



ระบบตรวจนับและจำแนกประเภทยานพาหนะแบบอัตโนมัติ
สำหรับถนนในเขตเมือง ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน

AUTOMATIC COUNTING AND CLASSIFICATION OF VEHICLE
ON URBAN ROADS BY CONVOLUTIONAL NEURAL NETWORK

อัฐพงศ์ สังข์เพชร

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2565

ระบบตรวจนับและจำแนกประเภทยานพาหนะแบบอัตโนมัติ
สำหรับถนนในเขตเมือง ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2565
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

AUTOMATIC COUNTING AND CLASSIFICATION OF VEHICLE
ON URBAN ROADS BY CONVOLUTIONAL NEURAL NETWORK



ATTAPONG SANGPHET

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2022

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

ระบบตรวจนับและจำแนกประเภทยานพาหนะแบบอัตโนมัติ
สำหรับถนนในเขตเมือง ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ของ
อัฐพงศ์ สังข์เพชร

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก
(อาจารย์ ดร.วีระ สอึ้ง)

..... ประธาน
(รองศาสตราจารย์ ดร.สุพัฒนา เขื่อนทิวเกียรติ)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	ระบบตรวจจับและจำแนกประเภทยานพาหนะแบบอัตโนมัติ สำหรับถนนในเขตเมือง ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ผู้วิจัย	อัฐพงศ์ สังข์เพชร
ปริญญา	วิทยาศาสตรมหาบัณฑิต
ปีการศึกษา	2565
อาจารย์ที่ปรึกษา	อาจารย์ ดร. วีระ สอิ่ง

ในพื้นที่เขตในเมืองของเมืองขนาดใหญ่หลายๆแห่งในปัจจุบันนั้น มีการขยายตัวขึ้นอย่างรวดเร็ว จึงส่งผลให้เกิดการเดินทางและปริมาณยานพาหนะที่ใช้สัญจรบนท้องถนนเพิ่มมากขึ้น ซึ่งก่อให้เกิดผลกระทบและปัญหาด้านการจราจรต่างๆตามมา และอาจส่งผลกระทบต่อไปยังการพัฒนาในภาคส่วนอื่นๆอย่าง ระบบเศรษฐกิจหรือระบบสิ่งแวดล้อมได้ เพื่อจัดการกับปัญหาด้านการจราจรตามหลักของวิศวกรรมขนส่งและจราจรนั้น ข้อมูลปริมาณจราจรจึงเป็นข้อมูลที่มีความสำคัญมากในการศึกษาและออกแบบเพื่อแก้ปัญหาด้านการจราจร โดยต้องมีการเก็บบันทึกข้อมูลปริมาณจราจรอย่างสม่ำเสมอ และเพื่อเป็นการส่งเสริมและพัฒนางานด้านวิศวกรรมจราจร ในงานวิจัยนี้ ผู้วิจัยได้นำเสนอระบบตรวจจับยานพาหนะและจำแนกประเภทของยานพาหนะ ที่ใช้หลักโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) อย่าง YOLOv8 เป็นอัลกอริทึมในการตรวจจับยานพาหนะ โดยมีการสร้างชุดข้อมูลของยานพาหนะท้องถิ่นในประเทศไทย สำหรับใช้เป็นข้อมูลในการฝึกฝนระบบตรวจจับยานพาหนะ ให้สามารถจำแนกยานพาหนะได้อย่างหลากหลาย และทำงานร่วมกับระบบติดตามยานพาหนะที่สามารถติดตามยานวัตถุหลายวัตถุในภาพได้ดีอย่าง ByteTrack และ BotSORT และนำไปประยุกต์ใช้ในการนับยานพาหนะโดยการสร้างเส้นอ้างอิงบนถนนในการเก็บข้อมูลจำนวนและประเภทของยานพาหนะที่เคลื่อนที่ผ่านในสภาพการณ์ที่ต่างกันไป โดยในระบบที่สร้างขึ้นนี้ มีระดับความแม่นยำเฉลี่ยในการนับจำนวนยานพาหนะที่ค่อนข้างแม่นยำสูงเกินร้อยละ 90 เปอร์เซ็นต์ในหลายๆสภาพการณ์ และมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) ในการจำแนกประเภทของยานพาหนะเฉลี่ยรวมทุกสภาพการณ์อยู่ที่ประมาณ 19 เปอร์เซ็นต์

คำสำคัญ : การนับยานพาหนะ, การตรวจจับยานพาหนะ, การติดตามยานพาหนะ, ระบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน

Title	AUTOMATIC COUNTING AND CLASSIFICATION OF VEHICLE ON URBAN ROADS BY CONVOLUTIONAL NEURAL NETWORK
Author	ATTAPONG SANGPHET
Degree	MASTER OF SCIENCE
Academic Year	2022
Thesis Advisor	Vera Sa-ing , Ph.D.

In current years, some large cities have expanded rapidly and many trips have been generated on the public roads in the city. This huge increase in the number of vehicles on the road causes many transportation and traffic problems, especially in urban areas. Without effective management, transportation problems will affect other development sectors, such as economics or environmental systems. In terms of transportation and traffic engineering management, traffic information is an important and needs to be collected regularly and use it for traffic studies and designs. In this paper, a vehicle counting and classification system was proposed using CNN for collecting volume and type of vehicles. The proposed system used YOLOv8 as our vehicle detector and trained a detector system with our local dataset of Thailand vehicles which is collected of 11 different types of vehicle images. Then, trained detectors were combined with some great performance trackers in multi-object tracking, ByteTrack and BotSORT. For the counting process, a referenced counting line was provided to collect the number of vehicles and their class when they drove past the line. Then the system was tested and evaluated with various scenarios of traffic conditions. The video results showed that our proposed system had a good performance for counting vehicles. The figures of average accuracy of total vehicle counting and weight mean absolute percentage error of classified counting were 90% and 19%, respectively.

Keyword : Vehicle counting, Vehicle detection, Vehicle tracking, Convolutional Neural Network

กิตติกรรมประกาศ

รายงานสารนิพนธ์ฉบับนี้สำเร็จสมบูรณ์ไปได้ เนื่องจากได้รับความช่วยเหลือและความเอาใจใส่เป็นอย่างยิ่งจาก ดร.วีระ สัจฉิ่ง อาจารย์ประจำภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และที่ปรึกษาหลักในงานวิจัยครั้งนี้ ที่ได้เสียสละเวลาส่วนตัวมาให้ความรู้ให้คำปรึกษาในการทำงานเสมอมา ตลอดจนช่วยแนะนำและแก้ไขข้อบกพร่องต่างๆในการทำงานวิจัยครั้งนี้ จนกระทั่งงานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ขอกราบขอบพระคุณอย่างสูงมา ณ ที่นี้

ขอขอบคุณคณาจารย์ทุกท่านที่สอนสั่งและให้ความรู้ตามแผนการเรียนรู้อิงหลักสูตรของสาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และให้คำแนะนำต่างๆในการทำงานที่เกี่ยวข้องกับงานวิจัยครั้งนี้

ขอขอบคุณพี่ๆและเพื่อนๆ นิสิตปริญญาโทร่วมชั้นเรียนทุกท่าน ที่คอยสนับสนุน ให้ความช่วยเหลือและให้กำลังใจผู้วิจัยในการทำงานครั้งนี้ตลอดมา

ขอขอบคุณเพื่อนร่วมงานทุกท่าน ที่ให้คำแนะนำในเรื่องการศึกษาและการทำงานวิจัยในครั้งนี้ ทั้งยังมีส่วนช่วยสนับสนุนข้อมูลต่างๆที่ได้รวบรวมมาใช้ในงานวิจัยครั้งนี้เป็นอย่างมาก ทำให้สามารถทำงานวิจัยฉบับนี้สำเร็จไปได้ตามแผนการทำงานที่ตั้งใจไว้

สุดท้ายนี้ผู้วิจัยหวังเป็นอย่างยิ่งว่า งานวิจัยฉบับนี้จะเป็นประโยชน์แก่ผู้ที่เกี่ยวข้องและสนใจต่อไปไม่มากนักน้อย หากมีข้อผิดพลาดประการใด ผู้วิจัยขอน้อมรับและขออภัยมา ณ ที่นี้ด้วย

อัฐพงศ์ สังข์เพชร

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ฌ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของงานวิจัย.....	1
1.2 วัตถุประสงค์ของการทำงานวิจัย	3
1.3 ขอบเขตของการทำงานวิจัย	4
1.4 ขั้นตอนของการทำงานวิจัย.....	4
1.5 ประโยชน์ของการทำงานวิจัย.....	5
บทที่ 2 ทบทวนวรรณกรรม และงานวิจัยที่เกี่ยวข้อง.....	6
2.1 ระบบตรวจจับยานพาหนะ (Vehicle Detection).....	6
2.2 ระบบติดตามยานพาหนะ (Vehicle Tracking)	15
2.3 ระบบนับยานพาหนะ (Vehicle Counting)	23
2.4 ระบบจำแนกประเภทยานพาหนะ (Vehicle Classification)	31
2.5 การประเมินประสิทธิภาพ (Evaluation).....	34
บทที่ 3 กระบวนการ และวิธีการดำเนินการวิจัย.....	39
3.1 การเก็บรวบรวมข้อมูล (Data Acquisition).....	39
3.2 การเตรียมข้อมูล (Pre-Processing).....	41

3.3 การตรวจจับยานพาหนะ (Vehicle Detection)	43
3.4 การติดตามยานพาหนะ (Vehicle Tracking)	47
3.5 การนับปริมาณจราจรและจำแนกประเภทของยานพาหนะ (Vehicle Counting and Classification)	47
3.6 วัดผลการทดลอง	48
บทที่ 4 การทดลอง และผลลัพธ์ของการวิจัย	49
4.1 ผลการทดลองเบื้องต้น	49
4.1.1 ระบบตรวจจับยานพาหนะ	49
4.1.3 ระบบนับยานพาหนะ	52
4.1.4 ระบบแยกประเภทยานพาหนะ	55
4.2 ผลการทดลองของระบบที่นำเสนอ	56
บทที่ 5 การสรุปผลการวิจัย การอภิปรายผล และข้อเสนอแนะของการวิจัย	67
บรรณานุกรม	73
ประวัติผู้เขียน	77

สารบัญตาราง

หน้า

ตาราง 1 ผลการเปรียบเทียบสัดส่วนความแม่นยำในการนับยานพาหนะของโมเดลที่เลือกใช้ ภายใต้เงื่อนไขความแตกต่างของสภาพอากาศและช่วงเวลาในงานวิจัยของ A. Alsanabani et al	36
ตาราง 2 ผลการนับยานพาหนะของงานวิจัยที่แนะนำให้เสนองานวิจัยของ Harjoko et al	37
ตาราง 3 แสดงผลการนับยานพาหนะแยกประเภทของยานพาหนะจากชุดข้อมูลที่ 1, ชุดข้อมูลที่ 2 และ ชุดข้อมูลที่ 3 ในงานวิจัยของ Zhang & Zhang	38
ตาราง 4 รายละเอียดจำนวน instance ของยานพาหนะแต่ละประเภทในชุดข้อมูล	42
ตาราง 5 แสดงผลการเปรียบเทียบการทำงานของ YOLOv8n, YOLOv8m และ YOLOv8x กับ ระบบติดตามวัตถุ ByteTrack	57
ตาราง 6 แสดงผลการเปรียบเทียบการทำงานของ YOLOv8n, YOLOv8m และ YOLOv8x กับ ระบบติดตามวัตถุ BotSORT	57
ตาราง 7 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ มีความละเอียดของภาพระดับ HD (720p)	59
ตาราง 8 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางคืน (จุดสำรวจตำแหน่งเดียวกันกับวิดีโอที่ 1) มีความ ละเอียดของภาพระดับ HD (720p).....	60
ตาราง 9 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งออกจากจุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ การจราจรใช้ความเร็วในการขับ ที่สูงมีความละเอียดของภาพระดับ HD (720p)	61
ตาราง 10 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน บริเวณพื้นถนนมีเงาตกกระทบไม้สุม้าเสมอ มีความ ละเอียดของภาพระดับ HD (720p).....	62

ตาราง 11 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ
 ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงน้อย มองเห็นยานพาหนะได้ชัดเจน มีความ
 ละเอียดยของภาพระดับ HD (720p)..... 63

ตาราง 12 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจร
 ค่อนข้างติดขัดเล็กน้อยจากการหยุดรถสัญญาณไฟจราจร ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลา
 กลางวัน มีความละเอียดยของภาพระดับ Full HD (1080p) 64

ตาราง 13 ผลสรุปผลการเปรียบเทียบการทำงานของระบบของการจราจรในทุกๆสภาพการณ์ โดย
 แสดงในรูปแบบความแม่นยำในการนับยานพาหนะทั้งหมด และค่าเฉลี่ยของเปอร์เซ็นต์ความ
 ผิดพลาดสัมบูรณ์ในการจำแนกประเภทของยานพาหนะทุกประเภท 65



สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 การทำ foreground extraction ด้วยหลักการ background subtraction ภาพพื้นหลัง, (b) ภาพปัจจุบัน และ (c) ภาพผลต่างของภาพพื้นหลังและภาพปัจจุบัน ในงานวิจัยของ Seenouvang et al.....	7
ภาพประกอบ 2 การทำ background subtraction ด้วยหลักการ Ground update algorithm ในงานวิจัยของ Liu et al.....	8
ภาพประกอบ 3 การทำ background subtraction ด้วยหลักการ Mixture of Gaussians 2 ในงานวิจัยของ Muchtar et al.....	9
ภาพประกอบ 4 รูปภาพ แสดงสถาปัตยกรรมของ YOLO (a) แสดงกระบวนการทำนายของหลักการ YOLO และ (b) แสดงโครงสร้างของสถาปัตยกรรม YOLOv1 ที่ใช้ในการเรียนรู้ด้วยหลักการโครงสร้างประสาทเทียมแบบคอนโวลูชัน.....	11
ภาพประกอบ 5 แสดงการตรวจนับประมาณยานพาหนะ โดยใช้หลักการ YOLO ในการตรวจจับยานพาหนะ ในงานวิจัยของ Cruz et al.....	12
ภาพประกอบ 6 รูปภาพแสดงตัวอย่างผลการตรวจจับยานพาหนะใช้หลักการ YOLO ในงานวิจัยของ Chauhan et al.....	14
ภาพประกอบ 7 รูปภาพแสดงผลการเปรียบเทียบการระบบตรวจจับยานพาหนะ ที่ใช้หลักการ YOLOv1 ถึง YOLOv5 โดยใช้ Mean Average Precision (mAP) เป็นตัวชี้วัด ในงานวิจัยของ Chauhan et al.....	14
ภาพประกอบ 8 แสดงตัวอย่างผลการตรวจจับยานพาหนะของงานวิจัยในงานวิจัยของ Harjoko et al.....	16
ภาพประกอบ 9 แสดงภาพตัวอย่างระบบติดตามวัตถุ ภาพต้นฉบับ, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของ YOLO, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของ foreground-background subtraction, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของอัลกอริทึมที่น่าเสนอในงานวิจัยของ Forero & Calderon.....	17

ภาพประกอบ 10 อัลกอริทึมการติดตามยานพาหนะและคนเดินเท้าที่นำเสนอในงานวิจัยของ Forero & Calderon	18
ภาพประกอบ 11 แสดงตัวอย่างผลการตรวจจับและติดตามยานพาหนะของงานวิจัยที่นำเสนอในงานวิจัยของ Forero & Calderon	19
ภาพประกอบ 12 กระบวนการทำงานของระบบในงานวิจัยของ Zhang & Zhang.....	21
ภาพประกอบ 13 การจัดอันดับโมเดลการติดตามวัตถุโดยใช้ตัวชี้วัดเป็น MOTA ที่มา: Papers with Code. (2023). https://paperswithcode.com/sota/multi-object-tracking-on-mot17	23
ภาพประกอบ 14 แสดงตัวอย่างการตรวจจับและนับจำนวนของยานพาหนะในงานวิจัยของ Choudhury et al	25
ภาพประกอบ 15 แสดงตัวอย่างการตรวจจับและนับจำนวนของยานพาหนะในงานวิจัยของ Sindhu (a) แสดงการตรวจจับยานพาหนะจับที่ทำงานได้ดี และ (b) แสดงการตรวจจับยานพาหนะที่ทำงานได้ไม่ดี.....	26
ภาพประกอบ 16 ผลการนับยานพาหนะของระบบในงานวิจัยของ Sindhu.....	26
ภาพประกอบ 17 ภาพแสดงการตัวอย่างระบบตรวจจับและนับยานพาหนะในงานวิจัยของ Seenouvang et al รูปภาพ (a) region of interest (b) การแบ่งแยกพื้นที่ของ ROI และ (c) virtual detection zone	28
ภาพประกอบ 18 ระบบตรวจจับยานพาหนะในงานวิจัยของ Seenouvang et al รูปภาพ (a), (b), (c) และ (d) แสดงตัวอย่างการนับยานพาหนะ	28
ภาพประกอบ 19 แสดงตัวอย่างการใช้ virtual loops และ detection line ในการนับจำนวนยานพาหนะของระบบในงานวิจัยของ Liu et al.....	30
ภาพประกอบ 20 แสดงตัวอย่างการใช้ detection line ในการนับจำนวนยานพาหนะของระบบในงานวิจัยของ Liu et al	31
ภาพประกอบ 21 ตัวอย่างการตรวจจับของระบบแยกประเภทของยานพาหนะท้องถิ่นในงานวิจัยของ Cruz et al	32
ภาพประกอบ 22 แสดงตัวอย่างผลการทดสอบการจำแนกประเภทของยานพาหนะท้องถิ่นที่สร้างขึ้นได้ โดยใช้ตัวชี้วัดเป็นค่า precision ในงานวิจัยของ Chauhan et al	33

ภาพประกอบ 23 ภาพแสดงการจำแนกประเภทของระบบในงานวิจัยของ Liu et al	34
ภาพประกอบ 24 ผลการเปรียบเทียบสัดส่วนความแม่นยำในการนับยานพาหนะของโมเดลที่ เลือกใช้ในงานวิจัยของ A. Alsanabani et al.....	35
ภาพประกอบ 25 แสดงภาพตัวอย่างผลการจดจำประเภทของยานพาหนะและจำนวนของเพลลา (a), (b) และ (c) แสดง confusion matrixes ของการจำแนกประเภทของยานพาหนะจากชุดข้อมูล ที่ 1, ชุดข้อมูลที่ 2 และ ชุดข้อมูลที่ 3 ในงานวิจัยของ Zhang & Zhang.....	38
ภาพประกอบ 26 ภาพประกอบแสดง Flowchart วิธีการดำเนินงานการวิจัย.....	39
ภาพประกอบ 27 ตัวอย่างภาพของวิดีโอที่ใช้สำหรับทดสอบระบบที่ 1 ถึง 6 ตามลำดับ	41
ภาพประกอบ 28 ตัวอย่างภาพยานพาหนะในชุดข้อมูลที่สร้างขึ้น	43
ภาพประกอบ 29 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8x weight และชุดข้อมูลยานพาหนะที่ สร้างขึ้น	44
ภาพประกอบ 30 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝน ระบบ ด้วย YOLOv8x weight.....	45
ภาพประกอบ 31 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8m weight และชุดข้อมูลยานพาหนะที่ สร้างขึ้น.....	45
ภาพประกอบ 32 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝน ระบบ ด้วย YOLOv8m weight	46
ภาพประกอบ 33 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8n weight และชุดข้อมูลยานพาหนะที่ สร้างขึ้น.....	46
ภาพประกอบ 34 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝน ระบบ ด้วย YOLOv8n weight	47
ภาพประกอบ 35 การกำหนดเส้นอ้างอิงในการนับยานพาหนะบนภาพ	48
ภาพประกอบ 36 ผลการตรวจจับยานพาหนะโดยการใช้ Background Subtraction กับข้อมูลมี ความละเอียดสูง	49
ภาพประกอบ 37 ผลการตรวจจับยานพาหนะโดยการใช้ Background Subtraction กับข้อมูลมี ความละเอียดต่ำกว่า	49

ภาพประกอบ 38 ผลการตรวจจับยานพาหนะโดยใช้ YOLOv3	50
ภาพประกอบ 39 ผลการตรวจจับยานพาหนะจากการใช้ YOLOv4.....	50
ภาพประกอบ 40 ผลการตรวจจับยานพาหนะจากการใช้ YOLOv5.....	51
ภาพประกอบ 41 ผลการตรวจจับยานพาหนะจากการใช้ YOLOv7	51
ภาพประกอบ 42 ผลการตรวจจับยานพาหนะจากการใช้ YOLOv8.....	51
ภาพประกอบ 43 แสดงผลการนับจำนวนยานพาหนะโดยใช้ Background Subtraction เป็น อัลกอริทึมในการตรวจจับวัตถุ.....	52
ภาพประกอบ 44 แสดงผลการนับจำนวนยานพาหนะโดยใช้ Background Subtractionเป็น อัลกอริทึมในการตรวจจับวัตถุ.....	52
ภาพประกอบ 45 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ วัตถุ.....	54
ภาพประกอบ 46 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ วัตถุ.....	54
ภาพประกอบ 47 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ วัตถุ.....	54
ภาพประกอบ 48 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ วัตถุ.....	55
ภาพประกอบ 49 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ วัตถุ.....	55
ภาพประกอบ 50 ตัวอย่างผลลัพธ์ที่ได้จากการทำงานของระบบนับและจำแนกประเภท ยานพาหนะที่นำเสนอ.....	58
ภาพประกอบ 51 ความผิดพลาดในการตรวจจับรถพ่วงที่บรรทุกถรณ์ึ่งส่วนบุคคลไว้ด้านบน... 70	

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของงานวิจัย

ในพื้นที่เขตในเมืองของเมืองขนาดใหญ่หลายๆแห่งในปัจจุบันนั้น มีการขยายตัวขึ้นอย่างรวดเร็ว และมีการเพิ่มขึ้นของประชากรผู้อยู่อาศัยในเขตเมืองนั้นๆในอัตราที่สูงขึ้นมาก จึงส่งผลให้เกิดการเดินทางและปริมาณยานพาหนะที่ใช้สัญจรบนท้องถนนเพิ่มมากขึ้นตามไปด้วย ซึ่งก่อให้เกิดผลกระทบและปัญหาด้านการจราจรต่างๆในเขตพื้นที่เมืองนั้นๆตามมา ซึ่งสำหรับการพัฒนาเมืองทุกเมืองนั้น การคมนาคมขนส่งทางบก ถือเป็นหนึ่งในพื้นฐานสำคัญการพัฒนาเศรษฐกิจและสังคม หากมีระบบการจัดการที่ไม่ดี อาจส่งผลกระทบต่อระบบเศรษฐกิจและสังคม ตลอดจนผลกระทบต่อระบบสิ่งแวดล้อมและอื่นๆได้ ด้วยเหตุผลดังกล่าว จึงได้เริ่มมีการนำเทคโนโลยีต่างๆ เข้ามาประยุกต์ใช้เพื่อพัฒนาการจัดการด้านการจราจรมากขึ้น เกิดเป็นแนวคิดการสร้างระบบขนส่งอัจฉริยะ (ITS) ที่ถูกพูดถึงมากขึ้นเรื่อยๆ และถูกพัฒนาขึ้นมาอย่างต่อเนื่อง หนึ่งใน การนำเทคโนโลยีเข้ามาจัดการปัญหาด้านการจราจรที่มีการใช้กันอย่างแพร่หลาย คือการใช้ระบบเฝ้าระวังด้านการจราจรด้วยกล้องบันทึกภาพวิดีโอ ซึ่งข้อมูลวิดีโอของการจราจรนี้ สามารถนำมาถอดข้อมูลด้านการจราจรต่างๆ สำหรับนำไปใช้ประโยชน์ต่อไปได้ อย่างเช่นข้อมูลปริมาณการจราจรบนถนนแต่ละเส้น ประเภทของยานพาหนะ ความเร็วของยานพาหนะ บ้ายทะเบียนของยานพาหนะ และอื่นๆอีกมากมาย ซึ่งข้อมูลด้านการจราจรดังกล่าวข้างต้นนี้ เป็นประโยชน์ต่อการพัฒนาเมืองเป็นอย่างมาก ทั้งในด้านของการออกแบบพัฒนาโครงสร้างพื้นฐาน หรือการกำหนดนโยบายต่างๆด้านการจราจร รวมไปถึงการใช้สำหรับควบคุมพฤติกรรมกรรมการขับขี่ของผู้ใช้รถใช้ถนนให้ปฏิบัติตามกฎจราจรมากขึ้นได้เป็นอย่างดีอีกด้วย

ในปัจจุบัน การจัดการด้านการจราจรโดยใช้ระบบการเฝ้าระวังด้านการจราจรด้วยกล้องบันทึกภาพวิดีโอสำหรับหลายๆเมืองนั้น ยังคงใช้วิธีการแปลผลหรือถอดข้อมูลจากข้อมูลประเภทวิดีโอโดยการนับด้วยสายตาหรือใช้คนในการแปลผลและถอดข้อมูลอยู่ ซึ่งเป็นการวิธีการทำงานที่มีต้นทุนค่อนข้างสูง ทั้งในแง่ของระยะเวลาในการถอดข้อมูลที่ใช้เวลาในการทำค่อนข้างมาก และยังคงอาจจะก่อให้เกิดข้อผิดพลาดจากการทำงานของถอดข้อมูลโดยใช้คน (human error) ได้ง่าย เพื่อแก้ปัญหาเหล่านั้น จึงได้มีการนำเทคโนโลยีการมองเห็นทางคอมพิวเตอร์ (computer vision) มาประยุกต์ใช้ในการทำงานร่วมกับข้อมูลประเภทรูปภาพและวิดีโอกันมากขึ้น เกิดการพัฒนาและนำเสนอระบบต่างๆสำหรับงานด้านการจราจรที่มีความสามารถในการถอดข้อมูลจากภาพหรือวิดีโอได้อย่างมีประสิทธิภาพมากขึ้นเรื่อยๆ และเนื่องจากในยุคปัจจุบันนี้ หลายๆเมืองขนาดใหญ่

