



การจำแนกสายพันธุ์และการระบุตัวตนสุนัขด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน  
DOG BREED CLASSIFICATION AND IDENTIFICATION USING CONVOLUTIONAL  
NEURAL NETWORKS



ณัฐกานต์ ท้าวพันวงศ์

การจำแนกสายพันธุ์และการระบุตัวตนสุนัขด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล  
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ  
ปีการศึกษา 2565

ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

DOG BREED CLASSIFICATION AND IDENTIFICATION USING CONVOLUTIONAL  
NEURAL NETWORKS



NATTAKAN TOWPUNWONG

A Master's Project Submitted in Partial Fulfillment of the Requirements  
for the Degree of MASTER OF SCIENCE  
(Data Science)

Faculty of Science, Srinakharinwirot University

2022

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การจำแนกสายพันธุ์และการระบุตัวตนสุนัขด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน

ของ

ณัฐกานต์ ท้าวพันวงศ์

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

ที่ปรึกษาหลัก

ประธาน

(ผู้ช่วยศาสตราจารย์ ดร.นภา แซ่เบ๊)

(อาจารย์ ดร.นิดา ชาติวัฒน์ศิริ)

กรรมการ

(อาจารย์ ดร.วีระ สอิ่ง)

ชื่อเรื่อง	การจำแนกสายพันธุ์และการระบุตัวตนสุนัขด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ผู้วิจัย	ณัฐกานต์ ท้าวพันวงศ์
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2565
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. นภา แซ่เบ๊

งานวิจัยนี้มีจุดประสงค์เพื่อศึกษาวิธีการจำแนกสายพันธุ์ของสุนัขและการระบุตัวตนของสุนัขด้วยภาพใบหน้า สายพันธุ์ไทยและสายพันธุ์ต่างประเทศ ประกอบด้วย 2 ขั้นตอน 1. การจำแนกสายพันธุ์ของสุนัขจากภาพถ่ายสุนัข ซึ่งเป็น Soft Biometrics ใช้ชุดข้อมูลจาก Stanford Dogs สำหรับสายพันธุ์ต่างประเทศ และจากฟาร์มสุนัขในประเทศไทยสำหรับสายพันธุ์ไทย รวมทั้งสิ้น 20,949 รูป จำนวน 122 สายพันธุ์ ใช้เทคนิคการถ่ายโอนการเรียนรู้ (Transfer Learning) จากแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks หรือ CNNs) สำหรับนำมาใช้ในการสกัดคุณลักษณะของรูปภาพสุนัข จากนั้นดำเนินการสร้างแบบจำลองใหม่สำหรับการจำแนกสายพันธุ์ของสุนัข โดยใช้แบบจำลอง CNNs ทั้งหมด 6 แบบจำลอง ที่มีการเรียนรู้กับชุดข้อมูล ImageNet ได้แก่ Xception, VGG16, ResNet50, InceptionV3, MobileNetV2 และ NasNetLarge และเปรียบเทียบประสิทธิภาพระหว่างการใช้งานแบบจำลองดั้งเดิม และการสกัดคุณลักษณะของแบบจำลองร่วมกับแบบจำลองในการจำแนกสายพันธุ์ที่สร้างขึ้น พบว่าผลลัพธ์การให้แบบจำลองดั้งเดิมได้ค่าความแม่นยำสูงสุดอยู่ที่ 91% ได้แก่ NasNetLarge ส่วนการใช้การสกัดคุณลักษณะร่วมกับแบบจำลองที่สร้างขึ้นมีค่าความแม่นยำสูงสุดอยู่ที่ 93% ได้แก่ NasNetLarge 2. การระบุตัวตนของสุนัขด้วยภาพใบหน้า ซึ่งเป็น Hard Biometrics ใช้ชุดข้อมูลจาก Flickr-dog สำหรับสายพันธุ์ต่างประเทศ และจากฟาร์มสุนัขในประเทศไทยสำหรับสายพันธุ์ไทย รวมทั้งสิ้น 500 รูป 62 ตัว 4 สายพันธุ์ โดยผู้วิจัยได้ตั้งสมมุติฐานว่า 4 สายพันธุ์นี้คือผลลัพธ์จากการทำจำแนกสายพันธุ์ ขั้นตอนนี้เริ่มจากการตรวจจับใบหน้าของสุนัข ทำการสกัดคุณลักษณะของสุนัขแต่ละตัว จาก 5 แบบจำลอง ซึ่งมีการเรียนรู้กับชุดข้อมูล ImageNet ประกอบด้วย VGG16, ResNet50, InceptionV3, MobileNetV2 และ NasNetLarge และแบบจำลองที่เรียนรู้มาจากใบหน้าอย่าง VGGFace จากนั้นดำเนินการสร้างแบบจำลองใหม่สำหรับการระบุตัวตนสุนัขและเปรียบเทียบประสิทธิภาพ โดย ResNet50 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 75% จากชุดข้อมูลที่ไม่มีการทำ Augmentation และ MobileNetV2 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 77% จากชุดข้อมูลที่มีการทำ Augmentation จะเห็นได้ว่าการทำ Augmentation มีผลเล็กน้อยในการเพิ่มประสิทธิภาพการรู้จำ และจากการวิเคราะห์ภาพรวมพบว่าสายพันธุ์ที่ทำให้ค่าความแม่นยำของแบบจำลองน้อย คือสายพันธุ์ Pug โดยค่าเฉลี่ยความแม่นยำของสายพันธุ์อยู่ที่ 40-50% และสายพันธุ์ไทยทั้ง 2 สายพันธุ์ มีค่าเฉลี่ยความแม่นยำแต่ละสายพันธุ์สูงถึง 80-90 %

คำสำคัญ : โครงข่ายประสาทเทียมแบบคอนโวลูชัน, ไปโอเมทริกซ์, จำแนกสายพันธุ์สุนัข, ระบุตัวตนสุนัข

Title	DOG BREED CLASSIFICATION AND IDENTIFICATION USING CONVOLUTIONAL NEURAL NETWORKS
Author	NATTAKAN TOWPUNWONG
Degree	MASTER OF SCIENCE
Academic Year	2022
Thesis Advisor	Dr. Napa Sae-bae

This research aims to study the methods for dog breed classification and dog identification from images of dogs' faces for Thai and foreign breeds. The main process involves two steps: The first step is dog breed classification using soft biometrics data, with a dataset of 20,949 images, 122 breeds from Stanford Dogs for foreign breeds and from dog farms in Thailand for Thai breeds. The transfer learning technique from a convolutional neural network (CNN) model to extract features of dog images from six models were trained on the ImageNet dataset: Xception, VGG16, ResNet50, InceptionV3, MobileNetV2, and NasNetLarge. Then, build a new model for dog breed classification and compare the performance when using the original models and using feature extraction fusion with the new models created. The result was found to be that the highest accuracy in dog breed classification using the original models was achieved by NasNetLarge, with a maximum accuracy of 91%. and classification of dog breeds using features extracted from fusion with the new classification models created, the highest accuracy was achieved by NasNetLarge, with an accuracy of 93%. The second step is dog identification, which is hard biometrics, utilizes a dataset of 500 images of 62 dogs from four breeds, including foreign dog breeds from Flickr-dog and Thai dog breeds from farms in Thailand. This research assumes that the four breeds represent the results of the breed classification step. Starting with dog face detection, extract the features of dogs by VGG16, ResNet50, InceptionV3, MobileNetV2, and NasNetLarge, as well as models from face recognition by VGGFace. Then, create a new model for dog identification. ResNet50 achieved a maximum accuracy of 75% on the dataset without augmentation, while MobileNetV2 achieved a maximum accuracy of 77% on the augmented dataset. This suggests that data augmentation has a minimal effect on the experimental results. Additionally, the pug breed makes for lower overall accuracy of the model, with an average pug breed accuracy of 40–50%, while both Thai breeds have high average accuracies of 80–90%.

Keyword : Dog Breed Classification, Dog Identification, CNN, Biometrics

## กิตติกรรมประกาศ

การจัดทำวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยการให้ความช่วยเหลือ แนะนำของ ผศ.ดร.นภา แซ่เบ๊ ซึ่งเป็นอาจารย์ที่ปรึกษาที่ได้กรุณาให้คำแนะนำ ข้อคิดเห็นสารนิพนธ์มาโดยตลอด และได้รับการสนับสนุนจากบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการนำเสนอผลงานวิจัย ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้

ขอขอบคุณ ฟาร์มบรมสุข จังหวัดนครราชสีมา ฟาร์มสุนัขไทยหลังอาน ดำรงไทย จังหวัดระยอง ฟาร์มกมลชัยบางแก้ว จังหวัดพิษณุโลก และฟาร์มไทยหลังอาน Muang Non-TRD จังหวัดนนทบุรี ที่ให้ความอนุเคราะห์ภาพถ่ายสุนัข สายพันธุ์ไทยหลังอาน และบางแก้วโดยไม่เสียค่าใช้จ่าย ซึ่งเป็นข้อมูลหลักในการดำเนินการวิจัยในครั้งนี้ เพื่อให้แบบจำลองสามารถใช้ได้กับสุนัขสายพันธุ์ไทยได้ ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้

ขอขอบคุณ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ในการสนับสนุนทุนในการทำสารนิพนธ์นี้

ขอขอบคุณ คณาจารย์ทุกท่านในภาควิชาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ที่ให้ความรู้และแนวทางการทำสารนิพนธ์นี้

ขอขอบคุณ นายชิน เลิศวิภาดา ผู้ให้ความช่วยเหลือ ให้คำปรึกษา และมีส่วนร่วมในการจัดทำในส่วนจำแนกสายพันธุ์ของสุนัข และเพื่อนร่วมสาขาวิทยาการข้อมูล รุ่น 2564 ที่ให้ความช่วยเหลือ ให้ความร่วมมือ และให้คำแนะนำ ทั้งการเรียน และการจัดทำสารนิพนธ์มาโดยตลอด ทำให้การทำสารนิพนธ์เป็นไปอย่างราบรื่นและสำเร็จลุล่วงไปได้

และที่สำคัญขอขอบคุณ จากครอบครัว เพื่อน พี่น้อง และทุกท่านที่ไม่ได้เอ่ยนาม ที่ส่งกำลังใจ อีกทั้งให้คำปรึกษาทำให้สามารถดำเนินการทดลองได้อย่างราบรื่น

ณัฐกานต์ ท้าวพินวงศ์

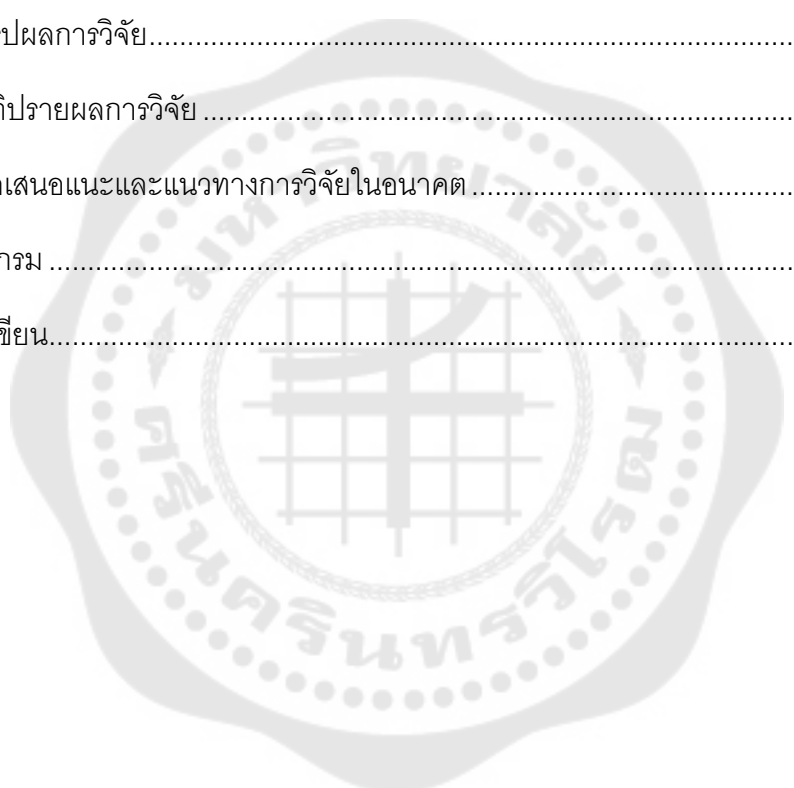
## สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	ง
บทคัดย่อภาษาอังกฤษ .....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ .....	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ .....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ภูมิหลัง .....	1
1.2 ความมุ่งหมายของงานวิจัย.....	3
1.3 ความสำคัญของงานวิจัย .....	3
1.4. ขอบเขตของงานวิจัย .....	4
1.4.1 ประชากรที่ใช้ในการวิจัย.....	4
1.4.2 กลุ่มตัวอย่างที่ใช้ในการวิจัย.....	4
1.4.3 ตัวแปรที่ศึกษา .....	5
1.5 กรอบแนวคิดการวิจัย .....	5
1.6 สมมุติฐานในการวิจัย.....	6
1.7 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย .....	6
บทที่ 2 ทบทวนวรรณกรรม.....	7
2.1 การเรียนรู้เชิงลึก (Deep Learning).....	8
2.1.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNNs).....	9



2.1.2 การถ่ายโยงการเรียนรู้ (Transfer Learning) .....	11
2.2 ทฤษฎีเกี่ยวกับไบโอเมตริกซ์ (Biometric).....	13
2.2.1 ประเภทของข้อมูลไบโอเมตริกซ์.....	13
2.2.2 การรู้จำใบหน้า.....	16
2.3 งานวิจัยที่เกี่ยวข้อง (Literature Review).....	18
บทที่ 3 วิธีดำเนินการวิจัย.....	29
3.1 การกำหนดประชากรและกลุ่มตัวอย่าง .....	29
3.1.1 ประชากร.....	29
3.1.2 กลุ่มตัวอย่าง.....	31
3.2 การออกแบบวิธีการดำเนินงานวิจัย และการแบ่งชุดข้อมูล .....	37
3.3 กระบวนการในการจำแนกสายพันธุ์ของสุนัข และประเมินประสิทธิภาพแบบจำลองในการ จำแนกสายพันธุ์ของสุนัข .....	39
3.4 กระบวนการในการระบุตัวตนของสุนัข และประเมินประสิทธิภาพแบบจำลองในการระบุ ตัวตน .....	42
บทที่ 4 ผลการดำเนินการวิจัย .....	45
4.1 ตัววัดประสิทธิภาพของแบบจำลองที่ใช้ในงานวิจัย .....	45
4.1.1 Confusion Matrix.....	45
4.1.2 Accuracy .....	46
4.1.3 Precision .....	46
4.1.4 Recall.....	47
4.1.5 F1-Score .....	47
4.1.6 Top-k Accuracy .....	47
4.2 ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกสายพันธุ์ ของสุนัข .....	48

4.3 ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในการระบุตัวตนของ สุนัข .....	61
4.3.1 ผลการตรวจจับใบหน้าสุนัข.....	61
4.3.2 ผลการทำ Data Augmentation .....	62
4.3.3 ผลการดำเนินการระบุตัวตนของสุนัข .....	63
บทที่ 5 สรุป อภิปรายผล และข้อเสนอแนะ .....	78
5.1 สรุปผลการวิจัย.....	78
5.2 อภิปรายผลการวิจัย .....	82
5.3 ข้อเสนอแนะและแนวทางการวิจัยในอนาคต .....	84
บรรณานุกรม .....	86
ประวัติผู้เขียน.....	91



## สารบัญตาราง

หน้า

ตาราง 1 ตารางเปรียบเทียบประสิทธิภาพจากงานวิจัยที่เกี่ยวข้อง .....	21
ตาราง 2 ตารางแสดงสายพันธุ์ และจำนวนรูปที่ใช้ในงานวิจัย จาก ฟาร์มสุนัขในประเทศไทย ....	31
ตาราง 3 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกสายพันธุ์ จาก ฟาร์มสุนัขในประเทศไทย แบ่งตามสายพันธุ์.....	32
ตาราง 4 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกสายพันธุ์ จาก ฟาร์มสุนัขในประเทศไทย ....	33
ตาราง 5 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกระบุตัวตน จาก ฟาร์มสุนัขในประเทศไทย แบ่งตามสายพันธุ์.....	35
ตาราง 6 ตารางแสดงจำนวนสุนัขที่ใช้ในการระบุตัวตน จาก ฟาร์มสุนัขในประเทศไทย .....	36
ตาราง 7 ตารางแสดงประสิทธิภาพของแบบจำลองที่นำมาใช้ในงานวิจัย จาก Keras.....	39
ตาราง 8 ตารางแสดงโครงสร้างแบบจำลองใหม่ที่สร้างขึ้น ในการจำแนกสายพันธุ์ของสุนัข .....	40
ตาราง 9 ตารางแสดงกระบวนการในการทำ Data Augmentation .....	43
ตาราง 10 ตารางแสดงโครงสร้างแบบจำลองใหม่ที่สร้างขึ้น ในการระบุตัวตน.....	44
ตาราง 11 ผลการทดลองการจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification).....	48
ตาราง 12 แสดงค่า Precision Recall และ F1-Score ของแบบจำลองที่ใช้ Pre-train Models เป็น NasNetLarge ร่วมกับแบบจำลองที่สร้างใหม่ และใช้รูปภาพ SF+Thai Dataset.....	50
ตาราง 13 ผลการตรวจจับใบหน้าของสุนัข จาก Thai Dataset .....	61
ตาราง 14 ตารางแสดงผลการทำ Data Augmentation .....	63
ตาราง 15 ตารางแสดงผลการทดลองการระบุตัวตนของสุนัข (Dog Identification) .....	64
ตาราง 16 แสดงผลการทดลองการระบุตัวตนของสุนัข (Dog Identification) แยกตามสายพันธุ์.65	
ตาราง 17 Confusion Matrix ของ สายพันธุ์ Pug จากการระบุตัวตนของสุนัข (MobileNetV2) ..	67
ตาราง 18 Confusion Matrix ของ สายพันธุ์ Husky จากการระบุตัวตนของสุนัข (MobileNetV2) .....	68

ตาราง 19 Confusion Matrix ของ สายพันธุ์ Bangkaew จากการระบุตัวตนของสุนัข (InceptionV3)	68
ตาราง 20 Confusion Matrix ของ สายพันธุ์ Ridgeback จากการระบุตัวตนของสุนัข (InceptionV3)	69



## สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 ตัวอย่างกระบวนการจำแนกประเภทของข้อมูล .....	7
ภาพประกอบ 2 โครงสร้างของ โครงข่ายประสาทเทียม .....	8
ภาพประกอบ 3 ความแตกต่างระหว่าง Machine Learning กับ Deep Learning .....	9
ภาพประกอบ 4 ตัวอย่างการคำนวณแบบคอนโวลูชัน .....	10
ภาพประกอบ 5 ส่วนประกอบ โครงข่ายประสาทเทียมแบบคอนโวลูชัน .....	10
ภาพประกอบ 6 การเปรียบเทียบระหว่าง Transfer Learning กับการใช้แบบจำลองแบบเดิม ....	12
ภาพประกอบ 7 ประเภทการทำ Transfer Learning .....	12
ภาพประกอบ 8 ตัวอย่าง Soft Biometric และ Hard Biometric ของสุนัข .....	13
ภาพประกอบ 9 ภาพแสดงลักษณะต่างๆ ของ Biometric .....	14
ภาพประกอบ 10 เปรียบเทียบ Biometric ชนิดต่างๆ กับคุณสมบัติของ Biometric ที่พึงประสงค์	15
ภาพประกอบ 11 ตัวอย่างการตรวจจับใบหน้า (Face Detection) จากกล้อง Webcam .....	16
ภาพประกอบ 12 ภาพกระบวนการทำการระบุตัวตนจากภาพใบหน้า .....	17
ภาพประกอบ 13 ภาพแสดง Timeline ของแต่ละแบบจำลอง .....	23
ภาพประกอบ 14 ภาพแสดงโครงสร้างชั้นของแบบจำลอง VGG16 .....	23
ภาพประกอบ 15 ภาพแสดงโครงสร้างชั้นของแบบจำลอง MobileNetV2 .....	24
ภาพประกอบ 16 ภาพแสดงโครงสร้างชั้นของแบบจำลอง InceptionV3 .....	25
ภาพประกอบ 17 ภาพแสดงโครงสร้างชั้นของแบบจำลอง Xception .....	26
ภาพประกอบ 18 ภาพแสดงโครงสร้างชั้นของแบบจำลอง ResNet50 .....	26
ภาพประกอบ 19 ภาพแสดงโครงสร้างชั้นของแบบจำลอง NasNetLarge .....	27
ภาพประกอบ 20 ภาพเปรียบเทียบประสิทธิภาพของแบบจำลองชนิดต่างๆ .....	28
ภาพประกอบ 21 ตัวอย่างรูปภาพ Stanford Dogs Dataset .....	29

ภาพประกอบ 22 ตัวอย่างรูปภาพจาก จาก Flickr-dog.....	30
ภาพประกอบ 23 ตัวอย่างภาพจากฟาร์มสุนัขในประเทศไทย .....	30
ภาพประกอบ 24 แสดงการใช้ชุดข้อมูลต่างๆ ในงานวิจัย .....	31
ภาพประกอบ 25 แสดงสายพันธุ์ และจำนวนรูปที่ใช้ในงานวิจัย จาก Stanford Dogs Dataset .	32
ภาพประกอบ 26 แสดงจำนวนสุนัขที่ใช้ จาก Flickr-dog .....	35
ภาพประกอบ 27 ภาพรวมของงานวิจัย.....	37
ภาพประกอบ 28 ตัวอย่างภาพที่เหมาะสมกับการนำมาทดลอง .....	38
ภาพประกอบ 29 ขั้นตอนในการจำแนกสายพันธุ์ของสุนัข .....	39
ภาพประกอบ 30 ขั้นตอนในการระบุตัวตน.....	42
ภาพประกอบ 31 ตาราง Confusion Matrix .....	46
ภาพประกอบ 32 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (SF only) .....	55
ภาพประกอบ 33 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (SF+Thai).....	55
ภาพประกอบ 34 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (SF only) .....	56
ภาพประกอบ 35 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (SF+Thai).....	56
ภาพประกอบ 36 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2(SF only).....	57
ภาพประกอบ 37 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (SF+Thai).....	57
ภาพประกอบ 38 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (SF only).....	58

ภาพประกอบ 39 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (SF+Thai) .....	58
ภาพประกอบ 40 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ Xception (SF only) .....	59
ภาพประกอบ 41 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ Xception (SF+Thai) .....	59
ภาพประกอบ 42 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (SF only) .....	60
ภาพประกอบ 43 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (SF+Thai) .....	60
ภาพประกอบ 44 ภาพการตรวจจับใบหน้าของสุนัขด้วย Dlib Library v19.4 .....	61
ภาพประกอบ 45 ลักษณะรูปภาพที่ไม่สามารถตรวจจับใบหน้าได้.....	62
ภาพประกอบ 46 ภาพต้นฉบับ และภาพหลังจากทำ Data Augmentation.....	63
ภาพประกอบ 47 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (Weight = ImageNet) .....	70
ภาพประกอบ 48 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (Weight = ImageNet +Data Augmentation) .....	70
ภาพประกอบ 49 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (Weight = ImageNet).....	71
ภาพประกอบ 50 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (Weight = ImageNet + Data Augmentation).....	71
ภาพประกอบ 51 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (Weight = ImageNet) .....	72
ภาพประกอบ 52 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (Weight = ImageNet + Data Augmentation) .....	72

ภาพประกอบ 53 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (Weight = ImageNet)..... 73

ภาพประกอบ 54 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (Weight = ImageNet + Data Augmentation)..... 73

ภาพประกอบ 55 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง ResNet50 ..... 74

ภาพประกอบ 56 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง ResNet50 (Data Augmentation) ..... 74

ภาพประกอบ 57 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (Weight = ImageNet)..... 75

ภาพประกอบ 58 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (Weight = ImageNet + Augmentation) ..... 75

ภาพประกอบ 59 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง VGG16 ..... 76

ภาพประกอบ 60 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง VGG16 (Data Augmentation) ..... 76

ภาพประกอบ 61 กราฟแสดงสรุปผลการจำแนกสายพันธุ์ของสุนัข..... 79

ภาพประกอบ 62 กราฟแสดงสรุปผลการระบุตัวตนของสุนัข..... 80

ภาพประกอบ 63 กราฟแสดงสรุปผลการระบุตัวตนของสุนัขและใช้ชุดข้อมูลที่มีการทำ Data Augmentation ..... 80

ภาพประกอบ 64 กราฟแสดงสรุปผลการระบุตัวตนของสุนัข แยกตามสายพันธุ์..... 81

ภาพประกอบ 65 กราฟแสดงสรุปผลการระบุตัวตนของสุนัขและใช้ชุดข้อมูลที่มีการทำ Data Augmentation แยกตามสายพันธุ์..... 81



## บทที่ 1

### บทนำ

#### 1.1 ภูมิหลัง

มนุษย์กับสุนัขถือเป็นสิ่งมีชีวิตที่มีความผูกพันกันเป็นเวลายาวนาน ซึ่งมนุษย์ได้เริ่มมีการนำสุนัขมาเป็นสัตว์เลี้ยงตั้งแต่ 12,000 ปีที่แล้ว (กมลพรรณ ประเสริฐสังข์, 2546) โดยสุนัขเป็นสัตว์หรือสิ่งมีชีวิตที่ชอบแสดงความรักต่อเจ้าของ มีความน่ารัก มีลักษณะของสายพันธุ์ที่แตกต่างกัน ทั้งขนสั้นและขนยาว รวมไปถึงขนาดที่หลากหลาย แต่สุนัขทุกสายพันธุ์จะมีลักษณะพิเศษที่เหมือนกันคือสามารถปรับตัวให้เข้ากับมนุษย์หรือเจ้าของได้เป็นอย่างดี เรียกได้ว่าสุนัขจะมีบุคลิกหรือพฤติกรรมบางอย่างที่เหมือนกับเจ้าของที่เลี้ยงนั่นเอง (อาภรณ์ รัชไชย, 2560) เพราะสุนัขมีความสามารถในการเรียนรู้ต่อสิ่งเร้ารอบตัวได้และสุนัขยังเป็นสัตว์ที่สามารถรับรู้ในด้านของอารมณ์และความรู้สึกของเจ้าของได้ดีอีกด้วย ผู้คนทั่วโลกจึงนิยมเลี้ยงสุนัขเป็นสัตว์เลี้ยงหรือเป็นเพื่อนหรือเอาไว้เฝ้าบ้านกันอย่างมากมาย

ในปัจจุบันจำนวนผู้เลี้ยงสุนัขเพิ่มสูงขึ้นตามสัดส่วนของจำนวนประชากรมนุษย์ โดยส่วนใหญ่เจ้าของไม่มีความเข้าใจในลักษณะการเลี้ยงสุนัขอย่างเหมาะสม รวมไปถึงไม่มีความพร้อมในด้านต่างๆ อีกทั้งสุนัขเป็นสัตว์เลี้ยงที่มีการแพร่พันธุ์กันอย่างง่าย และไม่ได้รับการคุมกำเนิดที่ถูกต้องทำให้จำนวนประชากรสุนัขเพิ่มขึ้นอย่างรวดเร็วโดยเจ้าของไม่สามารถเลี้ยงสุนัขที่เกิดใหม่ได้ทุกๆ ตัว ทำให้เกิดการนำสุนัขมาทิ้งตามสถานที่ต่างๆ เช่น สวนสาธารณะ วัด โรงเรียน แหล่งชุมชนต่างๆ และบางตัวเกิดการพลัดหลงกับเจ้าของ จึงเป็นต้นกำเนิดของปัญหาที่ตามมา คือ ปัญหาสุนัขจรจัดหรือสุนัขไม่มีเจ้าของ

ปัญหาสุนัขจรจัดถือเป็นปัญหาที่สำคัญมาก ซึ่งประเทศไทยพบสุนัขไม่มีเจ้าของสูงถึง 7 แสนตัว จากจำนวนสุนัขทั้งหมดมากกว่า 8.8 ล้านตัว และมีแนวโน้มจะเพิ่มสูงขึ้นอย่างต่อเนื่อง (สำนักงานปศุสัตว์เขต 9 กรมปศุสัตว์, 2565) โดยในยุคปัจจุบันที่มีการแพร่ระบาดของเชื้อโควิด19 ทำให้เจ้าของสุนัขต่างหวาดระแวงว่าตนหรือคนในครอบครัวจะได้รับการติดเชื้อจากการเล่นกับสุนัข รวมไปถึงเกิดปัญหาสภาพคล่องทางเศรษฐกิจ ทำให้ในช่วง 2 ปีที่ผ่านมาี้มีจำนวนสุนัขที่ถูกทอดทิ้งในประเทศไทยเพิ่มมากขึ้น (องค์กรพิทักษ์สัตว์แห่งโลก, 2563) โดยปัญหานี้ถือเป็นปัญหาระดับชาติที่ไม่สามารถแก้ไขได้เพียงหน่วยงานใดหน่วยงานหนึ่ง จึงมีหน่วยงานต่างๆ ที่เกี่ยวข้องพยายามหาร่วมกันเพื่อหาแนวทางในการแก้ไขปัญหาและปัญหานี้เป็นปัญหาที่สามารถส่งผลกระทบต่อในด้านต่างๆ มากมาย เช่น สร้างความรำคาญจากกลิ่นหรือเสียงของสุนัข การขบถ่ายไม่เป็นที่การที่ทำความเดือดร้อนแก่คนทั่วไป รวมไปถึงการแพร่กระจายของ

โรคระบาดต่างๆ เช่น โรคพิษสุนัขบ้าที่สามารถติดต่อจากสัตว์สู่คนได้ ซึ่งหากสุนัขที่ติดเชื้อและมีการแพร่เชื้อสู่คนนอกจากจะทำให้สุนัขตายแล้วยังมีโอกาสทำให้ผู้ที่ถูกสุนัขกัดเสียชีวิตได้ สาเหตุส่วนหนึ่งของปัญหาสุนัขจรจัดมาจากการทอดทิ้งสุนัขกลายเป็นสุนัขไม่มีเจ้าของ จึงทำให้ไม่มีผู้ดูแลเลี้ยงดูอย่างเหมาะสม และไม่มีการคุมกำเนิดของสุนัข จึงทำให้หน่วยงานที่เกี่ยวข้องไม่สามารถควบคุมจำนวนประชากรของสุนัข และควบคุมโรคได้อย่างทันทั่วถึง โดยวิธีการแก้ปัญหาดังกล่าวมีหลากหลายวิธี ทั้งการคุมกำเนิดสุนัขจรจัด การหาบ้านให้สุนัขที่พลัดหลง แต่อีก 1 วิธี ที่ถือว่าเป็นวิธีเหมาะกับยุคสมัยในปัจจุบันที่มีการใช้งานกล้องหรือโทรศัพท์มือถือกันอย่างแพร่หลายและใช้ค่าใช้จ่ายไม่สูง คือ การระบุตัวตนของสุนัขแต่ละตัว เพื่อเก็บรวบรวมข้อมูลประจำตัวสุนัขหรือข้อมูลที่เกี่ยวข้องกับสุนัขแต่ละตัวในประเทศ นำมาจัดเก็บเป็นฐานข้อมูลสุนัขในประเทศไทยจะทำให้สามารถนำข้อมูลไปบริหารจัดการได้อย่างมีประสิทธิภาพ ทำให้สามารถแก้ไขปัญหาต่างๆ ได้ตรงจุดมากยิ่งขึ้น

