

การประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์เพื่อการจัดสรรแรงงานในพื้นที่การก่อสร้าง

Application of AI & Computer Vision for Workforce Allocation in Construction Sites

นที จิรพงษ์¹ ธาริน พิชาดพัฒนา² มานพ แก้วโมราเจริญ³ และอลงกต สุคำวัง⁴

^{1,2,3} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

⁴ ภาควิชาวิศวกรรมอุตสาหการและเทคโนโลยี คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา

บทคัดย่อ

การบริหารจัดการแรงงานอย่างมีประสิทธิภาพเป็นความท้าทายสำคัญในอุตสาหกรรมก่อสร้างซึ่งส่งผลกระทบต่อผลิตภาพ ต้นทุน และระยะเวลาโครงการ งานวิจัยนี้จึงประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (AI) และคอมพิวเตอร์วิทัศน์ (Computer Vision) เพื่อพัฒนาระบบต้นแบบสำหรับวิเคราะห์การเคลื่อนไหวและสนับสนุนการจัดสรรแรงงานในพื้นที่ก่อสร้าง โดยมีวัตถุประสงค์เพื่อพัฒนาวิธีการตรวจสอบระดับกิจกรรมของแรงงานจากข้อมูลวิดีโอและเสนอแนวทางการจัดสรรแรงงานตามหลักวิศวกรรม ระเบียบวิธีวิจัยประกอบด้วยการรวบรวมและเตรียมข้อมูลวิดีโอจากกิจกรรมก่อสร้าง 3 ประเภทหลัก การประยุกต์ใช้แบบจำลอง YOLOv11 เพื่อคำนวณคะแนนการเคลื่อนไหว (Movement Score) และการใช้แบบจำลอง LSTM Autoencoder เพื่อวิเคราะห์ค่าความคลาดเคลื่อนในการสร้างข้อมูลกลับคืนมา (Reconstruction Error) อันนำไปสู่การจำแนกระดับกิจกรรมการทำงาน (ต่ำ ปกติ สูง/ผิดปกติ) โดยพิจารณาผลจากสองแนวทางนี้ร่วมกัน ผลการศึกษาเบื้องต้นจากแบบจำลองต้นแบบแสดงศักยภาพในการระบุระดับกิจกรรมการเคลื่อนไหวโดยรวมของกลุ่มแรงงาน แต่พบข้อจำกัดในการจำแนกประเภทงานก่อสร้างโดยอัตโนมัติด้วย MoViNet (Pre-trained) และการติดตามแรงงานรายบุคคล (Re-identification) การทดลองกับวิดีโอขนาดยาวชี้ว่าผลในการจำแนกระดับกิจกรรมจากทั้งสองวิธียังไม่แตกต่างกันอย่างมีนัยสำคัญเพียงพอที่จะนำไปสู่การจำแนกสถานการณ์เพื่อการจัดสรรแรงงานที่ซับซ้อนได้อย่างชัดเจนตามที่คาดหวังไว้ในเบื้องต้น ผลสำรวจความคิดเห็นจากบุคลากรในอุตสาหกรรมให้การตอบรับเชิงบวก แต่กังวลด้านความแม่นยำ ค่าใช้จ่าย และการยอมรับจากผู้ปฏิบัติงาน โดยสรุป งานวิจัยนี้ได้พัฒนารอบแนวคิดและระบบต้นแบบที่แสดงความเป็นไปได้ในการใช้ AI และ Computer Vision เพื่อวิเคราะห์กิจกรรมของแรงงาน ซึ่งสามารถเป็นข้อมูลพื้นฐานสำคัญสนับสนุนการตัดสินใจจัดสรรแรงงาน อย่างไรก็ตาม ยังจำเป็นต้องพัฒนาต่อยอดด้านชุดข้อมูล ความแม่นยำของแบบจำลอง และการบูรณาการปัจจัยอื่นที่เกี่ยวข้องกับประสิทธิภาพ เพื่อการประยุกต์ใช้ในอุตสาหกรรมก่อสร้างอย่างเป็นรูปธรรมในอนาคต

คำสำคัญ: ปัญญาประดิษฐ์, คอมพิวเตอร์วิทัศน์, การจัดสรรแรงงาน, การวิเคราะห์การเคลื่อนไหว

Abstract

Effective labor management is a critical construction industry challenge impacting productivity, costs, and schedules. This research applies Artificial Intelligence (AI) and Computer Vision to develop a prototype system for movement analysis to support labor allocation. Objectives included monitoring worker activity levels from video (covering painting, plastering, and masonry) and proposing an engineering-based allocation. The methodology involved preparing video data, using YOLOv11 for normalized Movement Scores, and an LSTM Autoencoder for Reconstruction Error to classify activity levels (low, normal, high/anomalous), jointly considering both analytical results. Initial findings show the prototype's potential to identify group activity levels, but limitations exist in automatic task classification (pre-trained MoViNet) and robust worker re-identification. With the current dataset, the analytical methods for activity classification did not yield sufficiently distinct differences for the anticipated nuanced labor allocation in complex scenarios. Industry feedback was positive on potential but noted concerns about accuracy, cost, and worker acceptance. In summary, this research demonstrates AI and Computer Vision's feasibility for worker activity analysis, providing baseline data for informed labor allocation. However, substantial further development in dataset scope, model accuracy for construction contexts, and integration of other performance factors beyond movement is crucial for impactful future applications.

Keywords: Artificial Intelligence, Computer Vision, Labor Allocation, Movement Analysis

1 บทนำ

อุตสาหกรรมการก่อสร้างเป็นภาคส่วนที่มีความสำคัญอย่างยิ่งต่อการพัฒนาเศรษฐกิจและโครงสร้างพื้นฐานของประเทศ อย่างไรก็ตาม การบริหารจัดการแรงงานในพื้นที่การก่อสร้าง ซึ่งส่วนใหญ่ยังคงต้องพึ่งพาแรงงานมนุษย์เป็นหลัก ยังคงเผชิญกับความท้าทายด้านประสิทธิภาพอย่างต่อเนื่อง ปัญหาการจัดสรรแรงงานที่ไม่สมดุลกับปริมาณงาน การขาดข้อมูลเชิงปริมาณที่เป็นปัจจุบันเพื่อสนับสนุนการตัดสินใจ และต้นทุนที่อาจเพิ่มสูงขึ้นจากความล่าช้าในโครงการเป็นประเด็นสำคัญที่สะท้อนให้เห็นถึงความจำเป็นในการพัฒนาระบบการและเครื่องมือที่ทันสมัย แม่นยำ และเป็นระบบมากขึ้นเพื่อตรวจสอบการทำงานของแรงงานและปรับปรุงประสิทธิภาพการทำงานให้สอดคล้องกับเป้าหมายของโครงการ

ในยุคปัจจุบัน เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) และคอมพิวเตอร์วิทัศน์ (Computer Vision) ได้แสดงให้เห็นถึงศักยภาพอันโดดเด่นในการวิเคราะห์ข้อมูลที่ซับซ้อนและการประมวลผลภาพ ทำให้เกิดแนวคิดในการนำเทคโนโลยีทั้งสองมาประยุกต์ใช้เพื่อยกระดับการบริหารจัดการแรงงานในอุตสาหกรรมการก่อสร้าง ปัญญาประดิษฐ์สามารถช่วยในการประมวลผลข้อมูลจำนวนมากได้อย่างรวดเร็วและแม่นยำ ในขณะที่คอมพิวเตอร์วิทัศน์มีความสามารถในการตรวจจับ วิเคราะห์ และตีความพฤติกรรมการทำงานของแรงงานจากข้อมูลภาพหรือวิดีโอได้อย่างมีประสิทธิภาพ การผสมผสานเทคโนโลยีทั้งสองนี้จึงเปิดโอกาสในการพัฒนาระบบที่สามารถให้ข้อมูลเชิงลึกแก่ผู้จัดการโครงการเพื่อการตัดสินใจจัดสรรทรัพยากรบุคคลได้อย่างเหมาะสมและทันทั่วถึง

