

ระบบการนับยานพาหนะแยกตามประเภทสำหรับวีดิทัศน์จรรยาจรหลายมุมมอง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2565
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Multi-Class Vehicle Counting System for Multi-View Traffic Videos



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	ระบบการนับยานพาหนะแยกตามประเภทสำหรับวีดิทัศน์
	จรรยาหลายมุมมอง
โดย	นายวิชูกร คันธินทร
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	อาจารย์ ดร.พรรณราย ศิริเจริญ
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ดร.กนกพรรณ เลิศนิพนธ์พันธุ์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณะบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(อาจารย์ ดร.พิตติพล คันธวัฒน์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(อาจารย์ ดร.พรรณราย ศิริเจริญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
(ดร.กนกพรรณ เลิศนิพนธ์พันธุ์)

..... กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.วีรพล จิรจรีต)

วิชุกร คันธินทร : ระบบการนับยานพาหนะแยกตามประเภทสำหรับวีดิทัศน์จราจร
หลายมุมมอง. (Multi-Class Vehicle Counting System for Multi-View Traffic
Videos) อ.ที่ปรึกษาหลัก : อ. ดร.พรณราย ศิริเจริญ, อ.ที่ปรึกษาร่วม : ดร.กนกพรณ
เลิศนิพนธ์พันธุ์

การบริหารจัดการการจราจรถือเป็นความท้าทายสำคัญสำหรับเมืองขนาดใหญ่ในปัจจุบัน ข้อมูลปริมาณความหนาแน่นของยานพาหนะจะมีส่วนช่วยในการวางแผนจัดการจราจร อาทิเช่น การวางแผนระยะเวลาในการเปิด-ปิดไฟจราจรให้เหมาะสมตามปริมาณความหนาแน่นของ ยานพาหนะ เป็นต้น ปัจจุบันเราใช้คนในการประเมินจำนวนยานพาหนะซึ่งเกิดความล่าช้า และ ผิดพลาด ทำให้ไม่เหมาะสมในนำข้อมูลไปใช้ในการบริหารจัดการจราจร งานวิจัยนี้นำเสนอระบบ นับแยกประเภทยานพาหนะจากวีดิทัศน์บันทึกภาพของกล้องจราจร โดยระบบจะประกอบด้วย object detection และ object tracking จากการทดสอบจะพบว่า YOLOX ทำประสิทธิภาพได้ดีกว่า YOLOv3 มากถึง 26.80% สำหรับชุดข้อมูลภาพมุมข้าง และ 8.34% สำหรับกรณีมุมมองบน เนื่องจาก YOLOX มีการแยกส่วนของ head ออกเป็น box classification และ box regression ซึ่งมีส่วนช่วยเพิ่มความแม่นยำ และ ByteTrack มีความเหมาะสมในการใช้ในการติดตาม วัตถุ object tracking อันเนื่องจาก ByteTrack สามารถในการจัดการการบดบังได้ดีกว่า Centroid track โดย ByteTrack จะการทำนายพิกัดของวัตถุที่เกิดการสูญหายขณะถูกบดบังด้วย เทคนิค kalman filter ทำให้ระบบสามารถติดตามวัตถุได้ต่อเนื่องเมื่อการบดบังสิ้นสุดลง จาก ผลการวิจัยสรุปได้ว่า การทำงานกันระหว่าง YOLOX และ ByteTrack ประกอบกับการนับแบบมี ROI จะช่วยให้ระบบคัดแยกประเภทยานพาหนะ และนับยานพาหนะตามประเภทที่มีค่าความ ผิดพลาดที่ต่ำอยู่ที่ 16.67% สำหรับวีดิทัศน์มุมข้างและ 23.40% สำหรับวีดิทัศน์มุมมองบน โดยระบบ ที่นำเสนอนี้สามารถใช้ในการช่วยติดตามดูแลสภาพจราจรในระบบขนส่งอัจฉริยะได้

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2565

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก
ลายมือชื่อ อ.ที่ปรึกษาร่วม

6370265021 : MAJOR COMPUTER SCIENCE

KEYWORD: Vehicle counting, Vehicle detection, Multi-vehicle tracking, Vehicle classification

Wichukorn Kuntintara : Multi-Class Vehicle Counting System for Multi-View Traffic Videos. Advisor: PUNNARAI SIRICHAROEN, Ph.D. Co-advisor: Kanokphan Lertniphonphan, Ph.D.

Large cities have significant challenges with traffic management. Data on vehicle density will assist authorities in managing traffic, such as planning the proper time to turn on and off traffic signals based on the amount of vehicle density, etc. Currently, we estimate the number of vehicles using humans. However, due to delays and inaccuracies, this method is unsuitable for traffic control. This research presents a vehicle classification and counting system from traffic video. The system consists of object detection and object tracking. From testing, it was found that YOLOX performs better than YOLOv3 by 26.80% for side view dataset and 8.34% for top view dataset because YOLOX has a network head separated into box classification and box regression, which contributes to an increased detection and classification accuracy, and ByteTrack outperform centroid method for object tracking, due to the ability to handle occlusion by predicting the coordinates of objects that have disappeared using kalman filter, the system can continue tracking the object once the occlusion is over. The research findings lead to the conclusion that the vehicle counting system will benefit from the synergy between YOLOX and ByteTrack with region of interest which error from system is 16.67% for side view video and 23.40% for top view video. The system can be used to monitor the traffic for intelligent transportation system.

Field of Study: Computer Science

Student's Signature

Academic Year: 2022

Advisor's Signature

Co-advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดีด้วยความกรุณาจากอาจารย์ ดร.พรรณราย ศิริเจริญ อาจารย์ที่ปรึกษาหลัก และ ดร.กนกพรรณ เลิศนิพนธ์พันธ์ อาจารย์ที่ปรึกษาร่วม กรุณาสละเวลาให้ความรู้ คำแนะนำ และตรวจสอบ การทำงานวิจัยตั้งแต่การเลือกหัวข้อวิจัย แนวทางการทำวิจัย การเลือกวิธีเผยแพร่ผลงานวิจัย ตลอดจนช่วยแก้ไขข้อบกพร่องในงานวิจัยนี้ให้เสร็จสมบูรณ์

ข้าพเจ้าขอกราบขอบพระคุณ อาจารย์ ดร.พิติพล คันธวัฒน์ และ ผู้ช่วยศาสตราจารย์ ดร.วีรพล จิรจรีด กรรมการสอบวิทยานิพนธ์ ที่ได้กรุณาสละเวลา ตรวจสอบ ชัดเกล้า และชี้แนะแนวทางให้วิทยานิพนธ์ฉบับนี้มีความถูกต้องสมบูรณ์ยิ่งขึ้น

ข้าพเจ้าขอกราบขอบพระคุณ ดร.ภาณินันท์ ไทยทัตกุล และ ดร.อรณิชา อนุชิตชาญชัย สถาบันการขนส่ง จุฬาลงกรณ์มหาวิทยาลัย ที่ให้คำปรึกษาเรื่องแนวทางการพัฒนา image processing เพื่อใช้ในการนับรถและวางแผนภาคการขนส่ง และได้รับสนับสนุนชุดข้อมูลวีดิทัศน์จาก โครงการการพัฒนาแนวทางการบริหารจัดการแหล่งกำเนิด PM2.5 ภาคการขนส่ง ในพื้นที่กรุงเทพมหานครและปริมณฑล (โครงการย่อยภายใต้แผนงานวิจัยเชิงบูรณาการด้านเทคโนโลยีเพื่อบรรเทาปัญหาฝุ่นละออง PM2.5: กรณีศึกษาพื้นที่กรุงเทพมหานครและปริมณฑล) ซึ่งได้รับทุนอุดหนุนการวิจัยจากสำนักงานการวิจัยแห่งชาติ

ท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณ คุณพ่อ คุณแม่ และครอบครัว สำหรับการให้กำลังใจในการทำวิทยานิพนธ์ รวมถึงขอขอบพระคุณผู้บังคับบัญชา เพื่อนร่วมงาน และมิตรสหาย ที่คอยช่วยเหลือและให้คำปรึกษาในด้านต่างๆที่เป็นประโยชน์ให้วิทยานิพนธ์ของข้าพเจ้าสำเร็จไปได้ด้วยดี

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

วิชูกร คันธินทร

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของงานวิจัย	1
1.3 ขอบเขตการวิจัย	1
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 ขั้นตอนการดำเนินงานวิทยานิพนธ์	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
2.1 งานวิจัยที่เกี่ยวข้องกับระบบนับจำนวนยานพาหนะ	3
2.2 YOLOv3.....	5
2.3 YOLOX	6
2.4 Centroid tracking	7
2.5 ByteTrack.....	7
บทที่ 3 แนวคิดและวิธีการวิจัย	9

3.1 ระบบนับจำนวนยานพาหนะ.....	9
3.2 ชุดข้อมูล	10
3.2.1 ชุดข้อมูลวีดิทัศน์จราจร	10
3.2.2 ชุดข้อมูลภาพ.....	11
3.3 Vehicle detection.....	12
3.4 Vehicle tracking.....	13
3.5 การกำหนดพื้นที่ ROI.....	14
3.6 Vehicle counting.....	16
บทที่ 4 การประเมินผลการวิจัย และผลการประเมินเบื้องต้น.....	18
4.1 เกณฑ์การประเมินผล.....	18
4.1.1 การตรวจจับวัตถุ (Object detection).....	18
4.1.2 การนับยานพาหนะ (Vehicle counting).....	19
4.2 ผลการทดสอบ	19
4.2.1 Vehicle detection.....	19
4.2.2 Vehicle tracking	21
4.2.3 Vehicle tracking	23
4.3 แก้ไขปรับปรุงพารามิเตอร์.....	24
บทที่ 5 บทสรุป.....	27
5.1 สรุปผลงานวิจัย.....	27
5.2 ปัญหาและข้อจำกัดที่พบ	27
5.2.1 ความสับสนในการแยกแยะยานพาหนะของ Vehicle detection.....	27
5.2.2 การสลับไอดีของยานพาหนะ	28
5.2.3 สาเหตุค่าความพลาดจากการนับของวีดิทัศน์มุมบนสูงกว่าวีดิทัศน์มุมข้าง.....	29
5.2.4 โมเดลทำประสิทธิภาพได้ดีกับวีดิทัศน์ที่เฉพาะเจาะจง	30

5.3 แนวทางการปรับปรุง	31
5.3.1 เพิ่มจำนวนยานพาหนะในชุดข้อมูล	31
5.3.2 เพิ่มการระบุทิศทางของยานพาหนะ	31
5.3.3 เพิ่มการระบุขอบเขตของถนนในการกำหนดพื้นที่ ROI	31
5.3.4 เทรน Detector เพิ่มเติมเมื่อมีการเปลี่ยนมุมมอง หรือเปลี่ยนลักษณะถนน	31
บรรณานุกรม.....	32
ประวัติผู้เขียน.....	36



สารบัญตาราง

	หน้า
ตารางที่ 1 จำนวนยานพาหนะแยกตามประเภทของแต่ละชุดข้อมูล	11
ตารางที่ 2 สรุปจำนวนยานพาหนะในวิดีโอที่สำหรับประเมินผล	17
ตารางที่ 3 ผลลัพธ์ทดสอบ object detector บนชุดข้อมูลทดสอบ.....	20
ตารางที่ 4 ผลลัพธ์ของระบบนับจำนวนยานพาหนะเปรียบเทียบระหว่าง Centroid tracking และ ByteTrack.....	22
ตารางที่ 5 ผลลัพธ์ของระบบนับจำนวนยานพาหนะโดยใช้ ByteTrack เปรียบเทียบแบบไม่มี ROI และมี ROI.....	23
ตารางที่ 6 แสดงรายละเอียดของพารามิเตอร์ที่จะทำการแก้ไขปรับปรุง.....	24
ตารางที่ 7 ค่า MAPE จากการแก้ไขปรับปรุงพารามิเตอร์ของวิดีโอที่คนมูมข้าง.....	25
ตารางที่ 8 ค่า MAPE จากการแก้ไขปรับปรุงพารามิเตอร์ของวิดีโอที่คนมูมบน	26
ตารางที่ 9 สรุปผลค่าความผิดพลาดของการนับยานพาหนะของวิดีโอที่คนมูมบน และวิดีโอที่คนมูมข้าง	29
ตารางที่ 10 จำนวนยานพาหนะที่นับผิดพลาดแยกตามประเภทของวิดีโอที่คนมูมบน	29

