



วารสารวิศวกรรมศาสตร์และนวัตกรรม Journal of Engineering and Innovation

บทความวิจัย

การประยุกต์ใช้โมเดลการตรวจจับและติดตามยานพาหนะในการประมาณค่าตัวแปรกระแสจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

Application of vehicle detection and tracking model: estimation of traffic flow variable based on Moving Observer Method

พงศกร เปรมศรี^{1*} สุทธิพงษ์ มีไย¹ พีรพล สิทธิวิจารณ์²

¹ สาขาวิชาวิศวกรรมขนส่ง สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี อำเภอเมือง จังหวัดนครราชสีมา 30000

² คณะโลจิสติกส์ มหาวิทยาลัยบูรพา อำเภอเมือง จังหวัดชลบุรี 20131

Pongsakorn Premsi^{1*} Sutthipong Meeyai¹ Peerapol Sittivijan²

¹ School of Transportation Engineering, Institute of Engineering, Suranaree University of Technology Nakhon Ratchasima 30000

² Faculty of Logistics, Burapha University Chonburi 20131

* Corresponding author.

E-mail: m6202446@gmail.ac.th; Telephone: 091-7652465

วันที่รับบทความ 19 ตุลาคม 2565; วันที่แก้ไขบทความ ครั้งที่ 1 26 พฤศจิกายน 2565; วันที่ตอบรับบทความ 7 มกราคม 2566

บทคัดย่อ

การสำรวจสภาพจราจรเป็นรากฐานสำคัญที่ใช้ในการวิเคราะห์ ออกแบบ วางแผน ประเมินและบริหารจัดการด้านการขนส่งและจราจร โดยวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะหรือ Moving Observer Method (MOM) เป็นวิธีการสำรวจจราจรระดับมหภาคที่ถูกใช้อย่างแพร่หลายซึ่งง่ายต่อการใช้งาน ประหยัดเวลาและค่าใช้จ่ายในการดำเนินการ งานวิจัยนี้ได้นำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้ในการสำรวจ โดยใช้ YOLOv7 architecture ในการตรวจจับยานพาหนะ, StrongSORT architecture ในการติดตามยานพาหนะและเทคนิค Canny Edge กับ Hough Transform ในการตรวจจับเส้นจราจรเพื่อนำมาจำแนกประเภทและรูปแบบเคลื่อนที่ของยานพาหนะแล้วนำผลลัพธ์ที่ได้ไปใช้ในการประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยทดลองใช้กับชุดข้อมูลสำรวจบนถนนระหว่างเมือง 5 ช่วงถนนในประเทศไทยที่มี 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางและมีความยาว 2 ถึง 5 กิโลเมตร โดยผลประเมินประสิทธิภาพของโมเดลในการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะประกอบด้วย จำนวนรถทิศทางตรงข้าม รถที่แซงรถสำรวจและรถที่ถูกรถสำรวจแซงมีค่า F1-score เท่ากับ 93.25, 94.79, 64.62% ตามลำดับ ส่งผลให้ประสิทธิภาพในการประมาณค่าตัวแปรกระแสจราจรตามวิธี MOM ที่ประกอบด้วย อัตราการไหล ความเร็วเฉลี่ยและความหนาแน่นกระแสจราจรเมื่อเปรียบเทียบกับการใช้ข้อมูลจริงพบว่า มีความคลาดเคลื่อนโดยสัมบูรณ์เฉลี่ยเท่ากับ 2.36, 0.73 และ 2.86% ตามลำดับ และมีค่าความคลาดเคลื่อนสัมบูรณ์สูงสุดเท่ากับ 7.88, 5.80 และ 7.65% ตามลำดับ

คำสำคัญ

ตัวแปรกระแสจราจร การสำรวจจราจร เทคนิคการเรียนรู้เชิงลึก การตรวจจับยานพาหนะ การติดตามยานพาหนะ

Abstract

Traffic surveys are the foundation for analysis, design, planning, assessment and management of traffic and transportation. The Moving Observer Method (MOM) is widely used for macroscopic traffic flow variable survey which is easy to apply and, cost and time efficient. This study applied artificial Intelligence (AI) techniques for traffic surveys, using YOLOv7 architecture for vehicle detection, StrongSORT architecture for vehicle tracking, Canny Edge and Hough Transform for lane line detection to classify vehicle type and movement for estimating traffic flow variables based on MOM. The experiment

was implemented with datasets from 5 intercity routes in Thailand, single carriageway road with 2 lanes, length 2 to 5 km. The results indicate that the performance of vehicle type and movement classification (number of opposing vehicles, vehicles overtaking the test car, vehicles passed by the test car) was F1-score of 93.25, 94.79, and 64.62% respectively. In summary, the performance of traffic flow variable estimation based on MOM (flow rate, mean speed and density) compared to the actual data was mean absolute percentage error of 2.36, 0.73 and 2.86% respectively and highest absolute percentage error was 7.88, 5.80 and 7.65% respectively.

Keywords


traffic flow variable; moving observer method; deep learning; vehicle detection; vehicle tracking

1. คำนำ

การสำรวจสภาพจราจร (Traffic Survey) เป็นหนึ่งส่วนสำคัญที่ต้องคำนึงถึงเพื่อนำข้อมูลการจราจรที่ถูกต้อง มีความน่าเชื่อถือและรวดเร็วไปใช้ในการวิเคราะห์ วางแผน ออกแบบในการบริหารจัดการด้านการขนส่งและจราจร ไม่ว่าจะเป็นการนำไปใช้กับเทคโนโลยีระบบขนส่งและจราจรอัจฉริยะ (Intelligent transportation system) ในการบริหารจัดการการจราจรและอุบัติเหตุ การออกแบบโครงสร้างพื้นฐาน และการวิเคราะห์ข้อมูลจราจรและอุบัติเหตุเชิงลึกเพื่อเพิ่มประสิทธิภาพในด้านความปลอดภัยและความสะดวกสบายต่อผู้ใช้ท้องถนน เป็นต้น ปัจจุบันเทคโนโลยีปัญญาประดิษฐ์หรือ Artificial Intelligence (AI) ในด้าน Computer vision มีบทบาทอย่างมากในการประมวลผลข้อมูลจากกล้องวิดีโอหรือเซนเซอร์เพื่อตรวจจับและวิเคราะห์รูปแบบและพฤติกรรมของการจราจร เช่น การจำแนกประเภทยานพาหนะ การตรวจจับยานพาหนะเพื่อประมาณค่าอัตราการไหลและความเร็ว เป็นต้น ซึ่งทำให้ได้ข้อมูลที่มีความถูกต้องแม่นยำและสามารถนำไปใช้งานได้ในแบบเรียลไทม์ โดยทั่วไปการสำรวจจราจรระดับมหภาค (Macroscopic traffic flow) เพื่ออธิบายพฤติกรรมของผู้ใช้ถนนโดยรวมจะถูกสำรวจในรูปแบบเฉพาะจุด (Stationary observer) ซึ่งมีข้อเสียคือ ข้อมูลเป็นแบบเฉพาะจุดซึ่งอาจไม่ครอบคลุมพฤติกรรมจราจรของช่วงถนนสำรวจที่สนใจ ยากต่อการติดตั้งอุปกรณ์เพื่อสำรวจในบางจุด เป็นต้น โดยยังมีวิธีสำรวจจราจรอีกวิธีหนึ่งที่มีชื่อว่า การสำรวจโดยการเคลื่อนที่ของยานพาหนะหรือ Moving Observer Method (MOM) ที่ทำการวิ่งรถสำรวจเพื่อบันทึกข้อมูลจราจรในทิศทางตรงข้ามและทิศทางเดียวกันเพื่อประมาณค่าตัวแปรกระแสจราจร ซึ่งมีข้อดีคือ สามารถประมาณค่าอัตราการไหล ความเร็วและเวลาเฉลี่ยในการ

เดินทางได้พร้อมกัน ไม่จำเป็นต้องติดตั้งอุปกรณ์บนถนน ใช้เวลาสำรวจเพื่อให้ได้ข้อมูลที่อยู่ในระดับความน่าเชื่อถือที่เหมาะสมน้อยกว่าแบบเฉพาะจุด และได้ข้อมูลจราจรเพิ่มเติม เช่น จุดขัดแย้งที่ทำให้จราจรเกิดความผันผวน เป็นต้น [1, 2]

