

การตรวจสอบความเสียหายโดยใช้ปัญญาประดิษฐ์ สำหรับการประเมินพื้นสะพาน AI-Based Damage Inspection for Bridge Deck Assessment

จิราธิป ไชยสิงห์ หนัศววัฒน์ คงเวหน พศวีร์ แสนหิรัญญ์ และ รศ.ดร.ธิดารัตน์ วิสุทธิ์เสรีวงศ์
ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพฯ

บทคัดย่อ

บทความนี้นำเสนอ "การตรวจสอบความเสียหายโดยใช้ปัญญาประดิษฐ์ สำหรับการประเมินพื้นสะพาน" ซึ่งมีวัตถุประสงค์เพื่อศึกษาและพัฒนากระบวนการตรวจสอบความเสียหายโครงสร้างสะพานคอนกรีตส่วนพื้นสะพานด้วยปัญญาประดิษฐ์ โดยในขั้นตอนการพัฒนากระบวนการตรวจสอบความเสียหายโครงสร้างสะพานคอนกรีตประกอบด้วย การเก็บรวบรวมและวิเคราะห์ข้อมูลภาพถ่ายของโครงสร้างสะพานคอนกรีตส่วนพื้นสะพาน การระบุประเภทความเสียหายจากข้อมูลภาพโดยใช้โปรแกรม MATLAB การฝึกอบรมปัญญาประดิษฐ์โดยใช้ Model R-CNN และการทดสอบโมเดลเพื่อทดสอบความถูกต้องและแม่นยำที่ได้จากการอบรมหรือเทรนโมเดล ประโยชน์ที่คาดว่าจะได้รับจากโครงการนี้คือ ระบบตรวจสอบความเสียหายโครงสร้างสะพานคอนกรีตด้วยปัญญาประดิษฐ์เป็นวิธีการตรวจสอบความเสียหายโครงสร้างสะพานคอนกรีตที่ใช้แรงงานและเวลาน้อยลงซึ่งอาจทำให้ประหยัดค่าใช้จ่ายมากขึ้น ทำให้วิธีนี้อาจจะเข้ามามีบทบาทสำคัญในอนาคตและจะช่วยเพิ่มความปลอดภัยให้กับระบบคมนาคมของขนส่งของประเทศไทยอีกด้วย

คำสำคัญ: R-CNN, การตรวจจบบัจุด, การจำแนกประเภทความเสียหาย, โครงสร้างสะพานส่วนพื้น

Abstract

This article presents "Damage Inspection Using Artificial Intelligence for Bridge Deck Assessment" which aims to study and develop a system for inspecting structural damage to concrete bridge decks using artificial intelligence. The development process of the damage inspection system for concrete bridge structures includes collecting and analyzing photographic data of bridge structures, identifying damage types from the image data using MATLAB software, training artificial intelligence using the R-CNN Model, and testing the model for accuracy and precision obtained from model training. The expected benefits of this project include a concrete bridge structural damage inspection system using

artificial intelligence, which requires less labor and time, potentially resulting in cost savings. This method may play a significant role in the future and help enhance the safety of Thailand's transportation infrastructure.

Keywords: R-CNN, Object detection, Classification, Bridge Deck

1. บทนำ

สะพานคอนกรีตเป็นโครงสร้างที่มีความสำคัญต่อระบบคมนาคมเป็นอย่างมาก เนื่องจากสะพานคอนกรีตเป็นโครงสร้างที่รับน้ำหนักและแรงกระแทกจากยานพาหนะจำนวนมาก จึงต้องมีการตรวจสอบสภาพความแข็งแรงของโครงสร้างอย่างสม่ำเสมอ เพื่อความปลอดภัยของผู้ใช้สะพานและประชาชนทั่วไป โดยในปัจจุบัน การตรวจสอบสภาพความแข็งแรงของโครงสร้างสะพานคอนกรีตส่วนใหญ่ใช้วิธีการตรวจสอบแบบดั้งเดิม เช่น การตรวจสอบด้วยเครื่องมือวัดการเคลื่อนตัว ซึ่งวิธีการเหล่านี้มีข้อจำกัดหลายประการ เช่น ใช้เวลาในการเก็บข้อมูลที่ค่อนข้างนาน ใช้แรงงานจำนวนมาก และอาจก่อให้เกิดความเสียหายต่อโครงสร้างสะพานได้ จึงได้มีการนำเทคโนโลยีสมัยใหม่เข้ามาใช้ในการตรวจสอบสภาพความแข็งแรงของโครงสร้างสะพานคอนกรีต เช่น เทคโนโลยีการประมวลผลภาพ (Image processing) เทคโนโลยีอากาศยานไร้คนขับ (UAV) เป็นต้น โครงการนี้ จึงมุ่งเน้นในการรวบรวมความเสียหายของโครงสร้างสะพานคอนกรีตที่ได้จากเทคโนโลยีการประมวลผลภาพ (Image processing) เนื่องจากเทคโนโลยีนี้ช่วยลดระยะเวลาและต้นทุนในการตรวจสอบได้ แต่อย่างไรก็ตามข้อมูลภาพความเสียหายจำเป็นต้องได้รับการประเมินด้วยวิศวกรผู้มีความเชี่ยวชาญสูง จึงทำให้มีแนวคิดในการนำปัญญาประดิษฐ์ (Artificial Intelligence: AI) มาช่วยในการประเมินสภาพของโครงสร้างสะพาน โดย AI ถือเป็นเทคโนโลยีที่พัฒนาขึ้นเพื่อเลียนแบบการเรียนรู้และพฤติกรรมของมนุษย์ AI มีศักยภาพที่จะนำมาประยุกต์ใช้ เพื่อการตรวจสอบสภาพความแข็งแรงของโครงสร้างสะพานคอนกรีตได้อย่างมีประสิทธิภาพ, แม่นยำและรวดเร็วกว่าวิธีการตรวจสอบแบบดั้งเดิมอีกด้วย

