

การตรวจจัดการแตกร่อนของคอนกรีตในอาคารชลประทาน โดยใช้โครงข่ายประสาทแบบเทียมคอนโวลูชัน Spalling Damage Detection in Irrigation Structures using Convolutional Neural Networks

ธนสรณ์ โคคม^{1,*} พรหมพัฒน์ ธัญสิทธิ์ศรี² และ อภิชาติ บัวติก³

^{1,2,3} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ จ.ปทุมธานี

*Corresponding author; E-mail address: thanasan66@gmail.com

บทคัดย่อ

อาคารชลประทานมีบทบาทสำคัญในการจัดการทรัพยากรน้ำ แต่ต้องเผชิญกับปัญหาความเสียหายของโครงสร้างคอนกรีต โดยเฉพาะการแตกร่อนของคอนกรีต (Spalling) ซึ่งพบได้บ่อยในบริเวณที่เข้าถึงยาก และส่งผลกระทบต่อความแข็งแรงและอายุการใช้งานโครงสร้างที่ต้องรับแรงดันน้ำและสภาพแวดล้อมที่มีการเปลี่ยนแปลงตลอดเวลา งานวิจัยนี้จึงนำเสนอการตรวจจัดการแตกร่อนของคอนกรีตในอาคารชลประทานด้วยการพัฒนาปัญญาประดิษฐ์ โดยทำการฝึกแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ด้วยชุดข้อมูลความเสียหายจากหลายแหล่ง รวมทั้งชุดข้อมูลการแตกร่อนที่พัฒนาขึ้นเอง เพื่อนำแบบจำลองมาใช้ตรวจสอบพื้นผิวคอนกรีตที่เป็นข้อมูลจากแบบจำลองสามมิติของอาคารชลประทานที่สร้างจากภาพถ่ายอากาศยานไร้คนขับ (UAV) โดยเริ่มจากเก็บข้อมูลภาพถ่ายอาคารชลประทานที่ต้องการศึกษาโดยใช้อากาศยานไร้คนขับ จากนั้นนำข้อมูลภาพถ่ายที่ได้มาสร้างแบบจำลองสามมิติ ซึ่งในขณะเดียวกันได้พัฒนาชุดข้อมูลการแตกร่อนเพื่อใช้ในการฝึกแบบจำลอง ในขั้นตอนสุดท้ายให้แบบจำลอง CNN ตรวจหาความเสียหายประเภทการแตกร่อนของคอนกรีต ผลลัพธ์ที่ได้พบแบบจำลองสามารถตรวจจัดการแตกร่อนของคอนกรีตและระบุตำแหน่งของความเสียหายดังกล่าวได้อย่างถูกต้อง แม่นยำ ช่วยให้สามารถค้นหาความเสียหายและประเมินผลการตรวจสอบอาคารชลประทานได้อย่างรวดเร็ว โดยทำการทดสอบเปรียบเทียบประสิทธิภาพของแบบจำลอง 4 แบบ ได้แก่ VGG16, VGG19, ResNet101 และ ResNet152 พบว่าแบบจำลอง VGG16 ได้ค่าความถูกต้องมากที่สุดร้อยละ 86.40 ซึ่งเป็นทางเลือกที่เหมาะสมสำหรับการนำไปใช้ในการตรวจสอบอาคารชลประทาน

คำสำคัญ: โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การตรวจจัดการแตกร่อน, อาคารชลประทาน, แบบจำลองสามมิติจากภาพถ่าย

Abstract

Irrigation structures play a crucial role in water resource management but often face deterioration of their concrete components, particularly concrete spalling. This type of damage frequently occurs in hard-to-access areas and significantly affects the strength and service life of structures that are subjected to water pressure and continuously changing environmental

conditions. This study proposes a method for detecting concrete spalling in irrigation structures by developing an artificial intelligence system using a Convolutional Neural Network (CNN). The CNN model was trained with a dataset combining spalling damage data collected from multiple sources and a newly developed spalling dataset. The approach involves capturing aerial images of irrigation structures using an Unmanned Aerial Vehicle (UAV) and creating three-dimensional models (3D models) of the structures. Simultaneously, the spalling dataset was developed and used for CNN model training. In the final stage, the trained CNN model was applied to detect spalling damage on the concrete surfaces of the 3D models. The results demonstrate that the CNN model accurately identified and localized instances of concrete spalling, enabling rapid damage detection and structural assessment of irrigation structures. Four CNN architectures—VGG16, VGG19, ResNet101, and ResNet152—were evaluated and compared. Among these, VGG16 achieved the highest accuracy of 86.40%, making it the most suitable model for practical application in irrigation structure inspections.

