



วารสารวิศวกรรมศาสตร์และนวัตกรรม Journal of Engineering and Innovation

บทความวิจัย

การตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดรูปตัวเอชจากรูปภาพโดย YOLOV5 ด้วยเทคนิคการถ่ายโอนการเรียนรู้

H-beam steel detection from images using YOLOV5 with transfer learning technique

กวินวิชัย เล้าบัวมิตติ กฤษติน สติรพิวงค์ กิตติพันธ์ พิพัฒสัตยานวงค์ เอกชาคร โชครัตนวิจิตร ฐิติรัตน์ ศิริบวรรัตนกุล*

คณะสถิติประยุกต์ สถาบันบัณฑิตพัฒนบริหารศาสตร์ 148 หมู่3 ถนนเสรีไทย คลองจั่น บางกะปิ กรุงเทพฯ 10240

Kavinwich Laobandit Krittin Satirapiwong Kittipan Pipatsattayanuwong Eakcharkon Chokrattanawijitr Thitirat Siriborvornratanakul*

Graduate School of Applied Statistics, National Institute of Development Administration, 148 Serithai Road, Klong-Chan, Bangkok, Thailand 10240

* Corresponding author.

E-mail: thitirat@as.nida.ac.th; Telephone: 0 2727 3067

วันที่รับบทความ 19 พฤษภาคม 2565; วันที่แก้ไขบทความ ครั้งที่ 1 7 กันยายน 2565; วันที่ตอบรับบทความ 4 ตุลาคม 2565

บทคัดย่อ

การบริหารจัดการคลังสินค้าให้มีประสิทธิภาพนั้น มีความสำคัญอย่างยิ่งในการดำเนินธุรกิจโดยขั้นตอนหนึ่งที่สำคัญคือการตรวจสอบสต็อกสินค้าภายในคลังสินค้าเปรียบเทียบกับตัวเลขสต็อกสินค้าที่เก็บไว้ระบบ ซึ่งขั้นตอนนี้จะต้องใช้พนักงานนับสินค้าจำนวนหลายคนเพื่อที่จะตรวจสอบสต็อกสินค้าในคลังสินค้าทั้งหมด ทำให้ใช้ระยะเวลาในการทำงานยาวนานและมีค่าใช้จ่ายที่สูงและอาจเกิดความผิดพลาดในการตรวจสอบได้ วัตถุประสงค์ของงานวิจัยนี้คือการนำเสนอตัวแบบเพื่อใช้ในการตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเอชเพื่อทำการตรวจสอบสต็อกสินค้า โดยเลือกใช้ตัวแบบที่ผ่านการฝึกมาแล้วล่วงหน้าคือ YOLOV5m และใช้การถ่ายโอนการเรียนรู้ ซึ่งสามารถตรวจจับเหล็กหน้าตัดตัวเอชได้ค่าความแม่นยำ (Precision) เท่ากับ 0.992 ค่าความระลึก (Recall) เท่ากับ 0.822 และค่า F1 score เท่ากับ 0.899

คำสำคัญ

เหล็กหน้าตัดตัวเอช การตรวจจับวัตถุ สินค้าคงคลัง คอมพิวเตอร์วิทัศน์ การเรียนรู้เชิงลึก

Abstract

Effective warehouse management is very important for running a business. An important step is to check the stock in the warehouse compared to the stock numbers stored in the system. This process requires multiple counting staffs to check the stock of all products in the warehouse. It takes a long time to work and is costly and may cause errors in the inspection. Therefore, our research objective is to present a model for detecting H-section hot-rolled steel for stock checking. A pre-trained model, YOLOV5m, is chosen and the transfer learning is used, resulting in H-section steel detection with precision of 0.992, recall of 0.822 and F1 score of 0.899.

