

การประยุกต์ใช้โมเดลการตรวจจับและติดตามยานพาหนะในการประมาณ
ค่าตัวแปรกระแสจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2566

APPLICATION OF VEHICLE DETECTION AND TRACKING MODEL:
ESTIMATION OF TRAFFIC FLOW VARIABLE BASED ON MOVING
OBSERVER METHOD



PONGSAKORN PREMSRI

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Civil, Transportation and
Geo Resources Engineering
Suranaree University of Technology
Academic Year 2023

การประยุกต์ใช้โมเดลการตรวจจับและติดตามยานพาหนะในการประมาณค่าตัวแปร
กระแสจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาโทบริหารธุรกิจ

คณะกรรมการสอบวิทยานิพนธ์



(ผศ. ดร.ศิริดล ศิริธร)

ประธานกรรมการ



(ผศ. ร.อ. ดร.สุทธิพงษ์ มีใย)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รศ. ดร.อาทิตย์ ศรีแก้ว)

กรรมการ



(รศ. ดร.นิตราชัย โชติชูช่างกูร)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

นายพงศกร เปรมศรี : การประยุกต์ใช้โมเดลการตรวจจับและติดตามยานพาหนะในการ
ประมาณค่าตัวแปรกระแสจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ
(APPLICATION OF VEHICLE DETECTION AND TRACKING MODEL: ESTIMATION OF
TRAFFIC FLOW VARIABLE BASED ON MOVING OBSERVER METHOD)
อาจารย์ที่ปรึกษา: ผู้ช่วยศาสตราจารย์ ร้อยเอก ดร.สุทธิพงษ์ มีโย, 138 หน้า.

คำสำคัญ : ตัวแปรกระแสจราจร/การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ/
ปัญญาประดิษฐ์/การตรวจจับยานพาหนะ

การสำรวจสภาพจราจรเป็นส่วนสำคัญเพื่อให้ได้ข้อมูลที่จำเป็นในการวิเคราะห์ ออกแบบ
วางแผน ประเมินและบริหารจัดการด้านการขนส่งและจราจร วิธีการสำรวจจราจรโดยการเคลื่อนที่
ของยานพาหนะหรือ Moving Observer Method (MOM) เป็นวิธีการสำรวจจราจรที่ถูกนำมาใช้
อย่างแพร่หลายในการประมาณค่าตัวแปรกระแสจราจรระดับมหภาคซึ่งเป็นวิธีที่มีความง่ายต่อการใช้
งาน และประหยัดเวลาและค่าใช้จ่ายในการดำเนินการ

งานวิจัยนี้ได้นำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้กับการสำรวจจราจรโดยใช้
(1) YOLOv7 Architecture ในการตรวจจับยานพาหนะ, (2) StrongSORT Architecture ในการ
ติดตามยานพาหนะ และ (3) เทคนิค Canny Edge Detection กับ Hough Transform ในการ
ตรวจจับเส้นสีจราจรเพื่อนำมาจำแนกประเภทและรูปแบบเคลื่อนที่ของยานพาหนะ จากนั้นนำ
ผลลัพธ์ที่ได้ไปใช้ในการประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยทดลองใช้กับชุด
ข้อมูลสำรวจจราจรด้วยกล้องวิดีโอหน้ารถบนถนนระหว่างเมือง 5 ช่วงถนนที่มี 1 ช่องจราจรต่อ
ทิศทางแบบไม่มีเกาะกลางในประเทศไทย

โดยผลการประเมินประสิทธิภาพของโมเดลในการจำแนกประเภทและรูปแบบการเคลื่อนที่
ของยานพาหนะ (จำนวนรถทิศทางตรงข้าม รถที่แซงรถสำรวจ และรถที่ถูกรถสำรวจแซง)
มีค่า F1-score เท่ากับ 93.25, 94.79, 64.62% ตามลำดับ และเมื่อเปรียบเทียบผลการประมาณ
ค่าตัวแปรกระแสจราจรตามวิธีสำรวจแบบ MOM (อัตราการไหล ความเร็วเฉลี่ย และความหนาแน่น
กระแสจราจร) ระหว่างการใช้ผลการจำแนกที่ได้จากโมเดลกับข้อมูลสำรวจจราจรจริง พบว่า
(1) มีเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเท่ากับ 2.36, 0.73 และ 2.86% ตามลำดับ และ
(2) มีเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์สูงสุดเท่ากับ 7.88, 5.80 และ 7.65% ตามลำดับ

สาขาวิชา วิศวกรรมขนส่ง
ปีการศึกษา 2566

ลายมือชื่อนักศึกษา นพดล
ลายมือชื่ออาจารย์ที่ปรึกษา ส.ป.

PONGSAKORN PREMSRI: APPLICATION OF VEHICLE DETECTION AND TRACKING MODEL: ESTIMATION OF TRAFFIC FLOW VARIABLE BASED ON MOVING OBSERVER METHOD. THESIS ADVISOR: ASST. PROF. FLT.LT. DR. SUTTHIPONG MEEYAI, 138 PP.

Keyword : Traffic flow variable/Moving observer method/Artificial Intelligence/
Vehicle detection

Traffic surveys are essential information for analysis, design, planning, assessment and management of traffic and transportation. A Moving Observer Method (MOM) is a traffic survey method, which is widely used to determine macroscopic variables. The MOM has several benefits: easy implementation, low cost and time saving

This study applies Artificial Intelligence (AI) techniques for traffic surveys by using (1) YOLOv7 architecture for vehicle detection, (2) StrongSORT architecture for vehicle tracking, and (3) Canny Edge detection and Hough Transform algorithm for lane line detection to classify vehicle type and movement. Then, the traffic flow variables were estimated according to the MOM. The traffic survey using a front vehicle camera was conducted on five intercity single carriageway roads in Thailand

The results show that the performance, F1-score, of vehicle type and movement classification (number of opposing vehicles, vehicle overtaking the test car, and vehicle passed by the test car) are 93.25, 94.79, and 64.62%, respectively. The comparison of traffic flow variable estimation based on the MOM (flow rate, mean speed, and density) and the actual data indicate that (1) the mean absolute percentage error are 2.36, 0.73 and 2.86% respectively and (2) the highest absolute percentage error are 7.88, 5.80 and 7.65%, respectively.

School of Transportation Engineering
Academic Year 2023

Student's Signature
Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดี ผู้วิจัยขอกราบขอบพระคุณ บุคคล และกลุ่มบุคคลต่าง ๆ ที่ได้กรุณาให้คำปรึกษา แนะนำและช่วยเหลือทั้งในด้านวิชาการและการดำเนินงานในงานวิจัย อาทิเช่น

ขอขอบคุณ ผู้ช่วยศาสตราจารย์ ร้อยเอก ดร.สุทธิพงษ์ มีโย อาจารย์ที่ปรึกษางานวิจัยที่กรุณาให้คำปรึกษา แนะนำ ชี้แนะให้เห็นถึงข้อบกพร่องและแนวทางการดำเนินการวิจัยที่ถูกต้อง

ขอขอบพระคุณ ประธานกรรมการสอบวิทยานิพนธ์รวมถึงคณะกรรมการสอบวิทยานิพนธ์ ได้แก่ ผู้ช่วยศาสตราจารย์ ดร.ศิริตล ศิริธร และ รองศาสตราจารย์ ดร.อาทิตย์ ศรีแก้ว ที่ตรวจสอบความถูกต้องและครบถ้วนของวิทยานิพนธ์ และแนวทางการปรับปรุงวิทยานิพนธ์ซึ่งทำให้วิทยานิพนธ์นี้มีเนื้อหาที่สมบูรณ์และมีความหนักแน่นทางวิชาการ

ขอขอบคุณพระคุณ คุณวันเพ็ญ สืบสาย และคุณปิยธิดา ปัญหาราช อดีตและเลขานุการสาขาวิชาวิศวกรรมขนส่งที่ให้ความช่วยเหลือในการประสานงานด้านเอกสารต่าง ๆ ในระหว่างการศึกษา

สุดท้ายนี้ผู้วิจัยหวังว่า งานวิจัยนี้จะมีประโยชน์ไม่มากนักน้อย จึงขอยกส่วนดีงามทั้งหมดนี้ให้แก่ อาจารย์ที่ปรึกษาวิทยานิพนธ์ คณะกรรมการสอบวิทยานิพนธ์และเหล่าคณาจารย์ที่ได้มอบความรู้และประสบการณ์แก่ผู้วิจัยตลอดระยะเวลาที่ศึกษาในระดับบัณฑิตศึกษา และขอกราบขอบพระคุณ บิดา มารดา ที่ให้การเลี้ยงดูอบรมและให้สนับสนุนแก่ผู้วิจัยตลอดมา

พงศกร เปรมศรี

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง.....	ช
สารบัญรูป	ญ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย	2
1.3 ขอบเขตการวิจัย.....	3
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
2 ทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 แนวคิดพื้นฐานเกี่ยวกับตัวแปรกระแสจราจร (Fundamental of Traffic Flow Characteristics).....	5
2.2 การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM).....	11
2.3 โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model).....	18
2.4 โมเดลการติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle Tracking Model).....	23

สารบัญ (ต่อ)

หน้า

2.5	โมเดลตรวจจับเส้นสีจราจร (Road Lane Line Detection).....	27
2.6	งานวิจัยที่เกี่ยวข้อง.....	28
3	วิธีดำเนินการวิจัย.....	30
3.1	การรวบรวมข้อมูล.....	30
3.1.1	พื้นที่ศึกษาในการสำรวจข้อมูลจราจรตามวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ	30
3.1.2	รูปที่ใช้ในกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ	32
3.2	เครื่องมือที่ใช้ในงานวิจัย.....	35
3.3	การออกแบบภาพรวมของโมเดลที่นำเสนอในงานวิจัย.....	36
3.4	การตั้งค่าและพัฒนาโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ.....	38
3.4.1	โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model) – YOLOv7.....	39
3.4.2	โมเดลติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle Tracking Model) – StrongSORT.....	42
3.4.3	โมเดลสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีจราจร (ROI Based on Lane Line Detection).....	45
3.4.4	โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle Type and Movement Classification Model).....	49
3.4.5	ขั้นตอนการใช้งานโมเดลที่นำเสนอ	56
3.5	การประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Estimation of Traffic Flow Variable Based on Moving Observers Method)	61

สารบัญ (ต่อ)


หน้า

3.6	การประเมินประสิทธิภาพโมเดล	61
3.6.1	การประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ ยานพาหนะ	61
3.6.2	เปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างผลที่ได้จาก จำแนกของโมเดลที่นำเสนอกับข้อมูลสำรวจจริง.....	63
4	ผลการวิเคราะห์ข้อมูลและการอภิปรายผล	65
4.1	ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ	65
4.2	ผลการฝึกฝนโมเดลสำหรับตรวจจับยานพาหนะ	71
4.3	ผลการประเมินประสิทธิภาพโมเดลการจำแนกประเภทและรูปแบบการเคลื่อนที่ของ ยานพาหนะ	76
4.3.1	ประสิทธิภาพด้านความเร็วประมวลผล.....	76
4.3.2	ประสิทธิภาพของการจำแนกประเภทและรูปแบบการเคลื่อนที่ของ ยานพาหนะ	77
4.4	ผลการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่	109
4.5	ผลการเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างข้อมูลจริงกับ โมเดลที่นำเสนอ	115
4.5.1	การประมาณค่าอัตราการไหล (Flow Rate).....	116
4.5.2	การประมาณค่าความเร็วเฉลี่ย (Space Mean Speed)	121
4.5.3	การประมาณค่าความหนาแน่นกระแสจราจร (Density).....	125
4.5.4	สรุปผลความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจร	129
5	สรุปผลและข้อเสนอแนะ	130
5.1	สรุปผลการศึกษา	130
5.2	ข้อเสนอแนะ	132

สารบัญ (ต่อ)

หน้า

รายการอ้างอิง	134
ประวัติผู้เขียน	138



สารบัญตาราง

ตารางที่	หน้า
3.1	รายละเอียดจุดสำรวจข้อมูลจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ 31
3.2	จำนวนรูปภาพยานพาหนะ (Vehicle Caption) และค่า PCU Factor ของแต่ละประเภท 35
3.3	การตั้งค่า Hyperparameter ของกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ 40
3.4	การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลตรวจจับยานพาหนะ 41
3.5	การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลติดตามยานพาหนะ 43
3.6	ขั้นตอนการปรับแก้เส้นกรอบพื้นที่ทางซ้ายมือ 48
3.7	ขั้นตอนการจำแนกรถทิศทางตรงข้าม 51
3.8	ขั้นตอนการจำแนกรถที่ถูกรถสำรวจแซง 52
3.9	ขั้นตอนการจำแนกรถที่แซงรถสำรวจ 53
3.10	การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลที่นำเสนอ 57
3.11	ความคลาดเคลื่อนที่ยอมรับได้ในประมาณค่าปริมาณจราจร 64
4.1	ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่วิ่งทิศทางตรงข้าม)..... 66
4.2	ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่ถูกรถสำรวจแซง)..... 67
4.3	ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่แซงรถสำรวจ) 69
4.4	ผลการสรุปข้อมูลสำรวจและจำนวนยานพาหนะเฉลี่ยในแต่ละจุดสำรวจ 70
4.5	ผลประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะกับรูปภาพยานพาหนะ (Validation Dataset) 73
4.6	ผลประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะกับรูปภาพยานพาหนะ (Testing Dataset)..... 75
4.7	ประสิทธิภาพด้านความเร็วประมวลผลเฉลี่ยของโมเดลที่นำเสนอ 76

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.8 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถทิศทางตรงข้าม (แบบรายประเภทยานพาหนะ).....	77
4.9 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถทิศทางตรงข้าม (แบบรายจุดสำรวจ).....	78
4.10 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถที่ถูกรถสำรวจแซง (แบบรายประเภทยานพาหนะ).....	85
4.11 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถที่ถูกรถสำรวจแซง (แบบรายจุดสำรวจ).....	86
4.12 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถที่แซงรถสำรวจ (แบบรายประเภทยานพาหนะ).....	93
4.13 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ - รถที่แซงรถสำรวจ (แบบรายจุดสำรวจ).....	93
4.14 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ (แบบรายประเภทยานพาหนะ).....	97
4.15 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ - ยานพาหนะไหล่ทางซ้าย (แบบรายจุดสำรวจ).....	97
4.16 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ - ยานพาหนะไหล่ทางขวา (แบบรายจุดสำรวจ).....	102
4.17 Confusion Matrix ของการจำแนกประเภทยานพาหนะโดยรวม.....	105
4.18 Confusion Matrix ของการจำแนกประเภทยานพาหนะมุมด้านหน้า (เฉพาะรถทิศทาง ตรงข้าม).....	105
4.19 Confusion Matrix ของการจำแนกประเภทยานพาหนะมุมด้านหลังและด้านข้าง (เฉพาะรถ ที่แซงและถูกรถสำรวจแซง).....	106

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.20 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ โดยรวม (Vehicle Type and Movement Classification Model).....	108
4.21 ผลการประเมินประสิทธิภาพโมเดลจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ โดยรวม (On-Left/Right Shoulder Vehicle Classification)	108
4.22 ผลการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบตามวิธีการสำรวจโดยการเคลื่อนที่ ของยานพาหนะ.....	110
4.23 เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบ การเคลื่อนที่	112
4.24 ผลการประมาณค่าอัตราการไหลระหว่างค่าจริงกับค่าที่ได้จากโมเดล	116
4.25 ผลการเปรียบเทียบการประมาณค่าอัตราการไหล	120
4.26 ผลการประมาณค่าความเร็วเฉลี่ยระหว่างค่าจริงกับค่าที่ได้จากโมเดล	121
4.27 ผลการประมาณค่าความหนาแน่นระหว่างค่าจริงกับค่าที่ได้จากโมเดล	125

สารบัญรูป

รูปที่	หน้า
2.1	กราฟความสัมพันธ์ระหว่างความเร็วกับความหนาแน่นกระแสจราจร 8
2.2	กราฟความสัมพันธ์ระหว่างอัตราการไหลกับความหนาแน่นกระแสจราจร 9
2.3	กราฟความสัมพันธ์ระหว่างความเร็วกับอัตราการไหล 10
2.4	ตัวอย่างขั้นตอนการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM) 12
2.5	การเปรียบเทียบประสิทธิภาพระหว่างค่า AP (Average Precision) กับค่า Inference Time ของโมเดลตรวจจับวัตถุ 20
2.6	โครงสร้างสถาปัตยกรรมของ YOLOv7 22
2.7	การเปรียบเทียบประสิทธิภาพระหว่างค่า IDF1 กับ MOTA ของอัลกอริทึมติดตามวัตถุ 24
2.8	ภาพรวมของกระบวนการติดตามวัตถุ DeepSORT Algorithm 24
2.9	การเปรียบเทียบโครงสร้างและประสิทธิภาพของอัลกอริทึม DeepSORT กับ StrongSORT 25
3.1	Key Map จุดสำรวจข้อมูลจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ 32
3.2	ตัวอย่างรูปที่ใช้ในการฝึกฝนโมเดลตรวจจับยานพาหนะ 33
3.3	ตัวอย่างยานพาหนะทั้ง 8 ประเภทที่ทำการจำแนกประเภทยานพาหนะในงานวิจัย 34
3.4	กระบวนการทำงานของโมเดลที่นำเสนอในงานวิจัย 36
3.5	Flow Chart ของกระบวนการจัดเตรียมข้อมูล, การฝึกฝนโมเดลและการใช้งานโมเดลตรวจจับยานพาหนะ 39
3.6	ตัวอย่างผลลัพธ์ที่ได้จากโมเดลตรวจจับยานพาหนะ 42
3.7	ตัวอย่างผลลัพธ์การติดตามการเคลื่อนที่ของยานพาหนะในแต่ละไอดี 44
3.8	ขั้นตอนการสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีจราจร (ROI Based on Lane Line Detection) 46

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.9	Flow Chart ของการใช้งานโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ.. 50
3.10	ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ A) นั้บรทิศทางตรงข้าม 54
3.11	ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ B) รถกำลังถูกรถสำรวจแซง 54
3.12	ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ C) รถกำลังแซงรถสำรวจ 55
3.13	ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ D) จำแนกรถบนไหล่ทางด้วยกรอบพื้นที่ที่สร้างขึ้น 55
3.14	ขั้นตอนการใช้งานโมเดลที่น่าเสนอ 56
3.15	ตัวอย่างภาพวิดีโอในขั้นตอนการระบุตำแหน่งกรอบพื้นที่สนใจ 59
4.1	กราฟแสดงค่า Box Loss, Objectness Loss, Classification Loss, Precision, Recall และ mAP ต่อจำนวนรอบในการฝึกฝนโมเดลตรวจจับยานพาหนะ 72
4.2	กราฟแสดงค่า mAP ของการฝึกฝนโมเดลตรวจจับยานพาหนะ 72
4.3	Confusion Matrix ของการจำแนกประเภทยานพาหนะกับรูปภาพยานพาหนะ (Validation Dataset)..... 74
4.4	Confusion Matrix ของการจำแนกประเภทยานพาหนะกับรูปภาพยานพาหนะ (Testing Dataset)..... 75
4.5	ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ – รถทิศทางตรงข้าม (แบบรายจุดสำรวจ)..... 80
4.6	ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ E) กรอบพื้นที่ในขนาดที่เกินจากขอบเขตช่องจราจรที่สนใจ..... 82

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.7 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ F) กรอบพื้นที่คลาดเคลื่อนจากขอบเขตช่องจราจรที่สนใจ.....	83
4.8 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ G) เหตุการณ์การติดตามไอติของยานพาหนะผิดพลาดทำให้โมเดลเกิดการนับซ้ำหรือไม่นับ ยานพาหนะที่วิ่งผ่านเส้น Counting Line.....	84
4.9 ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ – รถที่ถูกรถสำรวจแซง (แบบรายจุดสำรวจ).....	88
4.10 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ H) กรอบพื้นที่ไม่สอดคล้องกับช่องจราจรทำให้จำแนกรถบนไหล่ทางซ้ายเป็นรถที่ถูกรถ สำรวจแซงบริเวณตรงและทางโค้ง.....	90
4.11 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ I) รถจักรยานยนต์วิ่งทับเส้นไหล่ทางซ้ายทำให้โมเดลจำแนกเป็นรถที่ถูกรถสำรวจแซง	91
4.12 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ J) โมเดลไม่สามารถตรวจจับเหตุการณ์แซงรถบรรทุกที่วิ่งทับเส้นจราจรไหล่ทางซ้ายได้	92
4.13 ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ – รถที่แซงรถสำรวจ (แบบรายจุดสำรวจ).....	95
4.14 ผลการเปรียบเทียบค่าความแม่นยำของโมเดลจำแนกรถบนไหล่ทางซ้ายออกจากการคำนวณ รายจุดสำรวจ.....	99
4.15 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ K) โมเดลไม่สามารถตรวจจับเส้นสีจราจรและปรับแก้ตำแหน่งของกรอบใหม่ได้	101
4.16 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ M) โมเดลสร้างกรอบพื้นที่ปรับแก้เส้นขอบถนนเป็นตัวแทนของเส้นไหล่ทางซ้าย	101
4.17 ผลการเปรียบเทียบค่าความแม่นยำของโมเดลจำแนกรถบนไหล่ทางขวาออกจากการคำนวณ รายจุดสำรวจ.....	103

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.18	ผลเปรียบเทียบการประมาณค่าจำนวนรถทิศทางตรงข้ามระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล..... 111
4.19	ผลเปรียบเทียบการประมาณค่าจำนวนรถที่ถูกรถสำรวจวิ่งแข่งระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล 111
4.20	ผลเปรียบเทียบการประมาณค่าจำนวนรถที่แข่งรถสำรวจระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล..... 112
4.21	เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถทิศทางตรงข้าม 114
4.22	เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถที่ถูกรถสำรวจแข่ง..... 115
4.23	ผลการเปรียบเทียบค่าอัตราการไหลในแต่ละช่วงเวลาสำรวจ 117
4.24	ผลการเปรียบเทียบค่าอัตราการไหลระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาสำรวจ..... 118
4.25	ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าอัตราการไหลในแต่ละช่วงเวลาสำรวจ 119
4.26	ผลการเปรียบเทียบค่าความเร็วเฉลี่ยในแต่ละช่วงเวลาสำรวจ 122
4.27	ผลการเปรียบเทียบค่าความเร็วเฉลี่ยระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาสำรวจ..... 123
4.28	ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความเร็วเฉลี่ยในแต่ละช่วงเวลาสำรวจ 124
4.29	ผลการเปรียบเทียบค่าความหนาแน่นกระแสจราจรในแต่ละช่วงเวลาสำรวจ 126
4.30	ผลการเปรียบเทียบค่าความหนาแน่นกระแสจราจรระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาสำรวจ 127
4.31	ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความหนาแน่นกระแสจราจรในแต่ละช่วงเวลาสำรวจ 128
4.32	Box and Whisker ของค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าตัวแปรกระแสจราจร 129

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

การสำรวจสภาพจราจร (Traffic Survey) เป็นหนึ่งส่วนสำคัญที่ต้องคำนึงถึงเพื่อนำข้อมูลจราจรที่ถูกต้อง มีความน่าเชื่อถือและรวดเร็วไปใช้ในการวิเคราะห์ วางแผน ออกแบบในการบริหารจัดการด้านการขนส่งและจราจร ไม่ว่าจะเป็นการนำไปใช้กับเทคโนโลยีระบบขนส่งและจราจรอัจฉริยะ (Intelligent Transportation System) ในการบริหารจัดการการจราจรและอุบัติเหตุ การออกแบบโครงสร้างพื้นฐาน และการวิเคราะห์ข้อมูลจราจรและอุบัติเหตุเชิงลึกเพื่อเพิ่มประสิทธิภาพในด้านความปลอดภัยและความสะดวกสบายต่อผู้ใช้ที่ถนน เป็นต้น

ปัจจุบันเทคโนโลยีปัญญาประดิษฐ์หรือ Artificial Intelligence (AI) ในด้าน Computer Vision มีบทบาทอย่างมากในการประมวลผลข้อมูลจากกล้องวิดีโอหรืออุปกรณ์เซนเซอร์ต่าง ๆ เพื่อตรวจจับและวิเคราะห์รูปแบบและพฤติกรรมของการจราจร เช่น การจำแนกประเภทยานพาหนะ การตรวจจับยานพาหนะเพื่อประมาณค่าปริมาณจราจรและความเร็วของยานพาหนะ เป็นต้น ซึ่งทำให้ได้ข้อมูลที่มีความถูกต้องแม่นยำและสามารถนำไปใช้งานได้แบบเรียลไทม์ โดยทั่วไปการสำรวจจราจรระดับมหภาค (Macroscopic Traffic Flow) เพื่ออธิบายพฤติกรรมของผู้ใช้ถนนโดยรวมนั้นจะถูกสำรวจในรูปแบบเฉพาะจุด (Stationary Observer) ซึ่งมีข้อเสียคือ ข้อมูลเป็นแบบเฉพาะจุดซึ่งอาจไม่ครอบคลุมพฤติกรรมจราจรของช่วงถนนที่สนใจ ยกต่อการติดตั้งอุปกรณ์เพื่อสำรวจในบางจุด เป็นต้น โดยยังมีวิธีสำรวจจราจรอีกวิธีหนึ่งที่มีชื่อว่า การสำรวจโดยการเคลื่อนที่ของยานพาหนะ หรือ Moving Observer Method (MOM) ที่ทำการวิ่งรถสำรวจเพื่อบันทึกข้อมูลจราจรในทิศทางตรงข้ามและทิศทางเดียวกันเพื่อประมาณค่าตัวแปรกระแสจราจรได้ทั้ง 3 ตัวแปรซึ่งมีข้อดีคือ สามารถประมาณค่าอัตราการไหล ความเร็วและเวลาเฉลี่ยในการเดินทาง และความหนาแน่นของกระแสจราจรที่เป็นค่าตัวแทนเฉลี่ยของทั้งช่วงถนนได้พร้อมกันโดยไม่จำเป็นต้องติดตั้งอุปกรณ์บนถนน, ใช้เวลาสำรวจเพื่อให้ได้ข้อมูลที่อยู่ในระดับความน่าเชื่อถือที่เหมาะสมน้อยกว่าแบบเฉพาะจุด และได้ข้อมูลจราจรเพิ่มเติม เช่น จุดขัดแย้งหรือเหตุการณ์ที่ทำให้กระแสจราจรเกิดความผันผวนบนช่วงถนนที่สำรวจ เป็นต้น

เพื่อประยุกต์ใช้เทคโนโลยีกับการสำรวจจราจรเพื่อช่วยลดจำนวนคน เวลาและค่าใช้จ่ายในการดำเนินการ การศึกษานี้จึงมีวัตถุประสงค์ในการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ด้าน Computer Vision ในการพัฒนา (1) โมเดลตรวจจับยานพาหนะเพื่อระบุตำแหน่งและจำแนกประเภทยานพาหนะ (2) โมเดลติดตามการเคลื่อนที่ของยานพาหนะเพื่อใช้ในการจำแนกรูปแบบการเคลื่อนที่ และ (3) โมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อจำแนกเฉพาะยานพาหนะที่สนใจ (เฉพาะยานพาหนะที่วิ่งบนช่องจราจร) และไม่สนใจออกในการคำนวณ ได้แก่ ยานพาหนะที่จอดและวิ่งบนไหล่ทางและจอดตามที่อยู่อาศัยบริเวณขอบทางถนน เป็นต้น โดยใช้โมเดลตรวจจับเส้นสีจราจรในการปรับแต่งกรอบพื้นที่ให้สอดคล้องกับช่องจราจรจริงเพื่อใช้กับข้อมูลสำรวจจราจรที่ได้จากวิดีโอกล้องหน้ารถ จากนั้นนำผลลัพธ์ที่ได้จากทั้ง 3 โมเดลไปสร้าง (4) โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะเพื่อนับและจำแนกประเภทยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ แล้วนำผลลัพธ์ที่ได้ไปประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ โดยโมเดลที่นำเสนอในงานวิจัยนี้ถูกพัฒนาขึ้นสำหรับการทดลองใช้กับข้อมูลวิดีโอกล้องหน้ารถที่สำรวจบนถนนระหว่างเมืองที่มี 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางในประเทศไทย แล้วทำการประเมินประสิทธิภาพการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะของโมเดลที่นำเสนอและเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างการนำผลลัพธ์ที่ได้โมเดลที่นำเสนอกับข้อมูลสำรวจจริง

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 ประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) กับการสำรวจจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM) โดยสร้างโมเดลเพื่อการตรวจจับและจำแนกประเภทลักษณะของยานพาหนะและรูปแบบการเคลื่อนที่ซึ่งประกอบด้วย (1) รถที่วิ่งในทิศทางตรงข้าม (Opposing Vehicle), (2) รถที่รถสำรวจแซง (Passed Vehicle) และ (3) รถที่แซงรถสำรวจ (Overtaking Vehicle) เป็นต้น ซึ่งโมเดลที่นำเสนอจะประกอบ 4 โมเดลดังนี้

- 1) โมเดลตรวจจับยานพาหนะเพื่อระบุตำแหน่งและจำแนกประเภทยานพาหนะ
- 2) โมเดลติดตามการเคลื่อนที่ของยานพาหนะเพื่อใช้ในการจำแนกรูปแบบการเคลื่อนที่

3) โมเดลสร้างกรอบพื้นที่เพื่อจำแนกเฉพาะยานพาหนะที่สนใจ (เฉพาะยานพาหนะที่วิ่งบนช่องทางจราจร) และจำแนกยานพาหนะไม่สนใจออกในการคำนวณ ได้แก่ ยานพาหนะที่จอดและวิ่งบนไหล่ทางซ้ายและขวา และยานพาหนะที่จอดตามที่อยู่อาศัยบริเวณขอบทางถนน เป็นต้น เพื่อให้ได้ค่าตัวแปรกระแสจราจรที่เป็นตัวแทนของกระแสจราจรจริงที่วิ่งเฉพาะบนช่องทางจราจร

จากนั้นนำผลลัพธ์ของโมเดลทั้ง 3 มาสร้าง 4) โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะเพื่อนับและจำแนกจำนวนยานพาหนะในแต่ละประเภทและรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบ แล้วนำจำนวนยานพาหนะที่ได้ไปใช้ในการประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

1.2.2 ประเมินประสิทธิภาพของโมเดลในการตรวจนับและจำแนกประเภทลักษณะของยานพาหนะและรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบ และเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างการใช้ผลลัพธ์ที่ได้จากจำแนกโมเดลที่นำเสนอ กับข้อมูลสำรวจจริง ได้แก่ (1) อัตราการไหล (Flow Rate), (2) ความเร็วเฉลี่ย (Space Mean Speed) และ (3) ความหนาแน่นของกระแสจราจร (Density) เป็นต้น

1.3 ขอบเขตการวิจัย

1.3.1 ทำการสำรวจจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะบนถนนทางหลวงระหว่างเมืองที่มีจำนวนช่องทางจราจร 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางและมีการไหลกระแสจราจรแบบต่อเนื่องบนช่วงเวลาไม่เร่งด่วนและช่วงเร่งด่วน

1.3.2 การจำแนกประเภทยานพาหนะในงานวิจัยนี้แบ่งออกเป็น 8 ประเภท ได้แก่


- 1) รถจักรยานยนต์
- 2) รถยนต์ส่วนบุคคลน้อยกว่าเท่ากับ 7 ที่นั่ง (มีลักษณะเป็น Sedan และ Hatchback)
- 3) รถยนต์ส่วนบุคคลน้อยกว่าเท่ากับ 7 ที่นั่ง (มีลักษณะเป็น SUV และ MUV)
- 4) รถยนต์ส่วนบุคคลมากกว่า 7 ที่นั่ง (มีลักษณะเป็นรถตู้)
- 5) รถบรรทุกขนาดเล็ก (มีลักษณะเป็นรถกระบะแบบไม่มีตู้บรรทุกสินค้า)
- 6) รถบรรทุกขนาดเล็ก (มีลักษณะเป็นรถกระบะแบบมีตู้บรรทุกสินค้า)
- 7) รถบรรทุกขนาดใหญ่
- 8) รถโดยสารขนาดกลางและใหญ่

1.3.3 ซอฟต์แวร์เลือกใช้ระบบปฏิบัติการ Windows 10 และใช้ภาษาคอมพิวเตอร์ Python ในการสร้างโมเดลที่นำเสนอในงานวิจัย

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 สามารถนำโมเดลที่นำเสนอไปใช้ปฏิบัติจริงในการตรวจจับประเภทลักษณะของ ยานพาหนะและรูปแบบการเคลื่อนที่ของยานพาหนะ แล้วนำผลลัพธ์ที่ได้ไปใช้ประมาณค่าตัวแปร กระแสจราจรระดับมหภาคตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะบนถนนทางหลวงระหว่าง เมืองในประเทศไทย

1.4.2 ทราบถึงประสิทธิภาพของโมเดลที่นำเสนอ ข้อดี/ข้อเสีย และแนวทางปรับปรุงและพัฒนาต่อยอดเพื่อให้โมเดลมีประสิทธิภาพในการจำแนกประเภทและรูปแบบเคลื่อนที่ตามวิธีสำรวจ โดยการเคลื่อนที่ของยานพาหนะ และสามารถนำไปประยุกต์ในการสำรวจจราจรบนช่วงถนนที่มี ลักษณะกายภาพในรูปแบบอื่น ๆ ได้ในอนาคต เช่น ถนน 2 ช่องจราจรต่อทิศทาง มีเกาะกลางคั่น ระหว่างกลาง เป็นต้น



บทที่ 2

ทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ตามวัตถุประสงค์ของงานวิจัยที่ต้องการนำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method : MOM) เนื้อหาในบทนี้กล่าวถึงการทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการสำรวจโดยการเคลื่อนที่ของยานพาหนะและเทคโนโลยีปัญญาประดิษฐ์ในด้านต่าง ๆ ที่เกี่ยวข้องมาประยุกต์ใช้ในการวิจัยซึ่งแบ่งเนื้อหาออกเป็น 6 ส่วนดังนี้

ส่วนที่ 1 แนวคิดพื้นฐานเกี่ยวกับตัวแปรกระแสจราจร (Fundamental of Traffic Stream Characteristics)

ส่วนที่ 2 การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM)

ส่วนที่ 3 โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model)

ส่วนที่ 4 โมเดลการติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle Tracking Model)

ส่วนที่ 5 โมเดลตรวจจับเส้นจราจร (Road Lane Line Detection)

ส่วนที่ 6 งานวิจัยที่เกี่ยวข้อง

2.1 แนวคิดพื้นฐานเกี่ยวกับตัวแปรกระแสจราจร (Fundamental of Traffic Flow Characteristics)

Garber and Hoel (2019) ได้กล่าวถึงแนวคิดพื้นฐานเกี่ยวกับตัวแปรกระแสจราจรแบบมหภาค (Macroscopic Traffic Variables) ซึ่งประกอบด้วย 3 ตัวแปร ได้แก่

1) อัตราการไหล (Flow Rate) คือ อัตราส่วนระหว่างจำนวนยานพาหนะที่วิ่งผ่านจุดใดจุดหนึ่งต่อช่วงเวลา โดยสามารถคำนวณได้ดังสมการที่ (2.1)

$$q = \frac{n \times 3600}{t} \quad (2.1)$$

โดยที่ q คือ อัตราการไหล (คัน/ชม.)
 n คือ จำนวนยานพาหนะที่วิ่งผ่าน (คัน)
 t คือ ช่วงเวลาที่สำรวจ (วินาที)

2) ความหนาแน่น (Density) คือ อัตราส่วนระหว่างจำนวนยานพาหนะที่วิ่งอยู่บนช่วงถนน ต่อความยาวของช่วงถนนที่สำรวจ

$$k = \frac{n}{L} \quad (2.2)$$

โดยที่ k คือ ความหนาแน่น (คัน/กม.)
 n คือ จำนวนยานพาหนะที่วิ่งผ่าน (คัน)
 L คือ ความยาวของช่วงถนน (กม.)

3) ความเร็ว (Speed) คือ ความเร็วของกระแสจราจรที่วิ่งบนถนน โดยสามารถแบ่งย่อย ออกเป็น 2 ประเภทคือ

3.1) Time Mean Speed คือ ความเร็วเฉลี่ยของยานพาหนะแต่ละคันที่วิ่งผ่านจุดใดจุด หนึ่ง โดยมีสมการดังสมการที่ (2.3)

$$\bar{u}_t = \frac{1}{n} \sum_{i=1}^n u_i \quad (2.3)$$

โดยที่ \bar{u}_t คือ ความเร็วเฉลี่ยแบบ Time Mean Speed (กม./ชม.)
 n คือ จำนวนยานพาหนะ (คัน)
 u_i คือ ความเร็วของยานพาหนะที่ i (กม./ชม.)

3.2) Space Mean Speed คือ ความเร็วเฉลี่ยของยานพาหนะที่ได้จากการนำระยะทางที่ยานพาหนะวิ่งทั้งหมดหารด้วยเวลาที่ใช้ในการเดินทางระหว่างจุดเริ่มต้นจนถึงจุดสิ้นสุด ซึ่งเป็นความเร็วที่ใช้ในความสัมพันธ์ Flow-Speed-Density Relationship โดยสามารถคำนวณได้ดังสมการที่ (2.4) หรือ (2.6)

$$\bar{u}_s = \frac{n}{\sum_{i=1}^n \left(\frac{1}{u_i}\right)} \quad (2.4)$$

$$\bar{u}_s = \frac{nL}{\sum_{i=0}^n t_i} \quad (2.5)$$

โดยที่	\bar{u}_s	คือ	ความเร็วเฉลี่ยแบบ Space Mean Speed (กม./ชม.)
	n	คือ	จำนวนยานพาหนะ (คัน)
	t_i	คือ	ระยะเวลาที่ยานพาหนะวิ่งผ่านจุดเริ่มต้นจนถึงจุดสิ้นสุดของยานพาหนะที่ i (ชม.)
	u_i	คือ	ความเร็วของยานพาหนะที่ i (กม./ชม.)
	L	คือ	ความยาวของช่วงถนน (เมตร)

โดยตัวแปรกระแสจราจรทั้ง 3 ตัวมีความสัมพันธ์ดังสมการที่ (2.6)

$$q = k\bar{u}_s \quad (2.6)$$

โดยที่	q	คือ	อัตราการไหล (คัน/ชม.)
	k	คือ	ความหนาแน่นของกระแสจราจร (คัน/กม.)
	\bar{u}_s	คือ	ความเร็วเฉลี่ยแบบ Space Mean Speed (กม./ชม.)

