

การใช้ปัญญาประดิษฐ์เชิงตัวแทนในการติดตามเหล็กเสริมในสถานที่ก่อสร้าง เพื่อเพิ่มความสามารถในการจัดการโครงการก่อสร้าง

Utilizing Agentic AI for Rebar Tracking on Construction Sites to Enhance Construction Project Management

ภูมิพัฒน์ เดชชัย¹, พิศพันธ์ ขาววุฒินันท์^{2,*}, วัชร เพียรสุภาพ³, และ มานพ แก้วโมราเจริญ⁴

^{1,3,4} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย กรุงเทพมหานคร

² ภาควิชาเคหการ คณะสถาปัตยกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย กรุงเทพมหานคร

*Corresponding author; E-mail address: phatsaphan.c@chula.ac.th

บทคัดย่อ

การจัดการวัสดุก่อสร้างอย่างแม่นยำเป็นหัวใจสำคัญของการเพิ่มประสิทธิภาพโครงการและลดการสูญเสียวัสดุโดยไม่จำเป็น งานวิจัยนี้นำเสนอระบบตรวจสอบเหล็กเสริมโดยใช้ปัญญาประดิษฐ์เชิงตัวแทน ผสานกับเทคโนโลยีการมองเห็นของคอมพิวเตอร์เพื่อเพิ่มความสามารถในการติดตามและควบคุมวัสดุก่อสร้างแบบอัตโนมัติ ระบบประกอบด้วยกระบวนการวางแผน การตัดสินใจ และการประเมินผลแบบวนรอบ โดยใช้ภาพจากไซต์งานจริงในกระบวนการตรวจสอบตั้งแต่การขนส่ง ไปจนถึงการวางเหล็กเสริมก่อนเทคอนกรีต โมเดล YOLOv8 ถูกนำมาใช้ในการตรวจจับหน้าตัดและความยาวของเหล็กเสริม พร้อมเปรียบเทียบกับแบบจำลองโครงสร้างสามมิติเพื่อวิเคราะห์ความสอดคล้องกับปริมาณที่ต้องใช้จริง ข้อมูลที่ได้ยังถูกนำไปประมวลผลเพื่อกำหนดรูปแบบการตัดเหล็กเสริมให้เหมาะสมกับวัสดุที่มีจำหน่ายจริงในท้องตลาด โดยมีเป้าหมายเพื่อลดของเสียและเพิ่มความแม่นยำในการใช้วัสดุ การประยุกต์ใช้ปัญญาประดิษฐ์เชิงตัวแทนในงานนี้แสดงให้เห็นถึงศักยภาพในการเสริมสร้างระบบการจัดการวัสดุก่อสร้างให้มีประสิทธิภาพและพร้อมใช้งานในสภาพแวดล้อมจริงของไซต์งาน

คำสำคัญ: ปัญญาประดิษฐ์เชิงตัวแทน, การมองเห็นของคอมพิวเตอร์, การตรวจสอบเหล็กเสริม, การจัดการวัสดุก่อสร้าง

Abstract

Accurate construction material management is essential for enhancing project efficiency and minimizing unnecessary waste. This study proposes a rebar inspection system that integrates Agentic Artificial Intelligence with Computer Vision technology to enable automated tracking and control of construction materials. The system follows a cyclical workflow consisting of planning, decision-making, and performance evaluation, using real-site imagery to inspect rebar across key stages—ranging from transportation to placement before concrete pouring. The YOLOv8 model is utilized for detecting both rebar cross-sections and full-length geometry, with results compared against a 3D structural model to verify alignment with actual material requirements. The acquired data is further processed to optimize rebar cutting patterns based on standard commercial lengths, aiming to reduce waste and improve material utilization. The implementation of Agentic AI in this context demonstrates strong potential for advancing construction material

management systems, enhancing both operational efficiency and readiness for deployment in real-world construction environments.

Keywords: Agentic AI, Computer vision, Rebar tracking, Construction material management

1. คำนำ

ในโครงการก่อสร้างการบริหารจัดการเหล็กเสริมเป็นหนึ่งในขั้นตอนสำคัญที่ส่งผลโดยตรงทั้งต้นทุนและคุณภาพของงานก่อสร้าง ตั้งแต่กระบวนการวางแผน การจัดซื้อ การตัดเหล็กเสริม และการนำไปใช้ หากมีการบริหารจัดการที่มีประสิทธิภาพจะช่วยลดต้นทุนได้อย่างมีประสิทธิภาพ การลดปริมาณเหล็กเสริมจากแบบจำลองโครงสร้างสามมิติช่วยให้สามารถคำนวณหาปริมาณการใช้งานจริงได้อย่างแม่นยำ ส่งผลให้การจัดซื้อเหล็กเสริมมีความสอดคล้องกับความต้องการใช้งานจริงในหน้างาน เหล็กเสริมในแบบก่อสร้างมักมีความยาวหลากหลาย ไม่สามารถสั่งซื้อได้ตามความยาวที่ต้องการโดยตรง จึงจำเป็นต้องแปลงค่าที่ได้มาเป็นรายการตัดเหล็ก โดยพิจารณาจากขนาดมาตรฐานที่มีจำหน่าย เช่น 10 เมตร และ 12 เมตร พร้อมทั้งดำเนินการวิเคราะห์รูปแบบการตัดเพื่อลดปริมาณเศษเหล็กที่เหลือทิ้งให้น้อยที่สุด ซึ่งกระบวนการนี้สามารถดำเนินการได้อย่างมีประสิทธิภาพด้วยการประมวลผลผ่านโปรแกรมคอมพิวเตอร์