Keywords

H-beam steel; object detection; stock; computer vision; deep learning

1. คำนำ

เหล็กรูปพรรณรีดร้อน (Hot rolled steel) ถูกใช้งานอย่างแพร่หลายในงานก่อสร้างตั้งแต่ขนาดเล็กไปจนถึงขนาดใหญ่รวมถึงโครงสร้างพื้นฐานต่างๆ เช่น สะพาน เสาส่งไฟฟ้า และเสาส่งสัญญาณ เป็นต้น เนื่องจากการใช้งานเหล็กรูปพรรณในงานก่อสร้างนั้นสามารถช่วยลดระยะเวลาและใช้แรงงานน้อยกว่าการก่อสร้างด้วยระบบโครงสร้างคอนกรีตเสริมเหล็ก (Reinforced concrete) ดังนั้นเมื่อมีการนำเหล็กรูปพรรณรีดร้อนเข้ามาใช้ในการก่อสร้าง ผู้รับเหมาของโครงการก่อสร้างนั้นจะต้องมีส่งคนมาทำการตรวจสอบจำนวนเหล็กเพื่อรับสินค้า โดยที่พนักงานรับสินค้านั้นจะต้องตรวจสอบว่าจำนวนเหล็กที่นำเข้ามาถูกต้องครบถ้วนตามใบส่งของหรือไม่ หากทำการตรวจสอบแล้วสินค้าถูกต้องครบถ้วนก็จะสามารถรับสินค้าได้ ซึ่งการตรวจรับสินค้าจะใช้วิธีการนับสินค้าที่ละท่อนทำให้ใช้เวลาในการตรวจนับสินค้านานและอาจเกิดความผิดพลาดจากการนับสินค้าได้

เนื่องจากเหล็กรูปพรรณนั้นจะมีขนาดใหญ่กว่าเหล็กเส้น (Steel round bar) ที่ใช้สำหรับโครงสร้างคอนกรีตเสริมเหล็ก การนับสินค้าของเหล็กรูปพรรณจึงมีความยุ่งยากน้อยกว่าการนับจำนวนเหล็กเส้น ทำให้งานวิจัยส่วนใหญ่มุ่งเน้นไปที่การนำเทคโนโลยีในด้านคอมพิวเตอร์วิทัศน์เข้ามาช่วยในการนับเหล็กเส้นเป็นหลักเพื่อให้การตรวจนับสินค้ามีประสิทธิภาพมากยิ่งขึ้นและช่วยลดระยะเวลาในการทำงาน

อย่างไรก็ตามการตรวจนับสินค้าของเหล็กรูปพรรณรีดร้อนสำหรับร้านค้าวัสดุก่อสร้างหรือผู้ผลิตเหล็กรูปพรรณก็ยังเป็นงานที่ต้องใช้เวลาาน เนื่องจากมีจำนวนสินค้าที่ต้องเก็บสต็อกไว้เป็นจำนวนมากในคลังสินค้าของตนเอง และในการบริหารคลังสินค้ายังจำเป็นต้องมีการตรวจสอบจำนวนเหล็กในสต็อกเพื่อเปรียบเทียบกับจำนวนเหล็กที่มีอยู่ในระบบ ซึ่งเป็นขั้นตอนที่ใช้เวลานานและต้องใช้คนในการนับจำนวนหลายคน ส่งผลให้มีค่าใช้จ่ายจำนวนมากในการตรวจนับสินค้าและการใช้คนในการนับยังทำให้มีโอกาสเกิดความผิดพลาดจากการนับสินค้าได้

1.1 การตรวจนับเหล็กโดยไม่ใช้การเรียนรู้เชิงลึก

งานวิจัยของ [1] มีการใช้ Otsu เพื่อตรวจนับหน้าตัดเหล็กเส้น (Image segmentation) ร่วมกับเทคนิค Image

contours เพื่อใช้ในการนับจำนวนเหล็ก ซึ่งสามารถใช้นับจำนวนเหล็กแบบเรียลไทม์ได้ โดยมีความแม่นยำอยู่ที่ 98% และใช้เวลาในการประมวลน้อยกว่า 2 วินาที และจากการศึกษาของ [2] พบว่าการใช้เพียงเทคนิค Canny Edge Detection ร่วมกับ Morphological gradient ก็สามารถนำมาใช้ในการนับจำนวนเหล็กเส้นและแยกประเภทของเหล็กระหว่างเหล็กท่อทรงกลมและเหล็กท่อทรงเหลี่ยมได้เช่นกัน โดยให้ค่า F Score เท่ากับ 0.97

