

การพัฒนารถกอล์ฟไฟฟ้าอัตโนมัติสำหรับขนส่งผู้โดยสารระหว่างอาคาร



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมเครื่องกลและระบบกระบวนการ

มหาวิทยาลัยเทคโนโลยีสุรนารี

ปีการศึกษา 2565

DEVELOPMENT OF AUTONOMOUS ELECTRIC GOLF CART SYSTEM
FOR PASSENGER TRANSPORTATION BETWEEN BUILDINGS



A Thesis Submitted in Partial Fulfillment of the Requirement for the Degree of
Master of Engineering in Mechanical and Process System Engineering

Suranaree University of Technology

Academic Year 2022

การพัฒนารถกอล์ฟไฟฟ้าอัตโนมัติสำหรับขนส่งผู้โดยสารระหว่างอาคาร


มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักศึกษานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาโทบริหารบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์




(ผศ. ดร.ไชยธร ธรรมแท้)

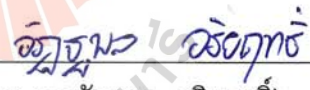
ประธานกรรมการ




(ผศ. ดร.สุรเดช ตัญตริยรัตน์)
กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รศ. ดร.จิระพล ศรีเสริฐผล)
กรรมการ




(ผศ. ดร.อานุรณ อริยฤทธิ์)
กรรมการ



(ผศ. ดร.นักษิธ นุ่มวงษ์)
กรรมการ



(รศ. ดร.ฉัตรชัย โชติชูช่างกูร)
รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร.พรศิริ จงกล)
คณบดีสำนักวิชาวิศวกรรมศาสตร์

วงศธร อ่างเข้ม : การพัฒนารถกอล์ฟไฟฟ้าอัตโนมัติสำหรับขนส่งผู้โดยสารระหว่างอาคาร
(DEVELOPMENT OF AUTONOMOUS ELECTRIC GOLF CART SYSTEM FOR
PASSENGER TRANSPORTATION BETWEEN BUILDINGS)

อาจารย์ที่ปรึกษา: ผู้ช่วยศาสตราจารย์ ดร.สุรเดช ตัญจรัยรัตน์ , 90 หน้า.

คำสำคัญ : รถกอล์ฟอัตโนมัติ/ยานยนต์ไร้คนขับ/ปัญญาประดิษฐ์

การใช้รถกอล์ฟไฟฟ้าสำหรับงานทางด้านการขนส่งผู้โดยสารระหว่างอาคาร ที่ใช้งานในพื้นที่ กึ่งเปิดกึ่งปิดเช่น สนามบินห้างสรรพสินค้า หรือโรงพยาบาล พบว่าปัญหาที่เกิดขึ้นจากผู้ขับขี่หรือคน ควบคุมรถกอล์ฟที่เป็นมนุษย์ มักเป็นสาเหตุให้เกิดอุบัติเหตุ และส่งผลให้เกิดความเสียหาย เพื่อแก้ไข ปัญหาดังกล่าว ผู้วิจัยจึงสนใจที่จะพัฒนารถกอล์ฟไฟฟ้าอัตโนมัติที่ควบคุมด้วยปัญญาประดิษฐ์ โดยใช้ การสร้างแผนที่และการระบุตำแหน่งด้วยข้อมูลจากเซนเซอร์วัดระยะด้วยแสง สร้างเส้นทางการ เคลื่อนที่ด้วยแผนที่ความละเอียดสูง ใช้ปัญญาประดิษฐ์ตรวจจับวัตถุและระบุตำแหน่งใน 3 มิติ และ สร้างเส้นทางการเคลื่อนที่สำหรับการหลบหลีกสิ่งกีดขวาง เพื่อนำไปใช้ในการตัดสินใจและควบคุมรถ กอล์ฟ โดยควบคุมความเร็วและมุมเลี้ยวแบบแปรตามความโค้งของเส้นทางการเคลื่อนที่ ให้เคลื่อนที่ ไปยังจุดหมายของการเดินทาง และประเมินประสิทธิภาพ และความคลาดเคลื่อนของการทำงานใน ส่วนต่างๆ ของระบบอัตโนมัติรวมถึงการตรวจจับวัตถุด้วยปัญญาประดิษฐ์ ซึ่งสามารถควบคุมได้ด้วย การส่งสัญญาณไฟฟ้าไปควบคุมระบบขับเคลื่อนด้วยไฟฟ้า ทั้งระบบเบรกไฟฟ้า ระบบคันเร่งไฟฟ้า และระบบพวงมาลัยไฟฟ้า การขับเคลื่อนอัตโนมัติจะทดสอบบนถนนรอบอาคารเครื่องมือ 5 ที่มีวัตถุ กีดขวางทางจราจรอยู่บนถนน โดยผลการทดสอบระบบตรวจจับวัตถุสามารถตรวจจับและระบุ ตำแหน่งของวัตถุได้ในระยะไม่เกิน 9 เมตร ที่ความแม่นยำเฉลี่ย 79.68% และรถกอล์ฟสามารถ เคลื่อนที่อัตโนมัติได้ตามเส้นทางการเคลื่อนที่ และสามารถหยุดรถในระยะเฉลี่ย 5.63 เมตรจากวัตถุ หรือหลบหลีกวัตถุได้เมื่อมีพื้นที่ในการเคลื่อนที่เพียงพอ

สาขาวิชาวิศวกรรมเครื่องกล
ปีการศึกษา 2565

ลายมือชื่อนักศึกษา วงศธร อ่างเข้ม
ลายมือชื่ออาจารย์ที่ปรึกษา สุรเดช ตัญจรัยรัตน์

WONGSATHON ANGKHEM : DEVELOPMENT OF AUTONOMOUS ELECTRIC
GOLF CART SYSTEM FOR PASSENGER TRANSPORTATION BETWEEN
BUILDINGS. THESIS ADVISOR : ASST. PROF. SURADET TANTRAIRATN, D.Eng.,
90 PP.

Keyword: Autonomous Golf cart/Self-drive Vehicle/Artificial intelligence

The Electric golf cart has been widely used to transport passengers between buildings that operate in semi-open areas such as shopping malls, airports, and hospitals. Most accidents with golf cart are by the driver, this damage the golf cart and passengers. The purpose of this research was to develop an Autonomous electric golf cart controlled by artificial intelligence with mapping and localization by Lidar, path generating from a High-definition map, Object detection and tracking in 3D, and path planning for collision avoidance. These systems are for the decision-making of electric golf cart controlling to drive to the goal of the mission. Velocity and Steering angle varies with the curvature of the path. The controller of the electric golf cart is using an electric signal for the Drive-by-wire system. The autonomous system is evaluated with performance and error. The autonomous golf cart is test on the road around the equipment building F5 with object on the road. The result of the object detection can detect and localize an object in a distance not exceeding 9 m, and the mean-average precision is 79.68%. The autonomous golf cart can drive by self-drive following the path from the high-definition map and stop from the object 5.63 m or drive to avoid the object.

School of Mechanical Engineering
Academic year 2022

Student's Signature Wongsathon
Advisor's Signature สุรเดช ตันตราิรัตน์

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จด้วยดี ข้าพเจ้าขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.สุรเดช ตัญจรัยรัตน์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้โอกาสทางการศึกษาระดับบัณฑิตศึกษา ให้แนวทาง ให้คำแนะนำ ให้คำปรึกษา และให้วิธีการแก้ปัญหาด้วยความเมตตากรุณาอย่างดียิ่ง ตลอดจนความช่วยเหลือในการตรวจทานแก้ไขวิทยานิพนธ์นี้จนเสร็จสมบูรณ์

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์อันประกอบไปด้วย ผู้ช่วยศาสตราจารย์ ดร.ชโลธร ธรรมแท้ ประธานกรรมการสอบ รองศาสตราจารย์ ดร.จิระพล ศรีเสริฐผล ผู้ช่วยศาสตราจารย์ ดร.อัญชลี อริยฤทธิ์ และ ผู้ช่วยศาสตราจารย์ ดร.นัทสิทธิ์ นุ่มวงษ์ ที่ตรวจทาน และให้คำแนะนำในการแก้ไขเพื่อให้วิทยานิพนธ์ฉบับนี้สมบูรณ์

ขอขอบพระคุณคณาจารย์และบุคลากรในสาขาวิชาวิศวกรรมเครื่องกล ที่คอยให้ความช่วยเหลือ และให้คำแนะนำในการจัดเตรียมเอกสารสำหรับวิทยานิพนธ์ฉบับนี้เป็นอย่างดี

สุดท้ายนี้ ขอกราบขอบพระคุณ บิดา มารดา ที่ให้การเลี้ยงดู อบรม ให้คำแนะนำ และส่งเสริมการศึกษาเป็นอย่างดีมาตลอด และเป็นกำลังใจให้ข้าพเจ้าเสมอมาจนสำเร็จการศึกษา

วงศธร อ่างเข้ม

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
บทที่	
1 บทนำ.....	1
1.1 ความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการศึกษา.....	2
1.3 ขอบเขตของการศึกษา.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
2 ปรัชญาบรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	3
2.1 รถกอล์ฟไฟฟ้าและระบบขับเคลื่อนด้วยไฟฟ้า.....	3
2.1.1 ระบบบังคับเลี้ยวไฟฟ้า.....	4
2.1.2 ระบบคันเร่งและเบรกไฟฟ้า.....	4
2.2 ยานยนต์อัตโนมัติ.....	5
2.2.1 เซนเซอร์ในยานยนต์อัตโนมัติ.....	6
2.3 การรับรู้ของยานยนต์อัตโนมัติ.....	9
2.3.1 แผนที่ความละเอียดสูง (High-definition map).....	10
2.3.2 การสร้างแผนที่ Point cloud.....	10
2.3.3 การระบุตำแหน่งของยานยนต์จากแผนที่ความละเอียดสูง.....	13

สารบัญ (ต่อ)

	หน้า
2.3.4 การตรวจจับวัตถุจากภาพ.....	14
2.3.5 การแบ่งกลุ่มข้อมูล Point cloud.....	21
2.4 การตัดสินใจของยานยนต์อัตโนมัติ.....	23
2.4.1 การสร้างเส้นทางหลบหลีกสิ่งกีดขวาง.....	24
2.4.2 การควบคุมยานยนต์อัตโนมัติตามเส้นทาง.....	25
3 วิธีดำเนินการวิจัย.....	29
3.1 การเตรียมการ.....	29
3.1.1 การศึกษาค้นคว้าและรวบรวมงานวิจัยที่เกี่ยวข้อง.....	29
3.1.2 การเตรียมรถกอล์ฟไฟฟ้า.....	30
3.1.3 ทดสอบเซนเซอร์.....	31
3.1.4 การสร้างแผนที่ความละเอียดสูง (High-definition map) และการทดสอบ... ..	32
3.2 การพัฒนาระบบขับเคลื่อนอัตโนมัติ.....	33
3.2.1 การระบุตำแหน่งของรถกอล์ฟ (Localization).....	33
3.2.2 การตรวจจับวัตถุจากภาพ (2D Object Detection).....	35
3.2.3 การแบ่งกลุ่มข้อมูล Point cloud.....	37
3.2.4 การตรวจจับวัตถุ 3 มิติ (3D Object detection) และการทดสอบ.....	38
3.2.5 การสร้าง Grid map.....	38
3.2.6 การสร้างเส้นทางหลบหลีกสิ่งกีดขวาง (Path planning).....	39
3.2.7 การควบคุมรถตามเส้นทาง (Path tracking control) และการทดสอบ.....	39
3.2.8 การควบคุมความเร็วในทางโค้ง.....	40
3.3 การทดสอบระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟไฟฟ้า.....	41
4 ผลการวิจัยและอภิปรายผล.....	43

สารบัญ (ต่อ)

	หน้า
4.1 ผลการสร้างแผนที่ความละเอียดสูง	43
4.2 ผลการทดสอบระบบระบุตำแหน่งของรถกอล์ฟอัตโนมัติ	46
4.3 ผลการดำเนินการตรวจจับวัตถุจากภาพ 2 มิติ	49
4.4 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ	54
4.5 ผลการทดสอบความเร็วในการเข้าโค้ง	56
4.6 ผลการทดสอบระบบขับเคลื่อนอัตโนมัติ	69
5 สรุปและข้อเสนอแนะ	77
5.1 สรุปผลการวิจัย	77
5.2 ข้อเสนอแนะ	78
รายการอ้างอิง	Error! Bookmark not defined.
ภาคผนวก ก	83
ประวัติผู้เขียน	90

สารบัญตาราง

ตารางที่	หน้า
4.1 ผลการวัดความผิดพลาดของแผนที่ POINT CLOUD MAP.....	44
4.2 แสดงพิกัดของตำแหน่งที่วัดจากแผนที่เปรียบเทียบกับตำแหน่งจากทดสอบ	46
4.3 แสดงความคลาดเคลื่อนของพิกัดที่ทดสอบในแต่ละตำแหน่ง	47
4.4 แสดงค่า MAP ของโมเดลตรวจจับวัตถุจากภาพ	53
4.5 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ.....	55
4.6 แสดงความโค้งและรัศมีความโค้งของเส้นทางการเคลื่อนที่ในพื้นที่ทดสอบ	57

สารบัญรูป

รูปที่	หน้า
2.1 รถกอล์ฟไฟฟ้า CLUB CAR PRECEDENT ขนาด 4 ที่นั่ง.....	3
2.2 (ซ้าย) เบรกและคันเร่งไฟฟ้า (ขวา) พวงมาลัยไฟฟ้า.....	4
2.3 การแบ่งระดับยานยนต์อัตโนมัติ.....	6
2.4 เซนเซอร์ในยานยนต์อัตโนมัติ.....	7
2.5 ตัวอย่างข้อมูล POINT CLOUD ของยานยนต์อัตโนมัติ.....	8
2.6 แผนที่ความละเอียดสูงในรูปแบบของ LANELET2.....	10
2.7 แผนที่ POINT CLOUD และการระบุตำแหน่งด้วย NDT เปรียบเทียบกับ GPS.....	13
2.8 การมองเห็นของคอมพิวเตอร์ด้วยรูปแบบสี RGB.....	14
2.9 โครงสร้างของโครงข่ายประสาทเทียม.....	15
2.10 โครงสร้างการเรียนรู้ของ CNN.....	16
2.11 กระบวนการของชั้น CONVOLUTION.....	16
2.12 กระบวนการ MAX POOLING และ AVERAGE POOLING.....	17
2.13 กระบวนการ FLATTENING.....	17
2.14 กระบวนการ FULLY CONNECTION.....	18
2.15 การตรวจจับวัตถุด้วย YOLOV3.....	19
2.16 โครงสร้างโมเดล YOLOV3 (AYOOSH KATHURIA, 2018).....	20
2.17 วิธีการคำนวณ IOU (ADRIAN ROSEBROCK, 2016).....	21
2.18 (ซ้าย) POINT CLOUD ขาเข้า (ขวา) POINT CLOUD ที่ได้จากการแบ่งกลุ่มด้วยวิธี EUCLIDEAN CLUSTERING.....	22

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.19 ตัวอย่างกระบวนการ K-D TREE แบบ 2 มิติ	23
2.20 ตัวอย่างการค้นหาเส้นทางการเคลื่อนที่ด้วย A-STAR	25
2.21 การควบคุมยานยนต์ตามเส้นทางด้วย PURE PURSUIT CONTROL	26
2.22 KINEMATIC MODEL ของ CAR-LIKE WHEELED VEHICLE	27
2.23 LOOK-AHEAD DISTANCE และการเปรียบเทียบเส้นทางการเคลื่อนที่ที่ยานยนต์เคลื่อนที่โดย ควบคุมด้วย PURE-PURSUIT กับ WAYPOINT	28
2.24 ผลการเคลื่อนที่ของการปรับระยะ LOOK-AHEAD DISTANCE ที่น้อยและเยอะเกินไป	28
3.1 การติดตั้งหน่วยประมวลผลกลางด้านหลังรถกอล์ฟไฟฟ้า	30
3.2 การติดตั้งเซนเซอร์ด้านหน้ารถกอล์ฟไฟฟ้า	31
3.3 การสอบเทียบกล้องด้วยตารางหมากรุก	31
3.4 POINT CLOUD MAP ภายในอาคารเครื่องมือ 5	32
3.5 POINT CLOUD MAP ด้านหน้าอาคารเครื่องมือ 5	32
3.6 การสร้างเส้นทางการเคลื่อนที่ด้วยเครื่องมือ TIER4 TOOLS	33
3.7 การทดสอบการระบุตำแหน่งด้วย NDT ภายในอาคารเครื่องมือ 5	34
3.8 ตำแหน่งของการวัดเทียบเพื่อทดสอบความแม่นยำของระบบระบุตำแหน่งของรถกอล์ฟ อัตโนมัติ	34
3.9 แสดงขั้นตอนการวัดตำแหน่งเพื่อติดเทปจุดอ้างอิง	35
3.10 ขั้นตอนการดำเนินการของการตรวจจับวัตถุด้วยภาพ	36
3.11 ตัวอย่างการตรวจจับวัตถุจากภาพถ่ายด้วยกล้องหน้ารถกอล์ฟ	36

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.12	แผนผังการทำงานของรถกอล์ฟไฟฟ้าอัตโนมัติระหว่างอาคาร37
3.13	การทดสอบการแบ่งกลุ่ม POINT CLOUD ด้านหน้าของรถกอล์ฟ37
3.14	การทดสอบการตรวจจับและระบุตำแหน่งของวัตถุใน 3 มิติจากรถกอล์ฟ.....38
3.15	การทดสอบการควบคุมรถกอล์ฟด้วย PURE PURSUIT CONTROL39
3.16	แสดงแรงที่เกิดขึ้นในแต่ละแกนระหว่างการเคลื่อนที่ของรถยนต์40
3.17	เซนเซอร์วัดความเฉื่อยและจุดติดตั้งบนรถกอล์ฟไฟฟ้า41
3.18	แผนที่สำหรับทดสอบระบบหลบหลีกสิ่งกีดขวาง.....42
4.1	แสดงจุดวัดเทียบค่าความคลาดเคลื่อนบนแผนที่ POINT CLOUD 8 จุด.....43
4.2	แผนที่ HIGH-DEFINITION MAP ของพื้นที่ทดสอบจากมุมมองด้านบน.....45
4.3	แผนที่ HIGH-DEFINITION MAP ของพื้นที่ทดสอบจากมุมมองฝั่งอาคารเครื่องมือ 545
4.4	แผนที่ HIGH DEFINITION MAP ของพื้นที่ทดสอบจากมุมมองฝั่งอาคารเครื่องมือ 445
4.5	แสดงความคลาดเคลื่อนในแนวแกน X ของการทดสอบทั้งหมดในแต่ละตำแหน่งที่ทดสอบ ..48
4.6	แสดงความคลาดเคลื่อนในแนวแกน Y ของการทดสอบทั้งหมดในแต่ละตำแหน่งที่ทดสอบ...49
4.7	ตัวอย่างการล้อมกรอบวัตถุ(1).....50
4.8	ตัวอย่างการล้อมกรอบวัตถุ(2).....50
4.9	ตัวอย่างการล้อมกรอบวัตถุ(3).....51
4.10	ตัวอย่างการล้อมกรอบวัตถุ(4)51
4.11	แสดงค่าการสูญเสียในแต่ละรอบของขั้นตอนการเรียนรู้ของโมเดล52
4.12	ผลการตรวจจับวัตถุจากภาพ(1).....53

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.13 ผลการตรวจจับวัตถุจากภาพ(2).....	54
4.14 ผลการตรวจจับวัตถุจากภาพ(3).....	54
4.15 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ	56
4.16 แสดงความโค้งของทางเลี้ยวในเส้นทางการเคลื่อนที่	56
4.17 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง	58
4.18 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LONGITUDINAL กับ เวลา ที่ความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง	59
4.19 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟ ที่เคลื่อนที่ด้วยความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง.....	59
4.20 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 6 กิโลเมตรต่อชั่วโมง.....	60
4.21 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟ ที่เคลื่อนที่ด้วยความเร็วคงที่ 6 กิโลเมตรต่อชั่วโมง.....	61
4.22 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 7 กิโลเมตรต่อชั่วโมง.....	62
4.23 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟ ที่เคลื่อนที่ด้วยความเร็วคงที่ 7 กิโลเมตรต่อชั่วโมง.....	62
4.24 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 8 กิโลเมตรต่อชั่วโมง.....	63

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.25	แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 8 กิโลเมตรต่อชั่วโมง.....64
4.26	แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 9 กิโลเมตรต่อชั่วโมง.....65
4.27	แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 9 กิโลเมตรต่อชั่วโมง.....65
4.28	แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน LATERAL กับ เวลา ที่ความเร็วคงที่ 10 กิโลเมตรต่อชั่วโมง.....66
4.29	แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 10 กิโลเมตรต่อชั่วโมง67
4.30	แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่แต่ละความเร็วที่ตำแหน่งโค้งหมายเลข 168
4.31	แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่แต่ละความเร็วที่ตำแหน่งโค้งหมายเลข 2 และ 3.....68
4.32	ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 170
4.33	ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 270
4.34	ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 171
4.35	ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 1.....72
4.36	ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 2.....72
4.37	ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 3.....73

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.38	การทดสอบการขับเคลื่อนหลบหลีกสิ่งกีดขวางของรถกอล์ฟอัตโนมัติ..... 74
4.39	ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 1 74
4.40	ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 2 75
4.41	ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 3 76



บทที่ 1

บทนำ

1.1 ความสำคัญของปัญหา

ยานยนต์สำหรับขนส่งผู้โดยสารระหว่างอาคารในประเทศไทย ถูกนำมาใช้อย่างแพร่หลายทั้งในหน่วยงานของภาครัฐและภาคเอกชน เพื่อช่วยอำนวยความสะดวกกับประชาชนที่เข้าไปใช้บริการในสถานที่ต่างๆ ลดความเหนื่อยล้าที่เกิดจากการเดินในสภาพอากาศของประเทศไทยที่มีอุณหภูมิระหว่างวันที่ค่อนข้างสูง และยังช่วยลดภาระที่เกิดจากการแบกสัมภาระ ตัวอย่างเช่น การขนส่งผู้โดยสารระหว่างอาคารกับที่จอดรถในห้างสรรพสินค้า การขนส่งผู้โดยสารระหว่างอาคารผู้โดยสารกับเครื่องบินในสนามบิน และการขนส่งผู้โดยสารระหว่างอาคารในโรงพยาบาล ซึ่งยานยนต์ขนส่งผู้โดยสารระหว่างอาคารโดยส่วนมากจะใช้เป็นรถกอล์ฟไฟฟ้า เนื่องจากขนาดของรถกอล์ฟที่เล็กกว่ารถยนต์ส่วนบุคคล จึงทำให้รถกอล์ฟนั้นสามารถนำไปใช้งานในพื้นที่ที่มีขนาดที่จำกัดได้อย่างมีประสิทธิภาพ และการขับเคลื่อนด้วยมอเตอร์ไฟฟ้าจะไม่ปล่อยมลพิษที่เกิดจากการเผาไหม้เหมือนกับเครื่องยนต์สันดาป

การจัดการระบบเดินรถของยานยนต์ขนส่งผู้โดยสารระหว่างอาคารเป็นสิ่งสำคัญที่จะทำให้สามารถตอบสนองความต้องการของผู้ใช้งานได้อย่างมีประสิทธิภาพ ทั้งในเรื่องของระยะเวลาและความปลอดภัย จากการศึกษาจึงทำให้พบว่าพนักงานขับรถเป็นปัจจัยหลักที่จะทำให้เกิดความผิดพลาดในระบบเดินรถ รวมถึงการเกิดอุบัติเหตุ ซึ่งมีสาเหตุจากความเมื่อยล้าจากการขับขีตลอดระยะเวลาการทำงาน อีกสาเหตุคือความสามารถในการควบคุมรถให้อยู่ในเส้นทางและใช้ความเร็วให้เหมาะสมกับแต่ละช่วงของเส้นทาง และความสะดวกสบายของผู้โดยสารที่เกิดจากการขับขีของพนักงานขับรถ นอกจากนี้สำหรับระบบเดินรถที่ต้องมีการทำงานทั้งกลางวันและกลางคืน จะต้องเพิ่มค่าใช้จ่ายในการจ้างพนักงานขับรถสองเท่า

เพื่อให้ระบบเดินรถโดยสารระหว่างอาคาร มีประสิทธิภาพในการรับส่งผู้โดยสาร ซึ่งจะทำให้ผู้โดยสารสามารถวางแผนการเดินทางระหว่างอาคารได้ ผู้วิจัยจึงมีแนวคิดในการพัฒนารถกอล์ฟไฟฟ้าให้วิ่งอัตโนมัติ เพื่อใช้แทนรถกอล์ฟที่มีพนักงานขับรถ ซึ่งพัฒนาจากรถกอล์ฟไฟฟ้าที่มีระบบขับเคลื่อนไฟฟ้า ระบบเลี้ยวไฟฟ้า และระบบเบรกไฟฟ้า (ปณิธิ เพ็ชรนอก, 2562) โดยควบคุมการทำงานด้วยปัญญาประดิษฐ์ ใช้ข้อมูลจากแผนที่และเซนเซอร์วัดระยะด้วยแสงสำหรับการระบุตำแหน่ง

ของรถกอล์ฟ ใช้ภาพจากกล้องรอบตัวรถตรวจจับมนุษย์และวัตถุด้านหน้ารถแล้วเคลื่อนที่หลบหลีกหรือหยุดรถเพื่อป้องกันการชน โดยจะใช้เส้นทางระหว่างอาคารเครื่องมือภายในมหาวิทยาลัยเป็นที่ทดสอบการใช้งานจริง

1.2 วัตถุประสงค์ของการศึกษา

1. เพื่อออกแบบและพัฒนาระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟไฟฟ้า
2. เพื่อพัฒนาระบบระบุตำแหน่ง และการทำแผนที่ของรถกอล์ฟไฟฟ้าอัตโนมัติ ในสภาพแวดล้อมภายนอกอาคาร
3. เพื่อปรับปรุงและใช้งานปัญญาประดิษฐ์ ให้รถกอล์ฟไฟฟ้าอัตโนมัติสามารถตรวจจับวัตถุแบบ 3 มิติ

1.3 ขอบเขตของการศึกษา

1. รถกอล์ฟไฟฟ้า Club car Precedent ขนาด 4 ที่นั่ง มีระบบพวงมาลัยไฟฟ้า ระบบเบรกไฟฟ้า และคันเร่งไฟฟ้า
2. ใช้เซนเซอร์วัดระยะด้วยแสงและกล้องเป็นหน่วยรับรู้ของรถกอล์ฟไฟฟ้าอัตโนมัติ
3. ความเร็วในการทำงานของรถกอล์ฟไฟฟ้าอัตโนมัติไม่เกิน 15 กิโลเมตรต่อชั่วโมง
4. รถกอล์ฟสามารถเลือกความเร็วที่เหมาะสมในแต่ละสถานะการเคลื่อนที่ อาทิ การเข้าโค้ง การวิ่งทางตรง หรือการขับเคลื่อนหลบหลีกสิ่งกีดขวาง
5. พื้นที่ทดสอบคือถนนด้านหน้าอาคารเครื่องมือ 5 มหาวิทยาลัยเทคโนโลยีสุรนารี และระยะในการทดสอบไม่เกิน 500 เมตร

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. รถกอล์ฟไฟฟ้าอัตโนมัติสามารถขับเคลื่อนได้ด้วยตัวเอง และสามารถหยุดหรือหลบหลีกได้เมื่อเจอสิ่งกีดขวางทางจราจร
2. รถกอล์ฟไฟฟ้าสามารถขับเคลื่อนอัตโนมัติผ่านพื้นที่นอกอาคารได้
3. ระบบอัตโนมัติของรถกอล์ฟไฟฟ้าสามารถตรวจจับวัตถุและระบุตำแหน่งใน 3 มิติได้

บทที่ 2

ปรีทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้เป็นการศึกษาและพัฒนาารถกอล์ฟไฟฟ้าอัตโนมัติ สำหรับการขนส่งผู้โดยสาร ในพื้นที่ภายนอกอาคาร โดยใช้กล้องและ Lidar เป็นเซนเซอร์หลักในการประมวลผลของระบบอัตโนมัติ ผู้วิจัยได้ทำการศึกษาค้นคว้าวรรณกรรมและงานวิจัยต่างๆ ที่เกี่ยวข้องเพื่อใช้ในการวิจัยและพัฒนา โดยอธิบายในหัวข้อต่อไปนี้

2.1 รถกอล์ฟไฟฟ้าและระบบขับเคลื่อนด้วยไฟฟ้า

รถกอล์ฟไฟฟ้า (Electric Golf Cart) คือรถสำหรับใช้ขนของหรือสัมภาระต่างๆ รวมถึงผู้โดยสารในสนามกอล์ฟ และยังมีการใช้ในวัตถุประสงค์อื่นๆอย่างกว้างขวาง ตัวอย่างดังรูปที่ 2.1 โดยรถกอล์ฟไฟฟ้าจะสามารถจุผู้โดยสารได้ตั้งแต่ 2-8 คน ส่วนการขับเคลื่อนของรถกอล์ฟไฟฟ้าจะใช้เป็นมอเตอร์ไฟฟ้าขนาดตั้งแต่ 36 – 48 Vdc ขึ้นอยู่กับการออกแบบระบบและแรงดันไฟฟ้าของแบตเตอรี่ โดยมอเตอร์จะมีทั้งชนิด AC และ DC โดยมีกล่องควบคุมสำหรับควบคุมการจ่ายกระแสไฟฟ้าให้กับมอเตอร์สำหรับการขับเคลื่อน ซึ่งกำลังของมอเตอร์จะถูกส่งผ่านเพลลาขับไปล้อโดยตรง โดยที่ระยะทางสูงสุดสำหรับรถกอล์ฟไฟฟ้าทั่วไปจะอยู่ที่ 70-100 กิโลเมตร



