ่งขึ้น

## 1.2 วัตถุประสงค์

1.2.1 เพื่อวิเคราะห์ ออกแบบ และพัฒนาตัวแบบจำแนกพันธุ์อย่างพาราจากลักษณะใบโดยใช้วิธีการเรียนรู้เชิงลึก

1.2.2 เพื่อประเมินประสิทธิภาพของตัวแบบจำแนกพันธุ์อย่างพาราให้ได้ตัวแบบที่มีความเหมาะสม

## 1.3 ขอบเขตการวิจัย

1.3.1 วิเคราะห์ ออกแบบ และพัฒนาตัวแบบจำแนกพันธุ์อย่างพาราที่ปลูกในประเทศไทย 6 สายพันธุ์ ได้แก่ BPM 24, PB 235, RRIM 600, RRIT 226, RRIT 251 และ RRIT 408

1.3.2 ประเมินประสิทธิภาพของตัวแบบจำแนกพันธุ์อย่างพาราให้ได้ตัวแบบที่เหมาะสมต่อการนำไปงาน

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

ได้ตัวแบบจำแนกพันธุ์อย่างพาราที่สามารถจำแนก และระบุพันธุ์จากลักษณะใบอย่างพาราได้อย่างมีประสิทธิภาพ เพื่อเป็นเครื่องมือช่วยอำนวยความสะดวกในการจำแนกพันธุ์อย่างพารา ฝึกสอนบุคลากร และช่วยในการตรวจสอบพันธุ์อย่างให้กับเกษตรกร

## 1.5 นิยามศัพท์เฉพาะ

1.5.1 การเรียนรู้ของเครื่อง (Machine Learning) คือ กระบวนการเรียนรู้งานของเครื่องคอมพิวเตอร์เพื่อทำการวิเคราะห์ และค้นหารูปแบบความสัมพันธ์จากชุดข้อมูล กลุ่มตัวอย่างหรือประสบการณ์ เพื่อสร้างความเข้าใจให้เครื่องคอมพิวเตอร์สามารถทำงานที่เรียนรู้ได้อย่างมีประสิทธิภาพ

1.5.2 เฮเทอโรไซกัส (Heterozygous) คือ ลักษณะทางพันธุกรรมที่เกิดจากการจับคู่ของยีน (Genotype) ที่แตกต่างกันระหว่างยีนเด่นกับยีนด้อย ส่งผลให้เกิดลักษณะ (Phenotype) ของสิ่งมีชีวิตที่ไม่สมบูรณ์ เรียกว่า ลักษณะพันธุทาง

1.5.3 การผสมภายในสายพันธุ์ (Inbreeding) คือ การผสมพันธุ์ของสิ่งมีชีวิตที่มีความสัมพันธ์กันทางสายพันธุ์ ทำให้ยีนด้อยปรากฏเพิ่มมากขึ้น และมีอัตราการเกิดพันธุ์แท้ (ลักษณะที่เกิดจากคู่ยีนที่เหมือนกัน) ซึ่งอาจเป็นลักษณะด้อยทั้งคู่ ส่งผลให้เกิดความเสื่อมของลักษณะทั้งความแข็งแรง และการให้ผลผลิต

1.5.4 ลักษณะทางสัณฐานวิทยา (Morphological Characteristics) คือ ลักษณะโครงสร้างภายนอกของสิ่งมีชีวิตที่สามารถสังเกตเห็นได้ชัดเจน เช่น สี ขนาด รูปร่าง รูปทรง เป็นต้น

## บทที่ 2

### เอกสารและงานวิจัยที่เกี่ยวข้อง

การศึกษาการจำแนกพันธุ์ยางพาราโดยใช้วิธีการเรียนรู้เชิงลึกในครั้งนี้ ผู้วิจัยได้ศึกษาความรู้พื้นฐานเกี่ยวกับพันธุ์ยางพารา งานวิจัยที่เกี่ยวข้องกับการจำแนกพันธุ์ยางพาราและพันธุ์พืชอื่น ๆ รวมทั้งแนวคิดและทฤษฎีที่สามารถนำมาประยุกต์ใช้ ได้แก่

- 2.1 พันธุ์ยางพารา (Hevea Clones)
- 2.2 การพัฒนาโปรแกรมแบบดั้งเดิม (Traditional Programming)
- 2.3 การเรียนรู้ของเครื่อง (Machine Learning)
- 2.4 เซลล์ประสาท (Biological Neuron)
- 2.5 โครงข่ายประสาท (Biological Neural Network)
- 2.6 เซลล์ประสาทประดิษฐ์ (Artificial Neuron)
- 2.7 โครงข่ายประสาทประดิษฐ์ (Artificial Neural Network)
- 2.8 โครงข่ายประสาทประดิษฐ์คอนโวลูชัน (Convolutional Neural Network)
- 2.9 การเรียนรู้เชิงลึก (Deep Learning)
- 2.10 การถ่ายโอนความรู้ (Transfer Learning)
- 2.11 ตัวแบบพื้นฐาน (Pre-trained Model)
- 2.12 งานวิจัยที่เกี่ยวข้อง (Related Research)

#### 2.1 พันธุ์ยางพารา (Hevea Clones)

ยางพารา (Para Rubber) เป็นพืชยืนต้น (Perennial Trees) ในจีนัส Hevea วงศ์ Euphorbiaceae เป็นแหล่งผลิตยางธรรมชาติร้อยละ 99 ของโลก [8] มีถิ่นกำเนิดมาจากทวีปอเมริกาใต้ ประเทศบราซิล เป็นพืชเศรษฐกิจที่มีความสำคัญต่อประเทศไทยที่มีสถิติการส่งออกเป็นอันดับ 1 ของโลก นับตั้งแต่ปี พ.ศ. 2534 เป็นต้นมา การปลูกยางในประเทศไทยเริ่มต้นจากการนำเมล็ดยางเข้ามาปลูกตั้งแต่ปี พ.ศ. 2443 ในระยะแรกได้ผลผลิตต่ำมาก ไม่ถึง 100 กิโลกรัมต่อไร่ต่อปี ต่อมาได้มีการศึกษาวิจัยใช้ความรู้ทางวิชาการในการปรับปรุงพันธุ์ยาง จนปัจจุบันพันธุ์ยางที่แนะนำให้เกษตรกรปลูกให้ผลผลิตเฉลี่ย 400-500 กิโลกรัมต่อไร่ต่อปี พันธุ์ยางที่แนะนำ แบ่งออกเป็น 3 กลุ่ม ตามวัตถุประสงค์การปลูก ได้แก่

- 1) พันธุ์ยางผลผลิตน้ำยางสูง เป็นพันธุ์ที่ปลูกเพื่อมุ่งเน้นผลผลิตน้ำยางเป็นหลัก ให้ผลผลิตน้ำยางสูง

2) พันธุ์ยางผลผลิตน้ำยางและเนื้อไม้สูง เป็นพันธุ์ที่ปลูกเพื่อมุ่งเน้นทั้งผลผลิตน้ำยางและเนื้อไม้ ลักษณะลำต้นตรง มีการเจริญเติบโตที่ดี ให้ผลผลิตน้ำยางและปริมาณเนื้อไม้ในส่วนของลำต้นสูง

3) พันธุ์ยางผลผลิตเนื้อไม้สูง เป็นพันธุ์ที่ปลูกเพื่อมุ่งเน้นผลผลิตเนื้อไม้เป็นหลัก ลักษณะลำต้นตรง มีการเจริญเติบโตดีมาก ให้ผลผลิตเนื้อไม้ในส่วนของลำต้นสูงมากแต่ระดับผลผลิตน้ำยางต่ำ

ผลผลิตที่ได้จากยางพาราจะขึ้นอยู่กับปัจจัยต่าง ๆ ตั้งแต่สายพันธุ์ สภาพแวดล้อมและการปรับตัวของพันธุ์เข้ากับสภาพแวดล้อม การปลูกยางพาราจึงยึดถือหลักการปลูกพันธุ์ที่ให้ผลผลิตสูงสุด และมีความเหมาะสมกับสภาพแวดล้อมในพื้นที่ของเกษตรกรผู้ปลูก โดยเฉพาะผลผลิตน้ำยางธรรมชาติที่ได้จากต้นยางพาราจะมีคุณสมบัติบางอย่างที่ยางสังเคราะห์ (Synthetic Rubber) ไม่สามารถทำให้เหมือนได้ ทำให้ความต้องการยางพาราเพิ่มสูงขึ้นและได้รับการปรับปรุงพันธุ์อย่างต่อเนื่อง ซึ่งสถาบันวิจัยยาง กรมวิชาการเกษตรได้ทำการศึกษาวิจัยเพื่อปรับปรุงพันธุ์และได้มีประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดต้นยางพันธุ์ดี พ.ศ. 2556 [2] เพื่อแนะนำให้เกษตรกรปลูกแบ่งออกเป็น 3 ชั้น ดังนี้

**พันธุ์ยางชั้น 1** แนะนำให้เกษตรกรปลูกได้โดยไม่จำกัดเนื้อที่ปลูก ผ่านการทดลองและศึกษา ลักษณะต่าง ๆ มาอย่างละเอียด ได้แก่ พันธุ์ RRIT 251, RRIT 226, RRIT 408, BPM 24, RRIM 600, RRII 118, PB 235, PB 255, PB 260, Chachoengsao 50, AVROS 2037, BPM 1

**พันธุ์ยางชั้น 2** แนะนำให้เกษตรกรปลูกได้ไม่เกินร้อยละ 30 ของเนื้อที่ปลูกยางที่ถือครอง แต่ละพันธุ์ควรปลูกไม่น้อยกว่า 7 ไร่ และควรปลูกภายใต้การแนะนำ เนื่องจากเป็นพันธุ์ที่อยู่ในระหว่างการทดลองและศึกษาลักษณะบางประการเพิ่มเติม ได้แก่ พันธุ์ RRIT 218, RRIT 250, RRIT 319, RRIT 405, RRIT 406, RRIT 410, RRIT 411, RRIT 416, RRIT 3601, RRIT 3602, RRIT 3605, RRIT 3606, Haiken 2, PR 302, PR 305, RRIC 100, RRIC 101, RRIT 312, RRIT 325, RRIT 403, RRIT 404, RRIT 407, RRIT 409, RRIT 412, RRIT 413, RRIT 3604, RRIT 3607, RRIC 121, RRII 203, RRIT 401, RRIT 414, RRIT 415

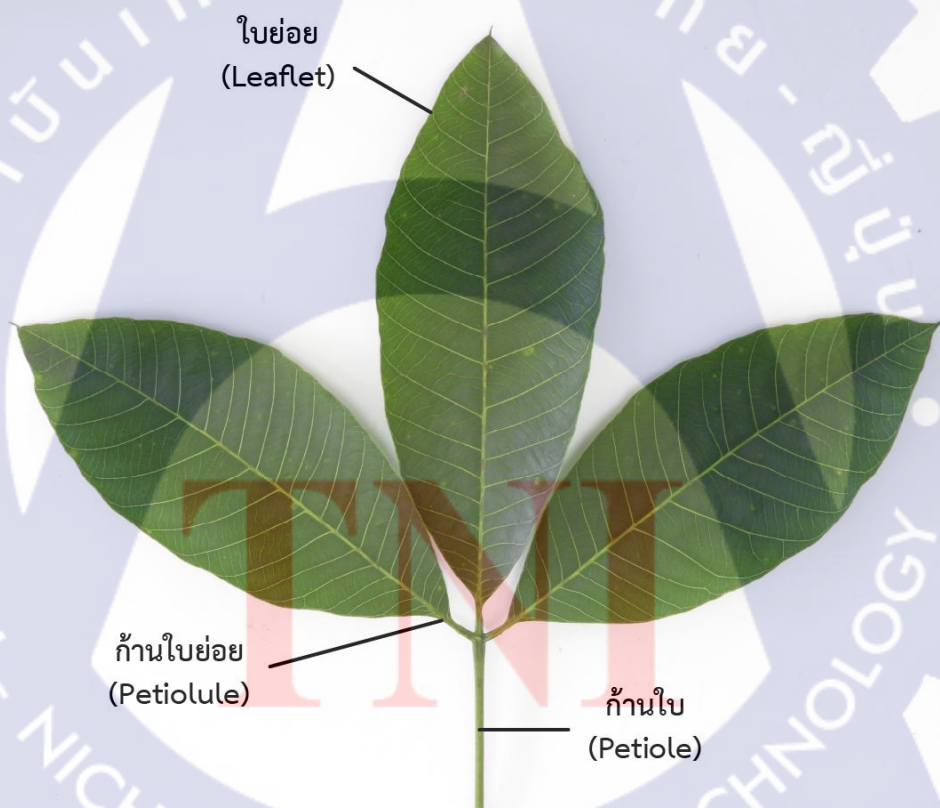
**พันธุ์ยางชั้น 3** แนะนำให้เกษตรกรปลูกได้ไม่เกินร้อยละ 20 ของเนื้อที่ปลูกยางที่ถือครอง แต่ละพันธุ์ควรปลูกไม่น้อยกว่า 7 ไร่ และควรปลูกภายใต้การแนะนำ เนื่องจาก เป็นพันธุ์ที่อยู่ในระหว่างการทดลองและยังมีข้อมูลจำกัด ได้แก่ RRIT 3701, RRIT 3702, RRIT 3901, RRIT 3902, RRIT 3903, RRIT 3904, RRIT 3905, RRIT 3906

การจำแนกพันธุ์ยางพาราจะพิจารณาจากลักษณะภายนอกหลายลักษณะประกอบกันผ่านการสังเกตและสัมผัส แบ่งออกเป็นกลุ่มตามลักษณะสัญญาณวิทยาในแต่ละระยะ คือ

1) ระยะต้นยางอ่อน (Immature) ลักษณะที่ใช้ในการจำแนกพันธุ์ ได้แก่ ฉัตรใบ (Leaf Storey) ใบ (Leaf) ก้านใบ (Petiole) ก้านใบย่อย (Petiolule) เปลือก (Bark) ตา (Axillary Bud) และสีน้ำยาง (Color of Latex)

2) ระยะต้นยางใหญ่ (Mature) ลักษณะที่ใช้ในการจำแนกพันธุ์ ได้แก่ ลำต้น (Stem) ทรงพุ่ม (Crown) การแตกกิ่ง (Branching) และเมล็ด (Seed)

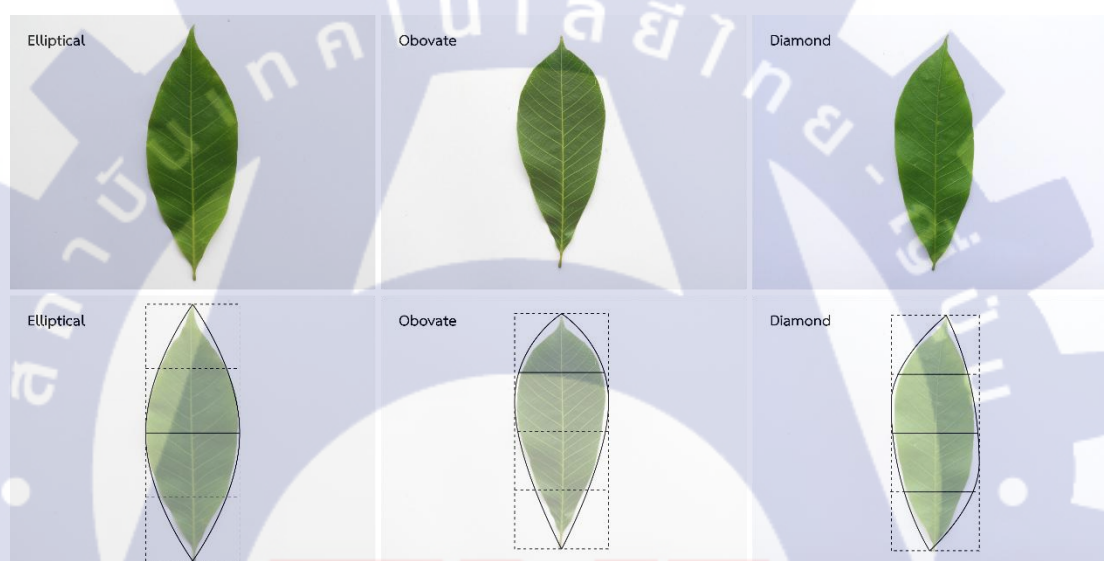
ลักษณะบางอย่างของต้นยางพารามีให้เห็นเพียงบางช่วงเวลา แต่การตรวจสอบความถูกต้องของพันธุ์ควรตรวจสอบตั้งแต่ยังอยู่ในระยะต้นยางชำถุง ก่อนที่จะปลูกลงแปลง ทำให้ลักษณะที่สามารถนำมาใช้ในการจำแนกได้นั้นถูกจำกัดลงไปอีก ใบ (Leaf) จึงเป็นเพียงลักษณะเดียวที่เหมาะสมในการจำแนกสายพันธุ์โดยมักพิจารณาจากรูปร่างใบ (Leaf Shape) เนื่องจากเป็นลักษณะที่มีความชัดเจน สามารถสังเกตเห็นได้ง่ายและรวดเร็ว ใบยางจัดเป็นใบประกอบ (Compound Leaf) ซึ่งมี 3 ใบย่อย (Leaflet) ตรึงอยู่บนก้านใบ (รูปที่ 2.1) ลักษณะและขนาดของใบจะแตกต่างกันไปตามพันธุ์ การจำแนกพันธุ์ยางจะใช้ลักษณะของใบกลางเป็นหลัก แบ่งออกเป็น 3 รูปทรงหลัก [6] ดังตารางที่ 2.1 และรูปที่ 2.2



รูปที่ 2.1 ใบย่อยยางพารา

ตารางที่ 2.1 รูปทรงใบอย่างพารา

ทรงใบ	ลักษณะ
ป้อมกลางใบ (Elliptical)	ความยาวของใบมีลักษณะประมาณ 2-3 เท่าของความกว้าง และส่วนที่กว้างที่สุดของใบอยู่บริเวณกลางใบ ขอบใบเรียบไปด้านปลายและฐานใบเท่ากัน
ป้อมปลายใบ (Obovate)	ส่วนกว้างที่สุดของใบอยู่บริเวณส่วนกลางระหว่างปลายใบและกึ่งกลางใบ
รูปเป็ยกปูน (Diamond)	ส่วนที่กว้างที่สุดของแผ่นใบสองข้างไม่ตรงกัน ส่วนกว้างที่สุดของใบอยู่บริเวณระหว่างปลายใบและกึ่งกลางใบ



รูปที่ 2.2 รูปทรงใบอย่างพารา

พันธุ์ยางพาราที่ปลูกในประเทศไทยทั้ง 6 สายพันธุ์ ได้แก่ RRIT 251, RRIT 226, RRIT 408, BPM 24, RRIM 600, และ PB 235 สามารถใช้ใบเป็นลักษณะในการจำแนกได้ดังตารางที่ 2.2

ตารางที่ 2.2 เกณฑ์ที่ใช้ในการจำแนกพันธุ์จากลักษณะใบ

เกณฑ์ที่ใช้ในการจำแนกพันธุ์จากลักษณะใบ			
เกณฑ์	BPM 24	PB 235	RRIM 600
1. รูปร่างของใบกลาง	ป้อมกลางใบ	ป้อมกลางใบ	ป้อมปลายใบ
2. ความกว้างของใบกลาง	แคบ	แคบ	กว้าง
3. ความยาวของใบกลาง	ยาว	ยาว	ปานกลาง
4. สีใบ	เขียว	เขียวอมเหลือง	เขียวอมเหลือง
5. ความมันของผิวใบ	ไม่เป็นมัน	เป็นมันเล็กน้อย	เป็นมัน
6. ปลายใบ	เรียวแหลม	เรียวแหลม	ติ่งแหลม
7. ฐานใบ	สอบเรียว	รูปลิ้ม	สอบเรียว
8. เส้นกลางใบ	ไม่ชัด	มองเห็นเด่นชัด	มองเห็นเด่นชัด
9. สีของเส้นใบ	เขียว	เหลืองอมเขียว	เหลืองอมเขียว
10. ลักษณะแผ่นใบ	เรียบ	เรียบ	เรียบ
11. ลักษณะใบตัดตามขวาง	ตรง	ตรง	ตรง
12. ลักษณะใบตัดตามยาว	ตรง	ตรง	ตรง
13. ขอบใบ	เรียบ	เรียบ	เรียบ
14. ใบย่อยซ้าย-ขวาเปรียบเทียบกับใบกลาง	รูปร่างแบบเดียวกันและขนาดเท่ากัน	รูปร่างแบบเดียวกันและขนาดเท่ากัน	รูปร่างแบบเดียวกันแต่ขนาดเล็กกว่า
15. ตำแหน่งขอบใบย่อย	สัมผัสกัน	แยกจากกัน	แยกจากกัน
16. ระดับของใบย่อย	อยู่ในแนวระดับเดียวกัน	อยู่ในแนวระดับเดียวกัน	อยู่ในแนวระดับเดียวกัน

ตารางที่ 2.2 เกณฑ์ที่ใช้ในการจำแนกพันธุ์จากลักษณะใบ (ต่อ)

เกณฑ์ที่ใช้ในการจำแนกพันธุ์จากลักษณะใบ			
เกณฑ์	RRIT 226	RRIT 251	RRIT 408
1. รูปร่างของใบกลาง	ป้อมปลายใบ	ป้อมปลายใบ	ป้อมปลายใบ
2. ความกว้างของใบกลาง	กว้าง	กว้าง	กว้าง
3. ความยาวของใบกลาง	ปานกลาง	ปานกลาง	ปานกลาง
4. สีใบ	เขียวอมเหลือง	เขียวอมเหลือง	เขียว
5. ความมันของผิวใบ	เป็นมัน	เป็นมัน	ไม่เป็นมัน
6. ปลายใบ	ติ่งแหลม	ติ่งแหลม	ติ่งแหลม
7. ฐานใบ	รูปลิ้ม	รูปลิ้ม	รูปลิ้ม
8. เส้นกลางใบ	มองเห็นเด่นชัด	มองเห็นเด่นชัด	มองเห็นเด่นชัด
9. สีของเส้นใบ	เหลืองอมเขียว	เหลืองอมเขียว	เหลืองอมเขียว
10. ลักษณะแผ่นใบ	หยาบ/ขรุขระ	หยาบ/ขรุขระ	เป็นลอน
11. ลักษณะใบตัดตามขวาง	ตรง	เว้า/ท้องเรือ	ตรง
12. ลักษณะใบตัดตามยาว	ตรง	ตรง	ตรง
13. ขอบใบ	เรียบ	คลื่นหยาบ	เรียบ
14. ใบย่อยซ้าย - ขวา เปรียบเทียบกับใบกลาง	รูปร่างแบบเดียวกัน แต่ขนาดเล็กกว่า	รูปร่างแบบเดียวกัน แต่ขนาดเล็กกว่า	รูปร่างแบบเดียวกัน แต่ขนาดเล็กกว่า
15. ตำแหน่งขอบใบย่อย	ทับกัน	แยกจากกัน	แยกจากกัน
16. ระดับของใบย่อย	อยู่ในแนวระดับเดียวกัน	อยู่ในแนวระดับเดียวกัน	อยู่ในแนวระดับเดียวกัน

## 2.2 การพัฒนาโปรแกรมแบบดั้งเดิม (Traditional Programming)

การพัฒนาโปรแกรมแบบดั้งเดิม คือ การพัฒนาโปรแกรมคอมพิวเตอร์ที่ต้องอาศัยผู้พัฒนาในการรวบรวมข้อมูล (Data) ศึกษาและวิเคราะห์ความต้องการของลักษณะงานเพื่อสร้างเงื่อนไข (Rule) และกำหนดวิธีการประมวลผล (Algorithm) ให้โปรแกรมมีกระบวนการทำงาน (Logic) ในการแก้ไขปัญหาต่าง ๆ ได้ตามที่ต้องการ โดยผลลัพธ์ (Answers) จะถูกส่งออกมาตามเงื่อนไขที่ได้ถูกกำหนดไว้ (รูปที่ 2.3) บนพื้นฐานความเข้าใจของผู้พัฒนา




รูปที่ 2.3 การพัฒนาโปรแกรมแบบดั้งเดิม

แต่เนื่องจากปัจจัยและสิ่งแวดล้อมที่เปลี่ยนแปลงอยู่ตลอดเวลาทำให้ไม่สามารถกำหนดเงื่อนไขต่าง ๆ ให้ครอบคลุมต่อการใช้งานได้ทั้งหมด การพัฒนาโปรแกรมคอมพิวเตอร์แบบดั้งเดิมไม่สามารถตอบสนองต่อความต้องการได้อย่างเต็มประสิทธิภาพ จึงทำให้เกิดแนวคิดในการพัฒนาให้คอมพิวเตอร์มีความชาญฉลาดมากยิ่งขึ้นด้วยการเรียนรู้จากตัวอย่าง เรียกว่า การเรียนรู้ของเครื่อง เพื่อแก้ปัญหาที่มีความซับซ้อนมากยิ่งขึ้น

## 2.3 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง คือ กระบวนการเรียนรู้งาน (Task) ของเครื่องคอมพิวเตอร์ (Machine) เพื่อทำการวิเคราะห์และค้นหารูปแบบ (Pattern) ความสัมพันธ์ (Relationships between Features) จากชุดข้อมูล (Dataset) กลุ่มตัวอย่าง (Sample) หรือประสบการณ์ (Experience) เพื่อสร้างความเข้าใจ กำหนดเป็นเงื่อนไขให้เครื่องคอมพิวเตอร์สามารถทำงานต่าง ๆ ได้อย่างมีประสิทธิภาพ (Performance) (รูปที่ 2.4) บนพื้นฐานของข้อมูลที่ใช้ในการฝึกสอน [9]



รูปที่ 2.4 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง แบ่งออกเป็น 4 กลุ่มดังนี้

- 1) การวิเคราะห์การถดถอย (Regression) เป็นการหาความสัมพันธ์ของตัวแปรที่สนใจเพื่อให้เครื่องคอมพิวเตอร์สามารถทำการพยากรณ์แนวโน้ม (Trend) ที่จะเกิดขึ้นได้อย่างมีประสิทธิภาพ
- 2) การจำแนกกลุ่มข้อมูล (Classification) เป็นการค้นหารูปแบบของข้อมูลเพื่อให้เครื่องคอมพิวเตอร์สามารถแยกแยะกลุ่ม (Class) ของข้อมูลได้อย่างมีประสิทธิภาพ
- 3) การแบ่งกลุ่มข้อมูล (Clustering) เป็นการค้นหารูปแบบของข้อมูลเพื่อให้เครื่องคอมพิวเตอร์สามารถจัดกลุ่ม (Cluster) ของข้อมูลตามคุณลักษณะต่าง ๆ ได้อย่างมีประสิทธิภาพ
- 4) การลดมิติข้อมูล (Dimensionality Reduction) เป็นการค้นหารูปแบบของข้อมูลให้เครื่องคอมพิวเตอร์สามารถทำการลดมิติข้อมูลเพื่อลดความซับซ้อนก่อนนำไปใช้งาน

การทำงานที่มีประสิทธิภาพของเครื่องคอมพิวเตอร์นั้นเกิดขึ้นจากการเลียนแบบลักษณะการเรียนรู้ของมนุษย์ โดยสามารถแบ่งการเรียนรู้ของเครื่องคอมพิวเตอร์ออกเป็น 3 ประเภท ได้แก่

### 2.3.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

กระบวนการเรียนรู้ของเครื่องคอมพิวเตอร์จากชุดข้อมูลที่มีการกำกับสถานะ (Labeled) ด้วยคุณลักษณะ (Feature) ของสิ่งที่ต้องการให้เครื่องทำความรู้จักได้อย่างชัดเจนและรวดเร็วเพื่อให้เครื่องทำการประมวลผล หลังจากที่ทำการฝึกสอนแล้วเครื่องสามารถแยกแยะสิ่งที่ทำการฝึกสอนได้อย่างมีประสิทธิภาพ

### 2.3.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

กระบวนการเรียนรู้ของเครื่องคอมพิวเตอร์ที่เรียนรู้ด้วยตนเองจากชุดข้อมูลที่ไม่ได้มีการกำกับสถานะ (Unlabeled) โดยจะทำการประมวลผลเพื่อค้นหารูปแบบและกฎเกณฑ์ต่าง ๆ ที่เป็นคุณลักษณะ (Feature) ที่แตกต่างกันออกไปโดยอัตโนมัติ

### 2.3.3 การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning)

กระบวนการเรียนรู้ของเครื่องคอมพิวเตอร์จากชุดข้อมูลด้วยการลองผิดลองถูก อาศัยผลลัพธ์ (Output) ตอบกลับการกระทำแล้วปรับปรุงตนเองจนสามารถทำงานได้อย่างมีประสิทธิภาพ

## 2.4 เซลล์ประสาท (Biological Neuron)

เซลล์ประสาท (Biological Neuron) เป็นหน่วยเล็กที่สุดในระบบประสาทของสิ่งมีชีวิตทำหน้าที่รับความรู้สึก ประสานงานและตอบสนองต่อสิ่งเร้า ผ่านการส่งสัญญาณไฟฟ้า [10] (รูปที่ 2.5) ประกอบด้วย

### 2.4.1 ใยประสาทนำเข้า (Dendrite)

ทำหน้าที่รับส่งสัญญาณสิ่งเร้าจากภายนอกและสัญญาณภายในร่างกาย (สัญญาณจากเซลล์ประสาทอื่น ๆ) นำกระแสประสาทเข้าสู่ตัวเซลล์

### 2.4.2 ตัวเซลล์ (Cell Body)

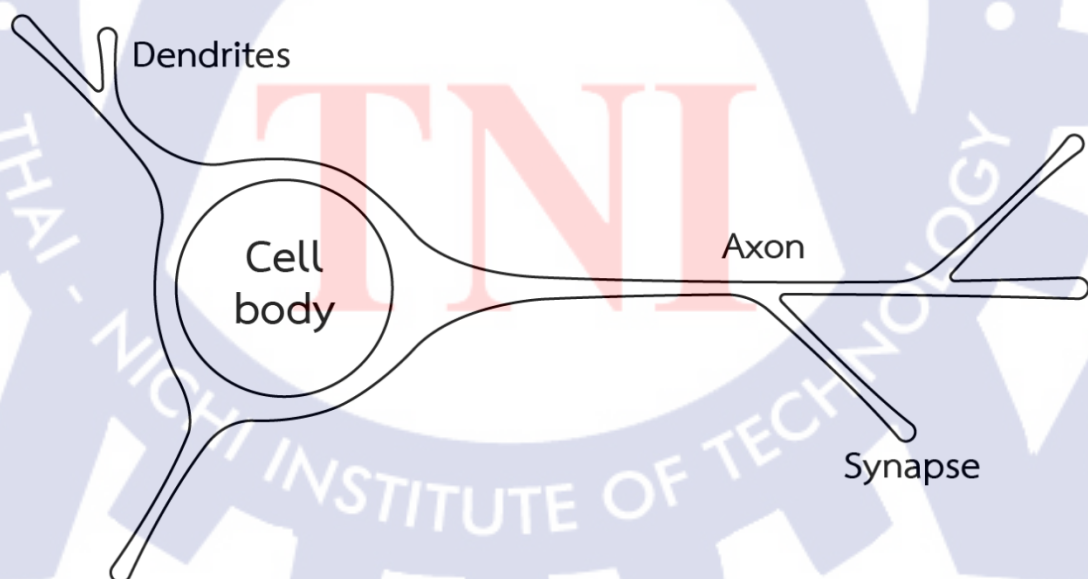
ทำหน้าที่เป็นจุดรวมสัญญาณที่ได้รับมาจากใยประสาทนำเข้าเพื่อนำมาทำการประมวลผลก่อนส่งออกไปยังเซลล์ตัวอื่น

### 2.4.3 แกนประสาทนำออก (Axon)

ทำหน้าที่นำส่งสัญญาณออก นำกระแสประสาทออกจากตัวเซลล์ส่งต่อไปยังเซลล์ตัวอื่น

### 2.4.4 จุดประสานประสาท (Synapse)

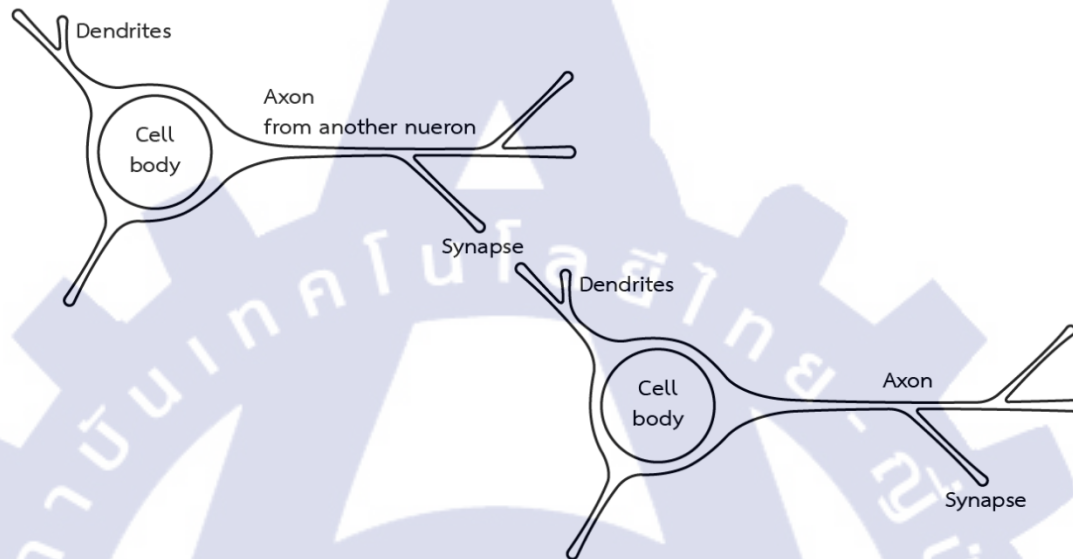
ทำหน้าที่ส่งสัญญาณจากแกนประสาทนำออกไปยังใยประสาทนำเข้าของเซลล์อื่น



รูปที่ 2.5 โครงสร้างเซลล์ประสาท [10]

## 2.5 โครงข่ายประสาท (Biological Neural Network)

โครงข่ายประสาท คือ ระบบประสาทของมนุษย์โดยภายในโครงข่ายประสาทประกอบด้วย เซลล์ประสาทจำนวนมากเชื่อมต่อกันระหว่างเซลล์จนเกิดเป็นโครงข่าย (Network) ที่ทำงานร่วมกัน ทำให้เกิดกระบวนการคิดวิเคราะห์ที่สลับซับซ้อน สามารถทำงานและแก้ปัญหาต่าง ๆ ได้อย่างมีประสิทธิภาพ ดังรูปที่ 2.6

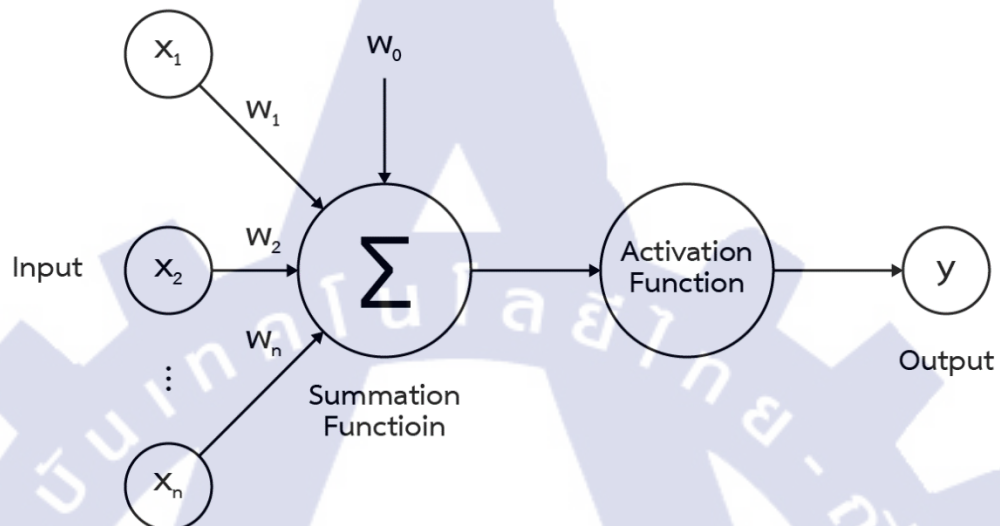


รูปที่ 2.6 โครงข่ายประสาท [10][11]

เมื่อคอมพิวเตอร์ทั่วไปไม่สามารถทำงานหรือแก้ไขปัญหาที่มีความซับซ้อนได้ มนุษย์จึงทำการเลียนแบบแนวคิดดังกล่าวขึ้นมาเพื่อเพิ่มประสิทธิภาพความฉลาดของเครื่องคอมพิวเตอร์ เรียกว่า เซลล์ประสาทประดิษฐ์ (Artificial Neuron) ที่มีความสามารถในการปรับตัว เรียนรู้จากสภาพแวดล้อมที่เปลี่ยนแปลงไปและถูกนำไปใช้อย่างแพร่หลาย

## 2.6 เซลล์ประสาทประดิษฐ์ (Artificial Neuron)

เซลล์ประสาทประดิษฐ์ คือ ตัวแบบทางคณิตศาสตร์ที่เลียนการทำงานของเซลล์ประสาทในสิ่งมีชีวิต [12] (รูปที่ 2.7) มีหน่วยนำเข้าข้อมูล (Input Node) ในการรับข้อมูลเข้าสู่เซลล์ประสาทโดยจะทำการคำนวณผลรวม (Summation Function) ออกมาทางหน่วยส่งผลลัพธ์ (Output Node)



รูปที่ 2.7 โครงสร้างเซลล์ประสาทประดิษฐ์ [10][11]

$$s = w_0 + (w_1 * x_1) + (w_2 * x_2) + \dots (w_n * x_n) \quad (2.1)$$

$$S = \sum_{j=1}^n w_j x_j \quad (2.2)$$

$w_0$  แทนค่า ส่วนเบี่ยงเบน (Bias)

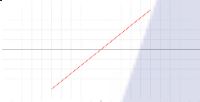
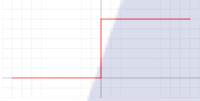


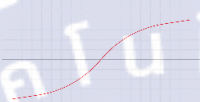


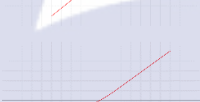
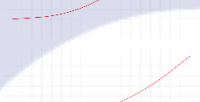
$w_n$  แทนค่า น้ำหนัก (Weight)

$x_n$  แทนค่า ข้อมูลนำเข้า (Input)

$n$  แทนค่า จำนวนข้อมูลนำเข้า (Number of Input)

ค่าผลรวมจะถูกนำมาประมวลผลเพื่อใช้ในการตัดสินใจผ่านฟังก์ชันกระตุ้น (Activation Function) (ตารางที่ 2.3) ด้วยค่าเกณฑ์ (Threshold) ที่ถูกกำหนดขึ้น


ตารางที่ 2.3 ฟังก์ชันกระตุ้น (Activation Function) พื้นฐาน

ฟังก์ชัน	แผนภาพ	สมการ
Identity		$f(x) = x$
Binary Step		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$
Sigmoid / Logistic (a. k. a. Soft step)		$f(x) = \frac{1}{1 + e^{-x}}$
TanH		$f(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$
ArcTan		$f(x) = \tan^{-1}(x)$
Rectified Linear Unit (ReLU)		$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$
Parametric Rectified Linear Unit (PReLU)		$f(x) = \begin{cases} \alpha x & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$
Exponential Linear Unit (ELU)		$f(x) = \begin{cases} \alpha(e^x - 1) & \text{for } x < 0 \\ x & \text{for } x \geq 0 \end{cases}$
SoftPlus		$f(x) = \log_e(1 + e^x)$

เซลล์ประสาทประติษฐ์ที่เชื่อมต่อกันจำนวนมากจนเกิดเป็นโครงข่ายประสาทประติษฐ์ (Artificial Neural Network) ทำให้คอมพิวเตอร์มีความเหมาะสมในการนำไปใช้ในการทำงานหรือแก้ปัญหาที่ต้องทำการวิเคราะห์โดยผู้เชี่ยวชาญและอาศัยประสบการณ์มากยิ่งขึ้น

