

การจำแนกข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่เพื่อตรวจหาพื้นผิวถนนและ  
หลุมบ่อด้วยโครงข่ายประสาทคอนโวลูชัน



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต  
สาขาวิชาวิศวกรรมสำรวจ ภาควิชาวิศวกรรมสำรวจ  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2564  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Classification of 3D Point Cloud Data from Mobile Mapping System for Detecting Road  
Surfaces and Potholes using Convolution Neural Networks



A Dissertation Submitted in Partial Fulfillment of the Requirements  
for the Degree of Doctor of Philosophy in Geomatic Engineering

Department of Survey Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การจำแนกข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่เพื่อตรวจหาพื้นผิวถนนและหลุมบ่อด้วย
โดย	นายสรศักดิ์ ชัยทวี
สาขาวิชา	วิศวกรรมสำรวจ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	อาจารย์ ดร.ธงทิศ ฉายากุล

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต

..... คณะบดีคณะวิศวกรรมศาสตร์  
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(ศาสตราจารย์ ดร.เฉลิมชนม์ สติระพจน์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(อาจารย์ ดร.ธงทิศ ฉายากุล)

..... กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.กรวิก ตันภษรานนท์)

..... กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร.ธีทัต เจริญกาลัญญูตา)

..... กรรมการภายนอกมหาวิทยาลัย  
(อาจารย์ ดร.กฤษญาณ อินทร์ตัน)

สรศักดิ์ ชัยทวี : การจำแนกข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่เพื่อตรวจหาพื้นผิวถนนและหลุมบ่อด้วยโครงข่ายประสาทคอนโวลูชัน . ( Classification of 3D Point Cloud Data from Mobile Mapping System for Detecting Road Surfaces and Potholes using Convolution Neural Networks) อ.ที่ปรึกษาหลัก :  
อ. ดร.ธงทิศ ฉายากุล

การชำรุดเสียหายของถนนส่งผลกระทบต่อผู้เดินทาง ทำให้เสี่ยงที่จะเกิดอุบัติเหตุต่อการขับขี่ ดังนั้นข้อมูลสภาพของพื้นผิวถนนและข้อมูลการชำรุดเสียหายจึงมีความจำเป็นในการสำรวจเก็บข้อมูล การตรวจหาการชำรุดเสียหายของถนนแบบอัตโนมัตินิยมใช้ข้อมูลภาพถ่ายหรือวิดีโอจากกล้องที่ติดตั้งบนยานพาหนะ และพัฒนาอัลกอริทึมต่าง ๆ ในการตรวจหา แต่อย่างไรก็ตามการใช้ภาพถ่ายหรือวิดีโอในการตรวจหาหลุมบ่อ มีข้อจำกัดในเรื่องของมาตราส่วนและตำแหน่งระบบพิกัดแผนที่ ทำให้ไม่สามารถทราบขนาดและตำแหน่งที่มีความแม่นยำได้ ดังนั้นในงานวิจัยนี้ใช้ระบบการทำแผนที่แบบเคลื่อนที่ในการสำรวจสภาพแวดล้อมของถนนเพื่อจำแนกหลุมบ่อ ถนนและวัตถุอื่น ๆ โดยใช้โครงข่ายประสาทคอนโวลูชันจำแนกจุดพิกัดสามมิติโดยตรง ด้วยวิธีการใช้ค่า XYZ และวิธีนำเสนอใช้ค่า XYZ-RGB จุดพิกัดสามมิติจากการสำรวจประเมินความถูกต้องตามมาตรฐาน NSSDA ปรากฏว่าให้ค่าความถูกต้องที่ความเชื่อมั่นร้อยละ 95 แบบสามมิติเท่ากับ 0.089 เมตร ซึ่งอยู่ในเกณฑ์งานขั้นที่ 2 และผลการจำแนกวิธีใช้เฉพาะค่า XYZ ให้ค่าความถูกต้องโดยรวมเท่ากับร้อยละ 96.77 และค่า IoU ของหลุมบ่อ ถนนและวัตถุอื่น ๆ เท่ากับร้อยละ 59.50, 94.22 และ 94.06 ตามลำดับ ในส่วนวิธีนำเสนอแบบใช้ค่า XYZ-RGB ให้ค่าความถูกต้องโดยรวมเท่ากับร้อยละ 97.50 และค่า IoU ของหลุมบ่อ ถนนและวัตถุอื่น ๆ เท่ากับร้อยละ 66.66, 95.43 และ 95.42 ตามลำดับ เมื่อนำผลการจำแนกทั้ง 2 วิธีเปรียบเทียบผลด้วยการทดสอบทางสถิติแล้วพบว่าที่ระดับความเชื่อมั่นร้อยละ 95 ผลการจำแนกจากทั้ง 2 วิธีมีผลที่แตกต่างกันอย่างมีนัยสำคัญในทางสถิติ

สาขาวิชา วิศวกรรมสำรวจ  
ปีการศึกษา 2564

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6071444321 : MAJOR GEOMATIC ENGINEERING

KEYWORD: Mobile mapping system, Point cloud, Convolutional neural network

Sorasak Chaithavee : Classification of 3D Point Cloud Data from Mobile Mapping System for Detecting Road Surfaces and Potholes using Convolution Neural Networks. Advisor: THONGTHIT CHAYAKULA, Ph.D.

Road damages can negatively impact commuters and increase the risks of road accidents. Therefore, data on the physical conditions of road surfaces and damages are crucial and must be obtained. In general, road damages can be detected automatically using photographic or video data derived from vehicle cameras in conjunction with the development of detection algorithms. However, when using photographic or video data to detect potholes, there remain limitations related to scales and map coordinates. More specifically, it has been challenging to determine the sizes and locations of detected potholes. This research utilized a mobile mapping system (MMS) to survey road environments and classify potholes, roads, and other objects. A convolution neural network (CNN) was used to directly identify 3D point clouds using the XYZ method in comparison with the proposed XYZ-RGB method. NSSDA's accuracy validation at the 95% confidence level showed that the observed 3D point clouds were approximately 0.089 meters (Class 2). The XYZ classification demonstrated an overall accuracy of 96.77%, with the intersection over union (IoU) of potholes, roads, and other objects of 59.50%, 94.22%, and 94.06%, respectively. The proposed XYZ-RGB classification indicated an overall accuracy of 97.50%, with the IoU of potholes, roads, and other objects of 66.66%, 95.43%, and 95.42%, respectively. Both datasets were statistically compared at the 95% confidence level, and the results revealed that both classifications produced significantly different results.

Field of Study: Geomatic Engineering

Student's Signature .....

Academic Year: 2021

Advisor's Signature .....

## กิตติกรรมประกาศ

การสรรเสริญทั้งหลายนี้เป็นสิทธิของอัลลอฮ์ ผู้ทรงแนะนำพวกเราให้ได้รับสิ่งนี้ และใช้ว่าพวกเราจะได้รับคำแนะนำก็หาไม่ หากว่าอัลลอฮ์ไม่ทรงแนะนำแก่พวกเรา (ซูเราะห์ อัล-อะฮอรอฟ : 43)

วิทยานิพนธ์ฉบับนี้เสร็จสมบูรณ์ไปได้ด้วยดีโดยได้รับความช่วยเหลือจากหลายฝ่าย ขอขอบพระคุณ อาจารย์ ดร.ธงทิศ ฉายากุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำแนะนำ ความรู้และข้อคิดเห็นในการทำงานวิจัย และช่วยตรวจสอบและแก้ไขให้วิทยานิพนธ์ฉบับนี้มีความสมบูรณ์ ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน ประกอบด้วย ศ.ดร.เฉลิมชนม์ สติระพจน์ ประธานคณะกรรมการสอบวิทยานิพนธ์ ผศ.ดร.ธีทัต เจริญกาลัญญาตา ผศ.ดร.กรวิก ตันเกษรานนท์ กรรมการสอบวิทยานิพนธ์ และ อ.ดร.กฤษฎาณ อินทร์ตัน กรรมการภายนอกมหาวิทยาลัย ที่กรุณาให้คำแนะนำ และตรวจสอบวิทยานิพนธ์ฉบับนี้ให้มีความสมบูรณ์ยิ่งขึ้น ขอขอบพระคุณคณาจารย์ภาควิชาวิศวกรรมสำรวจทุกท่านที่ให้ความรู้อันมีคุณค่า

ขอขอบคุณพ่อและแม่ที่กรีดหยาดเหงื่อเงินส่งลูกคนนี้เรียนตั้งแต่อุนบาลจนถึงระดับปริญญาเอก และคอยสนับสนุน ผลักดันและคอยเป็นกำลังใจให้ตลอดเวลา

ขอบคุณเพื่อน ๆ พี่ ๆ นิสิตปริญญาตรีบัณฑิต ภาควิชาวิศวกรรมสำรวจ ที่คอยให้คำแนะนำ และแลกเปลี่ยนวิชาความรู้ที่เป็นประโยชน์ต่อการศึกษาในระดับปริญญาตรีบัณฑิต

ขอบคุณบริษัท ท็อปคอน อินสทრูเมนต์ (ไทยแลนด์) จำกัด ที่อนุเคราะห์เครื่องมือระบบการทำแผนที่แบบเคลื่อนที่ TOPCON IP-S3 และทีม Technical Support จากทางบริษัทที่ช่วยเหลือในการเก็บข้อมูลในภาคสนาม

ขอบคุณชมรมมุสลิม จุฬาลงกรณ์มหาวิทยาลัย (Muslim Chula) ซึ่งเป็นครอบครัวเล็ก ๆ ใต้พักพิงใจในช่วงที่กำลังศึกษา

ขอบคุณทีมนางฟ้าแห่งเพชรบุรีซอย 7 ที่คอยเป็นกำลังใจให้กันเสมอมา

สรศักดิ์ ชัยทวี

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญรูป.....	ฎ
บทที่ 1 บทนำ .....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของการวิจัย .....	4
1.3 ขอบเขตการศึกษา.....	4
1.4 สมมติฐานของงานวิจัย.....	5
1.5 ประโยชน์คาดว่าจะได้รับ.....	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง .....	6
2.1 ความเสียหายของพื้นผิวถนน .....	6
2.1.1 หลุมบ่อ (Pothole).....	6
2.1.2 ยุบตัวเป็นแอ่ง (Depression) .....	7
2.1.3 ร่องล้อ (Rutting).....	7
2.1.4 รอยปะซ่อมที่เสียหาย (Bad Patching).....	8
2.1.5 พื้นผิวถนนหลุดร่อน (Raveling).....	8
2.1.6 รอยแตกร้าว (Crack).....	9
2.2 ระบบการทำแผนที่แบบเคลื่อนที่ (Mobile Mapping System).....	9

2.2.1 ส่วนประกอบของ MMS .....	10
2.2.2 การอ้างอิงระบบพิกัด.....	12
2.2.3 ความคลาดเคลื่อนของ MMS.....	14
2.3 การประเมินความถูกต้องของจุดพิกัดสามมิติ .....	16
2.3.1 มาตรฐานการทดสอบความถูกต้อง .....	16
2.3.2 ระดับความถูกต้องของจุดพิกัดสามมิติ.....	18
2.4 โครงข่ายประสาทเทียม (Artificial Neural network).....	19
2.5 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Networks).....	20
2.6 สถาปัตยกรรมโครงข่ายประสาทคอนโวลูชัน .....	21
2.6.1 ชั้นคอนโวลูชัน .....	22
2.6.2 ชั้นพูลลิง (Pooling layer).....	24
2.6.3 ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully connected layer) .....	25
2.7 การวัดประสิทธิภาพ.....	25
2.7.1 เมทริกซ์ความคลาดเคลื่อน (Confusion Matrix) .....	25
2.7.2 ความถูกต้องโดยรวม (Overall accuracy).....	26
2.7.3 ความถูกต้องของผู้ใช้ (User's Accuracy).....	26
2.7.4 ความถูกต้องของผู้ผลิต (Producer's Accuracy) .....	26
2.7.5 ค่าอัตราส่วนการซ้อนทับ Intersection over Union (IoU).....	26
2.7.6 ค่าฟังก์ชันความสูญเสีย (Loss Function).....	27
2.7.7 ค่าสถิติแค็ปปา (Kappa Statistics).....	27
2.7.8 การทดสอบทางสถิติ Z .....	27
2.8 โครงข่ายประสาทคอนโวลูชันจำแนกจุดพิกัดสามมิติ .....	28
2.9 งานวิจัยที่เกี่ยวข้อง.....	31
บทที่ 3 การดำเนินงานวิจัย .....	37



3.1. การสำรวจจัดเก็บข้อมูล .....	38
3.2 การประมวลผลข้อมูล MMS และการปรับแก้ข้อมูล .....	43
3.2.1 การประมาณค่าตำแหน่งเส้นทาง (Vehicle trajectory estimation) .....	43
3.2.2 การปรับแก้ข้อมูลจากหลายเส้นทาง (Align multiple passes) .....	44
3.2.3 การปรับแก้ตำแหน่งเส้นทางด้วย GCP (Align trajectory with GCPs) .....	44
3.2.4 การต่อภาพถ่ายแบบพาโนรามา (Stitch Panoramic image).....	45
3.2.5 การสร้างจุดพิกัดสามมิติ (Cloud generation) .....	45
3.2.6 การกรองข้อมูลจุดพิกัดสามมิติ (Filter cloud).....	45
3.3 ระบบและ Software ประมวลผลข้อมูล .....	45
3.3.1 ทฤษฎีการประมวลผล .....	45
3.3.2 ซอฟต์แวร์ประมวลผล.....	46
3.4 การจำแนกพื้นผิวถนนและหลุมบ่อจากข้อมูลจุดพิกัดสามมิติ .....	46
3.4.1 อัลกอริทึมสำหรับการจำแนกพื้นผิวถนนและหลุมบ่อ.....	46
3.4.2 การกรองข้อมูล.....	48
3.4.3 การเตรียมข้อมูลฝึกสอนโครงข่ายและข้อมูลอ้างอิงภาคพื้นดิน.....	49
3.4.4 การฝึกสอนและการทดสอบ.....	49
3.5 การทดสอบความถูกต้องของข้อมูลและการทดสอบประสิทธิภาพการจำแนก.....	52
3.5.1 การทดสอบความถูกต้องของจุดพิกัดสามมิติ.....	52
3.5.2 การทดสอบประสิทธิภาพของการจำแนกข้อมูลจุดพิกัดสามมิติ.....	53
3.5.3 ทดสอบสมมติฐานทางสถิติสำหรับการประเมินความถูกต้องทั้ง 2 วิธี.....	53
บทที่ 4 ผลการดำเนินงานวิจัย.....	54
4.1 ผลการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่.....	54
4.2 ผลการตรวจสอบความถูกต้องของจุดพิกัดสามมิติ.....	55
4.3 ผลการจำแนกจุดพิกัดสามมิติด้วยโครงข่ายประสาทคอนโวลูชัน .....	58

4.3.1 ผลการฝึกสอนโครงข่ายประสาทคอนโวลูชัน.....	58
4.3.2 ผลการทดสอบโครงข่ายประสาทคอนโวลูชัน .....	60
4.3.3 ผลทดสอบการจำแนก .....	62
4.3.4 ผลการทดสอบสถิติ Z เปรียบเทียบผลทั้ง 2 วิธี .....	65
บทที่ 5 อภิปรายและสรุปผล .....	66
5.1 อภิปรายผลการสำรวจด้วย MMS และประเมินความถูกต้องของจุดพิกัดสามมิติ.....	66
5.2 อภิปรายผลการจำแนกจุดพิกัดสามมิติด้วยโครงข่ายประสาทคอนโวลูชัน.....	68
5.3 การสรุปผลการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่.....	72
5.4 สรุปผลการจำแนกจุดพิกัดสามมิติด้วย CNN.....	72
5.5 ข้อจำกัดและปัญหาการวิจัย.....	73
5.6 ข้อเสนอแนะงานวิจัย .....	74
บรรณานุกรม.....	76
ประวัติผู้เขียน.....	83

## สารบัญตาราง

ตารางที่ 2-1 แสดงรายการพารามิเตอร์ที่เกี่ยวข้องในการแปลงค่าการอ้างอิงระบบพิกัดแผนที่โดยตรง และเวกเตอร์ข้อมูลการวางตำแหน่งของวัตถุเป้าหมาย P คำนวณโดยใช้สมการที่ (2-1).....	13
ตารางที่ 2-2 คุณสมบัติของอุปกรณ์ Topcon IP-S3 HD .....	16
ตารางที่ 2-3 แสดงการกำหนดชั้นของงานข้อมูลจุดพิกัดสามมิติจาก MMS .....	18
ตารางที่ 2-4 แสดงตารางเมทริกซ์ค่าความคลาดเคลื่อน (Confusion Matrix) .....	25
ตารางที่ 4-1 แสดงค่าพิกัดของจุด GCP และ CP.....	55
ตารางที่ 4-2 แสดงผลทดสอบความถูกต้องของจุดพิกัดสามมิติก่อนปรับแก้ด้วย GCP .....	56
ตารางที่ 4-3 แสดงผลทดสอบความถูกต้องของจุดพิกัดสามมิติหลังปรับแก้ด้วย GCP.....	57
ตารางที่ 4-4 แสดงผลการฝึกสอนโครงข่ายประสาทคอนโวลูชันของ Training Dataset .....	59
ตารางที่ 4-5 ผลทดสอบความแตกต่างของการฝึกสอนโครงข่ายด้วยสถิติ Z จากข้อมูลทั้งสองกลุ่ม .	60
ตารางที่ 4-6 แสดงผลการทดสอบโครงข่ายคอนโวลูชันของ Validation Dataset .....	61
ตารางที่ 4-7 ผลทดสอบความแตกต่างของการทดสอบโครงข่ายด้วยสถิติ Z จากข้อมูลทั้งสองกลุ่ม .	62
ตารางที่ 4-8 ตารางแสดงค่า IoU ของผลการจำแนกข้อมูลทั้ง 2 กลุ่ม .....	64
ตารางที่ 4-9 แสดง Confusion matrix ของการจำแนกข้อมูลแบบไม่มีค่า RGB.....	64
ตารางที่ 4-10 แสดง Confusion matrix ของการจำแนกข้อมูลแบบมีค่า RGB .....	65

## สารบัญรูป

รูปที่ 1-1 แสดงเส้นทางที่ศึกษาถนนโยธาธิการ เคหะการเกษตร หมู่ 10 ตำบลหนองเพรางาย อำเภอ ไทรน้อย จังหวัดนนทบุรี.....	4
รูปที่ 2-1 ความเสียหายประเภทหลุมบ่อ .....	6
รูปที่ 2-2 ความเสียหายประเภทยุบตัวเป็นแอ่ง.....	7
รูปที่ 2-3 ความเสียหายประเภทร่องล้อ .....	7
รูปที่ 2-4 ความเสียหายประเภทรอยปะซ่อมที่เสียหาย .....	8
รูปที่ 2-5 ความเสียหายประเภทพื้นผิวถนนหลุดร่อน.....	8
รูปที่ 2-6 ความเสียหายประเภทรอยแตกร้าว .....	9
รูปที่ 2-7 หลักการอ้างอิงระบบพิกัดแผนที่ของ MMS.....	13
รูปที่ 2-8 แสดงการประยุกต์ใช้งานจุดพิกัดสามมิติในงานขนส่งตามเกณฑ์ความถูกต้องและความ ละเอียดของข้อมูล รูปจาก Olsen et al. (2013).....	19
รูปที่ 2-9 ตัวอย่างโครงข่ายประสาทเทียมไปข้างหน้า 3 ชั้นข้อมูล .....	20
รูปที่ 2-10 แสดงตัวอย่างสถาปัตยกรรม CNN รูปจาก O'Shea and Nash (2015).....	21
รูปที่ 2-11 แสดงภาพของชั้นคอนโวลูชัน รูปจาก O'Shea and Nash (2015).....	23
รูปที่ 2-12 แสดงสถาปัตยกรรม PointNet รูปจาก C. Qi et al. (2017).....	29
รูปที่ 2-13 แสดงสถาปัตยกรรมของ PointNet++ รูปจาก C. R. Qi et al. (2017).....	31
รูปที่ 3-1 แสดงขั้นตอนการดำเนินงานวิจัย.....	37
รูปที่ 3-2 แสดงหลุมบ่อของพื้นที่ศึกษาถนนโยธาธิการ เคหะการเกษตร .....	38
รูปที่ 3-3 แสดงหมุดหลักฐานอ้างอิง GNSS 610373 ของกรมชลประทาน .....	39
รูปที่ 3-4 แสดงการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK ของจุด GCP และ CP.....	39
รูปที่ 3-5 แสดงตำแหน่งของหมุดอ้างอิง จุด GCP และ จุด CP .....	40
รูปที่ 3-6 ส่วนประกอบของอุปกรณ์ Topcon IP-S3 รูปดัดแปลงจาก Topcon (2021) .....	41
รูปที่ 3-7 แสดงภาพ DMI ที่ติดตั้งอยู่ที่ล้อของยานพาหนะ รูปจาก Topcon (2021) .....	41

รูปที่ 3-8 แสดงยานพาหนะที่ติดตั้งอุปกรณ์ IP-S3 เก็บข้อมูลสภาพแวดล้อมของถนน..... 43

รูปที่ 3-9 แสดงจุด GCP05 จาก GNSS วิธี RTK กับจุด Point-005 จาก MMS ..... 44

รูปที่ 3-10 แสดงค่าของข้อมูลจุดพิกัดสามมิติ กรอบสี่เหลี่ยมคือชุดข้อมูลที่มีเฉพาะ XYZ กรอบสีแดงคือชุดข้อมูลที่มีค่า XYZ-RGB และกรอบสีน้ำเงินคือข้อมูล Ground Truth กำกับชั้นข้อมูลแต่ละจุด ..... 47

รูปที่ 3-11 แสดงการนำเข้าข้อมูลจุดพิกัดสามมิติเข้าโครงข่าย CNN ในสถาปัตยกรรม PointNet++ เพื่อฝึกสอนและทดสอบและการนำออกผลการจำแนก รูปดัดแปลงจาก C. R. Qi et al. (2017) .... 47

รูปที่ 3-12 แสดงการแบ่ง Dataset สำหรับการฝึกสอน ทดสอบและการทดสอบจำแนกจริง..... 50

รูปที่ 3-13 ขั้นตอนการประมวลผลจำแนกข้อมูลจุดพิกัดสามมิติ ..... 51

รูปที่ 3-14 แสดงข้อมูลด้านซ้ายก่อนกรองข้อมูล ด้านขวาหลังจากกรองข้อมูล ..... 51

รูปที่ 4-1 ภาพถ่ายสีแบบพานอรามา 360 องศา จากระบบ MMS ..... 54

รูปที่ 4-2 แสดงข้อมูลจุดพิกัดสามมิติตามค่าสีจากภาพถ่าย ..... 55

รูปที่ 4-3 แสดงผลการฝึกสอนข้อมูลจุดพิกัดสามมิติแบบวิธีไม่มีค่า RGB และมีค่า RGB ..... 59

รูปที่ 4-4 แสดงผลการทดสอบข้อมูลจุดพิกัดสามมิติแบบไม่มีค่า RGB และมีค่า RGB..... 61

รูปที่ 4-5 แสดงผลการจำแนกข้อมูลจากทั้ง 2 วิธี ..... 62

รูปที่ 4-6 ผลการการจำแนกข้อมูล (a) ข้อมูลจุดพิกัดสามมิติ (b) ข้อมูล Label ของจุดพิกัดสามมิติ (c) ผลการจำแนกจุดพิกัดสามมิติวิธี XYZ (d) ผลการจำแนกจุดพิกัดสามมิติวิธี XYZ-RGB..... 63

รูปที่ 5-1 แสดงจุด CPO4 ที่อยู่ใกล้กับบริเวณบดบังสัญญาณดาวเทียม..... 67

รูปที่ 5-2 แสดงบริเวณถนนชำรุดเสียหายอย่างหนัก ..... 68

รูปที่ 5-3 แสดงผลการจำแนกขอบเขตถนนจากทั้ง 2 วิธี..... 69

รูปที่ 5-4 แสดงผลการจำแนกหลุมบ่อที่เกิดในบริเวณไม่ใช่พื้นผิวถนน..... 69

รูปที่ 5-5 แสดงผลการจำแนกหลุมบ่อที่มีค่าสี RGB เหมือนพื้นผิวถนน ..... 70

# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญ

การชำรุดเสียหายของถนนส่งผลกระทบต่อการเดินทางของผู้ใช้ถนน ทำให้เป็นอุปสรรคต่อการเดินทางและเสี่ยงที่จะเกิดอุบัติเหตุต่อการขับขี่ ดังนั้นจึงมีความจำเป็นในการสำรวจเก็บข้อมูลสภาพของพื้นผิวถนนและข้อมูลการชำรุดเสียหายของถนนอย่างเป็นระบบและต่อเนื่อง เพื่อนำไปประยุกต์ใช้ในการวางแผน ซ่อมบำรุงและจัดสรรงบประมาณให้มีประสิทธิภาพ เพื่อเพิ่มระดับการให้บริการของถนน และช่วยให้อายุการใช้งานของถนนยาวนานขึ้น การชำรุดเสียหายของพื้นถนนเกิดจากสาเหตุหลายประการ เช่น อายุการใช้งานถนน ปริมาณการจราจร ปริมาณรถบรรทุกหนักหรือลักษณะภูมิอากาศ เช่น ปริมาณน้ำฝน การเปลี่ยนแปลงของอุณหภูมิรวมทั้งการเคลื่อนไหวของดินชั้นต่าง ๆ ที่อยู่ใต้ถนนและลักษณะของโครงสร้างชั้นพื้นถนนเดิม ความเสียหายมีลักษณะแตกต่างกันหลายรูปแบบ เช่น รอยแตกกว้าง ทรุดเป็นแอ่ง หลุมบ่อ เป็นต้น (Ragnoli et al., 2018)

วิธีการสำรวจการชำรุดของถนนที่ง่ายที่สุดคือการเดินเท้าสำรวจด้วยสายตาและประเมินด้วยผู้เชี่ยวชาญ เป็นวิธีการดั้งเดิมและใช้กำลังคนและค่าใช้จ่ายค่อนข้างมาก รวมถึงใช้เวลานานและมักจะทำให้ข้อมูลที่ไม่มีความน่าเชื่อถือ นอกจากนี้ยังทำให้ผู้สำรวจต้องเสี่ยงกับอันตรายที่อาจเกิดขึ้นในขณะที่ทำงานบนถนน (Zakeri et al., 2017) เพื่อให้ลดปัญหาดังกล่าวจึงมีความพยายามใช้เทคโนโลยีและอุปกรณ์ที่ทันสมัยที่สามารถทำงานได้แบบอัตโนมัติ วิธีการที่ใช้เทคโนโลยีจะมีเพิ่มประสิทธิภาพและความแม่นยำมากขึ้น ซึ่งช่วยให้สามารถวิเคราะห์ผิวทางได้ดียิ่งขึ้น แต่อย่างไรก็ตามเนื่องจากการชำรุดเสียหายของถนนไม่มีลักษณะที่แน่นอน ทำให้การใช้เทคโนโลยีในการตรวจหาการชำรุดของถนนแบบอัตโนมัติมาใช้งานค่อนข้างน้อย (Kim and Ryu, 2014)

การตรวจหาการชำรุดของถนนแบบอัตโนมัตินิยมใช้ข้อมูลภาพถ่ายหรือวิดีโอจากกล้องที่ติดตั้งบนยานพาหนะ นำข้อมูลไปวิเคราะห์ตรวจหาการชำรุดเสียหายของถนนโดยเฉพาะการตรวจหาหลุมบ่อ ได้มีการพัฒนาอัลกอริทึมต่าง ๆ เช่น Earth Mover's Distance (EMD), อัลกอริทึมที่ใช้ Intensity and Motion และ Wavelet Energy Field เพื่อใช้ตรวจหาหลุมบ่อแบบอัตโนมัติจากข้อมูลภาพถ่ายหรือวิดีโอ (Ch et al., 2021; Jo et al., 2016; P. Wang et al., 2017) การใช้ Machine Learning (ML) เป็นวิธีที่ได้รับความนิยมในการตรวจหาหลุมบ่อจากภาพถ่าย โดยมีการใช้

เทคนิคต่าง ๆ เช่น การใช้วิธี Support Vector Machine (SVM) (Jindal and Nagarajan, 2019; Masud et al., 2021) วิธี Random Forest (RF) (Lakmal and Dissanayake, 2020) และการใช้โครงข่ายประสาทเทียม (Neural Network) (R. Li and Liu, 2021) การตรวจหาและจำแนกหลุมบ่อจากภาพถ่ายด้วยโครงข่ายประสาทเทียมเป็นวิธีที่ได้รับความนิยมเป็นอย่างมากในปัจจุบันเนื่องจากเป็นโมเดล AI ที่เลียนแบบเซลล์ประสาทสมอง โดยเฉพาะวิธีโครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network : CNN) ซึ่งเป็นเทคนิคเลียนแบบเปลือกสมองส่วนการมองเห็นของสิ่งมีชีวิต (H. Chen et al., 2020; Darapaneni et al., 2021; Jana et al., 2022)

อย่างไรก็ตามการใช้ภาพถ่ายในการตรวจหาหรือจำแนกหลุมบ่อ มีข้อจำกัดในเรื่องของมาตราส่วน ตำแหน่งพิกัดแผนที่และค่าระดับ ทำให้ไม่สามารถทราบตำแหน่งที่มีความแม่นยำของหลุมบ่อและนำข้อมูลคำนวณพื้นที่กับปริมาตรได้ ซึ่งการคำนวณพื้นที่กับปริมาตรของการเกิดหลุมบ่อสามารถใช้วิเคราะห์ความเสียหายเพื่อประมาณการซ่อมบำรุงถนนได้ จึงมีการพัฒนาการสำรวจด้วยวิธีอื่น ๆ เช่น การสำรวจทำแผนที่ภาพถ่ายด้วยอากาศยานไร้คนขับตรวจหาการชำรุดของถนน (Becker et al., 2019; Pan et al., 2018) เป็นวิธีที่สามารถใช้ข้อมูลแผนที่ภาพถ่ายทางอากาศที่มีมาตราส่วนและอยู่ในระบบพิกัดแผนที่ สามารถคำนวณหาขนาดหลุมบ่อจากข้อมูลแผนที่ภาพถ่ายทางอากาศได้ แต่ข้อมูลแผนที่ภาพถ่ายทางอากาศยังไม่สามารถตรวจหาหรือจำแนกหลุมบ่อที่เป็นรูปแบบสามมิติได้ การตรวจหาหลุมบ่อหรือจำแนกวัตถุของถนนแบบสามมิติส่วนใหญ่เลือกใช้ข้อมูลจากระบบการทำแผนที่แบบเคลื่อนที่ (Mobile Mapping System) หรือจะเรียกชื่อย่อว่า MMS (Ravi et al., 2020; D. Zhang et al., 2018) จุฬาลงกรณ์มหาวิทยาลัย

ระบบการทำแผนที่แบบเคลื่อนที่ประกอบด้วยเซ็นเซอร์ต่าง ๆ คือ เครื่องกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS (Global Navigation Satellite System) เครื่องเซ็นเซอร์วัดความเฉื่อย IMU (Inertial Measurement Unit) กล้องถ่ายภาพแบบพาโนรามา 360 องศา เครื่องสแกนด้วยเลเซอร์ (Laser Scanner) และเครื่องวัดระยะทางด้วยล้อ DMI (Distance Measurement Instrument) (Puente et al., 2013) ใช้ติดตั้งบนยานพาหนะเพื่อสำรวจแผนที่แบบเคลื่อนที่ ซึ่งข้อมูลจากการสำรวจด้วย MMS หลังจากประมวลผลจะจัดเก็บอยู่ในรูปแบบจุดพิกัดสามมิติ ซึ่งเป็นข้อมูลจุดที่มีความละเอียดเชิงพื้นที่ ทุกจุดมีค่าพิกัดตำแหน่งที่อ้างอิงตามระบบแผนที่ ทำให้มีงานวิจัยใช้ข้อมูลจุดพิกัดสามมิติจำแนกวัตถุต่าง ๆ ของสภาพแวดล้อมถนน (Ma et al., 2018; Xiang et al., 2018; M. Yang et al., 2019) ผลการจำแนกจุดพิกัดสามมิติสามารถคำนวณพื้นที่และปริมาตรได้ ดังนั้นการใช้จุดพิกัดสามมิติจำแนกหลุมบ่อที่เกิดขึ้นสามารถวิเคราะห์ความเสียหายและประเมินการซ่อมบำรุงที่

เกิดขึ้นได้ และในปัจจุบัน MMS มีกล้องถ่ายภาพพาโนรามา 360 องศา ที่ให้จุดพิกัดสามมิติที่มีค่าในย่านสีแดง เขียวและน้ำเงิน (RGB) ทำให้จุดสามารถแสดงผลเป็นสามมิติพร้อมกับค่าสีจากภาพถ่าย (D. Wang et al., 2020) ดังนั้นค่า RGB เป็นชุดข้อมูลที่เพิ่มเข้ามาในจุดพิกัดสามมิติ สามารถใช้เป็นข้อมูลจำแนกร่วมกันจุดพิกัดสามมิติที่เป็น XYZ อย่างไรก็ตามยังไม่มียานวิจัยทดสอบเปรียบเทียบความถูกต้องของการจำแนกจุดพิกัดสามมิติด้วยวิธีแบบมีค่า RGB และแบบไม่มีค่า RGB

การใช้ ML ได้รับความนิยมในการจำแนกวัตถุจากจุดพิกัดสามมิติเช่นเดียวกับการใช้ข้อมูลจากภาพถ่าย เช่นการใช้วิธี Random Forest (RF) ในการตรวจหาขอบถนนและสัญลักษณ์จราจรบนพื้นผิวถนน (B. Yang et al., 2017) การใช้วิธี Support Vector Machine (SVM) เพื่อจำแนกวัตถุต่าง ๆ ในพื้นที่เขตเมือง (Serna and Marcotegui, 2014) และ การใช้โครงข่ายประสาทเทียม (Neural Network) ในการใช้จำแนกวัตถุจากจุดพิกัดสามมิติโดยการใช้วิธี CNN (Zhongyang et al., 2018) การใช้ CNN ในการจำแนกจุดพิกัดสามมิติมีความซับซ้อนมากกว่าการจำแนกข้อมูลภาพถ่ายสองมิติ เนื่องจากจุดมีการเรียงตัวที่ไม่เป็นระเบียบ การจำแนกจุดพิกัดสามมิติสามารถแปลงข้อมูลจากสามมิติไปเป็นตารางสองมิติ (Pixel) เพื่อใช้ CNN จำแนกข้อมูล (L. Zhang et al., 2018) หรือหากต้องการจำแนกวัตถุที่ต้องการใช้ประโยชน์จากรูปทรงสามมิติ จำเป็นต้องแปลงข้อมูลจุดพิกัดสามมิติให้เป็นตารางลูกบาศก์ (Voxel) (Jing and Suya, 2016) สถาปัตยกรรมของ CNN ได้มีการพัฒนาจนสามารถจำแนกข้อมูลจุดพิกัดสามมิติได้โดยตรงในสถาปัตยกรรม PointNet (C. Qi et al., 2017)

