

โครงการข้อมูลจากอากาศยานไร้คนขับเพื่อตรวจติดตามข้อมูลปริมาณจราจรและการจัดทำแผนที่เชิงวิศวกรรม UAV-Assisted Traffic Surveillance with Anchor-Free Object Detector and Tracking

ศุภกฤต อยู่เย็น^{1,*} วิฑิต ปานสุข² พีรพล สิทธิวิจารณ์³ พชร กิจจาเจริญชัย⁴ และธีรดา รุ่งเรืองเจริญสุข⁵

^{1,2} ศูนย์เชี่ยวชาญเฉพาะทางนวัตกรรมการก่อสร้าง ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย กรุงเทพมหานคร

^{3,4} คณะโลจิสติกส์ มหาวิทยาลัยบูรพา กรุงเทพมหานคร

⁵ กรมทางหลวง กระทรวงคมนาคม

*Corresponding author; E-mail address: Suphakrit.yoo@gmail.com

บทคัดย่อ

โครงการนี้มีวัตถุประสงค์ในการศึกษาการประยุกต์ใช้อากาศยานไร้คนขับ (UAV) เพื่อการเก็บข้อมูลปริมาณจราจร และการจัดทำแผนที่เชิงวิศวกรรมในพื้นที่รับผิดชอบของกรมทางหลวง โดยได้ดำเนินการเก็บข้อมูลจากกล้อง UAV และกล้องภาคพื้น เพื่อนำมาวิเคราะห์ข้อมูลปริมาณจราจร ความเร็ว ความหนาแน่น รวมถึงการประมวลผลภาพถ่ายทางอากาศ เพื่อสร้างแผนที่ภูมิประเทศอย่างละเอียด โครงการได้ทดสอบการบิน UAV ในหลากหลายรูปแบบพื้นที่ ผลลัพธ์สนับสนุนแนวทางการพัฒนาระบบการเก็บข้อมูลจราจรและการทำแผนที่เชิงวิศวกรรมในอนาคต

คำสำคัญ: อากาศยานไร้คนขับ, การเฝ้าระวังจราจร, การจำแนกวัตถุ, การติดตามวัตถุ

Abstract

This project aims to study the application of unmanned aerial vehicles (UAVs) for traffic data collection and engineering mapping within the Department of Highways' responsibility areas. Data were gathered from UAV-mounted cameras and ground-based cameras to analyze traffic volume, speed, and density, as well as aerial imagery processing for detailed mapping. Various UAV flight experiments were conducted over road segments, intersections, and roundabouts. The results support the development of traffic surveillance and engineering mapping systems in the future.

Keywords: UAV, traffic surveillance, object detection, object tracking

1. คำนำ

การเก็บข้อมูลจราจรมีความสำคัญอย่างยิ่งต่อการวางแผนและออกแบบโครงสร้างพื้นฐานด้านคมนาคม การศึกษาพฤติกรรมของยานพาหนะ ความหนาแน่น และปริมาณจราจร จำเป็นต้องอาศัยข้อมูลที่แม่นยำและทันสมัย

ในปัจจุบัน เทคโนโลยีอากาศยานไร้คนขับ (UAV) หรือโดรน ได้กลายมาเป็นเครื่องมือสำคัญในการเก็บข้อมูลจราจร ด้วยข้อดีที่สามารถบินได้ยืดหยุ่น เข้าถึงพื้นที่ได้หลากหลาย และสามารถเก็บข้อมูลจากมุมสูงที่ให้รายละเอียดได้ดีกว่ากล้องภาคพื้นดินแบบเดิม

อย่างไรก็ตาม การนำข้อมูลวิดีโอจาก UAV มาใช้ในการวิเคราะห์ปริมาณจราจร จำเป็นต้องอาศัยเทคนิคการประมวลผลภาพที่มีประสิทธิภาพ เพื่อให้สามารถตรวจจับและติดตามยานพาหนะในสภาพแวดล้อมจริงได้อย่างแม่นยำ ในช่วงไม่กี่ปีที่ผ่านมา เทคโนโลยีการตรวจจับวัตถุแบบ deep learning มีการพัฒนาอย่างรวดเร็ว โดยเฉพาะอย่างยิ่ง การตรวจจับวัตถุแบบไม่ใช้ anchor (anchor-free object detection) ซึ่งช่วยลดความซับซ้อนในการตั้งค่ากรอบ anchor box และสามารถเพิ่มความแม่นยำในการตรวจจับได้

โครงการนี้จึงมีวัตถุประสงค์เพื่อศึกษาการประยุกต์ใช้เทคนิคการตรวจจับวัตถุแบบไม่ใช้ anchor ร่วมกับข้อมูลวิดีโอจาก UAV เพื่อพัฒนาระบบการตรวจจับและติดตามยานพาหนะในงานเฝ้าระวังจราจร และประเมินประสิทธิภาพของระบบในสภาพแวดล้อมจริง อันจะนำไปสู่การยกระดับการวิเคราะห์ข้อมูลจราจรและสนับสนุนการวางแผนโครงสร้างพื้นฐานในอนาคต

2. งานวิจัยที่เกี่ยวข้อง

ความพยายามวิจัยก่อนหน้านี้เกี่ยวกับการเฝ้าระวังและควบคุมการจราจรโดยใช้ UAV ส่วนใหญ่เกี่ยวข้องกับการพัฒนาแบบจำลองทางคณิตศาสตร์ แบบจำลองที่ถูกสร้างขึ้น เช่น Greenshields, Underwood, Greenberg และ Daganzo ถูกนำมาใช้เพื่อวิเคราะห์ลักษณะการจราจร เช่น ความหนาแน่น อัตราการไหล และความเร็ว อย่างไรก็ตาม ความแม่นยำของแบบจำลองเหล่านี้จะแตกต่างกันไปตามสภาพถนน รูปแบบการไหลของการจราจร และระดับความแออัด เพื่อให้ตรงตามข้อกำหนดของแบบจำลองเหล่านี้ จำเป็นต้องมีข้อมูลขนาดใหญ่และการเก็บข้อมูลต่อเนื่อง เช่น การติดตั้งอุปกรณ์ตรวจจับล่วงหน้าเพื่อตรวจสอบตัวแปรอย่างง่ายสองในสามตัว ซึ่งมีค่าใช้จ่ายสูงทั้งในการเก็บข้อมูลและการวิเคราะห์ข้อมูล

2.1 งานทบทวนทฤษฎี และงานวิจัยเกี่ยวกับ UAV ด้านการจราจร

การนำอากาศยานไร้คนขับ (UAV) มาใช้ในงานด้านการจราจรได้เพิ่มขึ้นอย่างต่อเนื่องในช่วงไม่กี่ปีที่ผ่านมา UAV มีศักยภาพในการเก็บข้อมูลที่มีความละเอียดสูง ครอบคลุมพื้นที่กว้างในเวลาอันสั้น และสามารถเข้าถึงพื้นที่ที่ยากต่อการติดตั้งเซ็นเซอร์ภาคพื้นดินได้ งานวิจัยต่าง ๆ ได้นำ UAV มาประยุกต์ใช้เพื่อตรวจจับและติดตามยานพาหนะในสภาพแวดล้อมจริง วิเคราะห์ความหนาแน่น ความเร็ว และปริมาณการจราจร ทั้งนี้เทคนิคที่ใช้ร่วมกับ UAV ได้แก่ การประมวลผลภาพถ่ายทางอากาศ การวิเคราะห์การเคลื่อนที่ของวัตถุ และการใช้โครงข่ายประสาทเทียม (Neural Networks)

