

การตรวจจับเส้นเลนถนนด้วยเทคโนโลยีระบบการทำแผนที่เคลื่อนที่จากเทคนิคการจัดกลุ่ม

Lane Marking Detection Using Mobile Mapping System Technology with Clustering Technique

อนุธิดา ฤทธิพันธ์^{1,*} เฉลิมชนม์ สติระพจน์² และ สุรเชษ ศรีนารา³

^{1,2} สาขาวิชาวิศวกรรมสำรวจ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพมหานคร

³ สาขาวิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยพะเยา จ.พะเยา

*Corresponding author; E-mail address: anuthida.rtp@gmail.com

บทคัดย่อ

ปัญหาความไวต่อแสงและสภาพแวดล้อมของกล้องส่งผลต่อความแม่นยำในการตรวจจับเส้นเลนในเทคโนโลยียานยนต์ไร้คนขับ งานวิจัยนี้จึงพัฒนาเทคนิคตรวจจับเส้นเลนจากระบบการทำแผนที่เคลื่อนที่ด้วยเทคนิค Spectral Clustering ซึ่งอ้างอิงจากหลักของทฤษฎีกราฟ ข้อมูลที่ใช้ศึกษาครอบคลุมระยะทาง 2.8 กิโลเมตรโดยรอบสถานีรถไฟความเร็วสูงชาหลุน เมืองไถหนานประเทศไต้หวัน และประมวลผลด้วยโปรแกรมทางวิศวกรรม MATLAB โดยข้อมูลจะถูกคัดแยกพื้นผิวถนนด้วยอัลกอริทึม RANSAC และตรวจจับเส้นเลนด้วยเทคนิค Spectral Clustering และเปรียบเทียบกับ DBSCAN ซึ่งเป็นเทคนิคการจัดกลุ่มที่ได้รับความนิยมในงานวิจัยโดยทั่วไป ผลการวิจัยแสดงให้เห็นความแม่นยำของ Spectral Clustering ด้วยค่า Precision 90.70%, Recall 83.37%, F1-Score 86.88% และ IoU 76.80% ที่สามารถตรวจจับเส้นเลนได้แม้ในบริเวณที่มีเงาจากรถยนต์หรือเลนที่มีสีจาง ซึ่งช่วยลดข้อจำกัดของเทคโนโลยีดั้งเดิมและพัฒนาศักยภาพให้กับการตรวจจับเส้นเลนถนนสำหรับเทคโนโลยียานยนต์ไร้คนขับ

คำสำคัญ: ระบบการทำแผนที่เคลื่อนที่, อัลกอริทึม RANSAC, ไลดาร์, เทคนิคการจัดกลุ่มแบบ Spectral, การเรียนรู้แบบไม่มีผู้สอน

Abstract

The sensitivity of cameras to lighting and environmental conditions affects the accuracy of lane detection in Autonomous Driving System. This study develops a lane detection technique using LiDAR data from a Mobile Mapping System, leveraging the intensity differences of lane markings painted with retro-reflective materials to enhance detection accuracy. The study covers a 2.8 km area around Shalun High-Speed Rail Station, Taiwan, with data processing conducted using MATLAB. Point cloud data is segmented to extract ground surface using the RANSAC algorithm, followed by lane detection using Spectral Clustering, which classifies data groups based on graph theory

with Precision 90.70%, Recall 83.37%, F1-Score 86.88% and IoU 76.80%. The research show that Spectral Clustering enhances Autonomous Driving System accuracy overcoming camera limitations and improving transportation.

Keywords: Mobile Mapping System, Extended Kalman Filter, Random Sample Consensus, Spectral Clustering, Unsupervised Learning

1. บทนำ

ปัจจุบันนี้เทคโนโลยียานยนต์ไร้คนขับ (Autonomous Vehicle) กำลังเป็นที่น่าจับตามองเพราะมีศักยภาพในการเพิ่มความปลอดภัยบนท้องถนน ลดอุบัติเหตุจากความผิดพลาดของมนุษย์ จากการผสมผสานเทคโนโลยีจากหลายศาสตร์ เช่น Computer Vision, Robotic, Deep learning และ Navigation เพื่อให้รถสามารถขับเคลื่อนได้อย่างปลอดภัยโดยไม่ต้องอาศัยผู้ควบคุม เทคโนโลยีนี้ต้องพึ่งพาองค์ประกอบสำคัญอย่างแผนที่ความละเอียดสูง (High-Definition Map) ในการควบคุมการเคลื่อนที่ โดยมีข้อมูลเส้นเลนเป็นองค์ประกอบสำคัญที่ช่วยให้รถยนต์ตัดสินใจในการควบคุมทิศทางอย่างถูกต้องตามการตรวจจับข้อมูลเส้นเลนให้แม่นยำยังคงเป็นความท้าทาย ในงานวิจัยด้านการตรวจจับเส้นเลนโดยส่วนใหญ่เลือกใช้ข้อมูลจากกล้องเนื่องจากมีต้นทุนต่ำและมีความแม่นยำ [1] แต่กลับพบปัญหาจากความไวต่อสภาพแวดล้อมในการเก็บข้อมูล [2] ตัวอย่างเช่นในงานวิจัย [3] ที่พัฒนาอัลกอริทึม LaneRTD สำหรับตรวจจับเส้นเลนจากกล้องและพบปัญหาที่อัลกอริทึมไม่สามารถแยกเส้นเลนออกจากพื้นหลังได้ชัดเจนในสถานการณ์ที่มีแสงจ้าหรือเงาทึบเกินไป ในงานวิจัย [4] จึงได้เสนอการใช้ Fuzzy Logic ในการแก้ปัญหาดังกล่าว ผลการศึกษพบว่าวิธีนี้ช่วยเพิ่มความแม่นยำของการตรวจจับเมื่อเทียบกับวิธีมาตรฐาน แต่ยังคงมีข้อจำกัดในการแยกแยะระหว่างเส้นทึบและเส้นประในบางสภาพแวดล้อมที่มีเงารบกวนซับซ้อน และในการศึกษา [5] พัฒนาเทคนิคแบ่งกลุ่มจากความหนาแน่น Density-based Spatial Clustering (DBSCAN) เพื่อเพิ่มความแม่นยำในการใช้กล้องตรวจจับเลนถนนและรับมือกับข้อมูลรบกวน (Noise) ได้เผชิญกับปัญหาการตรวจจับเลนขาดหายในข้อมูลที่ถูกรบกวนในช่วงพระอาทิตย์กำลังตกดิน จาก

งานวิจัยที่กล่าวไปข้างต้นแสดงถึงข้อจำกัดจากปัจจัยความไม่แน่นอนทางสภาพแวดล้อมจากอิทธิพลของแสงและเงา แต่ในความเป็นจริงแล้ว อัลกอริทึมควรตรวจจับเส้นได้แม้ในสภาพแวดล้อมในการเก็บข้อมูลไม่สามารถคาดเดาได้

