

การตรวจสอบความเสียหายของโครงสร้างส่วนบนของสะพาน

ด้วยโครงข่ายประสาทเทียม

Damage Detection for Superstructure of Bridges

using Artificial Neural Network

กุลพัฒน์ ศรีบุญยะไพโรจน์¹ ปรีวีร์ สุวรรณวารี² ปิยะณัฐ ปิยะณัตต์พิบูล³ และ รศ.ดร.ธิดารัตน์ วิสุทธิเสวีวงศ์⁴

^{1,2,3,4} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพฯ

บทคัดย่อ

สะพานของโครงข่ายทางหลวงทั่วประเทศมีจำนวน 17,219 แห่ง และเมื่อแบ่งตามช่วงอายุของสะพาน สะพานที่มีอายุ 30 ปีขึ้นไปมีจำนวน 10,369 แห่งซึ่งมากกว่าครึ่งหนึ่งของทั้งหมด ซึ่งสะพานที่มีอายุ 30 ปีขึ้นไปมักเกิดความเสียหายในระดับที่ควรได้รับการปรับปรุง โดยเฉพาะในเขตระเบียงเศรษฐกิจพิเศษภาคตะวันออก (Eastern Economic Corridor, EEC) ที่มีการจราจรของรถบรรทุกที่หนาแน่น จึงเป็นเหตุให้ต้องมีการตรวจสอบความเสียหายของสะพานเพื่อให้สามารถใช้งานสะพานได้อย่างปลอดภัย แต่ในการตรวจสอบแต่ละครั้งต้องใช้งบประมาณ เวลา และบุคลากรจำนวนมากทำให้การตรวจสอบไม่ทั่วถึงและอาจเกิดอันตราย จึงควรมีเทคโนโลยีในการช่วยตรวจสอบ ดังนั้นโครงงานฉบับนี้จึงมีเป้าหมายที่จะพัฒนาวิธีตรวจสอบความเสียหายของโครงสร้างส่วนบนของสะพาน (Superstructure) โดยจะตรวจสอบไปที่คานตามยาว (Girder) โดยใช้โปรแกรม Matlab ในการสร้างแบบจำลองโดยใช้หลักการตรวจจับวัตถุ (Object detection) ด้วย Deep learning ประมวลผล 2 ครั้ง (Two-stage detector) หรือ R-CNN (Region based Convolutional Neural Networks) โดยมีฐานข้อมูลภาพถ่ายความเสียหาย (Input) จากกรมทางหลวงมาฝึกอบรม (Train) เพื่อให้ได้แบบจำลอง เมื่อนำภาพถ่ายความเสียหายมาวิเคราะห์ผ่านแบบจำลอง (Output) จะสามารถจำแนกประเภทความเสียหายได้และสามารถระบุระดับความแม่นยำของการจำแนกประเภท เพื่อนำไปหาข้อเสนอแนะในการปรับปรุงสะพานเพื่อความปลอดภัยในการใช้งานและเพื่อให้สะพานสามารถใช้งานได้ต่อไปในอนาคต

คำสำคัญ: ความเสียหายของสะพาน, R-CNN, ความแม่นยำ

Abstract

The national highway network includes 17,219 bridges, with over half (10,369) being more than 30 years old. These older bridges frequently suffer damage that they require renovation. This problem is especially pronounced in the Eastern Economic Corridor (EEC), an area with a lot of heavy truck. To ensure the safe use of these bridges, regular damage inspections are crucial. However, these inspections demands significant budget, time, and manpower, often leading to incomplete assessments and potential safety risks. Therefore, technology to assist in inspections is necessary. This project aims to develop a method for inspecting damage to bridge superstructures, specifically focusing on girders. Using Matlab, the project will create a model employing object detection principles and deep learning, particularly utilizing a two-stage detector or Region-based Convolutional Neural Networks (R-CNN). Damage photographs provided by the Department of Highways will be used to train the model. By analyzing these photographs, the model will be able to classify types of damage and determine the accuracy of these classifications. This data will then inform recommendations for bridge improvements, ensuring their safe use and extending their operational lifespan.

Key words: Damage of Bridges, R-CNN, Accuracy

1. บทนำ

1.1 ที่มาและความสำคัญ

สะพานเป็นสิ่งก่อสร้างที่มีบทบาทสำคัญในโครงข่ายการขนส่งสินค้าและการเดินทางภายในประเทศโดยเฉพาะอย่างยิ่งโครงการพัฒนาเศรษฐกิจในภาคตะวันออก หรือ ECC ปัจจุบันสะพานของโครงข่ายทางหลวงทั่วประเทศมีจำนวน 17,219 สะพาน โดยทั่วไปการแบ่งประเภทสะพานมีได้หลายกรณีตัวอย่างเช่น การแบ่งประเภทตามประเภทการใช้งาน หรือการแบ่งประเภทตามอายุของสะพาน ซึ่งพบว่าอายุของสะพานที่มากกว่า 30 ปี มีจำนวนประมาณ 10,000 สะพานเลยทีเดียว