งานวิจัยนี้จึงมีวัตถุประสงค์หลักสองประการคือ 1) เพื่อพัฒนารูปแบบการตรวจสอบและประเมินผลระดับกิจกรรมการทำงานของแรงงานในพื้นที่ก่อสร้างโดยอาศัยเทคโนโลยี AI และ Computer Vision จากข้อมูลภาพหรือวิดีโอแบบทันที (Real-time) และ 2) เพื่อพัฒนาแนวทางการจัดสรรแรงงานโดยใช้ข้อมูลที่ได้จากการวิเคราะห์การเคลื่อนไหวดังกล่าว ประกอบกับหลักการทางวิศวกรรม การก่อสร้างและการจัดการทรัพยากร ขอบเขตของการศึกษาจะมุ่งเน้นการตรวจจับการเคลื่อนไหวของกลุ่มแรงงานจากข้อมูลวิดีโอที่ได้จากกล้องวงจรปิด (CCTV) หรือมุมมองที่คล้ายคลึงกัน เพื่อวิเคราะห์ความหนาแน่นของการเคลื่อนไหวในพื้นที่ต่างๆ โดยระบบจะให้ข้อมูลเพื่อสนับสนุนการตัดสินใจเพิ่มหรือลดจำนวนแรงงานในภาพรวม โดยไม่เจาะจงถึงการระบุตัวตนหรือทักษะของแรงงานแต่ละบุคคล และจะไม่ครอบคลุมผลกระทบจากปัจจัยภายนอก เช่น สภาพอากาศหรือปัจจัยทางสังคมในพื้นที่การก่อสร้างงาน

2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การพัฒนาระบบวิเคราะห์การเคลื่อนไหวของแรงงานและสนับสนุนการจัดสรรแรงงานในพื้นที่การก่อสร้างด้วยเทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์นั้น จำเป็นต้องอาศัยองค์ความรู้จากหลายศาสตร์ที่เกี่ยวข้อง การทบทวนวรรณกรรมในส่วนนี้จึงมุ่งเน้นไปที่แนวคิดหลักและงานวิจัยที่สำคัญซึ่งเป็นรากฐานและแนวทางในการดำเนินโครงการนี้

2.1 การประยุกต์ใช้ปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์ในอุตสาหกรรมการก่อสร้าง

ในช่วงทศวรรษที่ผ่านมา เทคโนโลยีปัญญาประดิษฐ์ (AI) และคอมพิวเตอร์วิทัศน์ (Computer Vision) ได้เข้ามามีบทบาทอย่างมากในการปฏิรูปอุตสาหกรรมต่างๆ รวมถึงอุตสาหกรรมการก่อสร้าง ซึ่งเป็นภาคส่วนที่มีความซับซ้อนสูงและต้องการการบริหารจัดการทรัพยากรอย่างแม่นยำ (Jang et al., 2023) การประยุกต์ใช้เทคโนโลยีเหล่านี้ในพื้นที่การก่อสร้างครอบคลุมหลากหลายมิติ ตั้งแต่การวางแผนโครงการ การวิเคราะห์ความเสี่ยง การติดตามความคืบหน้าของงาน ไปจนถึงการเพิ่มความปลอดภัยและประสิทธิภาพในการทำงานของแรงงาน (Cheng et al., 2022) งานวิจัยจำนวนมากได้แสดงให้เห็นถึงศักยภาพของ AI ในการประมวลผลข้อมูลจำนวนมากเพื่อสนับสนุนการตัดสินใจ และความสามารถของ Computer Vision ในการ "มองเห็น" และ "เข้าใจ" สภาพแวดล้อมและกิจกรรมที่เกิดขึ้นในพื้นที่การก่อสร้างจากข้อมูลภาพและวิดีโอ ซึ่งเป็นหัวใจสำคัญของงานวิจัยนี้

2.2 เทคโนโลยีการตรวจจับและวิเคราะห์การเคลื่อนไหว

เพื่อให้ระบบสามารถเข้าใจกิจกรรมของแรงงานได้ การตรวจจับและวิเคราะห์การเคลื่อนไหวของมนุษย์ (Human Motion Detection and Analysis) จึงเป็นองค์ประกอบหลัก ในระยะแรก เทคนิคการตรวจจับการเคลื่อนไหวมักอาศัยการเปรียบเทียบความแตกต่างของจุดภาพ (Pixel) ระหว่างเฟรมภาพวิดีโอ อย่างไรก็ตาม ด้วยความก้าวหน้าของเทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) ได้มีการพัฒนาแบบจำลองที่มีความสามารถสูงชันอย่างมากในการจัดการกับข้อมูลภาพที่มีความซับซ้อน แบบจำลองในตระกูล YOLO (You Only Look Once) เช่น YOLOv11 ที่ใช้ในงานวิจัยนี้ เป็นที่รู้จักในด้านความเร็วและความแม่นยำในการตรวจจับวัตถุแบบทันที (Real-time Object Detection) (Sulake, 2024)

นอกเหนือจากการตรวจจับบุคคลแล้ว การทำความเข้าใจท่าทาง (Pose Estimation) ก็มีความสำคัญอย่างยิ่งในการวิเคราะห์พฤติกรรมการทำงาน เทคโนโลยีอย่าง YOLO-Pose ซึ่งพัฒนาต่อยอดจาก YOLO ได้ถูกนำมาใช้เพื่อตรวจจับจุดสำคัญบนร่างกายมนุษย์ (Keypoints) เช่น ตำแหน่งของข้อต่อต่างๆ ทำให้สามารถวิเคราะห์โครงสร้างและท่าทางของแรงงานได้อย่างละเอียด (Ding et al., 2024) ข้อมูลท่าทางเหล่านี้เป็นพื้นฐานสำคัญในการคำนวณ "คะแนนการเคลื่อนไหว" ซึ่งเป็นตัวชี้วัดระดับกิจกรรมที่ใช้ในงานวิจัยนี้ การวิเคราะห์ลำดับของท่าทางและคะแนนการเคลื่อนไหวเมื่อเวลาผ่านไป ช่วยให้สามารถทำความเข้าใจรูปแบบการทำงานของแรงงานได้ดียิ่งขึ้น

2.3 การวิเคราะห์ข้อมูลอนุกรมเวลาและการตรวจจับความผิดปกติด้วย LSTM Autoencoder

ข้อมูลการเคลื่อนไหวของแรงงานที่เก็บรวบรวมได้อย่างต่อเนื่องนั้น มีลักษณะเป็นข้อมูลอนุกรมเวลา (Time-series Data) ซึ่งการวิเคราะห์ข้อมูลประเภทนี้จำเป็นต้องใช้แบบจำลองที่สามารถจัดการกับความสัมพันธ์ระหว่างข้อมูล ณ เวลาต่างๆ ได้ โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) ซึ่งเป็น

สถาปัตยกรรมหนึ่งในกลุ่ม Recurrent Neural Network (RNN) ได้รับการออกแบบมาโดยเฉพาะเพื่อจัดการกับข้อมูลอนุกรมเวลา และเรียนรู้ความสัมพันธ์ระยะยาว (Long-term Dependencies) ได้อย่างมีประสิทธิภาพ

