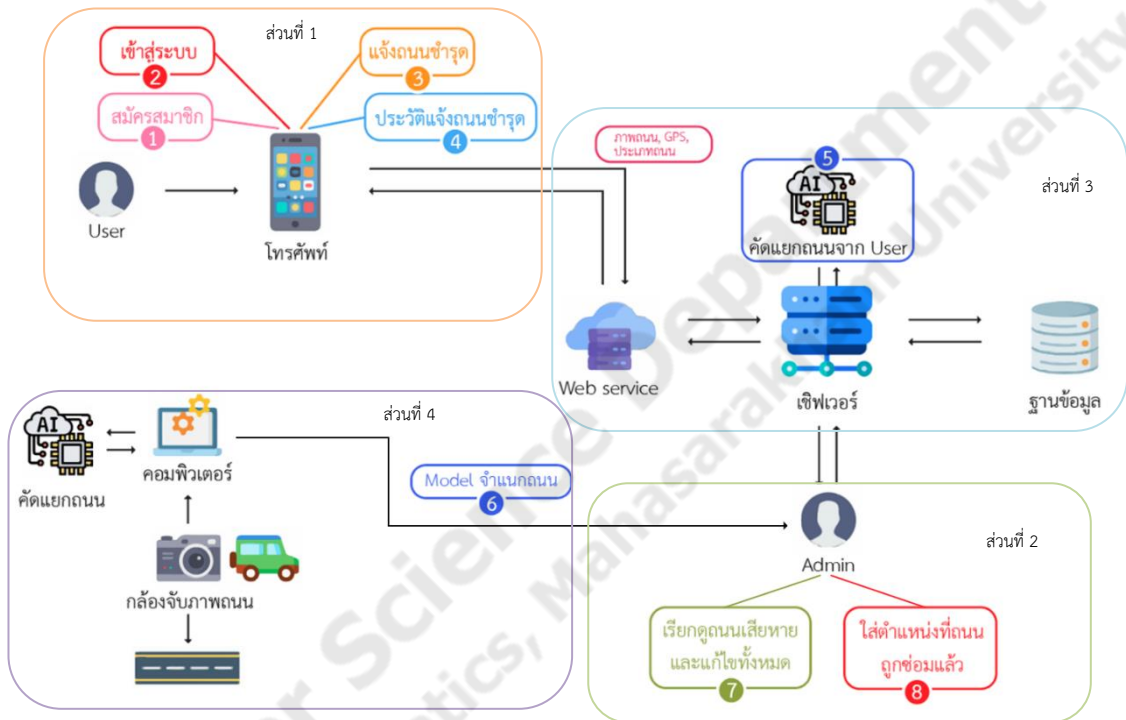


บทที่ 3

วิธีดำเนินงานวิจัย

3.1 กรอบการดำเนินงาน



ภาพประกอบที่ 3.1.1 ขั้นตอนการทำงานของระบบ

3.1.1 ส่วนที่ 1 ผู้ใช้ทั่วไป

คือระบบแจ้งถนนชำรุดสำหรับผู้ใช้ทั่วไปไม่มีเป็นแอปพลิเคชันที่ให้ผู้ทั่วไปส่งรายงานถนนพร้อมทั้งภาพตัวอย่าง และเก็บ GPS ระบุตำแหน่งของการแจ้งถนนชำรุดด้วย



ภาพประกอบที่ 3.1.2 การทำงานของผู้ใช้ทั่วไป

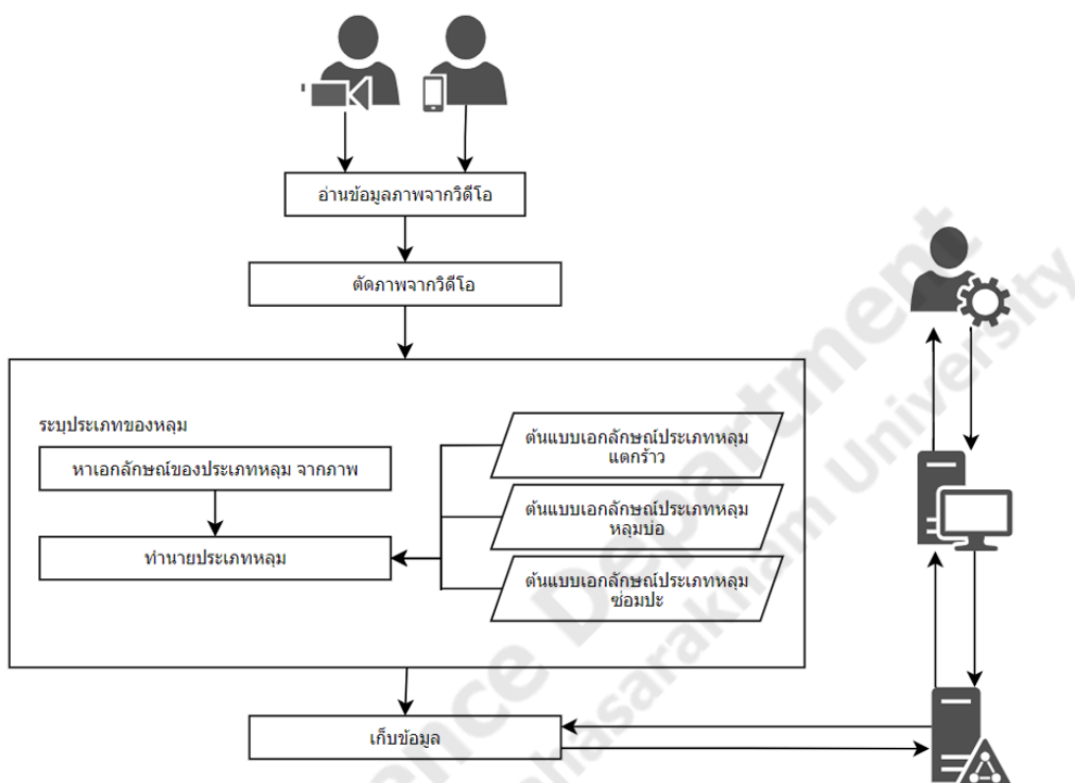
3.1.2 ส่วนที่ 2 ผู้ดูแลระบบ

คือระบบจัดการรายงานถนน สำหรับผู้ดูแลระบบ ผู้ดูแลระบบจะคอยตรวจสอบและจัดการความถูกต้องของรายงานถนนและสามารถเรียกดูรายงานถนนที่ถูกรายงานได้



ภาพประกอบที่ 3.1.3 ขั้นตอนการทำงานของผู้ดูแลระบบ

3.1.3 ส่วนที่ 3 ระบบหลังบ้าน (Backend)



ภาพประกอบที่ 3.1.4 ระบบ Backend

การนำเข้าข้อมูลของเจ้าหน้าที่ที่จะทำการถ่ายวิดีโอถนนและประมวลผล ผู้ใช้ทั่วไปจะส่งเป็นภาพเท่านั้น เมื่อประมวลผลข้อมูลเรียบร้อยแล้วจะทำการเก็บข้อมูลไว้ในระบบ เจ้าหน้าที่อีกฝ่ายจะทำการอ่านข้อมูลและสร้างรายงานถนนในภายหลัง

3.1.4 ส่วนที่ 4 เจ้าหน้าที่

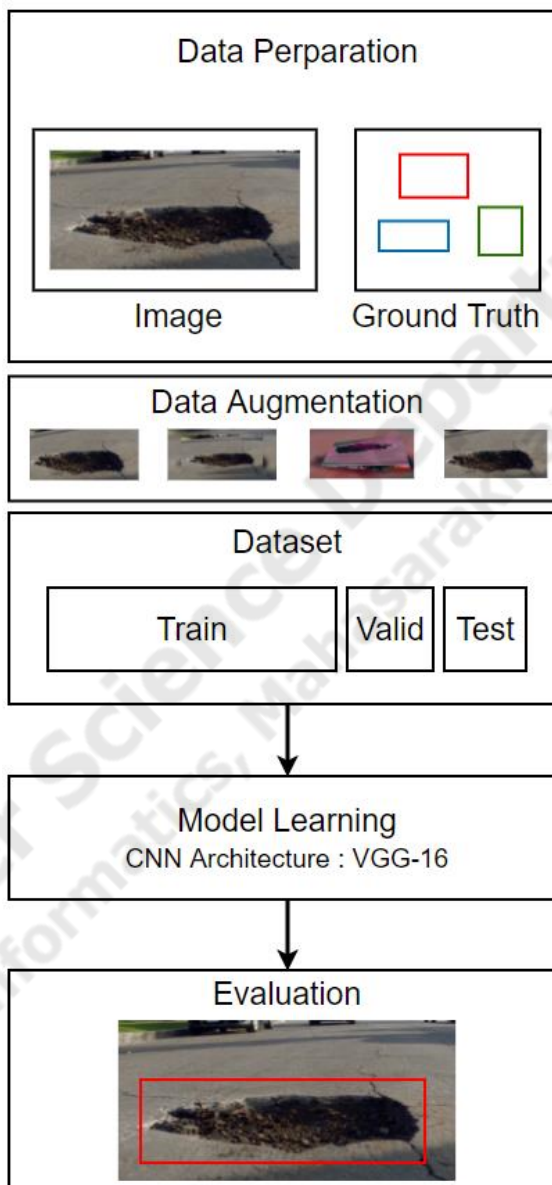
คือระบบเก็บภาพถนนชำรุดสำหรับเจ้าหน้าที่ เจ้าหน้าที่จะถ่ายวิดีโอถนนและนำเข้าโปรแกรมจำแนกถนนเพื่อทราบตำแหน่งถนนชำรุดโดยโปรแกรมมีขั้นตอนการทำงานหลัก ๆ ดังนี้



