

Computer Science Department
Faculty of Informatics, Maharakham University

บทความวิจัย

ระบบค้นหาสุนัขด้วยการเรียนรู้เชิงลึก

Find My Dog application using Deep Learning

นัทชา หาญจิตต์, วรรณธร นรินทร์รัมย์, พรทิวา ปะวะระ

สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาการสารสนเทศ มหาวิทยาลัยมหาสารคาม
natcha.hanjit@gmail.com, masterkiller7788@gmail.com, pornntiwa.p@msu.ac.th

บทคัดย่อ

ในปัจจุบันการคัดแยกประเภทหมวดหมู่มีบทบาทสำคัญในเรื่องการใช้จำแนกลักษณะเฉพาะของวัตถุ สิ่งมีชีวิตต่างๆ ดังนั้นการแยกประเภทหมวดหมู่สิ่งที่มีลักษณะคล้ายกันจึงเป็นเรื่องยากเมื่อสังเกตลักษณะทั่วไปโดยรวม จึงจำเป็นต้องมีการคัดแยกสิ่งที่มีลักษณะเฉพาะ ซึ่งมีเอกลักษณ์เด่นเฉพาะตัว ยกตัวอย่างเช่น การคัดแยกสายพันธุ์สุนัข และจำแนกลักษณะเด่นเฉพาะที่มีเพียงสุนัขตัว

ดังนั้นโครงงานฉบับนี้จึงนำเสนอการสร้างโมเดลของการประมวลผลเพื่อตามหาสุนัขที่หายไป โดยในงานนี้จะอยู่ในลักษณะของการแยกประเภทสายพันธุ์สุนัข โดยอาศัยการจำแนกภาพ (Classification) และโครงข่ายประสาทเทียม (Convolutional Neural Network: CNN)

1. บทนำ

ในปัจจุบันนี้จำนวนสุนัขจรจัดเป็นปัญหาอย่างยาวนาน เนื่องจากในแต่ละสถานที่สามารถพบเห็นสุนัขแทบทุกพื้นที่ ไม่ว่าจะเป็นสุนัขที่มีเจ้าของ หรือสุนัขที่หลงทางจากบ้านของมันเอง ซึ่งเป็นอีกปัญหาที่เจ้าของต้องการความช่วยเหลือ จะไปแจ้งตำรวจ

อาจจะดำเนินการล่าช้า หรือโพสต์ลงโซเชียล (Social) เพื่อต้องการตามหา หากแต่เป็นการค้นหาแบบวงกว้างเกินไปที่จะหาสุนัขพบ และสุนัขจรจัดที่เกิดจากการเพาะพันธุ์ขายและเกิดจากการผสมพันธุ์กันเองของสุนัข จนมีมาเกินความต้องการ และถูกปล่อยทิ้ง ดังนั้นสุนัขจรจัดเหล่านี้ส่วนมากแล้วจึงไม่เคยได้รับการทำหมัน ลูกสุนัขที่เกิดขึ้นในบ้านและเจ้าของไม่ต้องการเลี้ยง ก็ถูกนำมาปล่อยทิ้งแถวถนน ตลาด ตรอกข้างตึก หรือวัด ส่งผลกระทบด้านต่างๆ มากมาย ตั้งแต่เห่าหอนเสียงดังสร้างความรำคาญ วิ่งตัดหน้ารถเสียหลักจนเกิดอุบัติเหตุบนท้องถนน ขับถ่ายไม่เป็นที่เป็นทาง เป็นต้น เนื่องจากสุนัขแต่ละสายพันธุ์จะมีเอกลักษณ์เฉพาะ แต่อาจมีบางสายพันธุ์ที่ลักษณะใกล้เคียงกันจนทำให้คนทั่วไปแยกไม่ออก จึงเป็นเรื่องยากในการคัดแยกด้วยการมองเห็นลักษณะทั่วไปโดยรวม นอกจากจะสังเกตคุณสมบัติเฉพาะของแต่ละสายพันธุ์ ก็จะสร้างโมเดลจำแนกประเภทสุนัข (Model dog classification) เพื่อช่วยในการจำแนกสุนัขด้วยอัลกอริทึมแบบโครงข่ายประสาทเทียม (Convolutional Neural Network: CNN) โดยมีการจำแนกประเภทสายพันธุ์สุนัข