นอกจากนี้ เพื่อเพิ่มความแม่นยำในกระบวนการควบคุมวัสดุ ระบบการตรวจนับเหล็กเสริมโดยใช้เทคโนโลยีการประมวลผลภาพและการมองเห็นของคอมพิวเตอร์ จึงถูกนำมาใช้เพื่อตรวจสอบจำนวนเหล็กเสริมที่สั่งซื้อและจัดส่งจริงให้ตรงกับปริมาณที่คำนวณได้จากแบบจำลอง พร้อมทั้งช่วยตรวจสอบการวางแผนของเหล็กเสริมก่อนการเทคอนกรีต เพื่อให้แน่ใจว่างานก่อสร้างดำเนินไปตามแบบก่อสร้างจริง

2. หลักการและทฤษฎีที่เกี่ยวข้อง

2.1 การบริหารจัดการเหล็กเสริมในสถานที่ก่อสร้าง

เหล็กเสริมถือเป็นวัสดุก่อสร้างหลักที่มีสัดส่วนต้นทุนสูงในงานโครงสร้างคอนกรีตเสริมเหล็ก โดยเฉพาะในบางโครงการที่สัดส่วนของต้นทุนเหล็กเสริมอาจสูงถึง 60% ของต้นทุนโครงการทั้งหมด (Zheng et al., 2019) การบริหารจัดการเหล็กเสริมในสถานที่ก่อสร้างจึงมีความสำคัญอย่างยิ่ง ไม่เพียงเพื่อลดต้นทุนวัสดุ แต่ยังช่วยเพิ่มประสิทธิภาพการทำงานในภาคสนาม และลดของเสียจากกระบวนการตัดเหล็กเสริม การวางแผนอย่างบูรณาการตั้งแต่ขั้นตอนออกแบบ การจัดซื้อ การตัดเหล็ก ไปจนถึงการจัดตั้งในหน้างาน เป็นแนวทางสำคัญที่ได้รับการศึกษาและพัฒนาอย่างต่อเนื่อง

2.2 ปัญญาประดิษฐ์เชิงตัวแทน

ปัญญาประดิษฐ์เชิงตัวแทน (Agentic Artificial Intelligence) เป็นแนวคิดใหม่ที่พัฒนาเหนือกว่าปัญญาประดิษฐ์แบบดั้งเดิม โดยมีคุณสมบัติในการกำหนดเป้าหมาย ปรับกลยุทธ์ และตัดสินใจอย่างอัตโนมัติโดยมีการพึ่งพาการแทรกแซงจากมนุษย์น้อยที่สุด (Acharya et al., 2025; Viswanathan, 2025) โดย Agentic AI ประกอบด้วยโครงสร้างหลัก 4 ชั้น ได้แก่ ชั้นการรับรู้ที่ใช้เทคโนโลยีอย่าง Computer Vision และ NLP ชั้นการตัดสินใจที่อาศัย Reinforcement Learning ชั้นการปฏิบัติการที่เชื่อมต่อกับระบบอัตโนมัติ และชั้นการเรียนรู้ที่ใช้ Meta-Learning ในการปรับตัวต่อสิ่งแวดล้อมแบบไดนามิก (Parab, 2024) ทั้งนี้ นักวิจัยได้พัฒนาเกณฑ์ประเมินประสิทธิภาพของ Agentic AI เช่น อัตราความสำเร็จของเป้าหมาย (GAR), คะแนนการปรับตัว (AS), ประสิทธิภาพการตัดสินใจ (DE), การใช้ทรัพยากรอย่างมีประสิทธิภาพ (ROI), ความสามารถในการทำงานร่วมกับมนุษย์ (HCI) และการปฏิบัติตามจริยธรรม (ECS) เพื่อใช้วัดความสามารถของระบบในด้านต่าง ๆ (Viswanathan, 2025) ปัจจุบัน Agentic AI ได้รับการประยุกต์ใช้อย่างหลากหลายในภาคส่วนต่าง ๆ เช่น การนับเหล็กเสริมในอุตสาหกรรมก่อสร้าง การวินิจฉัยโรคในระบบสุขภาพ การตรวจจับการฉ้อโกงในระบบการเงิน และระบบหุ่นยนต์ในโรงงานผลิตอัจฉริยะ ทั้งนี้ ทิศทางการวิจัยในอนาคตมุ่งเน้นการเพิ่มความแม่นยำในการตัดสินใจ การเสริมแนวทางด้านจริยธรรม และการเพิ่มขีดความสามารถในการทำงานร่วมกับมนุษย์ เพื่อให้ปัญญาประดิษฐ์เชิงตัวแทนกลายเป็นระบบอัจฉริยะที่น่าเชื่อถือและมีประโยชน์ต่อสังคมในระยะยาว (Shavit et al., 2025)

