



การตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช ด้วย
วิธีการเรียนรู้เชิงลึก

HELMET DETECTION FOR MOTORCYCLE RIDERS AND PASSENGERS IN THE SIRIRAJ
HOSPITAL AREA USING DEEP LEARNING



ธวัชชัย แซ่ลี

การตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช ด้วย
วิธีการเรียนรู้เชิงลึก



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

HELMET DETECTION FOR MOTORCYCLE RIDERS AND PASSENGERS IN THE SIRIRAJ
HOSPITAL AREA USING DEEP LEARNING



THAWATCHAI SAELEE

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์
เรื่อง
การตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช ด้วยวิธีการเรียนรู้เชิงลึก
ของ
ธวัชชัย แซ่ลี่

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์จัตตชัย เอกปัญญาสกุล)
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.วราภรณ์ วิทยานนท์)

..... ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.อัศรา ประโยชน์)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่ โรงพยาบาลศิริราช ด้วยวิธีการเรียนรู้เชิงลึก
ผู้วิจัย	ธวัชชัย แซ่ลี้
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. วราภรณ์ วิทยานนท์

ปัจจุบันการสัญจรภายในพื้นที่โรงพยาบาลศิริราชด้วยรถจักรยานยนต์ ยังคงพบการไม่สวมใส่หมวกนิรภัย ซึ่งอาจจะนำมาสู่การบาดเจ็บรุนแรงบริเวณศีรษะของผู้ขับขี่และผู้ซ้อนในกรณีที่เกิดอุบัติเหตุ ในอดีตการตรวจจับการสวมใส่หมวกนิรภัยนั้นจะทำได้ด้วยวิธีการสังเกตการณ์ด้วยตัวบุคคล (Manual system) ทำให้เกิดความผิดพลาดขึ้นได้ (Human error) อันเนื่องมาจากสายตาและสมองของมนุษย์มีข้อจำกัดในการมองเห็นและการจดจำ ความผิดพลาดของการตรวจจับจะส่งผลให้ไม่เป็นไปตามนโยบายเรื่องกำหนดมาตรการให้คณะแพทยศาสตร์ศิริราชพยาบาล เป็นเขตสวมหมวกนิรภัย พ.ศ. 2563 งานวิจัยนี้จึงได้นำเสนอการตรวจจับการสวมใส่หมวกนิรภัยของผู้ขับขี่และผู้นั่งซ้อนท้ายที่สัญจรภายในโรงพยาบาลศิริราช ด้วยการเรียนรู้จากชุดข้อมูลที่เกิดขึ้นรวบรวมจากกล้องวงจรปิด (Custom data) ร่วมกับโมเดลการเรียนรู้เชิงลึก YOLOv8 ซึ่งเป็นโมเดลที่ใช้สำหรับงานตรวจจับวัตถุ (Objective Detection) เพื่อมาทดแทนวิธีการสังเกตการณ์ด้วยตัวบุคคล ทำให้ได้ผลลัพธ์คือโมเดล YOLOv8l และ YOLOv8x มีประสิทธิภาพสูงที่สุดจากทุกโมเดลโดย YOLOv8l มีค่าเฉลี่ยความแม่นยำ (Precision) อยู่ที่ 0.868, ค่าเฉลี่ยความถูกต้อง (Recall) อยู่ที่ 0.790, ค่าเฉลี่ย mAP50 อยู่ที่ 0.859 และค่าเฉลี่ย F1-Score อยู่ที่ 0.827 ส่วน YOLOv8x มีค่าเฉลี่ยความแม่นยำ (Precision) อยู่ที่ 0.842, ค่าเฉลี่ยความถูกต้อง (Recall) อยู่ที่ 0.811, ค่าเฉลี่ย mAP50 อยู่ที่ 0.858 และค่าเฉลี่ย F1-Score อยู่ที่ 0.826

คำสำคัญ : การตรวจจับหมวกนิรภัย, การตรวจจับวัตถุ, การเรียนรู้เชิงลึก, YOLOv8

Title	HELMET DETECTION FOR MOTORCYCLE RIDERS AND PASSENGERS IN THE SIRIRAJ HOSPITAL AREA USING DEEP LEARNING
Author	THAWATCHAI SAELEE
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Assistant Professor Dr. Waraporn Viyanon , Ph.D.

Siriraj Hospital has a large number of patients, who use motorcycles without helmets, leading to serious injuries when accidents occur. To address this issue, the hospital implemented a policy in 2020 requiring everyone at Siriraj Faculty of Medicine to wear a helmet. However, visual inspection by staff has limitations and is prone to errors, making it difficult to enforce the policy. This research presents a system for detecting helmet use by riders and passengers within Siriraj Hospital. The system uses the YOLOv8 deep learning model for object detection, trained on a custom dataset collected from CCTV cameras. This approach outperforms manual observation and achieves high accuracy, with a precision of 0.868, recall of 0.790, mAP50 of 0.859, and F1-Score of 0.827 for YOLOv8l and a precision of 0.842, recall of 0.811, mAP50 of 0.858, and F1-Score of 0.826 for YOLOv8x. The system has the potential to improve helmet compliance and reduce motorcycle-related injuries at Siriraj Hospital.

Keyword : Helmet Detection, Object Detection, Deep Learning, YOLOv8

กิตติกรรมประกาศ

สารนิพนธ์นี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์จาก ผศ.ดร.วราภรณ์ วิทยานนท์ อาจารย์ที่ปรึกษาที่ให้คำปรึกษา คำแนะนำในการทำสารนิพนธ์ ตลอดจนสนับสนุนข้อมูลทางวิชาการและข้อมูล สำหรับทำสารนิพนธ์นี้

ขอกราบขอบพระคุณคณะกรรมการสอบสารนิพนธ์ที่ได้ให้คำแนะนำและข้อเสนอแนะ สำหรับการปรับปรุงสารนิพนธ์



ธวัชชัย แซ่ลิ้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของโครงการ	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
บทที่ 2 วรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	3
2.1 ความรู้เกี่ยวกับหมวกนิรภัยสำหรับผู้ขับขี่รถจักรยานยนต์.....	3
2.2 คอมพิวเตอร์วิทัศน์.....	5
2.3 การประมวลผลภาพแบบดิจิทัล (Digital Image Processing)	6
2.4 บริเวณที่สนใจ (Region-of-interest หรือ ROI)	7
2.5 ปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI)	7
2.5.1 การเรียนรู้ของเครื่อง (Machine Learning)	9
2.5.2 การเรียนรู้แบบมีผู้สอน (Supervised Learning)	11
2.5.3 การแบ่งประเภทข้อมูล (Classification).....	11
2.5.4 การเรียนรู้เชิงลึก (Deep Learning).....	12

2.5.5 Convolution Neural Network (CNN)	12
2.5.6 Object Detection	13
2.5.7 YOLO	14
2.6 การประเมินประสิทธิภาพ	15
2.7 งานวิจัยที่เกี่ยวข้อง	18
บทที่ 3 วิธีการดำเนินการวิจัย	21
3.1 กระบวนการสร้างและทำงานของแบบจำลอง	21
3.2 เก็บรวบรวมข้อมูล	22
3.3 ทำการแปลงข้อมูลให้กลายเป็นข้อมูลที่สามารถนำไปวิเคราะห์	24
3.4 กำหนดกรอบวัตถุที่ต้องการ (Bounding Box)	28
3.5 การเสริมข้อมูล (Data Augmentation)	33
3.6 ฝึกแบบจำลอง	33
3.6 สรุปแนวคิดและวิธีวิจัย	38
บทที่ 4 ผลการวิจัย	40
รายละเอียดการทดลอง	40
ผลการทดลอง	40
ผลลัพธ์จากชุดข้อมูลที่ทำเทคนิคการเสริมข้อมูล Data Augmentation	43
การประเมินผลลัพธ์รูปภาพจากชุดข้อมูลทดสอบ	47
บทที่ 5 สรุปผลการวิจัย	54
5.1 สรุปผลการวิจัย	54
5.2 ปัญหาและอุปสรรคในการดำเนินการวิจัย	55
5.3 ข้อเสนอแนะ	56
บรรณานุกรม	57

ประวัติผู้เขียน.....59



สารบัญตาราง

	หน้า
ตาราง 1 การเปรียบเทียบการตรวจจำวัตถุ ชุดข้อมูล อัลกอริทึม และผลลัพธ์ของบทความวิจัยที่เกี่ยวข้อง.....	20
ตาราง 2 ผลลัพธ์ที่ได้จากการฝึกแบบจำลอง YOLOv8	36
ตาราง 3 ผลลัพธ์ที่ได้จากการตรวจสอบความถูกต้องของแบบจำลอง YOLOv8.....	37
ตาราง 4 การตั้งค่าพารามิเตอร์ที่สำคัญในการฝึกโมเดล.....	40
ตาราง 5 การประเมินผลลัพธ์โดยรวมของโมเดลแต่ละรุ่น	41
ตาราง 6 ผลลัพธ์คลาสสวมหมวกนิรภัย (Helmet) ของโมเดลแต่ละรุ่น	42
ตาราง 7 ผลลัพธ์คลาสรถจักรยานยนต์ (Motorcycle) ของโมเดลแต่ละรุ่น	42
ตาราง 8 ผลลัพธ์คลาสไม่สวมหมวกนิรภัย (No Helmet) ของโมเดลแต่ละรุ่น	43
ตาราง 9 การประเมินผลลัพธ์โดยรวมของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำการเสริมข้อมูล (Data Augmentation)	44
ตาราง 10 ผลลัพธ์คลาสสวมหมวกนิรภัย (Helmet) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำการเสริมข้อมูล (Data Augmentation)	45
ตาราง 11 ผลลัพธ์คลาสรถจักรยานยนต์ (Motorcycle) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำการเสริมข้อมูล (Data Augmentation).....	45
ตาราง 12 ผลลัพธ์คลาสไม่สวมหมวกนิรภัย (No Helmet) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำการเสริมข้อมูล (Data Augmentation)	46

สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 หมวกนิรภัยชนิดเต็มหน้า (Full Face Helmet)	3
ภาพประกอบ 2 หมวกนิรภัยชนิดเต็มศีรษะ (Jet Helmet)	4
ภาพประกอบ 3 หมวกนิรภัยชนิดครึ่งศีรษะ (Half Helmet).....	4
ภาพประกอบ 4 การประมวลผลภาพดิจิทัล	6
ภาพประกอบ 5 ตัวอย่างการกำหนดบริเวณที่สนใจ	7
ภาพประกอบ 6 ประเภทของ Machine Learning.....	10
ภาพประกอบ 7 Convolutional Neural Network ร่วมกับ Fully-Connected Neural Network .	13
ภาพประกอบ 8 ตัวอย่างงานตรวจจับวัตถุ	14
ภาพประกอบ 9 สถาปัตยกรรมอัลกอริทึม YOLO	15
ภาพประกอบ 10 ตาราง Confusion Matrix (Kevin Markham, 2014)	16
ภาพประกอบ 11 กระบวนการสร้างและทำงานของแบบจำลอง	21
ภาพประกอบ 12 บริเวณประตู 1	23
ภาพประกอบ 13 บริเวณประตู 5.....	23
ภาพประกอบ 14 บริเวณประตู 7	23
ภาพประกอบ 15 บริเวณประตู 8.....	24
ภาพประกอบ 16 การตั้งค่าโปรแกรม VLC ในการแปลงข้อมูลวิดีโอให้เป็นข้อมูลรูปภาพ	24
ภาพประกอบ 17 ผลลัพธ์การแปลงข้อมูลวิดีโอให้เป็นรูปภาพ.....	25
ภาพประกอบ 18 ผู้ขับขี่รถจักรยานยนต์ที่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)	25
ภาพประกอบ 19 ผู้ขับขี่รถจักรยานยนต์ที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)	26
ภาพประกอบ 20 ผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนที่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)	26

ภาพประกอบ 21 ผู้ขับขีรถจักรยานยนต์ที่สวมหมวกนิรภัยและผู้ซ้อนที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)..... 27

ภาพประกอบ 22 ผู้ขับขีรถจักรยานยนต์และผู้ซ้อนที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้) 27

ภาพประกอบ 23 ถนนที่ไม่มีผู้ขับขีรถจักรยานยนต์และผู้ซ้อน (รูปภาพที่ไม่สามารถใช้งานได้แต่นำไปทดสอบแบบจำลองได้) 28

ภาพประกอบ 24 ตัวอย่างเว็บไซต์ Roboflow ที่ใช้ในการกำหนดกรอบวัตถุ (Bounding Box) ... 29

ภาพประกอบ 25 กรอบวัตถุรถจักรยานยนต์จากเว็บไซต์ Roboflow..... 29

ภาพประกอบ 26 กรอบวัตถุผู้ขับขีรถจักรยานยนต์สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow.... 30

ภาพประกอบ 27 กรอบวัตถุผู้ขับขีรถจักรยานยนต์ไม่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow 30

ภาพประกอบ 28 กรอบวัตถุผู้ขับขีรถจักรยานยนต์และผู้ซ้อนที่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow 30

ภาพประกอบ 29 กรอบวัตถุผู้ขับขีรถจักรยานยนต์ที่สวมใส่หมวกนิรภัยและผู้ซ้อนไม่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow 31

ภาพประกอบ 30 กรอบวัตถุผู้ขับขีรถจักรยานยนต์และผู้ซ้อนไม่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow 31

ภาพประกอบ 31 การแบ่งชุดข้อมูลสำหรับใช้ในการเทรนนิ่งและทดสอบแบบจำลองจากเว็บไซต์ Roboflow 32

ภาพประกอบ 32 การเลือก Format เป็น YOLOv8 และทำการ Export dataset ออกมาเป็นลักษณะ Code..... 32

ภาพประกอบ 33 ตัวอย่าง Code ของชุดข้อมูลที่เตรียมไว้ใช้ในขั้นตอนการฝึกแบบจำลอง 33

ภาพประกอบ 34 โค้ดเรียกใช้ไลบรารี Ultralytics..... 34

ภาพประกอบ 35 คำสั่งติดตั้ง YOLOv8 และคำสั่งอื่นๆที่เกี่ยวข้อง 34

ภาพประกอบ 36 ตัวอย่างโค้ดของชุดข้อมูลจากเว็บไซต์ Roboflow 34

ภาพประกอบ 37 ตารางเปรียบเทียบ Pre-trained Weights ของ YOLOv8 สำหรับ Task detection.....	36
ภาพประกอบ 38 ตัวอย่างสคริปต์ภาษา Python ในการฝึกแบบจำลอง YOLOv8 และการกำหนดพารามิเตอร์.....	36
ภาพประกอบ 39 ตัวอย่างสคริปต์ภาษา Python ในการตรวจสอบความถูกต้องของแบบจำลอง YOLOv8	37
ภาพประกอบ 40 ตัวอย่างสคริปต์ภาษา Python ในการทดสอบแบบจำลอง YOLOv8	38
ภาพประกอบ 41 ตัวอย่างผลลัพธ์ในการทดสอบแบบจำลอง YOLOv8	38
ภาพประกอบ 42 แสดงการเปรียบเทียบปริมาณข้อมูลทุกคลาสที่ใช้ในการฝึกโมเดล	43
ภาพประกอบ 43 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 7.....	47
ภาพประกอบ 44 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 8.....	47
ภาพประกอบ 45 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8.....	48
ภาพประกอบ 46 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8.....	48
ภาพประกอบ 47 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7	49
ภาพประกอบ 48 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7	49
ภาพประกอบ 49 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7	50
ภาพประกอบ 50 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 5.....	50

ภาพประกอบ 51 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1	51
ภาพประกอบ 52 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1	51
ภาพประกอบ 53 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 5	52
ภาพประกอบ 54 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1.....	52
ภาพประกอบ 55 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1	53
ภาพประกอบ 56 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8	53

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

คณะแพทยศาสตร์ศิริราชพยาบาล เป็นสถานที่ให้บริการทางการแพทย์ โดยมีบุคลากร นักศึกษา และประชาชนทั่วไปเข้ามาใช้บริการเป็นจำนวนมาก พบว่าปัญหาความปลอดภัยด้านการจราจร เป็นปัญหาที่สำคัญเนื่องจากภายในคณะแพทยศาสตร์ศิริราชพยาบาลมีรถยนต์และรถจักรยานยนต์สัญจรไปมาเป็นจำนวนมาก ซึ่งบางครั้งก็ทำให้เกิดอุบัติเหตุบนท้องถนนขึ้นได้ โดยอุบัติเหตุที่เกิดขึ้นนั้นมักมีความเชื่อมโยงกับการขับขี่ที่ไม่ปลอดภัย ปัญหาที่น่ากังวลที่สุด คือ การไม่สวมหมวกนิรภัยในขณะขับขี่ นำมาซึ่งผลกระทบต่อร่างกายเนื่องจากอุบัติเหตุทางถนนที่เกิดขึ้น บางครั้งอาจทำให้เกิดบาดแผลที่ศีรษะและบริเวณใบหน้า การสวมหมวกนิรภัยช่วยป้องกันการกระทบกระเทือนที่ศีรษะและลดความเสี่ยงในการเกิดความเสียหายทางร่างกายที่รุนแรงในกรณีเกิดอุบัติเหตุขึ้น ในการนี้จึงได้มีการจัดตั้งโครงการศิริราชรณรงค์สวมหมวกนิรภัยขึ้น ซึ่งดำเนินการตั้งตั้งแต่ปี พ.ศ.2562 จนถึงปัจจุบัน ทั้งนี้ได้กำหนดมาตรการให้คณะแพทยศาสตร์ศิริราชพยาบาล เป็นเขตสวมหมวกนิรภัยและปฏิบัติตามกฎจราจร รวมถึงบทลงโทษในกรณีพบผู้ขับขี่หรือผู้ซ้อนท้ายรถจักรยานยนต์ที่ไม่สวมหมวกนิรภัย เพื่อดำเนินการตามมาตรการสำหรับผู้ฝ่าฝืนและกำหนดให้คณะทำงานรับผิดชอบการเปลี่ยนแปลงนโยบายสู่การปฏิบัติ โดยปัญหาที่พบจากการปฏิบัติ คือ การตรวจจับการสวมหมวกนิรภัย โดยใช้ระบบสังเกตการณ์ด้วยบุคคล (Manual System) ทำให้อาจเกิดความผิดพลาด (Human Error) ได้เป็นอย่างมาก จากการที่ตัวบุคคลไม่สามารถตรวจจับการสวมหมวกนิรภัยได้อย่างครบถ้วนจากการที่มีรถจักรยานยนต์สัญจรไปมาเป็นจำนวนมาก และยังมีข้อจำกัดทางสายตาและกระบวนการจดจำของมนุษย์