## 2.7 โครงข่ายประสาทประดิษฐ์ (Artificial Neural Network : ANN)

โครงข่ายประสาทประดิษฐ์ คือ ตัวแบบของระบบประสาทมนุษย์เกิดจากการประสานงานของเซลล์ประสาทประดิษฐ์ (Artificial Neuron) (รูปที่ 2.8) ประกอบด้วย



รูปที่ 2.8 โครงข่ายประสาทประดิษฐ์ [10][11]

### 2.7.1 ชั้นนำเข้าข้อมูล (Input Layer)

ทำหน้าที่นำข้อมูลเข้าสู่โครงข่าย โดยจำนวนเซลล์ประสาทจะขึ้นอยู่กับจำนวนข้อมูลนำเข้า

### 2.7.2 ชั้นประมวลผลข้อมูล (Hidden Layer)

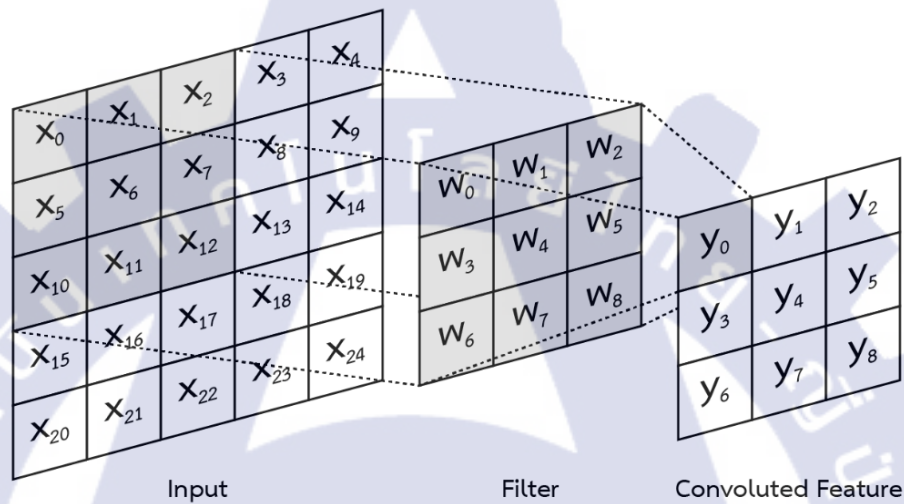
เป็นชั้นที่อยู่ระหว่างกลางของโครงข่ายที่ทำหน้าที่ในการประมวลผลทางคณิตศาสตร์เพื่อสกัดคุณลักษณะของข้อมูลที่ป้อนเข้ามาจากชั้นนำเข้าข้อมูล

### 2.7.3 ชั้นนำออกข้อมูล (Output Layer)

ทำหน้าที่นำผลลัพธ์ที่ได้จากชั้นประมวลผลออกจากโครงข่ายเพื่อนำไปใช้ในการตัดสินใจ

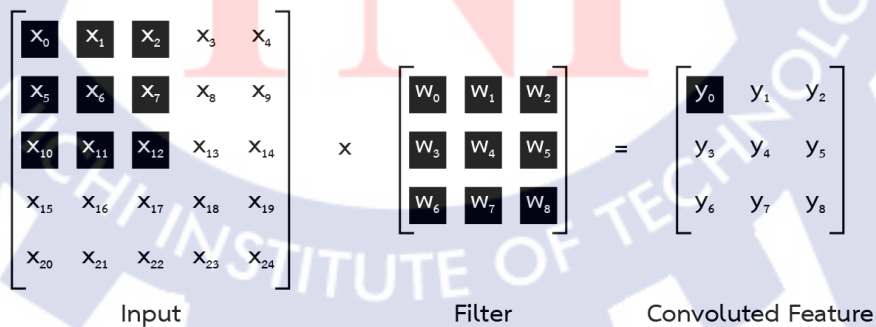
## 2.8 โครงข่ายประสาทประดิษฐ์คอนโวลูชัน (Convolutional Neural Network : CNN)

โครงข่ายประสาทประดิษฐ์คอนโวลูชันเป็นรูปแบบของโครงข่ายประสาทประดิษฐ์ [13][14] ที่เลียนแบบการมองเห็นของมนุษย์ออกเป็นพื้นที่ย่อย (Sub Region) ที่มีความสัมพันธ์กัน (Spatial Relationship) เพื่อทำการสกัดคุณลักษณะ (Feature Extraction) ด้วยการคูณเมทริกซ์ (Matrix Multiplication) ผ่านตัวกรอง (Filter) ซึ่งเป็นตาราง 2 มิติ ที่มีขนาดตามพื้นที่ย่อยที่ต้องการพิจารณา แล้วนำพื้นที่ย่อยมาพาสกันเพื่อประมวลผลสิ่งที่คอมพิวเตอร์มองเห็น (รูปที่ 2.9 และ 2.10)



รูปที่ 2.9 ตัวกรองคอนโวลูชัน [10][11]

$$(x_0 * w_0) + (x_1 * w_1) + (x_2 * w_2) + (x_5 * w_3) + (x_6 * w_4) + (x_7 * w_5) + (x_{10} * w_6) + (x_{11} * w_7) + (x_{12} * w_8) = y_0$$

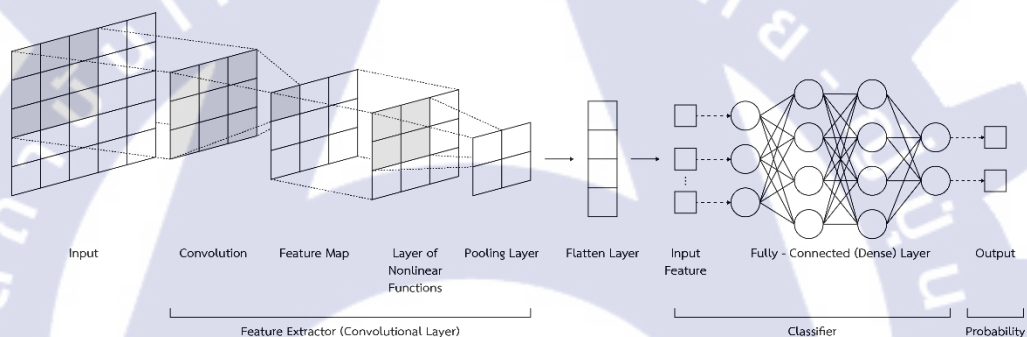


รูปที่ 2.10 การคูณเมทริกซ์

ปัญหาที่มีความท้าทายจำเป็นต้องอาศัยประสบการณ์และความชำนาญ ทำให้เกิดการประมวลผลที่มีความซับซ้อนนำไปสู่จำนวนโครงข่ายประสาทประดิษฐ์ที่เพิ่มมากขึ้น เรียกว่า การเรียนรู้เชิงลึก

## 2.9 การเรียนรู้เชิงลึก (Deep Learning : DL)

การเรียนรู้เชิงลึก คือ เทคโนโลยีคอมพิวเตอร์ที่เลียนแบบโครงสร้างระบบเซลล์ประสาท (Biological Neuron) ของมนุษย์ เกิดจากโครงข่ายประสาทประดิษฐ์ขนาดใหญ่ (Deep Neural Network : DNN) ที่เกิดจากการทำงานร่วมกันของเซลล์ประสาทประดิษฐ์จำนวนมากและมีหลายชั้น (Layers) ซ้อนกัน (Stack) เป็นโครงสร้าง โดยแต่ละชั้นจะเกิดการเรียนรู้ที่แตกต่างกัน [15][16] (รูปที่ 2.11) ทำให้สามารถเรียนรู้งานที่มีความซับซ้อนมากขึ้นได้อย่างมีประสิทธิภาพ [17][18] มีองค์ประกอบดังนี้



รูปที่ 2.11 การเรียนรู้เชิงลึก

### 2.9.1 ชั้นนำเข้าข้อมูล (Input Layer)

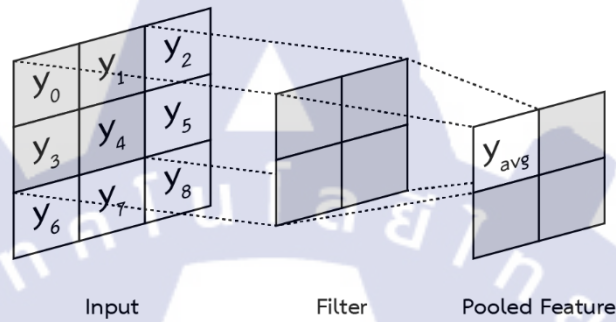
เป็นชั้นโครงข่ายประสาทประดิษฐ์ที่ทำหน้าที่ในการนำข้อมูลเข้าสู่โครงข่ายเพื่อนำไปใช้ประมวลผลในโครงข่ายชั้นถัดไป

### 2.9.2 ชั้นคอนโวลูชัน (Convolutional Layer)

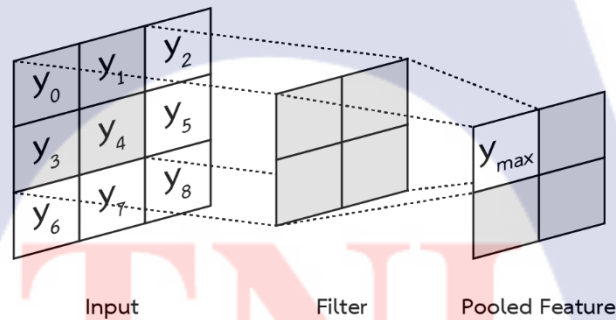
เป็นชั้นโครงข่ายประสาทประดิษฐ์ที่ทำการสกัดคุณลักษณะสำคัญของข้อมูล เพื่อปรับลดขนาดของฟังก์ชันคุณลักษณะ (Feature Map) ที่รับมาจากชั้นนำเข้าข้อมูลให้มีความเหมาะสมแล้วส่งต่อไปยังชั้นพูลลิง

### 2.9.3 ชั้นพูลลิง (Pooling Layer)

เป็นชั้นโครงข่ายประสาทประดิษฐ์ที่ทำการสกัดคุณลักษณะสำคัญของข้อมูลและปรับลดขนาดของฟังก์ชันลักษณะที่รับมาจากชั้นคอนโวลูชันให้มีความเหมาะสมแล้วส่งต่อไปยังชั้นเชื่อมโยงสมบูรณ์ แบ่งเป็น 2 ประเภท คือ การพูลลิงค่าเฉลี่ย (Average Pooling) ที่จะทำการเลือกค่าเฉลี่ยจากฟังก์ชันลักษณะ (รูปที่ 2.12) และการพูลลิงค่าสูงสุด (Max Pooling) ที่จะทำการเลือกค่าสูงสุดจากฟังก์ชันลักษณะ (รูปที่ 2.13)



รูปที่ 2.12 การพูลลิงค่าเฉลี่ย



รูปที่ 2.13 การพูลลิงค่าสูงสุด

### 2.9.4 ชั้นเชื่อมโยงสมบูรณ์ (Fully Connected Layer)

เป็นชั้นโครงข่ายประสาทประดิษฐ์ที่ทำหน้าที่ในการเรียนรู้และจำแนกประเภทของข้อมูลจากฟังก์ชันลักษณะที่มีคุณลักษณะสำคัญของชุดข้อมูลและผ่านการปรับลดขนาดมาแล้ว

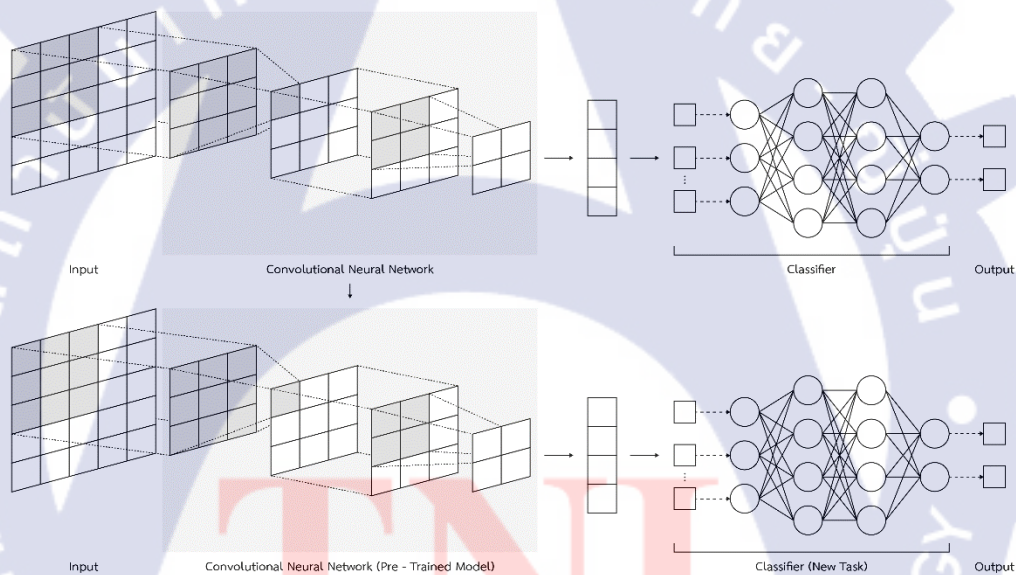
### 2.9.5 ชั้นนำออกข้อมูล (Output Layer)

เป็นชั้นโครงข่ายประสาทประดิษฐ์ที่ทำหน้าที่นำผลลัพธ์ที่ได้จากชั้นเชื่อมโยงสมบูรณ์ไปแปลผลหรือประยุกต์ใช้งานต่อไป

เนื่องจากข้อจำกัดของการเรียนรู้เชิงลึกที่จำเป็นต้องใช้ชุดข้อมูลที่มีปริมาณมาก กำลังการประมวลผลและระยะเวลาในการฝึกสอนทำให้เกิดวิธีการที่เพิ่มประสิทธิภาพของการเรียนรู้เชิงลึกโดยการนำความรู้บางส่วนของตัวแบบที่ผ่านการฝึกสอนมาแล้วมาใช้เป็นส่วนประกอบของตัวแบบใหม่ เรียกว่า การถ่ายโอนความรู้

## 2.10 การถ่ายโอนความรู้ (Transfer Learning)

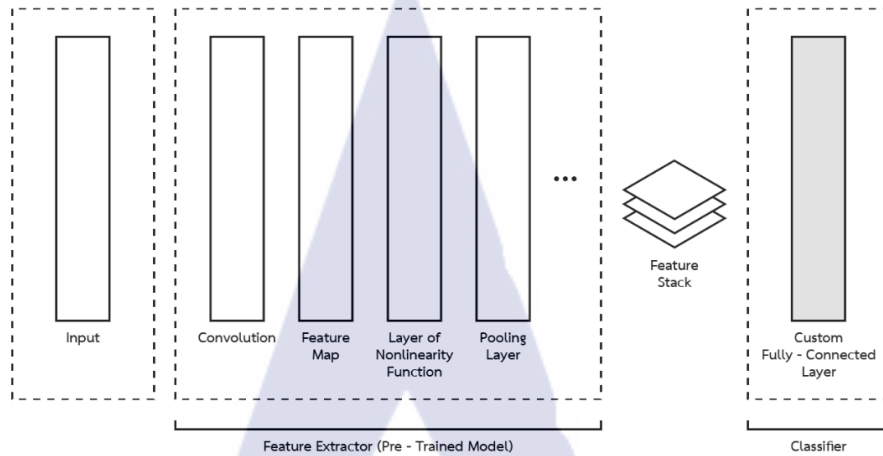
การถ่ายโอนความรู้ คือ การนำความรู้จากตัวแบบพื้นฐานที่ผ่านการฝึกสอนมาแล้ว (Pre-trained Model) มาใช้กับงานที่เกี่ยวข้องกัน เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของเครื่องด้วยชุดข้อมูลของงานที่ต้องการ (Specific Task) ที่มีปริมาณน้อยกว่าและประหยัดเวลาในการฝึกสอนมากกว่าการเรียนรู้เชิงลึกแบบปกติ [19] (รูปที่ 2.14)



รูปที่ 2.14 การถ่ายโอนความรู้

### 2.10.1 การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะ (Feature Extraction Approach : FEA)

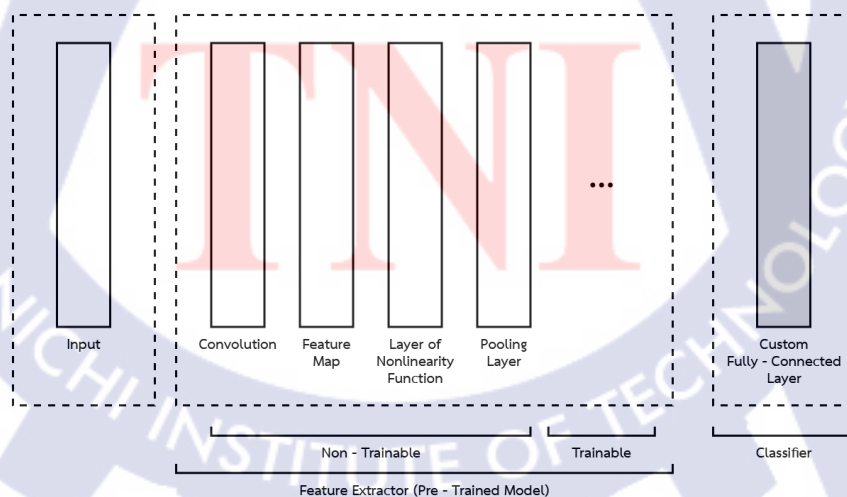
การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะเป็นวิธีการถ่ายโอนความรู้โดยใช้ตัวแบบพื้นฐานมาทำการสกัดคุณลักษณะจากชุดข้อมูลด้วยโครงข่ายประสาทประดิษฐ์แบบคอนโวลูชันไว้ล่วงหน้า แล้วนำคุณลักษณะที่ได้ไปใช้ฝึกสอนเพื่อปรับแต่งตัวจำแนกใหม่ที่ถูกเพิ่มเข้ามาใช้กับงานที่ต้องการ โดยไม่ต้องปรับแต่งตัวโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (รูปที่ 2.15) จึงทำให้สามารถทำการฝึกสอนตัวแบบได้อย่างรวดเร็ว



รูปที่ 2.15 การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะ

2.10.2 การถ่ายโอนความรู้ด้วยการปรับแต่งตัวแบบพื้นฐาน (Fine-Tuning Approach : FTA)

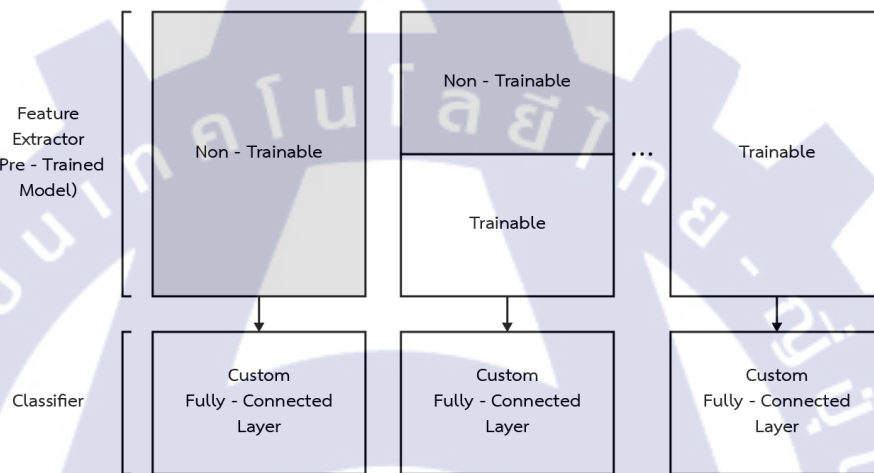
การถ่ายโอนความรู้ด้วยการปรับแต่งตัวแบบพื้นฐานเป็นวิธีการถ่ายโอนความรู้โดยทำการแก้ไขโครงข่ายประสาทประติขันธ์คอนโวลูชันของตัวแบบพื้นฐานเพื่อฝึกสอนตัวจำแนกใหม่ที่ถูกเพิ่มเข้ามาใช้กับงานที่ต้องการ แล้วยกเลิกการแก้ไขโครงข่ายประสาทประติขันธ์คอนโวลูชันเพื่อทำการปรับแต่ง (Fine-Tune) (รูปที่ 2.16 และ 2.17) การเรียนรู้ของโครงข่ายประสาทประติขันธ์คอนโวลูชันให้สามารถเรียนรู้งานที่ต้องการได้มีประสิทธิภาพมากยิ่งขึ้น [20] แบ่งออกเป็น



รูปที่ 2.16 การถ่ายโอนความรู้ด้วยการปรับแต่งตัวแบบพื้นฐาน

1) การปรับแต่งโครงข่ายประสาทประดิษฐ์คอนโวลูชันบางส่วน เป็นวิธีการปรับแต่งโดยทำการแช่แข็งชั้นของโครงข่ายประสาทประดิษฐ์คอนโวลูชันบริเวณส่วนต้นของตัวแบบพื้นฐานเพื่อให้สามารถทำการปรับแต่งชั้นของโครงข่ายประสาทประดิษฐ์คอนโวลูชันบริเวณส่วนปลายได้

2) การปรับแต่งโครงข่ายประสาทประดิษฐ์คอนโวลูชันทั้งตัวแบบ เป็นวิธีการปรับแต่งโดยทำการยกเลิกการแช่แข็งชั้นของโครงข่ายประสาทประดิษฐ์คอนโวลูชันเพื่อให้สามารถปรับแต่งได้ทั้งตัวแบบซึ่งจะใช้ระยะเวลาและกำลังในการประมวลผลสูงกว่าการปรับแต่งโครงข่ายประสาทประดิษฐ์คอนโวลูชันเพียงบางส่วน



รูปที่ 2.17 รูปแบบการปรับแต่งตัวแบบพื้นฐาน [18]

TNI


THAI - NICHI INSTITUTE OF TECHNOLOGY

## 2.11 ตัวแบบพื้นฐาน (Pre-trained Model)

ตัวแบบพื้นฐานที่ผ่านการฝึกสอนมาแล้ว (Pre-trained Model) คือ โครงข่ายประสาทประดิษฐ์เชิงลึกที่ผ่านการฝึกสอนกับฐานข้อมูลภาพ ImageNet [21] ที่มีภาพของวัตถุต่าง ๆ จำนวน 1,000 กลุ่ม ทำให้ตัวแบบมีน้ำหนักเริ่มต้น (Weight Initialization) ที่เป็นประโยชน์ [22] ต่อการนำไปใช้งาน โดยตัวแบบเหล่านี้จะมีโครงสร้างของโครงข่ายประสาทประดิษฐ์ที่แตกต่างกันออกไปตามวัตถุประสงค์การออกแบบและพัฒนา แบ่งออกเป็น

### 2.11.1 VGG

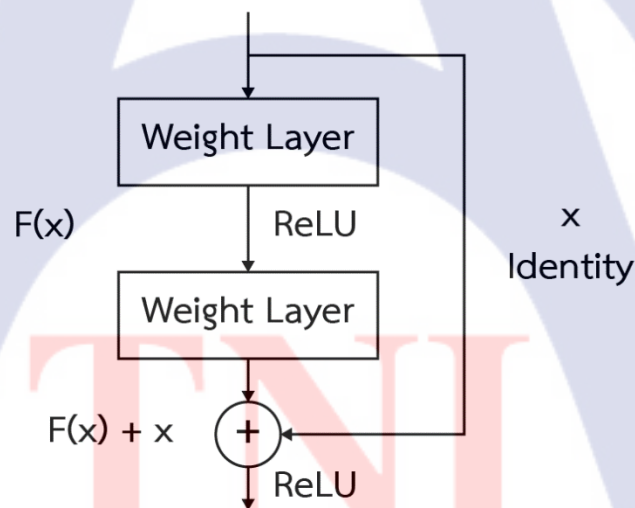
ตัวแบบกลุ่ม VGG (Visual Geometry Group) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2014 โดย Simonyan และ Zisserman [23] บนพื้นฐานแนวคิดของการเพิ่มชั้น (Layer) โครงข่ายประสาทประดิษฐ์คอนโวลูชัน โครงสร้างของตัวแบบประกอบไปด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชันที่เรียบง่าย โดยใช้ตัวกรองคอนโวลูชันขนาดเล็กซ้อนกันจำนวน 16-19 ชั้น (รูปที่ 2.18) เพื่อเพิ่มประสิทธิภาพในการสกัดคุณลักษณะ



รูปที่ 2.18 แนวคิดตัวแบบกลุ่ม VGG [23]

### 2.11.2 ResNet

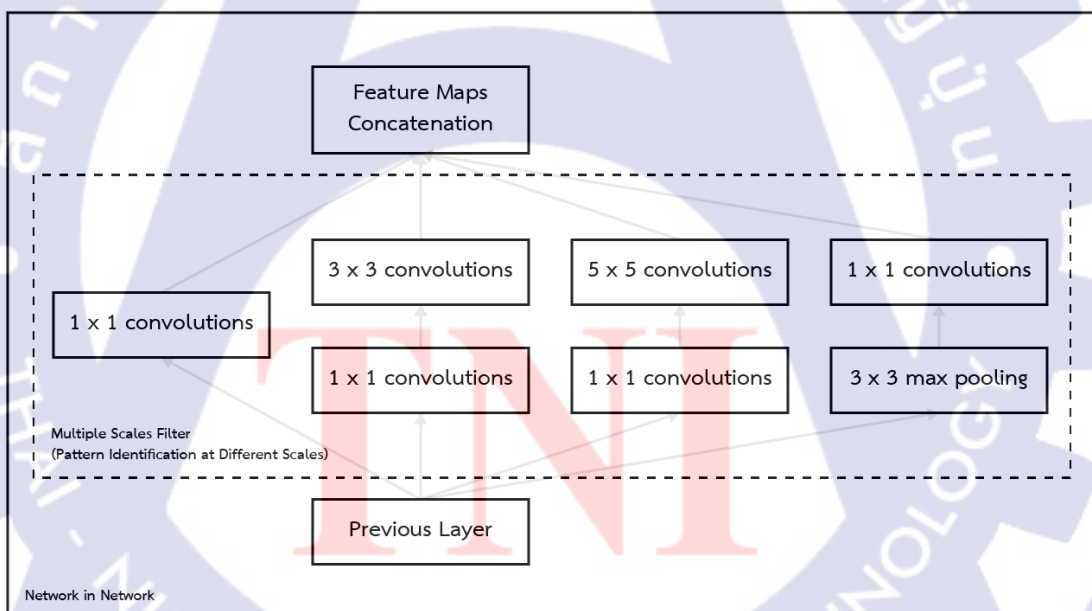
ตัวแบบกลุ่ม ResNet (Residual Network) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่แนะนำให้เสนอในปี ค.ศ. 2015 โดย He และคณะ [24] เพื่อแก้ปัญหาคุณลักษณะเลือนหาย (Vanishing Gradient) ซึ่งเป็นปัญหาที่เกิดขึ้นกับโครงข่ายประสาทประดิษฐ์เชิงลึกที่ทำให้เกิดความผิดพลาดในการฝึกสอนส่งผลให้ตัวแบบมีความแม่นยำลดลง ด้วยการส่งค่าคุณลักษณะข้ามชั้น (Shortcut Connection) แล้วนำมาคำนวณผลรวม (Residual Function) โดยอ้างอิงจากชั้นนำเข้าข้อมูล (Identity Map) (รูปที่ 2.19) ต่อมาแนวคิดนี้ได้ถูกพัฒนาในชื่อ ResNeXt [25] โดยแก้ไขเซลล์ประสาทประดิษฐ์แบบดั้งเดิมด้วยการแยก (Splitting) ข้อมูลนำเข้าไปลดมิติด้วยตัวกรองคอนโวลูชันขนาดเล็ก เพื่อทำการสกัดคุณลักษณะ (Transforming) แล้วคำนวณหาผลรวม (Aggregating) ทำให้ได้ตัวแบบที่มีขนาดเล็กลงและประสิทธิภาพสูงขึ้นตามจำนวนการแยกข้อมูล (Cardinality) ที่เพิ่มขึ้น รวมถึงต่อมาได้มีการปรับกลยุทธ์การฝึกสอนและอัตราส่วนของตัวแบบ [26] จนมีประสิทธิภาพสูงกว่าตัวแบบสมัยใหม่อีกด้วย



รูปที่ 2.19 แนวคิดตัวแบบกลุ่ม ResNet [24]

### 2.11.3 Inception

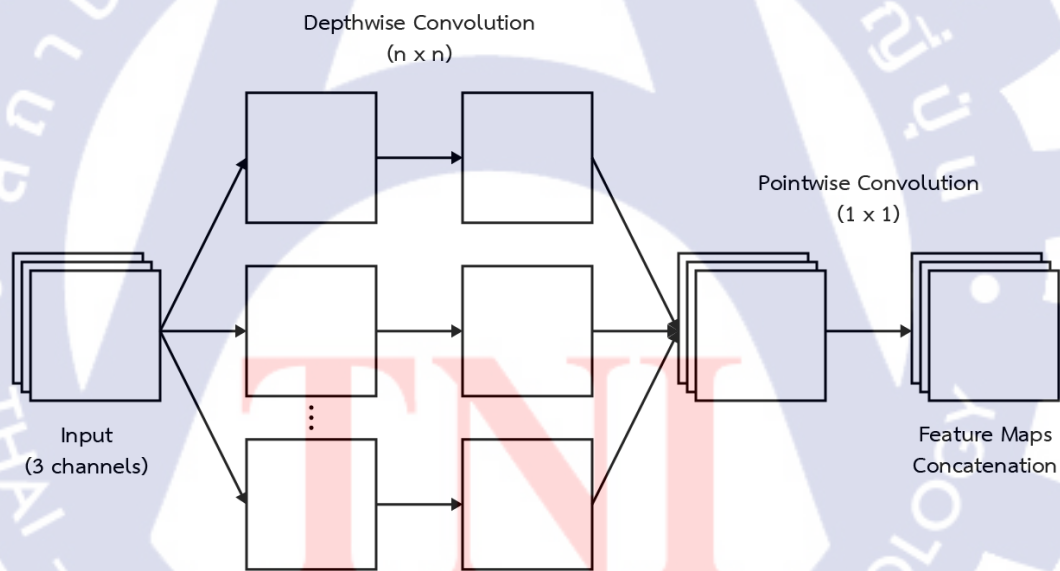
ตัวแบบกลุ่ม Inception เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2015 โดย Szegedy และคณะ [27] บนพื้นฐานแนวคิดความสามารถในการรู้จำรูปแบบจากการมองเห็นของมนุษย์ที่อัตราส่วนของภาพที่แตกต่างกัน โดยการใช้ตัวกรองหลากหลายขนาดแยกกันสกัดคุณลักษณะ (รูปที่ 2.20) ควบคู่กันไป (Parallel) เป็นโครงข่ายประสาทประดิษฐ์ย่อย (Network in Network) [28] แล้วนำค่าที่ได้มาคำนวณหาผลรวม (Concatenation) แต่เนื่องจากโครงสร้างการทำงานที่ซับซ้อน ทำให้ตัวแบบ Inception ถูกพัฒนาให้สามารถประมวลผลได้มีประสิทธิภาพมากยิ่งขึ้น [29] ด้วยการปรับลดขนาดตัวกรอง (Factorizing Convolution) พร้อมทั้งอาศัยแนวคิดการสกัดคุณลักษณะอสมมาตร (Asymmetric Convolution) รวมถึงตัวช่วยจำแนก (Auxiliary Classifier) และการแยกตัวกรอง (Grid Size Reduction) เพื่อลดจำนวนพารามิเตอร์ทำให้ตัวแบบสามารถสกัดคุณลักษณะของวัตถุในภาพที่มีอัตราส่วนแตกต่างกันได้อย่างมีประสิทธิภาพมากยิ่งขึ้น นอกจากนี้ยังมีการนำแนวคิดการส่งค่าคุณลักษณะข้ามชั้น (Residual Connection) มาใช้ในการพัฒนา [30] เพิ่มเติมอีกด้วย



รูปที่ 2.20 แนวคิดตัวแบบกลุ่ม Inception [27]

#### 2.11.4 MobileNet

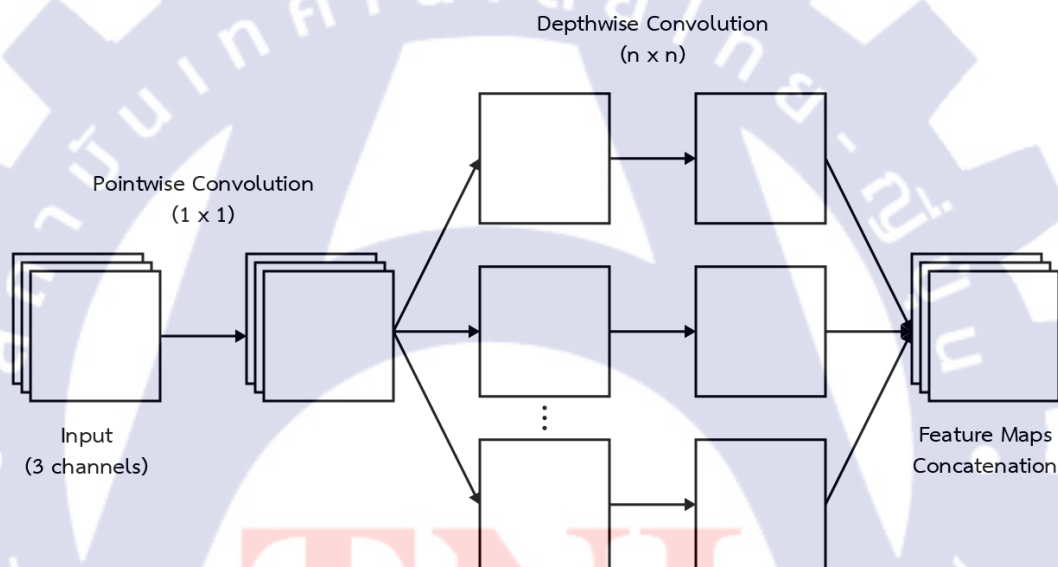
ตัวแบบกลุ่ม MobileNet เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2017 โดย Howard และคณะ [31] บนพื้นฐานแนวคิดการออกแบบภายใต้ทรัพยากรที่จำกัดเพื่อนำไปใช้งานบนอุปกรณ์ขนาดเล็ก การใช้ตัวกรองหลากหลายขนาดแยกกันสกัดคุณลักษณะควบคู่กันไป (Depthwise Separable Convolution) โดยแยกตัวกรองไปสกัดคุณลักษณะเพื่อหาความสัมพันธ์เชิงพื้นที่ในแต่ละช่องสี (Depthwise Convolution) แล้วทำการเชื่อมโยงความสัมพันธ์ของช่องสี (Pointwise Convolution) ด้วยตัวกรองขนาดเล็กเพื่อปรับปรุงความหน่วงในการรับส่งข้อมูล (Latency) และลดการประมวลผลของโครงข่ายประสาทประดิษฐ์คอนโวลูชันให้ได้ตัวแบบที่มีขนาดเล็กและประสิทธิภาพที่สามารถยอมรับได้ (รูปที่ 2.21) ต่อมาได้มีการปรับปรุงตัวแบบ MobileNet และนำแนวคิดของตัวแบบกลุ่ม ResNet (Inverted Residual Function) เข้ามาประยุกต์ใช้ [32][33] จนได้ตัวแบบที่มีขนาดเล็กและประสิทธิภาพสูงขึ้น เหมาะสำหรับการนำไปใช้บนอุปกรณ์ขนาดเล็กมากยิ่งขึ้น



รูปที่ 2.21 แนวคิดตัวแบบกลุ่ม MobileNet [31]

### 2.11.5 Xception

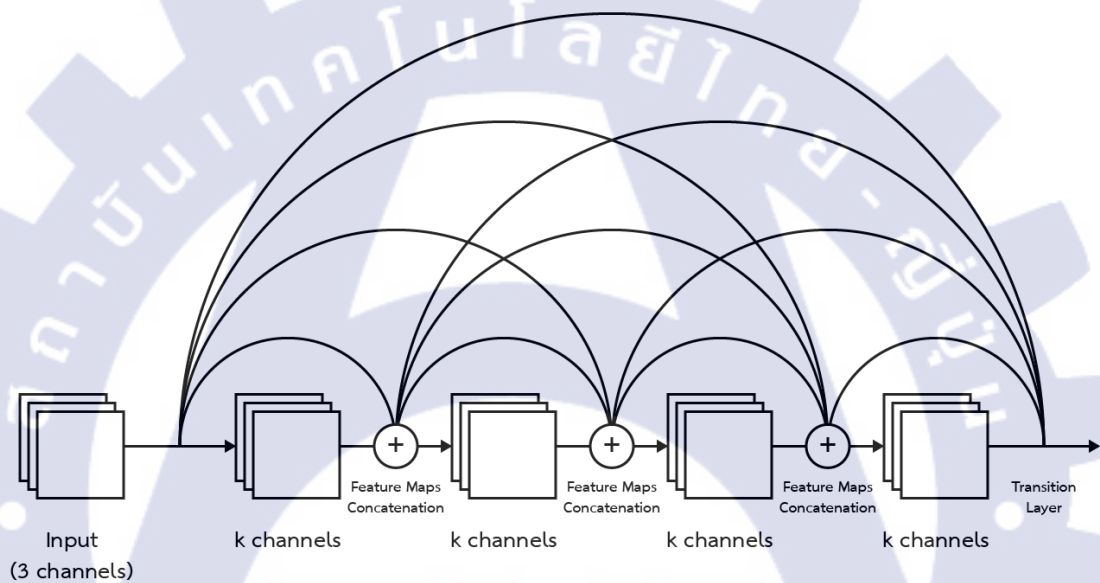
ตัวแบบกลุ่ม Xception (Extreme Inception) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่แนะนำเสนอในปี ค.ศ. 2017 โดย Chollet [34] บนพื้นฐานของตัวแบบกลุ่ม Inception ด้วยการปรับปรุงแนวคิดการใช้ตัวกรองหลากหลายขนาดแยกกันสกัดคุณลักษณะควบคู่กันไป (Depthwise Separable Convolution) ในตัวแบบกลุ่ม MobileNet ด้วยการเชื่อมโยงความสัมพันธ์ของช่องสี่ (Pointwise Convolution) แล้วแยกตัวกรองไปสกัดคุณลักษณะเพื่อหาความสัมพันธ์เชิงพื้นที่ (Spatial Correlation) ตามแต่ละช่องสี่ (Depthwise Convolution) แทนที่ การใช้ตัวกรองคุณลักษณะพื้นฐาน (Separable Inception Module) ทำให้การประมวลผลลดลงและตัวแบบมีความแม่นยำสูงขึ้น ดังรูปที่ 2.22



รูปที่ 2.22 แนวคิดตัวแบบกลุ่ม Xception [34]

