

การประยุกต์ใช้ปัญญาประดิษฐ์เพื่อถอดปริมาณงานไฟฟ้าในแบบก่อสร้างบ้าน Application of Artificial Intelligence (AI) In Electrical Quantity Takeoff From Housing Construction Drawings

เมธัส ชินทริญ^{1,*} กวิน ดันติเสวี²

^{1,2} ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ กรุงเทพมหานคร

Corresponding author; E-mail address: s6501081811026@email.kmutnb.ac.th

บทคัดย่อ

การถอดปริมาณงานระบบไฟฟ้าสำหรับโครงการก่อสร้างบ้านพักอาศัย มักดำเนินการด้วยมือซึ่งมีความเสี่ยงในการเกิดข้อผิดพลาด จึงเกิดแนวคิดในการนำเทคโนโลยีปัญญาประดิษฐ์ (AI) เข้ามาใช้ในการเพิ่มประสิทธิภาพและความแม่นยำในการถอดปริมาณงาน โดยเฉพาะการใช้แบบจำลองที่มีพื้นฐานจาก เครือข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เช่น Mask R-CNN, YOLOv9, และ U-Net ซึ่งได้รับความนิยมในการตรวจจับและจำแนกวัตถุในภาพต่างๆ งานวิจัยนี้จึงได้ศึกษาเชิงเปรียบเทียบการประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ 3 แบบได้แก่ Mask R-CNN, YOLOv9 และ U-Net มาใช้ในงานถอดปริมาณพื้นที่ห้องและอุปกรณ์ระบบไฟฟ้า ได้แก่ ดวงไฟ สวิตช์ และเต้ารับไฟฟ้า จากภาพแบบก่อสร้างสถาปัตยกรรม และแบบงานระบบไฟฟ้าของบ้านพักอาศัย โดยทดลองฝึกแบบจำลองด้วยตัวอย่างแบบก่อสร้างจำนวน 100 ถึง 300 แบบก่อสร้าง ปรับเปลี่ยนจำนวนรอบในการฝึก ความละเอียดของภาพ และประเมินความแม่นยำของแบบจำลองในการจำแนกอุปกรณ์ระบบไฟฟ้าและพื้นที่ห้องจากการฝึกด้วยจำนวนรูปภาพ 100 ถึง 300 รูป ผลการศึกษาพบว่า เมื่อฝึกฝนแบบจำลองด้วยรูปภาพจำนวน 300 รูป แบบจำลอง YOLOv9 มีความแม่นยำในการตรวจจับอุปกรณ์ ดวงไฟ สวิตช์ และเต้ารับไฟฟ้า มากที่สุดโดยมีความแม่นยำ 90% ในขณะที่แบบจำลอง U-net มีความแม่นยำในการระบุขอบเขตพื้นที่ห้องได้ดีที่สุดโดยมีค่า IOU เท่ากับ 83% ที่รอบการฝึก (Epochs) 80 รอบและความละเอียดของภาพขนาด 1700x1200 พิกเซลเท่ากัน

คำสำคัญ: ปัญญาประดิษฐ์, การถอดปริมาณงาน, แบบจำลองเครือข่ายประสาทเทียม, ระบบไฟฟ้า

Abstract

Quantity takeoff for electrical systems in housing construction projects is typically performed manually, which is prone to errors. This led to the idea of applying artificial intelligence (AI) technology, especially convolutional neural network (CNN) models, to enhance the efficiency and accuracy of the quantity takeoff process. Among various CNN models, Mask R-CNN, YOLO,

and U-Net have been increasingly used for object detection and classification in images. This research presents a comparative study on the application of three AI models Mask R-CNN, YOLOv9, and U-Net for extracting room areas and identifying number of electrical devices including light fixtures, switches, and receptacles from architectural and electrical construction drawings of residential buildings. The models were trained using a dataset of 100 to 300 construction drawings, with variations in training epochs, image resolution, and the number of training images of 100 to 300 images. The results showed that, when trained with 300 images at a resolution of 1700x1200 pixels and 80 epochs, YOLOv9 achieved the highest accuracy (90%) in detecting electrical devices such as lights, switches, and receptacles. Meanwhile, U-Net outperformed others in room area segmentation, achieving an Intersection over Union (IOU) score of 83%.

Keywords: Artificial Intelligence, estimation, Artificial Neural Network, Electrical system

1. บทนำ

การถอดปริมาณงานระบบไฟฟ้าเพื่อประมาณราคาก่อสร้างจำเป็นต้องมีการจำแนกและนับจำนวนอุปกรณ์ระบบไฟฟ้าต่าง ๆ อย่างละเอียดเพื่อให้ได้ปริมาณงานที่ถูกต้อง ถ้าเป็นงานที่ดำเนินการโดยผู้รับเหมาขนาดเล็ก เช่น งานก่อสร้างบ้านและอาคารพาณิชย์ ผู้รับเหมา มักนิยมถอดปริมาณงานด้วยมือ ซึ่งเป็นการทำงานที่ใช้เวลานาน ทำให้เกิดความเมื่อยล้าและมีโอกาสเกิดความคลาดเคลื่อนในการจำแนกและนับจำนวนอุปกรณ์ [1] ดังนั้นเพื่อลดข้อผิดพลาดจึงมีแนวคิดในการนำเทคโนโลยีปัญญาประดิษฐ์ซึ่งเป็นเทคโนโลยีที่พัฒนาระบบคอมพิวเตอร์ให้มีความสามารถทำงานเสมือนมนุษย์ได้ โดยเฉพาะเทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นการพัฒนาและฝึกฝนให้ระบบคอมพิวเตอร์สามารถเรียนรู้จากข้อมูลในอดีตเพื่อวิเคราะห์ จำแนกความแตกต่าง และตรวจจับวัตถุ ภาพตัวหนังสือ มาใช้เพิ่มประสิทธิภาพในการกระบวนการถอดปริมาณวัสดุจากแบบก่อสร้าง

เทคโนโลยีโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNN) เป็นเทคโนโลยีปัญญาประดิษฐ์ที่ได้รับความนิยมในการใช้ตรวจจับและจำแนกวัตถุในรูปภาพและเป็นพื้นฐานสำคัญในการพัฒนาแบบจำลองต่างๆ เช่น Mask R-CNN, YOLO และ U-Net [2] โดยแบบจำลองเหล่านี้ได้ถูกนำมาใช้ในอุตสาหกรรมก่อสร้างเพื่อประมาณการปริมาณของแบบหล่อคอนกรีต [3] ตรวจจับความกว้างของรอยแตกในอาคารคอนกรีต [4] และนับจำนวนคนงานในไซต์ก่อสร้าง [5]

ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อศึกษาเชิงเปรียบเทียบการประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ 3 แบบ ได้แก่ Mask R-CNN, YOLOv9 และ U-Net ในการลดปริมาณวัสดุอุปกรณ์ไฟฟ้าและพื้นที่จากแบบก่อสร้าง โดยดำเนินการฝึกฝนแบบจำลองและทดสอบเพื่อวัดผลประสิทธิภาพด้านความเที่ยงตรงและความแม่นยำภายใต้เงื่อนไขต่างๆ

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การลดปริมาณจากแบบก่อสร้าง

การประมาณราคาระบบไฟฟ้าภายในอาคาร เริ่มจากการลดปริมาณวัสดุและอุปกรณ์ไฟฟ้าทั้งหมดจากแบบก่อสร้าง เพื่อนำมาจัดทำรายการวัสดุจำแนกตามหมวดงาน และประมาณราคาค่าวัสดุและค่าแรงที่ต้องใช้รายละเอียดของงานไฟฟ้าถูกจัดทำอยู่ในแบบงานระบบไฟฟ้า ซึ่งประกอบด้วยแบบ แบบไฟฟ้าแสงสว่าง และแบบไฟฟ้ากำลัง

แบบไฟฟ้าแสงสว่างแสดงรายละเอียดของสวิทช์ที่ทำหน้าที่ควบคุมกระแสไฟฟ้าที่ผ่านเข้าไปในเครื่องใช้ไฟฟ้าต่างๆ เช่น สวิทช์ไฟ สวิทช์กดกริ่ง เป็นต้น และดวงไฟที่เป็นอุปกรณ์ไฟฟ้าที่ให้แสงสว่าง โดยสวิทช์ไฟและดวงไฟในแบบไฟฟ้าแสงสว่างมีตัวอย่างสัญลักษณ์ดังตารางที่ 1 และแบบไฟฟ้ากำลังจะแสดงตำแหน่งของเต้ารับไฟฟ้าที่ทำให้กระแสไฟฟ้าไหลเข้าสู่เครื่องใช้ไฟฟ้าให้ครบวงจรและการเชื่อมต่อเต้ารับไฟฟ้ากับวงจรไฟฟ้าของผู้ติดตั้งอุปกรณ์ควบคุมจ่ายไฟฟ้างดตารางที่ 1 [6]

2.2 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) คือ การสร้างอัลกอริทึมที่มีความสามารถในการเรียนรู้ ทำความเข้าใจและทำนายข้อมูลได้ โดยมีมนุษย์เป็นผู้สร้างรูปแบบและผลของการเรียนรู้ผ่านแบบจำลองทางคณิตศาสตร์ ด้วยชุดข้อมูล (Dataset) ต่างๆ

ชุดข้อมูลสำหรับใช้สอนแบบจำลองสามารถใช้ได้หลายรูปแบบ เช่น ตัวอักษร รูปภาพ วิดีโอ หรือ ตัวเลข แต่ข้อมูลดังกล่าวต้องผ่านกระบวนการเตรียมข้อมูล (Data preparation) เช่น การจัดตัวอักษร หรือ ย่อขนาดรูปภาพ ให้อยู่ในรูปของเวกเตอร์ตัวเลข หรือ คุณลักษณะ (Feature) และนำเข้าแบบจำลองเพื่อให้อัลกอริทึมทำการเรียนรู้ [2]

ประเภท	อุปกรณ์	สัญลักษณ์
ดวงโคม	ดวงโคมดาวไลน์	 
	ดวงโคม LED TUBE	 
	ดวงโคมนอกอาคาร	 
	โคมเพดาน	 
สวิทช์	สวิทช์ทางเดียว	 
	สวิทช์สองทาง	 
เต้ารับ	เต้ารับไฟฟ้าคู่	 
เต้ารับ	เต้ารับไฟฟ้าคู่แบบกันน้ำ	 

2.2.1 โครงข่ายประสาทเทียม (Artificial Neural Network)


โครงข่ายประสาทเทียม (Artificial Neural Network ANN) เป็นอัลกอริทึมในการเรียนรู้ที่มีความซับซ้อน ถูกพัฒนาขึ้นมาจากหลักการทำงานของเซลล์ประสาทของมนุษย์ที่ประกอบด้วยเซลล์ประสาทจำนวนมาก โดยเมื่อเปรียบเทียบกับการทำงานของคอมพิวเตอร์แล้วสามารถแบ่งการทำงานได้ออกเป็น 3 ชั้น ประกอบด้วยชั้นนำเข้า (Input layer) ชั้นซ่อน (Hidden layer) และชั้นนำออก (Output Layer) โดยชั้นนำเข้าเป็นชั้นที่นำเข้าข้อมูลมายังโครงข่ายประสาทเทียม ชั้นซ่อนอาจมีจำนวนหลายชั้น หน้าที่หลักคือการสกัดคุณลักษณะของข้อมูลที่ถูกป้อนเข้า และส่งต่อถึงชั้นนำออกที่จะได้ผลการเรียนรู้จากการสกัดข้อมูล [7]

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNN) [6] เป็นโครงข่ายที่ใช้สำหรับตรวจจับรูปภาพ โดยดึงข้อมูลเฉพาะคุณลักษณะสำคัญของภาพ เช่น เส้น ขอบ มุม ประกอบด้วย 3 ชั้น ดังรูปที่ 1 ได้แก่

1. ชั้นคอนโวลูชัน (Convolutional Layer) เป็นชั้นสำหรับดึงเอาคุณสมบัติเฉพาะของรูปภาพออกมาเช่น เส้น ขอบ มุม ปรับเปลี่ยนไปตามพิกเซลในแต่ละจุดของภาพ
2. ชั้นพูลลิง (Pooling Layer) สำหรับการลดขนาดของข้อมูลโดยการรวบรวมข้อมูลจากหลายพิกเซลเป็นพิกเซลเดียว ซึ่งช่วยลดความซับซ้อนของแบบจำลอง

ตารางที่ 1 สัญลักษณ์ของอุปกรณ์ไฟฟ้าในแบบงานระบบไฟฟ้า

3. ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer) คือชั้นที่มีการเชื่อมต่อระหว่างเซลล์ประสาทกับเซลล์ประสาทในชั้นก่อนหน้า เพื่อแปลงข้อมูลจากสองมิติเป็นหนึ่งมิติ เพื่อจำแนกประเภทหรือทำนายค่า