เพื่อประยุกต์ใช้เทคโนโลยีกับการสำรวจจราจรเพื่อช่วยลดจำนวนคน เวลาและค่าใช้จ่ายในการดำเนินการ การศึกษานี้จึงมีวัตถุประสงค์ในการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ด้าน Computer vision ในการพัฒนา (1) โมเดลตรวจจับยานพาหนะเพื่อระบุตำแหน่งและจำแนกประเภทยานพาหนะ (2) โมเดลติดตามการเคลื่อนที่ของยานพาหนะเพื่อใช้ในการจำแนกรูปแบบการเคลื่อนที่ และ (3) โมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อจำแนกเฉพาะยานพาหนะที่สนใจ (เฉพาะวิ่งบนช่องจราจร) และไม่สนใจในการคำนวณโดยใช้โมเดลตรวจจับเส้นสีจราจรในการปรับแต่งกรอบพื้นที่ให้สอดคล้องกับช่องจราจรจริง จากนั้นนำผลลัพธ์ที่ได้จากทั้ง 3 โมเดลไปสร้างโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะเพื่อนับและจำแนกประเภทยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ แล้วนำผลลัพธ์ไปประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยทดลองใช้กับข้อมูลวิดีโอกล้องหน้ารถที่สำรวจบนถนนระหว่างเมืองที่มี 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลาง แล้วทำการประเมินประสิทธิภาพการจำแนกและเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างผลการจำแนกที่ได้จากโมเดลที่นำเสนอกับข้อมูลจริง



รูปที่ 1 ตัวอย่างการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method technique : MOM)

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method : MOM)

วิธีการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method : MOM) ถูกพัฒนาโดย Wardrop and Charlesworth [3] เพื่อใช้สำรวจตัวแปรกระแสจราจรระดับมหภาค โดยทำการวิ่งรถสำรวจเพื่อบันทึกข้อมูลจำนวนรถที่รถสำรวจแซงและถูกแซง รถทิศทางตรงข้าม เวลา และระยะทางในการเดินทางขณะวิ่งสำรวจบนช่วงถนน แล้วนำข้อมูลไปประมาณค่าตัวแปรกระแสจราจรตามสมการความสัมพันธ์ Flow-Speed-Density ของ Greenshield's Model [4] ได้แก่ อัตราการไหล (Flow rate), ความเร็วเฉลี่ย (Mean speed) และความหนาแน่นกระแสจราจร (Density) เป็นต้น โดยสมการประมาณค่าตัวแปรกระแสจราจรตามวิธี MOM มีที่มาจากการศึกษาการพิจารณาการจราจรที่วิ่งบนช่วงถนนที่มีความยาว l และมีอัตราการไหลกระแสจราจร q ในรูปแบบคงที่ และกำหนดสมมติฐานให้รถสำรวจวิ่งตามกระแสจราจร (with the stream) จาก A ไป B มีความเร็วคงที่เท่ากับ v_w และรถสำรวจที่วิ่งต้านกระแสจราจร (against the stream) จาก A ไป B ด้วยความเร็วคงที่ที่ติดลบเท่ากับ v_a จากนั้นนำไปสร้างสมการเพื่อหาอัตราการไหลของรถที่รถสำรวจพบบนช่วงถนนสำรวจในทั้ง 2 กรณี ได้แก่ 1) จำนวนรถที่แซงรถสำรวจ (หรือลบด้วยจำนวนรถที่รถสำรวจแซง) ในกรณีวิ่งตามกระแสจราจร (m_w) และ 2) จำนวนรถที่รถสำรวจพบเจอทั้งหมดใน

กรณีวิ่งต้านกระแสจราจรซึ่งหมายถึงจำนวนรถทิศทางตรงข้ามเมื่อวิ่งจาก B ไป A (m_a) ดังแสดงตัวอย่างการสำรวจในรูปที่ 1 โดยมีสมการอัตราการไหลดังสมการ (1) – (2)

$$\frac{m_w}{t_w} = q \frac{(v_s - v_w)}{v_s} \quad (1)$$

$$\frac{m_a}{t_a} = q \frac{(v_s + v_a)}{v_s} \quad (2)$$

เมื่อแก้สมการ (1) – (2) จะได้สมการใหม่ดังสมการ (3) – (4)

$$m_w = q(t_w - t_{avg}) \quad (3)$$

$$m_a = q(t_a + t_{avg}) \quad (4)$$

จากสมการ (3) – (4) สามารถสร้างสมการหาตัวแปรอัตราการไหล q ของทิศทางนั้นได้ดังสมการ (5) แล้วนำตัวแปรไปแทนในสมการความสัมพันธ์ Flow-Speed-Density เพื่อให้ได้สมการประมาณค่าตัวแปรกระแสจราจรดังสมการ (6) – (8)

$$q = \frac{m_w + m_a}{t_w + t_a} = \frac{(o_w - p_w) + m_a}{t_w + t_a} \quad (5)$$

$$t_{avg} = t_w - \frac{m_w}{q} \quad (6)$$

$$v_s = \frac{l}{t_w - \frac{m_w}{q}} \quad (7)$$

$$k = \frac{q}{v_s} \quad (ค)$$

โดยที่

q = อัตราการไหล (คัน/ชม.)

m_w = จำนวนรถที่แซงรถสำรวจลบกับรถสำรวจแซง (คัน)

m_a = จำนวนรถที่วิ่งทิศทางตรงข้าม (คัน)

o_w	= จำนวนรถที่แข่งรถสำรวจในทิศทางเดียวกัน (คัน)
p_w	= จำนวนรถที่รถสำรวจแข่งในทิศทางเดียวกัน (คัน)
t_w	= เวลาที่ใช้สำรวจในทิศทางเดียวกัน (ชม.)
t_a	= เวลาที่ใช้สำรวจในทิศทางตรงข้าม (ชม.)
t_{avg}	= เวลาเฉลี่ยในการเดินทาง (ชม.)
v_s	= ความเร็วเฉลี่ยในการเดินทาง (กม./ชม.)
l	= ระยะทางในการเดินทาง (กม.)
k	= ความหนาแน่นของกระแสจราจร (คัน/กม.)

โดยเมื่อนำข้อมูลสำรวจจำนวนรถที่วิ่งในการแต่ละรูปแบบ การเคลื่อนที่และเวลาในการสำรวจแต่ละทิศทางเข้าสู่สมการ (5) จะได้ค่าอัตราการไหลในแต่ละทิศทางและเมื่อนำค่าอัตราการไหลไปแทนในการสมการ (6) ถึง (8) จะได้ค่าเวลาเฉลี่ยในการเดินทาง ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรของแต่ละทิศทางบนช่วงถนนที่สำรวจ แล้วจึงนำข้อมูลเหล่านี้ไปใช้ประโยชน์ในการประกอบการวิเคราะห์ ออกแบบ วางแผน ประเมินผลและสร้างแบบจำลองด้านขนส่งและจราจร

2.2 โมเดลตรวจจับยานพาหนะ (Vehicle detection model)

ปัจจุบันมีหลากหลายสถาปัตยกรรมที่ถูกพัฒนาเพื่อใช้งานในด้านการตรวจจับและจำแนกวัตถุบนเทคนิคการเรียนรู้เชิงลึก (Deep learning) โดยสามารถแบ่งออกเป็น 2 ประเภท [5] ได้แก่ 1) Two-stage object detection architectures เป็นสถาปัตยกรรมที่แบ่งโมเดลตรวจจับวัตถุออกจากโมเดลจำแนกวัตถุซึ่งมีข้อดีคือ มีประสิทธิภาพความถูกต้องในการตรวจจับที่สูงแต่ต้องแลกมาด้วยข้อเสียคือ ใช้เวลาประมวลผลที่สูงเช่นกัน ยกตัวอย่างสถาปัตยกรรมเช่น Faster RCNN [6] เป็นต้น และ 2) One-stage object detection architectures เป็นสถาปัตยกรรมที่ทำหน้าที่ทั้งระบุตำแหน่งและจำแนกประเภทของวัตถุในขั้นตอนเดียวซึ่งมีข้อดีคือ มีประสิทธิภาพด้านความเร็วในการประมวลผลที่สูงแต่ก็แลกมาด้วยความถูกต้องในการตรวจจับลดลง ยกตัวอย่างเช่น YOLOv7 [7] เป็นต้น การศึกษานี้เลือกใช้ One-stage object detection architectures โดยเลือกสถาปัตยกรรม YOLOv7 [7] ที่มีการปรับปรุงโครงสร้างสถาปัตยกรรมจาก YOLO