รูปที่ 2.1 รถกอล์ฟไฟฟ้า Club Car Precedent ขนาด 4 ที่นั่ง

ระบบขับเคลื่อนด้วยไฟฟ้าคือเทคโนโลยีที่ใช้ควบคุมการขับเคลื่อนของรถยนต์ในปัจจุบัน ถูกพัฒนาให้สั่งการทำงานด้วยสัญญาณไฟฟ้า ทำให้ระบบอัตโนมัติสามารถควบคุมระบบได้เกือบทั้งหมด ไม่ว่าจะเป็นระบบบังคับเลี้ยวไฟฟ้า (Steering-by-wire) ที่ถูกพัฒนาจากระบบปัมไฮดรอลิก เป็นมอเตอร์ไฟฟ้าสำหรับควบคุมการหมุนของพวงมาลัย หรือระบบคันเร่งไฟฟ้า (Throttle-by-wire) ที่ควบคุมการเปิดปิดลิ้นปีกผีเสื้อด้วยมอเตอร์ไฟฟ้าแทนลวดสลิงในเครื่องยนต์เผาไหม้ภายใน หรือควบคุมแรงดันที่จ่ายให้มอเตอร์ในรถไฟฟ้า และระบบเบรกไฟฟ้า (Brake-by-wire) ที่ควบคุมแรงดันของของเหลวในระบบเบรกด้วยมอเตอร์ แทนหม้อลมเบรก โดยระบบทั้งหมดได้ถูกพัฒนามาปรับใช้กับรถกอล์ฟไฟฟ้า เพื่อศึกษาการควบคุมด้วยตัวควบคุมแบบ PID (Panithi et al. ,2019) โดยมีรายละเอียดดังนี้


2.1.1 ระบบบังคับเลี้ยวไฟฟ้า

การควบคุมพวงมาลัยด้วยไฟฟ้า (Steering-by-wire) ของรถกอล์ฟ ถูกพัฒนาด้วยการติดตั้งมอเตอร์ไฟฟ้าพร้อมอุปกรณ์วัดมุม (Encoder) ทำให้สามารถควบคุมมุมเลี้ยวได้สองแบบ ทั้งการควบคุมโดยการบังคับด้วยมือและการใช้สัญญาณไฟฟ้ามาควบคุมมุมเลี้ยวของรถกอล์ฟ ดังรูปที่ 2.2

2.1.2 ระบบคันเร่งและเบรกไฟฟ้า

คันเร่งและเบรกของรถกอล์ฟไฟฟ้า ถูกพัฒนาให้สามารถใช้งานได้ด้วยการบังคับจากผู้ใช้ซึ่งติดตั้งมอเตอร์ไฟฟ้าพร้อมเซนเซอร์วัดมุมที่กลไกของคันเร่ง ให้สามารถควบคุมความเร็ว อัตราเร่ง และอัตราหน่วงความเร็วของรถกอล์ฟได้ด้วยสัญญาณไฟฟ้า ดังรูปที่ 2.2 (ซ้าย)

ระบบขับเคลื่อนด้วยไฟฟ้าทั้งหมด ถูกควบคุมด้วยระบบควบคุมแบบปิด (Close-loop control) ที่มีค่าส่งกลับจากเซนเซอร์วัดมุม และใช้ตัวชดเชยแบบ PID ซึ่งถูกเขียนให้ประมวลผลด้วยบอร์ด Arduino UNO R3



รูปที่ 2.2 (ซ้าย) เบรกและคันเร่งไฟฟ้า (ขวา) พวงมาลัยไฟฟ้า

2.2 ยานยนต์อัตโนมัติ

ยานยนต์ขับเคลื่อนอัตโนมัติ (Autonomous Vehicle) คือยานยนต์ที่สามารถตัดสินใจได้เองตั้งแต่ที่ผู้โดยสารขึ้นรถจนถึงที่หมาย โดยไม่จำเป็นต้องมีผู้ขับขี่คอยควบคุม ซึ่งจะใช้การรับรู้สถานะแวดล้อมรอบคันรถ ไม่ว่าจะเป็น คน สัตว์ ไฟจราจร เครื่องหมายจราจร เส้นจราจร และรถคันอื่นๆ บนท้องถนน ด้วยเซนเซอร์ต่างๆ เช่น กล้อง เซนเซอร์วัดระยะด้วยแสง (Lidar) เซนเซอร์วัดระยะด้วยคลื่นวิทยุ (Radar) เป็นต้น โดยจะมีหน่วยควบคุมหรือหน่วยประมวลผลกลาง ในการรับค่าจากเซนเซอร์ไปประมวลผลและใช้ในการตัดสินใจ แล้วส่งสัญญาณไปควบคุม ระบบบังคับเลี้ยว การเร่ง และการเบรก ของยานยนต์

Society of Automotive Engineers (2018) ได้ประกาศการแบ่งระดับของยานยนต์อัตโนมัติ ตั้งแต่ ระดับที่ไม่มีการช่วยเหลือการขับขี่ ถึงระดับที่มีการขับเคลื่อนอัตโนมัติโดยสมบูรณ์ ซึ่งมีเกณฑ์ในการแบ่งตาม การลดบทบาทหน้าที่ของผู้ขับขี่ การเพิ่มบทบาทของระบบอัตโนมัติ และ อุปกรณ์เครื่องมือวัดต่างๆ ที่ถูกติดตั้งเข้ากับรถ โดยแบ่งออกเป็น 6 ระดับและให้นิยามไว้ดังนี้

ระดับที่ 0 No Automation ผู้ขับขี่จะเป็นผู้ควบคุมยานพาหนะทั้งหมด ไม่มีอุปกรณ์ช่วยเหลือในการขับขี่

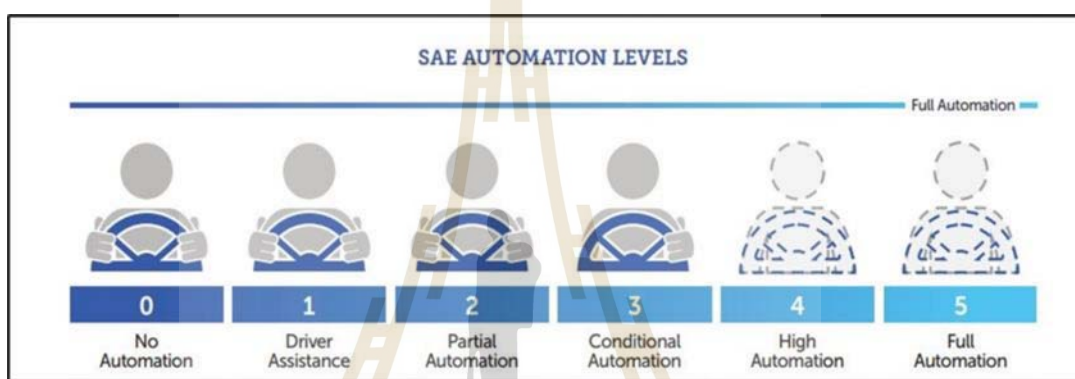
ระดับที่ 1 Driver Assistance คือระดับต่ำที่สุดของความเป็นอัตโนมัติ รถยนต์จะมีระบบช่วยเหลือผู้ขับขี่ (Driver Assistant System) ในการควบคุมรถยนต์ เช่น ระบบควบคุมความเร็ว (Adaptive Cruise Control) ที่ช่วยควบคุมความเร็วของรถและรักษาระยะห่างที่ปลอดภัยจากรถคันข้างหน้า แต่ผู้ขับขี่จะยังคงต้องควบคุมพวงมาลัย

ระดับที่ 2 Partial Automation รถยนต์จะมีระบบช่วยเหลือผู้ขับขี่ขั้นสูง (Advanced Driver Assistance System หรือ ADAS) โดยจะใช้ในการควบคุมระบบบังคับเลี้ยว และการเร่งความเร็วหรือเบรก ไปพร้อมกันทั้งสองระบบ แต่ผู้ขับขี่จะต้องนั่งอยู่หลังพวงมาลัยและต้องพร้อมที่จะควบคุมรถด้วยตัวเองอยู่ตลอดเวลา

ระดับที่ 3 Conditional Driving Automation จะคล้ายกับระดับที่ 2 โดยที่รถยนต์จะมีระบบช่วยเหลือผู้ขับขี่ขั้นสูง และมีการรับรู้สภาพแวดล้อม (Environment detection) เพิ่มเข้ามาช่วยในการตัดสินใจขับขี่ในพื้นที่ต่างๆ ของระบบอัตโนมัติ ซึ่งผู้ขับขี่ก็ต้องพร้อมที่จะเข้าควบคุมแทนอยู่ตลอดเวลา เช่นเดียวกันกับระดับที่ 2

ระดับที่ 4 High Driving Automation รถยนต์อัตโนมัติที่มีความสามารถในการควบคุมเมื่อระบบเกิดความผิดพลาด ทำให้ไม่จำเป็นต้องมีผู้ขับขี่คอยเฝ้าระวัง แต่ยังสามารถใช้คนในการขับขี่แทนระบบอัตโนมัติได้ หากเกิดเหตุฉุกเฉิน


ระดับที่ 5 Full Driving Automation ระบบอัตโนมัติสามารถควบคุมรถได้เองทั้งหมด ไม่มีข้อจำกัดด้านพื้นที่ใช้งาน ไม่จำเป็นต้องมีผู้ขับขี่ รวมถึงการที่รถอัตโนมัติในระดับนี้จะไม่มียุทธศาสตร์สำหรับควบคุมรถของผู้ขับขี่ เช่น พวงมาลัย แป้นคันเร่ง และแป้นเบรก โดยการขับขี่ของระบบอัตโนมัตินี้จะสามารถทำได้ทุกอย่างเหมือนกับรถยนต์ที่มีผู้ขับขี่



รูปที่ 2.3 การแบ่งระดับยานยนต์อัตโนมัติ (Ryan J Harrington, 2018)

2.2.1 เซนเซอร์ในยานยนต์อัตโนมัติ

ยานยนต์อัตโนมัติจำเป็นต้องมีเซนเซอร์ในการรับรู้สภาพแวดล้อมรอบตัวรถ ซึ่งรวมไปถึงสภาวะการเคลื่อนที่ของตัวยานยนต์อัตโนมัติด้วย โดยจะเห็นได้ว่าในปัจจุบันมีการพัฒนาเซนเซอร์ต่างๆ ที่เหมาะกับการนำมาใช้งานในยานยนต์อัตโนมัติ และงานวิจัยในด้านการพัฒนายานยนต์อัตโนมัติที่หลากหลาย ทำให้เห็นข้อดีและข้อเสีย รวมถึงความเหมาะสมของเซนเซอร์ในการใช้งานในแต่ละสภาพแวดล้อม ซึ่งมีการจำแนกประเภทไว้ดังตัวอย่างในรูปที่ 2.4 โดยมีรายละเอียดของเซนเซอร์แต่ละชนิดดังนี้




รูปที่ 2.4 เซนเซอร์ในยานยนต์อัตโนมัติ (Zach Wendt, 2018)

1. เซนเซอร์วัดระยะด้วยแสง (Light Detection And Ranging หรือ LiDAR)

คืออุปกรณ์ที่ใช้ในการวัดระยะทาง โดยการฉายแสงให้ไปตกกระทบวัตถุแล้วสะท้อนกลับ ซึ่งใช้หลักการของ Time of Flight (TOF) ด้วยการวัดระยะเวลาในการสะท้อนของแสงกลับไปที่เซนเซอร์ เพื่อคำนวณกลับเป็นระยะทางจากเซนเซอร์ถึงวัตถุนั้น ทำให้สามารถแสดงสภาพแวดล้อมออกมาได้ทั้ง 2 มิติ และ 3 มิติ ขึ้นอยู่กับการออกแบบของเซนเซอร์ ในปัจจุบัน Lidar สามารถตรวจวัดได้ด้วยควมถี่มากกว่า 150 กิโลเฮิร์ตซ์ และในอุปกรณ์สำหรับระยะไกล สามารถตรวจวัดได้ไกลกว่า 250 เมตร Lidar เป็นอุปกรณ์ที่ค่อนข้างจะมีประโยชน์อย่างมากกับหลายๆ ด้านของเทคโนโลยียานยนต์อัตโนมัติ และเป็นที่ยอมรับที่จะนำมาใช้กับระบบของยานยนต์อัตโนมัติ เนื่องจากเป็นอุปกรณ์ที่มีความแม่นยำและความถูกต้องของการตรวจวัดสูง สามารถให้ข้อมูล Point cloud จากการตรวจวัดได้ละเอียด ซึ่งข้อมูลเหล่านี้สามารถนำไปใช้ในการทำแผนที่แบบที่ต้องระบุตำแหน่งไปพร้อมกันได้ เช่นการทำ SLAM (Simultaneous Localization and Mapping)

ข้อมูล Point cloud คือ ข้อมูลจุดที่มีตำแหน่งใน 3 มิติ ในแกน x, y และ z เทียบกับจุดอ้างอิง อาทิเช่น จุดอ้างอิงกับตัวเซนเซอร์ จุดอ้างอิงกับตำแหน่งบนพื้นโลก จุดอ้างอิงกับตำแหน่งเริ่มต้นของแผนที่ โดยนอกจากพิกัดแล้วข้อมูลจุดยังสามารถที่จะแสดงสีเพิ่มเติมจากข้อมูลของความเข้มของแสงสะท้อนที่ส่งกลับไปที่เซนเซอร์ ซึ่งบ่งบอกความสามารถในการสะท้อนแสงของวัตถุนั้นๆ ทั้งนี้ขึ้นอยู่กับความสามารถในการวัดของเซนเซอร์แต่ละตัว



รูปที่ 2.5 ตัวอย่างข้อมูล Point cloud ของยานยนต์อัตโนมัติ (Mario Hirz, 2018)

2. กล้องหรือเซนเซอร์รับภาพ

เป็นเซนเซอร์ที่สำคัญที่สุดสำหรับยานยนต์อัตโนมัติ ซึ่งเปรียบเสมือนสายตาของมนุษย์ที่ใช้ในการขับรถ กล้องจะบันทึกภาพเหตุการณ์และสภาพแวดล้อมทั้งหมดรอบยานยนต์อัตโนมัติ เพื่อส่งต่อให้หน่วยประมวลผลสำหรับตรวจจับวัตถุและระบุตำแหน่งของวัตถุแต่ละชนิด โดยการทำงานของกล้องจะมีเลนส์กระจกสำหรับรวมแสงให้มาตกกระทบที่เซนเซอร์รับภาพที่อยู่ที่จุดรวมแสงหรือจุดโฟกัสของเลนส์นั้น ซึ่งปัญหาหลักของภาพที่ได้จากกล้องคือการบิดเบี้ยวของภาพ แต่อย่างไรก็ตาม การแก้ไขความบิดเบี้ยวของภาพสามารถทำได้ด้วยการสอบเทียบแล้วปรับค่าเมตริกซ์ของกล้อง นอกจากนี้ กล้องยังมีปัญหาในการใช้งานกับยานยนต์อัตโนมัติคือไม่สามารถระบุระยะจากภาพได้ แต่เนื่องจากการติดตั้งกล้องจะถูกยึดติดคงที่กับยานยนต์อัตโนมัติ ทำให้มุมกล้องทั้งสองแกนจะคงที่ จึงสามารถแก้ปัญหานี้ได้ด้วยการระบุระยะของเมตริกซ์ในภาพจากการเขียนโปรแกรม หรือเรียกว่า Depth estimation

นอกจากนี้ กล้องได้ถูกพัฒนาให้สามารถวัดความลึกได้แม่นยำขึ้น โดยกล้องสเตอริโอ Stereo camera เป็นกล้องที่มีเซนเซอร์รับภาพ 2 เซนเซอร์ ใช้หลักการของสามเหลี่ยมคล้ายมาใช้ในการวัดระยะจากภาพที่บันทึก ซึ่งเหมือนกับสายตามนุษย์ที่ประเมินความตื้นลึกของสิ่งที่เห็นได้

3. เซนเซอร์วัดระยะด้วยคลื่นวิทยุ (Radio Detecting and Ranging หรือ Radar)

เป็นอุปกรณ์สำหรับวัดระยะและความเร็วสัมพัทธ์ระหว่างเซนเซอร์กับวัตถุที่อยู่ในระยะตรวจจับของเซนเซอร์ ด้วยการใช้การสะท้อนของคลื่นกลับมาที่ตัวเซนเซอร์ เช่นเดียวกับ LiDAR โดยความถี่ของคลื่นวิทยุที่ใช้จะอยู่ในช่วง 76-85 GHz และระยะในการตรวจจับของเซนเซอร์จะเป็นระยะปานกลางคือ 80-200 m ข้อดีคือความแม่นยำ แต่ข้อเสียของ Radar คือมุมมองในการ

ตรวจวัดจะแคบ ปกติเซนเซอร์เพียงตัวเดียวจะตรวจวัดได้เพียงด้านหน้าของรถยนต์เท่านั้น โดย Radar เป็นเซนเซอร์ที่มีบทบาทสำคัญกับระบบ Adaptive cruise control เนื่องจากความเร็วสัมพัทธ์ของรถยนต์ระหว่างคันข้างหน้ากับเซนเซอร์ที่มีความแม่นยำจะถูกนำไปควบคุมความเร็วของรถยนต์ ซึ่งรวมถึงการหยุดรถกะทันหันหรือ Emergency brake ด้วย

4. ระบบระบุพิกัดบนพื้นโลก (Global Navigation Satellite System หรือ GNSS)

คืออุปกรณ์สำหรับรับสัญญาณคลื่นวิทยุที่ส่งมาจากดาวเทียม จากเครือข่ายของดาวเทียมที่โคจรรอบโลก ไม่ว่าจะเป็น GPS, GLONASS, Galileo, Beidou, IRNSS และ QZSS เพื่อใช้ระบุตำแหน่งของยานยนต์อัตโนมัติเทียบกับพิกัดบนพื้นโลก ซึ่งความแม่นยำจะอยู่ในหลักเมตรถึงเซนติเมตร ขึ้นอยู่กับจำนวนของดาวเทียมที่สามารถรับสัญญาณได้ ณ ขณะนั้น

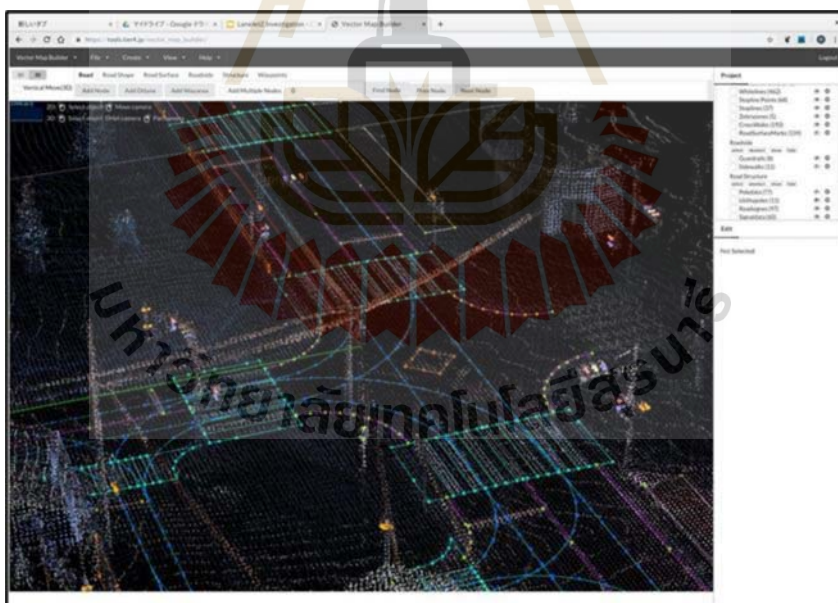
ระบบการทำงานของยานยนต์อัตโนมัติจะแบ่งออกเป็น 2 ส่วน คือส่วนการรับรู้ (perception) ที่ประกอบไปด้วยการรับรู้สถานะภายในและการรับรู้สภาพแวดล้อมรอบยานยนต์อัตโนมัติจากข้อมูลที่ได้จากเซนเซอร์ รวมถึงการนำข้อมูลที่ได้รับไปประมวลผลเพื่อประเมินสถานการณ์ ณ เวลานั้น และส่วนของการตัดสินใจ (making decision) ที่นำข้อมูลจากส่วนการรับรู้มาใช้ในการตัดสินใจระหว่างการเดินทางจากจุดเริ่มต้นไปยังเป้าหมาย (Claudine Badue et al., 2019)

2.3 การรับรู้ของยานยนต์อัตโนมัติ

ข้อมูลที่ได้รับเข้าจากเซนเซอร์ของยานยนต์อัตโนมัติ เช่น กล้อง, Lidar, Radar หรือ GPS จะถูกนำมาใช้ประมวลผลเพื่อให้ได้ข้อมูลสภาพแวดล้อมที่จะนำไปใช้ควบคุมยานยนต์อัตโนมัติ โดยข้อมูลสำคัญที่ต้องนำไปใช้ในการตัดสินใจอันดับแรกคือข้อมูลตำแหน่งของยานยนต์อัตโนมัติ จะมีการใช้วิธีการประมวลผลเพื่อระบุตำแหน่ง (Localization) โดยเทียบกับแผนที่หรือพิกัดบนพื้นโลก ซึ่งจะสัมพันธ์กับการสร้างแผนที่ (Mapping) ที่เก็บข้อมูลตำแหน่งของอาคาร เครื่องหมายจราจร ไฟจราจร ช่องจราจร รวมถึงทางมาลาาย ซึ่งรายละเอียดของแผนที่จะแตกต่างกันไปตามแต่ละรูปแบบ ข้อมูลอีกส่วนคือการตรวจจับวัตถุ (Object detection) เพื่อรับรู้ตำแหน่งของวัตถุรอบยานยนต์อัตโนมัติ นอกจากนี้ยังต้องใช้ข้อมูลด้านพลศาสตร์ของยานยนต์อัตโนมัติ (Dynamics of Autonomous car) เช่น ความเร็วเชิงเส้นในแนวแกน ความเร่งเชิงเส้น และความเร็วเชิงมุม

2.3.1 แผนที่ความละเอียดสูง (High-definition map)

แผนที่สำหรับยานยนต์อัตโนมัติ High Definition map ถูกนิยามครั้งแรกจาก Bertha Drive Project ในปี 2010 ซึ่งต่อมา Ziegler et al. (2014) ได้พัฒนาจากโปรเจกต์เดิมให้ยานยนต์อัตโนมัติ Mercedes Bens S-Class S 500 สามารถวิ่งด้วยระบบอัตโนมัติเป็นระยะทาง 103 กิโลเมตร บนถนนในเมืองและชนบท โดยใช้ข้อมูลวัตถุและช่องจราจรจากแผนที่ 3 มิติ High definition map มาใช้ในการระบุตำแหน่งและการตัดสินใจของยานยนต์อัตโนมัติ ต่อมา Fabian Poggenhans et al. (2018) ได้นำเสนอ High definition map framework ที่ชื่อว่า Lanelet2 สำหรับการสร้างและใช้งาน High definition map โดยรายละเอียดของแผนที่ที่สร้างด้วย Lanelet2 จะประกอบด้วย 2 ส่วน คือส่วนของ Point cloud map และ Road lane layer ซึ่ง Road lane layer คือจุดเชื่อมต่อและเส้นตรงที่เชื่อมต่อกันจนเป็นช่องจราจร และนอกจากนี้จุดและเส้นของ Road lane layer ยังสามารถระบุตำแหน่งของเส้นหยุดรถ และเสาไฟจราจรได้อีกด้วย ส่วนของ Point cloud map จะเกิดจากการสร้างแผนที่ 3 มิติด้วย Lidar หรือเรียกว่า Point cloud registration



รูปที่ 2.6 แผนที่ความละเอียดสูงในรูปแบบของ Lanelet2

2.3.2 การสร้างแผนที่ Point cloud

การสร้าง 3D Point cloud map ด้วยวิธีการ Point cloud registration มีทฤษฎีที่นิยม 2 ทฤษฎีคือ ICP (Iterative closet point) และ NDT (Normal distribution transform) โดย

Su Pang et al. (2019) ได้ศึกษาเปรียบเทียบการทำ Point cloud registration ทั้งสองวิธีในสภาพแวดล้อมจริงภายใน Michigan State University ด้วยการติดตั้งเซนเซอร์วัดระยะด้วยแสง Lidar Velodyne Puck และระบบระบุตำแหน่ง NovAtel PwrPak7 GNSS Inertial Navigation System เข้ากับรถยนต์ที่มีระบบ Drive-by-wire ชื่อว่า Lincoln MKZ พร้อมกับคอมพิวเตอร์ประมวลผลชิป Intel Core i7 ซึ่งทดสอบด้วยการวิ่งทำ 3D point cloud map เป็นระยะ 350 เมตร แบบเวลาจริง พบว่าผลลัพธ์ของทั้งสองวิธีสามารถสร้าง 3D point cloud map ออกมาได้ แต่ NDT จะมีความเร็วในการประมวลผลที่สูงกว่า และมีค่าความผิดพลาดเฉลี่ยของการระบุตำแหน่งที่ต่ำกว่า ICP

Normal distribution transform หรือ NDT เป็นอัลกอริทึมที่สร้างขึ้นมาเพื่อบรรจุข้อมูล 2 มิติ โดยมีหลักการทำงานคือการเปรียบเทียบข้อมูลการสแกน แต่แทนที่จะใช้การเปรียบเทียบโดยตรง NDT นั้นคือการใช้ความน่าจะเป็นจากการเปรียบเทียบข้อมูลสแกนในการหาตำแหน่งของตัวเอง เพื่อบรรจุข้อมูลสแกนในแต่ละตำแหน่ง (Martin Magnusson, 2009) ทำให้วิธีการนี้ ไม่จำเป็นต้องใช้การประมวลผลที่สูง เมื่อเทียบกับการเปรียบเทียบข้อมูลสแกนโดยตรง

การประมวลผลของ NDT ในการบรรจุข้อมูลสแกนนั้นมีเป้าหมายในการหาตำแหน่งที่มีความน่าจะเป็นของการเปรียบเทียบสูงที่สุด ซึ่งเทียบระหว่างข้อมูลสแกนปัจจุบันกับข้อมูลสแกนอ้างอิง โดยจะสนใจทั้งการเคลื่อนที่แบบ rotation และ translation ในขั้นตอนแรกนั้น ข้อมูลสแกนอ้างอิงจะถูกแบ่งออกเป็นส่วนย่อยๆ เรียกว่า grid cell หรือใน 3 มิติจะเรียกว่า voxel ซึ่งสำหรับข้อมูล 3 มิติ voxel จะเป็นลักษณะของลูกบาศก์ ในแต่ละ voxel จะมีข้อมูลสแกนอยู่ข้างในจำนวนหนึ่งซึ่งมากกว่าจำนวนต่ำสุดที่ยอมรับได้ (minimum number of points) ซึ่งขนาดของ voxel ก็ขึ้นอยู่กับความละเอียดของข้อมูลสแกน จากนั้น ค่า average position และค่า covariance matrix จะถูกคำนวณด้วยสมการ 2.1 และ 2.2

$$p_k = \frac{1}{M_k} \sum_{i=0}^{M_k-1} x_{k_i} \quad (2.1)$$

$$\sum_k = \frac{1}{M_k} \sum_{i=0}^{M_k-1} (x_{k_i} - p_k)(x_{k_i} - p_k)^t \quad (2.2)$$

เมื่อ p_k คือ ค่า average position ของข้อมูลสแกนใน voxel k

X_{ki} คือ ข้อมูลสแกน Point cloud ที่อยู่ใน voxel k

\sum_k คือ ค่า covariance matrix ของ voxel k

M_k คือ จำนวนของข้อมูล Point cloud ที่อยู่ใน voxel k

โดยกำหนดให้ k_i เป็นตัวแปรของ voxel ที่นำมาคำนวณค่าความน่าจะเป็น ซึ่งการคำนวณหาค่า Normal distribution นั้นจะใช้สมการ probability density function (PDF) ดังสมการ 2.3 ที่ใช้ค่า average precision และ covariance matrix ของ voxel k มาร่วมคำนวณด้วยในขั้นตอนนี้

$$e(x) = \exp\left(-\frac{(x-p_k)^t \sum_k M_k (x-p_k)}{2}\right) \quad (2.3)$$

จากนั้นข้อมูล Point cloud ที่เข้ามาใหญ่จากการสแกนรอบถัดมาจะต้องผ่านการแปลงพิกัดด้วยสมการ 3D coordinate สำหรับการแปลงข้อมูล Point cloud input ซึ่งได้แสดงดังสมการที่ 2.4

$$w_i = Rx_i + t \quad (2.4)$$

เมื่อ R คือ rotation matrix สำหรับการหมุนมุม euler angle α, β และ γ รอบแกน x, y

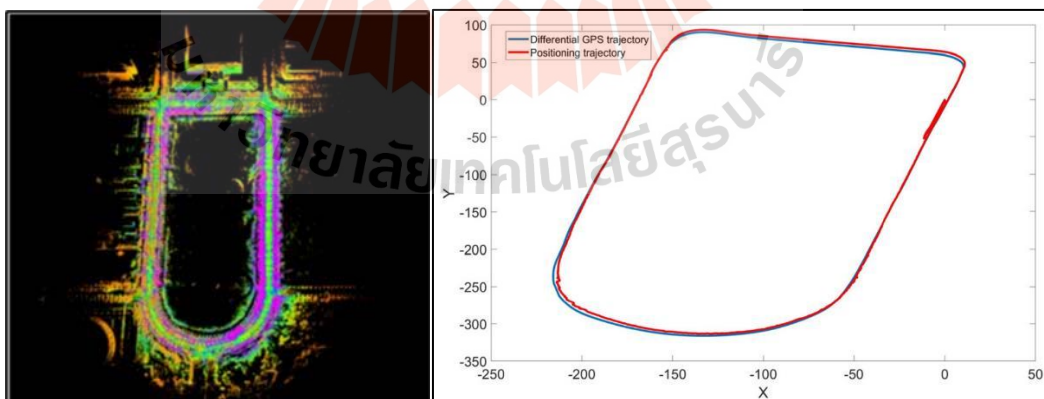
และ z

T คือ translation vector (tx, ty, tz)

โดยที่ตัวแปรทั้งหมดของ NDT จะได้จาก euler angle และ translation vector ซึ่งสามารถแสดงได้ดังรูปเวกเตอร์ $T = (\alpha, \beta, \gamma, tx, ty, tz)^t$ ซึ่งการเปรียบเทียบตำแหน่งที่เคลื่อนที่จากข้อมูล point cloud ที่สแกน 2 รอบที่ตำแหน่งต่างกันจะต้องใช้ Newton's method ในการ optimize ตัวแปรที่ทำให้ PDF ของการสแกนทั้งสองรอบมีค่าเท่ากัน สุดท้ายแล้ว เมื่อผลของ Newton's method นั้นลู่เข้า ข้อมูล Point cloud จากการสแกนทั้งสองรอบก็จะถูกบรรจุไว้เป็นแผนที่ Point cloud map และเกิดการประมวลผลข้อมูลที่สแกนเข้ามาอีกเรื่อยๆ ก็จะทำให้ได้ข้อมูลแผนที่ Point cloud map แบบ 3 มิติที่สมบูรณ์

