

ตัวแบบการใช้โครงข่ายประสาทเทียมแบบสังวัตนาการเพื่อตรวจหารอยร้าวคอนกรีต A Prototype of Using Convolutional Neural Network for Concrete Crack Detection.

ประวัติน สุวรรณประดิษฐ์¹, วิภาวรรณ บัวทอง¹ และ พิธา จารูปนผล^{1*}
Prawat Suwanpraditkul¹, Wipawan Buathong¹, Pita Jarupunphol^{1*}

¹ สาขาเทคโนโลยีดิจิทัล คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏภูเก็ต

¹ Program in Digital Technology, Faculty of Science and Technology, Phuket Rajabhat University

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาตัวแบบการใช้ปัญญาประดิษฐ์ด้วยวิธีโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เพื่อตรวจหารอยร้าวคอนกรีตแบบอัตโนมัติของงานสิ่งก่อสร้าง ช่วยลดความจำเป็นในการตรวจสอบด้วยตนเอง ชุดข้อมูลที่หลากหลายซึ่งประกอบด้วยสถานการณ์การแตกร้าวที่เป็นรูปธรรมต่างๆ ถูกนำมาใช้เพื่อฝึกฝนและทดสอบให้มั่นใจถึงความแข็งแกร่งในการตรวจจับการแตกร้าวในบริบทต่างๆ นอกจากการปรับปรุงความแม่นยำและความสม่ำเสมอแล้ว วิธีการที่ใช้การเรียนรู้ของเครื่องนี้ยังช่วยเพิ่มความปลอดภัยด้วยการตรวจสอบพื้นที่ที่ยากต่อการเข้าถึงหรืออันตราย นอกจากนี้ยังเพิ่มความสามารถในการปรับขนาดและประสิทธิภาพโดยอำนวยความสะดวกในการประเมินอย่างรวดเร็วของไซต์ขนาดใหญ่หรือหลายไซต์ วิธีการนี้ช่วยให้สามารถปรับปรุงแก้ไขได้ตั้งแต่เริ่มต้น ซึ่งสามารถป้องกันความวิบัติของโครงสร้างที่อาจเกิดขึ้น ลดค่าใช้จ่ายในการซ่อมแซม และยืดอายุการใช้งานของโครงสร้างคอนกรีตพื้นฐาน ผลลัพธ์แสดงให้เห็นว่าตัวโมเดลมีประสิทธิภาพสูงมาก โดยจำแนกอินสแตนซ์ได้ถูกต้อง 39,482 รายการจาก 40,000 รายการ ส่งผลให้มีความแม่นยำถึง 98.705% นอกจากนี้ มาตรฐานค่าเฉลี่ยถ่วงน้ำหนัก เช่น True Positive Rate, False Positive Rate, Precision, Recall และ F-Measure ได้สะท้อนถึงความแม่นยำระดับสูงนี้ โดยเกณฑ์เกือบทั้งหมดอยู่ที่ 0.987 ซึ่งชี้ให้เห็นว่าโมเดลของ CNN มีประสิทธิภาพสูงมาก ในขณะที่ผลการวิจัยจากการใช้วิธีการแบ่งสัดส่วนข้อมูลที่ 70/30 ก็เป็นไปในทิศทางเดียวกัน โดยแสดงให้เห็นว่าตัวแบบของโมเดลยังคงมีประสิทธิภาพสูงมาก ซึ่งให้ผลการทำนายอินสแตนซ์ที่ถูกต้องจำนวน 11,829 (98.575%) และผิดพลาดแค่ 171 (1.425%) รายการ

คำสำคัญ: การเรียนรู้ของเครื่อง การตรวจหารอยร้าวคอนกรีต โครงข่ายประสาทเทียมแบบสังวัตนาการ

Abstract

This research aims to develop a model for using artificial intelligence using convolutional neural networks (CNN) to automatically detect concrete cracks in construction work, reducing the need for manual inspection. A diverse dataset comprising various concrete crack scenarios is employed to train and test, ensuring robustness in crack detection across different contexts. In addition to improving accuracy and consistency, this machine learning-based approach enhances safety by enabling the inspection of difficult-to-reach or hazardous areas. Furthermore, it enhances scalability and efficiency by rapidly assessing large or multiple sites. This approach allows for early intervention, which can prevent potential structural failures, minimize repair costs, and extend the lifespan of concrete infrastructures. The outcomes indicate that the model is highly effective, accurately classifying 39,482 out of 40,000 instances, which equates to an accuracy rate of 98.705%. Moreover, the weighted average metrics, including True Positive Rate, False Positive Rate, Precision, Recall, and F-Measure, all closely align with this high

* Corresponding author: p.jarupunphol@pkru.ac.th

degree of accuracy, with almost all metrics at 0.987, demonstrating that the CNN model performance in accuracy and efficiency. Meanwhile, the results from the 70/30 Percentage Split method are in the same direction, representing the model's high performance. This yielded 11,829 (98.575%) correct instance predictions and only 171 (1.425%) incorrect instances.

Keywords: machine learning, concrete crack detection, convolutional neural network

1. บทนำ

คอนกรีตเป็นรากฐานที่สำคัญของการก่อสร้างสมัยใหม่ โดยทำหน้าที่เป็นส่วนประกอบสำคัญในโครงสร้างส่วนใหญ่ที่สร้างขึ้นเป็นวัสดุประกอบที่สร้างขึ้นจากส่วนผสมของมวลรวมละเอียดและหยาบที่ยึดติดกันด้วยซีเมนต์เฟสที่เหลวแต่มีความหนืด กาวนี้แข็งตัวเมื่อเวลาผ่านไป นำไปสู่วัสดุที่ทนทานและคงทนซึ่งเป็นแกนหลักของโครงสร้างพื้นฐาน วัสดุที่ทนทานนี้ถูกนำมาใช้ในการก่อสร้างรูปแบบต่างๆ ให้ความแข็งแรงและความทนทานแก่โครงสร้างที่ก่อตัวขึ้น (Cement, 2019) ในปัจจุบัน คอนกรีตได้รับการยอมรับว่าเป็นวัสดุก่อสร้างที่ใช้บ่อยที่สุดในโลก การใช้งานอย่างกว้างขวางเน้นย้ำถึงความสำคัญอย่างยิ่งยวดในการรักษาความสมบูรณ์ของโครงสร้างเพื่อความปลอดภัย ความคุ้มค่า และอายุการใช้งานที่ยาวนานของโครงสร้างพื้นฐานที่สร้างขึ้น ลักษณะสำคัญของการบำรุงรักษาคือการตรวจจစ်และซ่อมแซมรอยร้าวอย่างทันที่ ซึ่งอาจส่งผลกระทบต่อความสมบูรณ์ของโครงสร้างหากปล่อยทิ้งไว้โดยไม่แก้ไข ดังนั้น การตรวจจစ်รอยร้าวและการตรวจสอบความสมบูรณ์ของโครงสร้างคอนกรีตเป็นสิ่งสำคัญยิ่งสำหรับความปลอดภัยของโครงสร้างพื้นฐานและอายุการใช้งานที่ยาวนาน ในขณะที่อาคารคือหนึ่งในโครงสร้างพื้นฐานที่สำคัญซึ่งเป็นสิ่งก่อสร้างและนวัตกรรมของมนุษย์ที่ถูกออกแบบทางวิศวกรรมเพื่อความคงทนถาวรและประโยชน์ใช้สอย โดยอาคารส่วนมากถูกสร้างขึ้นด้วยโครง ผนัง และหลังคาอันเป็นส่วนประกอบที่ตอบสนองความต้องการทางสังคมมากมาย ทำหน้าที่เป็นที่กำบังจากสภาพอากาศที่เปลี่ยนแปลงอยู่เสมอ เปรียบเสมือนสถานที่ศักดิ์สิทธิ์ที่ให้ความปลอดภัย พื้นที่ส่วนตัวสำหรับกรอยู่อาศัย และสถานที่เก็บทรัพย์สิน ซึ่งรูปร่างและขนาดของอาคารที่หลากหลายเป็นเครื่องพิสูจน์ถึงความฉลาดของมนุษย์และการปรับตัว ที่สะท้อนถึงปัจจัยต่างๆ เช่น วัสดุก่อสร้างที่มีอยู่ สภาพอากาศ ราคาที่ดิน สภาพพื้นดิน การใช้งานเฉพาะด้าน และความสวยงาม (Why Concrete Testing Is Important in Engineering & Construction, 2022)