ล้วนมีการติดตั้งระบบเฝ้าระวังด้านการจราจรด้วยกล้องบันทึกภาพวีดีโอแบบปกติไว้อยู่แล้ว การมีระบบที่สามารถประยุกต์ใช้ถอดและเก็บข้อมูลด้านจราจรจากข้อมูลภาพเหล่านั้นได้อย่างแม่นยำและรวดเร็ว จะยิ่งส่งผลให้การเก็บข้อมูลด้านการจราจรมีประสิทธิภาพมากขึ้น ทำให้ระบบเหล่านี้เป็นระบบที่ถูกพัฒนามาอย่างต่อเนื่อง และเริ่มเข้ามามีบทบาทในการบริหารจัดการด้านการจราจรแทนที่วิธีการทำงานแบบเก่าๆมากขึ้น

จากการค้นคว้าเพื่อตรวจสอบข้อมูลด้านการจราจรพบว่า การเก็บข้อมูลด้านการจราจรที่หลายๆประเทศมักจะให้ความสำคัญ และยังคงมีการเก็บบันทึกเพื่อนำข้อมูลไปใช้ประโยชน์อยู่เสมอมา คือการเก็บข้อมูลปริมาณจราจรที่สัญจรบนถนนแบบแยกสายประเภทของยานพาหนะ โดยปกติแล้ว ตามหลักของงานด้านวิศวกรรมขนส่ง ข้อมูลปริมาณจราจรบนถนน ถือเป็นปัจจัยสำคัญอย่างหนึ่งที่ใช้ในการออกแบบและพัฒนาสิ่งอำนวยความสะดวกด้านการคมนาคมต่างๆ เช่น ใช้ในการคาดการณ์ปริมาณจราจรในอนาคต สำหรับกำหนดความจุถนนที่จะสร้างขึ้นเพื่อรองรับปริมาณจราจรที่อาจจะเกิดขึ้นจริง หรือใช้สำหรับศึกษาผลกระทบด้านการจราจรที่เกิดขึ้นจากการสร้างสิ่งปลูกสร้างต่างๆ หรือแม้กระทั่งการปรับปรุงรอบสัญญาณไฟจราจรให้มีความเหมาะสมกับสภาพการจราจรที่เกิดขึ้นจริงได้ เป็นต้น แต่เนื่องด้วยความหลากหลายของประเภทของยานพาหนะ การเก็บเพียงข้อมูลจำนวนของยานพาหนะ อาจไม่เพียงพอ เนื่องจากยานพาหนะแต่ละประเภท มีขนาดที่แตกต่างกันมาก ยานพาหนะที่มีขนาดใหญ่ย่อมใช้พื้นที่หรือความจุของถนนมากกว่ายานพาหนะที่มีขนาดเล็กกว่า ในการนำไปใช้งานจริง จำนวนของยานพาหนะแต่ละประเภท จะถูกแปลงให้อยู่ในหน่วยขนาดเดียวกันก่อน โดยมักจะมีการกำหนดหน่วยเทียบเท่ารถยนต์ส่วนบุคคล หรือ personal car unit (pcu) เพื่อเปรียบเทียบจำนวนของยานพาหนะทุกประเภทให้อยู่ในรูปของจำนวนของรถยนต์ส่วนบุคคล ซึ่งหน่วยเทียบเท่ารถยนต์ส่วนบุคคล (pcu) ของแต่ละพื้นที่หรือแต่ละประเทศ อาจมีความแตกต่างกันไปได้ ขึ้นอยู่กับกำหนดของหน่วยงานท้องถิ่นในพื้นที่นั้นๆ ดังนั้น การเก็บข้อมูลด้านปริมาณจราจรแบบแยกสายประเภทของยานพาหนะ จึงเป็นเรื่องที่สำคัญมากตามหลักการคำนวณด้านวิศวกรรมขนส่ง และจากการค้นคว้างานวิจัยที่เกี่ยวข้องที่เคยมีมา พบว่า มีการนำเสนอระบบที่ใช้นับยานพาหนะและจำแนกประเภทของยานพาหนะด้วยวิธีการที่แตกต่างกันมากมาย แต่ทุกๆระบบ ย่อมมีข้อผิดพลาดและข้อจำกัดของแต่ละระบบที่นำเสนอ จึงทำให้ระบบนับยานพาหนะและจำแนกประเภทของยานพาหนะนี้ ยังคงมีการพัฒนาต่อยอดได้อยู่เสมอมา และแม้ว่าในปัจจุบัน จะมีการนำเสนอการใช้หลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน หรือ Convolutional Neural Network (CNN) หลายรูปแบบในการตรวจจับ นับจำนวนและจำแนกประเภทของยานพาหนะจากรูปภาพที่สามารถ

ทำงานได้อย่างมีประสิทธิภาพอยู่แล้ว แต่ระบบต่างๆที่ถูกพัฒนาขึ้นมาขึ้น ส่วนใหญ่จะถูกสร้างจากการใช้ข้อมูลรูปภาพในการฝึกฝนระบบที่เก็บสำรวจมาจากพื้นที่ศึกษาตามภูมิลำเนาของผู้วิจัย แต่ละคนเป็นหลัก ซึ่งในแง่ของการนำไปใช้งานจริงสำหรับถอดข้อมูลในพื้นที่อื่นๆนั้น อาจมีประสิทธิภาพลดลงตามแต่ละพื้นที่นั้นๆที่ได้ อีกทั้งระบบที่มีอยู่ในปัจจุบันนั้น ส่วนใหญ่จะสามารถจำแนกประเภทของยานพาหนะได้ไม่ละเอียดมากนัก การนำไปใช้เพื่อจำแนกประเภทของยานพาหนะในบางประเทศที่มีการใช้ยานพาหนะหลากหลายประเภทมากๆ อย่างเช่น ประเทศฟิลิปปินส์ อินโดนีเซีย รวมทั้งประเทศไทยนั้น จำเป็นต้องมีการพัฒนาระบบระบบตรวจนับและแยกประเภทยานพาหนะที่มีประสิทธิภาพและเหมาะสมกับพื้นที่ของตัวเอง

ดังนั้นผู้วิจัยจึงได้พัฒนาบทความวิทยานี้ เพื่อนำเสนอกระบวนการของระบบตรวจนับยานพาหนะแบบอัตโนมัติสำหรับถนนในเขตเมือง โดยการใช้หลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่สามารถตรวจจับวัตถุที่เป็นยานพาหนะได้อย่างรวดเร็วและแม่นยำ และนำมาประยุกต์ใช้กับการนับปริมาณจราจร นอกจากนี้ บทความวิทยานี้ยังนำเสนอกระบวนการฝึกฝนระบบโครงข่ายประสาทเทียมแบบคอนโวลูชันด้วยชุดข้อมูลภาพของประเภทของยานพาหนะที่สร้างขึ้นจากข้อมูลที่เก็บสำรวจบนถนนในเขตเมืองของประเทศไทย ให้มีความสามารถในการตรวจจับและจำแนกประเภทของยานพาหนะที่มีความหลากหลายมากขึ้นและเหมาะสมกับการจราจรบนถนนในเขตเมืองของประเทศไทยได้

1.2 วัตถุประสงค์ของการทำงานวิจัย

1. เพื่อศึกษาปัญหาและหลักการที่ใช้ในการแก้ไขปัญหาของการตรวจนับปริมาณการจราจรและการจำแนกประเภทของยานพาหนะที่เคยมีมา
2. เพื่อนำเสนอระบบตรวจนับปริมาณจราจรที่สามารถนับจำนวนและจำแนกประเภทของยานพาหนะ ที่มีความสามารถใช้กับข้อมูลวิดีโอของการจราจรในประเทศไทยได้
3. เพื่อนำเสนอกระบวนการสร้างชุดข้อมูลยานพาหนะท้องถิ่นในพื้นที่เขตเมืองของประเทศไทยที่เก็บรวบรวมขึ้นมา สำหรับใช้ในการฝึกฝนระบบตรวจนับยานพาหนะและพัฒนาระบบตรวจนับปริมาณการจราจรและจำแนกประเภทของยานพาหนะบนถนนเขตเมืองของประเทศไทย

1.3 ขอบเขตของการทำงานวิจัย

1. ศึกษาหลักการที่ใช้ในการตรวจนับปริมาณการจราจรและการจำแนกประเภทของยานพาหนะบนถนนในเขตเมืองของประเทศไทย
2. เก็บข้อมูลรูปภาพและข้อมูลวิดีโอ เพื่อนำมาใช้ในการพัฒนาระบบการนับปริมาณและการจำแนกประเภทของยานพาหนะของประเทศไทย
3. ทดสอบโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความสามารถในการนับปริมาณและการจำแนกประเภทของยานพาหนะในเขตเมืองของประเทศไทย
4. ประเมินประสิทธิภาพการนับปริมาณและการจำแนกประเภทของยานพาหนะของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ปรับปรุงขึ้นกับข้อมูลวิดีโอที่เก็บรวบรวมจากการจราจรบนช่องทางภายในเขตเมืองของประเทศไทย

1.4 ขั้นตอนของการทำงานวิจัย

1. ศึกษากระบวนการตรวจจับวัตถุ เพื่อใช้ในการตรวจจับยานพาหนะในข้อมูลประเภทวิดีโอที่ได้จากการเก็บสำรวจ
2. ศึกษากระบวนการติดตามวัตถุ เพื่อใช้ในการติดตามยานพาหนะที่ถูกตรวจจับได้ในแต่ละภาพ
3. ศึกษากระบวนการนับปริมาณยานพาหนะจากข้อมูลการจราจรประเภทวิดีโอ โดยวิธีการสร้างเส้นอ้างอิง (Reference line) บนถนน สำหรับนับปริมาณยานพาหนะ เพื่อให้ระบบสามารถนับเฉพาะยานพาหนะที่ถูกตรวจจับและติดตามบนถนนหรือบริเวณที่สนใจในภาพได้
4. ศึกษากระบวนการจำแนกประเภทของยานพาหนะ โดยในงานวิจัยนี้ จะเน้นไปที่การจำแนกประเภทของยานพาหนะได้อย่างหลากหลายและแม่นยำ เพื่อประยุกต์ใช้ในการพัฒนาระบบให้สามารถจำแนกประเภทของยานพาหนะบนถนนในเขตเมืองของประเทศไทย
5. วิเคราะห์ข้อมูลต่างๆที่ได้ทำการรวบรวมมา เพื่อประยุกต์ใช้ในการออกแบบสร้างระบบตรวจนับยานพาหนะและจำแนกประเภทของยานพาหนะตามต้องการ
6. พัฒนาระบบตรวจนับยานพาหนะและจำแนกประเภทของยานพาหนะ โดยเขียนบนโปรแกรม Google Collaboratory ด้วยภาษา Python ใช้หลักการทำงานของโครงข่ายประสาทเทียมที่ทันสมัยในการฝึกฝนระบบรู้จำด้วยชุดข้อมูลที่สร้างขึ้นจากรูปภาพของยานพาหนะบนถนนในเขตเมืองของประเทศไทย เพื่อให้ระบบสามารถตรวจจับ ติดตามและนับจำนวนยานพาหนะได้อย่างแม่นยำมากขึ้น รวมทั้งสามารถจำแนกประเภทของยานพาหนะได้ละเอียดมากขึ้นตามที่มีการใช้งานจริงบนท้องถนนของประเทศไทย

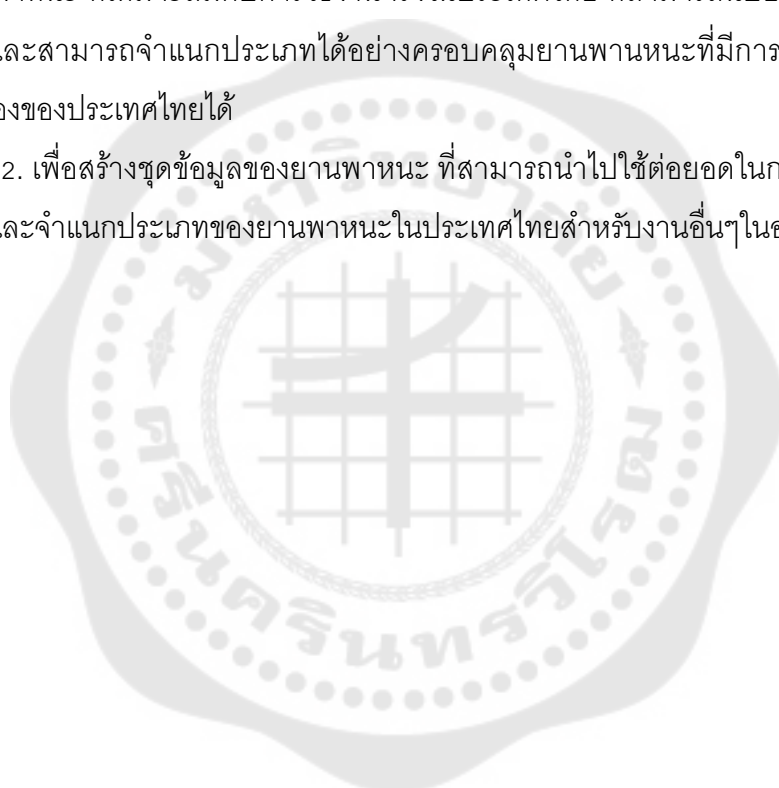
7. ประเมินผลการทำงานของระบบโดยการเปรียบเทียบกับข้อมูลเฉลี่ยที่ได้จากการถอดข้อมูลด้วยวิธีการใช้คนในการถอด

8. วิเคราะห์และอภิปรายผลการทดสอบระบบนับปริมาณยานพาหนะและจำแนกประเภทของยานพาหนะที่สร้างขึ้น

1.5 ประโยชน์ของการทำงานวิจัย

1. เพื่อนำเสนอระบบตรวจนับปริมาณจราจรที่สามารถนับจำนวนและจำแนกประเภทของยานพาหนะ ที่เหมาะสมกับการใช้งานจริงในประเทศไทย ที่สามารถนับยานพาหนะได้อย่างแม่นยำ และสามารถจำแนกประเภทได้อย่างครอบคลุมยานพาหนะที่มีการใช้งานจริงบนถนนเขตในเมืองของประเทศไทยได้

2. เพื่อสร้างชุดข้อมูลของยานพาหนะ ที่สามารถนำไปใช้ต่อยอดในการเรียนรู้ของระบบให้จดจำและจำแนกประเภทของยานพาหนะในประเทศไทยสำหรับงานอื่นๆในอนาคตได้



บทที่ 2

ทบทวนวรรณกรรม และงานวิจัยที่เกี่ยวข้อง

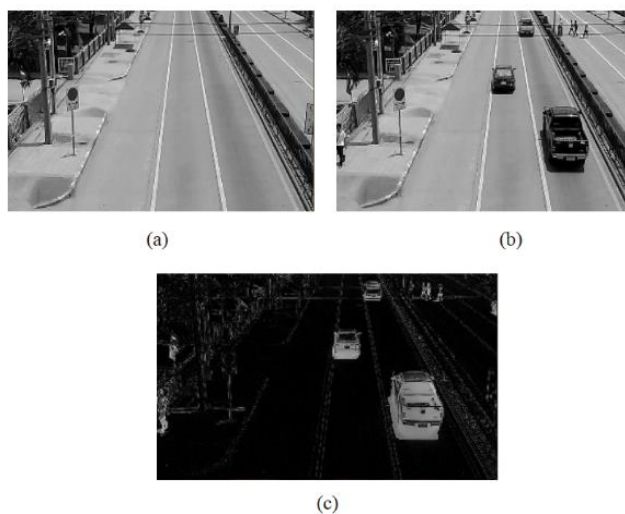
ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษางานวิจัยที่เกี่ยวข้องกับระบบตรวจจับยานพาหนะ ระบบติดตามยานพาหนะ ระบบนับยานพาหนะ และระบบจำแนกประเภทยานพาหนะ เพื่อนำความรู้ที่ได้มาประยุกต์ใช้กับการสร้างระบบตรวจจับและจำแนกประเภทยานพาหนะที่เหมาะสมกับการใช้งานกับการจราจรในประเทศไทย โดยมีรายละเอียดดังต่อไปนี้

2.1 ระบบตรวจจับยานพาหนะ (Vehicle Detection)

การตรวจจับวัตถุจากข้อมูลประเภทรูปภาพหรือ Object Detection เป็นเรื่องที่ได้รับ ความสนใจและมีการนำไปใช้ในการตรวจจับวัตถุหลากหลายประเภท หนึ่งในนั้นคือนำไปใช้เพื่อ ตรวจจับวัตถุที่เป็นยานพาหนะที่วิ่งอยู่บนท้องถนน ในอดีตที่ผ่านมา ระบบตรวจจับยานพาหนะ จากข้อมูลประเภทรูปหรือหรือวิดีโอที่เป็นที่นิยม จะใช้หลักการการแยกภาพพื้นหลังหรือ Background Subtraction ในการในการตรวจจับวัตถุที่สนใจ โดยแยกภาพที่เป็นวัตถุที่สนใจ (Foreground Object) ออกจากภาพที่เป็นวัตถุที่ไม่ได้สนใจ (Background Object) ซึ่งสามารถ นำไปใช้ต่อยอดในการนับปริมาณจราจรได้

2.1.1 งานวิจัยเรื่อง A Computer Vision Based Vehicle Detection and Counting System (Seenoung et al., 2016)

เสนอวิธีการตรวจจับยานพาหนะโดยการใช้ Background Subtraction เพื่อแยก ภาพพื้นหลังกับภาพยานพาหนะ โดยใช้ภาพพื้นหลังของถนนที่ไม่มียานพาหนะอยู่เลย และภาพที่มียานพาหนะ มาแปลงจากภาพสี (RGB) เป็น ภาพขาวดำ (Gray-scale) ภาพที่เป็นพื้นหลังจะถูก ลบออกจากภาพที่มียานพาหนะ ดังแสดงในภาพประกอบที่ 1



ภาพประกอบ 1 การทำ foreground extraction ด้วยหลักการ background subtraction ภาพพื้นหลัง, (b) ภาพปัจจุบัน และ (c) ภาพผลต่างของภาพพื้นหลังและภาพปัจจุบัน ในงานวิจัยของ Seenouvang et al

ที่มา : Seenouvang et al. (2016). A Computer Vision Based Vehicle Detection and Counting System

2.1.2 งานวิจัยเรื่อง A video-based real-time adaptive vehicle counting system for urban roads (Liu et al., 2017)

ได้นำเสนอการใช้ Ground update algorithm มาใช้ในการตรวจจับยานพาหนะบนท้องถนนแบบอัตโนมัติ ปรับปรุงขั้นตอน Extraction โดยใช้วิธีการ Block-wise background updating เพื่อแยกภาพที่เป็นพื้นหลังออกดังแสดงในภาพประกอบที่ 2 และใช้วิธีการ shadow suppression based on hue, saturation, and value (HSV) เพื่อลบเงาของพาหนะที่จะตรวจจับได้ออกให้เหลือเพียงภาพที่เป็นขนาดของยานพาหนะแต่ละคันจริงๆ และใช้เทคนิค extract the vehicle contour ในการเพิ่มประสิทธิภาพในการตรวจจับยานพาหนะจากภาพแต่ละเฟรม




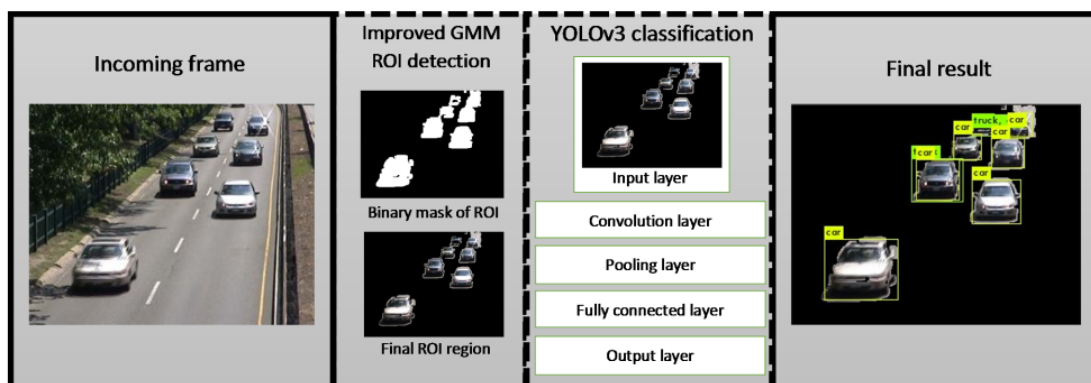
Fig 2. The background update result.

ภาพประกอบ 2 การทำ background subtraction ด้วยหลักการ Ground update algorithm ในงานวิจัยของ Liu et al

ที่มา : Liu et al. (2017). A video-based real-time adaptive vehicle counting system for urban roads

2.1.3 งานวิจัยเรื่อง Convolutional Network and Moving Object Analysis for Vehicle Detection in Highway Surveillance Videos (Mughtar et al., 2020)

นำเสนอการพัฒนาขั้นตอนการตรวจจับยานพาหนะที่เคลื่อนที่ โดยปรับปรุงกระบวนการทำงานของ Mixture of Gaussians (MOG) ที่ใช้การลดสัญญาณรบกวนด้วยวิธีการกรองข้อมูลด้วย bilateral filter ในข้อมูลภาพของวิดีโอที่ทำการทดลอง และสร้างภาพแยกระหว่าง Background Image กับพื้นที่ที่สนใจ หรือ ROI ของยานพาหนะ มากไปกว่านั้นยังใช้เทคนิคอย่าง Morphology และ Connected Components ในขั้นตอน Post-processing เพื่อเพิ่มความแม่นยำในการกำหนด ROI และกระบวนการแยกยานพาหนะออกจากพื้นหลัง สำหรับใช้ในการพัฒนา MOG2 เพื่องาน Background Subtraction ดังแสดงในภาพประกอบที่ 3 ที่สามารถแยกยานพาหนะออกจากภาพพื้นหลัง



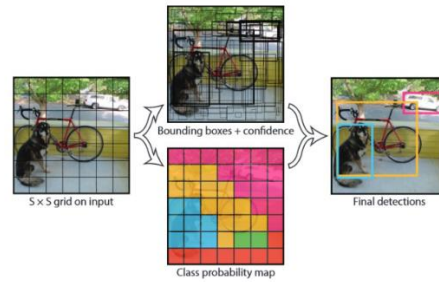
ภาพประกอบ 3 การทำ background subtraction ด้วยหลักการ Mixture of Gaussians 2 ใน
งานวิจัยของ Muchtar et al

ที่มา: Muchtar et al. (2020). Convolutional Network and Moving Object Analysis
for Vehicle Detection in Highway Surveillance Videos


ผลการทดลองจากบทความข้างต้นจะเห็นได้ว่า การใช้หลักการ background subtraction สามารถตรวจจับยานพาหนะได้ดีสำหรับสภาพการจราจรที่ไม่ติดขัดมากนัก สามารถแยกตำแหน่งของยานพาหนะกับภาพพื้นหลักได้อย่างชัดเจน แต่หากนำไปใช้กับสภาพการจราจรที่ติดขัดมากจะไม่สามารถตรวจจับแยกแยกยานพาหนะได้อย่างมีประสิทธิภาพ เนื่องจากยานพาหนะเคลื่อนที่ติดกันหรือเกิดการบดบังกันของยานพาหนะ ภาพที่ผ่านการทำ extraction ออกมานั้น จะทำได้ได้ภาพ foreground ที่ติดกัน กล่าวคือ ยานพาหนะ 2 คันที่มีการบดบังกัน ระบบจะมองยานพาหนะ 2 คันที่ติดกันนั้นเป็นยานพาหนะคันเดียวกัน ทำให้วิธีการดังกล่าวไม่สามารถแยกวัตถุที่เป็นยานพาหนะได้อย่างแม่นยำครอบคลุมทุกสถานการณ์ อีกทั้งวิธีการนี้ไม่สามารถนำไปต่อยอดเพื่อจำแนกประเภทของวัตถุได้อย่างมีประสิทธิภาพ ทำได้เพียงแค่ระบุตำแหน่งของวัตถุที่สนใจในภาพ

ในปัจจุบัน การใช้การเรียนรู้เชิงลึก หรือ Deep Learning เริ่มเข้ามามีบทบาทมากขึ้น ระบบประสาทเทียมแบบคอนโวลูชัน หรือ Convolution Neural Network สามารถทำงานกับข้อมูลรูปภาพได้ประสิทธิภาพที่ดีกว่า และเริ่มเข้ามาแทนที่วิธีการแบบเดิมๆ ระบบตรวจจับที่ใช้หลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชันตัวหนึ่งที่เป็นที่นิยมกันอย่างมากในช่วงเวลานี้คือ You Only Look Once หรือ YOLO (Redmon et al., 2016) ถูกพัฒนาขึ้นในปี ค.ศ.2016 โดย Joseph Redmon และคนอื่นๆ ให้มีรูปแบบการทำงานเป็น Single Neural Network ที่สามารถ

ทำนายกล่องขอบเขตของวัตถุ (Bounding Box) ภายในรูปภาพนำเข้าที่มีขนาดเป็นพื้นที่เล็กๆ ขนาด $S \times S$ พิกเซล และทำนายค่าความน่าจะเป็นของประเภทของวัตถุ (Class Probabilities) จาก ข้อมูลรูปภาพเต็มๆ นำเข้าได้โดยตรง โดยใช้การประมวลผลเพียงครั้งเดียว เป็นเหตุผลให้ YOLO ทำงานในการตรวจจับรวมทั้งจำแนกประเภทวัตถุได้อย่างรวดเร็วมาก โดยสามารถประมวลผล ข้อมูลประเภทรูปภาพได้ 45 ภาพต่อวินาที ซึ่งอยู่ในระดับการทำงานแบบ real-time ได้ ดังแสดง ในภาพประกอบที่ 4(a) สถาปัตยกรรมของ YOLO รุ่นแรกหรือ YOLOv1 ประกอบไปด้วย Convolutional layers จำนวน 24 ชั้น และ Fully connected layers จำนวน 2 ชั้น ดังแสดงใน ภาพประกอบที่ 4(b) โดยเมื่อเปรียบเทียบกับอัลกอริทึมที่ทันสมัยที่สุด (State-of-the-art) ในด้าน การตรวจจับวัตถุอื่นๆ อย่าง R-CNN หรือ DPM ที่มีความซับซ้อนมากกว่านั้น ในเรื่องของ ประสิทธิภาพของของอัลกอริทึมที่วัดโดยใช้ค่า Mean Average Precision (mAP) เป็นเกณฑ์ YOLO อาจมีประสิทธิภาพลดลงจากเดิมเพียงเล็กน้อย แต่มีข้อได้เปรียบในเรื่องของความเร็วการ ประมวลผลที่ดีกว่ามาก และเมื่อเปรียบเทียบกับอัลกอริทึมตรวจจับวัตถุแบบ real-time ตัวอื่นๆ YOLO สามารถตรวจจับได้ดีกว่ามาก โดยมีค่า mAP มากกว่าตัวอื่นๆถึงประมาณ 2 เท่าตัว ทำให้ YOLO ถูกนำไปใช้ในการตรวจจับวัตถุที่หลากหลายประเภทมากขึ้น รวมทั้งใช้ในการตรวจจับ วัตถุที่เป็นยานพาหนะ