2.3.3 การระบุตำแหน่งของยานยนต์จากแผนที่ความละเอียดสูง

การระบุตำแหน่งของยานยนต์อัตโนมัติด้วย Normal distribution transform ได้ถูกศึกษาโดย Naoki Akai et al. (2017) ซึ่งทำการทดลองสร้างแผนที่ของ Gwangju Institute of Science and Technology ด้วย 3D Point cloud จาก VLP-32 Lidar และใช้แผนที่นี้เป็นข้อมูลสำหรับเปรียบเทียบเพื่อระบุตำแหน่งด้วย NDT โดยใช้ยานยนต์อัตโนมัติที่พัฒนาจากรถยนต์ KIA Soul EV ติดตั้ง Lidar, GNSS และกล้อง ซึ่ง Lidar นี้เป็นชนิด 3 มิติ 32 channel ตรวจวัดได้ระยะมากกว่า 100 เมตร ขับรอบแผนที่ที่สร้างภายในมหาวิทยาลัย พร้อมกับประมวลผลตำแหน่งจากข้อมูล Point cloud ที่ตรวจจับได้ พบว่าผลการทดลองสามารถใช้ NDT สำหรับการระบุตำแหน่งของยานยนต์อัตโนมัติแบบเวลาจริง (Real-time) เช่นเดียวกันกับการศึกษา NDT ของ Sijia Liu et al. (2021) ที่สนใจที่จะแก้ปัญหาการขาดหายของสัญญาณ GPS จากการบดบังของสิ่งปลูกสร้างต่างๆ ด้วยการใช้ NDT จากข้อมูล Point cloud ในการระบุตำแหน่งของยานยนต์อัตโนมัติแทนที่ GPS โดยอุปกรณ์และเครื่องมือที่ใช้ในการทดลองคือ OUSTER 32-line Lidar ซึ่งติดตั้งบนยานยนต์ไฟฟ้า JAC Electric Vehicle และทำการทดลองภายในมหาวิทยาลัย Nanhu Campus of Wuhan University of Technology โดยขับขึ้นถนนที่มีสองช่องจราจรด้วยความเร็ว 20 กิโลเมตรต่อชั่วโมง ซึ่งผลการทดลองได้นำผลการระบุตำแหน่งจาก NDT มาเปรียบเทียบกับตำแหน่งจาก GPS พบว่าค่าความผิดพลาด Mean square error ของ NDT มีค่า 0.15 เมตร ซึ่งหมายความว่า NDT มีความสามารถในการระบุตำแหน่งที่ใกล้เคียงกับ GPS สามารถใช้แทนได้ในช่วงที่ GPS มีสัญญาณต่ำ




รูปที่ 2.7 แผนที่ Point cloud และการระบุตำแหน่งด้วย NDT เปรียบเทียบกับ GPS

วิธีการระบุตำแหน่งแบบ Normal distribution transform หรือ NDT นั้นสามารถอ้างอิงจากวิธีการสร้างแผนที่ด้วย NDT ที่ใช้ข้อมูลแอสแกน Point cloud แต่ละเฟรมเปรียบเทียบกับแผนที่ Point cloud แล้วนั้น การระบุตำแหน่งด้วย NDT จะใช้การเปรียบเทียบระหว่างข้อมูลแอสแกน Point cloud ณ เวลาปัจจุบันเปรียบเทียบกับข้อมูลแผนที่ Point cloud

2.3.4 การตรวจจับวัตถุจากภาพ

1. การมองเห็นของเครื่องจักร

การมองเห็นของคอมพิวเตอร์จะแตกต่างไปจากมนุษย์ โดยสิ่งที่คอมพิวเตอร์เห็นจากภาพถ่ายนั้นคือเมทริกซ์ของความเข้มสี รูปแบบของภาพที่เราใช้โดยทั่วไปคือ RGB ที่ย่อมาจาก Red, Green และ Blue เป็นรูปแบบของภาพที่มี เมทริกซ์ความเข้มสีจำนวนสามชั้นซ้อนกัน ซึ่งขนาดของเมทริกซ์แต่ละชั้นจะมีขนาดเท่ากัน โดยขึ้นอยู่กับความละเอียดของภาพถ่าย หรือจำนวน pixel นั้นเอง ยกตัวอย่างเช่น ภาพขนาด 720p ก็จะมีขนาดของเมทริกซ์กว้าง 720 และยาว 1280 หรือภาพขนาด 1080p ก็จะมีขนาดกว้าง 1080 และยาว 1920 โดยค่าความเข้มสีใน matrix แต่ละช่องจะเป็นตัวเลขฐานสองขนาด 8 บิต หรือแปลงเป็นตัวเลขฐานสิบได้ปริมาณตั้งแต่ 0-255 ดังรูปที่ 2.8



รูปที่ 2.8 การมองเห็นของคอมพิวเตอร์ด้วยรูปแบบสี RGB (Mukesh Chaudhary, 2020)

2. โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network)

โครงข่ายประสาทเทียม (Neural Network) คือการประมวลผลที่เลียนแบบมาจากเซลล์ประสาทของมนุษย์ หรือนิวรอน (Neuron) ที่ทำหน้าที่ประมวลผลจากค่ารับเข้าแล้วส่งข้อมูลด้วยสัญญาณไฟฟ้าและเคมีไปที่เซลล์อื่นๆ โดยโครงสร้างของโครงข่ายประสาทเทียมจะมีลักษณะดังรูปที่ 2.4 โดยประกอบไปด้วย 5 ส่วน คือ

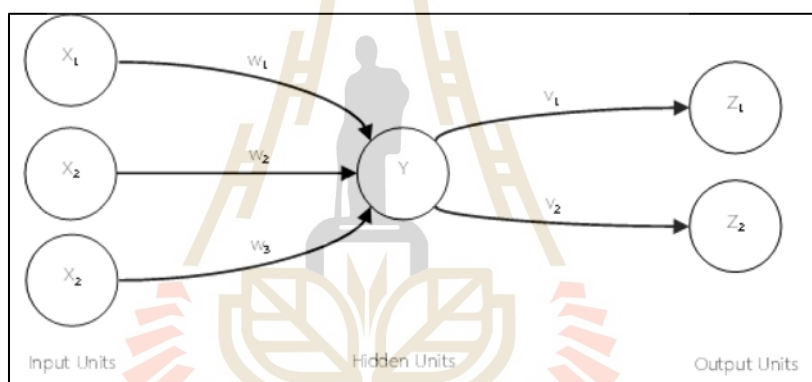
ข้อมูลป้อนเข้า (input) คือข้อมูลตัวเลขที่รับเข้ามาประมวลผลในโมเดลของโครงข่ายประสาทเทียม

ข้อมูลส่งออก (output) คือผลลัพธ์ที่เกิดจากระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

ค่าน้ำหนัก (weight) คือค่าคงที่ที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม เป็นค่าทักษะที่ใช้ในการประมวลผลข้อมูลขาเข้าของโมเดล


ฟังก์ชันผลรวม (summation function) เป็นผลรวมของข้อมูลขาเข้าและค่าน้ำหนัก

ฟังก์ชันการแปลง (transfer function) คือการแปลงข้อมูลป้อนเข้าให้อยู่ในรูปแบบของข้อมูลขาออก เช่น ซิกมอยด์ฟังก์ชัน (sigmoid function) ยูนิตสเตปฟังก์ชัน (unit step function) เป็นต้น



รูปที่ 2.9 โครงสร้างของโครงข่ายประสาทเทียม

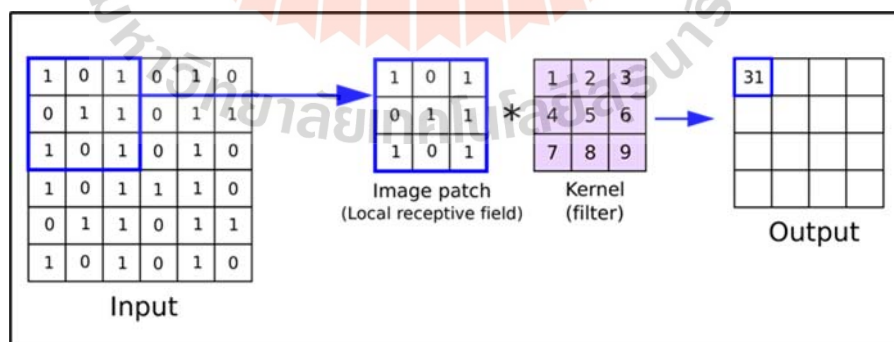
โครงข่ายประสาทเทียมแบบคอนโวลูชัน คือโครงข่ายประสาทเทียมที่มีชั้นของคอนโวลูชันเพิ่มเข้ามาในโครงสร้างของโครงข่ายประสาทเทียม ซึ่งชั้นคอนโวลูชัน(convolutional layer) จะเป็นการใช้ตัวกรองมาประมวลผลระหว่างคอร์เนล(Kernel) กับรูปภาพ เพื่อกรองหรือสกัดลักษณะเด่น(feature extraction) ของภาพออกมา เช่น เส้นขอบที่แสดงรูปร่างของวัตถุต่างๆ โดยที่ CNN จะนำ Convolution layer มาซ้อนกับชั้นอื่นๆ เช่น Pooling layer และนำกลุ่มของ layer นี้มาซ้อนกันหลายๆชั้น และปรับเปลี่ยน parameter บางอย่างในแต่ละกลุ่ม เช่นขนาดของตัวกรอง ซึ่ง Convolutional neural network จะมีโครงสร้างดังรูปที่ 2.10



รูปที่ 2.10 โครงสร้างการเรียนรู้ของ CNN (Mathworks, 2018)

และก่อนจะได้ข้อมูลขาออก จะมี Fully connected layer ทำหน้าที่เชื่อมข้อมูลสุดท้ายที่ออกจาก Convolution layer สำหรับทำนายผลลัพธ์ของภาพขาเข้า โดยหน้าที่ของแต่ละชั้นในโครงข่ายประสาทเทียมแบบคอนโวลูชันอธิบายได้ดังนี้


ชั้น Convolution ที่จะทำให้การคูณระหว่างรูปภาพขาเข้าที่เป็นเมทริกซ์กับ Kernel ซึ่งจะได้ผลลัพธ์ออกมาเป็น Feature map ดังตัวอย่างในรูปที่ 2.11 ซึ่งเป็นชั้นของคุณลักษณะเด่นที่ดึงออกมาจากภาพขาเข้า โดยคอร์เรนอลนั้นมีหลายแบบและหลายขนาด เช่น 2×2 , 3×3 และ 5×5 ขึ้นอยู่กับลักษณะเด่นของภาพที่ต้องการจะสกัดออกมา ตัวเลขที่อยู่ใน Kernel นั้นจะได้จากการเรียนรู้ของโมเดล ซึ่งจะถูกปรับจูนไปเรื่อยๆ และนอกจาก Kernel แล้ว ยังมี Stride ซึ่งทำหน้าที่ในการกำหนดจำนวนช่องการเลื่อนของ Kernel ในแต่ละครั้งของกระบวนการ Convolution และ Padding ที่เป็นการเพิ่มขนาดของภาพขาเข้าให้ได้ feature map ที่มีขนาดเท่ากัน ตามลำดับ



รูปที่ 2.11 กระบวนการของชั้น Convolution (Anh H. Reynolds, 2019)

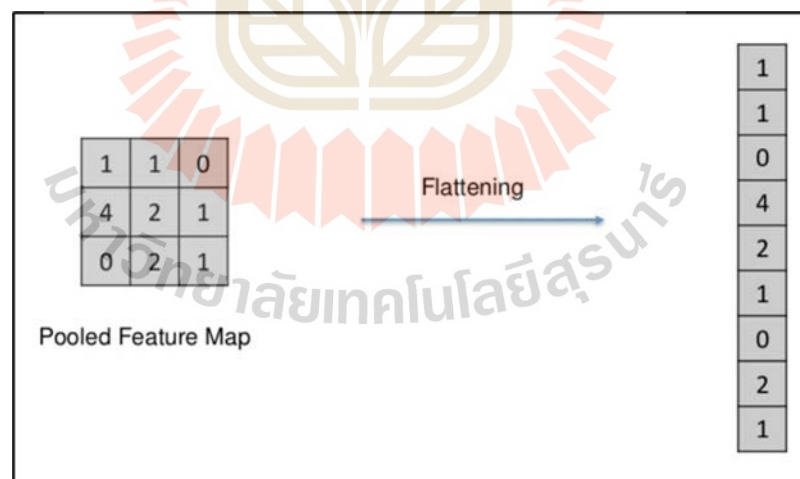
ชั้น Pooling จะรับข้อมูล Feature map จากชั้น Convolution เพื่อนำมาสกัดเอาคุณลักษณะที่สำคัญที่สุด และลดขนาดของข้อมูลเพื่อเพิ่มความเร็วในการประมวลผล ซึ่งชั้น Pooling นั้นมีอยู่ 2 ประเภท คือ Max Pooling และ Average Pooling โดย Average Pooling จะกรองเอา

ค่าเฉลี่ยของเมทริกซ์ 2×2 ของข้อมูลขาเข้าและลดขนาดลงมา เช่นเดียวกับกับ Max Pooling แต่ Max Pooling จะเลือกค่าสูงสุด ดังตัวอย่างในรูปที่ 2.12 โดยประเภทของชั้น Pooling ที่นิยมใช้มากที่สุดคือ Max Pooling



รูปที่ 2.12 กระบวนการ Max Pooling และ Average Pooling (Muhamad Yani, 2019)


กระบวนการ Flattening คือการนำคุณลักษณะเด่นที่ได้จากชั้น Pooling ที่เป็นเมทริกซ์แบบ 2 มิติ มาเรียงให้เป็นเมทริกซ์ 1 มิติที่มีคอลัมน์เดียว



รูปที่ 2.13 กระบวนการ Flattening (PradyaSin, 2019)

กระบวนการ Fully Connection คือการนำข้อมูลที่ได้จากกระบวนการ Flattening เป็นข้อมูลขาเข้าให้กับโครงข่ายประสาทเทียม (Artificial Neural Network) เพื่อประมวลผลและ


ทำนายความน่าจะเป็นของภาพขาเข้า ซึ่งจำนวนผลลัพธ์ขึ้นอยู่กับกรอกแบบของโมเดล CNN แต่ละชนิด



รูปที่ 2.14 กระบวนการ Fully Connection (PradyaSin, 2019)

จากข้อมูลคุณลักษณะเด่นที่ได้จากโครงข่ายประสาทเทียมแบบคอนโวลูชัน การจะระบุตำแหน่งของวัตถุแต่ละชนิดในภาพนั้นมีหลายวิธี ซึ่ง Ross Girshick and Microsoft Research (2015) ได้พัฒนาระบบตรวจจับวัตถุแบบเวลาจริงชื่อว่า Fast-RCNN ที่พัฒนาเพิ่มประสิทธิภาพจาก RCNN (Region-based Convolutional Network) ที่เป็นโมเดลตรวจจับวัตถุของ Ross Girshick et al. (2014) ซึ่งโมเดล RCNN เป็นการตรวจจับแบบสองชั้น คือชั้นแรกจะเป็นการนำเสนอจุดสนใจในภาพด้วยเครื่องมือ Selective search แล้วจึงนำไปเข้า CNN ทำให้ผลลัพธ์ด้านความเร็วในการประมวลผลของโมเดลต่ำ อยู่ในช่วง 2 FPS (Frame per sec) ซึ่ง Fast-RCNN ได้ถูกพัฒนาขึ้นมาโดยลดขั้นตอนการทำ Selective search เพื่อเพิ่มความเร็วให้กับกระบวนการประมวลผลของโมเดล โดยโมเดล Fast-RCNN ได้ใช้ CNN ในการหาวัตถุที่สนใจแล้วนำภาพเฉพาะวัตถุนั้นที่ดึงลักษณะเด่นด้วย CNN แล้ว ไปประมวลผลต่อด้วย SVM ให้ได้ค่าความมั่นใจของวัตถุแต่ละชนิด และใช้ Bounding box regression ในการระบุตำแหน่งและขนาดที่แน่นอนของวัตถุในภาพ ซึ่งผลทดสอบกับชุดข้อมูลทดสอบ Pascal VOC 2007 ของโมเดล Fast-RCNN มีค่า mAP (mean Average Precision) 70 และความเร็วในการประมวลผล 7 FPS ต่อมา Joseph Redmon et al. (2016) ได้พัฒนาระบบตรวจจับวัตถุแบบเวลาจริงที่ทำงานขั้นตอนเดียว (Single-stage) โดยนำเสนอโครงสร้าง CNN ที่ชื่อว่า You Only Look Once หรือ YOLO ซึ่งมีโครงสร้างเครือข่าย Convolutional layers 24 ชั้น และตามด้วย Fully connected layer 2 ชั้น โดยที่ค่าความคมชัดของภาพขาเข้าไปยังชุดเครือข่ายเท่ากับ 448x448 โดยที่การทำนายของโมเดลจะออกมาเป็น 2 ชนิด คือ ความน่าจะเป็นและตำแหน่ง

ของกล่องที่ตรวจจับวัตถุในภาพ และมีการใช้ Linear activation function ในทุกชั้นของโครงสร้าง แล้วให้โมเดลเรียนรู้กับชุดข้อมูลรูปภาพ Pascal VOC 2007 และ 2012 จากนั้นจึงนำค่าน้ำหนักไปทดสอบกับชุดข้อมูลทดสอบ Pascal VOC 2007 ได้ผลการทดสอบคือค่า mAP 66.4 และความเร็วในการประมวลผล 21 FPS ซึ่งเปรียบเทียบได้ว่าโมเดลสามารถทำการตรวจจับวัตถุได้ในเวลาจริง จากการเปรียบเทียบระหว่าง YOLO และ Fast-RCNN ผู้วิจัยต้องการมุ่งเน้นที่จะใช้งานระบบตรวจจับวัตถุแบบเวลาจริงที่มีความแม่นยำเพียงพอต่อการใช้งาน จึงมีแนวคิดที่จะเลือกใช้โมเดล YOLO มาใช้งานกับยานยนต์อัตโนมัติ เพราะความเร็วในการประมวลผลที่มากกว่าจะทำให้ได้ข้อมูลที่รวดเร็วพอในการตัดสินใจของรถกอล์ฟ




รูปที่ 2.15 การตรวจจับวัตถุด้วย YOLOv3

3. การตรวจจับวัตถุจากภาพด้วย YOLOv3

You Only Look Once version 3 หรือ YOLOv3 คืออัลกอริทึมสำหรับการตรวจจับวัตถุจากภาพถ่ายที่มีความแม่นยำและมีประสิทธิภาพในการตรวจจับแบบเวลาจริง ซึ่งกระบวนการและโครงสร้างของ YOLOv3 นั้น เป็นตัวแปรสำคัญที่ทำให้ YOLOv3 สามารถที่จะตรวจจับวัตถุแบบเวลาจริงได้อย่างแม่นยำ

YOLOv3 จะรับรูปภาพขาเข้าที่มีขนาด $S \times S$ และมีความลึกเท่ากับ 3 (RGB image) โดยความกว้างและความยาวของรูปภาพในหน่วยพิกเซลสามารถเป็นไปได้หลายขนาด ขึ้นอยู่กับความสามารถของหน่วยประมวลผลและความแม่นยำของการตรวจจับที่ผู้ใช้งานต้องการ โดยการเลือกความกว้างและความยาวที่สามารถหารลงตัวด้วยเลข 32 ซึ่งนิยมใช้ความละเอียดที่ 416×416




รูปที่ 2.16 โครงสร้างโมเดล YOLOv3 (Ayoosh Kathuria, 2018)

ภาพขาเข้านั้นจะผ่านเข้าสู่โครงสร้างของ YOLOv3 ที่มีชื่อว่า Darknet53 ซึ่งเป็นขั้นตอนของการดึงลักษณะเด่นจากภาพ (Feature extractor) และจะได้ข้อมูลขาออกเป็นข้อมูลชั้นลักษณะเด่น (Feature map) ดังรูปที่ 2.16 จากนั้นข้อมูลชั้นลักษณะเด่นจะถูกนำไปรวมกันกับชั้น residual ที่จะช่วยรักษาคุณลักษณะเด่นของภาพไว้ และนำไปสู่ชั้น prediction ทั้งหมด 3 ชั้น ซึ่งมีขนาดแตกต่างกัน และออกมาจากโครงสร้างในตำแหน่งที่แตกต่างกัน โดยข้อมูลขาออกที่ชั้น prediction จะมีข้อมูลของ Bounding box และค่า class probability บรรจุอยู่ในแต่ละช่อง grid ของชั้นข้อมูล ซึ่งข้อมูล Bounding box เหล่านี้อาจทำนายว่าพื้นที่บริเวณนั้นเป็นวัตถุชนิดเดียวกันได้หลาย box ทำให้โมเดล YOLOv3 เลือกที่จะใช้ Non-max suppression ในการรวม bounding box เหล่านี้ให้เป็น box เดียวที่มีค่าความมั่นใจสูงสุด และทำให้ได้ box ที่มีขนาดใกล้เคียงกับวัตถุมากที่สุด จากนั้น Bounding box สุดท้ายที่เป็นกรอบล้อมรอบวัตถุที่ตรวจจับได้จากภาพ จะประกอบไปด้วยข้อมูล 5 ชนิด คือ ตำแหน่งของจุดกึ่งกลาง box ในแนวแกน x และ y, ขนาดความกว้างและความสูงของกล่อง และค่าความมั่นใจในการตรวจจับ ซึ่งค่าความมั่นใจนี้จะมีจำนวนตามชนิดของวัตถุของโมเดลเรียนรู้ โดย Bounding box จะถูกนำมาแสดงรวมกับภาพขาเข้าพร้อมกับระบุชนิดของวัตถุที่มีค่าความมั่นใจสูงสุด ดังรูปที่ 2.15

การประเมินผลการเรียนรู้ของโมเดล (Evaluation) เป็นกระบวนการที่จะนำโมเดลที่ผ่านการเรียนรู้แล้วมาประเมินประสิทธิภาพและความถูกต้องของโมเดล ก่อนที่จะตัดสินใจว่าโมเดลนั้นมีประสิทธิภาพเพียงพอต่อการนำไปใช้งานหรือควรแก้ไขปรับปรุงเพื่อเข้าสู่กระบวนการเรียนรู้อีกครั้ง โดยการประเมินประสิทธิภาพของโมเดลตรวจจับวัตถุจากภาพนั้นจะนิยมใช้ตัวชี้วัด (Evaluation

metric) ที่มีชื่อว่า Mean-average Precision (mAP) ซึ่งก็คือค่าความแม่นยำเฉลี่ยในการตรวจจับวัตถุ โดยมีค่า Intersection Over Union (IOU) มาใช้เป็นจุดแบ่งของการประเมิน



รูปที่ 2.17 วิธีการคำนวณ IOU (Adrian Rosebrock, 2016)


การคำนวณ IOU นั้นจะพิจารณาจากพื้นที่ที่ซ้อนทับกันระหว่างกรอบของวัตถุที่ได้จากการทำนายของโมเดล (Predicted box) และกรอบของวัตถุที่ถูกต้อง (Ground truth box) ที่ได้จากการล้อมกรอบด้วยมือ โดยจะคำนวณจากการหาอัตราส่วนระหว่างพื้นที่ที่ซ้อนทับกันของทั้งสองกรอบและพื้นที่ทั้งหมด ดังตัวอย่างการคำนวณในรูปที่ 2.17

การคำนวณหาค่า mAP จะมีวิธีการคือนำโมเดลที่ได้จากกระบวนการเรียนรู้มาทำนายผลกับชุดข้อมูลทดสอบที่เตรียมไว้ โดยชุดข้อมูลทดสอบนี้จะใส่คำตอบที่ถูกต้องลงไปแล้ว จากนั้น คำนวณค่า IOU และแบ่งผลที่ได้ออกเป็น 2 ส่วน ซึ่งจะแบ่งแยกตามค่ายอมรับของ IOU ที่นิยมใช้คือ 0.5 IOU ผลการตรวจจับที่มีค่า IOU มากกว่าหรือเท่ากับค่ายอมรับจะจัดให้อยู่ในส่วนที่ทำนายได้ถูกต้อง และผลการตรวจจับที่มีค่าต่ำกว่าค่ายอมรับจะจัดให้อยู่ในส่วนที่ทำนายไม่ถูกต้อง แล้วคำนวณหาอัตราส่วนความถูกต้องของการตรวจจับกับข้อมูลในชุดทดสอบทั้งหมด ซึ่งค่า mAP ของโมเดลตรวจจับวัตถุจากภาพ YOLOv3 ที่มีการเรียนรู้กับชุดข้อมูลแบบ COCO นั้นมีค่าเท่ากับ 55.3 ที่ 0.5 IOU และความละเอียดของภาพขาเข้า 416 (Joseph Redmon, 2018)

2.3.5 การแบ่งกลุ่มข้อมูล Point cloud

ข้อมูลวัตถุที่อยู่รอบยานยนต์อัตโนมัติ เป็นสิ่งสำคัญที่จะถูกนำไปใช้ในการตัดสินใจของยานยนต์ด้วยเหตุผลทางด้านความปลอดภัย ซึ่งข้อมูลจาก Point cloud ที่ใช้เซนเซอร์วัดระยะด้วยแสงในการตรวจวัดรอบตัวรถอยู่ตลอดเวลา นั้น สามารถที่จะนำมาใช้ในการระบุตำแหน่งของวัตถุ

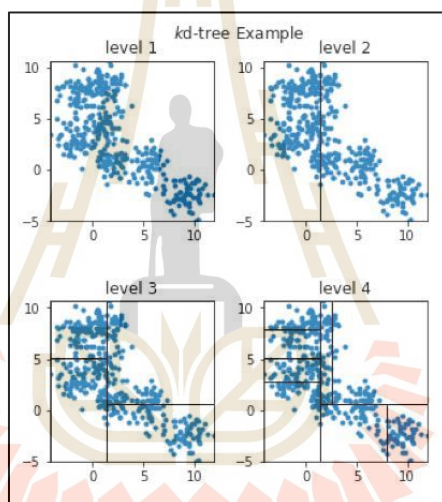
ต่างๆ ที่อยู่รอบๆ ได้ โดยการแบ่งกลุ่มข้อมูล Point cloud จากการศึกษาของ Anjani Josyula et al. (2019) ได้ใช้วิธีการแบ่งกลุ่ม Point cloud แบบ Euclidean Clustering สำหรับจำแนกวัตถุที่อยู่รอบยานยนต์อัตโนมัติแบบเวลาจริง โดยข้อมูล Point cloud ที่ได้จาก Lidar จะถูกกรองด้วย Voxel grid และนำมาแบ่งเป็นส่วนย่อยๆ ด้วยวิธีการ Slicing โดยใช้มุมมองในแนวตั้งเป็นตัวแบ่งส่วน จากนั้นข้อมูลในแต่ละส่วนจะถูกลบส่วนที่เป็นพื้นถนนด้วยวิธี Ground removal คือใช้อัลกอริทึมที่ชื่อว่า RANSAC ในการหาว่า Point cloud ส่วนไหนเป็นระนาบและกำจัดออกไป แล้วใช้ Euclidean clustering ในการรวมกลุ่ม Point cloud ที่อยู่ใกล้กันและนิยามให้เป็นวัตถุชนิดเดียวกัน จากการทดลองโดยใช้ข้อมูล Point cloud 2 ส่วน จาก KITTI dataset ที่เป็นข้อมูลของ Lidar 64 channel และข้อมูลที่ใช้ Lidar 16 channel เก็บจากภายใน Indian Institute of Technology – Hyderabad แล้วนำมาประมวลผลด้วยหน่วยประมวลผลแบบ Intel core i5 2.8 GHz พบว่าผลการแบ่งกลุ่มสามารถแยกวัตถุจำพวก คน รถ และสิ่งก่อสร้างต่างๆออกได้ โดยที่ ความเร็วในการประมวลผลแต่ละเฟรมที่ความละเอียดสูงสุดของข้อมูลจาก KITTI อยู่ที่ 500 ms และข้อมูลที่เก็บเองอยู่ที่ 50 ms หมายความว่า การแยกวัตถุด้วยข้อมูล Point cloud ด้วยวิธีการแบบ Euclidean นี้ สามารถใช้งานได้ ในเวลาจริง ซึ่งการแบ่งกลุ่ม Point cloud เป็นวิธีที่สามารถนำมาใช้งานในเวลาจริงได้ ดังนั้นการรับรู้ตำแหน่งของวัตถุต่างๆรอบตัวยานยนต์ก็สามารถที่จะตอบสนองได้ตลอดเวลาไม่ว่าจะเป็นวัตถุที่กำลังเคลื่อนที่ อาทิเช่น คนกำลังเดินข้ามถนน รถที่กำลังวิ่งอยู่บนถนน หรือวัตถุที่อยู่นิ่งๆ บนท้องถนนและรอบข้าง อาทิเช่น กรวยจราจร บ้ายซ่อมถนน



รูปที่ 2.18 (ซ้าย) Point cloud ขาเข้า (ขวา) Point cloud ที่ได้จากการแบ่งกลุ่มด้วยวิธี Euclidean Clustering (Anjani Josyula, 2019)

การแบ่งกลุ่มข้อมูล Point cloud แบบ Euclidean Clustering นั้น จะเริ่มพิจารณาที่ Point cloud ขาเข้าแต่ละเฟรม ซึ่งข้อมูล Point cloud 3 มิติ สำหรับยานยนต์อัตโนมัติเป็นข้อมูลที่มีขนาดใหญ่ โดยข้อมูล Point cloud ขาเข้าจะถูกแบ่งเป็นกล่องย่อยๆ ด้วยวิธี K-D tree

วิธีการค้นหาแบบ K-D tree หรือ K-Dimensions tree เป็นวิธีการแบ่งกลุ่มข้อมูล Point cloud ออกที่ละสองส่วนของแต่ละแกน โดยจัดเรียงข้อมูลในแต่ละแกนเพื่อคำนวณค่ามัธยฐานของข้อมูล Point cloud ในแกนนั้นๆ เมื่อแบ่งครบทุกแกนในครั้งแรก จะได้กล่องสี่เหลี่ยมที่บรรจุข้อมูล Point cloud จำนวน 2 กล่อง ที่มีจำนวนของ Point cloud ในทั้งสองกล่องเท่าหรือเกือบเท่ากัน ดังตัวอย่างในรูปที่ 2.17 จากนั้นจะเกิดกระบวนการนี้ซ้ำจนกว่าในแต่ละกล่องจะมีจำนวนข้อมูล Point cloud ตรงกับจำนวนที่ต้องการ