1.2 การตรวจนับเหล็กโดยใช้การเรียนรู้เชิงลึก

งานวิจัยของ [3] ที่ศึกษาการตรวจนับเหล็กเส้นมีการใช้วิธี Convolutional Neural Network (CNN) และ Distance Clustering (DC) ร่วมกันเรียกว่าวิธี CNN-DC ซึ่งวิธีนี้สามารถตรวจนับเหล็กเส้นพร้อมกับหาจุดกึ่งกลางของเหล็กเส้นได้โดยจะทำการคำนวณหาจุด Candidate center ด้วย CNN จากนั้นจะใช้เทคนิค DC เพื่อหาจุดกึ่งกลางของเหล็กเส้นที่ต้องการ ผลลัพธ์ของวิธีการนี้ให้ค่าความแม่นยำ (Accuracy) เท่ากับ 99.26% และค่า F1 score เท่ากับ 0.996 แต่วิธีการนี้จะใช้กับเหล็กเส้นที่มีขนาดของเส้นผ่านศูนย์กลางเฉพาะเจาะจงเท่านั้นและรูปภาพที่ใช้ในการเรียนรู้ (Train) และรูปภาพที่ใช้ในการทดสอบ (Test) ก็ต้องมีการตั้งกล้องถ่ายภาพเฉพาะจุดที่กำหนดไว้ ดังนั้นงานวิจัยของ [4] จึงได้มีการนำเทคนิคการเรียนรู้ของเครื่องจักร (Machine learning) เข้ามาสร้างตัวแบบเพื่อให้สามารถจำแนกประเภทของเหล็กออกมาได้หลายรูปแบบมากขึ้น เรียกว่าตัวแบบ SA-CNN-DC ทำให้ความแม่นยำของตัวแบบเท่ากับ 98%

นอกจากนี้ยังมีงานวิจัยของ [5] ที่ทำการศึกษาค้นคว้าใช้เทคนิค CNN ร่วมกับ Homography และ Gaussian distribution เพื่อแยกประเภทของเหล็กเส้น แต่ก็ยังพบว่ามี ความผิดพลาดสูงเนื่องจากตัวแบบยังติดข้อจำกัดในเรื่องของสภาพแวดล้อม โดยสภาพแวดล้อมส่วนใหญ่ที่ใช้ในการเรียนรู้ยังจำเป็นต้องถูกควบคุมให้เหมือนกัน จึงมีงานวิจัยของ [6] ใช้เทคนิค RetinaNet มาต่อยอดโดยปรับปรุงในเรื่องของขนาดภาพ (Frame size) และฟังก์ชันสูญเสีย (Loss function) ทำให้ตัวแบบสามารถนับจำนวนเหล็กที่วางอยู่ในสภาพแวดล้อมที่แตกต่างกันได้ โดยให้ค่า F1 score เท่ากับ 0.974 และเพื่อให้ตัวแบบมีความแม่นยำมากขึ้นอีกงานวิจัยของ [7] ใช้เทคนิค

Sliding Window Data Augmentation (SWDA) เพื่อเพิ่มจำนวนข้อมูลในชุดข้อมูลและนำเทคนิค Inception-RFB-FPN มาใช้ในการตรวจจับจำนวนเหล็กเส้น โดยให้ค่า F1 score เพิ่มขึ้นเป็น 0.9817

นอกจากนี้เพื่อให้ตัวแบบสามารถทำงานได้ในสภาพแวดล้อมที่หลากหลาย ในวิจัยงานของ [8] ที่ศึกษาการใช้ YOLOv3 ซึ่งมีการทำงาน 3 ขั้นตอน ได้แก่ Feature pyramid, complete IoU and Focal loss และ bag of freebies โดยทั้ง 3 ขั้นตอนนี้เข้ามาช่วยพัฒนาประสิทธิภาพของตัวแบบโดย Feature pyramid ถูกใช้เพื่อเพิ่มประสิทธิภาพตรวจจับเหล็กที่ถูกมัดรวมกัน complete IoU and Focal loss ถูกใช้เพื่อแก้ปัญหา Imbalance class ระหว่างข้อมูลที่เป็นพื้นที่ ที่สนใจกับไม่สนใจ และ bag of freebies ถูกใช้เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของตัวแบบ ทำให้ผลลัพธ์จากตัวแบบนี้มีความแม่นยำสูง โดยให้ค่าความแม่นยำเท่ากับ 99.7%

