


การออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ  
ด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาปรัชญาดุษฎีบัณฑิต  
สาขาวิชาเทคโนโลยีสารสนเทศ  
มหาวิทยาลัยเทคโนโลยีสุรนารี  
ปีการศึกษา 2562

**THE DESIGN AND DEVELOPMENT OF ALGORITHMS  
FOR ROAD SURFACE ANOMALY DETECTION WITH  
LOW-COST MULTIMODAL SENSORS**



**A Thesis Submitted in Partial Fulfillment of the Requirements for the  
Degree of Doctor of Philosophy Program in Information Technology**

**Suranaree University of Technology**

**Academic Year 2019**

การออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ  
ด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำ

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้บัณฑิตวิทยาลัยรับเป็นส่วนหนึ่งของการศึกษา  
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์




(ผู้ช่วยศาสตราจารย์ ดร.ชรา อังสกุล)

ประธานกรรมการ



(ผู้ช่วยศาสตราจารย์ ดร.สถิตย์โชค โพธิ์สอาด)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รองศาสตราจารย์ ดร.นิตยา เกิดประสพ)

กรรมการ



(รองศาสตราจารย์ ดร.พจน์ ตั้งงามจิตต์)

กรรมการ



(ผู้ช่วยศาสตราจารย์ ดร.รัฐพล ภูบวบผาพันธ์)

กรรมการ



(ผู้ช่วยศาสตราจารย์ ดร.ศุภกฤษฎี นีวัฒนากุล)

กรรมการ



(ดร.วสันต์ ภัทรอริคม)

กรรมการ



(รองศาสตราจารย์ ร.อ. ดร.กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและพัฒนาความเป็นสากล



(รองศาสตราจารย์ ดร.วีรพงษ์ พลนิกรกิจ)

คณบดีสำนักวิชาเทคโนโลยีสังคม

ปิติกุมิ โปสาวัง : การออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วย  
เครื่องรับรู้อัลตราซาวด์แบบต้นทุนต่ำ (THE DESIGN AND DEVELOPMENT OF ALGORITHMS  
FOR ROAD SURFACE ANOMALY DETECTION WITH LOW-COST MULTIMODAL  
SENSORS) อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ ดร.สถิตย์ โชค โพธิ์สอาด, 192 หน้า.

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติเป็นงานที่มีความสำคัญต่อการบำรุงรักษา  
ถนน การขนส่งทางถนนและระบบรถขับเคลื่อนอัตโนมัติเพื่อความปลอดภัยในการขับขี่ของผู้ใช้รถ  
ใช้ถนน ที่ผ่านมากการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติใช้อุปกรณ์พิเศษที่มีต้นทุนสูง ส่วนการใช้  
โทรศัพท์มือถือ โดยทั่วไปมักวิเคราะห์ข้อมูลจากเครื่องรับรู้อัลตราซาวด์แบบเดี่ยว ประสิทธิภาพของ  
การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติถูกจำกัดด้วยข้อมูลรูปแบบเดียวและสัณฐานลักษณะข้อมูล  
ด้วยมือ งานวิจัยนี้เสนอขั้นตอนวิธีใหม่เพื่อเพิ่มความแม่นยำในการตรวจจับ โดยใช้เครื่องรับรู้อัลตราซาวด์  
หลายรูปแบบและการสัณฐานลักษณะแบบอัตโนมัติ การเรียนรู้เชิงลึกและหลายรูปแบบถูกนำมาใช้เพื่อให้  
บรรลุผลตามเป้าหมายของงานวิจัย การใช้เครื่องรับรู้อัลตราซาวด์หลายรูปแบบช่วยเพิ่มความแม่นยำในการจำแนก  
สภาพพื้นผิวถนนที่ผิดปกติ ในขณะที่เทคนิคการเรียนรู้เชิงลึกหลายรูปแบบเป็นนวัตกรรมใหม่ที่  
ที่สัณฐานลักษณะ เรียนรู้และจำแนกคุณลักษณะข้อมูลที่เกิดขึ้นในเวลาเดียวกัน งานวิจัยนี้ใช้ตัวแบบ  
ที่ถูกฝึกมาแล้วล่วงหน้าเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติ จากนั้นเพิ่มความแม่นยำ  
ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติใหม่ด้วยการเรียนรู้เชิงลึกหลายรูปแบบ ชุดข้อมูลรูปภาพที่ใช้  
ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ มี 6 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว  
3) รอยแตกตามแนวขวาง 4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม และ 6) เนินชะลอความเร็ว/ เส้นชะลอ  
ความเร็ว ส่วนชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่ใช้ในการจำแนกสภาพพื้นผิว  
ถนนที่ผิดปกติใหม่มี 7 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง  
4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม 6) เนินชะลอความเร็ว เส้นชะลอความเร็ว และ 7) ถนนปกติ  
ผลจากงานวิจัย พบว่า ตัวแบบ SSD ResNet50 FPN ที่ผ่านการฝึกมาแล้วล่วงหน้ามีความเหมาะสม  
ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและการจำแนกสภาพพื้นผิวถนนใหม่ด้วยการเรียนรู้เชิงลึก  
หลายรูปแบบสามารถเพิ่มค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดที่ 35.38% ขั้นตอนวิธีใหม่และตัวแบบ  
ที่แม่นยำในงานวิจัยนี้สามารถนำไปประยุกต์ใช้เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในพื้นที่อื่น ๆ  
เพื่อเพิ่มคุณภาพ ประสิทธิภาพและความปลอดภัยในการเดินทางได้

สาขาวิชาเทคโนโลยีสารสนเทศ

ปีการศึกษา 2562

ลายมือชื่อนักศึกษา sh hr

ลายมือชื่ออาจารย์ที่ปรึกษา COL

ลายมือชื่ออาจารย์ที่ปรึกษาร่วม อนุสร

ลายมือชื่ออาจารย์ที่ปรึกษาร่วม อนุสร



PITIPHUM POSAWANG : THE DESIGN AND DEVELOPMENT OF  
ALGORITHMS FOR ROAD SURFACE ANOMALY DETECTION WITH  
LOW- COST MULTIMODAL SENSOR. THESIS ADVISOR : ASST.  
PROF. SATIDCHOKE PHOSAARD, Ph.D., 192 PP.

ROAD SURFACE ANOMALY DETECTION/ MULTIMODAL SENSOR/  
PRETRAINED MODEL/ MULTIMODAL DEEP CONVOLUTIONAL NEURAL  
NETWORKS/ MULTIMODAL DEEP LEARNING


An automatic road surface anomaly detection is an important task in road maintenance, road transportation, and autonomous driving, in order to assure all road users' safety. In the past, road surface anomaly detection using special equipment was a high cost and using smartphone sensors generally employ single modal sensor analysis. The performance of these methods is limited to a single sensor and manually extracted features.

This research proposes a novel alternative technique to enhance the detection accuracy using multiple sensors and automatic feature extraction. Deep and multimodal learning is employed to achieve this goal. Using multiple sensors enhances the detection accuracy; while the innovative multimodal deep learning technique automatically extracts, learns and classifies synchronized features. This study uses a pretrained model to automatically detect road surface anomalies and then increase the accuracy by using the multimodal deep learning reclassifications.

The image datasets for automatically detect road surface conditions have 6 categories: 1) pothole, 2) longitudinal cracks, 3) transverse cracks, 4) alligator cracks, 5) patch, and 6) speed bump/rumble strips. Moreover, the image and

acceleration datasets for road surface anomalies reclassifications have 7 categories: 1) pothole, 2) longitudinal cracks, 3) transverse cracks, 4) alligator cracks, 5) patch, 6) speed bump/rumble strips, and 7) normal road.

The results pointed out that an SSD ResNet50 FPN pretrained model is appropriate to visually detect road surface anomalies and the multimodal deep learning reclassifications can increase the mean average precision as high as 35.38%. The study yielded practical methodology and high accuracy models that could be used on widely available mobile devices, which can be applied to automatically and economically detect road surface anomalies in other regions of the world to improve quality, efficiency and driving safety.



School of Information Technology

Academic Year 2019

Student's Signature Pitiphum Pos.

Advisor's Signature S.P.

Co-advisor's Signature S. m.

Co-advisor's Signature [Signature]

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ผู้วิจัยขอกราบขอบพระคุณทุกท่านที่มีส่วนร่วมในการให้คำปรึกษา แนะนำ สนับสนุนส่งเสริมและช่วยเหลือเป็นอย่างดี โดยเฉพาะอย่างยิ่ง ผู้ช่วยศาสตราจารย์ ดร.สถิตย์โชค โพธิ์สอาด อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้ช่วยศาสตราจารย์ ดร.ศุภกฤษฎี นิวัฒนากุล และ ดร.วสันต์ ภัทรอธิคม อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม อาจารย์ ดร.ธรรมศักดิ์ เขียวนิเวศน์ คณาจารย์สาขาวิชาเทคโนโลยีสารสนเทศและคณาจารย์สาขาวิชาอื่น ๆ ที่เกี่ยวข้องในหลักสูตรที่ให้ความสำคัญกับการพัฒนาผู้วิจัยโดยการผลักดันให้เรียนรู้ ศึกษาและวิจัยในประเด็นต่าง ๆ อย่างหลากหลาย อีกทั้งยังส่งเสริมแนวความคิด ความสามารถ ประสบการณ์และความรู้ด้านต่าง ๆ ที่เป็นประโยชน์อย่างมหาศาลในการวิจัย เพื่อเพิ่มพูนความเชี่ยวชาญในการวิจัยด้านการรู้จำภาพ การตรวจจับและจำแนกวัตถุในภาพโดยใช้วิธีการเรียนรู้เชิงลึกและการเรียนรู้เชิงลึกหลายรูปแบบ

ยิ่งไปกว่านั้น ขอกราบขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.ธรา อังสกุล ประธานการสอบ โครงร่างวิทยานิพนธ์และการสอบป้องกันวิทยานิพนธ์ รองศาสตราจารย์ ดร.พจน์ ตั้งงามจิตต์ รองศาสตราจารย์ ดร.นิตยา เกิดประสพ และผู้ช่วยศาสตราจารย์ ดร.รัฐพล ภู่บุบผาพันธ์ คณะกรรมการในการสอบ โครงร่างวิทยานิพนธ์และการสอบป้องกันวิทยานิพนธ์ที่ให้คำแนะนำ แนวทางในการดำเนินวิจัยของผู้วิจัยเป็นอย่างดี

ขอกราบขอบพระคุณมหาวิทยาลัยเทคโนโลยีสุรนารี ที่ให้ทุนการศึกษาสำหรับผู้มีผลการเรียนดีเด่นที่เข้าศึกษาระดับบัณฑิตศึกษาด้านสาขาวิชาเทคโนโลยีสารสนเทศ สำนักวิชาเทคโนโลยีสังคม และขอกราบขอบพระคุณศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ ห้องปฏิบัติการวิจัยระบบขนส่งและจราจรอัจฉริยะ ที่ให้ทุนสนับสนุนการวิจัยในครั้งนี้

สุดท้ายนี้ ขอกราบขอบพระคุณ บิดา มารดา และครอบครัวโพสาวัง อันเป็นที่รักและเคารพยิ่งที่ให้การอบรมเลี้ยงดู ส่งเสริมด้านการศึกษาเป็นอย่างดีมาโดยตลอด

ปีติภูมิ โพสาวัง

# สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ง
สารบัญ.....	จ
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ฉ
<b>บทที่</b>	
<b>1 บทนำ.....</b>	<b>1</b>
1.1 ความสำคัญและที่มาของปัญหาการวิจัย.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	9
1.3 สมมติฐานการวิจัย.....	9
1.4 ข้อตกลงเบื้องต้น.....	10
1.5 ขอบเขตของการวิจัย.....	10
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	11
1.7 คำอธิบายศัพท์.....	11
<b>2 ปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>13</b>
2.1 แนวคิดเกี่ยวกับสภาพพื้นผิวถนน.....	13
2.1.1 ลักษณะสภาพพื้นผิวถนนที่ผิดปกติ.....	14
2.1.2 ลักษณะสภาพพื้นผิวถนนที่ปกติ.....	16
2.2 แนวคิดเกี่ยวกับวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	17
2.2.1 วิธีการวัดแรงสั่นสะเทือน.....	17
2.2.2 วิธีการสร้างภาพสามมิติ.....	19
2.2.3 วิธีการพื้นฐานจากการมองเห็น.....	20
2.2.4 วิธีการใช้อัลตราโซนิก.....	24
2.2.5 วิธีการวัดเสียง.....	25
2.2.6 วิธีการใช้เครื่องรับรู้ข้อมูลหลายรูปแบบ.....	26



## สารบัญ (ต่อ)

หน้า

2.3	แนวคิดเกี่ยวกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก .....	30
2.3.1	การเรียนรู้ของเครื่อง .....	30
2.3.2	การเรียนรู้เชิงลึก.....	32
2.3.3	การเรียนรู้เชิงลึกหลายรูปแบบ .....	34
2.3.4	สถาปัตยกรรมของตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน .....	35
2.4	แนวคิดเกี่ยวกับการตรวจจับวัตถุโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า .....	43
2.4.1	โครงสร้างของตัวตรวจจับวัตถุ .....	43
2.4.2	โครงสร้างของตัวสกัดคุณลักษณะ .....	46
2.5	งานวิจัยที่เกี่ยวข้องในการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนน ที่ผิดปกติบนโทรศัพท์สมาร์ทโฟน .....	48
2.5.1	งานวิจัยที่ใช้ข้อมูลจากเครื่องรับรู้มาตรวจความเร่ง .....	48
2.5.2	งานวิจัยที่ใช้รูปภาพและภาพวิดีโอจากกล้อง .....	57
2.5.3	งานวิจัยที่ใช้ข้อมูลหลายรูปแบบจากข้อมูลรูปภาพร่วมกับค่าอัตราเร่งของ แรงสั่นสะเทือน.....	68
<b>3</b>	<b>วิธีดำเนินการวิจัย.....</b>	<b>78</b>
3.1	วิธีวิจัย .....	78
3.1.1	การศึกษาปัญหาการพัฒนาระบบขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนน .....	79
3.1.2	การเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนน .....	80
3.1.3	การออกแบบตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนน .....	90
3.1.4	การออกแบบขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนน .....	101
3.1.5	การประเมินตัวแบบและขั้นตอนวิธีในการตรวจจับและจำแนก สภาพพื้นผิวถนนที่ผิดปกติ .....	107
3.2	เครื่องมือที่ใช้ในการวิจัย .....	109
3.2.1	เครื่องมือที่ใช้ในการพัฒนาระบบเก็บรวบรวมข้อมูลและการระบุ สภาพพื้นผิวถนนที่ผิดปกติ .....	109
3.2.2	เครื่องมือที่ใช้ในการสร้างตัวแบบตรวจจับและจำแนกสภาพพื้นผิวถนน ที่ผิดปกติ.....	110

## สารบัญ (ต่อ)

### หน้า


3.3 การเก็บรวบรวมข้อมูล .....	111
3.4 การวิเคราะห์ข้อมูล .....	111
3.4.1 เกณฑ์ประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	111
3.4.2 เกณฑ์ประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ.....	115
<b>4 ผลการวิจัยและการอภิปรายผล .....</b>	<b>121</b>
4.1 ผลการสร้างชุดข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ .....	121
4.1.1 ชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	122
4.1.2 ชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนก สภาพพื้นผิวถนนที่ผิดปกติ.....	125
4.2 ผลการประเมินตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ.....	128
4.2.1 ผลการประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	128
4.2.2 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ.....	136
4.3 ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	139
4.3.1 ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ จากข้อมูลรูปภาพ .....	139
4.3.2 ผลการประเมินขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ ผิดปกติใหม่จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน .....	144
4.3.3 ผลการเปรียบเทียบขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ....	146
4.3.4 ผลการพิจารณาและตัวอย่างการเลือกใช้เกณฑ์คะแนนความเชื่อมั่น ที่เหมาะสม.....	153
4.3.5 ต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	158
<b>5 สรุปและข้อเสนอแนะ.....</b>	<b>160</b>
5.1 สรุปผลการวิจัย .....	162
5.2 ข้อจำกัดของการวิจัย .....	169
5.3 การประยุกต์ผลการวิจัย.....	170
5.4 ข้อเสนอแนะในการวิจัยครั้งต่อไป.....	171
รายการอ้างอิง .....	173

## สารบัญ (ต่อ)

หน้า

### ภาคผนวก

ภาคผนวก ก ผลงานวิจัยที่ได้รับการตีพิมพ์เผยแพร่ .....	184
ภาคผนวก ข ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	185
ภาคผนวก ค ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน สำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ .....	188
ประวัติผู้เขียน .....	192



## สารบัญตาราง

ตารางที่	หน้า
2.1	ประเภทถนนและหน่วยงานผู้รับผิดชอบหลักในประเทศไทย..... 13
2.2	สรุปลักษณะสภาพพื้นผิวถนนที่ใช้ในการตรวจนับ ข้อดีและข้อจำกัด..... 27
2.3	สาเหตุที่ใช้การเรียนรู้เชิงลึก..... 34
2.4	สภาพพื้นผิวถนนที่ผิดปกติที่ถูกตรวจนับ โดยใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่ง..... 48
2.5	ระดับความแม่นยำในการตรวจนับโดยใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่ง..... 49
2.6	ขั้นตอนวิธีและเทคนิคที่ใช้ตรวจนับสภาพพื้นผิวถนน โดยใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่ง..... 53
2.7	ลักษณะสภาพพื้นผิวถนนและชนิดของอุปกรณ์ที่ใช้ตรวจนับ..... 57
2.8	ระดับความแม่นยำในการตรวจนับจากข้อมูลรูปภาพและภาพวิดีโอ..... 58
2.9	เทคนิคที่ใช้ในการประมวลผลภาพเบื้องต้น..... 59
2.10	การใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกและตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า..... 62
2.11	การใช้ข้อมูลจากเครื่องรับรู้หลายรูปแบบเพื่อตรวจนับสภาพพื้นผิวถนนที่ผิดปกติ..... 68
2.12	ทบทวนวรรณกรรมที่เกี่ยวข้องกับขั้นตอนวิธีการตรวจนับสภาพพื้นผิวถนนที่ผิดปกติ..... 72
3.1	ตัวอย่างข้อมูลที่บันทึกในไฟล์ .csv..... 83
3.2	ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้าที่มีค่า mAP สูงสุด 5 ลำดับแรกบนชุดข้อมูลทดสอบของโคโค..... 90
3.3	โครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ..... 97
3.4	กรณีตัวอย่างผลลัพธ์การทำงานเป็น TP FP และ FN..... 114
3.5	เมตริกซ์วัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลแบบ 2 กลุ่ม..... 115
3.6	เมตริกซ์วัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลแบบ 7 กลุ่ม..... 116
4.1	จำนวนชุดข้อมูลรูปภาพสำหรับตรวจนับสภาพพื้นผิวถนนที่ผิดปกติ..... 121
4.2	ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการตรวจนับสภาพพื้นผิวถนน..... 123
4.3	จำนวนชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ..... 125



## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.4 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการจำแนกสภาพพื้นผิวถนน .....	126
4.5 การกำหนดค่าตัวแปรสำหรับการสอนตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับ ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	130
4.6 ผลการประเมินความแม่นยำของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับตรวจจับ สภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลรูปภาพทดสอบ .....	133
4.7 ผลการประเมินประสิทธิภาพของตัวแบบสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ..	134
4.8 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ .....	137
4.9 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้ เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน .....	139
4.10 ผลเปรียบเทียบค่า mAP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	148
4.11 ตัวอย่างการตรวจจับสภาพพื้นผิวที่ผิดปกติประเภทหลุมบ่อด้วยขั้นตอนวิธีใหม่ .....	157
4.12 ต้นทุนการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้ .....	158
4.13 ต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	159
ข.1 ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ .....	185
ค.1 ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน .....	188

## สารบัญรูป

รูปที่	หน้า
2.1	ลักษณะสภาพพื้นผิวถนนที่ผิดปกติ ..... 15
2.2	ลักษณะสภาพพื้นผิวถนนที่ปกติ ..... 16
2.3	การตรวจจับสภาพพื้นผิวถนน โดยใช้เครื่องรับรู้มาตราความเร่ง ..... 18
2.4	การตรวจจับสภาพพื้นผิวถนน โดยใช้กล้องเลเซอร์สแกนแบบสามมิติ ..... 20
2.5	การตรวจจับสภาพพื้นผิวถนน โดยใช้กล้องจากโทรศัพท์สมาร์ทโฟน ..... 23
2.6	การตรวจจับสภาพพื้นผิวถนน โดยใช้อัลตราโซนิก ..... 24
2.7	การตรวจจับสภาพพื้นผิวถนน โดยใช้ไมโครโฟน ..... 25
2.8	สภาพพื้นผิวถนนที่ตรวจจับโดยใช้ข้อมูลจากเครื่องรับรู้ในโทรศัพท์สมาร์ทโฟน ..... 29
2.9	การใช้ขั้นตอนวิธีการประมวลผลภาพร่วมกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก 31
2.10	แสดงเซลล์ประสาทในสมองมนุษย์ ..... 32
2.11	แบบจำลองการทำงานของเซลล์ประสาทเทียม ..... 33
2.12	สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ..... 36
2.13	การใช้ตัวกรองซอแนทภาพเพื่อหาผลลัพธ์ของการคอนโวลูชัน ..... 37
2.14	การหาผลลัพธ์และการเลื่อนตัวกรองคอนโวลูชัน ..... 37
2.15	แผนที่คุณลักษณะหลายจำนวน (Multiple Feature Maps) ..... 38
2.16	การคอนโวลูชันที่มีการเติมค่าศูนย์ให้กับภาพเริ่มต้น ..... 39
2.17	กราฟแสดงสมการฟังก์ชันเรกติไฟด์เชิงเส้น ..... 41
2.18	การทำพลูลิงโดยวิธีการเลือกจุดที่มีค่ามากที่สุด ..... 41
2.19	โครงสร้างแบบ Faster R-CNN ..... 44
2.20	โครงข่ายเสนอพื้นที่ (Region Proposal Network) ..... 44
2.21	โครงข่ายแบบ SSD ..... 46
2.22	ขั้นตอนการตรวจจับสภาพพื้นผิวถนนโดยกำหนดค่าเทรสโฮลด์และการเรียนรู้ของเครื่อง 49
2.23	การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีวัดแรงสั่นสะเทือน ..... 74
2.24	การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการพื้นฐานจากการมองเห็น ..... 75
2.25	กรอบแนวคิดในการวิจัย ..... 76

## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.1 วิธีวิจัย .....	78
3.2 ขั้นตอนการเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนน .....	81
3.3 หน้าจอบันทึกข้อมูลภาพวิดีโอและค่าอัตราเร่งของแรงสั่นสะเทือน .....	81
3.4 ตำแหน่งติดตั้งโทรศัพท์มือถือบนคอนโซลหน้ารถ.....	82
3.5 แอปพลิเคชันบันทึกข้อมูลสภาพพื้นผิวถนน .....	83
3.6 ภาพวิดีโอลักษณะสภาพพื้นผิวถนนที่บันทึกในไฟล์ .mp4.....	84
3.7 ตำแหน่งการเก็บข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลภาพวิดีโอ .....	84
3.8 ตัวอย่างไฟล์รูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนที่ผ่านการสกรีนข้อมูลให้อยู่ในตำแหน่งที่ใกล้เคียงกัน .....	86
3.9 ขั้นตอนการสร้างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนน.....	86
3.10 โปรแกรม LabelImg สำหรับระบุสภาพพื้นผิวถนน .....	87
3.11 ไฟล์โครงสร้าง XML ของภาพที่ใช้ในการสร้างชุดข้อมูลเรียนรู้และทดสอบ.....	87
3.12 โครงสร้างของไฟล์ระบุแผนที่ป้ายกำกับที่ต้องการตรวจจับสภาพพื้นผิวถนน .....	88
3.13 โครงสร้างของตัวแบบจำแนกสภาพพื้นผิวถนนที่ฝึกปรักจากข้อมูลรูปภาพ .....	92
3.14 โครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ .....	94
3.15 การตรวจจับสภาพพื้นผิวถนนที่ฝึกปรักจากข้อมูลรูปภาพ .....	101
3.16 ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ฝึกปรักจากข้อมูลรูปภาพ .....	102
3.17 การตรวจจับสภาพพื้นผิวถนนที่ฝึกปรักจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน .....	104
3.18 ขั้นตอนวิธีใหม่ในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ฝึกปรักใหม่จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน.....	105
3.19 ขั้นตอนการประเมินตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ฝึกปรัก.....	108
4.1 การติดตั้งโทรศัพท์มือถือและระยะทางที่ใช้ในการตรวจจับสภาพพื้นผิวถนน .....	121
4.2 แสดงข้อมูลผลการประเมินระหว่างการสอนของตัวแบบ.....	129
4.3 กราฟแสดงการสูญเสียทั้งหมด (Total Loss) ของตัวแบบ.....	131
4.4 การประเมินผลตรวจจับของภาพตัวอย่างในแต่ละรอบการสอน .....	132
4.5 ภาพวัตถุของสภาพพื้นผิวถนนที่ฝึกปรักที่มีขนาดแตกต่างกัน .....	135

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.6 การเปรียบเทียบผลประเมินของตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ .....	138
4.7 ผลการประเมินด้วยค่า AP และ mAP ของตัวแบบ SSD ResNet50 FPN เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับ .....	140
4.8 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่ถูกต้อง.....	141
4.9 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่ไม่ถูกต้อง .....	143
4.10 ผลการประเมินด้วยค่า AP และ mAP ของตัวแบบ SSD ResNet50 FPN ร่วมกับ ตัวแบบ Multimodal DCNN เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับ.....	146
4.11 ผลการเปรียบเทียบค่า mAP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	147
4.12 ผลการเปรียบเทียบค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	149
4.13 ตัวอย่างการตรวจจับสภาพพื้นผิวที่ผิดปกติด้วยขั้นตอนวิธีใหม่ .....	154
5.1 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและค่าอัตราเร่งของ แรงสั่นสะเทือน .....	160
5.2 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ .....	165
5.3 สถาปัตยกรรมของระบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ.....	170



# บทที่ 1

## บทนำ

### 1.1 ความสำคัญและที่มาของปัญหาการวิจัย

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยอัตโนมัติ เป็นงานที่มีความสำคัญต่อการวางแผนบำรุงรักษาถนนให้คงรูปเดิมหรือมีสภาพใกล้เคียงกับสภาพการก่อสร้างแล้วเสร็จ เพื่อให้ได้รับข้อมูลสภาพความเสียหายของพื้นผิวถนนที่ถูกต้องและรวดเร็ว และเพื่อประกันความปลอดภัยในการเดินทาง เกิดความสะดวกรวดเร็ว ความคล่องตัวของระบบขนส่งและความเจริญเติบโตทางเศรษฐกิจของประเทศ (World Road Association, 2014, p. 1) ยิ่งไปกว่านั้น ข้อมูลสภาพความเสียหายของพื้นผิวถนนสามารถนำไปใช้ในระบบแจ้งเตือนผู้ขับขี่เพื่อวางแผนตัดสินใจในการเดินทาง และใช้ในระบบรถขับเคลื่อนอัตโนมัติ เพื่อชะลอความเร็วหรือเบรกโดยอัตโนมัติ (Kadam and Ghogare, 2017, p. 313)

ปัจจุบันประเทศไทยมีโครงข่ายถนนความยาวประมาณ 716,331 กิโลเมตร และมีหน่วยงานหลักที่มีหน้าที่รับผิดชอบ ก่อสร้าง กำกับดูแล บำรุงรักษาถนน จำนวน 3 หน่วยงาน ได้แก่ 1) กรมทางหลวง 2) กรมทางหลวงชนบท และ 3) องค์การปกครองส่วนท้องถิ่น (กรมทางหลวง, 2561; สำนักบำรุงทาง กรมทางหลวงชนบท, 2561, หน้า ๓; สำนักงานนโยบายและแผนการขนส่งและจราจร, 2558, หน้า 6; กองพัฒนาและส่งเสริมการบริหารงานท้องถิ่น, 2562) โครงข่ายถนนเมื่อเปิดใช้งานไปในระยะเวลาหนึ่ง สภาพพื้นผิวถนนมักเกิดความชำรุดเสียหาย พื้นผิวถนนเสื่อมเป็นหลุมเป็นบ่อ คุณภาพถนนแยกลงในทุก ๆ วัน จากรายงานการแข่งขันระดับโลกปี 2017-2018 โดยเปรียบเทียบจาก 137 ประเทศทั่วโลก พบว่าคุณภาพถนนของประเทศไทยจัดอยู่ในอันดับที่ 59 (Schwab and Sala-i-Martin, 2017, p. 287) คุณภาพของถนนที่ไม่ดีส่งผลกระทบต่อต้นทุนในการบำรุงรักษา ความมีประสิทธิภาพและความปลอดภัยในการเดินทาง

ยิ่งไปกว่านั้น หน่วยงานที่รับผิดชอบต้องใช้งบประมาณในการบำรุงรักษาถนนต่อปีเป็นจำนวนมาก เช่น ในปี พ.ศ. 2559 กรมทางหลวงได้รับงบประมาณเป็นจำนวน 22,694 ล้านบาท (กรมทางหลวง, 2560, หน้า 101) กรมทางหลวงชนบทได้รับงบประมาณเป็นจำนวน 18,092 ล้านบาท (สำนักบำรุงทางกรมทางหลวงชนบท, 2559, หน้า 5) เพื่อใช้สำรวจ ประเมินสภาพความเสียหายและวางแผนบำรุงรักษาตามลักษณะความเสียหายของพื้นผิวถนน การสำรวจ ติดตาม ตรวจสอบสภาพพื้นผิวถนนแบบเวลาจริงจึงถูกนำมาใช้เพื่อช่วยจัดการปัญหาความผิดปกติทางถนนให้รวดเร็วขึ้น เพื่อช่วยลดอุบัติเหตุทางถนน เพิ่มความปลอดภัยในการเดินทางและลดต้นทุนในการบำรุงรักษาถนน

และยานพาหนะ นอกจากนี้วิศวกรทางถนนสามารถนำข้อมูลสภาพพื้นผิวถนนไปใช้สร้างดัชนีสภาพทาง (Road Condition Index: RCI) เพื่อประเมินสภาพถนนได้อีกด้วย (Seraj, Zhang, Turkes, Meratnia, and Havinga, 2015, p. 1170; World Road Association, 2014, p 32)

หลายปีที่ผ่านมาจึงพบงานวิจัยที่เกี่ยวข้องกับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้เทคนิควิธีการแบบอัตโนมัติที่หลากหลายและแตกต่างกันตามลักษณะทางกายภาพของถนนในแต่ละประเทศ ในงานวิจัยนี้จำแนกวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติตามชนิดเครื่องรับรู้ (Sensor) ออกเป็น 6 วิธี ได้แก่ 1) วิธีการวัดแรงสั่นสะเทือน (Vibration-based Methods) 2) วิธีการใช้เครื่องรับรู้วัตถุแบบสามมิติ (3D Sensor-based Methods) 3) วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) 4) วิธีการวัดคลื่นเสียงความถี่สูง (Ultrasonic-based Methods) 5) วิธีการวัดเสียง (Audio-based Methods) และ 6) วิธีการใช้เครื่องรับรู้หลายรูปแบบ (Multimodal Data-based Methods) (Koch and Brilakis, 2011, p. 5; Kim and Ryu, 2014a, p. 603; Sharma, Singh, and Chand, 2016, p. 56; Enigo, Kumar, Vijay, and Prabu, 2016, p. 317; Madli, Hebbar, Pattar, and Golla, 2015, p. 4313; Tushar and Archana, 2017, p. 10324; Coenen and Golroo, 2017, p. 6)

วิธีการวัดแรงสั่นสะเทือน (Vibration-based Methods) เป็นการตรวจจับสภาพพื้นผิวถนนจากเครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) ในโทรศัพท์สมาร์ทโฟน (Smartphone) บนล้อรถ (On Wheel) บนแกนล้อ (On Wheel-axis) ในรถ (In Car) และในอุปกรณ์เครื่องมืออื่น ๆ เพื่อตรวจจับค่าอัตราเร่งของแรงสั่นสะเทือนของแนวแกนทั้ง 3 แกน ได้แก่ แกนเอ็กซ์ (X Axis) แกนวาย (Y Axis) และแกนแซด (Z Axis) ตามสภาพพื้นผิวถนนที่รถขับผ่าน

ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้วิธีวัดแรงสั่นสะเทือน ได้แก่ หลุมบ่อ (Pothole) (Yu, B. and Yu, X., 2006; De Zoysa, Keppitiyagama, Seneviratne, and Shihan, 2007; Eriksson et al., 2008; Mohan, Padmanabhan, and Ramjee, 2008; Mednis, Strazdins, Zviedris, Kanonirs, and Selavo, 2011; Perttunen et al., 2011; Astarita et al., 2012; Fazeen, Gozick, Dantu, Bhukhiya, and González, 2012; Kulkarni, Mhalgi, Gurnani, and Giri, 2014; Wang, Chen, Cheng, Lin, and Lo, 2015; Predic and Stojanovic, 2015; Casas-avellaneda and Lopez-parra, 2016) การปูดุน (Shoving) หรือเนินชะลอความเร็ว (Speed Bump) (Eriksson et al., 2008; Astarita et al., 2012; Fazeen et al., 2012) รอยแตก (Crack) รอยต่อถนน (Gaps) (Mednis et al., 2011) และความขรุขระของพื้นผิวถนน (Roughness) (González, O'brien, Li, and Cashell, 2008; Tai, Chan, and Hsu, 2010; Fazeen et al., 2012; Douangphachanh and Oneyama, 2013; Buttlar and Islam, 2014)

ข้อดีของวิธีวัดแรงสั่นสะเทือน คือ เป็นระบบที่มีต้นทุนต่ำ ใช้ขั้นตอนวิธีอย่างง่ายในการพัฒนา ใช้พื้นที่ในการจัดเก็บข้อมูลน้อยและข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลได้แบบเวลาจริง อย่างไรก็ตามการใช้วิธีวัดแรงสั่นสะเทือนตรวจจับสภาพพื้นผิวถนนที่ผิดปกติอาจให้ผลลัพธ์ที่ผิดพลาด เช่น รอยต่อถนน ฝาท่อระบายน้ำที่ต่างระดับกับผิวถนน อุณหภูมิหรือยางชะลอความเร็วที่ถูกตรวจพบว่าเป็นหลุมบ่อ ยิ่งไปกว่านั้นหลุมบ่อที่อยู่กลางช่องจราจรไม่สามารถตรวจพบได้โดยการใช้เครื่องรับรู้มาตรฐานความเร่ง เนื่องจากไม่มีการตกกระทบของล้อรถ (Eriksson et al., 2008, pp. 34-37; Kim and Ryu, 2014, p. 604; Chugh, Bansal, and Sofat, 2014, p. 600; Jo and Ryu, 2015, p. 29317) นอกจากนี้สิ่งรบกวนของยาง (Tire Noise) เช่น ความแปรปรวนของแรงดันยาง (Tire pressure variance) การเปลี่ยนรูปร่าง (Tire Deformation) การสั่นสะเทือนของยาง (Vibration of the Tires) ยังส่งผลต่อการสั่นสะเทือนขนาดเล็กของเครื่องรับรู้มาตรฐานความเร่งอีกด้วย (Coenen and Golroo, 2017, p. 11)

วิธีที่สองการใช้เครื่องรับรู้วัตถุแบบสามมิติ (3D Sensor-based Methods) เป็นการตรวจจับสภาพพื้นผิวถนนจากกล้องถ่ายภาพวัตถุและใช้เครื่องรับรู้วัตถุแบบสามมิติตรวจจับความลึกของวัตถุ จากนั้นประมวลผลข้อมูลออกมาเป็นแบบจำลองสามมิติเพื่อวิเคราะห์ข้อมูลสภาพพื้นผิวถนน

ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้เครื่องรับรู้วัตถุแบบสามมิติ ได้แก่ หลุมบ่อ (Pothole) รอยแตก (Crack) รอยปะซ่อม (Patching) ร่องล้อ (Rutting) การปูดนูน (Shoving) การซึม (Bleeding) ผิวมวลรวมถูกขัดสีเป็นมัน (Polished Aggregate) การหลุดร่อน (Ravelling) ความเสียหายตามขอบ (Edge Drop-off) น้ำไหลซึมขึ้นมาจากรอยแตกหรือชั้นถนน (Water Bleeding) และความขรุขระของผิวถนน (Roughness) (Mathavan, Kamal, and Rahman, 2015, p. 7; Coenen and Golroo, 2017, p. 6)

ข้อดีของวิธีการใช้เครื่องรับรู้วัตถุแบบสามมิติ คือ ได้รับข้อมูลสภาพพื้นผิวถนนที่ผิดปกติอย่างละเอียดและมีความถูกต้องสูง อย่างไรก็ตาม ข้อจำกัดของวิธีการนี้ คือ อุปกรณ์มีราคาแพงและเป็นวิธีที่ต้องใช้การคำนวณและประมวลผลสูง (Kim and Ryu, 2014, pp. 604-605; Enigo et al., 2016, p. 317)

วิธีที่สามใช้วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) เป็นการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากกล้องถ่ายภาพเพื่อจัดเก็บและบันทึกข้อมูลให้อยู่ในรูปแบบไฟล์รูปภาพหรือไฟล์วิดีโอจากนั้นใช้ขั้นตอนวิธีการประมวลผลภาพ (Image Processing) (Koch and Brilakis, 2011; Huidrom, Das, and Sud, 2013; Buza, Omanovic, and Huseinnovic, 2013; Kim and Ryu, 2014b; Enigo, Kumar, Vijay, and Prabu, 2016; Jo and Ryu, S. 2017; Buchinger and Silva, 2014; Nienaber, Booyesen, and Kroon, 2015; Ryu, Kim, T., and Kim, Y., 2015; Radopoulou and Brilakis, 2015) ใช้ขั้นตอนวิธีการประมวลผลภาพและการเรียนรู้ของเครื่อง (Lin and Liu, 2010)

ใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolution Neural Networks) ที่ถูกออกแบบโครงสร้างสถาปัตยกรรมเอง (Zhang, Yang, Daniel, and Zhu, 2016; Kawano, Yonezawa, and Nakazawa, J., 2017; Eisenbach et al., 2017) และใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) (Maeda, Sekimoto, and Seto, 2016a; Maeda, Sekimoto, and Seto, 2016b; Maeda et al., 2018; Singh and Shekhar, 2018; Koh et al., 2019)

ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้วิธีการพื้นฐานจากการมองเห็น ได้แก่ หลุมบ่อ (Pothole) รอยแตก (Crack) รอยแตกตามแนวยาว (Longitudinal Cracks) รอยแตกตามแนวขวาง (Transverse Cracks) รอยแตกหนังจระเข้ (Alligator Cracks) รอยปะซ่อม (Patching) ร่องล้อ (Rutting) การปูดนูน (Shoving) การเยิ้ม (Bleeding) ความขรุขระของผิวถนน (Roughness) เส้นจรรยาจรูรุดและเส้นข้ามทางม้าลายจรูรุด (Coenen and Golroo, 2017, p. 6; Maeda, et al., 2018, p. 7)

ข้อดีของวิธีการพื้นฐานจากการมองเห็น คือ สามารถตรวจจับหลุมบ่อกลางช่องจราจร คำนวณจำนวนของหลุมบ่อและตรวจจับฝาท่อระบายน้ำที่ต่างระดับกับผิวถนนได้ อย่างไรก็ตาม ข้อจำกัดของงานวิจัย คือ ภาพถ่ายพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงอาจส่งผลกระทบต่อความถูกต้องในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน (Koch and Brilakis, 2011, p. 512; Kim and Ryu, 2014, p. 604; Jo and Ryu, 2015, p. 29329; Nienaber et al., 2015, p. 9; Ryu et al., 2015, p. 9)

วิธีที่สื่การวัดคลื่นเสียงความถี่สูง (Ultrasonic-based Methods) หรือการใช้เครื่องรับรู้อัลตราโซนิก (Ultrasonic Sensor) เป็นการตรวจจับสภาพพื้นผิวถนนโดยวัดคลื่นเสียงความถี่สูงเพื่อวัดความลึกหรือความสูงจากพื้นรถหรือจากตำแหน่งที่ติดตั้งไปยังพื้นผิวถนน (Madli et al., 2015, p. 4313; Rayen, 2016, p. 548; Tushar and Archana, 2017, p. 10324)

ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้เครื่องรับรู้อัลตราโซนิก ได้แก่ หลุมบ่อ (Pothole) ร่องล้อ (Rutting) เนินชะลอความเร็ว (Humps) และความเสียหายตามขอบ (Edge Drop-off) (Madli et al., 2015, p. 4313; Rayen, 2016, p. 548; Tushar and Archana, 2017, p. 10324; Coenen and Golroo, 2017, p. 6)

ข้อดีของวิธีการใช้เครื่องรับรู้อัลตราโซนิก คือ ใช้ต้นทุนต่ำในการพัฒนา พื้นที่ในการจัดเก็บข้อมูลน้อยและข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลได้แบบเวลาจริง อย่างไรก็ตาม ข้อจำกัดของงานวิจัย คือ หลุมบ่อที่มีโคลนไม่สามารถตรวจพบได้ ซึ่งการแจ้งเตือนข้อมูลสภาพพื้นผิวถนนเป็นเพียงการใช้ข้อมูลเดิมที่ถูกจัดเก็บในฐานข้อมูลไว้แล้ว (Madli et al., 2015, p. 4313)



วิธีที่ทำการวัดเสียง (Audio-based Methods) เป็นการตรวจจับสภาพพื้นผิวถนนโดยใช้เครื่องรับรู้ประเภทไมโครโฟนที่ถูกติดตั้งภายในรถและภายนอกบริเวณใกล้ล้อรถ เพื่อวัดเสียงของล้อรถขณะตกกระทบกับพื้นผิวถนนในลักษณะต่าง ๆ

ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้วิธีการวัดเสียงจากการติดตั้งไมโครโฟนไว้ภายในรถ ได้แก่ หลุมบ่อ (Pothole) ขนาดใหญ่ ขนาดกลางและขนาดเล็ก (Mednis, Strazdins, Liepins, Gordjusins, and Selavo, 2010) ส่วนลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้โดยใช้วิธีการวัดเสียงจากการติดตั้งไมโครโฟนใกล้ล้อรถ ได้แก่ ผิวถนนเยิ้ม (Bleeding) ผิวรวมถูกรวมถูกขัดสีเป็นมัน (Polished Aggregate) การหลุดร่อน (Ravelling) (Zhang, Mcdaniel, and Wang, 2013) ลักษณะสภาพพื้นผิวถนนที่มีน้ำไหลซึมขึ้นมาจากรอยแตกหรือชั้นถนน (Water Bleeding) และความขรุขระของผิวถนน (Roughness) (Abdic, Fridman, Brown, Angell, Reimer, Marchi, and Schuller, 2016)

ข้อดีของวิธีการวัดเสียง คือ ใช้ต้นทุนต่ำในการพัฒนา พื้นที่ในการจัดเก็บข้อมูลน้อยและข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลแบบเวลาจริง (Real Time) ข้อจำกัดของงานวิจัย คือ เสียงรบกวน (Noise) เช่น เสียงของยางรถ เสียงลม เสียงของเครื่องยนต์ เสียงจากสภาพแวดล้อมรอบข้าง อาจส่งผลกระทบต่อวิธีการวัดเสียงของล้อรถขณะตกกระทบกับพื้นผิวถนนในลักษณะต่าง ๆ แต่อย่างไรก็ตาม การใช้วิธีการวัดเสียงอาจใช้เป็นส่วนเสริมในการตรวจสอบและสนับสนุนเครื่องรับรู้อื่นได้ (Zhang, Mcdaniel, and Wang, 2013, p. 1; Coenen and Golroo, 2017, p. 11)

วิธีที่ทำการใช้ข้อมูลหลายรูปแบบ (Multimodal Data-based Methods) เป็นการตรวจจับสภาพพื้นผิวถนนโดยใช้เครื่องรับรู้สองชนิดขึ้นไป เพื่อส่งเสริมสนับสนุนข้อมูลในการเรียนรู้ร่วมกันและเพิ่มความถูกต้องในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในลักษณะต่าง ๆ พบได้ในงานวิจัยของ Orhan (2013) Orhan และ Eren (2013a; 2013b) และงานวิจัยของ Rajamohan และคณะ (2015) ที่ใช้เครื่องรับรู้มาตรความเร่งร่วมกับรูปภาพจากกล้อง เพื่อตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อ (Potholes) เนินชะลอความเร็ว (Speed Bumps) และตรวจจับสิ่งกีดขวางบนถนน

ข้อดีของวิธีการใช้เครื่องรับรู้ข้อมูลหลายรูปแบบ คือ ส่งเสริมสนับสนุนข้อมูลในการเรียนรู้ร่วมกันเพื่อเพิ่มความถูกต้องในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในลักษณะต่าง ๆ อย่างไรก็ตามข้อจำกัดของงานวิจัย คือ บางงานวิจัยใช้ขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนจากข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อระบุสภาพพื้นผิวที่ผิดปกติแล้วจึงรูปภาพมาแสดงให้เห็นตรงตามผลการวิเคราะห์ข้อมูลจากเครื่องรับรู้มาตรความเร่งเท่านั้น (Orhan and Eren, 2013a, Orhan and Eren, 2013b; Orhan, 2013) ซึ่งไม่มีขั้นตอนวิธีในการวิเคราะห์รูปภาพร่วมด้วย นอกจากนี้ข้อมูลการทดสอบที่ไม่มีสภาพแวดล้อมใกล้เคียงกับข้อมูลที่ใช้ในการทดลอง พบว่า ความแม่นยำ

ในการจำแนกสภาพพื้นผิวถนนลดลงมาก เนื่องจากมีสภาพแวดล้อมเป็นอุปสรรค เช่น แสงและเงาบนพื้นผิวถนน (Rajamohan, Gannu, and Rajan, 2015, p. 1240)

ถึงแม้ว่าวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติทั้ง 6 วิธี มีการพัฒนาขั้นตอนวิธีด้วยเทคนิคต่าง ๆ ให้มีความน่าเชื่อถือที่สูงขึ้น แต่อย่างไรก็ตาม การตรวจสอบสภาพพื้นผิวถนนที่ผ่านมายังไม่มีการดำเนินการได้อย่างสมบูรณ์ (Chugh, Bansal, and Sofat, 2014, pp. 599-600) เนื่องจากวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแต่ละวิธีใช้เครื่องรับรู้ (Sensor) ที่แตกต่างกัน และถูกพัฒนาด้วยเครื่องรับรู้อุปแบบเดี่ยว (Single Sensor) จึงทำให้มีข้อดี ข้อจำกัดและลักษณะสภาพพื้นผิวถนนที่ตรวจจับได้แตกต่างกันด้วย

อย่างไรก็ดี การสำรวจและประเมินสภาพพื้นผิวถนนในประเทศไทย เช่น กรมทางหลวง เริ่มแรกในปี พ.ศ. 2550 ใช้วิธีการประเมินด้วยสายตา (Visual Inspection) ตามคำจำกัดความของความเสียหายแต่ละชนิด (กรมทางหลวง, 2550) ซึ่งเป็นวิธีที่ต้องใช้ระยะเวลาในการสำรวจยาวนาน และต้องใช้คนเป็นจำนวนมากในการรวบรวมข้อมูลสภาพความเสียหายของพื้นผิวถนน ต่อมาในปี พ.ศ. 2558 พัฒนาระบบบริหารจัดการความปลอดภัยทางถนนสำหรับกรมทางหลวง เพื่อสำรวจและรวบรวมข้อมูลความปลอดภัยทางถนนโดยใช้ยานพาหนะที่ติดตั้งอุปกรณ์สำรวจ ประกอบด้วย กล้องบันทึกภาพความละเอียดสูงที่เชื่อมโยงข้อมูลกับพิกัดตำแหน่งด้วยระบบ GPS (Global Positioning System) เพื่อจัดทำระบบสารสนเทศภูมิศาสตร์ เครื่องวัดระดับแบบเลเซอร์ (Laser Profilometer) เพื่อวัดความขรุขระ วัดค่าร่องล้อ วัดความหยาบผิวทาง เครื่องวัดค่าอัตราเร่งของแรงสั่นสะเทือน (Accelerometer) เพื่อใช้ในการปรับแก้ความคลาดเคลื่อนของเครื่องวัดระดับผิวทางแบบเลเซอร์เนื่องจากการสั่นของรถสำรวจ เครื่องวัดระยะทาง อุปกรณ์วัดค่ายกโค้ง เพื่อวัดค่าความเอียงของถนน อุปกรณ์รับสัญญาณ GPS และระบบคอมพิวเตอร์บันทึกข้อมูลสำรวจที่ติดตั้งในรถสำรวจ (สถาบันการขนส่งในจุฬาลงกรณ์มหาวิทยาลัย, 2558) แม้ว่าวิธีการสำรวจและประเมินสภาพพื้นผิวถนนโดยใช้ยานพาหนะที่ติดตั้งอุปกรณ์สำรวจแบบเลเซอร์จะทำให้ได้รับข้อมูลสภาพพื้นผิวถนนที่ผิดปกติอย่างละเอียดและมีความถูกต้องสูง อย่างไรก็ตาม อุปกรณ์สำรวจที่ใช้มีราคาแพงและเป็นวิธีที่ต้องใช้การคำนวณและประมวลผลสูง จากการสอบถามสำนักมาตรฐานและประเมินผลกรมทางหลวงในการประชุมนำเสนอผลพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติของผู้วิจัย พบว่า กรมทางหลวงมีรถสำรวจแบบเลเซอร์จำนวน 1 คัน มีมูลค่าสูงถึง 10 ล้านบาท ซึ่งต้นทุนในการพัฒนาสูงและไม่เพียงพอต่อความต้องการใช้สำรวจสภาพพื้นผิวถนนได้ทั่วประเทศ

วิธีการตรวจสอบสภาพพื้นผิวถนนที่ผิดปกติโดยใช้อุปกรณ์ที่มีต้นทุนต่ำในการพัฒนาใช้งานง่าย บุคคลทั่วไปสามารถเข้าถึงและเก็บรวบรวมข้อมูลได้เป็นจำนวนมากและในบริเวณกว้างโดยไม่จำเป็นต้องติดตั้งอุปกรณ์พิเศษเพิ่มเติมที่มีราคาแพง จึงเป็นแนวทางหนึ่งที่ใช้พิจารณาเลือก

วิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Orhan, 2013, p.11; Jo and Ryu, 2015, p. 29317) ด้วยเหตุผลดังกล่าว งานวิจัยนี้จึงเลือกใช้โทรศัพท์มือถือสำหรับเป็นเครื่องมือในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ในปัจจุบันผู้ใช้รถใช้ถนนส่วนใหญ่พกพาโทรศัพท์มือถือติดตามตัวในระหว่างการเดินทาง หากนำข้อมูลจากเครื่องรับรู้ (Sensor) ที่มีประโยชน์ในโทรศัพท์มือถือ เช่น เครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) โดยใช้วิธีวัดแรงสั่นสะเทือน (Vibration-based Methods) และเครื่องรับรู้ภาพ โดยใช้วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) มาใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติร่วมกัน เพื่อเพิ่มคุณลักษณะเด่นของข้อมูล ผลลัพธ์ที่น่าจะเป็นอีกวิธีการหนึ่งที่จะช่วยเพิ่มความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติมากยิ่งขึ้น

ที่ผ่านมาวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการพื้นฐานจากการมองเห็นจากรูปภาพหรือรูปภาพวิดีโอ ใช้วิธีการสกัดคุณลักษณะด้วยมือ (Hand-crafted Feature Extraction) โดยใช้ขั้นตอนวิธีการประมวลผลภาพ (Lin and Liu, 2010; Koch and Brilakis, 2011; Buza, Omanovic, and Huseinnovic, 2013; Huidrom, Das, and Sud, 2013) ความถูกต้องของการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติขึ้นอยู่กับคุณภาพของการสกัดคุณลักษณะพิเศษของข้อมูล (Features Extraction) และประสิทธิภาพของการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติถูกจำกัดด้วยข้อมูลจากเครื่องรับรู้รูปแบบเดียว

ปัจจุบันวิธีการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันเป็นขั้นตอนวิธีที่สามารถเรียนรู้ ค้นหาคุณลักษณะพิเศษของรูปภาพและจำแนกประเภทได้แบบอัตโนมัติ โดยไม่จำเป็นต้องใช้วิธีการสกัดคุณลักษณะพิเศษด้วยมือ นอกจากนี้ การเรียนรู้หลายรูปแบบ (Multimodal Learning) ด้วยโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks: Multimodal DCNN) เป็นนวัตกรรมใหม่ที่สกัดคุณลักษณะ เรียนรู้และจำแนกคุณลักษณะข้อมูลหลายรูปแบบที่เกิดขึ้นในเวลาเดียวกัน ยิ่งไปกว่านั้น การประยุกต์ใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) ยังเป็นการถ่ายโอนการเรียนรู้และปรับปรุงการเรียนรู้ในงานใหม่ ส่งผลให้ประหยัดเวลาในการเรียนรู้ ไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมากและมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น (Torrey and Shavlik, 2010) ด้วยเหตุผลดังกล่าว งานวิจัยนี้จึงศึกษาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าและการเรียนรู้หลายรูปแบบด้วยโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ เพื่อใช้เป็นแนวทางในการพัฒนาขั้นตอนวิธีใหม่ในงานวิจัยครั้งนี้

สำหรับประเด็นปัญหาในงานวิจัยที่เกี่ยวข้องกับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยใช้เครื่องรับรู้ในโทรศัพท์มือถือ มีประเด็นที่น่าสนใจสำหรับการดำเนินการวิจัยในครั้งนี้

คือ เหตุการณ์ที่มีการตรวจจับสภาพพื้นผิวถนนผิวดินลาด จากวิธีวัดแรงสั่นสะเทือน (Vibration-based Methods) โดยใช้เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์มือถือ พบว่า มีหลายเหตุการณ์ที่ไม่ได้เป็นความผิดปกติของถนน เช่น รอยต่อถนน ลูกกระพรวนหรือยางชะลอความเร็ว เหตุการณ์เหล่านี้แตกต่างจากสภาพถนนที่เป็นหลุมบ่อ ยิ่งไปกว่านั้น หลุมบ่อในกลางช่องจราจรยังไม่สามารถตรวจพบได้โดยการใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่งเพียงอย่างเดียว เนื่องจากการไม่มีการตกกระทบของล้อรถ (Eriksson et al., 2008, pp. 34-37; Chugh, Bansal, and Sofat, 2014, p. 600; Coenen and Golroo, 2017, p. 11; Jo and Ryu, 2015, p. 29317) ส่วนวิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) โดยใช้รูปภาพจากกล้องในโทรศัพท์มือถือ พบว่า ภาพถ่ายพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงอาจส่งผลกระทบต่อความถูกต้องในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อน คราบสีและคราบสกปรกต่าง ๆ บนผิวถนน (Koch and Brilakis, 2011, p. 512; Kim and Ryu, 2014, p. 604; Jo and Ryu, 2015, p. 29329; Nienaber et al., 2015, p. 9; Ryu et al., 2015, p. 9; Radopoulou, and Brilakis, 2015, p. 102) ดังนั้น ขั้นตอนวิธีที่มีประสิทธิภาพควรมีการพัฒนาเพื่อให้เพิ่มความแม่นยำมากยิ่งขึ้นสำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติตามลักษณะทางกายภาพของถนน

งานวิจัยนี้จึงเสนอแนวทางการแก้ไขปัญหาเพื่อออกแบบและพัฒนาขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด (Mean Average Precision: mAP) จำนวน 5 ลำดับแรก เมื่อทดสอบบนชุดข้อมูลรูปภาพของโคโค (COCO Dataset) ได้แก่ 1) ตัวแบบ Faster R-CNN NAS 2) ตัวแบบ Faster R-CNN Inception\_ResNetV2 Atrous 3) ตัวแบบ SSD ResNet50 FPN 4) ตัวแบบ SSD MobileNetV1 FPN และ 5) ตัวแบบ Faster R-CNN ResNet101 เพื่อเลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่เหมาะสมที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดเมื่อทดสอบบนชุดข้อมูลสภาพพื้นผิวถนนที่ผิดปกติ จำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips)

จากนั้นนำผลการตรวจจับที่ได้มาตรวจสอบและเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนใหม่ด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบ (Multimodal Deep Learning) โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal DCNN) จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อถ่ายทอดความรู้ที่เกี่ยวข้องกันในเวลาเดียวกัน ซึ่งเป็นการนำความสัมพันธ์ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนมาช่วยในการรับรู้ข้อมูลรูปภาพและนำข้อมูลรูปภาพมาช่วยในการรับรู้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อสร้าง

ระบบอัตโนมัติในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ จำนวน 7 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal Road) ตามลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงที่ส่งผลกระทบต่อความแม่นยำในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกบนพื้นผิวถนน

ผลที่ได้จากงานวิจัยนี้ก่อให้เกิดประโยชน์ในแง่ของความรู้ทางวิชาการ (Contributions) ดังนี้

1) ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าและเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการเรียนรู้เชิงลึกหลายรูปแบบด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบที่เกิดจากการหลอมรวมคุณลักษณะของข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน

2) ชุดข้อมูลสภาพพื้นผิวถนนที่ประกอบด้วยข้อมูลรูปภาพใช้สำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนใช้สำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่ ชุดข้อมูลสภาพพื้นผิวถนนในงานวิจัยนี้สามารถนำไปใช้เพื่อพัฒนาขั้นตอนวิธีในการเรียนรู้และทดสอบเพื่อสร้างตัวแบบตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติต่อไป

3) ผลจากการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติสามารถนำไปวิเคราะห์เพื่อเลือกใช้วิธีการซ่อมบำรุงรักษาถนนที่เหมาะสม ช่วยลดต้นทุนในการบำรุงรักษาถนนและเพิ่มความปลอดภัยในการเดินทางต่อไป

## 1.2 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อพัฒนาขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ข้อมูลหลายรูปแบบต้นทุนต่ำจากเครื่องรับรู้อุปกรณ์และมาตรการความเร่งในโทรศัพท์มือถือ

1.2.2 เพื่อประเมินประสิทธิภาพของขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ



### 1.3 สมมติฐานการวิจัย

ขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ข้อมูลหลายรูปแบบต้นทุนต่ำจากเครื่องรับรู้อุปกรณ์ภาพและมาตรการความเร่งใน โทรศัพท์มือถือสามารถตรวจจับสภาพพื้นผิวถนนได้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำมากกว่าขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนโดยใช้ข้อมูลจากเครื่องรับรู้อุปกรณ์ภาพเพียงอย่างเดียว

### 1.4 ข้อตกลงเบื้องต้น

1.4.1 การติดตั้งโทรศัพท์มือถือเพื่อเก็บรวบรวมข้อมูล ถูกติดตั้งไว้ในตำแหน่งที่กำหนดบริเวณตรงกลางคอนโซลภายในยานพาหนะและด้านบนของโทรศัพท์มือถือหันไปทางด้านซ้ายของตัวรถ กล้องในโทรศัพท์มือถือหันไปทางทิศทางการเดินทางของรถเพื่อให้มุมมองที่แสดงสภาพพื้นผิวถนนที่ชัดเจนตามวิธีเตรียมการทดลองเท่านั้น

1.4.2 ขั้นตอนวิธีที่ถูกพัฒนาขึ้นสามารถนำไปใช้ได้กับยานพาหนะที่มีระบบการป้องกันแรงสั่นสะเทือนที่ใกล้เคียงกับยานพาหนะที่ใช้ในการทดลองเท่านั้น

1.4.3 ระยะทางที่สามารถมองเห็นพื้นผิวถนนได้ชัดเจนในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติห่างจากตัวรถประมาณ 6.5 เมตร

1.4.4 โทรศัพท์มือถือที่ใช้ในการเก็บรวบรวมข้อมูล คือ Samsung Galaxy A9 Pro ปี 2016 ซึ่งถูกติดตั้งกลางคอนโซลหน้ารถยนต์รุ่น Honda City 2010

1.4.5 ความละเอียดของกล้องโทรศัพท์มือถือที่ใช้ คือ 1920×1080 พิกเซล (Pixels) และความถี่ที่ใช้ในการเก็บข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเท่ากับ 80 เฮิรตซ์ (Hz.)