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 โครงสร้างและองค์ประกอบของสะพาน

สะพานเป็นองค์ประกอบที่สำคัญในโครงข่ายของทางหลวง เป็นโครงสร้างที่มีการสร้างขึ้นเพื่อเชื่อมโยงระหว่างพื้นที่ต่างๆ ที่มีความสำคัญในการขนส่งและการเดินทางของประชาชนและสินค้าต่างๆ ในประเทศ โดยองค์ประกอบของโครงสร้างสะพานแบ่งเป็น 3 ส่วนที่สำคัญได้แก่

2.1.1 โครงสร้างสะพานส่วนบน (Superstructure)

โครงสร้างส่วนบนของสะพานซึ่งอยู่เหนือแผ่นรองรับคาน(Bearing) ขึ้นไป มีหน้าที่รองรับน้ำหนักจากแผ่นพื้นสะพาน, ผิวจราจรของสะพาน และน้ำหนักที่บรรทุกบนแผ่นพื้นสะพาน แล้วถ่ายแรงต่อไปยังจุดรองรับไปสู่โครงสร้างส่วนล่างต่อไปโดยผ่าน แรงดึง,แรงกด,แรงดัด หรือทั้งสามแรง โดยส่วนประกอบของโครงสร้างสะพานส่วนนี้ประกอบไปด้วย พื้นสะพาน(Deck), คานตามยาว(Girder), และค้ำยันคานตามยาว (Diaphragm)

2.1.2 โครงสร้างสะพานส่วนล่าง (Substructure)

โครงสร้างส่วนล่างของสะพาน คือ ชั้นส่วนต่างๆ ที่อยู่ต่ำกว่าแผ่นรองรับคาน (Bearing) ลงไปโดยมีหน้าที่รองรับและถ่ายน้ำหนักจากโครงสร้างส่วนบนให้ลงสู่ฐาน โดยส่วนประกอบของโครงสร้างสะพานส่วนนี้ประกอบไปด้วย คานรัดหัวเสา (Cap Beam), ค้ำยันตอมอ (Bracing), เสาตอมอ (Pier), กำแพงตอมอ (Pier Wall), ฐานราก (Footing), และเสาเข็ม (Pile)

2.1.3 ส่วนประกอบรอง (Secondary Components)

ส่วนประกอบเหล่านี้มีหน้าที่เป็นชั้นเสริมในการรับน้ำหนักที่กระทำต่อสะพานหรือมีประโยชน์ต่อสะพานด้านอื่นๆเช่น ผิวทาง (Wearing Surface)ช่วยรับน้ำหนักจากล้อรถและกระจายแรงสู่ระบบพื้นและคาน, ระบบระบายน้ำ(Drainage)ช่วยในการระบายน้ำที่ขังออกจากผิวทาง โดยตัวอย่างส่วนประกอบรองของโครงสร้างสะพานได้แก่ หูข้าง (Wing Wall), เชิงลาดสะพาน (Approach), แผ่นรองรับคาน (Bearing), รอยต่อเพื่อการขยาย (Expansion Joint), ผิวทาง (Wearing Surface), แผงกั้นจราจร (Traffic Barrier), ราวสะพาน (Railing), ทางเท้า (Sidewalk), ระบบระบายน้ำ (Drainage), กำแพงกันดิน (Retaining Wall), และลาดป้องกันตลิ่ง (Slope Protection)

2.2 องค์ประกอบสะพานที่กลุ่มสนใจและประเภทความเสียหาย

พื้นสะพาน (Deck) เป็นส่วนของสะพานที่เชื่อมระหว่างจุดสองข้างของสะพาน หน้าที่ของพื้นสะพานจะเป็นตัวสำคัญในการรองรับน้ำหนักของยานพาหนะและคนเดิน และยังทำหน้าที่ในการสนับสนุนโครงสร้างอื่นๆ เช่น คอลัมน์ เพื่อให้มันคงและปลอดภัยแก่ผู้ใช้งาน

โดยปกติแล้วพื้นสะพานจะมีโครงสร้างเป็นคอนกรีตเสริมเหล็ก เพราะฉะนั้นการตรวจสอบความเสียหายที่เกิดขึ้นจะตรวจสอบความเสียหายหลักๆที่พบและแบ่งประเภทความเสียหาย ได้เป็นรอยแตก (Cracking), การหลุดร่อน (Spalling) , การหลุดล่อนจนเห็นเหล็กเสริม (Steel Exposure)