2.3 วิธีการนับเหล็กเสริม

2.3.1 วิธีการนับเหล็กเสริมแบบดั้งเดิม

ในกระบวนการก่อสร้าง เหล็กเสริมถือเป็นวัสดุหลักที่มีบทบาทสำคัญต่อความมั่นคงของโครงสร้าง ซึ่งวิธีการนับเหล็กเสริมแบบดั้งเดิมที่ใช้แรงงานมนุษย์และการตรวจสอบด้วยสายตาตามข้อจำกัดด้านเวลา ความแม่นยำ และความสอดคล้องกับสภาพแวดล้อมของโครงการยุคใหม่ ด้วยเหตุนี้จึงมีการพัฒนาเครื่องมือและเทคโนโลยีใหม่เพื่อเพิ่มประสิทธิภาพในการนับเหล็กเสริม โดยสามารถแบ่งออกได้เป็น 5 กลุ่มหลัก ได้แก่ (1) วิธีการที่ใช้การประมวลผลภาพ ซึ่งใช้กล้องและเทคนิคการรู้จำวัตถุร่วมกับอัลกอริทึมการเรียนรู้ของเครื่องเพื่อตรวจจับเหล็กเสริมในภาพถ่าย (2) ระบบโดรน ซึ่งเหมาะกับไซต์งานขนาดใหญ่ที่ต้องการการเก็บข้อมูลจากพื้นที่ที่เข้าถึงยาก (3) แอปพลิเคชันบนมือถือที่รองรับการอัปเดตข้อมูลแบบเรียลไทม์และผสานเทคโนโลยีเสมือนจริงเพื่อการใช้งานในไซต์ (4) อัลกอริทึมเฉพาะทาง เช่น YOLO ที่สามารถตรวจจับเหล็กเสริมได้แม้ในสภาพแสงและการจัดเรียงที่ซับซ้อน และ (5) ระบบวิชันแมชชีนที่ผสานกล้อง เช่นเซอร์ และการประมวลผลเชิงลึกเพื่อสร้างระบบตรวจจับอัตโนมัติที่แม่นยำสูง แม้จะต้องใช้การลงทุนและความเชี่ยวชาญเฉพาะทาง เทคโนโลยีเหล่านี้จึงมีศักยภาพในการทดแทนการนับแบบดั้งเดิมอย่างมีประสิทธิภาพในยุคของการก่อสร้างสมัยใหม่หากจะใช้ต้นแบบนี้

2.3.2 วิธีการนับเหล็กเสริมด้วยปัญญาประดิษฐ์


ในช่วงทศวรรษที่ผ่านมา อุตสาหกรรมก่อสร้างได้ปรับเปลี่ยนจากการพึ่งพาวิธีการแบบดั้งเดิมที่ใช้แรงงานมนุษย์ มาสู่การนำเทคโนโลยีการประมวลผลภาพและปัญญาประดิษฐ์มาใช้ โดยเฉพาะเครือข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) และโมเดล YOLO (You Only Look Once) ซึ่งได้รับความนิยมสูงในการตรวจจับวัตถุ

แบบเรียลไทม์ในสภาพแวดล้อมก่อสร้างที่ซับซ้อน YOLO ได้รับการนำมาใช้ในงานก่อสร้างเพื่อการนับเหล็กเสริม ตรวจสอบวัสดุ และติดตามความคืบหน้าของโครงการ โดย Li et al. (2021) แสดงให้เห็นว่า YOLOv3 สามารถตรวจจับเหล็กเสริมได้อย่างแม่นยำถึง 99.7% แม้ในสภาพแสงไม่สม่ำเสมอหรือมีวัตถุบดบัง และได้รับการพัฒนาต่อยอดใน YOLOv4 และ YOLOv8 ให้สามารถตรวจจับวัตถุที่เล็กและซับซ้อนได้ดียิ่งขึ้น นอกจากนี้ Chen et al. (2024) ยังได้พัฒนาแอปพลิเคชันบนมือถือร่วมกับ YOLO เพื่อการนับและตรวจสอบวัสดุก่อสร้างแบบเรียลไทม์ อีกทั้งยังมีการประยุกต์ใช้อัลกอริทึมการเรียนรู้ของเครื่อง เช่น CNN-DC Framework และเทคนิคคลัสเตอร์เพื่อตรวจหาตำแหน่งเหล็กเสริมอย่างแม่นยำ และงานวิจัยของ Hernández-Ruiz et al. (2021) ที่ใช้การเรียนรู้ของเครื่องในการนับวัสดุจากภาพถ่ายเพื่อลดภาระในการติดตามข้อมูลแบบแมนนวล ขณะที่ Nath & Behzadan (2020) ได้ขยายขอบเขตการใช้ YOLO ไปสู่การตรวจจับเครื่องจักร แรงงาน และการติดตามความปลอดภัยในไซต์งาน โดยแสดงให้เห็นว่า YOLOv3 มีความแม่นยำกว่า YOLOv2 ในการตรวจจับวัตถุขนาดเล็กในพื้นที่จำกัด นอกจากนี้ยังมีการใช้เทคโนโลยี machine vision ร่วมกับเซ็นเซอร์ตรวจจับคุณภาพของเหล็กเสริมโดยไม่ต้องอาศัยแรงงานมนุษย์ (Zhang et al., 2018) ทำให้เทคโนโลยี YOLO และการเรียนรู้ของเครื่องกลายเป็นเครื่องมือสำคัญในการเสริมสร้างประสิทธิภาพด้านการจัดการวัสดุ การตรวจสอบคุณภาพ และการบริหารความคืบหน้าในงานก่อสร้างยุคใหม่อย่างมีประสิทธิภาพ

