



การตรวจจับทางข้ามที่ซีดจางโดยการใช้อัลกอริทึมโยโล

Pallid Faded Crosswalk Detection Using YOLO Algorithm

พงศ์นฤทธิ เลหาวิเชียร¹ วิรัตน์ จาริวงศ์ไพบูลย์² และ เสาวลักษณ์ วรรณภา³

¹หลักสูตรวิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์,
phongnarithlaoha@gmail.com

²ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์, wirat@tu.ac.th

³ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์, wsawalu@tu.ac.th

บทคัดย่อ

ทางม้าลายมีการชำรุดและซีดจางจากการใช้งานทุกวันทั่วโลก และอาจทำให้เกิดอุบัติเหตุระหว่างรถยนต์และคนเดินข้ามทางม้าลายได้ ซึ่งขั้นตอนวิธีในแบบ Machine learning มีศักยภาพที่จะสกัด Pattern ทางม้าลายที่ชำรุดและซีดจางออกมาได้ โดยการสร้างโมเดลจากภาพทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลาย ผู้วิจัยเลือกใช้ YOLOv8 ให้เป็นโมเดลสำหรับระบบตรวจจับทางม้าลายในทุกระดับความชัดเจนเพราะมีประสิทธิภาพดีในการตรวจจับวัตถุในภาพ และประมวลผลได้รวดเร็ว โดยผู้วิจัยได้จัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนจากการขับรถออกไปเก็บข้อมูลในเขตกรุงเทพฯ และปริมณฑล และได้จัดทำระบบในการคัดแยกภาพทางม้าลายออกเป็น 3 ระดับความชัดเจน นั่นคือ ชัดเจน ชำรุดและซีดจางน้อย และชำรุดและซีดจางมาก ซึ่งยังรวมถึงภาพไม่มีทางม้าลาย เพื่อนำมาจัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนตามสัดส่วนของ Train Validate และ Test ซึ่งใช้ในการสร้างโมเดลตรวจจับทางม้าลายในทุกระดับความชัดเจน และภายหลังจากการทดสอบโมเดลกับชุดข้อมูล Test แล้วโมเดลได้ค่า mAP50-95 ที่ 77.3% และได้ค่า mAP50 ที่ 96.2% ส่วน Precision ได้ที่ 94% และ Recall ได้ที่ 93% ซึ่งระบบตรวจจับทางม้าลายในทุกระดับความชัดเจนนี้จะมีส่วนช่วยในการพัฒนาระบบชะลอหรือเบรกการขับขี่ของรถยนต์อัตโนมัติเมื่ออยู่ใกล้ทางม้าลายในทุกระดับความชัดเจนได้ ที่จะช่วยส่งเสริมการขับขี่ของรถยนต์อัตโนมัติได้อย่างปลอดภัยได้ต่อไป

คำสำคัญ: ทางม้าลายที่ชำรุดและซีดจาง, การตรวจจับวัตถุ, การเรียนรู้เชิงลึก

ABSTRACT

Crosswalks deteriorate and fade from everyday use worldwide, which can lead to accidents between vehicles and pedestrians crossing the crosswalks. The machine learning techniques have the potential to extract patterns from pallid and faded crosswalks by creating models from images of crosswalks at all levels of clarity and images without crosswalks. we have chosen to use YOLOv8 as the model for the crosswalk detection system at all levels of clarity. This model is selected because it demonstrates good efficiency in object detection in images and can process data quickly. We have compiled a dataset of crosswalks at various levels of clarity by driving and collecting



data in the Bangkok metropolitan area and its outskirts, which contain zebra crossings of different clarity levels. Furthermore, we have developed a system to classify crosswalk images into three levels of clarity: clear, damaged and faded to a low extent, and heavily damaged and faded. This system also includes images without crosswalks. These images are used to create datasets for zebra crossings at all levels of clarity, following the proportions of training, validation, and testing data, which are used to build a model for detecting crosswalks at all levels of clarity. And after testing the model with the Test dataset, the model achieved an mAP50-95 score of 77.3% and an mAP50 score of 96.2%. As for Precision, it reached 94%, and Recall reached 93%. This crosswalk detection system at all levels of clarity will serve as an assistive component in developing the autonomous car's cruise control or braking system when approaching zebra crossings of any clarity level. It will contribute to promoting safe driving of autonomous vehicles in the vicinity of crosswalks in all clarity levels.

Keywords: Pallid faded crosswalk, Object detection, Deep learning

1. บทนำ

จากข้อมูลสถิติอุบัติเหตุจากประเศญี่ปุ่นในปี พ.ศ. 2550 มีคนเดินถนนที่ต้องประสบอุบัติเหตุที่ทางม้าลายคิดเป็นจำนวนถึง 50% จากจำนวนอุบัติเหตุที่เกิดกับคนเดินถนนทั้งหมด(Suzuki, 2010) ปกติแล้วอุบัติเหตุทางรถจักรยานยนต์มักเกิดขึ้นจากความผิดพลาดในการขับขี่จากผู้ขับขี่ ในขณะที่รถยนต์อัตโนมัติสามารถช่วยลดปัญหาในจุดนี้ได้ เนื่องจากรถยนต์อัตโนมัติสามารถลดปริมาณการควบคุมรถยนต์จากผู้ขับขี่ ซึ่งช่วยส่งเสริมให้เกิดการขับขี่ทางถนนที่ปลอดภัยมากยิ่งขึ้น และยังมีส่วนช่วยลดการจราจรที่ติดขัดได้(Grigorescu, 2019) ปัจจุบันงานวิจัยที่เกี่ยวกับรถยนต์อัตโนมัติมีหลายประเด็นที่ได้ถูกพัฒนาอย่างต่อเนื่อง เช่น การตรวจจับเส้นเลนถนน การตรวจจับรถยนต์และคนเดินถนน และการตรวจจับสัญลักษณ์ด้านการจราจรต่าง ๆ ซึ่งมีทั้งไฟสัญญาณจราจร ป้ายสัญญาณจราจร รวมถึงทางม้าลาย

ในปัจจุบันมีงานวิจัยที่พัฒนาระบบตรวจจับทางม้าลายขึ้นมามากมาย ซึ่งมีทั้งแบบสำหรับรถยนต์อัตโนมัติและแบบสำหรับคนตาบอด งานวิจัยเหล่านี้มีทั้งแบบที่ใช้ Engineering-based features และ Machine learning-based features(Trinh, 2022) แต่งานวิจัยเหล่านี้ส่วนมากมักใช้ตรวจจับทางม้าลายที่มีลักษณะสมบูรณ์ และงานวิจัยสำหรับระบบตรวจจับทางม้าลายที่ชำรุดและซีดจางซึ่งเกิดขึ้นจากการใช้งานนี้ยังมีอยู่น้อย แต่ก็เป็นประเด็นในการวิจัยที่สำคัญ เนื่องจากทางม้าลายถูกเสียดสีจากการใช้งานเป็นประจำทุกวัน จึงทำให้ทางม้าลายมีโอกาสที่จะมีความชัดเจนของ Pattern น้อยลงได้ซึ่งจะมีส่วนที่ทำให้เกิดอุบัติเหตุระหว่างรถยนต์และคนข้ามทางม้าลายได้โดยง่าย เนื่องจากไม่สามารถเห็นทางม้าลายได้อย่างชัดเจน ดังนั้นระบบการตรวจจับทางม้าลายที่มีประสิทธิภาพจะมีส่วนส่งเสริมให้รถยนต์อัตโนมัติทำงานได้อย่างปลอดภัย และระบบตรวจจับทางม้าลายดังกล่าวควรต้องสามารถตรวจจับทางม้าลายได้ในทุกระดับความชัดเจนนั่นคือ สามารถตรวจจับทางม้าลายได้ทั้งแบบที่มีความชัดเจน รวมถึงแบบที่ชำรุดและซีดจาง เพื่อสามารถรองรับเหตุการณ์ในการขับขี่รถยนต์อัตโนมัติได้อย่างครอบคลุม

ในการตรวจจับทางม้าลายสิ่งที่สำคัญคือการหา Pattern ของทางม้าลาย ซึ่งจะมีวิธีการโดยรวมอยู่สองแบบหนึ่งคือ Engineering-based features ที่สามารถประมวลผลได้รวดเร็วมากแต่มีความยืดหยุ่นในการตรวจจับ Pattern ของทางม้าลายต่ำ และสองคือ Machine learning-based features ที่มีความยืดหยุ่นต่อการตรวจจับ Pattern ของทางม้า