series และสถาปัตยกรรมอื่น ๆ เพื่อเพิ่มประสิทธิภาพความถูกต้องและรวดเร็วในการตรวจจับวัตถุมากยิ่งขึ้น โดยมีการปรับปรุงโดยรวมดังนี้ 1) ปรับปรุง computational block ในส่วน backbone โดยใช้ E-ELAN (Extended Efficient Layer Aggregation Network) ในการขยาย, สุ่ม และควบรวมเพื่อเพิ่มความสามารถในการเรียนรู้ของโครงข่ายให้ดียิ่งขึ้นโดยไม่ทำลาย Gradient path 2) ปรับปรุง model Scaling โดยใช้ compound model scaling เพื่อรักษาคุณสมบัติของโมเดลตั้งต้นและรักษาโครงสร้างที่เหมาะสมที่สุดเมื่อมีการย่อและขยายขนาดของโครงสร้างสถาปัตยกรรม 3) ปรับปรุง re-parameterization convolution strategy ใหม่โดยการใช้ RepConv ที่ไม่มี identity connection 4) ปรับปรุงส่วน head โดยสร้าง lead head เพื่อรับผิดชอบในประมวลผลผลลัพธ์สุดท้าย และ auxiliary head ที่มีหน้าที่ช่วยเหลือในกระบวนการฝึกสอนโมเดล เป็นต้น

2.3 โมเดลการติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle tracking model)

ปัจจุบันมีหลากหลายเทคนิคที่ถูกนำไปใช้ในการติดตามการเคลื่อนที่ของวัตถุ โดยเทคนิคการเรียนรู้เชิงลึก (Deep learning) ได้เข้ามามีบทบาทในการเพิ่มประสิทธิภาพความถูกต้องและแม่นยำให้ดียิ่งขึ้น โดยสามารถแบ่งออกเป็น 2 ประเภท [8] ได้แก่ 1) Detection-based tracking (DBT) เป็นเทคนิคที่นำผลลัพธ์ที่ได้จากโมเดลตรวจจับวัตถุมาใช้ในการหาความสัมพันธ์ของวัตถุระหว่างเฟรมก่อนหน้านี้กับเฟรมปัจจุบันหรือเฟรมในอนาคตเพื่อติดตามการเคลื่อนที่ของวัตถุ โดยยกตัวอย่างสถาปัตยกรรม เช่น DeepSORT [9], StrongSORT [10] เป็นต้น และ 2) Joint-detection and tracking เป็นเทคนิคที่ผสมผสานโมเดลตรวจจับและติดตามวัตถุเข้าด้วยกัน โดยทำการตรวจจับวัตถุทั้งสองเฟรมแล้วนำเทคนิคต่าง ๆ มาใช้ตัดสินความคล้ายคลึงกันของวัตถุของทั้งสองเฟรมในเวลาเดียวกันเพื่อติดตามการเคลื่อนที่ของวัตถุ ยกตัวอย่างสถาปัตยกรรม เช่น FairMOT [11] เป็นต้น จากจุดประสงค์ที่ต้องการตรวจจับและจำแนกประเภทยานพาหนะ การศึกษาจึงนี้เลือกใช้เทคนิคประเภท Detection-based tracking (DBT) โดยเลือกสถาปัตยกรรม StrongSORT [10] ที่มีการปรับปรุงจากสถาปัตยกรรม DeepSORT [9] โดยปรับปรุง

โครงสร้างและกระบวนการประมวลผลภายในได้แก่ Two lightweight, Plug-and-Play, Model-independent และ Appearance-free algorithms เป็นต้น โดยนำเสนอ 1) Appearance-free link model (AFLink) เป็นโมเดลที่ใช้ประโยชน์จากข้อมูลเชิงพื้นที่ (spatial-temporal information) เพื่อทำนายว่าวัตถุทั้งสองนั้นเป็นไอเดียเดียวกัน และ 2) Gaussian-smoothed interpolation (GSI) เป็นกระบวนการประมาณการเคลื่อนที่ของวัตถุที่ขาดหายจากการติดตามซึ่งปรับปรุงจากการใช้ linear interpolation ที่ไม่มีการใช้ motion information ในการประมวลผล และพัฒนาโครงสร้างสถาปัตยกรรมและกระบวนการอื่น ๆ เช่น 1) เปลี่ยน backbone เพื่อเพิ่มประสิทธิภาพของ discriminative features extraction 2) แทนที่ feature bank ด้วย feature updating strategy โดยใช้ exponential moving average (EMA) 3) นำ Enhanced Correlation Coefficient (ECC) มาใช้สำหรับกระบวนการ camera motion compensation 4) ใช้ NSA Kalman algorithm เพื่อเพิ่มประสิทธิภาพการติดตามวัตถุที่มีคุณภาพต่ำและมีมาตราส่วนที่เปลี่ยนแปลง และ 5) ปรับปรุง feature matching โดยใช้ appearance และ motion information และแทนที่ matching cascade ด้วย vanilla global linear assignment เป็นต้น

2.3 โมเดลตรวจจับเส้นสีจราจร (Road Lane line detection)

การตรวจจับเส้นสีจราจรมีวัตถุประสงค์ในการปรับแต่งกรอบพื้นที่ที่สนใจในการคำนวณให้สอดคล้องกับช่องจราจรจริง ปัจจุบันมีหลากหลายเทคนิคให้เลือกใช้ในการตรวจจับเส้นสีจราจร (Road Lane line detection) โดยสามารถแบ่งออกเป็น 3 ประเภท [12] ได้แก่ 1) Feature-based เป็นวิธีการที่ใช้เส้นขอบและคุณลักษณะเฉพาะของวัตถุที่สนใจในการตรวจจับเส้นจราจร เช่น สี ความสว่าง รูปทรง พื้นผิว เป็นต้น 2) Model-based เป็นการสร้างโมเดลพิจารณาองค์ประกอบรวมของถนนเพื่อตรวจจับและติดตามเส้นจราจร และ 3) Learning-based เป็นวิธีการที่ทำการฝึกฝนโมเดลให้จดจำคุณสมบัติของเส้นจราจรแล้วนำโมเดลที่ได้ไปหาความสัมพันธ์กับข้อมูลรูปเพื่อทำนายเส้นจราจรบนถนน โดยปัจจุบันเทคนิค learning-based ได้รับความนิยมสูงขึ้น

เนื่องจากเทคโนโลยีปัจจุบันมีความสามารถในการประมวลผลที่สูงจึงทำให้เทคนิคตรวจจับเส้นจราจรมีประสิทธิภาพสูงขึ้นและสมเหตุสมผลในการใช้งานแบบเรียลไทม์ แต่เทคนิคนี้มีความซับซ้อนที่สูงและต้องการชุดข้อมูลในการฝึกฝนที่มากเช่นกัน การศึกษานี้เลือกประยุกต์ใช้วิธีการของ Priyadharshini, Niketha [13] ในการตรวจจับเส้นจราจรอย่างง่ายเพื่อนำไปสร้างกรอบพื้นที่ในการจำแนกตำแหน่งยานพาหนะบนถนน โดยวิธีการตรวจจับเส้นจราจรนี้ได้นำภาพที่ผ่านการแปลงเป็น grayscale ไปผ่านวิธีการ image blurring เพื่อลด noise ของภาพ แล้วนำไปประมวลผลผ่านเทคนิค Canny Edge detection เพื่อตรวจจับเส้นขอบของวัตถุและใช้เทคนิค Hough transform ตรวจจับเส้นขอบวัตถุที่ตรงเงื่อนไขแล้วนำผลลัพธ์ไปจำแนกเพื่อสร้างเส้นสีจราจรบนถนน

