


**การตรวจจับและจำแนกประเภทยานพาหนะโดยใช้ DEEP LEARNING  
และ IMAGE ENHANCEMENT  
VEHICLE DETECTION AND CLASSIFICATION USING DEEP  
LEARNING AND IMAGE ENHANCEMENT**



ปริญญานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2561

การตรวจจับและจำแนกประเภทยานพาหนะโดยใช้ DEEP LEARNING  
และ IMAGE ENHANCEMENT  
VEHICLE DETECTION AND CLASSIFICATION USING DEEP  
LEARNING AND IMAGE ENHANCEMENT



ชินวัตร จันทร์ศรี

ปรุพหัทธพ์ ลิมรังสรรค์

ปริญญาานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2561

ปริญญาานิพนธ์ปีการศึกษา 2561

ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เรื่อง การตรวจจับและจำแนกประเภทยานพาหนะโดยใช้ Deep Learning และ Image Enhancement

VEHICLE DETECTION AND CLASSIFICATION USING DEEP LEARNING AND  
IMAGE ENHANCEMENT

ผู้จัดทำ

1. นายชินวัตร จันทร์ศรี รหัสนักศึกษา 58010297
2. นายปรุพหัทธพงษ์ ลิ้มรังสรรค์ รหัสนักศึกษา 58010753



อาจารย์ที่ปรึกษา

(อาจารย์สรยุทธ กลมกล่อม)

# การตรวจจับและจำแนกประเภทยานพาหนะโดยใช้

## Deep Learning และ Image Enhancement

นายชินวัตร จันทร์ศรี 58010297

นายปรุพท์ทรัพย์ ลีมรังสรรค์ 58010753

อาจารย์สรยุทธ กลมกล่อม อาจารย์ที่ปรึกษา

ปีการศึกษา 2561

### บทคัดย่อ

โครงการนี้มีจุดประสงค์เพื่อสร้างโมเดลตรวจจับและจำแนกประเภทยานพาหนะบนท้องถนน ด้วย Faster Region-Based Convolutional Neural Networks (Faster R-CNN) โดยใช้ TensorFlow Object detection API และกระบวนการ Image Pre-Processing (Contrast Transformation, Brightness Adjustment, Bilateral Filtering, Sharpening และ Grayscale) ในการเพิ่มความแม่นยำให้กับโมเดล ซึ่งทดสอบประสิทธิภาพโดยดูผลจากค่า Mean Average Precision (mAP) และ Accuracy เพื่อให้ได้โมเดลที่แม่นยำที่สุด ข้อดีของงานโครงการนี้คือการเพิ่มความแม่นยำในการตรวจจับและจำแนกประเภทยานพาหนะ ทำให้สามารถวิเคราะห์สภาพการจราจรได้อย่างมีประสิทธิภาพมากขึ้นและนำไปสู่การใช้แก้ปัญหาการจราจรและพัฒนาระบบคมนาคมต่อไป

# Vehicle Detection and Classification Using Deep Learning and Image Enhancement

Mr. Chinnawat Jansree 58010297

Mr. Paroonsub Limrungsan 58010753

Mr. Sorayut Glomglome Advisor

Academic Year 2561

## ABSTRACT

The purpose of this project is building vehicle detection and classification model for based on Faster Region-Based Convolutional Neural Networks (Faster R-CNN) using TensorFlow Object detection API and Image Pre-Processing (Contrast Transformation, Brightness Adjustment, Bilateral Filtering, Sharpening and Grayscale) to increase precision of the model. The metric to measure the precision of this model is Mean Average Precision (mAP) and Accuracy to make a model that most suitable for vehicle classification. The benefit of this project is to increases the performance of vehicle detection and classification, so we can use that model to analyze traffic conditions effectively and to solve traffic congestion and improve transportation system.

## กิตติกรรมประกาศ

ปริญญานิพนธ์ฉบับนี้สำเร็จลุล่วงลงไม่ได้หากปราศจากความช่วยเหลือของ อาจารย์ที่ปรึกษา อาจารย์สรยุทธ กลมกล่อม ผู้ให้คำแนะนำ คำปรึกษา และให้ความช่วยเหลือตลอดการทำปริญญานิพนธ์ ซึ่งทำให้การทำงานต่างๆ เป็นไปได้อย่างราบรื่นและสำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณอาจารย์และบุคลากรต่างๆ ในสาขาวิชาวิศวกรรมคอมพิวเตอร์ที่ได้ให้คำแนะนำ และตั้งความรู้ต่างๆ มาโดยตลอด รวมถึงห้องแล็บ HRCL (The Hybrid Computing research Laboratory) ที่ได้เอื้อเฟื้อสถานที่ในการทำวิจัยและพัฒนาปริญญานิพนธ์

ขอขอบคุณรุ่นพี่และเพื่อนหลาย ๆ คนในภาควิชาวิศวกรรมคอมพิวเตอร์ที่ได้ให้คำแนะนำ คำปรึกษาและแบ่งปันความรู้ในทุก ๆ ด้าน

ในสุดท้ายนี้ ขอขอบคุณ บิดา มารดา และครอบครัว ที่ได้เลี้ยงดู สั่งสอน และให้การสนับสนุน พร้อมทั้งให้โอกาสในการศึกษาและให้กำลังใจเสมอมา

ชินวัตร

จันทร์ศรี

ปรุฬห์ทรัพย์

ถัมรังสรรค์

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	I
บทคัดย่อภาษาอังกฤษ .....	II
กิตติกรรมประกาศ.....	III
สารบัญ .....	IV
สารบัญตาราง .....	VI
สารบัญรูป .....	VII
บทที่ 1 บทนำ .....	1
1.1 ความเป็นมาของปัญหา.....	1
1.2 วัตถุประสงค์โครงการ.....	3
1.3 ประโยชน์ที่คาดว่าจะได้รับ .....	3
1.4 ขอบเขตของโครงการ.....	3
1.5 ข้อจำกัดของโปรแกรม .....	3
1.6 แผนการดำเนินงาน .....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	6
2.1 Machine Learning (ML) .....	6
2.2 TensorFlow .....	12
2.3 Image Enhancement.....	13
2.4 Mean Average Precision (mAP) .....	15
2.5 งานวิจัยที่เกี่ยวข้อง.....	17

## สารบัญ(ต่อ)

	หน้า
บทที่ 3 การออกแบบและพัฒนา.....	21
3.1 ภาพรวมการทำงานภายในระบบ .....	21
3.2 การออกแบบขั้นตอนการทำงานของระบบ .....	22
บทที่ 4 การทดลอง .....	25
4.1 การทดลองเกี่ยวกับการเลือกใช้ Datasets.....	26
4.2 การทดลองเกี่ยวกับการเลือกใช้ความละเอียดของ Input.....	29
4.3 การทดลองเกี่ยวกับการเลือกใช้ Image Pre-Processing .....	43
4.4 สรุปการทดลอง .....	44
บทที่ 5 บทสรุปและข้อเสนอแนะ.....	46
5.1 บทสรุป.....	46
5.2 ปัญหาและอุปสรรค .....	46
5.3 แนวทางในการพัฒนาต่อ.....	47

# สารบัญตาราง

ตาราง	หน้า
1.1 แสดงแผนการดำเนินงาน (1) .....	4
1.2 แสดงแผนการดำเนินงาน (2) .....	5
4.1 แสดงตารางเปรียบเทียบ mAP ระหว่างโมเดล 240p และ 480p.....	28
4.2 แสดงตารางเปรียบเทียบ AP และ mAP ของแต่ละความละเอียดภาพของ Input .....	31
4.3 แสดงตัวอย่าง Confusion Matrix จากโมเดลที่ Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering, d=6) .....	36
4.4 แสดงค่า TP, TN, FP, FN, Accuracy, Precision และ Recall ของแต่ละคลาสของโมเดลที่ใช้ Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering, d=6) .....	36
4.5 แสดงค่า Precision ของแต่ละโมเดล.....	37
4.6 แสดงการเปรียบเทียบค่า Precision ของแต่ละโมเดล .....	37
4.7 แสดงค่า Recall ของแต่ละโมเดล.....	39
4.8 แสดงการเปรียบเทียบค่า Recall ของแต่ละโมเดล .....	39
4.9 แสดงค่า Accuracy ของแต่ละโมเดล .....	41
4.10 แสดงการเปรียบเทียบค่า Accuracy ของแต่ละโมเดล .....	41
4.11 แสดงการเปรียบเทียบค่า Accuracy ของ Pre-Processing Level I .....	44

# สารบัญรูป

รูป	หน้า
1.1 แสดงตัวอย่างการใช้ตรวจสอบสภาพจราจรแบบ Real Time .....	1
2.1 การทำงานของ Neuron .....	7
2.2 Neural Network .....	8
2.3 Deep neural network .....	9
2.4 แสดงองค์ประกอบของ Convolutional Neural Network layer.....	10
2.5 แสดงโครงสร้างของFaster R-CNN.....	11
2.6 แสดงการเปรียบเทียบ pre-trained model .....	12
2.7 แสดงการปรับ Image Filtering .....	13
2.8 แสดงการปรับ Contrast Adjustment .....	13
2.9 แสดงการปรับ Morphological Operations.....	14
2.10 แสดงการปรับ Deblurring .....	14
2.11 แสดงการปรับ Neighborhood and Block Processing .....	15
2.12 แสดงการคำนวณหาค่า Intersection over Union (IoU) .....	16
2.13 เปรียบเทียบความถูกต้องในการจำแนกประเภทยานพาหนะด้วยวิธีที่ต่างกัน.....	17
2.14 แสดงการเปรียบเทียบค่า mAP (Mean Average Precision) ของแต่ละโมเดล .....	18
2.15 แสดงค่า GPU time ของแต่ละ โมเดลที่ใช้.....	18
2.16 แสดงค่า Memory usage ของแต่ละ โมเดลที่ใช้.....	19
2.17 แสดงจำนวน Datasets ในการ Training และ Testing .....	19
3.1 System Diagram.....	20
3.2 Flowchart แสดงการทำงานของโปรแกรมโดยรวม.....	21
3.3 Flowchart แสดงการขั้นตอนการ Train Model .....	22
3.4 Flowchart แสดงอัลกอริทึมของ Faster R-CNN ที่ใช้จำแนกประเภทรถ .....	24
4.1 รูปเปรียบเทียบผลลัพธ์ที่ใช้ Datasets และ Input ที่มีความละเอียดต่างกัน.....	27
4.2 แสดงAP และ mAP ของ โมเดลความละเอียด 240p.....	27
4.3 แสดงAP และ mAP ของ โมเดลความละเอียด 480p.....	28
4.4 แสดงAP และ mAP ของ Input144p ด้วยModel 480p.....	29
4.5 แสดงAP และ mAP ของInput240p ด้วยModel 480p.....	30

## สารบัญรูป(ต่อ)

รูป	หน้า
4.6 แสดง AP และ mAP ของ Input 480p ด้วย Model 480p.....	30
4.7 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering) (1)Original, (2)Blur6, (3)Blur9, (4)Blur12, (5)Blur15, (6)Blur18.....	33
4.8 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Brightness Adjustments (1)Original, (2)Brightness30, (3) Brightness50, (4) Brightness70, (5) Brightness90, (6) Brightness110.....	34
4.9 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Contrast Adjustments (1)Original, (2)Contrast1.1, (3) Contrast1.2, (4) Contrast1.3, (5) Contrast1.4, (6) Contrast1.5 .....	35
4.10 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Grayscale และ Sharpening (1) Original, (2) Grayscale, (3) Sharpening .....	37
4.11 กราฟแสดงการเปรียบเทียบค่า Accuracy ของแต่ละ โมเดล .....	43
4.12 แสดงพื้นที่ที่โมเดลมีค่า Accuracy สูง .....	45

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาของปัญหา

ปัจจุบันในประเทศไทยการเดินทางและการคมนาคมขนส่งทางบกโดยรถยนต์และจักรยานยนต์ เป็นหนึ่งช่องทางที่ประชาชนเลือกใช้เป็นจำนวนมาก ซึ่งเป็นช่องทางหลักที่สะดวกและรวดเร็ว จึงก่อให้เกิดการจราจรติดขัดในบางพื้นที่ โดยเฉพาะอย่างยิ่งในช่วงเวลาเร่งด่วนที่เป็นปัญหาหลักที่ต้องการได้รับการแก้ไขซึ่งเห็นได้อย่างชัดเจนในจังหวัดกรุงเทพมหานคร

สำนักงานจราจรและขนส่ง(สจส) ได้พัฒนาแอปพลิเคชัน BMA TRAFFIC และเว็บไซต์ [www.bmatraffic.com](http://www.bmatraffic.com) ให้ประชาชน สามารถตรวจสอบสภาพจราจร ณ เวลาปัจจุบัน (Real-Time) จากการดึงภาพจากกล้องวงจรปิด (CCTV) กว่า 300 ตัวทั่วกรุงเทพมหานคร โดยรูปแบบของแอปพลิเคชันจะแสดงแผนที่จากGoogle Map พร้อมแสดงจุดติดตั้งกล้องวงจรปิด สามารถขยายเข้าไปดูภาพกล้องวงจรปิดแบบ Real-Time แต่ข้อมูลเหล่านี้ยังไม่เพียงพอที่ช่วยให้วิเคราะห์สภาพจราจรได้ ดังนั้นหากรู้จำนวนและประเภทของยานพาหนะบนท้องถนนได้จากกล้องวงจรปิด ก็สามารถนำข้อมูลเหล่านี้ไปใช้แก้ปัญหาการจราจรและพัฒนาระบบคมนาคมได้อย่างมีประสิทธิภาพ เช่น วางแผนการก่อสร้างถนนใหม่ วางแผนขยายถนนเพื่อรองรับปริมาณการจราจรที่มากขึ้น วิเคราะห์สาเหตุของการจราจรติดขัด การประเมินความเสี่ยงการเกิดอุบัติเหตุ ฯลฯ



รูป 1.1 แสดงตัวอย่างการใช้ตรวจสอบสภาพจราจรแบบ Real Time <sup>1</sup>

<sup>1</sup> <https://www.bmatraffic.com>

หากใช้ข้อมูลจากกล้องวงจรปิดที่มีทั้งหมด จะช่วยให้วิเคราะห์สภาพการจราจรได้อย่างมีประสิทธิภาพมากขึ้น แต่ปัญหาคือกล้องวงจรปิดแต่ละตัวจำเป็นต้องส่งภาพไปยังศูนย์ควบคุม (Server) ซึ่งมีข้อจำกัดเรื่องปริมาณการรับส่งของข้อมูล เพราะเป็นระบบ Real-time Server ต้องรับข้อมูลอยู่ตลอดเวลาภายใต้ อัตราการรับส่งข้อมูล (Bandwidth) ที่จำกัด หากต้องการใช้ข้อมูลจากกล้องที่มากขึ้น อัตราการรับส่งข้อมูลจะไม่เพียงพอ การลดคุณภาพของภาพจากกล้องจะสามารถช่วยแก้ปัญหาดังกล่าวได้