รูปที่ 1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

แบบจำลองที่ใช้ในการตรวจจับรูปภาพมีหลายแบบ โดยในงานวิจัยนี้ เน้นศึกษาแบบจำลองดังนี้

2.2.1.1 แบบจำลอง Mask R-CNN

Mask R-CNN เป็นแบบจำลองตรวจจับภาพที่นิยมสำหรับการแบ่งส่วนรูปภาพ โดยแบ่งในลักษณะพิกเซลต่อพิกเซลด้วย Roi Align ที่เป็นวิธีการเรียนรู้โดยการซ้อนทับกันระหว่างรูปที่ทำการระบุวัตถุไว้กับรูปที่ต้องการฝึก และให้แบบจำลองจดจำในระดับพิกเซล โดยผู้ฝึกต้องระบุชื่อของวัตถุตำแหน่งของวัตถุที่อยู่ในภาพ และบันทึกเป็นไฟล์ COCO (Common Objects in Context) ที่เปลี่ยนรูปภาพให้เป็นตัวเลข ก่อนที่ดำเนินการฝึกกับแบบจำลอง [8]



รูปที่ 2 หลักการ Roi Align [3]

2.2.1.2 แบบจำลอง YOLO

YOLO (You Only Look Once) เป็นแบบจำลองเพื่อตรวจจับวัตถุและจำแนกประเภทซึ่งเป็นที่ยอมรับในระบอบข้อผิดพลาด การตรวจสอบความปลอดภัย โดยเริ่มตรวจจับรูปภาพจากการแบ่งรูปออกเป็นหลายส่วน (Grid) และทำนายทุกส่วนพร้อมกันทำให้มีความรวดเร็วในการตรวจจับวัตถุ โดยในปัจจุบันแบบจำลองได้ถูกพัฒนาจนถึงเวอร์ชันที่ 9 (YOLOv9) ที่ใช้สถาปัตยกรรม GELAN (Generalized Efficient Layer Aggregation Network) เพื่อเพิ่มความชัดของภาพและความแม่นยำในการตรวจจับ [9]

2.2.1.3 แบบจำลอง U-net

U-Net เป็นแบบจำลองสำหรับแบ่งส่วนของภาพด้วยความละเอียดระดับพิกเซล โดย U-Net นิยมใช้ในการวิเคราะห์ภาพทางการแพทย์ งานในด้านชีววิทยา และการข้อผิดพลาด การเรียนรู้ของ U-net เริ่มจากการลดและขยายรูปภาพ หรือเรียกว่า Encoder และ Decoder ซึ่งเชื่อมกันในลักษณะตัว U โดยนำรูปที่มีขนาดใหญ่และรูปที่ระบุตำแหน่งวัตถุใน

มาซ้อนทับกันเพื่อให้แบบจำลองเรียนรู้ตำแหน่งของวัตถุในระดับพิกเซลและขนาดที่แตกต่างกัน วิธีนี้ช่วยให้แบบจำลองเรียนรู้จากจำนวนตัวอย่างที่น้อยได้อย่างมีประสิทธิภาพ [10]

2.2.2 การประเมินความสามารถของแบบจำลอง

การประเมินผลความสามารถของแบบจำลองในการตรวจจับวัตถุหรือพื้นที่จากรูปภาพนั้นมีความถูกต้องมากน้อยเพียงใดนั้นสามารถทำได้โดยทดสอบการตรวจจับวัตถุกับชุดตัวอย่างการทดสอบหลาย ๆ ชุดตัวอย่างและบันทึกผลการทดสอบในแต่ละชุดตัวอย่าง โดยความสามารถของแบบจำลองนั้นสามารถวัดได้หลายแบบ ดังนี้

2.2.2.1 ความแม่นยำ (Accuracy)

ความแม่นยำ (Accuracy) คือ การเปรียบเทียบระหว่างจำนวนภาพที่ทำนายถูกต้อง (True Positive และ True Negative) กับจำนวนภาพทั้งหมดที่ทำนายทั้งถูกและผิด เพื่อวัดความแม่นยำของแบบจำลอง

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

2.2.2.2 ความเที่ยงตรง (Precision)

ความเที่ยงตรง (Precision) คือการวัดจำนวนครั้งที่แบบจำลองทำนายถูก (True Positive) เทียบกับจำนวนที่แบบจำลองทำนายทั้งหมด

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

โดย TP, TN, FP และ FN หมายถึง

True Positive (TP) = วัตถุที่แบบจำลองตรวจพบ

True negative (TN) = พื้นที่ที่ไม่มีวัตถุและแบบจำลองตรวจไม่พบ (กำหนด TN=0)

False Positive (FP) = วัตถุที่ไม่ต้องการแต่แบบจำลองตรวจพบ

False negative (FN) = วัตถุที่ต้องการแต่แบบจำลองตรวจไม่พบ

2.2.2.3 ค่าไอโอยู (Intersection Over Union : IOU)

ค่าไอโอยู (IOU) เป็นค่าที่ใช้วัดการซ้อนทับกันระหว่างพื้นที่จากรูปจริงกับพื้นที่ที่แบบจำลองทำนาย ใช้สำหรับการประเมินความแม่นยำในการตรวจจับที่เกี่ยวกับการแบ่งพื้นที่

$$\text{ค่าไอโอยู (IOU)} = \frac{\text{พื้นที่ทำนาย}}{\text{พื้นที่จริง}} \quad (3)$$

2.3 งานวิจัยที่เกี่ยวข้อง

Chowdhury และ Moon [3] ได้ใช้ปัญญาประดิษฐ์ในการคำนวณปริมาณและการประมาณราคาค่าใช้จ่ายแบบอัตโนมัติของแบบหล่อคอนกรีต โดยเชื่อมข้อมูลเข้ากับฐานข้อมูลต้นทุนเพื่อสร้างรายการวัสดุ (BoMs) ใช้แบบจำลอง Mask R-CNN และเทคนิคการแบ่งส่วนภาพ ที่ฝึกฝนโดยใช้ภาพ CAD 2 มิติ 186 ภาพ แบ่งประเภทของภาพได้ 3353 ประเภท ได้ค่าเฉลี่ยความแม่นยำ (mean average precision, mAP) อยู่ที่ 98% ที่ นอกจากนี้ยังมีการใช้เทคโนโลยี Optical Character Recognition (OCR) เพื่อดึงข้อมูลตัวเลขจากรูปภาพ เพื่อผสานกับฐานข้อมูลต้นทุนของ