2.2.1 รอยแตก (Cracking)

รอยแตกอาจเกิดขึ้นเพียงส่วนหนึ่ง หรือทั้งหมดของแต่ละชิ้นส่วนของคอนกรีต ในคอนกรีตเสริมเหล็กรอยแตกจะมีขนาดใหญ่พอที่จะมองเห็นได้ด้วยตาเปล่า แต่ในคอนกรีตอัดแรงจะต้องใช้อุปกรณ์วัดรอยแตก (Crack Gauge) จึงจะเหมาะสมสำหรับการวัดรอยแตก และแยกแยะรอยแตกต่างๆรอยเบื่อนจากสนิม และการเกิดเชื้อเกลือมักจะปรากฏให้เห็นตามรอยแตกต่างๆรอยแตกทั้งขนาดใหญ่และเล็กที่เกิดขึ้นในองค์อาคารหลัก (Main Members)โดยเฉพาะอย่างยิ่งชิ้นส่วนที่เป็นคอนกรีตอัดแรง ควรจะบันทึกไว้อย่างระมัดระวังซึ่งขนาดของรอยแตกอาจถูกจัดประเภทออกเป็นรอยแตกขนาดเท่าเส้นผม (Hairline) รอยแตกขนาดกลาง(Medium) หรือรอยแตกขนาดใหญ่ (Wide) รอยแตกขนาดเท่าเส้นผมจะเป็นรอยแตกที่ไม่สามารถวัดขนาดได้ด้วยอุปกรณ์ธรรมดา

ในโครงสร้างคอนกรีตเสริมเหล็กทั่วไปรอยแตกเท่าเส้นผมนี้จะไม่ใช่อุปกรณ์ที่จะมีผลกระทบต่อการทำงานของรับน้ำหนักของโครงสร้าง ส่วนรอยแตกขนาดกลางและขนาดใหญ่ นั้น เราสามารถใช้อุปกรณ์ต่างๆ วัดได้ รอยแตกเหล่านี้จะเป็นสิ่งที่สำคัญมากและควรที่จะได้รับการตรวจสอบ และบันทึกไว้ในบันทึกการตรวจสอบดังรูปตัวอย่างรอยแตกและตารางบอกรายละเอียดของรอยแตกดังนี้

2.2.2 การหลุดร่อน (Spalling)

เป็นการยุบตัวของ คอนกรีตเป็นรูปคล้ายวงกลมหรือวงรีมีสาเหตุมาจาก การแยกตัว หรือการถูกเคลื่อนย้าย ของส่วนใดส่วนหนึ่งของคอนกรีตที่ ผิวหน้า ทำให้เห็นรอยแตกที่ค่อนข้างจะขนานกับผิวคอนกรีต และการหลุดร่อนนี้อาจมีสาเหตุมาจากการที่เหล็กเสริมเป็นสนิม และ การเกิดแรงเสียดทานจากการขยายตัวเนื่องจากความร้อน F โดยการหลุดร่อนแบ่งเป็น 2 ประเภท ได้แก่ การหลุดร่อนขนาดเล็กซึ่งจะมีความลึกน้อยกว่า 2.5 เซนติเมตร หรือมี เส้นผ่าศูนย์กลางประมาณ 15 เซนติเมตร, และการหลุดร่อนขนาดใหญ่ซึ่งจะมีความลึกมากกว่า 2.5 เซนติเมตร หรือมีเส้นผ่าศูนย์กลางมากกว่า 15 เซนติเมตร

2.2.3 การหลุดร่อนจนเห็นเหล็กเสริม(Steel Exposure)

เป็นประเภทความเสียหายที่รุนแรงขึ้นของการหลุดร่อน เกิดจากการสูญเสียของเลย์เออร์ป้องกันที่ทำให้เห็นเหล็กเสริมของโครงสร้างพื้นสะพานโดยตรง สภาวะนี้ส่งผลให้เหล็กเสริมได้รับความเสียหายจากสภาพแวดล้อม เช่น ความชื้น อุณหภูมิสูง หรือสารเคมีที่สามารถเข้าไปเป็นปัจจัยที่ทำให้เกิดการเสื่อมทำลายเร็วขึ้น ผลกระทบจากความเสียหายนี้อาจทำให้โครงสร้างพื้นสะพานสูญเสียความแข็งแรงและความทนทาน ทำให้เกิดความเสียหายรุนแรงและเสี่ยงต่อความปลอดภัยของผู้ใช้

2.3 การตรวจจบบัณฑิต (Object Detection Using Machine Learning)

การตรวจจบบัณฑิต (Object Detection) คือ เทคโนโลยีในทางคอมพิวเตอร์ หลักการที่เกี่ยวกับ Computer Vision และ Image Processing ที่ใช้งาน AI ตรวจจบบัณฑิตที่กำหนด เช่น มนุษย์ รถยนต์ อาคาร ที่อยู่ในรูปภาพ หรือวิดีโอ โดยอาจจะมีจำนวนวัตถุในแต่ละประเภทมากกว่าหนึ่ง เช่น อาจจะมีคน 5 คน และสุนัข 8 ตัว ใน