จากปัญหาดังกล่าว จึงมีความคิดริเริ่มจัดทำระบบตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์โดยใช้การเรียนรู้ของเครื่องจักรเพื่อใช้ในการตรวจจับผู้ขับขี่และผู้ซ้อนท้ายรถจักรยานยนต์ว่าสวมหมวกนิรภัยหรือไม่ ทางผู้วิจัยจึงได้พัฒนาระบบตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์โดยใช้อัลกอริทึม YOLOV8 วิเคราะห์ข้อมูลวิดีโอที่ได้จากกล้องวงจรปิด เพื่อพัฒนาระบบตรวจจับการสวมหมวกนิรภัยทดแทนการสังเกตการณ์ด้วยตัวบุคคลเพื่อตรวจจับวัตถุที่เคลื่อนที่และทำการจำแนกข้อมูล (Classification) โดยจำแนกว่าวัตถุที่เคลื่อนที่ เป็นรถจักรยานยนต์หรือรถประเภทอื่น เพื่อใช้ในการเก็บรวบรวมข้อมูลของผู้ขับขี่และผู้โดยสารรถจักรยานยนต์ และนำไปพัฒนาต่อเพื่อตรวจจับผู้ขับขี่รถจักรยานยนต์ที่ทำผิดกฎจราจร

1.2. วัตถุประสงค์ของงานวิจัย

1. เพื่อดำเนินการสร้างระบบในการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์
2. เพื่อนำไปพัฒนาเป็นอุปกรณ์ที่สามารถช่วยงานเจ้าหน้าที่รักษาความปลอดภัยได้จริง
3. เพื่อให้ผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนตระหนักถึงการรักษาความปลอดภัยบนท้องถนนมากยิ่งขึ้น

1.3. ขอบเขตของโครงการ

1. ข้อมูลที่ใช้ให้ระบบตรวจจับผู้ขับขี่รถจักรยานยนต์ที่สวมและไม่สวมหมวกนิรภัยเรียนรู้ นั้นจะมาจากกล้องวงจรปิดของงานสร้างเสริมสุขภาพ คณะแพทยศาสตร์ศิริราชพยาบาล
2. ระบบจะตรวจจับรถจักรยานยนต์ ผู้ขับขี่รถจักรยานยนต์ ผู้ซ้อนรถจักรยานยนต์ ที่สวมหมวกนิรภัยและไม่สวมหมวกนิรภัยเท่านั้น
3. คาดหวังให้ระบบสามารถตรวจจับส่วนของศีรษะของผู้ขับขี่และผู้ซ้อนรถจักรยานยนต์ ว่าสวมหมวกนิรภัยหรือไม่ โดยมีความแม่นยำอยู่ที่ 80%

1.4. ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถตรวจจับได้ว่าผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนสวมหมวกนิรภัยหรือไม่
2. ได้อุปกรณ์ เช่น กล้องเว็บแคมและจอแสดงผลที่มีระบบตรวจจับหมวกนิรภัยที่สามารถช่วยงานเจ้าหน้าที่รักษาความปลอดภัยได้จริง
3. ผู้ขับขี่รถจักรยานยนต์ปฏิบัติตามกฎจราจรมากขึ้น
4. ลดจำนวนผู้บาดเจ็บ หรือผู้เสียชีวิตที่เกิดจากอุบัติเหตุอันเนื่องมาจากการไม่สวมหมวกนิรภัย

บทที่ 2

วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในงานวิจัยนี้ ผู้วิจัยได้เลือกใช้ระบบตรวจจับวัตถุ (Object Detection) คือ YOLOv8 ที่มีความนิยม (GrassrootEngineer, 2563) ในวงการคอมพิวเตอร์วิทัศน์ (Computer Vision) และผู้วิจัยยังได้ศึกษาเอกสารทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการพัฒนากระบวนการในการตรวจจับผู้ขับขี่รถจักรยานยนต์ที่สวมใส่และไม่สวมใส่หมวกนิรภัย โดยได้นำเสนอตามหัวข้อดังต่อไปนี้

2.1 ความรู้เกี่ยวกับหมวกนิรภัยสำหรับผู้ขับขี่รถจักรยานยนต์

หมวกนิรภัยสำหรับผู้ขับขี่รถจักรยานยนต์เป็นอุปกรณ์สำคัญที่มีเป้าหมายในการป้องกันบาดเจ็บหนักหรืออันตรายต่อหัวและสมองของผู้ขับขี่ในกรณีเกิดอุบัติเหตุหรือการชนกับวัตถุหรือบุคคลอื่น ๆ

ประเภทของหมวกนิรภัย มีหลายประเภทสามารถจำแนกเป็นประเภทได้ 3 ประเภท (กุลญาดา เนื่องจํารงค์, 2563) ได้แก่ หมวกนิรภัยชนิดเต็มหน้า (Full Face Helmet), หมวกนิรภัยชนิดเต็มศีรษะ (Jet Helmet) และหมวกนิรภัยชนิดครึ่งศีรษะ (Half Helmet) ผู้ขับขี่ควรเลือกหมวกที่มีมาตรฐานป้องกันอันตรายและสะดวกสบายตามความเหมาะสมของการใช้งาน



ภาพประกอบ 1 หมวกนิรภัยชนิดเต็มหน้า (Full Face Helmet)

ที่มา : <https://thai.webbike.net/sd/23869365>



ภาพประกอบ 2 หมวกนิรภัยชนิดเต็มศีรษะ (Jet Helmet)

ที่มา : <https://www.indianmotorcycle.com/en-us/shop/apparel/motorcycle-helmets/2861396/>



ภาพประกอบ 3 หมวกนิรภัยชนิดครึ่งศีรษะ (Half Helmet)

ที่มา : <https://www.walmart.com/ip/Raider-Motorcycle-Half-Helmet-DOT-Approved-Gloss-Black-XL/973623197>

มาตรฐานคุณภาพของหมวกนิรภัยควรมีการรับรองตามมาตรฐานคุณภาพ เช่น DOT (Department of Transportation), ECE (Economic Commission for Europe), หรือ SNELL (Snell Memorial Foundation) การเลือกหมวกที่มีการรับรองตามมาตรฐานช่วยให้มั่นใจในคุณภาพและประสิทธิภาพของหมวกนิรภัย

การใช้งานที่ถูกต้องของหมวกนิรภัยควรสวมใส่ให้สมบุรณ์และมั่นคงทุกครั้งที่ขับขี่รถจักรยานยนต์ ประสิทธิภาพของหมวกจะลดลงถ้าไม่ถูกสวมใส่ให้สมบุรณ์หรือถูกสวมใส่ไม่เหมาะสม

การตรวจสอบความปลอดภัยของหมวกนิรภัยควรตรวจสอบเพื่อความปลอดภัยอย่างสม่ำเสมอ ควรตรวจสอบว่าไม่มีขอบหรือส่วนขาดหาย และวัสดุของหมวกยังคงมีความแข็งแรง

การเปลี่ยนหมวกนิรภัยควรถูกเปลี่ยนหากมีอุบัติเหตุถูกชนหรือมีการบุบสลายที่อาจทำให้มีความเสียหาย หมวกนิรภัยที่มีความเสียหายอาจไม่ป้องกันได้ตามมาตรฐานคุณภาพ

2.2 คอมพิวเตอร์วิทัศน์

คอมพิวเตอร์วิทัศน์ เป็นสาขาหนึ่งของวิทยาการคอมพิวเตอร์ ว่าด้วยเรื่องเกี่ยวกับการดึงสารสนเทศจากรูปภาพหรือวิดีโอ เครื่องมือที่ใช้ในคอมพิวเตอร์วิทัศน์ได้แก่ คณิตศาสตร์ โดยเฉพาะ เรขาคณิต พีชคณิตเชิงเส้น สถิติ และการวิจัยดำเนินงาน (การหาค่าเหมาะที่สุด) และการวิเคราะห์เชิงฟังก์ชัน โดยเครื่องมือเหล่านี้ใช้สร้างขั้นตอนวิธีในการแยกส่วนภาพ และการจัดกลุ่มภาพเพื่อให้คอมพิวเตอร์สามารถ "เข้าใจ" ทัศนียภาพหรือคุณลักษณะต่าง ๆ ในภาพ ("คอมพิวเตอร์วิทัศน์," 2564)

เป้าหมายโดยทั่วไปของคอมพิวเตอร์วิทัศน์ได้แก่

1. การตรวจจับ ตัดแบ่งขอบเขต ระบุตำแหน่ง และ รู้จำ วัตถุที่ต้องการในภาพ เช่น หน้าคน
 2. การประเมินผล สำหรับ การตัดแบ่งขอบเขตวัตถุในภาพ หรือ การวางทาบเทียบ เป็นต้น
 3. การวางทาบเทียบของ มุมมองต่าง ๆ ของทัศนียภาพ หรือ วัตถุหนึ่ง ๆ
 4. การติดตาม วัตถุหนึ่ง ๆ ในภาพต่อเนื่อง
 5. การเชื่อมโยงมุมมองต่าง ๆ ของทัศนียภาพหนึ่ง ๆ เพื่อสร้างแบบจำลองสามมิติของทัศนียภาพนั้น แบบจำลองดังกล่าวอาจนำมาใช้เพื่อนำทางหุ่นยนต์ ในทัศนียภาพจริง
 6. การกะประมาณ ท่าทางต่าง ๆ ของมนุษย์ และ ส่วนต่าง ๆ ของร่างกาย เช่น แขน ขา นิ้วมือ ฯลฯ ในสามมิติ
 7. การค้นหา รูปภาพด้วยเนื้อหาของภาพ ในฐานข้อมูลภาพขนาดใหญ่
- เพื่อที่จะบรรลุซึ่งเป้าหมายเหล่านี้ ระบบคอมพิวเตอร์วิทัศน์ จะต้องใช้กระบวนการต่าง ๆ เช่น การรู้จำแบบ การเรียนรู้เชิงสถิติ เรขาคณิตเชิงภาพฉาย การประมวลผลภาพ ทฤษฎีกราฟ และอื่น ๆ

คอมพิวเตอร์วิทัศน์การรับรู้ นั้น เกี่ยวข้องอย่างใกล้ชิดกับ จิตวิทยาการรับรู้ และ การคำนวณทางชีวภาพ


การประยุกต์ใช้คอมพิวเตอร์วิทัศน์อันหนึ่งที่น่าสนใจ ได้แก่ การสร้างปรากฏการลวงตาต่าง ๆ ในภาพยนตร์ ปัจจุบัน เราจะพบการประยุกต์ใช้ คอมพิวเตอร์วิทัศน์ในสาขาต่าง ๆ เช่น การแพทย์ การทหาร ระบบตรวจตราและรักษาความปลอดภัย การตรวจสอบและควบคุมคุณภาพ ระบบหุ่นยนต์ รถยนต์ และอื่น ๆ

ในปัจจุบัน เครื่องจักรวิทัศน์ และการจัดการรูปภาพทางการแพทย์ ที่ใช้วิธีการต่าง ๆ ทางคอมพิวเตอร์วิทัศน์ ได้รับการพัฒนา และ จัดจำหน่าย ในตลาดโลก คิดรวมเป็นมูลค่า หลายหมื่นล้านบาทต่อปี

2.3 การประมวลผลภาพแบบดิจิทัล (Digital Image Processing)

การประมวลผลภาพ (Digital image processing) คือ กระบวนการที่ใช้คอมพิวเตอร์หรือระบบคอมพิวเตอร์ในการแก้ไขหรือปรับปรุงภาพดิจิทัล ("การประมวลผลภาพดิจิทัล," 2561) โดยใช้วิธีการและอัลกอริทึมต่าง ๆ เพื่อแก้ไขหรือปรับปรุงคุณภาพของภาพดิจิทัลหรือดึงข้อมูลที่มีประโยชน์ออกมาจากภาพนั้น

ภาพดิจิทัล คือ ภาพที่ถูกแทนด้วยตัวเลขหรือพิกเซล (Pixels) บนหน้าจอคอมพิวเตอร์หรือในไฟล์ภาพดิจิทัลรวมความหมายถึงสัญญาณดิจิทัลใน 2 มิติอื่น ๆ ครอบคลุมถึงสัญญาณวิดีโอ (Video) หรือภาพเคลื่อนไหว ซึ่งเป็นชุดของภาพนิ่ง เรียกว่า เฟรม (Frame) หลาย ๆ ภาพต่อกันไปตามเวลา ภาพประกอบที่ 4



ภาพประกอบ 4 การประมวลผลภาพดิจิทัล


ที่มา : <https://th.wikipedia.org/wiki/การประมวลผลภาพดิจิทัล>

การประมวลผลภาพดิจิทัลใช้เทคนิคการคำนวณเพื่อทำการปรับแต่งคุณสมบัติและลักษณะของภาพ เช่น การปรับความสว่าง ความคมชัด หรือสีของภาพ การตรวจจับวัตถุ การตัดเส้นขอบ (Edge Detection) การฟิลเตอร์รูปภาพ การประมวลผลทางการแพทย์ การวิเคราะห์ภาพดาวเทียม และอื่น ๆ อีกมากมายในหลายสาขาวิชาและการประยุกต์ทางเทคโนโลยีต่างๆ การประมวลผลภาพดิจิทัลช่วยให้เราสามารถปรับแต่งหรือแปลงภาพดิจิทัลให้เหมาะสมกับวัตถุประสงค์ที่ต่างกัน เช่น การแก้ไขรูปถ่าย, การวิเคราะห์ข้อมูลในภาพและการสกัดข้อมูลที่น่าสนใจในภาพ เพื่อให้ได้ข้อมูลที่มีประโยชน์

2.4 บริเวณที่สนใจ (Region-of-interest หรือ ROI)

บริเวณที่สนใจหรือ Region-of-Interest (ROI) คือ คือบริเวณที่เราสนใจ อาจจะเป็นบริเวณใดภายในภาพก็ได้ โดยการตีกรอบล้อมรอบบริเวณที่สนใจ ด้วยวงกลม กรอบสี่เหลี่ยม หรือกรอบรูปเหลี่ยมใดๆ เพื่อนำภาพเฉพาะส่วนดังกล่าวมาประมวลผล หรือเปลี่ยนแปลงภาพตามต้องการ โดยไม่มีผลกระทบต่อส่วนอื่นๆ (NEXTSOFTWAREHOUSE, 2557) เนื่องจากบางครั้งผู้ประมวลผลภาพอาจไม่ต้องการประมวลผลทั้งภาพเพื่อปรับปรุงหรือดึงข้อมูล ผู้ประมวลผลภาพสามารถเลือกเฉพาะบริเวณที่สนใจเท่านั้น (ROI) เพื่อประหยัดทรัพยากรที่ใช้คำนวณและเวลาในการประมวลผล โดยภายในหนึ่งภาพสามารถกำหนดได้หลายๆบริเวณที่สนใจได้

ROI สามารถกำหนดให้เป็นส่วนหนึ่งของภาพในรูปแบบของสี่เหลี่ยม, วงรี, หรือรูปร่างอื่นๆ โดยการระบุตำแหน่ง (Coordinates) หรือการกำหนดขนาดของ ROI นั้น ผู้ประมวลผลภาพสามารถทำการปรับปรุงคุณสมบัติของ ROI นี้หรือดำเนินการการประมวลผลเฉพาะบริเวณนี้เพื่อเพิ่มความชัดเจนของข้อมูลหรือดึงข้อมูลที่เป็นประโยชน์ และหลังจากนั้นนำข้อมูลนี้ไปใช้หรือส่วนอื่นๆ ของกระบวนการประมวลผลภาพ บริเวณที่สนใจ (Region-of-interest หรือ ROI) มีประโยชน์ในการลดความซับซ้อนของการประมวลผลและเพิ่มประสิทธิภาพในกระบวนการประมวลผลภาพ



ภาพประกอบ 5 ตัวอย่างการกำหนดบริเวณที่สนใจ
ที่มา : <https://gearpatrol.com/cars/motorcycles/>

2.5 ปัญญาประดิษฐ์ (Artificial Intelligence หรือ AI)

ปัญญาประดิษฐ์หรือ "Artificial Intelligence" (AI) คือ ระบบคอมพิวเตอร์หรือโครงข่ายคอมพิวเตอร์ที่ถูกออกแบบและโปรแกรมให้สามารถทำงานแบบคิดหรือประมวลผลข้อมูลที่คล้ายกับการคิดของมนุษย์ได้ ("ปัญญาประดิษฐ์," 2566) ระบบปัญญาประดิษฐ์นี้ใช้การเรียนรู้จากข้อมูล