รูปที่ 2.19 ตัวอย่างกระบวนการ K-D tree แบบ 2 มิติ (Jeremy Jordan, 2019)

ข้อมูลกล่องย่อยที่บรรจุ Point cloud นั้นเป็นตัวแทนของข้อมูล Point cloud กลุ่มเล็กๆ จะถูกนำมาคำนวณเพื่อหาระยะห่างระหว่างแต่ละกล่องโดยใช้จุดกึ่งกลางของกล่องเป็นจุดวัด โดยใช้การวัดระยะห่างแบบ Euclidean distance ในการวัดเทียบ

2.4 การตัดสินใจของยานยนต์อัตโนมัติ

ข้อมูลที่ถูกประมวลผลจากส่วนการรับรู้ของยานยนต์อัตโนมัติ จะถูกนำมาใช้ในการจัดการ การเคลื่อนที่ของยานยนต์อัตโนมัติจากจุดเริ่มต้นไปยังเป้าหมายของการเดินทาง โดยการประมวลผล ในส่วนแรกคือการสร้างเส้นทาง (Path planner) เป็นการคำนวณจากข้อมูลตำแหน่งและแผนที่ของ ยานยนต์อัตโนมัติ จะสร้างจากข้อจำกัดที่สามารถให้รถขับเคลื่อนไปได้ ซึ่งระหว่างการเดินทางของ

ยานยนต์อัตโนมัติต้องใช้ในการสร้างเส้นทางเพื่อหลบหลีกสิ่งกีดขวาง (Obstacle avoidance) และส่วนของการควบคุมรถตามเส้นทางนั้น (Path tracking control)

2.4.1 การสร้างเส้นทางหลบหลีกสิ่งกีดขวาง


จากส่วนรับรู้ของยานยนต์อัตโนมัติ ในส่วนของการตัดสินใจส่วนแรกคือการสร้างเส้นทางของยานยนต์อัตโนมัติ โดยวิธีการที่ใช้ในการวางแผนเส้นทางหลบหลีกสิ่งกีดขวางของยานยนต์อัตโนมัติด้วยวิธี A-star ถูกนำเสนอโดย Saeid et al. (2019) โดยพัฒนาวิธีการหาเส้นทางด้วย A-star มาใช้กับรถยนต์ในพื้นที่สำหรับจอดรถ โดยทำการทดสอบบนสภาพแวดล้อมจริงและในโปรแกรมจำลองกว่า 1,000 ครั้งในสถานการณ์ที่แตกต่างกันออกไป ด้วยการทำงานของ A-star ที่ใช้ข้อมูล 2D grid map และตำแหน่งของยานยนต์และเป้าหมาย เพื่อหาเส้นทางที่สั้นที่สุดที่ยานยนต์อัตโนมัติจะขับเคลื่อนไปได้เร็วที่สุดโดยที่ไม่ชนสิ่งกีดขวาง พบว่าการทดลองครั้งนี้สามารถที่จะใช้ A-star ในการสร้างเส้นทางหลบหลีกได้ทั้งสิ่งกีดขวางที่เป็นวัตถุหยุดนิ่งและวัตถุที่กำลังเคลื่อนที่อยู่ได้ในเวลาจริง

1. การค้นหาเส้นทางแบบ A-star

การค้นหาเส้นทางในการเคลื่อนที่ที่ดีที่สุดจากจุดเริ่มต้นผ่านสิ่งกีดขวางไปยังเป้าหมายคือคำนิยามของอัลกอริทึม A-star ซึ่งเป็น Graph search algorithm ที่ถูกนำไปใช้ในการค้นหาเส้นทางอย่างกว้างขวางและเหมาะกับการนำมาใช้งานกับระบบของรถกอล์ฟอัตโนมัติ โดย A-star จะใช้วิธีการค้นหาเส้นทางและคำนวณค่าสำหรับการตัดสินใจในการผ่านจุดแต่ละจุด (Heuristic) ด้วยฟังก์ชัน $f(n)$ ที่ให้ค่าประมาณของค่า cost หรือทรัพยากรที่ต้องใช้ทั้งหมดของเส้นทางเคลื่อนที่ที่ผ่านจุด n โดย $f(n)$ สามารถคำนวณด้วยสมการ 2.5

$$f(n)=g(n)+h(n) \quad (2.5)$$

เมื่อ $f(n)$ คือ ค่าประมาณของ cost ทั้งหมดของเส้นทางที่เคลื่อนที่ผ่านที่ผ่านจุด n
 $g(n)$ คือ ค่า cost หรือทรัพยากรที่ใช้ตั้งแต่จุดเริ่มต้นจนถึงจุด n
 $h(n)$ คือ ค่าประมาณของค่า cost หรือทรัพยากรจากจุด n ถึงจุดหมาย



รูปที่ 2.20 ตัวอย่างการค้นหาเส้นทางการเคลื่อนที่ด้วย A-star (Chenguang Liu, 2019)


จากรูปที่ 2.20 เป็นตัวอย่างเส้นทางการเคลื่อนที่สีม่วงที่สร้างจากจุดเริ่มต้นจนถึงเป้าหมายของการเคลื่อนที่ โดยใช้การค้นหาด้วย A-star เพื่อเคลื่อนที่หลบสิ่งกีดขวางที่เป็นเครื่องหมายกากบาทสีแดง ลักษณะของการเคลื่อนที่จะเป็นเส้นทางการเคลื่อนที่ที่สั้นที่สุดที่จะไม่ชนสิ่งกีดขวางการเคลื่อนที่

2.4.2 การควบคุมยานยนต์อัตโนมัติตามเส้นทาง

การควบคุมยานยนต์ตามเส้นทางด้วย Pure pursuit control จะใช้จุดเป้าหมายจากเส้นทางที่มีระยะห่างจากยานยนต์ ที่เรียกว่า look-ahead distance โดยจะสร้างความสัมพันธ์ระหว่างตำแหน่งของยานยนต์เทียบกับเส้นทางการเคลื่อนที่ด้วยการเส้นโค้งระหว่างล้อหลังของยานยนต์กับจุดเป้าหมาย โดยเส้นโค้งนี้จะมีรัศมีเท่ากับระยะ R แล้วใช้ความโค้งของเส้นโค้งนี้ในการควบคุมมุมเลี้ยวของยานยนต์

การควบคุมยานยนต์อัตโนมัติให้เคลื่อนที่ตามเส้นทางนั้นมีวิธีการที่นิยมอยู่ 2 อัลกอริทึมคือ Pure Pursuit Control และ Model Predictive Control โดย Mohammad Rokonzaman et al. (2021) ได้ศึกษาเปรียบเทียบการควบคุมยานยนต์อัตโนมัติทั้งสองวิธี ซึ่งวิธีการควบคุมแบบ Pure Pursuit Control คือการควบคุมให้ยานยนต์อัตโนมัติเคลื่อนที่ไปยังเป้าหมายที่มีระยะห่างคือ look-ahead distance ด้วยการสร้างเส้นโค้งการเคลื่อนที่ เพื่อควบคุมทิศทางและความเร็วของยานยนต์จาก Kinematic model ของยานยนต์ ส่วนวิธีการควบคุมแบบ Model Predictive Control คือการควบคุมยานยนต์อัตโนมัติด้วยการประเมินสถานะล่วงหน้าของระบบ บนพื้นฐานของ Dynamic model ของยานยนต์ แล้วส่งคำสั่งล่าสุดไปควบคุมทิศทางและความเร็วของยานยนต์ พร้อมกับรับค่าสถานะมาประเมินซ้ำตลอดการเคลื่อนที่ โดยการศึกษาครั้งนี้ได้

ทำการทดลอง เปรียบเทียบค่าความผิดพลาดของการควบคุมในแนว lateral และ Orientation ของ ยานยนต์ในช่วงเวลาหนึ่ง ที่ความเร็วตั้งแต่ 20-60 km/h ซึ่งผลการทดลองได้สรุปไว้ว่าข้อดีของ Pure Pursuit Control นั้นง่ายต่อการนำมาใช้งานจริง มีความต้องการการประมวลผลที่ต่ำ มีประสิทธิภาพ ดีที่ความเร็วต่ำ และมีประสิทธิภาพในการติดตามเส้นทางได้ดีเมื่อจุดเริ่มต้นของยานยนต์อยู่ในเส้นทาง การเคลื่อน และข้อดีของ Model Predictive Control คือสามารถควบคุมภายใต้ตัวแปรของยานยนต์ที่หลากหลาย และมีประสิทธิภาพสูงในการควบคุม แต่แลกด้วยความต้องการในการประมวลผลที่สูง



รูปที่ 2.21 การควบคุมยานยนต์ตามเส้นทางด้วย Pure pursuit control (Mohammad Rokonzaman, 2021)

การควบคุมพวงมาลัยยานยนต์อัตโนมัติตามเส้นทางเคลื่อนที่แบบ pure-pursuit เป็นตัวควบคุมที่จะประมวลผลคำสั่งองศาการเลี้ยวให้กับหุ่นยนต์หรือยานยนต์ที่กำลังเคลื่อนที่ให้เข้าสู่จุด look-ahead point ในเส้นทางข้างหน้า โดยพิจารณาที่ความเร็วในทางตรงเป็นความเร็วคงที่ เมื่อยานยนต์เคลื่อนที่ จุด look-ahead point จะขยับไปข้างหน้าเช่นเดียวกับยานยนต์ โดยมีระยะห่างระหว่างยานยนต์กับ look-ahead point เท่ากับระยะ look-ahead distance ระยะ look-ahead distance เป็นระยะที่ยานยนต์มองจากตำแหน่งปัจจุบันเพื่อคำนวณคำสั่งองศาการเลี้ยวของพวงมาลัย จากรูปที่ 2.21 มีวิธีการคำนวณองศาการเลี้ยวของพวงมาลัยโดยอ้างอิงมุมการเลี้ยวจาก

โมเดล Kinematic แบบ car-like wheeled (R. Craig Coulter, 1990) จากรูปที่ 2.22 ด้วยสมการที่ 2.6 ดังนี้

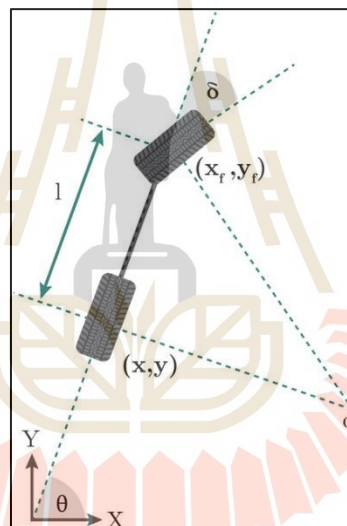
$$\delta = \tan^{-1} \left(\frac{2l \sin \alpha}{L} \right) \quad (2.6)$$

เมื่อ l_d คือ ระยะ look-ahead distance

L คือ ระยะฐานล้อของยานยนต์


α คือ มุมระหว่างทิศทางการเคลื่อนที่ของยานยนต์กับทิศทางระหว่างยานยนต์กับ look-ahead point

δ คือ องศาการเลี้ยวของพวงมาลัย



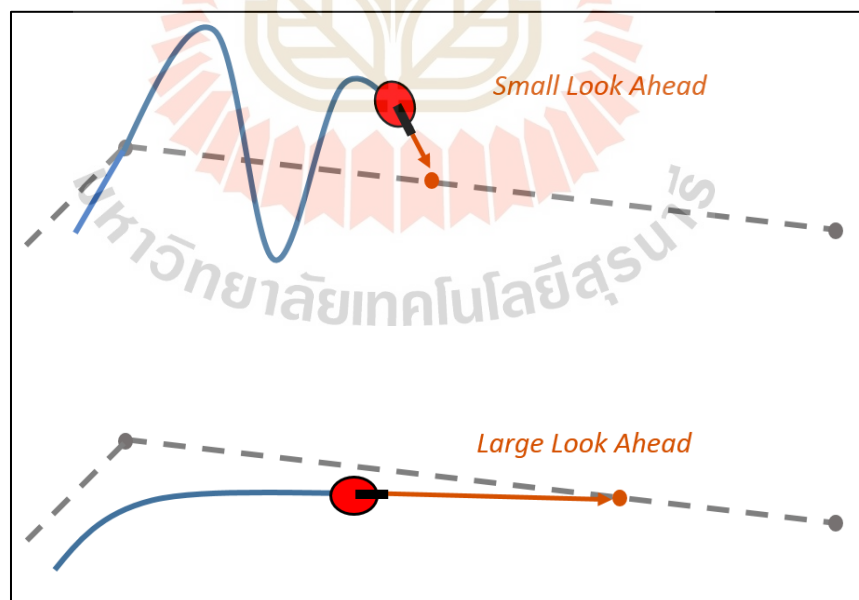
รูปที่ 2.22 Kinematic model ของ car-like wheeled vehicle (Mohammad Rokonzaman, 2021)

จากรูปที่ 2.23 ที่แสดงเส้นทางที่ยานยนต์เคลื่อนที่จริงจากการควบคุมด้วย pure pursuit เปรียบเทียบกับเส้นทางการเคลื่อนที่ waypoint และแสดงการมองไปที่ look-ahead point ด้วย ระยะ look-ahead distance



รูปที่ 2.23 Look-ahead distance และการเปรียบเทียบเส้นทางการเคลื่อนที่ที่ยานยนต์เคลื่อนที่ โดยควบคุมด้วย pure-pursuit กับ waypoint (R. Craig Coulter, 2022)

การปรับค่าระยะ *look-ahead distance* จะส่งผลให้เกิดความเปลี่ยนแปลงต่อการควบคุมยานยนต์ให้อยู่ในเส้นทาง การปรับให้ยานยนต์เคลื่อนเข้าเส้นทางการเคลื่อนที่ด้วยความเร็วที่มากขึ้น โดยใช้ระยะ *look-ahead distance* ที่น้อย จะทำให้ความคลาดเคลื่อนระหว่างจุด *look-ahead point* กับ heading ของยานยนต์มาก เมื่อตัวควบคุมส่งคำสั่งความเร็วเชิงมุมที่มีค่าเยอะกลับไปควบคุมยานยนต์ ก็จะทำให้เกิดผลลัพธ์ดังรูปที่ 2.24 ที่ จะเกิดการหลุดเส้นทางแบบ *Overshoot* ส่วนการปรับระยะ *look-ahead distance* ที่เยอะเกินไปก็จะส่งผลให้เกิดการเข้าสู่เส้นทางช้าและมีความโค้งที่เยอะกว่าเส้นทางการเคลื่อนที่ในทางโค้ง



รูปที่ 2.24 ผลการเคลื่อนที่ของการปรับระยะ *look-ahead distance* ที่น้อยและเยอะเกินไป (R. Craig Coulter, 2022)

บทที่ 3

วิธีดำเนินการวิจัย

การศึกษานี้แนะนำเสนอการพัฒนากระบวนการควบคุมรถกอล์ฟไฟฟ้าอัตโนมัติ โดยใช้ข้อมูลจากกล้อง เซนเซอร์วัดระยะด้วยแสง (Lidar) และแผนที่ สำหรับการระบุตำแหน่ง (Localization) ตรวจจับวัตถุแบบ 3 มิติ (3D Object detection) การสร้างเส้นทางการเคลื่อนที่ (Path planning) และการควบคุมรถกอล์ฟตามเส้นทาง (Path tracking control)

3.1 การเตรียมการ

ในขั้นตอนการเตรียมการได้ดำเนินการตามลำดับต่อไปนี้

3.1.1 การศึกษาค้นคว้าและรวบรวมงานวิจัยที่เกี่ยวข้อง

ศึกษาวิธีการ กระบวนการ และค้นคว้าหาความรู้จากเอกสารงานวิจัย วารสารวิชาการ หนังสือ และบทความต่างๆที่เกี่ยวข้อง ได้แก่ ทฤษฎีการมองเห็นของเครื่องจักร (Machine vision) หลักการของปัญญาประดิษฐ์ (Artificial intelligence) กระบวนการในการพัฒนาการเรียนรู้ของเครื่องจักร (Machine learning) กระบวนการตรวจจับวัตถุด้วยปัญญาประดิษฐ์ ทั้งการตรวจจับแบบ 2 มิติ และ 3 มิติ หลักการทำงานของ Convolution Neural Network สำหรับการประมวลผลภาพ หน่วยประมวลผลสำหรับการประมวลผลภาพ เซนเซอร์ที่ใช้ในยานยนต์อัตโนมัติ ระบบควบคุมการทำงานของระบบขับเคลื่อนแบบ Drive-by-wire ในรถกอล์ฟไฟฟ้า การทำแผนที่ด้วย Lidar การสร้างแผนที่ High Definition map ลำดับการตัดสินใจของผู้ขับขี่รถยนต์และยานยนต์อัตโนมัติ การระบุตำแหน่งของยานยนต์อัตโนมัติ การควบคุมความเร็วและการเคลื่อนที่ของยานยนต์อัตโนมัติ รวมถึงหลักการเขียนและวิธีการใช้ภาษาทางคอมพิวเตอร์สำหรับซอฟต์แวร์ Robot Operating System คือภาษา C++ และ ภาษา Python

3.1.2 การเตรียมรถกอล์ฟไฟฟ้า

รถกอล์ฟไฟฟ้าจะต้องทำการออกแบบอุปกรณ์จับยึดและตำแหน่งในการติดตั้งเซนเซอร์คือกล้อง Webcam Logitech C920 และเซนเซอร์วัดระยะด้วยแสง Velodyne Puck VLP-16 Lidar ที่ด้านหน้ารถกอล์ฟ และออกแบบตำแหน่งติดตั้งหน่วยประมวลผลกลางที่ด้านหลังรถ รวมถึงการเดินระบบไฟให้อุปกรณ์ต่างๆ จากแบตเตอรี่ของรถกอล์ฟ โดย Lidar นั้นจะต้องรับไฟ 12 Vdc จากแบตเตอรี่ ส่วนกล้องจะสามารถใช้ไฟจากสายเชื่อมต่อแบบ USB ที่เชื่อมกับหน่วยประมวลผลกลางของรถกอล์ฟได้โดยตรง และหน่วยประมวลผลกลางของรถกอล์ฟนั้นจะใช้ไฟ 48 Vdc จากแบตเตอรี่ของรถกอล์ฟ

หน่วยประมวลผลของรถกอล์ฟอัตโนมัตินั้นจะต้องถูกนำไปใช้ในการประมวลผลข้อมูลจากหลายทางที่เข้ามาพร้อมกัน ทั้งข้อมูลภาพถ่ายจากกล้องและข้อมูล Point cloud จาก Lidar ซึ่งจำเป็นจะต้องมีประสิทธิภาพที่เพียงพอต่อการประมวลผลแบบเวลาจริง ในการศึกษาครั้งนี้จึงเลือกใช้หน่วยประมวลผลแบบคอมพิวเตอร์ขนาดเล็กส่วนบุคคล (Mini-ITX PC) ที่ประกอบไปด้วยหน่วยประมวลผลกลาง Intel CORE I7-11700K และหน่วยประมวลผลด้านภาพ Nvidia Geforce RTX3080Ti




รูปที่ 3.1 การติดตั้งหน่วยประมวลผลกลางด้านหลังรถกอล์ฟไฟฟ้า



รูปที่ 3.2 การติดตั้งเซนเซอร์ด้านหน้ารถกอล์ฟไฟฟ้า

3.1.3 ทดสอบเซนเซอร์


กล้องและ Lidar ที่ติดตั้งบนรถกอล์ฟไฟฟ้าจะต้องใช้ซอฟต์แวร์ในการรับค่าขาเข้า โดยการรับข้อมูลจะใช้ไลบรารีของ Robot Operating System โดยกล้องจะส่งข้อมูลรูปภาพออกมาเป็น array ที่มี 3 ชั้น ส่วน Lidar จะส่งข้อมูลแอสแกน Point cloud แบบ 3 มิติ และนอกจากนี้ การใช้งานกล้องจะต้องมีการสอบเทียบ เพื่อชดเชยความผิดเพี้ยนและความบิดเบี้ยวของภาพที่ได้ โดยวิธีการ Intrinsic camera calibration ที่จะบันทึกภาพตารางหมากรุกในมุมต่างๆ สำหรับคำนวณหา transform matrix




รูปที่ 3.3 การสอบเทียบกล้องด้วยตารางหมากรุก

3.1.4 การสร้างแผนที่ความละเอียดสูง (High-definition map) และการทดสอบ

การสร้างแผนที่ความละเอียดสูงของยานยนต์อัตโนมัติในงานวิจัยนี้จะแบ่งออกเป็น 2 ส่วน โดยส่วนแรกคือเขียนคำสั่งในระบบของ Robot Operating System ในการรับค่าข้อมูลสแกน Point cloud มาประมวลผลด้วย Normal distribution transform mapping ซึ่งมีวิธีการคือ จะต้องนำรถกอล์ฟไฟฟ้าที่ควบคุมด้วยมือไปขับขึ้นเพื่อเก็บข้อมูล Point cloud รอบบริเวณพื้นที่การทำงานของรถกอล์ฟอัตโนมัติ โดยใช้ความเร็วที่ไม่เกิน 10 กิโลเมตรต่อชั่วโมง ซึ่งจะได้แผนที่ Point cloud map ที่เป็นแผนที่ 3 มิติ ออกมาในส่วนแรก ในขั้นตอนนี้จะดำเนินการสร้างแผนที่ทั้งหมด 3 แผนที่ เพื่อนำไปทดสอบความถูกต้องของขนาดของแผนที่

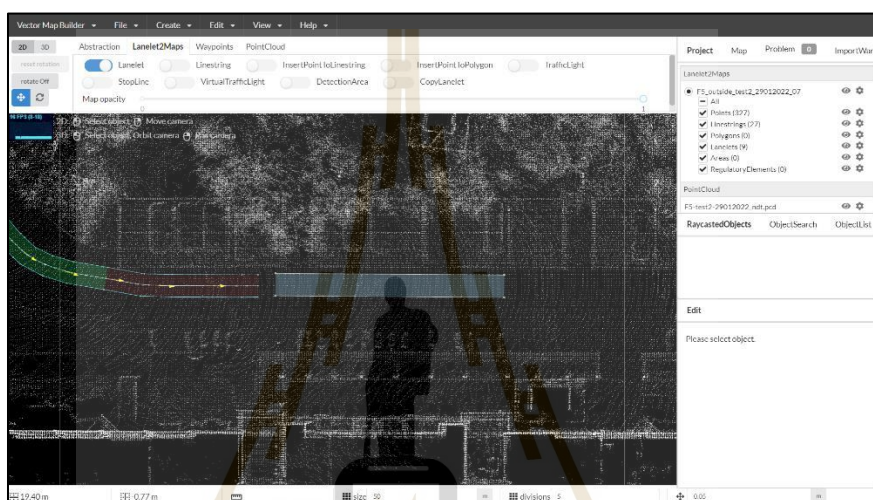


รูปที่ 3.4 Point cloud map ภายในอาคารเครื่องมือ 5



รูปที่ 3.5 Point cloud map ด้านหน้าอาคารเครื่องมือ 5

จากนั้น ข้อมูลแผนที่ Point cloud จะถูกนำไปใช้ในการอ้างอิงพิกัด เพื่อสร้างเส้นทางการเคลื่อนที่หรือช่องจราจรของรถกอล์ฟอัตโนมัติด้วยเครื่องมือ Tier4 tools ซึ่งจะต้องอ้างอิงตามขนาดและทิศทางของการเคลื่อนที่ตามช่องจราจรจริง ดังรูปที่ 3.6 โดยสุดท้ายจะได้แผนที่ความละเอียดสูงในรูปแบบที่มีชื่อว่า Lanelet2 ที่ประกอบไปด้วยช่องจราจรสำหรับการเคลื่อนที่ของรถกอล์ฟอัตโนมัติ และข้อมูลแผนที่ Point cloud สำหรับการระบุสิ่งก่อสร้างและการระบุตำแหน่งของรถกอล์ฟอัตโนมัติ



รูปที่ 3.6 การสร้างเส้นทางการเคลื่อนที่ด้วยเครื่องมือ Tier4 tools


3.2 การพัฒนาระบบขับเคลื่อนอัตโนมัติ

การพัฒนาระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟไฟฟ้า นั้นจะเขียนคำสั่งบนโปรแกรม Robot operating system หรือ ROS โดยใช้ข้อมูลที่ได้จากเซนเซอร์ และแผนที่ High definition map ที่ดำเนินการจัดเตรียมและทดสอบไว้ในส่วนแรก มาใช้ในการประมวลผลเพื่อควบคุมการเคลื่อนที่ของรถกอล์ฟอัตโนมัติ โดยแยกหัวข้อในการพัฒนาระบบต่างๆ ออกเป็นหัวข้อย่อยได้ดังนี้


3.2.1 การระบุตำแหน่งของรถกอล์ฟ (Localization)

การพัฒนาระบบระบุตำแหน่งของรถกอล์ฟอัตโนมัติ เริ่มต้นด้วยการเขียนคำสั่งในระบบ ROS เพื่อรับข้อมูล point cloud map จากแผนที่ High definition map และข้อมูลสแกน point cloud จากเซนเซอร์ Lidar เพื่อนำมาประมวลผลด้วยวิธี Normal distribution transform localization โดยในการเริ่มต้นการทำงานของระบบระบุตำแหน่งจำเป็นต้องให้ระบบของรถกอล์ฟนี้รู้ตำแหน่งเริ่มต้นด้วย คือจะต้องให้พิกัดตำแหน่งเริ่มต้นในแต่ละแกนการเคลื่อนที่ หรือเริ่มต้นการ

ทำงานระบบระบุตำแหน่งที่จุด 0,0,0 ของแผนที่ เมื่อระบบระบุตำแหน่งสามารถทำงานได้แล้วจะต้องมีการทดสอบและการวัดผล โดยการทดสอบระบบระบุตำแหน่งของรถกอล์ฟจะใช้วิธีการกำหนดจุดอ้างอิงจำนวน 12 จุด ตามเส้นทางการเคลื่อนที่ของรถกอล์ฟอัตโนมัติ ซึ่งจุดอ้างอิงนี้จะใช้พิกัดจากการวัดในแผนที่ Point cloud map ด้วยเครื่องมือ Cloud compare ดังรูปที่ 3.7 เพื่อเปรียบเทียบกับ การทดสอบด้วยการควบคุมรถกอล์ฟพร้อมกับการเปิดระบบระบุตำแหน่งไปที่จุดอ้างอิงแต่ละจุด ซึ่งจะให้จุดกึ่งกลางระหว่างล้อหลังของรถกอล์ฟเป็นจุดที่รถกอล์ฟใช้ในการระบุตำแหน่ง โดยจุดอ้างอิงแต่ละจุดในพื้นที่ทดสอบจะติดเทปแสดงตำแหน่งไว้ดังรูปที่ 3.8



รูปที่ 3.7 การทดสอบการระบุตำแหน่งด้วย NDT ภายในอาคารเครื่องมือ 5




รูปที่ 3.8 ตำแหน่งของการวัดเทียบเพื่อทดสอบความแม่นยำของระบบระบุตำแหน่งของรถกอล์ฟอัตโนมัติ



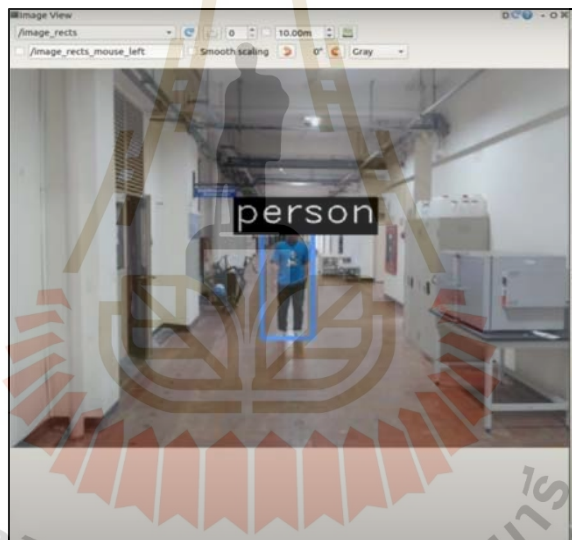
รูปที่ 3.9 แสดงขั้นตอนการวัดตำแหน่งเพื่อติดเทปจุดอ้างอิง

3.2.2 การตรวจจับวัตถุจากภาพ (2D Object Detection)


การพัฒนาาระบบตรวจจับวัตถุจากภาพถ่ายนั้นจะเลือกใช้โมเดล Convolutional Neural Network ที่มีชื่อว่า You Only Look Once v3 หรือ YOLOv3 โดยกระบวนการในการพัฒนาาระบบตรวจจับวัตถุสำหรับรถกอล์ฟอัตโนมัติมีขั้นตอนเริ่มต้นคือการเตรียมชุดภาพตัวอย่าง โดยใช้รถกอล์ฟบันทึกภาพคน รถยนต์และรถกอล์ฟ ในมุมมองและสภาพแสงต่างๆที่ครอบคลุมสภาพแวดล้อมของพื้นที่การทำงานของรถกอล์ฟอัตโนมัติ ซึ่งรูปภาพทั้งหมดนี้จะถูกเรียกว่าชุดข้อมูล หรือ Dataset แล้วนำภาพทั้งหมดที่อยู่ใน dataset มาทำกล่องสัญลักษณ์ ด้วยการใช้อุปกรณ์ที่มีชื่อว่า Supervise.ly (2021) ในการสร้างกรอบล้อมรอบคนและรถกอล์ฟที่ปรากฏในแต่ละภาพ จากนั้นจะต้องแบ่งภาพที่ทำสัญลักษณ์แล้วแบบสุ่มออกเป็นสัดส่วน 20:80 คือ test set 20% และ train set 80% แล้วนำข้อมูลที่อยู่ใน train set ไปผ่านกระบวนการเรียนรู้ของโมเดลและประมวลผลเพื่อหาค่า น้ำหนัก (Weight) ของโมเดล YOLOv3 ที่มีค่า loss ต่ำที่สุด ซึ่งค่าน้ำหนักนี้จะถูกนำไปทดสอบความสามารถในการการตรวจจับกับข้อมูลใน test set ซึ่งเป็นข้อมูลที่โมเดลไม่เคยเห็นมาก่อนและเป็นชุดข้อมูลที่แบ่งไว้เพื่อให้สามารถประเมินความแม่นยำและความถูกต้องของโมเดล โดยผลลัพธ์ที่ได้จากการตรวจจับวัตถุจากภาพใน test set จะถูกนำไปคำนวณเพื่อหาค่า Mean average precision หรือ mAP ของโมเดล เมื่อผ่านขั้นตอนนี้แล้วจำเป็นต้องวิเคราะห์ผลลัพธ์ของโมเดล ก่อน โดยเปรียบเทียบกับ mAP ของโมเดล YOLOv3 COCO เพื่อยืนยันความสามารถของโมเดลในการตรวจจับวัตถุในสภาพแวดล้อมการทำงานของรถกอล์ฟ แล้วจึงจะนำค่าน้ำหนักของโมเดลที่ผ่านการทดสอบและสรุปผลกับข้อมูลใน test set แล้ว ไปทดสอบกับสภาพแวดล้อมจริง ที่ช่วงเวลาต่างๆ