ระบบ AI หรือ Artificial Intelligence กำลังเป็นที่พูดถึงอย่างมาก ด้วยความฉลาดที่สามารถคิดและวิเคราะห์ รวมไปถึงการแยกแยะวิธีการจัดการในหลายๆ เรื่อง ส่งผลให้ AI ถูกจับตามองว่า จะเข้ามามีบทบาทสำคัญกับชีวิตมนุษย์ในอนาคตอันใกล้นี้ โดย AI ถูกใช้แพร่หลายในประเทศผู้นำด้านนวัตกรรม และมีการพัฒนาเพื่อเพิ่มประสิทธิภาพและความแม่นยำอย่างต่อเนื่อง โดยเฉพาะอย่างยิ่ง Machine Learning อีกแขนงหนึ่งของ AI ที่ใช้หลักการ Neural Network การประมวลผลในลักษณะคล้ายสมองของมนุษย์ กล่าวคือมีการเรียนรู้และตัดสินใจด้วยตัวเองจากการเรียนรู้ชุดข้อมูลที่มนุษย์ป้อนให้ซึ่งสามารถประยุกต์ใช้เป็นตัวช่วยในการตรวจจับและจำแนกประเภทของยานพาหนะได้เช่นกัน

ทำให้ผู้จัดทำโครงการมีความสนใจศึกษา การตรวจจับและจำแนกประเภทยานพาหนะด้วยกล้องวงจรปิด(CCTV) จากภาพวิดีโอคุณภาพต่ำ โดยนำเทคโนโลยี Machine Learning และ Image Processing มาช่วยเพิ่มประสิทธิภาพให้โมเดล (Deep learning) เพื่อเพิ่มขีดความสามารถของกล้องวงจรปิดที่ใช้เพียงบันทึกภาพ ซึ่งผู้จัดทำเลือกใช้ TensorFlow Object detection เป็น Python API ที่ช่วยให้ง่ายต่อการสร้าง ปรับปรุง และ แก้ไข โมเดล Deep Learning(CNN) จำพวก Object detection

## 1.2 วัตถุประสงค์โครงการ

- 1) เพื่อศึกษาและประยุกต์ใช้งาน Deep Learning Model ในงานรูปภาพ
- 2) เพื่อศึกษาและประยุกต์ใช้ความรู้ด้าน Deep Learning และ Image Processing ในการจำแนกยานพาหนะบนท้องถนน
- 3) เพื่อศึกษา Image Processing วิธีต่างๆ ที่มีผลต่อความแม่นยำของ Convolutional Neural Network Model ในการใช้จำแนกยานพาหนะบนท้องถนน
- 4) เพื่อเพิ่มประสิทธิภาพความแม่นยำของ Convolutional Neural Network Model ในการใช้จำแนกยานพาหนะบนท้องถนน

## 1.3 ประโยชน์ที่คาดว่าจะได้รับ

- 1) สามารถจำแนกประเภทยานพาหนะ ในรูปภาพได้
- 2) ข้อมูลที่ได้สามารถนำไปต่อยอดช่วยวิเคราะห์สภาพการจราจรบนท้องถนนได้
- 3) เข้าใจหลักการทำงานของ Convolutional Neural Network Model

## 1.4 ขอบเขตของโครงการ

- 1) ระบบที่สร้างขึ้นมาเพื่อตรวจจับและจำแนกยานพาหนะจากภาพวิดีโอความละเอียดต่ำ (854x480 px) ซึ่งเป็นการประมวลผลแบบ offline
- 2) Input เป็นภาพสีที่ได้จากการแยกเฟรมของไฟล์วิดีโอ เฟรมเรต 29.97 เฟรมต่อวินาที
- 3) ไฟล์วิดีโอที่ใช้บันทึกภาพบนถนนหน้าสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังช่วงเวลากลางวัน (06.00 น. – 18.00 น.)
- 4) ใช้การประมวลผลและ Training model ด้วย GPU: NVIDIA GeForce GTX 1050 4GB

## 1.5 ข้อจำกัดของโปรแกรม

- 1) ตัวโมเดลใช้ได้กับภาพที่มาจากกล้องเดียวกันกับ Datasets ที่ใช้ Train ให้กับโมเดล
- 2) Input ที่ใช้ไม่ได้เป็นการ Streaming จากกล้องโดยตรง แต่เป็น Input จากไฟล์วิดีโอที่ถ่ายไว้

## 1.6 แผนการดำเนินงาน

กิจกรรม	เดือน																					
	ส.ค.				ก.ย.				ต.ค.				พ.ย.				ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1-4	1-4	1-4	1-4	1-4	
ค้นหาหัวข้อโครงการที่สนใจ	■	■																				
เสนอหัวข้อกับอาจารย์ที่ปรึกษา		■																				
หางานวิจัยอ้างอิงที่เกี่ยวข้องกับ Vehicle Classification และ CNN Model			■	■																		
ศึกษาเทคโนโลยีที่จะนำมาใช้ในโครงการ				■	■																	
ทดลองรัน CNN Model							■	■														
การออกแบบ																						
เลือกและทดลอง CNN Model แต่ละแบบ								■	■													
ทดลองเพื่อหา Datasets ที่เหมาะสม											■	■										
ทดลองเพื่อหาคุณภาพของ Input ที่เหมาะสมต่อการใช้งานจริง												■	■									

ตารางที่ 1.2 แสดงแผนการดำเนินงาน(2)

กิจกรรม	เดือน																					
	ส.ค.				ก.ย.				ต.ค.				พ.ย.				ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1-4	1-4	1-4	1-4	1-4	1-4
พัฒนา																						
จัดทำเอกสารตั้งแต่บทที่ 1-4																						
ทดสอบสร้างและรัน โมเดล Faster R-CNN บน AWS																						
ทำ Pre-processing กับ ข้อมูลที่ใช้ใน Model																						
เปรียบเทียบผลลัพธ์ที่ได้ ก่อน-หลัง การทำ Image Pre-Processing																						
การปรับปรุงแก้ไข																						
ดูประสิทธิภาพของ โมเดล จาก Image Pre-Processing แล้วเลือกมา ปรับใช้กับโมเดล																						
จัดทำเอกสารเพื่อตีพิมพ์ รวบรวมองค์ความรู้ ทั้งหมดและสรุปผล โครงการ																						

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

### 2.1 Machine Learning (ML)

Machine Learning เป็นสาขาหนึ่งของปัญญาประดิษฐ์ (AI) เกี่ยวข้องกับการศึกษาและการสร้างอัลกอริทึมที่สามารถเรียนรู้ข้อมูลและทำนายข้อมูลได้ อัลกอริทึมนั้นจะทำงาน โดยอาศัยโมเดลที่สร้างมาจากชุดข้อมูลตัวอย่างซ้ำๆ เพื่อการทำนายหรือตัดสินใจในภายหลัง แทนที่จะทำงานตามลำดับของคำสั่ง โปรแกรมคอมพิวเตอร์ แบ่งออกเป็น 3 ประเภท ตามลักษณะของอัลกอริทึม

1) **Supervised learning** คือ การเรียนรู้แบบได้รับคำแนะนำ เน้นสอนโดยการศึกษาจากข้อมูลตัวอย่าง มักถูกนำไปใช้แทนการทำงานแบบ rule base คือมีกฎหรือรูปแบบการทำงานที่ตายตัวหรือสามารถอธิบายเหตุผลออกมาได้อย่างชัดเจน การที่ machine learning ได้รู้ก่อนว่าผลลัพธ์ของข้อมูลแบบนี้คืออะไร แบ่งออกเป็น

- Classification เป็นการจัดหมวดหมู่ให้ข้อมูล โดยนิยมใช้กับข้อมูลที่ไม่ต่อเนื่อง (discrete)
- Regression จะเป็นการใช้วิเคราะห์ข้อมูลที่มีความต่อเนื่อง โดย supervised learning

สามารถหาคำตอบได้แค่เท่าที่เราสอนไว้

2) **Unsupervised learning** เป็นการแบ่งข้อมูลเป็นกลุ่ม (clustering) แต่จะไม่สามารถระบุได้ว่าปลายทางเป็นอะไรบ้างได้แค่จัดข้อมูลแบ่งออกเป็นกลุ่มๆ เช่น การแบ่งลูกค้าออกเป็นกลุ่มย่อยๆ ตามลักษณะของลูกค้า เป็นต้น ไม่มีการสอนอย่างชัดเจน การเรียนรู้ของ machine learning เพื่อสร้างแบบจำลอง (model) นั้นมีอยู่ 3 ขั้นตอน

- Feature extraction การแปลงลักษณะของข้อมูล ที่อยู่ในรูปแบบของข้อความหรือรูปภาพ ให้กลายเป็นชุดตัวเลข

- Regularization พิจารณาคุณสมบัติ (feature) ของข้อมูลว่าส่งผลกระทบต่อข้อมูลมากแค่ไหน เพื่อตัดหรือลดส่วนที่ไม่จำเป็นออกเพื่อทำให้ โมเดลซับซ้อนน้อยลง

- Cross-validation หลังจากได้ model มาก็นำมาทดสอบว่าโมเดลที่ได้ สามารถวิเคราะห์ข้อมูลได้อย่างแม่นยำเพียงพหรือไม่

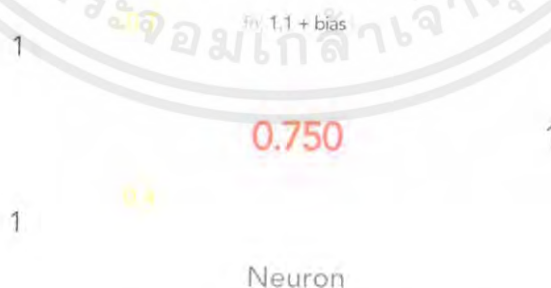
3) **Reinforcement learning** การเรียนรู้แบบลองผิดลองถูกเป็น machine learning ที่มีการปฏิสัมพันธ์กับระบบภายนอก โดยทุกครั้งที่เรียนรู้จะรับ input จากข้างนอกมาคำนวณด้วย input ที่นำเข้ามาคำนวณคือผลจากการลองผิดลองถูกจากครั้งก่อนหน้าซึ่งเราเรียกผลนี้

ว่า reward ซึ่งค่า reward นี้จะถูก feed กลับเข้าไปเป็น input ของการเรียนรู้รอบถัดไปและทำซ้ำไปเรื่อยๆ จนได้ผลที่ต้องการ

### 2.1.1 Artificial Neural Networks (ANN)

โครงข่ายประสาทเทียม (Artificial Neuron Networks) อาศัยแนวคิดและเทคนิคจากการทำงานของระบบโครงข่ายประสาทในระบบประสาทของมนุษย์โดยจำลองการทำงานเหมือนกลุ่มเซลล์ประสาทที่เชื่อมโยงกันเป็นระบบประสาทที่สามารถรับรู้หลายๆสิ่งในเวลาเดียวกัน ด้วยการประมวลผลแบบขนาน (Parallel Network) ทำให้ระบบสามารถตัดสินใจได้ใกล้เคียงกับมนุษย์

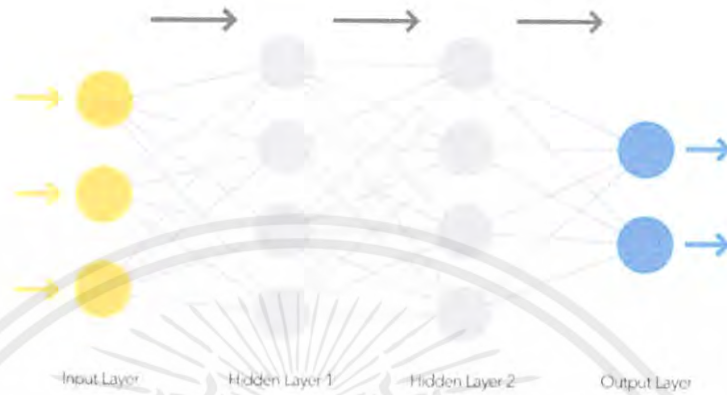
การทำงานของ Neural Networks คือเมื่อมี input เข้ามา จะนำ input มาคูณกับ weight ของแต่ละขา ผลที่ได้จาก input ทุกขาของ neuron จะนำมาบวกกันแล้วมาเทียบกับ threshold ที่กำหนดไว้ ซึ่งถ้าผลรวมมีค่ามากกว่า threshold neuron จะส่ง output ออกไปยัง input ของ neuron อื่นที่เชื่อมกันใน network ถ้าค่าน้อยกว่า threshold ก็จะไม่เกิด output สิ่งสำคัญคือต้องทราบค่า weight และ threshold สำหรับสิ่งที่ต้องการเพื่อให้คอมพิวเตอร์รู้จัก ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้คอมพิวเตอร์ pattern ของสิ่งที่ต้องการให้มันรู้จัก เรียกว่า "back propagation" ในการฝึก feed-forward Neural Networks จะมีการใช้อัลกอริทึมแบบ back-propagation เพื่อใช้ในการปรับปรุง Network Weight หลังจากได้รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว output จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดก็จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่า weight ต่อไป



รูป 2.1 การทำงานของ Neuron<sup>2</sup>

<sup>2</sup> <https://coladev.com/machine-learning/neural-network/2017/02/22/neural-network-basic>

Feed-Forward Neural Network จะแบ่ง Neuron ออกเป็นกลุ่มๆ โดยแต่ละกลุ่มจะเรียกเป็น Layer โดยข้อมูลที่เข้ามาจะไหลไปในทิศทางเดียวไม่ไหลย้อนกลับจาก Layer หนึ่งสู่อีก Layer หนึ่ง



รูป 2.2 Neural Network<sup>3</sup>

### ส่วนประกอบของ Neural Network

**Input Layer** ชั้นนี้จะเป็นข้อมูล input จำนวนของโหนด ขึ้นอยู่กับจำนวนของ input ว่ามีข้อมูลอะไรบ้างที่นำเข้ามาคิดใน โมเดล (ปกติแล้วจะเรียกปัจจัยที่นำมาวิเคราะห์ว่า feature)