จากสถิติของจำนวนสะพานที่มีอายุการใช้งานเกิน 30 ปี ซึ่งพบว่าสะพานส่วนใหญ่จะได้รับความเสียหาย ก่อให้เกิดความสูญเสียทั้งทางเศรษฐกิจและสังคมคิดเป็นมูลค่ามหาศาล ความเสียหายที่เกิดขึ้นอาจมีสาเหตุมาจากการรับน้ำหนักบรรทุกที่มากเกินไป ความสามารถของสะพานในการรับน้ำหนัก รวมถึงเมื่อสะพานใช้งานไประยะหนึ่งจะเกิดการเสื่อมสภาพและชำรุดเสียหาย ทำให้ความสามารถในการรับน้ำหนักของสะพานลดลงจากที่ออกแบบไว้เบื้องต้น ทำให้กรมทางหลวงจำเป็นต้องทำการตรวจสอบสภาพและบำรุงรักษาสะพานให้มีระดับการให้บริการที่ดีอยู่เสมอ เพื่อให้ยืดอายุการใช้งานของสะพาน และเพิ่มความปลอดภัยในการใช้งานให้กับประชาชน ปัจจุบันกระบวนการตรวจสอบสะพานด้วยวิธีตรวจสอบโดยใช้ตาเปล่า (Visual inspection) เป็นหนึ่งในวิธีการตรวจสอบความเสียหายเบื้องต้นเพื่อระบุประเภทความเสียหาย โดยสามารถแบ่งความเสียหายออกเป็น รอยแตกร้าว (Cracking) การหลุดล่อน (Spalling) และเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Steel Exposure) โดยวิธีการตรวจสอบนี้จำเป็นต้องใช้ผู้ที่มีความเชี่ยวชาญสูง และต้องมีประสบการณ์ในการตรวจสอบ อีกทั้งวิธีนี้ยังใช้ระยะเวลาในการเก็บข้อมูลนาน และมีการใช้บุคลากรเข้ามาตรวจสอบพร้อมกับการดูแลเฝ้าระวังความปลอดภัยค่อนข้างมาก ทำให้เกิดวิธีการตรวจสอบที่ใช้ความรู้และความสามารถของเทคโนโลยีเข้ามาช่วยทำให้ลดระยะเวลาในการตรวจสอบ รวมถึงลดจำนวนของบุคลากรไปด้วย แต่ยังคงได้ผลที่ถูกต้องและแม่นยำในระดับที่เอาไปใช้งานได้

ดังนั้นงานวิจัยนี้จึงมุ่งเน้นในการพัฒนาวิธีการตรวจสอบคานตามยาวของสะพาน (Girder) โดยใช้ปัญญาประดิษฐ์ (Artificial Intelligence) ซึ่งจะรวบรวมข้อมูลภาพถ่ายความเสียหายของคานตามยาวจากการเก็บภาคสนามของกรมทางหลวงมาใช้เพื่อทำการสอนให้ปัญญาประดิษฐ์สามารถตรวจจับความเสียหายของสะพานได้อย่างแม่นยำในระยะเวลาอันรวดเร็ว ซึ่งจะใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ในการตรวจจับ รวมไปถึงการจำแนกประเภทความเสียหาย ได้แก่ รอยแตกร้าว (Cracking) การหลุดล่อน (Spalling) และเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Steel Exposure) เพื่อประเมินสภาพและระดับความเสียหายของ

คานตามยาว (Girder) และนำไปสู่กระบวนการตรวจสอบเชิงละเอียด เพื่อใช้ในการบำรุงรักษาต่อไป

1.2 วัตถุประสงค์

- เพื่อรวบรวมข้อมูลภาพถ่ายความเสียหายของคานตามยาว (Girder) จากการเก็บภาคสนามของกรมทางหลวง
- เพื่อพัฒนาวิธีการตรวจจับความเสียหายโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)
- เพื่อเสนอการจำแนกประเภทของความเสียหายของคานตามยาวโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)
- เพื่อประเมินสภาพและระดับความเสียหายของคานตามยาว

1.3 ขอบเขตของการศึกษา

- งานวิจัยนี้มุ่งเน้นในการศึกษาสะพานจากฐานข้อมูลภาพถ่ายของกรมทางหลวง เป็นข้อมูลในการจำแนกและประเมินความเสียหายของคานตามยาว (Girder)
- งานวิจัยนี้มุ่งเน้นจำแนกประเภทของความเสียหายทั้งหมด 3 ประเภท ได้แก่ รอยแตกร้าว (Cracking) การหลุดล่อน (Spalling) และเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Steel Exposure)

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- สามารถประยุกต์ใช้ฐานข้อมูลภาพถ่ายของกรมทางหลวงในการระบุความเสียหายของคานตามยาว (Girder)
- สามารถตรวจจับความเสียหายโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)
- สามารถจำแนกประเภทของความเสียหายโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)
- สามารถรู้ระยะเวลาในการตรวจสอบสะพานได้

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 โครงสร้างและองค์ประกอบของสะพาน

การแบ่งประเภทของสะพานมีได้หลายกรณี ตัวอย่างเช่น การแบ่งประเภทตามวัสดุที่ใช้ก่อสร้าง สามารถแบ่งได้ 3 ประเภทคือ สะพานไม้ สะพานเหล็ก และสะพานคอนกรีต

การแบ่งตามลักษณะรูปร่างและโครงสร้างของสะพานแบ่งได้ 8 ประเภท คือ สะพานรูปโค้ง สะพานแบบคาน สะพานที่ขึงด้วย สายเคเบิล สะพานแขวน สะพานแบบคานขนาดใหญ่ สะพานแบบคานยื่น สะพานแบบโครงถัก สะพานแบบโครงข้อแข็ง

การแบ่งประเภทของสะพานตามแบบการก่อสร้างของกรมทางหลวงแบ่งได้ 9 ประเภท คือ


- 1) ระบบพื้นสะพานคอนกรีตเสริมเหล็กแบบหล่อในที่ (Slab Type)
- 2) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปตัวไอ (I-Girder)
- 3) ระบบพื้นสะพานคอนกรีตอัดแรงแบบคาน (Plank Girder)
- 4) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปกล่อง (Box Girder)
- 5) ระบบพื้นสะพานแบบคานคอนกรีตวางประชิด (Multi-Beam)
- 6) ระบบพื้นสะพานแบบคานคอนกรีตเสริมเหล็กรูปตัวทีเหล็กหล่อในที่ (RC T-Girder)
- 7) ระบบพื้นสะพานแบบคานเหล็กรูปตัวไอ (Steel I-Girder)
- 8) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปกล่องหล่อสำเร็จรูป (Segmental Box Girder)
- 9) ระบบพื้นสะพานแบบผสม (Multi Bridge Type)

