

ระบบตรวจจับและจำแนกประเภทยานพาหนะแบบอัตโนมัติ สำหรับถนนในเขตเมือง
ด้วยหลักการโครงข่ายแบบคอนโวลูชัน

อัฐพงศ์ สังข์เพชร¹, วีระ สอิ่ง²

บทคัดย่อ

ในพื้นที่เขตในเมืองของเมืองขนาดใหญ่หลายๆแห่งในปัจจุบันนั้น มีการขยายตัวขึ้นอย่างรวดเร็ว จึงส่งผลให้เกิดการเดินทางและปริมาณยานพาหนะที่ใช้สัญจรบนท้องถนนเพิ่มมากขึ้น ซึ่งก่อให้เกิดผลกระทบและปัญหาด้านการจราจรต่างๆตามมา โดยเฉพาะในเขตพื้นที่เมือง ปัญหาด้านการจราจรที่มีความรุนแรงอาจส่งผลกระทบต่อไปยังการพัฒนาในภาคส่วนอื่นๆ อย่างระบบเศรษฐกิจหรือระบบสิ่งแวดล้อมต่างๆได้ เพื่อจัดการกับปัญหาด้านการจราจรตามหลักของวิศวกรรมขนส่งและจราจร ข้อมูลปริมาณจราจรจึงเป็นข้อมูลที่มีความสำคัญมากในการศึกษาและออกแบบ และควรมีการเก็บบันทึกอย่างสม่ำเสมอ เพื่อเป็นการส่งเสริมและพัฒนางานด้านวิศวกรรมจราจร ในงานวิจัยนี้ ผู้วิจัยได้เสนอการระบบตรวจจับยานพาหนะและจำแนกประเภทของยานพาหนะ ที่ใช้หลักโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) อย่าง YOLOv8 เป็นอัลกอริทึมในการตรวจจับ โดยมีการสร้างชุดข้อมูลของยานพาหนะในประเทศไทยเพื่อใช้ในการฝึกฝนระบบตรวจจับยานพาหนะ ให้สามารถตรวจจับและจำแนกยานพาหนะได้ทั้งหมด 11 ประเภท และทำการเปรียบเทียบการทำงานร่วมกับระบบติดตามวัตถุที่สามารถติดตามวัตถุหลายๆวัตถุในภาพได้ดี ByteTrack และ BotSORT เพื่อศึกษาและเลือกใช้การทำงานร่วมกันของระบบตรวจจับยานวัตถุและระบบติดตามวัตถุที่มีประสิทธิภาพในงานติดตามยานพาหนะมากที่สุด และนำไปประยุกต์ใช้กับการนับยานพาหนะที่ใช้การสร้างเส้นอ้างอิงบนถนนเพื่อเก็บข้อมูลจำนวนและประเภทของยานพาหนะที่เคลื่อนที่ผ่าน โดยในระบบที่สร้างขึ้นนี้ ได้ทำการทดสอบกับข้อมูลการจราจรหลากหลายสภาพการณ์ที่อยู่บนถนนในเขตเมืองของประเทศไทย สามารถตรวจจับยานพาหนะได้ทั้ง 11 ประเภท มีระดับความแม่นยำเฉลี่ยในการนับจำนวนยานพาหนะที่ค่อนข้างแม่นยำอยู่ที่ประมาณ 90 เปอร์เซ็นต์ และมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ในการจำแนกประเภทของยานพาหนะทุกประเภทอยู่ที่ประมาณ 51 เปอร์เซ็นต์

คำสำคัญ : การนับยานพาหนะ, การตรวจจับยานวัตถุ, การติดตามยานวัตถุ, ระบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน

¹ หลักสูตรวิทยาศาสตร์มหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

* Corresponding author: Tel.: 087-6505044 E-mail address: attapong.sangphet@g.swu.ac.th

Automatic counting and Classification of vehicle on urban road
by convolutional Neural Network

Attapong Sangphet^{1*}, Vera Sa-ing²

Abstract

In current years, some large cities are expanding rapidly and many trip generations were generated on the public roads in their city. This huge increase in the number of vehicles on the road causes many transportation and traffic problems to their city, especially in the urban area. Without effective management, transportation problems will affect to another development sectors, economics, environment system and so on. To manage a growing traffic volume as transportation and traffic engineering practice, vehicles information is an important thing that we need to collect regularly and use it for study and designs or provided mitigation plan of any traffic issues. In this paper, we proposed a vehicle counting and classification system using convolutional neural network for collecting volume and type of vehicles. Our proposed system used YOLOv8 as our vehicle detector and trained detector system with our local dataset of Thailand vehicles which is collected of 11 different types of vehicle images. Then we combined our trained detector with some great performance trackers in multi-object tracking. In our experiment, we compared system performances between two state-of-the-art trackers, ByteTrack and BotSORT, to see how different between them and choose the best one as our tracker for the future works. For the counting process, we provide a referenced counting line to collect the number of vehicles and their class when they cross the line. we tested and evaluated our system with various scenario of traffic footage that collecting on urban road in Bangkok, Thailand. The video results show that our proposed system can detect and classify all 11 types in our provided video frames. The figures of average accuracy of total counting and mean absolute percentage error (MAPE) of classified counting are about 90 per cent and 51 percent respectively.

Keywords: Vehicle Counting, Object Detection, Object Tracking, Convolutional Neural Network, YOLO

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

* Corresponding author: Tel.: 087-6545044 E-mail address: attapong.sangphet@swu.ac.th

บทนำ

ในปัจจุบัน เมืองขนาดใหญ่หลายแห่งมีจำนวนประชากรที่อาศัยอยู่ในเมืองนั้นๆเพิ่มขึ้นสูงมาก ส่งผลโดยตรงให้เกิดการเดินทางสัญจรไปมาในเขตเมืองเพิ่มขึ้นและมีปริมาณจราจรบนท้องถนนมากขึ้นตามไปด้วย การเพิ่มขึ้นของปริมาณจราจรที่มากเกินไปจนความจุของถนนที่สามารถรองรับได้นั้น จะก่อให้เกิดปัญหาด้านการจราจรต่างๆตามมาเช่น การจราจรติดขัด หรือ การจัดเตรียมสิ่งอำนวยความสะดวกต่างๆอย่างถนนและที่จอดรถที่ไม่สอดคล้องกับปริมาณจราจรที่เกิดขึ้นจริง เป็นต้น หากปล่อยให้เกิดปัญหาเหล่านี้ขึ้นอย่างต่อเนื่อง อาจส่งผลกระทบต่อภาพรวมของการคมนาคมขนส่งทางบก รวมทั้งอาจส่งผลกระทบต่อระบบเศรษฐกิจหรือระบบสิ่งแวดล้อมและระบบอื่นๆตามมาได้ในอนาคต ด้วยเหตุผลดังกล่าว ปัญหาด้านการจราจรจึงเป็นหนึ่งในปัญหาหลักของทุกๆเขตเมืองขนาดใหญ่ที่ได้รับความสนใจในการปรับปรุงและพัฒนาให้เหมาะสมตามหลักวิศวกรรมขนส่งและจราจรอยู่เสมอมา และสำหรับการพัฒนาด้านวิศวกรรมขนส่งและจราจรนั้น ข้อมูลที่สำคัญที่สุดที่ใช้ในการศึกษาและออกแบบและมีการเก็บสำรวจอยู่เป็นประจำคือ ข้อมูลปริมาณจราจรที่วิ่งอยู่บนถนนแต่ละเส้น ซึ่งเป็นข้อมูลที่มีความหลากหลายในแง่ของประเภทของยานพาหนะและมีการเปลี่ยนแปลงอยู่ตลอดเวลาโดยมีแนวโน้มเพิ่มขึ้นเรื่อยๆในเกือบทุกๆปี การมีข้อมูลปริมาณจราจรที่ครบถ้วนและถูกต้องตามสภาพการจราจรที่เกิดขึ้นจริง จะช่วยให้สามารถจัดการกับปัญหาด้านจราจรได้ดียิ่งขึ้น รวมทั้งช่วยในการวางแผนจัดเตรียมสิ่งปลูกสร้างพื้นฐานหรือสิ่งอำนวยความสะดวกต่างๆเพื่อรองรับการใช้งานจริงได้อย่างเหมาะสมมากยิ่งขึ้น แต่การเก็บสำรวจข้อมูลด้านการจราจรขององค์กรหลายๆแห่งในประเทศไทยในปัจจุบันนั้น ยังคงใช้วิธีการแปลงผลหรือถอดข้อมูลจากข้อมูลประเภทวิดีโอที่ได้จากการเก็บสำรวจหน้างาน ด้วยการนับด้วยสายตาหรือใช้คนในการถอดข้อมูลอยู่ ซึ่งเป็นวิธีการทำงานที่มีต้นทุนค่อนข้างสูง ทั้งในแง่ของระยะเวลาในการถอดข้อมูลที่ใช้เวลาในการทำค่อนข้างนาน และยังคงเกิดข้อผิดพลาดจากการทำงานของถอดข้อมูลโดยใช้คนถอด (human error) ได้ง่าย