(Fine-grained classification) และคุณสมบัติเบื้องต้นของสุนัข(Multi-label classification) เพื่อทำการประมวลผลในการจัดกลุ่มสายพันธุ์

จากเหตุที่กล่าวมาข้างต้นจึงเกิดแนวคิดเพื่อประยุกต์ใช้ต้นแบบ Fine-grained classification และ Multi-label classification ในสร้างเป็นโมเดลจำแนกประเภทสุนัข(Model dog classification) ต้นแบบให้มีประสิทธิภาพและความแม่นยำสูง

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1. ทฤษฎีที่เกี่ยวข้อง

2.1.1. การเสริมข้อมูล (Data Augmentation) เป็นการเพิ่มข้อมูลรูปภาพหรือการแปลงภาพในข้อมูลการฝึกอบรม (Training Data) ให้เป็นภาพที่เปลี่ยนแปลงการหมุน พลิก เลื่อน ตัด หมุน หรือเปลี่ยนความสว่างของภาพ จะทำให้ได้ภาพรูปแบบต่างๆไม่จำกัด เนื่องจากความแม่นยำของโมเดลขึ้นอยู่กับปริมาณข้อมูลเป็นปัจจัยสำคัญหลัก เพื่อเพิ่มความน่าเชื่อถือให้กับชุดข้อมูล



ภาพประกอบที่ 1 Data Augmentation

2.1.2. Convolutional Neural Network (CNN) หรือโครงข่ายประสาทเทียมจัดเป็นการเรียนรู้เชิงลึก (Deep Learning) มีการทำงานเริ่มจากการรับข้อมูลเข้ามาผ่านชั้นนำเข้าข้อมูล (Input layer) เพื่อส่งเข้าไปทำ

การประมวลผลโดยหน่วยย่อยของแต่ละชั้นที่ชั้นประมวลผล (Hidden Layers) เมื่อประมวลผลเสร็จชั้นสุดท้ายจะส่งไปยังชั้นแสดงผล (Output layer) ซึ่ง CNN สามารถจับคุณสมบัติที่เด่นของข้อมูล โดยใช้ตัวกรองที่เกี่ยวข้อง ในการลดจำนวนพารามิเตอร์ของข้อมูล โดยไม่ลดประสิทธิภาพของคุณสมบัติลง ขั้นตอนการหลักของ Convolutional Neural Network มีทั้งหมด 3 ชั้น คือ

(1) Convolution layer เป็นการค้นหาคุณลักษณะที่สำคัญของภาพ โดยขั้นตอนนี้จะใช้ตัวกรอง (Filter หรือ Kernel) เพื่อแยกองค์ประกอบต่างๆของภาพ เช่น ขอบ สี เป็นต้น โดยปกติภาพจะมีสีหลัก 3 สี (RGB) คือ สีแดง สีน้ำเงิน และสีเขียว แบ่งเป็น 3 Channel และภาพแสดงเป็นเมทริกซ์ 3 มิติ คือ ความกว้าง ความสูง และความลึก (Width, Height, Depth) โดยความลึกสอดคล้องกับช่องสี (RGB) ซึ่งแต่ละพิกเซลบอกความเข้มของสี ตั้งแต่ 0 ถึง 255 และทำการ Convolution เพื่อเก็บค่าไว้ในเมทริกซ์ชุดใหม่ที่เรียกว่า Feature Map

(2) Pooling layer เป็นการลดขนาดของ Feature Map ให้มีขนาดเล็กลงแต่ยังคงรักษาคุณสมบัติของข้อมูลที่สำคัญไว้ โดยมีการหาส่วนที่สำคัญที่สุดของข้อมูล และเพิ่มประสิทธิภาพการประมวลผลรวดเร็วมากขึ้นด้วยการหาค่าที่สูงที่สุด (Max Pooling), การหาค่าเฉลี่ย (Average Pooling) ของส่วนที่ครอบคลุมด้วยตัวกรองเก็บไว้

