



การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบก่อสร้างอาคาร
บ้านพักอาศัย

นายเมธัส ชินหิรัญ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

วิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมโยธา

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบก่อสร้างอาคาร
บ้านพักอาศัย



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาหลักสูตร

วิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมโยธา

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ใบรับรองวิทยานิพนธ์

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

เรื่อง การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบ
ก่อสร้างอาคารบ้านพักอาศัย

โดย นายเมธัส ชินหิรัญ

ได้รับอนุมัติให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโยธา

..... คณบดีบัณฑิตวิทยาลัย / หัวหน้าภาควิชา

(ผู้ช่วยศาสตราจารย์ ดร.สุพจน์ จันทรวีวัฒน์)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ

(รองศาสตราจารย์ ดร.วิรัช วิปุลานุสาสน์)

..... อาจารย์ที่ปรึกษา

(ผู้ช่วยศาสตราจารย์ ดร.กวิน ตันติเสวี)

..... กรรมการ

(ศาสตราจารย์ ดร.วรรณวิทย์ แต้มทอง)

ชื่อ : นายเมธัส ชินศิริญ
 ชื่อวิทยานิพนธ์ : การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบก่อสร้างอาคารบ้านพักอาศัย
 สาขาวิชา : วิศวกรรมโยธา
 มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
 อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก : ผู้ช่วยศาสตราจารย์ ดร.กวิน ดันติเสวี
 ปีการศึกษา : 2568

บทคัดย่อ

การถอดปริมาณงานระบบไฟฟ้าสำหรับโครงการก่อสร้างบ้านพักอาศัยมักเป็นการถอดปริมาณด้วยมือซึ่งมีความเสี่ยงต่อการเกิดข้อผิดพลาด จึงเกิดแนวคิดในการนำเทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะการใช้แบบจำลองที่มีพื้นฐานจากโครงข่ายประสาทคอนโวลูชัน (CNN) ที่สามารถตรวจจับและจำแนกวัตถุได้มาช่วยเพิ่มประสิทธิภาพในการถอดปริมาณงาน อย่างไรก็ตามแบบจำลองแต่ละแบบมีจุดเด่นและจุดด้อยแตกต่างกัน ดังนั้นงานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาเชิงเปรียบเทียบการประยุกต์ใช้แบบจำลองโครงข่ายประสาทคอนโวลูชัน 3 แบบ ได้แก่ Mask R-CNN, YOLOv9 และ U-Net ในการถอดปริมาณพื้นที่ห้องและอุปกรณ์ระบบไฟฟ้า ได้แก่ ดวงไฟ สวิตช์ และเต้ารับไฟฟ้า จากภาพแบบก่อสร้างงานบ้านพักอาศัย ผลการวิจัยพบว่าความสามารถในการตรวจจับและจำแนกอุปกรณ์ไฟฟ้าและพื้นที่ของแบบจำลองปัญญาประดิษฐ์ทั้งสามแบบเพิ่มขึ้นตามจำนวนรอบการฝึก ระดับความละเอียดของภาพ และจำนวนรูปภาพที่ใช้ในการฝึก โดยที่เมื่อใช้จำนวนรอบการฝึก 80 รอบ ความละเอียดของภาพขนาด 1700×1200 พิกเซล และจำนวนภาพฝึก 350 รูป พบว่าแบบจำลอง YOLOv9 มีความสามารถในการตรวจจับอุปกรณ์ดวงไฟ สวิตช์ และเต้ารับไฟฟ้าได้อย่างแม่นยำที่สุด และมีความแม่นยำเกิน 90% ซึ่งใกล้เคียงกับการถอดปริมาณด้วยมือ ในขณะที่แบบจำลอง U-Net มีความสามารถในการจำแนกพื้นที่ห้องได้ดีที่สุด มีความแม่นยำประมาณ 84% ซึ่งแม้จะต่ำกว่าการถอดปริมาณด้วยมือเล็กน้อย แต่ใช้เวลาในการทำงานน้อยกว่าในทุกประเภทของงาน

(มีจำนวนทั้งสิ้น 124 หน้า)

คำสำคัญ : ปัญญาประดิษฐ์ การถอดปริมาณงาน โครงข่ายประสาทเทียม ระบบไฟฟ้า

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

Name : Mr. Metas Chinhiran
Thesis Title : Application of Artificial Intelligence in Quantity Takeoff
and Work Area Estimation for Electrical Systems in
House Construction Plans
Major Field : Civil Engineering
King Mongkut's University of Technology North Bangkok
Thesis Advisor : Assistant Professor Doctor Kevin Tantisevi
Academic Year : 2025

ABSTRACT

Quantity takeoff for electrical systems in residential construction projects is often performed manually which can be error-prone. One of the potential approaches to enhancing the efficiency and accuracy of the quantity takeoff process includes applying artificial intelligence (AI), particularly convolutional neural network (CNN)-based models which are capable of detecting and classifying objects from images. However, each model has its own strengths and limitations. Hence, this research aims to comparatively study the application of three convolutional neural network models Mask R-CNN, YOLOv9, and U-Net for extracting room areas and electrical equipment, including lighting fixtures, switches, and power outlets, from residential construction drawings. The results reveal that the detection and classification performance of all three AI models improves when increasing the number of training epochs, higher image resolutions, and larger training datasets. Specifically, when trained for 80 epochs with an image resolution of 1700×1200 pixels and 350 training images, YOLOv9 model achieved the highest accuracy in detecting electrical equipment, exceeding 90% which is comparable to manual quantity takeoff. Meanwhile, U-Net model has the best performance in room area segmentation, with an accuracy of approximately 84%, which was slightly lower than manual quantity takeoff but required less processing time in all task categories.

(Total 124 Pages)

Keywords: Artificial Intelligence, Quantity Takeoff, Neural Network, Electrical Systems

Advisor

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความรู้ความกรุณาและการสนับสนุนจากหลายฝ่าย

ขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.กวิน ตันติเสวี อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้ซึ่งเมตตาให้ความรู้ ชี้แนะแนวทาง ให้คำแนะนำอันมีค่า ตลอดจนข้อคิดเห็นที่เป็นประโยชน์ต่อการดำเนินงานวิจัย รวมถึงการตรวจแก้ไขข้อบกพร่องต่าง ๆ จนวิทยานิพนธ์ฉบับนี้สำเร็จสมบูรณ์

ผู้วิจัยขอแสดงความซาบซึ้งในความกรุณาของ ศาสตราจารย์ ดร.วรรณวิทย์ แด้มทอง รวมทั้งคณาจารย์และเจ้าหน้าที่สาขาวิศวกรรมโยธา ภาควิชาวิศวกรรมโยธา มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ที่ให้ความช่วยเหลือและเอื้อเฟื้อมาตลอดระยะเวลาการทำวิทยานิพนธ์

ท้ายที่สุดนี้ ผู้วิจัยขอขอบคุณเพื่อนร่วมสาขาบริหารงานก่อสร้าง และครอบครัวที่คอยให้กำลังใจ และการสนับสนุนอย่างต่อเนื่อง และต้องขออภัยสำหรับผู้ที่ไม่ได้กล่าวรายนามมา ณ ที่นี้ โดยประโยชน์อันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้เป็นผลมาจากความกรุณาของบุคคลดังกล่าวข้างต้น ผู้วิจัยจึงใคร่ขอขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

เมธัส ชินศิริญ

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญรูปภาพ.....	ฌ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย	2
1.3 ขอบเขตการศึกษา.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	2
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	3
2.1 การประมาณราคาก่อสร้าง.....	3
2.2 งานระบบในอาคาร	5
2.3 แบบก่อสร้าง	7
2.4 ปัญญาประดิษฐ์ (Artificial Intelligence).....	12
2.5 งานวิจัยที่เกี่ยวข้อง	23
2.6 สรุปผลการทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	27
บทที่ 3 ระเบียบการวิจัย	30
3.1 กำหนดประเภทของวัตถุและตัวแปรที่ใช้ในการฝึกฝนแบบจำลอง	30

สารบัญ (ต่อ)

	หน้า
3.2 รวบรวมรูปภาพแบบก่อสร้าง	36
3.3 เตรียมข้อมูลสำหรับฝึกแบบจำลอง	36
3.4 ฝึกฝนแบบจำลองปัญญาประดิษฐ์	39
3.5 ทดสอบและประเมินผลแบบจำลอง	39
3.6 เปรียบเทียบผลการถอดปริมาณด้วยแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ	46
บทที่ 4 ผลการวิจัย	52
4.1 ปัจจัยที่ส่งผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์	52
4.2 ผลการเปรียบเทียบการถอดปริมาณด้วยแบบจำลองกับการถอดปริมาณด้วยมือ	68
บทที่ 5 สรุปผลและข้อเสนอแนะ	77
5.1 สรุปผลการศึกษา	77
5.2 ข้อเสนอแนะ	80
บรรณานุกรม	82
ภาคผนวก ก	86
ภาคผนวก ข	99
ประวัติผู้เขียน	124

สารบัญตาราง

ตารางที่	หน้า
2-1 ตัวอย่างสัญลักษณ์มาตรฐานประเทศสหรัฐอเมริกา (ANSI)	11
2-2 สรุปงานวิจัยที่นำปัญญาประดิษฐ์มาประยุกต์ใช้ในงานก่อสร้าง	28
3-1 สัญลักษณ์ดวงไฟ	33
3-2 สัญลักษณ์สวิตช์ไฟ	33
3-3 สัญลักษณ์เต้ารับไฟฟ้า	34
3-4 จำนวนรูปภาพที่ใช้ฝึกฝนและทดสอบแบบจำลองจากขนาดของรูปภาพและจำนวนรอบการฝึกที่ต่างกัน	35
3-5 จำนวนรูปภาพที่ใช้ฝึกฝนและทดสอบความแม่นยำของแบบจำลองที่ต่างกัน	36
3-6 ประเภทและชื่อของวัตถุ	38
3-7 การเก็บค่า TP,TN,FP,FN จากการขนาดของรูปภาพกับจำนวนรอบการฝึกที่แตกต่างกัน	40
3-8 การเก็บค่าความแม่นยำจากรูปที่ใช้ทดสอบจากการฝึกด้วยจำนวนรูปที่แตกต่างกัน	41
3-9 เปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์กับขนาดของรูปภาพและจำนวนรอบที่ใช้ในการฝึก	43
3-10 เปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์กับจำนวนรูปที่ใช้ในการฝึก	44
3-11 เปรียบเทียบระยะเวลาในการนับวัตถุและแบ่งพื้นที่กับแบบจำลองปัญญาประดิษฐ์	49
4-1 ผลจากการตรวจจับดวงไฟทั้ง 3 แบบจำลอง จากการฝึกด้วยขนาดของรูปภาพและจำนวนรอบในการฝึกที่แตกต่างกัน	55
4-2 ผลความแม่นยำเฉลี่ยจากการตรวจจับดวงไฟทั้งแบบจำลอง จากการฝึกด้วยขนาดของรูปภาพและจำนวนรอบในการฝึกที่แตกต่างกัน	56
4-3 เปรียบเทียบความแม่นยำเมื่อแปลงเป็นหน่วยตารางเมตรกับค่า IOU	66
4-4 ข้อมูลประสิทธิภาพการทำงานของผู้ทดสอบ	68
4-5 ผลระยะเวลาของแบบจำลองปัญญาประดิษฐ์กับระยะเวลาในการถอดปริมาณด้วยมือ	73
4-6 ผลการถอดปริมาณได้อย่างต่อเนื่องตามประสิทธิภาพการทำงาน	74

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4-7 ความคิดเห็นที่มีต่อการนำแบบจำลองมาใช้ตรวจจับวัตถุและแบ่งพื้นที่ในแบบก่อสร้าง	76
5-1 เปรียบเทียบความแม่นยำและลักษณะของแบบจำลองที่ฝึกด้วยภาพขนาด 1700x1200 พิกเซล จำนวน 350 รูป และจำนวนรอบในการฝึก 80 รอบ	78
5-2 แบบจำลองที่ดีที่สุดสำหรับการตรวจจับวัตถุและแบ่งพื้นที่ จากการฝึกด้วยรูปภาพขนาด 1700x1200 พิกเซล จำนวน 350 รูป และจำนวนรอบการฝึก 80 รอบ	79
ข-1 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป	100
ข-2 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป	101
ข-3 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป	102
ข-4 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป	103
ข-5 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป	104
ข-6 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป	105
ข-7 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป	106
ข-8 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป	107
ข-9 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป	108
ข-10 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป	109
ข-11 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป	110
ข-12 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป	111
ข-13 ค่า TP,TN,FP,FN ในการตรวจจับเต้ารับจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป	112
ข-14 ค่า TP,TN,FP,FN ในการตรวจจับเต้ารับจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป	113
ข-15 ค่า TP,TN,FP,FN ในการตรวจจับเต้ารับจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป	114
ข-16 ค่า TP,TN,FP,FN ในการตรวจจับเต้ารับจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป	115
ข-17 ค่า TP,TN,FP,FN ในการตรวจจับเต้ารับจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป	116

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
ข-18 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป	117
ข-19 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป	118
ข-20 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป	119
ข-21 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป	120
ข-22 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป	121
ข-23 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป	122
ข-24 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป	123



สารบัญภาพ

ภาพที่	หน้า
2-1 สวิตช์ไฟ	6
2-2 เตารับไฟฟ้า	7
2-3 ตัวอย่างแบบสถาปัตยกรรม	8
2-4 ตัวอย่างแบบโครงสร้าง	8
2-5 ตัวอย่างแบบไฟฟ้า	9
2-6 ตัวอย่างแบบสุขาภิบาล	9
2-7 แบบไฟฟ้าแสงสว่างและแบบเตารับไฟฟ้า	11
2-8 ขั้นตอนการเรียนรู้ของเครื่อง (Machine Learning)	13
2-9 ขั้นตอนการสร้าง Region of Interest (ROI) (Raghavendra และ Busch, 2014)	13
2-10 เซลล์ประสาทของมนุษย์ (คนบดี, 2565)	15
2-11 โครงข่ายประสาทเทียม	15
2-12 การเรียนรู้แบบมีผู้สอน (Supervised Learning)	16
2-13 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)	16
2-14 โครงข่ายประสาทคอนโวลูชัน (CNN)	16
2-15 หลักการ RoiAlign และการแบ่งพื้นที่ของวัตถุด้วย Mask R-CNN (He และคณะ, 2017)	17
2-16 ตัวอย่างการแบ่งพื้นที่ห้องจากรูปภาพ	21
2-17 Confusion Matrix (ณิศวรา, กอปร และวุฒิพงษ์, 2566)	22
3-1 ขั้นตอนการดำเนินงานวิจัย	31
3-2 ตัวอย่างแบบสถาปัตยกรรม	32
3-3 ตัวอย่างแบบไฟฟ้าแสงสว่าง	32
3-4 ตัวอย่างแบบไฟฟ้ากำลัง	34

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3-5 ขั้นตอนการเตรียมไฟล์ข้อมูลเพื่อใช้ฝึกฝนแบบจำลองด้วยโปรแกรม CVAT	37
3-6 การแบ่งประเภทของวัตถุด้วยเครื่องมือ Rectangle และ Polygon ใน CVAT	38
3-7 การบันทึกและส่งออกไฟล์ด้วยรูปแบบที่แบบจำลองรองรับ	38
3-8 ตัวอย่างการหาค่าสำหรับการประเมินความแม่นยำ	40
3-9 การหาค่า IOU	45
3-10 ขั้นตอนการแปลงจากหน่วยพิกเซลให้เป็นหน่วยตารางเมตร	45
3-11 ตัวอย่างแบบดวงไฟและสวิตช์ไฟในแบบทดสอบ	47
3-12 ตัวอย่างแบบเต้ารับไฟฟ้าในแบบทดสอบ	47
3-13 ตัวอย่างแบบที่ใช้หาพื้นที่ในแบบทดสอบ	48
3-14 ตัวอย่างหน้าคำถามข้อมูลทั่วไปในแบบทดสอบจาก Psyt toolkit	50
3-15 ตัวอย่างหน้าคำถามการถอดปริมาณงานจาก Psyt toolkit	51
4-1 การตั้งค่าพารามิเตอร์สำหรับการฝึกแบบจำลอง	52
4-2 ผลลัพธ์จากแบบจำลอง Mask R-CNN	53
4-3 ผลลัพธ์จากแบบจำลอง YOLOv9	53
4-4 ผลลัพธ์จากแบบจำลอง U-Net	54
4-5 ตัวอย่างการหาค่าสำหรับการประเมินความแม่นยำ	54
4-6 แผนภาพเปรียบเทียบความแม่นยำและระยะเวลาที่ใช้ในการฝึกฝนของทั้ง 3 แบบจำลองจากการฝึกด้วยรูปภาพขนาด 1700x1200 พิกเซล	57
4-7 ตัวอย่างผลลัพธ์จากการตรวจจับดวงไฟ	58
4-8 ตัวอย่างผลลัพธ์จากการตรวจจับสวิตช์ไฟ	59
4-9 ตัวอย่างผลลัพธ์จากการตรวจจับเต้ารับไฟฟ้า	59