### 2.11.6 DenseNet

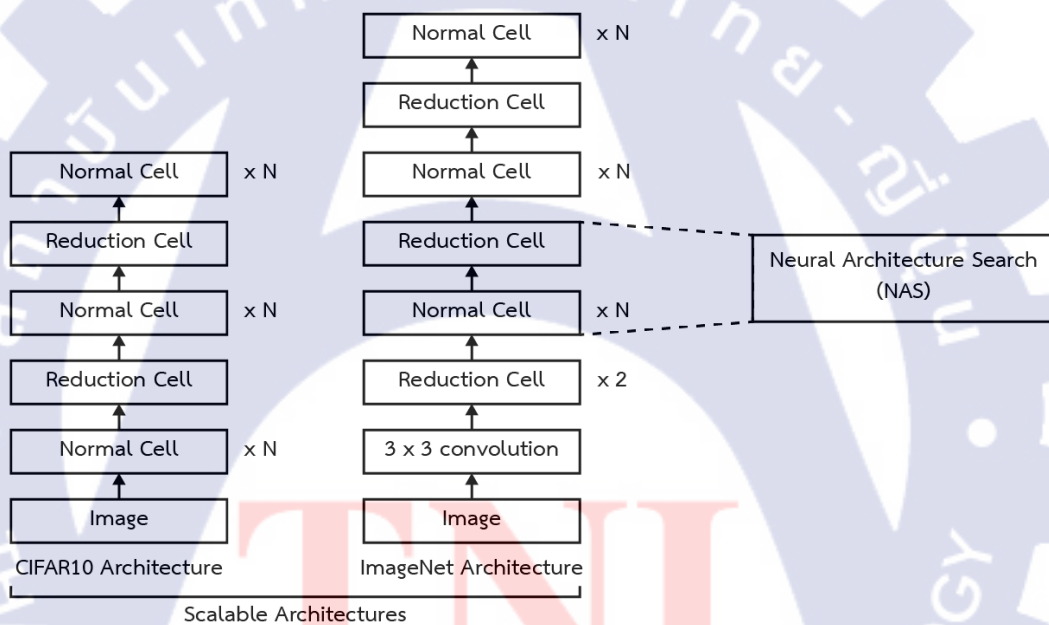
ตัวแบบกลุ่ม DenseNet (Dense Convolutional Network) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2017 โดย Huang และคณะ [35] บนพื้นฐานของแนวคิดการเชื่อมโยงระหว่างชั้นในระยะเวลาที่สั้นลงและใกล้กับชั้นนำเข้าข้อมูล (รูปที่ 2.23) ซึ่งจะทำให้สามารถฝึกสอนตัวแบบได้มีประสิทธิภาพมากยิ่งขึ้นและมีความแม่นยำสูงขึ้นตามไปด้วย ด้วยการส่งคุณลักษณะจากชั้นนำเข้าข้อมูลไปยังแต่ละช่วง (Block) ของโครงข่าย (Feed Forward) ที่เป็นกลุ่มของโครงข่ายประสาทประดิษฐ์คอนโวลูชันส่งผลให้แต่ละช่วงโครงข่ายสามารถสกัดคุณลักษณะที่เป็นประโยชน์ได้มากยิ่งขึ้น



รูปที่ 2.23 แนวคิดตัวแบบกลุ่ม DenseNet [35]

### 2.11.7 NASNet

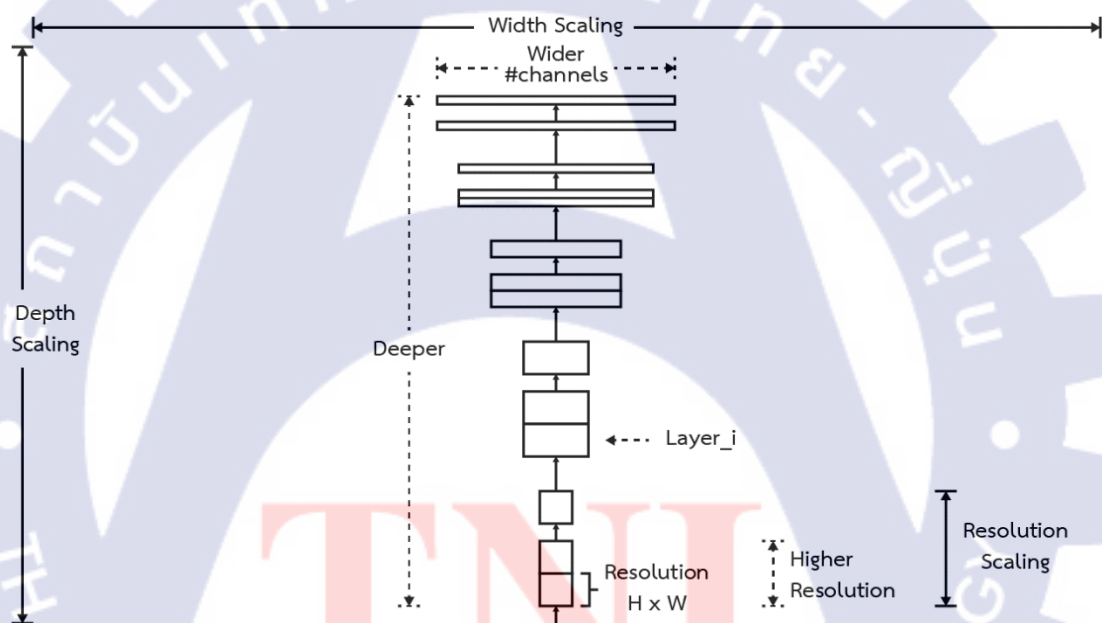
ตัวแบบกลุ่ม NASNet (Neural Architecture Search Network) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2018 โดย Zoph และคณะ [36] บนพื้นฐานของแนวคิดการออกแบบโครงข่ายประสาทประดิษฐ์ที่มีประสิทธิภาพสูงสุดโดยใช้ทรัพยากรที่มีอยู่อย่างจำกัด ด้วยการใช้วิธีการเรียนรู้แบบเสริมกำลังเพื่อค้นหาพารามิเตอร์ที่เหมาะสม (Search Space) ในการพัฒนาตัวแบบตั้งต้น (Child Network) ซึ่งประกอบไปด้วย ชั้นคอนโวลูชันที่ให้ผลลัพธ์เป็นฟังก์ชันลักษณะในมิติของภาพที่เหมือนเดิม (Normal Cell) และชั้นคอนโวลูชันที่ให้ผลลัพธ์เป็นฟังก์ชันลักษณะที่ถูกปรับลดมิติของภาพลง 2 เท่า (Reduction Cell) แล้วทำการคัดเลือกโครงสร้างที่เหมาะสมที่สุด (Optimal Architecture) ด้วยโครงข่ายประสาทประดิษฐ์แบบวนกลับ (Recurrent Neural Network Controller) ผ่านการทดสอบและประเมินผล ดังรูปที่ 2.24



รูปที่ 2.24 แนวคิดตัวแบบกลุ่ม NASNet [36]

### 2.11.8 EfficientNet

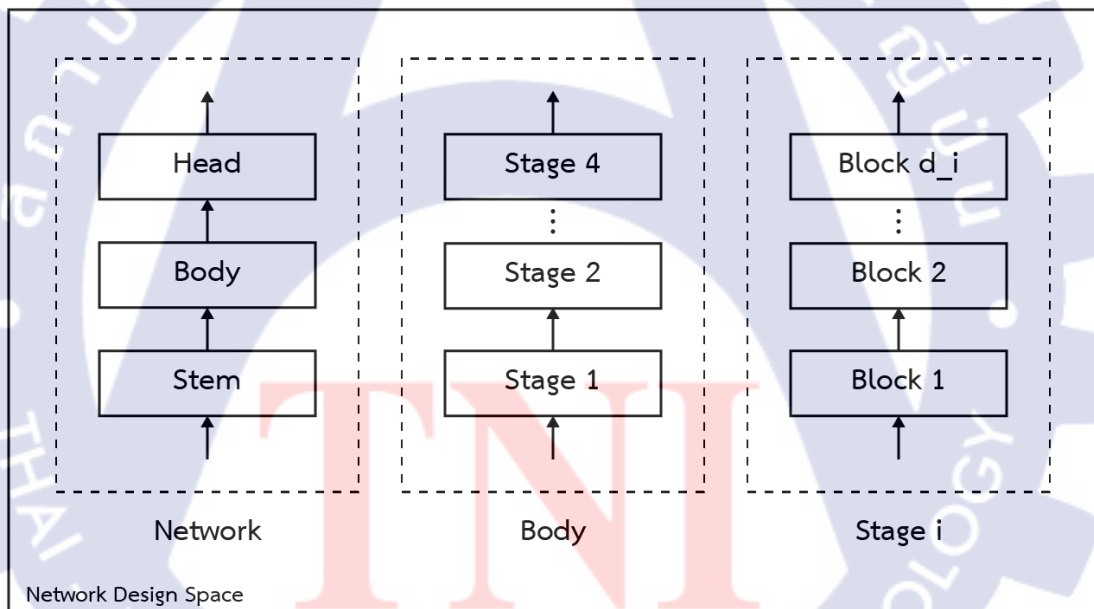
ตัวแบบกลุ่ม EfficientNet เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกรับรองในปี ค.ศ. 2019 โดย Tan และ Le [37] บนพื้นฐานแนวคิดของโครงข่ายประสาทประดิษฐ์ที่มีประสิทธิภาพในเชิงความลึก ความกว้างและความละเอียด ด้วยการใช้นิวโรออร์แกนิก (Neural Architecture Search) ในการออกแบบโครงข่ายตั้งต้น (Baseline Network) แล้วทำการทดลองปรับแต่งโครงสร้างเพื่อให้ได้โครงข่ายประสาทประดิษฐ์ที่มีประสิทธิภาพสูงสุด ด้วยการปรับแต่งความกว้าง (Width Scaling) ความลึก (Depth Scaling) ความละเอียด (Resolution Scaling) และการปรับแต่งแบบผสม (Compound Scaling) ซึ่งการปรับแต่งแบบผสมใช้อัตราส่วนคงที่ (Constant Ratio) ส่งผลให้ตัวแบบที่ได้มีประสิทธิภาพสูงขึ้น (รูปที่ 2.25) โดยจะใช้อัตราส่วนคงที่ที่แตกต่างกันไปในแต่ละตัวแบบของกลุ่ม EfficientNet



รูปที่ 2.25 แนวคิดตัวแบบกลุ่ม EfficientNet [37]

### 2.11.9 RegNet

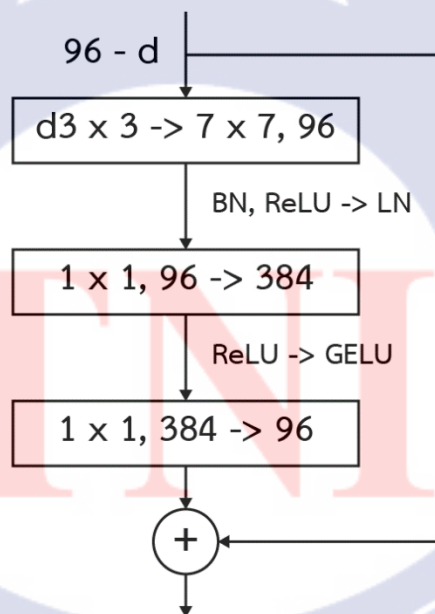
ตัวแบบกลุ่ม RegNet (Regular Network) เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่แนะนำให้เสนอในปี ค.ศ. 2020 พัฒนาโดย Radosavovic และคณะ [38] บนพื้นฐานแนวคิดการออกแบบโครงข่ายประสาทประดิษฐ์ที่มีประสิทธิภาพสูงสุดภายใต้สภาพแวดล้อมที่เปลี่ยนแปลงไป เพื่อแก้ปัญหการออกแบบโครงข่ายประสาทประดิษฐ์เชิงลึกแบบดั้งเดิม (Manual) ที่อาจทำให้ไม่ได้ตัวแบบที่มีประสิทธิภาพสูงสุด และการออกแบบโครงข่ายประสาทประดิษฐ์เชิงลึกแบบอัตโนมัติ (NAS) ที่ใช้ทรัพยากรในการประมวลผลสูง ด้วยการผสมจุดเด่นของการออกแบบโครงข่ายประสาทประดิษฐ์เชิงลึกทั้งสองรูปแบบ โดยทำการออกแบบโครงข่ายประสาทประดิษฐ์เชิงลึกที่เป็นไปได้ภายใต้พื้นที่การออกแบบ (Network Design Space) ที่ไร้ข้อจำกัด (AnyNet) พร้อมทั้งพิจารณาปัจจัยต่าง ๆ ทำให้ได้โครงข่ายประสาทประดิษฐ์พื้นฐาน (RegNet) ที่ผ่านการปรับแต่ง (Quantized Linear Function) จนได้ตัวแบบที่มีประสิทธิภาพสูงกว่าทั้งตัวแบบดั้งเดิมและตัวแบบสมัยใหม่บางกลุ่ม ดังรูปที่ 2.26



รูปที่ 2.26 แนวคิดตัวแบบกลุ่ม RegNet [38]

### 2.11.10 ConvNeXt

ตัวแบบกลุ่ม ConvNeXt เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่ถูกนำเสนอในปี ค.ศ. 2022 พัฒนาโดย Liu และคณะ [39] บนพื้นฐานแนวคิดของการเพิ่มประสิทธิภาพโครงข่ายประสาทประดิษฐ์คอนโวลูชันเพื่อแข่งขันกับอัลกอริทึม Vision Transformer [40] ที่มีความสามารถในการหาความสัมพันธ์เชิงพื้นที่ได้กว้างกว่าตัวกรองคอนโวลูชัน เป็นโครงข่ายประสาทประดิษฐ์เชิงลึกที่อ้างอิงโครงสร้างของตัวแบบกลุ่ม ResNet แล้วทำการปรับเปลี่ยนโครงสร้างตั้งแต่การประมวลผลข้อมูลนำเข้าจาก Convolutional Stem [41] เป็น Patchify Stem และปรับแต่งอัตราส่วนของโครงข่ายประสาทประดิษฐ์คอนโวลูชันให้มีความใกล้เคียงกับอัลกอริทึม Swin Transformer [42] นำแนวคิดของ ResNext ซึ่งเป็นตัวแบบปรับปรุงในกลุ่ม ResNet มาปรับใช้โดยการสกัดคุณลักษณะในเชิงช่องสี่ (Depthwise Convolution) ซึ่งมีความใกล้เคียงกับการคำนวณผลรวม (Weight Sum Operation) ของการนำข้อมูลทุกภาพมาเปรียบเทียบเพื่อหาความสัมพันธ์ (Self Attention) [43] ในอัลกอริทึม Vision Transformer [44] และเปลี่ยนการเรียงลำดับจำนวนช่องสี่ของแต่ละชั้นในช่วงโครงข่าย รวมถึงการใช้ตัวกรองคอนโวลูชันที่มีขนาดใหญ่ขึ้นและปรับพารามิเตอร์ต่าง ๆ ในแต่ละชั้นไปใช้วิธีการที่ถูกนำเสนอขึ้นใหม่ (รูปที่ 2.27) ส่งผลให้ตัวแบบมีประสิทธิภาพสูงขึ้นอย่างมีนัยสำคัญ



รูปที่ 2.27 แนวคิดตัวแบบกลุ่ม ConvNeXt [39]

## 2.12 งานวิจัยที่เกี่ยวข้อง (Related Research)

Olsen และคณะ [45] ได้ทำการศึกษาการจำแนกพันธุ์พืชด้วยการเรียนรู้เชิงลึก กับชุดข้อมูลพืช ประกอบด้วย 8 พันธุ์พืช และกลุ่มของพันธุ์พืชนอกเป้าหมาย จำนวนทั้งสิ้น 17,509 ภาพ ประกอบด้วยข้อมูลเชิงบวก (Positive) และข้อมูลเชิงลบ (Negative) ที่อัตราส่วน 5 : 5 ทำการเพิ่มชุดข้อมูลด้วยการหมุน (Rotate) ปรับขนาดแนวตั้ง (Vertical Scale) ปรับขนาดแนวนอน (Horizontal Scale) ปรับค่าปริภูมิสี (Color Channel Shifting) ปรับค่าความสว่าง (Intensity Shifting) ปรับระดับความสว่าง (Intensity Scale) เปลี่ยนแปลงมุมมอง (Perspective Transformation) และพลิกภาพแนวตั้ง (Horizontal Flip) แบ่งเป็นข้อมูลชุดฝึกสอน ข้อมูลชุดตรวจสอบความถูกต้อง และข้อมูลชุดทดสอบที่อัตราส่วน 6 : 2 : 2 แล้วฝึกสอนด้วยตัวแบบพื้นฐานจำนวน 2 ตัวแบบ ได้แก่ InceptionV3 และ ResNet50 พร้อมทั้งทำการตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation) โดยกำหนดจำนวน K = 5 ผลการศึกษา พบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 95.1% และ 95.7% ตามลำดับ

Zarrin และ Islam [46] ได้ทำการศึกษา การจำแนกพันธุ์พืชจากลักษณะใบด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) โดยใช้ชุดข้อมูลพันธุ์พืชท้องถิ่น ประกอบด้วย 10 พันธุ์พืช จำนวนทั้งสิ้น 10,000 ภาพ สายพันธุ์ละ 1,000 ภาพ แบ่งออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 8 : 2 ทำการฝึกสอนผ่านโครงข่ายประสาทประดิษฐ์คอนโวลูชัน ที่ 100, 500, 2,000 และ 2,500 รอบ ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำในการจำแนกที่ 96.65%, 98.55%, 99.00% และ 99.40% ตามลำดับ

Habiba และคณะ [47] ได้ทำการศึกษา การจำแนกพันธุ์พืชบังกลาเทศ 8 สายพันธุ์ โดยใช้วิธีการถ่ายโอนความรู้กับชุดข้อมูลภาพใบพันธุ์พืชในสภาพแวดล้อมที่มีพื้นหลังและแสงที่หลากหลาย จำนวน 8,000 ภาพ แบ่งข้อมูลออกเป็นข้อมูลชุดฝึกสอนและข้อมูลชุดทดสอบที่อัตราส่วน 8 : 2 ทำการฝึกสอนตัวแบบที่ผ่านการฝึกสอนงานที่เกี่ยวข้องมาแล้วพร้อมทั้งปรับแต่งตัวแบบพื้นฐาน ได้แก่ VGG16, VGG19, ResNet50, InceptionV3, InceptionResNetV2 และ Xception ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำในการทดสอบที่ 99.96%, 98.56%, 92.52%, 89.93% และ 85.51% ตามลำดับ การทดสอบประสิทธิภาพของตัวแบบกับข้อมูลที่ผ่านการหมุน (Rotate) ที่ 90, 180 และ 270 องศา พบว่า ความแม่นยำในการจำแนกของตัวแบบ VGG16, VGG19, ResNet50, InceptionV3, InceptionResNetV2 และ Xception ลดลงเพียงเล็กน้อยที่ค่าเฉลี่ย 3%, 3%, 1%, 12%, 3.6% และ 2% ตามลำดับ แสดงให้เห็นว่าตัวแบบที่สร้างขึ้นสามารถใช้งานได้อย่างมีประสิทธิภาพ

Pereira และคณะ [48] ได้ทำการศึกษา การจำแนกพันธุ์องุ่นด้วยการเรียนรู้เชิงลึก กับชุดข้อมูลสาธารณะ Douro Red Grape Variety (DRGV) ปี 2016 และ 2018 ประกอบด้วยพันธุ์องุ่น 6

สายพันธุ์ จำนวนทั้งสิ้น 224 ภาพ รวมทั้ง 2 ชุดข้อมูล ทำการเตรียมข้อมูลโดยลบผลงุ่นออกจากภาพ แล้วเพิ่มชุดข้อมูลด้วยการเลื่อนภาพ (Translation) การพลิกภาพแนวนอน (Horizontal Reflection) และการหมุนภาพ (Rotation) แบ่งออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดตรวจสอบความถูกต้องที่ อัตราส่วน 8 : 2 ทำการฝึกสอนตัวแบบพื้นฐาน AlexNet ผลการศึกษา พบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำ 77.30% เมื่อนำตัวแบบไปทดสอบกับชุดข้อมูลสาธารณะ Flavia ตัวแบบให้ความแม่นยำที่ 89.75%

Huang และคณะ [49] ได้ทำการศึกษาแนวทางการเรียนรู้เชิงลึกในการจำแนก *Cinnamomum camphora* จากลักษณะใบ โดยทำการเปรียบเทียบประสิทธิภาพของการใช้ตัวแบบพื้นฐาน จำนวน 7 ตัวแบบ ได้แก่ AlexNet, GoogleNet, ResNet50, ResNet101, InceptionV3, InceptionResNetV2 และ SqueezeNet ผลการทดลองสามารถสรุปได้ว่าการฝึกสอนผ่านโครงข่ายประสาทประดิษฐ์เชิงลึกด้วยการถ่ายโอนความรู้ให้ความแม่นยำในการจำแนกภาพใบพืชได้ดีกว่าเมื่อเปรียบเทียบกับวิธีการเรียนรู้จากการสกัดคุณลักษณะโดยอาศัยความรู้เฉพาะทาง (Hand-Craft Features) และโครงข่ายประสาทประดิษฐ์คอนโวลูชันที่แตกต่างกันเป็นปัจจัยสำคัญในการจำแนกพันธุ์พืชที่แตกต่างกันที่ความแม่นยำระหว่าง 69.8%-95.3%

Kamrul และคณะ [50] ได้ทำการศึกษาการจัดกลุ่มใบชาด้วยการเรียนรู้เชิงลึก เนื่องจากการจัดกลุ่มคุณภาพชาเป็นปัจจัยที่สำคัญต่อมาตรฐาน ความหอมและความหวานของชาซึ่งส่วนใหญ่ขึ้นอยู่กับระบบการจัดกลุ่ม โดยการนำการเรียนรู้ของเครื่องมาปรับใช้ในการรู้จำและจำแนกภาพแบบอัตโนมัติโดยไม่ต้องใช้คนเข้ามาเกี่ยวข้อง ทำการทดลองกับตัวแบบพื้นฐาน 2 ชนิด จำนวน 3 ตัวแบบ ได้แก่ Faster RCNN (InceptionV3), VGG16 และตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) กับชุดข้อมูล จำนวน 3,000 ภาพ ผลการศึกษาพบว่า ตัวแบบ Faster RCNN (InceptionV3) มีความแม่นยำสูงสุด รองลงมา คือ โครงข่ายประสาทประดิษฐ์คอนโวลูชัน และ VGG16 ที่ความแม่นยำ 96.28%, 95.23% และ 92.23% ตามลำดับ

Vizcarra และคณะ [51] ได้ทำการศึกษาการจำแนกพันธุ์พืชเปรูจากลักษณะใบกับชุดข้อมูล Peruvian Amazon Foresty ประกอบด้วย 10 พันธุ์พืช จำนวนทั้งหมด 59,441 ภาพ ทำการฝึกสอนผ่านตัวแบบพื้นฐานด้วยการถ่ายโอนความรู้ จำนวน 4 ตัวแบบ ได้แก่ AlexNet, VGG19, ResNet101 และ DenseNet201 แล้วประเมินประสิทธิภาพตัวแบบทั้งเชิงปริมาณ (Quantitative Evaluation) โดยทดสอบประสิทธิภาพในการใช้งานและเชิงคุณภาพ (Qualitative Evaluation) โดยทำการวิเคราะห์การสกัดคุณลักษณะของตัวแบบ ผลการศึกษาพบว่า ตัวแบบ VGG19 มีความแม่นยำสูงสุด โดยมีความแม่นยำในการรู้จำ 96.64% และความแม่นยำในการทดสอบ 96.52% ส่วนการเตรียมข้อมูล (Preprocessing) ไม่ส่งผลต่อประสิทธิภาพของตัวแบบ การสกัดคุณลักษณะของตัวแบบ AlexNet และ VGG16 สามารถทำได้อย่างมีประสิทธิภาพ โดยตัวแบบ AlexNet สามารถสกัด

คุณลักษณะรูปทรง พื้นผิวและลายใบได้ แต่ยังมีสัญญาณรบกวนเล็กน้อยในขณะที่ตัวแบบ VGG16 สกัดคุณลักษณะโดยมุ่งเน้นรูปทรงใบและลายใบได้อย่างชัดเจน

Nasiri และคณะ [52] ได้ทำการศึกษาระบุพันธุ์งุ่นอัตโนมัติจากลักษณะใบด้วยการเรียนรู้เชิงลึกกับชุดข้อมูลพันธุ์งุ่น ประกอบด้วย 6 สายพันธุ์ ที่ถูกบันทึกในสเปกตรัมที่สามารถมองเห็นได้ (400-700 นาโนเมตร) ทำการฝึกสอนผ่านตัวแบบพื้นฐาน VGG16 พร้อมทั้งตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation) จำนวน 5 Fold เพื่อประเมินประสิทธิภาพของตัวแบบ ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นสามารถรู้จำและจำแนกสายพันธุ์งุ่นได้อย่างแม่นยำที่ 99% จากผลการวิจัยดังกล่าวจึงเป็นวิธีการที่สามารถนำไปใช้ในการจำแนกพันธุ์งุ่นได้อย่างรวดเร็วและต้นทุนต่ำ

Trung และคณะ [53] ได้ทำการศึกษาระบุพันธุ์พืชสมุนไพรจากลักษณะใบกับชุดข้อมูลพืชสมุนไพรในประเทศเวียดนามตอนใต้ ประกอบด้วยพันธุ์พืชสมุนไพร 10 สายพันธุ์ จำนวน 2,296 ภาพ แล้วทำการฝึกสอนผ่านตัวแบบพื้นฐาน ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 98.7% แสดงให้เห็นว่าตัวแบบที่ผ่านการฝึกสอนด้วยการถ่ายโอนความรู้สามารถจำแนกพันธุ์พืชสมุนไพรได้อย่างมีประสิทธิภาพ

Azeez และ Rajapakse [54] ได้ทำการศึกษาระบุพันธุ์พืชสมุนไพรศรีลังกาด้วยการเรียนรู้เชิงลึกกับ 3 ชุดข้อมูล ชุดที่ 1 ประกอบด้วย 5 พันธุ์พืช จำนวน 369 ภาพ ชุดที่ 2 ประกอบด้วย 6 พันธุ์พืช จำนวน 455 ภาพ และชุดที่ 3 ประกอบด้วย 7 พันธุ์พืช จำนวน 552 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน ข้อมูลชุดตรวจสอบความถูกต้องและข้อมูลชุดทดสอบที่อัตราส่วน 8 : 1 : 1 ทำการฝึกสอนตัวแบบพื้นฐาน จำนวน 4 ตัวแบบ ได้แก่ InceptionV3, ResNet, MobileNet และ InceptionResNetV2 ผ่านการถ่ายโอนความรู้ด้วยวิธีการปรับแต่งตัวแบบพื้นฐาน ผลการศึกษาพบว่า ตัวแบบ InceptionV3, ResNet และ MobileNet มีความแม่นยำสูงสุดในชุดข้อมูลที่ 1 ที่ 88.6%, 95.5% และ 86.4% ในขณะที่ตัวแบบ InceptionResNetV2 มีความแม่นยำสูงสุดที่ชุดข้อมูลที่ 2 ที่ความแม่นยำ 83.3%

Dileep และ Pournami [55] ได้ทำการศึกษาระบุพันธุ์พืชสมุนไพรด้วยการเรียนรู้เชิงลึก (AyurLeaf) โดยใช้ลักษณะใบ เช่น รูปร่าง ขนาด สี เนื้อสัมผัส เป็นต้น ทำการรวบรวมชุดข้อมูลมาตรฐานสำหรับพืชสมุนไพรที่พบเห็นได้ทั่วไปในรัฐ Kerala สาธารณรัฐอินเดีย ประกอบด้วยตัวอย่างใบจากพืชสมุนไพร 40 ชนิด ทำการฝึกสอนผ่านตัวแบบพื้นฐาน AlexNet เพื่อประสิทธิภาพในการสกัดคุณลักษณะจากชุดข้อมูลและทำการจำแนกพันธุ์ผ่านตัวจำแนก Support Vector Machine ด้วยฟังก์ชันกระตุ้น Softmax พร้อมทั้งทำการตรวจสอบความถูกต้องแบบไขว้ จำนวน 5 Fold ได้ความแม่นยำในการจำแนก 96.76% ตัวแบบที่สร้างขึ้นสามารถช่วยให้นักวิจัยความรู้ด้านสมุนไพรที่สืบทอดมาจากบรรพบุรุษและช่วยให้สามารถจำแนกพันธุ์พืชสมุนไพรได้ง่ายขึ้น

Paulson และ Ravishankar [56] ได้ทำการศึกษาการระบุพันธุ์พืชสมุนไพรพื้นเมืองซึ่งส่งผลกระทบต่อการศึกษาที่เกี่ยวข้องกับการแพทย์เป็นอย่างมาก โดยใช้วิธีการเรียนรู้ของเครื่องกับชุดข้อมูลพืชสมุนไพรพื้นเมืองของรัฐ Kerala สาธารณรัฐอินเดีย ประกอบด้วย 64 พันธุ์พืชสมุนไพร จำนวนสายพันธุ์ละ 1,000 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 8 : 2 ทำการทดลองเปรียบเทียบประสิทธิภาพของตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) กับตัวแบบพื้นฐาน 2 ตัวแบบ ได้แก่ VGG16 และ VGG19 ผลการศึกษาพบว่า ตัวแบบ VGG16 มีความแม่นยำสูงสุด รองลงมา คือ VGG19 และโครงข่ายประสาทประดิษฐ์คอนโวลูชัน ที่ความแม่นยำ 97.8%, 97.6% และ 95.79% ตามลำดับ โดยสามารถนำผลการวิจัยไปใช้ในการจำแนกพันธุ์พืชสมุนไพรพื้นเมืองได้

Metripun [57] ได้ทำการศึกษาการจำแนกพันธุ์พืชสมุนไพรไทยจากลักษณะใบกับชุดข้อมูลรูปภาพใบพืชสมุนไพรไทยที่วางบนพื้นหลังสีขาวเรียบ ทำการเตรียมข้อมูล (Preprocessing) โดยแปลงปริภูมิสีของภาพเป็นโทนสีเทา ตรวจสอบขอบภาพ การกร่อนภาพ การเติมภาพและการขยายภาพแล้วแปลงเป็นภาพขาวดำเพื่อให้ได้ลักษณะของรูปทรงใบ ทำการสกัดคุณลักษณะ แกนหลัก แกนรอง อัตราส่วนกว้างยาว ความเยื้องศูนย์กลาง ความกลม ขอบเขต เส้นรอบรูป และอัตราส่วนของเส้นรอบรูปกับแกนหลัก แล้วทำการจำแนกผ่านโครงข่ายประสาทประดิษฐ์ (ANN) ผลการศึกษาพบว่า วิธีการดังกล่าวมีประสิทธิภาพในการจำแนกพันธุ์ได้ถูกต้องเฉลี่ย 90.50%

Muneer และ Fati [58] ได้ทำการศึกษาการจำแนกพันธุ์พืชสมุนไพรอัตโนมัติอย่างมีประสิทธิภาพด้วยคุณลักษณะด้านรูปทรงและพื้นผิวโดยใช้การเรียนรู้เชิงลึกกับชุดข้อมูลพันธุ์พืชสมุนไพรมาเลเซีย ประกอบด้วย 20 พันธุ์พืช จำนวนสายพันธุ์ละ 50 ภาพ แบ่งออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 6 : 4 ทำการทดลองการจำแนกพันธุ์พืชด้วยตัวแบบ Support Vector Machine และโครงข่ายประสาทประดิษฐ์เชิงลึก (DNN) ผลการศึกษาพบว่า ตัวแบบ Support Vector Machine มีความแม่นยำในการรู้จำ 74.64% ในขณะที่โครงข่ายประสาทประดิษฐ์เชิงลึกมีความแม่นยำในการรู้จำ 93% นำตัวแบบที่ได้ไปพัฒนาเป็นแอปพลิเคชันบนโทรศัพท์มือถือแล้วทำการทดสอบการจำแนกพันธุ์พืชสมุนไพร พบว่า ตัวแบบ Support Vector Machine ใช้เวลาในการประมวลผล 4 วินาที และตัวแบบโครงข่ายประสาทประดิษฐ์เชิงลึกใช้เวลา 5 วินาที ในขณะที่การประมวลผลบนแอปพลิเคชันใช้เวลาเพียง 2 วินาที เท่านั้น

Sachar และ Kumar [59] ได้ทำการศึกษาการจำแนกพันธุ์พืชสมุนไพรจากลักษณะใบด้วยการผสมการเรียนรู้เชิงลึกกับชุดข้อมูล Medicinal Leaf ประกอบด้วย 30 พันธุ์พืช แบ่งเป็นข้อมูลชุดฝึกสอน 1,547 ภาพ ข้อมูลชุดทดสอบ 294 ภาพ และแบ่งข้อมูลชุดตรวจสอบความถูกต้องแบบไขว้ที่ 3 และ 5 Fold ทำการฝึกสอนตัวแบบพื้นฐาน จำนวน 3 ตัวแบบ ได้แก่ MobileNetV2, InceptionV3 และ ResNet50 ผ่านการถ่ายโอนความรู้ด้วยการใช้ตัวแบบพื้นฐานเป็นตัวสกัด

คุณลักษณะแล้วนำผลลัพธ์ที่ได้มาผสมกันแล้วทำการจำแนกด้วยตัวจำแนกที่สร้างขึ้น ผลการศึกษาพบว่า ตัวแบบการผสมการเรียนรู้เชิงลึกมีความแม่นยำสูงถึง 99.66% และมีความแม่นยำสูงสุดที่ 99.94% เมื่อทำการตรวจสอบความถูกต้องแบบไขว้ จำนวน 5 Fold

Roopashree และ Anitha [60] ได้ทำการศึกษากำหนดพันธุ์พืชสมุนไพรด้วยการเรียนรู้เชิงลึกกับชุดข้อมูลสาธารณะ DeepHerb ประกอบด้วย 40 พันธุ์พืช จำนวน 2,515 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอนและข้อมูลชุดทดสอบที่อัตราส่วน 8 : 2 ทำการฝึกสอนตัวแบบพื้นฐาน 4 ตัวแบบ ได้แก่ VGG16, VGG19, InceptionV3 และ Xception ผ่านการถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะ โดยใช้ตัวจำแนกโครงข่ายประสาทประดิษฐ์ (ANN) และ Support Vector Machine ผลการศึกษาพบว่า ตัวแบบ Xception ที่ใช้ตัวจำแนก ANN มีความแม่นยำสูงสุดที่ 97.5%

Alimboyong และ Hernandez [61] ได้ทำการศึกษากำหนดประสิทธิภาพการเรียนรู้เชิงลึกสำหรับการจำแนกพันธุ์พืชต้นกล้ากับชุดข้อมูลสาธารณะ Plant Seedlings ประกอบด้วยพันธุ์พืช 12 สายพันธุ์ จำนวน 4,234 ภาพ โดยแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกสอน ข้อมูลชุดตรวจสอบความถูกต้อง และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 1 : 2 แล้วฝึกสอนตัวแบบผ่านโครงข่ายประสาทประดิษฐ์ใหม่ทั้งหมด (Scratch Model) ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 90.15%

Pearline และคณะ [62] ได้ทำการศึกษากำหนดพันธุ์พืชด้วยการประมวลผลภาพแบบคอนโวลูชันและการเรียนรู้เชิงลึกกับชุดข้อมูลสาธารณะ Folio, Swedish Leaf, Flavia และ Leaf12 แบ่งออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 3 โดยทำการฝึกสอนตัวจำแนกด้วยคุณลักษณะที่สกัดโดยอาศัยความรู้เฉพาะทาง เปรียบเทียบกับการฝึกสอนตัวแบบจากคุณลักษณะที่ผ่านการสกัดจากตัวแบบพื้นฐาน จำนวน 4 ตัวแบบ ได้แก่ VGG16, VGG19, InceptionV3 และ InceptionResNetV2 ผลการศึกษาพบว่า ตัวแบบที่ฝึกสอนด้วยคุณลักษณะจากการสกัดคุณลักษณะด้วยตัวแบบพื้นฐานให้ความแม่นยำสูงกว่าตัวแบบที่ฝึกสอนด้วยคุณลักษณะที่สกัดโดยอาศัยความรู้เฉพาะทาง โดยตัวแบบ Random Forest ให้ความแม่นยำ 82.38% ส่วนตัวแบบที่ใช้โครงสร้าง VGG16 ร่วมกับตัวจำแนก Logistic Regression ให้ความแม่นยำสูงถึง 97.14% กับชุดข้อมูล Leaf12 และตัวแบบที่ใช้โครงสร้าง VGG19 ร่วมกับตัวจำแนก Logistic Regression ให้ความแม่นยำสูงถึง 96.53%, 96.25% และ 99.41% กับชุดข้อมูล Folio, Flavia และ Swedish Leaf ตามลำดับ

Kaya และคณะ [63] ได้ทำการศึกษากำหนดการวิเคราะห์การถ่ายโอนความรู้สำหรับตัวแบบโครงข่ายประสาทประดิษฐ์เชิงลึกจำแนกพันธุ์พืชกับชุดข้อมูลสาธารณะ Flavia, Swedish Leaf, UCI Leaf และ Plant Village โดยทำการทดลองเปรียบเทียบประสิทธิภาพของตัวแบบผ่านการฝึกสอนด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (End to End CNN) ตัวแบบพื้นฐานร่วมกับการปรับแต่งตัวแบบ โครงข่ายประสาทประดิษฐ์คอนโวลูชันร่วมกับการปรับแต่งตัวแบบพื้นฐานกับชุดข้อมูลที่แตกต่างกัน (Cross Dataset Fine Tuning) การสกัดคุณลักษณะด้วยตัวแบบพื้นฐานร่วมกับ

ตัวจำแนก (Deep Feature Learning) และโครงข่ายประสาทประดิษฐ์คอนโวลูชันร่วมกับโครงข่ายประสาทประดิษฐ์แบบวนกลับ (CNN-RNN Classification) ผลการศึกษาพบว่า การถ่ายโอนความรู้สามารถเพิ่มประสิทธิภาพตัวแบบจำแนกพันธุ์พืชได้อย่างมีประสิทธิภาพโดยเฉพาะตัวแบบที่ผ่านการเรียนรู้คุณลักษณะเชิงลึกและการปรับแต่งตัวแบบพื้นฐาน

Diaz และคณะ [64] ได้ทำการศึกษาการเรียนรู้เชิงลึกสำหรับการจำแนกพันธุ์พืชในงานเกษตรกรรมที่มีความแม่นยำกับชุดข้อมูลสาธารณะ Plant Seedlings ประกอบด้วยพันธุ์พืช 12 สายพันธุ์ จำนวน 4,750 ภาพ ในระยะการเจริญเติบโตที่แตกต่างกัน โดยแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 7.8 : 2.2 แล้วฝึกสอนผ่านตัวแบบพื้นฐาน จำนวน 3 ตัวแบบ ได้แก่ VGG16, InceptionV3 และ Xception ผลการศึกษาพบว่า ตัวแบบที่ผ่านการถ่ายโอนความรู้จาก Xception มีความแม่นยำสูงสุดที่ 86.21%

Jasitha และ Dileep [65] ได้ทำการศึกษาการจำแนกพันธุ์พืชจากลักษณะเส้นใบด้วยการเรียนรู้เชิงลึกกับชุดข้อมูลสาธารณะ Dleaf, Flavia และ Leaf1 แบ่งเป็นข้อมูลชุดฝึกสอนและข้อมูลชุดทดสอบที่อัตราส่วน 8 : 2 และแบ่งข้อมูลชุดตรวจสอบความถูกต้องแบบไขว้ จำนวน 5 Fold ทำการฝึกสอนตัวแบบพื้นฐานด้วยการถ่ายโอนความรู้แบบการปรับแต่งตัวแบบ จำนวน 2 ตัวแบบ ได้แก่ GoogLeNet และ VGG16 ผลการศึกษาพบว่า ตัวแบบ GoogLeNet มีค่าความแม่นยำสูงสุด

Tiwari [66] ได้ทำการศึกษาการเปรียบเทียบตัวแบบการเรียนรู้เชิงลึกสำหรับการจำแนกพันธุ์พืชด้วยการสกัดคุณลักษณะโดยใช้ความรู้เฉพาะทาง (Handcraft Features) และการสกัดคุณลักษณะแบบอัตโนมัติ (Non-Handcraft Features) กับชุดข้อมูลพันธุ์พืชประกอบด้วย 40 พันธุ์พืช จำนวนทั้งสิ้น 340 ภาพ ทำการฝึกสอนตัวแบบโครงข่ายประสาทประดิษฐ์ด้วยคุณลักษณะที่ทำการสกัดไว้แล้วและฝึกสอนโครงข่ายประสาทประดิษฐ์คอนโวลูชันโดยให้สกัดคุณลักษณะด้วยตัวกรองคอนโวลูชัน ผลการศึกษาพบว่า ตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชันให้ความแม่นยำสูงกว่าโครงข่ายประสาทประดิษฐ์ที่ 95.58%