ภาพประกอบที่ 3.1.5 ขั้นตอนการทำงานของเจ้าหน้าที่

3.2 ขั้นตอนการดำเนินการระบบตรวจจับถนน

การสร้างแบบจำลองโมเดลโดยใช้วิธีการ Faster R-CNN จะคอยทำหน้าที่ตรวจจับและทำนายถนนเสียหายจากเจ้าหน้าที่และผู้ใช้ทั่วไป ในงานวิจัยนี้ใช้สถาปัตยกรรม CNN แบบ VGG-16



ภาพประกอบที่ 3.2.1 แผนผังขั้นตอนการดำเนินการระบบตรวจจับถนน

3.3 การทำงานของ VGG-16


	Layer	Feature Map	Size	Kernel Size	Stride	Activation
Input	Image	1	224 x 224 x 3	-	-	-
1	2 X Convolution	64	224 x 224 x 64	3x3	1	relu
	Max Pooling	64	112 x 112 x 64	3x3	2	relu
3	2 X Convolution	128	112 x 112 x 128	3x3	1	relu
	Max Pooling	128	56 x 56 x 128	3x3	2	relu
5	2 X Convolution	256	56 x 56 x 256	3x3	1	relu
	Max Pooling	256	28 x 28 x 256	3x3	2	relu
7	3 X Convolution	512	28 x 28 x 512	3x3	1	relu
	Max Pooling	512	14 x 14 x 512	3x3	2	relu
10	3 X Convolution	512	14 x 14 x 512	3x3	1	relu
	Max Pooling	512	7 x 7 x 512	3x3	2	relu
13	FC	-	25088	-	-	relu
14	FC	-	4096	-	-	relu
15	FC	-	4096	-	-	relu
Output	FC	-	1000	-	-	Softmax

ภาพประกอบที่ 3.3.1 ขั้นตอนการทำงานของ VGG-16

(ที่มา : www.kaggle.com/blurredmachine/vggnet-16-architecture-a-complete-guide)

ขั้นตอนของการตรวจจับวัตถุด้วย Faster R-CNN มีการใช้โมเดล VGG-16 ไปควบคู่กันในการตรวจจับ และมีการเรียกใช้ Region proposal network (RPN) ก่อนที่จะทำการคัดเลือกคำตอบออกมา และวิธีการทำงานของ VGG-16 หลัก ๆ มีดังต่อไปนี้

3.3.1 ค้นหาคุณลักษณะเด่นของภาพออกมา (Convolution)



ภาพประกอบที่ 3.3.2 ภาพรวมของการ Convolution

การทำงานของในขั้นตอนค้นหาคุณลักษณะเด่นของภาพออกมา (Convolution) จะทำการ Sliding Windows (Filter) เพื่อค้นหาองค์ประกอบของภาพเช่น สี หรือรูปร่าง

80	70	80	80
60	60	80	60
80	60	60	60
80	80	80	80

ภาพขนาด 4 x 4

1	0
0	1

Filter ขนาด 2 x 2

ภาพประกอบที่ 3.3.3 ขนาดภาพนำเข้าและขนาดของ Filter

กำหนดภาพนำเข้าขนาดเป็น 4 x 4 ขนาดของ Filter เป็น 2 x 2 Stride เป็น 1 และ Padding เป็น 1 สามารถแทนค่าสมการได้ดังนี้

$$\text{output of size} = \frac{4 - 2 + 2(1)}{1} + 1 = 5$$

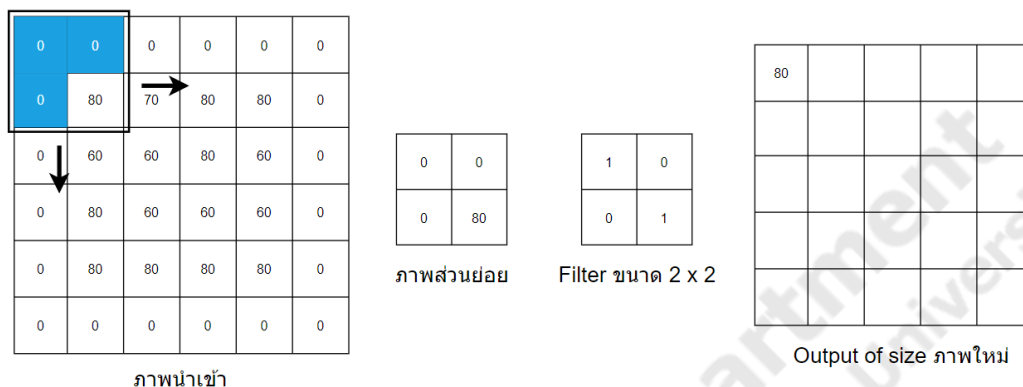
ภาพประกอบที่ 3.3.4 ขนาดภาพใหม่ Output of size ขนาด 5 x 5

กระบวนการ Convolution อาจทำให้ภาพมีขนาดที่เล็กลง ถ้าทำ Convolution หลาย ๆ ชั้น ภาพสุดท้ายที่ออกมาก็จะเล็กลงมาก นอกจากนั้น Convolution ยังมีโอกาสทำให้ข้อมูลที่อยู่ตามขอบภาพไม่ถูกคำนวณเพราะ Filter มีโอกาสจับข้อมูลตามขอบภาพน้อยกว่าตรงกลางภาพแก้ปัญหาด้วยการ Padding ขยายขอบภาพออกทุกด้านเท่า ๆ กันโดยตั้ง Padding เป็น 1

0	0	0	0	0	0
0	80	70	80	80	0
0	60	60	80	60	0
0	80	60	60	60	0
0	80	80	80	80	0
0	0	0	0	0	0

ภาพประกอบที่ 3.3.5 Padding ขยายขอบภาพ

จากนั้นนำ Filter คูณกับภาพที่ทำ Padding เริ่มที่ตำแหน่งแรกของภาพ และนำค่าทั้งสองคูณกันตามตำแหน่งที่ตรงกัน ผลลัพธ์ที่ได้นำมาบวกกันและเก็บผลลัพธ์ไว้ที่ Output of size และทำให้ครบทั่วทั้งภาพจะได้ภาพใหม่ที่เล็กลง



ภาพประกอบที่ 3.3.6 การ Convolutional

แสดงตัวอย่างการคำนวณภาพส่วนย่อยคูณกับ Filter ขนาด 2 x 2 ในรอบที่ 1 ได้ดังนี้

$$\text{ตำแหน่งที่ 1} \quad 0 \times 1 = 0$$

$$\text{ตำแหน่งที่ 2} \quad 0 \times 0 = 0$$

$$\text{ตำแหน่งที่ 3} \quad 0 \times 0 = 0$$

$$\text{ตำแหน่งที่ 4} \quad 80 \times 1 = 80$$

จากนั้น นำผลลัพธ์ของทุกตำแหน่งมาบวกกัน $(0 + 0 + 0 + 80) = 80$ และเก็บผลลัพธ์ไว้ที่ Output of size ภาพใหม่ และเลื่อนตำแหน่งไปให้ทั่วทั้งภาพผลลัพธ์ทั้งหมดจากการคำนวณได้ดังนี้

80	70	80	80	0
60	140	150	140	80
80	120	120	140	60
80	160	140	140	60
0	80	80	80	80

ภาพประกอบที่ 3.3.7 ผลลัพธ์ Output of size

3.3.2 ขั้นตอนการตรวจจับ (ReLU)

การตรวจจับ (Detector) ในขั้นตอนนี้จะทำหน้าที่รับข้อมูลที่ได้จากขั้นตอน Convolution มาแปลงให้อยู่ในรูปแบบที่ไม่เป็นเชิงเส้น (Nonlinear) โดยใช้ฟังก์ชันการกระตุ้น (Activation function) เช่น Rectified Linear Units (ReLU) โดยผลลัพธ์ที่ได้จากการทำ Convolution ในแต่ละตำแหน่งจะผ่านการแปลงค่าด้วยฟังก์ชัน ReLU ที่เป็นการแปลงแบบไม่เป็นเชิงเส้น เพื่อความง่ายในการคำนวณและประสิทธิภาพของผลลัพธ์ สามารถคำนวณด้วยสมการดังนี้

$$ReLU = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (8)$$

โดยที่ x คือจุดพิกเซลของ Output of size

ขั้นตอนการทำงานโดยเงื่อนไขดังนี้

- (1) ให้ x เป็น 0 ก็ต่อเมื่อ x น้อยกว่า 0
- (2) ให้ x เป็น x ก็ต่อเมื่อ x มากกว่าหรือเท่ากับ 0

การทำงาน ReLU กับภาพตัวอย่างแสดงได้ดังนี้

-50	80
60	80

ภาพตัวอย่าง

U_{00}	U_{01}
U_{10}	U_{11}

ReLU

ภาพประกอบที่ 3.3.8 ตัวอย่างการทำงานของ ReLU

$$U_{01} = \max(0, -50)$$

$$U_{00} = 0$$

$$U_{01} = \max(0, 80)$$

$$U_{01} = 80$$

$$U_{10} = \max(0, 60)$$

$$U_{10} = 60$$

$$U_{11} = \max(0, 80)$$

$$U_{11} = 80$$


สรุปภาพตัวอย่างหลังจากทำ ReLU ได้ผลลัพธ์ดังนี้

0	80
60	80

ภาพตัวอย่าง

ภาพประกอบที่ 3.3.9 ภาพตัวอย่างหลังจากทำ ReLU


3.3.3 ลดขนาดของภาพด้วยการเลือกจุดเด่นสุด (Max Pooling)