ในงานวิจัยนี้ได้มีการนำแนวคิดต่อยอดจากการใช้ปัญญาประดิษฐ์พื้นฐานมาช่วยในการบริหารจัดการเหล็กเสริมในโครงการก่อสร้าง

3. วิธีการดำเนินงาน

งานวิจัยนี้นำเสนอกรอบแนวคิดของปัญญาประดิษฐ์เชิงตัวแทนสำหรับการจัดการเหล็กเสริมในงานก่อสร้าง โดยระบบสามารถดำเนินการถอดปริมาณ จัดทำรายการตัด ตรวจสอบ และติดตามการใช้งานเหล็กเสริมโดยอัตโนมัติ ระบบประกอบด้วยขั้นตอนวางแผน การใช้เครื่องมือประมวลผลภาพเพื่อตรวจสอบวัสดุ และการเรียนรู้เพื่อตอบสนองต่อข้อมูลใหม่อย่างต่อเนื่อง เพื่อเพิ่มความแม่นยำและประสิทธิภาพในกระบวนการจัดการวัสดุก่อสร้างดังแสดงในรูปที่ 1




รูปที่ 1 แผนภาพการทำงานของตัวแทนปัญญาประดิษฐ์


3.1 กรอบแนวคิดปัญญาประดิษฐ์เชิงตัวแทน

กรอบแนวคิดการทำงานของตัวแทนปัญญาประดิษฐ์ ประกอบด้วยสามขั้นตอนหลัก ได้แก่ การวางแผน การลงมือปฏิบัติ และการสะท้อนผลลัพธ์ โดยเริ่มจากการนำเข้าสู่ข้อมูลเพื่อวิเคราะห์และแบ่งแผนงานออกเป็นส่วย่อยเพื่อให้สามารถเลือกเครื่องมือหรือวิธีการที่เหมาะสมกับลักษณะของงานในแต่ละส่วนได้อย่างมีประสิทธิภาพ จากนั้นระบบจะดำเนินการตามแผนโดยเลือกใช้เครื่องมือที่เหมาะสม เพื่อให้ผลลัพธ์ตรงตามเป้าหมาย และหากยังไม่เป็นที่น่าพอใจ ระบบจะวนกลับมาทำซ้ำจนกว่าจะได้ผลลัพธ์ที่ดีที่สุด ในขั้นตอนสุดท้าย ระบบจะทำการประเมินผลลัพธ์โดยเปรียบเทียบกับเป้าหมายที่กำหนดไว้ หากพบว่าสามารถปรับปรุงได้ จะกลับไปเริ่มต้น


กระบวนการวางแผนใหม่อีกครั้ง ทำให้ระบบสามารถเรียนรู้และพัฒนาตนเองอย่างต่อเนื่องดังแสดงในรูปที่ 2-4



รูปที่ 2 แผนภาพการวางแผนของตัวแทนปัญญาประดิษฐ์



รูปที่ 3 แผนภาพการเลือกใช้เครื่องมือของตัวแทนปัญญาประดิษฐ์



รูปที่ 4 แผนภาพการสะท้อนผลลัพธ์ของตัวแทนปัญญาประดิษฐ์

3.2 การเก็บข้อมูล

ในงานวิจัยนี้ได้มีการรวบรวมภาพเหล็กเสริมจากหลายแหล่งที่มา ได้แก่ ไซต์ก่อสร้างจริง ฐานข้อมูลสาธารณะ และแหล่งข้อมูลออนไลน์ โดยคัดเลือกภาพที่มีความหลากหลายทั้งในด้านมุมมอง สภาพแสง และรูปแบบการจัดวางของเหล็กเสริม เพื่อให้ครอบคลุมบริบทที่พบในสถานการณ์จริง ความหลากหลายของชุดข้อมูลนี้ช่วยเสริมความสามารถของแบบจำลองในการ

เรียนรู้และประมวลผลได้อย่างแม่นยำเมื่อนำไปประยุกต์ใช้ในสภาพแวดล้อมจริง ในส่วนของภาพที่ใช้ทดสอบได้นำภาพเหล็กเสริมที่ได้จากไซต์ก่อสร้างจริงที่โครงการสถานีรถไฟสายสีม่วงสำหรับภาพด้านหน้าและภาพการวางแนวเหล็กเสริมจากไซต์โครงการบ้านแฝดที่โครงการนิเวศกัลปพฤกษ์