(a)



(b)

ภาพประกอบ 4 รูปภาพ แสดงสถาปัตยกรรมของ YOLO (a) แสดงกระบวนการทำนายของ
 หลักการ YOLO และ (b) แสดงโครงสร้างของสถาปัตยกรรม YOLOv1 ที่ใช้ในการเรียนรู้ด้วย
 หลักการโครงสร้างประสาทเทียมแบบคอนโวลูชัน

ที่มา : Redmon et al. (2016). You Only Look Once: Unified, Real-Time Object
 Detection

2.1.4 งานวิจัยเรื่อง Classified Counting and Tracking of Local Vehicles in Manila Using
 Computer Vision (Cruz et al., 2019)

นำเสนอโมเดลที่ใช้ในการแยกประเภทและนับจำนวนของยานพาหนะที่ใช้ชุดข้อมูล
 ประเภทของยานพาหนะท้องถิ่นที่สร้างขึ้นมาเอง โดยการใช้การเรียนรู้ของเครื่อง โดยในขั้นตอน
 การตรวจจับยานพาหนะ ผู้วิจัยได้เลือกใช้หลักการของ YOLO เป็นอัลกอริทึมหลักในการฝึกฝน
 ด้วยชุดข้อมูลยานพาหนะท้องถิ่นที่สร้างขึ้นใหม่ ซึ่งผลการทดสอบแสดงให้เห็นว่า YOLO
 สามารถทำการตรวจจับยานพาหนะในภาพได้อย่างยอดเยี่ยม ส่งผลให้ระบบสามารถทำการนับ
 ยานพาหนะได้อย่างแม่นยำ ดังแสดงในภาพประกอบที่ 5



ภาพประกอบ 5 แสดงการตรวจนับประมาณยานพาหนะ โดยใช้หลักการ YOLO ในการตรวจจับยานพาหนะ ในงานวิจัยของ Cruz et al

ที่มา: Cruz et al. (2019). Classified Counting and Tracking of Local Vehicles in Manila Using Computer Vision

หลักการของอัลกอริทึม YOLO ถูกนำไปพัฒนาอย่างต่อเนื่องโดย Joseph Redmon และ Ali Farhadi และได้นำเสนอ YOLOv2 (Redmon & Farhadi, 2017) หรือมีอีกชื่อที่เป็นที่รู้จักกันคือ YOLO9000 เนื่องจาก Model ถูกฝึกฝนให้สามารถทำนายผลของวัตถุที่ต่างกันได้ถึง 9000 ประเภท และยังคงความสามารถในการทำงานแบบ real-time ได้ โดย YOLOv2 นี้ใช้ Darknet-19 เข้ามาเป็นโครงสร้างหลักของอัลกอริทึม และกลายเป็นโมเดลที่ทันสมัยที่สุด (State-of-the-art) ณ เวลานั้นในเรื่องของการตรวจจับวัตถุแทนโมเดลอื่นๆ และได้รับความสนใจอย่างแพร่หลาย ในปี ค.ศ.2018 Joseph Redmon และ Ali Farhadi ได้นำเสนอ YOLO รุ่นใหม่คือ YOLOv3 (Redmon & Farhadi, 2018) โดยการเปลี่ยนสถาปัตยกรรมหลักไปใช้ Darknet-53 แทนที่การใช้ Darknet-19 และใช้ Softmax Activation Function แทนการใช้ Logistic Classification แบบเดิม ทำให้ YOLOv3 สามารถทำนายประเภทของวัตถุที่ตรวจจับได้แม่นยำมากขึ้น โดยเฉพาะทำนายวัตถุที่มีขนาดเล็กได้ดีมากขึ้น หลังจากการประสบความสำเร็จของการพัฒนา YOLOv3 แล้ว ได้มีผู้สนใจคนอื่นๆ มากมายนำไปใช้และพัฒนาเป็นโมเดลรุ่นอื่นๆ ออกมาอีกมาก อย่างเช่น YOLOv4 (Bochkovskiy et al., 2020) ที่ถูกนำเสนอขึ้นในปี ค.ศ.2020 โดยผู้พัฒนาคนละกลุ่มกับรุ่นก่อนๆ คือ Alexey Bochkovskiy, Chien-Yao Wang, and Hong-Yuan Mark Liao เสนอการเปลี่ยนโครงสร้างหลักของ YOLOv3 ไปใช้ CSPDarknet53 ใช้ Spatial Pyramid Pooling (SPP)

และ Path Aggregation Network (PAN) แทนที่การใช้ Feature Pyramid Network (FPN) แต่ยังคงใช้ส่วนท้ายของระบบเป็น YOLOv3 ผลที่ได้จากการเปลี่ยนสถาปัตยกรรมดังกล่าว ทำให้ YOLOv4 มีค่า AP และ FPS สูงกว่า YOLOv3 ประมาณร้อยละ 10 และ 12 ตามลำดับ หลังจากนั้นไม่นาน Glenn Jocher ได้เปลี่ยนการทำงานของ YOLOv3 ไปใช้กับ Pytorch Deep Learning Framework แทนการใช้ Tensor Flow เป็นที่รู้จักกันในชื่อ YOLOv5 ซึ่งไม่ได้เป็นการนำเสนอองค์ความรู้ใหม่ใดๆ จึงทำให้ยังไม่มีกรณีพิพาทความของ YOLOv5 และพบว่าในบางงานวิจัย YOLOv5 มีประสิทธิภาพในการทำงานที่ดีกว่า YOLOv4 และ YOLOv3 แต่มีความเร็วในการทำงานใกล้เคียงกับ YOLOv4 อย่างไรก็ตาม เคยมีผู้ทำการศึกษางานวิจัยที่มีการแสดงผลการเปรียบเทียบผลการจำแนกประเภทของยานพาหนะโดยใช้หลักการ YOLO ไว้

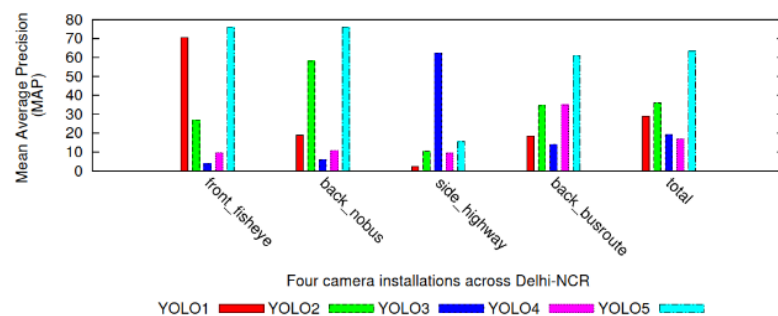
2.1.5 งานวิจัยเรื่อง Embedded CNN based vehicle classification and counting in non-laned road traffic (Chauhan et al., 2019)

ในงานวิจัยนี้ได้ทำการทดสอบกับข้อมูลจราจรบนถนนที่สร้างขึ้นมาจาก การเก็บสำรวจในเมืองเดลี (Delhi) ประเทศอินเดียที่แตกต่างกัน 4 จุดสำรวจ จากการทดลอง โดยแบ่งประเภทของยานพาหนะออกเป็น 7 ประเภท สำหรับ Object Detection และ Classification ใช้ CNN โมเดลอย่าง YOLO เป็น Pre-trained Model ร่วมกับ MS-COCO Dataset และ Fine-tune บน PASCAL VOC 2007 และ KITTI datasets ด้วย และทำการ fine-tune โดยทดลองกับทั้ง 5 โมเดล คือ YOLO1, YOLO2, YOLO3, YOLO4 และ YOLO5 และใช้ training data ที่ต่างกัน 5 Installation (ข้อมูลที่เก็บสำรวจ) ได้แก่ 4 ชุดข้อมูลจากแต่ละกล้องวิดีโอ และอีก 1 ชุดข้อมูลคือชุดข้อมูลที่รวมทั้ง 4 ชุดข้อมูลแรกเข้าด้วยกัน ดังนั้น จะทำการ Evaluate เพื่อหาโมเดลที่ดีที่สุดจาก 25 โมเดล โดยแบ่งข้อมูล 80 เปอร์เซ็นต์สำหรับ train และ นำไป Test กับ 20 เปอร์เซ็นต์ที่เหลือเพื่อทดสอบการจำแนกประเภทของยานพาหนะ ผลการตรวจจับและแยกประเภทของยานพาหนะแสดงดังภาพประกอบที่ 6 และจากการทดสอบพบว่า โดยเฉลี่ยการทำงานกับข้อมูลที่เก็บมาจากมุมกล้องที่แตกต่างกัน YOLOv5 ทำงานได้ค่อนข้างดีกว่าตัวอื่นๆ ดังแสดงในภาพประกอบที่ 7 ทำให้ YOLOv5 กลายเป็นระบบตรวจจับวัตถุที่เป็นที่นิยมมากที่สุดตัวหนึ่งในเวลาต่อมา



ภาพประกอบ 6 รูปภาพแสดงตัวอย่างผลการตรวจจับยานพาหนะที่ใช้หลักการ YOLO ในงานวิจัยของ Chauhan et al

ที่มา: Chauhan et al. (2019). Embedded CNN based vehicle classification and counting in non-laned road traffic



ภาพประกอบ 7 รูปภาพแสดงผลการเปรียบเทียบการระบบตรวจจับยานพาหนะที่ใช้หลักการ YOLOv1 ถึง YOLOv5 โดยใช้ Mean Average Precision (mAP) เป็นตัวชี้วัด ในงานวิจัยของ Chauhan et al

ที่มา: Chauhan et al. (2019). Embedded CNN based vehicle classification and counting in non-laned road traffic

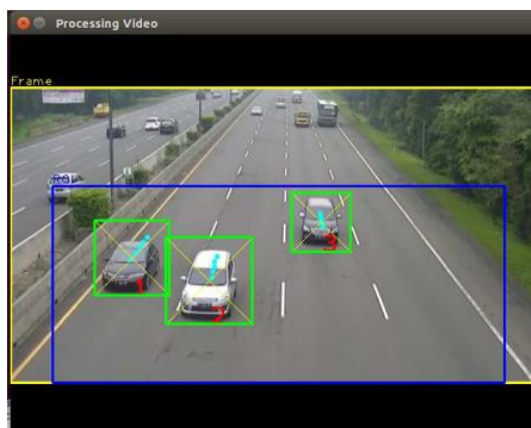
YOLO ยังคงได้รับการพัฒนาต่อเนื่องมาเรื่อยๆ และในปัจจุบันนี้ (ค.ศ.2023) Glenn Jocher และผู้พัฒนาอื่นๆ ที่ใช้ชื่อว่า Ultralytics ได้พัฒนาต่อยอดและนำเสนอ YOLOv8 ออกมาให้ใช้งาน ซึ่งสามารถทำงานในการตรวจจับและจำแนกประเภทของวัตถุได้ดีกว่า YOLOv5 มีความแม่นยำ และทำงานได้รวดเร็วกว่า อีกทั้งยังถูกพัฒนาให้สามารถใช้งานได้หลากหลายมากขึ้น อย่างเช่น ทำนายวัตถุแบบแบ่งส่วนรูปภาพหรือ Segmentation และการนำไปใช้ในการติดตามวัตถุได้

2.2 ระบบติดตามยานพาหนะ (Vehicle Tracking)

การติดตามวัตถุเป็นสิ่งที่สำคัญมากสำหรับการตรวจจับยานพาหนะที่เคลื่อนที่ในข้อมูลวิดีโอ การติดตามวัตถุจะช่วยให้การตรวจจับวัตถุมีความแม่นยำมากขึ้น ช่วยให้เราสามารถระบุได้ว่ายานพาหนะคันนั้นๆ ที่ถูกตรวจจับได้ในแต่ละภาพ เป็นคันตัวเดียวกันกับคันที่ถูกตรวจจับได้ในภาพก่อนหน้า ลดปัญหาการตรวจจับวัตถุซ้ำ ซึ่งจะส่งผลโดยตรงต่อการนับยานพาหนะและจำแนกประเภทของยานพาหนะต่อไป ระบบติดตามที่เหมาะสมสำหรับนำไปใช้งานกับข้อมูลรูปภาพ การจราจรที่วิ่งอยู่บนท้องถนนนั้น ควรเป็นระบบที่ถูกออกแบบมาเพื่อติดตามวัตถุหลายๆวัตถุที่เกิดขึ้นในข้อมูลรูปภาพพร้อมๆกันได้ หรือ multi-object tracking (MOT) เพื่อให้สามารถติดตามยานพาหนะทุกคันได้อย่างครบถ้วน

2.2.1 งานวิจัยเรื่อง Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow (Harjoko et al., 2017)

บทความนี้ใช้วิธีการ Haar Cascade Classifier สำหรับตรวจจับยานพาหนะ และใช้ Optical Flow ในการติดตามและนับปริมาณของยานพาหนะบนถนนหลวงของประเทศอินโดนีเซีย สำหรับการติดตามยานพาหนะ จะใช้ตำแหน่งจุดศูนย์กลางหรือ Centroid ของวัตถุที่ได้จากผลการทำ Haar Cascade Classifier และทำการเปรียบเทียบกับพื้นที่ของการตรวจจับยานพาหนะในภาพก่อนหน้ากับภาพปัจจุบันโดยการกำหนดค่า Threshold เพื่อตรวจสอบว่ายานพาหนะที่ถูกตรวจจับได้แต่ละคันเป็นยานพาหนะคันเดียวกันกับภาพก่อนหน้า เพื่อป้องกันไม่ให้นับยานพาหนะที่เคยนับแล้วซ้ำอีก ดังแสดงในภาพประกอบที่ 8 และจากการนำระบบไปใช้ทดสอบเพื่อตรวจจับ ติดตาม และนับยานพาหนะ พบว่าระบบที่นำเสนอมีประสิทธิภาพการทำงานที่แม่นยำ



ภาพประกอบ 8 แสดงตัวอย่างผลการตรวจจับยานพาหนะของงานวิจัยในงานวิจัยของ Harjoko et al

ที่ มา : Harjoko et al. (2017). Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow

2.2.2 งานวิจัยเรื่อง Vehicle and pedestrian video-tracking with classification based on deep convolutional neural networks (Forero & Calderon, 2019)

งานวิจัยนี้เสนออัลกอริทึมสำหรับ แยกประเภท, ติดตามและนับจำนวนยานพาหนะและคนเดินเท้าจากภาพวิดีโอ โดยใช้ Deep Convolutional Neural Network ที่เริ่มเป็นที่นิยมในช่วงปีหลังๆจนถึงปัจจุบันในการตรวจจับยานพาหนะจากข้อมูลวิดีโอ โดยในงานวิจัยนี้เลือกใช้ YOLOv2 เป็นอัลกอริทึมหลักในการฝึกฝนชุดข้อมูลที่ผ่านการทำ labeling ให้มีจำนวนประเภทของยานพาหนะทั้งหมด 9 ประเภทแล้ว และได้นำเสนอ Tracking Algorithm ในการติดตามยานพาหนะที่สร้างขึ้นมา ดังแสดงในภาพประกอบที่ 9 ซึ่งสามารถอธิบายเป็นขั้นตอน 5 ขั้นตอน ดังนี้

1.) Object Segmentation: ใช้ YOLO ในการแบ่งโดยสร้างเป็น ROI ของแต่ละยานพาหนะในทุกๆเฟรมเวลาที่แบ่ง (20FPM)

2.) Clustering: ในการ Detect Object อัลกอริทึมบางตัวสามารถจะสร้าง ROI หลายๆตัว สำหรับวัตถุขึ้นเดียวกันได้ อย่าง YOLO ก็เช่นกัน แต่ ROI ที่ได้จาก YOLO จะเป็นสี่เหลี่ยมที่มีส่วนที่ทับซ้อนสูง

3.) Feature Extraction: ใช้ตำแหน่งพิกัด pixel ของจุด Centroid, ขนาดของกรอบสี่เหลี่ยมและ label ในการทำงานของ YOLO

4.) Matching Cost Computation: สามารถคำนวณหา Matching cost ของภาพก่อนหน้าและภาพปัจจุบันได้

5.) Optimization: เมื่อคำนวณ Matching Cost ของทั้งคู่แล้ว จะนำไปทำ Winner Take All Optimization โดยขั้นตอนแบ่งเป็น 3 loops หลักๆ ดังแสดงในภาพประกอบที่ 10

loop ที่ 1 คือ loop ที่สร้างขึ้นเพื่อ optimize การจับคู่ของคู่วัตถุจากทั้งสองภาพ

loop ที่ 2 คือ loop ที่สร้างขึ้นเพื่อหา Object ใหม่ และทำการ Track loop ที่ 3 คือ 1loop จะใช้ time-to-live Filter เพื่อช่วยกรองหา วัตถุที่ไม่ได้ทำการตรวจจับ หรือตรวจจับไม่เจอในภาพที่กำหนด ช่วยในการทำงานในกรณีที่ยานพาหนะถูก environments อื่นๆบดบัง โดยรายละเอียดการทำงานของอัลกอริทึมนี้นำเสนอ



ภาพประกอบ 9 แสดงภาพตัวอย่างระบบติดตามวัตถุ ภาพต้นฉบับ, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของ YOLO, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของ foreground-background subtraction, ตัวอย่างผลลัพธ์การใช้ระบบติดตามของอัลกอริทึมที่นำเสนอในงานวิจัยของ Forero & Calderon

ที่มา : Forero & Calderon. (2019). Vehicle and pedestrian video-tracking with classification based on deep convolutional neural networks

Algorithm 1 WTA optimization for pairing objects in the previous and current frames

```

maxcost=100//or other pixel distance
ttl=5//or other number of frames in the time-to-live
while The remaining unassigned costs in  $O(o_i, o_j) <$ 
maxcost do
  1.  $c_{min}$  = minimum cost in  $O(o_i, o_j)$ 
  2. Find for the index  $i_{min}$  and  $j_{min}$  of  $c_{min}$  in  $O(o_i, o_j)$ 
  3. Store the match between the object  $i_{min}$  in the previous
  frame with the object  $j_{min}$  in the current frame
  4. Set all matching cost for the objects  $i_{min}$  and  $j_{min}$  in
   $O(o_i, o_j)$  as assigned costs
end while
while There are unassigned costs in  $O(o_i, o_j)$  do
  1. Find an unassigned index  $j_{new}$  in  $O(o_i, o_j)$ 
  2. Store this  $j_{new}$  as a new object to track, and assign
  the cost matrix index
end while
while There are stored objects in the previous frame un-
matched do
  1. Find an unassigned index  $i_{new}$  unmatched
  2. increase the ttl of this object
  if ttl of object  $i_{new} >$  ttl then
    delete the object  $i_{new}$ 
  end if
end while

```

ภาพประกอบ 10 อัลกอริทึมการติดตามยานพาหนะและคนเดินเท้าที่นำเสนองานวิจัยของ

Forero & Calderon

ที่มา : Forero & Calderon. (2019). Vehicle and pedestrian video-tracking with classification based on deep convolutional neural networks

ยานพาหนะที่ถูกติดตามด้วยระบบที่นำเสนอนี้ จะถูกนำไปทำการจำแนกประเภทของยานพาหนะและนับจำนวนยานพาหนะจากวัตถุที่เคลื่อนที่ผ่านเส้นที่กำหนดขึ้น ดังแสดงตัวอย่างผลการตรวจจับและนับยานพาหนะในภาพประกอบที่ 11 งานวิจัยนี้วัดผลการทดสอบโดยเปรียบเทียบกับการนับข้อมูลจริงจากลำดับวิดีโอของกรณีที่ถูกคัดมาจากหน่วยงานของเมืองโบคาตา ประเทศโคลอมเบีย ผลการทดสอบระบบดังกล่าวพบว่า สามารถนับประเภทได้ค่อนข้างดีและสามารถใช้ในการจำแนกประเภทที่หลากหลายมากขึ้นได้



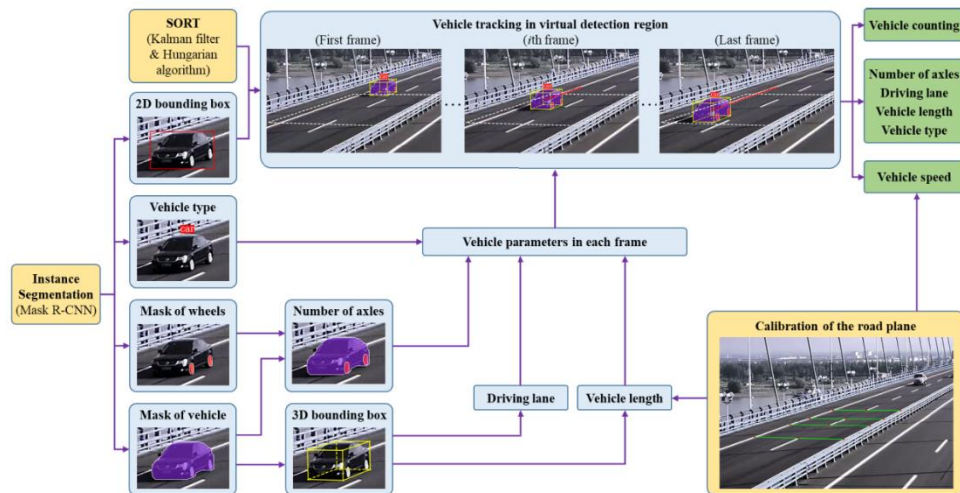
ภาพประกอบ 11 แสดงตัวอย่างผลการตรวจจับและติดตามยานพาหนะของงานวิจัยที่ถูกนำเสนอ
ในงานวิจัยของ Forero & Calderon

ที่ มา : Forero & Calderon. (2019). Vehicle and pedestrian video-tracking with classification based on deep convolutional neural networks

อัลกอริทึม Simple Online and Realtime Tracking หรือ SORT (Bewley et al., 2016) เป็นอัลกอริทึมที่สามารถตรวจจับวัตถุหลายๆวัตถุได้ และถูกออกแบบมาให้สามารถทำงานได้อย่างรวดเร็วสำหรับการทำงานแบบ real-time ได้ เป็นหลักการที่ถูกใช้อย่างแพร่หลายในการติดตามวัตถุหลายๆวัตถุพร้อมกันได้และทำงานได้อย่างรวดเร็วมาก สามารถนำไปประยุกต์ใช้เพื่อพัฒนาเป็นระบบติดตามแบบ real-time ได้ SORT ใช้เทคนิคทั่วไปอย่าง Kalman Filter (Kalman, 1960) และ Hungarian Algorithm (Kuhn, 1955) ในการติดตามวัตถุ ซึ่งสามารถติดตามวัตถุได้อย่างแม่นยำและรวดเร็วมาก เปรียบเทียบกับอัลกอริทึมติดตามวัตถุแบบ real-time ที่ทันสมัยที่สุด (State-of-the-art) ตัวอื่นๆที่เคยมีมาอย่างเช่น Markov Decision Process หรือ MDP และ Temporal Dynamic Appearance Modeling หรือ TDAM แล้ว SORT มีความแม่นยำในการตรวจจับที่ดีกว่า แต่ยังคงมีข้อเสียเรื่องการตรวจจับวัตถุที่ได้ไม่ตรงกับภาพก่อนหน้า หรือมี Identity Switches (DI sw) ที่สูงกว่า และทำงานได้ไม่ดีในสถานการณ์ที่วัตถุถูกบดบังมากนัก

2.2.3 งานวิจัยเรื่อง A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation (Zhang & Zhang, 2021)

นำเสนอระบบเฝ้าระวังด้านการจราจรที่เก็บข้อมูลของยานพาหนะได้อย่างครอบคลุม ประกอบไปด้วย ประเภทยานพาหนะ, จำนวนเพลลาของยานพาหนะ, กรอบภาพวัตถุแบบ 3 มิติ, ความเร็วของยานพาหนะ, ช่องจราจรของยานพาหนะ และปริมาณจราจรโดยใช้วิธีการทำ Segmentation จาก Mask R-CNN วิธีการทำงานหลักๆที่เสนอประกอบไปด้วย 1) การสร้างชุดข้อมูลที่เก็บภาพของรถยนต์ส่วนบุคคล, รถโดยสารขนาดใหญ่, รถบรรทุก และล้อของยานพาหนะ เพื่อใช้ในการ train Mask R-CNN; 2) วิธีการในการระบุจำนวนเพลลาของยานพาหนะที่ใช้ MaskIoU เป็นตัวระบุ; 3) กรอบภาพวัตถุแบบ 3 มิติที่สร้างขึ้นเพิ่มความแม่นยำของผลการทดลอง; 4) สำหรับการคำนวณความเร็วและความยาวของยานพาหนะที่ใช้เส้นอ้างอิงที่สร้างขึ้นบนถนน, เส้นแบ่งช่องจราจร และจุดสมมุติที่สร้างขึ้น ในการค้นหา Homography matrix; 5) เพื่อให้ข้อมูลของยานพาหนะที่ได้มีความน่าเชื่อถือ จะใช้วิธีการติดตามวัตถุอย่าง SORT ในการติดตามวัตถุหลายๆเฟรม ดังแสดงในภาพประกอบที่ 12 ชุดข้อมูลที่ใช้ในการฝึกฝน Mask R-CNN จะประกอบไปด้วยภาพของรถยนต์ส่วนบุคคล, รถโดยสารขนาดใหญ่, รถบรรทุก และล้อของยานพาหนะ ทั้งหมด 342 ภาพ แบ่งเป็น Training set จำนวน 243 ภาพ และเป็น Testing set จำนวน 99 ภาพ และเลือกใช้ pre-train model อย่าง ResNet-50 ฝึกฝนร่วมกับ ImageNet และชุดข้อมูลที่สร้างขึ้นมา โดยผลลัพธ์ที่ได้จากการทำ Mask R-CNN จะได้ผลลัพธ์เป็น ประเภทของยานพาหนะ, จำนวนเพลลาของยานพาหนะ, ช่องจราจรของยานพาหนะ และความยาวของยานพาหนะ และ กล่องขอบเขตของยานพาหนะแบบ 2 มิติ และถูกเก็บเป็นพารามิเตอร์ในขั้นตอนการติดตามวัตถุแต่ละภาพต่อไป และผลลัพธ์สุดท้ายของประเภทของยานพาหนะ จำนวนเพลลาของยานพาหนะ และช่องจราจรของยานพาหนะ จะได้จากการ voting ของทุกๆเฟรมที่ตรวจจับได้จากการทดสอบที่ได้จากระบบที่นำเสนอ ผลการจำแนกประเภทและจำนวนเพลลาของยานพาหนะ



