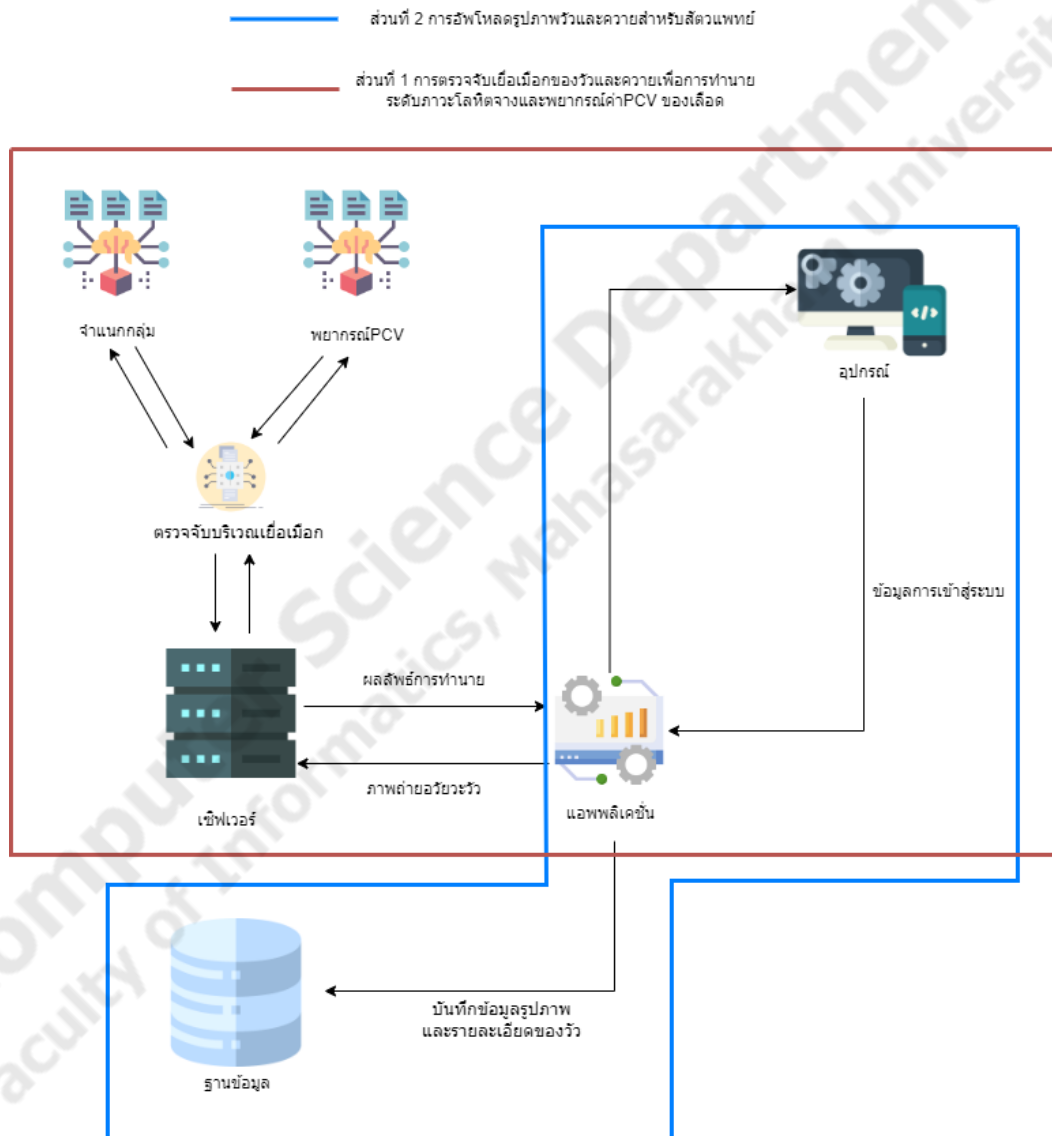


บทที่ 3

วิธีดำเนินงานวิจัย

3.1 กรอบการดำเนินงาน

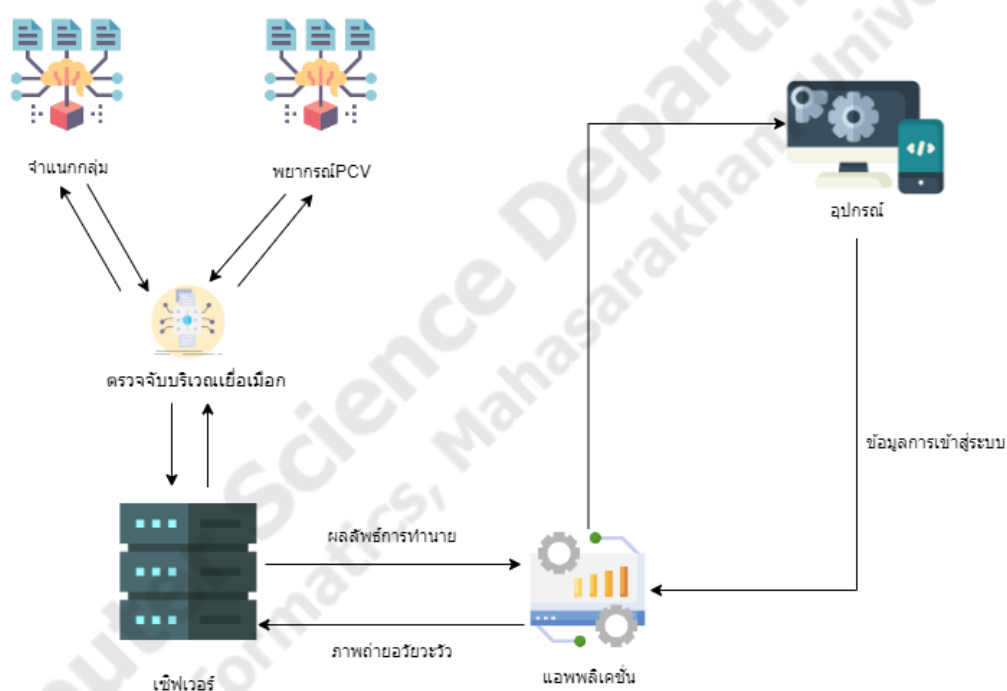


ภาพประกอบที่ 3.1 ขั้นตอนการทำงานของระบบ

จากภาพประกอบที่ 3.1 แผนผังการทำงานรวมของระบบจะแบ่งออกเป็น 2 ส่วนคือ ส่วนของผู้ใช้ที่ใช้ถ่ายภาพอวัยวะของวีวเพื่อทำนายระดับภาวะโลหิตจางและพยากรณ์ค่า PCV ของเลือด และ ส่วนของสัตวแพทย์ที่ใช้ในการอัปโหลดรูปภาพอวัยวะวีวและค่า PCV

ส่วนที่ 1 ส่วนของผู้ใช้ที่ใช้ถ่ายภาพอวัยวะของวัวเพื่อทำนายระดับภาวะโลหิตจางและพยากรณ์ค่า PCV ของเลือด


คือระบบการตรวจจับเยื่อเมือกของวัวและควายเพื่อการทำนายระดับภาวะโลหิตจางและพยากรณ์ค่า PCV ของเลือด ที่ให้ผู้ใช้ถ่ายรูปจากโทรศัพท์จากนั้นส่งไปที่เซิร์ฟเวอร์ เพื่อตรวจจับบริเวณเยื่อเมือกที่ต้องการก่อน แล้วจึงประมวลผลการจำแนกกลุ่มและพยากรณ์ค่า PCV ด้วยวิธีการ FRCNN เมื่อประมวลผลเสร็จ ก็จะส่งผลลัพธ์กลับมาแสดงที่แอปพลิเคชันคือ PCV และระดับภาวะโลหิตจางวัวและควาย โดยมีขั้นตอนตามหัวข้อ 3.2



ภาพประกอบที่ 3.2 การทำงานของระบบ

ส่วนที่ 2 ส่วนของสัตวแพทย์ที่ใช้ในการอัปโหลดรูปภาพอวัยวะวัวและค่า PCV คือระบบการการอัปโหลดรูปภาพสำหรับสัตวแพทย์