อย่างไรก็ตาม UAV มีข้อจำกัดด้านระยะเวลาบิน (เนื่องจากข้อจำกัดของแบตเตอรี่) ความเสถียรในการบินในสภาพลมแรง และข้อกำหนดทางกฎหมายในการใช้งานในเขตเมือง ดังนั้นการวางแผนการบิน การเลือกอุปกรณ์ และการออกแบบภารกิจต้องพิจารณาอย่างรอบคอบ เพื่อให้ได้ข้อมูลที่มีคุณภาพเหมาะสมกับการนำไปวิเคราะห์จราจร

2.2 งานทบทวนการใช้ UAV ด้านสำรวจ ออกแบบ และแผนที่เชิงวิศวกรรม

2.2.1 การประยุกต์ใช้การรังวัดด้วยภาพถ่าย

การรังวัดด้วยภาพถ่ายทางอากาศ (Photogrammetry) จาก UAV เป็นวิธีที่ได้รับความนิยมสูง สามารถสร้างแผนที่ภูมิประเทศแบบสองมิติและสามมิติได้อย่างแม่นยำ โดยใช้การถ่ายภาพซ้อนกันหลายมุม (Overlap) และประมวลผลด้วยซอฟต์แวร์เฉพาะทาง เช่น Pix4D, Agisoft Metashape ภาพถ่ายเหล่านี้สามารถนำมาสร้าง Orthoimage และแบบจำลองภูมิประเทศที่มีความละเอียดสูง ใช้ในงานวางแผนออกแบบโครงการได้อย่างแม่นยำ

2.2.2 การประยุกต์ใช้แบบจำลองพื้นผิวสามมิติ (3D Surface Model)

การสร้างแบบจำลองพื้นผิวสามมิติจากข้อมูล UAV ช่วยในการวิเคราะห์ลักษณะภูมิประเทศ เช่น ความลาดชัน ความสูงต่ำของพื้นที่ และการคำนวณปริมาตรดิน/วัสดุ แบบจำลอง DSM และ DTM เป็นพื้นฐานสำคัญในการออกแบบงานถนน เขื่อน อาคาร และโครงการวิศวกรรมอื่น ๆ โดยช่วยลดข้อผิดพลาดจากการสำรวจแบบดั้งเดิม และเพิ่มความเร็วในการประมวลผลข้อมูล

2.2.3 การประยุกต์ใช้กับงานชลศาสตร์

ในงานชลศาสตร์ UAV ถูกนำมาใช้เพื่อสำรวจพื้นที่ลุ่มน้ำ วิเคราะห์ลักษณะทางน้ำ เช่น ลำน้ำตื้น เขื่อน หรือพื้นที่เสี่ยงน้ำท่วม ข้อมูลภูมิประเทศที่ได้จาก UAV ช่วยในการจำลองการไหลของน้ำ (Hydraulic Modeling) เช่น HEC-RAS หรือ SWMM เพื่อวางแผนป้องกันน้ำท่วม การก่อสร้างระบบระบายน้ำ และการวิเคราะห์ผลกระทบจากโครงการพัฒนาโครงสร้างพื้นฐาน

2.2.4 การประยุกต์ใช้กับงานดิน

ข้อมูลจาก UAV สามารถนำมาใช้ประเมินเสถียรภาพของลาดดิน ตรวจสอบการกัดเซาะ การเคลื่อนตัวของดิน หรือการทรุดตัวของพื้นที่ได้อย่างมีประสิทธิภาพ ตัวอย่างเช่น การสร้าง Cut-Fill Map เพื่อวิเคราะห์พื้นที่ต้องถม/ตัดดินในการก่อสร้างโครงการโยธา

2.2.5 การทำ Profile & Cross Section

ภาพถ่าย UAV สามารถนำไปสร้างเส้นตัดขวาง (Cross Section) และเส้นแนวยาว (Profile) สำหรับการออกแบบถนน ระบบระบายน้ำ หรือโครงการวางท่อได้อย่างแม่นยำ ซึ่งช่วยลดระยะเวลาในการสำรวจภาคพื้นแบบเดิม และลดต้นทุนของโครงการ

2.2.6 การใช้ในงานอาคารและสิ่งปลูกสร้าง

UAV ถูกนำมาใช้ในการตรวจสอบอาคารสูง สะพาน เขื่อน และสิ่งปลูกสร้างขนาดใหญ่ โดยช่วยให้สามารถเข้าถึงพื้นที่อันตรายหรือเข้าถึงยากได้โดยไม่ต้องใช้อุปกรณ์ปีนไต่ การตรวจสอบด้วย UAV สามารถตรวจหาความเสียหาย เช่น รอยแตกร้าว หรือการเสื่อมสภาพของวัสดุได้อย่างรวดเร็วและปลอดภัย

2.3 งานพัฒนาวิธีการหรือแนวทางการประยุกต์ใช้ UAV

จากการทบทวนงานวิจัยพบว่า การประยุกต์ใช้ UAV ในงานวิศวกรรมจราจรและงานแผนที่เชิงวิศวกรรมยังมีช่องว่างที่สามารถพัฒนาเพิ่มเติมได้ทั้งในด้านวิธีการเก็บข้อมูล การประมวลผล และการนำข้อมูลไปวิเคราะห์ในรูปแบบที่เหมาะสมกับลักษณะของโครงการในแต่ละประเภท

2.3.1 การประยุกต์ใช้ในงานวิศวกรรมจราจร

การใช้ UAV ในงานจราจรประกอบด้วย การเก็บข้อมูลปริมาณจราจร การวิเคราะห์รูปแบบการไหลของยานพาหนะ การศึกษาความหนาแน่นและความเร็ว รวมถึงการจำแนกประเภทของยานพาหนะที่แตกต่างกัน งานวิจัยหลายชิ้นได้พัฒนาอัลกอริทึมตรวจจับวัตถุ เช่น YOLO, CenterNet หรือ Faster R-CNN เพื่อเพิ่มประสิทธิภาพการตรวจจับยานพาหนะจากวิดีโอ UAV

นอกจากนี้ ยังมีการนำเทคนิค Optical Flow และ Tracking Algorithms มาใช้ติดตามการเคลื่อนที่ของยานพาหนะ เพื่อคำนวณค่าพารามิเตอร์จราจรอย่างแม่นยำ เช่น ความเร็วเฉลี่ย ความหนาแน่น และอัตราการไหล