Miao และคณะ [67] ได้ทำการศึกษาการรู้จำพันธุ์พืชด้วยการถ่ายโอนความรู้กับชุดข้อมูล ImageNet ประกอบด้วยพันธุ์พืช 22 สายพันธุ์ จำนวน 21,325 ภาพ ฝึกสอนผ่านตัวแบบพื้นฐาน จำนวน 2 ตัวแบบ ได้แก่ InceptionV3 และ ResNetV2 แล้วทำการเปรียบเทียบประสิทธิภาพกับโครงข่ายประสาทประดิษฐ์และโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) พบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 87.8% และ 91.2% ตามลำดับ ผลการทดลองแสดงให้เห็นว่าตัวแบบที่ผ่านการฝึกสอนด้วยการถ่ายโอนความรู้มีประสิทธิภาพสูงกว่าตัวแบบโครงข่ายประสาทประดิษฐ์แบบดั้งเดิม

Riaz และคณะ [68] ได้ทำการศึกษาการจำแนกพันธุ์พืชด้วยโครงข่ายประสาทคอนโวลูชัน (CNN) แบบหลายเส้นทางกับชุดข้อมูล Leaf Snap และ MalayaKew โดยแบ่งโครงข่ายประสาท

ประดิษฐ์คอนโวลูชันออกเป็น 5 กลุ่ม ในแต่ละกลุ่มจะทำการสกัดคุณลักษณะแล้วส่งต่อไปพสานคุณลักษณะกับโครงข่ายประสาทกลุ่มถัดไป ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 99.38% และ 99.22% ตามลำดับ เมื่อทำการเปรียบเทียบแสดงให้เห็นว่าตัวแบบมีประสิทธิภาพสูงกว่าตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชันแบบดั้งเดิมและตัวแบบพื้นฐานรวมถึงมีจำนวนพารามิเตอร์น้อยกว่าตัวแบบทั้ง 2 ประเภท

Chang และ Chung [69] ได้ทำการศึกษากการเพิ่มประสิทธิภาพการเรียนรู้เชิงลึกสำหรับการรู้จำพันธุ์พืชในฟาร์มแบบเรียลไทม์ กับชุดข้อมูลรูปภาพใบพืช ประกอบด้วยพันธุ์พืช 3 สายพันธุ์ จำนวน 1,200 ภาพ สายพันธุ์ละ 400 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน 272 ภาพ ข้อมูลชุดตรวจสอบความถูกต้อง 80 ภาพ และข้อมูลชุดทดสอบ 48 ภาพ ทำการทดลองฝึกสอนตัวแบบโครงข่ายประสาทประดิษฐ์เชิงลึก YOLOv3 แล้วเปรียบเทียบประสิทธิภาพในการเรียนรู้ระหว่างชุดข้อมูลที่ผ่านการเตรียมข้อมูล (Pre-processing) ด้วยวิธีการสกัดรูปร่าง (Contour Extraction) และชุดข้อมูลที่ไม่ได้ผ่านการเตรียมข้อมูล ผลการศึกษา พบว่า การเตรียมการประมวลผล (Pre-processing) ช่วยให้ตัวแบบสามารถเรียนรู้ได้เร็วยิ่งขึ้นและมีความแม่นยำสูงกว่าการฝึกสอนกับชุดข้อมูลที่ไม่ได้ผ่านการเตรียมการประมวลผล (Pre-processing) ทั้งชุดที่ผ่านการเสริมข้อมูล (Data Augmentation) และไม่ได้ผ่านการเสริมข้อมูล

Liu และคณะ [70] ได้ทำการศึกษากการจำแนกพันธุ์พืชในมณฑลไห่หนานด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชันเชิงลึกด้วยการถ่ายโอนความรู้กับชุดข้อมูล Flavia ประกอบด้วย 32 พันธุ์พืช จำนวนทั้งสิ้น 1,907 ภาพ และ HNPlant ประกอบด้วย 10 พันธุ์พืช จำนวนทั้งสิ้น 3,176 ภาพ ทำการฝึกสอนผ่านตัวแบบพื้นฐาน ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำในการจำแนกพันธุ์พืชสูงสุดในชุดข้อมูล Flavia และ HNPlant ที่ 89% และ 95% ตามลำดับ แสดงให้เห็นถึงประสิทธิภาพของตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชันเชิงลึก ซึ่งให้ความแม่นยำในการจำแนกสูงสำหรับพืชในมณฑลไห่หนาน

Patil และคณะ [71] ได้ทำการศึกษากการเปรียบเทียบวิธีการเรียนรู้ของเครื่องในการรู้จำพันธุ์พืชกับชุดข้อมูลสาธารณะ Swedish Leaves ประกอบด้วย 15 พันธุ์พืช จำนวนทั้งสิ้น 1,060 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน 960 ภาพ และข้อมูลชุดทดสอบ 100 ภาพ ทำการฝึกสอนตัวแบบโดยใช้วิธีการเรียนรู้ของเครื่องแบบดั้งเดิม ได้แก่ Logistic Regression, Naïve Bayes, Support Vector Machine, Decision Tree, K-Nearest Neighbors และการเรียนรู้เชิงลึก ได้แก่ CNN, VGG16 และ ResNet ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นด้วยวิธีการเรียนรู้ของเครื่องแบบดั้งเดิมมีความแม่นยำในการจำแนกที่ 83.43%, 76.33%, 81.66%, 65.68% และ 82.84% ในขณะที่ตัวแบบที่สร้างขึ้นด้วยวิธีการเรียนรู้เชิงลึกมีความแม่นยำสูงกว่าที่ 96.60%, 95.75% และ 98.33% ตามลำดับ

Sachar และ Kumar [72] ได้ทำการศึกษาศึกษาการจำแนกพันธุ์พืชด้วยการถ่ายโอนความรู้กับชุดข้อมูลสาธารณะ Swedish Leaf, Flavia และ MalayaKew ทำการเลือกตัวแบบพื้นฐาน จำนวน 4 ตัวแบบ ได้แก่ VGG16, Xception, MobileNetV2 และ DenseNet121 แล้วทำการจำแนกด้วย Random Forest ผลการศึกษพบว่า ตัวแบบ DenseNet121 มีความแม่นยำสูงสุดรองลงมา คือ VGG-16, MobileNetV2 และ Xception ที่ความแม่นยำ 92.4%, 79%, 76% และ 75% ตามลำดับ โดยเมื่อทำการเปรียบเทียบกับตัวแบบสมัยใหม่แสดงให้เห็นว่าตัวแบบที่สร้างขึ้นมีความแม่นยำสูงสุด

Bisen [73] ได้ทำการศึกษาศึกษาการจำแนกพันธุ์พืชด้วยการเรียนรู้เชิงลึกจากลักษณะใบกับชุดข้อมูลสาธารณะ Swedish Leaf ประกอบด้วย 15 พันธุ์พืช สายพันธุ์ละ 75 ภาพ ทำการเตรียมข้อมูล (Preprocessing) โดยการแบ่งข้อมูลออกเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 3 พร้อมทั้งเพิ่มข้อมูล (Data Augmentation) แล้วทำการฝึกสอนผ่านโครงข่ายประสาทประดิษฐ์คอนโวลูชัน ผลการศึกษพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 97%

Kanda และคณะ [74] ได้ทำการศึกษาศึกษาการจำแนกพันธุ์พืชจากลักษณะใบด้วยการเรียนรู้เชิงลึกกับชุดข้อมูล MEW2012, Flavia, MalayaKew-D1, Folio, Amazon forest, Leaf snap และ Swedish Leaf โดยทำการสร้างข้อมูลภาพที่ไม่มีอยู่จริง (Synthetic Data) ด้วย Generative Adversarial Network เพื่อเพิ่มปริมาณข้อมูลจากนั้นสกัดคุณลักษณะด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) แล้วส่งคุณลักษณะที่สกัดได้ไปทำการจำแนกผ่านตัวจำแนก Logistic Regression ผลการศึกษพบว่า การสกัดคุณลักษณะด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชันให้ผลลัพธ์ด้านคุณลักษณะของใบพืชได้ดีกว่าการอาศัยความรู้เฉพาะทาง (Hand-Craft Features) ตัวแบบที่สร้างขึ้นมีความแม่นยำเฉลี่ยสูงถึง 96.1% เมื่อทำการทดสอบประสิทธิภาพของตัวแบบกับชุดข้อมูลที่ทำกรเพิ่มปริมาณข้อมูลภาพส่งผลให้ตัวแบบมีความแม่นยำสูงขึ้น 3% แสดงให้เห็นว่าการเพิ่มปริมาณข้อมูลด้วย Generative Adversarial Networks สามารถจัดการกับปัญหาปริมาณข้อมูลไม่เพียงพอรวมถึงชุดข้อมูลที่มีปริมาณไม่สมดุลสำหรับงานที่ต้องใช้วิธีการเรียนรู้เชิงลึกได้อย่างมีประสิทธิภาพ

Reddy และคณะ [75] ได้ทำการศึกษาศึกษาการปรับปรุงตัวแบบโครงข่ายประสาทประดิษฐ์คอนโวลูชัน (CNN) ระบุนพันธุ์พืชจากลักษณะใบโดยใช้วิธีการทางคอมพิวเตอร์วิทัศน์กับ 5 ชุดข้อมูลรูปภาพใบพืชที่ได้รับความนิยม ได้แก่ Leaf Snap, UCI Leaf, Plant Village, Flavia และ Swedish Leaf ทำการเตรียมข้อมูล (Preprocessing) ด้วยการปรับปรุงคุณภาพรูปภาพ (Image Enhancement) ตัดสัญญาณรบกวนบนรูปภาพ (Image Denoising) และการแบ่งส่วนรูปภาพ (Image Segmentation) พร้อมทั้งสกัดคุณลักษณะรูปร่างภายนอก (Morphological Shape Features) และลักษณะพื้นผิว (Texture Features) ของใบพืชแล้วฝึกสอนผ่านโครงข่ายประสาทประดิษฐ์คอนโวลูชันที่ 100, 150 และ 200 รอบ ผลการศึกษพบว่า ตัวแบบที่สร้างขึ้นมีประสิทธิภาพสูงสุดเมื่อทำการเปรียบเทียบกับตัวแบบสมัยใหม่ที่ไม่ได้มีการปรับปรุง

Pushpanathan และคณะ [76] ได้ทำการศึกษาการจำแนกพันธุ์พืชสมุนไพรท้องถิ่นยืนต้น จากลักษณะใบภายใต้สภาพแวดล้อมที่ไม่สามารถควบคุมได้ กับชุดข้อมูลสาธารณะ MYLPHerbs-1 ประกอบด้วย 12 พันธุ์พืช จำนวนทั้งสิ้น 34,200 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 3 ทำการฝึกสอนตัวแบบพื้นฐานผ่านการถ่ายโอนความรู้ จำนวน 5 ตัวแบบ ได้แก่ VGG16, VGG19, ResNet50, EfficientNetB0 และ EfficientNetB7 กับ 3 การทดลอง การทดลองที่ 1 ฝึกสอนตัวแบบกับชุดข้อมูลเต็ม การทดลองที่ 2 ฝึกสอนตัวแบบกับข้อมูลจำนวน 1/2 ของชุดข้อมูลเต็ม และการทดลองที่ 3 ฝึกสอนตัวแบบกับชุดข้อมูลจำนวน 1/4 จากชุดข้อมูลเต็ม แล้วทำการเปรียบเทียบประสิทธิภาพ ผลการศึกษาพบว่า ตัวแบบ VGG16 และ VGG19 มีความแม่นยำสูงสุดกว่า 90% ผลการวิเคราะห์ความแปรปรวน (ANOVA) พบว่า ขนาดชุดข้อมูลในการทดลองที่ 1, 2 และ 3 มีค่าผลทดสอบสมมติฐาน (p-value) ที่  $5.77 \times 10^{-24}$ ,  $4.77 \times 10^{-18}$  และ  $7.48 \times 10^{-24}$  ตามลำดับ ซึ่งถือว่า มีนัยสำคัญทางสถิติ แสดงให้เห็นว่าอัลกอริทึมของตัวแบบส่งผลต่อความแม่นยำในการจำแนกเมื่อทำการทดลองฝึกสอนด้วยขนาดชุดข้อมูลที่แตกต่างกัน ในขณะที่อัลกอริทึมของตัวแบบ VGG16, VGG19, ResNet50, EfficientNetB0 และ EfficientNetB7 มีค่าทดสอบสมมติฐานที่ 0.62, 0.62, 0.96, 0.17 และ 0.25 ตามลำดับ แสดงให้เห็นว่าขนาดของชุดข้อมูลที่แตกต่างกันไม่ส่งผลต่อความแม่นยำของตัวแบบ

Kundur และ Mallikarjuna [77] ได้ทำการศึกษาการจำแนกพันธุ์พืชต้นกล้าด้วยโครงข่ายประสาทประดิษฐ์คอนโวลูชันเชิงลึก กับชุดข้อมูลสาธารณะ Plant Seedlings ประกอบด้วยพันธุ์พืช 12 สายพันธุ์ จำนวนทั้งสิ้น 5,541 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน ข้อมูลชุดตรวจสอบความถูกต้อง และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 1.5 : 1.5 ทำการฝึกสอนตัวแบบพื้นฐานผ่านการถ่ายโอนความรู้ ด้วยการปรับแต่งตัวแบบ จำนวน 2 ตัวแบบ ได้แก่ EfficientNetB2 และ EfficientNetB4 ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 97% และ 99% ตามลำดับ

Anjomshoae และคณะ [78] ได้ทำการศึกษาการระบุขอบเขตใบ (Leaf Boundary) ของต้นพันธุ์ยางพารา เพื่อให้สามารถระบุขอบเขตของใบยางพาราได้แม่นยำมากยิ่งขึ้นโดยใช้วิธีการประมวลผลภาพดิจิทัลในการเปลี่ยนแปลงลักษณะโครงสร้างของภาพ (Morphological Transformation) และการตรวจจับขอบ (Edge Detection) กับข้อมูลภาพใบยางพาราทั้งแบบที่มีส่วนทับซ้อน (Overlapping) และไม่มีส่วนทับซ้อน (Non-Overlapping) ผลการศึกษา พบว่าสามารถทำการระบุขอบเขตของใบยางพาราได้อย่างมีประสิทธิภาพทั้งสองรูปแบบ

Anjomshoae และ Rahim [79] ได้ทำการศึกษาการสกัดคุณลักษณะใบยางพาราที่ทับซ้อนกัน กับชุดข้อมูลใบยางพารา 5 สายพันธุ์ ได้แก่ PB 350, RRIM 2001, RRIM 2002, RRIM 2025 และ RRIM 3001 จำนวน 250 ใบ จาก 25 ต้นยางพารา โดยทำการสกัดจุดสนใจ (Keypoint Extraction) ด้วย Scale-Invariant Feature Transformation (SIFT), Harris Corner Detection และ Features

from Accelerated Segment Test (FAST) และทำการสกัดมุม (Angle Extraction) ด้วย Hough Transform และ Boundary-Tracing พร้อมทั้งทำการเปรียบเทียบประสิทธิภาพ ผลการศึกษาพบว่าการสกัดจุดสนใจด้วย SIFT สามารถสกัดคุณลักษณะได้มีประสิทธิภาพสูงกว่า Harris และ FAST ในขณะที่การสกัดมุมด้วย Hough Transform ให้ผลลัพธ์ค่าองศาอยู่ในช่วงที่ดีกว่า Boundary-tracing

Pratomo และคณะ [80] ได้ทำการศึกษาคูณลักษณะใบของต้นพันธุ์ยางพารา 27 สายพันธุ์ เพื่อนำไปใช้ในการจำแนกพันธุ์ยางพารา โดยศึกษาคูณลักษณะด้านขนาดของความยาว (Size of the Length) ความกว้างของใบ (Maximum Leaf Width) และมุมของใบ (Angle) จำนวน 10 ลักษณะ ด้วยโปรแกรมคอมพิวเตอร์กับชุดข้อมูลรูปภาพใบยางพารา จำนวน 540 ภาพ ที่ผ่านการคัดเลือกใบที่ไม่สมบูรณ์ออก ผลการศึกษา พบว่า คุณลักษณะใบของต้นพันธุ์ยางพาราแต่ละสายพันธุ์มีความแตกต่างกัน จึงเป็นลักษณะทางสัณฐานวิทยาที่มีความเหมาะสมต่อการนำไปใช้ในการจำแนกสายพันธุ์

Pasaribu และคณะ [81] ได้ทำการศึกษาคูณลักษณะของใบยางพารากับชุดข้อมูลใบยางพารา 7 สายพันธุ์ ได้แก่ IRR 425, IRR 428, IRR 429, IRR 434, IRR 440, RRIC 100 และ BPM 24 ด้วยวิธี Leafgram ผลการศึกษาพบว่า คุณลักษณะที่สามารถนำมาใช้ในการจำแนกพันธุ์ยางพารา ได้แก่ ความกว้าง (Width), ความกว้างของแผ่นใบด้านซ้าย (Left Strand), มุมที่ปลายใบ (Apex Angle), มุมที่ฐานใบ (Basal Angle), อัตราส่วนความยาวต่อความกว้างของใบ (ratio length/width), อัตราส่วนความกว้างของแผ่นใบด้านซ้าย ต่อความยาวจากปลายใบถึงจุดพับใบตรงส่วนที่กว้างที่สุด (Ratio Left Strand/Top Fold Point), อัตราส่วนความกว้างของแผ่นใบด้านซ้ายต่อความยาวจากปลายใบถึงจุดกึ่งกลางใบ (Ratio Left Strand/Center Point) อัตราส่วนความยาวจากปลายใบถึงจุดพับใบตรงส่วนที่กว้างที่สุดต่อพื้นที่ใบ (Ratio Top Fold Point/Large), อัตราส่วนของมุมที่ปลายใบต่อมุมที่ฐานใบ (Ratio Apex/Basal Angle) อัตราส่วนของเส้นใบต่อมุมที่ปลายใบ (Ratio Vein/Apex Angle), และอัตราส่วนของเส้นใบต่อมุมที่ฐานใบ (Ratio Vein/Basal Angle)

วรรณสิริ ชุระชน และคณะ [82] ได้ทำการศึกษาระบบจำแนกพันธุ์ยางพาราโดยใช้ตัวจำแนก Naïve Baye เพื่อสร้างระบบจำแนกพันธุ์ยางพาราด้วยตัวจำแนก Naïve Baye กับข้อมูลตัวอย่างพันธุ์ยางพาราที่มีการปลูกในภาคตะวันออกเฉียงเหนือของประเทศไทย จำนวน 5 พันธุ์ คือ RRIT 251, RRIT 226, BPM 24, RRIM 600 และ PB 235 โดยอาศัยคุณลักษณะเด่นประจำพันธุ์ของยางพารา คือ ฉัตร ใบ ก้านใบ ก้านใบย่อย เปลือก และตา ซึ่งมีลักษณะย่อยอื่น ๆ รวม 32 คุณลักษณะ และทำการคัดเลือกคุณลักษณะที่มีความเกี่ยวพันกันน้อยที่สุดจนได้คุณลักษณะเด่นทั้งหมด 10 คุณลักษณะ ประกอบด้วย ความกว้างของฉัตร, ความเป็นมัน, ผิวใบ, ใบตัดตามขวาง, ขอบใบ, ความยาวของก้านใบ, รูปร่างของฐานก้านใบ, รอยแผลก้านใบ, ความยาวก้านใบย่อย และเปลือกส่วนสีเขียว ซึ่งลักษณะ

เด่นเหล่านี้สามารถใช้ในการจำแนกพันธุ์ยางพารา โดยระบบสามารถทำการจำแนกพันธุ์ยางพาราได้ ผลลัพธ์และระดับความถูกต้องของการจำแนกพันธุ์ยางพาราที่ 98.02%

Pongsomsong และ Ratanaworabhan [83] ได้ทำการศึกษาการจำแนกพันธุ์ยางพารา RRIM 600 และ RRIT 251 โดยพิจารณาจาก 4 คุณลักษณะ ได้แก่ ปลายใบ (Leaf Apex), ฐานใบ (Leaf Base), ขอบใบ (Leaf Margin), และลักษณะแผ่นใบ (Leaf Blade) ทำการเตรียมข้อมูล (Preprocessing) ด้วยการประมวลผลภาพดิจิทัลแล้วทำการฝึกสอนผ่านโครงข่ายประสาทประดิษฐ์ (ANN) ด้วยชุดข้อมูลรูปภาพใบยางพารา จำนวน 127 ภาพ แบ่งเป็นข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบที่อัตราส่วน 7 : 3 ผลการศึกษาพบว่า ตัวแบบที่สร้างขึ้นมีความแม่นยำสูงถึง 83.46% ขนาดของพื้นที่หน่วยความจำมีขนาดเล็กกว่า 100 กิโลไบต์ (Kbytes) และใช้เวลาในการจำแนกเฉลี่ย 3.42 วินาที



ตารางที่ 2.4 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Olsen และคณะ [45]	2019	จำแนกพันธุ์พืช จากลักษณะใบ	DL (Transfer Learning : FEA)	
			Model	Test Acc. (%)
			InceptionV3	95.10
			ResNet50	95.70
Zarrin และคณะ [46]	2019	จำแนกพันธุ์พืชท้องถิ่น จากลักษณะใบ	Sequential CNN	
			Model	Test Acc. (%)
			CNN	99.40
Habiba และคณะ [47]	2019	จำแนกพันธุ์พืชบังกลาเทศ จากลักษณะใบ	DL (Transfer Learning : FTA)	
			Model	Test Acc. (%)
			VGG16	99.96
			VGG19	98.56
			ResNet50	92.52
			InceptionV3	89.93
InceptionResNetV2	87.33			
			Xception	85.51

ตารางที่ 2.4 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง																			
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)																
Pereira และคณะ [48]	2019	จำแนกพันธุ์องุ่น จากลักษณะใบ	DL (Transfer Learning : FTA)																
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>AlexNet</td> <td>77.30</td> </tr> </tbody> </table>	Model	Test Acc. (%)	AlexNet	77.30												
Model	Test Acc. (%)																		
AlexNet	77.30																		
Huang และคณะ [49]	2019	จำแนก <i>Cinnamomum camphora</i> จากลักษณะใบ	DL (Transfer Learning : FTA)																
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>AlexNet</td> <td>93.40</td> </tr> <tr> <td>GoogLeNet</td> <td>95.30</td> </tr> <tr> <td>ResNet50</td> <td>95.30</td> </tr> <tr> <td>ResNet101</td> <td>94.30</td> </tr> <tr> <td>InceptionV3</td> <td>85.80</td> </tr> <tr> <td>InceptionResNetV2</td> <td>69.80</td> </tr> <tr> <td>SqueezeNet</td> <td>89.60</td> </tr> </tbody> </table>	Model	Test Acc. (%)	AlexNet	93.40	GoogLeNet	95.30	ResNet50	95.30	ResNet101	94.30	InceptionV3	85.80	InceptionResNetV2	69.80	SqueezeNet	89.60
			Model	Test Acc. (%)															
			AlexNet	93.40															
			GoogLeNet	95.30															
			ResNet50	95.30															
			ResNet101	94.30															
InceptionV3	85.80																		
InceptionResNetV2	69.80																		
SqueezeNet	89.60																		

ตารางที่ 2.4 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Kamrul [50]	2020	จัดกลุ่มใบชา	Sequential CNN, DL (Transfer Learning)	
			Model	Test Acc. (%)
			CNN	95.23
			VGG16	92.23
InceptionV3	96.28			
Vizcarra และคณะ [51]	2021	จำแนกพันธุ์พืชเปรู จากลักษณะใบ	DL (Transfer Learning : FTA)	
			Model	Test Acc. (%)
			AlexNet	95.98
			VGG19	96.52
			ResNet101	75.44
DenseNet201	86.29			
Nasiri และคณะ [52]	2021	จำแนกพันธุ์องุ่น จากลักษณะใบ	DL (Transfer Learning : FTA)	
			Model	Test Acc. (%)
			VGG16	99.00

ตารางที่ 2.5 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรด้วยวิธีการเรียนรู้ของเครื่อง

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง													
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)										
Trung และคณะ [53]	2019	จำแนกพันธุ์พืชสมุนไพร ในประเทศเวียดนามตอนใต้ จากลักษณะใบ	DL (Transfer Learning)										
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>MobileNet</td> <td>98.7</td> </tr> </tbody> </table>	Model	Test Acc. (%)	MobileNet	98.7						
Model	Test Acc. (%)												
MobileNet	98.7												
Azeez และ Rajapakse [54]	2019	จำแนกพันธุ์พืชสมุนไพร ศรีลังกา จากลักษณะใบ	DL (Transfer Learning : FTA)										
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>InceptionV3</td> <td>88.6</td> </tr> <tr> <td>ResNet50</td> <td>95.5</td> </tr> <tr> <td>MobileNet</td> <td>86.4</td> </tr> <tr> <td>InceptionResNetV2</td> <td>83.3</td> </tr> </tbody> </table>	Model	Test Acc. (%)	InceptionV3	88.6	ResNet50	95.5	MobileNet	86.4	InceptionResNetV2	83.3
			Model	Test Acc. (%)									
			InceptionV3	88.6									
ResNet50	95.5												
MobileNet	86.4												
InceptionResNetV2	83.3												

ตารางที่ 2.5 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Dileep และ Pournami [55]	2019	จำแนกพันธุ์พืชสมุนไพรในรัฐ Kerala สาธารณรัฐอินเดีย จากลักษณะใบ	Sequential CNN, DL (Transfer Learning : FTA) + CNN, SVM Classifier	
			<b>Model</b>	<b>Test Acc. (%)</b>
			AlexNet	94.87
			CNN (AyurLeaf)	93.16
			CNN (DLeaf)	95.06
CNN (AyurLeaf) + SVM	96.76			
Paulson และ Ravishankar [56]	2020	จำแนกพันธุ์พืชสมุนไพรในรัฐ Kerala สาธารณรัฐอินเดีย จากลักษณะใบ	Sequential CNN, DL (Transfer Learning)	
			<b>Model</b>	<b>Test Acc. (%)</b>
			VGG16	97.8
			VGG19	97.6
CNN	95.79			

ตารางที่ 2.5 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Mettripun [57]	2020	จำแนกพันธุ์พืชสมุนไพรไทย จากลักษณะใบ	ANN	
			Model	Test Acc. (%)
			ANN	90.50
Muneer และ Fati [58]	2020	จำแนกพันธุ์พืชสมุนไพร มาเลเซีย จากลักษณะใบ	SVM, DL	
			Model	Test Acc. (%)
			SVM	74.64
			DNN	93
Sachar และ Kumar [59]	2022	จำแนกพันธุ์สมุนไพร กับชุดข้อมูลสาธารณะ Medicinal Leaf จากลักษณะใบ	DL (Transfer Learning : FEA)	
			Model	Test Acc. (%)
			Ensemble (MobileNetV2 + InceptionV3 + ResNet50)	99.94

ตารางที่ 2.5 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชสมุนไพรจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Roopashree และ Anitha [60]	2021	จำแนกพันธุ์พืชสมุนไพร ชุดข้อมูลสาธารณะ DeepHerb จากลักษณะใบ	DL (Transfer Learning : FEA) + ANN, SVM Classifier	
			Model	Test Acc. (%)
			VGG16 + ANN	95.39
			VGG19 + ANN	95.97
			InceptionV3 + ANN	96.16
			Xception + ANN	97.50
			Xception + SVM	92.90
Xception + SVM + BO	95.20			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Alimboyong และคณะ [61]	2019	จำแนกพันธุ์พืชต้นกล้า ชุดข้อมูลสาธารณะ Plant Seedlings จากลักษณะใบ	Sequential CNN	
			Model	Test Acc. (%)
			CNN	90.15
Pearline และคณะ [62]	2019	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Folio, Swedish Leaf, Flavia และ Leaf12 จากลักษณะใบ	DL (Transfer Learning : FEA) + LDA, LR NB, KNN, CART, RF, BC Classifier	
			Model	Test Acc. (%)
			RF	82.38
			VGG16 + LR (Leaf12)	97.14
			VGG19 + LR (Folio)	96.53
VGG19 + LR (Flavia)	96.25			
VGG19 + LR (Swedish Leaf)	99.41			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Kaya และคณะ [63]	2019	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ Flavia, Swedish Leaf, UCI Leaf และ Plant Village จากลักษณะใบ	Sequential CNN, Parallel CNN, RNN, DL (Transfer Learning : FEA, FTA)	
			Model	Test Acc. (%)
			Sequential CNN (Flavia)	91.08
			Sequential CNN (Swedish Leaf)	96.06
			Sequential CNN (UCI Leaf)	76.15
			Sequential CNN (Plant Village)	97.40
			FTA : AlexNet, VGG16 (Flavia)	97.89, 98.16
FTA : AlexNet, VGG16 (Swedish Leaf)	95.56, 99.11			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง																					
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)																		
			Sequential CNN, Parallel CNN, RNN, DL (Transfer Learning : FEA, FTA)																		
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>FTA : AlexNet, VGG16 (UCI Leaf)</td> <td>89.41,</td> </tr> <tr> <td></td> <td>90.56</td> </tr> <tr> <td>จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish (Plant Village)</td> <td>98.60,</td> </tr> <tr> <td></td> <td>99.80</td> </tr> <tr> <td>Cross Dataset FTA : Sequential CNN (Flavia)</td> <td>91.43</td> </tr> <tr> <td>Cross Dataset FTA : Sequential CNN (Swedish Leaf)</td> <td>96.06</td> </tr> <tr> <td>Cross Dataset FTA : Sequential CNN (UCI Leaf)</td> <td>80.60</td> </tr> <tr> <td>Cross Dataset FTA : Sequential CNN (Plant Village)</td> <td>96.93</td> </tr> </tbody> </table>	Model	Test Acc. (%)	FTA : AlexNet, VGG16 (UCI Leaf)	89.41,		90.56	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish (Plant Village)	98.60,		99.80	Cross Dataset FTA : Sequential CNN (Flavia)	91.43	Cross Dataset FTA : Sequential CNN (Swedish Leaf)	96.06	Cross Dataset FTA : Sequential CNN (UCI Leaf)	80.60	Cross Dataset FTA : Sequential CNN (Plant Village)	96.93
Model	Test Acc. (%)																				
FTA : AlexNet, VGG16 (UCI Leaf)	89.41,																				
	90.56																				
จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish (Plant Village)	98.60,																				
	99.80																				
Cross Dataset FTA : Sequential CNN (Flavia)	91.43																				
Cross Dataset FTA : Sequential CNN (Swedish Leaf)	96.06																				
Cross Dataset FTA : Sequential CNN (UCI Leaf)	80.60																				
Cross Dataset FTA : Sequential CNN (Plant Village)	96.93																				
Kaya และคณะ [63]	2019	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish Leaf, UCI Leaf และ Plant Village จากลักษณะใบ																			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง													
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)										
			Sequential CNN, Parallel CNN, RNN, DL (Transfer Learning : FEA, FTA)										
			<table border="1"> <thead> <tr> <th>Model</th> <th>Test Acc. (%)</th> </tr> </thead> <tbody> <tr> <td>FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Flavia)</td> <td>99.00, 97.50, 99.10, 97.70</td> </tr> <tr> <td>FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Swedish Leaf)</td> <td>95.80, 97.80, 96.10, 98.80</td> </tr> <tr> <td>FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (UCI Leaf)</td> <td>96.20, 88.90, 94.80, 89.60</td> </tr> <tr> <td>FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Plant Village)</td> <td>98.70, 97.80, 98.70, 98.00</td> </tr> </tbody> </table>	Model	Test Acc. (%)	FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Flavia)	99.00, 97.50, 99.10, 97.70	FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Swedish Leaf)	95.80, 97.80, 96.10, 98.80	FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (UCI Leaf)	96.20, 88.90, 94.80, 89.60	FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Plant Village)	98.70, 97.80, 98.70, 98.00
Model	Test Acc. (%)												
FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Flavia)	99.00, 97.50, 99.10, 97.70												
FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Swedish Leaf)	95.80, 97.80, 96.10, 98.80												
FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (UCI Leaf)	96.20, 88.90, 94.80, 89.60												
FEA : AlexNet + LDA, SVM, VGG16 + LDA, SVM (Plant Village)	98.70, 97.80, 98.70, 98.00												
Kaya และคณะ [63]	2019	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish Leaf, UCI Leaf และ Plant Village จากลักษณะใบ											

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Kaya และคณะ [63]	2019	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia, Swedish Leaf, UCI Leaf และ Plant Village จากลักษณะใบ	Sequential CNN, Parallel CNN, RNN, DL (Transfer Learning : FEA, FTA)	
			Model	Test Acc. (%)
			Parallel CNN, RNN (Flavia)	92.65
			Parallel CNN, RNN (Swedish Leaf)	99.11
			Parallel CNN, RNN (UCI Leaf)	70.79
Parallel CNN, RNN (Plant Village)	98.77			
Diaz และคณะ [64]	2019	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ Plant Seedling จากลักษณะใบ	DL (Transfer Learning : FEA)	
			Model	Test Acc. (%)
			VGG16	78.84
			InceptionV3	76.60
Xception	86.21			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Jasitha และ Dileep [65]	2019	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ DLeaf, Flavia และ Leaf1 จากลักษณะใบ	DL (Transfer Learning : FTA) + SVM Classifier	
			Model	Test Acc. (%)
			GoogLeNet (DLeaf)	88.74
			GoogLeNet (Flavia)	94.00
			GoogLeNet (Leaf1)	98.00
			GoogLeNet + SVM (DLeaf)	95.10
			GoogLeNet + SVM (Flavia)	96.10
			GoogLeNet + SVM (Leaf1)	99.20
			VGG16 (DLeaf)	85.73
			VGG16 (Flavia)	96.57
			VGG16 (Leaf1)	97.00
			VGG16 + SVM (DLeaf)	83.34
			VGG16 + SVM (Flavia)	95.23
VGG16 + SVM (Leaf1)	96.00			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Tiwari [66]	2020	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ จากลักษณะใบ	DNN, CNN	
			Model	Test Acc. (%)
			DNN	91.17
			CNN	95.58
Miao และคณะ [67]	2020	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ ImageNet จากลักษณะใบ	ANN, CNN, DL (Transfer Learning)	
			Model	Test Acc. (%)
			ANN	75.41
			CNN	84.92
			InceptionV3	87.63
InceptionResNetV2	93.23			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Parallel CNN				
		จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Leaf Snap และ MalayaKew	Model Test Acc. (%)	
Riaz และคณะ [68]	2020	จากลักษณะใบ	CNN (Leafsnap)	99.38
			CNN (MalayaKew D1)	99.22
			CNN (MalayaKew D2)	98.71
			CNN (MalayaKew D3)	98.87
DL				
		จำแนกพันธุ์พืช ในฟาร์มจากลักษณะใบ แบบเรียลไทม์	Model mAP (%)	
Chang และ Chung [69]	2020		YOLOv3 (Data Augmentation)	98.30
			YOLOv3 (Data Augmentation, Preprocessing)	98.60
			YOLOv3	96.22
			YOLOv3 (Preprocessing)	97.40

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Liu และคณะ [70]	2021	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Flavia และ HNPlant จากลักษณะใบ	DL (Transfer Learning : FTA)	
			Model	Test Acc. (%)
			ResNet50 (Flavia)	89.00
			ResNet50 (HNPlant)	95.00
Patil และคณะ [71]	2021	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ Swedish Leaves จากลักษณะใบ	LR, NB, SVM, DT, KNN, CNN, DL (Transfer Learning)	
			Model	Test Acc. (%)
			LR	83.43
			NB	76.33
			SVM	81.66
			DT	65.68
			KNN	82.84
			CNN	96.60
			VGG16	95.75
			ResNet50	98.33

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Sachar และ Kumar [72]	2021	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Swedish Leaf, Flavia และ MalayaKew จากลักษณะใบ	DL (Transfer Learning : FEA) + Random Forest Classifier	
			Model	Test Acc. (%)
			VGG16 + RF (Swedish Leaf)	99.00
			Xception + RF (Swedish Leaf)	95.00
			MobileNetV2 + RF (Swedish Leaf)	99.00
			DenseNet121 + RF (Swedish Leaf)	100.00
VGG16 + RF (Flavia)	98.00			
Xception + RF (Flavia)	95.00			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Sachar และ Kumar [72]	2021	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Swedish Leaf, Flavia และ MalayaKew จากลักษณะใบ	DL (Transfer Learning : FEA) + Random Forest Classifier	
			Model	Test Acc. (%)
			MobileNetV2 + RF (Flavia)	98.00
			DenseNet121 + RF (Flavia)	99.00
			VGG16 + RF (MalayaKew)	79.00
			Xception + RF (MalayaKew)	75.00
MobileNetV2 + RF (MalayaKew)	76.00			
DenseNet121 + RF (MalayaKew)	92.40			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง			
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)
Bisen [73]	2021	จำแนกพันธุ์พืชชุดข้อมูล สาธารณะ Swedish Leaf จากลักษณะใบ	Sequential CNN
			Model Test Acc. (%)
			CNN 97.00
Kanda และคณะ [74]	2021	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ MEW2012, Flavia, MalayaKew-D1, Folio, Amazon forest, Leaf snap และ Swedish Leaf จากลักษณะใบ	CNN + Logistic Regression Classifier
			Model Test Acc. (%)
			CNN + LR (MEW2012) 98.72
			CNN + LR (Flavia) 99.58
			CNN + LR (MalayaKewD1) 89.35
			CNN + LR (MalayaKewD1 + Synthetic Dataset) 93.33
			CNN + LR (Folio) 98.75
			CNN + LR (Amazon Forest) 98.87
CNN + LR (LeafSnap) 98.27			
CNN + LR (Swedish Leaf) 100.00			

ตารางที่ 2.6 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะด้วยวิธีการเรียนรู้ของเครื่อง (ต่อ)

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์พืชชุดข้อมูลสาธารณะจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
Sequential CNN				
Reddy และคณะ [75]	2021	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ Leaf Snap, UCI Leaf, Plant Village, Flavia และ Swedish Leaf จากลักษณะใบ	Model	Test Acc. (%)
			CNN (Flavia)	100.00
			CNN (Swedish Leaf)	100.00
			CNN (UCI Leaf)	100.00
			CNN (Plant Village)	89.99
CNN (LeafSnap)	97.99			
DL (Transfer Learning : FEA)				
Pushpanathan [76]	2022	จำแนกพันธุ์พืช ชุดข้อมูล สาธารณะ MLYPHerbs-1 จากลักษณะใบ	Model	Test Acc. (%)
			VGG16	> 90.00
			VGG19	> 90.00
DL (Transfer Learning : FTA)				
Kundur [77]	2022	จำแนกพันธุ์พืช ชุดข้อมูลสาธารณะ Plant Seedling จากลักษณะใบ	Model	Test Acc. (%)
			EfficientNetB2	97.00
			EfficientNetB4	99.00

ตารางที่ 2.7 การเปรียบเทียบงานวิจัยการสกัดคุณลักษณะใบยางพารา

การเปรียบเทียบงานวิจัยการสกัดคุณลักษณะใบยางพารา			
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการ (Proposed Method)
Anjomshoae และคณะ [78]	2015	ระบุขอบเขตใบยางพาราเพื่อให้สามารถระบุขอบเขตใบยางพาราได้มีประสิทธิภาพมากยิ่งขึ้น	<ul style="list-style-type: none"> <li>- การเปลี่ยนแปลงลักษณะโครงสร้างภาพ (Morphological Transformation)</li> <li>- การตรวจจับขอบ (Edge Detection)</li> <li>- การสกัดจุดสนใจ (Keypoint Extraction)</li> <li>- การสกัดมุมใบ (Angle Extraction)</li> </ul>
Anjomshoae และ Rahim [79]	2018	สกัดคุณลักษณะใบยางพารา	<ul style="list-style-type: none"> <li>- การวิเคราะห์ความแปรปรวน (ANOVA)</li> </ul>
Pratomo และคณะ [80]	2021	ศึกษาลักษณะใบต้นพันธุ์ยางพาราเพื่อนำไปใช้ในการจำแนกพันธุ์ยางพารา	<ul style="list-style-type: none"> <li>- การวิเคราะห์ความแปรปรวน (ANOVA)</li> </ul>
Pasaribu และคณะ [81]	2022	ศึกษาลักษณะใบยางพาราเพื่อนำไปใช้ในการจำแนกพันธุ์ยางพารา	<ul style="list-style-type: none"> <li>- Leaf gram</li> </ul>