ในทางกลับกันระบบการทำแผนที่เคลื่อนที่หรือ Mobile Mapping System (MMS) เป็นเทคโนโลยีการสำรวจภูมิประเทศสามมิติที่ผสานการทำงานจากหลากหลายเซนเซอร์สามารถนำมาใช้ในการตรวจจับเส้นเลนได้เช่นกัน เนื่องจากสิ่งที่ใช้ในการทาเลนถนนเป็นสีที่มีความสามารถในการสะท้อนแสง (Retro-Reflective) เพื่อเพิ่มทัศนวิสัยในเวลากลางคืน [6] ทำให้ค่าความเข้มของสัญญาณสะท้อนกลับ (Intensity) ที่วัดได้จากการปล่อยพัลส์ลำแสงอินฟราเรดของไลดาร์ (Light Detection and Ranging: LiDAR) มีค่าสูงกว่าบริเวณอื่นอย่างชัดเจน การตรวจจับเส้นเลนจากค่า Intensity ไลดาร์จะช่วยลดผลกระทบและสัญญาณรบกวนที่เกิดขึ้นจากแสง จากการศึกษา [7] ที่เปรียบเทียบระหว่างการใช้ไลดาร์และกล้องพบว่าอัตราการตรวจจับเส้นเลนของไลดาร์มีค่าสูงกว่าทั้งในการเก็บข้อมูลช่วงเวลากลางวัน, การเปิดไฟต่ำเก็บข้อมูลในเวลากลางคืน และสภาพแวดล้อมที่มีฝุ่น ซึ่งมีค่ามากกว่าการใช้กล้องถึง 18%, 43% และ 26% ตามลำดับ เนื่องจากต้นทุนในการประมวลผลข้อมูลสามมิติที่ได้จากไลดาร์ ทำให้การศึกษาโดยส่วนใหญ่มุ่งเน้นไปที่การพัฒนาอัลกอริทึมใช้กำลังการประมวลผลต่ำแต่ยังคงให้ความแม่นยำสูง ต่อมาใน [6] ได้เลือกใช้เทคนิค Expectation-Maximization ในการตรวจจับเส้นเลนจากค่า Intensity พบว่าในขั้นตอนการแปลงข้อมูลจาก 3 มิติเป็น 2 มิติ หรือการทำ Rasterization สามารถช่วยลดภาระการประมวลผลได้ แต่การเลือกใช้ขนาดของกริดส่งผลต่อความละเอียดของผลลัพธ์และอาจทำให้เกิดการตรวจจับเกินได้ (False Positive) ต่อมา [8] ได้ตรวจจับเส้นในพื้นผิวคอนกรีตด้วยวิธีการกำหนดเกณฑ์ความเข้ม (Intensity Thresholding) ประเมินประสิทธิภาพได้ Precision 84.4%, Recall 57.9% และ F1-score 65.9% แต่เมื่อใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) สามารถช่วยเพิ่มความแม่นยำของการตรวจจับได้เป็น Precision 88.1%, Recall 83.3%, และ F1-score 85.1% และช่วยลดข้อผิดพลาดจากปัญหาความหนาแน่นของจุด (Point Cloud Density) บริเวณขอบเส้นเลนและเส้นชะลอความเร็ว

จากที่กล่าวมาข้างต้นแม้ว่าวิธีการเรียนรู้เชิงลึกจะช่วยเพิ่มประสิทธิภาพในการตรวจจับเส้นเลนได้ แต่ข้อจำกัดด้านปริมาณของข้อมูลและระยะเวลาในการฝึกสอน (Training data and period) ยังคงเป็นอุปสรรคสำคัญ จึงมีงานวิจัยบางส่วนเลือกใช้การเรียนรู้แบบไม่มีผู้สอนแทน (Unsupervised Learning) โดยเฉพาะเทคนิคการจัดกลุ่มไม่จำเป็นการอ้างอิงจากระยะทาง K-means และการอ้างอิงจากความหนาแน่น DBSCAN ตัวอย่างเช่น [9], [10] อย่างไรก็ตามเทคนิคเหล่านี้สามารถจัดกลุ่มได้เพียงข้อมูลที่ไม่ซับซ้อน ในการศึกษา [11] ได้นำเสนอการใช้ Spectral Clustering ในการตรวจจับหลุมบนถนนที่มีลักษณะไม่เป็นรูปร่างที่ชัดเจน การศึกษานี้แสดงให้เห็นถึงการรับมือกับข้อมูลที่มีโครงสร้างซับซ้อนและไม่เป็นเชิงเส้น (Non-linear) ของเทคนิคดังกล่าวได้ดีด้วยการแบ่งกลุ่มที่อ้างอิงจากทฤษฎีกราฟ การใช้เทคนิค Spectral Clustering ตรวจจับเส้นเลนจะแบ่งกลุ่มข้อมูลจากกราฟความคล้ายคลึง (Similarity

Graph) ของคุณลักษณะ (Feature) ที่ซับซ้อนไม่ว่าจะเป็นข้อมูลเชิงพื้นที่ รูปร่าง และค่าความเข้ม ทำให้เทคนิคนี้สามารถแบ่งกลุ่มข้อมูลในเชิงโครงสร้างมากกว่าเมื่อเปรียบเทียบกับวิธี DBSCAN ซึ่งเป็นที่นิยมในงานวิจัยโดยทั่วไป

จากที่กล่าวมาข้างต้นจึงนำมาสู่งานวิจัยศึกษาการตรวจจับเส้นเลนถนนโดยมีวัตถุประสงค์ของการศึกษานี้คือ

1.1 เพื่อแสดงให้เห็นถึงศักยภาพของเทคนิค Spectral Clustering ว่ามีประสิทธิภาพในการตรวจจับเส้นเลนได้ดีกว่าเมื่อเปรียบเทียบกับอัลกอริทึม DBSCAN ซึ่งเป็นเทคนิคที่ได้รับความนิยมอย่างแพร่หลายในงานวิจัยด้านการตรวจจับเส้นเลน

1.2 เพื่อแสดงให้เห็นว่าการเลือกใช้ค่าความเข้มจากไลดาร์เป็นคุณสมบัติหลักในการตรวจจับเส้นเลนให้ผลลัพธ์ที่แม่นยำกว่าการใช้ระบบสี RGB ที่มีความไวต่อแสงและเงา

โดยในบทความนี้แบ่งออกเป็น 4 ส่วน ส่วนที่ 2 แสดงแนวคิดวิธีดำเนินงาน ส่วนที่ 3 แสดงผลการศึกษา และส่วนที่ 4 จะแสดงอภิปรายผลและให้ข้อเสนอแนะสำหรับการศึกษานในอนาคต

2. วิธีการดำเนินงาน

2.1 ข้อมูลที่ใช้ในการศึกษา


เส้นทางการศึกษาคือถนนบริเวณสถานีรถไฟความเร็วสูงชาลุน (Taiwan High Speed Rail: THSR) ซึ่งตั้งอยู่ใกล้ชายแดนระหว่างเมืองเกาสงและไถหนานทางตอนใต้ของไต้หวัน โดยมีเส้นทางการศึกษายาว 2.8 กิโลเมตร แสดงดังรูปที่ 1 พื้นที่ศึกษาพบลักษณะเส้นเลนหลายประเภทไม่ว่าจะเป็นเส้นประ เส้นทึบ ตัวอักษร ลูกศร รวมถึงทางม้าลาย สภาพแวดล้อมโดยรอบข้างประกอบไปด้วยต้นไม้ขนาดใหญ่และสิ่งก่อสร้างเพียงเล็กน้อยเนื่องจากเป็นบริเวณสวนสาธารณะ แต่ในพื้นที่โดยส่วนใหญ่มีรถยนต์จอดข้างถนนบนตบถนนและเส้นเลนบางส่วน



รูปที่ 1 เส้นทางการศึกษาโดยรอบสถานีรถไฟไถหนาน

การเก็บข้อมูลใช้ระบบ Mobile Mapping System (MMS) โดยประกอบไปด้วยเซนเซอร์ไลดาร์แบบโซลิตสเตต Livox Horizon (HAP) พร้อมเสารับสัญญาณระบบนำทางด้วยดาวเทียม (Global Navigation Satellite System: GNSS) Novatel GPS-703-GGG โดยใช้วิธีการรังวัดแบบจลน์ (Real-time Kinematics: RTK) ในการวัดค่าพิกัด จากผลกระทบ

จากการแพร่กระจายของคลื่นหลายวิถี (Multipath) เมื่อเก็บข้อมูลในพื้นที่เมืองรวมถึงปัญหาความถี่ในการเก็บข้อมูลจึงมีการผนวกรวมระหว่าง GNSS ร่วมกับระบบนำหนแบบเฉื่อย (Inertial Navigation System: INS) ในระดับ Tactical grade ประกอบไปด้วยโมเดล iMAR-RQH และ Pwrpak E2 แสดงคุณสมบัติดังตารางที่ 1 และ 2 ตามลำดับ



รูปที่ 2 อุปกรณ์ที่ใช้ในการเก็บข้อมูล


ตารางที่ 1 คุณสมบัติของระบบนำทางเฉื่อย โมเดล iMAR-RQH

โมเดล iMAR-RQH	Accelerometer	Gyroscope
Bias Instability	< 10 μg	< 0.002°/hr
Random Walk Noise	< 8 $\mu\text{g}/\sqrt{\text{Hz}}$	< 0.0015°/√hr