Keywords: Convolutional neural network, Spalling Damage Detection, Irrigation structures, Photogrammetry-based 3D

1. บทนำ


ปัจจุบันในการตรวจสอบสภาพอาคารชลประทานของกรมชลประทานนั้น ใช้วิธีการตรวจสอบสภาพอาคารชลประทานด้วยสายตา (Visual Inspection) หรือวิธีการตรวจสอบแบบพินิจ โดยการเดินตรวจสอบสภาพอาคารเพื่อนำข้อมูลที่ได้มาประเมินสภาพอาคารชลประทานด้วยวิธีดัชนีสภาพ (Dam Assessment by Condition Index Method) [1] แต่วิธีการนี้ยังมีข้อจำกัด เช่น ปัญหาเรื่องการเข้าถึงในบริเวณที่เข้าถึงยากและความปลอดภัยในขณะตรวจสอบรวมถึงระยะเวลาในการตรวจสอบอาคารแต่ละแห่ง ซึ่งอาคารชลประทานมีบทบาทความสำคัญอย่างมากต่อการบริหารจัดการน้ำในปัจจุบัน โดยเฉพาะในด้านการเกษตร การอุปโภคบริโภค การป้องกันอุทกภัย และยังคงเผชิญกับปัญหาความเสียหายของโครงสร้างคอนกรีต ซึ่งความเสียหายที่พบได้บ่อยและอยู่ในจุดที่เข้าถึงยากคือ การแตกร่อนของคอนกรีต (Spalling) ซึ่งในฤดูน้ำหลากแต่ละปีอาคารชลประทานต้องรับแรงดันน้ำใน

ปริมาณที่มากและสภาพแวดล้อมที่มีการเปลี่ยนแปลงตลอดเวลาส่งผลต่อความแข็งแรงและอายุการใช้งานโครงสร้าง การตรวจสอบโครงสร้างอาคารชลประทานจึงมีความจำเป็นและกระบวนการในการตรวจสอบมีความสำคัญเป็นอย่างมากเพื่อให้มั่นใจว่าอาคารนั้นมีความมั่นคง แข็งแรง ปลอดภัย พร้อมใช้งาน โดยเฉพาะอาคารชลประทานที่มีอายุการใช้งานที่ยาวนานหรืออาคารชลประทานที่ต้องรับแรงดันน้ำในปริมาณมาก

ดังนั้น งานวิจัยนี้เสนอการตรวจจบบรอยแตกร่อนบนพื้นผิวคอนกรีตของอาคารชลประทานด้วยการพัฒนาแบบจำลองปัญญาประดิษฐ์ โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) [2] ซึ่งทำการฝึกสอนด้วยชุดข้อมูลภาพความเสียหาย ได้แก่ การเกิดคราบเกลือ (Efflorescence) การเปิดผิวของคอนกรีต (Exposed bar) รอยแตกร้าว (Cracks) การแตกร่อน (Spalling) และพื้นผิวที่ไม่มี ความเสียหาย (Background) [3] โดยใช้ข้อมูลรูปภาพจากสาธารณะหลายแหล่งร่วมกับชุดข้อมูลภาพความเสียหายของคอนกรีตที่พัฒนาขึ้นเอง [4] จากนั้นนำแบบจำลองที่พัฒนาขึ้นจากงานวิจัยไปใช้เพื่อวัตถุประสงค์ในการตรวจจบบรอยแตกร่อนที่ปรากฏบนพื้นผิวของโครงสร้างคอนกรีตโดยใช้ข้อมูลที่ได้จากแบบจำลองสามมิติของอาคารชลประทานที่ถูกสร้างขึ้นจากภาพถ่ายอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) [5] สามารถแสดงรายละเอียดของโครงสร้างอาคารชลประทาน พร้อมทั้งพัฒนาความสามารถของแบบจำลองให้สามารถตรวจจบบรอยแตกร่อน [6] และระบุตำแหน่งได้อย่างถูกต้อง แม่นยำ โดยในการศึกษานี้ได้ทดสอบแบบจำลองโครงข่ายประสาทเทียม 4 แบบ ได้แก่ VGG16, [5] [8] VGG19, ResNet101 และ ResNet152 [9] เพื่อเปรียบเทียบประสิทธิภาพ และเลือกแบบจำลองที่มีความแม่นยำสูงที่สุดสำหรับการใช้งานจริงต่อไป ซึ่งวัดประสิทธิภาพของแบบจำลองโดยใช้ Confusion Matrix ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-score โดยในการศึกษานี้ได้เลือกใช้อาคารชลประทานคือประตูระบายน้ำปากคลองบางแก้ว จังหวัดอ่างทอง ในการตรวจจบบรอยแตกร่อน (Spalling) จากแบบจำลองที่พัฒนาขึ้นภายใต้สภาพแวดล้อมจริง ซึ่งช่วยให้ผู้ตรวจสอบสามารถค้นหาและระบุตำแหน่งของการแตกร่อนได้อย่างสะดวก ครบถ้วน ชัดเจนนำไปสู่การวางแผนปรับปรุงบำรุงรักษาซ่อมแซมให้อาคารชลประทานใช้งานได้อย่างมีประสิทธิภาพ

