

การพัฒนาแบบจำลองการเรียนรู้เชิงลึกเพื่อประเมินสภาพผิวถนนด้วยข้อมูลจากอุปกรณ์ตรวจวัดความเร่งและวิดีโอ

Integration of accelerometer and video data for road surface condition evaluation using deep learning models

ผู้แต่ง¹ สโรช บุญศิริพันธ์¹ และ ผู้แต่ง² ศุภกฤต ธนสมบัติสกุล^{2,*}

^{1,2} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ บางเขน มหาวิทยาลัยเกษตรศาสตร์ จ.กรุงเทพฯ

*Corresponding author; E-mail address: supakrit.than@ku.th

บทคัดย่อ

ค่าดัชนีความขรุขระสากล (International Roughness Index ,IRI) เป็นดัชนีที่มีความสำคัญต่อการประเมินสภาพผิวถนนและการวางแผนซ่อมบำรุงถนน โดยทั่วไปแล้ว IRI จะวัดโดยใช้อุปกรณ์ Laser Profiler , Laser Crack Measurement System และ Walking Profiler ซึ่งต้องมีผู้เชี่ยวชาญในการควบคุมและประเมินผล อีกทั้งอุปกรณ์เหล่านี้ยังมีต้นทุนราคาที่สูง ทำให้ไม่สามารถจัดซื้อได้ในจำนวนมาก จึงส่งผลกระทบต่อความถี่ในการเก็บรวบรวมข้อมูล การศึกษานี้นำเสนอวิธีการใหม่ในการประเมินค่า IRI โดยใช้ข้อมูลที่ได้รวบรวมผ่านกล้องบันทึกภาพ GoPro ซึ่งประกอบด้วยข้อมูลความเร่ง (Acceleration) และภาพถ่ายของพื้นผิวถนน โดยภาพถ่ายที่ได้จะถูกประมวลผลผ่านกระบวนการตรวจจับวัตถุ (Object Detection) เพื่อระบุประเภทความเสียหายของถนนและบ่งบอกสถานะความเสียหายของผิวทาง (Road Distress) จากนั้นจึงนำข้อมูลความเสียหายผิวทางที่ได้มารวมเข้ากับข้อมูล Acceleration แล้วจึงประมวลผลผ่านแบบจำลองถดถอย (Regression Models) เพื่อคาดการณ์ค่า IRI และทำการเปรียบเทียบกับข้อมูลที่เก็บได้จากรถสำรวจวิธีการที่นำเสนอแสดงให้เห็นถึงความเป็นไปได้ในการใช้เครื่องมือที่มีต้นทุนต่ำ เพิ่มความถี่ในการเก็บข้อมูลและคำนวณค่า IRI อย่างแม่นยำ โดยงานวิจัยนี้คาดหวังว่าจะเป็นประโยชน์ต่อหน่วยงานหรือผู้พัฒนาที่ต้องการเก็บรวบรวมค่า IRI ที่มีข้อจำกัดด้านอุปกรณ์และงบประมาณ

คำสำคัญ: ค่าดัชนีความขรุขระสากล (International Roughness Index), ความเร่ง (Acceleration), แบบจำลองถดถอย (Regression Models), ความเสียหายผิวทาง (Road Distress) , กระบวนการตรวจจับวัตถุ (Object Detection)

Abstract

The International Roughness Index (IRI) is an important index for assessing road surface conditions and planning road maintenance. Typically, IRI is measured using equipment like Laser Profilers, Laser Crack Measurement Systems, and Walking Profilers, which require experts to control and evaluate the results. These devices also have high costs, limiting their availability and affecting the frequency of data collection. This study presents a new method for estimating IRI using data collected from a GoPro camera, which includes acceleration data and images of road surfaces. The images are processed through an object detection process to identify the type of road damage and indicate the road distress status. The road distress data is then combined with the acceleration data and processed through regression models to predict IRI values, which are compared with data collected from survey vehicles. The proposed method demonstrates the potential to use low-cost tools to increase data collection frequency and accurately calculate IRI. This research aims to be useful for agencies or developers who need to collect IRI values but face equipment and budget limitations.

Keywords: International Roughness Index (IRI), Acceleration, Regression Models, Road Distress, Object Detection

1. คำนำ

ถนนเป็นโครงสร้างพื้นฐานที่มีบทบาทสำคัญต่อการคมนาคมและกิจกรรมทางเศรษฐกิจ ความเสียหายบนผิวถนนจึงเป็นปัจจัยสำคัญที่ส่งผลกระทบต่อ การดำเนินชีวิตประจำวันในด้านความสะดวกสบายในการขับขี่และความปลอดภัยของผู้ใช้ถนน ดังนั้น การประเมินความเสียหายบนผิวถนนจึงเป็นกระบวนการสำคัญที่ช่วยให้สามารถคาดการณ์การเสื่อมสภาพและวางแผนซ่อมบำรุงได้อย่างมีประสิทธิภาพ โดย IRI เป็นค่ามาตรฐานสากลที่ได้รับการยอมรับสำหรับการประเมินสภาพถนน ในการเก็บข้อมูล IRI นั้นสามารถดำเนินการได้ด้วยอุปกรณ์หลากหลายชนิดเช่น Laser Profiler และ Laser Crack Measurement System [1] อย่างไรก็ตาม อุปกรณ์แบบดั้งเดิมมักมีราคาสูงและต้องการผู้เชี่ยวชาญในการดำเนินการ เพื่อลดข้อจำกัดดังกล่าว นักวิจัยได้พัฒนาแนวทางใหม่ที่สามารถลดต้นทุนและเพิ่มความสะดวกในการเก็บข้อมูล หนึ่งในวิธีที่ได้รับความนิยมคือการใช้อุปกรณ์เซ็นเซอร์ Accelerometer เพื่อบันทึกข้อมูลการสั่นสะเทือนขณะขับขี่ จากนั้นจึงนำข้อมูลมาวิเคราะห์เพื่อคำนวณค่า IRI การใช้อุปกรณ์เซ็นเซอร์ Accelerometer มีข้อดีหลายประการ เช่น ความสะดวกในการติดตั้ง ค่าใช้จ่ายต่ำ และความสามารถในการเก็บข้อมูลอย่างต่อเนื่อง [2] นอกจากการนำเอาข้อมูล Acceleration มาใช้แล้วการประมวลผลภาพ (Image Processing) เป็นอีกหนึ่งแนวทางที่ผู้เขียนให้ความสนใจ วิธีการนี้ใช้กล้องบันทึกภาพจากยานพาหนะเพื่อบันทึกสภาพผิวถนน จากนั้นจึงนำภาพที่ได้มาวิเคราะห์เพื่อระบุประเภทของความเสียหาย การผสมผสานข้อมูลจากเซ็นเซอร์ Acceleration และ Image Processing เพื่อเพิ่มความแม่นยำในการประเมินค่าและสามารถเปรียบเทียบผลลัพธ์กับมาตรฐานสากลได้อย่างมีประสิทธิภาพ

โดยวัตถุประสงค์งานวิจัยนี้มุ่งเน้นการพัฒนาวิธีการคำนวณ IRI โดยใช้เครื่องมือที่เข้าถึงได้ง่าย เน้นความคุ้มค่าและความแม่นยำ เพื่อช่วยให้นักวิจัยที่เกี่ยวข้องสามารถนำข้อมูลดังกล่าวในการวางแผนบำรุงรักษาถนนและปรับปรุงโครงสร้างพื้นฐานด้านคมนาคมได้อย่างมีประสิทธิภาพ

2. งานวิจัยที่เกี่ยวข้อง

ในการรวบรวมข้อมูลโดยใช้อุปกรณ์เซ็นเซอร์เพื่อวิเคราะห์และประเมินค่าดัชนีความขรุขระสากล จำเป็นต้องมีการศึกษาและเลือกใช้ข้อมูลที่เหมาะสม โดยพารามิเตอร์สำคัญที่ใช้ในการวิเคราะห์ ได้แก่ ข้อมูลความเร่งและข้อมูลรูปภาพสำหรับระบุประเภทความเสียหายบนพื้นผิวถนน