และปรับปรุงประสิทธิภาพของการทำงานของมันตามเวลา โดยอาจใช้งานกับข้อมูลทั้งข้อมูลตั้งต้น และข้อมูลที่ได้รับมาในระหว่างการทำงาน เพื่อให้สามารถเรียนรู้และปรับตัวเองเพื่อให้ทำงานได้ดียิ่งขึ้น

ระบบ AI สามารถทำหลายงานและภารกิจต่าง ๆ ได้ เช่น การประมวลผลข้อมูล, การวิเคราะห์ข้อมูล, การสร้างความเข้าใจภาษามนุษย์, การคิดเลข, การจำและอ่านภาพ, การควบคุมอุปกรณ์และโครงสร้างต่าง ๆ และการทำงานในสาขาอาชีพและอุตสาหกรรมต่าง ๆ อีกมากมาย การพัฒนาและใช้งาน AI มีศักยภาพในการเพิ่มประสิทธิภาพและลดทรัพยากรในการทำงานในหลายด้าน

ปัจจุบันงานวิจัยหลักๆ ของ AI มีแนวคิดในรูปที่เน้นเหตุผลเป็นหลัก เนื่องจากการนำ AI ไปประยุกต์ใช้แก้ปัญหา ไม่จำเป็นต้องอาศัยอารมณ์หรือความรู้สึกของมนุษย์ อย่างไรก็ตามนิยามทั้ง 4 ไม่ได้ต่างกันโดยสมบูรณ์ นิยามทั้ง 4 ต่างก็มีส่วนร่วมที่คาบเกี่ยวกันอยู่ นิยามดังกล่าวคือ

1. ระบบที่คิดเหมือนมนุษย์ (Systems that think like humans)

ระบบหรือโครงข่ายคอมพิวเตอร์ที่มีความสามารถในการคิดและประมวลผลข้อมูลอย่างคล้ายกับมนุษย์ในมุมมองทางปัญญาและการจัดการข้อมูล ระบบนี้อาจมีความสามารถในการเรียนรู้จากข้อมูล, การวิเคราะห์ข้อมูล, การแก้ปัญหา, การเข้าใจและใช้ภาษามนุษย์, การเรียนรู้จากประสบการณ์ และการคิดคำนวณคล้ายมนุษย์

ระบบที่คิดเหมือนมนุษย์ใช้หลายเทคนิคและเทคโนโลยี AI เช่น การใช้โครงข่ายประสาทเทียม (Neural Networks), การประมวลผลข้อมูลโดยใช้วิธี Machine Learning, การจำและสร้างความเข้าใจของข้อมูล, การควบคุมอุปกรณ์และการทำงานในงานที่ต้องการความสามารถในการคิดและตัดสินใจ

ระบบที่คิดเหมือนมนุษย์เป็นเป้าหมายหลักในการพัฒนาปัญญาประดิษฐ์ (AI) เนื่องจากมันมีศักยภาพในการทำงานที่ต้องการความสามารถในการคิดและประมวลผลข้อมูลแบบมนุษย์ทั่วไปในหลายสาขาและอุตสาหกรรม อาจเปลี่ยนแปลงวิธีการทำงานและชีวิตประจำวันของมนุษย์ให้มีประสิทธิภาพมากขึ้นในหลากหลายด้าน

2. ระบบที่กระทำเหมือนมนุษย์ (Systems that act like humans)

ระบบหรือโครงข่ายคอมพิวเตอร์ที่มีความสามารถในการทำงานหรือกระทำอย่างคล้ายกับมนุษย์ในมุมมองของพฤติกรรมและการปฏิบัติ ระบบนี้อาจทำงานที่คล้ายกับมนุษย์ในหลายสถานการณ์ และมีความสามารถในการทำงานที่มนุษย์มักกระทำได้ ระบบนี้อาจใช้สื่อสารได้ด้วยภาษาที่มนุษย์ใช้ เช่น ภาษาไทย ภาษาอังกฤษ ตัวอย่างคือ การแปลงข้อความเป็นคำพูดและการแปลงคำพูดเป็นข้อความ มีการรับสัมผัสคล้ายมนุษย์ เช่น คอมพิวเตอร์รับภาพได้โดยอุปกรณ์

รับสัมผัส แล้วนำภาพไปประมวลผล การเคลื่อนไหวได้คล้ายมนุษย์ เช่น หุ่นยนต์ช่วยงานต่าง ๆ อย่างการ ดูดฝุ่น เคลื่อนย้ายสิ่งของ เรียนรู้ได้โดยสามารถตรวจจับรูปแบบการเกิดของเหตุการณ์ใด ๆ แล้วปรับตัวสู่สิ่งแวดล้อมที่เปลี่ยนไปได้

3. ระบบที่คิดอย่างมีเหตุผล (Systems that think rationally)

ระบบหรือโครงข่ายคอมพิวเตอร์ที่มีความสามารถในการคิดและประมวลผลข้อมูลตามตรรกะและกฎเหตุผลอย่างมีหลักการ ระบบนี้ใช้การวิเคราะห์ข้อมูล, การประมวลผลข้อมูลตามกฎเหตุผล, การสร้างองค์ความรู้ที่ชัดเจน, และการตัดสินใจโดยใช้ข้อมูลและหลักการตรรกะที่ถูกต้อง

ระบบที่คิดอย่างมีเหตุผลใช้ความรู้และข้อมูลเป็นฐานในการตรวจสอบสาระสำคัญ, ตรวจสอบความถูกต้องของข้อมูล, และวิเคราะห์ข้อมูลเพื่อทำให้การตัดสินใจมีความเหตุผล ระบบนี้มักใช้วิธีการสร้างความรู้จากตรรกะและหลักการ, การทำนายตามข้อมูลที่มีอยู่ และการตรวจสอบความถูกต้องของข้อมูล ระบบที่คิดอย่างมีเหตุผลมักถูกใช้ในการแก้ปัญหาทางวิทยาการคอมพิวเตอร์, การวิเคราะห์ข้อมูลทางธุรกิจ, การควบคุมอุปกรณ์ที่ใช้งาน และการสร้างระบบอัตโนมัติที่ปฏิบัติตามกฎหรือหลักการเหตุผลที่ถูกต้อง

4. ระบบที่กระทำอย่างมีเหตุผล (Systems that act rationally)

ระบบหรือโครงข่ายคอมพิวเตอร์ที่กระทำหรือทำงานตามการเลือกที่มีเหตุผลและความเป็นระบบ โดยใช้ความรู้และการวิเคราะห์เพื่อเป็นระบบที่สามารถตัดสินใจและกระทำในลักษณะที่ถูกต้องและมีเหตุผลเพื่อบรรลุเป้าหมายที่ได้ตั้งไว้ ระบบนี้มีการใช้ความรู้, ข้อมูล, การเรียนรู้ และการทำนายเพื่อแสดงพฤติกรรมที่เป็นระบบและมีความเหตุผล เช่น Chatbots และผู้ช่วยเสมือน (Virtual Assistants) ใช้การประมวลผลภาษาธรรมชาติ (NLP) เพื่อตอบคำถามและให้ข้อมูลในลักษณะที่มีเหตุผลในการสื่อสารกับมนุษย์ ระบบนี้สามารถเชื่อมโยงความรู้จากฐานข้อมูลและความเข้าใจภาษาธรรมชาติเพื่อให้คำตอบที่ถูกต้องและมีเหตุผลตามความคิดของผู้สอบถาม เป็นต้น

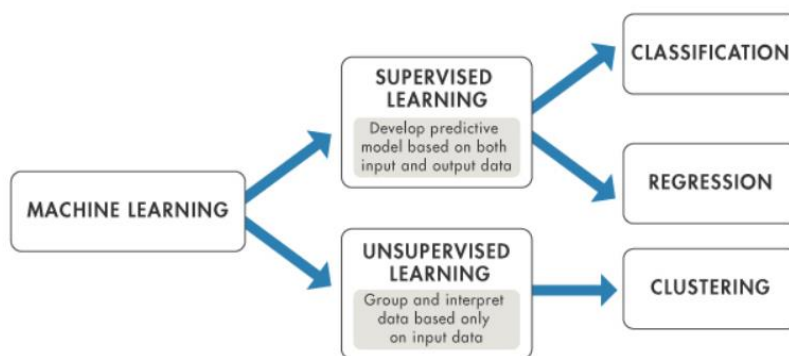
เป้าหมายงานวิจัยเกี่ยวกับปัญญาประดิษฐ์

ปัญหาโดยทั่วไปของการจำลอง (หรือสร้าง) ปัญญาถูกแบ่งออกเป็นปัญหาย่อย ๆ จำนวนมาก ในงานวิจัยนี้สนใจมากเป็นพิเศษในเรื่องดังต่อไปนี้

2.5.1 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นการศึกษาอัลกอริทึมของคอมพิวเตอร์ที่มีการพัฒนา การเรียนรู้ของเครื่องถูกมองว่าเป็นส่วนหนึ่งของปัญญาประดิษฐ์ ("การเรียนรู้ของเครื่อง," 2566) มีวัตถุประสงค์ในการทำความเข้าใจและสร้างโมเดลคอมพิวเตอร์ที่สามารถทำนาย,

จำแนกประเภท,แบ่งกลุ่ม หรือกระทำตามข้อมูลได้อย่างมีประสิทธิภาพ ซึ่งการเรียนรู้ของเครื่องมี 2 ประเภท ภาพประกอบที่ 6



ภาพประกอบ 6 ประเภทของ Machine Learning

ที่มา : <https://www.mathworks.com/help/stats/machine-learning-in-matlab.html>

การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นกระบวนการการเรียนรู้ที่ใช้ข้อมูลโดยไม่ต้องมีผู้สอนเสมอ มีหน้าที่หาแบบแผนหรือโครงสร้างจากข้อมูล โดยไม่มีข้อมูลตัวอย่างที่ระบุว่าข้อมูลแต่ละอย่างควรอยู่ในประเภทใด ซึ่งเป็นวิธีการในการค้นพบความสัมพันธ์และโครงสร้างของข้อมูลโดยอัตโนมัติ การตัดสินใจในการเรียนรู้แบบไม่มีผู้สอนอาจใช้ทฤษฎีการตัดสินใจ ส่วนการเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นกระบวนการการเรียนรู้ที่ใช้ข้อมูลที่มีการสอน เพื่อทำการแบ่งประเภทข้อมูล (Classification) หรือการวิเคราะห์การถดถอยเชิงตัวเลข (Regression) โดยการแบ่งประเภทข้อมูล (Classification) นั้นใช้เพื่อกำหนดว่าข้อมูลที่เข้ามาใหม่นั้นจัดอยู่ในกลุ่มประเภทใดหลังจากที่ได้เรียนรู้ตัวอย่างสอนที่ระบุว่าข้อมูลแต่ละข้อมูลควรอยู่ในประเภทใดมาแล้ว ส่วนการวิเคราะห์การถดถอยเชิงตัวเลขเป็นกระบวนการทางสถิติและการเรียนรู้ของเครื่องที่มุ่งหวังในการสร้างโมเดลทางคณิตศาสตร์เพื่ออธิบายความสัมพันธ์ระหว่างตัวแปรอิสระ (independent variables) และตัวแปรตาม (dependent variable) โดยการนำข้อมูลเชิงตัวเลข โดยทั่วไปมักนำมาใช้ในการทำนายค่าของตัวแปรตามเมื่อทราบค่าของตัวแปรอิสระ เพื่อวิเคราะห์และทำนายค่าของตัวแปรตามโดยอ้างอิงถึงค่าของตัวแปรอิสระ การเรียนรู้ทั้งสองแบบนี้สามารถวิเคราะห์ได้ด้วยทฤษฎีการตัดสินใจ (Decision theory) โดยใช้แนวคิดของประโยชน์ การวิเคราะห์ทางคณิตศาสตร์ของอัลกอริทึมทางการเรียนรู้ของเครื่องจักรและการวิเคราะห์ประสิทธิภาพของอัลกอริทึมนั้นเป็นอีกหนึ่งสาขาทางด้านวิทยาการคอมพิวเตอร์สายทฤษฎี

2.5.2 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอน เป็นรูปแบบการเรียนรู้รูปแบบหนึ่งของการเรียนรู้ของเครื่องที่จับคู่ระหว่างข้อมูลนำเข้าและข้อมูลส่งออกตามพื้นฐานตัวอย่าง การทำงานอ้างอิงจากข้อมูลสอนซึ่งประกอบด้วยชุดข้อมูลตัวอย่าง ("การเรียนรู้แบบมีผู้สอน," 2564)

ขั้นตอนหลักในการทำ Supervised Learning ประกอบด้วย

การเตรียมข้อมูล (Data Preparation) ขั้นตอนนี้เริ่มต้นด้วยการรวบรวมข้อมูลขาเข้าที่มีคำตอบ (labeled data) และทำการเตรียมข้อมูลให้พร้อมใช้งาน เช่น การทำการตรวจสอบและจัดการข้อมูลที่ขาดหายหรือไม่สมบูรณ์, การเลือกคุณลักษณะ (features) ที่จะใช้ในการสร้างโมเดล, และการแบ่งข้อมูลเป็นชุดฝึก (training set) และชุดทดสอบ (test set)

การสร้างโมเดล (Model Building) ขั้นตอนนี้ผู้ใช้งานเลือกและกำหนดโมเดลที่เหมาะสมในการทำนายผลลัพธ์ โดยใช้ข้อมูลในชุดฝึก โมเดลจะปรับค่าพารามิเตอร์ (parameters) ต่าง ๆ เพื่อให้สามารถทำนายผลลัพธ์ที่ถูกต้องมากที่สุด

การฝึกโมเดล (Model Training) ในขั้นตอนนี้ผู้ใช้งานใช้ข้อมูลชุดฝึกเพื่อฝึกโมเดล โมเดลจะปรับค่าพารามิเตอร์เพื่อลดความคลาดเคลื่อนในการทำนายผลลัพธ์

การทดสอบและประเมิน (Model Evaluation) เมื่อโมเดลถูกฝึกเสร็จสิ้น หลังจากนั้นจะมีการทดสอบด้วยชุดทดสอบ ในขั้นตอนนี้เราประเมินประสิทธิภาพของโมเดลโดยเปรียบเทียบผลลัพธ์ที่โมเดลทำนายกับคำตอบที่ได้จากชุดทดสอบ

การใช้งานและเปรียบเทียบ (Model Deployment and Comparison) หากโมเดลทำนายผลลัพธ์ได้ดีและถูกต้องตามความต้องการของผู้ใช้งาน ผู้ใช้งานสามารถนำโมเดลไปใช้ในการทำนายผลลัพธ์จริง หรือในการปฏิบัติงานจริง และใช้เปรียบเทียบกับประสิทธิภาพของโมเดลอื่น ๆ หรือวิธีการอื่น ๆ ที่มีอยู่

Supervised Learning มีการใช้ในหลากหลายงาน เช่น การทำนายราคาหุ้น, การจำแนกภาพถ่าย, การแปลภาษา, การตรวจจับการฉ้อโกงทางการเงิน, การจำแนกอีเมลขยะ (spam email), และงานอื่น ๆ ที่เกี่ยวข้องกับการทำนายหรือจำแนกข้อมูล

2.5.3 การแบ่งประเภทข้อมูล (Classification)

การแบ่งประเภทข้อมูล เป็นปัญหาพื้นฐานของการเรียนรู้แบบมีผู้สอน โดยปัญหาคือการทำนายประเภทของวัตถุจากคุณสมบัติต่าง ๆ ของวัตถุ ซึ่งการเรียนรู้แบบมีผู้สอนจะสร้างฟังก์ชันเชื่อมโยง ระหว่างคุณสมบัติของวัตถุ กับประเภทของวัตถุจากตัวอย่างสอน แล้วจึงใช้ฟังก์ชันนี้ทำนายประเภทของวัตถุที่ไม่เคยพบ เครื่องมือหรือขั้นตอนวิธีที่ใช้สำหรับการแบ่งประเภทข้อมูลเช่น โคจรข่ายประสาทเทียม ต้นไม้ตัดสินใจ ("การแบ่งประเภทข้อมูล," 2563)

2.5.4 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก เป็นส่วนหนึ่งของวิธีการการเรียนรู้ของเครื่องบนพื้นฐานของโครงข่ายประสาทเทียมและการเรียนเชิงคุณลักษณะ การเรียนรู้สามารถเป็นได้ทั้งแบบการเรียนรู้แบบมีผู้สอน การเรียนรู้แบบกึ่งมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน คำว่า "ลึก" ในความหมายมาจากการที่มีชั้นของโครงข่ายหลายชั้น ที่มีประสิทธิภาพมากขึ้น การเรียนที่สะดวกขึ้น และการเข้าใจในโครงสร้างที่ชัดเจนขึ้น ("การเรียนรู้เชิงลึก," 2565)

Deep Learning ได้รับแรงบันดาลใจมาจากสาขาประสาทวิทยา (Neuroscience) โดยเฉพาะการศึกษาโครงสร้างและการทำงานของระบบประสาทในสัตว์และมนุษย์ โครงสร้างของโครงข่ายประสาทในสมองได้ให้ความรู้แนวแบบในการสร้างโครงข่ายประสาทเทียมที่มีหลายชั้น (Deep Neural Networks) โดยจำลองการทำงานของเซลล์ประสาทในการประมวลผลข้อมูล