ตารางที่ 2 คุณสมบัติของระบบนำทางเฉื่อย โมเดล PwrPak7-E2

โมเดล PwrPak7-E2	Accelerometer	Gyroscope
Bias Instability	0.01 mg	0.8°/hr
Random Walk Noise	0.025 m/s/√hr	0.06°/√hr

2.2 วิธีการดำเนินงาน



รูปที่ 3 แผนผังขั้นตอนการทำงาน

จากแผนผังในรูปที่ 3 แสดงถึงลำดับขั้นตอนการทำงานโดยเริ่มจากการผนวกรวมข้อมูลของเซนเซอร์เพื่อให้ได้ข้อมูล Point cloud ที่มีค่าพิกัดที่แม่นยำ จากนั้นจึงทำการคัดแยกจุดที่เป็นพื้นถนนออกมาจากข้อมูลทั้งหมด และแปลงข้อมูลจุดที่ได้ให้อยู่ในรูปแบบราสเตอร์เพื่อที่จะตรวจสอบเส้นเลนในขั้นตอนสุดท้ายด้วย Spectral Clustering โดยรายละเอียดของแต่ละขั้นตอนแสดงในหัวข้อ 2.3 ถึง 2.7

2.3 การผนวกรวมสัญญาณ GNSS และ INS ด้วยตัวกรองคาลมานแบบขยาย (Extended Kalman Filter: EKF)

จากความรู้ในการเก็บข้อมูลที่ไม่เท่ากันของระบบ GNSS ที่มีค่า 10 เฮิร์ตกับระบบ INS ที่มีค่า 100 เฮิร์ตจึงต้องมีการใช้อัลกอริทึมตัวกรองคาลมานแบบขยาย (Extended Kalman Filter) เพื่อผนวกรวมสัญญาณพร้อมปรับแก้เพื่อให้ได้มาซึ่งข้อมูลทางตำแหน่งที่แม่นยำสำหรับ Point Cloud EKF เป็นอัลกอริทึมที่ถูกนำมาใช้ในการประมาณค่าสถานะของระบบพลศาสตร์ด้วยแบบจำลองที่ไม่เป็นเชิงเส้น (Non-linear) เพื่อรองรับการเคลื่อนที่ของรถยนต์ที่มีความซับซ้อนโดยการคำนวณซ้ำ 2 ขั้นตอนดังนี้

2.3.1 การทำนาย (Prediction step)

ในกระบวนการทำนายระบบจะคาดการณ์ค่าสถานะของระบบในช่วงเวลาถัดไปโดยอ้างอิงจากแบบจำลองการเคลื่อนที่ (Motion Model) โดยคาดการณ์การเปลี่ยนแปลงของระบบตามกาลเวลาจากสถานะปัจจุบันและข้อมูลการควบคุม (Input) ซึ่งอาจได้แก่ ความเร่งเชิงเส้น หรืออัตราการหมุนของยานพาหนะจากระบบ INS หลังจากนั้นจะมีการคำนวณค่าความแปรปรวนร่วม (Covariance) ที่ช่วยบ่งชี้ระดับความเชื่อมั่นของค่าที่คาดการณ์ได้ โดยพิจารณาปัจจัยที่อาจส่งผลกระทบต่อความแม่นยำของการทำนายรวมถึงค่าคลาดเคลื่อนที่อาจเกิดขึ้น แบบจำลองการเคลื่อนที่ที่แสดงดังสมการที่ (1)

$$x_t = f(x_{t-1}, u_t) + w_t \quad (1)$$

โดยที่ x_t คือสถานะของระบบที่เวลา t , u_t คือข้อมูลนำเข้าและ w_t คือความไม่แน่นอนของกระบวนการ (Process Noise)

2.3.2 การปรับปรุง (Update step)

เมื่อเข้าสู่ขั้นตอนการปรับปรุง อัลกอริทึมจะนำค่าที่วัดได้จากเซนเซอร์มาเปรียบเทียบกับค่าที่ทำนายไว้ หากพบความแตกต่างระหว่างค่าทั้งสองระบบจะทำการปรับแก้ค่าสถานะของระบบให้มีความถูกต้องมากขึ้น รวมไปถึงการแก้ไขเมตริกซ์ความแปรปรวนร่วมให้สะท้อนถึงระดับความเชื่อมั่นใหม่ที่ได้รับการปรับปรุง ขั้นตอนนี้ช่วยลดค่าคลาดเคลื่อนสะสมจากการคาดการณ์ก่อนหน้านี้ และช่วยให้ค่าที่ทำนายในการรอบถัดไปมีความแม่นยำยิ่งขึ้นโดยใช้แบบจำลองเซนเซอร์ (Sensor Model) แสดงดังสมการที่ (2)

$$z_t = h(x_t, v_t) \quad (2)$$

โดยที่ x_t คือสถานะของระบบที่เวลา t , z_t คือค่าสถานะจากการวัดที่เวลา t และ v_t คือค่าคลาดเคลื่อนที่ได้จากการวัด (Observation Noise)

กระบวนการทั้งหมดนี้ทำงานเป็นวงรอบอย่างต่อเนื่อง โดยที่แต่ละรอบจะนำค่าที่ได้รับการปรับปรุงไปใช้ในการทำนายครั้งถัดไป ทำให้ระบบสามารถติดตามและคำนวณตำแหน่งได้อย่างมีประสิทธิภาพ ช่วยแก้ไขปัญหาคำผิดในการเก็บข้อมูลต่ำและการเผชิญกับสภาพแวดล้อมที่ท้าทายของระบบ GNSS [13] ส่งผลให้ค่าพิกัดที่ได้รับความนิยมอย่างสูงขึ้น สามารถนำไปใช้ในงานที่ต้องการความละเอียดและความถูกต้องของข้อมูล [14]

2.4 การคัดแยกพื้นถนนด้วย Random Sample Consensus (RANSAC)

หลังจากได้ข้อมูลจุด Point Cloud ที่มีตำแหน่งแล้ว ในจุดข้อมูลประกอบไปด้วยสภาพแวดล้อมโดยรอบถนนไม่ว่าจะเป็น รถยนต์, อาคาร, ต้นไม้ และอื่น ๆ อีกมากมาย เทคนิค Random Sample Consensus (RANSAC) จึงถูกนำมาใช้ในการสร้างแบบจำลองที่เหมาะสมที่สุดสำหรับระนาบพื้นถนนเพื่อการคัดแยกจุด Point Cloud ที่เป็นถนนออกมาจากข้อมูลจุดอื่น ๆ โดยในพื้นที่บริเวณสถานีรถไฟฯ จะเลือกใช้ระนาบเส้นตรงเป็นแบบจำลองแสดงดังสมการที่ (3) เนื่องจากเมื่อทำการแบ่งข้อมูลจุดเป็นภาพตัดขวาง (Cross section) แล้วแสดงให้เห็นลักษณะผิวถนนที่เป็นเส้นตรง

$$ax + by + cz + d = 0 \quad (3)$$

โดยที่ a, b, c, d คือพารามิเตอร์ที่ต้องการคำนวณสำหรับการสร้างแบบจำลองระนาบพื้นถนน และ x, y, z คือแกนพิกัดสามมิติ

สำหรับหลักการการทำงานของ RANSAC จะเริ่มต้นจากการสุ่มจุดข้อมูลเริ่มต้นเพื่อการสร้างแบบจำลอง จากนั้นจุดใด ๆ บนข้อมูลจะถูกนำมาคำนวณระยะห่างจากแบบจำลองดังสมการที่ (4)

$$dist = \frac{ax_i + by_i + cz_i + d}{\sqrt{a^2 + b^2 + c^2}} \quad (4)$$

โดยที่ a, b, c, d คือสัมประสิทธิ์ของแบบจำลองระนาบพื้นถนน และ x_i, y_i, z_i คือค่าพิกัดสามมิติของข้อมูลจุดใด ๆ