อย่างไรก็ตาม แม้ว่าคอนกรีตจะมีความยืดหยุ่นและสอดคล้องกับความชำนาญของวิธีการก่อสร้างอาคารสมัยใหม่ แต่อาคารต่างๆ ก็ไม่อาจต้านทานความเสียหายที่อาจเกิดขึ้นจากภัยคุกคามตามธรรมชาติหรือภัยคุกคามที่เกิดจากมนุษย์ได้ หนึ่งในรูปแบบความเสียหายที่พบบ่อยที่สุดต่อโครงสร้างคอนกรีตคือการก่อตัวของรอยร้าว ซึ่งรอยร้าวในคอนกรีตเป็นรอยร้าวที่เกิดขึ้นบนพื้นผิวโดยไม่ทำให้แตกแยกเป็นชิ้นส่วน การแตกหักเหล่านี้สามารถเกิดขึ้นได้จากหลายสาเหตุ รวมถึงการเปลี่ยนแปลงของอุณหภูมิ การหดตัวระหว่างการอบแห้ง ความเครียดที่เกิดขึ้น หรือแม้แต่ความบกพร่องในเทคนิคการก่อสร้างในระหว่างกระบวนการและการบ่มคอนกรีต (Golding et al., 2022) ดังนั้น เพื่อปกป้องความสมบูรณ์ของโครงสร้างคอนกรีต การตรวจจစ်รอยร้าวตั้งแต่เริ่มต้น เป็นสิ่งสำคัญในการประเมินความปลอดภัยและความสมบูรณ์แข็งแรงของอาคาร การระบุรอยร้าวก่อนที่จะพัฒนาไปมากกว่านี้สามารถป้องกันความเสียหายเพิ่มเติม หลีกเลี่ยงการซ่อมที่มีราคาแพง และในกรณีที่รุนแรง อาจป้องกันความวิบัติของโครงสร้างทั้งหมดได้

ปัญหาที่กล่าวไว้ข้างต้นได้แสดงให้เห็นถึงความจำเป็นในการตรวจจစ်การแตกร้าวของคอนกรีตที่เป็นกลางและเชื่อถือได้มากขึ้น ซึ่งในปัจจุบันความก้าวหน้าของเทคโนโลยีสมัยใหม่ได้เห็นการบูรณาการเทคโนโลยีการเรียนรู้ของเครื่องเข้ากับการดำเนินธุรกรรมประเภทต่างๆ เพื่อเพิ่มความน่าเชื่อถือและลดความผิดพลาดในการตัดสินใจอย่างเป็นระบบ ดังนั้นการตรวจจစ်รอยร้าวโดยประยุกต์ใช้การเรียนรู้ของเครื่องด้วยวิธีการต่างๆ เช่น เครือข่ายประสาทเทียมที่สามารถทำให้กระบวนการเป็นไปโดยอัตโนมัติ ซึ่งช่วยเพิ่มประสิทธิภาพและความน่าเชื่อถืออย่างมากในการตรวจจစ်การแตกร้าวของคอนกรีต (Cement, 2019; Ding et al., 2023; Golding

et al., 2022) ความก้าวหน้าทางเทคโนโลยีปัญญาประดิษฐ์สามารถยกระดับการตรวจสอบรอยร้าว รับประกันอายุการใช้งานที่ยาวนานและความปลอดภัยของอาคารไปอีกขั้น โดยเน้นถึงความสำคัญของการตรวจจัดการแตกร้าวของคอนกรีตในการก่อสร้างและการบำรุงรักษาสภาพแวดล้อมที่สร้างขึ้น ดังนั้น อัลกอริทึมการเรียนรู้ของเครื่องถ้าหากได้รับการฝึกฝนและตรวจสอบอย่างเหมาะสมจะสามารถลดปัญหาเหล่านี้ เนื่องจากการใช้เกณฑ์เดียวกันอย่างสม่ำเสมอในการวิเคราะห์ภาพสำหรับการตรวจจัดการแตกร้าว โดยไม่ได้รับผลกระทบจากอิทธิพลทางความคิดที่อาจมีอคติต่อการตัดสินใจของมนุษย์ จึงสามารถให้แนวทางที่เป็นมาตรฐานและเชื่อถือได้มากขึ้นสำหรับการประเมินความสมบูรณ์ของโครงสร้างพื้นฐานที่เป็นรูปธรรม เช่นในงานวิจัยของ (Golding et al., Li et al., Sami et al., Imran et al., Yokoyama and Matsumoto) ด้วยสาเหตุดังกล่าว งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาตัวแบบการแก้ปัญหาประดิษฐ์ด้วยวิธีโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เพื่อตรวจหารอยร้าวคอนกรีตแบบอัตโนมัติของงานสิ่งก่อสร้าง

2. วัตถุประสงค์การวิจัย

- 2.1 เพื่อประยุกต์ใช้ปัญญาประดิษฐ์แบบสังวัตนาการเพื่อตรวจหารอยร้าวคอนกรีต
- 2.2 ทดสอบประสิทธิภาพจากการประยุกต์ใช้ปัญญาประดิษฐ์เพื่อตรวจหารอยร้าวคอนกรีต

3. วิธีดำเนินการวิจัย

วิธีดำเนินการวิจัยประกอบด้วย 5 ขั้นตอน คือ การรวบรวมข้อมูล การประมวลผลข้อมูลล่วงหน้า การเลือกและฝึกอบรมโมเดลโครงข่ายประสาทเทียม การประเมินโมเดล และการนำไปใช้จริง โดย WEKA (Witten et al., 2016) คือเครื่องมือหลักที่ใช้ในการวิจัยครั้งนี้

3.1 การรวบรวมข้อมูล

การรวบรวมข้อมูล (Data Collection) เป็นขั้นตอนแรกและเป็นขั้นตอนสำคัญในวิธีดำเนินการวิจัย ผู้วิจัยได้ชุดของภาพจาก Kaggle (Kaggle, n.d.) ซึ่งเป็นชุดข้อมูลประกอบด้วยรูปภาพของโครงสร้างที่มีและไม่มีรอยร้าวที่มองเห็นได้ ซึ่งนักวิจัยให้ความสนใจเป็นพิเศษในการถ่ายภาพที่มีรอยแตกประเภทต่างๆ ภายใต้สภาพแสงและมุมต่างกัน ในขณะเดียวกัน ผู้วิจัยจะเก็บภาพพื้นผิวคอนกรีตที่ไม่มีรอยร้าวเพื่อเป็นตัวอย่างเชิงลบสำหรับการฝึกโมเดล สิ่งสำคัญของการรวบรวมข้อมูลคือการทำให้มั่นใจว่าภาพมีความละเอียดสูงเพื่อการตรวจจัดการขนาดเล็กได้ดีขึ้นสำหรับการศึกษานี้