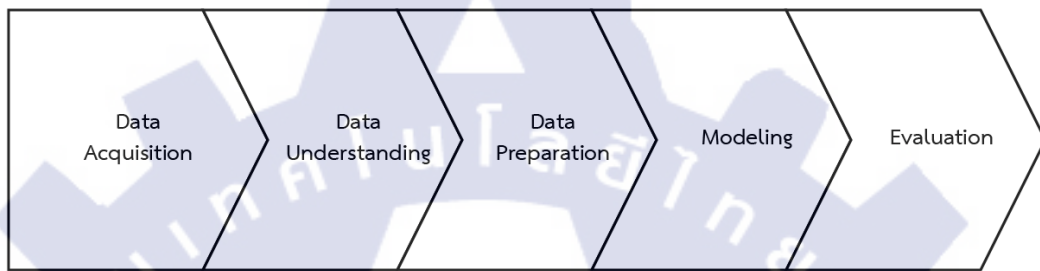
ตารางที่ 2.8 การเปรียบเทียบงานวิจัยการจำแนกพันธุ์ยางพาราจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง

การเปรียบเทียบงานวิจัยการจำแนกพันธุ์ยางพาราจากลักษณะใบด้วยวิธีการเรียนรู้ของเครื่อง				
ผู้วิจัย (Authors)	ปีที่ตีพิมพ์ (Published Year)	วัตถุประสงค์ (Objective)	วิธีการและประสิทธิภาพ (Proposed Method and Performance)	
วรรณสิริ ชุระชน และคณะ [82]	2014	จำแนกพันธุ์ยางพารา	Naïve Bayes	
			Model	Test Acc. (%)
			NB	98.02
Pongsomsong และ Ratanaworabhan [83]	2021	จำแนกพันธุ์ยางพารา จากลักษณะใบ	Artificial Neural Network	
			Model	Test Acc. (%)
			ANN	83.46



### บทที่ 3 วิธีการดำเนินงาน

การวิจัยนี้เป็นการศึกษาการจำแนกพันธุ์ยางพาราจากลักษณะใบ ดำเนินการวิเคราะห์ ออกแบบ และพัฒนาตัวแบบจำแนกพันธุ์ยางพาราโดยอาศัยหลักการเรียนรู้ของเครื่อง ผู้วิจัยได้ ทบทวนวรรณกรรมจากเอกสารและงานวิจัยที่เกี่ยวข้องแล้วนำองค์ความรู้ดังกล่าวมากำหนดเป็น ขั้นตอนการวิจัย (รูปที่ 3.1) ตามรายละเอียดการดำเนินงาน ดังนี้



รูปที่ 3.1 ขั้นตอนการดำเนินงาน

#### 3.1 การเก็บข้อมูล (Data Acquisition)

ดำเนินการเก็บข้อมูลภาพใบยางพารา 6 สายพันธุ์ ที่ปลูกในประเทศไทยจากแปลงกิ่งตา ศูนย์ควบคุมยางฉะเชิงเทรา กรมวิชาการเกษตร ด้วยกล้องดิจิทัล (ตารางที่ 3.1) ได้แก่ BPM 24, PB 235, RRIM 600, RRIT 226, RRIT 251 และ RRIT 408 โดยทำการถ่ายภาพใบยางพารา หลากหลายมุมมองด้วยการหมุนเวียน (Rotate) ใบยางพาราและการปรับมุมกล้อง (Camera Angle) ในสภาพแวดล้อมที่มีการควบคุมเพื่อให้ได้ข้อมูลกลุ่มตัวอย่างที่มีรูปแบบสำหรับการฝึกสอน

ตารางที่ 3.1 อุปกรณ์ที่ใช้ในการเก็บข้อมูล

อุปกรณ์เก็บข้อมูล			
กล้องดิจิทัล	ความละเอียด	ขนาดภาพ	
		ความกว้าง (Width)	ความสูง (Height)
Nikon COOLPIX B700	20 ล้านพิกเซล	5184 พิกเซล	3888 พิกเซล
Fujifilm FINEPIX F300EXR	12 ล้านพิกเซล	2816 พิกเซล	2112 พิกเซล

ข้อมูลภาพใบยางพาราชุดทดลองย่อย (ตารางที่ 3.2) ที่ใช้ในการศึกษานำร่อง (Pilot Study) เพื่อประเมินประสิทธิภาพของตัวแบบเบื้องต้น ประกอบด้วยภาพใบยางพาราสายพันธุ์ RRIM 600 จำนวนทั้งสิ้น 28,800 ภาพ เป็นกลุ่มตัวอย่างใบยางพาราจำนวน 800 ใบ แบ่งออกเป็น 2 กลุ่ม กลุ่มละ 400 ใบ ได้แก่ RRIM 600 Clone และ RRIM 600 Seedling

ตารางที่ 3.2 ข้อมูลภาพใบยางพาราชุดทดลองย่อย

ข้อมูลภาพใบยางพาราชุดทดลองย่อย	
กลุ่ม	จำนวน (ภาพ)
RRIM 600 Clone	14,400
RRIM 600 Seedling	14,400
<b>รวม</b>	<b>28,800</b>

ข้อมูลภาพใบยางพาราชุดทดลองหลัก (ตารางที่ 3.3) ที่ใช้ในการศึกษาวิจัยเพื่อสร้างตัวแบบ จำแนกพันธุ์ยางพารา ประกอบด้วย ภาพใบยางพาราสายพันธุ์ BPM 24, PB 235, RRIM 600, RRIT 226, RRIT 251 และ RRIT 408 จำนวนทั้งสิ้น 21,600 ภาพ เป็นกลุ่มตัวอย่างใบยางพาราจำนวน 600 ใบ สายพันธุ์ละ 100 ใบ

ตารางที่ 3.3 ชุดข้อมูลภาพใบยางพาราชุดทดลองหลัก

ข้อมูลภาพใบยางพาราชุดทดลองหลัก	
พันธุ์	จำนวน (ภาพ)
BPM 24	3,600
PB 235	3,600
RRIM 600	3,600
RRIT 226	3,600
RRIT 251	3,600
RRIT 408	3,600
<b>รวม</b>	<b>21,600</b>

### 3.2 การทำความเข้าใจข้อมูล (Data Understanding)

ดำเนินการศึกษาความแตกต่างของรูปทรงใบยางพาราทั้ง 6 สายพันธุ์ โดยอธิบายความแตกต่างของรูปทรงใบยางพาราแต่ละสายพันธุ์และจัดกลุ่มข้อมูลรูปภาพใบยางพาราที่มีคุณลักษณะใกล้เคียงกันรวมทั้งพิจารณาข้อมูลที่สามารถใช้เป็นตัวแทนประชากรได้ ตลอดจนคุณภาพของข้อมูล

### 3.3 การเตรียมข้อมูล (Data Preparation)

ดำเนินการเตรียมข้อมูลภาพที่มีขนาด 5184 x 3888 และ 2816 x 2112 พิกเซล โดยปรับลดขนาดของข้อมูลให้มีความเหมาะสมต่อการนำเข้าตัวแบบและแบ่งชุดข้อมูลออกเป็น 2 ชุด ได้แก่ ข้อมูลชุดฝึกสอน (Training Set) และข้อมูลชุดทดสอบ (Testing Set) ซึ่งเป็นข้อมูลที่ตัวแบบไม่เคยเห็นมาก่อน (Unseen Data)

#### 3.3.1 การปรับลดขนาดภาพ (Downsizing)

ทำการปรับลดขนาดภาพ (ตารางที่ 3.4) เพื่อให้สามารถทำการฝึกสอนตัวแบบได้รวดเร็วมากยิ่งขึ้น โดยรักษอัตราส่วนของรูปภาพ (Aspect Ratio) เพื่อไม่ให้ภาพเกิดการบิดเบี้ยว

ตารางที่ 3.4 การปรับลดขนาดภาพ


กล้องดิจิทัล	การปรับลดขนาดภาพ			
	ขนาดภาพ (ต้นฉบับ)		ขนาดภาพ (ปรับลด)	
	ความกว้าง (Width)	ความสูง (Height)	ความกว้าง (Width)	ความสูง (Height)
Nikon COOLPIX B700	5184 พิกเซล	3888 พิกเซล	324 พิกเซล	243 พิกเซล
Fujifilm FINEPIX F300EXR	2816 พิกเซล	2112 พิกเซล	352 พิกเซล	264 พิกเซล

#### 3.3.2 การเสริมข้อมูล (Data Augmentation)

ทำการเสริมข้อมูลสำหรับการฝึกสอนให้มีความหลากหลาย เพื่อเพิ่มประสิทธิภาพของตัวแบบให้ครอบคลุมต่อการใช้งานมากยิ่งขึ้น [84] ด้วยวิธีการต่าง ๆ ประกอบด้วย

1) การเสริมข้อมูลเชิงเรขาคณิต (Geometric Augmentation) ทำการเสริมข้อมูล 2 วิธีการ ได้แก่

การเสริมข้อมูลแบบดั้งเดิม (Traditional Method) ทำการเสริมข้อมูลด้วยการพลิกวัตถุ (Flip) และการหมุนเวียนวัตถุ (Rotation) เนื่องจากเป็นวิธีการเสริมภาพที่เรียบง่ายและมีประสิทธิภาพสูง [85] (รูปที่ 3.2 และ 3.3)




รูปที่ 3.2 การเสริมข้อมูลแบบดั้งเดิม




รูปที่ 3.3 ตัวอย่างรูปจากการเสริมข้อมูลแบบดั้งเดิม


การเสริมข้อมูลเฉพาะงาน (Specific Method) ทำการเสริมข้อมูลด้วยการปรับมุมกล้อง (Viewpoint) ประมาณ 60 องศา จากซ้ายไปขวาต่อการหมุนเวียนวัตถุทุก 45 องศา เพื่อให้รองรับรูปทรงใบที่เปลี่ยนแปลงไปจากการโค้งงอตามแรงโน้มถ่วงโลก (รูปที่ 3.4, 3.5 และ 3.6)



รูปที่ 3.4 การเสริมข้อมูลเฉพาะงาน

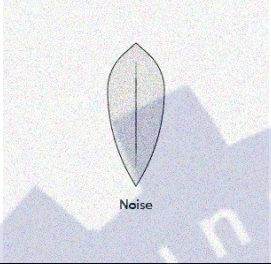

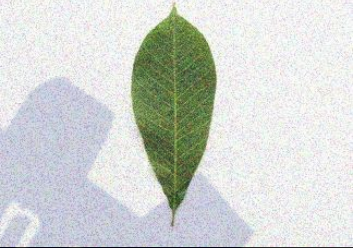
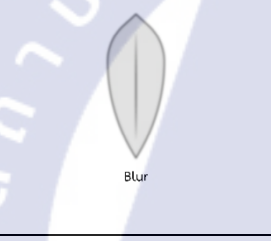


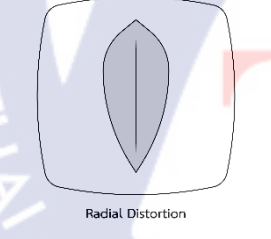




รูปที่ 3.5 ตัวอย่างรูปจากการปรับมุมกล้อง



รูปที่ 3.6 ตัวอย่างรูปจากการเสริมข้อมูลเฉพาะงาน

2) การเสริมข้อมูลเชิงคุณสมบัติของรูป (Photometric Augmentation) ทำการเสริมข้อมูลด้วยการมัวภาพแบบเกาส์เซียน (Gaussian Blur) การสร้างสัญญาณรบกวน (Noise) และการบิดเบี้ยวของเลนส์กล้อง (Radial Distortion) เพื่อให้ตัวแบบมีความทนทาน [86] ต่อความผิดเพี้ยนของภาพที่เกิดจากเลนส์กล้อง (Wide Angle Lens) [87] แสงสว่าง (Illumination) อุณหภูมิ (Temperature) [88] และรองรับต่อการใช้งานในสภาพแวดล้อมที่เปลี่ยนแปลงไป [89][90] (รูปที่ 3.7)

วิธีการ (Techniques)	ต้นฉบับ (Input)	ผลลัพธ์ (Output)
 <p>Noise</p>		
 <p>Blur</p>		
 <p>Radial Distortion</p>		

รูปที่ 3.7 ตัวอย่างรูปจากการเสริมข้อมูลเชิงคุณสมบัติของรูป

### 3.4 การสร้างตัวแบบ (Modeling)

ดำเนินการสร้างตัวแบบโดยใช้ตัวแบบพื้นฐานที่ผ่านการฝึกสอนงานที่เกี่ยวข้องมาแล้ว (Pre-trained Model) ที่มีประสิทธิภาพในการสกัดคุณลักษณะและทนทานต่อการใช้งาน ในสถานการณ์ต่าง ๆ [91] มาใช้เป็นตัวสกัดคุณลักษณะ โดยทำการคัดเลือกโครงข่ายที่มีประสิทธิภาพสูงทั้งขนาดเล็กและขนาดใหญ่ ดังตารางที่ 3.5

ตารางที่ 3.5 ตัวแบบพื้นฐานที่ใช้ในการทดลอง [92]

ตัวสกัดคุณลักษณะที่ใช้ในการทดลอง					
Model	Size (MB)	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth
VGG16	528	71.3%	90.1%	138.4M	16
ResNet50	98	74.9%	92.1%	25.6M	107
InceptionV3	92	77.9%	93.7%	23.9M	189
MobileNet	16	70.4%	89.5%	4.3M	55
Xception	88	79.0%	94.5%	22.9M	81
DenseNet201	80	77.3%	93.6%	20.2M	402
NASNetLarge	343	82.5%	96.0%	88.9M	533
MobileNetV2	14	71.3%	90.1%	3.5M	105
EfficientNetB7	256	84.3%	97.0%	66.7M	438
RegNetX064	-	-	-	-	-
RegNetY064	-	-	-	-	-
ResNetRS50	-	-	-	-	-
ConvNeXtBase	338.58	85.3%	-	88.5M	-

ทำการทดลองเพื่อสร้างตัวแบบที่เหมาะสมสำหรับปัญหาความผันแปรของรูปทรงใบ เนื่องจากโครงสร้างของแต่ละตัวแบบจะให้ประสิทธิภาพที่แตกต่างกันไปในแต่ละงาน โดยฝึกสอนโครงข่ายประสาทประดิษฐ์เชิงลึกด้วยการถ่ายโอนความรู้ทั้งวิธีการสกัดคุณลักษณะ (FEA) และการปรับแต่งตัวแบบพื้นฐาน (FTA) เพื่อเปรียบเทียบแล้วคัดเลือกโครงข่ายไปพัฒนาให้สามารถนำไปใช้งานได้มีประสิทธิภาพ

### 3.5 การประเมินผล (Evaluation)

ดำเนินการประเมินผลด้วยคอนฟิวชันเมทริกซ์ (Confusion Matrix) พร้อมทั้งคำนวณอัตราส่วนความถูกต้องในการพยากรณ์ด้วยตัวแบบกับสิ่งที่เกิดขึ้นจริง ประกอบด้วย

#### 3.5.1 คอนฟิวชันเมทริกซ์ (Confusion Matrix)

เป็นตารางแสดงประสิทธิภาพในการพยากรณ์ (Prediction) ของตัวแบบ (ตารางที่ 3.6)

- ความเป็นจริงเชิงบวก (True Positive) คือ พยากรณ์ว่าเป็นจริง (Positive Prediction) เมื่อสิ่งที่เกิดขึ้นเป็นจริง (Positive Label)

- ความเป็นจริงเชิงลบ (True Negative) คือ พยากรณ์ว่าเป็นเท็จ (Negative Prediction) เมื่อสิ่งที่เกิดขึ้นเป็นเท็จ (Negative Label)

- ความเป็นเท็จเชิงบวก (False Positive) คือ พยากรณ์ว่าเป็นจริง (Positive Prediction) เมื่อสิ่งที่เกิดขึ้นเป็นเท็จ (Negative Label)

- ความเป็นเท็จเชิงลบ (False Negative) คือ พยากรณ์ว่าเป็นเท็จ (Negative Prediction) เมื่อสิ่งที่เกิดขึ้นเป็นจริง (Positive Label)

ตารางที่ 3.6 คอนฟิวชันเมทริกซ์

	P' (Predicted)	N' (Predicted)
P (Actual)	True Positive	False Negative
N (Actual)	False Positive	True Negative

### 3.5.2 ค่าความแม่นยำ (Accuracy)

อัตราส่วนความถูกต้องของการพยากรณ์คำตอบทั้งหมดของตัวแบบเมื่อเทียบกับข้อมูลเฉลี่ย

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + True\ Negative + False\ Positive + False\ Negative} \quad (3.1)$$

### 3.5.3 ค่าความเที่ยงตรง (Precision)

อัตราส่วนของการพยากรณ์คำตอบได้ถูกต้องเมื่อเทียบกับการพยากรณ์ทั้งหมดของตัวแบบ

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (3.2)$$

### 3.5.4 ค่าการค้นพบ (Recall)

อัตราส่วนความถูกต้องของการพยากรณ์คำตอบเมื่อเทียบกับข้อมูลเฉลี่ยแต่ละกลุ่ม

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (3.3)$$

### 3.5.5 F1-Score

ค่าเฉลี่ย (Harmonic Mean) ของ Precision และ Recall

$$F1 = \frac{2 * True\ Positive}{2 * True\ Positive + False\ Positive + False\ Negative} \quad (3.4)$$

### 3.5.6 Receiver Operating Characteristic (ROC) Curve

แผนภาพแสดงความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวก (True Positive Rate : TPR) และอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบ (False Positive Rate : FPR) รวมถึงพื้นที่ใต้เส้นโค้ง (Area Under Curve : AUC) [93][94] เพื่อเปรียบเทียบประสิทธิภาพในการจำแนกข้อมูลของตัวแบบ

$$TPR (Sensitivity) = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (3.5)$$

$$FPR (1 - Specificity) = \frac{False\ Positive}{True\ Negative + False\ Positive} \quad (3.6)$$

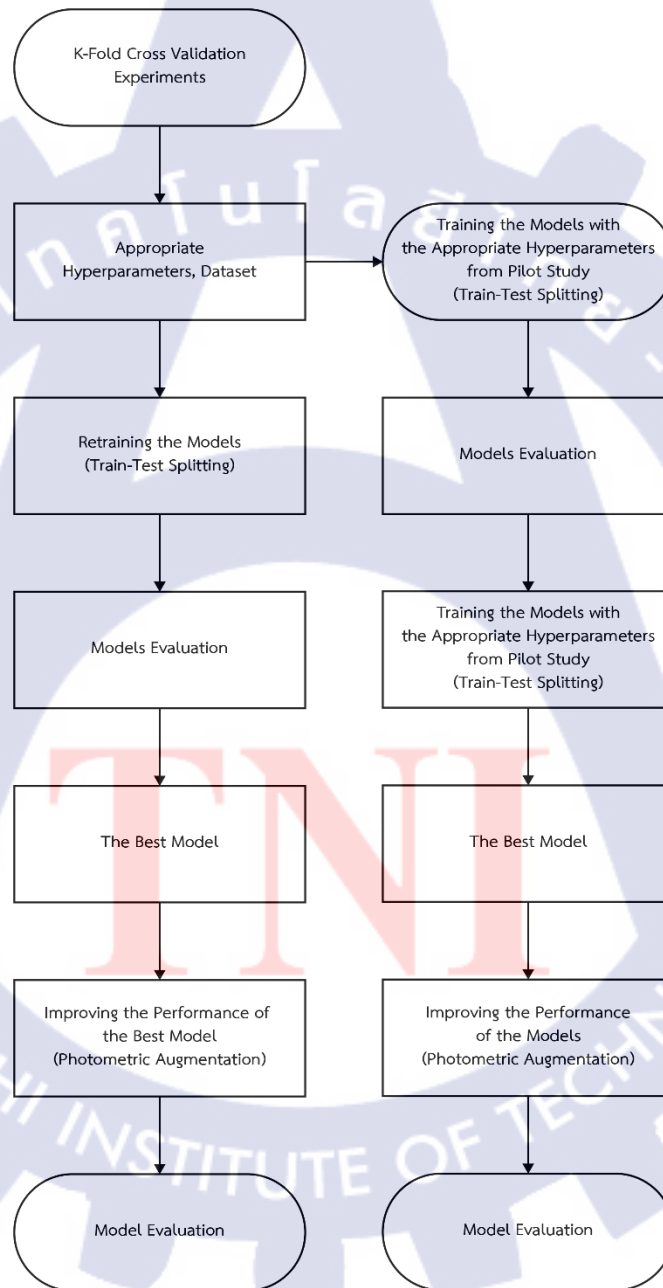
$$AUC = \frac{1}{2} \left( \left( \frac{True\ Positive}{True\ Positive + False\ Negative} \right) + \left( \frac{True\ Negative}{True\ Negative + False\ Positive} \right) \right) \quad (3.7)$$

TNII

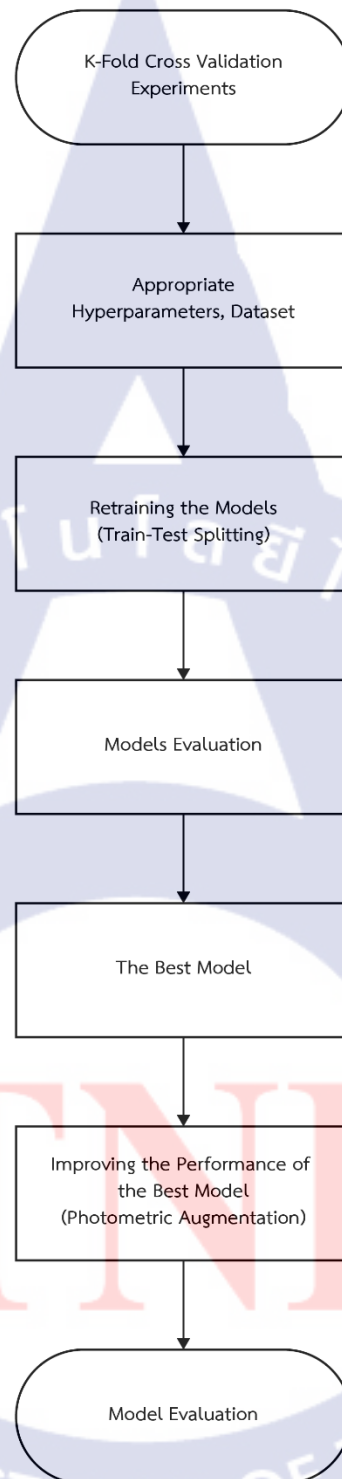
THAI - NICHI INSTITUTE OF TECHNOLOGY

### 3.6 การเตรียมการทดลอง (Experimental Setup)

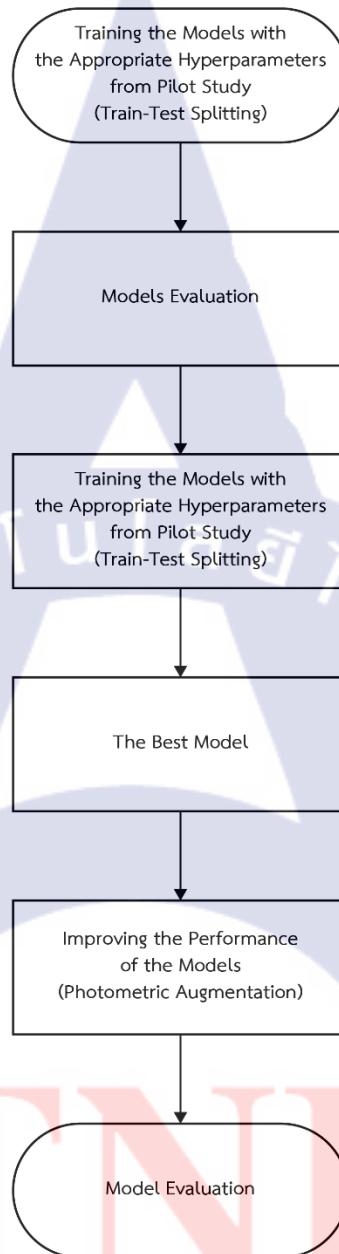
ดำเนินการเตรียมการทดลองการวิจัย (รูปที่ 3.8) ทั้งการทดลองย่อย (รูปที่ 3.9) และการทดลองหลัก (รูปที่ 3.10) โดยแบ่งออกเป็น 3 การทดลอง (ตารางที่ 3.7 และตารางที่ 3.8) สำหรับการทดลองย่อยให้ได้ขนาดชุดข้อมูลที่เหมาะสมต่อปัญหาเพื่อเป็นต้นแบบให้กับการทดลองหลัก (ตารางที่ 3.9) และลดระยะเวลาในการเก็บข้อมูล



รูปที่ 3.8 แผนภาพขั้นตอนการทดลอง



รูปที่ 3.9 แผนภาพขั้นตอนการทดลองย่อย



รูปที่ 3.10 แผนภาพขั้นตอนการทดลองหลัก

### 3.6.1 การแบ่งชุดข้อมูล (Data Splitting)

ทำการแบ่งชุดข้อมูลออกเป็น 2 ชุด ได้แก่ ข้อมูลชุดฝึกสอน (Training Set) และข้อมูลชุดทดสอบ (Testing Set) ที่อัตราส่วน 85 : 15 ดังตารางที่ 3.7 และ 3.8

ตารางที่ 3.7 การแบ่งข้อมูลชุดทดลองย่อย

ข้อมูลชุดทดลองย่อย			
การทดลอง (Experiment)	พันธุ์ (Classes)	ข้อมูลชุดฝึกสอน (Training Set)	ข้อมูลชุดทดสอบ (Testing Set)
Full (E1)	RRIM 600 Clone	12,240	2,160
	RRIM 600 Seedling	12,240	2,160
Half (E2)	RRIM 600 Clone	6,120	1,080
	RRIM 600 Seedling	6,120	1,080
Quarter (E3)	RRIM 600 Clone	3,060	540
	RRIM 600 Seedling	3,060	540

ตารางที่ 3.8 การแบ่งข้อมูลชุดทดลองย่อยสำหรับการทดลองการตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation)

ข้อมูลชุดทดลองย่อย (K-Fold Cross Validation)			
การทดลอง (Experiment)	พันธุ์ (Classes)	ข้อมูลชุดฝึกสอน (Training Set)	ข้อมูลชุดทดสอบ (Testing Set)
Full (E1)	RRIM 600 Clone	10,080	2,160
	RRIM 600 Seedling	10,080	2,160
Half (E2)	RRIM 600 Clone	5,040	1,080
	RRIM 600 Seedling	5,040	1,080
Quarter (E3)	RRIM 600 Clone	2,520	540
	RRIM 600 Seedling	2,520	540

ตารางที่ 3.9 การแบ่งข้อมูลชุดทดลองหลัก


ข้อมูลชุดทดลองหลัก			
การทดลอง (Experiment)	พันธุ์ (Classes)	ข้อมูลชุดฝึกสอน (Training Set)	ข้อมูลชุดทดสอบ (Testing Set)
Full	BPM 24	3,060	540
	PB 235	3,060	540
	RRIM 600	3,060	540
	RRIT 226	3,060	540
	RRIT 251	3,060	540
	RRIT 408	3,060	540

### 3.6.2 การออกแบบสถาปัตยกรรม (Architecture Design)

ทำการออกแบบสถาปัตยกรรมของตัวแบบ (ตารางที่ 3.10 และ 3.11) โดยกำหนดตัวจำแนกที่เหมาะสมต่อการจำแนกพันธุ์ยางพาราให้กับตัวแบบพื้นฐานเพื่อทำการทดลองฝึกสอนตัวแบบ [95]

1) ตัวสกัดคุณลักษณะ (Feature Extractor) เลือกใช้ตัวแบบ VGG16, ResNet50, InceptionV3, MobileNet, Xception, DenseNet201, NASNetLarge, MobileNetV2 EfficientnetB7, RegNetX064, RegNetY064, ResNetRS50 และ ConvNeXtBase เป็นตัวสกัดคุณลักษณะทั้งในการทดลองย่อยและการทดลองหลัก

2) ตัวจำแนก (Classifier) ทำการสร้างตัวจำแนกที่เหมาะสมต่อการจำแนกพันธุ์ยางพารา โดยควบคุมข้อมูลให้อยู่ในรูปแบบปกติ (Regularization) ด้วยการกำหนดชั้นปรับความเหมาะสมของชุดข้อมูลนำเข้า (Batch Normalization) เพื่อให้สามารถทำการฝึกสอนตัวแบบได้เร็วยิ่งขึ้นโดยปรับข้อมูล (Normalize) นำออกจากชั้นก่อนหน้าให้มีค่าใกล้เคียงกัน ทำให้การปรับน้ำหนัก (Weight) ของตัวแบบลดความแปรปรวนลงขณะฝึกสอนด้วยข้อมูลแต่ละชุด (Batch) ซึ่งช่วยให้ตัวแบบสามารถเรียนรู้สู่ค่าที่เหมาะสมได้เร็วยิ่งขึ้น [96] กำหนดชั้นปรับลดเซลล์ประสาทประดิษฐ์ (Dropout) ให้ตัวแบบมีความฉลาดลดลง (รูปที่ 3.11) เพื่อแก้ปัญหาตัวแบบที่มีความแม่นยำกับข้อมูลฝึกสอนมากเกินไป (Overfitting) [97] จนไม่สามารถนำไปใช้งานกับข้อมูลที่ตัวแบบไม่เคยเห็นมาก่อนได้อย่างมีประสิทธิภาพ และกำหนดชั้นเชื่อมโยงสมบูรณ์ (Dense) ให้มีการส่งผลลัพธ์ตามจำนวนสายพันธุ์ยางพาราที่ต้องการจำแนก

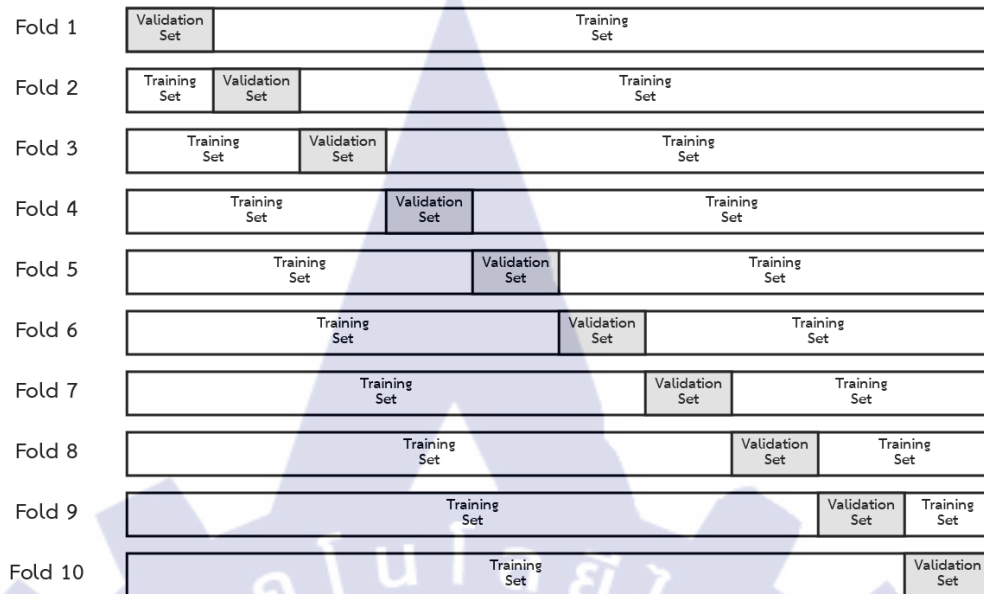


รูปที่ 3.11 การปรับลดเซลล์ประสาทประดิษฐ์

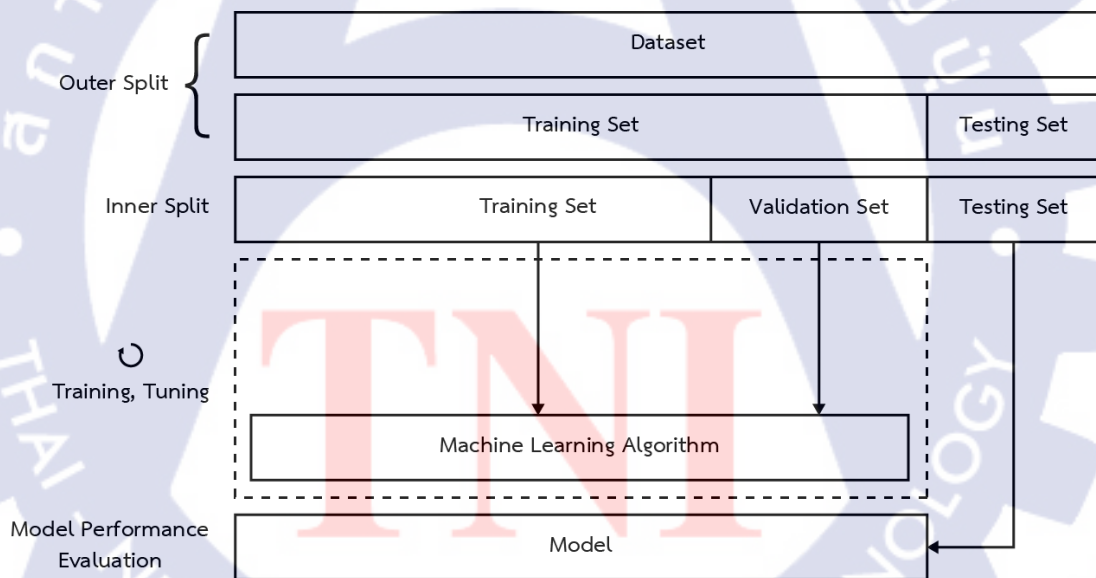
เลือกใช้ฟังก์ชันกระตุ้น ReLU (Rectified Linear Units) เนื่องจากเป็นฟังก์ชันที่มีประสิทธิภาพสูงในการลดความผิดพลาด (Loss) ในการฝึกสอนตัวแบบ [98][99] และสามารถปรับใช้กับโครงข่ายประสาทประดิษฐ์ได้หลากหลาย ใช้ฟังก์ชันกระตุ้น Sigmoid ในชั้นนำออกข้อมูล เพื่อปรับช่วงข้อมูล (Normalize) ให้มีค่าอยู่ในช่วงระหว่าง 0-1 แล้วกำหนดเกณฑ์ (Threshold) ที่ 0.5 สำหรับการจำแนกข้อมูล 2 กลุ่ม (Binary Classification) สำหรับการทดลองย่อย แล้วเปลี่ยนฟังก์ชันกระตุ้นในชั้นนำออกข้อมูลเป็น Softmax เพื่อปรับช่วงข้อมูลให้มีค่า 0-5 สำหรับการจำแนกข้อมูล 6 กลุ่ม (Multiclass Classification) ตามจำนวนสายพันธุ์ยุงพาราสำหรับการทดลองหลัก

### 3.6.3 การตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation)

ทำการตรวจสอบความถูกต้องแบบไขว้ซึ่งเป็นรูปแบบการฝึกสอนตัวแบบจำนวน K รอบ ด้วยการสุ่มแบ่งข้อมูลออกเป็น ส่วน (Fold) เท่า ๆ กัน โดยกำหนดจำนวน K เท่ากับ 10 (รูปที่ 3.12) เพื่อทำการฝึกสอน (Training) และตรวจสอบความถูกต้อง (Validation) ในการเรียนรู้ของตัวแบบให้มีการปรับปรุงประสิทธิภาพในการเรียนรู้ [100] และแก้ปัญหาตัวแบบมีความแม่นยำกับข้อมูลที่ฝึกสอนมากเกินไป (Overfitting) โดยจะทำการตรวจสอบตัวแบบจนกว่าข้อมูลทุกส่วนจะถูกนำมาใช้ ทำการบันทึกค่าความแม่นยำและความผิดพลาดของตัวแบบในแต่ละรอบแล้วคำนวณหาค่าเฉลี่ย ก่อนที่จะนำตัวแบบไปทำการทดสอบ (Testing) กับข้อมูลชุดทดสอบ ดังรูปที่ 3.13



รูปที่ 3.12 การแบ่งชุดข้อมูลตรวจสอบความถูกต้องแบบไขว้



รูปที่ 3.13 การตรวจสอบความถูกต้องแบบไขว้ (K-Fold Cross Validation)

### 3.6.4 ไฮเปอร์พารามิเตอร์ (Hyperparameter)

กำหนดไฮเปอร์พารามิเตอร์ก่อนทำการฝึกสอนตัวแบบ (ตารางที่ 3.10, 3.11) โดยปรับลดข้อมูลนำเข้าให้มีขนาดเล็กเพื่อให้ตัวแบบสามารถเรียนรู้ได้รวดเร็วยิ่งขึ้น แล้วนำเข้าชุดข้อมูลครั้งละ 32 ภาพ โดยกำหนดตัวปรับแต่ง (Optimizer) Adam (Adaptive Momentum Estimation), Nadam (Nesterov Accelerated Adaptive Momentum Estimation) และ RMSProp (Root Mean Square Propagation) สำหรับการฝึกสอนด้วยชุดข้อมูลขนาดใหญ่กับโครงข่ายประสาทประดิษฐ์เชิงลึก [101][102] ด้วยอัตราการเรียนรู้ (Learning Rate) ที่ 0.0001 เนื่องจากเป็นอัตราการเรียนรู้ที่มีประสิทธิภาพสูง [103] ซึ่งจะช่วยให้ตัวแบบสามารถเรียนรู้สู่ค่าที่เหมาะสมได้ดียิ่งขึ้น พร้อมทั้งกำหนดความอดทนในการเรียนรู้ (Patience) ที่ 10 รอบ เมื่อตัวแบบมีความแม่นยำสูงสุดแล้วไม่สามารถเรียนรู้ได้ดีกว่าเดิมจะหยุดการเรียนรู้ทันที (Early Stopping) เพื่อป้องกันปัญหาตัวแบบมีความแม่นยำกับข้อมูลที่ฝึกสอนมากเกินไป



ตารางที่ 3.10 สถาปัตยกรรมของตัวแบบและไฮเปอร์พารามิเตอร์สำหรับการทดลองย่อย

Hyperparameters	Setting					
	S1	S2	S3	S4	S5	S6
Input Shape	64 x 64					
	71 x 71 (InceptionV3)					
	75 x 75 (Xception)					
Batch Size	32					
Optimizer	Adam		Nadam		RMSProp	
Learning Rate	0.0001					
Patience (Early Stopping)	10					
<b>Model Architecture</b>						
Feature Extractors	Type			Structure		
	VGG16, ResNet50, InceptionV3, MobileNet, Xception, Pre-trained DenseNet201, NASNetLarge, MobileNetV2, EfficientNetB7, RegNetX064, RegNetY064, ResNetRS50, ConvNeXtBase					
Classifier	Flatten					
	512		1024		512	
	256		512		256	
	Dense		256		256	
	ReLU					
BatchNormalization						
Dropout (0.5)						
Dense		1		Sigmoid		

ตารางที่ 3.11 สถาปัตยกรรมของตัวแบบและไฮเปอร์พารามิเตอร์สำหรับการทดลองหลัก

Hyperparameters	Value	
Input Shape	64 x 64 71 x 71 (InceptionV3) 75 x 75 (Xception)	
Batch Size	32	
Optimizer	Adam	
Learning Rate	0.0001	
Patience (Early Stopping)	10	
Model Architecture		
	Type	Structure
Feature Extractors	Pre-trained	VGG16, ResNet50, InceptionV3, MobileNet, Xception, DenseNet201, NASNetLarge, MobileNetV2, EfficientNetB7, RegNetX064, RegNetY064, ResNetRS50, ConvNeXtBase
		Flatten
Classifier		512
	Dense	256
		ReLU
		BatchNormalization
	Dropout (0.5)	
	Dense	6
		Softmax