2. ขั้นตอนการศึกษา

ในการพัฒนาแบบจำลอง Convolutional Neural Network (CNN) เพื่อใช้ในการตรวจจบบรอยแตกร่อนจำเป็นต้องมีการเตรียมข้อมูลภาพให้มีความเหมาะสมและมีคุณภาพที่เพียงพอต่อการฝึกและประเมินแบบจำลอง เพื่อให้แบบจำลองสามารถเรียนรู้ของการแตกร่อนได้อย่างแม่นยำ โดยในการศึกษานี้ ได้เลือกใช้สถาปัตยกรรมของแบบจำลองของแบบจำลองโครงข่ายประสาทเทียมคอนโวลูชันจำนวน 4 แบบ ได้แก่ VGG16, VGG19, ResNet101 และ ResNet152 เพื่อศึกษาและเปรียบเทียบประสิทธิภาพ โดยจะเริ่มต้นด้วยการเก็บรวบรวมภาพข้อมูลความเสียหายของคอนกรีตเพื่อนำมาสร้างชุดข้อมูลสำหรับการฝึกสอนและการตรวจสอบความถูกต้องของแบบจำลอง จากนั้นจึงนำผลลัพธ์ที่ได้จากแบบจำลองแต่ละตัวมาเปรียบเทียบเพื่อหาค่าความแม่นยำในการตรวจจบบรอยแตกร่อน เพื่อหาแบบจำลองที่เหมาะสม แม่นยำที่สุดสำหรับการนำไปใช้งานจริงต่อไป



รูปที่ 1 ผังขั้นตอนการศึกษา

2.1 การเตรียมข้อมูลรูปภาพสำหรับการฝึกและการตรวจสอบแบบจำลอง


ในการเตรียมชุดข้อมูลสำหรับฝึกสอนและตรวจสอบประสิทธิภาพของแบบจำลอง ได้ทำการรวบรวมภาพความเสียหายของคอนกรีตซึ่งแบ่งเป็น 5 ประเภทความเสียหาย ได้แก่ การเกิดคราบเกลือ (Efflorescence) การเปิดผิวของคอนกรีต (Exposed bar) รอยแตกร้าว (Cracks) การแตกร่อน (Spalling) และพื้นผิวที่ไม่มี ความเสียหาย (Background) โดยข้อมูลภาพที่นำมาใช้นี้รวบรวมมาจากหลายแหล่ง เช่น ชุดข้อมูลที่เผยแพร่สาธารณะ (Open source datasets) ชุดข้อมูลความเสียหายที่พัฒนาขึ้นเอง ชุดข้อมูลจากหน่วยวิจัย Infrastructure Inspection, Monitoring, Repair and Strengthening (IIMRaS) จากแหล่งข้อมูลทั้งหมดได้ทำการรวบรวมภาพจำนวนทั้งหมด 7,500 ภาพ โดยจัดแบ่งข้อมูลภาพและทำการคัดแยกภาพออกเป็นหมวดหมู่ตามประเภทความเสียหาย ประเภทละ 1,500 ภาพ หลังจากรวบรวมภาพแล้ว นำภาพแต่ละภาพมาตัดแบ่งขนาดให้เท่ากัน คือ 150×150 พิกเซล เพื่อเลือกเฉพาะบริเวณที่มีความเสียหายชัดเจน ลดสิ่งรบกวนที่ไม่มีความจำเป็นออกไปเพื่อความสะดวกในการประมวลผล นอกจากนี้เพื่อเพิ่มความหลากหลายให้กับข้อมูล (Data diversity) ด้วยการประยุกต์ใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) [12] โดยทำการหมุนภาพในมุมต่างๆ ได้แก่ 90, 180 และ 270 องศา การขยายภาพ-ย่อภาพบางส่วน กลับภาพ ซ้าย-ขวา กลับภาพบน-ล่าง เพื่อช่วยเพิ่มจำนวนของชุดข้อมูลภาพโดยไม่เปลี่ยนลักษณะเฉพาะของความเสียหาย ดังแสดงในตารางที่ 1

ตารางที่ 1 จำนวนข้อมูลภาพสำหรับฝึกสอนและประเมินแบบจำลอง

Damage Type (150x150 Pixel)	Total Images	Training Images	Validation Images
Background 	1,500	1,000	500
Efflorescence 	1,500	1,000	500
Exposed bar 	1,500	1,000	500
Cracks 	1,500	1,000	500
Spalling 	1,500	1,000	500
	7,500	5,000	2,500