**Hidden Layer** เป็นชั้นที่อยู่ระหว่าง Input layer และ Output layer ซึ่งมีผลอย่างมากต่อประสิทธิภาพในการเรียนรู้ของ โมเดล ซึ่ง hidden layer จะมีกี่ชั้นก็ได้ แล้วแต่ละชั้นจะมีจำนวนของ Neuron เท่าไหร่ก็ได้เช่นกัน ในการเพิ่มจำนวนชั้นและจำนวน neuron จะส่งผลต่อการทำงานของ โมเดล

**Output Layer** ชั้นที่จะนำเอาข้อมูลจากการคำนวณไปใช้ จำนวนของโหนดในชั้นนี้นั้นจะขึ้นอยู่กับรูปแบบของ output ที่จะนำไปใช้

<sup>3</sup> <https://coladev.com/machine-learning/neural-network/2017/02/22/neural-network-basic>

### 2.1.2 Deep Learning

Deep Learning คือ Artificial Neuron Networks แต่ความแตกต่างระหว่าง Deep Learning กับ ANN คือระดับ hidden layer ที่ใน Deep Learning มี hidden layer มากกว่าใน ANN โดยหลักการของ Deep Learning จะเป็น ANN ที่มีโหนดหลายๆชั้น และจะใช้การประมวลผลแบบขนาน (Parallel Processing) ทำให้สามารถประมวลผลได้ครั้งละจำนวนมาก ช่วยให้การเรียนรู้ของเครื่องสามารถให้ผลลัพธ์ในการตัดสินใจและคาดการณ์ได้ดีมากยิ่งขึ้น



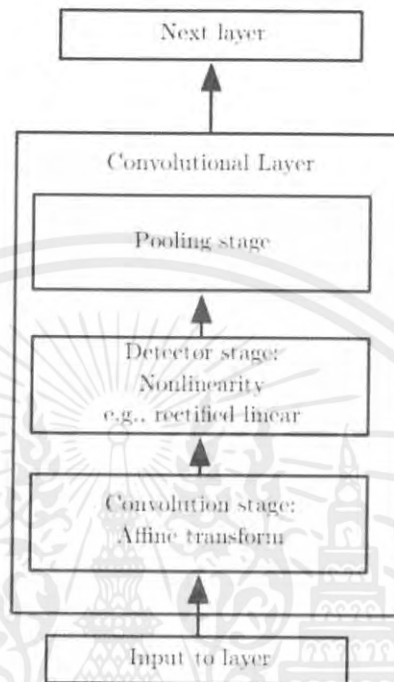
### 2.1.3 Convolutional Neural Network (CNN)

Convolutional Neural Network คือ Artificial Neural Network (ANN) ประเภทหนึ่งที่ใช้ Convolutional layers เพื่อกรองข้อมูลที่เป็นประโยชน์จากอินพุต การทำงานนั้นยังรวมถึงการรวมข้อมูลอินพุต (feature map) เข้ากับ Convolution kernel (filter) เพื่อสร้าง feature map ขึ้นมา โดย Filter ใน convolutional layers (conv layers) จะได้รับการปรับเปลี่ยนตามพารามิเตอร์เพื่อดึงข้อมูลที่เป็นประโยชน์ที่สุด Convolutional networks จะปรับ โดยอัตโนมัติเพื่อที่จะหาคุณลักษณะที่ดีที่สุด

มีการประยุกต์ใช้งาน Convolutional Neural Network ในด้านต่างๆมากมาย เช่น ด้านรูปภาพ (image recognition, image classification, video labeling, text analysis) หรือทางด้านเสียงพูด (speech recognition, natural language processing, text classification) รวมไปถึงระบบ AI ที่ล้ำยุค เช่น หุ่นยนต์, ผู้ช่วยเสมือน และ รถยนต์ไร้คนขับ

<sup>4</sup> <https://www.kdnuggets.com/2017/05/deep-learning-big-deal.html>

## องค์ประกอบของ Convolutional Neural Network



รูป 2.4 แสดงองค์ประกอบของ Convolutional Neural Network layer<sup>5</sup>

จากรูป จะเห็นได้ว่าใน 1 layer ประกอบไปด้วย 3 ส่วนใหญ่ๆ คือ

### 1. Convolution stage

ในขั้นตอนนี้จะสร้าง Sliding window(Filter) มาสแกนรูป input เพื่อทำ Feature map (ทำการสแกนรูปเพื่อแยกองค์ประกอบของรูป ออกมา เช่น ขอบ สี รูปทรง เป็นต้น)

### 2. Detector stage

ขั้นนี้จะทำหน้าที่รับ output จาก ข้อ 1 แปลงให้อยู่ในรูปของ nonlinear โดยใช้ activation เช่น Rectified Linear Units (ReLU)

<sup>5</sup> <https://medium.com/@thebear19/neural-network-101-cnn-with-tensorflow-fd5d515e979b>

### 3. Pooling stage

Pooling ทำหน้าที่ resize ข้อมูลให้ขนาดเล็กลงโดยที่รายละเอียดของ input ยังครบถ้วนเหมือนเดิม หลักการทำงานขั้นตอนนี้คล้ายกับ 1. แต่ต่างกันว่า output ที่ได้จะมีขนาดเล็กลง โดย Pooling มีประโยชน์ในเรื่องเพิ่มความไวในการคำนวณ และแก้ปัญหา overfitting

#### 2.1.4 Faster R-CNN

Faster R-CNN คือการนำ Selective Search มารวมไว้ใน Neural Network เดียวกัน ซึ่งมีส่วนประกอบหลัก 3 ส่วนคือ

- 1) ส่วนฐานที่ทำหน้าที่สกัด feature
- 2) ส่วน Region Proposal Network (RPN) ทำหน้าที่สกัดบริเวณที่น่าจะเป็นวัตถุจาก feature map
- 3) ส่วนจำแนกประเภท ที่นำ feature map และ region ที่ได้จาก RPN มาประมวลผลโดยทำ ROI pooling เพื่อตอบว่าบริเวณใดของภาพมีวัตถุอยู่



รูป 2.5 แสดงโครงสร้างของFaster R-CNN<sup>6</sup>

<sup>6</sup> <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>

## 2.2 TensorFlow

TensorFlow เป็น open source library ที่พัฒนาโดย google สำหรับอำนวยความสะดวกในการใช้งาน machine learning เช่น KERAS API สำหรับการ เทรนและการสร้างโมเดล, Eager execution สำหรับวิเคราะห์และ debug model ฯลฯ โดยสามารถเลือกประมวลผลได้ในหลายๆ platform (CPUs, GPUs, TPUs) ช่วยให้การทำงานด้าน machine learning และ deep learning เป็นไปได้อย่างและรวดเร็วยิ่งขึ้น

### TensorFlow Object detection API

TensorFlow Object detection API เป็น framework ที่สร้างบน TensorFlow อีกทีหนึ่ง ถูกพัฒนาเพื่อให้คนทั่วไปสร้าง โมเดล เทรน โมเดล และใช้งาน โมเดล ในด้านการตรวจจับวัตถุ ได้สะดวกและง่าย โดยมีการรวบรวม pre-trained model จาก datasets (COCO, Kitti, Open Images, AVA, iNaturalist Species) พร้อมแสดงการเปรียบเทียบ Speed และ mAP (Mean Average Precision) ของแต่ละ โมเดล เพื่อให้ นักพัฒนาและคนทั่วไป สามารถเลือกใช้โมเดลที่เหมาะสมกับงานตัวเอง

#### COCO-trained models

Model name	Speed (ms)	COCO mAP[^1]	Outputs
ssd_mobilenet_v1_coco	30	21	Boxes
ssd_mobilenet_v1_0.75_depth_coco	26	18	Boxes
ssd_mobilenet_v1_quantized_coco	29	18	Boxes
ssd_mobilenet_v1_0.75_depth_quantized_coco	29	16	Boxes
ssd_mobilenet_v1_ppm_coco	26	20	Boxes
ssd_mobilenet_v1_fpn_coco	56	32	Boxes
ssd_resnet_50_fpn_coco	76	35	Boxes
ssd_mobilenet_v2_coco	31	22	Boxes

#### Open Images-trained models

Model name	Speed (ms)	Open images mAP@0.5[^2]	Outputs
faster_rcnn_inception_resnet_v1_310k_1.0	72.7	27	Boxes
faster_rcnn_inception_resnet_v1_310k_1.0_quant	34.7		Boxes

#### iNaturalist Species-trained models

Model name	Speed (ms)	Pascal mAP@0.5	Outputs
faster_rcnn_inception_v1_101_fpn	365	5.8	Boxes
faster_rcnn_resnet50_fpn	366	5.5	Boxes

#### Kitti-trained models

Model name	Speed (ms)	Pascal mAP@0.5	Outputs
faster_rcnn_inception_v1_101_fpn	79	8.7	Boxes

#### AVA v2.1 trained models

Model name	Speed (ms)	Pascal mAP@0.5	Outputs
faster_rcnn_inception_v1_101_fpn_v2.1	93	11	Boxes

รูป 2.6 แสดงการเปรียบเทียบ pre-trained model (COCO, Kitti, Open Images, AVA, iNaturalist)<sup>7</sup>

โดยผู้จัดทำได้ใช้ TensorFlow Object detection API ในการช่วยสร้างโมเดล โดยใช้การ Configure CNNs จาก Pre-trained Model ของ Faster R-CNN Resnet-101 มาปรับใช้และสร้างโมเดลสำหรับตรวจจับและจำแนกยานพาหนะขึ้นมา


<sup>7</sup> [https://github.com/tensorflow/models/blob/master/research/object\\_detection/g3doc/detection\\_model\\_zoo.md](https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/detection_model_zoo.md)

## 2.3 Image Enhancement

คือ กระบวนการปรับปรุงภาพให้มีคุณภาพที่ดีขึ้น โดยไม่มีการเปลี่ยนแปลงเนื้อหาภาพไปจากเดิม มีหลากหลายวิธีเช่น การลดนอยซ์ของภาพ การปรับภาพให้คมขึ้น การปรับค่าความเข้มแสง ฯลฯ

### 1) Image Filtering

เป็นการนำภาพผ่านตัวกรองสัญญาณ เพื่อกรองข้อมูลที่สนใจหรือลดคุณสมบัติบางอย่างของภาพ เพื่อให้ภาพมีคุณสมบัติตามที่เรากำลังต้องการ



Blur

Median

Edge-Detect

High-Pass


Dilate

Erode

รูป 2.7 แสดงการปรับ Image Filtering<sup>8</sup>

### 2) Sharpening Spatial Filter

วัตถุประสงค์หลักของ sharpening คือต้องการเพิ่มรายละเอียดหรือปรับปรุงรายละเอียดของภาพ ดำเนินการได้โดย Differentiation ใน Spatial Domain

รูป 2.8 แสดงการปรับ Contrast Adjustment<sup>9</sup>

<sup>8</sup> [https://www.cs.ubc.ca/~lsigal/425\\_2018/Lecture4.pdf](https://www.cs.ubc.ca/~lsigal/425_2018/Lecture4.pdf)

<sup>9</sup> <http://staff.cs.psu.ac.th/sathit/DigitalImage/Sharpening%20Spatial%20Filters.pdf>


### 3) Brightness and Contrast Adjustments

Brightness ใช้ในการปรับค่าความสว่างของภาพ การปรับค่าความสว่างของภาพจะมีประสิทธิภาพในกรณีที่โทนของภาพทั้งภาพนั้นออกมาในแนวที่มีมืดหรือสว่างจนเกินไป และ Contrast คือระดับความแตกต่างระหว่างส่วนที่สว่างกับส่วนที่มีมืดของตัวภาพการเพิ่มค่า Contrast นั้นจะส่งผลให้ความแตกต่างดังกล่าวข้างต้นนั้นชัดเจนยิ่งขึ้นซึ่งทำให้ภาพนั้นมีความคมชัดมากขึ้นด้วย

สมการของค่า Brightness และค่า Contrast เป็นดังสมการข้างล่าง

$$g(x) = \alpha f(x) + \beta$$

$\alpha$  คือค่าของ Contrast และ  $\beta$  คือค่าของ Brightness ใช้ในการควบคุมความคมชัดและความสว่าง



รูป 2.9 แสดงการปรับ Brightness and Contrast<sup>10</sup>

### 4) Bilateral Filtering

หลักการของ bilateral filtering นั้นจะคำนวณ pixel โดยถ่วงน้ำหนักจากทั้ง space (ระยะห่าง ยิ่งห่างมากยิ่งมีน้ำหนักน้อย) และ range (ความแตกต่างของสี ยิ่งแตกต่างมากยิ่งมีน้ำหนักน้อย) การถ่วงน้ำหนักที่ใช้ จะใช้ Gaussian distribution ทั้ง space และ range



รูป 2.10 แสดงการปรับ Deblurring<sup>11</sup>

<sup>10</sup> <https://hcig1.wordpress.com/2017/02/16/brightness-and-contrast-adjustments-with-opencv/>

<sup>11</sup> [https://docs.opencv.org/3.1.0/d4/d13/tutorial\\_py\\_filtering.html](https://docs.opencv.org/3.1.0/d4/d13/tutorial_py_filtering.html)

## 2.4 Mean Average Precision (mAP)

mAP เป็นเครื่องมือที่ใช้ตรวจสอบความแม่นยำของNeuron Network Model นิยมใช้กับการตรวจสอบแบบMulticlass(หลายๆคลาส) โดยใช้การตรวจสอบจากผลลัพธ์ของการทาย (Predict) กับความจริง (Ground truth) โดยศัพท์ที่ควรรู้สำหรับการตรวจสอบดังกล่าวคือ

**True Positive (TP)** คือสิ่งที่ทายว่ามันมีจริง และเฉลยบอกว่ามีจริง

**True Negative (TN)** คือสิ่งที่ทายว่ามันไม่มีจริง และเฉลยก็บอกว่ามันไม่มีจริง

**False Positive (FP)** คือสิ่งที่ทายว่ามันมีจริง แต่เฉลยก็บอกว่ามันไม่มีจริง(มันไม่ถูก)

**False Negative (FN)** คือสิ่งที่ทายว่ามันไม่มีจริง แต่เฉลยก็บอกว่ามันมีจริง (มันไม่ถูก)

**Precision** คืออัตราการทำถูกต้อง การทายทั้งหมดเขียนเป็นสมการได้ดังนี้

$$\text{precision} = \frac{tp}{tp + fp} = \frac{tp}{n} \quad (2.1)$$

**Recall** คือจำนวนที่ทายถูกต้องจำนวนของความจริงทั้งหมดเขียนเป็นสมการได้ดังนี้

$$\text{recall} = \frac{tp}{tp + fn} \quad (2.2)$$

**Accuracy** คือความแม่นยำของระบบทั้งหมด เขียนเป็นสมการได้ดังนี้

$$\text{Accuracy} = \frac{tp + tn}{tp + tn + fp + fn} \quad (2.3)$$

**Intersection over Union (IoU)** คือตัวเปรียบเทียบตำแหน่งการ Box ของ ground truth กับ predict ในโมเดลที่ต้องการผลลัพธ์เป็นการแยกประเภทหรือระบุตำแหน่ง เพื่อเป็นตัวชี้วัดความถูกต้องเบื้องต้นจากการกำหนด Threshold ก่อนใช้ข้อมูลดังกล่าวคำนวณหาค่า AP