จากการทบทวนตรวจสอบเอกสารงานวิจัยที่ผ่านมาได้มีการสร้างแบบจำลองเพื่อประเมินค่า IRI โดยแบ่งออกตามชนิดข้อมูลที่ให้ได้หลายประเภท ได้แก่ แบบจำลองที่ใช้ข้อมูลความเร่ง แบบจำลองที่ใช้ข้อมูลความเร่งร่วมกับความเร็ว และแบบจำลองที่ใช้ข้อมูลประเภทความเสียหายบนผิวทาง

สำหรับการศึกษาแบบจำลองที่ใช้ข้อมูลความเร่ง ได้มีศึกษาพัฒนาวิธี Smartphone-based Roughness Estimation Methods (SRIE) โดยใช้

ข้อมูลจากสมาร์ตโฟนที่ติดตั้งในยานพาหนะจำนวน 4 คัน โดยข้อมูลความเร่งที่รวบรวมจะถูกนำไปวิเคราะห์โดยใช้เทคนิค Deep Learning ได้แก่ Convolutional Neural Networks (CNN) และ Long Short-Term Memory Networks (LSTM) โดยทำการเปรียบเทียบผลลัพธ์ที่ได้กับค่า IRI ที่เก็บรวบรวมมาจาก Laser Profiler ซึ่งผลลัพธ์แสดงความสัมพันธ์ระหว่างค่าคาดการณ์กับค่าจริงที่ $R^2 = 0.79$ บ่งบอกได้ถึงความสัมพันธ์ระหว่างค่าจริงและค่าทำนายที่ดีของแบบจำลอง [3] ในขณะเดียวกัน อีกการศึกษาเสนอวิธีการประเมินค่าดัชนีความขรุขระของผิวทาง โดยใช้ข้อมูลความเร่งด้วยวิธีการประมวลผลด้วย Fast Fourier Transform (FFT) เพื่อแยกความถี่การสั่นสะเทือนจากข้อมูลความเร่งที่รวบรวมจากเซ็นเซอร์บนสมาร์ตโฟนเป็นช่วงละ 100 เมตร จากนั้นนำค่าผลรวมขนาดของ FFT ไปเปรียบเทียบกับค่า IRI จาก Laser Profiler ผลลัพธ์พบว่าค่า IRI มีความสัมพันธ์เชิงเส้นกับผลรวมขนาดของ FFT โดยมีค่า $R^2 = 0.87$ ซึ่งชี้ให้เห็นว่าวิธีนี้สามารถใช้งานได้มีประสิทธิภาพ และได้มีการเสนอวิธีการ โดยการผสมผสานข้อมูลจากเครื่องวัดความเร่งในสมาร์ตโฟนเข้ากับแบบจำลองที่ใช้ Power Spectral Density (PSD) ข้อมูลที่รวบรวมได้จากสมาร์ตโฟนจะถูกแบ่งออกเป็นช่วง ๆ ละ 1 กิโลเมตร โดยการประมวลผลเบื้องต้นเกี่ยวข้องกับการปรับทิศทางแกนของเครื่องวัดความเร่ง (Axis Orientation) เพื่อให้ข้อมูลสะท้อนการสั่นสะเทือนอยู่ในแนวที่ถูกต้องและใช้อัลกอริทึม MATLAB เพื่อตรวจจับความผิดปกติของพื้นผิว และกรองผลกระทบของความผิดปกติดังกล่าวจากการวัดความหยาบ แบบจำลองนี้ได้รับการตรวจสอบความถูกต้องโดยใช้อุปกรณ์ Roughometer มาตรฐาน โดยค่าดัชนีความขรุขระ ที่ได้จากแบบจำลอง PSD มีค่า $R^2 = 0.86$ ซึ่งบ่งบอกถึงความแม่นยำที่ดีของแบบจำลอง [4]


นอกจากนี้ได้มีการพัฒนาแบบจำลองโมเดล IRI_Net สำหรับการตรวจสอบสภาพถนนแบบเรียลไทม์ ด้วยข้อมูลความเร่ง ความเร็วเชิงมุม ความเร็วยานพาหนะ และพิกัด GPS ที่เก็บจากสมาร์ตโฟนจำนวน 29 เครื่อง และทำการแบ่งข้อมูลออกเป็นช่วงละ 8.05 เมตร แต่เนื่องจากข้อมูลตำแหน่ง GPS ที่รวบรวมมีความไม่สอดคล้องกัน วิธีการเชิงเส้น (Linear Interpolation) จึงถูกนำมาใช้เพื่อปรับปรุงความแม่นยำของข้อมูล GPS ก่อนจะนำมาวิเคราะห์ด้วยเทคนิค Deep Learning ด้วยแบบจำลอง IRI_Net ซึ่งผลลัพธ์ที่ได้มีความสัมพันธ์ $R^2 = 0.79$ โดยบ่งชี้ว่า ความเร็วและความเร่งส่งผลต่อค่า IRI [5]

สำหรับแบบจำลองที่ใช้ข้อมูลประเภทความเสียหายของผิวทางได้พัฒนาแบบจำลองด้วยเครือข่ายประสาทเทียมแบบย้อนกลับ (Backpropagation Neural Network) เพื่อประเมินค่าดัชนีความขรุขระสากล โดยอ้างอิงจากประเภทความเสียหายของผิวทาง 14 ประเภท ดังรูปที่ 1 ที่เก็บรวบรวมด้วย Laser Profiler และกล้องวิดีโอคุณภาพสูงติดตั้งบน ARAN (Automatic Road Analyzer) การตรวจสอบประเภทความเสียหายจะดำเนินการโดยผู้เชี่ยวชาญในห้องปฏิบัติการข้อมูลโดยข้อมูลจะถูกแบ่งออกเป็นช่วง ๆ ความยาว 1 กิโลเมตร แบบจำลองนี้ใช้ Sigmoid Activation Function เพื่อปรับปรุงความแม่นยำในการคาดการณ์ โดยผลการวิเคราะห์พบว่า หลุมบ่อ (Potholes) และร่องล้อ (Rutting) มี

ผลกระทบสูงสุดต่อค่า IRI ดังรูปที่ 2 โดยค่าความสัมพันธ์ระหว่างค่า IRI ที่ทำนายได้กับค่าจริงเท่ากับ 0.94 ซึ่งบ่งบอกว่า ความเสียหายผิวทางส่งผลต่อค่า IRI [6]

Node	Input Variable
1	The road level
2	left rutting
3	right rutting
4	alligator cracking
5	cracking
6	digging/patching
7	mild potholes
8	severe potholes
9	patching
10	bleeding
11	corrugation
12	stripping
13	mild man-holes
14	severe man-holes