ในขณะเดียวกัน ทุกวันนี้ได้มีการส่งเสริมการนำเทคโนโลยีต่างๆ เข้ามาประยุกต์ใช้เพื่อพัฒนาการจัดการด้านการจราจรมากขึ้น และผลักดันให้เกิดเป็นระบบขนส่งอัจฉริยะ (ITS) โดยเฉพาะสำหรับพื้นที่ในเขตเมืองที่ได้รับผลกระทบจากปัญหาด้านการจราจร จึงได้มีการนำเทคโนโลยีการมองเห็นทางคอมพิวเตอร์ (computer vision) มาประยุกต์ใช้ในการทำงานร่วมกับข้อมูลประเภทรูปภาพและวิดีโอมากขึ้น เกิดการพัฒนาและนำเสนอระบบต่างๆสำหรับงานด้านการจราจรที่มีความสามารถในการถอดข้อมูลจากภาพได้อย่างมีประสิทธิภาพ และเนื่องจากในยุคสมัยนี้ หลายๆเมืองขนาดใหญ่ล้วนมีการติดตั้งระบบเฝ้าระวังด้านการจราจรจากกล้องบันทึกภาพวิดีโอแบบปกติไว้เรียบร้อยแล้ว การมีระบบที่สามารถประยุกต์ใช้ถอดและเก็บข้อมูลด้านจราจรจากข้อมูลภาพเหล่านั้นได้อย่างแม่นยำและรวดเร็ว จะช่วยให้การเก็บข้อมูลด้านการจราจรในอนาคตมีประสิทธิภาพและเป็นการส่งเสริมความเป็นระบบขนส่งอัจฉริยะมากยิ่งขึ้น ทำให้ระบบการถอดข้อมูลด้านจราจรเหล่านี้ ถูกพัฒนามาอย่างต่อเนื่องและเริ่มเข้ามามีบทบาทในการบริหารจัดการด้านการจราจรแทนที่วิธีการทำงานแบบเก่ามากขึ้น

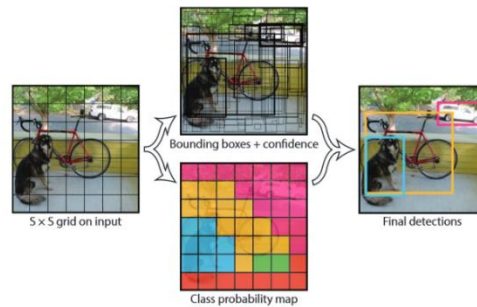
อย่างไรก็ดี ระบบการถอดข้อมูลด้านการจราจรที่ถูกพัฒนาขึ้นส่วนใหญ่อาจยังไม่เหมาะสมที่จะนำมาใช้งานการเก็บข้อมูลปริมาณจราจรในประเทศไทยนัก เนื่องจากระบบส่วนใหญ่ถูกสร้างและฝึกฝนข้อมูลโดยใช้ชุดข้อมูลของต่างประเทศที่อาจมีข้อจำกัดในเรื่องของประเภทของวัตถุ (Classes) ในชุดข้อมูลที่ใช้ในการฝึกฝนระบบ อีกทั้งประเภทของยานพาหนะที่ใช้ในประเทศไทย มีความหลากหลายค่อนข้างสูง และมีความแตกต่างกันในเรื่องของรูปลักษณ์ภายนอกของยานพาหนะ ทำให้ไม่สามารถนับหรือจำแนกประเภทของยานพาหนะในประเทศไทยได้อย่างครบถ้วนและเหมาะสม ดังนั้นทีมวิจัยจึงได้พัฒนาบทความวิจัยนี้ เพื่อจะเป็นการนำเสนอกระบวนการของระบบตรวจจับและจำแนกประเภทของยานพาหนะแบบอัตโนมัติสำหรับถนนในเขตเมือง โดยการใช้หลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชันในการฝึกฝนให้ระบบสามารถรู้จำและจำแนกประเภทของยานพาหนะได้ครอบคลุม

ยานพาหนะที่ใช้ในประเทศไทย สามารถตรวจจับวัตถุที่เป็นยานพาหนะได้อย่างแม่นยำ และนำมาประยุกต์ใช้กับการนับปริมาณจราจรแบบแยกสายประเภทของยานพาหนะได้อย่างเหมาะสมกับการใช้งานจริงในประเทศไทย


งานวิจัยที่เกี่ยวข้อง

1. ระบบตรวจจับยานพาหนะ (Vehicle Detection)

ในปัจจุบัน การใช้การเรียนรู้เชิงลึก หรือ Deep Learning เริ่มบทบาทมากขึ้น ระบบประสาทเทียมแบบคอนโวลูชัน หรือ Convolution Neural Network สามารถทำงานกับข้อมูลรูปภาพได้ประสิทธิภาพที่ดีกว่า และเริ่มเข้ามาแทนที่วิธีการแบบเดิมๆ อัลกอริทึมหนึ่งที่เป็นที่นิยมกันอย่างมากในช่วงเวลานี้คือ You Only Look Once หรือ YOLO (1) ถูกพัฒนาขึ้นในปี ค.ศ.2016 โดย Joseph Redmon และคนอื่นๆ ให้มีรูปแบบการทำงานเป็น Single Neural Network ที่สามารถทำนายกล่องขอบเขตของวัตถุ (Bounding Box) และทำนายค่าความน่าจะเป็นของประเภทของวัตถุ (Class Probabilities) จากข้อมูลรูปภาพ ได้อย่างรวดเร็ว ดังแสดงในภาพประกอบ 1(a) สถาปัตยกรรมของ YOLO รุ่นแรกหรือ YOLOv1 ประกอบไปด้วย Convolutional layers จำนวน 24 ชั้น และ Fully connected layers จำนวน 2 ชั้น ดังแสดงในภาพประกอบที่ 1(b) หลักการของอัลกอริทึม YOLO ถูกนำไปพัฒนาอย่างต่อเนื่องเป็นเวอร์ชัน 2, 3 และ 4 ให้มีประสิทธิภาพในการทำงานที่แม่นยำและรวดเร็วมากขึ้น (2), (3), (4)



(a)



(b)

ภาพประกอบ 1 รูปภาพ แสดงสถาปัตยกรรมของ YOLO

(a) แสดงกระบวนการทำนายของหลักการ YOLO และ (b) แสดงโครงสร้างของสถาปัตยกรรม YOLOv1 ที่ใช้ในการเรียนรู้ด้วยหลักการโครงสร้างประสาทเทียมแบบคอนโวลูชัน

งานวิจัย (5) นำเสนอระบบนัทยานพาหนะแบบแยกประเภทที่ YOLO เป็นอัลกอริทึมในการตรวจจับยานพาหนะ และประยุกต์ใช้ร่วมกับการนัทยานพาหนะและการฝึกฝนข้อมูลให้ทำนายประเภทยานพาหนะได้มากขึ้น ส่งผลให้ระบบสามารถทำกรนัทยานพาหนะได้อย่างแม่นยำ