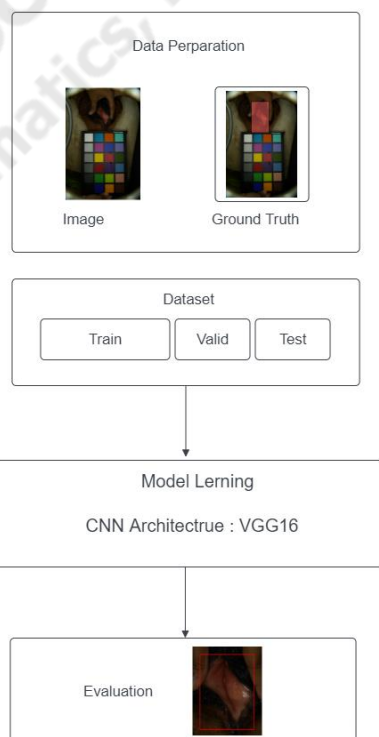
สัตวแพทย์เข้าสู่ระบบก่อนที่จะทำการอัปโหลดรูปภาพอวัยวะของวัวและควายจากอุปกรณ์พร้อมกับค่า PCV และรายละเอียดอื่นเพิ่มเติม โดยมีการออกแบบฐานข้อมูลตามหัวข้อ 3.7



ภาพประกอบที่ 3.3 การทำงานของระบบส้วแพทย์

3.2 ขั้นตอนการทำนายระดับภาวะโลหิตจางและพยากรณ์ค่า PCV ของเลือดวัวและควาย

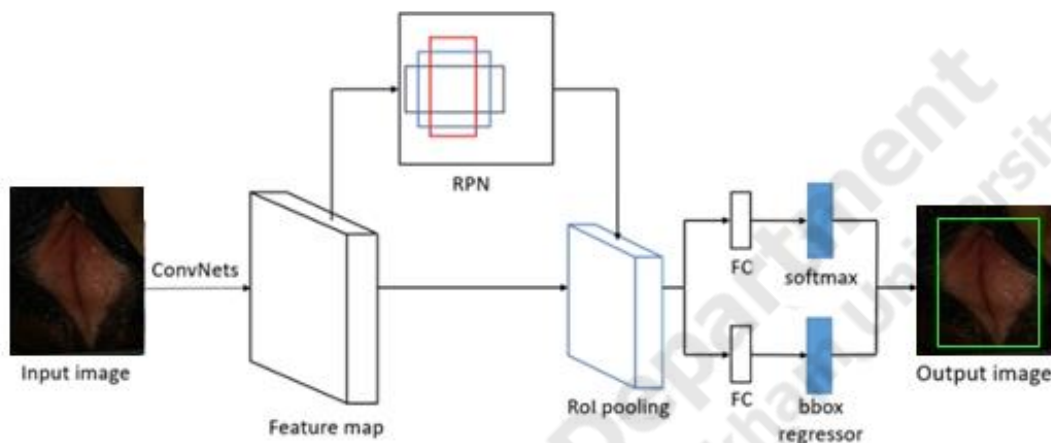
สร้างแบบจำลองโมเดลโดยใช้วิธีการ Faster R-CNN ที่ตรวจจับส่วนบริเวณเยื่อเมือกและทำนายระดับภาวะโลหิตจางและพยากรณ์ค่า PCV ของเลือดวัวและควาย ในงานวิจัยนี้ใช้สถาปัตยกรรม CNN แบบ VGG-16



ภาพประกอบที่ 3.4 ขั้นตอนการจำแนกค่า PCV

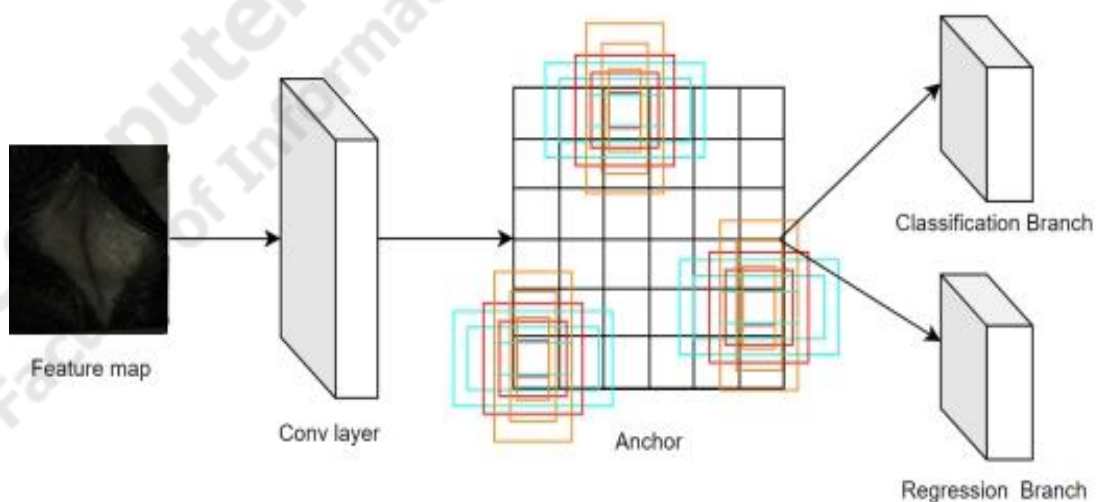
3.3 การตรวจจับวัตถุด้วย Faster R-CNN

Faster Regional-Convolutional Neural Networks พัฒนาต่อจาก CNN, R-CNN, Fast R-CNN โดยมีขั้นตอนดังนี้