1.4.6 ความเร็วในการขับรถยนต์เก็บข้อมูลไม่เกิน 60 กิโลเมตร/ชั่วโมง

1.4.7 สภาพแวดล้อมภายในรถยนต์ระหว่างการเก็บข้อมูล ไม่มีแรงสั่นสะเทือนที่เกิดจากการกระทำของผู้ขับขี่

### 1.5 ขอบเขตของการวิจัย

1.5.1 ถนนที่ใช้ในงานวิจัยนี้ คือ ถนนประเภทลาดยาง และลักษณะสภาพพื้นผิวถนนที่ผิดปกติที่ใช้ในงานวิจัยนี้มาจากงานวิจัยที่ผ่านมาที่สามารถตรวจจับได้โดยใช้โทรศัพท์มือถือ และการนิยามลักษณะความเสียหายพื้นผิวถนนของกรมทางหลวง ประกอบด้วย 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) ตามลักษณะพื้นผิวถนนทาง



ธรรมชาติที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงที่ เช่น เงา แสงสะท้อน และคราบสกปรกต่าง ๆ บนผิวถนน

1.5.2 การออกแบบขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติใช้ข้อมูลหลายรูปแบบจากเครื่องรับรู้รูปภาพและมาตรการความเร่งในโทรศัพท์มือถือ

1.5.3 พัฒนาแอปพลิเคชันต้นแบบสำหรับเก็บรวบรวมข้อมูลสภาพพื้นผิวถนนที่ผิดปกติบนระบบปฏิบัติการแอนดรอยด์

1.5.4 พื้นที่ศึกษาครอบคลุมสภาพพื้นผิวถนนจริงในเขตความรับผิดชอบของกรมทางหลวง กรมทางหลวงชนบทและองค์กรปกครองส่วนท้องถิ่นภายในจังหวัดนครราชสีมา

## 1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 ได้ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบ

1.6.2 ได้ตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติที่มีความแม่นยำมากขึ้น

1.6.3 ได้ขั้นตอนวิธีและตัวแบบที่หน่วยงานทางถนนหรือประชาชนที่เกี่ยวข้องสามารถนำไปใช้ในการตรวจจับและนำผลการตรวจจับไปรายงานสภาพพื้นผิวถนนที่ผิดปกติได้

## 1.7 คำอธิบายศัพท์

1.7.1 สภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomaly) หมายถึง สภาพความเสียหายของผิวถนน ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) และ 5) รอยปะซ่อม (Patch)

1.7.2 สภาพพื้นผิวถนนปกติ (Normal Road Surface) หมายถึง สภาพถนนปกติที่ไม่มี ความเสียหายของผิวถนน แต่มักมีการจำแนกลักษณะสภาพพื้นผิวถนนเป็นประเภทหลุมบ่อ ได้แก่ เนินชะลอความเร็ว เส้นชะลอความเร็ว (Speed Bumps) เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน

1.7.3 เครื่องรับรู้มาตรการความเร่ง (Accelerometer Sensor) หมายถึง เครื่องรับรู้ที่มีไว้สำหรับตรวจจับลักษณะการเคลื่อนไหวของโทรศัพท์มือถือ ซึ่งเป็นการตรวจจับแบบ 3 แกน ประกอบด้วยแกนเอ็กซ์ (X Axis) คือ แกนนอนหรือด้านกว้างของโทรศัพท์ แกนวาย (Y Axis) คือ แกนตั้งหรือด้านยาวของโทรศัพท์ และแกนแซด (Z Axis) คือ แกนที่พุ่งออกมาจากหน้าจอโทรศัพท์

1.7.4 การเรียนรู้ด้วยเครื่อง (Machine Learning) หมายถึง การทำให้เครื่องคอมพิวเตอร์เรียนรู้ได้จากข้อมูลตัวอย่างหรือจากสภาพแวดล้อม ที่มีจุดมุ่งหมายเพื่อการพัฒนาหรือปรับปรุง

ประสิทธิภาพการทำงานของระบบให้ดีขึ้น เมื่อเรียนรู้แล้วความรู้ที่เรียนได้จะเก็บไว้ในฐานความรู้ด้วยรูปแบบการแทนความรู้ได้อย่างใดอย่างหนึ่ง เช่น กฎ ฟังก์ชัน ฯลฯ

1.7.5 การเรียนรู้เชิงลึก (Deep Learning) หมายถึง เทคนิคหนึ่งของการเรียนรู้ด้วยเครื่องบนพื้นฐานของขั้นตอนวิธีที่พยายามสร้างแบบจำลองเพื่อแทนความหมายของข้อมูลในระดับสูงโดยใช้การประมวลผลข้อมูลหลายชั้นที่มีโครงสร้างที่ซับซ้อน ทำให้สามารถหาความเชื่อมโยงและเรียนรู้ข้อมูลจำนวนมากได้

1.7.6 การเรียนรู้หลายรูปแบบ (Multimodal Learning) หมายถึง แนวทางหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ที่สามารถเรียนรู้เพื่อแก้ไขปัญหาจากข้อมูลหลากหลายรูปแบบที่เกี่ยวข้องและเกิดขึ้นในเวลาเดียวกัน เพื่อถ่ายทอดความรู้ร่วมกัน (Knowledge Transfer)

1.7.7 เครื่องรับรู้หลายรูปแบบ (Multimodal Sensor) หมายถึง อุปกรณ์ในการรับรู้ค่าข้อมูลที่ต้องการตั้งแต่ 2 ชนิดขึ้นไป ในงานวิจัยนี้ใช้เครื่องรับรู้หลายรูปแบบ ได้แก่ เครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) และกล้องถ่ายภาพ (Camera) ในโทรศัพท์มือถือ

1.7.8 ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) หมายถึง ตัวแบบที่ถูกฝึกและทดสอบมาแล้วล่วงหน้าบนชุดข้อมูลรูปภาพของโคโค (COCO Dataset)

1.7.9 การถ่ายโอนการเรียนรู้ (Transfer Learning) หมายถึง การถ่ายโอนการเรียนรู้และปรับปรุงการเรียนรู้ในงานใหม่ที่มีความเกี่ยวข้องกันหรือมีลักษณะคล้ายกันจากตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าบนชุดข้อมูลรูปภาพของโคโค

## บทที่ 2

### ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในบทนี้เสนอการปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง ประกอบด้วย แนวคิดเกี่ยวกับสภาพพื้นผิวถนน แนวคิดเกี่ยวกับวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ แนวคิดเกี่ยวกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก งานวิจัยที่เกี่ยวข้องกับการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ มีรายละเอียดดังนี้

#### 2.1 แนวคิดเกี่ยวกับสภาพพื้นผิวถนน

ประเทศไทยมีโครงข่ายถนนความยาวประมาณ 716,331 กิโลเมตรและมีหน่วยงานหลักที่รับผิดชอบ ก่อสร้าง กำกับดูแล บำรุงรักษาถนน จำนวน 3 หน่วยงาน ได้แก่ กรมทางหลวง มีระยะทางประมาณ 70,010 กิโลเมตร แบ่งเป็นถนนคอนกรีตระยะทาง 5,511 กิโลเมตร ถนนลาดยางระยะทาง 64,455 กิโลเมตร และถนนลูกรังระยะทาง 43 กิโลเมตร กรมทางหลวงชนบทมีระยะทางประมาณ 47,983 กิโลเมตร แบ่งเป็นถนนคอนกรีตระยะทาง 2,293 กิโลเมตร ถนนลาดยางระยะทาง 44,110 กิโลเมตร และถนนลูกรังระยะทาง 1,579 กิโลเมตร และองค์กรปกครองส่วนท้องถิ่น มีระยะทางประมาณ 598,338 กิโลเมตร แบ่งเป็นถนนคอนกรีตระยะทาง 180,470 กิโลเมตร ถนนลาดยางระยะทาง 124,414 กิโลเมตร และถนนลูกรังระยะทาง 293,454 กิโลเมตร (กรมทางหลวง, 2561; สำนักบำรุงทาง กรมทางหลวงชนบท, 2561, หน้า ๓; สำนักงานนโยบายและแผนการขนส่งและจราจร, 2558, หน้า 6; กองพัฒนาและส่งเสริมการบริหารงานท้องถิ่น, 2562) ลักษณะพื้นผิวถนนในประเทศไทยส่วนใหญ่เป็นถนนลูกรังคิดเป็นร้อยละ 41.19 รองลงมาเป็นถนนลาดยางคิดเป็นร้อยละ 32.52 และถนนคอนกรีตคิดเป็นร้อยละ 26.28 ดังตารางที่ 2.1

ตารางที่ 2.1 ประเภทถนนและหน่วยงานผู้รับผิดชอบหลักในประเทศไทย

หน่วยงานที่รับผิดชอบ	ถนนคอนกรีต	ถนนลาดยาง	ถนนลูกรัง	รวม	ร้อยละ
กรมทางหลวง	5,511.49	64,455.49	43.39	70,010.37	9.77
กรมทางหลวงชนบท	2,293.86	44,110.36	1,579.19	47,983.41	6.69
องค์กรปกครองส่วนท้องถิ่น	180,470.00	124,414.00	293,454.00	598,338.00	83.52
รวม	188,275.35	232,979.85	295,076.58	716,331.78	-
ร้อยละ	26.28	32.52	41.19	-	100.00

สำหรับงานวิจัยนี้ใช้โครงข่ายถนนสายหลักที่รับผิดชอบโดยกรมทางหลวง กรมทางหลวงชนบทและองค์กรปกครองส่วนท้องถิ่น และใช้ถนนประเภทลาดยางที่มีอยู่จำนวนมากเป็นอันดับ 2 ในประเทศไทย

สภาพพื้นผิวถนนทุกประเภท เมื่อก่อสร้างแล้วเสร็จและเปิดการจราจรไปชั่วระยะเวลาหนึ่ง มักเกิดความชำรุดเสียหาย สาเหตุความชำรุดเสียหายของพื้นผิวถนนเกิดจากสาเหตุหลายประการ เช่น อายุการใช้งานพื้นผิวถนน ปริมาณจราจรเฉลี่ยต่อวันตลอดปี (Annual Average Daily Traffic: AADT) ปริมาณรถบรรทุกหนัก (Heavy Truck Volume) นอกจากนี้ความชำรุดเสียหายของพื้นผิวถนนยังเกิดจากลักษณะภูมิอากาศ เช่น ปริมาณน้ำฝนเฉลี่ยต่อปี การเปลี่ยนแปลงอุณหภูมิระหว่างวัน การเคลื่อนไหวของดินชั้นต่าง ๆ ที่อยู่ใต้พื้นผิวถนน ตลอดจนลักษณะโครงสร้างชั้นพื้นผิวถนนเดิม สิ่งเหล่านี้ล้วนเป็นปัจจัยที่ส่งผลกระทบต่อลักษณะความเสียหายที่แตกต่างกันออกไป (กรมทางหลวงชนบท, 2555, หน้า 4) ในงานวิจัยนี้จำแนกสภาพพื้นผิวถนนออกเป็น 2 ประเภท คือ ลักษณะสภาพพื้นผิวถนนที่ผิปกติและลักษณะสภาพพื้นผิวถนนที่ปกติ ดังนี้

### 2.1.1 ลักษณะสภาพพื้นผิวถนนที่ผิปกติ

ลักษณะสภาพพื้นผิวถนนที่ผิปกติในงานวิจัยนี้มาจากการปรัทัศนัวรรณกรรมและงานวิจัยที่ผ่านมาที่สามารถตรวจจับ ได้โดยใช้โทรศัพท์มือถือ (Coenen and Golroo, 2017, p. 18) และการนิยามลักษณะความเสียหายพื้นผิวถนนของกรมทางหลวง (กรมทางหลวง, 2550, หน้า 4-5) มีรายละเอียด ดังนี้


1) หลุม บ่อ (Potholes) เป็น ลักษณะ ความเสียหายที่เรียกว่า การหลุดร่อน (Disintegration) แต่มีลักษณะเกิดเป็นหลุมบ่อคล้ายถ้วย ดังรูปที่ 2.1-1 สาเหตุที่ทำให้พื้นผิวถนนเป็นหลุมบ่อเกิดจากโครงสร้างพื้นผิวถนนและโครงสร้างพื้นถนนไม่แข็งแรงเพียงพอ วัสดุที่นำมาก่อสร้างไม่ได้มาตรฐานที่กำหนดหรืออาจเกิดจากการระบายน้ำในชั้นพื้นผิวถนนไม่ดีพอหรืออาจเกิดจากการที่มีปริมาณรถบรรทุกหนักสัญจรผ่านมากเกินไปเกินกว่ามาตรฐานที่กำหนด

2) รอยแตกตามแนวยาว (Longitudinal Cracks) เป็นลักษณะความเสียหายที่เรียกว่า การแตกร้าว (Cracks) ซึ่งมีสภาพการแตกเป็นร่องตามแนวยาว ตรวจพบในกรณีที่มีการปูผิวแอสฟัลต์บนผิวทางลาดยางเดิม ดังรูปที่ 2.1-2 สาเหตุที่ทำให้พื้นผิวถนนมีลักษณะความเสียหายประเภทรอยแตกตามแนวยาวเกิดจากการขยายหรือหดตัวของชั้นโครงสร้างทางเดิม

3) รอยแตกตามแนวขวาง (Transverse Cracks) เป็นลักษณะความเสียหายที่เรียกว่า การแตกร้าว (Cracks) ซึ่งมีสภาพการแตกเป็นร่องตามแนวขวาง ตรวจพบในกรณีที่มีการปูผิวแอสฟัลต์บนผิวทางลาดยางเดิม ดังรูปที่ 2.1-3 สาเหตุที่ทำให้พื้นผิวถนนมีลักษณะความเสียหายประเภทรอยแตกตามแนวขวางเกิดจากการขยายหรือหดตัวของชั้นโครงสร้างทางเดิม

4) รอยแตกหนังจระเข้ (Alligator Cracks) เป็นลักษณะความเสียหายที่เรียกว่า การแตกร้าว (Cracks) ซึ่งมีสภาพเป็นตารางคล้ายหนังจระเข้หรือลวดตาข่าย ดังรูปที่ 2.1-4 สาเหตุที่ทำให้ผิวถนนมีลักษณะรอยแตกหนังจระเข้เกิดจากมีความชื้นในชั้นโครงสร้างถนนสูงทำให้ความสามารถรับน้ำหนักลดลง เมื่อมีน้ำหนักบรรทุกผ่านจึงเกิดการแตกร้าว

5) รอยปะซ่อมที่เสียหายหรือไม่ได้มาตรฐาน (Bad Patching) เป็นลักษณะความเสียหายที่เรียกว่า การบิดตัวเปลี่ยนลักษณะจากรูปเดิม (Distortion) ดังรูปที่ 2.1-5 สาเหตุที่ทำให้ผิวถนนมีลักษณะความเสียหายประเภทรอยปะซ่อมที่เสียหาย หรือไม่ได้มาตรฐานเกิดจากการซ่อมแซมผิวถนนตามแนววางท่อหรือระบบสาธารณูปโภคแล้วบดอัดวัสดุผสมหลุมที่ขุดไม่ได้คุณภาพ การที่ซ่อมบำรุงรักษาโดยวิธีการปะซ่อมผิวถนนและการอุดซ่อมผิวถนนเกิดการเสียรูปหรือเกิดจากการซ่อมที่ไม่ได้มาตรฐานตามที่กำหนด




รูปที่ 2.1 ลักษณะสภาพพื้นผิวถนนที่ผิดปกติ



### 2.1.2 ลักษณะสภาพพื้นผิวถนนที่ปกติ

งานวิจัยที่ผ่านมา พบว่า ลักษณะสภาพพื้นผิวถนนที่ไม่ได้เป็นความผิดปกติของถนน เช่น เนินชะลอความเร็ว เส้นชะลอความเร็ว รอยต่อถนน ที่มักมีการจำแนกลักษณะสภาพพื้นผิวถนนเป็นประเภทหลุมบ่อ ยิ่งไปกว่านั้นลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงอาจส่งผลกระทบต่อความถูกต้องในการตรวจจับสภาพพื้นผิวถนน เช่น เสา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน (Eriksson et al., 2008, pp. 34-37; Koch and Brilakis, 2011, p. 512; Kim and Ryu, 2014, p. 604; Jo and Ryu, 2015, p. 29329; Nienaber, et al., 2015, p.9; Ryu, et al., 2015, p. 9) ดังแสดงในรูปที่ 2.2



รูปที่ 2.2 ลักษณะสภาพพื้นผิวถนนที่ปกติ



สำหรับงานวิจัยนี้ ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ประกอบด้วย หลุมบ่อ รอยแตก ตามแนวยาว รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ รอยปะซ่อม และลักษณะสภาพพื้นผิวถนน ที่ไม่ได้เป็นความผิดปกติของถนน ได้แก่ ลูกกระนาคหรือยางชะลอความเร็ว และลักษณะพื้นผิวถนน ที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงที่อาจส่งผลกระทบต่อความถูกต้อง ในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน

## 2.2 แนวคิดเกี่ยวกับวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

วิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ พบว่า มีเทคนิควิธีการแบบอัตโนมัติที่หลากหลายและแตกต่างกันตามลักษณะทางกายภาพของถนนในแต่ละประเทศ ที่ผ่านมาการจำแนกวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติออกเป็น 3 วิธี ได้แก่ 1) วิธีการวัดแรงสั่นสะเทือน (Vibration-based Methods) 2) วิธีการวิธีการสร้างภาพสามมิติ (3D Reconstruction-based Methods) และ 3) วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) (Koch and Brilakis, 2011, p. 5; Jog, Koch, Golparvar-Fard, and Brilakis, 2012, p. 555; Kim and Ryu, 2014, p. 603; Sharma, Singh, and Chand, 2016, p. 56; Enigo, Kumar, Vijay, and Prabu, 2016, p. 317; Thekkethala, Reshma, Varughese, Mohan, and Titus, 2016, p. 59)

นอกจากนี้ ยังมีวิธีการใช้เครื่องรับรู้อัลตราโซนิก (Ultrasonic-based Methods) (Madli et al., 2015, p. 4313; Tushar and Archana, 2017, p. 10324) วิธีการวัดเสียง (Audio-based Methods) (Zhang, Mcdaniel, and Wang, 2013, p. 1; Coenen and Golroo, 2017, p. 11) และ การใช้เครื่องรับรู้อุปกรณ์หลายรูปแบบ (Multimodal Sensor) (Orhan and Eren, 2013a; Orhan and Eren, 2013b; Orhan, 2013; Rajamohan, Gannu, and Rajan, 2015) เพื่อตรวจจับสภาพพื้นผิวถนนอีกด้วย ดังนั้นงานวิจัยนี้จึงจำแนกแนวคิดเกี่ยวกับวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติออกเป็น 6 วิธี ดังนี้


### 2.2.1 วิธีการวัดแรงสั่นสะเทือน (Vibration-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนนจากเครื่องรับรู้อัตราความเร่ง (Accelerometer Sensor) ที่อยู่ในโทรศัพท์มือถือ ซึ่งเป็นเครื่องมือที่ใช้วัดค่าอัตราเร่งของแรงสั่นสะเทือน การเคลื่อนที่ของวัตถุ ประกอบด้วยระบบแกน 3 แกน ได้แก่ แกนเอ็กซ์ (X Axis) คือ แกนนอนหรือ ด้านกว้างของโทรศัพท์ แกนวาย (Y Axis) คือ แกนตั้งหรือด้านยาวของโทรศัพท์ และแกนแซด (Z Axis) คือ แกนที่พุ่งออกมาจากหน้าจอโทรศัพท์ เมื่อนำเครื่องรับรู้อัตราความเร่งที่อยู่ใน โทรศัพท์มือถือไปติดตั้งไว้ในรถ เครื่องรับรู้อัตราความเร่งสามารถตรวจจับค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกนทั้ง 3 แกน ตามเงื่อนไขสภาพพื้นผิวถนนที่รถขับผ่านได้

(González, O'brien, Li, and Cashell, 2008; Eriksson et al., 2008; Tai, Chan, and Hsu, 2010; Perttunen et al., 2011; Mednis et al., 2011; Douangphachanh and Oneyama, 2013; Kulkarni, Mhalgi, Gurnani, and Giri, 2014; Wang, Chen, Cheng, Lin, and Lo, 2015; Predic and Stojanovic, 2015; Enigo et al., 2016)

งานวิจัยที่ใช้วิธีวัดแรงสั่นสะเทือน เช่น González และคณะ (2008) นำเครื่องรับรู้มาตรฐานความเร่งไปติดตั้งไว้ในรถจำลองเพื่อประเมินสภาพถนนที่ขรุขระ ผลการทดลองพบว่า ความขรุขระของถนนสามารถวัดได้จากข้อมูลความเร่ง (Acceleration Data) ที่ได้รับจากเครื่องรับรู้มาตรฐานความเร่ง คล้ายกับงานวิจัยของ Tai, Chan และ Hsu (2010) และ Perttunen และคณะ (2011) เสนอการวิเคราะห์ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่งในสมาร์ทโฟน โดยการวิเคราะห์โดเมนความถี่จากการตั้งคุณสมบัติที่สอดคล้องกับรถขณะกระแทกบนถนนหรือสภาพถนนที่ขรุขระ ส่วนงานวิจัยของ Douangphachanh และ Oneyama (2013) ได้ทำการสำรวจคุณสมบัติและความสัมพันธ์ของแรงสั่นสะเทือนจากค่าอัตราเร่งของแรงสั่นสะเทือน (Acceleration Vibration) ของเครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์สมาร์ทโฟน ดังรูปที่ 2.3 เพื่อประเมินสภาพถนนขรุขระ ณ ความเร็วในการขับขี่ที่แตกต่างกัน ผลจากการทดลองและวิเคราะห์ข้อมูล พบว่า การรวบรวมข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน โดยใช้เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์สมาร์ทโฟน ณ ความเร็วในการขับขี่ที่แตกต่างกันมีความสัมพันธ์เชิงเส้นที่แตกต่างกันอย่างมีนัยสำคัญกับสภาพถนนที่ขรุขระ

สำหรับงานวิจัยของ Mohan และคณะ (2008) ใช้เครื่องรับรู้ในโทรศัพท์สมาร์ทโฟน ได้แก่ เครื่องรับรู้มาตรฐานความเร่ง ไมโครโฟน สัญญาณจีเอสเอ็มและจีพีเอส เพื่อตรวจจับสภาพถนนและสภาพจราจร ได้แก่ หลุมบ่อ (Potholes) การกระแทก (Bumps) การเบรก (Braking) และเสียงแตรรถยนต์ (Honking) ส่วนงานวิจัยของ Mednis และคณะ (2011) ใช้เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์สมาร์ทโฟน เพื่อตรวจจับหลุมบ่อและตำแหน่งบนถนน ดังรูปที่ 2.3 ซึ่งคล้ายกับงานวิจัยของ Kulkarni และคณะ (2014) ได้พัฒนาระบบตรวจจับหลุมบ่อ โดยใช้การเรียนรู้ของเครื่องบนระบบปฏิบัติการแอนดรอยด์ พร้อมทั้งระบุตำแหน่งที่ตั้งของหลุมบ่อด้วยระบบนำทางดาวเทียมทั่วโลกจากนั้นแสดงพิกัดตำแหน่งบนแผนที่ออนไลน์ของกูเกิ้ล (Google Map)



รูปที่ 2.3 การตรวจจับสภาพพื้นผิวถนนโดยใช้เครื่องรับรู้มาตรฐานความเร่ง

ที่มา: Mednis และคณะ (2011) Douangphachanh และ Oneyama (2013)

นอกจากนี้ยังพบงานวิจัยที่พัฒนาขั้นตอนวิธีเพื่อปรับปรุงวิธีวัดแรงสั่นสะเทือนให้มีความถูกต้องมากยิ่งขึ้นและประมวลผลได้แบบเวลาจริง เช่น งานวิจัยของ Wang และคณะ (2015) เสนอวิธีการตรวจจับหลุมบ่อแบบเวลาจริงสำหรับระบบขนส่งอัจฉริยะโดยใช้เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์มือถือ นอกจากนี้ยังมีการคำนวณมุมการวางโทรศัพท์มือถือเพื่อปรับปรุงขั้นตอนวิธีสำหรับการตรวจจับหลุมบ่อของ Mednis และคณะ (2011) อีกทั้งยังมีวิธีการแก้ไขข้อมูลเชิงพื้นที่เพื่อลดความผิดพลาดในการระบุตำแหน่งหลุมบ่อ ยิ่งไปกว่านั้นงานวิจัยของ Predic และ Stojanovic (2015) ได้เสนอการเพิ่มประสิทธิภาพการรับรู้ถึงสถานการณ์ของผู้ขับขี่ผ่านข้อมูลจราจรและข้อมูลการระบุสภาพพื้นผิวถนนที่ผิดปกติของกลุ่มผู้ใช้รถด้วยระบบตรวจจับแบบอัตโนมัติและรายงานสภาพการจราจรแก่ผู้ขับขี่

จากการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีวัดแรงสั่นสะเทือนที่กล่าวมาแล้วข้างต้น สรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ ข้อดีของวิธีวัดแรงสั่นสะเทือน คือ เป็นระบบที่มีต้นทุนต่ำ ใช้ขั้นตอนวิธีอย่างง่ายในการพัฒนา ใช้พื้นที่ในการจัดเก็บข้อมูลน้อยและข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลได้แบบเวลาจริง อย่างไรก็ตาม การใช้วิธีวัดแรงสั่นสะเทือนเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติอาจให้ผลลัพธ์ที่ผิดพลาดและเป็นข้อจำกัดของงานวิจัย เช่น รอยต่อถนน ฝาที่ระบายน้ำที่ต่างระดับกับผิวถนน ลูกกระพรวนหรือยางชะลอความเร็ว ที่ถูกตรวจพบว่าเป็นหลุมบ่อ ยิ่งไปกว่านั้นหลุมบ่อที่อยู่กลางช่องจราจรไม่สามารถตรวจพบได้โดยการใช้เครื่องรับรู้มาตรฐานความเร่ง เนื่องจากไม่มีการตกกระทบของล้อรถ (Eriksson et al., 2008, pp. 34-37; Kim and Ryu, 2014, p. 604; Chugh, Bansal, and Sofat, 2014, p. 600; Jo and Ryu, 2015, p. 29317)

## 2.2.2 วิธีการสร้างภาพสามมิติ (3D Reconstruction-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนนโดยวิธีการใช้กล้องเลเซอร์สแกนแบบสามมิติ (3D Laser Scanner Methods) พบได้ในงานวิจัยของ Chang และคณะ (2005) Li และคณะ (2009) Sun และคณะ (2012) และ Yu และคณะ (2014) ระบบการมองเห็นแบบสเตอริโอ (Stereo Vision) (Hou, Wang, and Gong, 2007; Salari, Chou, and Lynch, 2012) และเครื่องรับรู้ไคเนค (Kinect Sensor) (Joubert, Tyatyantsi, Mphahlele, and Manchidi, 2011; Moazzam, Kamal, Mathavan, Usman, and Rahman, 2013) จากนั้นนำข้อมูลสภาพพื้นผิวถนนมาสร้างแบบจำลองสามมิติแล้ววิเคราะห์ข้อมูลสภาพพื้นผิวถนน

งานวิจัยที่ใช้วิธีการใช้กล้องเลเซอร์สแกนแบบสามมิติ เช่น Chang และคณะ (2005) ได้เสนอวิธีการตรวจจับสภาพพื้นผิวถนนโดยใช้เทคโนโลยีเลเซอร์สแกนแบบสามมิติ เพื่อสร้างแบบจำลองสามมิติของหลุมบ่อ ผลการทดลองแสดงให้เห็นว่า เทคโนโลยีเลเซอร์สแกน

แบบสามมิติสามารถตรวจพบหลุมบ่อได้อย่างถูกต้องและครอบคลุมพื้นที่ที่ทำการตรวจสอบได้เป็นอย่างดี นอกจากนี้งานวิจัยของ Li และคณะ (2009) ได้เสนอระบบการตรวจจับร่องล้อ รอยย่นและหลุมบ่อ โดยใช้เทคนิคการสแกนตามขวางแบบสามมิติ (3D Transverse Scanning Techniques) ประกอบด้วยเครื่องปล่อยแสงอินฟราเรดและกล้องดิจิทัลสำหรับการตรวจจับภาพจากแสงสะท้อนอินฟราเรดทำให้ได้ภาพที่เป็นมิติ เพื่อปรับปรุงความถูกต้องของระบบ ยิ่งไปกว่านั้น งานวิจัยของ Sun และคณะ (2012) ได้เสนอการตรวจจับลักษณะรอยแตกของถนน โดยใช้เลเซอร์สแกนแบบสามมิติและใช้รถสำรวจที่ทำการติดตั้งอุปกรณ์เลเซอร์สแกนแบบสามมิติไว้ด้านท้ายรถ ผลลัพธ์จากระบบสามารถแสดงรูปแบบความเสียหายทั้งในแบบรอยร้าว (Rutting) และรอยแตก (Crack) ภายใต้สภาพแวดล้อมที่มีเงามากได้ นอกจากนี้งานวิจัยของ Yu และคณะ (2014) ได้เสนอขั้นตอนวิธีในการสกัดรอยแตกจากกล้องเลเซอร์สแกนแบบสามมิติที่ถูกติดตั้งไว้บนรถโมบาย LiDAR ดังรูปที่ 2.4 โดยใช้วิธีการประมวลผลภาพในการสกัดคุณลักษณะสำคัญเพื่อตรวจจับสภาพพื้นผิวถนนประเภทรอยแตก อย่างไรก็ตาม ข้อเสียของระบบนี้คือมีค่าใช้จ่ายในการติดตั้งและเวลาในการประมวลผลค่อนข้างสูงมาก



รูปที่ 2.4 การตรวจจับสภาพพื้นผิวถนนที่ใช้กล้องเลเซอร์สแกนแบบสามมิติ  
ที่มา: Yu และคณะ (2014)

จากการตรวจจับสภาพพื้นผิวถนนที่ผลิตปกติด้วยวิธีการนำภาพถ่ายมาสร้างให้อยู่ในรูปแบบสามมิติ ที่กล่าวมาแล้วข้างต้น สรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ ข้อดีของวิธีการนำภาพถ่ายมาสร้างให้อยู่ในรูปแบบสามมิติ คือได้รับข้อมูลสภาพพื้นผิวผลิตปกติที่ละเอียดและมีความถูกต้อง อย่างไรก็ตาม ข้อจำกัดของงานวิจัย คือ เครื่องสแกนวัตถุสามมิติด้วยแสงเลเซอร์มีราคาแพงและเป็นวิธีที่ต้องใช้การคำนวณและประมวลผลสูงไม่เหมาะกับการนำมาใช้ใน

สภาพแวดล้อมแบบเวลาจริง (Kim and Ryu, 2014, pp. 604-605; Enigo et al., 2016, p. 317; Jo and Ryu, 2015, p. 29317)

### 2.2.3 วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนน โดยใช้กล้องดิจิทัลเพื่อจัดเก็บและบันทึกข้อมูลให้อยู่ในรูปแบบภาพสองมิติ (2D Image) พบได้ในงานวิจัยของ Lin และ Liu (2010) Koch และ Brilakis (2011) Zhang และคณะ (2016) และ Maeda และคณะ (2016a, 2016b) หรือรูปภาพวิดีโอ (Video Image) พบได้ในงานวิจัยของ Buza และคณะ (2013) Huidrom และคณะ (2013) Kawano และคณะ (2017) Eisenbach และคณะ (2017) Maeda และคณะ (2018) Singh และ Shekhar (2018) และ Koh และคณะ (2019) จากนั้นใช้วิธีการประมวลผลภาพ (Image Processing) เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Networks) และตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Models) เพื่อตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

งานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็นจากรูปภาพสองมิติสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการประมวลผลภาพ เช่น งานวิจัยของ Koch และ Brilakis (2011) ได้เสนอวิธีการตรวจจับหลุมบ่อจากรูปภาพถนนแบบอัตโนมัติ ประกอบด้วยขั้นตอนการแยกองค์ประกอบของภาพ (Image Segmentation) การสกัดรูปทรงและลวดลายของภาพ (Shape and Texture Extraction) และเปรียบเทียบลวดลายของภาพระหว่างสภาพพื้นผิวถนนที่เป็นหลุมบ่อและสภาพพื้นผิวถนนที่ปกติ หากลวดลายของสภาพพื้นผิวถนนมีลวดลายที่หายหรือเป็นเม็ดเล็ก ๆ มากกว่าส่วนหนึ่งในลวดลายของสภาพพื้นผิวถนนที่ปกติ ให้สันนิษฐานว่า พื้นผิวถนนนั้นเป็นหลุมบ่อ วิธีการที่นำเสนอนี้สามารถตรวจจับหลุมบ่อจากรูปภาพถนนได้ค่าความถูกต้องสูง

ส่วนงานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็นจากรูปภาพสองมิติสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการประมวลผลภาพและเทคนิคการเรียนรู้ของเครื่อง เช่น งานวิจัยของ Lin และ Liu (2010) ใช้เทคนิคฮิสโตแกรม (Histogram) เพื่อสกัดคุณลักษณะลวดลาย (Texture) ของภาพพื้นผิวถนนและใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ในการระบุหลุมบ่อ

นอกจากนี้ งานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็นจากรูปภาพสองมิติสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Classification) ด้วยวิธีการเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ออกแบบโครงสร้างเอง เช่น งานวิจัยของ Zhang และคณะ (2016) Maeda และคณะ (2016a, 2016b) ได้ทำการออกแบบโครงสร้างที่ประกอบด้วยชั้นโครงสร้างคอนโวลูชัน (Convolution Layers) รวมทั้งแมกพูลริง (Max-pooling) และการเชื่อมต่อแบบทั่วถึง (Fully Connected Layers) เพื่อใช้ในการจำแนกสภาพพื้นผิวถนน เช่น



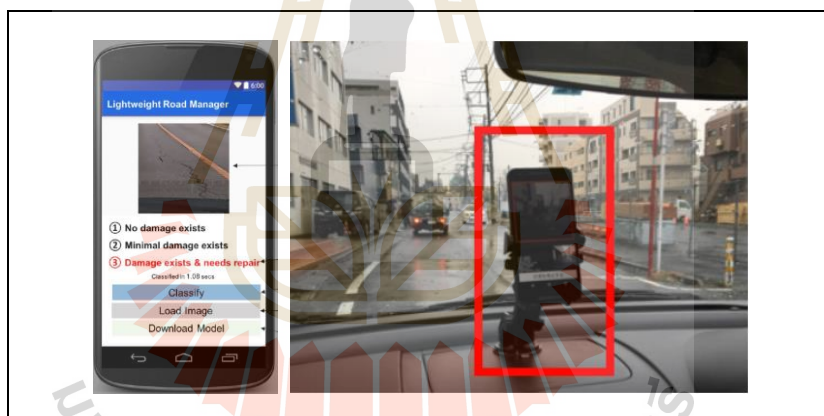
รอยแตก (Zhang et al., 2016) และสภาพความเสียหายของผิวถนน ที่ประกอบด้วย ไม่มี ความเสียหาย ความเสียหายน้อยที่ไม่จำเป็นต้องซ่อม ความเสียหายที่จำเป็นต้องซ่อม (Maeda et al., 2016a, 2016b)

วิธีการพื้นฐานจากการมองเห็นจากภาพวิดีโอสำหรับตรวจสอบสภาพพื้นผิวถนนที่ ผิดปกติโดยใช้วิธีการประมวลผลภาพ เช่น งานวิจัยของ Buza และคณะ (2013) ใช้วิธี การประมวลผลภาพและการจัดกลุ่มสเปกตรัม (Spectral Clustering) โดยขั้นตอนการจัดกลุ่ม สเปกตรัมถูกนำมาใช้เพื่อระบุขอบเขตข้อมูลฮิสโตแกรมของภาพ (Histogram-based Data) จากภาพระดับสีเทา (Gray-scale Image) เพื่อระบุคุณลักษณะของหลุมบ่อ ในงานวิจัยนี้ได้ทดสอบ หลุมบ่อขนาดต่าง ๆ ขั้นตอนวิธีที่นำเสนอสามารถตรวจจับหลุมบ่อได้ความถูกต้องสูง นอกจากนี้ งานวิจัยของ Huidrom และคณะ (2013) เสนอวิธีการอัตโนมัติในการตรวจสอบสภาพพื้นผิวถนน ประเภทหลุมบ่อ รอยแตกและรอยปะจากข้อมูลวิดีโอ โดยใช้เทคนิคการประมวลผลภาพ ซึ่งประกอบด้วย 2 ขั้นตอนคือ 1) การดึงภาพจากวิดีโอด้วยขั้นตอนวิธีการแยกภาพแบบรวดเร็ว และ 2) การประมวลผลข้อมูลภาพวิดีโอ โดยพัฒนาขั้นตอนวิธี 5 วิธี ได้แก่ การเพิ่มคุณภาพของภาพ (Image Enhancement) การแยกองค์ประกอบของภาพ (Image Segmentation) การสกัดคุณสมบัติ ของภาพ (Visual Properties Extraction) การตรวจจับและจำแนกภาพโดยใช้ตรรกะการตัดสินใจ (Detection and Classification by Decision Logic) และกระบวนการจัดเก็บภาพวิดีโอและข้อมูล คุณลักษณะที่ถูกจำแนกได้ (Stored and Quantified Information) ผลจากการทดลองพบว่า ขั้นตอน วิธีที่นำเสนอสามารถตรวจจับสภาพพื้นผิวถนนประเภท หลุมบ่อ รอยแตกและรอยปะได้ แต่อย่างไรก็ตาม ขั้นตอนวิธีที่เสนอยังมีความผิดพลาดในการตรวจจับรอยคราบน้ำมันบนผิวถนน ฝาท่อระบายน้ำ เครื่องหมายจราจรสีดำบนผิวถนน จุดสีต่าง ๆ บนผิวถนนที่มีลักษณะคล้ายกับ หลุมบ่อ รอยแตก รอยปะ

นอกจากนี้ งานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็นจากภาพวิดีโอสำหรับจำแนก สภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Classification) ด้วยวิธีการเรียนรู้เชิงลึก โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก เช่น งานวิจัยของ Kawano และคณะ (2017) และ Eisenbach และคณะ (2017) ได้ทำการออกแบบโครงสร้างที่ประกอบด้วยชั้น โครงสร้าง คอนโวลูชัน (Convolution Layers) รวมทั้งแมกพูลิ่ง (Max-pooling) และการเชื่อมต่อแบบทั่วถึง (Fully Connected Layers) เพื่อใช้ในการจำแนกสภาพพื้นผิวถนน เช่น รอยแตก หลุมบ่อ รอยปะซ่อม รอยต่อถนน (Eisenbach et al., 2017) และความเสียหายของเส้นจราจรที่ประกอบด้วย เส้นจราจรที่เสียหาย เส้นจราจรที่ไม่เสียหาย และไม่มีเส้นจราจร (Kawano, Yonezawa, and Nakazawa, 2017)



ยิ่งไปกว่านั้น งานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็นจากภาพวิดีโอสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้เชิงลึกโดยใช้ตัวแบบที่ฝึกมาแล้วล่วงหน้า (Pretrained Model) เช่น งานวิจัยของ Maeda และคณะ (2018) ใช้โทรศัพท์สมาร์ทโฟนในการเก็บรวบรวมข้อมูลสภาพพื้นผิวถนน ดังรูปที่ 2.5 จากนั้นสร้างชุดข้อมูลสำหรับตรวจจับความเสียหายบนถนนในญี่ปุ่นจำนวน 8 ประเภท ได้แก่ รอยแตกตามแนวยาวบริเวณล้อรถ รอยแตกตามแนวยาวบริเวณการก่อสร้าง รอยแตกตามแนวขวาง รอยแตกตามแนวขวางบริเวณการก่อสร้าง รอยแตกหนังจระเข้ หลุมบ่อ เส้นช่องจราจรชำรุดและเส้นข้ามทางม้าลายชำรุด โดยใช้ตัวแบบ SSD Inception\_V2 และ SSD MobileNet ส่วนงานวิจัยของ Singh และ Shekhar (2018) ใช้ชุดข้อมูลของ Maeda และคณะ (2018) เพื่อตรวจจับความเสียหายบนถนนด้วยตัวแบบ Mask Region-based Convolutional Network (Mask R-CNN) นอกจากนี้งานวิจัยของ Koh และคณะ (2019) ตรวจจับสภาพพื้นผิวถนนจากชุดข้อมูลหลุมบ่อในแอฟริกาใต้โดยใช้ตัวแบบ Region-based Fully Convolutional Networks (R-FCN)



รูปที่ 2.5 การตรวจจับสภาพพื้นผิวถนนโดยใช้กล้องจากโทรศัพท์สมาร์ทโฟน  
ที่มา: Maeda และคณะ (2016b) และ Maeda และคณะ (2018)

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการพื้นฐานจากการมองเห็น ที่กล่าวมาแล้วข้างต้น สรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ มุมมองของกล้องถ่ายภาพหรือกล้องวิดีโอสามารถตรวจจับสภาพพื้นผิวถนนกลางช่องจราจรและคำนวณจำนวนของหลุมบ่อจากลำดับของกรอบภาพได้ (Sequence of Frame) อย่างไรก็ตามวิธีการประมวลผลภาพยังมีความผิดพลาดหรือข้อจำกัดของงานวิจัย เมื่อภาพพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและมีความแปรปรวนสูง เช่น เงา แสงสะท้อน คราบสกปรกต่าง ๆ บนผิวถนน เครื่องหมายจราจรสีดำนบนผิวถนนและจุดสีต่าง ๆ บนผิวถนนที่มีลักษณะคล้ายกับหลุมบ่อ รอยแตก และรอยปะ (Koch and

Brilakis, 2011, p. 512; Huidrom, Das, and Sud, 2013, p. 320; Kim and Ryu, 2014, p. 604; Jo and Ryu, 2015, p. 29329; Nienaber et al., 2015, p. 9; Radopoulou and Brilakis, 2015, p. 102)

ที่ผ่านมามีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการพื้นฐานจากการมองเห็นจากรูปภาพหรือรูปภาพวิดีโอใช้วิธีการสกัดคุณลักษณะด้วยมือ (Hand-crafted Feature Extraction) โดยใช้ขั้นตอนวิธีการประมวลผลภาพ (Lin and Liu, 2010; Koch and Brilakis, 2011; Buza, Omanovic, and Huseinnovic, 2013; Huidrom et al., 2013) ความถูกต้องของการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติขึ้นอยู่กับคุณภาพของการสกัดคุณลักษณะพิเศษของข้อมูล (Features Extraction)

ปัจจุบันการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกเป็นขั้นตอนวิธีที่สามารถเรียนรู้ คำนวณหาคุณลักษณะพิเศษของรูปภาพและจำแนกประเภทได้แบบอัตโนมัติโดยไม่จำเป็นต้องใช้วิธีการสกัดคุณลักษณะพิเศษด้วยมือซึ่งถูกนำมาใช้ในงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Kawano, Yonezawa, and Nakazawa, 2017; Eisenbach et al., 2017)

แม้ว่าการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสามารถเรียนรู้และคำนวณหาคุณลักษณะพิเศษของรูปภาพที่มีประสิทธิภาพมากขึ้น แต่ในทางกลับกัน ส่งผลให้กระบวนการเรียนรู้ใช้เวลานานและต้องการชุดข้อมูลเป็นจำนวนมาก ด้วยเหตุนี้ การถ่ายโอนการเรียนรู้ (Transfer Learning) จึงถูกนำมาประยุกต์ใช้ผ่านตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Models) สำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Maeda et al., 2018; Singh and Shekhar, 2018; Koh et al., 2019) การใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเป็นการถ่ายโอนการเรียนรู้และปรับปรุงการเรียนรู้ในงานใหม่ ส่งผลให้ประหยัดเวลาในการเรียนรู้และไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมาก ยิ่งไปกว่านั้นตัวแบบที่ถูกฝึกมาแล้วล่วงหน้านั้นยังมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น (Torrey and Shavlik, 2010)

#### 2.2.4 วิธีการใช้อัลตราโซนิก (Ultrasonic-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนน โดยวัดคลื่นเสียงความถี่สูงหรือเครื่องรับรู้อัลตราโซนิก (Ultrasonic Sensor) เพื่อวัดความลึกหรือความสูงระหว่างพื้นรถและพื้นผิวถนน พบได้ในงานวิจัยของ Madli และคณะ (2015) พัฒนาระบบตรวจจับหลุมบ่อ (Potholes) และเนินชะลอความเร็ว (Humps) แบบอัตโนมัติเพื่อแจ้งเตือนผู้ขับขี่และหลีกเลี่ยงอุบัติเหตุหรือความเสียหายของยานพาหนะ เครื่องรับรู้อัลตราโซนิกถูกติดตั้งไว้ใต้ท้องรถ ดังรูปที่ 2.6 เพื่อวัดความลึกของหลุมบ่อและความสูงของเนินชะลอความเร็วโดยเปรียบเทียบกับค่าเทรสโฮลด์ (Threshold Value) ที่กำหนดไว้เป็นระดับความสูงปกติจากพื้นรถจนถึงผิวถนน หากค่าที่วัดได้มีค่ามากกว่าค่าเทรสโฮลด์ที่กำหนดแสดงว่าเป็นหลุมบ่อ แต่ถ้าค่าที่วัดได้มีค่าน้อยกว่าค่าเทรสโฮลด์

ที่กำหนดแสดงว่าพื้นผิวถนนเป็นเนินชะลอความเร็ว จากนั้นระบุตำแหน่งของหลุมบ่อและเนินชะลอความเร็วด้วยระบบนำทางดาวเทียมทั่วโลก นอกจากนี้ยังได้พัฒนาแอปพลิเคชันระบบปฏิบัติการแอนดรอยด์เพื่อแจ้งเตือนผู้ขับขี่ผ่านทางข้อความและเสียงเตือน ซึ่งคล้ายกับงานวิจัยของ Tushar และ Archana (2017) และ Rayen (2016) ที่นำเครื่องรับรู้อัลตราโซนิกไปติดตั้งไว้ในรถหุ่นยนต์ เพื่อวัดความลึกหรือความสูงจากตำแหน่งที่ติดตั้งไปยังพื้นผิวถนนสำหรับใช้ตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อและเนินชะลอความเร็ว



รูปที่ 2.6 การตรวจจับสภาพพื้นผิวถนนโดยใช้อัลตราโซนิก


ที่มา: Madli และคณะ (2015)

การตรวจจับสภาพพื้นผิวถนนที่ผิปกคิดด้วยวิธีการใช้อัลตราโซนิก ที่กล่าวมาแล้วข้างต้น สรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ ใช้ต้นทุนต่ำในพัฒนา ใช้พื้นที่ในการจัดเก็บข้อมูลน้อยและข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลได้แบบเวลาจริง อย่างไรก็ตาม การตรวจจับสภาพพื้นผิวถนนอาจให้ผลลัพธ์ที่ผิดพลาด เช่น หลุมบ่อที่เต็มไปด้วยโคลนไม่สามารถตรวจพบได้ ส่วนการแจ้งเตือนผู้ขับขี่เป็นการใช้ข้อมูลสภาพพื้นผิวถนนเดิมที่ถูกจัดเก็บไว้ในฐานข้อมูลแล้ว (Madli et al., 2015, p. 4313)

### 2.2.5 วิธีการวัดเสียง (Audio-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนนโดยใช้ไมโครโฟนที่ถูกติดตั้งใกล้ล้อรถ ดังรูปที่ 2.7 เพื่อวัดเสียงของล้อรถขณะตกกระทบกับพื้นผิวถนนในลักษณะต่าง ๆ ลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้ เช่น หลุมบ่อขนาดใหญ่ ขนาดกลางและขนาดเล็ก พบได้ในงานวิจัยของ Mednis และคณะ (2010) ส่วนลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้ประเภทผิวถนนมีการเย็บ (Bleeding) ผิวมวลรวมถูกขัดสีเป็นมัน (Polished Aggregate) และการหลุดร่อน (Ravelling) พบในงานวิจัยของ Zhang และคณะ (2013) นอกจากนี้ลักษณะสภาพพื้นผิวถนนที่

ผิดปกติประเภทน้ำไหลซึมขึ้นมาจากรอยแตกหรือชั้นถนน (Water Bleeding) และความขรุขระของผิวถนน (Roughness) พบได้ในงานวิจัยของ Abdic และคณะ (2016)



รูปที่ 2.7 การตรวจจับสภาพพื้นผิวถนนโดยใช้ไมโครโฟน

ที่มา: Zhang และคณะ (2013) และ Abdic และคณะ (2016)

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการวัดเสียง ที่กล่าวมาแล้วข้างต้นสรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ ใช้ต้นทุนต่ำในการพัฒนา พื้นที่ในการจัดเก็บข้อมูลน้อย และข้อมูลที่ได้รับจากการตรวจจับสามารถนำมาใช้ในการประมวลผลได้แบบเวลาจริง ข้อจำกัดของงานวิจัย คือ เสียงรบกวน (Noise) เช่น เสียงของยางรถ เสียงลม เสียงของเครื่องยนต์ เสียงจากสภาพแวดล้อมรอบข้าง อาจส่งผลต่อการวัดเสียงของล้อรถขณะตกกระทบกับพื้นผิวถนนในลักษณะต่าง ๆ แต่อย่างไรก็ตาม การใช้วิธีการวัดเสียงอาจใช้เป็นส่วนเสริมในการตรวจสอบและสนับสนุนเครื่องรับรู้อื่นได้ (Zhang, Mcdaniel, and Wang, 2013, p. 1; Coenen and Golroo, 2017, p. 11)

### 2.2.6 วิธีการใช้ข้อมูลหลายรูปแบบ (Multimodal Data-based Methods)

เป็นการตรวจจับสภาพพื้นผิวถนนโดยใช้เครื่องรับรู้สองชนิดขึ้นไป เพื่อส่งเสริมสนับสนุนข้อมูลในการเรียนรู้ร่วมกันและเพิ่มความถูกต้องในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในลักษณะต่าง ๆ พบได้ในงานวิจัยของ Orhan (2013) และ Orhan และ Eren (2013a, 2013b) เสนอระบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ประเภทหลุมบ่อ (Potholes) เนินชะลอความเร็ว (Speed Bumps) และตรวจจับสิ่งกีดขวางบนถนน โดยใช้เครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) กล้องบันทึกรูปภาพ (Camera) เครื่องรับรู้สนามแม่เหล็ก (Magnetometer) และระบบระบุตำแหน่งบนพื้นโลก (Global Positioning System: GPS) เหตุการณ์สภาพพื้นผิวถนนหลุมบ่อและเนินชะลอความเร็วถูกตรวจสอบและสกัดข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนโดยการกำหนดค่าเทรโซลและแสดงรูปภาพของสภาพพื้นผิวถนนหลุมบ่อและเนินชะลอความเร็วตามความเร็วของรถและตำแหน่งของข้อมูลที่ตรงกัน เมื่อตรวจพบเหตุการณ์สภาพพื้นผิวถนนที่

ผิดปกติจึงส่งไปวิเคราะห์ตำแหน่งและแจ้งเตือนผู้ขับขี่คนอื่น ๆ ที่อยู่บริเวณใกล้เคียง และงานวิจัยของ Rajamohan และคณะ (2015) เป็นการตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อโดยแบ่งเป็น 4 ระดับ ได้แก่ สภาพถนนดี สภาพถนนเป็นที่พอใจ สภาพถนนไม่น่าพอใจ สภาพถนนแย่ ซึ่งใช้ข้อมูลรูปภาพจากกล้อง เพื่อนำมาสกัดคุณลักษณะขอบของภาพ (Edge Feature Extract) ด้วยวิธีการประมวลผลภาพและใช้เครื่องรับรู้มาตรการความเร่ง เพื่อนำข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนมาจำแนกประเภทหลุมบ่อที่แบ่งเป็น 4 ระดับ ตามลักษณะสภาพถนน โดยใช้วิธีการเรียนรู้ด้วยเครื่อง ผลของการตรวจจับจากข้อมูลรูปภาพจะเป็นส่วนเสริมให้ระบบตรวจจับด้วยเครื่องรับรู้มาตรการความเร่งสมบูรณ์มากขึ้น หากมีการตรวจจับหลุมบ่อที่ผิดพลาดโดยใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการใช้เครื่องรับรู้ข้อมูลหลายรูปแบบที่กล่าวมาแล้วข้างต้น สรุปข้อดีและข้อจำกัดของงานวิจัยได้ ดังนี้ ส่งเสริมสนับสนุนข้อมูลในการเรียนรู้ร่วมกันเพื่อเพิ่มความถูกต้องในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในลักษณะต่าง ๆ อย่างไรก็ตามข้อจำกัดของงานวิจัย พบว่า ใช้ขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนจากข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อระบุสภาพพื้นผิวถนนที่ผิดปกติแล้วดึงรูปภาพมาแสดงให้ตรงตามผลการวิเคราะห์ข้อมูลจากเครื่องรับรู้มาตรการความเร่งเท่านั้น (Orhan, 2013; Orhan and Eren, 2013a; Orhan and Eren, 2013b) ซึ่งไม่ได้มีขั้นตอนวิธีการวิเคราะห์รูปภาพร่วมด้วย นอกจากนี้ข้อมูลการทดสอบที่ไม่มีสภาพแวดล้อมใกล้เคียงกับข้อมูลที่ใช้ในการทดลอง พบว่า ความแม่นยำในการจำแนกสภาพพื้นผิวถนนลดลงมาก หากมีสภาพแวดล้อมที่เป็นอุปสรรค เช่น แสงและเงาบนพื้นผิวถนน (Rajamohan, Gannu, and Rajan, 2015, p. 1240)

จากวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติทั้ง 6 วิธี สรุปลักษณะสภาพพื้นผิวถนนที่ใช้ในการตรวจจับ ข้อดีและข้อจำกัด ดังแสดงในตารางที่ 2.2



ตารางที่ 2.2 สรุปลักษณะสภาพพื้นผิวถนนที่ใช้ในการตรวจจับ ข้อดีและข้อจำกัด

สภาพพื้นผิวถนน ข้อดี ข้อจำกัด		วิธีการ					
		วิธีวัดแรงสั่นสะเทือน	วิธีนำภาพถ่ายมาสร้างภาพสามมิติ	วิธีการพื้นฐานจากการมองเห็น	วิธีใช้คลื่นความถี่สูง	วิธีวัดเสียง	วิธีใช้ข้อมูลหลายรูปแบบ
สภาพพื้นผิวถนนที่ตรวจจับ	หลุมบ่อ	✓	✓	✓	✓	✓	✓
	การปูคานู	✓	✓	✓			
	เนินชะลอความเร็ว	✓	✓	✓	✓		✓
	ความขรุขระของผิวถนน	✓	✓	✓		✓	
	รอยแตก		✓	✓			
	รอยปะซ่อม		✓	✓			
	ร่องล้อ		✓	✓	✓		
	ผิวถนนเอี่ยม		✓			✓	
	การหลุดร่อน น้ำไหลซึมจากรอยแตก		✓			✓	
	ความเสียหายตามขอบ		✓		✓		
ข้อดี	ต้นทุนต่ำ	✓		✓	✓	✓	✓
	ใช้พื้นที่เก็บข้อมูลน้อย	✓			✓		✓
	ประมวลผลแบบเวลาจริง	✓		✓	✓	✓	✓
	มีความถูกต้องสูง		✓				
	คำนวณจำนวนของหลุมบ่อได้			✓			
	ช่วยเสริมให้มีความถูกต้องสมบูรณ์ขึ้น						✓



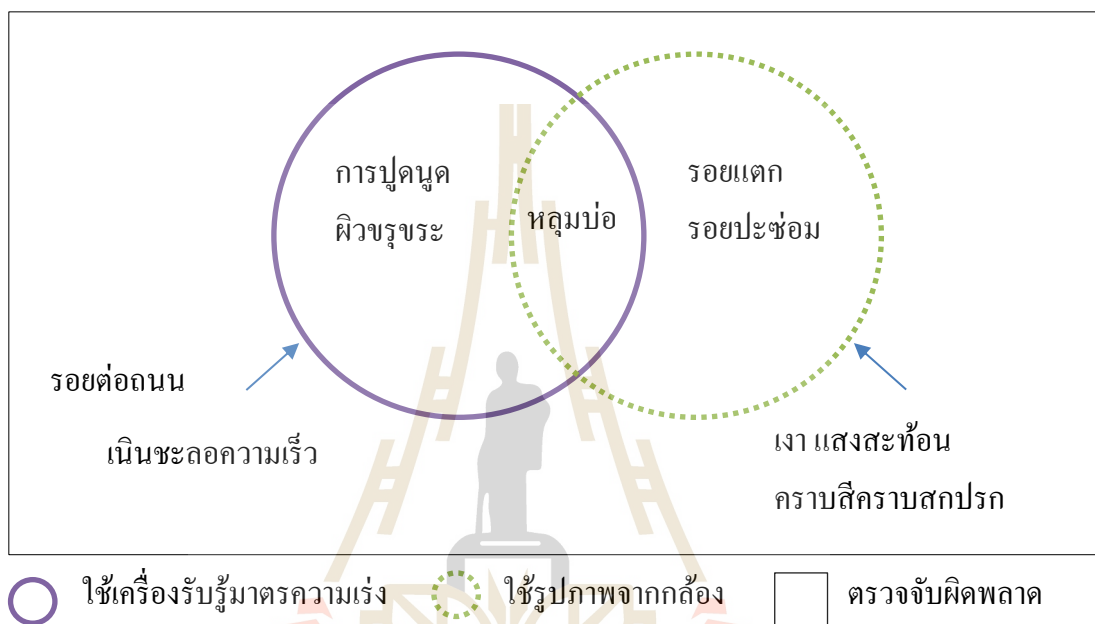
ตารางที่ 2.2 สรุปลักษณะสภาพพื้นผิวถนนที่ใช้ในการตรวจจับ ข้อดีและข้อจำกัด (ต่อ)

สภาพพื้นผิวถนน ข้อดี ข้อจำกัด		วิธีการ					
		วิธีวัดแรงสั่นสะเทือน	วิธีนำภาพถ่ายมาสร้าง ภาพสามมิติ	วิธีการพื้นฐานจากการมองเห็น	วิธีใช้คลื่นความถี่สูง	วิธีวัดเสียง	วิธีใช้ข้อมูลหลายรูปแบบ
ข้อจำกัด	มีราคาแพงและใช้การคำนวณและประมวลผลสูง		✓				
	รอยต่อถนน เนินชะลอความเร็ว หลุมบ่อกลางช่องจราจร	✓					
	เงา แสงสะท้อนและคราบสกปรก			✓			✓
	หลุมบ่อที่เต็มไปด้วยโคลน				✓		
	เสียงรบกวน					✓	

วิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติทั้ง 6 วิธี มีการพัฒนาขั้นตอนวิธีด้วยเทคนิคต่าง ๆ ให้มีความน่าเชื่อถือที่สูงขึ้น แต่อย่างไรก็ตามวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแต่ละวิธีใช้เครื่องรับรู้ (Sensor) ที่แตกต่างกันจึงทำให้มีข้อดี ข้อจำกัดและลักษณะสภาพพื้นผิวถนนที่สามารถตรวจจับได้แตกต่างกันด้วย การเลือกวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติสำหรับงานวิจัยนี้พิจารณาจากการใช้อุปกรณ์หรือเครื่องรับรู้ที่มีต้นทุนต่ำในการพัฒนา ใช้งานง่าย บุคคลทั่วไปสามารถเข้าถึงและเก็บรวบรวมข้อมูลได้เป็นจำนวนมากและในบริเวณกว้าง โดยไม่จำเป็นต้องติดตั้งอุปกรณ์พิเศษเพิ่มเติมที่มีราคาแพง

ดังนั้น งานวิจัยนี้จึงเลือกวิธีการตรวจสอบสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ข้อมูลจากเครื่องรับรู้ในโทรศัพท์มือถือ ได้แก่ เครื่องรับรู้มาตรความเร่ง (Accelerometer) ซึ่งเป็นวิธีวัดแรงสั่นสะเทือน (Vibration-based Methods) และรูปภาพจากกล้องถ่ายภาพซึ่งเป็นวิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) อย่างไรก็ตาม งานวิจัยที่ผ่านมาที่ใช้วิธีวัดแรงสั่นสะเทือนจากข้อมูลเครื่องรับรู้มาตรความเร่งในโทรศัพท์มือถือ พบว่า มีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจำนวน 4 ประเภท ได้แก่ หลุมบ่อ การปูดนูน เนินชะลอความเร็วและผิวขรุขระเป็นคลื่นคล้ายลูกกระนาค อย่างไรก็ตามสภาพพื้นผิวถนนที่มีการตรวจจับผิดพลาด ได้แก่ รอยต่อถนน

เน้นชะลอความเร็ว ส่วนวิธีการพื้นฐานจากการมองเห็น โดยใช้รูปภาพจากกล้องในโทรศัพท์  
 สมาร์ทโฟน พบว่า มีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจำนวน 3 ประเภท ได้แก่ หลุมบ่อ  
 รอยแตก รอยปะ อย่างไรก็ตามสภาพพื้นผิวถนนที่มีการตรวจจับผิดพลาดเกิดจากภาพถ่าย  
 พื้นผิวถนนที่มีสภาพแฉกแฉกไม่แน่นอนและแปรปรวนสูง ได้แก่ เงานะแสงสะท้อนและ  
 คราบสกปรกต่าง ๆ บนผิวถนน ดังแสดงในรูปที่ 2.8



รูปที่ 2.8 สภาพพื้นผิวถนนที่ตรวจจับโดยใช้ข้อมูลจากเครื่องรับรู้ในโทรศัพท์สมาร์ทโฟน

ดังนั้นขั้นตอนวิธีที่มีประสิทธิภาพควรมีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติให้มีความถูกต้องและตรวจจับลักษณะสภาพพื้นผิวถนนให้หลากหลายประเภทมากขึ้น งานวิจัยนี้ใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่งมาช่วยเพิ่มการรับรู้ข้อมูลรูปภาพ และนำข้อมูลรูปภาพมาช่วยเพิ่มการรับรู้ข้อมูลมาตรฐานความเร่ง ตัวอย่างเช่น สภาพพื้นผิวถนนที่มีการตรวจจับผิดพลาดโดยใช้เครื่องรับรู้มาตรฐานความเร่ง สามารถนำข้อมูลรูปภาพมาช่วยระบุลักษณะสภาพพื้นผิวถนนว่าแรงสั่นสะเทือน ณ ตำแหน่งนั้นเป็นรูปภาพลักษณะสภาพพื้นผิวถนนที่ผิดปกติในประเภทใด ในทางตรงกันข้ามสภาพพื้นผิวถนนที่มีการตรวจจับผิดพลาดโดยใช้ข้อมูลรูปภาพจากกล้องที่มีสภาพแฉกแฉกไม่แน่นอนและแปรปรวนสูง ได้แก่ เงานะแสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน สามารถใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่งเพื่อวัดแรงสั่นสะเทือนมาช่วยระบุสภาพพื้นผิวถนนปกติได้เนื่องจากข้อมูลรูปภาพ ณ ตำแหน่งนั้นไม่มีแรงสั่นสะเทือน

## 2.3 แนวคิดเกี่ยวกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

### 2.3.1 การเรียนรู้ของเครื่อง (Machine Learning)

เป็นสาขาหนึ่งของปัญญาประดิษฐ์ที่ศึกษาและสร้างขั้นตอนวิธีที่ทำให้เครื่องคอมพิวเตอร์เรียนรู้ได้จากข้อมูลตัวอย่างหรือจากสภาพแวดล้อม เพื่อสร้างแบบจำลองหรือขั้นตอนวิธีและนำไปใช้หรือทำนายข้อมูลใหม่ได้ โดยมีจุดมุ่งหมายเพื่อการพัฒนาหรือปรับปรุงประสิทธิภาพการทำงานของระบบให้ดีขึ้น เมื่อเรียนรู้แล้วความรู้ที่เรียนได้จะถูกเก็บไว้ในฐานความรู้ด้วยรูปแบบการแทนความรู้ได้อย่างใดอย่างหนึ่ง เช่น กฎ ฟังก์ชัน ฯลฯ (Ethem, 2010, pp. 3-4; Giancarlo, 2016, p. 7; Giancarlo, Rezaul, and Ahmed, 2017, p. 8)

ประเภทของการเรียนรู้ของเครื่อง ประกอบด้วย 1) การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการเรียนรู้จากลักษณะของข้อมูลตัวอย่างที่มีการระบุผลที่ต้องการหรือประเภทไว้แล้วนำไปทำนายข้อมูลอื่นที่ไม่รู้คำตอบ ทั้งนี้การเรียนรู้แบบมีผู้สอนสามารถนำไปประยุกต์ใช้ในการประมาณค่าของข้อมูล (Estimation) การจัดประเภทของข้อมูล (Classification) การพยากรณ์ข้อมูลในอนาคต (Prediction) และ 2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการสร้างตัวแบบที่เหมาะสมกับข้อมูล โดยไม่มีการระบุผลที่ต้องการหรือประเภทไว้ก่อน ทั้งนี้การเรียนรู้แบบไม่มีผู้สอนสามารถนำไปประยุกต์ใช้ในการจัดกลุ่มข้อมูลได้ (Clustering) (Giancarlo et al., 2017, pp. 8-9; Mohri, Rostamizadeh, and Talwalkar, 2012, p. 7)

หลายปีที่ผ่านมามีงานวิจัยด้านการรู้จำภาพ (Image Recognition) ได้มีการประยุกต์ใช้วิธีการเรียนรู้ของเครื่องแบบดั้งเดิม (Traditional Machine Learning) ซึ่งเน้นการวิเคราะห์รูปภาพจากขั้นตอนวิธีการประมวลผลภาพในระดับต่ำ (Low-level Image) โดยการลดความซ้ำซ้อนของสี (Color Normalization) การแยกส่วนของภาพ (Segmentation) การสกัดคุณลักษณะด้วยมือ (Hand-crafted Feature Extraction) เพื่อให้ได้คุณลักษณะของภาพที่เกี่ยวข้องกับสี รูปทรง เส้นขอบของภาพ จากนั้นจึงรู้จำรูปภาพโดยใช้ขั้นตอนวิธีการเรียนรู้ของเครื่อง แต่อย่างไรก็ตาม ขั้นตอนวิธีดังกล่าวไม่สามารถประมวลผลชุดคุณสมบัติของรูปภาพ (Image Features) ที่มีจำนวนมากได้ (High Dimensional) (Bezak, 2016, p. 159)

ถึงแม้ว่าขั้นตอนวิธีโครงข่ายประสาทเทียม (Artificial Neural Network) เป็นขั้นตอนวิธีหนึ่งที่ถูกนำมาประยุกต์ใช้เพื่อสกัดคุณสมบัติของรูปภาพที่มีมิติมากได้ แต่อย่างไรก็ตามความสามารถในการประมวลผลยังไม่เพียงพอที่ทำให้วิธีการดังกล่าวสามารถสกัดคุณสมบัติของรูปภาพที่มีมิติมากได้อย่างมีนัยสำคัญ (Bezak, 2016, p. 159) นอกจากนี้ ผลลัพธ์ที่มีประสิทธิภาพจากการใช้ขั้นตอนวิธีการประมวลผลภาพขึ้นอยู่กับวิธีการสกัดคุณลักษณะด้วยมือ (Hand-crafted Feature Extraction) ในขณะที่ลักษณะสำคัญของการเรียนรู้เชิงลึก (Deep Learning) เป็นขั้นตอนวิธีที่สามารถเรียนรู้ข้อมูลผ่านการเรียนรู้ (Training) แล้วสามารถค้นพบคุณลักษณะเด่น (Features)

จากข้อมูลที่น่ามาเรียนรู้ได้โดยตรง ซึ่งไม่ต้องใช้วิธีการสกัดคุณลักษณะ (Features Extraction) และเลือกคุณลักษณะด้วยมือ (Features Selection) (Maeda, Sekimoto, and Seto, 2016b, p. 39; Eisenbach et al., 2017, p. 2040) ดังแสดงในรูปที่ 2.9




รูปที่ 2.9 การใช้ขั้นตอนวิธีการประมวลผลภาพร่วมกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

ดังนั้นขั้นตอนวิธีใหม่ควรได้รับการพัฒนาเพื่อสกัดคุณสมบัติของรูปภาพที่มีมิติมากได้แบบอัตโนมัติโดยไม่จำเป็นต้องใช้วิธีการสกัดคุณลักษณะด้วยมือ ในปัจจุบันขั้นตอนวิธีโครงข่ายประสาทเทียมถูกนำมาประยุกต์ใช้งานอย่างแพร่หลายและมีการออกแบบทดลองโครงข่ายในชั้นซ่อนหลาย ๆ ชั้น (Hidden Layers) เรียกว่า โครงข่ายเชิงลึก (Deep Networks) ที่สามารถนำมาใช้กับงานการรู้จำภาพได้อย่างมีประสิทธิภาพ โดยเฉพาะอย่างยิ่งสถาปัตยกรรมการเรียนรู้เชิงลึกประเภทโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks) (Bezak, 2016, p. 159; Giancarlo, 2016, p. 126)

### 2.3.2 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้ที่มีโครงสร้างเชิงลึกหรือที่เรียกกันทั่วไปว่า การเรียนรู้เชิงลึก (Deep Learning) ได้กลายเป็นแนวทางใหม่สำหรับงานวิจัยเกี่ยวกับการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึกใช้ขั้นตอนวิธีโครงข่ายประสาทเทียม (Neural Network Algorithm) เพื่อสกัดคุณลักษณะเฉพาะสำหรับการเรียนรู้แบบมีผู้สอนหรือแบบไม่มีผู้สอนด้วยเทคนิคและขั้นตอนวิธีต่าง ๆ เพื่อการวิเคราะห์รูปแบบและการจำแนกข้อมูล เช่น ภาพ (Image) เสียง (Sound) และข้อความ (Text) เป็นต้น (Deng and Yu, 2014, pp. 198-201; Giancarlo, Rezaul, and Ahmed, 2017, p. 10)

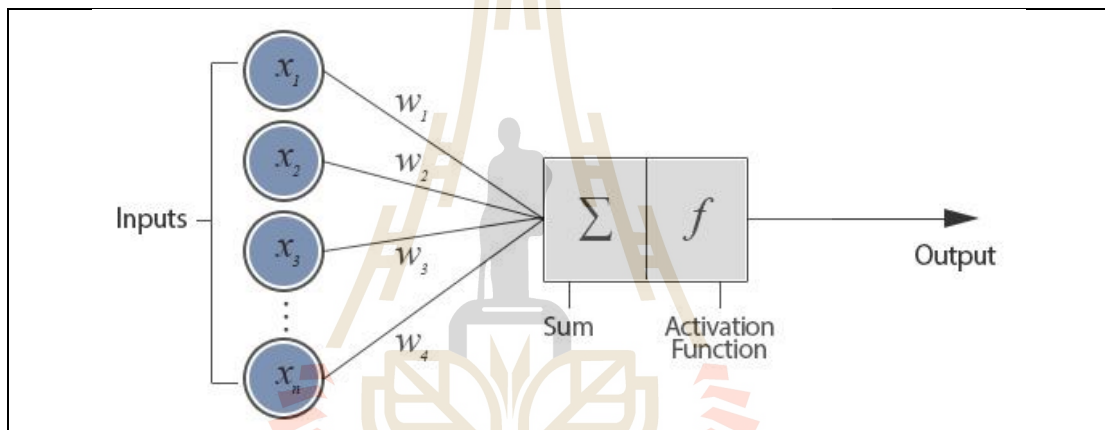
พื้นฐานที่สำคัญของขั้นตอนวิธีโครงข่ายประสาทเทียม (Artificial Neural Network) เกิดจากการเลียนแบบการทำงานของสมองมนุษย์ที่ประกอบด้วยเซลล์พิเศษจำนวนมากที่เรียกว่า เซลล์ประสาท (Neuron) หรือ นิวรอน (Neuron) โดยมีองค์ประกอบพื้นฐานที่สำคัญ 3 ส่วน ได้แก่ ส่วนแรกคือ ตัวเซลล์ (Cell Body) หรือ โซมา (Soma) ทำหน้าที่รวบรวมข้อมูลที่ได้จากปลายประสาทเปรียบเสมือนตัวรวบรวมน้ำหนักของสัญญาณไฟฟ้า ส่วนที่สองคือ เดนไดรต์ (Dendrite) เป็นเส้นใยบาง ๆ ทำหน้าที่รับสัญญาณไฟฟ้าที่ส่งมาจากเซลล์ประสาทข้างเคียงเข้าสู่เซลล์ประสาทเปรียบเสมือนอินพุต (Input) ที่รับข้อมูลเข้า และส่วนที่สามคือ แอ็กซอน (Axon) เป็นเส้นใยบาง ๆ ทำหน้าที่ส่งผ่านสัญญาณไปยังเซลล์อื่น ๆ เปรียบเสมือนเอาต์พุต (Output) ที่ส่งผลลัพธ์หรือคำตอบไปยังเซลล์ประสาทต่อไป เซลล์ประสาททำงานด้วยปฏิกิริยาทางเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่ตัวเซลล์ซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอตัวเซลล์จะกระตุ้นเซลล์อื่นโดยส่งผ่านทางแอ็กซอน ดังแสดงในรูปที่ 2.10 (Giancarlo et al., 2017, pp. 12 – 13)