รูปที่ 3.10 ขั้นตอนการดำเนินการของการตรวจจับวัตถุด้วยภาพ



รูปที่ 3.11 ตัวอย่างการตรวจจับวัตถุจากภาพถ่ายด้วยกล้องหน้ารถกอล์ฟ



รูปที่ 3.12 แผนผังการทำงานของรถกอล์ฟไฟฟ้าอัตโนมัติระหว่างอาคาร

3.2.3 การแบ่งกลุ่มข้อมูล Point cloud

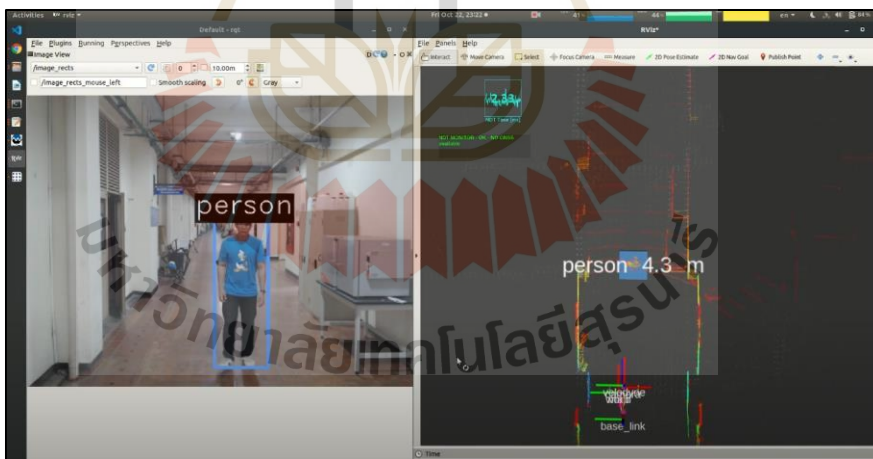
การระบุตำแหน่งของวัตถุใน 3 มิติ จะใช้การแบ่งกลุ่ม Point cloud แบบ Euclidean clustering มาแยกวัตถุแต่ละชิ้น โดยในกระบวนการนี้จะเขียนคำสั่งในการรับข้อมูล Point cloud จาก Lidar และประมวลผลการแบ่งกลุ่ม Point cloud เพื่อตรวจจับวัตถุแบบ 3 มิติ และทดสอบการประมวลผลโดยประมวลผลจากค่าความแม่นยำของตำแหน่ง และความถูกต้องของขนาดของวัตถุที่ตรวจจับได้จากการแบ่งกลุ่มของข้อมูล Point cloud



รูปที่ 3.13 การทดสอบการแบ่งกลุ่ม Point cloud ด้านหน้าของรถกอล์ฟ

3.2.4 การตรวจจับวัตถุ 3 มิติ (3D Object detection) และการทดสอบ

การพัฒนากระบวนการตรวจจับวัตถุใน 3 มิตินั้นจะเริ่มต้นจากการเขียนคำสั่งบนระบบ Robot operating system ในการรับข้อมูล Point cloud ที่แบ่งกลุ่มเป็นวัตถุต่างๆของสภาพแวดล้อมรอบข้างรถกอล์ฟแล้ว และข้อมูล Bounding box จากการตรวจจับวัตถุด้วยโมเดล YOLOv3 นำมารวมกันโดยใช้จุดกึ่งกลางของวัตถุจากการแบ่งกลุ่มของ Point cloud แต่ละวัตถุเปรียบเทียบกับพิกเซลกึ่งกลางของวัตถุที่ตรวจจับได้จากภาพถ่าย ด้วยการใช้ข้อมูลจากการสอบเทียบของ Extrinsic camera lidar calibration ในการเปรียบเทียบ และสร้างกล่อง 3 มิติ ล้อมรอบวัตถุ นั้นด้วยข้อมูลที่ได้จากแต่ละกลุ่มของ Point cloud เพื่อแสดงขนาดของวัตถุแต่ละชนิดที่ตรวจจับได้ และเพื่อใช้ในการระบุตำแหน่งของวัตถุนั้นลงบนแผนที่ grid map ในระหว่างที่รถกอล์ฟกำลังเคลื่อนที่แบบอัตโนมัติ เมื่อระบบตรวจจับวัตถุ 3 มิติ สามารถที่จะประมวลผลได้แล้วจะนำไปทดสอบ โดยการวัดระยะห่างระหว่างรถกอล์ฟกับตำแหน่งของวัตถุที่ตรวจจับได้ใน 3 มิติ เทียบกับระยะจริง ด้วยสายวัดระยะ โดยแบ่งช่วงในการวัดคือตั้งแต่ระยะ 1 เมตร และเพิ่มขึ้นครั้งละ 1 เมตร ทำการทดสอบซ้ำ 3 ครั้ง เพื่อหาความแม่นยำและความคลาดเคลื่อนของการระบุตำแหน่ง และช่วงระยะและความสามารถในการตรวจจับวัตถุใน 3 มิติ



รูปที่ 3.14 การทดสอบการตรวจจับและระบุตำแหน่งของวัตถุใน 3 มิติจากรถกอล์ฟ

3.2.5 การสร้าง Grid map

การควบคุมด้วยระบบอัตโนมัติของรถกอล์ฟจะใช้วิธีการตัดสินใจบนแผนที่ 2 มิติ หรือเรียกว่า Grid map โดยในการสร้างแผนที่ Grid map นั้นจะเริ่มจากการเขียนคำสั่งรับข้อมูลแผนที่ High definition map ทั้งข้อมูล Point cloud map และข้อมูลช่องจราจร ข้อมูลการระบุตำแหน่งของรถกอล์ฟ ข้อมูลตำแหน่งของวัตถุจากการตรวจจับวัตถุแบบ 3 มิติ ข้อมูลสแกน Point cloud


ของรถกอล์ฟ แล้วนำประมวลผลข้อมูลทั้งหมดลงในแผนที่ Grid map ที่มีความละเอียด 0.05 เซนติเมตร โดยให้ตำแหน่งที่มันวัตภูมิค่าเท่ากับ 1 และตำแหน่งที่รถกอล์ฟสามารถเคลื่อนที่ไปได้มีค่าเท่ากับ 0 ซึ่งจะต้องกำหนดช่วงความสูงของข้อมูลวัตถุที่จะบรรจุให้พื้นที่ตำแหน่งนั้นเป็นช่วงที่ไม่อนุญาตให้รถกอล์ฟเคลื่อนที่ผ่าน ทั้งจากข้อมูลสแกน point cloud และจาก point cloud map

3.2.6 การสร้างเส้นทางหลบหลีกสิ่งกีดขวาง (Path planning)

สำหรับขั้นตอนการพัฒนาการสร้างเส้นทางหลบหลีกวัตถุหรือสิ่งกีดขวางของระบบขับเคลื่อนอัตโนมัติจะเริ่มต้นที่ การเขียนคำสั่งรับข้อมูลจาก Grid map ที่ระบุไว้แล้วว่าพื้นที่ในตำแหน่งไหนบ้างที่รถกอล์ฟจะสามารถขับเคลื่อนไปได้ และเส้นทางการเคลื่อนที่จากแผนที่ High definition map แล้วประมวลผลเส้นทางการเคลื่อนที่ใหม่สำหรับหลบหลีกสิ่งกีดขวางหรือหลบหลีกการชนด้วย A* avoidance โดยเส้นทางเคลื่อนที่ใหม่นี้จะต้องอยู่ในขอบเขตของช่องจราจร

3.2.7 การควบคุมรถตามเส้นทาง (Path tracking control) และการทดสอบ


ขั้นตอนของการพัฒนาระบบควบคุมรถกอล์ฟตามเส้นทางการเคลื่อนที่โดยใช้วิธีการควบคุมแบบ Pure pursuit นั้นเริ่มต้นโดยการเขียนคำสั่งเพื่อรับข้อมูลเส้นทางการเคลื่อนที่ที่ได้จากการสร้างเส้นทางหลบสิ่งกีดขวางหรือเส้นทางการเคลื่อนที่จากเส้นกลางของช่องจราจร และประมวลผลด้วย Pure pursuit สำหรับควบคุมยานยนต์อัตโนมัติให้ขับเคลื่อนไปตามเส้นทางการเคลื่อนที่ที่ไม่มีสิ่งกีดขวาง โดยข้อมูลที่ได้จาก Pure Pursuit จะประมวลผลเทียบกับ Kinematic model ของรถกอล์ฟเพื่อส่งคำสั่งไปควบคุมองศาการเลี้ยวของพวงมาลัยที่อยู่ในการควบคุมของระบบ Low level control ซึ่งในขั้นตอนนี้จะต้องปรับตั้งค่า look-ahead distance ให้เหมาะสมกับระบบอีกด้วย



รูปที่ 3.15 การทดสอบการควบคุมรถกอล์ฟด้วย Pure Pursuit Control

3.2.8 การควบคุมความเร็วในทางโค้ง


การควบคุมความเร็วของการขับเคลื่อนด้วยระบบอัตโนมัติของรถกอล์ฟในทางตรงหรือทางเลี้ยวหรือการเข้าโค้งจะต้องใช้ความเร็วที่แตกต่างกัน เนื่องจากความความเร่งหรือการเปลี่ยนแปลงความเร็วโดยฉับพลันจะทำให้เกิดแรงที่ส่งผลกระทบต่อผู้โดยสาร โดยแรงที่สามารถควบคุมได้สำหรับระบบอัตโนมัติของรถกอล์ฟจะเป็นแรงในแนวแกน Longitudinal คือแรงที่เกิดจากการเร่งหรือเบรก และแกน Lateral คือแรงเหวี่ยงที่เกิดจากการขับเคลื่อนเข้าทางโค้ง ส่วนแรงที่กระทำในแนวแกน Vertical นั้นเกิดจากแรงกระตุ้นจากสภาพพื้นผิวถนนที่ขับเคลื่อนผ่าน ซึ่งจะสามารถควบคุมด้วยการปรับตั้งค่าระบบช่วงล่างของรถกอล์ฟ โดยแรงในแต่ละแนวแกนได้ถูกแสดงในรูปที่ 3.16



รูปที่ 3.16 แสดงแรงที่เกิดขึ้นในแต่ละแกนระหว่างการเคลื่อนที่ของรถยนต์ (Bir Armaan Singh Gill, 2018)

จากการศึกษาแรงที่เกิดจากความเร่งที่ส่งผลกระทบต่อผู้โดยสารของรถสาธารณะของ Il Bae (2019) นั้นพบว่า ความเร่งในแนวแกน Lateral และ Longitudinal ไม่ควรมีค่าเกิน 0.9-1.47 เมตรต่อวินาที² และจากการศึกษาเพื่อวิเคราะห์แรงจากการขับเคลื่อนที่ส่งผลกระทบต่อผู้โดยสารของ Il Bae (2019) นั้นพบว่ามนุษย์จะมีความรู้สึกสั่นสะเทือนอย่างมากกับแรงที่เกิดขึ้นในช่วงความถี่ 4-16.5 Hz สำหรับแกน Lateral และ Longitudinal ดังนั้น งานวิจัยนี้จะทำการทดสอบโดยการติดตั้งเซนเซอร์วัดความเฉื่อยเข้ากับรถกอล์ฟ โดยใช้ Xsense MTi-30 ติดตั้งบริเวณกึ่งกลางให้ใกล้เคียงตำแหน่งของจุดศูนย์ถ่วงของรถกอล์ฟมากที่สุด แล้วออกแบบการทดลองให้รถกอล์ฟอัตโนมัติขับเคลื่อนในเส้นทางเคลื่อนที่ในพื้นที่ทดสอบด้วยความเร็วคงที่ เพื่อวัดความเร่งที่เกิดขึ้นในแนวแกน Lateral และ Longitudinal เมื่อเคลื่อนที่ผ่านทางโค้งในพื้นที่ทดสอบ โดยแบ่งออกเป็น 5 ช่วงความเร็ว คือ

ความเร็วตั้งแต่ 5-10 กิโลเมตรต่อชั่วโมง เพื่อวิเคราะห์หาความเร็วที่เหมาะสมกับการเข้าโค้งในสถานที่ทดสอบและนำไปปรับใช้กับการขับเคลื่อนด้วยระบบอัตโนมัติ



รูปที่ 3.17 เซนเซอร์วัดความเฉื่อยและจุดติดตั้งบนรถกอล์ฟไฟฟ้า

3.3 การทดสอบระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟไฟฟ้า


ระบบขับเคลื่อนอัตโนมัติที่ถูกพัฒนาให้ใช้งานกับรถกอล์ฟจะต้องทดสอบการทำงานร่วมกันทั้งหมดและวิเคราะห์ผลของการทดสอบ โดยแบ่งวิธีการทดสอบออกเป็นสามส่วนย่อยคือ ทดสอบการเคลื่อนที่อัตโนมัติจากจุดเริ่มต้นไปจนถึงเป้าหมาย ทดสอบระบบเบรกอัตโนมัติเมื่อมีสิ่งกีดขวางอยู่ในเส้นทางการเคลื่อนที่ของรถกอล์ฟ และทดสอบระบบหลบหลีกสิ่งกีดขวาง

การทดสอบการขับเคลื่อนอัตโนมัติของรถกอล์ฟจะใช้วิธีการคือกำหนดจุดเป้าหมายการเดินทาง จากนั้น ให้รถกอล์ฟขับเคลื่อนอัตโนมัติไปตามเส้นทางการเคลื่อนที่ในพื้นที่ทดสอบ เพื่อดูผลการตอบสนองของระบบควบคุมมุมเลี้ยวของรถกอล์ฟ และการระบุตำแหน่งที่พิกัดต่างๆที่เคลื่อนที่ผ่าน

การทดสอบระบบเบรกอัตโนมัติจะดำเนินการต่อเนื่องกับการทดสอบการขับเคลื่อนอัตโนมัติ โดยออกแบบให้การทดสอบมีสิ่งกีดขวางที่เป็นคนยืนขวางเส้นทางการเคลื่อนที่แบบอยู่กับที่ และให้รถกอล์ฟดำเนินการขับเคลื่อนอัตโนมัติ เพื่อดูพฤติกรรมในการตรวจจับวัตถุ การลดความเร็ว และระบบเบรกอัตโนมัติของรถกอล์ฟ

ในส่วนสุดท้ายเป็นการทดสอบระบบหลบหลีกสิ่งกีดขวางของรถกอล์ฟ จากการที่การขับเคลื่อนอัตโนมัติของรถกอล์ฟนั้นจำเป็นต้องเคลื่อนที่อยู่ในช่องจราจรเท่านั้น ดังนั้น ในการทดสอบครั้งนี้จึงได้เพิ่มขนาดความกว้างของช่องจราจรบนแผนที่ High definition map จากเดิม 2 เมตร เป็น 4 เมตร เฉพาะช่วงที่ทดสอบ ดังรูปที่ 3.18 โดยมีวิธีการทดสอบเช่นเดียวกับระบบเบรกอัตโนมัติ

คือให้สิ่งกีดขวางที่เป็นคนยืนอยู่ในตำแหน่งที่ขวางเส้นทางการเคลื่อนที่ของรถกอล์ฟ แล้วให้รถกอล์ฟเคลื่อนที่อัตโนมัติ เพื่อดูผลการตอบสนองของการควบคุมรถกอล์ฟให้หลบสิ่งกีดขวาง




รูปที่ 3.18 แผนสำหรับทดสอบระบบหลบหลีกเลี่ยงสิ่งกีดขวาง



บทที่ 4 ผลการวิจัยและอภิปรายผล

4.1 ผลการสร้างแผนที่ความละเอียดสูง

การสร้างแผนที่ High definition map สำหรับรถกอล์ฟที่ใช้รูปแบบของ lanelet2 นั้นได้แบ่งกระบวนการดำเนินงานออกเป็น 2 ส่วน คือส่วนที่เป็น Point cloud map และส่วนต่อเนื่องที่เป็นการสร้างเส้นทางการเคลื่อนที่ ซึ่งจากผลการดำเนินการสร้างแผนที่ข้อมูล Point cloud ของสถานที่ทดสอบ ณ ถนนบริเวณอาคารเครื่องมือ 5 ด้วยการใช้ Normal distribution transform mapping เพื่อประสานข้อมูล Point cloud เป็นแผนที่แบบ 3 มิติ โดยทดลองสร้างแผนที่ Point cloud map จำนวน 3 แผนที่ จากการควบคุมรถกอล์ฟ 3 รอบตามช่องจราจร ข้อมูลแผนที่เหล่านี้ได้ถูกนำมาทดสอบความถูกต้องด้วยการเปรียบเทียบขนาดของแผนที่กับขนาดของพื้นที่ทดสอบจริง โดยใช้วิธีการวัดระยะในจุดต่างๆ ของแผนที่ Point cloud บนโปรแกรม Cloud compare เทียบกับระยะจริงที่ใช้สายวัดระยะในการวัด จำนวน 8 จุด เพื่อหาความคลาดเคลื่อนของการสร้างแผนที่ Point cloud ซึ่งตำแหน่งในการวัดเทียบได้แสดงดังรูปที่ 4.1



รูปที่ 4.1 แสดงจุดวัดเทียบค่าความคลาดเคลื่อนบนแผนที่ Point cloud 8 จุด


ตารางที่ 4.1 ผลการวัดความผิดพลาดของแผนที่ Point cloud map

ตำแหน่งวัด	ระยะทาง (เมตร)			ความคลาดเคลื่อน (%)			
	Ground truth	แผนที่ 1	แผนที่ 2	แผนที่ 3	แผนที่ 1	แผนที่ 2	แผนที่ 3
1	7.91	7.97	7.87	7.84	0.75	0.51	0.88
2	6.75	6.72	6.69	6.80	0.47	0.89	0.74
3	12.3	11.98	12.38	12.41	2.57	0.65	0.89
4	9.35	9.44	9.21	9.46	0.95	1.50	1.18
5	22.36	22.13	22.44	22.76	1.05	0.36	1.79
6	6.74	6.69	6.88	6.81	0.77	2.08	1.04
7	11.15	11.21	10.95	11.47	0.57	1.79	2.87
8	8.05	8.22	7.92	7.98	2.13	1.61	0.87


จากผลการเปรียบเทียบระยะจริงของพื้นที่ทดสอบ (Ground truth) กับระยะที่วัดจากแผนที่ Point cloud ได้ผลดังตารางที่ 4.1 สำหรับแผนที่ Point cloud หมายเลข 1 เมื่อเทียบระยะทางของจุดวัดแต่ละตำแหน่งแล้วพบว่าความคลาดเคลื่อนที่เกิดขึ้นนั้นอยู่ในระดับเซนติเมตร โดยตำแหน่งที่มีความคลาดเคลื่อนสูงที่สุดมีความคลาดเคลื่อน 0.32 เมตร ซึ่งเท่ากับ 2.57% ซึ่งความคลาดเคลื่อนนี้เกิดจากการรวมกันของความคลาดเคลื่อนของ Normal distribution transform mapping และความคลาดเคลื่อนจากการเลือกจุดวันในแผนที่ Point cloud เช่นเดียวกับกับแผนที่ Point cloud หมายเลข 2 และ 3 ซึ่งสามารถสรุปเป็นความคลาดเคลื่อนเฉลี่ย โดยความคลาดเคลื่อนเฉลี่ยของแผนที่หมายเลข 1, 2 และ 3 นั้นมีค่าอยู่ที่ 1.15 %, 1.17 % และ 1.28 % ตามลำดับ ดังนั้น จากการสร้างแผนที่ Point cloud และการทดสอบหาความคลาดเคลื่อนของแผนที่ทั้งหมด ในงานวิจัยนี้จึงเลือกแผนที่หมายเลข 1 เป็นแผนที่หลักสำหรับการสร้างแผนที่ High definition map สำหรับการทดสอบยานยนต์อัตโนมัติ

แผนที่ Point cloud ที่ได้จากการสแกนพื้นที่ทดสอบที่มีค่าความคลาดเคลื่อนของการทดสอบต่ำที่สุดได้ถูกเลือกให้นำมาสร้างเส้นทางการเคลื่อนที่ โดยอ้างอิงจากช่องจราจรจริงบนถนนในพื้นที่ทดสอบ ซึ่งเครื่องมือ Tier4tools นั้นเป็นเครื่องมือที่ใช้สำหรับการจัดการแผนที่ High definition map แบบ Lanelet2 ได้ถูกนำมาใช้เป็นเครื่องมือในการจัดการและการสร้างเส้นทางการเคลื่อนที่นี้ โดยกำหนดระยะขอบเขตของเส้นทางการเคลื่อนที่ให้มีระยะใกล้เคียงกับขนาดช่องจราจร


ซึ่งใช้ความกว้าง 2 เมตรเท่ากันตลอดเส้นทางการเคลื่อนที่ และมีทิศทางทางการเคลื่อนที่ของเส้นทางการเคลื่อนที่ทวนเข็มนาฬิกา ตามการทิศทางทางการเคลื่อนที่ของช่องจราจรฝั่งซ้ายของถนน ดังตัวอย่างของผลการสร้างแผนที่ High-definition map ในมุมมองต่างๆ จากรูปที่ 4.2, 4.3 และ 4.4



รูปที่ 4.2 แผนที่ High-definition map ของพื้นที่ทดสอบจากมุมมองด้านบน



รูปที่ 4.3 แผนที่ High-definition map ของพื้นที่ทดสอบจากมุมมองฝั่งอาคารเครื่องมือ 5



รูปที่ 4.4 แผนที่ High definition map ของพื้นที่ทดสอบจากมุมมองฝั่งอาคารเครื่องมือ 4

4.2 ผลการทดสอบระบบระบุตำแหน่งของรถกอล์ฟอัตโนมัติ

จากกระบวนการทดสอบการระบุพิกัดหรือตำแหน่งของรถกอล์ฟ เพื่อศึกษาความสามารถและความแม่นยำของการระบุตำแหน่งด้วย Normal distribution transform หรือ NDT สำหรับรถกอล์ฟอัตโนมัติ โดยใช้ข้อมูล Point cloud จาก Lidar เป็นข้อมูลในการอ้างอิงตำแหน่ง ซึ่งในเบื้องต้นวิธีการระบุตำแหน่งด้วยวิธี NDT ได้ถูกยืนยันถึงความแม่นยำไปบางส่วนแล้ว เนื่องจากเป็นวิธีการเดียวกันกับการระบุตำแหน่งในกระบวนการสร้างแผนที่ Point cloud จากหัวข้อที่ 4.1 และเพื่อให้แน่ใจว่าวิธีการระบุตำแหน่งแบบ NDT นั้นสามารถนำไปใช้งานสำหรับระบุตำแหน่งของวัตถุในรถกอล์ฟอัตโนมัติได้ จึงได้สรุปผลและวิเคราะห์ผลการทดสอบดังนี้

จากการทดสอบระบบระบุตำแหน่งของรถกอล์ฟอัตโนมัติที่บริเวณถนนหน้าอาคารเครื่องมือ 5 ที่เป็นสถานที่ทดสอบที่มีเส้นทางการเดินรถที่กว้างเพียงพอ ซึ่งจากการเปรียบเทียบตำแหน่งของรถกอล์ฟอัตโนมัติในแผนที่ Point cloud กับตำแหน่งที่คำนวณได้จากวิธี Normal distribution transform ด้วยข้อมูล Point cloud ของรถกอล์ฟ ทำให้สามารถสรุปผลความคลาดเคลื่อนจากการทดสอบทั้งหมด 12 จุด ในแกนการเคลื่อนที่ x และ y ได้ดังตารางที่ 4.2 และ 4.3


ตารางที่ 4.2 แสดงพิกัดของตำแหน่งที่วัดจากแผนที่เปรียบเทียบกับตำแหน่งจากทดสอบ

ตำแหน่งที่วัด	ตำแหน่ง (เมตร)							
	วัดจากแผนที่		วัดครั้งที่ 1		วัดครั้งที่ 2		วัดครั้งที่ 3	
	แกน x	แกน y	แกน x	แกน y	แกน x	แกน y	แกน x	แกน y
1	0.555	-0.702	0.689	-0.672	0.597	-0.748	0.643	-0.772
2	13.325	-0.705	13.141	-0.720	13.442	-0.661	13.272	-0.748
3	25.681	-0.700	25.536	-0.764	25.802	-0.747	25.710	-0.756
4	53.261	-0.902	53.304	-0.937	53.158	-0.982	53.341	-0.960
5	42.867	20.125	42.714	20.092	42.73	20.164	42.928	20.304
6	13.464	49.340	13.380	49.318	13.547	49.288	13.350	49.240
7	-18.060	76.472	-18.095	76.586	-18.140	76.441	-18.122	76.514
8	-30.344	59.043	-30.331	58.864	-30.284	59.230	-30.458	59.124
9	-30.300	45.517	-30.341	45.669	-30.322	45.449	-30.380	45.559
10	-30.300	33.084	-30.238	32.954	-30.347	32.894	-30.189	32.924
11	-29.901	15.696	-29.885	15.567	-29.795	15.821	-29.840	15.644
12	-15.125	-0.306	-15.221	-0.231	-15.082	-0.322	-15.162	-0.277

ตารางที่ 4.3 แสดงความคลาดเคลื่อนของพิกัดที่ทดสอบในแต่ละตำแหน่ง


ตำแหน่งที่วัด	ความคลาดเคลื่อนของตำแหน่ง (เมตร)					
	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	แกน x	แกน y	แกน x	แกน y	แกน x	แกน y
1	0.134	0.030	0.042	0.046	0.088	0.070
2	0.184	0.015	0.117	0.044	0.053	0.043
3	0.145	0.064	0.121	0.047	0.029	0.056
4	0.043	0.035	0.103	0.080	0.080	0.058
5	0.153	0.033	0.137	0.039	0.061	0.179
6	0.084	0.022	0.083	0.052	0.114	0.100
7	0.035	0.114	0.080	0.031	0.062	0.041
8	0.013	0.179	0.060	0.187	0.114	0.081
9	0.041	0.152	0.022	0.068	0.080	0.042
10	0.062	0.130	0.047	0.190	0.111	0.160
11	0.016	0.129	0.106	0.125	0.061	0.052
12	0.096	0.075	0.043	0.016	0.037	0.030

จากผลการทดสอบการระบุตำแหน่งของรถกอล์ฟอัตโนมัติ จากตารางที่ 4.2 ที่แสดงผลของการวัดตำแหน่งของรถกอล์ฟเทียบกับพิกัดของแผนที่ เปรียบเทียบกันระหว่างตำแหน่งจริงในแผนที่กับตำแหน่งที่แสดงบนรถกอล์ฟเมื่อเคลื่อนที่ไปที่จุดวัดแต่ละจุดของทั้ง 3 การทดสอบ จากนั้น ตารางที่ 4.3 ได้นำผลของการทดสอบการระบุตำแหน่ง จากตารางที่ 4.3 มาเพื่อหาความคลาดเคลื่อนของการระบุตำแหน่งในแต่ละแกน แต่ละจุด ของแต่ละการทดสอบ และสามารถนำมาสรุปหาความคลาดเคลื่อนเฉลี่ยของแต่ละการทดสอบ ในการทดสอบครั้งที่ 1 มีค่าความคลาดเคลื่อนของการระบุตำแหน่งเฉลี่ยที่ 0.082 เมตร การทดสอบครั้งที่ 2 มีค่าความคลาดเคลื่อนเฉลี่ย 0.078 เมตร และการทดสอบครั้งที่ 3 มีค่าความคลาดเคลื่อนเฉลี่ย 0.075 เมตร ซึ่งพบว่าความคลาดเคลื่อนเฉลี่ยของการทดสอบทั้งหมดมีค่าใกล้เคียงกัน และสามารถนำผลการทดสอบไปวิเคราะห์แยกในแต่ละแนวแกนได้ ดังรูปที่ 4.5 และ 4.6



รูปที่ 4.5 แสดงความคลาดเคลื่อนในแนวแกน x ของการทดสอบทั้งหมดในแต่ละตำแหน่งที่ทดสอบ

ผลความคลาดเคลื่อนของการระบุตำแหน่งจากตารางที่ 4.4 สามารถนำมาแสดงผลให้เห็นได้ชัดขึ้น ดังรูปที่ 4.5 เป็นกราฟแท่งแสดงความคลาดเคลื่อนในแต่ละจุดของแกน x ของทั้ง 3 การทดสอบ ซึ่งพบว่าในแนวแกน x มีการกระจายตัวของความผิดพลาดที่เกิดขึ้นไม่เท่ากัน ความผิดพลาดในแต่ละจุดของการทดสอบนั้นไม่สม่ำเสมอเมื่อเปรียบเทียบกับ การทดสอบแต่ละรอบ ซึ่งความคลาดของการระบุตำแหน่งนี้เกิดจากความคลาดเคลื่อนของการคำนวณด้วย NDT ส่วนหนึ่ง และเกิดจากความคลาดเคลื่อนในระหว่างการทดสอบ ที่จะต้องควบคุมรถกอล์ฟให้เคลื่อนที่ไปหยุดอยู่ที่จุดทดสอบแต่ละจุดด้วยการบังคับด้วยมือ แต่อย่างไรก็ตาม ค่าสูงสุดของความคลาดเคลื่อนที่เกิดขึ้นจากการทดสอบในแนวแกน x มีค่าเท่ากับ 0.184 เมตร ที่จุดที่ 2 ของการทดสอบครั้งที่ 1 และค่าเฉลี่ยของความคลาดเคลื่อนในแนวแกน x ของทุกการทดสอบมีค่าที่ 0.079 เมตร



รูปที่ 4.6 แสดงความคลาดเคลื่อนในแนวแกน y ของการทดสอบทั้งหมดในแต่ละตำแหน่งที่ทดสอบ