ภาพประกอบที่ 3.5 กระบวนการทำงานของ Faster R-CNN

การทำงานจะส่งภาพนำเข้า (Input Image) ไปประมวลผลด้วย Convolutional Layer ของ CNN ก่อนจะได้ผลลัพธ์เป็นภาพที่มีเพียง Feature Map เท่านั้น จากนั้นนำภาพไปทำงานในขั้นตอน Region Proposal Network (RPN) ทำหน้าที่สกัดคุณสมบัติที่คาดว่าจะน่าจะเป็นวัตถุออกจาก Feature Map แสดงขั้นตอนการทำงานได้ดังนี้




ภาพประกอบที่ 3.6 ขั้นตอนการแบ่ง Layer

(1) ขั้นตอนที่หนึ่ง

นำภาพที่ผ่านเข้ามาจะทำการ Convolutional Layer อีกครั้ง แล้วจะได้ Feature Map ที่เล็กลงไปอีก

(2) ขั้นตอนที่สอง


วาดจุดเล็ก ๆ ให้ทั่วทั้งภาพเพื่อให้ขั้นตอนต่อไปวาง Anchor Boxes ได้ทั่วทั้งจุด



ภาพประกอบที่ 3.7 จุดบอกตำแหน่ง

(3) ขั้นตอนที่สาม


สร้างกล่อง Anchor วางทั่วทั้งภาพที่เป็น Feature Map ในตำแหน่งจุดเล็ก ๆ ที่มีการสร้างมาก่อนหน้านี้ โดยในกล่องแต่ละกล่องจะมี Anchor Boxes อีก 9 กล่อง โดยทั่วไปแล้วจะมีสัดส่วน 1:1, 1:2, 2:1 และมีขนาดที่เหมาะสมกำหนดอยู่ที่ 128, 256, 512



ภาพประกอบที่ 3.8 Anchor Boxes

(4) ขั้นตอนที่สี่

ตอนนี้มีกล่อง Anchor ทั้ง 9 กล่องอยู่ในทุก ๆ ตำแหน่งทั่วทั้งแมพ Feature Map แล้วซึ่งในแต่ละตำแหน่งอาจจะเป็นสิ่งของก็ได้ หรืออาจจะเป็นแค่พื้นหลังก็ได้ สำหรับ Region Proposal Network (RPN) จะเรียนรู้ที่จะเลือกตำแหน่งใด ๆ ที่คาดว่าจะน่าจะเป็นสิ่งของจากการเรียนรู้ในขั้นตอนถัดไป



ภาพประกอบที่ 3.9 Anchor ที่กระจายตาม Feature Map


(5) ขั้นตอนที่ห้า

Region Proposal Network จะเรียนรู้และปรับเปลี่ยนด้วย Bounding Box Regression และ Bounding Box Classifications

Bounding Box Classification คำนวณคะแนน IoU ของผลเฉลย (Ground Truth) ด้วยกล่อง Anchor Boxes และจัดประเภทกล่อง Anchor Boxes ที่เป็นสิ่งของหรือเป็นพื้นหลังด้วยความน่าจะเป็น

Bounding Box Regression เรียนรู้การชดเชย (หรือความแตกต่าง) สำหรับค่า X, Y, W, H ที่โมเดลทำนาย (Predicted Box) ออกมาแล้วนำค่ามาเทียบกับผลเฉลย (Ground Truth) เพื่อปรับค่า Anchor Boxes ให้มีการวางตำแหน่งให้ดีขึ้นกว่าเดิม