Deep Learning ถูกนำมาประยุกต์ใช้ในงานต่างๆ เช่น การระบุใบหน้า (Face Detection) สามารถใช้ในระบบการจดจำใบหน้าเพื่อระบุและตรวจจับใบหน้าบุคคลในภาพหรือวิดีโอ โดยมีความแม่นยำสูง ตัวอย่างแอปพลิเคชันที่ใช้งานนี้ เช่น ระบบปลดล็อกโทรศัพท์มือถือด้วยใบหน้า รวมไปถึงวงการแพทย์ได้นำ Deep Learning ไปใช้ในการวิเคราะห์ภาพ เช่น ภาพรังสีเอ็กซเรย์, CT, MRI ในการวินิจฉัยทางการแพทย์

2.5.5 Convolution Neural Network (CNN)

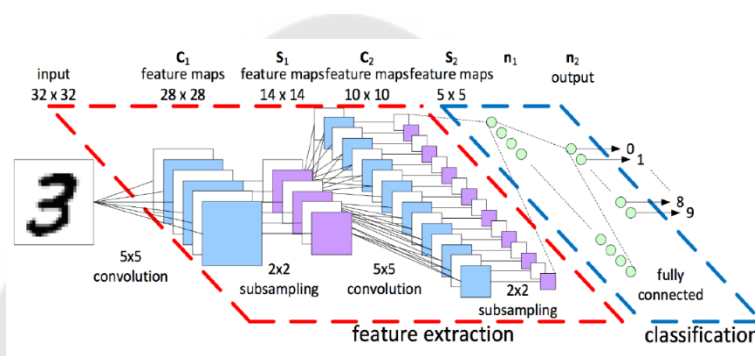
CNN เป็นโครงข่ายประสาทเทียมที่ออกแบบมาเพื่อการประมวลผลข้อมูลที่มีโครงสร้างแบบกริดอย่างภาพและวิดีโอ โครงข่าย CNN ถูกใช้กว้างขวางในการจดจำรูปภาพ, การตรวจจับวัตถุ, การจำจัดหมวดหมู่ข้อมูล เป็นต้น โดย CNN มีความสามารถในการคัดเลือกคุณสมบัติ (Feature Selection) ในแต่ละชั้นของโครงข่ายเพื่อใช้ในการจดจำและจำแนกหมวดหมู่ข้อมูล หลังจากนั้นจึงนำคุณลักษณะที่ได้จากการเรียนรู้แล้วไปเทรนระบบรู้จำซึ่งทำให้ผลลัพธ์ที่ออกมามีความถูกต้องสูง (Simard, Steinkraus, & Platt, 2003)

CNN มีชั้น Convolutional Layer ที่ใช้สกัดลักษณะสำคัญต่าง ๆ จากภาพออกมาได้ และเชื่อมกับชั้นที่เป็น Fully Connected Neural Network เพื่อสร้าง Neural Network สำหรับการทำนายประเภทของรูปภาพ

จากภาพประกอบที่ 7 ข้อมูลนำเข้าเป็นเมทริกซ์ขนาด 32×32 และ kernel เป็นเมทริกซ์ขนาด 5×5 โดยเมทริกซ์เกิดขึ้นจากการสไลด์ไปทั่วทั้งภาพของ kernel เพื่อคำนวณ dot product เรียกว่า Feature Map โดย kernel ทำหน้าที่ตรวจจับคุณสมบัติจากภาพ input ลดขนาดข้อมูลที่ต้องประมวลผลอีกด้วย ซึ่งก็คือ การลด resource ที่ต้องใช้ในการประมวลผล

Subsampling คือ การเก็บข้อมูลค่าพิกเซลของ local feature จากชั้น convolution โดยจะลด dimensionality ของแต่ละ feature map แต่เก็บข้อมูลสำคัญไว้ การทำ subsampling มีหลายวิธี ได้แก่ Max (หาค่าสูงสุด), Average (หาค่าเฉลี่ย), Sum (หาผลรวม)

Fully Connected คือ การเชื่อมต่อทุกตัวที่ได้จากเลเยอร์ก่อนหน้า output จากชั้น convolution แสดงถึง feature ของภาพ input จุดประสงค์ของชั้น Fully Connected คือ การใช้คุณสมบัติจากเลเยอร์ก่อนหน้าสำหรับการจัดรูปแบบลงในคลาสต่างๆ และส่วนสุดท้ายคือ output เป็นส่วนที่ได้จากการทำนาย



ภาพประกอบ 7 Convolutional Neural Network รวมกับ Fully-Connected Neural Network
ที่มา : <https://www.kernix.com/article/a-toy-convolutional-neural-network-for-image-classification-with-keras/>

2.5.6 Object Detection

การตรวจจับวัตถุ (Object Detection) คือ เทคโนโลยีในทางคอมพิวเตอร์ โดยใช้หลักการที่เกี่ยวกับคอมพิวเตอร์วิทัศน์ (Computer Vision) และการประมวลผลภาพที่ใช้ในงานปัญญาประดิษฐ์ตรวจจับวัตถุตามที่กำหนด เช่น มนุษย์ รถยนต์ อาคาร ที่อยู่ในรูปภาพ หรือวิดีโอ งานตรวจจับวัตถุในรูปภาพสามารถเจาะลึกลงไปได้อีกหลายแขนง เช่น การทำตรวจจับหน้าคน (Face Detection) ตรวจจับคนเดินถนน (Pedestrian Detection) สามารถประยุกต์ใช้ได้หลากหลาย เช่น ใช้ในงานรักษาความปลอดภัย และรถยนต์ไร้คนขับ เป็นต้น ("Object detection," 2023) ดังแสดงตัวอย่างในภาพประกอบที่ 8 ซึ่งเป็นผลจากการใช้อัลกอริทึม YOLO ตรวจจับวัตถุภายในรูปภาพ อาทิเช่น Person และ Bus



ภาพประกอบ 8 ตัวอย่างงานตรวจจับวัตถุ
(ที่มา : <https://github.com/ultralytics/ultralytics/issues/1656>)

2.5.7 YOLO


YOLO (You Only Look Once) เป็นหลักการของการ เรียนรู้เชิงลึกที่ถูกลำเอามาช่วยในงานปัญญาประดิษฐ์ (Artificial Intelligence) สามารถนำมาเป็นเครื่องมือในการตรวจจับวัตถุที่มีการทำงานด้วยความเร็วสูง โดยมีแนวคิดหลักที่ทำให้การตรวจหาวัตถุทำได้รวดเร็วคือ อย่างแรก ทำนายกรอบวัตถุ (Box) และจำแนกประเภท (Classify) วัตถุพร้อมกันทีเดียว อย่างที่สองแบ่งทั้งภาพออกเป็น ส่วน ๆ สำหรับแต่ละส่วนจะต้องมีการทำนายกรอบของวัตถุและคลาส (Class) ซึ่งสามารถนำมารวมกันเพื่อเลือกคู่กรอบวัตถุและคลาสที่มีความแม่นยำได้ (Kharchenko & Chyrka, 2018)

YOLOv8 เป็นโมเดลล่าสุดในตระกูล YOLO และถูกนำเสนอในปี 2022 โดย Ultralytics YOLOv8 ถูกสร้างบนพื้นฐานของ YOLOv5 และมีการปรับปรุงในเรื่องสถาปัตยกรรมและประสิทธิภาพจากนักพัฒนา YOLOv8 มีความเร็วและความแม่นยำมากกว่า YOLOv5 โดย YOLOv8 สามารถทำการตรวจจับวัตถุ การจำแนกหมวดหมู่ข้อมูลในรูปภาพ การแบ่งส่วนข้อมูลในรูปภาพ เป็นต้น (Roboflow, 2020)

YOLO จัดเป็นอัลกอริทึมที่อยู่ในกลุ่ม One-stage Object Detection ที่มีสถาปัตยกรรมทั้ง 4 ส่วน (Imane, 2564)

1. Input ข้อมูลนำเข้าสู่อัลกอริทึม YOLO ซึ่งก็คือข้อมูลรูปภาพหรือเฟรมจากวิดีโอ ข้อมูลนี้จะถูกประมวลผ่านเครือข่ายประสาทเทียม (Neural network)

2. Backbone เป็นส่วนที่สกัดคุณลักษณะของภาพ (Extract Feature) ออกจากรูปภาพที่เป็น Input
3. Neck เป็นส่วนที่ปรับอัลกอริทึมให้รองรับคุณลักษณะ (Feature) ของวัตถุที่มีหลายขนาด
4. Dense Prediction เป็นส่วนการทำนายผลลัพธ์ โดยจะทำนายในรูปแบบ Classes, Bounding box, Confident หรือผลลัพธ์อื่นๆ



ภาพประกอบ 9 สถาปัตยกรรมอัลกอริทึม YOLO

ที่มา : <https://stackoverflow.com/questions/63244184/how-yolo-3-is-implemented-in-yolo-4>

จากภาพประกอบที่ 9 สถาปัตยกรรมอัลกอริทึม YOLO ในส่วนของ Backbone จะใช้ Darknet53 ซึ่งเป็นการสกัดคุณลักษณะของภาพแบบ Convolutional Neural Network (CNN) ส่วน Neck จะใช้ SSP (Spatial Pyramid Pooling) และ PANet (Path Aggregation Network) และส่วน Dense Prediction จะเป็นการทำนายผลลัพธ์ด้วยอัลกอริทึม YOLO

2.6 การประเมินประสิทธิภาพ

ในการประเมินประสิทธิภาพของระบบตรวจจับห้วงผู้ขับที่รถจักรยานยนต์ ตัวชี้วัดที่แสดงประสิทธิภาพของระบบได้อย่างชัดเจนและนิยมใช้กัน คือ Confusion Matrix, Recall, Precision, F1-Score และ mAP

Confusion Matrix คือ ตารางในการวัดความสามารถของโมเดลในการตรวจจับวัตถุและการแก้ปัญหา Classification จากภาพประกอบที่ 10 ประกอบด้วย

True Positive (TP) คือภาพที่ทำนาย (Prediction) ตรงกับสิ่งที่เกิดขึ้นจริง (Actual) ก็คือทำนายว่าจริงและสิ่งที่เกิดขึ้นก็คือจริง เช่น เป็นภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัยจริง และโมเดลทำนายว่าเป็นผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัยจริง

True Negative (TN) คือภาพที่ทำนาย (Prediction) ตรงกับสิ่งที่เกิดขึ้นจริง (Actual) ก็คือทำนายว่าไม่จริงและสิ่งที่เกิดขึ้นก็คือไม่จริง เช่น ไม่ใช่ภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย และโมเดลทำนายว่าไม่เป็นภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย

False Positive (FP) คือการทำนาย (Prediction) ไม่ตรงกับสิ่งที่เกิดขึ้นจริง (Actual) ก็คือทำนายว่าจริง แต่สิ่งที่เกิดขึ้นก็คือไม่จริง เช่น ไม่ใช่ภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย แต่โมเดลทำนายว่าเป็นภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย จัดอยู่ในกลุ่มของ True Negative

False Negative (FN) คือการทำนาย (Prediction) แล้วไม่ตรงกับสิ่งที่เกิดขึ้นจริง (Actual) ก็คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้นก็คือจริง เช่น เป็นภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัยจริง แต่แบบจำลองทำนายว่าไม่เป็นภาพผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย จัดอยู่ในกลุ่ม True Positive

		Actual	
		Positive	Negative
Predicted	Positive	True Positive	False Positive
	Negative	False Negative	True Negative

ภาพประกอบ 10 ตาราง Confusion Matrix (Kevin Markham, 2014)

ที่มา : <https://www.v7labs.com/blog/mean-average-precision>

Recall หรือ True Positive Rate (TPR) หรือ Sensitivity คือ การเทียบอัตราส่วนการทำนายที่ถูกต้องต่อจำนวนของที่เป็นจริงทั้งหมด หรือ อัตราการหา True Positive เทียบกับ True Positive ทั้งหมด ตัวอย่างเช่น ค่าความถูกต้องของการตรวจจับผู้ขับขี่รถจักรยานยนต์สวมหมวก

นิรภัย, ค่าความถูกต้องของการตรวจจับผู้ขับขี่รถจักรยานยนต์ไม่สวมหมวกนิรภัย หาได้จากสูตร (1)

$$Recall = \frac{TP}{TP+FN} \quad (1)$$

Precision คือ ค่าที่สนใจผลการทำนาย (Prediction) ว่าเป็นกลุ่มที่สนใจเท่าไร ก็คือกลุ่มของ Positive ผลที่ทำนายถูกเท่าไร ตัวอย่างเช่น ค่าความแม่นยำของการตรวจจับผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย, ค่าความแม่นยำของการตรวจจับผู้ขับขี่รถจักรยานยนต์ไม่สวมหมวกนิรภัย หาได้จากสูตร (2)

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

F-Score คือ เป็นค่าที่สะท้อนค่า Recall กับ Precision พร้อมกัน เป็น General Term ที่ไม่ได้ระบุค่าเบต้า (Beta) เป็นการให้ค่าน้ำหนัก (Weight) ค่า Precision กับ Recall ว่า F ตัวนี้จะสะท้อนค่าอะไรมากกว่ากัน ถ้าค่าเบต้าเท่ากับ 0.5 จะสะท้อน Precision ออกมามากกว่าและค่าเบต้าเท่ากับ 2 จะสะท้อนค่า Recall ออกมามากกว่า Precision สำหรับ F1-score คือ F-score ที่ระบุค่าเบต้าเท่ากับ 1 ตัวอย่างเช่น ค่าเฉลี่ยระหว่างค่าความแม่นยำและค่าความถูกต้องของการตรวจจับผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัย, ค่าเฉลี่ยระหว่างค่าความแม่นยำและค่าความถูกต้องของการตรวจจับผู้ขับขี่รถจักรยานยนต์ไม่สวมหมวกนิรภัย หาได้จากสูตร (3)

$$F1 - score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (3)$$

mAP (mean Average Precision) คือ ตัววัดที่ใช้ในการประเมินประสิทธิภาพของระบบตรวจจับวัตถุ (object detection) ในกรณีที่ต้องการตรวจสอบภาพรวมในการเทรนและมีการเทรนคลาสมากกว่าหนึ่งคลาสขึ้นไป เพื่อตรวจสอบค่าเฉลี่ยของความแม่นยำของการตรวจจับวัตถุทั้งหมด ยกตัวอย่าง เช่น คำนวณจากค่าเฉลี่ยของความแม่นยำของการตรวจจับผู้ขับขี่รถจักรยานยนต์สวมหมวกนิรภัยกับความแม่นยำของการตรวจจับผู้ขับขี่รถจักรยานยนต์ไม่สวมหมวกนิรภัย หาได้จากสูตร (4)

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i \quad (4)$$

2.7 งานวิจัยที่เกี่ยวข้อง

ผู้วิจัยทำการทบทวนวรรณกรรมที่เกี่ยวข้องกับการตรวจจับวัตถุ โดยในประเทศจีนศึกษา การพัฒนาระบบตรวจจับหมาวนิรภัยของผู้ขับขี่รถจักรยานยนต์ โดยใช้อัลกอริทึม YOLOv5 มีการ เปรียบเทียบโมเดลแบบ Two-stage ได้แก่ Faster R-CNN, Cascade R-CNN และ Libra R-CNN กับแบบ One-Stage ได้แก่ SSD, RetinaNet และ FCOS ซึ่งผลลัพธ์ที่ได้ โมเดล YOLOv5 ที่เป็น แบบ One-Stage มีค่า mAP มากที่สุดเมื่อเปรียบเทียบกับทุกโมเดล โดยมีค่า mAP อยู่ที่ 97.7% และ F1-Score อยู่ที่ 92.7% (Jia, 2021) ต่อมาในประเทศพม่า ก็ได้ทำการศึกษาพัฒนาระบบ ตรวจจับหมาวนิรภัยเช่นกัน แต่จะนำวิธี CNN-base multi-task (MTL) มาใช้ โดยงานวิจัยนี้ได้ เลือกลงใช้โมเดล YOLOv2 และ RetinaNet มาทำการเปรียบเทียบประสิทธิภาพ โดยผลลัพธ์ที่ได้คือ โมเดล YOLOv2 มีค่า F1-Score อยู่ที่ 60.0% และโมเดล RetinaNet มีค่า F1-Score อยู่ที่ 67.3% (Lin, 2020) จะสังเกตได้ว่า จากผลลัพธ์ที่ได้เปรียบเทียบระหว่างการนำ YOLOv5 ในงานวิจัยใน ประเทศจีนและการนำ YOLOv2 และ RetinaNet ในงานวิจัยในประเทศพม่า จะเห็นได้ว่า YOLOv5 มีประสิทธิภาพสูงกว่าทั้ง YOLOv2 และ RetinaNet ในการตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่ รถจักรยานยนต์อันเนื่องมาจากโมเดล YOLOv5 นั้นได้รับการพัฒนาปรับปรุงมาจากเวอร์ชันก่อน หน้า