(3) Fully Connected Layer การเชื่อมต่อกันของแต่ละชั้นอย่างสมบูรณ์ จากกระบวนการ

การ 2 ชั้นตอน คือ Convolution layer ทำการสกัดคุณลักษณะที่สำคัญของภาพ และ Pooling layer ทำการลดมิติของ Feature Map ให้มีขนาดเล็กลงแต่ยังคงรักษาคุณสมบัติของข้อมูลที่สำคัญไว้ ซึ่งในชั้นตอนนี้จะเป็นการทำซ้ำตั้งแต่ Convolution layer ไปจนถึง Pooling layer จนกว่าจะเกิดการเชื่อมต่อกันอย่างสมบูรณ์ และทำกระบวนการ 2 ชั้นตอน ด้วย Activation Functions และ Loss Function เพื่อนำลักษณะเด่นที่สำคัญของภาพที่ได้มาทำการสร้างเป็น Neural Network สำหรับการเรียนรู้และทำนายประเภทของภาพ




2.1.3. สถาปัตยกรรม CNN (CNN Architecture)










2.1.3.1. เป็น Image Classifier Neural Network คือ Convolutional Neural Network และรุ่นที่สามของ Inception Model ซึ่งพัฒนาขึ้นครั้งแรกโดยโมเดล GoogLeNet เป็นโครงข่ายประสาทเทียมขนาดใหญ่และมีระดับความแม่นยำที่ดีตามการจัดประเภทภาพ คุณลักษณะบางอย่างของโมเดลนี้รวมถึงน้ำหนัก(weights) เป็นการจำแนกประเภทที่เป็นลักษณะเฉพาะที่สำคัญที่สุดบางประการสำหรับโมเดลนี้ Inception V3 เป็นโครงข่ายประสาทเทียมที่มีประสิทธิภาพเนื่องจากช่วยให้เรียนรู้ความซับซ้อนหลายอย่างและคุณลักษณะที่ยากของแบบจำลองหรือชุดข้อมูล มีขนาดตัวกรองหลายขนาด เช่น 1×1 , 3×3 , 5×5 ซึ่งสามารถใช้ได้ในระดับเดียวกัน

2.1.3.2. Residual Networks แบบ Deep Convolutional Networks มีแนวคิดพื้นฐานคือการเชื่อมต่อแบบ skipblock (หรือการเชื่อมต่อทางลัด) เพื่อให้พอดีกับ Input จากชั้นก่อนหน้าไปยังชั้นถัดไปโดยไม่ต้องปรับเปลี่ยนใดๆ ซึ่งในการทดลองของงานวิจัย จะทำการลบโมดูลทางลัดแบบลึกบางส่วนออกและเพิ่ม Classification layer ใหม่ที่ปรับให้เข้ากับชุดข้อมูลของงาน

2.1.3.3. การจัดประเภทภาพแบบ Fine-grained classification เป็นการแยกความแตกต่างระหว่างคลาสย่อย (Subclass) ของหมวดหมู่ (Class) เดียวกัน เพื่อลดความแปรปรวนภายในคลาสที่สูงและความแปรปรวนระหว่างคลาสที่ต่ำ เป็นการการออกแบบการแสดงคุณลักษณะและตัวแยกประเภทตามคำอธิบายระดับต่ำขั้นพื้นฐาน (Basic low-level descriptors) โดยตัวอย่างภาพอาจคล้ายกันมากและอาจแตกต่างกันในส่วนที่ละเอียดอ่อนบางคุณลักษณะที่แยกแยะได้

ความยากในการจำแนกประเภทหลายการแสดงผล คือปัญหาของการจำแนกประเภทคลาสที่มีลาเบลหลายรายการให้กับแต่ละข้อมูลเป็นการสร้างแบบจำลองเชิงคาดการณ์ที่เกี่ยวข้องกับการแสดงลาเบลหลายลาเบลของคลาสที่ได้รับข้อมูลเข้ามาเพื่อจดจำคุณสมบัติเฉพาะของข้อมูล

Basic-level Classification	Dog	Cat	Chicken
Input			

Fine-Grained classification	Doberman	Beagle	Golden
Input			
			
			