ภาพเดียว เราต้องการรู้ว่าวัตถุที่สนใจแต่ละอย่างนั้นอยู่ที่ใดบ้างในภาพ โดยกระบวนการตรวจจับวัตถุโดยทั่วไปประกอบด้วยขั้นตอนต่อไปนี้

2.3.1 การเตรียมข้อมูล

ขั้นตอนนี้เกี่ยวข้องกับการรวบรวมชุดข้อมูลภาพสำหรับวัตถุที่เราต้องการตรวจจับ

2.3.2 การฝึกโมเดล

ขั้นตอนนี้เกี่ยวข้องกับการฝึกอัลกอริทึมการตรวจจับวัตถุโดยใช้ชุดข้อมูลภาพที่มีป้ายกำกับ อัลกอริทึมจะเรียนรู้รูปแบบของวัตถุจากชุดข้อมูล และจะใช้รูปแบบเหล่านี้เพื่อตรวจจับวัตถุในภาพใหม่ การฝึกโมเดลอาจใช้เวลาหลายชั่วโมงขึ้นอยู่กับขนาดของชุดข้อมูลและอัลกอริทึมที่ใช้

2.3.3 การใช้โมเดล

ขั้นตอนนี้เกี่ยวข้องกับการใช้โมเดลที่ฝึกแล้วเพื่อตรวจจับวัตถุในภาพหรือวิดีโอ โมเดลจะสร้างกรอบรอบวัตถุที่ตรวจพบ และอาจจะระบุประเภทของวัตถุด้วย

2.4 งานวิจัยที่เกี่ยวข้อง

2.4.1 Convolution Neural Network on Concrete Bridge

Chen et al. (2023) งานวิจัยฉบับนี้เป็นการใช้เครือข่ายประสาทคอนโวลูชันสำหรับการจำแนกประเภทรูปภาพความเสียหายของสะพานคอนกรีตเสริมเหล็ก (RC) ของรถไฟความเร็วสูง (HSR) โดยที่แบ่งประเภทความเสียหายเป็น การเกิดรอยแตก, การหลุดร่อน, และการหลุดร่อนจนเห็นเหล็กเสริม โดยใช้ข้อมูลของสะพานในประเทศจีนในปี ค.ศ.2013-2017 โดยจากการทำการวิจัยดังกล่าวสามารถแยกประเภทความเสียหายได้ผลความถูกต้องของการดำเนินการดังนี้ การเกิดรอยแตก 86%, การหลุดร่อน 70%, และการหลุดร่อนจนเห็นเหล็กเสริม 82% จึงสรุปได้ว่าโมเดลที่ผ่านการใช้เครือข่ายประสาทคอนโวลูชันสำหรับการตรวจจับความเสียหายของสะพานคอนกรีตเสริมเหล็กได้อย่างน่าพอใจและรวดเร็ว

Arafin et al. (2022) การศึกษานี้ใช้การแบ่งส่วนเชิงความหมาย (semantic segmentation) เพื่อระบุตำแหน่งและตรวจจับข้อบกพร่องเชิงโครงสร้าง เช่น รอยร้าวและการหลุดร่อนบนส่วนประกอบของพื้นสะพาน ในขั้นแรกของการตรวจจับข้อบกพร่อง การศึกษานี้ได้พัฒนาชุดข้อมูลเฉพาะที่ประกอบด้วยภาพจริงเท่านั้นและหลีกเลี่ยงกระบวนการเพิ่มข้อมูล (image augmentation) จากนั้นใช้แบบจำลอง CNN 4 แบบ ได้แก่ VGG19, ResNet50, InceptionV3 และ EfficientNetB3 เพื่อวิเคราะห์ภาพรอยร้าวและการหลุดร่อนสำหรับการตรวจจับข้อบกพร่องโดยที่แบบจำลองทั้งหมดนี้ถูกวิเคราะห์บนฟังก์ชันการเพิ่มประสิทธิภาพสองแบบ คือ SGD (Stochastic Gradient Descent) และ ADAM (Adaptive Moment Estimation) ประสิทธิภาพของแบบจำลองเหล่านี้ถูกประเมินตามตัวชี้วัด Precision, Recall, และ F1-Score สำหรับการแบ่งส่วนรอยร้าว EfficientNetB3 กับการเพิ่มประสิทธิภาพด้วย SGD ได้รับความแม่นยำที่ดีที่สุด โดยมีคะแนน IoU (Intersection over Union) ที่ 0.846, Recall 0.918, และ F1-Score 0.912 ส่วนสำหรับการแบ่งส่วนหลุดร่อน InceptionV3 กับการเพิ่มประสิทธิภาพด้วย SGD ได้รับความแม่นยำสูงที่สุด โดยมี F1-Score 0.857, Recall 0.897 และ IoU Score 0.755