PointNet เป็นสถาปัตยกรรมที่น่าสนใจเนื่องจากสามารถจำแนกจุดพิกัดสามมิติได้โดยตรงลดขั้นตอนการแปลงข้อมูลเป็น Voxel หรือ Pixel ซึ่งจะทำให้เสียคุณลักษณะเฉพาะของจุดพิกัดสามมิติ และมีการพัฒนาสถาปัตยกรรมไปเป็น PointNet++ (C. R. Qi et al., 2017) ซึ่งมีจุดเด่นคือสามารถตรวจจับคุณลักษณะเฉพาะส่วนของวัตถุได้ดียิ่งขึ้น อย่างไรก็ตามในงานวิจัยที่ผ่านมายังไม่พบว่ามีงานนำข้อมูลจุดพิกัดสามมิติที่ได้จากระบบการทำแผนที่แบบเคลื่อนที่จำแนกหลุมบ่อและถนนโดยใช้ CNN รวมถึงการใช้ค่าสี RGB ร่วมกับจุดพิกัดสามมิติเพื่อช่วยจำแนกข้อมูลให้มีประสิทธิภาพมากยิ่งขึ้น ดังนั้นในงานวิจัยนี้ใช้ CNN ในสถาปัตยกรรม PointNet++ ที่สามารถจำแนกวัตถุจากจุดพิกัดสามมิติได้โดยตรง จำแนกข้อมูลที่ได้จากการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่ประกอบด้วยค่าพิกัดตำแหน่ง XYZ รวมถึงการใช้ค่าสี RGB จากกล้องถ่ายภาพพาโนรามา 360 องศา เพื่อช่วยในการจำแนกถนนและหลุมบ่อ ในงานวิจัยจะมุ่งเน้นไปยังการจำแนกหลุมบ่อเนื่องจากเป็นปัญหาที่เกิดขึ้นบนถนนในประเทศไทย แต่ยังคงมีความจำเป็นต้องจำแนกถนนร่วมด้วย เนื่องจากพื้นผิวถนนมีความจำเป็นในการนำมาวิเคราะห์การซ่อมบำรุง



## 1.2 วัตถุประสงค์ของการวิจัย


1.2.1 เพื่อประเมินความถูกต้องเชิงตำแหน่งและความละเอียดเชิงพื้นที่ของจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่

1.2.2 เพื่อประเมินประสิทธิภาพของระบบประมวลผลเชิงคำนวณ แนวคิดโครงข่ายประสาทคอนโวลูชัน ในการจำแนกข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่สำหรับการตรวจหาพื้นผิวถนนและหลุมบ่อ

## 1.3 ขอบเขตการศึกษา

1.3.1 การศึกษาใช้ข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่โดยอุปกรณ์ Topcon IP-S3 HD

1.3.2 พื้นที่ศึกษาเป็นถนนโยธาธิการ เคหะการเกษตร หมู่ 10 ตำบลหนองเพรางาย อำเภอไทรน้อย จังหวัดนนทบุรี เนื่องจากเส้นทางดังกล่าวเป็นที่ตั้งของโรงงานอุตสาหกรรมจำนวนมาก ทำให้มีรถบรรทุกหนักใช้งานเส้นทางเป็นประจำ จึงทำให้เส้นทางเกิดความชำรุดเกิดความเสียหายเป็นหลุมบ่อ จึงทำให้ผู้วิจัยเลือกใช้พื้นที่เส้นทางดังกล่าวในการสำรวจเก็บข้อมูลด้วยระบบการทำแผนที่แบบเคลื่อนที่ เพื่อนำข้อมูลมาวิเคราะห์จำแนกตรวจหาหลุมบ่อเพื่อประเมินความเสียหายโดยใช้ CNN ซึ่งตำแหน่งที่ตั้งแสดงในรูปที่ 1-1



รูปที่ 1-1 แสดงเส้นทางที่ศึกษาถนนโยธาธิการ เคหะการเกษตร หมู่ 10 ตำบลหนองเพรางาย อำเภอไทรน้อย จังหวัดนนทบุรี

#### 1.4 สมมติฐานของงานวิจัย


1.4.1 ข้อมูลที่ได้จากการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่ มีความถูกต้องเชิงตำแหน่งและมีความละเอียดเชิงพื้นที่ สามารถจำแนกวัตถุต่าง ๆ ได้โดยเฉพาะถนนและหลุมบ่อ

1.4.2 การใช้โครงข่ายประสาทคอนโวลูชันสามารถจำแนกถนนและหลุมบ่อจากจุดพิกัดสามมิติได้อย่างถูกต้องและแม่นยำ

#### 1.5 ประโยชน์คาดว่าจะได้รับ

1.5.1 ทราบความถูกต้องเชิงตำแหน่งและความละเอียดเชิงพื้นที่ของข้อมูลจุดพิกัดสามมิติที่ได้จากระบบการทำแผนที่แบบเคลื่อนที่

1.5.2 ทราบถึงประสิทธิภาพของระบบประมวลผลเชิงคำนวณ แนวคิดโครงข่ายประสาทคอนโวลูชัน ในการจำแนกข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่สำหรับการตรวจหาพื้นผิวถนนและหลุมบ่อ



## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

#### 2.1 ความเสียหายของพื้นผิวถนน

การชำรุดเสียหายของถนนเกิดจากหลายสาเหตุเช่น การสัญจรของรถมากเกินไป การใช้งานของรถบรรทุกหนัก อายุการใช้งานของถนน สภาพอากาศเป็นหนึ่งในสาเหตุเช่นเดียวกันคือ การเปลี่ยนแปลงอุณหภูมิระหว่างวัน ปริมาณฝนตก การเคลื่อนไหวและลักษณะของชั้นใต้ดินที่อยู่ใต้ถนน ทั้งหมดเป็นสาเหตุที่ทำให้ถนนเกิดความเสียหายและลักษณะความเสียหายเกิดขึ้นมีหลายรูปแบบเช่น หลุมบ่อ ยุบตัวเป็นแอ่ง ร่องล้อ รอยปะซ่อม ผิวทางทรุดตัว และรอยแตกร้าว เป็นต้น (Ragnoli et al., 2018)

การบำรุงรักษาความชำรุดเสียหายที่เกิดขึ้น จะใช้วิธีที่แตกต่างกันขึ้นอยู่กับลักษณะความเสียหาย ต้องเลือกวิธีที่ถูกต้องกับลักษณะของผิวทาง ซึ่งความเสียหายที่เกิดขึ้นกับผิวทางลาดยางสามารถแบ่งความเสียหายออกเป็น 6 ประเภท คือ หลุมบ่อ ยุบตัวเป็นแอ่ง ร่องล้อรอยปะซ่อมที่เสียหาย พื้นผิวถนนหลุดร่อน และรอยแตกร้าว (Ragnoli et al., 2018)

##### 2.1.1 หลุมบ่อ (Pothole)

ความเสียหายเกิดจากโครงสร้างถนนไม่แข็งแรง เนื่องจากวัสดุที่นำมาก่อสร้างไม่ได้มาตรฐานตามที่กำหนด หรืออาจเกิดจากรถบรรทุกหนักสัญจรผ่านจำนวนมาก หรืออาจเกิดจากระบบการระบายน้ำไม่ค่อยดี ทำให้เกิดหลุมบ่อลักษณะคล้ายถ้วย ตัวอย่างความเสียหายดังแสดงในรูปที่ 2-1



รูปที่ 2-1 ความเสียหายประเภทหลุมบ่อ

### 2.1.2 ยุบตัวเป็นแอ่ง (Depression)

การยุบตัวเป็นแอ่งมีสาเหตุเกิดจากรถบรรทุกหนักเกินกว่ากฎหมายกำหนดสัญจรผ่านในปริมาณที่มาก หรือเกิดจากการทรุดตัวของโครงสร้างที่ยุบตัวจากการการก่อสร้างที่ไม่มีคุณภาพ และไม่ถูกต้องตามแบบ ซึ่งความเสียหายของผิวถนนจะยุบตัวเป็นแอ่งต่ำกว่าระดับผิวทางปกติ บางครั้งอาจจะมีรอยแตกกร้าวรวมอยู่ด้วยตัวอย่างความเสียหายดังแสดงในรูปที่ 2-2



รูปที่ 2-2 ความเสียหายประเภทยุบตัวเป็นแอ่ง

### 2.1.3 ร่องล้อ (Rutting)

ความเสียหายในลักษณะของร่องล้อเกิดจากการรับน้ำหนักบรรทุกทุกเกินมาตรฐาน กำหนดที่สัญจรเป็นจำนวนมากและจากการบดอัดของวัสดุในชั้นทางที่ก่อสร้างไม่ดีหรือวัสดุทางมีส่วนผสมที่ไม่เหมาะสม ทำให้เกิดการเคลื่อนตัวของชั้นผิวทาง ทำให้ผิวทางเปลี่ยนรูปโดยมีการยุบตัวไปตามแนวร่องล้อ บริเวณด้านข้างถูกดันให้สูงขึ้น ตัวอย่างความเสียหายดังแสดงในรูปที่ 2-3



รูปที่ 2-3 ความเสียหายประเภทร่องล้อ

#### 2.1.4 รอยปะซ่อมที่เสียหาย (Bad Patching)

เกิดจากการซ่อมแซมความเสียหายบนพื้นผิวถนน หรือการบดอัดวัสดุถมหลุมที่ไม่ได้คุณภาพ หรือการซ่อมแซมพื้นผิวถนนตามระบบสาธารณสุขโรค ทำให้เกิดเป็นรอยปะซ่อมที่ไม่ได้คุณภาพ และปรากฏเป็นความเสียหายส่งผลกระทบต่อผู้ใช้ทาง ดังรูปที่ 2-4



รูปที่ 2-4 ความเสียหายประเภทรอยปะซ่อมที่เสียหาย

#### 2.1.5 พื้นผิวถนนหลุดร่อน (Raveling)

พื้นผิวถนนหลุดร่อนสาเหตุเกิดจากที่ผิวทางไม่ได้รับการบดอัดที่แน่นพอ หรือการผสมแอสฟัลต์ในปริมาณที่น้อยเกินไป หรือการก่อสร้างเกิดขึ้นในสภาพอากาศที่ชื้นเกินไป ทำให้วัสดุผิวทางแยกออกจากกัน จากผิวถนนชั้นบนจนถึงผิวถนนชั้นล่าง โดยวัสดุที่มีความละเอียดจะหลุดออกมาก่อน และวัสดุขนาดใหญ่จะทยอยหลุดร่วงตามมา ตัวอย่างความเสียหายดังแสดงในรูปที่ 2-5



รูปที่ 2-5 ความเสียหายประเภทพื้นผิวถนนหลุดร่อน

### 2.1.6 รอยแตกร้าว (Crack)

รอยแตกร้าว (crack) จะแบ่งความเสียหายไว้ 3 รูปแบบคือ รอยแตกร้าวตามแนวยาว รอยแตกร้าวตามแนวขวางและรอยแตกร้าวแบบหนึ่งจระเข้ เกิดจากการขยายตัวและหดตัวจากการเปลี่ยนแปลงของอุณหภูมิและความชื้น ทำให้ไหล่ทาง ช่องจราจรและรอยต่อระหว่างช่องจราจร ข้างเคียงไม่แข็งแรงเพียงพอสำหรับการกระจายน้ำหนัก ตัวอย่างความเสียหายดังแสดงในรูปที่ 2-6



รูปที่ 2-6 ความเสียหายประเภทรอยแตกร้าว

## 2.2 ระบบการทำแผนที่แบบเคลื่อนที่ (Mobile Mapping System)

เนื่องจาก GNSS เป็นเทคโนโลยีที่เข้าถึงได้ในช่วงหลายทศวรรษที่ผ่านมา ดังนั้นต่อมา เทคโนโลยีระบบการทำแผนที่แบบเคลื่อนที่ (MMS) ได้มีการพัฒนาตามมาอย่างรวดเร็ว เป็นเทคนิคการสำรวจและทำแผนที่ขั้นสูงสำหรับการรวบรวมข้อมูลเชิงพื้นที่อย่างมีประสิทธิภาพและรวดเร็ว (Lehtomäki et al., 2016) เมื่อเปรียบเทียบกับวิธีการสแกนด้วยเลเซอร์ภาคพื้นดิน (Terrestrial Laser Scanner) การสแกนด้วยเลเซอร์บนอากาศยานไร้คนขับ (Aerial Laser Scanner) และเทคโนโลยีการถ่ายภาพดาวเทียม ระบบ MMS มีความคล่องตัวและสามารถรวบรวมข้อมูลจุดพิกัดสามมิติที่มีความหนาแน่นสูงเมื่อเทียบกับระยะเวลาการทำงานระบบนี้ทำให้ประหยัดค่าใช้จ่ายในการทำงานมากกว่าวิธีอื่น ๆ โดยทั่วไปแล้วอุปกรณ์เซ็นเซอร์ต่าง ๆ ของ MMS ติดตั้งกับยานพาหนะคือ เครื่องสแกนด้วยเลเซอร์ (LiDAR) ระบบการกำหนดตำแหน่งด้วยระบบดาวเทียม (GNSS) เครื่องเซ็นเซอร์วัดความเฉื่อย (IMU) เครื่องวัดระยะทาง (DMI) กล้องดิจิทัลขั้นสูงและระบบคอมพิวเตอร์ส่วนกลางสำหรับการจัดเก็บและจัดการข้อมูล (Yu et al., 2015) โดย GNSS, IMU และ DMI เป็นระบบการกำหนดตำแหน่งและการปรับทิศทาง Position and Orientation System (POS) การทำแผนที่แบบเคลื่อนที่ ใช้เทคนิคการสแกนตามแนวของคลื่นสัญญาณและการตรวจจับความเข้ม

ของแสงเลเซอร์ที่สะท้อนจากพื้นผิววัตถุ MMS สามารถสแกนวัตถุที่มีความแม่นยำและสามารถนำไปสร้างแบบจำลองสามมิติของเมืองได้ (Ma et al., 2018) ความถูกต้องของการวัดระยะทางของการสแกน อาศัยความเร็วของแสงในการส่งสัญญาณคลื่นและสะท้อนกลับมา ดังนั้นความถูกต้องเชิงตำแหน่งในรูปแบบสามมิติจะขึ้นอยู่กับมุมของคลื่นที่ใช้สแกน ระยะทางในการวัด ตำแหน่งและการปรับทิศทางของอุปกรณ์ (J. Li et al., 2016)

นอกจากนี้ความละเอียดเชิงพื้นที่ของการสำรวจข้อมูลด้วย MMS จะถูกกำหนดตามคุณสมบัติเฉพาะของเซ็นเซอร์สแกนและความเร็วในการขยับยานพาหนะ ปัจจุบัน MMS เชิงพาณิชย์มีการใช้งานกันในประเทศไทยเช่น Topcon IP-S3 HD ให้การสแกนครั้งละ 30 แนวและจำนวนจุดอยู่ที่ 700,000 จุดต่อวินาที ซึ่งสามารถรวบรวมจุดพิกัดสามมิติที่มีความหนาแน่น สำหรับไปประยุกต์ใช้งานที่หลากหลาย เช่น การสร้างแบบจำลองของเมือง การสำรวจโมเดล การทำระบบขนส่งแบบอัจฉริยะ Intelligent Transportation Systems (ITS) งานทางด้านสถาปัตยกรรมและวิศวกรรม

รายละเอียดการทำงานของระบบการทำแผนที่แบบเคลื่อนที่สำหรับการสำรวจและการประยุกต์ใช้งานจะแบ่งรายละเอียดดังต่อไปนี้ 1) ส่วนประกอบของ MMS 2) การอ้างอิงระบบพิกัด 3) ค่าความคลาดเคลื่อนที่เกิดขึ้นจากระบบ

### 2.2.1 ส่วนประกอบของ MMS

#### 1) LiDAR (Light Detection and Ranging)

LiDAR เป็นระบบสแกนด้วยเลเซอร์ส่งคลื่นแสงออกไปอย่างต่อเนื่องโดยคลื่นอินฟราเรดใกล้ตกกระทบกับพื้นผิววัตถุต่าง ๆ และแปลงสัญญาณที่สะท้อนกลับเป็นรูปแบบดิจิทัล จากนั้นระยะเวลาในการเดินทางของแสงคำนวณเป็นระยะทางที่ระหว่างเซ็นเซอร์สแกนกับวัตถุ การสแกนสามารถคำนวณเป็นข้อมูลค่าพิกัดและค่าสัญญาณ ปัจจุบันมีการใช้เทคนิคที่ทันสมัย 2 รูปแบบในการวัดระยะของ MMS คือ ระยะเวลาของการเดินทางของคลื่น Time of flight (TOF) และการเปลี่ยนแปลงของคลื่นเฟส (Vosselman and Maas, 2010)

ในขณะที่คลื่นของเลเซอร์มีความแน่นอนและคงที่นั้น (Vosselman and Maas, 2010) ช่วงของการสแกนระหว่างเซ็นเซอร์สแกนกับวัตถุสามารถทราบค่าได้โดยการคำนวณระยะเวลาของการเดินทางของคลื่นหรือเรียกอีกอย่างว่าการหน่วงเวลา การคำนวณระหว่าง

การส่งคลื่นแสงไปและคลื่นสะท้อนจากวัตถุกลับยังเซ็นเซอร์สแกน (Lindner et al., 2010) MMS ในเชิงพาณิชย์ส่วนใหญ่ติดตั้งเครื่องสแกนด้วยเลเซอร์แบบวัดระยะเวลาของการเดินทางของคลื่น TOF เนื่องจากเครื่องสแกนดังกล่าวให้ระยะเวลาการวัดได้ไกลกว่าเครื่องสแกนแบบใช้คลื่นเฟส (Puente et al., 2013) และเมื่อเทียบกับเครื่องสแกนแบบใช้คลื่นเฟส จะปล่อยคลื่นแบบต่อเนื่องโดยใช้ความต่างของคลื่นเฟส ดังนั้นระยะห่างระหว่างเซ็นเซอร์สแกนและวัตถุเป้าหมายจะคำนวณได้ขึ้นอยู่กับ การเปลี่ยนเฟสจากการส่งลำแสงและการรับสัญญาณที่สะท้อนกลับมา

## 2) กล้องถ่ายภาพ (Digital cameras)

ความก้าวหน้าในการพัฒนากล้องดิจิทัลเพื่อประยุกต์ใช้กับ MMS เพื่อให้ครอบคลุมการมองเห็นของ MMS ในเชิงพาณิชย์ ส่วนใหญ่ใช้กล้องดิจิทัลระดับสูงเพื่อให้มีการแสดงจุดพิกัดสามมิติแบบสมจริงโดยใช้ข้อมูลภาพสี (Kumar et al., 2014) นอกจากนี้รูปทรงเรขาคณิตของภาพที่มีความเสถียรและภาพที่มีความละเอียดช่วยเพิ่มความน่าเชื่อถือของข้อมูลรวมถึงการนำจุดพิกัดสามมิติไปประยุกต์ใช้งานในอนาคตต่อไป (Toth, 2009) ดังนั้นผู้ผลิตกล้องส่วนใหญ่จึงให้ความสำคัญกับการวิจัยและพัฒนา กล้องดิจิทัลที่ปรับแต่งเองตามความต้องการเฉพาะของ MMS ตัวอย่างเช่นอุปกรณ์การทำแผนที่แบบเคลื่อนที่ Topcon IP-S3 HD มีกล้องดิจิทัล 6 ตัวเพื่อบันทึกข้อมูลรูปทรงเรขาคณิตที่หลากหลายเช่นข้อมูลสีและพื้นผิวของวัตถุเป้าหมาย เนื่องจากเครื่องสแกนด้วยเลเซอร์ส่วนใหญ่ให้ค่าการสะท้อนคลื่นที่ความยาวคลื่นเป็นข้อมูลพื้นผิว ในขณะที่ข้อมูลภาพสีขาดการอ้างอิงระบบพิกัด ดังนั้นการรวมกันของข้อมูลทั้งสองประเภทนี้สามารถนำไปใช้ในการสร้างจุดพิกัดสามมิติที่เป็นสีจริงเพื่อการสร้างแบบจำลองสามมิติของเมือง อย่างไรก็ตาม กล้องดิจิทัลเป็นบทบาทรองของ MMS ที่ใช้สร้างโมเดลสามมิติ ในขณะที่เครื่องสแกนด้วยเลเซอร์ที่อยู่ใน MMS เป็นแหล่งข้อมูลหลักและอ้างอิงระบบพิกัดที่แม่นยำ (Guan et al., 2015)

## 3) การกำหนดตำแหน่งด้วยระบบดาวเทียมและระบบการปรับแก้ทิศทาง (Global navigation satellite system and Orientation system)

ดังที่ได้กล่าวไว้ก่อนหน้านี้ GNSS, IMU และ DMI เป็นระบบการกำหนดตำแหน่งและปรับทิศทาง ซึ่งสามารถหาข้อมูลตำแหน่งของ MMS เซ็นเซอร์ GNSS ให้ข้อมูลตำแหน่งที่แม่นยำสูงถึงระดับเซนติเมตรและสามารถให้ข้อมูลเพิ่มเติม 2 ส่วนได้แก่ข้อมูลความเร็วและ



เวลา อย่างไรก็ตามความแม่นยำของตำแหน่งจะลดลงเนื่องจากปัญหาการแพร่กระจายคลื่นสัญญาณหลายวิถีที่เกิดจากสิ่งกีดขวางต่าง ๆ เช่น ต้นไม้สูง อาคารและอุโมงค์ ตัวอย่างเช่น ตัวรับสัญญาณ GNSS ถูกล้อมรอบด้วยอาคาร ต้นไม้ เพื่อที่จะกำจัดผลกระทบจากการแพร่กระจายคลื่นสัญญาณหลายวิถีและเพื่อแก้ปัญหาผลกระทบที่เกิดขึ้นของการสูญเสียสัญญาณของ GNSS ดังนั้น IMU จึงถูกใช้เพื่อช่วยเพิ่มความถูกต้องของตำแหน่ง ความเร็วและทิศทางของ MMS โดยทั่วไป IMU สามารถเพิ่มความเสถียรและความต่อเนื่องของตำแหน่งในกรณีที่เกิดการสูญเสียของสัญญาณ GNSS (Puente et al., 2013) นอกจากนี้ยังมีการติดตั้งเครื่องวัด 3 ทิศทางและมาตรวัดความเร่ง 3 ทิศทางใน IMU ซึ่งสามารถใช้วัดการหมุนเชิงมุมสามทิศทางและความเร่งสามทิศทาง เมื่อความแม่นยำของตำแหน่งและทิศทางลดลง การเพิ่มเวลาในการวัดและการประมวลผลรวมกันของ GNSS และ IMU จึงสามารถปรับปรุงความแม่นยำของตำแหน่งได้ (J. Li et al., 2016) ดังนั้น IMU จึงให้ข้อมูลตำแหน่งและการวางตัวแบบสัมพัทธ์ ในช่วงเวลาที่สัญญาณดาวเทียมสูญหายไป ในขณะที่ GNSS จะส่งข้อมูลตำแหน่งอย่างต่อเนื่องโดยละเอียดไปยัง IMU นอกจากนี้ DMI ที่ติดตั้งบนวงล้อของยานพาหนะโดยใช้สายเคเบิลส่งข้อมูล สามารถวัดค่าระยะทางเพื่อลดความผิดพลาดโดยเฉพาะอย่างยิ่งสำหรับพื้นที่ในเมืองที่มีสัญญาณ GNSS ที่ไม่เสถียร

#### 4) ระบบควบคุมส่วนกลาง (Central Control System)

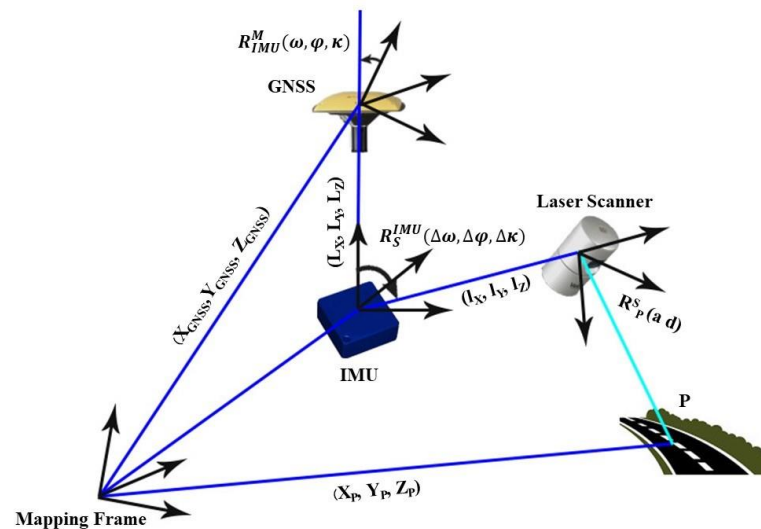
เป็นระบบควบคุมส่วนกลางขั้นสูงซึ่งใช้ซอฟต์แวร์ที่มีความซับซ้อนได้รับการออกแบบมาเพื่อควบคุมเซ็นเซอร์ทั้งหมดเช่นเครื่องสแกนด้วยเลเซอร์และกล้องดิจิทัล จะทำหน้าที่รวบรวม วิเคราะห์ ประมวลผลข้อมูลจากเซ็นเซอร์ดังกล่าวและจัดเก็บข้อมูลเส้นทางที่ได้จากระบบการกำหนดตำแหน่งและการปรับทิศทาง

#### 2.2.2 การอ้างอิงระบบพิกัด

วิธีการอ้างอิงระบบพิกัดแผนที่ได้อธิบายไว้ในรูปที่ 2-7 ตามการสแกนมุม  $\alpha$  และระยะการสแกน  $d$  ของจุดใดจุดหนึ่งคือ  $P$  ตำแหน่งนั้นจะถูกกำหนดในระบบพิกัดของระบบ นอกจากนี้ตำแหน่งในระบบพิกัดของการสแกนสามารถเปลี่ยนเป็นระบบพิกัดแผนที่ได้

ดังที่แสดงในตารางที่ 2-1 ได้แสดงรายการคำอธิบายและแหล่งที่มาของค่าพารามิเตอร์ที่เกี่ยวข้องกับการหาตำแหน่งพิกัดในระบบแผนที่ของจุด  $P$  โดยมีการคำนวณโดยใช้สมการที่ (2-1) ค่าพารามิเตอร์ที่แสดงในสมการ  $[X_p, Y_p, Z_p]^T$  แสดงข้อมูลตำแหน่งของวัตถุเป้าหมาย  $P$  ในระบบ

พิกัดแผนที่  $[X_{GNSS}, Y_{GNSS}, Z_{GNSS}]^T$  แสดงข้อมูลตำแหน่งของเครื่องรับสัญญาณ GNSS ในระบบแผนที่ ส่วนของ  $(\omega, \varphi, \kappa)$  คือรายละเอียดของค่า roll, pitch และ yaw ของ IMU ในระบบพิกัดแผนที่ และ  $(\Delta\omega, \Delta\varphi, \Delta\kappa)$  เป็นค่าปรับทิศทางของเครื่องสแกนด้วยเลเซอร์ไปหา IMU ในส่วนของ ตัวแปร  $a$  และ  $d$  หมายถึงมุมของเลเซอร์และระยะการของเลเซอร์ และสุดท้ายพารามิเตอร์อื่น ๆ คือ ค่าที่ได้จากการปรับแก้ของ MMS



รูปที่ 2-7 หลักการอ้างอิงระบบพิกัดแผนที่ของ MMS

ตารางที่ 2-1 แสดงรายการพารามิเตอร์ที่เกี่ยวข้องในการแปลงค่าการอ้างอิงระบบพิกัดแผนที่โดยตรง และเวกเตอร์ข้อมูลการวางตำแหน่งของวัตถุเป้าหมาย P คำนวณโดยใช้สมการที่ (2-1)

Parameters	Representation	Source
$(X_p, Y_p, Z_p)$	พิกัดจากเลเซอร์ของจุด P ในระบบพิกัดแผนที่	Mapping frame
$R_{IMU}^M(\omega, \varphi, \kappa)$	ข้อมูลการหมุนเพื่อจัดตำแหน่ง IMU ให้ตรงกับเฟรมแผนที่	IMU
$R_S^{IMU}(\Delta\omega, \Delta\varphi, \Delta\kappa)$	พารามิเตอร์ปรับค่าเลเซอร์ไปเป็นระบบของ IMU	System calibration
$R_P^S(a, d)$	ข้อมูลตำแหน่งจุด P ในระบบพิกัดสแกน	Laser scanners
$l_x, l_y, l_z$	ระยะขดเชย IMU กับเครื่องสแกน	System calibration
$L_x, L_y, L_z$	ระยะขดเชย GNSS กับ IMU	System calibration
$(X_{GNSS}, Y_{GNSS}, Z_{GNSS})$	ตำแหน่งของเครื่อง GNSS ในเฟรมแผนที่	GNSS antenna

$$\begin{bmatrix} X_p \\ Y_p \\ Z_p \end{bmatrix} = R_{IMU}^M(\omega, \varphi, \kappa) \cdot \left( \begin{bmatrix} l_x \\ l_y \\ l_z \end{bmatrix} + \begin{bmatrix} L_x \\ L_y \\ L_z \end{bmatrix} + r_p^S(a, d) \cdot R_S^{IMU}(\Delta\omega, \Delta\varphi, \Delta\kappa) \right) + \begin{bmatrix} X_{GNSS} \\ Y_{GNSS} \\ Z_{GNSS} \end{bmatrix} \quad (2-1)$$

### 2.2.3 ความคลาดเคลื่อนของ MMS

ดังที่แสดงในสมการ (2-1) ความสัมพันธ์ระหว่างค่าพารามิเตอร์กับค่ารั้งวัดถูกกำหนดเพื่ออ้างอิงระบบพิกัดแผนที่ให้กับจุดพิกัดสามมิติ ดังนั้นความคลาดเคลื่อนจากหลาย ๆ พารามิเตอร์อาจส่งผลให้ความถูกต้องของตำแหน่งลดลงหลังจากข้อมูลได้รับการปรับแก้จากพารามิเตอร์ดังกล่าว ซึ่งความคลาดเคลื่อนที่เกิดขึ้นจากเซ็นเซอร์ต่าง ๆ อธิบายได้ดังต่อไปนี้

#### 1) ความคลาดเคลื่อนจากการสแกนด้วยเลเซอร์ (Laser scanning errors)

ความถูกต้องของตำแหน่งในการเก็บข้อมูลจะขึ้นอยู่กับความคลาดเคลื่อนของการวัดระยะและความคลาดเคลื่อนทางมุมของเครื่องสแกนด้วยเลเซอร์ ความคลาดเคลื่อนของการวัดระยะจะหมายถึงความคลาดเคลื่อนของระบบการวัด ในการการจับเวลาการส่งและการรับสัญญาณของคลื่น และยิ่งไปกว่านั้นความคลาดเคลื่อนของมุมที่รวมเข้ามา เกิดจากความละเอียดเชิงมุมและความไม่คงที่ของตัวเลเซอร์ที่แตกต่างกัน (Olsen et al., 2013)

#### 2) ความคลาดเคลื่อนจากเครื่องวัดความเฉื่อย (IMU errors)

เซ็นเซอร์ IMU ใน MMS กำหนดรายละเอียดของ roll, pitch, และ yaw ซึ่งกำหนดเมทริกซ์การหมุนระหว่าง IMU และระบบพิกัดแผนที่ IMU ส่วนใหญ่จะมียังค์ประกอบด้วยกัน 2 ส่วนคือ 1) มาตรการวัดความเร่งเชิงมุม 3 ทิศทาง ที่ใช้วัดการเปลี่ยนแปลงของตำแหน่งตามแนวทิศทางและ 2) มาตรการวัดทิศทาง 3 ทิศทาง เป็นการรักษาทิศทางของมุมอ้างอิงแบบสัมบูรณ์ตามหลักการรักษาโมเมนตัมของมุม โดยทั่วไปแล้วความคลาดเคลื่อนของ IMU จะมีปัญหาตรงที่ความเอนเอียงของตัว accelerometer และ gyroscope เช่นการเยื้องศูนย์ของแรงโน้มถ่วงและความคลาดเคลื่อนแบบสุ่มเช่นสัญญาณรบกวนของเซ็นเซอร์ โดยทั่วไปแล้วจะมีการระบุความแม่นยำของ IMU จากผู้ผลิตไว้ในข้อกำหนดทางเทคนิคของอุปกรณ์

#### 3) ความคลาดเคลื่อนจากการกำหนดตำแหน่ง (Localization errors)

ความถูกต้องเชิงตำแหน่งของ GNSS นั้นส่วนใหญ่ได้รับผลกระทบจากหลายสาเหตุ เช่นความคลาดเคลื่อนจากการแพร่กระจายคลื่นสัญญาณหลายวิถี ความคลาดเคลื่อนในชั้นบรรยากาศ ความคลาดเคลื่อนจากระยะทางของเส้นฐานระหว่าง Base กับเครื่องรับสัญญาณ GNSS ใน MMS (McCormac et al., 2012) ดังนั้นการกำหนดตำแหน่งที่มีความถูกต้องจากการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS เป็นสิ่งที่สำคัญกับ MMS การทำงาน

เก็บข้อมูลด้วย MMS นั้นใช้การกำหนดตำแหน่งด้วยวิธี Post Process Kinematic (PPK) ความถูกต้องอยู่ในเกณฑ์ประมาณ 1 ซม. + 1 ppm ในทางราบและ 2 ซม. + 1 ppm ในทางดิ่งสำหรับความยาวของเส้นฐานไม่ไกลมาก

#### 4) ความคลาดเคลื่อนของการวัดค่าชดเชยระหว่างเซ็นเซอร์ (Lever-arm offset errors)

ค่า Lever-arm offset ของ MMS ส่วนใหญ่จะเป็นค่าที่ได้มาจากโรงงานผู้ผลิต สามารถให้ค่าความถูกต้องของระบบพิกัดแผนที่ที่ดี เมื่อมีค่าชดเชยระหว่างอุปกรณ์ที่แม่นยำ ดังนั้นอุปกรณ์ต้องมีการสอบเทียบและปรับแก้เพื่อให้ค่าชดเชยระยะของเซ็นเซอร์กับตำแหน่งที่ตั้งบนยานพาหนะให้มีค่าที่แม่นยำมากที่สุด (J. Li et al., 2016) ซึ่งค่าชดเชยความสูงของอุปกรณ์ MMS กับระดับพื้น หากไม่ได้วัดระยะที่แม่นยำอาจนำไปหาระดับของจุดพิกัดสามมิติมีความคลาดเคลื่อนสูง