ผลความคลาดเคลื่อนที่เกิดขึ้นในแนวแกน y จากตารางที่ 4.4 สามารถนำมาแสดงได้ดังรูปที่ 4.6 ที่เป็นกราฟกราฟแท่งแสดงความคลาดเคลื่อนในแต่ละจุดของแกน y ของทั้ง 3 การทดสอบ ซึ่งมีลักษณะของผลลัพธ์คล้ายกับในแนวแกน x คือมีการกระจายตัวของความคลาดเคลื่อนที่ไม่เท่ากันในแต่ละการทดสอบ แต่มีค่าเฉลี่ยของความคลาดเคลื่อนใกล้เคียงกัน ซึ่งผลที่แสดงนี้มีสาเหตุเดียวกันกับความคลาดเคลื่อนในแนวแกน x คือมาจากการคำนวณของ NDT ส่วนหนึ่ง และมากจากความคลาดเคลื่อนในการควบคุมรถกอล์ฟในระหว่างทดสอบอีกส่วนหนึ่ง โดยค่าความคลาดเคลื่อนสูงสุดในแนวแกน y นั้นมีค่า 0.190 เมตร ที่จุดที่ 10 ของการทดสอบครั้งที่ 2 และความคลาดเคลื่อนเฉลี่ยของการทดสอบการระบุตำแหน่งในแนวแกน y ของทุกการทดสอบมีค่า 0.078 เมตร ซึ่งมีค่าใกล้เคียงกันของทั้งแกน x และแกน y

4.3 ผลการดำเนินการตรวจจับวัตถุจากภาพ 2 มิติ

จากขั้นตอนดำเนินการเพื่อพัฒนาระบบตรวจจับวัตถุจากภาพถ่ายของรถกอล์ฟอัตโนมัติ ในกระบวนการแรกๆที่ดำเนินการคือการจัดเก็บข้อมูลภาพถ่าย ซึ่งใช้วิธีการบันทึกภาพวิดีโอด้วยกล้องด้านหน้ารถกอล์ฟที่ผ่านการสอบเทียบแล้ว แล้วนำวิดีโอชิ้นนั้นมาประมวลผลแยกออกมาเป็นเฟรมต่อเฟรม จากนั้นภาพทั้งหมดจะถูกนำมาประเมินความสมบูรณ์ โดยตรวจสอบจากความชัดของภาพ ความชัดของวัตถุในภาพ สภาพแสง และรายละเอียดของวัตถุในภาพ ภาพที่มีความสมบูรณ์น้อยจะถูกตัดออกจากชุดข้อมูล เมื่อทำการคัดกรองภาพทั้งหมดแล้ว ชุดข้อมูลภาพนี้จะถูกนำไปล้อมกรอบเพื่อ


บ่งบอกชนิดของวัตถุที่อยู่ในภาพ โดยวัตถุทั้งหมด 4 ชนิด คือ คน รถมอเตอร์ไซด์ รถยนต์ และ รถกอล์ฟ ได้ถูกล้อมกรอบด้วยภาพที่ 4.7, 4.8, 4.8 และ 4.10



รูปที่ 4.7 ตัวอย่างการล้อมกรอบวัตถุ(1)



รูปที่ 4.8 ตัวอย่างการล้อมกรอบวัตถุ(2)




รูปที่ 4.9 ตัวอย่างการล้อมกรอบวัตถุ(3)



รูปที่ 4.10 ตัวอย่างการล้อมกรอบวัตถุ(4)

จากผลการดำเนินการล้อมกรอบรูปทั้งหมด ทำให้ได้รูปทั้งหมดที่จะนำไปเข้าสู่กระบวนการเรียนรู้ของโมเดลตรวจจับวัตถุจากภาพ 1,726 รูป โดยมีจำนวนของวัตถุที่เป็นคน 1,064 เป้าหมาย, รถยนต์ 2,312 เป้าหมาย, รถมอเตอร์ไซด์ 874 เป้าหมาย และรถกอล์ฟ 586 เป้าหมาย จากนั้นชุดข้อมูลภาพได้ถูกนำไปแบ่งแยกออกเป็นสองส่วน คือชุดข้อมูลส่วนของการเรียนรู้ของโมเดล และชุดข้อมูลส่วนของการทดสอบโมเดล ซึ่งแบ่งออกเป็นสัดส่วน 90:10 โดยจำนวน 1554 รูปสำหรับการเรียนรู้ของโมเดล และ 172 รูปสำหรับการทดสอบโมเดล

เมื่อชุดข้อมูลได้ผ่านกระบวนการเตรียมและการแบ่งสำหรับเรียนรู้และทดสอบเรียบร้อยแล้ว ชุดข้อมูลสำหรับการเรียนรู้ของโมเดลได้ถูกนำไปเข้าสู่ขั้นตอนของการเรียนรู้ของโมเดล โดยกำหนดจำนวนรูปภาพต่อการคำนวณค่าปรับค่าน้ำหนัก (Batch size) 64 รูป และกำหนดจำนวนครั้งของการเรียนรู้ของโมเดล 100,100 ครั้ง



รูปที่ 4.11 แสดงค่าการสูญเสียในแต่ละรอบของขั้นตอนการเรียนรู้ของโมเดล

จากกระบวนการเรียนรู้ของโมเดล ได้กราฟแสดงผลค่าการสูญเสีย (loss) ดังรูปที่ 4.11 โดยได้ค่าการสูญเสียเฉลี่ยของโมเดลอยู่ที่ 0.3176 จากการเรียนรู้ 100,100 รอบ เมื่อเสร็จสิ้นกระบวนการเรียนรู้ของโมเดล ในขั้นตอนต่อไปคือการทดสอบโมเดลในการตรวจจับกับชุดข้อมูลทดสอบที่แบ่งไว้ในขั้นตอนการเตรียมชุดข้อมูล เพื่อคำนวณหาค่า Evaluation metric

ตารางที่ 4.4 แสดงค่า mAP ของโมเดลตรวจจับวัตถุจากภาพ

Class name	mAP (%) at 0.5 IOU
car	82.88
golf_cart	87.65
person	74.56
motorbike	73.63

จากการนำโมเดลที่ผ่านการเรียนรู้ไปประเมินผลในขั้นตอน Evaluation สามารถที่จะคำนวณค่า mAP ที่ 0.5 IOU เพื่อบ่งบอกประสิทธิภาพในการตรวจจับของโมเดล แสดงผลดังตารางที่ 4.1 โดยพบว่าค่า mAP ของวัตถุแต่ละชนิดนั้นมีค่าสูงกว่า 70% ทั้งหมด เมื่อเปรียบเทียบกับค่า mAP ของโมเดล YOLOv3 COCO นั้นที่มีค่า mAP 55.3% โมเดลที่ผ่านกระบวนการเรียนรู้ใหม่กับชุดข้อมูลที่สร้างขึ้นนี้มีค่า mAP สูงกว่า และเหมาะกับการใช้งานกับระบบของรถกอล์ฟอัตโนมัติมากกว่า เนื่องจากชุดข้อมูลที่สร้างขึ้นนี้เป็นชุดข้อมูลบันทึกสภาพแวดล้อมจริงของพื้นที่ทดสอบ และยังมีชนิดของข้อมูลรูปภาพที่เป็นรถกอล์ฟเพิ่มเข้ามาที่จะทำให้ระบบตรวจจับของรถกอล์ฟมีความเข้ากับสถานที่ทดสอบและสามารถนำไปใช้ในการทำงานจริงได้



รูปที่ 4.12 ผลการตรวจจับวัตถุจากภาพ(1)



รูปที่ 4.13 ผลการตรวจจับวัตถุจากภาพ(2)



รูปที่ 4.14 ผลการตรวจจับวัตถุจากภาพ(3)

ขั้นตอนสุดท้ายได้นำระบบตรวจจับวัตถุจากภาพ YOLOv3 ที่ผ่านกระบวนการเรียนรู้และทดสอบเรียบร้อยแล้ว มาทดลองใช้งานกับสภาพแวดล้อมจริง ซึ่งสามารถตรวจจับวัตถุต่างๆ ทั้งที่อยู่บนถนน และอยู่รอบข้างได้ดี ดังตัวอย่างของผลการตรวจจับในภาพที่ 4.12, 4.13 และ 4.14

4.4 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ


โมเดลตรวจจับวัตถุ 2 มิติ YOLOv3 ที่ผ่านกระบวนการเรียนรู้และทดสอบด้วยชุดข้อมูลวัตถุของสภาพแวดล้อมที่เป็นเป้าหมายในการทำงานของระบบอัตโนมัติจะถูกนำมาใช้ในการแยก

ประเภทของวัตถุจากภาพร่วมกับข้อมูลการแบ่งกลุ่ม Point cloud สำหรับระบบตรวจจับวัตถุและระบุตำแหน่งวัตถุใน 3 มิติ ซึ่งได้ดำเนินการทดสอบเพื่อหาความคลาดเคลื่อนของระบบตรวจจับวัตถุแบบ 3 มิติ เฉพาะประเภทของวัตถุที่เป็นบุคคล โดยผลการทดสอบดังรูปที่ 4.15 และสรุปผลดังตารางที่ 4.5

ตารางที่ 4.5 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ

ระยะวัด (เมตร)	ระยะที่ตรวจจับได้ (เมตร)		
	ทดสอบครั้งที่ 1	ทดสอบครั้งที่ 2	ทดสอบครั้งที่ 3
1	-	-	-
2	2.1	2.0	2.1
3	3.1	3.0	3.1
4	4.1	4.1	4.1
5	5.1	5.1	5.1
6	6.1	6.1	6.1
7	7.0	7.0	7.1
8	8.1	8.1	8.1
9	9.2	9.1	9.1
10	-	-	-

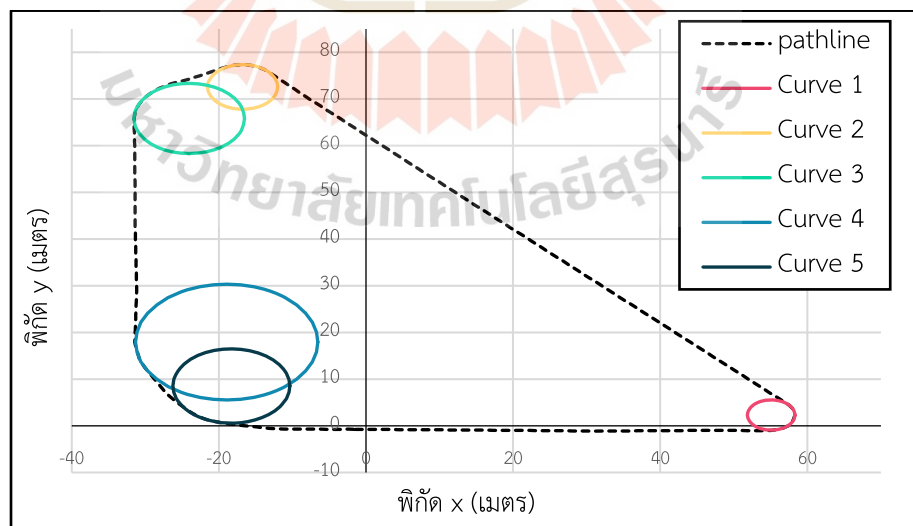
จากสรุปผลการทดสอบระบบตรวจจับวัตถุแบบ 3 มิติ พบว่ามีช่วงการทำงานของระบบนี้อยู่ในระยะ 2-9 เมตร เท่านั้น วัตถุที่อยู่ไกลและไกลเกินไปจะไม่สามารถระบุตำแหน่งใน 3 มิติได้ ในส่วนของการตรวจจับระยะไกลที่ไม่สามารถแสดงผลได้เนื่องจากวัตถุที่อยู่ไกลและมีขนาดใหญ่มีข้อมูล Point cloud ที่ไม่ได้เปรียบเทียบกับตำแหน่งของพิกเซลของภาพถ่ายจับกลุ่มอยู่ด้วย เมื่อจุดกึ่งกลางของวัตถุที่ตรวจจับได้ใน 2 มิติ นั้นชี้ไปที่ข้อมูล Point cloud ที่ไม่ได้ถูกสอบเทียบ จึงทำให้การระบุตำแหน่งของวัตถุใน 3 มิติ ไม่ได้ถูกแสดงผล แต่การตรวจจับวัตถุใน 2 มิติ และการแบ่งกลุ่มข้อมูล Point cloud เพื่อแสดงตำแหน่งของกลุ่มก้อน Point cloud ที่มีความเป็นไปได้ว่าจะเป็วัตถุนั้น ยังคงทำงานอยู่ ส่วนของการตรวจจับระยะไกลที่เกินกว่า 9 เมตร การตรวจจับวัตถุใน 2 มิติ ยังสามารถทำงานได้ แต่ข้อมูลกลุ่ม Point cloud นั้นไม่สามารถที่จะจัดรวมเป็นกลุ่มเดียวกันได้ เนื่องจากที่ระยะทางที่เพิ่มขึ้น ทำให้ข้อมูล Point cloud จากเซนเซอร์ Lidar ที่มีลักษณะของการวัดเป็นมุมในแนวตั้งและแนวนอน นั้นสามารถวัดจุดแต่ละแต่ได้มีระยะห่างมากขึ้น ตามระยะที่เพิ่มขึ้น



รูปที่ 4.15 ผลการทดสอบการตรวจจับวัตถุแบบ 3 มิติ

4.5 ผลการทดสอบความเร็วในการเข้าโค้ง

การใช้ความเร็วในการเลี้ยวหรือการเข้าโค้งจะทำให้เกิดแรงเหวี่ยงหนีศูนย์กลางที่จะกระทำกับตัวรถและผู้โดยสาร ซึ่งแรงเหวี่ยงที่เกิดขึ้นนั้นส่งผลให้เกิดความไม่สะดวกสบายของผู้โดยสารรถกอล์ฟอัตโนมัติ ในส่วนของการทดสอบความเร็วในการเข้าโค้งนั้นต้องการที่จะหาความเร็วที่มีค่าเหมาะสมในการขับเคลื่อนของระบบอัตโนมัติในรถกอล์ฟ โดยส่วนแรกคือการหาความโค้งของช่องจราจรของถนน ที่ถูกสร้างขึ้นจากแผนที่ High Definition map



รูปที่ 4.16 แสดงความโค้งของทางเลี้ยวในเส้นทางการเคลื่อนที่

จากการดึงข้อมูลจากแผนที่ High Definition map ได้นำมาสร้างกราฟแสดงตำแหน่งของเส้นกลางของช่องจราจร และคำนวณค่าความโค้งและรัศมีความโค้งของแต่ละโค้ง ซึ่งได้ผลดังตาราง 4.6


ตารางที่ 4.6 แสดงความโค้งและรัศมีความโค้งของเส้นทางการเคลื่อนที่ในพื้นที่ทดสอบ

หมายเลขทางโค้ง	ค่าความโค้ง (1/เมตร)	รัศมีความโค้ง (เมตร)
1	0.309	3.24
2	0.210	4.77
3	0.133	7.51
4	0.080	12.39
5	0.126	7.95

จากผลการวัดความโค้งของช่องจราจรในสถานที่ทดสอบ พบว่าจุดโค้งตำแหน่งที่ 1 นั้นมีความโค้งมากที่สุด และมีรัศมีความโค้งน้อยที่สุด 3.24 เมตร ดังนั้นการวิเคราะห์ความเร็วที่ทำให้เกิดแรงเหวี่ยงหนีศูนย์กลางของรถกอล์ฟ จะพิจารณาที่โค้งหมายเลข 1 เป็นหลัก และพิจารณาโค้งที่เหลือตามลำดับ

สำหรับผลการขับเคลื่อนด้วยความเร็วคงที่ของรถกอล์ฟอัตโนมัติ ที่แบ่งความเร็วออกเป็น 5 ค่าความเร็ว ตั้งแต่ 5-10 กิโลเมตรต่อชั่วโมง โดยที่ความเร็วแรก 5 กิโลเมตรต่อชั่วโมง ดังรูปที่ 4.17 ที่แสดงความสัมพันธ์ของความเร่งในแนวแกน Lateral เมื่อเคลื่อนที่ไปในช่องจราจรที่เวลาต่างๆ พบว่าช่วงวินาทีที่ 105 ความเร่งที่เกิดขึ้นในแนวด้านข้างหรือแกน Lateral นั้นมีค่าขึ้นสูงสุดที่ 0.5 เมตรต่อวินาที² ซึ่งเป็นช่วงการเคลื่อนที่ผ่านโค้งหมายเลข 1 และถ้าพิจารณาจุดที่มีความเร่งในแนวแกน Lateral สูงที่สุดของการเคลื่อนที่ 1 รอบ จะพบว่าช่วงวินาทีที่ 250 นั้นเป็นจุดที่มีความเร่งประมาณ 0.7 เมตรต่อวินาที² ซึ่งเป็นจุดที่เป็นตำแหน่งของทางโค้งหมายเลข 2 ด้วยเหตุผลที่ว่าความเร็วของรถกอล์ฟสามารถที่จะเร่งจนถึงจุดที่ความเร็วเท่ากับค่าที่ตั้งไว้ จากทางตรงระหว่างโงหมายเลข 1 และ 2 เมื่อมุมของพวงมาลัยเปลี่ยนกระทันหัน จึงเกิดแรงเหวี่ยงหนีศูนย์กลางและเกิดความเร่งในแนวแกน Lateral มากกว่าในโค้งหมายเลข 1 ซึ่งมีรัศมีความโค้งต่ำกว่าโค้งหมายเลข 2 และเมื่อกลับเข้าสู่ทางตรงในวินาทีต่อมา ความเร่งในแนวแกน Lateral ก็ก็จะเกิดในทางตรงกันข้ามเพื่อรักษาเสถียรภาพของรถกอล์ฟ ส่วนในโค้งหมายเลข 3,4 และ นั้นไม่ได้มีความแตกต่างไปจากโค้งที่ 1 ด้วยรัศมีความโค้งที่มากกว่า นอกจากนี้ ในช่วงวินาทีที่ 330 นั้นเกิดความเร่งทั้งในทางบวกและลบแบบกระทันหัน ทั้งนี้ไม่ได้เกิดจากการเข้าโค้งของการขับเคลื่อนรถกอล์ฟ แต่เกิดจากสิ่งที่ไม่สามารถ


ควบคุมได้ในงานวิจัยนี้คือสภาพพื้นผิวจราจรที่มีลักษณะเป็นร่องรอยต่อผิวถนน จะทำให้เกิดผลจากพฤติกรรมของรถกอล์ฟที่เคลื่อนที่ผ่านรอยต่อดังกล่าว




รูปที่ 4.17 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน lateral กับ เวลา ที่ความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง

เมื่อพิจารณาความเร่งที่เกิดขึ้นในแนวแกน longitudinal จากรูปที่ 4.18 ที่เกิดจากการเร่งความเร็วของมอเตอร์และแรงเบรก โดยความเร่งที่เป็นบวกนั้นคือการเร่งความเร็วของมอเตอร์ของรถกอล์ฟหรือการลงทางลาด ส่วนความเร่งที่เป็นค่าลบนั้นคือการสูญเสียความเร็วจากทางลาดชันหรือการเบรกของรถกอล์ฟ พบว่าที่การปรับค่าความเร่งในการเร่งความเร็วของการควบคุมด้วยระบบอัตโนมัติ และการปรับตั้งค่าตัวควบคุมความเร็วของระบบควบคุม Low-level นั้นสามารถที่จะควบคุมความเร่งของรถกอล์ฟให้อยู่ในช่วงการทำงานที่ไม่ส่งผลกระทบต่อความสะดวกสบายของผู้โดยสารรถกอล์ฟอัตโนมัติเลย จากผลการวัดความเร่งในแนวแกน longitudinal ที่ความเร็วการเคลื่อนที่ของรถกอล์ฟ 5 กิโลเมตรต่อชั่วโมง จะเห็นว่าในช่วงเริ่มต้นวินาทีที่ 20 รถกอล์ฟได้เริ่มเข้าสู่การทดสอบโดยเริ่มเร่งความเร็วไปที่ 5 กิโลเมตรต่อชั่วโมงจากจุดหยุดนิ่ง ซึ่งความเร่งในช่วงนี้จะมีค่าสูงเกือบที่สุดที่ประมาณ 0.7 เมตรต่อวินาที² และในช่วงวินาทีที่ 100 พบว่าเป็นช่วงที่มีความเร่งสูงที่สุด เนื่องจากความเร็วในแนวแกน longitudinal ที่สูญเสียจากการเข้าโค้งหมายเลข 1 จึงทำให้ระบบควบคุมความเร็วเร่งความเร็วเพิ่มขึ้นให้รถกอล์ฟกลับมามีความเร็วใกล้เคียงกับที่ตั้งค่าไว้ นอกจากนี้ยังมีผลที่เกิดจากความลาดชันของถนนทางตรงที่อยู่หลังโค้งหมายเลข 1 ที่มีลักษณะเป็นทางลาดลง ทำให้เกิดความเร่งสูงที่สุดในจุดนี้ นอกจากนี้ในช่วงวินาทีที่ 250 นั้นเกิดความเร่งติดลบที่ -

0.65 เมตรต่อวินาที² จากการทำงานของเบรกของระบบควบคุมความเร็ว เนื่องจากในช่วงโค้งหมายเลข 2 และ 3 นั้นมีลักษณะเป็นทางลาดลง ทำให้ความเร็วที่สูงเกินกว่าค่าที่ตั้งไว้ คือสูงเกิน 5 กิโลเมตรต่อชั่วโมง ทำให้เข้าเงื่อนไขการทำงานของระบบเบรกเพื่อลดความเร็ว และอีกสาเหตุคือความเร็วที่ลดลงจากการเข้าโค้ง เมื่อผลจากทั้งสองสาเหตุรวมกันจึงทำให้ความเร่งติดลบที่มีค่าสูง




รูปที่ 4.18 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน longitudinal กับ เวลา ที่ความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง

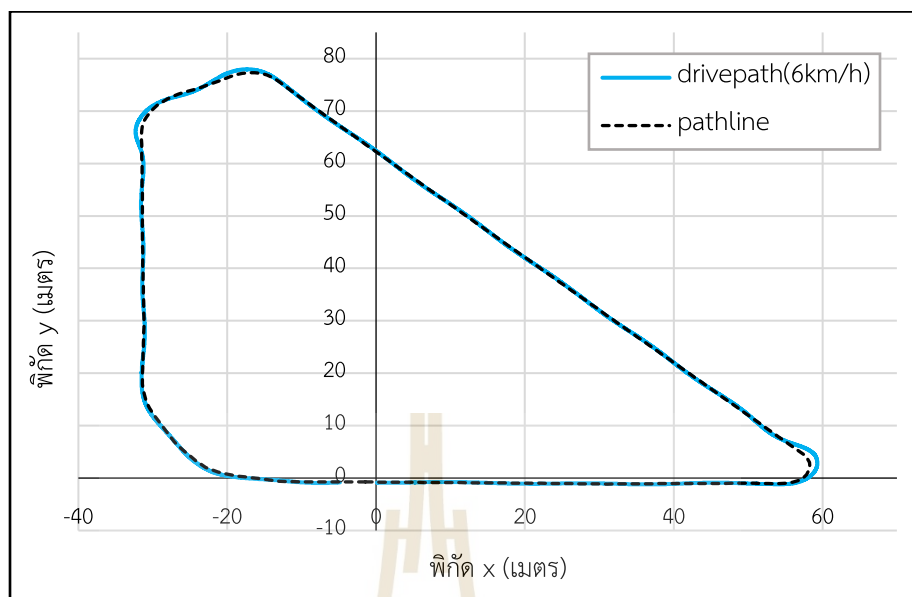


รูปที่ 4.19 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 5 กิโลเมตรต่อชั่วโมง

การทดสอบการขับเคลื่อนในทางโค้งที่ความเร็วคงที่ 6 กิโลเมตรต่อชั่วโมง พฤติกรรมของความความเร่งในแนวแกน lateral ได้แสดงในรูปที่ 4.20 ซึ่งพบว่าในช่วงการเข้าโค้งหมายเลข 1 ในช่วงวินาทีที่ 70 เป็นจุดสูงสุดจุดแรกของความเร่งในแนวแกน lateral ซึ่งมีความเร่งอยู่ที่ 0.7 เมตรต่อวินาที² ได้เป็นไปตามการเคลื่อนที่จริงที่โค้งหมายเลข 1 นั้นมีรัศมีความโค้งน้อย และระบบบังคับเลี้ยวแบบ Steering-by-wire ของรถกอล์ฟก็ยังตอบสนองได้ไม่ทันที ทำให้เกิดการเลี้ยวที่เลยไปในอีกช่องจราจรดังรูปที่ 4.21 ส่วนความเร่งในช่วงการเข้าโค้งหมายเลข 2 และ 3 นั้น เป็นช่วงที่เกิดความเร่งสูงสุดของการเคลื่อนที่ในพื้นที่ทดสอบ โดยมีความเร่งเพิ่มฉับพลันไปที่ 0.89 เมตรต่อวินาที² และลดลงมาที่ -0.69 เมตรต่อวินาที² ทันทีในช่วงวินาทีที่ 170 ด้วยเหตุผลเดียวกับการทดสอบที่ความเร็ว 5 กิโลเมตรต่อชั่วโมง คือเมื่อรถกอล์ฟทำความเร็วได้คงที่ก่อนเข้าโค้งหมายเลข 2 เมื่อเข้าโค้งโดยไม่ได้ลดความเร็วจึงเกิดแรงเหวี่ยงหนีศูนย์กลางมากทำให้เกิดความเร่งที่ค่าดังกล่าว ซึ่งมีค่าสูงกว่าความเร่งในโค้งหมายเลข 1 ถึงแม้ว่าในโค้งหมายเลข 2 จะมีรัศมีความโค้งมากกว่าโค้งหมายเลข 1 ก็ตาม




รูปที่ 4.20 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน lateral กับ เวลา ที่ความเร็วคงที่ 6 กิโลเมตรต่อชั่วโมง




รูปที่ 4.21 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 6 กิโลเมตรต่อชั่วโมง

การทดสอบขับเคลื่อนด้วยความเร็วคงที่ 7 กิโลเมตรต่อชั่วโมง ได้ผลการวัดความเร่งในแนวแกน lateral แต่ละช่วงเวลาของการทดสอบดังรูปที่ 4.22 จะเห็นว่าระยะเวลาในการทดสอบนั้นสั้นลงกว่าที่ความเร็ว 5 และ 6 กิโลเมตรต่อชั่วโมง ในส่วนของจุดสูงสุดจุดแรกที่ช่วงวินาทีที่ 55 มีความเร่งอยู่ที่ 0.8 เมตรต่อวินาที² ซึ่งเป็นช่วงที่เข้าโค้งหมายเลข 1 ดังภาพที่ 4.23 และเมื่อกลับเข้าสู่ทางตรงหลังพ้นโค้งก็มีความเร่งติดลบลงไปถึง -0.5 เมตรต่อวินาที² เนื่องจากความเร็วคงที่ในโค้งที่ทำให้เกิดแรงเหวี่ยงหนีศูนย์กลาง เช่นเดียวกับกับหลังพ้นโค้งที่มีการดึงกลับของรถกอล์ฟก็เป็นแรงเหวี่ยงหนีศูนย์กลางในทิศตรงข้าม ส่วนช่วงที่มีความเร่งสูงสุดของการทดสอบอยู่ในช่วงวินาทีที่ 140-150 เมื่อเปรียบเทียบกับภาพที่ 4.23 จะเป็นช่วงที่รถกอล์ฟเคลื่อนที่อยู่ในตำแหน่งของทางโค้งหมายเลข 2 และ ซึ่งมีความเร่งในแนวแกน lateral สูงสุดที่ 1.06 เมตรต่อวินาที² ในวินาทีที่ 137 ขณะเข้าโค้งช่วงโค้งหมายเลข 2 และความเร่งได้ลดลงมาทันทีที่ -0.66 เมตรต่อวินาที² ในวินาทีที่ 142 เมื่อกลับเข้าสู่ทางตรง แล้วผลจากการเข้าโค้งหมายเลข 3 ในวินาทีที่ 146 ทำให้เกิดความเร่งในทางตรงกันข้ามขึ้นไปถึง 0.86 เมตรต่อวินาที² ซึ่งใกล้เคียงกับการเข้าโค้งหมายเลข 1 เนื่องจากในช่วงโค้งหมายเลข 2 และ 3 นี้เป็นช่วงที่เป็นทางลาดลงจึงทำให้ความเร่งที่เกิดขึ้นในแนวแกน lateral นั้นมีค่าสูงมาก และจากผลของการถ่ายน้ำหนักหรือแรงเหวี่ยงหนีศูนย์กลางเมื่อทิศทางการเคลื่อนที่ของรถกอล์ฟมีการเปลี่ยนแปลง จึงทำให้เกิดผลลัพธ์ดังกล่าว




รูปที่ 4.22 แสดงความสัมพันธ์ระหว่างความแรงในแนวแกน lateral กับ เวลา ที่ความเร็วคงที่ 7 กิโลเมตรต่อชั่วโมง




รูปที่ 4.23 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 7 กิโลเมตรต่อชั่วโมง

การทดสอบการขับเคลื่อนด้วยความเร็วคงที่ ที่ความเร็ว 8 กิโลเมตรต่อชั่วโมง ที่ความเร็วนี้มีลักษณะของผลการตอบสนองของความแรงในแนวแกน lateral ใกล้เคียงกับการทดสอบที่ความเร็วต่ำกว่า แต่เมื่อใช้ความเร็วเพิ่มขึ้น ความแรงที่เกิดจากแรงเหวี่ยงหนีศูนย์กลางในแต่ละโค้งก็จะเพิ่มขึ้นแบบแปรผันตรงกัน ซึ่งจากรูปที่ 4.24 ที่แสดงผลการทดสอบในส่วนของความแรงในแนวแกน lateral กับ