## บทที่ 4

### ผลการวิเคราะห์ข้อมูล

#### 4.1 ผลการทดลองย่อย (Pilot Study)

การทดลองย่อยการพัฒนาตัวแบบจำแนกพันธุ์ยางพารา ประกอบด้วย การฝึกสอนตัวแบบด้วยการตรวจสอบความถูกต้องแบบไขว้เพื่อหาไฮเปอร์พารามิเตอร์และขนาดชุดข้อมูลที่เหมาะสม และการฝึกสอนเพื่อหาตัวแบบที่เหมาะสม พบว่า ตัวแบบที่ได้รับการฝึกสอนด้วยไฮเปอร์พารามิเตอร์แบบ S2 (ตารางที่ 4.1) มีความแม่นยำเฉลี่ยสูงสุด 96.12% ใช้ระยะเวลาในการฝึกสอน 126 ชั่วโมง 21 นาที 35 วินาที ในการทดลองขนาดชุดข้อมูล E1 ในขณะที่ตัวแบบที่ได้รับการฝึกสอนในการทดลองขนาดชุดข้อมูล E2 และ E3 ด้วยไฮเปอร์พารามิเตอร์แบบ S1 (ตารางที่ 4.2 และ 4.3) มีความแม่นยำเฉลี่ยสูงสุด 93.76% ใช้ระยะเวลาในการฝึกสอน 32 ชั่วโมง 42 นาที 40 วินาที และ 95.06% ใช้ระยะเวลาในการฝึกสอน 15 ชั่วโมง 14 นาที 24 วินาที ตามลำดับ

ตารางที่ 4.1 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E1

Setting	E1		Average Training Time (hh:mm:ss)
	Average Accuracy	Average Loss	
S1	0.9565	0.3164	65:15:09
S2	<b>0.9612</b>	<b>0.2633</b>	<b>126:21:35</b>
S3	0.9512	0.2973	82:32:31
S4	0.9499	0.4006	117:47:39
S5	0.9464	0.3593	49:41:42
S6	0.9482	0.5332	99:01:12

ตารางที่ 4.2 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E2

ผลการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E2			
Setting	E2		
	Average Accuracy	Average Loss	Average Training Time (hh:mm:ss)
S1	0.9376	0.3822	32:42:40
S2	0.9370	0.5623	63:14:12
S3	0.9337	0.6856	39:25:20
S4	0.9292	0.5298	83:18:13
S5	0.9313	0.7145	23:13:32
S6	0.9280	0.6981	49:38:21

ตารางที่ 4.3 ผลการทดลองการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E3

ผลการตรวจสอบความถูกต้องแบบไขว้บนชุดข้อมูลขนาด E3			
Setting	E3		
	Average Accuracy	Average Loss	Average Training Time (hh:mm:ss)
S1	0.9506	0.3457	15:14:24
S2	0.9471	0.3509	30:36:48
S3	0.9518	0.2619	19:51:04
S4	0.9439	0.6609	40:32:32
S5	0.9415	0.5272	11:43:37
S6	0.9387	0.8778	23:49:10

เมื่อพิจารณาจากข้อแลกเปลี่ยนระหว่างความแม่นยำและระยะเวลาที่ใช้ในการฝึกสอนของตัวแบบจะเห็นได้ว่าตัวแบบที่ได้รับการฝึกสอนด้วยไฮเปอร์พารามิเตอร์แบบ S1 ในการทดลองขนาดชุดข้อมูล E2 และ E3 จะทำให้ได้ตัวแบบที่มีความแม่นยำสูงภายในระยะเวลาที่จำกัด ดังนั้นตัวแบบทุกตัวจึงได้รับการตั้งค่าไฮเปอร์พารามิเตอร์บนพื้นฐานของผลการทดลองนี้ในการฝึกสอนเพื่อหาตัวแบบที่เหมาะสม


การฝึกสอนเพื่อหาตัวแบบที่เหมาะสมด้วยไฮเปอร์พารามิเตอร์ที่ดีที่สุด (S1) ด้วยชุดข้อมูลขนาด E2 พบว่า ตัวแบบที่อาศัยสถาปัตยกรรม MobileNetV2 มีความแม่นยำสูงสุด 89.12% ใช้ระยะเวลาในการฝึกสอน 21 นาที 4 วินาที รองลงมา คือ ConvNeXtBase และ DenseNet201 ที่ความแม่นยำ 87.96% และ 87.82% ใช้ระยะเวลาในการฝึกสอน 55 นาที 22 วินาที และ 21 นาที 46 วินาที ตามลำดับ โดยตัวแบบ NASNetLarge มีความแม่นยำต่ำสุดที่ 80.05% ใช้ระยะเวลาในการฝึกสอน 57 นาที 22 วินาที ดังตารางที่ 4.4 โดยมีพฤติกรรมการเรียนรู้และความสามารถในการระบุสายพันธุ์ ดังตารางที่ 4.5

ตารางที่ 4.4 ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2


ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2 (Retrained with S1 on E2)						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
VGG16	0.8648	0.8286	0.8862	0.8648	0.8754	00:08:29
ResNet50	0.8745	0.7093	0.8885	0.8745	0.8814	00:22:02
InceptionV3	0.8495	0.8782	0.8596	0.8495	0.8545	00:06:07
MobileNet	0.8745	0.7804	0.8949	0.8745	0.8846	00:13:06
Xception	0.8287	0.9201	0.8626	0.8287	0.8453	00:33:55
DenseNet201	0.8782	0.6825	0.8844	0.8782	0.8813	00:21:46
NASNetLarge	0.8005	0.7999	0.8031	0.8005	0.8018	00:57:22
MobileNetV2	<b>0.8912</b>	<b>0.7173</b>	<b>0.8963</b>	<b>0.8912</b>	<b>0.8937</b>	<b>00:21:04</b>
EfficientNetB7	0.8333	0.6107	0.8641	0.8333	0.8484	00:38:52
RegNetX064	0.8287	0.9860	0.8570	0.8287	0.8426	00:18:35
RegNetY064	0.8333	0.8914	0.8457	0.8333	0.8395	00:16:10
ResNetRS50	0.8708	0.8478	0.8924	0.8708	0.8815	00:24:01
ConvNeXtBase	0.8796	0.6632	0.8934	0.8796	0.8864	00:55:22

ตารางที่ 4.5 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2


VGG16




ResNet50




InceptionV3



MobileNet




Xception




ตารางที่ 4.5 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2 (ต่อ)


### DenseNet201




### NASNetLarge



### MobileNetV2




### EfficientNetB7




ตารางที่ 4.5 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E2 (ต่อ)


RegNetX064




RegNetY064



ResNetRS50



ConvNeXtBase

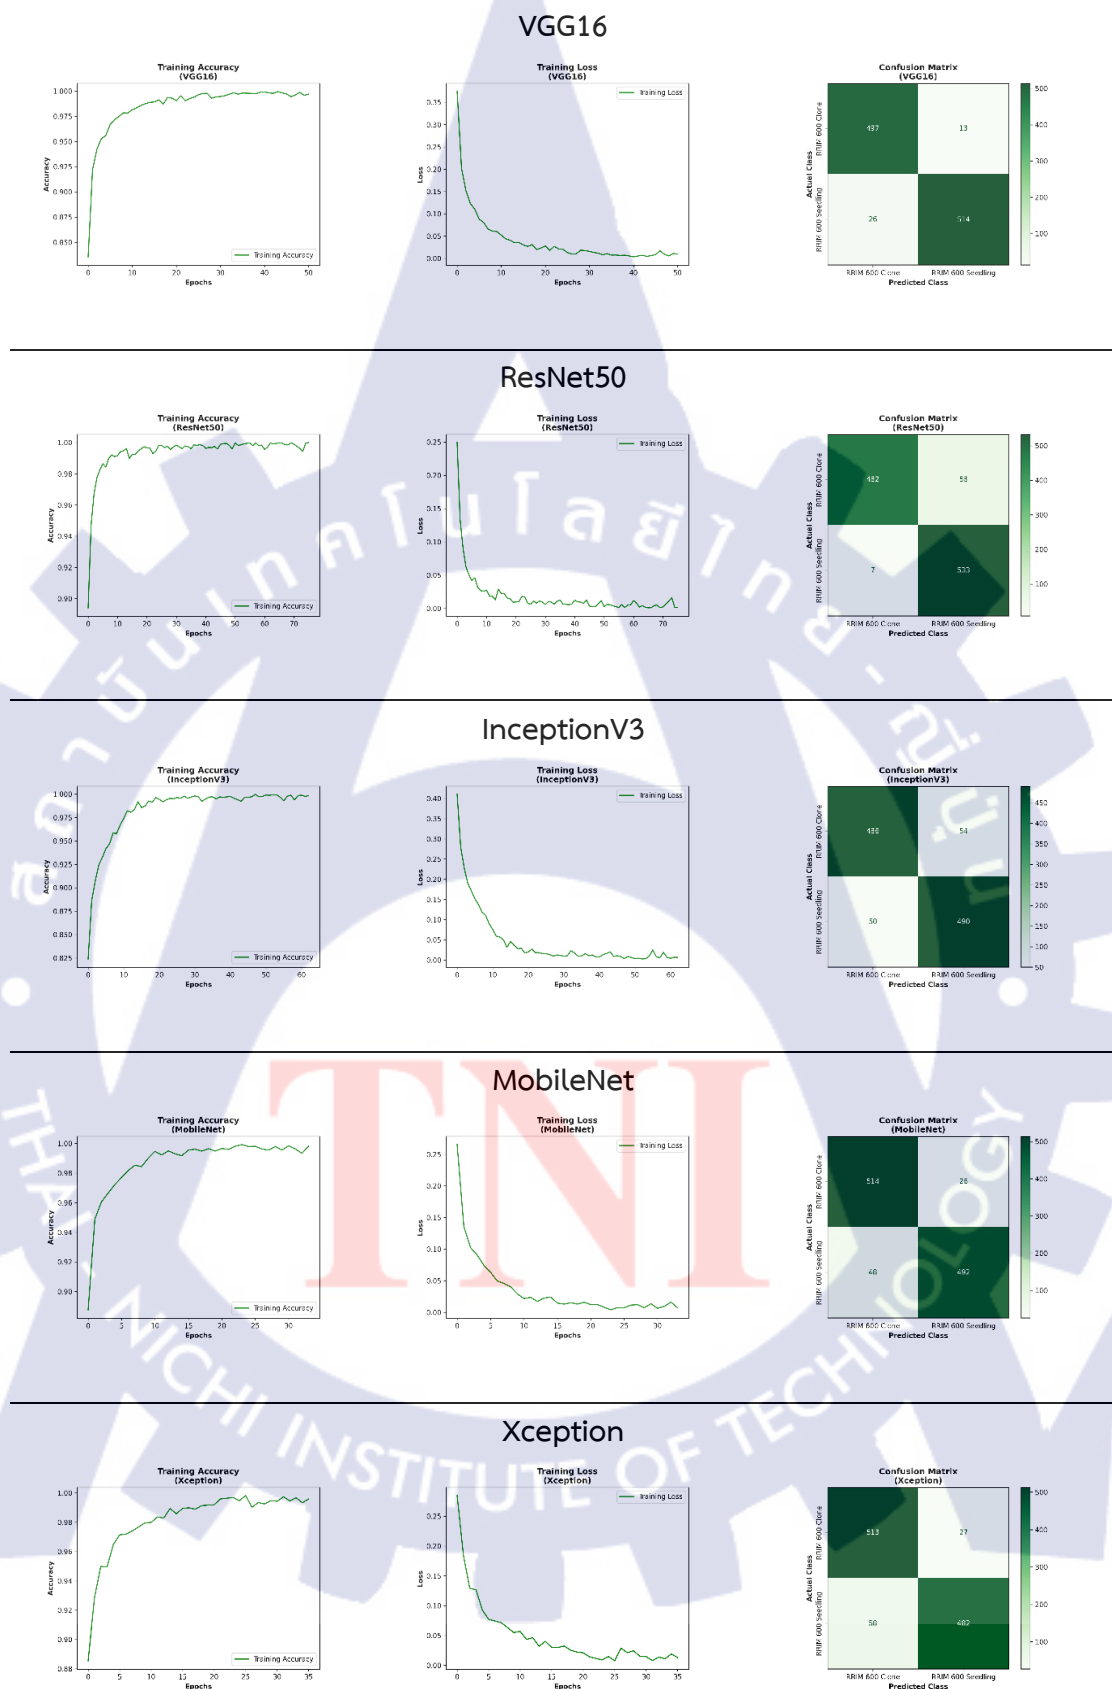


การฝึกสอนตัวแบบเพื่อหาตัวแบบที่เหมาะสมด้วยไฮเปอร์พารามิเตอร์ที่ดีที่สุด (S1) ด้วยชุดข้อมูลขนาด E3 พบว่า ตัวแบบที่อาศัยสถาปัตยกรรม ConvNeXtBase มีความแม่นยำสูงสุด 98.61% ใช้ระยะเวลาในการฝึกสอน 27 นาที 57 วินาที รองลงมา คือ RegNetY064 และ ResNetRS50 ที่ความแม่นยำ 95.83% และ 94.91% ใช้ระยะเวลาในการฝึกสอน 6 นาที 54 วินาที เท่ากัน โดยตัวแบบ EfficientNetB7 มีความแม่นยำต่ำสุดที่ 60.74% ใช้ระยะเวลาในการฝึกสอน 17 นาที 41 วินาที ดังตารางที่ 4.6 โดยมีพฤติกรรมการเรียนรู้และความสามารถในการระบุสายพันธุ์ ดังตารางที่ 4.7

ตารางที่ 4.6 ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3


ผลการฝึกสอนตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3 (Retrained with S1 on E3)						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
VGG16	0.9361	0.2271	0.9365	0.9361	0.9363	00:03:18
ResNet50	0.9398	0.2486	0.9438	0.9398	0.9418	00:13:14
InceptionV3	0.9037	0.4736	0.9037	0.9037	0.9037	00:03:30
MobileNet	0.9315	0.2330	0.9322	0.9315	0.9319	00:03:14
Xception	0.9213	0.2901	0.9227	0.9213	0.9220	00:13:32
DenseNet201	0.9296	0.3406	0.9298	0.9296	0.9297	00:10:05
NASNetLarge	0.8231	0.6686	0.8276	0.8231	0.8253	00:30:02
MobileNetV2	0.9204	0.3000	0.9206	0.9204	0.9205	00:04:53
EfficientNetB7	0.6074	2.6170	0.7801	0.6074	0.6830	00:17:41
RegNetX064	0.8685	0.4488	0.8919	0.8685	0.8800	00:08:25
RegNetY064	0.9583	0.1863	0.9588	0.9583	0.9586	00:06:54
ResNetRS50	0.9491	0.1869	0.9491	0.9491	0.9491	00:06:54
ConvNeXtBase	<b>0.9861</b>	<b>0.0416</b>	<b>0.9862</b>	<b>0.9861</b>	<b>0.9862</b>	<b>00:27:57</b>

ตารางที่ 4.7 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3




ตารางที่ 4.7 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3 (ต่อ)


### DenseNet201




### NASNetLarge



### MobileNetV2




### EfficientNetB7




ตารางที่ 4.7 การเรียนรู้และคอนฟิวชันเมทริกซ์ของตัวแบบการทดลองย่อยบนชุดข้อมูลขนาด E3 (ต่อ)


### RegNetX064




### RegNetY064



### ResNetRS50



### ConvNeXtBase




ตัวแบบทั้งหมดที่ได้รับการฝึกสอนสามารถเรียนรู้จากชุดข้อมูลขนาด E3 ได้ดีกว่า E2 โดยตัวแบบที่อาศัยสถาปัตยกรรมที่เรียบง่ายแบบ VGG16 เป็นตัวสกัดคุณลักษณะสามารถเรียนรู้เพื่อหาความสัมพันธ์จากชุดข้อมูลได้มีประสิทธิภาพเทียบเท่าและเหนือกว่าตัวแบบที่อาศัยสถาปัตยกรรมที่มีความซับซ้อนบางตัวแบบภายใต้ระยะเวลาในการฝึกสอนที่จำกัด

เมื่อปริมาณชุดข้อมูลที่ใช้ในการฝึกสอนอยู่ในระดับที่เพียงพอตัวแบบที่อาศัยสถาปัตยกรรม ConvNeXtBase จะมีความแม่นยำสูงสุดและมีประสิทธิภาพเหนือกว่าตัวแบบอื่น ๆ อย่างมีนัยสำคัญ โดยตัวแบบ NASNetLarge ใช้ระยะเวลาในการฝึกสอนมากที่สุดทั้งบนชุดข้อมูลขนาด E2 และ E3 ในขณะที่ MobileNet และ MobileNetV2 ให้ประสิทธิภาพที่น่าพึงพอใจภายในระยะเวลาการฝึกสอนที่จำกัดเมื่อเทียบกับตัวแบบอื่น ๆ

ตัวแบบส่วนใหญ่สามารถเรียนรู้การจำแนกพันธุ์อย่างพาราระหว่างต้นพันธุ์จากการติดตาม (Clone) และต้นพันธุ์จากการเพาะเมล็ด (Seedling) ได้ โดยประสิทธิภาพจะแตกต่างกันไปขึ้นอยู่กับสถาปัตยกรรมของตัวสกัดคุณลักษณะ ในแต่ละการทดลองประสิทธิภาพของตัวแบบจะลดหลั่นลงเล็กน้อยจากตัวแบบที่มีประสิทธิภาพสูงสุดในทางกลับกันตัวแบบที่อาศัยสถาปัตยกรรม NASNetLarge และ EfficientNetB7 จะให้ประสิทธิภาพที่ค่อนข้างต่ำ ความแม่นยำของตัวแบบลดลงอย่างมากในบางการทดลอง แสดงให้เห็นว่าทั้งสองตัวแบบเรียนรู้การจำแนกพันธุ์จากพาราลักษณะไปได้ไม่ดีเท่าตัวแบบอื่น ๆ

แผนภาพแสดงความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบ (รูปที่ 4.1) ของตัวแบบที่ได้รับการฝึกสอนด้วยชุดข้อมูลขนาด E2 แสดงให้เห็นว่าตัวแบบ ConvNeXtBase มีค่า AUROC สูงสุด 0.9762 รองลงมา คือ VGG16 และ MobileNetV2 ที่ 0.9726 และ 0.9704 ตามลำดับ โดย NASNetLarge มีค่า AUROC ต่ำสุดที่ 0.8815 ตัวแบบที่ได้รับการฝึกสอนด้วยชุดข้อมูลขนาด E3 ก็ยังแสดงให้เห็นว่า ConvNeXtBase มีประสิทธิภาพในการจำแนกข้อมูลเหนือกว่าตัวแบบอื่น ๆ มีค่า AUROC 0.9993 รองลงมา คือ ResNet50 และ RegNetY064 ที่ 0.9927 และ 0.9923 ตามลำดับ โดย NASNetLarge มีค่า AUROC ต่ำสุดที่ 0.8992 เส้นกราฟของ ConvNeXtBase เข้าใกล้มุมบนซ้ายและมีพื้นที่ใต้เส้นโค้งมากที่สุด



รูปที่ 4.1 แผนภาพการจำแนกข้อมูลที่ค่าเกณฑ์ (Threshold) ที่แตกต่างกัน

ตัวแบบที่อาศัยสถาปัตยกรรม ConvNeXtBase เป็นตัวสกัดคุณลักษณะจะใช้ระยะเวลาในการฝึกสอนนานกว่าตัวแบบอื่น ๆ ถึงแม้ว่า ConvNeXtBase จะไม่ได้มีความแม่นยำสูงสุดบนชุดข้อมูลขนาด E2 แต่สามารถจำแนกข้อมูลได้ดีกว่าตัวแบบอื่น ๆ ที่ค่าเกณฑ์ที่แตกต่างกันทั้งสองขนาดชุดข้อมูล ด้วยเหตุนี้ ConvNeXtBase จึงถูกเลือกนำไปฝึกสอนเพิ่มประสิทธิภาพด้วยชุดข้อมูลที่มีปริมาณและความซับซ้อนมากยิ่งขึ้นด้วยการเสริมข้อมูลเชิงคุณสมบัติของรูปด้วยการสร้างสัญญาณรบกวนและการบิดเบี้ยวของเลนส์กล้อง ดังตารางที่ 4.8

ตารางที่ 4.8 การแบ่งข้อมูลชุดเพิ่มประสิทธิภาพการทดลองย่อย


		ชุดข้อมูลเพิ่มประสิทธิภาพการทดลองย่อย			
Experiment	Classes	Training Set		Testing Set	
		Original + Geometric Augmented	Photometric Augmented	Original + Geometric Augmented	Photometric Augmented
Half (E2)	RRIM 600	6,120	1,530	1,080	270
	Clone	6,120	1,530	1,080	270
Quarter (E3)	RRIM 600	3,060	3,060	540	540
	Clone	3,060	3,060	540	540
	RRIM 600	3,060	3,060	540	540
	Seedling	3,060	3,060	540	540

หลังจากการฝึกสอนเพื่อเพิ่มประสิทธิภาพด้วยชุดข้อมูลขนาด E2 (ตารางที่ 4.9) พบว่า ความแม่นยำของตัวแบบ ConvNeXtBase เพิ่มขึ้นจาก 87.96% เป็น 89.19% และความผิดพลาดของตัวแบบลดลงจาก 0.6632 เป็น 0.4941 ใช้ระยะเวลาในการฝึกสอน 1 ชั่วโมง 10 นาที 15 วินาที

ตารางที่ 4.9 ผลการเพิ่มประสิทธิภาพตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลขนาด E2

ผลการเพิ่มประสิทธิภาพตัวแบบ ConvNeXtBase (Improved Retrained with S1 on E2)						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
ConvNeXtBase	0.8919	0.4941	0.9058	0.8919	0.8988	01:10:15

แผนภาพการเรียนรู้ (Learning Curve) (รูปที่ 4.2) แสดงให้เห็นว่าตัวแบบสามารถเรียนรู้ชุดข้อมูลที่มีความซับซ้อนมากยิ่งขึ้นได้ดี ความแม่นยำในการเรียนรู้เพิ่มขึ้นอย่างต่อเนื่องและสิ้นสุดด้วยความเสถียร (Convergence Area) โดย ConvNeXtBase สามารถเรียนรู้ได้อย่างเป็นปกติ (Generalization) มากกว่าตัวแบบอื่น ค่าความแม่นยำในการฝึกสอน (Training Accuracy) เพิ่มขึ้นเข้าใกล้ 1.00 โดยมีความแปรปรวน (Wavy) เล็กน้อย สอดคล้องกับค่าความผิดพลาดในการฝึกสอน (Training Loss) ที่ลดลงเข้าใกล้ 0.00 ด้วยความแปรปรวนเล็กน้อยเช่นเดียวกัน




รูปที่ 4.2 การเรียนรู้ของตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลเพิ่มประสิทธิภาพขนาด E2

การฝึกสอนเพื่อเพิ่มประสิทธิภาพด้วยชุดข้อมูลขนาด E3 (ตารางที่ 4.10) พบว่า ความแม่นยำของตัวแบบลดลงเล็กน้อยจาก 98.61% เป็น 97.82% และความผิดพลาดของตัวแบบเพิ่มขึ้นเล็กน้อยจาก 0.0416 เป็น 0.0950 ใช้ระยะเวลาในการฝึกสอน 54 นาที 20 วินาที เนื่องจากการเสริมข้อมูลเชิงคุณสมบัติของรูปส่งผลให้ปริมาณข้อมูลเพิ่มมากขึ้นและมีความซับซ้อนมากยิ่งขึ้นตามไปด้วย

ตารางที่ 4.10 ผลการเพิ่มประสิทธิภาพตัวแบบด้วยชุดข้อมูลขนาด E3


ผลการเพิ่มประสิทธิภาพตัวแบบ ConvNeXtBase (Improved Retrained with S1 on E3)						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
ConvNeXtBase	0.9782	0.0950	0.9786	0.9782	0.9784	00:54:20

แผนภาพการเรียนรู้ (รูปที่ 4.3) แสดงให้เห็นว่าตัวแบบสามารถเรียนรู้ได้ดีใกล้เคียงกับการเพิ่มประสิทธิภาพด้วยชุดข้อมูลขนาด E2 แต่ใช้จำนวนรอบ (Epochs) ในการฝึกสอนที่มากกว่า



รูปที่ 4.3 การเรียนรู้ของตัวแบบ ConvNeXtBase ด้วยชุดข้อมูลเพิ่มประสิทธิภาพขนาด E3

แผนภาพคอนฟิวชันเมทริกซ์ (รูปที่ 4.4) แสดงให้เห็นอย่างชัดเจนว่าตัวแบบสามารถระบุต้นพันธุ์จากการติดตามและต้นพันธุ์จากการเพาะเมล็ด ได้ถูกต้องเป็นส่วนใหญ่ ประสิทธิภาพของ ConvNeXtBase ที่ได้รับการฝึกสอนด้วยชุดข้อมูลขนาด E3 หลังจากที่ได้เพิ่มประสิทธิภาพแล้วมีความสามารถสูงกว่า ConvNeXtBase ที่ได้รับการฝึกสอนด้วยชุดข้อมูลขนาด E2 แต่การระบุสายพันธุ์จากภาพใบยางพาราของต้นพันธุ์จากการเพาะเมล็ด จะมีความผิดพลาดมากกว่าการระบุสายพันธุ์จากภาพใบยางพาราของต้นพันธุ์จากการติดตาม เนื่องจากลักษณะใบของต้นพันธุ์จากการเพาะเมล็ดมีความหลากหลายมากกว่า ซึ่งส่วนหนึ่งจะมีความใกล้เคียงกับต้นพันธุ์จากการติดตามมาก



รูปที่ 4.4 แผนภาพคอนฟิวชันเมทริกซ์ของตัวแบบ ConvNeXtBase ที่ผ่านการเพิ่มประสิทธิภาพด้วยชุดข้อมูลขนาด E2 (ซ้าย) และชุดข้อมูลขนาด E3 (ขวา)

## 4.2 ผลการทดลองหลัก (Full Research)


ผลการฝึกสอนตัวแบบในการทดลองหลัก (ตารางที่ 4.11) พบว่า ตัวแบบที่อาศัยสถาปัตยกรรม ResNetRS50 เป็นตัวสกัดคุณลักษณะ มีความแม่นยำสูงสุด 84.57% ใช้ระยะเวลาในการฝึกสอน 44 นาที 50 วินาที รองลงมา คือ DenseNet201 และ ConvNeXtBase มีความแม่นยำ 83.52% และ 82.19% ใช้ระยะเวลาในการฝึกสอน 34 นาที 2 วินาที และ 1 ชั่วโมง 23 นาที 38 วินาที ตามลำดับ โดยมีพฤติกรรมการเรียนรู้และความสามารถในการระบุสายพันธุ์ ดังตารางที่ 4.12 แล้วทำการเสริมข้อมูลเพื่อเพิ่มประสิทธิภาพด้วยการมัวภาพแบบเกาส์เซียน (Gaussian Blur) การสร้างสัญญาณรบกวน (Noise) และการบิดเบี้ยวของเลนส์กล้อง (Radial Distortion) ดังตารางที่ 4.13

ตารางที่ 4.11 ผลการฝึกสอนตัวแบบการทดลองหลัก


ผลการฝึกสอนตัวแบบการทดลองหลัก						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
VGG16	0.7642	1.5099	0.7678	0.7642	0.7660	00:21:00
ResNet50	0.8093	1.2207	0.8202	0.8093	0.8147	00:44:34
InceptionV3	0.7136	2.0116	0.7103	0.7136	0.7119	00:14:23
MobileNet	0.7475	1.8523	0.7516	0.7475	0.7495	00:26:48
Xception	0.7568	1.6288	0.7648	0.7568	0.7608	01:40:48
DenseNet201	<b>0.8352</b>	<b>0.8590</b>	<b>0.8372</b>	<b>0.8352</b>	<b>0.8362</b>	<b>00:34:02</b>
NASNetLarge	0.5790	3.0582	0.5748	0.5790	0.5769	01:42:30
MobileNetV2	0.7497	1.8436	0.7516	0.7497	0.7506	00:28:36
EfficientNetB7	0.4367	6.0786	0.5766	0.4367	0.4970	01:10:38
RegNetX064	0.7759	1.4388	0.8174	0.7759	0.7961	00:40:53
RegNetY064	0.7975	1.2534	0.8092	0.7975	0.8033	00:26:42
ResNetRS50	<b>0.8457</b>	<b>1.0433</b>	<b>0.8480</b>	<b>0.8457</b>	<b>0.8468</b>	<b>00:44:50</b>
ConvNeXtBase	0.8219	0.9258	0.8458	0.8219	0.8337	01:23:38

ตารางที่ 4.12 การเรียนรู้และคอนฟิวชันเมตริกซ์ของตัวแบบการทดลองหลัก

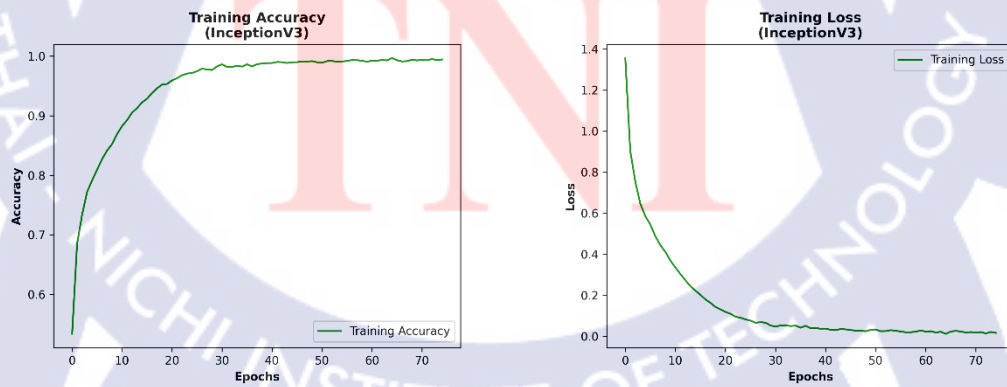
### VGG16



### ResNet50




### InceptionV3

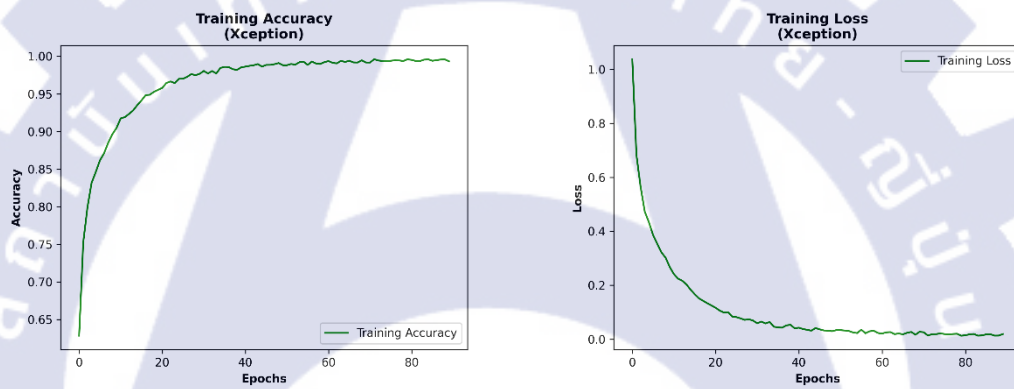


ตารางที่ 4.12 การเรียนรู้และคอนฟิวซ์ชั้นเมตริกซ์ของตัวแบบการทดลองหลัก (ต่อ)


### MobileNet



### Xception




### DenseNet201




ตารางที่ 4.12 การเรียนรู้และคอนฟิวซ์ชั้นเมตริกซ์ของตัวแบบการทดลองหลัก (ต่อ)


### NASNetLarge



### MobileNetV2

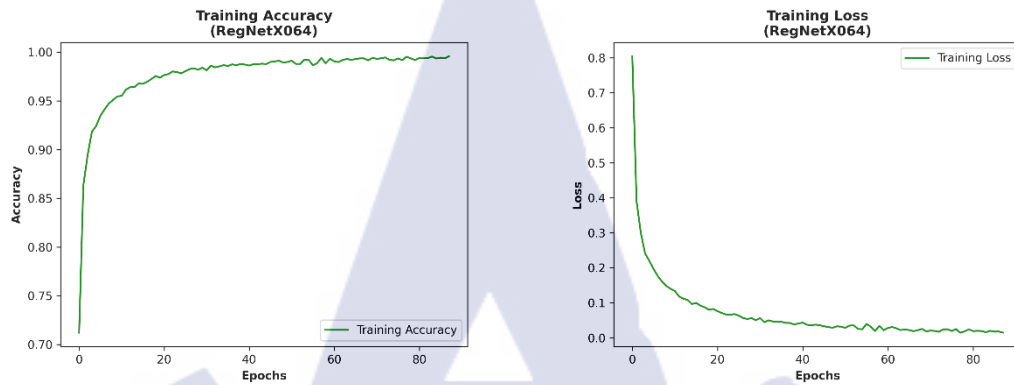


### EfficientNetB7

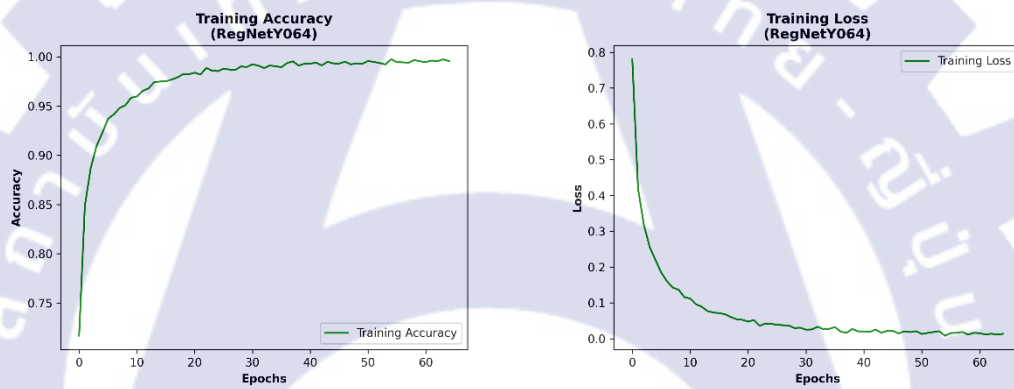


ตารางที่ 4.12 การเรียนรู้และคอนฟิวซ์ชั้นเมตริกซ์ของตัวแบบการทดลองหลัก (ต่อ)


### RegNetX064




### RegNetY064



### ResNetRS50



ตารางที่ 4.12 การเรียนรู้และคอนฟิวชันเมตริกซ์ของตัวแบบการทดลองหลัก (ต่อ)



ตารางที่ 4.13 การแบ่งชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก

**ชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก**

Experiment	Classes	Training Set		Testing Set	
		Original + Geometric Augmented	Photometric Augmented	Original + Geometric Augmented	Photometric Augmented
Full	BPM 24	3,060	1,530	540	270
	PB 235	3,060	1,530	540	270
	RRIM 600	3,060	1,530	540	270
	RRIT 226	3,060	1,530	540	270
	RRIT 251	3,060	1,530	540	270
	RRIT 408	3,060	1,530	540	270


ผลการเพิ่มประสิทธิภาพตัวแบบในการทดลองหลัก (ตารางที่ 4.14) พบว่า ตัวแบบที่อาศัยสถาปัตยกรรม ResNetRS50 เป็นตัวสกัดคุณลักษณะ มีความแม่นยำสูงสุด เพิ่มขึ้นจาก 84.57% เป็น 87.57% ใช้ระยะเวลาในการฝึกสอน 44 นาที 47 วินาที รองลงมา คือ ConvNeXtBase และ DenseNet มีความแม่นยำเพิ่มขึ้นจาก 82.19% เป็น 86.11% และเพิ่มขึ้นจาก 83.52% เป็น 85.39% ใช้ระยะเวลาในการฝึกสอน 2 ชั่วโมง 15 วินาที และ 1 ชั่วโมง 4 นาที 41 วินาที ตามลำดับ โดยมีพฤติกรรมการเรียนรู้ดังตารางที่ 4.15 และความสามารถในการระบุสายพันธุ์ ดังตารางที่ 4.16

ตารางที่ 4.14 ผลการเพิ่มประสิทธิภาพตัวแบบการทดลองหลัก


ผลการเพิ่มประสิทธิภาพตัวแบบการทดลองหลัก						
Model	Accuracy	Loss	Precision	Recall	F1-Score	Training Time (hh:mm:ss)
VGG16	0.8263	0.8744	0.8317	0.8263	0.8290	00:21:59
ResNet50	0.8352	1.0464	0.8488	0.8352	0.8419	01:09:43
InceptionV3	0.7267	1.9855	0.7298	0.7267	0.7282	00:27:16
MobileNet	0.7936	1.2316	0.8025	0.7936	0.7980	00:24:40
Xception	0.7909	1.3264	0.7953	0.7909	0.7931	02:27:13
DenseNet201	<b>0.8539</b>	<b>0.8776</b>	<b>0.8596</b>	<b>0.8539</b>	<b>0.8567</b>	<b>01:04:41</b>
NASNetLarge	0.6002	2.7335	0.5993	0.6002	0.5998	02:33:38
MobileNetV2	0.7551	1.6370	0.7599	0.7551	0.7575	00:45:02
EfficientNetB7	0.4500	4.4002	0.6138	0.4500	0.5193	01:44:27
RegNetX064	0.8447	0.9136	0.8610	0.8447	0.8528	01:10:12
RegNetY064	0.8442	0.9204	0.8492	0.8442	0.8467	00:56:02
ResNetRS50	<b>0.8757</b>	<b>0.6938</b>	<b>0.8754</b>	<b>0.8757</b>	<b>0.8756</b>	<b>00:44:47</b>
ConvNeXtBase	<b>0.8611</b>	<b>0.6480</b>	<b>0.8690</b>	<b>0.8611</b>	<b>0.8650</b>	<b>02:00:15</b>

ตารางที่ 4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก


### VGG16



### ResNet50




### InceptionV3




ตารางที่ 4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก (ต่อ)


### MobileNet



### Xception




### DenseNet201




ตารางที่ 4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก (ต่อ)


### NASNetLarge



### MobileNetV2




### EfficientNetB7




ตารางที่ 4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก (ต่อ)