2.4 งานวิจัยที่เกี่ยวข้อง

Guerrieri, Parla [14] ได้พัฒนา Application มือถือในการตรวจจับและจำแนกจำนวนรถในทิศทางตรงข้ามและรถที่แซงรถสำรวจเพื่อนำไปประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยใช้วิธี Aggregate Channel Features (ACF) ในการตรวจจับและจำแนกประเภทรถ แล้วใช้เทคนิค feature matching ในการติดตามการเคลื่อนที่ของรถเพื่อจำแนกรูปแบบการเคลื่อนที่ตามวิธี MOM โดยทดลองสำรวจบนถนนทางหลวง 1 ช่องจราจรต่อทิศทางที่มีระยะทาง 1.1 กิโลเมตร, มีลักษณะกายภาพของถนนเป็นเนื้อเดียวกันและมีการไหลของกระแสจราจรแบบต่อเนื่องเป็นจำนวน 30 รอบ โดยเมื่อเปรียบเทียบผลลัพธ์ระหว่างโมเดลที่สร้างขึ้นกับข้อมูลจริงพบว่า โมเดลมีความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจรสูงสุดที่ประมาณ 10 เปอร์เซ็นต์ และ Guerrieri and Parla [15] ยังได้พัฒนาโมเดลในการตรวจจับและจำแนกจำนวนรถในทิศทางตรงข้ามและรถที่แซงรถสำรวจเพื่อนำไปประมาณค่าตัวแปรกระแสจราจรตามวิธี MOM โดยใช้ YOLOv3 architecture ที่เป็นโมเดลเรียนรู้เชิงลึกในการตรวจจับและ feature matching ในการติดตามยานพาหนะกับการสำรวจช่วงถนนเดิมในการศึกษาก่อนหน้านี้ [14] ซึ่งวิ่งสำรวจเป็นจำนวน 35 รอบ โดยโมเดลมีความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจรสูงสุดเพียง 3 เปอร์เซ็นต์



รูปที่ 2 ตัวอย่างรูปที่ใช้ในการฝึกฝนโมเดลตรวจจับยานพาหนะ

3. วิธีดำเนินงานวิจัย

3.1 การรวบรวมข้อมูล

3.1.1 รูปที่ใช้ในกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ

รูปที่ใช้ในกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะได้จากรูปวิดีโอหน้ารถที่สำรวจบนถนน 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางในเขตชุมชนและชานเมืองบริเวณเขตอำเภอสรรพยาและบางละมุง จังหวัดชลบุรี บนสภาพอากาศปกติในช่วงเวลา 06:30 – 18:30 น. โดยมีจำนวน 2,300 รูป และมีขนาดรูป 1,280 x 720 pixels แสดงตัวอย่างดังรูปที่ 2 ซึ่งยานพาหนะแต่ละคันในรูปนั้นจะถูกระบุตำแหน่งและประเภทยานพาหนะ (Data labelling) เป็นจำนวนทั้งหมด 8,944 รูปยานพาหนะ (เฉลี่ย 65% ด้านหน้าและ 35% ด้านท้าย) โดยระบุประเภทยานพาหนะตามขนาดและลักษณะเฉพาะเมื่อมองจากมุมมองด้านหน้ารถที่มีความแตกต่างกันอย่างชัดเจน ประกอบไปด้วย 8 ประเภทซึ่งมีจำนวนรูปและการกำหนดค่าแปลงหน่วยรถยนต์ส่วนบุคคล (Passenger car unit : PCU) ตามหลักเกณฑ์ของกรมทางหลวง [16] ดังนี้

- 1) Motorcycle เป็นรถจักรยานยนต์, มีจำนวน 2,797 รูปและมีค่า PCU เท่ากับ 0.33
- 2) Car เป็นรถยนต์ส่วนบุคคลน้อยกว่า 7 ที่นั่งที่มีลักษณะเป็นรถ Sedan และ Hatchback, มีจำนวน 1,343 รูปและมีค่า PCU เท่ากับ 1.00
- 3) SUV เป็นรถยนต์ส่วนบุคคลน้อยกว่า 7 ที่นั่งที่มีลักษณะเป็นรถ SUV และ MUV, มีจำนวน 862 รูปและมีค่า PCU เท่ากับ 1.00

4) VAN เป็นรถยนต์ส่วนบุคคลมากกว่า 7 ที่นั่งที่มีลักษณะเป็นรถตู้, มีจำนวน 703 รูปและมีค่า PCU เท่ากับ 1.00

5) Light Truck เป็นรถบรรทุกขนาดเล็ก 4 ล้อที่มีลักษณะเป็นรถกระบะแบบไม่มีตู้บรรทุกสินค้า, มีจำนวน 1,294 รูปและมีค่า PCU เท่ากับ 1.00

6) Light Commercial Truck เป็นรถบรรทุกขนาดเล็ก 4 ล้อที่มีลักษณะเป็นรถกระบะแบบมีตู้บรรทุกสินค้า, มีจำนวน 873 รูปและมีค่า PCU เท่ากับ 1.00

7) Heavy Truck ประกอบด้วยรถบรรทุกขนาด 6 ล้อ, 10 ล้อ, รถพ่วงและกึ่งพ่วง, มีจำนวน 736 รูปและกำหนดค่า PCU เท่ากับ 2.5

8) BUS เป็นรถโดยสารขนาดเล็ก, กลางและใหญ่, มีจำนวน 336 รูปและกำหนดค่า PCU เท่ากับ 2.1

ซึ่งแสดงตัวอย่างยานพาหนะแต่ละประเภทดังรูปที่ 3 จากนั้นทำการแบ่งชุดข้อมูลออกเป็น 70% training, 15% validation และ 15% test เพื่อใช้ในกระบวนการฝึกฝนและประเมินประสิทธิภาพโมเดลตรวจจับยานพาหนะ

3.1.2 การสำรวจข้อมูลจราจรในงานวิจัย

งานวิจัยนี้ทำการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะหรือวิธีการสำรวจ MOM เพื่อทดลองใช้กับโมเดลที่นำเสนอ โดยใช้กล้องวิดีโอหน้ารถบันทึกกระแสจราจรที่เคลื่อนที่ผ่านรถสำรวจ โดยสำรวจบนช่วงถนนที่มีจำนวนช่องจราจร 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางตามขอบเขตงานวิจัย ซึ่งออกแบบการวิ่งสำรวจและการเลือกช่วงถนนดังนี้

- 1) สำรวจในช่วงเวลา 13:00 – 15:00 น. (ช่วงไม่เร่งด่วน) และ 16:30 – 18:00 น. (ช่วงเร่งด่วน)
- 2) ถนนระหว่างเมืองที่มีการไหลของกระแสจราจรแบบต่อเนื่อง (Uninterrupted flow)
- 3) ใช้ความเร็วเฉลี่ย 60 กม./ชม. ในการสำรวจโดยตัดสินการแซง การชะลอรถโดยผู้ขับขี่
- 4) วิ่งสำรวจตามวิธี MOM ในแต่ละทิศทางเพียง 6 รอบซึ่งเพียงพอต่อความน่าเชื่อถือและไม่เอนเอียงในการประมาณค่าตัวแปรกระแสจราจร [1, 17, 18]

5) องค์ประกอบทางเรขาคณิตของถนนเป็นเนื้อเดียวกัน ทั้งช่วงถนน ไม่มีเรขาคณิตของถนนหรืออุปสรรคมาบดบังการสำรวจและทำให้กระแสรถติดขัด [1]

6) ไม่มีทางแยกประกอบในช่วงถนนที่สำรวจหรือมีได้เล็กน้อยเพื่อลดความผันผวนของกระแสรถติดและเหตุการณ์อื่นที่ไม่อยู่ในขอบเขตงานวิจัย

7) อัตราการไหลและความยาวของช่วงถนนสำรวจที่สูงขึ้นยิ่งส่งผลต่อระดับความน่าเชื่อถือของข้อมูลและลดจำนวนรอบในการสำรวจ [2, 19]

โดยงานวิจัยนี้เลือกสำรวจจำนวน 5 ช่วงถนนที่มีความยาว 2.0 ถึง 5.0 กิโลเมตรดังแสดงใน

รูปที่ 4 และทำการสำรวจได้ทั้งหมด 153 เทียวก ซึ่งสามารถจับคู่เป็นรอบตามวิธีสำรวจ MOM (จากจุด A ไป B และจุด B ไป A ดังรูปที่ 1) ได้จำนวน 143 รอบ โดยแต่ละจุดสำรวจมีรอบการสำรวจประมาณ 4 – 8 รอบต่อทิศทางต่อช่วงเวลา (จุด B สามารถจับคู่ได้น้อยกว่า 6 รอบเพราะความผิดพลาดในการบันทึกวิดีโอสำรวจ)

3.2 เครื่องมือที่ใช้ในงานวิจัย

1) การสำรวจจราจร บันทึกการสำรวจโดยใช้กล้องวิดีโอถ่ายภาพนิ่งที่ QVP, model L18 - FULL HD 1080p