จากการศึกษางานวิจัยในอดีตพบว่าการใช้เทคนิคต่างๆ ยังขึ้นอยู่กับแค่เหล็กไม่กี่รูปแบบโดยเฉพาะท่อเหล็กทรงกลม ท่อเหล็กทรงเหลี่ยม ซึ่งหน้าตัดเหล็กเหล่านี้จะมีรูปทรงแน่นอน ทำให้งานวิจัยส่วนใหญ่จึงไม่จำเป็นต้องใช้การเรียนรู้เชิงลึกในการตรวจจับเหล็กโดยที่ยังให้ผลลัพธ์ที่แม่นยำและมีการประมวลผลที่รวดเร็ว ขณะที่งานวิจัยที่ตรวจจับเหล็กเส้นจะใช้การเรียนรู้เชิงลึก เนื่องจากรูปทรงของเหล็กเส้นมีรูปร่างที่มีความซับซ้อนกว่า ซึ่งสามารถสรุปได้ดังตารางที่ 1 ทั้งนี้เมื่อพิจารณาถึงลักษณะของเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเองที่ใช้ในงานวิจัยนี้ จะพบว่ามันมีลักษณะที่แตกต่างจากทั้งเหล็กเส้นและเหล็กหน้าตัดรูปทรงอื่นๆ ประกอบกับในการจัดเก็บเหล็กชนิดนี้ในคลังสินค้า จะมีการวางคาบเกี่ยวกันและซ้อนกันเป็นชั้น [9] [10] ดังนั้นในงานวิจัยนี้ผู้วิจัยจึงเลือกใช้ตัวแบบ YOLOV5 เพื่อตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเองโดยเฉพาะ

2. วัสดุ อุปกรณ์ และวิธีการวิจัย

2.1 การเก็บรวบรวมข้อมูล

การเก็บรวบรวมข้อมูลรูปภาพสต็อกสินค้าของเหล็กรูปพรรณรีดร้อนหน้าตัดรูปตัวเองนั้นแสดงตัวอย่างดังรูปที่ 1

โดยเป็นรูปจำนวน 104 รูปที่ผู้วิจัยถ่ายจากคลังสินค้าด้วยกล้องของ Apple iPad Pro ปี 2018 ซึ่งมีความละเอียดภาพขนาด 1478 x 1108 พิกเซล

ตารางที่ 1 สรุปรายละเอียดเทคนิคการตรวจจับของเหล็กแต่ละชนิด

งานวิจัย	ชนิดเหล็ก	เทคนิค
[1]	เหล็กเส้น	Otsu + image contours
[2]	เหล็กทรงกลม	Canny edge + Hough transform
[2]	เหล็กทรงเหลี่ยม	Canny edge + Morphological
[3]	เหล็กเส้น	CNN-DC
[4]	เหล็กทรงกลมและทรงเหลี่ยม	SA-CNN-DC
[5]	เหล็กเส้น	CNN + Homography
[6]	เหล็กเส้น	Improved RetinaNet
[7]	เหล็กเส้น	Inception-RFB-FPN
[8]	เหล็กเส้น	YOLOV3

2.2 การเตรียมชุดข้อมูล

เนื่องจากข้อมูลรูปภาพที่มีลักษณะการกองเก็บจำนวนหลายๆท่อนในคลังสินค้านั้นมีอยู่ไม่มาก ผู้วิจัยจึงทำการเพิ่มจำนวนของรูปภาพด้วยเทคนิค Data augmentation โดยอาศัยการตัดพื้นที่บางส่วนในรูปภาพเดิม (Cutout) จากนั้นใช้โปรแกรม Labellmg สร้างตำแหน่งของกรอบแสดงขอบเขตของวัตถุ (Bounding box) โดยทำการตีกรอบล้อมรอบในส่วนของแถว (Web) ของเหล็กหน้าตัดตัวเอง ดังรูปที่ 2 จากนั้นนำรูปภาพทั้งหมดที่ได้ นำไปเพิ่มฟิลเตอร์ (Filter) ทั้งหมด 6 แบบ โดยแบ่งออกเป็น RandomSunFlare, GaussianNoise, GaussianBlur, RandomBrightnessContrast, Sharpen และ Gray ดังรูปที่ 3 ทำให้มีข้อมูลรูปภาพเพิ่มขึ้นรวมเป็นจำนวนทั้งหมด 1,301 รูป ทั้งนี้การเพิ่มฟิลเตอร์ทั้ง 6 แบบเป็นไปในลักษณะของการผสมผสานฟิลเตอร์ทั้งหกแบบสุ่มเพื่อให้ได้ความหลากหลายของข้อมูลมากที่สุด จากนั้นรูปภาพทั้ง 1,301 รูปจะถูกนำมาแบ่งส่วน (Split) โดยข้อมูลรูปภาพจำนวน 80% (1,040 รูป) จะถูกใช้เป็นชุดข้อมูลในการเรียนรู้ (Training dataset) และที่เหลืออีก 20% (261 รูป) จะถูกใช้เป็นชุดข้อมูลทดสอบ (Testing dataset)