หากระยะห่างของจุดใด ๆ กับแบบจำลองเข้าเกณฑ์ที่กำหนด (Distance Threshold: T) จะถูกตีความเป็นจุดที่เป็นพื้นถนน (Inlier) ในทางกลับกันหากระยะห่างมากกว่าเกณฑ์จะถูกละทิ้งความเป็นวัตถุอื่นบนท้องถนน (Outlier) จากนั้นอัลกอริทึมจะสร้างแบบจำลองใหม่จากจุดที่ถูกตีความเป็นพื้นแล้วทำงานซ้ำตามหลักการของกำลังสองน้อยที่สุด (Least Square) เพื่อให้ได้แบบจำลองที่มีค่ารากที่สองค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root Mean Square Error: RMSE) น้อยที่สุดตามจำนวนรอบการวนซ้ำสูงสุดที่กำหนด (Maximum Iterations: N)

อย่างไรก็ตามการเลือกพารามิเตอร์สำหรับ RANSAC มีความสำคัญต่อความแม่นยำและประสิทธิภาพในการหาแบบจำลอง ในการศึกษาครั้งนี้เลือกค่า T เป็น 0.1 เมตร เพื่อเป็นเกณฑ์สำหรับกำหนดว่าจุดใดเป็นพื้นถนน ทั้งนี้ความเหมาะสมของค่า T ขึ้นอยู่กับลักษณะของพื้นที่ที่ศึกษา [8] และอีกหนึ่งพารามิเตอร์ที่สำคัญคือค่า N ที่ซึ่งสามารถใช้หลักการทางสถิติมาคำนวณได้ เพื่อให้แบบจำลองด้วยอยู่ในช่วงของค่าคลาดเคลื่อนที่สามารถรองรับได้จากการกำหนดช่วงระดับความเชื่อมั่น ทั้งนี้การเลือก

จำนวนรอบที่เหมาะสมจะถูกศึกษาและแสดงผลลัพธ์ในหัวข้อที่ 3 โดยในสมการที่ (5) จะแสดงการคำนวณหาจำนวนรอบขั้นต่ำที่จำเป็นต้องใช้สำหรับข้อมูล

$$N = \frac{\log(1-p)}{\log(1-w^m)} \quad (5)$$

โดยที่ p คือระดับความเชื่อมั่นที่กำหนด, w คือจำนวนร้อยละของข้อมูลที่คาดว่าเป็นพื้นถนนเมื่อเทียบกับจำนวนข้อมูลทั้งหมด และ m คือจำนวนจุดที่น้อยที่สุดที่จำเป็นต้องใช้เพื่อสร้างแบบจำลองเริ่มต้น ซึ่งมีค่าเป็น 3 สำหรับแบบจำลองระนาบเส้นตรง

ทั้งนี้ในการศึกษาครั้งนี้จะมีการดัดแปลงอัลกอริทึม RANSAC จากการสุ่มจุดเริ่มต้นเพื่อสร้างแบบจำลองเป็นการกำหนดจุดเริ่มต้นเองเพื่อเพิ่มความแม่นยำให้กับกระบวนการ [12] ผลลัพธ์ที่ได้จากขั้นตอนนี้คือข้อมูลจุด Point cloud เฉพาะจุดที่เป็นพื้นถนน

2.5 การแปลงข้อมูล Point cloud เป็นราสเตอร์ (Rasterization)


ในการประมวลผลข้อมูล Point Cloud จำเป็นต้องใช้ต้นทุนในการประมวลผลสูงเนื่องจากทุกจุดประกอบไปด้วยข้อมูลหลากหลายอรรถาธิบาย (Attribute) เช่น ค่าพิกัดสามมิติ, ค่าความเข้มแสง และค่าสี RGB เป็นต้น กระบวนการ Rasterization สามารถแปลงข้อมูลจากสามมิติเป็นข้อมูลราสเตอร์สองมิติโดยการเก็บค่าข้อมูลอรรถาธิบายไว้ในรูปแบบของกริด (Pixel) หนึ่งกริดจะเก็บข้อมูลเพียงหนึ่งอรรถาธิบายเพื่อลดต้นทุนในการประมวลผล ซึ่งข้อมูลอรรถาธิบายที่จำเป็นต้องใช้ในการประมวลผลครั้งนี้คือค่าความเข้มแสง (Intensity) ที่แสดงค่าพลังงานการสะท้อนพัลส์ของเลเซอร์ต่อพื้นผิววัตถุ ทั้งนี้ค่าความเข้มแสงโดยตรงที่ได้จากเลเซอร์มีค่าหลายหลักเพื่อลดความซับซ้อนของการประมวลผล ก่อนการนำไปแปลงเป็นกริดข้อมูลจะถูกปรับให้อยู่ในช่วงที่เหมาะสมด้วยการทำ Linear Normalization แสดงวิธีการค่างสมการที่ (6)

$$I' = \frac{I - I_{min}}{I_{max} - I_{min}} \quad (6)$$

โดยที่ I' คือค่าความเข้มแสงหลังจากการทำการปรับค่า, I_{min} คือค่าความเข้มแสงที่น้อยที่สุด, I_{max} คือค่าความเข้มแสงที่มากที่สุดและ I คือค่าความเข้มแสงเดิม

อย่างไรก็ตามการกำหนดขนาดกริดของราสเตอร์มีผลต่อความแม่นยำและประสิทธิภาพในการตรวจจับเส้นถนน หากขนาดกริดใหญ่เกินไปอาจทำให้ข้อมูลสูญเสียรายละเอียด ในขณะที่ขนาดกริดที่เล็กเกินไปอาจเพิ่มระยะเวลาในการประมวลผลหรืออาจทำให้เกิดช่องว่างของข้อมูล โดยขนาดกริดที่เหมาะสมไม่ควรมีความมากกว่าระยะห่างตั้งฉากที่สั้นที่สุดระหว่างเส้นถนนสองเส้น [8] ในงานวิจัยครั้งนี้เลือกใช้ขนาดกริด 0.05 เมตร หากเกิดช่องว่างของข้อมูลอันเนื่องมาจากความหนาแน่นของ Point Cloud เทคนิคเชิงเรขาคณิต Delaunay Triangulation จะถูกนำมาใช้เพื่อสร้างโครงสร้างสามเหลี่ยมในการประมาณค่าระหว่างจุดข้อมูล (Interpolation) เปรียบเทียบผลลัพธ์แสดงดังรูปที่ 4 เมื่อรูปซ้ายคือข้อมูลกริดราสเตอร์ที่มีลักษณะขาดหายบริเวณที่มีรถจอดติดบั้งถนน และรูปขวาคือข้อมูลกริดรา

สเตอร์หลังจากการประมาณค่าเพื่อเติมเต็มช่องว่างด้วยเทคนิค Delaunay Triangulation



รูปที่ 4 เปรียบเทียบผลลัพธ์จากการประมาณค่าข้อมูลที่ขาดหาย

2.6 การตรวจจับเส้นเลนด้วย Spectral Clustering

การจัดกลุ่มแบบสเปกตรัล (Spectral Clustering) เป็นหนึ่งในเทคนิคการเรียนรู้แบบไม่มีผู้สอนที่แบ่งกลุ่มข้อมูลอ้างอิงจากทฤษฎีกราฟ (Graph Theory) โดยมองข้อมูลแต่ละข้อมูลเป็นจุด (Node) และความสัมพันธ์ระหว่างจุดเป็นเส้นเชื่อม ซึ่งแต่ละเส้นเชื่อมมีค่าน้ำหนักที่สะท้อนระดับความคล้ายคลึงกันของข้อมูลสองจุดนั้น กระบวนการเริ่มจากการคำนวณความคล้ายคลึงระหว่างข้อมูลทุกคู่เพื่อสร้างเมตริกซ์ที่เรียกว่า Similarity Matrix จากนั้นนำข้อมูลนี้ไปวิเคราะห์ด้วยวิธีเชิงคณิตศาสตร์ เช่น การหา Eigenvalue และ Eigenvector ที่แสดงโครงสร้างของข้อมูลทำให้สามารถแยกข้อมูลออกเป็นกลุ่มๆ โดยข้อมูลที่มีลักษณะใกล้เคียงกันจะถูกจัดให้อยู่ในกลุ่มเดียวกันความพิเศษของวิธีนี้คือสามารถจัดกลุ่มข้อมูลที่มีรูปร่างซับซ้อนหรือไม่เป็นเส้นตรงได้ดีกว่าวิธีแบ่งกลุ่มทั่วไป [11] อีกทั้งยังสามารถทำนายจำนวนกลุ่มของข้อมูลได้ด้วยหลักทางคณิตศาสตร์ ซึ่งแตกต่างกับเทคนิคการจัดกลุ่ม K-means ที่จำเป็นต้องกำหนดจำนวนกลุ่มก่อนการประมวลผลแม้จะยังไม่ทราบจำนวน