Gulgec et al. (2017) งานวิจัยนี้นำเสนอเทคนิค Convolutional Neural Network (CNN) ซึ่งได้ทำให้เกิดผลลัพธ์ที่โดดเด่นในการมองเห็นด้วยคอมพิวเตอร์ สำหรับการทำนายความเสียหาย เทคนิค CNN มีความสามารถในการค้นพบลักษณะที่สามารถมองเห็นได้ ซึ่งสามารถแยกแยะด้านต่างๆ ที่สนใจในกรณีของงานวิจัยนี้ ลักษณะเหล่านี้ถูกใช้ในการจำแนก "Damaged" และ "Healthy" ของตัวอย่างซึ่งถูกจำลองผ่านการคำนวณแบบของเครือข่ายจำกัด การทดลอง CNN ดำเนินการโดยไลบรารีภาษา Python ที่เรียกว่า Theano พร้อมกับหน่วยประมวลผลกราฟิก (GPU) เพื่อให้ได้ประสิทธิภาพที่สูงการคำนวณที่ใช้ข้อมูลจำนวนมาก

3. การดำเนินงานวิจัย

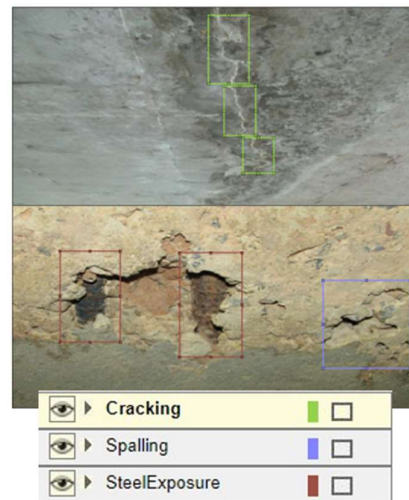
งานวิจัยนี้ดำเนินการศึกษาเฉพาะพื้นสะพานคอนกรีตเสริมเหล็กของสะพานคอนกรีตที่มีช่วงระยะ 10 - 40 เมตร และอยู่ภายในขอบเขตของ Eastern Economic Corridor (EEC) โดยงานวิจัยนี้จะมุ่งเน้นไปที่การพัฒนาปัญญาประดิษฐ์เพื่อใช้ในการตรวจสอบความเสียหายของพื้นสะพาน ซึ่งมีขั้นตอนดำเนินงานและรายละเอียดดังนี้

3.1 การวิเคราะห์และรวบรวมข้อมูลจาก dataset ของกรมทางหลวง

เนื่องจาก dataset มีข้อมูลของสะพานหลายๆส่วนด้วยกัน โดยข้อมูลจะมีทั้งชนิดของความเสียหายรวมถึงรูปภาพประกอบของส่วนนั้นๆ ซึ่งการนำข้อมูลส่วนพื้นสะพานออกมาจะต้องทำการคัดกรองจาก dataset ทั้งหมดโดยโปรแกรม MATLAB และมีการวิเคราะห์ความเสียหายเพิ่มเติมอีกครั้งเพื่อให้แน่ใจว่าข้อมูลถูกต้องและสามารถนำไปใช้งานได้

3.2 การ Labeling ข้อมูลภาพความเสียหาย

การ Labeling ข้อมูลภาพความเสียหายจะผ่านโปรแกรม MATLAB เพื่อป้องกันความเสียหายภายในรูป โดยขั้นตอนที่เราจะพิจารณาเฉพาะความเสียหายทั้งหมด 3 กรณีคือ รอยแตก(Cracking), การหลุดร่อน(Spalling), การหลุดร่อนจนเห็นเหล็กเสริม(Steel Exposure)



รูปที่ 1 การ Labeling ข้อมูลภาพความเสียหาย

3.3 การฝึกอบรมปัญญาประดิษฐ์ผ่านโปรแกรม MATLAB

3.3.1 การรวบรวมไฟล์ที่ทำการ Label มาเพื่อใช้ในการทำโมเดลต่อไป

3.3.2 การแบ่งชุดข้อมูลเพื่อใช้ในการ ฝึกโมเดล-ทดสอบโมเดล การฝึกอบรมปัญญาประดิษฐ์ (Train AI) ด้วยวิธี R-CNN (Region Based Convolutional Neural Networks) โดยการใช้อำนาจที่ labeling มาแบ่งเป็น 80% สำหรับการฝึกอบรม (Train) อีก 20% สำหรับการทดสอบ (Test)

3.3.3 การตั้งค่าและการ Train โมเดล

การ Train model จะให้ค่าความแม่นยำ (Accuracy) กับค่าความสูญเสีย (Loss) ออกมา ซึ่ง model ที่เราต้องการควรมีค่า Accuracy ที่สูงและค่า Loss ที่ต่ำ โดยการ Model ที่ได้จากการ Train จะได้ค่า Accuracy และ Loss ค่อนข้างสูงขึ้นอยู่กับ Option ที่เรา Input ลงไป จึงต้องมีการ Trial and error เพื่อหา Model ที่เหมาะสมในการ Test

จากการดำเนินการจะพบว่า การ Train model จะใช้เวลาค่อนข้างนาน เราจึงใช้เทคนิคปรับค่า Option ต่างๆ ให้เสร็จสิ้นแล้วจึงเลือก Train กับ Dataset ขนาดเล็กก่อน (2-3 รูป) และสังเกตว่า Accuracy กับ Loss เป็นไปตามที่คาดหวังหรือไม่ หากเป็นไปตามที่คาดหวังจึงเริ่มทำการ Train โมเดลด้วย Option นี้กับ Dataset ขนาดใหญ่เลย แต่ถ้าไม่เป็นไปตามที่คาดหวังจะทำการเปลี่ยน Option ในการ Train ทั้งนี้ โดยการใช้เทคนิคนี้จะช่วยให้ประหยัดเวลาได้ค่อนข้างมาก