ในปัจจุบันสุนัขจะสามารถระบุตัวตนได้ จากการใช้ปลอกคอ ผังไมโครชิพ หรือใช้ Tag GPS ติดตามตัว แต่ด้วยราคาที่สูง และอุปกรณ์เสี่ยงต่อการสูญหายหรือเสียหาย ทำให้ไม่เป็นที่ได้รับความนิยม รวมไปถึงสุนัขจรจัดก็เช่นกัน เพราะไม่มีผู้ดูแลหรือเจ้าของจึงไม่มีการติดตั้งอุปกรณ์ใดๆ ที่จะสามารถระบุตัวตนสุนัขเหล่านั้นได้ แต่หากสุนัขทุกตัวสามารถระบุตัวตนได้ จะสามารถทราบข้อมูลประจำตัวต่างๆ เช่น ชื่อเจ้าของ ที่อยู่ ข้อมูลติดต่อเจ้าของ หรือแม้แต่ข้อมูลประวัติด้านสุขภาพของสุนัข เช่น การฉีดวัคซีนป้องกันโรคต่างๆ ซึ่งเจ้าของจะสามารถดูแลสุนัขได้อย่างเหมาะสม สัตวแพทย์ที่ทำการรักษาจะสามารถทราบถึงข้อมูลด้านสุขภาพได้อย่างชัดเจน บุคคลทั่วไปจะสามารถนำสุนัขส่งคืนเจ้าของได้อย่างถูกต้องหรือจะสามารถทราบได้ว่าสุนัขตัวนั้นมีความปลอดภัยจากโรคระบาดต่างๆ หรือไม่ รวมไปถึงหน่วยงานของรัฐจะสามารถมีข้อมูลเพื่อนำมาบริหารจัดการการแก้ไขปัญหา การควบคุม และการจัดระเบียบการเลี้ยงสุนัขมีประสิทธิภาพมากขึ้น

ในงานวิจัยนี้ เราได้นำวิธีการที่เรียกว่า การรู้จำใบหน้า (Face Recognition) มาใช้งานกับรูปภาพของใบหน้าของสุนัขเพื่อระบุตัวตนของสุนัขแต่ละตัวโดยไม่ต้องติดตั้งอุปกรณ์ เพียงนำกล้องถ่ายภาพใบหน้าสุนัขก็จะสามารถทราบข้อมูลประจำตัวของสุนัขได้ทันที ซึ่งภาพใบหน้าของสุนัข ถือเป็นหนึ่งในลักษณะทางกายภาพ หรือ Hard Biometrics ที่น่าสนใจ เพราะเป็นข้อมูลที่ปลอมแปลงได้ยากและมีความเฉพาะเจาะจง สำหรับการใช้ตรวจสอบและระบุตัวตน โดยกระบวนการมีทั้งหมด 2 ส่วนประกอบหลักๆ คือ การจำแนกสายพันธุ์ของสุนัข เพื่อให้ลดพื้นที่ในการค้นหาของขั้นตอนถัดไป และทำการตรวจสอบใบหน้าเปรียบเทียบกับ

กับข้อมูลในฐานะข้อมูลว่าเป็นสุนัขตัวใด และทำการแสดงข้อมูลของสุนัขตัวดังกล่าว นอกจากนี้ยังสามารถนำวิธีการเหล่านี้ไปประยุกต์ใช้ร่วมกับสัตว์ชนิดอื่นๆ ได้ เช่น แมว โค กระบือ แพะ แกะ เป็นต้น

## 1.2 ความมุ่งหมายของงานวิจัย

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายที่จะสร้างแบบจำลองการจำแนกสายพันธุ์และการระบุตัวตนสุนัขด้วยภาพแบบโครงข่ายประสาทเทียม ชนิด MLP (Multi-layer Perceptron) โดยอาศัย Pre-train Models จาก CNNs (Convolutional Neural Network) ชนิดต่างๆ ในการสกัดเวกเตอร์ทางคุณลักษณะของภาพ โดยแบบจำลองดังกล่าวประกอบด้วยชั้นตอนสำคัญสองชั้นตอน ดังนี้

1. การสร้างแบบจำลองเพื่อการจำแนกสายพันธุ์ของสุนัขด้วยภาพถ่ายทั้งสายพันธุ์ต่างประเทศและสายพันธุ์ไทยรูปแบบต่างๆ และทดสอบประสิทธิภาพแบบจำลองที่สร้างขึ้น เพื่อหาแบบจำลองที่ได้ประสิทธิภาพดีที่สุด สำหรับการจำแนกสายพันธุ์ของสุนัขด้วยภาพถ่าย ทั้งสายพันธุ์ต่างประเทศ และสายพันธุ์ไทย

2. การสร้างแบบจำลองเพื่อการระบุตัวตนของสุนัขจากภาพใบหน้า ทั้งสายพันธุ์ต่างประเทศและสายพันธุ์ไทยในรูปแบบต่างๆ โดยอาศัยข้อมูลสายพันธุ์ที่ได้จากแบบจำลองในข้อ 1 เป็น Soft Biometric และทดสอบประสิทธิภาพแบบจำลองที่สร้างขึ้น เพื่อหาแบบจำลองที่ได้ประสิทธิภาพดีที่สุด สำหรับการระบุตัวตนของสุนัขจากภาพใบหน้าของสุนัขทั้งสายพันธุ์ต่างประเทศ และสายพันธุ์ไทย และเพื่อศึกษาการตรวจจับใบหน้าสุนัข โดยใช้ Dlib Library v19.4 (Mlachynska, Oplatkova, & Turecek, 2019) เมื่อมาใช้กับชุดข้อมูลที่เป็นสายพันธุ์ประเทศไทย เพื่อให้ได้ข้อมูลใบหน้าสุนัขสำหรับการระบุตัวตน

## 1.3 ความสำคัญของงานวิจัย

1.3.1 เทคนิคการจำแนกสายพันธุ์สุนัขทั้งสายพันธุ์ต่างประเทศและสายพันธุ์ไทยที่ได้จากผลการวิจัยครั้งนี้ สามารถเป็นแนวทางในการนำไปประยุกต์ใช้กับชุดข้อมูลสุนัขสายพันธุ์อื่นๆ และภาพใบหน้าของสัตว์ชนิดอื่นๆ ได้

1.3.2 เทคนิคการระบุตัวตนสุนัขที่ได้จากผลการวิจัยครั้งนี้ สามารถนำไปใช้เป็นแนวทางในการแก้ไขปัญหาสุนัขจรจัด สุนัขไม่มีเจ้าของ และปัญหาต่างๆ ที่เกิดขึ้นจากสุนัขที่ไม่สามารถระบุตัวตนได้ ทำให้ประหยัดค่าใช้จ่ายในการดูแล ทราบถึงสุขภาพสุนัขเหล่านี้ และบริหารจัดการภาพรวมของสุนัขภายในประเทศได้อย่างมีประสิทธิภาพ

## 1.4. ขอบเขตของงานวิจัย

### 1.4.1 ประชากรที่ใช้ในการวิจัย

แบ่งเป็น 3 ชุดข้อมูล ได้แก่

1. Stanford Dogs Dataset (Khosla, Jayadevaprakash, Yao, & Li, 2011) ภาพสุนัขจำนวน 20,580 รูปภาพ โดยแยกตามสายพันธุ์ทั้งหมด 120 สายพันธุ์ ใช้สำหรับการจำแนกสายพันธุ์ของสุนัข

2 . Flickr-dog (Pinheiro Moreira, Lisboa Perez, de Oliveira Werneck, & Valle, 2015) รวมทั้งหมด 374 รูปภาพ จำนวน 42 ตัว ตัวละอย่างน้อย 5 รูปภาพ โดยเป็นสุนัข 2 สายพันธุ์ ได้แก่ Husky และ Pug ใช้สำหรับการระบุตัวตนของสุนัข

3. รูปภาพจากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม ภาพสุนัขจำนวน 369 รูปภาพ โดยแยกตามสายพันธุ์ ทั้งหมด 2 สายพันธุ์ ได้แก่ บางแก้ว (Bangkaew) จำนวน 186 รูป และหลังอาน (Ridgeback) 183 รูป

### 1.4.2 กลุ่มตัวอย่างที่ใช้ในการวิจัย

แบ่งกลุ่มตัวอย่างเป็น 2 ส่วน ได้แก่

1. การจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification) ใช้รูปภาพสุนัขทั้งหมดจำนวน 20,949 รูปภาพ โดยใช้รูปภาพจาก 2 แหล่งที่มา ได้แก่

- **สายพันธุ์ต่างประเทศ** จาก Stanford Dogs Dataset (Khosla et al., 2011) ภาพสุนัขจำนวน 20,580 รูปภาพ มีทั้งหมด 120 สายพันธุ์ สายพันธุ์ละ อย่างน้อย 140 รูปภาพ

- **สายพันธุ์ไทย** จากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม รูปภาพสุนัขจำนวน 369 รูปภาพ ทั้งหมด 2 สายพันธุ์ สายพันธุ์บางแก้ว จำนวน 186 รูป และสายพันธุ์หลังอาน 183 รูป

2. การระบุตัวตนของสุนัข (Dog Identification) และการตรวจจับใบหน้าของสุนัข (Face Dog Detection) ใช้รูปภาพสุนัขที่แยกตามชื่อรายตัว จำนวนทั้งหมด 62 ตัว มีรูปภาพทั้งหมด 500 รูปภาพ โดยใช้รูปภาพจาก 2 แหล่งที่มา ได้แก่

- **สายพันธุ์ต่างประเทศ** ใช้ Flickr-dog (Pinheiro Moreira et al., 2015) จำนวน 374 รูปภาพ เป็นสุนัขจำนวน 42 ตัว อย่างน้อยตัวละ 5 รูป จากสายพันธุ์ Husky และ Pug โดยมีการระบุชื่อสุนัขแต่ละตัว

- **สายพันธุ์ไทย** รูปภาพจากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม จำนวน 126 รูปภาพ เป็นสุนัข 20 ตัว อย่างน้อยตัวละ 5 รูป จากสายพันธุ์บางแก้ว 10 ตัว และสายพันธุ์หลังอาน 10 ตัว

#### 1.4.3 ตัวแปรที่ศึกษา

**ตัวแปรต้น** รูปภาพสุนัข

**ตัวแปรตาม** สายพันธุ์ของสุนัข และ ตัวตนของสุนัข

- การจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification) ใช้รูปภาพสุนัขทั้งหมด 122 สายพันธุ์ โดยใช้ทั้งรูปภาพที่เป็นสายพันธุ์ต่างประเทศรวมกับสายพันธุ์ไทย

- การตรวจจับใบหน้าของสุนัข (Face Dog Detection) ใช้รูปภาพสุนัข ทั้งหมด 2 สายพันธุ์ จากฟาร์มสุนัขในประเทศไทย ที่เป็นรูปภาพที่ยังไม่ได้ทำการใดๆ เพื่อทดสอบการตรวจจับใบหน้าของสุนัข และทำการเตรียมข้อมูลรูปภาพ เพื่อจัดการในขั้นตอนต่อไป

- การระบุตัวตนของสุนัข (Dog Identification) ใช้รูปภาพสุนัขที่แยกตามชื่อ จำนวน 62 ตัว จาก 2 สายพันธุ์ต่างประเทศ คือ Husky และ Pug ที่เป็นรูปภาพที่ยังมีการตรวจจับครอบตัด เฉพาะใบหน้า ปรับขนาด และหมุนองศาแล้ว และจาก 2 สายพันธุ์ไทย ที่ได้มาจากขั้นตอนตรวจจับใบหน้าของสุนัข คือ บางแก้ว และหลังอาน

#### 1.5 กรอบแนวคิดการวิจัย

แนวคิดในการวิจัยในงานวิจัยนี้คือการนำกระบวนการ Image Processing โดยใช้ Deep Learning มาช่วยงานในการจำแนกสายพันธุ์ของสุนัขทั้งต่างประเทศและในประเทศไทย รวมทั้งการระบุตัวตนของสุนัขจากภาพใบหน้า เพื่อแก้ปัญหาด้านสุนัขจรจัด เพิ่มประสิทธิภาพในการจัดเก็บข้อมูลสุนัขในประเทศไทยและเพื่อนำข้อมูลที่ได้ไปใช้ประโยชน์ในการบริหารจัดการการเลี้ยงสุนัขภายในประเทศไทย และแนวคิดนี้ได้มาจากการศึกษาแนวคิด และทฤษฎีที่เกี่ยวข้องกับการระบุตัวตนของสุนัข

การศึกษาในครั้งนี้ผู้วิจัยจะทำการนำรูปภาพสุนัขทั้งหมด 20,949 รูปภาพ มาทำการจำแนกสายพันธุ์ของสุนัข เพื่อจำกัดขอบเขตในการค้นหาข้อมูลเพื่อการระบุตัวตนสุนัขในขั้นตอนต่อไป ซึ่งเป็นรูปภาพที่แยกตามสายพันธุ์โดยมีจำนวนทั้งหมด 122 สายพันธุ์ เป็นสายพันธุ์ต่างประเทศ 120 สายพันธุ์ และสายพันธุ์ในประเทศไทย 2 สายพันธุ์ จากนั้นใช้รูปภาพอีกชุดข้อมูลจำนวน 374 รูปภาพ สำหรับใช้ในการระบุตัวตน ซึ่งเป็นรูปภาพที่มีการแบ่งแยกเป็นสุนัขรายตัว มีการครอบตัด เฉพาะใบหน้าของสุนัข ปรับขนาดรูปภาพ และหมุนองศาให้ตรงเรียบร้อยแล้ว โดยเป็นสุนัขสายพันธุ์ husky และ pug ซึ่งในการวิจัยครั้งนี้ผู้วิจัยได้เพิ่มสุนัขสายพันธุ์ไทย ได้แก่ บางแก้ว

และหลังอ่าน อีกจำนวน 126 รูปภาพเพื่อทดสอบประสิทธิภาพในการใช้งานกับรูปภาพสุนัขสายพันธุ์ของประเทศไทย และขั้นตอนสุดท้ายคือการทดสอบประสิทธิภาพความแม่นยำในแต่ละขั้นตอนซึ่งเปรียบเทียบระหว่างค่าความแม่นยำของแบบจำลอง จาก CNNs (Convolutional Neural Network) จำนวน 6 models ได้แก่ ResNet50 VGG16 MobileNetV2 Xception InceptionV3 และ NasNetLarge กับแบบจำลองที่ผู้วิจัยได้ทำการปรับปรุง โดยอาศัย Pre-train Models จากทั้ง 6 แบบจำลองที่กล่าวข้างต้น ในการสกัดเวกเตอร์ทางคุณลักษณะของภาพ เพื่อเป็นแนวทางในการนำไปต่อยอดในอนาคต นอกจากนี้ยังมีการนำแบบจำลองที่ใช้สำหรับการรู้จำใบหน้า (Face Recognition) หรือสร้างจากชุดข้อมูลใบหน้าคน ได้แก่ VGGFace โดยอาศัยโครงสร้างของ ResNet50 และ VGG16 มาใช้ เพื่อเพิ่มตัวเลือกในการเปรียบเทียบประสิทธิภาพสำหรับการระบุตัวตนสุนัข

## 1.6 สมมุติฐานในการวิจัย

1.6.1 การนำ Pretrained CNNs (Convolutional Neural Network) model ชนิดต่างๆ มาใช้ในการสกัด Feature Vector เพื่อใช้เป็นข้อมูล Input ในการสร้างแบบจำลองโครงข่ายประสาทเทียมแบบ MLP (Multi Layer Perceptron) บนชุดข้อมูลภาพสุนัขสายพันธุ์ต่าง ๆ โดยตรง จะทำให้ได้แบบจำลองการจำแนกสายพันธุ์สุนัขที่มีประสิทธิภาพดีกว่าแบบจำลองต้นแบบที่สร้างจากชุดข้อมูล ImageNet ที่มีทั้ง ภาพสุนัขสายพันธุ์ต่าง ๆ และ ภาพวัตถุอื่น ๆ จำนวนรวม 1,000 ชนิด

1.6.2 Pretrained CNNs (Convolutional Neural Network) model ที่สร้างจากชุดข้อมูลใบหน้าคน สามารถนำมาใช้ในการสกัด Feature Vector เพื่อใช้เป็นข้อมูล Input ในการฝึกแบบจำลองโครงข่ายประสาทเทียมแบบ MLP (Multi Layer Perceptron) เพื่อการระบุตัวตนสุนัขที่มีประสิทธิภาพดีกว่า Pretrained CNNs (Convolutional Neural Network) model ที่สร้างจากชุดข้อมูล ImageNet

## 1.7 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

1.7.1 ได้แบบจำลองการจำแนกสายพันธุ์สุนัขและการระบุตัวตนสุนัขต้นแบบที่สามารถนำไปใช้ในการจำแนกสายพันธุ์สุนัขและการระบุตัวตนของสุนัข เพื่อลดค่าใช้จ่ายในการติดตั้งอุปกรณ์ในการระบุตัวตนสุนัขจรจัด หรือสุนัขที่ไม่มีเจ้าของได้

1.7.2 รูปแบบการสร้างแบบจำลองการจำแนกสายพันธุ์สุนัขและการระบุตัวตนสุนัข ที่สามารถนำไปใช้ในการสร้างแบบจำลอง เพื่อการจำแนกสายพันธุ์สัตว์อื่น ๆ หรือการระบุตัวตนของสัตว์ชนิดอื่น ๆ ได้

## บทที่ 2

### ทบทวนวรรณกรรม

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาเอกสารและงานวิจัยที่เกี่ยวข้อง และได้นำเสนอตามหัวข้อต่อไปนี้

1. ทฤษฎีเกี่ยวกับการเรียนรู้เชิงลึก (Deep Learning)
2. ทฤษฎีเกี่ยวกับไบโอเมตริกซ์ (Biometric)
3. งานวิจัยที่เกี่ยวข้อง (Literature Review)

ในงานวิจัยนี้ได้มีการนำหลักการของการจำแนกประเภทข้อมูลมาใช้ในการจำแนกสายพันธุ์ของสุนัข ซึ่งเป็นการระบุหรือจำแนกประเภทของข้อมูลต่างๆ ที่มีคุณสมบัติบางอย่างที่คล้ายคลึงกัน เพื่อให้ข้อมูลแบ่งเป็นกลุ่มย่อย ทำให้สามารถนำไปใช้งานในขั้นตอนต่อไปได้อย่างมีประสิทธิภาพ โดยการจำแนกประเภทนี้ สามารถจำแนกได้ทั้งข้อมูลที่เป็น ข้อมูลโครงสร้าง ข้อมูลรูปภาพ และอื่นๆ และจำแนกได้ทั้ง คน สัตว์ หรือสิ่งของต่างๆ อีกด้วย โดยวิธีการจำแนกข้อมูลขึ้นอยู่กับงานที่เกี่ยวข้อง เช่น จำแนกตามโครงสร้าง จำแนกตามลักษณะ จำแนกตามรูปร่าง จำแนกตามชนิดของสิ่งนั้น จำแนกตามสถานที่ หรือจำแนกตามช่วงเวลา

อีกทางหนึ่งในการจำแนกประเภทของข้อมูล สามารถประยุกต์ใช้ได้ในการทำงานด้านวิทยาการข้อมูล คือ การสร้างแบบจำลอง สำหรับการจำแนกประเภทข้อมูล (Classifier) เพื่อทำนายว่าข้อมูลที่นำเข้ามาในระบบนั้นจัดอยู่ในหมวดหมู่ใด เช่น การจำแนกสายพันธุ์ดอกไม้ การจำแนกประเภทอุบัติเหตุ การจำแนกข้อความที่เป็นเชิงลบหรือเชิงบวก เป็นต้น โดยสามารถจำแนกได้ตั้งแต่ 2 class เป็นต้นไป โดยการจำแนกข้อมูล มีข้อมูลทั้งหมด 2 ส่วน คือ ส่วนของคุณสมบัติ หรือ Feature และ ส่วนของผลลัพธ์ หรือ Label เพื่อให้แบบจำลองสามารถเรียนรู้จากข้อมูล และแสดงผลลัพธ์ในการจำแนกประเภทของข้อมูล (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)




ภาพประกอบ 1 ตัวอย่างกระบวนการจำแนกประเภทของข้อมูล

ข้อคำนึงสำคัญในการจำแนกประเภทของข้อมูล คือการเตรียมข้อมูลหรือทำความสะอาดข้อมูล หากข้อมูลมีการขาดหายควรเติมให้ครบถ้วน และหาก Feature ใดที่มีความสอดคล้องกับบาง Feature มากเกินไป สามารถเลือกใช้เพียง Feature เดียวได้ เพื่อลดน้ำหนักที่จะทำให้แบบจำลองเรียนรู้ผิดพลาด รวมไปถึงการแปลง Feature ต่างๆ ให้อยู่ในรูปแบบเดียวกัน ที่มีค่าไม่ต่างกันมากจนเกินไป

## 2.1 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้แบบอัตโนมัติเป็นส่วนหนึ่งของ Machine Learning แต่จะเป็นลักษณะเลียนแบบการทำงานของเซลล์ประสาทจริง (Biological neuron) ในสมองของมนุษย์ ซึ่งในทางคอมพิวเตอร์เซลล์ประสาทที่สร้างขึ้นว่า ประสาทเทียม (ผศ.ดร.กอบเกียรติ สระอุบล, 2565) โดยภายในร่างกายของมนุษย์มีเซลล์ประสาท (Neuron) จำนวนมากมายมหาศาล แต่แต่ละเซลล์จะเรียกว่า Neuron การที่คอมพิวเตอร์มีการจำลอง Neuron หลายตัวทำงานร่วมกันเป็นเครือข่าย เรียกว่า โครงข่ายประสาทเทียม (Neural Network) และการที่ Neural Network หลายๆ Layer มาต่อกัน เรียกว่า **Multi-Layer Perceptron (MLP)** โดยที่ Perceptron คือหน่วยของ Neuron ในโครงข่ายประสาทเทียม ดังภาพประกอบ 2 Layer แรก เรียกว่า **Input Layer** เป็น Layer ที่ทำหน้าที่รับข้อมูลเข้ามาในโครงข่าย เช่น ค่า Feature ต่างๆ Layer ต่อมา คือ **Hidden Layer** เป็น Layer เปรียบเสมือนเซลล์ประสาท (Neural) ที่ทำหน้าที่ประมวลผล โดยสามารถเพิ่มปัจจัยในการประมวลผลได้ ส่วนนี้จะเรียกว่า **Activation Function** และส่งข้อมูลไปยัง Layer ชั้นต่อไป และ Layer สุดท้าย คือ **Output Layer** ซึ่งจะรับข้อมูลมาและแสดงผลลัพธ์ของการดำเนินการหรือสิ่งที่เราต้องการ ซึ่งแต่ละระบบจะมีจำนวน Hidden Layer ที่แตกต่างกันตามความเหมาะสมที่ทำให้การทำงานของคอมพิวเตอร์ในการเรียนรู้มีประสิทธิภาพเพิ่มมากขึ้น




ภาพประกอบ 2 โครงสร้างของ โครงข่ายประสาทเทียม

ที่มา : (Heipke & Rottensteiner, 2020)



โดยความแตกต่างระหว่าง Machine Learning กับ Deep Learning ตามภาพประกอบ 3 การจำแนกรถและไม่ใช้รถ โดย Machine Learning เมื่อมีการนำเข้าข้อมูลแล้ว นักวิทยาการข้อมูล หรือ Data scientist จะทำการ Feature Extraction หรือ การแปลงข้อมูลให้อยู่ในรูปแบบที่ต้องการเพื่อนำไปใช้ต่อ แล้วจึงทำการจำแนก (Classification) และจึงได้ผลลัพธ์ออกมา ในส่วน Deep Learning ในส่วนของการทำ Feature Extraction และ Classification จะอยู่ใน Hidden Layer ซึ่งจะเป็นกระบวนการที่ดำเนินการโดยเครื่องคอมพิวเตอร์ และส่งผลลัพธ์ออกมา



ภาพประกอบ 3 ความแตกต่างระหว่าง Machine Learning กับ Deep Learning

ที่มา : (softwaretestinghelp, 2022)

### 2.1.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNNs)

เป็น Deep Learning ที่มี Neural Network หลายๆ ตัวต่อกัน ถูกออกแบบมาเพื่อเพิ่มประสิทธิภาพในการสกัดคุณสมบัติจากข้อมูลที่น่าเข้ามาและมีความซับซ้อน มักจะใช้กับข้อมูลที่เป็นรูปภาพ โดยจำลองการมองเห็นของมนุษย์ที่จะมองเป็นส่วนหรือพื้นที่ย่อยๆ แล้วจึงตัดสินใจ โดย CNNs จะมีการนำ kernel หรือ filter มาใช้ ทำการดึงลักษณะเด่นของของรูปภาพแต่ละส่วนแล้วนำมาเปรียบเทียบ เพื่อการพยากรณ์ในส่วนของผลลัพธ์

**คอนโวลูชัน (Convolution)** เป็นเทคนิคเพิ่มประสิทธิภาพโดยใช้ Mask/window/kernel นำมา Dot Product กับ พื้นที่ส่วนย่อยของรูปภาพที่เราสนใจ เพื่อดึงลักษณะเด่นของรูปภาพออกมา (Feature Extraction) โดย kernel ที่นำมาใช้จะมีลักษณะเป็นเมทริกซ์จัตุรัส (KRAINET, 2562) โดยสมการของ คอนโวลูชัน ดังสมการที่ 1 และ 2


$$G = h * F \tag{1}$$

$$G[i, j] = \sum_{u=-k}^k \sum_{v=0}^n h[u, v] F[i - u, j - v] \tag{2}$$

โดย  $h$  = รูปภาพ

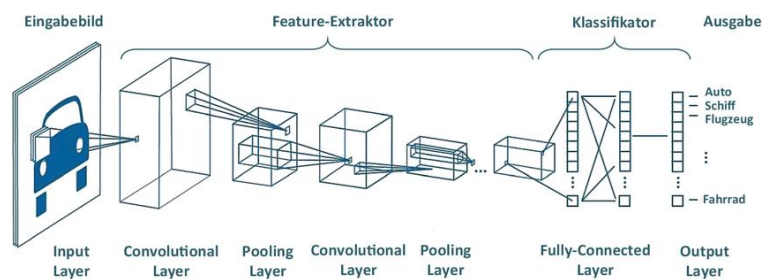
$F$  = kernel มีขนาดเท่ากับ  $k * k$

ซึ่งตัวอย่างการคำนวณ มีดังภาพประกอบ 4 โดยวิธีการคำนวณจะเริ่มที่ละ 3x3 ช่อง โดยจะนำ kernel มาทำการ Dot Product กันและนำผลลัพธ์มารวมกัน เช่น 3x3 ส่วนแรก จะคำนวณได้ดังนี้  $(3*1)+(1*-1)+(1*1)+(7*-1)+(2*1)+(5*-1) = -7$



ภาพประกอบ 4 ตัวอย่างการคำนวณแบบคอนโวลูชัน

ส่วนประกอบของโครงข่ายประสาทเทียมแบบคอนโวลูชัน 2 ส่วน คือ Feature Learning และ Classification ดังภาพประกอบ 5 และมี Layer ต่างๆ ดังนี้



ภาพประกอบ 5 ส่วนประกอบ โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ที่มา : (Zschech, Sager, Siebers, & Pertermann, 2021)

1. Convolution Layer ทำการประมวลผลกับ Filter หรือ kernel ตามหลักการคอนโวลูชัน โดยจะกระทำทีละส่วนแล้วทำการเลื่อนไปจนครบทุกช่อง โดยผลลัพธ์ที่ได้จากการคำนวณเรียกว่า Feature Map

2. ReLU Layer การทำให้ output ที่ออกมาจาก Convolution Layer ทั้งหมดมีค่ามากกว่า 0 ขึ้นไป โดยหากค่าส่วนใดติดลบ จะถูกแทนที่ด้วย 0

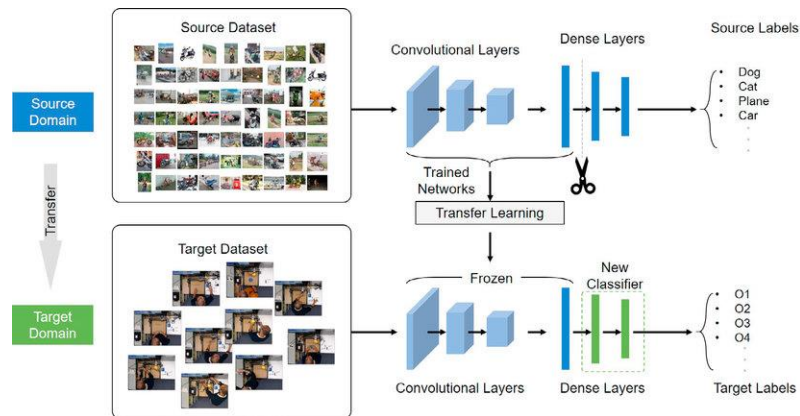
3. Pooling Layer การทำให้ Feature Map มีขนาดเล็กลงหรือการสกัดเอาส่วนที่สำคัญออก เพื่อนำไปใช้ใน Layer ถัดไป โดยมี 2 ลักษณะหลักๆ คือ Max Pooling คือการเลือกค่าตัวเลขที่สูงที่สุด และ Avg Pooling คือการนำตัวเลขทั้งหมดมาหาค่าเฉลี่ย

4. Flattening Layer การนำ Feature Map ไปเปลี่ยนรูป (Reshape) ให้เป็น vector ที่มีขนาด 1 column

5. Fully Connected Layer ทำหน้าที่ประมวลผลระหว่าง Input layer กับ Hidden Layer ให้ทำนายผลลัพธ์ตามที่ต้องการ ซึ่งจะมีจำนวน Node เท่ากับจำนวน Class ที่ต้องการทำนาย