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4-10 แผนภาพแสดงค่าชี้วัดของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200 และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับดวงไฟ	60
4-11 แผนภาพแสดงค่าชี้วัดของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200 และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับสวิตช์ไฟ	61
4-12 แผนภาพแสดงค่าชี้วัดของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200 และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับเต้ารับไฟฟ้า	62
4-13 ตัวอย่างผลลัพธ์จากการแบ่งพื้นที่ห้อง	63
4-14 ตัวอย่างพื้นที่จริงสำหรับการหาค่า IOU	64
4-15 แผนภาพแสดงค่า IOU จากการแบ่งพื้นที่ห้อง	64
4-16 ผลการแบ่งพื้นที่จากแบบจำลอง	65
4-17 ผลการตรวจหาตัวเลขและค้นหาเส้นจากแบบ	65
4-18 การกรอกระยะจริงของเส้นที่ตรวจจับได้และการแปลงหน่วยเป็นตารางเมตร	66
4-19 วัตถุที่วางติดกันและวัตถุที่ซ้อนทับเฟอร์นิเจอร์	67
4-20 แบบจำลองตรวจจับวัตถุอื่นที่ไม่ใช่สัญลักษณ์ที่ต้องการตรวจจับ	67
4-21 การตรวจจับเส้นบอกระยะที่ไม่สมบูรณ์	68
4-22 แผนภาพความแม่นยำในการนับจำนวนวัตถุและแบ่งพื้นที่ของผู้ตอบแบบสอบถาม	69
4-23 แผนภาพเปรียบเทียบความแม่นยำของแบบจำลองกับการถอดปริมาณด้วยมือ	70
4-24 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับดวงไฟจากแบบทดสอบ	71
4-25 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับสวิตช์ไฟจากแบบทดสอบ	72
4-26 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับเต้ารับจากแบบทดสอบ	72
4-27 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการแบ่งพื้นที่จากแบบทดสอบ	72
4-28 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการถอดปริมาณอย่างต่อเนื่องตามประสบการณ์	74

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ในปัจจุบันการถอดปริมาณงานเพื่อประมาณราคาก่อสร้างอย่างละเอียดสามารถทำได้หลายวิธี ถ้าเป็นโครงการก่อสร้างขนาดใหญ่ที่มีการใช้งานแบบจำลองสารสนเทศอาคาร (BIM) จะสามารถถอดปริมาณจากแบบจำลองได้โดยอัตโนมัติ มีความสะดวกรวดเร็วแต่ถ้าเป็นงานก่อสร้างที่ดำเนินโดยผู้รับเหมาขนาดเล็ก เช่น งานก่อสร้างบ้านและอาคารพาณิชย์ มักนิยมใช้การถอดปริมาณด้วยมือทำให้มีโอกาสเกิดความคลาดเคลื่อน หากผู้รับเหมาที่มีผู้ปฏิบัติงานที่จำกัด ย่อมส่งผลให้การถอดปริมาณล่าช้าและสูญเสียความสามารถในการแข่งขันในปัจจุบัน (วรรณวรงค์ และสยาม, 2563)

หนึ่งในแนวทางที่ช่วยเพิ่มประสิทธิภาพในการถอดปริมาณงานคือ การนำปัญญาประดิษฐ์ซึ่งเป็นเทคโนโลยีที่มีความสามารถเลียนแบบความสามารถของมนุษย์ ได้แก่ การจดจำรูปภาพ แยกแยะให้เหตุผลตัดสินใจ การสื่อสารและเรียนรู้ได้ด้วยตนเอง (พรทิพย์, 2566) มาใช้ในการตรวจนับและจำแนกวัตถุจากรูปภาพ โดยในปัจจุบันเทคโนโลยีปัญญาประดิษฐ์ได้ถูกนำมาใช้ในงานก่อสร้างหลายด้าน เช่น การประยุกต์ใช้ในการตรวจสอบรอยร้าว ตรวจนับจำนวนคนงานและความเสี่ยงด้านความปลอดภัย ช่วยออกแบบอาคารหรือผังเมือง ถอดปริมาณวัสดุจากแบบก่อสร้าง (วรพันธ์ และคณะ, 2567) ดังนั้นการนำเทคโนโลยีปัญญาประดิษฐ์มาปรับใช้กับงานถอดปริมาณงาน จึงช่วยให้กระบวนการถอดปริมาณวัสดุและการคำนวณต้นทุนสามารถทำได้อย่างรวดเร็ว

เทคโนโลยีปัญญาประดิษฐ์ที่นิยมใช้เพื่อตรวจนับและแยกแยะวัตถุในรูปภาพคือ โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network, CNN) ซึ่งเป็นพื้นฐานสำคัญในการพัฒนาแบบจำลองต่างๆ เช่น Mask R-CNN, YOLO และ U-Net (ชูพันธุ์, 2559) โดยแบบจำลองเหล่านี้ได้รับความนิยมในการใช้งานตรวจนับวัตถุในภาพอย่างมีประสิทธิภาพและมีการประยุกต์ใช้งานจริงในภาคอุตสาหกรรมก่อสร้าง ดังนั้นงานวิจัยนี้จึงมีเป้าหมายเพื่อประเมินผลการนำแบบจำลองโครงข่ายประสาทคอนโวลูชัน มาใช้ในการถอดปริมาณอุปกรณ์ระบบไฟฟ้าและพื้นที่จากแบบก่อสร้างบ้านพักอาศัย โดยได้ศึกษาปัจจัยที่ส่งผลต่อความแม่นยำของการตรวจนับพื้นที่และวัตถุด้วยแบบจำลอง พร้อมกับเปรียบเทียบผลความแม่นยำกับการถอดปริมาณด้วยมือ

1.2 วัตถุประสงค์ของการวิจัย

1.2.1 ศึกษาปัจจัยที่มีผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์ในการตรวจจับวัตถุในงานระบบไฟฟ้าและพื้นที่อาคารในแบบก่อสร้าง

1.2.2 เปรียบเทียบผลความแม่นยำของแบบจำลองปัญญาประดิษฐ์ในการตรวจจับวัตถุในงานระบบไฟฟ้าและพื้นที่อาคารในแบบก่อสร้างกับความแม่นยำจากการถอดปริมาณด้วยมือ

1.3 ขอบเขตการศึกษา

1.3.1 การศึกษาครั้งนี้จะนำแบบจำลองปัญญาประดิษฐ์มาประยุกต์ใช้เพื่อถอดปริมาณงานไฟฟ้าจากแบบก่อสร้างของบ้านพักอาศัย

1.3.2 เปรียบเทียบการใช้แบบจำลองปัญญาประดิษฐ์ที่เกี่ยวกับคอมพิวเตอร์วิทัศน์ทั้งหมด 3 แบบ ได้แก่ Mask R-CNN, YOLOv9 และ U-Net

1.3.3 เปรียบเทียบความแม่นยำในการตรวจจับ พื้นที่ห้อง และระบบไฟฟ้า ที่ประกอบด้วย ดวงไฟ สวิตช์ เต้ารับไฟฟ้า จากแบบก่อสร้างของทั้ง 3 แบบจำลอง

1.3.4 ศึกษาปัจจัยที่ส่งผลต่อความแม่นยำของแบบจำลอง โดยพิจารณาจากจำนวนรอบการฝึก (Epochs) ขนาดของรูปภาพ (Image Size) และจำนวนรูปภาพที่ใช้ในการฝึก (Image Samples)

1.3.5 เปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์ กับการถอดปริมาณด้วยมือ

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 ทำให้ทราบถึงปัจจัยที่มีผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์ ในการตรวจจับวัตถุในงานระบบไฟฟ้าและพื้นที่อาคารในแบบก่อสร้าง

1.4.2 สามารถเลือกแบบจำลองปัญญาประดิษฐ์สำหรับการตรวจจับและแบ่งประเภทของวัตถุในงานระบบไฟฟ้า โดยอ้างอิงจากความแม่นยำที่ได้จากการเปรียบเทียบแบบจำลองต่างๆ

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

งานวิจัยฉบับนี้ ผู้วิจัยได้นำแบบจำลองปัญญาประดิษฐ์ (Artificial Intelligence) มาประยุกต์ใช้ในบริบทของที่อยู่อาศัย โดยอ้างอิงข้อมูลจากหนังสือ บทความ วิทยานิพนธ์ และงานวิจัยที่เกี่ยวข้อง เพื่อใช้เป็นแนวทางในการรวบรวมข้อมูล วิเคราะห์ และสรุปผล โดยแบ่งเนื้อหาในการศึกษา ดังต่อไปนี้

2.1 การประมาณราคาก่อสร้าง

กรมโยธาธิการและผังเมือง (2555) ได้นิยามการประมาณราคาก่อสร้างว่าเป็นกระบวนการหรือวิธีการเพื่อให้ได้มาซึ่งราคาก่อสร้างที่ใกล้เคียงกับความเป็นจริงมากที่สุด ดังนั้นราคาก่อสร้างที่ได้จากการประมาณราคานั้นจึงไม่ใช่ราคาที่แท้จริงหรือถูกต้องสมบูรณ์ แต่เป็นเพียงราคาโดยประมาณที่ใกล้เคียงกับราคาก่อสร้างจริงเท่านั้น เนื่องจากปัจจัยหลายประการที่เข้ามาเกี่ยวข้อง

การประมาณราคาก่อสร้างสามารถทำได้หลายวิธี ตั้งแต่วิธีการประมาณราคาอย่างง่ายโดยอาศัยประสบการณ์และความชำนาญ ไปจนถึงการประมาณราคาอย่างละเอียด ซึ่งแต่ละวิธีมีข้อจำกัดและระยะเวลาที่แตกต่างกันออกไป โดยผลที่ได้จะเป็นเพียงค่าก่อสร้างที่มีความใกล้เคียงกับความเป็นจริงเท่านั้น (วิเชียร, 2545)

ในการประมาณราคาก่อสร้างอาคารและบ้านพักอาศัย โดยทั่วไปแบ่งเป็น 2 ประเภท ได้แก่

2.1.1 การประมาณราคาเบื้องต้น

การประมาณราคาเบื้องต้นเป็นการประมาณราคาในช่วงที่เริ่มโครงการ ซึ่งมีความแม่นยำอยู่ในช่วง -15% ถึง 20% เพื่อดังบประมาณเบื้องต้นในการวางแผนก่อสร้าง และศึกษาความเป็นไปได้ของโครงการ การประมาณราคาแบบนี้จึงขึ้นอยู่กับประสบการณ์ของผู้ประมาณราคาและข้อมูลของโครงการก่อนหน้าเป็นหลัก โดยการประมาณราคาเบื้องต้นสามารถดำเนินการ 3 วิธีได้แก่ (กวี, 2556 อ้างถึงใน กรรวิ และกวิน, 2561)

2.1.1.1 การประมาณราคาตามข้อมูลเดิม

การประมาณราคานี้จะใช้ข้อมูลเดิมของโครงการก่อสร้างก่อนหน้าที่มีลักษณะใกล้เคียงกัน มาปรับปรุงราคาให้เป็นปัจจุบัน และเปรียบเทียบกับวัสดุกับอาคารที่กำลังจะก่อสร้าง โดยวิธีนี้จะมีราคาคลาดเคลื่อน 20% ถึง 30%

2.1.1.2 การประมาณราคาด้วยตัวแปร (Parameter Estimate)

การประมาณราคานี้เป็นวิธีการประเมินโดยใช้ตัวแปรหรือพารามิเตอร์จากโครงการก่อนหน้า ที่เกี่ยวข้องกับลักษณะของโครงการ เช่น พื้นที่ก่อสร้าง ปริมาณวัสดุ และองค์ประกอบสำคัญของอาคาร โดยวิธีการคำนวณจะใช้ตัวแปรคูณกับต้นทุนต่อหน่วยของแต่ละตัวแปร เพื่อให้ได้ค่าประมาณต้นทุนรวมของโครงการ

2.1.1.3 การประมาณราคาด้วยแฟกเตอร์ (Factor Estimate)

การประมาณราคานี้เป็นวิธีการประเมินต้นทุนโครงการก่อสร้างโดยใช้ค่าแฟกเตอร์ (Factor) โดยคำนวณได้จากอัตราส่วนจากข้อมูลโครงการก่อนหน้า ที่แบ่งออกเป็นส่วนๆ เช่น งานโครงสร้าง 50% งานตกแต่งภายใน 25% งานระบบ 25% เป็นต้น ซึ่งเหมาะสำหรับการกำหนดงบประมาณสำหรับโครงการก่อสร้างที่สร้างคล้ายกัน

2.1.2 การประมาณราคาแบบละเอียด

การประมาณราคาแบบละเอียดจะถอดปริมาณตามแบบก่อสร้าง รวมถึงงานอื่นๆ ที่เกี่ยวข้อง เช่น งานสำรวจสถานที่ก่อสร้าง ปัญหาอุปสรรคที่ต้องแก้ไข งานตามสัญญา และปริมาณงานเพิ่มที่อาจจะมีในอนาคต โดยหลังจากที่ถอดปริมาณวัสดุตามแบบก่อสร้างจะจำแนกตามหมวดงานก่อสร้างเพื่อจัดให้เป็นระเบียบ อำนวยความสะดวกในการประมาณราคา และลดความผิดพลาดในการนับจำนวนวัสดุ (วิเชียร, 2545)

การประมาณราคาแบบละเอียดเพื่อจัดทำราคากลางหรือจัดทำงบประมาณที่ต้องเตรียมในการจัดหาผู้ทำการก่อสร้าง สามารถดำเนินการได้ 2 ทาง ดังนี้ (สันติภูมิ, 2565)

1) การประมาณราคาจากการถอดปริมาณวัสดุจากแบบก่อสร้างเพื่อกำหนดรายการก่อสร้าง และคำนวณปริมาณงาน วัสดุ และแรงงาน ออกมาเป็นหน่วยสำหรับแต่ละหมวดงาน แล้วคูณด้วยราคาวัสดุต่อหน่วย ค่าวัสดุรวมต่อหน่วย หรือค่าแรงงานต่อหน่วย จะได้เป็นยอดรวมค่าวัสดุและค่าแรงงานทั้งหมด แล้วนำไปคำนวณรวมกับค่าอำนวยการ ค่าดอกเบี้ย ค่ากำไร และค่าภาษี รวมทั้งค่าใช้จ่ายอื่นๆ ที่เกี่ยวข้องซึ่งวิธีนี้เป็นที่นิยมในประเทศไทย

2) การประมาณราคาจากปริมาณวัสดุก่อสร้างทั้งหมด ซึ่งจะคล้ายกับวิธีแรก โดยเริ่มจากการถอดปริมาณจากแบบก่อสร้างเพื่อกำหนดรายการก่อสร้าง และคำนวณปริมาณวัสดุก่อสร้างออกมาตามหมวดงาน แล้วคูณด้วยราคาต่อหน่วยของวัสดุแต่ละชนิด จากนั้นกำหนดค่าแรงงานเป็นเพิ่มจากค่าวัสดุทั้งหมด โดยจะกำหนดเป็นร้อยละ (%) ของค่าวัสดุ แล้วนำไปคำนวณรวมกับค่า

อำนวยการ ค่าดอกเบี้ย ค่ากำไร และค่าภาษี รวมทั้งค่าใช้จ่ายอื่นๆ ที่เกี่ยวข้อง จะได้เป็นราคาค่าก่อสร้างทั้งหมดแบบละเอียด

ในการประมาณราคาแบบละเอียด ขั้นตอนที่สำคัญขั้นตอนหนึ่งคือการถอดปริมาณวัสดุ ซึ่งเป็นการนับจำนวน วัดขนาด และคำนวณปริมาณวัสดุที่ต้องใช้จากแบบและนำเสนอออกมาในรูปแบบของหน่วยต่างๆ เช่น ความกว้างของพื้นที่ น้ำหนัก และปริมาณ ซึ่งสามารถนำไปใช้ในการคำนวณต้นทุนตามหมวดงานย่อยต่างๆ เช่น ปริมาณงานฐานราก ปริมาณงานระบบไฟฟ้า ปริมาณงานผนัง เป็นต้น (วิเชียร, 2545)

การถอดปริมาณงานก่อสร้างที่ดี ผู้ประมาณราคาควรมีแบบฟอร์มเพื่อใช้ในการตรวจสอบ และลดความผิดพลาดจากการคำนวณที่ไม่ครบถ้วน ซึ่งความผิดพลาดที่มักเกิดขึ้นจากการคำนวณปริมาณงาน ได้แก่ ความผิดพลาดจากการคำนวณปริมาณงาน ความผิดพลาดจากการคัดลอกแบบก่อสร้างไปยังแบบก่อสร้างอีกชุดหนึ่ง มาตรฐานที่ใช้ในการวัดปริมาณจากแบบไม่ตรงกับมาตรฐานในแบบก่อสร้าง และการขาดความรอบคอบในการคำนวณปริมาณงาน ดังนั้นการลดข้อผิดพลาดในขั้นตอนประมาณราคา ผู้ประมาณราคาควรมีความรู้และทักษะในด้านต่างๆ เช่น ความเข้าใจในการอ่านแบบ การเลือกใช้ราคาให้เหมาะสมกับวิธีการก่อสร้าง ความเข้าใจในเรื่องของรายละเอียดในการก่อสร้าง และการประมาณงาน เป็นต้น (เมธาสิทธิ์, 2565)

2.2 งานระบบในอาคาร

งานระบบในบ้านหรืออาคารเป็นส่วนสำคัญของการออกแบบและก่อสร้างบ้านที่ช่วยให้บ้านสามารถใช้งานได้สะดวกสบาย ปลอดภัย และมีประสิทธิภาพ โดยการออกแบบงานระบบในอาคารหรือในบ้านพักอาศัยจะประกอบด้วย ระบบเครื่องกล ระบบไฟฟ้า ระบบประปาและสุขาภิบาล ที่ตอบสนองตามความต้องการในชีวิตประจำวันของผู้อยู่อาศัย เช่น เครื่องปรับอากาศ ไฟฟ้าและแสงสว่าง ระบบท่อน้ำ เป็นต้น (สง, 2555)

2.2.1 ระบบไฟฟ้าภายในบ้าน

ระบบไฟฟ้าในบ้านเป็นองค์ประกอบที่สำคัญในการใช้ชีวิตประจำวัน โดยมีหน้าที่ในการจ่ายกระแสไฟฟ้าจากแหล่งจ่ายไปยังอุปกรณ์ไฟฟ้าภายในบ้าน โดยแบ่งออกเป็น 2 ระบบหลักได้แก่ ระบบไฟฟ้า 1 เฟส และระบบไฟฟ้า 3 เฟส

วงจรไฟฟ้าในบ้านคือเส้นทางที่กระแสไฟฟ้าไหลผ่านได้ครบรอบวงจรไฟฟ้าในบ้านโดยกระแสไฟฟ้าจะไหลผ่านสายไฟ สะพานไฟ ฟิวส์สวิตช์ และเครื่องใช้ไฟฟ้าตามลำดับแล้วไหลกลับทาง