เวลา พบว่าในวินาทีที่ 50 เป็นช่วงที่รถกอล์ฟเคลื่อนที่เข้าทางโค้งหมายเลข 1 เป็นช่วงที่เกิดความเร่งในแนวแกน lateral สูงสุดจุดแรกของการทดสอบ ซึ่งเป็นไปตามลักษณะของการเคลื่อนที่ในโค้งที่มีรัศมีความโค้งน้อย โดยมีความเร่งสูงสุดที่ 1.09 เมตรต่อวินาที² และการตอบสนองของพวงมาลัยแบบ Steering-by-wire ของรถกอล์ฟไฟฟ้านี้ไม่สามารถตอบสนองทางโค้งหมายเลข 1 ที่ความเร็วนี้ได้ทัน จากรูปที่ 4.25 จะเห็นว่ามีการเคลื่อนที่ออกนอกเส้นทางการเคลื่อนที่ก่อนจะกลับเข้ามาในเส้นทางการเคลื่อนที่หลังจากผ่านทางโค้งเข้าสู่ช่วงการขับเคลื่อนในทางตรง นอกจากนี้ จุดที่มีความเร่งสูงสุดของการทดสอบคือช่วงวินาทีที่ 118 หรือจุดที่เป็นตำแหน่งของทางโค้งหมายเลข 2 ซึ่งมีความเร่งในแนวแกน lateral สูงสุดที่ 1.24 เมตรต่อวินาที² ต่อจากนั้นเมื่รถกอล์ฟเคลื่อนที่ออกจากโค้งเข้าทางตรงก็เกิดความเร่งที่เกิดจากแรงเหวี่ยงหนีศูนย์กลางในทิศตรงข้ามลงไป -0.54 เมตรต่อวินาที² ในวินาทีที่ 122 และมีพฤติกรรมเดียวกันในโค้งหมายเลข 3 ที่ต่อเนื่องกับโค้งหมายเลข 2 คือความเร่งในแนวแกน lateral ขึ้นไปที่ 0.88 เมตรต่อวินาที² แล้วเกิดแรงในทิศตรงข้ามเมื่อกลับเข้าทางตรงที่ -0.4 เมตรต่อวินาที² ในช่วงวินาทีที่ 130 ซึ่งเมื่อสังเกตจากรูปที่ 4.25 จะพบว่าการตอบสนองของระบบ Steering-by-wire นั้นไม่สามารถควบคุมรถกอล์ฟให้อยู่ในเส้นทางการเคลื่อนที่ในทางโค้งหมายเลข 2 และ 3 สำหรับความเร็วการทดสอบนี้ได้




รูปที่ 4.24 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน lateral กับ เวลา ที่ความเร็วคงที่ 8 กิโลเมตรต่อชั่วโมง




รูปที่ 4.25 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 8 กิโลเมตรต่อชั่วโมง

การทดสอบการขับเคลื่อนในทางโค้งด้วยความเร็วคงที่ 9 กิโลเมตรต่อชั่วโมง จากรูปที่ 4.26 ที่แสดงความเร่งในแนวแกน lateral ที่สัมพันธ์กับเวลาในการเคลื่อนที่ในระหว่างการทดสอบ ในช่วงที่เกิดความเร่งสูงสุดจุดแรกและเป็นจุดที่สูงที่สุดของการทดสอบคือช่วงที่เข้าโค้งหมายเลข 1 ซึ่งมีความเร่งในทางโค้งสูงสุดที่ 1.44 เมตรต่อวินาที² ในช่วงวินาทีที่ 40 แล้วลดลงมาเมื่อกลับเข้าสู่ทางตรง และอีกจุดหนึ่งที่ความเร่งในแนวแกน lateral จะพุ่งขึ้นลงคือช่วงวินาทีที่ 100-120 ที่เป็นช่วงการเข้าโค้งหมายเลข 2 และ 3 ซึ่งความเร่งทั้งสองช่วงที่เกิดจุดสูงสุดนั้นเกิดจากแรงเหวี่ยงหนีศูนย์กลางของรถกอล์ฟจากการเข้าโค้งที่รัศมีความโค้งต่างๆ และเมื่อเปรียบเทียบกับ การทดสอบที่ความเร็วต่ำกว่า จะพบว่าความเร่งที่เกิดขึ้นในแต่ละโค้งจะสูงขึ้นตามความเร็วในการเข้าโค้งที่เพิ่มขึ้น นอกจากนี้ การตอบสนองของพวงมาลัยแบบ Steering-by-wire ของรถกอล์ฟก็ไม่สามารถที่จะตอบสนองให้สามารถเข้าโค้งได้ตามเส้นทางการเคลื่อนที่ของรถกอล์ฟ จากรูปที่ 4.27 จะเห็นได้ว่าตำแหน่งของรถกอล์ฟที่เคลื่อนที่ผ่านในแต่ละโค้งเกิดการหลุดออกนอกโค้งและดึงกลับมา ซึ่งเห็นได้ชัดทั้งในโค้งหมายเลข 1, 2 และ 3




รูปที่ 4.26 แสดงความสัมพันธ์ระหว่างความเร่งในแนวกอน lateral กับ เวลา ที่ความเร็วคงที่ 9 กิโลเมตรต่อชั่วโมง



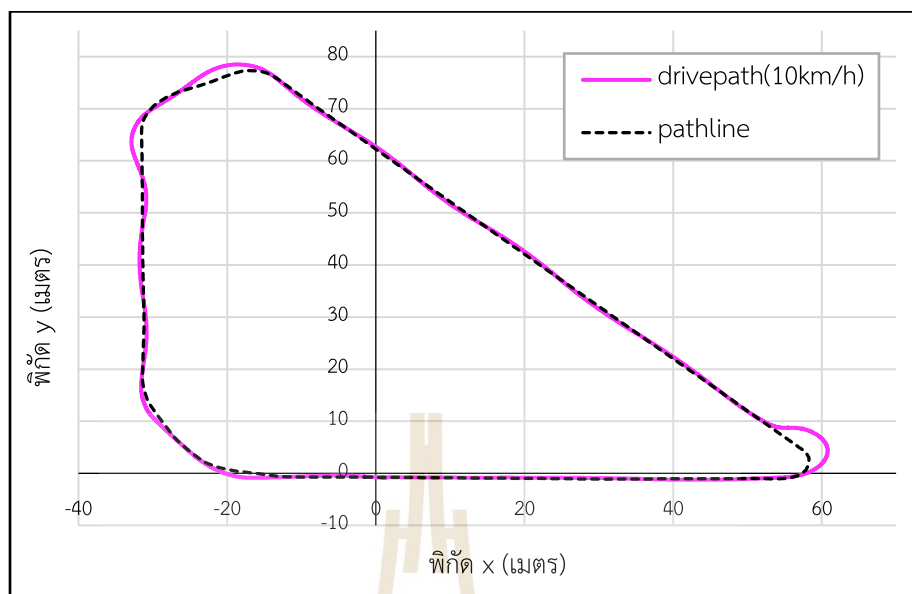
รูปที่ 4.27 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 9 กิโลเมตรต่อชั่วโมง

การทดสอบการขับเคลื่อนของรถกอล์ฟด้วยความเร็วคงที่ 10 กิโลเมตรต่อชั่วโมง เพื่อวัดความเร่งที่เกิดขึ้นในแนวกอน lateral ในรูปที่ 4.28 ที่แสดงความสัมพันธ์ของความเร่งเทียบกับระยะเวลาที่รถกอล์ฟเคลื่อนที่ในแต่ละตำแหน่ง จะเห็นว่าจุดสูงสุดของความเร่งในแนวกอน lateral นั้นอยู่ในช่วงเวลาวินาทีที่ 40 มีความเร่งสูงสุดที่ 2.36 เมตรต่อวินาที² โดยมีลักษณะของกราฟที่

แตกต่างออกไปจากการทดสอบที่ความเร็วต่ำกว่าเล็กน้อย และเมื่อเทียบกับรูปที่ 4.29 ที่ช่วงเวลาการเคลื่อนที่ที่มีความเร่งสูงสุดนี้คือจุดที่รถกอล์ฟขับเคลื่อนในโค้งหมายเลข 1 จะเห็นรถกอล์ฟมีการขับเคลื่อนออกนอกเส้นทางการเคลื่อนที่อย่างชัดเจน จากการตอบสนองของพวงมาลัย Steering-by-wire ที่ทำได้ไม่ทัน ที่ความเร็วในการเข้าโค้งนี้ และในระหว่างที่ทำการทดสอบในจุดที่รถกอล์ฟกำลังออกจากโค้งหมายเลข 1 นี้ การตอบสนองของพวงมาลัยที่ทำได้ไม่ทัน ทำให้ผู้วิจัยต้องปรับระบบมาใช้ในการควบคุมด้วยมือและลดความเร็วก่อนจะเกิดอุบัติเหตุด้วยช่วงระยะเวลาสั้นๆหลังจากออกจากทางโค้งแล้วจึงปรับระบบเข้าสู่การทดสอบดังเดิม นอกจากนี้ ในช่วงวินาทีที่ 95-110 ในรูปที่ 4.28 ก็มีลักษณะของความเร่งในแนวแกน lateral แบบพุ่งขึ้นลง จากแรงเหวี่ยงในการเข้าโค้งหมายเลข 2 และ 3 เช่นเดียวกันกับการทดสอบที่ความเร็วต่ำกว่า

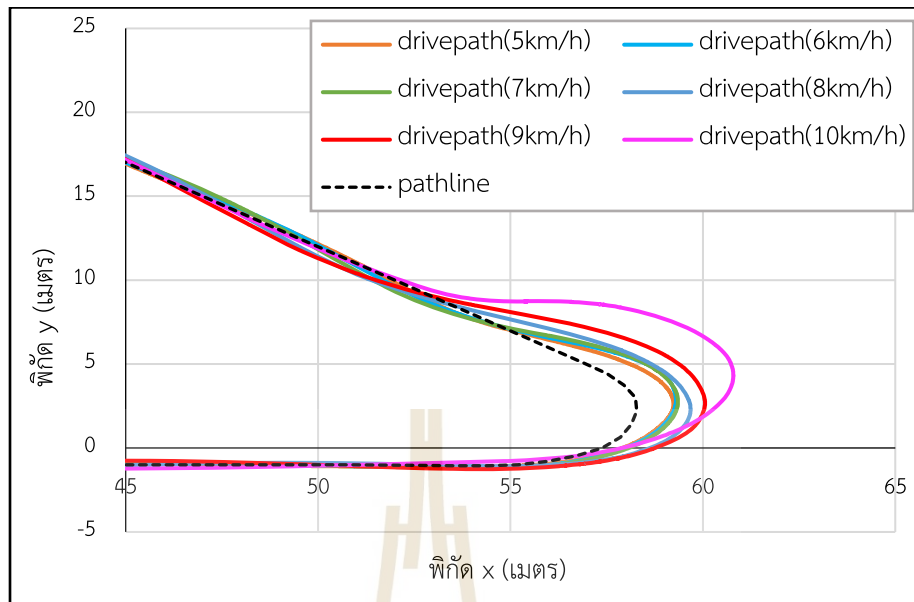


รูปที่ 4.28 แสดงความสัมพันธ์ระหว่างความเร่งในแนวแกน lateral กับ เวลา ที่ความเร็วคงที่ 10 กิโลเมตรต่อชั่วโมง




รูปที่ 4.29 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยความเร็วคงที่ 10 กิโลเมตรต่อชั่วโมง

จากการทดสอบการขับเคลื่อนรถกอล์ฟผ่านทางโค้งด้วยความเร็วคงที่ 5-10 กิโลเมตรต่อชั่วโมง ได้ผลการเปรียบเทียบตำแหน่งที่รถกอล์ฟเคลื่อนที่กับเส้นทางการเคลื่อนที่ของรถกอล์ฟดังรูปที่ 4.30 และ 4.31 จะพบว่าความเร็วในการเข้าโค้งนั้นส่งผลให้เกิดการเข้าโค้งไม่ทัน ไม่สามารถที่จะเคลื่อนที่ไปตามเส้นทางการเคลื่อนที่ในทางโค้งได้ ทั้งนี้ ที่ความเร็วต่ำ (5 กิโลเมตรต่อชั่วโมง) นั้นสามารถเคลื่อนที่เข้าโค้งได้ใกล้เคียงกับเส้นทางการเคลื่อนที่มากที่สุด และความสามารถในการเข้าโค้งให้ตรงกับเส้นทางการเคลื่อนที่จะลดลงตามความเร็วของรถกอล์ฟที่เพิ่มขึ้น เนื่องมาจากการตอบสนองของพวงมาลัยแบบ Steering-by-wire ของระบบควบคุม Low-level นั้นไม่สามารถตอบสนองได้ทัน



รูปที่ 4.30 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่แต่ละความเร็วที่ตำแหน่งโคงหมายเลข 1



รูปที่ 4.31 แสดงการเปรียบเทียบระหว่างเส้นทางการเคลื่อนที่ของช่องจราจรและตำแหน่งของรถกอล์ฟที่เคลื่อนที่แต่ละความเร็วที่ตำแหน่งโคงหมายเลข 2 และ 3

จากผลการทดสอบความเร็วในการเข้าโค้งโดยการขับเคลื่อนรถกอล์ฟด้วยความเร็วคงที่ในพื้นที่ทดสอบ เพื่อสังเกตผลการตอบสนองของรถกอล์ฟในแต่ละโค้ง ทั้งในส่วนของความสามารถใน


การขับเคลื่อนตามเส้นทางการเคลื่อนที่ในทางโค้งและความเร่งในแนวแกน Lateral ที่เกิดขึ้นในทางโค้ง เพื่อวิเคราะห์และสรุปความเร็วที่เหมาะสมของระบบอัตโนมัติของรถกอล์ฟที่จะใช้ในช่วงการเคลื่อนที่ในทางโค้ง พบว่า เมื่อเปรียบเทียบผลของความเร่งในแนวแกน lateral ที่ความเร็วต่างๆ กับค่าขอบเขตของความเร่งที่ส่งผลต่อความสะดวกสบายต่อผู้โดยสารรถกอล์ฟ โดยงานวิจัยนี้เลือกขอบเขตของความเร่งในแนวแกน lateral ที่ ± 0.9 เมตรต่อวินาที² ความเร็วในทางโค้งที่เหมาะสมที่สุดคือ 5 กิโลเมตรต่อชั่วโมง เนื่องจากเมื่อเปรียบเทียบกราฟแสดงผลความเร่งในแนวแกน lateral ของการทดสอบแต่ละความเร็วแล้ว ความเร่งในแต่ละทางโค้งของการขับเคลื่อนของรถกอล์ฟที่ความเร็ว 5 กิโลเมตรต่อชั่วโมงนั้นมีค่าน้อยที่สุดและต่ำกว่าค่าขอบเขตที่ ± 0.9 เมตรต่อวินาที² ถึงแม้ว่าการทดสอบที่ 6 กิโลเมตรต่อชั่วโมง นั้นมีค่าความเร่งในระหว่างเคลื่อนที่ต่ำกว่าเช่นเดียวกัน แต่การทดสอบที่ 6 กิโลเมตรต่อชั่วโมง นั้นเกิดความเร่งที่ใกล้เคียงกับค่าขอบเขตของความเร่งที่ส่งผลต่อความสะดวกสบายของผู้โดยสารมาก โดยเฉพาะในทางโค้งหมายเลข 2 และ 3 และนอกจากนี้ เมื่อเปรียบเทียบตำแหน่งของรถกอล์ฟที่เคลื่อนที่ผ่านโค้งของแต่ละความเร็ว ก็พบว่าที่ความเร็ว 5 กิโลเมตรต่อชั่วโมง นั้นสามารถที่จะควบคุมรถกอล์ฟให้อยู่ใกล้เคียงกับเส้นทางการเคลื่อนที่ได้มากที่สุดในทุกทางโค้ง

4.6 ผลการทดสอบระบบขับเคลื่อนอัตโนมัติ

การทดสอบระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟในส่วนแรกที่ทำเนิการทดสอบ เป็นการขับเคลื่อนตามเส้นทางการเคลื่อนที่ที่ออกแบบไว้ในแผนที่ High definition map โดยมีการควบคุมการปรับความเร็วในทางโค้งของพื้นที่ทดสอบให้มีค่าอยู่ที่ 5 กิโลเมตรต่อชั่วโมง ตามผลการทดสอบความเร็วในการเข้าโค้งของรถกอล์ฟอัตโนมัติ ใช้ความเร็วในการขับเคลื่อนในเส้นทางตรง 10 กิโลเมตรต่อชั่วโมง ซึ่งได้แสดงผลออกมาในรูปแบบของตำแหน่งของรถกอล์ฟที่เคลื่อนที่ด้วยระบบอัตโนมัติตามเส้นทางการเคลื่อน ดังรูปที่ 4.32, 4.33 และ 4.34


จากการทดสอบระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟในครั้งแรก โดยเริ่มต้นการเคลื่อนที่ที่จุด 0,0 จากพิกัดของแผนที่ high definition map ดังรูปที่ 4.32 พบว่าการเคลื่อนที่ของรถกอล์ฟที่พิกัดต่างๆ จากการควบคุมมุมเลี้ยวของพวงมาลัยด้วย pure pursuit โดยปรับแต่งและเลือกใช้ระยะ look-ahead distance ที่ 2.25 เมตร สามารถที่จะควบคุมการเคลื่อนที่ไปในแนวทางเดียวกันกับเส้นทางการเคลื่อนที่ โดยเมื่อมีการเคลื่อนที่ออกนอกเส้นทางการเคลื่อนที่ก็จะถูกดึงกลับมา เนื่องจากทิศทางเคลื่อนที่ที่ไม่สัมพันธ์กับเส้นทางการเคลื่อนที่ โดยมีระยะที่เคลื่อนที่ออกนอกเส้นทางการ

เคลื่อนที่ในทางตรงประมาณ 0.4 เมตร เนื่องจากการตอบสนองของพวงมาลัยที่ระบบของ low-level นั้นตอบสนองในมุมที่มีความคลาดเคลื่อนกับคำสั่งจาก pure pursuit และเนื่องจากความเอียงเล็กน้อยของล้อที่ทำให้รถกอล์ฟเคลื่อนที่เบนทิศทางออกนอกเส้นทางการเคลื่อนที่ที่เป็นเส้นตรง




รูปที่ 4.32 ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 1

และเมื่อพิจารณาจากตำแหน่งการเคลื่อนที่ของรถกอล์ฟในระหว่างการทดสอบครั้งที่ 2 และ 3 จากภาพที่ 4.33 และ 4.34 ตามลำดับแล้ว พบว่าพฤติกรรมเคลื่อนที่ของรถกอล์ฟนั้นมีลักษณะเดียวกันกับการทดสอบครั้งที่ 1




รูปที่ 4.33 ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 2



รูปที่ 4.34 ผลการทดสอบระบบขับเคลื่อนอัตโนมัติครั้งที่ 1


การทดสอบระบบเบรกอัตโนมัติของรถกอล์ฟเมื่อพบสิ่งกีดขวางหรือวัตถุอยู่ในเส้นทางการเคลื่อนที่ได้ทำการทดสอบร่วมกับระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟ โดยทำการทดสอบทั้งหมด 3 รอบ ได้ผลดังรูปที่ 4.35, 4.36 และ 4.37 จากการทดสอบครั้งที่ 1, 2 และ 3 ตามลำดับ โดยแสดงผลความเร็วของรถกอล์ฟ คำสั่งความเร็วจากระบบอัตโนมัติ ตำแหน่งของรถกอล์ฟในแนวแกน x และตำแหน่งของวัตถุกีดขวางในแนวแกน x เทียบกับเวลา

จากการทดสอบระบบเบรกอัตโนมัติครั้งที่ 1 เมื่อเริ่มต้นการทำงานของรถกอล์ฟอัตโนมัติในช่วงวินาทีที่ 5 คำสั่งความเร็วเริ่มไต่ระดับคำสั่งและรถกอล์ฟเริ่มเคลื่อนที่จนถึงความเร็วตั้งค่า คือ 10 กิโลเมตรต่อชั่วโมง ในขณะเดียวกัน รถกอล์ฟเริ่มเคลื่อนที่ไปตามเส้นทางการเคลื่อนที่โดยจะเห็นได้จากพิกัดที่เพิ่มขึ้นในแนวแกน x จากรูปที่ 4.35 จากนั้น ในวินาทีที่ 22 ระบบตรวจจับวัตถุของรถกอล์ฟสามารถที่จะตรวจจับตำแหน่งของวัตถุที่อยู่ในช่องจราจรและมีคำสั่งให้ลดความเร็วลง ทำให้ระบบเบรกที่ low level ของรถกอล์ฟไฟฟ้าเริ่มทำงาน และในเวลาต่อมา เมื่อรถกอล์ฟเคลื่อนที่เข้าใกล้วัตถุมากขึ้น คำสั่งความเร็วของระบบเบรกจึงสั่งให้หยุดรถที่ความเร็ว 0 กิโลเมตรต่อชั่วโมง โดยมีระยะห่างระหว่างวัตถุกับรถกอล์ฟที่ 6.2 เมตร ซึ่งในช่วงที่รถกอล์ฟลดความเร็วจนถึงจุดหยุดนิ่งนี้ ระยะเบรกของรถกอล์ฟจากการทดสอบครั้งนี้อยู่ที่ 4 เมตร




รูปที่ 4.35 ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 1

การทดสอบระบบเบรกอัตโนมัติครั้งที่ 2 ในรูปที่ 4.36 มีลักษณะผลการตอบสนองและการควบคุมเช่นเดียวกับครั้งที่ 1 คือเมื่อรถกอล์ฟเคลื่อนที่จนถึงจุดที่มองเห็นวัตถุและสามารถระบุพิกัดได้จากกราฟจะอยู่ในช่วง 10.2 เมตร คือช่วงที่เริ่มลดความเร็วเพื่อป้องกันการชน จากนั้นรถกอล์ฟเคลื่อนที่ไปอีก 5.4 เมตร แล้วหยุดรถห่างจากวัตถุ 4.4 เมตร



รูปที่ 4.36 ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 2

ส่วนของการทดสอบระบบเบรกอัตโนมัติครั้งที่ 3 จากรูปที่ 4.37 ในช่วงเริ่มต้นการทดสอบ รถกอล์ฟเคลื่อนที่ตามคำสั่งความเร็วไปตามเส้นทางการเคลื่อนที่จนถึงช่วงวินาทีที่ 19 ที่รถกอล์ฟสามารถระบุตำแหน่งของวัตถุได้และลดความเร็วลงจนถึงจุดที่รถกอล์ฟหยุดนิ่ง ที่ระยะห่างระหว่างรถกอล์ฟกับสิ่งกีดขวาง 5.3 เมตร




รูปที่ 4.37 ผลการทดสอบระบบเบรกอัตโนมัติครั้งที่ 3

จากการทดสอบระบบเบรกอัตโนมัติของรถกอล์ฟทั้ง 3 ครั้ง สามารถสรุปได้ว่าระยะเบรกเฉลี่ยของรถกอล์ฟ เมื่อเจอสิ่งกีดขวางที่อยู่ในช่องจราจรแบบหยุดนิ่งนั้นอยู่ที่ 4.3 เมตร และระยะห่างระหว่างวัตถุกับรถกอล์ฟที่หยุดเพื่อป้องกันการชนนั้นมีค่าเฉลี่ยอยู่ที่ 5.63 เมตร ซึ่งมีความคลาดเคลื่อนจากระยะที่ตั้งไว้ 0.63 เมตร เป็นผลมาจากทั้งความคลาดเคลื่อนที่ระบบระบุตำแหน่งร่วมกับผลการตอบสนองของระบบเบรก brake-by-wire ที่ใช้ลักษณะการควบคุมแบบ เปิด-ปิด ทำให้ควบคุมระยะเบรกที่แน่นอนได้ยาก


สำหรับส่วนสุดท้ายของการทดสอบระบบขับเคลื่อนอัตโนมัติของรถกอล์ฟคือระบบหลบหลีกสิ่งกีดขวาง จากการทดสอบระบบหลบหลีกสิ่งกีดขวางของรถกอล์ฟอัตโนมัติทั้ง 3 รอบ โดยให้คนเป็นสิ่งกีดขวางที่อยู่บนช่องจราจรและอยู่ใกล้กับเส้นทางการเคลื่อนที่ของรถกอล์ฟอัตโนมัติ ดังรูปที่ 4.38 เมื่อระบบตรวจจับของรถกอล์ฟสามารถตรวจจับวัตถุใน 3 มิติและระบุตำแหน่งของวัตถุที่ว่าอยู่ในเส้นทางการเคลื่อนที่ของรถกอล์ฟ A-star จะค้นหาเส้นทางที่รถกอล์ฟสามารถเคลื่อนที่หลบสิ่งกีด

ขวางได้ใกล้เส้นทางการเคลื่อนที่ที่สุด โดยยังอ้างอิงขอบเขตของช่องจราจรในการเคลื่อนที่ไม่ให้ออกนอกช่องจราจร



รูปที่ 4.38 การทดสอบการขับเคลื่อนหลบหลีกสิ่งกีดขวางของรถกอล์ฟอัตโนมัติ


การทดสอบครั้งที่ 1 จากรูปที่ 4.39 ได้แสดงตำแหน่งของรถกอล์ฟระหว่างการขับเคลื่อนหลบหลีกสิ่งกีดขวางซึ่งอยู่ที่พิกัด 21 เมตรในแนวแกน x และ -2.2 เมตรในแนวแกน y เทียบกับพิกัดของแผนที่ High definition map ซึ่งการเคลื่อนที่ของรถกอล์ฟได้เคลื่อนที่ออกนอกเส้นกลางเพื่อหลบสิ่งกีดขวางไปทาง $-y$ ประมาณ 1 เมตร เนื่องจากสิ่งกีดขวางที่อยู่ในช่องจราจรนั้นอยู่ในเส้นกลางและเยื้องไปทาง $+y$ เล็กน้อย เมื่อพื้นที่ว่างทางฝั่ง $-y$ นั้นมีมากกว่า การสร้างเส้นทางด้วย A-star จึงเลือกที่จะเคลื่อนที่หลบหลีกไปทางฝั่ง $-y$ ดังผลการทดสอบ



รูปที่ 4.39 ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 1


การทดสอบครั้งที่ 2 ของระบบหลบหลีกสิ่งกีดขวางของรถกอล์ฟ จากรูปที่ 4.40 ได้แสดงตำแหน่งและเส้นทางของสิ่งกีดขวางในขณะทดสอบนั้นมีการเคลื่อนที่จากฝั่ง $-y$ ในช่วงเริ่มต้นการ

ทดสอบไปทางฝั่ง $+y$ ซึ่งข้ามเส้นกลางสำหรับการเคลื่อนที่อัตโนมัติของรถกอล์ฟ ทำให้พิกัดตำแหน่งของรถกอล์ฟที่เคลื่อนที่ในการทดสอบ มีพฤติกรรมในการหลบหลีกสิ่งกีดขวางถึง 2 รอบ ไปทางแกน $+y$ เนื่องจากในช่วงแรกของการทดสอบนั้น พื้นที่ว่างที่ทางฝั่ง $+y$ มีมากกว่าและอยู่ใกล้เส้นกลางการเคลื่อนที่มากกว่า ทำให้เส้นทางการหลบหลีกสิ่งกีดขวางนั้นถูกสร้างให้เคลื่อนที่หลบในแกน $+y$ แต่ในเวลาต่อมา เมื่อสิ่งกีดขวางเคลื่อนที่ไปทาง $+y$ ซึ่งใกล้กับเส้นทางการหลบหลีกสิ่งกีดขวางที่สร้างขึ้นในครั้งแรก จึงเกิดเส้นทางใหม่ไปทางแกน $+y$ มากขึ้น แล้วเคลื่อนที่กลับเข้าสู่เส้นทางการเคลื่อนที่เดิม ดังผลการทดสอบ



รูปที่ 4.40 ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 2

การทดสอบระบบหลบหลีกสิ่งกีดขวางของรถกอล์ฟอัตโนมัติครั้งที่ 3 จากรูปที่ 4.41 นั้น แสดงให้เห็นตำแหน่งของสิ่งกีดขวางและตำแหน่งของรถกอล์ฟของการทดสอบ ซึ่งมีผลการทดสอบ คล้ายกับการทดสอบครั้งที่ 1 แต่กลับทิศทางในการเคลื่อนที่กัน ในการทดสอบครั้งนี้ สิ่งกีดขวางที่ขวางทางการเคลื่อนที่ของรถกอล์ฟนั้นมีตำแหน่งอยู่กึ่งกลางของช่องจราจรและอยู่บนเส้นการเคลื่อนที่ของรถกอล์ฟ แต่มีการเคลื่อนที่เข้ามาจากทาง $-y$ ในทิศทาง $+y$ ทำให้การตัดสินใจของระบบหลบหลีกสิ่งกีดขวางนั้นสร้างเส้นทางใหม่ในช่วงของช่องว่างด้าน $+y$ ซึ่งทำให้รถกอล์ฟนั้นเคลื่อนที่หลบสิ่งกีดขวางที่อยู่ในเส้นทางการเคลื่อนที่เดิมได้ ดังผลการทดสอบ



รูปที่ 4.41 ผลการทดสอบหลบหลีกสิ่งกีดขวางครั้งที่ 3

บทที่ 5

สรุปและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

วิทยานิพนธ์นี้นำเสนอการพัฒนาระบบขับเคลื่อนอัตโนมัติสำหรับรถกอล์ฟไฟฟ้า โดยใช้ข้อมูลจากกล้องและ Lidar สำหรับประมวลผลการระบุตำแหน่ง การตรวจจับวัตถุ การสร้างเส้นทางการเคลื่อนที่ การเคลื่อนที่ตามเส้นทาง และการหลบหลีกสิ่งกีดขวาง เพื่อให้รถกอล์ฟไฟฟ้าสามารถขับเคลื่อนด้วยระบบอัตโนมัติที่ปลอดภัย สำหรับการขนส่งผู้โดยสารระหว่างอาคาร งานวิจัยมีรายละเอียดโดยสรุปดังนี้

สร้างแผนที่ความละเอียดสูงที่ประกอบด้วยข้อมูล Point cloud map และเส้นทางการเคลื่อนที่ของพื้นที่ทดสอบ และตรวจสอบความคลาดเคลื่อนของแผนที่อยู่ที่ 1.15% ซึ่งเพียงพอกับการนำไปใช้งานกับระบบอัตโนมัติของรถกอล์ฟ

พัฒนาระบบระบุตำแหน่งด้วย Normal distribution transform โดยใช้ข้อมูลจาก Lidar เทียบกับแผนที่ความละเอียดสูง แล้วทดสอบความแม่นยำในการระบุตำแหน่ง ซึ่งมีความคลาดเคลื่อนเฉลี่ยอยู่ที่ 0.078 เมตร สามารถที่จะใช้ในการระบุตำแหน่งของรถกอล์ฟอัตโนมัติได้ในสภาพแวดล้อมระหว่างอาคาร

ระบบตรวจจับวัตถุและระบุตำแหน่ง ใน 3 มิติ ของรถกอล์ฟ สามารถทำงานได้ดีในช่วง 2-9 เมตร แต่การระบุข้อมูลของวัตถุใน 3 มิติ ในระยะไกลเกินกว่า 9 เมตร ยังสามารถที่จะทำงานได้จากข้อมูลแอสแกน Point cloud

การขับเคลื่อนอัตโนมัติของรถกอล์ฟ ด้วยความเร็ว 10 กิโลเมตรต่อชั่วโมง และความเร็วในทางโค้ง 5 กิโลเมตรต่อชั่วโมง ด้วยการควบคุมพวงมาลัยแบบ Pure pursuit สามารถที่จะเคลื่อนที่จากจุดเริ่มต้นไปยังตำแหน่งเป้าหมายการเคลื่อนที่ที่ต้องการได้ โดยมีความคลาดเคลื่อนของการควบคุมพวงมาลัยเคลื่อนที่ออกนอกเส้นทาง 0.4 เมตร และเมื่อพบวัตถุกีดขวางเส้นทางการเคลื่อนที่รถกอล์ฟจะสามารถที่จะลดความเร็วและหยุดรถที่ระยะห่างเฉลี่ยจากวัตถุ 5.63 เมตร หรือสามารถที่จะเคลื่อนที่หลบหลีกเมื่อมีพื้นที่เพียงพอในการหลบหลีกสิ่งกีดขวางได้

5.2 ข้อเสนอแนะ

1. ระบบควบคุมมุมเลี้ยวของรถกอล์ฟอัตโนมัตินั้นสามารถที่จะพัฒนาไปใช้ตัวควบคุมแบบ Model predictive เพื่อให้การตอบสนองของการเคลื่อนที่ในทางตรงและทางโค้งแม่นยำยิ่งขึ้น
2. ระบบควบคุมพวงมาลัยและเบรกไฟฟ้าสามารถพัฒนาให้มีการตอบสนองที่แม่นยำและรวดเร็วด้วยการเปลี่ยนอุปกรณ์ขับ
3. ควรเพิ่มเติมระบบตรวจจับวัตถุในระยะใกล้ เช่น Ultrasonic sensor เพื่อเพิ่มความปลอดภัยให้กับระบบอัตโนมัติของรถกอล์ฟ



รายการอ้างอิง

- ปณิธิ เพ็ชรนอก. (2562). การออกแบบและสร้างระบบควบคุมการขับเคลื่อนสำหรับรถออสไฟฟ้า. วิทยานิพนธ์ปริญญาโทมหาบัณฑิต สาขาวิชาวิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีสุรนารี
- Anjani, J., Bhaskar, A. and P., Rajalakshmi. (2019). **Fast Object Segmentation Pipeline for Point Clouds Using Robot Operating System**. IEEE 5th World Forum on Internet of Things (WF-IoT), Limerick, Ireland
- Adrian, R. (2016). **Intersection over Union (IoU) for object detection**. [Online]. Available: <https://pyimagesearch.com>. [Accessed 12 May 2021].
- Anh, H., R. (2019). **Convolutional Neural Networks (CNNs)**. [Online]. Available: <https://anhreynolds.com>. [Accessed 15 May 2021].
- Ayoosh. K. (2018). **What's new in YOLO v3**. [Online]. Available: <https://towardsdatascience.com>. [Accessed 21 May 2021].
- Anjani, J., Bhaskar, A. and P., Rajalakshmi. (2019). **Fast Object Segmentation Pipeline for Point Clouds Using Robot Operating System**. IEEE 5th World Forum on Internet of Things (WF-IoT), Limerick, Ireland
- Bir. A., S., G., Mayank. S. and Hardeep. S. (2018) **Four-Wheel Drive System: Architecture, Basic Vehicle Dynamics and Traction**. International Journal of Current Engineering and Technology. 8(02).
- Coulter, R. (1990). **Implementation of the Pure Pursuit Path Tracking Algorithm**. Carnegie Mellon University, Pittsburgh, Pennsylvania.
- Coulter, R. (2022). **Pure Pursuit Controller**. [Online]. Available: <https://www.mathworks.com>. [Accessed 20 May 2022].