ภาพประกอบที่ 2 Fine-grained classification

2.1.3.4. การจำแนกประเภทหลายลาเบล (Multi-label classification) เมื่อรับข้อมูลเข้ามา สามารถอยู่ในลาเบลได้มากกว่าหนึ่ง ซึ่งเป็นตัวแปรของสองคลาสขึ้นไปพร้อมกันได้ แต่ละข้อมูลสามารถเป็นได้มากกว่าหนึ่งคลาสในเวลาเดียวกัน ตัวอย่างเช่น สายพันธุ์สามารถอยู่ในประเภทใดประเภทหนึ่งเหล่านี้ ปีก, ไชปีเรียน, ปีเกิ้ล, คอร์กี้ หรืออาจเป็นของทั้งสี่ประเภทพร้อมกัน นอกจากนี้ในปัญหาการจำแนกหลายลาเบลคือไม่จำกัดว่าสามารถกำหนดข้อมูลที่นำเข้ามา ว่าแต่ละข้อมูลจะเป็นได้ที่คลาส

2.1.6 การประเมินประสิทธิภาพ (Evaluation)

(1) Confusion Matrix

ในการประเมินประสิทธิภาพการทำนาย หรือการทำนาย (Prediction) กับโมเดลที่สร้างขึ้น ในโปรแกรมแอปพลิเคชัน เปรียบเทียบกับ

ผลลัพธ์จริงที่ถูกต้อง โดยมีความหมายแต่ละตัวดังนี้

True Positive (TP) คือ ค่าทำนายว่าจริง และผลการทำนายบอกว่าจริง

False Positive (FP) คือ ค่าทำนายว่าจริง และผลการทำนายบอกว่าไม่จริง

True Negative (TN) คือ ค่าทำนายว่าไม่จริง และผลการทำนายบอกว่าไม่จริง

False Negative (FN) คือ ค่าทำนายว่าไม่จริง และผลการทำนายบอกว่าจริง

(2) ค่าระลึก (Recall)

ค่าที่โมเดลทำนายเป็นคลาสที่กำลังพิจารณาถูก (TP) ทหารค่าเหตุการณ์จริงเป็นคลาสที่กำลังพิจารณาทั้งถูกและผิด (TP+FN) คำนวณโดยสมการดังนี้

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

(3) ค่าความแม่นยำ (Precision)

ค่าที่โมเดลทำนายเป็นคลาสที่กำลังพิจารณาถูก (TP) ทหารค่าที่โมเดลทำนายว่าเป็นคลาสที่กำลังพิจารณาทั้งถูกและผิด (TP+FP) คำนวณโดยสมการดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

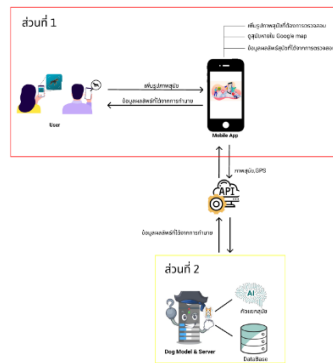
(4) ค่าความถูกต้อง (Accuracy)

การคำนวณความถูกต้องเพื่อเปรียบเทียบประสิทธิภาพการทำนาย จากค่าที่โมเดลทำนายถูกต้องทั้งหมด (TP+TN) ทหารค่าทั้งหมด (TP+TN+FP+FN) คำนวณโดยสมการดังนี้

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

3. วิธีดำเนินงานวิจัย

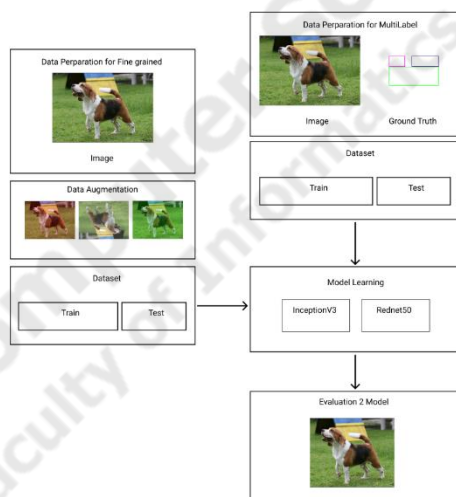
3.1. กรอบการดำเนินงาน



ภาพประกอบที่ 3 การดำเนินงานของระบบ

3.2. ขั้นตอนการดำเนินงานระบบค้นหาสุนัขด้วยการเรียนรู้เชิงลึก

การสร้างแบบจำลองโมเดลแบบ Classification โดยใช้ CNN ในงานวิจัยนี้ใช้สถาปัตยกรรม CNN แบบ Inception V3 และ ResNet50