2) การสร้างและรันโมเดลที่ได้นำเสนอไว้ โดยส่วนของฮาร์ดแวร์เลือกใช้ฮาร์ดแวร์หน่วยประมวลผล (CPU) รุ่น Intel(R) Xeon(R) CPU @ 2.20GHz, การ์ดจอประมวลผล (GPU) รุ่น Tesla A100-SXM4-40GB และหน่วยความจำหลัก (RAM) 13 GB บน Google Colab (Version: Colab Pro) และส่วนของซอฟต์แวร์เลือกใช้ระบบปฏิบัติการ Windows 10 และใช้ภาษา Python ในการสร้างโมเดลที่นำเสนอในงานวิจัย

3.3 การตั้งค่าและพัฒนาโมเดลตรวจจับและจำแนกเพื่อประมาณค่าตัวแปรจราจรตามวิธีสำรวจ MOM

กระบวนการพัฒนาโมเดลการจำแนกประเภทและรูปแบบเคลื่อนที่ของยานพาหนะ และการประมาณค่าตัวแปรจราจรจราจรมีขั้นตอนการพัฒนาดังรูปที่ 5 ซึ่งมีรายละเอียดดังนี้

3.3.1 โมเดลตรวจจับยานพาหนะ (Vehicle detection model) – YOLOv7

โมเดลการตรวจจับยานพาหนะ มีหน้าที่ระบุตำแหน่งและประเภทของยานพาหนะ เลือกใช้สถาปัตยกรรม YOLOv7 [7] โดยประยุกต์ใช้ source code จาก [7, 20] ซึ่งมีการตั้งค่าดังนี้


1) กระบวนการฝึกฝนโมเดลเลือกใช้ model weight เป็น YOLOv7 ที่ผ่านการฝึกฝนจาก MS COCO dataset โดยกำหนดการตั้งค่า hyperparameter ทั้งในการฝึกฝนและการปรับแต่งรูปเพื่อใช้ในการฝึกฝน (Image augmentation) ตามค่าตั้งต้น โดยตั้งค่า stochastic gradient descent, learning rate, image size, batch size และ epochs เท่ากับ 0.937, 0.01, [640,640], 16 และ 300 ตามลำดับ

2) การนำโมเดลตรวจจับยานพาหนะไปใช้จริง โดยตั้งค่า Image size เท่ากับ 640 pixel และ confidence threshold, IoU threshold เท่ากับ 0.5 และ 0.45 ตามลำดับ




หมายเหตุ : 1) Motorcycle, 2) Car, 3) SUV, 4) Light Truck, 5) Light Commercial Truck, 6) Van, 7) Bus, 8) Heavy Truck

รูปที่ 3 ตัวอย่างยานพาหนะทั้ง 8 ประเภทที่ทำการจำแนกประเภทยานพาหนะในงานวิจัย



ที่มา: <https://www.google.co.th/maps/>

รูปที่ 4 ช่วงถนนที่สำรวจทั้ง 5 ช่วงในการศึกษาครั้งนี้



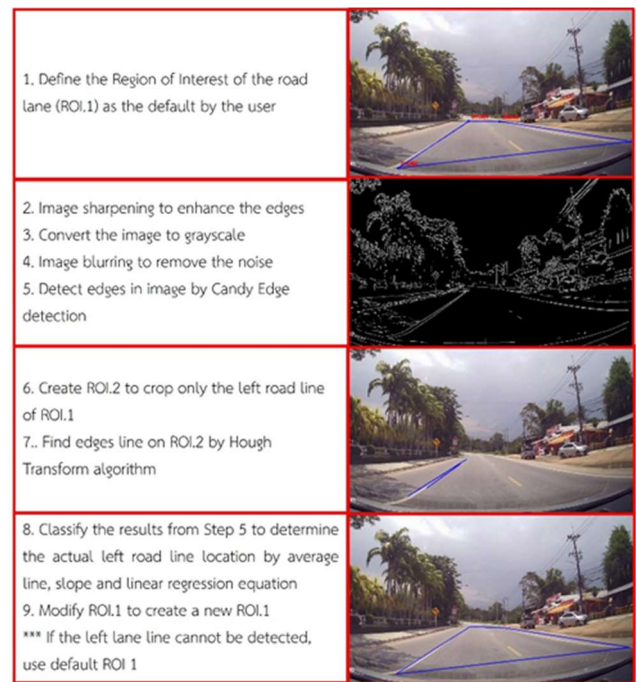
รูปที่ 5 กระบวนการพัฒนาโมเดลที่นำเสนอ

3.3.2 โมเดลติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle tracking model) – StrongSORT

โมเดลติดตามการเคลื่อนที่ของยานพาหนะ มีหน้าที่ติดตามการเคลื่อนที่ของยานพาหนะในแต่ละคันเพื่อนำข้อมูลไปใช้ในการจำแนกรูปแบบการเคลื่อนที่ตามวิธีสำรวจ MOM โดยนำผลลัพธ์ที่ได้จากโมเดลตรวจจับมาใช้ในการติดตามการเคลื่อนที่ของยานพาหนะซึ่งเลือกใช้สถาปัตยกรรม StrongSORT [10] โดยประยุกต์ใช้ source code จาก [20] ซึ่งมีการตั้งค่าดังนี้

1) พารามิเตอร์ที่ใช้ในโมเดลการติดตามยานพาหนะ กำหนดการตั้งค่าเป็นค่าตั้งต้น โดยตั้งค่า matching threshold, gating threshold, number of missed object age และ initial age for tracking เท่ากับ 0.2, 0.7, 15 และ 3 ตามลำดับ

2) deep-reid weight ที่ใช้ในการประมวลผลของ StrongSORT ใช้โมเดล osnet_ain_x1_0_msmt17 ของ torchreid ที่ฝึกฝนโมเดลแบบ Cross-domain ReID



รูปที่ 6 ขั้นตอนการสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีขาว (ROI based on lane line detection)

3.3.3 โมเดลสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีจราจร (ROI based on lane line detection)

โมเดลสร้างกรอบพื้นที่โดยการตรวจจับเส้นสีจราจร มีหน้าที่สร้างกรอบพื้นที่เพื่อจำแนกยานพาหนะที่สนใจ (ยานพาหนะที่วิ่งบนช่องจราจร) และที่ไม่สนใจ (ยานพาหนะบนไหล่ทาง จอดริมทางและที่อยู่อาศัย) ซึ่งมีขอบเขตพื้นที่อยู่ระหว่างเส้นไหล่ทางซ้ายถึงไหล่ทางขวา โดยประยุกต์ใช้เทคนิคตรวจจับเส้นสีจราจร [13] เพื่อปรับแต่งเส้นกรอบพื้นที่ทางซ้ายให้สอดคล้องกับเส้นไหล่ทางซ้ายซึ่งประยุกต์ใช้ source code จาก [21] โดยมีขั้นตอนการสร้างและตัวอย่างผลลัพธ์ดังรูปที่ 6

3.3.4 โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle type and movement classification model)

จากการพัฒนาโมเดลการตรวจจับและติดตามยานพาหนะและโมเดลสร้างกรอบพื้นที่ที่สนใจ ทำให้ได้ข้อมูลในแต่ละคัน ได้แก่ 1) ประเภทของยานพาหนะ 2) รูปแบบการเคลื่อนที่ของยานพาหนะ 3) ตำแหน่งของยานพาหนะ (อยู่ในกรอบ ROI หรือไม่) 4) จำนวนเฟรมที่ยานพาหนะถูกติดตาม เป็นต้น จึงนำข้อมูลที่ได้มาใช้ในการจำแนกประเภทและรูปแบบการเคลื่อนที่ตามวิธีสำรวจ MOM ทั้ง 3 รูปแบบได้แก่ (1) การจำแนกรถทิศทางตรงข้าม (Opposing vehicle classification), (2) การจำแนกรถที่แซงรถสำรวจ (Overtaking vehicle classification) และ (3) การจำแนกรถที่ถูกรถสำรวจแซง (Passed vehicle classification) เป็นต้น โดยแสดงตัวอย่างผลลัพธ์ดังรูปที่ 7A ถึง 7C ซึ่งมีการสร้างเงื่อนไขเพื่อนับและจำแนกรูปแบบการเคลื่อนที่ดังนี้