ในงานวิจัยนี้ ได้มีการนำ LSTM มาประยุกต์ใช้ร่วมกับ สถาปัตยกรรม Autoencoder ก่อให้เกิดเป็น LSTM Autoencoder เพื่อวัตถุประสงค์ในการเรียนรู้ "รูปแบบปกติ" ของ อนุกรมเวลาจากคะแนนการเคลื่อนไหว และตรวจจับความเบี่ยงเบน หรือ "ความผิดปกติ" (Anomaly Detection) หลักการของ Autoencoder คือการบีบอัดข้อมูล (Encoding) ให้เป็นข้อมูล ตัวแทนเชิงลึก (Latent Representation) แล้วจึงสร้างข้อมูลนั้น กลับคืนมา (Decoding) ให้ใกล้เคียงกับข้อมูลต้นฉบับมากที่สุด ค่า ความคลาดเคลื่อนในการสร้างข้อมูลกลับคืนมา (Reconstruction Error) จะถูกใช้เป็นตัวบ่งชี้ความผิดปกติ หากค่า Error สูง แสดงว่า ข้อมูลนั้นเบี่ยงเบนไปจากรูปแบบปกติที่แบบจำลองได้เรียนรู้มา ซึ่ง แนวคิดนี้ถูกนำมาใช้เพื่อจำแนกระดับกิจกรรมการทำงานของ แรงงานออกเป็น ต่ำ ปกติ หรือสูงหรือผิดปกติ

2.4 แนวคิดการวัดประสิทธิภาพและการจัดสรรทรัพยากร แรงงานในพื้นที่การก่อสร้าง

เป้าหมายสูงสุดของการวิเคราะห์กิจกรรมแรงงานคือการนำข้อมูลที่ได้ไปสนับสนุนการตัดสินใจเพื่อเพิ่มประสิทธิภาพการทำงานและ จัดสรรทรัพยากรแรงงาน (Labor Resource Allocation) ได้อย่างเหมาะสม การวัดประสิทธิภาพ (Productivity Measurement) ในอุตสาหกรรมก่อสร้างเป็นเรื่องที่ซับซ้อนและมีหลายมิติ ทั้งเชิง ปริมาณ (เช่น ปริมาณงานที่เสร็จต่อหน่วยเวลา) และเชิงคุณภาพ (เช่น คุณภาพงาน การทำงานเป็นทีม) แม้งานวิจัยนี้จะมุ่งเน้นการใช้ "การเคลื่อนไหว" เป็นตัวชี้วัดระดับกิจกรรมเบื้องต้น แต่ก็ตระหนักดี ว่าการเคลื่อนไหวเพียงอย่างเดียวไม่สามารถสะท้อนประสิทธิภาพ ทั้งหมดได้ ผลการสำรวจความคิดเห็นจากผู้มีประสบการณ์ใน อุตสาหกรรมได้ยืนยันถึงประเด็นนี้ โดยชี้ให้เห็นว่าประสิทธิภาพที่ แท้จริงต้องพิจารณาจากผลลัพธ์ของงาน และปัจจัยอื่นๆ ประกอบด้วย

อย่างไรก็ตาม ข้อมูลระดับกิจกรรมที่ได้จากระบบสามารถเป็น ข้อมูลพื้นฐานที่สำคัญสำหรับวิศวกรหรือผู้จัดการโครงการในการ ประเมินสถานการณ์ในพื้นที่การก่อสร้าง และประกอบการตัดสินใจ จัดสรรแรงงานตามหลักการทางวิศวกรรมการจัดการ (Engineering Management Principles) เช่น การระบุพื้นที่ที่อาจมีการใช้ แรงงานมากหรือน้อยเกินไปเมื่อเทียบกับปริมาณงานที่คาดหวัง หรือ การตรวจจบบรูปแบบการทำงานที่ผิดปกติซึ่งอาจบ่งชี้ถึงปัญหาคว่ ขวดหรือความไม่มีประสิทธิภาพในกระบวนการทำงาน งานวิจัยหลาย ชิ้นในอดีต ได้พยายามนำ แบบจำลองทางคณิตศาสตร์ (Optimization Models) หรือการจำลองสถานการณ์ (เช่น Multi-Agent Based Simulation - MABS) มาช่วยในการจัดสรรแรงงาน (Valente et al., 2019; Zhang et al., 2018) ซึ่งข้อมูลเชิงปริมาณ จากระบบที่พัฒนาขึ้นในงานวิจัยนี้สามารถเป็นปัจจัยนำเข้า (Input) ที่มีคุณค่าสำหรับแบบจำลองการตัดสินใจที่ซับซ้อนยิ่งขึ้นในอนาคตได้

3 ระเบียบวิธีวิจัย

3.1 การรวบรวมและเตรียมข้อมูลวิดีโอ

ข้อมูลหลักที่ใช้ในการพัฒนามาจากวิดีโอที่บันทึกการปฏิบัติงานของ แรงงานในพื้นที่ก่อสร้างจริง ครอบคลุมกิจกรรม 3 ประเภทหลัก ได้แก่ งานทาสี (Painting) งานฉาบผนัง (Plastering) และงานก่อ อิฐ (Masonry) ซึ่งถ่ายทำจากหลากหลายมุมมองและมีความยาว แตกต่างกัน ข้อมูลวิดีโอเหล่านี้ได้ผ่านกระบวนการเตรียมข้อมูล เบื้องต้น ได้แก่ การแปลงไฟล์ให้อยู่ในรูปแบบ .mp4, การปรับลด ความละเอียดของภาพลงมาอยู่ที่ 640x480 พิกเซล เพื่อให้ เหมาะสมกับการประมวลผลด้วยแบบจำลอง และการกำหนดอัตรา เฟรม (Frame Rate) สำหรับการวิเคราะห์ไว้ที่ 10 เฟรมต่อวินาที (fps) เพื่อสร้างสมดุลระหว่างการเก็บรายละเอียดการเคลื่อนไหวที่ เพียงพอกับการลดภาระการคำนวณ จากนั้น ได้กำหนดความยาวของ แต่ละลำดับข้อมูล (Sequence Length) ที่ใช้ในการวิเคราะห์ไว้ที่ 80 เฟรม (เทียบเท่ากับช่วงเวลาประมาณ 8 วินาทีที่ 10 fps) ซึ่งเป็น ช่วงเวลาที่อ้างอิงจากงานวิจัยที่เกี่ยวข้องว่าเหมาะสมสำหรับการ จัดจำกิจกรรมในงานก่อสร้าง นอกจากนี้ ยังมีการประยุกต์ใช้เทคนิค หน้าต่างแบบเลื่อน (Sliding Window) โดยมีการซ้อนทับกันของ ข้อมูล (Overlapping) เพื่อเพิ่มจำนวนชุดข้อมูลย่อยสำหรับการ ฝึกสอนและทดสอบแบบจำลอง

3.2 การวิเคราะห์การเคลื่อนไหวของแรงงาน

การวิเคราะห์การเคลื่อนไหวเริ่มต้นด้วยการใช้แบบจำลอง YOLOv11 ซึ่งมีความสามารถในการตรวจจับวัตถุและประเมินท่าทาง (Pose Estimation) เพื่อตรวจจับและติดตามตำแหน่งของจุดสำคัญ (Keypoints) 6 จุดบนร่างกายส่วนบนของแรงงานแต่ละบุคคล (ไหล่ ซ้าย/ขวา, ข้อศอกซ้าย/ขวา, ข้อมือซ้าย/ขวา) ในแต่ละเฟรมของวิดีโอ จากนั้น คะแนนการเคลื่อนไหวเบื้องต้น (Displacement Score) ของแรงงานแต่ละบุคคลจะถูกคำนวณจากผลรวมของการ เปลี่ยนแปลงตำแหน่งของจุดสำคัญเหล่านี้ระหว่างเฟรมต่อเนื่องกัน ตามสมการ 3.2-1 เพื่อลดผลกระทบจากระยะห่างระหว่างบุคคลกับ กล้อง คะแนนการเคลื่อนไหวนี้จะถูกนำไปปรับค่าสู่มาตรฐานเดียวกัน (Normalization) โดยการหารด้วยระยะห่างระหว่างหัวไหล่ทั้งสอง ข้างของบุคคลนั้นๆ ตามสมการ 3.2-2 ได้เป็นคะแนนการเคลื่อนไหว ที่ปรับมาตรฐานแล้ว (Normalized Movement Score) ซึ่งจะถูก ใช้ในการวิเคราะห์ระดับกิจกรรมต่อไป ในกรณีที่แบบจำลองไม่ สามารถตรวจจับจุดสำคัญบางจุดได้ในบางเฟรม จะมีการใช้วิธีการ ทดแทนข้อมูล (Data Imputation) โดยนำค่าพิกัดจากเฟรมก่อน หน้ามาใช้ชั่วคราว

$$Displacement = \frac{\sum_{f=1}^{80} \sum_{n=1}^6 \left(\sqrt{(x_{n,f} - x_{n,f-1})^2 + (y_{n,f} - y_{n,f-1})^2} \right)}{\text{Number of Frames}} \quad (1)$$