วัสดุ BoM-GAIM และสามารถสร้าง BoM สำหรับแบบหล่อคอนกรีตจากภาพ CAD 2D ได้ซึ่งช่วยประสิทธิภาพในการถอดปริมาณแบบหล่อคอนกรีต

Chen, Wu และ Puranam [4] ได้นำ U-Net มาตรวจสอบความกว้างของรอยแตกในโครงสร้างคอนกรีตเสริมเหล็ก (RC) ที่โดยปกติจะดึงพื้นที่ของรอยแตกออกมาแล้วทำการคำนวณความกว้าง แต่เพื่อให้ตรวจสอบได้แม่นยำขึ้นจึงได้ใช้แบบจำลองแบบหลายภารกิจ (multi-task) ที่สามารถคาดการณ์การรอยแตกและจุดกึ่งกลางของรอยแตกได้พร้อมกัน โดยใช้แบบจำลอง U-Net และใช้รูปภาพจากหน้างานจริงผสมกับรูปรอยแตกที่ทำขึ้นมาเอง จำนวน 1,014 ภาพ โดยผลจากการฝึกฝนแสดงให้เห็นว่าแบบจำลองหลายภารกิจมีประสิทธิภาพดีกว่าแบบจำลองพื้นฐานที่จากค่า IoU ที่ 59.5% กับ 61.7% และ F1 ที่ 0.55 กับ 0.61 โดยสามารถเพิ่มความแม่นยำได้หลังจากที่ทำนายความกว้างของรอยแตกแล้วด้วยการใช้คอมพิวเตอร์วิทัศน์ (Computer Vision) ในการคำนวณความกว้างของรอยแตกและใช้การสร้างภาพสามมิติจากรูปสองมิติโดยใช้ Projection Matrix เพื่อปรับรูปทรงของรอยแตก และแก้ไขความบิดเบี้ยวระหว่างการถ่ายรูปซึ่งผลที่ได้ช่วยให้อรรถภาพขนาดใกล้เคียงกับความจริง

วรพันธ์ และคณะ [5] ได้นำเทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์มาแก้ปัญหาการควบคุมงานที่ขาดประสิทธิภาพ โดยการตรวจนับจำนวนคนงานบริเวณสถานที่ก่อสร้างจากภาพถ่ายบริเวณสถานที่ก่อสร้างประกอบด้วยภาพจากกล้องวงจรปิด ภาพสถานที่ก่อสร้างกลางแจ้ง ภาพสถานที่ก่อสร้างภายในอาคาร และภาพสถานที่ก่อสร้างบริเวณแสงน้อย โดยใช้แบบจำลองสำหรับการตรวจนับรูปภาพ 4 ประเภทได้แก่ YOLOv4, YOLOv8, YOLOv9 และ ACF ซึ่งมีแบบจำลองย่อยรวม 10 แบบจำลองตรวจสอบค่าชี้วัดทั้งหมด 3 ค่าได้แก่ recall, precision และ F1-score พบว่าภาพจากกล้องวงจรปิดเป็นภาพที่แบบจำลองทำนายผิดพลาดมากที่สุดและภาพในที่แสงน้อยเป็นภาพที่แบบจำลองทำนายดีที่สุด โดย YOLOv9 มีความแม่นยำสูงสุด YOLOv4 YOLOv8 มีความแม่นยำรองลงมา และ ACF มีความแม่นยำต่ำที่สุด

Mei และคณะ [11] พบว่าการที่คนงานเดินเข้าสู่พื้นที่อันตรายเป็นสาเหตุสำคัญของอุบัติเหตุประเภทหนึ่ง งานวิจัยนี้จึงนำ YOLOv5 มาใช้ในการตรวจนับบุคคลที่บุกรุกเข้าสู่เขตพื้นที่อันตรายของไซต์ก่อสร้าง พร้อมทั้งสร้างฐานข้อมูลสำหรับการตรวจนับการบุกรุก (Intrusion Rule Base) ซึ่งกำหนดระดับความไวที่แตกต่างกันตามสถานะของการบุกรุก โดยจากการทดสอบพบว่า แบบจำลองที่พัฒนามี ค่า Precision ที่ 96.05% และ Recall ที่ 90.05% ซึ่งสามารถช่วยเพิ่มความปลอดภัยในไซต์งานก่อสร้างได้อย่างมีประสิทธิภาพ

สันติภูมิ [12] ได้นำโครงข่ายประสาทเทียม (Artificial Neural Networks) เพื่อสร้างแบบจำลองสำหรับประมาณราคาก่อสร้างเบื้องต้นด้วยโปรแกรม RapidMiner โดยใช้ข้อมูลพื้นที่ของอาคารที่ก่อสร้างแล้วภายในมหาวิทยาลัยเชียงใหม่จำนวน 50 แห่ง และเมื่อนำมาเปรียบเทียบกับราคาก่อสร้างจริงแล้ว พบว่าการประมาณราคาจากโครงข่ายประสาทเทียมมีความแม่นยำถึง 90.46%

Perez และคณะ [13] ได้นำปัญญาประดิษฐ์มาใช้ในการบำรุงรักษาถนน (Pavement Management) เพื่อประเมินสภาพพื้นผิวถนนแบบอัตโนมัติ ทำนายการเสื่อมสภาพ และสร้างแผนบำรุงรักษาภายใต้งบประมาณที่จำกัด โดยใช้เทคนิคปัญญาประดิษฐ์ 3 วิธี ได้แก่ Convolutional Neural Networks (CNN), Feed-Forward Neural Networks (FNN) และ Multi-Criteria Decision Making (MCDM)

จากการทบทวนงานวิจัยในอดีตที่กล่าวมาข้างต้น สามารถสรุปแบบจำลองที่นำมาประยุกต์ใช้ในงานก่อสร้างได้ดังตารางที่ 2 จะเห็นได้ว่าแบบจำลองทั้งสามแบบมีความเป็นไปได้ในการนำมาใช้ในการตรวจนับอุปกรณ์ระบบไฟฟ้าจากแบบก่อสร้าง ซึ่งผู้วิจัยจะดำเนินการศึกษาเชิงเปรียบเทียบการนำแบบจำลองทั้งสามไปใช้งานต่อไป