รูปที่ 2.10 แสดงเซลล์ประสาทในสมองมนุษย์

การเลียนแบบการทำงานของสมองมนุษย์ของคอมพิวเตอร์โดยการสร้างเซลล์ประสาทเทียม (Artificial Neural) ประกอบด้วยการกำหนดให้แต่ละโหนด (Node) เปรียบเสมือน

เป็นเซลล์ประสาทและสร้างการเชื่อมต่อกับโหนดเหล่านั้นเป็นโครงข่าย (Network) แต่ละโครงข่ายประกอบด้วยโหนดที่ถูกจัดแบ่งเป็นชั้น ๆ ที่เรียกว่า เลเยอร์ (Layer) แต่ละเลเยอร์มีหน้าที่การทำงานที่แตกต่างกันออกไป โครงสร้างของโครงข่ายประสาทเทียม ประกอบด้วย ส่วนอินพุต (Input) ของโครงข่าย อินพุตที่เข้าสู่โหนดอยู่ในรูปของเวกเตอร์แทนด้วย  $X_1, X_2, \dots, X_n$  โดยอินพุตแต่ละตัวจะมีค่าถ่วงน้ำหนัก (Weight) แทนด้วย  $W_1, W_2, \dots, W_n$  จากนั้นคำนวณผลคูณกันระหว่างค่าอินพุตกับค่าถ่วงน้ำหนักแต่ละค่าแล้วนำมารวมกัน ณ จุดรวมสัญญาณแล้วนำผลคูณทั้งหมดมารวมกับค่าเบี่ยงเบน (Bias) แล้วส่งผลรวมที่ได้ผ่านไปยังฟังก์ชันกระตุ้น (Activation function) และส่งออกเอาที่พุดออกไปยังโหนดอื่น ๆ ของโครงข่ายประสาทเทียม ดังแสดงในรูปที่ 2.11 (Giancarlo et al., 2017, p. 14)



รูปที่ 2.11 แบบจำลองการทำงานของเซลล์ประสาทเทียม

ประเภทของโครงข่ายการเรียนรู้เชิงลึก (Deep Learning Networks) ประกอบด้วย 3 ประเภท คือ 1) โครงข่ายเชิงลึกสำหรับการเรียนรู้แบบไม่มีผู้สอน (Deep Networks for Unsupervised) 2) โครงข่ายเชิงลึกสำหรับการเรียนรู้แบบมีผู้สอน (Deep Networks for Supervised Learning) และ 3) โครงข่ายเชิงลึกแบบผสม (Hybrid Deep Networks) (Deng and Yu, 2014, p. 215) สำหรับงานวิจัยนี้ จัดอยู่ในประเภทโครงข่ายเชิงลึกสำหรับการเรียนรู้แบบมีผู้สอน เพื่อเรียนรู้ลักษณะของข้อมูลตัวอย่างที่มีการระบุผลที่ต้องการหรือประเภทของสภาพพื้นผิวถนนที่ผิดปกติไว้แล้ว

เทคนิคการเรียนรู้เชิงลึกถือเป็นสิ่งสำคัญที่นักวิจัยด้านการเรียนรู้ของเครื่องได้ดำเนินการวิจัยและพัฒนาในช่วงหลายปีที่ผ่านมาซึ่งนำมาประยุกต์ใช้ในการรู้จำภาพ (Image Recognition) และการรู้จำเสียงพูด (Speech Recognition) สาเหตุหลายประการที่นักวิจัยใช้วิธีการเรียนรู้เชิงลึกในการรู้จำภาพ แสดงดังตารางที่ 2.3



### ตารางที่ 2.3 สาเหตุที่ใช้การเรียนรู้เชิงลึก

สาเหตุ	คำอธิบาย
1. สกัคคุณลักษณะเด่นจากข้อมูลที่น่ามาเรียนรู้ได้โดยตรง	ลักษณะสำคัญของการเรียนรู้เชิงลึก เป็นขั้นตอนวิธีที่สามารถเรียนรู้ข้อมูลผ่านการฝึกฝนและมีกระบวนการฝึกฝนที่ง่ายต่อการค้นหารูปแบบของข้อมูลจากโครงสร้างสถาปัตยกรรมของโครงข่ายที่มีหลายชั้นซึ่งในแต่ละชั้นจะค่อย ๆ สกัคคุณลักษณะเด่นออกมาให้ชั้นถัดไปเรียนรู้ข้อมูลได้โดยตรง (Giancarlo, 2016, pp. 124-126) ซึ่งไม่ต้องใช้วิธีการสกัคคุณลักษณะ และเลือกคุณลักษณะด้วยมือ (Maeda et al., 2016b, p. 39; Eisenbach, et al., 2017, p. 2040)
2. ความก้าวหน้าทางด้านฮาร์ดแวร์	ความก้าวหน้าทางด้านฮาร์ดแวร์ที่มีหน่วยประมวลผลกราฟิก (Graphics Processing Units: GPUs) ซึ่งช่วยลดเวลาในการฝึกฝนของโครงข่ายลงได้ครึ่งหนึ่ง (Giancarlo, 2016, p. 124)

สาเหตุดังกล่าว ทำให้มีการปรับปรุงแนวคิดและสถาปัตยกรรมโครงข่ายใหม่ เรียกว่าโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks) (Szegedy et al., 2015) ซึ่งเป็นโครงข่ายประสาทเทียมเชิงลึกรูปแบบหนึ่งที่ประสบความสำเร็จอย่างมากในการใช้งานจริงและได้รับการออกแบบมาสำหรับการรู้จำวัตถุในภาพ (Giancarlo, 2016, p. 126)

#### 2.3.3 การเรียนรู้เชิงลึกหลายรูปแบบ (Multimodal Deep Learning)

การเรียนรู้หลายงาน (Multi-task Learning) หรือการเรียนรู้หลายรูปแบบ (Multimodal Learning) เป็นแนวทางหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ในการเรียนรู้และแก้ไขปัญหาที่เกี่ยวข้องกันในเวลาเดียวกันจากการใช้ข้อมูลร่วมกัน เพื่อถ่ายโยงความรู้ (Transfer Learning) หรือถ่ายทอดความรู้ (Knowledge Transfer) ในลักษณะคล้ายกัน (Generalization) จากงานหลากหลายรูปแบบ (Deng and Yu, 2014, p. 331)

ที่ผ่านมามีงานวิจัยที่ประยุกต์ใช้การเรียนรู้หลายรูปแบบ (Multimodal Learning) ด้วยข้อมูลในลักษณะต่าง ๆ เช่น ข้อความ (Text) กับรูปภาพ (Image) เสียงพูด (Speech) กับรูปภาพ (Image) การเรียนรู้หลายรูปแบบนำความสัมพันธ์ระหว่างข้อความ (Text) กับรูปภาพ (Image) มาเรียนรู้ข้อมูลร่วมกัน โดยใช้ข้อมูลข้อความเพื่อช่วยการรับรู้รูปภาพและใช้ข้อมูลรูปภาพเพื่อช่วยในการรับรู้ข้อความ (Deng and Yu, 2014, p. 332) เช่น ระบบการรู้จำภาพเชิงความหมาย (Deep Visual-semantic Embedding: DeVISE) พัฒนาโดย Frome และคณะ (2013) เป็นการเรียนรู้


หลายรูปแบบ (Multimodal Learning) ที่ใช้ข้อมูลข้อความ (Labels) มาทำการฝึกฝนร่วมกับรูปภาพ (Images) เพื่อปรับปรุงระบบการรู้จำภาพให้ดีขึ้น

นอกจากนี้งานวิจัยที่ประยุกต์ใช้การเรียนรู้หลายรูปแบบ (Multimodal Learning) ด้วยข้อมูลรูปภาพ (Image) และข้อมูลเสียงพูด (Audio) พบได้ในงานวิจัยของ Ngiam และคณะ (2011) ที่นำความสัมพันธ์ระหว่างรูปภาพวิดีโอและเสียงพูดมาเรียนรู้ข้อมูลร่วมกัน โดยใช้การเรียนรู้หลายรูปแบบโครงข่ายประสาทเทียมแบบ Restricted Boltzmann Machine (RBM) ซึ่งสามารถเรียนรู้คุณลักษณะได้ดีกว่าการเรียนรู้จากข้อมูลรูปแบบเดียว (Single Modality)

ในการตรวจจับลักษณะสภาพพื้นผิวถนนที่ผ่านมา ยังไม่พบงานวิจัยใดที่ประยุกต์ใช้ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า ร่วมกับการจำแนกสภาพพื้นผิวถนนใหม่ด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบ (Multimodal Deep Learning) โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks: Multimodal DCNN) ดังนั้นงานวิจัยนี้ จึงเสนอขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าร่วมกับการจำแนกสภาพพื้นผิวถนนใหม่ด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อถ่ายทอดความรู้ที่เกี่ยวข้องกันในเวลาเดียวกัน ซึ่งเป็นการนำความสัมพันธ์ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนมาช่วยในการรับรู้ข้อมูลรูปภาพและนำข้อมูลรูปภาพมาช่วยในการรับรู้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อเพิ่มความถูกต้องของการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

#### 2.3.4 สถาปัตยกรรมของตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน

สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ประกอบด้วย ชั้นนำเข้าข้อมูล (Input Layer) เป็นชั้นที่นำเข้าภาพซึ่งภาพแต่ละภาพแทนด้วยเมทริกซ์ที่ประกอบด้วย ความกว้าง ความสูงและสี ชั้นถัดไปเรียกว่า ชั้นคอนโวลูชัน (Convolutional Layer) โดยนำภาพมาแบ่งเป็นส่วน ๆ ที่มีขนาดเล็กและในแต่ละส่วนถูกนำมาประมวลผลผ่านตัวกรอง (Filters) เพื่อค้นหารูปแบบเฉพาะที่เน้นคุณสมบัติบางอย่างที่ต้องการในภาพให้เด่นชัดขึ้นและลดทอนคุณสมบัติที่ไม่ต้องการลง ผลลัพธ์ของการประมวลผลในชั้นคอนโวลูชันจะถูกส่งต่อไปในแต่ละเซลล์ประสาท (Neurons) ในชั้นการเชื่อมต่อแบบโยงไปข้างหน้าแบบทั่วถึง (Fully Connected Layer) ที่เรียกว่าชั้นซ่อน (Hidden Layers) และชั้นผลลัพธ์ (Output Layers) เพื่อจำแนกข้อมูลต่อไป (Giancarlo et al., 2017, pp. 20-21) ดังแสดงในรูปที่ 2.12




รูปที่ 2.12 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Giancarlo et al., 2017, p. 21)

### 1) ชั้นนำเข้าข้อมูล (Input Layer)

เป็นชั้นที่นำเข้ารูปภาพซึ่งภาพแต่ละภาพแทนด้วยเมตริกซ์ที่ประกอบด้วย ความกว้าง ความสูงและความลึก (สี)

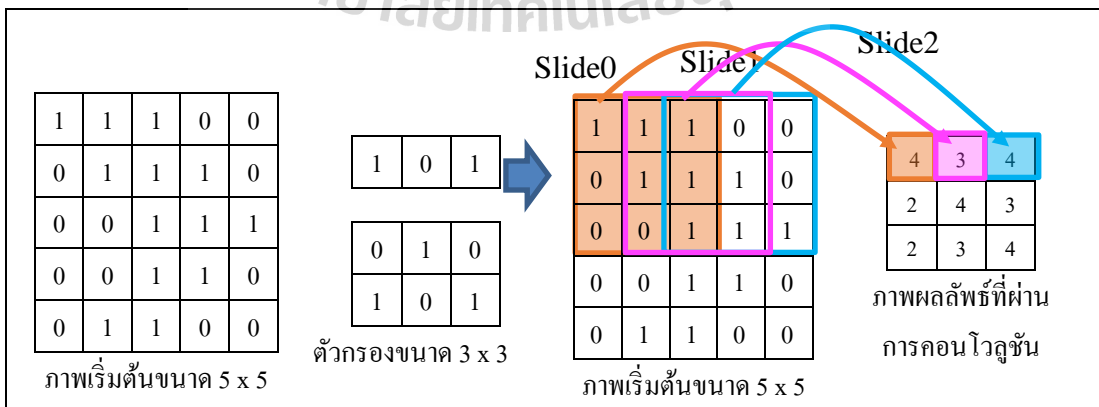
### 2) กระบวนการทำงานในชั้นคอนโวลูชัน (Convolutional Layer)

เป็นการดำเนินการทางคณิตศาสตร์ที่ใช้ในการประมวลผลผ่านตัวกรอง (Filters) เพื่อค้นหารูปแบบเฉพาะของข้อมูลภาพนำเข้าโดยการสกัดคุณลักษณะเชิงสัมพันธ์กับพื้นที่ในส่วน ของภาพ ในทุก ๆ ส่วนย่อยของภาพจะนำตัวกรองมาซ้อนทับภาพในตำแหน่งต่าง ๆ เช่น ตัวกรอง ขนาด 5x5 เพื่อหาผลลัพธ์ของการคอนโวลูชัน ผลลัพธ์ของการประมวลผลในชั้นคอนโวลูชันจะถูก ส่งต่อไปยังเซลล์ประสาท (Neurons) ในชั้นซ่อนแรก (First Hidden Layers) ดังแสดงในรูปที่ 2.13 โดยปกติการกำหนดจำนวนชั้นของคอนโวลูชันสามารถเพิ่มจำนวนชั้นได้หลายชั้นซึ่งจำนวนชั้นที่ เพิ่มมากขึ้นนี้เป็นแนวคิดพื้นฐานของการเรียนรู้เชิงลึกนั่นเอง (Giancarlo, 2016, p. 128)



รูปที่ 2.13 การใช้ตัวกรองซ้อนทับภาพเพื่อหาผลลัพธ์ของการคอนโวลูชัน (Giancarlo, 2016)

การหาผลลัพธ์ของการคอนโวลูชัน คือ การหาผลรวมของผลคูณระหว่างค่าในตัวกรองกับค่าระดับความเข้มแสงของภาพในบริเวณที่ตัวกรองซ้อนทับอยู่ จากนั้นจึงทำการเลื่อนตัวกรองไปยังตำแหน่งต่าง ๆ ของภาพจนครบ ตัวอย่างเช่น การคอนโวลูชันระหว่างภาพขนาด 5 x 5 กับตัวกรองขนาด 3 x 3 และเลื่อนตัวกรองคอนโวลูชัน (Slide Convolutional Filter) ครั้งละ 1 พิกเซล ดังแสดงในรูปที่ 2.14



รูปที่ 2.14 การหาผลลัพธ์และการเลื่อนตัวกรองคอนโวลูชัน

ตัวอย่างในรูปที่ 2.14 เป็นการเลื่อนกรอบตัวกรองของรูปภาพที่นำเข้ามา เพื่อคำนวณหาภาพผลลัพธ์ โดยหาผลรวมของผลคูณระหว่างกรอบตัวกรองกับภาพในบริเวณที่ แรเงา เช่น

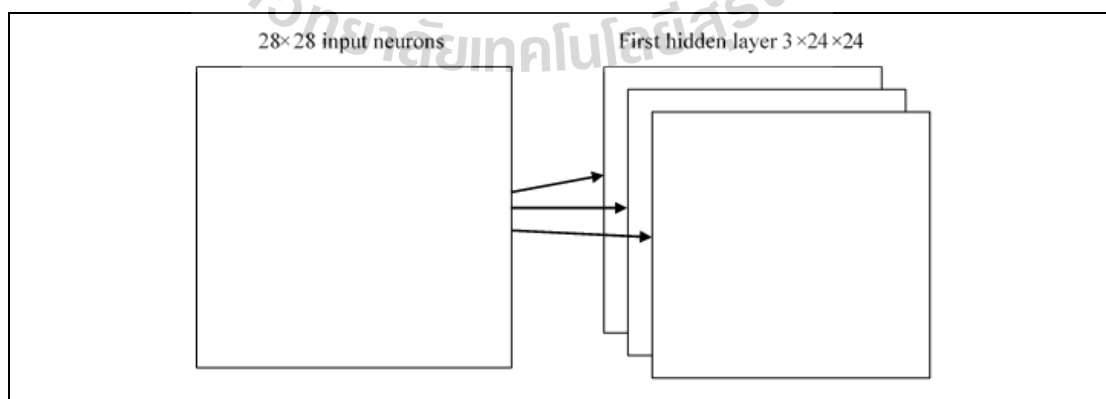
$$\text{Slide0 มีค่าเท่ากับ } (1 \times 1) + (1 \times 0) + (1 \times 1) + (0 \times 0) + (1 \times 1) + (1 \times 0) + (0 \times 1) + (0 \times 0) + (1 \times 1) = 4$$

$$\text{Slide1 มีค่าเท่ากับ } (1 \times 1) + (1 \times 0) + (0 \times 1) + (1 \times 0) + (1 \times 1) + (1 \times 0) + (0 \times 1) + (1 \times 0) + (1 \times 1) = 3$$

$$\text{Slide3 มีค่าเท่ากับ } (1 \times 1) + (0 \times 0) + (0 \times 1) + (1 \times 0) + (1 \times 1) + (0 \times 0) + (1 \times 1) + (1 \times 0) + (1 \times 1) = 4$$

จากตัวอย่างเป็นการเลื่อนครั้งละ 1 พิกเซล โดยทั่วไปสามารถกำหนดการเลื่อน กรอบตัวกรองได้มากกว่าครั้งละ 1 พิกเซล จำนวนที่ใช้ในการเลื่อนกรอบตัวกรองนี้ เรียกว่า สไตด์ หรือการเลื่อนข้าม (Stride)

หากรูปภาพมีขนาด  $28 \times 28$  พิกเซล กรอบตัวกรอง (Filter) มีขนาด  $5 \times 5$  พิกเซล จำนวน 1 ตัวกรองและเลื่อนข้าม ครั้งละ 1 พิกเซล ผลลัพธ์ที่ได้รูปภาพในชั้นซ่อนมีขนาด  $24 \times 24$  พิกเซล หรือมีจำนวนเซลล์ประสาท (Neurons) เท่ากับ 576 เซลล์ประสาทที่เป็นคุณลักษณะสำหรับการ เรียนรู้ โดยปกติแล้วการใช้ตัวกรองสามารถใช้ได้หลายตัวกรองเรียกว่า แผนที่คุณลักษณะ (Feature Maps) หากใช้แผนที่คุณลักษณะจำนวน 3 ตัวกรอง (Giancarlo, 2016, p. 130) ดังนั้นรูปภาพ ในชั้นซ่อนจะมีขนาด  $24 \times 24 \times 3$  พิกเซล หรือมีจำนวนเซลล์ประสาท (Neurons) เท่ากับ 1,728 เซลล์ประสาทที่เป็นคุณลักษณะสำหรับการเรียนรู้ ดังแสดงในรูปที่ 2.15

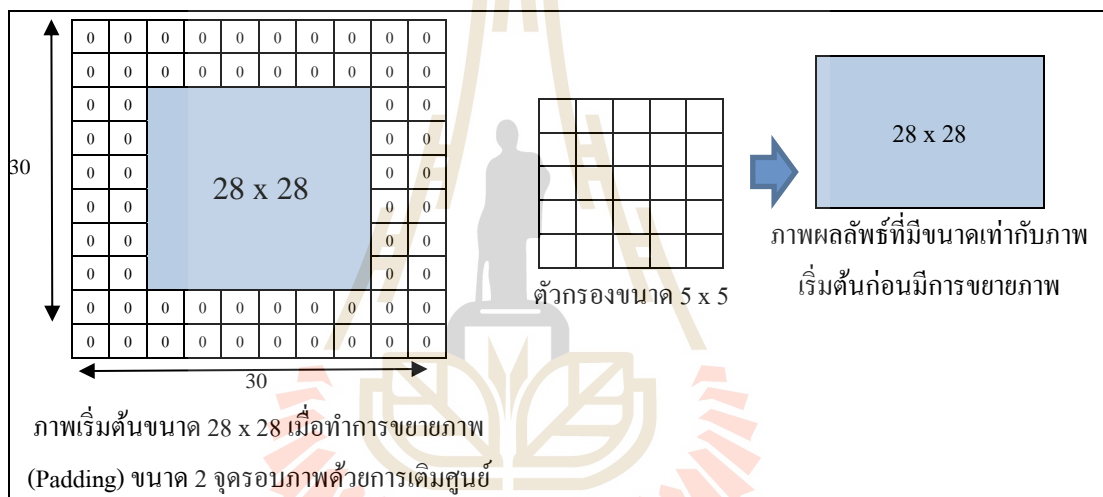


รูปที่ 2.15 แผนที่คุณลักษณะหลายจำนวน (Multiple Feature Maps) (Giancarlo, 2016, p. 130)



จากตัวอย่างที่ผ่านมา รูปภาพมีขนาด 28 x 28 พิกเซล กรอบตัวกรอง (Filter) มีขนาด 5 x 5 พิกเซล จำนวน 1 ตัวกรองและเลื่อนข้าม (Stride) ครั้งละ 1 พิกเซล ส่งผลให้รูปภาพมีขนาด 24 x 24 พิกเซล ซึ่งมีขนาดที่เล็กลง เนื่องจากการทำคอนโวลูชันจะไม่ยอมให้กรอบตัวกรอง (Filter) เลื่อนข้าม (Stride) ออกนอกบริเวณขอบภาพ วิธีการนี้ทำให้ได้ภาพที่มีขนาดเล็กลง หากต้องการคงขนาดภาพไว้ต้องใช้วิธีการขยายภาพ (Padding) ก่อนการทำคอนโวลูชัน

การขยายภาพ (Padding) เป็นวิธีการอย่างง่ายที่ทำให้ภาพผลลัพธ์มีขนาดเท่ากับภาพเริ่มต้นคือ การเติมค่าศูนย์บริเวณรอบ ๆ ภาพเริ่มต้น เพื่อทำให้ภาพเริ่มต้นมีขนาดใหญ่ขึ้น หลังจากผ่านการคอนโวลูชันแล้วจะทำให้ได้ภาพผลลัพธ์ที่มีขนาดเท่ากับภาพเริ่มต้นก่อนมีการขยายภาพ ดังแสดงในรูปที่ 2.16



รูปที่ 2.16 การคอนโวลูชันที่มีการเติมค่าศูนย์ให้กับภาพเริ่มต้น

จากตัวอย่างรูปภาพมีขนาด 28 x 28 พิกเซล ทำการขยายภาพ (Padding) จำนวน 2 จุดด้วยการเติมค่าศูนย์บริเวณรอบภาพเริ่มต้น กรอบตัวกรอง (Filter) มีขนาด 5 x 5 พิกเซล จำนวน 1 ตัวกรองและเลื่อนข้าม (Stride) ครั้งละ 1 พิกเซล ส่งผลให้รูปภาพมีขนาด 28 x 28 พิกเซล การคำนวณหาจำนวนจุดของการขยายภาพด้วยการเติมค่าศูนย์บริเวณรอบภาพ (Zero Padding) เพื่อทำคอนโวลูชันแล้วให้ได้ภาพผลลัพธ์เท่ากับภาพเริ่มต้น คำนวณได้ดังสมการที่ 2.1

$$\text{Zero padding} = \frac{(K-1)}{2} \quad (2.1)$$

เมื่อ Zero Padding คือ จำนวนจุดในการขยายภาพเริ่มต้น

K คือ ขนาดของตัวกรอง (Filter Size)

ตัวอย่างการคำนวณจำนวนจุดในการขยายภาพเริ่มต้น เช่น กรอบตัวกรอง (Filter) มีขนาด  $5 \times 5$  พิกเซลและเลื่อนข้าม (Stride) ครั้งละ 1 พิกเซล ดังนั้นจำนวนจุดในการขยายภาพด้วยการเติมค่าศูนย์บริเวณรอบ ๆ ภาพเริ่มต้น มีค่าเท่ากับ  $(5-1) / 2 = 2$  จุด

การคำนวณหาขนาดของภาพผลลัพธ์เมื่อผ่านการทำคอนโวลูชัน สามารถคำนวณได้ดังสมการที่ 2.2

$$O = \frac{(W-K+2P)}{S} + 1 \quad (2.2)$$

เมื่อ O คือ ขนาดของภาพผลลัพธ์เมื่อผ่านการทำคอนโวลูชัน

W คือ ความสูงของภาพเริ่มต้น

K คือ ขนาดของตัวกรอง


P คือ จำนวนจุดของการขยายภาพ (Padding) ด้วยการเติมค่าศูนย์รอบภาพ

S คือ จำนวนการเลื่อนข้าม (Stride)

จากตัวอย่างรูปภาพมีขนาด  $28 \times 28$  พิกเซล ทำการขยายภาพ (Padding) จำนวน 2 จุดด้วยการเติมค่าศูนย์บริเวณรอบภาพเริ่มต้น กรอบตัวกรอง (Filter) มีขนาด  $5 \times 5$  พิกเซล จำนวน 1 ตัวกรองและเลื่อนข้าม (Stride) ครั้งละ 1 พิกเซล ดังนั้นขนาดของภาพผลลัพธ์เมื่อผ่านการทำคอนโวลูชันมีค่าเท่ากับ  $((28 - 5 + 2(2)) / 1) + 1 = 28$

### 3) ชั้นกระตุ้น (Activation layer)

เป็นฟังก์ชันที่กำหนดให้ข้อมูลขาเข้าส่งต่อไปยังโหนดและใช้กำหนดผลลัพธ์ของโหนดนั้น ๆ ฟังก์ชันกระตุ้นที่นิยมใช้ในคอนโวลูชัน คือ ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified Linear Unit: ReLU) ที่ช่วยลดจำนวนตัวแปรในโครงข่ายซึ่งส่งผลทำให้โครงข่ายเรียนรู้ได้เร็วและมีประสิทธิภาพมากยิ่งขึ้น โดยการเปลี่ยนค่าลบจากผลลัพธ์ให้เป็น 0 และคงค่าที่เป็นบวกไว้ ดังรูปที่ 2.17 และสมการที่ 2.3




รูปที่ 2.17 กราฟแสดงสมการฟังก์ชันเรกติไฟด์เชิงเส้น

$$R(z) = \begin{cases} 0 & \text{if } z \leq 0 \\ z & \text{if } z > 0 \end{cases} \quad (2.3)$$

#### 4) ชั้นพูลลิ่ง (Pooling layer)

โครงข่ายประสาทเทียมแบบคอนโวลูชันมักใช้ชั้นพูลลิ่ง (Pooling Layer) หลังจากชั้นคอนโวลูชันทันที เพื่อลดขนาดของรูปภาพซึ่งเป็นการลดความกว้าง (Width) และความสูง (Height) เท่านั้น แต่ความลึก (Depth) ยังคงค่าไว้เหมือนเดิม เพื่อช่วยลดจำนวนตัวแปร (Parameters) และลดการคำนวณค่าน้ำหนัก (Wight) และค่าอคติ (Bias) ในแต่ละเซลล์ประสาทลงได้ นอกจากนี้ ตัวแปรที่มีจำนวนลดน้อยลงยังช่วยหลีกเลี่ยงการเกิดเหตุการณ์ที่แบบจำลองเรียนรู้ข้อมูลฝึกฝนได้ดีเกินไป (Overfitting) ในระหว่างกระบวนการฝึกฝน (Training) แต่มีข้อผิดพลาดอย่างมากในระหว่างกระบวนการทดสอบ (Testing) รูปแบบที่พบบ่อยในการทำพูลลิ่ง คือ การเลือกจุดที่มีค่ามากที่สุด (Max Pooling) (Giancarlo, 2016, pp. 130-131)

ตัวอย่างการทำพูลลิ่งโดยวิธีการเลือกจุดที่มีค่ามากที่สุด (Max Pooling) เมื่อใช้ตัวกรอง (Filter) ขนาด  $2 \times 2$  และการเลื่อนข้าม (Stride) จำนวน 2 จุด แสดงดังรูปที่ 2.18



รูปที่ 2.18 การทำพูลลิ่งโดยวิธีการเลือกจุดที่มีค่ามากที่สุด

การคำนวณหาขนาดของภาพผลลัพธ์เมื่อผ่านการพลูลิ่งโดยวิธีการเลือกจุดที่มีค่ามากที่สุด (Max Pooling) เมื่อภาพนำเข้ามีขนาด ความกว้าง x ความสูง x ความลึก แทนด้วย  $w_1 \times h_1 \times d_1$  ตามลำดับ ขนาดของตัวกรอง (Filter) คือ  $f \times f$  และการเลื่อนข้าม (Stride) คือ  $s$  ดังนั้น ภาพผลลัพธ์มีขนาด เท่ากับ ความกว้าง x ความสูง x ความลึก แทนด้วย  $w_2 \times h_2 \times d_2$  ดังสมการที่ 2.4, 2.5 และ 2.6

$$w_2 = ((w_1 - f) / s) + 1 \quad (2.4)$$

$$h_2 = ((h_1 - f) / s) + 1 \quad (2.5)$$

$$d_2 = d_1 \quad (2.6)$$

### 5) ชั้นการเชื่อมต่อแบบโยงไปข้างหน้าแบบทั่วถึง (Fully Connected Layer)

ในชั้นนี้แต่ละเซลล์ประสาท (Neuron) จะรับข้อมูลนำเข้าจากทุก ๆ เซลล์ประสาท ในชั้นคอนโวลูชันมาเชื่อมต่อทุก ๆ เซลล์ประสาท ในชั้นซ่อน (Hidden Layers) และชั้นเอาต์พุต (Output Layer) ในชั้นซ่อนอาจมีมากกว่า 1 ชั้น จำนวนชั้นและจำนวนโหนดที่อยู่ในชั้นซ่อนขึ้นอยู่กับข้อกำหนดของผู้ออกแบบ โครงข่าย ซึ่งต้องทำการทดลองหลาย ๆ แบบขึ้นอยู่กับความเหมาะสม โหนดที่อยู่ในชั้นเอาต์พุต จำนวนโหนดเท่ากับจำนวนกลุ่มหรือจำนวนประเภทของข้อมูลที่ต้องการจำแนก โดยโครงข่ายประสาทเทียมจะมีเส้นเชื่อมจากทุก ๆ โหนดในชั้นซ่อนไปยังทุก ๆ โหนดในชั้นเอาต์พุต เส้นเชื่อมแต่ละเส้นมีค่าน้ำหนัก (Weight) ที่ได้จากการปรับค่าของกระบวนการเรียนรู้เชิงลึกเพื่อการจำแนกข้อมูลภาพ

## 2.4 แนวคิดเกี่ยวกับการตรวจจับวัตถุโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า

การตรวจจับวัตถุโดยทั่วไปใช้ตัวตรวจจับวัตถุ (Object Detector) ด้วยวิธีการเปลี่ยนแปลงขนาดและตำแหน่ง เพื่อเสนอขอบเขตพื้นที่ (Region Proposals) ที่น่าจะมีวัตถุอยู่ภายในภาพ จากนั้นจึงจำแนกประเภท (Classifier) ของวัตถุนั้น ๆ หลายปีที่ผ่านมาประสิทธิภาพของตัวแบบที่ผ่านการเรียนรู้มาแล้วล่วงหน้าบนชุดข้อมูลมาตรฐานขนาดใหญ่ เช่น ชุดข้อมูลของโคโค (COCO Dataset) พบว่า มีความเร็วและความแม่นยำสูงเหมาะสำหรับนำมาใช้ในงานตรวจจับวัตถุอื่น ๆ (Huang et. al., 2017; Pkuzc, 2019)

โครงสร้างของตัวแบบดังกล่าว ประกอบด้วย 2 ส่วน ได้แก่ ตัวตรวจจับวัตถุ (Object Detector) และตัวสกัดคุณลักษณะ (Feature Extractor) สำหรับงานวิจัยนี้ใช้โครงสร้างของตัวตรวจจับวัตถุ 2 รูปแบบ และโครงสร้างของตัวสกัดคุณลักษณะ 5 รูปแบบ ดังนี้

### 2.4.1 โครงสร้างของตัวตรวจจับวัตถุ

โครงสร้างของตัวตรวจจับวัตถุถูกออกแบบเพื่อเสนอขอบเขตพื้นที่ (Region Proposals) ที่น่าจะมีวัตถุอยู่ภายในภาพ โดยใช้กรอบสี่เหลี่ยมหลากหลายขนาดที่ครอบคลุมคุณลักษณะของรูปภาพบนตำแหน่งต่าง ๆ ในภาพ ในงานวิจัยนี้ เปรียบเทียบประสิทธิภาพของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด (Mean Average Precision: mAP) จำนวน 5 ลำดับแรก เมื่อทดสอบบนชุดข้อมูลรูปภาพของโคโค ได้แก่ 1) ตัวแบบ Faster R-CNN NAS 2) ตัวแบบ Faster R-CNN Inception\_ResNetV2 Atrous 3) ตัวแบบ SSD ResNet50 FPN 4) ตัวแบบ SSD MobileNetV1 FPN และ 5) ตัวแบบ Faster R-CNN ResNet101 เพื่อเลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่เหมาะสมที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดเมื่อทดสอบบนชุดข้อมูลสภาพพื้นผิวถนนที่ผิดปกติ ดังนั้น โครงสร้างของตัวตรวจจับวัตถุที่ใช้ในงานวิจัยนี้จึงมี 2 โครงสร้าง ได้แก่ โครงสร้างแบบ Faster R-CNN และโครงสร้างแบบ SSD โดยมีรายละเอียด ดังนี้

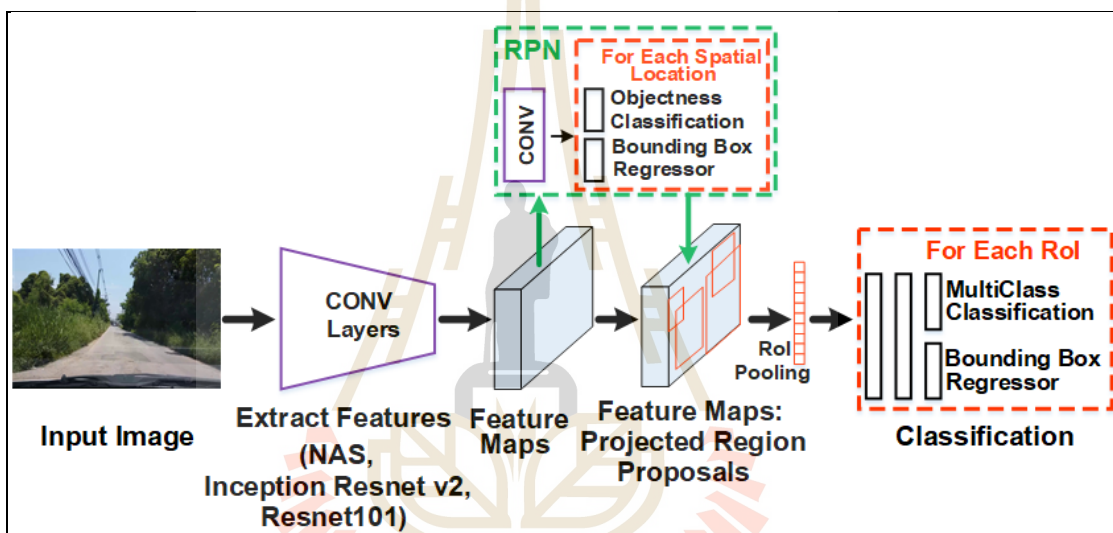
#### 1) โครงสร้างแบบ Faster R-CNN

Ren และคณะ (2017) เสนอโครงสร้างแบบ Faster R-CNN ในปี ค.ศ. 2017 ประกอบด้วย 2 ขั้นตอน ดังนี้

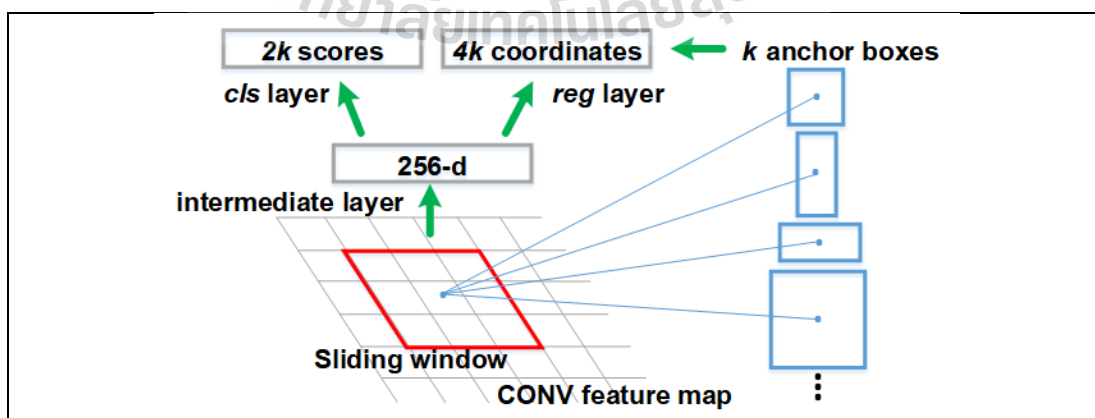
**ขั้นตอนแรก** เป็นการเสนอขอบเขตพื้นที่ที่น่าจะมีวัตถุภายในภาพโดยใช้โครงข่ายเสนอพื้นที่ ที่เรียกว่า Region Proposal Network (RPN) จากรูปที่ 2.19 เมื่อรูปภาพผ่านชั้นคอนโวลูชัน (Convolution Layers) ในขั้นตอนนี้จะทำการสกัดคุณลักษณะที่สำคัญในรูปภาพ โดยสามารถเลือกใช้โครงสร้างของตัวสกัดคุณลักษณะรูปแบบต่าง ๆ ที่มีโครงสร้างของการถ่ายโอนการเรียนรู้ภายในได้ เช่น NAS, Inception Resnet v2, และ Resnet101 ผลลัพธ์ที่ผ่านการทำ



คอนโวลูชันในตำแหน่งต่าง ๆ ของพื้นที่ส่วนย่อยในรูปภาพ เรียกว่า แผนภาพคุณลักษณะ (Feature Map) จากนั้นจึงส่งต่อไปยัง RPN เพื่อหาขอบเขตพื้นที่ที่น่าจะมีวัตถุในภาพ ซึ่งต้องผ่านชั้นคอนโวลูชันเพิ่มเติม เพื่อคำนวณโอกาสค้นพบวัตถุในแต่ละพื้นที่ย่อยเล็ก ๆ รวมถึงเสนอกรอบล้อมวัตถุมาให้ด้วย (Bounding Box) สำหรับขอบเขตพื้นที่ของ RPN ที่นำมาพิจารณา คือ กรอบสี่เหลี่ยมหลากหลายขนาดเรียกว่า แอจเคิล (Anchor Box) ซึ่งครอบคลุม Feature Map ในตำแหน่งต่าง ๆ ดังรูปที่ 2.20 จากจำนวนแอจเคิลทั้งหมดของ RPN จะทำการหาขอบเขตที่น่าจะเป็นวัตถุมากที่สุดมาจำนวนหนึ่ง เพื่อเสนอขอบเขตพื้นที่ที่น่าสนใจสุดท้ายหรืออาร์โอไอ (Region of Interest: RoI) จากนั้นจึงส่งไปขั้นตอนที่สอง



รูปที่ 2.19 โครงสร้างแบบ Faster R-CNN ปรับปรุงจาก Ren และคณะ (2017) และ Liu และคณะ (2018)

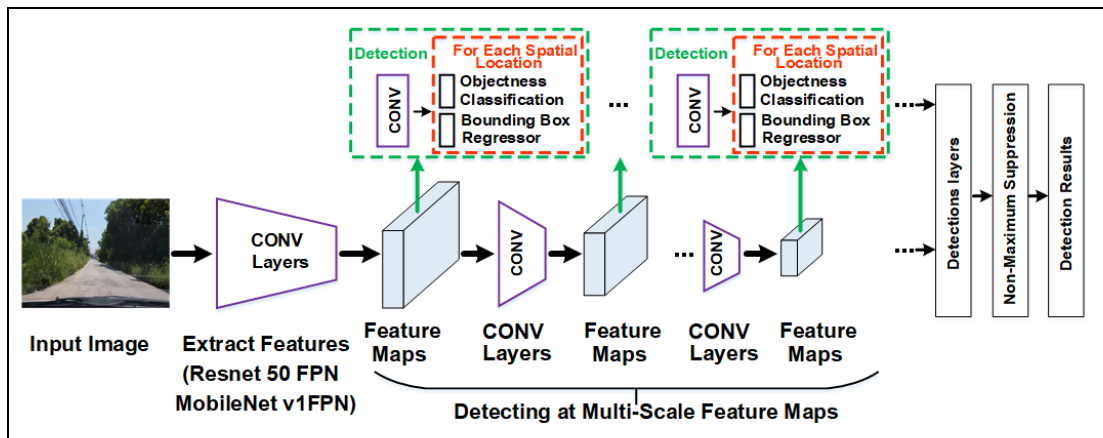


รูปที่ 2.20 โครงข่ายเสนอพื้นที่ (Region Proposal Network) ปรับปรุงจาก Ren และคณะ (2017)

**ขั้นตอนที่สอง** ประกอบด้วยขั้นตอนอาร์โอไอพูลลิ่ง (RoI Pooling) และการจำแนก (Classification) ดังรูปที่ 2.19 ขั้นตอนการทำ RoI Pooling เป็นการนำขอบเขตพื้นที่ที่น่าสนใจ (RoI) จาก Feature Map ที่มีขนาดต่าง ๆ มาลดขนาดลง (Down Sample) ให้ได้ค่าคุณลักษณะที่มีขนาดคงที่ (Fixed Size Feature Vector) โดยใช้ฟังก์ชันหาค่าสูงสุดในการคำนวณที่เรียกว่า Max Pooling แล้วส่งต่อไปยังโครงข่ายชั้นเชื่อมโยงแบบทั่วถึงถัดไป (Fully Connected Layer) ส่วนสุดท้ายเป็นส่วนการจำแนกประเภท (Multiclass Classification) เพื่อทำการจำแนกว่าวัตถุนั้นจัดอยู่ในประเภทอะไรและส่วนการทำนายขอบเขตของวัตถุจากพื้นที่ที่ถูกเสนอมา (Bounding Box Regressor) เพื่อคำนวณหาตำแหน่งของวัตถุให้แม่นยำมากยิ่งขึ้น

## 2) โครงสร้างแบบ SSD

Liu และคณะ (2016) เสนอโครงสร้างแบบ SSD ในปี ค.ศ. 2016 เพื่อตรวจจับวัตถุให้เร็วขึ้นโดยไม่สูญเสียความแม่นยำในการตรวจจับวัตถุมากเกินไป จากรูปที่ 2.21 เมื่อรูปภาพผ่านชั้นคอนโวลูชันซึ่งเป็นการสกัดคุณลักษณะที่สำคัญในรูปภาพ โดยสามารถเลือกใช้โครงสร้างของตัวสกัดคุณลักษณะรูปแบบต่าง ๆ ได้ เช่น Resnet 50 FPN และ MobileNet v1 FPN เป็นต้น จากนั้นจึงส่งผลลัพธ์ไปยังชั้นคอนโวลูชันที่มีขนาดต่าง ๆ (Multiple CONV Layers) ในแต่ละชั้นคอนโวลูชันจะทำการสกัดคุณลักษณะที่สำคัญในรูปภาพพร้อมทั้งจำแนกประเภทของวัตถุนั้นและทำนายขอบเขตของวัตถุมาให้อีกด้วย ซึ่งผลลัพธ์ที่ได้จากชั้นคอนโวลูชันนี้คือ Feature Map ที่มีขนาดต่าง ๆ (Multi Scale Feature Maps) วิธีนี้ช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุอย่างมีนัยสำคัญและเหมาะสมกับภาพที่มีวัตถุขนาด (Scale) ที่แตกต่างกันมากได้ จากนั้นจึงส่งผลลัพธ์ของ Feature Map ที่มีขนาดต่าง ๆ (ขอบเขตของวัตถุที่มีขนาดต่าง ๆ) และผลการจำแนกประเภทของวัตถุนั้น (ค่าความน่าจะเป็นของวัตถุนั้น ๆ) ไปยังชั้นตรวจจับ (Detections Layers) เพื่อเลือกขอบเขตของวัตถุที่มีหลากหลายขนาดให้เหลือเพียงขอบเขตของวัตถุที่ดีที่สุดออกมา โดยใช้ขั้นตอนวิธีที่ชื่อว่า Non-Maximum Suppression (NMS) ซึ่งเป็นการพิจารณาจากค่าความน่าจะเป็นของวัตถุนั้น ๆ ร่วมกับค่าไอยู (Intersection Over Union: IoU) กับทุกคู่ของคำตอบ เพื่อเลือกผลลัพธ์ที่ดีที่สุดออกมา นั่นคือ พิจารณาเลือกค่าความน่าจะเป็นของวัตถุนั้น ๆ ร่วมกับค่าไอยูของกลุ่มคำตอบที่มากที่สุดเป็นผลลัพธ์สุดท้ายจากการตรวจจับวัตถุ



รูปที่ 2.21 โครงข่ายแบบ SSD ปรับปรุงจาก Liu และคณะ (2016, 2018)

#### 2.4.2 โครงสร้างของตัวสกัดคุณลักษณะ

โครงสร้างของตัวสกัดคุณลักษณะถูกออกแบบมาเพื่อสกัดคุณลักษณะที่สำคัญในรูปภาพ โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อส่งผลลัพธ์จากการสกัดคุณลักษณะที่สำคัญไปจำแนกประเภทต่อไป ในงานวิจัยนี้ เปรียบเทียบประสิทธิภาพของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด (Mean Average Precision: mAP) จำนวน 5 ลำดับแรก เมื่อทดสอบบนชุดข้อมูลรูปภาพของโคโค (COCO Dataset) ได้แก่ 1) ตัวแบบ Faster R-CNN NAS 2) ตัวแบบ Faster R-CNN Inception\_ResNetV2 Atrous 3) ตัวแบบ SSD ResNet50 FPN 4) ตัวแบบ SSD MobileNetV1 FPN และ 5) ตัวแบบ Faster R-CNN ResNet101 เพื่อเลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่เหมาะสมที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดเมื่อทดสอบบนชุดข้อมูลสภาพพื้นผิวถนนที่ผิดปกติ ดังนั้น โครงสร้างของตัวสกัดคุณลักษณะที่ใช้ในงานวิจัยนี้จึงมี 5 โครงสร้าง ได้แก่ 1) โครงสร้างแบบ NASNet 2) โครงสร้างแบบ Inception Resnet v2 3) โครงสร้างแบบ Resnet 50 FPN 4) โครงสร้างแบบ MobileNet v1 FPN และ 5) โครงสร้างแบบ Resnet101 โดยมีรายละเอียด ดังนี้

##### 1) โครงสร้างแบบ NASNet

Zoph และคณะ (2018) ทีมพัฒนาของ Google เสนอ โครงสร้างแบบ NASNet (Neural Architecture Search Network) ที่เรียกว่า NASNet-A เป็นโครงข่ายโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ใช้สกัดคุณลักษณะสำคัญของรูปภาพ การนำตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่มีโครงสร้างแบบ Faster R-CNN NAS มาใช้ในงานตรวจจับวัตถุบนชุดข้อมูลของโคโค พบว่าได้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) สูงถึง 43% (Pkulzc, 2019)

## 2) โครงสร้างแบบ Inception Resnet v2

Szegedy และคณะ (2017) ทีมพัฒนาของ Microsoft Research เสนอโครงสร้างแบบ Inception Resnet v2 ที่รวมโครงสร้างการเชื่อมต่อแบบ Residual Network (Resnet) ของ He และคณะ (2016) และส่วนของ Inception V4 units (Szegedy et. al., 2017) เข้าไว้ด้วยกัน เพื่อเพิ่มประสิทธิภาพและลดเวลาการคำนวณ การนำตัวแบบที่ถูกฝึกมาล่วงหน้าที่มีโครงสร้างแบบ Faster R-CNN Inception ResNetV2 Atrous มาใช้ตรวจจับวัตถุบนชุดข้อมูลของโคโค พบว่า ได้ค่า mAP สูงถึง 37% (Pkulzc, 2019)

## 3) โครงสร้างแบบ Resnet 50 FPN

Lin และคณะ (2017a) ทีมพัฒนาของ Facebook AI Research เสนอโครงสร้างแบบ Resnet 50 FPN ที่ประกอบด้วยโครงสร้างแบบ Residual Network (Resnet) จำนวน 50 ชั้นที่ถูกพัฒนาโดย He และคณะ (2016) และเพิ่มชั้น Feature Pyramid Network (FPN) (Lin et. al., 2017b) ซึ่งเป็นการลดขนาดและเพิ่มขนาดของรูปภาพสำหรับสกัดคุณลักษณะสำคัญของรูปภาพ เพื่อเพิ่มความแม่นยำในการรู้จำและการจำแนกข้อมูล การนำตัวแบบที่ผ่านการฝึกมาล่วงหน้าที่มีโครงสร้างแบบ SSD Resnet 50 FPN มาใช้ตรวจจับวัตถุบนชุดข้อมูลของโคโค พบว่า ได้ค่า mAP สูงถึง 35% (Pkulzc, 2019)

## 4) โครงสร้างแบบ MobileNet v1 FPN

Howard และคณะ (2017) ทีมพัฒนาของ Google เสนอโครงสร้างแบบ MobileNet v1 ที่ถูกออกแบบมาเพื่อลดการคำนวณและลดขนาดของตัวแบบให้เหมาะสมกับการใช้งานบนโทรศัพท์มือถือ และเพิ่มชั้น Feature Pyramid Network (FPN) (Lin et. al., 2017b) เพื่อลดขนาดและเพิ่มขนาดของรูปภาพสำหรับสกัดคุณลักษณะสำคัญของรูปภาพ การนำตัวแบบที่ถูกฝึกมาล่วงหน้าที่มีโครงสร้างแบบ MobileNet v1 FPN มาใช้ตรวจจับวัตถุบนชุดข้อมูลของโคโค พบว่า ได้ค่า mAP สูงถึง 32% (Pkulzc, 2019)

## 5) โครงสร้างแบบ Resnet101

He และคณะ (2016) ทีมพัฒนาของ Microsoft Research เสนอโครงสร้างแบบ Resnet101 ซึ่งมีจำนวน 101 ชั้น เพื่อสกัดคุณลักษณะสำคัญของรูปภาพ การนำตัวแบบที่ถูกฝึกมาล่วงหน้าที่มีโครงสร้างแบบ Resnet101 มาใช้ตรวจจับวัตถุบนชุดข้อมูลของโคโค พบว่า ได้ค่า mAP สูงถึง 32% (Pkulzc, 2019)

## 2.5 งานวิจัยที่เกี่ยวข้องในการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนโทรศัพท์มือถือ

งานวิจัยที่เกี่ยวข้องกับการออกแบบและพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ สำหรับงานวิจัยนี้แบ่งออกเป็น 3 ส่วน คือ 1) งานวิจัยที่ใช้ข้อมูลจากเครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) 2) งานวิจัยที่ใช้ข้อมูลรูปภาพจากกล้อง (Camera) และ 3) งานวิจัยที่ใช้เครื่องรับรู้หลายรูปแบบ (Multimodal Sensor) จากเครื่องรับรู้มาตรความเร่งร่วมกับรูปภาพจากกล้อง มีรายละเอียดดังนี้

### 2.5.1 งานวิจัยที่ใช้ข้อมูลจากเครื่องรับรู้มาตรความเร่ง

การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ข้อมูลจากเครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) ในโทรศัพท์มือถือที่ถูกติดตั้งไว้ในรถและส่วนต่าง ๆ ของรถ พบว่างานวิจัยที่ผ่านมาใช้ข้อมูลจากเครื่องรับรู้มาตรความเร่งเพื่อตรวจจับสภาพพื้นผิวถนนประเภท หลุมบ่อ (Pothole) เนินชะลอความเร็ว (Bump) รอยต่อถนน (Gaps) ทางข้ามรางรถไฟ ฝาท่อระบายน้ำ และผิวขรุขระเป็นคลื่นคล้ายลูกกระพอน (Corrugation) ดังแสดงในตารางที่ 2.4

ตารางที่ 2.4 สภาพพื้นผิวถนนที่ผิดปกติที่ถูกตรวจจับโดยใช้ข้อมูลจากเครื่องรับรู้มาตรความเร่ง

ลักษณะสภาพพื้นผิวถนน	งานวิจัย
หลุมบ่อ (Pothole)	Eriksson et al., 2008; Tai, Chan, and Hsu, 2010; Mednis, Strazdins, Zviedris, Kanonirs, and Selavo, 2011; Kulkarni, Mhalgi, Gurmani, and Giri, 2014; Wang, Chen, Cheng, Lin, and Lo, 2015.
รอยต่อถนน (Gaps)	Mednis et al., 2011.
เนินชะลอความเร็ว (Speed Bump)	Eriksson et al., 2008; Astarita et al, 2012.
รอยต่อของถนน ทางข้ามรางรถไฟ ฝาท่อระบายน้ำ	Eriksson et al., 2008.
ผิวขรุขระเป็นคลื่นคล้ายลูกกระพอน	Tai et al., 2010; Chen et al., 2011; Douangphachanh and Oneyama, 2013.

เมื่อวิเคราะห์ตามระดับความแม่นยำ (Accuracy) ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยแบ่งออกเป็น 6 ระดับ ได้แก่ ต่ำกว่า 70%, 70 – 75%, 76 – 80%, 81 – 85%, 86 – 90%,




และมากกว่า 90% พบว่า ผลการทดสอบประสิทธิภาพของตัวแบบ ส่วนใหญ่มีความแม่นยำมากกว่า 90% ดังแสดงในตารางที่ 2.5

ตารางที่ 2.5 ระดับความแม่นยำในการตรวจจับโดยใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่ง

ระดับความแม่นยำ	งานวิจัย
ต่ำกว่า 70%	-
70 – 75%	Tai, Chan and Hsu, 2010.
76 – 80%	-
81 – 85%	-
86 – 90%	Eriksson et al., 2008; Mednis et al., 2011.
มากกว่า 90%	Astarita et al, 2012; Kulkarni et al., 2014; Wang et al., 2015; Predic and Stojanovic, 2015.

เมื่อวิเคราะห์ตามขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับ พบว่า มีการใช้ขั้นตอนวิธีและเทคนิคที่คล้ายกันและแตกต่างกัน แต่มีวัตถุประสงค์เดียวกัน คือ เพิ่มความแม่นยำในการตรวจจับตามลักษณะสภาพพื้นผิวถนนที่ใช้ศึกษา ขั้นตอนวิธีการกำหนดค่าเทรชโฮล (Threshold-based Method) และการเรียนรู้ของเครื่อง (Machine Learning-based Method) ประกอบด้วย 4 ขั้นตอน ดังนี้ 1) การนำเข้าข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน 2) การเตรียมข้อมูลก่อนประมวลผล (Preprocessing) 3) การสกัดคุณลักษณะ (Features Extraction) และ 4) การจำแนกประเภทข้อมูล (Classification) โดยการกำหนดค่าตรวจสอบหรือค่าเทรชโฮล เพื่อระบุลักษณะสภาพพื้นผิวถนนที่ผิดปกติและการใช้วิธีการเรียนรู้ของเครื่อง เพื่อจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ดังแสดงในรูปที่ 2.22



รูปที่ 2.22 ขั้นตอนการตรวจจับสภาพพื้นผิวถนนโดยกำหนดค่าเทรชโฮลและการเรียนรู้ของเครื่อง

ขั้นตอนการตรวจจับสภาพพื้นผิวถนน โดยกำหนดค่าเทรส โสไลด์และการเรียนรู้ของเครื่อง มีรายละเอียดดังนี้

### 1) ขั้นตอนการนำเข้าข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

เป็นขั้นตอนการรับข้อมูลจากอุปกรณ์เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์สมาร์ทโฟนที่ถูกติดตั้งไว้ในรถและส่วนต่าง ๆ ของรถ

### 2) ขั้นตอนการเตรียมข้อมูลก่อนการประมวลผล (Preprocessing)

เป็นขั้นตอนการนำข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนทั้ง 3 แกน มากำจัดสัญญาณรบกวนเพื่อปรับปรุงคุณภาพข้อมูลให้สามารถนำมาวิเคราะห์รูปแบบของสัญญาณตามลักษณะสภาพพื้นผิวถนนที่ผิดปกติให้ถูกต้องมากขึ้น โดยใช้ตัวกรองต่าง ๆ (Filters) เช่น งานวิจัยของ Eriksson และคณะ (2008, pp. 32-33) ได้เสนอระบบ Pothole Patrol เพื่อตรวจจับสภาพพื้นผิวถนนโดยใช้เครื่องรับรู้มาตรฐานความเร่งในโทรศัพท์สมาร์ทโฟนที่ถูกติดตั้งไว้หน้ารถ โดยหน้าจอโทรศัพท์ขึ้น ส่วนหัวหันไปในทิศทางรถแทนค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Y ด้านข้างของโทรศัพท์แทนค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X และค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X เป็นแกนที่พุ่งขึ้นมาจากหน้าจอโทรศัพท์ซึ่งตั้งฉากกับตัวรถ ขั้นตอนการเตรียมข้อมูลก่อนการประมวลผลในงานวิจัยนี้ใช้ตัวกรอง 2 แบบ ได้แก่ 1) ตัวกรองความเร็วต่ำ (Low Speed Filter) ใช้เพื่อตรวจสอบความเร็วรถที่ลดต่ำลงเมื่อรถวิ่งอย่างช้า ๆ หรือในขณะที่จอดและเปิดปิดประตูรถ ซึ่งอาจเกิดแรงสั่นสะเทือนที่ทำให้เครื่องรับรู้มาตรฐานความเร่งมีค่าสูงคล้ายกับลักษณะสภาพพื้นผิวถนนที่ผิดปกติซึ่งข้อมูลที่อยู่ในช่วงที่กำหนดนี้ไม่ถูกนำมาวิเคราะห์ลักษณะสภาพพื้นผิวถนน 2) ตัวกรองค่าความถี่สูง (High-pass Filter) เป็นตัวกรองที่เลือกเฉพาะความถี่สูงเท่านั้นซึ่งนำสัญญาณข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของแกน X และ Z ที่มีความถี่ต่ำออก ซึ่งเกิดขึ้นในขณะที่เลี้ยวรถ การเปลี่ยนทิศทาง การเบรกและการเปลี่ยนตำแหน่งของการวางเครื่องรับรู้มาตรฐานความเร่งของโทรศัพท์สมาร์ทโฟน 3) ตัวกรองค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z ที่สูงสุด (Z-peak Filter) เป็นตัวกรองที่เลือกเฉพาะค่าอัตราเร่งของแรงสั่นสะเทือนที่สูงสุดในแต่ละเหตุการณ์เมื่อขับรถผ่านตามลักษณะสภาพพื้นผิวถนนที่ผิดปกติ 4) ตัวกรองอัตราส่วนความสัมพันธ์ระหว่างแกน X และแกน Z (XZ Ratio Filter) เป็นตัวกรองที่ใช้ค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X ที่สามารถระบุสภาพพื้นผิวถนนที่ผิดปกติที่ครอบคลุม ความกว้างของถนนและส่งผลต่อค่าอัตราเร่งของแรงสั่นสะเทือนของล้อรถทั้ง 2 ด้านอย่างเท่าเทียมกัน เช่น ทางข้ามรถไฟ (Railway Crossings) เนินชะลอความเร็ว (Speed Bumps) และรอยต่อของถนน (Expansion Joints) ในกรณีของหลุมบ่อแรงสั่นสะเทือนจะส่งผลต่อด้านใดด้านหนึ่งของล้อรถเท่านั้นซึ่งใช้ค่าอัตราเร่งของแรงสั่นสะเทือนขนาดใหญ่ในแนวแกน Z ได้ (Z-peak Axis) และควรมีความสัมพันธ์อย่างมีนัยสำคัญกับค่าอัตราเร่งของแรงสั่นสะเทือนใน

แนวแกน X ด้วย และ 5) ตัวกรองความเร็วและอัตราเร่งแนวแกน Z (Speed and Z Ratio Filter) ในขณะที่รถวิ่งด้วยความเร็วสูงแม้ว่าลักษณะสภาพพื้นผิวถนนที่ผิดปกติจะมีขนาดเล็ก จะทำให้เกิดลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนมีค่าสูงได้ ดังนั้น ตัวกรองนี้จะลบข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนขนาดใหญ่ของแนวแกน Z (Z-peak Axis) ในขณะที่รถวิ่งด้วยความเร็วสูง

ขั้นตอนการเตรียมข้อมูลก่อนการประมวลผลในงานวิจัยของ Astarita และคณะ (2012) เสนอการตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว (Bumps) ใช้ตัวกรอง 3 แบบ ได้แก่ ตัวกรองความถี่ต่ำ (Low Frequency Filter: LFF) ตัวกรองความเร็วต่ำ (Speed Filter: SF) ตัวกรองสัญญาณจุดสูงสุดขนาดเล็ก (Small Peaks Filter: SPF) โดยกำหนดค่าตรวจสอบหรือค่าเทรชโฮลต่ำสุดและสูงสุดของแต่ละตัวกรอง หากค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z อยู่ในช่วงที่กำหนด ให้แทนค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z นั้นเป็นค่าอัตราเร่งของแรงสั่นสะเทือนเฉลี่ยของแนวแกน Z (Mean Acceleration Value)

ยิ่งไปกว่านั้นงานวิจัยของ Wang และคณะ (2015, pp. 2-5) ใช้ขั้นตอนวิธีการเตรียมข้อมูลก่อนการประมวลผล โดยคำนวณค่าอัตราเร่งของแรงสั่นสะเทือนทั้ง 3 แกนตามมุมการวางโทรศัพท์สมาร์ทโฟน เพื่อเสนอวิธีการตรวจจับหลุมบ่อให้มีความแม่นยำมากขึ้น ส่วนงานวิจัยของ Chen และคณะ (2011) ใช้ตัวกรองสัญญาณ โดยจะไม่นำข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลการระบุตำแหน่ง (GPS) มาใช้ในการสกัดคุณลักษณะเมื่อมีการส่งข้อมูลผิดพลาดหรือไม่ต่อเนื่อง และงานวิจัยของ Douangphachanh และ Oneyama (2013) ได้ศึกษาความสัมพันธ์ของแรงสั่นสะเทือนจากค่าอัตราเร่งของแรงสั่นสะเทือน (Acceleration Vibration) เพื่อประเมินสภาพถนนขรุขระโดยใช้ตัวกรองความเร็วที่ต่ำกว่า 25 กิโลเมตร/ชั่วโมง

### 3) ขั้นตอนการสกัดคุณลักษณะ (Features Extraction)

เป็นขั้นตอนการนำข้อมูลที่ผ่านปรับปรุงคุณภาพของสัญญาณค่าอัตราเร่งของแรงสั่นสะเทือนมาสกัดคุณลักษณะเด่นที่สำคัญ เพื่อกำหนดค่าตรวจสอบหรือค่าเทรชโฮลสำหรับระบุลักษณะสภาพพื้นผิวถนนที่ผิดปกติและการใช้วิธีการเรียนรู้ของเครื่องสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ เช่น งานวิจัยของ Mednis และคณะ (2011, p. 3) ใช้ขั้นตอนวิธีการสกัดคุณลักษณะเพื่อตรวจจับหลุมบ่อคล้ายกับระบบ Pothole Patrol ของ Eriksson และคณะ (2008, p. 32) และระบบ Nericell ของ Mohan และคณะ (2008, p. 331) ที่สกัดคุณลักษณะโดยใช้ตัวกรองค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z ที่สูงสุด (Z-peak Filter) มากำหนดค่าตรวจสอบหรือค่าเทรชโฮล หากค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z ที่สูงสุดเกินค่าเทรชโฮลที่กำหนด ให้ระบุลักษณะสภาพพื้นผิวถนนที่ผิดปกตินั้นเป็นหลุมบ่อขนาดใหญ่หรือกลุ่มของหลุมบ่อ โดยเรียกขั้นตอนวิธีการสกัดคุณลักษณะนี้ว่า Z-THRESH นอกจากนี้ยังเพิ่มขั้นตอนวิธีในการสกัดคุณลักษณะอีก 3 ขั้นตอนวิธีเพื่อตรวจจับหลุมบ่อ ได้แก่ ขั้นตอนวิธีการสกัดคุณลักษณะที่เรียกว่า

Z-DIFF เป็นขั้นตอนวิธีที่ใช้ตรวจสอบการเปลี่ยนแปลงค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z ที่เกิดขึ้นอย่างรวดเร็วด้วยการกำหนดค่าเทรสโสดที่แตกต่างกันสองค่า ขั้นตอนวิธีการสกัดคุณลักษณะที่เรียกว่า STDEV(Z) เป็นขั้นตอนวิธีในการสกัดคุณลักษณะส่วนเบี่ยงเบนมาตรฐานของค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน Z และขั้นตอนวิธีในการสกัดคุณลักษณะที่เรียกว่า G-ZERO เพื่อตรวจสอบค่าอัตราเร่งของแรงสั่นสะเทือนของทั้ง 3 แกนที่เข้าใกล้ค่า 0

ยิ่งไปกว่านั้นงานวิจัยของ Wang และคณะ (2015, pp. 2-5) ใช้ขั้นตอนวิธีของ Mednis และคณะ (2011, p.3) เพื่อสกัดคุณลักษณะของสัญญาณค่าอัตราเร่งของแรงสั่นสะเทือน แต่เพิ่มการคำนวณค่าอัตราเร่งของแรงสั่นสะเทือนทั้ง 3 แกนตามมุมมองการวางโทรศัพท์มือถือเพื่อเสนอวิธีการตรวจจับหลุมบ่อให้มีความแม่นยำมากขึ้น

งานวิจัยของ Chen และคณะ (2011) สกัดคุณลักษณะจากค่าอัตราเร่งของแรงสั่นสะเทือนของทั้ง 3 แกน เพื่อนำมาวิเคราะห์ค่าความหนาแน่นสเปกตรัม (Power Spectral Density: PSD) ร่วมกับวิธีฟูเรียร์ทรานสฟอร์ม (Fourier Transform) และใช้ค่าดัชนีความขรุขระของพื้นผิวถนนสากล (International Roughness Index: IRI) มาคำนวณระดับความขรุขระของพื้นผิวถนนเพื่อจำแนกสภาพถนนออกเป็น 4 ระดับ ได้แก่ ดีมาก ดี มีคุณภาพ ไม่มีคุณภาพ ซึ่งคล้ายกับงานวิจัยของ Douangphachanh และ Oneyama (2013)