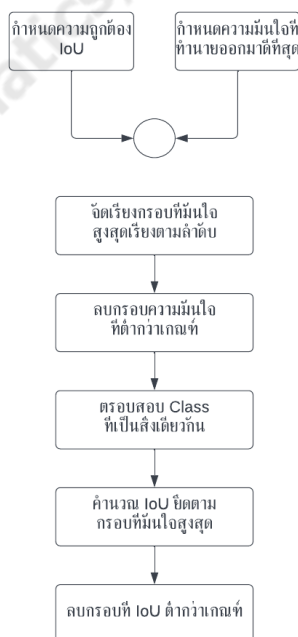
Intersection over union (IoU) เป็นการวัดความถูกต้องของโมเดล เป็นที่นิยมมากในการทำ Object Detection ซึ่งหาได้จากอัตราส่วนระหว่างพื้นที่ที่ Intersection กันของสองกรอบระหว่างกรอบที่โมเดลทำนาย (Predicted Box) ออกมาและกรอบที่มนุษย์เตรียมข้อมูลผลเฉลย (Ground Truth) ไว้ก่อน ผลลัพธ์จากการวัดความถูกต้องนี้จะอยู่ระหว่าง 0 ถึง 1 โดยทั่วไปแล้วความถูกต้องที่ยอมรับคือ 0.5 ขึ้นไป



ภาพประกอบที่ 3.10 การคำนวณหาค่า Intersection over Union

1. Non-max suppression (NMS)

เทคนิคที่ใช้เป็นหลักในการคัดเลือกกรอบวัตถุที่มีการทับซ้อนกันและอยู่ในตำแหน่งที่ใกล้เคียงกันโดยจะยึดตามกรอบที่ทำนายออกมามีความมั่นใจสูงสุด แสดงขั้นตอนการทำงานดังนี้




ภาพประกอบที่ 3.11 ขั้นตอน Non-Max Suppression




ภาพประกอบที่ 3.12 ผลลัพธ์ Non-Max Suppression

3.6.4 Region of interest Pooling (ROI)



ภาพประกอบที่ 3.13 การรวม Feature Map และ RPN

ผลลัพธ์ที่ได้จาก Region Network (RPN) ทำให้เกิดกรอบที่มีขนาดที่แตกต่างกัน หน้าที่ของ Region of Interest Pooling (ROI) จะทำการคัดเลือกคุณลักษณะเด่นจากกรอบแต่ละกรอบที่ได้จาก RPN แล้วจะแปลงเป็นข้อมูลกรอบขนาดที่เท่า ๆ กัน $n \times n$ และจะแบ่งกรอบที่ได้จาก RPN ตามขนาดของ Output เป็น $n \times n$ เช่นเดียวกัน



ภาพประกอบที่ 3.14 การทำงาน Region of Interest Pooling

(1) ขั้นตอนที่หนึ่ง

รับภาพ Feature Map จากภาพนำเข้า (Input Image) และนำกรอบผลการทำนาย (Predicted Box) ที่ผ่านการทำ Region Proposal Network (RPN) ทั้งหมด

(2) ขั้นตอนที่สอง

ในกรอบผลการทำนาย (Predicted Box) จะมีตำแหน่ง X,Y,W,H ที่ทำนายมาให้อีกแล้ววางทับกับภาพ Feature Map ในตำแหน่งเดียวกัน

(3) ขั้นตอนที่สาม

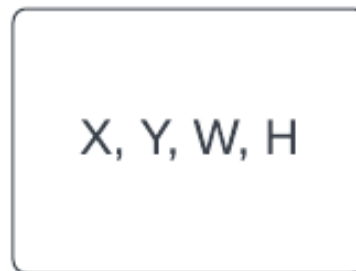
แบ่ง(Split) ผลการทำนาย (Predicted Box) ตามขนาดของ Output ที่เป็นไปได้ เช่น Output มีสองคำตอบที่เป็นไปได้ จะสามารถแบ่งได้ตาม $n \times n$ หรือ 2×2 จากนั้นจะเลือกค่าที่มากที่สุดจากกรอบที่แบ่ง (Split) แล้วผลลัพธ์สุดท้ายจะได้กรอบ ROI เพื่อใช้ในการตัดแยกประเภท CNN

(4) ขั้นตอนที่สี่

ทำต่อไปเรื่อย ๆ กับกรอบผลการทำนาย (Predicted Box) ทั้งหมดจนครบทุกกรอบที่ได้ผลลัพธ์จาก Region Proposal Network (RPN)

เมื่อทำงานครบทุกขั้นตอนก็จะมีทั้งภาพและกรอบที่คัดเลือกมาแล้วนำเข้าขั้นตอนของ Full Connected โดยขั้นตอนนี้จะมีการแบ่งกลุ่มข้อมูลที่ได้จาก ROI Pooling ออกเป็นสองส่วนและทำงานพร้อม ๆ กัน