องค์ประกอบของโครงสร้างสะพานส่วนใหญ่จะมีรูปแบบและลักษณะที่คล้ายคลึงกัน ซึ่งโดยทั่วไปแล้วมักจะแบ่งองค์ประกอบโครงสร้างออกเป็น 3 ส่วนด้วยกัน ได้แก่

1. โครงสร้างสะพานส่วนบน (Superstructure) เป็นส่วนที่อยู่เหนือแผ่นรองรับคาน (Bearing) ขึ้นไป ทำหน้าที่รองรับน้ำหนักจากแผ่นพื้นสะพาน ผิวจราจรของสะพาน และน้ำหนักที่บรรทุกบนแผ่น พื้นสะพาน จุดประสงค์ เพื่อบรรทุกน้ำหนักที่ถ่ายเทมาจากแผ่นพื้นสะพานตลอดความยาวช่วงสะพาน และถ่ายเทต่อไปยังจุดรองรับโครงสร้างส่วนล่าง โดยอาจถ่ายเทโดยผ่านแรงดึง แรงกด แรงอัด หรือทั้งสามแรงนี้รวมกัน สามารถแบ่งประเภทของโครงสร้างสะพานส่วนบนตามหน้าที่และการใช้งานได้ดังนี้ พื้นสะพาน (Deck) คานตามยาว (Girder) และค้ำยันคานตามยาว (Diaphragm)
2. โครงสร้างสะพานส่วนล่าง (Substructure) เป็นชิ้นส่วนต่างๆ ที่อยู่ต่ำกว่าแผ่นรองรับคาน (Bearing) ลงไป จุดประสงค์ของโครงสร้างส่วนล่าง คือ มีหน้าที่รองรับและถ่ายเทน้ำหนักจากโครงสร้างส่วนบนของสะพานให้ลงสู่ฐานราก ชิ้นส่วนต่าง ๆ ของโครงสร้างส่วนล่างจะต้านน้ำหนักทั้งแนวตั้งและแนวราบที่ถูกถ่ายเทมาจากโครงสร้างส่วนบน สามารถแบ่งประเภทของโครงสร้างสะพานส่วนล่างได้ดังนี้ คานรัดหัวเสา (Cap Beam) ค้ำ

ยันตอม่อ (Bracing) เสาตอม่อ (Pier) กำแพงตอม่อ (Pier Wall) ฐานราก (Footing) และเสาเข็ม (Pile)

3. ส่วนประกอบรอง (Secondary Components) เป็นชิ้นส่วนที่ช่วยเสริมการรับน้ำหนักที่กระทำต่อสะพาน หรือมีประโยชน์ต่อสะพานด้านอื่น ๆ เช่น ผิวทาง (Wearing Surface) ช่วยรับน้ำหนักจากล้อรถและกระจายแรงสู่ระบบพื้นและคาน ระบบระบายน้ำ (Drainage) ช่วยในการระบายน้ำที่ซังออกจากผิวทาง ซึ่งส่วนประกอบรองมีดังนี้ หูช้าง (Wing Wall) เียงลาดสะพาน (Approach) แผ่นรองรับคาน (Bearing) รอยต่อเพื่อการขยาย (Expansion Joint) ผิวทาง (Wearing Surface) แผงกั้นจราจร (Traffic Barrier) ราวสะพาน (Railing) ทางเท้า (Sidewalk) ระบบระบายน้ำ (Drainage) กำแพงกันดิน (Retaining Wall) ลาดป้องกันตลิ่ง (Slope Protection)



รูปที่ 2.1 องค์ประกอบสะพาน

2.2 การตรวจสอบสะพาน

การตรวจพินิจ (Visual Inspection) คือ การตรวจสอบด้วยตาเปล่า ประกอบกับอุปกรณ์การตรวจสอบพื้นฐาน เพื่อให้ได้มาซึ่งข้อมูลของความเสียหาย หรือการเสื่อมสภาพของโครงสร้างสะพาน การตรวจสอบวิธีนี้จะเป็นการกำหนดตำแหน่ง และขนาดของความเสียหายในโครงสร้าง ตัวอย่างลักษณะความเสียหายที่พบบ่อย ตัวอย่างเช่น รอยร้าว (Cracking) การหลุดร่อน (Spalling) และอื่น ๆ เป็นต้น

2.3 ประเภทความเสียหายของคานตามยาว (Girder)

คานตามยาว (Girder) เป็นองค์ประกอบหนึ่งในโครงสร้างสะพานส่วนบน (Superstructure) ซึ่งเป็นส่วนที่อยู่เหนือแผ่นรองรับคาน (Bearing) ขึ้นไป และเป็นส่วนของสะพานที่ทำหน้าที่รองรับน้ำหนักจากแผ่นพื้นสะพาน ผิวจราจรของสะพาน และน้ำหนักบรรทุกบนแผ่นพื้นสะพาน

รูปแบบของคานตามยาว (Girder) สามารถแบ่งประเภทของสะพาน เช่น ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปตัวไอ (I-Girder) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงแบบตัน (Plank Girder) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปกล่อง (Box Girder) ระบบพื้นสะพานแบบคานคอนกรีตอัดแรงรูปกล่องหล่อสำเร็จรูป (Segmental Box Girder)