ซึ่งความสัมพันธ์ของตัวแปรกระแสจราจรทั้ง 3 โดยพื้นฐานนั้นสามารถอธิบายได้จาก Greenshield's Model (Greenshields, Bibbins, Channing, & Miller, 1934) ที่มีการตั้งสมมุติฐานว่าความสัมพันธ์ระหว่างความเร็วและความหนาแน่นที่มีรูปแบบเป็นเส้นตรงทำให้เกิดสมการความสัมพันธ์ระหว่างความเร็วและความหนาแน่นดังสมการที่ (2.7) และแสดงดังรูปที่ 2.1

$$\bar{u}_s = \left(u_f - \frac{u_f}{k_j}\right)k \quad (2.7)$$

โดยที่ u_f คือ ความเร็วการไหลอิสระ (กม./ชม.)

k_j คือ ความหนาแน่นของกระแสจราจรสูงสุด (คัน/กม.)



หมายเหตุ จาก Traffic and highway engineering (262), by Garber, N. J., & Hoel, L. A., 2019, Cengage Learning.

รูปที่ 2.1 กราฟความสัมพันธ์ระหว่างความเร็วกับความหนาแน่นกระแสจราจร

โดยเมื่อนำสมการความสัมพันธ์ Flow-Speed-Density Relationship ดังสมการที่ (2.6) มาแปลงค่าให้อยู่ในรูปของ $k = q/\bar{u}_s$ และ $\bar{u}_s = q/k$ แล้วนำไปแทนค่าในสมการที่ (2.7) ทำให้ได้สมการความสัมพันธ์ระหว่างอัตราการไหลกับความหนาแน่นดังสมการที่ (2.8) และความสัมพันธ์ระหว่างความเร็วและอัตราการไหลดังสมการที่ (2.9) ซึ่งแสดงในรูปแบบกราฟความสัมพันธ์ดังรูปที่ 2.2 และรูปที่ 2.3 ตามลำดับ และเมื่อนำสมการที่ (2.8) และ (2.9) ไปใส่ในฟังก์ชันอนุพันธ์เพื่อสร้างสมการความสัมพันธ์ในการหาอัตราการไหลสูงสุด (q_{max}) ซึ่งทำให้จุด Optimum ของความเร็วและความ

หนาแน่นที่ทำให้เกิดอัตราการไหลสูงสุดดังสมการที่ (2.10) และ (2.11) ทำให้สามารถสร้างสมการประมาณค่าอัตราการไหลสูงสุดได้ดังสมการที่ (2.12)

$$q = \left(u_f k - \frac{u_f}{k_j}\right)k^2 \quad (2.8)$$

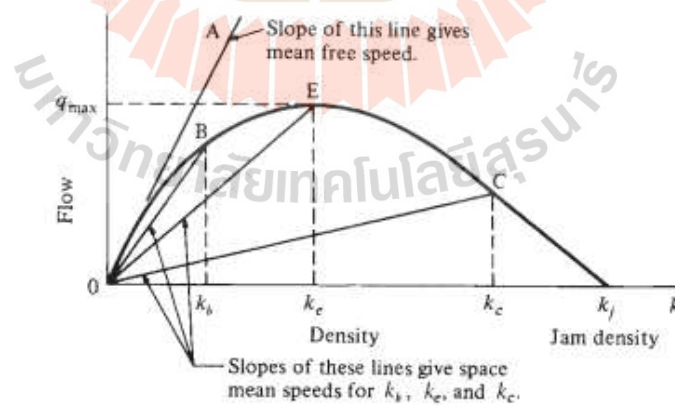
$$\bar{u}_s^2 = \left(u_f \bar{u}_s - \frac{u_f}{k_j}\right)q \quad (2.9)$$

$$k_o = \frac{k_j}{2} \quad (2.10)$$

$$u_o = \frac{2}{k_j} \frac{u_f}{2} \quad (2.11)$$

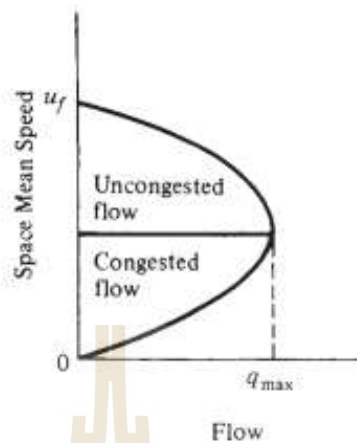
$$q_{\max} = \frac{k_j u_f}{4} \quad (2.12)$$

โดยที่ k_o คือ จุด Optimum Density ที่มีอัตราการไหลสูงสุด (คัน/กม.)
 u_o คือ จุด Optimum Speed ที่มีอัตราการไหลสูงสุด (กม./ชม.)
 q_{\max} คือ อัตราการไหลสูงสุด (คัน/ชั่วโมง)



หมายเหตุ จาก *Traffic and highway engineering* (262), by Garber, N. J., & Hoel, L. A., 2019, Cengage Learning.

รูปที่ 2.2 กราฟความสัมพันธ์ระหว่างอัตราการไหลกับความหนาแน่นกระแสรถ



หมายเหตุ จาก *Traffic and highway engineering* (262), by Garber, N. J., & Hoel, L. A., 2019, Cengage Learning.

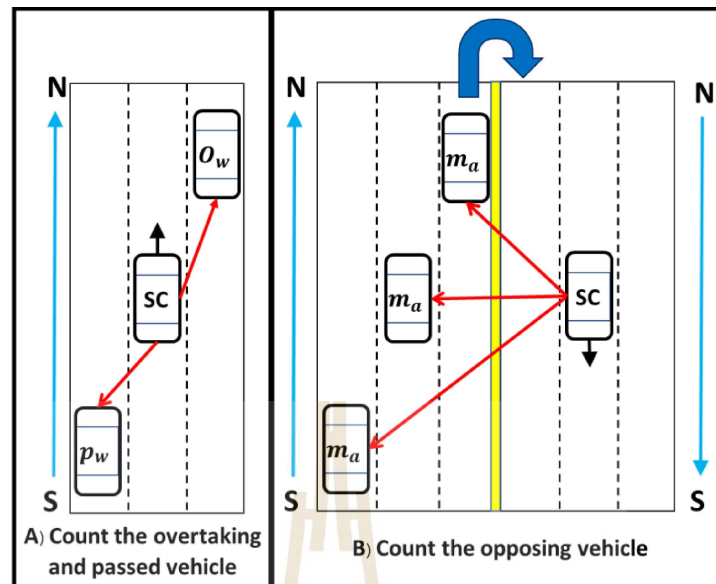
รูปที่ 2.3 กราฟความสัมพันธ์ระหว่างความเร็วกับอัตราการไหล

กราฟความสัมพันธ์ระหว่างตัวแปรกระแสจราจรดังรูปที่ 2.1 ถึงรูปที่ 2.3 สามารถอธิบายได้ดังนี้

- 1) เมื่อความหนาแน่นกระแสจราจรเท่ากับ 0 ทำให้อัตราการไหลจะเท่ากับ 0 เช่นกันดังรูปที่ 2.3 เพราะไม่มียานพาหนะวิ่งบนถนนและส่งผลให้สามารถใช้ความเร็วได้อย่างอิสระ (Free Flow Speed) ดังรูปที่ 2.1 และ
- 2) ถ้าความหนาแน่นเพิ่มขึ้นทำให้อัตราการไหลเพิ่มขึ้นดังรูปที่ 2.2 และอัตราการไหลเพิ่มขึ้นส่งผลให้ความเร็วลดลงเช่นเดียวกันดังรูปที่ 2.3
- 3) เมื่อความหนาแน่นถึงจุดสูงสุดหรือเรียกว่า Jam Density (k_j) ทำให้อัตราการไหลเท่ากับ 0 เพราะยานพาหนะไม่สามารถขยับได้ดังความสัมพันธ์บนกราฟดังรูปที่ 2.2 และส่งผลให้ความเร็วเท่ากับ 0 ดังแสดงความสัมพันธ์บนกราฟรูปที่ 2.1
- 4) ปริมาณจราจรเพิ่มมากขึ้นทำให้ความหนาแน่นเพิ่มขึ้นจาก 0 ไปจุดสูงสุด Jam Density (k_j) จะมีจุด ๆ หนึ่งที่ทำให้ค่าอัตราการไหลอยู่ที่จุดสูงสุด (q_{max}) และลดลงจนเท่ากับ 0 เนื่องจากความหนาแน่นที่สูงขึ้นทำให้จราจรติดขัดและใช้ความเร็วได้ช้าลงจนเท่ากับ 0 ดังรูปที่ 2.2

2.2 การสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM)

วิธีการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method : MOM) ถูกพัฒนาโดย Wardrop and Charlesworth (1954) เพื่อใช้สำรวจตัวแปรกระแสจราจรระดับมหภาค โดยทำการวิ่งรถสำรวจเพื่อบันทึกข้อมูลจำนวนรถที่รถสำรวจแซงและถูกแซง รถทิศทางตรงข้าม และเวลาและระยะทางในการเดินทางขณะวิ่งสำรวจบนช่วงถนน จากนั้นนำข้อมูลสำรวจที่ได้ไปประมาณค่าตัวแปรกระแสจราจรตามสมการความสัมพันธ์ Flow-Speed-Density ดังสมการที่ (2.6) ได้แก่ อัตราการไหล (Flow Rate), ความเร็วเฉลี่ย (Space Mean Speed) และความหนาแน่นกระแสจราจร (Density) เป็นต้น ซึ่งมีข้อดีคือ สามารถประมาณค่าอัตราการไหล ความเร็วและเวลาเฉลี่ยในการเดินทาง และความหนาแน่นของกระแสจราจรที่เป็นค่าตัวแทนเฉลี่ยของทั้งช่วงถนนได้พร้อมกัน, ไม่จำเป็นต้องติดตั้งอุปกรณ์บนถนนใช้เวลาสำรวจเพื่อให้ได้ข้อมูลที่อยู่ในระดับความน่าเชื่อถือที่เหมาะสมน้อยกว่าแบบเฉพาะจุด และได้ข้อมูลจราจรเพิ่มเติม เช่น จุดขัดแย้งที่ทำให้จราจรเกิดความผันผวน เป็นต้น



หมายเหตุ ปรับปรุงจาก “A statistical comparison of traffic measurements from the moving versus stationary observer methods”, by Alhomaidat, F., & Ardekani, S., 2015, *Journal of Transportation Technologies*, 04, 204.

รูปที่ 2.4 ตัวอย่างขั้นตอนการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM)

โดยสมการประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะมีที่มาจากการศึกษากระแสจราจรที่วิ่งบนช่วงถนนที่มีความยาว (L) และมีอัตราการไหลกระแสจราจร (q) ในรูปแบบคงที่ที่วิ่งด้วยความเร็วเฉลี่ย (\bar{v}) หรือ v_{avg} และกำหนดสมมุติฐานให้รถสำรวจที่วิ่งตามกระแสจราจร (With the Stream) จาก S ไป N มีความเร็วคงที่เท่ากับ v_w และรถสำรวจที่วิ่งต้านกระแสจราจร (Against the Stream) จาก S ไป N ด้วยความเร็วคงที่ที่ติดลบเท่ากับ v_u ทำให้สามารถสร้างสมการอัตราการไหลหรือจำนวนรถที่รถสำรวจพบเจอขณะวิ่งต่อช่วงเวลาที่สามารถได้เป็น 2 กรณี ได้แก่ 1) จำนวนรถที่แซงรถสำรวจ (Overtaking Vehicle) (หรือลบด้วยจำนวนรถที่ถูกรถสำรวจแซง (Passed Vehicle) ในกรณีวิ่งตามกระแสจราจรเท่ากับ m_w ต่อเวลาที่ใช้ในการสำรวจจาก S ไป N (t_w) ดังสมการที่ (2.13) และ 2) จำนวนรถที่รถสำรวจพบเจอทั้งหมดในกรณีวิ่งต้านกระแสจราจรจาก S ไป N ซึ่งหมายถึง จำนวนรถทิศทางตรงข้าม (Opposing Vehicle) เมื่อวิ่งจาก N ไป S

(m_a) ต่อเวลาที่ใช้ในการสำรวจจาก N ไป S (t_a) ดังสมการที่ (2.14) โดยสามารถแสดงตัวอย่างการวิ่งสำรวจในรูปแบบที่ 2.4 ที่มีการวิ่งจากจุด S ไป N และวนกลับเพื่อวิ่งจากจุด N ไป S

$$\frac{m_w}{t_w} = q \frac{(v_{avg} - v_w)}{v_{avg}} \quad (2.13)$$

$$\frac{m_a}{t_a} = q \frac{(v_{avg} + v_a)}{v_{avg}} \quad (2.14)$$

โดยที่	q	คือ	อัตราการไหลเฉลี่ย (คัน/ชม.)
	m_w	คือ	จำนวนรถที่แซงรถสำรวจ (หรือลบด้วยจำนวนรถที่ถูกรถสำรวจแซง) ในทิศทางเดียวกันจากจุด S ไป N (คัน)
	m_a	คือ	จำนวนรถที่วิ่งในทิศทางตรงข้ามจากจุด N ไป S (คัน)
	t_w	คือ	เวลาที่ใช้ในการเดินทางในทิศทางเดียวกันจากจุด S ไป N (ชม.)
	t_a	คือ	เวลาที่ใช้ในการเดินทางในทิศทางตรงข้ามจากจุด N ไป S (ชม.)
	v_{avg}	คือ	ความเร็วเฉลี่ยในการเดินทางของทิศทางที่สนใจ (กม./ชม.)
	v_w	คือ	ความเร็วในการเดินทางของทิศทางจากจุด S ไป N (กม./ชม.)
	v_a	คือ	ความเร็วในการเดินทางของทิศทางจากจุด N ไป S (กม./ชม.)

ตามสมมุติฐานที่อัตราการไหลและความเร็วเฉลี่ยมีค่าคงที่ และความเร็วในการเดินทางจาก S ไป N (v_w) และจาก N ไป S (v_a) มีรูปแบบคงที่เช่นกัน ทำให้เกิดสมการความสัมพันธ์ระหว่างเวลา ระยะทางและความเร็วดังสมการที่ (2.15) ถึง (2.17)

$$t_{avg} = \frac{L}{v_{avg}} \quad (2.15)$$

$$t_w = \frac{L}{v_w} \quad (2.16)$$

$$t_a = \frac{L}{v_a} \quad (2.17)$$

จากนั้นนำสมการที่ (2.15) ถึง (2.17) ไปแทนในสมการที่ (2.13) และ (2.14) เพื่อแก้สมการ

$$\frac{m_w}{t_w} = q \left(1 - \frac{v_w}{v_{avg}} \right) \quad (2.18)$$

$$\frac{m_a}{t_a} = q \left(1 + \frac{v_a}{v_{avg}} \right) \quad (2.19)$$

$$m_w = q \left(1 - \left(\frac{L}{t_w} \right) \left(\frac{t_{avg}}{L} \right) \right) (t_w) \quad (2.20)$$

$$m_a = q \left(1 + \left(\frac{L}{t_a} \right) \left(\frac{t_{avg}}{L} \right) \right) (t_a) \quad (2.21)$$

$$m_w = q (t_w - t_{avg}) \quad (2.22)$$

$$m_a = q (t_a + t_{avg}) \quad (2.23)$$

จากการแก้สมการทำให้ได้สมการที่ (2.22) และ (2.23) ซึ่งสามารถสร้างสมการหาค่าอัตราการไหล (q) ของทิศทางที่สนใจได้ตั้งสมการที่ (2.24) แล้วนำตัวแปรไปแทนในสมการความสัมพันธ์ Flow-Speed-Density Relationship ตั้งสมการที่ (2.6) เพื่อให้ได้สมการประมาณค่าตัวแปรกระแสจราจรใหม่ตั้งสมการที่ (2.25) ถึง (2.27)

$$q = \frac{m_w + m_a}{t_w + t_a} = \frac{(o_w - p_w) + m_a}{t_w + t_a} \quad (2.24)$$

$$t_{avg} = t_w - \frac{m_w}{q} \quad (2.25)$$

$$v_{avg} = \frac{L}{t_w - \frac{m_w}{q}} \quad (2.26)$$

$$k = \frac{q}{v_{avg}} \quad (2.27)$$

- โดยที่
- q คือ อัตราการไหล (คัน/ชม.)
 - m_w คือ จำนวนรถที่แซงรถสำรวจ (หรือลบด้วยจำนวนรถที่ถูกรถสำรวจแซง) ในทิศทางเดียวกัน จากจุด S ไป N (คัน)
 - m_a คือ จำนวนรถที่วิ่งในทิศทางตรงข้ามจากจุด N ไป S (คัน)
 - o_w คือ จำนวนรถที่แซงรถสำรวจในทิศทางเดียวกัน (คัน)

p_w	คือ	จำนวนรถที่ถูกรถสำรวจแซงในทิศทางเดียวกัน (คัน)
t_w	คือ	เวลาที่ใช้ในการเดินทางในทิศทางเดียวกันจากจุด S ไป N (ชม.)
t_a	คือ	เวลาที่ใช้ในการเดินทางในทิศทางตรงข้ามจากจุด N ไป S (ชม.)
t_{avg}	คือ	เวลาที่ใช้ในการเดินทางเฉลี่ย (ชม.)
v_{avg}	คือ	ความเร็วเฉลี่ยในการเดินทางของทิศทางที่สนใจ (กม./ชม.)
L	คือ	ระยะทางในการเดินทาง (กม.)
k	คือ	ความหนาแน่นของกระแสจราจร (คัน/กม.)

จากสมการความสัมพันธ์ระหว่างตัวแปรต่าง ๆ ที่ได้กล่าวไว้ในข้างต้น สามารถสรุปได้ว่าการสำรวจจราจรโดยวิธีการเคลื่อนของยานพาหนะ (Moving Observer Method : MOM) จะนำข้อมูลสำรวจที่บันทึกจำนวนรถที่รถสำรวจแซงและถูกแซง รถทิศทางตรงข้าม เวลา และระยะทางในการเดินทางขณะวิ่งสำรวจที่วิ่งสำรวจตั้งตัวอย่างรูปที่ 2.4 ไปแทนค่าในสมการที่ (2.24) เพื่อคำนวณหาค่าอัตราการไหล แล้วนำผลลัพธ์ที่ได้ไปแทนค่าในสมการที่ (2.25) ถึง (2.27) เพื่อหาค่าเวลาเฉลี่ยในการเดินทาง ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรบนทิศทางที่สนใจ จากนั้นจึงนำข้อมูลเหล่านี้ไปใช้ประโยชน์ในการประกอบการวิเคราะห์ ออกแบบ วางแผน ประเมินผลและสร้างแบบจำลองด้านขนส่งและจราจร

การกำหนดเกณฑ์การคัดเลือกช่วงถนนที่เหมาะสมในการสำรวจเป็นส่วนสำคัญที่เพิ่มความน่าเชื่อถือของข้อมูลสำรวจและการประมาณค่าตัวแปรกระแสจราจร โดย Guerrieri and Parla (2021); Guerrieri, Parla, and Mauro (2019) ได้มีการกำหนดเกณฑ์การคัดเลือกถนนที่เหมาะสมกับการสำรวจจราจร ซึ่งได้อ้างถึงเกณฑ์ของ Lee and Brocklebank (1993) ที่ได้การศึกษาเกี่ยวกับความสัมพันธ์ระหว่างความเร็ว อัตราการไหลและลักษณะกายภาพของถนนชนบทที่มีขนาด 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางซึ่งมีการกำหนดเงื่อนไขของช่วงถนนเบื้องต้นในการทดลองดังนี้

- 1) Homogeneity: ถนนมีองค์ประกอบทางเรขาคณิตของถนนเป็นเนื้อเดียวกันทั้งช่วงถนน (ทั้ง Horizontal และ Vertical Alignment)
- 2) Intersections: ไม่มีทางแยกภายในช่วงถนนที่สำรวจหรือห่างจากจุดสิ้นสุดน้อยกว่า 250 เมตร
- 3) Speed Limits: ไม่มีการจำกัดความเร็วในการวิ่งบนช่วงถนนสำรวจที่สำรวจหรือห่างจากจุดสิ้นสุดน้อยกว่า 250 เมตร

4) Roadworks: ไม่มีการก่อสร้างหรือปรับปรุงช่วงถนนที่สำรวจ

5) Length: ความยาวของช่วงถนนที่สำรวจมีความยาว 2-5 กม.

และ O'flaherty and Simons (1970) ได้กล่าวถึงข้อจำกัดของวิธีการสำรวจนี้ประกอบด้วย

1) ความถูกต้องในการประมาณค่าอัตราการไหลและความเร็วของกระแสจราจรมีความอ่อนไหวอย่างมากต่อปริมาณจราจรที่วิ่งบริเวณ On/Off-Ramp และบริเวณทางแยกที่มีการวิ่งตัดกระแสจราจรหลัก โดยสามารถลดความอ่อนไหวที่เกิดขึ้นด้วยการเพิ่มความยาวของช่วงถนนและรอบการสำรวจ และปัญหาที่มีปริมาณจราจรวิ่งเข้าและออกกระแสจราจรหลักที่สำรวจนั้นสามารถแก้ไขได้โดยการสำรวจยานพาหนะที่เลี้ยวเข้า/ออกกระแสจราจรหลักที่สำรวจเพิ่มเติมแล้วนำไปปรับแก้กับการสำรวจข้อมูลจราจรในกระแสจราจรหลัก

2) หากปริมาณจราจรบนช่วงถนนสำรวจมีปริมาณต่ำ (200-300 คัน/ชั่วโมง สำหรับ 2 ช่องจราจรต่อทิศทาง) ในช่วงชั่วโมงไม่เร่งด่วน การสำรวจต้องการรอบในการสำรวจมากขึ้นเพื่อลดความผันผวนของข้อมูลสำรวจ

Mortimer (1957) ได้กล่าวถึงจำนวนรอบสำรวจที่เหมาะสมในการสำรวจโดยวิธีสำรวจการเคลื่อนที่ยานพาหนะ พบว่า จำนวนรอบสำรวจที่เพิ่มขึ้น 6 ถึง 18 รอบส่งผลให้ค่า Relative Standard Error มีอัตราการลดลงที่ต่ำมาก จึงสรุปได้ว่าการสำรวจเพียง 6 รอบนั้นมีความคุ้มค่าด้านค่าใช้จ่ายและเวลาที่ใช้ต่อระดับความถูกต้องของข้อมูล

Mulligan and Nicholson (2002) ที่ได้มีการใช้ Risk Analysis ในการวิเคราะห์ความอ่อนไหวของคุณสมบัติช่วงถนนที่ต้องการสำรวจและประมาณค่าโดยวิธี MOM ประกอบด้วย อัตราการไหล, ความเร็ว, ความยาวของช่วงถนน, เวลาที่ใช้ในการวิ่งสำรวจ และจำนวนรอบสำรวจ พบว่า อัตราการไหล และความยาวถนนหรือเวลาที่ใช้ในการวิ่งสำรวจที่สูงขึ้นยิ่งส่งผลต่อจำนวนรอบที่ใช้ในการสำรวจน้อยลงเพื่อให้ได้ข้อมูลที่อยู่ขอบเขตความคลาดเคลื่อนที่สามารถยอมรับได้ ช่วงถนนที่มีการอัตราการไหลที่ต่ำต้องการจำนวนรอบสำรวจที่มากขึ้นเพื่อให้ได้ข้อมูลที่น่าเชื่อถือซึ่งอาจไม่เหมาะสมต่อการปฏิบัติจริงในการสำรวจ

Alhomaidat and Ardekani (2015) ได้ทำการทดลองเปรียบเทียบผลลัพธ์การประมาณค่าอัตราการไหลและความเร็วเฉลี่ยของกระแสจราจรในการสำรวจจราจรบนถนนทางหลวง 3 ช่องจราจรต่อทิศทางระหว่างการใช้วิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะมีจำนวน 6 รอบสำรวจกับการสำรวจแบบเฉพาะจุด (Stationary Observer Method) เป็นเวลา 30 นาที พบว่า อัตราการไหลและความเร็วเฉลี่ยไม่มีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับความเชื่อมั่นที่ 90%

T. Al-Bahr et al. (2021) ได้ทำการทดลองเปรียบเทียบผลลัพธ์การประมาณค่าอัตราการไหลในการสำรวจจราจรบนช่วงถนนในเขตเมืองบนถนน Jalan Pendidikan จำนวน 2 ช่องจราจรต่อทิศทางซึ่งมี 5 จุดเชื่อมต่อที่ 3 จุดถูกควบคุมด้วยป้ายบังคับจราจรและ 2 จุดถูกควบคุมโดยไฟสัญญาณจราจร 1 ทางแยก โดยเปรียบเทียบระหว่างการใช้วิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะกับการสำรวจแบบเฉพาะจุด (Stationary Observer Method) เป็นเวลา 90 นาที พบว่าเมื่อนำผลการประมาณค่าอัตราการไหลที่วิ่งสำรวจโดยวิธี MOM ที่ถูกเฉลี่ยที่ละ 6 รอบสำรวจไปเปรียบเทียบกับข้อมูลอัตราการไหลที่สำรวจโดยวิธีเฉพาะจุดราย 3 นาทีด้วยวิธีทางสถิติ (Z-standard Normal Distribution) พบว่าค่าอัตราการไหลของทั้ง 2 วิธีไม่มีความแตกต่างกันอย่างมีนัยสำคัญที่ 90% แสดงให้เห็นถึงศักยภาพของวิธีสำรวจ MOM ที่สามารถประมาณค่าอัตราการไหลของจราจรได้แม้อยู่ในสภาวะที่จราจรผันผวนอันเนื่องมาจากทางเชื่อมต่อและทางแยกไฟสัญญาณจราจร

T. M. Al-Bahr, Puan, Hassan, Idham, and Ismail (2019) ได้มีการใช้ Multilinear Regression Analysis ในการวิเคราะห์ความสัมพันธ์ระหว่างจำนวนรอบที่ใช้การสำรวจ MOM ที่ทำให้ค่าอัตราการไหลมีความแปรปรวนน้อยกว่าเท่ากับ 10% กับตัวแปรต่าง ๆ ได้แก่ ความยาวช่วงถนน, ความหนาแน่นของทางแยก (Intersection Density) และความหนาแน่นของช่วงถนนที่ไม่ถูกตัดผ่าน (Driveway Density) เป็นต้น โดยทดลองกับข้อมูลการสำรวจ 20 ช่วงถนน พบว่า ความหนาแน่นของทางช่วงถนนที่ไม่มีการตัดกระแสจราจรที่สูงขึ้นส่งผลต่อจำนวนรอบที่ลดลงมากที่สุดและรองลงมาเป็นความยาวของช่วงถนน และความหนาแน่นของทางแยกไม่มีนัยสำคัญในการเพิ่มขึ้นหรือลดลงของจำนวนรอบสำรวจซึ่งสามารถตีความได้ว่า กระแสจราจรรองของทางแยกในการทดลองที่มีการตัดกับกระแสจราจรหลักนั้นมีปริมาณต่ำกว่าจึงไม่มีการตัดกันจนทำให้กระแสจราจรหลักเกิดการหยุดชะงัก และสมการเชิงเส้นที่สร้างขึ้นมีค่า Constant เท่ากับ 9 ซึ่งตีความได้ว่าจำนวนรอบสำรวจเริ่มต้นที่ทำให้ได้ข้อมูลที่มีความแปรปรวนที่น้อยกว่า 10% เท่ากับ 9 รอบและลดลงตามความยาวช่วงถนน ความหนาแน่นของช่วงถนน

จากการทบทวนงานวิจัยที่ผ่านมาสามารถสรุปได้ว่า อัตราการไหลและความยาวช่วงถนนที่สูงขึ้นส่งผลต่อจำนวนรอบที่ใช้ในการสำรวจเพื่อให้ข้อมูลมีความถูกต้อง มีความน่าเชื่อถือและมีความคลาดเคลื่อนอยู่ในเกณฑ์ที่ผู้ใช้งานสามารถยอมรับ และกระแสจราจรที่ตัดกันบริเวณทางแยกอาจส่งผลต่อความผันผวนของกระแสจราจรซึ่งเป็นสาเหตุให้การประมาณค่าเกิดการคลาดเคลื่อน ดังนั้นการศึกษานี้ผู้วิจัยจึงตั้งหลักเกณฑ์ในการคัดเลือกช่วงถนนที่สำรวจในงานวิจัยไว้ดังนี้

1) เป็นช่วงถนนที่มีการไหลของกระแสจราจรแบบต่อเนื่อง (Uninterrupted Flow) และไม่มีสิ่งกีดขวางหรือเหตุการณ์ต่าง ๆ ที่ทำให้กระแสจราจรติดขัดและเกิดความผันผวนจากปกติ

- 2) องค์ประกอบทางเรขาคณิตของถนนเป็นเนื้อเดียวกันทั้งช่วงถนน ไม่มีเรขาคณิตของถนนหรืออุปสรรคมาบดบังการสำรวจและทำให้กระแสจราจรติดขัด
- 3) ไม่มีทางแยกประกอบในช่วงถนนที่สำรวจหรือมีทางแยกที่มีปริมาณจราจรต่ำที่ไม่ส่งผลกระทบต่อกระแสจราจรหลักที่สำรวจเพื่อลดความไม่ต่อเนื่องและผันผวนของกระแสจราจรและเหตุการณ์อื่นที่ไม่อยู่ในขอบเขตงานวิจัย
- 4) วิ่งสำรวจตามวิธีสำรวจโดยการเคลื่อนที่ยานพาหนะในแต่ละทิศทางอย่างน้อย 6 รอบ ซึ่งเพียงพอต่อความน่าเชื่อถือและไม่เอนเอียงในการประมาณค่าตัวแปรกระแสจราจร

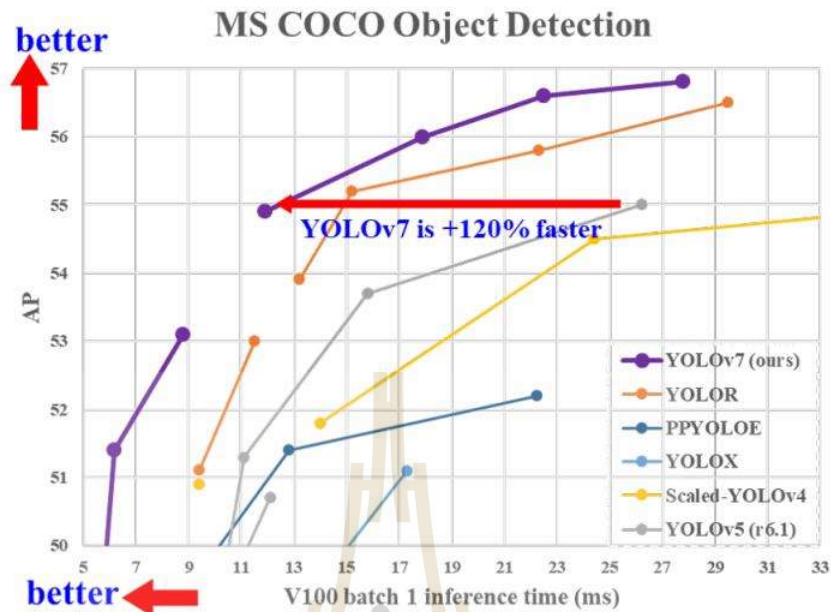
2.3 โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model)

ปัจจุบันมีหลากหลายงานวิจัยที่นำโมเดลตรวจจับวัตถุไปประยุกต์ใช้กับการตรวจจับและจำแนกประเภทยานพาหนะ เทคนิคการเรียนรู้เชิงลึก (Deep Learning) มีความนิยมอย่างมากในการนำมาใช้งานเนื่องจากมีประสิทธิภาพความถูกต้องหรือความเร็วประมวลผลเมื่อเทียบกับวิธีดั้งเดิม ยกตัวอย่างเช่น Boonsirisumpun and Surinta (2021) ได้มีการใช้ Convolutional Neural Network หลากหลายโมเดล (MobileNets, VGG16, VGG19, Inception V3 และ Inception V4) เพื่อเปรียบเทียบประสิทธิภาพในการจำแนกประเภทของยานพาหนะทั้ง 5 ประเภท (Sedan, Hatchback, Pick-up, SUV และอื่น ๆ) กับการทดลองต่าง ๆ ได้แก่ การปรับแต่งโครงสร้างของโมเดล และ Data Augmentation เป็นต้น โดยใช้รูปภาพยานพาหนะที่ได้จากกล้องสำรวจที่ติดตั้งบริเวณประตูทางเข้า-ออกที่ประกอบด้วยลักษณะของยานพาหนะในมุมมองด้านหน้า ด้านท้าย ด้านซ้าย และด้านขวาเมื่อถ่ายจากมุมสูงที่มีขนาดรูปภาพเท่ากับ 224 X 224 pixel พบว่า โมเดล MobileNets มีประสิทธิภาพด้านความถูกต้องในการทำนายผลมากที่สุดและยังเป็นโมเดลที่มีขนาดเล็กและใช้เวลาในการรันโมเดลที่น้อยที่สุดเมื่อเทียบกับโมเดลอื่น และยานพาหนะประเภท SUV มีความถูกต้องในการจำแนกต่ำที่สุดเพราะมีความคล้ายคลึงกับรถ Pick-up และ Hatchback และการใช้เทคนิคการปรับแต่งแสงรูปภาพ (Image Brightness) กับโมเดล MobileNets ส่งผลให้โมเดลมีความถูกต้องในการทำนายเพิ่มขึ้นมากที่สุด และ B. Xiao, Guo, and He (2021) ได้มีการปรับปรุงสถาปัตยกรรม YOLOv5s เพื่อเพิ่มประสิทธิภาพในการตรวจจับวัตถุบนถนนทั้ง 6 ประเภท ได้แก่ Car, Bus, Truck, Person, Bike และ Motorcycle บนชุดข้อมูล BDD100k ที่เป็นรูปภาพที่ได้จากกล้องหน้ารถบนช่วงเวลา สภาพอากาศและสิ่งแวดล้อมที่แตกต่างกัน โดยพบว่า โมเดล YOLOv5s กับ Improved YOLOv5s มีความเร็วในการประมวลเท่ากับ 83.3 และ 74.6 FPS และมีค่า mAP เท่ากับ

56.4 และ 59.4% ตามลำดับ ซึ่งความเร็วประมวลผลของโมเดล YOLOv5s ทำให้โมเดลสามารถใช้งานได้แบบเรียลไทม์

สถาปัตยกรรมที่ถูกพัฒนาเพื่อใช้งานในด้านการตรวจจับและจำแนกวัตถุบนเทคนิคการเรียนรู้เชิงลึก (Deep learning) สามารถแบ่งออกเป็น 2 ประเภท (Y. Xiao et al., 2020) ได้แก่ 1) Two-Stage Object Detection Architectures เป็นสถาปัตยกรรมที่แบ่งโมเดลตรวจจับวัตถุออกจากโมเดลจำแนกวัตถุซึ่งมีข้อดีคือ มีประสิทธิภาพความถูกต้องในการตรวจจับที่สูงแต่ต้องแลกมาด้วยข้อเสียคือ ใช้เวลาประมวลผลที่สูงเช่นกัน ยกตัวอย่างสถาปัตยกรรมเช่น Faster RCNN (Ren, He, Girshick, & Sun, 2017) เป็นต้น และ 2) One-Stage Object Detection Architectures เป็นสถาปัตยกรรมที่ทำหน้าที่ทั้งระบุตำแหน่งและจำแนกประเภทของวัตถุในขั้นตอนเดียวซึ่งมีข้อดีคือ มีประสิทธิภาพด้านความเร็วในการประมวลผลที่สูงแต่ก็แลกมาด้วยความถูกต้องในการตรวจจับลดลง ยกตัวอย่างเช่น YOLOv7 (Wang, Bochkovskiy, & Liao, 2023) เป็นต้น





หมายเหตุ จาก “YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors”, by Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M., 2023, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

รูปที่ 2.5 การเปรียบเทียบประสิทธิภาพระหว่างค่า AP (Average Precision) กับค่า Inference Time ของโมเดลตรวจจับวัตถุ

การศึกษานี้เลือกใช้สถาปัตยกรรมที่ประสิทธิภาพสูงทั้งด้านความถูกต้องในการทำนายและความเร็วประมวลผลที่สูงเพื่อให้สามารถใช้ได้ในแบบเรียลไทม์ (Real-Time Object Detection) โดยเลือกใช้สถาปัตยกรรม YOLOv7 (Wang et al., 2023) หนึ่งใน One-Stage Object Detection Architectures ที่มีความประสิทธิภาพด้านความแม่นยำตรวจจับและความเร็วในประมวลผลที่อยู่ในระดับสูงเมื่อเทียบกับสถาปัตยกรรมอื่น ๆ ดังรูปที่ 2.5 ซึ่ง YOLOv7 มีการปรับปรุงโครงสร้าง

สถาปัตยกรรมจาก YOLO Series และสถาปัตยกรรมอื่น ๆ เพื่อเพิ่มประสิทธิภาพความถูกต้องและรวดเร็วในการตรวจจับวัตถุมากยิ่งขึ้น ซึ่งมีการปรับปรุงโดยรวมดังนี้


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





หมายเหตุ จาก “Multi-classification recognition and quantitative characterization of surface defects in belt grinding based on YOLOv7”, by Zhu, B., Xiao, G., Zhang, Y., & Gao, H., 2023, *Measurement*. 216, 112937.