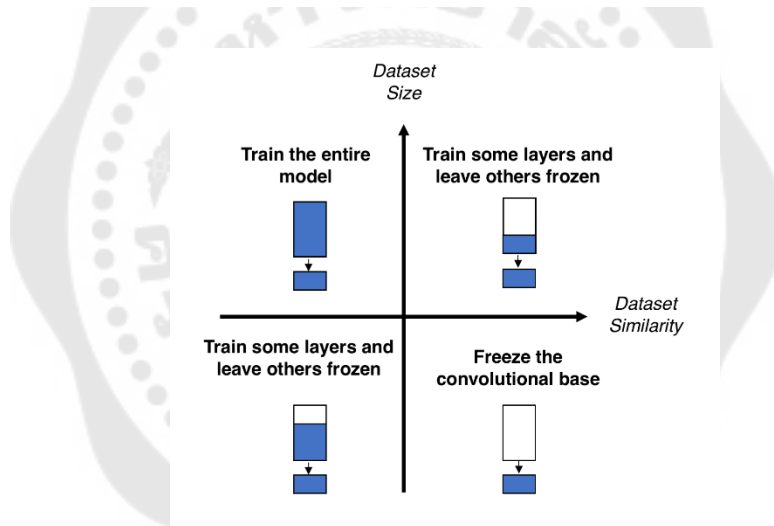
### 2.1.2 การถ่ายโอนการเรียนรู้ (Transfer Learning)

เป็นเทคนิคที่จะทำให้ลดเวลาในการ Train Deep Learning โดยจะนำแบบจำลองที่มีการ Train เรียบร้อยแล้ว จากชุดข้อมูลขนาดใหญ่ที่มีความใกล้เคียงกับงานมาใช้ หรือการส่งถ่ายความรู้จากแบบจำลองหนึ่งไปอีกแบบจำลองหนึ่ง คล้ายกับถ่ายทอดความรู้ ซึ่งจะมีการใช้งานเฉพาะส่วนที่เป็น Feature Learning (ผศ.ดร.ณัฐโชติ พรหมฤทธิ์, 2564)(ประกอบด้วย Convolution และ Pooling หรือเพิ่มเติมส่วนอื่นๆ) มาเพิ่มในส่วนของ New Classifier ใหม่ ให้สอดคล้องกับชุดข้อมูลใหม่ที่มีขนาดเล็กกว่าหรือมีจำนวนจำกัด ตัวอย่างดังภาพประกอบ 6 โดยเป็นแบบจำลองที่มีการ Train กับชุดข้อมูลภาพ ที่เป็นสุนัข แมว เครื่องบิน รถยนต์ และอื่นๆ แล้วนำมาจำแนกว่าสิ่งนั้นคืออะไร โดยเมื่อนำมาใช้งานเป็น Transfer Learning ได้เลือกเฉพาะในส่วนที่เป็น Convolutional Layers มาสกัดคุณสมบัติเด่นของวัตถุแต่ละชนิด แล้วเพิ่ม Dense Layers ที่อยู่ในส่วนของ Classification ใหม่ โดยหลักการคือจะมีการปรับค่าต่างๆ ให้เหมาะสม หรือที่เรียกว่า Fine-tuning และ Layer สุดท้าย จะกำหนดให้ Output เท่ากับจำนวน Class ทำให้ลดขั้นตอน ลดขนาดชุดข้อมูลในการ Train และลดระยะเวลาในการดำเนินการ พร้อมทั้งมีประสิทธิภาพในการทำนายเพิ่มมากขึ้น ซึ่งโดยส่วนใหญ่ชุดข้อมูลที่มีมักจะนิยมนำมาใช้ Train ได้แก่ ImageNet เป็นชุดข้อมูลที่มีข้อมูลตัวอย่างจำนวน 1.2 ล้านรูป ประกอบด้วย 1,000 หมวดหมู่ และเป็นชุดข้อมูลสาธารณะ



ภาพประกอบ 6 การเปรียบเทียบระหว่าง Transfer Learning กับการใช้แบบจำลองแบบเดิม

ที่มา : (Tao et al., 2020)



ภาพประกอบ 7 ประเภทการทำ Transfer Learning

ที่มา (Tavares, Costa, & Colanzi, 2021)

โดยการทำงานแบบ Transfer Learning มีหลากหลายรูปแบบ จากภาพประกอบ 7 มีรายละเอียดดังนี้

1. สำหรับข้อมูลที่มีขนาดใหญ่ ชุดข้อมูลใหม่มีความแตกต่างกับชุดข้อมูลที่แบบจำลองมีการ Train มาเรียบร้อยแล้ว มักจะนำแบบจำลองมาใช้งานทั้งหมด

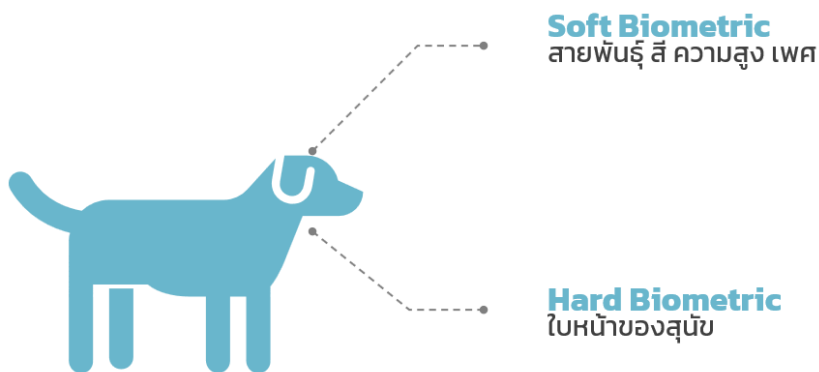
2. สำหรับข้อมูลขนาดใหญ่ ชุดข้อมูลใหม่มีความคล้ายกับชุดข้อมูลที่แบบจำลองมีการ Train มาเรียบร้อยแล้ว จะตัดส่วน Convolution บางส่วนออกไป และเพิ่ม Layer ใหม่ โดย Output สุดท้าย จะทำการกำหนดให้ Node = จำนวน Class

3. สำหรับชุดข้อมูลขนาดเล็ก ชุดข้อมูลใหม่มีความแตกต่างกับชุดข้อมูลที่แบบจำลองมีการ Train มาเรียบร้อยแล้ว จะตัดส่วน Convolution ส่วนใหญ่ออกไป และเพิ่ม Layer ใหม่ โดย Output สุดท้าย จะทำการกำหนดให้ Node = จำนวน Class

4. สำหรับชุดข้อมูลขนาดเล็ก ชุดข้อมูลใหม่มีความคล้ายกับชุดข้อมูลที่แบบจำลองมีการ Train มาเรียบร้อยแล้ว จะตัดเพียงส่วน Classification ออก และเพิ่ม Layer ใหม่ โดย Output สุดท้าย จะทำการกำหนดให้ Node = จำนวน Class

## 2.2 ทฤษฎีเกี่ยวกับไบโอเมตริกซ์ (Biometric)

ลักษณะเฉพาะที่มีความแตกต่างกันระหว่างบุคคลหรืออัตลักษณ์ของบุคคลหรือสิ่งมีชีวิต มักถูกนำไปใช้ในการยืนยันตัวบุคคล หรือระบุตัวตน เนื่องจากเป็นข้อมูลที่ปลอมแปลงได้ยาก โดยแยกประเภทของ Biometric ได้เป็น 2 ประเภท ได้แก่



ภาพประกอบ 8 ตัวอย่าง Soft Biometric และ Hard Biometric ของสุนัข

### 2.2.1 ประเภทของข้อมูลไบโอเมตริกซ์


1. **Soft Biometric** คุณลักษณะเฉพาะของบุคคลที่ถูกจำแนกออกตามกลุ่มประชากรตามลักษณะต่างๆ ซึ่งไม่ได้เฉพาะเรื่องใดเรื่องหนึ่งและไม่ระบุว่าเป็นบุคคลใด เช่น เพศ อายุ เชื้อชาติ ส่วนสูง สี สายพันธุ์ เป็นต้น ตัวอย่างที่กล่าวมานี้จะเห็นได้ว่า Soft Biometric สามารถสังเกตเห็นได้ในระยะไกลและทำความเข้าใจหรือจำแนกได้ง่าย เหมาะกับงานที่มีข้อจำกัดต่างๆ

โดยสามารถใช้ร่วมกับ Hard Biometric ได้ จะสามารถเพิ่มประสิทธิภาพของการระบุตัวตนแบบดั้งเดิมได้ และทำให้มนุษย์สามารถเข้าใจได้มากยิ่งขึ้น

2. Hard Biometric คุณลักษณะเฉพาะของบุคคล ที่เป็นรายละเอียดของแต่ละบุคคล ซึ่งจะมีความแตกต่างกัน สามารถแบ่งออกได้เป็น 2 ลักษณะ (สำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์, 2565) ดังนี้

2.1 ลักษณะเฉพาะทางสรีรวิทยา (Physiological Characteristics) หรือลักษณะกายภาพ ทั้งสามารถมองเห็นได้จากภายนอก และภายในส่วนใดส่วนหนึ่งของร่างกายมนุษย์ เป็นสิ่งที่สามารถเปลี่ยนแปลงได้ยาก เช่น ใบหน้า ม่านตา ลายนิ้วมือ ไบฮู DNA ลักษณะเส้นเลือดในลูกตา ลักษณะฝ่ามือ เป็นต้น

2.2 ลักษณะเฉพาะทางพฤติกรรม (Behavioral Characteristics) เป็นลักษณะเฉพาะที่เกิดจากการกระทำของมนุษย์แต่ละบุคคล เป็นสิ่งที่สามารถเปลี่ยนแปลงได้ง่ายกว่า ลักษณะเฉพาะทางสรีรวิทยา เช่น การเดิน การพูด จังหวะการกดแป้นพิมพ์ ลายเซ็น เป็นต้น



ภาพประกอบ 9 ภาพแสดงลักษณะต่างๆ ของ Biometric






ที่มา : (Elprocus)

ในการรักษาความปลอดภัยของข้อมูล Biometric ประเภทลักษณะเฉพาะทางสรีรวิทยานั้น เป็นสิ่งที่สำคัญมาก ถึงแม้ว่าจะปลอมแปลงได้ยาก แต่หากเกิดการรั่วไหลของข้อมูล จะทำให้ไม่สามารถแก้ไขข้อมูลในส่วนนี้ได้ ในงานที่มีความเสี่ยงต่อการรั่วไหลของข้อมูล จึงมักนิยมใช้เป็น Biometric ประเภทลักษณะเฉพาะทางพฤติกรรม เพราะสามารถแก้ไขเปลี่ยนแปลงได้

คุณสมบัติของ Biometric ที่พึงประสงค์ มีดังนี้

1. **ความเป็นสากล (Universality)** การที่มนุษย์ทุกคนในโลกมีลักษณะเฉพาะของตัวเอง เช่น ทุกคนจะต้องมีใบหน้า ทุกคนจะต้องมีลายนิ้วมือ เป็นต้น
2. **ความเป็นเอกลักษณ์ (Uniqueness)** มนุษย์ทุกคนจะต้องมีลักษณะเฉพาะที่แตกต่างกัน
3. **ความคงทน (Permanence)** ลักษณะที่ไม่มีการเปลี่ยนแปลงไปตามระยะเวลา เช่น การใช้ข้อมูลใบหน้าของเด็ก เมื่อเด็กโตขึ้นก็จะไม่สามารถใช้งานข้อมูลนั้นได้ เป็นต้น
4. **ความสามารถในการวัดค่า (Measurability)** ลักษณะที่สามารถจัดเก็บและสามารถนำข้อมูลไปวัดค่าความแตกต่างระหว่างบุคคล
5. **สมรรถภาพ (Performance)** ต้องมีประสิทธิภาพในการประมวลผลต้องอยู่ในเกณฑ์ที่เป็นที่ยอมรับ เช่น ความเร็ว ความแม่นยำ เป็นต้น เหมาะกับงานที่ต้องนำไปใช้
6. **ความสามารถในการยอมรับ (Acceptability)** ต้องเป็นที่ยอมรับ หรือได้รับคำยินยอมจากผู้ใช้งาน
7. **การปลอมแปลงยาก (Circumvention)** หรือความสามารถในการป้องกันการปลอมแปลง หรือทำลาย

Table 1. Comparison of several biometric technologies (assessments based on authors' perceptions).

BIOMETRIC	FINGERPRINT	FACE	HAND GEOMETRY	IRIS	VOICE
					
Barriers to universality	Worn ridges; hand or finger impairment	None	Hand impairment	Visual impairment	Speech impairment
Distinctiveness	High	Low	Medium	High	Low
Permanence	High	Medium	Medium	High	Low
Collectibility	Medium	High	High	Medium	Medium
Performance	High	Low	Medium	High	Low
Acceptability	Medium	High	Medium	Low	High
Potential for circumvention	Low	High	Medium	Low	High

ภาพประกอบ 10 เปรียบเทียบ Biometric ชนิดต่างๆ กับคุณสมบัติของ Biometric ที่พึงประสงค์

ที่มา : (Prabhakar, Pankanti, & Jain, 2003)


Biometric มักถูกนำไปใช้ในการยืนยันตัวตนบุคคล ซึ่งมีรูปแบบหลักๆ คือ การรู้จำใบหน้า การรู้จำเสียง การรู้จำลายนิ้วมือ การรู้จำลายเส้นเลือด การรู้จำลายเซ็น และการรู้จำเสียงพูด ซึ่งการเลือกใช้งานจะแตกต่างกันตามลักษณะของงาน โดยในงานวิจัยนี้จะมุ่งเน้นไปที่การรู้จำใบหน้า เพื่อใช้สำหรับการระบุตัวตนของสุนัข

## 2.2.2 การรู้จำใบหน้า

เทคโนโลยีที่นำ Biometrics หรือข้อมูลจำเพาะเจาะจงของบุคคลแต่ละคนมาแยกแยะลักษณะต่างๆ จากใบหน้าของบุคคล เพื่อใช้ในการระบุตัวตนของบุคคลของบุคคลนั้น โดยมีขั้นตอนหลักๆ ดังนี้

### 1. ตรวจจับใบหน้า (Face Detection)

กระบวนการหรือวิธีการในการค้นหาหรือตรวจจับใบหน้าของบุคคลในภาพ เพื่อนำไปประมวลผลและจัดเตรียมสำหรับขั้นตอนต่อไปให้มีประสิทธิภาพที่ดีขึ้น ถือเป็น Deep Learning ที่ใช้แยกความแตกต่างระหว่างส่วนที่เป็นใบหน้าและที่ไม่ใช่ใบหน้า จากนั้นจะปรับภาพใบหน้าให้ตรงตามความต้องการ ซึ่งใบหน้าถือเป็นคุณลักษณะจำเพาะทางสรีระ (Biometric) ของบุคคลที่มีความแตกต่างกันและมีความเฉพาะเจาะจงกันในแต่ละคน โดยการตรวจจับใบหน้าสามารถนำเข้าได้จากหลากหลายอุปกรณ์ เช่น โทรศัพท์มือถือ กล้องถ่ายภาพ Webcam Computer เป็นต้น ปัจจุบันรูปภาพหรือวิดีโอเป็นสิ่งสำคัญที่ช่วยให้การตรวจจับใบหน้าของบุคคลเป็นไปได้ได้อย่างสะดวกและรวดเร็ว โดยแบบจำลองจะทำการวิเคราะห์จากรูปภาพหรือข้อมูลนำเข้าว่าส่วนต่างๆ ของรูปภาพตรงกับสัดส่วนใบหน้าของบุคคลที่แบบจำลองเคยเรียนรู้ เช่น ส่วนของตา ส่วนของจมูก และส่วนของปาก นอกจากการตรวจจับใบหน้าแล้ว ยังมีอีกหลายแบบจำลองที่สามารถตรวจจับวัตถุอื่นๆ ได้ เช่น การตรวจจับเก้าอี้ การตรวจจับสัตว์ การตรวจจับสิ่งผิดปกติ เป็นต้น ตัวอย่างการตรวจจับใบหน้าจากรูปภาพ ตามภาพประกอบ 11



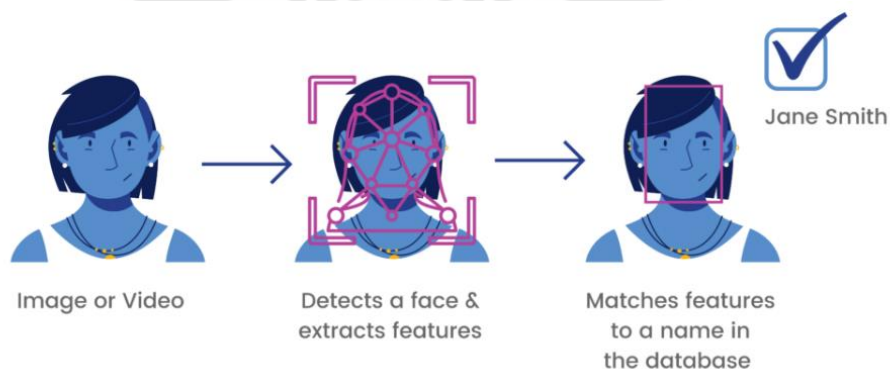
ภาพประกอบ 11 ตัวอย่างการตรวจจับใบหน้า (Face Detection) จากกล้อง Webcam



## 2. ระบุตัวตนด้วยภาพใบหน้า (Face Identification)

การระบุตัวตนด้วยภาพใบหน้า (Face Identification) หรือการรู้จำใบหน้า (Face Recognition) (ผศ.ดร.กอบเกียรติ สระอุบล, 2565) วิธีการระบุตัวตนจากรูปภาพหรือวิดีโอ ใบหน้าของบุคคล หรือสัตว์ เป็นการนำรูปภาพหรือวิดีโอใบหน้าที่ต้องการระบุตัวตนไปทำการประมวลผล โดยการเปรียบเทียบกับข้อมูลในฐานข้อมูล หากพบข้อมูลก็จะแสดงข้อมูลที่เกี่ยวข้องของบุคคลหรือสัตว์ตัวนั้น ซึ่งใช้วิธีการของ Deep Learning โดยเครื่องคอมพิวเตอร์จะทำการเรียนรู้และจดจำใบหน้า ทำการแยกข้อมูลภาพแต่ละส่วน มักจะถูกใช้ในกรณีที่ต้องการระบุตัวตนว่าเป็นใคร ซึ่งจะมีความคล้ายกับ Image Classification แต่ต่างตรงที่หากมีการเพิ่มใบหน้าใหม่ จะต้องมีการนำใบหน้าเหล่านั้นมาสอนให้แบบจำลองรู้จัก หรืออัปเดตเรื่อยๆ โดยนอกจากใบหน้าแล้ว ยังสามารถใช้คุณลักษณะจำเพาะทางสรีระอื่นๆ ของบุคคลได้ เช่น ลายนิ้วมือ ม่านตา เป็นต้น นอกจากนี้ยังสามารถระบุตัวตนจากพฤติกรรมของบุคคลได้อีกด้วย เช่น จังหวะการพิมพ์ ลักษณะการเดิน เป็นต้น

โดยก่อนที่จะสามารถระบุตัวตนจากภาพใบหน้าได้นั้น จะต้องมีการทำกระบวนการในข้อ 4 หรือการตรวจจับใบหน้า (Face Detection) ก่อน แล้วจึงนำข้อมูลที่มีเฉพาะใบหน้า มาทำการระบุตัวตนต่อ เพื่อหาใบหน้าที่ตรงกับใบหน้าที่นำเข้ามา นั้นหมายความว่า จะต้องมีการจัดการกับข้อมูลรูปภาพเหล่านี้ก่อนเพื่อให้การระบุตัวตนมีประสิทธิภาพนั่นเอง ตัวอย่างดังภาพประกอบ 12 และนอกจากนี้ บางกรณีอาจจะต้องมีการปรับปรุงรูปภาพให้อยู่ในรูปแบบที่เหมาะสมสำหรับการดำเนินการ เช่น การปรับขนาดรูปภาพ การหมุนองศา การปรับสี การลบพื้นหลัง เป็นต้น



ภาพประกอบ 12 ภาพกระบวนการทำการระบุตัวตนจากภาพใบหน้า

ที่มา : (Stike, 2019)

## 2.3 งานวิจัยที่เกี่ยวข้อง (Literature Review)

ในการวิจัยครั้งนี้ได้มีการศึกษาค้นคว้าและทบทวนวรรณกรรมงานวิจัยอื่นๆ ที่มีความเกี่ยวข้องและเป็นประโยชน์กับงานวิจัย ดังต่อไปนี้

1. บทความวิจัย เรื่อง Dog Identification using Soft Biometrics and Neural Networks โดย Kenneth Lai, Xinyuan Tu และ Svetlana Yanushkevich (Lai, Tu, & Yanushkevich, 2019)

ในงานนี้ผู้วิจัยต้องการแก้ไขปัญหา Biometric Identification ของสัตว์ เฉพาะสุนัข เพื่อหาเจ้าของของสุนัขที่หายไป และสนับสนุนแนวคิด e-health สำหรับสัตว์ ให้มีการจัดทำระบบสำหรับบันทึกข้อมูลสัตว์เลี้ยง เช่น ข้อมูลภาพถ่าย ข้อมูลประจำตัว ข้อมูลสุขภาพ เป็นต้น โดยใช้ Deep Learning ประมวลผลจากรูปถ่ายสุนัข เพื่อจะระบุตัวตนของสุนัข ซึ่งมีการใช้ Soft Biometric (สายพันธุ์ ส่วนสูง เพศ) ร่วมกับ Hard Biometric (ภาพของสัตว์) โดยผู้วิจัยได้ทดลองทำการจำแนกสายพันธุ์ของสุนัข จาก Stanford Dataset และ Columbia Dataset ก่อน เมื่อได้สายพันธุ์แล้ว จึงทำการระบุตัวตนของสุนัข โดยใช้ Flickr-Dog Dataset และมีการใช้ Transfer Learning อย่าง CNNs ชนิดต่างๆ เพื่อสร้าง Network เฉพาะของการจำแนกสายพันธุ์ ซึ่งได้ค่าความแม่นยำในการจำแนกสายพันธุ์อยู่ที่ 90.80% และ 91.29% (Xception) เมื่อแบ่งแยกระหว่างสุนัข 2 สายพันธุ์ กับ Dataset ที่แตกต่างกัน 2 ชุด และในการระบุตัวตนของสุนัข หากไม่ได้มีการใช้ Soft Biometric (แบ่งแยกสายพันธุ์, ระบุเพศ) จะได้ค่าความแม่นยำในการระบุตัวตนที่ 78.09% ซึ่งถ้าใช้ Network ที่ทำการสร้างเอง เพื่อจำแนกสายพันธุ์ร่วมกับ Soft Biometric จะได้ความถูกต้องถึง 84.94%

2. บทความวิจัย เรื่อง Combined Approach of Supervised and Unsupervised learning for Dog Face Recognition โดย D.T. Weerasekara; M.P.A.W. Gamage; K.S.A.F. Kulasooriya (Weerasekara, Gamage, & Kulasooriya, 2021)

ในงานวิจัยนี้ ผู้วิจัยต้องการแก้ปัญหาสุนัขหาย โดยใช้กระบวนการ Image Processing จากภาพใบหน้าสุนัข ผสมผสานระหว่าง Deep Learning กับ Machine Learning โดยใช้ CNNs ในการจำแนกรูปภาพและรู้จำใบหน้า หรือที่เรียกว่า Shift Invariant หรือ Space Invariant Neural Network (SIANN) และแบบจำลองที่เลือกมาใช้ในการสกัดคุณสมบัติของรูปภาพ คือ VGG16 ใช้งานผ่าน TensorFlow และ Keras และหาระยะห่างระหว่างข้อมูลของรูปภาพจาก KNeighbors โดยใช้รูปภาพสุนัขจาก google และเว็บไซต์อื่นๆ เช่น Flickr เป็นต้น ซึ่งมีทั้งหมด 320 ตัว จำนวน 2,500 รูปภาพ โดยหลังจากทำการจัดเตรียมรูปภาพ เช่น การหมุน การ

เลื่อน การปรับขนาดเรียบร้อยแล้ว ทำการเลือกสุนัขมาเพียง 5 Class เท่านั้น รวมรูปภาพทั้งหมด 1,305 ตัว ผลลัพธ์จากงานวิจัยนี้ แต่ละ Class ได้ค่าความแม่นยำมากกว่า 90%

3. บทความวิจัย เรื่อง Where Is My Puppy? Retrieving Lost Dogs by Facial Features โดย Thierry Pinheiro Moreira, Mauricio Lisboa Perez, Rafael de Oliveira Werneck, Eduardo Valle (Pinheiro Moreira et al., 2015)

ในงานวิจัยนี้ผู้วิจัยต้องการแก้ไขปัญหาสุนัขที่หายไป แต่ไม่สามารถกลับคืนสู่เจ้าของได้ โดยงานวิจัยนี้ผู้วิจัยได้เปรียบเทียบ EigenFaces, FisherFaces, LBPH และ a Sparse method สำหรับการรู้จำใบหน้ามนุษย์ มาใช้กับการระบุตัวตนของจากใบหน้าของสุนัข และการแก้ปัญหาแบบเดิม โดยใช้ Convolutional Neural Network คือ BARK และ WOOF (อ้างอิงจาก OverFeat off-the-shelf) ผลการทดลองพบว่าการรู้จำใบหน้าของมนุษย์ได้ค่าความแม่นยำเพียง 60% เมื่อนำไปใช้กับภาพใบหน้าสุนัข แสดงให้เห็นว่าการรู้จำใบหน้าของสุนัขไม่ใช่ส่วนหนึ่งของการรู้จำใบหน้าของมนุษย์ และเมื่อทดสอบกับ BARK ได้ค่าความแม่นยำสูงสุดที่ 81.1% และ WOOF 89.4% โดยการทดสอบได้ใช้ข้อมูล 2 ชุดข้อมูล คือ Flickr-dog จำนวนทั้งหมด 42 ตัว จากสุนัข 2 สายพันธุ์ คือ Pug และ Husky และ Snoopybook กับสุนัขพันธุ์แท้ อีก 18 ตัว

4. บทความวิจัย เรื่อง Dog Breed Classification Using Deep Learning โดย Akash Varshney, Abhay Katiyar, Aman Kumar Singh and Surendra Singh Chauhan (Varshney, Katiyar, Singh, & Chauhan, 2021)

ในงานวิจัยนี้ผู้วิจัยได้เสนอแบบจำลอง ในการจำแนกสายพันธุ์สุนัข โดยใช้ Stanford Dataset ในการทดลอง จำนวนรูปภาพทั้งหมด 20,580 รูปภาพ สุนัขทั้งหมด 120 สายพันธุ์ และมีการใช้วิธี pre-trained models การสกัดหาคุณสมบัติเด่น โดยเลือกแบบจำลองทั้งหมด 2 แบบจำลอง ได้แก่ InceptionV3 และ VGG16 และเปรียบเทียบค่าความแม่นยำ จากจำนวน epoch และ จำนวนชุดข้อมูลที่เท่ากัน ผลลัพธ์หลังจากการ Train แบบจำลองเรียบร้อยแล้ว ได้ค่าความแม่นยำอยู่ที่ 85% และ 69% ตามลำดับ ซึ่ง VGG ได้น้อยกว่า InceptionV3 ค่อนข้างมาก เนื่องจากมีชั้นความลึกที่แตกต่างกัน

5. บทความวิจัย เรื่อง IMPROVE DOG RECOGNITION BY MINING MORE INFORMATION FROM BOTH CLICK-THROUGH LOGS AND PRE-TRAINED MODELS โดย Guotian Xie, Kuiyuan Yang, Yalong Bai, Min Shang, Yong Rui และ Jianhuang Lai (Xie et al., 2016)

ในงานวิจัยนี้ผู้วิจัยต้องการรู้จำสายพันธุ์สุนัข โดยการ Click Through Rate หรือ CTR ซึ่งเป็นข้อมูลที่เกิดจากการทำ Data mining ที่ถูกค้นหาจากคำที่เกี่ยวข้องกับสุนัขแต่ละสายพันธุ์ และ pre-trained deep convolutional neural network (DCNN) ที่ผ่านการ Train มาเรียบร้อยแล้ว ได้แก่ AlexNet , VGG-A , VGG-16, ResNet-50 และ ResNet-101 เพื่อปรับปรุงความแม่นยำเพิ่มมากขึ้น โดยผลลัพธ์ข้อมูลที่ได้มาจาก CTR ทำให้ประสิทธิภาพความแม่นยำของ Pre-trained Model เพิ่มมากขึ้น เมื่อเปรียบเทียบกับการที่ไม่ใช้ข้อมูลจากการทำ CTR ซึ่งในงานวิจัยนี้ได้ใช้ชุดข้อมูลทั้งหมด ดังนี้

- Clickture-Full เอามาทั้งหมดที่ทำ mining เชื่อมโยงกับชุดข้อมูลที่ใช้ค้นหา
  - 95k เอามาเฉพาะ รูปที่มีคำว่า dog dogs puppy และ puppies
  - 68k เฉพาะรูปที่มีคำว่า dog อย่างน้อย 1 หรือ puppy อย่างน้อย 1
- โดยมีข้อมูลทั้งหมด 95k+68k จำนวน 344 สายพันธุ์ ซึ่งวิธีการมีดังนี้
- ใช้รูป 95k และแทนที่ Layer สุดท้ายของ DCNNs ที่ผ่านการ Train แล้ว
  - ใช้รูป 95k+68k และใช้ Layer สุดท้ายตามข้อแรก
  - ใช้รูป 95k+68k+full และใช้ DCNNs ทุก Layers

สำหรับการประเมินประสิทธิภาพ ได้นำข้อมูลจาก Stanford-Dog , Columbia-Dog และ ImageNet Dog ซึ่งผลการทดสอบ คือ 95K+68K+fully ได้ค่าความแม่นยำที่ 63.5% คือแบบจำลอง VGG-16 และเปรียบเทียบค่าความแม่นยำระหว่างที่ใช้และไม่ใช้ข้อมูลจากการ CTR คือ 86.90% และ 71.35%

6. บทความวิจัย เรื่อง Research on Pet Dog Species Identification Based on Convolution Neural Network โดย Yanmei Liu และ Yuda Chen (Liu & Chen, 2020)

ในงานวิจัยนี้ผู้วิจัยต้องการปรับปรุงประสิทธิภาพการรู้จำรูปภาพ ในรูปภาพสายพันธุ์ของสุนัข โดยเสนอแนวทางในการปรับปรุงโครงสร้างแบบจำลอง และวิธีการเพิ่มประสิทธิภาพในการ Train แบบจำลอง ซึ่งได้ผลลัพธ์สูงถึง 96% โดยการใส่รูปสุนัข 9,092 รูป ที่มาจากเว็บไซต์ crawler ซึ่งมีกระบวนการดังนี้ มีการสกัดคุณสมบัติของภาพ ผ่าน Convolution Neural Network อย่าง VGG16 มีการปรับที่ละเอียดมากขึ้น, ดำเนินการเฉพาะ L2 ทำให้เป็นมาตรฐาน, สร้าง Regularizer โดยวิธีการใน Tensor Flow และปรับค่า Weight ให้เป็นปกติ จากนั้นปรับ Hyperparameter เช่น learning rate , dropout เป็นต้น

7. บทความวิจัย เรื่อง Dog Breed Classifier using Convolutional Neural Networks โดย Middi Venkata Sai Rishita และ Tanvir Ahmed Harris (Rishita & Harris, 2018)