รูป 2.12 แสดงการคำนวณหาค่า Intersection over Union (IoU)<sup>12</sup>

**Average Precision (AP)** คือ ตัววัดประสิทธิภาพของคลาสจากการคำนวณพื้นที่ใต้กราฟจาก Precision และ Recall

$$\sum_{k=1}^N P(k) \Delta r(k)$$

(2.4)

โดย mAP เกิดจากการนำ AP ของทุกๆคลาสมาค่าเฉลี่ยได้ผลลัพธ์เป็นตัวแทนวัดความถูกต้องให้กับ โมเดลทั้งหมด

<sup>12</sup> <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>

## 2.5 งานวิจัยที่เกี่ยวข้อง

ในโครงการนี้เลือกใช้ Artificial Neural Network (ANN) จำพวก Convolutional Neural Network (CNN) ในการทำ Feature extraction สำหรับการจำแนกประเภทของรถ อ้างอิงมาจากงานวิจัย Traffic video surveillance: Vehicle detection and classification โดยงานวิจัยนี้เป็นการตรวจจับแยกประเภทและนับจำนวนยานพาหนะจากกล้อง CCTV ด้วยการเปรียบเทียบ 3 วิธีคือ ANN, SVM และ k-NN ซึ่งพิสูจน์ว่า ANN ให้ผลลัพธ์ความแม่นยำสูงที่สุดและใช้เวลาในการประมวลผลน้อยที่สุด

Classification Method	ANN and HOG	SVM and PCA [20]	KNN and PCA [21]
Total No. of vehicles	150	150	150
Correct Classification	134	119	128
Classification Accuracy(%)	<b>89.3</b>	<b>79.8</b>	<b>85.3</b>

Classification Method	Frames per second	Computational time (second)
ANN	65	0.015
SVM	42	0.023
k-NN	28	0.03

รูป 2.13 เปรียบเทียบความถูกต้องในการจำแนกประเภทยานพาหนะด้วยวิธีที่ต่างกัน

และในโครงการนี้ได้เลือกใช้ Faster R-CNN Resnet-101 เป็นโมเดล อ้างอิงจากงานวิจัย Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors โดยงานวิจัยนี้ได้นำโมเดล 3 ตัว ซึ่งคือ Faster RCNN, R-FCN และ SSD มาเปรียบเทียบกันด้วย Input ที่มีความละเอียด 300p ในด้านความถูกต้อง ความเร็ว ทรัพยากรที่ใช้ ซึ่งใช้ COCO dataset ในการเทรนและทดสอบ และได้พิสูจน์ว่า Faster R-CNN Resnet-101 เป็นโมเดลที่เร็ว ไม่ใช้ทรัพยากรมากจนเกินไป และมีความแม่นยำสูง




Figure 4: Accuracy stratified by object size, meta-architecture and feature extractor. We fix the image resolution to 300.

รูป 2.14 แสดงการเปรียบเทียบค่า mAP (Mean Average Precision) ของแต่ละโมเดล

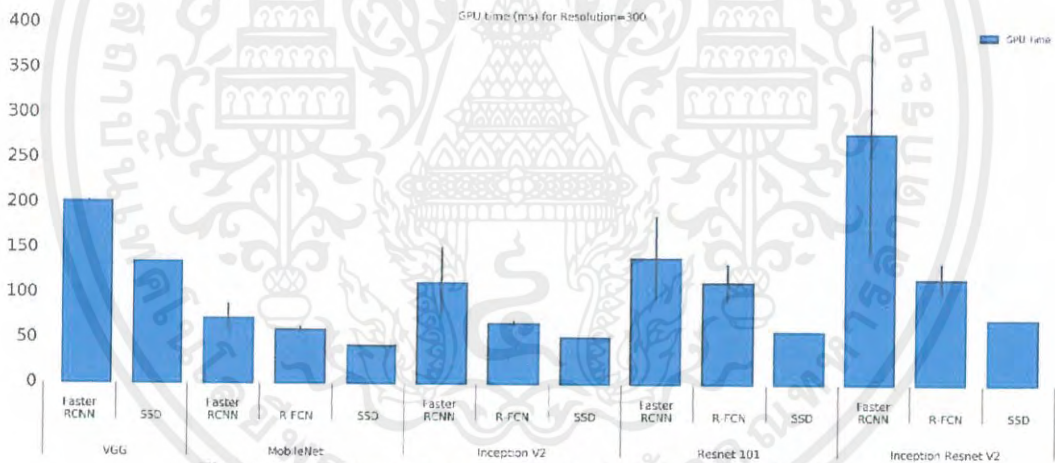


Figure 7: GPU time (milliseconds) for each model, for image resolution of 300.

รูป 2.15 แสดงค่า GPU time ของแต่ละโมเดลที่ใช้

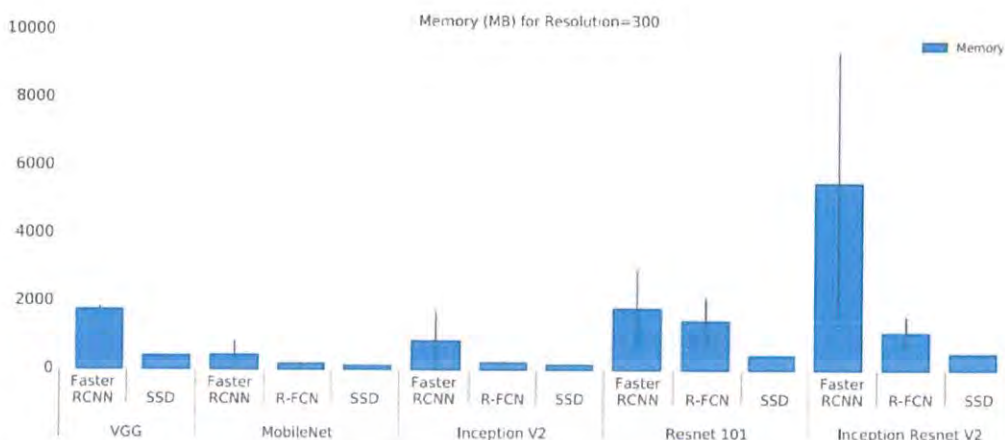


Figure 9: Memory (Mb) usage for each model. Note that we measure total memory usage rather than peak memory usage. Moreover, we include all data points corresponding to the low-resolution models here. The error bars reflect variance in memory usage by using different numbers of proposals for the Faster R-CNN and R-FCN models (which leads to the seemingly considerable variance in the Faster-RCNN with Inception Resnet bar).

### รูป 2.16 แสดงค่า Memory usage ของแต่ละโมเดลที่ใช้

และในโครงการนี้ได้เลือกใช้ จำนวน Datasets ที่ใช้ในการเทรนโมเดลจำนวนประมาณ 4000 ตัวอย่าง อ้างอิงจากงานวิจัย Weakly-supervised Vehicle Detection and Classification by Convolutional Neural Network โดยงานวิจัยนี้ได้้นำได้มีการจำแนกประเภทยานพาหนะเป็น 5 ประเภท คือ Sedan, Van, Bus, Truck และ Bike โดยใช้จำนวน Datasets ในการเทรนโมเดลจำนวน 4,097 ตัวอย่าง และได้ค่าประสิทธิภาพในการจำแนกยานพาหนะ mAP = 98.79% ค่าความแม่นยำ 98.28% และค่าประสิทธิภาพในการตรวจจับยานพาหนะ mAP = 85.26%

Table 2. Vehicle dataset from traffic surveillance

	Total	Sedan	Van	Bus	Truck	Bike
Training	4097	943	868	856	787	643
Testing	2051	426	412	462	421	330
Total	6142	1369	1280	1318	1280	973

### รูป 2.17 แสดงจำนวน Datasets ในการ Training และ Testing

และในโครงการนี้ได้เลือกใช้ วิธีการ Image Processing 4 วิธี คือ 1.Image Blurring (Bilateral Filtering) 2.Grayscale 3.Sharpening 4.Brightness and Contrast Adjustments อ้างอิงจาก งานวิจัย Road Damage Detection and Classification with Faster R-CNN เป็นงานวิจัยที่เกี่ยวกับ ตรวจจับและแยกประเภทรอยแตกของพื้นถนน โดยใช้ Faster R-CNN และได้มีการใช้วิธี Image Processing ต่างๆ มาใช้กับ Datasets ก่อนที่จะนำไปเทรนให้โมเดล ผลปรากฏว่า ค่า Mean F1-Score ของโมเดลมีค่ามากขึ้น

TABLE I  
COMPARISON OF RESULTS FOR DIFFERENT METHODS ON THE TEST DATA.

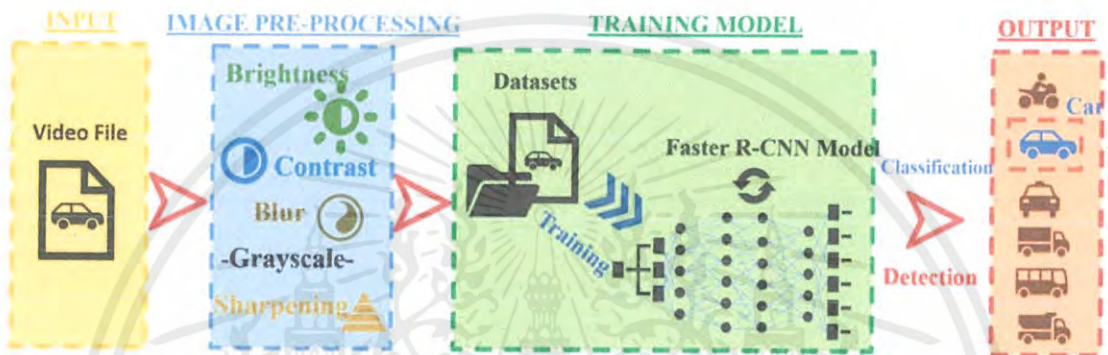
$N_{feat}$	ResNet-101	ResNet-152	ResNet-152	ResNet-152	ResNet-152
Faster R-CNN	✓	✓	✓	✓	✓
parameter adjustment			✓	✓	✓
data augmentation				✓	✓
fine-tuning					✓
Mean F1-Score	0.6099	0.6174	0.6218	0.6242	<b>0.6255</b>

รูป 2.18 แสดงค่า Mean F1-Score ที่ได้ในแต่ละวิธีของงานวิจัย

## บทที่ 3

### การออกแบบและพัฒนา

#### 3.1 ภาพรวมการทำงานภายในระบบ



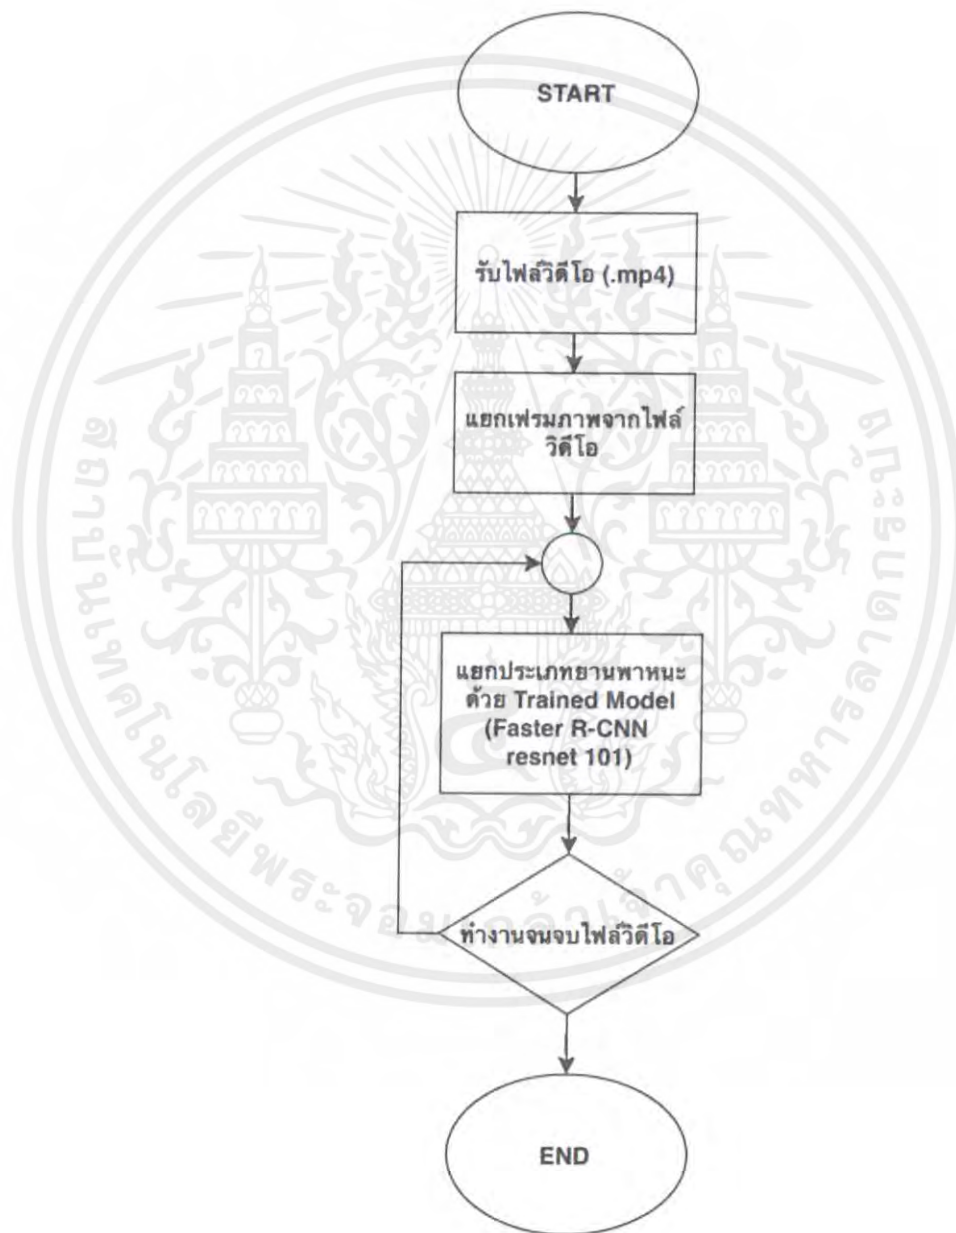
รูป 3.1 System Diagram

จาก Diagram สามารถแบ่งระบบเป็น 4 ส่วนหลัก ได้แก่ 1.Input 2.Image Pre-Processing 3.Training Model 4.Output