B-Box Repressor ทำหน้าที่ในการเรียนรู้และปรับค่าที่ผิดพลาดด้วยผลเฉลย (Ground Truth) ในตำแหน่งที่แท้จริงในรูปภาพที่เป็น Input ด้วยกรอบที่ส่งมาจาก ROI Pooling



ภาพประกอบที่ 3.15 ตัวอย่าง input ของ B-Box Regressor
SoftMax ทำหน้าที่เลือกคำตอบที่มีอยู่ใน Output และทำนายผลนั้นออกมาจาก Feature Map ที่ส่งมาจาก ROI Pooling



ภาพประกอบที่ 3.16 ตัวอย่าง Input ของ SoftMax
เมื่อดูภาพรวมของการทำงาน ROI Pooling จนได้ผลลัพธ์สุดท้ายของการตรวจจับวัตถุแล้วนำผลลัพธ์มาวางกับภาพจริง แสดงภาพโดยรวมดังต่อไปนี้



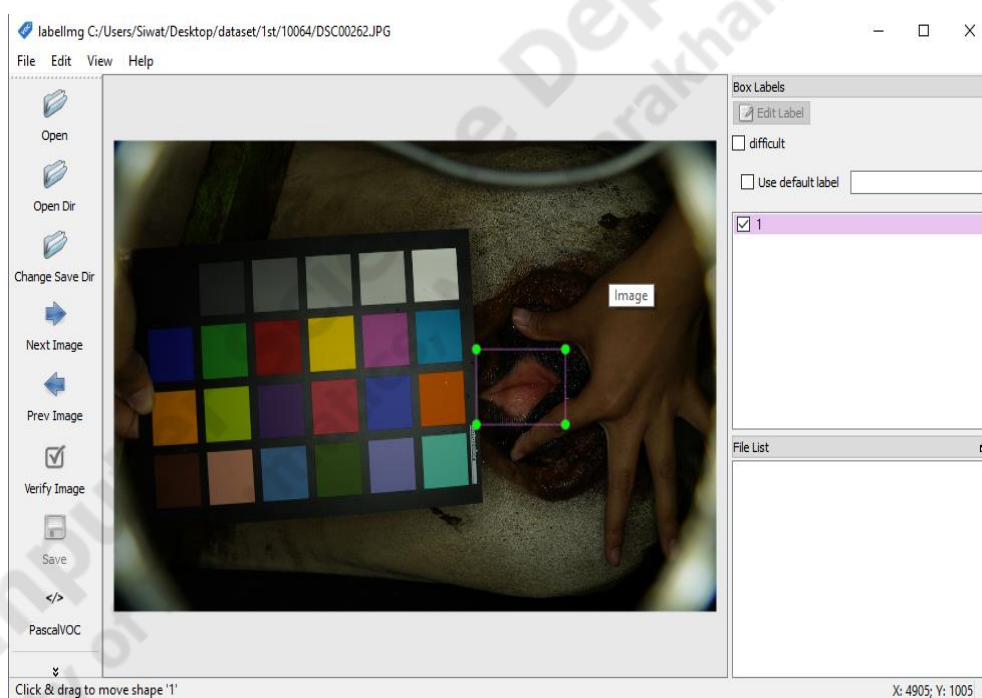
ภาพประกอบที่ 3.17 ผลลัพธ์สุดท้ายที่ได้จาก ROI Pooling

3.4 ระยะการรวบรวมข้อมูล

ในการวิจัยนี้ ได้ข้อมูลรูปภาพอวัยวะนิ้วและควายจากคณะสัตวแพทยศาสตร์ เป็นจำนวน 242 รูปภาพ โดยข้อมูลทั้งหมด นำมาทำ Ground Truth มี 3 ประเภท 3, 2, 1 คือค่าPCV High, Medium, Low,ตามลำดับ แบ่งเป็นจำนวนชนิดละ 79, 94, 69 ตามลำดับ

1. คำอธิบายประกอบข้อมูล (Data annotations)

การกำหนดค่าความจริงของวัตถุ (Ground Truth) ของข้อมูลโดยใช้โปรแกรม LabelImg เวอร์ชัน 1.8.0 ที่ พัฒนาโดย TzuTa ด้วยภาษา Python และ PyQt5 สามารถดาวน์โหลดได้ที่ <https://github.com/tzutalin/labelImg>