สารบัญรูปภาพ

	หน้า
รูปที่ 1 เปรียบเทียบสถาปัตยกรรมของ Darknet-19 (ซ้าย) และ Darknet-53 (ขวา)	6
รูปที่ 2 ความแตกต่างระหว่างส่วน Head ของ YOLOv3[15] และ YOLOX [18]	7
รูปที่ 3 ผลจากการบดบังที่มีผลต่อความเชื่อมั่นของ <i>object detector</i> [14].....	8
รูปที่ 4 แผนผังการทำงานของระบบนับจำนวนยานพาหนะ.....	9
รูปที่ 5 ตัวอย่างรูปภาพในชุดข้อมูลวีดิทัศน์จราจร	10
รูปที่ 6 ตัวอย่างการบดบังในวีดิทัศน์มุมข้าง.....	10
รูปที่ 7 ตัวอย่างรูปภาพในชุดข้อมูล	12
รูปที่ 8 พิกัดของ Bounding box ที่ถูกส่งออกจาก Vehicle detection.....	13
รูปที่ 9 แผนผังการทำงานของขั้นตอนวิธีในการหาพื้นที่ ROI.....	14
รูปที่ 10 กราฟพิกัดตามแนวแกนและค่าความเชื่อมั่นที่ใช้ในขั้นตอนวิธีในการหา ROI.....	15
รูปที่ 11 แสดงการกำหนดพื้นที่ ROI บนวีดิทัศน์มุมข้าง และมุมบน	15
รูปที่ 12 เปรียบเทียบการนับยานพาหนะแบบไม่มี ROI กับ มี ROI	16
รูปที่ 13 แสดง confusion matrix ของ YOLOX-S และ YOLOX-X.....	20
รูปที่ 14 แสดงปัญหาการตรวจจับที่ซ้ำซ้อน	21
รูปที่ 15 แสดงผลของการบดบังที่ยานพาหนะ ของ Centroid tracking	22
รูปที่ 16 แสดงผลของการบดบังที่ยานพาหนะ ของ ByteTrack	23
รูปที่ 17 เปรียบเทียบผลก่อนและหลังการแก้ไขปรับปรุงพารามิเตอร์	25
รูปที่ 18 โมเดลมีการตรวจจับบางส่วนของรถกระบะเป็นรถตู้.....	27
รูปที่ 19 โมเดลเกิดความสับสนจากยานพาหนะที่มีลักษณะคล้ายคลึงทั้งรถยนต์และรถกระบะ	28
รูปที่ 20 การสลับไอดีของรถจักรยานยนต์ที่วิ่งสวนทางกัน	28
รูปที่ 21 แสดงปัญหาการนับรถจักรยานยนต์ที่ไม่ได้อยู่บนถนนและมีจุดหยุดนิ่ง	29

- รูปที่ 22 แสดงความผิดพลาดในการนับยานพาหนะที่มีลักษณะคล้ายคลึงทั้งรถยนต์และรถกระบะ . 30
- รูปที่ 23 แสดงการเกิด False positive detection เมื่อมีการเปลี่ยนมุมมองกล้อง และถนน..... 30



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

การบริหารจัดการจราจรถือเป็นความท้าทายสำคัญสำหรับเมืองขนาดใหญ่ในปัจจุบัน โดยหน่วยงานที่เกี่ยวข้องจำเป็นต้องมีข้อมูลปริมาณยานพาหนะที่เดินทางเข้าและออกจากเมือง หรือ ปริมาณความหนาแน่นของยานพาหนะในแต่ละสี่แยกไฟแดงของเมือง เพื่อใช้ข้อมูลจำนวน ยานพาหนะในการวางแผนจัดการจราจร อาทิเช่น การปิดช่องทางจราจรในบางพื้นที่และบางช่วงเวลา เพื่อให้ยานพาหนะเดินทางเพียงทิศทางเดียว เนื่องจากในช่วงเวลานั้นของเส้นทางทางนั้นปริมาณ ยานพาหนะโดยส่วนมากอาจจะมียศทางการเดินทางเข้าเมืองเป็นหลัก หรือจะเป็นการวางแผน ระยะเวลาในการเปิด-ปิดไฟจราจรให้เหมาะสมตามปริมาณความหนาแน่นของยานพาหนะของแต่ละ ช่องจราจร

และอีกหนึ่งปัญหาสำคัญคือมลพิษทางอากาศ จากปริมาณ PM 2.5 ที่เกินค่ามาตรฐาน และ หนึ่งในปัจจัยสำคัญที่อาจจะทำให้ปริมาณ PM 2.5 เกินค่ามาตรฐานได้ มาจากควันท่อไอเสียของ ยานพาหนะที่มีการสันดาปภายใน ทำให้มีทิมวิจัยต้องการหาความสัมพันธ์ระหว่างปริมาณ PM 2.5 กับ ปริมาณยานพาหนะแต่ละประเภทในแต่ละช่วงเวลาของวัน โดยผลการศึกษาครั้งนี้จะมีส่วนช่วยใน บริหารจัดการให้มีการเดินทางบางประเภทในบางช่วงเวลา หรือบางพื้นที่ เพื่อจะสามารถลดปริมาณ PM 2.5 ได้

ในปัจจุบันการนับปริมาณยานพาหนะแต่ละประเภทใช้วิธีการใช้คนในการนับจากวิดีโอที่คนจาก กล้องจราจร ซึ่งต้องใช้เวลา และอาจจะเกิดความผิดพลาดขึ้นได้ เนื่องจากในแต่ละวินาทีจะ ยานพาหนะผ่านเคลื่อนที่ผ่านกล้องจราจรได้มากกว่าหนึ่งคัน และอาจจะมีหลายประเภท และ ยานพาหนะบางคันอาจจะวิ่งผ่านกล้องจราจรด้วยระยะเวลาที่สั้น การนับโดยใช้คนอาจจะเกิดความ ผิดพลาดในการนับจำนวนได้ง่าย

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อพัฒนาระบบคัดแยกประเภทยานพาหนะ และนับยานพาหนะตามประเภทเป็นจำนวน ทั้งหมด 6 ประเภท ได้แก่ รถโดยสาร รถยนต์ รถจักรยานยนต์ รถกระบะ รถบรรทุก และรถตู้ จากวิดีโอ ที่บันทึกภาพของกล้องจราจร

1.3 ขอบเขตการวิจัย

1.3.1 งานวิจัยนี้ศึกษาวิธีการในการจำแนกประเภทของยานพาหนะจากวิดีโอที่บันทึกภาพ ของกล้องจราจร โดยจำแนกออกเป็น 6 ประเภทดังนี้ รถโดยสาร รถยนต์ รถจักรยานยนต์ รถกระบะ รถบรรทุก และรถตู้

1.3.2 วิดีทัศน์บันทึกภาพของกล้องจราจรเกิดขึ้นในช่วงเวลาที่มีความสว่างเพียงพอ และสภาพอากาศเหมาะสมต่อการจำแนกประเภทของยานพาหนะด้วยบุคคล

1.3.3 งานวิจัยนี้จะศึกษาวิธีในการนับยานพาหนะ โดยไม่ได้แยกแยะทิศทางของการเคลื่อนที่ของยานพาหนะ

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 ได้ระบบนับยานพาหนะแยกตามประเภทจากวิดีโอทัศน์บันทึกภาพของกล้องจราจร

1.4.2 ลดงานของบุคคลในองค์กร และลดผิดพลาดของบุคคล

1.4.3 นำผลลัพธ์จากการนับแต่ละประเภทไปใช้สำหรับการพิจารณาการประมาณค่าฝุ่น PM2.5

1.5 ขั้นตอนการดำเนินงานวิทยานิพนธ์

ขั้นตอนการดำเนินการ	2565					2566				
	มิ.ย.- ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.	พ.ค.
ทบทวนวรรณกรรม			→							
รวบรวมชุดข้อมูล		→								
สอน object detector		→								
พัฒนาระบบนับจำนวนยานพาหนะ			→							
เขียนโครงร่างวิทยานิพนธ์				→						
สอบโครงร่างวิทยานิพนธ์			X							
ปรับปรุงประสิทธิภาพ								→		
เขียนเล่มวิทยานิพนธ์										→
สอบวิทยานิพนธ์										X

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ระบบขนส่งและจราจรอัจฉริยะ (Intelligent Transportation System หรือ ITS) [1] เป็นระบบที่ถูกพัฒนาเพื่อนำไปใช้ในการเพิ่มผลผลิตภาพของการขนส่งและจราจร หรือจะเป็นการเข้ามาช่วยลดผลกระทบต่อสิ่งแวดล้อมจากการขนส่งและจราจร ITS จะเป็นการรวมกันของเทคโนโลยีขั้นสูง เทคโนโลยีด้านการสื่อสาร ตัวรับรู้ ตัวควบคุมและคณิตศาสตร์ขั้นสูงเข้าด้วยกัน ในปัจจุบัน ITS เข้ามามีบทบาทในการเพิ่มประสิทธิภาพการบริหารการจราจรในเมืองใหญ่มากขึ้น โดยเฉพาะการนำข้อมูลความหนาแน่นของรถในแต่ละสี่แยกไฟแดงมากำหนดระยะเวลาในการเปิดปิดไฟแดง [2] แทนการกำหนดระยะเวลาแบบที่เป็นการตั้งค่าคงที่ ซึ่งอาจจะไม่สอดคล้องกับสภาพการจราจรในแต่ละช่วงเวลา โดยในงานวิจัยก่อนหน้ามีความพยายามในการจะพัฒนาระบบ ITS โดยใช้ทั้งฮาร์ดแวร์ และซอฟต์แวร์ เข้ามาช่วยในการนับจำนวนยานพาหนะเพื่อวัดปริมาณความหนาแน่นของสภาพจราจร อาทิ เช่น Manikonda, Yerrapragada และ Annasamudram [3] นำเทคโนโลยี RFID เข้ามาใช้นับจำนวนยานพาหนะ และหาความเร็วของเฉลี่ย เพื่อใช้ในการวางแผนการจราจรภาพรวมของเมือง หรือ จะเป็นการนำ Computer vision [2] เข้ามาช่วยวัดความหนาแน่นของรถในแต่ละสี่แยกเพื่อกำหนดระยะเวลาในการเปิดปิดไฟแดงของแต่ละทิศทางทางรถ โดยจะกำหนดเวลาให้สอดคล้องกับปริมาณความหนาแน่น เมื่อเปรียบเทียบกับระบบที่ใช้ฮาร์ดแวร์กับซอฟต์แวร์ ก็จะพบว่าระบบที่ใช้ฮาร์ดแวร์จะให้ความถูกต้องของการนับจำนวนยานพาหนะที่สูง แต่ก็มีค่าใช้จ่ายที่สูง และไม่สามารถจำแนกประเภทของยานพาหนะได้ ในทางตรงกันข้ามระบบที่ใช้ซอฟต์แวร์มีต้นทุนที่ต่ำกว่า และง่ายในการนำไปใช้ร่วมกับวิดิทัศน์ของกล้องจราจร ซึ่งมีการติดตั้งอยู่แล้วตามสี่แยกไฟแดง

2.1 งานวิจัยที่เกี่ยวข้องกับระบบนับจำนวนยานพาหนะ

งานวิจัยที่เกี่ยวข้องกับระบบนับจำนวนยานพาหนะโดยใช้ Computer vision จะเป็นการนำเทคนิคด้าน Object detection และ Object tracking มาทำงานร่วมกัน โดย Object detection ที่นำมาประยุกต์ใช้สามารถแบ่งได้ออกเป็น 2 ประเภทหลักคือ Traditional approach และ Deep learning approach โดยการนำเทคนิคด้าน image processing หรือ Traditional approach มาใช้ อาทิเช่น การใช้เทคนิค double-difference operator with gradient magnitude[4] หรือ adaptive background subtraction algorithm [5] โดยข้อดีของ Traditional approach คือสามารถประมวลผลการตรวจจับวัตถุได้รวดเร็ว และใช้ทรัพยากรในการประมวลผลที่ต่ำ แต่ข้อจำกัดที่สำคัญคือ วิธีการนี้ไม่สามารถแยกแยะประเภทของวัตถุได้อย่างแม่นยำ โดยเฉพาะอย่างยิ่งไม่สามารถแยกแยะจำนวนยานพาหนะที่เป็นรถจักรยานยนต์ออกจากรถยนต์ได้ ดังนั้นข้อมูลการนับจำนวนยานพาหนะจาก Traditional approach อาจจะไม่เพียงพอต่อการวางแผนการจราจร ดังนั้น