ลาย แต่มักประมวลผลได้ช้า สำหรับงานวิจัยในการหา Pattern ของทางม้าลายในแบบ Engineering-based features มีเป็นจำนวนมาก โดยส่วนใหญ่จะสกัด Feature ด้วยการพัฒนาให้การตรวจจับ Edge สามารถทำให้ Edge ของทางม้าลายในภาพให้ชัดเจนขึ้น โดย Suzuki (2010) ทำ Canny edge detection ในการสร้างภาพ Edge แล้วไปรวมกับภาพ Binary ด้วย AND operation เพื่อให้เห็น Edge ของทางม้าลายที่ชัดเจนขึ้น แต่สำหรับทางม้าลายที่ชัดเจนที่รูปแบบของสีเส้นที่อ่อนไม่ชัดเจน จะสามารถสกัด Edge จากการทำ Canny edge detection ได้ยากขึ้น ส่วน Ivanchenko (2008) หลังจากการตรวจจับ Edge ได้ใช้เทคนิค Non-maximal suppression เพื่อคัดเลือกเฉพาะ Edge ที่ชัดเจนมากในภาพออกมา แต่เทคนิคนี้เหมาะที่จะใช้กับทางม้าลายที่มีความชัดเจนของสีเส้นมากกว่าที่จะใช้กับทางม้าลายที่จางและชัดเจนที่สีเส้นมีความชัดเจนน้อยที่จะทำให้สกัด Edge ออกมาได้ดียิ่งขึ้นและทำให้ตรวจจับทางม้าลายที่จางและชัดเจนได้ยากขึ้น นอกจากนี้ Tümen (2020) ยังได้ใช้เทคนิค Canny edge detection และ Hough transform ในการหา Edge ของขอบเลนถนน ซึ่งจะใช้ได้ดีกับขอบเลนถนนที่ไม่มีสิ่งกีดขวางมากนัก และมีวัตถุที่เป็นจุกครบวง (Noise) ในภาพน้อย แต่ถ้าหากมีวัตถุที่เป็นจุกครบวง (Noise) ในภาพมาก ประสิทธิภาพในการหา Edge ของขอบเลนถนนก็จะลดลง ดังนั้นหากปรับใช้ทั้งเทคนิค Canny edge detection และ Hough transform ในการหา Pattern ของทางม้าลายในสภาพถนนจริงที่มีสิ่งรบกวนในภาพมากทั้งรถยนต์ คนเดินถนน เศษขยะ ความชัดเจนของสีเส้นของทางม้าลายเอง รวมไปถึงความชัดเจนของภาพทางม้าลาย ทั้งหมดนี้สามารถเป็นสิ่งรบกวนในภาพซึ่งจะเป็นอุปสรรคในการหา Pattern ของทางม้าลายเป็นอย่างมาก ดังนั้นวิธีการตรวจจับทางม้าลายแบบ Engineering-based features จึงใช้ในสภาพถนนจริงได้ยาก

สำหรับงานวิจัยการตรวจจับทางม้าลายในแบบ Machine learning-based features สำหรับ Tümen (2020) ได้ใช้ Convolutional neural network ในการตรวจจับทางม้าลาย ซึ่งก่อนที่จะตรวจจับทางม้าลายได้ใช้เทคนิคแบบ Engineering-based features ในการหา Region of interest ซึ่งสามารถตรวจจับทางม้าลายได้ดี แต่จำนวนภาพทางม้าลายมีน้อยโดยมีไม่ถึง 200 ภาพซึ่งได้ใช้ภาพจาก Google street view และไม่สามารถเข้าถึงชุดข้อมูลได้ ส่วน Rúbio (2020) ใช้ YOLO ในการตรวจจับทางม้าลายเพราะประมวลผลได้รวดเร็ว และได้ประสิทธิภาพที่ดีในการตรวจจับทางม้าลายด้วย นอกจากนี้ภายในชุดข้อมูลของ Rúbio (2020) มีทางม้าลายที่ชัดเจนอยู่ด้วยแต่เป็นในมุมมองของคนเดินถนนไม่ใช่มุมมองของผู้ขับขี่รถยนต์ ซึ่งมุมมองของภาพทางม้าลายในชุดข้อมูลจะมีผลต่อการเรียนรู้ Pattern ทางม้าลายของโมเดล ส่วน Trinh (2022) ได้ใช้ YOLOv4 ในการตรวจจับทางม้าลายเช่นเดียวกันโดยทางม้าลายในชุดข้อมูลอยู่ในมุมมองของผู้ขับขี่รถยนต์และมุมมองจากบนลงล่าง และได้ทำ Data augmentation จนทำให้มีภาพทางม้าลายในชุดข้อมูลถึง 20,000 ภาพ และได้ประสิทธิภาพในการตรวจจับทางม้าลายที่ดีเช่นกัน แต่ผู้วิจัยไม่ได้กล่าวชัดเจนว่าข้อมูลทางม้าลายต้นฉบับมีจำนวนกี่ภาพ และได้รวมทางม้าลายที่จางและชัดเจนไว้ในชุดข้อมูลด้วยหรือไม่ และไม่สามารถเข้าถึงชุดข้อมูลได้ ในขณะที่ Cao (2021) ใช้ MobileNet ที่ประมวลผลได้รวดเร็วคล้ายกันกับ YOLO เช่นเดียวกันโดยตรวจจับทางม้าลายในแบบ Semantic segmentation เพราะสามารถระบุตำแหน่งของทางม้าลายในภาพได้แม่นยำในระดับ Pixel และได้ใช้เทคนิค Depthwise separable convolution เพื่อลดความซ้ำซ้อนในการประมวลผลที่เกิดขึ้นในแต่ละ Pixel ในช่วงการทำ Convolution อีกด้วย และโมเดลสามารถตรวจจับทางม้าลายได้อย่างแม่นยำ อย่างไรก็ตามในชุดข้อมูลของผู้วิจัยมีภาพทางม้าลายจำนวน 200 ภาพ ในมุมมองของคนเดินถนน ทางม้าลายในชุดข้อมูลมี Pattern ชัดเจน แต่จะไม่ช่วยส่งเสริมต่อการสร้างโมเดลสำหรับการตรวจจับทางม้าลายในทุกระดับความชัดเจน โดยเฉพาะในมุมมองของการขับขี่รถยนต์

ในภาพรวมงานวิจัยส่วนมากในเรื่องการตรวจจับทางม้าลาย มักตรวจจับทางม้าลายที่มีสีเส้นที่ชัดเจน ซึ่งจะสามารถตรวจจับทางม้าลายได้เป็นอย่างดี แต่งานวิจัยที่มุ่งเน้นตรวจจับทางม้าลายที่ชัดเจนในมุมมองของผู้ขับขี่



รถยนต์ยังมีอยู่น้อย และชุดข้อมูลสำหรับทางม้าลายที่ชำรุดและซีดจางในมุมมองของผู้ขับขี่รถยนต์ที่สามารถเข้าถึงได้ ในปัจจุบันก็ยังมีน้อย สำหรับงานวิจัยนี้ผู้วิจัยเลือกใช้ YOLOv8 เป็นโมเดลในการตรวจจับทางม้าลายในทุกระดับ ความชัดเจน และได้จัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนในมุมมองของการขับขี่รถยนต์ ซึ่งผู้วิจัยได้ ทดสอบนำทางม้าลายที่ชัดเจนมาสร้างโมเดลในลักษณะใกล้เคียงกันกับงานวิจัยของ Trinh (2022) ที่ได้ใช้ YOLOv4 กับทางม้าลายที่มีความชัดเจน แล้วพบว่าโมเดล YOLOv4 ที่ถูกสร้างมีประสิทธิภาพต่ำในการตรวจจับทางม้าลายที่มีความ ชำรุดและซีดจางมาก ซึ่งช่วยส่งเสริมการขับขี่รถยนต์อย่างปลอดภัยเมื่อเจอกับทางม้าลายที่ชำรุดและซีดจางได้ ยาก โดยมีผลการทดลองเบื้องต้นดังตาราง 1 และ 2

ตารางที่ 1 ผลการตรวจจับทางม้าลายกับชุดข้อมูล Test จากโมเดลที่สร้างจากภาพทางม้าลายแบบชัดเจนและภาพไม่มีทางม้าลาย

		Bounding box				
ชุดข้อมูล	Class	mAP50	mAP50-95	Precision	Recall	Accuracy
ชัดเจน	ส่วนขาว	0.979	0.794	0.95	0.95	0.91
ซีดจางมาก	ส่วนขาว	0.868	0.603	0.9	0.8	0.74

ตารางที่ 2 ผล Confusion matrix ของการตรวจจับทางม้าลายกับชุดข้อมูล Test จากโมเดลที่สร้างจากภาพทางม้าลาย แบบชัดเจนและภาพไม่มีทางม้าลาย

ชุดข้อมูล			ค่าจริง	
			ส่วนขาว	พื้นหลัง
ชัดเจน	ทำนาย	ส่วนขาว	0.916	0.0416
		พื้นหลัง	0.0416	0
ซีดจางมาก	ทำนาย	ส่วนขาว	0.744	0.077
		พื้นหลัง	0.179	0

ด้วย ทางม้าลายซีดจางลงได้ตลอดในทุก ๆ วันเพราะเกิดการเสียดสีจากการใช้งานถนนของยานยนต์ โอกาส ที่จะเกิดทางม้าลายที่ซีดจางบนท้องถนนจึงมีมาก และอาจก่อให้เกิดอุบัติเหตุกับผู้ใช้ทางม้าลายได้ รวมถึงทำให้คนไม่ กล้าที่จะใช้ทางม้าลายที่ซีดจางด้วย ดังนั้น จึงมีความจำเป็นที่จะต้องจัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจน และภาพไม่มีทางม้าลาย ในมุมมองของการขับขี่รถยนต์ สำหรับสร้างโมเดล เพื่อให้โมเดลที่ได้สามารถตรวจจับทาง ม้าลายได้ดีในทุกระดับความชัดเจน ไม่ใช่ตรวจจับได้ดีเพียงทางม้าลายที่ชัดเจนเท่านั้น เพื่อที่จะเป็นส่วนช่วยในการ พัฒนาระบบรถยนต์อัตโนมัติให้สามารถป้องกันอุบัติเหตุในการใช้ทางม้าลายที่ชำรุดและซีดจางของผู้ใช้ถนนได้อย่าง มีประสิทธิภาพ