หลังจากนั้นไม่นาน Glenn Jocher ได้เปลี่ยนการทำงานของ YOLOv3 ไปใช้กับ Pytorch Deep Learning Framework แทนการใช้ Tensor Flow เป็นที่รู้จักกันในชื่อ YOLOv5 ซึ่งไม่ได้เป็นการนำเสนอองค์ความรู้ใหม่ๆ จึงทำให้ยังไม่มีการตีพิมพ์บทความของ YOLOv5 และพบว่าในบางงานวิจัย YOLOv5 มีประสิทธิภาพในการทำงานที่ดีกว่า YOLOv4 และ YOLOv3 แต่มีความเร็วในการทำงานใกล้เคียงกับ YOLOv4 อย่างไรก็ตาม เคยมีผู้ทำการศึกษางานวิจัยที่มีการแสดงผลการเปรียบเทียบผลการจำแนกประเภทของยานพาหนะโดยใช้หลักการ YOLO ไว้ ได้ผลว่า YOLOv5 ทำงานได้ค่อนข้างดีกว่าตัวอื่นๆ และในปีปัจจุบัน พ.ศ. 2023 Glenn Jocher และผู้พัฒนาอื่นๆที่ใช้ชื่อว่า Ultralytics ได้พัฒนา YOLOv8 ออกมา ซึ่งทำงานในการตรวจจับและจำแนกวัตถุได้ดีกว่า YOLOv5 มีความแม่นยำและรวดเร็วกว่า อีกทั้งยังถูกพัฒนาให้สามารถติดตามวัตถุ รวมทั้งทำนายวัตถุแบบแบ่งส่วนรูปภาพหรือ Segmentation ด้วยตัวมันเองได้อีกด้วย

2. ระบบติดตามยานพาหนะ (Vehicle Tracking)

การใช้ระบบติดตามวัตถุร่วมกับระบบตรวจจับวัตถุ จะช่วยให้ระบบที่พัฒนาขึ้นนั้น สามารถตรวจจับวัตถุในข้อมูลประเภทภาพเคลื่อนไหวได้ดียิ่งขึ้น โดยจะช่วยลดการตรวจจับซ้ำซ้อน ซึ่งข้อดีอีกอย่างหนึ่งในการเลือกใช้ YOLOv8 เนื่องจากว่า YOLOv8 ได้ถูกพัฒนาให้สามารถทำงานในการติดตามยานพาหนะของวัตถุประเภทวิดีโอได้ โดยระบบติดตามที่ถูกจัดเตรียมไว้สำหรับการติดตามยานพาหนะ 2 ตัว คือ ByteTrack และ BotSort จากการศึกษาพบว่า หนึ่งในคุณสมบัติที่เหมาะสมของระบบติดตามวัตถุที่จะนำมาใช้ในการติดตามยานพาหนะในภาพ คือ ต้องสามารถติดตามวัตถุหลายๆวัตถุที่เกิดขึ้นในข้อมูลรูปภาพพร้อมๆกันได้ (Multiple Object Tracking (MOT)) และจากการตรวจสอบการจัดอันดับของระบบติดตามยานพาหนะโดยใช้ตัวชี้วัดเป็น MOTA หรือ Multiple Object Tracking Accuracy กับชุดข้อมูล MOT17 ในปีปัจจุบันพบว่า ระบบติดตามวัตถุ 2 ตัวดังกล่าว มีประสิทธิภาพความแม่นยำที่สูงเกิน 80 เปอร์เซ็นต์ และถูกจัดอันดับอยู่ใน 3 อันดับแรกที่สามารถติดตามวัตถุแบบ MOT ได้อย่างแม่นยำที่สุดดังแสดงในภาพประกอบที่ 2 ByteTrack (7) ถูกพัฒนาขึ้นในปี 2021 ที่แตกต่างจากระบบติดตามตัวอื่นๆที่ส่วนใหญ่จะเน้นพัฒนาระบบให้สามารถติดตามวัตถุที่มีคะแนนกล่องขอบเขตที่ถูกตรวจจับได้สูงๆ แต่ ByteTrack จะทำงานโดยติดตามทุกๆวัตถุที่ถูกตรวจจับได้ และแยกเป็นวัตถุที่มีคะแนนการตรวจจับสูงกับวัตถุที่มีคะแนนการตรวจจับต่ำ ระบบติดตามนี้ถูกพัฒนาให้ทำงานกับวัตถุที่มีคะแนนการตรวจจับได้สูงๆ แต่ถูกบดบังหรือมีเปลี่ยนแปลงขนาดของวัตถุที่ทำให้ไม่สามารถติดตามวัตถุนั้นๆได้ โดยการพิจารณาวัตถุที่มีคะแนนการตรวจจับสูงที่ถูกยกเลิกการติดตาม ร่วมกับวัตถุที่มีคะแนนการตรวจจับต่ำ เพื่อทำการกู้คืนการติดตามวัตถุนั้นๆ ทำให้ ByteTrack เป็นระบบติดตามที่ทำงานในการติดตามวัตถุหลายๆวัตถุพร้อมๆกันได้เป็นอย่างดี ลดปัญหาการติดตามวัตถุที่เกิดการบดบังในบางภาพได้ และในปี 2022 BotSORT (6) ได้ถูกพัฒนาขึ้นโดย Nir Aharon, Roy Orfaig และ Ben-Zion Bobrovsky เป็นการพัฒนาระบบติดตามต่อยอดจากระบบติดตาม SORT โดยปรับปรุงสมการของ Kalman Filter และ metrics บางตัวของ SORT เป็นระบบที่มีประสิทธิภาพในการติดตามยานพาหนะหลายวัตถุ (MOT) ได้มีประสิทธิภาพมากที่สุดในเวลานั้น

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	🔗	📄	2022	
2	BoT-SORT	65.0	80.5	80.2	✓	BoT-SORT: Robust Associations Multi-Pedestrian Tracking	🔗	📄	2022	
3	ByteTrack		80.3	77.3	✓	ByteTrack: Multi-Object Tracking by Associating Every Detection Box	🔗	📄	2021	
4	StrongSORT	64.4	79.6	79.5	✓	StrongSORT: Make DeepSORT Great Again	🔗	📄	2022	

ภาพประกอบที่ 2 การจัดอันดับโมเดลการติดตามวัตถุโดยใช้ตัวชี้วัดเป็น MOTA

(source: <https://paperswithcode.com/sota/multi-object-tracking-on-mot17>)

3. ระบบนับยานพาหนะ (Vehicle Counting)

การนับยานพาหนะที่นิยมนำไปประยุกต์ใช้หลักจากขั้นตอนการตรวจจับยานพาหนะและให้ผลลัพธ์ที่ดีคือการกำหนดเส้นอ้างอิงบนถนนในข้อมูลภาพสำหรับนับยานพาหนะที่เคลื่อนที่ผ่าน (Detection Line) และกำหนดจุดอ้างอิงบนตำแหน่งของยานพาหนะ โดยการนับจำนวนยานพาหนะจะนับเมื่อ จุดอ้างอิงบนยานพาหนะที่กำหนด เคลื่อนที่ผ่านตำแหน่งของเส้นอ้างอิงที่กำหนด ทำให้สามารถนับยานพาหนะที่ถูกติดตามได้อย่างแม่นยำมากขึ้น

งานวิจัย (8), (9) และ (10) ใช้การสร้าง Reference line ขึ้นมา และใช้ Reference point บน Boundary box เป็นตัวกำหนดในการนับยานพาหนะ เมื่อเคลื่อนที่ผ่าน มีผลการนับและแยกประเภทของยานพาหนะที่มีความแม่นยำสูง

4. ระบบจำแนกประเภทยานพาหนะ (Vehicle Classification)

ด้วยหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน อย่าง YOLO ที่เลือกใช้ มีโครงสร้างเป็นระบบตรวจจับแบบขั้นตอนเดียว หรือ One Stage Detector ที่สามารถให้ผลลัพธ์ออกมาได้เป็นกล่องขอบเขตของวัตถุ และจำแนกประเภทของวัตถุได้เลย กล่าวคือ สามารถทำนายประเภทของยานพาหนะได้จากขั้นตอนการตรวจจับยานพาหนะ