ในงานวิจัยครั้งนี้ต้องการตรวจจับเส้นเลนถนนโดยเลือกใช้ข้อมูลสำหรับประเมินความคล้ายคลึง 4 ค่า ประกอบไปด้วยข้อมูลค่าความเข้มแสง, ค่าสี RGB, ข้อมูลตำแหน่งและขอบ (Edge) โดยเลือกใช้ทั้ง 4 ข้อมูลในค่าน้ำหนักที่แตกต่างกันเพื่อค้นหาวิธีที่เหมาะสมที่สุดสำหรับการตรวจจับเส้นเลน ในการศึกษาจะแบ่งการสร้างวิธีการหาเพื่อนบ้านที่ใกล้ที่สุด K-Nearest Neighbor (k-NN) สำหรับการสร้างเมตริกซ์ความคล้ายคลึงที่ซึ่งสามารถเชื่อมโยงกราฟระหว่างจุดข้อมูลได้แม้กลุ่มข้อมูลที่มีความหนาแน่นสูงมีค่าอยู่ไกลจากกลุ่มข้อมูลอื่น [11] แสดงการคำนวณได้ดังสมการที่ (7)

$$S(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (7)$$

โดยที่ $\|x_i - x_j\|$ คือการคำนวณระยะห่างระหว่างจุดข้อมูล และ σ คือค่าพารามิเตอร์ที่กำหนดเกณฑ์ระยะห่างของความคล้ายคลึงของข้อมูล (Gaussian Kernel) ในงานวิจัยนี้เลือกใช้ค่าตามค่าเริ่มต้นมาตรฐานเป็น 1

หลังจากสร้างเมตริกซ์ความคล้ายคลึง Spectral Clustering จะดำเนินการต่อไปโดยการสร้างเมตริกซ์ที่เรียกว่า Laplacian (L) สำหรับใช้วิเคราะห์

โครงสร้างของกราฟ ตามทฤษฎีแล้วค่า Eigenvalues ของเมตริกซ์ L จะสามารถบอกโครงสร้างของกราฟได้ ค่าที่ต่ำหรือใกล้เคียงศูนย์หมายถึงข้อมูลแบ่งกลุ่มกันอย่างชัดเจนและไม่มีความเชื่อมโยงกัน ค่าที่มากขึ้นแสดงถึงความซับซ้อนและการเชื่อมต่อกันระหว่างข้อมูล ทำให้อัลกอริทึมสามารถแบ่งกลุ่มพื้นที่ที่เป็นเส้นเลนถนนและพื้นถนนได้

2.7 การประเมินความถูกต้อง

ในการประเมินความถูกต้องของการตรวจจับเส้นเลน ข้อมูลจะถูกแบ่งออกเป็น 20% สำหรับใช้เป็นชุดทดสอบและเปรียบเทียบกับข้อมูลผลเฉลย (Ground Truth) ที่ได้จากการคัดเลือกเส้นเลนด้วยวิธี Manual ในโปรแกรม CloudCompare ซอฟต์แวร์ประมวลผลจุดข้อมูลสามมิติ (Point Cloud) การกำหนด Ground Truth ที่มีความแม่นยำสูงจะถูกใช้เป็นมาตรฐานในการตรวจสอบประสิทธิภาพของอัลกอริทึม Spectral Clustering โดยใช้ค่าดังต่อไปนี้สำหรับการประเมินความถูกต้องได้แก่ ค่า True Positive (TP) ที่หมายถึงพื้นที่ของเส้นเลนที่ถูกตรวจจับได้อย่างถูกต้อง, False Positive (FP) คือพื้นที่ที่โมเดลตรวจจับว่าเป็นเส้นเลน แต่ในความจริงนั้นไม่ใช่, False Negative (FN) คือพื้นที่ของเส้นเลนจริงแต่โมเดลตรวจจับไม่พบ, และ True Negative (TN) คือพื้นที่ที่ไม่ใช่เส้นเลนและโมเดลก็ไม่ตรวจจับว่าเป็นเส้นเลน โดยใช้ตัวชี้วัดดังนี้

2.7.1 ค่า Precision

ค่า Precision จะแสดงความแม่นยำของการตรวจจับโดยคำนวณจากสัดส่วนของจุดที่ถูกต้องต่อผลลัพธ์ทั้งหมดที่ถูกตรวจจับว่าเป็นเส้นเลน ค่าที่สูงหมายความว่าโมเดลสามารถแยกเส้นเลนออกจากพื้นถนนหรือวัตถุอื่นๆ ได้ดีแสดงการคำนวณดังสมการที่ (9)

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

2.7.2 ค่า Recall

ค่า Recall เป็นตัวชี้วัดที่วัดความครอบคลุมของการตรวจจับ คำนวณจากสัดส่วนของจุดเส้นเลนที่ถูกต้องที่ถูกตรวจจับได้ต่อจำนวนจุดเส้นเลนทั้งหมดในข้อมูล Ground Truth ค่าที่สูงหมายความว่าโมเดลสามารถตรวจจับเส้นเลนได้ครบถ้วนโดยไม่พลาดจุดที่เป็นเส้นเลนจริงรวมถึงอาจเกิดจากการที่โมเดลมีแนวโน้มตรวจจับมากเกินไปแสดงดังสมการที่ (10)

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

2.7.3 ค่า F1-score

ค่า F1-score เป็นตัวชี้วัดที่คำนวณจากค่าเฉลี่ยถ่วงน้ำหนักระหว่าง Precision และ Recall แสดงดังสมการที่ (11) ค่า F1-score จะแสดงให้เห็นถึงความสมดุลระหว่างการตรวจจับที่แม่นยำและการครอบคลุมของผลลัพธ์ หากค่า Precision สูงแต่ Recall ต่ำ หมายความว่าโมเดลสามารถแยกเส้นเลนได้แม่นยำ แต่พลาดเส้นเลนบางส่วน ในขณะที่ Recall สูงแต่ Precision ต่ำ แสดงว่าโมเดลสามารถตรวจจับได้ครบถ้วนแต่มีความผิดพลาดสูง

$$F1-score = \frac{2(Precision \times Recall)}{Precision + Recall} \quad (11)$$

2.7.4 ค่า Intersection over Union (IoU)

ค่า IoU ตัวชี้วัดที่ใช้วัดความใกล้เคียงของผลลัพธ์ที่ตรวจจับได้กับ Ground Truth คำนวณจากอัตราส่วนระหว่างพื้นที่ที่มีการตรวจจับถูกต้องกับพื้นที่รวมของผลลัพธ์และ ข้อมูล Ground Truth ค่าที่สูงบ่งบอกว่าโมเดลสามารถจับเส้นเลนได้อย่างแม่นยำทั้งตำแหน่งและขอบเขต โดยไม่มีการตรวจจับเกินหรือขาดมากเกินไปแสดงการคำนวณดังสมการที่ (12)

$$IoU = \frac{TP}{TP + FP + FN} \quad (12)$$


จากการใช้ตัวชี้วัดเหล่านี้จะประเมินความสามารถของ Spectral Clustering ในการตรวจจับเส้นเลนได้อย่างละเอียด รวมไปถึงการนำไปเปรียบเทียบกับผลลัพธ์จากวิธีการตรวจจับเส้นเลนของงานวิจัยในอดีต