$x_{n,f}$, $x_{n,f-1}$ คือตัวแปรหน่วยจุดภาพในตำแหน่งแกน x ของ จุดสำคัญที่ n และเฟรมที่ f และ f-1 ตามลำดับ, $y_{n,f}$, $y_{n,f-1}$ คือตัว แปรหน่วยจุดภาพในตำแหน่งแกน y ของจุดสำคัญที่ n และเฟรมที่ f และ f-1 ตามลำดับ, n คือดัชนีของจุดสำคัญบนร่างกาย (1 ถึง 6) และ f คือดัชนีของเฟรมในลำดับข้อมูล (1 ถึง 80)


$$\text{Movement Score} = \frac{\text{Displacement}}{\text{ระยะห่างระหว่างไหล่ทั้ง 2 ข้าง}} \quad (2)$$

Displacement หมายถึงผลลัพธ์ของการวิเคราะห์การเคลื่อนไหวของแรงงานแต่ละบุคคลจากสมการที่ (1), *Movement Score* หมายถึงผลลัพธ์ของการวิเคราะห์การเคลื่อนไหวของแรงงานแต่ละบุคคลที่ผ่านการปรับเข้าสู่มาตรฐานเดียวกัน

3.3 การจำแนกระดับกิจกรรมการทำงาน

3.3.1 วิธีการวัดโดยตรง (Direct Movement Score Method)


แนวทางนี้ใช้หลักการทางสถิติพื้นฐาน โดยคำนวณค่าเฉลี่ย (Mean) และค่าเบี่ยงเบนมาตรฐาน (Standard Deviation - SD) ของคะแนนการเคลื่อนไหวจากชุดข้อมูลที่ใช้ในการพัฒนา จากนั้นจึงกำหนดขอบเขตบนและล่าง (เช่น Mean ± 1.5 SD) เพื่อใช้เป็นเกณฑ์ในการพิจารณาว่าการเคลื่อนไหว ณ เวลาใดเวลาหนึ่งมีระดับกิจกรรมที่ ต่ำ ปกติ หรือสูง เมื่อเทียบกับเกณฑ์ดังกล่าว แสดงดังรูปที่ 1



รูปที่ 1 ตัวอย่างกราฟผลลัพธ์ของวิธีการ Direct Movement Score

3.3.2 วิธีการตรวจจับความผิดปกติด้วย LSTM Autoencoder (Reconstruction Error Method)

แนวทางนี้เป็นการประยุกต์ใช้สถาปัตยกรรม LSTM Autoencoder ซึ่งประกอบด้วยส่วน Encoder เพื่อบีบอัดอนุกรมเวลาของคะแนนการเคลื่อนไหวให้เป็นข้อมูลตัวแทนเชิงลึก (Latent Representation) และส่วน Decoder เพื่อสร้างอนุกรมเวลานั้นกลับมา แบบจำลองจะถูกฝึกสอนด้วยข้อมูลการทำงานที่ถือว่าเป็น "ปกติ" เพื่อให้เรียนรู้รูปแบบพื้นฐานของกิจกรรมนั้นๆ จากนั้นค่าความคลาดเคลื่อนในการสร้างข้อมูลกลับมา (Reconstruction Error) จะถูกนำมาใช้เป็นตัวบ่งชี้ความเบี่ยงเบนไปจากสภาวะปกติ ลำดับข้อมูลที่มี Reconstruction Error สูงจะถูกพิจารณาว่ามีลักษณะผิดปกติ (Anomaly) หรือมีระดับกิจกรรมที่สูงหรือต่ำกว่าปกติอย่างมีนัยสำคัญ โดยเกณฑ์ในการแบ่งระดับกิจกรรม (ต่ำ, ปกติ, สูง/ผิดปกติ) จะกำหนดจากการวิเคราะห์การกระจายตัวของค่า Reconstruction Error โดยใช้ค่าเปอร์เซ็นต์ไทล์กำหนดขอบเขตบนและล่าง แสดงดังรูปที่ 2



รูปที่ 2 ตัวอย่างกราฟผลลัพธ์ของวิธีการ Reconstruction Error

3.4 การพิจารณาเพื่อสนับสนุนการจัดสรรแรงงาน

ผลลัพธ์ที่ได้จากการจำแนกระดับกิจกรรมทั้งสองแนวทาง (Direct Movement Score และ Reconstruction Error) จะถูกนำมาพิจารณาร่วมกันเพื่อเป็นข้อมูลประกอบในการประเมินสถานการณ์ในพื้นที่ก่อสร้าง และสนับสนุนการตัดสินใจจัดสรรแรงงานตามหลักการทางวิศวกรรมจัดการ เช่น การระบุพื้นที่ที่อาจมีการใช้ทรัพยากรบุคคลไม่เหมาะสม หรือพื้นที่ที่ต้องการกำลังคนเพิ่มเติม


3.5 เครื่องมือพัฒนาและสภาพแวดล้อม

การพัฒนาโปรแกรมต้นแบบทั้งหมดดำเนินการโดยใช้ภาษา Python บนโปรแกรม Visual Studio Code (VS Code) และอาศัยไลบรารีที่สำคัญหลายตัว เช่น NumPy สำหรับการคำนวณเชิงตัวเลข, PyTorch สำหรับการสร้างและฝึกสอนแบบจำลอง Deep Learning, OpenCV สำหรับการประมวลผลภาพและวิดีโอ, scikit-learn สำหรับการประเมินผลแบบจำลอง, และ ultralytics สำหรับการใช้งานแบบจำลอง YOLO

4 ผลการศึกษาและอภิปรายผล

4.1 ลักษณะข้อมูลและผลการวิเคราะห์เบื้องต้น


ชุดข้อมูลหลักที่ใช้ในการพัฒนาประกอบด้วยวิดีโอทัศนการทำงาน 3 ประเภท (งานทาสี, งานฉาบผนัง, งานก่ออิฐ) รวมระยะเวลาประมาณ 80 นาที ซึ่งหลังจากการสกัดเป็นลำดับข้อมูลย่อย (Sequences) ได้จำนวนหลายพันลำดับข้อมูลสำหรับการพัฒนาแบบจำลอง การวิเคราะห์การกระจายตัวของคะแนนการเคลื่อนไหว (Movement Score) รายบุคคลของแต่ละประเภทงาน ดังแสดงในรูปที่ 3 ชี้ให้เห็นถึงลักษณะการกระจายที่แตกต่างกัน โดยงานทาสีมีการกระจายตัวของคะแนนที่ค่อนข้างสม่ำเสมอ ในขณะที่งานก่ออิฐและงานฉาบผนังมีความแปรปรวนของข้อมูลมากกว่า ซึ่งอาจสะท้อนถึงลักษณะการทำงานที่ไม่ต่อเนื่องหรือมีช่วงหยุดพักแทรกอยู่