3.3 การพัฒนาและฝึกฝนโมเดลสำหรับการตรวจจับเหล็กเสริม

งานวิจัยนี้ใช้โมเดลตรวจจับวัตถุ YOLOv8 โดยทำการฝึกฝนโมเดลปัญญาประดิษฐ์ 2 แบบที่แตกต่างกันบนเวิร์กสเตชันเฉพาะทาง เพื่อใช้ในการตรวจจับเหล็กเสริมในแต่ละขั้นตอนของกระบวนการก่อสร้าง โดยโมเดลแรกถูกออกแบบมาเพื่อตรวจจับหน้าตัดของเหล็กเสริม โดยใช้สถาปัตยกรรม YOLOv8M ขณะที่โมเดลที่สองเน้นการตรวจจับและแบ่งส่วนความยาวทั้งหมดของเหล็กเสริม โดยใช้สถาปัตยกรรม YOLOv8M-seg โมเดลทั้งสองได้รับการฝึกจากชุดข้อมูลจำนวน 1,126 ภาพ สำหรับการตรวจจับหน้าตัดและ 1,688 ภาพ สำหรับการตรวจจับความยาวของเหล็กเสริม โดยมีการปรับชุดข้อมูลให้เหมาะสมกับวัตถุประสงค์เฉพาะของแต่ละโมเดล รายละเอียดการฝึกฝนแสดงในตารางที่ 1

ตารางที่ 1 รายละเอียดการฝึกฝนโมเดลสำหรับเหล็กเสริม 2 แบบ

หัวข้อ	ภาพถ่ายด้านหน้า	ภาพถ่ายด้านบน
จำนวนภาพรวม	1,126 ภาพ	1,688 ภาพ
แหล่งข้อมูล	Roboflow - Kites 2023	Roboflow - Rebar Segmentation
การแบ่งสัดส่วนข้อมูล	Train: 897 ภาพ	Train: 1,549 ภาพ
	Validation: 130 ภาพ	Validation: 80 ภาพ
	Test: 99 ภาพ	Test: 59 ภาพ
การใช้งาน	ตรวจจับเหล็กก่อนขนลงจากรถบรรทุกและอัปเดตสถานะเหล็กระหว่างอยู่ในสต็อก	Segmentation เพื่อตรวจสอบจำนวนเหล็กเสริมก่อนเทคอนกรีต
โมเดลที่ใช้	YOLOv8M (Object Detection)	YOLOv8M-seg (Instance Segmentation)

โดยโมเดล YOLOv8M ถูกฝึกมาเพื่อมุ่งเน้นการตรวจจับลักษณะหน้าของเหล็กเสริมให้แม่นยำที่สุด ขณะที่ YOLOv8M-seg มุ่งเน้นการแยกเส้นและตำแหน่งของเหล็กเสริมทั้งเส้น เพื่อให้สามารถวิเคราะห์ลักษณะการจัดเรียงและรูปทรงโดยรวมได้อย่างครบถ้วน การใช้โมเดลแบบเฉพาะทางทั้งสองช่วยเพิ่มความแม่นยำและความยืดหยุ่นในการตรวจจับเหล็กเสริมในแต่ละสถานการณ์ในไซต์ก่อสร้าง โดยกระบวนการฝึกฝนดำเนินการบนเวิร์กสเตชันที่มีการ์ดจอ NVIDIA GeForce RTX 4060 Ti หน่วยความจำ RAM ขนาด 32 GB และหน่วยประมวลผล Intel Core i5-14400F (16 คอร์ ความเร็ว 2.5 GHz)

ในการประเมินประสิทธิภาพของโมเดลการตรวจจับเหล็กเสริม ได้ใช้เมตริกมาตรฐานในงานด้านการตรวจจับวัตถุ ซึ่งประกอบด้วย Precision, Recall, mAP@50 และ mAP@50-95 โดยมีรายละเอียดดังแสดงในตารางที่ 2

ตารางที่ 2 เกณฑ์การประเมินประสิทธิภาพของโมเดล

เมตริกซ์	คำอธิบาย
Precision	วัดความแม่นยำของการตรวจจับ โดยคำนวณจากสัดส่วนของวัตถุที่ตรวจพบทั้งหมดที่เป็นจริง (True Positives) ยิ่งค่าสูง แสดงว่าโมเดลตรวจจับผิดพลาดน้อย

Recall	วัดความครอบคลุมของการตรวจจับ โดยคำนวณจากสัดส่วนของวัตถุทั้งหมดที่ตรวจจับได้จริง ยิ่งค่าสูง แสดงว่าโมเดลสามารถตรวจจับได้ครบถ้วน
mAP@50	ค่าเฉลี่ยของความแม่นยำเมื่อกำหนดค่า IoU ≥ 0.5 เป็นเกณฑ์ขั้นต่ำ ใช้ประเมินเบื้องต้นว่าการตรวจจับอยู่ในตำแหน่งใกล้เคียงวัตถุจริงหรือไม่
mAP@50-95	ค่าเฉลี่ยของ mAP ที่คำนวณจากค่า IoU ตั้งแต่ 0.5 ถึง 0.95 (เพิ่มทีละ 0.05) เป็นตัวชี้วัดที่เข้มงวดขึ้น สะท้อนความแม่นยำโดยรวมของโมเดลในหลายระดับความทับซ้อน