ตารางที่ 2 งานวิจัยที่เกี่ยวข้องกับการนำแบบจำลองปัญญาประดิษฐ์มาใช้งานก่อสร้าง

หัวข้อ	รายละเอียด	แบบจำลองที่ใช้
การถอดปริมาณงาน	คำนวณปริมาณและค่าใช้จ่ายของแบบหล่อคอนกรีต [3]	Mask R-CNN
	ประมาณราคาก่อสร้างอาคารสูง [12]	โครงข่ายประสาทเทียม
การตรวจสอบสิ่งก่อสร้าง	ใช้แบบจำลองในการตรวจสอบความกว้างของรอยแตกในโครงสร้างคอนกรีตเสริมเหล็ก [4]	U-Net
	ใช้แบบจำลอง ในการประเมินสภาพพื้นผิวถนน [13]	U-Net
การตรวจนับวัตถุ	ใช้แบบจำลองในการตรวจนับคนงาน [5]	YOLO
	สร้างฐานข้อมูลและตรวจนับคนงานที่เดินเข้าสู่พื้นที่อันตรายในเขตก่อสร้าง [11]	YOLO

3. ระเบียบการวิจัย

งานวิจัยนี้ได้นำปัญญาประดิษฐ์มาเปรียบเทียบในการถอดปริมาณอุปกรณ์ระบบไฟฟ้าและพื้นที่ห้องจากแบบก่อสร้างอาคาร โดยแบ่งวิธีการวิจัยเป็น 5 ขั้นตอน ดังต่อไปนี้

3.1 กำหนดจำนวนรูปภาพและค่าตัวแปรที่ใช้ในการฝึกฝนแบบจำลอง

เนื่องจากการฝึกฝนแบบจำลองเพื่อมาใช้ในการตรวจนับวัตถุนั้น จำเป็นต้องมีการกำหนดค่าตัวแปรสำหรับการฝึกฝนแบบจำลองก่อน โดยค่าตัวแปรเหล่านี้ประกอบด้วย 1. จำนวนรอบของการฝึก (Epoch) 2. ขนาดหรือความละเอียดของรูปภาพที่นำมาฝึก (Image Size) และ 3.

จำนวนรูปภาพที่ใช้ในการฝึกฝน การเปลี่ยนแปลงค่าตัวแปรเหล่านี้ส่งผลต่อระยะเวลาในการฝึกฝนและความสามารถในการตรวจจับวัตถุของแบบจำลอง ดังนั้นในขั้นตอนแรกของงานวิจัย จึงเป็นการทดลองเพื่อหาความสัมพันธ์ระหว่างค่าตัวแปรต่อความแม่นยำในการตรวจจับวัตถุของแบบจำลอง ผู้วิจัยได้แบ่งการทดลองนี้ออกเป็น 2 ขั้นตอน ดังนี้

ขั้นตอนที่ 1 หาความสัมพันธ์ระหว่างขนาดของรูปภาพและจำนวนรอบการฝึกกับความแม่นยำของแบบจำลอง เมื่อกำหนดจำนวนรูปภาพที่ใช้ฝึกฝนคงที่จำนวน 100 รูปภาพ แบ่งข้อมูลเป็นชุดฝึก (Train) 90 รูป ชุดตรวจสอบ (Validate) 10 รูป และแยกชุดทดสอบ (Test) 10 รูป โดยมีตัวแปร ขนาดของรูปภาพและจำนวนรอบการฝึกฝนแบบจำลองแต่ละแบบดังตารางที่ 3 และการทดสอบความแม่นยำของแบบจำลองใช้การตรวจจับดวงไฟในแบบไฟฟ้าแสงสว่างจำนวน 10 รูป

ตารางที่ 3 จำนวนรูปภาพที่ใช้ฝึกฝนและทดสอบแบบจำลองแต่ละแบบ

		จำนวนรูปภาพที่ใช้ฝึกฝน (รูป)	จำนวนรูปภาพที่ใช้ตรวจสอบ (รูป)	จำนวนรูปภาพที่ใช้ทดสอบดวงไฟ (รูป)
ขนาดรูปภาพ (พิกเซล)	850x600	90	10	10
	1133x800	90	10	10
	1700x1200	90	10	10
จำนวนรอบการฝึก (รอบ)	40	90	10	10
	60	90	10	10
	80	90	10	10
	100	90	10	10

ขั้นตอนที่ 2 นำค่าจำนวนรอบการฝึกและขนาดของรูปภาพที่หาจากขั้นตอนที่ 1 มาใช้ในการฝึกฝนแบบจำลอง และหาความสัมพันธ์ระหว่างจำนวนรูปภาพที่ใช้ในการฝึกกับความแม่นยำของแบบจำลอง ดังตารางที่ 4 ในขั้นตอนที่ 2 นี้จะหาความสัมพันธ์ระหว่างจำนวนรูปภาพที่ใช้ในการฝึกฝนตั้งแต่ 100 – 300 รูป และนำมาทดสอบการตรวจจับดวงไฟ สวิตช์ เต้ารับ และพื้นที่อาคาร จำนวนอย่างละ 20 รูป

ตารางที่ 4 จำนวนรูปภาพที่ใช้ทดสอบ


จำนวนรูปภาพที่ใช้ฝึกฝน (รูป)	จำนวนรูปภาพที่ใช้ตรวจสอบ (รูป)	จำนวนรูปภาพที่ใช้ทดสอบ			
		ดวงไฟ	สวิตช์	เต้ารับ	พื้นที่
90	10	20	20	20	20
135	15	20	20	20	20
180	20	20	20	20	20
225	25	20	20	20	20
270	30	20	20	20	20

3.2 รวบรวมรูปภาพแบบก่อสร้าง


จากจำนวนการทดลองที่ได้ออกแบบไว้ ผู้วิจัยได้รวบรวมแบบบ้านพักอาศัยจาก 1 ชั้น และ 2 ชั้น จากกรมโยธาธิการและผังเมือง เว็บไซต์ที่รวบรวมรูปภาพสำหรับการฝึกปัญญาประดิษฐ์ แบบบ้านจากอินเทอร์เน็ต และจากไซต์งานก่อสร้างจริงที่มีรูปแบบแตกต่างกัน โดยแบบก่อสร้างส่วนใหญ่มีอยู่ในรูปแบบ PDF ซึ่งต้องแปลงเป็นไฟล์ PNG หรือ JPG ก่อนที่จะทำการฝึก โดยแบบที่ใช้ได้แก่ แบบสถาปัตยกรรม แบบไฟฟ้าแสงสว่าง และ แบบไฟฟ้ากำลัง