2.3.2 การจัดทำแผนที่เชิงวิศวกรรม

การจัดทำแผนที่เชิงวิศวกรรมด้วย UAV มีความสำคัญอย่างยิ่งในการสนับสนุนงานออกแบบและก่อสร้างโครงการทางหลวง โครงการระบบสาธารณูปโภค และโครงการผังเมือง ข้อมูลที่ได้สามารถนำไปใช้สร้างแผนที่ฐาน (Base Map) แผนที่เส้นทาง (Alignment Map) และแผนที่ระดับความสูง (Elevation Map) อย่างละเอียด ซึ่งส่งผลโดยตรงต่อความแม่นยำของการออกแบบและการประเมินต้นทุนโครงการ

3. ระเบียบวิธีการศึกษาโครงการ

3.1 ภาพรวม

กรอบแนวคิดทั่วไปของระบบการเฝ้าระวังจราจรด้วยอากาศยานไร้คนขับ (UAV) ที่นำเสนอในการศึกษานี้ แสดงไว้ในรูปที่ 3.1 โครงสร้างของระบบสามารถแบ่งออกได้เป็นสามชั้นหลัก ได้แก่ ชั้นแรก ครอบคลุมกระบวนการประมวลผลข้อมูลตั้งแต่ภาพวิดีโอจาก UAV โดยตรง โดยอาศัยระบบกันสั่นในตัว (gimbal) เพื่อช่วยให้การประมวลผลวิดีโอเป็นไปอย่างราบรื่น ก่อนที่จะผ่านเข้าสู่โมเดลตรวจจับที่ได้รับการฝึกฝนมาแล้ว เพื่อจำแนกประเภทและนับจำนวนยานพาหนะ ชั้นที่สอง หลังจากที่ได้ข้อมูลองค์ประกอบของยานพาหนะแล้ว จะดำเนินการติดตามการเคลื่อนที่ของยานพาหนะในแต่ละเฟรม เพื่อเก็บข้อมูลเกี่ยวกับเวลาเดินทาง (travel time) ของยานพาหนะเมื่อเข้าสู่พื้นที่ที่กำหนด (จากจุดต้นน้ำไปยังจุดปลายน้ำ) และนำไปใช้ในการคำนวณความเร็วเฉลี่ยเชิงพื้นที่ (space-mean speed) ชั้นที่สาม นำทฤษฎีการไหลของจราจรเข้ามาประยุกต์ใช้ โดยใช้ไดอะแกรมเวลา-ระยะทาง (time-space diagram) และกราฟสะสม (cumulative diagram) เพื่อประมาณความยาวของแถวยานพาหนะ (queue length) และระยะเวลาความล่าช้า (delay)




รูปที่ 1 โครงสร้างแกนหลัก 3 ชั้นของระบบเฝ้าระวังจราจรด้วยอากาศยานไร้คนขับ

3.2 การเก็บข้อมูล

ในการศึกษานี้ ได้มีการคัดเลือกพื้นที่ศึกษา จำนวน 31 จุด โดยแต่ละจุดได้รับการเลือกสรรตามปัจจัยผสมผสานหลายด้าน ได้แก่ ระดับการให้บริการ (Level of Service), ลักษณะการใช้งานของทางหลวง, สภาพภูมิประเทศโดยรอบ และสภาพแวดล้อมที่มีสิ่งปลูกสร้าง พื้นที่ศึกษาดังกล่าวครอบคลุมรูปแบบโครงสร้างพื้นฐานด้านคมนาคมที่หลากหลาย เช่น ทางหลวงสายหลัก ทางด่วน จุดตัดทางแยก และทางแยกหลายระดับ

กระบวนการเก็บข้อมูลประกอบด้วย การนับปริมาณยานพาหนะในลักษณะการเลี้ยว (Turning Movement Counts: TMC) และการนับจำแนกประเภทของยานพาหนะในช่วงกลางทาง (Mid-block Classified Counts: MBC) นอกจากนี้ ยังมีการติดตั้งอุปกรณ์ภาคพื้นเสริม (Supplementary Field Equipment) ได้แก่ กล้องวิดีโอภาคพื้น และเครื่องวัดความเร็วด้วยแสงเลเซอร์ เพื่อใช้เป็นข้อมูลอ้างอิง (Benchmark) ในการประเมินประสิทธิภาพของแนวทางการเก็บข้อมูลที่ใช้ UAV



รูปที่ 2 พื้นที่ศึกษาเป้าหมาย

นําส่งเกตว่า การศึกษานี้มุ่งเน้นไปที่ประเภทยานพาหนะหลัก 3 กลุ่ม ซึ่งพบได้บ่อยในโครงข่ายถนนของประเทศไทย และมีความเหมาะสมต่อการวิเคราะห์ภายใต้บริบทของโมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ได้แก่ รถยนต์ส่วนบุคคล รถจักรยานยนต์ และยานพาหนะขนาดใหญ่ (รถบรรทุกและรถโดยสาร)

การจำกัดขอบเขตให้ครอบคลุมเพียง 3 ประเภทหลักนี้ มีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพและความแม่นยำของโมเดลในการตรวจจับและจำแนกแบบแผนการไหลของจราจรในพื้นที่ศึกษาเป้าหมาย

ตารางที่ 1 ข้อมูลจำนวนยานพาหนะในพื้นที่ศึกษา

	การนับจำนวนยานพาหนะ			ทั้งหมด
	รถยนต์	รถจักรยานยนต์	รถขนาดใหญ่	
ช่วงถนน, หลายเลน	102,785	27,230	6,654	136,669
ช่วงถนน, เลนเดียว	1,605	252	61	1,918
ทางแยกต่างระดับ	19,942	4,425	2,852	27,219
ทางแยก	3,335	1,899	143	5,377

ตารางที่ 2 การกระจายน้ำหนักของยานพาหนะ

	การกระจายน้ำหนักของยานพาหนะ		
	รถยนต์	รถจักรยานยนต์	รถขนาดใหญ่
ช่วงถนน, หลายเลน	0.752	0.199	0.048
ช่วงถนน, เลนเดียว	0.837	0.131	0.032
ทางแยกต่างระดับ	0.733	0.163	0.105
ทางแยก	0.62	0.353	0.026

ข้อมูล UAV


ตารางที่ 3 รายละเอียดคุณลักษณะของอากาศยานไร้คนขับ

UAV	Phantom 4 Pro	DJI Air2S
ระยะเวลาการบิน	30 min	31 min
ระยะทาง	7 km	12 km
เซนเซอร์	CMOS 1"	CMOS 1"
	4K/60 fps video	5.4K/30 fps
แบตเตอรี่	5,870 mAh	3,500 mAh
ความละเอียดของภาพ	3840 x 2160	5472 x 3078


เพื่อให้ได้ข้อมูลภาพวิดีโอสำหรับการเฝ้าระวังการจราจรจากอากาศยานไร้คนขับ (UAV) การศึกษานี้ได้ดำเนินการเก็บข้อมูลวิดีโอเป็นระยะเวลา 360 นาทีต่อพื้นที่ศึกษาแต่ละแห่ง โดยในแต่ละเที่ยวบินมีการกำหนดให้ใช้ระยะเวลาบินอย่างน้อย 15 นาที ก่อนทำการชาร์จแบตเตอรี่ของ UAV ใหม่ ทั้งนี้ ทุกเที่ยวบินดำเนินการภายในเขตน่านฟ้าที่ได้รับอนุญาต และหลีกเลี่ยงสิ่งกีดขวางที่อาจเกิดขึ้นในบริเวณพื้นที่ปฏิบัติงาน