จากที่ได้กล่าวเกี่ยวกับแหล่งที่มาของความคลาดเคลื่อนแสดงให้เห็นว่าประสิทธิภาพโดยรวมของระบบการทำแผนที่แบบเคลื่อนที่ขึ้นอยู่กับความถูกต้องเชิงตำแหน่งของผลลัพธ์ที่ได้จากเครื่องสแกนด้วยเลเซอร์ GNSS และ IMU ส่วนของความคลาดเคลื่อนของระยะชดเชยของอุปกรณ์ย่อยจะถูกควบคุมอย่างมีประสิทธิภาพโดยการปรับแก้ที่เหมาะสมจากโรงงานผู้ผลิต นอกจากนี้ในส่วนของการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS สามารถสร้างผลกระทบต่อความถูกต้องโดยรวมของ MMS ผลกระทบจากคลื่นหลายวิถี (Multipath Error) และการสูญเสียสัญญาณเนื่องจากพื้นที่ใกล้ต้นไม้ใหญ่และตึกสูงตามแนวเส้นทางของ MMS จะทำให้ค่าความถูกต้องลดลง (McCormac et al., 2012) ดังนั้นการประมวลผลภายหลังของข้อมูลเส้นทางจึงเป็นสิ่งสำคัญเพื่อเพิ่มความถูกต้องของข้อมูล MMS

คุณสมบัติเฉพาะของเซ็นเซอร์ต่าง ๆ ที่ประกอบอยู่ในระบบ MMS เป็นอีกองค์ประกอบที่ทำให้ข้อมูลมีความถูกต้องมากยิ่งขึ้น หาก MMS ประกอบด้วยเซ็นเซอร์ที่มีประสิทธิภาพสูง จะทำให้ข้อมูลที่รับจากเซ็นเซอร์นั้น ๆ มีความถูกต้องสูงเช่นเดียวกัน แต่ต้องแลกกับอุปกรณ์ MMS ที่มีราคาที่สูง ในการศึกษาครั้งนี้เลือกใช้อุปกรณ์ MMS จากผู้ผลิต Topcon รุ่น IP-S3 ซึ่งประกอบด้วยเซ็นเซอร์ต่าง ๆ ที่มีคุณสมบัติตามตารางที่ 2-2 (Topcon, 2021)

ตารางที่ 2-2 คุณสมบัติของอุปกรณ์ Topcon IP-S3 HD

GNSS Receiver	
จำนวนช่องสัญญาณ	226 ช่อง
GPS	L1 / L2 carrier, L1P, L2P
GLONASS	L1 / L2 carrier, L1P, L2P
อัตราการส่งข้อมูล	10Hz
ความถูกต้องของการสำรวจรังวัดแบบสถิต	H : $\pm 3.0\text{mm} + 0.5\text{mm}$ / V : $\pm 3.0\text{mm} + 0.5\text{mm}$
ความถูกต้องของการสำรวจรังวัดแบบจลน์	H : $\pm 10\text{mm} + 1\text{mm}$ / V : $\pm 15\text{mm} + 1\text{mm}$
ระบบกันน้ำ	IP67
IMU	
ความเสถียรของ Gyro	1°/hr
ความเสถียรของอัตราเร่ง	7.5 mg
Laser scanner	
ความหนาแน่นจุด	700000 จุด/วินาที
ระยะสแกน	100 เมตร
กันน้ำ	IP67
กล้องถ่ายภาพรอบทิศทาง	
จำนวนกล้องถ่ายภาพ	6 ตัว รอบทิศทาง
ความละเอียดภาพสูงสุด	8000x4000 จุดภาพ
อัตราการบันทึกภาพ	10 เฟรมต่อวินาที

## 2.3 การประเมินความถูกต้องของจุดพิกัดสามมิติ

### 2.3.1 มาตรฐานการทดสอบความถูกต้อง

National Standard for Spatial Data Accuracy (NSSDA) เป็นมาตรฐานที่ใช้ตรวจสอบความถูกต้องของข้อมูลเชิงพื้นที่และข้อมูลเชิงตำแหน่ง เช่น ภาพถ่ายทางอากาศ ภาพถ่ายดาวเทียม การสแกนด้วยเลเซอร์ LiDAR และการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS ใช้วิธีการทางสถิติทดสอบความถูกต้องของข้อมูลเพื่อเป็นมาตรฐานกลางในการประเมินความถูกต้องของข้อมูลเชิงพื้นที่และข้อมูลเชิงตำแหน่ง โดยการกำหนดมาตรฐานความถูกต้องของ NSSDA วิธีการสามารถคำนวณความคลาดเคลื่อนและทดสอบความถูกต้องได้ดังต่อไปนี้ (ASPRS, 2014)

- ค่าความคลาดเคลื่อนเฉลี่ย (Mean Errors) เป็นการเฉลี่ยความคลาดเคลื่อนของชุดข้อมูลในทิศทางเดียวกันเช่น ทาง X, Y หรือ Z ได้จากการรวมความคลาดเคลื่อนทั้งหมดในทิศทางเดียวกัน แล้วหารด้วยจำนวนของข้อมูลที่มีความคลาดเคลื่อนทั้งหมด โดยใช้สูตรคำนวณดังแสดงในสมการที่ (2-2)

$$\bar{x} = \frac{1}{(n)} \sum_{i=1}^n x_i \quad (2-2)$$

เมื่อ

$x_i$  คือ ค่าความคลาดเคลื่อน

$n$  คือ จำนวนจุดตรวจสอบ

$i$  คือ ตัวเลขระหว่าง 1 ถึง  $n$

- ค่าความเบี่ยงเบนมาตรฐานของความคลาดเคลื่อน (Standard Deviation) เป็นการวัดการแพร่กระจายของความคลาดเคลื่อนจากข้อมูลความคลาดเคลื่อนเฉลี่ย เป็นวัดความแม่นยำของข้อมูลมากกว่าความถูกต้องของข้อมูล โดยคำนวณจากสูตรสมการที่ (2-3)

$$S_x = \sqrt{\frac{1}{(n-1)} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2-3)$$

เมื่อ

$x_i$  คือ ค่าความคลาดเคลื่อน

$\bar{x}$  คือ ค่าความคลาดเคลื่อนเฉลี่ย

$n$  คือ จำนวนจุดตรวจสอบ

$i$  คือ ตัวเลขระหว่าง 1 ถึง  $n$

- ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Squares Error) เป็นการหารากที่สองเฉลี่ยของชุดข้อมูลผลต่างของจุดพิกัดที่สำรวจกับจุดพิกัดอ้างอิงที่มีความถูกต้องสูงกว่า โดยคำนวณจากสูตรสมการที่ (2-4)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{i(MMS)} - x_{i(GNSS)})^2} \quad (2-4)$$

เมื่อ

$x_{i(MMS)}$  คือ ค่าพิกัดของจุดสำรวจด้วย MMS

$x_{i(GNSS)}$  คือ ค่าพิกัดของจุดตรวจสอบที่มีความถูกต้องสูงกว่าจาก GNSS วิธี RTK

$n$  คือ จำนวนจุดตรวจสอบ

$i$  คือ ตัวเลขระหว่าง 1 ถึง  $n$

### 2.3.2 ระดับความถูกต้องของจุดพิกัดสามมิติ

ความถูกต้องสามารถแสดงได้ในรูปแบบหนึ่งมิติ สองมิติและสามมิติ แต่การประเมินความถูกต้องของข้อมูลเชิงพื้นที่หรือเชิงตำแหน่ง ส่วนใหญ่จะแสดงในรูปแบบแนวราบ (สองมิติ) และในแนวตั้ง (หนึ่งมิติ) และข้อมูลจุดพิกัดสามมิติจาก MMS สามารถประเมินความถูกต้องได้ในรูปแบบสามมิติ สำหรับข้อมูลจุดพิกัดสามมิติจาก MMS ยังประเมินมาตรฐานของงานโดยอ้างอิงจากความหนาแน่นของจุดต่อตารางเมตร เนื่องจากความต้องการของงานจะพิจารณาจากความถูกต้องเชิงตำแหน่งของจุดและความหนาแน่นของจุด ดังนั้นมาตรฐานเกณฑ์ของงานจะแบ่งชั้นของงานดังแสดงไว้ในตารางที่ 2-3 (Olsen et al., 2013)

ตารางที่ 2-3 แสดงการกำหนดชั้นของงานข้อมูลจุดพิกัดสามมิติจาก MMS

ระดับชั้นความถูกต้อง ของงาน	ความถูกต้องแบบสามมิติที่ระดับ ความเชื่อมั่นร้อยละ 95 (เมตร)	ความหนาแน่นของจำนวนจุด ต่อตารางเมตร
1	$\leq 0.05$	$\geq 100$
2	$\leq 0.20$	$\geq 30$
3	$\leq 1.00$	$\geq 10$

- ความถูกต้องระดับชั้นที่ 1 มีข้อกำหนดให้สำหรับข้อมูลจุดพิกัดสามมิติจาก MMS มีความถูกต้องในรูปแบบสามมิติ 5 เซนติเมตร ที่ระดับความเชื่อมั่นร้อยละ 95 โดยมีความหนาแน่นของจุดไม่น้อยกว่า 100 จุดต่อตารางเมตร

- ความถูกต้องระดับชั้นที่ 2 มีข้อกำหนดให้สำหรับข้อมูลจุดพิกัดสามมิติจาก MMS มีความถูกต้องในรูปแบบสามมิติ 20 เซนติเมตร ที่ระดับความเชื่อมั่นร้อยละ 95 โดยมีความหนาแน่นของจุดไม่น้อยกว่า 30 จุดต่อตารางเมตร

- ความถูกต้องระดับชั้นที่ 3 มีข้อกำหนดให้สำหรับข้อมูลจุดพิกัดสามมิติจาก MMS มีความถูกต้องในรูปแบบสามมิติที่ 1 เมตร ที่ระดับความเชื่อมั่นร้อยละ 95 และความถูกต้องแบบสัมพัทธ์ 30 เซนติเมตร ที่ระดับความเชื่อมั่นร้อยละ 95 โดยมีความหนาแน่นของจุดไม่น้อยกว่า 10 จุดต่อตารางเมตร

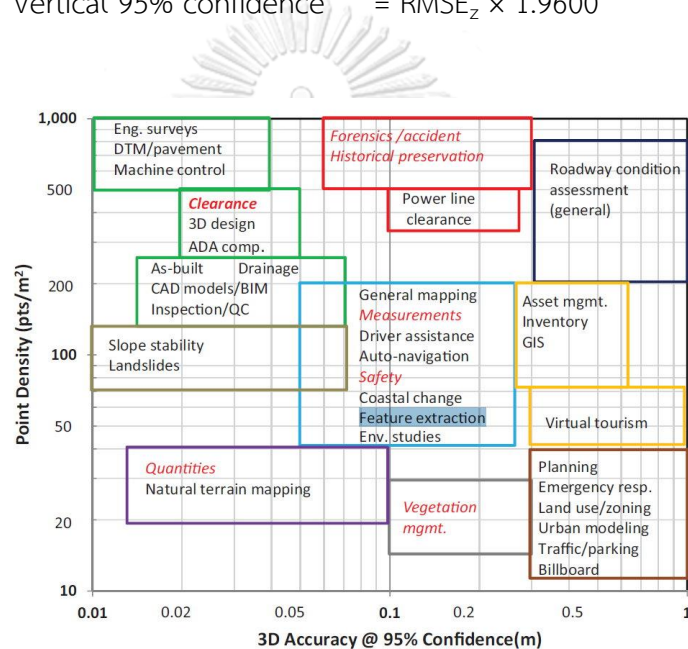
การคำนวณความคลาดเคลื่อนของจุดพิกัดสามมิติ โดยการหาค่าต่างของจุดพิกัดสามมิติกับจุดตรวจสอบความถูกต้อง จากนั้นคำนวณหาราคที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง

(RMSE) อ้างอิงที่ระดับความเชื่อมั่นร้อยละ 95 โดยคำนวณในรูปแบบสามมิติดังสมการที่ (2-5) คำนวณแนวราบแบบสองมิติดังแสดงในสมการที่ (2-6) และคำนวณในแนวตั้งแบบหนึ่งมิติดังแสดงในสมการที่ (2-7) ความถูกต้องเชิงตำแหน่งและความละเอียดเชิงพื้นที่ของจุดพิกัดสามมิติ สามารถนำไปประยุกต์ใช้งานในด้านการขนส่งตามที่ได้มีการแนะนำของ Olsen et al. (2013) ดังแสดงในรูปที่ 2-8

$$3D \text{ 95\% confidence} = 3D \text{ RMSE} \times 1.6166 \quad (2-5)$$

$$\text{Horizontal 95\% confidence} = \text{RMSE}_r \times 1.7308 \quad (2-6)$$

$$\text{Vertical 95\% confidence} = \text{RMSE}_z \times 1.9600 \quad (2-7)$$



รูปที่ 2-8 แสดงการประยุกต์ใช้งานจุดพิกัดสามมิติในงานขนส่งตามเกณฑ์ความถูกต้องและความละเอียดของข้อมูล รูปจาก Olsen et al. (2013)


## 2.4 โครงข่ายประสาทเทียม (Artificial Neural network)

โครงข่ายประสาทเทียม (ANN) เป็นระบบประมวลผลเชิงคำนวณซึ่งได้รับแรงบันดาลใจมาจากวิธีการทำงานของระบบประสาทชีวภาพเช่นสมองของมนุษย์ ANN ส่วนใหญ่ประกอบด้วยจุดการคำนวณที่เชื่อมต่อกันจำนวนมากเรียกว่าเซลล์ประสาทซึ่งทำงานในลักษณะกระจายเพื่อเรียนรู้ร่วมกันจากข้อมูลนำเข้าเพื่อเพิ่มประสิทธิภาพผลลัพธ์สุดท้าย



โครงสร้างพื้นฐานของ ANN สามารถจำลองได้ดังแสดงในรูปที่ 2-9 ข้อมูลนำเข้าโดยปกติจะอยู่ในรูปแบบของเวกเตอร์หลายมิติไปยังชั้นข้อมูลนำเข้า ซึ่งจะกระจายไปยังชั้นข้อมูลที่ซ่อนอยู่ จากนั้นชั้นข้อมูลที่ซ่อนอยู่จะทำการตัดสินใจจากชั้นข้อมูลก่อนหน้าและให้น้ำหนักการเปลี่ยนแปลงสู่ภายในหรือปรับปรุงผลลัพธ์สุดท้าย และสิ่งนี้เรียกว่ากระบวนการเรียนรู้ การมีชั้นข้อมูลที่ซ่อนอยู่หลายชั้นซ้อนกันมักเรียกว่าการเรียนรู้เชิงลึก

กระบวนการเรียนรู้ในงานการประมวลผลภาพมี 2 วิธีคือการเรียนรู้แบบกำกับดูแลและการเรียนรู้แบบไม่กำกับดูแล การเรียนรู้แบบกำกับดูแลคือการเรียนรู้ผ่านการบอกข้อมูลตัวอย่างกำกับไว้ล่วงหน้าซึ่งทำหน้าที่เป็นเป้าหมาย สำหรับแต่ละตัวอย่างการฝึกสอนจะมีชุดของค่านำเข้าและค่าส่งออกที่กำหนดอย่างน้อยหนึ่งค่า เป้าหมายของการฝึกสอนรูปแบบนี้คือการลดข้อผิดพลาดโดยรวมในการจำแนกของโมเดล ผ่านการคำนวณค่าผลลัพธ์ของตัวอย่างการฝึกสอนโดยการฝึกสอนอย่างถูกต้อง



รูปที่ 2-9 ตัวอย่างโครงข่ายประสาทเทียมไปข้างหน้า 3 ชั้นข้อมูล

การเรียนรู้แบบไม่กำกับดูแลแตกต่างกันตรงที่ชุดฝึกสอนจะไม่มี การบอกข้อมูลตัวอย่างความสำเร็จ จะพิจารณาจากโครงข่ายสามารถลดหรือเพิ่มฟังก์ชันต้นทุนที่เกี่ยวข้องได้หรือไม่ อย่างไรก็ตามสิ่งสำคัญคือต้องสังเกตว่างานจดจำรูปแบบที่เน้นรูปภาพ ส่วนใหญ่จะขึ้นอยู่กับการจัดหมวดหมู่โดยใช้การเรียนรู้แบบกำกับดูแล

## 2.5 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Networks)

โครงข่ายประสาทคอนโวลูชัน (CNN) นั้นคล้ายคลึงกับ ANN เนื่องจากประกอบด้วยโครงข่ายประสาทที่ปรับตัวเองให้เหมาะสมผ่านการเรียนรู้ โครงข่ายประสาทจะรับข้อมูลนำเข้าและดำเนินการเช่นข้อมูลขนาดและทิศทางตามด้วยฟังก์ชันที่ไม่ใช่เชิงเส้น ซึ่งเป็นพื้นฐานของ ANN ที่มีจำนวน

นับไม่ถ้วน ตั้งแต่การป้อนข้อมูลภาพไปจนถึงผลลัพธ์สุดท้ายของคะแนนการแบ่งชั้นข้อมูล ทั้งโครงข่ายจะแสดงฟังก์ชันคะแนนการรับรู้เพียงครั้งเดียว ชั้นข้อมูลสุดท้ายจะมีฟังก์ชันการสูญเสียที่เกี่ยวข้องกับชั้นข้อมูล และวิธีการทั่วไปทั้งหมดที่พัฒนาขึ้นสำหรับ ANN ยังคงนำมาประยุกต์ใช้


ความแตกต่างที่เด่นชัดระหว่าง CNN และ ANN คือ CNN จะถูกใช้ในด้านการวิเคราะห์ภาพเป็นหลัก สิ่งนี้ช่วยให้สามารถเข้ารหัสคุณลักษณะเฉพาะของรูปภาพลงในสถาปัตยกรรมได้ ทำให้โครงข่ายเหมาะสำหรับงานที่เน้นภาพมากขึ้น โดยที่ลดพารามิเตอร์ที่จำเป็นในการตั้งค่าโมเดลลง

## 2.6 สถาปัตยกรรมโครงข่ายประสาทคอนโวลูชัน

ดังที่ได้ระบุไว้ก่อนหน้านี้ CNN มุ่งเน้นไปที่ข้อมูลที่ป้อนเข้าประกอบด้วยรูปภาพเป็นหลัก การตั้งค่าสถาปัตยกรรมจะมุ่งเน้นให้เหมาะสมกับความต้องการในการจัดการกับข้อมูลประเภทใดประเภทหนึ่งมากที่สุด ความแตกต่างที่สำคัญประการหนึ่งคือโครงข่ายประสาทที่ชั้นต่าง ๆ ภายใน CNN ประกอบด้วยโครงข่ายประสาทที่เป็นสามมิติเชิงพื้นที่ของข้อมูลนำเข้า มีความสูง ความกว้าง และความลึก ส่วนความลึกไม่ใช่ทั้งหมดของจำนวนชั้นข้อมูลภายใน ANN แต่เป็นสามมิติของปริมาณการใช้งาน ซึ่งแตกต่างจากมาตรฐานของ ANN โครงข่ายประสาทภายในชั้นใด ๆ จะเชื่อมต่อกับส่วนเล็ก ๆ ของชั้นที่อยู่ข้างหน้าเท่านั้น

ในทางปฏิบัติความหมายสำหรับตัวอย่างที่ระบุไว้ก่อนหน้านี้นำเข้าข้อมูลที่เป็นปริมาตรที่มีขนาด  $64 \times 64 \times 3$  (ความสูง ความกว้างและความลึก) ซึ่งนำไปสู่ผลลัพธ์สุดท้ายของชั้นข้อมูลที่ประกอบด้วยมิติข้อมูล  $1 \times 1 \times n$  โดยที่  $n$  หมายถึงจำนวนชั้นความหมายที่เป็นไปได้ เนื่องจากการจะย่อมิติข้อมูลนำเข้าแบบเต็มให้เป็นคะแนนชั้นความหมายที่มีขนาดเล็กลงในมิติที่ลึก

CNN ประกอบด้วยชั้นข้อมูล 3 ประเภท คือชั้นคอนโวลูชัน ชั้นพูลลิงและชั้นเชื่อมโยงเต็มรูปแบบ และเมื่อนำชั้นข้อมูลมาซ้อนกับสถาปัตยกรรม CNN จะแสดงไว้ในรูปที่ 2-10



รูปที่ 2-10 แสดงตัวอย่างสถาปัตยกรรม CNN รูปจาก O'Shea and Nash (2015)


ฟังก์ชันพื้นฐานของ CNN ตัวอย่างข้างต้นสามารถแบ่งออกได้เป็น 4 ส่วนหลัก ๆ

- 1) ดังที่พบในโครงข่ายประสาทเทียมรูปแบบอื่น ๆ ชั้นข้อมูลนำเข้าจะเก็บค่าจุดภาพของรูปภาพ
- 2) ชั้นคอนโวลูชันจะกำหนดข้อมูลนำเข้าของโครงข่ายประสาทที่เชื่อมต่อกับข้อมูลที่นำเข้าผ่านการคำนวณข้อมูลขนาดทิศทางระหว่างค่าน้ำหนักและพื้นที่ที่เชื่อมต่อไปยังการนำเข้าข้อมูลปริมาตร หน่วยเชิงเส้นที่แก้ไขแล้วโดยทั่วไปเรียกว่า ReLu มีจุดมุ่งหมายเพื่อใช้ฟังก์ชันการกระตุ้น "elementwise" เช่น sigmoid กับข้อมูลนำเข้าจากการกระตุ้นที่สร้างโดยชั้นข้อมูลก่อนหน้า
- 3) ชั้นพูลลิงจะทำการสุ่มตัวอย่างตามมิติเชิงพื้นที่ของข้อมูลนำเข้าที่กำหนดซึ่งจะช่วยลดจำนวนพารามิเตอร์การกระตุ้นนั้น
- 4) ชั้นเชื่อมโยงเต็มรูปแบบจะทำหน้าที่เดียวกันกับที่พบในมาตรฐานของโครงข่ายประสาทเทียม และได้สร้างคะแนนชั้นความหมายจากการกระตุ้นเพื่อใช้ในการจำแนกประเภท นอกจากนี้ยังแนะนำให้ใช้ ReLu ระหว่างชั้นข้อมูลเหล่านี้เพื่อปรับปรุงประสิทธิภาพ

CNN สามารถเปลี่ยนชั้นนำเข้าข้อมูลทีละชั้นโดยใช้เทคนิคการสุ่มตัวอย่าง และการสุ่มตัวอย่างนั้นเพื่อสร้างคะแนนชั้นฝึกสอนสำหรับการจำแนกประเภทและการย้อนกลับ อย่างไรก็ตามสิ่งสำคัญคือการทำความเข้าใจสถาปัตยกรรมโดยรวมของโครงข่ายประสาทไม่เพียงพอ การสร้างและเพิ่มประสิทธิภาพของโมเดลเหล่านี้อาจใช้เวลาพอสมควรและอาจทำให้เกิดความสับสนได้

#### 2.6.1 ชั้นคอนโวลูชัน

การนำเข้าข้อมูลขนาดและทิศทางจะถูกคำนวณสำหรับแต่ละค่าในคอนเนลล์นั้นดังแสดงในรูปที่ 2-11 จากนั้นโครงข่ายจะเรียนรู้คอนเนลล์เมื่อเห็นคุณลักษณะเฉพาะที่ตำแหน่งเชิงพื้นที่ที่กำหนดของข้อมูลนำเข้า สิ่งเหล่านี้เรียกกันทั่วไปว่าการกระตุ้น ดังที่ได้กล่าวถึงก่อนหน้าการฝึกสอนโครงข่ายประสาทเทียมนำเข้าข้อมูลรูปภาพส่งผลให้โมเดลมีขนาดใหญ่เกินกว่าจะฝึกสอนได้อย่างมีประสิทธิภาพ เมื่อลองไปสู่ชั้นเชื่อมโยงเต็มรูปแบบในชั้นประสาทของมาตรฐานโครงข่ายประสาทเทียม ดังนั้นเพื่อหลีกเลี่ยงสิ่งนี้ทุกชั้นประสาทในชั้นคอนโวลูชันจึงเชื่อมต่อกับพื้นที่เล็ก ๆ ของปริมาณนำเข้าข้อมูล ขนาดของพื้นที่นี้เรียกกันโดยทั่วไปว่าขนาดพื้นที่รับของชั้นประสาท ขนาดของการเชื่อมต่อผ่านความลึกใกล้เคียงกับความลึกของข้อมูลนำเข้า



รูปที่ 2-11 แสดงภาพของชั้นคอนโวลูชัน รูปจาก O'Shea and Nash (2015)

ตัวอย่างหากนำเข้าข้อมูลไปยังโครงข่ายเป็นภาพขนาด  $64 \times 64 \times 3$  ภาพสี RGB ที่มีขนาด  $64 \times 64$  และตั้งค่าขนาดพื้นที่เปิดรับเป็น  $6 \times 6$  จะมีทั้งหมด 108 ค่าน้ำหนักของชั้นประสาท แต่ละชั้นภายในชั้นคอนโวลูชัน  $6 \times 6 \times 3$  โดยที่ 3 คือขนาดของการเชื่อมต่อในระดับความลึกของปริมาตร เพื่อให้มองเห็นได้ชั้นประสาท มาตรฐานรูปแบบอื่น ๆ ของโครงข่ายประสาทเทียม จะมี 12,288 ค่าน้ำหนัก (O'Shea and Nash, 2015)

ชั้นคอนโวลูชันยังสามารถลดความซับซ้อนของโมเดลได้มาก ผ่านการเพิ่มประสิทธิภาพของข้อมูลนำออก สิ่งนี้ได้รับการปรับให้มีความเหมาะสมโดยใช้ค่าพารามิเตอร์สามตัวคือ ความลึก การก้าวข้ามและการปรับขนาดข้อมูลนำเข้าเป็นศูนย์

ความลึกของปริมาณข้อมูลส่งออกที่สร้างโดยชั้นคอนโวลูชันสามารถกำหนดได้ด้วยตนเองผ่านจำนวนชั้นประสาทภายในพื้นที่เดียวกันของข้อมูลนำเข้า สิ่งนี้สามารถเห็นได้จากโครงข่ายประสาทเทียมในรูปแบบอื่น ๆ ซึ่งชั้นประสาททั้งหมดในชั้นที่ซ่อนอยู่จะเชื่อมต่อโดยตรงกับเซลล์ประสาททุกเซลล์ก่อนหน้านี้ การลดไฮเปอร์พารามิเตอร์นี้สามารถลดจำนวนเซลล์ประสาททั้งหมดของโครงข่ายได้มาก แต่ก็ลดความสามารถในการจดจำรูปแบบของโมเดลเช่นกัน

นอกจากนี้ยังสามารถกำหนดการก้าวข้าม ตั้งค่าความลึกรอบมิติเชิงพื้นที่ของข้อมูลเข้า เพื่อวางชั้นข้อมูลที่เปิดรับ ตัวอย่างเช่นถ้ากำหนดการก้าวข้ามเป็น 1 เราจะมีช่องรับสัญญาณที่ซ้อนทับกันมากทำให้เกิดการรับพื้นที่ขนาดใหญ่ หรืออีกวิธีคือการตั้งค่าการก้าวข้ามที่มากขึ้นจะช่วยลดจำนวนของการทับซ้อนและสร้างผลลัพธ์ของมิติเชิงพื้นที่ที่น้อยลง

การเพิ่มเติมค่าศูนย์เป็นกระบวนการที่เพิ่มขอบของข้อมูลนำเข้าและเป็นวิธีที่มีประสิทธิภาพในการควบคุมเพิ่มเติมเกี่ยวกับขนาดของมิติของข้อมูลนำออก สิ่งสำคัญคือเทคนิคเหล่านี้

จะเปลี่ยนมิติขนาดข้อมูลเชิงพื้นที่ของข้อมูลนำออกชั้นคอนโวลูชัน การคำนวณสามารถใช้สูตร ดังสมการที่ 2-9

$$\frac{(V-R)+2Z}{S+1} \quad (2-8)$$

โดยที่  $V$  แทนขนาดปริมาตรคือ ความกว้าง ความสูงและความลึก  $R$  หมายถึงขนาดพื้นที่รับได้  $Z$  คือจำนวนของชุดช่องว่างที่เป็นศูนย์และ  $S$  หมายถึงการก้าวข้าม หากผลลัพธ์ที่คำนวณได้จากสมการนี้ไม่เท่ากับจำนวนเต็มทั้งหมดแสดงว่าการก้าวข้ามนั้นถูกตั้งค่าไม่ถูกต้องเนื่องจากเซลล์ประสาทจะไม่สามารถปรับให้พอดีกับข้อมูลนำเข้าที่กำหนดได้

ถึงแม้ว่ามีการพยายามที่จะทำให้พื้นที่เล็กลง แต่ยังพบว่าแบบจำลองยังคงมีขนาดใหญ่ หากใช้การนำเข้าข้อมูลรูปภาพ อย่างไรก็ตามมีการพัฒนาวิธีการเพื่อลดจำนวนพารามิเตอร์โดยรวมภายในชั้นคอนโวลูชัน

การใช้พารามิเตอร์ร่วมกันในการทำงานบนสมมติฐานที่ว่าหากคุณลักษณะของพื้นที่มีประโยชน์ในการคำนวณข้อมูลเชิงพื้นที่ที่กำหนดไว้ หากจำกัดแผนผังการเปิดใช้งานแต่ละรายการภายในปริมาณข้อมูลนำเข้า ให้ค่าน้ำหนักและความเอนเอียงเท่ากัน จะเห็นการลดจำนวนพารามิเตอร์ที่สร้างโดยชั้นคอนโวลูชันลง

ด้วยเหตุนี้เมื่อเกิดการกระจายย้อนกลับเซลล์ประสาทแต่ละตัวในข้อมูลนำออก จะแสดงถึงการไล่ระดับสีโดยรวมซึ่งสามารถหาค่าได้ทั้งหมดในระดับความลึก ดังนั้นจึงปรับปรุงชุดน้ำหนักเพียงชุดเดียวเมื่อเทียบกับทุกชุด

### 2.6.2 ชั้นพูลลิง (Pooling layer)

ชั้นพูลลิงมีเป้าหมายเพื่อลดขนาดของการแสดงผลและลดจำนวนพารามิเตอร์และความซับซ้อนในการคำนวณของโมเดล ชั้นพูลลิงทำงานบนแผนที่การเปิดใช้งานแต่ละรายการในข้อมูลนำเข้าและปรับขนาดมิติข้อมูลโดยใช้ฟังก์ชัน MAX ในโครงข่ายคอนโวลูชัน ส่วนใหญ่จะอยู่ในรูปแบบของชั้นพูลลิงสูงสุดที่มีการใช้เคอเนลที่มีมิติเป็น  $2 \times 2$  โดยการใช้การก้าวข้าม 2 ตามมิติของข้อมูลเชิงพื้นที่นำเข้า สิ่งนี้จะปรับขนาดแผนที่การเปิดใช้งานลงเหลือ 25% ของขนาดดั้งเดิม ในขณะที่ยังคงรักษาระดับความลึกให้เป็นขนาดมาตรฐาน

เนื่องจากลักษณะของชั้นพูลลิงมีสองวิธีที่พบโดยทั่วไปในการทำ max-pooling โดยปกติแล้วการก้าวข้ามและตัวกรองของชั้นพูลลิงจะถูกตั้งค่าเป็น  $2 \times 2$  (O'Shea and Nash, 2015) ซึ่งจะช่วยให้ชั้นข้อมูลสามารถขยายได้ตลอดในมิติข้อมูลเชิงพื้นที่ของข้อมูลนำเข้า นอกจากนี้อาจใช้การพูลลิงที่ทับซ้อนกันโดยที่การก้าวข้ามถูกตั้งค่าเป็น 2 โดยกำหนดขนาดเคเนลเป็น 3 เนื่องจากลักษณะการดำเนินการของการพูลลิงมีขนาดเคเนลที่สูงกว่า 3 มักจะลดประสิทธิภาพของโมเดลลง

สิ่งสำคัญคือต้องเข้าใจว่านอกเหนือจากการ max-pooling แล้วสถาปัตยกรรม CNN อาจมีการ General-pooling และ average-pooling อย่างไรก็ตามการฝึกสอนจะเน้นไปที่การใช้ max-pooling เป็นหลัก

### 2.6.3 ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully connected layer)

ชั้นการเชื่อมโยงเต็มรูปแบบประกอบด้วยเซลล์ประสาทที่เชื่อมต่อโดยตรงกับเซลล์ประสาทในสองชั้นที่อยู่ติดกันโดยไม่ได้เชื่อมต่อกับชั้นใด ๆ ภายในเซลล์เหล่านี้ คล้ายกับวิธีการจัดเรียงเซลล์ประสาทในรูปแบบดั้งเดิมของโครงข่ายประสาทเทียมดังแสดงในรูปที่ 2-9

## 2.7 การวัดประสิทธิภาพ

### 2.7.1 เมทริกซ์ความคลาดเคลื่อน (Confusion Matrix)

การจำแนกวัตถุจะแสดงผลลัพธ์อยู่ในรูปแบบเมทริกซ์ค่าความคลาดเคลื่อน (Confusion Matrix) ความถูกต้องของการจำแนกตรวจสอบโดยการเปรียบเทียบข้อมูลระหว่างผลการจำแนกกับข้อมูลอ้างอิง เมทริกซ์ค่าความคลาดเคลื่อนเป็นตารางสำคัญในการวัดความสามารถของ Machine learning ในการจำแนกข้อมูลดังแสดงในตารางที่ 2-4

ตารางที่ 2-4 แสดงตารางเมทริกซ์ค่าความคลาดเคลื่อน (Confusion Matrix)

		ชั้นข้อมูลอ้างอิง				
		Class 1	Class 2	Class 3	Class $k$	$n_{i+}$
ชั้นข้อมูลที่จำแนก	Class 1	$n_{11}$	$n_{12}$	$n_{13}$	$n_{1k}$	$n_{1+}$
	Class 2	$n_{21}$	$n_{22}$	$n_{23}$	$n_{2k}$	$n_{2+}$
	Class 3	$n_{31}$	$n_{32}$	$n_{33}$	$n_{3k}$	$n_{3+}$
	Class $k$	$n_{k1}$	$n_{k2}$	$n_{k3}$	$n_{kk}$	$n_{k+}$
	$n_{+i}$	$n_{+1}$	$n_{+2}$	$n_{+3}$	$n_{+k}$	$n$

เมื่อ	$k$	คือ จำนวนชั้นของการจำแนก
	$n_{kk}$	คือ จำนวนจุดที่จำแนกตรงกับชั้นข้อมูลอ้างอิง
	$n_{+i}$	คือ จำนวนจุดทั้งหมดของข้อมูลอ้างอิงในชั้นข้อมูลที่ $i$
	$n_{i+}$	คือ จำนวนจุดทั้งหมดที่จำแนกเป็นชั้นข้อมูล $i$
	$n$	คือ จำนวนจุดทั้งหมด

### 2.7.2 ความถูกต้องโดยรวม (Overall accuracy)

เป็นการประเมินความถูกต้องของการจำแนกประเภท ซึ่งจะทำการวิเคราะห์ในตารางเมทริกซ์ความคลาดเคลื่อน โดยใช้เทคนิคทางสถิติช่วยในการคำนวณ ความถูกต้องโดยรวมคำนวณได้โดยนำค่าผลรวมในแนวทแยงหลักหารด้วยจำนวนจุดข้อมูลทั้งหมดที่ใช้ในการอ้างอิงในตารางเมทริกซ์ความคลาดเคลื่อนดังสมการที่ 2-9

$$\text{Overall Accuracy} = \frac{\sum_{i=1}^k n_{ii}}{n} \times 100 \quad (2-9)$$