3.2 การประมวลผลข้อมูลล่วงหน้า

เมื่อรวบรวมข้อมูลแล้ว ขั้นตอนต่อไปคือการประมวลผลข้อมูลล่วงหน้า (Data Preprocessing) ภาพที่รวบรวมต้องได้รับการประมวลผลล่วงหน้าก่อนนำไปใช้ ซึ่งขั้นตอนนี้เกี่ยวข้องกับการติดฉลากภาพ โดยระบุและทำเครื่องหมายรอยร้าวบนภาพแต่ละภาพด้วยตนเอง เพื่อให้ความจริงพื้นฐานเบื้องต้นที่โมเดลจะเรียนรู้ นอกเหนือจากนี้ การปรับขนาดรูปภาพให้มีมิติสม่ำเสมอและการใช้เทคนิคการเพิ่มรูปภาพ เช่น การหมุน การแปล และการพลิกเพื่อเพิ่มความทนทานของโมเดลและช่วยให้โมเดลมีภาพรวมที่ดีขึ้น สัญญาณรบกวนหรือข้อมูลที่ไม่เกี่ยวข้องใดๆ ในภาพจะลดลงหรือถูกลบออกเพื่อให้แน่ใจว่าโมเดลจะมุ่งเน้นไปที่คุณสมบัติที่เกี่ยวข้องสำหรับการตรวจจัดการ

3.3 การเลือกและฝึกอบรมโมเดลโครงข่ายประสาทเทียม

ในขั้นตอนนี้ ข้อมูลที่ผ่านการประมวลผลล่วงหน้าจะถูกย้ายไปยังขั้นตอนการฝึกโมเดล (Model Selection and Training) ซึ่งนักวิจัยจะใช้เทคนิคสังวัตนาการ ที่ได้รับการยอมรับว่ามีประสิทธิภาพสูงสำหรับงานวิเคราะห์ภาพและถูกนำไปใช้กับงานที่คล้ายคลึงกันในการศึกษาก่อนหน้านี้ได้สำเร็จ (Rubio et al., 2024; Yasin et al., 2024) ทั้งนี้ โมเดลจะได้รับการฝึกอบรมโดยใช้อัลกอริทึมการปรับให้เหมาะสมและฟังก์ชันการสูญเสียที่เหมาะสม โดยมีจุดประสงค์เพื่อลดความแตกต่างระหว่างการคาดการณ์ของโมเดลและป้ายกำกับจริงของข้อมูลการฝึกอบรม กระบวนการวนซ้ำนี้จะปรับพารามิเตอร์ภายในของโมเดลและทำให้สามารถเรียนรู้รูปแบบที่เกี่ยวข้อง

กับรอยร้าวของคอนกรีตได้ ภาพที่ประมวลผลล่วงหน้าจะแบ่งออกเป็นชุดการฝึกอบรมและชุดการตรวจสอบความถูกต้อง จากนั้นโมเดลด้วยเทคนิคสังวัตนาการก็เข้ารับการฝึกในชุดฝึกโดยใช้เทคนิคต่างๆ เช่น การหยุดก่อนกำหนดและการตรวจสอบโมเดลเพื่อป้องกันการโอเวอร์ฟิตและเพื่อรักษาโมเดลที่มีประสิทธิภาพดีที่สุด

3.4 การประเมินโมเดล

หลังจากการฝึกอบรม ประสิทธิภาพของโมเดลได้รับการประเมินโดยใช้เกณฑ์มาตรฐานตรวจสอบความถูกต้อง (Model Evaluation) ซึ่งเกณฑ์มาตรฐานหลักที่นำมาใช้ประเมินประสิทธิภาพ ได้แก่ TP (True Positive Rate), FP Rate (False Positive Rate), Precision, Recall, และ F-Measure เพื่อวัดประสิทธิภาพของโมเดลได้ยืนยันประสิทธิภาพของโมเดล โดยสามารถอธิบายได้ดังนี้

3.4.1 เกณฑ์อัตรา TP ทำหน้าที่ประเมินสัดส่วนของกรณีเชิงบวก ซึ่งจะวัดสัดส่วนของกรณีและปัญหาที่เกิดขึ้นจริง (รอยร้าว) ที่โมเดลระบุได้อย่างถูกต้อง

3.4.2 เกณฑ์อัตรา FP ทำหน้าที่ประเมินสัดส่วนของกรณีเชิงลบ (ไม่มีรอยร้าว) แต่ระบุอย่างไม่ถูกต้องว่าเป็นบวก (รอยร้าว)

3.4.3 เกณฑ์ความแม่นยำ (Precision) ทำหน้าที่ประเมินสัดส่วนของกรณีบวกที่คาดการณ์ไว้ ซึ่งเป็นผลบวกจริง

3.4.4 เกณฑ์การเรียกคืน (Recall) ทำหน้าที่ประเมินสัดส่วนของกรณีเชิงบวกเหมือนกับอัตรา TP โดยจะวัดสัดส่วนของกรณีเชิงบวกที่เกิดขึ้นจริงและระบุอย่างถูกต้องโดยโมเดล

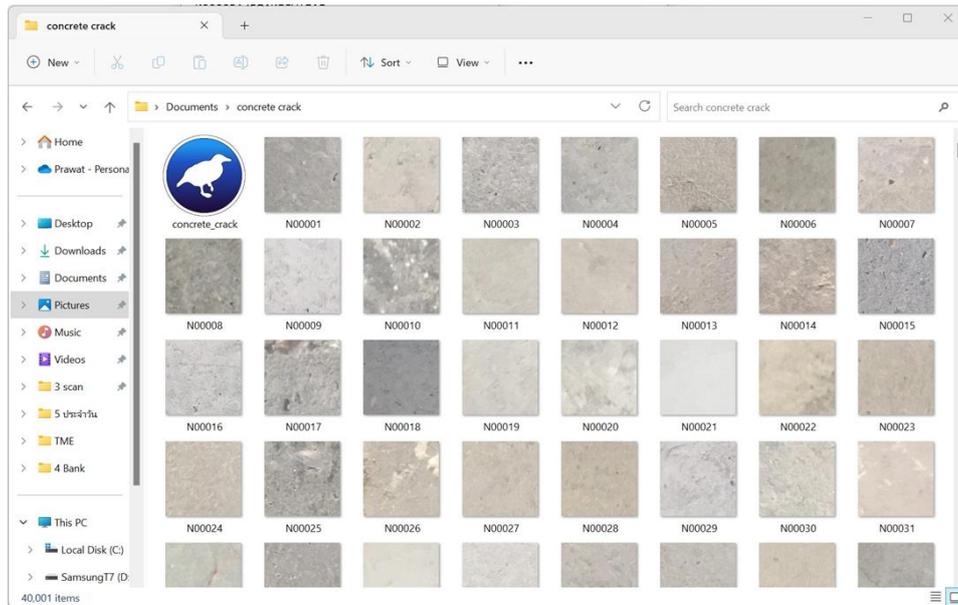
3.4.5 F-Measure หรือ F1 คือค่าเฉลี่ยของความแม่นยำและการเรียกคืน และให้เมตริกเดียวที่รวมทั้งสองเข้าด้วยกัน มีประโยชน์อย่างยิ่งเมื่อต้องการเปรียบเทียบโมเดล หรือเมื่อต้องการสร้างความสมดุลระหว่างความแม่นยำและการเรียกคืน โดยค่าทั้งหมดนี้จะถูกนำมาทดสอบกับโมเดล เมื่อพบว่าประสิทธิภาพของโมเดลเป็นที่น่าพอใจ ก็จะนำไปใช้สำหรับการทดสอบในโลกแห่งความเป็นจริง