รูปแบบความเสียหายของคานตามยาว ประกอบด้วย

1. รอยแตก (Cracking)
2. การหลุดและ (Spalling)
3. การเกิดรูพรุนเหมือนรังผึ้ง (Honeycombing)
4. การสึกกร่อน (Abrasion)
5. การหลุดร่อน (Spalling)
6. การแอ่นตัวมากกว่าปกติ (Excessive Deflection)
7. ความเสียหายที่เกิดจากการถูกชน (Collision Damage)



รูปที่ 2.2 รอยแตก (Cracking)



รูปที่ 2.3 เหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Steel Exposure)



รูปที่ 2.4 การหลุดล่อน (Spalling)

2.4 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep Learning) เป็นส่วนย่อยที่อยู่ใน Machine Learning (ML) คือการทำให้คอมพิวเตอร์หรือสมองกลเกิดการเรียนรู้จากข้อมูลหรือจากกระบวนการเรียนรู้ด้วยตัวเอง

การเรียนรู้เชิงลึก (Deep Learning) คือการสอนทำให้คอมพิวเตอร์เกิดการเรียนรู้ แล้วนำความรู้ที่นำมาใช้งาน โดยใช้โมเดลที่ได้รับการฝึกฝน ซึ่งใช้ชุดข้อมูลที่มีป้ายกำกับ (Label) จำนวนมากและสถาปัตยกรรมโครงข่ายประสาทเทียม (Artificial Neural Network) ที่ประกอบด้วยหลายชั้น คล้ายการทำงานของเซลล์ประสาทในสมองร่างกายมนุษย์ ตัวอย่างการเรียนรู้เชิงลึก (Deep Learning) ได้แก่ Convolutional Neural Networks (CNN), Fully Convolutional Network (FCN) หรือ Region-based Convolutional Neural Network (R-CNN)

สำหรับตัวอย่างการนำเอาการเรียนรู้เชิงลึก (Deep Learning) มาใช้งาน ได้แก่ การจำแนกภาพ (Image Recognition) การตรวจจับวัตถุ (Object Detection) การรู้จำใบหน้า (Face Recognition) การรู้จำเสียงพูด (Speech Recognition)

2.5 Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) เป็นโครงข่ายประสาทเทียม (Artificial Neural Network) สำหรับประมวลผลภาพโดยใช้การเรียนรู้เชิงลึก (Deep Learning) ที่มีหลักการมาจากการทำงานของระบบประสาทการมองเห็นมนุษย์ ที่มองวัตถุหรือภาพใด ๆ เป็นพื้นที่ย่อย ๆ ซึ่งจะทำการแยกคุณลักษณะเด่นเอาไว้เพื่อนำไปประกอบการพิจารณา จากนั้นจะนำเอากลุ่มลักษณะเด่นของพื้นที่ย่อยมาพิจารณาร่วมกัน เพื่อให้ได้รายละเอียดและวิเคราะห์ว่าวัตถุหรือภาพนั้นคืออะไร

กระบวนการของ CNN ประกอบด้วยสองส่วนหลักคือ การสกัดคุณลักษณะ (Feature Extraction) และ โครงข่ายประสาทเทียม (Neural Network) โดยที่ การสกัดคุณลักษณะ

(Feature Extraction) อาศัยหลักการประมวลผลภาพเพื่อทำการแยกเอาคุณลักษณะเด่นของวัตถุที่อยู่ในภาพออกมา เช่น เส้นขอบ เส้นโค้ง เส้นเอียง จากนั้นนำเอาข้อมูลเหล่านี้เข้าไปประมวลผลในโครงข่ายประสาทเทียม (Neural Network) ต่อไป

สถาปัตยกรรม CNN (CNN architecture) ประกอบด้วยชั้น (Layer) ดังนี้

1. Convolutional Layer เป็นชั้น (Layer) แรกที่ใช้สำหรับการสกัดแยกคุณสมบัตินี้ (Feature Extraction) จากภาพที่นำเข้ามา (input) โดยจะใช้ตัวกรอง (Kernel) เลื่อนไปบนรูปภาพและคำนวณผลคูณจุดระหว่างน้ำหนักของตัวกรองกับพิกเซล (Pixel) ของรูปภาพ โดยเมื่อตัวกรองเลื่อนตามรูปภาพ จะได้ผลลัพธ์เป็นแผนที่ลักษณะ ซึ่งเป็นผลลัพธ์ของการสกัดลักษณะ (Feature Extraction) จากรูปภาพนำเข้า
2. Pooling Layer เป็นชั้นการจัดกลุ่มที่มีจุดประสงค์หลักในการลดขนาดของแผนที่ลักษณะ (Feature map) เพื่อลดความซับซ้อนในการคำนวณ การลดขนาดนี้สามารถทำได้โดยการลดการเชื่อมต่อกันระหว่างชั้น และการดำเนินการอย่างอิสระบนแต่ละแผนที่ลักษณะ (Feature map) ขึ้นอยู่กับวิธีการที่ใช้ เช่น การจัดกลุ่มแบบ Max pooling และ average pooling
3. Fully Connected Layer เป็นชั้นที่มักจะถูกวางไว้ก่อนชั้นเอาต์พุต (Output Layer) และเป็นชั้นสุดท้ายของโครงสร้างของ CNN โดยที่ภาพแผนที่ลักษณะ (Feature map) ที่ได้จากชั้นก่อนหน้า จะมีข้อมูลลักษณะหลายมิติ ดังนั้นระบบจะทำการจัดข้อมูลให้เป็นแบบ Vector 1 มิติ เรียกว่า Flatten แล้วทำการนำเข้า Fully Connected Layer ซึ่งจะประกอบด้วยน้ำหนัก (weight) และไบแอส (Bias) พร้อมกับเซลล์ประสาท (Neurons)