ในงานวิจัยนี้ผู้วิจัยต้องการจำแนกสายพันธุ์ของสุนัขพันธุ์ต่างๆ กับคน เพื่อให้ได้ค่าความแม่นยำที่สูง โดยวิธีการคือจะเริ่มจากการตรวจจับมนุษย์โดยใช้ haarcascades ใน OpenCV, ตรวจจับสุนัขโดยใช้ ResNet-50 , สร้าง Convolutional Neural Network เพื่อจำแนกสายพันธุ์ตั้งแต่เริ่มต้น, ใช้ VGG16 ในการจำแนกสายพันธุ์, ทดสอบสกัดคุณสมบัติจาก Convolutional Neural Network จาก InceptionV3, สร้างแบบจำลองเพื่อจำแนกประเภท จาก InceptionV3 และทำการประเมินประสิทธิภาพ โดยใช้ชุดข้อมูล จำนวน 133 สายพันธุ์ มีรูปภาพสุนัขทั้งหมด 8,351 รูปภาพ โดยผลลัพธ์ที่ได้มีดังนี้

- สร้าง CNNs ตั้งแต่เริ่ม ได้ค่าความแม่นยำ 10.8852%
- VGG16 – Accuracy 36.6029%
- สร้างแบบจำลองใหม่ สกัด Feature มาจาก InceptionV3 Accuracy 87.42%

ในหัวข้อนี้ผู้วิจัยได้ทำการสร้างตารางเปรียบเทียบประสิทธิภาพของแต่ละงานวิจัยได้ดังนี้

ตาราง 1 ตารางเปรียบเทียบประสิทธิภาพจากงานวิจัยที่เกี่ยวข้อง

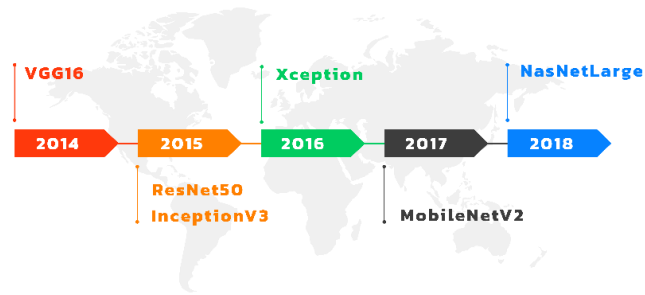
งานวิจัย	ชุดข้อมูล	วิธีการ	ค่าความแม่นยำที่สูงที่สุด
(Lai et al., 2019)	- Stanford-dog - Columbia-dog - Flickr-dog	จำแนกสายพันธุ์ก่อน จึงจะทำการระบุตัวตนของสุนัข จากภาพสุนัข โดยทุกวิธีการใช้ CNNs เป็น Pre-train Models ได้แก่ InceptionV3, MobileNet, VGG-16, Xception	- จำแนกสายพันธุ์ Xception 91.29% - ระบุตัวตนของสุนัข Xception 84.94%
(Weerasekara et al., 2021)	- จากเว็บไซต์ต่างๆ เช่น google Flickr เป็นต้น	จำแนกรูปภาพสุนัขโดยใช้ VGG16 ด้วยการทำให้ Feature Extraction ลบ Layer ชั้นที่ 16 ออกและ Predict โดยการหาค่า Distance	ได้ค่าความแม่นยำมากกว่า 90%
(Pinheiro Moreira et al., 2015)	- Flickr-dog - Snoopybook	ใช้ EigenFaces, FisherFaces, LBPH และ a Sparse method สำหรับการรู้จำใบหน้ามนุษย์ เปรียบเทียบกับข้อมูลใบหน้าสุนัข และเพิ่มเติมโดยใช้ BARK และ WOOF	- BARK 81.1% - WOOF 89.4%
(Varshney et al., 2021)	- Stanford-dog	ใช้ InceptionV3 และ VGG16 ด้วยการทำให้ Feature Extraction และสร้าง Classification Layer ใหม่	- InceptionV3 85% - VGG16 69%

ตาราง 1 (ต่อ)

งานวิจัย	ชุดข้อมูล	วิธีการ	ค่าความแม่นยำที่สูงที่สุด
(Xie et al., 2016)	- Clickture-Full เอามาทั้งหมดที่ ทำ mining เชื่อมโยงกับชุดข้อมูล 50 และ ResNet-101 ด้วยการ ที่ใช้ค้นหา Extraction และสร้าง Classification Layer - 95k เอามาเฉพาะ รูปที่มีคำว่า dog dogs puppy และ puppies - 68k เฉพาะรูปที่มีคำว่า dog อย่างน้อย 1 หรือ puppy อย่าง น้อย 1	- ใช้ AlexNet , VGG-A , VGG-16, ResNet- - ไม่ใช้ข้อมูลจากการ CTR	CTR 86.90% 71.35%
(Liu & Chen, 2020)	- จากเว็บไซต์ crawler	มีการสกัดคุณสมบัติของภาพ ผ่าน Convolution Neural Network อย่าง VGG16 มีการปรับที่ละเอียดมากขึ้น, ดำเนินการเฉพาะ L2 ทำให้เป็นมาตรฐาน, สร้าง Regularizer โดยวิธีการใน Tensor Flow และปรับค่า Weight ให้เป็นปกติ จากนั้นปรับ Hyperparameter เช่น learning rate , dropout เป็นต้น	Accuracy 96%
(Rishita & Harris, 2018)		- สร้าง Convolutional Neural Network เพื่อจำแนกสายพันธุ์ตั้งแต่เริ่มต้น - ใช้ VGG16 ในการจำแนกสายพันธุ์, ทดสอบสกัดคุณสมบัติจาก Convolutional Neural Network จาก InceptionV3 - สร้างแบบจำลองเพื่อจำแนกประเภท จาก InceptionV3	สร้าง CNNs ตั้งแต่เริ่ม ได้ค่าความแม่นยำ 10.8852% - VGG16 – Accuracy 36.6029% - สร้างแบบจำลองใหม่ สกัด Feature มาจาก InceptionV3 Accuracy 87.42%

จากงานวิจัยเหล่านี้ พบว่าโครงข่ายประสาทเทียม เหมาะสำหรับการนำมาจำแนกสายพันธุ์ของสุนัขและระบุตัวตนของสุนัข เพราะมีค่าความแม่นยำที่อยู่ในระดับที่ดี แต่ด้วยสายพันธุ์หรือชุดข้อมูลที่นำมาทดสอบ ส่วนใหญ่เป็นสุนัขสายพันธุ์ต่างประเทศ ซึ่งยังไม่มีการศึกษาหรือทดลองในส่วนของสายพันธุ์ไทย เพื่อสามารถนำแบบจำลองมาประยุกต์ใช้ในประเทศไทยได้


ในงานวิจัยนี้ผู้วิจัยได้เลือกแบบจำลองที่เป็นโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNNs) เนื่องจากเป็นแบบจำลองที่เหมาะสมกับงาน Image Processing ในลักษณะ Classification สอดคล้องตามตัวอย่างงานวิจัยที่ได้กล่าวไปข้างต้น โดยได้เลือกแบบจำลองทั้งหมด 6 แบบจำลอง ดังนี้



ภาพประกอบ 13 ภาพแสดง Timeline ของแต่ละแบบจำลอง

### 1. VGG16

Visual Geometry Group หรือ VGG16 เป็นแบบจำลองที่ถูกพัฒนาจากนักวิจัย Oxford ถูกปรับปรุงมาจาก AlexNet (ผศ.ดร.กอบเกียรติ สระอุบล, 2565) คุณสมบัติเด่นคือ เน้นการออกแบบ Layer แทน จำนวน Hyperparameter ซึ่งมีทั้งหมด 16 Layers โดยจะมีการปรับเปลี่ยนขนาดของ kernel จาก  $11 \times 11$  เป็น  $3 \times 3$  แบบเดียวกันทั้งโครงสร้าง ทำให้สามารถใช้ Hyperparameter จำนวนน้อยลงมาก ข้อมูลสำหรับการนำเข้าต้องมีขนาด  $224 \times 224 \times 3$  เหมาะกับการเริ่มต้นในการเรียนรู้ด้าน Computer Vision



ภาพประกอบ 14 ภาพแสดงโครงสร้างชั้นของแบบจำลอง VGG16

ที่มา : (Blauch, Behrmann, & Plaut, 2019)

## 2. MobileNetV2

เป็นแบบจำลองที่เหมาะสมกับงานเริ่มต้นและงาน Computer Vision สำหรับมือถือหรืออุปกรณ์ขนาดเล็ก เพราะเป็นแบบจำลองที่มีขนาดเล็กเพียง 16 MB (Pröve, 2018) ซึ่งจะทำให้ประมวลผลได้เร็ว มีความลึกทั้งหมด 53 layers แต่ให้ค่าความแม่นยำไม่ได้สูงมาก เมื่อเทียบกับแบบจำลองอื่นๆ เหมาะกับอุปกรณ์ที่มีทรัพยากรอย่างจำกัด ข้อมูลสำหรับการนำเข้าต้องมีขนาด  $224 \times 224 \times 3$  โดยแบบจำลองดังกล่าวได้ถูกพัฒนาขึ้นจาก Google โดย MobileNetV2 จะแตกต่างจากเดิมตรงมีการทำงานแบบกลับหัว โดย MobileNetV1 ทำงานแบบ 2 ชั้นตอนคือ Depthwise Convolution และ Pointwise Convolution

Input	Operator	$t$	$c$	$n$	$s$
$224^2 \times 3$	conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

ภาพประกอบ 15 ภาพแสดงโครงสร้างชั้นของแบบจำลอง MobileNetV2

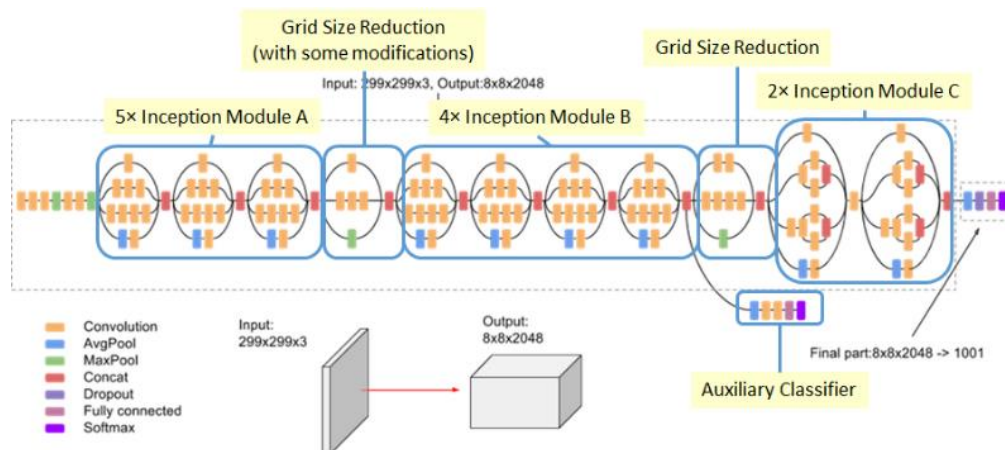
## 3. InceptionV3

ถูกพัฒนาโดย Google ต่อยอดมาจาก Inception 1 และ InceptionV2 ซึ่งพัฒนามาจาก GoogLeNet2012 มีความลึกทั้งหมด 48 layers โดยมีการลดโครงสร้างภายใน 5 ชั้นตอน (Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016) ดังนี้

- Module A จำนวน 5 Modules
- Grid Size of Reduction ชั้นตอนที่ 1 จำนวน 1 Module
- Module B จำนวน 4 Modules
- Grid Size of Reduction ชั้นตอนที่ 2 จำนวน 1 Module
- Module C จำนวน 2 Modules



และ Final part (8x8x2048) ซึ่งได้ Output ทั้งหมด 1,001 class ทำให้จำนวน Hyperparameter ลดลงจากเดิม และยังคงประสิทธิภาพสูง นอกจากนี้มีการปรับปรุง Convolution จาก 5x5 เป็น 3x3 และ Maxpooling จาก 3x3 เป็น 2x2 เพื่อให้ output เป็น tensor ข้อมูลสำหรับการนำเข้าต้องมีขนาด 299x299x3

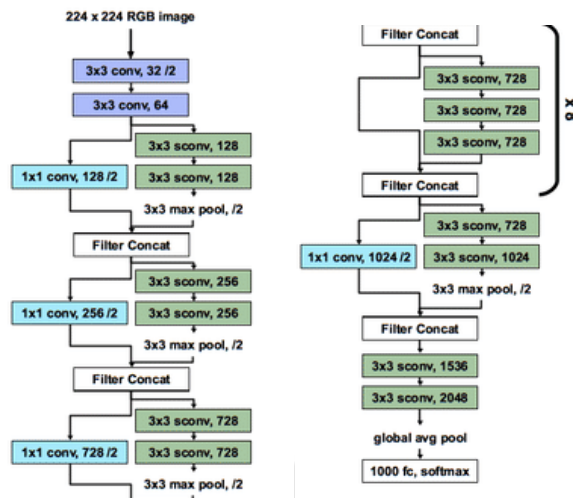


ภาพประกอบ 16 ภาพแสดงโครงสร้างชั้นของแบบจำลอง InceptionV3

ที่มา : (Faisal, Alsulaiman, Arafah, & Mekhtiche, 2020)

#### 4. Xception

Xception พัฒนาโดย François Chollet ผู้พัฒนา Keras หรือจาก Google ซึ่งพัฒนาต่อยอดมาจาก Inception จึงได้ชื่อว่า Extreme Inception หรือ Xception มีความลึกทั้งหมด 71 layers (Chollet, 2017) ซึ่งใช้หลักการของ depthwise separable convolution ซึ่งมีการทำ pointwise convolution (1x1 convolution) และทำ depthwise convolution เพื่อทำการลดขนาด channel ก่อน เป็นแบบจำลองที่ให้ค่าความแม่นยำค่อนข้างดี




ภาพประกอบ 17 ภาพแสดงโครงสร้างชั้นของแบบจำลอง Xception

ที่มา : (Leonardo, Carvalho, Rezende, Zucchi, & Faria, 2018)

### 5. ResNet50

Residual Network หรือ ResNet50 เป็นแบบจำลองที่มีทั้งหมด 50 layers ตามชื่อ ซึ่งได้รับความนิยมในงานด้าน Computer Vision มาก ในส่วนการตรวจจับวัตถุ ซึ่งจุดเด่นคือสามารถแก้ปัญหาการพบวาระหว่างการ Train Gradient มีขนาดลดลงมากจนไม่สามารถ Train ต่อได้ และทำให้แบบจำลองไม่เกิดการเรียนรู้ หรือที่เรียกว่า Vanishing Gradient โดยมักจะเกิดกับแบบจำลองที่มีโครงข่ายค่อนข้างลึกมาก (ผศ.ดร.กอบเกียรติ สระอุบล, 2565) ซึ่งแก้ไขโดยการส่งข้อมูลแบบข้ามชั้นตอน หรือ Skip Connection เพื่อไม่ให้ค่า Weight ลดลงมากไปจนไม่สามารถคำนวณต่อได้ ตามภาพประกอบ 18 โดยข้อมูลสำหรับการนำเข้าต้องมีขนาด 299x299x3



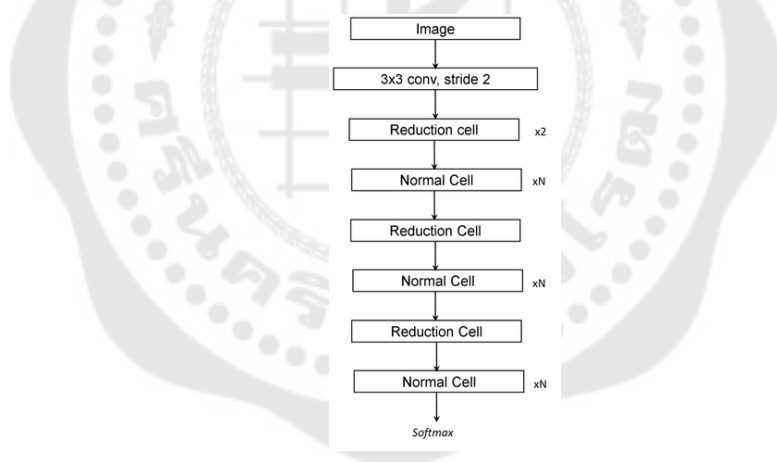
ภาพประกอบ 18 ภาพแสดงโครงสร้างชั้นของแบบจำลอง ResNet50

ที่มา : (Leonardo et al., 2018)

## 6. NasNetLarge

Neural Architecture Search Network หรือ NASNet ถูกคิดค้นขึ้นโดย Google (Zoph, Vasudevan, Shlens, & Le, 2018) โดยใช้งาน Reinforcement Learning ซึ่งมี reward เป็นค่าของความแม่นยำ เพื่อใช้แก้ปัญหาในการค้นหา CNN ที่ดีที่สุด แบบ AutoML โดยเป็นการพัฒนาต่อยอดมาจาก Neural Architecture Search (NAS) โดยข้อมูลสำหรับการนำเข้าต้องมีขนาด  $311 \times 311 \times 3$


NASNet ใช้งาน convolution cell 2 แบบ คือ Normal cell ซึ่ง return feature map ขนาดเท่าเดิม และ Reduction Cell ซึ่ง return feature map ขนาดเล็กลง โดยในแต่ละ cell จะใช้ Recurrent Neural Network (RNN) เพื่อหาสถาปัตยกรรมที่ดีที่สุด โดยเลือก 2 states จาก output ของ 2 layer ก่อนหน้า เพื่อนำมาทำ operation บางอย่าง เช่น pooling หรือ convolution จากนั้นเลือกวิธีในการรวม 2 states ที่ผ่านการทำ operation แล้ว เพื่อสร้างแบบ hidden state ตัวใหม่ โดยจะทำวนซ้ำจนครบ 5 รอบสำหรับแต่ละ block และทำวนซ้ำจนครบจำนวน block ที่กำหนด



ภาพประกอบ 19 ภาพแสดงโครงสร้างชั้นของแบบจำลอง NasNetLarge

ที่มา : (Albahli & Albattah, 2020)

จุดเด่นคือการใช้ทรัพยากรในการคำนวณที่น้อยลงอย่างมากและความสามารถในการ transfer ไปใช้งานกับ dataset ขนาดใหญ่ได้ โดยแบบจำลองดังกล่าวผ่านการเรียนรู้กับ dataset CIFAR-10 ที่ขนาดเล็ก แล้ว transfer ไปใช้งานกับ ImageNet ได้อย่างมีประสิทธิภาพ



ภาพประกอบ 20 ภาพเปรียบเทียบประสิทธิภาพของแบบจำลองชนิดต่างๆ

ที่มา : (mathworks)

จากภาพประกอบ 20 แสดงภาพการเปรียบเทียบประสิทธิภาพของแบบจำลองชนิดต่างๆ จากการ Train ด้วย ImageNet Dataset ซึ่งขนาดที่แตกต่างกันหมายถึง Size หน่วยความจำที่แบบจำลองต้องการ แกน X คือระยะเวลาที่ใช้ แกน Y คือค่าความแม่นยำของแต่ละแบบจำลอง

### บทที่ 3 วิธีดำเนินการวิจัย

ในงานวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

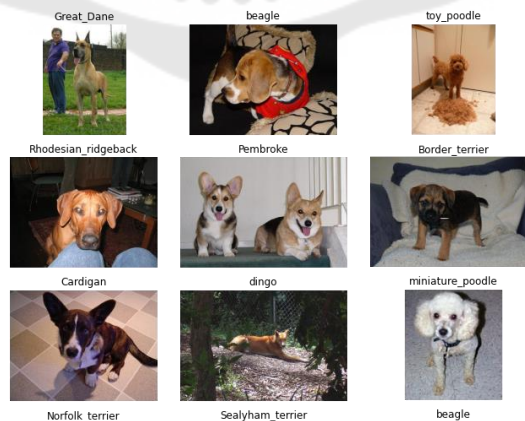
1. การกำหนดประชากรและกลุ่มตัวอย่าง
2. การออกแบบวิธีการดำเนินงานวิจัย และการแบ่งชุดข้อมูล
3. กระบวนการในการจำแนกสายพันธุ์ของสุนัข และประเมินประสิทธิภาพแบบจำลองในการจำแนกสายพันธุ์
4. กระบวนการในการระบุตัวตนของสุนัข และประเมินประสิทธิภาพแบบจำลองในการระบุตัวตน

#### 3.1 การกำหนดประชากรและกลุ่มตัวอย่าง

##### 3.1.1 ประชากร

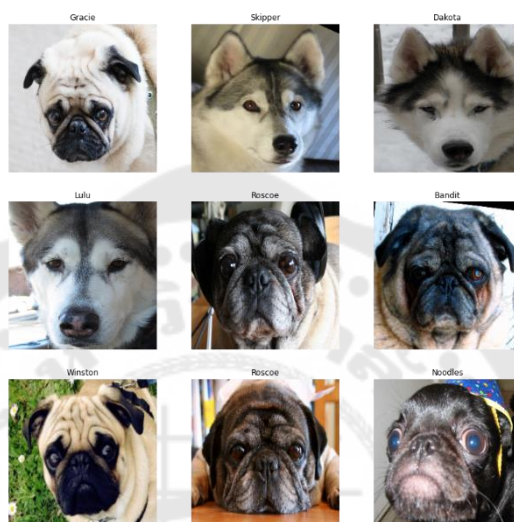
การวิจัยนี้ผู้วิจัยเลือกประชากรหรือชุดข้อมูลทั้งหมด 3 ชุดข้อมูล ใช้ในการทดลอง 2 ส่วน ซึ่งเป็นรูปภาพของสุนัขทั้งหมด ได้แก่

1. ชุดข้อมูลสาธารณะ จาก Stanford Dogs Dataset (Khosla et al., 2011) ใช้สำหรับการจำแนกสายพันธุ์สุนัข ซึ่งมีภาพสุนัขจำนวน 20,580 รูปภาพ 120 สายพันธุ์ สายพันธุ์ละ อย่างน้อย 140 รูปภาพ ซึ่งรูปภาพทั้งหมดเป็นรูปภาพที่มีขนาดแตกต่างกัน ยังไม่ได้มีการครอบตัดหรือทำการปรับคุณภาพใดๆ และสายพันธุ์ทั้งหมดที่อยู่ในชุดข้อมูล เป็นสุนัขสายพันธุ์ต่างประเทศ ตามภาพประกอบ 21



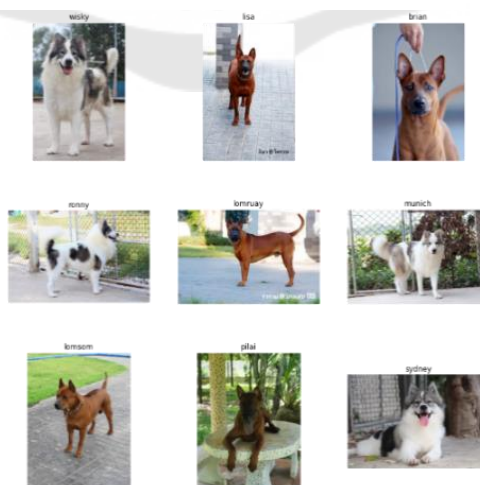
ภาพประกอบ 21 ตัวอย่างรูปภาพ Stanford Dogs Dataset

2. ชุดข้อมูลจาก Flickr-dog (Pinheiro Moreira et al., 2015) ใช้สำหรับการระบุตัวตนของสุนัข รวมทั้งหมด 374 รูปภาพ จำนวน 42 ตัว ตัวละอย่างน้อย 5 รูปภาพ โดยเป็นสุนัข 2 สายพันธุ์ ได้แก่ Husky และ Pug ชุดข้อมูลดังกล่าวเป็นชุดข้อมูลที่มีการทำการครอบตัดเฉพาะใบหน้าของสุนัข พร้อมทั้ง ปรับองศา ปรับโทนสี และลดขนาดเป็น 250x250 pixel เรียบร้อยแล้ว ตัวอย่างรูปภาพตามภาพประกอบ 22



ภาพประกอบ 22 ตัวอย่างรูปจาก จาก Flickr-dog

3. ชุดข้อมูลข้อมูลสุนัขสายพันธุ์ไทย (Thai Dataset) ใช้ข้อมูลจากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม รูปภาพสุนัขจำนวน 369 รูปภาพ มีทั้งหมด 2 สายพันธุ์ สายพันธุ์ละอย่างน้อย 180 รูปภาพ เป็นรูปภาพสุนัขทั้งหมด 51 ตัว ดังตาราง 2



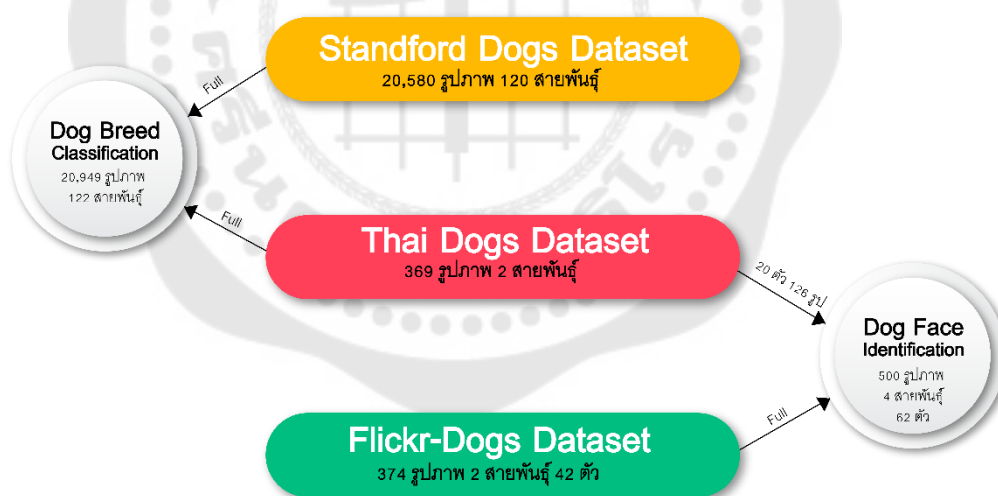
ภาพประกอบ 23 ตัวอย่างภาพจากฟาร์มสุนัขในประเทศไทย

ตาราง 2 ตารางแสดงสายพันธุ์ และจำนวนรูปที่ใช้ในงานวิจัย จาก ฟาร์มสุนัขในประเทศไทย

ลำดับ	สายพันธุ์	จำนวนรูปภาพ	ที่มา
1	บางแก้ว (Thai_Bangkaew)	186	กมลชัยบางแก้ว
2	หลังอาน (Thai_Ridgeback)	183	ฟาร์มบรมสุข, สุนัขไทยหลังอาน ดำรงไทย, ไทยหลังอาน Muang Non-TRD

โดยการใช้งานข้อมูลจากฟาร์มสุนัขในประเทศไทยจะนำไปใช้ทั้ง 2 กระบวนการ คือ การจำแนกสายพันธุ์สุนัขจะใช้รูปภาพทั้งหมดของทั้ง 2 สายพันธุ์ รวม 369 รูปภาพ เป็นรูปภาพเต็มตัวของสุนัข และการระบุตัวตนสุนัข จะทำการเลือกสายพันธุ์ละ 10 ตัว รวม 126 รูปภาพ ตัวละอย่างน้อย 5 รูปภาพ และจะทำการครอบตัดเฉพาะใบหน้าของสุนัข หรือทำการตรวจจับใบหน้าของสุนัขจากรูปภาพ และปรับให้คล้ายกับชุดข้อมูล Flickr-Dogs เพื่อนำไปทำการระบุตัวตนต่อไป

### 3.1.2 กลุ่มตัวอย่าง

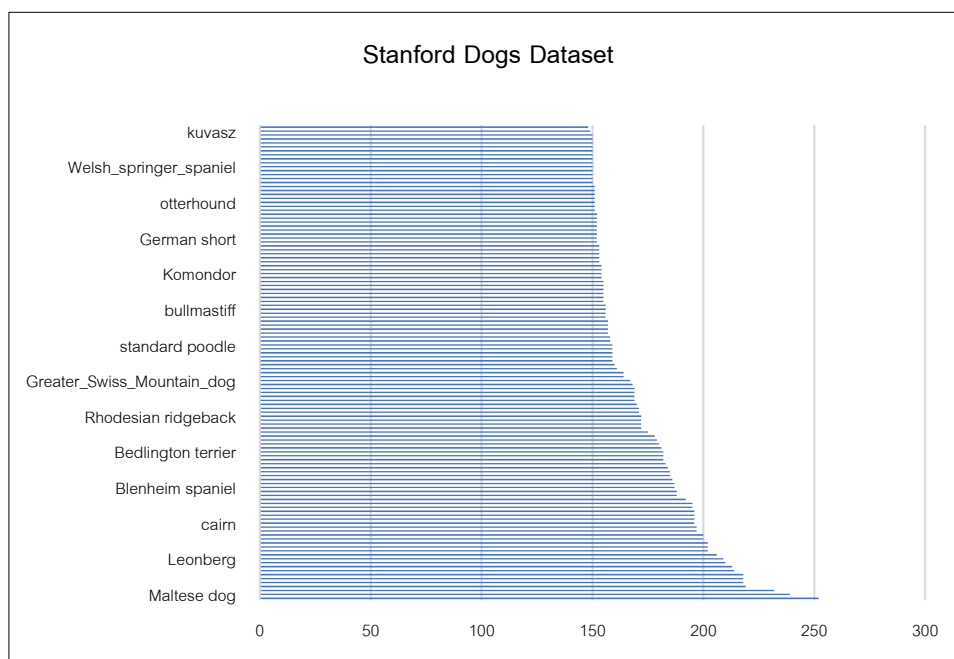


ภาพประกอบ 24 แสดงการใช้ชุดข้อมูลต่างๆ ในงานวิจัย

จากประชากรข้างต้น สามารถแบ่งกลุ่มตัวอย่างตามกระบวนการได้ดังนี้

1. การจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification) ใช้รูปภาพสุนัขทั้งหมดจำนวน 20,949 รูปภาพ 122 สายพันธุ์ โดยใช้รูปภาพจาก 2 แหล่งที่มา ได้แก่

- สายพันธุ์ต่างประเทศ จาก Stanford Dogs Dataset (Khosla et al., 2011) ภาพสุนัขจำนวน 20,580 รูปภาพ มีทั้งหมด 120 สายพันธุ์ สายพันธุ์ละ อย่างน้อย 140 รูปภาพ ลักษณะภาพเป็นภาพสุนัขเต็มตัว



ภาพประกอบ 25 แสดงสายพันธุ์ และจำนวนรูปที่ใช้ในงานวิจัย จาก Stanford Dogs Dataset

- สายพันธุ์ไทย (Thai Dataset) จากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม รูปภาพสุนัขจำนวน 369 รูปภาพ ทั้งหมด 2 สายพันธุ์ สายพันธุ์ละ อย่างน้อย 183 รูปภาพ ลักษณะภาพเป็นภาพสุนัขเต็มตัว