รูปที่ 2.6 โครงสร้างสถาปัตยกรรมของ YOLOv7


ยกตัวอย่างงานวิจัยที่มีการใช้ YOLOv7 Architecture ในการตรวจจับและจำแนกประเภทของวัตถุ เช่น Zhu et al. (2023) ที่ใช้การตรวจจับตำแหน่งจุดที่ผิวสายพาน (Belt Grinding) มีความเสียหายและจำแนกประเภทของความเสียหายที่เกิดขึ้นทั้ง 6 ประเภทกับข้อมูลรูปภาพผิวสายพานทั้งหมด 1,410 รูปภาพ โดยพบว่า YOLOv7 มีความแม่นยำในการทำนายจุดความเสียหายของผิวสายพานที่มีค่า mAP เท่ากับ 0.907 และ Siddique et al. (2023) ที่ได้มีการใช้ YOLOv7 ในการฝึกฝนโมเดลเพื่อจำแนกภาษามือ (Sign Language) เพื่อเปรียบเทียบประสิทธิภาพของทำนายระหว่างโมเดล Detectron2, EfficientDet และ YOLOv7 Tiny โดยใช้ข้อมูลภาษามือที่ประกอบด้วย 49 ประเภท ซึ่งประกอบด้วย 39 ตัวอักษรและ 10 ตัวเลขซึ่งมีจำนวน 3,760 รูปภาพที่มีสภาพแวดล้อมที่ต่างกันและวิดีโอทดลอง โดยพบว่า YOLOv7 Tiny มีความแม่นยำที่ใกล้เคียงกัน

และใช้เวลาในการฝึกฝนโมเดลน้อยที่สุดและมีความเร็วในการประมวลผลที่สุดเมื่อเทียบกับโมเดลอื่น ซึ่งเหมาะสมกับการตรวจจับวัตถุแบบเรียลไทม์

2.4 โมเดลการติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle Tracking Model)

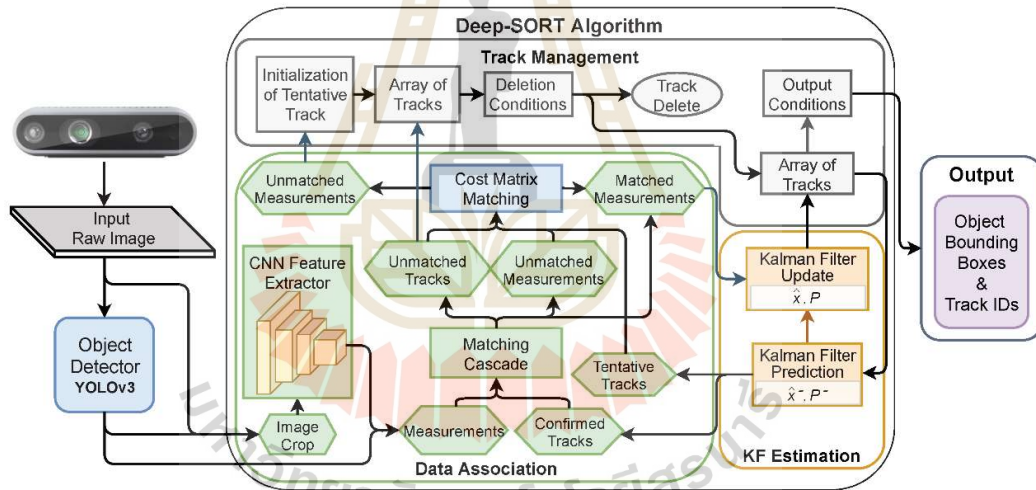
ปัจจุบันมีหลากหลายเทคนิคที่ถูกนำไปใช้ในการติดตามการเคลื่อนที่ของวัตถุ เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ได้เข้ามามีบทบาทในการเพิ่มประสิทธิภาพความถูกต้องให้ดียิ่งขึ้น ยกตัวอย่างเช่น S. Li, Chang, Liu, and Li (2020) ได้มีการใช้อัลกอริทึม Confidence Multi-Object Tracking (CMOT) ในการติดตามยานพาหนะร่วมกับผลลัพธ์ที่ได้จากการตรวจจับยานพาหนะของสถาปัตยกรรม YOLOv3 และ PM-YOLO ในการนับและประมาณค่าอัตราการไหลและความหนาแน่นของจราจรบนรูปภาพมุมสูงที่ได้จากกล้องวิดีโอสำรวจที่ติดตั้งบริเวณถนนและทางแยก และ Huang, He, Rangarajan, and Ranka (2022) ได้นำอัลกอริทึม DeepSORT มาประยุกต์ใช้ติดตามการเคลื่อนที่ของยานพาหนะบนข้อมูลที่ได้จากกล้องวิดีโอสำรวจ (Fisheye และ Pan Camera) บนทางแยกทั้ง 3 ทางแยก แล้วนำข้อมูลทั้ง 3 แหล่งไปใช้กับโมเดลจับคู่หรือหาความสัมพันธ์ของยานพาหนะที่วิ่งผ่านทางแยกทั้ง 3 เพื่อประมาณค่าเวลาในการเดินทางของยานพาหนะที่วิ่งจากทางแยกหนึ่งไปสู่ทางแยกหนึ่ง

โมเดลการติดตามวัตถุโดยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) สามารถแบ่งออกเป็น 2 ประเภท (Yang, Zhang, & Liu, 2022) ได้แก่ 1) Detection-Based Tracking (DBT) เป็นเทคนิคที่นำผลลัพธ์ที่ได้จากโมเดลตรวจจับวัตถุมาใช้ในการหาความสัมพันธ์ของวัตถุระหว่างเฟรมก่อนหน้านี้กับเฟรมปัจจุบันเพื่อติดตามการเคลื่อนที่ของวัตถุ โดยยกตัวอย่างอัลกอริทึม เช่น DeepSORT (Wojke, Bewley, & Paulus, 2017), StrongSORT (Du, Song, Yang, & Zhao, 2022) เป็นต้น และ 2) Joint-Detection and Tracking เป็นเทคนิคที่ผสมผสานโมเดลตรวจจับและติดตามวัตถุเข้าด้วยกัน โดยทำการตรวจจับวัตถุทั้งสองเฟรมแล้วนำเทคนิคต่าง ๆ มาใช้ตัดสินความคล้ายคลึงกันของวัตถุของทั้งสองเฟรมในเวลาเดียวกันเพื่อติดตามการเคลื่อนที่ของวัตถุ ยกตัวอย่างอัลกอริทึม เช่น FairMOT (Zhang, Wang, Wang, Zeng, & Liu, 2021) เป็นต้น




หมายเหตุ จาก “StrongSORT: Make DeepSORT Great Again”, by Du, Y., Song, Y., Yang, B., & Zhao, Y., 2022, [arXiv e-prints](https://arxiv.org/abs/2202.13514), arXiv:2202.13514.

รูปที่ 2.7 การเปรียบเทียบประสิทธิภาพระหว่างค่า IDF1 กับ MOTA ของอัลกอริทึมติดตามวัตถุ



หมายเหตุ จาก “Sort and Deep-SORT Based Multi-Object Tracking for Mobile Robotics: Evaluation with New Data Association Metrics”, by Pereira, R., Carvalho, G., Garrote, L., & Nunes, U. J., 2022, [Applied Sciences](https://doi.org/10.3390/app12031319), 12(3), 1319.

รูปที่ 2.8 ภาพรวมของกระบวนการติดตามวัตถุ DeepSORT Algorithm



หมายเหตุ จาก “StrongSORT: Make DeepSORT Great Again”, by Du, Y., Song, Y., Yang, B., & Zhao, Y., 2022, [arXiv e-prints](https://arxiv.org/abs/2202.13514), arXiv:2202.13514.

รูปที่ 2.9 การเปรียบเทียบโครงสร้างและประสิทธิภาพของอัลกอริทึม DeepSORT กับ StrongSORT

จากจุดประสงค์ที่ต้องการติดตามการเคลื่อนที่ของยานพาหนะ การศึกษาจึงนี้เลือกใช้เทคนิคประเภท Detection-Based Tracking (DBT) โดยเลือกอัลกอริทึม StrongSORT (Du et al., 2022) ที่เป็นโมเดลที่มีความประสิทธิภาพในการติดตามวัตถุอยู่ระดับสูงจากการวัดค่า IDF1 (Iterative Deep Feature Incorporation) และ MOTA (Multiple Object Tracking Accuracy) เมื่อเทียบกับโมเดลอื่น ๆ ดังรูปที่ 2.7 โดย StrongSORT มีการปรับปรุงจากสถาปัตยกรรม DeepSORT (Wojke et al., 2017) ที่มีภาพรวมของกระบวนการติดตามวัตถุดังรูปที่ 2.8 ซึ่งปรับปรุงโครงสร้างและกระบวนการประมวลผลภายในได้แก่ Two lightweight, Plug-and-Play, Model-Independent และ Appearance-Free Algorithms ซึ่งมีการนำเสนอ

1) Appearance-Free Link Model (AFLink) เป็นโมเดลที่ใช้ประโยชน์จากข้อมูลเชิงพื้นที่ (Spatial-Temporal Information) เพื่อทำนายว่าวัตถุทั้งสองนั้นเป็นไอดีเดียวกัน

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

โดยกระบวนการทำงานของ StrongSORT มีความคล้ายคลึงกับ DeepSORT ที่แสดงดังรูปที่ 2.9 ซึ่งประกอบด้วย 3 ส่วนหลักคือ

1) Data Association มีหน้าที่ คำนวณหาความเชื่อมโยงของรูปรยานพาหนะในแต่ละคันระหว่างเฟรมก่อนหน้ากับเฟรมปัจจุบันเพื่อระบุว่ายานพาหนะในเฟรมปัจจุบันสอดคล้องกับคันใดในเฟรมก่อนหน้า

2) State Update and Track Management: อัปเดตข้อมูลของยานพาหนะที่ติดตาม เช่น ตำแหน่ง ทิศทางและขนาดของยานพาหนะในเฟรมปัจจุบัน และจัดการข้อมูลยานพาหนะที่ถูกติดตามในแต่ละไอดี เช่น ข้อมูลลักษณะที่เปลี่ยนแปลงและการหายไปของยานพาหนะแบบชั่วคราว เป็นต้น

3) Estimation: ประมาณค่าตำแหน่งของยานพาหนะในเฟรมถัดไปโดยใช้ข้อมูลการติดตามวัตถุและความสัมพันธ์ของรูปรยานพาหนะระหว่างเฟรมก่อนหน้ากับเฟรมปัจจุบัน

ยกตัวอย่างงานวิจัยที่มีการใช้ StrongSORT Algorithm ในการติดตามวัตถุ เช่น F. Li, Chen, Hu, Luo, and Wang (2023) ได้มีการใช้ร่วมกับสถาปัตยกรรม YOLOv5s ในการตรวจจับการใส่หมวกของพนักงานในเขตก่อสร้างโดยใช้ StrongSORT ในการติดตามสถานะการใส่หมวกของพนักงานแต่ละคน และ Yeh, Hsu, Chou, Chen, and Tsai (2022) ได้มีการใช้ StrongSORT ร่วมกับโมเดล YOLOv5 ในตรวจจับและการติดตามการเคลื่อนที่คนเดินเท้าในสถานที่ต่าง ๆ โดยใช้ข้อมูลภาพมุมสูง แล้วนำข้อมูลที่ได้ไปวิเคราะห์พฤติกรรมของคนเดินเท้า (Crowd Analysis) ได้แก่ Counting และ Plotting Crowd Trajectories, Flow Direction Map และ Hotspot Map เพื่อวิเคราะห์ทิศทางการเคลื่อนที่และความหนาแน่นของผู้คนบริเวณนั้น

2.5 โมเดลตรวจจับเส้นสีจราจร (Road Lane Line Detection)

การตรวจจับเส้นสีจราจรมีวัตถุประสงค์ในการปรับแต่งกรอบพื้นที่ที่สนใจสอดคล้องกับช่องจราจรจริง ปัจจุบันมีหลากหลายเทคนิคให้เลือกใช้ในการตรวจจับเส้นสีจราจร (Road Lane Line Detection) โดยสามารถแบ่งออกเป็น 3 ประเภท (Kumar & Simon, 2015) ได้แก่ (1) Feature-Based เป็นวิธีการที่ใช้เส้นขอบและคุณลักษณะเฉพาะของวัตถุที่สนใจในการตรวจจับเส้นจราจร เช่น สี ความสว่าง รูปทรง พื้นผิว เป็นต้น (2) Model-Based เป็นการสร้างโมเดลพิจารณาองค์ประกอบรวมและสิ่งแวดล้อมของถนนเพื่อตรวจจับและติดตามเส้นจราจร และ (3) Learning-Based เป็นวิธีการที่ทำการฝึกฝนโมเดลให้จดจำคุณสมบัติของเส้นจราจรแล้วนำโมเดลที่ได้ไปหาความสัมพันธ์กับข้อมูลรูปเพื่อทำนายเส้นจราจรบนถนน ปัจจุบันเทคนิค Learning-Based ได้รับความนิยมสูงขึ้นเนื่องจากเทคโนโลยีปัจจุบันมีความสามารถในประมวลผลที่สูงจึงทำให้เทคนิคตรวจจับเส้นจราจรมีประสิทธิภาพสูงขึ้นและสมเหตุสมผลในการใช้งานแบบเรียลไทม์ ยกตัวอย่างเช่น Clnet (Zheng et al., 2022) และ YOLOv2 (Han et al., 2022) ที่มีการออกแบบสำหรับการตรวจจับวัตถุและช่องจราจรได้พร้อมกันเพื่อใช้ในด้าน Panoptic Driving Perception ซึ่งเป็นส่วนหนึ่งของระบบขับเคลื่อนอัตโนมัติ (Autonomous Driving) และเทคนิค Semantic Segmentation ที่ทำการจำแนก Pixel ของรูปภาพแต่ละจุดว่าเป็นวัตถุประเภทใดและระบุเป็นพื้นที่สีต่าง ๆ ตามประเภทของวัตถุนั้นเพื่อนำไปใช้ในการหาตำแหน่งของเส้นสีไหล่ทางจราจร เป็นต้น แต่เทคนิคนี้เหล่านี้มีความซับซ้อนที่สูงและต้องการชุดข้อมูลในการฝึกฝนจึงทำให้ผู้วิจัยสามารถนำประยุกต์ใช้จริงได้ยาก

การศึกษานี้เลือกประยุกต์ใช้วิธีการของ Priyadharshini, Niketha, Lakshmi, Sharmila, and Divya (2019) ในการตรวจจับเส้นสีจราจรซึ่งเป็นวิธีที่มีความซับซ้อนต่ำ ไม่ต้องการชุดข้อมูลในการฝึกฝนและสามารถเข้าถึงในการนำมาประยุกต์ใช้ได้ง่ายในการสร้างกระบวนการตรวจจับเส้นสีจราจรเพื่อนำไปสร้างกรอบพื้นที่ในการจำแนกตำแหน่งยานพาหนะบนถนนที่สอดคล้องกับช่องจราจรจริงตลอดการวิ่งรถสำรวจตามวัตถุประสงค์งานวิจัย โดยวิธีการตรวจจับเส้นจราจรนี้ได้นำภาพที่ผ่านการแปลงเป็น Grayscale ไปผ่านวิธีการ Image Blurring เพื่อลด Noise ของภาพ แล้วนำไปประมวลผลผ่านอัลกอริทึม Canny Edge Detection เพื่อตรวจจับเส้นขอบของวัตถุ และใช้อัลกอริทึม Hough Transform ในการตรวจจับเส้นตรงของวัตถุที่ตรงเงื่อนไขแล้วนำผลลัพธ์ที่ได้ไปจำแนกเพื่อสร้างเส้นตรงที่สอดคล้องกับเส้นสีจราจรจริง

2.6 งานวิจัยที่เกี่ยวข้อง

Guerrieri et al. (2019) ได้พัฒนา Mobile Application ในการตรวจจับและจำแนกจำนวนรถในทิศทางตรงข้าม (Opposing Vehicle) และรถที่แซงรถสำรวจ (Overtaking Vehicle) เพื่อนำไปประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ยานพาหนะ (Moving Observer Method) โดยใช้วิธี Aggregate Channel Features (ACF) ในการตรวจจับและจำแนกประเภทรถแล้วใช้เทคนิค Feature Matching ในการติดตามการเคลื่อนที่ของรถเพื่อจำแนกรูปแบบการเคลื่อนที่ตามวิธี MOM ซึ่งทำการทดลองสำรวจบนถนน Italian Highway (SS640) ที่มีระยะทาง 1.1 กิโลเมตร ซึ่งเป็นทางหลวงที่มีขนาด 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางและมีลักษณะกายภาพของถนนเป็นเนื้อเดียวกัน และมีการไหลของกระแสจราจรแบบต่อเนื่องเป็นจำนวนทั้งหมด 30 รอบ (10 รอบต่อช่วงเวลา 9:00–10:00, 11:00–12:00 และ 15:30–16:30 น.) ที่ความเร็วเฉลี่ย 60 กม./ชม. โดยเมื่อเปรียบเทียบผลลัพธ์ระหว่างโมเดลที่สร้างขึ้นกับข้อมูลจริงพบว่า โมเดลมีความคลาดเคลื่อนในการประมาณอัตราการไหลสูงสุดที่ประมาณ 10 เปอร์เซ็นต์เมื่อเปรียบเทียบกับการใช้ข้อมูลสำรวจจริงในการประมาณค่า ซึ่งความผิดพลาดหลักที่ทำให้การประมาณค่าเกิดความคลาดเคลื่อนคือ การนับและจำแนกยานพาหนะที่เกินจากความเป็นจริง (False Positive Case) ซึ่งเกิดจากอัตราการไหลและความเร็วของรถสำรวจที่เพิ่มขึ้นและอื่น ๆ เช่น มุมมองกล้อง การบดบังยานพาหนะ การสั่นสะเทือน เป็นต้น

Guerrieri and Parla (2021) ยังได้พัฒนาโมเดลในการตรวจจับและจำแนกจำนวนรถในทิศทางตรงข้ามและรถที่แซงรถสำรวจเพื่อนำไปประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ยานพาหนะ (Moving Observer Method) โดยใช้ YOLOv3 Architecture ที่เป็นโมเดลเรียนรู้เชิงลึกในการตรวจจับและ Feature Matching ในการติดตามการเคลื่อนที่ของรถเพื่อจำแนกรูปแบบการเคลื่อนที่ตามวิธี MOM ซึ่งทำการทดลองสำรวจบนถนน Italian Highway (SS640) ที่มีระยะทาง 1.1 กิโลเมตร ซึ่งเป็นทางหลวงที่มีขนาด 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลาง และมีลักษณะกายภาพของถนนเป็นเนื้อเดียวกัน และมีการไหลของกระแสจราจรแบบต่อเนื่องเป็นจำนวนทั้งหมด 35 รอบที่ความเร็ว 60 ± 5 กม./ชม. โดยเมื่อเปรียบเทียบผลลัพธ์ระหว่างโมเดลที่สร้างขึ้นกับข้อมูลจริงพบว่า โมเดลมีความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจรสูงสับน้อยกว่า 3% เมื่อเปรียบเทียบกับการใช้ข้อมูลสำรวจจริงในการประมาณค่า ซึ่งความผิดพลาดที่เกิดขึ้นในการนับและจำแนกยานพาหนะที่เกินความเป็นจริง (False Positive) และขาดจากความเป็นจริง (False

Negative) มีสาเหตุหลักจากการสั่นสะเทือนของกล้อง (Camera Vibrations) สิ่งแวดล้อมที่ไม่เอื้ออำนวย
(Adverse Environmental Conditions)



บทที่ 3

วิธีดำเนินการวิจัย

วิธีดำเนินการวิจัยในการสำรวจและออกแบบ ตั้งค่าโมเดลที่นำเสนอตามวัตถุประสงค์ของงานวิจัยประกอบด้วย 6 ส่วนได้แก่

ส่วนที่ 1 การรวบรวมข้อมูล

ส่วนที่ 2 เครื่องมือที่ใช้ในงานวิจัย

ส่วนที่ 3 การออกแบบโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะตามวิธีสำรวจแบบโดยการเคลื่อนที่ของยานพาหนะ

ส่วนที่ 4 การตั้งค่าและพัฒนาโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

ส่วนที่ 5 การประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

ส่วนที่ 6 การประเมินประสิทธิภาพโมเดล

3.1 การรวบรวมข้อมูล

3.1.1 พื้นที่ศึกษาในการสำรวจข้อมูลจราจรตามวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

งานวิจัยนี้ทำการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะหรือวิธีการสำรวจ MOM เพื่อทดลองใช้กับโมเดลที่นำเสนอ โดยใช้กล้องวิดีโอหน้ารถบันทึกกระแสจราจรที่เคลื่อนที่ผ่านจุดสำรวจ ที่ทำการวิ่งสำรวจบนช่วงถนนที่มีจำนวนช่องจราจร 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางตามขอบเขตงานวิจัยซึ่งได้มีการออกแบบการวิ่งสำรวจและการเลือกช่วงถนนดังนี้

1) สำรวจในช่วงเวลา 13:00–15:00 น. (ช่วงไม่เร่งด่วน) และ 16:30–18:00 น. (ช่วงเร่งด่วน)

2) ถนนระหว่างเมืองที่มีการไหลของกระแสจราจรแบบต่อเนื่อง (Uninterrupted Flow) และไม่มีสิ่งขัดขวางหรือเหตุการณ์ต่าง ๆ ที่ทำให้กระแสจราจรติดขัดและเกิดความผันผวนจากปกติ

3) องค์ประกอบทางเรขาคณิตของถนนเป็นเนื้อเดียวกันทั้งช่วงถนนและไม่มีเรขาคณิตของถนนหรืออุปสรรคมาดบังการสำรวจและทำให้กระแสจราจรติดขัด

4) ไม่มีทางแยกประกอบในช่วงถนนที่สำรวจหรือมีทางแยกที่มีปริมาณจราจรที่ต่ำมากเพื่อลดความไม่ต่อเนื่องและผันผวนของกระแสจราจรและเหตุการณ์อื่นที่ไม่อยู่ในขอบเขตงานวิจัย


5) ใช้ความเร็วเฉลี่ย 60 กม./ชม. ในการสำรวจโดยตัดสัญญาณแดงและชะลอรถโดยผู้ขับขี่

6) วิ่งสำรวจตามวิธีสำรวจโดยการเคลื่อนที่ยานพาหนะในแต่ละทิศทางอย่างน้อย 6 รอบ ซึ่งเพียงพอต่อความน่าเชื่อถือและไม่เอนเอียงในการประมาณค่าตัวแปรกระแสจราจร

โดยงานวิจัยนี้เลือกสำรวจจำนวน 5 ช่วงถนนที่มีความยาว 2.0 ถึง 5.0 กิโลเมตรที่ผ่านเกณฑ์การคัดเลือกช่วงถนนสำรวจทั้งหมด ซึ่งที่อยู่ภายในจังหวัดชลบุรีและระยองดังแสดงในรูปที่ 3.1 และทำการสำรวจได้ทั้งหมด 153 เทียบ ซึ่งสามารถจับคู่เป็นรอบตามวิธีสำรวจ MOM (จากจุด S ไป N และจุด N ไป S) ดังรูปที่ 2.4 ได้จำนวน 143 รอบ โดยแต่ละจุดสำรวจมีรอบการสำรวจประมาณ 4-9 รอบต่อทิศทางต่อช่วงเวลา (จุดสำรวจ B สามารถจับคู่ได้น้อยกว่า 6 รอบเพราะความผิดพลาดในการกำหนดช่วงเวลาในการสำรวจที่น้อยเกินไปและจุดกลับรถ)

ตารางที่ 3.1 รายละเอียดจุดสำรวจข้อมูลจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

ลำดับ	วันที่สำรวจ	ชื่อถนน	กม. เริ่มต้น	กม. สิ้นสุด	ความยาว ช่วงถนน (กิโลเมตร)	ความ กว้าง ช่อง จราจร (เมตร)	ความ กว้าง ไหล่ทาง (เมตร)
A	วันศุกร์ที่ 1 ก.ค. 65	ทล.3143	5+800	9+400	3.6	3.5	2.5, 2.5
B	วันพฤหัสบดีที่ 2 มิ.ย. 65	ทล.3144	3+400	8+400	5.0	3.5	2.0, 2.0
C	วันพุธที่ 2 มิ.ย. 65	ทล.3240	6+400	8+400	2.0	3.5	2.5, 2.5
D	วันพุธที่ 29 มิ.ย. 65	ทล.3240	11+800	13+900	2.1	3.5	2.5, 2.5
E	วันพุธที่ 28 มิ.ย. 65	ทข. ขบ.1032	4+600	8+200	3.6	3.25	2.5, 2.5



รูปที่ 3.1 Key Map จุดสำรวจข้อมูลจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

3.1.2 รูปที่ใช้ในกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ

รูปที่ใช้ในกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะได้จากรูปวิดีโอหน้ารถวิ่งที่สำรวจบนถนน 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางในเขตชุมชนและชานเมืองบริเวณเขตอำเภอศรีราชาและบางละมุง จังหวัดชลบุรี บนสภาพอากาศปกติในช่วงเวลา 06:30–18:30 น. โดยมีจำนวนทั้งหมด 2,300 รูป ที่มีขนาดรูป 1,280 x 720 Pixels แสดงตัวอย่างดังรูปที่ 3.2



รูปที่ 3.2 ตัวอย่างรูปที่ใช้ในการฝึกฝนโมเดลตรวจจับยานพาหนะ

ยานพาหนะแต่ละคันในรูปกล้องหน้ารถจากการสำรวจจะถูกระบุตำแหน่งและประเภทยานพาหนะ (Data Annotations) เป็นจำนวนทั้งหมด 8,944 รูปยานพาหนะ (ประกอบด้วยรูปยานพาหนะมุมมองด้านหน้าเฉลี่ยประมาณ 65% และ ด้านท้าย 35%) โดยยานพาหนะแต่ละคันจะถูกระบุประเภทยานพาหนะตามขนาดและลักษณะเฉพาะเมื่อมองจากมุมมองด้านหน้ารถที่มีความแตกต่างกันประกอบไปด้วย 8 ประเภทตามขอบเขตงานวิจัย ตัวอย่างรูปยานพาหนะแสดงดังรูปที่ 3.3

- 1) Motorcycle เป็นรถจักรยานยนต์
- 2) Car เป็นรถยนต์ส่วนบุคคลน้อยกว่า 7 ที่นั่งที่มีลักษณะเป็นรถ Sedan และ Hatchback
- 3) SUV เป็นรถยนต์ส่วนบุคคลน้อยกว่า 7 ที่นั่งที่มีลักษณะเป็นรถ SUV และ MUV
- 4) Light Truck เป็นรถบรรทุกขนาดเล็ก 4 ล้อที่มีลักษณะเป็นรถกระบะแบบไม่มีตู้บรรทุกสินค้า
- 5) Light Commercial Truck เป็นรถบรรทุกขนาดเล็ก 4 ล้อที่มีลักษณะเป็นรถกระบะแบบมีตู้บรรทุกสินค้า
- 6) VAN เป็นรถยนต์ส่วนบุคคลมากกว่า 7 ที่นั่งที่มีลักษณะเป็นรถตู้
- 7) BUS เป็นรถบัสโดยสารขนาดเล็ก, กลางและใหญ่
- 8) Heavy Truck ประกอบด้วยรถบรรทุกขนาด 6 ล้อ, 10 ล้อ, รถพ่วงและกึ่งพ่วง











หมายเหตุ 1) Motorcycle, 2) Car, 3) SUV, 4) Light Truck, 5) Light Commercial Truck,

6) Van, 7) Bus และ 8) Heavy Truck

รูปที่ 3.3 ตัวอย่างยานพาหนะทั้ง 8 ประเภทที่ทำการจำแนกประเภทยานพาหนะในงานวิจัย

จำนวนรูป 2,300 รูปที่ประกอบด้วย 8,944 รูปยานพาหนะจะถูกแปลงให้เป็นขนาด 640 X 640 Pixel แบ่งออกเป็นชุดข้อมูลต่าง ๆ ประกอบด้วย 70% Training, 15% Validation และ 15% Testing Dataset เพื่อใช้ในกระบวนการฝึกฝนและประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะ โดยยานพาหนะในแต่ละประเภทจะมีการกำหนดค่าแปลงเป็นหน่วยรถยนต์ส่วนบุคคล (Passenger Car Unit : PCU) ตามหลักเกณฑ์ของสำนักอำนวยความปลอดภัย กรมทางหลวง (สำนักอำนวยความปลอดภัย, 2564) เพื่อใช้ในการประมาณค่าตัวแปรกระแสจราจร ซึ่งสามารถสรุปค่า PCU และจำนวนรูปยานพาหนะได้ดังตารางที่ 3.2

ตารางที่ 3.2 จำนวนรูปภาพยานพาหนะ (Vehicle Caption) และค่า PCU Factor ของแต่ละประเภท

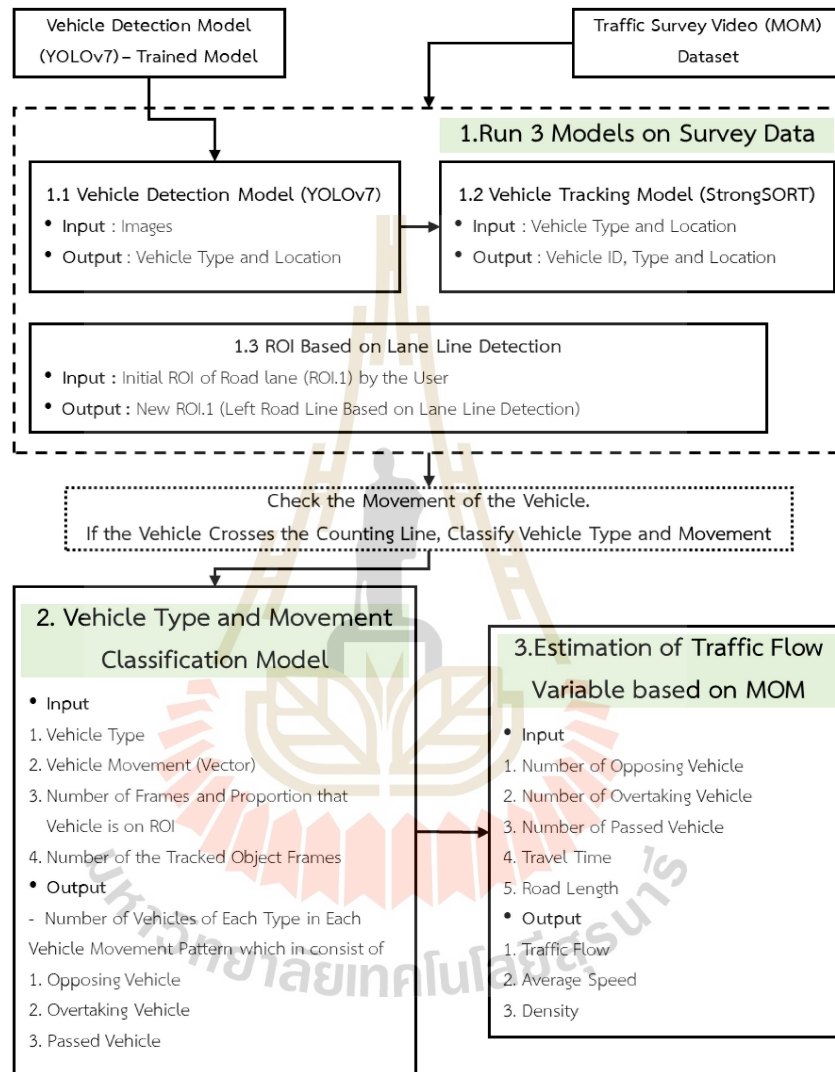
No	Vehicle Type		PCU Factor	No. of Vehicle Caption ->			
				Total (Front + Back)			
				Training	Validation	Testing	Total
1		Motorcycle	0.33	1,947	455	395	2,797
2		Car (Sedan + Hatchback)	1.00	887	222	234	1,343
3		SUV (SUV + MUV)	1.00	621	114	127	862
4		Van	1.00	481	117	105	703
5		Light Truck	1.00	899	191	204	1,294
6		Light Commercial Truck	1.00	614	133	126	873
7		Medium and Heavy Truck	2.50	517	115	104	736
8		Medium and Heavy Bus	2.10	236	40	60	336
Total				6,202	1,387	1,355	8,944

3.2 เครื่องมือที่ใช้ในงานวิจัย

เครื่องมือที่ใช้ในงานวิจัยประกอบไปด้วย 2 ส่วนคือ

- 1) การสำรวจจราจร บันทึกการสำรวจโดยใช้กล้องวิดีโอหน้ารถยี่ห้อ QVP, Model L18 FULL HD 1080p
- 2) การสร้างและรันโมเดลที่ได้นำเสนอในงานวิจัย
 - 2.1) ฮาร์ดแวร์เลือกใช้ฮาร์ดแวร์หน่วยประมวลผล (CPU) รุ่น Intel(R) Xeon(R) CPU @ 2.20GHz, การ์ดจอประมวลผล (GPU) รุ่น Tesla A100-SXM4-40GB และหน่วยความจำหลัก (RAM) 13 GB ที่มีการรันบน Google Colab (Version: Colab Pro)
 - 2.2) ซอฟต์แวร์เลือกใช้ระบบปฏิบัติการ Windows 10 และใช้ภาษา Python 3.10.11, Pytorch Ver. 1.12.1, Cuda Ver.11.3 ในการสร้างและทดลองโมเดลที่นำเสนอกับข้อมูลสำรวจจราจร

3.3 การออกแบบภาพรวมของโมเดลที่นำเสนอในงานวิจัย



รูปที่ 3.4 กระบวนการทำงานของโมเดลที่นำเสนอในงานวิจัย

จากวัตถุประสงค์ของงานวิจัยที่ต้องการสร้างโมเดลเพื่อการตรวจจับและจำแนกประเภทลักษณะของยานพาหนะและรูปแบบการเคลื่อนที่เพื่อนำผลลัพธ์ที่ได้ไปใช้ในการประมาณค่าตัวแปรกระแสรถจร สามารถนำมาสรุปเป็นกระบวนการไหลของข้อมูลทั้งหมดได้ดังรูปที่ 3.4 ซึ่งแต่ละส่วนมีหน้าที่การทำงานดังนี้

1) Run 3 Models on Survey data คือ การนำโมเดลทั้ง 3 โมเดลไปใช้กับข้อมูลวิดีโอสำรวจข้อมูลจราจรที่ถูกสำรวจโดยวิธีการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM) เพื่อนำผลลัพธ์ที่ได้ไปใช้โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ (Vehicle Type and Movement Classification) ในส่วนที่ 2 ซึ่งโมเดลในส่วนที่ 1 ประกอบด้วย

1.1) โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model) มีหน้าที่ ตรวจจับยานพาหนะที่อยู่บนภาพวิดีโอข้อมูลสำรวจทั้งหมด ทำให้ได้ข้อมูลประเภทยานพาหนะ (Vehicle Type) และตำแหน่งของยานพาหนะ (Vehicle Location) แล้วทำการส่งข้อมูลเหล่านี้ไปยังโมเดลติดตามยานพาหนะ (Vehicle Tracking)

1.2) โมเดลติดตามยานพาหนะ (Vehicle Tracking Model) มีหน้าที่ ติดตามการเคลื่อนที่ของยานพาหนะในแต่ละคันเพื่อใช้ในการระบุตำแหน่งของยานพาหนะตั้งแต่เริ่มต้นจนถึงเหตุการณ์ที่ยานพาหนะชนเส้น Counting Line และผ่านเงื่อนไขในการนับและจำแนกยานพาหนะที่สร้างขึ้น โดยผลลัพธ์ที่ได้จะประกอบด้วย (1) ไอดีของยานพาหนะแต่ละคัน (Vehicle Id), (2) ประเภทของยานพาหนะของแต่ละไอดี และ (3) ตำแหน่งยานพาหนะของแต่ละไอดี ซึ่งจะนำข้อมูลเหล่านี้ไปจำแนกประเภทยานพาหนะและรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบตามวิธีการสำรวจโดยวิธีการเคลื่อนที่ของยานพาหนะในส่วนที่ 2

1.3) โมเดลสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นจราจร (ROI Based on Lane Line Detection) มีหน้าที่ สร้างกรอบพื้นที่ตามขอบเขตของช่องจราจรที่อยู่ระหว่างเส้นไหล่ทางซ้ายถึงเส้นไหล่ทางขวาเพื่อจำแนกตำแหน่งของยานพาหนะตั้งแต่เริ่มต้นจนถึงเหตุการณ์ที่ยานพาหนะชนเส้น Counting Line ว่ามีการเคลื่อนที่อยู่ภายในช่องจราจรหรือไม่ แล้วนำข้อมูลที่ไปใช้ในการนับและจำแนกเฉพาะยานพาหนะที่สนใจ (เฉพาะวิ่งบนช่องจราจร) และจำแนกยานพาหนะที่วิ่งบนไหล่ทางและอื่น ๆ ที่ไม่สนใจออกจากการคำนวณเพื่อให้ได้จำนวนยานพาหนะจริงของทั้ง 3 รูปแบบการเคลื่อนที่ตามวิธี MOM ที่จะนำไปใช้ในการประมาณค่าตัวแปรกระแสจราจรในลำดับถัดไป

2) Vehicle Type and Movement Classification คือ การนำข้อมูลการตรวจจับและติดตามยานพาหนะจากส่วนที่ 1 ตั้งแต่เริ่มต้นการตรวจจับจนถึงเหตุการณ์ที่ยานพาหนะชนเส้น Counting Line ที่กำหนดไว้มาสร้างโมเดลการจำแนกประเภทและรูปแบบการเคลื่อนที่ ซึ่งข้อมูลยานพาหนะในแต่ละไอดีจะประกอบด้วย (1) ประเภทของยานพาหนะ (เฉพาะเมื่อชนเส้น Counting Line), (2) ทิศทางหรือรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle Movement หรือ Vector), (3) จำนวนเฟรมและสัดส่วนที่ยานพาหนะอยู่ในกรอบพื้นที่ที่สนใจ (อยู่ในช่องจราจร) เพื่อใช้ในการจำแนกรถที่ไม่เกี่ยวข้องออกจากการคำนวณ เช่น รถบนไหล่ทาง และ (4) จำนวนเฟรมที่ยานพาหนะ

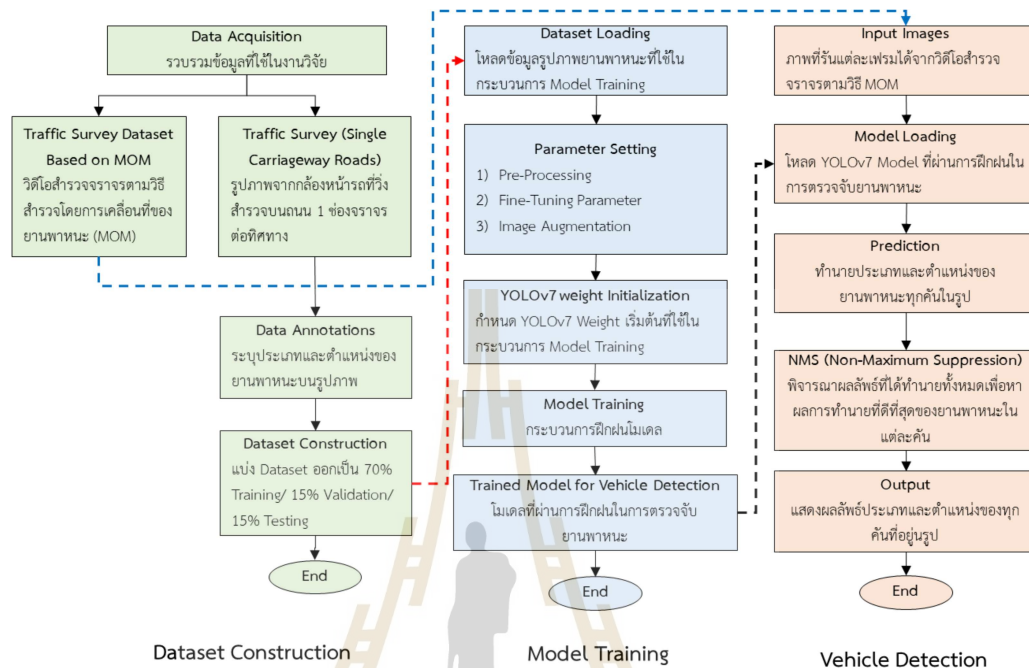
ถูกติดตามเพื่อใช้ในจำแนกยานพาหนะที่นับเข้าซ้อนจากข้อผิดพลาดในการตรวจจับและติดตามออกจากการคำนวณ โดยเมื่อนำข้อมูลต่าง ๆ ไปประมวลผลผ่านเงื่อนไขที่สร้างขึ้น โมเดลจะแสดงผลลัพธ์เป็นจำนวนยานพาหนะตามรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบ คือ (1) รถที่วิ่งในทิศทางตรงข้าม (Opposing Vehicle), (2) รถที่แซงรถสำรวจ (Overtaking Vehicle) และ (3) รถที่ถูกรถสำรวจแซง (Passed Vehicle) และแต่รูปแบบการเคลื่อนที่จะถูกแบ่งตาม 8 ประเภทยานพาหนะ

3) Estimation of Traffic Flow Variable Based on MOM คือ การนำข้อมูลจำนวนยานพาหนะทั้ง 3 รูปแบบการเคลื่อนที่ที่ได้จากส่วนที่ 2, ความยาวของช่วงถนนที่สำรวจ (Road Length) และเวลาในการเดินทางที่ได้จากการสำรวจ (Travel Time) มาใช้ในการประมาณค่าตัวแปรกระแสจราจรตามวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method : MOM) ประกอบด้วย (1) อัตราการไหลกระแสจราจร (Traffic Flow), (2) ความเร็วเฉลี่ย (Space Mean Speed) และ (3) ความหนาแน่นกระแสจราจร (Density)

3.4 การตั้งค่าและพัฒนาโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

การตั้งค่าและพัฒนาโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 ส่วนที่ได้นำเสนอในงานวิจัยมีรายละเอียดดังนี้

3.4.1 โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model) – YOLOv7



หมายเหตุ ปรับปรุงจาก “Tomato detection based on modified YOLOv3 framework”, by Lawal, O., 2021, *Scientific Reports*, 11.