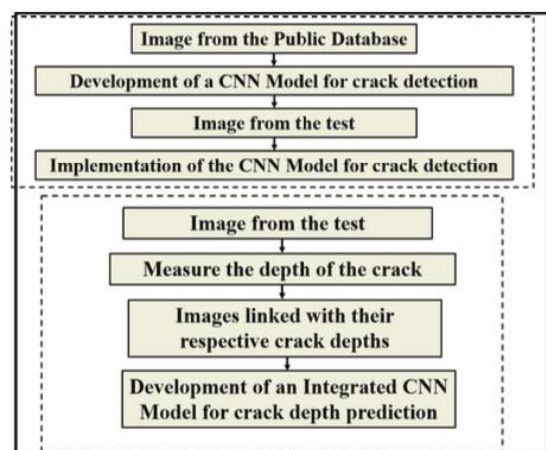
2.6 งานวิจัยที่เกี่ยวข้อง

2.6.1 การตรวจจ็บรอยแตกอัตโนมัติและการคาดการณ์ความลึกของรอยแตกสำหรับโครงสร้างคอนกรีตเสริมเหล็กโดยใช้การเรียนรู้เชิงลึก (Deep Learning)

Laxman K C และคณะ (2023) ใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) เพื่อตรวจจ็บรอยแตกโดยอัตโนมัติและทำนายความลึกของรอยแตกในโครงสร้างคอนกรีต ซึ่งสามารถช่วยประเมินความเสียหาย และกำหนดวิธีการซ่อมแซมที่เหมาะสมได้ โดยใช้แบบจำลอง Convolutional Neural Networks (CNN) ประเภท Binary Class สำหรับการตรวจจ็บรอยแตก และใช้แบบจำลอง CNN แบบบูรณาการ

(integrated CNN) พร้อมกับแบบจำลองการถดถอย (RF and XGBoost) สำหรับการทำนายความลึกของรอยแตกซึ่ง

ได้รับการตรวจสอบบนแผนพื้นคอนกรีตเสริมเหล็ก แบบจำลองใช้เครือข่ายประสาท CNN เพื่อตรวจจ็บรอยแตกบนพื้นผิวคอนกรีตซึ่งใช้ Layer เพื่อแยกคุณสมบัตินี้ออกจากภาพและสามารถจำแนกเป็นรอยแตก หรือไม่เสียหาย ประสิทธิภาพของแบบจำลองได้รับการประเมินโดยใช้เมตริก เช่น ค่าผิดพลาดสี่เหลี่ยมเฉลี่ย (MSE) และค่าสัมประสิทธิ์สหสัมพันธ์ (R2) ผลลัพธ์ของค่าจริงเทียบกับค่าที่คาดการณ์เพื่อเปรียบเทียบกัน ข้อมูลที่ใช้เป็นภาพพื้นผิวคอนกรีตที่นำมาจากอุปกรณ์พกพา และได้มีการระบุ (Label) ความลึกของรอยแตก เพื่อใช้ในการฝึกแบบจำลอง พบว่าแบบจำลอง Convolutional Neural Networks (CNN) ประเภท Binary Class สำหรับการตรวจจ็บรอยแตกมีความแม่นยำสูงในการจำแนกภาพเป็น ไม่เสียหาย หรือ เสียหาย รวมถึงแบบจำลองการถดถอย (RF and XGBoost) สำหรับการทำนายความลึกของรอยแตก ก็มี ความแม่นยำและความน่าเชื่อถือเช่นเดียวกัน




รูปที่ 2.5 ภาพรวมและกรอบการทำงานของทั้ง 2 แบบจำลอง

2.6.2 การตรวจจ็บและระบุความเสียหายหลายหมวดหมู่ในสะพานเหล็กคอนกรีตที่ใช้เป็นทางเร่งความเร็วสูง (HSR) ด้วยใช้ระบบโครงข่ายประสาทเชิงคอนโวลูชัน (CNNs) โดยใช้ภาพทดสอบ

Lingkun Chen และคณะ (2022) ได้เสนอการตรวจสอบโดยใช้ deep CNNs จำแนกและจดจำความเสียหายของโครงสร้างสะพานจากรูป และสร้างระบบตรวจสอบความเสียหายของสะพานอัตโนมัติใน 3 รูปแบบความเสียหาย โดยใช้ migration learning techniques จากการทดสอบชุดข้อมูลตัวอย่างพบว่าสามารถแยกประเภทความเสียหายของสะพานได้อย่างชัดเจน โดยในการทดสอบนี้มีการใช้ภาพนอกเหนือจากตัวอย่างทดลองด้วยการศึกษานี้ทำการเปรียบเทียบระหว่าง Unet model และ Unet +VGG16 model หลังจากการทดลองมากกว่า 50 ครั้งในกลุ่มตัวอย่างเดียวกันพบว่าทั้งคู่สามารถทำงานได้ดีโดยมีเปอร์เซ็นต์ความถูกต้องอยู่ที่ 91.7 % และ 92.3 % ตามลำดับ

3. การดำเนินงานวิจัย


งานวิจัยนี้ดำเนินการศึกษาภาพถ่ายความเสียหายคานตามยาว (Girder) ของสะพานคอนกรีตเสริมเหล็ก ซึ่งเป็นข้อมูลที่ต้องมีการระบุ (Label) ความเสียหาย และประเภทความเสียหาย เพื่อใช้ในการอบรมแบบจำลอง งานวิจัยนี้มีขั้นตอนการดำเนินงานและรายละเอียดดังต่อไปนี้