ภาพประกอบที่ 4 กรอบการดำเนินงาน

3.3. การรวบรวมชุดข้อมูล (Data Preparation)

ในการเก็บข้อมูลในการวิจัยนี้ ได้ทำการเก็บชุดข้อมูลสุนัข 11 สายพันธุ์จากเว็บไซต์

ต่างๆ จาก Google Search, Facebook, Stanford Dogs จาก ImageNet และจากการถ่ายภาพทางมือถือ โดยจะแบ่งชุดข้อมูลสำหรับ 2 โมเดล คือ

3.3.1. ชุดข้อมูลที่ใช้ในการสร้างโมเดลมีทั้งหมด 16,243 ภาพ จะแบ่งเป็นชุดข้อมูลสำหรับการสอน 12,994 ภาพ การทดสอบ 3,249 ภาพ



ภาพประกอบที่ 5 สุนัขแต่ละสายพันธุ์

3.3.2. ชุดข้อมูลสำหรับ Multi-label Model ชุดข้อมูลที่ใช้ในการสร้างโมเดลมีทั้งหมด 13,872 ภาพ ทำการปรับแต่ละภาพเป็นขนาด 227×227 และนำมาทำ Ground Truth จากนั้นจะแบ่งเป็นชุดข้อมูลสำหรับการสอน 80% และการทดสอบ 20% ด้วยมือ โดยจะกำหนดให้แต่ละ Label ของ Feature หู หาง ขน ปลายคอ มีอยู่ 2 กรณี คือ 0 หรือ 1 เช่น หูตั้ง หูตก หางสั้น หาง ยาว เป็นต้น

4. ผลการทดลอง

4.1. วิธีการทดลอง

จากชุดข้อมูลสำหรับ Fine-grained มีทั้งหมด 16,967 ภาพ และชุดข้อมูลสำหรับ Multi-label มีทั้งหมด 13,864 ภาพ โดยแต่ละโมเดลสามารถแบ่งชุดข้อมูลออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลการเรียนรู้ 80 เปอร์เซ็นต์ และชุดข้อมูลการตรวจสอบ 20 เปอร์เซ็นต์

ตารางที่ 1 การแบ่งข้อมูล

Classification	จำนวนข้อมูล		
	การเรียนรู้ (80%)	การตรวจสอบ (20%)	การทดสอบ
Fine-grained	12,994	3,973	2,558
Multi-label	11,092	2,772	

การตั้งค่าการฝึกการเรียนรู้

ตารางที่ 2 การตั้งค่าการฝึกการเรียนรู้

Function	Description
Threshold ค่ากลางในการแปลง ค่าทำนาย	0.5
Epoch กำหนดรอบการ เรียนรู้	15
Batch size ขนาดของชุดข้อมูล	32
Train base CNN ฝึกการเรียนรู้โมเดล ส่วนที่หา คุณลักษณะเด่นของ รูปภาพ (Feature	Inception V3, ResNet50

ตารางที่ 3 การตั้งค่าการฝึกการเรียนรู้ (ต่อ)

Function	Description
Extraction)	
Image size กำหนดขนาดภาพที่ จะทำการฝึกทั้งหมด	277
Activation for Multi class แปลงผลรวมเพื่อให้ ได้ผลลัพธ์สำหรับ การจัดหมวดหมู่สาย พันธุ์ หู หาง ขน ปลอกคอ	SoftMax
Activation for Multi-label แปลงผลรวมเพื่อให้ ได้ผลลัพธ์สำหรับ การจัดหมวดหมู่สี ตัว	Sigmoid
Optimizer	Adam, Learning rate 0.00001