รูปที่ 1 หมวดหมู่ของตัวแปรอินพุตโครงข่ายประสาทเทียม



รูปที่ 2 น้ำหนักของตัวแปรอินพุต

ในส่วนของการจำแนกประเภทความเสียหายของพื้นผิวถนนจะใช้วิธี Convolutional Neural Networks (CNN) ซึ่งเป็นเครื่องมือสำคัญที่ช่วยให้การระบุความเสียหายทำได้อย่างรวดเร็วและแม่นยำ โดยแบบจำลองที่พัฒนาขึ้นอาศัยข้อมูลหลายประเภท เช่น วิดีโอจากสมาร์ตโฟน ภาพถนนสามมิติ (3D Pavement Images) และสัญญาณการสั่นสะเทือนที่เก็บรวบรวมจากสมาร์ตโฟน ในกรณีของแบบจำลองที่ใช้ข้อมูลวิดีโอ ได้มีการพัฒนาเทคนิค Deep Learning โดยผสานข้อมูลจากเซ็นเซอร์ Accelerometer และวิดีโอผ่าน CNN ข้อมูลวิดีโอที่บันทึกจากมุมมองกระจกหน้ารถถูกประมวลผลเพื่อดึงลักษณะเฉพาะของความเสียหายพื้นผิวถนน พร้อมลดผลกระทบจากพื้นที่ที่ไม่เกี่ยวข้อง นอกจากนี้ยังรวมข้อมูลจากภาพและการสั่นสะเทือนผ่านการเข้ารหัสเป็นเวกเตอร์ค่าจริง (Real-Valued Vectors) ก่อนนำไปผ่านโมเดล Long Short-Term Memory Networks (LSTM) เพื่อวิเคราะห์ข้อมูลเชิงเวลา [7] ในทำนองเดียวกัน ได้พัฒนาแบบจำลองที่ใช้ภาพถ่ายถนนร่วมกับโมเดล CNN EfficientNet-B0 ซึ่งมีจุดเด่นที่ความสมดุลระหว่างประสิทธิภาพและความต้องการในการคำนวณ การเพิ่มชุดข้อมูล RSCD ให้ครอบคลุมมากขึ้นทำให้สามารถปรับตัวกับการเปลี่ยนแปลงแสงเงา และวัสดุพื้นถนนได้


นอกจากนี้ยังใช้เทคนิค Fusion แบบ Decision-Level เพื่อลดความผิดพลาดทำให้ได้ผลลัพธ์ที่เชื่อถือได้และเหมาะสมสำหรับการใช้งานจริงสำหรับแบบจำลองที่ใช้ข้อมูลภาพถนนสามมิติ [8]

นอกจากนี้ได้มีการศึกษาเสนอโมเดล CNN สำหรับตรวจวัดความเรียบของพื้นถนนผ่านภาพสามมิติ โดยสามารถจัดประเภทพื้นผิวถนนออกเป็น 4 ระดับ ได้แก่ ดีมาก, ดี, พอใช้, และแย่ นอกจากนี้ยังสามารถประมาณค่า International Roughness Index ได้อย่างแม่นยำ ผลวิจัยชี้ว่า CNN มีประสิทธิภาพดีกว่า ANN และ MNL [9] ในอีกแง่มุมหนึ่งได้มีงานวิจัยที่ใช้ 3D Point Clouds ร่วมกับโมเดล DeepLabv3+ ในการจำแนกหลุมบ่อ โดยสามารถระบุพิกัดและขอบเขตหลุมบ่อได้อย่างชัดเจน พร้อมทั้งคำนวณความลึกเฉลี่ยของหลุมบ่อเพื่อช่วยประเมินระดับความเสียหาย สำหรับแบบจำลองที่ใช้สัญญาณการสั่นสะเทือน [10] ในทางกลับกันอีกการศึกษาได้นำเสนอการวิเคราะห์ข้อมูลในโดเมนเวลา-ความถี่ (Time-Frequency Domain) ด้วยการใช้เทคนิค Short-Time Fourier Transform (STFT) และ Wavelet Transform (WT) เพื่อนำสัญญาณสั่นสะเทือนมาแปลงเป็นภาพพลังงานก่อนป้อนเข้าสู่ CNN แบบจำลอง WT-CNN และ STFT-CNN สามารถตรวจจบบรอยร้าวขวางบนถนนได้อย่างมีประสิทธิภาพสูง รองรับการใช้งานในสภาพแวดล้อมจริง และทำงานได้เกือบเรียลไทม์ [11]

จากการทบทวนวรรณกรรมพบว่ามีการใช้ข้อมูล Acceleration และ Road Distress ในการวิเคราะห์ความสัมพันธ์กับค่าดัชนีความขรุขระสากล อย่างไรก็ตาม งานวิจัยส่วนใหญ่มักใช้เพียงปัจจัยใดปัจจัยหนึ่งในการสร้างแบบจำลอง โดยยังไม่มีมีการนำทั้งสองปัจจัยมาวิเคราะห์ร่วมกัน การศึกษาครั้งนี้เสนอแนวทางโดยใช้เทคนิค Object Detection ในการระบุประเภทความเสียหายของถนน และนำข้อมูลดังกล่าวมารวมกับ Acceleration เพื่อใช้เป็นตัวแปรอิสระในแบบจำลองถดถอยสำหรับการคำนวณค่า IRI

3. วิธีการดำเนินงานวิจัย

การศึกษานี้มุ่งเน้นพัฒนาแบบจำลองที่สามารถประเมินค่า IRI ได้อย่างมีประสิทธิภาพ โดยใช้ข้อมูลสำคัญ ได้แก่ ผลรวมค่าความเร่ง และสถานะความเสียหายผิวทาง ที่สามารถระบุได้จาก Object Detection เป็นข้อมูลนำเข้า (Input) ขณะที่ค่าดัชนีความขรุขระของผิวทาง จะถูกใช้เป็นข้อมูลผลลัพธ์ (Output) ของแบบจำลอง โดยกรอบงานวิจัยแบ่งเป็น 3 ส่วนหลัก ได้แก่ การเก็บรวบรวมข้อมูล (Data Collection), การจัดเตรียมข้อมูล (Preprocessing) และ การพัฒนาแบบจำลอง (Model Development) ดังรูปที่ 3



รูปที่ 3 กรอบงานวิจัย

3.1.1 พื้นที่การศึกษา

การศึกษานี้มุ่งเน้นถนนสายหลักในความรับผิดชอบของกรมทางหลวง โดยการทดลองเกิดขึ้นบนทางหลวงหมายเลข 204 ความยาว 18.85 กิโลเมตร เทศบาลนครนครราชสีมา ตำบลในเมือง อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา ประเทศไทย ทิศทางมุ่งหน้าสู่จังหวัดขอนแก่น บนถนนมีรูปภาพดังรูปที่ 4



รูปที่ 4 พื้นที่การศึกษา

โดยสาเหตุที่เลือกทางหลวงหมายเลข 204 เนื่องจากเป็นถนนสายหลักเส้นทางสำคัญที่รองรับปริมาณการจราจรหนาแน่น และการขนส่งสินค้า รวมถึงการเดินทางของประชาชน ส่งผลให้เกิดความเสียหายของผิวทางที่หลากหลาย เช่น หลุมบ่อ รอยซ่อมชำรุด และรอยแตก ซึ่งเกิดจากการใช้งานหนัก และปัจจัยสิ่งแวดล้อม การเลือกศึกษาถนนสายหลักช่วยให้ครอบคลุมลักษณะความเสียหายที่หลากหลาย สามารถนำไปพัฒนาแบบจำลองหรือวิธีการวิเคราะห์ที่ปรับใช้กับถนนประเภทอื่น นอกจากนี้ กรมทางหลวงมีบทบาทหลักในการบริหารจัดการถนนสายหลักทั่วประเทศ การศึกษาถนนในความรับผิดชอบของกรมทางหลวงจะช่วยให้การเก็บข้อมูล การวิเคราะห์ และการนำผลการศึกษาไปใช้จริงสอดคล้องกับมาตรฐาน และนโยบายด้านการดูแล และซ่อมบำรุงถนนได้อย่างมีประสิทธิภาพ

3.1.2 อุปกรณ์และวิธีการเก็บข้อมูล

ในงานวิจัยนี้ ผู้เขียนได้ดำเนินการเก็บรวบรวมข้อมูล IRI โดยใช้รถสำรวจดังรูปที่ 5 ซึ่งข้อมูลที่สามารถเก็บได้จากรถสำรวจนั้นจะประกอบไปด้วยข้อมูลดังตารางที่ 1 และการศึกษาได้ทำการติดตั้งอุปกรณ์ กล้องบันทึกภาพรุ่น GoPro Hero 10 Black ดังรูปที่ 6 บนรถสำรวจ ซึ่งข้อมูลที่เก็บรวบรวมได้ประกอบด้วยข้อมูลดังตารางที่ 2 โดยข้อมูลทั้งหมดถูกจัดเก็บในรูปแบบต่อเนื่องตามค่า Framerate ที่กำหนด เพื่อให้ได้ข้อมูลที่มีความละเอียดและความถูกต้องสูงสุด