2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน หรือ CNN เป็นรูปแบบหนึ่งของปัญญาประดิษฐ์ที่ใช้วิเคราะห์และประมวลผลข้อมูลประเภทภาพ โดยเฉพาะ โดยมีจุดเด่นในการเรียนรู้และสกัดคุณลักษณะ (Feature Extraction) หลักการทำงานของ CNN ประกอบด้วยชั้นหลักที่สำคัญคือ ชั้นแรกเรียกว่า Convolutional Layer ทำหน้าที่ดึงคุณลักษณะหรือรายละเอียดสำคัญออกมาจากภาพอินพุตผ่านตัวกรองที่มีขนาดเล็ก ถัดมากคือ Pooling Layer ทำหน้าที่ลดขนาดข้อมูลที่ได้จากชั้นก่อนหน้าให้กระชับขึ้นแต่ยังคงคุณสมบัติสำคัญไว้ จากนั้นข้อมูลจะผ่าน Activation Function เช่น ReLU เพื่อเพิ่มประสิทธิภาพการเรียนรู้ ต่อมาข้อมูลจะถูกส่งไปยัง Fully Connected Layer ซึ่งเชื่อมโยงข้อมูลทั้งหมดเข้าด้วยกันเพื่อใช้ในการจำแนกประเภทหรือคาดการณ์ผลลัพธ์ และสุดท้ายคือ Output Layer ซึ่งแสดงผลลัพธ์ที่ได้



รูปที่ 2 โครงสร้างสถาปัตยกรรม Convolution Neural Network
(ที่มา Ogundokun RO, 2022)

แบบจำลอง VGG16 และ VGG19 เป็นแบบจำลองที่ใช้ในการวิเคราะห์และจำแนกภาพด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน หรือ CNN ซึ่งมีโครงสร้างคล้ายกันและเป็นที่ยอมรับในวงการ Deep Learning โดยแบบจำลอง VGG16 จะมีทั้งหมด 16 เลเยอร์ ขณะที่ VGG19 มีทั้งหมด 19 เลเยอร์ โดยทั้งสองแบบจำลองประกอบไปด้วยเลเยอร์สำคัญหลายชนิด เช่น Convolution Layer ที่ใช้วิเคราะห์และดึงคุณลักษณะของภาพ Activation (ReLU) ที่ช่วยตัดค่าที่เป็นลบออกเพื่อเพิ่มความเร็วในการคำนวณ, Max-Pooling Layer ที่ช่วยลดขนาดของข้อมูลภาพให้เล็กลง และ Fully Connected Layer รวมถึง Softmax Layer ที่ทำหน้าที่จำแนกประเภทภาพพร้อมแสดงความแม่นยำของการจำแนก

ResNet101 และ ResNet152 เป็นแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในกลุ่ม ResNet หรือ Residual Network ที่มีจำนวนชั้นลึกเป็นพิเศษ โดย ResNet101 ประกอบด้วยเลเยอร์ทั้งหมด 101 ชั้น และ ResNet152 ประกอบด้วยเลเยอร์ทั้งหมด 152 ชั้น โครงสร้างของแบบจำลองทั้งสองจะใช้แนวคิด Residual Block หรือที่เรียกว่า "ทางลัด" (Shortcut Connection) ซึ่งเป็นเทคนิคที่ช่วยลดปัญหาการเรียนรู้ได้ช้าเมื่อแบบจำลองมีจำนวนชั้นมากขึ้น ทำให้แบบจำลองสามารถเรียนรู้ข้อมูลที่ซับซ้อนและละเอียดได้ดีขึ้น มีประสิทธิภาพสูงในการจำแนกภาพ การตรวจจับวัตถุ และงานอื่นๆ ที่เกี่ยวข้องกับการวิเคราะห์ภาพ ซึ่งทั้ง ResNet101 และ ResNet152 นิยมถูกนำไปใช้งานในสถานการณ์ที่ต้องการความแม่นยำสูง แม้จะแลกกับการใช้เวลาการฝึกที่ยาวนานขึ้น และต้องการทรัพยากรในการประมวลผลที่มากกว่าแบบจำลองที่มีจำนวนชั้นน้อยกว่า แต่ก็ให้ผลลัพธ์ที่มีประสิทธิภาพและแม่นยำยิ่งขึ้นอย่างเห็นได้ชัด

ทั้งนี้ ในกระบวนการฝึกสอนและประเมินการสอนของงานวิจัยนี้ จะใช้วิธี Stochastic gradient descent (SGD) ร่วมกับการใช้ Momentum [10] เพื่อเพิ่มประสิทธิภาพในการปรับค่าน้ำหนัก ทำให้แบบจำลองสามารถเข้าหาค่าต่ำสุดของการคำนวณหา Loss ได้อย่างรวดเร็วและเสถียรขึ้นในการคำนวณ Loss ที่เกิดขึ้นระหว่างผลลัพธ์ที่ได้จริงและผลลัพธ์ที่แบบจำลองทำนาย โดยค่า Loss ที่ได้จาก SGD จะถูกปรับปรุงในแต่ละรอบของการฝึกสอน (Epoch) กระบวนการจะหยุดสอนเมื่อค่า Loss ที่ได้จาก SGD มีค่าน้อยกว่า 0.0001 ซึ่งแสดงให้เห็นว่าแบบจำลองได้เรียนรู้รูปแบบของข้อมูลอย่างเพียงพอและไม่เกิดการปรับเกินพอดี (Overfitting) การตั้งเกณฑ์นี้ช่วยให้กระบวนการฝึกสอนมีประสิทธิภาพและป้องกันไม่ให้งานหนักเกินไป การใช้ SGD ร่วมกับ Momentum จึงเป็นทางเลือกที่เหมาะสมในการฝึกแบบจำลอง