3.3 เตรียมข้อมูลสำหรับฝึกฝนแบบจำลอง

การเตรียมข้อมูลเริ่มจากกำหนดประเภทของวัตถุในรูปภาพโดยแบ่งเป็น 4 ประเภท (Class) ได้แก่ พื้นที่ห้อง ดวงไฟ สวิตช์ และ เต้ารับ ไฟฟ้า โดยใช้โปรแกรม CVAT (Computer Vision Annotation Tool) ในการระบุตำแหน่งวัตถุที่สนใจด้วยเครื่องมือ Rectangle สำหรับการหาตำแหน่งวัตถุ และ Polygon สำหรับการแบ่งพื้นที่ดังรูปที่ 3 และ 4 ตามลำดับ



รูปที่ 3 การแบ่งพื้นที่ด้วยเครื่องมือ Polygon



รูปที่ 4 การระบุตำแหน่งของวัตถุด้วยเครื่องมือ Rectangle

ในการกำหนดพื้นที่ของห้องจะกำหนดจากแนวมวงที่ใช้ในการแบ่งห้อง ส่วนการกำหนดวัตถุในแบบไฟฟ้าจะอ้างอิงจากสัญลักษณ์ของดวงไฟ สวิตช์ และเต้ารับไฟฟ้า ตามตารางที่ 1 จากนั้นจึงบันทึกข้อมูลของวัตถุและส่งออกเป็นไฟล์สำหรับการฝึกแบบจำลองได้แก่ ไฟล์ COCO (Common Objects in Context), Ultralytics YOLO และ Segmentation Mask สำหรับ Mask R-CNN YOLOv9 และ U-Net ตามลำดับ โดยในโปรแกรม

CVAT สามารถส่งออกข้อมูลที่รองรับของทั้งสามแบบจำลองได้ ซึ่งเป็นความสามารถที่แตกต่างจากโปรแกรมอื่นที่ใช้ในการระบุตำแหน่งของวัตถุ

3.4 ฝึกฝนแบบจำลองปัญญาประดิษฐ์

หลังจากที่แบ่งประเภทของวัตถุแล้ว การฝึกของทั้งสามแบบจำลองจะเหมือนกัน โดยเริ่มจากการสร้างไฟล์ที่ใช้ในการฝึกด้วยภาษา Python ทั้งหมด 4 ไฟล์ แยกตามประเภทของวัตถุ จากนั้นทำการฝึกตามกรณีการทดสอบจากหัวข้อที่ 3.1

3.5 ทดสอบและประเมินผลแบบจำลอง


หลังจากที่ฝึกฝนแบบจำลองตามหัวข้อที่ 3.1 แล้ว ทำการทดสอบผลลัพธ์ของทั้งสามแบบจำลอง โดยทดสอบกับรูปดวงไฟทั้งหมด 10 รูปเพื่อหาขนาดรูปภาพและจำนวนรอบในการฝึกที่เหมาะสม และนำค่าที่ได้มาทำการฝึกและทดสอบกับวัตถุทั้ง 4 ประเภท ประเภทละ 20 รูปเพื่อหาความแม่นยำของแบบจำลองทั้ง 3 ค่า ได้แก่ ความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) และ ค่าไอโอยู (IOU) โดยสามารถคำนวณได้จากสมการที่ (1) ถึง (3) ตามลำดับ

4. ผลการวิจัย


4.1 จำนวนรอบและขนาดของรูปภาพที่เหมาะสม

ในการวิจัยนี้ได้ใช้คอมพิวเตอร์ที่มีหน่วยประมวลผล i7-11700 หน่วยความจำ 16 GB และหน่วยประมวลผลกราฟิก (GPU) รุ่น GeForce GTX 1650 ทำให้สามารถฝึกแบบจำลองได้เฉพาะภาพขนาด 850×600, 1133×800 และ 1700×1200 พิกเซล และจำนวนรอบการฝึก (epochs) ที่ 40, 60, 80 และ 100 รอบเนื่องจากขนาดของรูปภาพ จำนวนรอบในการฝึก และความเร็วในการฝึกแบบจำลอง ขึ้นอยู่กับความสามารถของ GPU เป็นหลัก โดย GPU ที่มีหน่วยความจำ (VRAM) มากขึ้นและจำนวนคอร์สูง จะช่วยลดระยะเวลาในการฝึกแบบจำลองได้


รูปที่ 5 ถึงรูปที่ 7 ได้แสดงตัวอย่างผลการตรวจจับดวงไฟโดยใช้แบบจำลอง Mask R-CNN YOLOv9 และ U-Net โดยแบบจำลอง Mask R-CNN และ U-Net แสดงผลในลักษณะการระบายสีที่บนตำแหน่งของดวงไฟ (Segmentation) เพื่อระบุตำแหน่งของดวงไฟ ในขณะที่แบบจำลอง YOLOv9 แสดงผลโดยการสร้างกรอบสี่เหลี่ยม (Bounding Box) ล้อมรอบวัตถุ เพื่อระบุตำแหน่งของดวงไฟ



รูปที่ 5 ตัวอย่างผลลัพธ์ที่ได้จากการตรวจจับวัตถุด้วย Mask R-CNN




รูปที่ 6 ตัวอย่างผลลัพธ์ที่ได้จากการตรวจจับวัตถุด้วย YOLOv9




รูปที่ 7 ตัวอย่างผลลัพธ์ที่ได้จากการตรวจจับวัตถุด้วย U-net

หลังจากที่ได้ผลลัพธ์การตรวจจับดวงไฟแล้ว จึงตรวจสอบความถูกต้อง โดยจำแนกผลการตรวจจับเป็น 3 ค่า ค่าดังรูปที่ 8 ได้แก่ TP (True Positive) คือ จำนวนดวงไฟที่ตรวจจับได้อย่างถูกต้อง FP (False Positive) คือ จำนวนวัตถุที่ไม่ใช่ดวงไฟ FN (False Negative) คือ จำนวนดวงไฟที่ไม่ได้ตรวจจับ




รูปที่ 8 ตัวอย่างการจำแนกผลลัพธ์ของแบบจำลอง


ค่าที่ได้จากผลการตรวจจับดวงไฟจะนำมาหาความแม่นยำเฉลี่ยเปรียบเทียบกับระยะเวลาในการฝึกตามรูปที่ 9 ถึง 11