สายกลาง (สาย N) โดยแบ่งออกเป็น 2 วงจรได้แก่ วงจรปิด คือวงจรที่มีกระแสไฟฟ้าไหลผ่านได้ครบวงจร และวงจรเปิด คือวงจรที่มีส่วนหนึ่งขาดทำให้กระแสไฟฟ้าไหลผ่านไม่ได้

ฟิวส์ เป็นอุปกรณ์ไฟฟ้าที่ทำหน้าที่ตัดวงจรไฟฟ้าเพื่อป้องกันไม่ให้กระแสไฟฟ้าไหลผ่านมากเกินไป และเมื่อมีกระแสไฟฟ้าไหลผ่านเกินกำหนดจะส่งผลให้เกิดความร้อนทำให้ฟิวส์ขาด ฟิวส์จึงช่วยป้องกันอันตรายจากไฟฟ้าลัดวงจรได้ โดยฟิวส์มีหลายชนิด แต่ละชนิดจะใช้แตกต่างกันเช่น ฟิวส์แบบเส้นลวด ฟิวส์แบบขดกระเบื้อง ฟิวส์บรรจุในหลอดแก้ว ฟิวส์อัตโนมัติ เป็นต้น

สะพานไฟหรือคัทเอาต์ เป็นอุปกรณ์ที่ใช้เปิดและปิดวงจรไฟฟ้าในบ้านหรืออาคาร ซึ่งเหมือนกับสวิตช์ขนาดใหญ่ของบ้าน ใช้สำหรับควบคุมวงจรไฟฟ้าในบ้าน

สวิตช์ ทำหน้าที่ควบคุมกระแสไฟฟ้าที่จะผ่านเข้าไปในเครื่องใช้ไฟฟ้าต่างๆ ภายในบ้านดังภาพที่ 2-1 เพื่อเปิดและปิดได้ตามต้องการ เช่น สวิตช์ไฟ สวิตช์กดกริ่ง และสวิตช์พัดลม เป็นต้น โดยบนสวิตช์จะมีตัวเลขกำกับ เช่น 15 A 300 V AC หมายถึง กระแสไฟฟ้าสูงสุดไม่เกิน 15 แอมแปร์ ความต่างศักย์ไม่เกิน 300 โวลต์ และการต่อสวิตช์ต้องต่ออนุกรมกับเครื่องใช้ไฟฟ้า



ภาพที่ 2-1 สวิตช์ไฟ

เต้ารับไฟฟ้ามีหน้าที่ทำให้กระแสไฟฟ้าไหลเข้าสู่เครื่องใช้ไฟฟ้าให้ครบวงจรดังภาพที่ 2-2 โดยเครื่องใช้ไฟฟ้าหลายชนิด เช่น พัดลม โทรทัศน์ นอกจากจะมีสวิตช์ประจำตัวอยู่ที่ตัวเครื่องแล้ว ยังมีสายไฟติดมากับเครื่องใช้ไฟฟ้า ซึ่งมีเต้าเสียบที่ต้องนำไปเสียบกับเต้ารับเพื่อให้กระแสไฟฟ้าไหลเข้าสู่เครื่องใช้ไฟฟ้าได้ครบวงจร โดยภายในบ้านควรติดตั้งเต้ารับไว้หลายจุดเพื่อความสะดวกในการใช้เครื่องใช้ไฟฟ้า และไม่ควรต่อเครื่องใช้ไฟฟ้าหลายเครื่องเข้ากับเต้ารับอันเดียวกัน เพราะจะทำให้เกิดความร้อนสูงในสายไฟจนเกิดเพลิงไหม้ได้



ภาพที่ 2-2 เตาไฟฟ้า

การเดินสายไฟฟ้าสามารถแบ่งออกเป็น 2 รูปแบบ ได้แก่ การเดินสายไฟบนผนังหรือเดินลอย ซึ่งเป็นการติดตั้งสายไฟให้สามารถมองเห็นได้จากภายนอก มักใช้ในงานที่ต้องการความสะดวกในการติดตั้งและซ่อมแซม และการเดินสายไฟแบบฝังในผนัง ซึ่งเป็นการเดินท่อร้อยสายไฟที่ต้องทำควบคู่ไปกับงานก่อและฉาบผนัง ทำให้สายไฟถูกซ่อนอยู่ภายใน ช่วยเพิ่มความสวยงามและความปลอดภัยให้กับสายไฟฟ้าภายในอาคารมากขึ้น (สงว, 2555)


2.3 แบบก่อสร้าง

แบบก่อสร้าง คือเอกสารที่ถูกนำมาใช้สำหรับการก่อสร้างให้ได้ตามที่เจ้าของงานกำหนด โดยแบบก่อสร้างจะถูกออกแบบโดยมีสถาปนิก นักออกแบบ และวิศวกร ตามความต้องการและความเหมาะสมของพื้นที่ก่อสร้าง ซึ่งจะกำหนดรายละเอียดของพื้นที่ใช้งานทั้งภายในและภายนอก รวมไปถึงเฟอร์นิเจอร์ที่ใช้ให้ตรงกับการใช้งานห้องต่างๆ ในอาคารหรือบ้านพักอาศัย เนื่องจากแบบก่อสร้างเป็นเอกสารที่ส่งผลโดยตรงกับรูปแบบบ้าน การวางแผนงาน และการประมาณราคาก่อสร้าง


ในการเขียนแบบก่อสร้างจะมีหลายขั้นตอน เริ่มจากการร่างแบบ จัดทำแบบรายละเอียดสถาปัตยกรรม และแบบสำหรับก่อสร้างในขั้นตอนสุดท้าย ในแต่ละขั้นตอนจะมีการตรวจสอบและแก้ไขปรับเปลี่ยนแบบเกิดขึ้นเพื่อให้สามารถก่อสร้างได้อย่างต่อเนื่อง โดยในแบบก่อสร้างหนึ่งโครงการจะประกอบไปด้วยข้อมูลมากมาย จึงต้องมีการแยกข้อมูลออกเป็นรูปแบบต่างๆ แล้วนำกลับมารวมกัน (ฐิติพัฒน์, 2554)

2.3.1 รูปแบบของแบบก่อสร้างบ้านพักอาศัย


ในแบบก่อสร้างจะกำหนดถึงคุณสมบัติที่จะนำมาใช้ในการสร้าง เช่น การกำหนดขนาดของกำลังรับแรงของคอนกรีตและเหล็ก การกำหนดชนิดของสายไฟสำหรับงานเกี่ยวกับระบบไฟฟ้า รวมไปถึงการกำหนดคุณสมบัติของท่อน้ำสำหรับงานระบบประปา คุณสมบัติของวัสดุก่อสร้างทั้งหมด โดยจะทำการกำหนดไว้ในรายการประกอบแบบ ในส่วนของรายละเอียดของแบบก่อสร้างที่แตกต่างกันออกไปจะมี 4 รูปแบบ ดังภาพที่ 2-3 ถึง 2-6




ภาพที่ 2-3 ตัวอย่างแบบสถาปัตยกรรม



ภาพที่ 2-4 ตัวอย่างแบบโครงสร้าง



ภาพที่ 2-5 ตัวอย่างแบบไฟฟ้า



ภาพที่ 2-6 ตัวอย่างแบบสุขาภิบาล

1) แบบสถาปัตยกรรม ประกอบด้วย รูปด้าน รูปตัด แบบขยายในส่วนต่างๆ ที่จะให้ทราบระยะในการก่อสร้างได้อย่างละเอียด รวมไปถึงรายละเอียดของวัสดุที่ใช้สำหรับงานของแต่ละส่วน เช่น วัสดุปูพื้น ผนัง วัสดุที่ใช้มุงหลังคา หน้าต่าง ประตู เป็นต้น

2) แบบโครงสร้าง เป็นแบบที่ส่วนที่มีความสำคัญ เพราะโครงการก่อสร้างจะมีความแข็งแรง และได้มาตรฐาน ขึ้นอยู่กับส่วนนี้โดยตรง เนื่องจากจะต้องผ่านการออกแบบจากวิศวกรโครงสร้าง โดยจะประกอบด้วยแบบฐานราก ขนาดเสา ขนาดคาน และขนาดเหล็กเสริมที่นำมาใช้งานอย่างละเอียด

3) แบบระบบไฟฟ้า จะเป็นแบบที่บอกรายละเอียดเกี่ยวกับระบบไฟฟ้าที่นำมาใช้งานภายในโครงการก่อสร้าง ซึ่งจะประกอบด้วย 2 แบบหลักคือ แบบไฟฟ้าแสงสว่าง (Lighting Layout) ที่ระบุชนิดของดวงไฟทั้งหมดที่นำมาใช้งานและตำแหน่งในการติดตั้ง แบบไฟฟ้ากำลังที่ระบุตำแหน่งเต้ารับ ตำแหน่งเครื่องปรับอากาศ และเครื่องทำน้ำอุ่น ที่จะติดตั้งภายในโครงการทั้งหมด

4) แบบสุขาภิบาล จะกำหนดตำแหน่งในการวางระบบน้ำดี น้ำเสียของบ้าน อย่างชัดเจน รวมไปถึงการวางระบบการระบายน้ำที่บำบัดแล้วออกจากตัวบ้านไปสู่สาธารณะ แต่ถ้าที่ดินที่ทำการก่อสร้าง ไม่มีทางระบายน้ำสาธารณะ จะมีการวางระบบบ่อซึมแทน โดยจะต้องมีการจัดระเบียบ และวางแผนการดำเนินงานในแต่ละจุดอย่างเหมาะสมตามสถานที่ก่อสร้าง


แบบก่อสร้างเป็นเอกสารที่จำเป็นสำหรับการสร้างบ้านให้ออกมาสมบูรณ์แบบมากที่สุด แบบก่อสร้างที่มีรายละเอียดที่สำคัญครบถ้วน เข้าใจได้ง่าย จะส่งผลโดยตรงต่อการนำไปก่อสร้างได้อย่างมีประสิทธิภาพ และช่วยลดปัญหาที่เกี่ยวกับงานก่อสร้างได้ (ฐิติพัฒน์, 2554)

2.3.2 แบบระบบไฟฟ้า


การเขียนแบบไฟฟ้าเป็นขั้นตอนสำคัญในการออกแบบและติดตั้งระบบไฟฟ้าในอาคารบ้านเรือน หรือโรงงานอุตสาหกรรม มีวัตถุประสงค์เพื่อแสดงรายละเอียดของระบบไฟฟ้า เช่น การเดินสายไฟ วงจรไฟฟ้า เต้ารับ สวิตช์ไฟ ดวงไฟและอุปกรณ์ป้องกันไฟฟ้า นอกจากนี้ยังช่วยให้วิศวกรช่างไฟ และผู้เกี่ยวข้องสามารถถอดปริมาณได้อย่างถูกต้อง

การเขียนแบบไฟฟ้าในอาคารจะประกอบด้วยวงจร 2 วงจร ได้แก่ วงจรแสงสว่าง และวงจรกำลัง ซึ่งจะต้องทำการเขียนสัญลักษณ์ก่อนแล้วจึงเขียนแบบเดินสายไฟฟ้า โดยสัญลักษณ์ที่นิยมใช้ในงานเขียนแบบมี 2 มาตรฐาน คือ มาตรฐานประเทศสหรัฐอเมริกา (ANSI) ดังตารางที่ 2-1 กับ มาตรฐานประเทศเยอรมัน (DIN) (สุรศักดิ์, 2562)

ตารางที่ 2-1 ตัวอย่างสัญลักษณ์มาตรฐานประเทศสหรัฐอเมริกา (ANSI)

สัญลักษณ์	รายละเอียด	สัญลักษณ์	รายละเอียด
	โคมไฟติดเสมอผิวผนัง		สวิตช์ทางเดียว
	โคมไฟติดเพดาน		สวิตช์สองทาง
	ไฟทางออก		สวิตช์สามทาง
	โคมไฟลูออเรสเซนต์เปลี่ยน		สวิตช์กั้นน้ำ
	โคมไฟลูออเรสเซนต์แขวน		สวิตช์เซอร์กิตเบรกเกอร์
	โคมไฟลูออเรสเซนต์ซ่อน		ตัวรับวิทยุ, โทรทัศน์
	ตัวรับคู่		ตัวรับโทรศัพท์
	สามตัวรับ		ตัวรับกั้นน้ำ

การเขียนแบบไฟฟ้าแสงสว่างและตัวรับควรแยกออกจากกันเพื่อความปลอดภัยและความสะดวกในการก่อสร้าง เนื่องจากวงจรแสงสว่างใช้สวิตช์ในการเปิด-ปิดไฟแบบโซน ขณะที่ตัวรับใช้เซอร์กิตเบรกเกอร์เป็นตัวควบคุมกระแสแทนสวิตช์ ทำให้ทั้ง 2 วงจรต้องมีวิธีการเขียนแบบที่แตกต่างกัน แต่ในบางกรณีวงจรแสงสว่างอาจรวมกับวงจรตัวรับได้ ถ้าหากตำแหน่งของสวิตช์ไฟและตัวรับไม่ซ้อนทับกัน ดังภาพที่ 2-7



ภาพที่ 2-7 แบบไฟฟ้าแสงสว่างและแบบตัวรับไฟฟ้า

2.4 ปัญญาประดิษฐ์ (Artificial Intelligence)

ปัญญาประดิษฐ์เป็นสาขาหนึ่งของวิทยาการคอมพิวเตอร์ ที่มีวัตถุประสงค์ที่จะทำให้คอมพิวเตอร์ทำงานได้ใกล้เคียงกับมนุษย์มากขึ้น ซึ่งจะแบ่งย่อยเป็นสาขาต่างๆ เช่น การแปลภาษา ระบบการแนะนำข้อมูล และการสร้างรูปภาพ โดยเริ่มพัฒนาจากเครื่องคอมพิวเตอร์ที่ในช่วงเริ่มต้นจะมีหน้าที่คำนวณ และประมวลผลตามที่มนุษย์ต้องการ โดยมีมนุษย์เป็นผู้ควบคุม ป้อนคำสั่ง และรอผลลัพธ์จากเครื่องคอมพิวเตอร์ ทำให้เกิดแนวคิดที่จะพัฒนาให้เครื่องคอมพิวเตอร์ที่มีประสิทธิภาพสูงขึ้นเพียงพอที่จะอำนวยความสะดวกและลดกำลังการสนับสนุนจากมนุษย์ลง จึงต้องพัฒนาให้มีหลักการใช้เหตุผลเทียบเคียงกับสมองมนุษย์ โดยอาศัยหลักการจากการศึกษาวิธีคิด การตัดสินใจ หรือเหตุผลจากมนุษย์เพื่อนำไปใช้ในการพัฒนาศักยภาพของเครื่องคอมพิวเตอร์ให้สามารถตอบสนองการทำงานที่มากกว่าคอมพิวเตอร์หรือเป็นเพียงโปรแกรมทั่วไป ส่งผลให้เครื่องคอมพิวเตอร์มีความฉลาดมากขึ้นสามารถทำงานได้อย่างมีประสิทธิภาพโดยไม่ต้องอาศัยแรงงานจากมนุษย์ (คณบดี, 2565)

Russell และ Norvig (2003) ได้จำแนกปัญญาประดิษฐ์ออกเป็น 4 ลักษณะดังนี้

- 1) ระบบความคิดที่เลียนแบบมนุษย์หรือเครื่องจักรที่สามารถคิดเองได้ และแสดงการกระทำออกมาได้โดยอัตโนมัติ ซึ่งเป็นการคิดที่อาศัยรูปแบบแนวคิดของมนุษย์ส่งผลต่อการกระทำใน ด้านการตัดสินใจ การแก้ปัญหา และการเรียนรู้ที่คล้ายคลึงกับมนุษย์
- 2) ระบบการกระทำที่เหนือมนุษย์ อาศัยพื้นฐานการคิดที่เลียนแบบจากมนุษย์ ส่งผลให้การแสดงออกและการกระทำต่างๆ เติบโตด้วยรูปแบบการทำงานของมนุษย์ โดยมีประสิทธิภาพเทียบเท่าหรืออาจมากกว่าการกระทำของมนุษย์
- 3) ระบบความคิดอย่างมีเหตุผล เมื่อปัญญาประดิษฐ์ถูกสร้างขึ้นเพื่อคิดแทนมนุษย์ระบบสติปัญญาต่างๆ จึงต้องอาศัยแบบจำลองการคำนวณที่ช่วยให้ปัญญาประดิษฐ์สามารถเข้าใจหลักของเหตุและผล สามารถคำนวณเหตุการณ์ต่างๆ ตามความเป็นไปได้และคาดการณ์ไว้ล่วงหน้าได้
- 4) ระบบการกระทำอย่างมีเหตุผล หลังจากที่มีระบบความคิดอย่างมีเหตุผลของปัญญาประดิษฐ์ส่งผลให้การแสดงออกและการกระทำต่างๆ สอดคล้องกันอย่างสมเหตุสมผล ซึ่งกระบวนการคำนวณที่มีประสิทธิภาพจะแสดงถึงความฉลาดของปัญญาประดิษฐ์ที่กำหนดการกระทำหรือพฤติกรรมที่แสดงออกมาได้อย่างชัดเจน

2.4.1 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง คือการวิเคราะห์และสร้างอัลกอริทึมที่มีความสามารถในการเรียนรู้ทำความเข้าใจและทำนายข้อมูลได้ โดยมีมนุษย์เป็นผู้สร้างรูปแบบและผลของการเรียนรู้ผ่านแบบจำลองทางคณิตศาสตร์ซึ่งมีทั้งหมด 7 ขั้นตอนดังภาพที่ 2-8 ข้อมูลที่นำมาใช้ในการเรียนรู้ในแบบจำลองเรียกว่า ชุดข้อมูล (Dataset) ซึ่งจำนวนของชุดข้อมูลที่จะนำมาใช้จะต้องมีจำนวนข้อมูลที่มากเพียงพอ หากมีน้อยเกินไปจะส่งผลให้ ทักษะในการวิเคราะห์ของเครื่องคอมพิวเตอร์ต่ำและทำให้เกิดความผิดพลาดในการทำงาน (ชูพันธุ์, 2559)