- Claudine, B., Ranik, G., Rapheal, V., C., Pedro, A., Vinicius, B., C., Avelino, V., Luan, J., Rodrigo, B., Thiago, P., Filipe, M., Lucas, V., Thiago, O. and Alberto, F., D., S. (2019). **Self-Driving Cars: A Survey**. Expert Systems with Applications, Vol. 165.
- Chenguang, Liu., Qingzhou, M., Xiumin, C. and Shuo, X. **An Improved A-Star Algorithm Considering Water Current, Traffic Separation and Berthing for Vessel Path Planning**. Journals of Applied Sciences. 9(6), 1057.
- Fabian, P., Jan-Hendrik, P., Johannes, J., Stefan, O., Maximilian, N., Florian, K. and Matthias, M. (2018). **Lanelet2: A high-definition map framework for the future of automated driving**. International Conference on Intelligent Transportation Systems, Maui, Hawaii, USA
- Il. Bea., Jaeyoung. M. and Jeonseok. S. (2019). **Toward a Comfortable Driving Experience for a Self-Driving Shuttle Bus**. Article of Electronic. 8(9), 943.
- Jonay, T., Jose, D., P., Rafael, A., Daniel, A. and Leopoldo, A. (2018). **Improving Odometric Accuracy for an Autonomous Electric Cart**. State-of-the-Art Sensors Technology in Spain 2017
- Joseph, R., Santosh, D., Ross, G. and Ali, F. (2016). **You Only Look Once: Unified, Real-Time Object Detection**. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA
- Kuantama, E., Vesselenyi, T., Dzitac, S., & Tarca, R. (2017). **PID and Fuzzy-PID Control Model for Quadcopter Attitude with Disturbance Parameter**. International Journal of Computers, Communications and Control. 12. 519-532.
- Martin M. (2008). **The Three-Dimensional Normal-Distributions Transform – an Efficient Representation for Registration, Surface Analysis, and Loop Detection**. Örebro University. Örebro, Sweden.

- Muhamad, Y., Budhi, I. and Casi, S.(2019) . **Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail**. International Conference on Electronics Representation and Algorithm, 1201, 12052.
- Mukesh. C. (2020). **Digit Recognizer**. [Online]. Available: <https://medium.com/>. [Accessed 18 May 2022].
- Mathworks. (2018). **Convolutional Neural Network**. [Online]. Available: <https://www.mathworks.com>. [Accessed 22 May 2021].
- Mario, H. and Bernhard, W. (2018). **Sensor and object recognition technologies for self-driving cars**. Computer-Aided Design and Applications, Vol. 15(4), pp. 1-8.
- Mark, E., Luc, V., G., Christopher, K., I., W., John, M., W. and Andrew, Z. (2010). **The Pascal Visual Object Classes (VOC) challenge**. International Journal of Computer Vision, Vol. 88, pp. 303-338.
- Mohammad, R., Navid, M., Saeid, N. and Shady, M. (2021). **Review and performance evaluation of path tracking controllers of autonomous vehicles**, IET Intelligent Transport Systems, vol. 15, no. 5, pp. 646-670.
- Naoki, A., Luis, Y., M., Ejiro, T., Yuki, Y. and Yoshiki, N. (2017). **Robust Localization Using 3D NDT Scan Matching with Experimentally Determined Uncertainty and Road Marker Matching**. IEEE Intelligent Vehicles Symposium (IV), Los Angeles, California, USA
- Ryan. J., H., Carmine. S., John. M., S. and Ryan. M., Y. (2018) **The Role of Infrastructure in an Automated Vehicle Future**. 40, 48-55.
- Ross, G., Jeff, D., Trevor, D. and Jitendra, M. (2014). **Rich feature hierarchies for accurate object detection and semantic segmentation**. IEEE International Conference on Computer Vision and Pattern Recognition, Columbus, OH, USA.

- Ross, G. and Microsoft Research. (2015). **Fast R-CNN**. IEEE International Conference on Computer Vision and Pattern Recognition, Santiago, Chile
- Society of Automotive Engineers (2018). **Levels of Driving Automation**. Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, SAE J3016.
- Su, P., Daniel, K., Xi, C., Hothaifa A., Q., Daniel, M. and Hayder, R. (2019). **3D Scan Registration Based Localization for Autonomous Vehicles - A Comparison of NDT and ICP under Realistic Conditions**. IEEE 88th Vehicular Technology Conference (VTC-Fall), Chicago, USA
- Sijia, L., Jie, L., Jinmin, H., Haoru, L. and Yu, L. (2021). **Research on NDT-based Positioning for Autonomous Driving**. 5th International Workshop on Advances in Energy Science and Environment Engineering (AESEE 2021), Volume 257
- Scott, D., P., Tawit, U., Baixue, Q. and Wei, L. (2015). **Autonomous Golf Cars for Public Trial of Mobility-on-Demand Service**. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Hamburg, Germany
- Saeid, S., Doung-Van, N. and Klaus-Dieter., K. (2019). **Guided Hybrid A-star Path Planning Algorithm for Valet Parking Applications**. 5th International Conference on Control, Automation and Robotics (ICCAR 2019), Beijing, China
- Zach, W. and Jeremy S., Cook. (2018). **Saved by the Sensor: Vehicle Awareness in the Self-Driving Age**. [Online]. Available: <https://www.machinedesign.com>. [Accessed 20 May 2021].
- Ziegler, J., Bender, P., Schreiber, M., Lategahn, H., Strauss, T., Stiller, C., Dang, T., Franke, U., Appenrodt, N., Keller, C.G., Kaus, E., Stiller, C. and Herrtwich, R.G. (2014). **Making Bertha Drive - An Autonomous Journey on A Historic Route**. IEEE Intelligent Transportation Systems Magazine, 6, 8–20.



ภาคผนวก ก

ผลงานวิจัยที่ได้รับการเผยแพร่ระหว่างการศึกษา

บทความที่ได้รับการเผยแพร่ระหว่างการศึกษา

Wongsathon, A. & Suradet, T., (2022). **Night-Time Human Detection From UAV**. 7th International Conference on Business and Industrial Research (ICBIR2022). 19-20 May 2022, Bangkok, Thailand



Night-Time Human Detection From UAV

Wongsathon Angkhem
 Department of Mechanical Engineering
 Suranaree University of Technology
 Nakhon Ratchasima, Thailand
 m6203375@g.sut.ac.th

Suradet Tantrairatn
 Department of Mechanical Engineering
 Suranaree University of Technology
 Nakhon Ratchasima, Thailand
 suradetj@sut.ac.th

Abstract— The Unmanned Aerial Vehicle is an effective vehicle for rescue, search, and surveillance missions. A thermal camera improves the UAV system to operate these missions in the nighttime. Real-time human detection is an algorithm to increase performance and improve to be fully autonomous in rescue missions. Many studies have led to the integration of real-time human detection from thermal aerial images, but the task remains difficult from various human features from multi capture angle and UAV altitude. This paper proposes an experimental process for implementing real-time human detection from UAVs in the nighttime. We choose the YOLOv3 model for real-time human detection. Then, we create a custom thermal aerial human dataset that multi-capturing angle and altitude. The dataset is captured in the same condition of UAVs operation. We prepare and preprocess the dataset before sending it to the model training process. Finally, we evaluate a trained model for mean-Average Precision. The accuracy of prediction is evaluated with a test set and real-time detection performance. The results demonstrate that the model can detect a human in real-time with a thermal image from a UAV view and the accuracy of detection is mAP of 64.8% in the operating range of the UAV.

Keywords—UAV, Human detection, Real-time detection, Thermal image, Nighttime

I. INTRODUCTION

In recent years, Unmanned Aerial Vehicle has become widely used in rescue, search and surveillance mission [1]. These applications can operate in a large area, difficult or inaccessible to reach from the ground and thick area as thick forests. UAV are equipped with various sensors for perception as camera, lidar and ultrasonic. The ability of optical cameras from the UAV system has been used to analyze objects or humans. Nevertheless, the quality of images from a UAV camera depends on lighting conditions, object in shadow and time. Low lighting and nighttime will increase the noise in pixels of optical camera images. The optical camera has not been covered in all situations. Thermal camera has become to solve that's a problem. Instead of capturing the image from visible light, a thermal camera has captured the infrared radiation of an object. Rescue and surveillance missions of UAV have been able to perform at nighttime via thermal camera.

Images analysis and monitoring are difficult to identify an object in the image. Video streaming speed and rapid movements of UAV are problems and challenges of night mission. Object detection has been used for searching humans with thermal image. This system has improved UAV to a fully autonomous system. Human detection in UAV has gained popularity for search and rescue missions [2][3]. However, human detection has challenged to perform with thermal aerial imagery. Whether it be disparity features of thermal and visible light image, less resolution and temperature of the environment.

Object detector has divided into two parts, a two-stage detector such as R-CNN and Faster R-CNN and a one-stage detector such as YOLO and SSD [4]. Two-stage detectors have high accuracy for object localization and recognition, whereas the one-stage detectors achieve high inference speed. Many Object detections have been studied to detect a human from a thermal image. Those algorithms have specific advantages and disadvantages. RCNN [5] was used to detect vehicles, humans and traffic lights in thermal imagery. The result is High accuracy but unable to perform real-time detection. Besides, the YOLOv3 model [6] was used for real-time image detection and recognition of human faces and gait on thermal images. Besides that, YOLO-I [7] is a modified YOLOv3 model for implementation with Human detection using a Thermal camera. YOLO-I has adjusted some of the residual modules and optimized the structure in the residual block to detect small objects from low-resolution thermal images. YOLO-I has performance for real-time detection of the thermal image. YOLOv3 is a performances object detector for real-time detection with thermal images from a normal perspective. However, Human detection from UAV with a thermal camera is still a challenge.

Object detection is supervised learning, this must use data for the learning process of the model. The dataset must cover the model's working objectives. Human detection of Thermal images from UAV has to learn with the dataset that collects thermal aerial images. For computer vision research, several thermal image datasets have been published. For example, KAIST [8], OTCBVS [9], CVC-14 [10] and FLIR [11]. Almost all of this dataset was developed for use to detect in normal view. Compared to Thermal image human datasets KAIST, CVC-14 and FLIR have captured humans, cars and roads in the daytime and nighttime conditions on the ground. There are no thermal images of human datasets captured by UAV. Even the OTCBVS Thermal dataset, which is a CCTV picture, focuses on humans from a high angle view. However, the above dataset is in a different format. Whether it is a matter of resolution, image quality, temperature conditions and the most important thing is the Perspective of photography. There is no thermal image dataset suitable for object detection in a UAV perspective. On the other hand, the collection of aerial thermal imaginary datasets necessitates this research. The study of human detection for walking path prediction from motion with UAV [2] has captured color images of humans from a variety of angles and altitudes. The above research has explained the dataset acquisition process for meeting the efficient model of human detection from UAV.

This research presents the techniques of system development for human detection from UAV thermals images. the scope of this study is focused on humans identifying at nighttime and in low-light conditions. For the purpose of using the UAV in real-time surveillance and rescue operations at night.

II. PROPOSED METHOD

A. Architecture and algorithm

A.You Only Look Once, Version 3 (YOLOv3) Algorithm [7]. This is a popular real-time object detection algorithm, YOLOv3 has improved performance from YOLOv2 and YOLO. YOLOv3 extracts feature of the entire image, divides the image into grid $S \times S$ size, predicts and generate a bounding box and finds object probability and a class confident score of these boxes. YOLOv3 has the advantage of being able to perform fast and real-time object detection while maintaining accuracy. YOLOv3's work is object classification as well as bounding box regression at the same time, which differs from RCNN and Faster RCNN.




Fig. 1. The YOLOv3 architecture. Darknet53 without fully connected layers is represented by the green box and upsampling is indicated by the orange arrow.

The YOLOv3, input images size 416x416 or any size dividable 32, such as 320x320, 640x640, etc. are passthrough Darknet-53 at layer 0 – 74th. YOLOv3 has used the Darknet-53 backbone. Darknet53 are having high efficiency for feature extraction. The output from the darknet is a feature map. Down-sampled feature map are combined with features from the residual layer. The features are then transferred to the prediction layer in three scales, similar to FPN. The scale of the prediction layer, feature layer has been stridden 32, 16 and 8 respectively. Default of input image resolution 416x416, prediction layers grid size is equal to 13x13, 26x26 and 52x52 respectively for predict difference size of the object in the image. The outputs of prediction are bounding box data and class probability consists in each grid. The bounding box of YOLOv3 has three boxes per grid for the result. The bounding box from 3 layers of prediction is sometimes detected in the same object. Non-Max Suppression applies to these boxes to prevent multiple detections of the object. NMS passes one Bounding box for each object. The Bounding box consists of five values. The center position of the bounding box is represented in x and y. box width and height are represented in w and h. And c represents the confidence of the object in the bounding box. For the final process, The bounding box of the object with the highest class confidence is projected onto the input image for the result of object detection.

B. Project outline




Fig. 2. Outline of the project.

The procedure of this study starts with a setup scenario that approximates the UAV nighttime search operation and records a thermal image with a UAV perspective for correcting datasets. The corrected datasets are be preparing, cleaning and pre-processing for the model learning process. After model training, the results model is tested for finding evaluation index and detection performance on the real system.

C. System overview

This research proposes a technique for detecting people in real-time using UAV thermal imagery. The preparation of research and testing equipment is the initial step of the process. A Hexa-rotor UAV was utilized to install equipment during testing. Our UAV is equipped with Nvidia Jetson Xavier NX, this is a Single-board computer for real-time image processing. Along with a Wireless system 2.4GHz for sending data to other devices through WLAN. A FLIR tau 2 Thermal camera with a gimbal has also been installed on the UAV payload. The FLIR tau 2 is a longwave infrared (LWIR) thermal imaging camera core and lens 35mm 9.3H x 7.1V FoV equipped with the camera.



Fig. 3. UAV's thermal camera.

D. Data acquisition

Data acquisition or dataset collection is the first process of supervised learning. The outdoor UAV's operating range is flight upper 10-15 m. For obvious reasons, altitude must be a higher obstacle or building and the images from UAV's camera reveal a lot of details at high altitudes. We have designed and plan to collect custom datasets for use with High-altitude human detection from a Thermal camera. Our thermal camera has a resolution of 336x256 in the analog signal. Jetson Xavier NX with analog to digital converter is received data of images from the camera and converted them to digital images in a 420x360 resolution. We recorded streaming images into video format and saved them into memory for collecting.

With the ability to adjust pitch angle, the FLIR Tau 2 thermal camera with a gimbal can change the perspective of the image from a UAV. To detect a human at a variety of heights, the camera angle needs to be adjusted for capturing images from multiple angles if the flight of the UAV is limited, the height of the UAV affects the angle between the

camera and the human, the resulting image will change according to the height of the UAV, azimuth angle and polar angle.

We have divided the altitude of the UAV and camera angle for capturing as follows, the range of the UAV's altitude is 15,20,25,30,35,40 and 45 m from the actor and the camera angle are 45-85 degree depressed from the horizontal line for each UAV's altitude. We have defined the lowest altitude for dataset collecting following UAV's operating altitude. And defined the highest altitude from the minimum pixels of the object in the image, that a human detector can detect. When input image 420x360 (equal to dataset images resolution) resolution, fine object prediction layer of YOLOv3 is 52x52 grid. This means the minimum of pixels of the object for a feature in the fine grid is 8 pixels. We measured the pixel size of the objects for each altitude and discovered that the altitude for objects 8-10 pixels in the image should not exceed 45 m.

For recording, we have 5 persons as actors in the dataset. Video is recorded in 2 ways, from the high level of the building and from a UAV. Both recording techniques are recorded with a fixed thermal camera position and altitude, pitch and yaw vary from objects position. The walking pattern is set up so that actors walk in a circle, recording features from every azimuth angle in every polar angle. The features from different azimuth angles are shown in the following Fig. 4.



Fig. 4. Example of our dataset sample in different azimuth angles.

UAV's search and rescue mission must be able to perform in various areas. Environment background is one of the variables of the datasets. We plan to capture a thermal dataset in two different backgrounds, these are grassland and concrete. The infrared radiation of concrete and grassland differs at night. Additionally, we record the dataset of obscured humans behind the tree. Multi place dataset correcting is shown in the following Fig. 5.



Fig. 5. Example of our dataset in different environments.

E. Data preparing

Each frame of the UAV's thermal video must be extracted into an image. The whole images are called datasets. For cleaning the dataset, images that have obvious objects and

clear images were only selected. The image that is not an object in a frame and similarly feature (comparing frame-to-frame and feature are very little change) are being eliminated from the dataset. After the cleaning process, we have to label the object in the image. Supervise.ly [12] is a platform that we use for dataset labeling. We draw an enclosed rectangle to object for each image. And define the object's class, a Person is only one class in this study.

F. Data pre-processing

The labeled dataset has to pass through pre-processing before model training. The first step, augment the dataset to be distributed and more diverse. we prepare the dataset for the robustness of our model and prevent miss detection from a change of various environmental temperatures. This step has 3 parts as follows.

- 1) *Flipping*, increase diversity and quantity of images with a vertical flip
- 2) *Adding noise*, generate slight noise onto some images.
- 3) *Shuffle*, shuffling images in the dataset.

For the second step, the dataset has been split into 3 parts training dataset, validation dataset and test dataset in the ratio of 90:5:5. The training dataset has 13019 images, the validation has 2248 images and 2094 images for performance evaluation in a test dataset

G. Performance evaluation

The training process of YOLOv3 was done on Supervise.ly with our customized thermal dataset. The loss is a metric for using to initially indicate model performance. During the training process, the loss was reported at every checkpoint for evaluating the model on the validation dataset. The loss metric was used to analyze model overfitting or underfitting when training with our dataset. In this study, the model was trained with 200 epochs and the best loss of the model is 0.0019. The Models weight from the best-loss epoch was selected for our model.

To evaluate the performance of the Human detection model, we performed a trained human detection model on a test dataset with a 0.5 confident threshold. The prediction result is shown preliminary human detection performance.

Mean Average Precision (mAP) is a commonly used metric for evaluating object detection performance. This metric is comparing the result of detection and the ground truth. We used the result at the IOU threshold of 50% to calculate mAP. The IOU is calculating the ratio between intersection area and union area of two bounding boxes, between prediction result and ground truth, shown in Fig. 6.



Fig. 6. Intersection-over-Union Calculation.

H. Implementation for real-time human detection

The final step is to implement the model in our UAVs system. This is a real-time detection model performance evaluation testing. The UAVs were supposed to fly at a height of about 35 meters and capture images to be streamed into a processor. A Jetson Xavier NX downloaded our trained model weight into memory. Robot Operating System were used to run Human detection and stream the detection image passthrough WLAN protocols. We used a Ground computer station for checking the result of the detection.

III. RESULTS

TABLE I. EVALUATION METRICS OF THE MODEL

Evaluation matrix	mAP (0.5 IoU)	Precision	Recall
Proposed model	0.648	0.810	0.718
YOLOv3-COCO	0.230	0.438	0.138

Evaluation metric of Our proposed method is compared with YOLOv3 based on the COCO dataset for detection performance on the test dataset. The YOLOv3 COCO [7] is a pre-trained model for comparison of detection performance, this has 80 classes of objects and is included with the person class. Table I. shows Our proposed method has a mean Average precision of 0.648, which is more accurate than detection from YOLOv3 COCO with a mean average precision of 0.230. For the reason of human features from the thermal image and Bird-eye-view-perspective that differ from the normal view from RGB image. This means the model training of YOLOv3 with a custom dataset is capable to detect humans on a thermal image from UAV.




Fig. 7. Results of human detection on the test dataset (cyan box from prediction and violet box is ground truth). The normal range detection result in (a), hiding object detection in (b) and (c) show the highest detection range

The Average Precision of the model from the evaluation is 0.648. The above figures show a detection result of the evaluation process with the test dataset. All detections are affected by the detection results in each condition of the object's height, angle and surroundings.

Fig. 7 (a) is a result of a test dataset with a depressed shooting angle of 45-85 degrees with a concrete and grass background. And a height of the thermal camera to the object of approximately 30 m, resulting in a distance between the human and the thermal camera of approximately 30 -42 m. The outcome demonstrates that detection was successful in detecting people in this range. Because the image of the test dataset appears to be in the same range as the dataset used in the model's learning process. We can also see that the features depicted in the image retain the person's characteristics, thus giving such results.

Fig. 7 (b) shows the model's capability for a dataset with trees partially obscuring objects. The angle of the object for this set is in the range of 60-85 degrees and the height is about 15 m. Because YOLOv3 is a regression model, it has been found that it can detect 60% or more of appearing human features. In order for the result of the prediction to come out as a human feature obtained from an image, it would be necessary to be greater than 50% of the object's full attribute.

Fig. 7 (c) is a dataset taken at a height of 35 m with a depressed angle of 70-85 degrees to objects on a concrete background. The evaluation result that the model was able to detect sometimes. Because the features of the object from thermal images of this situation are very small. Furthermore, the resolution of Our Thermal camera is affected the human features that emerge are ambiguous. And the angle at which the feature is pressed makes determining what kind of object it is from this point of view and distance quite difficult.




Fig. 8. Comparison of human detection on the test dataset between YOLOv3 COCO (left) and the proposed method (right) with the same conditions and frame.

The above Fig. 8 show a comparison of detection results with the test dataset between our proposed method and YOLOv3 COCO. The YOLOv3 COCO predicts the person are bird, dog and person with low confidence in some views of the thermal aerial image. In the same view, Our proposed model predicts correctly with high confidence. This is to ensure the efficiency of Our proposed model is capable to detect a human from the UAV in the nighttime.

Finally, the Performance testing of real-time human detection from UAV in the nighttime was done on our UAVs system. A custom model YOLOv3 was performed on our UAVs stand-alone system, that inference time of computing can achieve real-time detection at 7 fps.

IV. CONCLUSION

In this study, we aimed to present techniques to perform real-time human detection from UAV in the nighttime. A thermal camera was used instead of an optical camera to capture the object in the nighttime. Data collection is implemented by recording human video streaming with various perspectives using thermal cameras. It is within the operating range of the UAV and this perspective results in different features and influences the human detection models. Dataset was used in the model learning process with YOLOv3 algorithm. In the testing process, a trained model was evaluated on the test dataset and implemented in a real environment. The detection model can detect a human in the height level of 15-45 m and a depressed angle of 45-85 degrees, but the recommended height range is 15-30 m for high accuracy. Furthermore, the detection performance of UAVs system with Jetson Xavier NX is achieved real-time detection at 7 FPS of inference time.

REFERENCES

- [1] J. Shi, G. Zhang, J. Yuan, and Y. Zhang, "Improved YOLOv3 Infrared Image Pedestrian Detection Algorithm", 6th International Conference of Pioneering Computer Scientists, vol. 1257, pp. 506-517, 2020, doi: 10.1007/978-981-15-7981-3_37
- [2] A. G. Perera, A. Al-Naji, Y. W. Law, and J. Chahl, "Human Detection and Motion Analysis from a Quadrotor UAV," IOP Conference Series: Materials Science and Engineering, vol. 405, no. 1, p. 012003, doi: 10.1088/1757-899X/405/1/012003
- [3] S. L. Krishna, G. S. R. Chaitanya, A. S. H. Reddy, A. M. Naidu, S. S. Poorna, and K. Amuraj, "Autonomous Human Detection System Mounted on a Drone," in 2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), Mar. 2019, pp. 335-338.
- [4] L. Jiao, F. Zhang, F. Liu, S. Yang, L. Li, Z. Feng, and R. Qu, "A Survey of Deep Learning-Based Object Detection," in IEEE Access, vol. 7, pp. 128837-128868, 2019, doi: 10.1109/ACCESS.2019.2939201.
- [5] U. Mittal, S. Srivastava, and P. Chawla, "Object Detection and Classification from Thermal Images Using Region based Convolutional Neural Network," Journal of Computer Science, vol. 15, no. 7, pp. 961-971, 2019, doi: 10.3844/jcssp.2019.961.971.
- [6] S. A. F. Manssor, S. Sun, and M. A. M. Elhassan, "Real-Time Human Recognition at Night via Integrated Face and Gait Recognition Technologies," Sensors, vol. 21, no. 13, p. 4323, Jun. 2021, doi: 10.3390/s21134323.
- [7] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," arXiv preprint arXiv:1804.02767, 2018.
- [8] S. Hwang, J. Park, N. Kim, Y. Choi and I. S. Kweon, "Multispectral pedestrian detection: Benchmark dataset and baseline," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 1037-1045, doi: 10.1109/CVPR.2015.7298706.
- [9] J. W. Davis and M. A. Keck, "A Two-Stage Template Approach to Person Detection in Thermal Imagery," 2005 Seventh IEEE Workshops on Applications of Computer Vision (WACV/MOTION'05) - Volume 1, 2005, pp. 364-369, doi: 10.1109/ACVIMOT.2005.14.
- [10] A. González, Z. Fang, Y. Socarras, D. Vázquez, J. Xu, and A. M. López, "Pedestrian Detection at Day/Night Time with Visible and FIR Cameras: A Comparison," Sensors, vol. 16, no. 6, p. 820, Jun. 2016, doi: 10.3390/s16060820.
- [11] Teledyne FLIR ADAS Dataset: Concatenated, 2019, Teledyne FLIR, June. 2019. [Online]. Available: <https://www.flir.in/om/adas/adas-dataset-form/>.
- [12] D. Drozdov, M. Kolomeychenko, and Y. Borisov, "Supervisely", supervise.ly, <https://supervise.ly/>.



ประวัติผู้เขียน

นายวงศธร อ่างเข้ม เกิดเมื่อวันที่ 9 พฤษภาคม พ.ศ.2541 จบการศึกษาในระดับมัธยมศึกษาตอนปลายจากโรงเรียนราชสีมาวิทยาลัย อ.เมือง จ.นครราชสีมา และสำเร็จการศึกษาวิศวกรรมศาสตรบัณฑิตในหลักสูตรวิศวกรรมยานยนต์ มหาวิทยาลัยเทคโนโลยีสุรนารี ในปี พ.ศ. 2562

ในปี พ.ศ.2563 เข้าศึกษาต่อในระดับปริญญาโท หลักสูตรวิศวกรรมเครื่องกลและระบบกระบวนการ ณ มหาวิทยาลัยเทคโนโลยีสุรนารี ได้รับการสนับสนุนทุนการศึกษาแก่นักศึกษาระดับบัณฑิตศึกษาที่คณาจารย์ได้รับทุนวิจัยจากแหล่งทุนภายนอก เป็นระยะเวลา 2 ปี ในระหว่างการศึกษาได้รับมอบหมายให้เป็นผู้ช่วยสอน รายวิชา 551755 ระบบที่ทำงานอิสระ ทั้งนี้ ผู้วิจัยได้สะสมความรู้ จากประสบการณ์การทำงานในห้องปฏิบัติการวิศวกรรมควบคุมและระบบอัตโนมัติ การสอน และการศึกษาในระดับบัณฑิตศึกษามาประยุกต์ใช้กับงานวิจัย และมีโอกาสได้ทำวิจัยในด้านปัญญาประดิษฐ์ จนได้รับการเผยแพร่ผลงานจำนวนทั้งสิ้น 1 งาน คือ

1. Wongsathon, A. & Suradet, T., (2022). Night-Time Human Detection From UAV. 7th International Conference on Business and Industrial Research (ICBIR2022). 19-20 May 2022, Bangkok, Thailand