โดยสามารถปรับค่าพารามิเตอร์ได้อย่างมีประสิทธิภาพและช่วยให้ได้ผลลัพธ์ที่แม่นยำและเสถียร

ในการฝึกแบบจำลองได้มีการกำหนดค่าพารามิเตอร์ที่เหมาะสมเพื่อให้กระบวนการเรียนรู้ของแบบจำลองมีความแม่นยำและมีประสิทธิภาพ โดยพารามิเตอร์ที่กำหนดไว้อย่างเหมาะสม มีรายละเอียดดังตารางที่ 2

ตารางที่ 2 การตั้งค่า Hyper-Parameter

Name of Parameters	Value of Parameters
Batch size	16
Optimization function	Stochastic gradient descent (SGD) With Momentum
Loss function	Categorical cross-entropy
Learning rate (Lr)	1×10^{-4}
Epoch	50
Decay rate	0.90

2.3 การประเมินประสิทธิภาพของแบบจำลอง

ในการศึกษานี้ จะทำการวัดประสิทธิภาพของแบบจำลอง โดยใช้ Confusion Matrix เป็นหลัก หลังจากที่ได้ฝึกสอนแบบจำลองเสร็จสมบูรณ์แล้ว จะนำแบบจำลองไปประเมินประสิทธิภาพโดยใช้ชุดข้อมูลภาพที่ไม่เคยถูกนำไปใช้ในการฝึกสอนหรือประเมินมาก่อน เพื่อให้ผลการทดสอบมีความถูกต้องและน่าเชื่อถือ Confusion Matrix เป็นตารางที่ใช้ในการแสดงผลการจำแนกเปรียบเทียบระหว่างข้อมูลจริง (Actual) กับข้อมูลที่ได้จากการทำนายของแบบจำลอง (Predicted) โดยแบ่งผลออกเป็น 4 กลุ่ม ได้แก่ True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) [9] ดังแสดงในตารางที่ 3 โดยมีคำอธิบายดังนี้

True Positive (TP) คือ จำนวนที่แบบจำลองทำนายว่า "Positive Class" และมีค่าเป็น "Positive Class"

True Negative (TN) คือ จำนวนที่แบบจำลองทำนายว่า "Negative Class" และมีค่าเป็น "Negative Class"

False Positive (FP) คือ จำนวนที่แบบจำลองทำนายว่า "Positive Class" แต่มีค่าเป็น "Negative Class"

False Negative (FN) คือ จำนวนที่แบบจำลองทำนายว่า "Negative Class" แต่มีค่าเป็น "Positive Class"

ตารางที่ 3 ตารางการจำแนกประเภทของการตรวจจับ

Classification		Actual	
		Positive Class	Negative Class
Predicted	Positive Class	TP	FN
	Negative Class	FP	TN

หลังจากการฝึกสอนแบบจำลองเสร็จสมบูรณ์แล้ว จะทำการประเมินประสิทธิภาพของแบบจำลองเพื่อวิเคราะห์ความสามารถในการทำนายโดยใช้วิธีการวัดผลที่สำคัญ ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และ ค่า F1-Score ซึ่งเป็นตัวชี้วัดที่ช่วยให้เข้าใจถึงประสิทธิภาพของแบบจำลองได้อย่างรอบด้านและครอบคลุมดังแสดงในสมการที่ (1) – (4)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Accuracy คือค่าที่บ่งบอกว่าแบบจำลองสามารถทำนายได้แม่นยำ

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Precision คือค่าที่บ่งบอกว่าแบบจำลองทำนายค่าถูกมีความถูกต้องเพียงตรงเพียงใด

$$Recall = \frac{TP}{TP+FN} \quad (3)$$


Recall คือค่าที่บ่งบอกว่าแบบจำลองทำนายถูกเป็นอัตราส่วนเท่าไร

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2TP}{2TP + FP + FN} \quad (4)$$


F1-Score คือค่าที่บ่งบอกถึงประสิทธิภาพของแบบจำลอง

3. ผลการศึกษา

ผลลัพธ์ที่ได้จากการฝึกสอนและการประเมินแบบจำลองทั้ง 4 แบบ ได้แก่ VGG16, VGG19, ResNet101 และ ResNet152 สามารถนำมาเปรียบเทียบได้โดยพิจารณาจากกราฟแสดงค่า Accuracy และค่าความสูญเสีย (Loss) ทั้งในระหว่างการฝึกสอน (Training) และการประเมินผล (Validation) โดยในการศึกษานี้จะเน้นเปรียบเทียบผลการทำนายเฉพาะการแตกร่อน (Spalling) ซึ่งแสดงผลไว้ในรูปที่ 3-4 ส่วนกราฟแสดงค่าความสูญเสียในการฝึกสอนและการประเมินของแบบจำลอง แสดงไว้ในรูปที่ 5-6