รูปที่ 1 ตัวอย่างข้อมูลรูปภาพสต็อกสินค้าของเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเอชที่ถูกจัดวางในรูปแบบที่แตกต่างกันและถูกถ่ายภาพจากระยะที่ต่างกัน โดยรูปซ้ายเป็นการวางสต็อกสินค้าของเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเอชปริมาณที่มากกว่าสต็อกสินค้าทางรูปขวา ทำให้ภาพเหล็กเส้นในรูปซ้ายมีขนาดหน้าตัดที่เล็กกว่าในรูปขวา

2.3 ตัวแบบที่ใช้ตรวจจับเหล็กรูปพรรณหน้าตัดตัวเอช

ผู้วิจัยนำตัวแบบที่ผ่านการฝึกฝนมาแล้วล่วงหน้า (Pre-trained model) บนชุดข้อมูลโคโค (COCO dataset) ซึ่งพัฒนาโดย Ultralytics มาใช้ในการตรวจจับเหล็กหน้าตัดรูปตัวเอชในงานวิจัยนี้ โดยได้เลือกตัวแบบ YOLOv5m ซึ่งเป็นตัวแบบที่มีประสิทธิภาพระบุด้วยค่า $mAP^{val} 0.5:0.95$ เท่ากับ 45.2 และค่า $mAP^{val} 0.5$ เท่ากับ 63.9 จากนั้นใช้เทคนิคการถ่ายโอนการเรียนรู้ (Transfer learning) เพื่อปรับปรุงการเรียนรู้ใหม่สำหรับการตรวจจับเหล็กหน้าตัดรูปตัวเอช

การกำหนดค่าพารามิเตอร์สำหรับการปรับแต่งการถ่ายโอนการเรียนรู้จะทำการปรับจำนวนคลาสผลลัพธ์ (Number of classes) ให้เท่ากับ 1 และลดขนาดรูปภาพโดยมีความละเอียดของรูปเท่ากับ $1,280 \times 1,280$ พิกเซลโดยเหตุผลในการใช้ความละเอียดของรูปเท่ากับ $1,280 \times 1,280$ พิกเซลนี้ เพราะว่าเป็นขนาดที่รองรับโดยตัวแบบที่เลือกใช้และเป็นขนาดที่ยังสามารถเห็นรายละเอียดของหน้าตัดเหล็กในภาพได้ นอกจากนี้ยังมีการกำหนดค่า Batch size เท่ากับ 8 มีจำนวนรอบในการฝึกฝนเท่ากับ 6,000 รอบและกำหนดอัตราการเรียนรู้ (Learning rate) เท่ากับ 0.01 โดยในขณะการฝึกฝนในแต่ละรอบหากค่าการสูญเสียการสอน (Training loss) 100 รอบล่าสุดไม่ลดลงหรือเริ่มคงที่จะหยุดการสอนและสำหรับค่าพารามิเตอร์อื่นๆนั้นจะใช้ค่าตามเดิมของตัวแบบที่ได้ผ่านการฝึกฝนล่วงหน้าแล้ว

2.4 การประเมินประสิทธิภาพของตัวแบบ

การประเมินประสิทธิภาพของตัวแบบเพื่อตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดเอชจะพิจารณาจากค่าดังนี้

ค่าความแม่นยำ (Precision) หมายถึงประสิทธิภาพที่คำนวณจากสัดส่วนระหว่างจำนวนของวัตถุที่ตรวจจับได้ถูกต้อง (TP) กับจำนวนวัตถุที่ตรวจจับได้ทั้งหมด (TP+FP) ดังสมการที่ (1)