รูปที่ 5 รถสำรวจเก็บข้อมูล IRI



รูปที่ 6 กล้องบันทึกภาพ รุ่น GoPro Hero 10 Black

ตารางที่ 1 รายละเอียดข้อมูลรถสำรวจ

ข้อมูล	รายละเอียดข้อมูล
กม.	ระยะทางที่รถสำรวจทำการเก็บข้อมูลในหน่วยกิโลเมตร
ค่าดัชนีความขรุขระ (ม./กม.)	ดัชนีความขรุขระระหว่างทางในหน่วยเมตรต่อกิโลเมตร
Lat	ค่าพิกัดละติจูด
Long	ค่าพิกัดลองจิจูด

ตารางที่ 2 รายละเอียดข้อมูลกล้องบันทึกภาพ

ข้อมูล	รายละเอียดข้อมูล
date	วันที่ และเวลาที่ข้อมูลถูกบันทึก
GPS (Lat.) [deg]	ค่าพิกัดละติจูดในหน่วยองศา
GPS (Long.) [deg]	ค่าพิกัดลองจิจูดในหน่วยองศา
Accelerometer [m/s ²]	ค่าความเร่งในหน่วยเมตรต่อวินาทียกกำลังสอง
Image	รูปภาพ

3.2 การประมวลผลข้อมูลเบื้องต้น (Preprocessing)

ในส่วนนี้การประมวลผลข้อมูลจะถูกแบ่งออกเป็นสองส่วนหลัก โดยเริ่มจากการเตรียมข้อมูลสำหรับแบบจำลองที่ใช้ในการระบุประเภทความเสียหาย ในขั้นตอนนี้จะใช้การทำ Image Annotation เพื่อทำการระบุและกำหนดประเภทของความเสียหายที่เกิดขึ้นบนถนนจากภาพถ่าย หลังจากนั้นจะเข้าสู่ขั้นตอนการเตรียมข้อมูลสำหรับแบบจำลองที่ใช้ในการประมาณค่า IRI ซึ่งมีขั้นตอนการทำ Data Correlation เพื่อวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลกับค่า IRI การทำ Data Normalization เพื่อนำข้อมูลที่ได้มาปรับสเกลให้อยู่ในช่วงที่เหมาะสม และสุดท้ายคือ Data Matching ที่ทำการจับคู่ข้อมูลระหว่างตัวแปร โดยขั้นตอนทั้งหมดนี้จะช่วยให้การสร้างแบบจำลองที่สามารถทำนายค่า IRI ได้มีความแม่นยำมากยิ่งขึ้น

3.2.1 Image Annotation

ในการวิจัยนี้ ข้อมูลที่ได้จากการบันทึกวิดีโอด้วยกล้องบันทึกภาพจะถูกแปลงเป็นภาพนิ่งที่อัตรา 30 เฟรมต่อวินาที (30 Hz) เพื่อให้สามารถใช้งานกับโมเดลได้อย่างสะดวกยิ่งขึ้น ก่อนที่ภาพเหล่านี้จะนำไปใช้ในการฝึกสอนโมเดลตรวจจับวัตถุ จำเป็นต้องมีการทำ Image Annotation หรือการให้คำอธิบายประกอบพร้อมระบุพิกัดของวัตถุในภาพ ซึ่งจะช่วยให้โมเดลสามารถเรียนรู้ลักษณะของวัตถุได้อย่างถูกต้อง ในขั้นตอนการทำ Image Annotation นี้ จะใช้เครื่องมือ Roboflow ซึ่งเป็นแพลตฟอร์มที่ช่วยในการทำ Annotation ได้อย่างมีประสิทธิภาพ โดยผู้เขียนจะทำการระบุและทำเครื่องหมาย (Label) พื้นที่ที่มีความเสียหายบนถนน เช่น รอยปะซ่อม, หลุมบ่อ และรอยแตก ภายในภาพแต่ละภาพที่ได้จากวิดีโอที่บันทึกจากกล้อง GoPro จากนั้นจะระบุประเภทของความเสียหายที่พบ โดยข้อมูลที่ได้จากการทำ Image Annotation จะถูกนำไปใช้ในการฝึกสอนโมเดลตรวจจับวัตถุ (Object Detection) เพื่อให้โมเดลสามารถเรียนรู้และแยกแยะประเภทความเสียหายบนถนนได้อย่างแม่นยำยิ่งขึ้น ข้อมูลที่รวบรวมได้ประกอบด้วยภาพถ่ายทั้งหมด 4,000 รูป ซึ่งจะช่วยให้โมเดลสามารถตรวจจับและจำแนกพื้นผิวถนนได้อย่างมีประสิทธิภาพ

3.2.2 Data Correlation

จากข้อมูลที่รวบรวมมานั้นได้ทำการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลความเร่งที่ได้จากกล้องบันทึกภาพและค่าความขรุขระของถนนที่เก็บรวบรวมได้จากรถสำรวจ โดยในการศึกษานี้ได้พิจารณาตัวแปรความเร่งออกเป็น 3 รูปแบบ ได้แก่ ผลรวมของค่าความเร่ง (Acc_SUM), ค่าเฉลี่ยความเร่ง (Acc_AVG) และค่าผลต่างระหว่างค่าความเร่งสูงสุดและต่ำสุด (Acc_MAX - MIN) การวัดหาความสัมพันธ์ในครั้งนี้ได้ใช้ค่าความสัมพันธ์เชิงเส้นหรือค่า R^2 (Coefficient of Determination) เป็นตัวชี้วัดหลัก โดยค่า R^2 จะช่วยบ่งชี้ระดับความสัมพันธ์ระหว่างตัวแปรความเร่งทั้งสามรูปแบบกับค่า IRI หากค่า R^2 มีค่าสูง แสดงว่าตัวแปรความเร่งที่พิจารณามีความสัมพันธ์กับค่า IRI ในระดับที่ดีและสามารถสะท้อนลักษณะของถนนที่มีความขรุขระได้อย่างแม่นยำ

3.2.3 Data Normalization

เนื่องจากข้อมูล IRI และ ผลรวมความเร่งมีขนาดและหน่วยต่างกัน จึงจำเป็นต้องทำให้ข้อมูลเป็นมาตรฐานเพื่อแปลงข้อมูลให้เป็นช่วงที่แคบลง และเฉพาะเจาะจงมากขึ้น การปรับขนาดข้อมูลนี้ช่วยลดความลำเอียงที่อาจเกิดจากค่าตัวเลขที่แตกต่างกันมาก ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานจะถูกคำนวณจากชุดข้อมูล เพื่อให้ได้ชุดข้อมูลที่เป็นมาตรฐาน ซึ่งช่วยให้โมเดลสามารถประมวลผลข้อมูลได้อย่างแม่นยำและมีเสถียรภาพมากขึ้น [12] ดังสมการที่ (1)