ตาราง 3 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกสายพันธุ์ จาก ฟาร์มสุนัขในประเทศไทย แบ่งตามสายพันธุ์

ลำดับ	สายพันธุ์	จำนวนสุนัข	จำนวนรูป
1	Thai_Bangkaew	32	186
2	Thai_Ridgeback	19	183
	<b>รวม</b>	<b>51</b>	<b>369</b>



ตาราง 4 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกสายพันธุ์ จาก ฟาร์มสุนัขในประเทศไทย

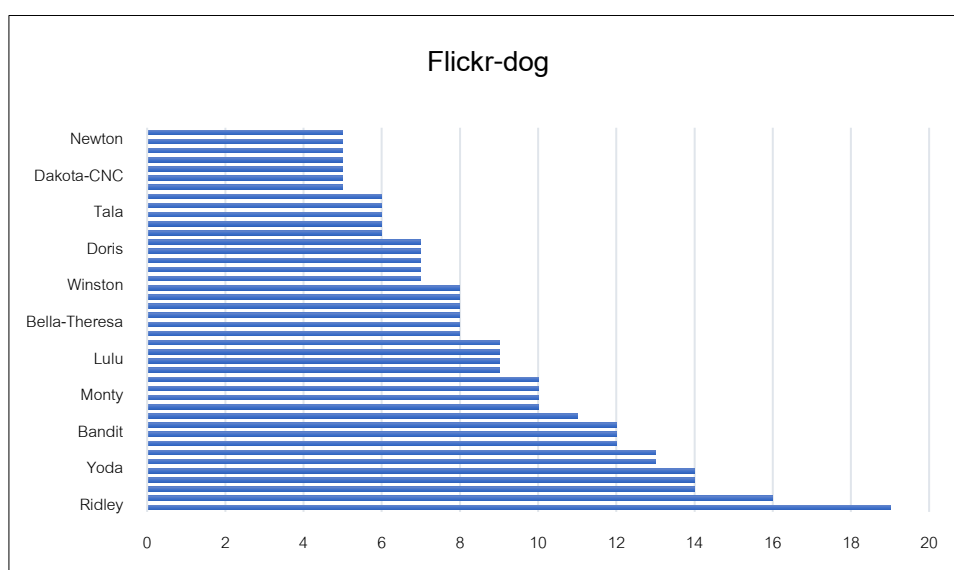
ลำดับ	สายพันธุ์	ชื่อสุนัข	จำนวนรูป
1	Thai_Bangkaew	apache	9
2	Thai_Bangkaew	barbi	5
3	Thai_Bangkaew	beauty	7
4	Thai_Bangkaew	cocori	4
5	Thai_Bangkaew	dodo	5
6	Thai_Bangkaew	giegie	4
7	Thai_Bangkaew	harmonie	9
8	Thai_Bangkaew	kafaa	6
9	Thai_Bangkaew	kwankaew	2
10	Thai_Bangkaew	maggi	7
11	Thai_Bangkaew	meiling	5
12	Thai_Bangkaew	miami	5
13	Thai_Bangkaew	minni	6
14	Thai_Bangkaew	munich	10
15	Thai_Bangkaew	namthip	6
16	Thai_Bangkaew	nora	7
17	Thai_Bangkaew	numchock	5
18	Thai_Bangkaew	omyim	5
19	Thai_Bangkaew	pekae	4
20	Thai_Bangkaew	pigus	7
21	Thai_Bangkaew	praw	4
22	Thai_Bangkaew	quarter	5
23	Thai_Bangkaew	ronny	11
24	Thai_Bangkaew	sainum	4
25	Thai_Bangkaew	sydney	6
26	Thai_Bangkaew	tangmo	3
27	Thai_Bangkaew	tarzan	6
28	Thai_Bangkaew	toni	4

ตาราง 4 (ต่อ)

ลำดับ	สายพันธุ์	ชื่อสุนัข	จำนวนรูป
29	Thai_Bangkaew	tono	6
30	Thai_Bangkaew	wisky	5
31	Thai_Bangkaew	yoko	7
32	Thai_Bangkaew	yone	7
33	Thai_Ridgeback	brian	12
34	Thai_Ridgeback	buw	4
35	Thai_Ridgeback	chaclo	4
36	Thai_Ridgeback	george	7
37	Thai_Ridgeback	kaewmanee	8
38	Thai_Ridgeback	kati	6
39	Thai_Ridgeback	kumpun	2
40	Thai_Ridgeback	lika	6
41	Thai_Ridgeback	lisa	7
42	Thai_Ridgeback	lomruay	35
43	Thai_Ridgeback	lomsom	19
44	Thai_Ridgeback	lula	6
45	Thai_Ridgeback	maruay	4
46	Thai_Ridgeback	montra	16
47	Thai_Ridgeback	olan	16
48	Thai_Ridgeback	pilai	4
49	Thai_Ridgeback	plachon	11
50	Thai_Ridgeback	pungpung	5
51	Thai_Ridgeback	rambo	11

2. การระบุตัวตนของสุนัข (Dog Identification) และการตรวจจับใบหน้าของสุนัข (Face Dog Detection) ใช้รูปภาพสุนัขที่แยกตามชื่อรายตัว จำนวนทั้งหมด 62 ตัว มีรูปภาพทั้งหมด 500 รูปภาพ โดยใช้รูปภาพจาก 2 แหล่งที่มา ได้แก่

- **สายพันธุ์ต่างประเทศ** จาก Flickr-dog (Pinheiro Moreira et al., 2015) จำนวน 374 รูปภาพ เป็นสุนัขจำนวน 42 ตัว อย่างน้อยตัวละ 5 รูป จากสายพันธุ์ Husky และ Pug โดยมีการระบุชื่อสุนัขแต่ละตัว ลักษณะภาพเป็นภาพใบหน้าสุนัข



ภาพประกอบ 26 แสดงจำนวนสุนัขที่ใช้ จาก Flickr-dog

- **สายพันธุ์ไทย** รูปภาพจากฟาร์มสุนัขในประเทศไทย จำนวน 4 ฟาร์ม จำนวน 126 รูปภาพ เป็นสุนัข 20 ตัว อย่างน้อยตัวละ 5 รูป จากสายพันธุ์บางแก้ว 10 ตัวและหลังอาน 10 ตัว ลักษณะภาพเป็นภาพสุนัขเต็มตัว

ตาราง 5 ตารางแสดงจำนวนสุนัขที่ใช้ในการจำแนกระบุตัวตน จาก ฟาร์มสุนัขในประเทศไทย แบ่งตามสายพันธุ์

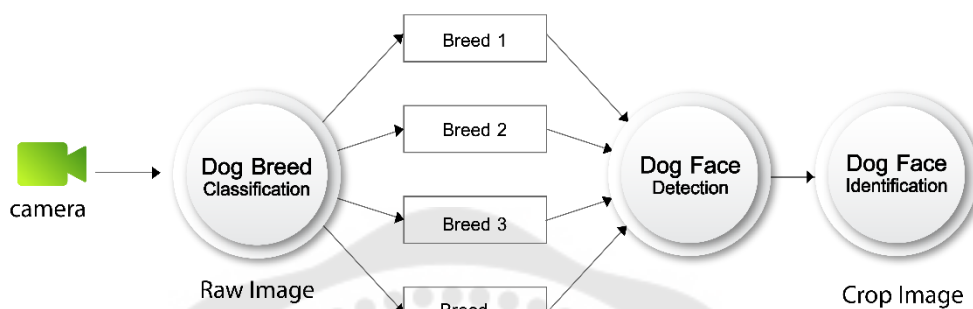
ลำดับ	สายพันธุ์	จำนวนสุนัข	จำนวนรูป
1	Thai_Bangkaew	10	64
2	Thai_Ridgeback	10	62
	<b>รวม</b>	20	126

ตาราง 6 ตารางแสดงจำนวนสุนัขที่ใช้ในการระบุตัวตน จาก ฟาร์มสุนัขในประเทศไทย

ลำดับ	สายพันธุ์	ชื่อสุนัข	จำนวนรูป
1	Thai_Bangkaew	apache	5
2	Thai_Bangkaew	brian	7
3	Thai_Bangkaew	george	5
4	Thai_Bangkaew	kaewmanee	8
5	Thai_Bangkaew	kafaa	5
6	Thai_Bangkaew	kati	6
7	Thai_Bangkaew	lisa	7
8	Thai_Bangkaew	lomruay	8
9	Thai_Bangkaew	lomsom	8
10	Thai_Bangkaew	lula	5
11	Thai_Ridgeback	maggi	6
12	Thai_Ridgeback	meiling	5
13	Thai_Ridgeback	namthip	6
14	Thai_Ridgeback	nora	5
15	Thai_Ridgeback	pigus	5
16	Thai_Ridgeback	plachon	8
17	Thai_Ridgeback	rambo	8
18	Thai_Ridgeback	tono	6
19	Thai_Ridgeback	yoko	7
20	Thai_Ridgeback	yone	6

### 3.2 การออกแบบวิธีการดำเนินงานวิจัย และการแบ่งชุดข้อมูล

งานวิจัยในครั้งนี้ ผู้วิจัยได้วิเคราะห์และออกแบบกระบวนการในการดำเนินงานวิจัย โดยภาพรวมแนวคิดในงานวิจัย ตามภาพประกอบ 27



ภาพประกอบ 27 ภาพรวมของงานวิจัย

จากภาพประกอบ 27 เริ่มจากการถ่ายภาพสุนัขผ่านกล้องประเภทต่างๆ โดยจะต้องเป็นรูปภาพสุนัข 1 ตัวที่ถ่ายจากมุมด้านหน้าหรือด้านข้าง โดยให้เห็นใบหน้าและลำตัวของสุนัข ซึ่งต้องไม่มีสิ่งของหรือเงาบัง และอยู่ในอิริยาบถที่มองเห็นลายของลำตัวและใบหน้าอย่างชัดเจน โดยช่วงอายุของสุนัขที่เหมาะสม คือ ต้องเป็นสุนัขที่โตเต็มวัย ช่วงอายุ 8-9 เดือนขึ้นไป (มหาวิทยาลัยขอนแก่น, 2015) และจะต้องเป็นสุนัขที่เคยลงทะเบียนไว้ในระบบเรียบร้อยแล้ว (การลงทะเบียนจะต้องใช้รูปภาพสุนัขอย่างน้อย 5 รูปภาพ ในการลงทะเบียน ซึ่งเป็นลักษณะเดียวกับที่กล่าวไปข้างต้น) แล้วนำภาพเหล่านั้นมาทำการจำแนกสายพันธุ์ของสุนัข เพื่อลดพื้นที่ในการค้นหาในขั้นตอนต่อไป ซึ่งขั้นตอนการระบุตัวตนของสุนัข มีการใช้สุนัขทั้งหมด 4 สายพันธุ์ โดยผู้วิจัยได้ตั้งสมมุติฐานว่าสายพันธุ์ของสุนัข 4 สายพันธุ์ เป็นผลลัพธ์ 4 อันดับ จากการจำแนกสายพันธุ์ แล้วทำการตรวจจับใบหน้าของสุนัข เพื่อนำไปใช้ในขั้นตอนสุดท้าย คือการระบุตัวตนของสุนัข ซึ่งทั้งหมดเป็นการดำเนินการในการนำข้อมูล Biometrics มาใช้ให้เกิดประโยชน์ ตั้งแต่ Soft Biometrics และ Hard Biometrics เพื่อได้ผลลัพธ์สุดท้ายของการระบุตัวตนของสุนัข ให้สามารถนำไปต่อยอดได้อย่างมีประสิทธิภาพ



ภาพประกอบ 28 ตัวอย่างภาพที่เหมาะสมกับการนำมาทดลอง

นอกจากนี้ ในงานวิจัยนี้มีการใช้เทคนิคการแบ่งชุดข้อมูลตามสัดส่วน เพื่อใช้ในการทดลอง ดังนี้

1. การจำแนกสายพันธุ์ (Dog Breed Classification) จำแนกสายพันธุ์จากภาพสุนัขเต็มตัว จำนวนรูปภาพที่ใช้ทั้งหมด 20,926 รูปภาพ โดยมีการแบ่งชุดข้อมูล หรือ Train Test Split ออกดังนี้

- Training Set จำนวน 85% 17,806 รูปภาพ
  - Training Data 85% จำนวน 15,135 รูปภาพ
  - Validation Data 15% จำนวน 2,671 รูปภาพ
- Testing Set 15% จำนวน 3,143 รูปภาพ

2. การระบุตัวตนสุนัข (Dog Face Identification) ระบุตัวตนจากภาพใบหน้า จำนวนรูปภาพที่ใช้ทั้งหมด 500 รูปภาพ โดยมีการแบ่งชุดข้อมูล หรือ Train Test Split ดังนี้

- Training Set จำนวน 85% 425 รูปภาพ
  - Training Data 80% จำนวน 340 รูปภาพ
  - Validation Data 20% จำนวน 85 รูปภาพ
- Testing Set 15% จำนวน 75 รูปภาพ


ในงานวิจัยนี้ผู้วิจัยได้เลือกใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNNs) เป็นเครื่องมือในการทำกรจำแนกสายพันธุ์และระบุตัวตนของสุนัข เนื่องจาก CNNs เป็น Deep Learning ที่ได้รับความนิยมในการนำมาใช้ในงาน Image Processing ในกระบวนการทำ Classification โดยแบบจำลองที่เลือกใช้ นำมาจาก Keras หรือ Deep Learning Framework (<https://keras.io/>) สำหรับ python ของ TensorFlow มีประสิทธิภาพดังนี้

ตาราง 7 ตารางแสดงประสิทธิภาพของแบบจำลองที่นำมาใช้ในงานวิจัย จาก Keras

Model	Size (MB)	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth
Xception	88	79.0%	94.5%	22.9M	81
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
NASNetLarge	343	82.5%	96.0%	88.9M	533

ที่มา : <https://keras.io/api/applications/>

### 3.3 กระบวนการในการจำแนกสายพันธุ์ของสุนัข และประเมินประสิทธิภาพแบบจำลองในการจำแนกสายพันธุ์ของสุนัข



ภาพประกอบ 29 ขั้นตอนในการจำแนกสายพันธุ์ของสุนัข

การจำแนกสายพันธุ์ของสุนัข ผู้วิจัยได้นำชุดข้อมูลจาก Stanford Dogs Dataset และ Thai Dataset ที่ไม่มีการปรับปรุงแก้ไขใดๆ เป็นภาพของสุนัขเต็มตัว 1 ตัว ที่ถ่ายจากมุมด้านหน้าหรือด้านข้างโดยให้เห็นใบหน้าและลำตัวของสุนัข ซึ่งต้องไม่มีสิ่งของหรือเงาบัง และอยู่ในอิริยาบถที่มองเห็นลายของลำตัวและใบหน้าอย่างชัดเจน ถือเป็นกรนำ Soft Biometrics หรือส่วน

ที่สามารถมองเห็นความแตกต่างได้อย่างชัดเจนและไม่มีลักษณะเฉพาะ มาใช้ในการทดลอง โดยขั้นตอนทั้งหมดมีรายละเอียด ดังนี้

1. นำข้อมูล Stanford Dogs Dataset และ Thai Dataset มารวมกัน
2. นำภาพทั้งหมด ไปเข้ากระบวนการ Feature Extraction หรือสกัดคุณสมบัติของภาพโดยใช้ Pre-train Models ทั้ง 6 แบบจำลอง ที่ผู้วิจัยได้เลือกมาจาก จาก CNNs กำหนด Weight เป็น ImageNet และทำการลบ Layer สุดท้าย หรือ Classification Layer ออก
3. ทำการ Train Test Split ชุดข้อมูลรูปภาพทั้งหมด ดังนี้ Training Set 85% (Training Set:85%, Validation Set:15%), Testing Set 15%
4. สร้างแบบจำลอง CNNs ใหม่ หรือ New Classification Layer สำหรับการจำแนกสายพันธุ์ของสุนัข เพื่อปรับแต่งให้ Layer สุดท้ายของแบบจำลองสอดคล้องกับจำนวน Class ที่นำมาทดสอบ รวมไปถึงปรับแต่งให้เหมาะสม เพื่อให้แบบจำลองได้ค่าความแม่นยำที่สูง แต่ไม่เกิด Overfitting และ Underfitting โดยมีรายละเอียดดังนี้

ตาราง 8 ตารางแสดงโครงสร้างแบบจำลองใหม่ที่สร้างขึ้น ในการจำแนกสายพันธุ์ของสุนัข

Layer	กระบวนการ	หมายเหตุ
1	GlobalAveragePooling2D	ทำให้ข้อมูลกลายเป็น Matrix 2 มิติ
2	flatten	การทำให้ข้อมูลจากหลาย Channel ให้เป็น vector 1 มิติ
3	dense 512,activation = relu	เป็น Layer ที่มี 512 Nodes จะรับข้อมูลจาก Layer ก่อนหน้าและส่งข้อมูลต่อไปยัง Layer ถัดไป และกำหนด activation ให้เป็น relu หรือ (Rectified Linear Unit) โดยจะทำให้ output = input ถ้า input > 0 และ output = 0 ถ้า input <= 0 (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)
4	dropout 0.4	สุ่มให้ Neuron Network บางตัวหยุดทำงานระหว่าง Train ช่วยไม่ให้ Node ที่มี Weight มาก จน Node อื่น ไม่ได้เรียนรู้ (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)
5	dense 256,activation = relu	
6	dropout 0.4	
7	dense 128,activation = relu	
8	BatchNormalization	การทำ Normalization เพื่อปรับค่าข้อมูลให้อยู่ในขอบเขตที่กำหนดก่อนส่งออกไปยัง Layer ถัดไป ใช้ในการ ลด Error เพิ่มประสิทธิภาพในการทำนาย เมื่อเกิด Underfitting หรือ Overfitting (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)
9	dropout 0.4	
10	dense n_classes, activation = sigmoid	Layer output จำนวน Nodes = จำนวน class และกำหนดค่า sigmoid คือ กแปลงค่าให้มีค่าตั้งแต่ 0-1 (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)



## 5. Compile แบบจำลองที่สร้างขึ้นใหม่และกำหนดรายละเอียดต่างๆ ได้แก่

5.1 `loss="sparse_categorical_crossentropy"` การกำหนด Loss Function หรือ ค่าความคลาดเคลื่อนที่เกิดจากการเปรียบเทียบระหว่าง Label และค่าที่ได้จากการทำนาย โดยใช้ `SparseCategoricalCrossentropy` เหมาะสำหรับ output ที่มี Class เป็นจำนวนมาก หรือไม่เหมาะกับการทำเป็น one-hot encoding ซึ่ง Loss Function ดังกล่าว จะไม่สร้าง output เป็นแบบ One-hot Encoding แต่ยังคงการคำนวณค่าแบบ Cross-entropy ได้ ซึ่งเป็นวิธีลดการใช้ Memory (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)


5.2 `optimizer='adam'` การกำหนด optimizer หรือการปรับค่าพารามิเตอร์ของแบบจำลองเพื่อลดค่าของฟังก์ชันความสูญเสีย (loss function) ในแต่ละรอบการของ Train โดย Adam เป็น optimizer ที่มีวิธีการทำงานคล้ายกับการผสมระหว่างอัลกอริทึม Momentum และ RMSprop โดยสามารถช่วยให้การ Train แบบจำลองได้เร็วขึ้นและสามารถเก็บค่าของพารามิเตอร์ไว้ในการ Train ครั้งต่อไปได้ดีกว่า optimizer อื่นๆ ในบางกรณี (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)

5.3 `metrics=['accuracy']` การกำหนด metrics หรือตัววัดประสิทธิภาพของแบบจำลอง โดย Accuracy เป็นตัววัดประสิทธิภาพที่แสดงค่าความแม่นยำในการทำนาย โดยคำนวณจากจำนวนข้อมูลที่ทำนายถูกเทียบกับจำนวนข้อมูลทั้งหมด (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)

6. นำข้อมูล Training set ไปเข้าแบบจำลองที่สร้างขึ้นใหม่ หรือ Classification Layer สำหรับการจำแนกสายพันธุ์ เพื่อสอนให้แบบจำลองเรียนรู้ โดยกำหนดค่า `epoch = 40` (จำนวนรอบในการ Train) `Bach size = 128` (จำนวนข้อมูลที่ใช้ในแต่ละรอบของการ Train)

7. ทำการนำชุดข้อมูล Testing set ทดสอบประสิทธิภาพแบบจำลองที่สร้างขึ้นใหม่ และประเมินประสิทธิภาพโดยใช้ Accuracy, Precision, Recall และ F1 Score

### 3.4 กระบวนการในการระบุตัวตนของสุนัข และประเมินประสิทธิภาพแบบจำลองในการระบุตัวตน



#### ภาพประกอบ 30 ขั้นตอนในการระบุตัวตน

ในขั้นตอนการระบุตัวตนของสุนัข ผู้วิจัยได้นำชุดข้อมูลจาก Flickr-Dog Dataset และ Thai Dataset ที่แบ่งแยกเป็นรายตัว มาใช้ ซึ่งจะมีการตรวจจับใบหน้าของสุนัข เป็นการดำเนินการกับ Hard Biometrics หรือส่วนที่ไม่สามารถมองเห็นความแตกต่างได้อย่างชัดเจนแต่มีความเฉพาะเจาะจง โดยแม้ว่า Flickr-Dog Dataset จะถูกครอบตัดใบหน้ามาเรียบร้อยแล้ว แต่เพื่อให้ข้อมูลที่นำมาทดสอบมีความคล้ายกันมากที่สุดจึงมีการนำมาทำการตรวจจับใบหน้าอีกครั้งพร้อมกับชุดข้อมูล Thai Dataset มีการใช้ Pre-train Models จาก CNNs และแบบจำลองที่เรียนรู้กับภาพใบหน้าของบุคคลมาเปรียบเทียบประสิทธิภาพ และเนื่องจากจำนวนของ Dataset ที่นำมาใช้มีไม่มากนัก จึงมีการทดลองนำข้อมูลรูปภาพมาเพิ่มปริมาณและสร้างความหลากหลายให้กับชุดข้อมูล คือการทำ Data Augmentation เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลองสำหรับการระบุตัวตนสุนัขให้แม่นยำมากยิ่งขึ้น ในขั้นตอนนี้จะทำการแบ่งชุดข้อมูลก่อนการทำ Data Augmentation เพื่อป้องกันปัญหา Data Leakage หรือการที่แบบจำลองเห็นข้อมูลก่อน ทำให้ค่าความแม่นยำที่ได้ไม่ถูกต้อง และป้องกันปัญหา Overfitting หรือการที่ได้ค่าความแม่นยำของ Training set ที่สูงมาก แต่เมื่อนำไปใช้กับ Testing set กลับได้ค่าความแม่นยำที่ต่ำมาก จะทำให้แบบจำลองที่สร้างขึ้นทำนายถูกและไม่มีประสิทธิภาพ โดยขั้นตอนทั้งหมดมีรายละเอียด ดังนี้

1. ในส่วนของข้อมูลที่จะนำไปใช้ในขั้นตอนการระบุตัวตนสุนัขต้องเลือกรูปภาพที่มีเฉพาะใบหน้าของสุนัขเพราะมีลักษณะความเฉพาะเจาะจงของสุนัขแต่ละตัวที่แตกต่างกัน จึงต้องนำชุดข้อมูลมาทำการตรวจจับใบหน้า (Face Detection) ก่อน โดยในงานวิจัยนี้ใช้ Dlib Library v19.4 และ OpenCV 3.3.0 (Vlachynska et al., 2019) ซึ่งสามารถตรวจจับใบหน้าได้ (Face

Detection) และสามารถตรวจจับจุดสังเกตบนใบหน้าได้ (Facial Landmark Detection) และทำการครอบตัดรูปที่ตรวจจับได้ ปรับขนาดเป็น 250x250 pixel

2. นำข้อมูล Flickr-Dogs และ Thai Dataset มารวมกัน

3. ทำการแบ่ง Train Test Split ภาพทั้งหมด ดังนี้ Training Set 85% (Training Set:80%, Validation Set:20%), Testing Set 15%

4. ทำการ Data Augmentation เพื่อเพิ่มจำนวนรูปภาพของสุนัข โดย 1 รูปจะเพิ่มรูปละ 6 รูปแบบ โดยมีรายละเอียดการปรับรูปภาพ ดังนี้

ตาราง 9 ตารางแสดงกระบวนการในการทำ Data Augmentation

ลำดับ	กระบวนการ	หมายเหตุ
1	rotation_range = 45	การหมุนรูปภาพในช่วง 45 องศา
2	shear_range = 0.3	การบิดรูปภาพในระยะไม่เกิน 30%
3	zoom_range = 0.2	การขยายภาพอยู่ระยะไม่เกิน 20%
4	horizontal_flip = True	การพลิกรูปภาพเป็นแนวนอน
5	brightness_range = (0.3, 1.8)	การปรับเปลี่ยนค่าความสว่างของรูปภาพ (Brightness) มีค่าอยู่ในช่วงระหว่าง 0.3 ถึง 1.8

5. นำภาพแต่ละ Dataset หลังจากทำ Data Augmentation เรียบร้อยแล้ว ไปเข้ากระบวนการ Feature Extraction หรือสกัดคุณสมบัตินี้ของภาพโดยใช้ Pre-train Models ที่ได้เลือกมาจาก CNNs ใช้ Weight เป็น ImageNet จำนวน 5 แบบจำลอง ได้แก่ ResNet50 VGG16 MobileNetV2 InceptionV3 และ NasNetLarge ซึ่งน้อยกว่าจำนวนแบบจำลองที่นำไปใช้ในการจำแนกสายพันธุ์ เนื่องจากในขั้นตอนนี้ผู้วิจัยมีการเพิ่มแบบจำลองที่มีการเรียนรู้จากใบหน้าของบุคคล หรือแบบจำลองสำหรับการจดจำใบหน้า (Face Recognition) โดยเฉพาะอย่าง VGGFace และเลือกใช้โครงสร้าง VGG และ ResNet50 เพื่อเปรียบเทียบประสิทธิภาพการระบุตัวตน โดยทั้งหมดจะทำการลบ Layer สุดท้าย หรือ Classification Layer ออก

6. สร้างแบบจำลอง CNNs ใหม่ หรือ New Classification Layer สำหรับการระบุตัวตน เพื่อปรับแต่งให้ Layer สุดท้ายของแบบจำลองสอดคล้องกับจำนวน Class ที่นำมาทดสอบรวมไปถึงปรับแต่งให้เหมาะสม เพื่อให้แบบจำลองได้ค่าความแม่นยำที่สูง แต่ไม่เกิด Overfitting และ Underfitting โดยมีรายละเอียดดังนี้

ตาราง 10 ตารางแสดงโครงสร้างแบบจำลองใหม่ที่สร้างขึ้น ในการระบุตัวตน

Layer	กระบวนการ	หมายเหตุ
1	GlobalAveragePooling2D	ทำให้ข้อมูลกลายเป็น Matrix 2 มิติ
2	flatten	การทำให้ข้อมูลจากหลาย Channel ให้เป็น vector 1 มิติ
3	dropout 0.8	การสุ่มให้ Neuron Network บางตัวหยุดทำงานระหว่างการ Train ช่วยไม่ให้ Node ที่มี Weight มาก มีอำนาจมากเกินไป จน Node อื่น ไม่ได้เรียนรู้ (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)
4	Dense100, activation = relu	เป็น Layer ที่มี 100 Nodes ซึ่งจะรับข้อมูลจาก Layer ก่อนหน้าและส่งข้อมูลต่อไปยัง Layer ถัดไป และกำหนด activation หรือฟังก์ชันที่ควบคุม Output ของ Layer นี้ ให้เป็น relu หรือ (Rectified Linear Unit) โดยจะกำหนดให้ output มีค่าเท่ากับ input ถ้า input มากกว่า 0 และมีค่าเท่ากับ 0 ถ้า input น้อยกว่าเท่ากับ 0 (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)
5	dropout 0.4	
6	dense n_classes, activation = sigmoid	เป็น Layer output จำนวน Node จะเท่ากับ จำนวน class และการกำหนดค่า sigmoid คือ การแปลงค่าให้มีค่าตั้งแต่ 0-1 (ผศ.ดร.กอบเกียรติ สระอุบล, 2565)

7. Compile แบบจำลองที่สร้างขึ้นใหม่และกำหนดรายละเอียดต่างๆ เช่นเดียวกับ การจำแนกสายพันธุ์ของสุนัข ได้แก่ `loss="sparse_categorical_crossentropy"`, `optimizer='adam'` และ `metrics=['accuracy']`

8. นำข้อมูล Training set ไปเข้าแบบจำลองที่สร้างขึ้นใหม่ หรือ Classification Layer สำหรับการระบุตัวตน เพื่อสอนให้แบบจำลองเรียนรู้ โดยกำหนดค่า `epoch = 200` (จำนวนรอบในการ Train) `Bach size = 258` (จำนวนข้อมูลที่ใช้ในแต่ละรอบของการ Train)

9. ทำการนำชุดข้อมูล Testing set ทดสอบประสิทธิภาพแบบจำลองที่สร้างขึ้นใหม่ และประเมินประสิทธิภาพโดยใช้ Accuracy, Precision, Recall และ F1 Score

10. ทดลองนำชุดข้อมูล Testing set เฉพาะสายพันธุ์ไทย จำนวน 20 รูปภาพ 20 ตัว และ 2 สายพันธุ์ ที่ยังไม่ทำการ Data Augmentation ไปทำการจำแนกสายพันธุ์ และการระบุตัวตนของสุนัข ตั้งแต่เริ่มต้นจนถึงขั้นตอนสุดท้าย เพื่อวัดประสิทธิภาพเมื่อมีการใช้งานร่วมกัน กับชุดข้อมูลเดียวกัน

## บทที่ 4

### ผลการดำเนินการวิจัย

ผู้วิจัยได้ทำการศึกษาและทดลองตามกระบวนการ และขั้นตอนต่างๆ ที่ได้ออกแบบไว้ข้างต้น โดยผลการดำเนินการหรือผลการทดลองแบ่งหัวข้อได้ดังนี้

1. ตัววัดประสิทธิภาพของแบบจำลองที่ใช้ในงานวิจัย
2. ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกสายพันธุ์ของสุนัข
3. ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในกระบวนการตัวตนของสุนัข

#### 4.1 ตัววัดประสิทธิภาพของแบบจำลองที่ใช้ในงานวิจัย

##### 4.1.1 Confusion Matrix

เครื่องมือทางสถิติที่ใช้สำหรับการประเมินประสิทธิภาพของการจำแนกประเภท (Classification) โดยเฉพาะงาน Machine Learning หรือ Deep Learning ซึ่งสามารถใช้ในการวัดประสิทธิภาพของแบบจำลองที่สร้างขึ้นและแสดงจำนวนผลการทำนายในรูปแบบตารางประกอบไปด้วยข้อมูล 4 ประเภท ได้แก่ True Positive (TP), False Positive (FP), False Negative (FN), และ True Negative (TN) โดยแต่ละประเภท มีความหมายดังนี้