3.5 การทดสอบโมเดล

การทดสอบโมเดล (Model Testing) เป็นขั้นตอนสุดท้ายของระเบียบวิธีวิจัยซึ่งในอนาคตมุ่งเน้นไปที่การนำโมเดลการเรียนรู้ของเครื่องไปใช้ในกระบวนการตรวจสอบรอยร้าวตามปกติที่ไซต์ก่อสร้าง ซึ่งสิ่งนี้เกี่ยวข้องกับการรวมโมเดลเข้ากับโครงสร้างพื้นฐานที่มีอยู่ รวมถึงระบบฮาร์ดแวร์หรือซอฟต์แวร์ที่จำเป็นใดๆ ในขั้นตอนนี้จำเป็นต้องมีการฝึกอบรมให้กับบุคลากรที่เกี่ยวข้องเพื่อดำเนินการและตีความผลลัพธ์ที่สร้างโดยโมเดลตลอดขั้นตอนการใช้งาน การตรวจสอบประสิทธิภาพของโมเดลอย่างใกล้ชิดและรวบรวมข้อคิดเห็นจากผู้ใช้เพื่อทำการปรับเปลี่ยนหรือปรับปรุงที่จำเป็นสำหรับการใช้งานจริงในอนาคต

4. ผลการวิจัย

โดยบทนี้แสดงมุมมองเชิงวิเคราะห์เกี่ยวกับประสิทธิภาพของการใช้โครงข่ายประสาทเทียมในการระบุรอยร้าวคอนกรีต ซึ่งในส่วนแรกของบทนี้จะนำเสนอข้อมูลดิบที่ได้รับจากการประยุกต์ใช้โมเดลเครือข่ายประสาทที่ผ่านการฝึกอบรมในชุดข้อมูลทดสอบ ในขั้นตอนนี้ ผู้วิจัยดำเนินการรวบรวมรูปภาพรอยร้าวของคอนกรีตจาก Kaggle (Kaggle, n.d.) โดยรูปภาพทั้งหมดจะถูกจัดเก็บไว้ในโฟลเดอร์ 'concrete crack' รูปภาพเหล่านี้จะเป็นแหล่งข้อมูลหลักสำหรับการฝึกอบรม ตรวจสอบ และทดสอบโมเดลการเรียนรู้ของเครื่อง และตรวจสอบให้แน่ใจว่าภาพทั้งหมดติดฉลากอย่างถูกต้อง โดยระบุว่าไม่มีรอยแตกหรือไม่



ภาพที่ 1 ข้อมูลทั้งหมดถูกจัดเก็บไว้ในโฟลเดอร์ 'concrete crack'

4.1 การประมวลผลข้อมูลล่วงหน้า

ARFF (Attribute-Relation File Format) หรือรูปแบบไฟล์ความสัมพันธ์เชิงแอตทริบิวต์ถูกใช้เพื่อจัดเก็บข้อมูลภาพรอยร้าวที่เป็นรูปธรรมสำหรับโครงการนี้ ซึ่งเป็นรูปแบบไฟล์ที่มักใช้ร่วมกับซอฟต์แวร์การเรียนรู้ของเครื่องของโปรแกรม WEKA โดยโครงสร้างของไฟล์ ARFF แบ่งออกเป็นสี่ส่วน ประกอบด้วย 1) @relation ซึ่งระบุชื่อของชุดข้อมูล 2) @attribute filename string ทำหน้าที่ระบุแอตทริบิวต์ที่ระบุชื่อไฟล์ของรูปภาพแต่ละรูปเป็นสตริง 3) @attribute class {POSITIVE, NEGATIVE} ซึ่งสร้างแอตทริบิวต์เป้าหมาย 'class' ซึ่งแสดงถึงการมีอยู่ (POSITIVE) หรือไม่มี (NEGATIVE) ของรอยร้าวคอนกรีต ดังนั้นการตั้งค่านี้นี้เป็นการจำแนกประเภทไบนารี และ 4) @data ที่ชุดข้อมูลจริงจะแสดงรายการด้วยแต่ละบรรทัดที่สอดคล้องกับรูปภาพ พร้อมด้วยชื่อไฟล์และคลาส ตัวอย่างเช่น N00001.jpg, NEGATIVE หมายความว่ารูปภาพ 'N00001.jpg' มีป้ายกำกับเป็น NEGATIVE ซึ่งแสดงว่าไม่มีรอยร้าวของคอนกรีต โครงสร้างนี้ช่วยให้มั่นใจถึงการจัดระเบียบข้อมูลที่มีประสิทธิภาพ ซึ่งช่วยให้ง่ายต่อการประมวลผลในขั้นตอนต่อไปของการเรียนรู้ของเครื่อง

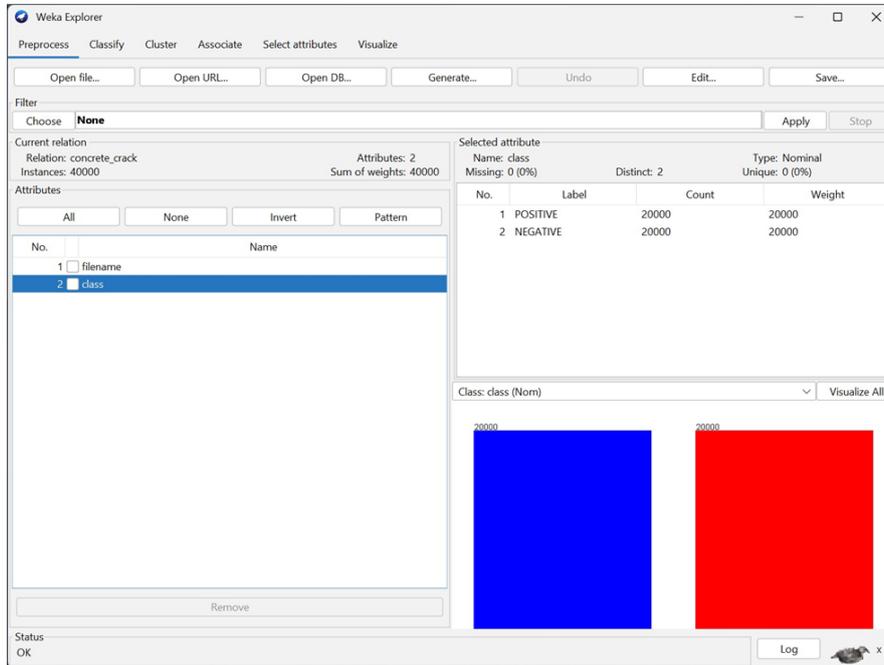
หลังจากนั้น เปิดใช้โปรแกรม WEKA แล้วคลิกปุ่ม Explorer ซึ่งจะเปิดอินเทอร์เน็ต Explorer ซึ่งในแผงการประมวลผลจะเห็นปุ่มเปิดไฟล์ และไปที่โฟลเดอร์ 'Concrete Crack' หลังจากนั้นค้นหาและเลือกไฟล์ ARFF ชื่อ 'concrete_crack' แล้วคลิก Open ซึ่งขั้นตอนนี้จะโหลดชุดข้อมูลลงใน WEKA และสามารถดูสรุปข้อมูล รวมถึงจำนวนอินสแตนซ์ (แถว) และคุณลักษณะ (คอลัมน์) ก่อนดำเนินการสำรวจ วิเคราะห์ และปรับใช้ต่างๆ อัลกอริทึมการเรียนรู้ของเครื่องไปยังชุดข้อมูล ซึ่งหลังจากเรียกใช้งานไฟล์ จะเห็นว่ารายละเอียดข้อมูลเป็นการสรุปเนื้อหาของไฟล์ ARFF 'concrete_crack' ดังนี้