หลังจากนั้นทางผู้วิจัยได้ทบทวนวรรณกรรมที่เกี่ยวข้องกับการนำโมเดล YOLO ไป ประยุกต์ใช้ร่วมกับ CNN โดยมีงานวิจัย (Sanchana, 2023) ได้นำ YOLO และ CNN มาทำงาน ร่วมกันในการตรวจจับหมาวนิรภัยจากชุดข้อมูลภาพ ชุดข้อมูลรูปภาพที่ใช้ในการฝึกมีทั้งหมด 30,000 รูปภาพ โดยแบ่งเป็น 13,000 รูปที่เป็นรูปภาพผู้ขับขี่รถจักรยานยนต์ที่ไม่สวมหมวกนิรภัย และ 17,000 รูปที่เป็นรูปภาพผู้ขับขี่รถจักรยานยนต์ที่สวมหมวกนิรภัย โดยนำชุดข้อมูลมาทำการฝึก กับ CNN เพื่อใช้ในการแยกคุณลักษณะที่จำเป็นจากรูปภาพ หลังจากนั้นนำคุณลักษณะที่ได้ไปทำการ ตรวจจับวัตถุและจำแนกโดยใช้ YOLO ได้ผลลัพธ์ที่มีความแม่นยำอยู่ที่ 94.29% และงานวิจัย (Dasgupta, 2019) ก็ได้เลือกใช้ YOLO และ CNN มาทำงานร่วมกัน แต่จะแตกต่างกันในส่วนของการ ประยุกต์ใช้งาน โดย YOLO จะถูกนำมาใช้ในการตรวจจับวัตถุในรูปภาพ ได้แก่ ผู้ขับขี่ รถจักรยานยนต์, ผู้ซ้อนรถจักรยานยนต์ และรถจักรยานยนต์ ส่วน CNN จะใช้ในการตรวจจับการ สวมใส่หมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์และผู้นั่งซ้อนท้าย โดยผลลัพธ์ในการตรวจจับผู้ขับขี่ รถจักรยานยนต์ ผู้นั่งซ้อนท้ายรถจักรยานยนต์ และรถจักรยานยนต์ นั้นมีความแม่นยำอยู่ที่

91.08% และในตรวจจับการสวมหมวกนิรภัยมีความแม่นยำอยู่ที่ 96.23% จะสังเกตได้ว่าทั้งสองงานวิจัยจะนำเสนอโมเดล YOLO เป็นวิธีการหลักในการตรวจจับวัตถุในรูปภาพ และใช้ CNN เพื่อประมวลผลเพิ่มเติมหรือการแยกแยะคุณลักษณะของวัตถุก่อนที่ YOLO จะทำการตรวจจับ นั้นมีประสิทธิภาพในการตรวจจับที่ค่อนข้างสูง

ผู้วิจัยมีความสนใจที่จะใช้ Google Colab เป็นเครื่องมือในการพัฒนาการตรวจจับการสวมหมวกนิรภัย จึงได้ทบทวนวรรณกรรมที่เกี่ยวข้องกับการใช้ Google Colab ในการพัฒนาพบว่างานวิจัย (Sivaraj, 2021) ได้ใช้ Google Colab เป็นเครื่องมือในการพัฒนาการตรวจจับการสวมหมวกนิรภัยกับชุดข้อมูลรูปภาพที่ใช้ในการฝึกโมเดลมาจากเว็บไซต์โอเพนซอร์ส มีจำนวนทั้งหมด 2,121 รูปภาพ ทำการฝึกกับ 3 โมเดล ได้แก่ YOLOv3, SSD300 และ Caffe Model โดยผลลัพธ์พบว่าโมเดล YOLOv3 มีความแม่นยำมากที่สุดจากทั้ง 3 โมเดล โดยมีความแม่นยำอยู่ที่ 90.13%

จากการทบทวนวรรณกรรมที่เกี่ยวข้องกับการตรวจจับวัตถุและความเหมาะสมกับการตรวจจับการสวมหมวกนิรภัยนั้น ทางผู้วิจัยจึงได้เลือกโมเดล Yolo (You Only Look Once) ที่เป็นการตรวจจับวัตถุแบบ One-stage detectors มาเป็นโมเดลในการฝึกกับชุดข้อมูลที่ผู้วิจัยได้ทำการเก็บรวบรวมข้อมูลมา

ตาราง 1 การเปรียบเทียบการตรวจจับวัตถุ ชุดข้อมูล อัลกอริทึม และผลลัพธ์ของบทความวิจัยที่เกี่ยวข้อง

บทความวิจัย	การตรวจจับวัตถุ	ชุดข้อมูล	อัลกอริทึม	ผลลัพธ์
1	-หมวกนิรภัยของผู้ขับขี่ -รถจักรยานยนต์	Custom dataset	YOLOv5	mAP 97.7% F1-Score 92.7%
2	-หมวกนิรภัยของผู้ขับขี่ -หมวกนิรภัยของผู้ซ้อน	Custom dataset	YOLOv2 RetinaNet	F1-Score 60.0% F1-Score 67.3%
3	-หมวกนิรภัยของผู้ขับขี่ -รถจักรยานยนต์	Public dataset	YOLOv3 YOLOv1 CNN SSD300 Caffe Model	Accuracy 91.19% Accuracy 81.00% Accuracy 85.00% Accuracy 74.30% Accuracy 76.00%
4	-หมวกนิรภัยของผู้ขับขี่	Public dataset	Y O L O ร่วมกับ CNN	Accuracy 94.29%
5	-ผู้ขับขี่และผู้ซ้อน -รถจักรยานยนต์ -หมวกนิรภัยของผู้ขับขี่ -หมวกนิรภัยของผู้ซ้อน	Public dataset	Y O L O ร่วมกับ CNN	Accuracy 91.08% Accuracy 96.23%

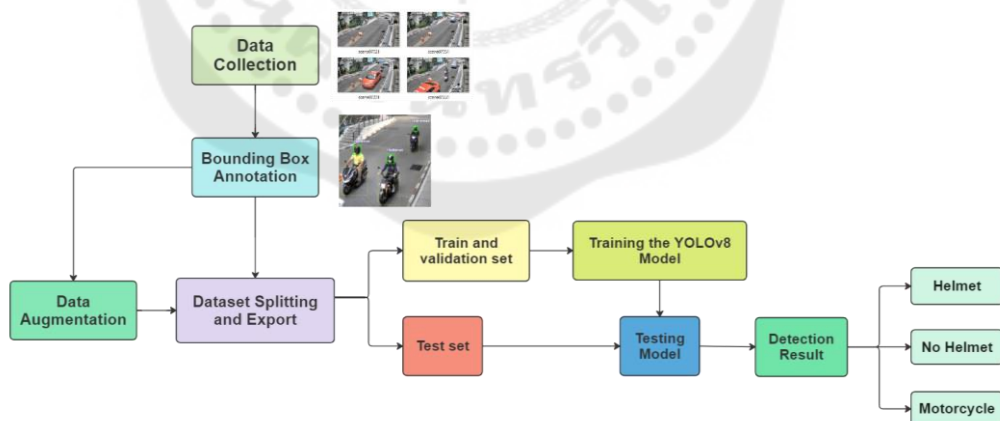
จากตาราง 1 เปรียบเทียบการตรวจจับวัตถุ ชุดข้อมูล อัลกอริทึม และผลลัพธ์ของบทความวิจัยที่เกี่ยวข้อง พบว่าบทความที่ 1 ใช้อัลกอริทึม YOLOv5 ร่วมกับ Custom dataset ให้ค่า mAP และ F1-score ที่ค่อนข้างสูง บทความที่ 2 จะเห็นถึงการเปรียบเทียบผลลัพธ์ของค่า F1-Score ที่แตกต่างกันพอสมควรของอัลกอริทึม YOLOv2 และ RetinaNet บทความที่ 3 ถึง 5 จะเป็นบทความที่เลือกใช้ Public dataset ในการฝึกอัลกอริทึม โดยบทความที่ 3 จะทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึมทั้งหมด 5 อัลกอริทึม โดยอัลกอริทึมที่ให้ผลลัพธ์ที่ดีที่สุดคือ YOLOv3 ส่วนบทความที่ 4 และ 5 จะมีความคล้ายคลึงกันในส่วนของอัลกอริทึมที่เลือกใช้เป็น YOLO ร่วมกับ CNN และในส่วนของชุดข้อมูลที่เลือกใช้เป็น Public dataset โดย YOLO ร่วมกับ CNN ของทั้งสองบทความให้ผลลัพธ์ที่ค่อนข้างสูงมากกว่า 90 % ขึ้นไป

บทที่ 3 วิธีการดำเนินการวิจัย

ในการพัฒนาการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์โดยใช้เทคนิคการเรียนรู้ของเครื่อง ผู้วิจัยได้เก็บรวบรวมข้อมูลจากงานวิจัยที่เกี่ยวข้อง ซึ่งเป็นประโยชน์ในการพัฒนาการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ โดยนำมาวิเคราะห์ ออกแบบ และพัฒนาเพื่อให้เกิดการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์มีประสิทธิภาพมากที่สุด ผู้วิจัยได้ดำเนินการตามขั้นตอนต่อไปนี้

- 3.1 กระบวนการสร้างและทำงานของแบบจำลอง
- 3.2 เก็บรวบรวมข้อมูล
- 3.3 ทำการแปลงข้อมูลให้กลายเป็นข้อมูลที่สามารถนำไปวิเคราะห์
- 3.4 กำหนดกรอบวัตถุที่ต้องการ
- 3.5 การเสริมข้อมูล (Data Augmentation)
- 3.6 ฝึกแบบจำลอง
- 3.7 สรุปแนวคิดและวิธีวิจัย

3.1 กระบวนการสร้างและทำงานของแบบจำลอง



ภาพประกอบ 11 กระบวนการสร้างและทำงานของแบบจำลอง

จากภาพประกอบที่ 11 อธิบายถึงกระบวนการสร้างแบบจำลองการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์โดยเริ่มจากขออนุมัติใช้ข้อมูลจากรองคณบดีงานสร้างเสริมสุขภาพ โดย

หลังจากที่ได้ข้อมูลมาแล้วข้อมูล (Get Image Data) จะอยู่ในรูปแบบข้อมูลวิดีโอจะต้องทำการเปลี่ยนข้อมูลวิดีโอให้เป็นข้อมูลภาพถึงจะสามารถใช้เป็นการฝึกแบบจำลองได้

เมื่อได้ข้อมูลภาพแล้ว ทำการคัดเลือกภาพที่สามารถนำไปใช้ในการฝึกแบบจำลองได้ เพราะเนื่องจากข้อมูลภาพที่ได้มานั้นมีข้อมูลที่สามารถใช้ในการฝึกแบบจำลองได้และไม่ได้ หลังจากนั้นนำข้อมูลภาพที่สามารถใช้ในการฝึกแบบจำลองได้ ไปทำการกำหนดกรอบวัตถุที่ระบุคลาส (Create bonding box) ได้แก่ คลาส Motorcycle สำหรับภาพที่มีผู้ขับขี่รถจักรยานยนต์, คลาส Helmet สำหรับภาพที่มีหมวกนิรภัยของทั้งผู้ขับขี่รถจักรยานยนต์และผู้ซ้อน, คลาส No Helmet สำหรับภาพที่ไม่มีหมวกนิรภัยของทั้งผู้ขับขี่รถจักรยานยนต์และผู้ซ้อน

หลังจากที่กำหนดกรอบวัตถุให้กับข้อมูลภาพเสร็จแล้วนั้น ผู้วิจัยได้นำชุดข้อมูลไปทำ Data Augmentation และอีกชุดข้อมูลที่ไม่ได้ทำ Data Augmentation มาทำการแบ่งข้อมูล (Dataset Splitting) ออกเป็นข้อมูลชุดสำหรับการฝึกแบบจำลอง ข้อมูลชุดสำหรับตรวจสอบความถูกต้องของแบบจำลอง (Train/Validation set) และข้อมูลชุดทดสอบแบบจำลอง (Testing set) นำข้อมูลชุดสำหรับการฝึกแบบจำลองไปฝึกกับแบบจำลอง YOLOv8 (Training Model) โดยต้องระบุนพารามิเตอร์ให้เหมาะสมกับการตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์

เมื่อแบบจำลอง YOLOv8 ได้รับการฝึกเป็นที่เรียบร้อยแล้ว นำแบบจำลองที่มีค่า Weight ที่เหมาะสม (Save weight) ไปทดสอบ (Testing Model) กับข้อมูลชุดทดสอบแบบจำลอง (Testing set) ด้วยการทำการตรวจจับวัตถุในภาพ (Object Detect) และแสดงผลพร้อมค่าประเมินต่างๆ ว่าแบบจำลองสามารถตรวจจับการหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนรวมถึงรถจักรยานยนต์ได้มากน้อยเพียงใด

3.2 เก็บรวบรวมข้อมูล

การดำเนินการศึกษาผู้วิจัยได้ทำการรวบรวมข้อมูลจากกล้องวงจรปิดทั้ง 4 บริเวณ ได้แก่ ประตู 1, ประตู 5, ประตู 7 และประตู 8 ภายในโรงพยาบาลศิริราช ที่ทางงานสร้างเสริมสุขภาพ คณะแพทยศาสตร์ศิริราชพยาบาล มหาวิทยาลัยมหิดลได้ทำการบันทึกไว้ ตลอด 24 ชั่วโมง ซึ่งข้อมูลที่ได้จะอยู่ในรูปแบบวิดีโอที่ผ่านการบันทึกภาพจากกล้องวงจรปิด โดยจะนำข้อมูลวิดีโอเฉพาะช่วงเวลาที่มีการปรากฏของวัตถุที่ต้องการจะตรวจจับมาเป็นข้อมูลสำหรับการฝึกแบบจำลอง



ภาพประกอบ 12 บริเวณประตู 1



ภาพประกอบ 13 บริเวณประตู 5



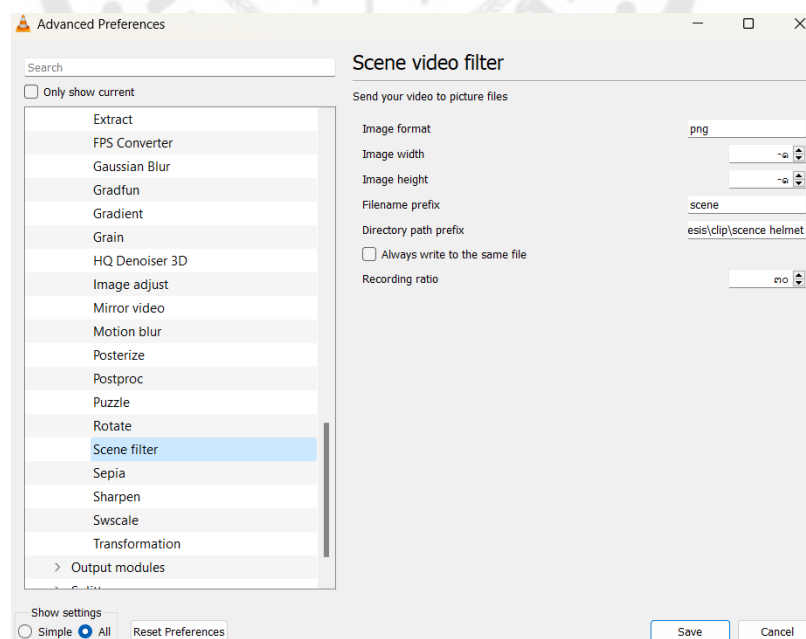
ภาพประกอบ 14 บริเวณประตู 7



ภาพประกอบ 15 บริเวณประตู 8

3.3 ทำการแปลงข้อมูลให้กลายเป็นข้อมูลที่สามารถนำไปวิเคราะห์

การนำข้อมูลที่ได้จากกล้องวงจรปิดทั้ง 4 บริเวณภายในโรงพยาบาลศิริราชนั้นไม่สามารถนำไปฝึกแบบจำลองได้ ต้องทำการแปลงข้อมูลในรูปแบบวิดีโอให้เป็นข้อมูลภาพและจึงจะสามารถนำข้อมูลภาพไปทำการกำหนดกรอบวัตถุ (Bounding Box) ในข้อมูลภาพได้ ขั้นตอนการแปลงข้อมูลวิดีโอให้เป็นภาพผู้วิจัยใช้โปรแกรม VLC ในการแปลงข้อมูลวิดีโอให้เป็นรูปภาพและมีการตั้งค่าโปรแกรม VLC ดังภาพประกอบที่ 16



ภาพประกอบ 16 การตั้งค่าโปรแกรม VLC ในการแปลงข้อมูลวิดีโอให้เป็นข้อมูลรูปภาพ

เมื่อทำการแปลงข้อมูลวิดีโอจากกล้องวงจรปิดทั้ง 4 บริเวณภายในโรงพยาบาลศิริราชให้เป็นข้อมูลรูปภาพจากโปรแกรม VLC จะได้จำนวนรูปภาพทั้งหมดเป็นจำนวนมาก ดังแสดงตัวอย่างในภาพประกอบที่ 17



ภาพประกอบ 17 ผลลัพธ์การแปลงข้อมูลวิดีโอให้เป็นรูปภาพ

ผลลัพธ์จากการแปลงข้อมูลวิดีโอให้เป็นรูปภาพจะมีภาพที่สามารถใช้งานได้และไม่สามารถใช้งานได้ ดังตัวอย่างเช่น ภาพที่ใช้ในการฝึกแบบจำลอง ได้คือ ภาพประกอบที่ 18, 19, 20, 21 และ 22 ส่วนภาพที่ไม่สามารถใช้ในการฝึกแบบจำลองแต่สามารถนำไปทดสอบแบบจำลองได้ คือ ภาพประกอบที่ 23



ภาพประกอบ 18 ผู้ขับขี่รถจักรยานยนต์ที่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)



ภาพประกอบ 19 ผู้ขับขี่รถจักรยานยนต์ที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)



ภาพประกอบ 20 ผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนที่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)



