

## บทที่ 4

### ผลการทดลอง

โครงการวิทยานิพนธ์ฉบับนี้นำเสนอการตรวจจับความเสียหายของถนนด้วยการเรียนรู้เชิงลึก โดยวัดความถูกต้องด้วยความแม่นยำเฉลี่ย (Average Precision) จาก Precision และ Recall ที่ได้จากชุดข้อมูลทดสอบ

#### 4.1 วิธีการทดลอง

##### 4.1.1 การเตรียมชุดข้อมูลก่อนการเรียนรู้

จากชุดข้อมูลที่ผ่านมาการ Data Augmentation ที่ทำการเพิ่มข้อมูลเพียงหลุมและถนนซ่อมปะเท่านั้นทำให้ได้ข้อมูลใหม่เพิ่มขึ้นตามตารางดังต่อไปนี้

ตารางที่ 4.1 ชุดข้อมูลจำนวนทั้งหมด

รหัส	ชนิด	จำนวนภาพ
1	หลุม	7,960
2	ถนนแตก	8,048
3	ถนนซ่อมปะ	8,704
รวม		24,712

ทำการแบ่งข้อมูลออกเพื่อใช้ตรวจสอบความถูกต้อง (Validation) ระหว่างเรียนรู้ (Train) และใช้ทดสอบ (Test) เพื่อวัดประสิทธิภาพแบ่งออกได้เป็นสามส่วนตามตารางดังต่อไปนี้

ตารางที่ 4.2 การแบ่งข้อมูล

จำนวนข้อมูลสำหรับเรียนรู้ (90%)		จำนวนข้อมูลสำหรับวัดประสิทธิภาพ (10%)		
22,241		2,471		
เรียนรู้ (90%)	ตรวจสอบ (10%)	หลุม	ถนนแตก	ถนนซ่อมปะ
20,016	2,225	824	824	823
ข้อมูลทั้งหมด 24,712 ภาพ				


## 4.1.2 ตั้งค่าการเรียนรู้ (Training setting)

ตารางที่ 4.3 การตั้งค่าการฝึกการเรียนรู้

Function	Description
Epoch กำหนดรอบการเรียนรู้	10
Train RPN ฝึกการเรียนรู้ โมเดล RPN	True
Train final classifier ฝึกการเรียนรู้ โมเดล VGG-16 ส่วนที่ทำการ คัดเลือกคำตอบ (Classification)	True
Train base NN ฝึกการเรียนรู้ โมเดล VGG-16 ส่วนที่หา คุณลักษณะเด่นของรูปภาพ (Feature Extraction)	True
Anchor box scales กำหนดขนาดของ Anchor box ทั้งสามขนาด	128, 256, 512
Anchor box ratios กำหนดสัดส่วนของ Anchor box ทั้งสามขนาด	[ 1 : 1 ], [ 0.7 : 1.4 ], [ 1.4 : 0.7 ]
Image size กำหนดขนาดภาพที่จะทำการฝึกทั้งหมด	600
Optimizer	Adam, Learning rate 0.00001
Augment สุ่มสร้างรูปภาพใหม่	False
Model training APIs ฟังก์ชันการฝึกการเรียนรู้ (Training)	train_on_batch

## 4.1.3 วิธีการนำภาพเข้าทดสอบ

การทดสอบนี้ใช้วิธีนำภาพพร้อมกับผลเฉลย (Ground Truth) เข้าทำการทดสอบในครั้งเดียว ซึ่งในหนึ่งภาพไม่ได้แปลว่ามีวัตถุเพียงอันเดียวโดยอาจจะมิได้หลายวัตถุก็ได้ แสดงภาพตัวอย่างกับชุดข้อมูลทดสอบเพียงหนึ่งภาพดังนี้



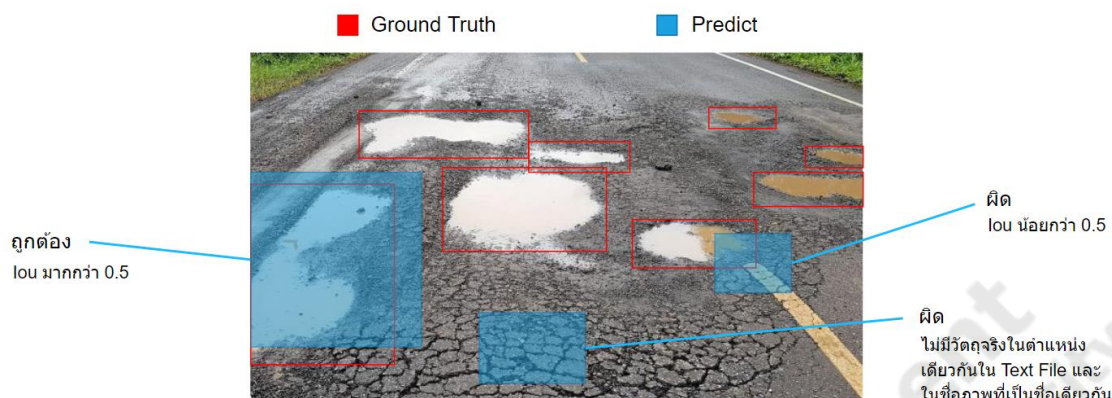
ภาพทดสอบที่ 1

Text File		
Filename	Class	Position
ภาพทดสอบที่ 1	หลุม	Position1
ภาพทดสอบที่ 1	หลุม	Position2
ภาพทดสอบที่ 1	หลุม	Position3
ภาพทดสอบที่ 1	หลุม	Position4
ภาพทดสอบที่ 1	หลุม	Position5
ภาพทดสอบที่ 1	หลุม	Position6
ภาพทดสอบที่ 1	หลุม	Position7
ภาพทดสอบที่ 1	หลุม	Position8
...	...	...
ภาพทดสอบที่ x	x	PositionX

Text File

#### ภาพประกอบที่ 4.1.1 วิธีการนำภาพเข้าทดสอบ

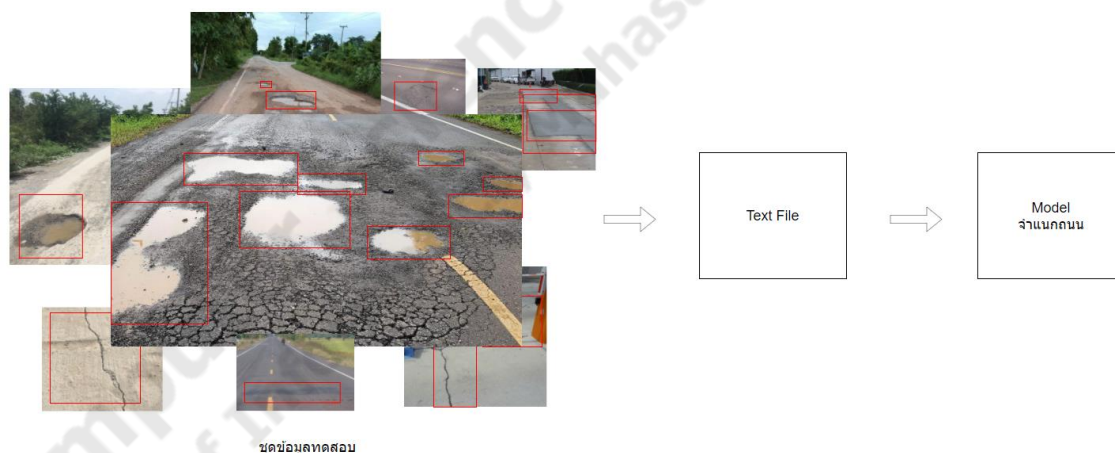
Text File เอาไว้เก็บค่าผลเฉลย (Ground Truth) ทั้งหมดเพื่อเอาไว้เทียบกับการทำนายในหนึ่งภาพ เมื่อการทำนายเกิดขึ้นในภาพทดสอบที่ 1 จะนำผลที่ทำนายมาตรวจสอบในข้อมูลที่เป็นผลเฉลย (Ground Truth) ที่อยู่ใน Text File และมีชื่อเดียวกัน โดยการตรวจจับสามารถทำนายออกมาแล้วได้รอบการทำนายมากกว่าหรือน้อยกว่าผลเฉลย (Ground Truth) ที่มีทั้งหมดในข้อมูลทดสอบ เพื่อเป็นการวัดว่าโมเดลจะทำนายผลที่ไม่มีอยู่จริงและมีอยู่จริงเป็นเปอร์เซ็นต์ทั้งหมดเท่าไร แสดงตัวอย่างการทำนายและวัดผลดังต่อไปนี้



ภาพประกอบที่ 4.1.2 ตัวอย่างการทำนายและวัดผล

เมื่อการวัดผลทำนายออกมาครบทุกภาพที่มีอยู่ในข้อมูลชุดทดสอบแล้วจะนำค่าทั้งหมดค่าความแม่นยำ (Precision) และ ค่าความระลึก (Recall) จากนั้นจะหาความแม่นยำเฉลี่ย (Average Precision) ในขั้นตอนสุดท้าย

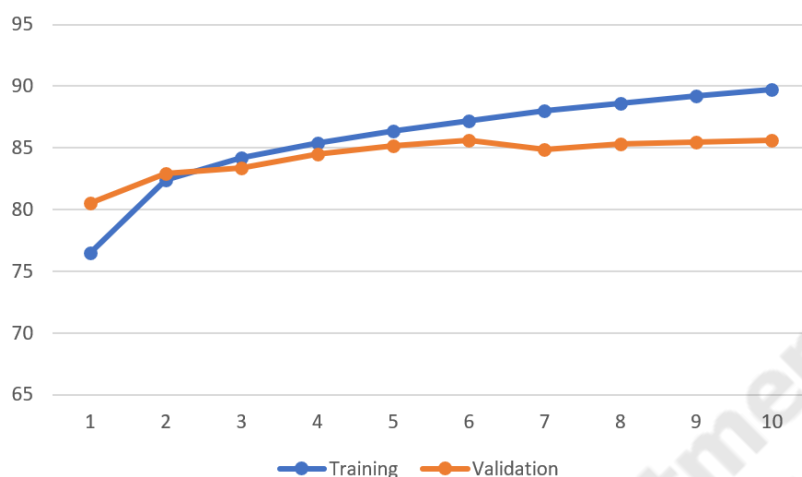
ในชุดข้อมูลทดสอบมีจำนวน 2,471 ภาพจะแสดงตัวอย่างภาพรวมของการนำภาพเข้าทดสอบดังนี้



ภาพประกอบที่ 4.1.3 ภาพรวมของการทดสอบ

## 4.2 ผลการทดลอง

การฝึกโมเดล 10 รอบ ด้วยข้อมูลสำหรับเรียนรู้ 80 เปอร์เซ็นต์จากข้อมูลทั้งหมดและข้อมูลตรวจสอบความถูกต้องอีก 10 เปอร์เซ็นต์จากข้อมูลทั้งหมด ซึ่งการทดสอบจากข้อมูลตรวจสอบความถูกต้องได้ผลลัพธ์ที่ 80 ถึง 85 เปอร์เซ็นต์ แสดงผลการฝึกทั้ง 10 รอบด้วยรูปต่อไปนี้



**ภาพประกอบที่ 4.2.1** ผลลัพธ์การฝึกการเรียนรู้

การฝึกการเรียนรู้มีการเพิ่มขึ้นเรื่อย ๆ ทุก ๆ รอบของการทดสอบ โดยเส้นของ Training มีแนวโน้มว่าจะเพิ่มขึ้นเรื่อย ๆ แต่เส้นของ Validation จะตกลงในรอบที่ 7 และอ้อมตัวอยู่ที่ 85 โดยประมาณและมีแนวโน้มว่าจะไม่เพิ่มมากกว่านี้อีกแล้ว

#### 4.3 การประเมินและวิเคราะห์ผลการประเมิน

การประเมินผลวัดจากข้อมูลสำหรับวัดประสิทธิภาพ 10 เปอร์เซ็นต์จากข้อมูลทั้งหมดและมีจำนวนข้อมูลที่เท่ากัน มีเพียงถนนซ่อมปะที่มีจำนวน 823 ภาพ ผู้วิจัยจึงเพิ่มข้อมูลหนึ่งภาพเข้าไปด้วยตัวเองเพื่อให้จำนวนที่เท่ากันทั้งสามชนิด จากนั้นนำข้อมูลสำหรับวัดประสิทธิภาพแต่ละชนิด หาค่าความแม่นยำ (Precision), ค่าความระลึก (Recall) ด้วย IoU ที่ได้ 0.5 ขึ้นไปและถือเป็นค่าวัดที่อยู่ในระดับกลางที่ใช้กันทั่วไปในงานตรวจจับวัตถุ เมื่อได้ผลลัพธ์แล้วนำค่าทั้งสองหาความแม่นยำเฉลี่ย (Average Precision)

ผลลัพธ์การตรวจจับในแต่ละหมวดหมู่จะแสดงรายละเอียดการตรวจจับทั้งหมดและจำนวนผลเฉลย (Ground Truth) ดังนี้

**ตารางที่ 4.4** รายละเอียดการตรวจจับของหลุม

ผลการตรวจจับของ หลุม	
จำนวนที่พบวัตถุ	5,525
จำนวนผลเฉลย	2,154
ทำนายถูก	740
ทำนายผิด	4,785
ความแม่นยำเฉลี่ย	0.23

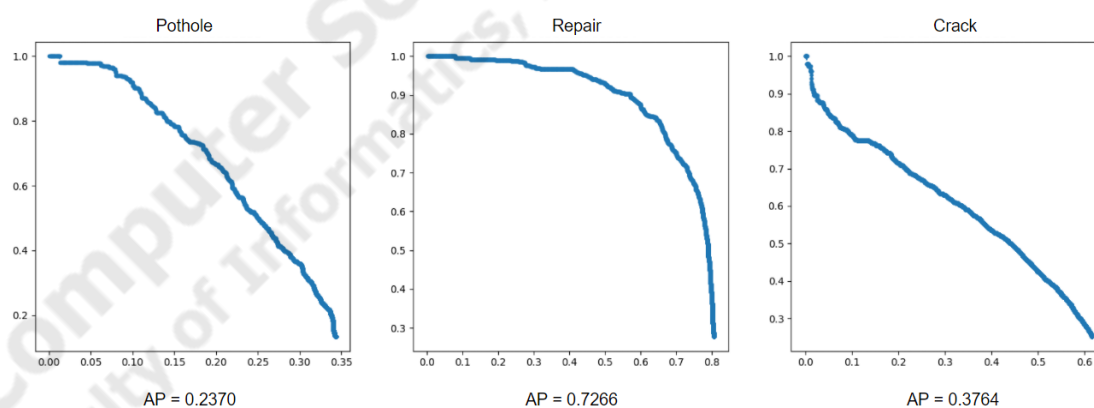
ตารางที่ 4.5 รายละเอียดการตรวจจับของซ่อมปะ

ผลการตรวจจับของ ซ่อมปะ	
จำนวนที่พบวัตถุ	4,590
จำนวนผลเฉลย	1,580
ทำนายถูก	1,273
ทำนายผิด	3,317
ความแม่นยำเฉลี่ย	0.72

ตารางที่ 4.6 รายละเอียดการตรวจจับของแตกร้าว

ผลการตรวจจับของ แตกร้าว	
จำนวนที่พบวัตถุ	17,467
จำนวนผลเฉลย	7,127
ทำนายถูก	4,389
ทำนายผิด	13,078
ความแม่นยำเฉลี่ย	0.37

และแสดงผลลัพธ์ทั้งสามชนิดด้วยความแม่นยำเฉลี่ย (Average Precision) ดังต่อไปนี้



ภาพประกอบที่ 4.3.1 ผลลัพธ์ทั้งสามชนิด

การประเมินผลจาก หลุมบ่อ ถนนซ่อมปะ ถนนแตก ได้ผลลัพธ์ตามลำดับดังนี้ 0.2370, 0.7266, 0.3764 เมื่อนำค่าทั้งสามชนิดมารวมกันและหาค่าเฉลี่ยทั้งหมดจะได้ค่า mAP (mean Average Precision) ดังนั้น mAP เท่ากับ 0.4466 หรือ 44 เปอร์เซ็นต์ ด้วย IoU ที่ 0.5

เมื่อสรุปผลจากกราฟของแต่ละหมวดหมู่ ถนนซ่อมปะ มีกราฟที่สูงกว่าหมวดอื่น ๆ และมี Recall สูงที่สุด แปลว่าถนนซ่อมปะมีการตรวจจับวัตถุที่มีอยู่ในผลเฉลย (Ground Truth) ได้มากกว่าหมวดอื่น ๆ อาจเป็นเพราะรูปร่างของถนนซ่อมปะมีลักษณะที่มองออกได้ง่ายและมีรูปทรงที่คล้าย ๆ กัน

เมื่อเทียบกับ หลุมและถนนแตก รูปร่างของวัตถุจะมีความไม่แน่นอนอาจทำให้การตรวจจับได้ยาก และเมื่อดูจากกราฟ หลุมและถนนแตก จะมีการตรวจจับวัตถุที่มีอยู่ในผลเฉลย (Ground Truth) ได้น้อยแต่มีความสม่ำเสมอของกราฟกว่าถนนซ่อมปะ ความสม่ำเสมอนี้เมื่อดูของถนนซ่อมปะจะเห็นได้ว่าการดิ่งลงของ Precision ตั้งแต่ช่วง 0.7 เป็นต้นไป แปลว่าถนนซ่อมปะจะตอบผิดมากกว่าปกติถ้าความมั่นใจต่ำลง

ค่าเฉลี่ย mAP (mean Average Precision) เท่ากับ 0.4466 หรือ 44 เปอร์เซ็นต์ ที่ได้ออกมาไม่สามารถบอกได้ว่าโมเดลจะทำนายผลแต่ละหมวดหมู่ได้มากน้อยเพียงใด แต่เป็นการบอกค่าโดยรวมที่โมเดลสามารถทำนายผลออกมาได้ เมื่อเทียบผลลัพธ์กับการตรวจจับวัตถุด้วยวิธี Yolo แสดงตารางดังต่อไปนี้

ตารางที่ 4.7 ประสิทธิภาพของโมเดล Yolo

Model	Dataset	Class	IoU	mAP
YOLOv3-608	Coco Dataset	90	0.5	57.9
YOLOv2	Coco Dataset	90	0.5	48.1
Tiny YOLO	Coco Dataset	90	0.5	23.7

ประสิทธิภาพโดยรวมของโมเดล Yolo อยู่ระหว่าง 20 ถึง 60 แต่วัดด้วยจำนวนหมวดหมู่ที่มากกว่าและค่า mAP (mean Average Precision) ที่ได้ไม่สามารถบอกได้ว่าหมวดหมู่ไหนทำนายออกมาได้ดีที่สุด โดยผลลัพธ์ของโมเดลจำแนกถนนได้ mAP เท่ากับ 44 เปอร์เซ็นต์ถือว่าอยู่ในเกณฑ์ที่ยอมรับได้



แต่เมื่อดูในระดับค่า AP (Average Precision) ถนนซ่อมปะมีค่าเฉลี่ยออกมาสูงที่สุดที่ 72 เปอร์เซ็นต์ ถือว่าเป็นเกณฑ์ในระดับปกติไม่ถือว่าดีซึ่งถ้ามากกว่า 75 เปอร์เซ็นต์ขึ้นไปถึงจะถือว่าดี โดยหลุมและถนนแตกมีเปอร์เซ็นต์ที่ต่ำกว่ามาก การนำไปใช้อาจเกิดปัญหาการการตรวจจับวัตถุไม่พบได้มากกว่า

ตารางที่ 4.8 Model จำแนกถนน

	หลุม	ถนนซ่อมปะ	ถนนแตก
AP	23%	72%	37%
ผลลัพธ์	ต่ำ	ปกติ	ต่ำ



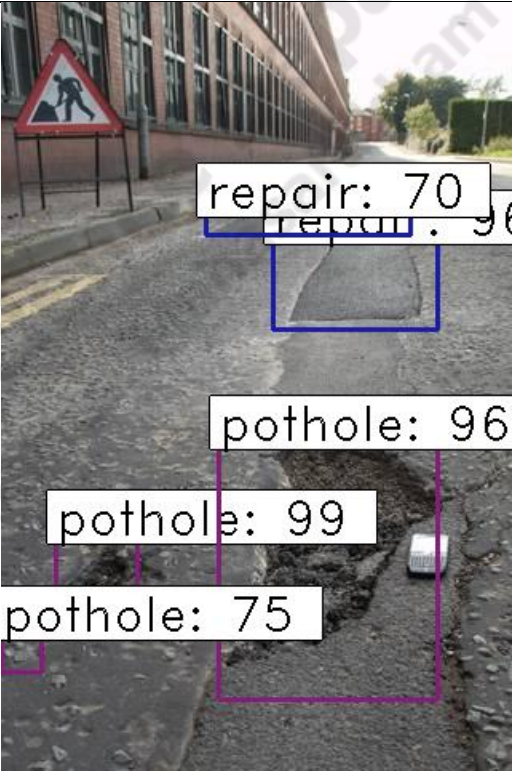
จากการการประเมินผลสามารถแสดงตัวอย่างการทำนายได้ตามตามตารางต่อไปนี้

ตารางที่ 4.9 ตัวอย่างผลลัพธ์การทำนายภาพที่ 1


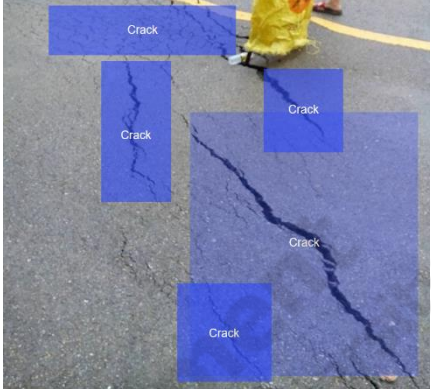
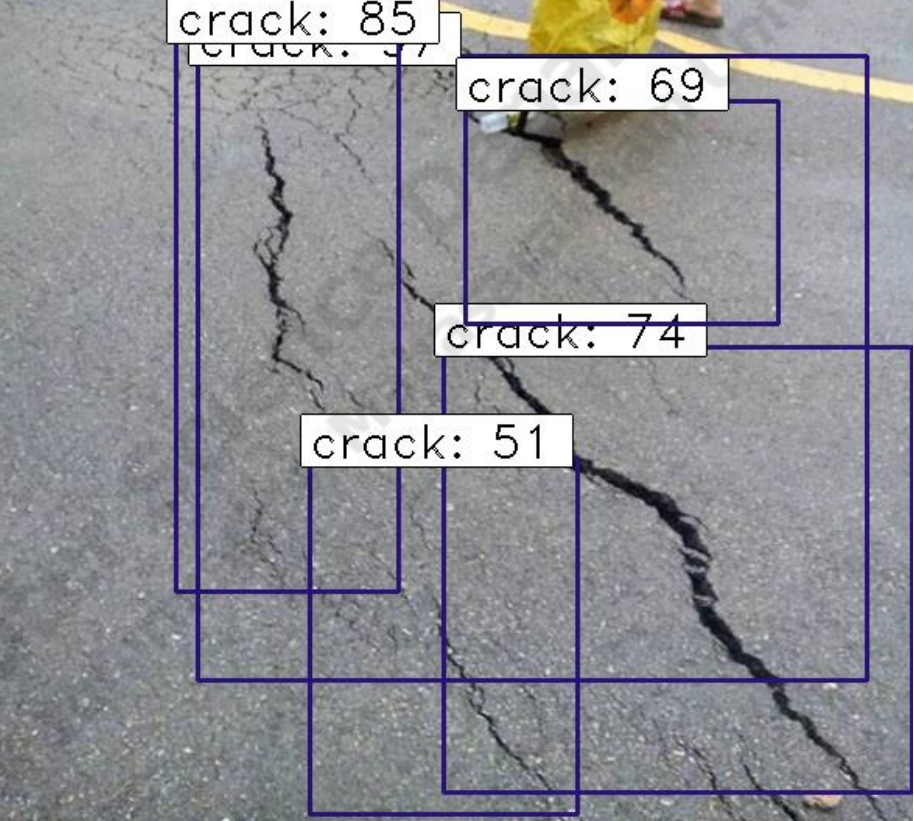
ภาพที่ 1																																										
ผลทำนาย																																										
รายละเอียด	<table border="1"> <thead> <tr> <th>No.</th> <th>ความมั่นใจ</th> <th>คำตอบ</th> <th>IoU</th> <th>ผลลัพธ์</th> </tr> </thead> <tbody> <tr> <td>1</td> <td>98%</td> <td>Repair</td> <td>0%</td> <td>ผิด</td> </tr> <tr> <td>2</td> <td>96%</td> <td>Pothole</td> <td>62%</td> <td>ถูก</td> </tr> <tr> <td>3</td> <td>95%</td> <td>Repair</td> <td>0%</td> <td>ผิด</td> </tr> <tr> <td>4</td> <td>91%</td> <td>Repair</td> <td>0%</td> <td>ผิด</td> </tr> <tr> <td>5</td> <td>90%</td> <td>Pothole</td> <td>79%</td> <td>ถูก</td> </tr> <tr> <td>6</td> <td>82%</td> <td>Pothole</td> <td>86%</td> <td>ถูก</td> </tr> <tr> <td>7</td> <td>81%</td> <td>Repair</td> <td>0%</td> <td>ผิด</td> </tr> </tbody> </table>	No.	ความมั่นใจ	คำตอบ	IoU	ผลลัพธ์	1	98%	Repair	0%	ผิด	2	96%	Pothole	62%	ถูก	3	95%	Repair	0%	ผิด	4	91%	Repair	0%	ผิด	5	90%	Pothole	79%	ถูก	6	82%	Pothole	86%	ถูก	7	81%	Repair	0%	ผิด	
No.	ความมั่นใจ	คำตอบ	IoU	ผลลัพธ์																																						
1	98%	Repair	0%	ผิด																																						
2	96%	Pothole	62%	ถูก																																						
3	95%	Repair	0%	ผิด																																						
4	91%	Repair	0%	ผิด																																						
5	90%	Pothole	79%	ถูก																																						
6	82%	Pothole	86%	ถูก																																						
7	81%	Repair	0%	ผิด																																						




ตารางที่ 4.10 ตัวอย่างผลลัพธ์การทำนายภาพที่ 2

ภาพที่ 2					
ผลทำนาย					
รายละเอียด	No.	ความมั่นใจ	คำตอบ	IoU	ผลลัพธ์
	1	99%	Pothole	58%	ถูก
	2	96%	Repair	93%	ถูก
	3	96%	Pothole	68%	ถูก
	4	75%	Pothole	0%	ผิด
	5	70%	Repair	65%	ถูก


ตารางที่ 4.11 ตัวอย่างผลลัพธ์การทำนายภาพที่ 3

ภาพที่ 3					
ผลทำนาย					
รายละเอียด	No.	ความมั่นใจ	คำตอบ	IoU	ผลลัพธ์
	1	97%	Crack	0%	ผิด
	2	85%	Crack	0%	ผิด
	3	74%	Crack	69%	ถูก
	4	69%	Crack	55%	ถูก
	5	51%	Crack	0%	ผิด

#### 4.4 ตัวอย่างการทำนายผลบน Mobile Application



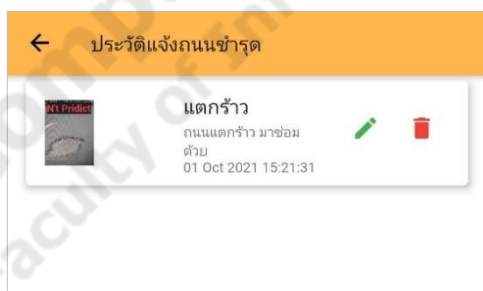
(ก) เลือกปุ่มเพื่อรายงานถนน



(ข) ใส่รายละเอียดและเลือกประเภทความเสียหาย

##### ภาพประกอบที่ 4.4.1 ตัวอย่างการทำนายบน Application ภาพที่ 1

ผู้ใช้ทั่วไปสามารถรายงานถนนเสียหายได้จาก Mobile Application โดยสามารถรายงานได้แค่ หลุมและถนนแตกเท่านั้น ยังสามารถใส่รายละเอียดเพิ่มเติมให้เจ้าหน้าที่ได้อ่านเพิ่มเติมได้



(ก) รายการรอการทำนายผลตามคิว

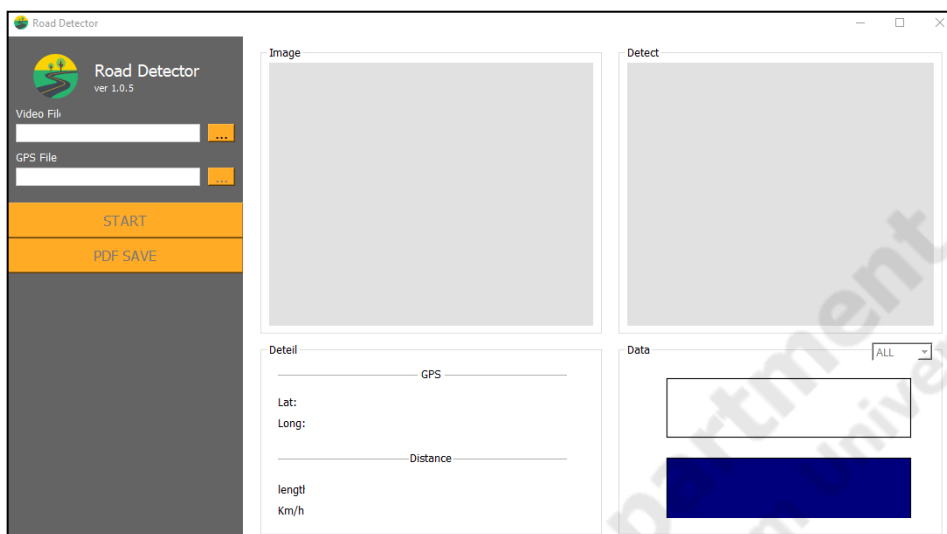


(ข) ระบบทำนายผลและเปลี่ยนประเภท

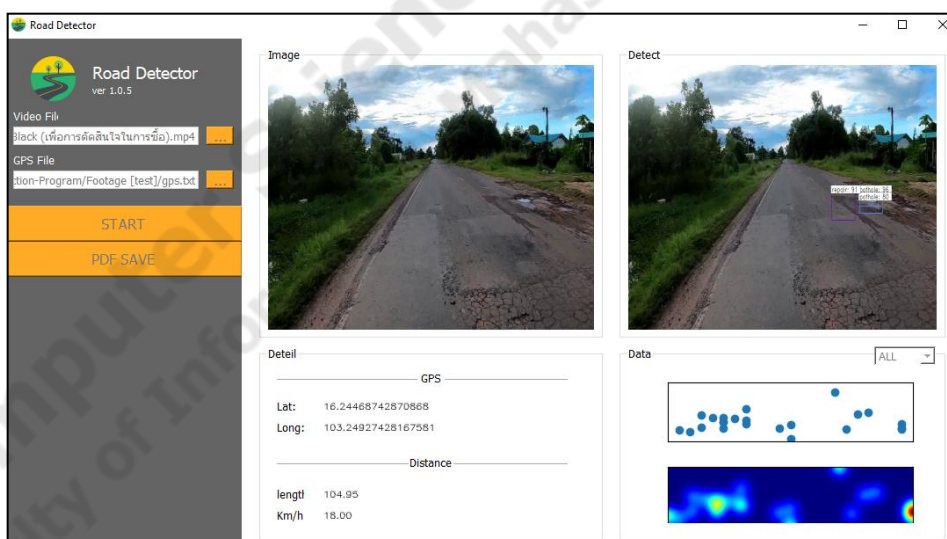
##### ภาพประกอบที่ 4.4.2 ตัวอย่างการทำนายบน Application ภาพที่ 2

ระบบตรวจจับอัตโนมัติจะไม่สามารถทำนายให้ทีเดียพร้อม ๆ กันทุกคนได้ จำเป็นต้องรอคิว เพราะการทำนายหนึ่งครั้งจำเป็นต้องใช้ทรัพยากรของระบบอย่างมาก

#### 4.5 ตัวอย่างการทำนายผลด้วย Desktop Application

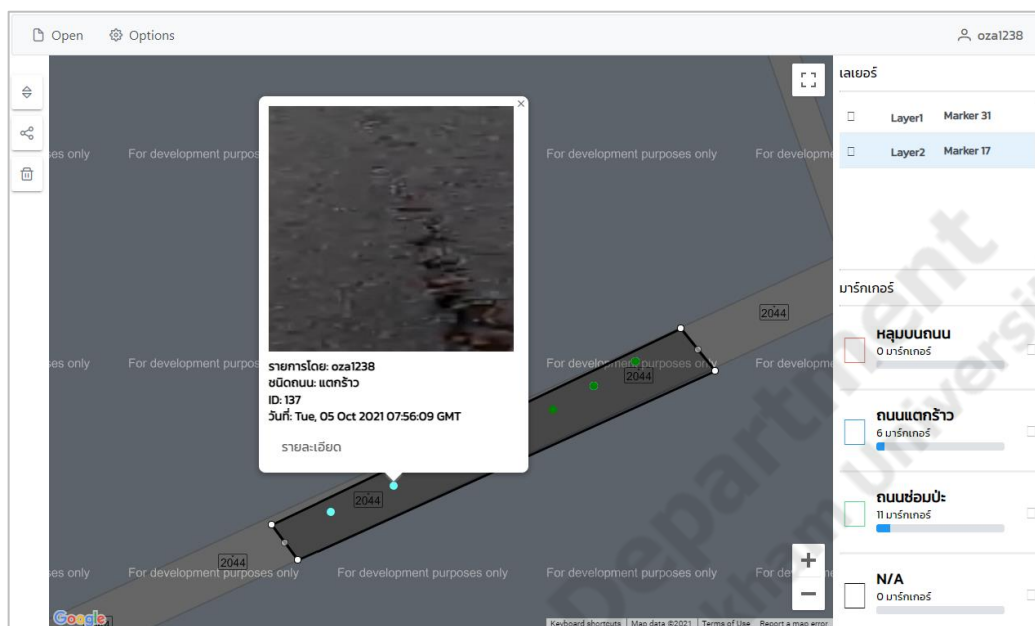


ภาพประกอบที่ 4.5.1 ตัวอย่างการทำนายผลด้วย Desktop Application ภาพที่ 1 สำหรับเจ้าหน้าที่ที่สามารถใช้โปรแกรม Desktop Application ได้ผ่านคอมพิวเตอร์ของตัวเอง โดยไม่ผ่านระบบเซิร์ฟเวอร์



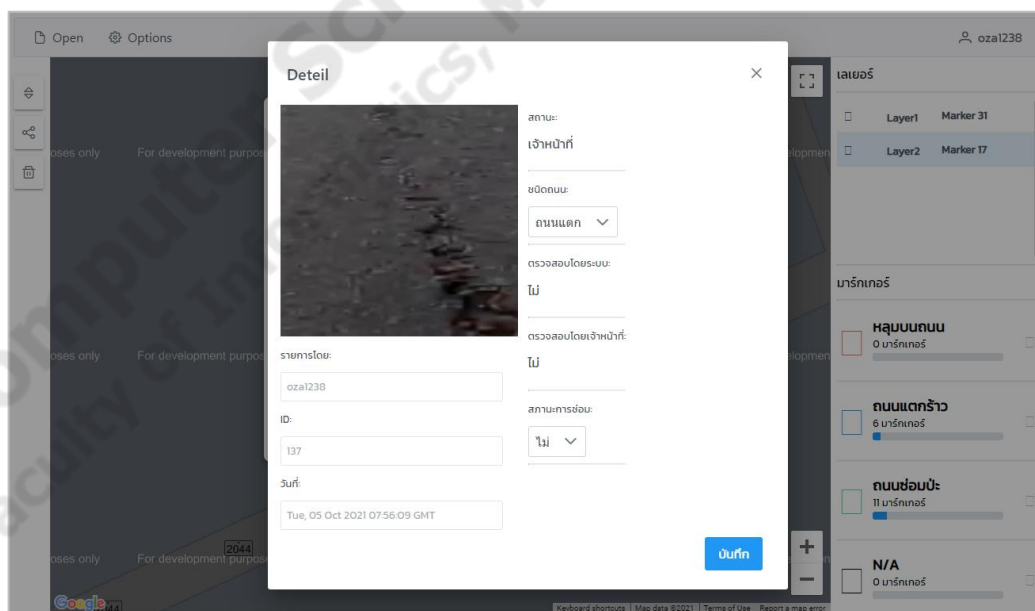
ภาพประกอบที่ 4.5.2 ตัวอย่างการทำนายผลด้วย Desktop Application ภาพที่ 2 โดยต้องมีไฟล์ GPS พร้อมกับไฟล์วิดีโอเพื่อให้โปรแกรมทำงานได้ เมื่อการทำนายเสร็จสิ้นก็สามารถกด PDF SAVE เพื่อทำรายงานที่ตรวจพบความเสียหายของถนนทั้งหมดได้และยังสามารถนำไฟล์ส่งไปที่เว็บไซต์เพื่อส่งรายงานทั้งหมดได้

#### 4.6 ตัวอย่างการจัดการการรายงานถนนด้วย Website



ภาพประกอบที่ 4.6.1 การจัดการการรายงานถนนด้วย Website ภาพที่ 1

เจ้าหน้าที่สามารถจัดการการรายงานถนนทั้งผู้ใช้ทั่วไปและการรายงานจากเจ้าหน้าที่เองพร้อมทั้งสามารถอ่านการทำนายผลจากโปรแกรม Desktop Application



ภาพประกอบที่ 4.6.2 การจัดการการรายงานถนนด้วย Website ภาพที่ 2

เจ้าหน้าที่สามารถจัดการการรายงานแบบเฉพาะเจาะจงได้โดยสามารถเปลี่ยนคำตอบใหม่ได้ และเมื่อเจ้าหน้าที่ได้ทำการซ่อมจริง ๆ บนถนนก็สามารถเปลี่ยนสถานะการซ่อมได้