Deep learning approach จึงได้รับความสนใจค่อนข้างมากในปัจจุบัน [6-8] เนื่องจากสามารถระบุตำแหน่งของวัตถุ และจำแนกประเภทของวัตถุได้ GoLeNet [6] นำเสนอการจำแนกยานพาหนะเป็น 3 ประเภท ได้แก่ รถยนต์ รถตู้ และรถโดยสารประจำทาง โดยใช้โมเดล ImageNet ที่ถูก fine-tuning ด้วยชุดข้อมูลของยานพาหนะ เพื่อเพิ่มประสิทธิภาพของของโมเดล หรือ Liang H. และคณะ [7] ได้นำโมเดล You Only Look Once version 3 (YOLOv3) มาใช้ในการตรวจจับ และจำแนกประเภทของยานพาหนะ ในงานวิจัยนี้มุ่งของกล้องจราจรเป็นภาพมุมมองบนทางด่วน ซึ่งความท้าทายในการตรวจจับและจำแนกประเภทยานพาหนะ คือ การที่ยานพาหนะมีการเปลี่ยนแปลงขนาด โดยเมื่อยานพาหนะอยู่ห่างจากกล้องจราจรยานพาหนะจะมีขนาดเล็ก แต่เมื่อยานพาหนะเคลื่อนที่เข้ามาใกล้กล้องจราจรมากขึ้นยานพาหนะจะมีขนาดใหญ่ โดย YOLOv3 สามารถช่วยในการตรวจจับ และจำแนกประเภทของยานพาหนะในแต่ละช่วงเวลาได้ หรืองานวิจัยของ Neupane B. และคณะ [8] มีการเปรียบเทียบประสิทธิภาพในการตรวจจับ และจำแนกประเภทของยานพาหนะระหว่าง YOLOv3 และ YOLOv5 โดยใช้ภาพจากกล้องจราจรที่เป็นภาพมุมมองสูง และจำแนกประเภทยานพาหนะออกเป็น 7 ประเภท คือ รถยนต์ รถโดยสารประจำทาง รถแท็กซี่ รถจักรยานยนต์ รถพิกอัพ รถบรรทุก และรถพ่วง ผลการวัดประสิทธิภาพแบบ Mean Average Precision (mAP) พบว่า YOLOv5 ให้ค่า mAP ที่สูงกว่า YOLOv3 ในขณะที่ใช้จำนวนเวลาในการ Train model ที่ต่ำกว่า ในงานวิจัยนี้จึงเลือกใช้ YOLOv5 เป็น Object detector

เพื่อให้ประสิทธิภาพการนับจำนวนมีความถูกต้องที่สูง นอกจากการใช้โมเดล object detection ที่มีประสิทธิภาพที่สูงแล้ว การเลือกใช้ Object tracking ก็มีส่วนในการเพิ่มความถูกต้องในการนับยานพาหนะด้วย โดยหลักการทำงานของ Object tracking คือ การเชื่อมโยงวัตถุที่ถูกตรวจจับในปัจจุบันกับรูปก่อนหน้าว่าวัตถุไหนเป็นวัตถุเดียวกัน ซึ่งในงานวิจัยก่อนหน้าก็มีการนำ Object tracking หลายวิธีการมาประยุกต์ใช้ในการนับจำนวนยานพาหนะ อาทิเช่น การนำ Centroid track [8] มาใช้ในการติดตามยานพาหนะจากกล้องจราจร โดยข้อดีของวิธีการนี้คือการประมวลผลค่อนข้างรวดเร็ว แต่ก็มีข้อจำกัดคือไม่สามารถติดตามยานพาหนะได้ ถ้าเกิดการปิดมิดชั่วคราว หรือได้มีการนำวิธีการ Kernel Correlation Filter (KCF) มาใช้ในการติดตามยานพาหนะบนฉากที่เป็นทางหลวง [7] ซึ่งข้อจำกัดของฉากที่เป็นทางหลวง คือ ยานพาหนะที่อยู่ห่างจากกล้องจราจรจะมีขนาดเล็ก และวัตถุจะมีขนาดใหญ่ขึ้นเมื่อยานพาหนะเคลื่อนที่เข้ามาใกล้กล้องจราจร จึงมีการปรับปรุงประสิทธิภาพของ KCF ให้สามารถทำงานได้ดีขึ้นกับการติดตามวัตถุที่มีการเปลี่ยนแปลงขนาด (Scale)

นอกจากการนำเทคนิคด้าน Object tracking มาใช้ในการติดตามยานพาหนะจากกล้องจราจรแล้ว Object tracking ยังถูกนำไปใช้ในการติดตามการเคลื่อนที่ของฝูงชน[9] การติดตามพฤติกรรมของมนุษย์[10] หรือใช้ในการนำทางหุ่นยนต์ในการเคลื่อนที่[11] ซึ่งปัญหาที่เกิดขึ้นใน

Object tracking ที่เลี่ยงไม่ได้คือ การเกิดการบดบัง (Occlusion) โดย Lee, B.Y. และคณะ [12] ได้จำแนกประเภทการบดบังออกเป็น 2 กลุ่ม คือ การบดบังบางส่วน (partial occlusion) และการบดบังแบบเต็ม (full occlusion) สำหรับการบดบังบางส่วนเกิดขึ้นเมื่อบางส่วนของวัตถุที่ถูกติดตามอยู่ถูกกีดขวางด้วยวัตถุอื่น วัตถุพื้นหลัง หรือส่วนอื่นของวัตถุเอง สำหรับการบดบังในลักษณะนี้สามารถใช้เทคนิค Mean Shift [13] ในการติดตามวัตถุได้

สำหรับการบดบังแบบเต็มจะเกิดขึ้นเมื่อวัตถุที่เรา กำลังติดตามไม่สามารถมองเห็นได้โดยสมบูรณ์ เมื่อเกิดการบดบังในลักษณะนี้เกิดขึ้นขั้นตอนวิธีการติดตามที่ใช้สภาพปรากฏของวัตถุในการติดตามจะไม่สามารถใช้งานได้เนื่องจากวัตถุได้สูญหายไปจากเฟรม เพื่อจัดการปัญหาการบดบังแบบเต็มต้องใช้ Object tracking ที่มีการรวมโมเดลการทำนายการเคลื่อนที่ของวัตถุ (Object spatial motion model) เข้าไว้ใน Object tracking ด้วย อาทิเช่น ByteTrack [14] ที่มีการใช้ Kalman filter (KF) ในการประมาณการตำแหน่ง และการเคลื่อนที่ของวัตถุ

2.2 YOLOv3

YOLOv3 [15] เป็นโมเดลในตระกูลของ YOLO โดยมีการปรับปรุง backbone จาก YOLOv2 [16] ซึ่งใช้ Darknet-19 มาเป็น Darknet-53 ที่มีประสิทธิภาพที่สูงกว่า และสามารถตรวจจับวัตถุที่มีขนาดเล็กได้ดีกว่า โดยสถาปัตยกรรมของ Darknet-19 และ Darknet 53 แสดงดังรูปที่ 1 อีกจุดที่มีการพัฒนาจาก YOLOv2 คือ YOLOv3 จะทำนายตำแหน่งของวัตถุออกมา 3 สเกลของแต่ละกริด ซึ่งใน YOLOv2 จะทำนายออกมาเพียง 2 สเกล และ YOLOv3 ยังมีการเปลี่ยน loss function ของ confidence loss และ classification loss มาเป็น cross-entropy error จาก sum-squared error เพื่อให้สามารถทำนายหลายคลาสได้ดีขึ้น YOLOv3 จะไม่ใช่ softmax แต่จะใช้ independent logistic classifier แทน ซึ่งมีประสิทธิภาพที่ดีสำหรับชุดข้อมูลที่มีความซับซ้อนสูง อาทิเช่น Open Image Dataset [17]

Type	Filters	Size/Stride	Output
Convolutional	32	3 × 3	224 × 224
Maxpool		2 × 2/2	112 × 112
Convolutional	64	3 × 3	112 × 112
Maxpool		2 × 2/2	56 × 56
Convolutional	128	3 × 3	56 × 56
Convolutional	64	1 × 1	56 × 56
Convolutional	128	3 × 3	56 × 56
Maxpool		2 × 2/2	28 × 28
Convolutional	256	3 × 3	28 × 28
Convolutional	128	1 × 1	28 × 28
Convolutional	256	3 × 3	28 × 28
Maxpool		2 × 2/2	14 × 14
Convolutional	512	3 × 3	14 × 14
Convolutional	256	1 × 1	14 × 14
Convolutional	512	3 × 3	14 × 14
Convolutional	256	1 × 1	14 × 14
Convolutional	512	3 × 3	14 × 14
Maxpool		2 × 2/2	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	512	1 × 1	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	512	1 × 1	7 × 7
Convolutional	1024	3 × 3	7 × 7
Convolutional	1000	1 × 1	7 × 7
Avgpool		Global	1000
Softmax			

Type	Filters	Size	Output
Convolutional	32	3 × 3	256 × 256
Convolutional	64	3 × 3 / 2	128 × 128
Convolutional	32	1 × 1	
Convolutional	64	3 × 3	
Residual			128 × 128
Convolutional	128	3 × 3 / 2	64 × 64
Convolutional	64	1 × 1	
Convolutional	128	3 × 3	
Residual			64 × 64
Convolutional	256	3 × 3 / 2	32 × 32
Convolutional	128	1 × 1	
Convolutional	256	3 × 3	
Residual			32 × 32
Convolutional	512	3 × 3 / 2	16 × 16
Convolutional	256	1 × 1	
Convolutional	512	3 × 3	
Residual			16 × 16
Convolutional	1024	3 × 3 / 2	8 × 8
Convolutional	512	1 × 1	
Convolutional	1024	3 × 3	
Residual			8 × 8
Avgpool		Global	
Connected		1000	
Softmax			


(a) Darknet-19 [16]

(b) Darknet 53 [15]

รูปที่ 1 เปรียบเทียบสถาปัตยกรรมของ Darknet-19 (ซ้าย) และ Darknet-53 (ขวา)

2.3 YOLOX

YOLOX [18] เป็นโมเดลที่ถูกพัฒนาต่อจาก YOLOv3 โดยยังคงใช้ backbone เป็น Darknet-53 เหมือน YOLOv3 แต่มีการเปลี่ยนมาเป็น anchor-free เพื่อลดความซับซ้อนของการตรวจจับ โดยลดจำนวน Predicted location ลงจาก 3 ใน YOLOv3 เป็น 1 นอกจากนี้ YOLOX ยังมีการแยกส่วนของ head ออกเป็น Box classification และ Box regression ดังแสดงในรูปที่ 2 ซึ่งมีส่วนช่วยเพิ่มประสิทธิภาพในการ Training และความแม่นยำของโมเดล YOLOX ยังมีการเพิ่ม Precision ด้วยเทคนิคการวางกลยุทธ์การมอบหมายการติดป้าย (Label assignment strategy) ด้วย SimOTA โดย YOLOX สามารถทำประสิทธิภาพ Average Precision (AP) ได้ 51.2% บนชุดข้อมูลทดสอบ COCO 2017[19] ซึ่งทำคะแนนได้สูงกว่า YOLOv3 ที่ทำได้ 43.9%



รูปที่ 2 ความแตกต่างระหว่างส่วน Head ของ YOLOv3[15] และ YOLOX [18]

2.4 Centroid tracking

Centroid tracking [8] เป็นวิธีการติดตามวัตถุที่มีความซับซ้อนที่น้อย และทำงานได้รวดเร็ว โดยหลักการเชื่อมโยงว่าวัตถุที่เวลา t ของวิดีโอที่ค้นเป็นวัตถุเดียวกันกับวัตถุที่เวลา $t-1$ ของวิดีโอที่ค้น คือ การวัดระยะทางแบบยุคลิด (Euclidean distance) ระหว่างเซนทรอยด์ (Centroid) ของแต่ละวัตถุที่ถูกตรวจจับที่เวลา $t-1$ ของวิดีโอที่ค้น เทียบกับเซนทรอยด์ของแต่ละวัตถุที่ถูกตรวจจับที่เวลา t ของวิดีโอที่ค้น โดยวัตถุที่ถูกตรวจจับคู่ไหนที่มีระยะทางแบบยุคลิดน้อยที่สุดก็จะถือว่าเป็นวัตถุที่ถูกตรวจจับเดียวกันที่คนละช่วงเวลา สมการคำนวณระยะ Euclidean ดังสมการที่ 1

$$\text{Euclidean distance} = \sqrt{(X_{t-1} - X_t)^2 + (Y_{t-1} - Y_t)^2} \quad (1)$$

2.5 ByteTrack

ByteTrack [14] เป็น Multi-Object Tracking (MOT) ที่มีวิธีการคิดที่เรียบง่าย และมีประสิทธิภาพที่ดี โดย ByteTrack จะใช้ YOLOX เป็น Object detector ในการตรวจจับวัตถุและแยกแยะชนิดของวัตถุ โดยจุดเด่นของ ByteTrack คือ จะนำวัตถุที่ถูกตรวจจับได้ทั้งที่มีคะแนนความเชื่อมั่นที่สูง และคะแนนความเชื่อมั่นที่ต่ำ มาใช้เพื่อเพิ่มประสิทธิภาพในการติดตามวัตถุ เนื่องจากในบางช่วงเวลาของวิดีโอที่ค้นวัตถุอาจจะถูกบดบังในบางส่วนทำให้คะแนนความเชื่อมั่นจาก Object detector มีค่าต่ำลงได้ ดังแสดงในรูปที่ 3 พบว่าบุคคลใน Frame t_1 ที่มีคะแนนความเชื่อมั่น 0.8 จะมีคะแนนความเชื่อมั่นลดลงเป็น 0.4 ใน Frame t_2 เมื่อมีบุคคลอื่นเคลื่อนที่มาบดบัง และจะมีคะแนนความเชื่อมั่นลดลงเหลือเพียง 0.1 ใน Frame t_3 ซึ่งการที่ ByteTrack นำวัตถุที่มีคะแนนความเชื่อมั่นที่ต่ำมาใช้ในการเชื่อมโยงด้วยก็จะมีส่วนช่วยในการลดปัญหาการติดตามวัตถุที่ถูกบดบังได้