ภาพประกอบ 21 ผู้ขับขี่รถจักรยานยนต์ที่สวมหมวกนิรภัยและผู้ซ้อนที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)



ภาพประกอบ 22 ผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนที่ไม่สวมหมวกนิรภัย (รูปภาพที่สามารถใช้งานได้)



ภาพประกอบ 23 ถนนที่ไม่มีผู้ขับขี่รถจักรยานยนต์และผู้ซ้อน (รูปภาพที่ไม่สามารถใช้งานได้แต่
นำไปทดสอบแบบจำลองได้)

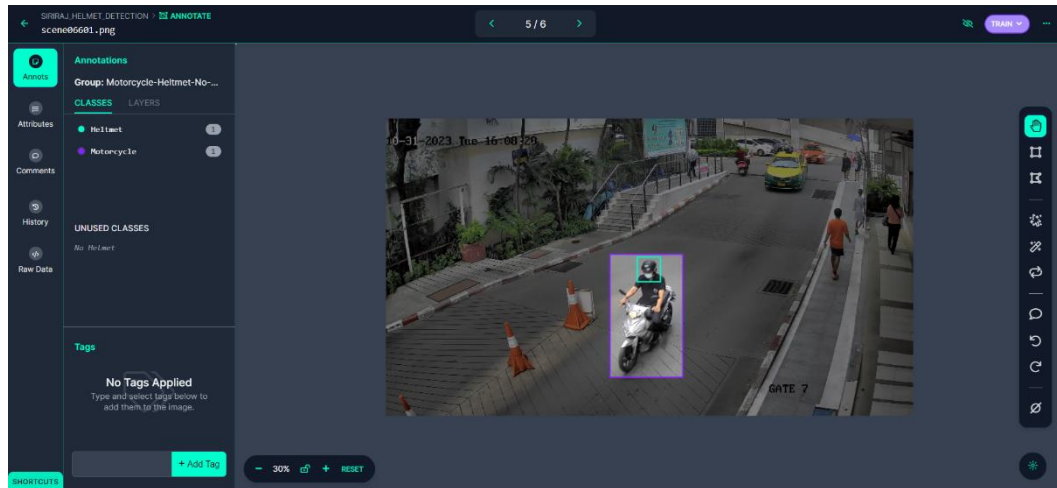
ทางผู้วิจัยได้ทำการเลือกรูปที่จะใช้ในการฝึกแบบจำลองทั้งหมด 2,105 รูปภาพ โดยมี
หลักการเลือก คือ

1. ข้อมูลรูปภาพต้องมีวัตถุที่ผู้วิจัยต้องการจะตรวจจับ ได้แก่ รถจักรยานยนต์ การ
สวมใส่หมวกนิรภัย และการไม่สวมใส่หมวกนิรภัย
2. ข้อมูลรูปภาพสามารถระบุผู้ขับขี่รถจักรยานยนต์ได้ว่าสวมใส่หมวกนิรภัยหรือไม่
สวมใส่หมวกนิรภัย
3. ข้อมูลรูปภาพสามารถระบุผู้ซ้อนรถจักรยานยนต์ได้ว่าสวมใส่หมวกนิรภัยหรือไม่
สวมใส่หมวกนิรภัย
4. ข้อมูลรูปภาพในแต่ละรูปจะไม่มีวัตถุที่ผู้วิจัยต้องการจะตรวจจับที่ซ้ำกัน

3.4 กำหนดกรอบวัตถุที่ต้องการ (Bounding Box)

เว็บไซต์ Roboflow เป็นเว็บไซต์ที่มีเครื่องมือและบริการที่ช่วยในการจัดการและปรับปรุง
ข้อมูลภาพสำหรับการฝึกแบบจำลองที่ใช้ในการเรียนรู้ของคอมพิวเตอร์ (Machine learning)
โดยเฉพาะในด้านการปรับปรุงข้อมูลภาพดิจิทัล นอกจากนี้ยังมีฟังก์ชันในการแบ่งชุดข้อมูล
ทดสอบ (Test dataset) และชุดข้อมูลที่ใช้ในการตรวจสอบ (Validation dataset) เพื่อใช้ในการวัด
ประสิทธิภาพของการฝึกแบบจำลอง การใช้ Roboflow ช่วยลดภาระงานในขั้นตอนการเตรียม
ข้อมูลสำหรับการฝึกแบบจำลองและทำให้กระบวนการนี้มีประสิทธิภาพมากขึ้น (Faizan, 2022)

โดยทางผู้วิจัยได้เลือกใช้เว็บไซต์ Roboflow ในการกำหนดกรอบวัตถุกับรูปที่จะใช้ในการฝึกแบบจำลอง



ภาพประกอบ 24 ตัวอย่างเว็บไซต์ Roboflow ที่ใช้ในการกำหนดกรอบวัตถุ (Bounding Box)

การกำหนดกรอบวัตถุ (Bounding Box) ผู้วิจัยทำการกำหนดกรอบวัตถุ ได้แก่ รถจักรยานยนต์ การสวมใส่หมวกนิรภัย การไม่สวมใส่หมวกนิรภัย ดังแสดงตัวอย่างในภาพประกอบที่ 25 ถึงภาพประกอบที่ 30



ภาพประกอบ 25 กรอบวัตถุรถจักรยานยนต์จากเว็บไซต์ Roboflow



ภาพประกอบ 26 กรอบวัตถุผู้ขับขี่รถจักรยานยนต์สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow



ภาพประกอบ 27 กรอบวัตถุผู้ขับขี่รถจักรยานยนต์ไม่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow



ภาพประกอบ 28 กรอบวัตถุผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนที่สวมใส่หมวกนิรภัยจากเว็บไซต์ Roboflow




ภาพประกอบ 29 กรอบวัตถุผู้ขับขี่รถจักรยานยนต์ที่สวมใส่หมวกนิรภัยและผู้ซ้อนไม่สวมใส่หมวก
นิรภัยจากเว็บไซต์ Roboflow



ภาพประกอบ 30 กรอบวัตถุผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนไม่สวมใส่หมวกนิรภัยจากเว็บไซต์
Roboflow

หลังจากทำการกำหนดกรอบวัตถุในข้อมูลรูปภาพทั้งหมดแล้วนั้นทางผู้วิจัยได้ทำการ Dataset Split ให้ได้ชุดข้อมูลสำหรับการฝึกแบบจำลองและทดสอบแบบจำลอง โดยรูปภาพในชุดข้อมูลฝึกแบบจำลองและทดสอบแบบจำลองนั้นจะไม่มีรูปภาพที่ซ้ำกัน ดังภาพประกอบที่ 31

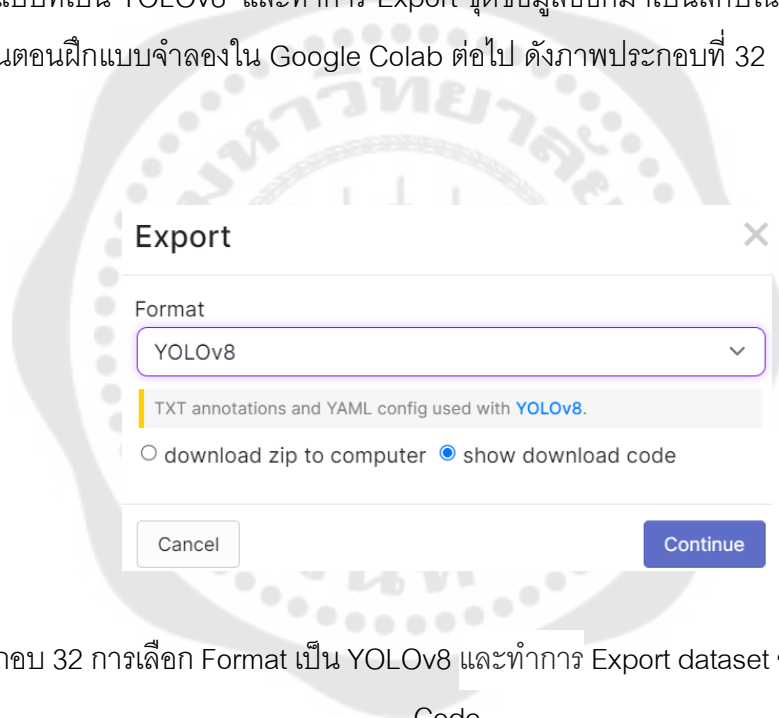


ภาพประกอบ 31 การแบ่งชุดข้อมูลสำหรับการเทรนนิ่งและทดสอบแบบจำลองจากเว็บไซต์
Roboflow

ที่มา : <https://roboflow.com/>

ทำการ Export ชุดข้อมูลโดยทางผู้วิจัยได้กำหนดรูปแบบให้เหมาะสมสำหรับแบบจำลองโดยการเลือก รูปแบบที่เป็น YOLOv8 และทำการ Export ชุดข้อมูลออกมาเป็นลักษณะ Code เพื่อเตรียมไว้ใช้ในขั้นตอนฝึกแบบจำลองใน Google Colab ต่อไป ดังภาพประกอบที่ 32 และภาพประกอบที่

33



ภาพประกอบ 32 การเลือก Format เป็น YOLOv8 และทำการ Export dataset ออกมาเป็นลักษณะ
Code

ที่มา : <https://roboflow.com/>


```
!pip install ultralytics
```

ภาพประกอบ 34 ได้ดเรียกใช้ไลบรารี Ultralytics

```
from ultralytics import YOLO
import os
import ultralytics
from IPython.display import display, Image
from IPython import display
display.clear_output()
!yolo mode=checks
ultralytics.checks()
```

ภาพประกอบ 35 คำสั่งติดตั้ง YOLOv8 และคำสั่งอื่นๆที่เกี่ยวข้อง

หลังจากนั้นจะเข้าสู่ขั้นตอนการฝึกแบบจำลอง YOLOv8 โดยเริ่มจากนำ Code ของชุดข้อมูลจากเว็บไซต์ Roboflow มาทำการรันบน Google Colab เพื่อเป็นการดาวน์โหลดชุดข้อมูลจากเว็บไซต์ Roboflow ที่จะใช้ในการฝึกแบบจำลอง ดังภาพประกอบที่ 36

```
!pip install roboflow

from roboflow import Roboflow
rf = Roboflow(api_key="68Tfdjd9iqdyBJZ4LxdG")
project = rf.workspace("swu-f4qdd").project("motorcycle-and-helmet-nhsgb")
dataset = project.version(3).download("yolov8")
```

ภาพประกอบ 36 ตัวอย่างโค้ดของชุดข้อมูลจากเว็บไซต์ Roboflow

เมื่อดาวน์โหลดชุดข้อมูลแล้วทำการเขียนสคริปต์ภาษา Python ในการฝึกแบบจำลอง YOLOv8 โดยต้องกำหนดการตั้งค่าต่างๆดังนี้ Task, Mode, Model, Data, Epochs และ Imgsz

พารามิเตอร์ Task เป็นพารามิเตอร์ไว้สำหรับกำหนดกรอบการทำงานที่เกี่ยวข้องกับงานด้านคอมพิวเตอร์วิทัศน์ของ YOLOv8 โดยขึ้นอยู่กับผู้ใช้งานในการกำหนดกรอบการทำงานให้ตรงกับวัตถุประสงค์ของผู้ใช้งานสามารถตั้งค่าได้ ดังนี้

- Detect ใช้สำหรับงานที่ต้องการระบุและตำแหน่งวัตถุหรือพื้นที่ที่น่าสนใจในภาพหรือวิดีโอ

- Segment ใช้สำหรับงานที่ต้องการการแบ่งภาพหรือวิดีโอเป็นพื้นที่หรือพิกเซลที่สอดคล้องกับวัตถุหรือคลาสต่างๆ

- Classify ใช้สำหรับงานที่ต้องการจำแนกคลาสต่างๆในรูปภาพ

- Pose ใช้สำหรับงานที่ต้องการติดตามการเคลื่อนไหวหรือการประมาณตำแหน่งจากจุดคีย์พอยต์ที่เฉพาะเจาะจงในภาพหรือวิดีโอ

พารามิเตอร์ Mode เป็นพารามิเตอร์ที่สำคัญที่ผู้ใช้งานควรทราบว่าแบบจำลองนั้นสามารถทำงานในรูปแบบใดได้บ้าง สามารถตั้งค่าได้ ดังนี้

- Train ใช้สำหรับการฝึกแบบจำลอง YOLOv8 ด้วยชุดข้อมูลที่กำหนดเอง

- Val ใช้สำหรับการตรวจสอบความถูกต้องของแบบจำลอง YOLOv8 หลังจากที่ได้รับการฝึก

- Predict ใช้สำหรับการทำนายโดยใช้แบบจำลอง YOLOv8 ที่ฝึกกับชุดข้อมูล

- Export ใช้สำหรับการส่งออกแบบจำลอง YOLOv8 เพื่อให้เป็นรูปแบบที่สามารถนำไปใช้งานต่อได้

- Track ใช้สำหรับการติดตามวัตถุในเวลาจริงโดยใช้แบบจำลอง YOLOv8

- Benchmark ใช้สำหรับการทดสอบความเร็วและความแม่นยำของการส่งออกแบบจำลอง YOLOv8

พารามิเตอร์ Model สามารถเลือกตั้งค่าได้ดังตารางเปรียบเทียบ Pre-trained Weights ของ YOLOv8 สำหรับ Task detection ซึ่งจะมีความแตกต่างในส่วน of mAP, Speed CPU ONNX, Speed A100 TensorRT, params และ FLOPs แต่ในส่วน of size (pixels) จะมีขนาด 640 ที่เท่ากันในทุกโมเดล ดังภาพประกอบที่ 37

Model	mAP ^{val} 50-95	Speed CPU ONNX (ms)	Speed CPU ONNX (ms)	Params (M)	FLOPs (B)
YOLOv8n	37.3	80.4	0.99	3.2	8.7
YOLOv8s	44.9	128.4	1.20	11.2	28.6
YOLOv8m	50.2	234.7	1.83	25.9	78.9
YOLOv8l	52.9	375.2	2.39	43.7	165.2
YOLOv8x	53.9	479.1	3.53	68.2	257.8

ภาพประกอบ 37 ตารางเปรียบเทียบ Pre-trained Weights ของ YOLOv8 สำหรับ Task detection
ที่มา : <https://docs.ultralytics.com/models/yolov8/#supported-modes>

พารามิเตอร์ Data กำหนดตำแหน่งของชุดข้อมูลที่ใช้ในการฝึกแบบจำลอง

พารามิเตอร์ Epoch กำหนดจำนวนรอบที่จะทำการฝึกแบบจำลอง

พารามิเตอร์ Imgsz กำหนดขนาดของภาพที่ใช้ในการฝึกแบบจำลอง

```
!yolo task=detect mode=train model=yolov8m.pt data=
{dataset.location}/data.yaml epochs=10 imgs=640
```

ภาพประกอบ 38 ตัวอย่างสคริปต์ภาษา Python ในการฝึกแบบจำลอง YOLOv8 และการกำหนด
พารามิเตอร์

ตาราง 2 ผลลัพธ์ที่ได้จากการฝึกแบบจำลอง YOLOv8

Class	Instances	P	R	mAP50	mAP50-95
No Helmet	141	0.739	0.738	0.821	0.433
Helmet	193	0.811	0.751	0.799	0.424
Motorcycle	266	0.919	0.929	0.965	0.682

หลังจากที่ฝึกแบบจำลอง YOLOv8 เป็นที่เรียบร้อยแล้วทางผู้วิจัยได้ทำการตรวจสอบความถูกต้องของแบบจำลองกับชุดข้อมูลตรวจสอบโดยเขียนสคริปต์ภาษา Python ดังภาพประกอบที่ 39

```
!yolo task=detect mode=val
model=/content/runs/detect/train6/weights/best.pt
data={dataset.location}/data.yaml
```

ภาพประกอบ 39 ตัวอย่างสคริปต์ภาษา Python ในการตรวจสอบความถูกต้องของแบบจำลอง YOLOv8

ตาราง 3 ผลลัพธ์ที่ได้จากการตรวจสอบความถูกต้องของแบบจำลอง YOLOv8

Class	Instances	P	R	mAP50	mAP50-95
No Helmet	141	0.740	0.738	0.821	0.433
Helmet	193	0.812	0.751	0.798	0.424
Motorcycle	266	0.919	0.929	0.965	0.681

โดยผลลัพธ์ที่ได้จากการฝึกและตรวจสอบความถูกต้องของแบบจำลอง YOLOv8 ดังตารางที่ 2 และ 3 จะมีการระบุจำนวนของภาพ (Images) ที่ถูกนำมาใช้ในการฝึกและตรวจสอบ โดยสามารถอธิบายรายละเอียดในตาราง ได้ดังนี้

1. Class คือ จำนวนของคลาสหรือประเภทของวัตถุที่แบบจำลองต้องการจำแนก
2. Instances คือ จำนวนของวัตถุทั้งหมดที่ถูกตรวจจับในแต่ละคลาส
3. P (Precision) คือ ค่าที่แสดงอัตราส่วนของวัตถุทั้งหมดที่ถูกตรวจจับถูกต้องต่อการทำนายว่าเป็นวัตถุทั้งหมดของแบบจำลอง (All Detections)
4. R (Recall) คือ ค่าที่แสดงอัตราส่วนของวัตถุทั้งหมดที่ถูกตรวจจับถูกต้องต่อจำนวนวัตถุทั้งหมดที่เป็นจริง (All Ground Truth)
5. mAP50 คือ ค่าความแม่นยำเฉลี่ยที่คำนวณจากการตรวจจับวัตถุที่ใช้ threshold ที่ 50% IoU ในกระบวนการคำนวณ Average Precision สำหรับแต่ละคลาส