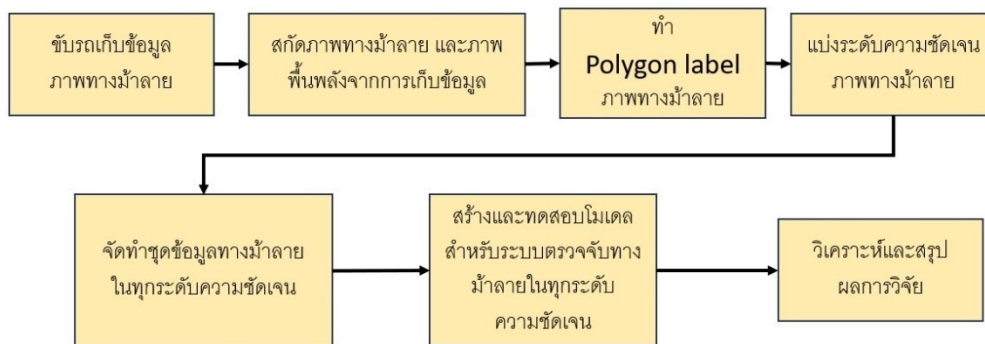


2. วัตถุประสงค์การวิจัย

- 2.1 เพื่อพัฒนาระบบตรวจจับทางม้าลายที่ชำรุดและซีดจางจากการใช้งาน
- 2.2 เพื่อพัฒนาชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนจากภาพทางม้าลายที่ได้จากการจับขึ้นในเขตกรุงเทพฯ และปริมณฑล
- 2.3 เพื่อพัฒนาระบบคัดแยกทางม้าลายตามระดับความชัดเจนออกเป็น 3 ระดับ คือ ชัดเจน ชำรุดและซีดจางน้อย และชำรุดและซีดจางมาก เพื่อใช้จัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจน

3. การดำเนินการวิจัย

ขั้นตอนหลักสำหรับการดำเนินการวิจัยแสดงรายละเอียดดัง ภาพที่ 1



ภาพที่ 1 การดำเนินการวิจัย

3.1 Hardware สำคัญที่ใช้ในการวิจัย มีดังนี้ Graphics Processing Unit ที่มี Ram 24 GB ที่ใช้ในการรันโมเดล และ Smartphone ที่มีกล้องที่สามารถอัปเดตวิดีโอที่ความละเอียดอย่างน้อย 1920*1080 Pixels และติดตั้งที่ตรงกลาง Console หน้ารถ

3.2 Software สำคัญที่ใช้ในการวิจัย มีดังนี้ LabelStudio เป็นโปรแกรมสำหรับ Label ภาพเพื่อจัดทำชุดข้อมูล ใช้ VLC เป็นโปรแกรมสำหรับบันทึก Screenshot จากคลิปวิดีโอ ใช้ภาษา Python ใช้ชุดคำสั่ง CUDA Toolkit และมี Library ที่สำคัญ เช่น Pytorch Numpy Pandas Opencv รวมถึง ScikitLearn

3.3 การจัดทำชุดข้อมูล

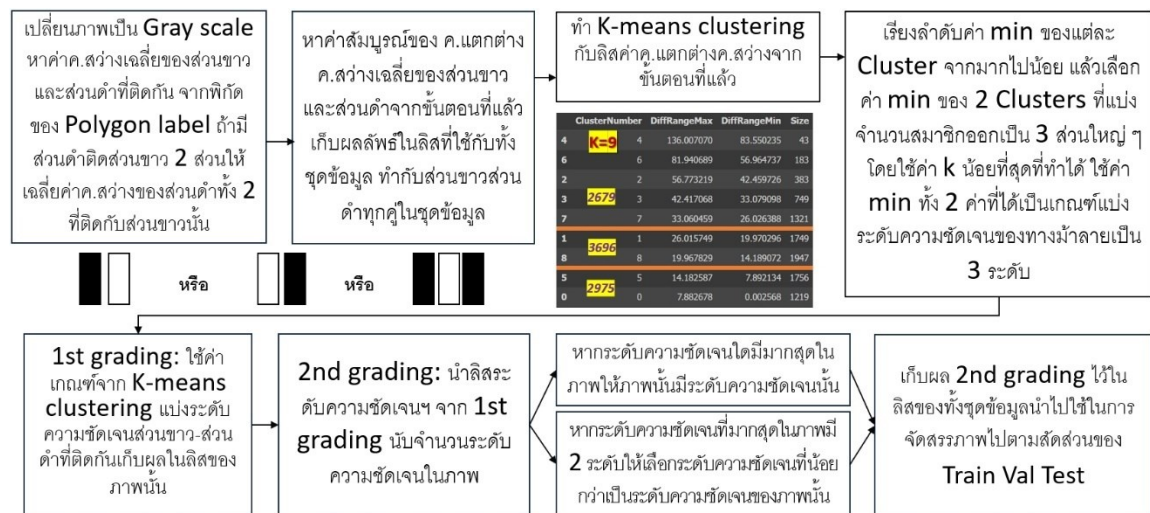
3.3.1 การจัดทำภาพทางม้าลายเพื่อจัดทำชุดข้อมูลทางม้าลาย: ผู้วิจัยได้ขับรถบันทึกวิดีโอที่มีภาพทางม้าลายในบริเวณกรุงเทพฯ และปริมณฑล ในช่วงเวลากลางวันที่มีอากาศแจ่มใส ซึ่งภาพทางม้าลายที่บันทึกได้จะอยู่ในมุมมองจากรถยนต์ทั้งหมด เมื่อได้คลิปวิดีโอบันทึกภาพทางม้าลายแล้ว ผู้วิจัยใช้โปรแกรม VLC บันทึกภาพ Screenshot ทางม้าลายขนาด 1920*1080 Pixels จากคลิปวิดีโอจากการขับรถเก็บข้อมูล โดยทางม้าลายในภาพ Screenshot จะต้องอยู่บริเวณกลางภาพและอยู่ใกล้กับรถให้มากที่สุดเพื่อให้เห็นรายละเอียดของทางม้าลายให้ชัดเจน รวมถึงเก็บภาพ Screenshot ของภาพที่ไม่มีทางม้าลายจากคลิปวิดีโอดังกล่าวด้วย ซึ่งภาพ Screenshot ที่เก็บจะต้องเป็นภาพหลังจากผ่านทางม้าลายไปแล้วบนถนนเส้นเดียวกัน โดยผ่านทางม้าลายไปไม่เกิน 5 วินาที หรือเป็นภาพ



Screenshot ก่อนที่จะพบทางม้าลายบนถนนเส้นเดียวกัน เพื่อให้สิ่งแวดล้อม ในภาพที่ไม่มีทางม้าลายมีความคล้ายคลึงกันกับภาพที่มีทางม้าลายเพื่อให้โมเดลสามารถเรียนรู้ได้ว่าจุดไหนในภาพคือทางม้าลาย และจุดไหนในภาพที่เป็นพื้นหลัง ซึ่งจะมีส่วนในการช่วยลด False positives ได้ (Shrivastava (2016)) แล้วนำภาพทั้งหมดที่ได้ไปจัดทำ Polygon label และยังสามารถทำภาพ Screenshot ของทางม้าลายที่อยู่ในระยะที่ห่างจากตัวรถพอสมควรเพื่อใช้เป็นชุดข้อมูลทดสอบโมเดลอีกชุดหนึ่งด้วยเพียงแต่ชุดข้อมูลภาพทางม้าลายที่อยู่ห่างจากตัวรถนี้จะไม่ได้ทำการ Label เหมือนกับชุดข้อมูลภาพทางม้าลายที่อยู่ใกล้ตัวรถ

3.3.2 การ Label ภาพทางม้าลายเพื่อจัดทำชุดข้อมูล: ผู้วิจัยได้ทำ Polygon label กับภาพทางม้าลายในชุดข้อมูล โดยมี Class ส่วนขาวของทางม้าลาย และส่วนดำของทางม้าลาย ที่ใช้เป็นข้อมูลฝึกสำหรับการหาค่าเกณฑ์ในการแบ่งระดับความชัดเจนของทางม้าลาย และใช้ Class ส่วนขาวของทางม้าลายแสดงการตรวจจับทางม้าลาย ในขณะที่ Class ส่วนดำของทางม้าลายไม่ใช้ในการตรวจจับทางม้าลายเพราะมีสีเหมือนกับถนนและไม่มีขอบเขตแน่นอนครบทั้ง 4 ด้าน ผู้วิจัยใช้ Polygon label กับภาพทางม้าลายเพราะเมื่อ YOLO แปลง Polygon label เป็น Bounding box จะได้ Bounding box ที่มีกรอบในแต่ละด้านแนบใกล้กับวัตถุในภาพอย่างมากที่สุด ซึ่งสะดวกกว่าการลาก Bounding box ครอบส่วนขาวของทางม้าลาย แต่จะต้องใช้โมเดล YOLO สำหรับ Instance segmentation ในการสร้างโมเดล