$$Z = \frac{X_i - \mu}{\sigma} \quad (1)$$

โดยที่

Z = ผลลัพธ์ที่ได้จาก Standardization

X_i = ค่าของข้อมูล

μ = ค่าเฉลี่ยของข้อมูลทั้งหมด

σ = ส่วนเบี่ยงเบนมาตรฐานของข้อมูล

3.2.4 Data Matching

ข้อมูลผลรวมความเร่ง ที่ได้ทำการเก็บรวบรวมมานั้นจะถูกทำการ mapping เข้ากับข้อมูล IRI ด้วยตำแหน่งพิกัด GPS แต่เนื่องจากอุปกรณ์ที่ใช้ในการเก็บรวบรวมข้อมูล IRI และ Acceleration นั้นอาจมีความถี่ของข้อมูลไม่เท่ากันซึ่งอาจส่งผลให้ข้อมูลมีความคลาดเคลื่อนได้ การศึกษานี้จึงใช้วิธี Dynamic Time Warping (DTW) เพื่อวัดความคล้ายคลึงกันระหว่างรูปแบบสัญญาณสองชุดในการวิเคราะห์อนุกรมเวลา โดยทั่วไป DTW มักใช้ในการจดจำเสียงพูดเพื่อประเมินความใกล้เคียงระหว่างลำดับเวลาสองลำดับที่เปลี่ยนแปลงไปตามเวลา [13] ดังนั้นการศึกษานี้จึงนำ DTW มาใช้เพื่อวัดความคล้ายคลึงกันระหว่างทั้งสองรูปแบบ เพื่อให้ได้กราฟที่ชัดเจนของความเร่งเทียบกับ IRI ซึ่งสามารถระบุจุดข้อมูลในสัญญาณได้อย่างง่ายดาย และช่วยในการค้นหาความผิดปกติได้อย่างมีประสิทธิภาพ


3.3 การพัฒนาแบบจำลอง (Model Development)

หลังจากเตรียมข้อมูลสำหรับการวิเคราะห์เสร็จสิ้นแล้ว แบบจำลองจะถูกแบ่งออกเป็นสองส่วนหลัก ได้แก่ แบบจำลอง Convolutional Neural Network (CNN) ที่ใช้ในการตรวจจับและจำแนกสถานะความเสียหายของถนนจากภาพถ่าย และแบบจำลอง Regression ที่ใช้ในการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลผลรวมความเร่ง และสถานะความเสียหายของถนนเพื่อทำนายค่า IRI โดยใช้ข้อมูลจากอุปกรณ์เดียวกัน

3.3.1 Convolutional Neural Network (CNN)

ในปัจจุบัน การเรียนรู้เชิงลึก (Deep Learning) มีบทบาทสำคัญในการวิเคราะห์ข้อมูลรูปภาพ โดยเฉพาะในงานที่เกี่ยวข้องกับการจำแนก และตรวจจับวัตถุ ระบบประสาทเทียมแบบคอนโวลูชัน หรือ Convolutional Neural Network (CNN) ได้รับความนิยมอย่างกว้างขวาง เนื่องจากสามารถทำงานกับข้อมูลรูปภาพได้อย่างมีประสิทธิภาพ และแม่นยำ

หนึ่งในอัลกอริทึมที่ได้รับการยอมรับ และใช้งานอย่างแพร่หลายในงานตรวจจับวัตถุคือ You Only Look Once (YOLO) [14] ซึ่งถูกพัฒนาขึ้นในปี ค.ศ. 2016 โดย Joseph Redmon และคณะ ซึ่ง YOLO มีรูปแบบเป็นระบบเครือข่ายประสาทเทียมแบบ Single Neural Network ที่สามารถประมวลผลภาพทั้งหมดในครั้งเดียว (Single Pass) โดยอัลกอริทึมนี้สามารถทำนาย Bounding Boxes หรือขอบเขตของวัตถุในภาพ พร้อมกับทำนายค่าความน่าจะเป็นของประเภทวัตถุ (Class Probabilities) ในเวลาเดียวกัน ดังรูปที่ 7



รูปที่ 7 กระบวนการทำงาน YOLO

ในการศึกษานี้ ได้นำแบบจำลอง YOLOv5 ซึ่งเป็นโมเดลสำหรับการตรวจจับวัตถุ มาพัฒนาต่อจากโครงการ พัฒนาระบบระบุจุดเสี่ยงสำหรับรถจักรยานยนต์ด้วยเซนเซอร์ในสมาร์ตโฟน (Smooth Ride) [15] เพื่อให้เหมาะสมกับบริบทของงานวิจัย โดยมีการ Pre-training โมเดลด้วยชุดข้อมูลใหม่ที่ได้จากการสำรวจภาคสนาม เพื่อให้มั่นใจว่าโมเดลสามารถเรียนรู้และประเมินผลได้อย่างมีประสิทธิภาพ

จากแบบจำลองที่ได้นำมาพัฒนาต่อสามารถจำแนกประเภทของความเสียหายบนพื้นผิวถนนได้ 3 ประเภทหลัก ได้แก่ หลุมบ่อ, รอยแตก และการปะชอม อย่างไรก็ตาม ในการศึกษาที่มุ่งเน้นไปที่การวิเคราะห์ความเสียหายที่มีผลกระทบโดยตรงต่อค่า IRI คือหลุมบ่อและการปะชอม เนื่องจากการทบทวนวรรณกรรมและการวิเคราะห์ข้อมูลพบว่า รอยแตกไม่ได้ส่งผลต่อค่า IRI อย่างมีนัยสำคัญ เนื่องจากไม่ก่อให้เกิดความเปลี่ยนแปลงของพื้นผิวถนนในระดับที่ส่งผลต่อความขรุขระ ในขณะที่หลุมบ่อและการปะชอม มีผลกระทบโดยตรงต่อค่าความขรุขระของถนน ส่งผลให้ค่าดัชนี IRI เปลี่ยนแปลงตามไปด้วย ดังนั้น ในการสร้างแบบจำลองถดถอย (Regression Model) เพื่อนำไปใช้ทำนายค่า IRI จึงเลือกใช้เฉพาะข้อมูลของหลุมบ่อและการปะชอมเป็นตัวแปรในการวิเคราะห์ เพื่อให้ผลลัพธ์ที่ได้มีความแม่นยำและสะท้อนความสัมพันธ์ที่แท้จริงระหว่างลักษณะของค่า IRI

3.3.2 แบบจำลองถดถอย

แบบจำลองถดถอย (Regression Model) เป็นแบบจำลองทางสถิติที่ใช้ในการคาดการณ์ผลลัพธ์จากข้อมูลที่มีความสัมพันธ์เชิงเส้น (Linear Relationship) ระหว่างตัวแปรอิสระ (Independent variables) และตัว

แปรตาม (Dependent variable) กรณีที่มีตัวแปรอิสระมากกว่าหนึ่งตัวแปรจะเรียกว่า Multiple Linear Regression ในงานวิจัยนี้ ตัวแปรตามที่เราต้องการคาดการณ์คือ IRI ซึ่งใช้เป็นตัวชี้วัดความขรุขระของถนน ส่วนตัวแปรอิสระประกอบด้วย ผลรวมความเร่ง และ สถานะความเสียหายผิวทาง โดย Multiple Linear Regression สำหรับงานวิจัยนี้สามารถเขียนได้ดังสมการที่ (2)

$$Y = \beta_1 X_1 + \beta_2 X_2 \quad (2)$$

โดยที่

- Y = ค่าดัชนีความขรุขระสากล
- β_1 = สัมประสิทธิ์ของข้อมูลความเร่ง
- X_1 = ผลรวมของค่าความเร่ง
- β_2 = สัมประสิทธิ์ของข้อมูลสถานะความเสียหายผิวทาง
- X_2 = ค่าระบุสถานะความเสียหายผิวทาง

3.3.3 การประเมินประสิทธิภาพแบบจำลอง

ในการทดสอบความแม่นยำของค่าดัชนีความขรุขระสากล ที่คำนวณได้จากแบบจำลอง การศึกษาที่ใช้วิธี Mean Absolute Percentage Error (MAPE) เป็นวิธีการหาค่าเฉลี่ยของเปอร์เซ็นต์ความแตกต่างสัมบูรณ์ระหว่างค่าพยากรณ์ และค่าจริงมีหน่วยเป็นเปอร์เซ็นต์ หาก MAPE มีค่าน้อย แสดงว่าแบบจำลองสามารถประมาณค่าได้ใกล้เคียงกับค่าจริง [16] โดย MAPE มีสูตรการคำนวณ ดังสมการที่ (3)

$$MAPE = 100 \frac{1}{N} \sum_{i=1}^N \left| \frac{X_M - X_A}{X_A} \right| \quad (3)$$