ภาพประกอบที่ 3.3.10 ภาพรวมของการ Max Pooling

ลดขนาดของภาพด้วยการเลือกจุดเด่นสุด (Max Pooling) เพื่อลดขนาดข้อมูลภาพให้เล็กลงแต่รายละเอียดยังคงลักษณะที่เด่นไว้ และยังเพิ่มความเร็วในการคำนวณในขั้นตอนถัดไป ในการคำนวณหาค่าสูงสุด (Max Pooling) วิธีการทำงานคล้ายกับ Convolution โดยเพิ่มขั้นตอนการหาค่าที่มากที่สุด และก่อนจะได้ผลลัพธ์ต้องนำภาพผ่านขั้นตอน ReLu อีกครั้ง และแสดงขั้นตอนการทำงานได้ดังนี้


Stride จะเลื่อน Filter ตามขนาดที่กำหนด เช่น ขนาด 2×2 ซึ่งจะทำให้มีการลดขนาดของภาพลงได้ครั้งหนึ่งดังตัวอย่าง




ตัวอย่างภาพนำเข้า

ภาพประกอบที่ 3.3.11 การหาค่าสูงสุด (Max Pooling)

3.3.4 แฝ่ภาพให้เป็นแนวตั้ง (Flatten)



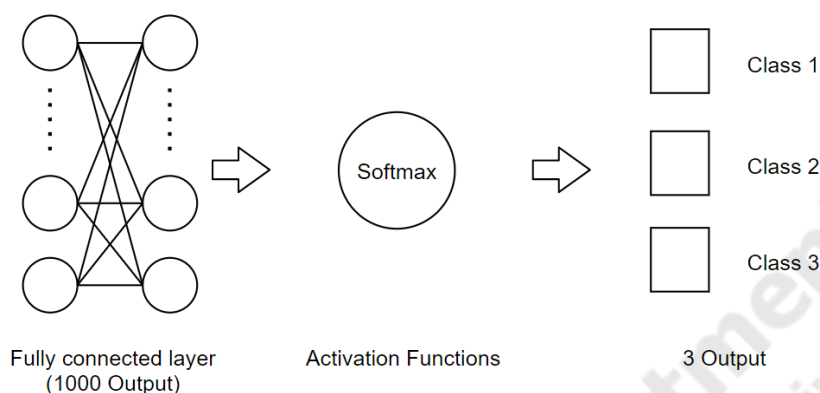
ภาพประกอบที่ 3.3.12 ภาพรวมของการ Flatten



ภาพประกอบที่ 3.3.13 ผลลัพธ์การเปลี่ยนโครงสร้างชุดข้อมูล

เมื่อทำการแฝ่ผลลัพธ์ด้วยฟังก์ชัน Flatten ในขั้นตอนต่อไปจะเป็นการนำผลลัพธ์ทั้งหมดเข้าไปทำงานในขั้นตอน Full connection เป็นขั้นตอนของโครงข่ายประสาทเทียม (Artificial Neural Network) ที่เป็นการรับ Input แบบแนวตั้ง

3.3.5 ปรับ Input ให้เหลือเท่ากับ Output (Full connection)



ภาพประกอบที่ 3.3.14 ภาพรวมของการ Full connection

เมื่อผ่านขั้นตอน Full connection จนเหลือ 1,000 ความเป็นไปได้ของ Output สุดท้ายจะต้องนำค่าที่ได้ทั้งหมดเข้าฟังก์ชัน Activation Functions แบบ Softmax ก่อนแล้วจะได้คำตอบ Output จริง ๆ ตัวอย่างการคำนวณ Softmax แสดงตัวอย่างด้วยชุดข้อมูลที่กำหนดให้ต่อไปนี้

$$\text{Full connection} = [-1, 0, 3]$$

แสดงวิธีการคำนวณด้วยตำแหน่งที่ 1 ดังนี้

$$S(-1) = \frac{e^{-1}}{e^{-1} + e^0 + e^3}$$

$$S(-1) = \frac{0.367}{0.367 + 1 + 20.08}$$

$$S(-1) = \frac{0.367}{21.44} \quad \text{หรือ} \quad S(-1) = 0.017$$


เมื่อคำนวณครบทุกค่าผลลัพธ์จะได้ตั้งแต่ 0 ถึง 1 ถ้าทั้งหมดรวมกันแล้วจะเท่ากับ 1 เสมอ

ตารางที่ 3.1 การคำนวณ Softmax

x	e^{-1}	ความน่าจะเป็น
-1	0.367	0.01714782554552
0	1	0.046612622577974
3	20.08	0.93623955187651
รวม		1

3.4 การตรวจจับวัตถุด้วย Faster R-CNN

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

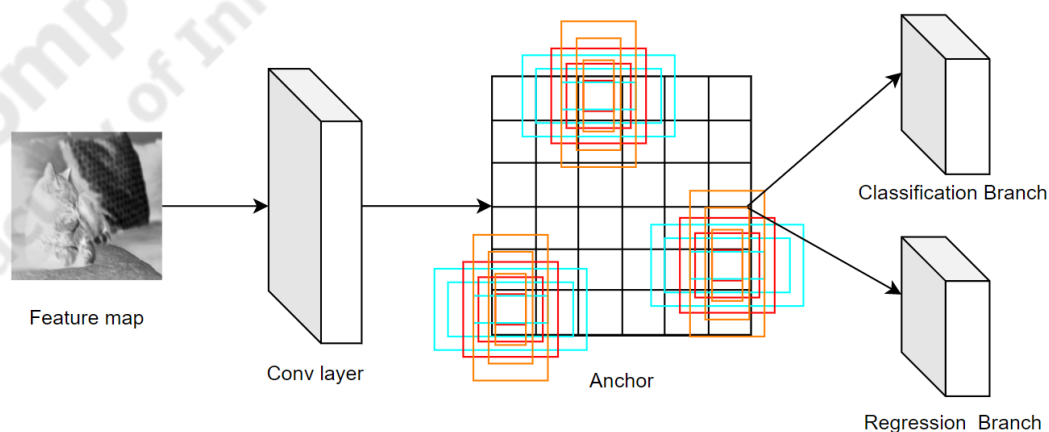


ภาพประกอบที่ 3.4.1 กระบวนการการทำงานของ Faster R-CNN

(ที่มา : www.mdpi.com/2072-4292/11/9/1117)

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

3.4.1 Region proposal network (RPN)




ภาพประกอบที่ 3.4.2 Region Proposal Network

(1) ขั้นตอนที่หนึ่ง

นำภาพที่ผ่านเข้ามาจะทำการ Convolutional Layer อีกครั้ง แล้วจะได้ Feature Map ที่เล็กลงไปอีก

(2) ขั้นตอนที่สอง

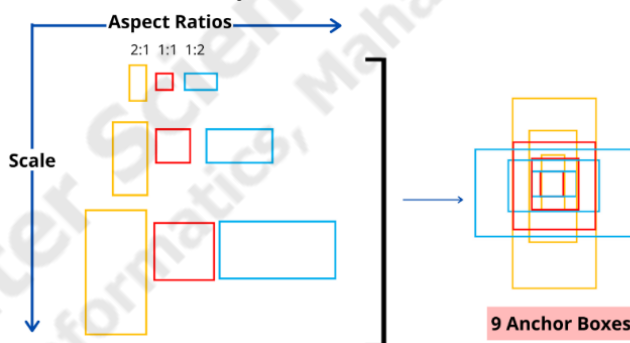
วางจุดเล็ก ๆ ให้ทั่วทั้งภาพเพื่อให้ขั้นตอนต่อไปวาง Anchor Boxes ได้ทั่วทั้งจุด



ภาพประกอบที่ 3.4.3 จุดบอกตำแหน่ง

(3) ขั้นตอนที่สาม

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




ภาพประกอบที่ 3.4.4 Anchor Boxes

(ที่มา : appliedsingularity.com/2021/06/08/object-detection-part-5-faster-r-cnn)

(4) ขั้นตอนที่สี่

ตอนนี้มีกล่อง Anchor Boxes ทั้ง 9 กล่องอยู่ในทุก ๆ ตำแหน่งทั่วทั้งภาพ Feature Map แล้ว ซึ่งในแต่ละตำแหน่งอาจจะเป็นสิ่งของก็ได้ หรืออาจจะเป็นแค่พื้นหลังก็ได้ สำหรับ Region Proposal Network (RPN) จะเรียนรู้ที่จะเลือกตำแหน่งใด ๆ ที่คาดว่าจะน่าจะเป็นสิ่งของจากการเรียนรู้ในขั้นตอนถัดไป



ภาพประกอบที่ 3.4.5 Anchor ที่กระจายตาม Feature Map

(ที่มา : dongjk.github.io/code/object+detection/keras/2018/05/21/Faster_R-CNN_step_by_step,_Part_I.html)

(5) ขั้นตอนที่ทำ

Region Proposal Network จะเรียนรู้และปรับเปลี่ยนด้วย Bounding Box Regression และ Bounding Box Classification

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) ออกมาแล้วนำมาค่ามาเทียบกับผลเฉลย (Ground Truth) เพื่อปรับค่า Anchor Boxes ให้มีการวางตำแหน่งให้ดีขึ้นกว่าเดิม




ภาพประกอบที่ 3.4.6 ตัวอย่างผลลัพธ์ของ RPN

(ที่มา : www.koen.me/research/selectivesearch)