#### 4) การจำแนกประเภทข้อมูล (Classification)

เป็นการนำคุณลักษณะเด่นที่สำคัญมากำหนดค่าตรวจสอบหรือค่าเทรสโสดหากค่าเทรสโสดอยู่ในช่วงที่กำหนดหรือเกินค่าที่กำหนดให้ระบุลักษณะสภาพพื้นผิวถนนเป็นประเภทนั้น เช่น งานวิจัยของ Wang และคณะ (2015) และงานวิจัยของ Mednis และคณะ (2011) ซึ่งแบ่งประเภทของหลุมบ่อเป็นประเภทย่อย ๆ ได้แก่ หลุมบ่อขนาดใหญ่ หลุมบ่อขนาดเล็กและกลุ่มของหลุมบ่อ ยิ่งไปกว่านั้นการกำหนดค่าเทรสโสดจากข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อตรวจจับลักษณะสภาพพื้นผิวถนนประเภทหลุมบ่อร่วมกับสภาพพื้นผิวถนนประเภทอื่น ๆ ได้แก่ ถนนราบเรียบ รอยต่อของถนน ทางข้ามรางรถไฟ ฝาท่อระบายน้ำ ยางชะลอความเร็ว พบในงานวิจัยของ Eriksson และคณะ (2008) รอยแตก หลุมท่อระบายน้ำ พบในงานวิจัยของ Mednis และคณะ (2011) และตรวจจับลักษณะสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว พบในงานวิจัยของ Astarita และคณะ (2012) นอกจากนี้การใช้ขั้นตอนวิธีการกำหนดค่าเทรสโสดเพื่อตรวจจับลักษณะสภาพพื้นผิวถนนประเภทความขรุขระของพื้นผิวถนน พบในงานวิจัยของ Chen และคณะ (2011) และงานวิจัยของ Douangphachanh และ Oneyama (2013)

นอกจากนี้ ยังมีการใช้ขั้นตอนวิธีการเรียนรู้ของเครื่องมาจำแนกลักษณะสภาพพื้นผิวถนนที่ผิดปกติประเภทหลุมบ่อ เช่น งานวิจัยของ Kulkarni และคณะ (2014) ใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X แกน Z และใช้เทคนิคโครงข่ายประสาทเทียม

เพื่อจำแนกประเภทหลุมบ่อ งานวิจัยของ Predic และ Stojanovic (2015) ใช้ข้อมูลค่าเฉลี่ยความเร่ง ค่าส่วนเบี่ยงเบนมาตรฐานของแกน X แกน Y แกน Z ค่าความสัมพันธ์ระหว่างแกน ค่าเฉลี่ย ความเข้มข้นของเวกเตอร์ความเร่ง ค่าพลังงาน ค่าเอนโทรปีและใช้ต้นไม้ตัดสินใจ (Decision Tree) เพื่อจำแนกประเภทหลุมบ่อ การหลีกเลี่ยงอุปสรรค การเบรกกะทันหัน การเปลี่ยนแปลงและขับขี้ออกติ ส่วนงานวิจัยของ Tai และคณะ (2010) ใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X แกน Y แกน Z และใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) มาจำแนก ประเภทหลุมบ่อและความขรุขระของผิวถนน

สรุปขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับโดยใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่ง ดังแสดงในตารางที่ 2.6

ตารางที่ 2.6 ขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับสภาพพื้นผิวถนนโดยใช้ข้อมูลจาก เครื่องรับรู้มาตรฐานความเร่ง

ขั้นตอนวิธี	ผู้วิจัย	Eriksson et al., 2008	Mednis et al., 2011	Chen et al.; 2011	Astarita et al, 2012	Douangphachanh et al., 2013	Wang et al., 2015	Tai et al., 2010	Kulkarni et al., 2014	Predic et al., 2015
<b>1 วิธีการจำแนกข้อมูล</b>										
1.1 กำหนดค่าเทรชโฮล		✓	✓	✓	✓	✓	✓		✓	
1.2 ซัพพอร์ตเวกเตอร์แมชชีน								✓		
1.3 โครงข่ายประสาทเทียม									✓	
1.4 ต้นไม้ตัดสินใจ										✓
<b>2. การเตรียมข้อมูล</b>										
2.1 กรองสัญญาณความเร็วต่ำ (Low Speed Filter)		✓			✓	✓		✓	✓	
2.2 กำจัดสัญญาณความถี่สูง (High-pass Filter)		✓			✓			✓	✓	
2.3 กำจัดสัญญาณความถี่ต่ำ (Low-pass Filter)								✓	✓	
2.4 กรองสัญญาณการส่งข้อมูลผิดพลาดของ ค่าความเร่งและข้อมูลการระบุตำแหน่ง				✓						

ตารางที่ 2.6 ขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับสภาพพื้นผิวถนน โดยใช้ข้อมูลจาก  
เครื่องรับรู้มาตรการความเร่ง (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย	Eriksson et al., 2008	Mednis et al., 2011	Chen et al.; 2011	Astarita et al, 2012	Douangphachanh et al., 2013	Wang et al., 2015	Tai et al., 2010	Kulkarni et al., 2014	Predic et al., 2015
2.5 คำนวณค่าอัตราเร่งของแรงสั่นสะเทือน ทั้ง 3 แกนตามมุมการวางโทรศัพท์							✓			
2.6 ตัวกรองรถเปลี่ยนทิศทางและการเอียง								✓		
<b>3. การสกัดคุณลักษณะ</b>										
3.1 ค่าอัตราเร่งของแรงสั่นสะเทือนของ แกน X, Y และ Z								✓		
3.2 ค่าอัตราเร่งของแรงสั่นสะเทือนของ แกน X และ Z									✓	
3.3 ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z					✓					
3.4 ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z (Z-peak) หรือ Z- THRESH	✓	✓					✓			
3.5 ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z และแกน X (XZ Ratio)	✓									
3.6 ค่าความเร็วและอัตราเร่งแนวแกน Z (Speed and Z Ratio)	✓									
3.7 ค่าความแตกต่างของความเร่งแกน Z (Z-DIFF)			✓				✓			
3.8 ค่าเบี่ยงเบนมาตรฐานของความเร่งแกน Z (STDEV(Z))			✓				✓			
3.9 ค่าอัตราเร่งของแรงสั่นสะเทือนของทั้ง 3 แกนที่เข้าใกล้ค่า 0 (G-ZERO)		✓					✓			



ตารางที่ 2.6 ขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับสภาพพื้นผิวถนน โดยใช้ข้อมูลจาก  
เครื่องรับรู้มาตรความเร่ง (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย	Eriksson et al., 2008	Mednis et al., 2011	Chen et al.; 2011	Astarita et al., 2012	Douangphachanh et al., 2013	Wang et al., 2015	Tai et al., 2010	Kulkarni et al., 2014	Predic et al., 2015
3.10 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของแกน X, Y และ Z										✓
3.11 ค่าความสัมพันธ์ระหว่างคู่ของแกนแต่ละแกน										✓
3.12 ค่าเฉลี่ยความเข้มข้นของเวกเตอร์ความเร่ง										✓
3.13 ผลรวมของความสูงของคลื่น										✓
3.14 ใช้ค่าอัตราเร่งของแรงสั่นสะเทือนทั้ง 3 แกน มาวิเคราะห์ค่าความหนาแน่นสเปกตรัม (Power Spectral Density) ร่วมกับวิธีฟูเรียร์ทรานสฟอร์ม				✓		✓				
3.15 ค่าดัชนีความขรุขระของพื้นผิวถนนสากล (International Roughness Index) มาคำนวณระดับความขรุขระ				✓		✓				
<b>4 ลักษณะสภาพพื้นผิวถนนที่ตรวจจับ</b>										
4.1 ถนนราบเรียบ ถนนปกติ	✓									
4.2 รอยต่อของถนน	✓									
4.3 ทางข้ามรางรถไฟ	✓									
4.4 หลุมบ่อ	✓						✓	✓	✓	✓
4.5 หลุมบ่อ ขนาดใหญ่ กลาง เล็ก		✓								
4.6 ฝาท่อระบายน้ำ	✓	✓								
4.7 ยางชะลอกความเร็ว	✓			✓						

ตารางที่ 2.6 ขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับสภาพพื้นผิวถนน โดยใช้ข้อมูลจาก  
เครื่องรับรู้มาตรความเร็ว (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย	Eriksson et al., 2008	Mednis et al., 2011	Chen et al.; 2011	Astarita et al, 2012	Douangphachanh et al., 2013	Wang et al., 2015	Tai et al., 2010	Kulkarni et al., 2014	Predic et al., 2015
4.8 รอยแตก รอยแยก			✓							
4.9 ความขรุขระของผิวถนน				✓		✓		✓		
4.10 หลีกเลียงอุปสรรค เบรกกะทันหัน เปลี่ยนเลน และการขับซิปกติ										✓

## 2.5.2 งานวิจัยที่ใช้ข้อมูลรูปภาพและภาพวิดีโอจากกล้อง

ที่ผ่านมางานวิจัยที่ใช้วิธีการพื้นฐานจากการมองเห็น (Vision-based Method) พบว่ามีการศึกษาขั้นตอนวิธีในการตรวจจับโดยใช้ข้อมูลรูปภาพ 2 มิติ (2D Image) และข้อมูลวิดีโอ (Video Data) ซึ่งเป็นข้อมูลที่มีมุมมองของพื้นผิวถนนในพื้นที่กว้างและมีต้นทุนต่ำในการพัฒนา

เมื่อวิเคราะห์ตามลักษณะสภาพพื้นผิวถนนและชนิดของอุปกรณ์ที่ใช้ตรวจจับ พบว่าสามารถตรวจจับสภาพพื้นผิวถนนที่ผิดปกติประเภทหลุมบ่อ (Pothole) รอยแตก (Crack) และรอยปะ (Patch) ได้โดยใช้อุปกรณ์ประเภทกล้องความเร็วสูง (High Speed Camera) กล้องดิจิทัล (Digital Camera) กล้องติดรถยนต์ (GoPro Camera) กล้องมองหลัง (Car's Parking Camera) กล้องในโทรศัพท์มือถือ (Camera Phone) ดังแสดงในตารางที่ 2.7

ตารางที่ 2.7 ลักษณะสภาพพื้นผิวถนนและชนิดของอุปกรณ์ที่ใช้ตรวจจับ

ลักษณะสภาพพื้นผิวถนน	อุปกรณ์ที่ใช้ตรวจจับ	งานวิจัย
หลุมบ่อ (Pothole)	- กล้องความเร็วสูง (High Speed Camera) - กล้องดิจิทัล (Digital Camera) - กล้องในโทรศัพท์มือถือ (Camera Phone) - กล้องติดรถยนต์ (GoPro Camera) - กล้องมองหลัง (Car's Parking Camera)	Koch and Brilakis, 2011; Buza et al., 2013; Huidrom et al., 2013; Enigo, et al., 2016; Jo and Ryu, 2017; Tedeschi and Benedetto, 2017; Buchinger and Silva, 2014; Kim and Ryu, 2014b; Nienaber et al., 2015; Ryu, et al., 2015.
รอยแตก (Crack)	- กล้องดิจิทัล (Digital Camera) - กล้องในโทรศัพท์มือถือ (Camera Phone)	Huidrom et al., 2013; Tedeschi and Benedetto, 2017; Buchinger and Silva, 2014.
รอยปะ (Patch)	กล้องดิจิทัล (Digital Camera)	Huidrom et al., 2013; Radopoulou and Brilakis, 2015.

เมื่อวิเคราะห์ตามระดับความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยแบ่งออกเป็น 6 ระดับ ได้แก่ ต่ำกว่า 70%, 70 – 75%, 76 – 80%, 81 – 85%, 86 – 90%, มากกว่า 90% พบว่า ส่วนใหญ่มีค่าความแม่นยำอยู่ระหว่าง 81 – 85% ดังแสดงในตารางที่ 2.8

ตารางที่ 2.8 ระดับความแม่นยำในการตรวจจับจากข้อมูลรูปภาพและภาพวิดีโอ

ระดับความแม่นยำ	งานวิจัย
ต่ำกว่า 70%	-
70 – 75%	Nienaber et al., 2015; Kim et al., 2015; Radopoulou and Brilakis, 2015.
76 – 80%	Tedeschi and Benedetto, 2017.
81 – 85%	Buza et al., 2013; Enigo et al., 2016; Jo and Ryu, 2017; Buchinger and Silva, 2014.
86 – 90%	Koch and Brilakis, 2011.
มากกว่า 90%	Huidrom et al., 2013.

เมื่อวิเคราะห์ตามขั้นตอนวิธีและเทคนิคที่ใช้ตรวจจับ พบว่า มีการใช้ขั้นตอนวิธีและเทคนิคที่คล้ายกันและแตกต่างกัน แต่มีวัตถุประสงค์เดียวกัน คือ เพิ่มความแม่นยำในการตรวจจับตามลักษณะสภาพพื้นผิวถนนที่ศึกษา สามารถจำแนกขั้นตอนวิธีและเทคนิคที่ใช้เป็น 3 ประเภท ดังนี้ 1) การใช้ขั้นตอนวิธีการประมวลผลภาพ 2) การใช้ขั้นตอนวิธีการประมวลผลภาพร่วมกับการเรียนรู้ด้วยเครื่อง 3) การใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกและตัวแบบที่ถูกลืมมาแล้วล่วงหน้า มีรายละเอียด ดังนี้

#### 1) การใช้ขั้นตอนวิธีการประมวลผลภาพ

เป็นการประยุกต์ใช้งานการประมวลผลภาพ เช่น ภาพนิ่ง (ภาพถ่าย) หรือภาพวิดีโอ มีขั้นตอนวิธีการประมวลผลภาพ ดังนี้ 1) การได้มาของรูปภาพ (Image acquisition) 2) การประมวลผลภาพเบื้องต้น (Preprocessing) 3) การแยกส่วนของภาพ (Segmentation) 4) การสกัดคุณลักษณะ (Feature Extraction) 5) การรู้จำวัตถุ (Object Recognition) และ 6) การวิเคราะห์โครงสร้าง (Structural) (Tedeschi and Benedetto, 2017, p. 13; Koch et al., 2015, p. 201)

เทคนิคที่สำคัญในการประมวลผลภาพเบื้องต้น (Image Preprocessing) เช่น การแปลงเป็นภาพระดับสีเทา (Gray Scaling) การปรับปรุงภาพ/การกรองสัญญาณรบกวน (Filtering/Enhancement) การแยกส่วนของภาพ (Segmentation) การเปลี่ยนแปลงลักษณะรูปร่างหรือโครงสร้างของภาพ (Morphological Processing) การหาขอบของภาพ (Edge Detection) เพื่อนำวัตถุที่ได้ไปวิเคราะห์หาข้อมูลเชิงปริมาณ เช่น จำนวน ขนาด รูปร่าง และทิศทางเคลื่อนที่ของวัตถุในภาพ ดังแสดงในตารางที่ 2.9

ตารางที่ 2.9 เทคนิคที่ใช้ในการประมวลผลภาพเบื้องต้น

วิธีการประมวลผลภาพ	เทคนิคที่ใช้	ผลงานวิจัย
การแปลงเป็นภาพระดับสีเทา (Gray Scaling)	- การหาเฉลี่ยค่าของแม่สี (Gray Scale Average Method) - การคิดค่าความสว่างของแต่ละแม่สี (Weighted Method or luminosity Method)	Koch and Brilakis, 2011; Enigo et al., 2016; Jo and Ryu, 2017; Buchinger and Silva, 2014; Nienaber et al., 2015; Radopoulou and Brilakis, 2015.
การกรองสัญญาณรบกวน (Noise Filter)	- ตัวกรองเกาส์เซียนเบลอ (Gaussian Blur) - ตัวกรองค่ามัธยฐาน (Median Filter)	Koch and Brilakis, 2011; Enigo et al., 2016; Jo and Ryu, 2017; Kim and Ryu, 2014b; Nienaber et al, 2015; Ryu et al., 2015; Radopoulou and Brilakis, 2015.
การเปลี่ยนแปลงลักษณะรูปร่างหรือโครงสร้างของภาพ (Morphological processing)	- การขยายพิกเซลของภาพ (Dilation) - การลดขนาดของพิกเซล (Erosion) - การกำจัดรายละเอียดขนาดเล็กของภาพ (Opening) - การทำให้ภาพเชื่อมต่อกัน (Closing)	Koch and Brilakis, 2011; Enigo et al., 2016; Jo and Ryu, 2017; Buchinger and Silva, 2014; Nienaber et al., 2015; Ryu et al., 2015; Radopoulou and Brilakis, 2015.
การแยกส่วนของภาพ (Segmentation)	- การกำหนดค่าเทรชโฮล (Thresholding) - วิธีฮิสโตแกรม (Histogram Equalization) - โอtsu (Otsu)	Koch and Brilakis, 2011; Jo and Ryu, 2017; Buchinger and Silva, 2014; Kim and Ryu, 2014b; Kim, T., and Kim, Y., 2015; Radopoulou and Brilakis, 2015; Lin and Liu, 2010.
การหาขอบของภาพ (Edge Detection)	- แคนนี่ (Canny) - โซเบล (Sobel) - การทำคอนทัวร์ (Contour)	Enigo, Kumar, Vijay and Prabu, 2016; Nienaber et al., 2015; Kim, T., and Kim, Y., 2015.

จากตารางที่ 2.9 แสดงเทคนิคที่ใช้ในการประมวลผลภาพเบื้องต้น (Image Preprocessing) เป็นเทคนิควิธีของการปรับปรุงคุณภาพของข้อมูลภาพ เพื่อให้ข้อมูลภาพมีความถูกต้องสมบูรณ์ก่อนนำไปประมวลผลต่อไป ที่ผ่านมามีงานวิจัยมีการประยุกต์ใช้หลากหลายเทคนิควิธี ดังนี้

**การกรองสัญญาณรบกวน (Noise Filter)** เป็นการทำให้รายละเอียดที่ไม่ชัดเจน ให้มีความชัดเจนขึ้นหรือทำให้คุณลักษณะที่สำคัญเด่นขึ้น ซึ่งการปรับปรุงภาพเป็นกระบวนการ

ในการกำจัดสัญญาณรบกวนที่เกิดขึ้นในภาพ (Noise) ที่ทำให้สีภายในภาพเกิดความไม่สม่ำเสมอ แหล่งที่ทำให้เกิดสัญญาณรบกวนของภาพดิจิทัล คือ สภาพแวดล้อมจากการได้มาของรูปภาพ ระดับของแสงที่ไม่เพียงพอและฝุ่นละอองที่เกิดขึ้นบนจอภาพ (Sharma, Singh, and Chand, 2016, p. 57) ภาพที่ถูกปรับให้คมชัดและคุณลักษณะของภาพสม่ำเสมอ เช่น ขอบภาพ ความคมชัดของภาพ จะเป็นประโยชน์มากต่อการนำภาพมาวิเคราะห์ เทคนิคที่ใช้ เช่น การกรองข้อมูลภาพ โดยใช้ค่ามัธยฐาน (Median Filtering) เป็นการนำเอาความเข้มแสงของจุดที่ตรงกันในภาพต่าง ๆ มาเรียงลำดับ (Sort) จากนั้นไปหามาก จากนั้นเลือกค่าที่อยู่ตรงกลางไปใช้ หากจำนวนภาพทั้งหมดเป็นจำนวนคู่ ค่าทั้งสองที่อยู่ตรงกลางจะนำมาหาค่าเฉลี่ย วิธีการนี้จะต้องใช้การเรียงลำดับซึ่งเป็นกระบวนการที่ใช้เวลาในการคำนวณสูง แต่มีข้อดีคือไม่สูญเสียความคมชัด (Sharma et al., 2016, pp. 57-58) พบได้ในงานวิจัยของ Koch และ Brilakis (2011) Radopoulou และ Brilakis (2015) Ryu และคณะ (2015) Enigo และคณะ (2016) และ Jo และ Ryu (2017) อีกหนึ่งเทคนิคที่พบคือ การใช้ตัวกรองเกาส์เซียน (Gaussian Filter) เพื่อกำจัดสัญญาณรบกวนออกจากภาพ พบได้ในงานวิจัยของ Nienaber และคณะ (2015) และ Jo และ Ryu (2017) นอกจากนี้เทคนิคการเปลี่ยนแปลงลักษณะรูปร่างหรือ โครงร่างของภาพ (Morphological Processing) เป็นอีกหนึ่งเทคนิคที่พบในขั้นตอนการประมวลผลภาพเบื้องต้นเพื่อให้ภาพมีลักษณะตามที่ต้องการ เช่น การขยายพิกเซลของภาพ (Dilation) การลดขนาดของพิกเซล (Erosion) การกำจัดรายละเอียดขนาดเล็กของภาพ (Opening) และการทำให้ภาพเชื่อมต่อกัน (Closing) พบในงานวิจัยของ Koch และ Brilakis (2011) Enigo และคณะ (2016) Jo และ Ryu (2017) Buchinger และ Silva (2014) Nienaber และคณะ (2015) Ryu และคณะ (2015) และ Radopoulou และ Brilakis (2015)

**การแยกส่วนของภาพ (Image Segmentation)** เป็นขั้นตอนวิธีที่แยกข้อมูลภาพออกเป็นส่วน ๆ ทำให้ได้ข้อมูลที่ต้องการออกจากพื้นหลัง เช่น การแยกส่วนของภาพหลุมบ่อ รอยแตกและรอยปะออกจากพื้นผิวถนนที่ปกติ โดยใช้เทคนิคการกำหนดค่าเทรชโฮล (Threshold) พบได้ในงานวิจัยของ Koch และ Brilakis (2011) และ Jo และ Ryu (2017) ส่วนการใช้วิธีฮิสโตแกรม (Histogram Equalization) เป็นวิธีการปรับแก้ความสว่างที่ทำการยืดข้อมูลภาพให้คมชัด โดยใช้ความสัมพันธ์ที่ไม่ใช่ลักษณะเชิงเส้นตรง จุดประสงค์ในการใช้วิธีนี้คือ พยายามเปลี่ยนการกระจายข้อมูลที่ไม่ปกติให้เป็นแบบปกติและปรับจำนวนจุดภาพในแต่ละค่าความเข้มให้มีจำนวนใกล้เคียงกัน (Sharma, Singh and Chand, 2016, p. 58) พบได้ในงานวิจัยของ Buza และคณะ (2013) Buchinger และ Silva (2014) Ryu และคณะ (2015) Radopoulou และ Brilakis (2015) Jo และ Ryu (2015) และ Lin และ Liu (2010) นอกจากนี้ยังพบเทคนิคการหาค่าเทรชโฮลโดยใช้วิธีของโอตสึ (Otsu) พบได้ในงานวิจัยของ Jo และ Ryu (2015)



**การหาขอบของภาพ (Edge Detection)** เป็นการหาเส้นรอบวัตถุที่อยู่ในภาพ เมื่อทราบเส้นรอบวัตถุแล้วจะสามารถคำนวณหาพื้นที่ ขนาด หรือรู้จำชนิดของวัตถุนั้นได้ โดยใช้เทคนิควิธีการของแคนนี่ (Canny) พบได้ในงานวิจัยของ Nienaber และคณะ (2015) Enigo และคณะ (2016) นอกจากนี้ยังพบเทคนิคการหาขอบของภาพด้วยวิธีโซเบล (Sobel) พบได้ในงานวิจัยของ Ryu และคณะ (2015)

## 2) การใช้ขั้นตอนวิธีการประมวลผลภาพพร้อมกับการเรียนรู้ด้วยเครื่อง

เป็นการประยุกต์ใช้ขั้นตอนวิธีการประมวลผลภาพ เพื่อสกัดคุณลักษณะที่สำคัญของรูปภาพสภาพพื้นผิวถนน จากนั้นใช้ขั้นตอนวิธีการเรียนรู้ด้วยเครื่องในการจำแนกประเภทสภาพพื้นผิวถนน เช่น งานวิจัยของ Lin และ Liu (2010) ได้เสนอวิธีการตรวจจับหลุมบ่อจากรูปภาพถนน โดยใช้เทคนิคฮิสโตแกรม (Histogram) เพื่อสกัดคุณลักษณะสวดลาย (Texture) ของภาพพื้นผิวถนนและใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ในการระบุหลุมบ่อ ขั้นตอนวิธีของงานวิจัยนี้สามารถตรวจจับหลุมบ่อในรูปภาพถนนได้เป็นอย่างดี

## 3) การใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกและตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า

การจำแนกสภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Classification) โดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolution Neural Networks Model) ที่ออกแบบโครงสร้างสถาปัตยกรรมเอง พบได้ในงานวิจัยของ Zhang และคณะ (2016) Kawano และคณะ (2017) และ Eisenbach และคณะ (2017) ส่วนการจำแนกสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Models) พบได้ในงานวิจัยของ Maeda และคณะ (2016a, 2016b) ยิ่งไปกว่านั้น การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Detection) โดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า พบได้ในงานวิจัยของ Maeda และคณะ (2018) Singh และ Shekhar (2018) และ Koh และคณะ (2019) ดังแสดงในตารางที่ 2.10

ตารางที่ 2.10 การใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียม  
แบบคอนโวลูชันเชิงลึกและตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า

ขั้นตอนวิธี	ผู้วิจัย							
	Zhang et al., 2016	Maeda et al., 2016a	Maeda et al., 2016b	Kawano et al., 2017	Eisenbach et al., 2017	Maeda et al., 2018	Singh, and Shekhar, 2018	Koh et al., 2019
<b>1. ข้อมูลจากเครื่องรับรู้</b>								
1.1 รูปภาพจากกล้องโทรศัพท์มือถือ	✓		✓					
1.2 รูปภาพวิดีโอจากโทรศัพท์มือถือ		✓				✓	✓	
1.3 รูปภาพจากกล้องถ่ายรูป				✓	✓			✓
<b>2. การเตรียมข้อมูล</b>								
หมุนภาพจาก 0 - 360 องศา	✓							
<b>3. ลักษณะสภาพพื้นผิวถนนที่ตรวจจับ</b>								
3.1 หลุมบ่อ					✓	✓	✓	✓
3.2 รอยแตก	✓				✓			
3.3 รอยแตกตามแนวยาวบริเวณล้อรถ						✓	✓	
3.4 รอยแตกตามแนวยาวบริเวณ ก่อสร้าง						✓	✓	
3.5 รอยแตกตามแนวขวาง						✓	✓	
3.6 รอยแตกตามแนวขวางบริเวณ ก่อสร้าง						✓	✓	
3.7 รอยแตกหนังจระเข้						✓	✓	
3.8 รอยปะซ่อม					✓			
3.9 รอยต่อถนน					✓			
3.10 ความเสียหายของเส้นจราจร				✓		✓	✓	
3.11 เส้นข้ามทางม้าลายชำรุด						✓	✓	
3.12 ความเสียหายของผิวถนน		✓	✓					



ตารางที่ 2.10 การใช้ขั้นตอนวิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกและตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย							
	Zhang et al., 2016	Maeda et al., 2016a	Maeda et al., 2016b	Kawano et al., 2017	Eisenbach et al., 2017	Maeda et al., 2018	Singh, and Shekhar, 2018	Koh et al., 2019
7.การเปรียบเทียบกับตัวแบบอื่น ๆ								
7.1 ซัพพอร์ตเวกเตอร์แมชชีน	✓			✓				
7.2 อัลกอริทึมบูสต์ติง	✓							
7.3 อัลกอริทึมกลุ่มต้นไม้ตัดสินใจ				✓				
7.4 เปรียบเทียบกับ Zhang และคณะ (2016)					✓			
8. การประเมินตัวแบบ								
8.1 ค่าความแม่นยำ (Accuracy)	92.5	93.0	91.7	94.1	97.7			
8.2 ค่าความแม่นยำและค่าความระลึก						>75		
8.3 ค่าตัววัดค่าเอฟ (F1-score)							52.8	
8.4 ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP)								89

จากตารางที่ 2.10 การจำแนกสภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Classification) โดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolution Neural Networks) ที่ออกแบบโครงสร้างสถาปัตยกรรมเอง เช่น งานวิจัยของ Zhang และคณะ (2016) เสนอวิธีการจำแนกรอยแตกจากรูปภาพในโทรศัพท์สมาร์ทโฟนบนถนนในเมืองฟิลาเดลเฟีย รัฐเพนซิลเวเนีย สหรัฐอเมริกา โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ถูกออกแบบโครงสร้างไว้ทั้งหมดจำนวน 6 ชั้น (Layers) ประกอบด้วยชั้นโครงสร้างคอนโวลูชัน (Convolution Layers) รวมทั้งแมกพูลริง (Max-pooling) จำนวน 4 ชั้น และการเชื่อมต่อแบบทั่วถึง (Fully Connected Layers) จำนวน 2 ชั้น เพื่อใช้ในการจำแนกรูปภาพ 2 ประเภท ได้แก่ รอยแตกและไม่ใช่อรอยแตก งานวิจัยนี้ใช้รูปภาพรอยแตกของถนนจำนวน 500 ภาพ จากนั้นทำการหมุนภาพโดยการสุ่มหมุนภาพจาก 0 ถึง 360 องศา

เพื่อเพิ่มจำนวนของรูปภาพรอยแตกและไม่ใช่อรอยแตกของถนนสำหรับใช้ชุดข้อมูลในการเรียนรู้และทดสอบ (Training and Testing Dataset) นอกจากนี้ได้ทำการเปรียบเทียบค่าความถูกต้องในการจำแนกข้อมูลรูปภาพระหว่างเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และเทคนิคการเรียนรู้ร่วมกันด้วยอัลกอริทึมแบบบูสต์ติง (Boosting) ที่ใช้คุณลักษณะของภาพที่ถูกสกัดไว้แล้วด้วยวิธีการประมวลผลภาพจำนวน 93 คุณลักษณะ (Feature) ผลการทดลองพบว่า กระบวนการเรียนรู้เชิงลึกโดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสามารถจำแนกรอยแตกได้ค่าความถูกต้อง 92.50% ซึ่งมีประสิทธิภาพดีกว่าวิธีการใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนและวิธีการบูสต์ติง

งานวิจัยของ Eisenbach และคณะ (2017) เสนอการจำแนกสภาพพื้นผิวถนนประเภทรอยแตก หลุมบ่อ รอยปะซ่อม รอยต่อถนน งานวิจัยนี้ออกแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกเองและเปรียบเทียบตัวแบบจากงานวิจัยของ Zhang และ (2016) ผลการวิจัยพบว่า โครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ถูกออกแบบเองประกอบด้วยชั้นคอนโวลูชันจำนวน 2 ชั้นต่อกันตามด้วยแม็กพูลิงจำนวน 1 ชั้น รวมทั้งหมด 4 ชั้น และการเชื่อมต่อแบบทั่วถึงจำนวน 3 ชั้น สามารถจำแนกลักษณะความเสียหายของพื้นผิวถนนได้ค่าความถูกต้อง 97.70%

นอกจากนี้งานวิจัยของ Kawano และคณะ (2017) เสนอวิธีการจำแนกความเสียหายของเส้นจราจรบนพื้นผิวถนนจากกล้องที่ถูกติดตั้งไว้บนรถเก็บขยะที่วิ่งผ่านถนนในเมืองฟุจิซะวะประเทศญี่ปุ่นทำให้ได้รับข้อมูลรูปภาพถนนที่ครอบคลุมพื้นที่ทั่วทั้งเมือง จากนั้นใช้ตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ถูกออกแบบเอง ประกอบด้วยโครงสร้างชั้นคอนโวลูชันและแม็กพูลิงจำนวน 4 ชั้น และการเชื่อมต่อแบบทั่วถึงจำนวน 2 ชั้น เพื่อสร้างตัวแบบที่ตั้งชื่อว่า Deep on Edge (DoE) เพื่อจำแนกรูปภาพความเสียหายของเส้นจราจรบนพื้นผิวถนนเป็น 3 ประเภท ได้แก่ เส้นจราจรที่เสียหาย เส้นจราจรที่ไม่เสียหาย และไม่มีเส้นจราจร สำหรับการทดลองได้ทำการเปรียบเทียบความถูกต้องในการจำแนกความเสียหายของเส้นจราจรบนพื้นผิวถนนโดยใช้ DoE กับวิธีพื้นฐานอื่น ๆ ได้แก่ เทคนิคซัพพอร์ตเวกเตอร์แมชชีน เทคนิคการเรียนรู้ร่วมกันด้วยอัลกอริทึมกลุ่มต้นไม้ตัดสินใจ (Random Forest) และโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกของ AlexNet (Krizhevsky, Sutskever, and Hinton, 2012) ผลการทดลองพบว่า การใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ชื่อว่า Deep on Edge มีประสิทธิภาพดีกว่าเทคนิคที่นำมาเปรียบเทียบ ซึ่งได้ค่าความถูกต้องในการจำแนกความเสียหายของเส้นจราจรบนพื้นผิวถนนอยู่ที่ 94.10%

การจำแนกสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Models) เช่น งานวิจัยของ Maeda และคณะ (2016a) ที่เสนอการจำแนกความเสียหายของพื้นผิวถนนในเมืองชิบะประเทศญี่ปุ่น โดยใช้รูปภาพวิดีโอจากโทรศัพท์สมาร์ทโฟนและใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าของ AlexNet สำหรับจำแนกรูปภาพ (Krizhevsky, Sutskever, and Hinton, 2012) และตัวแบบ GoogLeNet (Szegedy et al., 2015) เพื่อใช้จำแนกลักษณะความเสียหายของพื้นผิวถนนจำนวน 3 ประเภท ได้แก่ สภาพพื้นผิวถนนปกติไม่มีความเสียหาย ความเสียหายของพื้นผิวถนนที่ไม่จำเป็นต้องซ่อมและความเสียหายของพื้นผิวถนนที่จำเป็นต้องซ่อม ผลการวิจัยพบว่า ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าของ GoogLeNet สามารถจำแนกลักษณะความเสียหายของพื้นผิวถนนได้ค่าความถูกต้อง 93% ซึ่งสูงกว่าตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าของ AlexNet ที่จำแนกลักษณะความเสียหายของพื้นผิวถนนได้ค่าความถูกต้อง 90% แต่อย่างไรก็ตาม รูปภาพลักษณะความเสียหายที่ตัวแบบจำแนกไม่ถูกต้อง คือ ความเสียหายของพื้นผิวถนนที่ไม่จำเป็นต้องซ่อมและความเสียหายของพื้นผิวถนนที่จำเป็นต้องซ่อม ซึ่งความผิดพลาดนี้เกิดจากการระบุลักษณะภาพความเสียหายของเจ้าหน้าที่ในแต่ละหน่วยงานที่มีการนิยามความจำเป็นต้องซ่อมกับไม่ต้องซ่อมแตกต่างกัน

ยิ่งไปกว่านั้น Maeda และคณะ (2016b) ได้เสนอแอปพลิเคชันการจัดการถนน โดยให้ประชาชนสามารถถ่ายรูปลักษณะความเสียหายของถนนผ่านกล้องถ่ายรูปในโทรศัพท์สมาร์ทโฟนเพื่อส่งข้อมูลรูปภาพมาให้ตัวแบบประเมินลักษณะความเสียหาย ได้แก่ ไม่มีความเสียหาย ความเสียหายน้อยที่ไม่จำเป็นต้องซ่อมและความเสียหายที่จำเป็นต้องซ่อม โดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าของ Caffe (Jia, Shelhamer, Donahue, Karayev, Long, Girshick, Guadarrama, and Darrell, 2014) ที่ถูกออกแบบโครงสร้างไว้ทั้งหมดจำนวน 8 ชั้น (Layers) ประกอบด้วยชั้นโครงสร้างคอนโวลูชันรวมทั้งแมกพูริงจำนวน 5 ชั้น และการเชื่อมต่อแบบทั่วถึงจำนวน 3 ชั้น นอกจากนี้ยังใช้วิธีการตัดออกบางส่วน (Dropout) เพื่อหลีกเลี่ยงการเกิดการจำแนกข้อมูลพอดีเกินไปกับชุดข้อมูลเรียนรู้และทดสอบ (Overfitting) แต่อาจไม่เหมาะสมกับข้อมูลที่ต้องการทำนายจริง ผลการวิจัยพบว่า ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าของ Caffe สามารถจำแนกลักษณะความเสียหายของพื้นผิวถนนได้ค่าความถูกต้อง 91.70%

งานวิจัยที่ผ่านมา นำเข้ารูปภาพจากโทรศัพท์สมาร์ทโฟนผ่านตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ถูกออกแบบเองหรือตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ซึ่งรูปภาพนำเข้าจำเป็นต้องมีลักษณะสภาพพื้นผิวถนนที่ผิดปกติประเภทเดียว จึงจะสามารถใช้ตัวแบบจำแนกรูปภาพได้ (Image Classification Models) หากรูปภาพนำเข้านั้นมีลักษณะสภาพพื้นผิวถนนหลากหลายประเภทจำเป็นต้องใช้ตัวแบบสำหรับการตรวจจับวัตถุ (Object Detection Models)



งานวิจัยที่นำรูปภาพมาตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Road Surface Anomalies Detection) โดยใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า เช่น งานวิจัยของ Maeda และคณะ (2018) พัฒนาชุดข้อมูลสำหรับตรวจจับความเสียหายบนถนนในประเทศญี่ปุ่นจำนวน 8 ประเภท ได้แก่ รอยแตกตามแนวยาวบริเวณล้อรถ รอยแตกตามแนวยาวบริเวณการก่อสร้าง รอยแตกตามแนวขวาง รอยแตกตามแนวขวางบริเวณการก่อสร้าง รอยแตกหนังกระเบื้อง หลุมบ่อ เส้นช่องจราจรชำรุดและเส้นข้ามทางม้าลายชำรุด โดยใช้ตัวแบบ SSD Inception\_V2 และ SSD MobileNet ผลการทดลองพบว่า ทั้ง 2 ตัวแบบสามารถตรวจจับความเสียหายบนถนนได้ค่าความแม่นยำและค่าความระลึกรวมกันกว่า 75%

ส่วนงานวิจัยของ Singh และ Shekhar (2018) ใช้ชุดข้อมูลของ Maeda และคณะ (2018) เพื่อตรวจจับความเสียหายบนถนนด้วยตัวแบบ Mask Region-based Convolutional Network (Mask R-CNN) ผลการทดลองพบว่า ตัวแบบ Mask R-CNN ตรวจจับความเสียหายบนถนนได้ค่าตัววัดค่าเอฟ (F1-score) เท่ากับ 52.80% นอกจากนี้งานวิจัยของ Koh และคณะ (2019) ตรวจจับสภาพพื้นผิวถนนจากชุดข้อมูลหลุมบ่อในแอฟริกาใต้โดยใช้ตัวแบบ Region-based Fully Convolutional Networks (R-FCN) ผลการทดลองพบว่า ตัวแบบ R-FCN สามารถตรวจจับหลุมบ่อได้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) เท่ากับ 89%

### 2.5.3 งานวิจัยที่ใช้ข้อมูลหลายรูปแบบจากข้อมูลรูปภาพร่วมกับค่าอัตราเร่งของแรงสั่นสะเทือน

งานวิจัยที่ใช้ข้อมูลหลายรูปแบบเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ พบว่าเป็นการใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน (Acceleration Value) และข้อมูลรูปภาพ (Image) จากโทรศัพท์สมาร์ทโฟนมาทำการวิเคราะห์สภาพพื้นผิวถนนร่วมกันเพื่อเสริมข้อบกพร่องหรือข้อผิดพลาดจากการใช้ข้อมูลเครื่องรับรู้เพียงอย่างเดียว นอกจากนี้ยังใช้ตัวกรองข้อมูล (Filter) เพื่อสกัดข้อมูลที่ไม่ต้องการออก เช่น ตัวกรองความเร็ว (Velocity Filter) เพื่อกำหนดค่าความเร็วที่ใช้ในการตรวจสอบระหว่าง 10 – 60 กิโลเมตร/ชั่วโมง ตัวกรองทิศทางการวางโทรศัพท์สมาร์ทโฟน (Reorientation Filter) เพื่อเลือกใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนตามแนวแกนที่ตั้งฉากกับถนน ระบบที่เสนอสามารถจำแนกสภาพพื้นผิวถนน ประเภทหลุมบ่อ (Potholes) เนินชะลอความเร็ว (Speed Bumps) และตรวจจับสิ่งกีดขวางบนถนนได้ เช่น งานวิจัยของ Orhan (2013) Orhan และ Eren (2013a, 2013b) และงานวิจัยของ Rajamohan และคณะ (2015) ดังตารางที่ 2.11

ตารางที่ 2.11 การใช้ข้อมูลจากเครื่องรับรู้หลายรูปแบบเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ขั้นตอนวิธี	ผู้วิจัย Orhan et al., 2013a, 2013b	Rajamohan et al., 2015
<b>1. ข้อมูลจากเครื่องรับรู้หลายรูปแบบ</b>		
1.1 เครื่องรับรู้มาตรความเร่งในโทรศัพท์สมาร์ทโฟน	✓	✓
1.2 รูปภาพจากกล้องในโทรศัพท์สมาร์ทโฟน	✓	✓
<b>2. การเตรียมข้อมูล</b>		
2.1 กรองทิศทางการวางโทรศัพท์ เพื่อเลือกค่าอัตราเร่งของแรงสั่นสะเทือนตามแนวแกนที่ตั้งฉากกับถนน	✓	
2.2 ตัวกรองความเร็วรถ เพื่อใช้ความเร็วระหว่าง 10 – 60 กิโลเมตร/ชั่วโมง	✓	
2.3 กรองสัญญาณค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z ที่มีความถี่ต่ำออก ในขณะที่เบรกและเลียวรรด		✓
2.4 ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z ที่มีความถี่สูงมากำหนดส่วนเบี่ยงเบนมาตรฐาน		✓
<b>3. การสกัดคุณลักษณะ</b>		
3.1 ใช้ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z เพื่อกำหนดค่าเทรสโฮลด์ตามความเร็วของรถ	✓	
3.2 ใช้ไลบรารีโอเพ่นซีวี เพื่อสกัดภาพที่อยู่ในวิดีโอ เมื่อตรวจพบค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z เกินค่าเทรสโฮลด์ที่กำหนด ระบบจะทำการดึงภาพ ณ เวลานั้นมาแสดง	✓	
3.3 ใช้ค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z ส่วนเบี่ยงเบนมาตรฐานของค่าอัตราเร่งของแรงสั่นสะเทือนแกน Z มาสร้างตัวแบบในการจำแนกข้อมูลสภาพพื้นผิวถนนโดยใช้เพื่อนบ้านใกล้ที่สุด		✓
3.4 ใช้การประมวลผลภาพเพื่อค้นหาขอบภาพด้วยวิธีของแคนนี่ (Canny) และตีเส้นตามเส้นขอบใช้วิธีคอนทัวร์ (Edge Contours)		✓
3.5 ใช้เทคนิคฮิสโตแกรมเพื่อจำแนกระดับความเข้มของสีพื้นผิวถนน		✓

ตารางที่ 2.11 การใช้ข้อมูลจากเครื่องรับรู้หลายรูปแบบเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย	
	Orhan et al., 2013a, 2013b	Rajamohan et al., 2015
<b>4. ลักษณะสภาพพื้นผิวถนนที่ตรวจจับ</b>		
4.1 หลุมบ่อ	✓	
4.2 เนินชะลอความเร็ว	✓	
4.3 หลุมบ่อเป็น 4 ระดับ (สภาพถนนดี สภาพถนนเป็นที่พอใจ สภาพถนนไม่น่าพอใจ สภาพถนนแย่)		✓
4.4 จำแนกประเภทถนน (ถนนคอนกรีต ถนนลาดยาง และถนนลูกรังหรือถนนดินโคลน)		✓
<b>5. การประเมินตัวแบบ</b>		
ค่าความแม่นยำ (Accuracy)	82%	60 – 100%

งานวิจัยของ Orhan (2013) Orhan และ Eren (2013a, 2013b) พัฒนาระบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ประเภทหลุมบ่อ (Potholes) เนินชะลอความเร็ว (Speed Bumps) และสิ่งกีดขวางบนถนนในประเทศตุรกี โดยใช้เครื่องรับรู้มาตรความเร่ง (Accelerometer Sensor) เพื่อบันทึกข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนทั้ง 3 แกน กล้องบันทึกรูปภาพ (Camera) ของสภาพพื้นผิวถนน เครื่องรับรู้สนามแม่เหล็ก (Magnetometer) เพื่อบันทึกข้อมูลทิศทางของอุปกรณ์ และระบบกำหนดตำแหน่งบนพื้นโลก (Global Positioning System: GPS) เพื่อบันทึกข้อมูลตำแหน่งและความเร็วของรถ เหตุการณ์สภาพพื้นผิวถนนหลุมบ่อและเนินชะลอความเร็วจะถูกตรวจสอบและสกัดข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและรูปภาพตามความเร็วของรถและตำแหน่งของข้อมูลที่ตรงกัน จากนั้นจึงทำการวิเคราะห์เหตุการณ์สภาพพื้นผิวถนนตามขั้นตอนวิธีที่ถูกพัฒนาขึ้น เมื่อตรวจพบเหตุการณ์สภาพพื้นผิวถนนที่ผิดปกติจึงส่งไปวิเคราะห์ตำแหน่งและแจ้งเตือนผู้ขับขี่คนอื่น ๆ ที่อยู่บริเวณใกล้เคียง

การจำแนกหลุมบ่อและเนินชะลอความเร็วของงานวิจัยนี้ใช้เครื่องรับรู้มาตรความเร่งในแนวแกนแนว (Z Axis) ซึ่งเป็นการวิเคราะห์ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของแกนที่ตั้งฉากกับถนน เพื่อพัฒนาขั้นตอนวิธีในการจำแนกหลุมบ่อและเนินชะลอความเร็ว

โดยการกำหนดค่าตรวจสอบหรือค่าเทรชโฮลด์ (Thresholds) ตามความเร็วของรถ หากอยู่ในช่วงที่กำหนดจะระบุเป็นสภาพพื้นผิวถนนเป็นประเภทนั้น ๆ จากนั้นจึงใช้ไลบรารีโอเพ่นซีวี (OpenCV Library) เพื่อดึงรูปภาพที่อยู่ในวิดีโอโดยใช้ผลการวิเคราะห์จากเครื่องตรวจจับ ค่าอัตราเร่งของแรงสั่นสะเทือน หากตรวจพบสภาพพื้นผิวถนนที่ผิดปกติระบบจะทำการดึงภาพในตำแหน่งนั้นมาแสดง ผลจากการทดลองพบว่า ค่าความแม่นยำในการจำแนกสภาพพื้นผิวถนนอยู่ที่ 82% อย่างไรก็ตาม งานวิจัยนี้ยังไม่ได้ใช้ขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนจากข้อมูลรูปภาพเป็นเพียงการแสดงรูปภาพให้ตรงตามผลการวิเคราะห์ข้อมูลจากเครื่องรับรู้มาตรความเร่งเท่านั้น ซึ่งต่างจากงานวิจัยของ Rajamohan และคณะ (2015) ที่นอกจากวิเคราะห์สภาพพื้นผิวถนนที่ผิดปกติจากเครื่องรับรู้มาตรความเร่งแล้วยังทำการวิเคราะห์ข้อมูลรูปภาพโดยวิธีการประมวลผลภาพอีกด้วย

นอกจากนี้ระบบต้นแบบสำหรับการประเมินสภาพพื้นผิวถนน โดยใช้ในการหลอมรวมข้อมูลจากหลายเครื่องรับรู้ในโทรศัพท์สมาร์ทโฟน (Fusing Multi-sensor Data) ของ Rajamohan และคณะ (2015) ใช้ข้อมูลรูปภาพจากกล้องวิดีโอ ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลตำแหน่งในการเดินทาง เพื่อจำแนกหลุมบ่อในประเทศอินเดีย ข้อมูลรูปภาพจากกล้องวิดีโอจะถูกหลอมรวมเข้ากับข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนในตำแหน่งเดียวกัน ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจะถูกนำมาผ่านตัวกรองเพื่อกรองสัญญาณความถี่ต่ำในขณะเบรกและเลี้ยวรถออก จากนั้นจึงนำสัญญาณความถี่สูงมาใช้คำนวณส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) และระบุสภาพพื้นผิวถนนหลุมบ่อเป็น 4 ระดับ ได้แก่ สภาพถนนดี สภาพถนนเป็นที่พอใจ สภาพถนนไม่น่าพอใจ สภาพถนนแย่มาก จากนั้นนำชุดข้อมูลที่ได้ไปฝึกฝน (Training) เพื่อสร้างตัวแบบในการจำแนกข้อมูลสภาพพื้นผิวถนนโดยใช้ขั้นตอนวิธีการเพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbors Algorithm)

การตรวจจับสภาพพื้นผิวถนนโดยใช้ข้อมูลรูปภาพจากกล้อง เป็นการตรวจจับหลุมบ่อโดยพิจารณาจากคุณลักษณะขอบของภาพ (Edge Feature Detect) ผลของการตรวจจับจากข้อมูลรูปภาพจะเป็นส่วนเสริมให้ระบบการตรวจจับด้วยเครื่องรับรู้มาตรความเร่งสมบูรณ์มากขึ้น หากมีการตรวจจับหลุมบ่อจากข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่ผิดพลาด สำหรับการประมวลผลภาพเพื่อค้นหาขอบภาพใช้วิธีของแคนนี่ (Canny) และติเส้นตามเส้นขอบใช้วิธีคอนทัวร์ (Edge Contours) แล้วนับจำนวนคอนทัวร์ที่อยู่ในภาพ เพื่อระบุสภาพพื้นผิวถนนประเภทหลุมบ่อตามจำนวนของคอนทัวร์โดยแบ่งออกเป็น 4 ระดับ ได้แก่ สภาพถนนดี สภาพถนนเป็นที่พอใจ สภาพถนนไม่น่าพอใจ และสภาพถนนแย่มาก นอกจากนี้ได้จำแนกประเภทของผิวถนนจากข้อมูลรูปภาพ ได้แก่ ถนนคอนกรีต ถนนลาดยาง และถนนลูกรังหรือถนนดินโคลน โดยใช้เทคนิคฮิสโตแกรม (Histogram) ในการจำแนกระดับความเข้มของสีพื้นผิวถนน สำหรับการระบุ




ตารางที่ 2.12 ทบทวนวรรณกรรมที่เกี่ยวข้องกับขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)

ขั้นตอนวิธี	ผู้วิจัย																	งานวิจัยนี้					
	Erikson et al., 2008	Tai et al., 2010	Mednis et al., 2011	Chen et al., 2011	Douangphachanh et al., 2013	Kulkarni et al., 2014	Wang et al., 2015	Predic et al., 2015	Lin et al., 2010	Koch et al., 2011	Buza et al., 2013	Huidrom et al., 2013	Zhang et al., 2016	Maeda et al., 2016	Kawano et al., 2017	Eisenbach et al., 2017	Orhan et al., 2013a, 2013b		Rajamohan et al., 2015	Maeda et al., 2018	Singh and Shekhar, 2018	Koh et al., 2019	
3.4 เน้นชะลอความเร็ว	✓																						✓
3.5 ทางข้ามทางรถไฟ	✓					✓																	
3.6 เงา แสงสะท้อน คราบสี										✓		✓					✓	✓					✓
<b>4. ยานพาหนะที่ใช้เก็บข้อมูล</b>																							
4.1 รถถัง รถกระบะ รถแท็กซี่	✓		✓	✓	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓	✓			✓	✓	✓	✓	✓
4.2 รถจักรยานยนต์		✓																					
<b>5. ระบุตำแหน่ง</b>																							
ดาวเทียมนำทางทั่วโลก	✓	✓	✓	✓	✓	✓	✓	✓								✓	✓	✓					✓
<b>6. เทคนิคที่ใช้</b>																							
6.1 กำหนดค่าเทรสโฮลด์	✓		✓														✓						
6.2 สูตรคำนวณที่ผู้วิจัยสร้างขึ้น				✓	✓		✓																
6.3 โครงข่ายประสาทเทียม						✓																	
6.4 ต้นไม้ตัดสินใจ								✓															
6.5 ซัพพอร์ตเวกเตอร์แมชชีน	✓								✓														
6.6 วิธีการเพื่อนบ้านใกล้ที่สุด																			✓				
6.7 การประมวลผลภาพ									✓	✓	✓	✓					✓	✓					
6.8 ตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน													✓	✓	✓	✓							✓
6.9 ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า																			✓	✓	✓	✓	✓
6.10 การเรียนรู้เชิงลึกหลายรูปแบบ																							✓
<b>7. การประเมินผล</b>																							
ค่าความแม่นยำ (Accuracy)	92	78	90	-	-	90	100	95	100	86	81	93	92	93	94	97	82	60-100					✓
ค่าความแม่นยำ (Precision) และค่าความระลึก (Recall)																			75				✓
ค่าเอฟ (F1-score)																				52.8			✓
ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean average precision: mAP)																					89		✓



จากการทบทวนงานวิจัยที่เกี่ยวข้องสรุปได้ 3 ประเด็น เพื่อนำมาใช้เป็นแนวทางในการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ดังนี้

**ประเด็นที่ 1** การตรวจจับสภาพพื้นผิวถนนด้วยวิธีวัดแรงสั่นสะเทือน (Vibration-based Methods) โดยใช้เครื่องรับรู้มาตรฐานความเร่ง (Accelerometer Sensor) ในโทรศัพท์สมาร์ทโฟนที่ถูกติดตั้งไว้ในรถและส่วนต่าง ๆ ของรถ พบว่า งานวิจัยที่ผ่านมาทำการตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อ (Pothole) เนินชะลอความเร็ว (Speed Bump) รอยต่อถนน (Gaps) ทางข้ามรางรถไฟ ฝาท่อระบายน้ำ และผิวขรุขระเป็นคลื่นคล้ายลูกกระนาค (Corrugation) โดยใช้ขั้นตอนวิธีและเทคนิคที่ใช้จำแนกสภาพพื้นผิวถนน คือ การสกัดคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนในแต่ละแกน จากนั้นกำหนดค่าเทรชโฮล (Threshold-based Method) ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน และใช้การเรียนรู้ของเครื่อง (Machine Learning-based Method) เพื่อจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ผลที่ได้จากการจำแนกสภาพพื้นผิวถนนยังคงถูกจำกัดด้วยเครื่องรับรู้รูปแบบเดียวและความถูกต้องในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีวัดแรงสั่นสะเทือนขึ้นอยู่กับวิธีการสกัดคุณลักษณะด้วยมือ ยิ่งไปกว่านั้นผลลัพธ์ในการจำแนกสภาพพื้นผิวถนนที่ผิดพลาด พบว่า มีหลายเหตุการณ์ที่ไม่ได้เป็นความผิดปกติของถนน เช่น รอยต่อถนน ฝาท่อระบายน้ำที่ต่างระดับกับผิวถนน ลูกกระนาคหรือยางชะลอความเร็ว เหตุการณ์เหล่านี้แตกต่างจากสภาพถนนที่เป็นหลุมบ่อ ยิ่งไปกว่านั้นหลุมบ่อในกลางช่องจราจรยังไม่สามารถตรวจพบได้ โดยการใช้ข้อมูลจากเครื่องรับรู้มาตรฐานความเร่งเพียงอย่างเดียวเนื่องจากไม่มีการตกกระทบของล้อรถ (Eriksson et al., 2008, pp. 34-37; Chugh, Bansal, and Sofat, 2014, p. 600) ดังแสดงในรูปที่ 2.23



รูปที่ 2.23 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีวัดแรงสั่นสะเทือน

**ประเด็นที่ 2** การตรวจจับสภาพพื้นผิวถนนด้วยวิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) โดยใช้ข้อมูลรูปภาพจากกล้องเพียงอย่างเดียว พบว่า งานวิจัยที่ผ่านมาได้ตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อ (Pothole) รอยแตก (Crack) และรอยปะ (Patch) โดยใช้วิธีการประมวลผลภาพ (Image Processing) เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) เพื่อจำแนกสภาพพื้นผิวถนนที่ผิดปกติ อย่างไรก็ตาม ภาพถ่ายพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงอาจส่งผลกระทบต่อความถูกต้องในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกบนผิวถนน (Koch and Brilakis, 2011, p. 512; Kim and Ryu, 2014, p. 604; Jo and Ryu, 2015, p. 29329) ดังแสดงในรูปที่ 2.24 ดังนั้น ขั้นตอนวิธีที่มีประสิทธิภาพควรมีการพัฒนาให้จำแนกสภาพพื้นผิวถนนที่ผิดปกติได้อย่างถูกต้องมากขึ้น




**รูปที่ 2.24** การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการพื้นฐานจากการมองเห็น

**ประเด็นที่ 3** ปัจจุบันการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Networks) เป็นขั้นตอนวิธีที่สามารถเรียนรู้และคำนวณหาคุณลักษณะพิเศษของรูปภาพและจำแนกประเภทข้อมูลแบบอัตโนมัติโดยไม่จำเป็นต้องใช้วิธีการสกัดคุณลักษณะพิเศษด้วยมือ แม้ว่าการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสามารถเรียนรู้และคำนวณหาคุณลักษณะพิเศษของรูปภาพที่มีประสิทธิภาพมากขึ้น แต่ในทางกลับกัน ส่งผลให้

กระบวนการเรียนรู้ใช้เวลาและต้องการชุดข้อมูลเป็นจำนวนมาก ด้วยเหตุนี้ การถ่ายโอนการเรียนรู้ (Transfer Learning) จึงถูกนำมาประยุกต์ใช้ผ่านตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) ซึ่งเป็นการปรับปรุงการเรียนรู้ในงานใหม่ผ่านการถ่ายทอดความรู้จากตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า ส่งผลให้ประหยัดเวลาในการเรียนรู้และไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมาก ยิ่งไปกว่านั้นตัวแบบที่ถูกฝึกมาแล้วล่วงหน้ายังมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น (Torrey, and Shavlik, 2010)

ดังนั้น งานวิจัยนี้จึงศึกษาการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้อัลตราซาวด์แบบต้นทุนต่ำในโทรศัพท์สมาร์ทโฟน ดังแสดงในกรอบแนวคิดการวิจัยรูปที่ 2.25



รูปที่ 2.25 กรอบแนวคิดในการวิจัย

จากรูปที่ 2.25 งานวิจัยนี้ศึกษาแนวคิดและทฤษฎีที่เกี่ยวข้องที่ประกอบด้วย แนวคิดเกี่ยวกับสภาพพื้นผิวถนน แนวคิดเกี่ยวกับวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ แนวคิดเกี่ยวกับการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึกและการเรียนรู้เชิงลึกหลายรูปแบบ แนวคิดเกี่ยวกับการตรวจจับวัตถุ และแนวคิดเกี่ยวกับขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เพื่อใช้เป็นแนวทางในการออกแบบและพัฒนาขั้นวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำในโทรศัพท์สมาร์ตโฟน

โดยทำการพัฒนาแอปพลิเคชันในการเก็บรวบรวมข้อมูลรูปภาพของสภาพพื้นผิวถนนและค่าอัตราเร่งของแรงสั่นสะเทือนบนโทรศัพท์สมาร์ตโฟน แล้วจัดเตรียมข้อมูลเพื่อสร้างชุดข้อมูลสำหรับเรียนรู้และทดสอบ จากนั้นออกแบบและสร้างตัวแบบสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) เพื่อใช้ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ แล้วออกแบบและสร้างตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolutional Neural Network: Multimodal DCNN) เพื่อใช้จำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนซึ่งตัวแบบ Multimodal DCNN นี้ใช้เพื่อเพิ่มความแม่นยำในขั้นตอนตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ จากนั้นทำการประเมินตัวแบบและขั้นตอนวิธี เพื่อสร้างระบบอัตโนมัติในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ได้แก่ หลุมบ่อ รอยแตกตามแนวยาว รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ รอยปะช่อม รวมทั้งลักษณะสภาพพื้นผิวถนนที่ไม่ได้เป็นความผิดปกติของถนน ได้แก่ เนินชะลอความเร็วและถนนปกติที่มักมีการจำแนกลักษณะสภาพพื้นผิวถนนเป็นประเภทหลุมบ่อ อีกทั้งลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมตามธรรมชาติที่มีความไม่แน่นอนและแปรปรวนสูงที่ส่งผลต่อความถูกต้องในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน

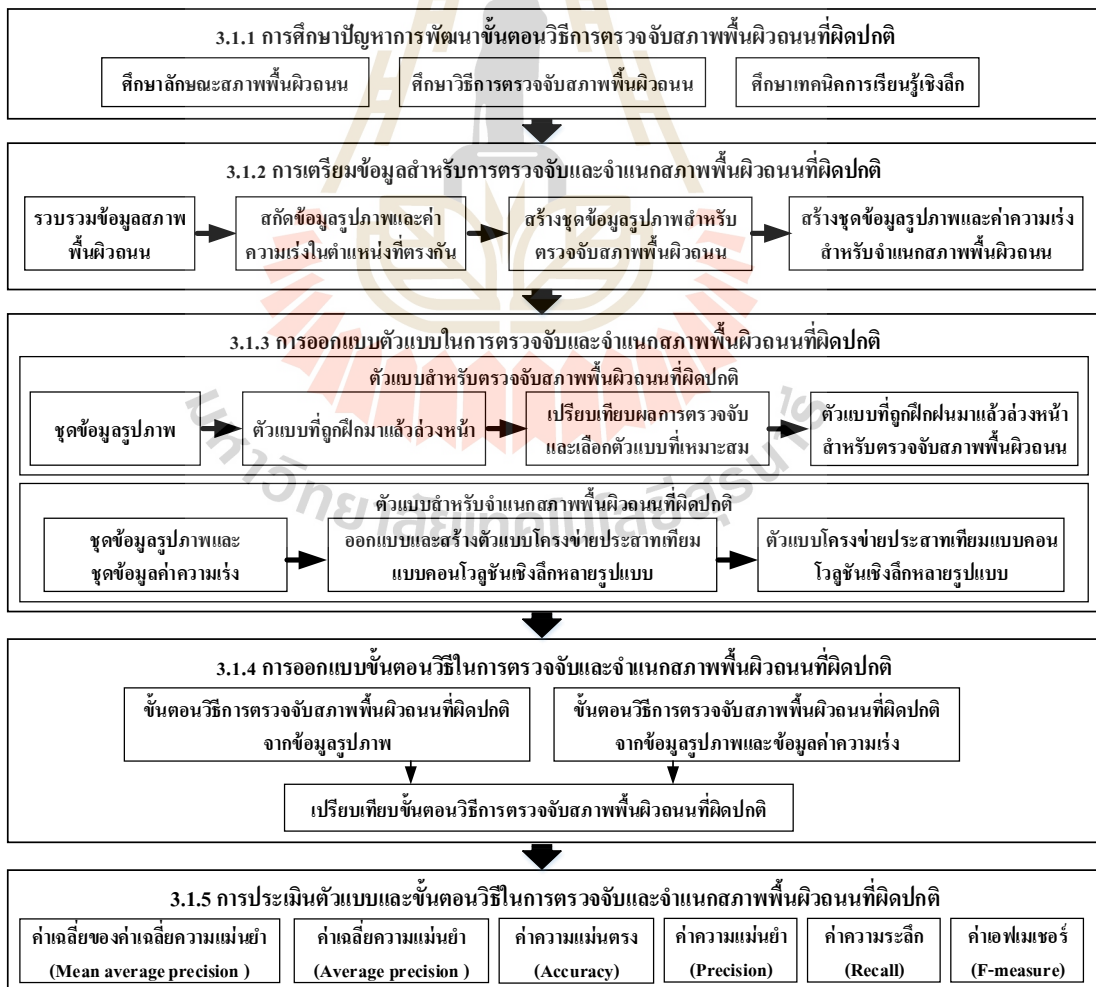
# บทที่ 3

## วิธีดำเนินการวิจัย

ในบทนี้กล่าวถึงวิธีดำเนินการวิจัย ประกอบด้วย วิธีวิจัย เครื่องมือที่ใช้ในการวิจัย การเก็บรวบรวมข้อมูล และการวิเคราะห์ข้อมูล โดยมีรายละเอียดดังนี้

### 3.1 วิธีวิจัย

งานวิจัยนี้เป็นงานวิจัยเชิงประยุกต์ (Applied Research) ที่มุ่งนำผลการวิจัยไปใช้ประโยชน์ในด้านการตรวจสุขภาพพื้นผิวดนที่ผิดปกติ ผลที่ได้จากงานวิจัยเชิงประยุกต์สามารถนำไปใช้ปรับปรุงขั้นตอนวิธีในการตรวจสุขภาพพื้นผิวดนที่ผิดปกติให้มีความถูกต้องมากขึ้น มีขั้นตอนการดำเนินงาน ดังแสดงในรูปที่ 3.1



รูปที่ 3.1 วิธีวิจัย

จากรูปที่ 3.1 ขั้นตอนการดำเนินงาน ประกอบด้วย 1) การศึกษาปัญหาการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ 2) การเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ 3) การออกแบบตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ 4) การออกแบบขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ และ 5) การประเมินตัวแบบและขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ โดยมีรายละเอียด ดังนี้

### 3.1.1 การศึกษาปัญหาการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนน

เป็นขั้นตอนในการกำหนดปัญหาและศึกษาความเป็นไปได้เพื่อวางแผนในการพัฒนาขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยศึกษาหลักการ ทฤษฎี เอกสารและงานวิจัยที่เกี่ยวข้อง ในงานวิจัยนี้ศึกษาปัญหาและขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ประกอบด้วย 1) ศึกษาลักษณะสภาพพื้นผิวถนน 2) ศึกษาวิธีการตรวจจับสภาพพื้นผิวถนน และ 3) ศึกษาเทคนิคการเรียนรู้เชิงลึก มีรายละเอียด ดังนี้

#### 1) ศึกษาลักษณะสภาพพื้นผิวถนน

เป็นการศึกษาลักษณะความเสียหายของสภาพพื้นผิวถนนที่กำหนดโดยสำนักบริหารบำรุงทาง กรมทางหลวง กระทรวงคมนาคม (กรมทางหลวง, 2550, หน้า 4-70) และงานวิจัยที่ผ่านมาสามารถตรวจจับลักษณะความเสียหายของพื้นผิวถนน โดยใช้ข้อมูลจากเครื่องรับรู้ มาตรการความเร่งและรูปภาพจากกล้องในโทรศัพท์สมาร์ทโฟน (Coenen and Golroo, 2017, p. 18) สำหรับงานวิจัยนี้ เลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่เหมาะสมที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด เมื่อทดสอบบนชุดข้อมูลสภาพพื้นผิวถนนที่ผิดปกติ จำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) จากนั้นนำผลการตรวจจับมาเพิ่มความแม่นยำด้วยการจำแนกสภาพพื้นผิวถนนใหม่โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks: Multimodal DCNN) จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน ซึ่งเป็นการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ จำนวน 7 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal Road) ตามลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงที่ส่ง



ผลกระทบต่อความแม่นยำในการตรวจจับสภาพพื้นผิวถนน เช่น เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน

## 2) ศึกษาวิธีการตรวจจับสภาพพื้นผิวถนน


เป็นการศึกษาวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากงานวิจัยที่ผ่านมาซึ่งมีเทคนิค วิธีการแบบอัตโนมัติที่หลากหลายและแตกต่างกันตามลักษณะทางกายภาพของถนนในแต่ละประเทศ ในงานวิจัยนี้จำแนกวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติออกเป็น 6 วิธี ได้แก่ 1) วิธีการวัดแรงสั่นสะเทือน (Vibration-based Methods) 2) วิธีการใช้เครื่องรับรู้วัตถุแบบสามมิติ (3D Sensor-based Methods) 3) วิธีการพื้นฐานจากการมองเห็น (Vision-based Methods) 4) วิธีการวัดคลื่นเสียงความถี่สูง (Ultrasonic-based Methods) 5) วิธีการวัดเสียง (Audio-based Methods) และ 6) วิธีการใช้ข้อมูลหลายรูปแบบ (Multimodal data-based Methods) สำหรับงานวิจัยนี้เลือกใช้วิธีการพื้นฐานจากการมองเห็นเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและวิธีการใช้ข้อมูลหลายรูปแบบเพื่อเพิ่มความถูกต้องในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