ภาพประกอบที่ 3.18 การตัด Ground Truth

3.5 ตัวอย่างการกำหนดค่าความจริง (Ground Truth)

โดยในการกำหนดค่าความจริงแต่ละภาพจะมีภาพละ 1 ชนิด ข้อมูลจะถูกบันทึกลงในไฟล์ข้อความ (.txt) ที่เป็นชื่อเดียวกันกับไฟล์ภาพ และทั้งหมดจะถูกรวมอยู่ในไฟล์ annotate.txt สำหรับการอ่านข้อมูลความจริงของวัตถุ (Ground Truth) และตำแหน่งรูปภาพเพื่อเป็นเส้นทางให้การการเรียนรู้ (Training) สามารถอ่านข้อมูลได้ง่าย ๆ สามารถแสดงวิธีการระบุชื่อไฟล์และชนิดได้ดังตารางดังนี้

ตารางที่ 3.1 การระบุตำแหน่งค่าความจริงและตำแหน่งภาพ

รูปที่	ตำแหน่งไฟล์รูป	X1	Y1	X2	Y2	ชื่อชนิด
1	dataset/10206/ DSC00300.jpg	3906	2021	4889	2817	1
2	dataset/10206/ DSC00301.jpg	3816	2077	4765	2858	1
3	dataset/10064 / DSC00269.jpg	3610	1773	4497	2412	1
....						
200	dataset/ 19679 / DSC00778.jpg	1610	1126	2383	1786	3

3.6 การประเมินผล

ในงานวิจัยนี้จะประเมินผลการ Classification ด้วย Precision Recall และ Mean Average Precision(mAP) ซึ่งเป็นการหาค่าเฉลี่ยของความแม่นยำ(Precision) และความลึก (Recall) ของวัตถุ ในรูปนั้น ๆ โดยโดยที่ ค่าความแม่นยำ หาได้จาก

$$\text{Precision} = \text{TPs} / (\text{TPs} + \text{FPs}) \quad (6)$$

$$\text{Recall} = \text{TPs} / (\text{TPs} + \text{FNs}) \quad (7)$$

โดยที่

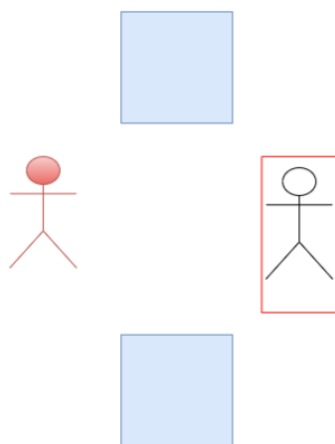
True Positive (TP) คือ สิ่งที่โปรแกรมทำนายว่าจริง และคนบอกว่ามันจริง

True Negative (TN) คือ สิ่งที่โปรแกรมทำนายว่าไม่จริง และคนบอกว่ามันไม่จริง

False Positive (FP) คือ สิ่งที่โปรแกรมทำนายว่าจริง แต่คนบอกว่าไม่จริง

False Negative (FN) คือ สิ่งที่โปรแกรมทำนายว่าไม่จริง แต่คนบอกว่าจริง Precision โดยมี

ตัวอย่างดังนี้



ภาพประกอบที่ 3.19 ตัวอย่างการคำนวณ Precision และ Recall

$$\text{Precision} = 1/1+2 = 0.33 \quad (8)$$


$$\text{Recall} = 1/1+1 = 0.5 \quad (9)$$

การหาค่า Precision และ Recall คำนวณที่ละขั้นตอนตามจำนวนที่ทำนายออกมาเรียงความมั่นใจ (Confident) จากมากไปหาน้อย โดยมีการนับค่าที่ทำนายถูกและผิดและมีการหาค่า Precision และ Recall ไปพร้อม ๆ กัน