รูปที่ 3 กราฟการกระจายของคะแนนการเคลื่อนไหวรายบุคคล

4.2 ประสิทธิภาพของแบบจำลองและการจำแนกประเภทกิจกรรม

ในการทดสอบความสามารถในการจำแนกประเภทกิจกรรมการทำงานโดยอัตโนมัติด้วยแบบจำลอง MoViNet (Pre-trained) พบว่าแบบจำลองยังไม่สามารถให้ผลลัพธ์ที่แม่นยำเพียงพอสำหรับงานก่อสร้างที่มีความเฉพาะเจาะจงสูง ดังรูปที่ 4 ทำให้ในการดำเนินงานส่วนใหญ่ต้องอาศัยการระบุประเภทงานด้วยตนเอง (Manual Labeling) สำหรับการวิเคราะห์การเคลื่อนไหวด้วยแบบจำลอง YOLOv11 พบว่าสามารถตรวจจับจุดสำคัญ (Keypoints) บนร่างกายส่วนบนได้ดีในสภาวะที่มองเห็นชัดเจน แต่ประสิทธิภาพลดลงเมื่อมีการบดบังบางส่วน หรือเมื่อแรงงานอยู่ในมุมที่ยากต่อการตรวจจับ ดังรูปที่ 5 ซึ่งได้มีการใช้วิธีการทดแทนข้อมูล (Data Imputation) เบื้องต้นเพื่อจัดการกับข้อมูลที่ขาดหาย

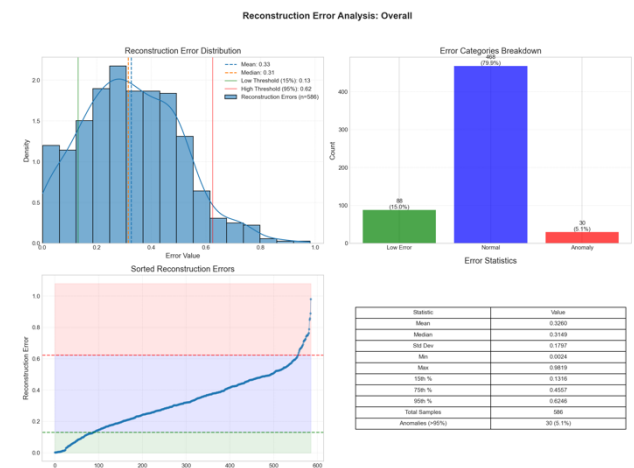


รูปที่ 4 ตัวอย่างผลลัพธ์ที่คลาดเคลื่อนของแบบจำลอง MoViNet




รูปที่ 5 ตัวอย่างผลลัพธ์ที่ผิดพลาดของแบบจำลอง YOLOv11


การจำแนกระดับกิจกรรมการทำงานโดยใช้ LSTM Autoencoder และวิเคราะห์ค่า Reconstruction Error ดังรูปที่ 6 แสดงให้เห็นถึงความสามารถของแบบจำลองในการเรียนรู้รูปแบบปกติและจำแนกข้อมูลออกเป็นระดับความหนาแน่นต่ำ ปกติ หรือสูง/ผิดปกติได้ในระดับหนึ่ง การเปรียบเทียบระหว่างอนุกรมเวลาของคะแนนการเคลื่อนไหวต้นฉบับกับอนุกรมเวลาที่สร้างขึ้นใหม่โดยแบบจำลอง ดังรูปที่ 7 ชี้ให้เห็นว่าแบบจำลอง Autoencoder มีแนวโน้มที่จะสร้างลำดับข้อมูลที่ราบเรียบกว่าและจับลักษณะสำคัญโดยรวมได้



รูปที่ 6 กราฟ Reconstruction Error รวมของทุกประเภทงาน



รูปที่ 7 กราฟก่อนและหลังใช้งานโมเดล LSTM Autoencoder ของทุกประเภทงานที่มีค่าการเคลื่อนไหวสูง



รูปที่ 8 กราฟก่อนและหลังใช้งานโมเดล LSTM Autoencoder ของทุกประเภทงานที่มีค่าการเคลื่อนไหวปานกลาง



รูปที่ 9 กราฟก่อนและหลังใช้งานโมเดล LSTM Autoencoder ของทุกประเภทงานที่มีค่าการเคลื่อนไหวต่ำ

4.3 การประยุกต์ใช้เพื่อการจัดสรรแรงงานและข้อจำกัด


เมื่อนำผลลัพธ์จากทั้งสองแนวทางการวิเคราะห์ (Direct Movement Score และ Reconstruction Error Method) มาพิจารณาเพื่อสนับสนุนการจัดสรรแรงงานแบ่งกรณีการวิเคราะห์ได้ 6 ประเภทสถานการณ์ดังนี้

1. ระดับการเคลื่อนไหวต่ำ และมีค่า Reconstruction Error อยู่ในเกณฑ์ปกติ
2. ระดับการเคลื่อนไหวต่ำ และมีค่า Reconstruction Error สูง (ผิดปกติ)
3. ระดับการเคลื่อนไหวปานกลาง และมีค่า Reconstruction Error อยู่ในเกณฑ์ปกติ
4. ระดับการเคลื่อนไหวปานกลาง และมีค่า Reconstruction Error สูง (ผิดปกติ)
5. ระดับการเคลื่อนไหวสูง และมีค่า Reconstruction Error อยู่ในเกณฑ์ปกติ
6. ระดับการเคลื่อนไหวสูง และมีค่า Reconstruction Error สูง (ผิดปกติ)


โดยที่ในงานวิจัยนี้ทดลองกับวิดีโอความยาว 10 นาทีขึ้นไปซึ่งจัดเป็นประเภทวิดีโอระยะเวลายาว เพื่อเปรียบเทียบผลการทดลองดังวัตถุประสงค์ของการใช้งานที่ตั้งไว้ โดยที่เปรียบเทียบระหว่างการทดลองดังรูปที่ 10 และ 13 ซึ่งมีผลลัพธ์จากการวิเคราะห์ของชุดการทดลองแรกและสองดังกราฟจากรูปที่ 11 – 12 และ 14 – 15 ตามลำดับดังนี้



รูปที่ 10 ตัวอย่างวิดีโอของงานทาสีที่มีแรงงาน 2 คน




รูปที่ 11 กราฟผลลัพธ์วิธี Direct Movement Score แรงงาน 2 คน




รูปที่ 12 กราฟผลลัพธ์วิธี Reconstruction Error แรงงาน 2 คน



รูปที่ 13 ตัวอย่างวิดีโอของงานทาสีที่มีแรงงาน 1 คน



รูปที่ 14 กราฟผลลัพธ์วิธี Direct Movement Score แรงงาน 1 คน



รูปที่ 15 กราฟผลลัพธ์วิธี Reconstruction Error แรงงาน 1 คน

ซึ่งจากทั้ง 2 ชุดการทดลองแสดงให้เห็นถึงความท้าทายของการติดตามและระบุตัวตนแรงงานรายบุคคล (Re-identification) อย่างต่อเนื่องในวิดีโอขนาดใหญ่ที่แสดงดังกราฟในรูปข้างต้นที่มีจำนวนบุคคลในวิดีโอมากกว่า จำนวนบุคคลที่มีอยู่จริง แต่ปัญหาดังกล่าวไม่ส่งผลให้การคำนวณการเคลื่อนไหวโดยเฉลี่ยคาดเคลื่อน เนื่องจากการคำนวณในสมการมีค่าคงที่ถึงปัญหาดังกล่าวนี้ เพียงแต่ในกรณีที่ต้องการข้อมูลการวิเคราะห์แยกรายบุคคลยังไม่สามารถทำได้ถึงขั้นนั้น

ทั้งนี้ ณ ปัจจุบัน งานวิจัยยังไม่สามารถทดสอบระบบร่วมกับกล้องวงจรปิด (CCTV) จากพื้นที่การก่อสร้างจริงได้โดยตรง เนื่องจากข้อจำกัดในการเข้าถึงข้อมูล ซึ่งจำเป็นต้องมีการติดต่อประสานงานกับผู้เกี่ยวข้องและอาจมีกระบวนการที่ต้องใช้ระยะเวลานาน อย่างไรก็ตามการทดลองกับข้อมูลวิดีโอที่มีลักษณะใกล้เคียงกับสภาพแวดล้อมจริงในส่วนนี้ ได้พยายามจำลองสถานการณ์การประยุกต์ใช้งานให้มากที่สุดเท่าที่จะเป็นไปได้ เพื่อตรวจสอบปัญหา ข้อจำกัด และข้อผิดพลาดที่อาจเกิดขึ้น ซึ่งจะเป็นประโยชน์อย่างยิ่งต่อการปรับปรุงและพัฒนาระบบให้มีความสมบูรณ์และพร้อมสำหรับการนำไปใช้งานจริงในอนาคต