DB20	51	28
RB9	1	101



รูปที่ 5 ตัวอย่างการตรวจนับเหล็กเสริมจากภาพถ่ายด้านหน้า

3.4 การตัดสินใจของปัญญาประดิษฐ์เชิงตัวแทน

ในขั้นตอนนี้ปัญญาประดิษฐ์เชิงตัวแทนนำผลลัพธ์ที่ได้จากขั้นตอนก่อนหน้า มาตัดสินใจตามเงื่อนไขจริง โดยเปรียบเทียบในรูปแบบเชิงตรรกะ ว่าค่าที่ได้มีค่ามากกว่า น้อยกว่า หรือเท่ากับกับค่าที่วางแผนไว้ และหากค่าไม่ตรงกับที่วางแผนไว้ ให้มีกระบวนการทำงานเป็นอย่างไร

4. ผลการศึกษา

4.1 ผลการศึกษาของปัญญาประดิษฐ์ในการตรวจนับเหล็กเสริม

เมื่อเราทราบจำนวนเหล็กเสริมที่จำเป็นต้องใช้สำหรับก่อสร้างทั้งหมดจากแบบจำลองโครงสร้างสามมิติแล้ว ขั้นตอนการตรวจนับเหล็กเสริมที่เกิดขึ้นจริงด้วยเทคโนโลยีคอมพิวเตอร์วิทัศน์จะช่วยให้การตรวจนับเหล็กเสริมและตรวจสอบการวางแผนเหล็กเสริมก่อนเทคอนกรีตได้อย่างถูกต้องและรวดเร็ว ซึ่งผลลัพธ์ที่ได้จากการฝึกสอนของโมเดลทั้งสองชนิดนั้นแสดงในตารางที่ 3

ตารางที่ 3 รายละเอียดการฝึกสอนของโมเดลทั้งสองชนิด

Model	Cross-section detection	Full-length rebar detection
Based model	YOLOv8M	YOLOv8M-seg
Training time	5 hours	9 hours
Precision	97.8%	86.9%
Recall	97.4%	75.8%
mAP@50	97.7%	82.4%
mAP@50-95	70.9%	70.3%

จากการวิเคราะห์หาปริมาณเหล็กเสริมที่ได้จากแบบจำลองโครงสร้างสามมิติและทำการคำนวณการตัดเหล็กเสริมด้วยอัลกอริธึมด้วยภาษา Python จะได้ผลลัพธ์ดังแสดงในตารางที่ 4

นอกจากนี้ เมื่อประยุกต์ใช้โมเดลตรวจจับจำนวนเหล็กเสริมและการวางแผนเหล็กเสริมก่อนการเทคอนกรีต พบว่า โมเดลสำหรับการนับเหล็กเสริมสามารถแสดงจุดสีแดงบนหน้าตัดของเหล็กเพื่อระบุการตรวจพบ อย่างไรก็ตาม มีข้อจำกัดบางประการ เช่น การตรวจไม่พบในกรณีที่เหล็กถูกบดบังหรือวางซ้อนกันจากมุมมอง รวมถึงการตรวจจับผิดพลาดในบางบริเวณที่ไม่มีเหล็กเสริมจริง ดังแสดงในรูปที่ 5 ส่วนโมเดลสำหรับการตรวจจับแนวการวางเหล็กเสริมจากภาพถ่ายด้านบน ดังแสดงในรูปที่ 6 พบปัญหาในการตรวจจับเหล็กเสริมที่มีการวางซ้อนกันหลายชั้นหรือมีปลายโค้งงอ ซึ่งส่งผลต่อความแม่นยำในการวิเคราะห์ตำแหน่งและความยาวของเหล็ก

ตารางที่ 4 จำนวนเหล็กเสริมทั้งหมด

เหล็กเสริม	จำนวนเหล็ก 10 เมตร (เส้น)	จำนวนเหล็ก 12 เมตร (เส้น)
DB12	487	340
DB16	69	8




รูปที่ 6 ตัวอย่างการตรวจจับเหล็กเสริมจากภาพถ่ายด้านบน

4.2 ผลของปัญญาประดิษฐ์เชิงตัวแทน

4.2.1 การถอดปริมาณเหล็กเสริม

ข้อมูลที่ใช้สำหรับการหาปริมาณเหล็กเสริมโดยแบบก่อสร้างสองมิติที่ใช้เป็นแบบก่อสร้างโกดังเก็บของ 1 ชั้น มีพื้นที่ใช้สอยประมาณ 317 ตารางเมตร มีความสูง 7.00 เมตร ประเภทคอนกรีตเสริมเหล็กลำนำสร้างแบบจำลองสารสนเทศอาคารผ่านทางซอฟต์แวร์ Autodesk Revit