รูปที่ 3.1 แผนผังการดำเนินงานวิจัย

3.1 ข้อมูลภาพถ่ายความเสียหายจากกรมทางหลวง


ข้อมูลภาพถ่ายความเสียหายส่วนต่าง ๆ ของสะพานคอนกรีตเสริมเหล็ก ที่เก็บรวบรวมโดยกรมทางหลวง นำมาจัดระเบียบข้อมูลเพื่อดูจำนวนข้อมูล และทำการกรองข้อมูลเพื่อเอาข้อมูลเฉพาะภาพถ่ายความเสียหายของชิ้นส่วนคานตามยาว (Girder) ของสะพานคอนกรีตเสริมเหล็ก



รูปที่ 3.2 ภาพถ่ายความเสียหายคานตามยาว (Girder)

3.2 การฝึกอบรมแบบจำลอง (Model training)

ทำการระบุความเสียหาย และประเภทความเสียหาย (Labeling) หลังจากนั้นจะใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่ประมวลผล 2 ครั้ง (Two-stage detector) ประกอบด้วย ตัวแกนหลัก (Backbone) ซึ่งใช้ CNN ประมวลผลทำหน้าที่คัดแยก Feature และคัดขอบเขตส่วนที่สนใจ (Region Proposal) ออกมา ซึ่งเป็นขอบเขตที่คาดว่าจะเป็วัตถุที่สนใจ จากนั้นเข้าสู่การประมวลผลครั้งที่ 2 คือการจำแนก (Classification) ว่าเป็นวัตถุอะไร



รูปที่ 3.3 การตรวจจับแบบประมวลผล 2 ครั้ง (two-stage detector)

R-CNN (Regional Convolutional Neural Network) เป็นเป็นโครงข่าย (Network) การตรวจจับแบบประมวลผล 2 ครั้ง (two-stage detector) ซึ่งเป็นงานวิจัยที่ถูกเขียนโดย Girshick R. et al.


การฝึกอบรมแบบจำลองเพื่อให้แบบจำลองมีความสามารถในการตรวจจับความเสียหาย และสามารถแบ่งประเภทความเสียหายได้

3.3 วิเคราะห์และสรุปงานวิจัย

ดูผลลัพธ์ที่เกิดขึ้นและเปรียบเทียบกับผลลัพธ์จริง เพื่อวิเคราะห์ความถูกต้องและแม่นยำ ทำให้สามารถนำข้อมูลไปใช้ต่อในการดำเนินการวางแผนการบำรุงรักษาสะพานต่อไป

4. ผลการดำเนินงานวิจัย


ในส่วนนี้จะแสดงผลการวิเคราะห์ที่ได้จากการตรวจจับความเสียหายคานตามยาว (Girder) โดยวิเคราะห์จากแบบจำลองที่ได้รับการฝึกฝน (Train) ด้วยภาพถ่ายความเสียหายคานตามยาว (Girder) จากกรมทางหลวง จำนวน 413 ภาพ รูปภาพจะถูกป้อนไปยังโมเดล (Input) และทำการฝึกฝน (Train) ผ่านแบบจำลองเพื่อจัดจำแนกประเภทความเสียหายตามป้ายกำกับ (Label) และระบุค่าความแม่นยำของประเภทความเสียหายนั้น (Output) (รูปที่ 9) K.C. Laxman et al.



รูปที่ 4.1 แผนผังแสดงขั้นตอนการดำเนินงาน

4.1 การวิเคราะห์ประเภทความเสียหายและระดับความแม่นยำ


การวิเคราะห์ประเภทความเสียหายจะถูกจัดประเภท (Image classification) ตามป้ายกำกับที่ระบุ (Label) ได้แก่ รอยแตกร้าว (Cracking), การหลุดล่อน (Spalling) และ เหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (ExposedReinforcement) (รูปที่ 10) ซึ่งผลลัพธ์ (Output) ที่ได้จากแบบจำลองนี้สามารถระบุประเภทความเสียหายได้หลายประเภทในภาพเดียว



รูปที่ 4.2 ประเภทความเสียหายตามป้ายกำกับที่ระบุ (Label)

การวิเคราะห์ระดับความแม่นยำจะระบุความแม่นยำของประเภทความเสียหาย โดยจะได้ค่าความแม่นยำเป็นตัวเลขที่ถูกส่งคืนจากเวกเตอร์ คะแนนที่สูงกว่าบ่งบอกถึงความแม่นยำที่สูงกว่าในตรวจจับ

ความแม่นยำในการฝึกฝน (Training accuracy) จะเพิ่มขึ้นตามจำนวนรอบการฝึกฝน (Epochs) และแสดงให้เห็นว่าการจำแนกประเภทความเสียหายมีความแม่นยำให้ผลลัพธ์ที่เชื่อถือได้ในการตรวจจับความเสียหาย



รูปที่ 4.3 กราฟความสัมพันธ์ระหว่าง Loss-Epochs และ Accuracy-Epochs


4.2 ตัวอย่างผลการตรวจจับประเภทความเสียหายและระดับความแม่นยำ



รูปที่ 4.3 ตัวอย่างผลลัพธ์การตรวจจับ Spalling



รูปที่ 4.5 ตัวอย่างผลลัพธ์การตรวจจับ Spalling



รูปที่ 4.7 ตัวอย่างผลลัพธ์การตรวจจับ ExposedReinforcement และ Spalling



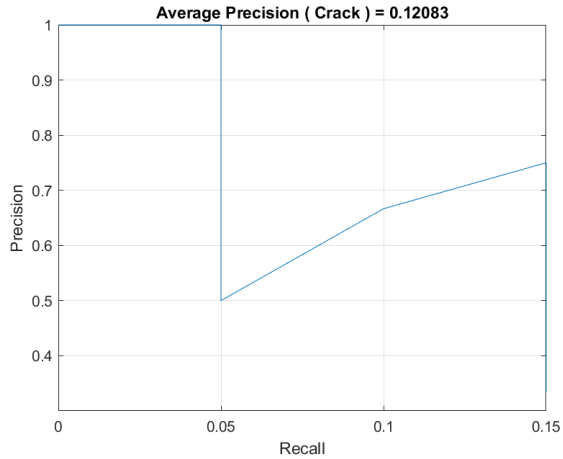
รูปที่ 4.6 ตัวอย่างผลลัพธ์การตรวจจับ ExposedReinforcement