3.3.3 การแบ่งระดับความชัดเจนของทางม้าลายในชุดข้อมูล: เนื่องจากทางม้าลายในแต่ละภาพมีความชัดเจนแตกต่างกัน และยากที่จะใช้ความรู้สึกตัดสินระดับความชัดเจนของทางม้าลาย ผู้วิจัยจึงได้ออกแบบระบบแบ่งระดับความชัดเจนของภาพทางม้าลายในชุดข้อมูล โดยใช้ภาษา Python ในการแบ่งระดับความชัดเจนของภาพทางม้าลาย โดยมีหลักการโดยย่อดังภาพที่ 2



ภาพที่ 2 ความชัดเจนของภาพทางม้าลาย

3.3.3.1 จัดทำ List ค่าความแตกต่างความสว่างระหว่างส่วนขาวและส่วนดำของทางม้าลายทั้งชุดข้อมูล: นำชุดข้อมูลทางม้าลายจากขั้นตอน 3.3.2 แปลงให้เป็นภาพขาวดำ (Gray scale) แล้วหาค่าความสว่างเฉลี่ยจากขอบเขตของส่วนขาวของทางม้าลายที่ได้จากพิกัดของ Polygon label และหาค่าความสว่างเฉลี่ยจากส่วนดำของทางม้าลายที่



ติดกับส่วนขาวของทางม้าลายจากพิกัดของ Polygon label เช่นเดียวกัน ซึ่งหากส่วนขาวของทางม้าลายติดกับส่วนดำของทางม้าลาย 2 ส่วนก็ให้นำค่าความสว่างเฉลี่ยของส่วนดำทั้ง 2 ส่วนนั้นมาเฉลี่ยกันอีกที จากนั้นให้นำค่าความสว่างเฉลี่ยของส่วนดำทั้งหมดที่ติดกับส่วนขาวของทางม้าลายมาลบกับค่าความสว่างเฉลี่ยของส่วนขาวของทางม้าลายที่พิจารณา นำผลลัพธ์ที่ได้มาทำเป็นค่าสัมบูรณ์ แล้วจัดเก็บผลลัพธ์ลงใน List ที่ใช้กับทั้งชุดข้อมูล ทำเช่นนี้กับส่วนขาวและส่วนดำที่ติดกันทุกคู่ในชุดข้อมูล

3.3.3.2 หาค่าเกณฑ์จำแนกระดับความชัดเจนของทางม้าลาย: นำ List จากขั้นตอนที่ 3.3.3.1 มาจัดกลุ่มด้วยการทำ K-means clustering โดยเลือกใช้ค่า K ที่น้อยที่สุดที่สามารถแบ่งกลุ่มจำนวนค่าความแตกต่างๆ ออกเป็น 3 กลุ่มในจำนวนที่ใกล้เคียงกันได้ แล้วให้ทำการจัดอันดับค่าขอบเขตที่น้อยที่สุดของแต่ละ Cluster จากมากไปน้อย แล้วเลือกค่าขอบเขตที่น้อยที่สุดของ Cluster หนึ่งกับค่าขอบเขตที่น้อยที่สุดของอีก Cluster หนึ่งที่สามารถใช้เป็นค่าเกณฑ์ในการแบ่งจำนวนค่าความแตกต่างๆ ของทั้งชุดข้อมูลออกเป็นจำนวน 3 กลุ่มที่มีค่าใกล้เคียงกันที่สุดเท่าทำได้ ซึ่งค่าเกณฑ์ในการแบ่งระดับความชัดเจนของทางม้าลายที่ได้ออกเป็น 3 ระดับคือ ชัดเจน ชำรุดชัดเจนน้อย และชำรุดชัดเจนมาก

3.3.3.3 หลักการแบ่งระดับความชัดเจนของภาพทางม้าลาย

3.3.3.3.1 การแบ่งระดับครั้งที่ 1 จะใช้ค่าเกณฑ์จากขั้นตอนที่ 3.3.3.2 มาแบ่งระดับความชัดเจนของส่วนขาวและดำของทางม้าลายที่ติดกันแต่ละกลุ่มในภาพเก็บไว้ใน List ที่ใช้ในภาพนั้น

3.3.3.3.2 การแบ่งระดับครั้งที่ 2 นำ List จากขั้นตอนที่ 3.3.3.3.1 มานับจำนวนระดับความชัดเจนในแต่ละระดับในภาพนั้น แล้วนำมาเปรียบเทียบกันดังนี้

3.3.3.3.2.1 หากจำนวนระดับความชัดเจนๆ ใดมีมากที่สุด ให้ใช้ค่าระดับความชัดเจนๆ นั้นเป็นค่าระดับความชัดเจนของทางม้าลายในภาพนั้น

3.3.3.3.2.2 จำนวนระดับความชัดเจนๆ ที่มากที่สุดมี 2 ระดับความชัดเจน ให้เลือกระดับความชัดเจนของทางม้าลายที่มีความชัดเจนน้อยกว่าเป็นระดับความชัดเจนของทางม้าลายในภาพนั้น

แล้วให้จัดเก็บระดับความชัดเจนของทางม้าลายในภาพแต่ละภาพจากขั้นตอนที่ 3.3.3.3.2 ลงใน List ที่ใช้กับทั้งชุดข้อมูล จนครบทุกภาพในชุดข้อมูล แล้วนำไปคัดแยกทางม้าลายตามระดับความชัดเจนออกเป็น 3 กลุ่มนั่นคือ กลุ่มทางม้าลายที่ชัดเจน กลุ่มทางม้าลายที่ชำรุดชัดเจนน้อย และกลุ่มทางม้าลายที่ชำรุดชัดเจนมาก จนเสร็จ

3.3.4 การสร้างชุดข้อมูล Train Validate และ Test: ทำการสุ่มข้อมูลภายในแต่ละกลุ่ม ทั้ง 3 กลุ่มจากขั้นตอนที่ 3.3.3.3.2 รวมถึงภาพไม่มีทางม้าลาย แล้วแบ่งข้อมูลภาพจากแต่ละกลุ่มจากทั้ง 4 กลุ่มมาแบ่งตามสัดส่วนให้เป็นชุดข้อมูล Train ที่ 70% Validate ที่ 10% และ Test ที่ 20% ทำไปจนครบทุกกลุ่ม แล้วนำข้อมูล Train Validate และ Test ทั้ง 4 กลุ่มที่แบ่งไว้มารวมกันเป็นชุดข้อมูล Train Validate และ Test ที่ต้องการ

นอกจากนี้ ให้แบ่งภาพจากชุดข้อมูล Test แบบรวมทุกระดับความชัดเจนของทางม้าลาย ให้เป็นชุดข้อมูล Test ในแต่ละระดับความชัดเจนของทางม้าลาย ซึ่งรวมถึงชุดข้อมูล Test ที่มีแต่ภาพไม่มีทางม้าลาย รวมถึงได้ภาพทางม้าลายที่อยู่ไกลที่ได้จัดทำไว้ที่ 3.3.1 มารวมไว้เป็นชุดข้อมูลสำหรับทดสอบอีกชุดด้วย

3.4 โครงข่ายประสาทเทียมที่ใช้ตรวจจับทางม้าลายในทุกระดับความชัดเจน: ผู้วิจัยเลือกใช้ YOLO(Jocher, 2023) ในการตรวจจับทางม้าลายในทุกระดับความชัดเจน เนื่องจากมีการนำหลักการของ Convolutional neural network มารวมกับหลักการของ Object localization ให้อยู่ภายใต้ Network เดียวกัน ซึ่งมีผลให้ YOLO สามารถ



ตรวจจับวัตถุในภาพได้ไว โดยสามารถตรวจจับวัตถุได้ด้วยความเร็ว 45 เฟรมต่อวินาที (Redmon, 2016) จึงเหมาะกับการตรวจจับทางม้าลายในขณะขับขี่ และ YOLO ยังได้รับการพิสูจน์แล้วว่ามีความแม่นยำสูง ซึ่งมีความแม่นยำสูงกว่าโมเดล Faster R-CNN ResNet และ SSD500 (Redmon, 2017) นอกจากนี้ YOLO ยังมีประสิทธิภาพดีในการตรวจจับวัตถุในสภาพแวดล้อมที่หลากหลายซึ่งสอดคล้องกับการตรวจจับทางม้าลายในถนนจริงที่อาจมีทั้งวันที่อากาศแจ่มใส แดดอ่อน แดดจัด ฟ้ามีด และฝนตกหนัก ยิ่งไปกว่านั้น YOLO ยังมีความแม่นยำในการตรวจจับวัตถุในสิ่งแวดล้อมที่มีวัตถุหลากหลายชนิด ซึ่งในสภาพการขับขี่จริงจะมีวัตถุอีกหลายอย่างที่ควรตรวจจับนอกจากทางม้าลาย เช่น รถยนต์ คนเดินถนน ทางเท้า ป้ายสัญญาณจราจร เส้นขอบเลนถนน ฯลฯ โดยผู้วิจัยเลือกใช้ YOLOv8 เป็นโมเดลในการตรวจจับทางม้าลายในทุกระดับความชัดเจนในแบบ Object detection โดย YOLOv8 สามารถทำ Object detection จากชุดข้อมูลที่ Label ด้วย Polygon label ได้