รูปที่ 3 กราฟความถูกต้องของการฝึกสอนแบบจำลอง



รูปที่ 4 กราฟความถูกต้องของการประเมินแบบจำลอง



รูปที่ 5 กราฟค่าการสูญเสียของการฝึกสอนแบบจำลอง



รูปที่ 6 กราฟค่าการสูญเสียของการประเมินแบบจำลอง

จากการพิจารณากราฟความถูกต้องของการฝึกสอนเทียบกับการประเมินการสอนแบบจำลอง โดยที่แบบจำลอง VGG16 แสดงค่าความถูกต้องทั้งในระหว่างการฝึกสอนและการตรวจสอบ โดยมีค่า Accuracy สูงถึงร้อยละ 92.30 และค่า Loss อยู่ที่ร้อยละ 25.25 แสดงให้เห็นว่าแบบจำลอง VGG16 มีประสิทธิภาพสูงและมีความเสถียรระหว่างชุดข้อมูลการฝึกและการประเมินสูงมาก โดยแทบไม่มีการ overfitting ขณะที่แบบจำลอง VGG19 แสดงค่าความถูกต้องทั้งในระหว่างการฝึกสอนและการตรวจสอบ โดยมีค่า Accuracy สูงถึงร้อยละ 94.82 และค่า Loss อยู่ที่ร้อยละ 13.94 จากข้อมูลแสดงให้เห็นว่าแบบจำลอง VGG19 มีประสิทธิภาพที่สูงมาก มี Accuracy สูงกว่า และ Loss ต่ำกว่าแบบจำลอง VGG16 เล็กน้อย ซึ่งแสดงให้เห็นว่าแบบจำลอง VGG19 นี้มีศักยภาพสูงในการทำนายข้อมูลใหม่อย่างแม่นยำและมีความเสถียรสูงในส่วนของแบบจำลอง ResNet101 มีประสิทธิภาพใกล้เคียงกับแบบจำลอง VGG16 แต่ต่ำกว่า VGG19 และแบบจำลองสุดท้าย ResNet152 มีประสิทธิภาพต่ำกว่าแบบจำลองอื่นๆ อย่างเห็นได้ชัด ทั้งค่า Accuracy ที่ต่ำกว่า และค่า Loss ที่สูงกว่าทั้ง 4 แบบจำลอง

การประเมินประสิทธิภาพของแบบจำลอง Confusion Matrix ผลลัพธ์การประเมินประสิทธิภาพ (Testing) ของทั้ง 4 แบบจำลอง ได้ค่า True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) ดังแสดงในตารางที่ 4

ตารางที่ 4 ผลลัพธ์ค่าการประเมินประสิทธิภาพความแม่นยำแต่ละแบบจำลองในการตรวจจับการแตกร่อน (Spalling)

Model	TP	FP	FN	TN	Accuracy (%)
VGG16	47	15	53	385	86.40
VGG19	35	10	65	390	85.00
ResNet101	24	41	76	359	76.60
ResNet152	25	35	75	365	78.00

ตารางที่ 5 ผลลัพธ์ค่าการประเมิน Precision, Recall และ F1-score แบบจำลองในการตรวจจับการแตกร่อน (Spalling)

Model	Precision (%)	Recall (%)	F1-score (%)
VGG16	75.81	47.00	58.02
VGG19	77.78	35.00	48.28
ResNet101	36.92	24.00	29.09
ResNet152	41.67	25.00	31.25

จากตารางที่ 4 และ ตารางที่ 5 ได้เปรียบเทียบประสิทธิภาพการตรวจจับความเสียหายจากรอยแตกร่อน (Spalling) ทั้ง 4 แบบจำลอง จากผลการทดสอบแบบจำลองทั้งหมด พบว่า ค่า Accuracy ของแบบจำลอง VGG16 มีค่าสูงที่สุดอยู่ที่ ร้อยละ 86.40 รองลงมาคือ VGG19 ที่ร้อยละ 85.00 โดยแบบจำลองตระกูล ResNet มีค่า Accuracy ต่ำกว่า ซึ่ง ResNet101 อยู่ที่ร้อยละ 76.60 และ ResNet152 อยู่ที่ร้อยละ 78.00

ค่า Precision แบบจำลอง VGG16 มีค่าสูงที่สุดอยู่ที่ร้อยละ 77.78 ตามมา VGG19 ที่ร้อยละ 75.81 ResNet 101 อยู่ที่ร้อยละ 36.92 และ ResNet152 ค่า Precision อยู่ที่ร้อยละ 41.67 ซึ่งดีขึ้นเล็กน้อย

ค่า Recall แบบจำลอง VGG16 มีค่าสูงที่สุดอยู่ที่ร้อยละ 47.00 รองลงมาคือ VGG19 ที่ร้อยละ 35.00 ResNet101 และ ResNet152 มีค่า Recall ที่ต่ำมาก คือ ร้อยละ 24.00 และร้อยละ 25.00 ตามลำดับ