### 2.7.3 ความถูกต้องของผู้ใช้ (User's Accuracy)

ความถูกต้องของผู้ใช้คือความน่าจะเป็นที่การจำแนกได้ผลลัพธ์ถูกต้องตรงกับข้อมูลอ้างอิง โดยคำนวณจากผลการจำแนกข้อมูลในชั้นนั้น ๆ ตรงกับข้อมูลอ้างอิงหารด้วยผลลัพธ์ที่จำแนกเป็นคลาสนั้น ๆ ทั้งหมด ดังสมการที่ 2-10

$$\text{User's Accuracy} = \frac{n_{ii}}{n_{i+}} \times 100 \quad (2-10)$$

### 2.7.4 ความถูกต้องของผู้ผลิต (Producer's Accuracy)

ความถูกต้องของผู้ผลิตคือค่าความน่าจะเป็นของชั้นข้อมูลอ้างอิง ได้ถูกจัดอยู่ในชั้นนั้นอย่างถูกต้อง โดยคำนวณจากผลการจำแนกข้อมูลจุดในคลาสนั้น ๆ ตรงกับข้อมูลอ้างอิงหารด้วยจำนวนจุดอ้างอิงทั้งหมดในชั้นการจำแนกนั้นตามสมการที่ 2-11

$$\text{Producer's Accuracy} = \frac{n_{ii}}{n_{+i}} \times 100 \quad (2-11)$$

### 2.7.5 ค่าอัตราส่วนการซ้อนทับ Intersection over Union (IoU)

ค่า IoU เป็นการวัดประสิทธิภาพของตัวโมเดลในการจำแนกจุดพิกัดสามมิติ เป็นการหาสัดส่วนจุดพิกัดสามมิติที่ได้จากการจำแนกด้วยโมเดลกับจุดพิกัดสามมิติที่เป็นข้อมูลอ้างอิง สำหรับค่า IoU สามารถเขียนดังสมการที่ 2-12

$$IoU = \frac{A \cap B}{A \cup B} \quad (2-12)$$

เมื่อ A คือ จุดที่ถูกจำแนกเป็นชั้นข้อมูลนั้น ๆ

B คือ จุดที่อ้างอิงเป็นชั้นข้อมูลนั้น ๆ

### 2.7.6 ค่าฟังก์ชันความสูญเสีย (Loss Function)

เป็นค่าชี้วัดที่เป็นตัวเลขค่าเดียว สามารถบ่งบอกประสิทธิภาพของโมเดลที่ได้จากการสอนโครงข่าย โดยการคำนวณ Loss Function เป็นการคำนวณความผิดพลาดถ้าหากค่า Loss = 0 แสดงว่าโมเดลไม่มีความผิดพลาด

### 2.7.7 ค่าสถิติแค็ปปา (Kappa Statistics)

ค่าสถิติแค็ปปาเป็นการประเมินความถูกต้องโดยการพิจารณาความสอดคล้องระหว่างข้อมูลที่จำแนกกับข้อมูลอ้างอิง ถ้าหากค่าทั้งสองมีความสอดคล้องกันสูงแสดงว่าผลการจำแนกนั้นออกมาดี และในบางครั้งวิธีนี้อาจใช้ในการเปรียบเทียบความสอดคล้องกันของผลการจำแนกข้อมูลเดียวกันจากการจำแนกคนละวิธี ดังแสดงในสมการที่ 2-13

$$\hat{\kappa} = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (2-13)$$

### 2.7.8 การทดสอบทางสถิติ Z

การทดสอบทางสถิติ Z จะแบ่งออกเป็นสองส่วนคือการทดสอบความแตกต่างของผลการฝึกสอนและการทดสอบของวิธีไม่มีค่า RGB กับมีค่า RGB จะใช้การทดสอบค่า z test two sample for means ดังแสดงในสูตรสมการที่ 2-14 จากผลฝึกสอน 300 รอบของแต่ละวิธี เพื่อทดสอบความแตกต่างของผลการฝึกสอนและการทดสอบ แต่ถ้าหากวิเคราะห์การจำแนกด้วยวิธีที่แตกต่างกัน ด้วยวิธีการเปรียบเทียบความถูกต้องของเมทริกซ์ความคลาดเคลื่อนของผลการจำแนกเพื่อวิเคราะห์ความแตกต่างของทั้ง 2 วิธี ใช้การนำค่าสัมประสิทธิ์แค็ปปามาทดสอบค่าสถิติ Z (Congalton and Green, 2019) ดังสมการที่ 2-15 ค่าสถิติ Z มีสมมติฐานหลักคือ ค่า  $H_0 : (K_1 - K_2) = 0$  คือผลการจำแนกไม่แตกต่างกัน และสมมติฐานรอง  $H_1 : (K_1 - K_2) \neq 0$  คือผลการจำแนกมีความแตกต่างกัน ดังนั้น  $H_0$  จะถูกปฏิเสธเมื่อ  $Z \geq Z_{\alpha/2}$  ที่ระดับความเชื่อมั่นร้อยละ 95 ค่าวิกฤตเท่ากับ 1.96 สำหรับการทดสอบค่า Z อยู่นอกช่วงค่าวิกฤตแบบสองทิศทางคือ -1.96 ถึง 1.96 หมายความว่าผลลัพธ์มีความแตกต่างอย่างมีนัยสำคัญที่ระดับความเชื่อมั่นร้อยละ 95



$$Z = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{\sigma_1^2}{N_1} + \frac{\sigma_2^2}{N_2}}} \quad (2-14)$$

เมื่อ  $\bar{x}$  คือ ค่าเฉลี่ยของกลุ่มตัวอย่าง

$\sigma$  คือ ความเบี่ยงเบนมาตรฐานของกลุ่มตัวอย่าง

$N$  คือ จำนวนกลุ่มตัวอย่าง

$$Z = \frac{|K_1 - K_2|}{\sqrt{\text{var}(K_1) + \text{var}(K_2)}} \quad (2-15)$$

เมื่อ  $K_1, K_2$  คือ ค่าประมาณค่าของเมทริกซ์ค่าความคลาดเคลื่อน 1 และ 2

$\text{var}(K_1) + \text{var}(K_2)$  คือ ค่าประมาณความแปรปรวนของค่าประมาณ

## 2.8 โครงข่ายประสาทคอนโวลูชันจำแนกจุดพิกัดสามมิติ


สถาปัตยกรรมโครงข่ายประสาทคอนโวลูชันโดยทั่วไปนิยมใช้ข้อมูลนำเข้าในลักษณะรูปแบบ Voxel หรือ Pixel แต่เนื่องจากจุดพิกัดสามมิติไม่ได้อยู่ในรูปแบบปกติ นักวิจัยส่วนใหญ่จะแปลงข้อมูลจุดพิกัดสามมิติไปเป็น Voxel หรือ Pixel (Jing and Suya, 2016; L. Zhang et al., 2018) ก่อนนำข้อมูลเข้าสู่การประมวลผลใน CNN การแปลงข้อมูลทำให้เกิดข้อมูลที่ไม่จำเป็นและบางครั้งไปลดทอนคุณภาพของข้อมูลจุดพิกัดสามมิติ ดังนั้นการจำแนกจุดพิกัดสามมิติได้โดยตรงจะลดขั้นตอนการแปลงข้อมูลที่ทำให้เสียคุณลักษณะเฉพาะและรายละเอียดต่าง ๆ ของจุดพิกัดสามมิติ ยิ่งไปกว่านั้น หากต้องการใช้ค่า RGB ในการจำแนกข้อมูลร่วมกับพิกัด XYZ การแปลงข้อมูลต้องเลือกใช้อย่างใดอย่างหนึ่งเท่านั้นทำให้ไม่ได้ใช้ประโยชน์จากข้อมูลจุดพิกัดสามมิติได้อย่างมีประสิทธิภาพ

สถาปัตยกรรม CNN ที่ใช้จำแนกจุดพิกัดสามมิติมีการพัฒนาขึ้นมามากมายเช่น สถาปัตยกรรม 3D CNN (Jing and Suya, 2016) เป็นสถาปัตยกรรมที่สามารถจำแนกข้อมูลจุดพิกัดสามมิติได้ แต่ต้องแปลงข้อมูลไปเป็น Voxel ก่อน เพื่อนำข้อมูลเข้าสู่โครงข่าย ซึ่งทำให้ข้อมูลมีขนาดใหญ่ขึ้นและที่สำคัญเทคนิคนี้จะเน้นการจำแนกข้อมูลจากรูปทรงสามมิติของ Voxel ไม่สามารถปรับใช้ข้อมูล RGB ได้ และในงานวิจัยของ L. Zhang et al. (2018) ได้ใช้วิธีการ Multi-View Convolutional Neural Network เพื่อจำแนกจุดพิกัดสามมิติ ด้วยการจับภาพจุดพิกัดสามมิติในหลายมุมมองเข้าสู่กระบวนการ Convolutional และจำแนกข้อมูลด้วย Neural Network ซึ่งเป็นเทคนิคที่ประยุกต์โดยการแปลงข้อมูลจุดพิกัดสามมิติเป็น 2 มิติ และในส่วนของสถาปัตยกรรม PointNet เป็น

สถาปัตยกรรมที่พัฒนาให้สามารถจำแนกจุดพิกัดสามมิติได้โดยตรง (C. Qi et al., 2017) และมีการปรับปรุงเป็น PointNet++ ที่มีการจำแนกจุดพิกัดสามมิติได้ดียิ่งขึ้น (C. R. Qi et al., 2017) ซึ่งในงานวิจัยนี้เลือกใช้สถาปัตยกรรม PointNet++ ในการนำมาจำแนกถนนและหลุมบ่อเนื่องจากสามารถจำแนกจุดพิกัดสามมิติได้โดยตรงและสามารถปรับปรุงเพิ่มค่า RGB เพื่อช่วยเพิ่มชุดข้อมูลให้โครงข่ายได้เรียนรู้ในการจำแนกเพิ่มขึ้น

PointNet เป็นสถาปัตยกรรมจาก CNN ที่สามารถจำแนกข้อมูลจุดพิกัดสามมิติได้โดยตรง (C. Qi et al., 2017) ได้พัฒนามาในปี 2017 และเป็นสถาปัตยกรรมพื้นฐานให้มีการพัฒนาสถาปัตยกรรมใหม่ ๆ ตามมาอีกมากมาย สถาปัตยกรรม PointNet ดังแสดงในรูปที่ 2-12 การนำเข้าข้อมูลไปยัง PointNet คือจุดพิกัดสามมิติโดยตรง  $P = R^{N \times D}$  โดยที่ N คือจำนวนของจุดพิกัดสามมิติ และ D คือมิติของข้อมูลโดยปกติ  $D = 3$  คือค่า XYZ ของแต่ละจุด แต่อย่างไรก็ตามสถาปัตยกรรมสามารถเพิ่มมิติของค่า D ได้ ซึ่งในงานวิจัยนี้ได้เพิ่มมิติของข้อมูล RGB จากข้อมูลนำเข้าไปเพื่อเพิ่มความลึกในการฝึกสอนโครงข่าย PointNet จะสร้างฟังก์ชันสมมาตรพื้นฐานขึ้นมา 2 ฟังก์ชันคือ Multi-Layer Perceptron (MLP) และ Max-Pooling Function ในส่วนของ MLP คือการแปลคุณลักษณะมิติของข้อมูลจุดจาก  $D = 3$  ไปยัง  $D = 1024$  มิติ และมีพารามิเตอร์ที่ใช้ร่วมกันทุกจุดในแต่ละชั้น ในการรวมคุณลักษณะทั้งหมด Max-Pooling Function จะถูกใช้เพื่อสร้างเวกเตอร์ 1024 มิติของคุณลักษณะทั้งหมด เวกเตอร์จะบ่งชี้การนำเข้าไปสำหรับการจัดจำและแบ่งความหมาย

โดยพื้นฐานแล้วเนื่องจากคุณลักษณะทั้งหมดของจุดพิกัดสามมิติจะไม่จัดเรียงเป็นระเบียบ การสร้างแบบจำลองเฉพาะส่วนจะขึ้นอยู่กับการทำ Sampling, Grouping และ Mapping Function มักจะถูกประมาณค่าโดย MLP จุดที่ใกล้เคียงที่สุดกับคุณลักษณะใดจะแสดงข้อมูลในระดับที่สูงขึ้น



รูปที่ 2-12 แสดงสถาปัตยกรรม PointNet รูปจาก C. Qi et al. (2017)


การสุ่มตัวอย่าง (Sampling) คือการลดความละเอียดของจุดที่ก้าวข้ามชั้นของความหมาย เหมือนกับหลักการทำงานของการลดความละเอียดของแผนที่ภาพถ่ายผ่านชั้นคอนโวลูชันและชั้นพูลลิง ให้จุดพิกัดสามมิติ  $P \in R^{N \times 3}$  ของจำนวน  $N$  จุดลดความละเอียดไปยัง  $M$  จุด  $P \in R^{M \times 3}$  เมื่อ  $M \leq N$  จุดสุ่มตัวอย่างย่อย  $M$  จะอ้างถึงจุดตัวแทนหรือศูนย์กลางใช้สำหรับบอกคุณลักษณะเฉพาะ ส่วนของพื้นที่ของข้อมูลที่ถูกสุ่มออกมา การสุ่มตัวอย่างจะนิยมใช้อยู่ 2 วิธี 1) การสุ่มตัวอย่างแบบสุ่ม โดยที่  $N$  จุด จะมีโอกาสถูกสุ่มเท่า ๆ กัน 2) การสุ่มตัวอย่างจากจุดที่ไกลที่สุด Farthest Point Sampling (FPS) โดยที่จุด  $M$  จุดจะถูกสุ่มจากจุดที่ไกลที่สุดจากส่วนที่เหลือของ  $M - 1$  จุด ส่วนวิธีการสุ่มตัวอย่างอื่น ๆ ได้แก่ การสุ่มตัวอย่างแบบสม่ำเสมอและการสุ่มตัวอย่างย่อยของ Gumbel

การจัดกลุ่มตัวอย่าง (Grouping) ทำหลังจากได้สุ่มตัวอย่างจุดโดยการใช้อัลกอริทึม k-Nearest Neighbor (kNN) เพื่อเลือกจุดบริเวณโดยรอบที่ใกล้ที่สุด เป็นกลุ่มจุดที่เป็นส่วนของลักษณะเฉพาะส่วน จุดในส่วนนี้จะใช้คำนวณหาคุณลักษณะเฉพาะส่วนในพื้นที่ใกล้เคียง ในตารางคอนโวลูชันจะรับชั้นข้อมูลที่เป็นจุดภาพของข้อมูลแผนที่ภายใต้เคอเนล ในส่วนของ kNN ใช้ข้อมูลโดยตรงสุ่มตัวอย่างจุด  $k$  ที่ใกล้ที่สุดไปยังจุดศูนย์กลางหรือจะใช้ ball query เลือกเฉพาะจุดที่อยู่ในระยะรัศมีของจุดศูนย์กลาง

ฟังก์ชันแผนที่แบบไม่เชิงเส้น เมื่อได้จุดที่ใกล้ที่สุดไปยังจุดตัวแทนของแต่ละจุดแล้ว ขั้นตอนต่อไปคือการทำแผนที่ไปยังเวกเตอร์คุณลักษณะซึ่งแสดงถึงโครงสร้างลักษณะเฉพาะส่วน ในข้อมูลตารางคอนโวลูชัน จะรับชั้นแผนที่ไปยังลักษณะประสาทโดยใช้เมทริกซ์ตัวคูณอย่างง่ายและการรวมกับเคอเนลคอนโวลูชัน วิธีการนี้เป็นสิ่งที่ทำได้ยากเนื่องจากจุดพิกัดสามมิติไม่มีโครงสร้าง ดังนั้นส่วนใหญ่จะใช้วิธีประมาณค่าของฟังก์ชันตามสถาปัตยกรรม PointNet ซึ่งประกอบด้วยเพอเซปตรอนหลายชั้น

PointNet ได้ถูกพัฒนาสถาปัตยกรรมเป็น PointNet++ ดังแสดงในรูปที่ 2-13 ซึ่งเป็นโครงข่ายประสาทเทียมแบบลำดับชั้น คุณลักษณะที่แตกต่างกันจะถูกจัดเรียงต่อกันเป็นหลายขนาด ข้อมูล โดยมีชั้นข้อมูลหลัก 3 ชั้นคือ Sampling layer, Grouping layer และ PointNet layer โดย Sampling layer จะสุ่มตัวอย่างจุดที่ไกลที่สุด โดยเลือกจากชุดข้อมูลจุดที่นำเข้ามาและหาจุดศูนย์กลางของชุดข้อมูล จากนั้นชุดข้อมูลที่ถูกสร้างขึ้นจะถูกจัดกลุ่มในชั้น Grouping layer โดยค้นหาจุดจากพื้นที่บริเวณใกล้เคียงกับจุดศูนย์กลาง หลังจากนั้นในชั้นของ PointNet layer จะแยกชุด

ข้อมูลของจุดให้อยู่ในระดับชั้น (C. R. Qi et al., 2017) PointNet++ มีความสามารถในการจำแนกวัตถุที่มีคุณลักษณะเฉพาะส่วนได้ดี ซึ่งมีความเหมาะสมกับการจำแนกถนนและหลุมบ่อจากจุดพิกัดสามมิติ



รูปที่ 2-13 แสดงสถาปัตยกรรมของ PointNet++ รูปจาก C. R. Qi et al. (2017)

## 2.9 งานวิจัยที่เกี่ยวข้อง

การสำรวจแบบอัตโนมัติเพื่อตรวจหาการชำรุดเสียหายของถนนโดยเฉพาะความเสียหายประเภทหลุมบ่อนิยมใช้ภาพถ่ายจากกล้องที่ติดตั้งบนยานพาหนะเก็บข้อมูลเพื่อนำมาจำแนกและตรวจหาหลุมบ่อบนผิวทางและมีการพัฒนาอัลกอริทึมต่าง ๆ เพื่อใช้จำแนกและตรวจหาหลุมบ่อแบบอัตโนมัติ ในงานวิจัยของ Djameluddin et al. (2017) ได้ตรวจหาหลุมบ่อแบบอัตโนมัติจากภาพถ่าย โดยมีกล้องและโปรแกรมคอมพิวเตอร์ที่ใช้ OpenCV โดยกำหนดใช้พารามิเตอร์หลายตัว เช่น รูปร่าง รวมถึงความกลม ความนูน และค่าความเฉื่อยถูกนำมาใช้เพื่อเพิ่มประสิทธิภาพการตรวจจับหลุมบ่อ รูปภาพที่ได้รับการทดสอบบนถนนจริงมีรูปร่างและขนาดหลุมที่แตกต่างกันและผลมีความแม่นยำร้อยละ 82.5

ในงานวิจัยของ P. Wang et al. (2017) ได้ตรวจหาหลุมบ่อจากภาพถ่ายโดยใช้ Wavelet Energy Field Model ดำเนินการทดสอบบนภาพถ่ายถนน 120 ภาพ ผลทดสอบแสดงให้เห็นว่าสามารถจำแนกหลุมบ่อจากรอยแตก รอยเปื้อนสิ่งสกปรก คราบน้ำมันและฝาปิดท่อระบายน้ำได้อย่างมีประสิทธิภาพ สำหรับการจำแนกและตรวจหาให้ค่าความถูกต้องโดยรวม ความแม่นยำและค่าเรียกคืน ที่ร้อยละ 86.7, 83.3 และ 87.5 ตามลำดับ สำหรับการจำแนกหลุมบ่อ ค่าส่วนที่ซ้อนทับ

ระหว่างหลุมบ่อที่ถูกจำแนกกับข้อมูลอ้างอิงมีค่าอยู่ที่ร้อยละ 85 โดยคิดเป็นร้อยละ 88.6 ของจำนวนหลุมบ่อที่ตรวจพบบนภาพทั้งหมด

การใช้ Machine Learning (ML) ในการจำแนกและตรวจหาหลุมบ่อจากภาพถ่ายเป็นวิธีที่มีประสิทธิภาพ ในงานวิจัยของ Lakmal and Dissanayake (2020) ได้นำเสนอการใช้ ML ในการตรวจหาแอ่งน้ำที่ขังอยู่ในหลุมบ่อ โดยทำการวิเคราะห์ร่วมกับลักษณะของขอบและพื้นผิวในการตรวจหาพื้นผิวน้ำ จากนั้นใช้เทคนิค Random Forest (RF) ในการจำแนก โดยเลือกข้อมูลในการสอนและทดสอบ ผลลัพธ์ของการสอนชุดข้อมูลมีความถูกต้องที่ 0.94 - 0.99 และค่าความถูกต้องของชุดข้อมูลที่ทดสอบเท่ากับ 0.83 - 0.87 ผลที่ได้บ่งบอกได้ว่าเทคนิค RF สามารถตรวจหาหลุมบ่อได้อย่างมีประสิทธิภาพ

เทคนิค Support vector machine (SVM) เป็นหนึ่งเทคนิคจาก ML ที่ใช้ในการจำแนกและตรวจหาหลุมบ่อจากภาพถ่าย ในงานวิจัยของ Yousaf et al. (2018) ได้นำเสนอเทคนิค SVM ในการสอนและทดสอบข้อมูลในการตรวจหาหลุมบ่อและนำเสนอการสร้างเส้นแบ่งขอบเขตเพื่อกำหนดตำแหน่งของหลุมบ่อพร้อมทั้งกำหนดป้ายกำกับ ในงานวิจัยได้ใช้ข้อมูลภาพถ่ายผิวทางที่มีลักษณะแตกต่างกัน โดยผลการสอนให้ค่าความถูกต้อง ค่าความแม่นยำและค่าเรียกคืนอยู่ที่ร้อยละ 95.7, 97 และ 94.1 ตามลำดับ ถึงแม้ว่าผลของข้อมูลทดสอบจะให้ค่าความถูกต้องอยู่ที่ร้อยละ 91.4

การใช้โครงข่ายประสาทคอนโวลูชัน (CNN) ตรวจหาหลุมบ่อจากภาพถ่ายเป็นเทคนิคที่ได้รับความนิยมอย่างมากเนื่องจาก CNN เป็นเทคนิคที่พัฒนาเพื่อเน้นการจำแนกข้อมูลภาพถ่าย ในงานวิจัยของ H. Chen et al. (2020) ได้นำเสนอวิธี Localization network โดยอ้างอิงจากเทคนิค CNN

ในการตรวจหาหลุมบ่อจากภาพถ่ายแบบรู้ตำแหน่ง ซึ่งมุ่งเน้นในการตรวจหาหลุมบ่อในบริเวณถนน แทนการตรวจหาในบริเวณทั้งหมดของภาพ ผลการทดสอบจากข้อมูลภาพถ่ายถนนที่มีหลุมบ่อแสดงให้เห็นว่าวิธีที่นำเสนอสามารถให้ความแม่นยำสูงถึงร้อยละ 95.2 และค่าเรียกคืนร้อยละ 92 ผลลัพธ์ยังแสดงให้เห็นอีกว่าวิธีที่นำเสนอเน้นแม่นยำและเพิ่มประสิทธิภาพการจำแนกได้มาก

CNN ได้ถูกพัฒนาให้มีการตรวจหาหลุมบ่ออัตโนมัติแบบทันทีทันใด ซึ่งมีอัลกอริทึมที่ถูกพัฒนาและนำมาใช้กันอย่างแพร่หลาย ในงานวิจัยของ Darapaneni et al. (2021) ได้ทดสอบตรวจหาหลุมบ่อจากภาพถ่ายโดยใช้อัลกอริทึมต่าง ๆ คือ Yolo V3, Yolo V4, Yolo V5 และ SSD เพื่อเปรียบเทียบผลลัพธ์จากการจำแนกภาพถ่ายจำนวน 9000 ภาพ โดยในการประมวลผล

ประสบความสำเร็จ 3 อัลกอริทึมคือ Yolo V3 ให้ค่าความแม่นยำที่ร้อยละ 60 Yolo V4 ให้ค่าความแม่นยำที่ร้อยละ 90 และ Yolo V5 ให้ค่าความแม่นยำที่ร้อยละ 40

การตรวจหาหลุมบ่อได้มีการใช้เทคโนโลยีเพื่อหาขนาดและความลึกของหลุมบ่อโดยในงานวิจัยของ Wu et al. (2019) ได้นำเสนออัลกอริทึมแบบใหม่เพื่อผสานข้อมูลจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่ร่วมกับข้อมูลภาพถ่ายแบบสองมิติ โดยเริ่มต้นด้วยการใช้ CNN ในการตรวจหาหลุมบ่อจากภาพถ่ายสองมิติ จากนั้นใช้ขอบของหลุมบ่อที่ได้จากภาพสร้างความสัมพันธ์กับจุดพิกัดสามมิติ โดยจุดพิกัดสามมิติที่คัดเลือกจะแบ่งออกเป็นสองกลุ่มคือ จุดภายในและจุดภายนอก โดยที่จุดภายนอกจะสัมพันธ์กับระนาบของแนวถนนและสามารถคำนวณรูปทรงสามมิติของหลุมบ่อได้ และใช้จุดในการตรวจสอบว่าหลุมบ่อที่ได้ตรวจหาจากภาพถ่ายเป็นหลุมบ่อหรือแผ่นปะซ่อมถนน โดยทดสอบเก็บข้อมูลทางด่วนเชียงใหม่ไฮ้ระยะทาง 26.4 กิโลเมตร ผลจากการตรวจหาจาก CNN วิธี DeepLabv3+ พบหลุมบ่อจำนวน 77 หลุม แต่เมื่อตรวจสอบคัดกรองจากข้อมูลจุดพิกัดสามมิติพบว่าเป็นหลุมบ่อ 49 หลุม และเป็นแผ่นปะซ่อมถนน 28 จุด

การสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่ (MMS) ไปตามแนวเส้นทางทำให้ได้จุดพิกัดสามมิติที่ให้รายละเอียดของเส้นทางเช่น พื้นผิวถนน ต้นไม้ เสาไฟ ป้ายจราจร การนำข้อมูลจุดพิกัดสามมิติจาก MMS จำแนกและตรวจหาการชำรุดเสียหายของถนน เป็นสิ่งที่น่าสนใจในปัจจุบันเนื่องจากจุดพิกัดสามมิติให้รายละเอียดของตำแหน่งพิกัดและค่าระดับ ซึ่งสามารถบอกความเสียหายได้ในรูปแบบสามมิติ และถ้า MMS มีการติดตั้งกล้องพานอรามา 360 องศา ข้อมูลจุดพิกัดสามมิติจะแสดงรายละเอียดพร้อมกับค่าสีจากกล้อง มีงานวิจัยของ D. Zhang et al. (2018) ได้นำเสนออัลกอริทึมที่จำแนกการชำรุดเสียหายของถนนด้วยจุดพิกัดสามมิติจาก MMS การประมวลผลจะใช้สมมติฐานว่ารอยแตกบนผิวทางเป็นความเสียหายขนาดเล็กและการเกิดหลุมบ่อหรือการเสียรูปของผิวทางเป็นความเสียหายขนาดใหญ่ การทดสอบดำเนินการโดยใช้ข้อมูลวัดข้อมูลจริงแบบสามมิติ ผลการศึกษาแสดงให้เห็นว่าข้อมูลจากการสแกนด้วยเลเซอร์สามมิติกับวิธีการที่นำเสนอสามารถตรวจหารอยแตกทั่วไปได้อย่างมีประสิทธิภาพภายใต้สภาพถนนและสภาพแวดล้อมที่แตกต่างกัน โดยมีความแม่นยำในการตรวจหาสูงถึงร้อยละ 98 นอกจากนี้ยังสามารถตรวจหาการชำรุดเสียหายประเภทต่าง ๆ ของผิวทางได้เช่น หลุมบ่อ ร่องล้อ การทรุดตัว ได้อย่างแม่นยำด้วยความผิดพลาดน้อยกว่าร้อยละ 8.7

ในงานวิจัยของ De Blasiis et al. (2020) ได้นำเสนออัลกอริทึมที่ใช้ตรวจหาการชำรุดของผิวทางในรูปแบบต่าง ๆ เช่น หลุมบ่อและผิวทางขรุขระจากข้อมูลจุดพิกัดสามมิติที่มีความหนาแน่นสูงโดยเลือกใช้ข้อมูลจุดพิกัดสามมิติความยาว 100 เมตร โดยความเร็วในการขัทยานพาหนะในช่วงเก็บข้อมูลอยู่ที่ 10 กิโลเมตรต่อชั่วโมง ในขั้นตอนแรกเริ่มด้วยการแยกเฉพาะพื้นผิวถนน จากนั้นทำการแปลงจุดพิกัดสามมิติให้เป็นแบบจำลองความสูงเชิงเลขแล้วใช้อัลกอริทึม MSAC จำแนกการชำรุดของถนนในรูปแบบต่าง ๆ ผลลัพธ์ที่ได้จากวิธีที่นำเสนอให้ผลลัพธ์ที่ดี กระบวนการทำงานของอัลกอริทึมสามารถจำแนกได้อย่างถูกต้องและระบุประเภทของการชำรุดได้

การใช้ Machine Learning เป็นสิ่งที่นิยมใช้จำแนกข้อมูลจุดพิกัดสามมิติเช่นเดียวกัน แต่งานวิจัยที่ใช้ ML ในจำแนกการชำรุดเสียหายหรือหลุมบ่อของถนนมีน้อยมาก ส่วนใหญ่จะใช้จำแนกวัตถุอื่น ๆ เช่น ถนน เสาไฟฟ้า ป้ายจราจร อาคาร ในงานวิจัย B. Yang et al. (2017) ได้นำเสนอคุณลักษณะข้อมูลสามมิติแบบใหม่ที่เรียกว่า Binary Kernel Descriptor (BKD) เพื่อจำแนกข้อมูลจุดพิกัดสามมิติที่ได้จากระบบการทำแผนที่แบบเคลื่อนที่ BKD การประมาณค่าความหนาแน่นของเกาส์เซียนเคอเนลและส่วนประกอบของไบนารีเพื่อเข้ารหัสรูปร่างและข้อมูลจุดพิกัดสามมิติไปยังโมเดลของ Random Forest Classifier (RFC) เพื่อจำแนกขอบถนนและเครื่องหมายจราจร แล้วนำผลที่ได้ไปหาจำนวนช่องจราจร ความกว้างของช่องจราจรและทางแยก ในการทดสอบจำแนกข้อมูลขอบถนนและเครื่องหมายจราจรของชุดข้อมูลที่เป็นในเมืองให้ค่าความแม่นยำที่ร้อยละ 90 ซึ่งแสดงให้เห็นว่า BKD มีความแม่นยำในการทำงานกับจุดที่มีความหนาแน่นและมีข้อมูลจุดครบถ้วน

ในงานวิจัยของ Serna and Marcotegui (2014) ได้นำเสนอวิธีการจำแนกวัตถุอัตโนมัติจากจุดพิกัดสามมิติที่ได้จากระบบการทำแผนที่แบบเคลื่อนที่ โดยการแปลงข้อมูลจุดพิกัดสามมิติให้เป็นรูปแบบ 2.5 มิติคือการให้เป็นภาพถ่ายที่อ้างอิงค่าตามระดับความสูงหรือจะเรียกว่าแบบจำลองความสูงเชิงเลข โดยการจำแนกใช้เทคนิค SVM ผลการทดสอบกับชุดข้อมูล โอไฮโอ ประเทศสหรัฐอเมริกาและ ปารีส ประเทศฝรั่งเศส สามารถตรวจจับวัตถุที่มีความถูกต้องที่ร้อยละ 98 ความถูกต้องการแบ่งความหมายร้อยละ 78 และ ความถูกต้องการจำแนกที่ร้อยละ 82

การจำแนกวัตถุจากจุดพิกัดสามมิติมีการใช้เทคนิค CNN ซึ่งมีการพัฒนาอัลกอริทึมต่าง ๆ เพื่อใช้จำแนกข้อมูลจุดพิกัดสามมิติที่ได้จากระบบการทำแผนที่แบบเคลื่อนที่ ในงานวิจัยของ Jing and Suya (2016) ได้นำเสนอเทคนิค 3D-CNN ในการจำแนกจุดพิกัดสามมิติโดยแบ่งวัตถุเป็น อาคาร ต้นไม้เสาไฟฟ้า รถ พื้น สายไฟ และอื่น ๆ โดยเทคนิค 3D-CNN จะแปลงข้อมูลจุดพิกัดสามมิติ

ให้เป็นข้อมูลตารางลูกบาศก์ (Voxel) ก่อนเข้าสู่กระบวนการสอนและทดสอบข้อมูล ผลการทดสอบการจำแนกรถและพื้นให้ความถูกต้องสูงที่ร้อยละ 95 ในขณะที่ อาคาร เสาไฟฟ้า สายไฟ มีความถูกต้องอยู่ที่ร้อยละ 80 – 95 ส่วนความถูกต้องของต้นไม้ที่ต่ำกว่าร้อยละ 80 โดยคิดเป็นความถูกต้องโดยรวมอยู่ที่ร้อยละ 93

การใช้ CNN ในการจำแนกจุดพิภักัดสามมิติในงานวิจัยที่ใช้วิธีการแปลงข้อมูลจากสามมิติให้เป็นข้อมูลภาพสองมิติ ในงานวิจัยของ L. Zhang et al. (2018) ได้ใช้วิธีการสร้างภาพถ่ายหลาย ๆ มุมของข้อมูลจุดพิภักัดสามมิติเพื่อนำข้อมูลเข้าสู่กระบวนการสอนและทดสอบการจำแนกใน CNN ซึ่งทดสอบกับวัตถุภายในอาคาร วิธีนี้อาจจะไม่เหมาะกับการจำแนกข้อมูลที่เป็นพื้นที่กว้าง ซึ่งผลการสอนและทดสอบ โดยความถูกต้องของการถ่ายภาพ 1 มุมเท่ากับร้อยละ 86.6 ถ่ายภาพ 6 มุมเท่ากับร้อยละ 90.5 และถ่ายภาพ 12 มุมเท่ากับร้อยละ 93.5

การใช้ CNN ที่จำแนกวัตถุจากจุดพิภักัดสามมิติได้โดยตรงมีการพัฒนาสถาปัตยกรรมที่ชื่อว่า PointNet ที่สามารถป้อนข้อมูลเข้าในรูปแบบจุดพิภักัดสามมิติได้โดยตรง (C. Qi et al., 2017) และมีการนำไปใช้จำแนกวัตถุต่างจากข้อมูลจุดพิภักัดสามมิติ ในงานวิจัยของ Zhongyang et al. (2018) ได้นำเสนอการใช้ PointNet ในการจำแนกจุดพิภักัดสามมิติที่ได้จากเครื่องสแกนด้วยเลเซอร์ภาคพื้นดิน (Terrestrial Laser Scanner : TLS) โดยมีการเพิ่มโครงข่ายหลายขนาดเพื่อช่วยแยกคุณลักษณะเฉพาะจุด ผลการทดสอบแสดงให้เห็นว่าอัลกอริทึมที่นำเสนอมีความแม่นยำในการจำแนกที่สูงขึ้นเมื่อเทียบกับสถาปัตยกรรมจากโครงข่ายประสาทเทียมแบบอื่น ในงานวิจัยของ Kowalczyk and Szymański (2019) ได้พัฒนา PointNet เพื่อจำแนกจุดพิภักัดสามมิติที่ได้จากการสแกนด้วยเลเซอร์บนอากาศยานไร้คนขับ (ALS) ผลการทดสอบความแม่นยำอยู่ที่ร้อยละ 77.9 โดยวัตถุที่สามารถจำแนกได้แม่นยำที่สุดคือหลังคาที่ร้อยละ 92.6 ซึ่งสอดคล้องกับข้อมูลที่ได้จาก ALS ที่ให้รายละเอียดของหลังคาได้ดี