หลักการเบื้องต้นในการประมวลผล YOLO จะทำการ Classification ด้วยการประมวลผลภาพทั้งภาพเพียงแค่ครั้งเดียว จึงทำให้สามารถประมวลผลได้อย่างรวดเร็ว สามารถตรวจจับวัตถุที่อยู่ซ้อนกัน ได้ สามารถบอกค่าความน่าจะเป็นของวัตถุที่ตรวจจับได้ ซึ่ง YOLO มีระบบ Grid cell ที่จะแบ่งภาพออกเป็น Grid ขนาดเท่ากัน โดยในแต่ละ Grid จะมี Vector ที่ใช้เก็บข้อมูลของ Grid cell นั้นซ่อนในแกนลึกเข้าไปอีก แล้วเมื่อนำ Vector ของแต่ละ Grid cell มาประกอบกันตามตำแหน่งของ Grid cell ในภาพก็จะได้ Tensor ของภาพนั้นออกมา ซึ่งรูปแบบการเก็บข้อมูลของภาพแบบ Grid cell นี้จะใช้ทั้งข้อมูลสำหรับ Ground truth label ที่เกิดขึ้นระหว่างการ Label ภาพในชุดข้อมูล และข้อมูลสำหรับการ Prediction เบื้องต้นข้อมูลภายใน Vector ของแต่ละ Grid cell โดยย่อมีดังนี้

3.4.1 คุณลักษณะของ Bounding box ในแบบพิกัดจุดศูนย์กลางของวัตถุ (X,Y) และความกว้างและสูงของวัตถุ (W,H) โดยจุดศูนย์กลางวัตถุจะอยู่ที่ครึ่งหนึ่งของความกว้างและความสูงของวัตถุ

3.4.2 ค่า Confidence ของแต่ละ Bounding box ซึ่งก็คือค่า IoU ของ Bounding box ที่ถูกทำนายกับ Bounding box ที่เป็น Ground truth label

3.4.3 ค่า Class label ซึ่งเป็นค่าของความน่าจะเป็นของ Bounding box ของ Class ใด Class หนึ่งในชุดข้อมูลที่เป็นความน่าจะเป็นแบบมีเงื่อนไขที่จะมีค่าระหว่าง 0 ถึง 1

หลังจากโมเดลได้กลุ่มของ Bounding box ทั้งหมดในภาพพร้อมค่า Confidence แล้ว โมเดลจะทำการเลือกเฉพาะ Bounding box ที่มีค่า Confidence หรือคือค่า IoU สูงที่สุดสำหรับแต่ละวัตถุในภาพให้เป็น Bounding box สำหรับการตรวจจับวัตถุนั้น ด้วยเทคนิค Non maximum suppression ที่จะทำรวมหมดทุก Class พร้อมกัน โดยมีหลักการสำคัญโดยย่อคือการทำการตัด Bounding box ที่มีค่า Confidence ใกล้เคียงกับ Bounding box ที่มีค่า Confidence สูงสุดของวัตถุนั้นออกไปจนหมด จึงทำให้เหลือ Bounding box เดียวต่อวัตถุนั้น ๆ ในภาพ แล้วเช่นนี้ไปกับทุกวัตถุในภาพ

3.5 วิธีการหาค่า Total batch size: สำหรับงานวิจัยนี้ Total batch size เป็นค่าจำนวนภาพที่ Optimizer ใช้เป็น Input ในการทำ Optimization แต่ละครั้ง (Optimization step) YOLO มีฟังก์ชัน AutoBatch ที่จะคำนวณค่า Total batch size สูงสุดที่เครื่องคอมพิวเตอร์แต่ละเครื่องสามารถใช้ได้ โดยหาจากสมการหาค่า Accumulate ซึ่งค่า Nominal batch size ทาง YOLO กำหนดเบื้องต้นไว้ที่ 64

$$accumulate = \max(\text{round}(\text{nominal batch size} \div \text{total batch size}))$$

สมการหาค่า Accumulate



3.6 วิธีการหาจำนวน Epoch: สำหรับงานวิจัยนี้ได้ใช้ค่า Bounding box loss ทั้งในส่วนของการ Train และ Validate ในแต่ละ Epoch ที่ได้หลังจากการ Train โมเดล YOLO มาเปรียบเทียบกับจำนวน Epoch ที่ค่า Validation loss เริ่มไม่ค่อยลดลง และค่า Training loss ยังคงลดลงอย่างต่อเนื่อง ซึ่งเป็นช่วงที่โมเดลเริ่มจะ Overfitting โดยจะใช้ค่า Epoch ที่จุดนั้นในการ Train โมเดลเพื่อไม่ให้โมเดลเกิดการ Overfitting

3.7 Optimizer ที่ใช้: ผู้วิจัยเลือกใช้ AdamW เป็น Optimizer ในการปรับค่า Weight และ Bias เพราะใช้ได้ดีกับกราฟ Loss function ของ Deep learning ที่มีความซับซ้อน ซึ่งมีการใช้ค่า Momentum ที่จะทำให้โมเดลเข้าหา Global minima ได้ไวขึ้นเมื่อพบทิศทางของ Gradient ที่ถูกต้อง และทำให้หนีออกจาก Local minima ได้ไวขึ้นเมื่อพบทิศทางของ Gradient ที่ไม่ถูกต้อง และยังคงโอกาสเกิด Overfitting ได้ดีเพราะมีการใช้พจน์ Weight decay ไปรวมกับค่า Loss ปกติทำให้โมเดลจะพยายามปรับค่า Weight เฉพาะใน Parameter ที่จำเป็น และปรับในระดับที่จำเป็นเพื่อไม่ให้ค่า Loss เพิ่มเร็วเกินไป

3.8 การวัดประสิทธิภาพ: เครื่องมือวัดประสิทธิภาพโมเดลเฉพาะที่สำคัญมีดังนี้

3.8.1 Precision และ Recall: ผู้วิจัยใช้ Precision วัดประสิทธิภาพในความแม่นยำของโมเดลว่ามีค่า False positive มากน้อยเพียงใด ซึ่ง Precision สูงจะมี False positive ต่ำ แต่ในระบบตรวจจับทางม้าลาย Recall ก็มีความสำคัญเพราะหาก Recall ต่ำที่หมายถึงมี False negative มาก ซึ่งมีนัยยะว่าโมเดลมองว่าส่วนของทางม้าลายในภาพว่าไม่ใช่ทางม้าลาย ซึ่งทำให้เกิดความไม่ปลอดภัยในการขับขี่

3.8.2 Confusion matrix: ผู้วิจัยใช้ Confusion matrix เพื่อวิเคราะห์ความแม่นยำในการตรวจจับทางม้าลายในแบบ Bounding box ซึ่งสามารถประเมินประสิทธิภาพการตรวจจับจากจำนวนของ Bounding box ที่เกิดขึ้นจากการสร้างหรือทดสอบโมเดลได้ โดย True positive จะแสดงว่าโมเดลสามารถตรวจจับทางม้าลายได้ถูกต้องเป็นจำนวนเท่าไรซึ่งควรต้องมีเป็นจำนวนมาก ในขณะที่ False negative จะแสดงความผิดพลาดของโมเดลที่ไม่สามารถตรวจจับทางม้าลายได้นั้นคือโมเดลมองว่าทางม้าลายเป็นสิ่งที่อื่นในภาพซึ่งควรต้องมีจำนวนน้อย True negative ที่ใช้วัดการทำนายที่ถูกต้องของ Class ที่ไม่ใช่ Class หลักที่ต้องการพิจารณา และ False positive ที่ใช้วัดความผิดพลาดในการทำนาย Class หลักที่ต้องการพิจารณา

3.8.3 mAP50 และ mAP50-95: mAP50 สำหรับงานวิจัยนี้ได้จากค่า Average precision ของทั้งชุดข้อมูลที่พื้นที่ของผลการตรวจจับส่วนของทางม้าลายซ้อนทับกันกับส่วนของทางม้าลายที่เป็น Ground truth label เป็นพื้นที่อย่างน้อย 50% (IoU = 0.50) ในขณะที่ mAP50-95 ก็จะคำนวณเหมือนกับการคำนวณค่า mAP50 เพียงแต่ mAP50-95 จะคำนวณค่า AP แยกไปในแต่ละ IoU ตั้งแต่ IoU ที่ 0.5 แล้วเพิ่มค่า IoU ที่ละ 0.05 ไปจนถึง IoU ที่ 0.95 แล้วนำค่า AP ในแต่ละ IoU ที่ได้ตั้งแต่ 0.5 – 0.95 มาเฉลี่ยกันอีกครั้ง ดังนั้นค่า mAP50-95 จะสามารถวัดประสิทธิภาพโมเดลได้ละเอียดกว่าค่า mAP50 ส่วนค่า mAP50 จะถูกใช้สำหรับ Precision-Recall curve ที่ได้จากโมเดล YOLO

3.8.4 IoU: คำนวณจากอัตราส่วนระหว่างพื้นที่ที่ซ้อนทับกันของ Bounding box ที่เป็น Ground truth และ Bounding box ที่ถูกทำนายกับพื้นที่ทั้งหมดของ Bounding box ที่เป็น Ground truth และ Bounding box ที่ถูกทำนายค่า IoU จะมีค่าตั้งแต่ 0 ถึง 1 โดยหากค่า IoU เท่ากับ 0 นั่นคือไม่มีพื้นที่ซ้อนทับกันระหว่าง Bounding box ที่ถูกทำนายกับ Bounding box ที่เป็น Ground truth เลย