การเก็บข้อมูลดำเนินการในช่วงเวลาเร่งด่วน ได้แก่ เวลา 08:00 – 10:00 น. เวลา 11:00 – 13:00 น. และเวลา 16:00 – 18:00 น. แนวทางดังกล่าวมีวัตถุประสงค์เพื่อให้สามารถครอบคลุมลักษณะและรูปแบบของการจราจรในช่วงที่มีความหนาแน่นสูงอย่างรอบด้าน

ระหว่างการบิน UAV ได้ใช้งานกลไกกันสั่น (Stabilization Mechanism) โดยติดตั้งระบบ Gimbal ภายใน เพื่อให้สามารถบันทึกภาพวิดีโอได้อย่างราบรื่นและมั่นคง แม้ในสภาวะที่มีลมแรงในบางพื้นที่ นอกจากนี้ ได้มีการทดลองบิน UAV ที่ระดับความสูงต่างกัน 3 ระดับ ได้แก่ 50 เมตร, 70 เมตร และ 90 เมตร พร้อมทั้งปรับมุมกล้องในมุมที่แตกต่างกัน ได้แก่ 30, 45, 70 และ 90 องศา วิธีการดังกล่าวช่วยให้สามารถเก็บข้อมูลจากมุมมองที่หลากหลาย ส่งผลให้เกิดความเข้าใจเชิงลึกมากขึ้นเกี่ยวกับศักยภาพของ UAV รวมถึงโมเดลการตรวจจับและติดตามวัตถุตามที่แสดงในรูปที่ 3 และ 4



รูปที่ 3 มุมกล้องต่าง ๆ ของ UAV ที่ระดับความสูง 90 เมตร บินเหนือทางแยกที่มีสัญญาณไฟจราจร เพื่อเก็บข้อมูลการนับยานพาหนะตามทิศทางการเลี้ยว (TMC)



รูปที่ 4 มุมกล้องต่าง ๆ ของ UAV ที่ระดับความสูง 90 เมตร ชนปะปนเหนือช่วงกลางทางถนน เพื่อการนับจำนวนประเภทของยานพาหนะในช่วงกลางทาง

3.3 การตรวจจับวัตถุ (Object Detection)

YOLOv8

เทคโนโลยีการตรวจจับวัตถุแบบ You Only Look Once (YOLO) ถูกพัฒนาขึ้นครั้งแรกโดย Joseph Redmon และ Ali Farhadi ในปี พ.ศ. 2558 (2015) โดยในช่วงแรก YOLO อาศัยโครงสร้างแบบลำดับชั้นของโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Networks) ในลักษณะพีระมิดจากบนลงล่าง (Top-Down Pyramid Architecture) เพื่อเพิ่มประสิทธิภาพในการจัดการกับลักษณะที่ซับซ้อนของวัตถุ และช่วยเสริมความสามารถในการเรียนรู้ของโมเดลโดยรวม ตั้งแต่นั้นเป็นต้นมา YOLO ได้รับการพัฒนาและปรับปรุงอย่างต่อเนื่องในหลายเวอร์ชัน ได้แก่ YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6 และ YOLOv7

ในโครงข่ายคอนโวลูชันมาตรฐาน (Standard CNNs) การดึงคุณลักษณะมักเกิดขึ้นที่ระดับสเกลเดียว ซึ่งจำกัดความสามารถในการตรวจจับวัตถุที่มีขนาดแตกต่างกันอย่างหลากหลาย อย่างไรก็ตาม YOLOv7 ได้มีการนำฟังก์ชัน "Focal Loss" เข้ามาใช้ เพื่อแก้ไขปัญหาความไม่สมดุลของกลุ่มข้อมูล (Class Imbalance) ซึ่งเป็นปัญหาที่พบในงานวิจัยก่อนหน้านี้ ที่ชุดข้อมูลขาดความหลากหลายของประเภทยานพาหนะ ฟังก์ชัน Focal Loss ช่วยให้น้ำหนักมากขึ้นกับตัวอย่างที่ตรวจจับได้ยาก และลดอิทธิพลของคลาสที่มีจำนวนมากเกินไปในชุดข้อมูล วิธีการนี้สอดคล้องกับการฝึกการตรวจจับในงานวิจัยนี้ เนื่องจากข้อมูลที่เก็บมาในแต่ละหมวดหมู่มีความไม่สมดุลกัน (ตามที่แสดงในตารางที่ 1) YOLOv8 ถือเป็นรุ่นล่าสุดของโมเดลการตรวจจับวัตถุที่มีความแม่นยำสูงและผ่านการพัฒนามาอย่างต่อเนื่อง โดยมีโครงสร้างพื้นฐาน (Backbone) ที่ใช้สถาปัตยกรรม CSPDarknet53 ซึ่งเน้นการรวมคุณลักษณะข้ามชั้น (Cross-Stage Feature Aggregation) เพื่อเสริมความสามารถในการแทนคุณลักษณะของวัตถุ เครือข่ายโครงข่ายได้รับการออกแบบให้สามารถจับข้อมูลในระดับนามธรรมที่หลากหลาย ตั้งแต่คุณลักษณะระดับต่ำไปจนถึงระดับสูง

ความโดดเด่นอีกประการหนึ่งของ YOLOv8 คือการนำแนวคิดการตรวจจับแบบไม่ใช้ Anchor (Anchor-Free Detection) เข้ามาใช้งาน

หมายความว่า โมเดลจะทำการคาดการณ์ตำแหน่งศูนย์กลางของวัตถุโดยตรง โดยไม่ต้องพึ่งพากรอบ Anchor Boxes แบบรุ่นก่อนหน้า ซึ่ง Anchor Boxes คือกรอบสี่เหลี่ยมที่กำหนดไว้ล่วงหน้าด้วยอัตราส่วนความสูงและความกว้างเฉพาะ สำหรับล้อมกรอบวัตถุที่ต้องการตรวจจับ การเลือก Anchor Boxes ในอดีตต้องอิงกับขนาดวัตถุในชุดข้อมูลฝึกสอน ทำให้แนวทางแบบ Anchor-Free ช่วยให้โมเดลมีความยืดหยุ่นและมีประสิทธิภาพสูงขึ้นในงานตรวจจับวัตถุ

ดังนั้น ในการศึกษา โมเดล YOLOv8 จึงถูกปรับแต่งเพิ่มเติม (Fine-tuned) ด้วยชุดข้อมูลยานพาหนะที่เก็บรวบรวมมาใหม่ เพื่อเพิ่มความแม่นยำและประสิทธิภาพสูงสุด โมเดลที่ได้รับการพัฒนานี้ทำหน้าที่เป็นกรอบโครงสร้างหลักในการตรวจจับและสกัดค่าพารามิเตอร์การจราจรในงานวิจัยครั้งนี้


3.4 การติดตามวัตถุ (Object Tracking)