Attributes = 2 หมายความว่า ชุดข้อมูลมีข้อมูลหรือคุณสมบัติสองประเภทต่ออินสแตนซ์ ในบริบทของโปรเจกต์นี้ คุณลักษณะเหล่านี้อาจเป็นชื่อไฟล์ของรูปภาพและคลาส (ระบุว่ารูปภาพนั้นติดป้ายกำกับเป็นบวกหรือลบสำหรับรอยร้าวคอนกรีต)

Instances = 40,000 หมายความว่า ชุดข้อมูลมี 40,000 ระเบียบหรืออินสแตนซ์แต่ละรายการ แต่ละอินสแตนซ์สอดคล้องกับภาพที่เป็นรูปธรรมเพียงภาพเดียว

Sum of Weights = 40,000 หมายความว่า ผลรวมของน้ำหนักเท่ากับจำนวนอินสแตนซ์ทั้งหมด โดยถือว่าแต่ละอินสแตนซ์มีน้ำหนักเริ่มต้นเป็น 1 ในบางชุดข้อมูล อินสแตนซ์อาจได้รับน้ำหนักที่แตกต่างกันเพื่อแสดงถึงความสำคัญที่สัมพันธ์กัน แต่ดูเหมือนว่าในกรณีนี้ ในกรณีที่อินสแตนซ์ทั้งหมดมีน้ำหนักเท่ากัน

POSITIVE (Count = 20,000, Weight 20,000) และ NEGATIVE (Count = 20,000, Weight 20,000) แสดงว่าชุดข้อมูลมีความสมดุลอย่างสมบูรณ์ โดยมีอินสแตนซ์ 20,000 รายการที่ระบุว่าเป็นค่าบวก หรือแสดงว่าไม่มีรอยร้าว ชุดข้อมูลดังกล่าวที่มีคลาสที่สมดุลและอินสแตนซ์จำนวนมากเป็นสิ่งที่พึงปรารถนาในการเรียนรู้ของเครื่อง เนื่องจากเป็นฐานที่แข็งแกร่งสำหรับโมเดลการฝึกอบรม และลดโอกาสที่จะเกิดอคติเนื่องจากความไม่สมดุลของคลาส

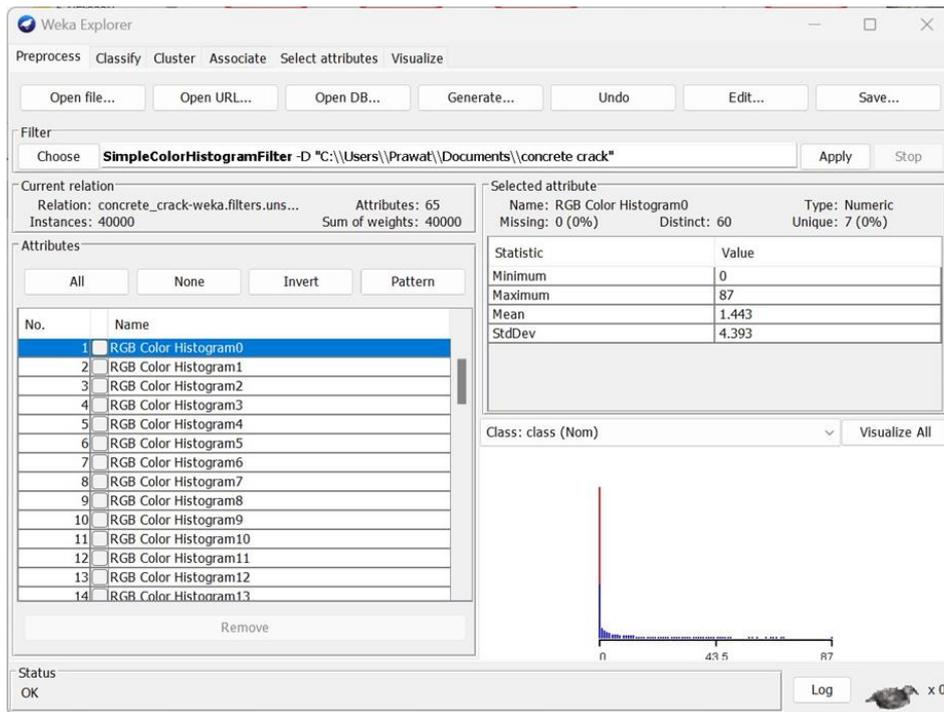


ภาพที่ 2 รายละเอียดของไฟล์ concrete crack

4.2 การกรองข้อมูล

ขั้นตอนต่อไปคือการกรองข้อมูล โดยทำการเลือกตัวกรองใน WEKA ตามขั้นตอน ดังนี้

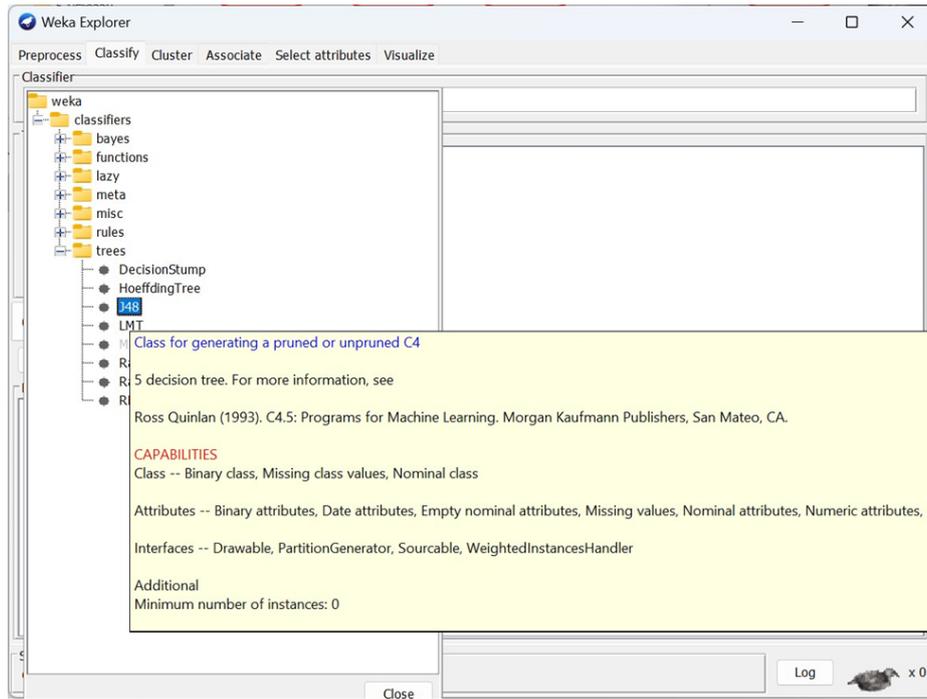
ทำการเลือกปุ่มตัวกรองในแผงการประมวลผลล่วงหน้า ซึ่งตัวกรองใน WEKA สามารถแบ่งออกได้เป็น 2 ประเภทหลัก คือ 1) แบบมีการควบคุม และ 2) แบบไม่มีการควบคุม ซึ่งสามารถเลือกตัวกรองจากหมวดหมู่ที่เหมาะสมได้ ในขณะที่ตัวกรองแบบมีการควบคุมจะมีตัวกรองแอตทริบิวต์และอินสแตนซ์ที่ได้รับการออกแบบให้ใช้กับป้ายกำกับคลาส ตัวกรองแบบไม่มีการควบคุมจะมีตัวกรองหลากหลายประเภท เช่น แอตทริบิวต์ อินสแตนซ์ ฯลฯ ซึ่งในกรณีที่สามารถเลือกแอตทริบิวต์ได้ รายการตัวกรองต่างๆ ที่สามารถใช้สำหรับการเลือกแอตทริบิวต์จะปรากฏขึ้น เช่น Remove, Normalize, Standardize, ฯลฯ แต่ถ้าเลือกอินสแตนซ์ ตัวกรองสำหรับจัดการกับอินสแตนซ์ เช่น RemoveWithValues, Resample เป็นต้น เมื่อพบตัวกรองที่ต้องการ ให้คลิกที่ตัวกรองแล้วเลือกปุ่มเลือกที่ด้านล่าง ในกรณีที่ต้องการใช้ SimpleColorHistogramFilter ใน WEKA สามารถทำได้โดยเลือกแถบประมวลผลล่วงหน้า และเลือก Select ข้าง Filter ซึ่งอยู่ใต้ส่วน Preprocess และเลือกอินสแตนซ์ และให้หาตัวกรองรูปภาพ (imagefilter) และเลือก SimpleColorHistogramFilter ซึ่งหลังจากเลือก SimpleColorHistogramFilter เรียบร้อยแล้ว จึงทำการใช้ตัวกรองนี้กับชุดข้อมูลโดยเลือกนำไปประยุกต์ใช้ (Apply) ในแท็บการประมวลผลล่วงหน้า ภาพที่ 3 แสดงการเลือกตัวกรองที่เป็นแบบ SimpleColorHistogramFilter