ภาพที่ 2-8 ขั้นตอนการเรียนรู้ของเครื่อง (Machine Learning)

ชุดข้อมูลสำหรับใช้สอนแบบจำลองสามารถใช้ได้หลายรูปแบบ เช่น ตัวอักษร รูปภาพ วิดีโอ หรือ ตัวเลข แต่ข้อมูลดังกล่าวจะต้องผ่านกระบวนการเตรียมข้อมูล (Data Preparation) เช่น การจัดตัวอักษร หรือ ย่อขนาดรูปภาพ ให้อยู่ในรูปของเวกเตอร์ตัวเลข และผลลัพธ์ที่ได้จากการเตรียมข้อมูลจะเรียกว่า คุณสมบัติ (Feature) จากนั้นจะต้องนำไปฝึกฝนแบบจำลองเพื่อให้เครื่องคอมพิวเตอร์ทำการเรียนรู้และสามารถทำนายข้อมูลได้ (คนบดี, 2565)

2.4.2 คอมพิวเตอร์วิทัศน์ (Computer Vision)

คอมพิวเตอร์วิทัศน์ (Computer Vision) เป็นสาขาหนึ่งของปัญญาประดิษฐ์ (AI) ทำให้คอมพิวเตอร์สามารถตีความ วิเคราะห์ และเข้าใจข้อมูลภาพได้เหมือนมนุษย์ ซึ่งความสามารถของคอมพิวเตอร์วิทัศน์คือ การจำวัตถุ การตรวจจับเหตุการณ์ การเข้าใจวัตถุ และการตัดสินใจตามภาพถ่าย โดยคอมพิวเตอร์วิทัศน์นี้มีการใช้กันอย่างกว้างขวาง เช่น ใช้ในการรักษาความปลอดภัยเพื่อวิเคราะห์ภาพจากกล้องวงจรปิดเพื่อตรวจจับการกระทำที่ผิดปกติหรือการระบุบุคคล ใช้ในการแพทย์เพื่อวิเคราะห์ภาพจากการสแกนต่างๆ ซึ่งช่วยลดข้อผิดพลาดจากมนุษย์และเพิ่มประสิทธิภาพ ใช้ในกระบวนการผลิตช่วยให้สามารถตรวจสอบสินค้าได้อย่างรวดเร็วและแม่นยำ

องค์ประกอบที่สำคัญของคอมพิวเตอร์วิทัศน์คือ Region of Interest (ROI) โดย ROI จะเป็นตัวช่วยให้คอมพิวเตอร์สามารถมองเห็นรูปภาพตามกรอบที่กำหนด โดยทั่วไปกรอบจะเป็นสี่เหลี่ยมหรือรูปทรงตามแบบจำลองที่ใช้งานดังภาพที่ 2-9 (Raghavendra และ Busch, 2014)



ภาพที่ 2-9 ขั้นตอนการสร้าง Region of Interest (ROI) (Raghavendra และ Busch, 2014)


2.4.3 Generative AI

Generative AI คือสาขาหนึ่งของปัญญาประดิษฐ์ ที่เน้นการสร้างเนื้อหาใหม่ในรูปแบบต่างๆ เช่นข้อความ รูปภาพ วิดีโอ เสียง โดยอาศัยการเรียนรู้จากข้อมูลจำนวนมากเพื่อจดจำรูปแบบ โครงสร้าง และลักษณะของข้อมูล เพื่อนำมาใช้ในการสร้างเนื้อหาใหม่ที่มีลักษณะคล้ายคลึงกับข้อมูลต้นฉบับ ซึ่งสามารถนำไปประยุกต์ใช้ในหลายสาขาวิชา เช่น ภาษา ศิลปะ ดนตรี วิทยาศาสตร์ เคมี ชีววิทยา โดยตัวอย่างของ Generative AI ที่เป็นที่รู้จักในปัจจุบัน ได้แก่ ChatGPT, Claude และ Gemini ซึ่งถูกพัฒนาโดยองค์กรที่แตกต่างกัน แต่แบบจำลองเหล่านี้มีความสามารถที่คล้ายกัน เช่น การสร้างและสรุปข้อความ การตอบคำถาม การวิเคราะห์ข้อมูล การแก้โจทย์คณิตศาสตร์ที่ซับซ้อน การเขียนโค้ดโปรแกรม และในปัจจุบันยังมีการพัฒนาแบบจำลองที่สามารถสร้างภาพและวิดีโอจากข้อความได้ ซึ่งสะท้อนให้เห็นถึงศักยภาพของ Generative AI

Generative AI แสดงให้เห็นถึงการพัฒนาของปัญญาประดิษฐ์ที่สามารถสร้างเนื้อหาใหม่ได้อย่างมีประสิทธิภาพและใกล้เคียงกับมนุษย์มาก ซึ่งเป็นเทคโนโลยีที่มีแนวโน้มในการเปลี่ยนแปลงวิธีการทำงานในหลายวงการ ทั้งด้านการศึกษา การออกแบบ สื่อสารมวลชน การแพทย์ และอุตสาหกรรมอื่นๆ แต่การใช้งานเทคโนโลยีนี้ยังต้องคำนึงถึงประเด็นทางจริยธรรม ความถูกต้องของข้อมูล และผลกระทบต่อสังคมในระยะยาว (Bubeck และคณะ, 2023)


2.4.4 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม (Artificial Neural Network) เป็นอัลกอริทึมในการเรียนรู้ที่มีความซับซ้อน ถูกพัฒนาขึ้นมาจากหลักการ ทำงานของเซลล์ประสาทของมนุษย์ ประกอบด้วยเซลล์ประสาทจำนวนมาก จากโครงสร้างทางชีววิทยาของสมองมนุษย์ ซึ่งเชื่อมต่อกันเป็นโครงข่าย (Network) ดังภาพที่ 2-10 โดยเซลล์ประสาท 1 เซลล์หรือนิวรอน (Neurons) ประกอบด้วยตัวเซลล์ (Cell Body) ที่มีช่องทางการรับข้อมูล (Input) เรียกว่า เส้นใยประสาทนำเข้า (Dendrite) โดยทำหน้าที่ในการรับสัญญาณประมวลผล และส่งผลลัพธ์ไปยังส่วนต่างๆ เพื่อประมวลผลต่อ โดยการส่งออกข้อมูลที่ถูกประมวลผลแล้วจะส่งผ่านแกนประสาทนำออก (Axon) เมื่อเปรียบเทียบกับการทำงานของคอมพิวเตอร์แล้ว เซลล์ประสาทก็คือหน่วยประมวลผลที่ใช้ข้อมูลที่รับมาจากการนำเข้าจากผู้ใช้งานซึ่งเชื่อมต่อกับอุปกรณ์อื่นๆ เมื่อข้อมูลถูกนำเข้า จะถูกประมวลผลแล้วจะถูกส่งผ่านช่องส่งออกเพื่อเชื่อมต่อกับอุปกรณ์อื่น เพื่อที่จะสร้างเครื่องมือที่มีความสามารถในการเรียนรู้ การจดจำ (Pattern Recognition) และการอนุมานความรู้ (Knowledge Deduction) (คณบดี, 2565)




ภาพที่ 2-10 เซลล์ประสาทของมนุษย์ (คนบดี, 2565)

โครงข่ายประสาทเทียมจะมีการรวมกลุ่มของหน่วยประมวลผลย่อย และการเชื่อมต่อนี้เป็นส่วนสำคัญที่ทำให้เกิดสติปัญญาของคอมพิวเตอร์ สามารถแบ่งการทำงานได้ออกเป็น 3 ชั้น ดังภาพที่ 2-11 ประกอบด้วยชั้นนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นส่งออก (Output Layer) โดยชั้นนำเข้าเป็นชั้นที่นำเข้าข้อมูลมายังโครงข่ายประสาทเทียม ชั้นซ่อนอาจมีจำนวนหลายชั้น แต่หน้าที่หลักคือการสกัดคุณลักษณะของข้อมูลที่ถูกป้อนเข้า ซึ่งทำได้หลายครั้งตามจำนวนของชั้นภายในชั้นซ่อน จนกระทั่งส่งต่อถึงชั้นส่งออก ซึ่งจะได้ผลลัพธ์ที่ได้จากการสกัดข้อมูล




ภาพที่ 2-11 โครงข่ายประสาทเทียม

เทคนิคการเรียนรู้ของโครงข่ายประสาทเทียมก็แตกต่างกันไปตามแต่ละชนิดของรูปภาพ และการสอนโครงข่าย โดยทำการคำนวณผลลัพธ์ พร้อมปรับปรุงค่าน้ำหนักจากข้อมูลที่นำเข้าสู่โครงข่ายและอาศัยกระบวนการทำซ้ำ ซึ่งสามารถแบ่งเทคนิคการเรียนรู้เป็น 2 ประเภท คือ การเรียนรู้แบบมีผู้สอน (Supervised Learning) และการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ดังภาพที่ 2-12 และ 2-13 โดยจะแตกต่างกันที่วิธีการป้อนข้อมูล คำตอบ และวิธีการนำปัญหาประดิษฐ์ไปปรับใช้ (คนบดี, 2565)




ภาพที่ 2-12 การเรียนรู้แบบมีผู้สอน (Supervised Learning)



ภาพที่ 2-13 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

2.4.5 โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network, CNN)

โครงข่ายประสาทคอนโวลูชัน (Convolutional Neural Network) คือโครงข่ายประสาทที่ถูกออกแบบด้วยแนวคิดของการคอนโวลูชันเพื่อลดจำนวนพารามิเตอร์ และความซับซ้อนของโครงข่าย โดยดึงข้อมูลเฉพาะคุณลักษณะสำคัญของภาพ เช่น เส้น ขอบ มุม โดยสถาปัตยกรรมของ CNN ประกอบด้วย 3 ชั้น ดังภาพที่ 2-14



ภาพที่ 2-14 โครงข่ายประสาทคอนโวลูชัน (CNN)

ชั้นคอนโวลูชัน (Convolutional Layer) เป็นชั้นพื้นฐานในกระบวนการประมวลผลภาพและการมองเห็นด้วยคอมพิวเตอร์ ประกอบไปด้วยคอร์เนลฟิลเตอร์ (Kernel Filter) ที่เป็นเมทริกซ์ขนาดเล็ก โดยมีขนาด 3×3 , 5×5 และ 7×7 สำหรับดึงเอาคุณสมบัติเฉพาะของรูปภาพออกมา เช่น เส้น ขอบ มุม ปรับเปลี่ยนไปตามพิกเซลในแต่ละจุดของภาพ


ชั้นพูลลิง (Pooling Layer) มีหน้าที่ลดขนาดของข้อมูลโดยการรวบรวมข้อมูลจากหลายพิกเซลเป็นพิกเซลเดียว ซึ่งช่วยลดความซับซ้อนของแบบจำลอง ประกอบด้วยค่ามากที่สุด (Max Pooling) น้อยที่สุด (Min Pooling) ผลรวม (Sum Pooling) และค่าเฉลี่ย (Average Pooling)

ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer) คือชั้นที่มีการเชื่อมต่อระหว่างเซลล์ประสาทในชั้นนี้กับเซลล์ประสาทในชั้นก่อนหน้าเพื่อแปลงข้อมูลจากชั้นก่อนหน้าที่เป็นสองมิติเป็นหนึ่งมิติ และทำการจำแนกประเภทหรือทำนายค่า (Sengupta และคณะ, 2020)

2.4.5.1 แบบจำลอง Mask R-CNN

แบบจำลอง Mask R-CNN เป็นแบบจำลองตรวจจับภาพที่นิยมสำหรับการแบ่งส่วนรูปภาพ โดยแบ่งในลักษณะพิกเซลต่อพิกเซล แบ่งออกเป็น 2 ขั้นตอน ขั้นตอนที่ 1 คือสร้างกรอบล้อมรอบรูปภาพที่ต้องการ และขั้นตอนที่ 2 คือแบ่งส่วนของรูปภาพ

Mask R-CNN จะทำนายวัตถุจากรูปภาพโดยการเพิ่มหน้าฉากคลุมให้กับวัตถุ โดยใช้ RoiAlign ดังภาพที่ 2-15 ที่เป็นวิธีการซ้อนทับกันระหว่างรูปที่ทำการระบุวัตถุไว้กับรูปที่ต้องการฝึก และให้แบบจำลองจดจำในระดับพิกเซล โดยผู้ฝึกจะต้องทำการระบุชื่อของวัตถุ ตำแหน่งของวัตถุที่อยู่ในภาพ และบันทึกเป็นไฟล์ COCO (Common Objects in Context) ที่จะเปลี่ยนรูปภาพให้เป็นตัวเลขก่อนที่จะทำการฝึกกับแบบจำลอง Mask R-CNN (He และคณะ, 2017)



ภาพที่ 2-15 หลักการ RoiAlign และการแบ่งพื้นที่ของวัตถุด้วย Mask R-CNN (He และคณะ, 2017)

2.4.5.2 แบบจำลอง YOLO

YOLO (You Only Look Once) เป็นแบบจำลองเพื่อตรวจจับวัตถุในรูป และ จำแนกประเภทซึ่งเป็นที่ยอมรับในระบบขับเคลื่อนอัตโนมัติ การตรวจสอบความปลอดภัย หุ่นยนต์ โดยมี การพัฒนาต่อเนื่องมาจากอัลกอริทึมตัวอื่น เปิดตัวครั้งแรกเมื่อปี พ.ศ. 2558 และเริ่มได้รับความนิยม ในรุ่น YOLOv3 เนื่องจากว่าเป็นรุ่นที่สามารถจำแนกได้หลายรูปแบบ จากนั้นในรุ่นต่อไปได้พัฒนาใน ด้านความไวและความแม่นยำโดยใช้วิธีต่างๆ เช่น สถาปัตยกรรม CSPNet (Cross Stage Partial Network) หรือ ELAN (Efficient Layer Aggregation Network) ในการตรวจจับรูปภาพ เป็นต้น และมีการพัฒนาอย่างต่อเนื่องจนถึง YOLOv9 ที่เปิดตัวเดือน กุมภาพันธ์ 2567 ที่ใช้สถาปัตยกรรม GELAN (Generalized Efficient Layer Aggregation Network) สำหรับเพิ่มความชัดและความ แม่นยำในการตรวจจับกับ PGI (Programmable Gradient Information) ในการลดคอขวดในช่วง ระหว่างการเรียนรู้ของโครงข่ายประสาทเทียม (Gallagher และ Skalski, 2024)

หลักการทำงานของแบบจำลอง YOLO คือจะเริ่มตรวจจับรูปภาพจากการแบ่ง รูปออกเป็นหลายส่วน และทำนายทุกส่วนพร้อมกันดัง ทำให้มีความรวดเร็วในการตรวจจับวัตถุอย่าง มาก (Wang, Yeh และ Liao, 2024)

2.4.5.3 แบบจำลอง U-Net

U-Net เป็นแบบจำลองสำหรับแบ่งส่วนของภาพด้วยหลักการ CNN เหมาะ สำหรับงานที่ต้องการแบ่งภาพด้วยความละเอียดระดับพิกเซล โดยใน U-Net จะนิยมใช้ในการ วิเคราะห์ภาพทางการแพทย์ งานในด้านชีววิทยา และการขับเคลื่อนอัตโนมัติ

หลักการทำงานของ U-Net คือการลดและขยายรูปภาพ หรือเรียกว่า Encoder และ Decoder ซึ่งเชื่อมกันในลักษณะตัว U โดยเริ่มจากการนำรูปที่มีขนาดใหญ่และรูปที่ ผู้ใช้ระบุตำแหน่งวัตถุในภาพมาลดความละเอียดเพื่อหาตำแหน่งของวัตถุในภาพ จากนั้นทำการเพิ่ม ความละเอียดของรูปภาพของวัตถุ และนำรูปจากช่วงที่ทำการลดขนาดมาทับกับรูปที่แบ่งประเภทของ วัตถุเพื่อให้แบบจำลองเรียนรู้ตำแหน่งของวัตถุในระดับพิกเซลด้วยขนาดที่แตกต่างกัน วิธีนี้ช่วยให้ แบบจำลองเรียนรู้จากจำนวนรูปตัวอย่างที่มีน้อยได้อย่างมีประสิทธิภาพ (Ronneberger, Fischer และ Brox, 2015 อ้างถึงใน กิตติกร และคณะ, 2567)

2.4.6 การฝึกฝนแบบจำลองโครงข่ายประสาทเทียม

การฝึกฝนแบบจำลองโครงข่ายประสาทเทียม เป็นขั้นตอนสำคัญที่มีผลต่อประสิทธิภาพ ของแบบจำลอง โดยเฉพาะในงานประมวลผลภาพที่ต้องอาศัยการเรียนรู้จากข้อมูลจำนวนมาก

กระบวนการฝึกฝนประกอบด้วยการตั้งค่าไฮเปอร์พารามิเตอร์ของโครงข่ายประสาทเทียม การเตรียมและป้อนข้อมูลเข้าสู่ระบบ และการประเมินความแม่นยำของแบบจำลองในแต่ละรอบการฝึก โดยรายละเอียดของแต่ละขั้นตอนจะถูกนำเสนอในหัวข้อย่อย ดังนี้

2.4.6.1 ค่าไฮเปอร์พารามิเตอร์ของโครงข่ายประสาทเทียม

ไฮเปอร์พารามิเตอร์ (Hyperparameters) คือ ค่าคุณสมบัติของแบบจำลองต่างๆ ที่ผู้ฝึกต้องกำหนดก่อนที่แบบจำลองจะทำการเรียนรู้ โดยค่าที่ใช้ในการฝึกแบบจำลองโครงข่ายประสาทเทียมหลักๆ มีดังนี้ (Zhou และคณะ, 2024)

1) อัตราการเรียนรู้ (Learning Rate) เป็นตัวกำหนดความเร็วในการเรียนรู้ของแบบจำลอง หากกำหนดค่าไว้สูงเกินไปทำให้แบบจำลองไม่สามารถเรียนรู้ได้อย่างละเอียด ถ้ากำหนดค่าไว้ต่ำเกินไป แบบจำลองจะใช้เวลาในการเรียนรู้ โดยค่าที่เหมาะสมสำหรับการฝึกควรอยู่ที่ 0.001 (Agustiansyah และคณะ, 2022) เนื่องจากเป็นค่าที่ให้ความแม่นยำด้วยระยะเวลาในการฝึกที่ไม่มากเกินไป