BoT-SORT

BoT-SORT เป็นอัลกอริทึมล้ำสมัย (State-of-the-Art) สำหรับการติดตามวัตถุ โดยมีเป้าหมายเพื่อการติดตามวัตถุหลายรายการ (Multi-object tracking) ภายในฉากเดียวกัน พร้อมทั้งรักษาหมายเลขประจำตัวที่ไม่ซ้ำกันของวัตถุแต่ละชิ้นตลอดช่วงเวลาปรากฏในเฟรม

อัลกอริทึม BoT-SORT ผสานข้อได้เปรียบทั้งในด้านข้อมูลการเคลื่อนไหว (Motion) และลักษณะปรากฏของวัตถุ (Appearance) เข้าด้วยกัน โดยใช้เวกเตอร์สถานะของ Kalman Filter ที่ได้รับการปรับปรุงให้แม่นยำยิ่งขึ้น ช่วยให้สามารถคาดการณ์ตำแหน่งของวัตถุในเฟรมถัดไปได้อย่างต่อเนื่อง แม้ในกรณีที่มีการบังกันหรือความไม่ต่อเนื่องในการตรวจจับ

ด้วยการผสมผสานข้อมูลทั้งเชิงตำแหน่งและรูปลักษณ์ BoT-SORT สามารถลดความผิดพลาดในการเชื่อมโยงเส้นทางการเคลื่อนที่ของวัตถุได้อย่างมีประสิทธิภาพ โดยเฉพาะในสภาพแวดล้อมที่มีความแออัด เช่น การจราจรที่มีความหนาแน่นสูง



รูปที่ 6 ภาพรวมของกระบวนการติดตามวัตถุด้วย BoT-SORT-ReID

4. ผลการศึกษาและอภิปรายผล

การประเมินผลการตรวจจับและติดตามวัตถุ

เมทริกซ์ความสับสน (Confusion Matrix)

แนวคิดของเมทริกซ์ความสับสน (Confusion Matrix) ถูกนำมาใช้เพื่อประเมินประสิทธิภาพของทั้งการตรวจจับวัตถุและการติดตามวัตถุ โดยการเปรียบเทียบผลลัพธ์จากโมเดลกับข้อมูลจริง (Ground Truth) เมทริกซ์ความสับสนประกอบด้วยองค์ประกอบหลัก 4 ประการ ได้แก่ True Positives (TP) หมายถึง ยานพาหนะที่ถูกจำแนกอย่างถูกต้องตามประเภทของตนเอง, True Negatives (TN) หมายถึง ยานพาหนะที่ไม่ได้ถูกจำแนกเข้าไปในประเภทใด ๆ และยานพาหนะนั้นไม่ได้อยู่ในประเภทนั้นจริง,

False Positives (FP) หมายถึง ยานพาหนะที่ถูกจำแนกผิดไปยังประเภทอื่น, และ False Negatives (FN) หมายถึง ยานพาหนะที่ควรถูกจำแนกแต่กลับถูกระบุว่าไม่มีการตรวจจับ (negative)

นอกจากนี้ การประเมินผลการติดตามวัตถุยังใช้ดัชนี Multiple Object Tracking Accuracy (MOTA) ซึ่งนิยามใช้กันอย่างแพร่หลาย เพื่อประเมินประสิทธิภาพการติดตามเส้นทางของยานพาหนะภายในพื้นที่ที่สนใจ (ROI) พร้อมทั้งวิเคราะห์การปฏิสัมพันธ์ของยานพาหนะภายในภาพวิดีโอ ปัจจัยเพิ่มเติมที่นำมาใช้ประเมินได้แก่ IDSW (ID Switch) คือการสลับหมายเลขระบุตัวตนไปยังยานพาหนะคันอื่น อันเกิดจากความสับสนระหว่างยานพาหนะ, Missed Targets คือจำนวนครั้งที่ระบบสูญเสียการติดตามยานพาหนะใน ROI ซึ่งมักเกิดจากการเปลี่ยนมุมมองเนื่องจากการเคลื่อนที่แบบเลี้ยว และ GT (Ground Truth) คือจำนวนยานพาหนะจริงทั้งหมดภายใน ROI

เมื่อกำหนดนิยามของ TP, TN, FP และ FN แล้ว ความแม่นยำของโมเดลการจำแนกประเภทสามารถคำนวณและประเมินประสิทธิภาพได้ดังที่แสดงในตารางที่ 4

ตารางที่ 4 เกณฑ์การประเมินผล

เกณฑ์การประเมิน	สูตรการคำนวณ	คำอธิบาย
ความแม่นยำเชิงบวก (Precision)	$P = \frac{TP}{TP + FP}$	อัตราส่วนของ TP ต่อจำนวนตัวอย่างที่ถูกจำแนกเป็นบวกทั้งหมด
ความแม่นยำเชิงบวก (Precision)	$P = \frac{TP}{TP + FP}$	อัตราส่วนของ TP ต่อจำนวนตัวอย่างที่ถูกจำแนกเป็นบวกทั้งหมด
อัตราการตรวจจับ (Recall)	$R = \frac{TP}{TP + FN}$	อัตราส่วนของ TP ต่อจำนวนตัวอย่างบวกจริงทั้งหมด
ค่าคะแนนเฉลี่ย (F1-Score)	$F1 = \frac{2 \cdot P \cdot R}{P + R}$	ค่าเฉลี่ยฮาร์โมนิกระหว่างค่า Precision และ Recall
ความแม่นยำการติดตามหลายวัตถุ (MOTA)	$MOTA = 1 - \frac{\sum_t (FN_t + FP_t + IDSW_t)}{\sum_t GT_t}$	ความแม่นยำของการติดตามวัตถุหลายรายการตลอดช่วงเวลาที่มีการตรวจจับต่อเนื่อง

ผลการประเมินประสิทธิภาพของโมเดลแสดงในตารางที่ 5 ชุดข้อมูลที่ใช้ในการศึกษานี้ประกอบด้วยลักษณะทางกายภาพและรูปแบบทางเรขาคณิตของถนนที่หลากหลาย เพื่อเลียนแบบสภาพจริงของโครงข่ายทางหลวงและเส้นทางในเขตเมือง ตัวอย่างพื้นที่ศึกษาได้แก่ พื้นที่ใจกลางเมืองเขตศูนย์กลางธุรกิจ และทางหลวงระหว่างรัฐ

การตั้งค่าการฝึกสอนโมเดล YOLOv8 ใช้ขนาดแบตช์ (Batch Size) เท่ากับ 64 ใช้ตัวปรับค่าพารามิเตอร์แบบ Stochastic Gradient Descent (SGD) ร่วมกับ Momentum ตั้งไว้ที่ 0.937 กำหนดอัตราการเรียนรู้ (Learning Rate) ที่ 0.01 อัตราการลดน้ำหนัก (Weight Decay) ที่ 0.0005 และค่าแกมมา (Gamma) ของฟังก์ชัน Focal Loss ที่ 0.0 เพื่อเพิ่มประสิทธิภาพของโมเดล มีการปรับแต่งข้อมูลฝึกสอนด้วยวิธี Data Augmentation เช่น การปรับค่าเฉดสี (Hue), ความอิ่มตัวของสี (Saturation), การปรับขนาด (Scaling) และการกลับทิศทางของภาพ (Image Flipping)