- 1) ตรวจสอบรูปแบบการเคลื่อนที่จากจุดเริ่มต้นจนถึงจุดที่ชนกับเส้น counting line เพื่อใช้กำหนดเงื่อนไข
- 2) ตรวจสอบการเคลื่อนที่ของยานพาหนะว่าอยู่ในกรอบพื้นที่ที่สนใจหรือไม่ มีสัดส่วนอยู่/ไม่อยู่ในกรอบเท่าไรเพื่อใช้กำหนดเงื่อนไขในการนับและจำแนก
- 3) นำจำนวนเฟรมของยานพาหนะที่ถูกติดตามไปใช้กำหนดเงื่อนไขในการนับและจำแนก และใช้ลดความผิดพลาดของการจำแนก เช่น วัตถุติดตามซ้ำซ้อน นับซ้ำ ความผิดพลาดของการติดตาม การจำแนกรถไหล่ทางซ้ายและขวา เป็นต้น
- 4) การนับและจำแนกรถที่วิ่งในทิศทางตรงข้ามและวิ่งแซงรถสำรวจจะถูกพิจารณาและนับเมื่อชนกับเส้น counting

line ที่กำหนดเป็นเส้น ROI ด้านล่างและผ่านเงื่อนไขที่สร้างขึ้น แต่ในกรณีการนับรถที่รถสำรวจแซงนั้นจะทำการพิจารณา 2 ขั้นตอนประกอบด้วย (1) เมื่อรถชนกับเส้น counting line ที่กำหนดเป็นเส้น ROI ด้านซ้ายและผ่านเงื่อนไขที่สร้างขึ้น รถคันนั้นจะถูกระบุว่ามีโอกาสเป็นรถที่รถสำรวจแซง (2) รถที่ถูกระบุว่ามีโอกาสถูกแซงนั้นจะถูกพิจารณาเพื่อนับเมื่อตำแหน่งของรถอยู่ต่ำกว่าเส้น ROI ทางซ้ายตามเกณฑ์ที่กำหนดไว้

3.3.5 การประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM (Estimation of traffic flow variable based on MOM)

ผลลัพธ์การนับจำนวนยานพาหนะแต่ละประเภทและแต่ละรูปแบบการเคลื่อนที่ในแต่ละเที่ยวการสำรวจ นำไปจับคู่เพื่อให้ได้จำนวนยานพาหนะในแต่ละรอบสำรวจตามวิธี MOM แล้วนำข้อมูลไปแปลงค่าในรูปแบบรถยนต์ส่วนบุคคล (Passenger car unit: PCU) แล้วทำการหาค่าเฉลี่ยของจำนวนยานพาหนะแต่ละรูปแบบในแต่ละทิศทางเพื่อนำไปคำนวณหาค่าอัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นของกระแสจราจรตามสมการที่ (5), (7) และ (8)

3.3.6 การประเมินประสิทธิภาพของโมเดล

การประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะเลือกใช้ (1) Precision เพื่อวัดความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องตามวัตถุประสงค์ (นับเฉพาะยานพาหนะที่อยู่บนช่องจราจรและจำแนกประเภทและรูปแบบการเคลื่อนที่ได้ถูกต้อง) ต่อยานพาหนะที่นับได้ทั้งหมด (2) Recall เพื่อวัดความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องต่อยานพาหนะที่เกี่ยวข้อง (ยานพาหนะที่นับและจำแนกถูกต้องรวมกับไม่สามารถนับได้) (3) F1-score เพื่อวัดประสิทธิภาพโดยรวมของโมเดลโดยใช้ค่า Precision กับ Recall มาเฉลี่ยแบบ harmonic mean และ (4) Accuracy เพื่อวัดความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องต่อเหตุการณ์ที่เกิดขึ้นทั้งหมด (5) Confusion Matrix เพื่อแสดงความแม่นยำในการจำแนกยานพาหนะในแต่ละประเภท และ (6) Mean absolute percentage error (MAPE) เพื่อวัดความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจรระหว่างผลลัพธ์ที่ได้จากโมเดลที่นำเสนอ กับจำนวนเหตุการณ์จริง



หมายเหตุ: เหตุการณ์ A) นักรถที่ตรงข้าม, B) รถกำลังถูกรถสำรวจแซง, C) นักรถสำรวจถูกแซง, D) จำแนกรถบนไหล่ทางด้วยกรอบพื้นที่ที่สร้างขึ้น, E) กรอบพื้นที่เกินจากขอบเขตช่องจราจร และ F) กรอบพื้นที่แคบกว่าขอบเขตช่องจราจร โดยเส้นสีแดงคือเส้นกรอบพื้นที่ที่สร้างขึ้น

รูปที่ 7 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะกับข้อมูลสำรวจจราจรตามวิธี MOM

ตารางที่ 1 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle type and movement classification model) และความแม่นยำในการจำแนกยานพาหนะบนไหล่ทางจากการคำนวณ (On-left/right shoulder vehicles classification)

Classification Model	Number of Events				Precision	Recall	F1-score	Accuracy
	TP	FP1	FP2	FN				
Opposing vehicle classification	5365	191	353	233	90.79	95.84	93.25	87.35
Overtaking vehicle classification	91	10	0	0	90.10	100	94.79	90.10
Passed vehicle classification	21	1	15	7	56.76	75.00	64.62	47.73
On-left shoulder vehicles classification	374	-	13	-	96.64	-	-	96.64
On-right shoulder vehicles classification	1374	-	327	-	80.78	-	-	80.78

หมายเหตุ : 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

/สามารถจำแนกรถบนไหล่ทางจากการคำนวณได้

2) FP1 (False Positive case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้องแต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive case 2) คือ เหตุการณ์ที่นับและจำแนกประเภทยานพาหนะผิดพลาด/จำแนกรถบนไหล่ทางเข้าสู่การคำนวณ

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะจากข้อผิดพลาดของโมเดล

Vehicle type classification (Prediction Accuracy (%))		Number of events	Predicted Class							
			Motorcycle	Car	SUV	Light truck	Light commercial truck	Heavy truck	Van	Bus
Actual Class	Motorcycle	582	99.66	0	0.17	0.17	0	0	0	0
	Car	1247	0	97.11	2.41	0.48	0	0	0	0
	SUV	590	0	10.17	88.31	0.17	1.36	0	0	0
	Light truck	1601	0	0	0.12	98.69	1.06	0.12	0	0
	Light commercial truck	698	0.14	0	0.43	4.87	94.27	0.29	0	0
	Heavy truck	515	0	0	0	0	0.19	99.81	0	0
	Van	396	0	1.26	4.29	0	1.52	0	92.93	0
	Bus	50	0	0	6.00	0	0	4.00	0	90.00

รูปที่ 8 ตาราง Confusion Matrix แสดงความแม่นยำในการจำแนกประเภทยานพาหนะโดยรวมทั้ง 3 รูปแบบการเคลื่อนที่

4. ผลการวิจัย

ผลการวิจัยประกอบด้วย 3 ส่วนหลักได้แก่ 1) ผลการฝึกฝนโมเดลตรวจจับยานพาหนะ 2) ผลการประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ 3) ผลการเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างการใช้อัลกอริทึมการตรวจจับและผลลัพธ์การจำแนกที่ได้จากโมเดลที่นำเสนอ

4.1 ผลการฝึกฝนโมเดลตรวจจับยานพาหนะ

ผลการฝึกฝนโมเดลตรวจจับยานพาหนะเพื่อใช้ในการตรวจจับและจำแนกประเภทยานพาหนะในงานวิจัย โดยเมื่อทดลองใช้กับ test dataset (15% จากข้อมูลรูปทั้งหมด)

พบว่า มีค่า Precision, Recall, F1-score, mAP@.5 (mean Average Precision ที่ IoU threshold เท่ากับ 0.5) เท่ากับ 86.0, 86.7, 86.3 และ 91.7% ตามลำดับ

4.2 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

4.2.1 ประสิทธิภาพด้านความเร็วประมวลผล

ผลการใช้โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะกับข้อมูลสำรวจจราจร 153 เทียวก โดยโมเดลมีความเร็วประมวลผลเฉลี่ย 57.5 ms/frame หรือ 17.4 FPS โดยแบ่งเป็นเวลาประมวลผลของโมเดล Vehicle detection, Vehicle tracking, ROI based on lane line detection และอื่น ๆ เป็นเวลาเฉลี่ยเท่ากับ 12.9, 15.8, 12.6 และ 16.1 ms/frame ตามลำดับ

4.2.2 ประสิทธิภาพของการจำแนกรูปแบบการเคลื่อนที่ของยานพาหนะ

ผลการประเมินประสิทธิภาพการใช้งานโมเดลในการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะบนกรอบพื้นที่ที่สนใจ (ยานพาหนะที่วิ่งบนช่องจราจร) กับข้อมูลสำรวจจราจรทั้ง 153 เทียวกจาก 5 ช่วงถนนสำรวจ สามารถสรุปผลได้ดังตารางที่ 1 ซึ่งสามารถอภิปรายผลลัพธ์ได้ดังนี้