2) จำนวนภาพที่ใช้ในการฝึกฝนในแต่ละรอบ (Batch Size) คือจำนวนข้อมูลที่ป้อนเข้าสู่แบบจำลองก่อนในการเรียนรู้ 1 ครั้ง โดยการกำหนดค่าในระดับสูงช่วยให้ผลลัพธ์มีความเสถียรแต่ต้องใช้ทรัพยากรคอมพิวเตอร์อย่างมาก ส่วนค่าที่ต่ำช่วยลดการใช้ทรัพยากรและอาจช่วยให้แบบจำลองเรียนรู้ได้ละเอียดมากขึ้น

3) จำนวนรอบการฝึก (Epochs) หมายถึงจำนวนครั้งที่แบบจำลองได้เรียนรู้จากชุดข้อมูลทั้งหมด โดยหากมีจำนวนรอบที่น้อย แบบจำลองจะเกิดปัญหาการเรียนรู้ไม่เพียงพอ (Underfitting) แต่ถ้ามากเกินไปจะทำให้เกิดการจดจำข้อมูลมากเกินไป (Overfitting) และส่งผลให้ความสามารถในการทำนายข้อมูลใหม่ลดลง หรือมีความแม่นยำที่คงที่

4) ขนาดของภาพที่ใช้ในการฝึกฝน (Image Size) เป็นตัวกำหนดระดับรายละเอียดของข้อมูลที่แบบจำลองได้รับ โดยภาพที่มีขนาดใหญ่สามารถรักษารายละเอียดได้มากขึ้น แต่ใช้ทรัพยากรและเวลาในการเรียนรู้มาก ส่วนภาพขนาดเล็กช่วยให้การประมวลผลรวดเร็วขึ้นแต่มีความเสี่ยงในการสูญเสียรายละเอียดของวัตถุที่ต้องการและส่งผลต่อความแม่นยำของแบบจำลอง

2.4.6.2 ข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง

ข้อมูลที่ใช้ในการฝึกฝน คือชุดข้อมูลหรือรูปภาพที่ถูกป้อนเข้าไปในโครงข่ายประสาทเทียม (Artificial Neural Network) เพื่อให้แบบจำลองสามารถเรียนรู้รูปแบบและลักษณะเฉพาะของข้อมูลได้ เช่น รูปภาพแบบก่อสร้าง รูปภาพจากสถานที่ก่อสร้าง เป็นต้น

ข้อมูลรูปภาพที่ใช้ในการฝึกฝนแบบจำลอง จะต้องปรับให้อยู่ในขนาดเดียวกัน และแยกชุดข้อมูลออกเป็น 3 ชุด ได้แก่

1) ชุดสำหรับการฝึก (Training set) ใช้สำหรับการเรียนรู้ลักษณะและรูปแบบของวัตถุในรูปภาพ

2) ชุดสำหรับการตรวจสอบความถูกต้อง (Validation set) ใช้สำหรับปรับแต่งพารามิเตอร์และตรวจสอบความสามารถของแบบจำลองในระหว่างการฝึก เพื่อป้องกันปัญหาการเรียนรู้มากเกินไป (Overfitting) ซึ่งเกิดขึ้นเมื่อจำนวนชั้นหรือพารามิเตอร์มากเกินไป หรือข้อมูลที่ใช้ฝึกมีปริมาณไม่เพียงพอ ทำให้จดจำรายละเอียดของข้อมูลมากเกินไปจนไม่สามารถทำนายข้อมูลใหม่ได้อย่างแม่นยำ


3) ชุดสำหรับการทดสอบ (Testing set) ใช้สำหรับทดสอบประสิทธิภาพของแบบจำลองกับข้อมูลที่ไม่เคยเห็นมาก่อน เพื่อประเมินความสามารถในการทำนายของแบบจำลอง ดังนั้น การแยกข้อมูลออกเป็นทั้ง 3 ชุดนี้จึงมีความจำเป็นเพื่อให้การฝึกฝนแบบจำลองมีความถูกต้องและเชื่อถือได้ (คนบดี, 2565)

การแบ่งข้อมูลรูปภาพมักนิยมใช้รูปแบบ 80 10 10 โดยร้อยละ 80 ใช้ในการฝึกแบบจำลอง (Training) ร้อยละ 10 ใช้สำหรับตรวจสอบ (Validation) และร้อยละ 10 ใช้สำหรับทดสอบ (Testing) การจัดข้อมูลในลักษณะนี้ช่วยให้ แบบจำลองได้รับข้อมูลเพียงพอในการเรียนรู้ จับลักษณะสำคัญของข้อมูล และแบ่งข้อมูลเพื่อทดสอบประสิทธิภาพได้ตามรูปแบบที่ต้องการ (กิตติการ และคณะ, 2567)

การเลือกจำนวนข้อมูลที่มีความหลากหลายและตรงกับที่ต้องการ เป็นปัจจัยสำคัญที่ส่งผลต่อความสามารถของแบบจำลองในการจดจำและจำแนกข้อมูลใหม่ จำนวนรูปภาพจึงมีผลโดยตรงต่อประสิทธิภาพของแบบจำลอง หากมีข้อมูลไม่เพียงพอ แบบจำลองจะไม่สามารถเรียนรู้รูปแบบที่ซับซ้อนของข้อมูลได้ดี แต่ถ้ามีข้อมูลมากเกินไปอาจทำให้การฝึกใช้เวลานาน ต้องการทรัพยากรคอมพิวเตอร์สูง และไม่ได้ช่วยเพิ่มประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ โดยการเพิ่มจำนวนข้อมูลในการฝึกฝนจะทำให้เกิดเส้นโค้งการเรียนรู้ (Learning Curve) โดยสามารถเพิ่ม

ข้อมูลได้ทั้งในรูปแบบลอการิทึม เช่น 10, 100, 300, 500, 1000 และแบบเชิงเส้น (Linear) เช่น 100 125, 150, 200 (Shahinfar และคณะ, 2020)


รูปภาพที่ใช้ในการฝึกฝนจะต้องผ่านการแบ่งส่วนของวัตถุในรูปภาพ (Annotation) เพื่อกำหนดตำแหน่งของวัตถุ แบ่งพื้นที่ของวัตถุภายในภาพ หรือการระบุประเภทของวัตถุ ดังภาพที่ 2-16 โดยสามารถดำเนินการผ่านเครื่องมือออนไลน์ เช่น Roboflow CVAT หรือ Makesense.ai ที่ช่วยให้ผู้ใช้งานสามารถแบ่งส่วนของวัตถุได้สะดวก รวดเร็ว และสามารถบันทึกผลลัพธ์เป็นไฟล์ในรูปแบบที่แบบจำลองรองรับ เช่น JSON XML และ COCO (Ding and Luo, 2023)



ภาพที่ 2-16 ตัวอย่างการแบ่งพื้นที่ห้องจากรูปภาพ

2.4.6.3 การตรวจสอบความแม่นยำของแบบจำลอง

หลังจากที่แบบจำลองผ่านการฝึกเพื่อตรวจจับรูปภาพแล้ว จะต้องทำการวัดผล เพื่อให้ทราบถึงความแม่นยำในการตรวจจับวัตถุ เพื่อนำไปปรับปรุงและพัฒนาแบบจำลองต่อไป โดยผลการตรวจจับวัตถุถูกจำแนกออกเป็น 4 ประเภทในรูปแบบของ Confusion Matrix ดังภาพที่ 2-17 (ณิศวรา, กอปร และจุฬิพงษ์, 2566)



ภาพที่ 2-17 Confusion Matrix (ณิศวรา, กอปร และวุฒิพงษ์, 2566)

1) True Positive (TP) หมายถึง การที่แบบจำลองสามารถตรวจจับวัตถุ (Ground Truth) ได้อย่างถูกต้อง หรือการทำนายของแบบจำลองตรงกับตำแหน่งของวัตถุจริงที่สนใจ เช่น ถ้าในภาพมีดวงไฟและแบบจำลองครอบวัตถุดวงไฟจะนับเป็น True Positive

2) False Negative (FN) หมายถึงแบบจำลองไม่สามารถตรวจจับหรือครอบวัตถุที่อยู่ในภาพได้แสดงถึงการตรวจจับที่ผิดพลาดของแบบจำลอง เช่น หากในภาพมีโคมไฟแต่แบบจำลองไม่สามารถตรวจจับได้ จะนับเป็น False Negative

3) True Negative (TN) หมายถึง ส่วนของภาพที่ไม่มีวัตถุ และแบบจำลองไม่ได้สร้างกรอบมาครอบพื้นที่นั้น เพื่อแสดงถึงความถูกต้องของแบบจำลองตรวจจับสิ่งที่ไม่ใช่วัตถุ เช่น ถ้าในภาพมีพื้นที่ว่างและแบบจำลองไม่ได้สร้างกรอบครอบพื้นที่นั้นแสดงว่าเป็น True Negative

4) False Positive (FP) หมายถึง แบบจำลองสร้างกรอบครอบบริเวณที่ไม่มีวัตถุ หรือไม่ใช่วัตถุที่ต้องการ แสดงให้เห็นถึงความผิดพลาดของแบบจำลองในการตรวจจับวัตถุ เช่น แบบจำลองจะต้องตรวจจับดวงไฟ แต่ตรวจจับสวิตช์ไฟแทน จะนับเป็น False Positive

หลังจากที่จำแนกผลของแบบจำลองแล้ว จะนำค่าที่ได้มาคำนวณหาตัวชี้วัดต่างๆ สำหรับการกำหนดประสิทธิภาพของแบบจำลองดังนี้ (วรพันธ์ และคณะ, 2567)

ความแม่นยำ (Accuracy) การเปรียบเทียบระหว่างจำนวนภาพที่ทำนายถูกต้อง (True Positive และ True Negative) กับจำนวนภาพทั้งหมดที่ทำนายทั้งถูกและผิด เพื่อวัดความแม่นยำของแบบจำลองตามสมการที่ 2-1

$$\text{ความแม่นยำ (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2-1)$$

ความเที่ยงตรง (Precision) คือการวัดจำนวนครั้งที่แบบจำลองทำนายถูก (True Positive) เทียบกับจำนวนครั้งที่แบบจำลองทำนายทั้งหมดตามสมการที่ 2-2

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

ค่ารีคอล (Recall) คือค่าที่ใช้วัดความสามารถของแบบจำลองในการหาวัตถุที่ถูก (True Positive) เทียบกับจำนวนวัตถุทั้งหมดรวมกับวัตถุที่แบบจำลองทำนายพลาดตามสมการที่ 2-3

$$\text{ค่ารีคอล (Recall)} = \frac{TP}{TP+FN} \quad (2-3)$$

ค่าเอฟวัน (F1 Score) คือค่าเฉลี่ยระหว่างความเที่ยงตรงและค่ารีคอล เพื่อวัดประสิทธิภาพของแบบจำลอง โดยมีค่าระหว่าง 0 ถึง 1 ถ้าสูงกว่า 0.7 ถือว่าแบบจำลองทำนายได้ดี แต่ถ้าต่ำกว่า 0.3 ต้องทำการปรับปรุง โดยการคำนวณตามสมการที่ 2-4

$$\text{ค่าเอฟวัน (F1 Score)} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2-4)$$

5) Intersection Over Union (IOU) เป็นค่าที่ใช้วัดการซ้อนทับกันระหว่างพื้นที่จากรูปจริงกับพื้นที่ที่แบบจำลองทำนาย ใช้สำหรับการประเมินความแม่นยำของแบบจำลองในกรณีที่เกี่ยวข้องกับการหาพื้นที่ตามสมการที่ 2-5 (He และคณะ, 2017)

$$\text{ค่า IOU} = \frac{\text{พื้นที่ทำนาย}}{\text{พื้นที่จริง}} \quad (2-5)$$

2.5 งานวิจัยที่เกี่ยวข้อง

2.5.1 งานวิจัยเกี่ยวกับการประมาณราคาก่อสร้าง

Al-Khalil และ Al-Ghafly (1999) ได้ศึกษาโครงการก่อสร้างจำนวน 130 โครงการ ในประเทศซาอุดีอาระเบีย พบว่าความแม่นยำของการประมาณต้นทุนเฉลี่ยอยู่ที่ 86.5% ซึ่งแตกต่างกันไปตามประเภทของโครงการ โครงการอาคารที่อยู่อาศัยมีความแม่นยำที่สุดที่ 91.4% และโครงการที่เกี่ยวข้องกับระบบน้ำมีความแม่นยำน้อยที่สุดที่ 75.6% โดยปัจจัยสำคัญที่มีผลต่อความแม่นยำของการประมาณต้นทุน ได้แก่ การเปลี่ยนแปลงการออกแบบ 92.3% สภาพตลาด 84.6% และวัตถุดิบที่ใช้ในการก่อสร้าง 80.8%

กรรวิ และกวิน (2561) ได้ใช้วิธีการประมาณราคาด้วยตัวแปร โดยกำหนด 3 ตัวแปรได้แก่ พื้นที่อาคารรวม ความสูงอาคาร และจำนวนชั้น แล้วนำไปใช้ในแบบจำลองการวิเคราะห์ความถดถอย และวิธีความสัมพันธ์ระหว่างต้นทุนกับความสามารถในการผลิต (Cost-Capacity Relationship) เพื่อประมาณราคางานก่อสร้างอาคารพักอาศัยของภาครัฐ จากการศึกษา พบว่า แบบจำลองการวิเคราะห์ความถดถอยมีค่าความคลาดเคลื่อนอยู่ระหว่าง -4% ถึง 14% ส่วนวิธีความสัมพันธ์ระหว่างต้นทุนกับความสามารถในการผลิต (Cost-Capacity Relationship) มีค่าความคลาดเคลื่อนอยู่ระหว่าง -3% ถึง 15% ซึ่งยังอยู่ในเกณฑ์การประมาณราคาเบื้องต้นที่ยอมรับได้ระหว่าง -15% ถึง 20%

เทชฤทธิ์ (2565) ได้นำวิธีประมาณราคาด้วยตัวแปร มาใช้กับโครงการก่อสร้างคอนโดมิเนียมสูงในเขตกรุงเทพฯ โดยคำนวณจากตัวแปร 7 ตัว ได้แก่ พื้นที่ดิน พื้นที่กรอบอาคาร พื้นที่ก่อสร้าง พื้นที่ใช้สอย งานพื้นคอนกรีตอัดแรงภายหลัง จำนวนห้องพัก และจำนวนชั้น ในการคำนวณราคาก่อสร้างจากการใช้ตัวแปรคูณกับราคาต่อหน่วย จากผลการศึกษาพบว่าการประมาณราคาด้วยวิธีนี้มีความคลาดเคลื่อนจากต้นทุนการก่อสร้างจริงอยู่ที่ 5% ถึง 20%

สุนันท์ และคณะ (2566) ได้หาวิธีการปริมาณเหล็กเสริมต่อปริมาตรคอนกรีตของอาคารขนาดใหญ่จากการเฉลี่ยข้อมูลเดิม โดยพบว่าสัดส่วนของเหล็กเสริมจะอยู่ระหว่าง 93.42 ถึง 97.89 กก./ลบ.ม. และเมื่อนำไปทดสอบกับอาคารตัวอย่างหนึ่งโครงการ พบว่าปริมาณเหล็กเสริมที่ได้แตกต่างกับปริมาณจริงไม่เกิน 10% ซึ่งอยู่ในเกณฑ์ยอมรับได้

2.5.2 งานวิจัยที่นำปัญญาประดิษฐ์มาประยุกต์ใช้ในงานก่อสร้าง

2.5.2.1 งานวิจัยที่เกี่ยวกับการตรวจจับวัตถุ

Xiao และ Kang (2021) ได้สร้างแบบจำลองในการตรวจจับวัตถุ ด้วยการเรียนรู้เชิงลึกเพื่อระบุเครื่องจักรที่ใช้ในงานก่อสร้างต่างๆ จากภาพและวิดีโอ และนำข้อมูลที่ตรวจจับได้มาวิเคราะห์ผลผลิตและตรวจสอบกิจกรรม โดยสร้างจากชุดข้อมูลภาพการก่อสร้างของอัลเบอร์ตา (ACID) ที่มีการรวบรวมภาพจำนวน 10,000 ภาพ มีเครื่องจักรที่ใช้ในงานก่อสร้าง 10 ประเภทเช่น รถบรรทุก รถขุด เครนเคลื่อนที่ และรถดักล้อยาง เป็นต้น โดยทำการฝึกฝนแบบจำลองในการตรวจจับวัตถุ 4 แบบ ได้แก่ YOLO-v3, Inception-SSD, R-FCN-ResNet101 และ Faster-RCNN-ResNet101 พบว่ามีค่าเฉลี่ยความแม่นยำ (mAP) อยู่ที่ 83.0% สำหรับ Inception-SSD 87.8% สำหรับ YOLO-v3 88.8% สำหรับ R-FCN-ResNet101 และ 89.2% สำหรับ Faster-RCNN-ResNet101 ความเร็วในการตรวจจับของ YOLO-v3 เร็วที่สุดที่ 26.3 fps และ Faster-RCNN-ResNet101 ช้าที่สุดที่ 8.3 fps

Mei และคณะ (2022) พบว่าการที่คนงานเดินเข้าสู่พื้นที่อันตรายเป็นสาเหตุสำคัญของอุบัติเหตุประเภทหนึ่ง ขณะที่ระบบการจัดการความปลอดภัยแบบเดิมยังคงพึ่งพาการตรวจตราของเจ้าหน้าที่ ซึ่งใช้เวลานานและต้องใช้แรงงานมาก ดังนั้น งานวิจัยนี้จึงนำ YOLOv5 มาใช้ในการตรวจจับบุคคลที่บุกรุกเข้าสู่เขตพื้นที่อันตรายของไซต์ก่อสร้าง พร้อมทั้งสร้างฐานข้อมูลสำหรับการตรวจจับการบุกรุก (Intrusion Rule Base) ซึ่งกำหนดระดับความไวที่แตกต่างกันตามสถานะของการบุกรุก โดยจากการทดสอบพบว่า แบบจำลองที่พัฒนาขึ้นมี ค่าความเที่ยงตรงที่ 96.05% และ ค่ารีคอลที่ 90.05% ซึ่งแสดงให้เห็นว่าวิธีนี้สามารถช่วยเพิ่มความปลอดภัยในไซต์งานก่อสร้างได้อย่างมีประสิทธิภาพ