งานวิจัย (5) และ (11) ที่นำเสนอระบบนับและจำแนกประเภทยานพาหนะ ที่ใช้การฝึกฝนข้อมูลจากชุดข้อมูลที่สร้างขึ้นมาเอง ทำให้ระบบสามารถจำแนกประเภทของยานพาหนะท้องถิ่นได้หลากหลายมากขึ้น


5. การประเมินประสิทธิภาพ (Evaluation)

ในการประเมินประสิทธิภาพของระบบนับยานพาหนะยานพาหนะ ผู้วิจัยนิยมนำเสนอผลการทดลองด้วยวิธีการเปรียบเทียบผลลัพธ์ที่ได้กับผลเฉลยของข้อมูลที่เกิดขึ้นจริง (ground truth) จากการนับด้วยสายตา ตัวชี้วัดที่แสดงประสิทธิภาพ

ของระบบได้อย่างชัดเจนและนิยมใช้กันมากคือ ค่าความแม่นยำ (Accuracy) ของระบบที่นำเสนอ งานเช่นงานวิจัย (12) และ (13) ที่วัดผลการทดลองโดยใช้ค่าความแม่นยำเป็นเกณฑ์ในการวัดผล

วิธีดำเนินการ

กระบวนการวิจัยทั้งหมดของผู้ทำวิจัย จะมุ่งเน้นในการศึกษางานวิจัย เพื่อนำมาใช้ในการการปรับปรุง พัฒนา และค้นหา รูปแบบการนับยานพาหนะ ในเส้นทางที่กำหนด ด้วยการใช้หลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่มีพื้นฐานมาจาก วิธีการเรียนรู้เชิงลึก หรือที่เรียกกันว่า Deep Learning ที่มีประสิทธิภาพและเหมาะสมกับการนำมาใช้ในงานวิจัยนี้ โดยงานวิจัยนี้ ผู้วิจัยได้ออกแบบขั้นตอนของการดำเนินการวิจัยดังภาพประกอบที่ 3 ที่มีการแบ่งขั้นตอนการทำงานออกเป็น 6 ขั้นตอน เพื่อนำเสนอรูปแบบที่เหมาะสมกับการทำวิจัย และในขั้นตอนสุดท้ายจะนำเสนอวิธีการประเมินประสิทธิภาพของรูปแบบที่นำเสนอ ด้วยการวัดทั้งด้านปริมาณ (Quantitative evaluation) และทางด้านคุณภาพ (Qualitative evaluation) เพื่อเป็นการแสดงถึง ประสิทธิภาพของกระบวนการทำวิจัย



ภาพประกอบ 2 ภาพประกอบแสดง Flowchart วิธีการดำเนินงานการวิจัย

1. การเก็บรวบรวมข้อมูล (Data Acquisition)

ข้อมูลปริมาณจราจรที่เลือกใช้ เป็นข้อมูลในรูปแบบของข้อมูลภาพภาพและข้อมูลภาพเคลื่อนไหวหรือวิดีโอ ที่ได้จากการเก็บสำรวจปริมาณจราจรของยานพาหนะบนถนนเขตในเมือง ของประเทศไทย โดยเป็นข้อมูลที่เก็บรวบรวมโดยบริษัทที่ปรึกษาด้านวิศวกรรมขนส่งและจราจรของหน่วยงานเอกชนแห่งหนึ่ง โดยตั้งสมมติฐานของความแตกต่างของการเก็บสำรวจทั้งในด้านของสถานที่ในการทำการบันทึกข้อมูล สภาพการณ์ของการจราจร ช่วงเวลาและสภาพอากาศ มากไปกว่านั้นข้อมูลของยานพาหนะที่ทำการบันทึกมา ยังมีความหลากหลายของประเภทของยานพาหนะ ที่ค่อนข้างครอบคลุมประเภทของยานพาหนะที่ใช้งานจริงในประเทศไทยอีกด้วย และสำหรับงานวิจัยนี้จะมุ่งเน้นไปที่ข้อมูลของการบันทึกวิดีโอในพื้นที่ปิด อย่างเช่น ถนนทางด่วน หรือเส้นทางที่สามารถใช้ความเร็วได้ เพื่อลดความหลากหลายของข้อมูลที่มากเกินไปจนทำให้รูปแบบของการเรียนรู้ไม่สามารถจำแนกหรือนับข้อมูลได้อย่างถูกต้อง ข้อมูลที่นำมาใช้ทั้งหมดแบ่งเป็นข้อมูลประเภทรูปภาพของการจราจรจำนวน 250 รูปภาพ สำหรับใช้เป็นข้อมูลตั้งต้นในการฝึกฝนระบบ และข้อมูลวิดีโอที่มีบันทึกจากจุดสำรวจที่แตกต่างกัน 5 จุดสำรวจ เป็นจำนวน 6 วิดีโอ ที่มีสภาพการณ์ที่แตกต่างกันดังแสดงในภาพประกอบที่ 3 ใช้เป็นข้อมูลในการทดสอบการทำงานของระบบที่นำเสนอ โดยแต่ละวิดีโอมีความยาวประมาณ 10 นาที และมีรายละเอียดอื่น ๆ ดังต่อไปนี้

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



ภาพประกอบที่ 3 ตัวอย่างภาพของวิดีโอที่ใช้สำหรับทดสอบระบบที่ 1 ถึง 6 ตามลำดับ

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

นอกจากนี้ยังใช้ Roboflow ในการทำ Data Augmentation กับข้อมูลตั้งต้นและสร้างรูปภาพเป็นรูปภาพใหม่ๆ เพื่อเพิ่มความหลากหลายและจำนวนข้อมูลได้ โดยในขั้นตอนนี้ ผู้วิจัยเลือกใช้วิธีการ กลับด้านรูปภาพ (Flip), ตัดบางส่วนของภาพ (Crop), หมุนรูปภาพ (Rotation), ปรับเฉือนรูปภาพ (Shear), ปรับแสงสว่าง (Brightness) และ เพิ่มสิ่งรบกวนลงไปในภาพ (Noise) ก่อนนำไปสร้างเป็นชุดข้อมูลเพื่อฝึกฝนแบบจำลองในขั้นตอนต่อไป จากผลการทำ Labelling และ Data Augmentation โดยใช้เครื่องมือ Roboflow นี้ ทำให้ได้ชุดข้อมูลที่มีรูปภาพทั้งหมด 3000 รูปภาพ และมี label ที่แตกต่างกันทั้งหมด 11 ประเภท ยานพาหนะ สำหรับใช้ในการฝึกฝนระบบรู้จำประเภทยานพาหนะ ตัวอย่างของภาพในชุดข้อมูลที่สร้างแสดงดังภาพประกอบที่ 4



รูปภาพที่ 4 ตัวอย่างภาพยานพาหนะในชุดข้อมูลที่สร้างขึ้น

3. ระบบตรวจจับยานพาหนะ (Vehicle Detection)

สำหรับในขั้นตอนการตรวจจับวัตถุที่เป็นยานพาหนะ ผู้วิจัยได้เลือกใช้หลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน อย่าง 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 จึงต้องทำงานฝึกฝนระบบด้วยชุดข้อมูลที่สร้างขึ้นมาในขั้นตอนก่อนหน้านี้นี้ ให้ระบบสามารถตรวจจับและทำนายประเภทของยานพาหนะได้ทั้งหมด 11 ประเภทตามที่กำหนดในชุดข้อมูล โดยเลือกฝึกฝนด้วย pretrained weight ที่มีโครงสร้างแตกต่างกันสามตัวได้แก่ yolov8n, YOLOv8m และ YOLOv8x ซึ่งเป็น weight ที่ได้จากการฝึกฝนโดยใช้ชุดข้อมูล COCO val2017 โดยกำหนดพารามิเตอร์ batch = 16 และ epoch = 100 และเลือก weight ที่ดีที่สุดของแต่ละตัวไว้ใช้สำหรับทดสอบระบบต่อไป จากผลของการฝึกฝนข้อมูลพบว่า การเลือกใช้ YOLOv8x เป็น weight ในการฝึกฝน ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า mAP50 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 97 เปอร์เซ็นต์ และค่า mAP50-95 เฉลี่ยรวมทุกประเภทยานพาหนะอยู่ที่ประมาณ 81.7 เปอร์เซ็นต์ ดังแสดงในภาพประกอบที่ 5 และ confusion matrix ของการทำนายประเภทของยานพาหนะแสดงดังภาพประกอบที่ 6

```

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