รูปที่ 3.5 Flow Chart ของกระบวนการจัดเตรียมข้อมูล, การฝึกฝนโมเดลและการใช้งานโมเดลตรวจจับยานพาหนะ

โมเดลการตรวจจับยานพาหนะเลือกใช้สถาปัตยกรรม YOLOv7 (Wang et al., 2023) โดยประยุกต์ใช้ Source Code ของ Broström (2022); Wang et al. (2023) ซึ่งมีการตั้งค่าดังนี้

1) กระบวนการฝึกฝนโมเดลเลือกใช้ Pretrained Model Weight ที่ผ่านการฝึกฝนจาก MS COCO Dataset ที่มีชื่อว่า “YOLOv7” เป็นโมเดลตั้งต้นสำหรับการใช้ในการสร้างโมเดลตรวจจับยานพาหนะในงานวิจัยนี้ โดยใช้ข้อมูลรูปภาพยานพาหนะที่ได้จากการสำรวจจราจรตั้งที่ได้กล่าวไว้ในหัวข้อ 3.1.2 ในการฝึกฝน ซึ่งมีการกำหนดการตั้งค่า Hyperparameter ของค่าเริ่มต้นของการรันโมเดลฝึกฝน (Pre-Processing) และการเรียนรู้ของโมเดล (Fine-Tuning Parameter) และ

การปรับแต่งรูปเพื่อใช้ในการฝึกฝน (Image Augmentation) ตามค่าตั้งต้นซึ่งมีการตั้งค่าดังตารางที่ 3.3

ตารางที่ 3.3 การตั้งค่า Hyperparameter ของกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ

No.	Parameter	Detail	Value
Pre-Processing			
1	YOLOv7 weight	Pretrained YOLOv7 weight	YOLOv7
2	Batch size	Number of images are processed together	16
3	Ephochs	Number of learning algorithm processing times	300
4	Image size	Image size for model training	640 X 640 pixel
Fine-Tuning Parameter			
1	lr0	initial learning rate (SGD=1E-2, Adam=1E-3)	0.01
2	lrf	final OneCycleLR learning rate (lr0 * lrf)	0.2
3	momentum	SGD momentum/Adam beta1	0.937
4	weight_decay	Optimizer weight decay	0.0005
5	warmup_epochs	Warmup epochs (fractions ok)	3
6	warmup_momentum	Warmup initial momentum	0.8
7	warmup_bias_lr	Warmup initial bias lr	0.1
8	box	Box Loss gain	0.05
9	cls	Class loss gain	0.3
10	cls_pw	Class BCELoss positive_weight	1
11	obj	Objectness loss gain (scale with pixel)	0.7
12	obj_pw	Objectness BCELoss positive_weight	1
13	iou_t	IoU training threshold	0.2
14	anchor_t	Anchor-multiple threshold	4
15	fl_gamma	Focal Loss gamma	0

ตารางที่ 3.3 การตั้งค่า Hyperparameter ของกระบวนการฝึกฝนโมเดลตรวจจับยานพาหนะ (ต่อ)

No.	Parameter	Detail	Value
Image Augmentation			
1	hsv_h:	Image HSV-Hue augmentation (fraction)	0.015
2	hsv_s	Image HSV-Saturation augmentation (fraction)	0.7
3	hsv_v	Image HSV-Value augmentation (fraction)	0.4
4	degrees	Image Rotation (+/- deg)	0
5	translate	Image Translation (+/- fraction)	0.2
6	scale	Image Scale (+/- gain)	0.9
7	shear	Image Shear (+/- deg)	0
8	perspective	Image Perspective (+/- fraction), range_0-0.001	0
9	flipud	Image Flip up-down (probability)	0
10	fliplr	Image Flip left-right (probability)	0.5
11	mosaic	Image Mosaic (probability)	1
12	mixup	Image Mixup (probability)	0.15
13	copy_paste	Image Copy-pastes (probability)	0
14	paste_in	Image Paste in (probability)	0.15

2) การนำโมเดลตรวจจับยานพาหนะที่ผ่านการฝึกฝนแล้วไปใช้งานกับข้อมูลสำรวจจราจรมีการกำหนดการตั้งค่าดังตารางที่ 3.4

ตารางที่ 3.4 การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลตรวจจับยานพาหนะ

No.	Parameter	Detail	Value
1	Image size	Image size for object detection	640 X 640 pixel
2	conf-thres	Confidence threshold	0.5
3	IoU-thres	Intersection over Union threshold	0.45
4	half	use FP16 half-precision inference	False



รูปที่ 3.6 ตัวอย่างผลลัพธ์ที่ได้จากโมเดลตรวจจับยานพาหนะ

3.4.2 โมเดลติดตามการเคลื่อนที่ของยานพาหนะ (Vehicle Tracking Model) – StrongSORT

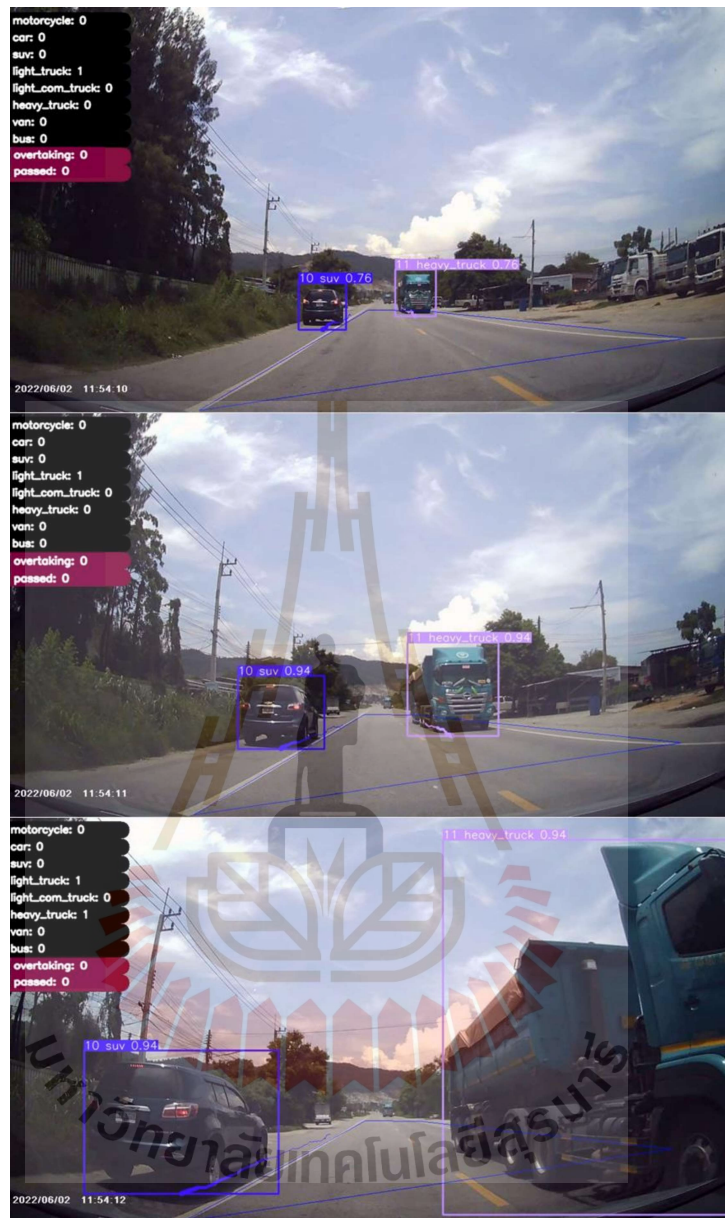
โมเดลติดตามการเคลื่อนที่ของยานพาหนะเลือกใช้อัลกอริทึม StrongSORT (Du et al., 2022) โดยประยุกต์ใช้ Source Code ของ Broström (2022) ซึ่งมีการตั้งค่าดังนี้

1) พารามิเตอร์ที่ใช้ในโมเดลการติดตามยานพาหนะ กำหนดการตั้งค่าเป็นค่าตั้งต้น ดังตารางที่ 3.5

2) Deep-Reid Weight ที่ใช้ในการประมวลผลของสถาปัตยกรรม StrongSORT เลือกใช้โมเดล osnet_a1n_x1_0_msmt17 ของ Torchreid ที่ผ่านการฝึกฝนโมเดลแบบ Cross-domain ReID

ตารางที่ 3.5 การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลติดตามยานพาหนะ


No.	Parameter	Detail	Value
1	ECC	To activate a Camera Motion Compensation	TRUE
2	MC_LAMBDA	Matching with both appearance (1 - MC_LAMBDA) and motion cost	0.995
3	EMA_ALPHA	Updates appearance state in an exponential moving average manner	0.9
4	MAX_DIST	The matching threshold. Samples with larger distance are considered an invalid match	0.2
5	MAX_IOU_DISTANCE	Gating threshold. Associations with cost larger than this value are disregarded.	0.7
6	MAX_AGE	Maximum number of missed misses before a track is deleted	15
7	N_INIT	Number of frames that a track remains in initialization phase	3
8	NN_BUDGET	Maximum size of the appearance descriptors gallery	100



รูปที่ 3.7 ตัวอย่างผลลัพธ์การติดตามการเคลื่อนที่ของยานพาหนะในแต่ละไอดี

3.4.3 โมเดลสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีจราจร (ROI Based on Lane Line Detection)

โมเดลสร้างกรอบพื้นที่โดยการตรวจจับเส้นสีจราจร มีหน้าที่ สร้างกรอบพื้นที่เพื่อจำแนกยานพาหนะที่สนใจ (เฉพาะยานพาหนะที่วิ่งบนช่องจราจร) และที่ไม่สนใจ (ยานพาหนะบนไหล่ทาง จอดริมทางและที่อยู่อาศัย) ซึ่งมีขอบเขตพื้นที่อยู่ระหว่างเส้นไหล่ทางซ้ายถึงเส้นไหล่ทางขวาที่ครอบคลุมถนนที่วิ่งในทิศทางเดียวกันและทิศทางตรงข้ามทั้ง 2 ช่องจราจรตลอดการวิ่งสำรวจ โดยประยุกต์ใช้เทคนิคตรวจจับเส้นสีจราจร (Priyadharshini et al., 2019) เพื่อตรวจจับเส้นจราจรเฉพาะไหล่ทางซ้ายไหล่ทางขวาแล้วนำไปใช้ในการปรับแก้เส้นกรอบพื้นที่ทางซ้ายมือให้สอดคล้องกับเส้นไหล่ทางซ้ายของช่องจราจรจริงซึ่งจะทำให้ได้ขอบเขตของกรอบพื้นที่ครอบคลุมและสอดคล้องกับช่องจราจรที่สนใจตลอดการสำรวจ โดยผู้วิจัยนี้เลือกไม่ใช้การตรวจจับเส้นสีจราจรที่เส้นไหล่ทางขวาเพื่อช่วยในการสร้างกรอบพื้นที่เนื่องจากยานพาหนะที่วิ่งในทิศทางตรงข้ามวิ่งบดบังเส้นสีจราจรไหล่ทางขวามือและโมเดลที่นำมาใช้นั้นมีประสิทธิภาพต่ำในการจำแนกเส้นตรงไหล่ทางขวาและเส้นตรงขอบถนนจึงอาจทำให้ได้ตำแหน่งเส้นไหล่ทางขวาที่ผิดพลาดจากการทดลอง ดังนั้นจึงใช้เพียงเส้นสีจราจรไหล่ทางซ้ายในการอ้างอิงเพื่อสร้างกรอบพื้นที่ในการจำแนกตำแหน่งของยานพาหนะที่ครอบคลุมทั้ง 2 ช่องจราจร ผู้วิจัยได้ประยุกต์ใช้ Source Code ของ Vykari (2021) ในการตรวจจับเส้นสีจราจรซึ่งสามารถแสดงตัวอย่างผลลัพธ์การทำงานได้ดังรูปที่ 3.8



รูปที่ 3.8 ขั้นตอนการสร้างกรอบพื้นที่ที่สนใจโดยการตรวจจับเส้นสีจราจร (ROI Based on Lane Line Detection)

โดยมีกระบวนการทำงานและการตั้งค่าดังนี้

1) ในเริ่มต้นที่ผู้ใช้งานกดใช้งานโมเดลที่นำเสนอกับข้อมูลวิดีโอสำรวจ ผู้ใช้งานต้องกำหนดกรอบพื้นที่ที่สนใจ (ROI.1) ให้ครอบคลุมช่องจราจรทั้ง 2 โดยมีขอบเขตเป็นเส้นไหล่ทางซ้ายและขวา เพื่อตั้งค่าเป็นค่าตั้งต้นของตำแหน่งมุมกรอบพื้นที่ที่สนใจ องศาของเส้นไหล่ทางซ้ายและขวา และความกว้างของกรอบพื้นที่ที่ครอบคลุมช่องจราจรทั้ง 2 ทิศทางดังตัวอย่างในรูปที่ 3.8-A

2) นำภาพวิดีโอในแต่ละเฟรมมาทำการปรับแต่งภาพให้มีความคมชัด (Image Sharpening) เพื่อให้เห็นเส้นสีจราจรได้ชัดเจนยิ่งขึ้น โดยใช้ cv2.filter2D บน OpenCV Package

3) ปรับภาพให้เป็น Gray Scale เพื่อใช้ในการหาเส้นขอบของวัตถุ โดยใช้ cv2.cvtColor บน OpenCV Package

4) ปรับแต่งความเบลอให้กับภาพ (Image Blurring) เพื่อลด Noise จากการใช้อัลกอริทึมตรวจจับเส้นขอบวัตถุในลำดับถัดไปโดยใช้ cv2.GaussianBlur บน OpenCV Package

5) ตรวจจับเส้นขอบของวัตถุโดยใช้อัลกอริทึม Canny Edge Detection ด้วย cv2.Canny บน OpenCV Package ซึ่งมีกำหนด Minimum and Maximum threshold ของ Hysteresis Procedure ที่ใช้ในกระบวนการเท่ากับ 100 และ 200 ตามลำดับ ซึ่งสามารถแสดงตัวอย่างผลลัพธ์ดังตัวอย่างในรูปที่ 3.8-B

6) เมื่อได้ภาพที่ได้จากการตรวจจับเส้นขอบของวัตถุทั้งหมดในภาพแล้ว จากนั้นทำการสร้างกรอบพื้นที่เพิ่มเติม (ROI.2) ที่ครอบคลุมเฉพาะเส้นไหล่ทางซ้ายที่ได้จากการกำหนดกรอบพื้นที่ตั้งต้น (ROI.1) ดังตัวอย่างในรูปที่ 3.8-C (ไฮไลต์พื้นที่สีเหลือง) เพื่อให้โมเดลนำเส้นขอบของวัตถุเฉพาะบริเวณเส้นไหล่ทางซ้ายมาใช้ในการตรวจจับเส้นสีจราจรไหล่ทางซ้ายลำดับถัดไป

7) นำเส้นขอบของวัตถุที่อยู่ในกรอบพื้นที่เฉพาะเส้นไหล่ทางซ้ายที่ได้กรอบพื้นที่ (ROI.2) มาจำแนกเส้นตรงเพื่อหาตำแหน่งของเส้นไหล่ทางซ้ายด้วยอัลกอริทึม Hough Transform โดยใช้ cv2.HoughLinesP บน OpenCV Package ซึ่งมีกำหนดค่าพารามิเตอร์ rho (ความละเอียดของระยะทางของการสะสมในหน่วย Pixel), theta (ความละเอียดขององศาของสะสมในหน่วย Pixel), minLineLength (ความยาวขั้นต่ำของเส้น), maxLineGap (ช่วงห่างสูงสุดของเส้นที่ยอมรับได้) เท่ากับ 2, $\pi/180$, 80 และ 20 ตามลำดับ โดยแสดงตัวอย่างรูปที่ 3.8-C (เส้นสีน้ำเงิน)

8) ผลลัพธ์เส้นตรงที่ได้จากข้อ 7 นำมาจำแนกและคำนวณเพื่อระบุตำแหน่งของเส้นขอบทางซ้ายมือใหม่ (new line_left) ที่จะใช้เป็นตัวแทนของเส้นสีจราจรไหล่ทางซ้ายจริง เมื่อได้เส้นขอบทางซ้ายมือใหม่ที่ถูกปรับแก้ให้สอดคล้องกับเส้นไหล่ทางซ้ายจริงแล้วนำข้อมูลตำแหน่งมุมกรอบอื่น ๆ และความกว้างของกรอบพื้นที่ตั้งต้นที่ได้จากข้อ 1 มาสร้างกรอบพื้นที่ใหม่ที่เส้นไหล่ทางซ้ายและขวาสอดคล้องและครอบคลุมช่องจราจรจริงซึ่งมีขั้นตอนและเงื่อนไขการปรับแก้เส้นขอบทางซ้ายมือใหม่ดังตารางที่ 3.6

ตารางที่ 3.6 ขั้นตอนการปรับแก้เส้นกรอบพื้นที่ทางซ้ายมือ


ลำดับ	ขั้นตอนการจำแนก	เงื่อนไข
1	ตรวจสอบความชันของเส้นตรงที่ได้จาก Hough Transform ว่ามีความใกล้เคียงกับเส้นขอบทางซ้ายที่ได้กำหนดในเริ่มต้นในข้อที่ 1 (draw line_left) หรือไม่ ถ้าใช่ นำเส้นตรงเหล่านี้เข้าสู่ขั้นตอนถัดไป	ถ้า Slope ของเส้นตรง < Slope ของเส้นกรอบพื้นที่ทางซ้ายที่กำหนดตอนค่าเริ่มต้น (draw line_left) - 10 และ Slope < 0
2	นำค่า Slope และ Intercept ของเส้นตรงผ่านเงื่อนไขขั้นตอนที่ 1 ทั้งหมดมาเฉลี่ยพิกัดแกน X และแกน Y แล้วสร้างสมการเชิงเส้นตรงของเส้นขอบทางซ้ายใหม่ (new line_left)	-
3	เปรียบเทียบระยะห่างของแกน X ระหว่างเส้นขอบทางซ้ายเริ่มต้น (draw line_left) และเส้นขอบทางซ้ายใหม่ (new line_left) ด้วยประมาณค่าตำแหน่งมุมด้านซ้ายล่างของกรอบพื้นที่เพื่อตรวจสอบว่ามีความใกล้เคียงกันหรือไม่ หากใกล้เคียงตามเงื่อนไขให้เข้าสู่ขั้นตอนถัดไป	หาตำแหน่งแกน X ของมุมด้านซ้ายล่างของกรอบพื้นที่โดยใช้สมการ $X = (Y - \text{Intercept}) / \text{Slope}$ ของเส้นขอบทางซ้ายเริ่มต้น (draw line_left) และ เส้นขอบทางซ้ายใหม่ (new line_left) แล้วเปรียบเทียบเงื่อนไข ถ้า $-150 \text{ pixel} < \text{ระยะห่างระหว่างแกน X ของเส้นตรงใหม่กับเส้นกรอบพื้นที่ทางซ้าย} > 150 \text{ pixel}$

ตารางที่ 3.6 ขั้นตอนการปรับแก้เส้นกรอบพื้นที่ทางซ้ายมือ (ต่อ)

ลำดับ	ขั้นตอนการจำแนก	เงื่อนไข
4	ปรับแก้กรอบพื้นที่ใหม่โดยใช้เส้นขอบทางซ้ายใหม่ (new line_left) เป็นเส้นอ้างอิงในการปรับแต่งตำแหน่งของเส้นกรอบด้านขวาและมุมกรอบต่าง ๆ โดยใช้ความกว้างของช่องจราจรหรือความยาวของเส้นกรอบอื่น ๆ จากกรอบพื้นที่ที่ตั้งต้น (ROI.1) ในการปรับแก้ *ถ้าไม่พบเส้นขอบทางซ้ายใหม่ (new line_left) ที่ตรงตามเงื่อนไขให้ใช้ตำแหน่งเส้นกรอบพื้นที่ที่ตั้งต้น (ROI.1) ในการกำหนดกรอบพื้นที่ที่สนใจ	

3.4.4 โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle Type and Movement Classification Model)

จากการพัฒนาโมเดลการตรวจจับและติดตามยานพาหนะและโมเดลสร้างกรอบพื้นที่ที่สนใจ ทำให้ได้ข้อมูลในแต่ละคัน ได้แก่ (1) ประเภทของยานพาหนะ (Vehicle Type), (2) ทิศทางหรือรูปแบบการเคลื่อนที่ของยานพาหนะ (Vehicle Movement), (3) จำนวนเฟรมและสัดส่วนที่ยานพาหนะอยู่ในกรอบพื้นที่ที่สนใจ (วิ่งอยู่ในช่องจราจร) เพื่อใช้ในการจำแนกรถที่ไม่เกี่ยวข้องออกจากการคำนวณ เช่น รถบนไหล่ทาง และ (4) จำนวนเฟรมที่โมเดลติดตามยานพาหนะแต่ละคันเพื่อใช้ในการจำแนกยานพาหนะที่นับซ้ำซ้อนจากข้อผิดพลาดจากการคำนวณ เป็นต้น จึงนำข้อมูลที่ได้มาใช้ในการจำแนกประเภทและรูปแบบการเคลื่อนที่ตามวิธีสำรวจ MOM ทั้ง 3 รูปแบบ ได้แก่ (1) การจำแนกรถทิศทางตรงข้าม (Opposing Vehicle Classification), (2) การจำแนกรถที่แซงรถสำรวจ (Overtaking Vehicle Classification) และ (3) การจำแนกรถที่ถูกรถสำรวจแซง (Passed Vehicle Classification) เป็นต้น



รูปที่ 3.9 Flow Chart ของการใช้งานโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

โดยขั้นตอนและเงื่อนไขเพื่อนับและจำแนกรูปแบบการเคลื่อนที่มีรายละเอียดดังนี้

1) การจำแนกรถทิศทางตรงข้าม (Opposing Vehicle Classification)

ตารางที่ 3.7 ขั้นตอนการจำแนกรถทิศทางตรงข้าม

ลำดับ	ขั้นตอนการจำแนก	เงื่อนไข
1.1)	เมื่อรถชนเส้น Counting Line ตรวจสอบจำนวนเฟรมที่ติดตามยานพาหนะตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line (เส้นกรอบด้านล่าง)	ถ้ายานพาหนะถูกติดตาม ≥ 5 เฟรม
1.2)	ตรวจสอบตำแหน่งของยานพาหนะที่วิ่งในเฟรมก่อนหน้านี้ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าตำแหน่งของยานพาหนะเฟรม (t-2) อยู่ในกรอบพื้นที่ที่สนใจ
1.3)	ตรวจสอบเวกเตอร์การเคลื่อนที่ของยานพาหนะ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าเวกเตอร์การเคลื่อนที่ตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line ในแกน $X > 0$ และแกน $Y < 0$
1.4)	ตรวจสอบตำแหน่งของยานพาหนะที่วิ่งบนกรอบพื้นที่ที่สนใจ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าวิ่งบนกรอบพื้นที่ที่สนใจ ≥ 5 เฟรม
1.5)	ตรวจสอบตำแหน่งของยานพาหนะเพื่อกำจัดปัญหากรณีที่มีการติดตามไอดีของยานพาหนะไม่เสถียรซึ่งทำให้เกิดการนับที่ผิดพลาด ถ้าผ่านเงื่อนไขให้ทำการนับและบันทึกประเภทยานพาหนะ	ถ้าตำแหน่งของยานพาหนะเฟรม (t-0) ในแกน X อยู่บริเวณช่องจราจรฝั่งขวาที่รถวิ่งในทิศทางข้าม (ช่วงความยาว 2/5 ถึง 5/5 ของเส้นกรอบด้านล่าง)

2) การจำแนกรถที่ถูกรถสำรวจแซง (Passed Vehicle Classification)

ตารางที่ 3.8 ขั้นตอนการจำแนกรถที่ถูกรถสำรวจแซง


ลำดับ	ขั้นตอนการจำแนก	เงื่อนไข
2.1)	เมื่อรถชนเส้น Counting Line ตรวจสอบจำนวนเฟรมที่ติดตามยานพาหนะตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line (เส้นกรอบด้านซ้าย)	ถ้ายานพาหนะถูกติดตาม ≥ 5 เฟรม
2.2)	ตรวจสอบจำนวนเฟรมที่ยานพาหนะด้านหน้าวิ่งบนกรอบพื้นที่ที่สนใจ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้ายานพาหนะอยู่ในกรอบพื้นที่ที่สนใจ ≥ 45 เฟรมและมีสัดส่วนที่ยานพาหนะนั้นอยู่ในกรอบพื้นที่ $\geq 60\%$
2.3)	ตรวจสอบเวกเตอร์การเคลื่อนที่ของยานพาหนะ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าเวกเตอร์การเคลื่อนที่ตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line ในแกน $X < 0$ และแกน $Y < 0$
2.4)	ระบบจะบันทึกข้อมูลยานพาหนะนี้ว่ามีโอกาสที่จะเป็นรถที่จะถูกรถสำรวจแซง	
2.5)	รถที่ถูกระบุว่ามีโอกาสถูกแซงนั้นจะถูกนับว่าเป็นรถที่ถูกรถสำรวจแซงต่อเมื่อตำแหน่งของรถอยู่ใกล้เคียงเส้น ROI ทางซ้ายมือตามเกณฑ์ที่กำหนดไว้	ถ้าตำแหน่งของยานพาหนะเฟรม (t-0) ในแกน Y อยู่ต่ำกว่าตำแหน่ง 1/2 ของเส้นกรอบพื้นที่ด้านซ้ายมือ

3) การจำแนกรถที่แซงรถสำรวจ (Overtaking Vehicle Classification)


ตารางที่ 3.9 ขั้นตอนการจำแนกรถที่แซงรถสำรวจ

ลำดับ	ขั้นตอนการจำแนก	เงื่อนไข
3.1)	เมื่อรถชนเส้น Counting Line ตรวจสอบจำนวนเฟรมที่ติดตามยานพาหนะตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line (เส้นกรอบด้านล่าง)	ถ้ายานพาหนะถูกติดตาม ≥ 5 เฟรม
3.2)	ตรวจสอบเวกเตอร์การเคลื่อนที่ของยานพาหนะ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าเวกเตอร์การเคลื่อนที่ตั้งแต่เริ่มต้นจนถึงชนเส้น Counting Line ในแกน $X < 0$ และแกน $Y > 0$
3.3)	ตรวจสอบตำแหน่งของยานพาหนะที่วิ่งในเฟรมก่อนหน้านี้ ถ้าผ่านเงื่อนไขให้ดำเนินการขั้นตอนถัดไป	ถ้าตำแหน่งของยานพาหนะเฟรม (t-2) ไม่อยู่ในกรอบพื้นที่สนใจ
3.4)	ตรวจสอบตำแหน่งของยานพาหนะเพื่อกำจัดปัญหากรณีที่มีการติดตามไอดีของยานพาหนะไม่เสถียรซึ่งทำให้เกิดการนับที่ผิดพลาด ถ้าผ่านเงื่อนไขให้ทำการนับและบันทึกประเภทยานพาหนะ	ถ้าตำแหน่งของยานพาหนะเฟรม (t-0) ในแกน X อยู่บริเวณช่องจราจรฝั่งขวาที่รถวิ่งในทิศทางข้าม (ช่วงความยาว 2/5 ถึง 5/5 ของเส้นกรอบด้านล่าง)


โดยสามารถแสดงตัวอย่างเหตุการณ์ที่ยานพาหนะกำลังวิ่งชนเส้น Counting Line ของทั้ง 3 รูปแบบการเคลื่อนที่เพื่อให้เห็นถึงการแสดงผลของโมเดลในการระบุประเภทยานพาหนะ เวกเตอร์การเคลื่อนที่และเส้นกรอบพื้นที่ที่สร้างขึ้น (กรอบสีน้ำเงินคือกรอบที่ผ่านการปรับแก้ กรอบสีแดงคือกรอบที่ไม่สามารถปรับแก้ได้ซึ่งจะใช้ค่าตั้งต้นในการสร้างกรอบพื้นที่) ดังรูปที่ 3.10 ถึงรูปที่ 3.13




รูปที่ 3.10 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
A) นักรถทิศทางตรงข้าม



รูปที่ 3.11 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
B) รถกำลังถูกรถสำรวจแซง



รูปที่ 3.12 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
C) รถกำลังแซงรถสำรวจ



รูปที่ 3.13 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
D) จำแนกรถบนไหล่ทางด้วยกรอบพื้นที่ที่สร้างขึ้น

3.4.5 ขั้นตอนการใช้งานโมเดลที่นำเสนอ



รูปที่ 3.14 ขั้นตอนการใช้งานโมเดลที่นำเสนอ

จากการออกแบบโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะในหัวข้อ 3.4 สามารถแสดงเป็นขั้นตอนการใช้งานโมเดลที่นำเสนอกับข้อมูลวิดีโอสำรวจ 1 เทียบดังรูปที่ 2.4 โดยแต่ละขั้นตอนมีรายละเอียดดังนี้

1) เริ่มต้น : เริ่มต้นการใช้งานโมเดลโดยการเข้าไปที่ไฟล์ detect_MOM.py ที่เป็น Source Code หลักในการรันโมเดลที่นำเสนอทั้งหมด

2) กำหนดค่า Initial Parameter ในการรันโมเดลและค่าตั้งต้นของกรอบพื้นที่

(1) กำหนด Initial Parameter ในการรันโมเดลซึ่งแบ่งออกเป็น 2 ส่วนได้แก่

(1.1) พารามิเตอร์ที่ต้องระบุทุกครั้งก่อนใช้งานโมเดลที่นำเสนอแสดงดัง

ตารางที่ 3.10

ตารางที่ 3.10 การตั้งค่าพารามิเตอร์ในการใช้งานโมเดลที่นำเสนอ

No.	Parameter	Detail
1	weights	ระบุ YOLOv7 weight ที่ต้องการใช้ในการตรวจจับยานพาหนะ
2	source	ระบุวิดีโอสำรวจจราจรที่ต้องการรัน
3	conf-thres	ระบุค่า Confidence Threshold ของยานพาหนะที่ต้องการแสดงผล (โดยมีค่าตั้งต้นเท่ากับ 0.5)
4	detect_veh_movement	เรียกใช้งานโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่เพื่อบันทึกข้อมูลสำรวจตามวิธีสำรวจ MOM
5	laneDetect	เรียกใช้งานอัลกอริทึมตรวจจับเส้นจราจรเพื่อปรับแก้กรอบพื้นที่ที่สนใจที่ต้องตรวจจับเฉพาะยานพาหนะที่วิ่งบนช่องจราจร
6	define_roi_list	ระบุค่าตำแหน่งแกน (X, Y) ของมุมกรอบพื้นที่ทั้ง 4 มุม

(1.2) พารามิเตอร์ที่กำหนดเป็นค่าตั้งต้นในการรันโมเดล เช่น การตั้งค่าพารามิเตอร์การประมวลผลของโมเดลติดตามวัตถุ StrongSORT การตั้งค่าพารามิเตอร์การประมวลผลของโมเดลตรวจจับวัตถุ YOLOv7 และการตั้งค่าการแสดงผลบนหน้าจอ เป็นต้น เป็นไปตามที่ได้อธิบายในหัวข้อ 3.4.1 ถึง 3.4.4

(2) กำหนดค่าตั้งต้นของกรอบพื้นที่เพื่อใช้โมเดลการสร้างกรอบพื้นที่ที่สนใจ (--define_roi_list):

(2.1) กรณีที่ผู้ใช้งานทำการรันบนเครื่องคอมพิวเตอร์ ผู้ใช้งานสามารถเลือกที่จะกำหนดค่าตัวเลขตำแหน่งแกน (X, Y) ของมุมกรอบพื้นที่ทั้ง 4 มุม หรือทำการคลิกเพื่อระบุตำแหน่งกรอบพื้นที่ในตอนเริ่มต้นการรันได้ ซึ่งระบบจะแสดงภาพวิดีโอเริ่มต้นเพื่อให้ผู้ใช้งานได้กำหนดจุดมุมของกรอบพื้นที่เพื่อเป็นค่าตั้งต้นด้วยตนเองดังตัวอย่างในรูปที่ 3.15

(2.2) หากรันบน Web Browser หรือ Google Colab ผู้ใช้งานต้องทำการกำหนดค่าตัวเลขตำแหน่งแกน (X, Y) ของมุมกรอบพื้นที่ทั้ง 4 มุมในการกำหนด initial parameter เท่านั้น ซึ่งสามารถหาค่าตำแหน่งได้จากการรันไฟล์ run_selectRoi_byMouse.py บนเครื่องคอมพิวเตอร์ดังตัวอย่างในรูปที่ 3.15 เช่นกัน

โดยสามารถยกตัวอย่างการกำหนดค่าพารามิเตอร์ในการรันแต่ละครั้งได้ดัง Source Code ด้านล่าง

```
# 1) กรณีมีการกำหนดค่าตำแหน่งมุมของกรอบพื้นที่ที่สนใจด้วยพารามิเตอร์
python detect_modify.py
--source ..\datasets\1.Bangphra\1_peak_mp4\1_2_MOVA0020.mp4
--weights yolov7_weights/yolov7_onlyfrontV2_defaultP5_best300.pt
--conf-thres 0.5
--detect_veh_movement
--laneDetect
--view-img
--define_roi_list "[[673, 543], [422, 717], [1278, 604], [757, 544]]"
```

2) กรณีต้องการคลิกเพื่อระบุตำแหน่งมุมของกรอบพื้นที่ที่สนใจ (เฉพาะการรันบนเครื่องคอมพิวเตอร์)

```
python detect_modify.py
```

```
--source ..\datasets\1.Bangphra\1_peak_mp4\1_2_MOVA0020.mp4
```

```
--weights yolov7_weights/yolov7_onlyfrontV2_defaultP5_best300.pt
```

```
--conf-thres 0.5
```

```
--detect_veh_movement
```

```
--laneDetect
```

```
--view-img
```



รูปที่ 3.15 ตัวอย่างภาพวิดีโอในขั้นตอนการระบุตำแหน่งกรอบพื้นที่ที่สนใจ

3) สร้าง Loop เพื่อประมวลผลวิดีโอสำรวจที่ละเฟรม

4) ประมวลผลภาพวิดีโอโดยโมเดลทั้ง 3 : ภาพวิดีโอเฟรมที่ i จะถูกประมวลผลโดยโมเดลทั้ง 3 ส่วน

a. Vehicle Detection Model (YOLOv7) โมเดลจะทำการตรวจจับยานพาหนะที่อยู่บนภาพ แล้วส่งข้อมูลไปยังโมเดลติดตามยานพาหนะ

b. Vehicle Tracking Model (StrongSORT) โมเดลจะทำการติดตามการเคลื่อนที่ของยานพาหนะของแต่ละไอดี แล้วส่งข้อมูลไปยังโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่

c. ROI Based on Lane Line Detection โมเดลจะทำการปรับแก้กรอบพื้นที่ที่สนใจ ให้สอดคล้องกับช่องจราจรจริงตลอดการสำรวจ แล้วส่งข้อมูลกรอบพื้นที่ที่ถูกปรับแก้ไปยังโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่

5) ตรวจสอบการเคลื่อนที่ของยานพาหนะโดย Vehicle Type and Movement Classification Model : ข้อมูลการติดตามการเคลื่อนที่ของยานพาหนะตั้งแต่เริ่มต้นจะถูกส่งมายังโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ที่ยานพาหนะ หากยานพาหนะวิ่งชนเส้น Counting Line จะทำการพิจารณาในขั้นต่อไป

6) พิจารณานับและจำแนกยานพาหนะและบันทึกผล: ข้อมูลทั้งหมดจะถูกส่งไปยังโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ที่ยานพาหนะ (Vehicle Movement Classification Model) หากยานพาหนะคันใดวิ่งชนเส้น Counting Line โมเดลจะนำข้อมูลการติดตามตั้งแต่เริ่มต้นจนถึงชนเส้นที่กำหนดไว้ประกอบด้วย มานับและจำแนกจำนวนยานพาหนะทั้ง 3 รูปแบบ ได้แก่ (1) รถที่วิ่งในทิศทางตรงข้าม (Opposing Vehicle), (2) รถที่ถูกรถสำรวจแซง (Passed Vehicle) และ (3) รถที่แซงรถสำรวจ (Overtaking Vehicle)

7) สรุปผลข้อมูลยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ลงในไฟล์ csv : เมื่อโมเดลรันถึงเฟรมสุดท้าย สรุปผลข้อมูลยานพาหนะทั้ง 3 รูปแบบและบันทึกข้อมูลการติดตามยานพาหนะของแต่ละไอดีและข้อมูลวิดีโอและเวลาที่ใช้การรันลงในไฟล์ csv

8) จบการทำงาน

3.5 การประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Estimation of Traffic Flow Variable Based on Moving Observers Method)

ผลลัพธ์การนับและจำแนกจำนวนยานพาหนะแต่ละประเภทของทั้ง 3 รูปแบบการเคลื่อนที่ของโมเดลที่นำเสนอจึงถูกนำไปใช้ในการประมาณค่าตัวแปรกระแสจราจร โดยมีขั้นตอนดังนี้