สำหรับการเชื่อมโยง ByteTrack จะใช้ Kalman Filter ในการพยากรณ์ตำแหน่งของวัตถุที่ถูกตรวจจับจากเวลา $t-1$ ของวิดีโอที่คิดว่าควรมีตำแหน่งของวัตถุอยู่ที่ตำแหน่งไหนที่เวลา t ของวิดีโอ จากนั้นจะนำตำแหน่งของวัตถุที่ถูกพยากรณ์มาหาการเชื่อมโยงกับวัตถุที่ถูกตรวจจับที่เวลา t ที่มีคะแนนความเชื่อมั่นสูงก่อน โดยใช้ Intersect Over Union (IOU) เป็น motion similarity สำหรับจับคู่ความเชื่อมโยง และเมื่อจับคู่ตำแหน่งของวัตถุที่ถูกพยากรณ์กับวัตถุที่ถูกตรวจจับที่มีความเชื่อมั่นสูงครบแล้ว จึงจะนำตำแหน่งของวัตถุที่ถูกพยากรณ์ที่ยังไม่ถูกจับคู่ไปจับคู่กับวัตถุที่ถูกตรวจจับที่มีความเชื่อมั่นต่ำต่อไป โดย ByteTrack สามารถทำประสิทธิภาพแบบ MOTA ได้ 80.3 และ 77.8 บนชุดข้อมูลทดสอบของ MOT17 [20] และ MOT20 [21] ตามลำดับ




รูปที่ 3 ผลจากการบดบังที่มีผลต่อความเชื่อมั่นของ object detector [14]

บทที่ 3

แนวคิดและวิธีการวิจัย

3.1 ระบบนับจำนวนยานพาหนะ

สำหรับระบบนับจำนวนยานพาหนะมีกรอบความคิดมาจากการประกอบระบบ Vehicle detection และ Vehicle tracking เข้าด้วยกัน โดยเมื่อระบบอ่านวิดีโอที่ส่งจากกล้องจราจร วิดีโอจะถูกแยกออกเป็นเฟรมเรียงต่อกันตามเวลา แต่ละเฟรมจะถูกส่งให้ Vehicle detection เพื่อตรวจจับยานพาหนะที่อยู่ในเฟรม และแยกแยะชนิดของยานพาหนะ จากนั้นจึงส่งพิกัดของ Bounding box และประเภทของยานพาหนะไปให้ Vehicle tracking ซึ่งจะทำหน้าที่ติดตาม และระบุไอดี (ID) ของยานพาหนะแต่ละคัน โดย Vehicle tracking จะทำการตรวจสอบว่าพิกัดของยานพาหนะที่ถูกส่งมาเป็นพิกัดของยานพาหนะที่กำลังติดตามอยู่หรือไม่ ถ้าพบว่าเป็นยานพาหนะใหม่ที่ไม่เคยติดตาม Vehicle tracking จะทำการลงทะเบียนในระบบว่าพบยานพาหนะใหม่เกิดขึ้น โดยทำการสร้างไอดีใหม่ให้กับยานพาหนะ จดจำพิกัดเริ่มต้น และประเภทของยานพาหนะ แต่ถ้าสามารถหาความเชื่อมโยงได้ว่าเป็นยานพาหนะเดียวกันกับยานพาหนะที่เคยส่งมาให้ในภาพก่อนหน้า นี้ก็จะอัปเดตพิกัดใหม่ให้กับยานพาหนะเดิม และเมื่อมียานพาหนะที่เราติดตามเคลื่อนที่เข้ามาในบริเวณ ROI ระบบ Vehicle counting จะทำการจดจำ ID ของยานพาหนะไว้ กระแสงานทั้งระบบจะดำเนินการวนซ้ำจนครบวิดีโอ การนับจำนวนยานพาหนะจะนับจากไอดีของยานพาหนะที่ถูกบันทึกไว้ในระบบ Vehicle counting โดยแผนผังการทำงานของระบบนับจำนวนยานพาหนะสามารถแสดงได้ดังในรูปที่ 4



รูปที่ 4 แผนผังการทำงานของระบบนับจำนวนยานพาหนะ

3.2 ชุดข้อมูล

สำหรับชุดข้อมูลประกอบด้วย 2 ชุดข้อมูล คือ ชุดข้อมูลวิดีโอทัศนจราจร และชุดข้อมูลรูปภาพ โดยชุดข้อมูลแต่ละชุดมีรายละเอียดดังนี้

3.2.1 ชุดข้อมูลวิดีโอทัศนจราจร

เป็นชุดข้อมูลที่ได้รับจาก สถาบันขนส่ง จุฬาลงกรณ์มหาวิทยาลัย ซึ่งประกอบด้วยวิดีโอทัศนจากกล้องจราจรที่ถูกตั้งใน 2 มุมมองคือ มุมข้าง และมุมบน ดังแสดงในรูปที่ 5 โดยชุดข้อมูลวิดีโอทัศนจะถูกใช้ในการสร้างชุดข้อมูลภาพ และใช้เป็นวิดีโอทัศนในการประเมินประสิทธิภาพของระบบนํายานพาหนะแยกตามประเภท



(a) วิดีทัศน์มุมข้าง




(b) วิดีทัศน์มุมบน

รูปที่ 5 ตัวอย่างรูปภาพในชุดข้อมูลวิดีโอทัศนจราจร

จากการสำรวจวิดีโอทัศนจราจรทั้ง 2 มุมมองจะพบความท้าทายหลักคือ การบดบัง (Occlusion) โดยวิดีโอทัศนมุมบนจะเป็นการบดบังบางส่วน แต่สำหรับวิดีโอทัศนมุมข้างจะเกิดการบดบังเต็มคัน เนื่องจากมุมมองของกล้องจราจรอยู่ในระดับใกล้เคียงกับระดับยานพาหนะ และมียานพาหนะเคลื่อนที่สวนทางกัน ดังแสดงในรูปที่ 6



(a) รถจักรยานยนต์ก่อนบดบัง



(b) รถจักรยานยนต์ขณะบดบัง

รูปที่ 6 ตัวอย่างการบดบังในวิดีโอทัศนมุมข้าง

3.2.2 ชุดข้อมูลภาพ

เป็นชุดข้อมูลที่ใช้สำหรับนำมา training ตัว Vehicle detector โดยสร้างมาจากชุดข้อมูล 2 แหล่งด้วยกัน คือ Open Image Dataset V4 [17] และวีดิทัศน์จราจร โดยชุดข้อมูลทุกชุดจะถูกนำมาเปลี่ยนคลาสของยานพาหนะให้สอดคล้องกับวัตถุประสงค์การวิจัยเป็น 6 ประเภท ประกอบด้วย รถโดยสาร รถยนต์ รถจักรยานยนต์ รถกระบะ รถบรรทุก และรถตู้ จากนั้นชุดข้อมูลแต่ละชุดจะถูกนำมาแบ่งออกเป็น train, validation และ test ในสัดส่วน 50%, 25% และ 25% ตามลำดับ และจำนวนของยานพาหนะแยกตามประเภทแสดงในตารางที่ 1

สำหรับชุดข้อมูลรูปภาพจาก Open Image Dataset V4 [17] เป็น Publish dataset ที่มีการแยกแยะด้วยวัตถุในรูปออกเป็น 600 ประเภท โดยเราจะคัดเลือกมาเฉพาะรูปที่มียานพาหนะอยู่เท่านั้น ประกอบด้วยรูปจำนวนทั้งหมด 5878 รูป แสดงดังรูปที่ 7 (a)

สำหรับชุดข้อมูลรูปภาพจากวีดิทัศน์จราจรจะถูกแยกออกเป็น 2 ชุดข้อมูลย่อย คือ ชุดข้อมูลในมุมมองด้านข้าง (side view) ประกอบด้วยรูปจำนวน 817 รูป ตัวอย่างของรูปในชุดข้อมูล แสดงดังรูปที่ 7 (b) และชุดข้อมูลภาพด้านบน (top view) ประกอบด้วยรูปจำนวน 1948 รูป ตัวอย่างของรูปในชุดข้อมูล แสดงดังรูปที่ 7 (c)

ตารางที่ 1 จำนวนยานพาหนะแยกตามประเภทของแต่ละชุดข้อมูล

ประเภทยานพาหนะ	Open Image	ภาพมุมข้าง (side view)	ภาพมุมบน (top view)
รถโดยสาร	2455	199	426
รถยนต์	9276	1422	4925
รถจักรยานยนต์	2469	706	3128
รถกระบะ	1079	164	2365
รถบรรทุก	2374	11	116
รถตู้	1872	133	178



(a) ชุดข้อมูล Open Image



(b) ชุดข้อมูลภาพมุมข้าง (side view)



(c) ชุดข้อมูลภาพมุมบน (top view)

รูปที่ 7 ตัวอย่างรูปภาพในชุดข้อมูล

3.3 Vehicle detection

จากรูปที่ 4 Vehicle detection จะเป็นส่วนที่รับเข้าภาพจากวีดิทัศน์ของกล้องจราจรที่สะพาน จากนั้นจะทำการตรวจหายานพาหนะทั้งหมดที่อยู่ในบริเวณที่กำหนดผลจากการตรวจหา ยานพาหนะของ Vehicle detection จะประกอบด้วยค่า พิกัดของ Bounding box, ประเภทของ ยานพาหนะ และค่าความเชื่อมั่น โดยค่าพิกัดของ Bounding box จะถูกระบุด้วยตัวเลข 4 ตัว คือ X_1 , Y_1 , X_2 และ Y_2 ดังแสดงในรูปที่ 8 เมื่อ Vehicle detection ตรวจหาตำแหน่งของยานพาหนะ แล้ว ค่าพิกัดของ Bounding box ของยานพาหนะจะถูกส่งให้ Vehicle tracking ในติดตาม และ ระบุไอดีของยานพาหนะต่อไป สำหรับการเลือกโมเดลของ Object detector ที่จะใช้สำหรับ

Vehicle detection จะทำการเปรียบเทียบประสิทธิภาพของโมเดล YOLOv3 กับ YOLOX โดยจะทำการ train แต่ละโมเดลบนชุดข้อมูล 2 ชุดข้อมูล โมเดลแรกจะ train โมเดล YOLOv3 และ YOLOX บนชุดข้อมูล Open Image ร่วมกับภาพมุมข้าง และโมเดลที่ 2 จะ train โมเดลจากชุดข้อมูลภาพมุมบน จากนั้นจึงทำการเปรียบเทียบประสิทธิภาพของ object detector ที่เหมาะสมของแต่ละชุดข้อมูล

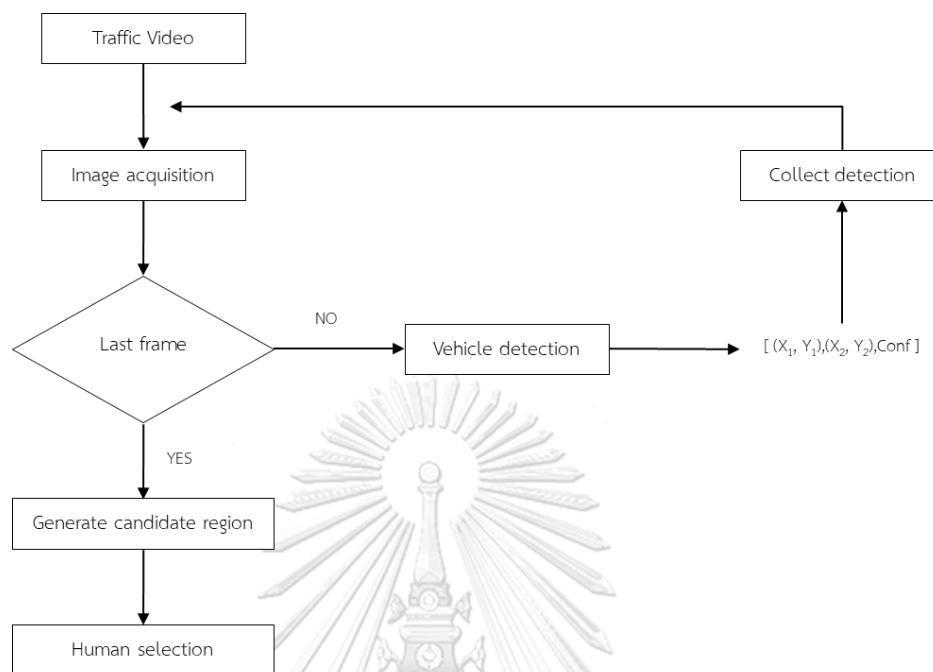


รูปที่ 8 พิกัดของ Bounding box ที่ถูกส่งออกจาก Vehicle detection

3.4 Vehicle tracking

จากรูปที่ 4 เมื่อ Vehicle detection ส่งค่าพิกัดของยานพาหนะมาให้กับ Vehicle tracking จะทำการเชื่อมโยงกับพิกัดของยานพาหนะที่กำลังติดตาม โดยถ้าสามารถเชื่อมโยงได้ว่าเป็นยานพาหนะที่กำลังติดตามอยู่ก็จะทำการกำหนดไอดีที่เชื่อมโยงได้ให้กับยานพาหนะนั้น แต่ถ้าไม่สามารถเชื่อมโยงกับยานพาหนะที่กำลังติดตามได้ก็จะทำการกำหนดไอดีใหม่ให้กับยานพาหนะ โดยไอดีและพิกัดของยานพาหนะจะถูกส่งให้ Vehicle counting ในการจดจำไอดีของยานพาหนะ สำหรับ Vehicle tracking จะเลือก MOT ที่มีประสิทธิภาพที่ดีเพื่อทำงานร่วมกับระบบ Vehicle counting โดยจะเปรียบเทียบ 2 ขั้นตอนวิธีด้วยกัน คือ Centroid tracking [8] กับ ByteTrack [14] โดยจะทำการเปรียบเทียบประสิทธิภาพบนวิดีโอที่สุ่มมา 1 นาที ทั้งมุมข้าง และมุมบน แบบไม่มีการกำหนดพื้นที่ ROI เพื่อหาขั้นตอนวิธีที่ให้ค่าความผิดพลาดต่ำที่สุดเทียบกับการนับด้วยบุคคล