ภาพที่ 3 ตัวกรองที่เป็นแบบ SimpleColorHistogramFilter

4.3 การจำแนกข้อมูล

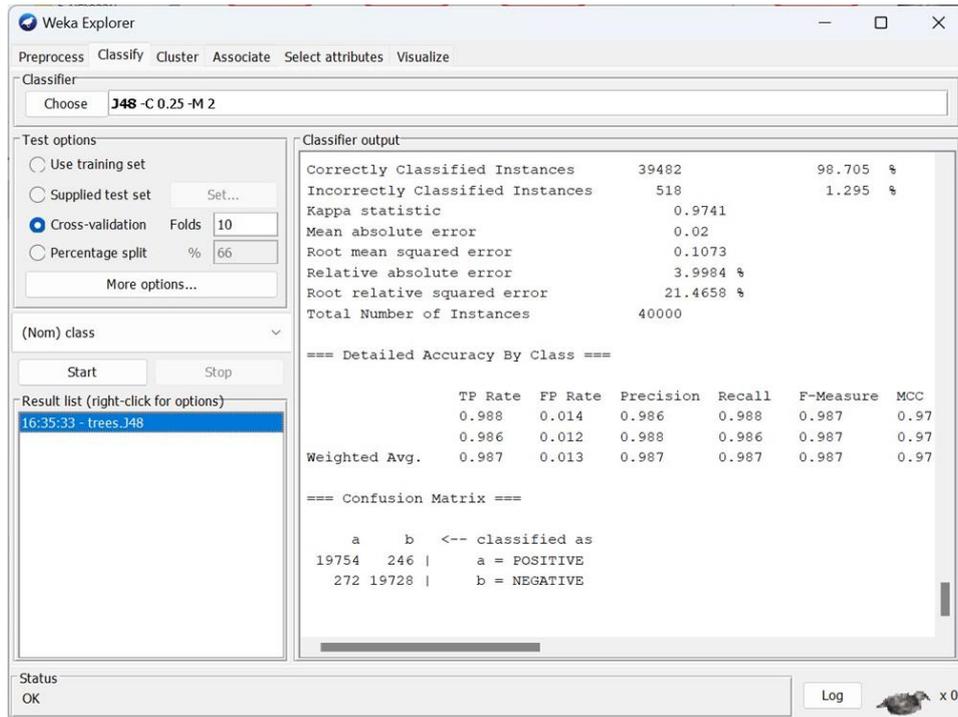
ขั้นตอนต่อไปคือการจำแนกข้อมูล (Data Classification) ซึ่งแท็บจำแนก (Classify) ใน WEKA เป็นแถบที่สามารถเลือกอัลกอริทึมการเรียนรู้ของเครื่องเพื่อใช้กับข้อมูลได้ ซึ่งตัวแยกประเภทเหล่านี้จัดกลุ่มเป็นหมวดหมู่ เช่น Bayes, Function, Lazy, Meta, Rules, Tree และเบ็ดเตล็ด โดยแต่ละหมวดหมู่เผยให้เห็นตัวแยกประเภทเฉพาะภายใน ตัวอย่างเช่น หากขยาย Tree จะพบอัลกอริทึมแผนผังต้นไม้การตัดสินใจ เช่น J48 ซึ่งเป็นการนำอัลกอริทึม C4.5 มาใช้งานแบบโอเพ่นซอร์สใน WEKA และเป็นตัวจำแนกประเภทแบบ Decision Trees ซึ่งโดยทั่วไปมีประสิทธิภาพสำหรับงานที่เกี่ยวข้องกับข้อมูลที่จัดหมวดหมู่ เมื่อพบตัวแยกประเภทที่ใช้จึงทำการเลือกและตั้งค่าพารามิเตอร์ที่จำเป็นก่อนที่จะเรียกใช้ตัวแยกประเภทกับข้อมูล วิธีนี้เป็นหนึ่งในวิธีที่ได้รับความนิยมมากที่สุดในการเรียนรู้ของเครื่อง เนื่องจากความเรียบง่ายต่อความเข้าใจและมีประสิทธิภาพกับข้อมูลหลายประเภท ในงานวิจัยนี้ หลังจากข้อมูลที่ไฟล์ .arff ถูกโหลดในแถบประมวลผลล่วงหน้า (Preprocess) จึงดำเนินการขั้นตอนการจัดประเภท โดยเลือกแถบ Classify และทำการตั้งค่าพารามิเตอร์สำหรับการแยกประเภท ซึ่งทางผู้วิจัยเลือกตัวแยกประเภทแบบ J48 ในหมวดหมู่ trees ภาพที่ 4 แสดงหน้าจอการเลือกตัวจำแนกข้อมูลแบบ J48 ในหน้าต่าง Weka Explorer