วรพันธ์ และคณะ (2567) ได้นำเทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์มาแก้ปัญหาคัดกรองงานที่ขาดประสิทธิภาพ โดยการตรวจจับจำนวนคนงานบริเวณสถานที่ก่อสร้างจากภาพถ่ายบริเวณสถานที่ก่อสร้าง ประกอบด้วยภาพจากกล้องวงจรปิด ภาพสถานที่ก่อสร้างกลางแจ้ง ภาพสถานที่ก่อสร้างภายในอาคาร และภาพสถานที่ก่อสร้างบริเวณแสงน้อย การทดสอบได้แบบจำลองสำหรับตรวจสอบ 4 ประเภทประกอบด้วย YOLOv4, YOLOv8, YOLOv9 และ ACF ซึ่งมีแบบจำลองย่อยรวม 10 แบบจำลอง ใช้ภาพถ่ายในการฝึกฝนรวม 50 ภาพ ตรวจสอบค่าชี้วัดทั้งหมด 3 ค่าได้แก่ ค่ารีคอล ค่าความเที่ยงตรง และค่าเอฟวัน พบว่าภาพจากกล้องวงจรปิดเป็นภาพที่แบบจำลองทำนายผิดพลาดมากที่สุดและภาพในที่แสงน้อยเป็นภาพที่แบบจำลองทำนายดีที่สุด เนื่องจากจำนวนคนทำงานน้อย โดย YOLOv9 มีความแม่นยำสูงสุด YoLov4, YoLov8 มีความแม่นยำรองลงมา และ ACF มีความแม่นยำต่ำที่สุด

กิตตากร และคณะ (2567) ได้นำ U-Net มาแบ่งพื้นที่ภาพถ่ายทางอากาศ ซึ่งเป็นภาพที่ได้จากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) จำนวน 1,286 ภาพ โดยจำแนกพื้นที่ด้วยโปรแกรม CVAT (Computer Vision Annotation Tool) ด้วยสี RGB และแบ่งพื้นที่ทั้งหมด 10 พื้นที่ ได้แก่ สนามบิน สนามกีฬา ป่าไม้ พื้นที่ทางการเกษตร แม่น้ำ รถ ถนน สิ่งก่อสร้าง ซึ่งในการทดลองนี้ได้ใช้แบบจำลองย่อยใน U-NET ได้แก่ MobileNetV2, ResNet50, ResNet50V2, DenseNet201 และ VGG16 ในการจำแนกพื้นที่ของภาพถ่ายทางอากาศ ผลจากการทดลองพบว่าแต่ละแบบจำลองมีความแม่นยำ (MAP) ประมาณ 80% โดย ResNet50 มีความแม่นยำน้อยที่สุดอยู่ที่ 66.23% และ MobileNetV2 มีความแม่นยำมากที่สุดอยู่ที่ 82.33% มีความเร็วในการตรวจสอบอยู่ที่ 2 วินาที

2.5.2.2 งานวิจัยที่เกี่ยวกับการถอดปริมาณ

สันติภูมิ (2565) ได้นำโครงข่ายประสาทเทียม (Artificial Neural Networks) เพื่อสร้างแบบจำลองสำหรับประมาณราคาก่อสร้างเบื้องต้นด้วยโปรแกรม RapidMiner โดยใช้ข้อมูลพื้นที่ของอาคารที่ก่อสร้างแล้วภายในมหาวิทยาลัยเชียงใหม่จำนวน 50 แห่ง และเมื่อนำมาเปรียบเทียบกับราคาก่อสร้างจริงแล้ว พบว่าการประมาณราคาจากโครงข่ายประสาทเทียมมีความแม่นยำถึง 90.46%

Chowdhury และ Moon (2023) ได้ใช้ปัญญาประดิษฐ์ในการคำนวณปริมาณและการประมาณราคาค่าใช้จ่ายเป็นอัตโนมัติของแบบหล่อคอนกรีต โดยเชื่อมข้อมูลเข้ากับฐานข้อมูลต้นทุนเพื่อสร้างรายการวัสดุ (BoMs) แบบจำลองที่ใช้คือ Mask R-CNN และเทคนิคการแบ่งส่วนภาพได้รับการฝึกฝนโดยใช้ภาพ CAD สองมิติ 186 ภาพ แบ่งประเภทของภาพได้ 3353 ประเภท ได้ค่าเฉลี่ยความแม่นยำ (Mean Average Precision, mAP) อยู่ที่ 98% ที่ นอกจากนี้ยังมีการใช้เทคโนโลยี การรู้จำอักขระด้วยแสง (OCR) เพื่อดึงข้อมูลตัวเลขจากรูปภาพ เพื่อผสมกับฐานข้อมูลต้นทุนของวัสดุ BoM-GAIM จะสามารถสร้าง BoM สำหรับแบบหล่อคอนกรีตจากภาพ CAD 2D ได้ ซึ่งช่วยประสิทธิภาพในการออกแบบแบบหล่อคอนกรีต

2.5.2.3 งานวิจัยที่เกี่ยวกับการตรวจสอบสิ่งก่อสร้าง

Chen, Wu และ Puranam (2024) ได้นำ U-Net มาตรวจสอบความกว้างของรอยแตกในโครงสร้างคอนกรีตเสริมเหล็ก (RC) ที่โดยปกติจะดึงพื้นที่ของรอยแตกออกมาแล้วทำการคำนวณความกว้าง แต่เพื่อให้ตรวจสอบได้แม่นยำขึ้นจึงได้ใช้แบบจำลองแบบหลายภารกิจ (multi-task) ที่สามารถคาดการณ์การรอยแตกและจุดกึ่งกลางของรอยแตกได้พร้อมกัน โดยใช้แบบจำลอง U-Net ใช้รูปภาพจากหน้างานจริงผสมกับรูปรอยแตกที่สร้างขึ้นมาจากแลป จำนวน 1,014 ภาพ โดยผลจากการฝึกฝนแสดงให้เห็นว่า แบบจำลองหลายภารกิจมีประสิทธิภาพดีกว่าแบบจำลองพื้นฐานที่จากค่า IoU ที่ 59.5% กับ 61.7% และค่าเอฟวัน ที่ 0.55 กับ 0.61 หลังจากที่ทำนายความกว้างของรอยแตกแล้วจะต้องใช้คอมพิวเตอร์วิทัศน์ (Computer Vision) ในการคำนวณความกว้างของรอยแตกและใช้การสร้างภาพสามมิติจากรูปสองมิติโดยใช้เมทริกซ์โปรเจกชัน (Projection Matrix) เพื่อปรับรูปทรงของรอยแตก และแก้ไขความบิดเบี้ยวระหว่างการถ่ายรูป ซึ่งผลที่ได้ช่วยให้รอยแตกขนาดใกล้เคียงกับความจริง

Zhou และคณะ (2024) นำ YOLO มาตรวจจับรอยแตกของไม้จากอาคาร แต่การระบุตำแหน่งรอยแตกในวัสดุไม่มีความท้าทาย เนื่องจากขนาดที่แตกต่างกันระหว่างรอยแตกและคุณภาพของรูปภาพที่มีอยู่ไม่เหมือนกัน เพื่อแก้ปัญหานี้ จึงต้องสร้างแบบจำลองตรวจจับรอยแตกที่

ออกแบบมาเฉพาะสำหรับวัสดุไม้ที่มีชื่อว่า ICDW-YOLO (Improved Crack Detection For Wooden Material) โดยได้ออกแบบโครงสร้างโครงข่ายและเลเยอร์ รวมถึงอัลกอริทึม Anchor มาใช้เพื่อเพิ่มประสิทธิภาพและปรับปรุงแบบจำลองดั้งเดิม โดย ผลลัพธ์ที่ได้จากการเรียนรู้จากรูปภาพ 1,617 ภาพสามารถตรวจจับเป้าหมายได้อย่างมีประสิทธิภาพ โดยไม่เพิ่มความซับซ้อนของแบบจำลองอย่างมีนัยสำคัญ ค่า mAP50-95 ของแบบจำลองอยู่ที่ 79.018% F1Score 0.984 มากกว่า YOLOv8 1.87% และ 0.011 เมื่อเทียบกับ YOLOv8 แสดงให้เห็นถึงแบบจำลองที่สร้างขึ้นมีความแม่นยำกว่าแบบจำลองปรกติเล็กน้อย

Perez และคณะ (2024) ได้นำปัญญาประดิษฐ์มาโดยใช้แบบจำลอง U-Net ในการบริหารจัดการบำรุงรักษาถนน (Pavement Management) เพื่อประเมินสภาพพื้นผิวถนนแบบอัตโนมัติ ทำนายการเสื่อมสภาพ และสร้างแผนบำรุงรักษาภายใต้งบประมาณที่จำกัด โดยใช้เทคนิคปัญญาประดิษฐ์ 3 วิธี ได้แก่

1) Pavement Condition Index (PCI) เป็นมาตรฐานในการวัดความแข็งแรงของโครงสร้างและสภาพพื้นผิวถนน กับโครงข่ายประสาทคอนโวลูชัน (CNN) ในการเพื่อจำแนกและวิเคราะห์ความเสียหาย

2) Feed-Forward Neural Network (FNN) เพื่อใช้เป็นข้อมูลจากการตรวจสอบสภาพพื้นถนน และปัจจัยด้านสภาพอากาศและการจราจร (อุณหภูมิ ปริมาณฝน และหิมะ) เพื่อคาดการณ์สภาพถนนในอนาคต

3) Multi-Criteria Decision Making (MCDM) ที่ออกแบบด้วยขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดด้วยฮิวริสติก (Heuristic Optimization Algorithms) เพื่อช่วยผู้ตัดสินใจเลือกแผนบำรุงรักษาที่เหมาะสม และสร้างแผนการซ่อมแซมถนน

2.6 สรุปผลการทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง

จากการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง พบว่ามีการประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ในงานก่อสร้างได้หลากหลายรูปแบบ ไม่ว่าจะเป็นการตรวจจับวัตถุ ประเมินการค่าใช้จ่ายก่อสร้าง และกระบวนการตรวจสอบงานก่อสร้าง ซึ่งสามารถสรุปแนวทางการประยุกต์ใช้ในแต่ละหัวข้อดังแสดงดังตารางที่ 2-2

ตารางที่ 2-2 สรุปงานวิจัยที่นำปัญญาประดิษฐ์มาประยุกต์ใช้ในงานก่อสร้าง

หัวข้อ	แบบจำลองที่ใช้	รายละเอียด	ผู้แต่ง
การถอดปริมาณงาน	Mask R-CNN	ใช้แบบจำลองในการคำนวณปริมาณและค่าใช้จ่ายของแบบหล่อคอนกรีต	Chowdhury และ Moon (2023)
	RapidMiner	ใช้โครงข่ายประสาทเทียมในการประมาณราคาค่าก่อสร้าง	สันติภูมิ (2565)
	U-Net	ใช้แบบจำลองมาแบ่งพื้นที่ภาพถ่ายทางอากาศ	กิตติกร และคณะ (2567)
การตรวจสอบสิ่งก่อสร้าง	U-Net	ใช้แบบจำลองในการตรวจสอบความกว้างของรอยแตกในโครงสร้างคอนกรีตเสริมเหล็ก	Chen, Wu และ Puranam (2024)
	Yolo	ใช้แบบจำลองตรวจจับรอยแตกของไม้จากอาคาร	Zhou และคณะ (2024)
	U-Net	ใช้แบบจำลอง ในการประเมินสภาพพื้นผิวถนน ทำนายการเสื่อมสภาพ และ สร้างแผนบำรุงรักษา	Perez และคณะ (2024)
การตรวจจับวัตถุ	Mask R-CNN และ Yolo	เปรียบเทียบแบบจำลองในการตรวจจับเครื่องจักรที่ใช้ในงานก่อสร้าง	Xiao และ Kang (2021)
	Yolo	สร้างฐานข้อมูลและตรวจจับคนงานที่เดินเข้าสู่พื้นที่อันตรายในเขตก่อสร้าง	Mei และคณะ (2022)
	Yolo	ใช้แบบจำลองตรวจจับคนงานในไซต์ก่อสร้าง	วรพันธ์ และคณะ (2567)

ตารางที่ 2-2 แสดงให้เห็นว่ามีงานวิจัยที่ศึกษาการใช้แบบจำลองโครงข่ายประสาทเทียมมาช่วยถอดปริมาณงานและการประมาณค่าใช้จ่ายในงานก่อสร้าง โดยก่อนการนำไปใช้งาน จำเป็นต้องฝึกฝนเพื่อให้แบบจำลองเรียนรู้จากข้อมูลจริงจนสามารถนำไปใช้ตรวจจับวัตถุหรือวิเคราะห์ผลได้ตามที่ต้องการ งานวิจัยนี้จึงได้นำแนวทางการฝึกฝนแบบจำลองจากงานวิจัยของ Chowdhury และ Moon (2023) วรพันธ์ และคณะ (2567) Mei และคณะ (2022) และกิตติกร และคณะ (2567) มาใช้เป็นแนวทางสำหรับการฝึกฝนและประเมินผลของแบบจำลอง Mask R-CNN, YOLO และ U-Net ในการตรวจจับอุปกรณ์ระบบไฟฟ้า และการแบ่งพื้นที่ห้องจากแบบก่อสร้างบ้านพักอาศัย ซึ่งรายละเอียดเพิ่มเติมจะกล่าวถึงในบทถัดไป



บทที่ 3

ระเบียบการวิจัย

งานวิจัยนี้เป็นการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ในกระบวนการประมาณราคาก่อสร้าง โดยมุ่งเน้นการนำแบบจำลองปัญญาประดิษฐ์โครงข่ายประสาทคอนโวลูชัน จำนวน 3 แบบจำลอง ได้แก่ Mask R-CNN, YOLOv9 และ U-Net มาประยุกต์ใช้ในการตรวจจับวัตถุเพื่อถอดปริมาณ อุปกรณ์ระบบไฟฟ้าและแบ่งพื้นที่ห้องจากแบบก่อสร้างบ้านพักอาศัย ซึ่งในบทนี้ได้กล่าวถึงขั้นตอน การวิจัยทั้งหมด 6 ขั้นตอนประกอบด้วย (1) กำหนดประเภทของวัตถุและตัวแปรที่ใช้ในการฝึกฝน แบบจำลอง (2) รวบรวมรูปภาพแบบก่อสร้าง (3) เตรียมข้อมูลสำหรับฝึกแบบจำลอง (4) ฝึกฝน แบบจำลองปัญญาประดิษฐ์ (5) ทดสอบและประเมินผลแบบจำลอง และ (6) การเปรียบเทียบผลการ ถอดปริมาณด้วยแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ ดังภาพที่ 3-1

3.1 กำหนดประเภทของวัตถุและตัวแปรที่ใช้ในการฝึกฝนแบบจำลอง

3.1.1 กำหนดประเภทของวัตถุ

งานวิจัยนี้มีขอบเขตการดำเนินงานที่จะเปรียบเทียบผลการตรวจจับและการจำแนกวัตถุ จากภาพแบบก่อสร้าง โดยแบ่งออกเป็น 4 ประเภท ได้แก่ (1) พื้นที่ห้อง (2) ดวงไฟ (3) สวิตช์ และ (4) เต้ารับไฟฟ้า ซึ่งในแบบก่อสร้างมีการใช้สัญลักษณ์สำหรับแสดงวัตถุเหล่านี้ที่แตกต่างกันหลาย รูปแบบ ดังนั้น ขั้นตอนแรกของงานวิจัยจึงต้องกำหนดรูปแบบสัญลักษณ์ของวัตถุแต่ละประเภท เพื่อใช้ในการฝึกฝนแบบจำลองดังนี้

3.1.1.1 พื้นที่ห้อง


ภาพที่ใช้ในการเรียนรู้สำหรับการแบ่งพื้นที่ห้องจากแบบก่อสร้าง นำมาจากแบบสถาปัตยกรรม เนื่องจากเป็นแบบที่แสดงการกั้นห้องและมีระยะของห้องระบุอย่างชัดเจน ทำให้ทราบขนาดของห้องและช่วยในการตรวจจับพื้นที่ในแบบก่อสร้าง โดยในแบบสถาปัตยกรรมจะ ประกอบด้วยห้องหลายประเภท เช่น ห้องนอน ห้องน้ำ ห้องครัว และห้องนั่งเล่น ดังภาพที่ 3-2

3.1.1.2 ดวงไฟ


ภาพที่ใช้ฝึกสำหรับการตรวจจับดวงไฟนำมาจากแบบไฟฟ้าแสงสว่าง ซึ่งเป็นแบบที่ระบุตำแหน่งและประเภทของดวงไฟที่ใช้ในบ้านดังภาพที่ 3-3 โดยมีสัญลักษณ์ที่เป็นมาตรฐาน ในงานวิศวกรรมไฟฟ้า (สุรศักดิ์, 2562) เช่น ดวงไฟแบบดาวนไลต์ หลอดฟลูออเรสเซนต์ โคมไฟติด ผนัง ดังตารางที่ 3-1



ภาพที่ 3-1 ขั้นตอนการดำเนินงานวิจัย





ภาพที่ 3-2 ตัวอย่างแบบสถาปัตยกรรม



ภาพที่ 3-3 ตัวอย่างแบบไฟฟ้าแสงสว่าง

ตารางที่ 3-1 สัญลักษณ์ดวงไฟ

สัญลักษณ์	รายละเอียด
	ดวงโคมดาวไลน์
	ดวงโคม LED TUBE
	ดวงโคมนอกอาคาร
	โคมเพดาน

3.1.1.3 สวิตช์ไฟ


ภาพที่ใช้ฝึกสำหรับการตรวจจับสวิตช์ไฟนำมาจากแบบไฟฟ้าและแสงสว่าง ซึ่งระบุตำแหน่งของสวิตช์ที่เชื่อมกับดวงไฟที่ใช้ในบ้าน โดยสัญลักษณ์ของสวิตช์ไฟที่ใช้ในแบบสามารถแบ่งได้ดังตารางที่ 3-2