3.5 การกำหนดพื้นที่ ROI




รูปที่ 9 แผนผังการทำงานของขั้นตอนวิธีในการหาพื้นที่ ROI

ROI เป็นการกำหนดพื้นที่ที่เรากำหนดขึ้นเพื่อใช้เป็นบริเวณที่จะทำการการนับ และแยกประเภทของยานพาหนะ โดยกำหนดพื้นที่ ROI จะมีปัจจัยประกอบหลายอย่าง อาทิเช่น ประสิทธิภาพของ Object detection ในการตรวจจับวัตถุ หรือ ระยะห่างจากตำแหน่งการติดตั้งกล้องจราจร

สำหรับขั้นตอนวิธีในการหาจุดเริ่มต้นของ ROI แสดงในรูปที่ 9 โดยจะใช้ Vehicle detector ตรวจจับยานพาหนะในวิดิทัศน์จราจรไปที่ละเฟรม และการเก็บค่าพิกัด และความมั่นใจของยานพาหนะในแต่ละเฟรมของวิดิทัศน์จนถึงเฟรมสุดท้ายของวิดิทัศน์ จากนั้นจะนำค่าความมั่นใจที่มีการเก็บบันทึกไว้มาทำการหาค่าเฉลี่ยของตามพิกัดในวิดิทัศน์ ถ้าเป็นวิดิทัศน์มุมข้างจะหาค่าเฉลี่ยของค่าความมั่นใจตามพิกัดแนวแกน X ดังแสดงในรูปที่ 10 (a) และสำหรับวิดิทัศน์มุมบนจะหาค่าเฉลี่ยของค่าความมั่นใจตามพิกัดแนวแกน Y ดังแสดงในรูปที่ 10 (b) จากนั้นจะหาพิกัดตามแนวแกนที่มีความมั่นใจสูงมา 2-3 พิกัด จากนั้นเราก็จะนำพิกัดที่ได้นี้มาทำการจุดเริ่มต้นที่เหมาะสม โดยจะต้องคำนึงว่าจุดเริ่มต้นและจุดสิ้นสุดต้องไม่ใกล้กับขอบของวิดิทัศน์มากเกินไป และต้องไม่มีสิ่งขีดขวางที่มีโอกาสจะทำให้เกิด False detection ได้ เป็นต้น



(a) ค่าความมั่นใจที่แต่ละพิกัดของวีดิทัศน์มุมข้าง

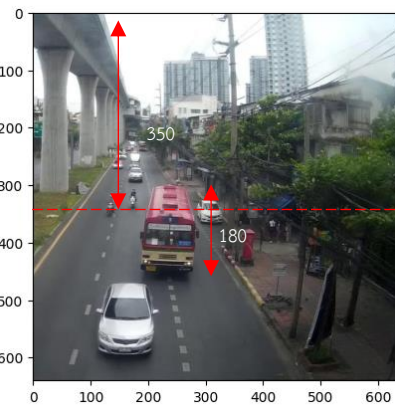


(b) ค่าความมั่นใจที่แต่ละพิกัดของวีดิทัศน์มุมบน

รูปที่ 10 กราฟพิกัดตามแนวแกนและค่าความเชื่อมั่นที่ใช้ในขั้นตอนวิธีในการหา ROI



(a) วีดิทัศน์มุมข้าง



(b) วีดิทัศน์มุมบน

รูปที่ 11 แสดงการกำหนดพื้นที่ ROI บนวีดิทัศน์มุมข้าง และมุมบน



จากผลการรัน Vehicle detection บนวีดิทัศน์มุมข้างจะได้ค่าความเชื่อมั่นตามพิกัดแกน x ดังแสดงในรูปที่ 10 (a) โดยเลือกมีพิกัดที่ให้ค่าความเชื่อมั่นสูงมา 2 พิกัดตามแนวแกน X คือ 140 พิกเซล และ 210 พิกเซล มาพิจารณาพิกัดที่มีความเหมาะสมเป็นจุดเริ่มต้นของพื้นที่ ROI โดยเราจะ

พิจารณาจากการหาขนาดความกว้างของ ROI จะพบว่ายานพาหนะที่มีขนาดกว้างที่สุดที่เคลื่อนที่ผ่านกล้องจราจรมุมข้างมีขนาด 300 พิกเซล ดังแสดงในรูปที่ 11 (a) กรณีนี้การเลือกจุดเริ่มต้นเป็น 140 พิกเซล จะได้จุดสิ้นสุดเป็น 440 พิกเซล หรือ จุดเริ่มต้นเป็น 210 พิกเซล จะได้จุดสิ้นสุดเป็น 510 พิกเซล ซึ่งจุดสิ้นสุดทั้งสองอยู่ห่างจากของวัตถุที่สนใจทั้งคู่ แต่หากพิจารณาในเชิงคุณภาพของวัตถุที่สนใจจะพบว่า ระยะระหว่าง 210 พิกเซล ถึง 510 พิกเซล จะมีบริเวณที่วัตถุที่สนใจพวามัวค่อนข้างเยอะ ทำให้การเลือกจุดเริ่มต้นเป็น 140 พิกเซล อาจจะมีเหมาะสมกว่า


สำหรับวัตถุที่สนใจมุมข้างจากรูปที่ 10 (b) จะพบว่าเมื่อมีพิกัดที่ให้ค่าความเชื่อมั่นสูงมา 2 พิกัดตามแนวแกน Y คือ 350 พิกเซล และ 460 พิกเซล เมื่อนำมาพิจารณาพิกัดที่มีความเหมาะสมเป็นจุดเริ่มต้นของพื้นที่ ROI จะพบว่ายานพาหนะที่มีขนาดกว้างที่สุดที่เคลื่อนที่ผ่านกล้องจราจรมุมข้างมีขนาด 180 พิกเซล ดังแสดงในรูปที่ 11 (b) ถ้าเราเลือกพิกัด 460 พิกเซล เป็นจุดเริ่มต้น จุดสิ้นสุดก็จะเป็น 640 พิกเซล ซึ่งเป็นขอบของวัตถุที่สนใจ ทำให้พิกัด 350 พิกเซล จึงมีความเหมาะสมที่จะใช้เป็นจุดเริ่มต้นของพื้นที่ ROI

3.6 Vehicle counting

สำหรับ Vehicle counting จะทำหน้าที่ในการนับยานพาหนะที่เกิดขึ้นในวัตถุที่แยกตามประเภทของยานพาหนะ โดยหลักการจะเป็นการนับไอทีที่เกิดขึ้นจาก Vehicle tracking ซึ่ง Vehicle counting จะทำการนับเฉพาะยานพาหนะที่มีพิกัดอยู่ในพื้นที่การนับเท่านั้น



(a) ไม่มี ROI



(b) มี ROI

รูปที่ 12 เปรียบเทียบการนับยานพาหนะแบบไม่มี ROI กับ มี ROI

การกำหนดพื้นที่การนับจะเปรียบเทียบ 2 วิธีการด้วยกันคือ แบบมี ROI และไม่มี ROI เพื่อให้เห็นผลจากระยะระหว่างยานพาหนะกับกล้องจราจร สำหรับการนับแบบไม่มี ROI พิกัดและไอดีของยานพาหนะจะถูกนำเข้า Vehicle counting เพื่อบันทึกทันทีที่ยานพาหนะถูกติดตาม ในขณะที่การนับแบบมี ROI ยานพาหนะจะถูกนำเข้า Vehicle counting เมื่อยานพาหนะเคลื่อนที่เข้าพื้นที่ ROI เท่านั้น

สำหรับการทดสอบประสิทธิภาพของ Vehicle counting จะทดสอบบนวีดิทัศน์มุมข้าง (side view) และมุมบน (top view) ที่เกิดจากสุมวีดิทัศน์จราจรที่ได้รับจาก สถาบันการขนส่ง จุฬาลงกรณ์มหาวิทยาลัย โดยสุมมาเป็นระยะเวลา 1 นาที จากนั้นจะทำการคำนวณความผิดพลาดจากการนับด้วยระบบเทียบกับการนับด้วยบุคคล เพื่อทำการหา Vehicle counting ที่ให้ค่าความผิดพลาดที่ต่ำที่สุด

ตารางที่ 2 สรุปลำดับยานพาหนะในวีดิทัศน์ที่ใช้สำหรับประเมินผล

พื้นที่การนับ	ประเภทยานพาหนะ	วีดิทัศน์ภาพมุมข้าง	วีดิทัศน์ภาพมุมบน
ไม่มี ROI	รถโดยสาร	1	2
	รถยนต์	22	21
	รถจักรยานยนต์	24	18
	รถกระบะ	3	6
	รถบรรทุก	0	2
	รถตู้	3	1
มี ROI	รถโดยสาร	1	2
	รถยนต์	19	19
	รถจักรยานยนต์	22	18
	รถกระบะ	3	6
	รถบรรทุก	0	2
	รถตู้	3	0

บทที่ 4

การประเมินผลการวิจัย และผลการประเมินเบื้องต้น

4.1 เกณฑ์การประเมินผล

4.1.1 การตรวจจับวัตถุ (Object detection)

สำหรับการวัดประสิทธิภาพของ Object detector จะใช้ตัววัดเป็น mean average precision (mAP) โดย mAP เป็นการหาค่าเฉลี่ยของ Average Precision (AP) สำหรับทุกคลาส (k) ในชุดข้อมูล สามารถคำนวณได้ตามสมการที่ 2

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (2)$$

โดยที่

AP คือ Average Precision

mAP คือ Mean Average Precision

k คือ จำนวนคลาสของวัตถุในชุดข้อมูล

Average Precision[22] สามารถคำนวณได้จากพื้นที่ใต้กราฟ (Area Under Curve) ของกราฟ Precision x Recall โดยค่าของพื้นที่ใต้กราฟที่สูงบ่งชี้ถึงค่า Precision (Pr) และ Recall (Rc) ที่สูงด้วย ในทางปฏิบัติกราฟระหว่าง Precision x Recall ไม่ได้เป็นฟังก์ชันทางเดียว (monotonic) แต่มีลักษณะเป็นรูปซิกแซก (zigzag) ทำให้มีความท้าทายในการหาพื้นที่ใต้กราฟ

ในการคำนวณค่า AP เราจะเริ่มจากการกำหนดเซตของค่าความเชื่อมั่น (confidence value) ที่จะใช้ในการคำนวณเป็นจำนวน k ค่า จากนั้นเราก็จะทำการคำนวณค่า Precision และ Recall ที่แต่ละค่าความเชื่อมั่น k ซึ่งทำให้กราฟ Precision x Recall เป็นจุดไม่ต่อเนื่อง (discrete) ของคู่อันดับ $(Pr_{@k}, Rc_{@k})$ ตามจำนวนค่าความเชื่อมั่น k ค่า หลังจากนั้นเราจะทำการเชื่อมต่อดูด (interpolate) บนกราฟให้มีความต่อเนื่องโดยใช้ฟังก์ชันต่อเนื่อง (continuous function) ของ $Pr_{interp}(R)$ ตามสมการที่ 3 ซึ่งค่า $Pr_{interp}(R)$ เป็นค่า Precision สูงที่สุดของ Recall ที่มีค่ามากกว่าหรือเท่ากับ R ที่จุดนั้นๆ