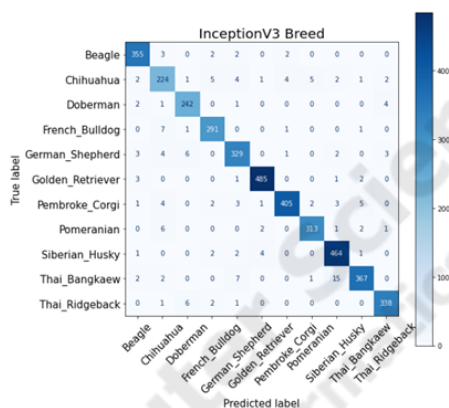
4.2. การเปรียบเทียบประสิทธิภาพการ

รู้จำจากสถาปัตยกรรม CNN

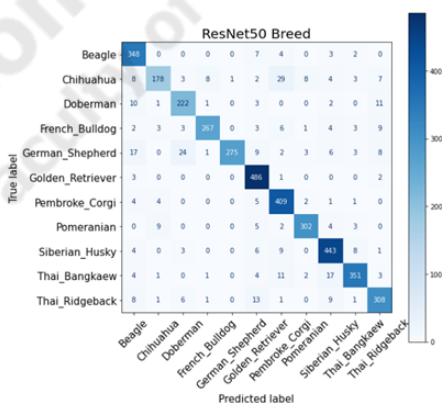
ในการจำแนกสายพันธุ์ได้ประยุกต์ใช้ร่วมกับสถาปัตยกรรม CNN โดยทำการเลือกใช้สถาปัตยกรรม Inception V3 และ ResNet50 ตามลำดับเพื่อหาผลการเรียนรู้ที่มีประสิทธิภาพที่ดีที่สุด โดยทำการประเมินประสิทธิภาพโมเดลด้วย confusion matrix ในการทดลองนี้ ได้ใช้ข้อมูลในการเรียนรู้ในการทำ Fine-grained

classification สำหรับสายพันธุ์ การทำ Multi-label classification สำหรับหู หาง สีตัว ขน ปลอกคอ

การประเมินผลประสิทธิภาพด้วย confusion matrix กับชุดข้อมูลตรวจสอบ 20 เปอร์เซ็นต์จากข้อมูลทั้งหมด จากนั้นนำข้อมูลสำหรับประเมินประสิทธิภาพแต่ละหมวดหมู่ หาค่าความแม่นยำ (Precision), ค่าความระลึก (Recall) ด้วย Confusion Matrix ที่มีค่ากลางเป็น 0.5 เมื่อได้ผลลัพธ์แล้วนำค่าทั้งสองหาค่าความถูกต้อง (Accuracy) สามารถแสดงตัวอย่างการทำ confusion matrix ได้ดังนี้



ภาพประกอบที่ 6 InceptionV3 Confusion matrix



ภาพประกอบที่ 7 ResNet50 Confusion matrix

จากผลการประเมินประสิทธิภาพพบว่าค่าความถูกต้องของสถาปัตยกรรม Inception V3 ดีกว่าหรือใกล้เคียงอยู่ที่ประมาณ 2-3 เปอร์เซ็นต์เมื่อเทียบกับ ResNet50 และได้ทำการทดสอบกับภาพ 100 ภาพ พบว่าโมเดลที่ประยุกต์ใช้กับสถาปัตยกรรม Inception V3 ได้ผลลัพธ์ที่ถูกต้องมากกว่า ดังนั้นเราจึงเลือกใช้สถาปัตยกรรม Inception V3 ประยุกต์ร่วมกับโมเดล โดยการทดลองดังกล่าว สามารถแสดงภาพตัวอย่างที่ได้จากการทำนายผลลัพธ์โดยยกตัวอย่าง ได้ดังต่อไปนี้

ตารางที่ 4 ผลลัพธ์จากการทดสอบของสถาปัตยกรรมที่ประยุกต์ใช้

ภาพที่ 5	ผลเฉลย	ผลทำนายจากสถาปัตยกรรม	
		Inception V3	ResNet50
	หลังอาน	หลังอาน	บักเก็ต
	หูตั้ง	หูตั้ง	หูตก
	หางยาว	หางยาว	หางสั้น
	สีน้ำตาลเข้ม	สีน้ำตาลเข้ม	สีขาว
	ขนสั้น	ขนสั้น	ขนสั้น
	ไม่มีปลอกคอ	ไม่มีปลอกคอ	ไม่มีปลอกคอ