ค่า F1-score แบบจำลอง VGG16 มีค่าสูงที่สุดอยู่ที่ร้อยละ 58.02 ตามมาด้วย VGG19 ที่ร้อยละ 48.28 ส่วน ResNet101 และ ResNet152 มีค่า F1-score ที่ค่อนข้างต่ำมาก คือร้อยละ 29.03 และร้อยละ 21.25 ตามลำดับ ซึ่ง F1-score แสดงถึงความสมดุลระหว่าง Precision และ Recall ซึ่งโมเดล VGG ดีกว่า ResNet

4. สรุปผลการศึกษา

การตรวจจัดการการแตกรรอนในโครงสร้างคอนกรีตเป็นความท้าทายที่ต้องการความแม่นยำสูง เพื่อป้องกันความเสียหายและลดความเสี่ยงในการใช้งานโครงสร้าง งานวิจัยนี้ศึกษาการตรวจจรรอยแตกรรอนของคอนกรีตโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยทดสอบเปรียบเทียบประสิทธิภาพของแบบจำลอง 4 แบบ ได้แก่ VGG16, VGG19, ResNet101 และ ResNet152 จากการประเมินประสิทธิภาพ โดยพิจารณาจากค่า Accuracy ค่า Precision ค่า Recall และค่า F1-score พบว่าแบบจำลอง VGG16 เป็นแบบจำลองที่มีประสิทธิภาพสูงสุด โดยมีค่า Accuracy อยู่ที่ร้อยละ 86.40 และมีค่า F1-score สูงที่สุดที่ร้อยละ 58.02 ทำให้สามารถจำแนกข้อมูลได้แม่นยำกว่าแบบจำลองอื่น ๆ และรักษาสัมดุลระหว่าง Precision หรือ Recall ได้ดี จึงเหมาะสมที่จะนำแบบจำลองนี้ไปใช้ในการตรวจจรรอยแตกรรอนบนผิวคอนกรีตในอาคารชลประทานต่อไป แม้ว่า VGG19 จะมีค่า Precision สูงที่สุดที่ร้อยละ 77.70% แต่มีค่า Recall เพียงร้อยละ 35.00 ส่งผลให้ค่า F1-score (ร้อยละ 48.28) ต่ำกว่า VGG16 (F1-score ร้อยละ 58.02) จึงไม่เหมาะสมเท่ากับ VGG16 ในขณะที่กลุ่มแบบจำลอง ResNet มีประสิทธิภาพต่ำกว่าชัดเจน ดังนั้น แบบจำลอง VGG16 จึงเป็นทางเลือกเหมาะสมในการนำไปใช้งาน เพื่อตรวจจรรอยแตกรรอนบนผิวคอนกรีตในอาคารชลประทานในระดับที่น่าพอใจ

อย่างไรก็ตาม แม้ผลการทดสอบแบบจำลองจะมีประสิทธิภาพที่ดี โดยสามารถจำแนกประเภทของความเสียหายบนพื้นผิวคอนกรีตได้แม่นยำในระดับที่น่าพอใจนั้น แต่ความแม่นยำที่ยังคงขึ้นอยู่กับคุณภาพและลักษณะของข้อมูลภาพที่ใช้ฝึกสอน ซึ่งอาจมีข้อจำกัดด้านความหลากหลาย เช่น ขนาด รูปทรง แสง พื้นหลัง ความละเอียด ลักษณะมุมมอง รูปแบบเฉพาะของรอยแตกรรอนบนพื้นผิวคอนกรีต ที่ยังไม่ครอบคลุมลักษณะอย่างเพียงพอ ดังนั้นเพื่อเพิ่มความแม่นยำและประสิทธิภาพของแบบจำลองควรเพิ่มชุดข้อมูลให้มีความหลากหลายและครอบคลุมลักษณะการแตกรรอนที่มากขึ้น จะช่วยปรับปรุงประสิทธิภาพของแบบจำลอง รวมถึงเพิ่มความแม่นยำ ความน่าเชื่อถือ และขยายขีดความสามารถของแบบจำลองในการนำไปใช้งานจริงดียิ่งขึ้น

แนวทางการวิจัยต่อจากนี้ จะนำแบบจำลองที่ได้จากการฝึกสอนและประเมินผลการสอนที่ดีที่สุดนำไปตรวจจรรอยแตกรรอนบนแบบจำลองสามมิติของประตูระบายน้ำปากคลองบางแก้ว จังหวัดอ่างทอง ที่สร้างขึ้นจากภาพถ่ายอากาศยานไร้คนขับ โดยคาดหวังเป็นอย่างยิ่งว่าแบบจำลองจะสามารถตรวจจรรอยแตกรรอนตำแหน่งของรอยแตกรรอนได้อย่างแม่นยำ ซึ่งนำไปสู่กระบวนการวางแผนปรับปรุงบำรุงรักษา ซ่อมแซม ให้อาคารชลประทานใช้งานได้อย่างมีประสิทธิภาพ และทำการศึกษาเกี่ยวกับเทคนิคประมวลผลภาพเพิ่มเติม รวมไปถึงการขยายผลนำแบบจำลองการตรวจจัดการการแตกรรอนไปใช้กับโครงสร้างคอนกรีตอื่น ๆ