เราสามารถคำนวณค่า AP ด้วยวิธีการของ Riemann integral ซึ่งเราสามารถคำนวณโดยใช้เทคนิค The N-point interpolation ซึ่งจะทำให้เราคำนวณ AP ได้ตามสมการที่ 4 และเราสามารถคำนวณค่า recall $R_r(n)$ ได้ตามสมการที่ 5 โดยจำนวน N ที่ได้รับความนิยมจะเป็น 101 ใน COCO Detection Challenge[23] และ 11 ใน Pascal Object Classes Challenge [24]

$$Pr_{interp}(R) = \max_{k|Rc(k) \geq R} \{Pr(k)\} \quad (3)$$

โดยที่

$Pr_{interp}(R)$ คือ ค่า precision จากการ interpolate ที่ R

R คือ จำนวนจริงที่มีค่าระหว่าง 0-1

$$AP = \frac{1}{N} \sum_{n=1}^N Pr_{interp}(R_r(n)) \quad (4)$$

โดยที่

$Pr_{interp}(R_r(n))$ คือ ค่า precision จากการ interpolate ที่ $R_r(n)$

$R_r(n)$ คือ ค่า recall ที่แต่ละจุดของ n

n คือ ค่าในเซตของ 1 ถึง N

$$R_r(n) = \frac{N - n}{N - 1}, n = 1, 2, \dots, N \quad (5)$$

โดยที่

N คือ จำนวนจุดที่จะทำการคำนวณค่า

$$Precision = \frac{True\ positive}{True\ positive + False\ positive} \quad (6)$$

โดยที่

True positive คือ จำนวนวัตถุที่ทำนายถูก

False positive คือ จำนวนวัตถุที่ทำนายผิด

$$Recall = \frac{True\ positive}{True\ positive + False\ negative} \quad (7)$$

โดยที่

False negative คือ จำนวนวัตถุที่ไม่ถูกทำนาย

4.1.2 การนับยานพาหนะ (Vehicle counting)

สำหรับการวัดประสิทธิภาพของระบบนับจำนวนยานพาหนะ จะใช้ตัววัดเป็น mean absolute percent error (MAPE) โดยสามารถคำนวณได้ตามสมการที่ 6

$$MAPE = \frac{|number\ of\ ground\ truth - number\ of\ counting|}{number\ of\ ground\ truth} \times 100 \quad (6)$$

4.2 ผลการทดสอบ

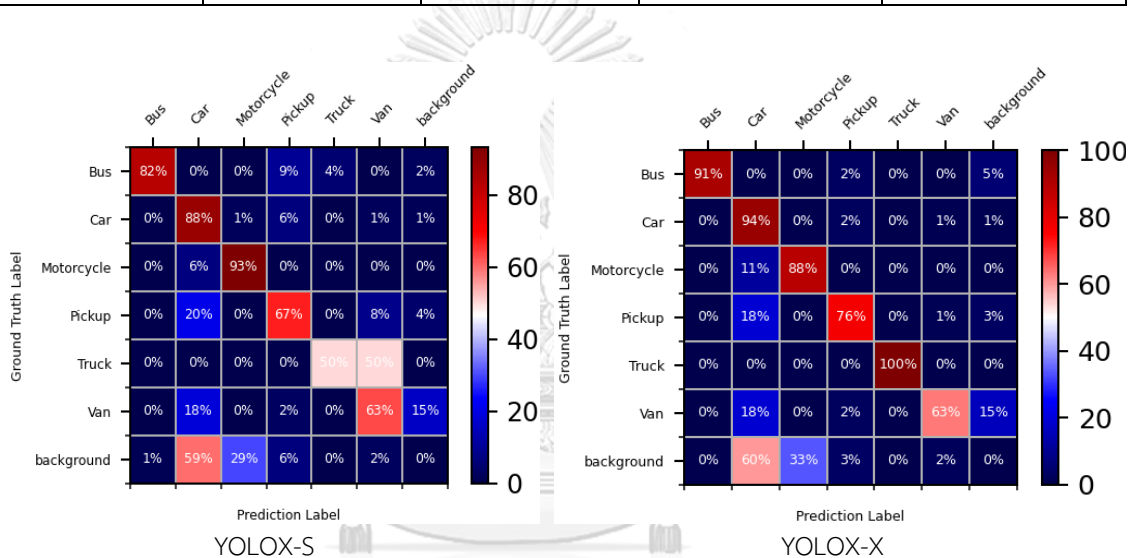
4.2.1 Vehicle detection

หลังจากการ training โมเดล YOLOv3 YOLOX-S และ YOLOX-X บนชุดข้อมูลรูปภาพมุมข้าง และภาพมุมมองบน เราทำการประเมินประสิทธิภาพการตรวจจับและแยกแยะยานพาหนะของโมเดล โดยใช้ mAP ดังแสดงในตารางที่ 3 ผลลัพธ์การทดสอบ object detector บนชุดข้อมูลทดสอบ

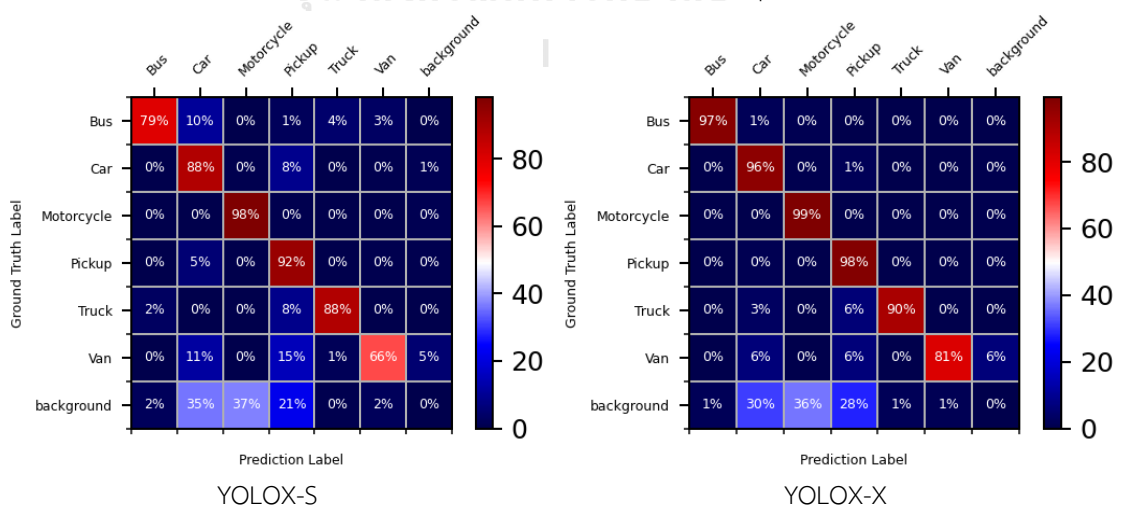
จากผลการเปรียบเทียบประสิทธิภาพแบบ mAP ของโมเดล YOLOv3 YOLOX-S และ YOLOX-X พบว่า YOLOX-X ทำประสิทธิภาพได้ดีกว่า YOLOv3 และ YOLOX-S บนชุดข้อมูลภาพมุมข้าง และภาพมุมมองบน สำหรับชุดข้อมูลภาพมุมข้าง YOLOX-X ทำประสิทธิภาพได้ดีกว่า YOLOv3 และ YOLOX-S 12.51% และ 1.45% ตามลำดับ และชุดข้อมูลภาพมุมมองบน YOLOX-X ทำประสิทธิภาพ mAP ได้ดีกว่า YOLOv3 และ YOLOX-S 26.80% และ 8.34% ตามลำดับ

ตารางที่ 3 ผลลัพธ์การทดสอบ object detector บนชุดข้อมูลทดสอบ

วิธีทัศน์	เกณฑ์การประเมินผล	YOLOv3	YOLOX-S	YOLOX-X
ภาพมุมข้าง	mAP	53.34%	64.40%	65.85%
	AP@50	85.28%	89.56%	90.84%
	AP@75	65.63%	78.62%	81.71%
ภาพมุมบน	mAP	56.08%	74.54%	82.88%
	AP@50	89.59%	96.16%	97.66%
	AP@75	63.49%	85.68%	93.59%



(a) แสดง Confusion matrix ของภาพมุมข้าง



(b) แสดง Confusion matrix ของภาพมุมบน

รูปที่ 13 แสดง confusion matrix ของ YOLOX-S และ YOLOX-X

เมื่อพิจารณา confusion matrix ระหว่าง YOLOX-S และ YOLOX-X ดังแสดงในรูปที่ 13 จะพบว่าสำหรับชุดข้อมูลภาพมูมข้าง YOLOX-X ทำประสิทธิภาพได้ดีกว่า YOLO-S สำหรับยานพาหนะประเภทรถจักรยานยนต์ซึ่งเป็นยานพาหนะที่มีจำนวนมากเป็นอันดับ 2 ในชุดข้อมูลทดสอบรองจากรถยนต์ จึงทำให้ค่า mAP ของ YOLOX-X สูงกว่า YOLOX-S เพียงเล็กน้อยในชุดข้อมูลภาพมูมข้าง โดยในยานพาหนะประเภทรถจักรยานยนต์ YOLOX-X มีการจำแนกผิดเป็นยานพาหนะประเภทรถยนต์ ประมาณ 11% สาเหตุมาจากในบางรูปภาพมูมข้าง โมเดลเกิดการตรวจจับวัตถุที่ซ้ำซ้อน ดังแสดงในรูปที่ 14 จะพบว่ารถจักรยานยนต์ถูกตรวจจับเป็นทั้งรถจักรยานยนต์และรถยนต์ในวัตถุเดียวกัน ซึ่งเป็น false detection โดยสามารถลดผลกระทบจากปัญหานี้ในระบบนับยานพาหนะได้ด้วยการปรับค่าพารามิเตอร์ให้เหมาะสม สำหรับ confusion matrix ของชุดข้อมูลภาพมูมบนจะพบว่า YOLOX-X ทำประสิทธิภาพได้ดีในยานพาหนะทุกประเภท ดังนั้น YOLOX-X จึงมีความเหมาะสมสำหรับ Vehicle detection



รูปที่ 14 แสดงปัญหาการตรวจจับที่ซ้ำซ้อน

4.2.2 Vehicle tracking

ผลการเปรียบเทียบค่าความผิดพลาดของนับจำนวนยานพาหนะของ Centroid tracking กับ ByteTrack แบบไม่มีการกำหนด ROI แสดงดังตารางที่ 4

เมื่อพิจารณาค่า MAPE ระหว่าง Centroid tracking กับ ByteTrack ในตารางที่ 4 จะพบว่า ByteTrack จะให้ค่า MAPE ที่ต่ำกว่า Centroid track 45.28% และ 72.00% สำหรับวิดีโอที่มูมข้าง และวิดีโอที่มูมบน ตามลำดับ โดยสาเหตุหลักที่ทำให้ ByteTrack ทำประสิทธิภาพได้ดีกว่ามาจากการที่ ByteTrack สามารถจัดการการบดบัง (Occlusion) ได้ดีกว่า Centroid tracking ทำให้ ByteTrack สามารถติดตาม id ของยานพาหนะได้ตลอดวิดีโอ ในขณะที่ Centroid tracking อาจเกิดการหลุดการติดตามจากการบดบังจนทำให้เกิดการสร้าง id ของยานพาหนะขึ้นมาใหม่ โดยปัญหาการบดบังจะเกิดขึ้นบ่อยในวิดีโอที่มูมข้าง ดังแสดงในรูปที่ 15 จะพบว่ารถจักรยานยนต์

ก่อนเกิดการบดบังจะมี id เป็น 110 แต่เมื่อเครื่องที่สวนทางกับรถยนต์จะพบว่ารถจักรยานยนต์คันดังกล่าวเกิดการหลุดการติดตาม และถูกสร้าง id ให้ใหม่เป็น 116 ในขณะที่ ByteTrack สามารถติดตามรถจักรยานยนต์ได้ต่อเนื่องแม้จะเกิดการบดบังดังแสดงในรูปที่ 16 ดังนั้น ByteTrack จึงมีความเหมาะสมกว่า Centroid tracking สำหรับ Vehicle tracking

ตารางที่ 4 ผลลัพธ์ของระบบนับจำนวนยานพาหนะเปรียบเทียบระหว่าง Centroid tracking และ ByteTrack

วิธีทัศน์	ประเภทยานพาหนะ	GT	Centroid tracking		ByteTrack	
			Number	Error	Number	Error
ภาพมุมข้าง	รถโดยสาร	1	2	1	1	0
	รถยนต์	22	98	76	75	53
	รถจักรยานยนต์	24	28	4	53	29
	รถกระบะ	3	46	43	17	14
	รถบรรทุก	0	0	0	0	0
	รถตู้	3	16	13	20	17
	ผลรวม	53	-	137	-	113
	MAPE			-	258.49%	-
ภาพมุมบน	รถโดยสาร	2	2	0	5	3
	รถยนต์	21	84	63	38	17
	รถจักรยานยนต์	18	33	15	45	27
	รถกระบะ	6	9	3	24	18
	รถบรรทุก	2	30	28	9	7
	รถตู้	1	2	1	3	2
	ผลรวม	50	-	110	-	74
	MAPE				220%	-