รูปที่ 9 ความแม่นยำและระยะเวลาในการฝึกจากการฝึกด้วยรูปขนาด 850x600



รูปที่ 10 ค่าความแม่นยำและระยะเวลาในการฝึกจากการฝึกด้วยรูปขนาด 1133x800




รูปที่ 11 ความแม่นยำและระยะเวลาในการฝึกจากการฝึกด้วยรูปขนาด 1700x1200


จากผลความแม่นยำในการตรวจจับดวงไฟแสดงให้เห็นว่าขนาดของรูปภาพและจำนวนรอบในการฝึกส่งผลต่อความแม่นยำในการตรวจจับวัตถุ โดยจากรูปที่ 11 การใช้ภาพขนาด 1700x1200 พิกเซล ให้ความแม่นยำสูงสุด ส่วนจำนวนรอบในการฝึกส่งผลให้ความแม่นยำเพิ่มขึ้นจนถึง 80 รอบก่อนที่จะเพิ่มขึ้นเพียงเล็กน้อย (1% - 3%) เมื่อถึง 100 รอบ แต่ใช้ระยะเวลาในการฝึกเพิ่มขึ้น 8 ถึง 136 นาทีตามแบบจำลองที่แตกต่างกัน ดังนั้นในงานวิจัยนี้จึงเลือกใช้รอบในการฝึก 80 รอบ และความละเอียดของภาพ 1700x1200 พิกเซล เพื่อให้สอดคล้องกับฮาร์ดแวร์ที่ใช้ทำงาน

4.2 ผลการเปรียบเทียบความแม่นยำ


นำค่าขนาดของรูปภาพและจำนวนรอบมาฝึกกับแบบจำลองทั้งสามและทำการทดสอบความแม่นยำกับวัตถุทั้งสี่ประเภท โดยใช้จำนวนรูปภาพสำหรับการฝึก 100, 150, 200, 250, 300 รูป ได้ผลลัพธ์ความแม่นยำ (Accuracy) ดังนี้




รูปที่ 12 ความแม่นยำ (Accuracy) ในการตรวจจับดวงไฟของแต่ละแบบจำลอง




รูปที่ 13 ความเที่ยงตรง (Precision) ในการตรวจจับดวงไฟของแต่ละแบบจำลอง




รูปที่ 14 ความแม่นยำ (Accuracy) ในการตรวจจับสวิตช์ไฟของแต่ละแบบจำลอง




รูปที่ 17 ความเที่ยงตรง (Precision) ในการตรวจจับตัวรับไฟฟ้าของแต่ละแบบจำลอง



รูปที่ 15 ความเที่ยงตรง (Precision) ในการตรวจจับสวิตช์ไฟของแต่ละแบบจำลอง



รูปที่ 18 ค่าไอโอยูจากการแบ่งพื้นที่ห้องของแต่ละแบบจำลอง



รูปที่ 16 ความแม่นยำ (Accuracy) ในการตรวจจับตัวรับไฟฟ้าของแต่ละแบบจำลอง

4.3 อภิปรายผล

รูปที่ 9 ถึง 11 แสดงผลการทดสอบค่าความแม่นยำทั้ง 3 ค่า ได้แก่ ความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) และค่าไอโอยู (IOU) ด้วยการฝึกด้วยภาพขนาด 1700x1200 พิกเซลและจำนวนรอบในการฝึก 80 รอบ ทั้งสามแบบจำลองมีแนวโน้มไปในทิศทางเดียวกัน โดยจะเพิ่มขึ้นตามจำนวนรูปภาพที่ใช้ในการฝึก

รูปที่ 12 ถึง 18 แสดงให้เห็นว่าจำนวนรูปภาพส่งผลต่อความแม่นยำในการตรวจจับวัตถุ โดยค่าความแม่นยำเพิ่มขึ้น 10-30% ในช่วงจำนวนรูป 100 ถึง 250 รูป และเพิ่มขึ้นเพียงเล็กน้อย (1%-5%) ในช่วง 250 ถึง 300 รูป

ค่าความแม่นยำในการตรวจจับวัตถุแต่ละประเภทมีความแตกต่างกันในแต่ละแบบจำลอง โดยตารางที่ 5 แสดงผลของแบบจำลองที่ดีที่สุดสำหรับการจำแนกวัตถุแต่ละประเภทจากการฝึกด้วยรูปภาพจำนวน 300 รูป พบว่า การตรวจจับตัวรับไฟฟ้ามีความแม่นยำสูงสุดที่ 99% รองลงมา

คือดวงไฟที่ 95% และสวิตช์ไฟที่ 88% ตามลำดับ ในขณะที่การแบ่งพื้นที่ห้องมีความแม่นยำสูงสุดอยู่ที่ 83%

ตารางที่ 5 แบบจำลองที่ดีที่สุดสำหรับแต่ละวัตถุจากการฝึกด้วยรูปภาพขนาด 1700x1200 พิกเซล จำนวน 300 รูป และ รอบการฝึก 80 รอบ

ประเภทของวัตถุ	แบบจำลองที่ดีที่สุด (Best Model)	Accuracy (%)	IoU (%)
ดวงไฟ	YOLOv9	95%	-
สวิตช์ไฟ	YOLOv9	88%	-
เต้ารับ	YOLOv9	99%	-
พื้นที่ห้อง	U-Net	-	83%

นอกจากความสามารถของแบบจำลองและปัจจัยในการฝึกที่ส่งผลต่อความแม่นยำของแบบจำลองแล้ว ปัจจัยอื่นที่ส่งผลต่อความแม่นยำ ได้แก่ ขนาดและรายละเอียดของวัตถุ เช่น สัญลักษณ์สวิตช์ไฟและดวงไฟมีขนาดเล็กกว่าปลั๊กไฟ ความซับซ้อนของสัญลักษณ์ต่างๆ และการจัดวางสัญลักษณ์ใกล้กันอาจทำให้แบบจำลองเกิดความสับสน วัตถุที่มีลักษณะคล้ายกัน เช่น สัญลักษณ์หัวฝักบัวที่คล้ายกับดวงไฟ รวมถึงเส้น Gridline ที่คล้ายกับผนังห้องซึ่งส่งผลให้เกิดความผิดพลาดในการแบ่งพื้นที่ห้อง