ตารางที่ 5 สรุปผลการประเมินประสิทธิภาพ

แบบเดิม	Accuracy (%)	เลือกใช้
สายพันธุ์	96	✓
หู	96	✓
หาง	76	✓
สีตัว	68	✓
ขน	45	×
ปลอกคอ	86	×

จากผลการเรียนรู้ของ 2 ปัตยกรรม ทั้ง 6 โมเดล โดยการทดลองดังกล่าว โดยที่ โมเดลจากที่ได้เลือกเรียงจากค่า accuracy สูง ไปต่ำ พบว่าโมเดลชนและปลอกคอมีค่า Precision และค่า Recall ต่ำ และเมื่อนำ โมเดลทั้ง 2 ไปทำนายผลกับรูปภาพสุนัข 100 รูป มีค่าเฉลี่ยการทำนายถูกต้องที่ต่ำ จึงเลือก มาโมเดล 4 โมเดลจากทั้ง 6 โมเดล คือ โมเดล สายพันธุ์ หู หาง สีตัว

5. สรุปและอภิปรายผลการทดลอง

5.1. สรุปผลและอภิปรายผล

โครงการงานปริญญานิพนธ์ฉบับนี้นำเสนอ ระบบค้นหาสุนัขด้วยการเรียนรู้เชิงลึก (Find My Dog application using Deep Learning) โดยใช้สถาปัตยกรรม Inception V3 และ ResNet50 มาประยุกต์ใช้ในงานนี้ ร่วมกับการเรียนเรียนรู้เชิงลึก ซึ่งสามารถใช้งานการประมวลผลกับ โมเดลที่จำเป็นต่อการนำไปประยุกต์ใช้บน Application

จากการทดลองประเมินประสิทธิภาพด้วย Confusion Matrix การรู้จำภาพสุนัขโดยใช้ชุด ข้อมูลรูปภาพสายพันธุ์สุนัข 3,973 ภาพ และ ภาพคุณลักษณะของสุนัข 2,772 ภาพ ด้วยการ ประยุกต์ใช้ร่วมกับสถาปัตยกรรม Inception V3 มีประสิทธิภาพในการทำนายสูงสุด และได้ ทำการเลือกโมเดลที่จำเป็นเพื่อนำมา ประมวลผลบน Application ได้แก่โมเดลสาย พันธุ์ หู หาง สีตัว เนื่องจากมีค่าความถูกต้องสูง และผลการทดสอบกับภาพสุนัข 100 ภาพมีผล

การทำนายที่ถูกต้องมากกว่าเมื่อเทียบเท่ากับ โมเดลชนและปลอกคอ

โดยจะพบปัญหาเกี่ยวกับภาพสำหรับการ เรียนรู้ Fine-grained classification มีภาพ สุนัขสายพันธุ์ต่างกันหลายตัวในหนึ่งภาพ อีกทั้งมีบางลักษณะคล้ายกับอีกสายพันธุ์ และภาพ ที่ใช้ในการเรียนรู้เพื่อทำ Ground truth สำหรับ Multi-label classification ส่วนใหญ่ เป็นภาพทางด้านหน้าสุนัขและไม่เห็น คุณลักษณะอื่นที่ชัดเจน รวมทั้งคุณลักษณะที่ สัดส่วนข้อมูลไม่เท่ากัน ทำให้เรียนรู้ข้อมูลและ รู้จำข้อมูลที่มีจำนวนมากกว่า ทำให้การ ประมวลผลมีการทำนายออกมาผิดพลาดและ ค่าความถูกต้องของโมเดลต่ำลง