```

ภาพประกอบที่ 5 ภาพรวมการฝึกฝนระบบ ด้วย YOLOv8x weight และชุดข้อมูลยานพาหนะที่สร้างขึ้น




ภาพประกอบที่ 6 confusion matrix แสดงผลการทำนายประเภทยานพาหนะของชุดข้อมูลที่ฝึกฝน

4. การติดตามยานพาหนะ (Vehicle Tracking)

สำหรับระบบติดตามยานวัตถุเลือกใช้ ผู้วิจัยจะใช้ระบบติดตามของ BotSORT และ ByteTrack ที่มีการจัดเตรียมไว้ใน repository ของ YOLOv8 อยู่แล้ว เป็นระบบติดตามยานพาหนะ โดยจะใช้ระบบติดตามทั้ง 2 ตัวดังกล่าวทำงานร่วมกับระบบตรวจจับยานพาหนะที่ใช้โครงสร้างของ YOLOv8 และ custom weight ที่ได้จากการฝึกฝนระบบด้วยชุดข้อมูลที่สร้างขึ้น (Local Dataset) ระบบตรวจจับและติดตามยานพาหนะที่สร้างขึ้นมานี้ จะถูกนำไปประยุกต์ใช้ในขั้นตอนการนับยานพาหนะและวัดผลการทดสอบระบบต่อไป

5. การนับปริมาณจราจรและจำแนกประเภทของยานพาหนะ (Vehicle Counting and Classification)

ในการนับและจำแนกประเภทของยานพาหนะ จะใช้ผลลัพธ์ที่ได้จากขั้นตอนการตรวจจับและติดตามยานพาหนะ นั่นคือ Bounding boxes และ Class Probabilities เป็นพารามิเตอร์สำหรับถอดข้อมูลของยานพาหนะแต่ละคัน ในการนับยานพาหนะ จะใช้วิธีการสร้างเส้นอ้างอิงขึ้นบนถนนตามแนวกว้างของถนนในภาพ โดยใช้ OpenCV Library และทำการกำหนดจุดอ้างอิงบน Boundary Box ของยานพาหนะแต่ละคันที่ได้จากขั้นตอนการตรวจจับและติดตามยานพาหนะก่อนหน้า โดยใช้จุดกึ่งกลางของภาพยานพาหนะในการอ้างอิงตำแหน่งของยานพาหนะ และเพื่อเพิ่มความแม่นยำในการนับยานพาหนะ ผู้วิจัยได้สร้างเป็นพื้นที่ในการตรวจนับยานพาหนะ โดยทำการกำหนดเส้น offset = 15 ทั้งสองด้านของเส้นอ้างอิงดังแสดงตัวอย่างในภาพประกอบที่ 7 ระบบนับยานพาหนะที่สร้างขึ้นนี้ จะทำการนับยานพาหนะยานพาหนะ เมื่อจุดอ้างอิงของยานพาหนะ เคลื่อนที่ผ่านกับเส้นอ้างอิงที่สร้างขึ้นในแต่ละรูป หรือเมื่อตำแหน่งของจุดอ้างอิงของยานพาหนะเคลื่อนที่ไปอยู่ในพื้นที่ของเส้นอ้างอิง ระบบจะทำการเก็บข้อมูลพารามิเตอร์ของยานพาหนะคันนั้นๆ คือข้อมูลประเภทของยานพาหนะและจำนวนสะสมของยานพาหนะประเภทนั้นๆ แล้วแสดงผลและบันทึกผลในรูปแบบข้อความบนภาพวิดีโอดังแสดงตัวอย่างในภาพประกอบที่ 7 (แสดงผลลัพธ์บริเวณมุมบนซ้ายของภาพ)



ภาพประกอบที่ 7 การกำหนดเส้นอ้างอิงในการนับยานพาหนะบนภาพ

6. การวัดผลการทดลอง (Evaluation)

การทดสอบระบบที่สร้างขึ้น ผู้วิจัยได้เลือกใช้ตัวชี้วัดค่าความแม่นยำ (Accuracy) สำหรับวัดผลระบบนับจำนวนยานพาหนะ และใช้ตัวชี้วัดค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ Mean Absolute Percentage Error (MAPE) สำหรับวัดผลระบบจำแนกประเภทของยานพาหนะ โดยเป็นการเปรียบเทียบผลลัพธ์จำนวนยานพาหนะแบบแยกประเภทที่ได้จากระบบกับผลของข้อมูลเฉลย (ground truth) ที่ได้จากการถอดข้อมูลด้วยมือ โดยรูปแบบการแสดงผลการทดลองดังกล่าวนี้ จะแสดงผลในหัวข้อถัดไป

ผลการวิจัยและอภิปรายผลการวิจัย

ก่อนที่จะทำการทดสอบระบบกับวิดีโอที่จัดเตรียมไว้ทุกสภาพการณ์ เนื่องจากตัวโมเดลของ YOLOv8 เพิ่งถูกปล่อยออกมาให้ใช้งานได้ไม่นานนัก ยังไม่ได้เป็นที่นิยมอย่างแพร่หลายเหมือน YOLOv5 ผู้วิจัยจึงได้ทดสอบความแตกต่างของระบบตรวจจับและระบบติดตามยานพาหนะที่เลือกใช้ เพื่อตรวจสอบประสิทธิภาพของระบบตรวจจับที่มีแนวโน้มจะให้ผลลัพธ์ที่ดีที่สุด โดย **ตารางที่ 1** แสดงการเปรียบเทียบระหว่างการการระบบตรวจจับที่ใช้โครงสร้างของ YOLOv5 กับ YOLOv8 กับข้อมูลวิดีโอที่ 1 ที่ได้จัดเตรียมไว้ จะเห็นได้ว่า ในภาพรวมแล้ว YOLOv8 ทำงานได้ดีกว่ามากในเรื่องของจำนวนยานพาหนะที่ตรวจจับได้มีค่าความแม่นยำสูงถึง 97 เปอร์เซ็นต์ มากกว่า YOLOv5 ที่ทำได้ประมาณ 78 เปอร์เซ็นต์ หากพิจารณาเรื่องความแม่นยำในการทำนายประเภทของยานพาหนะ (เนื่องจาก YOLO ถูกฝึกฝนให้ทำนายยานพาหนะได้เพียง 4 ประเภทหลักๆดังแสดงในตาราง) ตัว YOLO ทั้ง 2 เวอร์ชัน อาจจะยังทำงานกับข้อมูลที่เลือกใช้ไม่ได้ดีมากนัก โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ที่มีค่าสูงมากๆ และถึงแม้ว่าผลลัพธ์ที่ได้ของ YOLOv8+ByteTrack ค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ที่สูงกว่า YOLOv8+BotSORT แต่มีข้อสังเกตที่ว่า YOLOv8 สามารถตรวจจับยานพาหนะที่เป็นประเภท motorcycle ได้ ในขณะที่ YOLOv5 ไม่สามารถตรวจจับได้เลย ทำให้ผู้วิจัยเลือกที่จะศึกษาและใช้ YOLOv8 เป็นโครงสร้างหลักของการทำงานของระบบ