- 1) Input เป็นไฟล์วิดีโอ 3 ช่วงเวลา (7.30-8.00 น. ,14.00-14.30 น. และ 16.00.-17.00 น.)
- 2) Image Pre-Processing ใช้ 5 วิธี คือ 1. Brightness Adjustments 2. Contrast Adjustments 3. Image Blurring (Bilateral Filtering) 4. Grayscale และ 5. Sharpening
- 3) Training Model นำ Dataset ที่ Image Pre-Processing แล้ว มาแบ่งออกเป็น 2 ส่วนคือ Train Datasets และ Test Datasets โดย Train Datasets จะนำไปสร้าง Faster R-CNN และ Test Datasets จะนำไป Evaluate Model หลังจากนั้นนำไป Detection และ Classification เพื่อตรวจหาและแยกประเภทยานพาหนะ
- 4) Output เป็นผลลัพธ์ที่ได้จากการ Detection และ Classification โดยจะได้ตำแหน่งของยานพาหนะและประเภทของยานพาหนะ (รถจักรยานยนต์, รถยนต์, รถแท็กซี่, รถบรรทุก, รถสองแถว และ รถตู้)

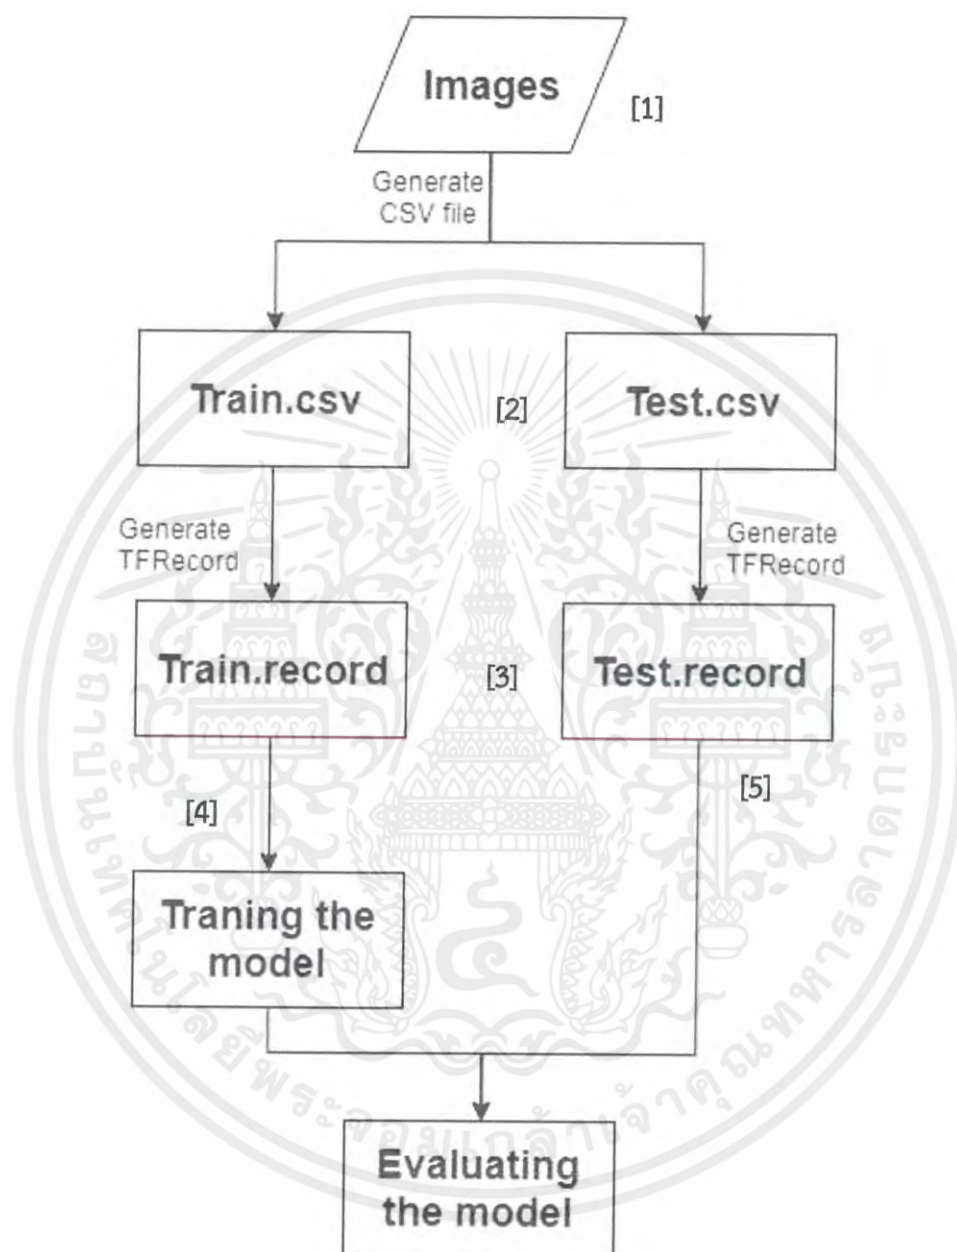
### 3.2 การออกแบบขั้นตอนการทำงานของระบบ

นำไฟล์วิดีโอ แยกเป็นเฟรมจากนั้นส่งไปทำ Image Pre-Processing เพื่อปรับคุณภาพของภาพให้ดีขึ้น แล้วส่งเข้าโมเดล Faster R-CNN ที่สร้างไว้ จะได้เฟรมรูปภาพที่มี Box Detection พร้อมแสดงประเภทของยานพาหนะที่ตรวจจับได้ ซึ่งมีขั้นตอนการทำงานดังนี้



รูป 3.2 Flowchart แสดงการทำงานของโปรแกรมโดยรวม

## 3.2.1) ขั้นตอนการ Train Model Fast R-CNN



รูป 3.3 Flowchart แสดงการขั้นตอนการ Train Model

1) เลือกภาพที่ใช้เป็น Datasets ให้กับโมเดลโดยการกำหนด Box และ Label คลาส ให้กับยานพาหนะที่ตรวจจับได้บนภาพ โดยเก็บไว้ในรูปแบบ csv ที่มีHeader คือ filename, width, height, class, xmin, ymin, xmax และ ymax

- filename: ชื่อไฟล์ของภาพจากการ Box และ Label สำหรับอ้างอิง ข้อมูลภาพ
- width: ความกว้างของภาพ (pixels)
- height: ความสูงของภาพ (pixels)
- class: ประเภทของยานพาหนะ (Car, Motorcycle, Taxi, Pick-up Truck, Van และ Truck)
- xmin, ymin, xmax, ymax: พิกัดที่ Box ยานพาหนะอ้างอิงจากภาพ

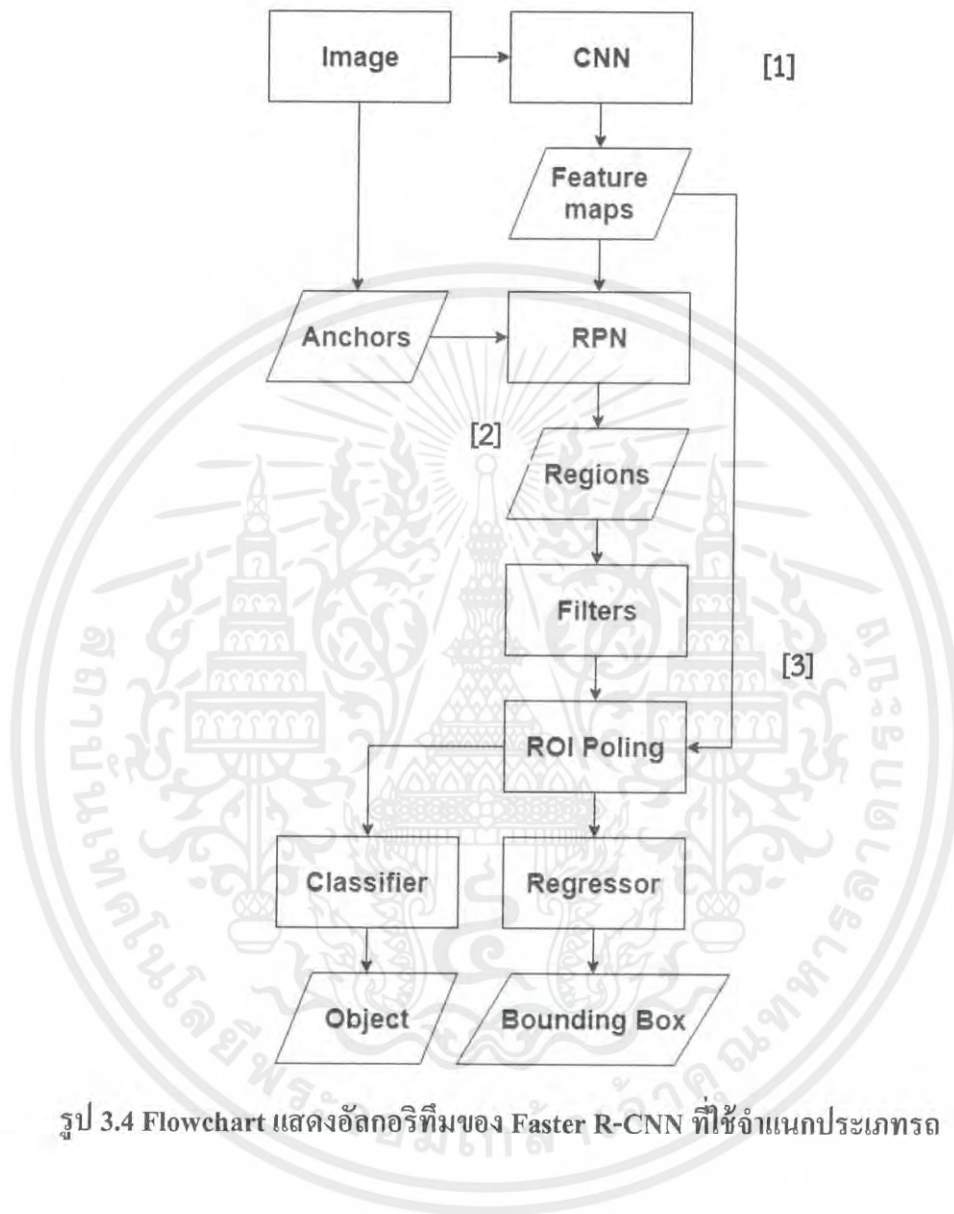
2) แบ่ง Datasets เป็น 2 กลุ่มคือ Test และ Train โดยกลุ่ม Train เป็นข้อมูลเพื่อให้โมเดล เรียนรู้และ กลุ่ม Test เป็นตัวทดสอบความถูกต้อง โดยแบ่งสัดส่วน Train:Test เป็น 80:20 ด้วยวิธีการ Split Test

3) กลุ่มข้อมูล Train และ Test จะถูกแปลงให้อยู่ในรูปแบบ tfrecord เป็นรูปแบบสำหรับ รวมไฟล์หลายๆข้อมูลจาก csv และ Images เพื่อให้ง่ายต่อการอ่าน โดย TensorFlow Model

4) Train ข้อมูลให้โมเดลด้วย Train.record

5) ประเมินผลความถูกต้องของข้อมูลด้วย Test.record เรื่อยๆจนได้โมเดลที่พอใจ

### 3.2.2) การทำงานของ Faster R-CNN ที่ใช้จำแนกประเภท



รูป 3.4 Flowchart แสดงอัลกอริทึมของ Faster R-CNN ที่ใช้จำแนกประเภท

- 1) Convolutional Neural Network (CNN) ทำหน้าที่สกัด feature สร้างเป็น feature maps ส่งไปยัง ROI Poling และ RPN
- 2) Region Proposal Network (RPN) ทำหน้าที่สกัดเอาบริเวณที่น่าจะเป็นวัตถุจาก feature maps
- 3) จำแนกประเภทโดยนำ feature maps และ region ที่ได้มาประมวลผลโดยทำ ROI pooling เพื่อตอบว่าบริเวณใดของภาพมีวัตถุอยู่

## บทที่ 4

### การทดลอง

หลังจากออกแบบการทำงานภายในระบบแล้ว การทดลองในบทนี้จะเป็นการทดลองเกี่ยวกับ Datasets ที่นำไปใช้ในโมเดล Faster R-CNN Resnet-101 แบ่งออกเป็น

- 1) การทดลองเกี่ยวกับการเลือกใช้ Datasets
- 2) การทดลองเกี่ยวกับการเลือกใช้ความละเอียดของ Input
- 3) การทดลองเกี่ยวกับการเลือกใช้ Image Pre-Processing

โดยใช้ Configuration จาก “Faster R-CNN with Resnet-101 (v1) configured for the Oxford-IIT Pet Dataset”

#### 4.1 การทดลองเกี่ยวกับการเลือกใช้ Datasets

##### 4.1.1 จุดประสงค์

เพื่อเลือกความละเอียดของภาพ Datasets ที่เหมาะสมสำหรับใช้เทรนให้โมเดล Faster R-CNN

##### 4.1.2 วิธีการทดลอง

- 1) เลือกใช้ datasets ในการเทรนให้โมเดลที่มีความละเอียด 854x480 (480p) เปรียบเทียบกับ Datasets ที่มีความละเอียด 426x240 (240p) โดยใช้จำนวน Datasets เท่ากัน (2358 index) แบ่งเป็น 6 คลาส (Car, Motorcycle, Taxi, Pick-up Truck, Van และ Truck) เทรนด้วย Model Faster R-CNN และจำนวนรอบในการเทรนเหมือนกัน (976 steps)



ก)