3. ผลการดำเนินงาน


3.1 การคัดแยกพื้นถนนด้วย RANSAC

3.1.1 การกำหนดจุดเริ่มต้นใน RANSAC

จากที่กล่าวไปในหัวข้อ 2.4 โดยทั่วไปแล้วการทำงานของ RANSAC สำหรับแบบจำลองผิวถนนเริ่มจากการสุ่มข้อมูลสามจุดเพื่อนำมาสร้างแบบจำลองเริ่มต้น ในการศึกษานี้ได้นำเสนอวิธีการกำหนดสามจุดเริ่มต้นเองเพื่อเพิ่มความแม่นยำของแบบจำลอง [12] จากรูปที่ 5 และ 6 แสดงผลลัพธ์การคัดแยกพื้นถนนจากการสุ่มจุดเริ่มต้นและการกำหนดจุดเริ่มต้นเองตามลำดับ สังเกตได้ว่ารูปที่ 5 ผลจากการคัดแยกพื้นถนนมีลักษณะเป็นช่องว่างบริเวณขอบถนนและมีการคัดแยกบริเวณทางเท้ามารวมในผิวถนนด้วยส่งผลให้มีค่า RMSE อยู่ที่ 0.0747 ม. แตกต่างจากในรูปที่ 6 ที่สามารถคัดเลือกผิวถนนอย่างเต็มพื้นที่และมีเพียงทางเท้าบางส่วนที่ถูกคัดเลือกมาเป็นพื้นถนนโดยมีค่า RMSE 0.0569 ม.



รูปที่ 5 ผลลัพธ์จากการคัดแยกพื้นด้วย RANSAC แบบสุ่มจุดเริ่มต้น



รูปที่ 6 ผลลัพธ์จากการคัดแยกพื้นด้วย RANSAC แบบกำหนดจุดเริ่มต้นเอง

3.1.2 จำนวนรอบของการวนซ้ำ

จากสมการที่ (5) ได้กล่าวถึงวิธีคำนวณจำนวนรอบการวนซ้ำของ RANSAC เพื่อให้ผลลัพธ์อยู่ในช่วงค่าคลาดเคลื่อนที่ยอมรับได้ ผลการศึกษาพบว่าจำนวนรอบการวนซ้ำที่เพิ่มขึ้นมีผลโดยตรงต่อจำนวนจุดที่ถูกกำหนดว่าเป็นพื้นดิน (Inlier) สำหรับข้อมูลที่ใช้ในจำเป็นต้องใช้จำนวนรอบขั้นต่ำคือ 25 รอบ ซึ่งในกรณีนี้พบว่าจำนวนจุดที่ถูกคัดเลือกให้เป็นพื้นดินคิดเป็น 31.98% เมื่อเพิ่มจำนวนรอบการวนซ้ำเป็น 50 รอบ ค่า Inlier เพิ่มขึ้นเป็น 45.51% หากเพิ่มเป็น 100 รอบ ค่า Inlier จะอยู่ที่ 48.41% และเมื่อเพิ่มเป็น 175 รอบ ค่า Inlier จะเพิ่มขึ้นเป็น 51.16% ดังนั้นจำนวนรอบที่น้อยเกินไปทำให้พื้นถนนที่ได้อาจขาดหาย ในขณะที่จำนวนรอบที่มากเกินไปอาจมีการตรวจจับเกินเกิดขึ้นนอกจากนั้นยังเพิ่มระยะเวลาในการประมวลผลโดยไม่จำเป็น ซึ่งผลลัพธ์แสดงให้เห็นว่าจำนวนการวนซ้ำที่เหมาะสมอยู่ที่ 100 รอบ ใช้ระยะเวลา 7 วินาทีการประมวลผลต่อความยาวถนนขนาด 20 เมตร


3.2 การเลือกฟีเจอร์เวกเตอร์สำหรับ Spectral Clustering

ในการตรวจจับเลนโดยใช้ Spectral Clustering การเลือกฟีเจอร์มีผลต่อการจัดกลุ่มข้อมูลและความแม่นยำของผลลัพธ์ โดยฟีเจอร์ที่เลือกใช้งานวิจัยครั้งนี้ได้แก่ ข้อมูลทางตำแหน่ง (x, y), ขอบ (Edge), ค่าความเข้ม (I), ค่าสี RGB (R, G, B) ค่าเหล่านี้จะถูกนำไปสร้างฟีเจอร์เวกเตอร์เพื่อใช้ในการคำนวณหาเมตริกซ์ความคล้ายคลึงที่เป็นส่วนสำคัญในการคัดแยกเลนของ Spectral Clustering โดยผลการศึกษาของการสร้างฟีเจอร์เวกเตอร์ที่ต่างกันแสดงดังต่อไปนี้

3.2.1 ข้อมูลตำแหน่งและค่าความเข้ม

การเลือกใช้ฟีเจอร์เวกเตอร์เป็น $[x, y, I]$ มีข้อได้เปรียบสำคัญคือ ข้อมูลตำแหน่งช่วยให้อัลกอริทึมตรวจจับโครงสร้างเส้นเลนได้แม่นยำขึ้น และค่าความเข้มช่วยแยกแยะระหว่างเส้นเลนและโครงสร้างอื่น ๆ เช่น รอยแตกของถนน ซึ่งมักมีค่าความเข้มที่แตกต่างจากพื้นถนนโดยรอบอย่างชัดเจน ทั้งนี้การให้น้ำหนักของข้อมูลตำแหน่งน้อยกว่าค่าความเข้มจะให้ผลลัพธ์ที่ดีที่สุด จากการศึกษาพบว่า การให้น้ำหนักของ I มากกว่า (x, y) 10 เท่าให้ผลลัพธ์ที่ดีที่สุดด้วยค่า Precision 90.70%, Recall 83.37%, F1-Score 86.88% และ IoU 76.80% เนื่องจากทำให้อัลกอริทึม

สามารถเน้นที่การจำแนกเส้นเลนโดยพิจารณาความเข้มเป็นหลัก แต่ยังคงใช้ข้อมูลตำแหน่งช่วยในการกำหนดขอบเขตเชิงพื้นที่ หากไม่มีการกำหนดค่าน้ำหนักที่เหมาะสมจะส่งผลให้เกิดความผิดพลาดในการตรวจจับเส้นเลนได้ แสดงดังรูปที่ 7 ที่เปรียบเทียบผลลัพธ์การตรวจจับภายใต้ค่าน้ำหนักที่แตกต่างกัน



รูปที่ 7 เปรียบเทียบผลลัพธ์จากการให้ค่าน้ำหนักที่แตกต่างกัน

จากรูปที่ 7 (a) แสดงค่าความเข้มของข้อมูลต้นฉบับ, รูป (b) แสดงกรณีที่ใช้เพียงข้อมูลความเข้มเป็นฟีเจอร์ส่งผลให้สามารถตรวจจับได้เพียงรอยแตกและเกิดสัญญาณรบกวน (Noise) จำนวนมาก, รูป (c) แสดงกรณีที่ให้ค่าน้ำหนักทางตำแหน่งและความเข้มเท่ากันพบว่ามีผลการตรวจจับผิดพลาดโดยอัลกอริทึมไม่สามารถตรวจจับสิ่งใดได้เลย และรูป (d) แสดงกรณีที่ให้ค่าน้ำหนักของความเข้มมากกว่าฟีเจอร์ตำแหน่งในระดับที่เหมาะสม ทำให้สามารถแยกขอบเขตของเส้นเลนและถนนได้อย่างชัดเจน แต่อย่างไรก็ตามค่าความเหมาะสมของน้ำหนักแต่ละฟีเจอร์อาจแตกต่างกันไปขึ้นอยู่กับลักษณะของข้อมูลต้นทาง เช่น ประเภทของพื้นผิวถนน ความเข้มของเส้นเลน และสภาพแวดล้อมโดยรอบ