ตารางที่ 1 ผลการทดสอบระบบการนับยานพาหนะแบบแยกสายประเภทเปรียบเทียบกับข้อมูลเฉลี่ย

Class	Ground Truth	YOLOv5+ DeepSORT			YOLOv8x+ByteTrack		
		Counting	Accuracy rate	MAPE	Counting	Accuracy rate	MAPE
car	407	489	-	1646.4	556	-	1885.7
motorcycle	28	0		100.0	4		98.9
bus	2	81		161.3	65		109.7
truck	343	35		85.8	134		45.7
Total	780	605	77.53	-	759	97.27	-
MAPE		-		498.4		-	535.0

นอกจากนั้น ผู้วิจัยยังได้ทำการทดสอบการทำงานของระบบตรวจจับยานพาหนะที่ถูกฝึกฝนด้วยชุดข้อมูลยานพาหนะในประเทศไทยทั้ง 11 ประเภทที่สร้างขึ้น โดยมี weight ที่ใช้ในการฝึกฝนของ YOLOv8 ที่แตกต่างกัน และทดสอบการทำงานร่วมกับระบบติดตามทั้ง 2 ตัว (ByteTrack และ BotSORT) ทำการทดสอบเบื้องต้นกับข้อมูลวิดีโอที่ 1 เช่นเดิม โดยมีสมมติฐานว่า ประสิทธิภาพการทำงานของ weight ที่เลือกใช้ จะมีความสอดคล้องกับผลลัพธ์ที่ได้จากการฝึกฝนระบบ กล่าวคือ ระบบที่เลือกใช้ YOLOv8x จะให้ความแม่นยำในการนับยานพาหนะมากที่สุด จาก **ตารางที่ 2** และ **ตารางที่ 3** ตามลำดับ

ตารางที่ 2 แสดงผลการเปรียบเทียบการทำงานของ yolov8n, YOLOv8m และ YOLOv8x กับระบบติดตามวัตถุ ByteTrack

Class	Ground Truth	YOLOv8n+ByteTrack			YOLOv8m+ByteTrack			YOLOv8x+ByteTrack		
	Counting	Counting	Accuracy Rate	Absolute Percentage Error	Counting	Accuracy Rate	Absolute Percentage Error	Counting	Accuracy Rate	Absolute Percentage Error
Motorcycle	28	4	-	85.7	16	-	42.9	16	-	42.9
Passenger Car	376	364		3.2	433		15.2	395		5.1
Van	31	51		64.5	63		103.2	40		29.0
Light Truck	247	184		25.5	192		22.3	224		9.3
Medium Truck	37	6		83.9	11		70.5	10		73.2
Heavy Truck	16	9		43.8	2		87.5	4		75.0
Light Bus	2	0		100.0	0		100.0	0		100.0
Medium Bus	0	4		-	5		-	8		-
Heavy Bus	0	1		-	3		-	1		-
Semi-Trailer	39	4		89.7	24		38.5	27		30.8
Full Trailer	4	0		100.0	1		75.0	0		100.0
Total	780	627		80.35	-		750	96.11		-
MAPE	-		66.3	-		61.7	-		51.7	

ตารางที่ 3 แสดงผลการเปรียบเทียบการทำงานของ yolov8n, YOLOv8m และ YOLOv8x กับระบบติดตามวัตถุ BotSORT

Class	Ground Truth	YOLOv8n+ByteTrack			YOLOv8m+ByteTrack			YOLOv8x+ByteTrack		
	Counting	Counting	Accuracy Rate	Absolute Percentage Error	Counting	Accuracy Rate	Absolute Percentage Error	Counting	Accuracy Rate	Absolute Percentage Error
Motorcycle	28	13	-	53.6	24	-	14.3	26	-	7.1
Passenger Car	376	378		0.5	502		33.5	465		23.7
Van	31	48		54.8	53		71.0	40		29.0
Light Truck	247	177		28.3	144		41.7	171		30.8
Medium Truck	37	3		92.0	14		62.5	12		67.9
Heavy Truck	16	7		56.3	1		93.8	3		81.3
Light Bus	2	0		100.0	0		100.0	0		100.0
Medium Bus	0	6		-	10		-	12		-
Heavy Bus	0	2		-	1		-	7		-
Semi-Trailer	39	5		87.2	27		30.8	27		30.8
Full Trailer	4	0		100.0	0		100.0	0		100.0
Total	780	639		81.89	-		776	99.44		-
MAPE	-		63.6	-		60.8	-		52.3	

จะเห็นได้ว่าการทำงานของ YOLOv8x และ YOLOv8m มีความแม่นยำที่สูงใกล้เคียงกัน โดย YOLOv8m อาจมีความแม่นยำในการตรวจจับมากกว่า YOLOv8x อยู่เล็กน้อย แต่หากพิจารณาถึงความแม่นยำในการจำแนกประเภท จะเห็นได้อย่างชัดเจนว่า YOLOv8x มีประสิทธิภาพที่สูงกว่า ทั้งการทำงานร่วมกับ ByteTrack และ BotSORT โดยมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) น้อยกว่า YOLOv8m ดังนั้นสำหรับการพิจารณาการทำงานของระบบกับข้อมูลวิดีโออื่น ๆ ต่อไปนั้น ทางผู้วิจัยจะเลือกใช้ YOLOv8x เป็น weight ในการทำงานร่วมกับระบบติดตามวัตถุทั้งสองตัวและแสดงผลออกมาในรูปแบบตารางเปรียบเทียบการทำงานของ YOLOv8x+ByteTrack และ YOLOv8x+BotSORT โดยภาพตัวอย่างของผลลัพธ์ที่ได้แสดงดังภาพประกอบที่ 8



ภาพประกอบที่ 8 ตัวอย่างผลลัพธ์ที่ได้จากการทำงานของระบบนับและจำแนกประเภทยานพาหนะที่นำเสนอ

จะเห็นได้ว่า ระบบที่การตรวจจับที่ผ่านการฝึกฝนด้วยชุดข้อมูลของยานพาหนะทั้ง 11 ประเภทที่สร้างขึ้นมาช่วยให้ระบบสามารถตรวจจับยานพาหนะได้อย่างอยากหลายประเภทตามต้องการ และผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจรในสภาพการณ์ต่างๆแสดงดังตารางที่ 4 ถึงตารางที่ 9

ตารางที่ 4 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)
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	8		-	12		-
Heavy Bus	0	1		-	7		-
Semi-Trailer	39	27		30.77	27		30.77
Full Trailer	4	0		100.00	0		100.00
Total	780	725		92.91	-		763
MAPE	-	-	-	51.69	-	-	52.28

ตารางที่ 5 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางคืน (จุดสำรวจตำแหน่งเดียวกันกับวิดีโอที่ 1) มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)
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	-		616
MAPE	-	-	-	104.34	-	-	117.81

ตารางที่ 6 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งออกจากจุดสำรวจ ช่วงเวลากลางวัน แสงค่อนข้างเยอะ การจราจรใช้ความเร็วในการขับซึ่งสูงมีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)
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	-		935
MAPE	-	-	-	27.06	-	-	34.74

ตารางที่ 7 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ
ช่วงเวลากลางวัน บริเวณพื้นถนนมีเงาตกกระทบไม่สม่ำเสมอ มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)
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	-		601
MAPE	-	-	-	51.22	-	-	52.78

ตารางที่ 8 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรปกติ ทิศทางมุ่งเข้าสู่จุดสำรวจ
ช่วงเวลากลางวัน แสงน้อย มองเห็นยานพาหนะได้ชัดเจน มีความละเอียดของภาพระดับ HD (720p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	Absolute Percentage Error (%)
Motorcycle	165	164	-	0.61	164	-	0.61
Passenger Car	336	340		1.19	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	4		-	2		-
Semi-Trailer	36	18		50.00	16		55.56
Full Trailer	3	0		100.00	0		100.00
Total	761	765		99.48	-		715
MAPE	-	-	-	55.80	-	-	72.70

ตารางที่ 9 แสดงผลการเปรียบเทียบการทำงานของระบบกับวิดีโอการจราจร สภาพการจราจรค่อนข้างติดขัดเล็กน้อยจากการหยุดรอสัญญาณไฟจราจร ที่ศทางมุ่งเข้าสู่จุดสำรวจ ช่วงเวลากลางวัน มีความละเอียดของภาพระดับ Full HD (1080p)