กิตติกรรมประกาศ

ขอขอบคุณคณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ สำหรับการสนับสนุนงานวิจัยเรื่อง "การตรวจจัดการการแตกรรอนของคอนกรีตในอาคารชลประทานด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Spalling Damage Detection in Irrigation Structures using Convolutional Neural Networks)" และขอขอบคุณหน่วยวิจัย IIMRaS (Infrastructure Inspection Monitoring Repair and Strengthening) ที่เอื้อเฟื้อข้อมูลภาพถ่ายความเสียหายของคอนกรีตสำหรับการวิจัยครั้งนี้ ขอขอบพระคุณ รศ.ดร.พรหมพัฒน์ ธัญสิทธิ์ศรีคุณอภิชาติ บัวตึก และคุณสิริธร โพธิพิพิธ ที่ได้กรุณาให้คำปรึกษาแนะนำ ตลอดจนข้อเสนอแนะที่มีคุณค่า ซึ่งช่วยให้การดำเนินงานวิจัยมีประสิทธิภาพและมีคุณภาพมากยิ่งขึ้น

เอกสารอ้างอิง

- [1] ส่วนความปลอดภัยเขื่อน สำนักบริหารจัดการน้ำและอุทกวิทยา (2561). คู่มือการตรวจสอบสภาพเขื่อนด้วยวิธีทางสายตา (Dam Inspection Manual by Visual Inspection). ส่วนความปลอดภัยเขื่อน สำนักบริหารจัดการน้ำและอุทกวิทยา กรมชลประทาน
- [2] Cha, Y. J., Choi, W., & Büyükoztürk, O. (2017). Deep learning-based crack damage detection using convolutional neural networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(5), 361-378..
- [3] Chen, L., Chen, W., Wang, L., Zhai, C., Hu, X., Sun, L., ... Jiang, L. (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.
- [4] Ali, L., Alnajjar, F., Jassmi, H. A., Gocho, M., Khan, W., & Serhani, M. A. (2021). Performance evaluation of deep CNN- based crack detection and localization techniques for concrete structures. *Sensors*, 21(5), 1688.
- [5] อภิชาติ บัวตึก, ฤชญา ไชยสาร, และคณะ. (2560). การตรวจสอบการเปลี่ยนแปลงของพื้นผิวก่ออิฐในโครงสร้างโบราณสถานด้วยเทคโนโลยีสามมิติจากภาพถ่าย. มหาวิทยาลัยธรรมศาสตร์.
- [6] Arafin, P., Billah, A. M., Issa, A. (2024). Deep learning-based concrete defects classification and detection using semantic segmentation. *Structural Health Monitoring*, 23(1), 383-409
- [7] Dung, C. V. (2019). Autonomous concrete crack detection using deep fully convolutional neural network. *Automation in Construction*, 99, 52-58.
- [8] พิสุทธิวัชร กัลปิยะภณต์, รัตติพงษ์สมมติมงคล และฤชญา ไชยสาร (2564). การตรวจสอบรอยร้าวบน พื้นผิวคอนกรีตด้วยการเรียนรู้เชิงลึกด้วยสถาปัตยกรรม VGG16. *วารสารวิชาการสมาคมคอนกรีตแห่งประเทศไทย* 9(2) 20-27
- [9] ศวิษฐ์ ธรรมวิจิต, และฤชญา ไชยสาร. (2565). การตรวจจรรอยร้าวของอาคารชลประทานโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน. *มหาวิทยาลัยธรรมศาสตร์*.

- [10] Chee, J., & Li, P. (2020, December). Understanding and detecting convergence for stochastic gradient descent with momentum. In 2020 IEEE international conference on big data (Big Data) (pp. 133-140). IEEE.
- [11] Chaiyasarn, K., Buatik, A., Mohamad, H., Zhou, M., Kongsilp, S., & Poovarodom, N. (2022). Integrated pixel-level CNN-FCN crack detection via photogrammetric 3D texture mapping of concrete structures. Automation in Construction, 140, 104388.
- [12] อภิชาติ บัวติก, พรหมพัฒน์ ญญศิริชัยศรี, ศิริศิลป์ กองศิลป์ และคณะ. (2566). การตรวจสอบความเสียหายในโครงสร้างพื้นฐานทางวิศวกรรมโยธาด้วยระบบการเรียนรู้เชิงลึกของปัญญาประดิษฐ์และความเป็นจริงเสมือน. มหาวิทยาลัยธรรมศาสตร์.
- [13] สโรชา ช่วงชู, และกฤษฎา ไชยสาร. (2565). การตรวจสอบรอยร้าวอาคารชลประทานด้วยเทคโนโลยีสามมิติจากภาพถ่ายและโครงข่ายประสาทเทียมคอนโวลูชันแบบสมบูรณ์. มหาวิทยาลัยธรรมศาสตร์.