3.3.4 การ Test โดยใช้โมเดล R-CNN (มีการแยกเก็บข้อมูลตามประเภทความเสียหายเพื่อง่ายต่อการประเมินต่อไป)




3.3.5 ปรับเปลี่ยนรูปแบบข้อมูลของ Test Data ที่ได้ทำการ label เพื่อง่ายต่อการเปรียบเทียบกับโมเดล

3.3.6 การประเมินโมเดล

ในการประเมินโมเดล จะทำการประเมินข้อมูลจากที่โมเดลทำนายเทียบกับ ส่วนที่กลุ่มเราทำการลาเบลไป และใช้อัตราส่วน Threshold ในการนับว่าภาพนั้นถูกต้อง

3.4 การทดสอบ Model R-CNN กับรูปภาพจริง

นำโมเดลที่ได้จากการ Train มาทำการทดสอบกับรูปภาพจริงได้ผลลัพธ์เป็นรูปภาพพร้อมกับเปอร์เซ็นต์ความมั่นใจ (Confident level) โดยจะเลือกเฉพาะ Confidence level มากกว่า 50%



รูปที่ 2-4 ตัวอย่างการทดสอบโมเดลบนภาพจริง

3.5 การคำนวณค่าที่สนใจ


ค่าต่างๆ เหล่านี้จะเป็นค่าที่ใช้ในการประเมินประสิทธิภาพในการทำงานของตัวโมเดล โดยจะเป็นการเปรียบเทียบผลการคาดเดาของตัวโมเดลกับฐานข้อมูลที่กำหนดไว้ โดยค่าเหล่านี้จะถูกใช้ในการประเมินว่าเหมาะแก่การใช้งานหรือไม่

3.5.1 Accuracy

ค่า Accuracy หมายถึงความแม่นยำในการตรวจจับภาพหรือระบุวัตถุหรือลักษณะต่างๆ ในภาพ โดยจะนิยามว่าเป็นอัตราส่วนระหว่างข้อมูลที่ถูกต้อง (True Positive) ต่อข้อมูลที่ถูกต้องทั้งหมด

$$Accuracy = \frac{Correct\ prediction}{All\ prediction}$$

$$Accuracy = \frac{TP}{TP + FP}$$



รูปที่ 5 แผนภาพแสดงสูตรคำนวณค่า Accuracy

4.1.2 Precision

ค่า Precision หมายถึงความแม่นยำในการตรวจจับหรือระบุวัตถุหรือลักษณะต่างๆในภาพโดยจะนิยามว่าเป็นอัตราส่วนระหว่างข้อมูลที่ถูกต้องจับถูกต้อง (True Positive) ต่อข้อมูลที่ถูกต้องจับของแต่ละชนิดข้อมูล โดยค่า Precision มีสูตรการคำนวณดังนี้

$$Precision = \frac{Correct\ prediction_{Class\ A}}{All\ prediction_{Class\ A}}$$

$$Precision = \frac{TP_{Class\ A}}{TP_{Class\ A} + FP_{Class\ A}}$$

ซึ่งค่า Precision ที่สูงแสดงถึงการตรวจจับหรือการระบุที่มีความแม่นยำสูงและมีความน่าเชื่อถือในการใช้งานของผลลัพธ์ที่ได้สูงมาก ในขณะที่ค่า Precision ที่ต่ำแสดงถึงการระบุหรือตรวจจับที่ไม่แม่นยำหรือมีข้อผิดพลาดในการตรวจจับวัตถุในภาพ


4.1.3 Recall

ค่า Recall หมายถึงความสามารถในการตรวจจับหรือระบุวัตถุหรือลักษณะต่างๆในภาพที่มีอยู่จริง ซึ่งค่า Recall นิยามว่าเป็นอัตราส่วนระหว่างจำนวนข้อมูลที่ถูกต้องจับหรือระบุถูกต้องต่อจำนวนข้อมูลทั้งหมดที่มีจริงในภาพ (labelled data) โดยค่า Recall มีสูตรการคำนวณดังนี้

$$Recall = \frac{Correct\ prediction_{Class\ A}}{All\ labeled\ data_{Class\ A}}$$

$$Recall = \frac{TP_{Class\ A}}{TP_{Class\ A} + FN_{Class\ A}}$$

โดยการคำนวณค่า Recall ช่วยให้เราเข้าใจถึงประสิทธิภาพของระบบหรือวิธีการตรวจจับหรือระบุในการจดจำหรือตรวจจับวัตถุในภาพ โดยการวัดว่าระบบสามารถตรวจจับหรือระบุวัตถุที่เราสนใจได้อย่างไรในเชิงรวมโดยพิจารณาทั้งจำนวนข้อมูลที่ระบบตรวจจับหรือระบุได้ถูกต้องและที่พลาดไป