1) ผลลัพธ์การนับและจำแนกจำนวนยานพาหนะแต่ละประเภทของทั้ง 3 รูปแบบการเคลื่อนที่ที่สนใจในแต่ละเที่ยวการสำรวจ นำไปจับคู่เพื่อให้ได้จำนวนยานพาหนะในแต่ละรอบสำรวจตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ (Moving Observers Method: MOM)

2) นำข้อมูลจำนวนยานพาหนะแต่ละประเภทไปแปลงค่าในรูปแบบรถยนต์ส่วนบุคคล (Passenger Car Unit: PCU)

3) ทำการหาค่าเฉลี่ยของจำนวนยานพาหนะทั้ง 3 รูปแบบ, เวลา และระยะทางเฉลี่ยการเดินทางในแต่ละทิศทางและช่วงเวลาสำรวจเพื่อนำไปคำนวณหาค่าอัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นของกระแสจราจรตามสมการที่ (2.24), (2.26) และ (2.27) ตามลำดับ

3.6 การประเมินประสิทธิภาพโมเดล

การประเมินประสิทธิภาพของโมเดลที่นำเสนอในงานวิจัยประกอบด้วย 2 ส่วนได้แก่

3.6.1 การประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

เลือกใช้เครื่องมือในการวัดผลประเมินภาพในการตรวจจับและจำแนกประกอบไปด้วย Precision, Recall, F1-score, Accuracy และ Confusion Matrix และ (2) การประเมินความคลาดเคลื่อนของการประมาณค่าตัวแปรกระแสจราจรเมื่อเปรียบเทียบระหว่างการใช้ข้อมูลจริงกับผลลัพธ์ที่ได้จากโมเดลที่นำเสนอเลือกใช้เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error (APE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error (APE) โดยแต่ละเครื่องมือวัดผลมีรายละเอียดดังนี้

1) Precision เพื่อวัดความแม่นยำหรือความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องตามวัตถุประสงค์ (นับเฉพาะยานพาหนะที่อยู่บนช่องจราจรและจำแนกประเภทและรูปแบบการเคลื่อนที่ได้ถูกต้อง) ต่อจำนวนยานพาหนะที่โมเดลสามารถนับและจำแนกได้ทั้งหมด (รวมเหตุการณ์ที่โมเดลจำแนกทั้งถูกและผิด)

$$\text{Precision} = \frac{\text{TP}}{\text{TP}+\text{FP}} \quad (3.1)$$

โดยที่	TP	คือ (True Positive) จำนวนเหตุการณ์ที่โมเดลนับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง/สามารถจำแนกรถบนไหล่ทางออกจากการคำนวณได้
	TF	คือ (True Negative) จำนวนเหตุการณ์ที่โมเดลไม่ตรวจจับยานพาหนะ เพราะไม่มีเหตุการณ์ที่ต้องตรวจจับในความจริง
	FP	คือ (False Positive) จำนวนเหตุการณ์ที่โมเดลนับยานพาหนะได้แต่จำแนกประเภทยานพาหนะผิดพลาดและนับซ้ำซ้อน/จำแนกรถบนไหล่ทางและอื่น ๆ ที่ไม่สนใจเข้าสู่การคำนวณ
	FN	คือ (False Negative) จำนวนเหตุการณ์ที่ไม่สามารถนับยานพาหนะได้

(2) Recall เพื่อวัดครบถ้วนหรือความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องต่อยานพาหนะที่เกิดขึ้นในการสำรวจทั้งหมด (ยานพาหนะที่นับและจำแนกถูกต้องรวมกับยานพาหนะที่ไม่สามารถนับได้)

$$\text{Recall} = \frac{\text{TP}}{\text{TP}+\text{FN}} \quad (3.2)$$

(3) F1-score เพื่อวัดประสิทธิภาพโดยรวมของโมเดลโดยนำค่า Precision กับ Recall มาเฉลี่ยแบบ Harmonic Mean

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.3)$$

(4) Accuracy เพื่อวัดความน่าจะเป็นที่โมเดลจำแนกได้ถูกต้องต่อเหตุการณ์ที่เกิดขึ้นทั้งหมด

$$\text{Accuracy} = \frac{\text{TP}+\text{TN}}{\text{TP}+\text{TN}+\text{FP}+\text{FN}} \quad (3.4)$$

(5) Confusion Matrix เพื่อแสดงความแม่นยำในการจำแนกยานพาหนะแต่ละประเภทในรูปแบบตารางเมทริกซ์

3.6.2 เปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างผลที่ได้จากจำแนกของโมเดลที่นำเสนอกับข้อมูลสำรวจจริง

(1) Mean Absolute Percentage Error (MAPE) เพื่อวัดความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจรระหว่างการใช้ข้อมูลสำรวจจริงกับผลลัพธ์ที่ได้จากโมเดลที่นำเสนอ

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|A_i - F_i|}{A_i} \quad (3.5)$$

โดยที่ A_i คือ ค่าจริง
 F_i คือ ค่าที่ได้จากการทำนาย

(2) GEH Statistic เป็นเครื่องมือทางสถิติที่มีความนิยมด้านการจราจรและขนส่ง และมีค่ามาตรฐานที่ยอมรับในระดับสากลในการนำไปใช้เปรียบเทียบข้อมูลปริมาณจราจรรายชั่วโมงระหว่างข้อมูลสำรวจจริงกับผลที่ได้จากการคำนวณและทำนายผลว่าอยู่ในเกณฑ์ความคลาดเคลื่อนที่สามารถยอมรับได้หรือไม่ โดยสามารถคำนวณได้ดังสมการที่ (3.6) ซึ่งมีเกณฑ์การยอมรับความคลาดเคลื่อนของข้อมูลดังตารางที่ 3.11 โดยงานวิจัยนี้จะทำการเปรียบเทียบค่าอัตราการใช้ระหว่างการประมาณค่าโดยใช้ผลที่ได้จากโมเดลที่นำเสนอกับข้อมูลสำรวจจริง หากค่า GEH ของช่วงถนนสำรวจในทิศทางนั้นมีค่าน้อยกว่า 5 แสดงให้เห็นว่า ค่าอัตราการใช้ที่ได้จากโมเดลที่นำเสนอมีความคลาดเคลื่อนที่อยู่ในเกณฑ์ที่สามารถยอมรับได้

$$GEH = \sqrt{\frac{2(M - C)^2}{M + C}} \quad (3.6)$$

โดยที่ GEH คือ ค่าที่ใช้เปรียบเทียบแบบจำลองการจราจร
 M คือ ปริมาณจราจรที่ได้จากแบบจำลอง (คัน/ชม. หรือ PCU/ชม.)
 C คือ ปริมาณจราจรจากการสำรวจ (คัน/ชม. หรือ PCU/ชม.)

ตารางที่ 3.11 ความคลาดเคลื่อนที่ยอมรับได้ในประมาณค่าปริมาณจราจร

ค่าชี้วัดการเปรียบเทียบ	เกณฑ์การเปรียบเทียบ	เป้าหมายการเปรียบเทียบ
ปริมาณจราจรแต่ละทิศทาง	GEH < 5	> 85% ของกรณีทั้งหมด

หมายเหตุ จาก TAG UNIT M3.1: Highway Assignment Modelling (20), by TASM, 2020,
 London : Department of Transport.

บทที่ 4

ผลการวิเคราะห์ข้อมูลและการอภิปรายผล

ผลการวิเคราะห์ข้อมูลจราจรและการประเมินประสิทธิภาพของโมเดลที่นำเสนอ ประกอบด้วย 5 ส่วนหลักดังนี้

ส่วนที่ 1 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

ส่วนที่ 2 ผลการฝึกฝนโมเดลตรวจจับยานพาหนะ

ส่วนที่ 3 ผลการประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

ส่วนที่ 4 ผลการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่

ส่วนที่ 5 ผลการเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างข้อมูลจริงกับโมเดลที่นำเสนอ

4.1 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะ

จากการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะบนจุดสำรวจทั้งหมด 5 จุดแสดงดังรูปที่ 3.1 ทั้งช่วงเวลาไม่เร่งด่วนและเร่งด่วนเป็นจำนวนทั้งหมด 153 เทียบนำมาจับคู่ตามวิธีการสำรวจ MOM ได้ทั้งหมด 143 รอบ (ช่วงถนนสำรวจละ 4-9 รอบต่อทิศทางต่อช่วงเวลา) โดยสามารถแสดงจำนวนยานพาหนะแต่ละประเภทในแต่ละรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบประกอบด้วย (1) รถที่วิ่งในทิศทางทาง (Opposing Vehicle), (2) รถที่ถูกรถสำรวจวิ่งแซง (Passed Vehicle) และ (3) รถที่แซงรถสำรวจ (Overtaking Vehicle) ได้ดังตารางที่ 4.1 ถึงตารางที่ 4.3 จากนั้นนำจำนวนยานพาหนะแต่ละประเภทที่ได้ไปแปลงหน่วยรถยนต์ส่วนบุคคล (Passenger Car Unit: PCU) แล้วทำการเฉลี่ยรายจุดสำรวจ ทิศทางและช่วงเวลาเพื่อนำไปคำนวณหาค่าตัวแปรกระแสจราจรประกอบไปด้วย อัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรในลำดับถัดไปในหัวข้อ 4.5 ซึ่งสามารถแสดงจำนวนยานพาหนะแต่ละรูปแบบเคลื่อนที่ ระยะทางและเวลาการเดินทางเฉลี่ยของการสำรวจได้ดังตารางที่ 4.4

ตารางที่ 4.1 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่วิ่งทิศทางตรงข้าม)

Number of Opposing Vehicle												
Location	Direction	Period	Number of Round	Motorcycl	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total
A	W-E	Off-Peak	8	4	38	21	64	24	28	5	0	184
	W-E	Peak	7	29	100	36	102	23	21	25	7	343
	Total W-E		15	33	138	57	166	47	49	30	7	527
	E-W	Off-Peak	7	8	29	15	50	31	17	6	2	158
	E-W	Peak	8	15	84	21	100	21	21	17	3	282
	Total E-W		15	23	113	36	150	52	38	23	5	440
B	W-E	Off-Peak	5	5	35	21	39	16	32	4	0	152
	W-E	Peak	4	32	55	27	47	12	10	7	0	190
	Total W-E		9	37	90	48	86	28	42	11	0	342
	E-W	Off-Peak	5	17	32	11	29	13	45	4	0	151
	E-W	Peak	4	12	27	12	43	8	8	3	0	113
	Total E-W		9	29	59	23	72	21	53	7	0	264
C	W-E	Off-Peak	9	11	52	28	56	34	22	7	0	210
	W-E	Peak	7	25	58	36	80	29	7	7	0	242
	Total W-E		16	36	110	64	136	63	29	14	0	452
	E-W	Off-Peak	9	20	40	24	48	40	23	1	0	196
	E-W	Peak	8	61	64	41	68	32	10	9	0	285
	Total E-W		17	81	104	65	116	72	33	10	0	481
D	W-E	Off-Peak	7	5	47	26	54	42	29	10	0	213
	W-E	Peak	9	24	112	51	112	42	20	15	1	377
	Total W-E		16	29	159	77	166	84	49	25	1	590
	E-W	Off-Peak	7	10	41	21	53	37	17	15	1	195
	E-W	Peak	9	18	73	37	67	39	33	19	1	287
	Total E-W		16	28	114	58	120	76	50	34	2	482

ตารางที่ 4.1 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่วิ่งทิศทางตรงข้าม) (ต่อ)

Number of Opposing Vehicle												
Location	Direction	Period	Number of Round	Motorcycl	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total
E	W-E	Off-Peak	8	46	62	35	108	52	58	16	1	378
	W-E	Peak	8	140	92	40	127	62	26	108	22	617
	Total W-E		16	186	154	75	235	114	84	124	23	995
	E-W	Off-Peak	7	44	43	27	106	61	45	32	6	364
	E-W	Peak	7	103	73	32	143	45	27	50	3	476
	Total E-W		14	147	116	59	249	106	72	82	9	840
Total			143	629	1157	562	1496	663	499	360	47	5413

ตารางที่ 4.2 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่ถูกรถสำรวจแซง)

Number of Passed Vehicle													
Location	Direction	Period	Number of Round	Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total	
A	W-E	Off-Peak	8	0	0	0	0	1	0	0	0	1	
	W-E	Peak	7	0	0	0	2	0	0	1	0	3	
	Total W-E		15	0	0	0	2	1	0	1	0	4	
	E-W	Off-Peak	7	0	0	0	0	0	4	0	0	4	
	E-W	Peak	8	0	0	0	0	0	1	1	0	2	
	Total E-W		15	0	0	0	0	0	5	1	0	6	
B	W-E	Off-Peak	5	0	0	0	0	0	1	0	0	1	
	W-E	Peak	4	0	0	0	0	0	0	0	0	0	
	Total W-E		9	0	0	0	0	0	1	0	0	1	
	E-W	Off-Peak	5	0	0	0	0	0	0	1	0	0	1
	E-W	Peak	4	2	0	0	0	1	1	0	0	4	
	Total E-W		9	2	0	0	0	1	2	0	0	5	

ตารางที่ 4.2 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่ถูกรถสำรวจแซง) (ต่อ)

Number of Passed Vehicle												
Location	Direction	Period	Number of Round	Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total
C	W-E	Off-Peak	9	0	0	0	0	0	0	0	0	0
	W-E	Peak	7	0	0	0	0	1	0	0	0	1
	Total W-E		16	0	0	0	0	1	0	0	0	1
	E-W	Off-Peak	9	0	0	0	0	0	0	0	0	0
	E-W	Peak	8	0	0	0	0	0	0	0	0	0
	Total E-W		17	0	0	0	0	0	0	0	0	0
D	W-E	Off-Peak	7	0	0	0	0	0	0	0	0	0
	W-E	Peak	9	0	0	0	0	0	1	0	0	1
	Total W-E		16	0	0	0	0	0	1	0	0	1
	E-W	Off-Peak	7	0	0	0	0	0	0	0	0	0
	E-W	Peak	9	0	0	0	0	0	0	0	0	0
	Total E-W		16	0	0	0	0	0	0	0	0	0
E	W-E	Off-Peak	8	0	0	0	3	0	0	0	0	3
	W-E	Peak	8	1	0	0	0	0	0	0	0	1
	Total W-E		16	1	0	0	3	0	0	0	0	4
	E-W	Off-Peak	7	0	0	0	0	0	2	0	0	2
	E-W	Peak	7	1	0	0	0	0	0	0	1	2
	Total E-W		14	1	0	0	0	0	2	0	1	4
Total			143	4	0	0	5	3	11	2	1	26

ตารางที่ 4.3 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่แซงรถสำรวจ)

Number of Overtaking Vehicle												
Location	Direction	Period	Number of Round	Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total
A	W-E	Off-Peak	8	1	3	3	2	3	1	0	0	13
	W-E	Peak	7	0	0	1	5	0	0	0	0	6
	Total W-E		15	1	3	4	7	3	1	0	0	19
	E-W	Off-Peak	7	0	1	0	2	0	0	0	0	3
	E-W	Peak	8	1	3	0	5	2	0	0	1	12
	Total E-W		15	1	4	0	7	2	0	0	1	15
	B	W-E	Off-Peak	5	1	2	0	0	0	0	0	0
W-E		Peak	4	0	0	0	1	0	0	0	0	1
Total W-E		9	1	2	0	1	0	0	0	0	4	
E-W		Off-Peak	5	0	2	1	0	0	1	0	0	4
E-W		Peak	4	1	1	1	2	1	0	0	0	6
Total E-W		9	1	3	2	2	1	1	0	0	10	
C		W-E	Off-Peak	9	1	0	1	1	0	0	0	0
	W-E	Peak	7	0	0	0	0	1	0	0	0	1
	Total W-E		16	1	0	1	1	1	0	0	0	4
	E-W	Off-Peak	9	0	0	2	3	1	0	1	0	7
	E-W	Peak	8	0	1	2	0	1	0	0	0	4
	Total E-W		17	0	1	4	3	2	0	1	0	11
	D	W-E	Off-Peak	7	0	2	0	2	3	0	1	0
W-E		Peak	9	1	1	1	2	0	0	1	0	6
Total W-E		16	1	3	1	4	3	0	2	0	14	
E-W		Off-Peak	7	0	1	0	3	1	0	0	0	5
E-W		Peak	9	0	2	0	5	0	0	2	0	9
Total E-W		16	0	3	0	8	1	0	2	0	14	

ตารางที่ 4.3 ผลการสำรวจข้อมูลจราจรตามวิธีสำรวจโดยการเคลื่อนที่ของยานพาหนะในแต่ละจุดสำรวจ (รถที่แซงรถสำรวจ) (ต่อ)

Number of Overtaking Vehicle												
Location	Direction	Period	Number of Round	Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Total
E	W-E	Off-Peak	8	0	0	0	1	0	0	0	0	1
	W-E	Peak	8	1	0	0	0	0	0	0	0	1
	Total W-E		16	1	0	0	1	0	0	0	0	2
	E-W	Off-Peak	7	1	0	0	0	1	0	0	0	2
	E-W	Peak	7	1	0	0	0	0	0	0	0	1
	Total E-W		14	2	0	0	0	1	0	0	0	3
	Total			143	9	19	12	34	14	2	5	1

ตารางที่ 4.4 ผลการสรุปข้อมูลสำรวจและจำนวนยานพาหนะเฉลี่ยในแต่ละจุดสำรวจ

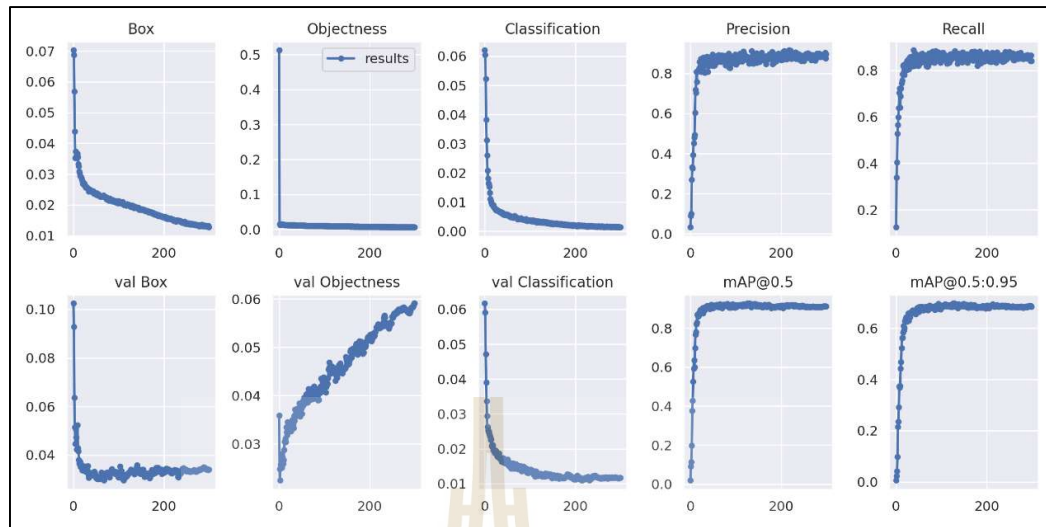
No.	Location	Direction	Period	Travel Time	Travel Time (Opposing Vehicle)	Road Length	Number of Vehicles by Movement Type (PCU)		
							Opposing Vehicle	Passed Vehicle	Overtaking Vehicle
1	A	E-W	Off-Peak	233.29	235.00	3.60	26.33	1.43	0.43
2	A	W-E	Off-Peak	234.38	232.75	3.60	26.50	0.13	1.73
3	A	E-W	Peak	230.75	234.75	3.60	50.90	0.44	1.55
4	A	W-E	Peak	235.57	232.14	3.60	37.84	0.43	0.86
5	B	E-W	Off-Peak	335.60	333.20	5.00	34.83	0.50	1.10
6	B	W-E	Off-Peak	335.00	335.60	5.00	41.43	0.50	0.47
7	B	E-W	Peak	325.50	328.50	5.00	45.91	1.04	1.33
8	B	W-E	Peak	328.50	322.00	5.00	29.91	0.00	0.25

ตารางที่ 4.4 ผลการสรุปข้อมูลสำรวจและจำนวนยานพาหนะเฉลี่ยในแต่ละจุดสำรวจ (ต่อ)

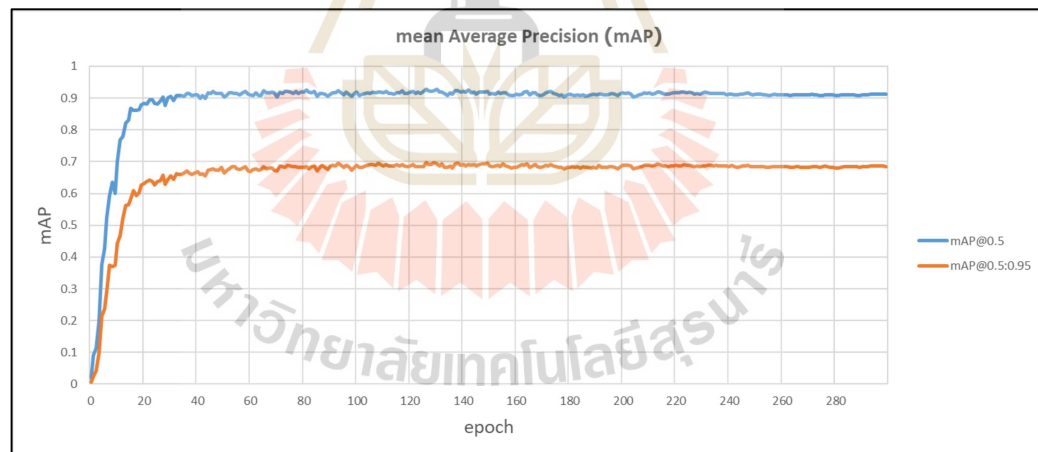
No.	Location	Direction	Period	Travel Time	Travel Time (Opposing Vehicle)	Road Length	Number of Vehicles by Movement Type (PCU)		
							Opposing Vehicle	Passed Vehicle	Overtaking Vehicle
9	C	E-W	Off-Peak	133.11	134.67	2.00	28.31	0.00	0.78
10	C	W-E	Off-Peak	134.22	133.11	2.00	24.13	0.00	0.26
11	C	E-W	Peak	130.00	136.13	2.00	33.57	0.00	0.50
12	C	W-E	Peak	136.43	130.29	2.00	33.90	0.14	0.14
13	D	E-W	Off-Peak	132.29	138.00	2.10	32.81	0.00	0.71
14	D	W-E	Off-Peak	138.57	132.29	2.10	30.70	0.00	1.14
15	D	E-W	Peak	129.78	139.33	2.10	45.30	0.00	1.00
16	D	W-E	Peak	141.33	129.78	2.10	36.18	0.28	0.59
17	E	E-W	Off-Peak	238.57	250.00	3.60	55.30	0.71	0.19
18	E	W-E	Off-Peak	250.13	239.50	3.60	56.72	0.38	0.13
19	E	E-W	Peak	268.43	255.29	3.60	75.21	0.35	0.05
20	E	W-E	Peak	253.38	270.63	3.60	65.38	0.04	0.04

4.2 ผลการฝึกฝนโมเดลสำหรับตรวจจับยานพาหนะ

โมเดลตรวจจับยานพาหนะเป็นส่วนหนึ่งของโมเดลการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะที่ได้นำเสนอในงานวิจัย มีหน้าที่ จำแนกประเภทยานพาหนะและระบุตำแหน่งของวัตถุ ซึ่งโมเดลจะถูกฝึกฝนก่อนนำไปประยุกต์กับโมเดลที่นำเสนอในงานวิจัยดังกล่าว กระบวนการในหัวข้อที่ 3.4.1 โดยผลการฝึกฝนโมเดลตรวจจับยานพาหนะพบว่า ใช้เวลาในการฝึกฝนโมเดลจำนวน 300 Epochs เท่ากับ 13.54 ชั่วโมง และสามารถแสดงผลการวัดประสิทธิภาพต่าง ๆ ต่อจำนวนรอบที่ใช้ฝึกฝนโมเดลได้ดังรูปที่ 4.1 และรูปที่ 4.2 ซึ่งค่า mean Average Precision (mAP) เริ่มมีค่าคงที่ที่ประมาณ Epoch ที่ 40



รูปที่ 4.1 กราฟแสดงค่า Box Loss, Objectness Loss, Classification Loss, Precision, Recall และ mAP ต่อจำนวนรอบในการฝึกฝนโมเดลตรวจจับยานพาหนะ



รูปที่ 4.2 กราฟแสดงค่า mAP ของการฝึกฝนโมเดลตรวจจับยานพาหนะ

และเมื่อนำโมเดลที่ผ่านการฝึกฝนและใช้งานจริงในงานวิจัยไปใช้งานกับรูปภาพยานพาหนะในชุดข้อมูล Validation Dataset สามารถแสดงประสิทธิภาพการทำนายผลของโมเดลประกอบด้วยค่า Precision, Recall, F1-score, mAP@0.5 (mean Average Precision ที่ IoU threshold เท่ากับ 0.5) และ mAP@0.5:0.95 (mean Average Precision ที่ IoU threshold เท่ากับ 0.5 ถึง 0.95) ได้ดังตารางที่ 4.5 ซึ่งพบว่า โมเดลตรวจจับยานพาหนะมีค่า mAP@.5 โดยรวมเท่ากับ 0.912 หรือ 91.2 % โดยยานพาหนะประเภท SUV มีค่า mAP@.5 น้อยที่สุดที่ 0.856 หรือ 85.6 % และเมื่อวัดประสิทธิภาพการจำแนกประเภทยานพาหนะด้วย Confusion Matrix ดังรูปที่ 4.3 พบว่า ยานพาหนะประเภท SUV มีความแม่นยำในการทำนายน้อยที่สุดที่ 0.71 หรือ 71%

ตารางที่ 4.5 ผลประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะกับรูปภาพยานพาหนะ (Validation Dataset)

Class	Precision	Recall	mAP@.5	mAP@.5:.95
Motorcycle	0.912	0.754	0.884	0.529
Car	0.904	0.808	0.919	0.68
SUV	0.735	0.789	0.856	0.674
Light Truck	0.834	0.764	0.864	0.624
Light Commercial Truck	0.919	0.858	0.916	0.71
Heavy Truck	0.954	0.913	0.974	0.745
Van	0.982	0.918	0.953	0.744
Bus	0.937	0.925	0.927	0.759
All Class	0.897	0.841	0.912	0.683

Vehicle Type Classification (Validation Dataset)		Predicted Class								Background FN
		Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	
Actual Class	Motorcycle	0.85	0.01	-	0.01	-	-	-	-	0.14
	Car		0.9	0.03	-	-	-	-	-	0.07
	SUV	0.01	0.11	0.71	0.10	0.02	-	0.01	0.01	0.02
	Light Truck		0.03	0.08	0.81	0.02	-	0.01	-	0.06
	Light Commercial Truck	-	-	0.01	0.06	0.85	0.01	0.01	-	0.06
	Heavy Truck	-	-	-	0.01	0.01	0.93	-	0.01	0.04
	Van	-	-	-	-	-	-	0.96	-	0.04
	Bus	-	-	-	-	-	-	0.05	0.92	0.02
	Background FP	0.38	0.15	0.13	0.18	0.06	0.03	0.04	0.02	-

รูปที่ 4.3 Confusion Matrix ของการจำแนกประเภทยานพาหนะกับรูปภาพยานพาหนะ (Validation Dataset)

โดยเมื่อทำการประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะกับข้อมูล Testing Dataset (15% จากข้อมูลรูปยานพาหนะทั้งหมด) ดังตารางที่ 4.6 พบว่า โมเดลตรวจจับยานพาหนะ มีค่า mAP@.5 โดยรวมเท่ากับ 0.917 หรือ 91.7 % โดยยานพาหนะประเภท SUV มีค่า mAP@.5 น้อยที่สุดที่ 0.870 หรือ 87.0 % โดยเมื่อวัดประสิทธิภาพการจำแนกประเภทยานพาหนะกับ Testing Dataset ด้วย Confusion Matrix ดังรูปที่ 4.4 พบว่า ยานพาหนะประเภท SUV มีความแม่นยำในการทำนายน้อยที่สุดที่ 0.71 หรือ 71%

ตารางที่ 4.6 ผลประเมินประสิทธิภาพของโมเดลตรวจจับยานพาหนะกับรูปภาพยานพาหนะ
(Testing Dataset)

Class	Precision	Recall	mAP@.5	mAP@.5:.95
Motorcycle	0.861	0.832	0.893	0.523
Car	0.875	0.805	0.913	0.675
SUV	0.684	0.864	0.870	0.675
Light Truck	0.887	0.775	0.899	0.671
Light Commercial Truck	0.85	0.857	0.922	0.709
Heavy Truck	0.896	0.913	0.936	0.735
Van	0.905	0.909	0.948	0.74
Bus	0.92	0.983	0.956	0.787
All Class	0.86	0.867	0.917	0.689

Vehicle Type Classification (Testing Dataset)		Predicted Class								
		Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus	Background FN
Actual Class	Motorcycle	0.92	0.01	-	-	-	-	-	-	0.07
	Car	0.01	0.9	0.04	0.01	-	-	-	-	0.04
	SUV	-	0.14	0.71	0.09	0.03	-	0.02	-	0.01
	Light Truck	-	0.03	0.01	0.89	0.03	-	0.01	-	0.04
	Light Commercial Truck	-	-	0.03	0.12	0.79	0.02	0.01	-	0.04
	Heavy Truck	-	-	-	-	0.02	0.95	-	-	0.03
	Van	-	0.02	-	0.01	-	0.01	0.95	0.01	-
	Bus	-	-	-	-	-	-	0.05	0.95	-
	Background FP	0.35	0.15	0.17	0.14	0.07	0.05	0.05	0.01	-

รูปที่ 4.4 Confusion Matrix ของการจำแนกประเภทยานพาหนะกับรูปภาพยานพาหนะ
(Testing Dataset)

4.3 ผลการประเมินประสิทธิภาพโมเดลการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

ผลการประเมินประสิทธิภาพการใช้งานโมเดลในการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะที่วิ่งบนกรอบพื้นที่ที่สนใจ (เฉพาะยานพาหนะที่วิ่งบนช่องจราจร) กับข้อมูลสำรวจจราจรทั้งหมด 153 เทียบจาก 5 ช่วงถนนสำรวจสามารถแสดงผลการประเมินประสิทธิภาพได้ดังนี้

4.3.1 ประสิทธิภาพด้านความเร็วประมวลผล

ผลการประเมินประสิทธิภาพด้านความเร็วของโมเดลที่นำเสนอกับการรันบน Google Colab ดังที่ได้ออกแบบเครื่องมือที่ใช้ในงานวิจัย สามารถแบ่งออกเป็น 5 ส่วนได้แก่ โมเดลตรวจจับยานพาหนะ (Vehicle Detection Model), โมเดลติดตามยานพาหนะ (Vehicle Tracking Model), โมเดลสร้างกรอบพื้นที่ที่สนใจ (ROI Based on Lane Line Detection), โมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ (Vehicle Type and Movement Classification Model) และอื่น ๆ ได้แก่ การเก็บและแปลงข้อมูลภาพเพื่อใช้กับโมเดลต่าง ๆ , การแสดงผลข้อมูลบนภาพ, การบันทึกวิดีโอ เป็นต้น แสดงผลดังตารางที่ 4.7 พบว่า โมเดลที่นำเสนอโดยรวมมีความเร็วในการประมวลผลเฉลี่ยในแต่ละรอบสำรวจเท่ากับ 57.55 ms/frame หรือ 17.38 FPS

ตารางที่ 4.7 ประสิทธิภาพด้านความเร็วประมวลผลเฉลี่ยของโมเดลที่นำเสนอ

No.	Model	Average Processing Time (ms/frame)
1	Vehicle Detection Model	12.84
2	Vehicle Tracking Model	15.78
3	ROI Based on Lane Line Detection	12.53
4	Vehicle Type and Movement Classification Model	0.34
5	Other	16.06
Total		57.55
Frame Rate Per Second (FPS)		17.38

4.3.2 ประสิทธิภาพของการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ

ผลการประเมินประสิทธิภาพการใช้งานโมเดลในการจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะที่วิ่งบนกรอบพื้นที่ที่สนใจ (เฉพาะยานพาหนะที่วิ่งบนช่องจราจร) กับข้อมูลสำรวจจราจรสามารถแบ่งออกเป็น 5 ส่วนได้แก่ (1) การจำแนกรถทิศทางตรงข้าม (Opposing Vehicle Classification), (2) การจำแนกรถที่ถูกรถสำรวจแซง (Passed Vehicle Classification), (3) การจำแนกรถที่แซงรถสำรวจ (Overtaking Vehicle Classification), (4) การจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ (On-left/right shoulder Vehicle Classification) และ (5) การจำแนกประเภทยานพาหนะทั้ง 8 ประเภท โดยแสดงผลการประเมินและการอภิปรายผลลัพธ์ได้ดังนี้

4.3.2.1 การจำแนกรถทิศทางตรงข้าม (Opposing Vehicle Classification)

ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะของรถทิศทางตรงข้าม (Opposing Vehicle) เมื่อใช้กับข้อมูลสำรวจจราจรมีจำนวนเหตุการณ์ที่เกิดขึ้นทั้งหมด 6,142 เหตุการณ์ ซึ่งมีการประเมินประสิทธิภาพด้าน Precision, Recall, F1-score และ Accuracy ในรูปแบบรวมและแยกรายประเภทยานพาหนะได้ดังตารางที่ 4.8 และรูปแบบรายจุดสำรวจได้ดังตารางที่ 4.9

ตารางที่ 4.8 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
– รถทิศทางตรงข้าม (แบบรายประเภทยานพาหนะ)

Opposing Vehicle Classification	Number of Events				Precision (%)	Recall (%)	F1-score (%)	Accuracy (%)
	TP	FP1	FP2	FN				
Motorcycle	567	0	282	98	66.78	85.26	74.90	59.87
Car	1195	64	16	25	93.73	97.95	95.79	91.92
SUV	509	49	11	26	89.46	95.14	92.21	85.55
Light Truck	1540	41	22	41	96.07	97.41	96.73	93.67
Light Commercial Truck	641	31	9	16	94.13	97.56	95.81	91.97
Heavy Truck	505	6	13	17	96.37	96.74	96.56	93.35
Van	364	0	0	10	100	97.33	98.64	97.33
Bus	44	0	0	0	100	100	100	100
Total	5365	191	353	233	90.79	95.84	93.25	87.35

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทางและอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้

ตารางที่ 4.9 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
- รถทิศทางตรงข้าม (แบบรายจุดสำรวจ)

Opposing Vehicle Classification											
Location	Direction	Period	TP	FP	FN	Precision	Recall	F1-score	Accuracy		
A	W-E	Off-Peak	170	5	14	9	89.95	94.97	92.39	85.86	
	W-E	Peak	363	8	50	14	86.22	96.29	90.98	83.45	
	Total W-E		533	13	64	23	87.38	95.86	91.42	84.20	
	E-W	Off-Peak	174	3	7	8	94.57	95.60	95.08	90.63	
	E-W	Peak	256	10	24	16	88.28	94.12	91.10	83.66	
Total E-W		430	13	31	24	90.72	94.71	92.67	86.35		
B	W-E	Off-Peak	164	9	2	6	93.71	96.47	95.07	90.61	
	W-E	Peak	166	13	12	11	86.91	93.79	90.22	82.18	
	Total W-E		330	22	14	17	90.16	95.10	92.57	86.16	
	E-W	Off-Peak	145	2	2	4	97.32	97.32	97.32	94.77	
	E-W	Peak	132	5	7	10	91.67	92.96	92.31	85.71	
Total E-W		277	7	9	14	94.54	95.19	94.86	90.23		
C	W-E	Off-Peak	231	9	38	1	83.09	99.57	90.59	82.80	
	W-E	Peak	255	19	52	0	78.22	100	87.78	78.22	
	Total W-E		486	28	90	1	80.46	99.79	89.09	80.33	
	E-W	Off-Peak	182	12	13	2	87.92	98.91	93.09	87.08	
	E-W	Peak	267	12	27	6	87.25	97.80	92.23	85.58	
Total E-W		449	24	40	8	87.52	98.25	92.58	86.18		

ตารางที่ 4.9 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ
– รถทิศทางตรงข้าม (แบบรายจุดสำรวจ) (ต่อ)

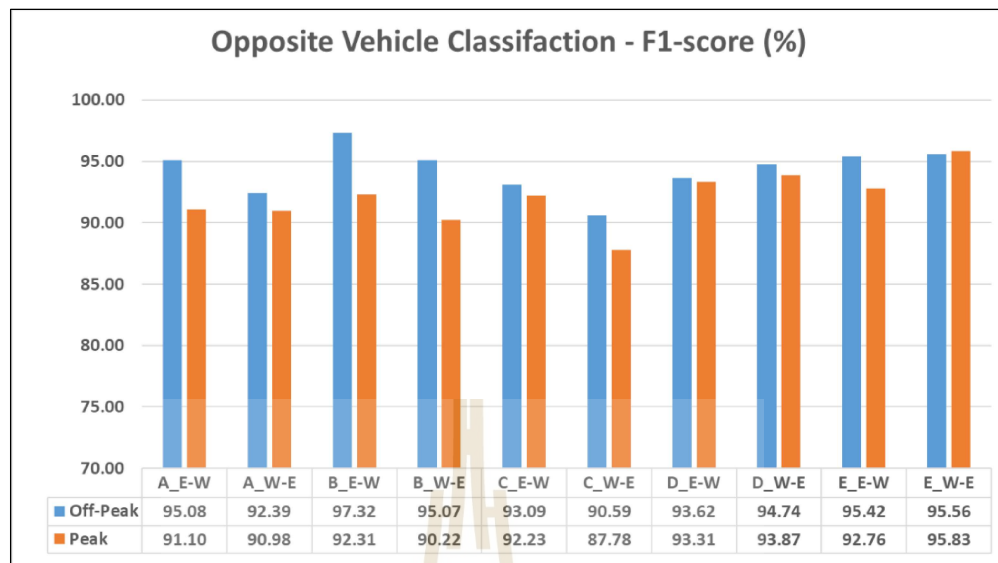
Opposing Vehicle Classification											
Location	Direction	Period	TP	FP	FP	FN	Precision	Recall	F1-score	Accuracy	
D	W-E	Off-Peak	207	8	2	13	95.39	94.09	94.74	90.00	
	W-E	Peak	398	9	20	23	93.21	94.54	93.87	88.44	
	Total W-E		605	17	22	36	93.94	94.38	94.16	88.97	
	E-W	Off-Peak	176	11	5	8	91.67	95.65	93.62	88.00	
	E-W	Peak	265	10	16	12	91.07	95.67	93.31	87.46	
	Total E-W		441	21	21	20	91.30	95.66	93.43	87.67	
E	W-E	Off-Peak	355	6	10	17	95.69	95.43	95.56	91.49	
	W-E	Peak	574	12	7	31	96.80	94.88	95.83	91.99	
	Total W-E		929	18	17	48	96.37	95.09	95.72	91.80	
	E-W	Off-Peak	385	11	17	9	93.22	97.72	95.42	91.23	
	E-W	Peak	500	17	28	33	91.74	93.81	92.76	86.51	
	Total E-W		885	28	45	42	92.38	95.47	93.90	88.50	
Total			5365	191	353	233	90.79	95.84	93.25	87.35	