ตารางที่ 3-2 สัญลักษณ์สวิตช์ไฟ

สัญลักษณ์	รายละเอียด
	สวิตช์ทางเดียว
	สวิตช์สองทาง

3.1.1.4 เ้ารับไฟฟ้า

ภาพที่ใช้ฝึกสำหรับการตรวจจับเ้ารับไฟฟ้านำมาจากแบบเ้ารับไฟฟ้าหรือแบบไฟฟ้ากำลังดังภาพที่ 3-4 ซึ่งเป็นแบบที่ระบุตำแหน่งและประเภทของเ้ารับที่ใช้ในบ้าน เพื่อใช้ในการถอดปริมาณและการติดตั้ง โดยสัญลักษณ์ของเ้ารับไฟฟ้าที่ใช้สามารถแบ่งได้ดังตารางที่ 3-3



ภาพที่ 3-4 ตัวอย่างแบบไฟฟ้ากำลัง

ตารางที่ 3-3 สัญลักษณ์ได้รับไฟฟ้า

สัญลักษณ์	รายละเอียด
 	ได้รับไฟฟ้าคู่ 250V.
 	ได้รับไฟฟ้าคู่ 250V. แบบกันน้ำ

3.1.2 กำหนดตัวแปรสำหรับการฝึกฝนแบบจำลอง

การฝึกฝนแบบจำลองเพื่อใช้ในการตรวจจับวัตถุจำเป็นต้องมีการกำหนดตัวแปรสำหรับการฝึกฝนแบบจำลอง โดยตัวแปรในงานวิจัยที่ให้ความสนใจคือ จำนวนรอบของการฝึก (Epoch) ขนาดหรือความละเอียดของรูปภาพที่นำมาฝึก (Image Size) และจำนวนรูปภาพที่ใช้ในการฝึก

การเปลี่ยนแปลงตัวแปรเหล่านี้ส่งผลต่อระยะเวลาในการฝึกฝนและความสามารถในการตรวจจับวัตถุของแบบจำลอง โดยผู้วิจัยได้แบ่งขั้นตอนการฝึกออกเป็น 2 ขั้นตอน ดังนี้

3.1.2.1 หาความสัมพันธ์ระหว่างขนาดของรูปภาพและจำนวนรอบในการฝึกกับความแม่นยำของแบบจำลอง

ขั้นตอนที่ 1 คือการหาความสัมพันธ์ระหว่างขนาดของรูปภาพและจำนวนรอบในการฝึกโดยกำหนดจำนวนรูปภาพที่ใช้ฝึก (Training Set) 90 รูป รูปตรวจสอบ (Validation Set) 10 รูป สำหรับการตรวจผลลัพธ์ระหว่างการฝึก และแยกรูปภาพสำหรับทดสอบความแม่นยำ (Testing Set) 10 รูป รวมทั้งหมด 110 รูป (กิตติกร และคณะ, 2567)

ทั้ง 3 แบบจำลองจะตั้งค่าเหมือนกัน โดยใช้อัตราการเรียนรู้ (Learning Rate) ที่ 0.001 เนื่องจากค่านี้เป็นค่าที่เหมาะสมสำหรับการฝึก (Agustiansyah และคณะ, 2022) ถ้าค่าต่ำเกินไปจะใช้เวลาในการฝึกนาน แต่ถ้าสูงเกินไปจะส่งผลต่อความแม่นยำของแบบจำลอง จากนั้นทำการกำหนดขนาดรูปที่ใกล้เคียงกับแบบก่อสร้าง โดยมี 3 ขนาดได้แก่ 1700×1200, 1133×800 และ 850×600 พิกเซล และกำหนดจำนวนรอบการฝึก (Epoch) ที่ 40, 60, 80, 100, 120 และ 140 รอบ (Shahinfar และคณะ, 2020) ดังตารางที่ 3-4 จากนั้นทำการหาความแม่นยำโดยการตรวจจับดวงไฟในแบบไฟฟ้าแสงสว่างจากชุดทดสอบจำนวน 10 รูป

ตารางที่ 3-4 จำนวนรูปภาพที่ใช้ฝึกฝนและทดสอบแบบจำลองจากขนาดของรูปภาพและจำนวนรอบการฝึกที่ต่างกัน

		จำนวนรูปภาพ ที่ใช้ฝึกฝน (Training)	จำนวนรูปภาพ ที่ใช้ตรวจสอบ (Validation)	จำนวนรูปภาพ ที่ใช้ทดสอบ (Testing)
ขนาดรูปภาพ	850×600	90	10	10
	1133×800	90	10	10
	1700×1200	90	10	10
จำนวนรอบการ ฝึก (Epoch)	40	90	10	10
	60	90	10	10
	80	90	10	10
	100	90	10	10
	120	90	10	10
	140	90	10	10

3.1.2.2 หาความสัมพันธ์ระหว่างจำนวนรูปภาพที่ใช้ในการฝึกกับความแม่นยำของแบบจำลอง

ขั้นตอนที่ 2 เป็นการนำค่าจำนวนรอบในการฝึกและขนาดของรูปภาพที่เหมาะสมจากขั้นตอนที่ 1 มาใช้ในการฝึกฝนแบบจำลอง โดยกำหนดจำนวนชุดรูปภาพที่ใช้ในการฝึก

100, 150, 200, 250, 300 และ 350 รูป และแบ่งเป็นรูปภาพที่ใช้ฝึกฝน (Training Set) รูปตรวจสอบ (Validation Set) และแยกรูปภาพสำหรับทดสอบ (Testing Set) การตรวจจับดวงไฟ สวิตช์ เติร์ปไฟฟ้า และแบ่งพื้นที่ จำนวนอย่างละ 20 รูป ดังตารางที่ 3-5

ตารางที่ 3-5 จำนวนรูปภาพที่ใช้ฝึกฝนและทดสอบความแม่นยำของแบบจำลองที่ต่างกัน

จำนวนรูปภาพที่ใช้ฝึกฝน (Training)	จำนวนรูปภาพที่ใช้ตรวจสอบ (Validation)	รวมรูปภาพที่ใช้ฝึกฝนกับตรวจสอบ	จำนวนรูปภาพที่ใช้ทดสอบ (Testing)			
			ดวงไฟ	สวิตช์	เติร์ปไฟฟ้า	พื้นที่
90	10	100	20	20	20	20
135	15	150	20	20	20	20
180	20	200	20	20	20	20
225	25	250	20	20	20	20
270	30	300	20	20	20	20
315	35	350	20	20	20	20

3.2 รวบรวมรูปภาพแบบก่อสร้าง


งานวิจัยนี้ได้รวบรวมแบบบ้านพักอาศัย 1 ชั้น และ 2 ชั้น จากกรมโยธาธิการและผังเมือง เว็บไซต์ที่รวบรวมรูปภาพสำหรับการฝึกปัญญาประดิษฐ์ แบบบ้านจากอินเทอร์เน็ต และจากไซต์งานก่อสร้างจริงที่มีรูปแบบแตกต่างกัน โดยแบ่งชุดข้อมูลรูปภาพออกเป็น 3 ชุดได้แก่ ชุดสำหรับฝึก (Training Set) ชุดสำหรับการตรวจสอบ (Validation Set) และชุดสำหรับทดสอบ (Testing Set)

แบบก่อสร้างส่วนใหญ่จะอยู่ในรูปแบบของไฟล์ PDF แต่การฝึกแบบจำลองปัญญาประดิษฐ์จำเป็นต้องแปลงแบบดังกล่าวให้อยู่ในรูปแบบของไฟล์ภาพ ซึ่งสามารถดำเนินการได้ด้วยโปรแกรมสำหรับการอ่าน PDF เช่น Adobe Acrobat Foxit Reader และ Xchange Editor โดยโปรแกรมเหล่านี้สามารถใช้คำสั่ง "Save as" เพื่อเปลี่ยนไฟล์ PDF เป็นรูปภาพโดยตรง หรือสามารถใช้โปรแกรมจับภาพหน้าจอ (Screen Capture) เพื่อแปลงภาพจากหน้าจอให้เป็นไฟล์รูปภาพได้

3.3 เตรียมข้อมูลสำหรับฝึกแบบจำลอง

หลังจากที่ได้รูปภาพจากแบบก่อสร้างแล้ว ขั้นตอนต่อมาคือการจัดเตรียมข้อมูลด้วยการกำหนดวัตถุในรูปภาพ (Mask) โดยในงานวิจัยนี้ได้เลือกใช้โปรแกรม CVAT (Computer Vision Annotation Tool) จากเว็บไซต์ www.cvat.ai เนื่องจากเป็นเครื่องมือที่ใช้งานง่าย และสามารถบันทึกไฟล์ใน

รูปแบบที่รองรับได้หลายแบบจำลอง (Ding and Luo, 2023) โดยการเตรียมข้อมูลด้วยโปรแกรม CVAT มีขั้นตอนแสดงดังภาพที่ 3-5




ภาพที่ 3-5 ขั้นตอนการเตรียมไฟล์ข้อมูลเพื่อใช้ฝึกฝนแบบจำลองด้วยโปรแกรม CVAT


การเตรียมข้อมูลเริ่มต้นจากการสร้างงาน (Task) ผ่านแถบเมนู โดยกดปุ่ม “+” เพื่อกำหนดประเภทและชื่อของวัตถุออกเป็น 4 ประเภท ดังตารางที่ 3-6 จากนั้นทำการแบ่งประเภทวัตถุโดยใช้เครื่องมือ 2 ประเภท ได้แก่เครื่องมือ Rectangle หรือรูปทรงสี่เหลี่ยมสำหรับการตรวจจำวัตถุ และเครื่องมือ Polygon หรือรูปหลายเหลี่ยมสำหรับการแบ่งพื้นที่ห้องดังภาพที่ 3-6 และทำการบันทึกและส่งออกไฟล์ด้วยรูปแบบที่แบบจำลองรองรับ โดยแบ่งออกเป็น 3 ประเภท ได้แก่ไฟล์ COCO สำหรับ Mask R-CNN ไฟล์ YOLO Detection สำหรับ YOLO และ ไฟล์ Segmentation Mask สำหรับ U-Net ดังภาพที่ 3-7

ตารางที่ 3-6 ประเภทและชื่อของวัตถุ

ประเภทของวัตถุ (Class)	ชื่อของวัตถุ (Label)
พื้นที่ห้อง	Room
ดวงไฟ	Light
สวิตช์	switch 1
	switch 2
เต้ารับไฟฟ้า	Socket 1
	Socket 2



ภาพที่ 3-6 การแบ่งประเภทของวัตถุด้วยเครื่องมือ Rectangle และ Polygon ใน CVAT



ภาพที่ 3-7 การบันทึกและส่งออกไฟล์ด้วยรูปแบบที่แบบจำลองรองรับ

3.4 ฝึกฝนแบบจำลองปัญญาประดิษฐ์

ขั้นตอนการฝึกฝนของทั้ง 3 แบบจำลองเหมือนกันและเขียนด้วยภาษา Python ทั้งหมด โดยเริ่มจากการสร้างไฟล์สำหรับการฝึกทั้งหมด 4 ไฟล์ แยกตามประเภทของวัตถุและจากนั้นทำการฝึกตามตัวแปรที่กำหนดไว้ในหัวข้อที่ 3.1.2 โดยใช้ไฟล์ที่ระบุตำแหน่งของวัตถุแล้วจากโปรแกรม CVAT ร่วมกับไฟล์รูปภาพและทำการบันทึกระยะเวลาที่ใช้ในการฝึกแต่ละแบบจำลอง โดยระยะเวลาในการฝึกจะแตกต่างกันตามประเภทของแบบจำลอง จำนวนรูปที่ใช้ฝึก จำนวนรอบการฝึก อัตราการเรียนรู้ และประสิทธิภาพของเครื่องคอมพิวเตอร์

งานวิจัยนี้ใช้เครื่องคอมพิวเตอร์ที่มีหน่วยประมวลผล Intel Core i7-11700 หน่วยความจำหลัก (RAM) ขนาด 16 GB การ์ดจอ NVIDIA GeForce GTX 1650 และเขียนด้วยภาษา Python เป็นเครื่องมือหลักในการฝึกฝนแบบจำลองปัญญาประดิษฐ์ ไลบรารีที่ใช้ในการฝึกแบบจำลอง ได้แก่ TensorFlow และ Pytorch ซึ่งเป็นไลบรารีสำหรับการสร้างแบบจำลองสำหรับการจดจำรูปภาพที่พัฒนาโดย Google และ Facebook

3.5 ทดสอบและประเมินผลแบบจำลอง


ขั้นตอนการทดสอบและประเมินผลทั้ง 3 แบบจำลองเหมือนกัน โดยเริ่มจากการสร้างไฟล์ที่ใช้สำหรับการทดสอบด้วยภาษา Python ทั้งหมด 4 ไฟล์ แยกตามประเภทของวัตถุ และในแต่ละไฟล์จะต้องระบุตำแหน่งของไฟล์ต่างๆ ได้แก่

- 1) ตำแหน่งของไฟล์แบบจำลองที่เรียนรู้แล้ว (Model Path)
- 2) ตำแหน่งของไฟล์รูปที่ใช้ทดสอบ (Input Image Directory)
- 3) ตำแหน่งของไฟล์ที่ใช้บันทึกผลลัพธ์ (Output Image Directory)
- 4) ไฟล์ COCO ระบุตำแหน่งจริงของวัตถุ (COCO Annotation Path)

จากนั้นทำการทดสอบผลลัพธ์ของทั้ง 3 แบบจำลองกับรูปดวงไฟทั้งหมด 10 รูป เพื่อหาขนาดของรูปภาพและจำนวนรอบในการฝึกที่เหมาะสม และนำค่าที่ได้มาใช้ในการฝึกและทดสอบการตรวจจับวัตถุทั้ง 4 ประเภท ประเภทละ 20 รูปเพื่อเปรียบเทียบความแม่นยำของแบบจำลองที่ต่างกัน

3.5.1 ค่าที่ใช้ในการตรวจจับวัตถุ

การประเมินความแม่นยำของแบบจำลองในการตรวจจับวัตถุต้องใช้ค่าทั้งหมด 4 ค่า ได้แก่ True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) ซึ่งได้จากผลลัพธ์จากการตรวจจับวัตถุของแบบจำลอง โดยสามารถหาค่าเหล่านี้ได้ด้วยการนับจากรูปผลการทดสอบของแบบจำลองดังภาพที่ 3-8 (ณิศวรา, กอปร และวุฒิพงษ์, 2566)



ภาพที่ 3-8 ตัวอย่างการหาค่าสำหรับการประเมินความแม่นยำ

ค่าที่ได้จากการตรวจจับมีการจัดเก็บข้อมูลในรูปแบบตาราง โดยแบ่งออกเป็น 2 ขั้นตอนตามหัวข้อที่ 3.1.2 ได้แก่ การเก็บข้อมูลจากการตรวจจับดวงไฟในแบบไฟฟ้าแสงสว่างจากการทดสอบจำนวน 10 รูป จากขนาดของรูปภาพ (Image Size) กับจำนวนรอบการฝึก (Number of Epochs) ที่แตกต่างกันดังตารางที่ 3-7 และการเก็บข้อมูลจากการจากการตรวจจับอุปกรณ์ไฟฟ้าทั้งหมดและการหาพื้นที่จากการทดสอบจำนวน 20 รูป จากจำนวนรูปที่ใช้ในการฝึกที่แตกต่างกันดังตารางที่ 3-8 เพื่อนำไปใช้ในการวิเคราะห์ค่าความแม่นยำและปัจจัยที่ส่งผลต่อความแม่นยำของแบบจำลอง

ตารางที่ 3-7 การเก็บค่า TP,TN,FP,FN จากการขนาดของรูปภาพกับจำนวนรอบการฝึกที่แตกต่างกัน

		ขนาดของรูปภาพ											
		850x600				1133x800				1700x1200			
แบบจำลอง	รอบการฝึก (Epoch)	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
Mask R-CNN	40												
	60												
	80												
	100												
	120												
	140												

ตารางที่ 3-7 (ต่อ)

แบบจำลอง	รอบการฝึก (Epoch)	ขนาดของรูปภาพ											
		850x600				1133x800				1700x1200			
		TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
YOLOv9	40												
	60												
	80												
	100												
	120												
	140												
U-Net	40												
	60												
	80												
	100												
	120												
	140												

ตารางที่ 3-8 การเก็บค่าความแม่นยำจากรูปที่ใช้ทดสอบจากการฝึกด้วยจำนวนรูปที่แตกต่างกัน

แบบจำลอง		จำนวนรูปที่ใช้ฝึก 100 รูป			
		รูปที่ 1	รูปที่ 2	รูปที่	รูปที่ 20
Mask R-CNN	TP				
	TN				
	FP				
	FN				

ตารางที่ 3-8 (ต่อ)

		จำนวนรูปที่ใช้ฝึก 100 รูป			
แบบจำลอง		รูปที่ 1	รูปที่ 2	รูปที่ ...	รูปที่ 20
YOLOv9	TP				
	TN				
	FP				
	FN				
U-Net	TP				
	TN				
	FP				
	FN				

3.5.2 การหาความแม่นยำในการตรวจจับวัตถุ

หลังจากการทดสอบแบบจำลองและเก็บค่าแล้ว สามารถคำนวณค่าความแม่นยำของแบบจำลอง เพื่อนำมาเปรียบเทียบความแม่นยำในการตรวจจับวัตถุและคัดเลือกแบบจำลองที่เหมาะสมสำหรับชุดข้อมูลต่างๆ ดังตารางที่ 3-9 และ 3-10 โดยใช้สมการที่ 3-1 ถึง 3-4 (วรพันธ์ และคณะ, 2567)

$$\text{ความแม่นยำ (Accuracy)} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3-1)$$

$$\text{ความเที่ยงตรง (Precision)} = \frac{TP}{TP+FP} \quad (3-2)$$

$$\text{ค่ารีคอล (Recall)} = \frac{TP}{TP+FN} \quad (3-3)$$

$$\text{ค่าเอฟวัน (F1 Score)} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3-4)$$