PointNet ได้มีการพัฒนามาเป็นสถาปัตยกรรม PointNet++ หลังจากทดสอบผลปรากฏว่าสามารถจำแนกวัตถุได้ดียิ่งขึ้น ในงานวิจัยของ Y. Chen et al. (2021) ได้พัฒนา PointNet++ เพื่อจำแนกข้อมูลจุดพิภักัดสามมิติที่ได้จาก ALS จำนวนจุดที่ใช้สอนทั้งหมด 753,876 จุด และข้อมูลทดสอบทั้งหมด 411,722 จุด ซึ่งข้อมูลจุดพิภักัดสามมิติจาก ALS นั้นมีลักษณะที่เบาบางไม่สามารถหาจุดเปลี่ยนแปลงบริเวณใกล้เคียงได้อย่างชัดเจน แต่ PointNet++ สามารถให้ความถูกต้องเพิ่มขึ้น



ร้อยละ 2 PointNet ผลทดสอบบ่งบอกว่า PointNet++ สามารถจำแนกวัตถุได้ดีและสามารถจดจำวัตถุบางอย่างได้ดีที่บางครั้งอาจจะถูกละเลยอย่างเช่นสายไฟ


ระบบการทำแผนที่แบบเคลื่อนที่ในปัจจุบันมีกล้องพาโนรามา 360 องศาติดตั้งไว้ในระบบสามารถบันทึกข้อมูลทัศนวิสัยโดยรอบไปพร้อมกับเซ็นเซอร์อื่น ๆ ระบบสามารถประมวลผลภาพถ่ายและใช้ค่า RGB ไปรวมอยู่ในจุดพิกัดสามมิติทำให้สามารถแสดงผลจุดสามมิติให้มีสีเสมือนจริงได้ ค่า RGB ที่อยู่ในจุดพิกัดสามมิติเปรียบเสมือนค่า RGB ที่อยู่ในข้อมูลภาพถ่าย ดังนั้นการใช้ค่า RGB เพิ่มมิติของข้อมูลที่ป้อนเข้าช่วยให้การสอนโครงข่ายมีประสิทธิภาพมากขึ้น ในงานวิจัยของ D. Wang et al. (2020) ได้นำเสนอการจำแนกวัตถุของระบบโครงสร้างพื้นฐานต่าง ๆ ที่ได้จากการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่ด้วยโครงข่าย Symmetric Ensemble Point (SEP) แล้วปรับแต่งผลลัพธ์ในอัลกอริทึม Euclidean Cluster Extraction (ECE) โดยยึดจากสถาปัตยกรรม PointNet การทดสอบเทคนิคนี้สามารถจำแนกวัตถุในระบบโครงสร้างพื้นฐานได้ 6 ประเภทได้แก่ ถนน อาคาร รั้ว ป้ายจราจร ต้นไม้ และไฟจราจร ความถูกต้องโดยรวมของวิธี SEP-ECE ดีขึ้นจาก PointNet ที่ร้อยละ 3.97 ความแม่นยำในการจำแนกโดยเฉลี่ยอยู่ที่ร้อยละ 99.74

จะเห็นได้ว่างานวิจัยก่อนหน้านี้แทบจะไม่มีการศึกษาการใช้ CNN ในการจำแนกหลุมบ่อบนพื้นถนนจากข้อมูลจุดพิกัดสามมิติ ทางผู้ศึกษาเห็นว่า การใช้จุดพิกัดสามมิติในการจำแนกและตรวจหาหลุมบ่อ มีประโยชน์ในการวิเคราะห์ความเสียหายที่เกิดขึ้นเพราะข้อมูลมีตำแหน่งพิกัดแผนที่ ทำให้ทราบตำแหน่งของปัญหาการเกิดหลุมบ่อและจุดพิกัดสามมิติสามารถบอกรูปร่าง ระดับความลึกของความเสียหายที่เกิดขึ้นได้และสามารถนำไปคำนวณปริมาตรของความเสียหายที่เกิดขึ้นได้ ทางผู้ศึกษายังมองเห็นถึงความสำคัญของการจำแนกหลุมบ่อที่ไม่ปรากฏลักษณะที่เด่นชัดของภาพ การใช้จุดพิกัดสามมิติจำแนกด้วยรูปร่าง ทำให้การตรวจหาหลุมบ่อมีประสิทธิภาพมากขึ้น ทางผู้วิจัยจะใช้ข้อมูลจุดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่ด้วยอุปกรณ์ Topcon IP-S3 HD จัดเก็บข้อมูลในพื้นที่ศึกษาที่เกิดหลุมบ่อ จากนั้นนำข้อมูลเข้าสู่กระบวนการสอนและทดสอบจำแนกหลุมบ่อและถนนด้วยโครงข่ายประสาทคอนโวลูชันโดยใช้สถาปัตยกรรม PointNet++

### บทที่ 3

#### การดำเนินงานวิจัย


การดำเนินงานวิจัยจะแบ่งออกเป็น 4 ขั้นตอนดังต่อไปนี้ คือ 1) การสำรวจเก็บข้อมูลด้วยระบบการทำแผนที่แบบเคลื่อนที่ (MMS) 2) การประมวลผลข้อมูล MMS การปรับแก้ข้อมูลและการประเมินความถูกต้อง 3) การจำแนกข้อมูลด้วย CNN 4) การวิเคราะห์ผลการจำแนกและการวัดประสิทธิภาพการจำแนกและการเปรียบเทียบผล ขั้นตอนการดำเนินงานได้สรุปไว้ในรูปที่ 3-1



รูปที่ 3-1 แสดงขั้นตอนการดำเนินงานวิจัย

### 3.1. การสำรวจจัดเก็บข้อมูล

การสำรวจจัดเก็บข้อมูลด้วยระบบการทำแผนที่แบบเคลื่อนที่ (MMS) เริ่มต้นด้วยการสำรวจพื้นที่เส้นทางถนนในกรุงเทพมหานครและปริมณฑลเพื่อหาพื้นที่ถนนที่มีปัญหาชำรุดเป็นหลุมบ่อจากการการสำรวจของผู้วิจัยพบว่ามีเส้นทางถนนโยธาธิการ เคหะการเกษตร หมู่ 10 ตำบลหนองเพรางาย อำเภอนิคมพัฒนา จังหวัดนนทบุรี ที่ติดตั้งแสดงในรูปที่ 1-1 ซึ่งตลอดเส้นทางจะพบเจอปัญหาการชำรุดของเส้นทางเช่นเป็นหลุมบ่อ ปัญหารอยแตกของพื้นผิวถนน ดังแสดงในรูปที่ 3-2 ดังนั้นผู้วิจัยจึงได้เลือกเส้นทางดังกล่าวเป็นพื้นที่ศึกษาวิจัย



รูปที่ 3-2 แสดงหลุมบ่อของพื้นที่ศึกษาถนนโยธาธิการ เคหะการเกษตร

กระบวนการสำรวจด้วย MMS ความถูกต้องของข้อมูลจุดพิกัดสามมิติในเชิงตำแหน่งของระบบแผนที่เป็นสิ่งสำคัญในการทำงาน เพื่อให้มีความเชื่อมั่นในการนำไปประยุกต์ใช้งานร่วมกับข้อมูลสำรวจภาคสนามในวิธีอื่น ๆ เช่นการกำหนดตำแหน่งด้วยระบบ GNSS การสำรวจด้วยกล้องประมวลผลรวมและกล้องระดับ ดังนั้นในการดำเนินงานจะใช้จุดอ้างอิงสถานีฐานจากหมุดควบคุมในพื้นที่ใกล้เคียงให้กับ MMS ซึ่งเป็นหมุดจากกรมชลประทานที่สำรวจด้วย GNSS วิธี Static หมุดหลักฐานที่เลือกใช้ชื่อหมุด GNSS 610373 ดังแสดงในรูปที่ 3-3 มีระบบพิกัดแผนที่แบบกริด UTM WGS 84 Zone 47N มีค่า Northing เท่ากับ 1527509.770 เมตร และค่า Easting = 643081.373 เมตร ส่วนค่าระดับจะอ้างอิงจากระดับทะเลปานกลาง มีค่าเท่ากับ 4.052 เมตร ซึ่งการสำรวจด้วย MMS จะเก็บข้อมูลและประมวลผล GNSS แบบ PPK ค่าพิกัดตำแหน่งของจุดพิกัดสามมิติจะอยู่ในระบบเดียวกับหมุดอ้างอิง

การปรับแก้ข้อมูลจุดพิกัดสามมิติจาก MMS ให้มีความถูกต้องมากยิ่งขึ้น จำเป็นต้องสำรวจจัดทำจุดควบคุมภาคพื้นดิน Ground Control Point (GCP) และตรวจสอบความถูกต้องด้วยจุด Check Point (CP) โดยการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี Real Time Kinematic (RTK) โดยที่การสำรวจจุด GCP และ CP อ้างอิงด้วยหมุด GNSS 610373 เช่นเดียวกับ MMS




รูปที่ 3-3 แสดงหมุดหลักฐานอ้างอิง GNSS 610373 ของกรมชลประทาน

ในการดำเนินงานสร้างจุด GCP ได้ทำสัญลักษณ์สีเหลี่ยมแบบกากบาท เพื่อให้มองเห็นเป็นสัญลักษณ์ในข้อมูล MMS ดังแสดงในรูปที่ 3-4 จากนั้นทำการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK เก็บข้อมูลด้วยวิธีการเก็บค่าพิกัดทุกวินาทีเป็นเวลา 3 นาที และนำค่าพิกัดที่จัดเก็บทั้งหมด 180 ค่า คำนวณหาค่าเฉลี่ยของพิกัดเพื่อนำมาใช้เป็นตำแหน่งพิกัดของจุด GCP และ CP



รูปที่ 3-4 แสดงการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK ของจุด GCP และ CP

จุด GCP ทั้งหมดมีจำนวน 6 จุด และจุด CP มีจำนวน 6 จุดเช่นเดียวกัน ในระยะทางสำรวจ ประมาณ 4 กิโลเมตร โดยรวมทั้งพื้นที่ศึกษาจะมีจุด GCP และ CP ประมาณทุก 500 เมตร ดังแสดง ในรูปที่ 3-5 ตามแนวทางของการสำรวจด้วย MMS ของ (Olsen et al., 2013) ได้นำเสนอไว้ว่า หาก ต้องการใช้ข้อมูลจุดพิกัดสามมิติในการจำแนกวัตถุแบบอัตโนมัติหรือกึ่งอัตโนมัติ ควรใช้ข้อมูล ที่มีความถูกต้องที่อยู่ในเกณฑ์งานชั้นที่ 2 หรือดีกว่า ซึ่งงานชั้นที่ 2 ได้นำเสนอให้ใช้จุด GCP ห่างกัน ไม่เกิน 700 เมตร ซึ่งในงานศึกษานี้กำหนดจุด GCP ที่มีระยะห่างอยู่ในเกณฑ์งานชั้นที่ 2



รูปที่ 3-5 แสดงตำแหน่งของหมุดอ้างอิง จุด GCP และ จุด CP

การสำรวจเก็บข้อมูลด้วย MMS จำเป็นต้องขับเคลื่อนยานพาหนะในความเร็วที่ช้า เพื่อให้ ข้อมูลจากการสแกนมีความละเอียดเชิงพื้นที่ได้มากที่สุด เนื่องจากจุดสแกนที่มีความละเอียดเชิงพื้นที่ จะทำให้ข้อมูลแสดงรูปทรงของวัตถุได้ชัดเจนยิ่งขึ้น ซึ่งจะส่งผลให้การจำแนกมีความแม่นยำมากยิ่งขึ้น ในงานวิจัยครั้งนี้ได้ดำเนินการขับรถที่ความเร็วไม่เกิน 40 กิโลเมตรต่อชั่วโมงที่ความเร็วคงที่

การสำรวจเก็บข้อมูลด้วย MMS เริ่มต้นด้วยการติดตั้งอุปกรณ์บนยานพาหนะทำการวัด ค่าชดเชยต่าง ๆ เช่น ความสูงของอุปกรณ์เซ็นเซอร์จากพื้นดิน เพื่อความถูกต้องทางดิ่งมีความแม่นยำ โดยที่องค์ประกอบต่าง ๆ ของ MMS ที่ทำการติดตั้งประกอบด้วยส่วนหลัก ๆ ดังต่อไปนี้ คือ

1) ส่วนของชุดอุปกรณ์หลักจะประกอบด้วยเซ็นเซอร์ดังต่อไปนี้คือ GNSS, IMU, เครื่องสแกน ด้วยเลเซอร์และกล้องถ่ายภาพดังแสดงในรูปที่ 3-6



รูปที่ 3-6 ส่วนประกอบของอุปกรณ์ Topcon IP-S3 รูปดัดแปลงจาก Topcon (2021)

2) เครื่องวัดระยะทางด้วยล้อเรียกว่า DMI เป็นอุปกรณ์ที่ติดตั้งกับล้อของรถเพื่อวัดระยะทาง ข้อมูลจากการวัดระยะทางจะช่วยให้การประมวลผลตำแหน่งของเส้นทางที่เก็บข้อมูลและช่วยลดความคลาดเคลื่อนเมื่อระบบอยู่ในสถานะ GNSS ไม่มีสัญญาณ เซ็นเซอร์ DMI ติดตั้งไว้ที่ล้อรถดังแสดงไว้ในรูปที่ 3-7



รูปที่ 3-7 แสดงภาพ DMI ที่ติดตั้งอยู่ที่ล้อของยานพาหนะ รูปจาก Topcon (2021)

3) ส่วนระบบควบคุมและจัดเก็บข้อมูล เป็นส่วนที่เชื่อมต่ออุปกรณ์ทั้งหมดเข้าด้วยกัน ผ่านกล่องควบคุม Timing Box ระบบจะจัดเก็บข้อมูลและแสดงสถานะผ่านโปรแกรม Mobile Master Field บนระบบปฏิบัติการ Windows ของระบบคอมพิวเตอร์ ส่วนการดำเนินงานสำรวจเก็บข้อมูลจะมีขั้นตอนการทำงานของระบบในภาคสนามดังต่อไปนี้

- การตรวจสอบสถานะการทำงานของเซ็นเซอร์ทั้งหมดของระบบเช่น GNSS, Laser Scanner, IMU, Camera, Wheel และ DMI ถ้าหากสถานะเซ็นเซอร์ทั้งหมดแสดงเป็นปกติ แสดงว่าอุปกรณ์พร้อมเริ่มทำงานได้ทันที

- การกำหนดตำแหน่งของการจัดเก็บข้อมูลในหน่วยความจำ ซึ่งข้อมูลจะส่งผ่าน 2 ช่องทาง คือ USB 3.0 จะส่งข้อมูลการบันทึกภาพจากกล้องถ่ายภาพจำนวน 6 กล้องเป็นไฟล์ภาพ JPG และช่องทาง Ethernet Cable จะรวบรวมจัดเก็บข้อมูลจากเซ็นเซอร์อื่น ๆ คือ GNSS, Laser Scanner, IMU และ DMI

- การทำ Self-calibration ปรับตำแหน่งและปรับทิศทางของ IMU ในขณะหยุดนิ่ง ระบบจะดำเนินการเก็บข้อมูล GNSS เป็นเวลา 10 วินาทีเพื่อเป็นการทำ Initialization ของวิธีการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS แบบ Continuous Kinematic เพื่อให้ได้ผลลัพธ์จากการประมวลผลภายหลังมีความถูกต้องเพิ่มขึ้น ซึ่งขั้นตอน Static Alignment ต้องทำในสภาพแวดล้อมที่รับสัญญาณดาวเทียม GNSS อย่างน้อย 5 ดวงขึ้นไป โดยห่างจากอาคารหรือต้นไม้สูงที่จะรบกวนสัญญาณ GNSS

- การทำ Self-calibration ของ IMU เป็นการปรับตำแหน่งแบบเคลื่อนที่เพื่อปรับตำแหน่งและทิศทางของ IMU การดำเนินการจะทำในขณะที่ยานพาหนะเคลื่อนที่โดยมีการดำเนินการทำ 2 ขั้นตอนคือ

- 1) ขับรถด้วยความเร็ว 30 กิโลเมตรต่อชั่วโมง
- 2) เลี้ยวขวาและเลี้ยวซ้ายอย่างละ 1 ครั้งหรือมากกว่า

- การเริ่มเก็บข้อมูลสำรวจ โดยการขับชี้พาหนะที่ติดตั้งอุปกรณ์ IP-S3 ดังแสดงในรูปที่ 3-8 ไปตามเส้นทางที่กำหนดไว้ เซ็นเซอร์ทุกตัวบนอุปกรณ์ที่จะดำเนินการจัดเก็บข้อมูลระหว่างเส้นทางลงในหน่วยความจำของระบบคอมพิวเตอร์

- การทำ Self-calibration ก่อนสิ้นสุดการสำรวจ หลังจากจัดเก็บข้อมูลสำรวจเสร็จสิ้นระบบให้จัดตำแหน่งและทิศทางของ IMU อีกครั้งเช่นเดียวกับตอนเริ่มต้น โดยเริ่มจากการทำ Kinematic Alignment แล้วตามด้วย Static Alignment โดยรายละเอียดการทำงานเหมือนตอนเริ่มทำงานทุกประการ จากนั้นเป็นการเสร็จสิ้นการทำงานเก็บข้อมูลสำรวจภาคสนามของ MMS ต่อไปเป็นการเข้าสู่ในส่วนของการประมวลผลข้อมูล



รูปที่ 3-8 แสดงยานพาหนะที่ติดตั้งอุปกรณ์ IP-S3 เก็บข้อมูลสภาพแวดล้อมของถนน

### 3.2 การประมวลผลข้อมูล MMS และการปรับแก้ข้อมูล

การสำรวจด้วย MMS ข้อมูลที่ได้เป็นข้อมูลดิบที่ได้รับจากเซ็นเซอร์ต่าง ๆ ของตัวอุปกรณ์ ข้อมูลต้องได้รับการประมวลผลและปรับแก้ความถูกต้อง เพื่อนำผลลัพธ์จุดพิกัดสามมิติไปใช้งาน การประมวลผลและการปรับแก้ข้อมูล MMS จะใช้ซอฟต์แวร์ Magnet Collage ของ Topcon ซึ่งเป็นโปรแกรมเฉพาะในการประมวลผลข้อมูลที่ได้จากการสำรวจด้วยอุปกรณ์ IP-S3 โดยการประมวลผลจะมีขั้นตอนดังต่อไปนี้

#### 3.2.1 การประมาณค่าตำแหน่งเส้นทาง (Vehicle trajectory estimation)

การประมวลผล Vehicle trajectory estimation เป็นการประมวลผลตำแหน่งเส้นทางสำรวจเก็บข้อมูลโดยใช้ GNSS ร่วมกับ IMU และ DMI เพื่อเป็นตำแหน่งเปิดถ่ายของกล้องถ่ายภาพ และตำแหน่งอ้างอิงการสแกนด้วยเลเซอร์ที่มีความถูกต้องสูง การดำเนินงานจำเป็นต้องใช้ข้อมูล GNSS จากสถานีฐานเพื่อเป็นตำแหน่งอ้างอิงให้การประมวลผลการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS แบบ Relative ของวิธี PPK ใช้ข้อมูล Raw Data จากสถานีฐานประมวลผลกับข้อมูล GNSS ที่ได้จาก MMS และเมื่อใช้ GNSS ประมวลผลร่วมกับ IMU และ DMI ทำให้ค่าความถูกต้องเพิ่มสูงขึ้น และช่วยแก้ปัญหาเมื่อระบบเจอฟันที่อ้างอิงดาวเทียม ระบบจะใช้ข้อมูลของ IMU และ DMI ช่วยในการคำนวณ Trajectory

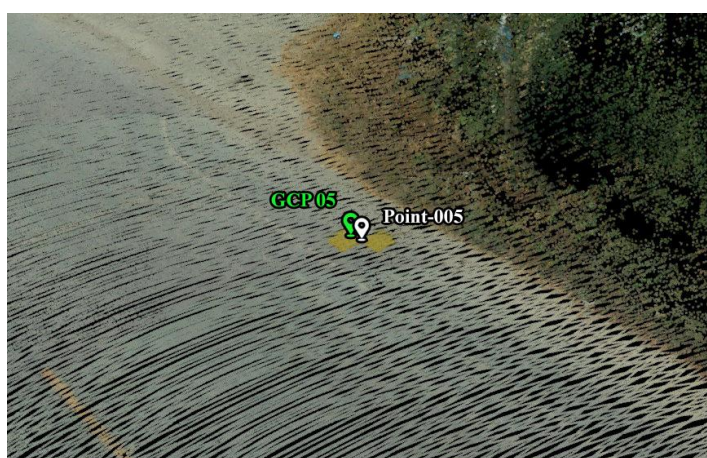


### 3.2.2 การปรับแก้ข้อมูลจากหลายเส้นทาง (Align multiple passes)

การประมวลผล Align multiple passes เป็นการปรับแก้ตำแหน่งเส้นทางโดยอ้างอิงจากข้อมูลสแกน ซอฟต์แวร์สร้างจุดสแกนจากตำแหน่งเส้นทาง จากนั้นซอฟต์แวร์ใช้อัลกอริทึมปรับแก้จุดสแกนด้วยการทำ Registration แบบอัตโนมัติ จุดสแกนจะถูกปรับแก้ให้มีความถูกต้องลดปัญหาจุดสแกนเหลื่อมกันจากความคลาดเคลื่อนของตำแหน่งเส้นทาง หลังจากการปรับแก้จุดสแกนเสร็จสิ้น ระบบจะประมวลผลตำแหน่งเส้นทางใหม่อีกครั้งโดยอ้างอิงจากจุดสแกนที่ได้รับการปรับแก้แล้ว

### 3.2.3 การปรับแก้ตำแหน่งเส้นทางด้วย GCP (Align trajectory with GCPs)

การประมวลผล Align trajectory with GCPs เป็นการปรับแก้ข้อมูลตำแหน่งเส้นทางด้วย Ground Control Point (GCP) เป็นขั้นตอนหลังจากทำ Align multiple passes แล้ว เพื่อให้จุดพิกัดสามมิติในขั้นตอนสุดท้ายมีความถูกต้องเชิงตำแหน่งมากยิ่งขึ้น ในเทคนิคการประมวลผลมีการใช้จุดควบคุมภาคพื้นดินโดยการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS โดยใช้วิธี RTK รั้ววัดจุดที่สามารถสังเกตได้ในพื้นที่ โดยใช้วิธีการพ่นสีเป็นสีเหลืองมกาทาไว้ในจุดที่สังเกตเห็นได้ในบริเวณขอบทาง ดังแสดงในรูปที่ 3-9 จุด GCP05 คือจุดที่กำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK ที่เป็นจุดควบคุมภาคพื้นดิน จุด Point-005 คือจุดที่ได้จาก MMS ซึ่งถ้าหากไม่มีความคลาดเคลื่อนทั้ง 2 จุดจะอยู่ตำแหน่งเดียวกัน ระยะห่างแบบสามมิติของทั้ง 2 จุดคือค่าความคลาดเคลื่อนที่เกิดขึ้น ซึ่งจะได้รับการปรับแก้ด้วย GCP โดยถ้าหากจุด GCP มีจำนวนมากจะทำให้การปรับแก้ข้อมูลมีความถูกต้องเชิงตำแหน่งมากยิ่งขึ้น



รูปที่ 3-9 แสดงจุด GCP05 จาก GNSS วิธี RTK กับจุด Point-005 จาก MMS

### 3.2.4 การต่อภาพถ่ายแบบพาโนรามา (Stitch Panoramic image)

การประมวลผล Stitch Panoramic image เป็นการสร้างภาพถ่ายพาโนรามา 360 องศาจากกล้องดิจิทัลที่ติดตั้งอยู่ในอุปกรณ์จำนวน 6 กล้อง บันทึกภาพในทุกระยะทาง 5 เมตร ภาพถ่ายทั้งหมดถูกคำนวณตำแหน่งจุดเปิดถ่ายจาก GNSS เพื่อนำข้อมูลภาพถ่ายเข้าสู่ระบบแผนที่ Street View และจากมุมมองของภาพถ่ายพาโนรามา ระบบสามารถประมวลผลค่าสีของภาพถ่ายไปยังจุดที่ได้จากการสแกนเข้าด้วยกันทำให้จุดพิกัดสามมิติที่ได้จากการสแกน แสดงผลค่าสีเหมือนในภูมิประเทศจริงเป็นรูปแบบสามมิติ

### 3.2.5 การสร้างจุดพิกัดสามมิติ (Cloud generation)

การประมวลผล Cloud generation เป็นการสร้างจุดพิกัดสามมิติจากข้อมูลสแกนที่ได้รับการปรับแก้และใส่ค่าสีที่ได้จากภาพพาโนรามา 360 องศาเรียบร้อยแล้ว เป็นข้อมูลจุดที่สร้างขึ้นมาสุดท้ายก่อนที่จะนำจุดทั้งหมดออกไปประยุกต์ใช้งานในด้านต่าง ๆ ในรูปแบบมาตรฐานของจุดพิกัดสามมิติ ซึ่งในงานศึกษาครั้งนี้จะนำข้อมูลจุดพิกัดสามมิติที่ได้จากการสำรวจด้วย MMS จำแนกพื้นผิวถนนและหลุมบ่อที่เกิดขึ้นในพื้นที่ศึกษาโดยใช้ CNN

### 3.2.6 การกรองข้อมูลจุดพิกัดสามมิติ (Filter cloud)

การประมวลผล Filter cloud เป็นการกรองข้อมูลจุดพิกัดสามมิติที่สร้างขึ้นมาจากข้อมูลสแกนขั้นสุดท้าย โดยการลบข้อมูลจุดที่ระบบตรวจสอบว่าเป็นสัญญาณรบกวนของระบบจุดพิกัดที่พบเจอจะวางตัวกระจายไม่เป็นระเบียบ ทำให้จุดพิกัดสามมิติเหล่านี้จะถูกระบบลบออกไปจากข้อมูล ทำให้ข้อมูลจุดพิกัดสามมิติมีความราบเรียบและสวยงามมากยิ่งขึ้น

## 3.3 ระบบและ Software ประมวลผลข้อมูล

### 3.3.1 ทรัพยากรประมวลผล

Intel® Core i7-8750H ความเร็ว 2.2 GHz หน่วยความจำขนาด 32 GB หน่วยประมวลผลกราฟฟิก NVIDIA GeForce RTX2070 หน่วยความจำกราฟฟิกขนาด 8 GB ใช้ระบบปฏิบัติการ Windows 10 และ Linux Mint 19.3

### 3.3.2 ซอฟต์แวร์ประมวลผล

- การจัดเก็บข้อมูลภาคสนามด้วย MMS ใช้ซอฟต์แวร์ Mobile Master Field และประมวลผลข้อมูลด้วยซอฟต์แวร์ Magnet Collage ลิขสิทธิ์จากบริษัท ท็อปคอน อินสทรูเมนต์ ไทยแลนด์ จำกัด

- ซอฟต์แวร์ Autodesk Recap ลิขสิทธิ์ทดลองใช้ 1 ปีสำหรับนักศึกษา ใช้การจำแนกข้อมูลอ้างอิงจุดพิกัดสามมิติ และใช้ซอฟต์แวร์ Matlab Version 2021 ลิขสิทธิ์จากจุฬาลงกรณ์มหาวิทยาลัย สร้างชั้นข้อมูลอ้างอิง (Label) ให้จุดพิกัดสามมิติ ในส่วนของการจำแนกข้อมูลจุดพิกัดสามมิติ ใช้ซอฟต์แวร์รหัสเปิดภาษา Python โดยใช้ Library ด้าน Machine Learning คือ TensorFlow

## 3.4 การจำแนกพื้นผิวถนนและหลุมบ่อจากข้อมูลจุดพิกัดสามมิติ

### 3.4.1 อัลกอริทึมสำหรับการจำแนกพื้นผิวถนนและหลุมบ่อ

โดยทั่วไปประสิทธิภาพการตรวจหาและความถูกต้องของการจำแนกพื้นผิวถนนเป็นข้อกำหนดเบื้องต้นสำหรับการตรวจหาและการจำแนกสิ่งต่าง ๆ ที่มีอยู่บนผิวถนนเช่น หลุมบ่อ ฝาท่อ เส้นจราจร (H. Wang et al., 2015) การลดปริมาณข้อมูลที่ได้จากการสแกน สามารถเพิ่มความรวดเร็วในการตรวจหาและการจำแนกข้อมูลพื้นผิวถนน (Yu et al., 2015) นอกจากนี้การกรองข้อมูลจุดพิกัดสามมิติที่อยู่นอกพื้นผิวถนน สามารถลดการใช้ทรัพยากรคอมพิวเตอร์ในการประมวลผลได้ วิธีการและอัลกอริทึมที่หลากหลายได้รับการพัฒนาสำหรับการตรวจหาและจำแนกพื้นผิวถนน โดยใช้ข้อมูลจาก MMS การจำแนกพื้นผิวถนนโดยใช้จุดพิกัดสามมิติจาก MMS โดยตรงหรือภาพถ่ายแบบสองมิติ

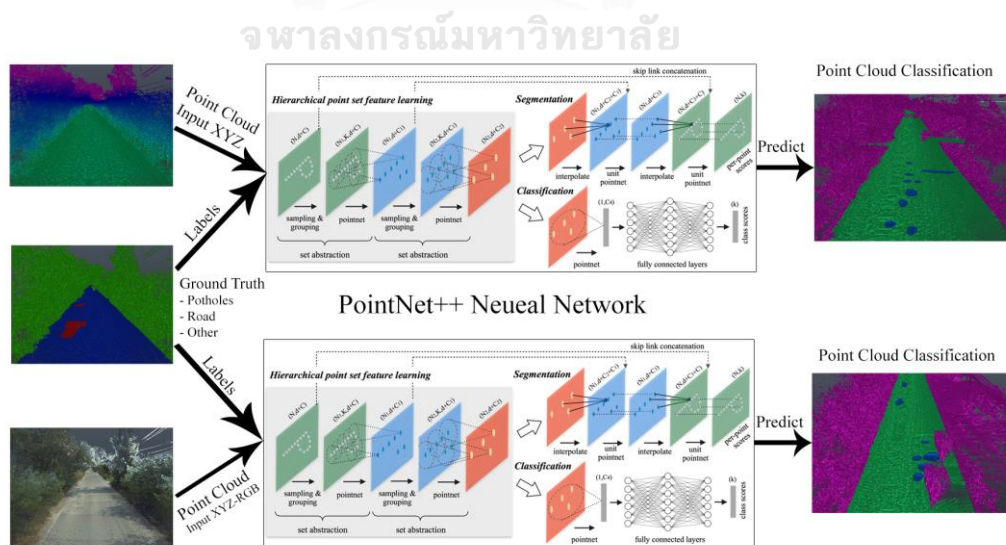
ในงานวิจัยนี้ได้สำรวจเก็บข้อมูลด้วย MMS ในพื้นที่ศึกษาที่เกิดหลุมบ่อ โดยประมวลผลเป็นข้อมูลจุดพิกัดสามมิติที่มีความถูกต้องเชิงพื้นที่ จำแนกข้อมูลถนนและหลุมบ่อโดยใช้ CNN ในสถาปัตยกรรม PointNet++ โดยปรับปรุงให้ฝึกสอน ทดสอบและจำแนกจุดพิกัดสามมิติที่มีค่า XYZ กับค่า RGB โดยเบื้องต้น PointNet++ รองรับการนำเข้าข้อมูลจุดพิกัดสามมิติแบบ  $N \times 3$  คือ XYZ โดยที่ N คือจำนวนจุดพิกัดสามมิติ ในงานวิจัยนี้ได้นำเสนอการนำเข้าข้อมูลแบบ  $N \times 6$  คือ XYZ-RGB ดังแสดงในรูปที่ 3-10 โดยการปรับ Channel นำเข้าข้อมูลของ PointNet ให้เป็น 6 Channel นำเข้าข้อมูล XYZ-RGB เข้าสู่โครงข่าย เพื่อทดสอบประสิทธิภาพของ CNN ในการจำแนก

จุดพิกัดสามมิติจากวิธีไม่มีค่า RGB และวิธีนำเสนอมีค่า RGB เพื่อประเมินประสิทธิภาพของการใช้ค่า RGB ที่ได้จากภาพถ่ายของ MMS ในการจำแนกข้อมูล โดยการดำเนินงานจะใช้ข้อมูลชุดเดียวกันทั้ง ข้อมูลชุดฝึกสอน ข้อมูลชุดทดสอบ ข้อมูลชุดทดสอบการจำแนก และข้อมูลอ้างอิงภาคพื้นดิน (Ground Truth) หรือจะเรียกว่าข้อมูลกำกับ (Label) และเปรียบเทียบผลจากวิธีการที่ต่างกัน โดยกระบวนการแสดงไว้ในรูปที่ 3-11

X	Y	Z	R	G	B	Labels
642562.294	1534948.521	2.217	167	175	164	1
642562.813	1534949.05	2.243	169	177	166	2
642561.378	1534948.438	2.239	170	182	172	2
642561.787	1534949.665	2.261	170	177	169	2
642562.688	1534949.776	2.261	150	163	156	2
642562.462	1534949.139	2.216	168	175	159	3
642561.237	1534949.429	2.255	179	184	177	3
642561.414	1534949.532	2.251	171	183	173	3
642568.671	1534945.696	2.274	141	150	133	3
642568.497	1534946.038	2.267	148	152	138	1
642562.359	1534949.337	2.244	162	167	160	2
642561.296	1534948.608	2.234	157	165	150	2
642561.902	1534949.541	2.258	170	180	171	3
642561.42	1534949.698	2.255	154	167	158	3
642561.217	1534949.373	2.247	176	186	177	2
642568.159	1534945.592	2.262	147	150	141	3
642561.865	1534948.625	2.212	163	175	163	3
642567.552	1534945.35	2.286	143	147	133	2
642561.25	1534949.625	2.264	162	174	164	1
642562.539	1534948.489	2.246	166	172	158	1
642561.701	1534949.723	2.249	143	156	149	2
642562.925	1534949.475	2.269	179	187	176	2
642562.756	1534949.394	2.243	168	176	165	2
642561.629	1534949.42	2.238	165	172	164	2