รูปที่ 6 แผนภาพแสดงสูตรการคำนวณค่า Recall และ Precision

4.1.4 F-1 Score

ค่า F-1 Score คือค่าที่ใช้ในการประเมินประสิทธิภาพของโมเดล โดยการใช้ข้อมูลทั้ง Precision และ Recall ในหารคำนวณค่า F-1 Score โดยการคำนวณค่า F-1 Score มีสูตรดังนี้

$$F1 = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

ค่า F-1 Score จะมีค่าอยู่ในช่วง 0 ถึง 1 ซึ่งค่า 1 หมายถึง Precision และ Recall ที่ดีเยี่ยม และค่า 0 หมายถึงประสิทธิภาพที่ไม่ดี

4. ผลงานวิจัย


4.1 ผลการคำนวณ

ผลการคำนวณค่าต่างๆที่ได้จากการนำโมเดลที่ได้ไป Test จะพบว่ามีค่าต่างๆดังนี้

Test results							
Test sample type	Number of labeled sample	Number of detect by model	Number of correct detect	Precision	Recall	F1-Score	Accuracy
Concrete cracks	116	52	32	61.54%	27.59%	38.10%	46.13%
Concrete spalling	142	114	50	43.86%	35.21%	39.06%	
Reinforcement exposure	182	105	43	40.95%	23.63%	29.97%	

ตารางที่ 1 ตารางแสดงผลลัพธ์ค่าที่สนใจ

จากผลการดำเนินการจะเห็นว่าค่า Precision จะมีค่าเฉลี่ยอยู่ที่ 48.78% และค่า Recall จะมีค่าเฉลี่ยอยู่ที่ 28.81% ซึ่งหมายความว่า การตรวจจับของโมเดลมีโอกาสในการตอบถูกอยู่ที่ 48.78% จากที่ตรวจพบ แต่ความครอบคลุมจะอยู่ที่ 28.81% นั่นคือโมเดลอาจจะตรวจไม่พบข้อมูลความเสียหายทั้งหมดที่มีอยู่ในรูปซึ่งสามารถอธิบายได้ดังตัวอย่างด้านล่าง



รูปที่ 7 ตัวอย่างการตรวจจับของโมเดล

จากรูปจะเห็นว่าตัวโมเดลของเราสามารถตรวจจับและจำแนกประเภทความเสียหายได้ซึ่งมีความแม่นยำอยู่ในช่วง 40 - 60% ซึ่งอยู่ในเกณฑ์ที่ยอมรับได้และสามารถนำไปพัฒนาต่อยอดในเรื่องของความครอบคลุมหรือทำให้ความแม่นยำเพิ่มขึ้นไปอีก

5. สรุปผลการวิจัย

5.1 สรุปผลการดำเนินการ

งานวิจัยนี้มีวัตถุประสงค์เพื่อการศึกษาทฤษฎีและเทคโนโลยีที่เกี่ยวข้องกับปัญญาประดิษฐ์ ซึ่งจะเป็นการรวบรวมข้อมูลรูปภาพจาก

กรมทางหลวงฯ ภาววิเคราะห์และจำแนกเฉพาะความเสียหายของพื้น สะพาน 3 ชนิดได้แก่ รอยแตก (Cracking), การหลุดร่อน (Spalling), และการหลุดร่อนจนเห็นเหล็กเสริม (Steel Exposure) โดยมีเป้าหมาย เพื่อที่จะออกแบบและสร้างระบบตรวจสอบความเสียหายด้วย ปัญญาประดิษฐ์โดยสามารถสรุปผลงานวิจัยได้ดังนี้

5.1.1 ประสิทธิภาพของปัญญาประดิษฐ์ในการตรวจจับรอยแตก (Cracking)

มีความแม่นยำในการตรวจจับและจำแนกชนิดความเสียหาย (Precision) อยู่ที่ 61.54% และมีค่าความครอบคลุม (Recall) อยู่ที่ 27.59% ซึ่งสามารถสรุปได้ว่าตัวปัญญาประดิษฐ์มีความสามารถในการ ตรวจจับและจำแนกชนิดความเสียหายอยู่ในเกณฑ์ที่พอรับได้ แต่มี ความครอบคลุมที่น้อยจึงอาจไม่สามารถตรวจจับความเสียหายได้ครบ ทั้งหมดภายใน 1 รูป

5.1.2 ประสิทธิภาพของปัญญาประดิษฐ์ในการตรวจจับการหลุด ร่อน (Spalling)

มีความแม่นยำในการตรวจจับและจำแนกชนิดความเสียหาย (Precision) อยู่ที่ 43.68% และมีค่าความครอบคลุม (Recall) อยู่ที่ 35.21% ซึ่งสามารถสรุปได้ว่ามีความแม่นยำและความครอบคลุมค่อนข้าง น้อยซึ่งมีผลมาจากรูปภาพที่มีสิ่งก่อกวนมากเช่น แสง เงา และต้นไม้ เป็นต้น และการ Label ข้อมูลที่ไม่เหมาะสมกับชนิดข้อมูลส่งผลให้มีค่า ใน Database ที่มีความละเอียดเกินไป ทำให้ Precision และ Recall มี ค่าที่ต่ำลง

5.1.3 ประสิทธิภาพของปัญญาประดิษฐ์ในการตรวจจับการหลุด ร่อนจนเห็นเหล็กเสริม (Steel Exposure)