3.2.2 ข้อมูลตำแหน่ง, ค่า Intensity และ Edges

ผลจากการศึกษาเมื่อนำข้อมูลรูสเตอร์ไปตรวจจับเส้นขอบ (Edge Detection) ก่อน แล้วจึงนำข้อมูลขอบเข้าไปรวมเป็นฟีเจอร์ในการตรวจจับเส้นเลนด้วยฟีเจอร์เวกเตอร์เป็น $[x, y, I, Edge]$ พบว่าข้อมูลขอบช่วยเพิ่มประสิทธิภาพเพียงเล็กน้อยให้กับกระบวนการตรวจจับเส้นเลนที่มีรูปร่างซับซ้อนได้โดยเฉพาะเส้นที่เป็นตัวอักษร แต่ในเลนลักษณะอื่น ๆ เช่น ลูกศร เส้นทึบ และเส้นประ การตรวจจับขอบไม่ได้ช่วยเพิ่มประสิทธิภาพมากนัก ในบางกรณี เช่น ถนนที่มีรอยแตกวิธี Edge Detection อาจตรวจจับเส้นที่ไม่มีอยู่จริงจึงทำให้เกิดการตรวจจับเกิน (False Positive) ขึ้น เมื่อประเมินความ


ถูกต้องของการใช้ฟีเจอร์เวกเตอร์นี้ได้ Precision 82.01%, Recall 67.32%, F1-Score 73.94% และ IoU 58.66% แสดงให้เห็นว่าการนำข้อมูลขอบมารวมเป็นฟีเจอร์ในการตรวจจับเส้นเลนไม่ได้ช่วยให้ประสิทธิภาพของอัลกอริทึมทำงานได้ดีขึ้น

3.2.3 ค่าสี RGB

เมื่อเลือกใช้ฟีเจอร์เวกเตอร์เป็น $[R, G, B]$ พบว่ามีค่าความแม่นยำต่ำกว่าการใช้ข้อมูลความเข้มและขอบโดยมีค่า Precision 49.41%, Recall 65.97%, F1-Score 56.50% และ IoU 39.38% สาเหตุอันเนื่องมาจากแสงและเงาที่กระทบแตกต่างกัน ในบริเวณที่มีแสงตกกระทบมากข้อมูลจุด Point Cloud บริเวณนั้นจะสว่างกว่าจุดอื่นจึงเกิดการตรวจจับที่ผิดพลาด

3.3 ประสิทธิภาพของ Spectral Clustering

จากผลการทดลองพบว่า Spectral Clustering ให้ค่าความถูกต้องโดยรวมสูงกว่า DBSCAN โดย DBSCAN ให้ค่าความแม่นยำอยู่ที่ Precision 57.30%, Recall 87.19%, F1-score 69.16% และ IoU 52.85% ซึ่ง DBSCAN มีแนวโน้มที่จะเกิด False Positive และ False Negative มากกว่า ทำให้ผลการตรวจจับเส้นเลนมีข้อผิดพลาดมากขึ้นดังที่แสดงการเปรียบเทียบในรูปที่ 8 เมื่อรูป (a) แสดงถนนจากข้อมูล Point Cloud, รูป (b) แสดงการใช้ Spectral Clustering ด้วยฟีเจอร์เวกเตอร์เป็นค่าความเข้ม, รูป (c) แสดงกรณีที่ใช้ DBSCAN ที่มีการตรวจจับผิดพลาดบริเวณที่มีความหนาแน่นของข้อมูล Point Cloud ต่ำเนื่องจากรถยนต์ที่จอดข้างถนน และรูป (d) แสดงกรณีที่ใช้ข้อมูลสี RGB เป็นฟีเจอร์เวกเตอร์ในวิธีการ Spectral Clustering ทำให้พบ Noise จำนวนมากอันเนื่องมาจากแสงและเงาที่ตกกระทบจุดถนนบนข้อมูล Point Cloud



รูปที่ 8 อุปกรณ์ที่ใช้ในการเก็บข้อมูล

ในตารางที่ 3 จะแสดงค่าความแม่นยำจากทุกวิธีที่ได้กล่าวมาข้างต้น เพื่อเปรียบเทียบประสิทธิภาพการทำงานของแต่ละวิธี ทั้งนี้ผลลัพธ์อาจขึ้นอยู่กับลักษณะของข้อมูลและพื้นที่ที่ศึกษา

ตารางที่ 3 ผลการคำนวณตัวชี้วัดเปรียบเทียบในแต่ละวิธี

Method	Feature	Precision	Recall	F1-score	IoU
Spectral Clustering	Intensity	90.70%	83.37%	86.88%	76.80%
	Edge	82.01%	67.32%	73.94%	58.66%
	RGB	49.41%	65.97%	56.50%	39.38%
DBSCAN	Intensity	57.30%	87.19%	69.16%	52.85%

จากปัญหาเรื่องรถยนต์จอดบนถนนบดบังสภาพแวดล้อมการเก็บข้อมูลของพื้นที่บริเวณรถไฟขบวนทำให้ข้อมูล Point Cloud ที่มีความหนาแน่นไม่สม่ำเสมอ แต่จากผลการทดลองพบว่าการใช้เทคนิค Spectral Clustering ร่วมกับข้อมูลค่าความเข้ม (Intensity) ในงานวิจัยนี้สามารถตรวจจับเส้นเลนได้ภายใต้เงื่อนไขดังกล่าว โดยมีแม่นยำกว่างานศึกษาของหน้า [8] ที่ใช้วิธีกำหนดเกณฑ์ค่าความเข้ม (Intensity Thresholding) ซึ่งได้ค่า Precision 84.4%, Recall 57.9% และ F1-Score 65.9 เท่านั้น ในขณะที่วิธีการในงานวิจัยนี้ให้ผลลัพธ์ที่สูงกว่าอย่างชัดเจนและมีประสิทธิภาพใกล้เคียงกับการใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ซึ่งมีค่า Precision 88.1%, Recall 83.3% และ F1-Score 85.1 โดยเทคนิคการเรียนรู้เชิงลึกมีจุดเด่นที่สามารถลดข้อผิดพลาดจากปัญหาความหนาแน่นไม่สม่ำเสมอของข้อมูล Point Cloud ได้อย่างมีประสิทธิภาพ เช่นเดียวกับ Spectral Clustering ในงานวิจัยนี้ที่สามารถแยกกลุ่มข้อมูลโดยอาศัยการวิเคราะห์โครงสร้างความสัมพันธ์ของข้อมูลเชิงลึก จึงทำให้มีความทนทานต่อปัญหาความหนาแน่นของจุดข้อมูลที่ไม่สม่ำเสมอ แตกต่างจากเทคนิค DBSCAN ที่ประสิทธิภาพลดลงอย่างมากเมื่อข้อมูลมีความหนาแน่นไม่สม่ำเสมอ

4. สรุปและอภิปรายผล

จากการศึกษานี้พบว่าเทคนิค Spectral Clustering มีศักยภาพสูงในการตรวจจับเส้นเลนบนถนนได้ดีกว่าอัลกอริทึม DBSCAN ซึ่งเป็นเทคนิคที่ได้รับความนิยมในปัจจุบัน โดย Spectral Clustering สามารถวิเคราะห์ความเชื่อมโยงเชิงโครงสร้างของข้อมูลได้ละเอียดและมีประสิทธิภาพมากกว่า ทำให้สามารถตรวจจับเส้นเลนได้แม่นยำยิ่งขึ้น แม้ในบริเวณที่ข้อมูลมีความซับซ้อนหรือมีความหนาแน่นของจุดไม่สม่ำเสมอ ในทางกลับกัน DBSCAN มักเกิดข้อผิดพลาดในบริเวณที่มีความหนาแน่นของข้อมูลแตกต่างกัน เช่น บริเวณที่มีเกาะหรือรถยนต์จอดบัง ทำให้เกิดการตรวจจับที่ไม่สมบูรณ์หรือมีจุดรบกวนมากกว่าที่ควร แต่อย่างไรก็ตามแม้ Spectral Clustering จะให้ผลลัพธ์ที่แม่นยำกว่า แต่ก็ยังมีข้อจำกัดด้านความไวต่อค่าพารามิเตอร์ในทุกขั้นตอน ไม่ว่าจะเป็นการเลือกพารามิเตอร์สำหรับสร้างกราฟความคล้ายคลึง การเลือกเทคนิคสร้างกราฟ ความเหมาะสมของจำนวนกลุ่ม และค่าน้ำหนักของความสัมพันธ์ระหว่างจุดข้อมูล ความไวเหล่านี้ทำให้ Spectral Clustering ต้องอาศัยการปรับแต่งค่าพารามิเตอร์อย่างแม่นยำ หากไม่กำหนดค่าที่เหมาะสมอาจส่งผลต่อคุณภาพของผลลัพธ์และระยะเวลาในการประมวลผล ทำให้ Spectral Clustering มีความซับซ้อนสูงกว่าวิธีการจัดกลุ่มแบบอื่นเช่น DBSCAN อย่างชัดเจน