  XYZ Data   
   XYZ-RGB Data   
   Labels

รูปที่ 3-10 แสดงค่าของข้อมูลจุดพิกัดสามมิติ กรอบสีเขียวคือชุดข้อมูลที่มีเฉพาะ XYZ กรอบสีแดงคือชุดข้อมูลที่มีค่า XYZ-RGB และกรอบสีน้ำเงินคือข้อมูล Ground Truth กำกับชั้นข้อมูลแต่ละจุด



รูปที่ 3-11 แสดงการนำเข้าข้อมูลจุดพิกัดสามมิติเข้าโครงข่าย CNN ในสถาปัตยกรรม PointNet++ เพื่อฝึกสอนและทดสอบและการนำออกผลการจำแนก รูปดัดแปลงจาก C. R. Qi et al. (2017)

### 3.4.2 การกรองข้อมูล

การกรองข้อมูลในกระบวนการจำแนกจุดพิกัดสามมิติ ในงานวิจัยนี้ทำการกรองข้อมูลในขั้นตอนการประมวลผล MMS โดยการกำจัดจุดพิกัดสามมิติที่ไม่จำเป็นในการจำแนกพื้นผิวถนนและหลุมบ่อด้วยการกำหนดระยะสแกนในขั้นตอนการประมวลผลให้น้อยลง เนื่องจากคุณสมบัติของเครื่องสแกนด้วยเลเซอร์มีระยะไกล 100 เมตร สแกนพื้นที่โดยรอบแบบ 360 องศา ถ้าหากมีการนำข้อมูลทั้งหมดจากการสแกนไปใช้จำแนกข้อมูล อาจทำให้ข้อมูลใหญ่เกินไป ทำให้ใช้ทรัพยากรคอมพิวเตอร์ค่อนข้างสูง ดังนั้นการศึกษานี้มีวัตถุประสงค์ในการจำแนกเฉพาะพื้นผิวถนนและหลุมบ่อ จึงมีความจำเป็นที่ต้องจำกัดระยะการสแกนให้มีความพอดีกับความกว้างของผิวถนน เพื่อจำกัดข้อมูลจุดพิกัดสามมิติไม่ให้มากเกินไป ในงานวิจัยนี้ได้กำหนดระยะการสแกนไว้ที่ 20 เมตรจากเซ็นเซอร์ ทำให้ลดความใหญ่ของข้อมูลและลดความซับซ้อนจากข้อมูลที่ไม่จำเป็นในการจำแนกพื้นผิวถนนและหลุมบ่อ

ในส่วนของการกรองข้อมูลในขั้นตอนของการเตรียมข้อมูลเพื่อนำเข้าฝึกสอนโครงข่ายเรียกว่าการทำ Down sampling คือเป็นการกรองข้อมูลจุดพิกัดสามมิติบางส่วนออกไป ทำให้จุดพิกัดสามมิติในภาพรวมมีความหนาแน่นน้อยลงเพื่อลดปริมาณของข้อมูล แต่ยังคงรักษาลักษณะรูปแบบของจุดพิกัดสามมิติไว้ การกรองข้อมูลในขั้นตอนนี้จะรวมถึงการแปลงค่าพิกัด (Transformation) เป็นการแปลงค่าของระบบพิกัดแบบ UTM ให้มีค่าพิกัดมีตัวเลขน้อยลงเพื่อลดปริมาณของข้อมูลจุดพิกัดสามมิติ โดยการทอนค่าพิกัดทางทิศตะวันออกและทางทิศเหนือที่ -638,000 เมตรและ -1534,000 เมตร ซึ่งหลังจากเสร็จกระบวนการจำแนกข้อมูล ระบบจะ Transformation ข้อมูลกลับไปสู่ระบบพิกัด UTM ตามเดิมเพื่อนำไปใช้งานทางด้านแผนที่ร่วมกับข้อมูลสำรวจด้วยวิธีอื่น ๆ

การกรองข้อมูลจะทำให้โครงข่ายลดความซับซ้อนในการเรียนรู้ของข้อมูล ในการจำแนกพื้นผิวถนนและหลุมบ่อ อีกทั้งยังช่วยให้การประมวลผลมีความรวดเร็วมากยิ่งขึ้นเพราะใช้ทรัพยากรของคอมพิวเตอร์น้อยลง อย่างไรก็ตามเมื่อมีการทำ Down Sampling ให้จุดพิกัดสามมิติบางลง อาจจะลดประสิทธิภาพการฝึกสอนของ CNN ในการเรียนรู้ลักษณะการเกิดหลุมบ่อที่มีขนาดเล็กได้ในที่นี้เป็นข้อจำกัดของการศึกษานี้ เนื่องจากมีคอมพิวเตอร์คุณภาพสูงไม่เพียงพอต่อการฝึกสอนข้อมูลแบบไม่ต้องลดขนาดลง แต่ในภายหลังมีการทำ Interpolation ให้จุดพิกัดสามมิติกลับมาหนาแน่นเหมือนเดิมเพื่อนำไปใช้งานต่อไป

### 3.4.3 การเตรียมข้อมูลฝึกสอนโครงข่ายและข้อมูลอ้างอิงภาคพื้นดิน

ข้อมูลจุดพิกัดสามมิติที่ได้จากการสำรวจด้วย MMS มีระยะทางประมาณ 4 กิโลเมตร และระยะทางด้านข้าง 20 เมตรอ้างอิงระยะจากเซ็นเซอร์ ข้อมูลจุดพิกัดสามมิติจากการประมวลผล นำออกข้อมูลเป็นรูปแบบ Text file โดยข้อมูลจะแบ่งออกเป็น 2 ชุด คือข้อมูลจุดพิกัดสามมิติที่มี เฉพาะ XYZ และจุดพิกัดสามมิติที่มีค่า XYZ และ RGB ค่าสี RGB มีค่าระหว่าง 0-255

ข้อมูลอ้างอิงภาคพื้นดินเป็นข้อมูลที่ผู้วิจัยได้จำแนกจุดพิกัดสามมิติไว้ โดยการทำตัวเลข กำกับชั้นของข้อมูลที่จำแนกไว้หรือที่เรียกว่า Labels ซึ่งเป็นการสร้าง Text file ที่มีจำนวนแถว เท่ากับจุดพิกัดสามมิติ ทุกแถวจะมีเลขกำกับชั้นข้อมูลที่ได้จำแนกไว้ โดยแบ่งชั้นข้อมูลออกเป็น 3 กลุ่มคือ ถนน หลุมบ่อและวัตถุอื่น ๆ โดยกำหนดตัวเลขกำกับในแถว เป็น 1, 2 และ 3 โดยที่เลข 1 หมายถึงถนน เลข 2 หมายถึงพื้นผิวถนนและเลข 3 หมายถึงวัตถุอื่น ๆ ในกระบวนการจำแนก จุดอ้างอิงภาคพื้นดิน ใช้ซอฟต์แวร์ Autodesk Recap Pro ในการแบ่งกลุ่มจุดพิกัดสามมิติ และใช้ ซอฟต์แวร์ Matlab สร้างไฟล์ Labels จากกลุ่มข้อมูลอ้างอิงที่ได้จำแนกไว้

การกำหนด Label ของถนนแบ่งตามขอบทางที่สังเกตเห็นได้ชัดเจน รวมถึงถนนที่เป็น ซอยเล็ก ๆ ที่อยู่ทางด้านซ้ายและด้านขวาของทางหลัก ในส่วนของหลุมบ่อจะกำหนดขอบเขตหลุมบ่อ จากขอบหลุมที่สังเกตเห็นได้ชัดเจนจากสี RGB ของจุดพิกัดสามมิติ ถ้าหากมีหลุมบ่อที่มีขอบเขตไม่ ชัดเจนจากสี RGB ผู้จัดทำจะแสดงผลจุดพิกัดสามมิติโดยอ้างอิงตามค่าระดับ และใช้ค่าต่างระดับของ หลุมบ่อกับพื้นผิวถนนเป็นตัวกำหนดขอบเขตหลุมบ่อ ในงานวิจัยนี้ไม่รวมการจำแนกการชำระดู เสียหายของถนนประเภทอื่น ๆ ที่ไม่มีการเปลี่ยนแปลงของค่าระดับเช่น รอยปะซ่อม รอยแตกของผิว ถนน ผิวถนนหลุมบ่อ และในส่วนสุดท้ายการกำหนด Label ของวัตถุอื่น ๆ จะจำแนกวัตถุอื่น ๆ ทั้งหมดที่ไม่ใช่ถนนและหลุมบ่อเช่น ข้อมูลจุดของรถที่วิ่งอยู่บนถนน สายไฟและต้นไม้ที่อยู่เหนือถนน และวัตถุอื่น ๆ ที่อยู่บริเวณสองข้างของถนน


### 3.4.4 การฝึกสอนและการทดสอบ

โมเดลจากการฝึกสอนของโครงข่ายสามารถจำแนกวัตถุได้แม่นยำกับข้อมูลที่ไม่เคยเห็น มาก่อนเป็นเป้าหมายสำคัญของการพัฒนาโครงข่าย เพราะถ้าโมเดลสามารถจำแนกได้แม่นยำเฉพาะ กับข้อมูลที่เห็นมาก่อน แสดงว่าโครงข่ายไม่ได้เกิดการเรียนรู้ข้อมูลที่แตกต่างจากเดิม การสอนและ การทดสอบเป็นสิ่งสำคัญที่จะทำให้โครงข่ายเกิดการเรียนรู้และสร้างโมเดลที่ดีที่สุดในการคาดการณ์

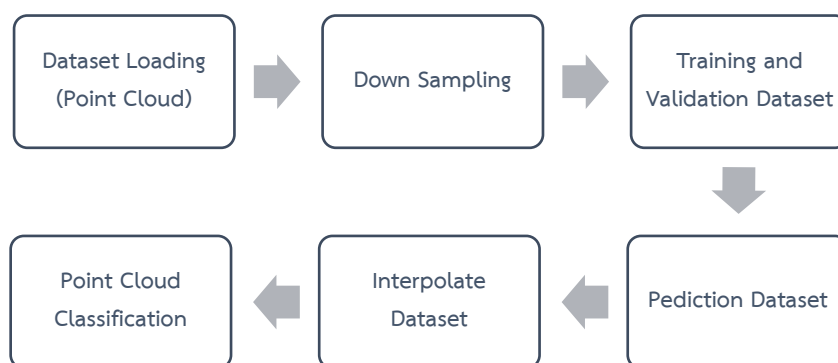
ข้อมูลที่ไม่เคยเห็นมาก่อน ในการทำงานต้องมีการกำหนดเงื่อนไขและพารามิเตอร์ที่เหมาะสมกับข้อมูลที่ต้องการจำแนก ในงานวิจัยจะแบ่งข้อมูลออกเป็น 3 ส่วนคือ

- 1) Training set เป็นข้อมูลจุดพิกัดสามมิติกลุ่มตัวอย่างที่ใช้ฝึกสอนโครงข่ายให้มีความสามารถในการจำแนกและจดจำคุณลักษณะของข้อมูล เป็นการบอกโครงข่ายให้สร้างโมเดลที่จำแนกข้อมูลตามกลุ่มตัวอย่างตามที่ข้อมูลกลุ่มตัวอย่างกำหนดไว้
- 2) Validation set เป็นข้อมูลกลุ่มตัวอย่างอีกชุดที่มีไว้ให้โมเดลที่ได้จากการฝึกสอนใช้ทดสอบการจำแนกและนำผลที่ได้ไปปรับแก้โมเดลให้ดียิ่งขึ้น
- 3) Testing set เป็นชุดข้อมูลที่ต้องการให้โมเดลทดสอบจริงในการจำแนกข้อมูล ซึ่งเป็นข้อมูลที่ไม่เคยรู้จักมาก่อน ถ้าหากโมเดลมีประสิทธิภาพจะจำแนกข้อมูลทดสอบได้ดี มีความถูกต้องสูง

การแบ่งข้อมูลเพื่อใช้ฝึกสอน ทดสอบและจำแนกส่วนใหญ่จะมีการแบ่งข้อมูลเป็น 80:10:10, 70:15:15 และ 60:20:20 (Baheti, 2022) ในงานศึกษาวิจัยนี้ข้อมูลจุดพิกัดสามมิติที่ได้จาก MMS มีระยะทางประมาณ 4 กิโลเมตร จะแบ่งเป็นข้อมูลใช้ฝึกสอน Training Dataset ระยะทาง 2500 เมตร ข้อมูลสำหรับการทดสอบ Validation Dataset ระยะทาง 500 เมตร และข้อมูลทดสอบจำแนก Test Dataset ระยะทาง 1000 เมตร ดังแสดงในรูปที่ 3-12 โดยวิธีการประมวลผลโครงข่ายเพื่อจำแนกข้อมูลจุดพิกัดสามมิติมีขั้นตอนและรายละเอียดดังแสดงในรูปที่ 3-13



รูปที่ 3-12 แสดงการแบ่ง Dataset สำหรับการฝึกสอน ทดสอบและการทดสอบจำแนกจริง



รูปที่ 3-13 ขั้นตอนการประมวลผลจำแนกข้อมูลจุดพิกัดสามมิติ

Dataset Loading เป็นการนำเข้าข้อมูลจุดพิกัดสามมิติจาก MMS และข้อมูล Labels ในรูปแบบ Text File จากนั้นทำการแปลงข้อมูลให้อยู่ในรูปแบบมาตรฐานของจุดพิกัดสามมิติ ที่รองรับการอ่านในโปรแกรมภาษา Python นั่นคือรูปแบบ PCD (Point Cloud Data) ไฟล์ทั้งหมด จะแบ่งเป็น 3 ชุดคือ Training Dataset, Validation Dataset และ Test Dataset

Down Sampling เป็นการกรองข้อมูลจุดพิกัดสามมิติให้ข้อมูลมีความหนาแน่นของจุด น้อยลงเพื่อลดระยะเวลาในการประมวลผล ขนาดข้อมูลที่กรองออกไปต้องคำนึงถึงวัตถุที่ต้องการ จำแนก ถ้าหากกรองข้อมูลมากเกินไป อาจส่งผลต่อความถูกต้องของการจำแนกได้ ในงานวิจัยนี้ มีวัตถุประสงค์จำแนกหลุมบ่อซึ่งมีขนาดเล็กและรูปทรงไม่ค่อยชัดเจนดังนั้น จำเป็นต้องกรองข้อมูล ออกเพียงเล็กน้อยเท่านั้นเพื่อให้การจำแนกยังคงมีประสิทธิภาพดังแสดงในรูปที่ 3-14



รูปที่ 3-14 แสดงข้อมูลด้านซ้ายก่อนกรองข้อมูล ด้านขวาหลังจากกรองข้อมูล



Training and Validation เป็นการนำข้อมูลชุด Training Dataset และ Validation Dataset เข้าสู่กระบวนการฝึกสอนและทดสอบ ซึ่งระบบทำการฝึกสอนข้อมูล Training Dataset จนได้โมเดลที่ดี จากนั้นระบบจะใช้ข้อมูล Validation Dataset ในการทดสอบจำแนกข้อมูลจากโมเดล และนำผลการทดสอบไปปรับแก้โมเดลใหม่ จะทำซ้ำไปจนได้ค่าความถูกต้องในการจำแนกที่พอใจและใช้โมเดลที่ดีที่สุดจำแนกข้อมูล Test Dataset ซึ่งเป็นข้อมูลที่โมเดลไม่รู้จำมาก่อน

Prediction Dataset เป็นการนำโมเดลที่ดีที่สุดที่ได้จากการฝึกสอนและทดสอบ จำแนกข้อมูล Test Dataset ที่โมเดลไม่เคยรู้จักมาก่อน ซึ่งเป็นการทดสอบคุณภาพของโมเดลถึงประสิทธิภาพในการจำแนกจุดพิกัดสามมิติ ซึ่งโดยทั่วไปประสิทธิภาพจะไม่ดีเท่าชุดข้อมูลที่ใช้ตรวจสอบ (Validation Dataset) เนื่องจากข้อมูล Test Dataset เป็นข้อมูลที่โมเดลไม่เคยรู้จัก

Interpolate Dataset เป็นการนำชุดข้อมูลที่ได้จากการจำแนกด้วยโมเดล สร้างจุดพิกัดสามมิติให้มีความหนาแน่นเพิ่มขึ้น โดยการอ้างอิงจากข้อมูลจุดพิกัดสามมิติเดิมก่อนทำการกรองข้อมูลข้อมูลที่ทำ Down sampling ทำให้ข้อมูลเบาบางลงเพื่อลดปริมาณข้อมูลให้น้อยลงเพื่อให้การจำแนกรวดเร็วยิ่งขึ้น จะมีจุดหนาแน่นกลับมาเหมือนเดิมหลังจากที่ได้ทำ Interpolation

Point Cloud Classification เป็นข้อมูลจุดพิกัดสามมิติจากข้อมูล Test Dataset ที่ผ่านการจำแนกข้อมูลด้วยโมเดลที่ได้รับการฝึกสอนและทดสอบ ข้อมูลแบ่งตามชั้นข้อมูลที่ได้รับการจำแนก ซึ่งผลลัพธ์จะสามารถนำไปประยุกต์ใช้งานต่าง ๆ ได้

### 3.5 การทดสอบความถูกต้องของข้อมูลและการทดสอบประสิทธิภาพการจำแนก

#### 3.5.1 การทดสอบความถูกต้องของจุดพิกัดสามมิติ

- ทดสอบความความถูกต้องของจุดพิกัดสามมิติจากการสำรวจด้วย MMS กรณีที่ยังไม่ได้ปรับแก้ด้วย GCP โดยใช้จุด GCP และ CP ทั้งหมดเป็นจุดตรวจสอบ ประเมินความถูกต้องตามมาตรฐาน NSSDA โดยทดสอบความถูกต้องที่ระดับความเชื่อมั่นร้อยละ 95

- ทดสอบความความถูกต้องของจุดพิกัดสามมิติจากการสำรวจด้วย MMS หลังจากปรับแก้ด้วย GCP จำนวน 6 จุด ตรวจสอบความถูกต้องโดยใช้จุด CP จำนวน 6 จุด ประเมินความถูกต้องตามมาตรฐาน NSSDA โดยทดสอบความถูกต้องที่ระดับความเชื่อมั่นร้อยละ 95

### 3.5.2 การทดสอบประสิทธิภาพของการจำแนกข้อมูลจุดพิกัดสามมิติ

- การทดสอบประสิทธิภาพการจำแนกของโมเดลจากการฝึกสอนโครงข่าย ด้วยการสร้างเมทริกซ์ความคลาดเคลื่อน เปรียบเทียบผลการจำแนกข้อมูลที่ทดสอบจำแนกจริง ค่าความถูกต้องของการจำแนกในแต่ละแถวของเมทริกซ์ความคลาดเคลื่อนแทนจำนวนข้อมูลที่ถูกต้องถูกจำแนกเป็นชั้นข้อมูลนั้น

- เปรียบเทียบความถูกต้องของผลการจำแนกข้อมูลทดสอบจริงที่ได้จากโมเดลที่ฝึกสอนกับข้อมูลอ้างอิง โดยคำนวณค่าความถูกต้องโดยรวม ความถูกต้องของผู้ใช้ และความถูกต้องของผู้ผลิต และค่า IoU ของแต่ละชั้นข้อมูล

### 3.5.3 ทดสอบสมมติฐานทางสถิติสำหรับการประเมินความถูกต้องทั้ง 2 วิธี

การทดสอบสมมติฐานทางสถิติเพื่อต้องการเปรียบเทียบผลการจำแนกข้อมูลจุดพิกัดสามมิติแบบวิธีไม่มีค่า RGB กับวิธีนำเสนอที่มีค่า RGB โดยทดสอบหาค่าสถิติ Z จากผลการคำนวณค่าสัมประสิทธิ์แคปปาในตารางเมทริกซ์ความคลาดเคลื่อน ที่เพื่อวิเคราะห์ความแตกต่างของผลการจำแนกที่ได้จากทั้ง 2 วิธี (Congalton and Green, 2019) เพื่อทดสอบว่าการจำแนกวิธีเพิ่มค่า RGB มีความถูกต้องมากกว่าอย่างมีนัยสำคัญ

## บทที่ 4

### ผลการดำเนินงานวิจัย

#### 4.1 ผลการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่

ผลการสำรวจจัดเก็บข้อมูลพื้นที่ศึกษา มีระยะทางประมาณ 4 กิโลเมตร ใช้ความเร็วเฉลี่ย 30 กิโลเมตรต่อชั่วโมง ข้อมูล GNSS รับสัญญาณดาวเทียมเฉลี่ย 12 ดวง (GPS+GLONASS) สถานีฐานอ้างอิงตำแหน่งหมุด GNSS 610373 รับสัญญาณดาวเทียม เฉลี่ย 19 ดวง (GPS+GLONASS) ระบบ MMS ใช้วิธี Post Process Kinematic (PPK) ประมวลผลตำแหน่งเส้นทาง ในส่วนของข้อมูลการสแกนระบบได้บันทึกค่าในอัตรา 2.11 mb/s และบันทึกภาพถ่าย 6 กล้องพร้อมกันทุกระยะ 5 เมตร มีการรับส่งข้อมูลเข้าสู่ระบบคอมพิวเตอร์ในอัตรา 27 mb/s ผลการสำรวจภาคสนามด้วยระบบ MMS ต้องนำข้อมูล Raw Data ประมวลผลด้วยซอฟต์แวร์ Magnet Collage เพื่อนำออกจุดพิกัดสามมิติใช้ในการจำแนกข้อมูล

ตามขั้นตอนการประมวลผลทั้งหมดที่ได้กล่าวไว้ในบทที่ 3 ผลลัพธ์ที่นำออกมาจากระบบ MMS คือข้อมูลจุดพิกัดสามมิติ เป็นข้อมูลที่ได้จากการสแกนด้วยเลเซอร์ ซึ่งตามคุณสมบัติของอุปกรณ์สามารถสแกนจุดได้ 700,000 จุดต่อวินาที ผลลัพธ์ของจุดพิกัดสามมิติที่ได้จาก MMS มีจำนวนมากถึง 282 ล้านจุด มีความละเอียดเชิงพื้นที่มากพอที่จะจำแนกหลุมบ่อของถนนได้ จุดพิกัดสามมิติจาก MMS มีการนำค่าสีภาพจากกล้องถ่ายภาพ 6 กล้องที่ประมวลผลเป็นรูปแบบภาพพาโนรามา 360 องศา ดังแสดงในรูปที่ 4-1 ดังนั้นจุดพิกัดสามมิติจากการสแกนจะรวมค่าสีของภาพถ่ายพาโนรามา 360 องศาเข้าด้วยกัน ซึ่งค่าสีภาพในจุดพิกัดสามมิติจะช่วยให้ข้อมูลมีความสมจริงและใช้เพิ่มมิติข้อมูลจำแนกวัตถุจากจุดพิกัดสามมิติได้ ดังแสดงในรูปที่ 4-2



รูปที่ 4-1 ภาพถ่ายสีแบบพานอรามา 360 องศา จากระบบ MMS



รูปที่ 4-2 แสดงข้อมูลจุดพิกัดสามมิติตามค่าสีจากภาพถ่าย

#### 4.2 ผลการตรวจสอบความถูกต้องของจุดพิกัดสามมิติ

การสำรวจด้วย MMS เป็นการสำรวจที่อ้างอิงบนระบบพิกัดแผนที่ จุดพิกัดสามมิติทุกจุดมีค่าพิกัดระบบแผนที่ ดังนั้นการประเมินความถูกต้องเชิงตำแหน่งทำให้ทราบถึงความน่าเชื่อถือของข้อมูล และประเมินความเหมาะสมในการนำไปใช้งานได้ การประเมินความถูกต้องแบ่งเป็น 2 กรณีคือ ทดสอบความถูกต้องของจุดพิกัดสามมิติจาก MMS ที่ไม่ได้ปรับแก้ด้วย GCP และที่ปรับแก้ด้วย GCP ในกรณีไม่ได้ปรับแก้ทดสอบด้วยการใช้จุด GCP และ CP ทั้งหมดจำนวน 12 จุดที่กำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK ดังแสดงค่าพิกัดในตารางที่ 4-1 ทดสอบความถูกต้องของข้อมูล

ตารางที่ 4-1 แสดงค่าพิกัดของจุด GCP และ CP

Point Name	Easting	Northing	Elevation	Status
GCP01	643014.067	1535060.476	2.464	GCP
GCP02	642343.200	1534931.149	2.427	GCP
GCP03	641915.275	1534889.441	2.411	GCP
GCP04	641285.618	1534831.523	2.435	GCP
GCP05	640672.423	1534745.304	2.425	GCP
GCP06	640208.819	1534543.590	2.370	GCP
CP01	643023.257	1535057.394	2.384	CP
CP02	642339.195	1534934.387	2.286	CP
CP03	641918.922	1534885.807	2.347	CP
CP04	641288.220	1534835.517	2.326	CP
CP05	640719.840	1534748.531	2.253	CP
CP06	640204.969	1534546.029	2.290	CP

เมื่อทดสอบใช้จุด GCP และ CP ตรวจสอบความถูกต้องของจุดพิกัดสามมิติที่ได้จาก MMS ก่อนทำการปรับแก้ด้วย GCP พบว่าค่า RMSE<sub>r</sub> ทางราบอยู่ที่ 0.084 เมตร และ RMSE ในทางตั้งอยู่ที่ 0.123 เมตร ดังแสดงในตารางที่ 4-2 แสดงให้เห็นว่าระบบ MMS มีความถูกต้องที่อยู่ในเกณฑ์ที่ดี ในทางราบ ส่วนทางตั้งมีค่าความคลาดเคลื่อนค่อนข้างสูง เมื่อนำผลทดสอบความถูกต้องประเมิน ตามมาตรฐานของ National Standard for Spatial Data Accuracy (NSSDA) ตรวจสอบตาม เกณฑ์ความถูกต้องในระดับความเชื่อมั่นที่ร้อยละ 95 แบบสามมิติ โดยใช้สูตรสมการที่ 2-5 ผลปรากฏว่าค่าระดับความเชื่อมั่นที่ร้อยละ 95 มีค่าเท่ากับ 0.241 เมตร ซึ่งเมื่อเทียบชั้นของงานตาม มาตรฐาน NSSDA ของข้อมูลจุดพิกัดสามมิติ ผลปรากฏว่าข้อมูลอยู่ในเกณฑ์งานชั้นที่ 3 ซึ่งมีค่าอยู่ ระหว่าง 0.2 – 1 เมตร ซึ่งความเหมาะสมของงานที่จำนวนจุดมากกว่า 100 จุดต่อตารางเมตรใน เกณฑ์งานชั้นที่ 3 คือการประเมินสภาพทั่วไปของถนน การจัดการสินทรัพย์และงานวางแผน (Olsen et al., 2013)

ตารางที่ 4-2 แสดงผลทดสอบความถูกต้องของจุดพิกัดสามมิติก่อนปรับแก้ด้วย GCP

MMS Point	E	N	Z	Check Point	E	N	Z	ΔE	ΔN	ΔZ
Point-001	643014.027	1535060.560	2.617	GCP01	643014.067	1535060.476	2.464	-0.040	0.084	0.153
Point-002	642343.320	1534931.105	2.564	GCP02	642343.200	1534931.149	2.427	0.120	-0.044	0.137
Point-003	641915.274	1534889.492	2.498	GCP03	641915.275	1534889.441	2.411	-0.001	0.051	0.087
Point-004	641285.648	1534831.553	2.485	GCP04	641285.618	1534831.523	2.435	0.030	0.030	0.050
Point-005	640672.489	1534745.297	2.313	GCP05	640672.423	1534745.304	2.425	0.066	-0.007	-0.112
Point-006	640208.842	1534543.623	2.482	GCP06	640208.819	1534543.590	2.370	0.023	0.033	0.112
Point-007	643023.178	1535057.515	2.521	CP01	643023.257	1535057.394	2.384	-0.079	0.121	0.137
Point-008	642339.279	1534934.383	2.477	CP02	642339.195	1534934.387	2.286	0.084	-0.004	0.191
Point-009	641918.932	1534885.868	2.422	CP03	641918.922	1534885.807	2.347	0.010	0.061	0.075
Point-010	641288.313	1534835.496	2.379	CP04	641288.220	1534835.517	2.326	0.093	-0.021	0.053
Point-011	640719.895	1534748.538	2.073	CP05	640719.840	1534748.531	2.253	0.055	0.007	-0.180
Point-012	640205.029	1534546.069	2.372	CP06	640204.969	1534546.029	2.290	0.060	0.040	0.082
Mean Error (m)								0.035	0.029	0.065
Standard Deviation (m)								0.057	0.047	0.108
RMSE (m)								0.065	0.053	0.123
RMSE <sub>r</sub> (m)								0.084		
NSSDA Horizontal Accuracy at 95% Confidence Level								0.145		
NSSDA Vertical Accuracy at 95% Confidence Level								0.240		
NSSDA Horizontal and Vertical Accuracy at 95% Confidence Level								0.241		

จากตารางที่ 4-2 จะเห็นได้ว่าข้อมูลจุดพิกัดสามมิติบางจุดมีค่าความคลาดเคลื่อนค่อนข้างสูง ทั้งในทางราบและทางตั้ง สาเหตุอาจเกิดขึ้นจากคลื่นหลายวิถี (Multipath error) หรือความไม่แน่นอนในองค์ประกอบด้านเรขาคณิตของดาวเทียม Geometric Dilution of Precision (GDOP) ที่เกิดขึ้นในขณะที่มีการขยับยานพาหนะในพื้นที่มีอาคารและต้นไม้สูง รวมถึงพื้นที่ศึกษาที่มีการขรุขระของถนนเกิดเป็นหลุมบ่อค่อนข้างมาก อาจทำให้เกิดการเอียงตัวและแรงกดทับของยานพาหนะ ทำให้ค่าชดเชยของระบบมีความคลาดเคลื่อนสูง การปรับแก้ด้วย GCP มีความจำเป็นหากต้องการเพิ่มความถูกต้องให้กับข้อมูลก่อนนำไปประยุกต์ใช้งานต่อไป

การปรับแก้จุดพิกัดสามมิติที่ได้จากการสำรวจด้วย MMS โดยใช้ GCP ทำให้ค่าพิกัดตำแหน่งมีความถูกต้องมากยิ่งขึ้น ซึ่งวิธีการตรวจสอบที่ดี ควรมีจุดตรวจสอบ (CP) เพื่อประเมินความถูกต้องของจุดพิกัดสามมิติ หลังจากปรับแก้ด้วย GCP ทั้ง 6 จุดแล้ว จุด CP เป็นสิ่งสำคัญในการตรวจสอบความถูกต้อง เนื่องจากเป็นจุดที่ถูกสุ่มเลือกมาจากจุดใด ๆ ในจุดพิกัดสามมิติ เพื่อเช็คความถูกต้องโดยรวมของข้อมูลจุดพิกัดสามมิติหลังจากที่ได้รับการปรับแก้แล้ว จะเห็นได้ว่าค่าความคลาดเคลื่อนลดลงหลังจากปรับแก้ด้วย GCP ดังแสดงในตารางที่ 4-3

ตารางที่ 4-3 แสดงผลทดสอบความถูกต้องของจุดพิกัดสามมิติหลังปรับแก้ด้วย GCP

MMS Point	E	N	Z	Check Point	E	N	Z	$\Delta E$	$\Delta N$	$\Delta Z$
Point-013	643023.195	1535057.431	2.367	CP01	643023.257	1535057.394	2.384	-0.062	0.037	-0.017
Point-014	642339.206	1534934.426	2.351	CP02	642339.195	1534934.387	2.286	0.011	0.039	0.065
Point-015	641918.978	1534885.825	2.337	CP03	641918.922	1534885.807	2.347	0.056	0.018	-0.010
Point-016	641288.337	1534835.458	2.331	CP04	641288.220	1534835.517	2.326	0.117	-0.059	0.005
Point-017	640719.879	1534748.542	2.167	CP05	640719.840	1534748.531	2.253	0.039	0.011	-0.086
Point-018	640205.043	1534546.042	2.268	CP06	640204.969	1534546.029	2.290	0.074	0.013	-0.022
Mean Error (m)								0.039	0.010	-0.011
Standard Deviation (m)								0.061	0.036	0.049
RMSE (m)								0.068	0.034	0.046
RMSEr (m)								0.076		
NSSDA Horizontal Accuracy at 95% Confidence Level								0.132		
NSSDA Vertical Accuracy at 95% Confidence Level								0.090		
NSSDA Horizontal and Vertical Accuracy at 95% Confidence Level								0.089		

ผลการตรวจสอบความถูกต้องจากจุด CP ค่า RMSE<sub>r</sub> ทางราบเท่ากับ 0.076 เมตร และค่า RMSE ทางตั้งเท่ากับ 0.046 เมตร จะเห็นได้ว่าความถูกต้องในทางตั้งเพิ่มขึ้นอย่างเห็นได้ชัดหลังจากปรับแก้ด้วย GCP เมื่อทดสอบตามมาตรฐาน NSSDA ที่ระดับความเชื่อมั่นร้อยละ 95 แบบสามมิติ ตามสมการที่ 2-5 ความถูกต้องมีค่าเท่ากับ 0.089 เมตร ซึ่งอยู่ในเกณฑ์งานชั้นที่ 2 ที่มีความถูกต้องระหว่าง 0.05 - 0.20 เมตร ตามมาตรฐานสามารถนำไปใช้งานทางด้าน งานแผนที่ งานป้องกันอุบัติเหตุ ระบบขับเคลื่อนอัตโนมัติและการจำแนกข้อมูลแบบอัตโนมัติหรือกึ่งอัตโนมัติ (Olsen et al., 2013)

ผลทดสอบความถูกต้องของจุดพิกัดสามมิติจะเห็นว่าข้อมูลที่ไม่ได้ปรับแก้ด้วย GCP กับข้อมูลที่ปรับแก้ด้วย GCP ค่าความคลาดเคลื่อนทางราบมีค่าใกล้เคียงกัน แต่ค่าความคลาดเคลื่อนทางตั้งของข้อมูลที่ไม่ได้ปรับแก้ด้วย GCP มีค่าความคลาดเคลื่อนค่อนข้างสูง และที่สำคัญจุดพิกัดสามมิติมีการใช้งานในทั้งในทางราบและในทางตั้ง หากต้องการความถูกต้องของข้อมูลที่สูง ควรปรับแก้ด้วย GCP ทุกครั้งเพื่อให้ข้อมูลมีความถูกต้องเพิ่มขึ้น