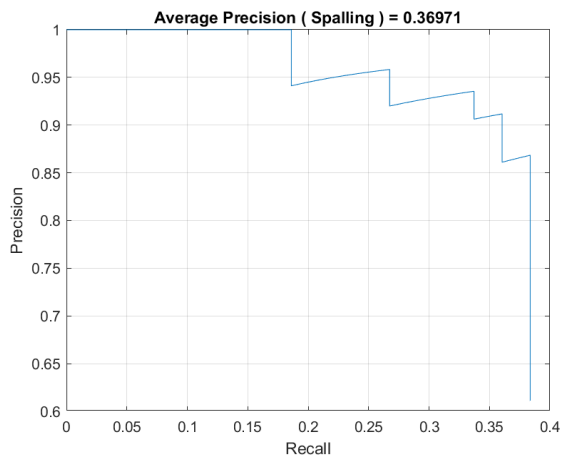
รูปที่ 4.8 ตัวอย่างผลลัพธ์การตรวจจับ Crack

4.3 ผลการประเมินประสิทธิภาพของแบบจำลอง

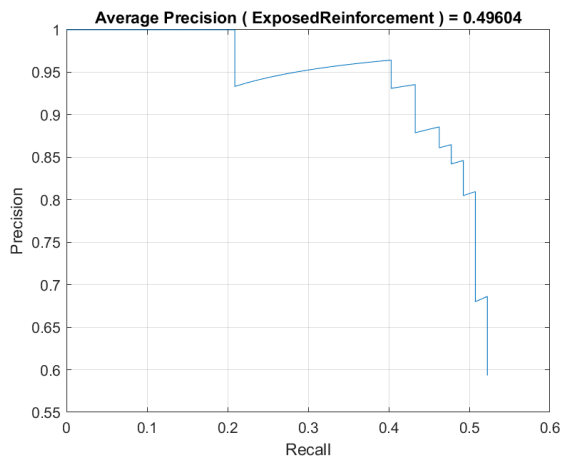
กราฟแสดงความสัมพันธ์ระหว่าง Precision และ Recall ซึ่ง Precision จะแสดงให้เห็นความแม่นยำในการทำนายในกลุ่มเป้าหมาย และ Recall จะแสดงให้เห็นถึงความสามารถในการทำนายหรือตรวจจับสิ่งที่สนใจ



รูปที่ 4.9 Crack Precision-Recall curve



รูปที่ 4.10 Spalling Precision-Recall curve



รูปที่ 4.11 Exposed Reinforcement Precision-Recall curve

4.4 ผลการทดสอบการตรวจจับความเสียหาย

จากการทดสอบการตรวจจับความเสียหายพบว่าจากการตรวจจับรอยแตกร้าว (Crack) จำนวน 31 กรอบ พบว่าตรวจจับได้ 5 กรอบและถูกต้อง 3 กรอบซึ่งคิดเป็นความแม่นยำ Precision 60.00% และ Recall 10.34% จากการตรวจจับการหลุดล่อน (Spalling) จำนวน 70 กรอบ พบว่าตรวจจับได้ 60 กรอบและถูกต้อง 31 กรอบซึ่งคิดเป็นความแม่นยำ Precision 51.67% และ Recall 75.61% และจากการตรวจจับเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Exposed Reinforcement) จำนวน 58 กรอบ พบว่าตรวจจับได้ 30 กรอบและถูกต้อง 17 กรอบซึ่งคิดเป็นความแม่นยำ Precision 56.67% และ Recall 37.78% ดังนั้นจากการตรวจจับความเสียหายทั้งหมด จำนวน 159 กรอบ พบว่าตรวจจับได้ 95 กรอบและถูกต้อง 51 กรอบซึ่งคิดเป็นความแม่นยำ Precision 53.68% และ Recall 44.35%

ตารางที่ 4.1 ผลการทดสอบการตรวจจับความเสียหาย

Test Data	Number of Labeled Test	Number of Prediction	Correct Prediction	Precision	Recall
Crack	31	5	3	60.00%	10.34%
Spalling	70	60	31	51.67%	75.61%
Exposed Reinforcement	58	30	17	56.67%	37.78%
Overall	159	95	51	53.68%	44.35%

5.สรุปผลการวิจัย

การวิจัยนี้มีวัตถุประสงค์การวิจัยเพื่อจำแนกประเภทของความเสียหายของคานตามยาวโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เพื่อลดระยะเวลาและบุคลากรในการจำแนกประเภทด้วยวิธีเดิม และนำไปหาข้อเสนอแนะในการปรับปรุงสะพานเพื่อความปลอดภัยในการใช้งานและเพื่อให้สะพานสามารถใช้งานได้ต่อไปในอนาคต

5.1 สรุปผลการวิจัย

5.1.1 ผลจากการจำแนกประเภทความเสียหายและระดับความแม่นยำ

จากการตรวจจับความเสียหายโดยใช้ภาพถ่าย 80% ไปฝึกฝนแบบจำลองและ 20% ไปทดสอบตรวจจับความเสียหายพบว่า การจำแนกประเภทความเสียหายของแบบจำลองสามารถจำแนกประเภทได้อย่างถูกต้อง ตีกรอบ (Bounding box) อยู่ในตำแหน่งที่เหมาะสมและมีระดับความแม่นยำสูงกว่า 50% จึงสามารถเชื่อถือการตรวจนี้ได้