5. สรุปผลและข้อเสนอแนะ

จากการนำปัญญาประดิษฐ์มาประยุกต์ใช้ในการถอดปริมาณจากรูปภาพเพื่อแบ่งพื้นที่ห้อง ตรวจสอบดวงไฟ สวิตช์ และเต้ารับไฟฟ้า พบว่าขนาดภาพ จำนวนรอบการฝึก และจำนวนรูปภาพในการฝึกฝนมีผลต่อความแม่นยำของแบบจำลองทั้ง 3 แบบ โดยขนาดภาพที่ใหญ่ขึ้น จำนวนรอบการฝึกที่มากขึ้น และจำนวนรูปภาพที่เพิ่มขึ้น ช่วยให้แบบจำลองเรียนรู้รายละเอียดของวัตถุได้ดีขึ้นและส่งผลให้ความแม่นยำเพิ่มขึ้น แต่เมื่อถึงจุดหนึ่งความแม่นยำจะเพิ่มขึ้นไม่มากนัก ในขณะที่ระยะเวลาที่ใช้ในการฝึกฝนจะเพิ่มมากขึ้น และขนาดภาพที่ใหญ่ขึ้นนั้นส่งผลต่อการประมวลผลกราฟิกและพบข้อจำกัดด้านฮาร์ดแวร์ของหน่วยประมวลผลกราฟิก (GPU) โดยงานวิจัยนี้พบว่าควรใช้รูปภาพขนาดอย่างน้อย 1700x1200 พิกเซล จำนวนรอบในการฝึกอย่างน้อย 80 รอบ และจำนวนรูปภาพอย่างน้อย 250 รูปในการฝึกฝนแบบจำลอง

เมื่อเปรียบเทียบความแม่นยำในการตรวจนับวัตถุระหว่างแบบจำลองทั้งสาม พบว่าแบบจำลอง YOLOv9 มีค่าความแม่นยำในการตรวจนับวัตถุ (object detection) เช่น ดวงไฟ สวิตช์ และเต้ารับสูงที่สุด ส่วนการแบ่งพื้นที่ห้อง (segmentation) นั้น พบว่า แบบจำลอง U-Net ให้ผลลัพธ์แม่นยำที่สุด ซึ่งแสดงให้เห็นถึงความเหมาะสมของแบบจำลองแต่ละประเภทตามลักษณะของงานที่ต้องการ และเมื่อนำแบบจำลองมาใช้งานจะช่วยลดภาระงาน และเพิ่มความรวดเร็วในการนับจำนวนวัตถุได้

งานวิจัยนี้มุ่งเน้นการฝึกแบบจำลองสำหรับการถอดปริมาณงานไฟฟ้าในบ้านพักอาศัยเท่านั้น โดยในการทำงานในอนาคต สามารถฝึกแบบจำลองเพื่อให้สามารถตรวจนับวัตถุประเภทอื่นในงานก่อสร้างได้ และอาจนำ

แบบจำลองที่ฝึกเสร็จแล้วไปพัฒนาให้เป็นแอปพลิเคชันหรือโปรแกรมคอมพิวเตอร์ เพื่อเพิ่มความสะดวกในการใช้งาน

เอกสารอ้างอิง

- [1] จิตาภรณ์ พอบุตรดี. (2565). ระบบช่วยสั่งงานด้วยเสียงสำหรับถอดปริมาณงานก่อสร้างอาคาร. วารสารศรีปทุมปริทัศน์ ฉบับวิทยาศาสตร์และเทคโนโลยีปีที่ 14.
- [2] คณบดี ศรีสมบุญ. (2565). การเรียนรู้ของเครื่อง (Machine Learning) (Vol. 1). มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ: ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์.
- [3] Ayesha Chowdhury and Sungwoo Moon. (2023). Generating integrated bill of materials using mask R-CNN artificial intelligence model. *Automation in Construction*.
- [4] Yi-Chang Chen, Rih-Teng Wu and Aishwarya Puranam. (2024). Multi-task deep learning for crack segmentation and quantification in RC structures. *Automation in Construction*.
- [5] วรพันธ์ ปัญญาภาศ, พรพจน์ นุเสน, ชนิษฐา ไชยพันธุ์ และมานพ แก้วโมราเจริญ. (2567). การเปรียบเทียบปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์ สำหรับกระบวนการก่อสร้างในระหว่างการก่อสร้าง ระหว่างโมเดล YOLOv9 และ ACF. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 29.
- [6] สวง บุณรอด. (2555). ความรู้เบื้องต้นเกี่ยวกับระบบไฟฟ้า. วิทยาลัยเทคโนโลยีพัฒนการอยุธยา. แผนกวิชาสามัญสัมพันธ์ (วิทยาศาสตร์ – คณิตศาสตร์).
- [7] Saptarshi Sengupta, Sanchita Basak, Pallabi Saikia, Sayak Paul, Vasilios Tsalavoutis, Frederick Atiah and Alan Peters. (2020). A review of deep learning with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems*, Volume 194.
- [8] Kaiming He, Georgia Gkioxari, Piotr Dollár and Ross Girshick. (2017). Mask R-CNN. *Computer Vision (ICCV), 2017 IEEE International Conference*.
- [9] Chien-Yao Wang, I-Hau Yeh and Hong-Yuan Mark Liao. (2024). YOLOv9: Learning what you want to learn using programmable gradient information. *arXiv preprint arXiv:2402*.
- [10] Olaf Ronneberger, Philipp Fischer and Thomas Brox. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, Cham.
- [11] Xinyu Mei, Xiaojing Zhou, Feng Xu and Zhipeng Zhang. (2022). Human Intrusion Detection in Static Hazardous Areas at Construction Sites: Deep Learning-Based Method. *Journal of Construction Engineering and Management*.

- [12] สันติภูมิ สิทธิราษฎร์. (2565). การประมาณราคาเบื้องต้น สำหรับงานก่อสร้างอาคารด้วยวิธีเทคนิคโครงข่ายประสาทเทียม. สาขาวิศวกรรมศาสตรมหาบัณฑิต. ภาควิชาวิศวกรรมและการบริหารการก่อสร้าง. มหาวิทยาลัยเชียงใหม่
- [13] Noelia Molinero-Perez, Tatiana García-Segura, Laura Montalbán-Domingo, Amalia Sanz, Jordi Mansanet and Eugenio Pellicer. (2024). Artificial Intelligent Techniques to Improve Pavement Maintenance Management. Construction Research Congress 2024.