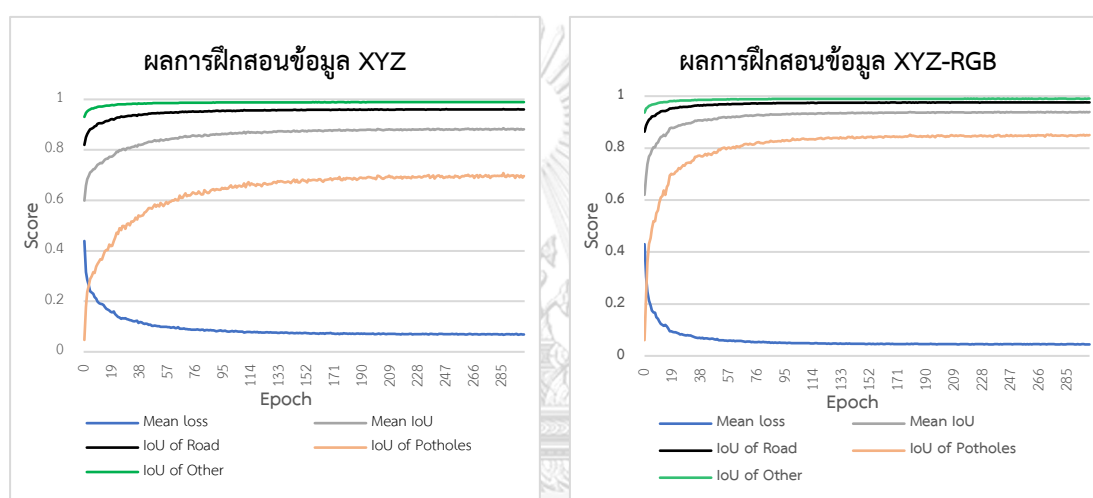
#### 4.3 ผลการจำแนกจุดพิกัดสามมิติด้วยโครงข่ายประสาทคอนโวลูชัน

##### 4.3.1 ผลการฝึกสอนโครงข่ายประสาทคอนโวลูชัน

งานวิจัยได้ใช้การสอนโครงข่ายจำนวน 300 รอบเท่านั้น เนื่องจากค่าความถูกต้องโดยรวมและค่าความสูญเสียเริ่มมีค่าคงที่ในการฝึกสอนในรอบที่ 200 เป็นต้นไปดังแสดงในรูปที่ 4-3 ซึ่งการฝึกสอนใช้เวลาในการประมวลผลรอบละประมาณ 30 นาที ค่าที่ได้จากการฝึกสอนโครงข่ายจะได้ค่าความสูญเสียเฉลี่ย (Mean Loss) ค่าความถูกต้องโดยรวม (Overall Accuracy) ค่าเฉลี่ย Intersection over Union (Mean IoU) และค่า IoU ของข้อมูลแต่ละชั้นที่ได้รับการฝึกสอน โดยผลจากการฝึกสอนครั้งนี้จะแบ่งข้อมูลออกเป็น 3 ชั้นคือหลุมบ่อ ถนนและวัตถุอื่น ๆ โดยการฝึกสอนจะแบ่งออกเป็น 2 วิธีคือ วิธีที่ใช้ข้อมูลจุดพิกัดสามมิติที่มีเฉพาะค่า XYZ และวิธีนำเสนอที่มีค่า XYZ กับค่า RGB ผลการฝึกสอนที่ดีที่สุดแสดงในตารางที่ 4-4 และผลการฝึกสอนในแต่ละรอบดังแสดงไว้ในรูปที่ 4-3 เมื่อเปรียบเทียบผลการฝึกสอนโครงข่ายจะเห็นได้ว่า วิธีนำเสนอการใช้ค่า RGB ในข้อมูลจุดพิกัดสามมิติ เพื่อฝึกสอนโครงข่ายทำให้เกิดการเรียนรู้การจำแนกข้อมูลที่ดีขึ้น ถึงแม้ว่าค่า IoU ของการจำแนกถนนและวัตถุอื่น ๆ จะมีผลใกล้เคียงกันก็ตาม แต่ค่าความสูญเสียเฉลี่ยและค่า IoU ของการจำแนกหลุมบ่อมีความแตกต่างอย่างมีนัยสำคัญ

ตารางที่ 4-4 แสดงผลการฝึกสอนโครงข่ายประสาทคอนโวลูชันของ Training Dataset

	XYZ	XYZ-RGB
Mean Loss	0.068	0.044
Overall Accuracy	0.989	0.992
Mean IoU	0.883	0.938
IoU of Potholes	0.698	0.848
IoU of Road	0.961	0.976
IoU of Other	0.989	0.990



รูปที่ 4-3 แสดงผลการฝึกสอนข้อมูลจุดพิกัดสามมิติแบบวิธีไม่มีค่า RGB และมีค่า RGB

จากผลการฝึกสอนโครงข่ายจากข้อมูลทั้ง 2 วิธี ผลการฝึกสอนที่ดีที่สุดวิธีที่ไม่มีค่า RGB ดังแสดงในตารางที่ 4-4 จะเห็นได้ว่าผลการฝึกสอนค่า IoU ของหลุมบ่อมีค่าอยู่ที่ 0.698 หรือประมาณร้อยละ 70 ซึ่งน้อยกว่าค่า IoU ของถนนและวัตถุอื่น ๆ ที่มีค่าเท่ากับ 0.961 และ 0.989 สามารถวิเคราะห์ได้ว่าการฝึกสอนโครงข่ายให้เรียนรู้การจำแนกหลุมบ่อเป็นสิ่งที่ทำได้ยากกว่าถนนและวัตถุอื่น ๆ เนื่องจากหลุมบ่อมีคุณลักษณะที่ไม่ชัดเจนและกลมกลืนกับพื้นผิวถนน ทำให้โครงข่ายสามารถเรียนรู้การจำแนกได้ไม่ดีเท่าถนนและวัตถุอื่น ๆ ในงานศึกษานี้ได้นำเสนอการใช้ค่าสีของภาพถ่ายที่เป็น RGB เข้าไปฝึกสอนโครงข่ายปรากฏว่าผลการฝึกสอนโครงข่ายมีค่าที่ดีขึ้น ค่าความสูญเสียเฉลี่ยลดลงจาก 0.068 เป็น 0.044 และค่า IoU ของหลุมบ่อมีค่าดีขึ้นจาก 0.698 เป็น 0.848 ส่วนค่าความถูกต้องโดยรวมกับค่า IoU ของถนนและวัตถุอื่น ๆ มีค่าค่อนข้างใกล้เคียงกัน จะเห็นได้ว่าเมื่อใช้ค่า RGB ในการฝึกสอนโครงข่ายช่วยให้ความถูกต้องเพิ่มขึ้น โดยเฉพาะค่า IoU ของหลุมบ่อ



เมื่อเปรียบเทียบค่าความถูกต้องจากการฝึกสอนทั้ง 2 วิธีโดยใช้การทดสอบทางสถิติ Z เพื่อทดสอบความแตกต่างของผลการฝึกสอนดังแสดงในตารางที่ 4-5 ค่าวิกฤตของการทดสอบอยู่ในช่วง  $-1.96$  ถึง  $1.96$  ที่ระดับนัยสำคัญที่  $0.05$  โดยผลการทดสอบค่า Z จะเห็นว่าค่าอยู่นอกช่วงของค่าวิกฤตทั้งหมด แสดงว่าผลการฝึกสอนจากข้อมูลทั้งสองกลุ่มมีความแตกต่างกันอย่างมีนัยสำคัญ และความถูกต้องของผลการฝึกสอนชุดข้อมูลที่มีค่า RGB ให้ความถูกต้องที่สูงกว่า

ตารางที่ 4-5 ผลทดสอบความแตกต่างของการฝึกสอนโครงข่ายด้วยสถิติ Z จากข้อมูลทั้งสองกลุ่ม

ค่าทดสอบ	ค่าสถิติ Z	ค่าวิกฤต
Mean Loss	-10.01	
Overall Accuracy	8.68	
Mean IoU	20.56	-1.96 - 1.96
IoU of Potholes	14.62	
IoU of Road	22.61	
IoU of Other	3.08	

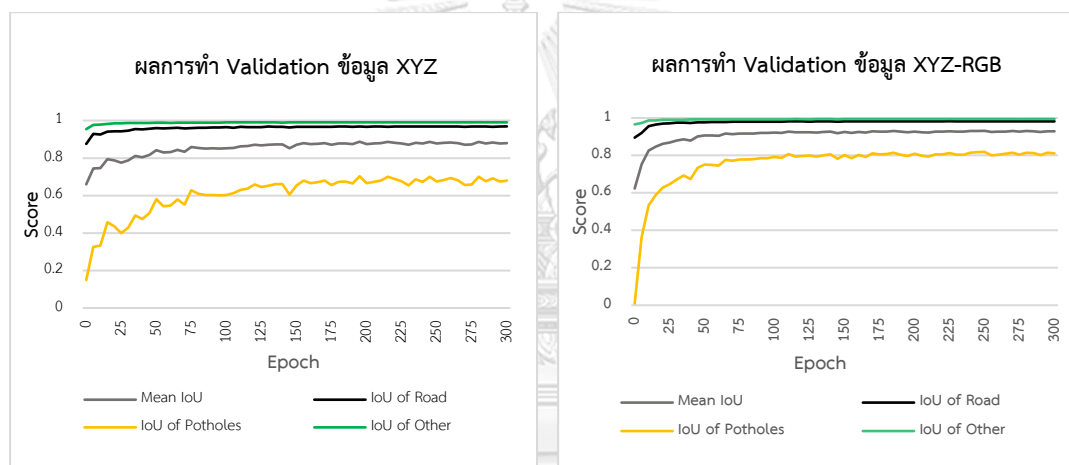
#### 4.3.2 ผลการทดสอบโครงข่ายประสาทคอนโวลูชัน

เมื่อมีการฝึกสอนข้อมูล Training Dataset ครบทุก 5 รอบจะมีการทดสอบการจำแนกด้วยชุดข้อมูล Validation Dataset 1 ครั้งเพื่อจัดเก็บโมเดลไว้จำแนกข้อมูลทดสอบจำแนกจริง โดยที่ระบบจะจัดเก็บโมเดลที่มีค่าทดสอบที่ดีกว่ารอบก่อนหน้าเท่านั้น ผลการทดสอบจะได้ค่าความถูกต้องโดยรวม (Overall Accuracy) ค่าเฉลี่ย Intersection over Union (Mean IoU) และค่า IoU ของข้อมูลแต่ละชั้นที่ได้รับการทดสอบ โดยผลการทดสอบที่ดีที่สุดดังแสดงในตารางที่ 4-6 และผลการทดสอบทุก 5 รอบจากการฝึกสอนดังแสดงในรูปที่ 4-4 จะเห็นได้ว่าผลการทดสอบในรอบที่ดีที่สุด ความถูกต้องเป็นไปในทิศทางเดียวกับผลการฝึกสอนคือ วิธีนำเสนอที่มีค่า RGB ให้ค่าความถูกต้องที่สูงกว่าวิธีที่ไม่มีค่า RGB โดยเฉพาะค่า IoU ของหลุมบ่อ จากวิธีที่ไม่มี RGB ค่า IoU อยู่ที่  $0.700$  และวิธีนำเสนอที่มีค่า RGB ค่า IoU อยู่ที่  $0.813$  ซึ่งผลการทดสอบจะเห็นว่าวิธีไม่มีค่า RGB มีค่าทดสอบใกล้เคียงกับผลการฝึกสอน ส่วนวิธีนำเสนอมีค่า RGB ให้ผลที่ทดสอบความถูกต้องลดลงจากการฝึกสอนอยู่ที่ร้อยละ  $3.5$  แต่ผลทดสอบวิธีนำเสนอยังให้ค่าความถูกต้องในการทดสอบมากกว่าวิธีไม่มี RGB ส่วนค่า IoU การทดสอบของถนนและวัตถุอื่น ๆ ให้ค่าใกล้เคียงกับการฝึกสอนในทั้ง 2 วิธี แต่พบว่าค่าทดสอบมีค่าที่ดีกว่าเล็กน้อยไม่ถึงร้อยละ  $1$  สาเหตุอาจเกิดจาก

ข้อมูลชุด Validation Dataset มีระยะทางที่สั้น ข้อมูลในการทดสอบมีจำนวนที่น้อยทำให้โมเดลทดสอบค่าออกมาใกล้เคียงและดีกว่าผลจากการฝึกสอนอยู่เล็กน้อย

ตารางที่ 4-6 แสดงผลการทดสอบโครงข่ายคอนโวลูชันของ Validation Dataset

	XYZ	XYZ-RGB
Overall Accuracy	0.991	0.994
Mean IoU	0.886	0.930
IoU of Potholes	0.700	0.813
IoU of Road	0.968	0.983
IoU of Other	0.991	0.993



รูปที่ 4-4 แสดงผลการทดสอบข้อมูลจุดพิกัดสามมิติแบบไม่มีค่า RGB และมีค่า RGB


เมื่อนำผลการทดสอบการจำแนกด้วยชุดข้อมูล Validation Dataset เปรียบเทียบความแตกต่างของผลทดสอบจากวิธีไม่มีค่า RGB กับวิธีนำเสนอมีค่า RGB ด้วยการทดสอบทางสถิติ Z ผลการทดสอบทั้งหมดดังแสดงในตารางที่ 4-7 จะพบว่าข้อมูลทั้งสองกลุ่มให้ผลที่แตกต่างกัน โดยค่า Z ไม่ได้อยู่ในช่วงของค่าวิกฤต  $-1.96$  ถึง  $1.96$  ที่ระดับนัยสำคัญ  $0.05$  และค่าของวิธีที่มีค่า RGB ให้ความถูกต้องในการทดสอบที่ดีกว่า

ตารางที่ 4-7 ผลทดสอบความแตกต่างของการทดสอบโครงข่ายด้วยสถิติ Z จากข้อมูลทั้งสองกลุ่ม

ค่าทดสอบ	ค่าสถิติ Z	ค่าวิกฤต
Overall Accuracy	3.66	
Mean IoU	6.84	
IoU of Potholes	6.46	-1.96 – 1.96
IoU of Road	6.95	
IoU of Other	4.03	

#### 4.3.3 ผลทดสอบการจำแนก


ผลทดสอบการจำแนกจริงในชุดข้อมูล Test Dataset ซึ่งเป็นชุดข้อมูลที่โมเดลไม่รู้จักมาก่อน เพื่อทดสอบประสิทธิภาพการเรียนรู้ของโครงข่าย ข้อมูลจุดพิกัดสามมิติมีระยะทางประมาณ 1 กิโลเมตร มีจำนวนจุดประมาณ 72 ล้านจุด จำแนกด้วยโมเดลที่ดีที่สุดจากการฝึกสอนและทดสอบโครงข่าย ผลทดสอบการจำแนกจริงทั้งวิธีไม่มีค่า RGB และวิธีนำเสนอมีค่า RGB ดังแสดงในรูปที่ 4-5 การจำแนกโดยรวมทำได้ดีในชั้นข้อมูลถนนและวัตถุอื่น ๆ การจำแนกจากทั้ง 2 วิธีมีความใกล้เคียงกัน แต่วิธีไม่มี RGB จะพบว่ามี การจำแนกพื้นผิวถนนผิดพลาดมากกว่า โดยจะมีบางช่วงของข้อมูลที่โมเดลจำแนกวัตถุอื่น ๆ เป็นพื้นผิวถนนด้วยเช่นกัน ส่วนผลการจำแนกหลุมบ่อสามารถจำแนกได้ค่อนข้างดี แต่ความถูกต้องยังน้อยกว่าชั้นข้อมูลถนนและวัตถุอื่น ๆ โดยผลจำแนกหลุมบ่อวิธีมีค่า RGB สามารถจำแนกได้ใกล้เคียงกับข้อมูล Label มากกว่าดังแสดงในรูปที่ 4-6




รูปที่ 4-5 แสดงผลการจำแนกข้อมูลจากทั้ง 2 วิธี




(a)



(b)



(c)



(d)

รูปที่ 4-6 ผลการการจำแนกข้อมูล (a) ข้อมูลจุดพิกัดสามมิติ (b) ข้อมูล Label ของจุดพิกัดสามมิติ (c) ผลการจำแนกจุดพิกัดสามมิติวิธี XYZ (d) ผลการจำแนกจุดพิกัดสามมิติวิธี XYZ-RGB

ผลการวัดประสิทธิภาพของการจำแนกโดยประเมินจากค่า IoU ของแต่ละชั้นข้อมูล ดังแสดงในตารางที่ 4-8 ค่าเฉลี่ย IoU ของวิธีที่ไม่มีค่า RGB มีค่าเท่ากับร้อยละ 82.6 ส่วนวิธีนำเสนอที่มีค่า RGB มีค่าเท่ากับร้อยละ 85.8 โดยค่า IoU ของถนนและวัตถุอื่น ๆ ของทั้ง 2 กลุ่มข้อมูลให้ค่าที่ใกล้เคียงกันประมาณร้อยละ 94.1 - 95.5 ส่วนค่า IoU ของหลุมบ่อมีผลลัพธ์ที่แตกต่างกัน วิธีไม่มี RGB มีค่าเท่ากับร้อยละ 59.5 และวิธีนำเสนอมีค่า RGB มีค่าเท่ากับร้อยละ 66.7 ซึ่งสอดคล้องกับผลการฝึกสอนและทดสอบ ที่วิธีนำเสนอมีค่า RGB ได้ฝึกสอนและทดสอบผลได้ดีกว่าวิธีไม่มีค่า RGB ถึงแม้ว่าผลการทดสอบการจำแนกจริงกับข้อมูลที่โครงข่ายไม่รู้จักมาก่อนจะมีค่า IoU ลดลงจากการทดสอบถึงร้อยละ 10.5 จากวิธีไม่มี RGB และลดลงร้อยละ 14.6 จากวิธีนำเสนอที่มี RGB ส่วนผลการทดสอบจำแนกข้อมูลจริงในชั้นข้อมูลที่เป็นถนนและวัตถุอื่น ๆ สามารถทำได้ดีจากทั้ง 2 วิธี

ตารางที่ 4-8 ตารางแสดงค่า IoU ของผลการจำแนกข้อมูลทั้ง 2 กลุ่ม

	XYZ	XYZ-RGB
Mean IoU	0.826	0.858
IoU of Potholes	0.595	0.667
IoU of Road	0.942	0.954
IoU of Other	0.941	0.954

การแจกแจงผลการจำแนกข้อมูลจุดพิกัดสามมิติใน Confusion Matrix เพื่อวัดประสิทธิภาพของการจำแนกทั้ง 2 วิธี ผลการจำแนกวิธีไม่มี RGB ให้ค่าความถูกต้องโดยรวมอยู่ที่ร้อยละ 96.8 และมีค่าความสอดคล้องการจำแนกโดยคำนวณจากค่าสัมประสิทธิ์แคปปามีค่าเท่ากับ 0.94 ดังแสดงในตารางที่ 4-9 และผลการจำแนกวิธีนำเสนอมีค่า RGB ให้ค่าความถูกต้องโดยรวมอยู่ที่ร้อยละ 97.5 และมีค่าสัมประสิทธิ์แคปปาที่ 0.95 ดังแสดงในตารางที่ 4-10 จะเห็นได้ว่าค่าความถูกต้องโดยรวมจากการจำแนกจุดพิกัดสามมิติวิธีนำเสนอมีค่า RGB ให้ค่าที่สูงกว่าวิธีไม่มี RGB อยู่เล็กน้อย จากร้อยละ 96.8 ไปเป็นร้อยละ 97.50 เช่นเดียวกับค่าความถูกต้องผู้ผลิต (PA) และค่าความถูกต้องผู้ใช้ (UA) ที่ผลการจำแนกจุดพิกัดสามมิติวิธีนำเสนอมีค่า RGB มีค่าความถูกต้องเพิ่มขึ้น ตารางที่ 4-9 แสดง Confusion matrix ของการจำแนกข้อมูลแบบไม่มีค่า RGB

Point Cloud Classification without RGB					
Classes	Ground Truth			Total	UA, %
	Potholes	Road	Other		
Potholes	510197	164134	24202	698533	73.0
Road	157417	37435563	1673580	39266560	95.3
Other	1533	301056	31676656	31979245	99.1
Total	669147	37900753	33374438	71944338	
PA, %	76.3	98.8	94.9		
Overall Accuracy	96.8%				
Kappa	0.94				

ตารางที่ 4-10 แสดง Confusion matrix ของการจำแนกข้อมูลแบบมีค่า RGB

Point Cloud Classification with RGB					
Classes	Ground Truth			Total	UA, %
	Potholes	Road	Other		
Potholes	533176	129340	1342	663858	80.3
Road	135651	37580084	1342928	39058663	96.2
Other	320	191329	32030168	32221817	99.4
Total	669147	37900753	33374438	71944338	
PA, %	79.7	99.2	96.0		
Overall Accuracy	97.5%				
Kappa	0.95				

จากผลการจำแนกค่าความถูกต้องของการจำแนกข้อมูลถนนและวัตถุอื่น ๆ สามารถให้ความถูกต้องที่ดีและมีค่าใกล้เคียงกันทั้ง 2 วิธี ทำให้ค่าความถูกต้องโดยรวมมีค่าใกล้เคียงกันเพราะว่าข้อมูลจุดพิภคสามมิติส่วนใหญ่ของงานวิจัยจะเป็นกลุ่มของข้อมูลถนนและวัตถุอื่น ๆ ถึงแม้ผลการจำแนกหลุมบ่อจะมีค่าความถูกต้องที่ต่างกันอย่างมีนัยสำคัญ แต่เนื่องจากเป็นชั้นข้อมูลที่มีจำนวนจุดที่น้อยทำให้ส่งผลกับการคำนวณค่าความถูกต้องโดยรวมที่น้อยเช่นกัน และถึงแม้ว่าความถูกต้องโดยรวมและค่าสัมประสิทธิ์แคปปาจากทั้ง 2 วิธีมีความใกล้เคียงกัน แต่การเปรียบเทียบความแตกต่างของผลการจำแนกของทั้ง 2 วิธีมีความจำเป็นต้องทดสอบทางสถิติเพื่อยืนยันว่ามีความแตกต่างอย่างมีนัยยะสำคัญหรือไม่ ซึ่งจะกล่าวในหัวข้อถัดไป

#### 4.3.4 ผลการทดสอบสถิติ Z เปรียบเทียบผลทั้ง 2 วิธี

ทดสอบผลการจำแนกจากของผลลัพธ์ทั้ง 2 วิธีเพื่อเปรียบเทียบความแตกต่างของความถูกต้องด้วยค่าสถิติ Z ที่ระดับความเชื่อมั่นร้อยละ 95 ผลการจากการทดสอบได้ค่า Z เท่ากับ 261.27 ซึ่งค่าอยู่นอกช่วงค่าวิกฤต -1.96 ถึง 1.96 จากผลการทดสอบค่าสถิติ Z จากผลการจำแนกใน Confusion Matrix ทั้ง 2 วิธี ผลการจำแนกมีค่าต่างกันอย่างมีนัยสำคัญ วิธีนำเสนอมีค่า RGB ให้ค่าความถูกต้องการจำแนกที่ดีกว่าวิธีไม่มีค่า RGB โดยเฉพาะการจำแนกหลุมบ่อที่ให้ค่าความถูกต้องที่ดีกว่าอย่างมีนัยสำคัญ

## บทที่ 5

### อภิปรายและสรุปผล

งานวิจัยนี้แบ่งการอภิปรายและสรุปผลเป็น 5 ส่วน ส่วนแรกเป็นการอภิปรายผลการสำรวจด้วย MMS รวมถึงการประเมินความถูกต้องของข้อมูลจุดพิกัดสามมิติ ส่วนที่สองเป็นการอภิปรายและผลของการจำแนกข้อมูลจุดพิกัดสามมิติด้วยโครงข่ายคอนโวลูชัน เพื่อตรวจหาหลุมบ่อและถนน ส่วนที่สามเป็นการสรุปผลการสำรวจด้วย MMS รวมถึงการประเมินความถูกต้องของข้อมูลจุดพิกัดสามมิติ ส่วนที่สี่สรุปผลการจำแนกข้อมูลจุดพิกัดสามมิติด้วยโครงข่ายคอนโวลูชัน เพื่อตรวจหาหลุมบ่อและถนนและส่วนที่ห้าข้อเสนอแนะงานวิจัย

#### 5.1 อภิปรายผลการสำรวจด้วย MMS และประเมินความถูกต้องของจุดพิกัดสามมิติ

จุดพิกัดสามมิติจากการสำรวจด้วย MMS มีความหนาแน่นของจุดประมาณ 5000 จุดต่อตารางเมตรในบริเวณพื้นผิวถนน ซึ่งมีความหนาแน่นมากพอที่ใช้จำแนกความชำรุดเสียหายของถนน โดยเฉพาะหลุมบ่อ ถึงแม้ MMS สามารถสำรวจโดยอ้างอิงตำแหน่ง GNSS แบบจุดเดี่ยว (Absolute) จุดพิกัดสามมิติจากระบบสแกนมีความแม่นยำเพียงพอในการตรวจหาหรือจำแนกวัตถุ แต่การสำรวจด้วยวิธีแบบสัมพัทธ์ (Relative) ทำให้ความถูกต้องเชิงตำแหน่งในระบบแผนที่ที่มีความถูกต้องสูงขึ้นด้วยวิธี PPK และยังสามารถตรวจสอบความถูกต้องเชิงตำแหน่งได้อย่างเป็นระบบ ด้วยการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK

จุดพิกัดสามมิติจากการสำรวจด้วย MMS หากยังไม่ปรับแก้ด้วยจุด GCP จะเห็นได้ว่าค่าความถูกต้องในระดับความเชื่อมั่นที่ร้อยละ 95 แบบสามมิติเท่ากับ 0.241 เมตร อยู่ในเกณฑ์งานชั้นที่ 3 คือมีค่าความถูกต้องอยู่ระหว่าง 0.2 – 1 เมตร ซึ่งมีค่าเกินจากงานชั้นที่ 2 เพียงเล็กน้อย และค่าความคลาดเคลื่อนส่วนใหญ่เกิดขึ้นในทางตั้งเป็นหลัก แสดงให้เห็นว่าถ้าหากกำจัดหรือลดความคลาดเคลื่อนในทางตั้งได้ จะสามารถทำงานให้อยู่ในเกณฑ์งานชั้นที่ 2 ได้โดยไม่ต้องปรับแก้ด้วยจุด GCP ซึ่งความถูกต้องของค่าระดับมีความเกี่ยวข้องกับความสูงของอุปกรณ์ ซึ่งความคลาดเคลื่อนอาจเกิดขึ้นได้จาก 2 สาเหตุ คือการวัดความสูงของอุปกรณ์ที่ไม่มีความแม่นยำ เนื่องจากอุปกรณ์ติดตั้งอยู่ในตำแหน่งที่วัดความสูงได้ยาก อาจทำให้เกิดความคลาดเคลื่อนในชั้นตอนนี้ และน้ำหนักของบุคลากรที่ควบคุมระบบขนานพาหนะ อาจทำให้ค่าความสูงของอุปกรณ์มีการเปลี่ยนแปลง และสาเหตุที่สองเนื่องจากถนนบางเส้นทางหรือเส้นทางที่เลือกทำวิจัย มีสภาพชำรุดเป็นหลุมบ่อ อาจจะ

เป็นสาเหตุให้เกิดแรงกดทับของยานพาหนะกับระบบกันสะเทือน ทำให้ค่าระดับของอุปกรณ์มีการเปลี่ยนแปลงตลอดเวลา ส่งผลให้ค่าระดับมีความคลาดเคลื่อนตามการเปลี่ยนแปลงความสูงของอุปกรณ์ และหากมีความประณีตในการทำงาน ใช้เครื่องมือช่วยในการวัดความสูงที่แม่นยำเช่น การใช้กล้องประมวลผลรวม วัดความสูงของอุปกรณ์ในขณะที่มีบุคลากรอยู่บนยานพาหนะ จะทำให้ค่าความสูงอุปกรณ์มีความถูกต้องมากยิ่งขึ้น รวมถึงถ้าหากเส้นทางสำรวจมีสภาพถนนที่ดี ความถูกต้องของงานอาจจะอยู่ในเกณฑ์งานชั้นที่ 2 โดยไม่ต้องใช้จุด GCP ในการปรับแก้

ผลการประเมินความถูกต้องหลังจากปรับแก้ด้วยจุด GCP ความถูกต้องที่ค่าระดับความเชื่อมั่นร้อยละ 95 ในแบบสามมิติเท่ากับ 0.089 เมตร แต่พบว่ายังมีบางจุดหลังจากปรับแก้แล้วมีค่าความคลาดเคลื่อนทางราบเพิ่มขึ้นคือตำแหน่งจุดตรวจสอบ CP04 จะเห็นได้ว่าเมื่อคำนวณค่าความคลาดเคลื่อนทางราบของจุด CP04 ตามตารางที่ 4-2 ได้ค่าเป็น 0.095 เมตร หลังจากปรับแก้ด้วย GCP ค่าความคลาดเคลื่อนทางราบเพิ่มขึ้นเป็น 0.131 เมตร ซึ่งปัญหานี้ถ้าสังเกตค่าความคลาดเคลื่อนของจุดนี้ในตารางที่ 4-2 ค่าความคลาดเคลื่อนค่อนข้างสูง และหลังจากปรับแก้ค่าความคลาดเคลื่อนเพิ่มสูงขึ้น สาเหตุอาจเกิดจากผลกระทบจากดาวเทียมไม่สามารถรับสัญญาณได้ต่อเนื่อง เกิดจากการถูกบดบังสัญญาณจากสภาพแวดล้อม โดยเฉพาะต้นไม้ในบริเวณดังกล่าว ดังแสดงในภาพที่ 5-1 ทำให้ค่าความคลาดเคลื่อนอาจเกิดขึ้นได้จากทั้งจุด CP04 และจาก MMS ทำให้หลังจากปรับแก้ค่าความคลาดเคลื่อนในจุดดังกล่าวยังมีค่าที่สูง แต่ในภาพรวมค่าความคลาดเคลื่อนของจุดอื่น ๆ มีค่าลดลง จะเห็นว่าค่าความคลาดเคลื่อนในทางตั้งหลังจากปรับแก้ด้วย GCP ค่า RMSE ทางตั้งมีค่าน้อยกว่าค่า RMSE<sub>r</sub> ในทางราบ



รูปที่ 5-1 แสดงจุด CP04 ที่อยู่ใกล้กับบริเวณบดบังสัญญาณดาวเทียม




## 5.2 อภิปรายผลการจำแนกจุดพิกัดสามมิติด้วยโครงข่ายประสาทคอนโวลูชัน

จากผลการฝึกสอนและการทดสอบโครงข่ายคอนโวลูชันในการเรียนรู้การจำแนกข้อมูลจุดพิกัดสามมิติสามารถทำได้ดีในชั้นข้อมูลถนนและวัตถุอื่น ๆ แต่ในชั้นข้อมูลหลุมบ่อมีประสิทธิภาพลดลง เนื่องจากพื้นที่ศึกษามีบางช่วงของเส้นทางที่มีการชำรุดเสียหายอย่างหนักของถนนทำให้เกิดหลุมบ่อหลายรูปแบบที่อาจทำให้โครงข่ายมีความสับสนในการให้ค่าน้ำหนักในการจำแนกดังแสดงในรูปที่ 5-2 หลุมบ่อที่เกิดจากการชำรุดเสียหายของผิวถนนในลักษณะนี้ ทำให้สามารถจำแนกขอบเขตหลุมบ่อได้ค่อนข้างยากในข้อมูลฝึกสอนโครงข่ายและข้อมูลทดสอบ ทำให้การวัดประสิทธิภาพของการฝึกสอนและการทดสอบมีค่า IoU อยู่ที่ประมาณร้อยละ 69 – 84 เท่านั้น ซึ่งต่างจากชั้นข้อมูลถนนและวัตถุอื่น ๆ ที่มีค่าอยู่ที่ประมาณร้อยละ 96 – 99



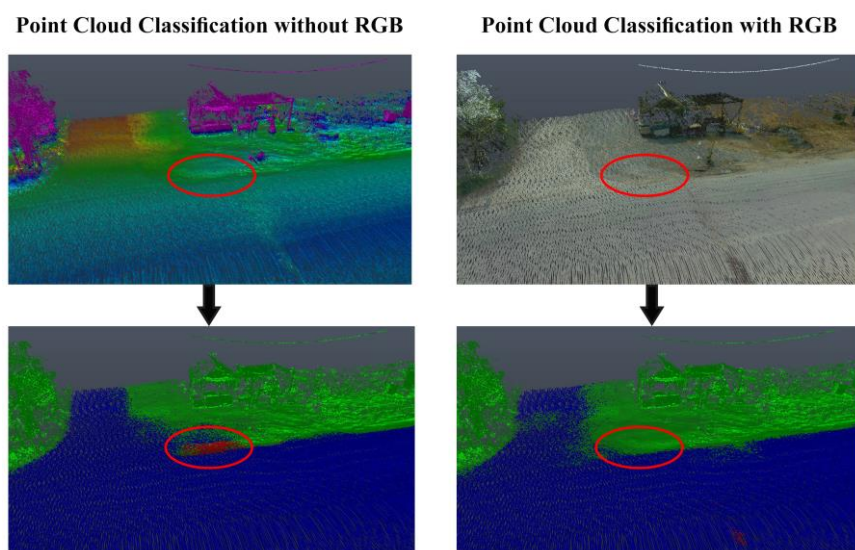
รูปที่ 5-2 แสดงบริเวณถนนชำรุดเสียหายอย่างหนัก

การจำแนกชุดข้อมูลทดสอบจริง Test Dataset พบว่าการจำแนกด้วยวิธีไม่มี RGB มีความผิดพลาดอย่างเห็นได้ชัดในหลายตำแหน่งมากกว่าวิธีมี RGB เช่น การจำแนกวัตถุอื่น ๆ เป็นพื้นผิวถนน เกิดขึ้นในหลายตำแหน่งโดยเฉพาะบริเวณที่ขอบเขตถนนกับพื้นที่ขอบทางมีค่าระดับใกล้เคียงกันดังแสดงในรูปที่ 5-3 ความผิดพลาดดังกล่าวเป็นสิ่งที่เห็นความแตกต่างระหว่างผลการจำแนกจากทั้ง 2 วิธี จะเห็นได้ว่าค่าสี RGB ของถนนที่มีความแตกต่างกับบริเวณขอบทางช่วยให้โมเดลเกิดการเรียนรู้ในการจำแนกขอบเขตถนนได้มีความแม่นยำมากยิ่งขึ้น




รูปที่ 5-3 แสดงผลการจำแนกขอบเขตถนนจากทั้ง 2 วิธี

จากตารางที่ 4-9 จะพบว่าผลการจำแนกหลุมบ่อด้วยวิธีไม่มี RGB จุดผิดพลาดสามมิติไปตกอยู่ในข้อมูลอ้างอิงที่เป็นวัตถุอื่น ๆ อยู่ที่ 24,202 จุด เมื่อเทียบกับตารางที่ 4-10 ผลการจำแนกหลุมบ่อด้วยวิธีมี RGB มีจุดไปตกอยู่ในชั้นข้อมูลอื่น ๆ อยู่ที่ 1,342 จุดเท่านั้นจะเห็นได้ว่าการใช้ค่า RGB ช่วยไม่ให้โมเดลจำแนกหลุมบ่อจากพื้นที่นอกขอบเขตถนน ซึ่งข้อมูลตัวอย่างที่ใช้ฝึกสอนในงานวิจัยนี้ จำแนกตรวจหาหลุมบ่อที่อยู่บนพื้นผิวถนนเท่านั้น แต่ถ้าหากใช้จุดผิดพลาดสามมิติที่ไม่มี RGB โมเดลมีการจำแนกหลุมบ่อที่เกิดขึ้นในบริเวณอื่นที่ไม่ใช่บนพื้นผิวถนนดังแสดงในรูปที่ 5-4