จากผลการประเมินการทำงานจริงพบว่า Spectral Clustering สามารถตรวจจับเส้นเลนได้ดีในบริเวณที่เส้นเลนมีสีจางหรือมีเกาะรบกวน ซึ่งแสดงให้เห็นถึงข้อได้เปรียบในการวิเคราะห์โครงสร้างข้อมูล แต่ในบริเวณที่เส้นเลนมีการขาดหายหรือขาดความต่อเนื่อง Spectral Clustering ยังไม่สามารถเติมเต็มหรือประมาณค่าส่วนที่ขาดหายได้ ทำให้การตรวจจับเส้นเลนยังมีความไม่สมบูรณ์ในบางพื้นที่ ดังนั้นข้อเสนอแนะสำหรับงานวิจัยในอนาคตคือ การพัฒนาอัลกอริทึมเพิ่มเติมที่สามารถประมาณค่าตำแหน่งของเส้นเลนที่ขาดหายได้ เช่น การใช้เทคนิคการคาดคะเน (Estimation) หรือการเรียนรู้รูปแบบเส้นโค้ง เพื่อช่วยให้การตรวจจับเส้นเลนสมบูรณ์ยิ่งขึ้น โดยเฉพาะอย่างยิ่งในบริบทของถนนในประเทศไทยที่เส้นเลนมักขาดหายหรือสึกหรออย่างต่อเนื่อง และนอกจากนี้งานวิจัยในอนาคตควรให้ความสำคัญกับการพัฒนา Adaptive Spectral Clustering ที่สามารถปรับค่าพารามิเตอร์ได้อย่างอัตโนมัติ เพื่อลดผลกระทบจากความไวต่อพารามิเตอร์ และเพิ่มความยืดหยุ่นในการใช้งานกับข้อมูลที่มีสภาพแวดล้อมหลากหลาย เช่น ถนนในเมืองที่มีสิ่งกีดขวางมาก หรือถนนที่เส้นเลนจากเนื่องจากการขาดการบำรุงรักษา เพื่อรองรับการประยุกต์ใช้เทคโนโลยีในสภาพการใช้งานจริงได้อย่างมีประสิทธิภาพยิ่งขึ้น

นอกจากนี้งานวิจัยยังแสดงให้เห็นว่าการเลือกใช้ข้อมูลค่าความเข้ม (Intensity) จากไลดาร์เป็นฟีเจอร์หลักในการตรวจจับเส้นเลนให้ผลลัพธ์ที่แม่นยำกว่าการใช้ข้อมูลสี RGB เนื่องจากข้อมูลสีมีความไวต่อแสงและเงาในสภาพแวดล้อมจริง ซึ่งมักทำให้เกิดข้อผิดพลาดในการตรวจจับ ในขณะที่ค่าความเข้มจากไลดาร์มีความคงที่และมีความไวต่อสภาพแวดล้อมน้อยกว่า ช่วยให้การตรวจจับเส้นเลนมีความแม่นยำสูงขึ้น แม้ในกรณีที่สภาพแสงเปลี่ยนแปลงตลอดเวลา จึงสามารถสรุปได้ว่าการใช้ Mobile Mapping System ถือเป็นแนวทางที่เหมาะสมสำหรับการพัฒนาเทคโนโลยียานยนต์ไร้คนขับ (Autonomous Vehicles) และการสร้างแผนที่ความละเอียดสูงที่มีความแม่นยำสูง ซึ่งช่วยลดโอกาสเกิดอุบัติเหตุบนท้องถนน และสนับสนุนการพัฒนาาระบบคมนาคมอัจฉริยะที่ปลอดภัยและมีประสิทธิภาพมากขึ้น

กิตติกรรมประกาศ

ขอแสดงความขอบคุณเป็นอย่างยิ่งต่อ ศาสตราจารย์ ดร.เฉลิมพนธ์ สติระพจน์ และ ดร.สุรเชษ ศรีนารา สำหรับการให้ความรู้ คำแนะนำ และข้อเสนอแนะที่มีคุณค่าในการดำเนินงานวิจัยครั้งนี้ และขอขอบคุณ National Cheng Kung University จากได้ให้ทุน สำหรับการสนับสนุนข้อมูลและทรัพยากรที่จำเป็นต่อการดำเนินงานวิจัย ทำให้งานวิจัยนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี

เอกสารอ้างอิง

- [1] Zakaria, N.J., et al., *Lane Detection in Autonomous Vehicles: A Systematic Review*. IEEE Access, 2023. 11: p. 3729-3765.
- [2] Hao, W., *Review on lane detection and related methods*. Cognitive Robotics, 2023. 3: p. 135-141.
- [3] Farag, W. and Z. Saleh, *Road Lane-Lines Detection in Real-Time for Advanced Driving Assistance Systems*. 2018. 1-8.

- [4] Hoang, T.M., et al. *Road Lane Detection Robust to Shadows Based on a Fuzzy System Using a Visible Light Camera Sensor*. Sensors, 2017. **17**, DOI: 10.3390/s17112475.
- [5] Guo, Y., et al., *Robust Lane Line Detection and Tracking Using Enhanced DBSCAN Optimized RANSAC and Optical Flow*. Transportation Research Record. **0**(0): p. 03611981241277751.
- [6] Jung, J., et al., *Efficient and robust lane marking extraction from mobile lidar point clouds*. ISPRS Journal of Photogrammetry and Remote Sensing, 2019. **147**: p. 1-18.
- [7] Jordan Britt, D.B., Christopher Rose. *A Comparison of Lidar and Camera-Based Lane Detection Systems*. 2012 [cited 2024 5/11]; Available from: <https://www.gpsworld.com/a-comparison-of-lidar-and-camera-based-lane-detection-systems/>
- [8] Cheng, Y.-T., et al., *LIDAR-BASED LANE MARKING EXTRACTION THROUGH INTENSITY THRESHOLDING AND DEEP LEARNING APPROACHES: A PAVEMENT-BASED ASSESSMENT*. ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020. **XLIII-B3-2020**: p. 507-514
- [9] Tran, L.A. and M.H. Le. *Robust U-Net-based Road Lane Markings Detection for Autonomous Driving*. in 2019 International Conference on System Science and Engineering (ICSSE). 2019.
- [10] Wang, J., W. Hong, and L. Gong. *Lane detection algorithm based on density clustering and RANSAC*. in 2018 Chinese Control And Decision Conference (CCDC). 2018.
- [11] Omanovic, S., E. Buza, and A. Huseinovic, *Pothole Detection with Image Processing and Spectral Clustering*. 2013.
- [12] Fischler, M.A. and R.C. Bolles, *Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography*. Commun. ACM, 1981. **24**(6): p. 381–395.
- [13] Konrad, T., Breuer, M., Engelhardt, T., & Abel, D. (2017). State Estimation for a Multirotor using Tight-Coupling of GNSS and Inertial Navigation. *IFAC-PapersOnLine*, 50(1), 11683-11688. <https://doi.org/https://doi.org/10.1016/j.ifacol.2017.08.1684>
- [14] Ziedan, N.I., "Extended Kalman Filter-Based Deeply Integrated GNSS/Low-Cost INS for Reliable Navigation Under GNSS Weak Interrupted Signal Conditions," Proceedings of the 19th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS 2006), Fort Worth, TX, September 2006, pp. 2889-2900.