ภาพที่ 4 หน้าจอการเลือกตัวจำแนกข้อมูลแบบ J48 ในหน้าต่าง Weka Explorer

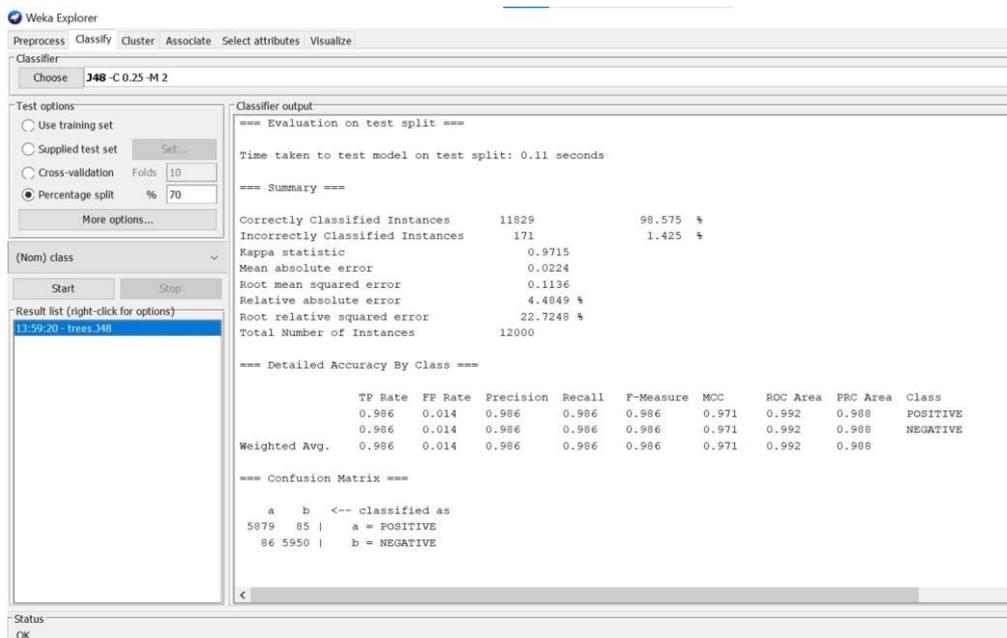
นอกเหนือจากนี้ การใช้ K-Fold Cross Validation มีความสำคัญ เนื่องจากเป็นวิธีการทั่วไปในการประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่อง โดย 'พับ' หรือแบ่งข้อมูลออกเป็น K ส่วนเท่ากัน ซึ่งการประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่องโดยทั่วไปจะใช้ 10-Fold Cross Validation เพื่อแบ่งข้อมูลออกเป็น 10 ส่วนเท่ากัน หลังจากนั้น โมเดลจะได้รับการฝึกกับ 9 พับเหล่านี้และทดสอบกับอีก 1 พับที่เหลือ ดังนั้น กระบวนการนี้จะมีการทำซ้ำ 10 ครั้ง โดยแต่ละพับใช้ครั้งเดียวตามที่ชุดทดสอบกำหนด การวัดประสิทธิภาพขั้นสุดท้ายคือค่าเฉลี่ยของผลลัพธ์จากการทำซ้ำแต่ละครั้งจาก 10 ครั้ง หลังจากนั้นจึงดำเนินการแยกประเภท ซึ่งผลลัพธ์จะแสดงในส่วนผลลัพธ์ของตัวแยกประเภท (Classifier Output)

ผลลัพธ์บ่งชี้ว่าโมเดลทำงานได้อย่างมีประสิทธิภาพ สามารถระบุการมีรอยร้าวได้อย่างถูกต้องในสัดส่วนที่สูงมากของภาพ และยังรักษาอัตราการเกิดผลบวกผิดพลาดที่ต่ำ จากจำนวนอินสแตนซ์ทั้งหมด (40,000) โมเดลนี้สามารถจำแนกจำนวนอินสแตนซ์ 39,482 จาก 40,000 รายการได้อย่างถูกต้อง ซึ่งเท่ากับว่ามีความแม่นยำสูงถึง 98.705% สิ่งนี้บ่งชี้ว่าโมเดลนั้นมีประสิทธิภาพสูงในการทำนายอย่างถูกต้องว่าภาพคอนกรีตที่อยู่ในหมวดหมู่ 'มีรอยร้าว' (Crack) หรือ 'ไม่มีรอยร้าว' (No Crack) นอกเหนือจากนี้ มาตรการวัดเฉลี่ยถ่วงน้ำหนัก (Weighted Average Metrics) ประกอบด้วยเกณฑ์ TP (True Positive Rate), FP Rate (False Positive Rate), Precision, Recall, และ F-Measure เพื่อวัดประสิทธิภาพของโมเดลได้ยืนยันประสิทธิภาพของโมเดล โดยได้ค่า TP ที่ 0.987 แสดงว่าโมเดลสามารถระบุ 98.7% ของกรณีรอยร้าวจริงทั้งหมดได้อย่างถูกต้อง และได้ค่า FP ที่ 0.013 บ่งชี้ว่า 1.3% ของกรณีที่ไม่ 'มีรอยร้าว' จริงทั้งหมด แต่ถูกระบุอย่างไม่ถูกต้องว่า 'มีรอยร้าว' มีอัตราข้อผิดพลาดที่ค่อนข้างต่ำ นอกเหนือจากนี้ ยังได้ค่าความแม่นยำ (Precision) ที่ 0.987 แสดงว่าเมื่อโมเดลทำนายภาพว่าเป็น 'รอยร้าว' และภาพนั้นถูกต้องเป็นอัตราส่วนที่ 98.7% ของเวลาทั้งหมด และค่าเรียกคืน (Recall) ที่ได้ผลเหมือนกับ TP ที่ 0.987 นอกจากนี้ยังได้ค่า F ได้ 0.987 แสดงว่าโมเดลมีความสมดุลที่ดีมากระหว่างความแม่นยำและการเรียกคืน



ภาพที่ 5 ผลลัพธ์ประสิทธิภาพของโมเดลด้วยวิธี 10-Fold Cross Validation

นอกจากการใช้ 10-Fold Cross Validation ผลการวิจัยจากการใช้วิธีการแบ่งสัดส่วนข้อมูล (Percentage Split) ที่ 70/30 โดยแบ่งข้อมูลสำหรับการเรียนรู้ (Training) ที่ 28,000 อินสแตนซ์ และข้อมูลสำหรับการทดสอบ (Testing) ที่ 12,000 อินสแตนซ์ แสดงให้เห็นว่าตัวแบบของโมเดลยังคงมีประสิทธิภาพสูง ซึ่งให้ผลการทำนายอินสแตนซ์ที่ถูกต้องจำนวน 11,829 (98.575%) และผิดพลาดแค่ 171 (1.425%) รายการ



ภาพที่ 6 ผลลัพธ์ประสิทธิภาพของโมเดลด้วยวิธี Percentage Split (70/30)

5. อภิปรายผลการวิจัยและข้อเสนอแนะ

งานวิจัยนี้นำเสนอตัวแบบการใช้โมเดลสังวัตนาการในการตรวจหารอยร้าวคอนกรีต ซึ่งผลลัพธ์ที่ได้ซึ่งชี้ถึงการปรับปรุงที่สำคัญกว่าวิธีการแบบเดิมในแง่ของความแม่นยำและประสิทธิภาพ โดยเฉพาะการใช้ตัวแยกประเภท J48 ที่มีแผนผังการตัดสินใจ C4.5 เพื่อแก้ไขปัญหาที่สำคัญของการตรวจจัดการแตกร้าวของคอนกรีตในอุตสาหกรรมการก่อสร้าง ใช้เครื่องมือการเรียนรู้ของเครื่องที่มีประสิทธิภาพอย่าง WEKA และชุดข้อมูล 40,000 ภาพคอนกรีตที่แสดง ‘รอยร้าว’ หรือ ‘ไม่มีรอยร้าว’ โมเดลนี้ได้รับการพัฒนาซึ่งแสดงให้เห็นความแม่นยำในการจำแนกประเภทถึง 98.705% ผลลัพธ์เหล่านี้สะท้อนให้เห็นอย่างสม่ำเสมอในตัวชี้วัดประสิทธิภาพหลักทั้งหมด เช่น TP (True Positive Rate), FP Rate (False Positive Rate), Precision, Recall, และ F-Measure ซึ่งทั้งหมดนี้แสดงคะแนน 0.987 ที่แสดงให้เห็นถึงความสามารถของโมเดลในการจำแนกการมีอยู่หรือไม่มีอยู่ของรอยแตกคอนกรีตอย่างถูกต้องด้วยความแม่นยำและความน่าเชื่อถือสูง อย่างไรก็ตาม ถึงแม้ว่าผลการศึกษานี้จะออกมาเป็นที่น่าพอใจ สิ่งสำคัญที่จะต้องยอมรับข้อจำกัดโดยธรรมชาติของประสิทธิภาพของโมเดลที่ขึ้นอยู่กับชุดข้อมูล เนื่องจากประสิทธิภาพของโมเดลในงานวิจัยนี้ขึ้นอยู่กับชุดข้อมูลเฉพาะที่ใช้สำหรับการฝึกอบรม ในบริบทของการใช้งานจริง ประสิทธิภาพของโมเดลอาจแตกต่างกันไปเมื่อสัมผัสกับชุดข้อมูลที่แตกต่างกัน โดยเฉพาะอย่างยิ่งชุดที่แตกต่างจากชุดการฝึกตั้งเดิมอย่างมาก ดังนั้น การตรวจสอบและปรับแต่งโมเดลอย่างต่อเนื่องโดยใช้ชุดข้อมูลที่หลากหลายจึงเป็นขั้นตอนสำคัญในการรักษาประสิทธิภาพและความแม่นยำของโมเดล งานวิจัยนี้ยังต้องเผชิญกับความท้าทายบางประการ เช่น การจำแนกความแตกต่างระหว่างรอยร้าวและความผิดปกติอื่นๆ ซึ่งเป็นพื้นที่สำหรับการต่อยอดงานวิจัยในอนาคต