- True Positive (TP) จำนวน Sample ของการทำนายว่าเป็น Positive และค่าจริงเป็น Positive หรือ จำนวน Sample ที่แบบจำลองทำนายได้ถูกต้องใน Class ที่กำลังสนใจ
- False Positive (FP) จำนวน Sample ของการทำนาย ว่าเป็น Positive แต่ค่าจริงเป็น Negative หรือ จำนวน Sample ที่แบบจำลองทำนายผิดใน Class ที่กำลังสนใจ
- False Negative (FN) จำนวน Sample ของการทำนายว่าเป็น Negative แต่ค่าจริงเป็น Positive หรือ จำนวน Sample ที่แบบจำลองทำนายผิดใน Class ที่ไม่ได้สนใจ
- True Negative (TN) จำนวน Sample ของการทำนาย ว่าเป็น Negative และผลจริงก็เป็น Negative หรือ จำนวน Sample ที่แบบจำลองทำนายทั้งถูกใน Class ที่ไม่ได้สนใจ

		Actual Class	
		Positive	Negative
Prediction Class	Positive	TP	FP
	Negative	FN	TN

ภาพประกอบ 31 ตาราง Confusion Matrix

#### 4.1.2 Accuracy

ค่าความแม่นยำหรือประสิทธิภาพโดยรวมของแบบจำลองในการทำนายสายพันธุ์ ซึ่งคำนวณจากจำนวนภาพที่แบบจำลองทำนายได้ถูกต้องทั้งหมดหารด้วยจำนวนของรูปภาพทั้งหมด ตามสมการที่ 3 ซึ่งค่า Accuracy จะมีค่าอยู่ระหว่าง 0 ถึง 1 โดยค่าที่ใกล้ 1 จะแสดงว่าแบบจำลองมีประสิทธิภาพในการทำนายอย่างแม่นยำ

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (3)$$

#### 4.1.3 Precision

ค่าความถูกต้องที่แบบจำลองทำการทำนาย Class ที่กำลังสนใจ (Class Positive หรือ บวก) ซึ่งคำนวณจากจำนวนภาพที่แบบจำลองทำนายได้ถูกต้องใน Class ที่กำลังสนใจ (TP) หารด้วยจำนวนภาพที่แบบจำลองทำนายทั้งถูก (TP) และผิด (FP) ใน Class ที่กำลังสนใจ ตามสมการที่ 4 ซึ่งค่า Precision จะมีค่าอยู่ระหว่าง 0 ถึง 1 โดยค่าที่ใกล้ 1 จะแสดงว่าแบบจำลองมีประสิทธิภาพสูงในการทำนาย Class ที่กำลังสนใจได้อย่างถูกต้อง

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

#### 4.1.4 Recall

ค่าครบถ้วนที่แบบจำลองทำการจำแนกของ Class ที่กำลังสนใจ ซึ่งคำนวณจากจำนวนภาพที่แบบจำลองทำนายได้ถูกต้องใน Class ที่กำลังสนใจ (TP) หารด้วยจำนวนภาพที่แบบจำลองทำนายทั้งถูกใน Class ที่กำลังสนใจ (TP) และจำนวนภาพที่แบบจำลองทำนายผิดใน Class ที่ไม่ได้สนใจ (Class Negative หรือ ลบ) (FN) ตามสมการที่ 5 ซึ่งค่า Recall จะมีค่าอยู่ระหว่าง 0 ถึง 1 โดยค่าที่ใกล้ 1 จะแสดงว่าแบบจำลองมีประสิทธิภาพในการทำนาย Class ที่กำลังสนใจได้อย่างครบถ้วน

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

#### 4.1.5 F1-Score

ค่าที่แสดงประสิทธิภาพของแบบจำลอง โดยการคำนวณหาค่าเฉลี่ยฮาร์มอนิก (Harmonic Mean) ของ Precision และ Recall ตามสมการที่ 6 สำหรับ F1-score จะมีค่าอยู่ระหว่าง 0 ถึง 1 โดยค่าที่ใกล้ 1 จะแสดงว่าแบบจำลองมีประสิทธิภาพสูงในการทำนาย

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision+Recall} \quad (6)$$

#### 4.1.6 Top-k Accuracy

การวัดประสิทธิภาพการทำนายของแบบจำลอง Machine Learning โดยใช้วิธีการเปรียบเทียบค่าความน่าจะเป็น (Probability) ของแบบจำลองกับค่าความเป็นจริง (Ground Truth) โดยเลือกเอาเพียง k ค่าที่มีความน่าจะเป็นสูงสุดมาคำนวณค่าความถูกต้อง (Accuracy) ของแบบจำลองนั้น ๆ

ตัวอย่างเช่น ถ้ามีภาพที่ให้มาและต้องการให้แบบจำลองจำแนกว่าเป็นสุนัขสายพันธุ์ใด โดยแบบจำลองมีค่า Top-1 Score เท่ากับ 0.8 และ Top-5 Score เท่ากับ 0.95 หมายความว่าแบบจำลองทำนายได้ว่าภาพนี้เป็นสุนัขสายพันธุ์บางแก้ว โดยมีความน่าจะเป็น 80% ใน Top-1 และ 95% ใน Top-5 ของข้อมูลที่ใช้สำหรับการทดสอบแบบจำลอง ซึ่งข้อมูลนั้นจะมีมากที่สุด 5 อันดับหรือ 5 สายพันธุ์ของสุนัขที่เป็นไปได้

#### 4.2 ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกสายพันธุ์ของสุนัข

ในการจำแนกสายพันธุ์ของสุนัขจะเป็นการเปรียบเทียบประสิทธิภาพระหว่างการใช้ Pre-train Models จาก CNNs แบบดั้งเดิมในการจำแนกสายพันธุ์ของสุนัข และการใช้ Pre-train Models จาก CNNs ในการสกัดเวกเตอร์คุณลักษณะของรูปภาพร่วมกับแบบจำลองที่สร้างขึ้นใหม่โดยผู้วิจัย โดยในการทดลองนี้ได้มีการสร้างชุดข้อมูล 2 ชุด ได้แก่ ชุดข้อมูลสุนัขสายพันธุ์ต่างประเทศที่ปรากฏใน ImageNet Dataset และชุดข้อมูลที่มีการเพิ่มภาพสุนัขสายพันธุ์ไทยจำนวน 2 สายพันธุ์และเปรียบเทียบประสิทธิภาพการรู้จำของแบบจำลองในชุดข้อมูลทั้งสอง และได้มีการปรับพารามิเตอร์ของ New Classification ที่ได้สร้างขึ้นใหม่ให้เหมาะสมกับลักษณะของชุดข้อมูลที่นำมาใช้ เพื่อรักษาสมดุลระหว่างความคลาดเคลื่อนและความแปรปรวนของแบบจำลอง (Model bias and variance)

ตาราง 11 ผลการทดลองการจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification)

Dataset	Model	Accuracy		Precision (Macro-avg)	Recall (Macro-avg)	F1-Score (Macro-avg)
		Train	Test			
Full Layers						
Sf only	VGG16		0.74	0.74	0.72	0.73
	ResNet50		0.78	0.78	0.76	0.77
	MobileNetV2		0.83	0.82	0.81	0.82
	InceptionV3		0.89	0.88	0.87	0.87
	Xception		0.89	0.88	0.87	0.87
	NasNetLarge		<u>0.92</u>	0.9	0.9	0.9
Sf + Th	VGG16		0.72	0.72	0.71	0.71
	ResNet50		0.77	0.75	0.75	0.75
	MobileNetV2		0.82	0.8	0.8	0.8
	InceptionV3		0.88	0.85	0.86	0.85
	Xception		0.87	0.85	0.86	0.85
	NasNetLarge		<u>0.91</u>	0.88	0.89	0.88



ตาราง 11 (ต่อ)

Dataset	Model	Accuracy		Precision	Recall	F1-Score
		Train	Test	(Macro-avg)	(Macro-avg)	(Macro-avg)
Pre-train Models & New Classification						
Sf only	VGG16	0.87	0.60	0.62	0.60	0.59
	ResNet50	0.92	0.67	0.69	0.67	0.66
	MobileNetV2	0.96	0.77	0.78	0.77	0.77
	InceptionV3	0.94	0.89	0.89	0.89	0.89
	Xception	0.96	0.88	0.89	0.88	0.88
	NasNetLarge	0.98	<b>0.93</b>	0.94	0.93	0.93
Sf + Th	VGG16	0.88	0.61	0.63	0.60	0.60
	ResNet50	0.93	0.66	0.68	0.66	0.65
	MobileNetV2	0.96	0.77	0.78	0.76	0.76
	InceptionV3	0.94	0.89	0.89	0.88	0.88
	Xception	0.97	0.87	0.88	0.87	0.87
	NasNetLarge	0.98	<b>0.93</b>	0.93	0.93	0.93

จากตาราง 11 ได้มีการเลือกใช้ชุดข้อมูลในการทดลองแบ่งออกเป็น 2 กลุ่ม ได้แก่ Sf only คือการใช้ชุดข้อมูล Stanford Dogs Dataset เพียงอย่างเดียว หรือเป็นการใช้ชุดข้อมูลเฉพาะสุนัขสายพันธุ์ต่างประเทศที่ ImageNet มีข้อมูลอยู่ และ Pre-train Models จาก CNNs เคยเรียนรู้สายพันธุ์เหล่านี้แล้ว และ Sf + Thai คือการใช้ชุดข้อมูล ข้อมูล Stanford Dogs Dataset ร่วมกับ Thai Dataset หรือสายพันธุ์ต่างประเทศรวมกับสายพันธุ์ไทยทั้ง 2 สายพันธุ์ โดยแบ่งการทดลองออกเป็น 4 วิธีการ และได้ผลลัพธ์ดังนี้

1. การเปรียบเทียบแบบจำลอง CNNs ดั้งเดิม (Full Layer) ในการจำแนกสายพันธุ์กับชุดข้อมูล Stanford พบว่าแบบจำลองที่มีค่าความแม่นยำต่ำที่สุดคือ VGG16 (74%) โดยแบบจำลองที่มีค่าความแม่นยำสูงสุดได้แก่ NasNetLarge (92%)

2. การเปรียบเทียบแบบจำลอง CNNs ดั้งเดิม (Full Layer) ในการจำแนกสายพันธุ์กับชุดข้อมูล Stanford และ สุนัขไทย พบว่าแบบจำลองที่มีค่าความแม่นยำต่ำที่สุดคือ VGG16 (72%) โดยแบบจำลองที่มีค่าความแม่นยำสูงสุดได้แก่ NasNetLarge (91%)

3. การเปรียบเทียบ Pre-train Models ในการสกัดเวกเตอร์คุณลักษณะกับชุดข้อมูล Stanford ร่วมกับ New Classification ที่ผู้วิจัยได้สร้างขึ้น พบว่าแบบจำลองที่มีค่าความแม่นยำต่ำที่สุดคือ VGG16 (61%) โดยแบบจำลองที่มีค่าความแม่นยำสูงสุดได้แก่ NasNetLarge (93%)

4. การเปรียบเทียบ Pre-train Models ในการสกัดเวกเตอร์คุณลักษณะกับชุดข้อมูล Stanford และ สุนัขไทย ร่วมกับ New Classification ที่ผู้วิจัยได้สร้างขึ้น พบว่าแบบจำลองที่มีค่าความแม่นยำต่ำที่สุดคือ VGG16 (60%) โดยแบบจำลองที่มีค่าความแม่นยำสูงสุดได้แก่ NasNetLarge (93%)

ซึ่งจากการทดสอบการจำแนกสายพันธุ์ของสุนัขทั้งไทยและต่างประเทศ ประสิทธิภาพที่ได้โดยใช้ Pre-train Models แบบดั้งเดิมทั้ง 6 Models พบว่าแบบจำลอง NasNetLarge มีความแม่นยำสูงถึง 91% และลำดับรองลงมา ได้แก่แบบจำลอง InceptionV3, Xception, MobileNetV2 โดยมีความแม่นยำอยู่ที่ 88%, 87%, 82% ตามลำดับ แต่แบบจำลองแบบดั้งเดิมเหล่านี้ไม่สามารถจำแนกสุนัขที่เป็นสายพันธุ์ไทยได้ เนื่องจากไม่เคยมีการฝึกฝนกับ Class สายพันธุ์ไทยมาก่อน ซึ่งเมื่อเปลี่ยนวิธีการโดยการใช้งาน Feature Extraction จาก Pretrained Models และทำการสร้าง Classification Layer ใหม่ เพื่อกำหนด Layer ต่างๆ ให้เหมาะสมกับชุดข้อมูล สามารถให้ประสิทธิภาพความแม่นยำสูงที่สุดอยู่ที่ 93% ได้แก่ แบบจำลอง NasNetLarge และลำดับรองลงมา ได้แก่แบบจำลอง InceptionV3, Xception โดยมีความแม่นยำอยู่ที่ 89%, 87% ตามลำดับ โดยในงานจำแนกสายพันธุ์ของสุนัขจะเน้นที่ค่า Precision หรือ ค่าความถูกต้องของการทำนายสายพันธุ์ของสุนัข เนื่องจากต้องการนำแบบจำลองการจำแนกสายพันธุ์ไปช่วยลดพื้นที่ในการค้นหาตัวตนของสุนัข หาก Precision มีค่าน้อย จะทำให้โอกาสที่เจอสุนัขตัวนั้นน้อยลงจนถึงไม่สามารถระบุตัวตนได้ ซึ่งแบบจำลองที่มีค่า Precision สูงที่สุดยังคงเป็น NasNetLarge ที่ 93% รองลงมาเป็น InceptionV3 89% และน้อยที่สุดที่ VGG16 63%

ตาราง 12 แสดงค่า Precision Recall และ F1-Score ของแบบจำลองที่ใช้ Pre-train Models เป็น NasNetLarge ร่วมกับแบบจำลองที่สร้างใหม่ และใช้รูปภาพ SF+Thai Dataset

Labels	Labels Name	Precision	Recall	F1-score	Support
0	Chihuahua	1	1	1	23
1	Japanese_spaniel	0.964286	1	0.981818	27
2	Maltese_dog	0.945946	0.921053	0.933333	38
3	Pekinese	0.956522	1	0.977778	22
4	Shih-Tzu	0.928571	0.8125	0.866667	32
5	Blenheim_spaniel	1	0.964286	0.981818	28

ตาราง 12 (ต่อ)

Labels	Labels Name	Precision	Recall	F1-score	Support
6	papillon	1	1	1	29
7	toy_terrier	0.956522	0.846154	0.897959	26
8	Rhodesian_ridgeback	0.916667	0.846154	0.88	26
9	Afghan_hound	1	1	1	36
10	basset	0.96	0.923077	0.941176	26
11	beagle	0.805556	0.966667	0.878788	30
12	bloodhound	0.931034	0.964286	0.947368	28
13	bluetick	0.962963	1	0.981132	26
14	black-and-tan_coonhound	1	0.916667	0.956522	24
15	Walker_hound	0.888889	0.695652	0.780488	23
16	English_foxhound	0.782609	0.75	0.765957	24
17	redbone	1	0.954545	0.976744	22
18	borzoi	1	1	1	22
19	Irish_wolfhound	0.909091	0.9375	0.923077	32
20	Italian_greyhound	0.928571	0.962963	0.945455	27
21	whippet	1	0.928571	0.962963	28
22	Ibizan_hound	0.965517	1	0.982456	28
23	Norwegian_elkhound	1	0.933333	0.965517	30
24	otterhound	0.956522	0.956522	0.956522	23
25	Saluki	1	1	1	30
26	Scottish_deerhound	0.941176	0.914286	0.927536	35
27	Weimaraner	1	0.958333	0.978723	24
28	Staffordshire_bullterrier	0.791667	0.826087	0.808511	23
29	American_Staffordshire_terrier	0.846154	0.88	0.862745	25
30	Bedlington_terrier	1	1	1	28
31	Border_terrier	1	1	1	26
32	Kerry_blue_terrier	0.962963	0.962963	0.962963	27
33	Irish_terrier	1	0.96	0.979592	25
34	Norfolk_terrier	0.928571	1	0.962963	26
35	Norwich_terrier	1	0.821429	0.901961	28
36	Yorkshire_terrier	0.806452	1	0.892857	25
37	wire-haired_fox_terrier	0.92	1	0.958333	23
38	Lakeland_terrier	0.966667	0.966667	0.966667	30
39	Sealyham_terrier	1	0.966667	0.983051	30
40	Airedale	0.967742	1	0.983607	30

ตาราง 12 (ต่อ)

Labels	Labels Name	Precision	Recall	F1-score	Support
41	cairn	0.967742	1	0.983607	30
42	Australian_terrier	0.9	0.9	0.9	30
43	Dandie_Dinmont	0.961538	0.925926	0.943396	27
44	Boston_bull	1	1	1	27
45	miniature_schnauzer	0.913043	0.913043	0.913043	23
46	giant_schnauzer	0.916667	0.956522	0.93617	23
47	standard_schnauzer	0.84	0.875	0.857143	24
48	Scotch_terrier	0.923077	1	0.96	24
49	Tibetan_terrier	0.775	1	0.873239	31
50	silky_terrier	0.958333	0.851852	0.901961	27
51	soft-coated_wheaten_terrier	0.923077	1	0.96	24
52	West_Highland_white_terrier	0.961538	0.961538	0.961538	26
53	Lhasa	0.793103	0.821429	0.807018	28
54	flat-coated_retriever	0.92	1	0.958333	23
55	curly-coated_retriever	0.956522	0.956522	0.956522	23
56	golden_retriever	1	1	1	22
57	Labrador_retriever	0.888889	0.96	0.923077	25
58	Chesapeake_Bay_retriever	1	1	1	25
59	German_short-haired_pointer	0.954545	0.913043	0.933333	23
60	vizsla	0.821429	1	0.901961	23
61	English_setter	0.923077	1	0.96	24
62	Irish_setter	0.956522	0.956522	0.956522	23
63	Gordon_setter	0.956522	0.956522	0.956522	23
64	Brittany_spaniel	1	1	1	23
65	clumber	1	0.909091	0.952381	22
66	English_springer	0.916667	0.916667	0.916667	24
67	Welsh_springer_spaniel	1	1	1	22
68	cocker_spaniel	1	1	1	23
69	Sussex_spaniel	0.958333	1	0.978723	23
70	Irish_water_spaniel	1	0.956522	0.977778	23
71	kuvasz	1	0.826087	0.904762	23
72	schipperke	1	0.956522	0.977778	23
73	groenendael	1	1	1	22
74	malinois	1	1	1	22
75	briard	0.913043	0.913043	0.913043	23

ตาราง 12 (ต่อ)

Labels	Labels Name	Precision	Recall	F1-score	Support
76	kelpie	0.956522	0.956522	0.956522	23
77	komondor	1	0.956522	0.977778	23
78	Old_English_sheepdog	1	0.92	0.958333	25
79	Shetland_sheepdog	0.88	0.956522	0.916667	23
80	collie	0.941176	0.695652	0.8	23
81	Border_collie	0.846154	0.956522	0.897959	23
82	Bouvier_des_Flandres	0.904762	0.826087	0.863636	23
83	Rottweiler	1	0.956522	0.977778	23
84	German_shepherd	1	1	1	23
85	Doberman	0.916667	0.956522	0.93617	23
86	miniature_pinscher	0.928571	0.928571	0.928571	28
87	Greater_Swiss_Mountain_dog	0.916667	0.88	0.897959	25
88	Bernese_mountain_dog	0.885714	0.96875	0.925373	32
89	Appenzeller	0.85	0.73913	0.790698	23
90	EntleBucher	0.870968	0.870968	0.870968	31
91	boxer	1	0.863636	0.926829	22
92	bull_mastiff	0.92	0.958333	0.938776	24
93	Tibetan_mastiff	0.958333	1	0.978723	23
94	French_bulldog	1	1	1	24
95	Great_Dane	1	0.913043	0.954545	23
96	Saint_Bernard	1	1	1	26
97	Eskimo_dog	0.428571	0.26087	0.324324	23
98	malamute	0.92	0.851852	0.884615	27
99	Siberian_husky	0.487179	0.678571	0.567164	28
100	affenpinscher	0.954545	0.954545	0.954545	22
101	basenji	0.96875	1	0.984127	31
102	pug	1	1	1	30
103	Leonberg	1	1	1	31
104	Newfoundland	1	0.896552	0.945455	29
105	Great_Pyrenees	0.864865	1	0.927536	32
106	Samoyed	1	1	1	33
107	Pomeranian	0.970588	1	0.985075	33
108	chow	1	1	1	29
109	keeshond	1	1	1	23
110	Brabancon_griffon	1	0.869565	0.930233	23

ตาราง 12 (ต่อ)


Labels	Labels Name	Precision	Recall	F1-score	Support
111	Pembroke	0.96	0.888889	0.923077	27
112	Cardigan	0.814815	0.956522	0.88	23
113	toy_poodle	0.75	0.652174	0.697674	23
114	miniature_poodle	0.652174	0.652174	0.652174	23
115	standard_poodle	0.84	0.875	0.857143	24
116	Mexican_hairless	1	0.958333	0.978723	24
117	dingo	0.96	1	0.979592	24
118	dhole	1	0.909091	0.952381	22
119	African_hunting_dog	0.96	0.96	0.96	25
120	Thai_Bangkaew	0.925926	0.925926	0.925926	27
121	Thai_Ridgeback	0.892857	1	0.943396	25

เนื่องจากแบบจำลอง NasNetLarge เป็นแบบจำลองที่ให้ค่าความแม่นยำที่สูงที่สุดทั้งจากการใช้ Pre-train Models แบบดั้งเดิมและ Feature Extraction จาก Pre-train Models ร่วมกับการสร้าง Classification Layer ใหม่ และผลลัพธ์จากการทำนายโดยแบบจำลอง NasNetLarge ทำนายถูกต้องที่สุด โดยทำนายถูกต้องทั้งหมด (100%) จำนวน 40 Classes และ ทำนายถูกต้องน้อยที่สุด Class 97 หรือ Eskimo\_dog จำนวน 6 รูปภาพ จาก 23 รูปภาพ เมื่อเทียบกับจากแบบจำลอง VGG16 ที่ให้ค่าความแม่นยำที่น้อยที่สุดจากทุกวิธีการทดลอง ทำนายถูกต้องที่สุดใน Class 1 หรือ Japanese\_spaniel จำนวน 26 รูปภาพ จาก 28 รูปภาพ ทำนายถูกต้องน้อยที่สุดใน Class 50 หรือ silky\_terrier จำนวน 3 รูปภาพ จาก 27 รูปภาพ โดยทำนายเป็น Class 36 หรือ Yorkshire\_terrier จำนวน 13 รูปภาพ จาก 27 รูปภาพ ซึ่งทั้ง 2 แบบจำลอง สามารถทำนายสุนัขสายพันธุ์ไทยทั้งสองสายพันธุ์ได้ โดย NasNetLarge ทำนายถูกต้องทั้งหมดสองสายพันธุ์ 50 จาก 52 รูปภาพ หรือ 94% และ VGG ทำนายถูกต้องรวมทั้งหมดสองสายพันธุ์ 40 จาก 55 รูปภาพ (คิดเป็น 82%)

และจากการทดลองสร้างแบบจำลองในการจำแนกสายพันธุ์ได้ผลการทดสอบระหว่างค่า Accuracy และค่า Loss Function ระหว่าง Training Set กับ Validation Set โดยแสดงผ่านกราฟ Loss Function ซึ่งเป็นกราฟที่แสดงค่าความผิดพลาดของแบบจำลองที่ถูกฝึก ตามจำนวนรอบการฝึก (epoch) หรือจำนวนการปรับค่าพารามิเตอร์ในแบบจำลอง (iteration) ซึ่งในงานวิจัยนี้เราได้ใช้ข้อมูล Training Set กับ Validation Set ในการฝึกหรือการ Train Model ซึ่งหากค่า loss ลดลงตาม

จำนวนรอบการฝึกแสดงว่าแบบจำลองแสดงให้เห็นว่าแบบจำลองมีความผิดพลาดน้อยลง โดยผลลัพธ์ของแต่ละแบบจำลอง ดังภาพประกอบด้านล่าง


### Results using Feature Extraction from **VGG16 (SF only)**



ภาพประกอบ 32 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (SF only)

### Results using Feature Extraction from **VGG16 (SF + Thai)**


Results using Feature Extraction from VGG16 sf +th



ภาพประกอบ 33 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (SF+Thai)

## Results using Feature Extraction from **ResNet50 (SF only)**


Results using Feature Extraction from ResNet50



ภาพประกอบ 34 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (SF only)

## Results using Feature Extraction from **ResNet50 (SF + Thai)**


Results using Feature Extraction from ResNet50 SF+TH



ภาพประกอบ 35 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (SF+Thai)




### Results using Feature Extraction from **MobileNetV2 (SF only)**



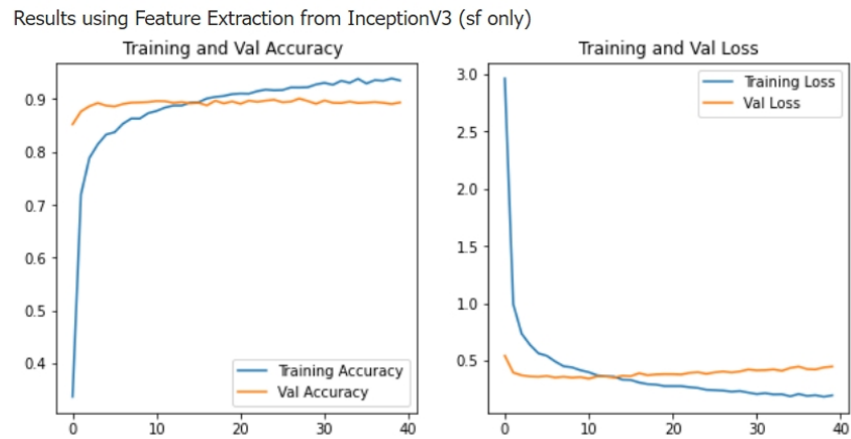
ภาพประกอบ 36 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2(SF only)

### Results using Feature Extraction from **MobileNetV2 (SF + Thai)**




ภาพประกอบ 37 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (SF+Thai)

### Results using Feature Extraction from InceptionV3 (SF only)



ภาพประกอบ 38 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (SF only)


### Results using Feature Extraction from InceptionV3 (SF + Thai)



ภาพประกอบ 39 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (SF+Thai)

## Results using Feature Extraction from **Xception (SF only)**


Results using Feature Extraction from Xception



ภาพประกอบ 40 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ Xception (SF only)


## Results using Feature Extraction from **Xception (SF + Thai)**

Results using Feature Extraction from Xception



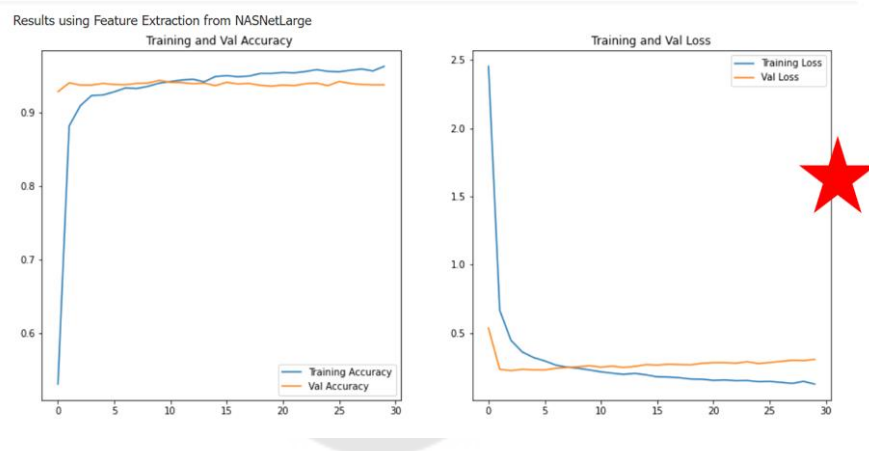
ภาพประกอบ 41 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ Xception (SF+Thai)

### Results using Feature Extraction from **NASNetLarge (SF only)**



ภาพประกอบ 42 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (SF only)

### Results using Feature Extraction from **NASNetLarge (SF + Thai)**



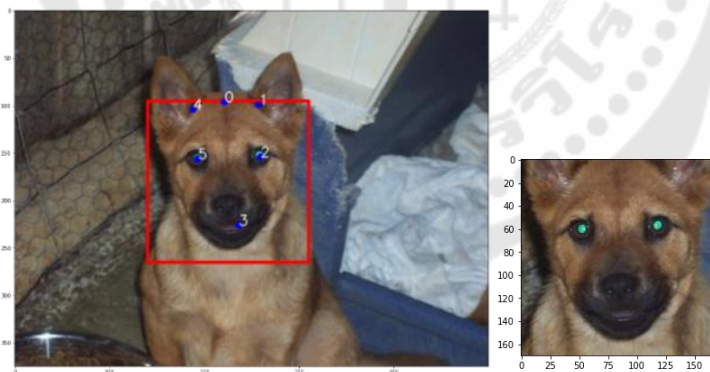
ภาพประกอบ 43 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (SF+Thai)

จากกราฟในภาพประกอบ 32-43 จะเห็นว่า แบบจำลองที่สร้างขึ้นมีการปรับจูนพารามิเตอร์โดยรวมสำหรับการทดลองอยู่ในระดับกลาง ไม่ทำให้เกิด Overfitting และ Underfitting กับแบบจำลองใดแบบจำลองใดแบบจำลองหนึ่งมากเกินไป โดย Pre-train Models ที่กราฟเป็นไปในทิศทางที่ดีที่สุด คือ NASNetLarge ที่ใช้ชุดข้อมูล Stanford Dataset ร่วมกับ Thai Dataset ซึ่งได้ทั้งค่า Accuracy ที่สูง และค่า Loss ที่ต่ำ

#### 4.3 ผลการดำเนินการและการเปรียบเทียบประสิทธิภาพของแบบจำลองในการระบุตัวตนของสุนัข

##### 4.3.1 ผลการตรวจจับใบหน้าสุนัข

ในการระบุตัวตนของสุนัขจำเป็นต้องใช้ใบหน้าของสุนัข เนื่องจากใบหน้าของสุนัขถือเป็น Hard Biometrics ที่ไม่สามารถสังเกตเห็นได้อย่างชัดเจน มีหลากหลายและมีความจำเพาะของสุนัขแต่ละตัว โดยจึงต้องมีการใช้เทคนิคการตรวจจับใบหน้า หรือ Face Detection โดยในขั้นตอนนี้ผู้วิจัยได้นำ Dlib Library v19.4 และ OpenCV 3.3.0 (Vlachynska et al., 2019) ซึ่งสามารถตรวจจับใบหน้าได้ (Face Detection) และสามารถตรวจจับจุดสังเกตบนใบหน้าได้ (Facial Landmark Detection) นำมาเป็นเครื่องมือในการตรวจจับใบหน้าโดยมีการใช้งานกับรูปภาพ Thai Dataset ซึ่งเป็นรูปภาพของสุนัขสายพันธุ์ไทย ได้แก่ บางแก้วและหลังอาน จำนวน 20 ตัว รวมทั้งหมด 126 รูปภาพ เมื่อทำการตรวจจับใบหน้า ได้ผลการตรวจจับรูปภาพประกอบ 44 ซึ่งผลลัพธ์จะได้รูปภาพขนาด 250x250 pixel โดย Library จะทำการตรวจจับจากจุดบนใบหน้าสุนัขทั้งหมด 6 จุด ได้แก่ จุดที่สูงที่สุดในส่วนหัวของสุนัข จุดด้านในของต้นโขนทั้งสองข้าง ดวงตา และจุดระหว่างจมูกและปาก หลังจากนั้นจะสร้างเส้นรอบบริเวณที่พบ 6 จุด และทำการครอบตัดให้เหลือเฉพาะส่วนที่ได้ทำการตรวจจับใบหน้า