ภาพประกอบ 12 กระบวนการทำงานของระบบในงานวิจัยของ Zhang & Zhang

ที่ ม า : Zhang & Zhang, (2021). A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation

DeepSORT (Wojke et al., 2017) พัฒนาจาก SORT เพื่อแก้ปัญหาเรื่อง Identity Switches ให้มีประสิทธิภาพที่ดีกว่าเดิม โดยใช้การเรียนรู้เชิงลึก (Deep Learning) ให้เรียนรู้จาก Deep Association Metric ที่ประกอบไปด้วยการเคลื่อนที่และรูปร่างของวัตถุ และฝึกฝนกับชุดข้อมูล person re-identification ขนาดใหญ่ จากผลการทดสอบเปรียบเทียบกับ SORT พบว่ามีประสิทธิภาพสูงกว่ามาก โดยมี Identity Switches (DI sw) ที่ต่ำลงจากเดิมถึงประมาณร้อยละ 45 DeepSORT จึงเป็นอัลกอริทึมติดตามวัตถุหลายๆวัตถุพร้อมกันที่ทำงานได้แม่นยำมากกว่า และกลายเป็นนิยมมากขึ้นในการนำไปใช้เพื่อติดตามยานพาหนะจากข้อมูลวิดีโอ

2.2.4 งานวิจัยเรื่อง Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis (A. Alsanabani et al., 2020)

ในปี ค.ศ. 2020 Ala A. Alsanabani, Mohammed A. Ahmed และ Ahmad M. Al Smadi ได้เสนองานวิจัยที่ทำการเปรียบเทียบการเลือกใช้ระบบตรวจจับและระบบติดตามยานพาหนะที่เป็น State-of-the-Art มากมาย มาทำงานร่วมกันแล้วส่งผลให้ระบบนับยานพาหนะมีประสิทธิภาพที่ดีที่สุด ในส่วนของ Object Detector ที่เลือกมาทดสอบ ได้แก่ CenterNet, Detectron2, YOLOv4 และ EfficientDet และในส่วนของ Object Tracker ที่เลือกมาทดสอบ ได้แก่ SORT, Deep SORT, IOU (the Intersection-Over-Union) และ KIOU

(Kalman Filter+IOU) และประยุกต์ใช้ในการนับปริมาณจราจรแบบอัตโนมัติจากข้อมูลวิดีโอของ กระแสจราจร เพื่อศึกษาความแม่นยำของโมเดลเปรียบเทียบกับข้อมูลจริง โดยมีตัวชี้วัดที่เลือกใช้ แสดงผลเปรียบเทียบคือ True Positive (TP) และจากงานวิจัยได้ข้อสรุปว่า ในแง่ของการนับ จำนวนยานพาหนะ การทำงานร่วมกันของโมเดลที่ให้มีความแม่นยำสูงที่สุดได้แก่ การใช้ Detectron2 ร่วมกับ Deep SORT, CenterNet ร่วมกับ Deep SORT, และ YOLOv4 ร่วมกับ DeepSORT และในแง่ของการจำแนกประเภทระหว่าง รถยนต์นั่งส่วนบุคคลกับรถบรรทุก การ ทำงานร่วมกันของโมเดลที่ให้มีความแม่นยำสูงที่สุดได้แก่การใช้ Detectron2 ร่วมกับ SORT, CenterNet ร่วมกับ IOU, YOLOv4 ร่วมกับ Deep SORT, และ CenterNet ร่วมกับ SORT และยัง ได้ข้อสรุปที่สำคัญอีกอย่างว่า โดยภาพรวมแล้ว การเลือกใช้ DeepSort เป็นระบบติดตาม ยานพาหนะ ส่งผลให้การทำงานของระบบนับยานพาหนะมีประสิทธิภาพสูงที่สุด

จากงานวิจัยข้างต้นเกี่ยวกับระบบตรวจจับยานพาหนะและระบบติดตามยานพาหนะ แสดงให้เห็นว่า การเลือกใช้ระบบติดตามที่ทำงานได้ดีในการติดตามวัตถุหลายวัตถุ (Multiple Object Tracking) สามารถนำไปประยุกต์ใช้ในการติดตามยานพาหนะได้เป็นอย่างดี และหลายๆ กรณีที่นำไปใช้งานร่วมกับระบบตรวจจับยานพาหนะที่ใช้โครงสร้างพื้นฐานของ YOLO สามารถ ช่วยให้ระบบนับยานพาหนะและจำแนกประเภทของยานพาหนะมีผลลัพธ์ที่มีประสิทธิภาพมากขึ้น โดยจะช่วยลดการตรวจจับยานพาหนะในภาพซ้ำซ้อนลงได้

ByteTrack (Zhang et al., 2022) เป็นระบบติดตามวัตถุที่ถูกพัฒนาขึ้นในปี 2021 มีความแตกต่างจากระบบติดตามตัวอื่น ๆ ที่ส่วนใหญ่จะเน้นพัฒนาระบบให้สามารถติดตามวัตถุที่มี คະแนนกล่องขอบเขตที่ถูกตรวจจับได้สูงๆ แต่ ByteTrack จะทำงานโดยติดตามทุกวัตถุที่ถูก ตรวจจับได้ และแยกเป็นวัตถุที่มีคะแนนการตรวจจับสูงกับวัตถุที่มีคะแนนการตรวจจับต่ำ ระบบ ติดตามนี้ถูกพัฒนาให้ทำงานกับวัตถุที่มีคะแนนการตรวจจับได้สูงๆ แต่ถูกบดบังหรือมีเปลี่ยน ขนาดของวัตถุที่ทำให้ไม่สามารถติดตามวัตถุนั้นๆ ได้ โดยการพิจารณาวัตถุที่มีคะแนนการตรวจจับ สูงที่ถูกยกเลิกการติดตาม ร่วมกับวัตถุที่มีคะแนนการตรวจจับต่ำ เพื่อทำการกู้คืนการติดตามวัตถุ นั้นๆ ทำให้ ByteTrack เป็นระบบติดตามที่ทำงานในการติดตามวัตถุหลายวัตถุพร้อมๆ กันได้เป็น อย่างดี ลดปัญหาการติดตามวัตถุที่เกิดการบดบังในบางภาพได้

และในปี 2022 BotSORT (Aharon et al., 2022) ได้ถูกพัฒนาขึ้นโดย Nir Aharon, Roy Orfaig และ Ben-Zion Bobrovsky เป็นการพัฒนาระบบติดตามต่อยอดจากระบบติดตาม SORT โดยปรับปรุงสมการของ Kalman Filter และ metrics บางตัวของ SORT เป็นระบบที่มี ประสิทธิภาพในการติดตามยานพาหนะหลายวัตถุ (MOT) ได้มีประสิทธิภาพมากที่สุดในเวลานั้น

จากการศึกษาประสิทธิภาพการทำงานของระบบติดตามยานพาหนะทั้งสองระบบดังกล่าว พบว่ามีผลการจัดอันดับของระบบติดตามยานพาหนะที่ใช้ตัวชี้วัดเป็น MOTA หรือ Multiple Object Tracking Accuracy กับชุดข้อมูล MOT17 ในปีปัจจุบัน (มีนาคม พ.ศ. 2566) อยู่ในอันดับ 2 และ 3 ตามลำดับ โดยมีประสิทธิภาพความแม่นยำในการติดตามที่สูงเกิน 80 เปอร์เซนต์ทั้งคู่ ดังแสดงในภาพประกอบที่ 13 มากไปกว่านั้น จากการที่ระบบตรวจจับวัตถุ YOLOv8 ได้ถูกพัฒนาต่อยอดให้สามารถทำงานในการติดตามยานพาหนะของวัตถุประเภทวิดีโอ ได้มีการเลือกใช้และรวมรวบระบบติดตามวัตถุ 2 ระบบหลักคือ ByteTrack และ BotSORT ไว้ใน Github repository ทางของ กลุ่มผู้พัฒนา YOLOv8 ทำให้สามารถใช้งานการติดตามวัตถุได้อย่างสะดวกสบายมากยิ่งขึ้น จึงทำให้ระบบติดตามทั้งสองระบบนี้ มีความน่าใจมากยิ่งขึ้น ที่จะถูกนำมาพัฒนางานด้านการติดตามยานพาหนะบนท้องถนนในยุคสมัยนี้ ผู้วิจัยจึงเห็นว่า การใช้งานระบบตรวจจับยานพาหนะโดยใช้โครงสร้างพื้นฐานของ YOLOv8 ในการทำงานร่วมกับระบบติดตามยานพาหนะที่ใช้โครงสร้างของ ByteTrack หรือ BotSORT จะเป็นระบบที่เหมาะสมและมีประสิทธิภาพดีสำหรับการพัฒนาเป็นระบบนับยานพาหนะและจำแนกประเภทของยานพาหนะต่อไป

Rank	Model	HOTA	MOTA↑	IDF1	Extra Training Data	Paper	Code	Result	Year	Tags
1	SMILETrack	65.24	81.06	80.5	✓	SMILETrack: SIMilarity LEarning for Multiple Object Tracking	Code	Result	2022	
2	BoT-SORT	65.0	80.5	80.2	✓	BoT-SORT: Robust Associations Multi-Pedestrian Tracking	Code	Result	2022	
3	ByteTrack		80.3	77.3	✓	ByteTrack: Multi-Object Tracking by Associating Every Detection Box	Code	Result	2021	
4	StrongSORT	64.4	79.6	79.5	✓	StrongSORT: Make DeepSORT Great Again	Code	Result	2022	

ภาพประกอบ 13 การจัดอันดับโมเดลการติดตามวัตถุโดยใช้ตัวชี้วัดเป็น MOTA ที่มา: Papers with Code. (2023). <https://paperswithcode.com/sota/multi-object-tracking-on-mot17>

2.3 ระบบนับยานพาหนะ (Vehicle Counting)


ระบบนับปริมาณยานพาหนะในปัจจุบัน มีการใช้งานอย่างหลากหลายรูปแบบ แต่ระบบตรวจจับเหล่านั้นล้วนมีข้อเสียของแต่ละระบบอยู่ อย่างเช่นการฝังลูบตรวจจับสนามแม่เหล็กใต้พื้นผิวจราจร (Inductive loop) ระบบท่อลมนิวเมติก (Pneumatic loop) ที่มีข้อจำกัดที่สามารถเก็บข้อมูลจุดสำรวจได้เฉพาะตำแหน่งที่ติดตั้ง ทั้งยังมีค่าใช้จ่ายในการติดตั้งรวมทั้งค่าบำรุงรักษาที่

สูง, หรือแม้กระทั่งเซนเซอร์ตรวจจับแบบอินฟราเรด (Infrared Sensor) ที่สามารถทำงานได้อย่างแม่นยำ แต่มีต้นทุนในการติดตั้งสูง ในปัจจุบัน เทคโนโลยีคอมพิวเตอร์เข้ามามีบทบาทในการทำงานทุกสายงานมากขึ้น การนับยานพาหนะโดยใช้เทคโนโลยีคอมพิวเตอร์จึงถูกพัฒนาและนำมาใช้อย่างแพร่หลาย โดยเฉพาะกับการนับยานจำนวนพาหนะจากข้อมูลประเภทวิดีโอหรือจากกล้องวงจรปิดต่างๆ

การทำงานของระบบนับยานพาหนะ ต้องอาศัยระบบตรวจจับและติดตามยานพาหนะที่ดีในระบุนับว่า ยานพาหนะที่เกิดขึ้นอยู่ที่ตำแหน่งใดของข้อมูลภาพ และเคลื่อนที่ไปในทิศทางใดในแต่ละภาพต่อเนื่อง โดยการกำหนดกรอบขอบเขตของยานพาหนะ (Bounding Box) และตำแหน่งศูนย์กลางของยานพาหนะในภาพได้ จึงจะสามารถนำไปประยุกต์ใช้ในการนับจำนวนของยานพาหนะต่อไปได้ ในอดีต ได้มีบางงานวิจัยเสนอการวัดผลการนับยานพาหนะ โดยนับจากจำนวนของยานพาหนะที่ถูกตรวจจับได้จากระบบตรวจจับยานพาหนะ

2.3.1 งานวิจัยเรื่อง Vehicle Detection and Counting using Haar Feature-Based Classifier (Choudhury et al., 2017)

นำเสนอโมเดลของตัวเองที่ใช้ Haar Feature-Based Cascade Classifier โดยในการใช้ Haar Feature Technique ในการ classify ระหว่าง positive object กับ Negative object เริ่มจากขั้นตอนแรก Asset Preparation ทำการtrain ตัว Image Classifier เพื่อใช้ตรวจจับวัตถุจากภาพที่กำหนดเป็น Positive และ Negative โดยภาพที่เป็น Positive Object คือภาพของยานพาหนะจาก Online Car Image Datasets และภาพที่เป็น Negative Object ที่ภาพที่ไม่มียานพาหนะอยู่ โดยการตัดภาพมาจากวิดีโอ (เพิ่มภาพโดยการทำ Augmentation ด้วยวิธีการหมุนภาพ) ขั้นตอนที่สองคือการสร้าง Metadata ที่เก็บ Number of objects, position และ dimensions of objects จากในแต่ละภาพ แล้วเรียกใช้เพื่อ train ตัว Classifier ขั้นตอนที่สาม เมื่อ train เรียบร้อยแล้ว จึงนำไป test กับภาพที่จับภาพมาจากวิดีโอที่เตรียมไว้เพื่อตรวจจับยานพาหนะ และใช้ detectMultiscale Function ช่วยในการสร้าง loop และตรวจจับยานพาหนะและนับยานพาหนะถูกตรวจจับได้ดังแสดงในภาพประกอบที่ 14 และผลการทดสอบพบว่า ระบบการนับดังกล่าวของงานวิจัยให้ผลการนับที่ดี แต่ผลที่ได้จะขึ้นอยู่กับคุณภาพของภาพที่ใช้

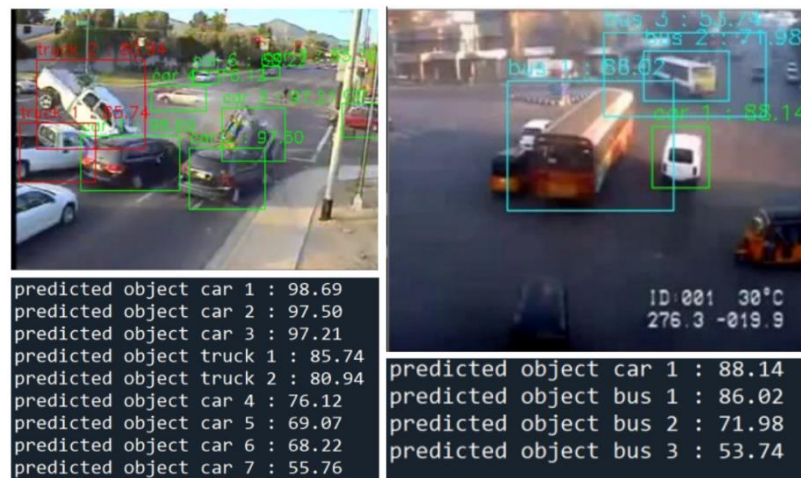


ภาพประกอบ 14 แสดงตัวอย่างการตรวจจับและนับจำนวนของยานพาหนะในงานวิจัยของ Choudhury et al

ที่มา : Choudhury et al. (2017). Vehicle Detection and Counting using Haar Feature-Based Classifier

2.3.2 งานวิจัยเรื่อง Vehicle Identification from Traffic Video Surveillance Using YOLOv4 (Sindhu, 2021)

ได้นำเสนอโมเดลที่ประยุกต์ใช้ YOLOv4 เป็นตัวตรวจจับยานพาหนะของระบบ เพื่อเพิ่มประสิทธิภาพของโมเดลให้สามารถตรวจจับได้แบบ real-time ได้ และใช้ทดสอบกับสภาพการณ์ที่แตกต่างกันอย่างเช่น สภาพการจราจรในขณะที่มีฝนตก, มีวิสัยทัศน์ในการมองเห็นที่แย่, ช่วงเวลากลางวัน-กลางคืน, มีหิมะตก เป็นต้น โมเดลนี้จะนำไปใช้ในการพัฒนา framework สำหรับตรวจจับอุบัติเหตุของยานพาหนะแบบ real-time ต่อไป และทำการนับปริมาณยานพาหนะที่ได้จากการตรวจจับ เพื่อเปรียบเทียบความประสิทธิภาพของโมเดล จากผลการทดสอบแสดงให้เห็นว่า ระบบตรวจจับที่นำมาใช้ ให้ผลดีกับบางสถานการณ์ดังแสดงในภาพประกอบที่ 15(a) และไม่ดีในบางสถานการณ์ ดังแสดงในภาพประกอบที่ 15(b) ส่งผลให้การใช้ระบบตรวจจับเป็นหลักการในการนับ มีทั้งผลการทดสอบที่ดีและไม่ดี ขึ้นอยู่กับระบบตรวจจับยานพาหนะ ดังแสดงในภาพประกอบที่ 16 จะเห็นได้ว่า ระบบทำการนับจำนวนยานพาหนะได้มากเกินกว่าความเป็นจริงอยู่พอสมควร ซึ่งระบบการตรวจจับที่เลือกใช้ ควรได้รับการพัฒนาต่อไป



ภาพประกอบ 15 แสดงตัวอย่างการตรวจจับและนับจำนวนของยานพาหนะในงานวิจัยของ Sindhu (a) แสดงการตรวจยานพาหนะจับที่ทำงานได้ดี และ (b) แสดงการตรวจจับยานพาหนะที่ทำงานได้ไม่ดี

ที่มา: Sindhu. (2021). Vehicle Identification from Traffic Video Surveillance Using YOLOv4

```

detections_count = 193, unique_truth_count = 150
class_id = 0, name = car, ap = 24.84% (TP = 32, FP = 27)
class_id = 1, name = truck, ap = 8.33% (TP = 0, FP = 2)
class_id = 2, name = motorcycle, ap = 30.00% (TP = 1, FP = 1)
class_id = 3, name = bus, ap = 45.97% (TP = 5, FP = 4)

```

ภาพประกอบ 16 ผลการนับยานพาหนะของระบบในงานวิจัยของ Sindhu

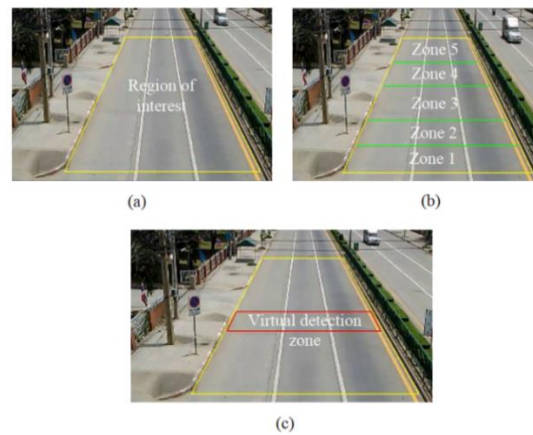
ที่มา: Sindhu. (2021). Vehicle Identification from Traffic Video Surveillance Using YOLOv4

วิธีการนับยานพาหนะจากจำนวนของยานพาหนะที่ถูกตรวจจับได้จากระบบตรวจจับยานพาหนะดังกล่าว ความแม่นยำในการนับจะขึ้นอยู่กับความแม่นยำของระบบตรวจจับ อาจให้ผลที่ดีเฉพาะกรณีที่ข้อมูลจากรามีคุณภาพสูง และ มีการจราจรคล่องตัว ยานพาหนะทุกคันไม่ถูกบดบัง การนับยานพาหนะโดยใช้ระบบตรวจจับ จะเป็นการนับยานพาหนะทุกคันที่ปรากฏใน

ภาพ อาจไม่สามารถระบุได้ว่ายานพาหนะแต่ละคันวิ่งไปในทิศทางใด อีกทั้งยังก่อให้เกิดความผิดพลาดการนับได้ง่ายจากการตรวจจับวัตถุเดิมซ้ำที่อาจเกิดขึ้นจากการบดบังกันของยานพาหนะ หรือการตรวจจับวัตถุในตำแหน่งที่อยู่ไกล ภาพของวัตถุมีขนาดเล็กได้ไม่ดัดนัก เพื่อให้การนับสามารถนับยานพาหนะที่เคลื่อนที่ผ่านจุดนั้นๆ ได้อย่างแม่นยำมากขึ้น วิธีการนับยานพาหนะที่นิยมนำไปประยุกต์ใช้หลักจากขั้นตอนการตรวจจับยานพาหนะและให้ผลลัพธ์ที่ดีคือการกำหนดเส้นอ้างอิงบนถนนในข้อมูลภาพสำหรับนับยานพาหนะที่เคลื่อนที่ผ่าน (Detection Line) และกำหนดจุดอ้างอิงบนตำแหน่งของยานพาหนะ โดยการนับจำนวนยานพาหนะจะนับเมื่อ จุดอ้างอิงบนยานพาหนะที่กำหนด เคลื่อนที่ผ่านตำแหน่งของเส้นอ้างอิงที่กำหนด และอีกวิธีที่นิยมใช้เพิ่มเพิ่มความแม่นยำในการนับปริมาณยานพาหนะคือการสร้างพื้นที่ตรวจจับตรวจจับยานพาหนะ (Virtual Detection Region) บนถนนในข้อมูลภาพ เหมือนการสร้างเส้นอ้างอิงในการนับแบบขนานกันสองเส้น ทำให้สามารถนับยานพาหนะที่ถูกติดตามได้อย่างแม่นยำมากขึ้น

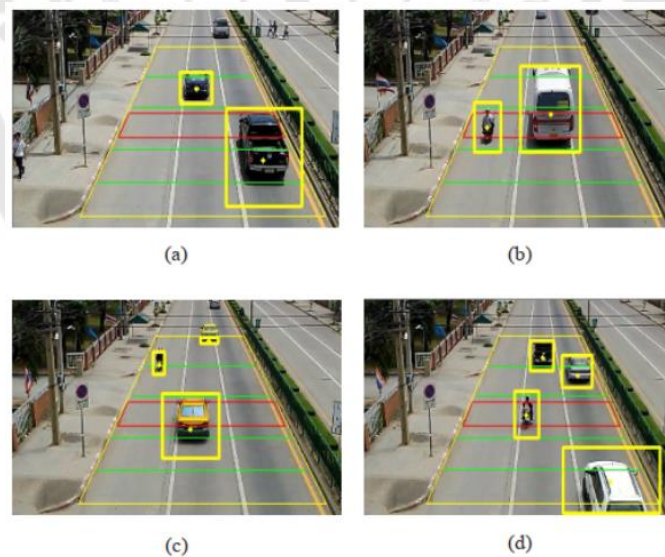
2.3.3 งานวิจัยเรื่อง A Computer Vision Based Vehicle Detection and Counting System (Seenouvang et al., 2016)

หลักการที่นำเสนอในการนับจำนวนยานพาหนะในงานวิจัยนี้ได้กำหนด Region of Interest ดังภาพประกอบที่ 17(a) ซึ่งจะใช้พื้นที่เฉพาะที่อยู่ใน ROI ในการตรวจจับและนับปริมาณยานพาหนะต่อไป และลบส่วนพื้นที่อื่นที่อยู่นอก ROI ทิ้งไป ROI ที่สร้างขึ้นจะแบ่งเป็น 5 โซน ดังแสดงในภาพประกอบที่ 17(b) และกำหนด Virtual Detection Zone สำหรับนับปริมาณจราจรไว้ที่โซน 3 ซึ่งเป็นตำแหน่งที่เห็นยานพาหนะได้ชัดเจน ดังภาพประกอบที่ 17(c) เพื่อนับยานพาหนะที่เคลื่อนที่ผ่านพื้นที่ที่กำหนด ในขั้นตอนของการนับยานพาหนะ จะใช้ตำแหน่ง centroid ของ contours ที่กำหนดไว้บนยานพาหนะเป็นจุดอ้างอิง เมื่อตำแหน่ง centroid อยู่ที่โซน 1 หรือ 2 จะมี status เป็น 0 แล้วเมื่อถึง Virtual Detection จะเปลี่ยนเป็น 1 หรือถูกนับแล้ว ดังแสดงในภาพประกอบที่ 18 เพื่อป้องกันการนับยานพาหนะคันนั้นซ้ำๆ ซึ่งในงานวิจัยนี้ได้ผลการทดลองที่มีความแม่นยำของระบบนับปริมาณจราจรที่นำเสนออยู่ที่ประมาณ 96 เปอร์เซ็นต์



ภาพประกอบ 17 ภาพแสดงการตัวอย่างระบบตรวจจับและนับยานพาหนะในงานวิจัยของ Seenouvang et al รูปภาพ (a) region of interest (b) การแบ่งแยกพื้นที่ของ ROI และ (c) virtual detection zone

ที่ ม ๑ : Seenouvang et al. (2016). A Computer Vision Based Vehicle Detection and Counting System




ภาพประกอบ 18 ระบบตรวจจับยานพาหนะในงานวิจัยของ Seenouvang et al รูปภาพ (a), (b), (c) และ (d) แสดงตัวอย่างการนับยานพาหนะ

ที่ ม ๑ : Seenouvang et al. (2016). A Computer Vision Based Vehicle Detection and Counting System

2.3.4 งานวิจัยเรื่อง A video-based real-time adaptive vehicle counting system for urban roads (Liu et al., 2017)