Class	Ground Truth	YOLOv8x+ByteTrack			YOLOv8x+BotSORT		
	Counting	Counting	Accuracy (%)	Absolute Percentage Error (%)	Counting	Accuracy (%)	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	2		-	0		-
Heavy Truck	0	0		-	0		-
Light Bus	0	0		-	0		-
Medium Bus	3	3		0.00	4		33.33
Heavy Bus	0	1		-	0		-
Semi-Trailer	0	0		-	0		-
Full Trailer	0	0		-	0		-
Total	291	278		95.53	-		287
MAPE	-	-	-	12.93	12.93	-	21.63

ตารางที่ 10 ผลสรุปผลการเปรียบเทียบการทำงานของระบบของการจราจรในทุกๆสภาพการณ์ โดยแสดงในรูปแบบความแม่นยำในการนับยานพาหนะทั้งหมด และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ในการจำแนกประเภทของยานพาหนะทุกประเภท

Evaluation Metrics	Situation	YOLOv8x + ByteTrack	YOLOv8x + BotSORT
Accuracy of Vehicle Counting (%)	Incoming traffic/ Bright Light/ AM period/ HD 720p	92.91	97.78
	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	93.96
	Incoming traffic/ congestion/ AM period/ Full HD 1080p	95.53	98.63
	Average		89.50
Mean Absolute Percentage Error (MAPE) (%)	Incoming traffic/ Bright Light/ AM period/ HD 720p	51.69	52.28
	Incoming traffic/ PM period/ HD 720p	104.34	117.81
	Outgoing traffic / AM period/ HD 720p	27.06	34.74
	Incoming traffic with road shadow/ AM period/ HD 720p	51.22	52.78
	Incoming traffic/ vehicles are seen more clearly/ AM period/ HD 720p	55.80	72.70
	Incoming traffic/ congestion/ AM period/ Full HD 1080p	12.93	21.63
	Average		50.51

โดยภาพรวมแล้ว ระบบตรวจจับและจำแนกประเภทของยานพาหนะที่นำเสนอนี้ สามารถนับยานพาหนะจากภาพวิดีโอที่เลือกมาใช้ในการทดสอบได้อย่างแม่นยำสภาพการณ์ที่หลากหลาย สามารถนำไปใช้จำแนกยานพาหนะได้ครอบคลุมทุกประเภทของยานพาหนะที่ใช้อยู่ทั่วไปในประเทศไทย แต่ยังคงมีข้อผิดพลาดในเรื่องความแม่นยำในการจำแนกประเภทอยู่บ้าง สำหรับยานพาหนะบางประเภท จากตารางที่ 10 สามารถสรุปได้ว่าระบบตรวจจับและจำแนกประเภทของยานพาหนะที่ใช้โครงสร้างระบบตรวจจับของ YOLOv8x ทำงานร่วมกับระบบติดตาม ByteTrack ให้ผลลัพธ์ในการทำงานกับภาพวิดีโอทุกสภาพการณ์โดยเฉลี่ยที่ดีที่สุด มีความแม่นยำในการนับยานพาหนะทั้งหมดโดยเฉลี่ยของทุกวิดีโออยู่ที่ประมาณ 90 เปอร์เซ็นต์ อาจมีค่าความแม่นยำในการนับยานพาหนะน้อยกว่าการใช้โครงสร้างระบบตรวจจับของ YOLOv8x ทำงานร่วมกับระบบติดตาม BotSORT เพียงเล็กน้อย ประมาณ 1 เปอร์เซ็นต์ แต่สามารถจำแนกประเภทของยานพาหนะได้แม่นยำกว่ามาก โดยมีความแม่นยำเฉลี่ยในการจำแนกประเภทของยานพาหนะทุกประเภทของทุกวิดีโออยู่ที่ประมาณ 51 เปอร์เซ็นต์ ซึ่งมีค่าน้อยกว่าการใช้โครงสร้างระบบตรวจจับของ YOLOv8x ทำงานร่วมกับระบบติดตาม BotSORT อยู่ที่ประมาณ 8 เปอร์เซ็นต์

สรุปผลการวิจัย

งานวิจัยนี้นำเสนอระบบตรวจจับและจำแนกประเภทของยานพาหนะ บนถนนเขตในเมืองของประเทศไทย ที่ใช้หลักการประสาทเทียมแบบคอนโวลูชันของ YOLOv8 เป็นอัลกอริทึมในการตรวจจับยานพาหนะ โดยใช้หลักการการเรียนรู้ของเครื่องในการฝึกฝนระบบตรวจจับยานพาหนะกับชุดข้อมูลที่สร้างขึ้น ให้สามารถตรวจจับและทำนายประเภทของยานพาหนะได้อย่างครอบคลุมประเภทยานพาหนะที่ใช้ในประเทศไทย และเลือกใช้ ByteTrack และ BotSORT เป็นอัลกอริทึมในการติดตามยานพาหนะเพื่อทำการเปรียบเทียบและหาแบบจำลองที่ดีที่สุด แล้วจึงประยุกต์ใช้วิธีการนับยานพาหนะโดยการสร้างเส้นอ้างอิงด้วย OpenCV ในการนับยานพาหนะที่เคลื่อนที่ผ่าน โดยระบบที่นำเสนอนี้ได้ผลการทดลองมีค่าความแม่นยำในการนับยานพาหนะที่ดีที่สุด มีค่าความแม่นยำในการนับยานพาหนะเฉลี่ยอยู่ที่ประมาณ 90 เปอร์เซ็นต์และมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ในการจำแนกประเภทของยานพาหนะทุกประเภทอยู่ที่ประมาณ 51 เปอร์เซ็นต์ ทั้งนี้ การนับยานพาหนะแบบแยกประเภทอาจยังมีประสิทธิภาพที่ไม่ดีมากนัก เนื่องจากชุดข้อมูลที่ใช้ในการฝึกฝนอาจยังมีความหลากหลายและจำนวนข้อมูลไม่มากเพียงพอ ในการพัฒนาต่อยอดในอนาคต อาจสามารถปรับปรุงชุดข้อมูลยานพาหนะท้องถิ่นของประเทศไทยที่สร้างขึ้นมาให้ดียิ่งขึ้น เพื่อใช้ในการฝึกฝนระบบให้สามารถจดจำและจำแนกประเภทของยานพาหนะได้อย่างแม่นยำมากขึ้นต่อไป

จากผลการเปรียบเทียบการทำงานของระบบนับและจำแนกประเภทของยานพาหนะกับวิดีโอการจราจรในสภาพการณ์ต่างๆข้างต้น พบว่าทั้งระบบของ YOLOv8x+ByteTrack และ YOLOv8x+BotSORT สามารถตรวจจับยานพาหนะได้มีความแม่นยำค่อนข้างสูง และมีประสิทธิภาพใกล้เคียงกัน โดยส่วนใหญ่ (ไม่รวมวิดีโอที่ 2) มีความแม่นยำในการนับจำนวนยานพาหนะทั้งหมดอยู่ที่ประมาณ 91 – 99 เปอร์เซ็นต์ ไม่ว่าจะเป็นภาพวิดีโอที่ยานพาหนะวิ่งเข้าสู่หรือออกจากตำแหน่งบันทึกภาพ (ทำงานได้ค่อนข้างดีทั้งกับรูปถ่ายด้านหน้าและด้านหลังของยานพาหนะ) หรือวิดีโอที่มีเงาตกกระทบบนพื้นผิวดถนนแบบไม่สม่ำเสมอ หรือจะ