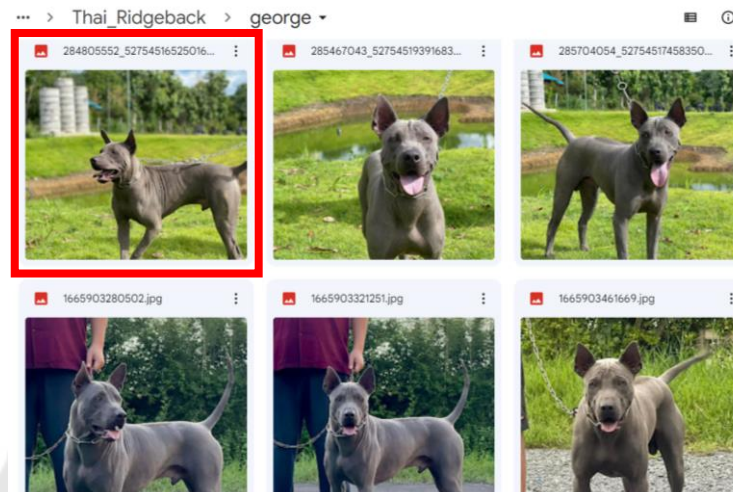


ภาพประกอบ 44 ภาพการตรวจจับใบหน้าของสุนัขด้วย Dlib Library v19.4

ตาราง 13 ผลการตรวจจับใบหน้าของสุนัข จาก Thai Dataset

Breeds	Raw Data	Detected	Accuracy
Thai_Ridgeback	71	70	98.6
Thai_Bangkaew	56	56	100
รวม	127	126	99.3

จากตาราง 13 ผลการตรวจจับใบหน้าของสุนัขสายพันธุ์ไทยจากรูปภาพ จำนวน 127 รูปภาพ จากการใช้ Dlib Library v19.4 และ OpenCV 3.3.0 พบว่าสามารถตรวจจับสุนัขสายพันธุ์บางแก้วได้ครบทุกรูปภาพ และหลังอ่านไม่สามารถตรวจจับได้เพียง 1 รูปภาพ โดยรวมทั้งสองสายพันธุ์อยู่ที่ 126 รูปภาพ คิดเป็น 99.3%

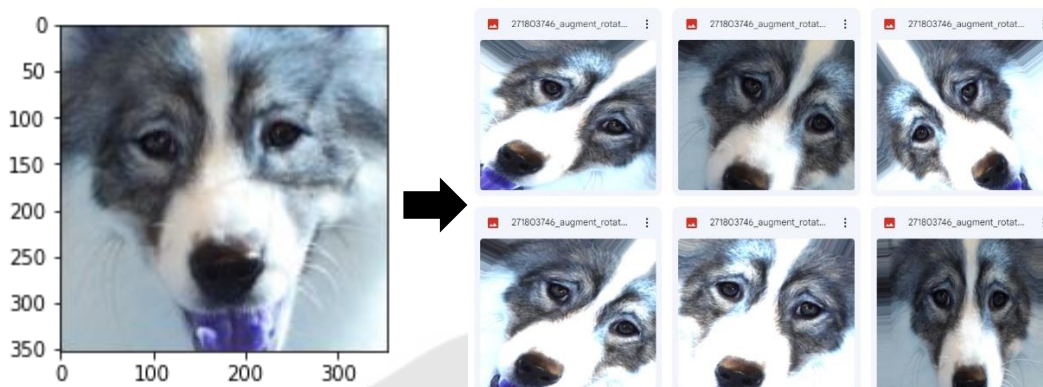


ภาพประกอบ 45 ลักษณะรูปภาพที่ไม่สามารถตรวจจับใบหน้าได้

#### 4.3.2 ผลการทำ Data Augmentation

เนื่องจากจำนวนรูปภาพที่นำมาใช้ในขั้นตอนการระบุตัวตนของสุนัขมีอย่างจำกัด และเพื่อดำเนินการทดลองให้สอดคล้องกับการนำไปใช้งานจริง โดยผู้วิจัยได้ออกแบบไว้ว่าการลงทะเบียนสุนัขในระบบจะต้องเพิ่มรูปอย่างน้อย 5 รูปในการลงทะเบียน รูปภาพที่นำมาใช้ในงานระบุตัวตนจากสุนัขทั้งหมด 62 ตัว จึงต้องมีอย่างน้อย 5 รูปขึ้นไป และขั้นตอนการเตรียมข้อมูลหรือรูปภาพเพื่อนำไปใช้ จึงต้องมีการทำ Data Augmentation ซึ่งเป็นเทคนิคหนึ่งที่จะช่วยเพิ่มขนาดของชุดข้อมูลด้วยการสร้าง Sample ใหม่จากข้อมูลเดิมโดยใช้เทคนิคต่างๆ และช่วยเพิ่มความหลากหลายให้กับชุดข้อมูล เช่น หมุนภาพ สลับฝั่ง เปลี่ยนขนาด บิดภาพ ปรับแสง หรือการกระจายตัวของข้อมูล เป้าหมายของ Data Augmentation คือเพื่อให้ชุดข้อมูลมีขนาดใหญ่ขึ้นโดยไม่ต้องเพิ่มข้อมูลจริงๆ ซึ่งสามารถช่วยให้แบบจำลองเรียนรู้และแยกแยะวัตถุหรือความเหมือนกันได้ดีขึ้น นอกจากนี้ยังช่วยลด Overfitting ที่อาจเกิดขึ้นในแบบจำลองโดยไม่ต้องเพิ่มข้อมูลจริงๆ ที่อาจสร้างความยุ่งยากซับซ้อนให้กับแบบจำลองได้เช่นกัน (Yang et al., 2022) ซึ่งในขั้นตอนนี้ได้มีการกำหนดให้ข้อมูลมีการปรับเปลี่ยนได้ทั้งหมด 5 ค่า ได้แก่ หมุนรูปภาพในช่วง 45 องศา บิดรูปภาพในระยะไม่เกิน 30% ขยายภาพอยู่ในระยะไม่เกิน 20% พลิกรูปภาพเป็นแนวนอน และปรับเปลี่ยนค่าความสว่างของรูปภาพ (Brightness) มีค่าอยู่ในช่วงระหว่าง 0.3 ถึง 1.8 ซึ่ง

กำหนดให้ Output เพิ่มรูปภาพละ 5-6 รูปภาพ โดยแสดงผลการทำ Data Augmentation ตามภาพประกอบ 46



ภาพประกอบ 46 ภาพต้นฉบับ และภาพหลังจากทำ Data Augmentation

ตาราง 14 ตารางแสดงผลการทำ Data Augmentation

Dataset	Detected	Augmented
Training Set	340	2,375
Validation Set	85	595
Test Set	75	524
Total	500	3,494

จากตาราง 14 จากรูปภาพต้นฉบับทั้งหมด 500 รูปภาพ สามารถเพิ่มจำนวนรูปภาพทั้งหมดเป็น 3,494 รูปภาพ และรูปภาพแต่ละรูปภาพมีความแตกต่างกันอย่างชัดเจน โดยไม่จำเป็นต้องปรับปรุงแก้ไขกับรูปภาพต้นฉบับหรือข้อมูลจริง

#### 4.3.3 ผลการดำเนินการระบุตัวตนของสุนัข

ในการระบุตัวตนของสุนัขจะเป็นการเปรียบเทียบประสิทธิภาพระหว่างการใช้ Pre-train Models จาก CNNs ในการสกัดเวกเตอร์คุณลักษณะของรูปภาพร่วมกับแบบจำลองที่สร้างขึ้นใหม่โดยผู้วิจัย ซึ่งมีทดลองปรับเปลี่ยนชุดข้อมูลที่นำมาฝึกให้แบบจำลองเรียนรู้ เพื่อสร้างความหลากหลายในการทดลองและได้มีการปรับปรุงพารามิเตอร์ของ New Classification ที่ได้สร้างขึ้นใหม่ให้เหมาะสมกับลักษณะของชุดข้อมูลที่นำมาใช้ ป้องกันไม่ให้เกิด Overfitting และ Underfitting และใช้แบบจำลองที่ถูกเรียนรู้มาจากใบหน้าของบุคคลหรือการรู้จำใบหน้าโดยเฉพาะ (Face Recognition) รวมไปถึงเนื่องจากรูปภาพในการทดลองมีเพียง 500 รูป จึงมีการเพิ่มจำนวน

และความแตกต่างของรูปภาพด้วยการทำ Data Augmentation เปรียบเทียบกับการไม่ได้ทำ Data Augmentation

ตาราง 15 ตารางแสดงผลการทดลองการระบุตัวตนของสุนัข (Dog Identification)

Model	Parameter	Train Acc	Test Acc	Top3 Acc	Top5 Acc	Precision (Macro-avg)	Recall (Macro-avg)	F1-Score (Macro-avg)
Raw Data 500 รูปภาพ สุนัข 62 ตัว 4 สายพันธุ์								
MobileNetV2	weight = imagenet	0.8	0.71	0.87	0.95	0.62	0.68	0.63
InceptionV3	weight = imagenet	0.78	0.65	0.91	0.97	0.61	0.65	0.61
NASNetLarge	weight = imagenet	0.87	0.72	0.92	0.97	0.64	0.69	0.65
VGG16	weight = imagenet	0.04	0.05	0.13	0.21	0.01	0.03	0.01
ResNet50	weight = imagenet	0.8	<u>0.75</u>	0.87	0.93	0.66	0.73	0.68
VGGFace	model = 'vgg16'	0.08	0.15	0.27	0.41	0.04	0.09	0.05
VGGFace	model = 'resnet50'	0.83	0.61	0.89	0.93	0.54	0.59	0.55
Data Augmentation 3,494 รูปภาพ สุนัข 62 ตัว 4 สายพันธุ์								
MobileNetV2	weight = imagenet	0.82	0.77	0.92	0.97	0.77	0.77	0.74
InceptionV3	weight = imagenet	0.79	<u>0.78</u>	0.93	0.98	0.77	0.77	0.76
NASNetLarge	weight = imagenet	0.89	0.74	0.89	0.94	0.71	0.72	0.7
VGG16	weight = imagenet	0.16	0.23	0.48	0.65	0.13	0.19	0.13
ResNet50	weight = imagenet	0.86	0.76	0.86	0.93	0.73	0.75	0.73
VGGFace	model = 'vgg16'	0.17	0.28	0.52	0.68	0.19	0.22	0.17
VGGFace	model = 'resnet50'	0.76	0.54	0.82	0.88	0.56	0.52	0.51

จากตาราง 15 ได้มีการเลือกใช้ชุดข้อมูลในการทดลองแบ่งออกเป็น 2 กลุ่ม ได้แก่ กลุ่มที่ทำ Data Augmentation และไม่ได้ทำ Data Augmentation ได้ผลลัพธ์ดังนี้

1. การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้งาน Pre-train models ในการสกัดเวกเตอร์คุณลักษณะ ร่วมกับ New Classification พบว่าแบบจำลอง VGG16 มีความแม่นยำต่ำที่สุด (0.5%) ส่วนแบบจำลอง ResNet50 มีความแม่นยำสูงที่สุด (75%) สำหรับชุดข้อมูลที่ไม่ได้มีการทำ Data Augmentation

2. การเปรียบเทียบประสิทธิภาพของแบบจำลองซึ่งใช้งาน Pre-train models ในการสกัดเวกเตอร์คุณลักษณะ ร่วมกับ New Classification พบว่าแบบจำลอง VGG16 มีความแม่นยำต่ำที่สุด (2.3%) ส่วนแบบจำลอง InceptionV3 มีความแม่นยำสูงที่สุด (78%) สำหรับชุดข้อมูล



มีการทำ Data Augmentation และหากดูค่าความแม่นยำแบบ Top3 และ Top5 พบว่าแต่ละแบบจำลองจะมีค่าความแม่นยำที่สูงมากขึ้น จึงเห็นได้ว่า Class ที่ถูกต้องของสุนัขแต่ละตัวอยู่ภายใน 3 หรือ 5 อันดับ ของผลลัพธ์ที่ได้จากการทำนายของแบบจำลอง

นอกจากนี้ ในส่วนของกรนำแบบจำลองสำหรับการรู้จำใบหน้า (Face Recognition) โดยเฉพาะอย่าง VGGFace และเลือกใช้โครงสร้าง VGG16 และ ResNet50 ได้ค่าความแม่นยำที่ต่ำกว่าแบบจำลองที่ถูกฝึกมาจาก ImageNet โดย ค่าที่สูงที่สุดในการทดลองของ VGGFace อยู่ที่ 61% จากโครงสร้างแบบจำลอง Resnet50 สำหรับข้อมูลที่ไม่ได้ทำการ Data Augmentation และค่าที่สูงที่สุดในการทดลองของ VGGFace อยู่ที่ 54% จากโครงสร้างแบบจำลอง Resnet50 สำหรับข้อมูลที่มีการทำ Data Augmentation ซึ่งโครงสร้างแบบจำลอง VGG16 เป็นแบบจำลองที่มีค่าความแม่นยำค่อนข้างน้อยมาก อยู่ที่ 15% และ 28% สำหรับข้อมูลที่ไม่ได้ทำการ Data Augmentation และข้อมูลที่ทำกร Data Augmentation ตามลำดับ

ตาราง 16 แสดงผลการทดลองการระบุตัวตนของสุนัข (Dog Identification) แยกตามสายพันธุ์

Breeds	ค่าเฉลี่ยตัววัด	MobileNetV2	InceptionV3	NASNet Large	VGG16	Resnet50	VGGface (VGG16)	VGGface (ResNet50)
Raw Data 500 รูปภาพ สุนัข 62 ตัว 4 สายพันธุ์								
Husky 21 ตัว	F1score	0.7	0.72	0.7	0	<u>0.83</u>	0.072	0.56
-Train 143 รูป	Recall	0.76	0.76	0.74	0	<u>0.85</u>	0.14	0.62
-Test 25 รูป	Precision	0.68	0.71	0.68	0	<u>0.83</u>	0.06	0.54
Pug 21 ตัว	F1score	<u>0.54</u>	0.37	0.51	0.03	0.48	0.07	0.39
- Train 176 รูป	Recall	<u>0.57</u>	0.41	0.55	0.08	0.55	0.13	0.4
- Test 30 รูป	Precision	<u>0.58</u>	0.4	0.51	0.03	0.44	0.05	0.4
Bangkaew 10 ตัว	F1score	0.51	1	0.87	0	0.62	0	0.87
- Train 46 รูป	Recall	0.6	1	0.9	0	0.7	0	0.9
- Test 10 รูป	Precision	0.48	1	0.85	0	0.58	0	0.85
Ridgeback 10 ตัว	F1score	0.77	0.52	0.64	0	<u>0.87</u>	0	0.53
- Train 60 รูป	Recall	0.8	0.6	0.7	0	<u>0.9</u>	0	0.6
- Test 10 รูป	Precision	0.75	0.48	0.6	0	<u>0.85</u>	0	0.5
<b>รวม 500 รูป</b>	<b>Avg F1score</b>	0.63	0.65	0.68	0.01	<u>0.7</u>	0.04	0.59
- Train 425 รูป	<b>Avg Recall</b>	0.68	0.69	0.72	0.02	<u>0.75</u>	0.07	0.63
- Test 75 รูป	<b>Avg Precision</b>	0.62	0.65	0.66	0.01	<u>0.68</u>	0.03	0.57

ตาราง 16 (ต่อ)

Breeds	ค่าเฉลี่ยตัววัด	MobileNetV2	InceptionV3	NASNet Large	VGG16	Resnet50	VGGface (VGG16)	VGGface (ResNet50)
Data Augmentation 3,494 รูปภาพ สุนัข 62 ตัว 4 สายพันธุ์								
Husky 21 ตัว	F1score	<u>0.87</u>	0.84	0.79	0.09	0.85	0.2	0.56
- Train 998 รูป	Recall	<u>0.9</u>	0.85	0.81	0.15	0.87	0.27	0.59
- Test 174 รูป	Precision	<u>0.88</u>	0.85	0.8	0.08	0.86	0.2	0.62
Pug 21 ตัว	F1score	<u>0.59</u>	0.53	0.47	0.14	0.45	0.11	0.4
- Train 1,230 รูป	Recall	<u>0.61</u>	0.55	0.51	0.18	0.51	0.16	0.41
- Test 210 รูป	Precision	<u>0.61</u>	0.53	0.47	0.17	0.43	0.1	0.42
Bangkaew 10 ตัว	F1score	0.85	<u>1</u>	0.97	0.22	0.94	0.21	0.72
- Train 322 รูป	Recall	0.87	<u>1</u>	0.97	0.31	0.94	0.2	0.71
- Test 70 รูป	Precision	0.92	<u>1</u>	0.98	0.18	0.96	0.35	0.78
Ridgeback 10 ตัว	F1score	0.67	<u>0.83</u>	0.72	0.08	<u>0.82</u>	0.19	0.4
- Train 420 รูป	Recall	0.73	<u>0.83</u>	0.73	0.14	<u>0.83</u>	0.27	0.41
- Test 20 รูป	Precision	0.72	<u>0.86</u>	0.78	0.08	<u>0.86</u>	0.21	0.49
รวม 3,494 รูป	Avg F1score	0.75	<u>0.80</u>	0.74	0.13	0.77	0.18	0.52
- Train 2,970 รูป	Avg Recall	0.78	<u>0.81</u>	0.76	0.20	0.79	0.23	0.53
- Test 524 รูป	Avg Precision	0.78	<u>0.81</u>	0.76	0.13	0.78	0.22	0.58

เมื่อตรวจสอบผลการทดลองพบว่าแบบจำลองทุกแบบจำลองให้ค่าความแม่นยำที่ค่อนข้างดีในระดับปานกลางเท่านั้น จึงทำการแสดงข้อมูลโดยแยกตามสายพันธุ์ของสุนัขทั้ง 62 ตัว ตามตาราง 16 พบว่า ทั้งสองกระบวนการ สายพันธุ์ที่ทำให้ค่าความแม่นยำโดยรวมของแบบจำลองน้อยเกิดจากสายพันธุ์ Pug ที่ค่าเฉลี่ย F1-Score อยู่ที่ 0.07-0.6 เท่านั้น ซึ่งแตกต่างกันไปตามประสิทธิภาพของแบบจำลอง โดยแบบจำลองที่ค่า F1-Score สูงสุดของสายพันธุ์ Pug คือ MobileNetV2 โดยวิเคราะห์ได้ว่าใบหน้าของสุนัขสายพันธุ์ Pug มีความคล้ายคลึงกันค่อนข้างมากทำให้แบบจำลองแยกได้ยาก ซึ่งสายพันธุ์ที่ให้ค่า F1-Score เฉลี่ยสูงที่สุดได้แก่ Bangkaew อยู่ที่ 1 จากแบบจำลอง InceptionV3 รองลงมาเป็น Ridgeback และ Husky อยู่ที่ 0.9 โดยแบบจำลอง ResNet50 และ MobileNetV2 ตามลำดับ

ตาราง 17 Confusion Matrix ของ สายพันธุ์ Pug จากการระบุตัวตนของสุนัข (MobileNetV2)

True label	Prediction ID																				Cross breed	
	2	6	7	8	9	12	13	15	22	23	24	25	26	27	29	31	32	33	37	38		39
2	1.00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	1.00	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	0	0	0.29	0	0	0	0	0	0	0	0.29	0	0	0	0.29	0	0.14	0	0	0	0	0
8	0	0	0	0	0	0.29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.71
9	0	0	0	0	0.29	0	0	0	0	0	0	0.29	0	0	0.43	0	0	0	0	0	0	0
12	0	0	0	0	0	0.14	0	0.29	0	0	0	0	0	0	0	0	0	0	0	0	0	0.57
13	0.07	0.29	0	0	0	0.07	0.21	0.14	0	0	0	0	0	0	0	0	0	0	0	0	0	0.21
15	0	0.29	0	0	0	0	0	0.71	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22	0	0	0	0	0	0	0	0	1.00	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0.14	0	0	0	0	0	0	0	0	0.86	0	0	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	0	0	0	0	0	0	1.00	0	0	0	0	0	0	0	0	0	0	0
25	0	0	0	0	0.43	0	0	0	0	0	0	0.57	0	0	0	0	0	0	0	0	0	0
26	0	0	0	0	0	0	0	0.14	0	0	0	0	0.86	0	0	0	0	0	0	0	0	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00	0	0	0	0	0	0	0	0
29	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00	0	0	0	0	0	0	0
31	0	0	0	0	0	0	0	0	0.14	0	0	0	0.14	0	0	0.71	0	0	0	0	0	0
32	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.00	0	0	0	0	0	0
33	0	0	0	0	0.07	0	0	0	0	0	0.14	0	0	0	0	0	0.57	0.21	0	0	0	0
37	0	0	0	0	0.71	0	0	0	0	0	0	0.14	0	0	0.14	0	0	0	0	0	0	0
38	0	0	0	0	0	0	0	0.43	0	0	0	0	0	0	0	0	0	0	0	0.29	0.29	0
39	0	0	0	0	0	0	0	0	0	0	0	0	0	0.43	0	0	0	0	0	0	0	0.57
Cross breed	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

จากตารางที่ 17 แสดง Confusion Matrix ของ สายพันธุ์ Pug จากการระบุตัวตนของสุนัข (MobileNetV2) จะเห็นได้ชัดว่า สายพันธุ์ Pug พบการทำนายที่ผิดพลาดค่อนข้างสูงแบบจำลองทำนายถูกต้องเพียง 12 ตัว จาก 21 ตัว หรือคิดเป็น 55% เท่านั้น โดยค่าความแม่นยำของแต่ละ Class ที่ทำนายผิดกระจายอยู่ตาม Class หรือสุนัขตัวอื่นๆ ภายในสายพันธุ์เดียวกันและไม่ได้มีการทำนายผิดพลาดข้ามสายพันธุ์




ตาราง 20 Confusion Matrix ของ สายพันธุ์ Ridgeback จากการระบุตัวตนของสุนัข (InceptionV3)

True label	Prediction ID										
	43	44	45	47	48	49	50	51	57	58	Cross breed
43	0.71	0	0	0	0	0	0	0	0.29	0	0
44	0	1.00	0	0	0	0	0	0	0	0	0
45	0	0	1.00	0	0	0	0	0	0	0	0
47	0	0	0	0.86	0	0	0	0	0	0.14	0
48	0	0	0	0	0.86	0.14	0	0	0	0	0
49	0	0	0	0	0	0.57	0.43	0	0	0	0
50	0	0	0	0	0	0	0.71	0	0.29	0	0
51	0	0	0	0	0	0	0	0.86	0	0.14	0
57	0	0	0	0.14	0	0	0	0	0.86	0	0
58	0	0	0	0	0	0	0	0	0	1.00	0
Cross breed	0	0	0	0	0	0	0	0	0	0	0

จากตารางที่ 18,19 และ 20 แสดง Confusion Matrix ของ สายพันธุ์ Husky, Bangkaew และ Ridgeback จากการระบุตัวตนของสุนัข (MobileNetV2, InceptionV3) จะเห็นได้ว่า สายพันธุ์อื่นๆ จากแบบจำลอง ทำนายได้ถูกต้องมากกว่า 80% โดยเฉพาะสายพันธุ์ Bangkaew ที่ทำนายได้ถูกต้องทั้งหมด หรือคิดเป็น 100% รองลงมาเป็น Ridgeback และ Husky แสดงให้เห็นว่าสุนัขสายพันธุ์ Pug ทำให้ค่าความแม่นยำโดยรวมของแบบจำลองลดลง นอกจากนี้ ผู้วิจัยได้ทดลองนำสายพันธุ์ไทย มาทำการทดสอบตั้งแต่การจำแนกสายพันธุ์จนถึงการระบุตัวตนพบว่า สายพันธุ์ไทยสามารถให้ค่าความแม่นยำได้ค่อนข้างสูงมากกว่า 90% ทั้งการจำแนกสายพันธุ์และการระบุตัวตนของสุนัข


และจากการทดลองสร้างแบบจำลองในการระบุตัวตนของสุนัขได้ผลการทดสอบระหว่างค่า Accuracy และค่า Loss Function ระหว่าง Training Set กับ Validation Set โดยแสดงผ่านกราฟ Loss Function ดังภาพประกอบด้านล่าง

## Results using InceptionV3\_imagenet\_not\_Augmentation




ภาพประกอบ 47 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (Weight = ImageNet)

## Results using InceptionV3\_imagenet\_Augmentation




ภาพประกอบ 48 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ InceptionV3 (Weight = ImageNet +Data Augmentation)

## Results using **MobileNetV2\_imagenet\_not\_Augmentation**




ภาพประกอบ 49 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (Weight = ImageNet)

## Results using **MobileNetV2\_imagenet\_Augmentation** ★




ภาพประกอบ 50 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ MobileNetV2 (Weight = ImageNet + Data Augmentation)

### Results using **NASNetLarge\_imagenet\_not\_Augmentation**



ภาพประกอบ 51 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (Weight = ImageNet)


### Results using **NASNetLarge\_imagenet\_Augmentation**



ภาพประกอบ 52 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ NASNetLarge (Weight = ImageNet + Data Augmentation)




## Results using **ResNet50** \_imagenet\_not\_Augmentation




ภาพประกอบ 53 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (Weight = ImageNet)

## Results using **ResNet50** \_imagenet\_Augmentation




ภาพประกอบ 54 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ ResNet50 (Weight = ImageNet + Data Augmentation)

### Results using VGGFace\_ResNet50\_not\_Augmentation




ภาพประกอบ 55 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง ResNet50

### Results using VGGFace\_ResNet50\_Augmentation




ภาพประกอบ 56 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง ResNet50 (Data Augmentation)

### Results using **VGG16\_imagenet\_not\_Augmentation**




ภาพประกอบ 57 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (Weight = ImageNet)

### Results using **VGG16\_imagenet\_Augmentation**




ภาพประกอบ 58 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGG16 (Weight = ImageNet + Augmentation)

### Results using VGGFace\_VGG16\_not\_Augmentation



ภาพประกอบ 59 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง VGG16

### Results using VGGFace\_VGG16\_Augmentation



ภาพประกอบ 60 กราฟแสดงค่า Accuracy และค่า Loss ระหว่าง Training Set กับ Validation Set ของ VGGFace โครงสร้าง VGG16 (Data Augmentation)

จากกราฟในภาพประกอบ 47-60 จะเห็นว่า แบบจำลองที่สร้างขึ้นมีการปรับจูนพารามิเตอร์โดยรวมสำหรับการทดลองอยู่ในระดับกลาง ไม่ทำให้เกิด Overfitting และ Underfitting กับแบบจำลองใดแบบจำลองใดแบบจำลองหนึ่งมากเกินไป โดย Pre-train Models ที่กราฟเป็นไปในทิศทางที่ดีที่สุด คือ MobileNetV2 ที่กำหนด Weight = ImageNet และมีการทำ Data Augmentation ซึ่งได้ทั้งค่า Accuracy ที่สูง และค่า Loss ที่ต่ำ ส่วนกราฟที่เป็นไปในทิศทางที่ไม่ดี คือ VGG16 ที่ยังไม่ทำ Data Augmentation ซึ่งจะเห็นได้ว่ากราฟเส้นอยู่ในเกณฑ์ที่ต่ำและไม่เสถียร



## บทที่ 5

### สรุป อภิปรายผล และข้อเสนอแนะ


ผู้วิจัยได้วัดประสิทธิภาพของแบบจำลองในขั้นตอนต่างๆ เพื่อนำมาเปรียบเทียบและสรุปผลการวิจัย โดยสามารถแบ่งหัวข้อในการสรุปผลการวิจัยได้ดังนี้

1. สรุปผลการวิจัย
2. อภิปรายผลการวิจัย
3. ข้อเสนอแนะและแนวทางการวิจัยในอนาคต

#### 5.1 สรุปผลการวิจัย

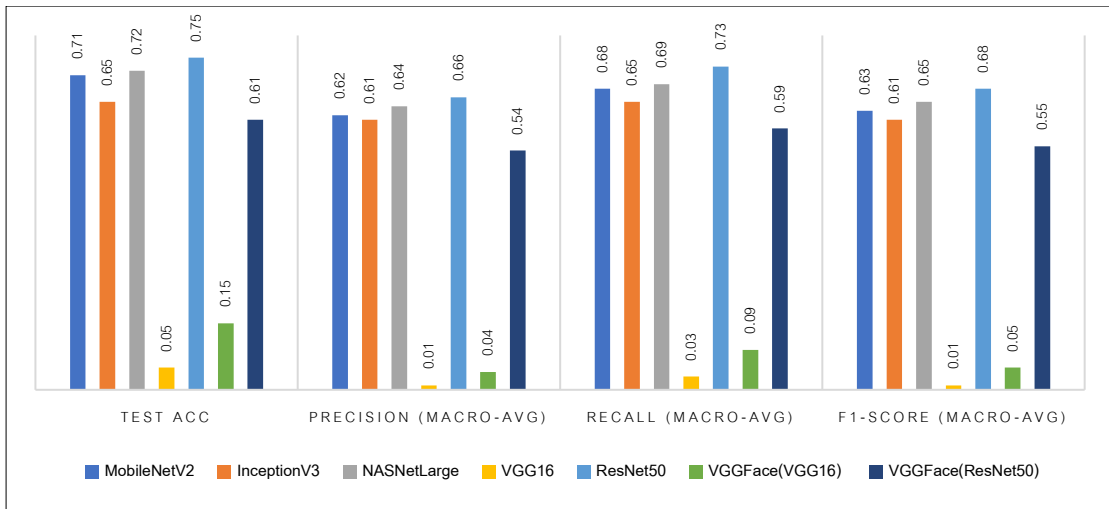
ในงานวิจัยนี้เป็นการศึกษาการจำแนกสายพันธุ์ (Dog Breed Classification) และการระบุตัวตนของสุนัข (Dog Identification) จากภาพถ่าย เพื่อทราบถึงข้อมูลของสุนัขตัวดังกล่าว เช่น ชื่อ เจ้าของ ที่อยู่ โรคประจำตัว เป็นต้น รวมไปถึงนำมาช่วยในการแก้ไขปัญหาสุนัขจรจัดที่มีปริมาณเพิ่มมากขึ้น ปัญหาผู้เลี้ยงสุนัขไม่สามารถตามหาสุนัขเจอ ปัญหาสัตว์แพทย์ไม่มีข้อมูลประจำตัวสุนัขที่แน่ชัดในการรักษา ปัญหาหน่วยงานไม่สามารถบริหารจัดการและแก้ไขปัญหาสุนัขในประเทศได้ และปัญหาในด้านอื่นๆ ที่จะตามมา เช่น อันตรายจากสุนัขไม่มีเจ้าของ ความเสี่ยงต่อการเกิดโรคติดต่อจากสัตว์สู่คน เป็นต้น โดยมุ่งเน้นไปที่สายพันธุ์ไทยจำนวน 2 สายพันธุ์ ได้แก่ บางแก้ว (Bangkaew) และหลังอาน (Ridgeback) เพื่อสามารถนำมาต่อยอดในประเทศไทย และต่อยอดนำไปใช้กับสัตว์ชนิดอื่นๆ ได้ เช่น แมว โค กระบือ แพะ แกะ เป็นต้น