4.4 มุมมองจากผู้เกี่ยวข้องในอุตสาหกรรม

ผลการสำรวจความคิดเห็นจากวิศวกร ผู้รับเหมา และนิสิตนักศึกษา (จำนวน 28 ท่าน) ส่วนใหญ่แสดงทัศนคติเชิงบวกต่อศักยภาพของเทคโนโลยี AI และ Computer Vision ในการช่วยขับเคลื่อนและพัฒนาอุตสาหกรรมก่อสร้าง และเห็นด้วยว่าการติดตามการทำงานและการใช้เทคโนโลยีช่วยเพิ่มลดจำนวนแรงงานตามความต้องการจะช่วยเพิ่มประสิทธิภาพโดยรวมได้ อย่างไรก็ตาม มีข้อกังวลอย่างมากต่อสมมติฐานที่ว่า "การเคลื่อนไหวที่มาก หมายถึง ประสิทธิภาพสูง" (ค่าเฉลี่ยความเห็นด้วยเพียง 2.96/5) และมีความคิดเห็นที่หลากหลายต่อสมมติฐาน "ยิ่งจำนวนคนที่มากขึ้น ยิ่งก่อให้เกิดประสิทธิภาพการทำงานที่รวดเร็วขึ้น" (ค่าเฉลี่ย 3.07/5) ข้อกังวลหลักที่ถูกหยิบยกขึ้นคือความแม่นยำของระบบ (Accuracy of the system) ตามมาด้วยค่าใช้จ่ายในการประยุกต์ใช้ (Cost of implementation) ความเป็นส่วนตัวของแรงงาน (Privacy concerns) และการต่อต้านจากคนงาน (Resistance from workers) ข้อเสนอแนะที่เป็นประโยชน์รวมถึงการพิจารณาแยกแยะระหว่างคนงานกับเครื่องจักรหรือผู้ควบคุม และการใช้วิดีโอจากหลายมุมมอง

5 สรุปผลการศึกษา

5.1 การรวบรวมและเตรียมข้อมูลวิดีโอ

โครงการวิศวกรรมโยธาฉบับนี้ได้นำเสนอการพัฒนาและประเมินระบบต้นแบบสำหรับการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ (AI) และคอมพิวเตอร์วิทัศน์ (Computer Vision) เพื่อวิเคราะห์การเคลื่อนไหวของแรงงานและสนับสนุนการตัดสินใจจัดสรรแรงงานในพื้นที่การก่อสร้าง โดยมีวัตถุประสงค์หลักในการพัฒนารอบแนวคิดและวิธีการตรวจสอบระดับกิจกรรมของแรงงานจากข้อมูลวิดีโอ และเสนอแนวทางการนำข้อมูลดังกล่าวไปใช้ประกอบการจัดสรรแรงงานตามหลักวิศวกรรม การดำเนินงานสำคัญประกอบด้วยการรวบรวมและเตรียมชุดข้อมูลวิดีโอที่บันทึกจากกิจกรรมก่อสร้าง 3 ประเภทหลัก (งานทาสี, งานฉาบผนัง, งานก่ออิฐ), การประยุกต์ใช้แบบจำลอง YOLOv11 เพื่อคำนวณคะแนนการเคลื่อนไหว (Movement Score) ที่ผ่านการปรับค่าสู่มาตรฐาน (Normalization), และการใช้แบบจำลอง LSTM Autoencoder เพื่อวิเคราะห์ค่าความคลาดเคลื่อนในการสร้างข้อมูลกลับคืนมา (Reconstruction Error) อันนำไปสู่การจำแนกระดับกิจกรรมการทำงาน (ต่ำ, ปกติ, สูง/ผิดปกติ) ผลการศึกษาเบื้องต้นแสดงให้เห็นถึงศักยภาพของระบบในการระบุแนวโน้มระดับกิจกรรมโดยรวมของกลุ่มแรงงาน และได้รวบรวมความคิดเห็นจากผู้เกี่ยวข้องในอุตสาหกรรมเพื่อเป็นแนวทางในการพัฒนาต่อไป

5.2 การอภิปรายผล

ผลการศึกษาจากโครงการนี้ให้มุมมองที่สำคัญหลายประการต่อการประยุกต์ใช้ AI และ Computer Vision ในการบริหารจัดการแรงงานก่อสร้าง ระบบต้นแบบที่พัฒนาขึ้นสามารถแสดงให้เห็นถึงความเป็นไปได้ในการใช้ข้อมูลการเคลื่อนไหวเป็นตัวชี้วัดระดับกิจกรรมของแรงงาน อย่างไรก็ตาม การเชื่อมโยง "การเคลื่อนไหว" กับ "ประสิทธิภาพ" โดยตรงนั้นเป็นประเด็นที่ต้องพิจารณาอย่างรอบคอบ ดังที่ผลการสำรวจความคิดเห็นจากผู้มีประสบการณ์ในอุตสาหกรรมได้ชี้ให้เห็นถึงข้อจำกัดต่อสมมติฐานนี้ ประสิทธิภาพในงานก่อสร้างเป็นผลลัพธ์จากปัจจัยที่ซับซ้อนกว่าเพียงแค่การเคลื่อนไหวทางกายภาพ สำหรับแบบจำลองที่ใช้ แม้ YOLOv11 จะมีความสามารถในการตรวจจับท่าทางได้ดีในสถานะที่เหมาะสม แต่ก็ยังคงมีความท้าทายในสภาพแวดล้อมจริงที่มีการบดบังและมุมมองที่จำกัด ส่วน LSTM Autoencoder แสดงให้เห็นถึงแนวทางที่มีศักยภาพในการเรียนรู้ "รูปแบบปกติ" ของกิจกรรมและตรวจจับความผิดปกติผ่าน Reconstruction Error แต่ความแม่นยำก็ยังขึ้นอยู่กับคุณภาพและความเป็นตัวแทนของชุดข้อมูลฝึกสอนอย่างมาก เมื่อเปรียบเทียบผลลัพธ์จากสองแนวทางการวิเคราะห์หลัก (Direct Movement Score และ Reconstruction Error Method) ด้วยชุดข้อมูลปัจจุบัน พบว่ายังไม่สามารถสร้างความแตกต่างที่ชัดเจนเพียงพอสำหรับการจำแนกสถานการณ์การทำงานที่ซับซ้อนทั้ง 6 ประเภทตามที่คาดหวังไว้ในเบื้องต้นได้ ซึ่งชี้ให้เห็นถึงความจำเป็นในการพัฒนาชุดข้อมูลและเกณฑ์การตัดสินใจให้มีความละเอียดและแม่นยำยิ่งขึ้น จุดแข็งของงานวิจัยนี้คือการเป็นความพยายามริเริ่มในการสร้างระบบวิเคราะห์กิจกรรมแรงงานอย่างเป็นขั้นตอนและมีการพิจารณาแนวทางการวิเคราะห์ที่หลากหลาย แต่ก็มีจุดอ่อนในด้านข้อจำกัดของชุดข้อมูลที่ใช้และความท้าทายในการ

ทดสอบระบบในสภาพแวดล้อมจริงอย่างเต็มรูปแบบ ซึ่งเป็นประเด็นสำคัญสำหรับการพัฒนาในอนาคต