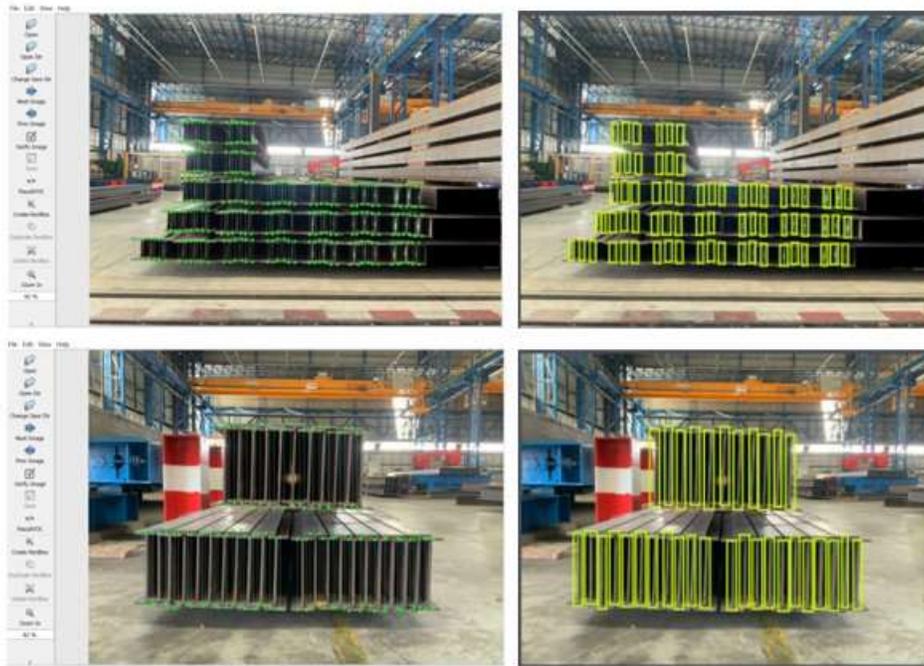
$$\text{Precision} = \frac{TP}{(TP + FP)} \quad (1)$$

ค่าความระลึก (Recall) หมายถึงประสิทธิภาพที่คำนวณจากสัดส่วนระหว่างจำนวนของวัตถุที่ตรวจจับได้ถูกต้อง (TP) กับจำนวนวัตถุที่ถูกต้องทั้งหมด (TP+FN) ดังสมการที่ (2)

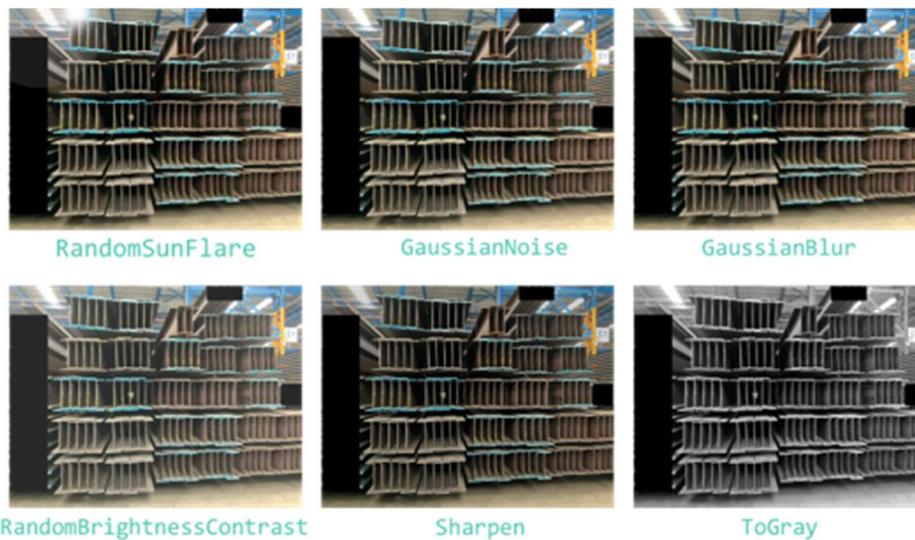
$$\text{Recall} = \frac{TP}{(TP + FN)} \quad (2)$$

ค่า F1 score หมายถึงค่าเฉลี่ยแบบ Harmonic mean ระหว่างค่าความแม่นยำและค่าความระลึก ดังสมการที่ (3)

$$\text{F1 score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$



รูปที่ 2 ตัวอย่างข้อมูลรูปภาพที่ถูกสร้างกรอบแสดงขอบเขตของวัตถุบริเวณแถวของเหล็กโดยโปรแกรม LabelImg