ผลการวิจัยมีความหมายอย่างมากต่ออุตสาหกรรมการก่อสร้าง ส่งสัญญาณถึงการเปลี่ยนแปลงครั้งสำคัญในการตรวจสอบโครงสร้าง ซึ่งส่งผลให้แนวทางปฏิบัติในการก่อสร้างมีความปลอดภัย เชื่อถือได้ และยั่งยืนมากขึ้นด้วยการประยุกต์ใช้การเรียนรู้ของเครื่องสำหรับการตรวจหารอยร้าวคอนกรีต งานวิจัยนี้ให้แนวทางไปสู่การยอมรับการใช้งานเทคโนโลยีขั้นสูงในอุตสาหกรรมการก่อสร้างในวงกว้าง ในอนาคต งานวิจัยควรถูกนำไปประยุกต์ใช้กับบริบทที่กว้างขึ้น ผลลัพธ์เหล่านี้มีส่วนสำคัญต่อความพยายามอย่างต่อเนื่องในการทำให้เป็นอัตโนมัติและปรับปรุงความน่าเชื่อถือของการตรวจจรรอยร้าวในอุตสาหกรรมการก่อสร้าง โมเดลที่มีความแม่นยำสูงดังกล่าวสามารถเพิ่มประสิทธิภาพ ความเที่ยงธรรม และความปลอดภัยได้อย่างมาก นับเป็นก้าวสำคัญในเส้นทางสู่แนวทางปฏิบัติในการก่อสร้างที่ก้าวหน้าทางเทคโนโลยีและยั่งยืน ดังนั้น ความพยายามในการวิจัยในอนาคตควรมุ่งเน้นไปที่การทดสอบและการปรับแต่งโมเดลโดยใช้ชุดข้อมูลที่หลากหลายภายใต้สภาพแวดล้อมที่แตกต่างกันเพื่อการปรับปรุงโมเดลนี้ให้ดียิ่งขึ้น ทั้งนี้ อาจรวมเข้ากับโมเดลการเรียนรู้ของเครื่องแบบอื่น เพื่อสร้างเครื่องมือตรวจสอบคอนกรีตแบบหลายแง่มุมและปรับแต่งอย่างต่อเนื่อง ซึ่งอาจนำไปสู่การพัฒนาเครื่องมือตรวจสอบคอนกรีตที่ครอบคลุมรายละเอียดในการตรวจสอบรอยร้าวมากขึ้น

6. กิตติกรรมประกาศ

ขอขอบคุณวารสารวิชาการวิทยาศาสตร์ มหาวิทยาลัยราชภัฏจันทรเกษม ที่จัดเตรียมเทมเพลตสำหรับการส่งบทความวิจัยนี้จนสำเร็จลุล่วงไปได้ด้วยดี

7. เอกสารอ้างอิง

- Cement, G. F. P. (12 September 2019). *The Importance of Concrete in Construction Projects*. GFP Cement Contractors LLC. <https://gfpcement.com/the-importance-of-concrete-in-construction-projects/>
- Ding, W., Yang, H., Yu, K., and Shu, J. (2023). Crack detection and quantification for concrete structures using UAV and transformer. *Automation in Construction*, 152, 104929. <https://doi.org/10.1016/j.autcon.2023.104929>
- Golding, V. P., Gharineiat, Z., Munawar, H. S., and Ullah, F. (2022). Crack Detection in Concrete Structures Using Deep Learning. *Sustainability*, 14(13), 8117. <https://doi.org/10.3390/su14138117>

- Imran, H., Al-Abdaly, N. M., Shamsa, M. H., Shatnawi, A., Ibrahim, M., and Ostrowski, K. A. (2022). Development of Prediction Model to Predict the Compressive Strength of Eco-Friendly Concrete Using Multivariate Polynomial Regression Combined with Stepwise Method. *Materials*, *15*(317), 317. <https://doi.org/10.3390/ma15010317>
- Kaggle. (n.d.). *Concrete Crack Images for Classification*. Kaggle. <https://www.kaggle.com/datasets/arnavr10880/concrete-crack-images-for-classification>.
- Li, Z., Yoon, J., Zhang, R., Rajabipour, F., Iii, W. V. S., Dabo, I., and Radlinska, A. (2022). Machine learning in concrete science: Applications, challenges, and best practices. *Npj Computational Materials*, *8*(1), 1–17. <https://doi.org/10.1038/s41524-022-00810-x>
- Rubio, J. de J., Garcia, D., Rosas, F. J., Hernandez, M. A., Pacheco, J., and Zacarias, A. (2024). Stable convolutional neural network for economy applications. *Engineering Applications of Artificial Intelligence*, *132*, 107998. <https://doi.org/10.1016/j.engappai.2024.107998>
- Sami, B. H. Z., Sami, B. F. Z., Kumar, P., Ahmed, A. N., Amieghemen, G. E., Sherif, M. M., and El-Shafie, A. (2023). Feasibility analysis for predicting the compressive and tensile strength of concrete using machine learning algorithms. *Case Studies in Construction Materials*, *18*, e01893. <https://doi.org/10.1016/j.cscm.2023.e01893>
- Why concrete testing is important in engineering & construction*. (2 november 22022). Douglas Partners. <https://www.douglaspartners.com.au/news/the-importance-of-concrete-testing>.
- Witten, I. H., Frank, E., Hall, M. A., and Pal, C. J. (2016). Data Mining: Practical Machine Learning Tools and Techniques. In *Data Mining: Practical Machine Learning Tools and Techniques*. <https://doi.org/10.1016/c2009-0-19715-5>.
- Yasin, M., Sarigül, M., and Avci, M. (2024). Logarithmic Learning Differential Convolutional Neural Network. *Neural Networks*, *172*, 106114. <https://doi.org/10.1016/j.neunet.2024.106114>
- Yokoyama, S., and Matsumoto, T. (2017). Development of an Automatic Detector of Cracks in Concrete Using Machine Learning. *Procedia Engineering*, *171*, 1250–1255. <https://doi.org/10.1016/j.proeng.2017.01.418>