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทางและอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้



รูปที่ 4.5 ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
– รถทิศทางตรงข้าม (แบบรายจุดสำรวจ)

จากผลการประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะของรถทิศทางตรงข้าม (Opposing Vehicle Classification) พบว่า โมเดลมีประสิทธิภาพจำแนกโดยรวม (F1-score) เท่ากับ 93.25% โดยผลการประเมินประสิทธิภาพรายประเภทยานพาหนะดังตารางที่ 4.8 พบว่า อันดับที่ 1 เป็นยานพาหนะประเภท Bus มีค่า F1-score เท่ากับ 100% และอันดับที่ 2 เป็นยานพาหนะประเภท Van ที่มีค่า F1-score เท่ากับ 97.33% ซึ่งยานพาหนะที่มีค่า F1-score น้อยที่สุดคือ Motorcycle ที่มีค่า F1-score เพียง 58.75 % ซึ่งความผิดพลาดที่เกิดขึ้นส่วนใหญ่นั้นมาจากความผิดพลาดของโมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อนับและจำแนกยานพาหนะเฉพาะที่วิ่งบนช่องจราจรที่นับยานพาหนะบนไหล่ทางขวาเป็นรถทิศทางตรงข้าม เนื่องจากขอบเขตของกรอบพื้นที่ที่คลาดเคลื่อนทำให้มีการนับยานพาหนะขาดและเกินกับข้อมูลจริง ซึ่งจะอภิปรายเพิ่มเติมในหัวข้อ 4.3.2.4 และรองลงมาเป็นการจำแนกประเภทยานพาหนะผิด


ผลการประเมินประสิทธิภาพรายจุดสำรวจดังตารางที่ 4.9 และรูปที่ 4.5 พบว่า ประสิทธิภาพโดยรวม (F1-score) ของแต่ละจุดสำรวจอยู่ในช่วง 87.78–97.32 % ซึ่งในช่วงเร่งด่วนมีค่า F1-score มีน้อยกว่าช่วงไม่เร่งด่วนเป็นส่วนใหญ่ โดยจุด E ทิศทาง W-E ช่วงเร่งด่วนมีค่า F1-score สูงที่สุดเท่ากับ 95.83% และจุด C ทิศทาง W-E ช่วงเร่งด่วนมีค่า F1-score ต่ำสุดเท่ากับ

87.78% ซึ่งความผิดพลาดส่วนใหญ่ที่เกิดขึ้นมาจากจำแนกยานพาหนะบนไหล่ทางขวาออกจากการคำนวณ

เหตุการณ์ทั้งหมด 6,142 เหตุการณ์แบ่งออกเป็น 5,365 เหตุการณ์ที่ต้องตามวัตถุประสงค์ และเหตุการณ์ที่ผิดพลาด 777 เหตุการณ์ (FP1+FP2+FN) ซึ่งมีสาเหตุจาก

1) FP1 (False Positive Case 1) มี 191 เหตุการณ์ (24.6%) ซึ่งเป็นเหตุการณ์ที่โมเดลจำแนกประเภทยานพาหนะผิดพลาดซึ่งจะอภิปรายผลในหัวข้อ 4.3.2.5

2) FP2 (False Positive Case 2) มี 353 เหตุการณ์ (45.4%) ซึ่งเป็นเหตุการณ์ที่โมเดลนับยานพาหนะที่ไม่ได้อยู่บนช่องจราจรที่สนใจเป็นรถทิศทางตรงข้าม โดยแบ่งเป็น 89.2% เป็นเหตุการณ์นับรถบนไหล่ทางขวาเป็นรถทิศทางตรงข้ามซึ่งมีสาเหตุจากการจำแนกรถบนไหล่ทางขวาออกจากการคำนวณ (On-Right Shoulder Vehicle Classification) โดยใช้โมเดลการสร้างกรอบพื้นที่ที่สนใจเพื่อนับยานพาหนะบนช่องจราจรที่มีประสิทธิภาพความแม่นยำเพียง 80.78% ซึ่งความผิดพลาดของโมเดลทำให้เส้นกรอบด้านขวามีความคลาดเคลื่อนเกินขอบเขตช่องจราจรที่สนใจดังตัวอย่างในรูปที่ 4.6 ทำให้การจำแนกรถบนไหล่ทางขวาโดยเฉพาะรถจักรยานยนต์หรือประเภท Motorcycle ที่มีสัดส่วนความผิดพลาดสูงมากที่สุด และ 10.8% เป็นเหตุการณ์นับยานพาหนะซ้ำ, นับรถบนไหล่ทางตอนที่รถกำลังแซงรถคันข้างหน้า และนับรถที่รอเลี้ยวขวา




รูปที่ 4.6 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ E) กรอบพื้นที่ในขนาดที่เกินจากขอบเขตช่องจราจรที่สนใจ

3) FN (False Negative) มี 233 เหตุการณ์ (30.0%) ซึ่งเป็นความผิดพลาดที่โมเดลไม่สามารถนับยานพาหนะได้ โดยแบ่งเป็น 44.2% เป็นเหตุการณ์ที่โมเดลสร้างกรอบพื้นที่ช่องจราจรที่สร้างขึ้นเกิดความคลาดเคลื่อนจากตำแหน่งที่เหมาะสม (กรอบพื้นที่เล็กหรือผิดปกติจากขอบเขตช่องจราจรที่สนใจดังตัวอย่างในรูปที่ 4.7 ทำให้ไม่สามารถนับและจำแนกรถได้โดยเฉพาะรถประเภท Motorcycle ในไหล่ทางขวาที่มีความผิดพลาดสูงมากที่สุด และ 37.3% เป็นเหตุการณ์ไอดีของยานพาหนะขาดหายหรือเปลี่ยนแปลงไอดีแบบฉับพลันจากการติดตามการเคลื่อนที่ของยานพาหนะแต่ละคันดังรูปที่ 4.8 และ 8.2% เป็นเหตุการณ์รถหายตอนเบี่ยงซ้ายเพื่อให้แซงรถสำรวจทำให้โมเดลไม่สามารถสร้างกรอบพื้นที่ครอบคลุมทั้ง 2 ช่องจราจรได้ทั้งหมด และอื่น ๆ เช่น รถโดนบดบังโดยรถคันอื่น รถไม่ชนกับ Counting Line เป็นต้น



รูปที่ 4.7 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
F) กรอบพื้นที่คลาดเคลื่อนจากขอบเขตช่องจราจรที่สนใจ



รูปที่ 4.8 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ G) เหตุการณ์การติดตามไอดีของยานพาหนะผิดพลาดทำให้โมเดลเกิดการนับซ้ำหรือไม่นับยานพาหนะที่วิ่งผ่านเส้น Counting Line

มหาวิทยาลัยเทคโนโลยีสุรนารี

4.3.2.2 การจำแนกรถที่ถูกรถสำรวจแขง (Passed Vehicle Classification)

ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะของรถที่ถูกรถสำรวจแขง (Passed Vehicle) กับข้อมูลสำรวจจราจรมีจำนวนเหตุการณ์ที่เกิดขึ้นทั้งหมด 44 เหตุการณ์ ซึ่งมีการประเมินประสิทธิภาพด้าน Precision, Recall, F1-score และ Accuracy ในรูปแบบรวมและแยกรายประเภทยานพาหนะดังตารางที่ 4.10 และรูปแบบรายจุดสำรวจดังตารางที่ 4.11

ตารางที่ 4.10 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะ – รถที่ถูกรถสำรวจแขง (แบบรายประเภทยานพาหนะ)

Passed Vehicle Classification	Number of Events				Precision (%)	Recall (%)	F1-score (%)	Accuracy (%)
	TP	FP1	FP2	FN				
Motorcycle	4	1	11	0	25.00	100	40.00	25.00
Car	0	0	0	0	-	-	-	-
SUV	0	0	0	0	-	-	-	-
Light Truck	5	0	0	0	100	100	100	100
Light Commercial Truck	3	0	0	0	100	100	100	100
Heavy Truck	7	0	2	5	77.78	58.33	66.67	50.00
Van	2	0	2	0	50.00	100	66.67	50.00
Bus	0	0	0	2	-	0.00	-	0.00
Total	21	1	15	7	56.76	75.00	64.62	47.73

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทางและอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้

ตารางที่ 4.11 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
ยานพาหนะ - รถที่ถูกตรวจสอบแซง (แบบรายจุดสำรวจ)

Passed Vehicle Classification										
Location	Direction	Period	TP	FP	FP	FN	Precision	Recall	F1-score	Accuracy
A	W-E	Off-Peak	0	1	0	0	0.00	-	-	0.00
	W-E	Peak	3	0	0	0	100	100	100	100
	Total W-E		3	1	0	0	75.00	100	85.71	75.00
	E-W	Off-Peak	2	0	0	2	100	50.00	66.67	50.00
	E-W	Peak	2	0	0	0	100	100	100	100
	Total E-W		4	0	0	2	100	66.67	80.00	66.67
B	W-E	Off-Peak	1	0	1	0	50.00	100	66.67	50.00
	W-E	Peak	0	0	1	0	0.00	-	-	0.00
	Total W-E		1	0	2	0	33.33	100	50.00	33.33
	E-W	Off-Peak	1	0	0	0	100	100	100	100
	E-W	Peak	3	0	0	1	100	75.00	85.71	75.00
	Total E-W		4	0	0	1	100	80.00	88.89	80.00
C	W-E	Off-Peak	0	0	1	0	0.00	-	-	0.00
	W-E	Peak	1	0	0	0	100	100	100	100
	Total W-E		1	0	1	0	50.00	100	66.67	50.00
	E-W	Off-Peak	0	0	0	0	-	-	-	-
	E-W	Peak	0	0	0	0	-	-	-	-
	Total E-W		0	0	0	0	-	-	-	-
D	W-E	Off-Peak	0	0	0	0	-	-	-	-
	W-E	Peak	1	0	1	0	50.00	100	66.67	50.00
	Total W-E		1	0	1	0	50.00	100	66.67	50.00
	E-W	Off-Peak	0	0	0	0	-	-	-	-
	E-W	Peak	0	0	0	0	-	-	-	-
	Total E-W		0	0	0	0	-	-	-	-

ตารางที่ 4.11 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
ยานพาหนะ – รถที่ถูกตรวจสอบแข่ง (แบบรายจุดสำรวจ) (ต่อ)


Passed Vehicle Classification											
Location	Direction	Period	TP	FP	FP	FN	Precision	Recall	F1-score	Accuracy	
E	W-E	Off-Peak	3	0	1	0	75.00	100	85.71	75.00	
	W-E	Peak	1	0	3	0	25.00	100	40.00	25.00	
	Total W-E		4	0	4	0	50.00	100	66.67	50.00	
	E-W	Off-Peak	2	0	1	2	66.67	50.00	57.14	40.00	
	E-W	Peak	1	0	6	2	14.29	33.33	20.00	11.11	
	Total E-W		3	0	7	4	30.00	42.86	35.29	21.43	
Total			21	1	15	7	56.76	75.00	64.62	47.73	

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภท
ยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง
แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทาง
และอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้



รูปที่ 4.9 ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
– รถที่ถูกรถสำรวจแขง (แบบรายจุดสำรวจ)

จากผลการประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ยานพาหนะของรถที่ถูกรถสำรวจแขง (Passed Vehicle Classification) พบว่า มีประสิทธิภาพโดยรวม (F1-score) เท่ากับ 64.62% โดยเมื่อประเมินประสิทธิภาพรายประเภทยานพาหนะตารางที่ 4.10 พบว่า ยานพาหนะประเภท Light Truck และ Light Commercial Truck มีค่า F1-score ที่ 100% แต่ยานพาหนะประเภท Bus มีค่า Recall เท่ากับ 0 ซึ่งหมายความว่า โมเดลไม่สามารถจำแนกเหตุการณ์แขงยานพาหนะประเภท Bus ทั้ง 2 เหตุการณ์ได้


ผลประเมินประสิทธิภาพรายจุดสำรวจดังตารางที่ 4.11 และรูปที่ 4.9 พบว่า บางจุดสำรวจไม่มีเหตุการณ์ที่รถถูกรถสำรวจแขง โดยจุดเกิดเหตุการณ์มีค่า F1-score อยู่ในช่วง 0–100% หมายความว่า มีจุดที่ไม่สามารถจำแนกรถที่รถสำรวจแขงได้ คือ จุด C ทิศทาง W-E และจุด B ทิศทาง W-E ซึ่งเกิดจากความผิดพลาดของการจำแนกรถบนไหล่ทางซ้าย ทำให้โมเดลนับรถที่วิ่งบนไหล่ทางเป็นรถที่ถูกรถสำรวจแขง ซึ่งค่า F1-score เท่ากับ 0% นั้นไม่อาจสามารถบ่งบอกถึงประสิทธิภาพการจำแนกรายจุดสำรวจเพราะบางจุดสำรวจมีเหตุการณ์ที่เกิดขึ้นเพียง 1 ครั้ง

เหตุการณ์ทั้งหมด 44 เหตุการณ์แบ่งออกเป็น 21 เหตุการณ์ที่ถูกต้องตามวัตถุประสงค์ และเหตุการณ์ที่ผิดพลาด 23 เหตุการณ์ (FP1+FP2+FN) มีสาเหตุจาก


1) FP1 (False Positive Case 1) มี 1 เหตุการณ์ (4.4%) ซึ่งเป็นการจำแนกประเภทยานพาหนะผิดพลาด

2) FP2 (False Positive Case 2) มี 15 เหตุการณ์ (65.2%) ซึ่งเป็นการนับรถบนไหล่ทางซ้ายเป็นรถสำรวจแสง โดยเป็นแบ่ง 86.7% เป็นข้อผิดพลาดของโมเดลสร้างเส้นรอบพื้นที่ทางซ้ายที่ปรับแต่งรอบพื้นที่ให้สอดคล้องกับเส้นไหล่ทางซ้ายจริงเพื่อจำแนกรถไหล่ทางซ้ายออกจากการคำนวณ (On-Left Shoulder Vehicle Classification) ซึ่งจากการวัดประสิทธิภาพของการจำแนกรถไหล่ทางซ้ายออกจากการคำนวณดังกล่าวข้อ 4.3.2.4 พบว่า มีความแม่นยำเท่ากับ 96.64% แต่จำนวนความผิดพลาดที่เกิดขึ้นบวกกับจำนวนเหตุการณ์ที่รถสำรวจแสงรถที่วิ่งบนถนนที่น้อยจึงทำให้ค่าความแม่นยำที่วัดได้นั้นต่ำมาก การที่โมเดลไม่สามารถตรวจจับเส้นสีไหล่ทางซ้ายและการที่รอบพื้นที่มีรูปแบบเป็นกรอบสี่เหลี่ยมเส้นตรงซึ่งไม่สอดคล้องกับช่องจราจรบริเวณบริเวณทางโค้ง ทำให้นับรถบนไหล่ทางซ้ายในช่วงทางตรงและช่วงทางโค้งเป็นรถที่ถูกรถสำรวจแสงตัวอย่างในรูปที่ 4.10 บวกกับเงื่อนไขในการจำแนกรถที่รถสำรวจแสงที่มีการใช้เหตุการณ์ที่ยานพาหนะที่จะถูกรถสำรวจแสงวิ่งทับเส้นกรอบทางซ้ายมือการตรวจจับนั้นยังมีประสิทธิภาพต่ำซึ่งไม่ครอบคลุมในทุกเหตุการณ์โดยเฉพาะการจำแนกรถที่วิ่งทับเส้นจราจรไหล่ทางซ้ายดังตัวอย่างผลลัพธ์ในรูปที่ 4.11 และ 13.3% เป็นการนับซ้ำซ้อนและนับรถเลี้ยวซ้ายเป็นรถที่ถูกรถสำรวจแสง


3) FN (False Negative) มี 7 เหตุการณ์ (30.4%) ที่โมเดลไม่สามารถนับยานพาหนะได้ โดยแบ่งเป็น 42.9% เหตุการณ์รถสำรวจแสงรถขนาดใหญ่ที่วิ่งทับเส้นไหล่ทางซ้าย, 28.6% การแสงจากระยะไกล และ 28.6% เป็นการเปลี่ยนแปลงไอดีแบบฉับพลัน เป็นต้น แสดงให้เห็นว่ารอบพื้นที่ที่สร้างขึ้นและเงื่อนไขในการจำแนกรถที่รถสำรวจแสงที่มีการใช้เหตุการณ์ที่ยานพาหนะที่จะถูกรถสำรวจแสงวิ่งทับเส้นกรอบทางซ้ายมือในการตรวจจับนั้นมีประสิทธิภาพต่ำซึ่งไม่ครอบคลุมในทุกเหตุการณ์โดยเฉพาะการจำแนกรถที่วิ่งทับเส้นไหล่ทางซ้ายดังตัวอย่างรูปที่ 4.12



รูปที่ 4.10 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ H) กรอบพื้นที่ไม่สอดคล้องกับช่องจราจรทำให้จำแนกรถบนไหล่ทางซ้ายเป็นรถที่ถูกรถสำรวจแซงบริเวณตรงและทางโค้ง



รูปที่ 4.11 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
 1) รถจักรยานยนต์วิ่งทับเส้นไหล่ทางซ้ายทำให้โมเดลจำแนกเป็นรถที่ถูกรถสำรวจแซง



รูปที่ 4.12 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
 J) โมเดลไม่สามารถตรวจจับเหตุการณ์แซงรถบรรทุกที่วิ่งทับเส้นจราจรไหล่ทางซ้ายได้

4.3.2.3 การจำแนกรถที่แซงรถสำรวจ (Overtaking Vehicle Classification)

ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะของรถที่แซงรถสำรวจ (Overtaking Vehicle) กับข้อมูลสำรวจจราจร โดยมีจำนวนเหตุการณ์ที่เกิดขึ้นทั้งหมด 101 เหตุการณ์ ซึ่งมีการประเมินประสิทธิภาพด้าน Precision, Recall, F1-score และ Accuracy สามารถแสดงในรูปแบบรายประเภทยานพาหนะได้ดังตารางที่ 4.12 และรูปแบบรายจุดสำรวจได้ดังตารางที่ 4.13

ตารางที่ 4.12 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
ยานพาหนะ – รถที่แซงรถสำรวจ (แบบรายประเภทยานพาหนะ)

Overtaking Vehicle	Number of Events				Precision (%)	Recall (%)	F1-score (%)	Accuracy (%)
	TP	FP1	FP2	FN				
Motorcycle	9	0	0	0	100	100	100	100
Car	16	1	0	0	94.12	100	96.97	94.12
SUV	12	7	0	0	63.16	100	77.42	63.16
Light Truck	35	1	0	0	97.22	100	98.59	97.22
Light Commercial Truck	14	1	0	0	93.33	100	96.55	93.33
Heavy Truck	2	0	0	0	100	100	100	100
Van	2	0	0	0	100	100	100	100
Bus	1	0	0	0	100	100	100	100
Total	91	10	0	0	90.10	100	94.79	90.10

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทางและอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้


ตารางที่ 4.13 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
ยานพาหนะ – รถที่แซงรถสำรวจ (แบบรายจุดสำรวจ)

Overtaking Vehicle Classification											
Location	Direction	Period	TP	FP	FP	FN	Precision	Recall	F1-score	Accuracy	
A	W-E	Off-Peak	10	3	0	0	76.92	100	86.96	76.92	
	W-E	Peak	6	0	0	0	100	100	100	100	
	Total W-E			16	3	0	0	84.21	100	91.43	84.21
	E-W	Off-Peak	3	0	0	0	100	100	100	100	
	E-W	Peak	10	2	0	0	83.33	100	90.91	83.33	
	Total E-W			13	2	0	0	86.67	100	92.86	86.67

ตารางที่ 4.13 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่
ยานพาหนะ - รถที่แซงรถสำรวจ (แบบรายจุดสำรวจ) (ต่อ)

Overtaking Vehicle Classification										
Location	Direction	Period	TP	FP	FN	Precision	Recall	F1-score	Accuracy	
B	W-E	Off-Peak	3	0	0	100	100	100	100	
	W-E	Peak	1	0	0	100	100	100	100	
	Total W-E		4	0	0	100	100	100	100	
	E-W	Off-Peak	4	0	0	100	100	100	100	
	E-W	Peak	7	0	0	100	100	100	100	
	Total E-W		11	0	0	100	100	100	100	
C	W-E	Off-Peak	3	0	0	100	100	100	100	
	W-E	Peak	1	0	0	100	100	100	100	
	Total W-E		4	0	0	100	100	100	100	
	E-W	Off-Peak	6	1	0	85.71	100	92.31	85.71	
	E-W	Peak	4	0	0	100	100	100	100	
	Total E-W		10	1	0	90.91	100	95.24	90.91	
D	W-E	Off-Peak	10	1	0	90.91	100	95.24	90.91	
	W-E	Peak	6	1	0	85.71	100	92.31	85.71	
	Total W-E		16	2	0	88.89	100	94.12	88.89	
	E-W	Off-Peak	5	0	0	100	100	100	100	
	E-W	Peak	8	1	0	88.89	100	94.12	88.89	
	Total E-W		13	1	0	92.86	100	96.30	92.86	
E	W-E	Off-Peak	0	1	0	0.00	-	-	0.00	
	W-E	Peak	1	0	0	100	100	100	100	
	Total W-E		1	1	0	50.00	100	66.67	50.00	
	E-W	Off-Peak	2	0	0	100	100	100	100	
	E-W	Peak	1	0	0	100	100	100	100	
	Total E-W		3	0	0	100	100	100	100	
Total			91	10	0	90.10	100	94.79	90.10	

- หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง
- 2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด
- 3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทางและอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง
- 4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้



รูปที่ 4.13 ผลการเปรียบเทียบค่า F1-score ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ - รถที่แซงรถสำรวจ (แบบรายจุดสำรวจ)

จากผลการประเมินประสิทธิภาพของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ที่ยานพาหนะของรถที่แซงรถสำรวจ (Overtaking Vehicle Classification) พบว่า มีประสิทธิภาพโดยรวม (F1-score) เท่ากับ 94.79% และมีค่า Recall เท่ากับ 100% ซึ่งหมายความว่า โมเดลสามารถตรวจจับและนับเหตุการณ์การแซงรถสำรวจได้ทั้งหมด โดยเมื่อประเมินประสิทธิภาพรายประเภทยานพาหนะตารางที่ 4.12 พบว่า ยานพาหนะประเภท SUV มีค่า F1-score น้อยที่สุด เท่ากับ 77.47% ซึ่งความผิดพลาดทั้งหมดเกิดจากการจำแนกประเภทยานพาหนะที่ผิดประเภท และ

เมื่อประเมินประสิทธิภาพรายจุดสำรวจดัง ตารางที่ 4.13 และรูปที่ 4.13 พบว่า มีค่า F1-score อยู่ใน ช่วง 86.95–100% โดยจุดสำรวจ A มีค่า F1-score น้อยที่สุดที่ 86.96% ซึ่งความผิดพลาดเกิดจากการจำแนกประเภทยานพาหนะที่ผิด

เหตุการณ์ทั้งหมด 101 เหตุการณ์แบ่งออกเป็น 91 เหตุการณ์ที่ถูกต้องตาม วัตถุประสงค์ และเหตุการณ์ที่ผิดพลาด 10 เหตุการณ์ (FP1+FP2+FN) ที่เกิดจากการจำแนกประเภท ยานพาหนะผิดประเภทซึ่งจะอภิปรายผลในหัวข้อ 4.3.2.5

4.3.2.4 การจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ (On-Left/Right Shoulder Vehicle Classification)

การประเมินประสิทธิภาพการจำแนกยานพาหนะบนไหล่ทางออกจากการ คำนวณเพื่อให้เห็นถึงประสิทธิภาพของโมเดลสร้างกรอบพื้นที่จำแนกเฉพาะพื้นที่ที่สนใจ (เฉพาะ ยานพาหนะที่วิ่งบนช่องจราจร) มีการเก็บข้อมูล 2 ประเภทคือ (1) True Positive (TP) หมายถึง โมเดลไม่ทำการนับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ (ไม่นับเป็นรถทิศทางตรงข้าม/รถที่ถูกรถ สสำรวจแซง/รถที่แซงรถสำรวจ) และ (2) False Positive Case 2 (FP2) หมายถึง ความผิดพลาดที่ โมเดลทำการนับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ โดยความผิดพลาดเหล่านี้จะส่งผลต่อ จำนวนรถในทิศทางตรงข้าม รถที่ถูกรถสำรวจแซงและรถที่แซงรถสำรวจที่เกินจากความเป็นจริงซึ่งทำ ให้การประมาณค่าตัวแปรกระแสจราจรเกิดความคลาดเคลื่อนขึ้น

ตารางที่ 4.14 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ
(แบบรายประเภทยานพาหนะ)

Classification Model	Number of Events				Precision (%)	Recall (%)	F1-score (%)	Accuracy (%)
	TP	FP1	FP2	FN				
On-Left Shoulder Vehicle Classification	374	-	13	-	96.64	-	-	96.64
Non-Motorcycle	189	-	3	-	98.44	-	-	98.44
Motorcycle	185	-	10	-	94.87	-	-	94.87
On-Right Shoulder Vehicle Classification	1374	-	327	-	80.78	-	-	80.78
Non-Motorcycle	158	-	50	-	75.96	-	-	75.96
Motorcycle	1216	-	277	-	81.45	-	-	81.45

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่โมเดลไม่นับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ

2) FP2 (False Positive Case 2) คือ เหตุการณ์ที่โมเดลนับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ

ตารางที่ 4.15 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ
- ยานพาหนะไหล่ทางซ้าย (แบบรายจุดสำรวจ)


On-Left Shoulder Vehicle Classification							
Location	Direction	Period	TP	FP2	Precision (%)	Accuracy (%)	
A	W-E	Off-Peak	9	0	100	100	
	W-E	Peak	17	0	100	100	
	Total W-E			26	0	100	100
	E-W	Off-Peak	12	0	100	100	
	E-W	Peak	21	0	100	100	
	Total E-W			33	0	100	100

ตารางที่ 4.15 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ
- ยานพาหนะไหล่ทางซ้าย (แบบรายจุดสำรวจ) (ต่อ)

On-Left Shoulder Vehicle Classification						
Location	Direction	Period	TP	FP2	Precision (%)	Accuracy (%)
B	W-E	Off-Peak	5	0	100	100
	W-E	Peak	21	1	95.45	95.45
	Total W-E		26	1	96.30	96.30
	E-W	Off-Peak	7	0	100	100
	E-W	Peak	24	0	100	100
	Total E-W		31	0	100	100
C	W-E	Off-Peak	8	1	88.89	88.89
	W-E	Peak	10	0	100	100
	Total W-E		18	1	94.74	94.74
	E-W	Off-Peak	9	0	100	100
	E-W	Peak	6	0	100	100
Total E-W		15	0	100	100	
D	W-E	Off-Peak	12	0	100	100
	W-E	Peak	10	1	90.91	90.91
	Total W-E		22	1	95.65	95.65
	E-W	Off-Peak	5	0	100	100
	E-W	Peak	9	0	100	100
Total E-W		14	0	100	100	
E	W-E	Off-Peak	34	1	97.14	97.14
	W-E	Peak	40	2	95.24	95.24
	Total W-E		74	3	96.10	96.10
	E-W	Off-Peak	54	1	98.18	98.18
	E-W	Peak	61	6	91.04	91.04
Total E-W		115	7	94.26	94.26	
Total			374	13	96.64	96.64

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่โมเดลไม่นับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ

2) FP2 (False Positive Case 2) คือ เหตุการณ์ที่โมเดลนับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ




รูปที่ 4.14 ผลการเปรียบเทียบค่าความแม่นยำของโมเดลจำแนกรถบนไหล่ทางซ้ายออกจากการคำนวณรายจุดสำรวจ

โดยผลการประเมินประสิทธิภาพแบบรายประเภทยานพาหนะของการจำแนกรถบนไหล่ทางซ้ายและขวาออกจากการคำนวณแสดงดังตารางที่ 4.14 พบว่า

การจำแนกยานพาหนะบนไหล่ทางซ้าย (On-Left Shoulder Vehicle Classification) มีความแม่นยำ (Precision) โดยรวมเท่ากับ 96.64 โดยยานพาหนะประเภทที่ไม่ใช่รถจักรยานยนต์ (Non-Motorcycle) เช่น รถประเภท Car, SUV และ Light Truck มีความแม่นยำที่ 98.44% และประเภท Motorcycle มีความแม่นยำ 94.87% ซึ่งข้อผิดพลาดที่เกิดจากโมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อนับและจำแนกยานพาหนะเฉพาะที่วิ่งบนช่องจราจรเกิดความผิดพลาดทำให้มีการนับรถบนไหล่ทางเข้าสู่การคำนวณ ซึ่งมีสาเหตุจาก (1) อัลกอริทึมในการตรวจจับเส้นสีจราจรที่สร้างขึ้นนั้นมีความสามารถในการตรวจจับเส้นตรงเท่านั้น จึงไม่สามารถสร้างเส้นโค้งที่สอดคล้องกับ

เส้นไหล่ทางบริเวณทางโค้งได้ ทำให้กรอบพื้นที่เป็นกรอบพื้นที่ที่สร้างขึ้นไม่สอดคล้องกับช่องจราจร บริเวณทางโค้งเป็นเหตุให้โมเดลนักรถที่อยู่บนไหล่ทางซ้ายในช่วงทางโค้งเป็นรถที่ถูกตรวจสอบแข่งดัง ตัวอย่างในรูปที่ 4.10, (2) อัลกอริทึมตรวจจับเส้นจราจรไหล่ทางซ้ายไม่สามารถปรับแก้ให้เส้นกรอบพื้นที่สอดคล้องกับเส้นไหล่ทางซ้ายจริงได้เนื่องจากความสั่นสะเทือนทำให้กล้องวิดีโอมีตำแหน่งหรือมุมกล้องที่คลาดเคลื่อนซึ่งอาจส่งผลให้ตำแหน่งค่าตั้งต้นของกรอบพื้นที่เกิดความคลาดเคลื่อนจึงทำให้กระบวนการปรับแก้เส้นกรอบพื้นที่ไม่สามารถดำเนินการสร้างได้และใช้ตำแหน่งของกรอบพื้นที่ตั้งต้นในการจำแนกตัวอย่างรูปที่ 4.16 ที่ความสั่นสะเทือนทำให้กรอบพื้นที่ตั้งต้นคลาดเคลื่อนไปจากช่องจราจรจริงจนโมเดลไม่สามารถปรับแก้ได้และอาจทำให้เกิดเหตุการณ์ที่อัลกอริทึมตรวจจับเส้นจราจรนำเส้นขอบถนนหรือเส้นขอบวัตถุอื่น ๆ มาพิจารณาพร้อมในการสร้างเส้นกรอบพื้นที่ทางซ้ายมือ ดังตัวอย่างรูปที่ 4.15 และ (3) เงื่อนไขในการจำแนกที่ยังไม่ครอบคลุมเหตุการณ์หรือพฤติกรรมการขับขี่ทั้งหมด เช่น การที่ยานพาหนะวิ่งทับบนเส้นจราจรไหล่ทางซ้ายทำให้โมเดลระบุว่าเป็นรถที่ถูกตรวจสอบแข่งดังตัวอย่างในรูปที่ 4.11 ความผิดพลาดเหล่านี้เป็นเหตุให้เกิดการนับและจำแนกรถที่วิ่งไหล่ทางแข่งรถที่ถูกตรวจสอบแข่ง (Passed Vehicle)

ผลการประเมินประสิทธิภาพการจำแนกยานพาหนะบนไหล่ทางซ้ายแบบรายจุดสำรวจดังตารางที่ 4.15 และเปรียบเทียบความแม่นยำในแต่ละจุดสำรวจดังรูปที่ 4.14 พบว่าความแม่นยำในการจำแนกยานพาหนะบนไหล่ทางซ้าย (On-Left Shoulder Vehicle Classification) รายจุดสำรวจมีค่าระหว่าง 88.89-100% ความผิดพลาดการจำแนกยานพาหนะบนไหล่ทางซ้ายที่มากที่สุดเกิดบนจุดสำรวจ C ทิศทาง E-W ที่มีความแม่นยำต่ำที่สุดที่ 88.89% ซึ่งจุดสำรวจ C เป็นจุดสำรวจที่มีความแม่นยำในการจำแนกรถบนไหล่ทางซ้ายและขวาโดยรวมต่ำที่สุดเมื่อเทียบกับจุดสำรวจอื่น ๆ



รูปที่ 4.15 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
K) โมเดลไม่สามารถตรวจจับเส้นสีจางและปรับแก้ตำแหน่งของกรอบใหม่ได้



รูปที่ 4.16 ตัวอย่างผลลัพธ์ของโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะ
M) โมเดลสร้างกรอบพื้นที่ปรับแก้เส้นขอบถนนเป็นตัวแทนของเส้นไหล่ทางซ้าย


ตารางที่ 4.16 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ
- ยานพาหนะไหล่ทางขวา (แบบรายจุดสำรวจ)

On-Right Shoulder Vehicle Classification							
Location	Direction	Period	TP	FP	Precision (%)	Accuracy (%)	
A	W-E	Off-Peak	39	14	73.58	73.58	
	W-E	Peak	155	47	76.73	76.73	
	Total W-E			194	61	76.08	76.08
	E-W	Off-Peak	42	6	87.50	87.50	
	E-W	Peak	85	23	78.70	78.70	
	Total E-W			127	29	81.41	81.41
B	W-E	Off-Peak	35	2	94.59	94.59	
	W-E	Peak	40	10	80.00	80.00	
	Total W-E			75	12	86.21	86.21
	E-W	Off-Peak	23	0	100	100	
	E-W	Peak	51	7	87.93	87.93	
	Total E-W			74	7	91.36	91.36
C	W-E	Off-Peak	23	38	37.70	37.70	
	W-E	Peak	51	52	49.51	49.51	
	Total W-E			74	90	45.12	45.12
	E-W	Off-Peak	27	12	69.23	69.23	
	E-W	Peak	69	23	75.00	75.00	
	Total E-W			96	35	73.28	73.28
D	W-E	Off-Peak	23	2	92.00	92.00	
	W-E	Peak	103	20	83.74	83.74	
	Total W-E			126	22	85.14	85.14
	E-W	Off-Peak	16	5	76.19	76.19	
	E-W	Peak	57	15	79.17	79.17	
	Total E-W			73	20	78.49	78.49

ตารางที่ 4.16 ผลการประเมินประสิทธิภาพในการจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ
- ยานพาหนะไหล่ทางขวา (แบบรายจุดสำรวจ) (ต่อ)

On-Right Shoulder Vehicle Classification						
Location	Direction	Period	TP	FP	Precision (%)	Accuracy (%)
E	W-E	Off-Peak	87	10	89.69	89.69
	W-E	Peak	190	4	97.94	97.94
	Total W-E		277	14	95.19	95.19
	E-W	Off-Peak	86	16	84.31	84.31
	E-W	Peak	172	21	89.12	89.12
	Total E-W		258	37	87.46	87.46
Total			1374	327	80.78	80.78

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่โมเดลไม่นับยานพาหนะบนไหล่ทางเข้าสู่การ
คำนวณ
2) FP2 (False Positive Case 2) คือ เหตุการณ์ที่โมเดลนับยานพาหนะบนไหล่ทางเข้าสู่
การคำนวณ



รูปที่ 4.17 ผลการเปรียบเทียบค่าความแม่นยำของโมเดลจำแนกรถบนไหล่ทางขวาออกจากการ
คำนวณรายจุดสำรวจ

ผลการประเมินประสิทธิภาพแบบรายประเภทยานพาหนะของการจำแนกรถบนไหล่ทางซ้ายและขวาออกจากการคำนวณแสดงดังตารางที่ 4.14 พบว่า การจำแนกยานพาหนะบนไหล่ทางขวา (On-Right Shoulder Vehicle Classification) มีความแม่นยำ (Precision) โดยรวมเท่ากับ 80.78% โดยยานพาหนะประเภท Non-Motorcycle มีความแม่นยำที่ 75.96% และประเภท Motorcycle มีความแม่นยำที่ 81.45% ซึ่งข้อผิดพลาดที่เกิดขึ้นมีสาเหตุ (1) โมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อนับและจำแนกยานพาหนะเฉพาะที่วิ่งบนช่องจราจรที่มีการใช้เพียงเส้นกรอบทางซ้ายมือที่ถูกปรับแก้โดยกระบวนการตรวจจับเส้นจราจรและใช้ตำแหน่งมุมกรอบและความกว้างของช่องจราจรที่ได้กำหนดในเริ่มต้นในการสร้างกรอบพื้นที่ใหม่ให้มีขอบเขตที่ครอบคลุม 2 ช่องจราจรและสอดคล้องกับขอบเขตไหล่ทางซ้ายและขวาตลอดการสำรวจตามวัตถุประสงค์เพื่อนำไปใช้ในการจำแนกรถบนไหล่ทางขวาออกจากการคำนวณยังมีประสิทธิภาพที่ต่ำทำให้ขอบเขตของกรอบพื้นที่ที่ใช้ในการจำแนกยานพาหนะที่วิ่งเฉพาะในช่องจราจรนั้นมีขอบเขตคลาดเคลื่อนไปจากความจริงดังตัวอย่างในรูปที่ 4.6 และรูปที่ 4.7 ซึ่งทำให้เกิดการนับยานพาหนะบนไหล่ทางขวาเป็นรถทิศทางตรงข้าม (2) อัลกอริทึมตรวจจับเส้นจราจรไหล่ทางซ้ายไม่สามารถปรับแก้ให้เส้นกรอบพื้นที่สอดคล้องกับเส้นไหล่ทางซ้ายจริงได้เนื่องจากความสับสนเพื่อนำให้กล้องวิดีโอไม่มีตำแหน่งหรือมุมกล้องที่คลาดเคลื่อนซึ่งอาจส่งผลให้ตำแหน่งค่าตั้งต้นของกรอบพื้นที่เกิดความคลาดเคลื่อนจึงทำให้กระบวนการปรับแก้เส้นกรอบพื้นที่ไม่สามารถดำเนินการสร้างได้และใช้ตำแหน่งของกรอบพื้นที่ตั้งต้นในการจำแนกตัวอย่างรูปที่ 4.16 ซึ่งความผิดพลาดเหล่านี้จะส่งผลต่อการนับและจำแนกจำนวนรถทิศทางตรงข้าม (Opposing Vehicle)