6. mAP50-95 คือ ค่าความแม่นยำเฉลี่ยที่คำนวณจากการตรวจจับวัตถุที่ใช้ threshold ตั้งแต่ 50% ถึง 95% IoU ในกระบวนการคำนวณ Average Precision สำหรับแต่ละคลาส

หลังจากที่ทำการตรวจสอบความถูกต้องของแบบจำลองเป็นที่เรียบร้อยแล้ว ทางผู้วิจัยได้ทำการทดสอบแบบจำลอง YOLOv8 กับชุดข้อมูลทดสอบโดยเขียนสคริปต์ภาษา Python และได้ดำเนินการโชว์ผลลัพธ์ ดังภาพประกอบที่ 40 และ 41

```
!yolo task=detect mode=predict
model=/content/runs/detect/train2/weights/best.pt
source='/content/drive/MyDrive/siriraj_helmet_detection'
```

ภาพประกอบ 40 ตัวอย่างสคริปต์ภาษา Python ในการทดสอบแบบจำลอง YOLOv8



ภาพประกอบ 41 ตัวอย่างผลลัพธ์ในการทดสอบแบบจำลอง YOLOv8

3.6 สรุปแนวคิดและวิธีวิจัย

งานวิจัยนี้มีเป้าหมายในการศึกษาสร้างระบบตรวจจับหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ในพื้นที่โรงพยาบาลศิริราช โดยใช้ชุดข้อมูลจากกล้องวงจรปิดจำนวน 1,006 รูปภาพ บริเวณ ประตู 1 ประตู 5 ประตู 7 และประตู 8 เพื่อทดแทนการสังเกตโดยบุคคล การสร้างแบบจำลองมีขั้นตอนดังนี้

ทำการขออนุมัติใช้ข้อมูลจากรองคมนตรีฝ่ายสร้างเสริมสุขภาพ เมื่อได้รับข้อมูลมาแล้วทำความเข้าใจข้อมูลและตรวจสอบความพร้อมของข้อมูลก่อนนำไปใช้ในการสร้างแบบจำลอง ข้อมูลวิดีโอจะถูกแปลงเป็นข้อมูลภาพจากโปรแกรม VLC

ข้อมูลภาพจะถูกนำเข้าเว็บไซต์ Roboflow เพื่อทำการสร้าง Bounding box (กรอบวัตถุ) ที่ระบุคลาสต่างๆ ได้แก่ Motorcycle, Helmet, No Helmet และทำการแบ่งข้อมูลที่ทำกรกำหนดกรอบวัตถุแล้วออกเป็นข้อมูลสำหรับการฝึกแบบจำลองและทดสอบ

อัลกอริทึมที่ใช้ในการระบบตรวจจับห้วงกนริภยของผู้ขับขี่รถจักรยานยนต์ในพื้นที่โรงพยาบาลศิริราช คือ YOLOv8 ที่จะถูกปรับ Parameter ดังนี้ task, mode, model, data, epochs และ imgsiz ให้มีประสิทธิภาพและเหมาะสมกับเป้าหมายในการตรวจจับห้วงกนริภยร่วมกับชุดข้อมูลสำหรับการฝึกแบบจำลองที่ได้เตรียมไว้

ทำการตรวจสอบความถูกต้องและทดสอบผลลัพธ์ของอัลกอริทึม YOLOv8 ร่วมกับชุดข้อมูลทีแบบจำลองไม่ได้รับการฝึก และประเมินผลลัพธ์ด้วยค่าการประเมินต่างๆ ร่วมกับแสดงผลลัพธ์ออกมาเป็นรูปภาพที่มี Bounding box, Class ที่ถูกต้องตรงกับความเป็นจริง



บทที่ 4

ผลการวิจัย

ผู้วิจัยจะนำเสนอรายละเอียดของผลลัพธ์และอภิปรายประเด็นจากผลลัพธ์ที่น่าสนใจ โดยผู้วิจัยเลือกตัวชี้วัดที่ใช้ในการประเมินผลลัพธ์ ได้แก่ Precision, Recall, mAP50, F1-Score และผลลัพธ์รูปภาพจากชุดข้อมูลทดสอบ

รายละเอียดการทดลอง

ในการทดลองหลังจากที่สร้างกรอบวัตถุ (Bounding box) ให้กับชุดข้อมูลแล้วนั้น ในขั้นตอนของการทำ Preprocessing ผู้วิจัยได้ทำการปรับเปลี่ยนขนาดของภาพ (Resize) ทุกภาพในชุดข้อมูลจาก 2560*1440 ให้มีขนาด 640*640 โดยขนาดภาพ 640*640 นั้นจะเป็นขนาดที่เหมาะสมสำหรับโมเดลในการประมวลผล เพราะถ้าขนาดของภาพใหญ่เกินไปอาจทำให้การตรวจจับวัตถุไม่แม่นยำ เนื่องจากโมเดลอาจไม่สามารถจดจำรายละเอียดของวัตถุได้ดีพอในภาพที่มีขนาดใหญ่ เครื่องมือที่ใช้ในการฝึกและทดสอบโมเดลนั้นทางผู้วิจัยเลือกใช้เป็น Google Colab ที่เลือก Runtime type เป็น Python 3 และกำหนด Hardware accelerator เป็น NVIDIA Tesla V100 SXM2 16 GB และทำการการตั้งค่าพารามิเตอร์ที่สำคัญในการฝึกโมเดลตามตารางที่ 4

ตาราง 4 การตั้งค่าพารามิเตอร์ที่สำคัญในการฝึกโมเดล

Parameter	Value
imgsz	640
batch	16
epochs	100
optimizer	AdamW
Learning rate	0.01

ผลการทดลอง

จากการที่ได้ทดลองฝึกโมเดล YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l และ YOLOv8x ร่วมกับชุดข้อมูลที่ได้เก็บรวบรวมมาเองนั้น ผู้วิจัยได้ประเมินผลลัพธ์โดยรวม (ALL) ของโมเดลแต่ละรุ่นได้ผลลัพธ์ตามตารางที่ 5 จะพบว่าระยะเวลาในการฝึกโมเดลนั้น YOLOv8x ใช้

ระยะเวลาในการฝึกนานที่สุดเมื่อเปรียบเทียบกับโมเดลในรุ่นอื่นๆ ซึ่งเหตุผลมาจากจำนวนพารามิเตอร์ของโมเดล YOLOv8x นั้นมีจำนวนพารามิเตอร์ที่มากที่สุด ส่วน YOLOv8n และ YOLOv8s ใช้ระยะเวลาในการฝึกที่น้อยเมื่อเปรียบเทียบกับโมเดลในรุ่นอื่นๆ ในส่วนของค่าความแม่นยำ (Precision) ของ YOLOv8l มีความแม่นยำสูงที่สุดอยู่ที่ 0.868, ค่าความถูกต้อง (Recall) ของ YOLOv8x มีความถูกต้องสูงที่สุดอยู่ที่ 0.811 และค่าเฉลี่ยความแม่นยำ (mAP50) ของ YOLOv8l และ YOLOv8x มีค่าที่ใกล้เคียงกัน จะเห็นได้ว่า YOLOv8l มีความแม่นยำและประสิทธิภาพในการตรวจจับที่ครอบคลุมสูง แต่ใช้ระยะเวลาในการฝึกที่น้อยกว่า YOLOv8x ส่วน YOLOv8m เป็นตัวเลือกที่ดีในเรื่องของความสมดุลระหว่างระยะเวลาในฝึกและประสิทธิภาพของโมเดล โดยมีค่า Recall, mAP50 และ F1-Score ที่ใกล้เคียงกับ YOLOv8l แต่มีใช้ระยะเวลาฝึกที่น้อยกว่า

ตาราง 5 การประเมินผลลัพธ์โดยรวมของโมเดลแต่ละรุ่น

Model	Training time (hours)	Precision	Recall	mAP50	F1-Score
YOLOv8n	0.471	0.799	0.751	0.803	0.774
YOLOv8s	0.541	0.837	0.783	0.839	0.809
YOLOv8m	1.024	0.855	0.791	0.854	0.822
YOLOv8l	1.201	0.868	0.790	0.859	0.827
YOLOv8x	2.470	0.842	0.811	0.858	0.826

ผลลัพธ์ในคลาสสวมหมวกนิรภัย (Helmet) ในตารางที่ 6 จะพบว่า ค่าความแม่นยำ (Precision) ของ YOLOv8l มีความแม่นยำสูงที่สุด อยู่ที่ 0.855 ส่วนค่าความถูกต้อง (Recall) ของ YOLOv8x มีความถูกต้องสูงที่สุด อยู่ที่ 0.832 และค่า mAP50 ของทั้ง YOLOv8l และ YOLOv8x นั้นมีค่าสูงที่สุดและมีค่าเท่ากันอยู่ที่ 0.870 จากการวิเคราะห์ผลลัพธ์ในคลาสสวมหมวกนิรภัย ผู้วิจัยพบว่าถ้าหากต้องการความแม่นยำของการตรวจจับการสวมหมวกนิรภัยที่สูง สามารถเลือกใช้โมเดล YOLO ได้ทุกรุ่นยกเว้น YOLOv8n เนื่องจากค่าความแม่นยำ (Precision) ของ YOLOv8n นั้นมีค่าไม่สูงมากเมื่อเทียบกับรุ่นอื่น แต่ถ้าต้องการความถูกต้องในการตรวจจับการสวมหมวกนิรภัย (Recall) สามารถเลือกใช้โมเดล YOLOv8l และ YOLOv8x ได้เพราะมีค่าสูงถึง 80% ขึ้นไป

ตาราง 6 ผลลัพธ์คลาสสวมหมวกนิรภัย (Helmet) ของโมเดลแต่ละรุ่น

Model	Precision	Recall	mAP50
YOLOv8n	0.772	0.743	0.802
YOLOv8s	0.816	0.798	0.839
YOLOv8m	0.844	0.789	0.865
YOLOv8l	0.855	0.809	0.870
YOLOv8x	0.829	0.832	0.870

ผลลัพธ์ในคลาสรถจักรยานยนต์ (Motorcycle) ในตารางที่ 7 จะพบว่า ค่าความแม่นยำ (Precision) ของ YOLOv8s มีความแม่นยำสูงที่สุด อยู่ที่ 0.899, ค่าความถูกต้อง (Recall) ของทั้ง YOLOv8s, YOLOv8m และ YOLOv8x มีความถูกต้องที่เท่ากันและมีค่าสูงที่สุด อยู่ที่ 0.940 และค่า mAP50 ของ YOLOv8l มีค่าสูงที่สุด อยู่ที่ 0.967 จากการวิเคราะห์ผลลัพธ์ในคลาสรถจักรยานยนต์ ค่าความถูกต้อง (Recall) และค่า mAP50 ของทุกโมเดลที่รุ่นนั้นมีค่าที่สูง อันเนื่องมาจากโมเดลทุกรุ่นที่ผู้วิจัยนำมาทดลองนั้นเป็น Pretrained detect models ที่ได้ผ่านการฝึกกับชุดข้อมูล COCO ซึ่งภายในชุดข้อมูลมีคลาสรถจักรยานยนต์ด้วยเช่นกัน

ตาราง 7 ผลลัพธ์คลาสรถจักรยานยนต์ (Motorcycle) ของโมเดลแต่ละรุ่น

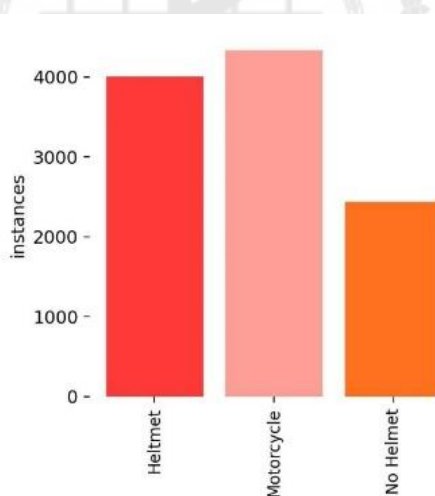
Model	Precision	Recall	mAP50
YOLOv8n	0.878	0.937	0.959
YOLOv8s	0.899	0.940	0.962
YOLOv8m	0.883	0.940	0.966
YOLOv8l	0.893	0.925	0.967
YOLOv8x	0.874	0.940	0.965

ผลลัพธ์ในคลาสไม่สวมหมวกนิรภัย (No Helmet) ในตารางที่ 8 จะพบว่า ค่าความแม่นยำ (Precision) ของ YOLOv8l มีความแม่นยำสูงที่สุด อยู่ที่ 0.856, ค่าความถูกต้อง (Recall) ของ YOLOv8x มีความถูกต้องที่สูงที่สุด อยู่ที่ 0.660 และค่า mAP50 ของ YOLOv8l มีค่าสูงที่สุด อยู่ที่ 0.740 จากการวิเคราะห์ผลลัพธ์ในคลาสไม่สวมหมวกนิรภัย ในส่วนของค่าความถูกต้อง

(Recall) ของโมเดลทุกรุ่นนั้นให้ค่าผลลัพธ์ที่ยังไม่สูงมาก เนื่องมาจากปริมาณของข้อมูลของคลาสไม่สวมหมวกนิรภัย ที่ใช้ในการฝึกโมเดลนั้นมีปริมาณที่น้อยกว่าเมื่อเปรียบเทียบกับคลาสอื่นในภาพประกอบที่ 42

ตาราง 8 ผลลัพธ์คลาสไม่สวมหมวกนิรภัย (No Helmet) ของโมเดลแต่ละรุ่น

Model	Precision	Recall	mAP50
YOLOv8n	0.747	0.572	0.648
YOLOv8s	0.797	0.611	0.714
YOLOv8m	0.837	0.644	0.730
YOLOv8l	0.856	0.634	0.740
YOLOv8x	0.823	0.660	0.738



ภาพประกอบ 42 แสดงการเปรียบเทียบปริมาณข้อมูลทุกคลาสที่ใช้ในการฝึกโมเดล

ผลลัพธ์จากชุดข้อมูลที่ทำเทคนิคการเสริมข้อมูล Data Augmentation

ผู้วิจัยได้ทดลองเพิ่มเทคนิคการเสริมข้อมูล (Data Augmentation) กับชุดข้อมูลที่ได้เก็บรวบรวมมา โดยการเพิ่มแสงสว่าง (Brightness) ทำให้ชุดข้อมูลมีความสว่างเพิ่มขึ้นจากเดิม 20 เปอร์เซ็นต์ ทำและได้ชุดข้อมูลเพิ่มขึ้นเป็น 7,098 ภาพ หลังจากนั้นผู้วิจัยได้นำชุดข้อมูลที่ทำ

Data Augmentation ไปฝึกกับโมเดล YOLOv8 ทุกโมเดล จากตารางที่ 9 พบว่าผลลัพธ์ของทุกโมเดลให้ค่า Precision, Recall, mAP50 และค่า F1-Score ที่น้อยลงกว่าชุดข้อมูลที่ไม่ได้ทำ Data augmentation ซึ่งจะมีเหตุผลมาจาก การซูมและการปรับเปลี่ยนข้อมูลอาจทำให้ไม่สอดคล้องกับความเป็นจริง เช่น การเพิ่มแสงสว่างนั้นอาจทำให้วัตถุภายในภาพเบลอหรือไม่ชัดเจนไปจากเดิม ส่งผลต่อประสิทธิภาพของโมเดลในการตรวจจับวัตถุ

ตาราง 9 การประเมินผลลัพธ์โดยรวมของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำเทคนิคการเสริมข้อมูล (Data Augmentation)

Model	Training time (hours)	Precision	Recall	mAP50	F1-Score
YOLOv8n	1.026	0.794	0.670	0.726	0.727
YOLOv8s	1.082	0.828	0.703	0.766	0.760
YOLOv8m	1.452	0.817	0.739	0.798	0.776
YOLOv8l	1.883	0.828	0.726	0.792	0.774
YOLOv8x	2.481	0.816	0.760	0.806	0.787

ผลลัพธ์ในคลาสสวมหมวกนิรภัย (Helmet) ที่ทำเทคนิค Data Augmentation ในตารางที่ 10 จะพบว่า ค่า Precision, Recall และ mAP50 นั้นมีค่าลดลงเมื่อเทียบกับข้อมูลที่ไม่ได้ทำเทคนิค Data Augmentation ทั้งนี้อาจเกิดจากการที่เพิ่มแสงสว่าง (Brightness) ทำให้ชุดข้อมูลภาพที่มีวัตถุหมวกนิรภัยนั้นมีการเปลี่ยนแปลงลักษณะที่แตกต่างกับไปจากชุดข้อมูลเดิมจึงทำให้โมเดลนั้นทำการตรวจจับได้ยากขึ้น

ตาราง 10 ผลลัพธ์คลาสสวมหมวกนิรภัย (Helmet) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำเทคนิคการเสริมข้อมูล (Data Augmentation)

Model	Precision	Recall	mAP50
YOLOv8n	0.750	0.641	0.696
YOLOv8s	0.769	0.709	0.754
YOLOv8m	0.770	0.743	0.769
YOLOv8l	0.808	0.738	0.802
YOLOv8x	0.787	0.766	0.805