รูปที่ 7 แบบจำลองโครงสร้างสามมิติ

4.2.2 การคำนวณหาจำนวนเหล็กเสริมที่ต้องสั่งซื้อ

แบบจำลองโครงสร้างสามมิติที่พัฒนาขึ้นสามารถระบุปริมาณเหล็กเสริมได้อย่างละเอียด ทั้งประเภท ขนาด และความยาวของแต่ละเส้น อย่างไรก็ตาม ความยาวที่ได้มักไม่ตรงกับขนาดมาตรฐานที่มีจำหน่าย เช่น 10 และ 12 เมตร จึงต้องแปลงข้อมูลให้เหมาะกับการจัดซื้อ โดยวิเคราะห์รูปแบบ

การตัดเหล็กเสริม เพื่อเพิ่มประสิทธิภาพการใช้วัสดุและลดเศษเหลือ โดยใช้ ภาษา Python ผ่านทาง Jupyter Notebook ภายใต้ Anaconda Environment เพื่อจัดเรียงรูปแบบการตัดที่เหมาะสมที่สุดดังแสดงในรูปที่ 6 และตารางที่ 4-5

ตารางที่ 5 ตระกะและเงื่อนไขของการหาเหล็กเสริม

โครงสร้าง	เหล็กเสริม	กลยุทธ์	จำนวน เหล็ก 10 เมตร (เส้น)	จำนวน เหล็ก 12 เมตร (เส้น)	เศษ (เมตร)
เสา	DB16	Only 10m	16	0	5.36
	DB20	Mixed 10m & 12m	1	13	24.4
	RB9	Only 12m	0	28	13.5
ฐานราก	DB12	Mixed 10m & 12m	60	39	10.92
คาน	DB12	Mixed 10m & 12m	1	92	64.05
	DB16	Mixed 10m & 12m	53	8	32.38
	DB20	Mixed 10m & 12m	50	15	17.97
	RB9	Mixed 10m & 12m	1	73	30.73
พื้น	DB12	Mixed 10m & 12m	426	209	420.98

4.2.3 การตรวจสอบการนับเหล็กเสริมด้วยคอมพิวเตอร์วิทัศน์

แม้ว่าระบบปัญญาประดิษฐ์เชิงตัวแทนจะช่วยเพิ่มความแม่นยำในการถอดปริมาณและตรวจสอบเหล็กเสริมด้วยคอมพิวเตอร์วิทัศน์ได้อย่างมีประสิทธิภาพ แต่ยังมีข้อจำกัดในสภาพแวดล้อมจริง สาเหตุเกิดจากการซ้อนทับของเหล็ก มุมกล้องไม่เหมาะสม และแสงที่ไม่สม่ำเสมอและตัวโมเดลเอง ซึ่งสามารถปรับปรุงได้ด้วยการใช้ชุดข้อมูลจากไซต์งานจริง ร่วมกับเทคนิค Fine-tuning, Transfer Learning และ Data Augmentation เพื่อเพิ่มความหลากหลายและความครอบคลุมของข้อมูล นอกจากนี้ การนำสถาปัตยกรรมใหม่ เช่น YOLOv11 ที่มีศักยภาพในการตรวจจับวัตถุในบริบทซับซ้อนมาใช้งาน รวมถึงการใช้โมเดลแบบ Hybrid หรือ Multi-stage ที่รวมการตรวจจับและแบ่งส่วนในขั้นตอนเดียว จะช่วยยกระดับความแม่นยำและความพร้อมของระบบในการใช้งานจริงได้ดียิ่งขึ้น

4.2.4 กรอบการทำงานของปัญญาประดิษฐ์เชิงตัวแทน

ความสามารถในการทำงานของปัญญาประดิษฐ์เชิงตัวแทนช่วยให้งานกระบวนการถอดปริมาณเหล็กเสริมจากแบบก่อสร้างเป็นไปอย่างรวดเร็ว แม่นยำ และมีประสิทธิภาพยิ่งขึ้น โดยสามารถตรวจสอบและวิเคราะห์ความเพียงพอของวัสดุเทียบกับปริมาณที่ต้องใช้จริงตามแบบได้อย่างเป็นระบบ อย่างไรก็ตาม แม้ระบบจะมีความอัตโนมัติสูงในหลายขั้นตอน แต่ยังคงต้องอาศัยการแทรกแซงของมนุษย์ในบางกระบวนการ เช่น การจัดเตรียมข้อมูลภาพจากหน้างานหรือการตรวจสอบข้อมูลเบื้องต้น หากต้องการยกระดับการทำงานของระบบให้มีความอัตโนมัติอย่างสมบูรณ์ จึงควรพัฒนาแนวทางเพื่อลดการพึ่งพามนุษย์ในจุดที่มีความเสี่ยงต่อข้อผิดพลาด และเพิ่มความแม่นยำในการประมวลผลข้อมูลจากสภาพแวดล้อมจริง เพื่อให้ระบบสามารถดำเนินงานได้อย่างมีประสิทธิภาพสูงสุด