โดยที่

- i = ข้อมูลตัวอย่างที่ i ; 1, 2, ..., N
- N = จำนวนตัวอย่างข้อมูล
- X_M = ค่า IRI ที่ได้จากแบบจำลอง
- X_A = ค่า IRI ที่ได้จากผลสำรวจ

4. ผลลัพธ์

4.1 ผลลัพธ์การเก็บข้อมูล

ผลลัพธ์ที่ได้เก็บรวบรวมข้อมูลเมื่อวันที่ 30 กรกฎาคม 2567 บนทางหลวงหมายเลข 204 มีความยาวทั้งสิ้น 18.85 กิโลเมตร และผู้เขียนได้ทำการแบ่งถนนออกเป็น 2 ช่วงคือ Train Dataset และ Test Dataset ซึ่งมีระยะทาง 15 กิโลเมตร และ 3.85 กิโลเมตร ตามลำดับ โดยข้อมูลทั้ง 2 ช่วงนั้นจะประกอบไปด้วยถนนชนิดแอสฟัลต์คอนกรีต (Asphalt Concrete - AC) และคอนกรีตซีเมนต์ (Cement Concrete - CC) โดยมีอัตราส่วนข้อมูลดังตารางที่ 3

ตารางที่ 3 สรุปชุดข้อมูลถนน


Type Road	Train Dataset	Test Dataset
Asphalt Concrete	13.5 กิโลเมตร (90 %)	3.35 กิโลเมตร (87 %)
Cement Concrete	1.5 กิโลเมตร (10 %)	0.5 กิโลเมตร (13 %)

4.2 ผลลัพธ์การประมวลผลข้อมูล

จากการรวบรวมข้อมูลจำนวน 4,000 รูปภาพ ผลลัพธ์ที่ได้จากการ Image Annotation ซึ่งประกอบด้วยข้อมูลความเสียหายรวมทั้งสิ้น 10,645 รายการ แบ่งออกเป็น การปะซ่อม (Patching) 5,789 รายการ, รอยแตก (Crack) 2,807 รายการ และหลุมบ่อ (Pothole) 2,049 รายการ ข้อมูลทั้งหมดนี้ได้ผ่านกระบวนการทำ Image Annotation ซึ่งเป็นการทำเครื่องหมายในรูปภาพเพื่อระบุและจัดประเภทความเสียหายในแต่ละภาพอย่างละเอียด ดังรูปที่ 8 จากนั้นข้อมูลเหล่านี้ถูกแบ่งออกเป็นชุดข้อมูลฝึกสอน (Train) 70%, ตรวจสอบ (Validation) 20% และทดสอบ (Test) 10% เพื่อใช้ในการพัฒนาและประเมินผลการทำงานของแบบจำลองดังรูปที่ 9




รูปที่ 8 การระบุประเภทความเสียหายในภาพด้วยเครื่องมือ RoboFlow



รูปที่ 9 สรุปชุดข้อมูลที่ได้จากเครื่องมือ RoboFlow

ในส่วนของการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลความเร่งและค่า IRI พบว่า ตัวแปรผลรวมค่าความเร่ง มีความสัมพันธ์กับค่า IRI มากที่สุด เมื่อเทียบกับค่าเฉลี่ยความเร่ง และค่าผลต่างระหว่างค่าความเร่งสูงสุดและต่ำสุด โดยมีค่า R^2 เท่ากับ 0.71 ซึ่งบ่งชี้ว่าผลรวมของค่าความเร่งสามารถสะท้อนลักษณะความขรุขระของถนนได้อย่างมีประสิทธิภาพ ดังที่แสดงในรูปที่ 10 จากผลลัพธ์ดังกล่าว ในงานวิจัยนี้จึงได้เลือกใช้ตัวแปรผลรวมค่า


ความเร่ง ร่วมกับข้อมูลความเสียหายบนผิวทาง เป็นตัวแปรสำคัญในแบบจำลองถดถอย เพื่อเพิ่มประสิทธิภาพในการทำนายค่า IRI เนื่องจากทั้งสองตัวแปรนี้มีความสัมพันธ์กับค่าความขรุขระของถนนและสามารถช่วยสะท้อนสภาพผิวทางที่มีความหลากหลายได้อย่างเหมาะสม



รูปที่ 10 ความสัมพันธ์ระหว่างข้อมูลความเร่ง และค่าดัชนีความขรุขระสากล

4.3 ผลลัพธ์การพัฒนาแบบจำลอง

ในส่วนนี้จะนำเสนอผลลัพธ์จากทั้งสองแบบจำลอง ได้แก่ แบบจำลอง Convolutional Neural Network (CNN) และแบบจำลอง Regression Model โดยผลลัพธ์จากแบบจำลอง CNN จะแสดงถึงประสิทธิภาพในการตรวจจับและจำแนกประเภทความเสียหายของถนน ผ่านการแสดงผลในรูปแบบของ Confusion Matrix ซึ่งช่วยให้เราเห็นถึงความแม่นยำในการจำแนกประเภทต่าง ๆ ของความเสียหาย โดยเฉพาะอย่างยิ่งการจำแนกประเภท หลุมบ่อ (Pothole) และ การปะซ่อม (Patching) ซึ่งสามารถดูได้จากรูปที่ 11 และตัวอย่างผลลัพธ์การระบุประเภทความเสียหายในภาพได้อย่างแม่นยำที่ได้จากแบบจำลองดังรูปที่ 12 และรูปที่ 13



รูปที่ 11 Confusion Matrix



รูปที่ 12 ความเสียหายชนิดการปะซ่อม



รูปที่ 13 ความเสียหายชนิดหลุมบ่อ


ในส่วนของแบบจำลองถดถอย (Regression Model) ผลลัพธ์ที่ได้แสดงดังรูปที่ 14 โดยผลลัพธ์ที่ได้จะแสดงถึงความแม่นยำของแบบจำลอง ซึ่งพิจารณาจากค่าความคลาดเคลื่อนโดยเฉลี่ย (MAPE) สามารถคำนวณได้จากการเปรียบเทียบระหว่างค่า IRI ที่เก็บรวบรวมจากรถสำรวจ (Actual) และค่า IRI ที่ได้จากการทำนายของแบบจำลอง (Predicted) โดยในงานวิจัยนี้ได้แบ่งการวิเคราะห์ออกเป็น 4 ส่วนหลัก เพื่อประเมินประสิทธิภาพของแบบจำลองภายใต้เงื่อนไขที่แตกต่างกัน ดังนี้

1. แบบจำลองที่ใช้ข้อมูลผลรวม Acceleration เพียงอย่างเดียว [Acc]
2. แบบจำลองที่ใช้ข้อมูลผลรวม Acceleration ร่วมกับข้อมูล Road Distress [Acc + Road Distress]
3. แบบจำลองที่ใช้ข้อมูลผลรวม Acceleration เพียงอย่างเดียว แต่พิจารณาเฉพาะข้อมูลในช่วงที่เป็นถนน Asphalt Concrete [Acc (Ac)]
4. แบบจำลองที่ใช้ข้อมูลผลรวม Acceleration ร่วมกับ Road Distress แต่พิจารณาเฉพาะข้อมูลในช่วงที่เป็นถนน Asphalt Concrete [Acc + Road Distress (Ac)]


จากผลลัพธ์ที่ได้พบว่า เมื่อแบบจำลอง Regression ใช้ตัวแปรผลรวม Acceleration ร่วมกับ Road Distress นั้นมีผลต่อความแม่นยำในการ