งานวิจัยนี้ นำเสนอการใช้ Ground update algorithm มาใช้ในการตรวจนับยานพาหนะบนท้องถนนแบบอัตโนมัติ และใช้รูปแบบการนับปริมาณของยานพาหนะที่ตรวจนับได้ด้วยวิธีการใช้ Virtual loop และ Detection line นอกจากนี้ ยังได้นำเสนอวิธีการใหม่ๆ ที่ช่วยพัฒนาการตรวจนับยานพาหนะตามสภาพการจราจร (ความติดขัดของการจราจร) ในแต่ละช่วงถนนอีกด้วย ซึ่งระบบต้นแบบที่พัฒนาด้วยวิธีการดังกล่าวข้างต้นได้ถูกติดตั้งและอยู่ในขั้นตอนการทดลองใช้งานจริงบนถนนในเมือง ในขั้นตอนการนับยานพาหนะ ได้ปรับปรุงวิธีการที่ใช้สำหรับนับปริมาณจราจรเรียกว่า frame difference function (FDF) สำหรับนับปริมาณจราจรที่มีสภาพการจราจรแตกต่างกันระหว่างการจราจรที่มีความคล่องตัวกับการจราจรที่มีความติดขัดโดยสำหรับสภาพการจราจรที่มีความคล่องตัว จะใช้ Detection line บนถนนแต่ละช่องจราจร และนับปริมาณจราจรจากกรอบสี่เหลี่ยมที่ได้ระบุจากการตรวจนับยานพาหนะที่เคลื่อนผ่านเส้น base line ในแต่ละภาพ โดยมีการอ้างอิงจุดของ Target ที่เคลื่อนที่ผ่านเส้น baseline และ จุดบนเส้น base line สำหรับสภาพการจราจรที่มีความติดขัด เนื่องจากยานพาหนะอาจอยู่ในตำแหน่งที่ติดกันมากๆ การใช้เส้น Base line อาจทำให้ระบบนับยานพาหนะที่มีส่วนของ segment ที่ทับกันรวมเป็นคันเดียวกันได้ จึงเลือกใช้ Virtual Loop ที่สร้างขึ้นเป็นกรอบสี่เหลี่ยม และนับปริมาณจราจรจากสัดส่วน object pixels ของแต่ละ segment ต่อขนาดของ Virtual Loop และ สัดส่วนความกว้าง object ของแต่ละ segment ต่อความกว้างของ Virtual Loop เป็นเกณฑ์ในการนับ ดังแสดงในภาพประกอบที่ 19 และระบบสามารถปรับเปลี่ยนรูปแบบการนับปริมาณจราจรระหว่างทั้งสองแบบนี้ได้ตามสภาพการจราจรได้อย่างรวดเร็ว ผลการทดลองพบว่า เมื่อเปรียบเทียบกับระบบอื่นๆ ที่ยกมาอ้างอิงแล้ว ระบบที่พัฒนามานี้ มีระดับความแม่นยำในการนับปริมาณจราจรเฉลี่ยอยู่ที่ประมาณร้อยละ 99.29 ซึ่งสูงกว่าทุกๆ ระบบที่ยกมา



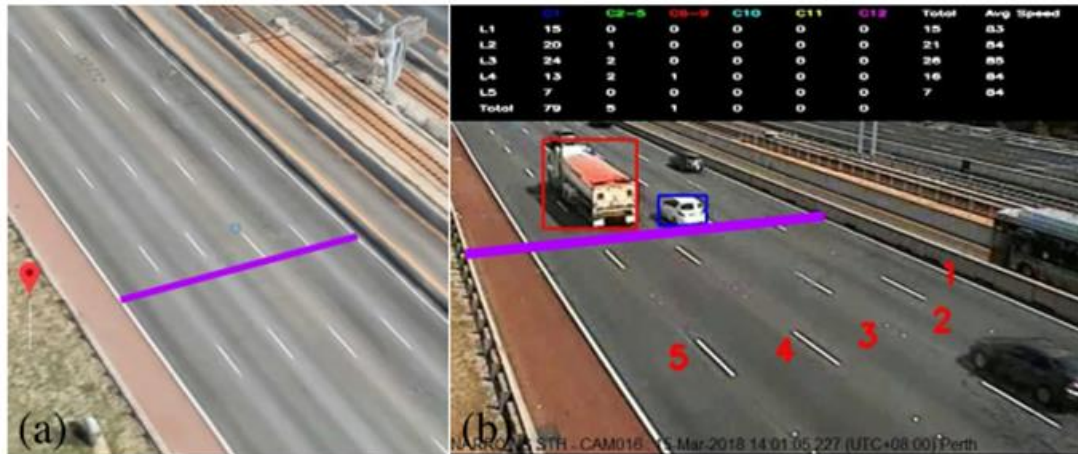
ภาพประกอบ 19 แสดงตัวอย่างการใช้ virtual loops และ detection line ในการนับจำนวนยานพาหนะของระบบในงานวิจัยของ Liu et al

ที่มา : Liu et al. (2017). A video-based real-time adaptive vehicle counting system for urban roads

2.3.5 งานวิจัยเรื่อง A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification (Liu et al., 2021)

ได้นำเสนอการประยุกต์ใช้เทคโนโลยีด้านคอมพิวเตอร์วิทัศน์กับอุปกรณ์เก่าๆที่มีใช้อยู่อย่างมีประสิทธิภาพ เพื่อดึงเอาข้อมูลด้านการจราจรจากภาพบันทึกวีดีโอ โดยนำการตรวจจับวัตถุที่เป็น state-of-the-art มาใช้ และทำการ transfer-learning เพื่อตรวจจับวัตถุที่เป็นยานพาหนะ, คนเดินเท้า, และจักรยาน จากกล้องวีดีโอ เราได้นำเสนอการใช้งานรูปแบบใหม่ คือ image-to-world homography ที่ช่วยเพิ่มประสิทธิภาพในการนับจำนวนยานพาหนะจากช่องจราจรและคาดการณ์ความยาวของยานพาหนะและความเร็วของยานพาหนะตามหน่วยจริงได้ และได้ทำการรวม convolutional neural network (CNN) classifier กับข้อมูลภาพเชิงเรขาคณิตเข้าไปด้วย เพื่อใช้ในการแยกประเภทของยานพาหนะ ในส่วนของการนับปริมาณจราจร รวมทั้งคนเดินเท้าและจักรยาน ได้ทำการสร้าง Reference line ขึ้นมา และใช้ Reference point บน Boundary box เป็นตัวกำหนดในการนับเมื่อเคลื่อนที่ผ่าน Reference line ดังแสดงในภาพประกอบที่ 20 และ

สำหรับผลการนับและแยกประเภทของยานพาหนะที่ได้ พบว่าโมเดลที่นำเสนอ ให้ผลที่ดีมากมีความแม่นยำมากกว่า 90 เปอร์เซ็นต์



ภาพประกอบ 20 แสดงตัวอย่างการใช้ detection line ในการนับจำนวนยานพาหนะของระบบในงานวิจัยของ Liu et al

ที่มา : Liu et al. (2021). A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification

2.4 ระบบจำแนกประเภทยานพาหนะ (Vehicle Classification)

ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน อย่าง YOLO ที่เลือกใช้ มีโครงสร้างเป็นระบบตรวจจับแบบขั้นตอนเดียว หรือ One Stage Detector ที่สามารถให้ผลลัพธ์ออกมาได้เป็นกล่องขอบเขตของวัตถุ และจำแนกประเภทของวัตถุได้ กล่าวคือ สามารถทำนายประเภทของยานพาหนะได้จากขั้นตอนการตรวจจับยานพาหนะ แต่ด้วยตัว YOLO ที่พัฒนาเพื่อตรวจจับและจำแนกประเภทของยานพาหนะโดยทั่วไป ถูกฝึกฝนระบบโดยใช้ชุดข้อมูล COCO ที่มีประเภทของยานพาหนะที่วิ่งบนถนนอยู่เพียง 4 ประเภทเท่านั้น คือ motorcycle, car, bus และ truck ในการพัฒนาระบบให้สามารถจำแนกประเภทให้มีความหลากหลายตามที่ต้องการได้ จะต้องมีการสร้างชุดข้อมูลของตนเองขึ้นมาเพื่อใช้เป็นข้อมูลให้ระบบเรียนรู้และทำนายประเภทที่มีความหลากหลายมากขึ้น

2.4.1 งานวิจัยเรื่อง Classified Counting and Tracking of Local Vehicles in Manila Using Computer Vision (Cruz et al., 2019)

ในงานวิจัยนี้ได้นำเสนอระบบนับและจำแนกยานพาหนะท้องถิ่นในเมืองมะนิลา ประเทศฟิลิปปินส์ ซึ่งเมืองมะนิลาเอง มีประเภทของยานพาหนะที่แตกต่างกับบนถนนสายหลักอยู่อย่างน้อย 9 ประเภท, ถนนสายรองอย่างน้อยประมาณ 21 ประเภท เพื่อให้สามารถจำแนกประเภทของยานพาหนะได้หลากหลายมากขึ้น ผู้วิจัยได้นำเสนอการสร้างชุดข้อมูลยานพาหนะท้องถิ่นที่สร้างขึ้นเอง เพื่อใช้การเรียนรู้ของเครื่องโดยจากข้อมูลวิดีโอที่นำมาใช้ สามารถแยกความแตกต่างของประเภทของยานพาหนะได้เป็นทั้งหมด 11 ประเภท ดังแสดงในภาพประกอบที่ 21 สำหรับการพัฒนาโมเดลเพื่อจำแนกประเภทของยานพาหนะนั้น ได้ใช้ Neural Network Algorithms ที่ฝึกฝนด้วย Pre-train model ที่เลือกมาทดสอบ 3 โมเดล ได้แก่ 1.) SSD+Mobilenet, 2.) Faster-RCNN + ResNet50 และ 3.) Faster-RCNN + ResNet101 แล้วทำการเปรียบเทียบเพื่อเลือกโมเดลที่ให้ผลดีที่สุดไปใช้ในการตรวจจับและจำแนกประเภทของยานพาหนะ ซึ่งจากผลการทดสอบระบบ ทำให้เห็นว่า ในการทดลองเปรียบเทียบโมเดลที่ดีที่สุดในการจำแนกประเภทยานพาหนะ ระบบที่สามารถจำแนกประเภททั้งหมด สามารถทำงานได้ผลที่ค่อนข้างดี สามารถแยกประเภทได้โดยมีความแม่นยำอยู่ที่ 92.96 เปอร์เซ็นต์ โดยโมเดลที่ใช้ตรวจจับและแยกประเภทได้ดีที่สุดคือ Faster-RCNN + ResNet101




ภาพประกอบ 21 ตัวอย่างการตรวจจับของระบบแยกประเภทของยานพาหนะท้องถิ่นในงานวิจัยของ Cruz et al

ที่มา: Cruz et al. (2019). Classified Counting and Tracking of Local Vehicles in Manila Using Computer Vision

2.4.2 งานวิจัยเรื่อง Embedded CNN based vehicle classification and counting in non-laned road traffic (Chauhan et al., 2019)

ในงานวิจัยนี้ นอกจากจะนำเสนอโมเดลที่เพื่อเปรียบเทียบผลการจำแนกประเภทและนับจำนวนยานพาหนะการโดยใช้หลักการ CNN ที่มีความแตกต่างกันแล้ว ยังได้นำเสนอการนำชุดข้อมูลที่สร้างขึ้นเอง โดยใช้วิดีโอที่เก็บมา 4 รูปแบบที่มีมุมมองของยานพาหนะที่แตกต่างกัน มาสร้างเป็นข้อมูลของตนเอง เพื่อแบ่งยาน พาหนะออกเป็น 7 ประเภท เพื่อฝึกฝนระบบโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันในการตรวจจับและจำแนกประเภทตามประเภทของยานพาหนะท้องถิ่น ซึ่งจากการทดสอบนี้ แสดงให้เห็นว่า ระบบสามารถทำการจำแนกประเภทของยานพาหนะที่หลากหลายได้ค่อนข้างดี ดังแสดงในภาพประกอบที่ 22



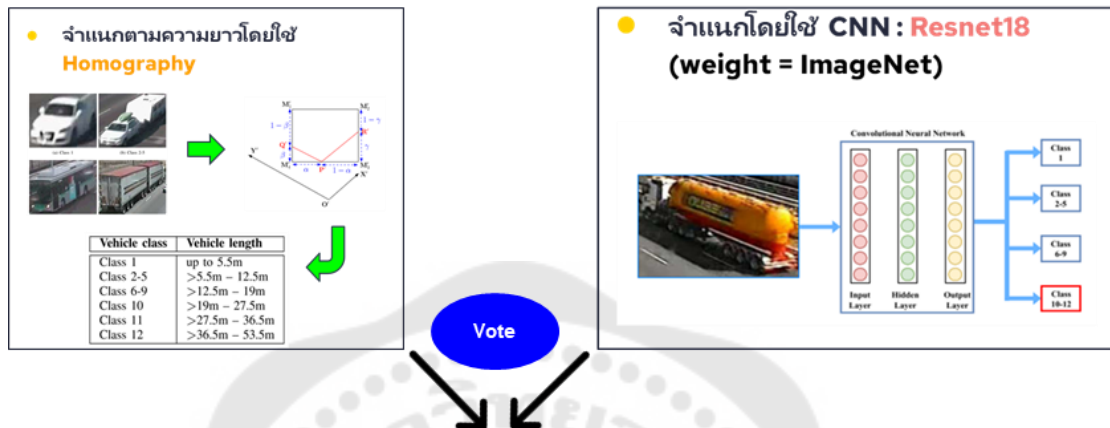
ภาพประกอบ 22 แสดงตัวอย่างผลการทดสอบการจำแนกประเภทของยานพาหนะท้องถิ่นที่สร้างขึ้นได้ โดยใช้ตัวชี้วัดเป็นค่า precision ในงานวิจัยของ Chauhan et al

ที่มา: Chauhan et al. (2019). Embedded CNN based vehicle classification and counting in non-laned road traffic

2.4.3 งานวิจัยเรื่อง A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification (Liu et al., 2021)

ได้นำเสนอการประยุกต์ใช้เทคโนโลยีด้านคอมพิวเตอร์วิทัศน์กับอุปกรณ์ต่างๆที่มีใช้อยู่อย่างมีประสิทธิภาพ เพื่อดึงเอาข้อมูลด้านการจราจรจากภาพบันทึกวิดีโอ โดยในส่วนการแยกประเภทของยานพาหนะ ได้แบ่งประเภทของยานพาหนะออกเป็น 12 ประเภท และเสนอวิธีการตรวจจับ 2 วิธี คือการใช้ความยาวของยานพาหนะที่ได้จากขั้นตอนการตรวจจับเป็นตัวจำแนกร่วมกับการใช้หลักการของ CNN เพื่อจำแนกประเภทของยานพาหนะ แล้วจึงทำการโหวตเพื่อหา

ประเภทของยานพาหนะ โดยผลลัพธ์ประเภทของยานพาหนะที่มีเลือกจำนวนครั้งที่มากที่สุดของที่ถูกจำแนกในทุกๆภาพ ดังแสดงในภาพประกอบที่ 23 เพื่อให้ได้ผลการทำนายที่แม่นยำและน่าเชื่อถือมากขึ้น



Final Class = Class(\hat{i}), where $\hat{i} = \text{argmax count}(i)$

ภาพประกอบ 23 ภาพแสดงการจำแนกประเภทของระบบในงานวิจัยของ Liu et al

ที่มา : Liu et al. (2021). A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification

จากงานวิจัยที่ผ่านมา พบว่าระบบการจำแนกประเภทของยานพาหนะที่ใช้การหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชันในการฝึกฝนโมเดลที่ถูกฝึกฝนมาแล้ว (Pretrained Model) ร่วมกับชุดข้อมูลยานพาหนะท้องถิ่นที่ได้สร้างขึ้นใหม่จากรูปถ่ายของยานพาหนะที่มีการใช้งานอยู่จริงในพื้นที่นั้นๆ สามารถพัฒนาให้เป็นระบบที่จำแนกประเภทยานพาหนะได้หลากหลายประเภทมากขึ้นตามต้องการได้ และทำงานได้อย่างแม่นยำ สามารถนำไปประยุกต์ใช้กับระบบการจำแนกประเภทของยานพาหนะท้องถิ่นในสถานที่ต่างๆได้


2.5 การประเมินประสิทธิภาพ (Evaluation)

ในการประเมินประสิทธิภาพของระบบนับยานพาหนะยานพาหนะ ผู้วิจัยนิยมนำเสนอผลการทดลองด้วยวิธีการเปรียบเทียบผลลัพธ์ที่ได้กับผลเฉลยของข้อมูลที่เกิดขึ้นจริง (ground truth) จากการนับด้วยสายตา ตัวชี้วัดที่แสดงประสิทธิภาพของระบบได้อย่างชัดเจนและนิยมใช้กันมากคือ ค่าความแม่นยำ (Accuracy) และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error (MAPE)) ที่มักถูกนำมาเป็นตัววัดความผิดพลาดในการทำนายประเภทของ

ยานพาหนะโดยภาพรวมของระบบที่นำเสนอ นอกจากนี้ ยังมีตัวชี้วัดอื่นๆ ที่ถูกเลือกมาใช้อธิบาย เพื่อแสดงรายละเอียดการจำแนกประเภทยานพาหนะของระบบ อย่างเช่น Precision, True Positive Rate หรือ Recall, True Negative Rate หรือ Specificity, False Positive Rate, False Negative Rate และ Confusion Matrix ที่แสดงรายละเอียดของ True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN) เป็นต้น

2.5.1 งานวิจัยเรื่อง Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis (A. Alsanabani et al., 2020)

งานวิจัยนี้นำเสนอการสำรวจระบบการนับปริมาณจราจรที่เป็นการรวมกันของ Deep Learning Algorithms สำหรับการตรวจจับวัตถุ (Object Detector) และ Algorithms สำหรับการติดตามวัตถุ (Object Tracker) ที่เป็นที่ยอมรับในปัจจุบัน เพื่อนำไปปรับใช้กับการนับปริมาณจราจร โดยในการทดสอบระบบ ใช้ผลที่ได้จากการนับโดยโมเดลเปรียบเทียบกับการนับด้วยสายตาจากข้อมูลจริง โดยมีตัวชี้วัดที่เลือกใช้แสดงผลเปรียบเทียบคือ Accuracy Percentage โดยภาพประกอบที่ 24 แสดงผลการเปรียบเทียบสัดส่วนความแม่นยำโดยรวมในการนับยานพาหนะของโมเดลที่เลือกใช้ และตารางที่ 1



ภาพประกอบ 24 ผลการเปรียบเทียบสัดส่วนความแม่นยำในการนับยานพาหนะของโมเดลที่เลือกใช้ในงานวิจัยของ A. Alsanabani et al

ที่มา : A. Alsanabani et al. (2020). Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis

ตาราง 1 ผลการเปรียบเทียบสัดส่วนความแม่นยำในการนับยานพาหนะของโมเดลที่เลือกใช้ ภายใต้เงื่อนไขความแตกต่างของสภาพอากาศและช่วงเวลาในงานวิจัยของ A. Alsanabani et al

Model	Daylight		Night		Rain	
	Counts	Pct. %	Counts	Pct. %	Counts	Pct. %
CenterNet and Deep SORT	1693	96	811	97	72	104
CenterNet and IOU	2350	133	1246	149	1208	173
CenterNet and KIOU	1359	77	644	77	845	121
CenterNet and SORT	2033	115	945	113	942	135
Detectron2 and Deep SORT	1637	93	775	92.7	649	93
Detectron2 and IOU	2722	155	1413	169	1180	169
Detectron2 and KIOU	1387	79	694	83	796	144
Detectron2 and SORT	1984	113	928	111	879	126
EfficientDet and IOU	1405	80	686	82	642	92
EfficientDet and KIOU	597	34	318	38	30	53
EfficientDet and SORT	562	32	510	61	342	49
YOLOv4 and Deep SORT	1633	93	769	92	642	92
YOLOv4 and IOU	2581	147	1204	144	1040	149
YOLOv4 and KIOU	1264	72	585	70	586	84
YOLOv4 and SORT	1984	113	903	108	845	121

ที่ มา : A. Alsanabani et al. (2020). Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis

2.5.2 งานวิจัยเรื่อง Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow (Harjoko et al., 2017)

งานวิจัยที่นำเสนอระบบตรวจจับ ติดตามและนับปริมาณจราจรที่ใช้ Haar Cascade Classifier สำหรับตรวจจับยานพาหนะ และใช้วิธีการ Optical Flow ในการติดตามยานพาหนะ และนับปริมาณจราจรจากการตรวจจับและติดตามยานพาหนะการทดสอบระบบ จะรวมทั้งการตรวจจับ ติดตาม และนับปริมาณของยานพาหนะ โดยในการทดสอบการตรวจจับยานพาหนะ ได้เปรียบเทียบการใช้ min_neighbours value (min_nb) ที่หลากหลาย และเปรียบเทียบโดยใช้ค่า Accuracy Percentage เป็นตัวชี้วัด เพื่อดูประสิทธิภาพในการนับระบบ ดังแสดงในตารางที่ 2 จะเห็นได้ว่า ระบบที่นำเสนอมีความแม่นยำในการนับที่ค่อนข้างมีประสิทธิภาพ โดยมีความแม่นยำสูงสุดอยู่ที่ประมาณ 89.40 เปอร์เซ็นต์


ตาราง 2 ผลการนับยานพาหนะของงานวิจัยที่ภู่านำเสนอในงานวิจัยของ Harjoko et al

Min-nb	Real	Detected	TP	TN	FP	FN	Acc (%)
2	1744	1769	1648	0	121	96	88.36
3	1744	1688	1620	0	68	124	89.4
4	1744	1625	1577	0	48	167	88

ที่ ม า : Harjoko et al. (2017). Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow

2.5.3 งานวิจัยเรื่อง A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation (Zhang & Zhang, 2021)

นำเสน่วิธีการในการพัฒนาระบบเฝ้าระวังด้านการจราจรที่เก็บข้อมูลของยานพาหนะ (ประกอบไปด้วย ประเภทยานพาหนะ, จำนวนเพลลาของยานพาหนะ, กรอบภาพวัตถุแบบ 3 มิติ, ความเร็วของยานพาหนะ, ช่องจราจรของยานพาหนะ และปริมาณจราจร) โดยการใช้ Mas R-CNN ในการทำ Instance Segmentation เพื่อตรวจวัตถุ, ใช้ SORT ในการติดตามวัตถุ และทำการ calibrate ภาพในข้อมูลวิดีโอ เพื่อสร้าง homography matrix ในการกำหนดระยะต่างๆตามความเป็นจริง ในการวัดผลการจำแนกของระบบที่นำเสนอ ผู้วิจัยได้แสดงผลโดยใช้ confusion matrixes ในการแสดงให้เห็นถึงรายละเอียดการจำแนกอย่างชัดเจนดังแสดงใน **ภาพประกอบที่ 25** และในส่วนของการวัดผลการจำแนกของระบบที่นำเสนอ ได้แสดงเป็นสัดส่วนของผลการนับจากระบบเปรียบเทียบกับผลเฉลยของข้อมูลจริงดังแสดงใน **ตารางที่ 3** พบว่ามีความแม่นยำเฉลี่ยในการจำแยกประเภทของยานพาหนะในวิดีโอทั้งสามอยู่ที่ 97.3 เปอร์เซ็นต์, 98.8 เปอร์เซ็นต์ และ 99.1 เปอร์เซ็นต์ และความแม่นยำเฉลี่ยในการจำแยกจำนวนเพลลาของยานพาหนะในวิดีโอทั้งสามอยู่ที่ 95.4 เปอร์เซ็นต์, 88.5 เปอร์เซ็นต์ และ 99.5 เปอร์เซ็นต์



ภาพประกอบ 25 แสดงภาพตัวอย่างผลการจดจำประเภทของยานพาหนะและจำนวนของเพลลา (a), (b) และ (c) แสดง confusion matrixes ของการจำแนกประเภทของยานพาหนะจากชุดข้อมูลที่ 1, ชุดข้อมูลที่ 2 และ ชุดข้อมูลที่ 3 ในงานวิจัยของ Zhang & Zhang

ที่ ม ๓ : Zhang & Zhang. (2021). A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation

ตาราง 3 แสดงผลการนับยานพาหนะแยกประเภทของยานพาหนะจากชุดข้อมูลที่ 1, ชุดข้อมูลที่ 2 และ ชุดข้อมูลที่ 3 ในงานวิจัยของ Zhang & Zhang

	Driving lane	Car (CN/GT)	Coach (CN/GT)	Truck (CN/GT)	All Types (CN/GT)
Video 1	Inside	202/202	7/8	8/6	217/216
	Outside	61/58	13/12	89/90	163/160
Video 2	Inside	148/148	13/12	4/4	156/156
	Outside	72/68	15/15	95/95	182/178
Video 3	Inside	125/128	2/0	12/7	139/135
	Outside	165/164	2/2	38/30	205/196

ที่ ม ๓ : Zhang & Zhang. (2021). A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation

บทที่ 3

กระบวนการ และวิธีการดำเนินการวิจัย

กระบวนการวิจัยทั้งหมดของผู้ทำวิจัย จะมุ่งเน้นในการศึกษางานวิจัย เพื่อนำมาใช้ในการการปรับปรุง พัฒนา และค้นหารูปแบบการนับยานพาหนะ ในเส้นทางที่กำหนด ด้วยการนำหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่มีพื้นฐานมาจากวิธีการเรียนรู้เชิงลึก หรือที่เรียกกันว่า Deep Learning ที่มีประสิทธิภาพและเหมาะสมกับการนำมาใช้ในงานวิจัยนี้ โดยงานวิจัยนี้ ผู้วิจัยได้ออกแบบขั้นตอนของการดำเนินการวิจัยดังภาพประกอบที่ 26 ที่มีการแบ่งขั้นตอนการทำงานออกเป็น 6 ขั้นตอน เพื่อนำเสนอรูปแบบที่เหมาะสมกับการทำวิจัย และในขั้นตอนสุดท้ายจะนำเสนอวิธีการประเมินประสิทธิภาพของรูปแบบที่นำเสนอ ด้วยการวัดผลทั้งด้านปริมาณ (Quantitative evaluation) และทางด้านคุณภาพ (Qualitative evaluation) เพื่อเป็นการแสดงถึงประสิทธิภาพของกระบวนการทำวิจัย