5.2. ปัญหาและอุปสรรคในการ

ดำเนินงาน

5.2.1. ชุดข้อมูลในการเรียนรู้มีสัดส่วน ของแต่ละลักษณะต่างกันมาก(Imbalanced dataset) ทำให้การเรียนรู้จำข้อมูลไม่เท่ากัน ข้อมูล ของลักษณะหูตั้งมีมากกว่าหูตก หางยาว มากกว่าหางสั้น ไม่มีปลอกคอมากกว่าสีปลอก คออื่นๆ ทำให้โมเดลรู้จำข้อมูลที่มีจำนวน มากกว่าและทำนายผลลัพธ์ได้ไม่ดีพอ

5.2.2. ค่าคะแนน และ threshold อาจยังไม่เหมาะสม ทำให้ข้อมูลที่ต้องการไม่ แสดงผล

5.2.3. ทรัพยากรบนเซิร์ฟเวอร์มีจำกัด ทำให้ต้องใช้เซิร์ฟเวอร์ 3 เซิร์ฟในการทำงาน ด้านการประมวลผลภาพ อัปโหลดและรับส่ง ข้อมูลภาพรวมทั้งตำแหน่ง GPS ออกมาใช้งาน และจัดเก็บข้อมูลผลการทำนายภาพ

5.2.4. เนื่องจากภาพถ่ายที่ถ่ายจากมือถือมีขนาดใหญ่ จำเป็นต้องใช้ทรัพยากรในการประมวลผลบนเซิร์ฟเวอร์อย่างมาก จึงมีปัญหาในการส่งภาพไปทำนายบนเซิร์ฟเวอร์

5.3. ข้อเสนอแนะ

5.3.1. ควรเพิ่มข้อมูลของลักษณะรูปร่าง และปลอกคอ ในชุดข้อมูลสำหรับการเรียนรู้ให้มีสัดส่วนใกล้เคียงกันมากขึ้น

5.3.2. ปรับค่า threshold ความถูกต้อง จากช่วงของค่า threshold เพื่อปรับเกณฑ์การให้คะแนนแต่ละรายการข้อมูล

5.3.3. ควรพัฒนาส่วน Application ในการปรับลดขนาดภาพก่อนส่งไปประมวลผลผ่านเซิร์ฟเวอร์

เอกสารอ้างอิง

1. พิมพ์ ชีวาประกอบกิจ. (2019). การปรับปรุงประสิทธิภาพในการจำแนกภาพด้วยโครงข่ายประสาท แบบคอนโวลูชัน โดยใช้เทคนิคการเพิ่มภาพ. Retrieved 7 July 2021 from 2019 TNI Journal ENG.indd - ThaiJO
2. Machine Learning Tutorial. (2020). Convolutional Neural Networks. Retrieved 7 August 2021 from https://sci2lab.github.io/ml_tutorial/cnn/
5. International Conference on Intelligent Technologies (CONIT). (2021). Dog Breed Classification Using Deep Learning. Retrieved 1 July 2022 from https://www.researchgate.net/publication/353693466_Dog_Breed_Classification_Using_Deep_Learning
6. creativecommons. (2019). Optimized Deep Convolutional Neural Networks for Identification of Macular Diseases from Optical Coherence Tomography Images. Retrieved 1 July 2022 from https://www.researchgate.net/publication/331364877_Optimized_Deep_Convolutional_Neural_Networks_for_Identification_of_Macular_Diseases_from_Optical_Coherence_Tomography_Images
7. Tiago Carvalho. (2019). Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae). Retrieved 1 July 2022 from https://www.researchgate.net/publication/330478807_Deep_Feature-Based_Classifiers_for_Fruit_Fly_Identification_Diptera_Tephritidae
8. Saeed Anwar, et al. (2020). A Systematic Evaluation: Fine Grained CNN vs. Traditional CNN Classifiers. Retrieved 1 July 2022 from <https://deepai.org/publication/a-systematic-evaluation-finegrained-cnn-vs-traditional-cnn-classifiers>

12. Saugata Paul. (2019). A detailed case study on Multi-Label Classification with Machine Learning algorithms and predicting movie tags based on plot summaries!. Retrieved 7 August 2021 from <https://medium.com/@saugata.paul1010/a-detailed-case-study-on-multi-label-classification-with-machine-learning-algorithms-and-72031742c9aa>

Computer Science Department
Faculty of Informatics, Maharakham University