5.1.2 ผลจากการประเมินประสิทธิภาพของแบบจำลอง

จากกราฟแสดงความสัมพันธ์ Precision-Recall พบว่าผลของรอยแตกร้าว (Crack) ให้ค่าที่แสดงถึงการตรวจจับความเสียหายที่ไม่ดีเนื่องจากกราฟแสดงความสัมพันธ์ แสดงให้เห็นว่าแบบจำลองแทบจะไม่สามารถตรวจจับความเสียหายจากรอยแตกร้าวได้ ส่วนผลของการหลุดล่อน (Spalling) และเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็น (Exposed Reinforcement) แสดงให้เห็นว่าแบบจำลองสามารถตรวจจับความเสียหายได้ในระดับที่ดี โดยเฉพาะรูปแบบความเสียหายแบบการหลุดล่อน (Spalling)

5.1.3 ผลจากการวิเคราะห์การทดสอบ

จากผลการตรวจจับรอยแตกร้าว (Crack) มีความแม่นยำ Precision 60.00% และ Recall 10.34% นั้นหมายถึงแบบจำลองสามารถจำแนกประเภทรอยแตกร้าวได้ดี แต่ไม่สามารถตรวจจับรอยแตกร้าวในภาพได้ดีพอ ส่วนผลการตรวจจับการหลุดล่อน (Spalling) มีความแม่นยำ Precision 51.67% และ Recall 75.61% และเหล็กเสริมในคอนกรีตโผล่ออกมาให้เห็นมีความแม่นยำ Precision 56.67% และ Recall 37.78% และเมื่อนำผลทั้งหมดมาวิเคราะห์พบว่ามีความแม่นยำ Precision 53.68% และ Recall 44.35% ซึ่งถือว่ามีความแม่นยำมากพอสำหรับการตรวจจับความเสียหายในเบื้องต้น

5.2 ข้อเสนอแนะ

จากผลการตรวจจับทั้งหมดจะพบว่ามีความแม่นยำ Precision 53.68% และ Recall 44.35% ในขณะที่ความแม่นยำของการตรวจจับรอยแตกร้าวมีค่าความแม่นยำ Precision 60.00% และ Recall 10.34% เนื่องจากมีตัวอย่างน้อยเกินไปและภาพมีรายละเอียดต่ำ ดังนั้นควรเพิ่มภาพถ่ายรอยร้าวให้มากขึ้น อีกทั้งควรเพิ่มภาพถ่ายความเสียหายทั้งหมดเพื่อให้การฝึกฝนแบบจำลองมีประสิทธิภาพสูงที่สุด

การนำผลที่จะได้จากการทำนายไปประเมินผลเพื่อใช้สำหรับการบำรุงรักษาสะพานในส่วนของคนตามยาว (Girder) จำเป็นจะต้องทำการตรวจสอบโดยละเอียดอีกครั้ง

กิตติกรรมประกาศ

คณะผู้วิจัยขอกราบขอบพระคุณ รศ.ดร.ธิดารัตน์ วิสุทธ์เสรีวงศ์ ผู้เป็นที่ปรึกษาและให้คำแนะนำในการจัดทำโครงการงานวิศวกรรม นอกจากนี้ คณะผู้วิจัย ยังขอกราบขอบพระคุณ กรมทางหลวงและบุคลากรที่ให้ความร่วมมือในการใช้ฐานข้อมูลภาพถ่ายความเสียหาย อนึ่ง ทางคณะวิจัย ขอขอบพระคุณ คุณ ศุภศิษฏ์ ศรีวรานันท์, คุณ อดิชน คุณาวิตรุต, คุณ วรวิวัฒน์ นิลประพันธ์, คุณ ปิยพนธ์ คงทอง ที่ให้คำแนะนำและความรู้ในเรื่องวิธีการใช้โปรแกรม Matlab และความรู้ในเรื่องการตรวจจับวัตถุ (Object detection) ไปจนถึงกระบวนการทำแบบจำลอง สุดท้ายนี้ขอขอบคุณภาควิชา

วิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในความเอื้อเฟื้ออุปการะและเครื่องมือทดสอบตลอดจนเป็นสถานที่ในการศึกษาปฏิบัติการปริญญาโทตั้งแต่เริ่มต้นจนบรรลุผลสำเร็จ

สุดท้ายนี้ หากปริญญาโทฉบับนี้เกิดข้อผิดพลาดหรือข้อบกพร่องประการใด ทางคณะผู้จัดทำ ใคร่ขออภัยมา ณ ที่นี้ด้วย และหวังว่าปริญญาโทฉบับนี้จะมีประโยชน์แก่ผู้อ่านและผู้สนใจศึกษาปริญญาโทฉบับนี้ต่อไป

เอกสารอ้างอิง

สำนักก่อสร้างสะพาน. (2555). คู่มือการสำรวจและตรวจสอบสะพาน.

รองศาสตราจารย์ ดร.กอบเกียรติ สระอุบล. (2565). เรียนรู้ AI: Deep Learning ด้วย Python.

Nishat Tabassum, Li Ai, Casey Cole, Paul Ziehl, Laxman K C. (2023). Automated crack detection and crack depth prediction for reinforced concrete structures using deep learning.

Wenxin Chen, Lu Wang, Chencheng Zhai, Xiaolun Hu, Linlin Sun, Yuan Tian, Xiaoming Huang, Lizhong Jiang Lingkun Chen. (2022). Convolutional neural networks (CNN-s)-based multi-category damage detection and recognition of high-speed rail (HSR) reinforced concrete (RC) bridges using test images.

Jeff Donahue, Trevor Darrell, Jitendra Malik Ross Girshick. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation.