

CRACK DETECTION ON CONCRETE SURFACE BY DEEP LEARNING FROM VGG16 ARCHITECTURE

การตรวจสอบรอยร้าวบนพื้นผิวคอนกรีตด้วยการเรียนรู้เชิงลึกด้วยสถาปัตยกรรม VGG16

พิศุทธิ์วัชร กัลปิยะภณ¹ รกิตพงษ์ สหมิตรมงคล² กฤษฎา ไชยสาร³

¹ นักศึกษาปริญญาโท สาขาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ศูนย์รังสิต

² ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

³ ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ศูนย์รังสิต

ARTICLE INFO:

Received July 2, 2021

Received Revised Form:

July 12, 2021

Accepted: July 19, 2021

ABSTRACT:

Crack is one of the main problems in concrete structure, which is caused by weathering, rust in reinforcing steel, collapse, erosion of structures. Structural inspection is important to verify the usability of structure. Automated crack detection is an essential tool to help improving efficiency in inspection systems. This research presents the methods for automatic crack detection system using a pre-trained convolutional neural network model by transfer learning technique. The transfer learning technique can be customized a pre-trained model with (i) feature extraction, and (ii) fine-tuning. The VGG16 is one of the Convolutional neural network architecture, which is a pre-trained model that will be used to detect cracks on concrete beam images in this paper, and compared results with Spatially Tuned-Robust Multi feature (STRUM features) with the AdaBoost classifier. The classification performance of VGG16 by fine-tuning method is 95.76% accurate and the VGG16 by feature extraction method is 84.56% accurate. The STRUM classification with the AdaBoost classifier is 71.85% accurate.

KEYWORDS: Crack detection, Convolutional neural network, Transfer learning, STRUM, Classification

บทคัดย่อ:

หนึ่งในปัญหาของโครงสร้างคอนกรีตมีสาเหตุมาจากการผุกร่อน, สนิมในเหล็กเสริม, การทรุดตัว, การพังทลายและอื่นๆ การตรวจสอบโครงสร้างนั้นจึงมีความสำคัญในการตรวจการจ้างงานของโครงสร้าง งานวิจัยนี้นำเสนอการนำแบบจำลองโครงข่ายประสาทเทียมที่ได้รับการฝึกมาแล้ว (Pre-trained convolutional neural network model) มาประยุกต์ในการใช้หา รอยร้าวด้วยเทคนิคการถ่ายทอดความรู้ (Transfer learning) ซึ่งมีด้วยกัน 2 วิธีคือ วิธีการดึง คุณสมบัติ (Feature extraction) และวิธีการปรับละเอียด (Fine-tuning) โดยจะเป็นการนำแบบจำลองที่ได้รับการฝึกแล้วคือ VGG16 มาทำการสร้างแบบจำลองใหม่เพื่อใช้สำหรับการตรวจสอบรอยร้าวบนภาพคาน และเปรียบเทียบกับวิธี STRUM (Spatially tuned robust multi feature) ซึ่งเป็นวิธีในการสร้างเวกเตอร์คุณสมบัติ (Feature vector) ในการนำคุณสมบัติพื้นฐาน (Feature-based) ของภาพมาใช้ร่วมกับเครื่องมือในจำแนก (Classifiers) โดยได้นำ AdaBoost classifier มาใช้ในการจำแนกจากคุณสมบัติพื้นฐานของภาพ จากการ

*Corresponding Author,
Email address: ckrisada@engr.tu.ac.th

ศึกษาพบว่าความถูกต้องของแบบจำลอง Convolutional neural network คือแบบจำลอง VGG16 วิธีการ Fine-tuning จะได้ความถูกต้องของการทดสอบมากที่สุดที่ 95.76% และสำหรับแบบจำลอง VGG16 วิธีการ Feature extraction ได้ความถูกต้องที่ 84.56% ส่วนวิธี STRUM เมื่อวิเคราะห์เวกเตอร์คุณสมบัติและจำแนกด้วยการใช้ AdaBoost classifier จะได้ความถูกต้องของการทดสอบคือ 71.85 %

คำสำคัญ: การตรวจหารอยร้าว, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การถ่ายทอดความรู้, คุณสมบัติการปรับแต่งเชิงพื้นที่แบบหลายคุณสมบัติ, การจำแนก

1. บทนำ

ปัญหาอย่างหนึ่งที่มักพบเกี่ยวกับคานคือการเกิดรอยร้าว ซึ่งมักส่งผลเสียต่อโครงสร้างและมักเป็นจุดเริ่มต้นของปัญหา อาจเกิดขึ้นต่อการใช้งานโครงสร้างนั้น เช่น การเกิดการสึกกร่อน การเกิดสนิมของเหล็กเสริมของโครงสร้างคอนกรีตเสริมเหล็ก การเกิดปัญหาพื้นผิวหลุดล่อนเป็นต้น การหลุดตัวของโครงสร้าง การพังทลายของโครงสร้าง เป็นต้น การตรวจสอบโครงสร้างจึงเป็นสิ่งสำคัญ

ในการศึกษานี้จะเป็นการนำโครงข่ายประสาทเทียม หรือ Convolutional Neural Network โดยมีชื่อเรียกสั้นๆว่า CNN หรือ ConvNet โดย Prateek Prasanna [1] อธิบายว่าเป็น CNN นั้นเป็นหนึ่งใน Deep neural network ที่มักใช้กันอย่างแพร่หลายในงานวิเคราะห์ภาพ โดย VGG16 นั้นเป็นสถาปัตยกรรม Convolutional Neural Network ที่มีความเรียบง่ายและมีการซึ่งมักนำไปใช้งานด้านต่างๆ เช่น การจดจำภาพ การจำแนกภาพ การวิเคราะห์ภาพทางการแพทย์ เป็นต้น โดย VGG16 เป็นสถาปัตยกรรมที่บ่งบอกถึงจำนวนชั้นเลเยอร์ทั้งหมด 16 เลเยอร์ โดยในที่นี้จะเป็นการนำแบบจำลอง VGG16 ซึ่งเป็นแบบจำลองโครงข่ายประสาทเทียมที่ได้รับการเรียนฝึกแล้ว (Pre-trained convolutional neural network model) โดย VGG16 ได้ผ่านการเรียนรู้ด้วยชุดข้อมูลภาพของ ImageNet ซึ่งมีจำนวนมากกว่า 14 ล้านภาพและมีจำนวนชนิด (Classes) 1,000 ชนิด และนำมาสร้างเป็นแบบจำลองใหม่โดยใช้เทคนิคการถ่ายโอนความรู้มีด้วยกัน 2 วิธีคือ วิธีการดึงคุณสมบัติ (Feature extraction) จะเป็นวิธีที่นำเอาคุณสมบัติที่ได้จากการฝึกไว้แล้วมาทำการฝึกและจำแนกภาพใหม่ที่เราใช้ในการฝึก และอีกหนึ่งวิธีคือวิธีการปรับละเอียด (Fine-tuning) จะเป็นการนำภาพใหม่มาใช้ในการฝึกและทำการจำแนกควบคู่ไปกับคุณสมบัติมาทำการปรับเพื่อให้ทำงานร่วมกับข้อมูลใหม่ได้ดีขึ้น โดยในการทดสอบนั้นจะเป็นการนำภาพที่มีขนาด 224x224 pixel ในระบบสี RGB มาเข้า

กระบวนการแปลงข้อมูลเข้าสู่กระบวนการ Convolution เพื่อแปลงข้อมูลภาพเพื่อนำมาใช้ในการจำแนก (Classification) และวัดผลความแม่นยำของแบบจำลอง

อีกหนึ่งวิธีที่จะใช้ในการทดสอบเพื่อเปรียบเทียบกันคือวิธี Spatially Tuned Robust Multi Features (STRUM features) ซึ่งถูกใช้โดย Prateek Prasanna [1] ซึ่งเป็นวิธีการที่จะนำเอาคุณสมบัติพื้นฐานของภาพ (Image feature based) ซึ่งเป็นวิธีที่ง่ายและสามารถทำได้โดยอาศัยหลักการทางคณิตศาสตร์เบื้องต้นในการคำนวณเพื่อสร้างเป็นเวกเตอร์คุณสมบัติ (Feature vector) และนำเวกเตอร์ที่ได้นั้นมาทำการจำแนกด้วยเครื่องมือจำแนก (Classifier) อย่าง AdaBoost โดยในการสร้างแบบจำลองจะใช้ชุดข้อมูลเดียวกับที่ใช้ในการสร้างแบบจำลอง CNN มาทำการสร้างแบบจำลองและทดสอบการตรวจหารอยร้าวด้วยเครื่องมือจำแนกที่ได้นำมาใช้สร้างแบบจำลองเพื่อสร้างภาพปะรอยร้าวที่เกิดขึ้น

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 Convolutional Neural Network (CNN)

Convolutional Neural Network หรือ CNN คือ โครงข่ายประสาทเทียมแบบหนึ่งสำหรับการเรียนรู้เชิงลึก (Deep Learning) เหมาะสำหรับนำมาใช้ในงานด้าน การมองเห็นทางคอมพิวเตอร์ (Computer Vision), การจดจำวัตถุ (Object Recognition) โดย CNN จะทำการหา รูปแบบ , พื้นผิว , เส้น , ขอบ , สี หรือลักษณะต่างๆ โดยจะจำลองการมองเห็นเป็นขั้นย่อยๆ และนำมารวมกันเพื่อจำแนกว่าสิ่งนั้นคืออะไร โดยในการแยกนั้นจะเรียกว่า การแยกคุณสมบัติ (Extract Feature) โดยจะทำการดึงคุณสมบัติต่างๆ มาวิเคราะห์รวมกัน โดย CNN มีประโยชน์อย่างมากและทำให้เป็นที่นิยมเพราะ , ความแม่นยำสูง และสามารถนำมาฝึกใหม่ (Retrain) เพื่อนำมาใช้งานเฉพาะทางได้

2.2 Convolutional Neural Network Architecture

สถาปัตยกรรมของ Convolutional Neural Network ประกอบด้วย Layer หลายชั้น หลายประเภท มารวมกันเป็นโครงข่ายซึ่ง โดยในชั้นต่างๆ จะมีการดำเนินการแปลงข้อมูลโดยมีจุดมุ่งหมายเพื่อเรียนรู้ลักษณะเฉพาะของข้อมูลแบ่งได้ดังนี้


- 1) Convolutional Layer คือการนำเข้าสู่ข้อมูลภาพเพื่อกรองข้อมูลซึ่งจะเป็นการเปิดใช้งานบางคุณสมบัติ
- 2) Activation หรือ Rectified Linear Unit (ReLU) คือ เป็นการช่วยการฝึกให้เร็วขึ้นและมีประสิทธิภาพโดยจะทำการคืนค่าที่ติดลบให้เป็น 0 และ และจะคืนค่าที่เป็นบวกตามเมื่อค่าที่ได้จากข้อมูลนั้นเป็นบวก
- 3) Max Pooling คือการหาค่าสูงสุดในระนาบของข้อมูลและเลือกค่ามากที่สุดบนระนาบนั้นมาสร้างข้อมูลสำหรับชุดข้อมูลใหม่
- 4) Fully Connected Layer เป็นขั้นตอนในการคำนวณหาเวกเตอร์ลักษณะเฉพาะโดยผลที่ได้ในขั้นตอนนี้จะเป็นข้อมูลสำหรับการนำเข้าสู่สำหรับกระบวนการแบ่งหมวดหมู่ (Classification) โดยเวกเตอร์นี้จะมีควมน่าจะเป็นสำหรับแต่ละ Class ของภาพนั้นๆ
- 5) Classification Layer เป็นขั้นตอนในการจำแนกประเภท โดยทั่วไปมักจะใช้ Softmax Classifier ในการจำแนก

2.3 Pre-trained Model

Francois Chollet [2] ได้กล่าวเกี่ยวกับ Pre-trained Model นั้นเป็นโมเดลที่ได้รับการเรียนรู้มาแล้วด้วยชุดข้อมูลภาพขนาดเล็ก จำนวนมาก สามารถตรวจหาวัตถุภายใต้จำนวนชนิดของวัตถุที่โมเดลนั้นได้ถูกสอนไว้ ซึ่งถ้าจำนวนชุดข้อมูลสำหรับฝึกนั้นมีมากพอจะมีประโยชน์ในด้าน Computer vision เป็นอย่างมาก โดยในการทดสอบนี้ได้เลือกแบบจำลอง VGG16 มาใช้ในการหารอยร้าว

โดยแบบจำลอง VGG16 เป็น Convolutional Neural Network สำหรับใช้ในการจดจำรูปภาพ (Image Recognition) ซึ่งแบบจำลองนี้จะถูกฝึกด้วยชุดข้อมูลของ ImageNet ที่มีจำนวนภาพมากกว่า 14 ล้านภาพ สามารถจำแนกได้ 1,000 ประเภท โดยแบบจำลอง VGG16 จะไม่สามารถนำมาใช้ในการจำแนกรอยร้าวบนพื้นผิวคอนกรีตได้เนื่องจากไม่มีฐานข้อมูลเกี่ยวกับรอยร้าว คอนกรีตจึงไม่สามารถนำมาใช้ในการจำแนกรอยร้าวได้ ในการนำมาใช้ตรวจหารอยร้าว นั้นสามารถทำได้โดยนำมาประยุกต์ใช้ร่วมกับเทคนิค Transfer Learning ซึ่งแบ่งเป็น 2 วิธีคือวิธีการดึงคุณสมบัติ (Feature extraction) และ วิธีการปรับละเอียด (Fine

Tuning) ซึ่งทั้ง 2 วิธี เป็นวิธีสำหรับปรับปรุงแบบจำลองให้สามารถใช้งานเฉพาะทางได้



รูปที่ 1 ภาพแสดงสถาปัตยกรรมของโครงข่าย VGG16

2.4 Spatially Tuned Robust Multi Feature (STRUM Features)

Prateek Prasanna [1] ได้อธิบายเกี่ยวกับการใช้งาน STRUM Features ที่ถูกพัฒนาเพื่อให้ได้ความถูกต้องที่มีประสิทธิภาพสูงบนรูปของพื้นผิวคอนกรีต อัลกอริทึม STRUM เริ่มจากกำหนดพื้นที่รอยร้าวที่อาจเกิดขึ้นแม้ในที่ที่มีสิ่งรบกวน คุณสมบัติการมองเห็นเชิงพื้นที่จะถูกปรับให้เข้ากับพื้นที่ที่มีการคำนวณไว้แล้ว การคำนวณคุณสมบัติการมองเห็นนี้รวมถึงความสามารถในการปรับขนาดพื้นที่เพื่อวิเคราะห์รอยแตกที่ไม่รู้จัก ชุดการรวมกันคุณสมบัติด้านการมองเห็นที่เป็นไปได้จะได้รับการประเมินด้วยการทดสอบด้วย Classifier โดย STRUM Classifier มีส่วนประกอบหลักด้วยกัน 3 ส่วนคือ

- 1) Robust line segment detector
- 2) Spatially tuned multiple feature
- 3) Machine learning classifier

ส่วนสำคัญของวิธีนี้คือการนำเข้าสู่ข้อมูลไปยัง Classifier มาตรฐาน นั่นคือเวกเตอร์ของลักษณะรอยแตกที่ได้จาก STRUM โดยเป็นการรวมคุณสมบัติหลายตัวเข้าด้วยกันเพื่อให้ได้ผลการจำแนกที่ดีที่สุด แบ่งเป็น 3 ชุด ดังนี้

- 1) คุณสมบัติพื้นฐานทางความเข้มสี (Intensity based features)
- 2) คุณสมบัติพื้นฐานทางการไล่สี (Gradient based features)
- 3) คุณสมบัติขนาดพื้นที่ (Scale space features)

คุณสมบัติพื้นฐานทางความเข้มสี (Intensity based features) และ คุณสมบัติพื้นฐานทางการไล่สี (Gradient based features) คุณสมบัติการปรับเชิงพื้นที่ (Spatially tuned features) ให้การระบุประเภทเชิงปริมาณตลอดแนวเส้น ตัวอย่างเช่น ค่าเฉลี่ยความเข้มสีตลอดแนวเส้นจะถูกเลือกมาประกอบเป็นคุณสมบัติเพราะ พิกเซลของภาพที่เป็นรอยร้าวจะมีค่าความเข้มสีที่ต่ำ อย่างไรก็ตามคุณสมบัติเดียวนั้นไม่พอสำหรับการจำแนกให้ได้ความถูกต้องที่สูง สำหรับรอยร้าวที่เล็กมาก ๆ ความมืดของความเข้มสีของ พิกเซลทำให้ไม่น่าเชื่อถือ รวมถึงจุดมืดตลอดแนวเส้นในระนาบที่ไม่มีรอยร้าว เพราะมีค่าเฉลี่ยของความเข้มสีต่ำ หลายๆคุณสมบัติให้สัญญาณที่อ่อนรวมกันในวิธีนี้ โดยเฉพาะการใช้ชุดคุณสมบัติพื้นฐานของความเข้มสีที่คำนวณจากพิกเซลโดยใช้ทั้งหมด 5 คุณสมบัติดังนี้

- 1) ค่าเฉลี่ยของความเข้มสีในระบบฮิสโตแกรม
- 2) ส่วนเบี่ยงเบนมาตรฐานของความเข้มสี
- 3) ค่าเฉลี่ยของขนาดการไล่ระดับสี
- 4) ส่วนเบี่ยงเบนมาตรฐานของขนาดการไล่ระดับสี

5) อัตราส่วนระหว่างค่าเฉลี่ยตามแนวเส้นเทียบกับค่าเฉลี่ยของความเข้มสีของระนาบ

คุณสมบัติของขนาดพื้นที่ (Scale space feature) รูปภาพที่นำมาใช้มีรอยร้าวที่มีขนาดแตกต่างกันโดยมีขนาดเล็กระดับ มิลลิเมตรไปจนถึงเป็นเซนติเมตร Laplacian pyramids เป็นวิธีที่หยาดถึงละเอียดซึ่งมีส่วนช่วยในการค้นหาขนาดพื้นที่ โครงสร้างของภาพอย่างรอยร้าวมีความสำคัญเป็นพิเศษ นั่นคือมันโดดเด่นที่สุดในระดับที่ 1 ของ Laplacian pyramid โดยภาพ Laplacian pyramid แสดงให้เห็นถึงความแตกต่างของย่านความถี่เชิงพื้นที่ ซึ่งในระดับที่ 0 จะประกอบไปด้วยข้อมูลภาพที่ความถี่เชิงพื้นที่สูงสุดและระดับที่ตามมามีความสอดคล้องกับย่านความถี่เชิงพื้นที่ที่ต่ำกว่า ในส่วนนี้แทนที่จะใช้ ค่าความเข้มสีของพิกเซล ค่า Laplacian pyramid เป็นค่าเฉลี่ยทั้งพริมาตรระดับที่ 1, 2 และ 3 คุณสมบัติขนาดพื้นที่ประกอบไปด้วยคุณสมบัติของ Laplacian pyramid ดังนี้

- 1) ค่ามากที่สุดของ Laplacian pyramid ทั้ง 3 ระดับ
- 2) ค่าน้อยสุดของ Laplacian pyramid ทั้ง 3 ระดับ
- 3) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 1
- 4) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 2
- 5) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 3

3. วิธีการศึกษา

ในการศึกษานี้จะทำการสร้างแบบจำลองทั้งหมด 2 วิธีหลักคือ การประยุกต์แบบจำลอง VGG16 เข้ากับชุดข้อมูลที่เตรียมไว้ และ วิธี STRUM ที่จำแนกด้วย Classifier โดยเริ่มต้นจากการเก็บข้อมูลภาพรอยร้าวเพื่อมาทำการสร้างชุดข้อมูลสำหรับการสร้างแบบจำลอง ในส่วนของการสร้างแบบจำลองโดยการประยุกต์แบบจำลอง VGG16 แบ่งย่อยออกเป็น 2 แบบ โดยสร้างแบบจำลองใหม่โดยใช้เทคนิค Transfer learning ซึ่งมี 2 วิธีคือ Feature extraction และ Fine-tuning เข้ามาประยุกต์ ในส่วนของวิธี STRUM ที่จำแนกด้วย Classifier นั้นจะทำการสร้างแบบจำลองโดยเลือก AdaBoost มาเป็นตัวจำแนก ดังนั้นจะมีแบบจำลองสำหรับทดสอบดังนี้


- 1) แบบจำลอง VGG16 ด้วยวิธี Feature extraction
- 2) แบบจำลอง VGG16 ด้วยวิธี Fine-tuning
- 3) แบบจำลอง STRUM ด้วยตัวจำแนก AdaBoost

3.1 การเตรียมข้อมูลรูปภาพสำหรับการฝึกและการตรวจสอบแบบจำลอง


ในการเตรียมชุดข้อมูลภาพสำหรับการฝึกและตรวจสอบแบบจำลองนั้นจะเป็นการนำภาพพื้นผิวคอนกรีตจากหลายๆแหล่งที่มาเพื่อมาทำการตัดแบ่งจากภาพที่มีขนาดใหญ่ให้ได้ภาพที่มีขนาด 150x150 พิกเซล และแบ่งเป็นกลุ่มภาพที่มีรอยร้าวและไม่มีรอยร้าว ซึ่งในการนำไปทดสอบจะมีการปรับขนาดของภาพให้มีขนาดเป็น 224x224 พิกเซล ตามขนาดที่แบบจำลอง VGG16 กำหนดไว้ โดยมีจำนวนภาพดังตารางที่ 1

ตารางที่ 1 ระยะการก่อดัวของซีเมนต์เพสต์

การฝึก		การตรวจสอบ	
Crack	Non-crack	Crack	Non-crack
10,000	10,000	5,000	5,000



รูปที่ 2 ภาพตัวอย่างชุดข้อมูลภาพพื้นผิวคอนกรีตที่มีรอยร้าว



รูปที่ 3 ภาพตัวอย่างชุดข้อมูลภาพพื้นผิวคอนกรีตที่ไม่มีรอยร้าว


3.2 เทคนิค Transfer Learning และ Fine Tuning

เป็นการนำแบบจำลองสถาปัตยกรรม VGG16 ที่ทำการสอนไว้แล้ว (Pre-trained Model) มาใช้ในการประยุกต์เพื่อการจำแนกแบบเฉพาะทางโดยมีด้วยกัน 2 วิธีดังนี้

1) Feature extraction เป็นวิธีการที่จะดึงเอาคุณสมบัติ (Feature extract) ที่ได้รับการเรียนรู้จากโครงข่ายก่อนหน้าเพื่อดึงคุณลักษณะที่มีความหมายออกมาเพื่อฝึกแบบจำลองใหม่ โดยวิธีนี้จะต้องทำการตรึงแบบจำลองพื้นฐาน (Freezing) เพื่อไม่ให้สถานะของเลเยอร์ที่ถูกดึงไว้ได้รับการอัปเดตหลังจากการฝึกแบบจำลองใหม่

2) Fine Tuning เป็นหนึ่งวิธีที่จะเพิ่มประสิทธิภาพของแบบจำลอง วิธีนี้จะคลายการตรึงแบบจำลองพื้นฐาน

(Unfreezing) โดยจะเทรนร่วมไปกับ Classes ที่เพิ่มเข้ามาใหม่ โดยจุดมุ่งหมายของวิธีนี้คือการปรับให้คุณสมบัติเฉพาะทางให้ทำงานร่วมกับชุดข้อมูลใหม่




รูปที่ 4 ภาพสถาปัตยกรรม VGG16 ที่จะทำการปรับแต่งเพื่อใช้งาน

เมื่อผ่านกระบวนการ Convolution ทั้ง 5 Block มาจะต้องทำการกลับในส่วนของ Fully Connected Layer และ Classification ออกเพื่อไม่ให้แบบจำลองใช้กระบวนการจำแนก ImageNet Classification ที่ติดมากับแบบจำลอง โดยจะทำการเพิ่ม Layer ที่ใช้ในการจำแนกเข้าไปแทนที่ โดยจะเลียนแบบตามสถาปัตยกรรมเดิมของ VGG16 เพื่อใช้ในการตรวจหารอยร้าว

3.3 การสร้าง STRUM Feature

ในการสร้างแบบจำลองด้วยวิธี STRUM นั้นจะต้องสร้างเวกเตอร์คุณสมบัติ (Feature vectors) และกำหนด AdaBoost เป็นเครื่องมือในการจำแนก (Classifier) โดยได้เลือกคุณสมบัติที่จะนำมาสร้างเป็นเวกเตอร์คุณสมบัติ 9 คุณสมบัติดังนี้

- 1) ส่วนเบี่ยงเบนมาตรฐานของความเข้มสี
- 2) ค่าเฉลี่ยของขนาดการไล่ระดับสี
- 3) ส่วนเบี่ยงเบนมาตรฐานของขนาดการไล่ระดับสี
- 4) อัตราส่วนระหว่างค่าเฉลี่ยตามแนวเส้นเทียบกับค่าเฉลี่ยของความเข้มสีของระนาบ
- 5) ค่ามากที่สุดของ Laplacian pyramid ทั้ง 3 ระดับ
- 6) ค่าน้อยสุดของ Laplacian pyramid ทั้ง 3 ระดับ
- 7) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 1
- 8) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 2
- 9) ค่าเฉลี่ยของ Laplacian pyramid ระดับที่ 3




รูปที่ 5 แผนผังแสดงขั้นตอนในการสร้างและทดสอบแบบจำลองในการหารอยร้าว

เมื่อทำการสร้าง Feature vector เสร็จจะต้องนำ Feature vector ของข้อมูลภาพที่เตรียมไว้สำหรับฝึกแบบจำลองมาทำการฝึกแบบจำลอง และเมื่อทำการฝึกสำเร็จจากนั้นจะนำ Feature vector ของชุดข้อมูลภาพคนที่จะนำมาทดสอบเพื่อตรวจสอบส่วนที่มีรอยร้าวโดยใช้ AdaBoost Classifier ในการตรวจและวัดผลค่าความแม่นยำในการทายผลของแบบจำลอง