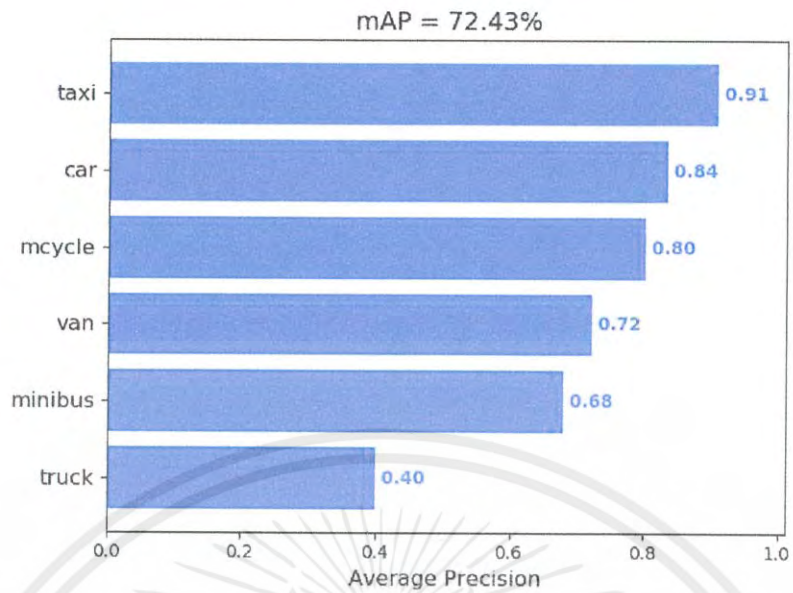
ข)

รูป 4.1 รูปเปรียบเทียบผลลัพธ์ที่ใช้ Datasets และ Input ที่มีความละเอียดต่างกัน


ก) ใช้ Datasets ในการเทรนที่มีความละเอียด 240p และรับ Input ความละเอียด 240p

ข) ใช้ Datasets ในการเทรนที่มีความละเอียด 480p และรับ Input ความละเอียด 480p

2) หาค่า mAP (Mean Average Precision) ของทั้งสองโมเดลจากการใช้ชุดข้อมูลทดสอบเดียวกัน(ภาพเดียวกันแต่ความละเอียดของภาพต่างกันตามโมเดลที่ใช้ทดสอบ)



รูป 4.2 แสดง AP และ mAP ของโมเดลความละเอียด 240p



รูป 4.3 แสดง AP และ mAP ของโมเดลความละเอียด 480p

### 3) เปรียบเทียบค่า mAP ของทั้งสองโมเดล(240p,480p)

ตาราง 4.1 แสดงตารางการเปรียบเทียบ mAP ระหว่างโมเดล 240p และ 480p

MODEL	AP						mAP
	Car	Mycle	Taxi	Pick-up Truck	Van	Truck	
240p	83.51%	80.15%	90.81%	67.96%	72.13%	40.00%	72.43%
480p	86.10%	82.81%	92.59%	86.94%	100.00%	80.40%	<b>88.14%</b>

จากภาพ4.2 โมเดล240p mAP = 72.43%

จากภาพ4.3 โมเดล480p mAP = 88.14%

จึงสรุปได้ว่าคุณภาพของ datasets มีผลต่อการจำแนกคลาสของ โมเดล ยิ่งข้อมูล  
เทรนมีคุณภาพสูง ยิ่งทำให้ Model มีประสิทธิภาพในการจำแนกคลาสได้ดี

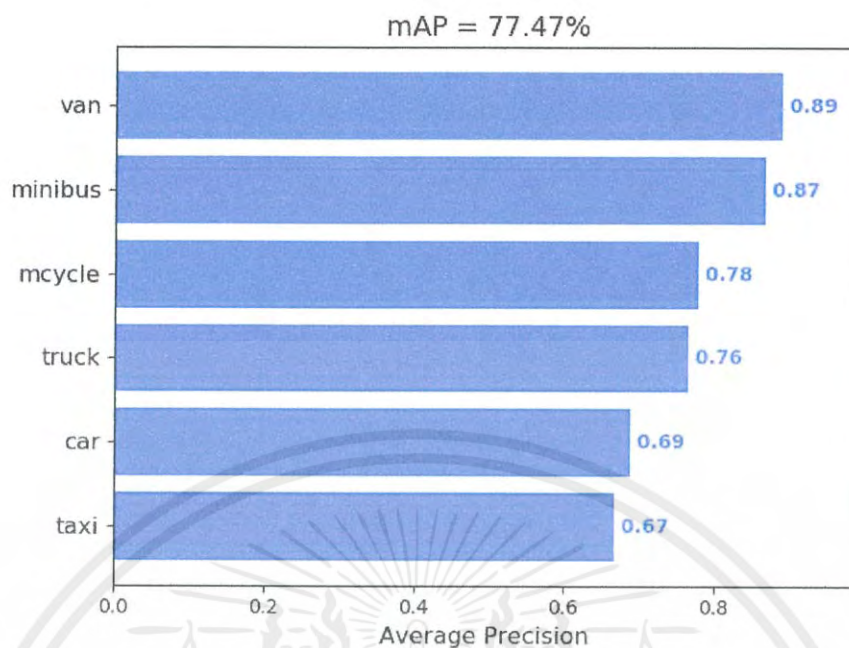
## 4.2 การทดสอบเกี่ยวกับการเลือกใช้ความละเอียดของ Input

### 4.2.1 จุดประสงค์

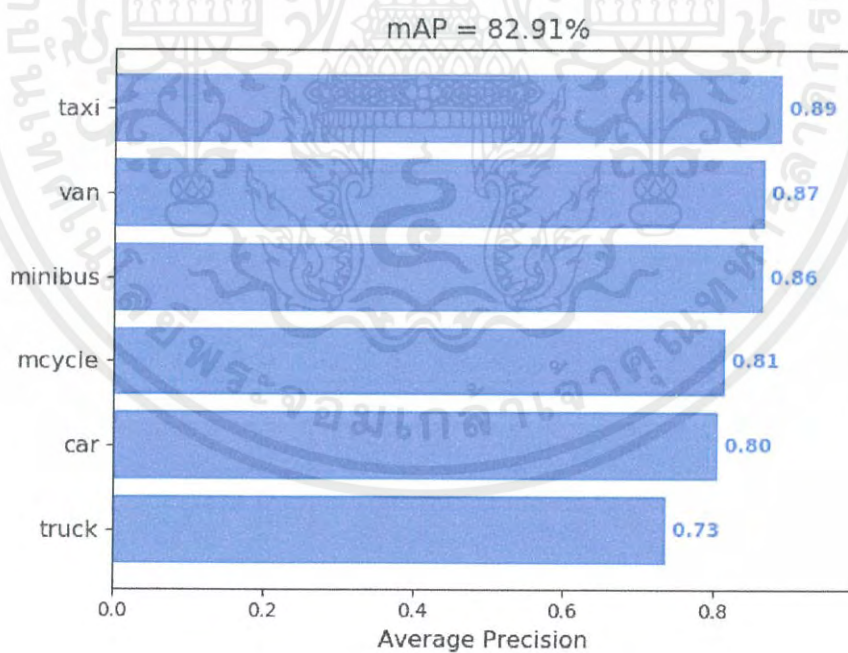
เพื่อเปรียบเทียบและเลือกใช้ความละเอียด Input ที่เหมาะสมสำหรับนำไปใช้งานจริง

### 4.2.2 วิธีการทดลอง

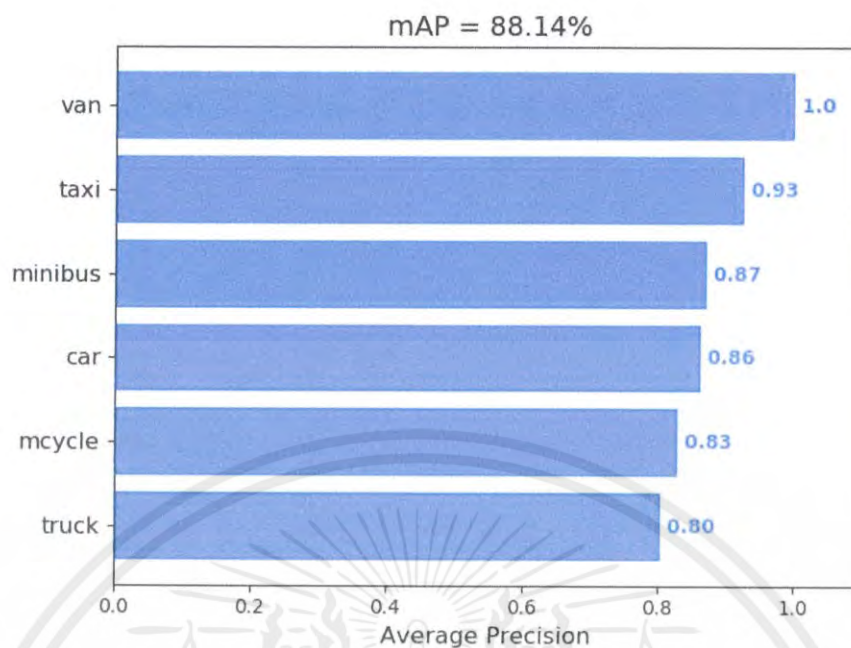
- 1) ใช้ Input ที่มีความละเอียด 480p, 240p และ 144p ทดสอบกับ Model 480 (จากการทดลองที่ 4.1)



รูป 4.4 แสดง AP และ mAP ของ Input144p ด้วย Model 480p



รูป 4.5 แสดง AP และ mAP ของ Input240p ด้วย Model 480p



รูป 4.6 แสดง AP และ mAP ของ Input 480p ด้วย Model 480p

2) เปรียบเทียบค่า mAP ของทั้งสาม Model

ตารางที่ 4.2 แสดงตารางเปรียบเทียบ AP (Average Precision) และ mAP (Mean Average Precision) ของแต่ละความละเอียดภาพของ Input (144p, 240p, 480p)

Input Resolution	AP						mAP
	Car	Mcycle	Taxi	Pick-up Truck	Van	Truck	
144p	68.65%	77.65%	66.67%	86.61%	76.36%	<b>88.89%</b>	77.47%
240p	80.49%	81.41%	<b>88.89%</b>	86.49%	86.67%	73.50%	82.91%
480p	<b>86.10%</b>	<b>82.81%</b>	86.94%	<b>92.59%</b>	<b>100.00%</b>	80.40%	<b>88.14%</b>

จากรูป 4.6 แสดงให้เห็นว่ายิ่ง Input มีความละเอียดของภาพสูง ยิ่งสามารถแยกประเภทของยานพาหนะได้ดียิ่งขึ้น แต่สำหรับภาพความละเอียดต่ำ (144p,240p) จะสามารถแยกประเภทของยานพาหนะได้ไม่ดีเท่ากับภาพที่มีความละเอียดสูง

จากการทดลองที่ 4.1 และ 4.2 ทำให้สรุปได้ว่าการใช้ Datasets ในการเทรน โมเดล และ Input ที่มีความละเอียด 480p จะสามารถแยกประเภทของยานพาหนะได้ดีที่สุด

### 4.3 การทดลองเกี่ยวกับการเลือกใช้ Image Pre-Processing

วิธีการ Image Pre-Processing ที่เลือกใช้มีดังต่อไปนี้ 1. Brightness Adjustments 2. Contrast Adjustments 3. Image Blurring (Bilateral Filtering) 4. Grayscale และ 5. Sharpening

#### 4.3.1 จุดประสงค์

เพื่อเลือกวิธีการ Image Pre-Processing และค่าพารามิเตอร์ที่เหมาะสมสำหรับใช้เทรนให้ โมเดล Faster R-CNN

#### 4.3.2 วิธีการทดลอง

- 1) เลือกวิธีการ Image Pre-Processing แต่ละวิธีมาใช้กับ Datasets ที่จะเทรนให้กับ โมเดล ด้วย Datasets ในการเทรน โมเดล และ Input ที่มีความละเอียด 854x480 (480p) โดยมีค่าพารามิเตอร์ จำนวน Datasets และ Test Input ดังต่อไปนี้
  - Brightness Adjustments ปรับค่าพารามิเตอร์ 5 ค่า คือ  $\beta = 30, 50, 70, 90, 110$
  - Contrast Adjustments ปรับค่าพารามิเตอร์ 5 ค่า คือ  $\alpha = 1.1, 1.2, 1.3, 1.4, 1.5$
  - Bilateral Filtering ปรับค่าพารามิเตอร์ 5 ค่า คือ diameter(d) = 6,9,12,15,18
  - Grayscale ปรับค่าสี RGB เป็น Grayscale
  - Sharpening ใช้ kernel =  $\begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$

และใช้จำนวน Datasets เท่ากัน (2358 index) และจำนวนรอบในการเทรนเท่ากัน (20,000 steps)



รูป 4.7 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering) (1)Original, (2)Blur6, (3)Blur9, (4)Blur12, (5)Blur15, (6)Blur18



รูป 4.8 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Brightness Adjustments (1)Original, (2)Brightness30, (3) Brightness50, (4) Brightness70, (5) Brightness90, (6) Brightness110



รูป 4.9 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Contrast Adjustments (1)Original, (2)Contrast1.1, (3) Contrast1.2, (4) Contrast1.3, (5) Contrast1.4, (6) Contrast1.5



รูป 4.10 แสดงตัวอย่าง Datasets หลัง Pre-Processing ด้วยวิธี Grayscale และ Sharpening (1) Original, (2) Grayscale, (3) Sharpening

ตารางที่ 4.3 แสดงตัวอย่าง Confusion Matrix จากโมเดลที่ Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering,  $d=6$ )

		Predicted							N/A
		mcycle	car	taxi	pick-up truck	van	truck		
Actual	mcycle	50	0	0	0	0	0	0	24
	car	1	23	3	1	1	1	1	79
	taxi	0	0	17	0	0	0	0	2
	pick-up truck	0	0	0	14	0	0	0	0
	van	0	0	0	0	9	0	0	0
	truck	0	0	0	0	0	0	8	0
	N/A	1	0	0	0	0	0	1	0

ตารางที่ 4.4 แสดงค่า TP, TN, FP, FN, Accuracy, Precision และ Recall ของแต่ละคลาสของ โมเดลที่ใช้ Pre-Processing ด้วยวิธี Blurring (Bilateral Filtering,  $d=6$ )

	TP	TN	FP	FN	Recall(%)	Precision(%)	Accuracy(%)
mcycle	50	71	2	24	67.60	96.62	83.30
car	23	98	0	86	21.11	100.00	58.50
taxi	17	104	3	2	89.50	85.00	96.00
pick-up truck	14	107	1	0	100.00	93.33	99.20
van	9	112	1	0	100.00	90.00	99.20
truck	8	113	2	0	100.00	80.00	98.40
allclass	50	71	3	111	79.70	90.80	51.50

2) เปรียบเทียบค่า Precision ของแต่ละโมเดล ได้ผลลัพธ์ดังต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้ สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใด ๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.5 แสดงค่า Precision ของแต่ละโมเดล