3.4.2 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

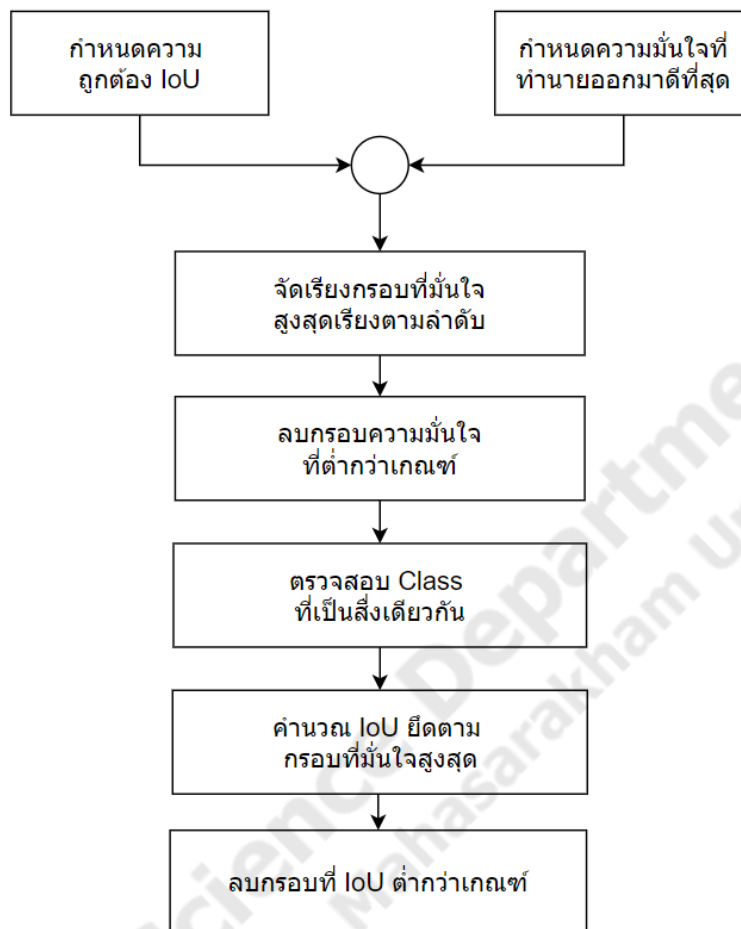


$$\text{IoU} = \frac{\text{พื้นที่ซ้อนทับกัน (A} \cap \text{B)}}{\text{พื้นที่ทั้งหมด (A} \cup \text{B)}}$$

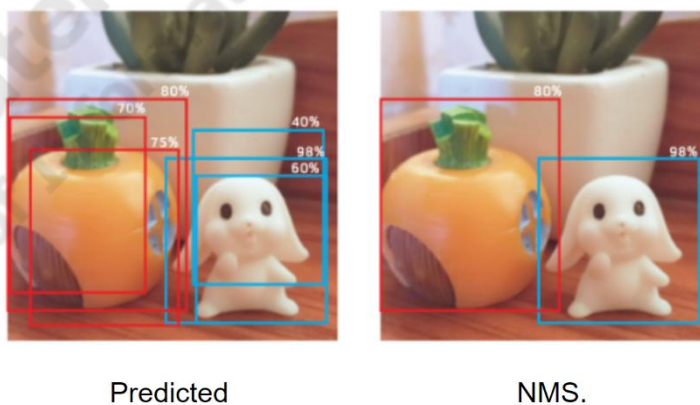
ภาพประกอบที่ 3.4.7 การคำนวณหาค่า Intersection over Union

3.4.3 Non-max suppression (NMS)

เทคนิคที่ใช้เป็นหลักในการคัดเลือกกรอบวัตถุที่มีการทับซ้อนกันและอยู่ในตำแหน่งที่ใกล้เคียงกัน โดยจะยึดตามกรอบที่ทำนายออกมามีความมั่นใจสูงสุด แสดงขั้นตอนการทำงานดังนี้




ภาพประกอบที่ 3.4.8 ขั้นตอน Non-Max Suppression



ภาพประกอบที่ 3.4.9 ผลลัพธ์ Non-Max Suppression


3.4.4 Region of Interest Pooling (ROI)



ภาพประกอบที่ 3.4.10 การรวม Feature Map และ RPN

(ที่มา : deepsense.ai/region-of-interest-pooling-explained)

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



ภาพประกอบที่ 3.4.11 การทำงาน Region of Interest Pooling

(ที่มา : deepsense.ai/region-of-interest-pooling-explained)

(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 ที่ทำนายมาให้อยู่แล้ววางทับกับภาพ 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 กับกรอบการทำนาย (Predicted Box) ทั้งหมดจนครบทุกกรอบที่ได้ผลลัพธ์จาก Region Proposal Network (RPN)


เมื่อทำงานครบทุกขั้นตอนก็จะมีทั้งภาพและกรอบที่คัดเลือกมาแล้วนำเข้าสู่ขั้นตอนของ Full Connected โดยขั้นตอนนี้จะมีการแบ่งข้อมูลที่ได้จาก ROI Pooling ออกเป็นสองส่วนและทำงานพร้อม ๆ กัน

B-box Regressor ทำหน้าที่ในการเรียนรู้และปรับค่าที่ผิดพลาดด้วยผลเฉลย (Ground Truth) ในตำแหน่งที่แท้จริงในรูปภาพที่เป็น Input ด้วยกรอบที่ส่งมาจาก ROI Pooling




ภาพประกอบที่ 3.4.12 ตัวอย่าง Input ของ B-box Regressor

Softmax ทำหน้าที่เลือกคำตอบที่มีอยู่ใน Output และทำนายผลนั้นออกมาจาก Feature Map ที่ส่งมาจาก ROI Pooling



ภาพประกอบที่ 3.4.13 ตัวอย่าง Input ของ Softmax

เมื่อดูภาพรวมของการทำงานของ ROI Pooling จนได้ผลลัพธ์สุดท้ายของการตรวจจับวัตถุแล้ว นำผลลัพธ์มาวางกับภาพจริง แสดงภาพโดยรวมดังต่อไปนี้



ภาพประกอบที่ 3.4.14 ผลลัพธ์สุดท้ายที่ได้จาก ROI Pooling

3.5 ระยะเวลาการรวบรวมข้อมูล (Data Preparation)

ในการเก็บข้อมูลในการวิจัยนี้ ได้ทำการเก็บข้อมูลจากเว็บไซต์ต่าง ๆ จาก Google Search, Google Maps และ Kaggle และยังมีชุดข้อมูลที่มีการแจกให้ใช้งานดังนี้




Annotated Potholes Image Dataset ข้อมูลโดย Atikur Rahman Chitholian จากเว็บ Kaggle เป็นชุดข้อมูลหลุม พร้อมกับ Ground Truth จำนวน 665 ภาพ

PID-Pavement-Image-Dataset ข้อมูลโดย hanshenChen จาก Github เป็นชุดข้อมูลที่ใช้ Google API ดึงภาพออกมาจาก Google maps มีชนิดถนนแตกพร้อมกับ Ground Truth จำนวน 7,237 ภาพ

Road Pothole Images for Pothole detection ข้อมูลโดย Sovit Ranjan Rath จาก Kaggle เป็นข้อมูลที่ใช้กล้องติดรถยนต์เก็บภาพที่เป็นหลุมและทำ Ground Truth เก็บเป็นไฟล์ CSV มีข้อมูลหลุมจำนวน 1,119 ภาพ

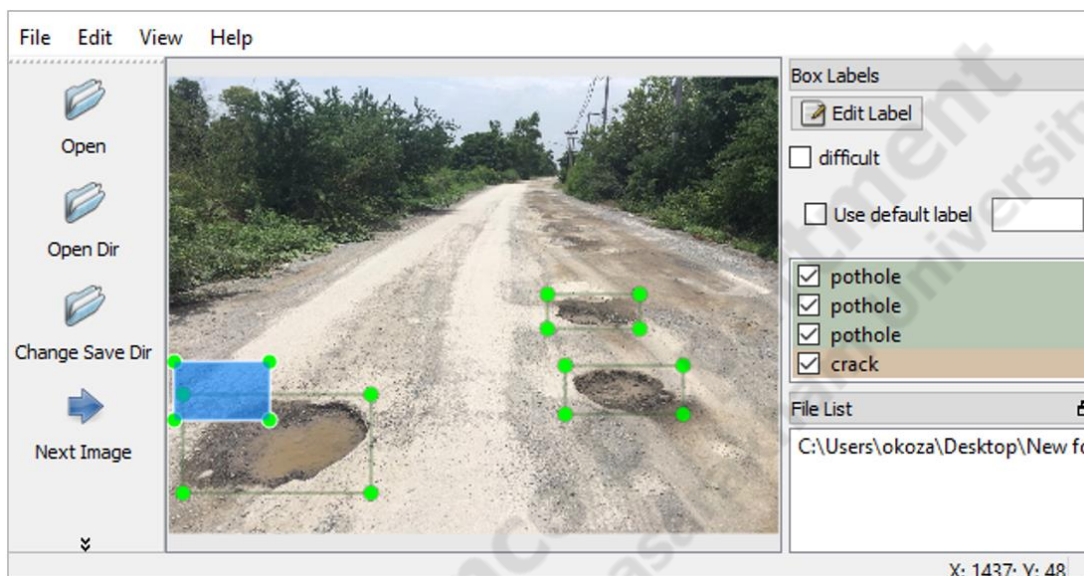
โดยข้อมูลทั้งหมดที่เก็บมาได้มีประเภทของหลุม 3 ชนิด หลุม, ถนนแตก, ถนนซ่อมปะ แบ่งเป็นจำนวนชนิดละ 1,990, 8,048, 1,088 ตามลำดับ รวมทั้งสิ้น 11,126 ภาพ

ตารางที่ 3.2 แสดงคลาสของชุดข้อมูลถนนเสียหายจำนวน 3 ชนิด

รหัส	ภาพ	ชนิด	จำนวนภาพ
1		หลุม	1,990
2		ถนนแตก	8,048
3		ถนนซ่อมปะ	1,088
รวม			11,126

3.5.1 คำอธิบายประกอบข้อมูล (Data annotations)

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



ภาพประกอบที่ 3.5.1 ตัวอย่างการกำหนดค่าความจริง (Ground Truth)

โดยในการกำหนดค่าความจริงแต่ละภาพอาจจะมีรายการถนนเสียหายรวมกันมากกว่า 1 ชนิด ข้อมูลจะถูกบันทึกลงในไฟล์ข้อความ (.txt) ที่เป็นชื่อเดียวกันกับไฟล์ภาพ และทั้งหมดจะถูกรวมอยู่ในไฟล์ annotate.txt สำหรับการอ่านข้อมูลความจริงของวัตถุ (Ground Truth) และตำแหน่งรูปภาพ เพื่อเป็นเส้นทางให้การการเรียนรู้ (Training) สามารถอ่านข้อมูลได้ง่าย ๆ สามารถแสดงวิธีการระบุชื่อไฟล์และชนิดได้ดังตารางดังนี้





ตารางที่ 3.3 การระบุตำแหน่งค่าความจริงและตำแหน่งภาพ

รูปที่	ตำแหน่งไฟล์รูป	X1	Y1	X2	Y2	ชื่อชนิด
1	images/0.png	1217	663	2103	1196	Pothole
2	images/0.png	1802	247	2209	410	Crack
3	images/1.jpg	444	223	960	560	Repair
...
11,126	images/11126.jpg	12	11	258	143	Crack

3.5.2 Data Augmentation

การขยายชุดข้อมูลภาพให้มีความหลากหลายจะช่วยให้มีการสร้างข้อมูลเพิ่มจากเดิมได้มากกว่าสองเท่า และช่วยให้โมเดลได้เรียนรู้ข้อมูลหลาย ๆ แบบ โดยการทำให้ Data Augmentation ได้ใช้ Source code โปรแกรม Bounding Box Augmentation ที่สร้างโดย mukopikmin และ tonybjorkman จาก Github สามารถสุ่มสร้างภาพใหม่โดยมีการคำนวณ Ground Truth ให้ใหม่โดยอัตโนมัติ โดยมีฟังก์ชันให้เลือกในการสุ่มสร้างภาพใหม่มากมายเช่น เปลี่ยนสี ใส่ข้อมูลรบกวน บิดภาพ เบลอ เป็นต้น แต่งานวิจัยเลือกที่จะใช้วิธีตามตารางดังนี้

ตารางที่ 3.4 Data Augmentation

Affine	Blur	Arithmetic	Color
			


ขั้นตอนสร้างภาพใหม่จะสร้างเฉพาะข้อมูลที่มีน้อยมากเกินไปเช่น หลุมและถนนซ่อมปะ ที่มีข้อมูลน้อยกว่าถนนแตก จึงสร้างภาพใหม่แค่หลุมและถนนซ่อมปะ กำหนดจำนวนดังนี้

หลุม 1 ภาพ กำหนดให้สร้างภาพใหม่เป็น 3 ภาพ ทำให้ได้ข้อมูลเพิ่มเป็น 5,970 ภาพ

ถนนซ่อมปะ 1 ภาพ กำหนดให้สร้างภาพใหม่เป็น 7 ภาพ ทำให้ได้ข้อมูลเพิ่มเป็น 7,616 ภาพ

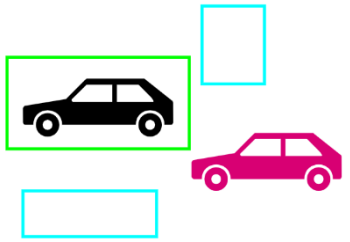
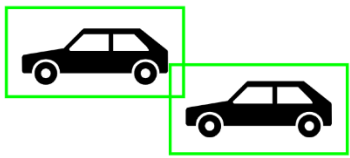
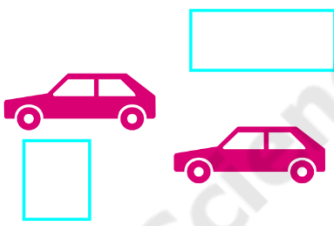
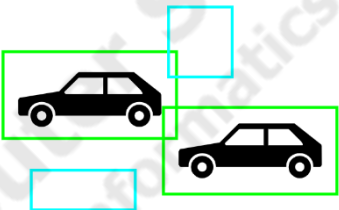

3.6 การประเมินผล (Evaluation)

ตัวอย่างการคำนวณหา Precision และ Recall ของการตรวจจับวัตถุกำหนดค่าความจริง (Ground Truth) ดังรูปต่อไปนี้



ภาพประกอบที่ 3.6.1 ตัวอย่างการกำหนดผลเฉลย

ตารางที่ 3.5 ตัวอย่างการคำนวณ Precision และ Recall


ลำดับ	ตัวอย่างการ Predict	Precision $\frac{TP}{(TP + FP)}$	Recall $\frac{TP}{(TP + FN)}$
A		$\frac{1}{1 + 2} = 0.33$	$\frac{1}{1 + 1} = 0.5$
B		$\frac{2}{2 + 0} = 1$	$\frac{2}{2 + 0} = 1$
C		$\frac{0}{0 + 2} = 0$	$\frac{0}{0 + 2} = 0$
D		$\frac{1}{1 + 2} = 0.33$	$\frac{1}{1 + 1} = 0.5$
E		$\frac{1}{1 + 0} = 1$	$\frac{1}{1 + 1} = 0.5$

การหาค่า Precision และ Recall คำนวณด้วยตารางที่ละขั้นตอนตามจำนวนที่ทำนายออกมา
เรียงความมั่นใจ (Confident) จากมากไปหาน้อย ในระหว่างนั้นก็มีการนับค่าที่ทำนายถูกและผิดและมี
การหาค่า Precision และ Recall ไปพร้อม ๆ กัน

ตารางที่ 3.6 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

เมื่อนำค่า Precision และ Recall ไปสร้างเป็นกราฟจะได้ตามรูปภาพดังนี้



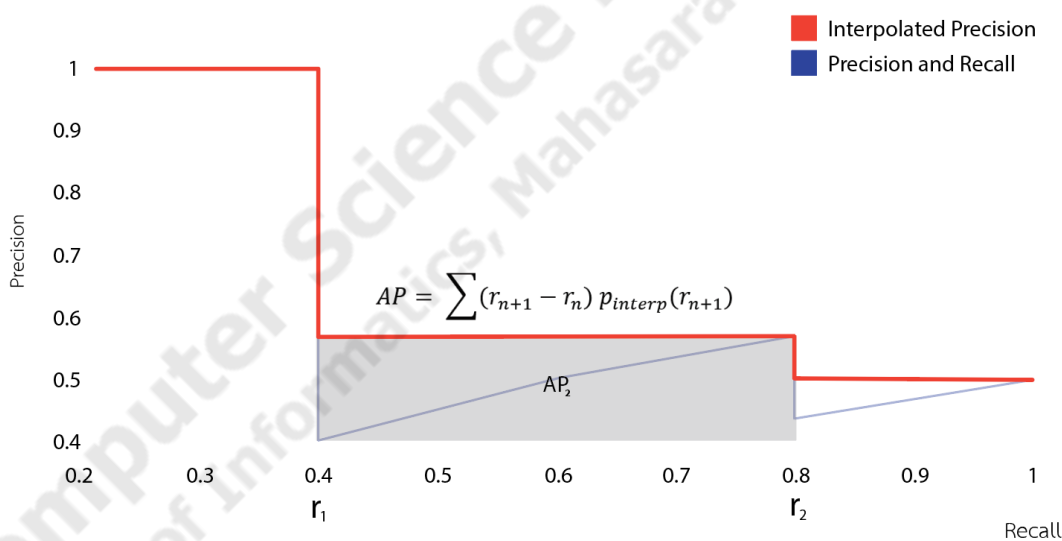
ภาพประกอบที่ 3.6.2 ตารางกราฟ Precision และ Recall

จัดเรียกค่า Precision ใหม่ด้วยฟังก์ชัน Interpolated Precision



ภาพประกอบที่ 3.6.3 Interpolated Precision

เลือกเฉพาะเส้น Precision ที่มีค่าเท่ากันและแบ่งกราฟออกเป็นส่วน ๆ เพื่อหาพื้นที่ใต้กราฟ (AUC) ทำได้ดังนี้