4. ผลการทดสอบ

ในการทดสอบจะทำการนำภาพพื้นผิวคนที่จะใช้ในการทดสอบนั้นมาทำการแบ่งเป็นภาพที่มีขนาด 150 x 150 พิกเซล ซึ่งจะสามารถแบ่งและจำแนกได้จำนวนภาพตามตารางที่ 2 จากนั้นทำการทดสอบตรวจหารอยร้าว โดยสามารถวัดผลความแม่นยำได้วิธีใช้แบบจำลอง CNN โมเดล VGG16 Fine-tuning สามารถวัดความแม่นยำได้สูงที่สุด 95.76% โดยได้สรุปผลความแม่นยำที่แบบจำลองตรวจหารอยร้าวทั้งหมดไว้ดังตารางที่ 3 เมื่อตรวจหารอยร้าวแล้วระบบจะทำการสร้างเป็นภาพที่แบบจำลองแต่ละแบบตรวจจับว่าเป็นรอยร้าวและจะนำมาเปรียบเทียบกับภาพต้นแบบที่แสดงเฉพาะพื้นที่ที่มีรอยร้าวบริเวณกึ่งกลางคน และนำมาเปรียบเทียบผล




รูปที่ 6 ภาพตัวอย่างพื้นผิวคนที่ใช้ในการทดสอบ

ตารางที่ 2 ระยะการก่อตัวของซีเมนต์เพสต์


	Crack	Non-crack
จำนวนภาพสำหรับใช้ในการทดสอบ	53	2,833

ตารางที่ 3 ผลการวัดความถูกต้องของการหารอยร้าว


Model	Accuracy
VGG16 Feature extraction	84.56%
VGG16 Fine Tuning	95.76%
STRUM AdaBoost	71.85%




รูปที่ 7 กราฟแสดงความถูกต้องของการฝึกและตรวจสอบ
แบบจำลอง VGG16




รูปที่ 8 กราฟแสดงค่าการสูญเสียของข้อมูลของการฝึกและ
ตรวจสอบแบบจำลอง VGG16




รูปที่ 9 ภาพที่ได้จากการหารอยร้าวของแบบจำลอง VGG 16
ด้วยวิธี Transfer Learning




รูปที่ 10 ภาพที่ได้จากการหารอยร้าวของแบบจำลอง VGG 16
ด้วยวิธี Fine tuning



รูปที่ 11 ภาพที่ได้จากการหารอยร้าวของแบบจำลอง STRUM ที่
ใช้ AdaBoost classifier



รูปที่ 12 ภาพต้นแบบที่แสดงเฉพาะรอยร้าวบริเวณกึ่งกลางถนน



VGG16 Feature extraction VGG16 Fine-tuning AdaBoost

รูปที่ 13 ภาพบริเวณที่มีรอยร้าวช่วงกึ่งกลางถนนที่ได้จากการหา
รอยร้าวด้วยของแต่ละแบบจำลอง

จากผลที่ได้จากการตรวจหารอยร้าวโดยใช้แบบจำลองที่เตรียมมา โดยรวมพบว่าทั้ง 3 แบบจำลองสามารถตรวจหารอยร้าวได้ครอบคลุมรอยร้าวที่บริเวณกึ่งกลางถนน ซึ่งเมื่อนำมาเปรียบเทียบกับภาพต้นแบบที่แสดงเฉพาะส่วนที่มีรอยร้าวบริเวณกึ่งกลางถนนเท่านั้น สามารถเห็นได้ว่าแบบจำลองมีความสามารถในการตรวจหารอยร้าวได้ แต่ยังมีพื้นที่ผิดพลาดเช่นรอยเส้นที่ถูกเขียนด้วยปากกานั้นถูกคิดว่าเป็นรอยร้าวไปด้วย หรือขอบของตัวคนที่มีการตัดภาพพื้นหลังออกเป็นสีขาว ซึ่งบ่งบอกถึงความผิดพลาดในการตรวจสอบการหารอยร้าวของของแบบจำลองที่แบบจำลองอาจคิดว่ารอยปากกา หรือขอบของตัวคนที่ไม่โดนตัดภาพพื้นหลังออกนั้น คือรอยร้าวซึ่งนั่นส่งผลให้แบบจำลองมีผลความแม่นยำที่ลดลง แต่ยังถือว่ามีความแม่นยำในการหารอยร้าวได้ แต่จากภาพผลการทดสอบการหารอยร้าวด้วยแบบจำลอง STRUM ที่ใช้ตัวจำแนก AdaBoost นั้นมีความผิดพลาดสูงกว่าแบบจำลองอื่นซึ่งบ่งบอกว่าแบบจำลอง STRUM ที่ใช้ตัวจำแนก AdaBoost นั้นมีความแม่นยำน้อยกว่าแบบจำลองอื่นแต่ยังมีความสามารถที่ตรวจหารอยร้าวจริงได้