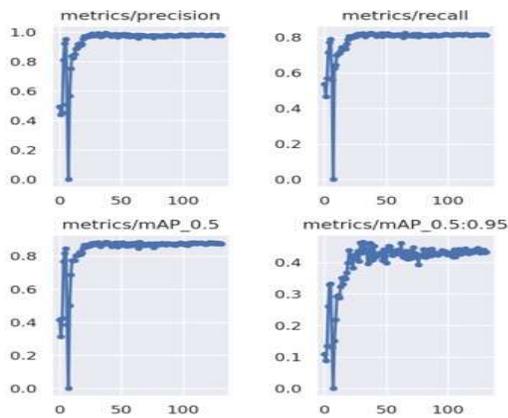


รูปที่ 3 ตัวอย่างข้อมูลรูปภาพหลังจากทำการเพิ่มจำนวนของรูปภาพ

3. ผลการวิจัยและการอภิปรายผล

จากการฝึกฝนและทดสอบด้วยตัวแบบ YOLOV5m สำหรับการตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเอชโดยใช้ Google Colab Pro ด้วย GPU รุ่น Tesla T4 แรม 16GB มีจำนวนรอบการเรียนรู้ทั้งหมด 132 รอบ ได้ผลการทดสอบคือ ตัวแบบมีค่าความแม่นยำ (Precision) เท่ากับ 0.992 ค่าความระลึก (Recall) เท่ากับ 0.822 และค่า F1 score เท่ากับ 0.899 และมีกราฟแสดงการเรียนรู้ดังรูปที่ 4 จากรูปจะเห็นว่าในช่วง

ต้นของการเรียนรู้ที่กราฟทั้งสองมีการแกว่งเล็กน้อยแต่เมื่อเรียนรู้ผ่านไปสักระยะกราฟส่วนใหญ่ก็เริ่มคงที่ ทั้งนี้กราฟล่างซ้ายซึ่งเป็นกราฟแสดง mAP (mean Average Precision) เมื่อกำหนดให้ค่าจุดตัด IoU (Intersection over Union) มีค่าเท่ากับ 0.5 นั้นมีความคงที่ของเส้นกราฟมากกว่ากราฟล่างขวาเนื่องจากกราฟล่างขวาเป็นกราฟแสดงค่าของ mAP ที่เฉลี่ยจากค่าจุดตัด IoU หลายค่าตั้งแต่ 0.5 ถึง 0.95 (โดยขยับค่าของจุดตัด IoU ทีละ +0.05)



รูปที่ 4 กราฟแสดงผลของการเรียนรู้ทั้งหมด 132 รอบ ซึ่งประกอบด้วย ค่าความแม่นยำ (กราฟบนซ้าย) ค่าความระลึกลับ (กราฟบนขวา) ค่าเฉลี่ยของค่าความแม่นยำ ณ IoU=0.5 (กราฟล่างซ้าย) และ ค่าเฉลี่ยของค่าความแม่นยำตั้งแต่ IoU เท่ากับ 0.5 ถึง 0.95 (กราฟล่างขวา)

อย่างไรก็ตามตัวแบบยังตรวจจับเหล็กหน้าตัดตัวเอชได้ไม่ดีในหลายๆกรณีดังรูปที่ 5 เช่นกองเหล็กในรูปภาพอยู่ในระยะไกลเกินไปทำให้ตัวแบบไม่สามารถมองเห็นขนาดและลักษณะเด่นของหน้าตัดรูปตัวเอชในภาพได้ชัดเจนเพียงพอสำหรับการตรวจจับ หรือกองเหล็กที่มีการวางใกล้ชิดกันมากจนทำให้ตัวแบบมองไม่เห็นหน้าตัดตัวเอชของเหล็กแต่ละเส้นแยกกันชัดเจน หรือหากในรูปภาพมีจำนวนเหล็กทั้งหน้าตัดขนาดเล็กและหน้าตัดขนาดใหญ่ ตัวแบบจะตรวจจับเหล็กที่มีหน้าตัดขนาดเล็กได้ไม่ดี ซึ่งอาจจะทำการแก้ไขโดยเพิ่มจำนวนชุดข้อมูลในการเรียนรู้สำหรับหน้าตัดขนาดเล็กมากขึ้นหรือการปรับค่าพารามิเตอร์ในส่วนของ Anchor boxes