Precision							
Method	mcycle	car	taxi	pick-up truck	van	truck	mAP
original	96.67	98.44	94.12	93.33	88.89	89.89	<b>93.39</b>
gray	92.31	100.00	91.67	93.33	90.00	77.78	90.85
sharpening	86.21	93.85	100.00	93.33	56.25	85.71	<b>85.89</b>
contrast1.1	96.67	100.00	100.00	87.50	72.73	88.89	90.96
contrast1.2	91.67	95.65	100.00	93.33	88.89	80.00	91.59
contrast1.3	96.15	97.30	100.00	93.33	88.89	88.89	<b>94.09</b>
contrast1.4	96.77	88.57	88.24	93.33	88.89	80.00	89.30
contrast1.5	97.30	94.59	100.00	93.33	88.89	87.50	<b>93.60</b>
brightness30	97.56	98.11	100.00	93.33	81.82	88.89	93.29
brightness50	94.74	97.18	100.00	93.33	88.89	88.89	<b>93.84</b>
brightness70	92.31	91.84	100.00	87.50	88.89	80.00	90.11
brightness90	92.00	97.73	94.44	93.33	88.89	97.50	92.32
brightness110	64.95	95.52	94.44	93.33	88.89	85.71	<b>87.14</b>
blur6	96.15	100.00	85.00	93.33	90.00	80.00	90.75
blur9	95.00	100.00	94.44	93.33	88.89	80.00	91.94
blur12	95.00	96.23	90.00	93.33	88.89	88.89	92.06
blur15	91.30	100.00	94.74	93.33	90.00	80.00	91.56
blur18	87.76	96.15	100.00	93.33	69.23	70.00	<b>86.08</b>

ตารางที่ 4.6 แสดงการเปรียบเทียบค่า Precision ของแต่ละโมเดล

Compared Precision							
Method	mcycle	car	taxi	pick-up truck	van	truck	mAP
gray	-4.36	1.56	-2.45	0.00	1.11	-12.11	-2.54
sharpening	-10.46	-4.59	5.88	0.00	<b>-32.64</b>	-4.18	<b>-7.50</b>
contrast1.1	0.00	1.56	5.88	-5.83	-16.16	-1.00	-2.43
contrast1.2	-5.00	-2.79	5.88	0.00	0.00	-9.89	-1.80
contrast1.3	-0.52	-1.14	5.88	0.00	0.00	-1.00	<b>0.70</b>
contrast1.4	0.10	-9.87	-5.88	0.00	0.00	-9.89	-4.09
contrast1.5	0.63	-3.85	5.88	0.00	0.00	-2.39	<b>0.21</b>
brightness30	0.89	-0.33	5.88	0.00	-7.07	-1.00	-0.10
brightness50	-1.93	-1.26	5.88	0.00	0.00	-1.00	<b>0.45</b>
brightness70	-4.36	-6.60	5.88	-5.83	0.00	-9.89	-3.28
brightness90	-4.67	-0.71	0.32	0.00	0.00	<b>7.61</b>	-1.07
brightness110	<b>-31.72</b>	-2.92	0.32	0.00	0.00	-4.18	<b>-6.25</b>
blur6	-0.52	1.56	-9.12	0.00	1.11	-9.89	-2.64
blur9	-1.67	1.56	0.32	0.00	0.00	-9.89	-1.45
blur12	-1.67	-2.21	-4.12	0.00	0.00	-1.00	-1.33
blur15	-5.37	1.56	0.62	0.00	1.11	-9.89	-1.83
blur18	-8.91	-2.29	5.88	0.00	-19.66	-19.89	<b>-7.31</b>

จากตารางที่ 4.5 และ 4.6

วิธี Image Pre-Processing ที่ให้ค่า mAP สูงสุด 3 อันดับแรกได้แก่

- 1) Contrast Adjustments ( $\alpha=1.3$ ) ให้ค่า mAP = 94.09% เพิ่มมาจากโมเดลเดิม 0.70%
- 2) Brightness Adjustments ( $\beta=50$ ) ให้ค่า mAP = 93.84% เพิ่มมาจากโมเดลเดิม 0.45%
- 3) Contrast Adjustments ( $\alpha=1.5$ ) ให้ค่า mAP = 93.60% เพิ่มมาจากโมเดลเดิม 0.21%

วิธี Image Pre-Processing ที่ให้ค่า mAP แ่ลง 3 อันดับแรกได้แก่

- 1) Sharpening ให้ค่า mAP = 90.85% ลดลงจากโมเดลเดิม 7.50%
- 2) Brightness Adjustments ( $\beta=130$ ) ให้ค่า mAP = 90.85% ลดลงจากโมเดลเดิม 7.31%
- 3) Bilateral Filtering (d=18) ให้ค่า mAP = 90.85% ลดลงจากโมเดลเดิม 6.25%

วิธี Image Pre-Processing ที่ส่งผลต่อการเปลี่ยนแปลงค่า AP ของคลาสที่โดดเด่นได้แก่

- 1) Sharpening ให้ค่า AP ของรถตู้ (truck) ลดลง 32.64%
- 2) Brightness Adjustments ( $\beta=110$ ) ให้ค่า AP ของรถจักรยานยนต์ (mecycle) ลดลง 31.72%
- 3) Brightness Adjustments ( $\beta=90$ ) ให้ค่า AP ของรถบรรทุก (truck) เพิ่มขึ้น 7.61%

3) เปรียบเทียบค่า Recall ของแต่ละโมเดล ได้ผลลัพธ์ดังต่อไปนี้

ตารางที่ 4.7 แสดงค่า Recall ของแต่ละโมเดล

Recall							
Method	mcycle	car	taxi	pick-up truck	van	truck	mAR
original	39.19	57.80	84.21	100.00	88.89	100.00	78.35
gray	64.86	61.47	57.89	100.00	100.00	87.50	78.62
sharpening	33.78	55.96	78.95	100.00	100.00	75.00	73.95
contrast1.1	39.19	19.27	84.21	100.00	88.89	100.00	71.93
contrast1.2	74.32	60.55	78.95	100.00	88.89	100.00	83.79
contrast1.3	33.78	66.06	89.47	100.00	88.89	100.00	79.70
contrast1.4	40.54	28.44	78.95	100.00	88.89	100.00	72.80
contrast1.5	48.65	32.11	78.95	100.00	88.89	87.50	72.68
brightness30	54.05	47.71	89.47	100.00	100.00	100.00	81.87
brightness50	48.65	63.30	84.21	100.00	88.89	100.00	80.84
brightness70	48.65	52.29	73.68	100.00	88.89	100.00	77.25
brightness90	62.16	39.46	89.47	100.00	88.89	87.50	77.91
brightness110	85.14	58.72	89.47	100.00	88.89	75.00	82.87
blur6	67.57	21.10	89.47	100.00	100.00	100.00	79.69
blur9	51.35	46.79	94.74	100.00	88.89	100.00	80.29
blur12	51.35	46.79	94.74	100.00	88.89	100.00	80.29
blur15	56.76	38.53	94.74	100.00	100.00	100.00	81.67
blur18	58.11	68.81	94.74	100.00	100.00	87.50	84.86

ตารางที่ 4.8 แสดงการเปรียบเทียบค่า Recall ของแต่ละโมเดล

Compared Recall							
Method	mcycle	car	taxi	pick-up truck	van	truck	mAR
gray	25.67	3.67	-26.32	0.00	11.11	-12.50	0.27
sharpening	-5.41	-1.84	-5.26	0.00	11.11	-25.00	-4.40
contrast1.1	0.00	-38.53	0.00	0.00	0.00	0.00	-6.42
contrast1.2	35.13	2.75	-5.26	0.00	0.00	0.00	5.44
contrast1.3	-5.41	8.26	5.26	0.00	0.00	0.00	1.35
contrast1.4	1.35	-29.36	-5.26	0.00	0.00	0.00	-5.55
contrast1.5	9.46	-25.69	-5.26	0.00	0.00	-12.50	-5.67
brightness30	14.86	-10.09	5.26	0.00	11.11	0.00	3.52
brightness50	9.46	5.50	0.00	0.00	0.00	0.00	2.49
brightness70	9.46	-5.51	-10.53	0.00	0.00	0.00	-1.10
brightness90	22.97	-18.34	5.26	0.00	0.00	-12.50	-0.44
brightness110	45.95	0.92	5.26	0.00	0.00	-25.00	4.52
blur6	28.38	-36.70	5.26	0.00	11.11	0.00	1.34
blur9	12.16	-0.92	5.26	0.00	0.00	0.00	2.75
blur12	12.16	-11.01	10.53	0.00	0.00	0.00	1.94
blur15	17.57	-19.27	10.53	0.00	11.11	0.00	3.32
blur18	18.92	11.01	10.53	0.00	11.11	-12.50	6.51

### จากตารางที่ 4.7 และ 4.8

วิธี Image Pre-Processing ที่ให้ค่า Recall สูงสุด 3 อันดับแรกได้แก่

- 1) Bilateral Filtering ( $d=18$ ) ให้ค่า Recall = 84.86% เพิ่มมาจากโมเดลเดิม 6.51%
- 2) Contrast Adjustments ( $\alpha=1.2$ ) ให้ค่า Recall = 83.79% เพิ่มมาจากโมเดลเดิม 5.44%
- 3) Brightness Adjustments ( $\beta=110$ ) ให้ค่า Recall = 82.87% เพิ่มมาจากโมเดลเดิม 4.52%

วิธี Image Pre-Processing ที่ให้ค่า Recall แ่ลง 3 อันดับแรกได้แก่

- 1) Contrast Adjustments ( $\alpha=1.1$ ) ให้ค่า Recall = 71.93% ลดลงจากโมเดลเดิม 6.42%
- 2) Contrast Adjustments ( $\alpha=1.5$ ) ให้ค่า Recall = 72.68% ลดลงจากโมเดลเดิม 5.67%
- 3) Contrast Adjustments ( $\alpha=1.4$ ) ให้ค่า Recall = 72.80% ลดลงจากโมเดลเดิม 5.55%

วิธี Image Pre-Processing ที่ส่งผลต่อการเปลี่ยนแปลงค่า Recall ของคลาสที่โดดเด่นได้แก่

- 1) Brightness Adjustments ( $\beta=110$ ) ให้ค่า Recall ของรถจักรยานยนต์ (mcycle) เพิ่มขึ้น 45.95%
- 2) Contrast Adjustments ( $\alpha=1.1$ ) ให้ค่า Recall ของรถยนต์ (car) ลดลง 38.53%
- 3) Bilateral Filtering ( $d=6$ ) ให้ค่า Recall ของรถยนต์ (car) ลดลง 36.70%

4) เปรียบเทียบค่า Accuracy ของแต่ละโมเดล ได้ผลลัพธ์ดังต่อไปนี้  
 ตารางที่ 4.9 แสดงค่า Accuracy ของแต่ละโมเดล

Accuracy	
Method	Accuracy
original	59.47
gray	65.55
sharpening	53.94
contrast1.1	40.68
contrast1.2	69.17
contrast1.3	61.02
contrast1.4	44.54
contrast1.5	48.94
brightness30	59.32
brightness50	63.71
brightness70	57.08
brightness90	56.49
brightness110	65.90
blur6	51.45
blur9	62.29
blur12	57.32
blur15	55.58
blur18	67.76

ตารางที่ 4.10 แสดงการเปรียบเทียบค่า Accuracy ของแต่ละโมเดล

Compared Accuracy	
Method	Accuracy
gray	6.08
sharpening	-5.53
contrast1.1	-18.79
contrast1.2	9.70
contrast1.3	1.55
contrast1.4	-14.93
contrast1.5	-10.53
brightness30	-0.15
brightness50	4.24
brightness70	-2.39
brightness90	-2.98
brightness110	6.43
blur6	-8.02
blur9	2.82
blur12	-2.15
blur15	-3.89
blur18	8.29

เอกสารนี้เป็นเอกสารที่สงวนไว้ สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
 ไม่ว่าจะกรณีใด ๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