## 3) ศึกษาเทคนิคการเรียนรู้เชิงลึก

เป็นการศึกษาเทคนิคการเรียนรู้เชิงลึก ประกอบด้วย 1) โครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชัน (Deep Convolutional Neural Networks) 2) ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained models) และ 3) โครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolutional Neural Networks: Multimodal DCNN) เพื่อสร้างตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า และเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

### 3.1.2 การเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนน

เป็นขั้นตอนในการเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ดังแสดงในรูปที่ 3.2 มีรายละเอียดดังนี้



รูปที่ 3.2 ขั้นตอนการเตรียมข้อมูลสำหรับการตรวจจับและจำแนกสภาพพื้นผิวถนน

### 1) รวบรวมข้อมูลสภาพพื้นผิวถนนจากแอปพลิเคชันที่ถูกพัฒนาขึ้น

งานวิจัยนี้ออกแบบและพัฒนาแอปพลิเคชันบนระบบปฏิบัติการแอนดรอยด์ เพื่อเก็บรวบรวมข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนจากโทรศัพท์มือถือรุ่น Samsung Galaxy A9 Pro (2016) กล้องถ่ายภาพความละเอียด 16 ล้านพิกเซล ซึ่งมีขนาดภาพในการบันทึกภาพวิดีโอเท่ากับ  $1920 \times 1080$  พิกเซล (Pixels) อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความเร็วในการจัดเก็บภาพเท่ากับ 80 Hz ดังแสดงในรูปที่ 3.3 และรูปที่ 3.4



รูปที่ 3.3 หน้าจอบันทึกข้อมูลภาพวิดีโอและค่าอัตราเร่งของแรงสั่นสะเทือน



รูปที่ 3.4 ตำแหน่งติดตั้งโทรศัพท์สมาร์ทโฟนบนคอนโซลหน้ารถ


จากรูปที่ 3.3 แสดงหน้าจอบันทึกข้อมูลภาพวิดีโอและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากโทรศัพท์สมาร์ทโฟนที่ถูกติดตั้งไว้ตรงกลางคอนโซลหน้ารถดังแสดงในรูปที่ 3.4 ด้านบนของโทรศัพท์สมาร์ทโฟนหันไปทางด้านซ้ายของตัวรถ กล้องในโทรศัพท์สมาร์ทโฟนหันไปทางทิศทางการเดินทางของรถเพื่อให้มุมมองที่แสดงสภาพพื้นผิวถนนที่ชัดเจน ดังนั้นค่าอัตราเร่งของแรงสั่นสะเทือนของทั้ง 3 แกน ประกอบด้วย

แกน X คือ ทิศทางที่ตั้งฉากกับตัวรถแสดงการเคลื่อนที่ของรถในแนวขึ้นลง ซึ่งค่าอัตราเร่งของแรงสั่นสะเทือนตามแนวแกน X นี้มีค่าตามแนวแรงโน้มถ่วงของโลกที่มีค่าประมาณ  $9.8 \text{ m/s}^2$

แกน Y คือ ทิศทางที่แสดงการเคลื่อนที่ในแนวด้านข้างซ้ายขวาของตัวรถ

แกน Z คือ ทิศทางที่พุ่งไปข้างหน้าตามทิศทางการเคลื่อนที่ไปข้างหน้าของรถ แสดงการเคลื่อนที่ในแนวหน้าหลังของรถ

ขั้นตอนการใช้งานแอปพลิเคชันบันทึกข้อมูลสภาพพื้นผิวถนนบนระบบปฏิบัติการแอนดรอยด์ มีขั้นตอนดังนี้ เปิดแอปพลิเคชันบันทึกข้อมูลสภาพพื้นผิวถนน จากนั้นโปรแกรมจะแสดงหน้าจอดังรูปที่ 3.5 ให้ทำการตั้งค่าเริ่มต้นของระบบ โดยกดที่ปุ่มเลือกความละเอียดของภาพ ปุ่มเลือกอัตราเฟรมในการจัดเก็บภาพ และปุ่มเลือกความถี่ในการจัดเก็บภาพที่ต้องการ สำหรับงานวิจัยนี้ กำหนดค่าเริ่มต้นของระบบ ดังนี้ ความละเอียดของภาพเท่ากับ 1080p นั่นคือ ขนาดภาพจะมีค่าเท่ากับ  $1920 \times 1080$  พิกเซล อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความถี่ในการจัดเก็บภาพเท่ากับ 80 Hz จากนั้นเมื่อต้องการบันทึกข้อมูลสภาพพื้นผิวถนนให้กดปุ่มบันทึกข้อมูล จากนั้นโปรแกรมจะทำการบันทึกข้อมูลวิดีโอและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนไว้ในอุปกรณ์เก็บข้อมูล (SD Card) ของโทรศัพท์สมาร์ทโฟน




รูปที่ 3.5 แอปพลิเคชันบันทึกข้อมูลสภาพพื้นผิวถนน

ข้อมูลถูกเก็บรวบรวมผ่านแอปพลิเคชันบนระบบปฏิบัติการแอนดรอยด์ ประกอบด้วย วันที่ เวลา (DateTime) ละติจูด (Latitude) ลองจิจูด (Longitude) ทิศทาง (Heading) ความเร็ว (Speed) ค่าอัตราเร่งของแรงสั่นสะเทือนในแกน X ค่าอัตราเร่งของแรงสั่นสะเทือนในแกน Y ค่าอัตราเร่งของแรงสั่นสะเทือนในแกน Z ซึ่งถูกบันทึกลงในไฟล์ .csv ดังแสดงตัวอย่างในตารางที่ 3.1 และข้อมูลวิดีโอถูกบันทึกข้อมูลลงในไฟล์ .mp4 ดังแสดงในรูปแบบที่ 3.6 เพื่อนำไปประมวลผลต่อไป

ตารางที่ 3.1 ตัวอย่างข้อมูลที่บันทึกในไฟล์ .csv

DateTime	Latitude	Longitude	Heading	Speed	Acc X	Acc Y	Acc Z
16/10/2016	14.88364762	102.0240792	59	7.13	10.17416	0.89423436	-0.9995792
16/10/2016	14.88364762	102.0240792	59	7.13	10.475829	0.33877954	-1.2916719
16/10/2016	14.88364762	102.0240792	61	7.13	9.417592	0.38187516	-1.3587095
16/10/2016	14.88364762	102.0240792	62	7.13	8.124723	0.7074866	-1.5885528
16/10/2016	14.88364762	102.0240792	59	7.13	11.22282	0.30047232	-1.62686
16/10/2016	14.88364762	102.0240792	57	7.13	9.853337	-0.09935937	-0.7170634
16/10/2016	14.88364762	102.0240792	58	7.13	9.163807	0.34835634	-0.6931214
16/10/2016	14.88364762	102.0240792	60	7.13	9.2069025	0.8415619	-0.7697359
16/10/2016	14.88364762	102.0240792	60	7.13	9.96347	0.7505822	-1.3395559
16/10/2016	14.88364762	102.0240792	58	7.13	9.508572	0.44891283	-0.94211835
16/10/2016	14.88367693	102.0241544	58	8.14	9.929952	0.027533319	-1.4879963
16/10/2016	14.88367693	102.0241544	58	8.14	10.696096	0.5638345	-1.8567034






รูปที่ 3.6 ภาพวิดีโอลักษณะสภาพพื้นผิวถนนที่บันทึกในไฟล์ .mp4

## 2) การสกัดชุดข้อมูลรูปภาพและชุดข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้อยู่ในตำแหน่งที่ใกล้เคียงกัน

เนื่องจากขั้นตอนการเก็บรวบรวมข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของแต่ละสภาพพื้นผิวถนน ข้อมูลที่ได้รับยังไม่อยู่ในตำแหน่งที่ตรงกันเพราะว่าข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนอยู่ ณ ตำแหน่งของรถ ส่วนข้อมูลรูปภาพอยู่ในตำแหน่งที่ห่างจากรถไปประมาณ 6.5 เมตร ซึ่งเป็นระยะที่สามารถมองเห็นสภาพพื้นผิวถนนได้ชัดเจน ดังนั้นจึงต้องคำนวณหาเวลาที่บวกเพิ่มจากเวลาที่ดึงรูปภาพ โดยใช้สูตรการเคลื่อนที่ในอัตราเร่งคงที่ (การเคลื่อนที่ในแนวตรง) เพื่อให้โปรแกรมสกัดข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนกับข้อมูลรูปภาพให้อยู่ในตำแหน่งที่ใกล้เคียงกัน ดังรูปที่ 3.7 และสมการที่ 3.1



รูปที่ 3.7 ตำแหน่งการเก็บข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลรูปภาพวิดีโอ

$$s = ut + \frac{1}{2} at^2 \quad (3.1)$$

เมื่อ  $s$  = ระยะทางที่เคลื่อนที่ (m)  
 $u$  = ความเร็ว ณ เวลาใด ๆ (m/s)  
 $a$  = ความเร่ง (ขับรถด้วยความเร็วคงที่  $a = 0$ )  
 $t$  = เวลา (s)

ตัวอย่างเช่น ในขณะที่บันทึกข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลภาพวิดีโอลักษณะสภาพพื้นผิวถนนที่ผิดปกติ รถวิ่งด้วยความเร็ว 40 กิโลเมตร/ชั่วโมง กำหนดระยะทาง 6.5 เมตร ซึ่งเป็นจุดที่สนใจบริเวณพื้นที่ที่ต้องการตรวจสภาพพื้นผิวถนน จะใช้ระยะเวลากี่วินาที เพื่อให้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและข้อมูลภาพอยู่ในตำแหน่งที่ตรงกัน


ระยะทางในการเคลื่อนที่ คือ  $s = 6.5$  เมตร  
 ความเร็วเริ่มต้น คือ  $u = (40 \times 1000) / 3,600$  (แปลงให้เป็นหน่วย เมตร/วินาที)  
 $= 11.11$  เมตร/วินาที  
 แทนค่า  $6.5 = 11.11 \times t + ((1/2) \times 0 \times t^2)$   
 $t = 0.5850$  วินาที

ดังนั้น ต้องบวกเวลาเพิ่มอีก 0.5850 วินาที เพื่อให้รูปภาพและค่าความเร่งอยู่ในตำแหน่งที่ตรงกัน

โปรแกรมจะทำการสกัดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน โดยดึงข้อมูลรูปภาพในทุก ๆ 1 วินาที และปรับลดขนาดรูปภาพลงครึ่งหนึ่งจากความละเอียดเท่ากับ 1920 x 1080 พิกเซล ให้มีความละเอียดเท่ากับ 960 x 540 พิกเซล (Pixels) เพื่อให้มีขนาดที่เหมาะสมประมวลผลได้เร็วขึ้น จากนั้นบันทึกไฟล์รูปภาพให้อยู่ในรูปแบบไฟล์ .jpg

จากนั้นสกัดข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อให้รูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนอยู่ในตำแหน่งที่ใกล้เคียงกันโดยการบวกเวลาเพิ่ม  $t$  วินาทีนั้น ในงานวิจัยนี้ใช้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนทั้งก่อนและหลัง  $\pm 2$  วินาที ของเวลาที่ตรงกัน ( $t$ ) นั่นคือใช้เวลาที่  $t+2, t+1, t, t-1, t-2$  เพื่อให้ได้รับช่วงของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนในแต่ละประเภทของสภาพพื้นผิวถนนที่ครบถ้วนสมบูรณ์ ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของแต่ละรูปภาพสภาพพื้นผิวถนนมีค่าเท่ากับ 1,200 ค่า ( $3 \times 80 \times 5$ ) ซึ่งได้มาจากข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของทั้ง 3 แกน (X, Y และ Z) ซึ่งแต่ละแกนมีความถี่ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเท่ากับ 80 Hz และใช้ข้อมูล 5 ช่วงเวลา ( $t+2, t+1, t, t-1, t-2$ ) จากนั้นบันทึกข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้อยู่ในรูปแบบไฟล์ .csv ดังนั้น ไฟล์รูปภาพ 1 ไฟล์จะมีไฟล์ค่าอัตราเร่งของแรงสั่นสะเทือน 1 ไฟล์ควบคู่กัน ดังรูปที่ 3.8







รูปที่ 3.8 ตัวอย่างไฟล์รูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนที่ผ่านการสกัดข้อมูลให้อยู่ในตำแหน่งที่ใกล้เคียงกัน

3) การสร้างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนน

เป็นการนำไฟล์ข้อมูลรูปภาพจากขั้นตอนที่ 2 มาระบุสภาพพื้นผิวถนนในแต่ละประเภทโดยใช้โปรแกรม LabelImg (Tzutalin, 2019) โดยมีขั้นตอนการสร้างชุดข้อมูลรูปภาพดังรูปที่ 3.9



รูปที่ 3.9 ขั้นตอนการสร้างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนน



รูปที่ 3.10 โปรแกรม LabelImg สำหรับระบุสภาพพื้นผิวถนน

จากรูปที่ 3.9 ขั้นตอนการสร้างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนน โดยนำรูปภาพที่ต้องการระบุสภาพพื้นผิวถนน เข้าโปรแกรม LabelImg ดังแสดงในรูปที่ 3.10 จากนั้นติกรอบล้อมรอบวัตถุที่ต้องการตรวจจับ (Bounding box) แล้วระบุประเภทสภาพพื้นผิวถนน ใน 6 ประเภทและบันทึกให้อยู่ในรูปแบบไฟล์ eXtensible Markup Language (XML) ในแต่ละภาพ ดังแสดงในรูปที่ 3.11 ไฟล์ XML ประกอบด้วยพิกัดของสี่เหลี่ยมปิดล้อมวัตถุ ชื่อไฟล์ภาพ ข้อมูลประเภทของสภาพพื้นผิวถนน และข้อมูลอื่น ๆ เป็นต้น จากนั้นส่งผลการระบุสภาพพื้นผิวถนน ด้วยโปรแกรม LabelImg ให้ผู้เชี่ยวชาญตรวจสอบจำนวน 3 ท่าน เพื่อตรวจสอบความถูกต้อง ในการระบุสภาพพื้นผิวถนน ก่อนนำไฟล์ที่ได้ไปใช้สร้างชุดข้อมูลสำหรับเรียนรู้และทดสอบต่อไป

```

<annotation>
  <folder>images</folder>
  <filename>video-1550036661_150.jpg</filename>
  <path>/DatasetRoad/images/video-1550036661_150.jpg</path>
  <source>
    <database>Unknown</database>
  </source>
  <size>
    <width>960</width>
    <height>540</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
  <object>
    <name>alligatorCrack</name>
    <bndbox>
      <xmin>298</xmin>
      <ymin>438</ymin>
      <xmax>519</xmax>
      <ymax>516</ymax>
    </bndbox>
  </object>
</annotation>

```

รูปที่ 3.11 ไฟล์โครงสร้าง XML ของภาพที่ใช้ในการสร้างชุดข้อมูลเรียนรู้และทดสอบ

ชุดข้อมูลเรียนรู้และทดสอบจำเป็นต้องสร้างไฟล์ระบุมแผนที่ป้ายกำกับ (Label Map) ที่เกี่ยวข้องกับชุดข้อมูลนั้น เพื่อทำหน้าที่เป็นตัวแปลงชื่อของประเภทสภาพพื้นผิวถนน (Label Name) เป็นรหัสตัวเลข (Numeric id) งานวิจัยนี้ใช้ประเภทสภาพพื้นผิวถนนจำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง 4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม 6) เนินชะลอความเร็ว/เส้นชะลอความเร็ว โครงสร้างของไฟล์ระบุมแผนที่ป้ายกำกับที่ต้องการตรวจจับสภาพพื้นผิวถนนในงานวิจัยนี้แสดงดังรูปที่ 3.12

<pre> item {   id: 1   name: 'pothole' } item {   id: 2   name: 'patch' } item {   id: 3   name: 'longCrack' } </pre>	<pre> item {   id: 4   name: 'lateralCrack' } item {   id: 5   name: 'alligatorCrack' } item {   id: 6   name: 'speedBump' } </pre>
---	---

รูปที่ 3.12 โครงสร้างของไฟล์ระบุมแผนที่ป้ายกำกับที่ต้องการตรวจจับสภาพพื้นผิวถนน

การตรวจจับวัตถุในภาพด้วยเทนเซอร์โฟล (TensorFlow Object Detection API) ต้องการชุดข้อมูลที่อยู่ในรูปแบบไฟล์ TFRecord ซึ่งช่วยเพิ่มประสิทธิภาพในการอ่านข้อมูลไฟล์รูปภาพนำเข้าเพื่อนำไปใช้ในกระบวนการสอนตัวแบบ ดังนั้น ขั้นตอนต่อไปจึงต้องนำเข้าข้อมูลรูปภาพแล้วอ่านข้อมูลตามโครงสร้างในไฟล์ XML ในแต่ละรูปภาพ จากนั้นแปลงชุดข้อมูลทั้งหมดให้เป็นรูปแบบไฟล์ TFRecord โดยในงานวิจัยนี้แบ่งข้อมูลออกเป็นชุดข้อมูลการเรียนรู้เป็นจำนวน 70% (Training Dataset) และชุดข้อมูลทดสอบเป็นจำนวน 30% (Testing Dataset) ผลลัพธ์จากการสร้างไฟล์ TFRecord คือ ไฟล์ train.record เพื่อใช้เป็นชุดข้อมูลการเรียนรู้และ test.record เพื่อใช้เป็นชุดข้อมูลทดสอบ

#### 4) การสร้างชุดข้อมูลรูปภาพสำหรับจำแนกสภาพพื้นผิวถนน

ทำการตัดภาพเฉพาะวัตถุลักษณะสภาพพื้นผิวถนนของแต่ละประเภทเพื่อจัดเก็บข้อมูลรูปภาพวัตถุในโฟลเดอร์ตามประเภทของสภาพพื้นผิวถนนทั้ง 7 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง 4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม 6) เนินชะลอความเร็ว/เส้นชะลอความเร็ว และ 7) ถนนปกติ จากนั้นสุ่มผลการระบุสภาพพื้นผิวถนนให้ผู้เชี่ยวชาญตรวจสอบจำนวน 3 ท่าน เพื่อตรวจสอบความถูกต้องในการระบุสภาพ

พื้นผิวถนนแต่ละประเภท ก่อนนำไปสร้างชุดข้อมูลเรียนรู้และทดสอบ (Training and Testing Dataset) ที่ประกอบด้วย ข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับใช้จำแนกสภาพพื้นผิวถนนต่อไป

ในระหว่างการอ่านชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อสร้างตัวแบบจำแนกสภาพพื้นผิวถนน งานวิจัยนี้ใช้วิธีการแปลงข้อมูล (Data Transformation) โดยการทำนอร์มอลไลซ์ (Normalization) ด้วยเทคนิค Min-Max Normalization เพื่อปรับข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้มีความแตกต่างที่น้อยลงและประมวลผลได้เร็วขึ้น ดังสมการที่ 3.2

$$A = \frac{a - Min}{Max - Min} \quad (3.2)$$

เมื่อ  $A$  = ผลลัพธ์ที่ได้จากการแปลงข้อมูล

$a$  = ข้อมูลที่ต้องการแปลงข้อมูล

$Min$  = ข้อมูลที่มีค่าน้อยที่สุด

$Max$  = ข้อมูลที่มีค่ามากที่สุด

สำหรับข้อมูลรูปภาพทำการปรับขนาดให้มีขนาดเท่ากับ  $299 \times 299$  พิกเซล เพื่อให้รูปภาพนำเข้ามีขนาดที่เท่ากันทุกรูป จากนั้นจึงนำข้อมูลแต่ละพิกเซลของรูปภาพไปแปลงข้อมูลตัวอย่างเช่น ข้อมูลรูปภาพในพิกเซลนั้นมีค่าเท่ากับ 225 ข้อมูลรูปภาพที่มีค่าน้อยที่สุดเท่ากับ 0 และข้อมูลรูปภาพที่มีค่ามากที่สุดเท่ากับ 255

ดังนั้น

$$A = (255 - 0) / (255 - 0) \\ = 0.882352$$

ส่วนข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนแต่ละค่านำไปแปลงข้อมูล ตัวอย่างเช่น ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน มีค่าเท่ากับ 11.7018374 ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่มีค่าน้อยที่สุดในงานวิจัยนี้มีค่าเท่ากับ -18.553865 และข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่มีค่ามากที่สุดในงานวิจัยนี้มีค่าเท่ากับ 36.83599

ดังนั้น

$$A = (11.7018374 - (-18.553865)) / (36.83599 - (-18.553865)) \\ = 0.546231$$

### 3.1.3 การออกแบบตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนน

ในงานวิจัยนี้ออกแบบกระบวนการเรียนรู้เชิงลึกที่ประกอบด้วย 1) ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) เพื่อใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติซึ่งเป็นการถ่ายโอนการเรียนรู้และปรับปรุงการเรียนรู้ในงานใหม่ ส่งผลให้ประหยัดเวลาในการเรียนรู้ ไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมากและมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น 2) ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolutional Neural Network) เพื่อใช้เพิ่มความแม่นยำในการจำแนกข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน ซึ่งเป็นการถ่ายทอดความรู้ที่เกี่ยวข้องกันในเวลาเดียวกัน โดยนำความสัมพันธ์ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนมาช่วยในการรับรู้ข้อมูลรูปภาพและนำข้อมูลรูปภาพมาช่วยในการรับรู้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน มีโครงสร้างการออกแบบสถาปัตยกรรมในแต่ละตัวแบบ ดังนี้

#### 1) การออกแบบตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (Object detection model) ด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model)

ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า (Pretrained Model) ถูกพัฒนามาจากเทนเซอร์โฟล (TensorFlow) ซึ่งเป็นไลบรารีโอเพ่นซอร์สสำหรับงานด้านการตรวจจับวัตถุ งานวิจัยนี้ใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) สูงสุดจำนวน 5 ลำดับแรก บนชุดข้อมูลรูปภาพของโคโค (COCO Dataset) (Pikulz, 2019) ดังตารางที่ 3.2 จากนั้นจึงใช้เทคนิคการถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติ จำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง 4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม และ 6) เนินชะลอความเร็ว/ เส้นชะลอความเร็ว

ตารางที่ 3.2 ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้าที่มีค่า mAP สูงสุด 5 ลำดับแรกบนชุดข้อมูลทดสอบของโคโค

ตัวแบบ	ชื่อตัวแบบ		ความเร็ว	mAP
	ตัวตรวจจับวัตถุ	ตัวสกัดคุณลักษณะ		
FRN	Faster R-CNN	NAS	1.833	43
FRIR	Faster R-CNN	Inception ResNetV2 Atrous	0.620	37
SRF	SSD	ResNet50 FPN	0.076	35
SMF	SSD	MobileNetV1 FPN	0.056	32
FRR	Faster R-CNN	ResNet101	0.106	32




การกำหนดค่าพารามิเตอร์สำหรับปรับแต่งการถ่ายโอนการเรียนรู้ใช้ตามรูปแบบข้อกำหนดใน (Pkulzc, 2019) เช่น จำนวนประเภทสภาพพื้นผิวถนนเท่ากับ 6 ประเภท ( $\text{num\_classes} = 6$ ) กำหนดจำนวนรอบในการเรียนรู้เท่ากับ 30,000 รอบ ( $\text{num\_step} = 30,000$ ) กำหนดอัตราการเรียนรู้ (Learning Rate) ตามรูปแบบข้อกำหนดของแต่ละตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า ในระหว่างการสอนตัวแบบ ผู้วิจัยทำการสังเกตค่าสูญเสียการสอน (Training Loss) ซึ่งจะค่อย ๆ ลดลงตามการเรียนรู้ในแต่ละรอบ หากการสูญเสียการสอนนั้นสูงขึ้นหรือเริ่มคงที่ ผู้วิจัยจะทำการหยุดการสอนที่รอบการสอนนั้น และกำหนดพารามิเตอร์ของไฟล์ของตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า เป็นต้น สำหรับการกำหนดค่าพารามิเตอร์อื่น ๆ ใช้ค่าตามไฟล์ต้นฉบับของแต่ละตัวแบบที่อ้างอิงใน (Pkulzc, 2019) ซึ่งเป็นการกำหนดค่าเบื้องต้นที่เหมาะสมตามโครงสร้างของตัวตรวจจับวัตถุและโครงสร้างของตัวสกัดคุณลักษณะของแต่ละตัวแบบที่ผ่านการฝึกมาแล้วแล้ว

## 2) การออกแบบตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติ (Image classification model)

การออกแบบตัวแบบจำแนกเพื่อใช้เพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ได้ออกแบบตัวแบบจำนวน 2 ตัวแบบ ได้แก่ ตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolutional Neural Network Model) จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อเลือกใช้ตัวแบบที่เหมาะสมในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ โดยมีรายละเอียด ดังนี้

การออกแบบโครงสร้างของตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ แสดงดังรูปที่ 3.13





รูปที่ 3.13 โครงสร้างของตัวแบบจำแนกสภาพพื้นผิวถนนที่ฝึกปรือจากข้อมูลรูปภาพ


จากรูปที่ 3.13 โครงสร้างของตัวแบบจำแนกสภาพพื้นผิวถนนที่ฝึกปรือจากข้อมูลรูปภาพใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าซึ่งเรียกว่า Inception-v3 ของ GoogLeNet (Szegedy et al., 2016) เพื่อใช้สกัดคุณลักษณะข้อมูลรูปภาพสภาพพื้นผิวถนนด้วยเทคนิคการถ่ายโอนการเรียนรู้ (Transfer Learning) ซึ่งเป็นการปรับปรุงการเรียนรู้ในงานใหม่ผ่านการถ่ายทอดความรู้จากตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า ส่งผลให้ประหยัดเวลาในการเรียนรู้และไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมาก ยิ่งไปกว่านั้นตัวแบบที่ถูกฝึกมาแล้วนี้ยังมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น งานวิจัยนี้ได้ทำการถ่ายทอดความรู้จากตัวแบบ Inception-v3 ที่มีทั้งหมด 22 ชั้น (Layers) เพื่อใช้สกัดคุณลักษณะข้อมูลรูปภาพ โดยป้อนข้อมูลขาเข้าที่ถูกจัดอยู่ในรูปแบบ 3 มิติ ได้แก่ ความสูง ความกว้างและความลึกที่มีขนาดเท่ากับ  $299 \times 299 \times 3$  ตามข้อกำหนดการป้อนข้อมูลเข้าของตัวแบบ Inception-v3 เมื่อข้อมูลรูปภาพผ่านการสกัดคุณลักษณะจากตัวแบบ Inception-v3 ทำให้ได้คุณลักษณะข้อมูลรูปภาพทั้งหมด 2,048 คุณลักษณะ (Features) จากนั้นจึงส่งผ่านคุณลักษณะข้อมูลรูปภาพที่ได้รับไปยังชั้นเชื่อมต่อแบบทั่วถึงในชั้นแรก (First Fully Connected Layer) เพื่อให้ตัวแบบเรียนรู้และจำแนกสภาพพื้นผิวถนน

ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 1 และ 2 (FC1 และ FC2) ของ แต่ละเซลล์ประสาท (Neuron) จะรับคุณลักษณะรูปภาพนำเข้ามาจากทุก ๆ เซลล์ประสาทในชั้นแล้วออกมาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC1 โดยกำหนดจำนวนโหนดในชั้น FC1 เท่ากับ 1,024 โหนด และชั้น FC2

เท่ากับ 512 โหนด โครงข่ายประสาทเทียมจะมีเส้นเชื่อมจากทุก ๆ โหนดในชั้น FC1 ไปยังทุก ๆ โหนดในชั้น FC2 เส้นเชื่อมแต่ละเส้นมีค่าน้ำหนัก (Weight) ที่ได้จากการปรับค่าของกระบวนการเรียนรู้เชิงลึกเพื่อการจำแนกข้อมูลคุณลักษณะรูปภาพ ในชั้น FC1 ใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้นและใช้ดรอปเอาต์ (Dropout) เท่ากับ 0.5 เพื่อป้องกันการเกิด Overfitting โดยการสุ่มปิดโหนดในเซลล์ประสาทเทียมไม่ให้ส่งข้อมูล โดยแต่ละรอบการฝึกการไหลของข้อมูลจะต่างกัน ทำให้การเรียนรู้ในแต่ละโหนดกระจายอย่างทั่วถึงไม่กระจุกตัว จากนั้นแต่ละเซลล์ประสาท ทุก ๆ เซลล์ จะเชื่อมต่อไปยังทุก ๆ เซลล์ประสาทในชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 3 ซึ่งเป็นชั้นสุดท้าย

ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 3 (FC3) ในแต่ละเซลล์ประสาทจะรับคุณลักษณะรูปภาพนำเข้าจากทุก ๆ เซลล์ประสาทในชั้น FC2 มาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC3 โดยกำหนดจำนวนโหนดในชั้น FC3 เท่ากับ 7 โหนด ซึ่งจำนวนประเภทสภาพพื้นผิวถนนที่ต้องการจำแนก ในชั้น FC3 ใช้ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function) ซึ่งเป็นฟังก์ชันกระตุ้นที่ถูกใช้ในชั้นสุดท้ายของโครงข่ายเพื่อคาดการณ์หรือทำนายประเภทข้อมูลและใช้ความน่าจะเป็นสูงสุดเป็นคำตอบสุดท้าย

การออกแบบโครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ โดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อสกัดคุณลักษณะข้อมูลรูปภาพและโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันเพื่อสกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน จากนั้นจึงหลอมรวมคุณลักษณะข้อมูลทั้งสองเข้าด้วยกันในชั้นการเชื่อมต่อแบบทั่วถึงและจำแนกคุณลักษณะข้อมูลเพื่อทำนายสภาพพื้นผิวถนน แสดงดังรูปที่ 3.14



รูปที่ 3.14 โครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

จากรูปที่ 3.14 ส่วนบน เป็น โครงสร้างของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า ที่เรียกว่า Inception-v3 ของ GoogLeNet (Szegedy et. al., 2016) เพื่อใช้สกัดคุณลักษณะข้อมูลรูปภาพ สภาพพื้นผิวถนนด้วยเทคนิคการถ่ายโอนการเรียนรู้ (Transfer Learning) ซึ่งเป็นการปรับปรุง การเรียนรู้ในงานใหม่ผ่านการถ่ายทอดความรู้จากตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้า ส่งผลให้ ประหยัดเวลาในการเรียนรู้และไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมาก ยิ่งไปกว่านั้น ตัวแบบที่ถูกฝึกมาแล้วนี้ยังมีประสิทธิภาพที่ดีกว่าตัวแบบทั่วไปที่ถูกสร้างขึ้นมาเองตั้งแต่ เริ่มต้น งานวิจัยนี้ได้ทำการถ่ายทอดความรู้จากตัวแบบ Inception-v3 ที่มีทั้งหมด 22 ชั้น (Layers) เพื่อใช้สกัดคุณลักษณะข้อมูลรูปภาพ โดยป้อนข้อมูลขาเข้าที่ถูกจัดอยู่ในรูปแบบ 3 มิติ ได้แก่ ความสูง ความกว้างและความลึกที่มีขนาดเท่ากับ  $299 \times 299 \times 3$  ตามข้อกำหนดการป้อนข้อมูลเข้า ของตัวแบบ Inception-v3 เมื่อข้อมูลรูปภาพผ่านการสกัดคุณลักษณะจากตัวแบบ Inception-v3 ทำให้ได้คุณลักษณะข้อมูลรูปภาพทั้งหมด 2,048 คุณลักษณะ (Features) จากนั้นจึงส่งผ่าน คุณลักษณะข้อมูลรูปภาพที่ได้รับไปยังชั้นเชื่อมต่อแบบทั่วถึงในชั้นแรก (First Fully Connected Layer) เพื่อให้ตัวแบบเรียนรู้และจำแนกสภาพพื้นผิวถนนต่อไป

จากรูปที่ 3.14 ส่วนล่าง เป็นการออกแบบโครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันเพื่อใช้สกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน งานวิจัยนี้ ใช้ชั้นคอนโวลูชัน (Convolution Layers) จำนวน 3 ชั้น เพื่อดำเนินการเปลี่ยนแปลงข้อมูลและ เรียนรู้จากคุณลักษณะของข้อมูลขาเข้า หลังจากการทำคอนโวลูชันมักตามด้วยชั้นพูลลิ่ง (Pooling Layer) เพื่อใช้ลดขนาดเฉพาะความกว้างและความสูงของข้อมูลค่าอัตราเร่งของ แรงสั่นสะเทือนแต่ความลึกยังคงค่าไว้เหมือนเดิม ชั้นสุดท้ายเป็นชั้นเชื่อมต่อแบบทั่วถึงเพื่อใช้ แปลงผลลัพธ์จากการทำคอนโวลูชันและทำหน้าที่ในการสร้างผลลัพธ์สุดท้ายของการจำแนก คุณลักษณะข้อมูล โดยโครงสร้างของแต่ละชั้นมีรายละเอียด ดังนี้

ชั้นข้อมูลขาเข้า (Input Layer) ข้อมูลขาเข้าถูกจัดอยู่ในรูปแบบ 2 มิติ ได้แก่ ความสูงและความกว้าง โดยความสูง คือ ค่าอัตราเร่งของแรงสั่นสะเทือนในแนวแกน X แกน Y แกน Z ของช่วงเวลาก่อนและหลัง  $\pm 2$  วินาทีของเวลาที่ตรงกัน (t) นั่นคือใช้เวลาที่  $t+2, t+1, t, t-1, t-2$  และความกว้าง คือ ความถี่ของค่าอัตราเร่งของแรงสั่นสะเทือนซึ่งถูกกำหนดให้มีค่าเท่ากับ 80 เฮิรท์ซ ดังนั้น ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนขาเข้าจึงมีขนาดเท่ากับ  $15 \times 80$  ซึ่งมี ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนนำเข้าตัวแบบทั้งสิ้น 1,200 ค่า จากนั้นจึงส่งผ่านข้อมูลขาเข้า ไปยังชั้นคอนโวลูชันถัดไป

ชั้น คอนโวลูชัน (Convolution Layer: Conv) ในแต่ละชั้นคอนโวลูชัน ประกอบด้วยชั้นย่อย 3 ชั้น ได้แก่ ชั้นคอนโวลูชัน ชั้นพูลลิ่งและชั้นกระตุ้น เพื่อใช้สกัดคุณลักษณะ ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

ชั้นคอนโวลูชัน ประกอบด้วยตัวกรอง (Filters) หรือแกนกลาง (Kernels) ที่มีลักษณะเป็นเมทริกซ์ประกอบกัน ได้แก่ ความกว้าง ความยาว และความลึก ตัวกรองนี้เป็นเวกเตอร์ของค่าน้ำหนักที่ใช้ในการประมวลผลกับข้อมูลขาเข้า ข้อมูลขาเข้าที่ผ่านตัวกรองของชั้นคอนโวลูชัน ถูกเรียกว่า ฟีเจอร์แมพ (Feature Map) โดยสามารถเพิ่มจำนวนตัวกรองของปริมาตรข้อมูลขาเข้า เพื่อเพิ่มจำนวนฟีเจอร์แมพได้ซึ่งแต่ละฟีเจอร์แมพจะเรียนรู้มุมมองที่แตกต่างกันในข้อมูล ค่าอัตราเร่งของแรงสั่นสะเทือน ตัวกรองหลายตัวในชั้นคอนโวลูชันของโครงข่ายประสาทเทียม ถูกใช้เพื่อสกัดคุณลักษณะที่ซับซ้อนได้โดยที่ค่าเมทริกซ์ของตัวกรองจะมีการเรียนรู้ในระหว่างขั้นตอนการสอนของตัวแบบอีกด้วย จากนั้นตัวกรองจะเลื่อนผ่านหรือมีการก้าวข้าม (Stride) เมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือนไปเรื่อย ๆ เพื่อดำเนินการประมวลผลหาผลคูณและผลรวมระหว่างเมทริกซ์ของตัวกรองและเมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือนจนได้ค่าเมทริกซ์ของฟีเจอร์แมพที่สมบูรณ์เพื่อส่งคุณลักษณะต่าง ๆ ที่ผ่านชั้นคอนโวลูชันนี้ไปยังชั้นพูลลิ่ง

ชั้นพูลลิ่ง (Pooling Layer) หลังจากการทำคอนโวลูชันมักตามด้วยชั้นพูลลิ่งที่มีลักษณะเป็นเมทริกซ์ประกอบกัน ได้แก่ ความกว้าง ความยาว เพื่อใช้ลดขนาดเฉพาะความกว้างและความสูงแต่ความลึกยังคงค่าไว้เหมือนเดิม ในงานวิจัยนี้เลือกใช้แมกซ์พูลลิ่ง (Max Pooling) เพื่อดึงค่ามากที่สุดในแต่ละเมทริกซ์ของฟีเจอร์แมพค่าอัตราเร่งของแรงสั่นสะเทือนในแต่ละแกน เพื่อส่งคุณลักษณะต่าง ๆ ที่ผ่านชั้นพูลลิ่งนี้ไปยังชั้นกระตุ้น

ชั้นกระตุ้น (Activation Layer) เป็นฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมดจากทุกข้อมูลขาเข้าแล้วพิจารณาส่งต่อไปยังโหนดและกำหนดผลลัพธ์ของโหนดนั้น ๆ โดยฟังก์ชันกระตุ้นที่เป็นที่นิยมใช้ในชั้นคอนโวลูชัน คือ ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified Linear Unit: ReLU) ซึ่งเป็นฟังก์ชันที่ใช้เปลี่ยนค่าลบจากผลลัพธ์ให้เป็นศูนย์และคงที่ค่าบวกไว้ ส่งผลให้ช่วยลดจำนวนตัวแปรในโครงข่ายที่ส่งผลให้โครงข่ายเรียนรู้ได้เร็วและมีประสิทธิภาพมากยิ่งขึ้น งานวิจัยนี้จึงใช้ฟังก์ชันเรกติไฟด์เชิงเส้นเป็นฟังก์ชันกระตุ้น ในแต่ละชั้นคอนโวลูชัน จากนั้นจึงนำผลลัพธ์ของคุณลักษณะที่ได้ส่งต่อไปยังชั้นคอนโวลูชันถัดไป

สำหรับชั้นคอนโวลูชันสุดท้าย จะถูกส่งเข้าชั้นแผ่ออก (Flatten Layer) เพื่อแปลงเมทริกซ์ของฟีเจอร์แมพค่าอัตราเร่งของแรงสั่นสะเทือนขนาด 2 มิติ ให้เป็นเวกเตอร์ที่สามารถป้อนเข้าสู่ขั้นตอนการเชื่อมต่อแบบทั่วถึงของโครงข่ายประสาทเทียมเพื่อจำแนกคุณลักษณะของข้อมูลต่อไป

ชั้นเชื่อมต่อแบบทั่วถึง (Fully Connected Layer) เป็นชั้นที่ดำเนินการหลังจากการสกัดคุณลักษณะในหลายชั้นของโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อหลอมรวมคุณลักษณะข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน จากนั้นจึงจำแนกคุณลักษณะข้อมูลเหล่านี้ ในชั้นนี้มีการเชื่อมต่อการกระตุ้นทั้งหมดในชั้นก่อนหน้าและคำนวณ



การกระตุ้นเหล่านี้ด้วยการคูณเมทริกซ์ด้วยค่าไบแอส (Bias) จากนั้นส่งผลลัพธ์ไปยังชั้นถัดไป สำหรับชั้นสุดท้ายของโครงข่ายถูกใช้เพื่อคาดการณ์หรือทำนายประเภทข้อมูล ในชั้นนี้จะแสดงเวกเตอร์ผลลัพธ์ของจำนวนประเภทที่โครงข่ายต้องการคาดการณ์ผลลัพธ์ โดยใช้ฟังก์ชันกระตุ้นสำหรับการจำแนกประเภท คือ ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function) ซึ่งเป็นฟังก์ชันการถดถอยโลจิสติกที่ถูกใช้ในชั้นสุดท้ายของโครงข่ายเพื่อคาดการณ์หรือทำนายประเภทข้อมูลและใช้ความน่าจะเป็นสูงสุดเป็นคำตอบสุดท้าย

งานวิจัยนี้ ได้ออกแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันเพื่อใช้สกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและใช้ตัวแบบ Inception-v3 ที่ถูกฝึกไว้แล้วล่วงหน้าเพื่อสกัดคุณลักษณะรูปภาพสภาพพื้นผิวถนน จากนั้นจึงหลอมรวมคุณลักษณะข้อมูลทั้งสองเข้าด้วยกันในชั้นการเชื่อมต่อแบบทั่วถึงและจำแนกคุณลักษณะข้อมูลเพื่อทำนายสภาพพื้นผิวถนน รายละเอียดโครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบแสดงดังตารางที่ 3.3

ตารางที่ 3.3 โครงสร้างของโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

โครงสร้าง		ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน					ข้อมูลรูปภาพ
		ข้อมูลนำเข้า (Input)	15×80				ข้อมูลนำออก (Output)
ขนาดตัว กรอง (Filters size)	จำนวนตัว กรอง (Number of filters)		การก้าว ข้าม (Stride)				
คอนโวลูชัน ชั้นที่ 1	Conv.1	15×80	1×3	64	1		ตัวแบบ Inception-v3 22 layers
	Max-pooling		1×3		3	15×27×64	
	ReLU						
คอนโวลูชัน ชั้นที่ 2	Conv.2	15×27×64	1×3	64	1		
	Max-pooling		1×3		3	15×9×64	
	ReLU						
คอนโวลูชัน ชั้นที่ 3	Conv.3	15×9×64	1×3	64	1		
	Max-pooling		1×3		3	15×3×64	
	ReLU						
ชั้นแผ่ออก (Flatten layer)		15×3×64				2880	2048
ชั้นเชื่อมต่อแบบทั่วถึง (Fully connected layer: FC)							
ชั้น FC1 (ReLU, Dropout 0.5)						1440	1024
ชั้น FC2 (ReLU, Dropout 0.5)						512	512
ชั้น FC3 (ReLU, Dropout 0.5)						1024	
ชั้น FC4						512	
ชั้น FC5 (SoftMax)						7	



ขั้นตอนการสกัดคุณลักษณะรูปภาพสภาพพื้นผิวถนน จากตารางที่ 3.3 เมื่อป้อนข้อมูลรูปภาพขนาด  $299 \times 299 \times 3$  เข้าตัวแบบ Inception-v3 ที่ถูกฝึกไว้แล้วล่วงหน้าซึ่งมีทั้งหมดจำนวน 22 ชั้น (Layers) เพื่อใช้สกัดคุณลักษณะรูปภาพสภาพพื้นผิวถนน ผลลัพธ์ที่ได้คือคุณลักษณะรูปภาพสภาพพื้นผิวถนนที่มีจำนวน 2,048 คุณลักษณะ เพื่อส่งผ่านคุณลักษณะรูปภาพไปยังชั้นเชื่อมต่อแบบทั่วถึงต่อไป

ขั้นตอนการสกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน จากตารางที่ 3.3 เมื่อป้อนข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 80$  เข้าชั้นคอนโวลูชันที่ 1 (Conv 1) เพื่อสกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน มีการกำหนดตัวแปรและผลลัพธ์จากการสกัดคุณลักษณะ ดังนี้

ชั้นคอนโวลูชันที่ 1 (Conv 1) กำหนดขนาดตัวกรอง (Filters Size) เท่ากับ  $1 \times 3$  จำนวน 64 Filters เพื่อสกัดคุณลักษณะที่ซับซ้อนของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน โดยที่ค่าเมทริกซ์ของตัวกรองจะมีการเรียนรู้ในระหว่างขั้นตอนการสอนของตัวแบบ จากนั้นตัวกรองจะเลื่อนผ่านหรือมีการก้าวข้าม (Stride) เมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือน ไปเรื่อย ๆ ครั้งละ 1 Step เพื่อดำเนินการประมวลผลหาผลคูณและผลรวมระหว่างเมทริกซ์ของตัวกรองและเมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือนจนได้ค่าเมทริกซ์ของพีเจอร์แมพที่สมบูรณ์ เพื่อส่งคุณลักษณะต่าง ๆ ของค่าอัตราเร่งของแรงสั่นสะเทือนที่ผ่านชั้นคอนโวลูชันนี้แล้วไปยังชั้นพลูลิง ในชั้นพลูลิงกำหนดขนาดตัวกรองเท่ากับ  $1 \times 3$  และการก้าวข้าม เท่ากับ 3 เพื่อดึงค่ามากที่สุดในแต่ละเมทริกซ์ของพีเจอร์แมพ ค่าอัตราเร่งของแรงสั่นสะเทือนในแต่ละแกน เพื่อส่งคุณลักษณะต่าง ๆ ที่ผ่านชั้นพลูลิงนี้ไปยังชั้นกระตุ้น ในชั้นกระตุ้นใช้ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified Linear Unit: ReLU) ซึ่งเป็นฟังก์ชันที่ใช้เปลี่ยนค่าลบจากผลลัพธ์ให้เป็นศูนย์และคงที่ค่าบวกไว้ส่งผลให้ช่วยลดจำนวนตัวแปรในโครงข่ายที่ส่งผลให้โครงข่ายเรียนรู้ได้เร็วและมีประสิทธิภาพมากยิ่งขึ้น ดังนั้น เมื่อข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนผ่านการประมวลผลเรียบร้อยแล้ว ผลลัพธ์สุดท้ายคือ คุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 27 \times 64$  จากนั้นนำผลลัพธ์ของคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่ได้ส่งต่อไปยังชั้นคอนโวลูชันที่ 2 (Conv 2) ต่อไป

ชั้นคอนโวลูชันที่ 2 (Conv 2) นำคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 27 \times 64$  จากเข้าชั้น Conv 1 เข้าชั้น Conv 2 โดยในชั้น Conv 2 กำหนดขนาดตัวกรองเท่ากับ  $1 \times 3$  จำนวน 64 Filters และการก้าวข้ามเท่ากับ 1 เพื่อดำเนินการประมวลผลหาผลคูณและผลรวมระหว่างเมทริกซ์ของตัวกรองและเมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือนจนได้ค่าเมทริกซ์ของพีเจอร์แมพที่สมบูรณ์ จากนั้นส่งคุณลักษณะต่าง ๆ ของค่าอัตราเร่งของแรงสั่นสะเทือนที่ผ่านชั้นคอนโวลูชันนี้ไปยังชั้นพลูลิง โดยกำหนดขนาดตัวกรองของชั้นพลูลิง

เท่ากับ  $1 \times 3$  และการก้าวข้าม เท่ากับ 3 เพื่อหาค่ามากที่สุดในแต่ละเมทริกซ์ของพีเจอร์แมพ ค่าอัตราเร่งของแรงสั่นสะเทือนในแต่ละแกน แล้วส่งผลลัพธ์ผ่านไปยังชั้นกระตุ้น โดยใช้ฟังก์ชัน ReLU ผลลัพธ์สุดท้าย คือ คุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 9 \times 64$  จากนั้นจึงนำผลลัพธ์ของคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่ได้ส่งต่อไปยังชั้นคอนโวลูชันที่ 3 (Conv 3)

ชั้นคอนโวลูชันที่ 3 (Conv 3) นำคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 9 \times 64$  เข้าชั้น Conv 2 เข้าชั้น Conv 3 โดยในชั้น Conv 3 กำหนดขนาดตัวกรองเท่ากับ  $1 \times 3$  จำนวน 64 Filters และการก้าวข้ามเท่ากับ 1 แล้วดำเนินการประมวลผลหาผลคูณและผลรวมระหว่างเมทริกซ์ของตัวกรองและเมทริกซ์ของค่าอัตราเร่งของแรงสั่นสะเทือนจนได้ค่าเมทริกซ์ของพีเจอร์แมพที่สมบูรณ์ จากนั้นส่งคุณลักษณะต่าง ๆ ของค่าอัตราเร่งของแรงสั่นสะเทือนที่ผ่านชั้นคอนโวลูชันนี้ไปยังชั้นพูลลิง โดยกำหนดขนาดตัวกรองของชั้นพูลลิงเท่ากับ  $1 \times 3$  และการก้าวข้ามเท่ากับ 3 แล้วส่งผลลัพธ์ผ่านไปยังชั้นกระตุ้น โดยใช้ฟังก์ชัน ReLU ผลลัพธ์สุดท้าย คือ คุณลักษณะ ค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 3 \times 64$  จากนั้นจึงนำผลลัพธ์ของคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่ได้ส่งต่อไปยังชั้นแผ่ออก

ชั้นแผ่ออก (Flatten Layer) นำคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีขนาดเท่ากับ  $15 \times 3 \times 64$  เข้าชั้นแผ่ออก (Flatten Layer) เพื่อแปลงเมทริกซ์ของพีเจอร์แมพ ค่าอัตราเร่งของแรงสั่นสะเทือนขนาด 2 มิติ ให้เป็นเวกเตอร์ที่สามารถป้อนเข้าสู่ขั้นตอนการเชื่อมต่อแบบทั่วถึงของโครงข่ายประสาทเทียมเพื่อจำแนกคุณลักษณะของข้อมูล ผลลัพธ์สุดท้าย คือ คุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีจำนวน 2,880 คุณลักษณะ

หลังจากสกัดคุณลักษณะรูปภาพสภาพพื้นผิวถนนและค่าอัตราเร่งของแรงสั่นสะเทือนในหลายชั้นของโครงข่ายประสาทเทียมแบบคอนโวลูชันเรียบร้อยแล้ว ผลลัพธ์ที่ได้ คือ คุณลักษณะรูปภาพสภาพพื้นผิวถนนที่มีจำนวน 2,048 คุณลักษณะ และคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนที่มีจำนวน 2,880 คุณลักษณะ จากนั้นป้อนคุณลักษณะรูปภาพสภาพพื้นผิวถนนและค่าอัตราเร่งของแรงสั่นสะเทือนเข้าสู่ขั้นตอนการเชื่อมต่อแบบทั่วถึง

ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 1 และ 2 (FC1 และ FC2) ของคุณลักษณะรูปภาพแต่ละเซลล์ประสาท (Neuron) จะรับคุณลักษณะรูปภาพนำเข้าจากทุก ๆ เซลล์ประสาทในชั้นแผ่ออกมาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC1 โดยกำหนดจำนวนโหนดในชั้น FC1 เท่ากับ 1,440 โหนด และชั้น FC2 เท่ากับ 512 โหนด โครงข่ายประสาทเทียมจะมีเส้นเชื่อมจากทุก ๆ โหนดในชั้น FC1 ไปยังทุก ๆ โหนดในชั้น FC2 เส้นเชื่อมแต่ละเส้นมีค่าน้ำหนัก (Weight) ที่ได้จากการปรับค่าของกระบวนการเรียนรู้เชิงลึกเพื่อการจำแนกข้อมูลคุณลักษณะรูปภาพ ในชั้น FC1 และ FC2 ใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้นและใช้ดรอปเอาต์ (Dropout) เท่ากับ 0.5 เพื่อป้องกัน

การเกิด Overfitting โดยการสุ่มปิดโหนดในเซลล์ประสาทเทียมไม่ให้ส่งข้อมูล ในแต่ละรอบ การฝึกการไหลของข้อมูลจะต่างกันทำให้การเรียนรู้ในแต่ละโหนดกระจายอย่างทั่วถึงไม่กระจุกตัว ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 1 และ 2 (FC1 และ FC2) ของคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือน แต่ละเซลล์ประสาทจะรับคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนนำเข้าจากทุก ๆ เซลล์ประสาทในชั้นแ่ออกมาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC1 โดยกำหนดจำนวนโหนดในชั้น FC1 เท่ากับ 1,024 โหนด และชั้น FC2 เท่ากับ 512 โหนด ในชั้น FC1 และ FC2 ใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้นและใช้ครอปเอ้าท์ (Dropout) เท่ากับ 0.5

ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 3 (FC3) เป็นชั้นที่ใช้หลอมรวมคุณลักษณะข้อมูลรูปภาพ (512 โหนด) และค่าอัตราเร่งของแรงสั่นสะเทือน (512 โหนด) เข้าด้วยกัน เพื่อถ่ายทอดความรู้ที่เกี่ยวข้องกันและเกิดขึ้นในเวลาเดียวกัน ซึ่งเป็นการนำความสัมพันธ์ของข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนมาช่วยในการรับรู้ข้อมูลรูปภาพและนำข้อมูลรูปภาพมาช่วยในการรับรู้ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน การหลอมรวมคุณลักษณะข้อมูลในชั้นนี้ใช้ฟังก์ชัน Concat (Concatenate) เพื่อรวมโหนดผลลัพธ์ที่ได้จากชั้น FC2 ของคุณลักษณะรูปภาพและคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือน ผลลัพธ์ที่ได้ คือ จำนวนโหนดในชั้น FC3 เท่ากับ 1,024 โหนด ในชั้น FC3 ใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้นและใช้ครอปเอ้าท์ (Dropout) เท่ากับ 0.5


ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 4 (FC4) ในแต่ละเซลล์ประสาทจะรับคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนนำเข้าจากทุก ๆ เซลล์ประสาทในชั้น FC3 มาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC4 โดยกำหนดจำนวนโหนดในชั้น FC4 เท่ากับ 512 โหนด ในชั้น FC4 ใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้น จากนั้นแต่ละเซลล์ประสาท ทุก ๆ เซลล์ จะเชื่อมต่อไปยังทุก ๆ เซลล์ประสาทในชั้น FC5 ซึ่งเป็นชั้นสุดท้าย

ชั้นเชื่อมต่อแบบทั่วถึงชั้นที่ 5 (FC5) ในแต่ละเซลล์ประสาทจะรับคุณลักษณะค่าอัตราเร่งของแรงสั่นสะเทือนนำเข้าจากทุก ๆ เซลล์ประสาทในชั้น FC4 มาเชื่อมต่อทุก ๆ เซลล์ประสาทในชั้น FC5 โดยกำหนดจำนวนโหนดในชั้น FC5 เท่ากับ 7 โหนด ซึ่งจำนวนประเภทสภาพพื้นผิวถนนที่ต้องการจำแนก ในชั้น FC5 ใช้ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function) ซึ่งเป็นฟังก์ชันกระตุ้นที่ถูกใช้ในชั้นสุดท้ายของโครงข่ายเพื่อคาดการณ์หรือทำนายประเภทข้อมูลและใช้ความน่าจะเป็นสูงสุดเป็นคำตอบสุดท้าย

### 3.1.4 การออกแบบขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนน

#### 1) ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ


งานวิจัยที่ผ่านมาได้แก่ งานวิจัยของ Maeda และคณะ (2018) Singh และ Shekhar (2018) และ Koh และคณะ (2019) ใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ดังรูปที่ 3.15



รูปที่ 3.15 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

จากรูปที่ 3.15 งานวิจัยที่ผ่านมาเริ่มต้นจากการนำเข้าข้อมูลรูปภาพผ่านตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับตรวจจับวัตถุ ได้แก่ ตัวแบบ SSD Inception V2 และตัวแบบ SSD MobileNet พบได้ในงานวิจัยของ Maeda และคณะ (2018) ตัวแบบ Mark R-CNN พบได้ในงานวิจัยของ Singh และ Shekhar (2018) และตัวแบบ R-FCN พบได้ในงานวิจัยของ Koh และคณะ (2019) เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ หลังจากนั้นตรวจสอบเกณฑ์ค่าความเชื่อมั่นที่กำหนด

โดยค่าความเชื่อมั่น (Confidence Score) เป็นค่าที่แสดงถึงความเป็นไปได้ (Probability) ของวัตถุที่ถูกตรวจจับซึ่งถูกคำนวณมาจากฟังก์ชันค่าสูงสุดอย่างอ่อนหรือที่เรียกว่า ฟังก์ชันซอฟต์แมกซ์ (Softmax Function) โดยจะทำการเปลี่ยนค่าที่เข้ามาให้ผลลัพธ์อยู่ในช่วง 0 ถึง 1 ผู้วิจัยสามารถกำหนดเกณฑ์ค่าความเชื่อมั่นในระดับที่ยอมรับได้ หากค่าความเชื่อมั่นของวัตถุที่ถูกตรวจจับได้มากกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนด ให้ยอมรับวัตถุที่ถูกตรวจจับนั้น แล้วแสดงกรอบล้อมรอบวัตถุและระบุประเภทสภาพพื้นผิวถนนพร้อมทั้งแสดงค่าความเชื่อมั่นของวัตถุนั้น ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุนั้นในภาพ สำหรับรายละเอียดสรุปขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ แสดงดังรูปที่ 3.16



รูปที่ 3.16 ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ



จากรูปที่ 3.16 ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ ประกอบด้วย 4 ขั้นตอนดังนี้

### เริ่มต้น

ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

### ขั้นตอนที่ 1

รับข้อมูลรูปภาพจากโทรศัพท์สมาร์ทโฟน

### ขั้นตอนที่ 2

สกัดข้อมูลรูปภาพ

### ขั้นตอนที่ 3

นำเข้าข้อมูลรูปภาพเพื่อตรวจจับวัตถุด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า

### ขั้นตอนที่ 4

เมื่อได้วัตถุที่ถูกตรวจจับมาแล้ว ตรวจสอบค่าความเชื่อมั่น (Confidence Score) หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด (Confidence Score Threshold) ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุนั้นในภาพ


### จบการทำงาน

2) ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

ในงานวิจัยนี้เสนอขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติ โดยรับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากสมาร์ทโฟน จากนั้นสกัดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนในตำแหน่งที่ตรงกัน แล้วนำเข้าข้อมูลรูปภาพเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า ผลลัพธ์ที่ได้คือวัตถุที่ถูกตรวจจับ จากนั้นตรวจสอบค่าความเชื่อมั่นของวัตถุที่ถูกตรวจจับได้ หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้นำวัตถุดังเลือกนั้น (Candidate Objects) มาตรวจสอบตำแหน่งของวัตถุดังเลือกโดยคำนวณค่าไอโอยู (Intersection Over Union: IoU) คือ อัตราส่วนพื้นที่ที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุดังเลือกนั้น กับพื้นที่ในภาพบริเวณสี่รถ

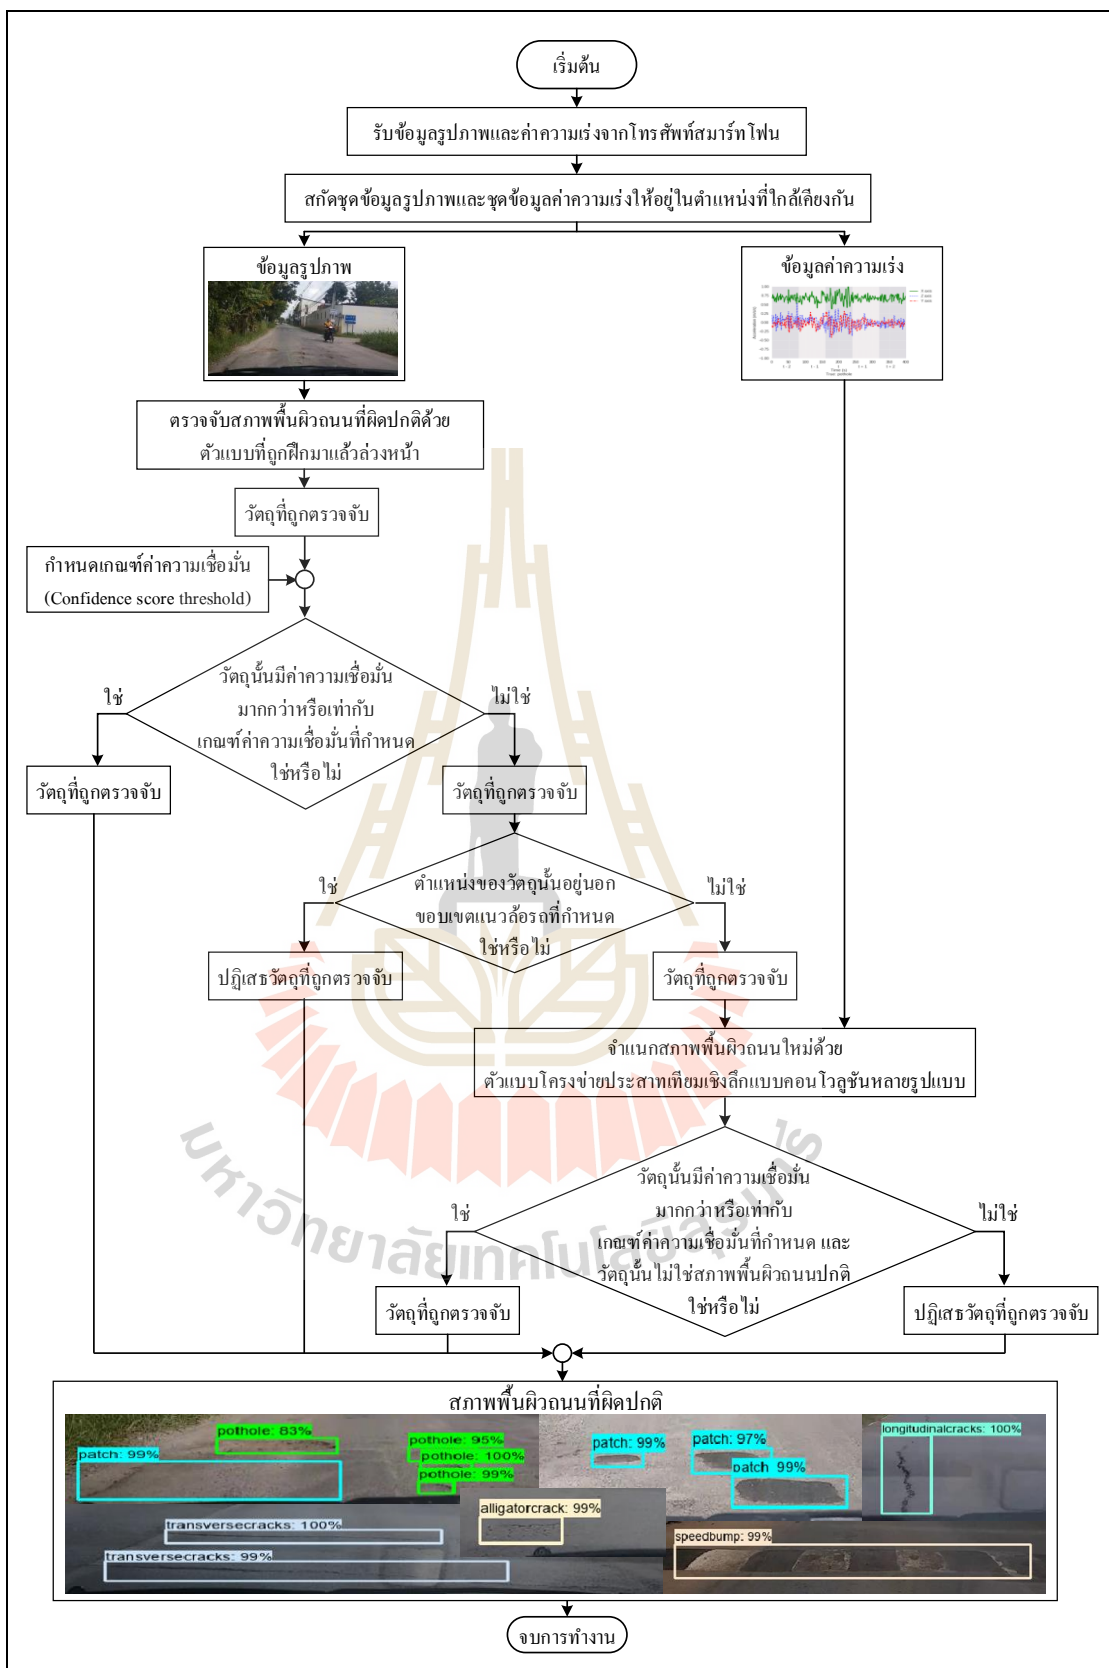


ที่กำหนดหารด้วยพื้นที่รวมทั้งหมด (Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้นกับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ภายในขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0 ให้นำวัตถุนั้นมาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ โดยนำเข้าภาพวัตถุและค่าอัตราเร่งของแรงสั่นสะเทือนของรูปภาพนั้นเพื่อจำแนกสภาพพื้นผิวถนนใหม่ งานวิจัยนี้เพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบที่หลอมรวมคุณลักษณะของข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน ผลลัพธ์ที่ได้คือ ภาพของวัตถุที่ถูกตรวจจับพร้อมทั้งระบุประเภทสภาพพื้นผิวถนนและค่าความเชื่อมั่นของภาพวัตถุนั้น จากนั้นตรวจสอบค่าความเชื่อมั่น หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด และวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติ ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ดังแสดงในรูปที่ 3.17



รูปที่ 3.17 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน

สำหรับรายละเอียดสรุปขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน แสดงดังรูปที่ 3.18



รูปที่ 3.18 ขั้นตอนวิธีใหม่ในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

จากรูปที่ 3.18 ขั้นตอนวิธีใหม่ในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน ประกอบด้วย 7 ขั้นตอนดังนี้

### เริ่มต้น

ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยการรับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

### ขั้นตอนที่ 1

รับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากโทรศัพท์สมาร์ทโฟน

### ขั้นตอนที่ 2

สกัดชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้อยู่ในตำแหน่งที่ใกล้เคียงกัน (ตำแหน่งที่มองเห็นสภาพพื้นผิวถนนได้ชัดเจนอยู่ห่างจากรถเป็นระยะทาง 6.5 เมตรและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนซึ่งอยู่ในตำแหน่งของรถ) โดยทำการคำนวณหาเวลาที่บวกเพิ่มจากเวลาที่ดึงรูปภาพซึ่งใช้สูตรการเคลื่อนที่ในอัตราเร่งคงที่

### ขั้นตอนที่ 3

ป้อน ข้อมูลรูปภาพเข้าตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ผลลัพธ์ที่ได้คือวัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวถนนใน 6 ประเภท

### ขั้นตอนที่ 4

ตรวจสอบค่าความเชื่อมั่น หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้นำวัตถุตัวเลือกนั้น (Candidate Objects) เข้าตรวจสอบในขั้นตอนถัดไป ซึ่งวัตถุตัวเลือกนั้นอาจเป็นสภาพพื้นผิวถนนที่ผิดปกติที่ต้องการ

### ขั้นตอนที่ 5

ตรวจสอบตำแหน่งของวัตถุตัวเลือกนั้น โดยคำนวณหาค่าไอโอยู (Intersection Over Union: IoU) คือ อัตราส่วนพื้นที่ที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณล้อรถที่กำหนดหารด้วยพื้นที่รวมทั้งหมด (Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณล้อรถที่กำหนด หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวล้อรถที่กำหนด นั่นคือ ค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ภายในขอบเขตแนวล้อรถที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0ให้นำวัตถุนั้นมาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

### ขั้นตอนที่ 6

นำเข้าภาพวัตถุตัวเลือกนั้นและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ ผลลัพธ์ที่ได้คือวัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวถนนใน 7 ประเภท

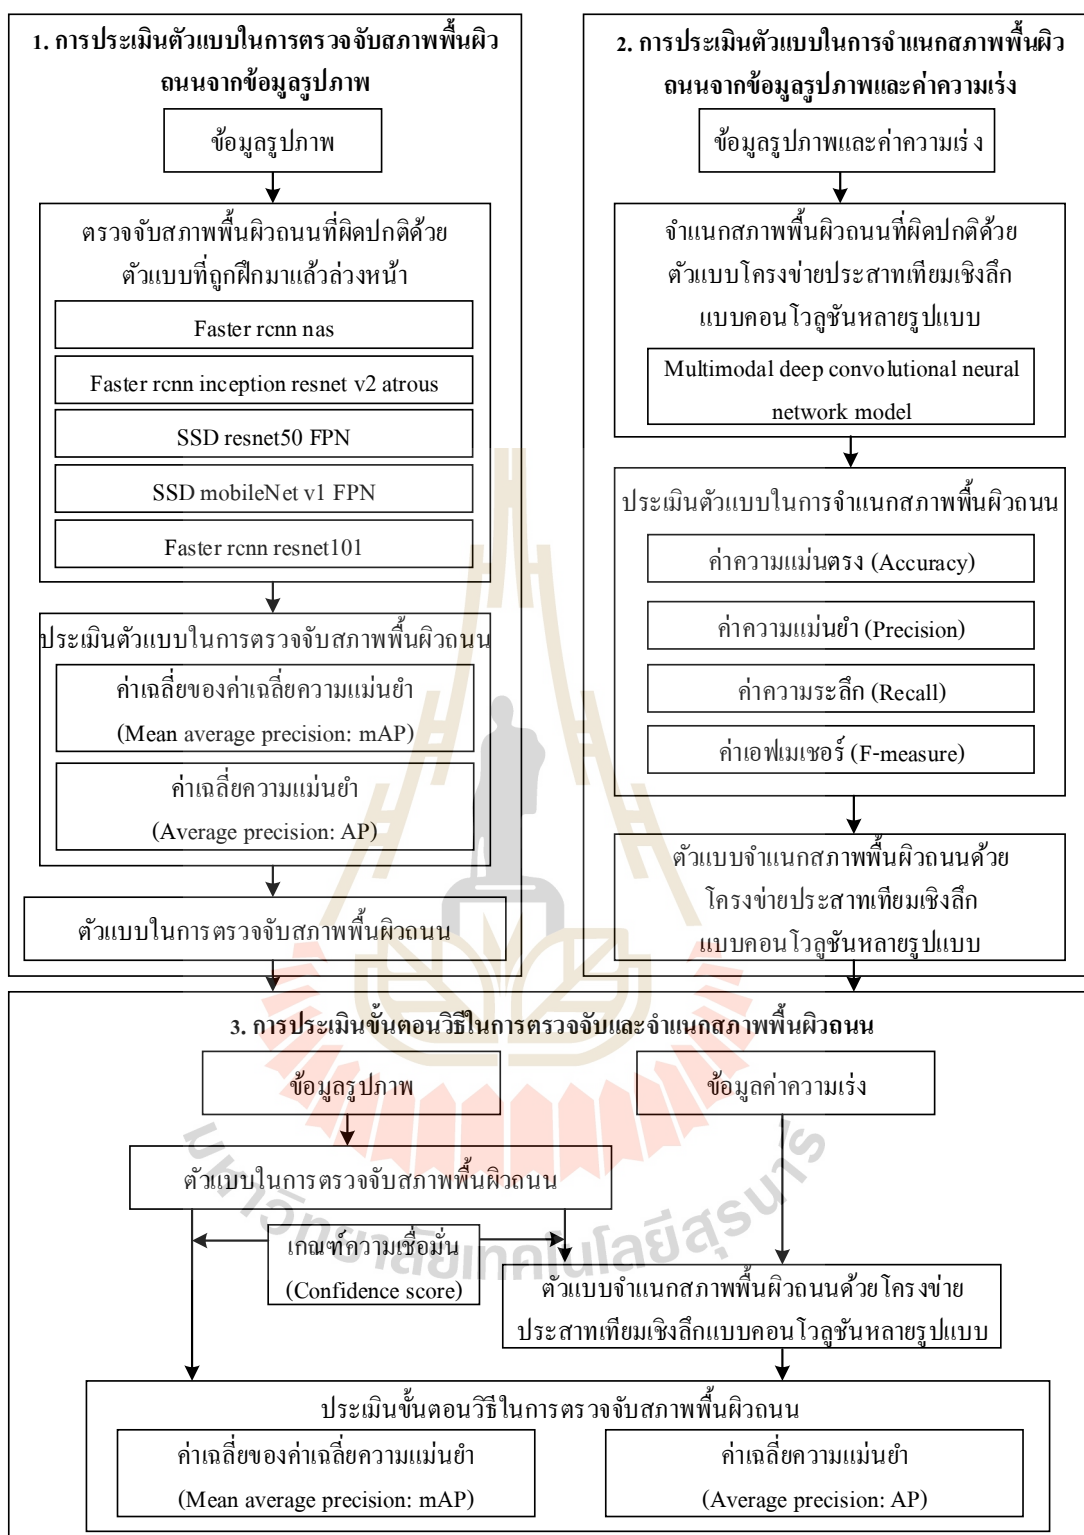
### ขั้นตอนที่ 7

ตรวจสอบค่าความเชื่อมั่น หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด และวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ

### จบการทำงาน

#### 3.1.5 การประเมินตัวแบบและขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนน

การประเมินตัวแบบและขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ประกอบไปด้วย 3 ขั้นตอน ได้แก่ การประเมินตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ การประเมินตัวแบบโครงข่ายประสาทเทียมเชิงลึกหลายรูปแบบสำหรับการจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน และการประเมินขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ดังรูปที่ 3.19



รูปที่ 3.19 ขั้นตอนการประเมินตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

### 1) การประเมินตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

ใช้เกณฑ์การประเมิน ได้แก่ ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) และค่าเฉลี่ยความแม่นยำ (Average Precision: AP) เพื่อพิจารณาเลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่เหมาะสมที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดเมื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบ

### 2) การประเมินตัวแบบโครงข่ายประสาทเทียมเชิงลึกหลายรูปแบบสำหรับการจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

ใช้เกณฑ์การประเมิน ได้แก่ ค่าความแม่นยำ (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าเอฟเมเชอร์ (F-measure) เพื่อประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบ

### 3) การประเมินขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

โดยเปรียบเทียบตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่ใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพเพียงอย่างเดียวและตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่ใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพรวมกับการจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่จากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน ใช้เกณฑ์การประเมิน ได้แก่ ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) และค่าเฉลี่ยความแม่นยำ (AP) เพื่อพิจารณาเลือกใช้ขั้นตอนวิธีที่เหมาะสมที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุดเมื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบ

## 3.2 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้ในการวิจัย ประกอบด้วย เครื่องมือที่ใช้ในการพัฒนาระบบเก็บรวบรวมข้อมูลและการระบุสภาพพื้นผิวถนนและเครื่องมือที่ใช้ในการสร้างตัวแบบตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ มีรายละเอียด ดังนี้

### 3.2.1 เครื่องมือที่ใช้ในการพัฒนาระบบเก็บรวบรวมข้อมูลและการระบุสภาพพื้นผิวถนน

#### 1) ด้านฮาร์ดแวร์

- เครื่องคอมพิวเตอร์ ใช้ในการประมวลผลและจัดเก็บข้อมูลสภาพพื้นผิวถนน
- เครื่องโทรศัพท์มือถือ (Smartphone) ที่มีเครื่องรับรู้มาตราความเร่ง (Accelerometer Sensor) เพื่อวัดค่าอัตราเร่งของแรงสั่นสะเทือน ในขณะที่รถเคลื่อนที่



บนสภาพพื้นผิวถนนในลักษณะต่าง ๆ และกล้องบันทึกภาพวิดีโอ เพื่อบันทึกข้อมูลภาพวิดีโอของสภาพพื้นผิวถนน

## 2) ด้านซอฟต์แวร์

- ใช้ภาษาจาวา (JAVA) เพื่อพัฒนาระบบเก็บรวบรวมข้อมูลสภาพพื้นผิวถนนที่ผิดปกติบนระบบปฏิบัติการแอนดรอยด์ (Android Operating System)

- แอนดรอยด์สตูดิโอ (Android Studio) เป็นเครื่องมือพัฒนาแอนดรอยด์แอปพลิเคชันเก็บรวบรวมข้อมูลสภาพพื้นผิวถนนที่ผิดปกติ

- โปรแกรม LabelImg เป็นเครื่องมือที่ถูกใช้เพื่อติกรอบล้อมรอบวัตถุที่ต้องการตรวจจับ (Bounding Box) และระบุประเภทสภาพพื้นผิวถนน

### 3.2.2 เครื่องมือที่ใช้ในการสร้างตัวแบบตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

#### 1) ด้านฮาร์ดแวร์

- เครื่องแม่ข่าย (Server) ใช้เครื่องแม่ข่าย (Google Cloud Platform) เป็นระบบคลาวด์แพลตฟอร์มที่ให้บริการลักษณะ Web Server ที่ถูกพัฒนาขึ้นโดยกูเกิลเพื่อใช้ในการสร้างตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและการประมวลผลข้อมูลเพื่อเรียนรู้และทดสอบข้อมูล (Training and Testing Data) โดยใช้ GPU รุ่น NVIDIA Tesla T4 หน่วยความจำ 20 GB พื้นที่จัดเก็บข้อมูล 200 GB

- เครื่องลูกข่าย (Client) ใช้คอมพิวเตอร์โน้ตบุ๊กในการติดต่อข้อมูลจากเครื่องแม่ข่ายเพื่อสั่งงานและแสดงผลข้อมูล

#### 2) ด้านซอฟต์แวร์

- ใช้ภาษาไพธอน (Python) เป็นภาษาโปรแกรมคอมพิวเตอร์ระดับสูง เพื่อเขียนโปรแกรมเรียกใช้ไลบรารีเทนเซอร์โฟลของกูเกิล (TensorFlow of Google)

- ใช้โปรแกรม Jupyter Notebook ในการรันภาษาไพธอนและเรียกใช้งานไลบรารีต่าง ๆ เช่น TensorFlow V1.15, NumPy, Matplotlib, Sklearn, OpenCV เป็นต้น

- ใช้เทนเซอร์โฟล (TensorFlow) เวอร์ชัน 1.15 ซึ่งเป็นไลบรารีโอเพ่นซอร์สสำหรับงานด้านการตรวจจับวัตถุ

### 3.3 การเก็บรวบรวมข้อมูล

งานวิจัยนี้เก็บรวบรวมข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของสภาพพื้นผิวถนนที่ผิดปกติบนถนนลาดยางแอสฟัลท์ภายในจังหวัดนครราชสีมาด้วยแอปพลิเคชันที่ถูกพัฒนาขึ้นบนระบบปฏิบัติการแอนดรอยด์จากกล้องบันทึกวิดีโอและเครื่องวัดค่าอัตราเร่งของแรงสั่นสะเทือน (Accelerometer) ในโทรศัพท์สมาร์ทโฟนรุ่น Samsung Galaxy A9 Pro ปี 2016

โทรศัพท์สมาร์ทโฟนถูกติดตั้งบนคอนโซลหน้ารถยนต์รุ่น Honda City 2010 ระยะทางจากจุดตั้งโทรศัพท์ไปจนถึงจุดที่สามารถเห็นภาพได้ชัดเจน คือ 6.5 เมตร ความเร็วรถยนต์ในการเก็บข้อมูล 40 - 60 กิโลเมตร/ชั่วโมง กำหนดค่าเริ่มต้นของระบบบันทึกข้อมูลภาพวิดีโอและค่าอัตราเร่งของแรงสั่นสะเทือนของสภาพพื้นผิวถนน ดังนี้ ความละเอียดของภาพเท่ากับ 1080p นั่นคือ ขนาดภาพจะมีค่าเท่ากับ 1920 x 1080 พิกเซล อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความถี่ในการจัดเก็บภาพเท่ากับ 80 Hz

งานวิจัยนี้ใช้โครงข่ายถนนลาดยางที่รับผิชอบโดยกรมทางหลวง กรมทางหลวงชนบท และองค์กรปกครองส่วนท้องถิ่นภายในจังหวัดนครราชสีมา ได้แก่ ถนนสาย 304 นครราชสีมา-ปักธงชัยและถนนสายรอง ถนนทางหลวงแผ่นดินหมายเลข 204 หรือทางเลี่ยงเมืองนครราชสีมา และถนนสายรอง ถนนเลกิงพล ถนนคลองส่งน้ำ ที่มีสภาพพื้นผิวถนนในลักษณะต่าง ๆ ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหน้างู (Alligator Cracks) 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal Road) ตามลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมทางธรรมชาติ

### 3.4 การวิเคราะห์ข้อมูล

การวิเคราะห์ข้อมูลเพื่อค้นหาขั้นตอนวิธีใหม่ในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ โดยพิจารณาเกณฑ์การประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ และเกณฑ์การประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ดังนี้

#### 3.4.1 เกณฑ์ประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

งานวิจัยนี้ประเมินประสิทธิภาพของตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยค่าไอโอยู ค่าความเชื่อมั่น ค่าเฉลี่ยความแม่นยำและค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Liu et al, 2018) มีรายละเอียดดังนี้

1) ค่าไอโอยู (Intersection Over Union: IoU) เป็นค่าที่นิยมใช้วัดความแม่นยำในการตรวจจับวัตถุ ซึ่งวัดได้จากอัตราส่วนพื้นที่ที่ทับซ้อนกัน (Area of overlap) ระหว่างพื้นที่บริเวณทำนาย (Prediction area) กับพื้นที่จริง (Ground truth area) หาด้วยพื้นที่รวมทั้งหมด (Area of union) ระหว่างพื้นที่บริเวณทำนายและพื้นที่จริง ดังสมการที่ 3.3

$$\text{IoU} = \frac{\text{Area of overlap}}{\text{Area of union}} \quad (3.3)$$

เมื่อ Area of overlap = พื้นที่ทับซ้อนกันระหว่างพื้นที่ทำนายกับพื้นที่จริง  
Area of union = พื้นที่รวมทั้งหมดระหว่างพื้นที่บริเวณทำนายและพื้นที่จริง

2) ค่าคะแนนความเชื่อมั่น (Confidence Score) เป็นค่าที่แสดงถึงความน่าจะเป็น (Probability) ของแต่ละคลาสที่ต้องการจำแนก ซึ่งถูกคำนวณมาจากฟังก์ชันค่าสูงสุดอย่างอ่อนหรือที่เรียกว่าฟังก์ชันซอฟต์แมกซ์ (Softmax Function) โดยจะทำการเปลี่ยนค่าที่เข้ามาให้ผลลัพธ์อยู่ในช่วง 0 ถึง 1 ซึ่งผลรวมของค่าความน่าจะเป็นที่ได้จะมีผลรวมเป็น 1 ดังสมการที่ 3.4

$$f(x)_j = \frac{e^{x_j}}{\sum_{i=1}^k e^{x_i}} \quad (3.4)$$

โดยการทดลองตรวจจับวัตถุในภาพสามารถกำหนดเกณฑ์ค่าคะแนนความเชื่อมั่นขั้นต่ำ (Confidence score threshold) ที่ใช้ในการตรวจจับวัตถุได้ หากวัตถุที่ถูกตรวจจับอยู่ในคลาสนั้นถูกต้อง มีค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 และมีค่าคะแนนความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าคะแนนความเชื่อมั่นขั้นต่ำที่กำหนด ให้ถือว่าตัวแบบสามารถตรวจจับวัตถุของสภาพพื้นผิวถนนที่ผิดปกติได้ถูกต้อง

3) ค่าเฉลี่ยความแม่นยำ (Average precision: AP) เป็นค่าที่นิยมใช้วัดประสิทธิภาพของตัวตรวจจับวัตถุซึ่งได้มาจากการคำนวณพื้นที่ใต้กราฟของค่าความแม่นยำและค่าความระลึกในแต่ละระดับของแต่ละคลาส ดังสมการที่ 3.5

$$AP = \sum_{i=1}^{n-1} (r_{i+1} - r_i) p_{interp}(r_{i+1}) \quad (3.5)$$

เมื่อ  $r$  = ค่าความละเอียดในแต่ละระดับที่ค่าความแม่นยำ มีการเปลี่ยนแปลงค่าครั้งแรก (First interpolate)  
 $n$  = จำนวนรูปภาพทั้งหมด  
 $p_{interp}$  = การกำหนดค่าใหม่ให้ค่าความแม่นยำซึ่งค่าสูงสุดของ ค่าความแม่นยำจะเท่ากับค่าสูงสุดของค่าความละเอียดในแต่ละระดับ

โดยค่าความแม่นยำ (Precision) หมายถึง ประสิทธิภาพของตัวตรวจจับวัตถุ โดยดูจากอัตราส่วนของจำนวนวัตถุที่ตรวจจับได้ถูกต้อง (TP) จากจำนวนวัตถุที่ถูกตรวจจับได้ ทั้งหมด (TP+FP) ดังสมการที่ 3.6

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.6)$$

ค่าความละเอียด (Recall) หมายถึง ประสิทธิภาพของตัวตรวจจับวัตถุ โดยดูจาก อัตราส่วนของจำนวนวัตถุที่ตรวจจับได้ถูกต้อง (TP) จากวัตถุที่ถูกต้องทั้งหมด (TP+FN) ดังสมการที่ 3.7

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.7)$$

เมื่อ TP (True positive) = วัตถุที่ตัวแบบทำนายว่าเป็นสภาพพื้นผิวถนน ที่ผิดปกติในคลาส  $C_i$  และวัตถุนั้นเป็นสภาพพื้นผิวถนนที่ผิดปกติในคลาส  $C_i$  จริง มีค่าไอโอยู มากกว่าหรือเท่ากับ 0.5 และมีค่าคะแนนความเชื่อมั่น มากกว่าหรือเท่ากับ เกณฑ์ค่าคะแนน ความเชื่อมั่นขั้นต่ำที่กำหนด

FP (False positive) = วัตถุที่ตัวแบบทำนายว่าเป็นสภาพพื้นผิวถนน ที่ผิดปกติในคลาส  $C_i$  แต่วัตถุนั้นไม่ใช่สภาพพื้นผิวถนนที่ผิดปกติในคลาส  $C_i$  หรือวัตถุนั้น มีค่าไอโอยู น้อยกว่า 0.5 หรือวัตถุนั้นไม่มีพื้นที่ทับซ้อนกัน (No overlap) ระหว่างพื้นที่บริเวณ ทำนายกับพื้นที่จริง หรือวัตถุนั้นมีค่าคะแนนความเชื่อมั่นน้อยกว่าเกณฑ์ค่าคะแนนความเชื่อมั่น ขั้นต่ำที่กำหนด

FN (False negative) = มีสภาพพื้นผิวถนนที่ผิดปกติในคลาส  $C_i$  แต่ตัวแบบไม่สามารถตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในคลาส  $C_i$  นั้นได้

$C_i$  = คลาสของสภาพพื้นผิวถนนที่ผิดปกติจำนวน 6 ประเภท เมื่อ  $1 \leq i \leq 6$  (หลุมบ่อ รอยแตกตามแนวยาว รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ และรอยปะซ่อม)

กรณีตัวอย่างผลลัพธ์การทำนายเป็น TP FP และ FN ภาพตัวอย่างและความหมาย แสดงดังตารางที่ 3.4

ตารางที่ 3.4 กรณีตัวอย่างผลลัพธ์การทำนายเป็น TP FP และ FN

นิยามการตรวจจับวัตถุ	ภาพตัวอย่าง	ความหมาย
TP (True Positive)		วัตถุที่ตัวแบบทำนายว่าเป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติและวัตถุนั้นเป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติจริง และมีค่าไอโอยู $\geq 0.5$ และมีค่าคะแนนความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าคะแนนความเชื่อมั่นที่กำหนด
FP (False Positive)		วัตถุที่ตัวแบบทำนายว่าเป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติแต่วัตถุนั้นไม่เป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติ
		วัตถุนั้นมีค่าคะแนนความเชื่อมั่นน้อยกว่าเกณฑ์ค่าคะแนนความเชื่อมั่นที่กำหนด ซึ่งอาจเป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติจริงหรือไม่เป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติก็ได้
FP (False Positive)		วัตถุที่ตัวแบบทำนายมีค่าไอโอยูน้อยกว่า 0.5
		วัตถุที่ตัวแบบทำนายไม่มีพื้นที่ทับซ้อนกัน (No Overlap) ระหว่างพื้นที่บริเวณทำนายกับพื้นที่จริง
FN (False Negative)		มีวัตถุที่เป็นประเภทสภาพพื้นผิวถนนที่ผิดปกติในภาพแต่ตัวแบบไม่สามารถตรวจจับวัตถุได้
โดยที่		กรอบล้อมรอบวัตถุจริง (Ground Truth Box)
		กรอบทำนาย (Predicted Box)

4) ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) เป็นการนำค่า AP ของทุกคลาสมาทำการหาค่าเฉลี่ย ดังสมการที่ 3.8

$$mAP = \frac{\sum_{i=1}^K AP_i}{K} \quad (3.8)$$

เมื่อ  $K$  = จำนวนคลาสทั้งหมด  
 $AP_i$  = ค่าเฉลี่ยความแม่นยำของคลาสที่  $i$

### 3.4.2 เกณฑ์ประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

งานวิจัยนี้ประเมินประสิทธิภาพของตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยค่าความแม่นยำ (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าเอฟเมเชอร์ (F-measure) มีรายละเอียดดังนี้

เครื่องมือที่ใช้วัดประสิทธิภาพของการจำแนกข้อมูลนิยมใช้เมทริกซ์วัดประสิทธิภาพ (Confusion Matrix) ที่แสดงผลการจำแนกจากกลุ่มข้อมูลจริงและกลุ่มข้อมูลจากการทำนายซึ่งมีขนาด  $m \times m$  โดยที่  $m$  คือ จำนวนของคลาส ตัวอย่างเมทริกซ์วัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลแบบ 2 กลุ่ม แสดงดังในตารางที่ 3.5 (Witten, Frank, and Hall., 2011, p. 164)

ตารางที่ 3.5 เมทริกซ์วัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลแบบ 2 กลุ่ม

		Predicted class	
		Yes	No
Actual class	Yes	True Positive (TP)	False Negative (FN)
	No	False Positive (FP)	True Negative (TN)

จากตารางที่ 3.5 แถวของเมทริกซ์แสดงจำนวนของตัวอย่างจริงของแต่ละคลาสและคอลัมน์แสดงจำนวนที่ทำนายได้ของแต่ละคลาส โดยแบ่งออกเป็น 4 กรณี ดังนี้

1. ค่า True Positive หรือ TP คือ จำนวนข้อมูลที่อยู่ในคลาส Positive แล้วตัวแบบทำนายว่าเป็นคลาส Positive
2. ค่า False Negative หรือ FN คือ จำนวนข้อมูลที่อยู่ในคลาส Positive แล้วตัวแบบทำนายว่าเป็นคลาส Negative
3. ค่า False Positive หรือ FP คือ จำนวนข้อมูลที่อยู่ในคลาส Negative แล้วตัวแบบทำนายว่าเป็นคลาส Positive



4. ค่า True Negative หรือ TN คือ จำนวนข้อมูลที่อยู่ในคลาส Negative แล้วตัวแบบทำนายว่าเป็นคลาส Negative

โดยใช้เกณฑ์ในการประเมินประสิทธิภาพการจำแนกข้อมูลประกอบด้วย ค่าความแม่นยำ (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าเอฟเมเชอร์ (F-measure) ดังสมการที่ 3.9, 3.10, 3.11 และ 3.12

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.9)$$

$$Precision = \frac{TP}{TP+FP} \quad (3.10)$$

$$Recall = \frac{TP}{TP+FN} \quad (3.11)$$

$$F - measure = \frac{(2 * Precision * Recall)}{(Precision + Recall)} \quad (3.12)$$

สำหรับงานวิจัยนี้ใช้เมทริกซ์วัดประสิทธิภาพ (Confusion Matrix) ที่แสดงผลสรุปของการประเมินความสามารถในการจำแนกข้อมูลจากการทดสอบด้วยชุดข้อมูลทดสอบแบบผลลัพธ์ 7 ค่า ได้แก่ หลุมบ่อ รอยแตกตามแนวยาว รอยแตกตามแนวขวาง รอยแตกผนังกระเซ้ รอยปะซ่อม เนินชะลอความเร็ว/ เส้นชะลอความเร็ว และถนนปกติที่มีสภาพแวดล้อมแตกต่างกัน (เงา แสงสะท้อน คราบสี คราบน้ำมัน) โดยมีรูปแบบดังตารางที่ 3.6

ตารางที่ 3.6 เมทริกซ์วัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลแบบ 7 กลุ่ม

ผลการจำแนก สภาพพื้นผิวถนน		สภาพพื้นผิวถนนจากผลการทำนายของตัวแบบ						
		หลุมบ่อ	รอยแตก ตามแนว ยาว	รอยแตก ตามแนว ขวาง	รอยแตก ผนังกระเซ้	รอยปะซ่อม	เนินชะลอ ความเร็ว	ถนนปกติ
สภาพพื้นผิวถนนจริง	หลุมบ่อ	A1	A2	A3	A4	A5	A6	A7
	รอยแตกตามแนวยาว	B1	B2	B3	B4	B5	B6	B7
	รอยแตกตามแนวขวาง	C1	C2	C3	C4	C5	C6	C7
	รอยแตกผนังกระเซ้	D1	D2	D3	D4	D5	D6	D7
	รอยปะซ่อม	E1	E2	E3	E4	E5	E6	E7
	เนินชะลอความเร็ว	F1	F2	F3	F4	F5	F6	F7
	ถนนปกติ	G1	G2	G3	G4	G5	G6	G7

จากตารางที่ 3.6 แสดงแถวของเมทริกซ์ที่แสดงจำนวนของตัวอย่างสภาพพื้นผิวถนนจริงของแต่ละคลาส และคอลัมน์ที่แสดงจำนวนการทำนายได้ของแต่ละคลาส โดยแบ่งออกเป็น 49 กรณี แทนด้วยตัวแปร A1 – A7, B1 – B7, C1 – C7, D1 – D7, E1 – E7, F1 – F7, G1 – G7, H1 – H7, I1 – I7 และ J1 – J7

จากนั้นนำผลลัพธ์การจำแนกข้อมูลสภาพพื้นผิวถนนในตารางที่ 3.6 มาคำนวณหาค่าผลการประเมินประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลทั้ง 7 กลุ่ม ดังนี้

### 1) ค่าความแม่นยำ (Accuracy)

เป็นเกณฑ์ที่ใช้วัดความถูกต้องหรือความแม่นยำในการจำแนกประเภทข้อมูลโดยรวมทุกคลาสของตัวแบบดังสมการที่ 3.13

$$\text{Accuracy} = \frac{A1+B2+C3+D4+E5+F6+G7}{(A1+\dots+A7+B1+\dots+B7+C1+\dots+C7+D1+\dots+D7+E1+\dots+E7+F1+\dots+F7+G1+\dots+G7)} \quad (3.13)$$

### 2) ค่าความแม่นยำ (Precision)

เป็นเกณฑ์ที่ใช้วัดความแม่นยำในการจำแนกประเภทข้อมูลของตัวแบบ โดยพิจารณาจำนวนข้อมูลทำนายที่อยู่ในคลาสนั้นเทียบกับจำนวนข้อมูลที่ทำนายว่าเป็นคลาสนั้นทั้งหมด ดังสมการที่ 3.14

$$\text{Precision} = \frac{\text{จำนวนข้อมูลทำนายที่อยู่ในคลาสนั้น}}{\text{จำนวนข้อมูลที่ทำนายว่าเป็นคลาสนั้นทั้งหมด}} \quad (3.14)$$

การคำนวณค่าความแม่นยำในการจำแนกประเภทข้อมูลของตัวแบบในแต่ละคลาสมีดังนี้

$$\text{Precision ของคลาสดูมบ่อ} = \frac{A1}{(A1+B1+C1+D1+E1+F1+G1)} \quad (3.15)$$

$$\text{Precision ของคลาสรอยแตกตามแนวยาว} = \frac{B2}{(B2+A2+C2+D2+E2+F2+G2)} \quad (3.16)$$

$$\text{Precision ของคลาสรอยแตกตามแนวขวาง} = \frac{C3}{(C3+A3+B3+D3+E3+F3+G3)} \quad (3.17)$$

$$\text{Precision ของคลาสรอยแตกหนึ่งจระเข้} = \frac{D4}{(D4+A4+B4+C4+E4+F4+G4)} \quad (3.18)$$

$$\text{Precision ของคลาสรอยปะซ่อม} = \frac{E5}{(E5+A5+B5+C5+D5+F5+G5)} \quad (3.19)$$

$$\text{Precision ของคลาสเนินชะลอความเร็ว} = \frac{F6}{(F6+A5+B5+C5+D5+E5+G5)} \quad (3.20)$$

$$\text{Precision ของคลาสถนนปกติ} = \frac{G7}{(G7+A7+B7+C7+D7+E7+F7)} \quad (3.21)$$

### 3) ค่าความระลึก (Recall)

เป็นเกณฑ์ที่ใช้วัดค่าความระลึกในการจำแนกประเภทข้อมูลของตัวแบบ โดยพิจารณาจำนวนข้อมูลทำนายที่อยู่ในคลาสนั้นเทียบกับจำนวนข้อมูลจริงทั้งหมดของคลาสนั้น ดังสมการที่ 3.21

$$\text{Recall} = \frac{\text{จำนวนข้อมูลทำนายที่อยู่ในคลาสนั้น}}{\text{จำนวนข้อมูลจริงทั้งหมดของคลาสนั้น}} \quad (3.22)$$

การคำนวณค่าความระลึกในการจำแนกประเภทข้อมูลของตัวแบบในแต่ละคลาส มีดังนี้

$$\text{Recall ของคลาสหุ้มโป้} = \frac{A1}{(A1+A2+A3+A4+A5+A6+A7)} \quad (3.23)$$

$$\text{Recall ของคลาสรอยแตกตามแนวยาว} = \frac{B2}{(B2+B1+B3+B4+B5+B6+B7)} \quad (3.24)$$

$$\text{Recall ของคลาสรอยแตกตามแนวขวาง} = \frac{C3}{(C3+C1+C2+C4+C5+C6+C7)} \quad (3.25)$$

$$\text{Recall ของคลาสรอยแตกหนึ่งจระเข้} = \frac{D4}{(D4+D1+D2+D3+D5+D6+D7)} \quad (3.26)$$

$$\text{Recall ของคลาสรอยปะซ่อม} = \frac{E5}{(E5+E1+E2+E3+E4+E6+E7)} \quad (3.27)$$

$$\text{Recall ของคลาสเนินชะลอความเร็ว} = \frac{F6}{(F6+F1+F2+F3+F4+F5+F7)} \quad (3.28)$$

$$\text{Recall ของคลาสถนนปกติ} = \frac{G7}{(G7+G1+G2+G3+G4+G5+G6)} \quad (3.29)$$

#### 4) ค่าเอฟเมเชอร์ (F-measure)

เป็นการวัดความแม่นยำโดยดูจากผลเฉลี่ยของ Precision และ Recall ดังสมการที่ 3.29

$$F\text{-measure} = \frac{(2 \times \text{ค่า Precision} \times \text{ค่า Recall})}{(\text{ค่า Precision} + \text{ค่า Recall})} \quad (3.30)$$

การคำนวณค่าเอฟเมเชอร์ในการจำแนกประเภทข้อมูลของตัวแบบในแต่ละคลาส

มีดังนี้

$$F\text{-measure ของคลาสหลุมบ่อ} = \frac{(2 \times \text{ค่า Precision ของคลาสหลุมบ่อ} \times \text{ค่า Recall ของคลาสหลุมบ่อ})}{(\text{ค่า Precision ของคลาสหลุมบ่อ} + \text{ค่า Recall ของคลาสหลุมบ่อ})} \quad (3.31)$$

$$F\text{-measure ของคลาสรอยแตกตามแนวยาว} = \frac{(2 \times \text{ค่า Precision ของคลาสรอยแตกตามแนวยาว} \times \text{ค่า Recall ของคลาสรอยแตกตามแนวยาว})}{(\text{ค่า Precision ของคลาสรอยแตกตามแนวยาว} + \text{ค่า Recall ของคลาสรอยแตกตามแนวยาว})} \quad (3.32)$$

$$F\text{-measure ของคลาสรอยแตกตามแนวขวาง} = \frac{(2 \times \text{ค่า Precision ของคลาสรอยแตกตามแนวขวาง} \times \text{ค่า Recall ของคลาสรอยแตกตามแนวขวาง})}{(\text{ค่า Precision ของคลาสรอยแตกตามแนวขวาง} + \text{ค่า Recall ของคลาสรอยแตกตามแนวขวาง})} \quad (3.33)$$

$$F\text{-measure ของคลาสรอยแตกหนึ่งจระเข้} = \frac{(2 \times \text{ค่า Precision ของคลาสรอยแตกหนึ่งจระเข้} \times \text{ค่า Recall ของคลาสรอยแตกหนึ่งจระเข้})}{(\text{ค่า Precision ของคลาสรอยแตกหนึ่งจระเข้} + \text{ค่า Recall ของคลาสรอยแตกหนึ่งจระเข้})} \quad (3.34)$$

$$F\text{-measure ของคลาสรอยปะช่อม} = \frac{(2 \times \text{ค่า Precision ของคลาสรอยปะช่อม} \times \text{ค่า Recall ของคลาสรอยปะช่อม})}{(\text{ค่า Precision ของคลาสรอยปะช่อม} + \text{ค่า Recall ของคลาสรอยปะช่อม})} \quad (3.35)$$

$$F\text{-measure ของคลาสเนินชะลอกความเร็ว} = \frac{(2 \times \text{ค่า Precision ของคลาสเนินชะลอกความเร็ว} \times \text{ค่า Recall ของคลาสเนินชะลอกความเร็ว})}{(\text{ค่า Precision ของคลาสเนินชะลอกความเร็ว} + \text{ค่า Recall ของคลาสเนินชะลอกความเร็ว})} \quad (3.36)$$

$$F\text{-measure ของคลาสถนนปกติ} = \frac{(2 \times \text{ค่า Precision ของคลาสถนนปกติ} \times \text{ค่า Recall ของคลาสถนนปกติ})}{(\text{ค่า Precision ของคลาสถนนปกติ} + \text{ค่า Recall ของคลาสถนนปกติ})} \quad (3.37)$$

## บทที่ 4


### ผลการวิจัยและการอภิปรายผล

ในบทนี้กล่าวถึงผลการวิจัยและการอภิปรายผล ประกอบด้วย ผลการสร้างชุดข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ผลการประเมินตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติและผลการประเมินขั้นตอนวิธีในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ โดยมีรายละเอียดดังนี้

#### 4.1 ผลการสร้างชุดข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

ข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนถูกเก็บรวบรวมบนสภาพพื้นผิวถนนลาดยางแอสฟัลท์ในจังหวัดนครราชสีมา จากกล้องบันทึกวิดีโอในโทรศัพท์รุ่น Samsung Galaxy A9 Pro ปี 2016 ที่ถูกติดตั้งบนคอนโซลหน้ารถยนต์รุ่น Honda City 2010 ระยะทางจากจุดตั้งโทรศัพท์ไปจนถึงจุดที่สามารถเห็นภาพได้ชัดเจน คือ 6.5 เมตร ดังรูปที่ 4.1 โปรแกรมที่ใช้บันทึกภาพวิดีโอถูกพัฒนาขึ้นบนระบบปฏิบัติการแอนดรอยด์ กำหนดค่าเริ่มต้นของระบบ ดังนี้ ความละเอียดของภาพเท่ากับ 1080p นั่นคือ ขนาดภาพจะมีค่าเท่ากับ 1920 x 1080 พิกเซล อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความถี่ในการจัดเก็บภาพเท่ากับ 80 Hz ขับรถเก็บรวบรวมข้อมูลด้วยความเร็ว 40 - 60 กิโลเมตร/ชั่วโมง รวมระยะทางประมาณ 350 กิโลเมตร

ข้อมูลที่ถูกจัดเก็บ ได้แก่ วัน เวลา ละติจูด ลองจิจูด ภาพวิดีโอสภาพพื้นผิวถนนทั้ง 7 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks), 3) รอยแตกตามแนวขวาง (Transverse Cracks), 4) รอยแตกหนังจระเข้ (Alligator Cracks), 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed Bumps) และ 7) ถนนปกติ (Normal Road) ตามสภาพแวดล้อมทางธรรมชาติที่แตกต่างกัน



รูปที่ 4.1 การติดตั้งโทรศัพท์สมาร์ทโฟนและระยะทางที่ใช้ในการตรวจจับสภาพพื้นผิวถนน



เช่น ขนาด รูปทรง แสงเงาของต้นไม้ รอยคราบสกปรก คราบน้ำมันและเครื่องหมายจราจรบนผิวถนน ผลการสร้างชุดข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ ประกอบด้วย 2 ชุดข้อมูล ได้แก่ ชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ และชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ มีรายละเอียดดังนี้

#### 4.1.1 ชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ






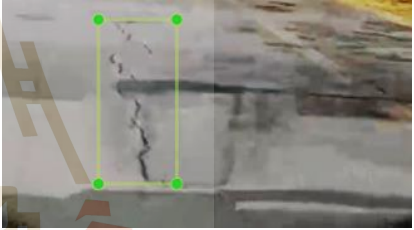



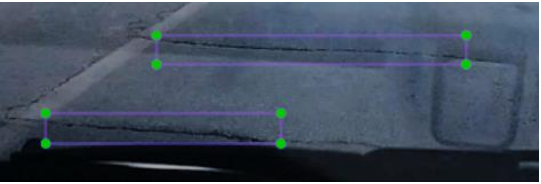


ชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติมีทั้งสิ้น 6,584 ภาพ ประกอบด้วย กรอบล้อมวัตถุพร้อมทั้งระบุประเภทสภาพพื้นผิวถนนใน 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) ซึ่งมีจำนวนทั้งสิ้น 10,240 วัตถุ จากนั้น สุ่มแบ่งข้อมูลรูปภาพจำนวน 70% (7,168) ใช้เป็นชุดข้อมูลเรียนรู้ (Training Dataset) และ 30% (3,072) ใช้เป็นชุดข้อมูลทดสอบ (Testing Dataset) ดังตารางที่ 4.1

ตารางที่ 4.1 จำนวนชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ








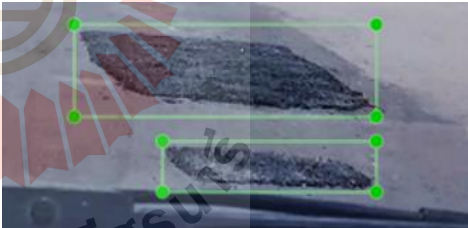
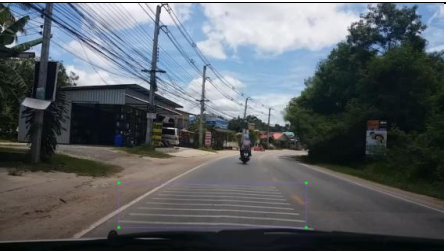



ประเภทสภาพพื้นผิวถนน	จำนวนของวัตถุ (Bounding Boxes)		
	ข้อมูลเรียนรู้	ข้อมูลทดสอบ	รวม
หลุมบ่อ	1,294	565	1,859
รอยแตกตามแนวยาว	1,399	595	1,994
รอยแตกตามแนวขวาง	1,100	443	1,543
รอยแตกหนังจระเข้	1,244	565	1,809
รอยปะซ่อม	1,292	539	1,831
เนินชะลอความเร็ว	839	365	1,204
<b>รวม</b>	<b>7,168</b>	<b>3,072</b>	<b>10,240</b>

ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการตรวจจับสภาพพื้นผิวถนนในแต่ละประเภทแสดงดังตารางที่ 4.2

ตารางที่ 4.2 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการตรวจจับสภาพพื้นผิวถนน

ภาพต้นฉบับ	ภาพขยาย
<b>1. สภาพพื้นผิวถนนประเภทหลุมบ่อ</b>	
	
	
<b>2. สภาพพื้นผิวถนนประเภทรอยแตกตามแนวยาว</b>	
	
	
<b>3. สภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวาง</b>	
	
	

ตารางที่ 4.2 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการตรวจจับสภาพพื้นผิวถนน (ต่อ)

ภาพต้นฉบับ	ภาพขยาย
<b>4. สภาพพื้นผิวถนนประเภทรอยแตกหน้าจระเข้</b>	
	
	
<b>5. สภาพพื้นผิวถนนประเภทรอยปะซ่อม</b>	
	
	
<b>6. สภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว</b>	
	
	



#### 4.1.2 ชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

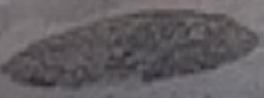

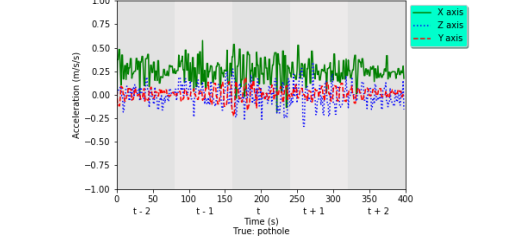


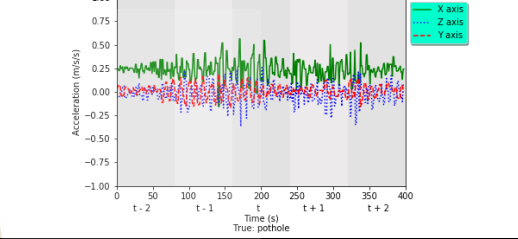
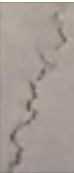

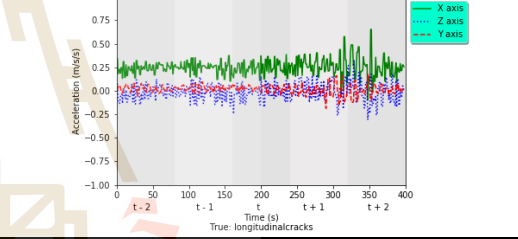


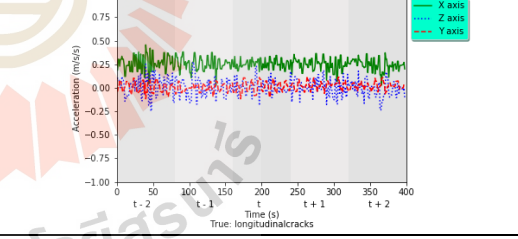
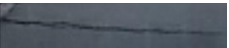
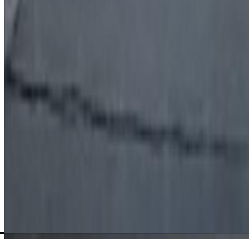
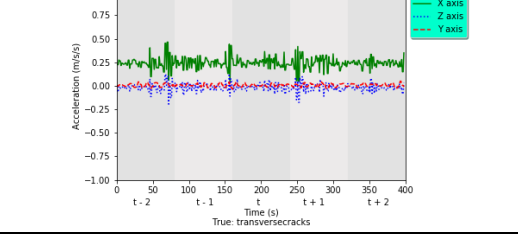


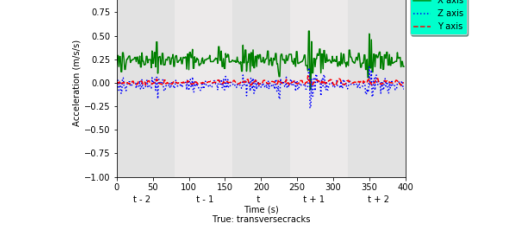
ชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติมีทั้งหมด 6,399 ภาพประกอบด้วยรูปภาพวัตถุพร้อมทั้งระบุประเภทสภาพพื้นผิวถนนใน 7 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนั้จระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal Road) จากนั้นสั้แบ่งข้อมูลรูปภาพจำนวน 70% (4,480) ใช้เป็นชุดข้อมูลเรียนรู้ (Training Dataset) และ 30% (1,919) ใช้เป็นชุดข้อมูลทดสอบ (Testing Dataset) ดังตารางที่ 4.3

ตารางที่ 4.3 จำนวนชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

ประเภทสภาพพื้นผิวถนน	จำนวนชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน		
	ข้อมูลเรียนรู้	ข้อมูลทดสอบ	รวม
หลุมบ่อ	654	280	934
รอยแตกตามแนวยาว	641	274	915
รอยแตกตามแนวขวาง	643	276	919
รอยแตกหนั้จระเข้	637	273	910
รอยปะซ่อม	633	271	904
เนินชะลอความเร็ว	639	274	913
ถนนปกติ	633	271	904
รวม	4,480	1,919	6,399

ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการจำแนกสภาพพื้นผิวถนนแสดงดังตารางที่ 4.4

ตารางที่ 4.4 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการจำแนกสภาพพื้นผิวถนน

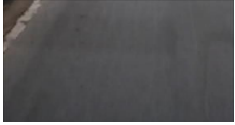

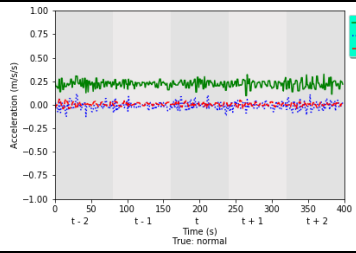


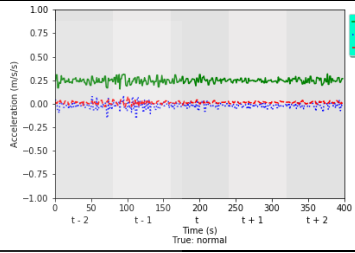
ภาพที่ถูกตัด	ภาพที่ถูกปรับขนาด	กราฟข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน
<b>1. สภาพพื้นผิวถนนประเภทหลุมบ่อ</b>		
		
		
<b>2. สภาพพื้นผิวถนนประเภทรอยแตกตามแนวยาว</b>		
		
		
<b>3. สภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวาง</b>		
		
		

ตารางที่ 4.4 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการจำแนกสภาพพื้นผิวถนน (ต่อ)

ภาพที่ถูกตัด	ภาพที่ถูกปรับขนาด	กราฟข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน
<b>4. สภาพพื้นผิวถนนประเภทรอยแตกหนึ่งจระเข้</b>		
<b>5. สภาพพื้นผิวถนนประเภทรอยปะซ่อม</b>		
<b>6. สภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว</b>		



ตารางที่ 4.4 ตัวอย่างชุดข้อมูลเรียนรู้และทดสอบสำหรับการจำแนกสภาพพื้นผิวถนน (ต่อ)

ภาพที่ถูกต้อง	ภาพที่ถูกปรับขนาด	กราฟข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน
<b>7. สภาพพื้นผิวถนนประเภทถนนปกติ</b>		
		
		

## 4.2 ผลการประเมินตัวแบบในการตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

การประเมินตัวแบบ ประกอบด้วย 2 ส่วน ได้แก่ 1) การประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เพื่อเปรียบเทียบตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าแล้วเลือกตัวแบบที่เหมาะสมมาใช้ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและ 2) การประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบการเรียนรู้เชิงลึกหลายรูปแบบเพื่อเพิ่มความแม่นยำในขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติที่นำเสนอในงานวิจัยนี้ ผลการประเมินตัวแบบ มีดังนี้

### 4.2.1 ผลการประเมินตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

งานวิจัยนี้เสนอแนวทางในการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ จำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนั่งจระเข้ (Alligator Cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) โดยทำการเปรียบเทียบประสิทธิภาพของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Models) ที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงที่สุด จำนวน 5 ลำดับแรก เมื่อทดสอบชุดข้อมูลรูปภาพของโคโค ได้แก่ 1) Faster R-CNN NAS (FRN) 2) Faster R-CNN Inception\_ResNetV2 Atrous (FRIR) 3) SSD ResNet50 FPN (SRF) 4) SSD MobileNetV1 FPN (SMF) และ 5) Faster R-CNN ResNet101 (FRR) เพื่อเลือกใช้ตัวแบบถูกฝึกมาแล้วล่วงหน้า

ที่มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด (mAP) เมื่อทดสอบบนชุดข้อมูลรูปภาพของสภาพพื้นผิวถนนที่ผิดปกติ

ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติถูกเรียนรู้และทดสอบบนกูเกิลคลาวด์แพลตฟอร์ม (Google Cloud Platform) ด้วย GPU รุ่น NVIDIA Tesla T4 แรม 20 GB

การกำหนดค่าตัวแปรสำหรับการสอนและทดสอบตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ทั้ง 5 ตัวแบบ แสดงดังตารางที่ 4.5

กระบวนการสอนตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ในงานวิจัยนี้ใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) สูงสุดจำนวน 5 ลำดับแรก บนชุดข้อมูลรูปภาพของโคโค (COCO Dataset) (Pikulz, 2019) จากนั้นจึงใช้เทคนิคการถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติ กระบวนการเริ่มจากการใช้ขั้นสุดท้ายที่มีข้อมูลประเภทที่ต้องการตรวจจับจากตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าแล้วแทนที่ด้วยข้อมูลประเภทสภาพพื้นผิวถนนที่ผิดปกติจำนวน 6 ประเภท ได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง 4) รอยแตกหนึ่งจระเข้ 5) รอยปะช่อม และ 6) เนินชะลอความเร็ว โดยกระบวนการนี้ใช้ขั้นตอนการตรวจจับและการจำแนกคุณลักษณะที่ได้รับการสอนจากตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อถ่ายโอนการเรียนรู้และใช้คุณลักษณะของสภาพพื้นผิวถนนที่ผิดปกติมาสอนตัวแบบตรวจจับข้อมูลประเภทใหม่

เริ่มต้นการสอนตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าให้เรียนรู้คุณลักษณะของสภาพพื้นผิวถนนที่ผิดปกติ ดังแสดงในรูปที่ 4.2

```

strength l edge matrix
2019-01-29 17:17:32.194277: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1988] 0
2019-01-29 17:17:32.194295: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1100] 0: N
2019-01-29 17:17:32.195255: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1115] Created TensorFlow device (/job:localh
ost/replica:0/task:0/device:GPU:0 with 14028 MB memory) -> physical GPU (device: 0, name: Tesla T4, pci bus id: 0000:00:04.
0) compute capability: 7.5)
INFO:tensorflow:Restoring parameters from faster_rcnn_resnet101_coco_11_06_2017/model.ckpt
INFO:tensorflow:Running local init op.
INFO:tensorflow:Done running local init op.
INFO:tensorflow:Starting Session.
INFO:tensorflow:saving checkpoint to path train_datasetRoadsurface_faster_rcnn_resnet101/model.ckpt
INFO:tensorflow:Starting Queues.
INFO:tensorflow:global_step/sec: 0
INFO:tensorflow:Recording summary at step 0.
INFO:tensorflow:global step 1: loss = 3.5306 (24.329 sec/step)
INFO:tensorflow:global step 2: loss = 3.3364 (0.375 sec/step)
INFO:tensorflow:global step 3: loss = 3.2235 (0.371 sec/step)
INFO:tensorflow:global step 4: loss = 3.0542 (0.367 sec/step)
INFO:tensorflow:global step 5: loss = 2.5349 (0.362 sec/step)
INFO:tensorflow:global step 6: loss = 2.2591 (0.367 sec/step)
INFO:tensorflow:global step 7: loss = 2.1538 (0.368 sec/step)
INFO:tensorflow:global step 8: loss = 1.5110 (0.369 sec/step)
INFO:tensorflow:global step 9: loss = 1.5813 (0.366 sec/step)
INFO:tensorflow:global step 10: loss = 0.9829 (0.364 sec/step)
INFO:tensorflow:global step 11: loss = 1.0669 (0.350 sec/step)
INFO:tensorflow:global step 12: loss = 1.0741 (0.373 sec/step)
INFO:tensorflow:global step 13: loss = 0.9586 (0.372 sec/step)
INFO:tensorflow:global step 14: loss = 0.8197 (0.364 sec/step)
INFO:tensorflow:global step 15: loss = 0.6479 (0.360 sec/step)
INFO:tensorflow:global step 16: loss = 0.8123 (0.375 sec/step)
INFO:tensorflow:global step 17: loss = 0.7367 (0.367 sec/step)
INFO:tensorflow:global step 18: loss = 0.8290 (0.367 sec/step)
INFO:tensorflow:global step 19: loss = 0.5765 (0.367 sec/step)
INFO:tensorflow:global step 20: loss = 0.5637 (0.370 sec/step)
INFO:tensorflow:global step 21: loss = 0.4919 (0.361 sec/step)
INFO:tensorflow:global step 22: loss = 0.6124 (0.371 sec/step)
INFO:tensorflow:global step 23: loss = 0.5296 (0.379 sec/step)

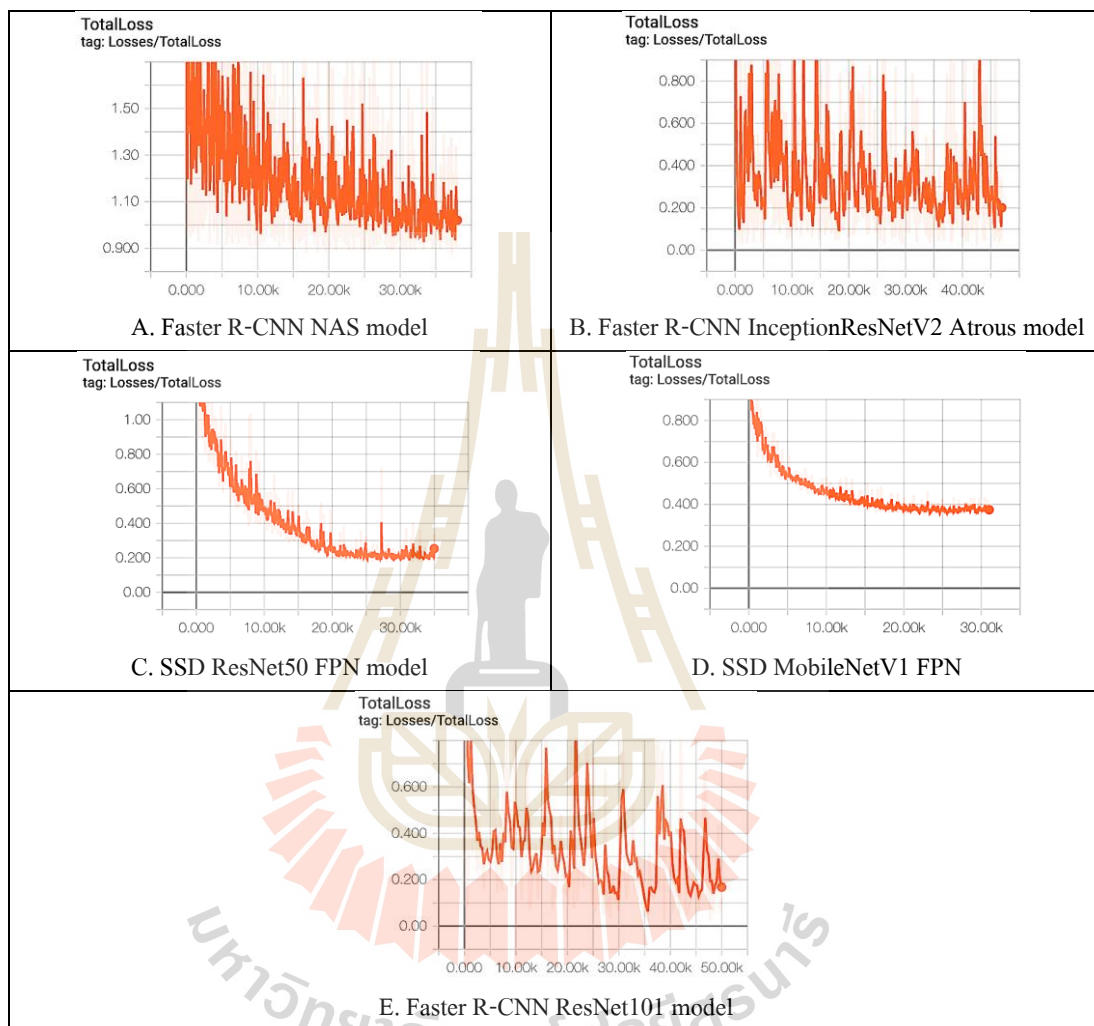
```

รูปที่ 4.2 แสดงข้อมูลผลการประเมินระหว่างการสอนของตัวแบบ

ตารางที่ 4.5 การกำหนดค่าตัวแปรสำหรับการสอนตัวแบบที่ถูกต้องขึ้นมาแล้วล่วงหน้าสำหรับตรวจจับสภาพพื้นผิวก้อนที่ผิดปกติ

การตั้งค่า	ชื่อตัวแปร	คำอธิบาย	ค่าตัวแปรของแต่ละตัวแบบ				
			Faster R-CNN NAS	Faster R-CNN Inception_ResNetV2 Atrous	SSD ResNet50 FPN	SSD MobileNetV1 FPN	Faster R-CNN ResNet101
ภาพนำเข้า	fixed_shape_resizer	ขนาดรูปภาพ	1200 x 1200	600 x 1024	640 x 640	640 x 640	600 x 1024
	num_class	จำนวนประเภทข้อมูล สภาพพื้นถนน	6	6	6	6	6
	batch_size	จำนวนของรูปภาพ ตัวอย่างในแต่ละรอบ การสอน	1	1	64	64	1
การสอน	learning_rate	อัตราการเรียนรู้	0.0003	0.0003	0.0400	0.0400	0.0003
	fine_tune_checkpoint	เส้นทางไปยังตัวแบบ ที่ถูกต้องขึ้นมาแล้วล่วงหน้า	./model.ckpt	./model.ckpt	./model.ckpt	./model.ckpt	./model.ckpt
	train_input_reader	เส้นทางไปยังไฟล์ TFRecord	./Train.record	./Train.record	./Train.record	./Train.record	./Train.record
	label_map_path	แผนที่ป้ายกำกับการสอน	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt
	eval_input_reader	เส้นทางไปยังไฟล์ TFRecord	./Test.record	./Test.record	./Test.record	./Test.record	./Test.record
การทดสอบ	label_map_path	แผนที่ป้ายกำกับ การทดสอบ	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt	./label_map.pbtxt

ในระหว่างการสอนและตรวจสอบประสิทธิภาพของตัวแบบที่ได้รับการสอนในครั้งนี้ สามารถสังเกตการแสดงผลการทำงานได้บน Tensorboard ซึ่งเป็นเครื่องมือที่สามารถนำข้อมูลการสอนของตัวแบบมาแสดงผลภายนอกได้ ดังแสดงในรูปที่ 4.3




รูปที่ 4.3 กราฟแสดงการสูญเสียทั้งหมด (Total Loss) ของตัวแบบ

ในระหว่างการสอนตัวแบบ ผู้วิจัยทำการสังเกตค่าสูญเสียการสอน (Training Loss) ซึ่งจะค่อย ๆ ลดลงตามการเรียนรู้ในแต่ละรอบ หากการสูญเสียการสอนนั้นสูงขึ้นหรือเริ่มคงที่ ผู้วิจัยจะทำการหยุดการสอนที่รอบการสอนนั้น หลังจากดำเนินการสอนของตัวแบบ SSD ResNet50 FPN ดังแสดงในรูปที่ 4.3 C. พบว่า รอบที่ 34,833 รอบ ค่าการสูญเสียทั้งหมด (Total Loss) ลดลงถึง 0.20661 ซึ่งมีแนวโน้มการลดลงอย่างต่อเนื่อง โดยปลายกราฟพุ่งเข้าใกล้ 0 แสดงให้เห็นว่า ตัวแบบสามารถเรียนรู้ข้อมูลได้ดี ยิ่งไปกว่านั้น ค่าการสูญเสียทั้งหมดของตัวแบบ SSD ResNet50 FPN ยังน้อยกว่าตัวแบบ SSD MobileNetV1 FPN ซึ่งค่าการสูญเสียทั้งหมดลดลงถึง




0.35816 ดังแสดงในรูปที่ 4.3 D. ส่วนตัวแบบ Faster R-CNN ResNet101 ตัวแบบ Faster R-CNN Inception\_ResNetV2 Atrous และตัวแบบ Faster R-CNN NAS ซึ่งกราฟแสดงค่าการสูญเสียทั้งหมด ขึ้นลงไม่คงที่ ดังแสดงในรูปที่ 4.3 A, B, และ E. แสดงว่าตัวแบบมีความไม่เสถียรหรือไม่สามารถเรียนรู้ข้อมูลได้ดีกว่าตัวแบบ SSD ResNet50 FPN และตัวแบบ SSD MobileNetV1 FPN ที่กราฟแสดงค่าการสูญเสียทั้งหมดมีแนวโน้มการลดลงอย่างต่อเนื่องโดยปลายกราฟลู่เข้าใกล้ 0

นอกจากนี้ในระหว่างการสอนตัวแบบสามารถสังเกตการประเมินผลของภาพตัวอย่างในแต่ละรอบการสอนได้บน Tensorboard ดังแสดงในรูปที่ 4.4



รูปที่ 4.4 การประเมินผลตรวจจับของภาพตัวอย่างในแต่ละรอบการสอน



รูปที่ 4.4 การประเมินผลตรวจจับของภาพตัวอย่างในแต่ละรอบการสอน (ต่อ)

ผลการประเมินความแม่นยำและประสิทธิภาพของตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ แสดงดังตารางที่ 4.6

ตารางที่ 4.6 ผลการประเมินความแม่นยำของตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลรูปภาพทดสอบ

ตัวแบบ*	ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP)	ค่าเฉลี่ยความแม่นยำ (AP) เมื่อ IoU ≥ 0.5					เนินชะลอความเร็ว
		หลุมบ่อ	รอยแตกตามแนวยาว	รอยแตกตามแนวขวาง	รอยแตกหนังจระเข้	รอยปะซ่อม	
FRN	81.83	81.01	76.60	82.95	80.01	70.77	<b>99.67</b>
FRIR	84.34	80.90	<b>79.35</b>	82.02	87.47	77.33	98.97
SRF	<b>87.38</b>	<b>84.39</b>	79.02	<b>92.77</b>	<b>87.55</b>	<b>80.94</b>	99.63
SMF	85.21	82.90	76.25	89.56	86.70	76.41	99.47
FRR	83.53	77.26	78.85	88.43	86.33	70.77	99.33

หมายเหตุ \* FRN = Faster R-CNN NAS, FRIR = Faster R-CNN Inception\_ResNetV2 Atrous, SRF = SSD ResNet50 FPN, SMF = SSD MobileNetV1 FPN, และ FRR = Faster R-CNN ResNet101



จากตารางที่ 4.6 พบว่า ตัวแบบ SRF มีค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) บนชุดข้อมูลทดสอบ เมื่อกำหนดค่าไอโอยู (IoU) มากกว่าหรือเท่ากับ 0.5 และเกณฑ์ค่าความเชื่อมั่น (Confidence Score Threshold) เท่ากับ 0.0 คือ 87.38% รองลงมา คือ ตัวแบบ SMF, FRIR, FRR และ FRN ซึ่งได้ค่า mAP เท่ากับ 85.21%, 84.34%, 83.53% และ 81.83% ตามลำดับ นั้นแสดงว่า ตัวแบบ SRF สามารถตรวจจับสภาพพื้นผิวถนนทั้ง 4 ประเภทได้ดีกว่าอีก 4 ตัวแบบที่นำมาเปรียบเทียบในการทดลองครั้งนี้ เมื่อเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของแต่ละตัวแบบ พบว่า ตัวแบบ SRF ให้ค่าเฉลี่ยความแม่นยำสูงที่สุด จำนวน 4 คลาส ได้แก่ รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ หลุมบ่อและรอยปะซ่อม ซึ่งได้ค่า AP เท่ากับ 92.77%, 87.55%, 84.39% และ 80.94% ตามลำดับ รองลงมาคือ รอยแตกตามแนวยาว และเนินชะลอความเร็ว ซึ่งได้ค่า AP เท่ากับ 79.02% และ 99.63%

ตารางที่ 4.7 ผลการประเมินประสิทธิภาพของตัวแบบสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ตัวแบบ	ระยะเวลาการเรียนรู้ (ชั่วโมง)	ระยะเวลาทดสอบ (ชั่วโมง)	ระยะเวลาทดสอบต่อ 1 ภาพ (วินาที)
FRN	~ 41	~ 1.45	~ 2.0507
FRIR	~ 15	~ 0.27	~ 0.5273
SRF	~ 28	~ 0.03	~ 0.0585
SMF	~ 26	~ 0.02	~ 0.0390
FRR	~ 6	~ 0.07	~ 0.1367

จากตารางที่ 4.7 พบว่า ตัวแบบที่ใช้เวลาเรียนรู้มากที่สุด คือ FRN ซึ่งใช้เวลาประมาณ 41 ชั่วโมง รองลงมา คือ ตัวแบบ SRF, SMF, FRIR และ FRR ซึ่งใช้เวลาเรียนรู้ประมาณ 28, 26, 15 และ 6 ชั่วโมง ตามลำดับ ส่วนตัวแบบ SMF ใช้เวลาทดสอบน้อยที่สุด ซึ่งใช้เวลาประมาณ 2 นาที (1 ภาพใช้เวลาประมาณ 0.039 วินาที) รองลงมา คือ ตัวแบบ SRF, FRR, FRIR และ FRN ซึ่งใช้เวลาทดสอบประมาณ 3, 7, 27 นาที และ 1 ชั่วโมง 45 นาที ตามลำดับ

แม้ว่าตัวแบบ FRN และ FRIR มีค่า mAP มากกว่าตัวแบบ SRF บนชุดข้อมูลทดสอบของโคโค แต่อย่างไรก็ตามเมื่อนำตัวแบบ FRN และ FRIR มาถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ พบว่า ทั้งสองตัวแบบให้ค่า mAP น้อยกว่าตัวแบบ SRF บนชุดข้อมูลทดสอบสภาพพื้นผิวถนนที่ผิดปกติ ดังนั้น การนำโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกที่ผ่านการฝึกมาแล้วล่วงหน้าที่มีโครงสร้างของตัวตรวจจับวัตถุและโครงสร้างของตัวสกัดคุณลักษณะที่แตกต่างกัน มาใช้เทคนิคการถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับงานตรวจจับวัตถุอื่น ๆ ควรพิจารณาเปรียบเทียบผลการประเมิน

ความแม่นยำและประสิทธิภาพของแต่ละตัวแบบ เพื่อเลือกใช้ตัวแบบที่เหมาะสมกับชุดข้อมูล สำหรับงานตรวจจับวัตถุ นั้น ๆ

ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้าที่เหมาะสมสำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ คือ ตัวแบบ SRF (SSD ResNet50 FPN) ซึ่งให้ค่า mAP สูงที่สุด โดยมีโครงสร้างของตัวตรวจจับวัตถุแบบ SSD และมีโครงสร้างของการสกัดคุณลักษณะแบบ Resnet 50 FPN จุดเด่นของโครงสร้างแบบ SSD คือ ผลลัพธ์ที่ได้จากการทำคอนโวลูชันในแต่ละชั้นที่มีขนาดแตกต่างกัน ช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุได้อย่างมีนัยสำคัญและเหมาะสมกับภาพที่มีวัตถุขนาดต่างกันมากได้ (Liu et al., 2016) สอดคล้องกับผลการทดลองนี้ซึ่งภาพวัตถุของสภาพพื้นผิวถนนที่ผิดปกติที่มีขนาดแตกต่างกัน ดังแสดงในรูปที่ 4.5 ส่งผลให้การตรวจจับวัตถุที่ใช้โครงสร้างแบบ SSD นั้นคือ ตัวแบบ SRF และ SMF ให้ค่า mAP สูงกว่าตัวแบบ FRIR, FRR และ FRN ที่มีโครงสร้างแบบ Faster R-CNN นอกจากนี้ผลการประเมินประสิทธิภาพด้านเวลาของตัวแบบสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบ พบว่า ตัวแบบ SRF และตัวแบบ SMF ที่มีโครงสร้างแบบ SSD ใช้เวลาในการตรวจจับวัตถุต่อ 1 ภาพ น้อยกว่าตัวแบบ FRIR, FRR และ FRN ที่มีโครงสร้างแบบ Faster R-CNN

1. หลุม บ่อ	
2. รอยแตกตาม แนวยาว	
3. รอยแตก ตามแนว	
4. รอยแตก หนังจระเข้	
5. รอยปะ ซ่อม	
6. เนินชะลอ ความเร็ว	

รูปที่ 4.5 ภาพวัตถุของสภาพพื้นผิวถนนที่ผิดปกติที่มีขนาดแตกต่างกัน

#### 4.2.2 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

การประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน เพื่อนำตัวแบบที่ได้มาใช้เพิ่มความแม่นยำในขั้นตอนวิธีจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่ใน 7 ประเภทได้แก่ 1) หลุมบ่อ 2) รอยแตกตามแนวยาว 3) รอยแตกตามแนวขวาง 4) รอยแตกหนังจระเข้ 5) รอยปะซ่อม 6) เนินชะลอความเร็ว/ เส้นชะลอความเร็ว และ 7) ถนนปกติ โดยเพิ่มลักษณะสภาพพื้นผิวถนนปกติอีก 1 ประเภท คือ ถนนปกติ เพื่อให้ตัวแบบจำแนกลักษณะสภาพพื้นผิวถนนที่ไม่ได้เป็นความผิดปกติของถนนที่มักตรวจจับผิดพลาด เนื่องจากลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อมที่มีความไม่แน่นอนและแปรปรวนสูงย่อมส่งผลกระทบต่อความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เช่น เงา แสงสะท้อนและคราบสกปรกต่าง ๆ บนผิวถนน ลักษณะถนนประเภทนี้มักไม่มีแรงสั่นสะเทือนหรือมีค่าอัตราเร่งของแรงสั่นสะเทือนค่อนข้างคงที่ ซึ่งแตกต่างจากแรงสั่นสะเทือนหรือค่าอัตราเร่งของแรงสั่นสะเทือนที่แปรปรวน เมื่อล่อรถตกกระทบบนลักษณะสภาพพื้นผิวถนนในลักษณะต่าง ๆ เช่น หลุมบ่อ รอยแตกตามแนวยาว รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ รอยปะซ่อมและเนินชะลอความเร็ว/ เส้นชะลอความเร็ว

##### 1) ผลการประเมินตัวแบบจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

การตั้งค่าก่อนสอนตัวแบบได้กำหนดอัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.0001 จำนวนขนาดตัวอย่าง (Batch size) เท่ากับ 64 ตัวอย่าง จำนวนรอบ (Epochs) ที่ใช้ในการสอนตัวแบบเท่ากับ 10,000 รอบ ผลการประเมินแสดงดังตารางที่ 4.8

ตารางที่ 4.8 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

Dataset	Accuracy		ประเภทของสภาพพื้นผิวถนน							Weighted avg
			หลุมบ่อ	รอยแตกตามยาว	รอยแตกตามขวาง	รอยแตกหนังจระเข้	รอยปะซ่อม	เนินชะลอความเร็ว	ถนนปกติ	
Train	97.41	Precision	93.50	98.55	99.23	96.86	96.84	100.00	96.96	97.42
		Recall	95.51	95.20	99.42	95.91	96.08	100.00	99.61	97.41
		F-measure	94.49	96.85	99.33	96.38	96.46	100.00	98.27	97.41
Test	88.69	Precision	80.51	92.40	91.00	83.05	86.26	98.21	90.31	88.80
		Recall	90.00	88.69	98.91	89.74	67.16	100.00	85.98	88.69
		F-measure	84.99	90.50	94.79	86.27	75.52	99.10	88.09	88.48

จากตารางที่ 4.8 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าซึ่งเรียกว่า Inception-v3 ของ GoogLeNet จากนั้นจึงส่งผ่านคุณลักษณะข้อมูลรูปภาพที่ได้รับไปยังชั้นเชื่อมต่อแบบทั่วถึงจำนวน 3 ชั้น ให้ค่าความแม่นยำ (Accuracy) เท่ากับ 97.41% บนชุดข้อมูลเรียนรู้ (Training Dataset) และ 88.69% บนชุดข้อมูลทดสอบ (Testing Dataset) เมื่อพิจารณาผลการประเมินในแต่ละประเภทสภาพพื้นผิวถนน พบว่า ค่าความแม่นยำ (Precision) อยู่ระหว่าง 80.51% - 98.21% ค่าความระลึก (Recall) อยู่ระหว่าง 67.16% - 100% และค่าเอฟเมเชอร์ (F-measure) อยู่ระหว่าง 75.52% - 99.10

## 2) ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน

การตั้งค่าก่อนสอนตัวแบบได้กำหนดอัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.0001 จำนวนขนาดตัวอย่าง (Batch size) เท่ากับ 64 ตัวอย่าง จำนวนรอบ (Epochs) ที่ใช้ในการสอนตัวแบบเท่ากับ 10,000 รอบ ผลการประเมินตัวแบบแสดงดังตารางที่ 4.9


ตารางที่ 4.9 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

Dataset	Accuracy		ประเภทของสภาพพื้นผิวถนน							Weighted avg.
			หลุม บ่อ	รอย แตก ตาม แนว ยาว	รอย แตก ตาม แนว ขวาง	รอย แตก หนึ่ง จระเข้	รอย ปะซ่อม	เนิน ชะลอ ความเร็ว	ถนน ปกติ	
Train	99.61	Precision	99.41	99.60	99.82	99.81	98.59	100.0	100.0	99.61
		Recall	99.61	99.21	100.0	99.03	100.0	100.0	99.42	99.61
		F-measure	99.51	99.40	99.91	99.42	99.29	100.0	99.71	99.61
Test	91.30	Precision	88.62	92.14	95.42	88.28	82.35	99.28	93.03	91.31
		Recall	91.79	94.16	98.19	88.28	82.66	100.0	83.76	91.30
		F-measure	90.18	93.14	96.79	88.28	82.50	99.64	88.16	91.26

จากตารางที่ 4.9 ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบให้ค่าความแม่นยำ (Accuracy) เท่ากับ 99.61% บนชุดข้อมูลเรียนรู้ (Training Dataset) และ 91.30% บนชุดข้อมูลทดสอบ (Testing Dataset) เมื่อพิจารณาผลการประเมินในแต่ละประเภทสภาพพื้นผิวถนน พบว่า ค่าความแม่นยำ (Precision) อยู่ระหว่าง

82.35% - 99.28% ค่าความระลึก (Recall) อยู่ระหว่าง 82.66% – 100% และค่าเอฟเมเชอร์ (F-measure) อยู่ระหว่าง 82.50% - 99.64% .ผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบ ในภาพรวมให้ค่าความแม่นยำและค่าความระลึกมากกว่า 80% ขึ้นไปทุกประเภทสภาพพื้นผิวถนนซึ่งมีทั้งสิ้น 7 ประเภท

เมื่อเปรียบเทียบค่าความแม่นยำตรงระหว่างผลการประเมินตัวแบบจำแนกสภาพพื้นผิวถนนที่ฝึกปกติจากข้อมูลรูปภาพและผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบบนชุดข้อมูลทดสอบ พบว่า ตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบให้ค่าความแม่นยำ ค่าเฉลี่ยค่าความแม่นยำ ค่าเฉลี่ยค่าความระลึกและค่าเฉลี่ยค่าเอฟเมเชอร์ เท่ากับ 91.30% 91.31% 91.30% และ 91.26% ตามลำดับ ซึ่งมีค่ามากกว่าค่าความแม่นยำตรง ค่าเฉลี่ยค่าความแม่นยำ ค่าเฉลี่ยค่าความระลึกและค่าเฉลี่ยค่าเอฟเมเชอร์ ของตัวแบบจำแนกสภาพพื้นผิวถนนที่ฝึกปกติจากข้อมูลรูปภาพ ซึ่งให้ค่าเท่ากับ 88.69% 88.80% 88.69% และ 88.48% ตามลำดับ ดังแสดงในรูปที่ 4.6



รูปที่ 4.6 การเปรียบเทียบผลประเมินของตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติ

ดังนั้น งานวิจัยนี้จึงเลือกใช้ตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบในการจำแนกสภาพพื้นผิวถนนใหม่ เพื่อเพิ่มความแม่นยำในขั้นตอนตรวจจับสภาพพื้นผิวถนนที่ฝึกปกติ



### 4.3 ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ประกอบด้วย ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและ ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน และผลการเปรียบเทียบขั้นตอนวิธีในการตรวจจับ สภาพพื้นผิวถนนที่ผิดปกติ โดยมีรายละเอียด ดังนี้


#### 4.3.1 ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

ที่ผ่านมาขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพของ Maeda และคณะ (2018) Singh และ Shekhar (2018) และ Koh และคณะ (2019) เลือกใช้ตัวแบบ ที่ ถูก ฝึก มา แล้วล่วงหน้า ได้แก่ SSD Inception\_V2, SSD MobileNet, Mask region-based convolutional network (Mask R-CNN) และ Region-based Fully Convolutional Networks (R-FCN) เมื่อผ่านขั้นตอนการตรวจจับจากตัวแบบดังกล่าวแล้ว ผลลัพธ์ที่ได้คือ ตำแหน่งของวัตถุ ในภาพเพื่อแสดงขอบเขตของวัตถุนั้น ข้อมูลประเภทสภาพพื้นผิวถนนของวัตถุและคะแนน ความเชื่อมั่นของวัตถุหรือค่าความน่าจะเป็นว่าวัตถุที่จัดอยู่ในประเภทสภาพพื้นผิวถนนนั้นมีความเป็นไปได้อาจจะเป็นสภาพพื้นผิวถนนนั้นก็เปอร์เซ็นต์

อย่างไรก็ตามงานวิจัยที่ผ่านมาได้กำหนดเกณฑ์คะแนนความเชื่อมั่น (Confidence Score Threshold) เท่ากับ 0 หรือเลือกกำหนดเกณฑ์คะแนนความเชื่อมั่นตามความเหมาะสมของผู้วิจัย จากนั้นนำคะแนนความเชื่อมั่นของแต่ละวัตถุมาตรวจสอบกับเกณฑ์คะแนนความเชื่อมั่นที่กำหนด หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับ มีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุนั้นในภาพ

ในงานวิจัยนี้ เลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า คือ ตัวแบบ SSD ResNet50 FPN ซึ่งให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงที่สุด (mAP = 87.38%) เพื่อตรวจจับสภาพพื้น ผิวถนนที่ผิดปกติจากข้อมูลรูปภาพบนชุดข้อมูลทดสอบ ในการทดลองกำหนดเกณฑ์คะแนน ความเชื่อมั่นระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) และค่าไอ โอยูมากกว่าหรือเท่ากับ 0.5 เพื่อเลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่เหมาะสม ผลการประเมินขั้นตอนวิธีในการตรวจจับ สภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบ SSD ResNet50 FPN เมื่อกำหนดเกณฑ์คะแนน ความเชื่อมั่นในแต่ละระดับ แสดงดังรูปที่ 4.7






รูปที่ 4.7 ผลการประเมินด้วยค่า AP และ mAP ของตัวแบบ SSD ResNet50 FPN  
เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับ


จากรูปที่ 4.7 ผลการทดลอง พบว่า การเพิ่มค่าเกณฑ์คะแนนความเชื่อมั่นให้มากขึ้นในแต่ละระดับระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) ส่งผลให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) มีแนวโน้มลดลง (จาก 87.38% ลดลงเหลือ 40.67%) และค่าเฉลี่ยความแม่นยำ (AP) ของแต่ละประเภทสภาพพื้นผิวถนนที่ผิดปกติมีแนวโน้มลดลงเช่นกัน โดยเฉพาะอย่างยิ่งค่าเฉลี่ยความแม่นยำของรอยแตกตามแนวขวางที่มีค่าลดลงอย่างมากจาก 91.01% ลดลงเหลือ 1.80% ซึ่งเป็นผลมาจากขั้นตอนวิธีในการตรวจสอบเกณฑ์คะแนนความเชื่อมั่น ได้ปฏิเสธวัตถุที่ถูกตรวจพบ (False Positive) เนื่องจากคะแนนความเชื่อมั่นของวัตถุที่ถูกตรวจพบมีค่าน้อยกว่าเกณฑ์คะแนนความเชื่อมั่นที่กำหนด

เมื่อตรวจสอบผลของการตรวจจับวัตถุในภาพที่เป็นประเภทรอยแตกตามแนวขวางพบว่า ส่วนใหญ่วัตถุที่ถูกตรวจพบมีค่าคะแนนความเชื่อมั่นน้อยกว่า ~ 25% ส่วนค่าเฉลี่ยความแม่นยำของแต่ละประเภทสภาพพื้นผิวถนนที่ผิดปกติที่มีแนวโน้มลดลงรองลงมา คือ รอยแตกตามแนวยาว รอยปะซ่อม (จาก 79.02% ลดลงเหลือ 33.70%) หลุมบ่อ (จาก 84.39% ลดลงเหลือ 36.63%) รอยแตกหนังจระเข้ (จาก 87.55% ลดลงเหลือ 62.54%) และเนินชะลอความเร็ว/ เส้นชะลอความเร็ว (จาก 99.63% ลดลงเหลือ 64.84%) ตามลำดับ

ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบ SSD ResNet50 FPN บนชุดข้อมูลรูปภาพทดสอบสภาพพื้นผิวถนน เมื่อมีค่าคะแนนความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าคะแนนความเชื่อมั่นในแต่ละระดับที่กำหนดและค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 พบว่าตัวแบบ SSD ResNet50 FPN สามารถตรวจจับวัตถุในภาพทดสอบได้ถูกต้อง (True Positive) ดังแสดงในรูปที่ 4.8 และตรวจจับวัตถุในภาพทดสอบไม่ถูกต้อง (False Positive) ดังแสดงในรูปที่ 4.9



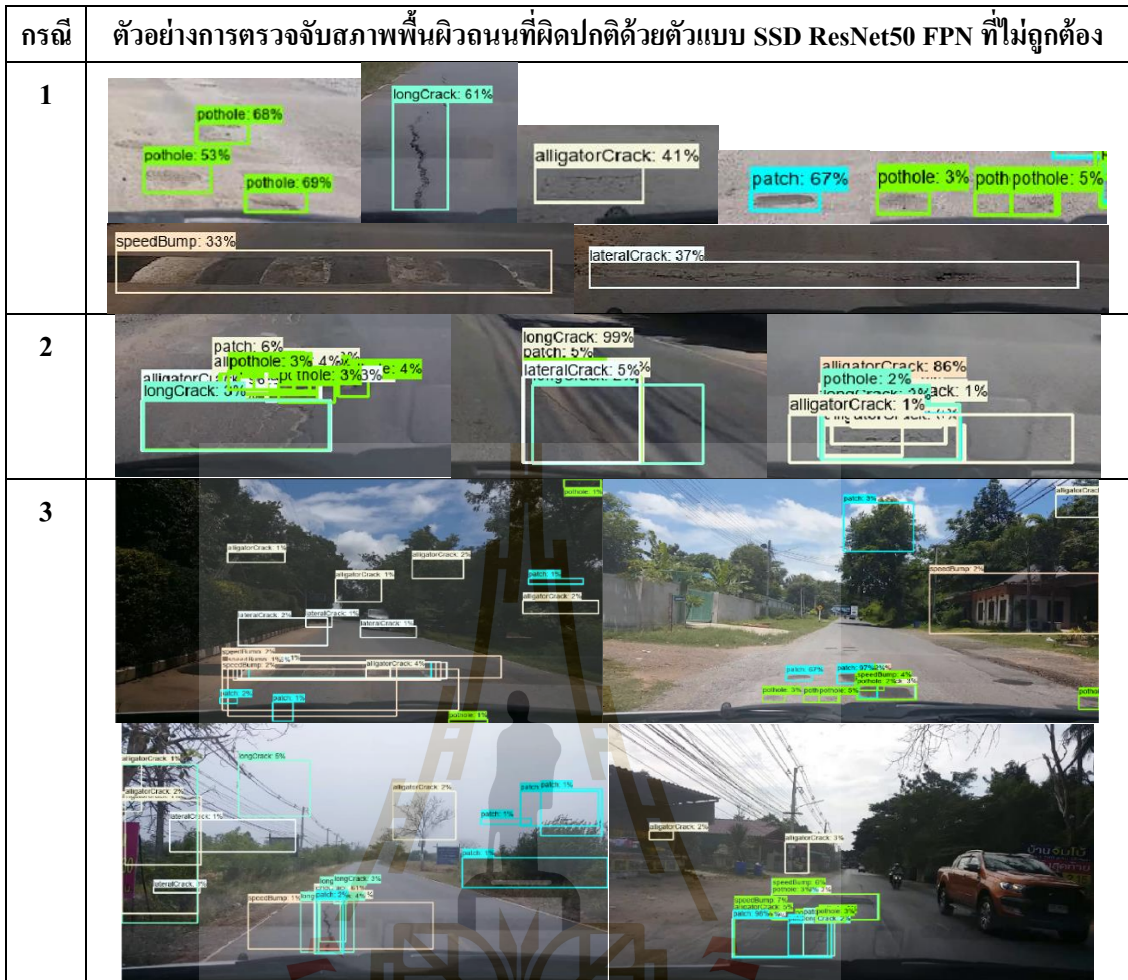
รูปที่ 4.8 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50FPN ที่ถูกต้อง



รูปที่ 4.8 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่ถูกต้อง (ต่อ)

จากรูปที่ 4.8 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่สามารถตรวจจับวัตถุในภาพทดสอบได้ถูกต้อง (True Positive) หมายความว่า ตัวแบบตรวจพบวัตถุที่มีค่าคะแนนความเชื่อมั่น (Confidence Score) มากกว่าหรือเท่ากับ เกณฑ์ค่าคะแนนความเชื่อมั่นที่กำหนดในแต่ละระดับ (Confidence Score Threshold) และค่าไอโอยู (Intersection Over Union: IoU) มากกว่าหรือเท่ากับ 0.5 แล้วตัวแบบทำนายวัตถุว่า เป็นประเภท สภาพพื้นผิวถนนนั้นแล้ววัตถุนั้น เป็นประเภทสภาพพื้นผิวถนนนั้นจริง ดังนั้น ตัวแบบ SSD ResNet50 FPN จึงยอมรับวัตถุนั้นและแสดงผลโดยการตีกรอบล้อมรอบวัตถุ (Bounding Box) พร้อมทั้งแสดงชื่อประเภทของสภาพพื้นผิวถนน (Class Name) และค่าความเชื่อมั่นของวัตถุที่ได้ (Confidence Score)





รูปที่ 4.9 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่ไม่ถูกต้อง

ในขณะที่ รูปที่ 4.9 ตัวอย่างการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยตัวแบบ SSD ResNet50 FPN ที่ตรวจจับวัตถุในภาพทดสอบไม่ถูกต้อง (False Positive) หมายความว่า

กรณีที่ 1 ตัวแบบ SSD ResNet50 FPN ตรวจพบวัตถุที่มีค่าคะแนนความเชื่อมั่น น้อยกว่าเกณฑ์ค่าคะแนนความเชื่อมั่นในแต่ละระดับที่กำหนดและค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 และทำนายว่าเป็นประเภทสภาพพื้นผิวถนนนั้นแล้ววัตถุนั้นเป็นประเภทสภาพพื้นผิวถนนนั้นจริง ดังแสดงในรูปที่ 4.9 กรณีที่ 1

กรณีที่ 2 ตัวแบบ SSD ResNet50 FPN ตรวจพบวัตถุที่มีค่าคะแนนความเชื่อมั่น น้อยกว่าเกณฑ์ค่าคะแนนความเชื่อมั่นในแต่ละระดับที่กำหนดและค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 และทำนายว่าเป็นประเภทสภาพพื้นผิวถนนนั้นแล้ววัตถุนั้น ไม่เป็นประเภทสภาพพื้นผิวถนนนั้น ดังแสดงในรูปที่ 4.9 กรณีที่ 2

**กรณีที่ 3** ตัวแบบ SSD ResNet50 FPN ตรวจพบวัตถุอยู่นอกพื้นที่ผิวถนนและวัตถุที่ถูกรวบรวมได้ส่วนใหญ่มีค่าคะแนนความเชื่อมั่นน้อยกว่า 0.05 ดังแสดงในรูปที่ 4.9 กรณีที่ 3

อย่างไรก็ตาม วัตถุที่ถูกรวบรวมทั้งกรณีที่ 1 และ 2 ที่มีค่าคะแนนความเชื่อมั่นของวัตถุน้อยกว่าเกณฑ์คะแนนความเชื่อมั่นที่กำหนด (False Positive) อาจเป็นวัตถุตัวเลือก (Candidate Objects) ที่ถูกรวบรวมได้ถูกต้องหรือไม่ถูกต้องตามประเภทสภาพพื้นผิวถนนที่ผิดปกติ หากนำวัตถุตัวเลือกเหล่านี้มาตรวจสอบและจำแนกประเภทใหม่โดยใช้ตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน ผลการตรวจสอบและจำแนกประเภทใหม่อาจจะเป็นอีกวิธีหนึ่งที่เพิ่มความแม่นยำในขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติได้

ส่วนกรณีที่ 3 วัตถุที่ถูกรวบรวมอยู่นอกพื้นผิวถนน ควรมีการตรวจสอบขอบเขตพื้นที่ในภาพบริเวณที่ต้องการตรวจจับวัตถุและปฏิเสธวัตถุที่ถูกรวบรวมที่อยู่นอกพื้นผิวถนน ซึ่งเป็นส่วนที่ช่วยเพิ่มความแม่นยำในการตรวจจับสภาพพื้นผิวถนนได้อีกทางหนึ่ง

#### 4.3.2 ผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

ขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน โดยนำข้อมูลรูปภาพเข้าตัวแบบที่ถูกฝึกมาแล้วหน้า คือ ตัวแบบ SSD ResNet50 FPN ที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด (mAP = 87.38%) เมื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบ โดยกำหนดเกณฑ์คะแนนความเชื่อมั่น (Confidence Score Threshold) ระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) และค่าไอโอยู (Intersection Over Union: IoU) มากกว่าหรือเท่ากับ 0.5 ผลลัพธ์ที่ได้ คือ วัตถุที่ถูกรวบรวมเป็นสภาพพื้นผิวถนนใน 6 ประเภท


จากนั้นตรวจสอบค่าความเชื่อมั่นของแต่ละวัตถุ หากวัตถุที่ถูกรวบรวมมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนดในแต่ละระดับ ให้ยอมรับและติกรอบล้อมรอบวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกรวบรวมมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดในแต่ละระดับให้นำวัตถุตัวเลือกนั้น (Candidate Objects) เข้าตรวจสอบและจำแนกประเภทใหม่ (Reclassification) โดยทำการตรวจสอบตำแหน่งของวัตถุตัวเลือกนั้นด้วยการคำนวณค่าไอโอยู คือ อัตราส่วนพื้นที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้นกับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หาด้วยพื้นที่รวมทั้งหมด (Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้นกับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด

หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวล้อมที่กำหนด นั่นคือ ค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ภายในขอบเขตแนวล้อมที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0 ให้นำวัตถุนั้นมาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks: Multimodal DCNN) จากข้อมูลภาพวัตถุตัวเลือกและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของรูปภาพนั้นจะถูกตัวแบบ Multimodal DCNN สกัดคุณลักษณะและหลอมรวมคุณลักษณะเพื่อจำแนกประเภทสภาพพื้นผิวถนน ผลลัพธ์ที่ได้ คือ วัตถุที่ถูกจำแนกใหม่เป็นสภาพพื้นผิวถนนใน 7 ประเภท จากนั้นตรวจสอบค่าความเชื่อมั่นของแต่ละวัตถุ หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนดและวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติให้ยอมรับและตีกรอบล้อมรอบวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดหรือเป็นประเภทสภาพพื้นผิวถนนปกติให้ปฏิเสธวัตถุตัวเลือกนั้น

ผลการทดลอง พบว่า การเพิ่มค่าเกณฑ์คะแนนความเชื่อมั่นให้มากขึ้นในแต่ละระดับระหว่าง 0.05 – 0.95 (เพิ่มระดับละ 0.05) ส่งผลให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) มีค่าระหว่าง 76.06% – 90.65% ซึ่งมีแนวโน้มเพิ่มขึ้นเมื่อเทียบกับขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่สกัดจากข้อมูลรูปภาพเพียงอย่างเดียวโดยใช้ตัวแบบ SSD ResNet50 FPN

ยิ่งไปกว่านั้นค่าเฉลี่ยความแม่นยำ (AP) ของแต่ละประเภทสภาพพื้นผิวถนนมีแนวโน้มเพิ่มขึ้น โดยค่าเฉลี่ยความแม่นยำของแต่ละประเภทสภาพพื้นผิวถนนที่สกัดปกติ มีค่าดังนี้ เนินชะลอความเร็ว/ เส้นชะลอความเร็ว มีค่าระหว่าง 94.80% – 99.63% รอยแตกตามแนวขวาง มีค่าระหว่าง 80.82% – 94.85% รอยแตกหนึ่งจระเข้มีค่าระหว่าง 77.52% – 92.15% รอยแตกตามแนวยาวมีค่าระหว่าง 69.37% – 85.67% หลุมบ่อมีค่าระหว่าง 66.58% – 96.67% และรอยปะซ่อมมีค่าระหว่าง 57.82% – 85.05% ดังแสดงในรูปที่ 4.10 สำหรับผลการเปรียบเทียบขั้นตอนวิธีแสดงรายละเอียดในหัวข้อถัดไป






รูปที่ 4.10 ผลการประเมินด้วยค่า AP และ mAP ของตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับ

#### 4.3.3 ผลการเปรียบเทียบขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ผลการเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) และค่าเฉลี่ยความแม่นยำ (AP) ระหว่างขั้นตอนวิธีที่ผ่านมาและขั้นตอนวิธีใหม่ที่น่าเสนอในงานวิจัยนี้เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ มีรายละเอียดดังนี้

##### 1) ผลการเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำของขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

การเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) ระหว่างขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากรูปภาพเพียงอย่างเดียวโดยใช้ตัวแบบ SSD ResNet50 FPN ที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงสุด คือ 87.38% เมื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลรูปภาพทดสอบ และขั้นตอนวิธีใหม่ที่น่าเสนอในงานวิจัยนี้เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนโดยใช้ตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal DCNN model) เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.00 – 0.95 เพิ่มขึ้นระดับละ 0.05 และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 ผลการเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำของทั้ง 2 ขั้นตอนวิธี แสดงดังรูปที่ 4.11



รูปที่ 4.11 ผลการเปรียบเทียบค่า mAP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

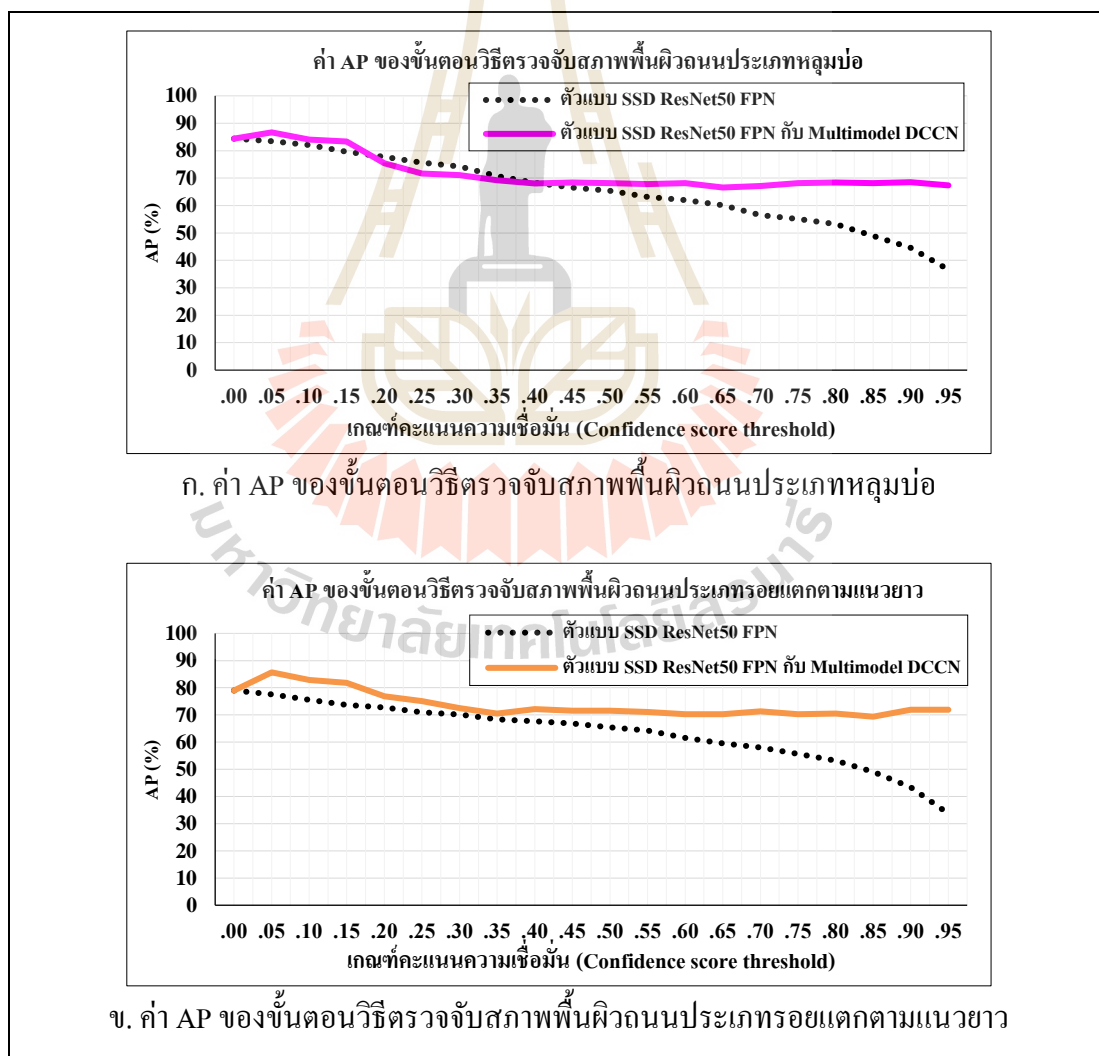
จากรูปที่ 4.11 ผลการเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) ของทั้ง 2 ขั้นตอนวิธี เมื่อกำหนดค่าเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับระหว่าง 0.00 – 0.95 พบว่า ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำที่มีค่าลดลงจาก 87.38% เหลือ 40.67% ส่วนขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน โดยใช้ตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำที่มีค่าระหว่าง 87.38 – 90.65% (ค่า mAP เพิ่มขึ้นระหว่าง 0.76% – 35.38%) หากต้องการเลือกใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติที่มีค่า mAP สูงที่สุด ควรพิจารณาเลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่ระดับ 0.05 ซึ่งได้ค่า mAP เท่ากับ 90.65% ดังแสดงรายละเอียดในตารางที่ 4.11

ตารางที่ 4.10 ผลเปรียบเทียบค่า mAP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ


เกณฑ์คะแนน ความเชื่อมั่น	ค่า mAP ของขั้นตอนวิธีโดยใช้		ผลต่างของ ค่า mAP
	ตัวแบบ SSD ResNet50 FPN	ตัวแบบ SSD ResNet50 FPN กับ ตัวแบบ Multimodal DCNN	
.00	87.38	87.38	0.00
.05	86.1445	90.65	↑ 4.51
.10	84.9276	89.00	↑ 4.07
.15	83.5345	87.77	↑ 4.24
.20	82.0075	82.77	↑ 0.76
.25	79.6794	80.61	↑ 0.93
.30	76.4225	79.19	↑ 2.77
.35	72.5205	78.20	↑ 5.68
.40	69.6849	77.83	↑ 8.15
.45	67.1905	77.54	↑ 10.35
.50	65.4356	77.49	↑ 12.05
.55	63.7084	77.57	↑ 13.86
.60	61.8294	77.60	↑ 15.77
.65	59.9089	76.57	↑ 16.66
.70	57.9291	77.30	↑ 19.37
.75	56.4401	77.54	↑ 21.10
.80	53.9913	76.73	↑ 22.74
.85	51.3484	76.92	↑ 25.57
.90	47.1434	77.02	↑ 29.88
.95	40.6792	76.06	↑ 35.38

## 2) ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำของขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ


การเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ระหว่างระหว่างขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากรูปภาพโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพียงอย่างเดียวและและขั้นตอนวิธีใหม่ที่น่าเสนอในงานวิจัยนี้เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (ตัวแบบ SSD ResNet50 FPN) ร่วมกับตัวแบบ โครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal DCNN) โดยกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.00 – 0.95 (เพิ่มขึ้น ระดับละ 0.05) และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำของทั้ง 2 ขั้นตอนวิธี แสดงดังรูปที่ 4.12




รูปที่ 4.12 ผลการเปรียบเทียบค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ



ค. ค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวาง




ง. ค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกหนึ่งจระเข้



จ. ค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะช่อม

รูปที่ 4.12 ผลการเปรียบเทียบค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)





#### รูปที่ 4.12 ผลการเปรียบเทียบค่า AP ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)

จากรูปที่ 4.12 ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ในแต่ละประเภทสภาพพื้นผิวถนนของทั้ง 2 ขั้นตอนวิธี พบว่า

##### 1. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อ

จากรูปที่ 4.12 ก.ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.05 – 0.15 (ค่า AP มากกว่าระหว่าง 1.96 – 3.7%) และ 0.45 – 0.95 (ค่า AP มากกว่าระหว่าง 1.91 – 30.71%) และค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่าน้อยกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทหลุมบ่อด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.20 – 0.40 (ค่า AP น้อยกว่าระหว่าง 11.53 – 3.94%)

##### 2. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวยาว

จากรูปที่ 4.12 ข.ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวยาวด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวยาว

ด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในทุก ๆ ระดับระหว่าง 0.05 – 0.95 (ค่า AP มากกว่าระหว่าง 2.15 – 38.25%)

### 3. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวาง

จากรูปที่ 4.12 ค. ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวางด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวางด้วย ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวเมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.05 – 0.15 (ค่า AP มากกว่าระหว่าง 3.83 – 4.43%) และ 0.25 – 0.95 (ค่า AP มากกว่าระหว่าง 3.35 – 84.45%) ส่วนค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวางด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่าน้อยกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกตามแนวขวางด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวเมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นที่ 0.20 (ค่า AP น้อยกว่า 1.77%)

### 4. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกหนึ่งจระเข้

จากรูปที่ 4.12 ง.ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกหนึ่งจระเข้ด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยแตกหนึ่งจระเข้ด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในทุก ๆ ระดับระหว่าง 0.05 – 0.95 (ค่า AP มากกว่าระหว่าง 0.89 – 14.97%)

### 5. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะซ่อม

จากรูปที่ 4.12 จ. ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะซ่อมด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะซ่อมด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.05 – 0.20 (ค่า AP มากกว่าระหว่าง 0.58 – 6.12%) และ 0.60 – 0.95 (ค่า AP มากกว่าระหว่าง 0.43 – 13.28%) ส่วนค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะซ่อมด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่าน้อยกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทรอยปะซ่อมด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวเมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.25 – 0.55 (ค่า AP น้อยกว่าระหว่าง 0.01 – 2.26%)

## 6. ผลการเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว

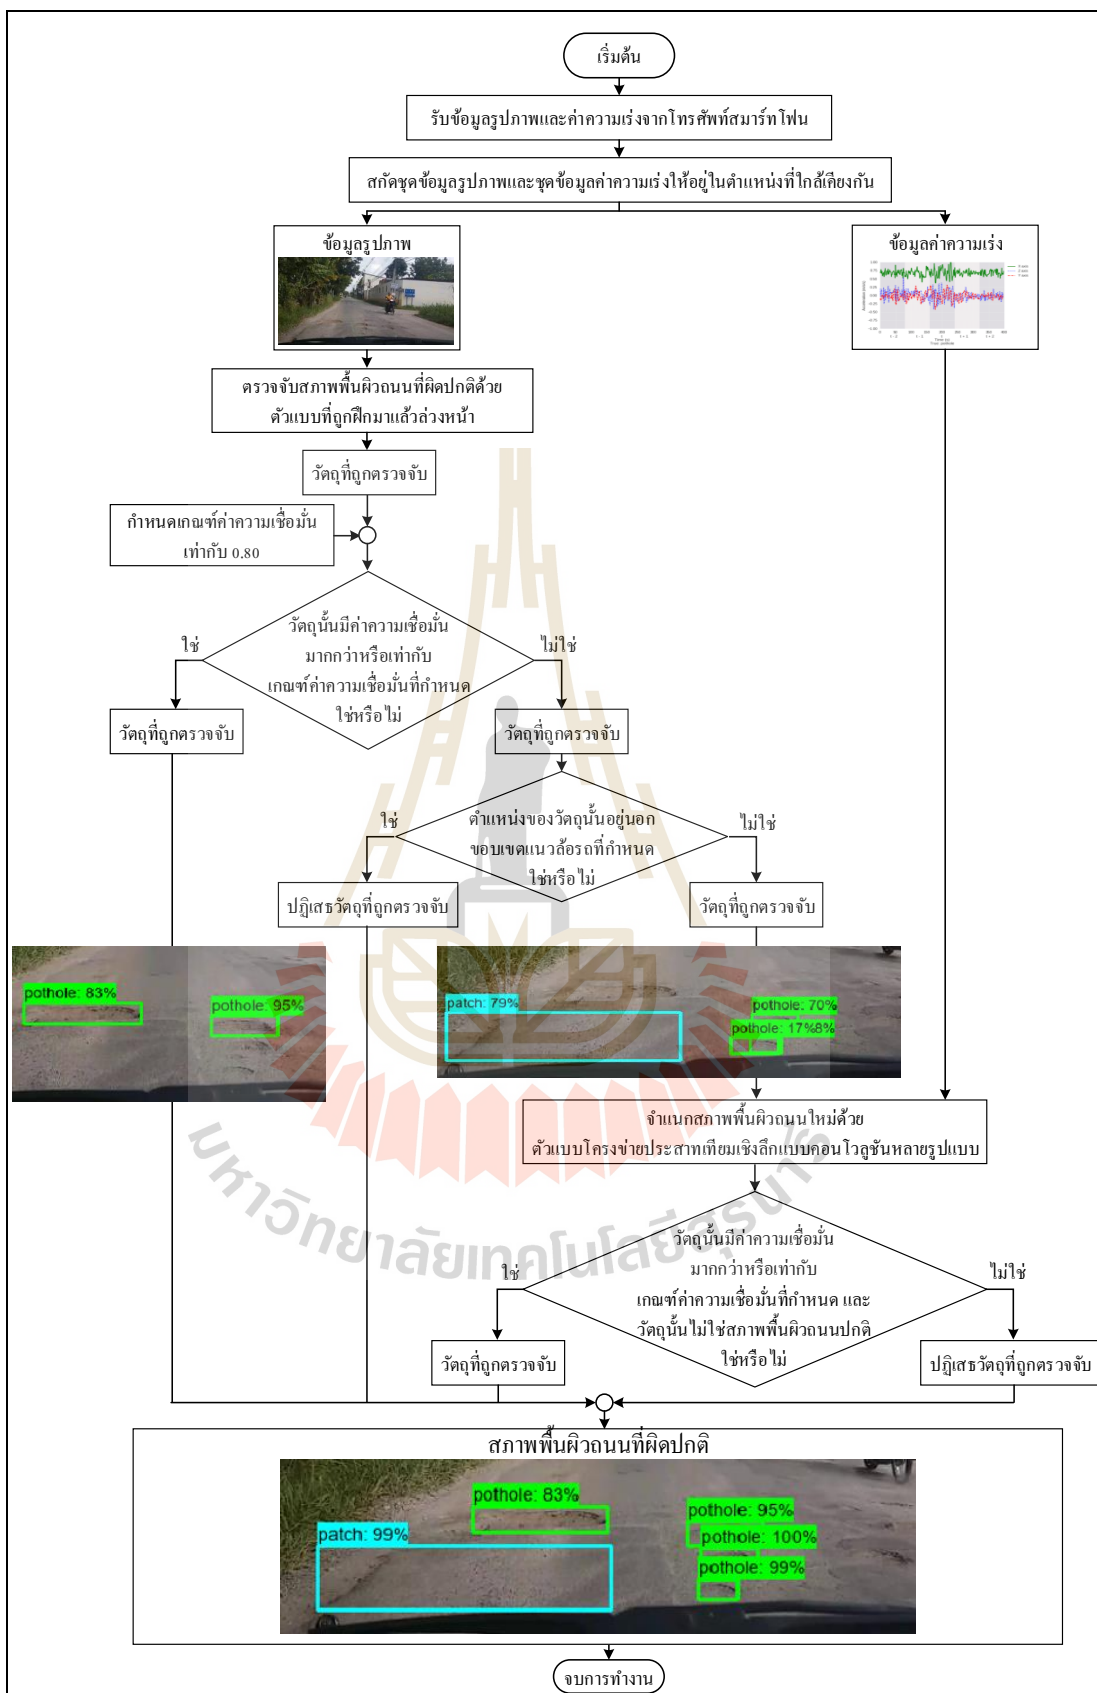
จากรูปที่ 4.12 ค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว ด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่ามากกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว ด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นที่ 0.15 (ค่า AP มากกว่า 0.24%) และระหว่าง 0.25 – 0.95 (ค่า AP มากกว่าระหว่าง 0.09 - 30.60%) ส่วนค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว ด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN มีค่าน้อยกว่าค่า AP ของการใช้ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนประเภทเนินชะลอความเร็ว/ เส้นชะลอความเร็ว ด้วยตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่น 0.05 – 0.10 (ค่า AP น้อยกว่า 0.01%) และ 0.20 (ค่า AP น้อยกว่า 0.20%)

### 4.3.4 ผลการพิจารณาและตัวอย่างการเลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่เหมาะสม

หากต้องการเลือกใช้ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยให้ความสำคัญกับค่า mAP สูงที่สุด ดังแสดงในตารางที่ 4.20 ควรพิจารณาเลือกใช้เกณฑ์คะแนนความเชื่อมั่นระดับ 0.05 ซึ่งทำให้ได้รับค่า mAP เท่ากับ 90.65% โดยค่า mAP เพิ่มขึ้น 4.51% เมื่อเปรียบเทียบกับขั้นตอนวิธีที่ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวที่ให้ค่า mAP เพียง 86.14%

นอกจากนี้ หากต้องการเลือกใช้ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยให้ความสำคัญทั้งค่า mAP และ ค่า AP สูงในทุก ๆ ประเภทของสภาพพื้นผิวถนน ดังแสดงในตารางที่ 4.20 และรูปที่ 4.11 ควรพิจารณาเลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่ 0.60 ขึ้นไป ซึ่งจะทำให้ได้รับค่า mAP ระหว่าง 76.06 – 77.60% และให้ค่า AP ระหว่าง 64.58 – 95.45% เมื่อเปรียบเทียบกับขั้นตอนวิธีที่ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวที่ให้ค่า mAP ระหว่าง 40.67 – 61.82% และให้ค่า AP ระหว่าง 1.80 – 85.35%

ตัวอย่างขั้นตอนวิธีตรวจจับสภาพพื้นผิวที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน โดยใช้ตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN ซึ่งประกอบด้วย 7 ขั้นตอน โดยกำหนดเกณฑ์คะแนนความเชื่อมั่นที่ 0.80 และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 แสดงดังรูปที่ 4.13



รูปที่ 4.13 ตัวอย่างการตรวจจับสภาพพื้นผิวที่ผิดปกติด้วยขั้นตอนวิธีใหม่

จากรูปที่ 4.13 ตัวอย่างการตรวจจับสภาพพื้นผิวที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนด้วยขั้นตอนวิธีใหม่ที่น่าเสนอในงานวิจัยนี้ ประกอบด้วย 7 ขั้นตอนดังนี้

### เริ่มต้น

ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวดนที่ผิดปกติโดยการรับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

### ขั้นตอนที่ 1

รับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากโทรศัพท์สมาร์ทโฟน

### ขั้นตอนที่ 2

สกัดชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้อยู่ในตำแหน่งที่ใกล้เคียงกัน (ตำแหน่งที่มองเห็นสภาพพื้นผิวดนได้ชัดเจนอยู่ห่างจากรถเป็นระยะทาง 6.5 เมตรและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนซึ่งอยู่ในตำแหน่งของรถ) โดยทำการคำนวณหาเวลาที่บวกเพิ่มจากเวลาที่ดึงรูปภาพซึ่งใช้สูตรการเคลื่อนที่ในอัตราเร่งคงที่ ผลลัพธ์ที่ได้คือข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่ต้องการตรวจจับสภาพพื้นผิวดน

### ขั้นตอนที่ 3

ป้อน ข้อมูลรูปภาพเข้าตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อตรวจจับสภาพพื้นผิวดนที่ผิดปกติ ผลลัพธ์ที่ได้คือ วัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวดนใน 6 ประเภท

### ขั้นตอนที่ 4

ตรวจสอบค่าความเชื่อมั่น จากตัวอย่างในรูปที่ 4.13 กำหนดเกณฑ์คะแนนความเชื่อมั่นที่ 0.80 หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับ 0.80 (เกณฑ์ค่าความเชื่อมั่นที่กำหนด) ให้ยอมรับแล้วแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ชื่อประเภทสภาพพื้นผิวดนและค่าความเชื่อมั่นของวัตถุนั้น ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่า 0.80 ให้นำวัตถุตัวเลือกนั้น (Candidate Objects) เข้าตรวจสอบในขั้นตอนถัดไป ซึ่งวัตถุตัวเลือกนั้นอาจเป็นสภาพพื้นผิวดนที่ผิดปกติที่ต้องการ จากตัวอย่างในรูปที่ 4.13 พบ วัตถุตัวเลือกจำนวน 4 วัตถุ คือ รอยปะซ่อม (Patch: 79%) หลุมบ่อ (Pothole: 70%, Pothole: 38% และ Pothole: 17%)

### ขั้นตอนที่ 5

ตรวจสอบตำแหน่งของวัตถุตัวเลือกนั้น โดยคำนวณหาค่าไอโอยู (Intersection Over Union: IoU) คือ อัตราส่วนพื้นที่ที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณล้อรถที่กำหนด หาด้วยพื้นที่รวมทั้งหมด



(Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณล้อรถที่กำหนด หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวล้อรถที่กำหนด นั่นคือ ค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ในขอบเขตแนวล้อรถที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0 จากตัวอย่างในรูปที่ 4.13 พบว่า วัตถุตัวเลือกทั้ง 4 วัตถุมีค่าไอโอยูมากกว่า 0 แสดงว่า พื้นที่ของวัตถุตัวเลือกอยู่ในพื้นที่บริเวณล้อรถที่กำหนด จากนั้นจึงนำวัตถุตัวเลือกนั้นและค่าอัตราเร่งของแรงสั่นสะเทือนของรูปภาพที่ถูกสกัดข้อมูลให้อยู่ในตำแหน่งที่ใกล้เคียงกันไว้แล้ว มาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

### ขั้นตอนที่ 6

นำเข้าภาพวัตถุตัวเลือกนั้นและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ ผลลัพธ์ที่ได้ คือ วัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวถนนใน 7 ประเภท จากตัวอย่างในรูปที่ 4.13 ผลลัพธ์ที่ได้ คือ รอยปะซ่อม (Patch: 99%) หลุมบ่อ (Pothole: 100%, Pothole: 99% และ Pothole: 78%)

### ขั้นตอนที่ 7

ตรวจสอบค่าความเชื่อมั่น หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับ 0.8 (เกณฑ์ค่าความเชื่อมั่นที่กำหนด) และวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ จากผลลัพธ์ที่ได้ คือ รอยปะซ่อม (Patch: 99%) หลุมบ่อ (Pothole: 100%, Pothole: 99% และ Pothole: 78%) พบว่า มีวัตถุตัวเลือกจำนวน 3 วัตถุที่มีค่าความเชื่อมั่นมากกว่าหรือเท่ากับ 0.8 ดังนั้นให้ยอมรับวัตถุตัวเลือกเหล่านี้แล้วแสดงกรอบขอบเขตของวัตถุในภาพ ส่วนวัตถุตัวเลือกที่มีค่าความเชื่อมั่นน้อยกว่า 0.8 เช่น Pothole: 78% ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ


### จบการทำงาน

ตัวอย่างการใช้ขั้นตอนวิธีใหม่ที่นำเสนอในงานวิจัยนี้เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในแต่ละประเภทสภาพพื้นผิวถนนจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนด้วยตัวแบบ SSD ResNet50 FPN ร่วมกับ ตัวแบบ Multimodal DCNN เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นที่ 0.80 และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 แสดงดังตารางที่ 4.11

ตารางที่ 4.11 ตัวอย่างผลการตรวจจับสภาพพื้นผิวที่ผิดปกติด้วยขั้นตอนวิธีที่ผ่านมา และขั้นตอนวิธีใหม่

ขั้นตอนวิธีที่ผ่านมา	ขั้นตอนวิธีใหม่ที่เสนอในงานวิจัยนี้

ตารางที่ 4.11 ตัวอย่างผลการตรวจจับสภาพพื้นผิวที่ผิดปกติด้วยขั้นตอนวิธีที่ผ่านมา และขั้นตอนวิธีใหม่ (ต่อ)



#### 4.3.5 ต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ต้นทุนในการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้ ประกอบด้วย ค่าโทรศัพท์มือถือ ค่าเช่าเครื่องคอมพิวเตอร์ ค่าเช่าเครื่องแม่ข่ายของกูเกิล ค่าเช่ารถยนต์ ค่าใช้จ่ายในการเดินทาง และค่าดำเนินการ ดังแสดงในตารางที่ 4.12

ตารางที่ 4.12 ต้นทุนการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้

รายละเอียด	งบประมาณ
ค่าโทรศัพท์มือถือที่มีกล้อง มาตรฐานแรงและระบบระบุตำแหน่งบนพื้นโลก	17,900
ค่าเช่าเครื่องคอมพิวเตอร์ใช้ในการประมวลผลและจัดเก็บข้อมูลสภาพพื้นผิวถนน ในระยะเวลา 12 เดือน	25,000
ค่าเช่าเครื่องแม่ข่าย (Google Cloud Platform) ที่ใช้ GPU รุ่น NVIDIA Tesla T4 หน่วยความจำ 20 GB พื้นที่จัดเก็บข้อมูล 200 GB เพื่อใช้สร้างตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ในระยะเวลา 12 เดือน	30,000
ค่าเช่ารถยนต์ เพื่อเก็บรวบรวมข้อมูล (วันละ 800 บาท จำนวน 60 วัน)	48,000
ค่าใช้จ่ายในการเดินทาง (ค่าน้ำมัน กิโลเมตรละ 5 บาท จำนวน 350 กิโลเมตร ค่าจ้างผู้ใช้งานเก็บรวบรวมข้อมูล วันละ 300 บาท จำนวน 60 วัน)	20,000
ค่าดำเนินการ (10% ของงบประมาณทั้งหมด)	14,090
<b>รวม</b>	<b>154,990</b>

ต้นทุนในการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากงานวิจัยที่ผ่านมา เช่น งานวิจัยของเงินและคณะ (Chen et al, 2016) พัฒนาระบบเก็บข้อมูลสภาพพื้นผิวถนนจากเครื่องรับรู้อหลายรูปแบบ ได้แก่ กล้อง (Camera) มาตรฐานความแรง



(Accelerometer) และระบบระบุตำแหน่งบนพื้นโลก (Global Positioning System) เพื่อตรวจจับสภาพพื้นผิวดถนนประเภทรอยแตก รดสำรวจสแกนวัตถุสามมิติด้วยแสงเลเซอร์เพื่อตรวจสอบสภาพพื้นผิวดถนนของกรมทางหลวง (กรมทางหลวง, 2550). และการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบในงานวิจัยนี้ สรุปดังตารางที่ 4.13

ตารางที่ 4.13 ต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติ

	งานวิจัยของเฉินและคณะ (Chen et al, 2016)	รถสแกนวัตถุสามมิติด้วยแสง เลเซอร์ของกรมทางหลวง (กรมทางหลวง, 2550).	งานวิจัยนี้
อุปกรณ์ เครื่องมือที่ใช้	กล้อง มาตรฐานความเร่ง ระบบระบุตำแหน่งบน พื้นโลก แบตเตอรี่ คอมพิวเตอร์และอุปกรณ์ ต่อพ่วงอื่น ๆ	กล้องสแกนวัตถุด้วยแสงเลเซอร์ มาตรฐานความเร่ง ระบบระบุ ตำแหน่งบนพื้นโลก ระบบคอมพิวเตอร์และเครือข่าย	กล้อง มาตรฐานความเร่งและ ระบบระบุตำแหน่งบนพื้น โลก ในโทรศัพท์มือถือ โฟน ระบบคอมพิวเตอร์ และเครือข่าย
งบประมาณ	230,000 บาท	10,000,000 บาท	154,990 บาท


จากตารางที่ 4.13 ต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติ งานวิจัยของเฉินและคณะ (Chen et al, 2016) พัฒนาระบบเก็บข้อมูลสภาพพื้นผิวดถนนจากเครื่องรับรู้หลายรูปแบบ เพื่อตรวจจับสภาพพื้นผิวดถนนประเภทรอยแตก ใช้งบประมาณในการดำเนินงาน ประมาณ 230,000 บาท ในประเทศไทยกรมทางหลวงพัฒนารถสแกนวัตถุสามมิติด้วยแสงเลเซอร์ของกรมทางหลวง (กรมทางหลวง, 2550). ใช้งบประมาณในการดำเนินงานประมาณ 10,000,000 บาท ซึ่งมีมูลค่าที่สูงมากและรถสำรวจมีอยู่ 1 คัน หากนำมาใช้สำรวจถนนทั่วประเทศคงไม่เพียงพอต่อความต้องการใช้งานของหน่วยงานต่าง ๆ แต่อย่างไรก็ตาม ผลที่ได้รับจากการตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติมีความแม่นยำสูง

งานวิจัยนี้ ออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำบนโทรศัพท์มือถือ ซึ่งใช้งบประมาณในการดำเนินงานประมาณ 154,990 บาท ถึงแม้ว่า ระบบสามารถตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติได้จำนวน 6 ประเภท และมีความแม่นยำในระดับหนึ่ง แต่อย่างไรก็ตาม มีความเป็นไปได้ในการนำไปพัฒนาต่อยอดติดตั้งระบบภายในรถสำรวจของหน่วยงานต่าง ๆ โดยใช้อุปกรณ์ที่มีต้นทุนต่ำในการพัฒนาบุคคลทั่วไปสามารถเข้าถึงและเก็บรวบรวมข้อมูลได้เป็นจำนวนมากและในบริเวณกว้าง โดยไม่จำเป็นต้องติดตั้งอุปกรณ์พิเศษเพิ่มเติมที่มีราคาแพง จึงเป็นแนวทางหนึ่ง ที่ควรพิจารณาเลือกใช้ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวดถนนที่ผิดปกติที่เสนอในงานวิจัยนี้

## บทที่ 5

### สรุปและข้อเสนอแนะ

งานวิจัยนี้เสนอขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการเรียนรู้เชิงลึก (Deep Learning) ด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model) ร่วมกับวิธีการเรียนรู้เชิงลึกหลายรูปแบบ (Multimodal Deep Learning) ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks Model) เพื่อเพิ่มความแม่นยำในขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ การใช้วิธีการเรียนรู้เชิงลึกด้วยตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเป็นการถ่ายโอนการเรียนรู้และปรับปรุงการเรียนรู้ใหม่สำหรับใช้ในงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ส่งผลให้ประหยัดเวลาในการเรียนรู้ ไม่จำเป็นต้องใช้ชุดข้อมูลเรียนรู้เป็นจำนวนมากและมีประสิทธิภาพที่ดีกว่าตัวแบบที่ถูกสร้างขึ้นมาเองตั้งแต่เริ่มต้น ส่วนการใช้วิธีการเรียนรู้เชิงลึกหลายรูปแบบด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบเป็นนวัตกรรมใหม่ที่สกัดคุณลักษณะและหลอมรวมคุณลักษณะแบบอัตโนมัติเพื่อเรียนรู้และจำแนกคุณลักษณะข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่เกิดขึ้นในเวลาเดียวกัน โดยสรุปขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนที่นำเสนอในงานวิจัย ดังแสดงในรูปที่ 5.1



รูปที่ 5.1 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน



ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติ ดังรูปที่ 5.1 เริ่มต้นนำข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากสมาร์ตโฟน จากนั้นสกัดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนในตำแหน่งที่ตรงกัน แล้วนำเข้าข้อมูลรูปภาพเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า

ผลลัพธ์ที่ได้ คือ วัตถุที่ถูกระบุจากนั้นตรวจสอบค่าความเชื่อมั่นของวัตถุที่ถูกระบุได้ หากวัตถุที่ถูกระบุมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกระบุมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้นำวัตถุตัวเลือกนั้น (Candidate Objects) มาตรวจสอบตำแหน่งของวัตถุตัวเลือกโดยคำนวณค่าไอโอยู (Intersection Over Union: IoU) คือ อัตราส่วนพื้นที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้นกับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หาค่าพื้นที่รวมทั้งหมด (Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้นกับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือ ค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ในขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0ให้นำวัตถุตัวเลือกนั้นมาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

โดยนำเข้าภาพวัตถุและค่าอัตราเร่งของแรงสั่นสะเทือนของรูปภาพนั้นเพื่อจำแนกสภาพพื้นผิวถนนใหม่ งานวิจัยนี้เพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบที่หลอมรวมคุณลักษณะของข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน ผลลัพธ์ที่ได้คือ ภาพของวัตถุที่ถูกระบุพร้อมทั้งระบุประเภทสภาพพื้นผิวถนนและค่าความเชื่อมั่นของภาพวัตถุนั้น จากนั้นตรวจสอบค่าความเชื่อมั่น หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด และวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติ ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพและสิ้นสุดขั้นตอนการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ผลที่ได้จากงานวิจัยนี้ก่อให้เกิดประโยชน์ในแง่องค์ความรู้ทางวิชาการ (Contributions) ดังนี้

1) ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติโดยใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าและเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติโดยใช้วิธีการเรียนรู้เชิงลึกหลายรูปแบบด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชัน

หลายรูปแบบที่เกิดจากการหลอมรวมคุณลักษณะของข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน

2) ชุดข้อมูลสภาพพื้นผิวถนนที่ประกอบด้วยข้อมูลรูปภาพสำหรับใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติและข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับการจำแนกสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้สามารถนำไปใช้เพื่อพัฒนาขั้นตอนวิธีสำหรับเรียนรู้และทดสอบ เพื่อสร้างตัวแบบตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติต่อไป

3) ผลจากการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติสามารถนำไปวิเคราะห์เพื่อเลือกใช้วิธีการซ่อมบำรุงรักษาถนนที่เหมาะสม ช่วยลดต้นทุนในการบำรุงรักษาถนนและเพิ่มความปลอดภัยในการเดินทางต่อไป

สำหรับในบทนี้กล่าวถึงสรุปผลการวิจัย ข้อจำกัดของการวิจัย การประยุกต์ผลการวิจัยและข้อเสนอแนะในการวิจัยครั้งต่อไป มีรายละเอียดดังนี้

## 5.1 สรุปผลการวิจัย

### 5.1.1 สรุปผลการเก็บรวบรวมข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

งานวิจัยนี้เก็บรวบรวมข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนของสภาพพื้นผิวถนนที่ผิดปกติบนถนนลาดยางแอสฟัลท์ภายในจังหวัดนครราชสีมาโดยใช้แอปพลิเคชันที่ถูกพัฒนาขึ้นบนระบบปฏิบัติการแอนดรอยด์จากกล้องบันทึกวิดีโอและเครื่องวัดค่าอัตราเร่งของแรงสั่นสะเทือน (Accelerometer) ในโทรศัพท์มือถือรุ่น Samsung Galaxy A9 Pro ปี 2016 โทรศัพท์มือถือถูกติดตั้งบนคอนโซลหน้ารถยนต์รุ่น Honda City 2010 ระยะทางจากจุดตั้งโทรศัพท์ไปจนถึงจุดที่สามารถเห็นภาพได้ชัดเจน คือ 6.5 เมตร ความเร็วรถยนต์ในการเก็บข้อมูล 40 – 60 กิโลเมตร/ชั่วโมง กำหนดค่าเริ่มต้นของระบบบันทึกข้อมูลภาพวิดีโอและค่าอัตราเร่งของแรงสั่นสะเทือนของสภาพพื้นผิวถนน ดังนี้ ความละเอียดของภาพเท่ากับ 1920 x 1080 พิกเซล อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความถี่ในการจัดเก็บภาพเท่ากับ 80 Hz

โครงข่ายถนนลาดยางแอสฟัลท์ที่ถูกเก็บรวบรวมข้อมูล ได้แก่ ถนนสาย 304 นครราชสีมา-ปักธงชัยและถนนสายรอง ถนนทางหลวงแผ่นดินหมายเลข 204 หรือทางเลี่ยงเมืองนครราชสีมาและถนนสายรอง ถนนเอกิงพล ถนนคลองส่งน้ำ ที่มีสภาพพื้นผิวถนนในลักษณะต่าง ๆ ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks) 3) รอยแตกตามแนวขวาง (Transverse Cracks) 4) รอยแตกหนังจระเข้ (Alligator Cracks) 5) รอยปะซ่อม

(Patch) 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal Road) ตามลักษณะพื้นผิวถนนที่ได้มาจากสภาพแวดล้อม

### 5.1.2 สรุปผลการสร้างชุดข้อมูลสำหรับตรวจจับและจำแนกสภาพพื้นผิวถนนที่ผิดปกติ

ชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ มีทั้งสิ้น 6,584 ภาพ ประกอบด้วย กรอบล้อมวัตถุ (Bounding Box) พร้อมทั้งระบุประเภทสภาพพื้นผิวถนน (Class Name) ซึ่งมีจำนวนทั้งสิ้น 10,240 วัตถุ งานวิจัยนี้แบ่งประเภทสภาพพื้นผิวถนนออกเป็น 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal cracks) 3) รอยแตกตามแนวขวาง (Transverse cracks) 4) รอยแตกหนังจระเข้ (Alligator cracks) 5) รอยปะซ่อม (Patch) และ 6) เนินชะลอความเร็ว (Speed bumps)/ เส้นชะลอความเร็ว (Rumble Strips)

ชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนสำหรับจำแนกสภาพพื้นผิวถนนที่ผิดปกติมีทั้งหมด 6,399 ภาพ ประกอบด้วย รูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนที่ถูกระบุประเภทสภาพพื้นผิวถนนไว้แล้วใน 7 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal cracks) 3) รอยแตกตามแนวขวาง (Transverse cracks) 4) รอยแตกหนังจระเข้ (Alligator cracks) 5) รอยปะซ่อม (Patch) 6) เนินชะลอความเร็ว (Speed bumps)/ เส้นชะลอความเร็ว (Rumble Strips) และ 7) ถนนปกติ (Normal road)

### 5.1.3 สรุปผลการประเมินตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (Pretrained Model)

ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าถูกเลือกมาจากตัวแบบที่ให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (Mean Average Precision: mAP) สูงสุดจำนวน 5 ลำดับแรก เมื่อทดสอบบนชุดข้อมูลรูปภาพของโคโค (COCO Dataset) จากนั้นใช้เทคนิคการถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับงานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เพื่อเปรียบเทียบและเลือกใช้ตัวแบบที่ให้ค่า mAP สูงที่สุด เมื่อทดสอบบนชุดข้อมูลตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ผลการทดลองแสดงให้เห็นว่า ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้าที่เหมาะสมสำหรับการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ คือ ตัวแบบ SSD ResNet50 FPN ซึ่งให้ค่า mAP สูงถึง 87.38% โดยมีโครงสร้างของตัวตรวจจับวัตถุแบบ SSD และมีโครงสร้างของการสกัดคุณลักษณะแบบ Resnet 50 FPN จุดเด่นของโครงสร้างแบบ SSD คือ ผลลัพธ์ที่ได้จากการทำคอนโวลูชันในแต่ละชั้นที่มีขนาดแตกต่างกัน ช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุได้อย่างมีนัยสำคัญและเหมาะกับภาพที่มีวัตถุขนาดแตกต่างกันมากได้ (Liu et al., 2016) สอดคล้องกับผลการทดลองนี้ที่ภาพวัตถุของสภาพพื้นผิวถนนที่ผิดปกติที่มีขนาดแตกต่างกันส่งผลให้การตรวจจับวัตถุที่ใช้โครงสร้างแบบ SSD นั้น ให้ค่า mAP สูงกว่าตัวแบบที่มีโครงสร้าง

แบบ Faster R-CNN ที่นำมาเปรียบเทียบในการทดลองครั้งนี้ นอกจากนี้ผลการประเมินประสิทธิภาพด้านเวลาในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติบนชุดข้อมูลทดสอบโดยใช้ตัวแบบ SSD ResNet50 FPN แสดงว่า ตัวแบบที่มีโครงสร้างแบบ SSD ใช้เวลาในการตรวจจับวัตถุต่อ 1 ภาพน้อยกว่าตัวแบบที่มีโครงสร้างแบบ Faster R-CNN ที่นำมาเปรียบเทียบในการทดลองครั้งนี้