4. ผลการวิจัยและอภิปราย

4.1 ผลการแบ่งระดับความชัดเจนของภาพทางม้าลาย: ในชุดข้อมูลทางม้าลายในทุกระดับความชัดเจน มีภาพทางม้าลายทั้งหมด 600 ภาพ จากสถานที่ต่าง ๆ กัน และเมื่อกำหนดค่า K เท่ากับ 9 สำหรับการทำ K-means clustering เพื่อหาค่าเกณฑ์สำหรับแบ่งระดับทางม้าลายจากส่วนที่ 3.3.3.2 ได้ค่าเกณฑ์สำหรับแบ่งระดับทางม้าลาย และได้ผลในการแบ่งระดับทางม้าลายดังนี้


4.1.1 ทางม้าลายที่ชัดเจน ใช้ค่าความแตกต่างของค่าความสว่างมากกว่าเท่ากับ 26.026388 ได้ภาพทางม้าลายที่ชัดเจนจำนวน 139 ภาพ ดังภาพ 3

4.1.2 ทางม้าลายที่ชำรุดชัดเจนน้อย ใช้ค่าความแตกต่างของค่าความสว่างน้อยกว่า 26.026388 และมากกว่าเท่ากับ 14.189072 ได้ภาพทางม้าลายที่ชำรุดและชัดเจนน้อยจำนวน 236 ภาพ ดังภาพ 4


4.1.3 ทางม้าลายที่ชำรุดและชัดเจนมาก ใช้ค่าความแตกต่างของค่าความสว่างน้อยกว่า 14.189072 ได้ภาพทางม้าลายที่ชำรุดและชัดเจนมากจำนวน 225 ภาพ ดังภาพ 5



ภาพที่ 3



ภาพที่ 4



ภาพที่ 5

ผู้วิจัยยังได้จัดทำภาพไม่มีทางม้าลายจากคลิปวิดีโอทางม้าลายเป็นจำนวน 413 ภาพ และได้ภาพทางม้าลายที่อยู่ในระยะไกลเป็นจำนวน 54 ภาพ

4.2 ผลการจัดทำชุดข้อมูลภาพทางม้าลายในทุกระดับความชัดเจน

เมื่อนำภาพทางม้าลายในทุกระดับความชัดเจน และภาพไม่มีทางม้าลายที่ได้แบ่งตามสัดส่วนของ Train Validate และ Test เมื่อรวมกันเป็น Train ที่ 70% Validate ที่ 10% และ Test ที่ 20% ที่ต้องการแล้วมีรายละเอียดดังนี้

4.2.1 ชุดข้อมูล Train มีภาพทั้งหมด 713 ภาพ โดยเป็นทางม้าลายที่ชัดเจนจำนวน 99 ภาพ ทางม้าลายที่ชำรุดและชัดเจนน้อยจำนวน 166 ภาพ ทางม้าลายที่ชำรุดและชัดเจนมากจำนวน 158 ภาพ และภาพไม่มีทางม้าลายจำนวน 290 ภาพ

4.2.2 ชุดข้อมูล Validate มีภาพทั้งหมด 99 ภาพ โดยเป็นทางม้าลายที่ชัดเจนจำนวน 13 ภาพ ทางม้าลายที่ชำรุดและชัดเจนน้อยจำนวน 23 ภาพ ทางม้าลายที่ชำรุดและชัดเจนมากจำนวน 22 ภาพ และภาพไม่มีทางม้าลายจำนวน 41 ภาพ

4.2.3 ชุดข้อมูล Test มีภาพทั้งหมด 201 ภาพ โดยเป็นทางม้าลายที่ชัดเจนจำนวน 27 ภาพ ทางม้าลายที่ชำรุดและชัดเจนน้อยจำนวน 47 ภาพ ทางม้าลายที่ชำรุดและชัดเจนมากจำนวน 45 ภาพ และภาพไม่มีทางม้าลายจำนวน 82 ภาพ ซึ่งสำหรับชุดข้อมูล Test ผู้วิจัยยังได้แยกเป็นชุดข้อมูล Test สำหรับทางม้าลายในแต่ละระดับความชัดเจนจากชุดข้อมูล Test หลักที่มีภาพทั้งหมด 201 ภาพ ไว้อีกด้วย เพื่อใช้ในการวิเคราะห์ข้อมูลให้ชัดเจนมากขึ้น



สำหรับสาเหตุที่ภาพทางม้าลายที่ชัดเจนมีจำนวนน้อยกว่าทางม้าลายที่ชำรุดและซีดจางเป็นเพราะภาพทางม้าลายที่ชัดเจนมักมีจำนวนค่าความแตกต่างฯ ในภาพเป็นจำนวนมากกว่าภาพทางม้าลายที่ชำรุดและซีดจาง นั่นคือภาพทางม้าลายที่ชัดเจนมักจะมีส่วนขาวของทางม้าลายในภาพที่สมบูรณ์เป็นจำนวนมากในภาพ ในขณะที่ภาพทางม้าลายที่ชำรุดและซีดจางมักจะมีส่วนขาวของทางม้าลายในภาพเป็นจำนวนน้อยเนื่องจากได้ชำรุดและซีดจางจนไม่สามารถทำ Polygon label ได้นั่นเอง นอกจากนี้ภาพทางม้าลายที่ชำรุดและซีดจางหลายภาพแท้จริงแล้วอาจไม่ได้ชำรุดและซีดจางมากแต่เป็นเพราะถูกแสงสะท้อนที่ทางม้าลายทำให้มองเห็นความแตกต่างระหว่างส่วนขาวและส่วนดำของทางม้าลายได้ยาก

4.3 ผลการจัดชุดข้อมูลทางม้าลายเฉพาะระดับที่ชัดเจนกับภาพไม่มีทางม้าลาย

ในส่วนของการนำเสนอเพื่อชี้ให้เห็นปัญหาของการไม่ใช้ภาพทางม้าลายที่ชำรุดและซีดจางในการสร้างโมเดล ผู้วิจัยได้จัดทำชุดข้อมูล Train ที่ 70% Validate 10% และ Test ที่ 20% ที่มีเฉพาะทางม้าลายที่ชัดเจนจำนวน 139 ภาพ กับภาพไม่มีทางม้าลายจำนวน 413 ภาพ สำหรับสร้างโมเดลตรวจจับทางม้าลาย แล้วนำไปใช้ตรวจจับทางม้าลายที่มีความชำรุดและซีดจางมาก มีรายละเอียดดังนี้


4.3.1 ชุดข้อมูล Train มีภาพทั้งหมด 389 ภาพ เป็นภาพทางม้าลายชัดเจนจำนวน 99 ภาพ และเป็นภาพไม่มีทางม้าลายจำนวน 290 ภาพ

4.3.2 ชุดข้อมูล Validate มีภาพทั้งหมด 54 ภาพ เป็นภาพทางม้าลายชัดเจนจำนวน 13 ภาพ และเป็นภาพไม่มีทางม้าลายจำนวน 41 ภาพ

4.3.3 ชุดข้อมูล Test มีภาพทั้งหมด 109 ภาพ เป็นภาพทางม้าลายชัดเจนจำนวน 27 ภาพ และเป็นภาพไม่มีทางม้าลายจำนวน 82 ภาพ

4.4 ผลการหาค่า Total batch size: ผู้วิจัยใช้ฟังก์ชัน AutoBatch ของ YOLO แล้วได้ค่า Total batch size ที่ 52 ซึ่งหากเทียบกับค่า Nominal batch size ที่ 64 จะทำให้ในแต่ละครั้งของการ Optimization จะเสียโอกาสในการรับภาพไปเป็นส่วนต่างของ 64 และ 52 นั่นคือ 12 ภาพ ผู้วิจัยจึงปรับค่า Batch size ของโมเดลให้เหลือ 32 ทำให้ค่า Accumulate เพิ่มขึ้นเป็น 2 ซึ่งแม้ว่าจะใช้เวลาในการ Optimization เพิ่มขึ้นแต่ในการ Optimization แต่ละครั้งจะได้จำนวนภาพที่สูงสุดที่ 64 ภาพ เพื่อให้โมเดลได้เรียนรู้ข้อมูลทางม้าลายอย่างเต็มที่ในการ Optimization แต่ละครั้ง

4.5 ผลการหาจำนวน Epoch: ผู้วิจัยได้ตั้งค่า YOLOv8 โดยใช้ค่า Batch size ที่ 32 ค่า Epoch ที่ 1000 และตั้งค่า Optimizer เป็น AdamW รวมถึงตั้งค่าให้มีการ Validate โมเดล และค่า Patience ตั้งเป็น 0 คือไม่มีการทำ Early stopping สำหรับ Argument ที่เหลือใช้เป็นค่าตั้งต้น แล้วตั้ง Train โมเดล แล้วนำผลลัพธ์ที่ได้ทำการสร้างกราฟระหว่างค่า Bounding box loss ของการ Train และ Validate พบว่าจุดที่ Validate loss มีอัตราการลดลงต่างกับ Train loss อย่างชัดเจนอยู่ที่ 500 Epoch ดังภาพ 6 ซึ่งเป็นจำนวน Epoch ที่เหมาะสมกับการสร้างโมเดลตรวจจับทางม้าลายในทุกระดับความชัดเจน