ภาพประกอบ 26 ภาพประกอบแสดง Flowchart วิธีการดำเนินงานการวิจัย

3.1 การเก็บรวบรวมข้อมูล (Data Acquisition)

ข้อมูลที่ใช้ในงานวิจัยนี้ จะเป็นข้อมูลที่อยู่ในรูปแบบของข้อมูลรูปภาพและวิดีโอ ที่เป็นการบันทึกข้อมูลของปริมาณจราจรของยานพาหนะบนถนนเขตในเมือง ของประเทศไทย ที่ได้ทำการเก็บรวบรวมโดยแผนกวิศวกรรมขนส่งและจราจรของบริษัทที่ปรึกษาด้านวิศวกรรมของหน่วยงานหนึ่ง และตั้งสมมติฐานของความแตกต่างทั้งในด้านของสถานที่ในการทำการสำรวจ สภาพการณ์ของการจราจร ช่วงเวลาและสภาพอากาศ มากไปกว่านั้นข้อมูลของยานพาหนะที่ทำการบันทึกมา ยังมีความหลากหลายของประเภทของยานพาหนะอีกด้วย และสำหรับงานวิจัยนี้จะมุ่งเน้นไปที่ข้อมูลของการบันทึกวิดีโอในพื้นที่ปิด อย่างเช่น ถนนทางด่วน หรือเส้นทางที่สามารถใช้ความเร็วได้ เพื่อลดความหลากหลายของข้อมูลที่มากเกินไปจนทำให้รูปแบบของการเรียนรู้ไม่สามารถจำแนกหรือนับข้อมูลได้อย่างถูกต้อง

ข้อมูลทั้งหมดแบ่งออกเป็น 2 ส่วน เป็นข้อมูลประเภทรูปภาพของการจราจรจำนวน 250 รูปภาพ สำหรับใช้เป็นข้อมูลตั้งต้นในการสร้างชุดข้อมูลยานพาหนะท้องถิ่นของประเทศไทย

สำหรับฝึกฝนระบบ และข้อมูลวิดีโอที่มีบันทึกจากจุดสำรวจที่แตกต่างกัน 5 จุดสำรวจ เป็นจำนวน 6 วิดีโอ ที่มีสภาพการณที่แตกต่างกันดังแสดงในภาพประกอบที่ 27 ใช้เป็นข้อมูลในการทดสอบการทำงานของระบบที่นำเสนอ โดยเป็นข้อมูลวิดีโอที่บันทึกทางมุมสูง (เก็บสำรวจบนสะพานลอยคนเดินข้ามถนน) และแต่ละวิดีโอมีความยาวประมาณ 10 นาที โดยมีรายละเอียดอื่น ๆ ดังต่อไปนี้

1. วิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ มีความละเอียดของภาพระดับ HD (720p)
2. วิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางคืน (จุดสำรวจตำแหน่งเดียวกันกับวิดีโอที่ 1) มีความละเอียดของภาพระดับ HD (720p)
3. วิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งออกจากจุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ การจราจรใช้ความเร็วในการขับที่ค่อนข้างสูงมีความละเอียดของภาพระดับ HD (720p)
4. วิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน บริเวณพื้นถนนมีเงาตกกระทบไม้ส้วมามีความละเอียดของภาพระดับ HD (720p)
5. วิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงน้อย มองเห็นยานพาหนะได้ชัดเจน มีความละเอียดของภาพระดับ HD (720p)
6. วิดีโอการจราจร สภาพการจราจรค่อนข้างติดขัดเล็กน้อยจากการหยุดรถสัญญาณไฟจราจร ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน มีความละเอียดของภาพระดับ Full HD (1080p)

ข้อมูลวิดีโอสำหรับทดสอบผลการทดลองครั้งนี้ จะถูกใช้ในการนับด้วยบุคลากรที่มีความสามารถ เพื่อกำหนดให้เป็นข้อมูลผลเฉลยของชุดข้อมูล หรือ Ground Truth โดยจะใช้ในการเปรียบเทียบกับผลลัพธ์การนับปริมาณยานพาหนะและจำแนกประเภทของยานพาหนะของระบบ เพื่อประเมินประสิทธิภาพของระบบที่สร้างขึ้น



ภาพประกอบ 27 ตัวอย่างภาพของวิดีโอที่ใช้สำหรับทดสอบระบบที่ 1 ถึง 6 ตามลำดับ

3.2 การเตรียมข้อมูล (Pre-Processing)

ในการเตรียมความพร้อมของชุดข้อมูล ผู้วิจัยได้จัดทางผู้วิจัยได้ใช้ภาพถ่ายตั้งต้นของยานพาหนะบนท้องถนนทั้งหมด 250 รูปภาพ และทำการกำหนดป้ายชื่อประเภทของยานพาหนะในรูป หรือการทำ labelling โดยใช้เครื่องมือ Roboflow เพื่อสร้างชุดข้อมูลรูปภาพของยานพาหนะที่มีประเภทของยานพาหนะที่แตกต่างกัน 11 ประเภท ตามรูปแบบการแบ่งประเภทของยานพาหนะของกรมทางหลวงแห่งประเทศไทย ได้แก่

1. Motorcycle หรือ รถจักรยานยนต์
2. Passenger Car หรือ รถยนต์นั่งส่วนบุคคลไม่เกิน 7 ที่นั่ง
3. Van หรือ รถยนต์นั่งส่วนบุคคลเกิน 7 ที่นั่ง
4. Light Truck หรือ รถบรรทุกขนาดเล็ก 4 ล้อ
5. Medium Truck หรือ รถบรรทุกขนาดกลาง 6 ล้อ
6. Heavy Truck หรือ รถบรรทุกขนาดใหญ่ 10 ล้อ

7. Light Bus หรือ รถโดยสารขนาดเล็ก
8. Medium Bus หรือ รถโดยสารขนาดกลาง
9. Heavy Bus หรือ รถโดยสารขนาดใหญ่
10. Semi-Trailer หรือ รถกึ่งพ่วง
11. Full-Trailer หรือ รถพ่วง

นอกจากนี้ Roboflow ยังสามาถสามารถใช้เป็นเครื่องมือในการทำ Data Augmentation กับข้อมูลตั้งต้นและสร้างรูปภาพเป็นรูปภาพใหม่ๆ เพื่อเพิ่มความหลากหลายและจำนวนข้อมูลได้ โดยในขั้นตอนนี้ ผู้วิจัยเลือกใช้วิธีการ กลับด้านรูปภาพ (Flip), ตัดบางส่วนของภาพ (Crop), หมุนรูปภาพ (Rotation), ปรับเฉือนรูปภาพ (Shear), ปรับแสงสว่าง (Brightness) และ เพิ่มสิ่งรบกวนลงไปในภาพ (Noise) ก่อนนำไปสร้างเป็นชุดข้อมูลเพื่อฝึกฝนแบบจำลองในขั้นตอนต่อไป จากผลการทำงาน Labelling และ Data Augmentation โดยใช้เครื่องมือ Roboflow นี้ ทำให้ได้ชุดข้อมูลที่มีรูปภาพทั้งหมด 3000 รูปภาพ และมี label ที่แตกต่างกันทั้งหมด 11 ประเภท โดยมีรายละเอียด instance ของยานพาหนะแต่ละประเภทดังแสดงในตารางที่ 4 สำหรับใช้ในการฝึกฝนระบบรู้จำประเภทยานพาหนะ ตัวอย่างของภาพในชุดข้อมูลที่สร้างแสดงดัง ภาพประกอบที่ 28

ตาราง 4 รายละเอียดจำนวน instance ของยานพาหนะแต่ละประเภทในชุดข้อมูล

Class	Description	Instances
0	motorcycle	11,905
1	Passenger Car	21,676
2	Van	2,231
3	light bus	144
4	medium bus	1,322
5	heavy bus	276
6	light truck	12,641
7	medium truck	1,322
8	heavy truck	1,228
9	semi-trailer	1,023
10	full trailer	402



ภาพประกอบ 28 ตัวอย่างภาพยานพาหนะในชุดข้อมูลที่สร้างขึ้น

3.3 การตรวจจับยานพาหนะ (Vehicle Detection)

สำหรับในขั้นตอนการตรวจจับวัตถุที่เป็นยานพาหนะ ผู้วิจัยได้เลือกใช้หลักการโครงข่ายประสาทเทียมแบบคอนโวลูชันอย่าง YOLOv8 เป็นสถาปัตยกรรมหลักของระบบในการตรวจจับวัตถุที่เป็นยานพาหนะ โดยผลลัพธ์ที่ได้จากขั้นตอนการตรวจจับนี้คือ กล่องขอบเขต 2 มิติของยานพาหนะ (2D Bounding Box) และความน่าจะเป็นของประเภทของวัตถุ (Class Probabilities) ซึ่งผลลัพธ์ดังกล่าวไปนี้ จะถูกใช้เป็นพารามิเตอร์ในขั้นตอนการติดตามยานพาหนะ (Vehicle Tracking) ต่อไป แต่เนื่องด้วย YOLO ถูกฝึกฝนโดยใช้ชุดข้อมูล COCO ซึ่งภายในชุดข้อมูลนี้มีวัตถุที่เป็นยานพาหนะบนถนนเพียง 4 ประเภท ได้แก่ motorcycle, car, truck และ bus ทำให้ทำนายประเภทของวัตถุได้เพียงแค่ 4 ประเภทเท่านั้น เพื่อให้ระบบที่สร้างสามารถทำนายผลประเภทของยานพาหนะได้ตามต้องการ จึงต้องทำงานฝึกฝนระบบด้วยชุดข้อมูลที่สร้างขึ้นมาในขั้นตอนก่อนหน้านี้ ให้ระบบสามารถตรวจจับและทำนายประเภทของยานพาหนะได้ทั้งหมด 11 ประเภทตามที่กำหนดในชุดข้อมูล โดยเลือกฝึกฝนด้วย pretrained weight ที่มีโครงสร้างแตกต่างกันสามตัวได้แก่ YOLOv8n, YOLOv8m และ YOLOv8x ซึ่งเป็น weight ที่ได้จากการฝึกฝนโดยใช้ชุดข้อมูล COCO val2017 โดยกำหนดพารามิเตอร์ batch = 16 และ epoch = 100 และเลือก weight ที่ดีที่สุดของแต่ละโครงสร้างไว้ใช้สำหรับทดสอบระบบต่อไป จากผลของการฝึกฝนข้อมูลพบว่า การเลือกใช้ YOLOv8x เป็น weight ในการฝึกฝน ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า mAP50 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 98 เปอร์เซ็นต์ และค่า mAP50-95 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 86.3 เปอร์เซ็นต์ ดังแสดงในภาพประกอบที่ 29 และ

confusion matrix ของการทำนายประเภทของยานพาหนะแสดงดังภาพประกอบที่ 30 รองลงมาคือ YOLOv8m เป็น weight ในการฝึกฝน ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า mAP50 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 97 เปอร์เซ็นต์ และค่า mAP50-95 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 81.7 เปอร์เซ็นต์ ดังแสดงในภาพประกอบที่ 31 และ confusion matrix ของการทำนายประเภทของยานพาหนะแสดงดังภาพประกอบที่ 32 และสำหรับ YOLOv8n เป็น weight ในการฝึกฝน มีประสิทธิภาพต่ำที่สุด โดยมีค่า mAP50 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 86.9 เปอร์เซ็นต์ และค่า mAP50-95 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 62.3 เปอร์เซ็นต์ ดังแสดงในภาพประกอบที่ 33 และ confusion matrix ของการทำนายประเภทของยานพาหนะแสดงดังภาพประกอบที่ 34

```

100 epochs completed in 9.482 hours.
Optimizer stripped from runs/detect/train/weights/last.pt, 136.7MB
Optimizer stripped from runs/detect/train/weights/best.pt, 136.7MB

Validating runs/detect/train/weights/best.pt...
Ultralytics YOLOv8.0.54 Python-3.9.16 torch-1.13.1+cu116 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 268 layers, 68134161 parameters, 0 gradients, 257.4 GFLOPs

```


Class	Images	Instances	Box(P)	R	mAP50	mAP50-95):
all	3000	54960	0.989	0.959	0.98	0.863
full_trailer	3000	402	0.996	0.998	0.995	0.92
heavy_bus	3000	276	0.993	0.995	0.995	0.889
heavy_truck	3000	1228	0.983	0.909	0.959	0.802
light_bus	3000	144	0.991	1	0.995	0.936
light_truck	3000	12641	0.988	0.941	0.977	0.83
medium_bus	3000	1322	0.994	0.981	0.994	0.904
medium_truck	3000	2112	0.99	0.964	0.986	0.86
motorcycle	3000	11905	0.972	0.859	0.922	0.715
passenger_car	3000	21676	0.983	0.955	0.984	0.847
semi_trailer	3000	1023	0.997	0.993	0.995	0.93
van	3000	2231	0.986	0.95	0.982	0.857

```

Speed: 0.3ms preprocess, 25.6ms inference, 0.0ms loss, 1.5ms postprocess per image
Results saved to runs/detect/train

```

ภาพประกอบ 29 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8x weight และชุดข้อมูลยานพาหนะที่สร้างขึ้น



ภาพประกอบ 30 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝนระบบ ด้วย YOLOv8x weight

```


100 epochs completed in 4.464 hours.
Optimizer stripped from runs/detect/train3/weights/last.pt, 52.0MB
Optimizer stripped from runs/detect/train3/weights/best.pt, 52.0MB

Validating runs/detect/train3/weights/best.pt...
Ultralytics YOLOv8.0.55 Python-3.9.16 torch-1.13.1+cu116 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 218 layers, 25846129 parameters, 0 gradients, 78.7 GFLOPs
Class Images Instances Box(P R mAP50 mAP50-95): 100% 94/94 [01:08<00:00, 1.36it/s]
all 3000 54960 0.984 0.935 0.97 0.817
full_trailer 3000 402 0.989 0.99 0.995 0.88
heavy_bus 3000 276 0.982 0.982 0.995 0.847
heavy_truck 3000 1228 0.984 0.849 0.936 0.75
light_bus 3000 144 0.996 1 0.995 0.911
light_truck 3000 12641 0.981 0.907 0.961 0.777
medium_bus 3000 1322 0.988 0.974 0.99 0.869
medium_truck 3000 2112 0.975 0.942 0.981 0.813
motorcycle 3000 11905 0.964 0.808 0.888 0.645
passenger_car 3000 21676 0.978 0.927 0.972 0.798
semi_trailer 3000 1023 0.998 0.985 0.995 0.893
van 3000 2231 0.988 0.92 0.964 0.804

Speed: 0.3ms preprocess, 11.2ms inference, 0.0ms loss, 1.0ms postprocess per image
Results saved to runs/detect/train3

```

ภาพประกอบ 31 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8m weight และชุดข้อมูลยานพาหนะที่สร้างขึ้น



ภาพประกอบ 32 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝนระบบ ด้วย YOLOv8m weight

```


100 epochs completed in 2.937 hours.
Optimizer stripped from runs/detect/train2/weights/last.pt, 6.2MB
Optimizer stripped from runs/detect/train2/weights/best.pt, 6.2MB

Validating runs/detect/train2/weights/best.pt...
Ultralytics YOLOv8.0.55 Python-3.9.16 torch-1.13.1+cu116 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 168 layers, 3007793 parameters, 0 gradients, 8.1 GFLOPs
Class      Images  Instances  Box(P  R      mAP50  mAP50-95): 100% 94/94 [00:44<00:00, 2.11it/s]
  all            3000     54960    0.931  0.786  0.869  0.623
  full_trailer  3000      402     0.941  0.836  0.914  0.696
  heavy_bus     3000      276     0.923  0.827  0.882  0.643
  heavy_truck   3000    1228     0.941  0.634  0.75   0.531
  light_bus     3000      144     0.976  0.86   0.909  0.729
  light_truck   3000   12641    0.916  0.734  0.85   0.565
  medium_bus    3000     1322    0.932  0.876  0.941  0.702
  medium_truck  3000     2112    0.906  0.764  0.866  0.602
  motorcycle    3000   11905    0.894  0.62   0.73   0.42
  passenger_car 3000   21676    0.93   0.789  0.892  0.61
  semi_trailer  3000     1023    0.95   0.919  0.948  0.737
  van           3000     2231    0.931  0.785  0.874  0.619

Speed: 0.2ms preprocess, 2.3ms inference, 0.0ms loss, 1.0ms postprocess per image
Results saved to runs/detect/train2

```

ภาพประกอบ 33 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8n weight และชุดข้อมูลยานพาหนะที่สร้างขึ้น



ภาพประกอบ 34 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝนระบบ ด้วย YOLOv8n weight


3.4 การติดตามยานพาหนะ (Vehicle Tracking)

สำหรับระบบติดตามยานพาหนะที่เลือกใช้ ผู้วิจัยจะใช้ระบบติดตามของ BotSORT และ ByteTrack เป็นระบบติดตามยานพาหนะ โดยจะใช้ระบบติดตามทั้ง 2 ตัวดังกล่าวทำงานร่วมกับระบบตรวจจับยานพาหนะที่ใช้โครงสร้างของ YOLOv8 และ custom weight ที่ได้จากการฝึกฝนระบบด้วยชุดข้อมูลยานพาหนะท้องถิ่นของประเทศไทยที่สร้างขึ้น (Local Dataset) ผลลัพธ์ที่ได้จากระบบตรวจจับและติดตามยานพาหนะที่สร้างขึ้นมานี้ จะได้ ตำแหน่งของยานพาหนะแต่ละคันในภาพ (Bounding Box), ประเภทของยานพาหนะ (Class) และ ค่าระดับความเชื่อมั่นของประเภทยานพาหนะที่ถูกทำนาย (Confidence Score) ซึ่งผลลัพธ์ทั้งหมดนี้ จะถูกเก็บเป็นพารามิเตอร์สำหรับนำไปประยุกต์ใช้ในขั้นตอนการนับยานพาหนะ จำแนกประเภทยานพาหนะและวัดผลการทดสอบระบบต่อไป

3.5 การนับปริมาณจราจรและจำแนกประเภทของยานพาหนะ (Vehicle Counting and Classification)

ในการนับและจำแนกประเภทของยานพาหนะ จะใช้ผลลัพธ์ที่ได้จากขั้นตอนการตรวจจับและติดตามยานพาหนะ นั่นคือ Bounding boxes และ Class Probabilities เป็นพารามิเตอร์สำหรับถอดข้อมูลของยานพาหนะแต่ละคัน ในการนับยานพาหนะ จะใช้วิธีการสร้างเส้นอ้างอิงขึ้น

บนถนนตามแนวกว้างของถนนในภาพ โดยใช้ OpenCV Library และทำการกำหนดจุดอ้างอิงบน Boundary Box ของยานพาหนะแต่ละคันที่ได้จากขั้นตอนการตรวจจับและติดตามยานพาหนะ ก่อนหน้า โดยใช้จุดกึ่งกลางของภาพยานพาหนะในการอ้างอิงตำแหน่งของยานพาหนะ และเพื่อเพิ่มความแม่นยำในการนับยานพาหนะ ผู้วิจัยได้เพิ่มพื้นที่ในการตรวจนับยานพาหนะ โดยทำการกำหนดเส้น offset = 15 ทั้งสองด้านของเส้นอ้างอิงดังแสดงตัวอย่างในภาพประกอบที่ 35 ระบบนับยานพาหนะที่สร้างขึ้นนี้ จะทำการนับยานพาหนะยานพาหนะ เมื่อจุดอ้างอิงของยานพาหนะ เคลื่อนที่ผ่านกับเส้นอ้างอิงที่สร้างขึ้นในแต่ละรูป หรือเมื่อตำแหน่งของจุดอ้างอิงของยานพาหนะ เคลื่อนที่ไปอยู่ในพื้นที่ของเส้นอ้างอิง ระบบจะทำการเก็บข้อมูลพารามิเตอร์ของยานพาหนะคัน นั้นๆ คือข้อมูลประเภทของยานพาหนะและจำนวนสะสมของยานพาหนะประเภทนั้นๆ แล้ว แสดงผลและบันทึกผลในรูปแบบข้อความบนภาพวิดีโอแสดงตัวอย่างในภาพประกอบที่ 35 (แสดงผลลัพธ์บริเวณมุมบนซ้ายของภาพ)



ภาพประกอบ 35 การกำหนดเส้นอ้างอิงในการนับยานพาหนะบนภาพ

3.6 วัดผลการทดลอง

การทดสอบระบบที่สร้างขึ้น ผู้วิจัยได้เลือกใช้ตัวชี้วัดค่าความแม่นยำ (Accuracy) สำหรับ วัดผลระบบนับจำนวนยานพาหนะ โดยจะเป็นการนับยานพาหนะทุกคันที่เคลื่อนที่ผ่านเส้นอ้างอิง รวมทุกประเภท และใช้ตัวชี้วัดค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (Weight Mean Absolute Percentage Error (WMAPE)) สำหรับวัดผลระบบจำแนกประเภทของ ยานพาหนะ เนื่องจากปริมาณจราจรแต่ละประเภทในวิดีโอทดสอบอาจมีความไม่สมดุลกัน จึงต้อง ทำการถ่วงน้ำหนักเพื่อวัดค่าความผิดพลาดโดยรวมของการจำแนกยานพาหนะทุกประเภท และ จะทำการเปรียบเทียบผลลัพธ์จำนวนยานพาหนะแบบแยกประเภทที่ได้จากระบบกับผลของข้อมูล เฉลย (ground truth) ที่ได้จากการถอดข้อมูลโดยใช้คน โดยรูปแบบการแสดงผลการทดลอง ดังกล่าวนี้ จะแสดงผลในรูปแบบตารางในหัวข้อถัดไป


บทที่ 4
การทดลอง และผลลัพธ์ของการวิจัย

4.1 ผลการทดลองเบื้องต้น


4.1.1 ระบบตรวจจับยานพาหนะ

4.1.1.1 การตรวจจับยานพาหนะด้วยหลักการลบข้อมูลจากพื้นหลัง
(Background Subtraction)

ผลการตรวจจับยานพาหนะด้วยหลักการลบข้อมูลจากพื้นหลัง แสดงให้เห็นว่า ในแยกวัตถุที่สนใจ สำหรับข้อมูลภาพที่มีความละเอียดสูง สามารถตรวจจับยานพาหนะได้ ดังแสดงในภาพประกอบที่ 36 แต่ใจการตรวจจับวัตถุจากภาพที่มีความละเอียดต่ำ และวัตถุที่สนใจมีขนาดเล็กในภาพ กลับมีผลการตรวจจับที่ไม่ดีมากนัก ดังแสดงในภาพประกอบที่ 37



ภาพประกอบ 36 ผลการตรวจจับยานพาหนะโดยการใช้ Background Subtraction กับข้อมูลมีความละเอียดสูง



ภาพประกอบ 37 ผลการตรวจจับยานพาหนะโดยการใช้ Background Subtraction กับข้อมูลมีความละเอียดต่ำกว่า

4.1.1.2 การตรวจจับยานพาหนะด้วยหลักการ YOLO

ผลการทดสอบการตรวจจับยานพาหนะจากข้อมูลประเภทวิดีโอ โดยใช้ YOLOv3, YOLOv4, YOLOv5, YOLOv7 และ YOLOv8 แสดงดังภาพประกอบที่ 38 ถึงภาพประกอบที่ 42 ตามลำดับ จะเห็นได้ว่าการทำงานของ YOLO ทุกเวอร์ชันสามารถตรวจจับวัตถุที่เป็นยานพาหนะทุกคันที่อยู่ในภาพได้เป็นอย่างดี โดยสามารถตรวจจับและแยกประเภทของยานพาหนะส่วนใหญ่ได้ค่อนข้างแม่นยำ โดยจะเห็นได้ชัดเจนว่า สามารถทำงานกับข้อมูลที่วัตถุมีขนาดเล็กได้ดีกว่าหลักการลบข้อมูลพื้นหลังมาก แต่จากรูปที่แสดงให้เห็นได้ว่า รถบรรทุก 1 คันที่ถูกตรวจจับได้บริเวณส่วนกลางล่างของภาพ ระบบทำการแสดงการตรวจจับที่ผิดพลาดในบางช่วง กลายเป็นตรวจจับได้วัตถุ 2 วัตถุ แยกเป็นบริเวณส่วนหัวลากและบริเวณตู้คอนเทนเนอร์ออกจากกัน




ภาพประกอบ 38 ผลการตรวจจับยานพาหนะโดยการใช้ YOLOv3



ภาพประกอบ 39 ผลการตรวจจับยานพาหนะจากการใช้ YOLOv4



ภาพประกอบ 40 ผลการตรวจจับยานพาหนะจากการใช้ YOLOV5



ภาพประกอบ 41 ผลการตรวจจับยานพาหนะจากการใช้ YOLOV7




ภาพประกอบ 42 ผลการตรวจจับยานพาหนะจากการใช้ YOLOV8


4.1.3 ระบบนับยานพาหนะ

4.1.3.1 การนับรถยนต์ด้วยหลักการ Background Subtraction

ผลการทดสอบการนับรถโดยใช้หลักการลบข้อมูลจากพื้นหลังกับข้อมูลภาพที่มีความคมชัดสูงกับภาพที่มีความคมชัดต่ำกว่า แสดงดังภาพประกอบที่ 43 และภาพประกอบที่ 44 ตามลำดับ จะเห็นได้ว่าประสิทธิภาพของการนับยานพาหนะจะขึ้นอยู่กับประสิทธิภาพของการตรวจจับโดยตรง ทำให้การทำงานกับข้อมูลภาพที่มีความละเอียดสูง สามารถนับรถได้แม่นยำมากกว่า ข้อมูลภาพที่มีความละเอียดต่ำกว่าและยานพาหนะมีขนาดเล็กกว่า เนื่องจากระบบตรวจจับทำงานได้ไม่ดีพอ เกิดปัญหาการนับซ้ำหรือนับขาดขึ้นอยู่กับบ่อยครั้ง



ภาพประกอบ 43 แสดงผลการนับจำนวนยานพาหนะโดยใช้ Background Subtraction เป็นอัลกอริทึมในการตรวจจับวัตถุ



ภาพประกอบ 44 แสดงผลการนับจำนวนยานพาหนะโดยใช้ Background Subtraction เป็นอัลกอริทึมในการตรวจจับวัตถุ