เมื่อเปรียบเทียบค่าเฉลี่ยความแม่นยำ (AP) ของแต่ละตัวแบบ พบว่า ตัวแบบ SSD ResNet50 FPN (SRF) ให้ค่า AP สูงที่สุด มีจำนวน 4 ประเภท ได้แก่ รอยแตกตามแนวขวาง รอยแตกหนังจระเข้ หลุมบ่อและรอยปะซ่อม ซึ่งได้ค่า AP เท่ากับ 92.77%, 87.55%, 84.39% และ 80.94% ตามลำดับ นั้นแสดงว่า ตัวแบบ SRF สามารถตรวจจับสภาพพื้นผิวถนนทั้ง 4 ประเภทได้ดีกว่าอีก 4 ตัวแบบที่นำมาเปรียบเทียบในการทดลองครั้งนี้ รองลงมาคือ รอยแตกตามแนวยาว และเนินชะลอความเร็ว/เส้นชะลอความเร็ว ซึ่งได้ค่า AP เท่ากับ 79.02% และ 99.63% ตามลำดับ โดยกำหนดเกณฑ์คะแนนความเชื่อมั่นเท่ากับ 0.00 และค่าไอโอยูเท่ากับ 0.5

#### 5.1.4 สรุปผลการประเมินตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (Multimodal Deep Convolution Neural Networks Model)

ตัวแบบ Multimodal DCNN ถูกสร้างมาจากตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าซึ่งชื่อ Inception V3 ที่มีทั้งหมด 22 ชั้น (Layers) เพื่อใช้สกัดคุณลักษณะข้อมูลรูปภาพ โดยป้อนข้อมูลรูปภาพเข้าที่มีขนาดเท่ากับ  $299 \times 299 \times 3$  ตามข้อกำหนดการป้อนข้อมูลเข้าของตัวแบบ Inception-v3 และตัวแบบ Multimodal DCNN ถูกสร้างมาจากโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันเพื่อใช้สกัดคุณลักษณะข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนและห่อรวมคุณลักษณะข้อมูลทั้งสองเข้าด้วยกันในชั้นการเชื่อมต่อแบบทั่วถึงจากนั้นจึงจำแนกคุณลักษณะข้อมูลเพื่อทำนายสภาพพื้นผิวถนน

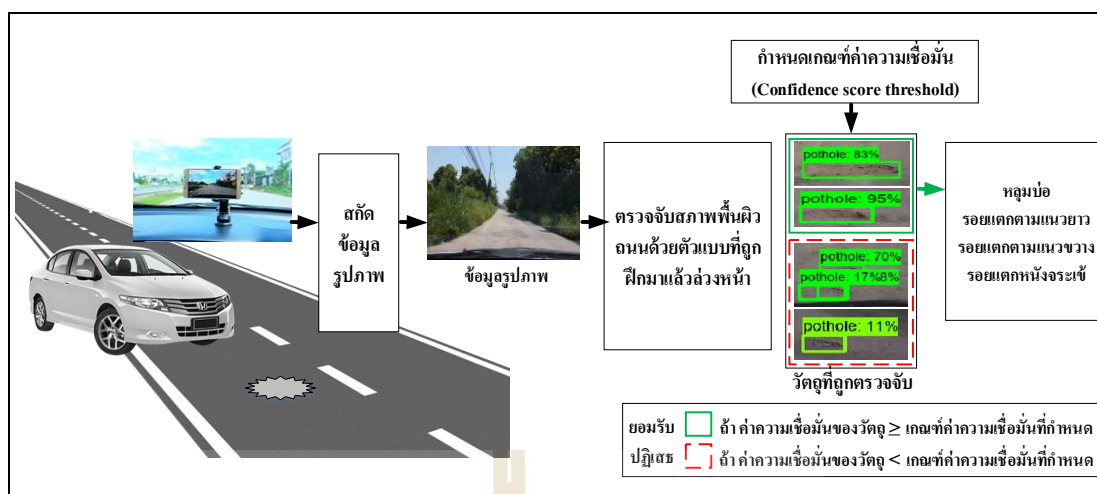
ในระหว่างการอ่านชุดข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อสร้างตัวแบบจำแนกสภาพพื้นผิวถนน งานวิจัยนี้ใช้วิธีการแปลงข้อมูล (Data Transformation) โดยการทำนอร์มอลไลซ์ (Normalization) ด้วยเทคนิค Min-Max Normalization เพื่อปรับข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้มีความแตกต่างที่น้อยลงและช่วยให้การประมวลผลเร็วขึ้น นอกจากนี้ ในชั้นคอนโวลูชันได้ใช้ฟังก์ชัน ReLU (Rectified Linear Unit) เป็นฟังก์ชันกระตุ้นซึ่งใช้เปลี่ยนค่าลบจากผลลัพธ์ให้เป็นศูนย์และคงที่ค่าบวกไว้ ส่งผลให้ช่วยลดจำนวนตัวแปรในโครงข่ายที่ส่งผลให้โครงข่ายเรียนรู้ได้เร็วและมีประสิทธิภาพมากยิ่งขึ้น ยิ่งไปกว่านั้น ในชั้นการเชื่อมต่อแบบทั่วถึงได้ใช้ดรอปเอาต์ (Dropout) เพื่อป้องกันการเกิด Overfitting โดยการสุ่มปิดโหนดในเซลล์ประสาทเทียมไม่ให้ส่งข้อมูลในแต่ละรอบการสอนตัวแบบ

ผลการประเมินตัวแบบ Multimodal DCNN บนชุดข้อมูลทดสอบรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน แสดงให้เห็นว่า ได้ค่าความแม่นยำ (Accuracy) เท่ากับ 91.30% เมื่อพิจารณาผลการประเมินในแต่ละประเภทสภาพพื้นผิวถนน พบว่า ค่าความแม่นยำ (Precision) อยู่ระหว่าง 82.35% – 99.28% ค่าความระลึก (Recall) อยู่ระหว่าง 82.66% – 100% และค่าเอฟเมเชอร์ (F-measure) อยู่ระหว่าง 82.50% – 99.64% ซึ่งผลการประเมินตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบในภาพรวมให้ค่าความแม่นยำและค่าความระลึกรวมกันมากกว่า 80% ขึ้นไปทุกประเภทสภาพพื้นผิวถนนที่มีทั้งสิ้น 7 ประเภท

### 5.1.5 สรุปผลการประเมินขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ฝึกปกติที่ผ่านมา

งานวิจัยที่ผ่านมาของ Maeda และคณะ (2018) Singh และ Shekhar (2018) และ Koh และคณะ (2019) เลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า ได้แก่ SSD Inception\_V2, SSD MobileNet, Mask region-based convolutional network (Mask R-CNN) และ Region-based Fully Convolutional Networks (R-FCN) โดยกำหนดเกณฑ์คะแนนความเชื่อมั่น (Confidence Score Threshold) เท่ากับ 0.00 หรือเลือกกำหนดเกณฑ์คะแนนความเชื่อมั่นตามความเหมาะสมของผู้วิจัย ส่งผลให้วัตถุที่ถูกตรวจจับที่มีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด ถูกยอมรับและตีกรอบล้อมรอบวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับที่มีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุนั้นในภาพ หารู้จักดี วัตถุที่ถูกตรวจจับที่มีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนด (False Positive) อาจเป็นวัตถุตัวเลือก (Candidate Objects) ที่ถูกตรวจจับได้ถูกต้องหรือไม่ถูกต้องตามประเภทสภาพพื้นผิวถนนที่ฝึกปกติ หากนำวัตถุตัวเลือกเหล่านี้มาตรวจสอบและจำแนกประเภทใหม่โดยใช้ตัวแบบในการจำแนกสภาพพื้นผิวถนนที่ฝึกปกติด้วยวิธีการเรียนรู้เชิงลึกหลายรูปแบบจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือน ผลการตรวจสอบและจำแนกประเภทใหม่อาจจะเป็นอีกวิธีหนึ่งที่เพิ่มความแม่นยำในขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ฝึกปกติได้ ดังแสดงในรูปที่ 5.2





รูปที่ 5.2 การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพ

ในงานวิจัยนี้ เลือกใช้ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า คือ ตัวแบบ SSD ResNet50 FPN ซึ่งให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำสูงที่สุดที่ 87.38% เพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ในการทดลองได้กำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 เพื่อเลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่เหมาะสม ผลการทดลองแสดงให้เห็นว่า การเพิ่มค่าเกณฑ์คะแนนความเชื่อมั่นให้มากขึ้นในแต่ละระดับระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) ส่งผลให้ค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) มีแนวโน้มลดลง (จาก 87.38% ลดลงเหลือ 40.67%) และค่าเฉลี่ยความแม่นยำ (AP) ของแต่ละประเภทสภาพพื้นผิวถนนที่ผิดปกติมีแนวโน้มลดลงเช่นกัน เพื่อเพิ่มความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นในแต่ละระดับระหว่าง 0.00 – 0.95 และกำหนดค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 งานวิจัยนี้จึงนำวัตถุที่ถูกรวบรวม (False Positive) ที่ค่าคะแนนความเชื่อมั่นของวัตถุน้อยกว่าเกณฑ์คะแนนความเชื่อมั่นที่กำหนด มาตรวจสอบและจำแนกประเภทใหม่โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (ตัวแบบ Multimodal DCNN)

### 5.1.6 สรุปขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติแบบอัตโนมัติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN และเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนใหม่โดยใช้ตัวแบบ Multimodal DCNN ที่หลอมรวมคุณลักษณะข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเข้าด้วยกัน โดยมีขั้นตอนการตรวจจับสภาพพื้นผิวถนนซึ่งประกอบด้วย 7 ขั้นตอน ดังนี้

## เริ่มต้น

ขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยการรับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

### ขั้นตอนที่ 1

รับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนจากโทรศัพท์สมาร์ทโฟน

### ขั้นตอนที่ 2

สกัดชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนให้อยู่ในตำแหน่งที่ใกล้เคียงกัน (ตำแหน่งที่มองเห็นสภาพพื้นผิวถนนได้ชัดเจนอยู่ห่างจากรถเป็นระยะทาง 6.5 เมตรและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนซึ่งอยู่ในตำแหน่งของรถ) โดยทำการคำนวณหาเวลาที่บวกเพิ่มจากเวลาที่ดึงรูปภาพซึ่งใช้สูตรการเคลื่อนที่ในอัตราเร่งคงที่

### ขั้นตอนที่ 3

ป้อนข้อมูลรูปภาพเข้าตัวแบบที่ถูกฝึกมาแล้วล่วงหน้าเพื่อตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ผลลัพธ์ที่ได้คือวัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวถนนใน 6 ประเภท

### ขั้นตอนที่ 4

ตรวจสอบค่าความเชื่อมั่น หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด ให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุที่ถูกตรวจจับมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้นำวัตถุตัวเลือกนั้น (Candidate Objects) เข้าตรวจสอบในขั้นตอนถัดไป ซึ่งวัตถุตัวเลือกนั้นอาจเป็นสภาพพื้นผิวถนนที่ผิดปกติที่ต้องการ

### ขั้นตอนที่ 5

ตรวจสอบตำแหน่งของวัตถุตัวเลือกนั้น โดยคำนวณหาค่าไอโอยู (Intersection Over Union: IoU) คือ อัตราส่วนพื้นที่ที่ทับซ้อนกัน (Area of Overlap) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หาค่าด้วยพื้นที่รวมทั้งหมด (Area of Union) ระหว่างพื้นที่ของวัตถุตัวเลือกนั้น กับพื้นที่ในภาพบริเวณสี่เหลี่ยมที่กำหนด หากวัตถุตัวเลือกนั้นอยู่ภายนอกขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือ ค่าไอโอยูเท่ากับ 0 ให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นอยู่ภายในขอบเขตแนวสี่เหลี่ยมที่กำหนด นั่นคือ ค่าไอโอยูมากกว่า 0 ให้นำวัตถุนั้นมาจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ

## ขั้นตอนที่ 6

นำเข้าภาพวัตถุตัวเลือกนั้นและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเพื่อจำแนกสภาพพื้นผิวถนนใหม่ด้วยตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ ผลลัพธ์ที่ได้คือวัตถุที่ถูกตรวจจับเป็นสภาพพื้นผิวถนนใน 7 ประเภท

## ขั้นตอนที่ 7

ตรวจสอบค่าความเชื่อมั่น หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นมากกว่าหรือเท่ากับเกณฑ์ค่าความเชื่อมั่นที่กำหนด และวัตถุตัวเลือกนั้นไม่ใช่สภาพพื้นผิวถนนปกติให้ยอมรับและแสดงกรอบขอบเขตของวัตถุนั้นในภาพ ในทางตรงกันข้าม หากวัตถุตัวเลือกนั้นมีค่าความเชื่อมั่นน้อยกว่าเกณฑ์ค่าความเชื่อมั่นที่กำหนดให้ปฏิเสธวัตถุตัวเลือกนั้นในภาพ

### จบการทำงาน

#### 5.1.7 สรุปผลการเปรียบเทียบขั้นตอนวิธีในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ผลการเปรียบเทียบค่าเฉลี่ยของค่าเฉลี่ยความแม่นยำ (mAP) ระหว่างขั้นตอนวิธีที่ผ่านมาและขั้นตอนวิธีใหม่ที่น่าสนใจในงานวิจัยนี้ เมื่อกำหนดเกณฑ์คะแนนความเชื่อมั่นระหว่าง 0.00 – 0.95 (เพิ่มขึ้นระดับละ 0.05) และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 พบว่า

1) ขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวให้ค่า mAP ที่มีค่าลดลงจาก 87.38% เหลือ 40.67% ส่วนขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนโดยใช้ตัวแบบ SSD ResNet50 FPN ร่วมกับตัวแบบ Multimodal DCNN ให้ค่า mAP ที่มีค่าระหว่าง 87.38 – 90.65% ซึ่งค่า mAP เพิ่มขึ้นระหว่าง 0.76% – 35.38%

ดังนั้น ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำจากข้อมูลรูปภาพและค่าอัตราเร่งของแรงสั่นสะเทือนในโทรศัพท์สมาร์ทโฟน สามารถตรวจจับสภาพพื้นผิวถนนได้ความแม่นยำมากกว่าขั้นตอนวิธีการตรวจจับสภาพพื้นผิวถนนโดยใช้ข้อมูลจากรูปภาพเพียงรูปแบบเดียว

2) หากต้องการเลือกใช้ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยให้ความสำคัญกับค่า mAP สูงที่สุด ควรพิจารณาเลือกใช้เกณฑ์คะแนนความเชื่อมั่นระดับ 0.05 และค่าไอโอยูมากกว่าหรือเท่ากับ 0.5 ซึ่งทำให้ได้รับค่า mAP เท่ากับ 90.65% โดยค่า mAP เพิ่มขึ้น 4.51% เมื่อเทียบกับขั้นตอนวิธีที่ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียวที่ให้ค่า mAP เพียง 86.14%

3) หากต้องการเลือกใช้ขั้นตอนวิธีใหม่ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ โดยให้ความสำคัญทั้งค่า mAP และ ค่า AP สูงในทุก ๆ ประเภทของสภาพพื้นผิวถนน ควรพิจารณา

เลือกใช้เกณฑ์คะแนนความเชื่อมั่นที่ 0.60 ขึ้นไปซึ่งจะทำให้ได้รับค่า mAP ระหว่าง 76.06 – 77.60% และให้ค่า AP ระหว่าง 64.58 – 95.45% เมื่อเทียบกับขั้นตอนวิธีที่ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติจากข้อมูลรูปภาพโดยใช้ตัวแบบ SSD ResNet50 FPN เพียงอย่างเดียว ที่ให้ค่า mAP ระหว่าง 40.67 – 61.82% และให้ค่า AP ระหว่าง 1.80 – 85.35%

### 5.1.8 สรุปต้นทุนในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

การพัฒนาขั้นตอนวิธีใหม่ที่เสนอสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำ เมื่อพิจารณาต้นทุนในการพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนน พบว่า การพัฒนาขั้นตอนวิธีใหม่ที่เสนอมีต้นทุนที่น้อยกว่าการใช้เครื่องมือและอุปกรณ์จากงานวิจัยที่ผ่านมา แต่อย่างไรก็ตาม ความแม่นยำและลักษณะสภาพพื้นผิวถนนที่ตรวจจับมีความแตกต่างกันตามเครื่องมือและอุปกรณ์ที่ใช้ในการพัฒนา

### 5.2 ข้อจำกัดของการวิจัย

5.2.1 ชุดข้อมูลที่ใช้ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้ เป็นลักษณะสภาพพื้นผิวถนนที่ผิดปกติที่สามารถมองเห็นได้ชัดเจนผ่านกล้องโทรศัพท์มือถือที่ใช้ในการทดลองเท่านั้น ซึ่งลักษณะสภาพพื้นผิวถนนที่ผิดปกติขนาดเล็กที่ไม่สามารถมองเห็นผ่านกล้องโทรศัพท์มือถือได้ชัดเจนไม่นำมาใช้เป็นชุดข้อมูลและไม่สามารถตรวจจับได้

5.2.2 ชุดข้อมูลที่ใช้ในการเรียนรู้และทดสอบตัวแบบตรวจจับมาจากสภาพพื้นผิวถนนที่ผิดปกติมาจากถนนลาดยางแอสฟัลท์ ไม่สามารถนำตัวแบบตรวจจับมาจากสภาพพื้นผิวถนนที่ผิดปกติไปใช้บนถนนคอนกรีตและถนนลูกรังได้

5.2.3 ชุดข้อมูลที่ใช้ในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติถูกเก็บรวบรวมข้อมูลภายในจังหวัดนครราชสีมาภายใต้สภาพแวดล้อมทางธรรมชาติ ดังนั้น เพื่อเพิ่มความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติควรเก็บรวบรวมข้อมูลสภาพพื้นผิวถนนเพิ่มขึ้นในหลาย ๆ จังหวัด เพื่อให้ได้ชุดข้อมูลมาให้ตัวแบบเรียนรู้ลักษณะสภาพพื้นผิวถนนที่หลากหลายภายใต้สภาพแวดล้อมต่าง ๆ

5.2.4 การับรุดเก็บรวบรวมข้อมูลหรือการนำตัวแบบไปใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ควรับรุดด้วยความเร็วที่ 40 - 60 กิโลเมตร/ชั่วโมงเท่านั้นจึงจะสามารถนำตัวแบบไปใช้ตรวจจับสภาพพื้นผิวถนนที่ผิดปกติได้ใกล้เคียงกับผลการทดลอง

5.2.5 โทรศัพท์มือถือที่ใช้สำหรับการตรวจจับสภาพพื้นผิวถนนต้องมีความละเอียดของหน้าจอเท่ากับ 1920×1080 พิกเซล (Pixels) อัตราเฟรมในการจัดเก็บภาพเท่ากับ 30 fps (Frame per Second) และความถี่ในการจัดเก็บภาพเท่ากับ 80 Hz หากใช้โทรศัพท์มือถือรุ่นอื่น

ที่มีความละเอียดแตกต่างจากการทดลองอาจส่งผลต่อความแม่นยำในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

5.2.6 ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนเก็บข้อมูลด้วยความถี่ 80 เฮิร์ตซ์ (Hz.) เท่านั้น จึงจะสามารถนำตัวแบบไปใช้งานตรวจจับสภาพพื้นผิวถนนที่ผิดปกติได้ใกล้เคียงกับผลการทดลอง

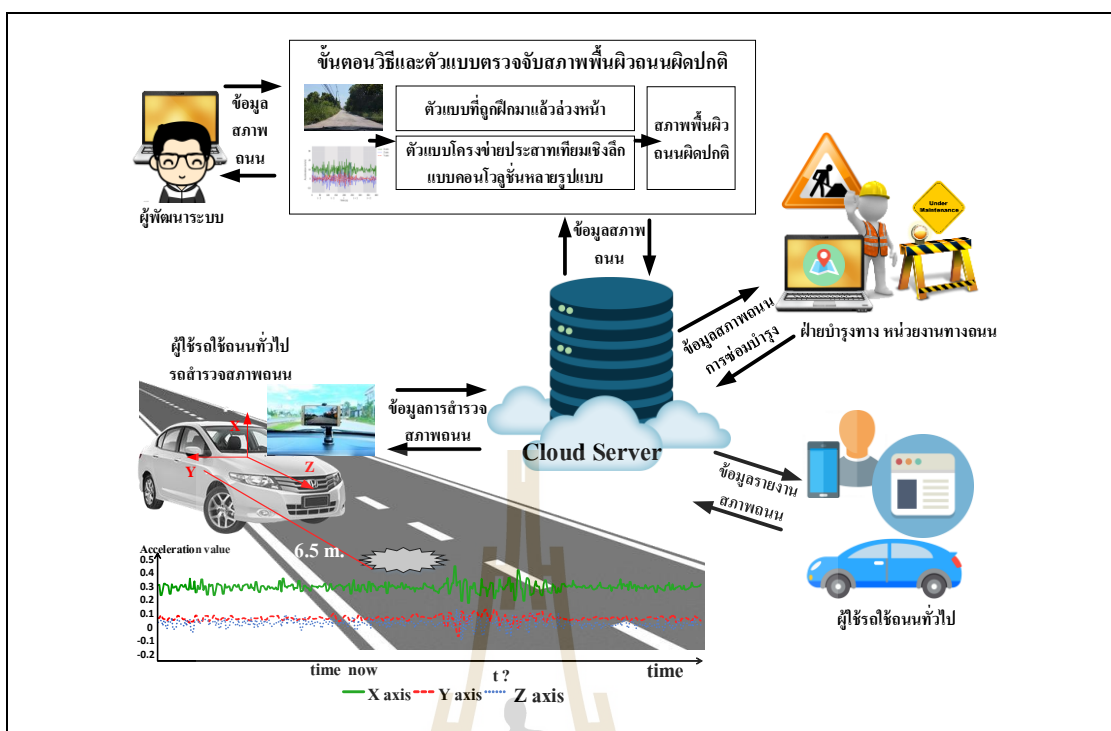
5.2.7 ข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนหรือแรงสั่นสะเทือนของรถยนต์แต่ละคันแตกต่างกัน ขึ้นตอนวิธีที่ถูกพัฒนาขึ้นสามารถนำไปใช้ได้กับยานพาหนะที่มีระบบการป้องกันแรงสั่นสะเทือนที่ใกล้เคียงกับยานพาหนะที่ใช้ในการทดลองเท่านั้น

5.2.8 โทรศัพท์สมาร์ทโฟนถูกติดตั้งไว้ในตำแหน่งที่กำหนดบริเวณตรงกลางคอนโซลภายในยานพาหนะ ด้านบนของโทรศัพท์สมาร์ทโฟนหันไปทางด้านซ้ายของตัวรถ กล้องในโทรศัพท์สมาร์ทโฟนหันไปทางทิศทางการเดินทางของรถเพื่อให้มุมมองที่แสดงสภาพพื้นผิวถนนที่ชัดเจนตามวิธีเตรียมการทดลองเท่านั้น ซึ่งการติดตั้งโทรศัพท์สมาร์ทโฟนในตำแหน่งที่แตกต่างกันส่งผลให้ได้รับข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือนที่แตกต่างกันด้วย

### 5.3 การประยุกต์ผลการวิจัย

ขั้นตอนวิธีและตัวแบบในการตรวจจับสภาพพื้นผิวถนนผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำในงานวิจัยนี้ ประกอบด้วย ตัวแบบที่ถูกฝึกมาแล้วล่วงหน้า (ตัวแบบ SSD ResNet50 FPN) และเพิ่มความแม่นยำในการจำแนกสภาพพื้นผิวถนนที่ผิดปกติใหม่โดยใช้ตัวแบบโครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชันหลายรูปแบบ (ตัวแบบ Multimodal DCNN) ซึ่งสามารถตรวจจับสภาพพื้นผิวถนนลาดยางแอสฟัลท์ที่ผิดปกติได้ 6 ประเภท ได้แก่ 1) หลุมบ่อ (Pothole) 2) รอยแตกตามแนวยาว (Longitudinal Cracks), 3) รอยแตกตามแนวขวาง (Transverse Cracks), 4) รอยแตกหนังจระเข้ (Alligator Cracks), 5) รอยปะชั้ อม (Patch) และ 6) เนินชะลอความเร็ว (Speed Bumps)/ เส้นชะลอความเร็ว (Rumble Strips) ขั้นตอนวิธีใหม่และตัวแบบที่เสนอสามารถนำไปประยุกต์ใช้กับสภาพพื้นผิวถนนลาดยางแอสฟัลท์อื่น ๆ ที่มีลักษณะใกล้เคียงกับถนนที่ใช้ในการทดลองตามสภาพแวดล้อมทางธรรมชาติได้ทั่วโลก เพื่อนำผลการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติไปแจ้งเตือนผู้ใช้รถใช้ถนน รายงานและจัดสรรงบประมาณการบำรุงรักษาถนนได้ต่อไปในอนาคต โดยเฉพาะอย่างยิ่ง หน่วยงานภาครัฐของประเทศไทย ได้แก่ กรมทางหลวง กรมทางหลวงชนบท และองค์กรปกครองส่วนท้องถิ่น การประยุกต์ผลการวิจัยโดยนำขั้นตอนวิธีและตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ แสดงดังสถาปัตยกรรมของระบบในรูปที่ 5.3





รูปที่ 5.3 สถาปัตยกรรมของระบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

จากรูป 5.3 แสดงสถาปัตยกรรมของระบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ เพื่อการประยุกต์ผลการวิจัยโดยนำขั้นตอนวิธีและตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ ด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำในงานวิจัยนี้ ไปเก็บไว้ใน Cloud Server เพื่อประมวลผล ข้อมูลสภาพพื้นผิวถนน เมื่อผู้ใช้รถใช้ถนนทั่วไปหรือรถสำรวจสภาพพื้นผิวถนนของหน่วยงาน ทางถนนต้องการสำรวจและส่งข้อมูลสภาพถนน ให้ติดตั้งแอปพลิเคชันระบบบันทึกข้อมูล สภาพพื้นผิวถนนที่ถูกพัฒนาขึ้นบนระบบปฏิบัติการแอนดรอยด์ จากนั้นส่งข้อมูลผ่านเครือข่าย อินเทอร์เน็ตไปยัง Cloud Server จากนั้นผู้พัฒนาระบบทำการสร้างขั้นตอนวิธีและตัวแบบตรวจจับ สภาพพื้นผิวถนนที่ผิดปกติ ซึ่งสามารถดึงข้อมูลสภาพพื้นผิวถนนมาจาก Cloud Server เพื่อทำการสร้างชุดข้อมูลสำหรับเรียนรู้และทดสอบได้แล้วนำผลการพัฒนาตัวแบบมาใช้งาน ส่วนผู้ใช้รถใช้ถนนทั่วไปที่ต้องการข้อมูลรายงานหรือแจ้งเตือนสภาพพื้นผิวถนนที่ผิดปกติ สามารถเลือกแสดงรายงานหรือแจ้งเตือนได้จากแอปพลิเคชันรายงานสภาพพื้นผิวถนนที่ผิดปกติ สำหรับฝ่ายบำรุงทางหรือหน่วยงานทางถนนที่ต้องการข้อมูลรายงานสภาพพื้นผิวถนนที่ผิดปกติ เพื่อวางแผนซ่อมบำรุงรักษาดูแลถนน สามารถเลือกแสดงรายงานหรือแจ้งเตือนได้จากแอปพลิเคชัน รายงานสภาพพื้นผิวถนนที่ผิดปกติ

#### 5.4 ข้อเสนอแนะในการวิจัยครั้งต่อไป

ขั้นตอนวิธีและตัวแบบในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบต้นทุนต่ำบนโทรศัพท์สมาร์ตโฟนในงานวิจัยนี้เป็นงานวิจัยเชิงประยุกต์ซึ่งถูกออกแบบและพัฒนาเพื่อนำเทคโนโลยีสารสนเทศมาประยุกต์ใช้ในการตรวจจับสภาพพื้นผิวถนนผิดปกติให้มีความแม่นยำมากยิ่งขึ้น ในการวิจัยครั้งต่อไปเพื่อให้ตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติมีความแม่นยำมากยิ่งขึ้น ควรรวบรวมข้อมูลสภาพพื้นผิวถนนจากยานพาหนะที่แตกต่างกัน รวมทั้งเพิ่มจำนวนชุดข้อมูลเรียนรู้และทดสอบ เพื่อให้ตัวแบบสามารถเรียนรู้คุณลักษณะข้อมูลสภาพพื้นผิวถนนที่มีความหลากหลายและครอบคลุมตามสภาพแวดล้อมทางธรรมชาติมากขึ้น นอกจากนี้ ควรพัฒนาให้ตัวแบบเรียนรู้ประเภทถนน เช่น ถนนคอนกรีต และถนนลูกรัง ที่ยังคงมีสภาพพื้นผิวถนนที่ผิดปกติอยู่ในประเทศไทยและนำผลการตรวจจับวัตถุที่ได้จากตัวแบบมาตรวจสอบระดับความรุนแรงตามลักษณะพื้นผิวถนนในแต่ละประเภท

ยิ่งไปกว่านั้น ขั้นตอนวิธีและตัวแบบตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในงานวิจัยนี้ถือว่าเป็นการยกระดับงานด้านการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติในปัจจุบันและเป็นการสร้างมาตรฐานด้านการประยุกต์ใช้เทคโนโลยีสารสนเทศในการตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบที่มีต้นทุนต่ำบนโทรศัพท์สมาร์ตโฟนสำหรับประเทศไทย ผลการศึกษาที่ได้รับทั้งขั้นตอนวิธี ตัวแบบและชุดข้อมูลสภาพพื้นผิวถนนสำหรับการเรียนรู้และทดสอบ ดังนั้น ควรได้รับการพัฒนาต่อยอดบนฐานความรู้ของหน่วยงานภาครัฐของประเทศไทย ได้แก่ กรมทางหลวง กรมทางหลวงชนบทและองค์กรปกครองส่วนท้องถิ่น เพื่อเป็นการยกระดับงานตรวจสอบสภาพพื้นผิวถนนในปัจจุบันและส่งผลประโยชน์ที่ได้รับจากขั้นตอนวิธีใหม่ในงานวิจัยนี้ไปยังประชาชนผู้ใช้รถใช้ถนน เพื่อความปลอดภัยในการเดินทาง เกิดความสะดวกรวดเร็ว ความคล่องตัวของระบบขนส่งและความเจริญเติบโตทางเศรษฐกิจและสังคมในประเทศไทยต่อไป

## รายการอ้างอิง

- กรมทางหลวง. (2550). **คู่มือตรวจสอบและประเมินสภาพความเสียหายของผิวทาง**. กรุงเทพฯ: กรมทางหลวง.
- กรมทางหลวงชนบท. (2555). **คู่มือบำรุงปกติ**. กรมทางหลวงชนบท. พิมพ์ครั้งที่ 3. กรุงเทพฯ: กรมทางหลวงชนบท กระทรวงคมนาคม.
- กรมป้องกันและบรรเทาสาธารณภัย. (2554). **แผนที่นำทางเชิงกลยุทธ์ทศวรรษแห่งความปลอดภัยทางถนน พ.ศ. 2554- 2563**. กรุงเทพฯ: กรมป้องกันและบรรเทาสาธารณภัย.
- กรมส่งเสริมการปกครองส่วนท้องถิ่น กระทรวงมหาดไทย. (2554). **มาตรฐานถนน ทางเดินและทางเท้า**. กรุงเทพฯ: สำนักมาตรฐานการบริหารงานองค์กรปกครองส่วนท้องถิ่น.
- กรมทางหลวง. (2561). **ระยะทางในความรับผิดชอบกรมทางหลวง**. [ออนไลน์]. ได้จาก: <http://www.doh.go.th/content/page/page/1103>
- การทางพิเศษแห่งประเทศไทย. (2559). **รายงานประจำปี 2559**. [ออนไลน์]. ได้จาก: <http://exat.emworkgroup.co.th/images/633/annualreport2559.pdf>
- กองพัฒนาและส่งเสริมการบริหารงานท้องถิ่น. (2562). **สรุปปริมาณข้อมูลลงทะเบียนสายทาง “ถนนที่ อปท. รับผิดชอบ” รวมทั้งจังหวัด**. [ออนไลน์]. ได้จาก: [http://www.dla.go.th/upload/document/type2/2019/5/21698\\_1\\_1556701700498.pdf](http://www.dla.go.th/upload/document/type2/2019/5/21698_1_1556701700498.pdf)
- สถาบันการขนส่งในจุฬาลงกรณ์มหาวิทยาลัย. (2558). **รายงานฉบับสมบูรณ์ โครงการพัฒนาระบบบริหารจัดการความปลอดภัยทางถนนสำหรับกรมทางหลวง (ระยะที่ 1)**. กรุงเทพฯ: สถาบันการขนส่งในจุฬาลงกรณ์มหาวิทยาลัย.
- สำนักงานนโยบายและแผนการขนส่งและจราจร สำนักแผนความปลอดภัย กลุ่มพัฒนาความปลอดภัย. (2558). **รายงานการวิเคราะห์สถานการณ์อุบัติเหตุทางถนน พ.ศ. 2557**. กรุงเทพฯ: สำนักงานนโยบายและแผนการขนส่งและจราจร.
- สำนักบำรุงทาง กรมทางหลวงชนบท. (2561). **โครงข่ายสายทางกรมทางหลวงชนบท ประจำปีงบประมาณ 2561**. [ออนไลน์]. ได้จาก: [http://maintenance.drr.go.th/sites/maintenance.drr.go.th/files/KlongKai\\_61\\_2.pdf](http://maintenance.drr.go.th/sites/maintenance.drr.go.th/files/KlongKai_61_2.pdf)
- โอภาส เอี่ยมสิริวงศ์. (2555). **การวิเคราะห์และออกแบบระบบ (ฉบับปรับปรุงเพิ่มเติม)**. กรุงเทพฯ: ซีเอ็ดยูเคชั่น.

- Abdic, I., Fridman, L., Brown, D. E., Angell, W., Reimer, B., Marchi, E., and Schuller, B. (2016). Detecting road surface wetness from audio: A deep learning approach. In **Pattern Recognition (ICPR), 2016 23rd International Conference** (pp. 3458-3463). IEEE.
- Astarita, V., Caruso, M.V., Danieli, G., Festa, D.C., Giofrè, V.P., Iuele, T., and Vaiana, R. (2012). A mobile application for road surface quality control: UNIquALroad. In **Procedia - Social and Behavioral Sciences**, 54: 1135-114. ISSN 1877-0428, <https://doi.org/10.1016/j.sbspro.2012.09.828>.
- Bezak, P. (2016). Building recognition system based on deep learning. In **Artificial Intelligence and Pattern Recognition (AIPR), International Conference on** (pp. 159-163). IEEE.
- Buchinger, D., and Silva, A. G. (2014). Anomalies detection in asphalt pavements: a morphological image processing approach. **Revista Brasileira de Computação Aplicada**. 6(1): 121-129.
- Buttlar, W. G. and Islam, M. S. (2014). **Integration of smartphone-based pavement roughness data collection tool with asset management system**. [Online]. Available: <https://www.purdue.edu/discoverypark/nextrans/assets/pdfs/098IY04IntegrationofSmartphone-Based-PavementRoughnessdatacollectiontoolwithassetmanagementsystem.pdf>
- Buza, E., Omanovic, S and Huseinnovic, A. (2013) Pothole detection with image processing and spectral clustering. In **Proceedings of the 2nd International Conference on Information Technology and Computer Networks**. (pp. 48–53).
- Casas-avellaneda, D. A., and Lopez-parra, J. F. (2016). Detection and localization of potholes in roadways using smartphones. **DYNA**, 83 (195): 156-162. doi:10.15446/dyna.v83n195.44919
- Chang, K. T., Chang, J. R., and Liu, J. K. (2005). Detection of pavement distresses using 3D laser scanning technology. In **Proceedings of the 2005 ASCE international conference on computing in civil engineering**. (pp. 12-15).
- Chen, K., Lu, M., Fan, X., Wei, M., and Wu, J. (2011). Road condition monitoring using on-board three-axis accelerometer and GPS sensor. In **Communications and Networking in China (CHINACOM), 2011 6th International ICST Conference**. (pp. 1032-1037).

- Chen, Y. L., Jahanshahi, M. R., Manjunatha, P., Gan, W., Abdelbarr, M., Masri, S. F., ... and Caffrey, J. P. (2016). Inexpensive multimodal sensor fusion system for autonomous data acquisition of road surface conditions. **IEEE Sensors Journal**, 16 (21): 7731-7743.
- Chugh, G., Bansal, D., and Sofat, S. (2014). Road condition detection using smartphone sensors: A Survey. In **International Journal of Electronic and Electrical Engineering**. 7 (6): 595-601
- Coenen, T. B., and Golroo, A. (2017). A review on automated pavement distress detection methods. **Cogent Engineering**, 4 (1), 1374822.
- Cortes, C., and Vapnik, V. (1995). Support-vector networks. **Machine learning**. 20 (3): 273-297.
- Deng, L., and Yu, D. (2014). Deep learning: methods and applications. **Foundations and Trends® in Signal Processing**, 7 (3-4), 197-387.
- De Zoysa, K., Keppitiyagama, C., Seneviratne, G. P., and Shihan, W. W. A. T. (2007). . In **Proceedings of the 2007 workshop on Networked systems for developing regions**. (p. 9).
- Douangphachanh, V., and Oneyama, H. (2013). A study on the use of smartphones for road roughness condition estimation. **Journal of the Eastern Asia Society for Transportation Studies**. 10 (0): 1551-1564.
- Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M., Ebersbach, D., Stoeckert, U., and Gross, H. M. (2017). How to get pavement distress detection ready for deep learning? A systematic approach. In **Neural Networks (IJCNN), 2017 International Joint Conference** (pp. 2039-2047). IEEE.
- Enigo, V. F., Kumar, T. V., Vijay, S., and Prabu, K. G. (2016). Crowd sourcing based online petitioning system for pothole detection using android platform. **Procedia Computer Science**. 87: 316-321.
- Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., and Balakrishnan, H. (2008). The pothole patrol: using a mobile sensor network for road surface monitoring. In **Proceedings of the 6th international conference on Mobile systems, applications, and services**. (pp. 29-39).
- Ethem, A. (2010). **Introduction to Machine Learning Second Edition**. Massachusetts London, England: The MIT Press Cambridge.



- Fazeen, M., Gozick, B., Dantu, R., Bhukhiya, M., and González, M. C. (2012). Safe Driving Using Mobile Phones. In **Journal IEEE Transactions on Intelligent Transportation Systems**. 13 (3), 1462-1468. DOI=<http://dx.doi.org/10.1109/TITS.2012.2187640>
- Frome, A., Corrado, G. S., Shlens, J., Bengio, S., Dean, J., and Mikolov, T. (2013). Devise: A deep visual-semantic embedding model. In **Advances in neural information processing systems** (pp. 2121-2129).
- Giancarlo, Z. (2016). **Getting Started with TensorFlow**. United Kingdom: Packt Publishing.
- Giancarlo Z., Rezaul K., and Ahmed M. (2017). **Getting Started with Deep Learning**. United Kingdom: Packt Publishing.
- GNSS European GNSS Agency. (2015). **GNSS Market Report** Issue 4. [Online]. Available: [http://www.gsa.europa.eu/system/files/reports/GNSS-Market-Report-2015-issue4\\_0.pdf](http://www.gsa.europa.eu/system/files/reports/GNSS-Market-Report-2015-issue4_0.pdf). [Accessed 20 March 2016].
- González, A., O'brien, E. J., Li, Y. Y., and Cashell, K. (2008). The use of vehicle acceleration measurements to estimate road roughness. **Vehicle System Dynamics**. 46 (6): 483–499.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 770-778).
- Hou, Z., Wang, K. C., and Gong, W. (2007). Experimentation of 3D pavement imaging through stereovision. In **International Conference on Transportation Engineering 2007** (pp. 376-381).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., ... and Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 7310-7311).
- Huidrom, L., Das, L. K., and Sud, S. K. (2013). Method for automated assessment of potholes, cracks and patches from road surface video clips. **Procedia-Social and Behavioral Sciences**. 104: 312-321.

- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S., and Darrell, T. (2014). Caffe: Convolutional architecture for fast feature embedding. In **Proceedings of the 22nd ACM international conference on Multimedia** (pp. 675-678). ACM.
- Jo, Y., and Ryu, S. (2015). Pothole detection system using a black-box camera. **Sensors**. 15 (11): 29316-29331.
- Jo, Y., and Ryu, S. (2017). Pothole Detection Using Android Smartphone with a Video Camera. In **Journal of Emerging Trends in Computing and Information Sciences**. 1 (8): 25 - 29.
- Jog, G. M., Koch, C., Golparvar-Fard, M., and Brilakis, I. (2012). Pothole properties measurement through visual 2D recognition and 3D reconstruction. In **Proceedings of the ASCE International Conference on Computing in Civil Engineering**. (pp. 553-560).
- Joubert, D., Tyatyantsi, A., Mphahlehle, J., and Manchidi, V. (2011). Pothole tagging system. In **Proceedings of the 4th Robotics and Mechatronics Conference of South Africa**. (pp. 1-4).
- Kadam, A. S., and Ghogare, A. H. (2017). Pothole Detection and Notification Using Smartphone for Self-driving Vehicles, Drivers and Road Authorities. In **International Journal of Advanced Research in Computer and Communication Engineering**. 6 (10): 313-317.
- Kawano, M., Yonezawa, T. and Nakazawa, J. (2017). Deep on Edge: Opportunistic Road Damage Detection with Official City Vehicles. In **The Third International Conference on Smart Portable, Wearable, Implantable and Disability-oriented Devices and Systems (SPWID 2017)** (pp. 5 – 10).
- Kim, T., and Ryu, S. K. (2014). Review and analysis of pothole detection methods. **Journal of Emerging Trends in Computing and Information Sciences**. 5 (8): 603-608.
- Koch, C., and Brilakis, I. (2011). Pothole detection in asphalt pavement images. **Advanced Engineering Informatics**. 25 (3): 507-515.
- Koch, C., Georgieva, K., Kasireddy, V., Akinci, B., and Fieguth, P. (2015). A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure. **Advanced Engineering Informatics**, 29 (2), 196-210.

- Koh, J. J., Yap, T. T. V., Ng, H., Goh, V. T., Tong, H. L., Ho, C. C., and Kuek, T. Y. (2019). Autonomous Road Potholes Detection on Video. In **Computational Science and Technology** (pp. 137-143).
- Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In **Advances in neural information processing systems** (pp. 1097-1105).
- Kulkarni, A., Mhalgi, N., Sagar Gurnani, D., and Giri, N. (2014). Pothole detection system using machine learning on android. **International Journal of Emerging Technology and Advanced Engineering**. 4(7): 360-364.
- Li, Q., Yao, M., Yao, X., and Xu, B. (2009). A real-time 3D scanning system for pavement distortion inspection. **Measurement Science and Technology**. 21(1): 015702.
- Lin, J., and Liu, Y. (2010). Potholes detection based on SVM in the pavement distress image. In **Distributed Computing and Applications to Business Engineering and Science (DCABES)** (pp. 544-547).
- Lin, T. Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017a). Focal loss for dense object detection. In **Proceedings of the IEEE international conference on computer vision** (pp. 2980-2988).
- Lin, T. Y., Dollár, P., Girshick, R., He, K., Hariharan, B., and Belongie, S. (2017b). Feature pyramid networks for object detection. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 2117-2125).
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., and Pietikäinen, M. (2018). Deep learning for generic object detection: A survey. arXiv preprint arXiv:1809.02165.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., and Berg, A. C. (2016). Ssd: Single shot multibox detector. In **European conference on computer vision** (pp. 21-37).
- Madli, R., Hebbar, S., Pattar, P., and Golla, V. (2015). Automatic detection and notification of potholes and humps on roads to aid drivers. **IEEE Sensors Journal**, 15 (8): 4313-4318.
- Maeda, H., Sekimoto, Y., and Seto, T. (2016a). An Easy Infrastructure Management Method Using On-Board Smartphone Images and Citizen Reports by Deep Neural Network. In **Proceedings of the Second International Conference on IoT in Urban Space** (pp. 111-113). ACM.

- Maeda, H., Sekimoto, Y., and Seto, T. (2016b). Lightweight road manager: smartphone-based automatic determination of road damage status by deep neural network. In **Proceedings of the 5th ACM SIGSPATIAL International Workshop on Mobile Geographic Information Systems** (pp. 37-45). ACM.
- Maeda, H., Sekimoto, Y., Seto, T., Kashiyama, T., and Omata, H. (2018). Road damage detection using deep neural networks with images captured through a smartphone. arXiv preprint arXiv:1801.09454.
- Mathavan, S., Kamal, K., and Rahman, M. (2015). A review of three-dimensional imaging technologies for pavement distress detection and measurements. In **IEEE Transactions on Intelligent Transportation Systems**. 16 (5), 2353-2362.
- Mednis, A., Strazdins, G., Liepins, M., Gordjusins, A., and Selavo, L. (2010). RoadMic: Road surface monitoring using vehicular sensor networks with microphones. **Communications in Computer and Information Science**. 88: 417-429.
- Mednis, A., Strazdins, G., Zviedris, R., Kanonirs, G., and Selavo, L. (2011). Real time pothole detection using android smartphones with accelerometers. In **2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS)**.
- Moazzam, I., Kamal, K., Mathavan, S., Usman, S., and Rahman, M. (2013). Metrology and visualization of potholes using the microsoft kinect sensor. In **16th International IEEE Conference on Intelligent Transportation Systems (ITSC 2013)** (pp. 1284-1291).
- Mohan, P., Padmanabhan, V.N., and Ramjee, R. (2008) Nericell: rich monitoring of road and traffic conditions using mobile smartphones. In **Proceedings of the 6th ACM Conference on Embedded Network Sensor Systems** (pp. 323-336). ACM.
- Mohri, M., Rostamizadeh, A., and Talwalkar, A. (2012). **Foundations of machine learning**. MIT press.
- Musulin, I., Brcic, D., and Kos, S. (2014). A study of smartphone satellite positioning performance at sea using GPS and GLONASS systems. In **ISEP 2014: ITS for Seamless and Energy Smart Transport**. (pp. 1-7).
- Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., and Ng, A. Y. (2011). Multimodal deep learning. In Proceedings of the 28th international conference on machine learning (ICML-11) (pp. 689-696).

- Nienaber, S., Booyesen, M. J., and Kroon, R. S. (2015). Detecting potholes using simple image processing techniques and real-world footage. In **34th Annual Southern African Transport Conference SATC 2015** (pp. 1- 10).
- Orhan, F. (2013). **A multimodal sensor analysis framework for vehicular mobile applications**. M.S. Thesis, Middle East Technical University.
- Orhan, F., and Eren, P. E. (2013a). A multi-modal sensor analysis framework for in-car mobile applications. In **Signal Processing and Communications Applications Conference (SIU)** (pp. 1-4). IEEE.
- Orhan, F., and Eren, P. E. (2013b). Road hazard detection and sharing with multimodal sensor analysis on smartphones. In **Next Generation Mobile Apps, Services and Technologies (NGMAST), 2013 Seventh International Conference** (pp. 56-61). IEEE.
- Perttunen, M., Mazhelis, O., Cong, F., Kauppila, M., Leppänen, T., Kantola, J., Collin J., Pirttikangas, S., Haverinen, J., and Ristaniemi, T. (2011) Distributed road surface condition monitoring using mobile phones. **Ubiquitous Intelligence and Computing**. (pp 64–78).
- Predic, B., and Stojanovic, D. (2015). Enhancing driver situational awareness through crowd intelligence. **Expert Systems with Applications**. 42 (11): 4892-4909.
- Pkulzc, (2019). **TensorFlow detection model zoo**, [On-line]. Available: [https://github.com/tensorflow/models/blob/master/research/object\\_detection/g3doc/detection\\_model\\_zoo.md](https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/detection_model_zoo.md), accessed on: 18 March 2019.
- Radopoulou, S. C., and Brilakis, I. (2015). Patch detection for pavement assessment. **Automation in Construction**. 53: 95-104.
- Rajamohan, D., Gannu, B., and Rajan, K. S. (2015). MAARGHA: a prototype system for road condition and surface type estimation by fusing multi-sensor data. **ISPRS International Journal of Geo-Information**. 4 (3), 1225-1245.
- Rayen, S. J. (2016). Implementation of monitoring the detection and modification of potholes and humps on roads. **International Journal for Technological Research in Engineering**. 4 (3): 548-550.
- Ren, S., He, K., Girshick, R., and Sun, J. (2017). Faster R-CNN: Towards real-time object detection with region proposal networks, **IEEE transactions on pattern analysis and machine intelligence**. 39 (6): 1137-1149.



- Ryu, S. K., Kim, T., and Kim, Y. R. (2015). Image-based pothole detection system for ITS service and road management system. **Mathematical Problems in Engineering**, 2015: 1 - 11.
- Salari, E., Chou, E., and Lynch, J. J. (2012). Pavement distress evaluation using 3d depth information from stereo vision. Michigan Ohio University Transportation Center. Accessed July. 27, 2018.
- Schwab, K., Sala-i-Martin, X. (2017) **The global competitiveness report 2017–2018**. The world economic forum, Geneva Switzerland. [Online]. Available: <http://www3.weforum.org/docs/GCR2017-2018/05FullReport/TheGlobalCompetitivenessReport2017%E2%80%932018.pdf>
- Seraj, F., Zhang, K., Turkes, O., Meratnia, N. and Havinga, P. J. (2015). A smartphone based method to enhance road pavement anomaly detection by analyzing the driver behavior. In **Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers** (pp. 1169-1177).
- Sharma, R., Singh, K., and Chand, L. (2016). Analysis of image processing techniques for road Anomalies Detection. **International Journal of Emerging Research in Management and Technology**. 5 (1): 56-60.
- Shelly, G. B., Cashman, T. J., and Rosenblatt, H. J. (2008). **Systems analysis and design**. 7th Ed. Boston, MA: Course Technology.
- Singh, J., and Shekhar, S. (2018). Road Damage Detection and Classification In Smartphone Captured Images Using Mask R-CNN. arXiv preprint arXiv:1811.04535.
- Someswar, G. M., Rao, T. S. C., and Chigurukota, D. R. (2013). Global navigation satellite systems and their applications. **International Journal of Software and Web Sciences**. 3 (1): 17-23.3
- Sun, X., Huang, J., Liu, W., and Xu, M. (2012). Pavement crack characteristic detection based on sparse representation. **EURASIP Journal on Advances in Signal Processing**. 2012 (1): 1-11.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 1-9).
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 2818-2826).
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. A. (2017). Inception-v4, inception-resnet and the impact of residual connections on learning. In **Thirty-First AAAI Conference on Artificial Intelligence**.
- Tai, Y., Chan, C., and Hsu, J. Y. (2010). Automatic road anomaly detection using smart mobile Device. In **2010 Conference on Technologies and Applications of Artificial Intelligence**, Hsinchu, Taiwan (pp. 18-20).
- Tedeschi, A., and Benedetto, F. (2017). A real-time automatic pavement crack and pothole recognition system for mobile Android-based devices. **Advanced Engineering Informatics**. 32, 11-25.
- Thekkethala, M. V., Reshma, S., Varughese, S. J., Mohan, V., and Titus, G. (2016). Pothole detection and volume estimation using stereoscopic cameras. In **Proceedings of 38th IRF International Conference** (pp. 59-62).
- Torrey, L., and Shavlik, J. (2010). Transfer learning. In **Handbook of research on machine learning applications and trends: algorithms, methods, and techniques** (pp. 242-264). IGI Global.
- Tushar D. Patil, and Archana B. Kanwade. (2017). Detection and Notification of Potholes and Humps by Using Ultrasonic Sensor and Automation of Vehicles. **International Journal of Innovative Research in Computer and Communication Engineering**. 5 (5): 10324 – 10328.
- Tzutalin. (2019). **Labelimg**. [On-line]. Available: <https://github.com/tzutalin/labelImg>, accessed on: 7 Apr 2019.
- Wang, H. W., Chen, C. H., Cheng, D. Y., Lin, C. H., and Lo, C. C. (2015). A real-time pothole detection approach for intelligent transportation system. **Mathematical Problems in Engineering**. 2015: 1-8.

- Witten, I. H., Frank, E., and Hall, M. A. (2011). **Data Mining: Practical machine learning tools and techniques**. Morgan Kaufmann.
- World Road Association. (2014). **The Importance of Road Maintenance**. [On-line]. Available: <http://www.piarc.org/en/order-library/22252-en-The%20importance%20of%20road%20maintenance.html>
- Yamane, T., and Yamane, T. (1973). **Statistics; an introductory analysis** (No. 04; HA29, Y3 1973).
- Yu, B. X., and Yu, X. (2006). Vibration-based system for pavement condition evaluation. In **Applications of Advanced Technology in Transportation. The Ninth International Conference**. 183–189.
- Yu, Y., Li, J., Guan, H., and Wang, C. (2014). 3D crack skeleton extraction from mobile LiDAR point clouds. In **2014 IEEE Geoscience and Remote Sensing Symposium**. 914-917.
- Zhang, L., Yang, F., Zhang, Y. D., and Zhu, Y. J. (2016). Road crack detection using deep convolutional neural network. In **Image Processing (ICIP), 2016 IEEE International Conference** (pp. 3708-3712). IEEE.
- Zhang, Y., Mcdaniel, J. G., and Wang, M. L. (2013). Estimation of pavement macrotexture by principal component analysis of acoustic measurements. **Journal of Transportation Engineering**. 140 (1): 1–12.
- Zoph, B., Vasudevan, V., Shlens, J., and Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. In **Proceedings of the IEEE conference on computer vision and pattern recognition** (pp. 8697-8710).

## ภาคผนวก ก

### ผลงานวิจัยที่ได้รับการตีพิมพ์เผยแพร่

Posawang, P., Phosaard, S., Niwattanakul, S. and Pattara-atikom, W. (2018). Classification of Road Surface Anomalies Using Ensemble Methods with Deep Convolutional Neural Network. In The 16th ITS Asia-Pacific Forum FUKUOKA 2018. pp. 824–836.

ปิติภูมิ โพสาวัง สถิตย์โชค โพธิ์สอาด สุภกฤษฎี นีวัฒนากุล และ วสันต์ ภัทรอริคม. (2564). การตรวจจับสภาพพื้นผิวถนนที่ผิดปกติโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกด้วยเทคนิคการถ่ายโอนการเรียนรู้. วารสารเทคโนโลยีสารสนเทศ. 17 (1).



## ภาคผนวก ข

### ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ

ตารางที่ ข.1 ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ





ตารางที่ ข.1 ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)



ตารางที่ ข.1 ตัวอย่างชุดข้อมูลรูปภาพสำหรับตรวจจับสภาพพื้นผิวถนนที่ผิดปกติ (ต่อ)


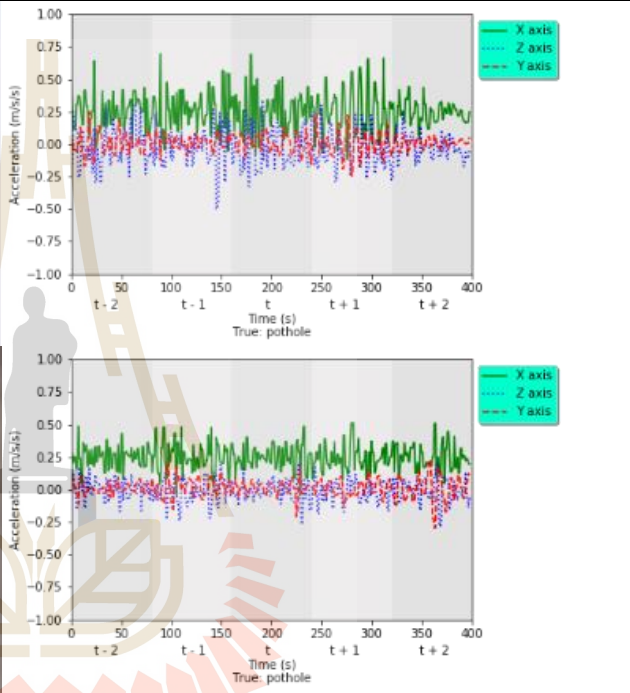

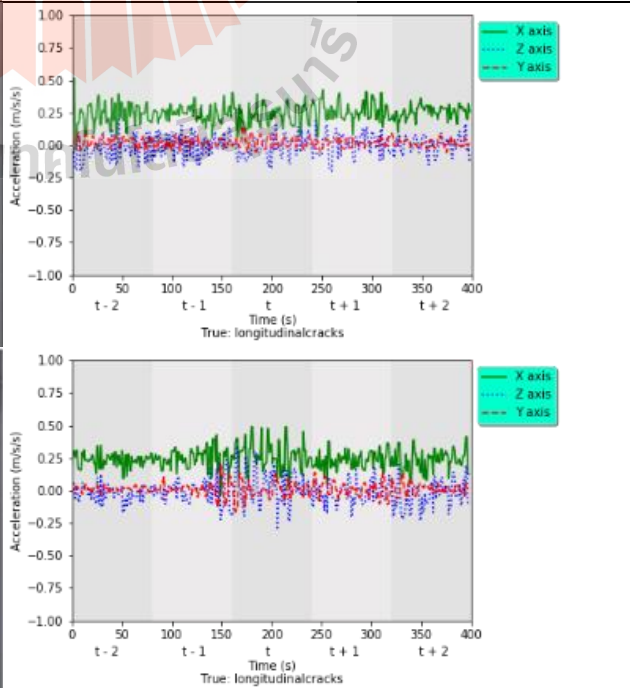




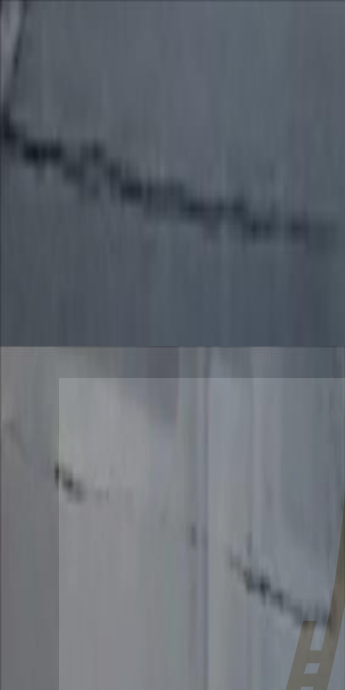
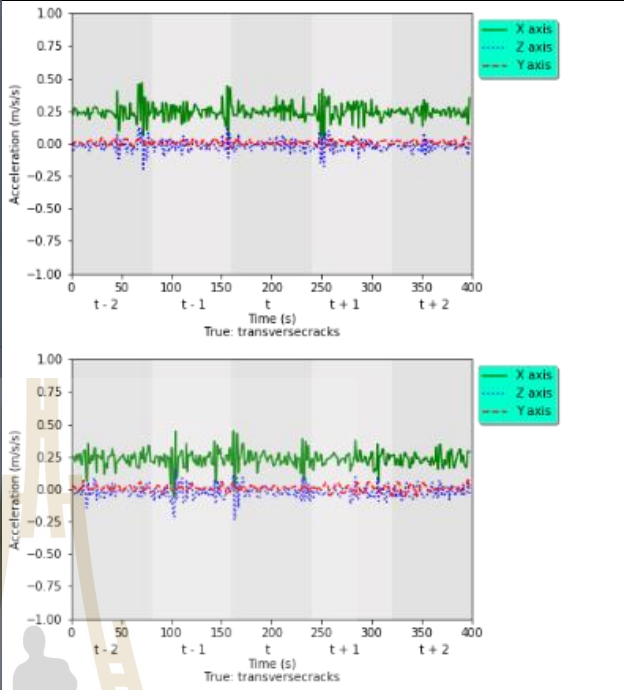

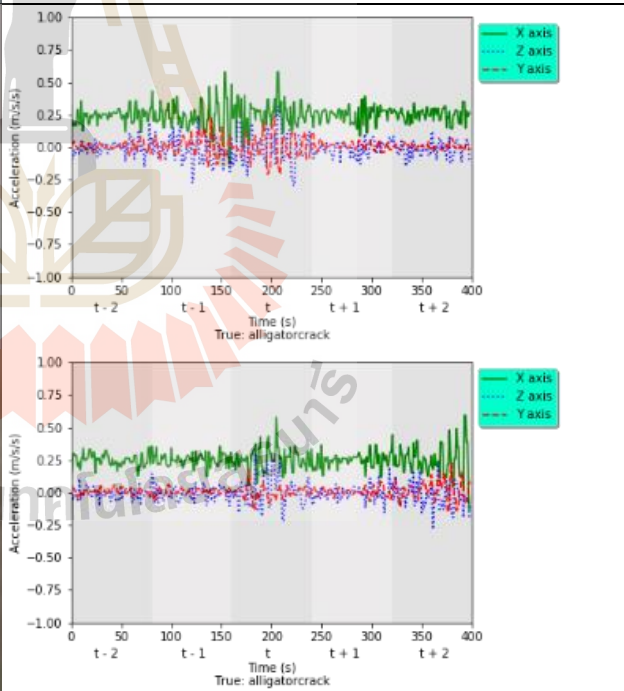
## ภาคผนวก ค

### ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน สำหรับจำแนกสภาพพื้นผิวถนนผิดปกติ


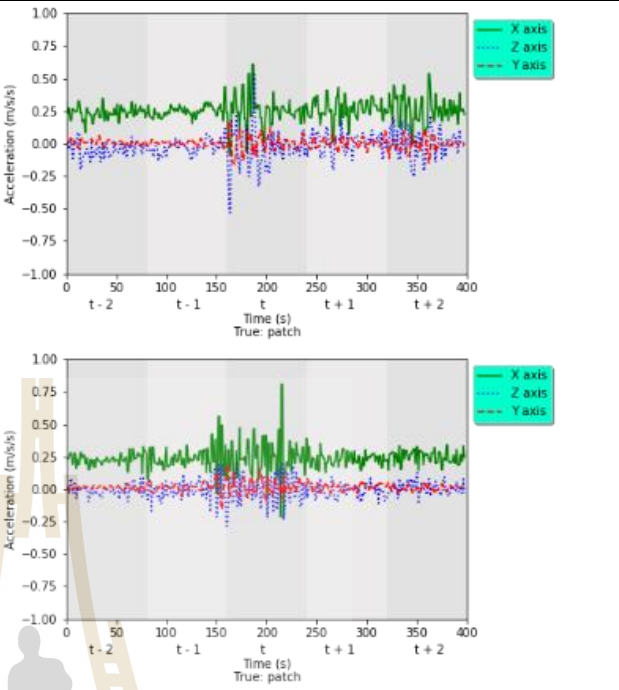

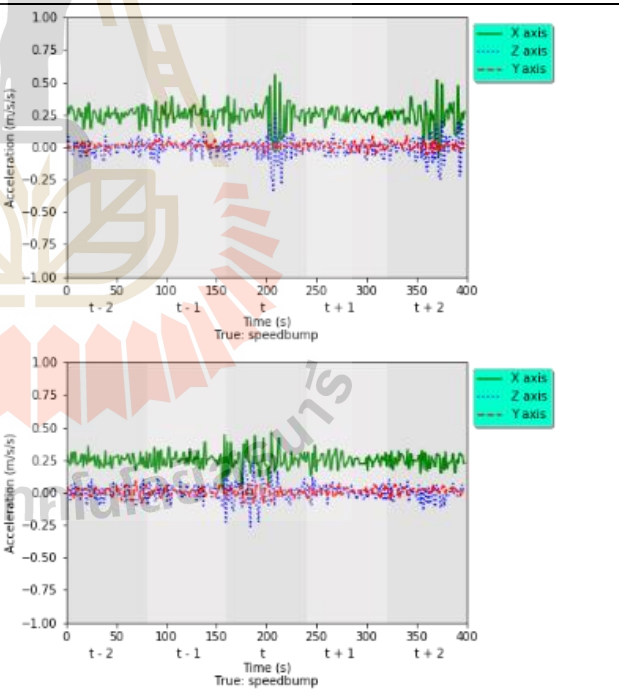
ตารางที่ ค.1 ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน

1. หลุมบ่อ		
2. รอยแตกตามแนวยาว		

ตารางที่ ค.1 ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน (ต่อ)


<p>3. รอยแตกตามแนวขวาง</p>		
<p>4. รอยแตกทรงรังไข่</p>		

ตารางที่ ค.1 ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน (ต่อ)

<p>5. รอยปะซ่อม</p>		
<p>6. เนินชะลอความเร็ว/เส้นชะลอความเร็ว</p>		



ตารางที่ ค.1 ตัวอย่างชุดข้อมูลรูปภาพและข้อมูลค่าอัตราเร่งของแรงสั่นสะเทือน (ต่อ)



## ประวัติผู้เขียน

นายปิฎกภูมิ โปสาวัง เกิดเมื่อวันที่ 21 กันยายน พ.ศ. 2522 สำเร็จการศึกษาระดับปริญญาตรี สาขาวิชาวิทยาการคอมพิวเตอร์ มหาวิทยาลัยราชภัฏนครราชสีมา ต่อมาในปี พ.ศ. 2550 เข้าศึกษาต่อระดับบัณฑิตศึกษา ในสาขาวิชาเทคโนโลยีสารสนเทศ สำนักวิชาเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีสุรนารี มีความสนใจในการประยุกต์ใช้เทคโนโลยีสารสนเทศในการพัฒนาระบบรายงานระดับความตึงเครียดของจราจรทางบกโดยใช้โครงข่ายประสาทเทียม โดยได้รับทุนสนับสนุนการวิจัยจากหน่วยปฏิบัติการวิจัยเทคโนโลยีเครือข่าย ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ และสำเร็จการศึกษาในระดับมหาบัณฑิตในปี พ.ศ. 2551 หลังจากนั้นในปี พ.ศ. 2558 เข้าศึกษาต่อในระดับปริญญาเอก ในสาขาวิชาเทคโนโลยีสารสนเทศ สำนักวิชาเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีสุรนารี เพื่อพัฒนาความรู้ ความสามารถและความเชี่ยวชาญในการวิจัยเกี่ยวกับการออกแบบและพัฒนาขั้นตอนวิธีตรวจจับสภาพพื้นผิวถนนที่ผิดปกติด้วยเครื่องรับรู้หลายรูปแบบ โดยได้รับทุนสนับสนุนผู้มีผลการเรียนดีเด่นที่เข้าศึกษาระดับบัณฑิตศึกษา สาขาวิชาเทคโนโลยีสารสนเทศ สำนักวิชาเทคโนโลยีสังคม มหาวิทยาลัยเทคโนโลยีสุรนารีและทุนสนับสนุนในการวิจัยด้านการรู้จำภาพ การตรวจจับและจำแนกวัตถุในภาพโดยใช้วิธีการเรียนรู้เชิงลึกหลายรูปแบบจากห้องปฏิบัติการวิจัยระบบขนส่งและจราจรอัจฉริยะ ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ

มหาวิทยาลัยเทคโนโลยีสุรนารี