(a) ก่อนการบดบัง

(b) หลังการบดบัง

รูปที่ 15 แสดงผลของการบดบังที่ยานพาหนะ ของ Centroid tracking



(a) ก่อนการบดบัง

(b) หลังการบดบัง

รูปที่ 16 แสดงผลของการบดบังที่ยานพาหนะ ของ ByteTrack

4.2.3 Vehicle tracking

สำหรับผลการเปรียบเทียบการทำงานของ ByteTrack ร่วมกับ Vehicle counting ทั้งแบบไม่มี ROI และมี ROI ได้ผลแสดงดังตารางที่ 5 ซึ่งจะพบว่าการนับแบบมี ROI จะให้ค่า MAPE ที่ต่ำกว่าแบบไม่มี ROI 177.80% และ 105.50% สำหรับวิดิทัศน์มุมข้าง และวิดิทัศน์มุมบน ตามลำดับ โดยสาเหตุหลักมาจากการนับแบบไม่มี ROI จะเกิด False detection ค่อนข้างสูงในบริเวณที่อยู่ห่างจากกล้องจราจร วัตถุที่อยู่ห่างจากกล้องจราจรจะมีขนาดเล็กทำให้ Vehicle detection จำแนกวัตถุว่าไม่ได้ไม่ดี ดังนั้นการนับจำนวนยานพาหนะแบบมี ROI จึงมีความเหมาะสมกว่าการนับแบบไม่มี ROI ตารางที่ 5 ผลลัพธ์ของระบบนับจำนวนยานพาหนะโดยใช้ ByteTrack เปรียบเทียบแบบไม่มี ROI และมี ROI

วิดิทัศน์	ประเภทยานพาหนะ	ไม่มี ROI			มี ROI		
		GT	Number	Error	GT	Number	Error
มุมข้าง	รถโดยสาร	1	1	0	1	1	0
	รถยนต์	22	75	53	19	21	2
	รถจักรยานยนต์	24	53	29	22	26	4
	รถกระบะ	3	17	14	3	6	3
	รถบรรทุก	0	0	0	0	0	0
	รถตู้	3	20	17	3	11	8
	ผลรวม	53	-	113	48	-	17
	MAPE		-	213.21%			35.41%
มุมบน	รถโดยสาร	2	5	3	2	3	1
	รถยนต์	21	38	17	19	23	4
	รถจักรยานยนต์	18	45	27	18	26	8
	รถกระบะ	6	24	18	6	12	6
	รถบรรทุก	2	9	7	2	3	1
	รถตู้	1	3	2	0	0	0
	ผลรวม	50	-	74	47	-	20
	MAPE		-	148.00%			42.50%

4.3 แก้ไขปรับปรุงพารามิเตอร์

เพื่อประสิทธิภาพในการนับ และแยกพาหนะของระบบ จึงทำการแก้ไขปรับปรุง (Fine-tuning) พารามิเตอร์ที่เกี่ยวข้องทั้งในส่วนของ YOLOX และ ByteTrack ดังแสดงในตารางที่ 6 โดยเราจะทำการแก้ไขปรับปรุงพารามิเตอร์ที่ส่งผลต่อประสิทธิภาพของระบบ ซึ่งพารามิเตอร์ ค่า IOU ของ Non-Maximum Suppression (IOU_threshold) และ ค่าความเชื่อมั่น (Score_thr) ของ YOLOX จะมีช่วยลดการเกิด False detection และการตรวจจับที่ทับซ้อนกันได้ในขณะที่ ค่าจำนวนเฟรมสูงสุดที่จะทำการติดตามวัตถุ (Num_frame_retain) และ จำนวนความต่อเนื่องของเฟรมที่จะทำการยืนยัน (Num_tentatives) ของ ByteTrack จะมีส่วนช่วยในการลดผลกระทบที่เกิดจากการบดบังได้ โดยผลการทดสอบแก้ไขปรับปรุงพารามิเตอร์ของวิดิทัศน์มุมข้าง และวิดิทัศน์มุมบน ดังแสดงในตารางที่ 7 และ 8 ตามลำดับ

ตารางที่ 6 แสดงรายละเอียดของพารามิเตอร์ที่จะทำการแก้ไขปรับปรุง

โมเดล	พารามิเตอร์	รายละเอียด	ค่าเริ่มต้น
YOLOX-X	IOU_threshold	ค่า IOU ของ Non-Maximum Suppression (NMS) ที่ใช้สำหรับการกรองวัตถุที่มีการตรวจจับซ้ำซ้อนกันออก	0.7
	Score_thr	เป็นค่าขีดแบ่งสำหรับการกรองวัตถุที่มีค่าความมั่นใจที่ต่ำกว่าค่าขีดแบ่งนี้	0.1
ByteTrack	Num_frame_retain	จำนวนเฟรมสูงสุดที่จะทำการติดตามวัตถุต่อไป ในกรณีที่วัตถุไม่ถูกตรวจจับได้ในเฟรมปัจจุบัน	30
	Num_tentatives	จำนวนความต่อเนื่องของเฟรมที่จะทำการยืนยันการติดตาม	3

จากการแก้ไขปรับปรุงพารามิเตอร์ของ YOLOX และ ByteTrack บนวิดิทัศน์มุมข้างจะพบว่าชุดพารามิเตอร์ Score_thr, IOU_Threshold, Num_frame_retain และ Num_tentatives เป็น 0.4, 0.3, 90 และ 1 ตามลำดับให้ค่าความผิดพลาดต่ำที่สุด ตามตารางที่ 7 สามารถลดค่าความผิดพลาดลงได้ 18.75% ก่อนการแก้ไขปรับปรุงพารามิเตอร์ ซึ่งช่วยแก้ปัญหาการตรวจจับซ้ำซ้อนลงได้ดังแสดงในรูปที่ 17 ซึ่งมีช่วยในการลดค่าความผิดพลาดของระบบลดลงได้



(a) ก่อนการ Finetune



(b) หลังการ Finetune

รูปที่ 17 เปรียบเทียบผลก่อนและหลังการแก้ไขปรับปรุงพารามิเตอร์

ตารางที่ 7 ค่า MAPE จากการแก้ไขปรับปรุงพารามิเตอร์ของวิดิทัศน์มุมข้าง

วิดิทัศน์	พารามิเตอร์				MAPE
	Score_thr	IOU_threshold	Num_frame_retain	Num_tentatives	
มุมข้าง	0.1	0.7	30	3	35.42%
			90	1	33.33%
			30	3	33.33%
		0.3	90	1	31.25%
			30	3	27.08%
			90	1	25.00%
	0.4	0.7	30	3	27.08%
			90	1	22.92%
			30	3	33.33%
		0.3	90	1	31.25%
			30	3	25.00%
			90	1	22.91%
			30	3	27.08%
			90	1	25.00%
			30	3	18.75%
			90	1	16.67%

สำหรับการแก้ไขปรับปรุงพารามิเตอร์บนวิดิทัศน์มุมบนพบว่าชุดพารามิเตอร์ Score_thr, IOU_Threshold, Num_frame_retain และ Num_tentatives เป็น 0.4, 0.3, 90 และ 1 ตามลำดับให้ค่าความผิดพลาดต่ำที่สุด ตามตารางที่ 8 สามารถลดค่าความผิดพลาดลงได้ 19.15% เปรียบเทียบกับก่อนการแก้ไขปรับปรุงพารามิเตอร์

ตารางที่ 8 ค่า MAPE จากการแก้ไขปรับปรุงพารามิเตอร์ของวีดิทัศน์มูมบน

วีดิทัศน์	พารามิเตอร์				MAPE
	Score_thr	IOU_threshold	Num_frame_retain	Num_tentatives	
มูมบน	0.1	0.7	30	3	42.55%
				1	34.04%
			90	3	38.30%
				1	29.79%
		0.3	30	3	36.17%
				1	27.66%
			90	3	31.91%
				1	23.40%
	0.4	0.7	30	3	42.55%
				1	34.04%
			90	3	38.30%
				1	29.79%
		0.3	30	3	36.17%
				1	27.66%
			90	3	31.91%
				1	23.40%

บทที่ 5

บทสรุป

5.1 สรุปผลงานวิจัย

จากการทดสอบ Object detection พบว่า YOLOX-X สามารถทำประสิทธิภาพ mAP บนชุดข้อมูลภาพมุมข้าง และภาพด้านมุมบน เท่ากับ 65.85% และ 82.88% ตามลำดับ โดยสูงกว่า YOLOV3 และ YOLOX-S ดังนั้น YOLOX-X จึงมีความเหมาะสมที่จะถูกนำมาใช้ในระบบ Vehicle detection จากนั้นจึงทำการเปรียบเทียบ object tracking จำนวน 2 ขั้นตอนวิธี คือ Centroid tracking และ ByteTrack พบว่า ByteTrack ให้ค่าความคลาดเคลื่อนจากการนับที่น้อยกว่า Centroid tracking track 45.28% และ 72.00% สำหรับวิดีโอที่มุมข้าง และวิดีโอที่มุมบน ตามลำดับ อันเนื่องจาก ByteTrack มีความสามารถในการจัดการการบดบัง (Occlusion) ได้ดีกว่า และเมื่อนำ YOLOX-X และ ByteTrack ไปทำงานร่วมกับการนับแบบมี ROI จะช่วยลดค่าความผิดพลาดลงได้อีก 177.80% และ 105.50% สำหรับวิดีโอที่มุมข้าง และวิดีโอที่มุมบน ตามลำดับ

เพื่อเพิ่มประสิทธิภาพในการนับจำนวนยานพาหนะเราได้ทำการแก้ไขปรับปรุงพารามิเตอร์ที่จะช่วยลดค่าความผิดพลาดลงได้ของทั้ง YOLOX-X และ ByteTrack ซึ่งประกอบไปด้วย Score_thr, IOU_Threshold, Num_frame_retain และ Num_tentatives โดยผลหลังการแก้ไขปรับปรุงพารามิเตอร์ พบว่าสามารถลดค่าความผิดพลาดลงได้ 18.75% และ 19.15% สำหรับวิดีโอที่มุมข้าง และมุมบนตามลำดับ โดยการแก้ไขปรับปรุงพารามิเตอร์จะช่วยลดปัญหาการตรวจจับซ้ำซ้อนลงได้ และช่วยรักษาการติดตามวัตถุขณะเกิดการบดบังได้

5.2 ปัญหาและข้อจำกัดที่พบ

5.2.1 ความสับสนในการแยกแยะยานพาหนะของ Vehicle detection

ในวิดีโอที่มุมข้าง และมุมบน จะพบยานพาหนะในบางประเภทจะมีลักษณะที่คล้ายคลึงกัน หรือมีบางส่วนของยานพาหนะไปคล้ายคลึงกับยานพาหนะอีกประเภท ดังรูปที่ 18 และ 19 โดยในรูปที่ 18 จะพบว่ามีส่วนของรถกระบะที่มีลักษณะคล้ายคลึงกับรถตู้ และในรูปที่ 19 ยานพาหนะในรูปจะมีลักษณะคล้ายคลึงทั้งรถยนต์ และรถกระบะ ทำให้โมเดลเกิดความสับสนขึ้นได้



รูปที่ 18 โมเดลมีการตรวจจับบางส่วนของรถกระบะเป็นรถตู้



(a) วิดีทัศน์มุมข้าง



(b) วิดีทัศน์มุมบน

รูปที่ 19 โมเดลเกิดความสับสนจากยานพาหนะที่มีลักษณะคล้ายคลึงทั้งรถยนต์และรถกระบะ

5.2.2 การสลับไอดีของยานพาหนะ

เมื่อยานพาหนะประเภทเดียวกัน ขนาดใกล้เคียงกัน ในวิดีโอทัศน์มุมข้างเกิดการเคลื่อนที่สวนทางกัน ในแนวระดับใกล้เคียงกัน จะพบการเกิดการสลับไอดีของยานพาหนะขึ้นได้ดังแสดงในรูปที่ 20 โดยรถจักรยานยนต์ที่เคลื่อนที่จากทางด้านซ้ายของวิดีโอทัศน์เกิดการเคลื่อนที่สวนทางกับรถจักรยานยนต์ในทิศทางตรงกันข้ามและมีพื้นที่ bbox ซ้อนทับกันในบางเฟรม จึงเกิดการสลับไอดีกันขึ้น โดยปัญหาการสลับไอดีอาจนำไปสู่การนับยานพาหนะที่ขาดหายไป



รูปที่ 20 การสลับไอดีของรถจักรยานยนต์ที่วิ่งสวนทางกัน

5.2.3 สาเหตุค่าความผิดพลาดจากการนับของวิดิทัศน์มุมบนสูงกว่าวิดิทัศน์มุมข้าง

จากผลการทดสอบในตารางที่ 7 และ 8 สามารถสรุปผลค่าความผิดพลาดที่ต่ำที่สุดของวิดิทัศน์มุมข้าง และมุมบน ได้ดังตารางที่ 9 ซึ่งจะพบว่าค่าความผิดพลาดของการนับในวิดิทัศน์มุมบนมีค่าที่สูงกว่าวิดิทัศน์มุมข้าง โดยที่วิดิทัศน์มุมบนไม่เกิดปัญหาการบดบังแบบเต็มเหมือนกับวิดิทัศน์มุมข้าง