4.1.3.2 การนับรถยนต์ด้วยหลักการ YOLO

ระบบนับยานพาหนะที่ทำการทดสอบ แสดงผลการทดสอบดัง **ภาพประกอบที่ 45** ถึง **ภาพประกอบที่ 49** จากการทดสอบนับจำนวนยานพาหนะในหลายมุมมองต่างกัน โดยใช้ YOLO ในการตรวจจับยานพาหนะ และทำการนับจำนวนตามจำนวนของยานพาหนะที่ถูกตรวจจับได้ จากผลการทดสอบพบว่า แม้จะเป็นข้อมูลภาพในมุมมองที่สามารถมองเห็นยานพาหนะได้ค่อนข้างชัดเจน แต่ระบบมีการตรวจจับยานพาหนะคันเดิมซ้ำเกิดขึ้นบ่อยครั้ง จึงเกิดการนับจำนวนซ้ำมากเกินไปกว่าจำนวนยานพาหนะที่เกิดขึ้นจริงมาก ดังแสดงใน **ภาพประกอบที่ 45** นอกจากนี้ พบว่าสำหรับบางข้อมูล การนับยานพาหนะทำได้ผิดพลาดเนื่องจากตรวจจับภาพที่ไม่ใช่ยานพาหนะเป็นยานพาหนะ ดังแสดงใน **ภาพประกอบที่ 46** หรือผิดพลาดเนื่องจากตรวจจับภาพซ้ำเนื่องจากการสภาพการจราจรที่ติดขัด หรือตำแหน่งมุมมองที่เก็บสำรวจ ทำให้เกิดการบดบังกันของยานพาหนะเยอะมาก ดังแสดงใน **ภาพประกอบที่ 47** และ **ภาพประกอบที่ 48** หรืออีกกรณีคือ นับยานพาหนะผิดพลาดจากข้อมูลยานพาหนะที่คุณภาพของภาพไม่สูงนักและมีขนาดยานพาหนะเล็กมาก ๆ ในข้อมูลภาพ ส่งผลให้การระบบไม่สามารถตรวจจับยานพาหนะในภาพได้อย่างครอบคลุมดังแสดงใน **ภาพประกอบที่ 49**

ดังนั้น ในการนำไปใช้งานจริงสำหรับนับจำนวนยานพาหนะ จึงควรมีการควบคุมมุมมองที่เก็บข้อมูลการจราจรให้สามารถมองเห็นยานพาหนะให้ชัดเจนที่สุด และควรมีการกำหนดพื้นที่ที่สนใจ (ROI) ให้ชัดเจน เพื่อเพิ่มความแม่นยำในการนับจำนวนยานพาหนะที่วิ่งอยู่บนถนนแบบแยกสายทิศทางที่สนใจได้ และใช้วิธีการนับโดยกำหนดเส้นอ้างอิงในการนับจำนวนยานพาหนะ (Reference Line) ในตำแหน่งที่ตรวจจับวัตถุได้อย่างชัดเจน จะช่วยให้ระบบการนับยานพาหนะทำงานได้ดีขึ้น



ภาพประกอบ 45 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ
วัตถุ



ภาพประกอบ 46 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ
วัตถุ




ภาพประกอบ 47 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ
วัตถุ



ภาพประกอบ 48 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ

วัตถุ



ภาพประกอบ 49 แสดงผลการนับจำนวนยานพาหนะโดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ

วัตถุ

4.1.4 ระบบแยกประเภทยานพาหนะ

4.1.4.1 ระบบแยกประเภทยานพาหนะ โดยใช้ Background Subtraction เป็นอัลกอริทึมในการตรวจจับวัตถุ

การใช้ Background Subtraction ในการตรวจจับยานพาหนะที่แสดงดังรูปประกอบที่ 35 และ รูปประกอบที่ 36 จะเห็นได้ว่า ระบบทำการตรวจจับยานพาหนะโดยแยกวัตถุที่สนใจกับวัตถุที่เป็นพื้นหลัง ได้ผลลัพธ์เป็นภาพขาวดำ (Binary Image) ทำให้ยากต่อการนำไปใช้จำแนกประเภทของยานพาหนะ หากจะนำไปใช้เพื่อจำแนกประเภทของยานพาหนะจริง อาจสามารถทำได้จากการใช้ขนาดความกว้างหรือความยาวของยานพาหนะเป็นเกณฑ์ในการจำแนกประเภท

และต้องทำการ ปรับเทียบขนาดของภาพให้สามารถกำหนดขนาดตามโลกความเป็นจริงได้ (Road Calibration) อีกทั้ง การทำ Background Subtraction อาจไม่สามารถระบุขนาดของยานพาหนะได้อย่างแม่นยำ จึงไม่เป็นที่นิยมในนำไปใช้แยกประเภทของยานพาหนะมากนัก

4.1.4.2 ระบบแยกประเภทยานพาหนะ โดยใช้ YOLO เป็นอัลกอริทึมในการตรวจจับวัตถุ

สำหรับผลการแยกประเภทที่ใช้ YOLO เป็นอัลกอริทึมในการตรวจจับ จะเห็นได้จากภาพประกอบที่ 38 ถึง ภาพประกอบที่ 42 ว่าระบบสามารถแยกประเภทของยานพาหนะได้ทันทีหลังจากตรวจจับโดยใช้ อัลกอริทึม YOLO และมีความแม่นยำสูง แต่มีข้อจำกัดคือสามารถแยกได้เพียง 4 ประเภททั่วไปเท่านั้น คือ รถยนต์นั่งส่วนบุคคล รถจักรยานยนต์ รถบรรทุก และรถโดยสารประจำทาง ดังนั้น เพื่อที่จะนำระบบไปใช้งานจริงสำหรับเก็บข้อมูลจำนวนยานพาหนะแบบแยกประเภท ให้มีความเหมาะสมกับการจราจรในประเทศไทย สามารถถอดข้อมูลเก็บข้อมูลยานพาหนะแบบแยกประเภทที่ละเอียดมากกว่านี้ จึงต้องสร้างชุดข้อมูลยานพาหนะที่เป็นยานพาหนะท้องถิ่นในประเทศไทย เพื่อใช้ในการฝึกฝนระบบให้สามารถจำแนกประเภทได้อย่างเหมาะสมต่อไป

4.2 ผลการทดลองของระบบที่นำเสนอ

หลังจากการลองเบื้องต้นแล้ว ผู้วิจัยจึงได้ทำการทดสอบการทำงานของระบบตรวจจับและจำแนกประเภทของยานพาหนะที่นำเสนอ โดยเป็นระบบตรวจจับยานพาหนะที่ถูกฝึกฝนด้วยชุดข้อมูลยานพาหนะในประเทศไทยทั้ง 11 ประเภทที่สร้างขึ้น โดยมี weight ที่ใช้ในการฝึกฝนของ YOLOv8 ที่แตกต่างกัน ของ YOLOv8n, YOLOv8m และ YOLOv8x และทำงานร่วมกับระบบติดตามทั้ง 2 ตัว (ByteTrack และ BotSORT) โดยทำการทดสอบเบื้องต้นเพื่อหาการจับคู่กันของระบบตรวจจับยานพาหนะและระบบติดตามยานพาหนะที่ให้ผลลัพธ์ที่ดีที่สุดกับข้อมูลวิดีโอที่ 1 และในการทดลองนี้มีสมมติฐานว่า ประสิทธิภาพการทำงานของ weight ที่เลือกใช้ จะมีความสอดคล้องกับผลลัพธ์ที่ได้จากการฝึกฝนระบบ กล่าวคือ ระบบที่เลือกใช้ YOLOv8x จะให้ความแม่นยำในการนับยานพาหนะมากที่สุด จากตารางที่ 5 และ ตารางที่ 6 ตามลำดับ


ตาราง 5 แสดงผลการเปรียบเทียบการทำงานของ YOLOv8n, YOLOv8m และ YOLOv8x กับระบบติดตามวัตถุ ByteTrack

Class	Ground Truth	YOLOv8n+ByteTrack		YOLOv8m+ByteTrack			YOLOv8x+ByteTrack			
		Counting	Counting	Acc. Rate (%)	Absolute Percentage Error (%)	Counting	Acc. Rate (%)	Absolute Percentage Error (%)	Counting	Acc. Rate (%)
Motorcycle	28	4	-	85.71	16	-	42.86	16	-	42.86
Passenger Car	376	364	-	3.19	433	-	15.16	395	-	5.05
Van	31	51	-	64.52	63	-	103.23	40	-	29.03
Light Truck	247	184	-	25.51	192	-	22.27	224	-	9.31
Medium Truck	37	6	-	83.93	11	-	70.54	10	-	73.21
Heavy Truck	16	9	-	43.75	2	-	87.50	4	-	75.00
Light Bus	2	0	-	100.00	0	-	100.00	0	-	100.00
Medium Bus	0	0	-	-	0	-	-	0	-	-
Heavy Bus	0	0	-	-	0	-	-	0	-	-
Semi-Trailer	39	4	-	89.74	24	-	38.46	27	-	30.77
Full Trailer	4	0	-	100.00	1	-	75.00	0	-	100.00
Total	780	622	79.71	-	742	95.09	-	716	91.76	-
WMAPE	-	-	-	25.42	-	-	27.72	-	-	15.42

ตาราง 6 แสดงผลการเปรียบเทียบการทำงานของ YOLOv8n, YOLOv8m และ YOLOv8x กับระบบติดตามวัตถุ BotSORT

Class	Ground Truth	YOLOv8n+ BotSORT		YOLOv8m+ BotSORT			YOLOv8x+BotSORT			
		Counting	Counting	Acc. Rate (%)	Absolute Percentage Error (%)	Counting	Acc. Rate (%)	Absolute Percentage Error (%)	Counting	Acc. Rate (%)
Motorcycle	28	13	-	53.57	24	-	14.29	26	-	7.14
Passenger Car	376	378	-	0.53	502	-	33.51	465	-	23.67
Van	31	48	-	54.84	53	-	70.97	40	-	29.03
Light Truck	247	177	-	28.34	144	-	41.70	171	-	30.77
Medium Truck	37	3	-	91.96	14	-	62.50	12	-	67.86
Heavy Truck	16	7	-	56.25	1	-	93.75	3	-	81.25
Light Bus	2	0	-	100.00	0	-	100.00	0	-	100.00
Medium Bus	0	0	-	-	0	-	-	0	-	-
Heavy Bus	0	0	-	-	0	-	-	0	-	-
Semi-Trailer	39	5	-	87.18	27	-	30.77	27	-	30.77
Full Trailer	4	0	-	100.00	0	-	100.00	0	-	100.00
Total	780	631	80.86	-	765	98.04	-	744	95.34	-
WMAPE	-	-	-	24.01	-	-	39.90	-	-	29.77

จะเห็นได้ว่าการทำงานของ YOLOv8x และ YOLOv8m มีความแม่นยำที่สูงใกล้เคียงกัน โดย YOLOv8m อาจมีความแม่นยำในการตรวจจับมากกว่า YOLOv8x อยู่เล็กน้อย แต่หากพิจารณาถึงความแม่นยำในการจำแนกประเภท จะเห็นได้อย่างชัดเจนว่า YOLOv8x มีประสิทธิภาพที่สูงกว่า ทั้งการทำงานร่วมกับ ByteTrack และ BotSORT โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) น้อยกว่า YOLOv8m อย่างเห็นได้ชัด ดังนั้นสำหรับการพิจารณาการทำงานของระบบกับข้อมูลวิดีโอในสภาพการณ์อื่นๆต่อไปนั้น ทางผู้วิจัยจะเลือกใช้ YOLOv8x เป็น weight ในการทำงานร่วมกับระบบติดตามวัตถุทั้งสองตัว และแสดงออกมาในรูปแบบตารางเปรียบเทียบการทำงานของแบบจำลองทั้ง 2 คือ YOLOv8x+ByteTrack และ YOLOv8x+BotSORT โดยภาพตัวอย่างของผลลัพธ์ที่ได้แสดงดังภาพประกอบที่ 50



ภาพประกอบ 50 ตัวอย่างผลลัพธ์ที่ได้จากการทำงานของระบบนับและจำแนกประเภทยานพาหนะที่นำเสนอ

จะเห็นได้ว่า ระบบการตรวจจับยานพาหนะที่ผ่านการฝึกฝนด้วยชุดข้อมูลของยานพาหนะ ทั้ง 11 ประเภทที่สร้างขึ้นมาช่วยให้ระบบสามารถตรวจจับยานพาหนะได้อย่างหลากหลายประเภท ตามต้องการ และผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจรในสภาพการณ์ต่างๆ แสดงดังตารางที่ 7 ถึงตารางที่ 13

ตาราง 7 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างแยบเยอะ มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)
Motorcycle	28	16	-	42.86	-	26	-	7.14	-
Passenger Car	376	395	-	5.05	-	465	-	23.67	-
Van	31	40	-	29.03	-	40	-	29.03	-
Light Truck	247	224	-	9.31	-	171	-	30.77	-
Medium Truck	37	10	-	73.21	-	12	-	67.86	-
Heavy Truck	16	4	-	75.00	-	3	-	81.25	-
Light Bus	2	0	-	100.00	-	0	-	100.00	-
Medium Bus	0	0	-	-	-	0	-	-	-
Heavy Bus	0	0	-	-	-	0	-	-	-
Semi-Trailer	39	27	-	30.77	-	27	-	30.77	-
Full Trailer	4	0	-	100.00	-	0	-	100.00	-
Total	780	716	91.76	-	15.42	744	95.34	-	29.77

ตาราง 8 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางคืน (จุดสำรวจตำแหน่งเดียวกันกับวิดีโอที่ 1) มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)
Motorcycle	38	2	-	94.74	-	0	-	100.00	-
Passenger Car	679	503	-	25.92	-	538	-	20.77	-
Van	72	2	-	97.22	-	2	-	97.22	-
Light Truck	123	97	-	21.14	-	71	-	42.28	-
Medium Truck	3	0	-	100.00	-	0	-	100.00	-
Heavy Truck	5	0	-	100.00	-	0	-	100.00	-
Light Bus	0	0	-	-	-	0	-	-	-
Medium Bus	1	4	-	300.00	-	5	-	400.00	-
Heavy Bus	5	0	-	100.00	-	0	-	100.00	-
Semi-Trailer	2	0	-	100.00	-	0	-	100.00	-
Full Trailer	0	0	-	-	-	0	-	-	-
Total	928	608	65.52	-	35.13	616	66.38	-	34.48

ตาราง 9 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ
 ทิศทางมุ่งออกจากจุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ การจราจรใช้ความเร็วในการขับ
 ที่สูงมีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)
Motorcycle	67	25	-	62.69	-	65	-	2.99	-
Passenger Car	449	455	-	1.34	-	486	-	8.24	-
Van	36	25	-	30.56	-	26	-	27.78	-
Light Truck	279	275	-	1.43	-	331	-	18.64	-
Medium Truck	17	6	-	64.71	-	4	-	76.47	-
Heavy Truck	5	4	-	20.00	-	1	-	80.00	-
Light Bus	0	0	-	-	-	0	-	-	-
Medium Bus	7	4	-	42.86	-	5	-	28.57	-
Heavy Bus	2	2	-	0.00	-	1	-	50.00	-
Semi-Trailer	20	16	-	20.00	-	16	-	20.00	-
Full Trailer	0	0	-	-	-	0	-	-	-
Total	882	812	92.06	-	9.30	935	94.33	-	14.17

ตาราง 10 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน บริเวณพื้นถนนมีเงาตกกระทบไม่สม่ำเสมอ มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)
Motorcycle	196	160	-	18.37	-	169	-	13.78	-
Passenger Car	245	333	-	35.92	-	349	-	42.45	-
Van	19	14	-	26.32	-	14	-	26.32	-
Light Truck	153	61	-	60.13	-	51	-	66.67	-
Medium Truck	7	3	-	57.14	-	2	-	71.43	-
Heavy Truck	4	0	-	100.00	-	0	-	100.00	-
Light Bus	2	0	-	100.00	-	0	-	100.00	-
Medium Bus	14	16	-	14.29	-	13	-	7.14	-
Heavy Bus	2	0	-	100.00	-	0	-	100.00	-
Semi-Trailer	3	3	-	0.00	-	3	-	0.00	-
Full Trailer	0	0	-	-	-	0	-	-	-
Total	645	590	91.47	-	36.43	601	93.18	-	39.07

ตาราง 11 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงน้อย มองเห็นยานพาหนะได้ชัดเจน มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)
Motorcycle	165	164	-	0.61	-	164	-	0.61	-
Passenger Car	336	344	-	2.38	-	282	-	16.07	-
Van	25	21	-	16.00	-	5	-	80.00	-
Light Truck	178	205	-	15.17	-	222	-	24.72	-
Medium Truck	6	12	-	100.00	-	18	-	200.00	-
Heavy Truck	6	0	-	100.00	-	0	-	100.00	-
Light Bus	2	0	-	100.00	-	0	-	100.00	-
Medium Bus	4	1	-	75.00	-	6	-	50.00	-
Heavy Bus	0	0	-	-	-	0	-	-	-
Semi-Trailer	36	18	-	50.00	-	16	-	55.56	-
Full Trailer	3	0	-	100.00	-	0	-	100.00	-
Total	761	765	99.48	-	10.25	713	93.69	-	21.55

ตาราง 12 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรค่อนข้างติดขัดเล็กน้อยจากการหยุดรอสัญญาณไฟจราจร ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน มีความละเอียดของภาพระดับ Full HD (1080p)

Class	Ground Truth		YOLOv8x+ByteTrack			YOLOv8x+BotSORT			
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	WMAPE (%)	Counting	Accuracy (%)	MAPE (%)	Absolute Percentage Error (%)
Motorcycle	149	133	-	10.74	-	139	-	6.71	-
Passenger Car	111	105	-	5.41	-	121	-	9.01	-
Van	6	5	-	16.67	-	3	-	50.00	-
Light Truck	22	29	-	31.82	-	20	-	9.09	-
Medium Truck	0	0	-	-	-	0	-	-	-
Heavy Truck	0	0	-	-	-	0	-	-	-
Light Bus	0	0	-	-	-	0	-	-	-
Medium Bus	3	3	-	0.00	-	4	-	33.33	-
Heavy Bus	0	0	-	-	-	0	-	-	-
Semi-Trailer	0	0	-	-	-	0	-	-	-
Full Trailer	0	0	-	-	-	0	-	-	-
Total	291	275	94.50	-	10.31	287	98.63	-	8.93

ตาราง 13 ผลสรุปผลการเปรียบเทียบการทำงานของระบบของการจราจรในทุกๆสภาพการณ์ โดยแสดงในรูปแบบความแม่นยำในการนับยานพาหนะทั้งหมด และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ในการจำแนกประเภทของยานพาหนะทุกประเภท

Evaluation Metrics	Situation	YOLOv8x	YOLOv8x
		+	+
		ByteTrack	BotSORT
Accuracy of Vehicle Counting (%)	Incoming traffic/ Bright Light/ AM period/ HD 720p	91.76	95.34
	Incoming traffic/ PM period/ HD 720p	65.52	66.38
	Outgoing traffic / AM period/ HD 720p	92.06	94.33
	Incoming traffic with road shadow/ AM period/ HD 720p	91.47	93.18
	Incoming traffic/ vehicles are seen more clearly/ AM period/ HD 720p	99.48	93.69
	Incoming traffic/ congestion/ AM period/ Full HD 1080p	94.50	98.63
	Average	89.13	90.26
Weight Mean Absolute Percentage Error (WMAPE) (%)	Incoming traffic/ Bright Light/ AM period/ HD 720p	15.42	29.77
	Incoming traffic/ PM period/ HD 720p	35.13	34.48
	Outgoing traffic / AM period/ HD 720p	9.30	14.17
	Incoming traffic with road shadow/ AM period/ HD 720p	36.43	39.07
	Incoming traffic/ vehicles are seen more clearly/ AM period/ HD 720p	10.25	21.55
	Incoming traffic/ congestion/ AM period/ Full HD 1080p	10.31	8.93
	Average	19.47	24.66

จากผลการทดลองทั้งหมดและผลการเปรียบเทียบการทำงานของทั้ง 2 แบบจำลองที่นำเสนอในแต่ละสภาพการณ์ดังแสดงในตารางข้างต้น พบว่าโดยภาพรวม แบบจำลองที่นำเสนอสามารถตรวจจับ ติดตาม และนับจำนวนยานพาหนะได้ค่อนข้างดี แต่มีผลการจำแนกประเภทของยานพาหนะโดยภาพรวมทุกประเภททุกสภาพการณ์ที่อาจจะไม่ดีนัก โดยแบบจำลองที่ให้ผลความแม่นยำในการนับจำนวนยานพาหนะสูงที่สุดคือ YOLOv8x + ByteTrack ที่ทำการทดสอบกับข้อมูลวิดีโอชุดที่ 5 ที่มีการจราจรทิศทางมุ่งหน้าเข้าสู่จุดบันทึกข้อมูล ในช่วงเวลากลางวัน สภาพการจราจรปกติ มีแสงน้อย สามารถมองเห็นยานพาหนะได้ชัดเจน มีความละเอียดของภาพระดับ HD (720p) โดยมีค่าความแม่นยำในการนับยานพาหนะทั้งหมดสูงที่สุดอยู่ที่ประมาณ 99 เปอร์เซ็นต์ ซึ่งผลการนับยานพาหนะดังกล่าวเป็นผลการนับยานพาหนะที่โดยรวมทุกประเภทเท่านั้น ไม่ได้พิจารณาถึงความแม่นยำในการจำแนกประเภท และแบบจำลองที่สามารถจำแนกประเภทยานพาหนะที่แม่นยำที่สุด คือแบบจำลอง YOLOv8x + BotSORT ที่ทำการทดสอบกับข้อมูลวิดีโอชุดที่ 6 การจราจรทิศทางมุ่งหน้าเข้าสู่จุดบันทึกข้อมูล ในช่วงเวลากลางวัน สภาพ

จราจรเคลื่อนตัวไปอย่างช้าๆ มีความละเอียดของภาพสูงที่สุดระดับ Full HD (1080p) โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) ที่น้อยที่สุดอยู่ที่ประมาณ 9 เปอร์เซ็นต์ ส่วนแบบจำลองการทำงานที่มีประสิทธิภาพแ่ที่สุดในการนับปริมาณยานพาหนะในการทดลองครั้งนี้คือ การใช้ YOLOv8x + BotSORT ที่ทำการทดสอบกับข้อมูลวิดีโอชุดที่ 2 การจราจรทิศทางมุ่งหน้าเข้าสู่จุดบันทึกข้อมูล ในช่วงเวลากลางคืน สภาพจราจรล่องตัว มีความละเอียดของภาพอยู่ที่ระดับ HD (720p) โดยมีค่าความแม่นยำในการนับยานพาหนะอยู่ที่น้อยที่สุด มีค่าประมาณ 66 เปอร์เซ็นต์ และแบบจำลองที่จำแนกประเภทยานพาหนะได้ผิดพลาดมากที่สุดคือ ใช้ YOLOv8x + BotSORT ที่ทำการทดสอบกับข้อมูลวิดีโอชุดที่ 4 โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) ที่มากที่สุดอยู่ที่ประมาณ 39 เปอร์เซ็นต์

จากผลการเปรียบเทียบการทดลองของการใช้ YOLOv8x+ByteTrack และ YOLOv8x+BotSORT จะเห็นได้ว่าประสิทธิภาพในการนับจำนวนรวมของยานพาหนะของ YOLOv8x+BotSORT ทำงานได้ดีกว่าเพียงเล็กน้อย โดยมีค่าความแม่นยำในการนับจำนวนยานพาหนะเฉลี่ยรวมทุกสภาพการณ์อยู่ที่ประมาณ 90 เปอร์เซ็นต์ มากกว่า YOLOv8x+ByteTrack เพียงประมาณ 1 เปอร์เซ็นต์ ที่มีค่าความแม่นยำในการนับจำนวนยานพาหนะเฉลี่ยรวมทุกสภาพการณ์อยู่ที่ประมาณ 89 เปอร์เซ็นต์ แต่ในการจำแนกประเภทยานพาหนะ พบว่า โดยภาพรวมแล้ว YOLOv8x+ByteTrack สามารถจำแนกประเภทยานพาหนะได้แม่นยำกว่าอย่างเห็นได้ชัด โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) เฉลี่ยรวมทุกสภาพการณ์อยู่ที่ประมาณ 19 เปอร์เซ็นต์ มีค่าน้อยกว่า YOLOv8x+ BotSORT ประมาณ 6 เปอร์เซ็นต์ ที่มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) เฉลี่ยรวมทุกสภาพการณ์อยู่ที่ประมาณ 25 เปอร์เซ็นต์

บทที่ 5

การสรุปผลการวิจัย การอภิปรายผล และข้อเสนอแนะของการวิจัย.