ภาพประกอบที่ 3.6.4 วิธีการคำนวณหาพื้นที่ใต้กราฟ

แสดงวิธีการคำนวณตั้งแต่ค่า r_1 ถึง r_2 และ Interpolated Precision ตำแหน่งที่ r_1 ถึง r_2 มีค่าเป็น 0.57 ได้ดังนี้

$$AP_2 = (0.8 - 0.4) * 0.57$$

$$A_2 = 0.228$$

เมื่อทำการคำนวณทุกค่าแล้วจะได้พื้นที่ใต้กราฟ (AUC) ทุก ๆ ส่วน

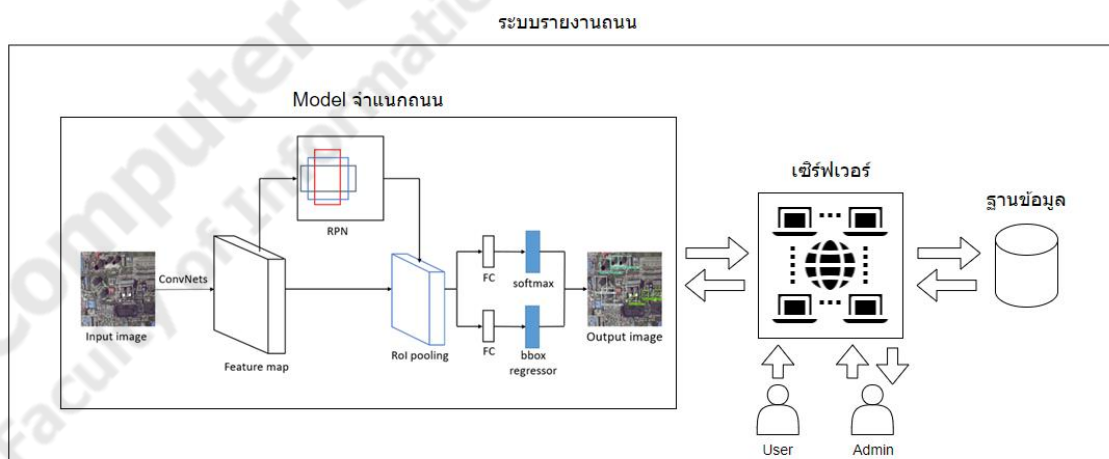


ภาพประกอบที่ 3.6.5 ผลลัพธ์การคำนวณหาพื้นที่ใต้กราฟ

เมื่อนำค่า A_1 , A_2 , A_3 มารวมกันคำตอบจะเป็นค่าความแม่นยำเฉลี่ย (Average Precision) ดังนั้น $AP = 0.5664$ หรือ $AP = 56\%$

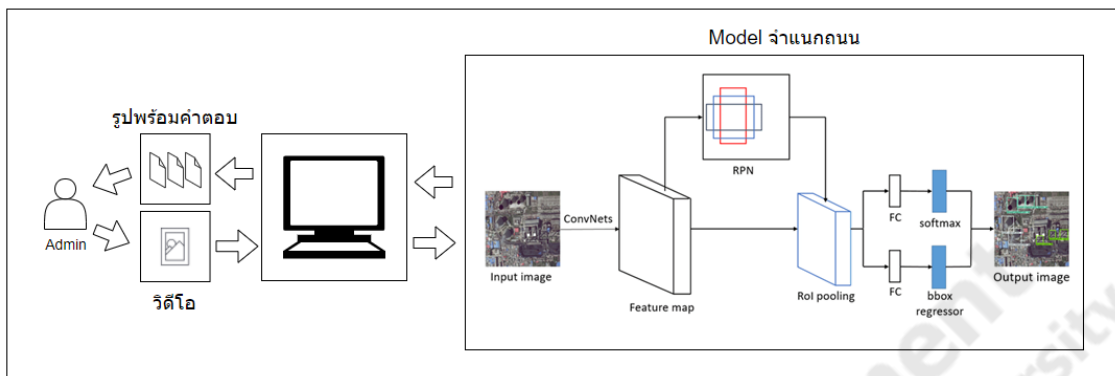
3.7 การนำโมเดลไปใช้งาน

การนำไปใช้จะนำโมเดลใส่ในโปรแกรมจำแนกถนนสำหรับโปรแกรมคอมพิวเตอร์ และนำไปใช้ในเซิร์ฟเวอร์ระบบรายงานถนนสำหรับผู้ใช้ทั่วไป



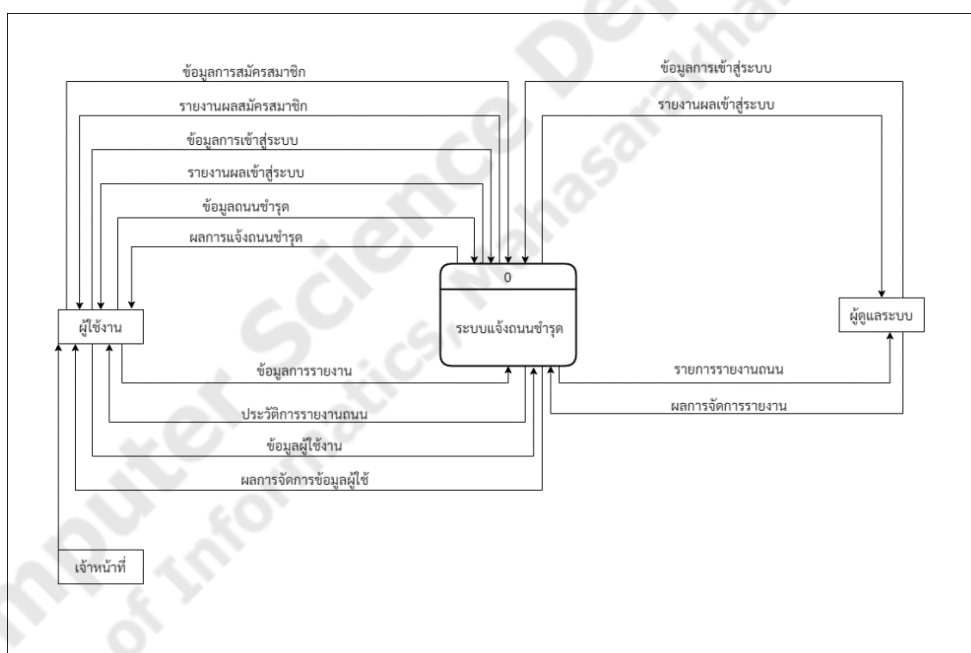
ภาพประกอบที่ 3.7.1 โมเดลในระบบรายงานถนน

โปรแกรมจำแนกถนน

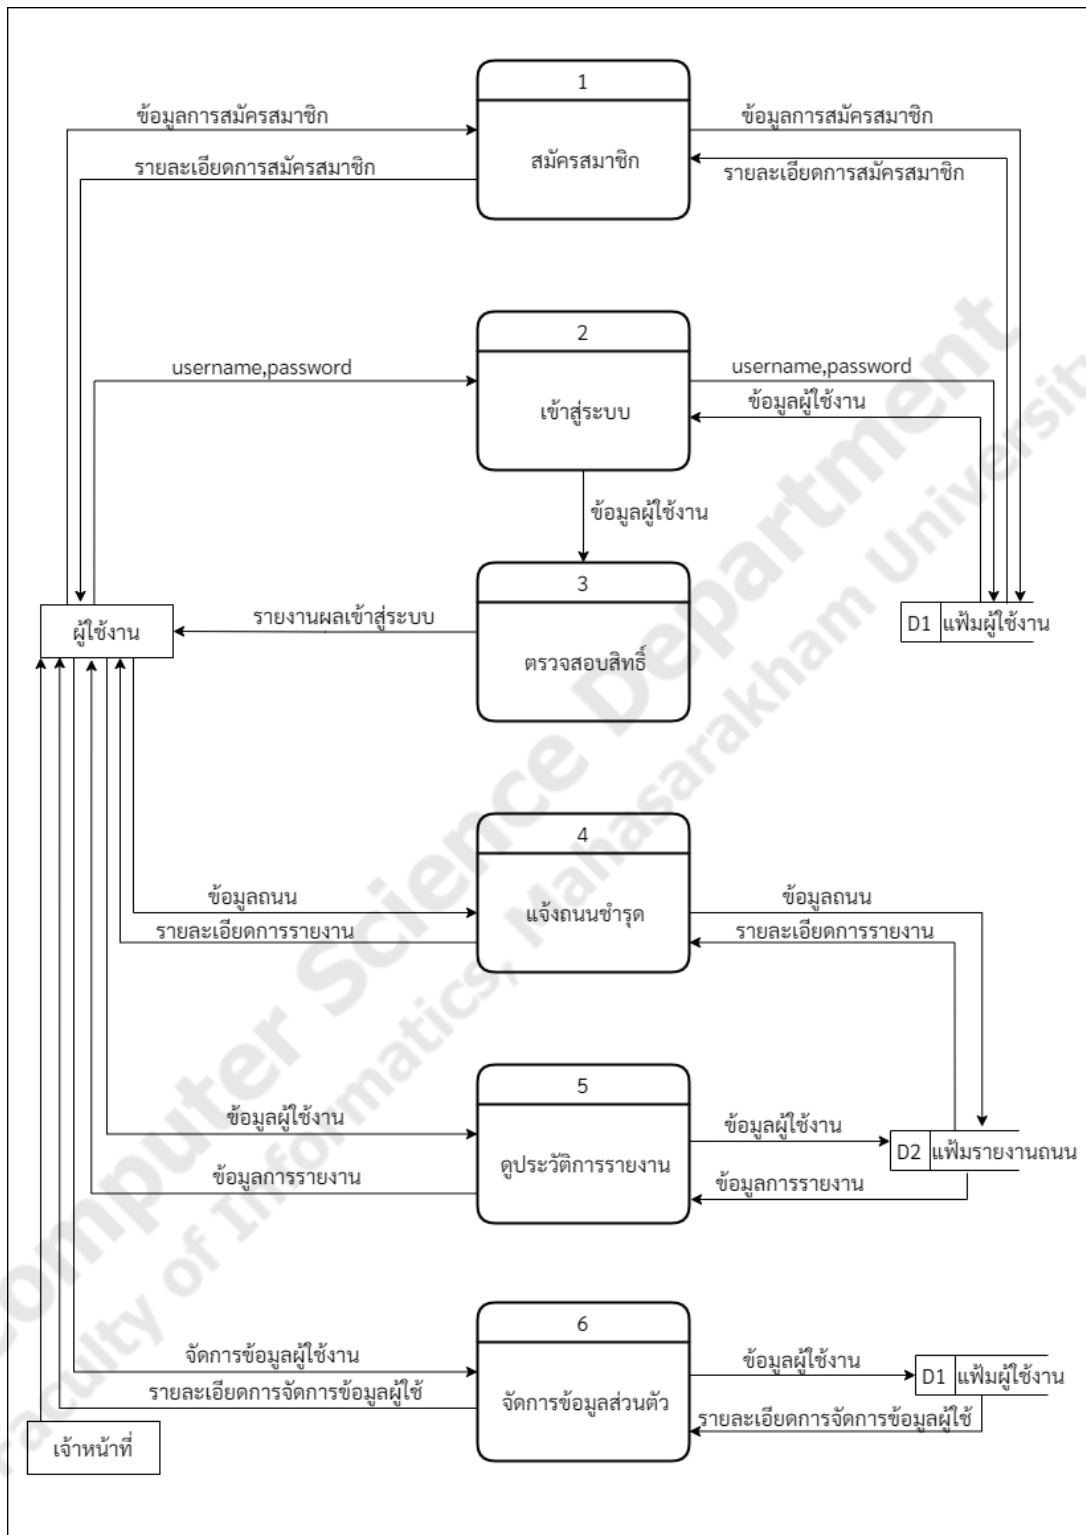


ภาพประกอบที่ 3.7.2 โมเดลในโปรแกรมจำแนกถนน

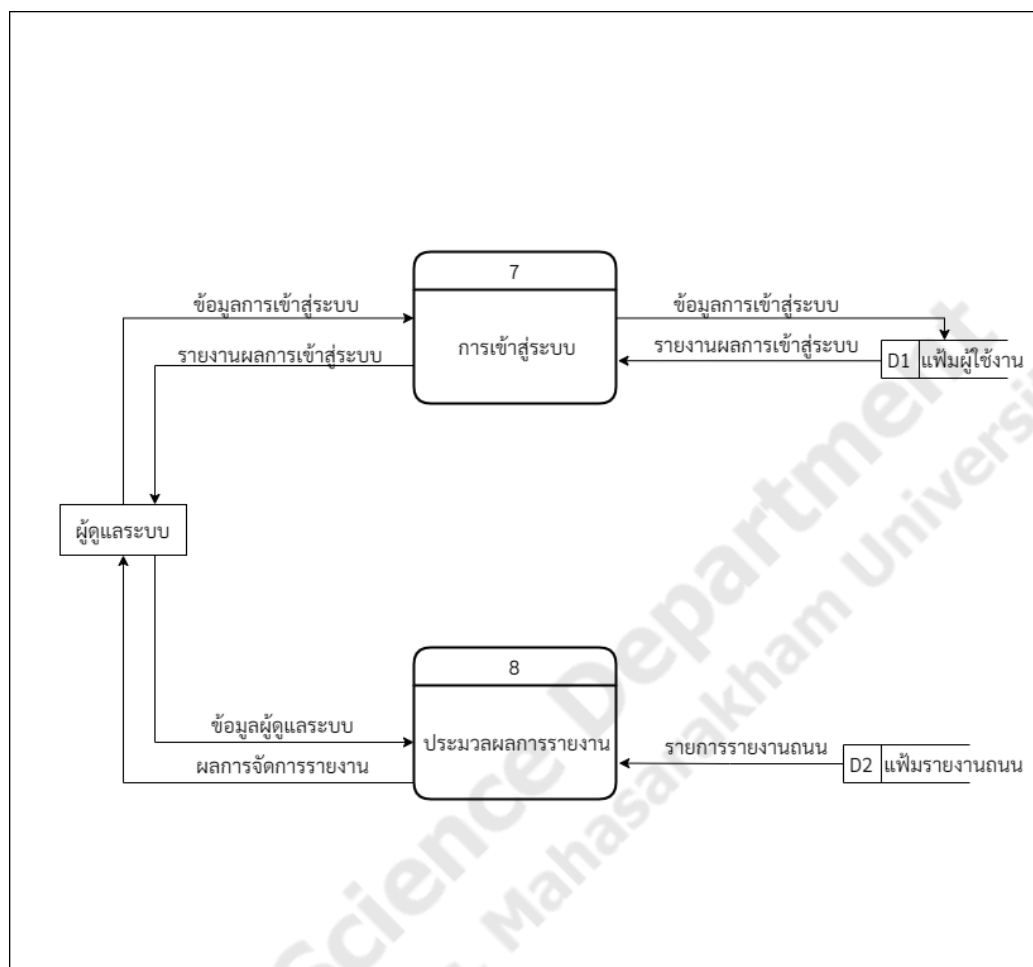
3.8 ผลการออกแบบและพัฒนาระบบ



ภาพประกอบที่ 3.8.1 Context diagram



ภาพประกอบที่ 3.8.2 แผนภาพกระแสข้อมูล ระดับที่ 1 (Data Flow Diagram Level 1)



ภาพประกอบที่ 3.8.2 แผนภาพกระแสข้อมูล ระดับที่ 1 (Data Flow Diagram Level 1) (ต่อ)

3.8.1 External Entity Description

ตารางที่ 3.7 ตารางแสดง External Entity Description

Name	Description	Input Data Flow	Output Data Flow
ผู้ใช้งาน,เจ้าหน้าที่	ผู้ที่เข้ามาใช้งานระบบ แจ้งถนนชำรุด สามารถ สมัครสมาชิกและล็อก อินเพื่อเข้าใช้งานใน ระบบได้ แล้วจากนั้น สามารถทำการถ่ายรูป แล้วส่งรูปภาพไป ประมวลผลแจ้ง รายงานถนนชำรุดได้ แล้วจากนั้นสามารถดู ประวัติผลการรายงาน ที่รายงานไปแล้วได้ และสามารถแก้ไขโปร ไฟล์ของตัวเองได้	-ข้อมูลการสมัคร สมาชิก -ข้อมูลการเข้าสู่ระบบ -ข้อมูลถนนชำรุด -ข้อมูลการรายงาน ถนน -ข้อมูลผู้ใช้งาน	-รายงานผลสมัคร สมาชิก -รายงานผลเข้าสู่ ระบบ -ผลการแจ้งถนน ชำรุด -ประวัติการรายงาน ถนน -ผลการจัดการข้อมูล
ผู้ดูแลระบบ	ผู้ดูแลระบบการแจ้ง ถนนชำรุด สามารถ สมัครสมาชิกเพื่อล็อก อินเข้าสู่ระบบได้ แล้ว จากนั้นก็ยังมีหน้าที่ใน การดำเนินการ ตรวจสอบการรายงาน จากผู้ใช้งานที่แจ้ง รายงานถนนชำรุดเสีย หาเข้ามาได้	-ข้อมูลการเข้าสู่ระบบ -รายการรายงานถนน	-ผลการเข้าสู่ระบบ -ผลการจัดการ รายงาน

3.8.2 Data Store Description

ตารางที่ 3.8 Data Store Description

ID	Name	Description	Data Structure
D1	เพิ่มผู้ใช้งาน	ฐานข้อมูลสำหรับเก็บข้อมูลผู้ใช้งาน	Id + username + password
D2	เพิ่มรายงานถนน	ฐานข้อมูลสำหรับเก็บข้อมูลการแจ้ง รายงานถนน	Id + วันที่ + ละติจูด + ลองจิจูด + ประเภท ของถนน + รูปภาพ ถนน + รายละเอียด + ผลการทำนาย + state

3.8.3 Data Structure Description

ตารางที่ 3.9 Data Structure Description

Name	Description	Source	Destination	Data Structure
ข้อมูลการ สมัครสมาชิก	ข้อมูลที่ใช้ในการ สมัครสมาชิก	สมาชิก	process 1 ตรวจสอบการ สมัครสมาชิก	username + password
		เจ้าหน้าที่	process 1 ตรวจสอบการ สมัครสมาชิก	
		process 1 ตรวจสอบการ สมัครสมาชิก	D1 เพิ่มข้อมูล ผู้ใช้งาน	
รายละเอียด การสมัคร สมาชิก	ผลการแจ้งสมัคร สมาชิกว่าสำเร็จ หรือไม่ หากไม่ก็ จะแจ้งเตือนไปยัง ผู้ใช้งาน ให้กรอกให้ ถูกต้อง	process 1 ตรวจสอบการ สมัครสมาชิก	สมาชิก	username + password
		process 1 ตรวจสอบการ สมัครสมาชิก	เจ้าหน้าที่	

ตารางที่ 3.9 Data Structure Description (ต่อ)