ผลการประเมินประสิทธิภาพการจำแนกยานพาหนะบนไหล่ทางขวาแบบรายจุดสำรวจดังตารางที่ 4.16 และเปรียบเทียบความแม่นยำในแต่ละจุดสำรวจดังรูปที่ 4.17 พบว่าความแม่นยำในการจำแนกยานพาหนะบนไหล่ทางขวา (On-Right Shoulder Vehicle Classification) รายจุดสำรวจมีค่าระหว่าง 37.70-100% ความผิดพลาดการจำแนกยานพาหนะบนไหล่ทางขวาที่มากที่สุดเกิดบนจุดสำรวจ C ทิศทาง W-ES ที่มีความแม่นยำเพียง 37.70% ซึ่งมีสาเหตุจากโมเดลสร้างกรอบพื้นที่ที่สนใจที่มีประสิทธิภาพต่ำดังที่ได้กล่าวในขั้นต้น โดยเฉพาะการจำแนกยานพาหนะบนไหล่ทางขวาประเภท Motorcycle ที่มีจำนวนความผิดพลาดสูง

4.3.2.5 การจำแนกประเภทยานพาหนะ

เมื่อนำผลลัพธ์เฉพาะการจำแนกประเภทยานพาหนะมาสร้างตาราง Confusion Matrix เพื่อแสดงความแม่นยำและข้อผิดพลาดในการจำแนกประเภทยานพาหนะในงานวิจัย สามารถแสดงประสิทธิภาพโดยรวมได้ดังตารางที่ 4.17 และแบ่งตามมุมมองด้านหน้า

ยานพาหนะ (ทิศทางตรงข้าม) และด้านหลังกับด้านข้าง (ยานพาหนะที่แข่งและถูกรถสำรวจแข่ง) ได้
ดังตารางที่ 4.18 และตารางที่ 4.19 ตามลำดับ

ตารางที่ 4.17 Confusion Matrix ของการจำแนกประเภทยานพาหนะโดยรวม

Vehicle Type Classification (Overall) (%)		Number of Events	Predicted Class							
			Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus
Actual Class	Motorcycle	582	99.66	-	0.17	0.17	-	-	-	-
	Car	1247	-	97.11	2.41	0.48	-	-	-	-
	SUV	590	-	10.17	88.31	0.17	1.36	-	-	-
	Light Truck	1601	-	-	0.12	98.69	1.06	0.12	-	-
	Light Commercial Truck	698	0.14	-	0.43	4.87	94.27	0.29	-	-
	Heavy Truck	515	-	-	-	-	0.19	99.81	-	-
	Van	396	-	1.26	4.29	-	1.52	-	92.93	-
	Bus	50	-	-	6.00	-	-	4.00	-	90.00

ตารางที่ 4.18 Confusion Matrix ของการจำแนกประเภทยานพาหนะมุมด้านหน้า (เฉพาะรถทิศทางตรงข้าม)

Vehicle Type Classification (Opposing Vehicle) (%)		Number of Events	Predicted Class							
			Motorcycle	Car	SUV	Light Truck	Light Commercial Truck	Heavy Truck	Van	Bus
Actual Class	Motorcycle	569	99.65	-	0.18	0.18	-	-	-	-
	Car	1227	-	97.39	2.12	0.49	-	-	-	-
	SUV	577	-	10.23	88.21	0.17	1.39	-	-	-
	Light Truck	1560	-	-	0.13	98.72	1.03	0.13	-	-
	Light Commercial Truck	679	-	-	0.44	4.86	94.40	0.29	-	-
	Heavy Truck	506	-	-	-	-	0.20	99.80	-	-
	Van	389	-	1.29	3.60	-	1.54	-	93.57	-
	Bus	49	-	-	6.12	-	-	4.08	-	89.80

การจำแนกประเภทยานพาหนะ (Vehicle Type Classification) เมื่อรวมเหตุการณ์ที่โมเดลสามารถนับบนกรอบพื้นที่ที่สนใจและจำแนกประเภทยานพาหนะได้ถูกต้อง (TP: True Positive) กับจำแนกประเภทยานพาหนะผิดประเภท (FP1: False Positive Case 1) ทั้ง 3 รูปแบบการเคลื่อนที่ทั้งหมด 5,679 เหตุการณ์ดังตารางที่ 4.17 พบว่า โมเดลมีความแม่นยำในการจำแนกประเภทโดยรวมเท่ากับ 96.44% โดยที่ยานพาหนะประเภท SUV มีความแม่นยำต่ำที่สุดที่ 88.31%โดยเมื่อแยกออกเป็นการจำแนกประเภทยานพาหนะเฉพาะมุมมองด้านหน้าที่เกิดขึ้นกับการนับและจำแนกยานพาหนะในทิศทางตรงข้ามซึ่งมีเหตุการณ์ทั้งหมด 5,556 เหตุการณ์ (97.83% จากทั้งหมด) ดังตารางที่ 4.18 พบว่า ความแม่นยำในการจำแนกประเภทโดยรวมเท่ากับ 96.56% โดยการจำแนกยานพาหนะประเภท SUV มีความแม่นยำต่ำที่สุดที่ 88.21% ซึ่งการจำแนกประเภทระหว่าง SUV กับ CAR โดยเฉพาะรถ Hatchback กับ SUV และ MUV มีสัดส่วนความผิดพลาดมากที่สุดเท่ากับ 10.23% เนื่องจากมีลักษณะใกล้เคียงกันแต่แตกต่างกันที่ขนาดเมื่อมองจากมุมมองด้านหน้ารถของรถที่วิ่งในทิศทางตรงข้าม และรองลงมาเป็นประเภท Bus มีความแม่นยำที่ 89.80% เนื่องจากโมเดลจำแนกยานพาหนะประเภท SUV และ Heavy Truck เป็น Bus ซึ่งจากการสังเกตพบว่า ลักษณะของประเภท Bus เมื่อวิ่งชนเส้น Counting Line ที่มีขนาดใหญ่ ทำให้ไม่เห็นลักษณะที่ครอบคลุมทั้งหมดจึงทำให้จำแนกผิดพลาด

ตารางที่ 4.19 Confusion Matrix ของการจำแนกประเภทยานพาหนะมุมมองด้านหลังและด้านข้าง (เฉพาะรถที่แซงและถูกรถสำรวจแซง)

Vehicle Type Classification (Passed and Overtaking Vehicle) (%)		Number of Events	Predicted Class							
			Motorcycle	Car	SUV	Light Truck	Light Commercial	Heavy Truck	Van	Bus
Actual Class	Motorcycle	13	100	-	-	-	-	-	-	-
	Car	20	0	80.00	20.00	-	-	-	-	-
	SUV	13	0	7.69	92.31	-	-	-	-	-
	Light Truck	41	0	-	-	97.56	2.44	-	-	-
	Light Commercial Truck	19	5.26	-	-	5.26	89.47	-	-	-
	Heavy Truck	9	0	-	-	-	-	100	-	-
	Van	7	0	-	42.86	-	-	-	57.14	-
	Bus	1	0	-	-	-	-	-	-	100

โดยเมื่อแยกออกเป็นการจำแนกประเภทยานพาหนะเฉพาะมุมมอง ด้านหลังและด้านข้างที่เกิดขึ้นกับการนับและจำแนกยานพาหนะที่แซงและถูกรถสำรวจแซงซึ่งมี เหตุการณ์ทั้งหมด 123 เหตุการณ์ (2.17% จากทั้งหมด) แสดงดังตารางที่ 4.19 พบว่า ความแม่นยำ ในการจำแนกประเภทโดยรวมเท่ากับ 91.06% โดยยานพาหนะประเภท VAN มีความแม่นยำต่ำที่สุด ที่ 57.14% ซึ่งมีสาเหตุจากลักษณะที่คล้ายคลึงกันอาจทำให้โมเดลทำนายรถประเภท VAN เป็น SUV และรองลงมาเป็นประเภท Car มีความแม่นยำที่ 80.00% ซึ่งมีสาเหตุจากลักษณะที่คล้ายคลึงกันอาจ ทำให้โมเดลทำนายรถประเภท Car กับ SUV แต่เมื่อดูจากจำนวนเหตุการณ์ของการจำแนกจาก มุมมองด้านหลังและด้านข้างพบว่า มีจำนวนเหตุการณ์โดยเฉลี่ยเพียง 15 เหตุการณ์ต่อประเภท ยานพาหนะ โดยมีเหตุการณ์ต่ำสุดที่ 1 เหตุการณ์ในการจำแนกประเภท Bus และเหตุการณ์สูงสุด 41 เหตุการณ์ที่ในการจำแนกประเภท Light Truck ซึ่งจำนวนเหตุการณ์รายประเภทยานพาหนะที่น้อย จนเกินไปอาจทำให้ไม่สามารถสรุปถึงประสิทธิภาพในการจำแนกประเภทยานพาหนะด้านหลังและ ด้านข้างได้

4.3.2.6 สรุปผลประสิทธิภาพในการจำแนกประเภทและรูปแบบการเคลื่อนที่ของ ยานพาหนะในงานวิจัย

จากผลการประเมินประสิทธิภาพในการจำแนกประเภทและรูปแบบการ เคลื่อนที่ของยานพาหนะทั้ง 5 ส่วน ได้แก่ 1) การจำแนกรถที่ศทางตรงข้าม (Opposing Vehicle Classification), 2) การจำแนกรถที่ถูกรถสำรวจแซง (Passed Vehicle Classification), 3) การ จำแนกรถที่แซงรถสำรวจ (Overtaking Vehicle Classification), 4) การจำแนกยานพาหนะบนไหล่ ทางออกจากการคำนวณ (On-Left/Right Shoulder Vehicle Classification) และ 5) การจำแนก ประเภทยานพาหนะทั้ง 8 ประเภท สามารถสรุปผลการประสิทธิภาพโดยรวมจากเหตุการณ์ที่เกิดขึ้น ทั้งหมดได้ดังตารางที่ 4.20 และตารางที่ 4.21

ตารางที่ 4.20 ผลการประเมินประสิทธิภาพโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ ยานพาหนะโดยรวม (Vehicle Type and Movement Classification Model)

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

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจและจำแนกประเภท ยานพาหนะได้ถูกต้อง

2) FP1 (False Positive Case 1) คือ เหตุการณ์ที่นับเฉพาะยานพาหนะที่สนใจได้ถูกต้อง แต่จำแนกประเภทยานพาหนะผิด

3) FP2 (False Positive Case 2) คือ เหตุการณ์ที่นับและจำแนกยานพาหนะบนไหล่ทาง และอื่น ๆ เข้าสู่การคำนวณที่เกินความเป็นจริง

4) FN (False Negative) คือ เหตุการณ์ที่ไม่สามารถนับยานพาหนะที่สนใจได้

ตารางที่ 4.21 ผลการประเมินประสิทธิภาพโมเดลจำแนกยานพาหนะบนไหล่ทางออกจากการคำนวณ โดยรวม (On-Left/Right Shoulder Vehicle Classification)

Classification Model	Number of Events				Precision	Recall	F1-score	Accuracy
	TP	FP1	FP2	FN				
On-Left Shoulder Vehicle Classification	374	-	13	-	96.64	-	-	96.64
On-Right Shoulder Vehicle Classification	1374	-	327	-	80.78	-	-	80.78

หมายเหตุ 1) TP (True Positive) คือ เหตุการณ์ที่โมเดลไม่นับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ

2) FP2 (False Positive Case 2) คือ เหตุการณ์ที่โมเดลนับยานพาหนะบนไหล่ทางเข้าสู่การคำนวณ


4.4 ผลการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่

จากการนำข้อมูลจราจรที่สำรวจทั้ง 5 จุดทั้งช่วงไม่เร่งด่วนและช่วงเร่งด่วนไปใช้กับโมเดล จำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะที่ได้นำเสนอในงานวิจัยนี้เป็นจำนวนทั้งหมด 153 เทียบ นำมาจับคู่ตามวิธีการสำรวจ MOM ได้ทั้งหมด 143 รอบ จากนั้นนำจำนวนยานพาหนะแต่ละประเภทที่ได้ไปแปลงหน่วยรถยนต์ส่วนบุคคล (Passenger Car Unit : PCU) แล้วทำการเฉลี่ยรายจุดสำรวจ ทิศทางและช่วงเวลาเพื่อนำไปคำนวณเพื่อหาค่าตัวแปรกระแสจราจรประกอบไปด้วย อัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรในลำดับถัดไป สามารถแสดงผลประมาณค่าจำนวนยานพาหนะ 3 รูปแบบการเคลื่อนที่ตามวิธีสำรวจโดยการเคลื่อนที่ยานพาหนะ (Moving Observer Method: MOM) ทั้งจากการใช้ข้อมูลสำรวจจริงและผลการจำแนกที่ได้จากโมเดลที่นำเสนอตั้งตารางที่ 4.22 และผลเปรียบเทียบการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ระหว่างการใช้อข้อมูลสำรวจจริงกับผลที่ได้จากโมเดลตั้งรูปที่ 4.18 ถึงรูปที่ 4.20

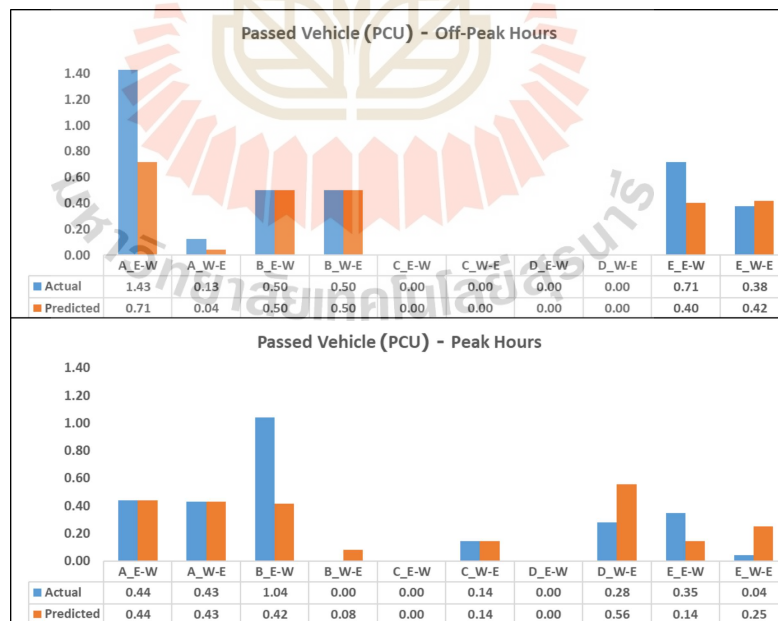


ตารางที่ 4.22 ผลการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบตามวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะ

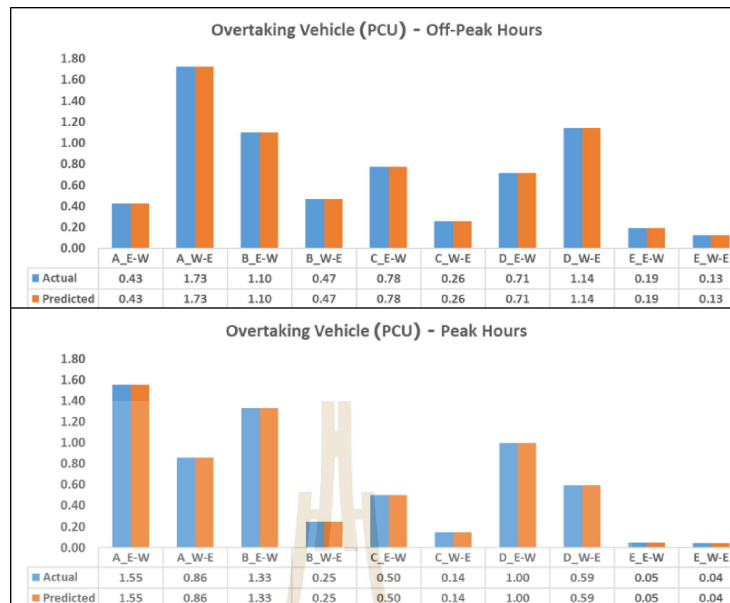
No.	Location	Direction	Period	Number of Vehicle by Movement Pattern (PCU)					
				Actual			Predicted		
				Opposing Vehicle	Passed Vehicle	Overtaking Vehicle	Opposing Vehicle	Passed Vehicle	Overtaking Vehicle
1	A	E-W	Off-Peak	26.33	1.43	0.43	25.76	0.71	0.43
2	A	E-W	Peak	50.90	0.44	1.55	51.73	0.44	1.55
3	A	W-E	Off-Peak	26.50	0.13	1.73	25.75	0.04	1.73
4	A	W-E	Peak	37.84	0.43	0.86	37.24	0.43	0.86
5	B	E-W	Off-Peak	34.83	0.50	1.10	34.47	0.50	1.10
6	B	E-W	Peak	45.91	1.04	1.33	46.71	0.42	1.33
7	B	W-E	Off-Peak	41.43	0.50	0.47	40.87	0.50	0.47
8	B	W-E	Peak	29.91	0.00	0.25	28.96	0.08	0.25
9	C	E-W	Off-Peak	28.31	0.00	0.78	30.09	0.00	0.78
10	C	E-W	Peak	33.57	0.00	0.50	36.26	0.00	0.50
11	C	W-E	Off-Peak	24.13	0.00	0.26	24.70	0.00	0.26
12	C	W-E	Peak	33.90	0.14	0.14	34.47	0.14	0.14
13	D	E-W	Off-Peak	32.81	0.00	0.71	31.62	0.00	0.71
14	D	E-W	Peak	45.30	0.00	1.00	43.94	0.00	1.00
15	D	W-E	Off-Peak	30.70	0.00	1.14	30.28	0.00	1.14
16	D	W-E	Peak	36.18	0.28	0.59	35.32	0.56	0.59
17	E	E-W	Off-Peak	55.30	0.71	0.19	55.11	0.40	0.19
18	E	E-W	Peak	75.21	0.35	0.05	74.09	0.14	0.05
19	E	W-E	Off-Peak	56.72	0.38	0.13	57.81	0.42	0.13
20	E	W-E	Peak	65.38	0.04	0.04	65.61	0.25	0.04



รูปที่ 4.18 ผลเปรียบเทียบการประมาณค่าจำนวนรถที่ตรงข้ามระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล



รูปที่ 4.19 ผลเปรียบเทียบการประมาณค่าจำนวนรถที่ถูกรถสำรวจวิ่งแซงระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล



รูปที่ 4.20 ผลเปรียบเทียบการประมาณค่าจำนวนรถที่แซงรถสำรวจระหว่างการใช้ข้อมูลจริงและผลที่ได้จากโมเดล

ตารางที่ 4.23 เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่

Absolute Percentage Error – APE (%)							
Location	Direction	Opposing Vehicle		Passed Vehicle		Overtaking Vehicle	
		Off-Peak	Peak	Off-Peak	Peak	Off-Peak	Peak
A	E-W	2.17	1.64	50.00	0.00	0.00	0.00
A	W-E	2.83	1.58	66.70	0.00	0.00	0.00
B	E-W	1.05	1.72	0.00	60.01	0.00	0.00
B	W-E	1.37	3.20	0.00	0.00	0.00	0.00
C	E-W	6.27	8.00	0.00	0.00	0.00	0.00
C	W-E	2.38	1.68	0.00	0.00	0.00	0.00

ตารางที่ 4.23 เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ (ต่อ)


Absolute Percentage Error – APE (%)							
Location	Direction	Opposing Vehicle		Passed Vehicle		Overtaking Vehicle	
		Off-Peak	Peak	Off-Peak	Peak	Off-Peak	Peak
D	E-W	3.63	2.99	0.00	0.00	0.00	0.00
D	W-E	1.40	2.36	0.00	100	0.00	0.00
E	E-W	0.34	1.49	43.34	58.94	0.00	0.00
E	W-E	1.92	0.35	11.10	500.30	0.00	0.00
MAPE		2.34	2.50	17.11	71.92	0.00	0.00
MAPE		2.45		44.52		0.00	

หมายเหตุ APE หมายถึง Absolute Percentage Error

MAPE หมายถึง Mean Absolute Percentage Error


จากผลการประเมินเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนยานพาหนะในแต่ละรูปแบบการเคลื่อนที่ดังตารางที่ 4.23 สามารถอภิปรายได้ดังนี้

1) เปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถทิศทางตรงข้าม (Opposing Vehicle) เฉลี่ยทุกจุดสำรวจและช่วงเวลามีค่าเท่ากับ 2.45% โดยที่ช่วงเร่งด่วนมีความคลาดเคลื่อนที่ 2.50% มากกว่าช่วงไม่เร่งด่วนที่มีค่าเท่ากับ 2.34% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจดังรูปที่ 4.21 พบว่า จุดสำรวจ C ทิศทาง E-W เป็นจุดสำรวจที่มีความคลาดเคลื่อนมากที่สุดทั้งช่วงเร่งไม่ด่วนที่มีความคลาดเคลื่อนที่ 6.27% และช่วงเร่งด่วนที่ 8.00% ซึ่งมีสาเหตุส่วนใหญ่จากความผิดพลาดจากการสร้างกรอบพื้นที่ที่สนใจในการจำแนกรถที่วิ่งในทิศทางตรงข้ามและจำแนกรถบนไหล่ทางขวา ทำให้จำนวนยานพาหนะโดยเฉพาะยานพาหนะประเภท Motorcycle ขาดและเกินจากข้อมูลสำรวจจริงดังได้อภิปรายไว้ในหัวข้อ 4.3.2.1 และ 4.3.2.4



รูปที่ 4.21 เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถทิศทางตรงข้าม

2) เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถที่ถูกรถสำรวจแซง (Passed Vehicle) เฉลี่ยทุกจุดสำรวจและช่วงเวลามีค่าเท่ากับ 44.52% โดยที่ช่วงเร่งด่วนมีความคลาดเคลื่อนที่ 71.92% มากกว่าช่วงไม่เร่งด่วนที่มีค่าเท่ากับ 11.10% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจรูปที่ 4.22 พบว่า จุดสำรวจ E ทิศทาง W-E W เป็นจุดสำรวจที่มีความคลาดเคลื่อนมากที่สุดช่วงเร่งด่วนที่มีความคลาดเคลื่อนที่ 500.30% (ผลลัพธ์จากข้อมูลจริง 0.04 PCU แต่ผลลัพธ์จากโมเดลที่นำเสนอ 0.25 PCU) และช่วงไม่เร่งด่วนเป็นจุดสำรวจ A ทิศทาง W-E ที่มีความคลาดเคลื่อน 66.70% ซึ่งมีสาเหตุจากกรอบสร้างกรอบพื้นที่ที่สนใจในการจำแนกรถบนไหล่ทางซ้ายออกจากการคำนวณและเงื่อนไขในการจำแนกรถที่วิ่งแซงรถสำรวจที่สร้างขึ้นที่มีประสิทธิภาพต่ำ ทำให้จำนวนยานพาหนะเกินจากข้อมูลสำรวจจริงดังได้อภิปรายไว้ในหัวข้อ 4.3.2.2 และ 4.3.2.4



รูปที่ 4.22 เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถที่ถูกรถสำรวจแซง

3) เปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าจำนวนรถที่แซงรถสำรวจ (Overtaking Vehicle) เฉลี่ยทุกจุดสำรวจ เท่ากับ 0% แสดงให้เห็นว่า ผลการประมาณค่าจำนวนรถที่แซงรถสำรวจโดยใช้ข้อมูลจากโมเดลที่นำเสนอมีค่าเท่ากับการประมาณค่าโดยใช้ข้อมูลจริงทุกจุดสำรวจ

4.5 ผลการเปรียบเทียบผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรระหว่างข้อมูลจริงกับโมเดลที่นำเสนอ

ผลลัพธ์การจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 รูปแบบ (จำนวนรถที่วิ่งในทิศทางตรงข้าม, รถที่วิ่งแซงรถสำรวจ และรถที่ถูกรถสำรวจแซงแบบรายประเภทยานพาหนะ) ของข้อมูลสำรวจจราจรทั้ง 5 ช่วงถนน นำมาจับคู่ตามวิธีการสำรวจ MOM ได้ทั้งหมด 143 รอบ (ช่วงถนนสำรวจละ 4-8 รอบต่อทิศทางต่อช่วงเวลา) แล้วนำไปคำนวณเพื่อหาค่าอัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจรตั้งสมการที่ (2.24), (2.26) และ (2.27) ของแต่ละทิศทาง ช่วงเวลาและจุดสำรวจ ซึ่งสามารถแสดงผลลัพธ์การประมาณค่าตัวแปรกระแสจราจรและเปอร์เซนต์ความคลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error) ระหว่างการใช้ข้อมูลจริงที่ได้จากสำรวจโดยสายตากับการใช้โมเดลที่นำเสนอในการตรวจจับและจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะได้ดังต่อไปนี้

4.5.1 การประมาณค่าอัตราการไหล (Flow Rate)

ผลการประมาณค่าอัตราการไหลและการเปรียบเทียบผลลัพธ์ที่ได้ในแต่ละจุดสำรวจ และช่วงเวลาสำรวจสามารถแสดงได้ดังต่อไปนี้

ตารางที่ 4.24 ผลการประมาณค่าอัตราการไหลระหว่างค่าจริงกับค่าที่ได้จากโมเดล


อัตราการไหล (Flow Rate) - หน่วย : PCU/ชั่วโมง							
Location	Direction	ช่วงไม่เร่งด่วน 13:00 – 15:00 น.			ช่วงเร่งด่วน 16:30 – 18:00 น.		
		Actual	Predicted	APE (%)	Actual	Predicted	APE (%)
A	E-W	194.75	195.85	0.56	402.27	408.73	1.61
A	W-E	216.62	211.48	2.37	294.53	289.95	1.56
B	E-W	190.73	188.75	1.03	254.34	262.14	3.07
B	W-E	222.24	219.20	1.37	166.94	161.17	3.45
C	E-W	391.11	415.00	6.11	460.93	497.26	7.88
C	W-E	328.42	336.14	2.35	457.60	465.29	1.68
D	E-W	446.51	430.65	3.55	619.31	601.22	2.92
D	W-E	423.28	417.59	1.35	484.56	469.56	3.10
E	E-W	403.60	404.48	0.22	514.95	508.67	1.22
E	W-E	415.19	422.91	1.86	449.17	449.31	0.03
MAPE Off-Peak				2.08	MAPE Peak Hours		2.65
Overall MAPE of Flow Rate							2.36

หมายเหตุ Actual หมายถึง ผลลัพธ์ที่ได้จากการข้อมูลสำรวจจริง


Predicted หมายถึง ผลลัพธ์ที่ได้จากการโมเดลที่นำเสนอ

APE หมายถึง Absolute Percentage Error

MAPE หมายถึง Mean Absolute Percentage Error



รูปที่ 4.23 ผลการเปรียบเทียบค่าอัตราการไหลในแต่ละช่วงเวลาสำรวจ




รูปที่ 4.24 ผลการเปรียบเทียบค่าอัตราการไหลระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลา
สำรวจ

ผลลัพธ์การประมาณค่าอัตราการไหลของกระแสจราจร (Flow Rate) ระหว่างการใช้ข้อมูลสำรวจจริง (Actual) กับการใช้ข้อมูลการจำแนกยานพาหนะที่ได้จากโมเดลที่นำเสนอ (Predicted) สามารถแสดงได้ดังตารางที่ 4.24 โดยสามารถแสดงผลการเปรียบเทียบอัตราการไหลระหว่างช่วงไม่เร่งด่วนและช่วงเร่งด่วนเพื่อให้เห็นถึงอัตราการไหลที่แตกต่างกันในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.23 และผลการเปรียบเทียบค่าอัตราการไหลระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาเพื่อให้เห็นถึงความแตกต่างระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงและข้อมูลที่ได้จากโมเดลดังรูปที่ 4.24 และผลการเปรียบเทียบค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าอัตราการไหลในแต่ละช่วงเวลาสำรวจเพื่อให้เห็นถึงค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error: APE) ในการประมาณค่าอัตราการไหลของโมเดลที่นำเสนอในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.25 โดยพบว่า

1) อัตราการไหลของกระแสจราจรที่ได้จากการใช้ข้อมูลสำรวจจริงของทั้ง 5 จุดสำรวจมีค่าเฉลี่ยอยู่ที่ 366.85 PCU/ชั่วโมง และมีค่าต่ำสุดอยู่ที่ 166.94 PCU/ชั่วโมง ในจุดสำรวจ B ทิศทาง E-W และค่าสูงสุดอยู่ 619.31 PCU/ชั่วโมง ในจุด D ทิศทาง E-W

2) โดยช่วงเร่งด่วนมีอัตราการไหลที่ได้จากการใช้ข้อมูลสำรวจจริงมีค่าสูงกว่าช่วงไม่เร่งด่วนโดยเฉลี่ยที่ 34.7% และ มีค่าต่ำสุดอยู่ที่ 8.2% ในจุดสำรวจ E ทิศทาง W-E และมีค่าสูงสุดอยู่ที่ 106.6% ในจุด A ทิศทาง E-W

3) เมื่อนำผลการเปรียบเทียบระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงกับผลลัพธ์ที่ได้จากโมเดลตั้งตารางที่ 4.24 มาคำนวณค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error) ดังรูปที่ 4.25 พบว่า ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error) ของทุกจุดสำรวจและทุกช่วงเวลามีค่าเท่ากับ 2.36% แบ่งเป็นช่วงไม่เร่งด่วนมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 2.08% และช่วงเร่งด่วนเท่ากับ 2.65% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจพบว่า จุดสำรวจ C ทิศทาง E-W มีความคลาดเคลื่อนสูงที่สุดในช่วงไม่เร่งด่วนที่ 6.11% และในช่วงเร่งด่วนที่ 7.88% ซึ่งจุดสำรวจนี้มีความคลาดเคลื่อนในการจราจรตรงข้าม (Opposing Vehicle) สูงที่สุดดังรูปที่ 4.21 จึงทำให้การประมาณค่าอัตราการไหลมีความคลาดเคลื่อนสูงเช่นกัน



รูปที่ 4.25 ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าอัตราการไหลในแต่ละช่วงเวลาสำรวจ

โดยเมื่อทำการเปรียบเทียบการประมาณค่าอัตราการไหลของกระแสจราจรด้วย GEH Statistic สามารถแสดงผลที่ได้ดังตารางที่ 4.25 พบว่า ทั้ง 5 จุดสำรวจที่แบ่งตามทิศทางและช่วงเวลามีค่า GEH อยู่ในช่วง 0.01 ถึง 1.66 ซึ่งทุกการสำรวจมีค่า GEH < 5 แสดงให้เห็นว่า ค่าอัตราการไหลที่ได้จากการใช้ผลที่ได้จากโมเดลที่นำเสนอมีความคลาดเคลื่อนจากการใช้ข้อมูลสำรวจจริงอยู่ในเกณฑ์ที่สามารถยอมรับได้ทุกการสำรวจ

ตารางที่ 4.25 ผลการเปรียบเทียบการประมาณค่าอัตราการไหล

อัตราการไหล (Flow Rate) - หน่วย : PCU/ชั่วโมง						
Location	Direction	Period	Actual	Predicted	GEH	Acceptance?
A	E-W	Off-Peak	194.75	195.85	0.08	Yes (GEH <5)
A	E-W	Peak	402.27	408.73	0.32	Yes (GEH <5)
A	W-E	Off-Peak	216.62	211.48	0.35	Yes (GEH <5)
A	W-E	Peak	294.53	289.95	0.27	Yes (GEH <5)
B	E-W	Off-peak	190.73	188.75	0.14	Yes (GEH <5)
B	E-W	Peak	254.34	262.14	0.49	Yes (GEH <5)
B	W-E	Off-Peak	222.24	219.2	0.20	Yes (GEH <5)
B	W-E	Peak	166.94	161.17	0.45	Yes (GEH <5)
C	E-W	Off-Peak	391.11	415	1.19	Yes (GEH <5)
C	E-W	Peak	460.93	497.26	1.66	Yes (GEH <5)
C	W-E	Off-Peak	328.42	336.14	0.42	Yes (GEH <5)
C	W-E	Peak	457.6	465.29	0.36	Yes (GEH <5)
D	E-W	Off-Peak	446.51	430.65	0.76	Yes (GEH <5)
D	E-W	Peak	619.31	601.22	0.73	Yes (GEH <5)
D	W-E	Off-Peak	423.28	417.59	0.28	Yes (GEH <5)
D	W-E	Peak	484.56	469.56	0.69	Yes (GEH <5)
E	E-W	Off-Peak	403.6	404.48	0.04	Yes (GEH <5)
E	E-W	Peak	514.95	508.67	0.28	Yes (GEH <5)
E	W-E	Off-Peak	415.19	422.91	0.38	Yes (GEH <5)
E	W-E	Peak	449.17	449.31	0.01	Yes (GEH <5)

หมายเหตุ Actual หมายถึง ผลลัพธ์ที่ได้จากการข้อมูลสำรวจจริง

Predicted หมายถึง ผลลัพธ์ที่ได้จากการโมเดลที่นำเสนอ

4.5.2 การประมาณค่าความเร็วเฉลี่ย (Space Mean Speed)

ผลการประมาณค่าความเร็วเฉลี่ยและการเปรียบเทียบผลลัพธ์ที่ได้ในแต่ละจุดสำรวจและช่วงเวลาสำรวจสามารถแสดงได้ดังต่อไปนี้

ตารางที่ 4.26 ผลการประมาณค่าความเร็วเฉลี่ยระหว่างค่าจริงกับค่าที่ได้จากโมเดล

ความเร็วเฉลี่ย (Space Mean Speed) - หน่วย : กม./ชม.							
Location	Direction	ช่วงไม่เร่งด่วน 13:00 – 15:00 น.			ช่วงเร่งด่วน 16:30 – 18:00 น.		
		Actual	Predicted	APE (%)	Actual	Predicted	APE (%)
A	E-W	60.34	56.83	5.80	53.83	53.87	0.07
A	W-E	49.65	49.26	0.79	53.82	53.80	0.03
B	E-W	51.88	51.87	0.03	54.61	53.24	2.50
B	W-E	53.82	53.82	0.00	53.91	54.18	0.50
C	E-W	51.33	51.48	0.29	53.77	53.88	0.21
C	W-E	52.53	52.56	0.05	52.77	52.77	0.00
D	E-W	54.76	54.68	0.15	55.76	55.68	0.13
D	W-E	50.98	50.94	0.09	52.62	53.38	1.45
E	E-W	55.41	54.76	1.17	48.66	48.40	0.53
E	W-E	52.27	52.33	0.13	51.15	51.49	0.66
MAPE Off-Peak Hours				0.85	MAPE Peak Hours		0.61
Overall MAPE of Space Mean Speed				0.73			

หมายเหตุ Actual หมายถึง ผลลัพธ์ที่ได้จากการข้อมูลสำรวจจริง

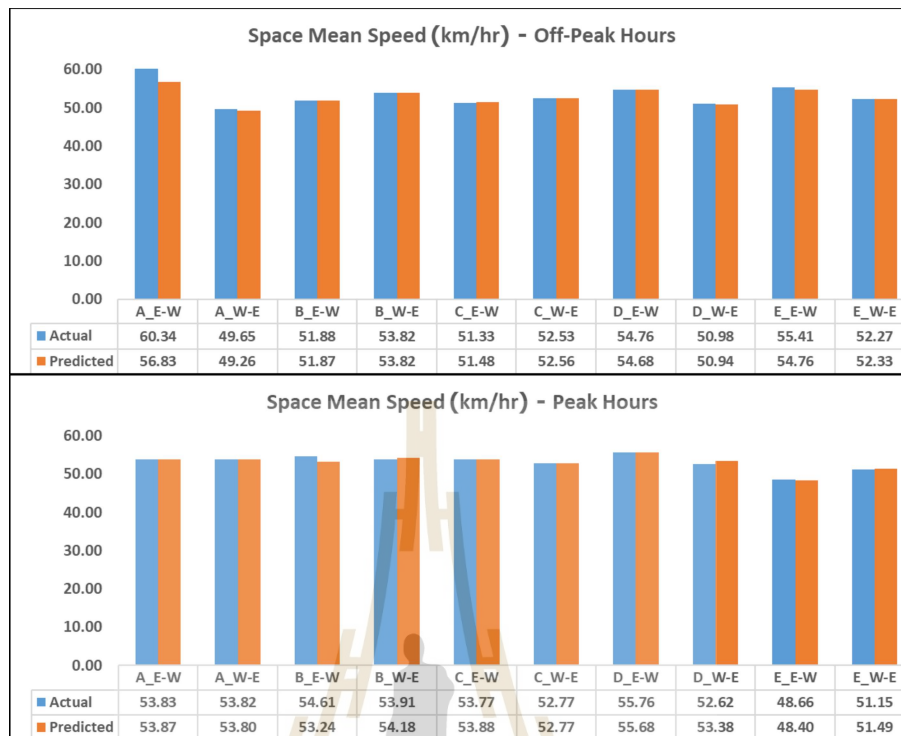
Predicted หมายถึง ผลลัพธ์ที่ได้จากการโมเดลที่นำเสนอ

APE หมายถึง Absolute Percentage Error

MAPE หมายถึง Mean Absolute Percentage Error



รูปที่ 4.26 ผลการเปรียบเทียบค่าความเร็วเฉลี่ยในแต่ละช่วงเวลาสำรวจ



รูปที่ 4.27 ผลการเปรียบเทียบค่าความเร็วเฉลี่ยระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลา
สำรวจ


ผลลัพธ์การประมาณค่าความเร็วเฉลี่ยของกระแสจราจร (Space Mean Speed) ระหว่างการใช้ข้อมูลสำรวจจริง (Actual) กับการใช้ข้อมูลการจำแนกยานพาหนะที่ได้จากโมเดลที่นำเสนอ (Predicted) สามารถแสดงได้ดังตารางที่ 4.26 โดยสามารถแสดงผลการเปรียบเทียบความเร็วเฉลี่ยระหว่างช่วงไม่เร่งด่วนและช่วงเร่งด่วนเพื่อให้เห็นถึงความเร็วเฉลี่ยที่ต่างกันในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.26 และผลการเปรียบเทียบค่าความเร็วเฉลี่ยระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาเพื่อให้เห็นถึงความแตกต่างระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงและข้อมูลที่ได้จากโมเดลดังรูปที่ 4.27 และผลการเปรียบเทียบค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความเร็วเฉลี่ยในแต่ละช่วงเวลาสำรวจเพื่อให้เห็นถึงค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percent Error: APE) ในการประมาณค่าความเร็วเฉลี่ยของโมเดลที่นำเสนอในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.28 โดยพบว่า