ตารางที่ 9 สรุปผลค่าความผิดพลาดของการนับยานพาหนะของวิดิทัศน์มุมบน และวิดิทัศน์มุมข้าง

วิดิทัศน์	ค่าความผิดพลาดของการนับ (MAPE)
วิดิทัศน์มุมข้าง	16.67%
วิดิทัศน์มุมบน	23.40%

ซึ่งเมื่อทำการวิเคราะห์จำนวนของยานพาหนะที่มีการนับผิดในแต่ละประเภทของวิดิทัศน์มุมบนดังแสดงในตารางที่ 10 จะพบว่ายานพาหนะประเภทรถจักรยานยนต์ที่มีจำนวนนับผิดพลาดเยอะที่สุด ซึ่งสาเหตุหลักมาจากปัญหาการกำหนดพื้นที่ ROI ที่กว้างเกินขอบเขตถนน ดังแสดงในรูปที่ 21 จะพบว่าระบบนับยานพาหนะมีการนับรถจักรยานยนต์ที่ไม่ได้อยู่บนถนนแต่มีการจอดอยู่บริเวณทางเท้าข้างบน และรถจักรยานยนต์บดบังด้วยตู้ไปรษณีย์และเสาไฟฟ้า ซึ่งทำให้เกิดการนับจักรยานยนต์คันซ้ำด้วยกันถึง 4 ID จากจำนวนที่นับพลาดทั้งหมด 5 ID

ตารางที่ 10 จำนวนยานพาหนะที่นับผิดพลาดแยกตามประเภทของวิดิทัศน์มุมบน

ประเภทยานพาหนะ	จำนวนยานพาหนะที่เกิดขึ้น	จำนวนยานพาหนะที่นับ	จำนวนที่นับผิดพลาด (Error)
	จริง (Ground Truth)	จากระบบ (Counting)	
รถโดยสาร	2	3	1
รถยนต์	19	22	3
รถจักรยานยนต์	18	23	5
รถกระบะ	6	8	2
รถบรรทุก	2	2	0
รถตู้	-	-	-



รูปที่ 21 แสดงปัญหาการนับรถจักรยานยนต์ที่ไม่ได้อยู่บนถนนและมีจอดหยุดนิ่ง


สำหรับจำนวนยานพาหนะประเภทรถยนต์ และรถกระบะ ที่มีการนับเกินจำนวนเกิดจากปัญหาการนับซ้ำในรถที่มีลักษณะที่มีความคล้ายคลึงกับรถใน 2 ประเภท คือ รถ SUV และ รถกระบะที่มีการต่อเติมกระบะข้างหลังดังรูปที่ 22



รูปที่ 22 แสดงความผิดพลาดในการนับยานพาหนะที่มีลักษณะคล้ายคลึงทั้งรถยนต์และรถกระบะ

5.2.4 โมเดลทำประสิทธิภาพได้ดีกับวีดิทัศน์ที่เฉพาะเจาะจง

เนื่องจากโมเดลถูกเทรนกับชุดข้อมูลภาพที่มีจำเพาะเจาะจงมุมของกล้อง และลักษณะของถนน เพื่อให้ระบบมีประสิทธิภาพในการตรวจจับและแยกแยะประเภทยานพาหนะที่สูง แต่เมื่อมีการเอาระบบไปใช้กับวีดิทัศน์อื่นๆประสิทธิภาพก็อาจจะลดต่ำลง หรือเกิด False positive detection ขึ้นได้ ดังแสดงในรูปที่ 23 จะพบว่าเมื่อเราเอาระบบนับยานพาหนะที่พัฒนาสำหรับวีดิทัศน์มุมข้างอื่นๆ ที่มีการเปลี่ยนมุมของกล้อง และลักษณะของถนน จะพบปัญหา False positive detection ขึ้น อย่างไรก็ตามในมุมมองของวีดิทัศน์ที่มีลักษณะคล้ายคลึงกัน เราสามารถใช้พารามิเตอร์ของ YOLOX และ ByteTrack ชุดเดียวกันที่ได้มีการปรับปรุงให้มีความเหมาะสมตามมุมของกล้อง โดยชุดของพารามิเตอร์แสดงดังตารางที่ 7 และ 8 มาเป็นค่าเริ่มต้นได้



รูปที่ 23 แสดงการเกิด False positive detection เมื่อมีการเปลี่ยนมุมกล้อง และถนน

5.3 แนวทางการปรับปรุง

5.3.1 เพิ่มจำนวนยานพาหนะในชุดข้อมูล

เพิ่มจำนวนภาพของยานพาหนะบางลักษณะที่ Vehicle detection ยังมีความสับสนในจำแนกประเภท เพื่อให้โมเดลสามารถเรียนรู้ และจำแนกยานพาหนะแต่ละลักษณะได้ถูกประเภทได้ดีขึ้น และช่วยลดค่าความผิดพลาดในการนับจำนวนยานพาหนะด้วย

5.3.2 เพิ่มการระบุทิศทางของยานพาหนะ

เพื่อช่วยลดปัญหาการสลับไอดีของยานพาหนะ ระบบอาจจะต้องมีการระบุทิศทางเคลื่อนที่ของยานพาหนะแต่ละคนเข้าไปเป็นอีกหนึ่งตัวแปรในการติดตามวัตถุ นอกเหนือจากใช้ค่า IOU เพียงอย่างเดียว ซึ่งจะช่วยลดปัญหาการตกหล่นของไอดีที่ควรจะนับ

5.3.3 เพิ่มการระบุขอบเขตของถนนในการกำหนดพื้นที่ ROI

เพื่อช่วยลดปัญหา False detection และ การนับยานพาหนะที่ไม่ได้สัญจรบนท้องถนน โดยระบบอาจจะทำการ Segmentation บริเวณที่เป็นถนนในวีดิทัศน์เพื่อช่วยกำหนดความกว้างของ ROI ให้กว้างเท่ากับพื้นที่ที่เป็นถนนเท่านั้น

5.3.4 เทรน Detector เพิ่มเติมเมื่อมีการเปลี่ยนมุมมอง หรือเปลี่ยนลักษณะถนน

เมื่อมีการปรับองศาของมุมมองจากเดิมทั้งมุมข้าง หรือมุมบน เพื่อเพิ่มประสิทธิภาพในการตรวจจับและแยกแยะ อาจจะมีการเทรน Detector เพิ่มเติมด้วยชุดข้อมูลขนาดเล็กของมุมมอง และถนนนั้น โดยใช้การ Transfer learning จากโมเดลที่เทรนบนชุดข้อมูลภาพมุมข้าง หรือมุมบนเป็นโมเดลตั้งต้น

บรรณานุกรม

- 1 Lin, Y., Wang, P., and Ma, M.: 'Intelligent Transportation System(ITS): Concept, Challenge and Opportunity', in Editor (Ed.)^(Eds.): 'Book Intelligent Transportation System(ITS): Concept, Challenge and Opportunity' (2017, edn.), pp. 167-172
- 2 Malhi, M.H., Aslam, M.H., Saeed, F., Javed, O., and Fraz, M.: 'Vision based intelligent traffic management system', in Editor (Ed.)^(Eds.): 'Book Vision based intelligent traffic management system' (IEEE, 2011, edn.), pp. 137-141
- 3 Manikonda, P., Yerrapragada, A.K., and Annasamudram, S.S.: 'Intelligent traffic management system', in Editor (Ed.)^(Eds.): 'Book Intelligent traffic management system' (IEEE, 2011, edn.), pp. 119-122
- 4 Cucchiara, R.a.P., M. and Mello, P.: 'Image Analysis and Rule-Based Reasoning for a Traffic Monitoring System', Trans. Intell. Transport. Syst., 2000, 1, pp. 119-130
- 5 Klein, I., Toledo, T., and Filin, S.: 'Vehicle Detection in Far Field of View of Video Sequences', Transportation Research Record, 2008, 2086, (1), pp. 23-29
- 6 Zhuo, L., Jiang, L., Zhu, Z., Li, J., Zhang, J., and Long, H.: 'Vehicle classification for large-scale traffic surveillance videos using Convolutional Neural Networks', Mach. Vision Appl., 2017, 28, (7), pp. 793-802
- 7 Liang, H., Song, H., Li, H., and Dai, Z.: 'Vehicle Counting System using Deep Learning and Multi-Object Tracking Methods', Transportation Research Record, 2020, 2674, (4), pp. 114-128
- 8 Neupane, B., Horanont, T., and Aryal, J.: 'Real-Time Vehicle Classification and Tracking Using a Transfer Learning-Improved Deep Learning Network', Sensors, 2022, 22, (10), pp. 3813
- 9 Ali, I., and Dailey, M.N.: 'Multiple human tracking in high-density crowds', Image and vision computing, 2012, 30, (12), pp. 966-977
- 10 Hongyong, T., and Youling, Y.: 'Finger tracking and gesture recognition with kinect', in Editor (Ed.)^(Eds.): 'Book Finger tracking and gesture recognition with kinect' (IEEE, 2012, edn.), pp. 214-218
- 11 Capi, G., Toda, H., and Nagasaki, T.: 'A vision based robot navigation and human

- tracking for social robotics’, in Editor (Ed.)^(Eds.): ‘Book A vision based robot navigation and human tracking for social robotics’ (IEEE, 2010, edn.), pp. 1-6
- 12 Lee, B.Y., Liew, L.H., Cheah, W.S., and Wang, Y.C.: ‘Occlusion handling in videos object tracking: A survey’, in Editor (Ed.)^(Eds.): ‘Book Occlusion handling in videos object tracking: A survey’ (IOP Publishing, 2014, edn.), pp. 012020
- 13 Comaniciu, D., and Ramesh, V.: ‘Mean shift and optimal prediction for efficient object tracking’, in Editor (Ed.)^(Eds.): ‘Book Mean shift and optimal prediction for efficient object tracking’ (IEEE, 2000, edn.), pp. 70-73
- 14 Zhang, Y., Sun, P., Jiang, Y., Yu, D., Weng, F., Yuan, Z., Luo, P., Liu, W., and Wang, X.: ‘ByteTrack: Multi-Object Tracking by Associating Every Detection Box’ (arXiv, 2021. 2021)
- 15 Redmon, J., and Farhadi, A.: ‘YOLOv3: An Incremental Improvement’, arXiv, 2018
- 16 Redmon, J., and Farhadi, A.: ‘YOLO9000: better, faster, stronger’, in Editor (Ed.)^(Eds.): ‘Book YOLO9000: better, faster, stronger’ (2017, edn.), pp. 7263-7271
- 17 Kuznetsova, A., Rom, H., Alldrin, N., Uijlings, J., Krasin, I., Pont-Tuset, J., Kamali, S., Popov, S., Mallocci, M., Kolesnikov, A., Duerig, T., and Ferrari, V.: ‘The Open Images Dataset V4’, International Journal of Computer Vision, 2020, 128, (7), pp. 1956-1981
- 18 Ge, Z., Liu, S., Wang, F., Li, Z., and Sun, J.: ‘YOLOX: Exceeding YOLO Series in 2021’, arXiv, 2021
- 19 Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C.L.: ‘Microsoft coco: Common objects in context’, in Editor (Ed.)^(Eds.): ‘Book Microsoft coco: Common objects in context’ (Springer, 2014, edn.), pp. 740-755
- 20 Milan, A., Leal-Taixé, L., Reid, I., Roth, S., and Schindler, K.: ‘MOT16: A benchmark for multi-object tracking’, arXiv preprint arXiv:1603.00831, 2016
- 21 Dendorfer, P., Rezatofighi, H., Milan, A., Shi, J., Cremers, D., Reid, I., Roth, S., Schindler, K., and Leal-Taixé, L.: ‘Mot20: A benchmark for multi object tracking in crowded scenes’, arXiv preprint arXiv:2003.09003, 2020
- 22 Padilla, R., Passos, W.L., Dias, T.L., Netto, S.L., and Da Silva, E.A.: ‘A comparative analysis of object detection metrics with a companion open-source toolkit’, Electronics, 2021, 10, (3), pp. 279

- 23 Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., and Zitnick, C.L.: 'Microsoft coco: Common objects in context', in Editor (Ed.)^(Eds.): 'Book Microsoft coco: Common objects in context' (Springer, 2014, edn.), pp. 740-755
- 24 Zisserman, A., Winn, J., Fitzgibbon, A., Van Gool, L., Sivic, J., Williams, C., and Hogg, D.: 'In memoriam: Mark Everingham', IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34, (11), pp. 2081-2082





จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	วิชูกร คันธินทร
วัน เดือน ปี เกิด	18 กันยายน 2536
สถานที่เกิด	จังหวัดสุราษฎร์ธานี
วุฒิการศึกษา	จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	133/90 ต.มะขามเตี้ย อ.เมืองสุราษฎร์ธานี จ.สุราษฎร์ธานี
ผลงานตีพิมพ์	W. Kuntintara, K. Lertniphonphan and P. Siricharoen, "Multi-class Vehicle Counting System for Multi-view Traffic Videos," 2022 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC), Chiang Mai, Thailand.