สำหรับการตั้งค่าไฮเปอร์พารามิเตอร์ของอัลกอริทึมติดตามวัตถุ BoT-SORT กำหนดค่าความเชื่อมั่นในการปรากฏตัว (Appearance Threshold) ไว้ที่ 0.481 ใช้วิธีการ Sparse Optical Flow ตั้งค่าความเชื่อมั่นขั้นต่ำ (Confidence Threshold) ที่ 0.3501 อัตราเฟรม (Frame Rate) ที่ 30 เฟรมต่อวินาที ค่าแลมบ์ดา (Lambda) ที่ 0.9896 ค่าการจับคู่ (Matching Threshold) ที่ 0.2273 และค่าการสร้างเส้นทางใหม่ (New Track Threshold) ที่ 0.2114

ตารางที่ 5 การประเมินประสิทธิภาพโดยรวม

	Section	MOTA
MBC	Corridor (แนวทางถนน)	
	มุกก้องหันหน้าไปข้างหน้า (Aggregated)	96.8
	มุกก้องหันกลับหลัง (Aggregated)	96.6
	มุกก้องหันหน้าไปข้างหน้า (ช่องทางเดียว)	76.0
	มุกก้องหันกลับหลัง (ช่องทางเดียว)	88.3
Hybrid	Interchange (ทางแยกหลายระดับ)	
	ระดับความสูงต่ำ (Altitude – Low)	92.1
	ระดับความสูงปานกลาง (Altitude – Medium)	93.5
	ระดับความสูงสูง (Altitude – High)	70.7
TMC	การนับจำนวนยานพาหนะที่ทางแยก (Intersection)	62.3

จากตารางที่ 5 พบว่า ผลการตรวจนับและติดตามยานพาหนะในกลุ่มข้อมูล MBC (ช่วงกลางทางถนน) แสดงผลความแม่นยำที่น่าพอใจเมื่อเปรียบเทียบกับกลุ่มข้อมูล TMC การทดสอบดำเนินการกับวิดีโอจำนวน 51 ไฟล์ โดยแต่ละไฟล์มีระยะเวลา 60 นาที ผลลัพธ์แสดงให้เห็นว่าความแม่นยำในการจำแนกและติดตามยานพาหนะภายใต้สภาพแวดล้อมที่เหมาะสมมีค่ามากกว่า 95 เปอร์เซ็นต์

ยานพาหนะที่ศึกษาแบ่งออกเป็น 3 ประเภท ได้แก่ รถยนต์นั่งส่วนบุคคล รถจักรยานยนต์ และยานพาหนะขนาดใหญ่ (รถบรรทุก/รถโดยสาร) นอกจากนี้ ยังสามารถสกัดค่าพารามิเตอร์อื่น ๆ จากวิดีโอ UAV ได้ เช่น

ความเร็วของยานพาหนะ ความหนาแน่นของการจราจร และระยะเวลาความล่าช้า

จากการศึกษา พบว่าประเภทการเคลื่อนที่แบบผสม (Hybrid Movement) — ซึ่งประกอบด้วยลักษณะของ MBC ผสมกับการไหลของการจราจรแบบ TMC — เป็นลักษณะที่พบได้ทั่วไปในพื้นที่ทางแยกหลายระดับ (Interchanges) ที่กำหนดไว้ โมเดลมีประสิทธิภาพสูงมากที่ระดับความสูงต่ำและปานกลาง โดยสามารถทำความเข้าใจได้มากกว่า 90 เปอร์เซ็นต์ อย่างไรก็ตาม ที่ระดับความสูง 90 เมตร ประสิทธิภาพของโมเดลลดลงอย่างมีนัยสำคัญเหลือ 70.7 เปอร์เซ็นต์ ซึ่งเป็นการแลกเปลี่ยนระหว่างประสิทธิภาพของโมเดลกับขนาดพื้นที่ครอบคลุมที่เพิ่มขึ้น

จากการวิเคราะห์ดังกล่าว พบว่ามีระดับความสูงที่เหมาะสมที่สุด (Optimal Altitude) ซึ่งสามารถครอบคลุมพื้นที่ได้กว้าง โดยไม่สูญเสียคุณภาพของภาพวิดีโอและประสิทธิภาพของโมเดล สำหรับการเคลื่อนที่แบบ MBC ความสูงที่เหมาะสมคือ 50 เมตร และมุกก้องที่เหมาะสมคือ 45 องศา ในขณะที่สำหรับการเก็บข้อมูลแบบ Hybrid ที่ทางแยกหลายระดับ ควรเก็บข้อมูลที่ระดับความสูงระหว่าง 60–70 เมตร เพื่อให้สามารถจับภาพในระดับความสูงที่แตกต่างกันได้ พร้อมรักษาประสิทธิภาพของโมเดลให้อยู่ในระดับสูง

ผลลัพธ์ของการตรวจนับและติดตามยานพาหนะสามารถดูได้ในรูปที่ 9 ถึงรูปที่ 11




รูปที่ 9 ประสิทธิภาพของโมเดลในพื้นที่สนใจ (ROI) ของทางเดินรถหลายช่องทางและทางเดินรถช่องทางเดียว



รูปที่ 10 ประสิทธิภาพของโมเดลที่ทางแยกมีสัญญาณไฟจราจรตามทิศทางการเคลื่อนที่ที่แตกต่างกัน



รูปที่ 11 ประสิทธิภาพของโมเดลที่ทางแยกหลายระดับตามทิศทางการเคลื่อนที่ที่แตกต่างกัน



รูปที่ 12 การแจกแจงยานพาหนะและผลการตรวจจับสำหรับข้อมูลช่วงกลางทาง (MBC) และข้อมูลทางแยก (TMC)

รูปที่ 12 แสดงการแจกแจงยานพาหนะและผลการประเมินประสิทธิภาพของโมเดลโดยละเอียดจากชุดข้อมูลทดสอบ จากตารางที่ 5 นำสังเกตว่า แม้จะมีความไม่สมดุลของกลุ่มข้อมูล (Class Imbalance) ภายในทั้งชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ (สัดส่วน 0.75/0.17/0.06) โมเดลจำแนกประเภทช่วงกลางทาง (Mid-block Classifier) ยังคงแสดงผลลัพธ์ที่มีความน่าเชื่อถือ ความสำเร็จนี้จึงไม่สามารถเกิดขึ้นได้หากยังคงใช้การฝึกสอนกับโมเดลที่อิงกับ Anchor แบบเดิม ซึ่งความไม่สมดุลของข้อมูลมักส่งผลให้ประสิทธิภาพของโมเดลลดลงโดยรวม วิธีการแบบไม่ใช้ Anchor (Anchor-Free Method) ช่วยให้โมเดลสามารถคาดการณ์ตำแหน่งของวัตถุได้โดยตรง โดยไม่ต้องอาศัยการขจัดขอบรอบขอบเขต (Bounding Box Offset)