1) การจำแนกรถทิศทางตรงข้าม (Opposing vehicle classification) มีประสิทธิภาพโดยรวม (F1-score) เท่ากับ 93.25% โดยความผิดพลาด 777 เหตุการณ์ (FP1+FP2+FN) มีสาเหตุจาก

1.1) FP1 (False Positive case 1) มี 191 เหตุการณ์ (24.6%) ซึ่งเป็นเหตุการณ์จำแนกประเภทยานพาหนะผิด

1.2) FP2 (False Positive case 2) มี 353 เหตุการณ์ (45.4%) ซึ่งเป็นเหตุการณ์นับยานพาหนะที่ไม่เกี่ยวข้องในการคำนวณบนข้อผิดพลาดของโมเดลเป็นรถทิศทางตรงข้าม โดยแบ่งเป็น 89.2% เป็นเหตุการณ์นับรถบนไหล่ทางขวาเป็นรถทิศทางตรงข้ามซึ่งมีสาเหตุจากการจำแนกรถบนไหล่ทางขวาจากการคำนวณโดยกรอบพื้นที่ที่สนใจ (On-right shoulder vehicles classification) ที่มีความแม่นยำเพียง 80.78% (เกิดจากเส้นกรอบด้านขวามีความคลาดเคลื่อนเกินขอบเขตช่องจราจรที่สนใจดังตัวอย่างในรูปที่ 7E) โดยเฉพาะการจำแนกรถจักรยานยนต์ในไหล่ทางขวาที่มีความผิดพลาดสูง

มากที่สุด และ 10.8% เป็นเหตุการณ์นับยานพาหนะซ้ำ, นับรถบนไหล่ทางตอนรถสำรวจกำลังแซงและรถรอเลี้ยวขวา

1.3) FN (False Negative) มี 233 เหตุการณ์ (30.0%) ซึ่งเป็นความผิดพลาดที่โมเดลไม่สามารถนับยานพาหนะได้ โดยแบ่งเป็น 44.2% เป็นเหตุการณ์ที่กรอบพื้นที่ที่สร้างขึ้นเกิดความคลาดเคลื่อนจากตำแหน่งที่เหมาะสม (กรอบพื้นที่เล็กหรือผิดปกติกจากขอบเขตช่องจราจรที่สนใจดังรูปที่ 7F) และ 37.3% เป็นเหตุการณ์ไอดีของยานพาหนะขาดหายหรือเปลี่ยนแปลงไอดีแบบฉับพลันจากการติดตามรถ และ 8.2% เป็นเหตุการณ์รถหายตอนเบี่ยงซ้ายเพื่อให้แซง และอื่น ๆ เช่น รถโดนบดบังโดยรถคันอื่น รถไม่ชนกับ counting line เป็นต้น

2) การจำแนกรถที่แซงรถสำรวจ (Overtaking vehicle classification) มีประสิทธิภาพโดยรวม (F1-score) เท่ากับ 94.79% และมีค่า Recall เท่ากับ 100% ซึ่งหมายความว่าโมเดลสามารถตรวจจับเหตุการณ์การแซงรถสำรวจได้ทั้งหมด โดยความผิดพลาดที่เกิดขึ้น 10 เหตุการณ์เกิดจากการจำแนกประเภทยานพาหนะ

3) การจำแนกรถที่ถูกรถสำรวจแซง (Passed vehicle classification) มีประสิทธิภาพโดยรวม (F1-score) เท่ากับ 64.62% โดยความผิดพลาดที่เกิดขึ้น 22 เหตุการณ์ (FP2+FN) มีสาเหตุจาก

3.1) FP2 (False Positive case 2) มี 15 เหตุการณ์ (68.2%) ซึ่งเป็นการนับรถบนไหล่ทางซ้ายเป็นรถสำรวจแซง โดยเป็นแบ่ง 86.7% เป็นข้อผิดพลาดของการสร้างเส้นกรอบพื้นที่ทางซ้ายที่ปรับแต่งโดยโมเดลตรวจจับเส้นสีจราจรเพื่อให้สอดคล้องกับเส้นไหล่ทางซ้ายจริงทำให้การจำแนกรถไหล่ทางซ้ายออกจากการคำนวณ (On-left shoulder vehicles classification) ที่มีความแม่นยำเท่ากับ 96.64% โดยเฉพาะการจำแนกรถจักรยานยนต์และรถบนช่วงทางโค้งและ 13.3% เป็นการนับซ้ำซ้อนและนับรถเลี้ยวซ้าย

3.2) FN (False Negative) มี 7 เหตุการณ์ (31.8%) ที่โมเดลไม่สามารถนับยานพาหนะได้ โดยเป็นเหตุการณ์รถสำรวจแซงรถขนาดใหญ่ที่วิ่งทับไหล่ทางซ้าย การแซงจากระยะไกลและการเปลี่ยนแปลงไอดีแบบฉับพลัน เป็นต้น


4) การจำแนกประเภทยานพาหนะ (Vehicle type classification) เมื่อรวมเหตุการณ์ที่โมเดลสามารถนับบนกรอบพื้นที่ที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

(TP: True Positive) กับจำแนกประเภทยานพาหนะผิดประเภท (FP1: False Positive case 1) ทั้ง 3 รูปแบบการเคลื่อนที่ พบว่าโมเดลมีความแม่นยำในการจำแนกประเภทโดยรวมเท่ากับ 96.44% ซึ่งแสดงความแม่นยำรายประเภทได้ดังรูปที่ 8 โดยการจำแนกยานพาหนะประเภท SUV มีความแม่นยำต่ำที่สุดที่ 88.31% ซึ่งการจำแนก SUV เป็น CAR มีสัดส่วนความผิดพลาดสูงที่สุดเนื่องจากลักษณะที่คล้ายคลึงกัน โดยเฉพาะรถ Hatchback กับ SUV และ MUV ที่วิ่งในทิศทางตรงข้าม


4.3 ผลการเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างข้อมูลจริงกับโมเดลที่นำเสนอ

ผลลัพธ์การจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 รูปแบบ (จำนวนรถที่วิ่งในทิศทางตรงข้าม, รถที่วิ่งแซงรถสำรวจและรถที่ถูกรถสำรวจแซงแบบรายประเภทยานพาหนะ) ของข้อมูลสำรวจจราจรทั้ง 5 ช่วงถนนนำมาจับคู่ตามวิธีการสำรวจ MOM ได้ทั้งหมด 143 รอบ (ช่วงถนนสำรวจละ 4 – 8 รอบต่อทิศทางต่อช่วงเวลา) แล้วนำไปคำนวณเพื่อหาค่าอัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรของแต่ละทิศทาง ช่วงเวลาและจุดสำรวจดังสมการ (5), (7) และ (8) โดยแสดงผลเปรียบเทียบการประมาณค่าระหว่างผลลัพธ์การจำแนกที่ได้จากโมเดลกับข้อมูลจริง (จำนวนยานพาหนะที่เกิดขึ้นจริงทั้ง 3 รูปแบบการเคลื่อนที่) ดังรูปที่ 9 ซึ่งพบว่า ช่วงสำรวจทั้ง 5 มีอัตราการไหลต่ำสุด, เฉลี่ยและสูงสุดอยู่ที่ 190, 367 และ 619 คัน/ชั่วโมงตามลำดับ โดยช่วงเร่งด่วนมีอัตราการไหลสูงกว่าช่วงไม่เร่งด่วนโดยเฉลี่ยที่ 34.7% และสูงสุดอยู่ที่ 106.6% และเมื่อคำนวณค่าคลาดเคลื่อนสัมบูรณ์ (absolute percentage error) ในการประมาณค่าอัตราการไหลระหว่างช่วงไม่เร่งด่วนกับช่วงเร่งด่วนดังรูปที่ 10 พบว่า ช่วงไม่เร่งด่วนมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 2.08% และช่วงเร่งด่วนเท่ากับ 2.65% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจพบว่าจุด C มีความคลาดเคลื่อนสูงที่สุดที่ 7.88% ซึ่งเกิดจากจำแนกรถจักรยานยนต์บนไหล่ทางขวาที่มีความผิดพลาดสูงมาก และเมื่อคำนวณความคลาดเคลื่อนสัมบูรณ์โดยรวมในการประมาณตัวแปรกระแสจราจรทั้ง 3 ตัวแปรดังรูปที่ 11 พบว่า อัตราการไหลมีความคลาดเคลื่อนจากข้อมูลจริงสูงสุดเท่ากับ 7.88%