งานวิจัยนี้นำเสนอระบบตรวจจับและจำแนกประเภทของยานพาหนะ บนถนนเขตในเมืองของประเทศไทย ที่ใช้หลักการประสาทเทียมแบบคอนโวลูชันของ YOLOv8 เป็นอัลกอริทึมในการตรวจจับยานพาหนะ โดยใช้หลักการการเรียนรู้ของเครื่องในการฝึกฝนระบบตรวจจับยานพาหนะด้วยชุดข้อมูลยานพาหนะท้องถิ่นที่สร้างขึ้นมาจากข้อมูลการจราจรบนถนนในเมืองของประเทศไทยโดยใช้ Roboflow เป็นเครื่องมือในการสร้าง ให้สามารถตรวจจับและทำนายประเภทของยานพาหนะได้อย่างครอบคลุมประเภทยานพาหนะที่ใช้อยู่ในประเทศไทย โดยใช้ระบบตรวจจับยานพาหนะดังกล่าวที่ผ่านการฝึกฝนมาแล้ว ให้ทำร่วมกับระบบติดตามวัตถุที่เลือกใช้ 2 ระบบได้แก่ ByteTrack และ BotSORT เป็นอัลกอริทึมในการติดตามยานพาหนะ เพื่อเปรียบเทียบแบบจำลองของระบบตรวจจับและติดตามยานพาหนะที่มีแนวโน้มจะให้ผลลัพธ์ที่ดีที่สุด จากนั้นจึงประยุกต์ใช้วิธีการนับยานพาหนะโดยการสร้างเส้นอ้างอิงด้วย OpenCV ในการนับยานพาหนะที่เคลื่อนที่ผ่าน โดยจากการทดสอบแบบจำลองที่นำเสนอกับภาพวิดีโอที่มีความละเอียดของภาพสูงตั้งแต่ระดับ HD (720p) ขึ้นไป ในสภาพการณ์ที่แตกต่างกัน 6 วิดีโอนั้น พบว่าระบบที่นำเสนอทั้ง 2 แบบจำลอง สามารถทำการนับจำนวนรวมของยานพาหนะในหลายๆสภาพการณ์ได้ผลที่ค่อนข้างดี มีความแม่นยำสูง โดยเฉพาะการนับปริมาณจราจรในช่วงเวลากลางวัน แต่ยังคงมีข้อบกพร่องในการทำนายประเภทของยานพาหนะในภาพรวมได้ไม่แม่นยำมากนัก อย่างไรก็ตาม ระบบที่นำเสนอยังคงมีความสามารถในการจำแนกประเภทของยานพาหนะบางประเภทคือ รถจักรยานยนต์, รถยนต์นั่งส่วนบุคคลไม่เกิน 7 ที่นั่ง และ รถบรรทุกขนาดเล็ก 4 ล้อ ที่มีผลการจำแนกที่ค่อนข้างดีอย่างเห็นได้ชัดในหลายๆสภาพการณ์

จากผลการทดลองและผลการเปรียบเทียบการทำงานของระบบนับและจำแนกประเภทของยานพาหนะกับข้อมูลวิดีโอการจราจรในสภาพการณ์ต่างๆข้างต้น พบว่าทั้งระบบของ YOLOv8x+ByteTrack และ YOLOv8x+BotSORT สามารถนับจำนวนรวมของยานพาหนะได้โดยมีความแม่นยำที่ค่อนข้างสูงและมีประสิทธิภาพที่ใกล้เคียงกัน โดยผลการทดสอบกับการจราจรในสภาพการณ์ส่วนใหญ่ (ไม่รวมวิดีโอที่ 2 ที่มีสภาพการณ์ในช่วงเวลากลางคืน) มีความแม่นยำในการนับจำนวนยานพาหนะทั้งหมดอยู่ในช่วงประมาณ 91 – 99 เปอร์เซ็นต์ ทั้งภาพวิดีโอที่ยานพาหนะวิ่งเข้าสู่และออกจากตำแหน่งบันทึกภาพ (ทำงานได้ค่อนข้างดีทั้งกับรูปถ่ายด้านหน้าและด้านหลังของยานพาหนะ), สภาพการจราจรที่มีเงาตกกระทบบนพื้นผิวถนนแบบไม่สม่ำเสมอ และถนนที่การจราจรมีการสัญจรไปอย่างรวดเร็วหรือเคลื่อนตัวไปอย่างล่าช้า ระบบที่นำเสนอ

สามารถตรวจจับ ติดตาม และนับจำนวนยานพาหนะได้เป็นอย่างดี มีเพียงผลลัพธ์ที่ได้ภาพวิดีโอที่ 2 ที่มีค่าแม่นยำในการนับที่ค่อนข้างน้อยกว่าวิดีโออื่นๆอย่างเห็นได้ชัด โดยมีค่าความแม่นยำอยู่ที่ประมาณ 66 เปอร์เซ็นต์ ในทั้งสองแบบจำลองที่เลือกใช้ เนื่องจากเป็นสภาพการจราจรที่บันทึกในช่วงเวลากลางคืน ส่งผลให้ยานพาหนะในภาพมีความคมชัดลดลงไปจากตอนกลางวันเป็นอย่างมาก และเนื่องจากในช่วงเวลากลางคืนนั้น ยานพาหนะทุกคันจำเป็นต้องเปิดไฟหน้ารถระหว่างการขับขี่ เมื่อบันทึกด้วยกล้องที่มีความคมชัดระดับ HD (720p) ทำแสงของไฟหน้ายานพาหนะทุกคันกระจายออกมาบดบังรูปลักษณะของยานพาหนะซ้ำไปกว่าเดิม ซึ่งเป็นอุปสรรคและความท้าทายต่อการทำงานของระบบในการตรวจจับยานพาหนะมาก อีกทั้งรูปภาพส่วนใหญ่ของชุดข้อมูลที่สร้างขึ้นเพื่อใช้ในการฝึกฝนข้อมูลสำหรับการทดลองครั้งนี้ล้วนเป็นภาพของยานพาหนะในช่วงเวลากลางวัน มองเห็นได้ชัดเจน ทำให้ระบบที่นำเสนอไม่สามารถตรวจจับยานพาหนะของการจราจรในช่วงเวลากลางคืนในภาพได้อย่างครบถ้วน ถึงแม้จะมีการเพิ่มความหลากหลายของชุดข้อมูลโดยการปรับแสงสว่างดังกล่าวไปในบทที่ 3 ข้างต้นบ้างแล้ว แต่ก็ยังไม่ดีพอให้ระบบสามารถตรวจจับยานพาหนะในสภาพการจราจรที่มีแสงน้อยได้ดีนัก ส่งผลให้ระบบนับยานพาหนะทำการนับยานพาหนะจากภาพวิดีโอที่มีแสงน้อยได้ไม่ดีเท่าที่ควร

เมื่อพิจารณาผลการจำแนกประเภทของยานพาหนะ พบว่าระบบที่ฝึกฝน YOLOv8 ด้วยชุดข้อมูลยานพาหนะท้องถิ่นที่สร้างขึ้นเองจากข้อมูลรูปภาพตั้งต้นจำนวนเพียง 250 รูปภาพดังที่นำเสนอไปนั้น ยังคงมีผลการจำแนกประเภทของยานพาหนะโดยภาพรวมที่ไม่ดีนัก โดยผลการจำแนกของแบบจำลอง YOLOv8x+ByteTrack และ YOLOv8x+BotSORT มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) ในการจำแนกประเภทของยานพาหนะทุกประเภทอยู่ที่ประมาณ 19 เปอร์เซ็นต์ และ 25 เปอร์เซ็นต์ตามลำดับ ซึ่งถือว่าคุณค่าค่อนข้างสูงเกินกว่าจะยอมรับและนำไปใช้งานจริงสำหรับเก็บข้อมูลประเภทของยานพาหนะทุกประเภทได้ อย่างไรก็ตามก็ดีผลการทดสอบของระบบที่นำเสนอยังแสดงให้เห็นว่า แม้ระบบที่นำเสนอจะมีผลการจำแนกประเภทของยานพาหนะโดยเฉลี่ยทุกประเภทที่ไม่ดีนัก แต่สามารถทำงานได้ดีในการจำแนกยานพาหนะบางประเภทที่มีความแม่นยำสูงกว่าการจำแนกยานพาหนะประเภทอื่นๆ อย่างเห็นได้ชัด และมีผลการจำแนกในบางสภาพการจราจรอยู่ในระดับที่สามารถยอมรับได้ นั่นคือยานพาหนะประเภท รถจักรยานยนต์, รถยนต์นั่งส่วนบุคคลไม่เกิน 7 ที่นั่ง และ รถบรรทุกขนาดเล็ก 4 ล้อ ที่มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ที่ค่อนข้างต่ำ เมื่อเปรียบเทียบกับประเภทอื่นๆ นั้นเป็นเพราะภาพที่ใช้ในการสร้างชุดข้อมูลและวิดีโอที่ใช้ทดสอบเป็นภาพของการจราจรโดยปกติบนท้องถนน ซึ่งการเดินทางโดยทั่วไปในชีวิตประจำวันของผู้คนในเขต

เมือง ของประเทศไทยนั้น ล้วนแต่ใช้งานยานพาหนะส่วนตัวทั้ง 3 ประเภทดังกล่าวมากกว่า ยานพาหนะประเภทอื่นๆที่เหลือ จึงทำให้ทั้งชุดข้อมูลรูปภาพยานพาหนะท้องถิ่นที่สร้างขึ้นเพื่อใช้ในการฝึกฝนระบบรู้จำ รวมทั้งข้อมูลวิดีโอที่ใช้ในการทดสอบมีจำนวนยานพาหนะทั้ง 3 ประเภทนี้ มากเป็นพิเศษเมื่อเทียบกับยานพาหนะประเภทอื่นๆ ส่งผลให้ระบบที่นำเสนอนี้ สามารถทำงานได้ดีและแสดงผลเปรียบเทียบได้อย่างเด่นชัดกับยานพาหนะทั้ง 3 ประเภทนี้ และมีผลลัพท์ในการ จำแนกประเภทของยานพาหนะที่ความแม่นยำประเภทอื่นๆในหลายๆสภาพการณ์ อีกประเด็นที่ ส่งผลให้การทำงานของยานพาหนะประเภทอื่นๆมีผลการจำแนกที่ค่อนข้างต่ำนั้น อาจเป็นเพราะ เนื่องจากยานพาหนะบางประเภทมีลักษณะภายนอกที่คล้ายคลึงกันในบางมุม รวมทั้งขนาดและสี ของยานพาหนะ ยกตัวอย่างเช่น ยานพาหนะประเภทรถบรรทุกขนาดกลางและขนาดใหญ่ หรือ รถ โดยขนาดกลางและขนาดใหญ่ ประกอบกับการมีภาพยานพาหนะประเภทอื่นๆในชุดข้อมูลที่ใช้ ในการฝึกฝนที่มีจำนวนและความหลากหลายที่ไม่มากพอ จึงทำให้ระบบทำนายผลประเภทของ ยานพาหนะประเภทอื่นๆที่เหลือน้อยลงและเคลื่อนไปมาก และในการจำแนกประเภทของยานพาหนะใน สภาพการณ์จริงที่มีแสงสว่างน้อย ผลการทดสอบก็แสดงให้เห็นว่า ระบบที่นำเสนอยังคงมี ประสิทธิภาพในการทำนายประเภทยานพาหนะในสภาพการณ์ตอนกลางคืนที่ค่อนข้างต่ำ เช่นเดียวกันกับการนับปริมาณจราจรในช่วงเวลากลางคืน โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความ ผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) สูงกว่าผลการทดสอบของวิดีโอในสภาพการณ์อื่นๆ อย่างเห็นได้ชัด อยู่ที่ประมาณ 35 เปอร์เซ็นต์ เนื่องจากรูปภาพที่อยู่ในชุดข้อมูลที่ใช้ฝึกฝนระบบนั้น ส่วนใหญ่เป็นภาพของยานพาหนะที่บันทึกในช่วงเวลากลางวันดังกล่าวไปข้างต้น สามารถเห็น รูปลักษณะ สีของยานพาหนะ และความแตกต่างของยานพาหนะแต่ละประเภทได้ค่อนข้างชัดเจน ผิดกับข้อมูลวิดีโอที่บันทึกในช่วงเวลากลางคืน ที่ไม่สามารถมองเห็นยานพาหนะได้ชัดเจน เนื่องจากแสงสว่างที่น้อยมากและแสงสะท้อนจากไฟหน้าของยานพาหนะแต่ละคัน ทำให้ระบบ ทำนายรูปลักษณะของยานพาหนะผิดพลาด อีกทั้งสีของยานพาหนะในช่วงเวลากลางคืน ที่ทุกๆคัน แทบจะมีสีไปในโทนเดียวกัน ส่งผลให้ระบบที่นำเสนอ ไม่สามารถทำนายประเภทของยานพาหนะ ในบริเวณมีแสงน้อยได้อย่างมีประสิทธิภาพ ในขณะเดียวกัน ผลการจำแนกประเภทยานพาหนะ ของวิดีโอชุดที่ 4 ที่มีเงาตกกระทบบนพื้นถนนไม่สม่ำเสมอ ก็มีผลการจำแนกที่มีความผิดพลาดสูง เช่นเดียวกัน โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) อยู่ที่ ประมาณ 36 และ 39 เปอร์เซ็นต์ แสดงให้เห็นว่าเงาที่ส่งผลต่อสีและความสว่างของยานพาหนะที่ เคลื่อนที่ผ่านนั้น ค่อนข้างมีผลกระทบต่อประสิทธิภาพในการจำแนกประเภทของยานพาหนะ เช่นเดียวกัน

นอกจากนี้ ยังมียานพาหนะบางประเภทที่ยังคงเป็นปัญหาในการตรวจจับและจำแนกประเภทของระบบ อย่างเช่น ยานพาหนะประเภทรถพ่วงที่บรรทุกรถรถนั่งส่วนบุคคลไว้ด้านบน แสดงในภาพประกอบที่ 51 ซึ่งทำให้ผลการทดลองการนับจำนวนยานพาหนะของ YOLOv8x+ByteTrack กับวิดีโอชุดที่ 5 ในตารางที่ 12 มีผลการการนับจำนวนยานพาหนะที่มากกว่าจำนวนข้อมูลเฉลย เนื่องจากระบบได้ทำการตรวจจับรถที่ถูกบรรทุกอยู่ด้านบนนั้น และนับรวมเป็นยานพาหนะที่เคลื่อนที่ผ่านเส้นอ้างอิงไปด้วย ทำให้ผลการนับยานพาหนะผิดพลาดไปจากความเป็นจริงได้ และในการทดลองครั้งนี้ยังมีข้อสังเกตว่า ผลลัพธ์ที่ได้จากการนับยานพาหนะในวิดีโอ 6 ที่มีคุณภาพของรูปภาพมากกว่าวิดีโออื่นๆ (Full HD (1080p)) ดังแสดงในตารางที่ 13 มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์แบบถ่วงน้ำหนัก (WMAPE) ของยานพาหนะทุกประเภทที่น้อยที่สุดและมีค่าน้อยกว่าค่าเฉลี่ยของทุกสภาพการณ์อยู่มาก จึงอาจสรุปได้ว่า ความละเอียดของรูปภาพที่ใช้ในการฝึกฝนและทดสอบระบบ มีผลต่อประสิทธิภาพการทำงานของระบบอย่างเห็นได้ชัด ดังนั้น การเลือกเก็บบันทึกและใช้ข้อมูลภาพวิดีโอที่มีความละเอียดของสูงมากขึ้น จะช่วยให้ระบบการนับยานพาหนะมีความแม่นยำในการจำแนกประเภทของยานพาหนะมากยิ่งขึ้นเช่นกัน



ภาพประกอบ 51 ความผิดพลาดในการตรวจจับรถพ่วงที่บรรทุกรถรถนั่งส่วนบุคคลไว้ด้านบน

อีกเหตุผลหนึ่งที่ส่งผลต่อประสิทธิภาพทั้งในการนับและจำแนกประเภทของยานพาหนะได้อย่างชัดเจนคือ ตำแหน่งของเส้นอ้างอิงที่สร้างขึ้นเพื่อนับจำนวนยานพาหนะที่เคลื่อนที่ผ่านจากวิดีโอที่ได้จากการทดลองพบว่า เกิดจากการที่ระบบตรวจจับและติดตามยานพาหนะยังคงตรวจจับยานพาหนะที่อยู่ในตำแหน่งที่ไกลออกไปจากจุดบันทึกในภาพไม่ได้หรือไม่แม่นยำนัก หรืออาจตรวจจับได้แต่จำแนกประเภทยานพาหนะผิดพลาดประเภท หากทำการสร้างเส้นอ้างอิงที่ไกลออกไปมากๆ จะส่งผลให้ระบบไม่สามารถนับและจำแนกยานพาหนะในตำแหน่งนั้นได้ดี ในทางกลับกัน หากทำการสร้างเส้นอ้างอิงในภาพในตำแหน่งที่ใกล้กับจุดบันทึกข้อมูลมากเกินไป อาจมียานพาหนะบางคัน (โดยเฉพาะยานพาหนะขนาดใหญ่) ที่เคลื่อนที่ออกจากเฟรมภาพไปบางส่วน

แล้ว แต่ระบบตรวจจับยังคงตรวจจับตำแหน่งได้ จึงมีผลการทำนายประเภทของยานพาหนะผิดเพี้ยนไปจากเดิม เนื่องจากรูปลักษณ์ของยานพาหนะที่ตรวจจับได้นั้น มีบางส่วนขาดหายไป ก็อาจส่งผลต่อประสิทธิภาพการทำงานของระบบเช่นเดียวกัน ดังนั้นการเลือกตำแหน่งเส้นทางโดยรวมทั้งความยาวของเส้นอ้างอิงและระยะ offset ของเส้นอ้างอิง ยังคงต้องมีการกำหนดให้เหมาะสมตามแต่ละสภาพการณ์ของข้อมูลวิดีโอทุกๆ โดยควรเป็นตำแหน่งที่สามารถมองเห็นรูปลักษณ์ของยานพาหนะทุกๆคันได้อย่างชัดเจน จะช่วยให้ระบบสามารถตรวจจับ และติดตามรวมทั้งจำแนกประเภทได้แม่นยำ ส่งผลให้การนับปริมาณยานพาหนะแบบแยกประเภทนั้นมีประสิทธิภาพสูงขึ้นได้

ทั้งนี้ จะเห็นได้ว่า โดยภาพรวมแล้ว ระบบที่นำเสนอสามารถทำงานในเรื่องของการตรวจจับ ติดตาม และนับจำนวนยานพาหนะได้อย่างแม่นยำ เห็นได้จากความแม่นยำโดยรวมในการนับยานพาหนะทุกคันในการทดลองกับข้อมูลวิดีโอทุกสถานการณ์ ว่าสามารถทำงานได้อย่างยอดเยี่ยม และสำหรับการนับยานพาหนะแบบแยกประเภทซึ่งเป็นผลลัพธ์มาจากความสามารถในการจำแนกประเภทของระบบนั้น อาจยังมีประสิทธิภาพที่ไม่ดีมากเท่าไรนัก เนื่องจากชุดข้อมูลที่ใช้ในการฝึกฝนระบบในครั้งนี้ ยังมีจำนวนและความหลากหลายของข้อมูลไม่มากเพียงพอ ในการพัฒนาประสิทธิภาพในการจำแนกประเภทของยานพาหนะ ทางผู้วิจัยแนะนำให้ทำการปรับปรุงชุดข้อมูลยานพาหนะท้องถิ่นของประเทศไทยที่สร้างขึ้นมาสำหรับการฝึกฝนระบบให้ดียิ่งขึ้น โดยการเพิ่มจำนวนรูปภาพตั้งต้นที่ใช้สร้างชุดข้อมูล เพิ่มความหลากหลายของยานพาหนะที่ทำการติดป้ายชื่อ (Labeling) แต่ละประเภทและความหลากหลายของช่วงเวลาเก็บสำรวจ เก็บบันทึกข้อมูลเพิ่มโดยใช้รูปภาพการจราจรที่มีความละเอียดสูงขึ้น เพื่อให้ระบบสามารถรู้จำและจำแนกประเภทของยานพาหนะได้อย่างแม่นยำมากขึ้น รวมถึงอาจมีการเพิ่มยานพาหนะประเภทอื่นๆอย่างรถจักรยาน 2 ล้อ, จักรยาน 3 ล้อ หรือรถจักรยานยนต์ 3 ล้อ (รถตุ๊กตุ๊ก) หรือแม้กระทั่งรถพ่วงที่บรรทุกถรณ์นั่งส่วนบุคคลไว้ด้านบนและอื่นๆ เพื่อให้ระบบสามารถจำแนกยานพาหนะในประเทศไทยได้ครอบคลุมการใช้งานจริงมากขึ้นต่อไป นอกจากนี้ เพื่อให้ได้ระบบตรวจนับและจำแนกประเภทของยานพาหนะที่มีความเสถียรมากยิ่งขึ้น ผู้วิจัยแนะนำว่า ควรทดสอบการทำงานของระบบกับข้อมูลที่มีความหลากหลายของสภาพการณ์อื่นๆที่แตกต่างออกไป เช่น สภาพการณ์จราจรที่มีฝนตก หรือสภาพการณ์จราจรที่มีวัตถุกีดขวางการมองเห็นยานพาหนะ หรือสภาพการณ์จราจรที่บันทึกข้อมูลยานพาหนะจากมุมมองด้านข้าง หรือมุมสูงจากการบันทึกด้วยโดรน เป็นต้น

ในอนาคต หากมีการพัฒนาระบบที่นำเสนอจนมีประสิทธิภาพที่แม่นยำและมั่นคงแล้ว นั้น สามารถนำไปพัฒนาต่อยอดได้อย่างหลากหลาย โดยเฉพาะการพัฒนางานต่างๆที่เป็นการส่งเสริมระบบขนส่งและจราจรในประเทศไทย เช่น การนำระบบนับปริมาณยานพาหนะและจำแนกประเภทของยานพาหนะไปเก็บข้อมูลการจราจรบริเวณทางแยกเพื่อปรับปรุงสัญญาณไฟจราจรที่เหมาะสม พัฒนาต่อเป็นระบบตรวจจับยานพาหนะพิเศษอย่างเช่น รถพยาบาลฉุกเฉินหรือรถดับเพลิง เป็นต้น เพื่อให้มีความสำคัญกับเหตุการณ์ฉุกเฉินและให้สัญญาณไฟจราจรสีเขียวแก่ทิศทางของยานพาหนะพิเศษนั้นๆก่อน หรือแม้แต่การนำไปใช้เป็นระบบเฝ้าระวังและควบคุมวินัยการจราจรต่างๆ เนื่องจากการทำงานของระบบตรวจจับอย่าง YOLO ในปัจจุบัน สามารถตรวจจับยานพาหนะได้อย่างรวดเร็วระดับ real-time การนำไปใช้ร่วมกับกล้องวงจรปิดเฝ้าระวังที่มีการติดตั้งไว้ก่อนแล้ว จะเป็นการช่วยยกระดับระบบควบคุมวินัยการจราจรต่างๆมากยิ่งขึ้น อย่างเช่น ระบบตรวจจับยานพาหนะที่ขับซี้ในทิศทางการจราจรที่ไม่ถูกต้อง หรือในพื้นที่ต้องห้ามหรือการตรวจจับการจราจรที่ไม่ปกติหรือมีอุบัติเหตุ เพื่อแจ้งเตือนและให้ข้อมูลการเลือกใช้เส้นทางของถนนในเขตเมืองได้ เป็นต้น

บรรณานุกรม

Uncategorized References

- A. Alsanabani, A., A. Ahmed, M., & M. Al Smadi, A. (2020, 2020). Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis.
- Aharon, N., Orfaig, R., & Bobrovsky, B.-Z. (2022). BoT-SORT: Robust associations multi-pedestrian tracking. *arXiv preprint arXiv:2206.14651*.
- Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016, 25-28 Sept. 2016). Simple online and realtime tracking. 2016 IEEE International Conference on Image Processing (ICIP),
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-y. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*.
- Chauhan, M. S., Singh, A., Khemka, M., Prateek, A., & Sen, R. (2019, 2019). Embedded CNN based vehicle classification and counting in non-laned road traffic.
- Choudhury, S., Chattopadhyay, S. P., & Hazra, T. K. (2017, 16-18 Aug. 2017). Vehicle detection and counting using haar feature-based classifier. 2017 8th Annual Industrial Automation and Electromechanical Engineering Conference (IEMECON),
- Cruz, F. R. G., Santos, C. J. R., & Vea, L. A. (2019, 29 Nov.-1 Dec. 2019). Classified Counting and Tracking of Local Vehicles in Manila Using Computer Vision. 2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM),
- Forero, A., & Calderon, F. (2019, 24-26 April 2019). Vehicle and pedestrian video-tracking with classification based on deep convolutional neural networks. 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA),
- Harjoko, A., Candradewi, I., & Bakhtiar, A. A. A. (2017, 2017). Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow.
- Kalman, R. E. (1960). A New Approach to Linear Filtering and Prediction Problems. *Journal*

- of *Basic Engineering*, 82(1), 35-45. <https://doi.org/10.1115/1.3662552>
- Kuhn, H. W. (1955). The Hungarian method for the assignment problem. *Naval Research Logistics Quarterly*, 2(1-2), 83-97. <https://doi.org/10.1002/nav.3800020109>
- Liu, C., Huynh, D. Q., Sun, Y., Reynolds, M., & Atkinson, S. (2021). A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification. *IEEE Transactions on Intelligent Transportation Systems*, 22(12), 7547-7560. <https://doi.org/10.1109/TITS.2020.3004066>
- Liu, F., Zeng, Z., & Jiang, R. (2017). A video-based real-time adaptive vehicle-counting system for urban roads. *PLOS ONE*, 12(11), e0186098. <https://doi.org/10.1371/journal.pone.0186098>
- Muchtar, K., Afdhal, A., & Nasaruddin, N. (2020, 10-11 Dec. 2020). Convolutional Network and Moving Object Analysis for Vehicle Detection in Highway Surveillance Videos. 2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI),
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. <https://doi.org/10.1109/CVPR.2016.91>
- Redmon, J., & Farhadi, A. (2017). *YOLO9000: Better, Faster, Stronger*. <https://doi.org/10.1109/CVPR.2017.690>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*.
- Seenouvang, N., Watchareeruetai, U., Nuthong, C., Khongsomboon, K., & Ohnishi, N. (2016, 3-6 Feb. 2016). A computer vision based vehicle detection and counting system. 2016 8th International Conference on Knowledge and Smart Technology (KST),
- Sindhu, V. S. (2021, 6-8 May 2021). Vehicle Identification from Traffic Video Surveillance Using YOLOv4. 2021 5th International Conference on Intelligent Computing and Control Systems (ICICCS),
- Wojke, N., Bewley, A., & Paulus, D. (2017, 17-20 Sept. 2017). Simple online and realtime tracking with a deep association metric. 2017 IEEE International Conference on Image Processing (ICIP),

Zhang, B., & Zhang, J. (2021). A Traffic Surveillance System for Obtaining Comprehensive Information of the Passing Vehicles Based on Instance Segmentation. *IEEE Transactions on Intelligent Transportation Systems*, 22(11), 7040-7055.

<https://doi.org/10.1109/TITS.2020.3001154>

Zhang, Y., Sun, P., Jiang, Y., Yu, D., Weng, F., Yuan, Z., Luo, P., Liu, W., & Wang, X. (2022). Bytetrack: Multi-object tracking by associating every detection box. *Computer Vision–ECCV 2022: 17th European Conference, Tel Aviv, Israel, October 23–27, 2022, Proceedings, Part XXII*,



ประวัติผู้เขียน