มีความแม่นยำในการตรวจจับและจำแนกชนิดความเสียหาย (Precision) อยู่ที่ 40.95% และมีค่าความครอบคลุม (Recall) อยู่ที่ 23.63% ซึ่งสามารถสรุปได้ว่ามีความแม่นยำและความครอบคลุมน้อย ที่สุดเมื่อเปรียบเทียบกับความเสียหายอีก 2 ชนิด เนื่องจากความ เสียหายชนิดนี้นั้นมีลักษณะเป็นแท่งสี่เหลี่ยมตรงกลาง ซึ่งทำให้โมเดลเกิด ความสับสนเมื่อตรวจจับเจอวัตถุอื่น ๆ ที่มีลักษณะเดียวกันเช่น กิ่งไม้ และเงา เป็นต้น ส่งผลให้ Precision และ Recall มีค่าต่ำลงอย่างเห็นได้ ชัด

5.2 ข้อเสนอแนะ

จากปัญหาที่เกิดขึ้นในงานวิจัยจะพบว่าสามารถพัฒนา ผลลัพธ์ของประสิทธิภาพของปัญญาประดิษฐ์ได้ด้วยวิธีการดังต่อไปนี้

5.2.1 การใช้รูปภาพที่ปราศจากสิ่งรบกวนและรูปที่มีความคมชัด มากขึ้นในการทดสอบโมเดล เพื่อให้ปัญญาประดิษฐ์ไม่เกิด ความสับสน

5.2.2 ทำการตัดรูปภาพให้เห็นเพียงความเสียหายก่อนนำไป ทดสอบเพื่อไม่ให้เกิดการตรวจจับที่ผิดพลาด

5.2.3 การเพิ่มจำนวนข้อมูลรูปภาพในการ Train และ Test ของตัว โมเดลเพราะจะทำให้ปัญญาประดิษฐ์มีประสิทธิภาพในการ ทำงานมากขึ้น

5.2.4 การ Label ให้เหมาะสมกับชนิดความเสียหาย โดยความ ความเสียหายขนาดเล็กเช่น รอยแตก (Cracking) ควรทำ

การ Label เป็นขนาดเล็ก ในขณะที่การหลุดร่อน (Spalling) และการหลุดร่อนจนเห็นเหล็กเสริม (Steel Exposure) ซึ่งมี พื้นที่ของความเสียหายเป็นบริเวณกว้าง ไม่ควรทำเป็น ขนาดเล็ก เพราะจะทำให้ตรวจจับได้ยากและส่งผลกระทบต่อ Precision และ Recall มีค่าต่ำลง

กิตติกรรมประกาศ

โครงการการตรวจสอบความเสียหายโดยใช้ปัญญาประดิษฐ์ สำหรับการประเมินพื้นสะพานฉบับนี้สามารถดำเนินการจนประสบ ความสำเร็จลุล่วงไปด้วยดี โดยได้รับความอนุเคราะห์และการสนับสนุน เป็นอย่างยิ่งจาก รศ.ดร.ธิดารัตน์ วิสุทธิเสวีวงศ์ อาจารย์ที่ปรึกษา โครงการนี้ที่ได้ให้คำปรึกษาและคำแนะนำที่เป็นประโยชน์ในการพัฒนา และแก้ไขปัญหาที่เกิดขึ้น

นอกจากนี้คณะผู้วิจัยยังขอขอบคุณคณาจารย์และผู้ให้ความ ช่วยเหลือทุกท่าน ที่ให้ความกรุณาแนะนำ ที่สละเวลามาให้ความรู้และ แนวทางในการดำเนินโครงการงานวิจัยนี้

สุดท้ายนี้คณะผู้วิจัยหวังเป็นอย่างยิ่งว่างานวิจัยฉบับนี้นี้จะเป็น ประโยชน์สำหรับบุคคลที่เกี่ยวข้องและผู้สนใจศึกษาต่อไป

อ้างอิง

- [1] Arafin, P., A. Issa and M. Billah (2022). BRIDGE SURFACE DAMAGE DETECTION USING CONVOLUTIONAL NEURAL NETWORK.
- [2] Chen, L., et al. (2023). "Convolutional neural networks (CNNs)-based multi-category damage detection and recognition of high-speed rail (HSR) reinforced concrete (RC) bridges using test images." Engineering Structures 276: 115306.
- [3] Evidently AI Team. Accuracy, precision, and recall in multi-class classification (n.d.). Retrieved April 19, 2024. from <https://www.evidentlyai.com/classification-metrics/multi-class-metrics>
- [4] Gulgec, N., M. Takáč and S. Pakzad (2017). Structural Damage Detection Using Convolutional Neural Networks: 331-337.
- [5] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth. List of Deep Learning Layers. Deep Learning Toolbox User's Guide (1992-2024). 46-55.
- [6] Natthawat Phongchit. Convolutional Neural Network (CNN) คืออะไร (2018). Retrieved April 15, 2024. from <https://medium.com>
- [7] The MathWorks, Incorporated. Train Fast R-CNN Stop Sign Detector. Computer Vision Toolbox User's Guide (2004-2024). 155-157.