ภาพที่ 6

4.6 ผลการใช้ YOLOv8 ในการตรวจจับทางม้าลายในทุกระดับความชัดเจน: ผู้วิจัยได้ตั้งค่าการ Train YOLOv8 โดยจำนวน Epoch ตั้งไว้ที่ 500 และค่า Patience ตั้งให้ทำ Early stopping ไว้ที่ 100 epoch สำหรับ Argument ที่เหลือตั้งไว้เหมือนข้อ 4.5 ซึ่งได้ผลการทดสอบกับชุดข้อมูล Test ดังตารางที่ 3 และ 4

ตารางที่ 3 ผลการตรวจจับทางม้าลายในทุกระดับความชัดเจนกับชุดข้อมูล Test

		Bounding box				
ชุดข้อมูล	Class	mAP50	mAP50-95	Precision	Recall	Accuracy
รวม	ส่วนขาว	0.962	0.773	0.94	0.93	0.87
ชัดเจน	ส่วนขาว	0.982	0.812	0.95	0.94	0.9
ชัดเจนน้อย	ส่วนขาว	0.974	0.813	0.94	0.95	0.89
ชัดเจนมาก	ส่วนขาว	0.939	0.704	0.92	0.89	0.83

ตารางที่ 4 ผล Confusion matrix ของการตรวจจับทางม้าลายในทุกระดับความชัดเจนกับชุดข้อมูล Test

ชุดข้อมูล			ค่าจริง	
			ส่วนขาว	พื้นหลัง
รวม	ทำนาย	ส่วนขาว	0.879	0.054
		พื้นหลัง	0.066	0
ชัดเจน	ทำนาย	ส่วนขาว	0.9	0.042
		พื้นหลัง	0.049	0
ชัดเจนน้อย	ทำนาย	ส่วนขาว	0.896	0.056
		พื้นหลัง	0.046	0
ชัดเจนมาก	ทำนาย	ส่วนขาว	0.836	0.063
		พื้นหลัง	0.1	0




จากผลการทดลองพบว่าโมเดล YOLOv8 ที่ถูกสร้างจากภาพทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลายมีประสิทธิภาพในการตรวจจับทางม้าลายที่มีความชำรุดและซีดจางได้ดีกว่า โมเดล YOLOv8 ที่ถูกสร้างจากภาพทางม้าลายที่มีความชัดเจนและภาพไม่มีทางม้าลาย โดยหากเทียบกับการตรวจจับทางม้าลายที่ชำรุดและซีดจางมากด้วยกัน โมเดลที่สร้างจากภาพทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลายได้ค่า mAP50-95 ดีกว่า 10.1% ได้ค่า Recall ดีกว่า 9% ได้ค่า True positive ดีกว่า 9.2% และค่า False negative ดีกว่า 7.9% จึงเห็นได้ว่าหากไม่มีการให้ภาพทางม้าลายที่มีความชำรุดและซีดจางให้กับโมเดลได้เรียนรู้ โมเดลก็จะตรวจจับทางม้าลายที่ชำรุดและซีดจางได้แย่ง ดังที่ปรากฏทั้งในส่วนของความแม่นยำในแต่ละครั้งที่ทำนายจากค่า Precision และจำนวนทางม้าลายที่ชำรุดและซีดจางที่ไม่สามารถตรวจจับได้จากค่า False positive ดังนั้น ชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนของผู้วิจัยจึงมีส่วนส่งเสริมให้สามารถสร้างโมเดลที่ตรวจจับทางม้าลายที่ชำรุดและซีดจางได้ดียิ่งขึ้น

นอกจากนี้ แม้ในส่วนของการทางม้าลายที่มีความชัดเจนก็ยังมีประสิทธิภาพในการตรวจจับที่ดีในระดับใกล้เคียงกัน แม้ว่าโมเดลที่สร้างจากภาพทางม้าลายที่มีความชัดเจนและภาพไม่มีทางม้าลายจะมีค่า Precision เท่ากัน Recall ดีกว่า 2% True positive ดีกว่า 1.6% False negative ดีกว่า 7.4% แต่เมื่อเทียบกับผลการทดลองของโมเดลกับทางม้าลายที่ชำรุดและซีดจางมากซึ่งทำได้แย่งกว่าโมเดลที่ถูกสร้างจากภาพทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลาย จึงกล่าวได้ว่าโมเดลที่สร้างจากภาพทางม้าลายที่มีความชัดเจนและภาพไม่มีทางม้าลายมีความ Overfit เพราะมีประสิทธิภาพแย่งกับทางม้าลายที่ชำรุดและซีดจางมาก นอกจากนี้ค่า mAP50-95 ของโมเดลของผู้วิจัยยังมีค่าที่ดีกว่า 1.8% แสดงให้เห็นว่าภาพทางม้าลายในทุกระดับความชัดเจนมีส่วนส่งเสริมให้โมเดลสามารถทำนายตำแหน่งของ Bounding box ได้แม่นยำกว่าโมเดลที่ถูกสร้างจากภาพทางม้าลายที่ชัดเจนและภาพไม่มีทางม้าลายด้วย อย่างไรก็ตาม โมเดลยังมี False positive ที่ 5.4% กับภาพไม่มีทางม้าลายที่โมเดลเข้าใจว่าสัญลักษณ์จราจรอื่นบนถนน เช่น ตัวหนังสือ และลูกศร เป็นทางม้าลาย


4.7 Precision-Confidence และ Recall-Confidence Curve: ผู้วิจัยได้ใช้ชุดข้อมูล Test ในแต่ละระดับความชัดเจนของทางม้าลายตามข้อ 4.2.3 นำมาวิเคราะห์ค่า Precision และ Recall ที่สัมพันธ์กับค่า Confidence หรือ IoU ที่ 50% หรือคือ mAP50 จากการทำ Object detection ตามที่ได้จากโมเดล YOLO โดยได้ผลการตรวจจับทางม้าลายระหว่างภาพทางม้าลายชัดเจน และภาพทางม้าลายที่ชำรุดและซีดจางมากดังนี้

4.7.1 ทางม้าลายที่ชัดเจน ได้ผล Precision-confidence ดังภาพ 7 และ Recall-confidence ดังภาพ 8


4.7.2 ทางม้าลายที่ชำรุดและซีดจางมาก ได้ผล Precision-confidence ดังภาพ 9 และ Recall-confidence ดังภาพ 10




ภาพที่ 7



ภาพที่ 8



ภาพที่ 9




ภาพที่ 10




จากการเปรียบเทียบผลตรวจจับทางม้าลายที่ชัดเจนกับทางม้าลายที่จางและซีดจางมาก หากพิจารณาจาก Precision-confidence และ Recall confidence พบว่าโมเดลสามารถตรวจจับส่วนขาวของทางม้าลายได้ดีทั้งทางม้าลายที่ชัดเจนและจางและซีดจางมาก โดยมีค่า Precision เกิน 0.9 ตั้งแต่ค่า Confidence ตั้งแต่ 0.5 ขึ้นไปในการตรวจจับทางม้าลายที่ชัดเจนและจางและซีดจางมาก เพราะว่าส่วนขาวของทางม้าลายมีลักษณะ Pattern ของรูปร่างที่ชัดเจน นั่นคือเป็นรูปทรงสี่เหลี่ยมเหมือนกันทั้งหมดต่างกันเพียงขนาด สี และความชัดเจนของสีและขอบเท่านั้น นอกจากนี้ตำแหน่งของทางม้าลายที่มักอยู่แนวขวางใกล้รถและอยู่บริเวณกลางภาพเกือบทุกรูป ยิ่งทำให้โมเดลจดจำตำแหน่งของทางม้าลายได้ว่าต้องเป็นแนวขวางบริเวณกลางภาพและตรวจจับส่วนขาวของทางม้าลายได้ง่ายยิ่งขึ้น และตำแหน่งของทางม้าลายที่อยู่แนวขวางใกล้รถและอยู่บริเวณกลางภาพก็มีผลทำให้โมเดลสามารถแยกแยะความแตกต่างระหว่างส่วนขาวของทางม้าลายกับเส้นขอบเลนถนน และขอบทางเท้า ได้ดีขึ้น อย่างไรก็ตาม ความคมชัดของภาพและความชัดเจนของส่วนขาวของทางม้าลายเป็นสิ่งที่ทำให้เกิดความไม่แน่นอนซึ่งเมื่อโมเดลพยายามลด False negative ในการตรวจจับทางม้าลายที่จางและซีดจางมาก โดยเพิ่มค่า Confidence ตั้งแต่ 0.6 ขึ้นไป แต่ค่า Recall กลับลดลงอย่างรวดเร็ว และไม่สามารถตรวจจับทางม้าลายที่จางและซีดจางมากได้เลยหากเพิ่มค่า Confidence ไปถึงระดับ 0.9 ดังนั้นความชัดเจนของภาพทางม้าลาย และความจางและซีดจางของทางม้าลายเอง เป็นปัจจัยที่มีผลต่อความแม่นยำในการตรวจจับส่วนขาวของทางม้าลาย แต่แม้ความแม่นยำของโมเดลจะลดในการตรวจจับทางม้าลายที่จางและซีดจาง แต่ความแม่นยำที่ลดจากค่า Confidence ที่ต่ำไม่ได้หมายความว่าตรวจจับส่วนขาวของทางม้าลายในภาพนั้นไม่ได้ เพียงแต่ว่าตำแหน่งของ Bounding box มีความคลาดเคลื่อนมากกว่า Bounding box ที่เป็น Ground truth โดยมีความคลาดเคลื่อน ไปจาก Ground truth box ที่ 38% ที่ค่า Recall 0.8