ประมาณค่า IRI อย่างมีนัยสำคัญ เมื่อเปรียบเทียบกับการใช้แค่ตัวแปรผลรวม Acceleration เพียงอย่างเดียว

โดยเฉพาะอย่างยิ่งเมื่อพิจารณา ในช่วงถนนประเภทแอสฟัลต์คอนกรีต จะแสดงให้เห็นถึงความสัมพันธ์ระหว่างค่า IRI ที่ได้จากรถสำรวจและค่า IRI ที่ได้จากการทำนายของแบบจำลองนั้นมีแนวโน้มไปในทิศทางเดียวกันดังรูปที่ 15 ซึ่งบ่งชี้ว่าแบบจำลองสามารถสะท้อนลักษณะของ IRI ได้อย่างเหมาะสมและแม่นยำในบริบทของข้อมูลที่ใช้ในการศึกษา



รูปที่ 14 ผลลัพธ์แบบจำลองถดถอย



รูปที่ 15 ความสัมพันธ์ระหว่างค่าจริงและค่าทำนาย (ถนนแอสฟัลต์)

5. อภิปราย

จากการวิเคราะห์ผลการจำแนกประเภทของแบบจำลองด้วย Confusion Matrix ดังรูปที่ 11 พบว่าแบบจำลองสามารถจำแนกประเภทของความเสียหายบนพื้นผิวถนนได้อย่างแม่นยำ โดยมี ค่าแม่นยำ (Accuracy) สำหรับประเภท การปะซ่อม (Patching) เท่ากับ 0.91 (91%) และ หลุมบ่อ (Pothole) เท่ากับ 0.71 (71%) ตามลำดับ ซึ่งสอดคล้องกับจำนวนตัวอย่างที่ใช้ในการฝึกแบบจำลอง โดยมีจำนวนตัวอย่างของแต่ละประเภทเท่ากับ 5,789 และ 2,049 ตามลำดับ โดยผลลัพธ์ที่ได้ชี้ให้เห็นว่าแบบจำลองสามารถจำแนกประเภทของความเสียหายได้อย่างแม่นยำมากขึ้น เมื่อได้รับจำนวนรูปภาพที่เพิ่มมากขึ้นในการฝึกฝนแบบจำลอง เนื่องจากการมีข้อมูลที่หลากหลายและครอบคลุมลักษณะเฉพาะของแต่ละประเภทความเสียหายช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบได้ดีขึ้น ส่งผลให้ความสามารถในการจำแนกประเภทของความเสียหายมีประสิทธิภาพสูงขึ้น

อย่างไรก็ตาม ในการระบุความเสียหายประเภทหลุมบ่อยังพบปัญหาบางประการ โดยมีข้อผิดพลาดในกรณีที่เป็นแบบจำลองไม่สามารถตรวจจับหลุมบ่อที่มีอยู่จริงในภาพได้ (False Negative) สูงถึง 27% ซึ่งเกิดจากการที่แบบจำลองไม่สามารถเรียนรู้ลักษณะเฉพาะของหลุมบ่อได้อย่างเพียงพอเนื่องจากจำนวนตัวอย่างที่มีจำกัด นอกจากนี้ยังพบว่าแบบจำลองมีความผิดพลาดในตรวจจับความเสียหายที่ไม่ได้เกิดขึ้นจริง (False Positive) โดยสาเหตุหลักของปัญหานี้มาจากปัจจัยด้านแสงและเงา รวมถึงแอ่งน้ำบนพื้นผิวถนน ซึ่งอาจทำให้ภาพที่ได้มีลักษณะที่คล้ายกับหลุมบ่อ ส่งผลให้แบบจำลองเกิดความคลาดเคลื่อนในการตัดสินใจ

สำหรับการวิเคราะห์ผลของแบบจำลองถดถอยดังรูปที่ 14 พบว่าเมื่อใช้เพียงข้อมูลผลรวม Acceleration ในการทำนายค่า IRI แบบจำลองให้ค่าความคลาดเคลื่อนโดยเฉลี่ยอยู่ที่ $MAPE = 30.6\%$ โดยเมื่อทำการเพิ่มตัวแปร Road Distress เข้าไปในแบบจำลอง พบว่าค่าความผิดพลาดลดลงเหลือ $MAPE = 28.0\%$ แสดงให้เห็นว่าการเพิ่มข้อมูลเกี่ยวกับสภาพถนนช่วยเพิ่มความแม่นยำของการทำนาย IRI ได้ดีขึ้น

นอกจากนี้เมื่อลองพิจารณาเฉพาะช่วงถนนที่เป็นแอสฟัลต์คอนกรีต พบว่าแบบจำลองที่ใช้เฉพาะข้อมูลผลรวม Acceleration นั้นจะให้ค่า $MAPE = 25.5\%$ และเมื่อใช้ข้อมูลผลรวม Acceleration ร่วมกับข้อมูล Road Distress สำหรับถนนแอสฟัลต์ พบว่าค่าความผิดพลาดลดลงเหลือ $MAPE = 23.5\%$ ซึ่งเป็นค่าที่ต่ำที่สุดในบรรดาแบบจำลองทั้งหมด บ่งชี้ว่าการผสมผสานข้อมูลผลรวม Acceleration และ Road Distress โดยเฉพาะบนพื้นผิวถนนที่เป็นแอสฟัลต์ สามารถช่วยให้การทำนายค่า IRI มีความแม่นยำสูงขึ้น

โดยสาเหตุที่เลือกช่วงแอสฟัลต์คอนกรีต นั้นเพราะว่าช่วงถนนคอนกรีตซีเมนต์ ไม่มีความเสียหายประเภทการบวมหรือหลุมบ่อ ส่วนใหญ่พื้นถนนคอนกรีตจะมีความเสียหายประเภทรอยแตก ซึ่งไม่ใช่ความเสียหายที่ส่งผลกระทบต่อค่า IRI และในพื้นที่การศึกษานี้ถนนที่เป็นคอนกรีตซีเมนต์ นั้นจะอยู่ในช่วงที่เป็นรอยต่อหรืออยู่ในช่วงขึ้นและลงสะพาน ทำให้ค่าผลรวม Acceleration ที่เก็บรวบรวมได้นั้นมีความแปรปรวนไม่สอดคล้องต่อค่า IRI

6. บทสรุป

งานวิจัยนี้ได้นำเสนอแนวทางในการประมาณค่า IRI โดยใช้ข้อมูล Acceleration จากกล้องบันทึกภาพ และศึกษาว่าการเพิ่มตัวแปร Road Distress สามารถช่วยให้การทำนายมีความแม่นยำมากขึ้นหรือไม่ โดยจากผลการทดลองพบว่า การใช้ข้อมูลผลรวม Acceleration เพียงอย่างเดียวให้ค่าความผิดพลาดสูงสุด ($MAPE = 30.6\%$) แต่เมื่อเพิ่มตัวแปร Road Distress เข้าไป ค่าความผิดพลาดลดลงอย่างมีนัยสำคัญ นอกจากนี้ เมื่อนำข้อมูลเฉพาะถนนแอสฟัลต์มาวิเคราะห์ พบว่าความแม่นยำของแบบจำลองดีขึ้นอย่างชัดเจน โดยโมเดลที่ใช้ข้อมูลผลรวม Acceleration ร่วมกับ Road Distress ให้ค่าความผิดพลาดต่ำที่สุดที่ $MAPE = 23.5\%$ ผลลัพธ์เหล่านี้แสดงให้เห็นว่า การนำข้อมูลความเสียหายบนผิวทาง ซึ่งเป็นปัจจัยที่

มีผลต่อค่า IRI มาพิจารณาพร้อมกับข้อมูลผลรวมความเร่ง ทำให้ผลลัพธ์มีความแม่นยำมากยิ่งขึ้น