และมีค่าเฉลี่ยเท่ากับ 2.36% และส่งผลให้ความคลาดเคลื่อนของความเร็วเฉลี่ยและความหนาแน่นจราจรมีค่าสูงสุดเท่ากับ 5.80 และ 7.65% ตามลำดับและมีค่าเฉลี่ยเท่ากับ 0.73 และ 2.86% ตามลำดับ



รูปที่ 9 การเปรียบเทียบผลลัพธ์การประมาณค่าอัตราการไหลระหว่างโมเดลที่นำเสนอกับข้อมูลจริง



รูปที่ 10 การเปรียบเทียบค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าอัตราการไหลระหว่างช่วงไม่เร่งด่วนกับช่วงเร่งด่วน



รูปที่ 11 Box and whisker ของค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าตัวแปรกระแสจราจร

5. สรุปผลการวิจัย

งานวิจัยนี้ได้นำเสนอโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 รูปแบบ (จำนวนรถที่วิ่งในทิศทางตรงข้าม, รถที่วิ่งแซงรถสำรวจและรถที่ถูกรถสำรวจแซงแบบรายประเภทยานพาหนะ) ตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM) โดยใช้ 1) สถาปัตยกรรม YOLOv7 ในการตรวจจับและจำแนกประเภทยานพาหนะ 2) สถาปัตยกรรม StrongSORT ในการติดตามการเคลื่อนที่ยานพาหนะ และ 3) เทคนิค Canny Edge detection กับ Hough transform ในการตรวจจับเส้นสีจราจรเพื่อปรับแต่งกรอบพื้นที่จำแนกเฉพาะยานพาหนะที่สนใจให้สอดคล้องกับช่องจราจร จากนั้นนำผลลัพธ์การจำแนกไปใช้ประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยทดลองกับข้อมูลสำรวจจราจรที่วิ่งสำรวจบนถนน 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลาง โมเดลที่นำเสนอมีประสิทธิภาพโดยรวม (F1- score) ในการจำแนกรถในทิศทางตรงข้าม รถที่แซงรถสำรวจและรถที่ถูกรถสำรวจแซงเท่ากับ 93.25, 94.79 และ 64.62% ตามลำดับ ซึ่งความคลาดเคลื่อนในการจำแนกเกิดจากโมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อจำแนกเฉพาะยานพาหนะที่วิ่งบนช่องจราจรที่มีประสิทธิภาพต่ำซึ่งไม่สอดคล้องกับขอบเขตช่องจราจรโดยเฉพาะขอบเขตเส้นไหล่ทางขวาจึงทำให้ยานพาหนะขาดหายและเกินจากความเป็นจริงโดยเฉพาะการจำแนกรถจักรยานยนต์บนไหล่ทางขวาที่มีความผิดพลาดสูงมาก และรองลงมาเป็นรถประเภทยานพาหนะที่ยานพาหนะประเภท SUV มีสัดส่วนความผิดพลาดสูงที่สุด และเมื่อเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างผลที่ได้จากโมเดลกับข้อมูลจริงพบว่า อัตราการไหล ความเร็วเฉลี่ยและความหนาแน่นมีความคลาดเคลื่อนสัมบูรณ์สูงสุดเท่ากับ 7.88, 5.80 และ 7.65% ตามลำดับและมีค่าเฉลี่ยเท่ากับ 2.36, 0.73 และ 2.86% ตามลำดับ

โดยโมเดลที่นำเสนอมีข้อจำกัดประกอบไปด้วย (1) โมเดลสามารถใช้ได้เฉพาะช่วงถนนที่มี 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางและมีขนาดช่องจราจรเท่ากันทั้งช่วงถนน (2) โมเดลต้องการช่องจราจรที่เส้นสีจราจรไหล่ทางซ้ายมีความคมชัด ต่อเนื่องและไม่เป็นเส้นโค้งเพื่อให้สามารถตรวจจับ

เส้นสีจราจรได้ และ (3) โมเดลต้องการผู้ใช้งานในการกำหนดขอบเขตกรอบพื้นที่ที่สนใจในขั้นตอนเริ่มต้น เป็นต้น

เอกสารอ้างอิง

- [1] Alhomaidat F, Ardekani S. A statistical comparison of traffic measurements from the moving versus stationary observer methods. *Journal of Transportation Technologies*. 2015;5: 204-13.
- [2] Mulligan AM, Nicholson A. Uncertainty in traffic flow estimation using the moving- observer method. *IPENZ Transportation Group Conference Papers*; 2002.
- [3] Wardrop JG, Charlesworth G. A method of estimating speed and flow of traffic from a moving vehicle. *Proceedings of the Institution of Civil Engineers*. 1954;3(1): 158-171.
- [4] Greenshields B, Bibbins J, Channing W, Miller H. A study of traffic capacity. *Highway research board proceedings*; 1935. p. 448-477.
- [5] Xiao Y, Tian Z, Yu J, Zhang Y, Liu S, Du S, et al. A review of object detection based on deep learning. *Multimedia Tools and Applications*. 2020;79(33): 23729-23791.
- [6] Ren S, He K, Girshick R, Sun J. Faster RCNN: Towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017;39(6): 1137-1149.
- [7] Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint arXiv:2207.02696*. 2022.
- [8] Yang F, Zhang X, Liu B. Video object tracking based on YOLOv7 and DeepSORT. *arXiv preprint arXiv:2207.02696*. 2022.
- [9] Wojke N, Bewley A, Paulus D. Simple online and realtime tracking with a deep association metric. *2017 IEEE International Conference on Image Processing (ICIP)*; 2017. p. 3645-3649.

- [10] Du Y, Song Y, Yang B, Zhao Y. StrongSORT: make DeepSORT great again. *arXiv e-prints*. 2022: arXiv:2202.13514.
- [11] Zhang Y, Wang C, Wang X, Zeng W, Liu W. Fairmot: on the fairness of detection and re-identification in multiple object tracking. *International Journal of Computer Vision*. 2021;129(11): 3069-3087.
- [12] Kumar A, Simon P. Review of lane detection and tracking algorithms in advanced driver assistance system. *International Journal of Computer Science and Information Technology*. 2015;7: 65-78.
- [13] Priyadharshini P, Niketha P, Lakshmi KS, Sharmila S, Divya R. Advances in vision based lane detection algorithm based on reliable lane markings. *2019 5th International Conference on Advanced Computing & Communication Systems* 2019. p. 880-885.
- [14] Guerrieri M, Parla G, Mauro R. Traffic flow variables estimation: an automated procedure based on moving observer method: potential application for autonomous vehicles. *Transport and Telecommunication Journal*. 2019;20: 205-214.
- [15] Guerrieri M, Parla G. Deep Learning and YOLOv3 systems for automatic traffic data measurement by moving car observer technique. *Infrastructures*. 2021;6(9): 134.
- [16] Kraisingsom S, Phawiakkharakun N. *Traffic congestion index and density analysis report in 2021*. Bureau of Highway Safety, Department of Highways, Thailand; 2021.
- [17] Al-Bahr T, Puan OC, Hassan SA, Azhari SF, Al-Sabaei AM, Mohammed HA. Statistical evaluation of moving observer method accuracy for measuring traffic flow variables on urban roads. *2021 International Congress of Advanced Technology and Engineering (ICOTEN)*; 2021. p. 1-6.
- [18] Mortimer WJ. Moving vehicle method of estimating traffic volumes and speeds. *Highway Research Board Bulletin*. 1957;156: 14-26.
- [19] Al-Bahr TM, Puan OC, Hassan SA, Idham MK, Ismail CR. Parameters affecting fluctuation in traffic stream on urban roads. *IOP Conference Series: Materials Science and Engineering*. 2019;527(1): 012067.
- [20] Broström M. Real-time multi-camera multi-object tracker using YOLOv7 and StrongSORT with OSNet. Available from: https://github.com/mikel-brostrom/Yolov7_StrongSORT_OSNet. [Accessed 21th August 2020].
- [21] Vykari N. Understanding Hough Transform With A Lane Detection Model. Available from: <https://blog.paperspace.com/understanding-hough-transform-lane-detection/>. [Accessed 13th February 2022].