A. แสดงการตรวจจับกองเหล็กที่อยู่ไกล



B. แสดงการตรวจจับกองเหล็กที่มีการวางชิดกัน



C. แสดงการตรวจจับกองเหล็กที่มีหลายขนาด



D. แสดงการตรวจจับกองเหล็กที่อยู่ไกลและไกล



E. แสดงการตรวจจับลวดมัดเหล็ก



F. แสดงการตรวจจับช่องแสงระหว่างเหล็ก

รูปที่ 5 ตัวอย่างผลการตรวจจับที่มีปัญหา

นอกจากนี้การที่ผู้วิจัยทำการตีกรอบล้อมรอบในส่วนของ เหวเหล็กหน้าตัวเอช ทำให้มีการตรวจจับวัตถุอื่น ๆ ที่มีลักษณะ คล้ายกันเช่น ลวดมัดเหล็กและช่องแสงระหว่างเหล็ก การ แยกแยะความแตกต่างในกรณีนั้นนอกจากการแก้ไขทางตรงที่ ต้องเพิ่มเติมชุดข้อมูลที่ใช้ฝึกสอนตัวแบบให้มีความหลากหลาย และครอบคลุมสถานการณ์จริงดังกล่าวให้ได้ทั้งหมดแล้ว ยัง รวมถึงทางเลือกของการใช้เทคนิคตรวจจับอื่น เช่น การหาจุด สันใจของภาพ (Keypoint detection) ซึ่งจะสามารถตรวจจับ รูปร่างตัวเอชของหน้าตัดเหล็กได้ดีกว่าเทคนิคที่ใช้การวงกรอบ สีเหลี่ยมในปัจจุบัน

4. สรุปผลการศึกษา

งานวิจัยนี้นำเสนอวิธีการตรวจจับเหล็กรูปพรรณรีดร้อน หน้าตัดตัวเอชด้วยตัวแบบ YOLOV5m ที่ผ่านการฝึกฝนมา ล่วงหน้าบนชุดข้อมูลโคโค และใช้เทคนิคการถ่ายโอนการเรียนรู้เพื่อปรับปรุงการเรียนรู้ใหม่ ผลการทดลองพบว่าตัวแบบ สามารถตรวจจับเหล็กรูปพรรณรีดร้อนหน้าตัดตัวเอชได้โดยให้ ค่าความแม่นยำเท่ากับ 0.992 ค่าความระลึกลับเท่ากับ 0.822 และค่า F1 score เท่ากับ 0.899 ผลการศึกษาวิจัยที่ได้นี้ สามารถถูกนำไปต่อยอดเพื่อเพิ่มความแม่นยำในการตรวจจับ เหล็กเส้น รวมถึงสามารถนำไปพัฒนาตัวแบบอื่น ๆ ให้สามารถ ตรวจจับเหล็กหน้าตัดอื่นๆได้ด้วย เช่น เหล็กรางน้ำ (Channel Steel), เหล็กฉาก (Angle Steel) และเหล็กเข็มพืด (Sheet Pile Steel)

เอกสารอ้างอิง

- [1] Liu X, Ouyang J. (2018). Research on steel bar detection and counting method based on contours. In: *Proceeding of 2018 International Conference on Electronics Technology (ICET)*. Chengdu, China; 23-27 May 2018. pp. 294-297.
- [2] Ghazali MF, Wong LK, See J. Automatic Detection and Counting of Circular and Rectangular Steel Bars. In: *Proceeding of 9th International Conference on Robotic, Vision, Signal Processing and Power Applications*. Lecture Notes in Electrical Engineering. Springer, Singapore. 2017;398.
- [3] Fan Z, Lu J, Qiu B, Jiang T, An K. Josephraj A, et al. Automated steel bar counting and center localization with convolutional neural networks. arXiv.org. 2019. Available from: <https://arxiv.org/abs/1906.00891>.
- [4] Hernández-Ruiz AC, Martínez-Nieto JA, Alejandro Buldain- Pérez, JD. Steel bar counting from images with machine learning. *Electronics*. 2021;10(4):402.
- [5] Shin Y, Heo S, Han S, Kim J, Na S. An image-based steel rebar size estimation and counting method using a convolutional neural network combined with homography. *Buildings*. 2021; 11:463.
- [6] Han Y, Chenghua F. (2019). Quantity detection of steel bars based on deep learning. *Open Access Library Journal*. 2019;6: e5784.
- [7] Zhu Y, Tang C, Liu H, Huang P. End- face localization and Segmentation of steel bar based on convolution neural network. *IEEE Access*.2020;8:4679-74690.
- [8] Yang L, Yujie L, Jun C. A deep learning approach for real-time rebar counting on the construction site based on YOLOv3 detector. *Automation in Construction*. 2021;124: 103602.
- [9] Zhang W, Zhu C, Widera GEO. On the use of the upper-bound method for load determination in H-beam rolling. *Journal of Materials Processing Technology*. 1996;56(1): 820-833.
- [10] Guan B, Zang Y, Wu D, Qin Q. Stress-inheriting behavior of H-beam during roller straightening process. *Journal of Materials Processing Technology*. 2017;244: 253-272.