รูปที่ 5-4 แสดงผลการจำแนกหลุมบ่อที่เกิดในบริเวณไม่ใช่พื้นผิวถนน

ในทางกลับกันผลการจำแนกหลุมบ่อในลักษณะที่หลุมมีค่าระดับที่เปลี่ยนแปลงไปจากพื้นผิวถนนแต่ค่าสี RGB ไม่มีความแตกต่างจากพื้นผิวถนน ผลการจำแนกแบบไม่ใช้ค่า RGB ทำได้ดีกว่าดังแสดงในรูปที่ 5-5 บริเวณที่เกิดหลุมบ่อสามารถสังเกตได้จากค่าต่างระดับ แต่ไม่สามารถสังเกตได้จากค่าสีของภาพ ดังนั้นการเรียนรู้ของโครงข่ายแบบวิธี RGB อาจจะทำให้ค่าน้ำหนักในการจำแนกที่สับสนเล็กน้อย เนื่องจากค่า XYZ ให้ความหมายของการเกิดหลุมบ่อจากค่า Z ที่เปลี่ยนไป แต่ข้อมูลในส่วนของ RGB ให้ความหมายพื้นผิวดังกล่าวคือพื้นผิวถนน ทำให้วิธีไม่มี RGB สามารถจำแนกในกรณีนี้ได้ดีกว่า แต่ในพื้นที่ศึกษามีข้อมูลการเกิดหลุมบ่อในลักษณะเช่นนี้ค่อนข้างน้อย ซึ่งทำให้ข้อมูลตัวอย่างในการฝึกสอนและทดสอบไม่มากพอ ซึ่งอาจเป็นเหตุผลที่ทำให้วิธีนำเสนอมีค่า RGB จำแนกข้อมูลส่วนนี้ได้ไม่ค่อยดี



รูปที่ 5-5 แสดงผลการจำแนกหลุมบ่อที่มีค่าสี RGB เหมือนพื้นผิวถนน

การจำแนกหลุมบ่อจากจุดพิกัดสามมิติด้วย CNN เมื่อเปรียบเทียบกับผลการจำแนกหลุมบ่อจากภาพถ่ายที่ติดตั้งบนยานพาหนะโดยใช้ CNN เหมือนกัน ผลปรากฏว่าในงานวิจัยของ Wu et al. (2019) ให้ค่า IoU ของหลุมบ่อเท่ากับ 0.685 และในงานวิจัยของ Anandhalli et al. (2022) ที่ใช้แผนที่ภาพถ่ายทางอากาศจากอากาศยานไร้คนขับตรวจหาหลุมบ่อด้วย CNN ด้วยอัลกอริทึม YOLO ให้ค่า IoU เท่ากับ 0.667 ซึ่งผลผลการจำแนกมีความถูกต้องใกล้เคียงกัน แต่ในงานวิจัยที่ใช้ภาพถ่ายยังมีข้อจำกัดในการนำผลการจำแนกไปประยุกต์ใช้งาน เนื่องจากข้อมูลไม่มีพิกัดแผนที่และมาตราส่วน ส่วนการจำแนกด้วยแผนที่ภาพถ่ายทางอากาศถึงแม้ว่ามีค่าพิกัดแผนที่และมาตราส่วน แต่การจำแนก

ยังใช้แค่ค่าสีของภาพ ซึ่งหลุมบ่อที่เกิดขึ้นจริงบางครั้งอาจจะไม่ปรากฏให้เห็นชัดเจนได้ในภาพถ่าย และผลลัพธ์ของการจำแนกไม่สามารถบอกถึงค่าระดับความลึกของหลุมบ่อได้ ในส่วนของงานวิจัยนี้ ถึงแม้ว่าให้ค่าความถูกต้องใกล้เคียงกัน แต่การจำแนกเกิดจากการประเมินทั้งค่าระดับและค่าสี RGB ทำให้ผลการจำแนกสามารถให้ผลการจำแนกหลุมบ่อที่เกิดขึ้นจริง ถึงแม้ว่าหลุมบ่อจะไม่ปรากฏให้เห็นในภาพก็ตาม

ผลการจำแนกถนนจากจุดพิกัดสามมิติที่ได้จาก MMS ด้วย CNN ให้ผลลัพธ์ค่อนข้างดี โดยเฉพาะการเพิ่มการใช้ค่า RGB ในการจำแนกทำให้ผลการจำแนกมีความถูกต้องสูงขึ้น โดยมีค่า IoU เท่ากับ 0.954 เมื่อเปรียบเทียบกับผลการจำแนกถนนจากจุดพิกัดสามมิติจากเครื่องสแกนด้วยเลเซอร์ภาคพื้นดิน (Terrestrial Laser Scanner) ในงานวิจัยของ Hackel et al. (2016) ที่ใช้ CNN โดยปรับปรุงวิธี Point-wise ซึ่งผลการวัดประสิทธิภาพจะได้เป็นค่า Recall, Precision และ F1 เท่ากับ 0.879, 0.965 และ 0.920 ตามลำดับ เมื่อเทียบกับงานวิจัยนี้ที่ใช้วิธีมี RGB จะได้ค่า Recall, Precision และ F1 เท่ากับ 0.962, 0.992 และ 0.977 จะเห็นได้ว่าการจำแนกถนนในงานวิจัยนี้ที่ใช้ข้อมูลจาก MMS ให้ประสิทธิภาพที่ดีกว่า และเมื่อเปรียบเทียบกับผลการจำแนกถนนจากข้อมูลที่ได้จาก MMS ในงานวิจัยเดียวกันในชุดข้อมูล Paris-rue-Cassette ให้ค่า Recall, Precision และ F1 เท่ากับ 0.982, 0.987 และ 0.985 ซึ่งมีค่าใกล้เคียงกัน เนื่องจากถนนเป็นข้อมูลที่มี MMS สามารถบันทึกได้ชัดเจนทำให้การใช้ CNN ในการจำแนกถึงแม้ว่าเทคนิคและวิธีแตกต่างกัน แต่ส่วนใหญ่จะได้ผลออกมาค่อนข้างดี ผลลัพธ์จะแตกต่างกันไปขึ้นอยู่กับข้อมูลแต่ละสถานที่ที่มีความยากง่ายในการจำแนกที่แตกต่างกัน

ในงานวิจัยนี้จะมุ่งเน้นศึกษาการจำแนกหลุมบ่อจากจุดพิกัดสามมิติที่ได้จากการสำรวจด้วย MMS เนื่องจากมีการศึกษาวิจัยค่อนข้างน้อย และเป็นสิ่งที่น่าสนใจเพราะว่าจุดพิกัดสามมิติจาก MMS เป็นข้อมูลที่มีความถูกต้องสูง สามารถนำผลการจำแนกหลุมบ่อไปวิเคราะห์ความเสียหายที่เกิดขึ้นบนถนนได้ค่อนข้างสะดวก เพราะจุดพิกัดสามมิติอ้างอิงกับระบบพิกัดแผนที่ที่สามารถทราบตำแหน่งที่เกิดความเสียหายได้ และค่าระดับสามารถทราบความลึกของหลุมบ่อที่เกิดขึ้น ทำให้ผู้ที่เกี่ยวข้องและผู้ประเมินความเสียหายสามารถวิเคราะห์เพื่อซ่อมบำรุงได้อย่างมีประสิทธิภาพ

### 5.3 การสรุปผลการสำรวจด้วยระบบการทำแผนที่แบบเคลื่อนที่

ระบบการทำแผนที่แบบเคลื่อนที่ที่เป็นวิธีการสำรวจสภาพแวดล้อมของถนนได้อย่างมีประสิทธิภาพ ให้ความถูกต้องของจุดพิกัดสามมิติในระดับที่ดี สามารถนำไปประยุกต์ใช้งานได้หลากหลาย การปฏิบัติการในภาคสนามสามารถทำงานได้อย่างรวดเร็ว มีความปลอดภัยในการเก็บข้อมูล เนื่องจากการปฏิบัติงานแทบจะไม่ต้องลงไปเก็บข้อมูลบนท้องถนนด้วยตัวผู้ปฏิบัติงานเอง ผลการสำรวจเก็บข้อมูลยังได้ข้อมูลจุดพิกัดสามมิติที่มีความละเอียดเชิงพื้นที่ได้ดี สามารถวิเคราะห์พื้นผิวถนน การเกิดการชำรุดของผิวถนน และสิ่งปลูกสร้างโดยรอบของสภาพแวดล้อมของถนนได้

จากการประเมินความถูกต้องของจุดพิกัดสามมิติจาก MMS ด้วยจุดตรวจสอบจากการกำหนดตำแหน่งด้วยระบบดาวเทียม GNSS วิธี RTK ข้อมูลจุดสามมิติที่ไม่ได้ปรับแก้ด้วย GCP มีความถูกต้องตามมาตรฐาน NSSDA ที่ระดับความเชื่อมั่นร้อยละ 95 แบบสามมิติที่ 0.241 เมตร ซึ่งอยู่ในเกณฑ์งานชั้นที่ 3 สามารถนำข้อมูลไปประยุกต์ใช้ในงาน การสำรวจสิทธิ์ งานวางแผน งานสร้างแผนที่เมืองแบบสามมิติและงานประเมินปัญหาของสภาพถนน ส่วนของข้อมูลจุดพิกัดสามมิติที่ได้ปรับแก้ด้วย GCP มีความถูกต้องตามมาตรฐาน NSSDA ที่ระดับความเชื่อมั่นร้อยละ 95 แบบสามมิติที่ 0.089 เมตร ซึ่งอยู่ในเกณฑ์งานชั้นที่ 2 สามารถนำข้อมูลไปประยุกต์ใช้ในงานการสำรวจทำแผนที่ภูมิประเทศ การช่วยเหลือการขั้วชี้ การจำแนกวัตถุด้วยวิธีอัตโนมัติและกึ่งอัตโนมัติ การสำรวจหาแนวสายไฟฟ้าและการวิเคราะห์ความปลอดภัย (Olsen et al., 2013)

### 5.4 สรุปผลการจำแนกจุดพิกัดสามมิติด้วย CNN

จุดพิกัดสามมิติจาก MMS มีคุณลักษณะบอกถึงตำแหน่งพิกัดของสิ่งต่าง ๆ ได้อย่างแม่นยำและมีความละเอียดเชิงพื้นที่ สามารถบอกรูปร่างของวัตถุต่าง ๆ ได้ดี รวมถึงการมีกล้องถ่ายภาพ 360 องศาในระบบช่วยใช้ข้อมูลแสดงตำแหน่งของวัตถุต่าง ๆ ในรูปแบบสามมิติได้พร้อมกับสีภาพจริง การที่ข้อมูลจุดพิกัดสามมิติมีลักษณะดังกล่าว ทำให้การนำข้อมูลมาจำแนกตามลักษณะของวัตถุและสีภาพมีความถูกต้อง การใช้โครงข่ายคอนโวลูชันในสถาปัตยกรรม PointNet++ ที่มีจุดเด่นในการจำแนกข้อมูลจุดพิกัดสามมิติได้โดยตรง และสามารถปรับให้ใช้ค่าสี RGB ในการฝึกสอน ทดสอบและจำแนกข้อมูลทดสอบจริง ทำให้ตอบโจทย์วัตถุประสงค์ประสงค์ในการใช้จุดเด่นของจุดพิกัดสามมิติจากตำแหน่ง XYZ และค่าสี RGB ในการช่วยให้การจำแนกมีความแม่นยำมากยิ่งขึ้น

ผลการดำเนินงานการจำแนกจุดพิกัดสามมิติตั้งแต่ขั้นตอนการสอนโครงข่าย การทดสอบและการจำแนกข้อมูลทดสอบจริงในทั้ง 2 วิธีจะพบว่าการปรับโครงข่ายคอนโวลูชันในสถาปัตยกรรม PointNet++ ให้รองรับค่า RGB ในการฝึกสอนและทดสอบโครงข่ายทำให้โครงข่ายมีการเรียนรู้ที่ดียิ่งขึ้นมากกว่าการใช้เฉพาะค่า XYZ รวมถึงการทดสอบจำแนกจริง วิธีการเพิ่มข้อมูล RGB ให้ผลที่ดีกว่า ถึงแม้ว่าผลการจำแนกข้อมูลถนนและวัตถุอื่น ๆ มีค่าที่ดีกว่าเพียงเล็กน้อย แต่การจำแนกหลุมบ่อวิธีเพิ่มค่า RGB สามารถทำได้ดีกว่าอย่างมีนัยสำคัญ

จากการฝึกสอนและทดสอบโครงข่ายจากชุดข้อมูล Training Dataset และ Validation Dataset โครงข่ายสามารถเรียนรู้การจำแนกข้อมูลถนนและวัตถุอื่น ๆ ได้รวดเร็ว ค่า IoU จากการฝึกสอนและทดสอบของทั้ง 2 วิธีมีค่าสูงถึงร้อยละ 96-99 แต่การเรียนรู้การจำแนกหลุมบ่อโครงข่ายเรียนรู้ได้ช้ากว่าชั้นข้อมูลอื่นและผลการฝึกสอนทำได้ดีที่สุดจากวิธีไม่มี RGB และวิธีนำเสนอมี RGB อยู่ที่ร้อยละ 69.77 และร้อยละ 84.80 ผลการทดสอบอยู่ที่ร้อยละ 70.01 และร้อยละ 81.25 และผลการจำแนกข้อมูลทดสอบจริงในชุดข้อมูล Test Dataset ค่า IoU ของถนนและวัตถุอื่น ๆ ลดลงไปอยู่ที่ร้อยละ 94 - 95 แต่ข้อมูลหลุมบ่อลดลงไปอยู่ที่ร้อยละ 59.50 และร้อยละ 66.66 จะเห็นได้ว่าการจำแนกข้อมูลหลุมบ่อจากจุดพิกัดสามมิติเป็นสิ่งที่มีความท้าทายในงานวิจัยนี้ ถึงแม้ว่าวิธีนำเสนอใช้ค่า RGB ทำให้ค่าการฝึกสอน การทดสอบและการจำแนกดีขึ้น แต่ผลการจำแนกยังมีค่าที่น้อยเมื่อเทียบกับชั้นข้อมูลถนนและวัตถุอื่น ๆ

## 5.5 ข้อจำกัดและปัญหาการวิจัย

5.5.1 การเกิดหลุมบ่อบนท้องถนนในแต่ละเส้นทางจะมีลักษณะที่แตกต่างกัน การชำรุดเสียหายที่แตกต่างกันอาจทำให้ผลการจำแนกมีความถูกต้องที่แตกต่างกัน ผลการจำแนกในงานวิจัยนี้อ้างอิงกับข้อมูลที่ใช้ในงานวิจัยนี้เท่านั้น ไม่สามารถอ้างอิงกับข้อมูลวิจัยอื่นที่จำแนกหลุมบ่อ ถึงแม้ว่าจะใช้เทคนิคเดียวกันก็ตาม

5.5.2 ผลการประเมินความถูกต้องเชิงตำแหน่งของระบบการทำแผนที่แบบเคลื่อนที่ อ้างอิงเฉพาะการสำรวจในงานนี้เท่านั้น เนื่องจากค่าความถูกต้องจะเปลี่ยนแปลงตามสภาพแวดล้อมของการเก็บข้อมูลในแต่ละพื้นที่ ซึ่งมีสิ่งบดบังและรบกวนการรับสัญญาณ GNSS รวมถึงระยะทางและจำนวนในการกำหนดจุด GCP ด้วย

5.5.3 การเตรียมข้อมูลจุดพิกัดสามมิติเพื่อเข้าสู่กระบวนการฝึกสอน การทดสอบและการจำแนก ผู้วิจัยต้องทำการจำแนกข้อมูลด้วยตนเองก่อนเพื่อเป็นข้อมูลอ้างอิง (Label) ซึ่งขั้นตอนนี้ใช้เวลานานพอสมควร เพราะการจำแนกข้อมูลจุดพิกัดสามมิติจะยากกว่าการจำแนกข้อมูลภาพถ่ายที่เป็นสองมิติ ดังนั้นผู้วิจัยจะต้องมีทักษะและคอมพิวเตอร์ที่มีประสิทธิภาพสูงในการจัดการข้อมูลจุดพิกัดสามมิติในซอฟต์แวร์เฉพาะที่รองรับการจัดการข้อมูลจุดพิกัดสามมิติ

5.5.4 การจำแนกจุดพิกัดสามมิติด้วย CNN ต้องการทรัพยากรคอมพิวเตอร์ค่อนข้างสูง โดยเฉพาะหน่วยประมวลผลกราฟิก ซึ่งช่วงเวลาที่ศึกษาวิจัยเกิดปัญหา หน่วยประมวลผลกราฟิกตลาดแคลนและมีราคาแพงจึงทำให้มีข้อจำกัดในการจัดหา ทำให้การฝึกสอน การทดสอบและการจำแนกข้อมูลจุดพิกัดสามมิติทำได้ค่อนข้างช้า มีความจำเป็นที่ต้องกรองข้อมูลบางส่วน เพื่อให้ระบบทำการฝึกสอนได้เร็วยิ่งขึ้น ดังนั้นทำให้ข้อมูลสูญเสียบางส่วนไปบางส่วน

5.5.5 การกำหนดข้อมูลอ้างอิง (Label) ของหลุมบ่อในพื้นที่ศึกษา เลือกเฉพาะหลุมบ่อที่มีการยุบตัวลงไปเท่านั้น ไม่ได้กำหนด Label จากการชำรุดเสียหายในรูปแบบอื่น ๆ

## 5.6 ข้อเสนอแนะงานวิจัย

5.6.1 การสำรวจด้วย MMS โดยใช้อุปกรณ์ Topcon IP-S3 ผู้วิจัยใช้ค่าความสูงของอุปกรณ์ตามที่บริษัทได้กำหนดค่าไว้ โดยไม่ได้ทำการวัดสอบใหม่ให้สอดคล้องกับน้ำหนักของผู้ควบคุมระบบบนยานพาหนะ ซึ่งอาจเป็นสาเหตุหนึ่งที่ทำให้ค่าระดับของจุดพิกัดสามมิติที่ยังไม่ได้ปรับแก้ด้วย GCP มีค่าความคลาดเคลื่อนที่สูง ดังนั้นการสำรวจด้วยระบบ MMS ควรมีการวัดสอบค่าความสูงของอุปกรณ์จากพื้นทุกครั้งเพื่อเพิ่มความถูกต้องในทางดิ่ง

5.6.2 หากต้องการความถูกต้องเชิงตำแหน่งของจุดพิกัดสามมิติที่สูงขึ้น อาจเลือกใช้อุปกรณ์ MMS ที่มีคุณสมบัติเฉพาะทางเทคนิคที่สูงขึ้น เช่น อาจจะใช้เลือกใช้อุปกรณ์ที่ใช้เครื่องรับสัญญาณดาวเทียม GNSS ที่รองรับดาวเทียมได้มากกว่าแค่ GPS และ GLONASS อาจจะใช้เลือกที่รองรับ BEIDOU, GALILEO และ QZSS ด้วยและช่องรับสัญญาณที่มีมากกว่า 226 ช่อง อาจทำให้ความถูกต้องเชิงตำแหน่งสูงขึ้น และอุปกรณ์ IMU, DMI และ LiDAR หากใช้อุปกรณ์ที่มีประสิทธิภาพสูง อาจทำให้การเก็บข้อมูลโดยรวมมีความถูกต้องมากยิ่งขึ้นและสุดท้ายทำให้จุดพิกัดสามมิติมีความถูกต้องเชิงตำแหน่งมากขึ้น

5.6.3 การศึกษาคั้งนี้สำรวจเก็บข้อมูลในเส้นทางที่ถนนชำรุดเป็นหลุมบ่อ ซึ่งมีระยะทางประมาณ 4 กิโลเมตรในพื้นที่จังหวัดนนทบุรี ทำให้การเก็บข้อมูลจุดพิกัดสามมิติจาก MMS ไม่ได้เก็บข้อมูลในพื้นที่สภาพแวดล้อมที่หลากหลาย ทำให้ไม่ได้วัดประสิทธิภาพของความถูกต้องเชิงตำแหน่งในสภาพแวดล้อมที่แตกต่างกัน ที่อาจจะมีสิ่งที่ยับยั้งสัญญาณดาวเทียม เช่นตึกสูงที่ทำให้เกิด Multipath สถานีหรือระบบรางของรถไฟฟ้ามหานครที่มีคลื่นแม่เหล็กสนาม ดังนั้นหากต้องการศึกษาความถูกต้องเชิงตำแหน่งของจุดพิกัดสามมิติจาก MMS อาจจะต้องศึกษาในระยะทางที่ยาวกว่านี้และมีสภาพแวดล้อมที่แตกต่างกัน เพื่อประเมินประสิทธิภาพของ MMS ในการทำงานที่อาจเกิดขึ้นจริง

5.6.4 CNN ในสถาปัตยกรรม PointNet++ สามารถจำแนกหลุมบ่อได้ ในอนาคตควรมีการศึกษาจำแนกของการเกิดการชำรุดเสียหายของถนนในประเภทต่าง ๆ เช่น รอยแตก รอยปะซ่อม ร่องล้อ การยุบตัวของถนน เป็นต้น

5.6.5 การจำแนกตรวจหาหลุมบ่อเป็นสิ่งที่มีความท้าทายในงานวิจัยนี้ เนื่องจากมีข้อจำกัดในการหาพื้นที่ศึกษาที่เกิดปัญหาหลุมบ่อแบบต่อเนื่องและมีระยะทางที่ยาว งานวิจัยต่อไปควรสำรวจหาพื้นที่เกิดปัญหาหลุมบ่อที่มีระยะทางที่ยาวขึ้นเพื่อจะได้มีข้อมูลตัวอย่างที่เป็นหลุมบ่อ เพื่อฝึกสอน CNN ให้เรียนรู้และจดจำได้ดียิ่งขึ้น



## บรรณานุกรม

- Anandhalli, M., Tanuja, A., Baligar, V., and Baligar, P. (2022). Indian pothole detection based on CNN and anchor-based deep learning method. *International Journal of Information Technology*. doi:10.1007/s41870-022-00881-5
- ASPRS. (2014). American Society for Photogrammetry and Remote Sensing In *ASPRS Positional Accuracy Standards for Digital Geospatial Data* (Vol. 81, pp. A1–A26): Photogrammetric Engineering & Remote Sensing.
- Baheti, P. (2022). Train Test Validation Split: How To & Best Practices [2022]. Retrieved from <https://www.v7labs.com/blog/train-validation-test-set>
- Becker, Y. V. F., Siqueira, H. L., Matsubara, E. T., Gonçalves, W. N., and Marcato, J. M. (2019). *Asphalt Pothole Detection in UAV Images Using Convolutional Neural Networks*. Paper presented at the IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium.
- Ch, G. L., Sankar, V. U., and Yellampalli, S. S. (2021). *Image based Road distress detection*. Paper presented at the 2021 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON).
- Chen, H., Yao, M., and Gu, Q. (2020). Pothole detection using location-aware convolutional neural networks. *International Journal of Machine Learning and Cybernetics*, 11(4), 899-911. doi:10.1007/s13042-020-01078-7
- Chen, Y., Liu, G., Xu, Y., Pan, P., and Xing, Y. (2021). PointNet++ Network Architecture with Individual Point Level and Global Features on Centroid for ALS Point Cloud Classification. *Remote Sensing*, 13(3). doi:10.3390/rs13030472
- Congalton, R. G., and Green, K. (2019). *Assessing the accuracy of remotely sensed data: principles and practices*: CRC press.
- Darapaneni, N., Reddy, N. S., Urkude, A., Paduri, A. R., Satpute, A. A., Yogi, A., . . . Srivastava, U. (2021). *Pothole Detection Using Advanced Neural Networks*. Paper presented at the 2021 IEEE 12th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON).

- De Blasiis, M. R., Di Benedetto, A., and Fiani, M. (2020). Mobile Laser Scanning Data for the Evaluation of Pavement Surface Distress. *Remote Sensing*, 12(6). doi:10.3390/rs12060942
- Djamaluddin, D., Achmad, A., and Parung, R. (2017). Prototype of vehicles potholes detection based blob detection method. *Journal of Theoretical and Applied Information Technology*, 95(11), 2509-2515.
- Guan, H., Li, J., Yu, Y., Chapman, M., Wang, H., Wang, C., and Zhai, R. (2015). Iterative Tensor Voting for Pavement Crack Extraction Using Mobile Laser Scanning Data. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3), 1527-1537. doi:10.1109/TGRS.2014.2344714
- Hackel, T., Wegner, J., and Schindler, K. (2016). FAST SEMANTIC SEGMENTATION OF 3D POINT CLOUDS WITH STRONGLY VARYING DENSITY. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III-3, 177-184. doi:10.5194/isprs-annals-III-3-177-2016
- Jana, S., Thangam, S., Kishore, A., Kumar, V. S., and Vandana, S. (2022). Transfer learning based deep convolutional neural network model for pavement crack detection from images. *International Journal of Nonlinear Analysis and Applications*, 13(1), 1209-1223. doi:10.22075/ijnaa.2021.24521.2762
- Jindal, A., and Nagarajan, K. (2019). *Detection of Potholes and Speedbumps by Monitoring Front Traffic*. SAE Technical Paper, 2019-01-5031. doi:https://doi.org/10.4271/2019-01-5031.
- Jing, H., and Suyu, Y. (2016). *Point cloud labeling using 3D Convolutional Neural Network*. Paper presented at the 2016 23rd International Conference on Pattern Recognition (ICPR).
- Jo, Y., Ryu, S. K., and Kim, Y. R. (2016). Pothole detection based on the features of intensity and motion. *Transportation Research Record*, 2595, 18-28. doi:10.3141/2595-03
- Kim, T., and Ryu, S. (2014). Review and analysis of pothole detection methods. *Journal of Emerging Trends in Computing and Information Sciences*, 5, 603-608.

- Kowalczyk, Z., and Szymański, K. (2019). Classification of objects in the LIDAR point clouds using Deep Neural Networks based on the PointNet model. *IFAC-PapersOnLine*, 52(8), 416-421. doi:<https://doi.org/10.1016/j.ifacol.2019.08.099>
- Kumar, P., McElhinney, C. P., Lewis, P., and McCarthy, T. (2014). Automated road markings extraction from mobile laser scanning data. *International Journal of Applied Earth Observation and Geoinformation*, 32, 125-137. doi:<https://doi.org/10.1016/j.jag.2014.03.023>
- Lakmal, H. K. I. S., and Dissanayake, M. B. (2020). *Pothole Detection with Image Segmentation for Advanced Driver Assisted Systems*. Paper presented at the 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering (WIECON-ECE).
- Lehtomäki, M., Jaakkola, A., Hyypä, J., Lampinen, J., Kaartinen, H., Kukko, A., . . . Hyypä, H. (2016). Object Classification and Recognition From Mobile Laser Scanning Point Clouds in a Road Environment. *IEEE Transactions on Geoscience and Remote Sensing*, 54(2), 1226-1239. doi:10.1109/TGRS.2015.2476502
- Li, J., Cao, S., and Yu, Y. (2016). Use of mobile LiDAR in road information inventory: a review AU - Guan, Haiyan. *International Journal of Image and Data Fusion*, 7(3), 219-242. doi:10.1080/19479832.2016.1188860
- Li, R., and Liu, C. (2021). *Road Damage Evaluation via Stereo Camera and Deep Learning Neural Network*. Paper presented at the 2021 IEEE Aerospace Conference (50100).
- Lindner, M., Schiller, I., Kolb, A., and Koch, R. (2010). Time-of-Flight sensor calibration for accurate range sensing. *Computer Vision and Image Understanding*, 114(12), 1318-1328. doi:<https://doi.org/10.1016/j.cviu.2009.11.002>
- Ma, L., Li, Y., Li, J., Wang, C., Wang, R., and Chapman, M. A. (2018). Mobile Laser Scanned Point-Clouds for Road Object Detection and Extraction: A Review. *Remote Sensing*, 10(10). doi:10.3390/rs10101531

- Masud, A. K. M. J. A., Sharin, S. T., Shawon, K. F. T., and Zaman, Z. (2021). *Pothole Detection Using Machine Learning Algorithms*. Paper presented at the 2021 15th International Conference on Signal Processing and Communication Systems (ICSPCS).
- McCormac, J. C., Sarasua, W., and Davis, W. (2012). *Surveying*. Wiley Global Education; Hoboken, NJ, USA.
- O'Shea, K., and Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- Olsen, M. J., Roe, G. V., Glennie, C. L., Persi, F. M., Reedy, M., Hurwitz, D. S., . . . Knodler, M. A. (2013). Guidelines for the Use of Mobile LIDAR in Transportation Applications. *NCHRP Report*.
- Pan, Y., Zhang, X., Cervone, G., and Yang, L. (2018). Detection of Asphalt Pavement Potholes and Cracks Based on the Unmanned Aerial Vehicle Multispectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3701-3712. doi:10.1109/JSTARS.2018.2865528
- Puente, I., González-Jorge, H., Martínez-Sánchez, J., and Arias, P. (2013). Review of mobile mapping and surveying technologies. *Measurement*, 46(7), 2127-2145. doi:<https://doi.org/10.1016/j.measurement.2013.03.006>
- Qi, C., Su, H., Mo, K., and Guibas, L. J. (2017). PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 77-85.
- Qi, C. R., Yi, L., Su, H., and Guibas, L. J. (2017). *PointNet++: deep hierarchical feature learning on point sets in a metric space*. Paper presented at the Proceedings of the 31st International Conference on Neural Information Processing Systems, Long Beach, California, USA.
- Ragnoli, A., De Blasiis, M. R., and Di Benedetto, A. (2018). Pavement distress detection methods: A review. *Infrastructures*, 3(4), 58.
- Ravi, R., Habib, A., and Bullock, D. (2020). Pothole mapping and patching quantity estimates using lidar-based mobile mapping systems. *Transportation Research Record*, 2674(9), 124-134. doi:10.1177/0361198120927006

- Serna, A., and Marcotegui, B. (2014). Detection, segmentation and classification of 3D urban objects using mathematical morphology and supervised learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 243-255. doi:10.1016/j.isprsjprs.2014.03.015
- Topcon. (2021). IP-S3 HD1 Compact, High-Density 3D Mobile Mapping System. Retrieved from <https://www.topconpositioning.com/scanning/mobile-mapping/ip-s3>
- Toth, C. (2009). R&D of mobile LIDAR mapping and future trends. *American Society for Photogrammetry and Remote Sensing Annual Conference 2009, ASPRS 2009*, 2, 9-13.
- Vosselman, G., and Maas, H.-G. (2010). Airborne and Terrestrial Laser Scanning. *CRC Press: Boca Raton, FL, USA*.
- Wang, D., Wang, J., Scaioni, M., and Si, Q. (2020). Coarse-to-Fine Classification of Road Infrastructure Elements from Mobile Point Clouds Using Symmetric Ensemble Point Network and Euclidean Cluster Extraction. *Sensors*, 20(1). doi:10.3390/s20010225
- Wang, H., Luo, H., Wen, C., Cheng, J., Li, P., Chen, Y., . . . Li, J. (2015). Road Boundaries Detection Based on Local Normal Saliency From Mobile Laser Scanning Data. *IEEE Geoscience and Remote Sensing Letters*, 12(10), 2085-2089. doi:10.1109/LGRS.2015.2449074
- Wang, P., Hu, Y., Dai, Y., and Tian, M. (2017). Asphalt Pavement Pothole Detection and Segmentation Based on Wavelet Energy Field. *Mathematical Problems in Engineering*, 2017. doi:10.1155/2017/1604130
- Wu, H., Yao, L., Xu, Z., Li, Y., Ao, X., Chen, Q., . . . Meng, B. (2019). Road pothole extraction and safety evaluation by integration of point cloud and images derived from mobile mapping sensors. *Advanced Engineering Informatics*, 42, 100936. doi:<https://doi.org/10.1016/j.aei.2019.100936>
- Xiang, B., Yao, J., Lu, X., Li, L., Xie, R., and Li, J. (2018). Segmentation-based classification for 3D point clouds in the road environment. *International Journal of Remote Sensing*, 39, 1-31. doi:10.1080/01431161.2018.1455235

- Yang, B., Liu, Y., Dong, Z., Liang, F., Li, B., and Peng, X. (2017). 3D local feature BKD to extract road information from mobile laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 329-343. doi:<https://doi.org/10.1016/j.isprsjprs.2017.06.007>
- Yang, M., Liu, X., Jiang, K., Xu, J., Sheng, P., and Yang, D. (2019). Automatic Extraction of Structural and Non-Structural Road Edges from Mobile Laser Scanning Data. *Sensors*, 19(22). doi:10.3390/s19225030
- Yousaf, M. H., Azhar, K., Murtaza, F., and Hussain, F. (2018). Visual analysis of asphalt pavement for detection and localization of potholes. *Advanced Engineering Informatics*, 38, 527-537. doi:<https://doi.org/10.1016/j.aei.2018.09.002>
- Yu, Y., Li, J., Guan, H., and Wang, C. (2015). Automated Extraction of Urban Road Facilities Using Mobile Laser Scanning Data. *IEEE Transactions on Intelligent Transportation Systems*, 16(4), 2167-2181. doi:10.1109/TITS.2015.2399492
- Zakeri, H., Nejad, F. M., and Fahimifar, A. (2017). Image Based Techniques for Crack Detection, Classification and Quantification in Asphalt Pavement: A Review. *Archives of Computational Methods in Engineering*, 24, 935-977.
- Zhang, D., Zou, Q., Lin, H., Xu, X., He, L., Gui, R., and Li, Q. (2018). Automatic pavement defect detection using 3D laser profiling technology. *Automation in Construction*, 96, 350-365. doi:<https://doi.org/10.1016/j.autcon.2018.09.019>
- Zhang, L., Sun, J., and Zheng, Q. (2018). 3D Point Cloud Recognition Based on a Multi-View Convolutional Neural Network. *Sensors (Basel, Switzerland)*, 18(11), 3681. doi:10.3390/s18113681
- Zhongyang, Z., Yinglei, C., Xiaosong, S., Xianxiang, Q., and Li, S. (2018). *Classification of LiDAR Point Cloud based on Multiscale Features and PointNet*. Paper presented at the 2018 Eighth International Conference on Image Processing Theory, Tools and Applications (IPTA).



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	สรศักดิ์ ชัยทวี
วัน เดือน ปี เกิด	29 ตุลาคม 2532
สถานที่เกิด	สงขลา
วุฒิการศึกษา	วิศวกรรมศาสตรบัณฑิต (วิศวกรรมสำรวจ) วิศวกรรมศาสตรมหาบัณฑิต (วิศวกรรมสำรวจ)
ที่อยู่ปัจจุบัน	32/2 บ้านม่วงอน หมู่ที่ 5 ตำบลนาทับ อำเภอจะนะ จังหวัดสงขลา
ผลงานตีพิมพ์	สรศักดิ์ ชัยทวี, ธงทิศ ฉายากุล และสุรเชษ ศรีนารา. (2564). การประเมินความถูกต้องกลุ่มของจุดพิกัดสามมิติจากระบบการทำแผนที่แบบเคลื่อนที่. วารสารวิศวกรรมสาร มก., 34(111), 85-100.