5.3 ปัญหา อุปสรรค และข้อเสนอแนะในการปรับปรุง

ตลอดระยะเวลาการดำเนินโครงการ แม้ว่าระบบต้นแบบจะแสดงให้เห็นถึงศักยภาพเบื้องต้นในการประยุกต์ใช้เทคโนโลยี AI และ Computer Vision เพื่อวิเคราะห์กิจกรรมของแรงงาน แต่ก็ได้ประสบกับปัญหาและอุปสรรคหลายประการ ซึ่งเป็นความท้าทายสำคัญที่ชี้ให้เห็นถึงความจำเป็นในการพัฒนาและปรับปรุงอย่างต่อเนื่อง ประเด็นหลักที่พบคือ ข้อจำกัดด้านข้อมูล ทั้งในเชิงปริมาณ ความหลากหลาย และคุณภาพของวิดีโอจากพื้นที่การก่อสร้างจริง ซึ่งส่งผลโดยตรงต่อความสามารถในการสรุปผลโดยทั่วไป (Generalizability) ของแบบจำลองที่พัฒนาขึ้น และความต้องการข้อมูลที่ติดป้าย (Labeled Data) จำนวนมากสำหรับการจำแนกประเภทงานโดยอัตโนมัติ ควบคู่ไปกับ ข้อจำกัดเชิงเทคนิคของแบบจำลอง AI ที่เลือกใช้ เช่น ความแม่นยำในการจำแนกประเภทงานของ MoViNet (Pre-trained) ที่ยังไม่เพียงพอสำหรับงานก่อสร้างเฉพาะทาง ความทนทานของ YOLOv11 ต่อการบดบังและมุมมองที่หลากหลายในสภาพแวดล้อมจริง และความท้าทายในการติดตามและระบุตัวตนแรงงาน (Re-identification) อย่างต่อเนื่อง ซึ่งจำเป็นอย่างยิ่งสำหรับการวิเคราะห์พฤติกรรมรายบุคคล นอกจากนี้ ความซับซ้อนในการตีความ "การเคลื่อนไหว" และการกำหนดเกณฑ์ที่เหมาะสมสำหรับแต่ละประเภทงานก็เป็นอุปสรรคสำคัญ

จากปัญหาและอุปสรรคดังกล่าว แนวทางการพัฒนาต่อยอดที่สำคัญควรเริ่มต้นจากการ พัฒนาและปรับปรุงชุดข้อมูล (Dataset Enhancement) โดยการเพิ่มปริมาณและความหลากหลายของข้อมูลวิดีโอที่บันทึกจากพื้นที่การก่อสร้างจริงให้ครอบคลุมประเภทงาน สภาพแวดล้อม และช่วงเวลาที่แตกต่างกันมากขึ้น และอาจพิจารณาสร้างชุดข้อมูลมาตรฐานสำหรับการเปรียบเทียบเพื่อกระตุ้นการพัฒนาในวงกว้าง ควบคู่กันนี้ การปรับปรุงประสิทธิภาพและความสามารถของแบบจำลอง AI เป็นสิ่งจำเป็น โดยอาจรวมถึงการปรับแต่งแบบจำลองจำแนกประเภทงานให้มีความเฉพาะเจาะจงกับงานก่อสร้าง การพัฒนาระบบติดตามรายบุคคลที่ทนทานยิ่งขึ้น และที่สำคัญคือการนิยาม "ประสิทธิภาพ" หรือ "ระดับกิจกรรม" ให้มีความซับซ้อนและอิงบริบทมากกว่าการพิจารณาการเคลื่อนไหวทางกายภาพเพียงอย่างเดียว ซึ่งอาจทำได้โดยการผสมผสานข้อมูลจากหลายแหล่ง (Multi-modal Data Fusion) เช่น ข้อมูลจาก BIM หรือเซ็นเซอร์อื่นๆ เพื่อให้การวิเคราะห์มีความสมบูรณ์และแม่นยำยิ่งขึ้น นอกจากนี้ การปรับปรุงด้านเทคนิคและการใช้งานของระบบ เช่น การทดลองใช้ระบบกล้องหลายมุมมองเพื่อลดปัญหาบดบัง การเพิ่มประสิทธิภาพการประมวลผลให้ใกล้เคียง Real-time มากขึ้น และการพัฒนาระบบแจ้งเตือนและส่วนติดต่อผู้ใช้งานที่ง่ายต่อการใช้งานจริง จะช่วยเพิ่มศักยภาพในการนำระบบไปประยุกต์ใช้ท้ายที่สุด การ ทดสอบและประเมินผลในสภาพแวดล้อมการทำงานจริง โดยการร่วมมือกับภาคอุตสาหกรรมเพื่อทดสอบภาคสนาม จะเป็นขั้นตอนสำคัญในการตรวจสอบความถูกต้อง ความน่าเชื่อถือ และการยอมรับของระบบจากผู้ใช้งานจริง ซึ่งจะนำไปสู่การปรับปรุงที่

ตอบโจทย์ความต้องการของอุตสาหกรรมการก่อสร้างได้อย่างแท้จริง และช่วยให้เทคโนโลยีนี้สามารถเป็นเครื่องมือสนับสนุนการตัดสินใจของวิศวกรโยธาในการบริหารจัดการแรงงานได้อย่างมีประสิทธิภาพ

5.4 การเผยแพร่ผลงานวิจัยเพื่อการพัฒนาต่อยอด

เพื่อส่งเสริมการแลกเปลี่ยนองค์ความรู้และเปิดโอกาสให้ผู้สนใจสามารถนำแนวคิดหรือส่วนของโปรแกรมที่พัฒนาขึ้นในโครงการนี้ไปศึกษาและพัฒนาต่อยอดได้ คณะผู้จัดทำจึงได้ดำเนินการเผยแพร่ส่วนของโค้ด (Source Code) และแบบจำลองเบื้องต้น (Initial Models) สู่อสาธารณะผ่านแพลตฟอร์ม GitHub ซึ่งเป็นพื้นที่เก็บข้อมูลและควบคุมเวอร์ชันที่เป็นที่ยอมรับในระดับสากล ผ่านลิงก์นี้ https://github.com/tutuututu/performance_estimation_in_construction_site

คณะผู้จัดทำหวังเป็นอย่างยิ่งว่าการเผยแพร่ส่วนหนึ่งของผลงานวิจัยนี้ จะเป็นประโยชน์ต่อผู้ที่สนใจ ไม่ว่าจะเป็นการนำไปศึกษาเพื่อเป็นแนวทางในการทำโครงการลักษณะเดียวกัน การนำไปทดลองประยุกต์ใช้ในสถานการณ์จริง หรือการนำไปเป็นจุดเริ่มต้นในการพัฒนาต่อยอดเพื่อสร้างสรรค์นวัตกรรมที่จะช่วยเพิ่มประสิทธิภาพและความยั่งยืนให้กับอุตสาหกรรมการก่อสร้างและอุตสาหกรรมที่เกี่ยวข้องต่อไปในอนาคต

กิตติกรรมประกาศ

โครงการวิศวกรรมโยธาฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความอนุเคราะห์และความช่วยเหลืออย่างดียิ่งจากหลายท่าน และหลายหน่วยงาน คณะผู้จัดทำขอกราบขอบพระคุณทุกท่านมา ณ โอกาสนี้ ขอกราบขอบพระคุณ ผศ.ดร.มานพ แก้วโมราเจริญ อาจารย์ที่ปรึกษาโครงการ ที่ได้กรุณาเสียสละเวลาอันมีค่าในการให้คำปรึกษาอย่างใกล้ชิด ให้คำแนะนำอันเป็นประโยชน์ยิ่งในการดำเนินงานวิจัย ชี้แนะแนวทางการวิเคราะห์ข้อมูลและแนวทางการแก้ไขปัญหาต่างๆ ที่เกิดขึ้นระหว่างการทำโครงการ ตลอดจนตรวจทานและแก้ไขข้อบกพร่องต่างๆ ของรายงานฉบับนี้ด้วยความเอาใจใส่เสมอมา จนกระทั่งโครงการนี้สำเร็จสมบูรณ์ได้ คณะผู้จัดทำขอขอบพระคุณ นายอลงกต สุควัง เจ้าของบริษัท คอนสตรัคชั่น 89 เป็นอย่างสูง ที่ได้ให้ความอนุเคราะห์และเอื้อเฟื้อข้อมูลวิดีโอที่บันทึกการปฏิบัติงานของแรงงานในพื้นที่ก่อสร้างจริง ซึ่งเป็นข้อมูลหลักที่มีความสำคัญอย่างยิ่งต่อการพัฒนาและทดสอบแบบจำลองในโครงการวิจัยนี้ ความช่วยเหลือของท่านทำให้โครงการนี้สามารถดำเนินการได้อย่างเป็นรูปธรรม