### RegNetX064




### RegNetY064



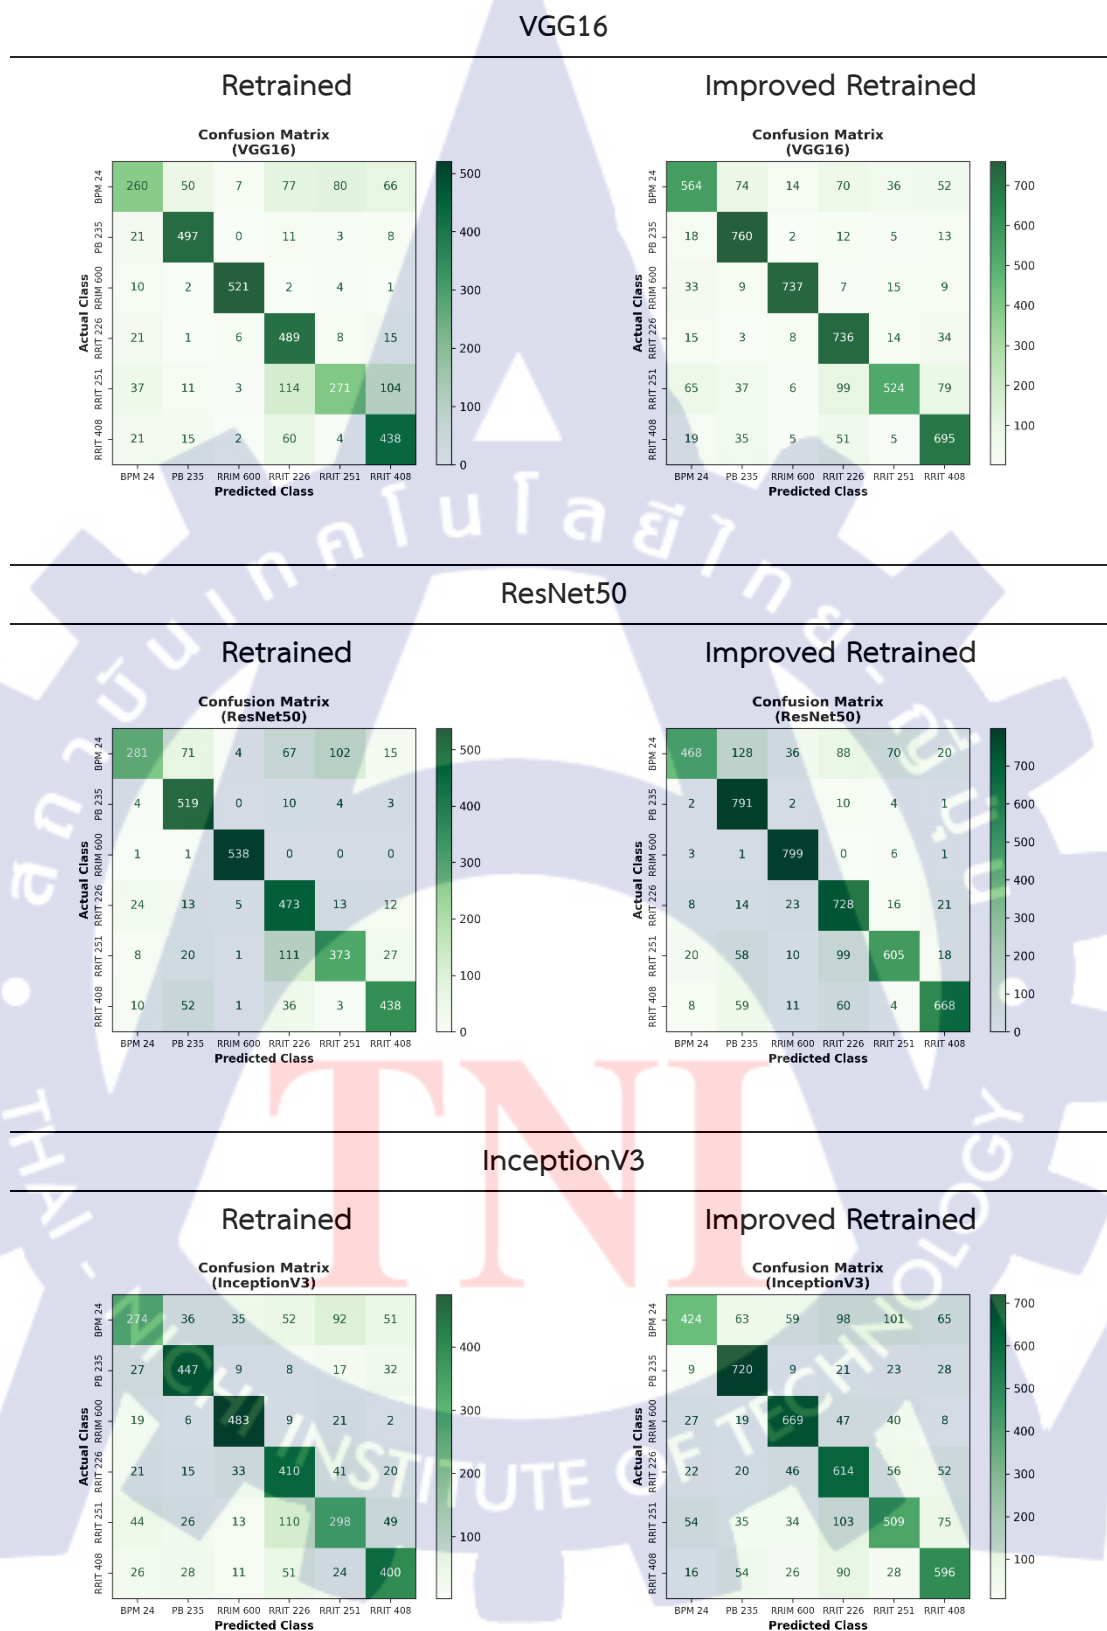
### ResNetRS50



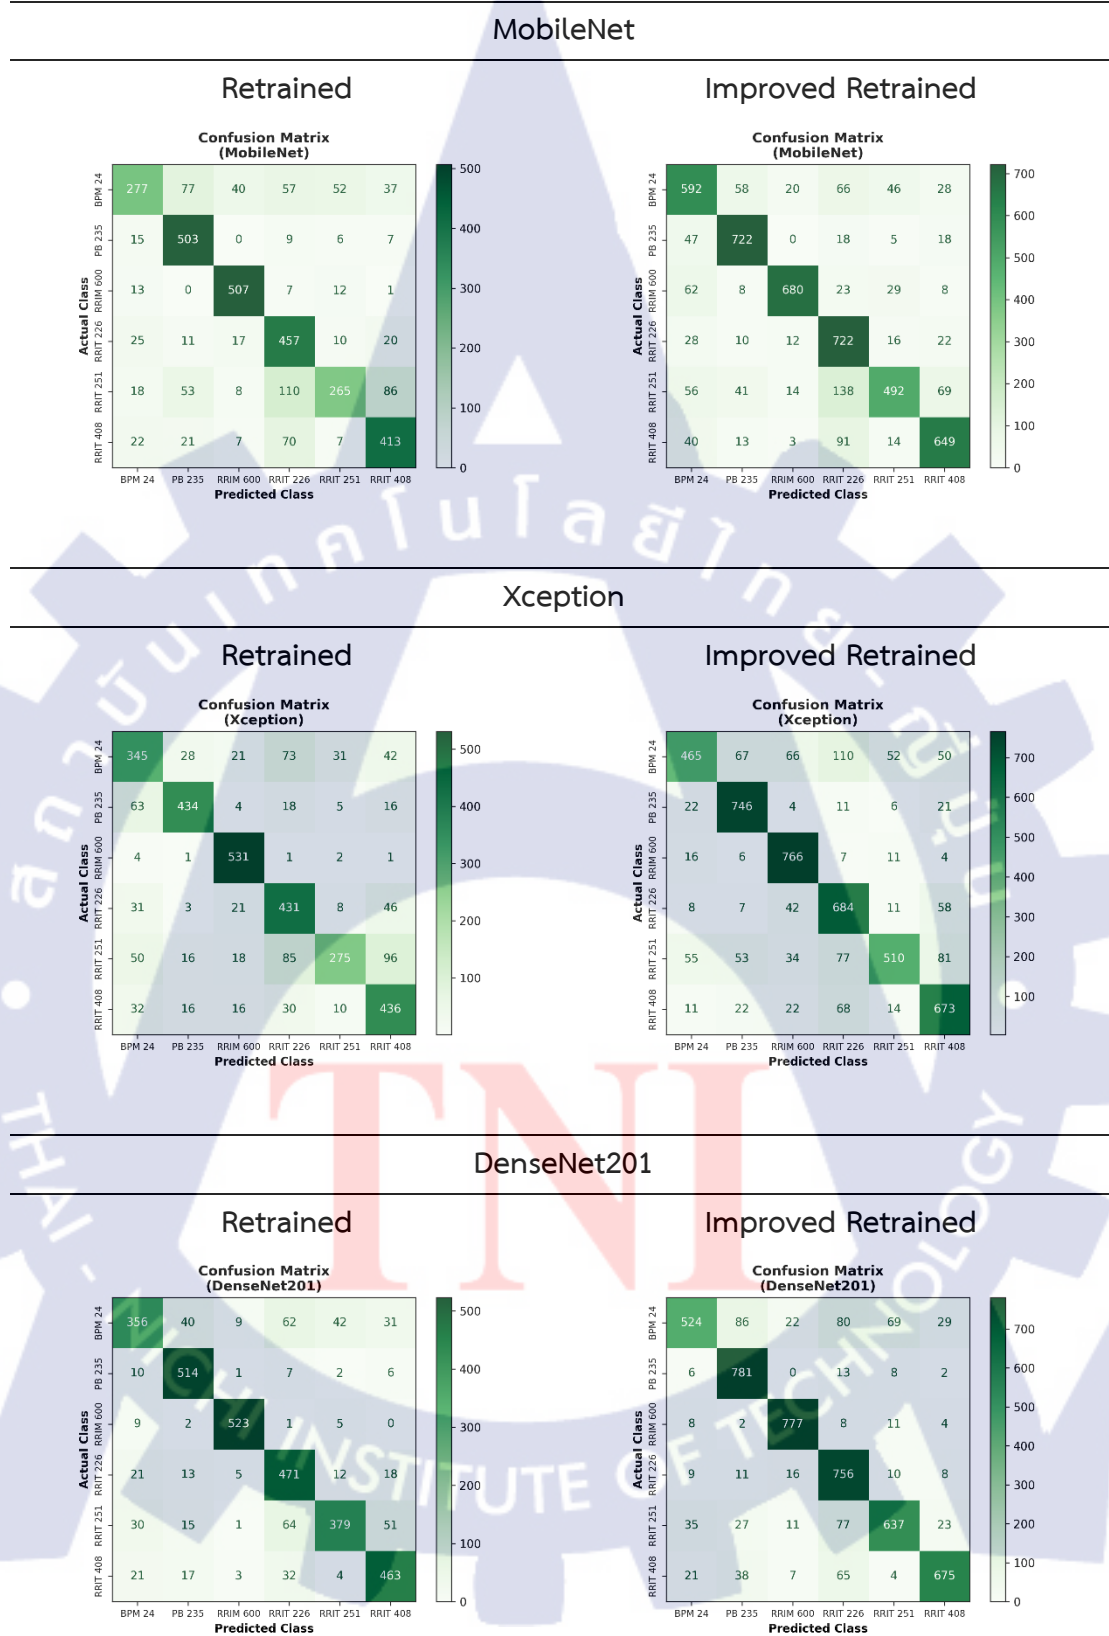
ตารางที่ 4.15 การเรียนรู้ของตัวแบบด้วยชุดข้อมูลเพิ่มประสิทธิภาพการทดลองหลัก (ต่อ)



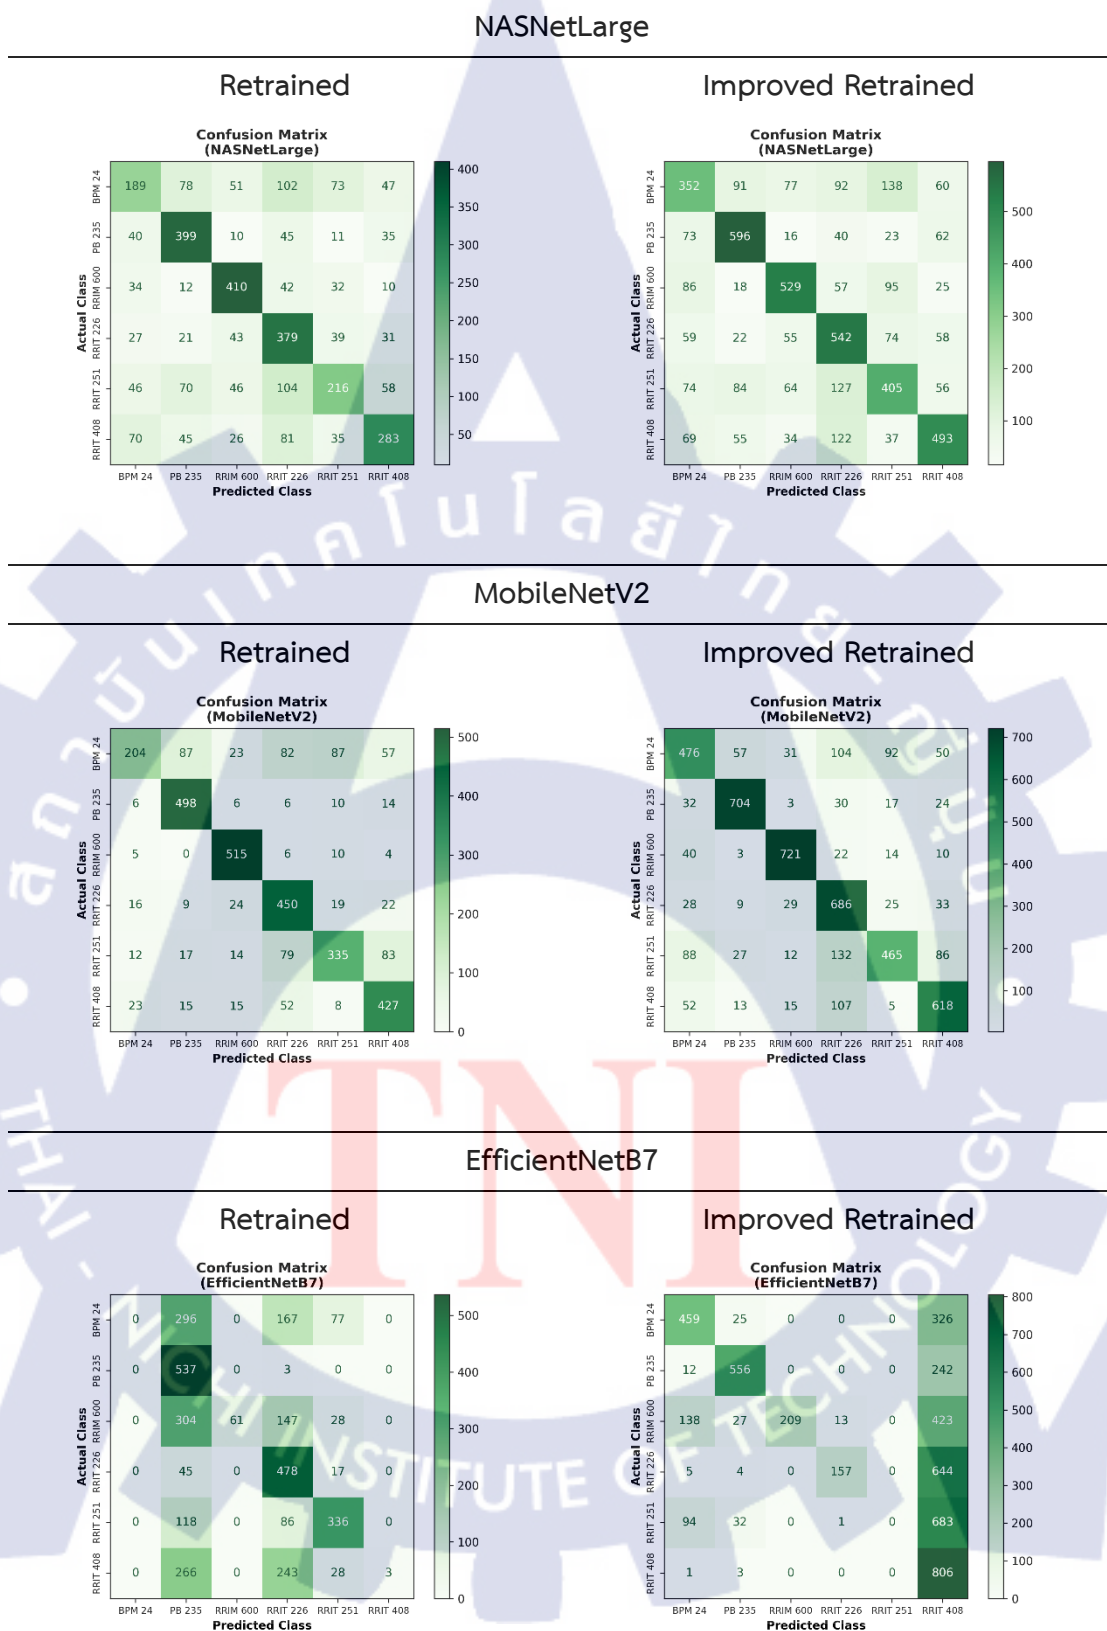
ตารางที่ 4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก



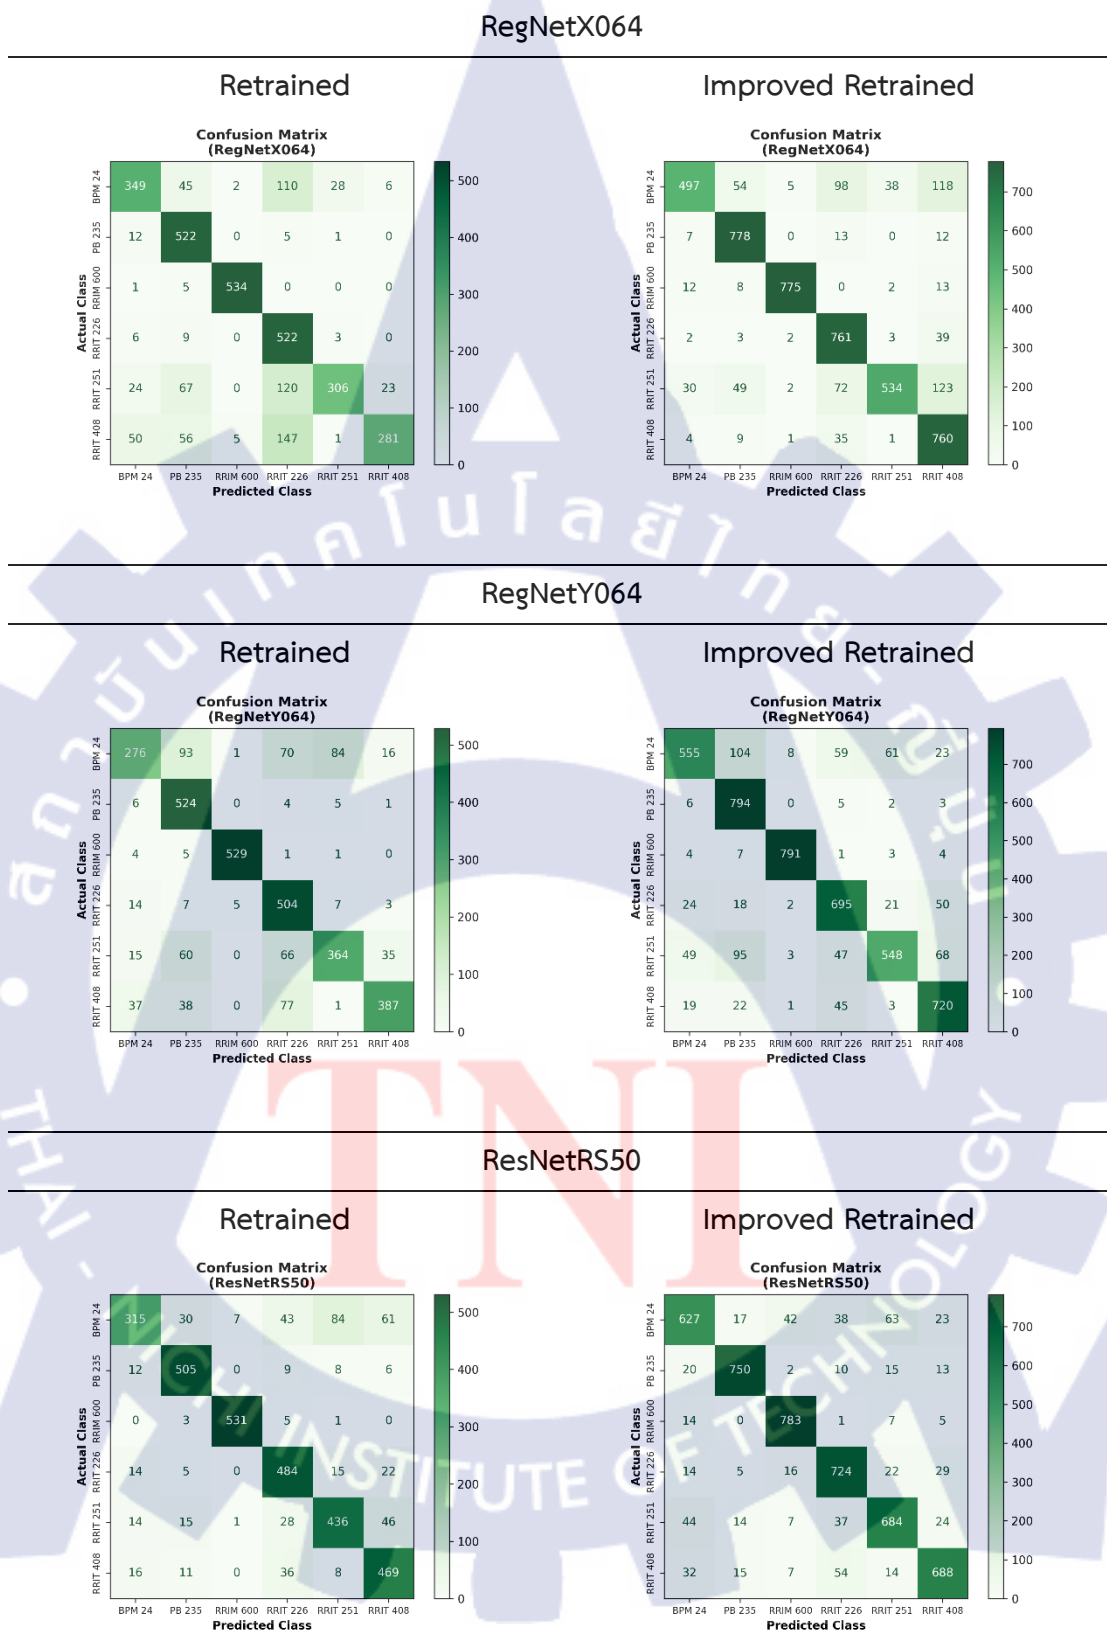
ตารางที่ 4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก (ต่อ)




ตารางที่ 4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก (ต่อ)



ตารางที่ 4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก (ต่อ)

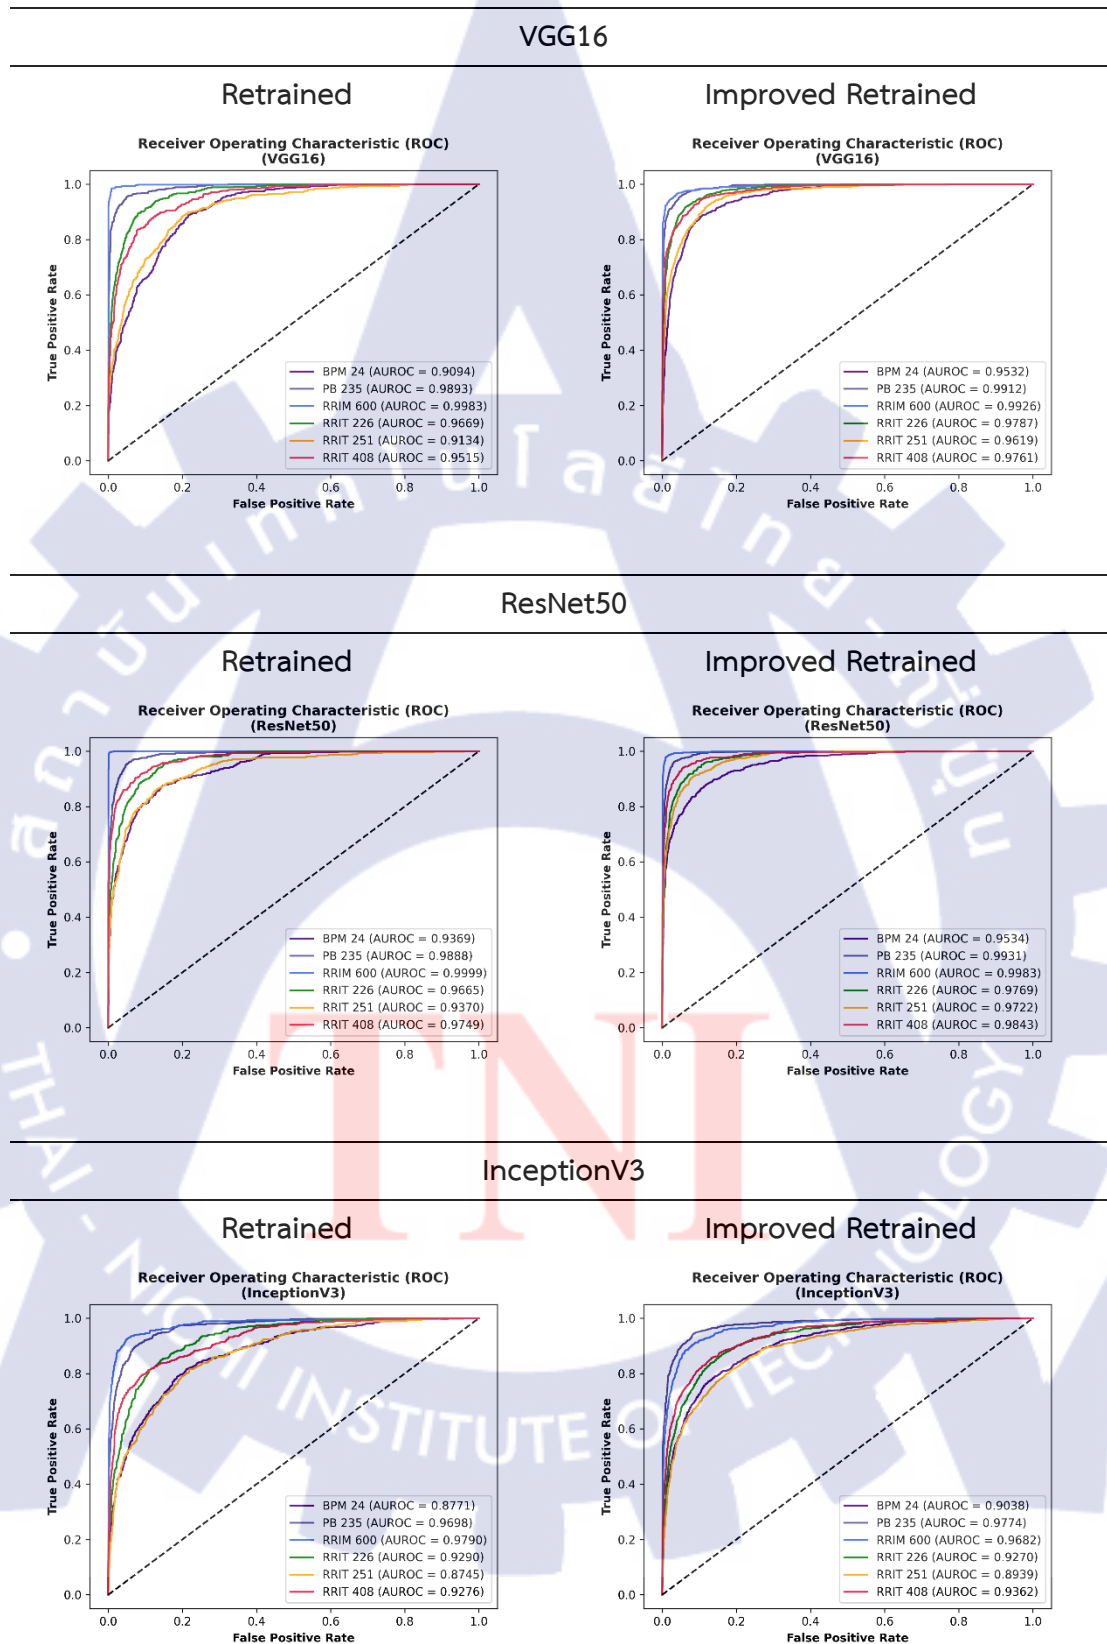


ตารางที่ 4.16 คอนฟิวชันเมทริกซ์ของตัวแบบการทดลองหลัก (ต่อ)

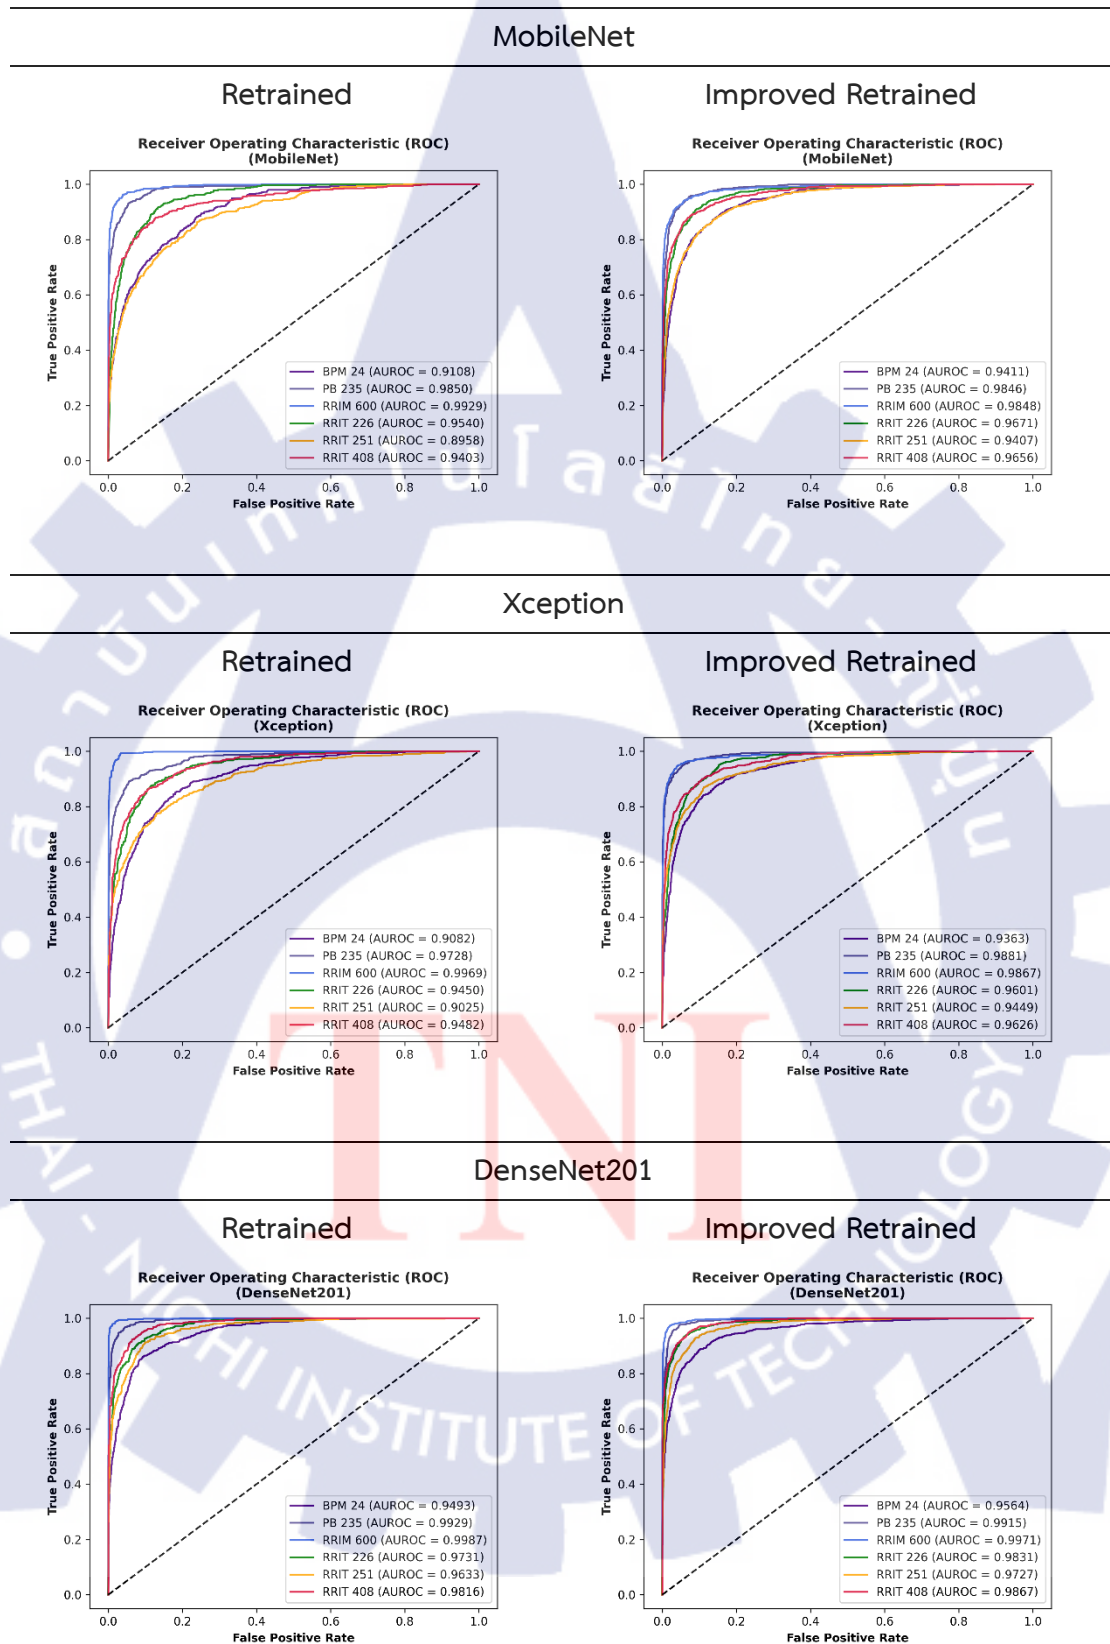


แผนภาพแสดงความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบ (ตารางที่ 4.17) ของตัวแบบในการทดลองหลัก แสดงให้เห็นว่า เมื่อทำการเพิ่มประสิทธิภาพความสามารถในการจำแนกข้อมูลพันธุ์ยางพาราแต่ละสายพันธุ์ที่ค่าเกณฑ์ที่แตกต่างกันสูงขึ้นในทุกตัวแบบโดย ConvNeXtBase มีค่า AUROC สูงสุดในภาพรวมเส้นกราฟของ ConvNeXtBase เข้าใกล้มุมบนซ้ายและมีพื้นที่ใต้เส้นโค้งมากที่สุด

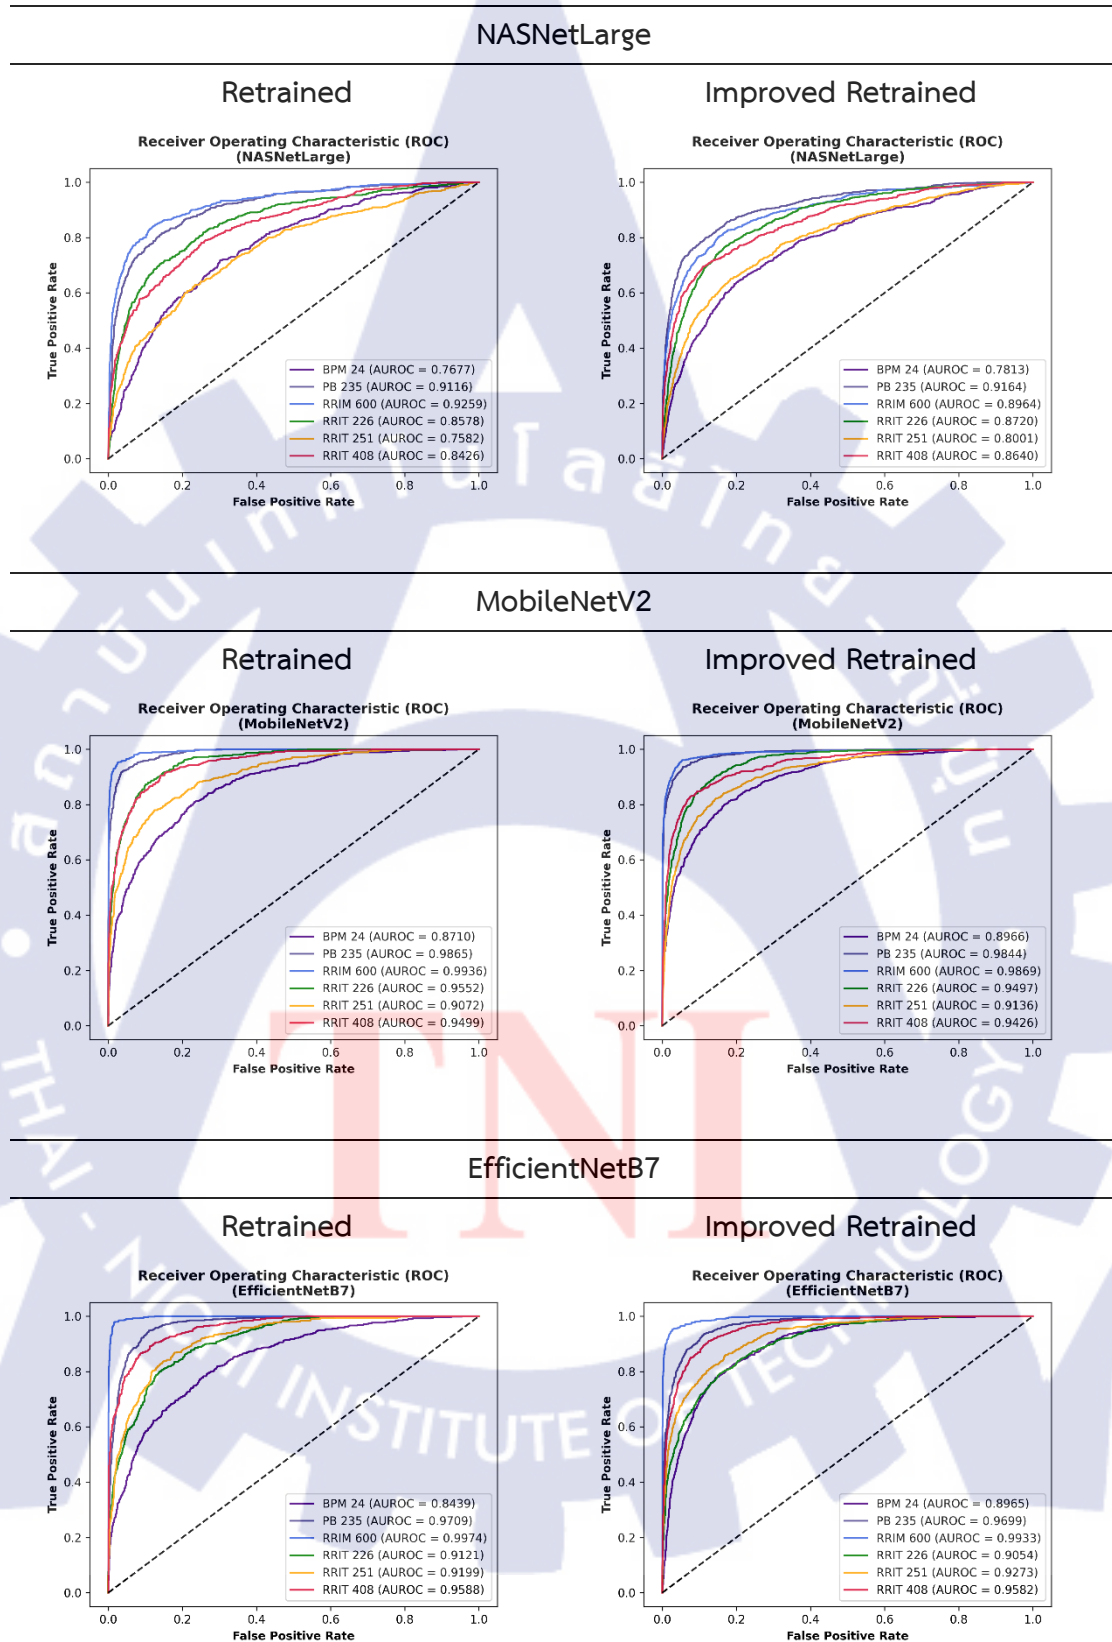
ตารางที่ 4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก



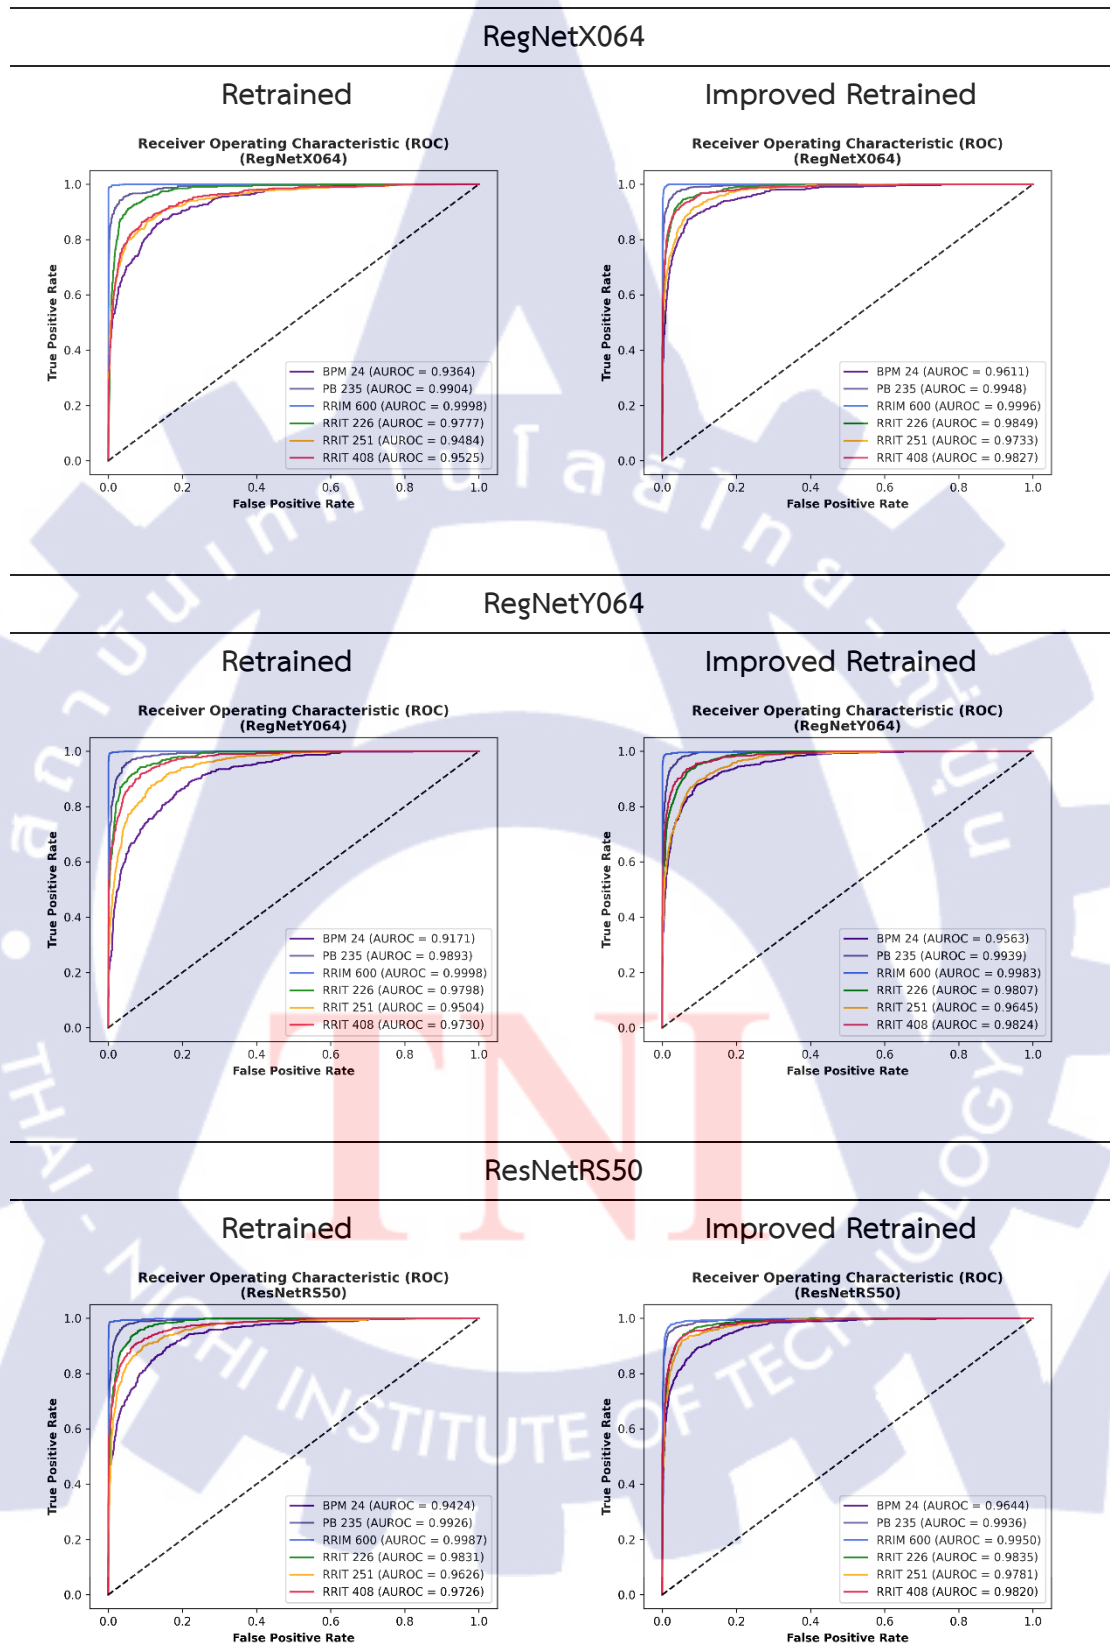
ตารางที่ 4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก (ต่อ)




ตารางที่ 4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก (ต่อ)



ตารางที่ 4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก (ต่อ)



ตารางที่ 4.17 ความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบของตัวแบบการทดลองหลัก (ต่อ)



ผลการทดลองแสดงให้เห็นว่า ตัวแบบที่อาศัยสถาปัตยกรรม ConvNeXtBase มีความเหมาะสมที่สุดสำหรับกระบวนการสกัดคุณลักษณะ ปริมาณชุดข้อมูลขนาด E3 เพียงพอต่อการฝึกสอนให้ได้ตัวแบบจำแนกพันธุ์อย่างพาราที่มีประสิทธิภาพสูง ชุดข้อมูลที่มีความหลากหลายมากยิ่งขึ้นจากการเสริมข้อมูลด้วยวิธีการต่าง ๆ ทั้งแบบดั้งเดิมและการสร้างขึ้นด้วยคอมพิวเตอร์ เมื่อข้อมูลถูกสกัดแบบอัตโนมัติด้วยโครงข่ายประสาทประดิษฐ์เชิงลึกจะส่งผลให้ได้คุณลักษณะที่เป็นประโยชน์ซึ่งมีประสิทธิภาพเทียบเท่ากับคุณลักษณะที่สกัดโดยผู้เชี่ยวชาญแต่อาศัยการเตรียมการและระยะเวลาที่น้อยลง หลังจากการฝึกสอน ตัวแบบมีประสิทธิภาพสูงกว่าการใช้คุณลักษณะที่สกัดโดยผู้เชี่ยวชาญซึ่งสอดคล้องกับงานวิจัยของ Huang และคณะ [49] Tiwari [66] และ Kanda และคณะ [74] และอัลกอริทึมแบบดั้งเดิม [82][83] อย่างไรก็ตามชุดข้อมูลในงานวิจัยนี้ถูกเก็บรวบรวมภายใต้สภาพแวดล้อมที่มีการควบคุมเป็นอย่างดี ตัวแบบไม่สามารถจำแนกข้อมูลที่ไม่เคยเห็นมาก่อนซึ่งมีความแตกต่างอย่างมากจากชุดข้อมูลที่ใช้ในการฝึกสอนได้อย่างมีประสิทธิภาพ ดังนั้นความหลากหลายของชุดข้อมูลจึงเป็นปัจจัยสำคัญในการทำให้ตัวแบบมีความทนทานต่อสภาพแวดล้อมที่เปลี่ยนแปลงไปและสามารถใช้งานได้ครอบคลุมหลากหลายสถานการณ์

## บทที่ 5

### บทสรุป ข้อเสนอแนะ บทวิจารณ์

การศึกษารูปแบบการจำแนกพันธุ์อย่างพาราที่ปลูกในประเทศไทย 6 สายพันธุ์ ด้วยการเรียนรู้เชิงลึก โดยการถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะผ่าน 13 สถาปัตยกรรม ได้แก่ VGG16, ResNet50, InceptionV3, MobileNet, Xception, DenseNet201, NASNetLarge, MobileNetV2, EfficientNetB7, RegNetX064, RegNetY064, ResNetRS50 และ ConvNeXtBase บนชุดข้อมูลที่มีปริมาณแตกต่างกัน ดำเนินการหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดผ่านการตรวจสอบความถูกต้องแบบไขว้ จากการศึกษาการทดลองย่อยการจำแนกระหว่างต้นพันธุ์ RRIM600 ที่ได้จากการติดตาม และที่ได้จากการเพาะเมล็ด พบว่า ตัวแบบที่ได้รับการฝึกสอนด้วยไฮเปอร์พารามิเตอร์ S1 ให้ผลลัพธ์ที่คุ้มค่า เมื่อพิจารณาถึงความแม่นยำและระยะเวลาที่ใช้ในการฝึกสอน ตัวแบบสามารถเรียนรู้จากชุดข้อมูลขนาด E2 และ E3 ได้อย่างมีประสิทธิภาพโดย ตัวแบบ MobileNetV2 มีความแม่นยำสูงสุด 89.12% ใช้ระยะเวลาในการฝึกสอน 21 นาที 4 วินาที บนชุดข้อมูลขนาด E2 และ ConvNeXtBase มีความแม่นยำสูงสุด 98.61% ใช้ระยะเวลาในการฝึกสอน 27 นาที 27 วินาที บนชุดข้อมูลขนาด E3 โดยตัวแบบ ConvNeXtBase มีประสิทธิภาพในการจำแนกข้อมูลได้ดีกว่าตัวแบบอื่น ๆ ที่ค่าเกณฑ์ที่แตกต่างกัน แสดงให้เห็นว่า ConvNeXtBase เป็นตัวแบบที่เหมาะสมสำหรับการจำแนกพันธุ์อย่างพาราระหว่างต้นพันธุ์จากการติดตามและต้นพันธุ์จากการเพาะเมล็ด หลังจากการเพิ่มประสิทธิภาพด้วยการเสริมข้อมูลเชิงคุณสมบัติของรูป ความแม่นยำเพิ่มขึ้นจาก 87.96% เป็น 89.19% และความผิดพลาดของตัวแบบลดลงจาก 0.6632 เป็น 0.4941 บนชุดข้อมูลขนาด E2 และความแม่นยำลดลงเล็กน้อยจาก 98.61% เป็น 97.82% ความผิดพลาดของตัวแบบเพิ่มขึ้นเล็กน้อยจาก 0.0416 เป็น 0.0950 บนชุดข้อมูลขนาด E3 เนื่องจากการเสริมข้อมูลเชิงคุณสมบัติของรูปส่งผลให้ปริมาณข้อมูลเพิ่มขึ้นและมีความซับซ้อนมากยิ่งขึ้น ภาพใบยางพาราส่วนใหญ่ได้รับการระบุสายพันธุ์อย่างถูกต้อง โดยประสิทธิภาพของ ConvNeXtBase ที่ได้รับการเพิ่มประสิทธิภาพบนชุดข้อมูลขนาด E3 ดีกว่า E2 ในภาพรวม

การศึกษารูปแบบการทดลองหลัก การจำแนกพันธุ์อย่างพาราที่ปลูกในประเทศไทย 6 สายพันธุ์ พบว่า ตัวแบบ ResNetRS50 มีความแม่นยำสูงสุด 84.57% ใช้ระยะเวลาในการฝึกสอน 44 นาที 50 วินาที หลังจากทำการเพิ่มประสิทธิภาพ ความแม่นยำของตัวแบบเพิ่มขึ้นเป็น 87.57% แต่เมื่อหาความสัมพันธ์ระหว่างอัตราส่วนความถูกต้องของการพยากรณ์เชิงบวกและอัตราส่วนความถูกต้องของการพยากรณ์เชิงลบ ตัวแบบ ConvNeXtBase มีค่า AUROC สูงกว่า ResNetRS50 ในภาพรวม แสดง

ให้เห็นว่าถึงแม้ ConvNeXtBase จะไม่ได้มีความแม่นยำสูงสุดแต่มีความสามารถจำแนกข้อมูลที่ค่าเกณฑ์ที่แตกต่างกันได้โดยมีประสิทธิภาพ

จากการศึกษาจะเห็นได้ว่า การฝึกสอนตัวแบบโดยใช้การถ่ายโอนความรู้ด้วยการสกัดคุณลักษณะสามารถจำแนกพันธุ์ยางพาราได้เป็นอย่างดีโดยเฉพาะเมื่ออาศัย ConvNeXtBase เป็นตัวสกัดคุณลักษณะ แม้ว่าตัวแบบจะใช้ระยะเวลาในการฝึกสอนนาน แต่มีประสิทธิภาพเหนือกว่าตัวแบบอื่น ๆ อย่างมีนัยสำคัญ ตัวแบบที่สร้างขึ้นสามารถใช้จำแนกพันธุ์ยางพาราในระยะต้นยางอ่อนจากภาพลักษณะใบบนพื้นหลังสีขาวได้อย่างรวดเร็ว แต่ยังเป็นเพียงเครื่องมือสนับสนุนการตัดสินใจให้บุคลากรที่ไม่ได้มีความชำนาญในการจำแนกสายพันธุ์ยางซึ่งยังต้องพึ่งนักจำแนกพันธุ์ที่มีประสบการณ์สูงในการฝึกฝน เพื่อให้การจำแนกสายพันธุ์ดำเนินไปอย่างถูกต้อง และนอกเหนือจากลักษณะใบแล้ว การจำแนกสายพันธุ์ให้ได้แม่นยำมากยิ่งขึ้นยังต้องอาศัยการสังเกตลักษณะอื่นประกอบการตัดสินใจ อีกทั้งการถ่ายภาพเพื่อการจำแนกจำเป็นต้องอาศัยการควบคุมสภาพแวดล้อมจึงจะทำให้ตัวแบบสามารถจำแนกได้มีประสิทธิภาพสูงสุด อย่างไรก็ตามงานวิจัยนี้เป็นเพียงความพยายามในการจำแนกพันธุ์ยางพาราที่ปลูกในประเทศไทย 6 สายพันธุ์ ภาพในชุดข้อมูลถูกถ่ายบนพื้นหลังสีขาวที่ผ่านการควบคุมสภาพแวดล้อมเป็นอย่างดี ในอนาคตควรพัฒนาต่อยอดโดยการเพิ่มสายพันธุ์ที่ใช้ในการฝึกสอน ด้วยชุดข้อมูลจากสภาพแวดล้อมในพื้นที่การใช้งานเพื่อให้ตอบโจทย์ต่อการใช้งานจริงมากยิ่งขึ้นหรือในงานเฉพาะทางอื่น ๆ ที่ชุดข้อมูลมีความหลากหลายสูงต่อไป นอกจากนี้ยังมีการนำตัวแบบไปพัฒนาเป็นเว็บแอปพลิเคชันต้นแบบสำหรับการระบุพันธุ์ยางพาราโดยการอัปโหลดภาพใบกลาง ผลการทดลองใช้งานตัวแบบสามารถระบุสายพันธุ์ได้อย่างมีประสิทธิภาพทั้งภาพขนาดเล็กและขนาดใหญ่



บรรณานุกรม

## บรรณานุกรม

- [1] สำนักงานสถิติการเกษตร, “สถิติการเกษตรของประเทศไทยปี 2566,” [Online]. Available: <https://www.oae.go.th/assets/portals/1/files/journal/2567/statistic2566.pdf> [Accessed: 29 มกราคม 2566].
- [2] กรมวิชาการเกษตร, “ประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดต้นยางพันธุ์ดี พ.ศ. 2556,” [Online]. Available: <https://www.doa.go.th/rc/buriram/wp-content/uploads/2018/11/actGoodrubber.pdf> [Accessed: 29 มกราคม 2566].
- [3] Y. A. Varghese and K. K. Mydin, “Genetic improvement,” *Natural Rubber Agromanagement and Crop Processing*, Cochin, India, January 1, 2000, pp. 36-46.
- [4] S. Withanage, Genetic Improvement of Hevea and Suitable Genotypes, *Handbook of Rubber Vol.1*, Agalawatta, Sri Lanka : Rubber Research Institute of Sri Lanka, 2021.
- [5] C. K. Saraswathyamma et al., “Planting materials,” *Natural Rubber Agromanagement and Crop Processing*, Cochin, India, January 1, 2000, pp. 59-74.
- [6] กรรณิการ์ ชีรวัดนสุข และคณะ, คู่มือการจำแนกลักษณะพันธุ์ยาง, พิมพ์ครั้งที่ 1, กรุงเทพฯ : บริษัท นิเวศรรมดา การพิมพ์ จำกัด, 2560.
- [7] K. K. Liyanage, *Handbook of Rubber Vol.1 : Agronomy*, Agalawatta, Sri Lanka : Rubber Research Institute of Sri Lanka, 2021.
- [8] D. Premakumari and C. K. Saraswathyamma, *Natural Rubber Agromanagement and Crop Processing*, India : Anaswara Printing and Publishing Company, 2000.
- [9] ปริญญา สงวนสัตย์, การเรียนรู้ของเครื่อง, AI สร้างได้ด้วยแมชชีนเลิร์นนิง, พิมพ์ครั้งที่ 1, นนทบุรี : บริษัท ไอดีซี พรีเมียร์ จำกัด, 2562.
- [10] J. D. Kelleher, *Deep Learning*, London : The MIT Press, 2019.
- [11] J. Patterson and A. Gibson, *Deep Learning : A Practitioner’s Approach*, United States of America : O’Reilly Media, Inc, 2017.
- [12] F. Rosenblatt, “The perceptron : A probabilistic model for information storage and organization in the brain,” *Psychological Review*, vol. 65, no. 6, pp. 386-408, November 1958, doi:10.1037/h0042519.
- [13] K. O’Shea and R. Nash, “An Introduction to Convolutional Neural Networks,” 2015, arXiv:1511.08458.

- [14] M. D. Zeiler and R. Fergus, "Visualizing and understanding convolutional networks," *13th European Conference on Computer Vision (ECCV)*, Zurich, Switzerland, September 6-12, 2014, pp. 818-833.
- [15] Y. Lecun et al., "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436-444, May 2015, doi:10.1038/nature14539.
- [16] G. E. Hinton, "How neural networks learn from experience," *Scientific American Magazine*, vol. 267, no. 3, pp. 144-151, September, 1992, doi:10.1038/scientificamerican0992-144.
- [17] Y. Bengio et al., "Deep learning for AI," *Communications of the ACM*, vol. 64, no. 7, pp. 58-65, July, 2021, doi:10.1145/3448250.
- [18] A. Krizhevsky et al., "ImageNet classification with deep convolutional neural networks," *26th Conference on Neural Information Processing Systems*, Lake Tahoe, Nevada, USA, December 3-8, 2012, pp. 1-9.
- [19] X. Yin et al., "Fine-tuning and visualization of convolutional neural networks," *2017 12th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, Siem Reap, Cambodia, June 18-20, 2017, pp. 1310-1315, doi:10.1109/ICIEA/2017/8283041.
- [20] ณัฐโชติ พรหมฤทธิ์ และ สัจจาภรณ์ ไวจรรยา, "การ Transfer Learning ด้วย KERAS สำหรับ Computer Vision Applications," *Fundamental of Deep Learning in Practice*, พิมพ์ครั้งที่ 1, นนทบุรี: บริษัท ไอทีซี พรีเมียร์ จำกัด, 2564.
- [21] J. Deng et al., "ImageNet : A large-scale hierarchical image database," *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami, FL, USA, June 20-25 2009, pp. 248-255, doi:10.1109/CVPR.2009.5206848.
- [22] J. Yosinski et al., "How transferable are features in deep neural networks," *27th Advances in Neural Information Processing Systems (NIPS)*, Montreal, Canada, December 8-13, 2014, pp. 3320-3328.
- [23] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," 2015, arXiv:1409.1556v6.
- [24] K. He et al., "Deep residual learning for image recognition," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27-30, 2016, pp. 770-778, doi:10.1109/CVPR.2016.90.

- [25] S. Xie et al., "Aggregated residual transformations for deep neural networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, July 21-26, 2017, pp. 5987-5995, doi:10.1109/CVPR.2017.634.
- [26] I. Bello et al., "Revisiting ResNets : Improved training and scaling strategies," *35<sup>th</sup> Conference on Neural Information Processing System (NeurIPS)*, NY, USA, December 6-14, 2021, pp. 22614-22627.
- [27] C. Szegedy et al., "Going deeper with convolutions," *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, June 7-12, 2015, pp. 1-9, doi:10.1109/CVPR.2015.7298594.
- [28] M. Lin et al., "Network in Network," 2014, arXiv:1312.4400v3.
- [29] C. Szegedy et al., "Rethinking the inception architecture for computer vision," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27-30, 2016, pp. 2818-2826, doi:10.1109/CVPR.2016.308.
- [30] C. Szegedy et al., "Inception-v4, inception-resnet and the impact of residual connections on learning," *31st AAAI Conference on Artificial Intelligence*, San Francisco, California, USA, February 4-9, 2017, pp. 4278-4284.
- [31] A. G. Howard et al., "MobileNets : Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, arXiv:1704.04861.
- [32] M. Sandler et al., "MobileNetV2 : Inverted Residuals and Linear Bottlenecks," *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, June 18-23, 2019, pp. 4510-4520, doi:10.1109/CVPR.2018.00474.
- [33] A. Howard et al., "Searching for mobileNetV3," *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, Seoul, Korea (South), October 27-November 2, 2019, pp. 1314-1324, doi:10.1109/ICCV.2019.00140.
- [34] F. Chollet, "Xception : Deep learning with depthwise separable convolutions," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, July 21-26, 2017, pp. 1800-1807, doi:10.1109/CVPR.2017.195.
- [35] G. Huang et al., "Densely connected convolutional network," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, July 21-26, 2017, pp. 2261-2269, doi:10.1109/CVPR.2017.243.

- [36] B. Zoph et al., "Learning transferable architecture for scalable image recognition," *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, UT, USA, June 18-23, 2018, pp. 8697-8710, doi : 10.1109/CVPR.2018.00907.
- [37] M. Tan and Q. V. Le, "EfficientNet : Rethinking model scaling for convolutional neural networks," *36th International Conference on Machine Learning (ICML)*, Long Beach, California, 9-15 June, 2019, pp. 6105-6114.
- [38] I. Radosavovic et al., "Designing network design spaces," *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA, June 13-19, 2020, pp. 10425-10433, doi:10.1109/CVPR42600.2020.01044.
- [39] Z. Liu et al., "A ConvNet for the 2020s," *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA, June 18-24, 2022, pp. 11966-11976, doi:10.1109/CVPR52688.2022.01167.
- [40] A. Dosovitskiy et al., "An image is worth 16x16 words : Transformers for image recognition at scale," *International Conference on Learning Representations (ICLR)*, Vienna, Austria, May 4, 2021, pp. 1-21.
- [41] T. Xiao et al., "Early convolutions help transformers see better," *35th International Conference on Neural Information Processing System (NIPS)*, New York, United States, December 6-14, 2021.
- [42] Z. Liu et al., "Swin transformer: Hierarchical vision transformer using shifted windows," *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, QC, Canada, October 10-17, 2021, pp. 10012-10022, doi:10.1109/ICCV48922.2021.00986.
- [43] P. Ramachandran et al., "Stand-alone self-attention in vision models," *33rd International Conference on Neural Information Processing System (NIPS)*, Vancouver, Canada, December 8-14, 2019, pp. 68-80.
- [44] N. Carion et al., "End-to-end object detection with transformers," *16th European Conference on Computer Vision (ECCV)*, Glasgow, UK, August 23-28, 2020, pp. 213-229.
- [45] A. Olsen et al., "DeepWeeds : A multiclass weed species image dataset for deep learning," *Scientific Reports*, vol. 9, no. 2058, February. 14, 2019, doi:10.1038/s41598-018-38343-3.

- [46] I. Zarrin and S. Islam, "Leaf based trees identification using convolutional neural network," *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, Bombay, India, March 29-31, 2019, pp. 1-4, doi:10.1109/I2CT45611.2019.9033914.
- [47] S. U. Habiba et al., "Bangladesh plant recognition using deep learning based leaf classification," *2019 International Conference on Computer, Communication, Chemical, Materials and Electronic Engineering (IC4ME2)*, Rajshahi, Bangladesh, July 11-12, 2019, pp. 1-4, doi:10.1109/IC4ME247184.2019.9036515.
- [48] C. S. Pereira et al., "Deep learning techniques for grape plant species identification in natural images," *Sensors*, vol. 19, no. 22, pp. 1-22, November 2019, doi:10.3390/s19224850.
- [49] Z.-K. Huang et al., "Cinnamomum camphora classification based on leaf image using transfer learning," *2019 IEEE 4<sup>th</sup> Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, Chengdu, China, December 20-22, 2019, pp. 1426-1429, doi:10.1109/IAEAC47372.2019.8997791.
- [50] M. H. Kamrul et al., "A deep learning based approach on categorization of tea leaf," *International Conference on Computing Advancement (ICCA)*, New York, United States, March 20, 2020, pp. 1-8, doi:10.1145/3377049.3377122.
- [51] G. Vizcarra et al., "The peruvian amazon foresty dataset : A leaf image classification corpus," *Ecological Informatics*, vol. 62, no. 101268, pp. 1-10, May 2021, doi:10.1016/j.ecoinf.2021.101268.
- [52] A. Nasiri et al., "Automated grapevine cultivar identification via leaf imaging and deep convolutional neural networks : A proof-of-concept study employing primary Iranian varieties," *Machine Learning in Plant Identification and Phenological, Anatomical, and Morphological Research*, vol. 10, no. 8, pp. 1628, August 2021, doi:10.3390/plants10081628.
- [53] N. D.-Trung et al., "A combination of transfer learning and deep learning for medicinal plant classification," *2019 4th International Conference Intelligent Information Technology (ICIIT)*, New York, United States, February 20, 2019, pp. 83-90, doi:10.1145/3321454.3321464.

- [54] Y. R. Azeez and C. Rajapakse, "An application of transfer learning techniques in identifying herbal plants in Sri Lanka," *2019 International Research Conference on Smart Computing and Systems Engineering (SCSE)*, Colombo, Sri Lanka, March 28, 2019, pp. 172-178, doi:10.23919/SCSE.2019.8842681.
- [55] M. R. Dileep and P. N. Pournami, "AyurLeaf : A deep learning approach for classification of medicinal plants," *TENCON2019-2019 IEEE Region 10 Conference (TENCON)*, Kochi, India, October 17-20, 2019, pp. 321-325, doi:10.1109/TENCON.2019.8929394.
- [56] A. Paulson and S. Ravishankar, "AI based indigenous medicinal plant identification," *2020 Advanced Computing and Communication Technologies for High Performance Applications (ACCTHPA)*, Cochin, India, July 2-4, 2020, pp. 57-63, doi:10.1109/ACCTHPA49271.2020.9213224.
- [57] N. Mettripun, "Thai herb leaves classification based on properties of image regions," *2020 59th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE)*, Chiang Mai, Thailand, September 23-26, 2020, pp. 372-377, doi:10.23919/SICE48898.2020.9240256.
- [58] A. Muneer and S. M. Fati, "Efficient and automated herbs classification approach using deep learning," *IEEE Access*, vol. 8, no. 18, pp. 196747-196764, October 2020, doi:10.1109/ACCESS.2020.3034033.
- [59] S. Sachar and A. Kumar, "Deep ensemble learning for automatic medicinal leaf identification," *International Journal of Information Technology*, vol. 14, no. 6, pp. 3089-3097, August 2022, doi:10.1007/s41870-022-01055-z.
- [60] S. Roopashree and J. Anitha, "DeepHerb : A vision based system for medicinal plants using xception features," *IEEE Access*, vol. 9, no. 3116207, pp. 135297-135941, September 2021, doi:10.1109/ACCESS.2021.3116207.
- [61] C. R. Alimboyong and A. A. Hernandez, "An improved deep neural network for classification of plant seedling images," *2019 IEEE 15th International Colloquium on Signal Processing & Its Applications (CSPA)*, Penang, Malaysia, March 8-9, 2019, pp. 217-222, doi:10.1109/CSPA.2019.8696009.
- [62] S. A. Pearline et al., "A study on plant recognition using conventional image processing and deep learning approaches," *Journal of Intelligent & Fuzzy Systems*, vol. 36, no. 3, pp. 1997-2004, March 2019, doi:10.3233/JIFS-169911.

- [63] A. Kaya et al., "Analysis of transfer learning for deep neural network based plant classification models," *Computers and Electronics in Agriculture*, vol. 158, pp. 20-29, March 2019, doi:10.1016/j.compag.2019.01.041.
- [64] C. A. M. Diaz et al., "Deep learning for plant classification in precision agriculture," *2019 International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, Tangerang, Indonesia, October 23-24, 2019, doi:10.1109/IC3INA48034.2019.8949612.
- [65] P. Jasitha and M. R. Dileep, "Venation based plant leaves classification using GoogLeNet and VGG," *2019 4th International Conference on Recent Trends on Electronics, Information, Communication & Technology (RTEICT)*, Bangalore, India, May 17-18, 2019, pp. 715-719, doi:10.1109/RTEICT46194.2019.9016966.
- [66] S. Tiwari, "A comparative study of deep learning models with handcraft features and non-handcraft features for automatic plant species identification," *International Journal of Agricultural and Environmental Information Systems*, vol. 11, no. 2, pp. 44-57, April 2020, doi:10.4018/IJAEIS.2020040104.
- [67] S. MIAO et al., "Plant images recognition based on transfer learning," *2020 4th International Conference on Innovation in Artificial Intelligence (ICIAI)*, New York, United States, June 4, 2020, pp. 125-129, doi:10.1145/3390557.3394310.
- [68] S. A. Riaz et al., "Multipath deep shallow convolutional networks for large scale plant species identification in wild image," *2020 International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, July 19-24, 2020, pp. 1-7, doi:10.1109/IJCNN48605.2020.9207113.
- [69] C.-L. Chang and S.-C. Chung, "Improved deep learning-based approach for real-time plant species recognition on the farm," in *2020 12th International Symposium in Communication Systems, Networks and Digital Signal Processing (CSNDSP)*, Porto, Portugal, July 20-22, 2020, pp. 1-5, doi:10.1109/CSNDSP49049.2020.9249558.
- [70] W. Liu et al., "Plant taxonomy in Hainan based on deep convolutional neural network and transfer learning," *2020 IEEE 19th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom)*, Guangzhou, China, December 29-January 1, 2021, pp. 1461-1467, doi:10.1109/TrustCom50675.2020.00197.

- [71] S. Patil et al., "Recognizing plant species using digitized leaves-a comparative study," *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, June 21, 2021, pp. 1138-1143, doi:10.1109/ICOEI51242.2021.9453003.
- [72] S. Sachar and A. Kumar, "Automatic plant identification using transfer learning," *1<sup>st</sup> International Conference on Computational Research and Data Analytics (ICCRDA)*, Rajpura, India, October 24, 2021, pp. 1-10, doi:10.1088/1757-899X/1022/1/012086.
- [73] D. Bisen, "Deep convolutional neural network based plant species recognition through features of leaf," *Multimedia Tools and Applications*, vol. 80, no. 4, pp. 6443-6456, October 2021, doi:10.1007/s11042-020-10038-w.
- [74] P. S. Kanda et al., "A deep learning-based recognition technique for plant leaf classification," *IEEE Access*, vol. 9, no. 3131726, pp. 162590-162613, November 2021, doi:10.1109/ACCESS.2021.3131726.
- [75] S. R. G. Reddy et al., "Optimized convolutional neural network model for plant species identification from leaf images using computer vision," *International Journal of Speech Technology*, vol. 26, no. 1, pp. 23-50, April 2021, doi:10.1007/s10772-021-09843-x.
- [76] K. Pushpanathan et al., "MYLPHerb-1 : A dataset of Malaysian local perennial herbs for the study of plant images classification under uncontrolled environment," *Pertanika Journal of Science & Technology*, vol. 30, no. 1, pp. 413-431, January 2022, doi:10.47836/pjst.30.1.23.
- [77] N. C. Kunder and P. B. Mallikarjuna, "Deep convolutional neural network architecture for plant seedling classification," *Engineering, Technology & Applied Science Research*, vol. 12, no. 6, pp. 9464-9470, December 2022, doi:10.48084/etasr.5282.
- [78] S. T. Anjomshoae et al., "Hevea leaf boundary identification based on morphological transformation and edge detection," *Pattern Recognition and Image Analysis*, vol. 25, no. 2, pp. 291-294, June 2015, doi:10.1134/S1054661815020029.
- [79] S. T. Anjomshoae and M. S. M. Rahim, "Feature extraction of overlapping Hevea leaves : A comparative study," *Information Processing in Agriculture*, vol. 5, no. 2, pp. 234-245, June. 2018, doi:10.1016/j.inpa.2018.02.001.

- [80] B. Pratomo et al., "Short communication digital identification approach to characterize *Hevea brasiliensis* leaves," *Biodiversitas Journal of Biological Diversity*, vol. 22, no. 2, pp. 1006-1013, February 2021, doi:10.13057/biodiv/d220257.
- [81] S. A. Pasaribu et al., "Leaf characterizations of IRR 400 Series, BPM 24, and RRIC 100 rubber (*Hevea brasiliensis* Muell. Arg.) clone using leafgram method," *International Journal on Advanced Science Engineering Information Technology*, vol. 12, no. 5, pp. 1721-1727, October 2022, doi:10.18517/ijaseit.12.5.15512.
- [82] วรณะสิริ ชุระชน และคณะ, "การจำแนกพันธุ์ยางพาราโดยใช้ตัวจำแนกนาอ์ฟเบย์," *การประชุมทางวิชาการระดับชาติด้านคอมพิวเตอร์และเทคโนโลยีสารสนเทศ, โรงแรมอัสนา Laguna อำเภอดอนเจดีย์, จังหวัดบุรีรัมย์, 8-9 พฤษภาคม 2557, หน้า 20-25.*
- [83] P. Pongsomsong and P. Ratanaworabhan, "Automatic rubber tree classification," *2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, Chiang Mai, Thailand, May 19-22, 2021, pp. 167-170.
- [84] D. Fonseka and C. Chrysoulas, "Data augmentation to improve the performance of a convolutional neural network on image classification," *2020 International Conference on Decision Aid Sciences and Application (DASA)*, Sakheer, Bahrain, November 8-9, 2020, pp. 515-518, doi:10.1109/DASA51403.2020.9317249.
- [85] C. Lei et al., "A preliminary study on data augmentation of deep learning for image classification," *11th Asia-Pacific Symposium on Internetware*, Fukuoka, Japan, October 28-29, 2019, pp. 1-6, doi:10.1145/3361242.3361259.
- [86] S. Zheng et al., "Improving the robustness of deep neural networks via stability training," *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, June 27-30, 2016, pp. 4480-4488, doi:10.1109/CVPR.2016.485.
- [87] J. Buquet et al., "Evaluating the impact of wide-angle lens distortion on learning-based depth estimation," *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Nashville, TN, USA, June 19-25, 2021, pp. 3688-3696, doi:10.1109/CVPRW53098.2021.00409.

- [88] Y. Zhou et al., "On classification of distorted images with deep convolutional neural networks," *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, New Orleans, LA, USA, June 5-9, 2017, pp. 1213-1217, doi:10.1109/ICASSP.2017.7952349.
- [89] S. Dodge and L. Karam, "Understanding how image quality affects deep neural networks," *2016 Eight International Conference on Quality of Multimedia Experience (QoMEX)*, Lisbon, Portugal, June 6-8, 2016, pp. 1-6, doi:10.1109/QoMEX.2016.7498955.
- [90] K. Xiao et al., "Noise or signal : The role of image backgrounds in object recognition," 2020, arXiv:2006.09994.
- [91] D. Hendrycks et al., "Using pre-training can improve model robustness and uncertainty," *International Conference on Machine Learning (ICML)*, Long Beach, California, USA, June 9-16, 2019, pp. 2712-2721.
- [92] Keras Applications, "Keras: The Python Deep Learning API," [Online]. Available <https://keras.io/api/applications>. [Accessed: February 20, 2023].
- [93] J. Huang and C. X. Ling, "Using AUC and accuracy in evaluating learning algorithms," *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 3, pp. 299 - 310, doi:10.1109/TKDE.2005.50.
- [94] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, no. 8, pp.861-874, December 2005, doi:10.1016/j.patrec.2005.10.010.
- [95] S. Bianco, et al., "Benchmark analysis of representative deep neural network architectures," *IEEE Access*, vol. 6, pp. 64270-64277, 2018, doi:10.1109/ACCESS.2018.2877890.
- [96] S. Ioffe and C. Szegedy, "Batch normalization : Accelerating deep network training by reducing internal covariate shift," in *32nd International Conference on Machine Learning*, Lille, France, July 6-11, 2015, pp. 448-456, doi:10.5555/3045118.3045167.
- [97] N. Srivastava et al., "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929-1958, January 2014, doi:10.5555/2627435.2670313.
- [98] B. Ding et al., "Activation functions and their characteristics in deep neural networks," *2018 Chinese Control And Decision Conference (CCDC)*, Shenyang, China, June 9-11, 2018, pp. 1836-1841, doi:10.1109/CCDC.2018.8407425.

- [99] A. M. Javid et al., "A ReLU dense layer to improve the performance of neural networks," *ICASSP 2021-2021 IEEE International Conference of Acoustics, Speech and Signal Processing (ICASSP)*, Toronto, ON, Canada, June 6-11, 2021, pp. 2810-2814, doi:10.1109/ICASSP39728.2021.9414269.
- [100] S. Yadav and S. Shukla, "Analysis of k-fold cross validation over hold-out validation on colossal datasets for quality classification," *2016 IEEE 6th International Conference on Advanced Computing (IACC)*, Bhimavaram, India, February 27-28, 2016, pp. 78-83, doi:10.1109/IACC.2016.25.
- [101] E. M. Dogo et al., "On the relative impact of optimizers on convolutional neural networks with varying depth and width for image classification," *Applied Sciences*, vol. 12, no. 23, pp. 1-36, November 2022, doi:10.3390/app122311976.
- [102] D. P. Kingma and J. L. Ba, "ADAM : A Method for Stochastic Optimization," 2017, arXiv:1412.6980.
- [103] J. Jepkoech et al., "The effect of adaptive learning rate on the accuracy of neural networks," *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 12, no. 8, pp. 736-751, August 2021, doi:10.14569/IJACSA.2021.0120885.





ภาคผนวก

TNI



ภาคผนวก ก.  
เว็บแอปพลิเคชัน

TNI

## Hevis

AI for (Thai) *Hevea* Clone Identification

"Please, capture an image of leaf placed on white background by focusing on the target object for the best identification performance."

Supported file : .jpg .jpeg and .png files.  
Maximum file size : 10 MB.

Model : Binary Classification (RRIM 600 Clone, RRIM 600) ▾

Click to upload Let's identify

## Identification Result

**Clone :**

None

**Probability :**

0%

### What is Hevis ?

Hevis (*Hevea* Vision) is a deep learning model for *Hevea* clone identification. The model will help cultivators to ensure the right clones are used for planting. You can easily identify them by uploading a leaf image to the website.

There are two models available for common cultivated clones in Thailand as follows :

- Binary Classification : This model was trained for two classes including RRIM 600 clone and seedling.
- Multiclass Classification : This model was trained for six classes including BPM 24, PB 235, RRIM 600, RRIT 226, RRIT 251, and RRIT 408.

© COPYRIGHT 2025 Hevis

## Hevis

AI for (Thai) *Hevea* Clone Identification

"Please, capture an image of leaf placed on white background by focusing on the target object for the best identification performance."

Supported file : .jpg .jpeg and .png files.  
Maximum file size : 10 MB.



Model : Multiclass Classification (BPM 24, PB 235, RRIM) ▾

Click to upload Let's identify

## Identification Result

**Clone :**

RRIM 600

**Probability :**

92.59%

### What is Hevis ?

Hevis (*Hevea* Vision) is a deep learning model for *Hevea* clone identification. The model will help cultivators to ensure the right clones are used for planting. You can easily identify them by uploading a leaf image to the website.

There are two models available for common cultivated clones in Thailand as follows :

- Binary Classification : This model was trained for two classes including RRIM 600 clone and seedling.
- Multiclass Classification : This model was trained for six classes including BPM 24, PB 235, RRIM 600, RRIT 226, RRIT 251, and RRIT 408.

© COPYRIGHT 2025 Hevis