ผลลัพธ์ในคลาสรถจักรยานยนต์ (Motorcycle) ที่ทำเทคนิค Data Augmentation ในตารางที่ 11 จะพบว่า ค่า Precision ของโมเดลรุ่น YOLOv8s, YOLOv8m, YOLOv8l, และ YOLOv8x นั้นมีค่าที่สูงกว่าเมื่อเทียบกับชุดข้อมูลที่ไม่ได้ทำเทคนิค Data Augmentation ส่วนค่า Recall และ mAP50 นั้นมีค่าที่ลดลงเมื่อเทียบกับชุดข้อมูลที่ไม่ได้ทำเทคนิค Data Augmentation โดยในคลาสนี้จะให้ผลลัพธ์ที่ค่อนข้างสูงเมื่อเทียบกับคลาสอื่นๆ เนื่องจากโมเดล YOLOv8 นั้นได้มีการปรับ Weight จากชุดข้อมูล COCO ซึ่งภายในชุดข้อมูลนี้มีคลาสรถจักรยานยนต์ จึงเป็นสาเหตุที่โมเดลนั้นมีผลลัพธ์การตรวจจับที่ดีในคลาสนี้

ตาราง 11 ผลลัพธ์คลาสรถจักรยานยนต์ (Motorcycle) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำเทคนิคการเสริมข้อมูล (Data Augmentation)


Model	Precision	Recall	mAP50
YOLOv8n	0.884	0.909	0.934
YOLOv8s	0.909	0.905	0.937
YOLOv8m	0.906	0.913	0.940
YOLOv8l	0.913	0.897	0.940
YOLOv8x	0.905	0.920	0.942

ผลลัพธ์ในคลาสไม่สวมหมวกนิรภัย (No Helmet) ที่ทำเทคนิค Data Augmentation ในตารางที่ 12 จะพบว่า ค่า Precision ของโมเดล YOLOv8m, YOLOv8l, และ YOLOv8x นั้นลดลงอย่างเห็นได้ชัดเมื่อเปรียบเทียบกับชุดข้อมูลที่ไม่ได้ทำเทคนิค Data Augmentation ส่วนค่า Recall และ mAP50 นั้นก็มีผลลัพธ์ที่ลดลงด้วยเช่นกัน โดยเหตุผลที่คลาสนี้มีผลลัพธ์ที่น้อยเมื่อเทียบกับคลาสอื่นมาจากจำนวนของชุดข้อมูลในคลาสไม่สวมหมวกนิรภัยในชุดข้อมูลที่ให้โมเดลทำการฝึกนั้นมีปริมาณที่น้อยเมื่อเปรียบเทียบกับคลาสอื่นๆ รวมทั้งการทำเทคนิค Data Augmentation ที่เพิ่มความแสงสว่างอาจส่งผลให้เกิดการลดคุณภาพของข้อมูลทำให้การตรวจจับคลาสไม่สวมหมวกนิรภัยนั้นมีความแม่นยำน้อยลง


ตาราง 12 ผลลัพธ์คลาสไม่สวมหมวกนิรภัย (No Helmet) ของโมเดลแต่ละรุ่นที่ฝึกกับชุดข้อมูลที่ทำการเสริมข้อมูล (Data Augmentation)

Model	Precision	Recall	mAP50
YOLOv8n	0.747	0.459	0.548
YOLOv8s	0.807	0.496	0.607
YOLOv8m	0.776	0.562	0.657
YOLOv8l	0.763	0.543	0.633
YOLOv8x	0.757	0.595	0.671

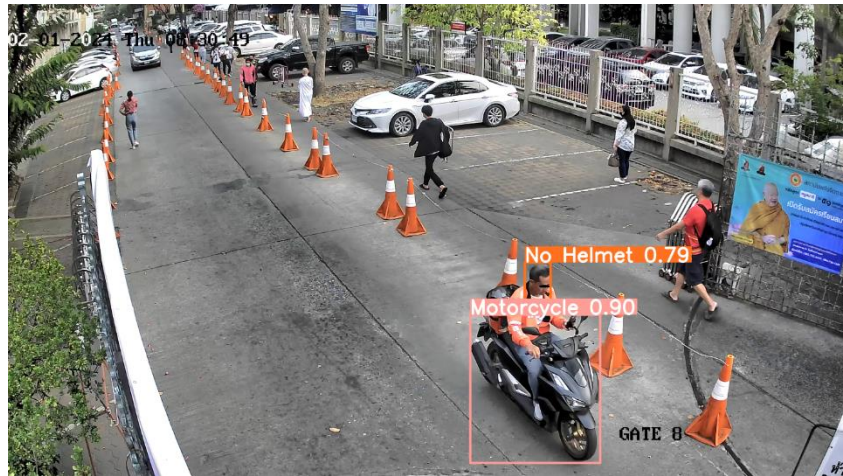
การประเมินผลลัพท์รูปภาพจากชุดข้อมูลทดสอบ




ภาพประกอบ 43 ผลลัพท์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 7



ภาพประกอบ 44 ผลลัพท์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 8




ภาพประกอบ 45 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8



ภาพประกอบ 46 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8



ภาพประกอบ 47 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7



ภาพประกอบ 48 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7



ภาพประกอบ 49 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 7




ภาพประกอบ 50 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้สวมหมวกนิรภัย บริเวณประตู 5



ภาพประกอบ 51 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1



ภาพประกอบ 52 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1



ภาพประกอบ 53 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 5



ภาพประกอบ 54 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์และผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1



ภาพประกอบ 55 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 1



ภาพประกอบ 56 ผลลัพธ์รูปภาพที่ระบบตรวจจับรถจักรยานยนต์ ผู้สวมหมวกนิรภัยและผู้ไม่สวมหมวกนิรภัย บริเวณประตู 8

บทที่ 5

สรุปผลการวิจัย

ในการพัฒนาระบบตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช โดยใช้อัลกอริทึม YOLOv8 เพื่อพัฒนาระบบตรวจจับการสวมหมวกนิรภัยทดแทนการสังเกตการณ์ด้วยตัวบุคคล โดยแบ่งหัวข้อการสรุปผลได้ดังต่อไปนี้

- 5.1 สรุปผลการวิจัย
- 5.2 ปัญหาและอุปสรรคในการดำเนินการวิจัย
- 5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากปัญหาการสัญจรด้วยรถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช ที่ผู้ขับขี่และผู้ซ้อนรถจักรยานยนต์ นั้นมีการสวมใส่และไม่สวมใส่หมวกนิรภัยขณะสัญจร ทำให้ในบางครั้งการไม่ใส่หมวกนิรภัยนั้นนำมาซึ่งอุบัติเหตุที่ร้ายแรงต่อร่างกายได้ งานวิจัยนี้จึงสร้างขึ้นมาเพื่อเป็นระบบตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช ทดแทนการตรวจจับการสวมหมวกนิรภัย โดยใช้ระบบสังเกตการณ์ด้วยบุคคล (Manual System) และเป็นเครื่องมือหนึ่งที่จะช่วยตอบสนองมาตรการให้ คณะแพทยศาสตร์ศิริราชพยาบาล เป็นเขตสวมหมวกนิรภัย พ.ศ.2563

ผู้วิจัยได้ทำการสร้างระบบตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช โดยใช้อัลกอริทึม YOLOv8 โดยเริ่มจากการขออนุมัติการใช้ข้อมูลจากคณะแพทยศาสตร์ศิริราชพยาบาล เมื่อได้รับการอนุมัติแล้ว ทำการดาวน์โหลดข้อมูลไฟล์วิดีโอจากกล้องวงจรทั้ง 4 ประตูกภายในพื้นที่โรงพยาบาลศิริราช ประกอบไปด้วย ประตู 1, ประตู 5, ประตู 7 และประตู 8 เมื่อได้ไฟล์วิดีโอจากกล้องวงจรมาแล้วทำการแปลงไฟล์วิดีโอให้เป็นไฟล์รูปภาพ หลังจากนั้นทำการคัดกรองรูปภาพทั้งหมดที่ได้ให้เหลือเพียงรูปภาพที่อยู่ในรูปามมีวัตถุที่สนใจสำหรับฝึกระบบตรวจจับ ได้แก่ รถจักรยานยนต์, สวมหมวกนิรภัย และไม่สวมหมวกนิรภัย หลังจากคัดกรองแล้วจึงได้ไฟล์รูปภาพทั้งหมด 2,400 ภาพ โดยแบ่งเป็นประตูละ 600 ภาพ เมื่อได้ไฟล์รูปภาพที่ผ่านการคัดกรองแล้วทำการสร้าง Bonding box ได้แก่ คลาส Motorcycle สำหรับภาพที่มีผู้ขับขี่รถจักรยานยนต์, คลาส Helmet สำหรับภาพที่มีการสวมใส่หมวกนิรภัยของทั้งผู้ขับขี่รถจักรยานยนต์และผู้ซ้อนและคลาส No Helmet สำหรับภาพที่ไม่มีการสวมใส่หมวกนิรภัยของทั้งผู้ขับขี่รถจักรยานยนต์และผู้ซ้อน หลังจากนั้นผู้วิจัยได้นำชุดข้อมูลไปทำเทคนิคการเสริมข้อมูล

(Data Augmentation) ด้วยการเพิ่มแสงสว่าง (Brightness) เพื่อนำมาเปรียบเทียบกับชุดข้อมูลที่ไม่ได้ทำเทคนิค Data Augmentation

ทำการแบ่งข้อมูลออกเป็นข้อมูลสำหรับการใช้ในการฝึกอัลกอริทึม YOLOv8 และทดสอบอัลกอริทึม YOLOv8 เมื่อได้ข้อมูลที่ทำกรแบ่งและพร้อมใช้งานแล้ว นำชุดข้อมูลทั้งแบบที่ทำเทคนิคการเสริมข้อมูล (Data Augmentation) และไม่ได้ทำมาแยกฝึกกับอัลกอริทึม YOLOv8 และประเมินประสิทธิภาพของระบบตรวจจับ โดยประเมินจาก Confusion Matrix, Precision, Recall, F1-Score, mAP50 และผลลัพธ์รูปภาพจากชุดข้อมูลทดสอบ

ผลจากการวิเคราะห์ประสิทธิภาพของระบบตรวจจับการสวมหมวกนิรภัยของผู้ขับขี่รถจักรยานยนต์ภายในพื้นที่โรงพยาบาลศิริราช พบว่า โมเดล YOLOv8l และ YOLOv8x มีประสิทธิภาพสูงที่สุดจากทุกโมเดลโดย YOLOv8l มีค่าเฉลี่ยความแม่นยำ (Precision) อยู่ที่ 0.868, ค่าเฉลี่ยความถูกต้อง (Recall) อยู่ที่ 0.790, ค่าเฉลี่ย mAP50 อยู่ที่ 0.859 และค่าเฉลี่ย F1-Score อยู่ที่ 0.827 ส่วน YOLOv8x มีค่าเฉลี่ยความแม่นยำ (Precision) อยู่ที่ 0.842, ค่าเฉลี่ยความถูกต้อง (Recall) อยู่ที่ 0.811, ค่าเฉลี่ย mAP50 อยู่ที่ 0.858 และค่าเฉลี่ย F1-Score อยู่ที่ 0.826 โดยทั้งสองโมเดลนั้นเป็นโมเดลที่ไม่ได้ทำเทคนิค Data Augmentation

5.2 ปัญหาและอุปสรรคในการดำเนินการวิจัย

5.2.1 กระบวนการแปลงข้อมูลไฟล์วิดีโอจากกล้องวงจรปิดทั้ง 4 บริเวณภายในโรงพยาบาลศิริราช ให้เป็นไฟล์รูปภาพจะได้จำนวนไฟล์รูปภาพในปริมาณที่มาก จึงทำให้ต้องเตรียมพื้นที่ว่างสำหรับการเตรียมข้อมูลไฟล์รูปภาพพอสมควร

5.2.2 กระบวนการคัดเลือกไฟล์รูปภาพที่จะใช้ในการฝึกและทดสอบให้กับระบบและกระบวนการสร้าง Bonding box ให้กับชุดข้อมูล ใช้ระยะเวลาในจัดทำนาน

5.2.3 ไฟล์รูปภาพที่ใช้ฝึกและทดสอบมีคลาสไม่สวมหมวกนิรภัย (No Helmet) ในปริมาณที่ค่อนข้างน้อยเมื่อเทียบกับคลาสอื่นๆ ทำให้ส่งผลต่อการวัดประสิทธิภาพของระบบในการตรวจจับคลาสไม่สวมหมวกนิรภัย

5.2.4 มุมกล้องบริเวณประตู 5 เป็นมุมกล้องแบบภาพกว้าง ส่งผลให้ไม่สามารถตรวจจับวัตถุได้อย่างถูกต้องและแม่นยำได้ในบางกรณี

5.2.5 ยังพบความผิดพลาดของระบบที่ไม่สามารถตรวจจับการสวมใส่หรือไม่สวมใส่หมวกนิรภัยของเด็กที่นั่งอยู่ด้านหน้าของผู้ขับขี่รถจักรยานยนต์

5.3 ข้อเสนอแนะ

5.3.1 ควรเพิ่มชุดข้อมูลที่ใช้สำหรับการฝึกให้มีความหลากหลายมากยิ่งขึ้น เช่น ไฟล์รูปภาพที่มีมุมมองที่เห็นบริเวณศีรษะของผู้ขับขี่และผู้ซ้อนที่ชัดเจนมากยิ่งขึ้น, ไฟล์รูปภาพที่มีแสงและเงาที่แตกต่างกัน, ไฟล์รูปภาพที่เห็นศีรษะของเด็กที่นั่งอยู่ด้านหน้าผู้ขับขี่ เป็นต้น การเพิ่มชุดข้อมูลที่ใช้สำหรับการฝึกเหล่านี้อาจเพิ่มประสิทธิภาพในการตรวจจับได้ดีมากยิ่งขึ้น

5.3.2 ทดลองใช้ชุดข้อมูลที่ใช้สำหรับการฝึกเป็นช่วงเวลากลางคืนทั้งหมด เพื่อให้ อัลกอริทึมได้เรียนรู้ชุดข้อมูลที่มีสภาพแสงและเงาที่น้อยกว่าช่วงเวลากลางวัน และนำมาเปรียบเทียบประสิทธิภาพของการใช้ชุดข้อมูลสำหรับการฝึกที่มีช่วงเวลาที่แตกต่างกัน

5.3.3 สามารถเพิ่มความแม่นยำและความถูกต้องของระบบมากยิ่งขึ้นโดยการเพิ่มชุดข้อมูลสำหรับการฝึกในคลาสของการไม่สวมหมวกนิรภัย เพราะข้อมูลไฟล์รูปภาพที่ผู้วิจัยได้มานั้น ส่วนใหญ่เป็นคลาสของการสวมหมวกนิรภัย

5.3.4 ต่อยอดพัฒนาระบบในการตรวจจับวัตถุอื่นๆ เช่น ระบบตรวจจับเป็นป้ายทะเบียน, ระบบตรวจจับผู้ซ้อนรถจักรยานยนต์เกิน 3 คน เพื่อนำไปสู่การจับกุมสำหรับผู้ฝ่าฝืนกฎจราจร ภายในพื้นที่โรงพยาบาลศิริราช

บรรณานุกรม

Faizan, M. (2022). Roboflow. Retrieved from <https://medium.com/red-buffer/roboflow-d4e8c4b52515>

GrassrootEngineer. (2563). YOLO คืออะไรในงาน object detection. Retrieved from <https://grassrootengineer.medium.com/yolo-คืออะไร-ในงาน-object-detection-83b3a7461114>

Imane, C. (2564). YOLO v5 model architecture. Retrieved from <https://iq.opengenius.org/yolov5>

Kharchenko, V., & Chyrka, I. (2018). *Detection of airplanes on the ground using YOLO neural network*. Paper presented at the 2018 IEEE 17th international conference on mathematical methods in electromagnetic theory (MMET).

NEXTSOFTWAREHOUSE. (2557). ความรู้เบื้องต้นเกี่ยวกับการประมวลผลภาพดิจิทัล. Retrieved from <https://goo.gl/w8oKCy>

Object detection. (2023). Retrieved from https://en.wikipedia.org/wiki/Object_detection

Roboflow. (2020). What is YOLOv8? Retrieved from <https://yolov8.com/>

Simard, P. Y., Steinkraus, D., & Platt, J. C. (2003). *Best practices for convolutional neural networks applied to visual document analysis*. Paper presented at the Icdar.

การเรียนรู้เชิงลึก. (2565). Retrieved from <https://th.wikipedia.org/wiki/การเรียนรู้เชิงลึก>

การเรียนรู้แบบมีผู้สอน. (2564). Retrieved from <https://th.wikipedia.org/wiki/การเรียนรู้แบบมีผู้สอน>

การเรียนรู้ของเครื่อง. (2566). Retrieved from <https://th.wikipedia.org/wiki/การเรียนรู้ของเครื่อง>

การแบ่งประเภทข้อมูล. (2563). Retrieved from <https://th.wikipedia.org/wiki/การแบ่งประเภทข้อมูล>

การประมวลผลภาพดิจิทัล. (2561). Retrieved from <https://th.wikipedia.org/wiki/การประมวลผลภาพดิจิทัล>

กฤษณา หนองจางค์, ค. พ. (2563). การศึกษาพฤติกรรมการสวมหมวกนิรภัยของนิสิต มหาวิทยาลัยบูรพา. 4-5.

คอมพิวเตอร์วิทัศน์. (2564). Retrieved from <https://th.wikipedia.org/wiki/คอมพิวเตอร์วิทัศน์>

ปัญญาประดิษฐ์. (2566). Retrieved from <https://th.wikipedia.org/wiki/ปัญญาประดิษฐ์>



ประวัติผู้เขียน