อย่างไรก็ตาม การวิเคราะห์วิดีโอในกลุ่มข้อมูล TMC ยังคงเป็นความท้าทาย การแยกช่องทางเดินรถในวิดีโอจำเป็นต้องรับมือกับการเปลี่ยนแปลงของลักษณะปรากฏของยานพาหนะในแต่ละช่องทาง ซึ่งทำให้ตัวติดตามวัตถุ (Object Tracker) เกิดความสับสน นำไปสู่การนับซ้ำของยานพาหนะคันเดียวกัน (ระบบลงทะเบียนยานพาหนะซ้ำซ้อน) หรือเกิดการบดบัง (Occlusion) ซึ่งทำให้ UAV สูญเสียการมองเห็นยานพาหนะ

ที่ระดับความสูง 70 เมตร การตั้งตำแหน่ง UAV ให้สูงขึ้นจำเป็นสำหรับการครอบคลุมพื้นที่ขนาดใหญ่ แต่ขนาดของรถจักรยานยนต์ที่เล็กกว่ารถยนต์ส่วนบุคคลและยานพาหนะขนาดใหญ่อย่างมีนัยสำคัญ ส่งผลให้ประสิทธิภาพในการติดตามยานพาหนะลดลง เหลือเพียง 30 เปอร์เซ็นต์ โดยเฉพาะอย่างยิ่งบริเวณทางแยกมีความไวและมีแนวโน้มที่จะเกิดปัญหาดังกล่าวมากกว่าพื้นที่อื่น อย่างไรก็ตาม เมื่อทำการบินที่ระดับความสูง 50 เมตร ความแม่นยำเพิ่มขึ้นอย่างมีนัยสำคัญถึง 85 เปอร์เซ็นต์

ข้อจำกัดที่พบ คือ ที่ระดับความสูง 50 เมตร สามารถสังเกตเห็นเพียงสองขาของทางแยกได้อย่างชัดเจน ในขณะที่การประเมินความยาวของแถวยานพาหนะ (Queue Length) และการคำนวณเวลาความล่าช้า (Delay Estimation) จำเป็นต้องจับภาพขาทางแยกที่ยาวขึ้นเพื่อให้ครอบคลุมข้อมูลอย่างเพียงพอสำหรับการปรับปรุงการตั้งค่าสัญญาณไฟจราจร

ในทางปฏิบัติ แม้ว่าการลดระดับการบินลงเหลือ 50 เมตรจะช่วยเพิ่มความแม่นยำสูงสุด เช่นเดียวกับผลการศึกษาในช่วงกลางทางสำหรับการนับข้อมูล MBC แต่แนวทางนี้จำเป็นต้องมีการใช้งาน UAV หลายลำบิน

พร้อมกันแบบขนานในพื้นที่เดียวกัน เพื่อให้สามารถจับภาพการจราจรได้ครบทุกทิศทาง

5. สรุปผลการศึกษา

ในบทความนี้ได้นำเสนอกระบวนการเฝ้าระวังการจราจรและการสกัดค่าพารามิเตอร์จราจรที่สำคัญในเขตเมือง โดยออกแบบโครงสร้างการทำงานแบบสามชั้น (Three-Layer Framework) มุ่งเน้นการศึกษาช่วงเวลาเร่งด่วน (Rush Hour) กรอบแนวทางที่นำเสนอได้ผสมผสานการทำงานของอัลกอริทึมการประมวลผลภาพที่มีความแข็งแกร่ง ร่วมกับข้อมูลที่ได้จากการบันทึกวิดีโอความละเอียดสูงของอากาศยานไร้คนขับ (UAV)

ในการศึกษานี้ ได้ใช้โมเดล YOLOv8 สำหรับการจำแนกประเภทวัตถุ และโมเดล BoT-SORT สำหรับการติดตามยานพาหนะ ผลลัพธ์แสดงให้เห็นถึงประสิทธิภาพที่โดดเด่น โดยสามารถทำความเข้าใจความแม่นยำสูงสุดถึง 96.8 เปอร์เซ็นต์ในสภาพแวดล้อมทางเดินรถบนทางหลวง (Highway Corridor)

นอกจากนี้ ยังได้ดำเนินการศึกษาอย่างเป็นระบบเกี่ยวกับผลกระทบของระดับความสูงของ UAV และมุมกล้องต่อประสิทธิภาพโดยรวมของโมเดล ผลการศึกษานี้ให้ข้อมูลเชิงลึกที่มีคุณค่าเกี่ยวกับการแลกเปลี่ยนระหว่างประสิทธิภาพของโมเดลกับขนาดพื้นที่ที่ครอบคลุม โดยข้อค้นพบชี้แนะว่า เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด ควรดำเนินการบิน UAV ที่ระดับความสูงระหว่าง 50 ถึง 70 เมตร และตั้งมุมกล้องไว้ที่ 45 องศา

สำหรับการศึกษาวิจัยในอนาคต มีโอกาสในการพัฒนาประสิทธิภาพของโมเดลเพิ่มเติม ทั้งในด้านการตรวจจับยานพาหนะขนาดเล็กหรือยานพาหนะที่พบได้ไม่บ่อยนอกเหนือจากรถยนต์ส่วนบุคคล รวมถึงการเพิ่มความแข็งแกร่งของโมเดลการติดตามยานพาหนะในกรณีที่มีการเปลี่ยนทิศทางการเคลื่อนที่ เช่น การเลี้ยว ทั้งนี้เพื่อเพิ่มขีดความสามารถและความแม่นยำของระบบเฝ้าระวังการจราจรในอนาคตให้สูงขึ้น

เอกสารอ้างอิง

- [1] Adaimi, George, Kreiss, Sven, Alahi, Alexandre, 2023. Traffic perception from aerial images using butterfly fields. Transp. Res. C 153 104181
- [2] Aharon, Nir, Orfaig, Roy, Bobrovsky, Ben-Zion, 2022. BoT-SORT: Robust Associations Multi-Pedestrian Tracking. arXiv:2206.14651
- [3] Ashqer, Ashqar, Elhenawy, Almannaa, Aljamal, Rakha, Bikdash, 2023. Evaluating a Signalized Intersection Performance Using Unmanned Aerial Data.
- [4] Ashutosh, Manohara, Ujjwal, Radhika, 2020. Efficient Vehicle Counting by Eliminating Identical Vehicles in UAV aerial videos. IEEE International Conference on Distributed

Computing, VLSI, Electrical Circuits and Robotics (DISCOVER), pp. 246-251.

[5] Bashir, Boudjit, Zeadally, 2022. A closed-loop control architecture of UAV and WSN for traffic surveillance on highways. *Computer Communications*. Vol. 190, pp. 78-86.

[6] Benjdira, Khursheed, Koubaa, Ammar, Ouni, 2019. Car Detection using Unmanned Aerial Vehicles: Comparison between Faster R-CNN and YOLOv3. *IEEE 1st International Conference on Unmanned Vehicle Systems-Oman (UVS)*, pp 1-6.

[7] Bozcan, Kayacan, 2020. AU-AIR: A Multi-modal Unmanned Aerial Vehicle Dataset for Low Altitude Traffic Surveillance. *IEEE International Conference on Robotics and Automation (ICRA)*, pp 9504-8510.

[8] Butilă, Boboc, 2022. Urban Traffic Monitoring and Analysis Using Unmanned Aerial Vehicles (UAVs): A Systematic Literature Review. *Remote Sensing*. Vol. 14, issue 3, pp. 620.