โดยงานวิจัยประกอบด้วย 2 ขั้นตอนหลัก ขั้นตอนแรก การจำแนกสายพันธุ์ของสุนัข (Dog Breed Classification) จากภาพถ่ายสุนัข โดยใช้ชุดข้อมูล Standford Dataset สำหรับสายพันธุ์ต่างประเทศ และ Thai Dataset จากฟาร์มสุนัขในประเทศไทย สำหรับสายพันธุ์ไทย จำนวนทั้งสิ้น 20,949 รูปภาพ จำนวน 122 สายพันธุ์ เพื่อช่วยในการลดพื้นที่ในการค้นหาข้อมูลในขั้นตอนระบุตัวตนของสุนัข มีการใช้งาน Pre-train Models จาก CNNs จำนวน 6 แบบจำลอง ได้แก่ Xception, VGG16, ResNet50, InceptionV3, MobileNetV2 และ NasNetLarge เพื่อสกัดเวกเตอร์คุณลักษณะของรูปภาพสุนัข ในขั้นตอนนี้ผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพในการจำแนกสายพันธุ์ระหว่างการใช้แบบจำลองแบบดั้งเดิม (Full Layer) ที่มีการฝึกมาแล้ว และการใช้แบบจำลองที่ผู้วิจัยสร้างขึ้น ผลการทดลองพบว่าการใช้แบบจำลองดั้งเดิม (Full Layer) ที่มีค่าความแม่นยำสูงสุดอยู่ที่ 91% ได้แก่ NasNetLarge ส่วนการใช้การสกัดเวกเตอร์คุณลักษณะร่วมกับแบบจำลองที่สร้างขึ้นมีค่าความแม่นยำสูงสุดอยู่ที่ 93% ได้แก่ NasNetLarge




ภาพประกอบ 61 กราฟแสดงผลการจำแนกสายพันธุ์ของสุนัข

ขั้นตอนที่สอง การระบุตัวตนของสุนัข (Dog Identification) จากการใช้ภาพใบหน้าของสุนัข โดยใช้ชุดข้อมูล Flickr-Dog Dataset สำหรับสายพันธุ์ต่างประเทศ และ Thai Dataset จากฟาร์มสุนัขในประเทศไทย สำหรับสายพันธุ์ไทย จำนวนทั้งสิ้น 500 รูปภาพ จำนวน 4 สายพันธุ์ จำนวนสุนัข 62 ตัว เริ่มจากการตรวจจับใบหน้าของสุนัข (Dog Face Detection) ด้วยการให้ Dlib Library และ OpenCV และเพื่อเพิ่มปริมาณและความหลากหลายของข้อมูลจึงนำชุดข้อมูลมาการทำ Data Augmentation เช่น การหมุน การบิด การขยาย เป็นต้น และนำภาพใบหน้าที่ได้มาสกัดเวกเตอร์คุณลักษณะของสุนัขแต่ละตัวจาก Pre-train Models ของ CNNs จำนวน 5 แบบจำลอง ได้แก่ VGG16, ResNet50, InceptionV3, MobileNetV2 และ NasNetLarge รวมถึงแบบจำลองที่ผ่านการเรียนรู้จากใบหน้ามนุษย์ (Face Recognition) ได้แก่ VGGFace โดยใช้โครงสร้างของ VGG16 และ ResNet50 จากนั้นนำเวกเตอร์คุณลักษณะที่ได้มาทำการสร้างแบบจำลองการระบุตัวตนโดยการเปรียบเทียบประสิทธิภาพของแบบจำลองในการระบุตัวตนของสุนัขระหว่างแบบจำลองที่ถูกฝึกมาจากชุดข้อมูลที่มีการทำ Data Augmentation และไม่มีการทำ Data Augmentation จากผลการทดลองพบว่า ResNet50 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 75% จากชุดข้อมูลที่ไม่มีการทำ Augmentation และ InceptionV3 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 78% จากชุดข้อมูลที่มีการทำ Augmentation ซึ่งจะเห็นได้ว่าการทำ Augmentation ส่งผลต่อการทดลองเพียงเล็กน้อย และจากผลการทดลองพบว่าสายพันธุ์ที่มีค่าความแม่นยำน้อยที่สุดคือ สายพันธุ์ Pug โดยมีค่าเฉลี่ยความแม่นยำอยู่ที่ 40-50% ทำให้ไม่สามารถจำแนกสุนัขแต่ละตัวในสายพันธุ์ได้อย่างถูกต้อง ส่วนสายพันธุ์ไทยทั้ง 2 สายพันธุ์ มีค่าเฉลี่ยความแม่นยำสูงถึง 80-90%




ภาพประกอบ 62 กราฟแสดงสรุปผลการระบุตัวตนของสุนัข




ภาพประกอบ 63 กราฟแสดงสรุปผลการระบุตัวตนของสุนัขและใช้ชุดข้อมูลที่มีการทำ Data Augmentation





ภาพประกอบ 64 กราฟแสดงสรุปผลการระบุตัวตนของสุนัข แยกตามสายพันธุ์



ภาพประกอบ 65 กราฟแสดงสรุปผลการระบุตัวตนของสุนัขและใช้ชุดข้อมูลที่มีการทำ Data Augmentation แยกตามสายพันธุ์

## 5.2 อภิปรายผลการวิจัย

ภาพรวมหรือกระบวนการของงานวิจัยนี้สามารถนำไปใช้งานได้เพียงผู้คนสามารถถ่ายภาพผ่าน Smart Device ต่างๆ แล้วอัปโหลดเข้าสู่ Application หรือ ระบบ เพื่อค้นหาข้อมูลของสุนัข ได้ทุกที่ ทุกเวลา โดยเริ่มจาก Soft Biometrics หรือว่าการดำเนินการในส่วนที่สามารถมองเห็นได้อย่างชัดเจน ซึ่งในงานวิจัยนี้ เลือกลายพันธุ์ของสุนัขมาใช้ในการทดลอง เนื่องจากสุนัขในโลกนี้มีจำนวนมาก การจัดกลุ่มของสุนัขตามสายพันธุ์จึงมีความน่าสนใจเนื่องจากแต่ละสายพันธุ์มีความแตกต่างกัน ทั้ง สี ขน ขนาด และลาย เป็นต้น

โดยการจำแนกสายพันธุ์ของสุนัข ผลการทดลองวิเคราะห์ได้ว่า การจำแนกสายพันธุ์ในกรณีที่ต้องการเน้นสายพันธุ์ไทย โดยวิธีการสกัดเวกเตอร์คุณลักษณะ ร่วมกับ New Classification ที่ถูกตั้งค่ามาอย่างเหมาะสมและสอดคล้องกับ Class ที่มีอยู่ในชุดข้อมูล Pre-train Models จาก CNNs ที่ให้ค่าความแม่นยำในสูงที่สุดคือ NasNetLarge อยู่ที่ 93% รองลงมา InceptionV3, Xception โดยมีความแม่นยำอยู่ที่ 89%, 87% ตามลำดับ ซึ่งทั้ง 3 แบบจำลอง เหมาะสมในการนำมาจำแนกสายพันธุ์ของสุนัขสายพันธุ์ไทยได้ แต่เนื่องจากแบบจำลอง NasNetLarge เป็นแบบจำลองที่มีขนาดใหญ่ ต้องการทรัพยากรในการประมวลผลสูงและใช้เวลาในการทดลองนาน จึงอาจพิจารณาให้ถ่วงในการนำไปใช้งาน จากที่กล่าวข้างต้นว่า ในงานวิจัยนี้ผู้วิจัยได้ออกแบบให้ใช้งานกับโทรศัพท์หรือ Smart Device ต่างๆ ได้ แบบจำลอง NasNetLarge จึงยังไม่เหมาะสมมากนัก ควรเลือกเป็น InceptionV3 หรือ Xception เนื่องจากทั้งสองแบบจำลองให้ค่าความแม่นยำที่ค่อนข้างสูงแต่ใช้ทรัพยากรในการประมวลผลไม่สูงเท่าแบบจำลอง NasNetLarge ในขณะที่การใช้แบบจำลองดั้งเดิมมีค่าความแม่นยำสูงสุดอยู่ที่ 91% ได้แก่แบบจำลอง NasNetLarge แต่ไม่สามารถทำนายสายพันธุ์ไทยได้ เนื่องจากไม่ได้มีการกำหนด Classification Layer ให้สอดคล้องกับ Class ที่มีอยู่ในชุดข้อมูล และแบบจำลองถูกฝึกมาจากชุดข้อมูล ImageNet จึงไม่สามารถนำวิธีการนี้ไปใช้งานต่อได้ ในกรณีที่ต้องการสายพันธุ์ที่นอกเหนือจาก 120 สายพันธุ์

ในขั้นตอนการระบุตัวตนของสุนัข ขั้นตอนในการตรวจจับใบหน้าของสุนัข (Face Detection) อาจมีผลต่อการเพิ่มประสิทธิภาพของแบบจำลองในการระบุตัวตนสุนัข และการทำ Data Augmentation เพื่อเพิ่มปริมาณ และความหลากหลายให้กับข้อมูลสามารถเพิ่มประสิทธิภาพการรู้จำให้แบบจำลองได้เล็กน้อย โดยในการทดลอง แบบจำลอง ResNet50 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 75% จากชุดข้อมูลที่ไม่มีการทำ Augmentation และแบบจำลอง InceptionV3 ให้ค่าความแม่นยำสูงสุดอยู่ที่ 78% จากชุดข้อมูลที่มีการทำ Augmentation และแบบจำลองที่ให้ค่าใกล้เคียง คือ MobileNetV2 อยู่ที่ 77% และ ResNet50 อยู่ที่ 76% ซึ่งค่าความแม่นยำส่วนใหญ่มี

ค่าไม่ถึง 80% อาจเกิดจากชุดข้อมูลที่มีจำนวนจำกัดและคุณภาพของข้อมูลยังไม่ดีเท่าที่ควร อาจจะทำให้แบบจำลองไม่สามารถเรียนรู้ได้อย่างเต็มประสิทธิภาพ ซึ่งหากมีรูปภาพในการฝึกฝนเพิ่มขึ้น และเพิ่มเทคนิค เพิ่มช่วงค่าต่างๆ ในการ Augmentation อาจทำให้ค่าความแม่นยำสูงขึ้น และแบบจำลองมีประสิทธิภาพเพิ่มมากขึ้น โดยในงานวิจัยนี้มีการนำแบบจำลองสำหรับการรู้จำใบหน้า (Face Recognition) โดยเฉพาะอย่าง VGGFace เลือกใช้โครงสร้างของแบบจำลอง VGG16 และ ResNet50 โดยค่าความแม่นยำที่สูงที่สุดในการทดลองของ VGGFace อยู่ที่ 61% จาก Resnet50 สำหรับข้อมูลที่ไม่ได้ทำการ Data Augmentation และค่าที่สูงที่สุดในการทดลองของ VGGFace อยู่ที่ 54% จาก Resnet50 สำหรับข้อมูลที่มีการทำ Data Augmentation จะเห็นได้ว่าการใช้งานแบบจำลองที่ใช้ในงานรู้จำใบหน้าโดยเฉพาะ และใช้งานกับใบหน้ามนุษย์ไม่สามารถนำมาใช้กับการระบุตัวตนด้วยภาพใบหน้าของสุนัข โดยข้อสังเกตในการสร้างแบบจำลองในการระบุตัวตนของสุนัข พบว่าสายพันธุ์ Pug ทำให้ค่าความแม่นยำโดยรวมของแบบจำลองลดน้อยลง โดยมีการกระจายความแม่นยำกับสุนัขตัวอื่นๆ ภายในสายพันธุ์เดียวกัน ซึ่งหมายถึงสุนัขแต่ละตัวในสายพันธุ์ Pug มีความแตกต่างกันค่อนข้างน้อย เมื่อเทียบกับสายพันธุ์อื่นๆ อย่างบางแก้วที่มีความแตกต่างกันมาก ทำให้สามารถระบุตัวตนของสุนัขในสายพันธุ์ได้มากถึง 100%

นอกจากนี้ ผู้วิจัยได้ทดลองใช้วิธีการจำแนกสายพันธุ์ของสุนัขและการระบุตัวตนของสุนัข โดยใช้ชุดข้อมูลสายพันธุ์ไทยชุดเดียวกันตั้งแต่ขั้นตอนแรก คือการจำแนกสายพันธุ์ไปจนถึงขั้นตอนสุดท้ายคือการระบุตัวตนของสุนัข เพื่อทดสอบและวิเคราะห์ความแม่นยำของทั้งกระบวนการนี้ ผลการทดสอบพบว่าสายพันธุ์ไทยสามารถให้ค่าความแม่นยำได้สูงถึง 90% ซึ่งเป็นผลลัพธ์ที่ดีมาก อย่างไรก็ตาม สำหรับในงานวิจัยนี้การนำวิธีการจำแนกสายพันธุ์ของสุนัขมาใช้งานร่วมกับการระบุตัวตนของสุนัขอาจยังไม่จำเป็นมากนัก โดยจะต้องพิจารณาความแตกต่างของสายพันธุ์ที่นำมาใช้งาน เนื่องจาก 4 สายพันธุ์ที่นำมาทดสอบมีความแตกต่างกัน แต่ถ้าพบกรณีที่สายพันธุ์มีลักษณะใกล้เคียงกัน การนำวิธีการนี้มาใช้งานจะช่วยในการแยกสุนัขแต่ละตัวได้มากขึ้น อีกทั้งยังสามารถช่วยเพิ่มประสิทธิภาพของการประมวลผล ช่วยลดระยะเวลาในการค้นหา และช่วยเลือกแบบจำลองที่เหมาะสมกับแต่ละสายพันธุ์ได้ โดยงานวิจัยนี้สะท้อนให้เห็นว่าการนำรูปภาพของสุนัขมาใช้งาน Image Processing สามารถนำไปช่วยแก้ไขปัญหาต่างๆ ที่ไม่สามารถแก้ไขได้อย่างง่ายแก่สังคมได้ รวมไปถึงสามารถนำวิธีการทดลองไปปรับใช้กับสัตว์ชนิดอื่นๆ ที่มีมูลค่าหรือมีผลกระทบต่อสังคมในอนาคตได้

### 5.3 ข้อเสนอแนะและแนวทางการวิจัยในอนาคต

ผลการทดลองต่างๆ อาจได้ผลที่แตกต่างกัน เนื่องจากการใช้ชุดข้อมูล จำนวนชุดข้อมูล การเลือกใช้แบบจำลอง และการตั้งค่าต่างๆ ที่แตกต่างกัน โดยผู้วิจัยมีข้อเสนอแนะและแนวทางการวิจัยในอนาคต ซึ่งคาดว่าจะทำให้ผลการทดลองต่างๆ มีแนวโน้มที่ดีขึ้น แบ่งเป็น 4 ด้าน ดังนี้

#### 5.3.1 ด้านข้อจำกัดของชุดข้อมูล มีข้อเสนอแนะดังนี้

1. เพิ่มชุดข้อมูลของสุนัขแต่ละตัวที่มีช่วงอายุที่แตกต่างกัน เพื่อทดลองว่าสามารถใช้กับสุนัขในช่วงอายุใดได้บ้าง หรือแบบจำลองในการระบุตัวตนของสุนัขตัวเดียวกันแต่ช่วงอายุแตกต่างกัน เพื่อพิสูจน์ว่าช่วงอายุของสุนัขเป็นข้อจำกัดในการทดลองหรือไม่

2. เพิ่มชุดข้อมูลในการระบุตัวตน ให้มากกว่า 5 รูปภาพ ในการลงทะเบียนอย่างน้อย เพื่อให้แบบจำลองได้เรียนรู้คุณลักษณะของสุนัขแต่ละตัวได้มากขึ้น

#### 5.3.2 ด้านการเพิ่มประสิทธิภาพหรือการปรับปรุงการทำงาน มีข้อเสนอแนะดังนี้

1. จากผลการทดลองของขั้นตอนการระบุตัวตนจะเห็นได้ว่าสายพันธุ์ Pug ทำให้ค่าความแม่นยำโดยรวมของแบบจำลองลดน้อยลง เพราะเกิดความสับสนภายในสายพันธุ์ซึ่งหากต้องการเพิ่มความแม่นยำ ควรเพิ่ม ข้อมูล Soft Biometrics อื่นๆ เช่น เพศ สี เป็นต้น หรืออาจเพิ่มข้อมูล Location หรือสถานที่ที่สุนัขตัวนั้นอาศัยอยู่ ก็จะช่วยลดพื้นที่ในการค้นหาสุนัขเพื่อระบุตัวตน และเพิ่มประสิทธิภาพให้แก่แบบจำลอง

2. ในขั้นตอนของการตรวจจับใบหน้าของสุนัข เนื่องจากงานวิจัยนี้ได้นำ Dlib Library มาใช้งานและปรับแต่งเพียงเล็กน้อย ซึ่งการค้นหาจุดต่างๆ ของใบหน้าของสุนัขมีเพียง 6 จุดเท่านั้น ซึ่งหากเพิ่มเป็น 8 จุด นั่นคือปลายใบหูทั้งสองข้าง อาจเพิ่มคุณลักษณะความแตกต่างของสุนัขแต่ละตัวได้ เช่น บางตัวหูตั้งและบางตัวหูตก และนอกจากนี้อาจทดลองเปลี่ยนวิธีการหรือ Library อื่นๆ ในการตรวจจับใบหน้า เช่น YOLO MTCNN เป็นต้น

3. นำ Pre-train Models จาก CNNs ชนิดอื่นมาทดลองเพื่อเพิ่มโอกาสที่จะค้นหา Pre-train Models ที่ช่วยในการสร้างแบบจำลองการจำแนกสายพันธุ์และการระบุตัวตนที่มีประสิทธิภาพมากขึ้น และคำนึงถึงความเหมาะสมในการนำไปใช้งานจริง หากแบบจำลองที่ต้องการทรัพยากรระบบมากๆ อาจไม่เหมาะกับการใช้งานกับอุปกรณ์ อย่าง โทรศัพท์มือถือ

4. อาจเลือกใช้วิธี One-Shot Learning ที่เป็นเทคนิคการเรียนรู้แบบ Transfer Learning ซึ่งแบบจำลองจะเรียนรู้ด้วยข้อมูลจำนวนมากก่อน แล้วนำมาใช้กับการจำแนกที่มีข้อมูลตัวอย่างน้อยหรือไม่มีตัวอย่างเลย โดยวิธีนี้จะช่วยลดปริมาณการใช้ข้อมูลลงได้

### 5.3.3 ด้านความครอบคลุม มีข้อเสนอแนะดังนี้

1. เนื่องจากการทดลองได้ใช้ Pre-train Models ของ CNNs ที่ได้เรียนรู้จากชุดข้อมูล ImageNet ซึ่งสามารถเรียนรู้สายพันธุ์ของสุนัขได้เพียง 120 สายพันธุ์จากทั่วโลกเท่านั้น ซึ่ง ณ ปัจจุบันสุนัขพันธุ์มีมากกว่า 300 สายพันธุ์ที่ได้รับการยอมรับโดยคณะกรรมการสากลเพื่อความเข้าใจและความสามารถในการแยกสายพันธุ์ของสุนัขทั่วโลก (The Fédération Cynologique Internationale, FCI) และองค์การสุนัขยุโรป (The Kennel Club of Europe) นอกจากนี้ยังมีสายพันธุ์อื่นๆ ที่ไม่ได้รับการยอมรับโดยคณะกรรมการสากล ดังนั้นจำนวนของสุนัขพันธุ์อาจจะแตกต่างกันไปตามแหล่งอ้างอิงที่ต่างกัน จึงอาจทำให้แบบจำลองไม่สามารถใช้งานกับสุนัขทุกสายพันธุ์ ซึ่งอาจจะต้องนำวิธีการจากงานวิจัยไปประยุกต์สร้างแบบจำลองให้สามารถจำแนกสายพันธุ์ให้สอดคล้องกับความเป็นจริง

2. เนื่องจากชุดข้อมูลของสุนัขสายพันธุ์ไทยที่นำมาใช้ เป็นสายพันธุ์ไทยแท้ที่มีการขึ้นทะเบียนไว้ แต่ในประเทศไทยยังมีสายพันธุ์ผสมอื่นๆ รวมไปถึงสุนัขบ้านที่ยังไม่ได้มีการขึ้นทะเบียน หากต้องการนำแบบจำลองไปใช้งานอาจจะต้องทดสอบกับชุดข้อมูลสุนัขภายในประเทศให้ครอบคลุม เพื่อให้สอดคล้องกับการนำไปใช้

### 5.3.4 ด้านการทำ Data augmentation มีข้อเสนอแนะดังนี้

1. เนื่องจากจำนวนรูปภาพในงานระบุตัวตนของสุนัขมีอย่างจำกัด ซึ่งมีเพียง 500 รูปภาพเท่านั้น อาจทำให้แบบจำลองเรียนรู้ได้อย่างไม่เต็มประสิทธิภาพ ซึ่งควรเพิ่มปริมาณสำหรับการเรียนรู้ที่เหมาะสม และจึงนำรูปภาพเหล่านั้นไปทำการ Augmentation อีกครั้งเพื่อเพิ่มความหลากหลาย

2. การทำ Data Augmentation ของงานวิจัยนี้ได้เพิ่มรูปภาพหรือตัวอย่างเพียงรูปภาพละ 6 รูปภาพเป็นอย่างมาก ซึ่งอาจทดลองปรับเพิ่มจำนวนรูปภาพ และเพิ่มช่วงของการทำ Data Augmentation แต่ละรูปภาพ อาจทำให้เพิ่มความหลากหลายให้กับชุดข้อมูลและเพิ่มประสิทธิภาพให้กับแบบจำลองได้

## บรรณานุกรม

- Albahli, S., & Albattah, W. (2020). Detection of coronavirus disease from X-ray images using deep learning and transfer learning algorithms. *Journal of X-ray Science and Technology*, 28(5), 841-850.
- Blauch, N. M., Behrmann, M., & Plaut, D. C. (2019). Computational insights into human expertise for familiar and unfamiliar face recognition. *Psyarxiv [Abstract][Google Scholar]*.
- Chollet, F. (2017). *Xception: Deep learning with depthwise separable convolutions*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- coghub. COGNITIVE COMPUTING AND MACHINE LEARNING. Retrieved from <https://www.coghub.com/index.php/cognitive-platform/>
- Elprocus. Biometric Sensors – Types and Its Working. Retrieved from <https://www.elprocus.com/different-types-biometric-sensors/>
- Faisal, M., Alsulaiman, M., Arafah, M., & Mekhtiche, M. A. (2020). IHDS: Intelligent harvesting decision system for date fruit based on maturity stage using deep learning and computer vision. *IEEE Access*, 8, 167985-167997.
- Heipke, C., & Rottensteiner, F. (2020). Deep learning for geometric and semantic tasks in photogrammetry and remote sensing. *Geo-spatial Information Science*, 23(1), 10-19.
- KEMP, S. (2022). DIGITAL 2022: GLOBAL OVERVIEW REPORT. Retrieved from <https://datareportal.com/reports/digital-2022-global-overview-report>
- Khosla, A., Jayadevaprakash, N., Yao, B., & Li, F.-F. (2011). *Novel dataset for fine-grained image categorization: Stanford dogs*. Paper presented at the Proc. CVPR workshop on fine-grained visual categorization (FGVC).
- KRAINET, J. (2562). เรียนรู้และทำความเข้าใจเรื่อง Convolutional Neural Network (CNN) คืออะไร. Retrieved from <https://www.glurgeek.com/education/ml-cnn/>
- Kumar, A. (2021). Different types of Machine Learning: Models / Algorithms. Retrieved

- from <https://vitalflux.com/different-types-of-machine-learning-models-algorithms/>
- Lai, K., Tu, X., & Yanushkevich, S. (2019, 14-19 July 2019). *Dog Identification using Soft Biometrics and Neural Networks*. Paper presented at the 2019 International Joint Conference on Neural Networks (IJCNN).
- Leonardo, M. M., Carvalho, T. J., Rezende, E., Zucchi, R., & Faria, F. A. (2018). *Deep feature-based classifiers for fruit fly identification (Diptera: Tephritidae)*. Paper presented at the 2018 31st SIBGRAPI conference on graphics, patterns and images (SIBGRAPI).
- Liu, Y., & Chen, Y. (2020). *Research on Pet Dog Species Identification Based on Convolution Neural Network*. Paper presented at the 2020 13th International Symposium on Computational Intelligence and Design (ISCID).
- mathworks. Tips in Selecting a Model. Retrieved from <https://www.mathworks.com/solutions/deep-learning/models.html>
- Ngoma, Y. M. (2017). *Analysis of Control Attainment in Endogenous Electroencephalogram Based Brain Computer Interfaces*. Tshwane University of Technology.
- Pinheiro Moreira, T., Lisboa Perez, M., de Oliveira Werneck, R., & Valle, E. (2015). Where Is My Puppy? Retrieving Lost Dogs by Facial Features. *arXiv e-prints*, arXiv: 1510.02781.
- Prabhakar, S., Pankanti, S., & Jain, A. K. (2003). Biometric recognition: security and privacy concerns. *IEEE Security & Privacy*, 1(2), 33-42.
- Pröve, P.-L. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. Retrieved from <https://towardsdatascience.com/mobilenetv2-inverted-residuals-and-linear-bottlenecks-8a4362f4ffd5>
- Rishita, M. V. S., & Harris, T. A. (2018). *Dog breed classifier using convolutional neural networks*. Paper presented at the 2018 International Conference on Networking, Embedded and Wireless Systems (ICNEWS).
- softwaretestinghelp. (2022). Data Mining Vs Machine Learning Vs Artificial Intelligence Vs Deep Learning. Retrieved from <https://www.softwaretestinghelp.com/data-mining->

vs-machine-learning-vs-ai/

- Stike, T. (2019). Comparing Face Detection to Face Recognition. Retrieved from <https://honorlock.com/blog/face-detection-vs-face-recognition-in-online-proctoring/>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). *Rethinking the inception architecture for computer vision*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Tao, W., Al-Amin, M., Chen, H., Leu, M. C., Yin, Z., & Qin, R. (2020). Real-time assembly operation recognition with fog computing and transfer learning for human-centered intelligent manufacturing. *Procedia Manufacturing*, 48, 926-931.
- Tavares, J. F., Costa, Y. M., & Colanzi, T. E. (2021). *Classification of UML Diagrams to Support Software Engineering Education*. Paper presented at the 2021 36th IEEE/ACM International Conference on Automated Software Engineering Workshops (ASEW).
- Varshney, A., Katiyar, A., Singh, A. K., & Chauhan, S. S. (2021). *Dog Breed Classification Using Deep Learning*. Paper presented at the 2021 International Conference on Intelligent Technologies (CONIT).
- Vlachynska, A., Oplatkova, Z. K., & Turecek, T. (2019). *Dogface Detection and Localization of Dogface's Landmarks*, Cham.
- Weerasekara, D., Gamage, M., & Kulasooriya, K. (2021). *Combined Approach of Supervised and Unsupervised learning for Dog Face Recognition*. Paper presented at the 2021 6th International Conference for Convergence in Technology (I2CT).
- Xie, G., Yang, K., Bai, Y., Shang, M., Rui, Y., & Lai, J. (2016). *Improve dog recognition by mining more information from both click-through logs and pre-trained models*. Paper presented at the 2016 IEEE International Conference on Multimedia & Expo Workshops (ICMEW).
- Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., & Shen, F. (2022). Image data augmentation for deep learning: A survey. *arXiv preprint arXiv:2204.08610*.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). *Learning transferable architectures*



for scalable image recognition. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.

Zschech, P., Sager, C., Siebers, P., & Pertermann, M. (2021). Mit Computer Vision zur automatisierten Qualitätssicherung in der industriellen Fertigung: Eine Fallstudie zur Klassifizierung von Fehlern in Solarzellen mittels Elektrolumineszenz-Bildern. *HMD Praxis der Wirtschaftsinformatik*, 58(2), 321-342.

กมลพรรณ ประเสริฐสังข์. (2546). สุนัขกับคน. Retrieved from

<https://www.nectec.or.th/schoolnet/library/create-web/10000/generality/10000-10203.html>

ผศ.ดร.กอบเกียรติ สระอุบล. (2565). เรียนรู้ *Ai Deep Learning* ด้วย *Python*. กรุงเทพฯ: อินเทอร์เน็ตมีเดีย.

ผศ.ดร.ณัฐโชติ พรหมฤทธิ์. (2564). Transfer Learning with Keras for Computer Vision Applications. Retrieved from <https://blog.pijop.org/transfer-learning-with-keras-for-computer-vision-applications/>

พิพัฒน์ สมโลก. (2563). Machine Learning สิ่งใกล้ตัวแห่งโลกยุคใหม่. Retrieved from <https://www.depa.or.th/th/article-view/article11-2563>

มหาวิทยาลัยขอนแก่น, ค. ค. (2015). เอกสารประกอบการสอน วิชาการจัดการดูแลสุนัข Dog Management. Retrieved from <https://vet.kku.ac.th/physio/DOG%20PDF/>

สำนักงานปศุสัตว์เขต 9 กรมปศุสัตว์. (2565). ผลการดำเนินงานตามประเด็นการตรวจติดตามโครงการสัตว์ปลอดโรค คนปลอดภัย จากโรคพิษสุนัขบ้า ปีงบประมาณ 2564.

สำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์. (2565). การพิสูจน์ และยืนยันตัวตนด้วยระบบไบโอเมตริก.

องค์กรพิทักษ์สัตว์แห่งโลก. (2563). สุนัขที่ถูกทิ้งกว่า 300 ตัวจากผลกระทบโควิด19 กับความช่วยเหลือทั่วโลก. Retrieved from <https://www.worldanimalprotection.or.th/helping-stray-dogs>

อาภรณ์ ไร่ไซ. (2560). พฤติกรรมสัตว์ (Animal Behavior). Retrieved from <https://www.scimath.org/lesson-biology/item/7042-animal-behavior>



ประวัติผู้เขียน