5. สรุปผล

งานวิจัยนี้นำเสนอแนวทางการประยุกต์ใช้ปัญญาประดิษฐ์เชิงตัวแทน เพื่อเพิ่มประสิทธิภาพในการจัดการเหล็กเสริมในงานก่อสร้าง โดยระบบถูกออกแบบให้สามารถดำเนินการกระบวนการได้แบบอัตโนมัติ ตั้งแต่การถอด

ปริมาณจากแบบจำลองโครงสร้างสามมิติ การจัดทำรายการตัด ตรวจสอบนับเหล็กเสริมด้วยภาพถ่าย ไปจนถึงการประเมินความสอดคล้องกับแบบก่อสร้างผ่านกระบวนการเรียนรู้และตัดสินใจของระบบ

ระบบประกอบด้วยกระบวนการวางแผน การเลือกใช้เครื่องมือที่เหมาะสม และการประเมินผลลัพธ์อย่างต่อเนื่อง โดยผสมผสานเทคโนโลยีคอมพิวเตอร์วิทัศน์เข้ากับการประมวลผลข้อมูลเชิงตรรกะผ่านตัวแทนอัจฉริยะ ทั้งนี้ ได้มีการพัฒนาโมเดล YOLOv8 สำหรับการตรวจจับเหล็กเสริมในแต่ละมุมมอง และฝึกฝนด้วยข้อมูลจากหลายแหล่งที่มีความหลากหลายของบริบท เพื่อตอบสนองต่อสภาพแวดล้อมที่พบจริงในไซต์งาน นอกจากนี้ งานวิจัยยังรวมการคำนวณรูปแบบการตัดเหล็กเสริมให้เหมาะสมกับขนาดมาตรฐานของวัสดุที่สามารถจัดซื้อได้จริง โดยอาศัยอัลกอริธึมที่พัฒนาด้วยภาษา Python ซึ่งช่วยสนับสนุนการวางแผนการใช้วัสดุให้มีประสิทธิภาพสูงสุดและลดการสูญเสียในกระบวนการก่อสร้าง

แม้ระบบที่พัฒนาขึ้นจะสามารถลดการพึ่งพาแรงงานมนุษย์และทำงานได้อย่างเป็นระบบ แต่ยังมีข้อจำกัดบางประการที่ควรปรับปรุง เช่น ความแม่นยำในสภาพแวดล้อมจริง หรือความซับซ้อนของภาพถ่ายจากไซต์งาน ดังนั้นจึงควรมีการพัฒนาเพิ่มเติมด้วยเทคนิคขั้นสูงเพื่อให้ระบบสามารถทำงานได้อย่างยั่งยืน ครอบคลุม และพร้อมใช้งานในสภาพจริงมากยิ่งขึ้น

เอกสารอ้างอิง

- [1] Zheng, Y., Zhou, G., & Lu, B. (2023). A Multi-Scale Rebar Detection Network with an Embedded Attention Mechanism. *Applied Sciences*, 13 (14) . <https://doi.org/10.3390/app13148233>
- [2] Kim, H., et al. (2007). A Case Study on Rebar Supply Chain Management by GS E&C.
- [3] Rebolj, D., et al. (2008). Automated construction activity monitoring system. *Advanced Engineering Informatics*, 22(4), 493-503. <https://doi.org/10.1016/j.aei.2008.06.002>
- [4] Acharya, D. B., Kuppan, K., & Divya, B. (2025). Agentic AI: Autonomous Intelligence for Complex Goals—A Comprehensive Survey. *IEEE Access*.
- [5] Viswanathan, P. S. (2025). Agentic AI: A Comprehensive Framework for Autonomous Decision-Making Systems. *International Journal of Computer Engineering and Technology*.
- [6] Parab, G. U. (2024). Agentic AI in Data Analytics: Transforming Autonomous Insights and Decision-Making.
- [7] Shavit, Y., Agarwal, S., & Brundage, M. (2025). Practices for Governing Agentic AI Systems.
- [8] Li, Y., Lu, Y., & Chen, J. (2021). A deep learning approach for real-time rebar counting on the construction site based on YOLOv3 detector. *Automation in Construction*, 124. <https://doi.org/10.1016/j.autcon.2021.103602>
- [9] Chen, J., et al. (2024). Automated Counting of Steel Construction Materials. *Buildings*, 14(6). <https://doi.org/10.3390/buildings14061661>
- [10] Hernández-Ruiz, A. C., et al. (2021). Steel Bar Counting from Images with Machine Learning. *Electronics*, 10(4). <https://doi.org/10.3390/electronics10040402>

- [11] Terven, J., et al. (2023). A Comprehensive Review of YOLO Architectures. *Machine Learning and Knowledge Extraction*, 5(4). <https://doi.org/10.3390/make5040083>
- [12] Wang, H., et al. (2023). Synthetic Datasets for Rebar Instance Segmentation Using Mask R-CNN. *Buildings*, 13(3). <https://doi.org/10.3390/buildings13030585>
- [13] Nath, N. D., & Behzadan, A. H. (2020). Deep Convolutional Networks for Construction Object Detection. *Frontiers in Built Environment*, 6. <https://doi.org/10.3389/fbuil.2020.00097>
- [14] Zhang, Y., et al. (2018). Automated quality inspection of rebar using machine vision.