4.8 ผลการตรวจจับทางม้าลายในทุกระดับความชัดเจนที่อยู่ไกล: ผู้วิจัยได้ใช้โมเดลที่สร้างจากภาพทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลายมาทำการตรวจจับทางม้าลายในชุดข้อมูลทางม้าลายที่อยู่ในระยะไกล และพบว่าถ้าทางม้าลายอยู่ไกลจะตรวจจับทางม้าลายยากขึ้น หากตรวจจับได้ก็มักตรวจจับส่วนขาวของทางม้าลายได้ไม่ครบทุกส่วนในภาพนั้น ดังภาพ 11 เทียบกับภาพ 12 ที่เป็นการตรวจจับทางม้าลายที่อยู่ใกล้ ส่วนสาเหตุที่เป็นเช่นนี้เพราะว่าทางม้าลายในชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนอยู่ใกล้และอยู่ตรงกลางภาพทั้งหมด จึงทำให้โมเดลเห็นว่าตำแหน่งของทางม้าลายในภาพจะมี Pattern ที่จะอยู่กลางภาพและอยู่ใกล้นั่นเอง



ภาพที่ 11



ภาพที่ 12



5. บทสรุปและข้อเสนอแนะ

ตามที่เป็นปัจจุบันชุดข้อมูลที่มีภาพทางม้าลายในทุกระดับความชัดเจนยังมีน้อย ผู้วิจัยจึงได้จัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนและภาพไม่มีทางม้าลายเพื่อใช้สร้างโมเดล YOLOv8 ที่ใช้ตรวจจับทางม้าลายในทุกระดับความชัดเจนได้ จากผลการทดลองพบว่าหากสร้างโมเดลจากภาพทางม้าลายที่มีความชัดเจนและภาพไม่มีทางม้าลายโมเดลจะ Overfit และตรวจจับทางม้าลายที่ชำรุดและซีดจางมากได้ไม่คืนัก และเมื่อสร้างโมเดลจากภาพทางม้าลายในทุกระดับความชัดเจนรวมทั้งภาพไม่มีทางม้าลาย โมเดลสามารถตรวจจับทางม้าลายในแต่ละระดับความชัดเจนได้ดี นอกจากนี้ยังพบว่าที่โมเดลของผู้วิจัยมีประสิทธิภาพที่ดีส่วนหนึ่งมาจาก โมเดลได้จดจำตำแหน่งของทางม้าลายในภาพที่อยู่ใกล้และอยู่กลางภาพเป็น Pattern ของทางม้าลายด้วย และเป็นสิ่งที่ควรพัฒนาต่อไป และยังพบอีกว่าความชัดเจนของ Pattern ทางม้าลายในภาพที่ตรวจจับยังคงเป็นปัจจัยสำคัญที่ส่งผลต่อการเพิ่มหรือลดประสิทธิภาพในการตรวจจับทางม้าลาย อย่างไรก็ตามโมเดลยังมี False positive จากการไม่สามารถแยกแยะสัญลักษณ์บนถนนบางอย่างที่ไม่ใช่ทางม้าลาย

เพื่อพัฒนางานวิจัยในประเด็นนี้ต่อไปจึงควรจัดทำชุดข้อมูลทางม้าลายในทุกระดับความชัดเจนให้มีคุณภาพที่ดียิ่งขึ้น เช่น การใช้กล้องบันทึกวิดีโอที่มีความคมชัดของภาพมากขึ้นและมีระบบกันการสะท้อนขณะบันทึกภาพที่ดี รวมถึงควรมีการจัดทำชุดข้อมูลทางม้าลายที่ครอบคลุมระยะห่างระหว่างทางม้าลายและตัวรถอย่างน้อย 2 ระยะ คือ ใกล้และไกล และเพิ่มจำนวนภาพไม่มีทางม้าลายให้มากขึ้นในแต่ละประเด็น เช่น ประเด็นสัญลักษณ์จราจรอื่น ๆ บนถนนที่ไม่ใช่ทางม้าลาย นอกจากนี้ เมื่อสามารถสร้างโมเดลให้ตรวจจับทางม้าลายในทุกระดับความชัดเจน และในหลายระยะห่างจากตัวรถ ได้อย่างดีแล้ว ก็ควรที่จะนำโมเดลนั้น และชุดข้อมูลนั้น มาพัฒนาต่อให้สามารถตรวจจับวัตถุในภาพชนิดอื่น ๆ นอกเหนือจากทางม้าลายได้ด้วยเพื่อให้สอดคล้องกับสภาพการขับขี่จริง เช่น คนเดินถนน รถยนต์ เส้นขอบเลนถนน สัญลักษณ์จราจร ฯลฯ ซึ่งเมื่อสามารถตรวจจับวัตถุหลายชนิดในภาพได้อย่างดีแล้ว ก็ควรพัฒนาโมเดลและชุดข้อมูลต่อไปอีกให้สามารถตรวจจับวัตถุกับชุดข้อมูลที่เป็นภาพเคลื่อนไหวได้ และโมเดลยังควรรองรับการพยากรณ์ทิศทางเคลื่อนที่ของวัตถุในภาพในระยะสั้น ๆ เช่น การเคลื่อนที่ของรถ การเคลื่อนที่ของคน ฯลฯ รวมถึงการวิเคราะห์บริบทของสถานการณ์ในขณะนั้น เช่น ช่วงรถติด ช่วงรถเคลื่อนที่ช้า ช่วงรถเคลื่อนที่ช้า และรวมถึงสถานการณ์ที่อาจเกิดอุบัติเหตุต่าง ๆ ด้วย เพื่อให้ได้โมเดลที่สามารถใช้งานได้จริงกับการใช้ยานยนต์อัตโนมัติ มากไปกว่าเพื่อใช้ตรวจจับทางม้าลายแต่เพียงอย่างเดียว

เอกสารอ้างอิง

- Cao, Z., Xu, X., Hu, B. & Zhou, M. (2021). *Rapid Detection of Blind Roads and Crosswalks by Using a Lightweight Semantic Segmentation Network*, in IEEE Transactions on Intelligent Transportation Systems, vol. 22, no. 10, pp. 6188-6197, Oct. 2021. doi: 10.1109/TITS.2020.2989129.
- Engineering and Automated Learning – IDEAL 2020. IDEAL 2020. Lecture Notes in Computer Science(), vol 12490. Springer, Cham. doi: 10.1007/978-3-030-62365-4_59
- Grigorescu, M. S., Trasnea, B., Cocias, T. & Macesanu, G. (2019). *A survey of deep learning techniques for autonomous driving*. Journal of Field Robotics. 37. 10.1002/rob.21918.
- Informatics 2021. AISI 2021. Lecture Notes on Data Engineering and Communications Technologies, vol 100. Springer, Cham. doi: 10.1007/978-3-030-89701-7_6



- Ivanchenko, V., Coughlan, J. & Shen, H. (2008). *Detecting and locating crosswalks using a camera phone*. 2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, Anchorage, AK, USA. (pp. 1-8). doi: 10.1109/CVPRW.2008.4563143.
- Jocher, G., Munawar, R. & Exel, A. (2023, November 12). Ultralytics YOLO Docs. *ultralytics*. Retrieved from: <https://docs.ultralytics.com/#yolo-licenses-how-is-ultralytics-yolo-licensed>
- Redmon, J., & Farhadi, A. (2017). *YOLO9000: Better, Faster, Stronger*. arXiv preprint arXiv:1612.08242.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 779-788).
- Rúbio, R.P.M. T., Cruz, A. J., Jacob, J., Garrido, D., Cardoso, L. H., Silva, D. & Rodrigues R. (2020). *A Semi-automatic Object Identification Technique Combining Computer Vision and Deep Learning for the Crosswalk Detection Problem*. In: Analide, C., Novais, P., Camacho, D. & Yin, H. (eds) Intelligent Data
- S. Suzuki, P. Raksincharoensak, I. Shimizu, M. Nagai & R. Adomat (2010). *Sensor fusion-based pedestrian collision warning system with crosswalk detection*. 2010 IEEE Intelligent Vehicles Symposium, La Jolla, CA, USA. (pp. 355-360). doi: 10.1109/IVS.2010.5548120.
- Shrivastava, A., Gupta, A., & Girshick, R. (2016). *Training Region-based Object Detectors with Online Hard Example Mining*. arXiv preprint arXiv:1604.03540.
- Trinh, T.D., Nguyen, T.P., Le, T.N.D., Van Nguyen, N., Debnath, N.C. & Nguyen, V.D. (2022). *Robust Crosswalk Detection Using Deep Learning Approach*. In: Hassanien, A.E., Snášel, V., Chang, KC., Darwish, A. & Gaber, T. (eds) Proceedings of the International Conference on Advanced Intelligent Systems and
- Tümen, V. & Ergen, B. (2020). *Intersections and crosswalk detection using deep learning and image processing techniques*. Physica A: Statistical Mechanics and its Applications, Volume 543. doi:10.1016/j.physa.2019.123510.