5. กิตติกรรมประกาศ

สรุปจากการทดสอบคือแบบจำลอง VGG16 ด้วยเทคนิค Transfer learning ด้วยวิธี Fine-tuning เป็นแบบจำลองที่ได้ผลการ

ทดสอบที่ดีที่สุดจำนวนแบบจำลองที่นำมาทดสอบนี้ สามารถนำไปใช้ในการทดสอบโดยหวังผลได้ มีความถูกต้องที่สูง ถึงแม้จะได้ผลการทดสอบที่ดีที่สุด แต่ผลการทดสอบนั้นเป็นผลที่ได้จากการคาดเดา (Predict) โดยอาศัยคุณสมบัติของแบบจำลองที่ได้จากการฝึกซึ่งมีโอกาสที่จะผิดพลาดได้

ซึ่งในแต่ละแบบจำลองนั้นมีความสามารถในการตรวจหารอยร้าวได้จริงแต่ความแม่นยำจะต่างกันออกไป ซึ่งจากการทดสอบนั้นบ่งบอกว่าแบบจำลองในกลุ่ม Convolutional neural network นั้นมีความสามารถในการตรวจหารอยร้าวได้ดีกว่าแบบจำลอง STRUM ที่ใช้ AdaBoost classifier โดยตรวจพบจุดที่ไม่ใช่รอยร่วน้อยกว่ามากจึงส่งผลให้แบบจำลองในกลุ่ม CNN มีความแม่นยำที่สูงกว่า โดยที่แบบจำลอง STRUM ที่ใช้ AdaBoost classifier นั้นมีความผิดพลาดในการตรวจหารอยร้าวเป็นจำนวนมากซึ่งไปตรวจจับวาร์รอยปากกาที่ขีดเขียนบนพื้นผิวคานคอนกรีตและขอบของตัวคานที่ตัดฉากหลังเป็นสีขาวนั้นเป็นรอยร้าวจึงทำให้แบบจำลองวิเคราะห์ว่าส่วนนั้นเป็นรอยร้าวจึงทำให้ความแม่นยำลดลง

ในการเพิ่มความถูกต้องอาจจะต้องการในส่วนของการปรับภาพสำหรับฝึกแบบจำลองให้มากขึ้นกว่านี้เนื่องจากภาพที่มีอาจจะไม่ครอบคลุมลักษณะพื้นผิวคอนกรีตที่สีคอนกรีตผิดไปจากความเป็นจริง เช่นรอยปากกาหรือสีที่ขีดตำแหน่ง และอีกสิ่งที่สำคัญคือเรื่องแสงของภาพที่เก็บได้และการปรับโทนแสงขาว (White balance) ของกล้องที่เป็นปัจจัยในการเก็บภาพเนื่องจากจะเป็นส่วนหนึ่งที่ทำให้เกิดการเปลี่ยนแปลงของ Intensity ของภาพได้

6. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนการสนับสนุนการวิจัยจากคณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์

7. เอกสารอ้างอิง

[1] Prateek Prasanna. Automated Crack Detection on Concrete Bridges. IEEE Transactions on Automation

Science and Engineering. Vol: 13, Issue: 2, p.591-599, 2014.

[2] Francois Chollet, Deep learning with Python, Manning Publications Co., 2018.

[3] Krisada Chaiyasarn. Crack detection in historical structures based on Convolutional neural networks. International Journal of GEOMATE Vol.15, Issue 51, pp.240-251, 2018.

[4] Mayank Sharma. Concrete crack detection using the integration of convolutional neural networks and support vector machine. Science & Technology Asia, 23, 19-28, 2018.

[5] Krisada Chaiyasarn. Crack detection in masonry structures using the Convolutional neural networks and support vector machine. 35th International Symposium on Automation and Robotics in Construction (ISARC), 2018.