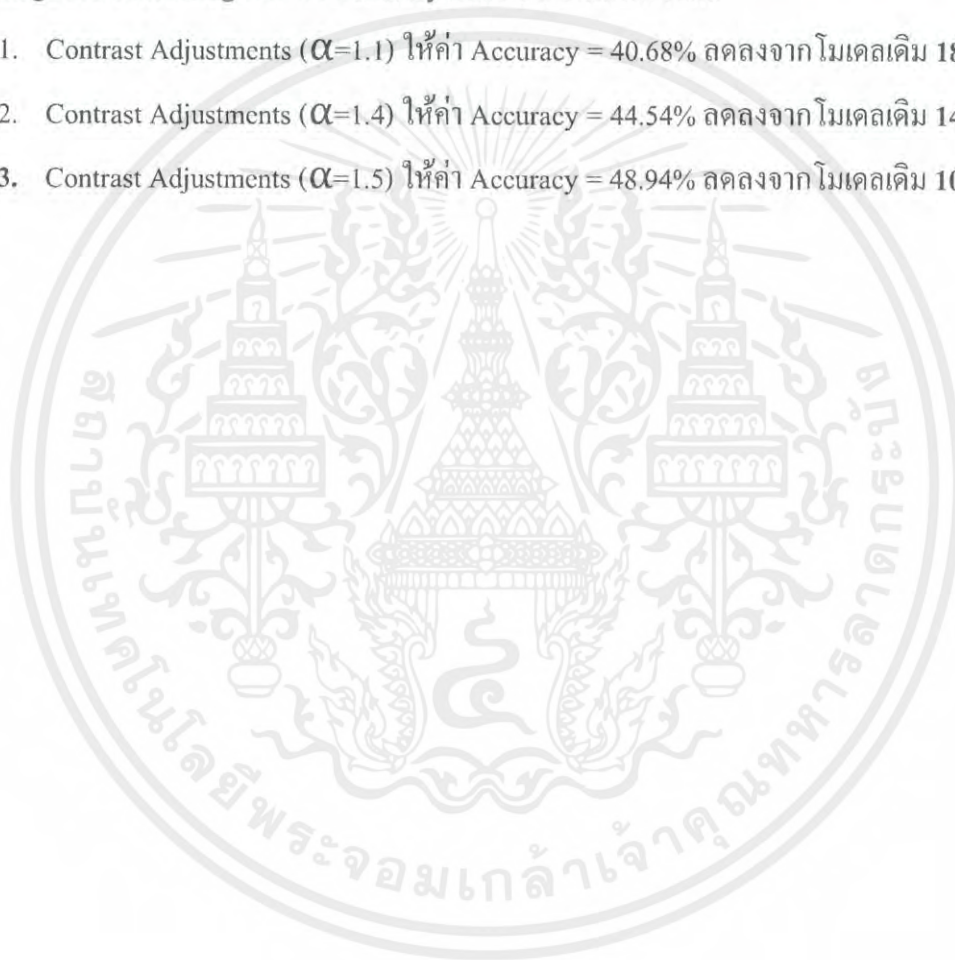
### จากตารางที่ 4.9 และ 4.10

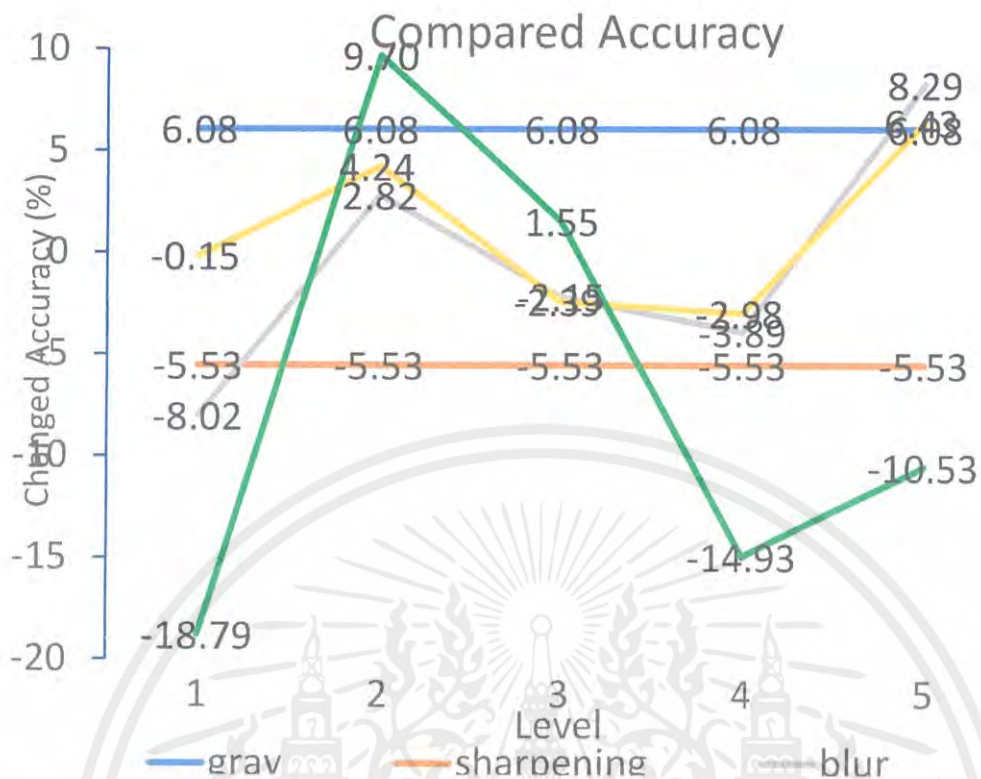
วิธี Image Pre-Processing ที่ให้ค่า Accuracy สูงสุด 3 อันดับแรกได้แก่

1. Contrast Adjustments ( $\alpha=1.2$ ) ให้ค่า Accuracy = 69.17% เพิ่มมาจาก โมเดลเดิม 9.70%
2. Bilateral Filtering ( $d=18$ ) ให้ค่า Accuracy = 67.76% เพิ่มมาจาก โมเดลเดิม 8.29%
3. Brightness Adjustments ( $\beta=110$ ) ให้ค่า Accuracy = 65.90% เพิ่มมาจาก โมเดลเดิม 6.43%

วิธี Image Pre-Processing ที่ให้ค่า Accuracy แย่ลง 3 อันดับแรกได้แก่

1. Contrast Adjustments ( $\alpha=1.1$ ) ให้ค่า Accuracy = 40.68% ลดลงจาก โมเดลเดิม 18.79%
2. Contrast Adjustments ( $\alpha=1.4$ ) ให้ค่า Accuracy = 44.54% ลดลงจาก โมเดลเดิม 14.93%
3. Contrast Adjustments ( $\alpha=1.5$ ) ให้ค่า Accuracy = 48.94% ลดลงจาก โมเดลเดิม 10.53%





รูป 4.11 กราฟแสดงการเปรียบเทียบค่า Accuracy ของแต่ละโมเดล

แม้ใช้วิธีการ Pre-Processing เดียวกัน แต่การปรับสัมประสิทธิ์ มาก-น้อย ส่งผลต่อโมเดลต่างกัน ไม่ได้เป็นไปในทิศทางเดียวกันเสมอไป สังเกตได้จากตารางที่ 4.10

1) จากกราฟเส้นสีเขียว (Contrast) เมื่อปรับเพิ่มค่า  $\alpha$  ค่า Accuracy เพิ่ม/ลด ในลักษณะฟันปลา (กราฟ Sin) ที่มีจุด Peak สูงสุด และต่ำสุดหากเทียบกับกราฟเส้นอื่น (Max = 9.70, Min = -18.79) จากตารางที่ 4.6 และ 4.8 จะสังเกตได้ว่า Contrast ที่สูงมากไป ( $\alpha > 1.3$ ) จะมีผลกระทบมากในการตรวจจับและแยกประเภทใน Class Car ค่าสัมประสิทธิ์ที่เหมาะสมสำหรับปรับใช้ใช้คือ  $\alpha = 1.2$

2) จากกราฟเส้นสีส้ม (Brightness) มีลักษณะกราฟ ในลักษณะฟันปลาเล็กๆที่มีความเป็นเปลี่ยนแปลงในทางที่ดีของแต่ละ Level ไม่มากนัก จากตารางที่ 4.6 และ 4.8 จะสังเกตได้ว่าค่า Precision และ Recall แปรผกผันกัน เห็นได้ชัดจากโมเดลสามารถแยกประเภท Motorcycle ได้ดีขึ้น แต่ตรวจจับเจอ Motorcycle น้อยลง ตามค่า Brightness ที่สูงขึ้น ค่าสัมประสิทธิ์ที่เหมาะสมสำหรับปรับใช้ใช้คือ  $\beta = 50, 110$

3) จากกราฟเส้นสีเทา (Blur) มีลักษณะการแปรผกผันระหว่าง Precision และ Recall เช่นเดียวกับกับกราฟสีส้ม (Brightness) ค่าสัมประสิทธิ์ที่เหมาะสมสำหรับปรับใช้คือ  $d = 9,18$

4) จากกราฟเส้นสีน้ำเงิน (Gray scale) และสีแดง (Sharpening) ทั้งสองเป็นการปรับ filter ในลักษณะที่ไม่มีการปรับเปลี่ยนค่าสัมประสิทธิ์ ทำให้ทุกระดับมีค่าเท่ากันโดย gray scale ทำให้ accuracy เพิ่มขึ้น 6.08 % ส่วน Sharpening ทำให้ค่า Accuracy ลดลงถึง 8.02%

5) ในแต่ละวิธีการ Pre-Processing จากตารางที่ 4.11 สังเกตได้ว่าในทุกการปรับค่าสัมประสิทธิ์ Level 1 จะทำให้โมเดลมีค่า Accuracy ลดลงเสมอ และจะดีขึ้นเรื่อยๆจนถึงค่าหนึ่ง (ในช่วง Gap ระหว่าง Level 1 ถึง Level 3)

ตารางที่ 4.11 แสดงการเปรียบเทียบค่า Accuracy ของ Pre-Processing Level 1


Method	acc
contrast1.1	-18.79
brightness30	-0.15
blur6	-8.02

## 4.4 สรุปการทดลอง

จากการทดลองด้วยวิธี Pre-Processing จากการ Image Enhancement สามารถสรุปผลการทดลองได้ดังนี้

- 1) การใช้วิธี Grayscale เหมาะสมกับโมเดลที่ต้องการตรวจจับรถจักรยานยนต์เนื่องจากให้ค่า Recall เพิ่มขึ้นถึง 25.67%
- 2) การใช้วิธี Image Blurring (Bilateral Filtering) และ วิธี Brightness Adjustments เหมาะสมกับโมเดลที่ต้องการตรวจจับรถจักรยานยนต์ เนื่องจากในการปรับค่าพารามิเตอร์ทุกระดับ ทำให้ค่า Recall มีเปอร์เซ็นต์เพิ่มขึ้นเสมอ
- 3) การใช้วิธี Image Blurring (Bilateral Filtering) เหมาะสมกับโมเดลที่ต้องการตรวจจับรถแท็กซี่ เนื่องจากในการปรับค่าพารามิเตอร์ทุกระดับ ทำให้ค่า Recall มีเปอร์เซ็นต์เพิ่มขึ้นเสมอ
- 4) การใช้วิธี Contrast Adjustments ด้วยการปรับค่าพารามิเตอร์  $\alpha = 1.2$  ทำให้ค่า Accuracy โดยรวมของโมเดลเพิ่มขึ้นมากที่สุด คือ 9.70%

เนื่องด้วยการวัดผลโมเดลจาก Test Datasets ที่สุ่มมา ทำให้พบว่ายานพาหนะที่อยู่ระยะไกลจากภาพ สามารถตรวจจับได้น้อย ทำให้ค่า Accuracy ของโมเดลน้อยลงมา จากรูป 4.12 หากเน้นวัดผลเฉพาะยานพาหนะที่อยู่ระยะสายตา ประมาณ 15-20 เมตรจากกล้อง (บริเวณเส้นสีแดง) จะทำให้ค่า Accuracy เพิ่มสูงขึ้นถึง 80% ประกอบกับการใช้ปรับ Contrast Adjustments ด้วยค่าพารามิเตอร์  $\alpha = 1.2$  ทำให้ Accuracy เพิ่มสูงขึ้นถึง 86%



รูป 4.12 แสดงพื้นที่ที่โมเดลมีค่า Accuracy สูง

เอกสารนี้เป็นเอกสารที่สงวนไว้ สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใด ๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

# บทสรุปและข้อเสนอแนะ

### 5.1 บทสรุป

จากการที่ได้ทดลองใช้ Model Faster R-CNN Resnet-101 มาตรวจจับและจำแนกยานพาหนะ ได้ผลดังนี้

ความละเอียดของภาพ Datasets ที่ใช้ในการเทรนให้โมเดล และ ความละเอียดของภาพ Input ส่งผลต่อความแม่นยำในการตรวจจับและจำแนกยานพาหนะของโมเดลเป็นอย่างมาก โดยหากใช้ภาพ Datasets ที่มีความละเอียดสูงในการเทรนให้โมเดล ความแม่นยำของโมเดลในการตรวจจับและแยกประเภทยานพาหนะจะมากขึ้นตามไปด้วย เช่นเดียวกับกับความละเอียดของภาพ Input รวมไปถึงวิธีการ Image Pre-Processing ด้วย Image Enhancement เป็นอีกวิธีการที่เพิ่มประสิทธิภาพให้กับโมเดลได้

โดยโมเดลจาก Image Pre-Processing ด้วย Image Enhancement แต่ละวิธีมีข้อดีข้อเสียต่างกัน เหมาะสมกับความต้องการใช้ที่ต่างกัน เช่น หากต้องการ โมเดลที่เน้นไปที่การตรวจจับและแยกประเภท จักรยานยนต์ Grayscale, Brightness และ Blur (Bilateral Filtering) เป็นตัวเลือกที่ดี หากต้องการ โมเดลที่เน้นไปที่การตรวจจับแท็กชื่อ Blur เป็นตัวเลือกที่ดี

### 5.2 ปัญหาและอุปสรรค

- 1) การประมวลผลและ Training Model ใช้เวลานาน (GPU: NVIDIA GeForce GTX 1050 4GB) ทำให้กินระยะเวลาในการทดสอบโมเดลแต่ละตัว ไม่เหมาะกับการทำงาน Real Time
- 2) Trained Model ในตอนนี้ให้ค่าความแม่นยำยังน้อย (Accuracy = 69.17%)

### 5.3 แนวทางในการพัฒนาต่อ

#### ในด้านการเพิ่มประสิทธิภาพของโมเดล

- 1) ใช้ Image Pre-processing method หลายวิธีพร้อมกัน(ผสมกัน)
- 2) เพิ่ม Attributes ในการส่งข้อมูลเข้าโมเดล (ปัจจุบันใช้เพียงค่า Pixel ของภาพ เช่น เวลา, ค่าความเข้มแสง เป็นต้น)
- 3) แบ่งประเภทยานพาหนะให้ละเอียดกว่าเดิม

#### ในด้านการประยุกต์ใช้โมเดล

- 1) ระบบนับรถ/ตรวจจับความเร็วรถ/แยกประเภทรถ/จากกล้องวงจรปิด
- 2) ระบบค้นหาและติดตามรถต้องสงสัย
- 3) ระบบตรวจจับรถจักรยานยนต์ที่ทำผิดกฎจราจร
- 4) ระบบตรวจจับจำนวนรถแท็กซี่ตามห้างสรรพสินค้า



## บรรณานุกรม

- J. Huang, V. Rathod, C. Sun, M. Zhu, A. Korattikara, A. Fathi, I. Fischer, Z. Wojna, Y. Song, S. Guadarrama, K. Murphy, "Speed/accuracy trade-offs for modern convolutional object detectors", *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 2017.
- KB Saran, G Sreelekha, "Traffic Video Surveillance: Vehicle Detection and Classification", *International Conference on Control Communication and Computing India*, 2015.
- C. Jiang, B. Zhang, "Weakly-supervised vehicle detection and classification by convolutional neural network", *Int. Congr. Image and Sig. Proc. BioMedical Eng. and Informatics*. IEEE, pp. 570-575, 2016.
- S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks." In *IEEE Trans. Pattern Anal. Mach. Intell.* 39(6): 1137–1149 (2017)
- Wenzhe Wang, Bin Wu, Sixiong Yang, Zhixiang Wang, "Road Damage Detection and Classification with Faster R-CNN", *IEEE International Conference on Big Data*, 2018.
- ระบบกล้องโทรทัศน์วงจรปิด (cctv). [Online].  
Available: <https://www.bmatraffic.com>
- Deep Learning คืออะไร. [Online].  
Available: <https://medium.com/@athivvat>
- สรุปแนวคิด Neural Network แบบไม่มี Math. [Online].  
Available: <https://coladev.com/>

Neural Network 101: CNN with TensorFlow(cctv). [Online].

Available: <https://medium.com/@thebear19>

R-CNN, Fast R-CNN, Faster R-CNN, YOLO—Object Detection Algorithms. [Online].

Available: <https://towardsdatascience.com>

What is mAP Evaluation?. [Online].

Available: <https://medium.com/boobeejung/>

Tensorflow Object Detection API. [Online].

Available: <https://github.com/tensorflow/>

Get Started with TensorFlow. [Online].

Available: <https://www.tensorflow.org/tutorials/>

Convolutional Neural Network (CNN). [Online].

Available: <https://developer.nvidia.com/>

Convolutional Networks. [Online].

Available: <http://www.deeplearningbook.org/contents/convnets.html>