[9] Chen, Chiu, Hsieh, Lin, Angah, 2020. Conflict analytics through the vehicle safety space in mixed traffic flows using UAV image sequences. *Transp. Res. C* 119 102744.

[10] Elloumi, Dhaou, Escrig, Idoudi, 2018. Monitoring road traffic with a UAV-based system. *IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1-6.

[11] Guido, Gallelli, Rogano, Vitale, 2016. Evaluating the accuracy of vehicle tracking data obtained from Unmanned Aerial Vehicles. *International Journal of Transportation Science and Technology*. Vol. 5, Issue 3, pp. 136-151.

[12] Kanistras, Martins, Rutherford, Valavanis, 2013. A survey of unmanned aerial vehicles (UAVs) for traffic monitoring. *2013 International Conference on Unmanned Aircraft Systems (ICUAS)*, pp. 221-234.

[13] Ke, Li, Tang, Pan, Wang, 2019. Real-Time Traffic Flow Parameter Estimation From UAV Video Based on Ensemble Classifier and Optical Flow. *IEEE Trans. Intell. Transport. Syst.* Vol 20, issue 1, pp.54-64.

[14] Khan, Ectors, Bellemans, Janssens, Wets, 2017. UAV-Based Traffic Analysis: A Universal Guiding Framework Based on Literature Survey. *Transportation Research Procedia*. Vol. 22, pp. 251-550.

[15] Khan, Ectors, Bellemans, Janssens, Wets, 2018. Unmanned Aerial Vehicle-Based Traffic Analysis: A Case Study for Shockwave Identification and Flow Parameters Estimation at Signalized Intersections. *Remote Sensing*. Vol. 10, issue 3, pp. 458.

[16] Khan, Jhanjhi, Brohi, Usmani, Nayyar, 2020. Smart traffic monitoring system using Unmanned Aerial Vehicles (UAVs). *Computer Communications*. Vol. 157, pp. 434-443.

[17] Lin, Dollár, Girshick, He, Hariharan, Belongie, 2017. Feature Pyramid Networks for Object Detection. *arXiv:1612.03144*

[18] Najiya, Archana, 2018. UAV Video Processing for Traffic Surveillance with Enhanced Vehicle Detection. *IEEE Second International Conference on Inventive Communication and Computational Technologies (ICICCT)*, pp.662-668.

[19] Outay, Mengash, Adnan, 2020. Applications of unmanned aerial vehicle (UAV) in road safety, traffic and highway infrastructure management: Recent advances and challenges. *Trans. Res.* Vol.141, pp.116-129.

[20] Rumba, Nikitenko, 2020. The wild west of drones: a review on autonomous- UAV traffic-management. *IEEE International Conference on Unmanned Aircraft Systems (ICUAS)*, pp. 1317-1322.

[21] Salvo, Caruso, Scordo, 2014. Urban Traffic Analysis through an UAV. *Procedia – Social and Behavioral Sciences*. Vol. 111, pp. 1083-1091.

[22] Salvo, Caruso, Scordo, Guido, Vitale, 2017. Traffic data acquirement by unmanned aerial vehicle. *European Journal of Remote Sensing*. Vol. 50, issue 1, pp. 343-351.

[23] Shirazi, Patooghy, Shisheie, Haque, 2020. Application of Unmanned Aerial Vehicles in Smart Cities using Computer Vision Techniques. *IEEE International Smart Cities Conference (ISC2)*, pp1-7.

[24] Wang, Chen, Yin, 2016. Detecting and tracking vehicles in traffic by unmanned aerial vehicles. *Automation in Construction*. Vol. 72, pp. 294-308.

[25] Zheng, Luo, Qiao, Gao, 2023. UAV-Assisted Traffic Speed Prediction via Gray Relational Analysis and Deep Learning. *Drones*. Vol. 7, issue 6, pp. 372.

[26] Zhu, Sun, Jia, Li, Hou, Lin, Liu, Qiu, 2018. Urban Traffic Density Estimation Based on Ultrahigh-Resolution UAV Video and Deep Neural Network. *IEEE Journal of*

Selected Topics in Applied Earth Observations and Remote Sensing. Vol. 11, issue 12, pp. 4968-4981.

[27] Barmounakis, Vlahogianni, Golias, Babinec, 2019. How accurate are small drones for measuring microscopic traffic parameters? Transportation Letters. Vol. 11, issue 6, pp. 332-340.

[28] Xu, Yu, Wang, Wu, Ma, 2017. Car Detection from Low-Altitude UAV Imagery with the Faster R-CNN. Journal of Advanced Transportation. pp. 1-10.

[29] Ke, Li, Kim, Ash, Cui, Wang, 2017. Real-Time Bidirectional Traffic Flow Parameter Estimation From Aerial Videos. IEEE Transactions on Intelligent Transportation Systems. Vol. 18, issue 4, pp. 890-901.

[30] Barmounakis, Sauvin, Geroliminis, 2020. Lane Detection and Lane-Changing Identification with High-Resolution Data from a Swarm of Drones. Transportation Research Record: Journal of the Transportation Research Board. Vol. 2674, issue 7, pp. 1-15.

[31] Kaewunruen, AbdelHadi, Kongpuang, Pansuk, Remennikov, 2023. Digital Twins for Managing Railway Bridge Maintenance, Resilience, and Climate Change Adaptation. Sensors, article 252.

[32] Niu, Gonzalez-Prelcic, Heath, 2018. A UAV-based traffic monitoring system-invited paper. IEEE 87th Vehicular Technology Conference (VTC Spring), pp. 1-5.

[33] Ke, Li, Tang, Pan, Wang, 2018. Real-time traffic flow parameter estimation from UAV video based on ensemble

classifier and optical flow. IEEE Trans. Intell. Transp. Syst., pp. 54-64.

[34] Ke, Feng, Cui, Wang, 2020 Advanced framework for microscopic and lane-level macroscopic traffic parameters estimation from UAV video, IET Intell. Transp. Syst., pp. 724-734.

[35] Kyrkou, Timotheou, Kolios, Theodorides, Panayiotou, 2018. Optimized vision-directed deployment of UAVs for rapid traffic monitoring. IEEE International Conference on Consumer Electronics, ICCE 2018, 2018-Janua, pp. 1-6.

[36] Zhao, Zhang, Brooks, Banach, Aden, 2018. A comprehensive overview of improving traffic flow observability using UAVs as mobile sensors. 97th Annual Meeting, Transportation Research Board, Washington DC, USA. Paper No. 18-04949.

[37] Zhang, Liptrott, Bessis, Cheng, 2019. Real-time traffic analysis using deep learning techniques and UAV based video. In: 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS), pp. 1-5.

[38] Liu, Wang, Shi, Liu, Li, Mao, 2019. Vehicle tracking by detection in UAV aerial video. Science China Informat. Sci. 62, 24101.

[39] Ahmed, Outay, Zaidi, Adnan, Ngoduy, 2020. Examining queue-jumping phenomenon in heterogeneous traffic stream at signalized intersection using UAV-based data. Pers. Ubiquit. Comput.