1) ความเร็วเฉลี่ยของกระแสจราจรที่ได้จากการใช้ข้อมูลสำรวจจริงของ 5 จุดสำรวจ มีค่าเฉลี่ยอยู่ที่ 53.19 กิโลเมตร/ชั่วโมง และมีค่าต่ำสุดอยู่ที่ 48.66 กิโลเมตร/ชั่วโมงในจุดสำรวจ

E ทิศทาง E-W ในช่วงเร่งด่วนและค่าสูงสุดอยู่ 60.34 กิโลเมตร/ชั่วโมง ในจุด A ทิศทาง E-W ในช่วงไม่เร่งด่วน

2) โดยช่วงเร่งด่วนมีความเร็วเฉลี่ยที่ได้จากการใช้ข้อมูลสำรวจจริงมีค่าต่ำกว่าช่วงไม่เร่งด่วนโดยเฉลี่ยที่ 4.9% และ มีค่าต่ำสุดอยู่ที่ 0.2% ในจุดสำรวจ B ทิศทาง W-E และมีค่าสูงสุดอยู่ที่ 12.2% ในจุด E ทิศทาง E-W

3) เมื่อนำผลการเปรียบเทียบระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงกับผลลัพธ์ที่ได้จากโมเดลดังตารางที่ 4.26 มาคำนวณค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error) ดังรูปที่ 4.28 พบว่า ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error) ของทุกจุดสำรวจและทุกช่วงเวลามีค่าเท่ากับ 0.73% แบ่งเป็นช่วงไม่เร่งด่วนมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 0.85% และช่วงเร่งด่วนเท่ากับ 0.61% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจพบว่า ช่วงไม่เร่งด่วน ณ จุดสำรวจ A ทิศทาง E-W มีความคลาดเคลื่อนสูงที่สุดที่ 5.80% และในช่วงเร่งด่วน ณ จุดสำรวจ B ทิศทาง E-W ที่มีความคลาดเคลื่อนสูงที่สุด 2.50% ซึ่งทั้งสองจุดมีความแตกต่างของจำนวนรถที่ถูกรถสำรวจแซง (Passed Vehicle) ลบกับรถที่แซงรถสำรวจ (Overtaking Vehicle) ระหว่างข้อมูลสำรวจจริงกับข้อมูลที่ได้จากโมเดลมากที่สุดดังรูปที่ 4.19 และรูปที่ 4.20 และบวกกับความคลาดเคลื่อนของจำนวนรถทิศทางตรงข้าม (Opposing Vehicle) ทำให้การประมาณค่าความเร็วเฉลี่ยมีความคลาดเคลื่อนสูงเมื่อเทียบกับจุดสำรวจอื่น



รูปที่ 4.28 ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความเร็วเฉลี่ยในแต่ละช่วงเวลาสำรวจ

4.5.3 การประมาณค่าความหนาแน่นกระแสจราจร (Density)

ผลการประมาณค่าความหนาแน่นกระแสจราจรและการเปรียบเทียบผลลัพธ์ที่ได้ในแต่ละจุดสำรวจและช่วงเวลาสำรวจสามารถแสดงได้ดังต่อไปนี้

ตารางที่ 4.27 ผลการประมาณค่าความหนาแน่นระหว่างค่าจริงกับค่าที่ได้จากโมเดล

ความหนาแน่น (Density) - หน่วย : PCU/กม.							
Location	Direction	ช่วงไม่เร่งด่วน 13:00 – 15:00 น.			ช่วงเร่งด่วน 16:30 – 18:00 น.		
		Actual	Predicted	APE (%)	Actual	Predicted	APE (%)
A	E-W	3.23	3.45	5.80	7.47	7.59	1.54
A	W-E	4.36	4.29	0.79	5.47	5.39	1.52
B	E-W	3.68	3.64	0.03	4.66	4.92	5.71
B	W-E	4.13	4.07	0.00	3.10	2.97	3.94
C	E-W	7.62	8.06	0.29	8.57	9.23	7.65
C	W-E	6.25	6.40	0.05	8.67	8.82	1.68
D	E-W	8.15	7.88	0.15	11.11	10.80	2.80
D	W-E	8.30	8.20	0.09	9.21	8.80	4.48
E	E-W	7.28	7.39	1.17	10.58	10.51	0.69
E	W-E	7.94	8.08	0.13	8.78	8.73	0.63
MAPE Off-Peak Hours				2.66	MAPE		3.06
Overall MAPE of Space Mean Speed				2.86			

หมายเหตุ Actual หมายถึง ผลลัพธ์ที่ได้จากการข้อมูลสำรวจจริง

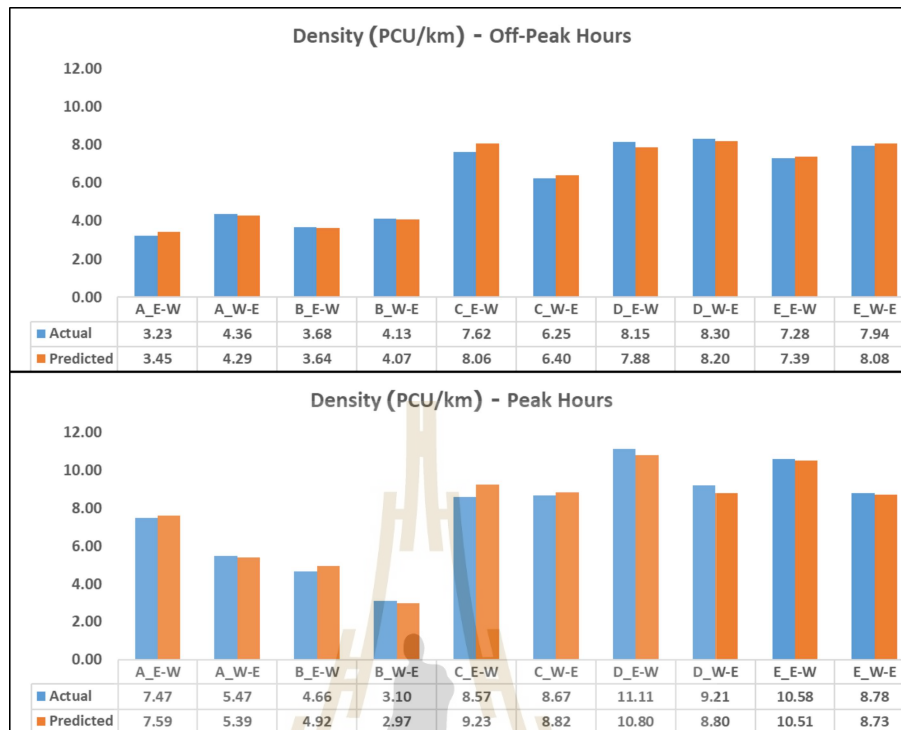
Predicted หมายถึง ผลลัพธ์ที่ได้จากการโมเดลที่นำเสนอ

APE หมายถึง Absolute Percentage Error

MAPE หมายถึง Mean Absolute Percentage Error



รูปที่ 4.29 ผลการเปรียบเทียบค่าความหนาแน่นจราจรในแต่ละช่วงเวลาสำรวจ




รูปที่ 4.30 ผลการเปรียบเทียบค่าความหนาแน่นกระแสจราจรระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาสำรวจ

ผลลัพธ์การประมาณค่าความหนาแน่นของกระแสจราจร (Density) ระหว่างการใช้ข้อมูลสำรวจจริง (Actual) กับการใช้ข้อมูลการจำแนกยานพาหนะที่ได้จากโมเดลที่นำเสนอ (Predicted) สามารถแสดงได้ดังตารางที่ 4.27 โดยสามารถแสดงผลการเปรียบเทียบหนาแน่นกระแสจราจรระหว่างช่วงไม่เร่งด่วนและช่วงเร่งด่วนเพื่อให้เห็นถึงความหนาแน่นกระแสจราจรที่ต่างกันในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.29 และผลการเปรียบเทียบค่าความหนาแน่นกระแสจราจรระหว่างค่าจริงกับค่าที่ได้จากโมเดลในแต่ละช่วงเวลาเพื่อให้เห็นถึงความแตกต่างระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงและข้อมูลที่ได้จากโมเดลดังรูปที่ 4.30 และผลการเปรียบเทียบค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความหนาแน่นกระแสจราจรในแต่ละช่วงเวลาสำรวจเพื่อให้เห็นถึงค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percent Error: APE) ในการประมาณค่าความหนาแน่นกระแสจราจรของโมเดลที่นำเสนอในแต่ละช่วงเวลาและจุดสำรวจดังรูปที่ 4.31 โดยพบว่า

1) ความหนาแน่นกระแสจราจรที่ได้จากการใช้ข้อมูลสำรวจจริงของ 5 จุดสำรวจมีค่าเฉลี่ยอยู่ที่ 6.93 PCU/กิโลเมตร และมีค่าต่ำสุดอยู่ที่ 2.97 PCU/กม. ในจุดสำรวจ B ทิศทาง W-E และค่าสูงสุดอยู่ 11.11 PCU/กม. ในจุด D ทิศทาง E-W


2) โดยช่วงเร่งด่วนมีความหนาแน่นกระแสจราจรที่ได้จากการใช้ข้อมูลสำรวจจริงมีค่าต่ำกว่าช่วงไม่เร่งด่วนโดยเฉลี่ยที่ 36.3% และ มีค่าต่ำสุดอยู่ที่ 10.5% ในจุดสำรวจ E ทิศทาง W-E และมีค่าสูงสุดอยู่ที่ 131.5% ในจุด A ทิศทาง E-W

3) เมื่อนำผลการเปรียบเทียบระหว่างผลลัพธ์ที่ได้จากข้อมูลจริงกับผลลัพธ์ที่ได้จากโมเดลตั้งตารางที่ 4.27 มาคำนวณค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์ (Absolute Percentage Error) ดังรูปที่ 4.31 พบว่า ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error) ของทุกจุดสำรวจและทุกช่วงเวลามีค่าเท่ากับ 2.86% แบ่งเป็นช่วงไม่เร่งด่วนมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 2.66% และช่วงเร่งด่วนเท่ากับ 3.06% และเมื่อดูความคลาดเคลื่อนรายจุดสำรวจพบว่า ช่วงไม่เร่งด่วน ณ จุดสำรวจ A มีความคลาดเคลื่อนสูงที่สุดที่ 6.76% และในช่วงเร่งด่วน ณ จุดสำรวจ C ที่มีความคลาดเคลื่อนสูงที่สุด 7.65% ซึ่งเป็นจุดที่มีความคลาดเคลื่อนในการประมาณค่าอัตราการไหลและความเร็วเฉลี่ยที่สูงเมื่อเทียบกับจุดสำรวจอื่น



รูปที่ 4.31 ผลการเปรียบเทียบเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าความหนาแน่นกระแสจราจรในแต่ละช่วงเวลาสำรวจ

4.5.4 สรุปผลความคลาดเคลื่อนในการประมาณค่าตัวแปรกระแสจราจร



รูปที่ 4.32 Box and Whisker ของค่าคลาดเคลื่อนสัมบูรณ์ในการประมาณค่าตัวแปรกระแสจราจร

ผลลัพธ์การจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 รูปแบบ (จำนวนรถที่วิ่งในทิศทางตรงข้าม, รถที่วิ่งแซงรถสำรวจ และรถที่ถูกรถสำรวจแซงแบบรายประเภท ยานพาหนะ) ของข้อมูลสำรวจจราจรทั้ง 5 ช่วงถนน นำมาจับคู่ตามวิธีการสำรวจ MOM ได้ทั้งหมด 143 รอบ แล้วนำไปคำนวณเพื่อหาค่าอัตราการไหล ความเร็วเฉลี่ย และความหนาแน่นกระแสจราจร เมื่อกำหนดความคลาดเคลื่อนสัมบูรณ์โดยรวมในการประมาณตัวแปรกระแสจราจรทั้ง 3 ตัวแปรดังรูปที่ 4.32 พบว่า อัตราการไหลมีความคลาดเคลื่อนเฉลี่ยเท่ากับ 2.36% และสูงสุดเท่ากับ 7.88% ส่งผลให้ความคลาดเคลื่อนของความเร็วเฉลี่ยและความหนาแน่นจราจรค่าเฉลี่ยเท่ากับ 0.73 และ 2.86% และมีค่าสูงสุดเท่ากับ 5.80 และ 7.65% ตามลำดับ โดยการจำแนกรถทิศทางตรงข้าม (Opposing Vehicle) เป็นปัจจัยหลักที่ทำให้เกิดความคลาดเคลื่อนในการประมาณค่าและรองลงมาเป็นการจำแนกรถที่ถูกรถสำรวจ (Passed Vehicle) ที่ทำให้ค่าตัวแปรกระแสจราจรคลาดเคลื่อนเมื่อเทียบกับการใช้ข้อมูลจริง

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผลการศึกษา

งานวิจัยนี้ได้นำเสนอโมเดลจำแนกประเภทและรูปแบบการเคลื่อนที่ของยานพาหนะทั้ง 3 รูปแบบ (จำนวนรถที่วิ่งในทิศทางตรงข้าม (Opposing Vehicle), รถที่วิ่งแซงรถสำรวจ (Overtaking Vehicle) และรถที่ถูกรถสำรวจแซง (Passed Vehicle) แบบรายประเภทยานพาหนะ) ตามวิธีสำรวจ โดยการเคลื่อนที่ของยานพาหนะ (Moving Observer Method: MOM) โดยใช้ (1) สถาปัตยกรรม YOLOv7 ในการตรวจจับและจำแนกประเภทยานพาหนะ, (2) อัลกอริทึม StrongSORT ในการติดตามการเคลื่อนที่ของยานพาหนะ และ (3) อัลกอริทึม Canny Edge Detection กับ Hough Transform ในการตรวจจับเส้นสีจราจรเพื่อสร้างกรอบพื้นที่จำแนกเฉพาะยานพาหนะที่สนใจ (เฉพาะที่วิ่งบนช่องจราจร) ให้สอดคล้องกับเส้นไหล่ทางจริงตลอดการสำรวจ จากนั้นนำผลลัพธ์การจำแนกไปใช้ในการประมาณค่าตัวแปรกระแสจราจรตามวิธีสำรวจ MOM โดยทดลองกับข้อมูลสำรวจจราจรที่วิ่งสำรวจบนถนน 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางในช่วงเวลา 13:00–15:00 น. (ช่วงไม่เร่งด่วน) และ 16:30–18:00 น. (ช่วงเร่งด่วน) ทั้ง 5 ช่วงถนนในประเทศไทย

โมเดลที่นำเสนอมีประสิทธิภาพโดยรวม (F1-score) ในการจำแนกรถในทิศทางตรงข้าม, รถที่แซงรถสำรวจ และรถที่ถูกรถสำรวจแซงเท่ากับ 93.25, 94.79 และ 64.62% ตามลำดับ ซึ่งความคลาดเคลื่อนในการจำแนกนั้นส่วนใหญ่เกิดจากโมเดลสร้างกรอบพื้นที่ที่สนใจเพื่อจำแนกเฉพาะยานพาหนะที่วิ่งบนช่องจราจรที่มีการใช้ตำแหน่งและความกว้างของกรอบตั้งต้นและการใช้เพียงแค่ตำแหน่งของเส้นไหล่ทางซ้ายมือที่ได้จากโมเดลตรวจจับเส้นสีจราจรในการอ้างอิงเพื่อสร้างกรอบพื้นที่ที่สนใจ ทำให้กรอบพื้นที่ที่สร้างนั้นไม่สอดคล้องกับขอบเขตช่องจราจรจริง โดยเฉพาะการสร้างกรอบพื้นที่ขอบเขตตามเส้นไหล่ทางขวาจึงส่งผลทำให้จำนวนรถที่วิ่งในทิศทางตรงข้าม (Opposing Vehicle) ขาดหายและเกินจากความเป็นจริง และรองลงมาคือความคลาดเคลื่อนจากการจำแนกประเภทของยานพาหนะทั้ง 8 ประเภท และความคลาดเคลื่อนจากการจำแนกรถที่รถสำรวจแซง (Passed Vehicle) ที่เกิดจากโมเดลสร้างกรอบพื้นที่เพื่อจำแนกรถบนไหล่ทางซ้ายและเงื่อนไขในการจำแนกรถที่รถสำรวจแซงที่สร้างขึ้นมีประสิทธิภาพต่ำยังไม่ครอบคลุมในทุกเหตุการณ์

เช่น เหตุการณ์ที่ยานพาหนะบนไหล่ทางที่วิ่งบนทางโค้ง หรือทับเส้นสีจราจรไหล่ทางด้านซ้าย เป็นต้น และความคลาดเคลื่อนจากเหตุการณ์อื่น ๆ เช่น การขาดหาย การนับซ้ำซ้อน และการเปลี่ยนแปลง ไอเดียยานพาหนะแบบฉับพลันที่เกิดจากโมเดลติดตามยานพาหนะ การบังคับยานพาหนะ เป็นต้น โดยอัตราการไหลที่เพิ่มขึ้นในช่วงเร่งด่วนส่งผลให้อัตราความผิดพลาดสูงยิ่งขึ้นและมีปัจจัยอื่น ๆ ที่ส่งผลกระทบต่อประสิทธิภาพของโมเดลที่น่าเสนอ เช่น เส้นสีจราจรที่ขาดหายหรือไม่คมชัดในบางช่วงถนน สำรวจ แร่งสันสะท้อนที่ทำให้มุมกล้องเกิดความคลาดเคลื่อนจากเดิมซึ่งทำให้โมเดลสร้างกรอบพื้นที่มีประสิทธิภาพลดลง เป็นต้น

ประสิทธิภาพของโมเดลตรวจจับยานพาหนะในการจำแนกประเภทยานพาหนะทั้ง 8 ประเภทนั้นพบว่า ยานพาหนะประเภท SUV มีความแม่นยำต่ำที่สุด การจำแนกประเภทระหว่าง SUV กับ CAR โดยเฉพาะรถ Hatchback กับ SUV และ MUV มีสัดส่วนความผิดพลาดที่มากที่สุด เนื่องจากมีลักษณะใกล้เคียงกันแต่แตกต่างกันที่ขนาดเมื่อมองจากมุมมองด้านหน้ารถของรถที่วิ่งในทิศทางตรงข้าม และการจำแนกประเภทยานพาหนะในมุมมองด้านหลังรถของรถที่วิ่งแข่งรถสำรวจและรถที่ถูกรถสำรวจแข่ง ยานพาหนะประเภท VAN มีความแม่นยำต่ำที่สุด ซึ่งความผิดพลาดเกิดจากการจำแนกประเภทระหว่าง SUV กับ VAN เนื่องจากมีลักษณะใกล้เคียงกัน

และเมื่อเปรียบเทียบผลการประมาณค่าตัวแปรกระแสจราจรระหว่างการใช้ผลลัพธ์ที่ได้จากโมเดลที่น่าเสนอกับข้อมูลสำรวจจริงพบว่า อัตราการไหล ความเร็วเฉลี่ยและความหนาแน่นมีเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์สูงสุดเท่ากับ 7.88, 5.80 และ 7.65% ตามลำดับและมีค่าเฉลี่ยเท่ากับ 2.36, 0.73 และ 2.86% ตามลำดับ และเมื่อปรับเทียบการประมาณค่าอัตราการไหลด้วย GEH Statistic พบว่า ทั้ง 5 จุดสำรวจที่แบ่งตามทิศทางและช่วงเวลา ทุกการสำรวจมีค่า GEH น้อยกว่า 5 แสดงให้เห็นว่า ค่าอัตราการไหลที่ถูกประมาณค่าจากผลลัพธ์ที่ได้จากโมเดลที่น่าเสนอนั้นมีความคลาดเคลื่อนจากการใช้ข้อมูลสำรวจจริงที่อยู่ในเกณฑ์ที่สามารถยอมรับได้ทั้งหมด

งานวิจัยนี้ได้ทำการพัฒนาต่อยอดงานวิจัยก่อนหน้านี้นี้โดยมีการนำเสนอโมเดลตรวจจับยานพาหนะและติดตามยานพาหนะที่มีประสิทธิภาพด้านความถูกต้องแม่นยำที่สูงขึ้นมาประยุกต์ใช้เพื่อลดความผิดพลาดในการนำไปใช้ในการจำแนกประเภทยานพาหนะทั้ง 8 ประเภทและรูปแบบการเคลื่อนที่ทั้ง 3 รูปแบบ (รถที่วิ่งในทิศทางตรงข้าม, รถที่วิ่งแข่งรถสำรวจ และรถที่ถูกรถสำรวจแข่ง) ซึ่งเป็นข้อมูลที่จะถูกนำไปใช้ในการประมาณค่าตัวแปรกระแสจราจร และนำเสนอโมเดลสร้างกรอบพื้นที่เพื่อบังคับและจำแนกเฉพาะยานพาหนะที่วิ่งบนช่องจราจรและจำแนกยานพาหนะที่ไม่เกี่ยวข้องออกจากการประมาณค่าตัวแปรกระแสจราจร ได้แก่ ยานพาหนะที่จอดและวิ่งบนไหล่ทางซ้ายและขวา และยานพาหนะที่จอดตามที่อยู่อาศัยบริเวณขอบทางถนนที่เป็นพฤติกรรมของผู้ใช้ถนนในบางช่วง

ถนนในประเทศไทยเพื่อให้ได้ค่าตัวแปรกระแสจราจรที่เป็นตัวแทนของกระแสจราจรจริงที่วิ่งเฉพาะบนช่องจราจร โดยความคลาดเคลื่อนในการนำผลลัพธ์ของโมเดลที่นำเสนอไปใช้ในการประมาณค่าตัวแปรกระแสจราจรที่มีความคลาดเคลื่อนเฉลี่ยที่ต่ำและการประมาณค่าอัตราการไหลของทั้ง 5 จุดสำรวจที่แบ่งตามทิศทางและช่วงเวลา ทุกการสำรวจอยู่ในเกณฑ์ความคลาดเคลื่อนที่สามารถยอมรับได้จากการวัดประสิทธิภาพโดยใช้ GEH Statistic

โมเดลที่นำเสนอมีข้อจำกัดประกอบไปด้วย (1) โมเดลสามารถใช้ได้เฉพาะช่วงถนนที่มี 1 ช่องจราจรต่อทิศทางแบบไม่มีเกาะกลางและมีขนาดช่องจราจรเท่ากันทั้งช่วงถนนที่สำรวจ (2) โมเดลต้องการผู้ใช้งานในการกำหนดขอบเขตกรอบพื้นที่ที่สนใจในชั้นตอนเริ่มต้น (3) โมเดลต้องการช่วงถนนสำรวจที่มีเส้นสีจราจรไหลทางซ้ายที่ความคมชัดและต่อเนื่องและช่วงถนนสำรวจที่มีลักษณะเป็นทางตรงเพื่อให้โมเดลตรวจจับเส้นสีจราจรไหลทางซ้ายที่ใช้ในการสร้างกรอบพื้นที่ที่สนใจมีประสิทธิภาพสูงที่สุด

5.2 ข้อเสนอแนะ

1) โมเดลสร้างกรอบพื้นที่ตามขอบเขตช่องจราจรต้องการคุณภาพของเส้นสีจราจรที่มีความคมชัดเช่นเดียวกับโมเดลตรวจจับยานพาหนะที่ต้องการคุณภาพของภาพที่ดีในการฝึกฝนการจำแนกประเภทยานพาหนะในแต่ละประเภท ดังนั้นงานวิจัยในอนาคตควรมีการคำนึงถึงคุณภาพของเส้นสีจราจรของช่วงถนนที่สำรวจ คุณภาพของภาพจากกล้องวิดีโอและควรคำนึงถึงการติดตั้งอุปกรณ์เสริมเพื่อลดแรงสั่นสะเทือนที่อาจทำให้มุมกล้องหนักรถเกิดการเปลี่ยนแปลงซึ่งอาจเป็นสาเหตุทำให้โมเดลสร้างกรอบพื้นที่ในการจำแนกเกิดความคลาดเคลื่อนและไม่สามารถตรวจจับตำแหน่งของเส้นสีจราจรไหลทางซ้ายจริงของถนนซึ่งเป็นกระบวนการสำคัญในการสร้างกรอบพื้นที่ในการจำแนกได้

2) การใช้เพียงเส้นสีจราจรไหลทางซ้ายในการอ้างอิง และตำแหน่งมุมกรอบและความกว้างของกรอบตั้งต้นในการสร้างกรอบพื้นที่ให้ครอบคลุมทั้งช่องจราจรตลอดการวิ่งสำรวจส่งผลให้การนับและจำแนกยานพาหนะโดยเฉพาะการจำแนกรถบนไหลทางออกจากการคำนวณยังมีประสิทธิภาพต่ำและมีขอบเขตที่ไม่สอดคล้องกับช่วงถนนบริเวณทางโค้ง ดังนั้นงานวิจัยในอนาคตควรมีการพิจารณาเส้นสีจราจรอื่นหรือสิ่งแวดล้อมอื่น ๆ ประกอบในการสร้างหรือปรับใช้อัลกอริทึมที่มีประสิทธิภาพสูงยิ่งขึ้น เช่น เทคนิค Semantic Segmentation ที่มีความสามารถในการจำแนกและระบุตำแหน่งและขอบเขตพื้นที่ของเส้นสีจราจรและวัตถุอื่น ๆ บนถนน เป็นต้น เพื่อให้ได้กรอบพื้นที่ที่ครอบคลุมและสอดคล้องกับช่องจราจรทั้งทางตรงและทางโค้งตลอดการสำรวจและรองรับกรณีที่มีเส้นสีจราจรขาด

หาย ไม่คมชัดหรือถูกบดบังโดยยานพาหนะที่วิ่งผ่าน ทำให้สามารถลดความผิดพลาดในการจำแนกยานพาหนะที่จอดหรือวิ่งบนไหล่ทางและจอดบริเวณขอบถนนและเป็นผลให้ได้ค่าตัวแปรกระจายจรรยาที่มีความคลาดเคลื่อนจากข้อมูลสำรวจจริงที่ลดลง

3) ควรมีการทดลองปรับแต่งพารามิเตอร์และขนาดของโมเดลตรวจจับยานพาหนะ ขนาดของภาพที่ใช้ฝึกฝนโมเดล และทำการเสริมแต่งรูปภาพ (Image Augmentation) เพื่อสร้างโมเดลตรวจจับยานพาหนะที่มีประสิทธิภาพในการจำแนกประเภทยานพาหนะมากยิ่งขึ้น

4) วิธีการสำรวจจราจรโดยการเคลื่อนที่ของยานพาหนะสามารถนำไปใช้ในการประมาณค่าตัวแปรกระจายจราจรกับข้อมูลสำรวจจราจรบนช่วงถนนที่มีลักษณะกายภาพแตกต่างจากวิจัยนี้ได้เช่นกัน ยกตัวอย่างเช่น ถนน 2 ช่องจราจรต่อทิศทาง มีเกาะกลางคั่นระหว่างกลาง มีการวิ่งผ่านทางเชื่อมและทางแยก เป็นต้น งานวิจัยในอนาคตควรมีการพัฒนาด้านเทคโนโลยีปัญญาประดิษฐ์และออกแบบการใช้งานอุปกรณ์สำรวจและบันทึกผลเพื่อให้สามารถนำไปประยุกต์ใช้ในการสำรวจจราจรบนวิธีการสำรวจโดยการเคลื่อนที่ของยานพาหนะบนช่วงถนนในลักษณะกายภาพอื่น ๆ ได้



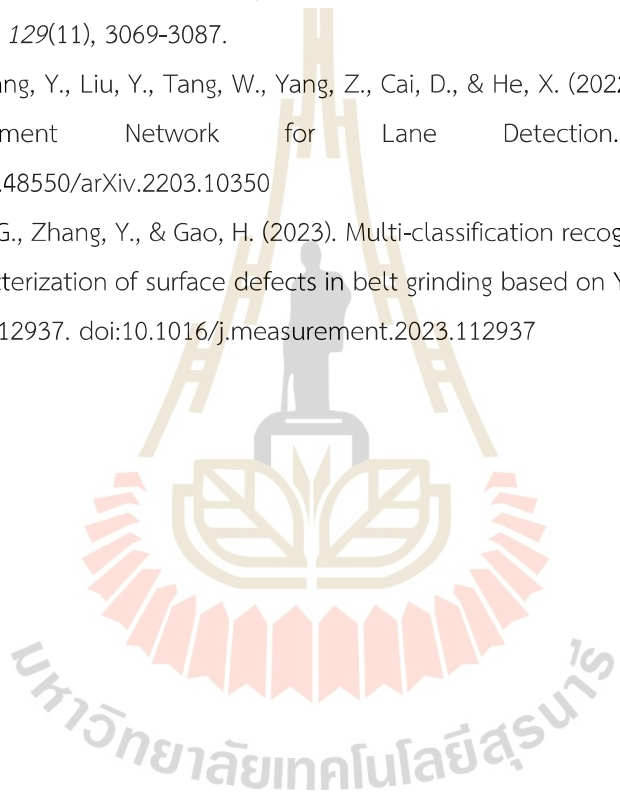
รายการอ้างอิง

- สำนักอำนวยการความปลอดภัย. (2564). รายงานการวิเคราะห์ค่าความถี่การจราจรติดขัดและความหนาแน่นการจราจร ประจำปี 2564. สำนักอำนวยการความปลอดภัย, กรมทางหลวง
- Al-Bahr, T., Puan, O. C., Hassan, S. A., Azhari, S. F., Al-Sabaei, A. M., & Mohammed, H. A. (2021, 2021). *Statistical Evaluation of Moving Observer Method Accuracy for Measuring Traffic Flow Variables on Urban Roads*. Paper presented at the 2021 International Congress of Advanced Technology and Engineering (ICOTEN), Taiz, Yemen.
- Al-Bahr, T. M., Puan, O. C., Hassan, S. A., Idham, M. K., & Ismail, C. R. (2019). Parameters affecting fluctuation in traffic stream on urban roads. *IOP Conference Series: Materials Science and Engineering*, 527(1), 012067. doi:10.1088/1757-899x/527/1/012067
- Alhomaidat, F., & Ardekani, S. (2015). A statistical comparison of traffic measurements from the moving versus stationary observer methods. *Journal of Transportation Technologies*, 5(04), 204.
- Boonsirisumpun, N., & Surinta, O. (2021). Fast and Accurate Deep Learning Architecture on Vehicle Type Recognition. *Current Applied Science and Technology*, 22, 1-16. doi:10.55003/001
- Broström, M. (2022). *Real-time multi-camera multi-object tracker using YOLOv7 and StrongSORT with OSNet*. Retrieved from https://github.com/mikel-brostrom/Yolov7_StrongSORT_OSNet
- Du, Y., Song, Y., Yang, B., & Zhao, Y. (2022). StrongSORT: Make DeepSORT Great Again. *arXiv e-prints*, arXiv:2202.13514. Retrieved from <https://ui.adsabs.harvard.edu/abs/2022arXiv220213514D>
- Garber, N. J., & Hoel, L. A. (2019). *Traffic and highway engineering*: Cengage Learning.
- Greenshields, B., Bibbins, J., Channing, W., & Miller, H. (1934). *A study of traffic capacity*. Paper presented at the Highway research board proceedings.
- Guerrieri, M., & Parla, G. (2021). Deep Learning and YOLOv3 Systems for Automatic Traffic Data Measurement by Moving Car Observer Technique. *Infrastructures*, 6(9), 134. doi:10.3390/infrastructures6090134

- Guerrieri, M., Parla, G., & Mauro, R. (2019). Traffic Flow Variables Estimation: An Automated Procedure Based on Moving Observer Method. Potential Application for Autonomous Vehicles. *Transport and Telecommunication Journal*, 20, 205-214. doi:10.2478/ttj-2019-0017
- Han, C., Zhao, Q., Zhang, S., Chen, Y., Zhang, Z., & Yuan, J. (2022). YOLOPv2: Better, Faster, Stronger for Panoptic Driving Perception. *arXiv preprint arXiv:2208.11434*.
- Huang, X., He, P., Rangarajan, A., & Ranka, S. (2022). Machine-Learning-Based Real-Time Multi-Camera Vehicle Tracking and Travel-Time Estimation. *Journal of Imaging*, 8(4), 101. Retrieved from <https://www.mdpi.com/2313-433X/8/4/101>
- Kumar, A., & Simon, P. (2015). Review of Lane Detection and Tracking Algorithms in Advanced Driver Assistance System. *International Journal of Computer Science and Information Technology*, 7, 65-78. doi:10.5121/ijcsit.2015.7406
- Lawal, O. (2021). Tomato detection based on modified YOLOv3 framework. *Scientific Reports*, 11. doi:10.1038/s41598-021-81216-5
- Lee, B., & Brocklebank, P. (1993). Speed-flow-geometry Relationships for Rural Single Carriageway Roads. TRRL Contractor Report 319. *Transport Research Laboratory, Crowthorne, UK*.
- Li, F., Chen, Y., Hu, M., Luo, M., & Wang, G. (2023). Helmet-Wearing Tracking Detection Based on StrongSORT. *Sensors*, 23, 1682. doi:10.3390/s23031682
- Li, S., Chang, F., Liu, C., & Li, N. (2020). Vehicle counting and traffic flow parameter estimation for dense traffic scenes. *IET Intelligent Transport Systems*, 14(12), 1517-1523. doi:<https://doi.org/10.1049/iet-its.2019.0521>
- Mortimer, W. J. (1957). Moving vehicle method of estimating traffic volumes and speeds. *Highway Research Board bulletin*, 156, 14-26.
- Mulligan, A.-M., & Nicholson, A. (2002). *Uncertainty in traffic flow estimation using the moving-observer method*. Paper presented at the IPENZ Transportation Group Conference Papers, Institution of Professional Engineers New Zealand.
- O'flaherty, C., & Simons, F. (1970). *An evaluation of the moving observer method of measuring traffic speeds and flows*. Paper presented at the Australian Road Research Board (ARRB) Conference, 5th, 1970, Canberra, Australian.
- Pereira, R., Carvalho, G., Garrote, L., & Nunes, U. J. (2022). Sort and Deep-SORT Based Multi-Object Tracking for Mobile Robotics: Evaluation with New Data Association Metrics.

- Applied Sciences*, 12(3), 1319. Retrieved from <https://www.mdpi.com/2076-3417/12/3/1319>
- Priyadharshini, P., Niketha, P., Lakshmi, K. S., Sharmila, S., & Divya, R. (2019, 15-16 Mar. 2019). *Advances in Vision based Lane Detection Algorithm Based on Reliable Lane Markings*. Paper presented at the 2019 5th International Conference on Advanced Computing & Communication Systems Coimbatore, India.
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. doi:10.1109/TPAMI.2016.2577031
- Siddique, S., Islam, S., Neon, E. E., Sabbir, T., Naheen, I. T., & Khan, R. (2023). Deep Learning-based Bangla Sign Language Detection with an Edge Device. *Intelligent Systems with Applications*, 18, 200224. doi:<https://doi.org/10.1016/j.iswa.2023.200224>
- TASM. (2020). *TAG UNIT M3.1: Highway Assignment Modelling*. London: Department for Transport.
- Vykari, N. (2021). *Understanding Hough Transform With A Lane Detection Model*. Retrieved from <https://blog.paperspace.com/understanding-hough-transform-lane-detection/>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2023). *YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors*. Paper presented at the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.
- Wardrop, J. G., & Charlesworth, G. (1954). A Method of Estimating Speed and Flow of Traffic from a Moving Vehicle. *Proceedings of the Institution of Civil Engineers*, 3(1), 158-171.
- Wojke, N., Bewley, A., & Paulus, D. (2017, 17-20 Sept. 2017). *Simple online and realtime tracking with a deep association metric*. Paper presented at the 2017 IEEE International Conference on Image Processing (ICIP), Beijing, China.
- Xiao, B., Guo, J., & He, Z. (2021, 29-31 Oct. 2021). *Real-Time Object Detection Algorithm of Autonomous Vehicles Based on Improved YOLOv5s*. Paper presented at the 2021 5th CAA International Conference on Vehicular Control and Intelligence (CVCI), Tianjin, China.
- Xiao, Y., Tian, Z., Yu, J., Zhang, Y., Liu, S., Du, S., & Lan, X. (2020). A review of object detection based on deep learning. *Multimedia Tools and Applications*, 79(33), 23729-23791. doi:10.1007/s11042-020-08976-6

- Yang, F., Zhang, X., & Liu, B. (2022). Video object tracking based on YOLOv7 and DeepSORT. *arXiv preprint arXiv:2207.02696*. doi:10.48550/ARXIV.2207.12202
- Yeh, K. H., Hsu, I. C., Chou, Y. Z., Chen, G. Y., & Tsai, Y. S. (2022, 3-6 Nov. 2022). *An Aerial Crowd-Flow Analyzing System for Drone Under YOLOv5 and StrongSort*. Paper presented at the 2022 International Automatic Control Conference (CACs), Kaohsiung, Taiwan.
- Zhang, Y., Wang, C., Wang, X., Zeng, W., & Liu, W. (2021). Fairmot: On the fairness of detection and re-identification in multiple object tracking. *International Journal of Computer Vision*, 129(11), 3069-3087.
- Zheng, T., Huang, Y., Liu, Y., Tang, W., Yang, Z., Cai, D., & He, X. (2022). CLRNet: Cross Layer Refinement Network for Lane Detection. arXiv:2203.10350. doi:10.48550/arXiv.2203.10350
- Zhu, B., Xiao, G., Zhang, Y., & Gao, H. (2023). Multi-classification recognition and quantitative characterization of surface defects in belt grinding based on YOLOv7. *Measurement*, 216, 112937. doi:10.1016/j.measurement.2023.112937



ประวัติผู้เขียน

นายพงศกร เปรมศรี เกิดเมื่อวันที่ 3 เดือนพฤษภาคม พ.ศ. 2538 จังหวัดชลบุรี สำเร็จการศึกษาระดับชั้นมัธยมศึกษาจากโรงเรียนศรีราชา อำเภอศรีราชา จังหวัดชลบุรี ในปีการศึกษา 2555 สำเร็จการศึกษาระดับปริญญาตรีจากสำนักวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่งและโลจิสติกส์ มหาวิทยาลัยเทคโนโลยีสุรนารีในปีการศึกษา 2560 และในปีการศึกษา 2562 ได้ศึกษาต่อในระดับปริญญาโท สำนักวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี

ขณะที่กำลังศึกษานั้นได้มีโอกาสเป็นผู้สอนปฏิบัติการ สาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี จำนวน 2 รายวิชา ได้แก่ (1) ปฏิบัติการวิเคราะห์อุปสงค์การเดินทาง (TRAVEL DEMAND ANALYSIS LABORATORY) (2) การจำลองในงานขนส่งและโลจิสติกส์ (SIMULATION AND TRANSPORTATION AND LOGISTICS) ตลอดระยะเวลาที่ศึกษา และเป็นผู้ช่วยวิจัยในโครงการศึกษาและวิเคราะห์ด้านการจราจรและขนส่งต่าง ๆ ในระหว่างการศึกษา



มหาวิทยาลัยเทคโนโลยีสุรนารี