ขอขอบพระคุณ คณาจารย์ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ทุกท่าน ที่ได้ประสิทธิ์ประสาทวิชาความรู้ทางด้านวิศวกรรมโยธา และเป็นแบบอย่างที่ดีในการศึกษาค้นคว้าและทำงานวิจัย อีกทั้งขอขอบพระคุณเจ้าหน้าที่ของภาควิชาฯ ทุกท่านที่ได้อำนวยความสะดวกในด้านต่างๆ

ขอขอบคุณ รศ. ดร. วีระ เพียรสุภาพ และ รศ. ดร. นพพล จอกแก้ว ที่ได้กรุณาให้คำแนะนำและข้อเสนอแนะอันเป็นประโยชน์

ขอขอบคุณเพื่อนนิสิตสถาปัตย์วิศวกรรมโยธา ตลอดจนผู้ที่สละเวลาตอบแบบสอบถามทุกท่าน สำหรับกำลังใจ ความช่วยเหลือ และข้อมูลอันเป็นประโยชน์ ซึ่งมีส่วนสำคัญในการดำเนินงานวิจัยนี้

ท้ายที่สุดนี้ คณะผู้จัดทำขอกราบขอบพระคุณบิดามารดาและสมาชิกในครอบครัวทุกท่าน สำหรับความรัก ความห่วงใย กำลังใจ และการสนับสนุนในทุกๆ ด้าน ทั้งด้านการศึกษาและด้านอื่นๆ มาโดยตลอด คุณค่าและประโยชน์อันใดก็ตามที่พึงมีจากโครงการฉบับนี้ คณะผู้จัดทำขอมอบเป็นเครื่องบูชาพระคุณแด่ทุกท่านที่มีส่วนเกี่ยวข้องในการให้ความช่วยเหลือและสนับสนุนทุกท่าน

เอกสารอ้างอิง

- [1] Addepto. "Benefits of AI in Software Development and Product Building". Addepto Blog, Sep. 13, 2022. [Online]. Available: <https://www.google.com/search?q=https://addepto.com/blog/benefits-of-ai-in-software-development-and-product-building/>.
- [2] Agency, K. "Creating safer jobsites: Understanding how human factors and performance impact construction safety". Construction Dive, Mar. 10, 2025. [Online]. Available: <https://www.constructiondive.com/spons/creating-safer-jobsites-understanding-how-human-factors-and-performance-im/740765/>.
- [3] Akhavian, R. and A. H. Behzadan. "An integrated data collection and analysis framework for remote monitoring and planning of construction operations". *Advanced Engineering Informatics*, 26(4), pp. 749–761, Oct. 2012. doi: 10.1016/j.aei.2012.05.004.
- [4] Al-Bayati, A. J., Harvey, P., Uddin, M. S., and J. L. Reyes-Rodríguez. "BIM for Safety: Applying Real-Time Monitoring Technologies to Prevent Falls from Height in Construction". *Applied Sciences*, 15(4), p. 2218, Feb. 2025. doi: 10.3390/app15042218. [Online]. Available: <https://www.mdpi.com/2076-3417/15/4/2218>.
- [5] Anderson, D. R., Higgins, K. D., and M. L. Jenson. "Real-time monitoring of construction site activities using IoT and computer vision for workforce optimization". *Proc. 2021 IEEE Int. Conf. Syst., Man, Cybern. (SMC)*, Melbourne, Australia, Oct. 17–20, 2021, pp. 2450–2455. doi: 10.1109/SMC52423.2021.9659056.
- [6] Ascanio, A. C., Pellicer, O., Yepes, V., and E. Herrera. "Factors Affecting Labor Productivity in the Global Construction Industry: A Critical Review, Classification and Ranking". *Tecnológicas*, 27(60), p. e2872, Apr. 2024. doi: 10.22430/22565337.2872. [Online]. Available: <https://dialnet.unirioja.es/descarga/articulo/9429171.pdf>
- [7] Baek, J., Kim, D., and B. Choi. "Deep learning-based automated productivity monitoring for on-site module installation in off-site construction". *Developments in the Built Environment*, 18, p. 100382, Apr. 2024. doi: 10.1016/j.dibe.2024.100382.
- [8] Brown, D. H., Rodriguez, S. M., and K. T. Chang. "Real-Time Spatial Data Analysis for Workforce Distribution in Construction Sites". *Proc. 2020 IEEE Int. Conf. Big Data (Big Data)*, Online, Dec. 10–13, 2020, pp. 4588–4593. doi: 10.1109/BigData50022.2020.9378338.
- [9] Brown, J. A. K., Zhi, L., and L. Nguyen. "An AI-driven approach to construction workforce scheduling and resource optimization". *Automation in Construction*, 119, p. 103349, Nov. 2020. doi: 10.1016/j.autcon.2020.103349.
- [10] Cheng, J. C. P., Wong, P. K.-Y., Luo, H., Wang, M., and P. H. Leung. "Vision-based monitoring of site safety compliance based on worker re-identification and personal protective equipment classification". *Automation in Construction*, 139, p. 104312, Jul. 2022. doi: 10.1016/j.autcon.2022.104312.
- [11] Collins, R. L., Nguyen, E. J., and A. T. Lee. "Efficiency Analysis for Workforce Optimization in Complex Construction Projects". *Automation in Construction*, 144, p. 104581, Dec. 2022. doi: 10.1016/j.autcon.2022.104581.
- [12] Ding, J., Niu, S., Nie, Z., and W. Zhu. "Research on Human Posture Estimation Algorithm Based on YOLO-Pose". *Sensors*, 24(10), p. 3036, May 2024. doi: 10.3390/s24103036.
- [13] Hedegaard, L., Heidari, N., and A. Iosifidis. "Human Activity Recognition". Chapter 14 in *Deep Learning for Robot Perception and Cognition*. (ScienceDirect/Publisher details unknown), 2022.
- [14] Jang, Y. et al. "Multi-Camera-Based Human Activity Recognition for Human–Robot Collaboration in Construction". *Sensors*, 23(15), p. 6997, Aug. 2023. doi: 10.3390/s23156997.
- [15] Keller, J. D., Fernandez, M. S., and T. J. Elliot. "Resource Allocation and Efficiency in Construction Projects: A Framework for Labor Optimization". *Automation in Construction*, 127, p. 103710, Jul. 2021. doi: 10.1016/j.autcon.2021.103710.

- [16] Khanam, R. and M. Hussain. "YOLOv11: An Overview of the Key Architectural Enhancements". arXiv:2410.17725v1 [cs.CV], Oct. 2024. doi: 10.48550/arXiv.2410.17725.
- [17] Pham, H. H., Khoudour, L., Crouzil, A., Zegers, P., and S. A. Velastin. "Video-based Human Action Recognition using Deep Learning: A Review". arXiv:2208.03775 [cs.CV], Aug. 2022. [Online]. Available: <https://arxiv.org/abs/2208.03775>
- [18] Sulake, N. R. "A Comprehensive Guide to YOLOv11 Object Detection". Analytics Vidhya, Oct. 28, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2024/10/yolo-v11-object-detection/>.
- [19] Zhang, Y., Li, X., and K. P. Cheung. "Optimizing manpower allocation using a multi-agent based simulation for construction site management". Journal of Ambient Intelligence and Humanized Computing, 9(6), pp. 1989–2001, Dec. 2018. doi: 10.1007/s12652-018-0798-5.