จากการศึกษาพบว่ามีการจำกัดบางประการที่อาจส่งผลกระทบต่อความแม่นยำของแบบจำลอง โดยสามารถแบ่งออกเป็นสองส่วนหลัก ได้แก่ ข้อจำกัดของแบบจำลองการจำแนกประเภทความเสียหาย (CNN Model) และ ข้อจำกัดของแบบจำลองถดถอย (Regression Model)

สำหรับแบบจำลองการจำแนกประเภทความเสียหาย พบว่ามีข้อจำกัดที่สำคัญหลายประการ ประการแรก คือ จำนวนข้อมูลฝึกที่ใช้ในการพัฒนาแบบจำลองมีอยู่อย่างจำกัดในแต่ละประเภทความเสียหาย ทำให้แบบจำลองอาจไม่สามารถเรียนรู้ลักษณะเฉพาะของแต่ละประเภทได้อย่างมีประสิทธิภาพ ส่งผลให้ความสามารถในการจำแนกประเภทความเสียหายลดลง ดังนั้น หากต้องการให้แบบจำลองมีประสิทธิภาพมากขึ้น ควรมีการเพิ่มจำนวนข้อมูลฝึกให้หลากหลายและครอบคลุมลักษณะความเสียหายที่แตกต่างกันมากขึ้น ประการต่อมา คือ มุมกล้องที่ใช้ในการเก็บข้อมูล ซึ่งในการศึกษานี้ กล้องถูกติดตั้งในตำแหน่งที่เน้นมุมมองด้านหน้า (Front View) เป็นหลัก ทำให้ภาพที่ได้อาจมีข้อจำกัดในบางสถานการณ์ ส่งผลให้ความแม่นยำของแบบจำลองลดลง นอกจากนี้ ยังพบว่าผลกระทบจากปัจจัยภายนอก เช่น แสง เงา และแอ่งน้ำ มีผลต่อการจำแนกประเภทความเสียหายของแบบจำลอง

ในส่วนของแบบจำลองถดถอย พบว่ามีข้อจำกัดสำคัญที่ควรพิจารณาประการแรก คือ ค่า Acceleration ที่ได้จากถนนคอนกรีตซีเมนต์ (Cement Concrete - CC) ไม่สอดคล้องกับค่า IRI ซึ่งอาจเกิดจากโครงสร้างของถนนและตำแหน่งของการเก็บข้อมูลที่อยู่บริเวณรอยต่อของถนนหรือสะพาน ส่งผลให้ค่าความเร่งที่รวบรวมได้มีความแปรปรวนสูง และอาจไม่สะท้อนถึงระดับความขรุขระของถนนได้อย่างถูกต้อง นอกจากนี้ ข้อจำกัดอีกประการหนึ่งของแบบจำลองถดถอย คือ ตัวแปรที่ใช้ในการศึกษานี้ อาจยังไม่ครอบคลุมปัจจัยที่ส่งผลกระทบต่อค่า IRI อย่างครบถ้วน โดยการศึกษาที่มุ่งเน้นไปที่ความเสียหายบางประเภทเท่านั้น ซึ่งอาจทำให้ผลลัพธ์ไม่สะท้อนถึงสภาพความเสียหายที่เกิดขึ้นทั้งหมด ในความเป็นจริงความเสียหายประเภทอื่น ๆ เช่น ร่องล้อ (Rutting) อาจมีผลต่อค่า IRI อย่างมีนัยสำคัญ แต่ไม่ได้ถูกนำมาพิจารณาในการศึกษานี้เนื่องจาก พื้นที่การศึกษาไม่มีความเสียหายชนิดร่องล้อ โดยการศึกษาในอนาคต หากต้องการเพิ่มความแม่นยำของแบบจำลอง ควรพิจารณาปรับปรุงคุณภาพของข้อมูล โดยเพิ่มจำนวนข้อมูลฝึกในแบบจำลองการจำแนกประเภทความเสียหาย รวมถึงการติดตั้งมุมกล้องในการเก็บรวบรวมข้อมูลให้ครอบคลุมหลายด้าน และพิจารณาความเสียหายที่หลากหลายมากขึ้นในแบบจำลอง เพื่อให้สามารถสะท้อนค่าดัชนี IRI ได้อย่างครอบคลุมและแม่นยำมากยิ่งขึ้น

กิตติกรรมประกาศ

ขอขอบคุณ โครงการส่งเสริมจากการศึกษาระดับปริญญาโท แผนการเรียนแบบ ก คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ที่ให้การสนับสนุนทางด้านทุนการศึกษา และขอแสดงความขอบคุณ กรมทางหลวง ที่ให้การสนับสนุนข้อมูลที่สำคัญในการศึกษานี้ รวมถึงโครงการ

พัฒนาระบบระบุจุดเสี่ยงสำหรับรถจักรยานยนต์ด้วยเซนเซอร์ในสมาร์ทโฟน
(Smooth Ride) ที่ได้ให้ข้อมูลและความรู้ที่เป็นประโยชน์ต่อการศึกษาวิจัย

เอกสารอ้างอิง

- [1] Montha, A., et al., Road Roughness Estimation Using Acceleration Data from Smartphones. International Road Federation World Meeting & Exhibition, 2021.
- [2] Pierce, L.M., et al., AI Applications for Automatic Pavement Condition Evaluation. 2024.
- [3] Sang, Y., et al., Smartphone-Based IRI Estimation for Pavement Roughness Monitoring: A Data-Driven Approach. IEEE Internet of Things Journal, 2024. **11**(11): p. 19708-19720.
- [4] Janani, L., V. Sunitha, and S. Mathew, Influence of surface distresses on smartphone-based pavement roughness evaluation. International Journal of Pavement Engineering, 2020. **22**(13): p. 1637-1650.
- [5] Jeong, J.-H. and H. Jo, Toward Real-World Implementation of Deep Learning for Smartphone-Crowdsourced Pavement Condition Assessment. IEEE Internet of Things Journal, 2024. **11**(4): p. 6328-6337.
- [6] Lin, J.-D., Jyh-Tyng Yau, and Liang-Hao Hsiao., Correlation analysis between international roughness index (IRI) and pavement distress by neural network. 82nd Annual Meeting of the Transportation Research Board, 2003.
- [7] Xin, H., et al., Sustainable Road Pothole Detection: A Crowdsourcing Based Multi-Sensors Fusion Approach. Sustainability, 2023. **15**(8).
- [8] Zhao, T., et al., A Comprehensive Implementation of Road Surface Classification for Vehicle Driving Assistance: Dataset, Models, and Deployment. IEEE Transactions on Intelligent Transportation Systems, 2023. **24**(8): p. 8361-8370.
- [9] Abohamer, H., et al., Development of a Deep Convolutional Neural Network for the Prediction of Pavement Roughness from 3D Images. Journal of Transportation Engineering, Part B: Pavements, 2021. **147**(4).
- [10] Wu, H., et al., Road pothole extraction and safety evaluation by integration of point cloud and images derived from mobile mapping sensors. Advanced Engineering Informatics, 2019. **42**.
- [11] Chen, C., H. Seo, and Y. Zhao, A novel pavement transverse cracks detection model using WT-CNN and STFT-CNN for smartphone data analysis. International Journal of Pavement Engineering, 2021. **23**(12): p. 4372-4384.
- [12] Chollet, F., Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek. MITP-Verlags GmbH & Co. Textbook, 2018.
- [13] Gale, W.A., and Kenneth Ward Church., A program for aligning sentences in bilingual corpora. Computational linguistics, 1994.
- [14] Redmon, J., You only look once: Unified, real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016.
- [15] Wanchai Yodsudjai, e.a., Smooth Ride Project. 2023.
- [16] Lewis, C.D., Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting. Textbook, 1982.