เป็นช่วงถนนที่การจราจรเคลื่อนตัวไปอย่างล่าช้า ระบบที่นำเสนอสามารถตรวจจับและนับยานพาหนะได้เป็นอย่างดี มีเพียงผลลัพธ์ที่ได้ภาพวิดีโอที่ 2 ที่มีความแม่นยำในการนับอยู่ที่ประมาณ 66 เปอร์เซ็นต์ และมีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) สูงกว่าผลการทดสอบของวิดีโออื่นๆ อยู่ที่ประมาณ 104 และ 118 เปอร์เซ็นต์ เนื่องจากเป็นสภาพการจราจรที่บันทึกในช่วงเวลากลางคืน ส่งผลให้ยานพาหนะในภาพมีความคมชัดลดลงไปจากตอนกลางวันมาก และในช่วงเวลากลางคืน ยานพาหนะทุกคันจำเป็นต้องเปิดไฟหน้ารถระหว่างการขับขี่ เมื่อบันทึกด้วยกล้องที่มีความคมชัดระดับ HD (720p) ทำให้ภาพของไฟหน้ายานพาหนะทุกคัน กระจายออกมาบดบังรูปลักษณะของยานพาหนะซ้ำกว่าเดิม ซึ่งเป็นอุปสรรคต่อและความท้าทายต่อการตรวจจับยานพาหนะมาก อีกทั้งอาจเป็นเพราะรูปภาพที่อยู่ในชุดข้อมูลที่ใช้ฝึกฝนระบบนั้น ส่วนใหญ่เป็นภาพของยานพาหนะที่ยืนติดในตอนกลางวัน เห็นรูปลักษณะและสีของยานพาหนะได้ชัดเจน ส่งผลให้ระบบนับยานพาหนะทำงานกับภาพวิดีโอที่มีแสงน้อยได้ไม่ดีนก

เมื่อพิจารณาผลการจำแนกประเภทของยานพาหนะ พบว่าระบบที่นำเสนอสามารถจำแนกยานพาหนะได้ทุกประเภทและมีผลการจำแนกส่วนใหญ่เป็นที่น่าพึงพอใจ โดยเฉพาะยานพาหนะประเภท รถจักรยานยนต์, รถยนต์นั่งส่วนบุคคลไม่เกิน 7 ที่นั่ง, รถยนต์นั่งส่วนบุคคลเกิน 7 ที่นั่งและ รถบรรทุกขนาดเล็ก 4 ล้อ ที่มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ที่ค่อนข้างต่ำ อาจเป็นเพราะในภาพวิดีโอที่ใช้ทดสอบเป็นปริมาณจราจรโดยปกติบนท้องถนน ซึ่งส่วนใหญ่มีการใช้งานยานพาหนะส่วนตัวทั้ง 4 ประเภทดังกล่าวมากกว่ายานพาหนะประเภทอื่นๆที่เหลือ จึงทำให้เห็นผลลัพธ์ในการตรวจจับได้ชัดเจนมากกว่า รวมทั้งข้อมูลยานพาหนะในชุดข้อมูลที่สร้างขึ้นนั้น มีจำนวนของยานพาหนะทั้ง 4 ประเภทนี้มากกว่ายานพาหนะประเภทที่เหลือมาก ส่งผลให้ระบบที่นำเสนอนี้ ทำงานได้ดีกับยานพาหนะทั้ง 4 ประเภทนี้มากเป็นพิเศษ และอาจเป็นเพราะเนื่องจากยานพาหนะบางประเภทมีลักษณะภายนอกที่คล้ายคลึงกันใบบางมุม ยกตัวอย่างเช่น ยานพาหนะประเภทรถบรรทุกขนาดกลางและขนาดใหญ่ หรือ รถโดยสารขนาดกลางและขนาดใหญ่ หรือแม้กระทั่ง รถยนต์นั่งส่วนบุคคลและรถบรรทุกขนาดเล็ก 4 ล้อ จึงทำให้ระบบทำนายผลประเภทของยานพาหนะคลาดเคลื่อนไปได้ และในการทดลองครั้งนี้ ยังมีข้อสังเกตว่า ผลลัพธ์ที่ได้จากการนับยานพาหนะในวิดีโอ 6 ที่มีคุณภาพของรูปภาพมากกว่าวิดีโออื่นๆ (Full HD (1080p)) มีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (MAPE) ของยานพาหนะทุกประเภทที่น้อยที่สุด จึงอาจสรุปได้ว่าการเลือกเก็บบันทึกและใช้ข้อมูลภาพวิดีโอที่มีความละเอียดของสูงมากขึ้น จะช่วยให้ระบบการนับยานพาหนะมีความแม่นยำในการจำแนกประเภทของยานพาหนะมากยิ่งขึ้นเช่นกัน

ทั้งนี้ เพื่อให้ระบบทำงานได้แม่นยำมากยิ่งขึ้นสำหรับการพัฒนาต่อยอดในอนาคต ผู้วิจัยแนะนำให้มีการปรับปรุงชุดข้อมูล อาจสามารถทำได้โดยการเพิ่มข้อมูลภาพตั้งต้นของชุดข้อมูลที่ฝึกฝนให้มีความหลากหลายของยานพาหนะแต่ละประเภทมากขึ้น (อาจพิจารณาถึงยานพาหนะที่มีลักษณะเฉพาะท้องถิ่นอย่างรถจักรยานยนต์ 3 ล้อเข้าไปด้วย) และเพิ่มจำนวนข้อมูลภายในชุดข้อมูลให้มากขึ้น รวมทั้งเพิ่มจำนวนของยานพาหนะทุกประเภทให้มีจำนวนใกล้เคียงกันที่สุดเท่าที่จะจัดเตรียมได้ จะช่วยให้ระบบสามารถฝึกฝนการรู้จำรูปลักษณะของยานพาหนะและทำนายประเภทได้อย่างแม่นยำมากขึ้น

กิตติกรรมประกาศ

การจัดทำวิจัยได้รับการสนับสนุนจากบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการนำเสนอผลงานวิจัย ผู้วิจัยจึงขอขอบคุณมา ณ ที่นี้

เอกสารอ้างอิง

- [1.] Redmon J, Divvala S, Girshick R, Farhadi A. You Only Look Once: Unified, Real-Time Object Detection 2016. 779-88 p.
- [2.] Redmon J, Farhadi A. YOLO9000: Better, Faster, Stronger 2017. 6517-25 p.
- [3.] Redmon J, Farhadi A. YOLOv3: An Incremental Improvement. 2018.
- [4.] Bochkovskiy A, Wang C-Y, Liao H-y. YOLOv4: Optimal Speed and Accuracy of Object Detection 2020.
- [5.] Cruz FRG, Santos CJR, Veal LA, editors. 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); 2019 29 Nov.-1 Dec. 2019.
- [6.] Aharon N, Orfaig R, Bobrovsky B-Z. BoT-SORT: Robust associations multi-pedestrian tracking. arXiv preprint arXiv:2206.14651. 2022.
- [7.] Zhang Y, Sun P, Jiang Y, Yu D, Weng F, Yuan Z, et al., editors. 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; 2022: Springer.
- [8.] Seenoung N, Watchareeruetai U, Nuthong C, Khongsomboon K, Ohnishi N, editors. A computer vision based vehicle detection and counting system. 2016 8th International Conference on Knowledge and Smart Technology (KST); 2016 3-6 Feb. 2016.
- [9.] Liu F, Zeng Z, Jiang R. A video-based real-time adaptive vehicle-counting system for urban roads. PLOS ONE. 2017;12(11):e0186098.
- [10.] Liu C, Huynh DQ, Sun Y, Reynolds M, Atkinson S. A Vision-Based Pipeline for Vehicle Counting, Speed Estimation, and Classification. IEEE Transactions on Intelligent Transportation Systems. 2021;22(12):7547-60.
- [11.] Chauhan MS, Singh A, Khemka M, Prateek A, Sen R, editors. Embedded CNN based vehicle classification and counting in non-laned road traffic 2019 2019: ACM.
- [12.] A. Alsanabani A, A. Ahmed M, M. Al Smadi A, editors. Vehicle Counting Using Detecting-Tracking Combinations: A Comparative Analysis 2020 2020: ACM.
- [13.] Harjoko A, Candradewi I, Bakhtiar AAA, editors. Intelligent Traffic Monitoring Systems: Vehicles Detection, Tracking, And Counting using Haar Cascade Classifier and Optical Flow 2017 2017: ACM.