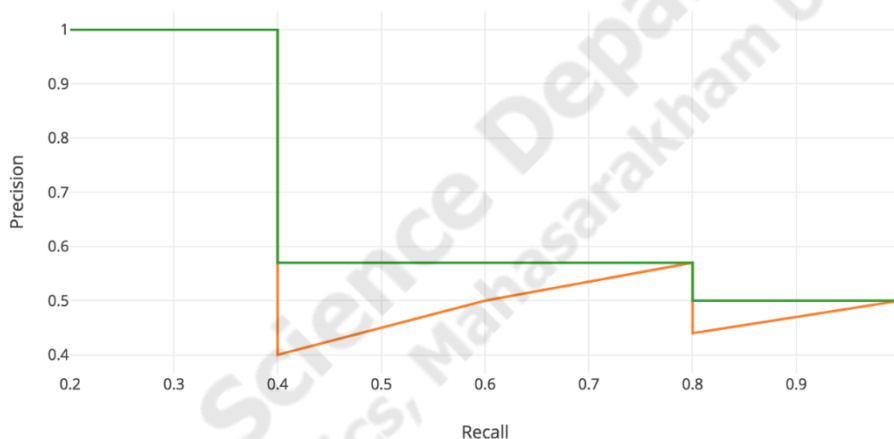
ตารางที่ 3.2 วัดความแม่นยำ

Confident	TP	FP	ALL TP	ALL FP	Precision	Recall
99%	1	0	1	0	1.0	0.2
98%	1	0	2	0	1.0	0.4
95%	0	1	2	1	0.67	0.4
87%	0	1	2	2	0.5	0.4
75%	0	1	2	3	0.4	0.4
60%	1	0	3	3	0.5	0.6
55%	1	0	4	3	0.57	0.8
45%	0	1	4	4	0.5	0.8
33%	0	1	4	5	0.44	0.8
30%	1	0	5	0	0.5	1.0

เมื่อนำ Precision และ Recall ไปสร้างเป็นกราฟจะได้ดังรูป



ภาพประกอบที่ 3.20 Precision และ Recall จากตาราง



ภาพประกอบที่ 3.21 Interpolated Precision

จัดเรียงค่า Precision ด้วยฟังก์ชัน Interpolated Precision จากนั้นหาพื้นที่ใต้กราฟ (AUC) เมื่อได้พื้นที่ใต้กราฟก็จะหา Mean Average Precision (mAP) เพราะ mAP มีค่าเท่ากับ

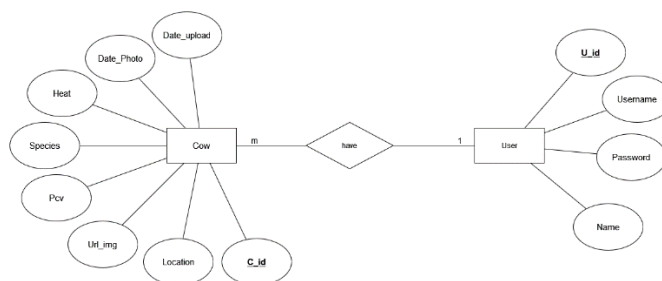
$$AUC = (0.4-0.2) * 1 + (0.8-0.4) * 0.57 + (1-0.8) * 0.5 = 0.528$$

และในส่วนของการ Regression จะประเมินด้วย R-Squared (R2) คือตัวสถิติที่ใช้วัดว่าตัวแบบคณิตศาสตร์ที่ได้นี้มีความสมรूपกับข้อมูลมากน้อยอย่างไร Root Mean Square Error (RMSE) และโดยมีวิธีการดังนี้ สูตรการหา R-Squared (R2) และ RMSE

$$R2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_t)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (prediction - actual)^2} \quad (11)$$

3.7 ER diagram



ภาพประกอบที่ 3.22 ER diagram

3.8 รายละเอียดตารางข้อมูล (Data Table Description)

ตารางที่ 3.3 ตารางแสดงข้อมูล (Cow)

Attribute Name	Type	Size	Description	Key type	References
folder_id	varchar	50	หมายเลขชุดข้อมูลวัว	-	18sf4AamUJO93u 8iKN65CUiWfTV8v JkXQ
folder_name	varchar	50	ชื่อชุดข้อมูลวัว	-	2023-05-12 19:53:56
pcv	int	11	ค่า PCV	-	23
date	date	-	วันที่	-	2023-05-23
specie	varchar	50	สายพันธุ์	-	วัวพื้นเมือง
tools	varchar	50	อุปกรณ์	-	sony alpha 7 iv
description	varchar	255	รายละเอียดเพิ่มเติม	-	2021-06-08 22:27:52

ตารางที่ 3.4 User

Attribute Name	Type	Size	Description	Key type	References
Username	varchar	50	ชื่อผู้ใช้งาน	-	Potna123
Password	varchar	50	รหัสผู้ใช้งาน	-	Popo1223
Name	varchar	50	ชื่อนามสกุล	-	นพรัตน์ จันทร์การดอน