Name	Description	Source	Destination	Data Structure
การเข้าสู่ระบบ	ข้อมูลที่ใช้ในการเข้าสู่ระบบ	สมาชิก	Process 2 ตรวจสอบการเข้าสู่ระบบ	username + password
การเข้าสู่ระบบ รายงานผล การเข้าสู่ระบบ	ข้อมูลที่ใช้ในการเข้าสู่ระบบ แสดงผลการเข้าสู่ระบบ สำเร็จหรือไม่ ถ้าไม่ก็ให้กรอกข้อมูลให้ถูกต้อง	เจ้าหน้าที่ ผู้ดูแลระบบ	Process 2 ตรวจสอบการเข้าสู่ระบบ Process 2 ตรวจสอบการเข้าสู่ระบบ	username + password username + password
		Process 2 ตรวจสอบการเข้าสู่ระบบ	D1 เพิ่มข้อมูล ผู้ใช้งาน	
		Process 3 การตรวจสอบสิทธิ์ผู้ใช้งาน	Process 2 ตรวจสอบการเข้าสู่ระบบ	
		Process 3 การตรวจสอบสิทธิ์ผู้ใช้งาน	สมาชิก	
รายงานผล การเข้าสู่ระบบ ข้อมูลถนน	แสดงผลการเข้าสู่ระบบ ว่าเข้าสู่ระบบสำเร็จหรือไม่ ถ้าไม่ก็ให้กรอกข้อมูลให้ถูกต้อง กรอกรายละเอียดเกี่ยวกับการแจ้งรายงานถนน	Process 3 การตรวจสอบสิทธิ์ผู้ใช้งาน Process 3 การตรวจสอบสิทธิ์ผู้ใช้งาน สมาชิก	เจ้าหน้าที่ ผู้ดูแลระบบ Process 4 แจ้งถนนชำรุด	username + password วันที่และเวลา + ละติจูด + ลองจิจูด + ประเภทของหลุม + รูปภาพรายงาน + รายละเอียดของหลุม + state

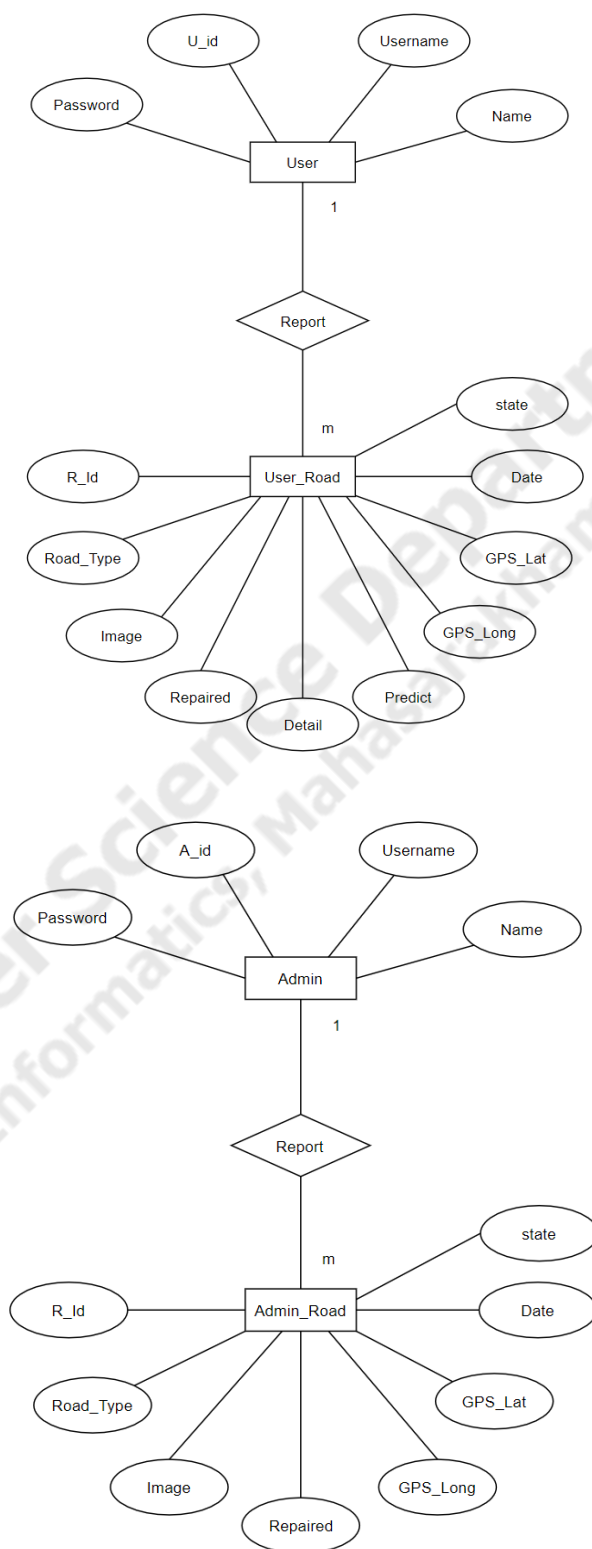
ตารางที่ 3.9 Data Structure Description (ต่อ)

Name	Description	Source	Destination	Data Structure
ข้อมูลถนน	กรอกรายละเอียด เกี่ยวกับการแจ้ง รายงานถนน	เจ้าหน้าที่	Process 4 แจ้ง ถนนชำรุด	วันที่และเวลา + ละติจูด + ลองติ จูด + ประเภท ของหลุม + รูปภาพรายงาน + รายละเอียดของ หลุม + state
		process 4 แจ้ง ถนนชำรุด	D2 เพิ่มรายงาน ถนน	
รายละเอียด การรายงาน	แจ้งและแสดงผลการ รายงานถนนชำรุด	process 4 แจ้ง ถนนชำรุด	สมาชิก	วันที่และเวลา + ละติจูด + ลองติ จูด + ประเภท ของหลุม + รูปภาพรายงาน + รายละเอียดของ หลุม + state
		process 4 แจ้ง ถนนชำรุด	เจ้าหน้าที่	
ประวัติการ รายงาน	ดูประวัติการรายงาน ถนนชำรุด	สมาชิก	process 5 ดู ประวัติการ รายงานถนน	Username + id + password
		เจ้าหน้าที่	process 5 ดู ประวัติการ รายงานถนน	
		process 5 ดู ประวัติการ รายงานถนน	D2 เพิ่มรายงาน ถนน	
ข้อมูลการ รายงาน	แสดงผลประวัติการ รายงาน	process 5 ดู ประวัติการ รายงานถนน	สมาชิก	Username + id + password
			เจ้าหน้าที่	

ตารางที่ 3.9 Data Structure Description (ต่อ)

Name	Description	Source	Destination	Data Structure
จัดการข้อมูล ผู้ใช้งาน	การจัดการข้อมูลของ ผู้ใช้งานเช่น เพิ่ม ลบ แก้ไข ชื่อนามสกุล หรือข้อมูลของผู้ใช้ ระบบ	สมาชิก	Process 6 จัดการข้อมูล ส่วนตัวผู้ใช้งาน	ชื่อ + นามสกุล + ชื่อเล่น + ที่อยู่ + เบอร์โทร + อีเมล
		สมาชิก	Process 6 จัดการข้อมูล ส่วนตัวผู้ใช้งาน	
		Process 6 จัดการข้อมูล ส่วนตัวผู้ใช้งาน	D1 เพิ่มข้อมูล ผู้ใช้งาน	
รายละเอียด การจัดการ ข้อมูลผู้ใช้งาน	รายละเอียดแสดงผล การจัดการข้อมูลผู้ใช้ ว่าเปลี่ยนข้อมูล ส่วนตัวได้หรือไม่	Process 6 จัดการข้อมูล ส่วนตัวผู้ใช้งาน	สมาชิก	ชื่อ + นามสกุล + ชื่อเล่น + ที่อยู่ + เบอร์โทร + อีเมล
		Process 6 จัดการข้อมูล ส่วนตัวผู้ใช้งาน	สมาชิก	

3.9 ER diagram



ภาพประกอบที่ 3.9.1 ER diagram

3.9.1 รายละเอียดตารางข้อมูล (Data table Description)

ตารางที่ 3.10 ตารางแสดงข้อมูลสมาชิก (User)

Attribute Name	Type	Size	Description	Key type	References
username	varchar	30	ชื่อผู้ใช้งาน		Del01
password	varchar	200	รหัสผ่าน		Del01
user_id	int	11	ไอดีผู้ใช้งาน	primary key	8

ตารางที่ 3.11 ราคาแสดงข้อมูลการรายงานถนน (User_Road)

Attribute Name	Type	Size	Description	Key type	References
R_id	int	100	ไอดีถนน	primary key	10
date	datetime		วันที่		2021-03-07 00:56:50
gps_longitude	varchar	30	ลองติจูด		103.2501767
gps_latitude	varchar	30	ละติจูด		16.2456183
crack_type	int	11	ประเภทถนน		3
image	varchar	100	รูปภาพ		96716337051524330254392 857359970763214324083090 9
predict	int	11	ผลการทำนาย		0
state	int	11	ได้รับการตรวจสอบ		0
repaired	int	10	ได้รับการซ่อม		0
detail	varchar	500	รายละเอียด		มาซ่อมด้วย
user_id_fk	int	100	อ้างอิงไอดีผู้ใช้	foreign key	5

ตารางที่ 3.12 ตารางแสดงข้อมูลสมาชิก (Admin)

Attribute Name	Type	Size	Description	Key type	References
username	varchar	30	ชื่อผู้ใช้งาน		Admin01
password	varchar	200	รหัสผ่าน		Admin01
user_id	int	11	ไอดีผู้ใช้งาน	primary key	1

ตารางที่ 3.13 ราคาแสดงข้อมูลการรายงานถนน (Admin_Road)

Attribute Name	Type	Size	Description	Key type	References
R_id	int	100	ไอดีถนน	primary key	2
date	datetime		วันที่		2021-03-07 00:00:00
gps_longitude	varchar	30	ลองติจูด		103.2501744
gps_latitude	varchar	30	ละติจูด		16.2456150
crack_type	int	11	ประเภทถนน		2
image	varchar	100	รูปภาพ		96716337051524330254392 857359970763214354878454 2
state	int	11	ได้รับการตรวจสอบ		0
repaired	int	10	ได้รับการซ่อม		0
user_id_fk	int	100	อ้างอิงไอดีผู้ใช้	foreign key	1