ตารางที่ 3-9 เปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์กับขนาดของรูปภาพ
และจำนวนรอบที่ใช้ในการฝึก

แบบจำลอง	จำนวนรอบการฝึก (Epoch)	ความแม่นยำตามขนาดของรูปภาพ		
		850x600	1133x800	1700x1200
Mask R-CNN	40			
	60			
	80			
	100			
	120			
	140			
YOLOv9	40			
	60			
	80			
	100			
	120			
	140			
U-Net	40			
	60			
	80			
	100			
	120			
	140			

หมายเหตุ ค่าความแม่นยำที่คำนวณได้มีหน่วยเป็นเปอร์เซ็นต์

ตารางที่ 3-10 เปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์กับจำนวนรูปที่ใช้ในการฝึก

	ความแม่นยำตามจำนวนรูปภาพที่ใช้ในการฝึก					
แบบจำลอง	100	150	200	250	300	350
Mask R-CNN						
YOLOv9						
U-Net						

หมายเหตุ ค่าความแม่นยำที่คำนวณได้มีหน่วยเป็นเปอร์เซ็นต์

ค่าความแม่นยำ (Accuracy) เป็นตัวชี้วัดประสิทธิภาพในการทำนายของแบบจำลอง โดยคำนวณจากผลลัพธ์ที่ทำนายถูกต้องทั้งหมดเทียบกับผลลัพธ์ทั้งหมด

ความเที่ยงตรง (Precision) ใช้ประเมินความน่าเชื่อถือของผลลัพธ์ โดยเทียบวัตถุที่ทำนายถูกต้องกับวัตถุที่ทำนายทั้งหมด

ค่ารีคอล (Recall) เป็นค่าที่บอกความสามารถของแบบจำลองในการตรวจจับวัตถุที่ทำนายถูกต้อง เทียบกับจำนวนวัตถุจริงทั้งหมดในภาพ เพื่อตรวจความผิดพลาดของแบบจำลอง

ค่าเอฟวัน (F1 Score) เป็นค่าเฉลี่ยระหว่าง Precision และ Recall ซึ่งเป็นค่าที่ประเมินประสิทธิภาพของแบบจำลอง โดยแบบจำลองที่มีประสิทธิภาพควรมีค่าเอฟวันที่ 90 เปอร์เซ็นต์หรือมากกว่า (Agustiansyah และคณะ, 2022)

ผลลัพธ์ของค่าความแม่นยำ (Accuracy) ค่าความเที่ยงตรง (Precision) ค่ารีคอล (Recall) และ ค่าเอฟวัน (F1-score) จะถูกนำไปสร้างเป็นแผนภาพเพื่อการวิเคราะห์และประเมินระดับการเพิ่มขึ้นจากการเปลี่ยนแปลงตัวแปรที่ใช้ในการฝึกฝน โดยข้อมูลจะถูกจัดเป็น 3 ระดับ ดังนี้

เพิ่มขึ้นมาก หมายถึงค่าเพิ่มขึ้นมากกว่า 20% จากค่าก่อนหน้า

เพิ่มขึ้นปานกลาง หมายถึงค่าเพิ่มขึ้นระหว่าง 10-20% จากค่าก่อนหน้า


เพิ่มขึ้นน้อย หมายถึงเพิ่มขึ้นน้อยกว่า 10% จากค่าก่อนหน้า

3.5.3 การหาความแม่นยำในการแบ่งพื้นที่ห้อง

3.5.3.1 การหาความแม่นยำจากค่า IOU

การหาความแม่นยำของแบบจำลองที่ใช้ในการแบ่งพื้นที่ห้อง (Room Segmentation) จะใช้ค่า Intersection Over Union (IOU) ซึ่งเป็นค่าที่ได้จากการซ้อนทับกันระหว่างพื้นที่ทำนายและพื้นที่จริงดังภาพที่ 3-9 โดยใช้สมการที่ 3-5 (He และคณะ, 2017)

$$\text{ค่า IOU} = \frac{\text{พื้นที่ทำนาย}}{\text{พื้นที่จริง}} \quad (3-5)$$



ภาพที่ 3-9 การหาค่า IOU

3.5.3.2 การหาความแม่นยำจากการเปรียบเทียบตารางเมตร

หลังจากที่หาค่าความแม่นยำของแบบจำลองในการแบ่งพื้นที่จาก IOU แล้ว ขั้นตอนต่อไปคือการแปลงจากหน่วยพิกเซลให้เป็นหน่วยตารางเมตร โดยแบ่งออกเป็น 3 ขั้นตอนดังภาพที่ 3-10 ได้แก่ 1.นับจำนวนพิกเซลทั้งหมดจากพื้นที่ที่ผ่านการตรวจจบบจากแบบจำลอง 2.หาค่าพิกเซลต่อตารางเมตรจากเส้นขอบระยะในแบบจำนวน 3 เส้น และนำค่าที่ได้มาแปลงเป็นหน่วยตารางเมตรโดยใช้สมการที่ 3-6 และ 3-7



ภาพที่ 3-10 ขั้นตอนการแปลงจากหน่วยพิกเซลให้เป็นหน่วยตารางเมตร

$$\text{ค่าพิกลเซตต่อตารางเมตร} = \left(\frac{\text{จำนวนพิกลเซตจากเส้นระยะจากแบบก่อสร้าง}}{\text{ความยาวของเส้นระยะในแบบ}} \right)^2 \quad (3-6)$$

$$\text{พื้นที่ตรวจจับ} = \frac{\text{จำนวนพิกลเซตที่แบบจำลองทำนาย}}{\text{ค่าพิกลเซตต่อตารางเมตร}} \quad (3-7)$$

เมื่อได้ค่าพื้นที่ที่แปลงเป็นตารางเมตรแล้ว นำค่าดังกล่าวไปใช้ในการหาค่าความแม่นยำของทั้ง 3 แบบจำลอง โดยใช้สมการที่ 3-8 เพื่อเปรียบเทียบกับค่า IOU และวิเคราะห์แบบจำลองที่มีความแม่นยำสูงที่สุดในการแบ่งพื้นที่

$$\text{ความแม่นยำ (\%)} = 100 - \left(\left| \frac{\text{พื้นที่ที่ตรวจจับ} - \text{พื้นที่จากการถอดปริมาณด้วยมือ}}{\text{พื้นที่จากการถอดปริมาณด้วยมือ}} \right| \right) \times 100 \quad (3-8)$$

3.6 เปรียบเทียบผลการถอดปริมาณด้วยแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ

การเก็บข้อมูลจากการถอดปริมาณด้วยมือในงานวิจัยนี้ได้ดำเนินการ โดยการจัดทำแบบทดสอบ และแจกให้กับกลุ่มเป้าหมายที่มีประสบการณ์ในการถอดปริมาณจากแบบก่อสร้าง โดยแบ่งออกเป็น 4 หัวข้อ ได้แก่ ความแม่นยำในการถอดปริมาณ ระยะเวลาในการดำเนินการ ความคิดเห็นและข้อเสนอแนะจากผู้ใช้งาน และความสามารถในการถอดปริมาณได้อย่างต่อเนื่อง


3.6.1 วิธีการเก็บข้อมูล

3.6.1.1 การเก็บข้อมูลความแม่นยำและระยะเวลาในการถอดปริมาณด้วยมือ


การเก็บข้อมูลเพื่อเปรียบเทียบความแม่นยำและระยะเวลาในการถอดปริมาณงานระหว่างการถอดปริมาณด้วยมือกับปัญญาประดิษฐ์ จะทำการเก็บข้อมูลโดยใช้แบบทดสอบ ซึ่งตัวอย่างแบบทดสอบดังกล่าวได้แสดงไว้ในภาคผนวก ก เพื่อเปรียบเทียบผลลัพธ์จากการนับจำนวนดวงไฟ สวิตช์ไฟ เตารับไฟฟ้า รวมถึงการแบ่งพื้นที่จากแบบบ้าน โดยแบ่งออกเป็น 2 ส่วน

ส่วนที่ 1 ข้อมูลทั่วไปประกอบด้วย ชื่อ ประสบการณ์ทำงาน และตำแหน่งงาน


ส่วนที่ 2 แบบทดสอบการถอดปริมาณงาน ประกอบด้วยการนับจำนวนอุปกรณ์ไฟฟ้าและถอดปริมาณพื้นที่จากแบบบ้าน 3 หลัง ประกอบด้วย บ้านชั้นเดียวจำนวน 2 หลัง และบ้าน 2 ชั้นจำนวน 1 หลัง รวมทั้งหมด 4 แบบดังภาพที่ 3-11 ถึง 3-13 โดยในแบบทดสอบจะทำการจับเวลาในการดำเนินการโดยอัตโนมัติ



ภาพที่ 3-11 ตัวอย่างแบบดวงไฟและสวิตช์ไฟในแบบทดสอบ



ภาพที่ 3-12 ตัวอย่างแบบได้รับไฟฟ้าในแบบทดสอบ



ภาพที่ 3-13 ตัวอย่างแบบที่ใช้หาพื้นที่ในแบบทดสอบ

ขั้นตอนต่อไปคือการวิเคราะห์ข้อมูล โดยการคำนวณค่าเฉลี่ยความแม่นยำของผลลัพธ์ที่ได้จากการนับอุปกรณ์ไฟฟ้าและการถอดปริมาณพื้นที่จากแบบทดสอบ โดยใช้สมการที่ 3-9 และ 3-10

$$\text{ความแม่นยำ (\%)} = 100 - \left(\frac{\text{จำนวนวัตถุหรือการแบ่งพื้นที่ด้วยมือ} - \text{จำนวนวัตถุหรือพื้นที่จริง}}{\text{จำนวนวัตถุหรือพื้นที่จริง}} \right) \times 100 \quad (3-9)$$

$$\text{ค่าเฉลี่ยความแม่นยำ (\%)} = \frac{\sum \text{ความแม่นยำทั้งหมด}}{\text{จำนวนผู้ทำแบบทดสอบ}} \quad (3-10)$$

ค่าเฉลี่ยความแม่นยำที่ได้จากการทดสอบมีหน่วยเป็นเปอร์เซ็นต์ โดยนำผลลัพธ์มาจัดทำเป็นแผนภาพแสดงความสัมพันธ์ระหว่างค่าความแม่นยำกับระดับประสบการณ์ทำงานของผู้ทดสอบ ซึ่งแบ่งออกเป็น 3 กลุ่ม ได้แก่ ประสบการณ์ทำงานระหว่าง 1-5 ปี ประสบการณ์ทำงาน 5-10 ปี และประสบการณ์ทำงาน 10 ปีขึ้นไป เพื่อวิเคราะห์แนวโน้มความแม่นยำจากประสบการณ์ทำงานที่เพิ่มขึ้น พร้อมทั้งทำการเปรียบเทียบกับค่าความแม่นยำของแบบจำลองปัญญาประดิษฐ์ที่มีประสิทธิภาพดีที่สุด (Best Model)

หลังจากการเปรียบเทียบความแม่นยำระหว่างแบบจำลองกับการถอดปริมาณด้วยมือแล้ว ขั้นตอนต่อไปคือการเปรียบเทียบด้านระยะเวลาในการทำงาน โดยได้จัดทำตารางเปรียบเทียบระยะเวลาเฉลี่ยที่ใช้ในการถอดปริมาณด้วยมือแยกตามประสบการณ์ทำงาน กับระยะเวลาที่แบบจำลองใช้ในการตรวจจับ ดังตารางที่ 3-11

ตารางที่ 3-11 เปรียบเทียบระยะเวลาในการนับวัตถุและแบ่งพื้นที่กับแบบจำลองปัญญาประดิษฐ์

	ระยะเวลาที่ใช้ (วินาที)			
	ดวงไฟ	สวิตช์ไฟ	เต้ารับ	แบ่งพื้นที่
แบบจำลอง				
Mask R-CNN				
YOLOv9				
U-Net				
การถอดปริมาณด้วยมือ				
ประสบการณ์ 1-5 ปี				
ประสบการณ์ 5-10 ปี				
ประสบการณ์ 10 ปีขึ้นไป				

3.6.1.2 ความสามารถในการถอดปริมาณได้อย่างต่อเนื่อง

การเก็บข้อมูลเพื่อประเมินความสามารถในการถอดปริมาณอย่างต่อเนื่องและความล่าช้าของผู้ทดสอบ ดำเนินการโดยให้ผู้ทดสอบทำการนับจำนวนดวงไฟ สวิตช์ไฟ และเต้ารับไฟฟ้าอย่างละ 20 แบบ รวมทั้งสิ้น 60 แบบ พร้อมทั้งบันทึกเวลาในการทำแต่ละชุด โดยลักษณะการทดสอบมีความคล้ายกับการประเมินความแม่นยำและระยะเวลาในการถอดปริมาณ แต่มีวัตถุประสงค์

หลักเพื่อใช้วิเคราะห์ความสามารถของผู้ทดสอบในการทำงานอย่างต่อเนื่องจนรู้สึกเหนื่อยล้าและจำเป็นต้องหยุดพัก

3.6.1.3 การเก็บข้อมูลความคิดเห็นและข้อเสนอแนะจากผู้ใช้งาน

หลังจากที่ผู้เข้าร่วมการทดสอบได้ทำการถอดปริมาณด้วยมือเสร็จสิ้นแล้ว จะต้องทำการตอบแบบสอบถามจำนวน 3 ข้อ เพื่อใช้ในการศึกษามุมมองของผู้ใช้งานต่อการประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ในการถอดปริมาณงานก่อสร้าง โดยแบบสอบถามดังกล่าวจะครอบคลุมประเด็นสำคัญ ได้แก่ ระดับความยุ่งยากและความยอมรับของผู้ใช้งานต่อผลลัพธ์ของแบบจำลองในกรณีที่มีความแม่นยำอยู่ในช่วง 80% ถึง 90% ความเป็นไปได้ในการนำระบบไปประยุกต์ใช้ในกระบวนการประมาณราคา และข้อเสนอแนะหรือแนวทางในการปรับปรุงระบบ

3.6.2 เครื่องมือในการเก็บข้อมูล

เครื่องมือที่ใช้ในการรวบรวมข้อมูลจากการถอดปริมาณด้วยมือในงานวิจัยนี้คือเว็บไซต์ www.psychtoolkit.org ซึ่งเป็นเว็บไซต์สำหรับการสร้างและเผยแพร่แบบสอบถามหรือแบบทดสอบออนไลน์ โดยเครื่องมือนี้จะทำการสอบถามผู้ใช้งานทีละคำถาม พร้อมทั้งบันทึกเวลาในการตอบคำถามแต่ละข้อโดยอัตโนมัติ ทำให้สามารถเก็บข้อมูลได้อย่างแม่นยำ ดังภาพที่ 3-14 และ 3-15

ประสบการณ์ทำงานในสายงานก่อสร้าง/ถอดปริมาณ

☐ น้อยกว่า 5 ปี

☐ 5 - 10 ปี


☐ 10 ปีขึ้นไป

Click this button to continue

ตำแหน่งงานปัจจุบัน (เช่น วิศวกรสนาม, ผู้ควบคุมงาน, ผู้ประมาณราคา)

Click this button to continue

ภาพที่ 3-14 ตัวอย่างหน้าคำถามข้อมูลทั่วไปในแบบทดสอบจาก Psychtoolkit



ภาพที่ 3-15 ตัวอย่างหน้าคำถามการถอดปริมาณงานจาก Psytokit

3.6.3 การวิเคราะห์และสรุปผล

ขั้นตอนการวิเคราะห์และสรุปผลในงานวิจัยนี้เริ่มจากการรวบรวมผลลัพธ์ที่ได้จากการปรับค่าไฮเปอร์พารามิเตอร์ของแบบจำลองปัญญาประดิษฐ์ทั้ง 3 แบบ ได้แก่ Mask R-CNN, YOLOv9 และ U-Net เพื่อหาค่าพารามิเตอร์สำหรับการฝึกแบบจำลองแต่ละประเภทที่ส่งผลให้ผลลัพธ์เริ่มคง จากนั้นทำการเปรียบเทียบผลของแบบจำลองจากค่าความแม่นยำ (Accuracy) และค่า IOU เพื่อหาแบบจำลองที่ให้ผลลัพธ์ในการตรวจจับและการแบ่งพื้นที่จากแบบก่อสร้างที่ดีที่สุดในแต่ละประเภทของอุปกรณ์ระบบไฟฟ้า

หลังจากนั้นงานวิจัยนี้ได้เปรียบเทียบผลความแม่นยำของแบบจำลองกับผลการถอดปริมาณด้วยมือจากกลุ่มตัวอย่าง ซึ่งเป็นผู้มีประสบการณ์ในการถอดปริมาณงานจากแบบก่อสร้าง เพื่อทำการวิเคราะห์ 2 หัวข้อ ได้แก่

- 1) ความแม่นยำของแบบจำลองเทียบกับระดับประสบการณ์ทำงาน เพื่อประเมินว่าแบบจำลองมีความสามารถเทียบเท่ากับผู้ที่ม่ประสบการณ์ก็ปี
- 2) ระยะเวลาในการถอดปริมาณ เพื่อเปรียบเทียบประสิทธิภาพด้านเวลาในการทำงานระหว่างแบบจำลองกับการถอดปริมาณด้วยมือ

นอกจากนี้ยังได้ทำการวิเคราะห์จำนวนแบบก่อสร้างที่ผู้เข้าร่วมสามารถถอดปริมาณได้อย่างต่อเนื่องก่อนจำเป็นต้องหยุดพักในระหว่างการทดสอบ และรวบรวมความคิดเห็นของกลุ่มผู้ใช้งานเกี่ยวกับความแม่นยำของแบบจำลอง ความเหมาะสมในการนำแบบจำลองไปใช้ในงานจริง และข้อเสนอแนะเพื่อการปรับปรุงและพัฒนาในอนาคต

บทที่ 4

ผลการวิจัย

การศึกษาค้นคว้าครั้งนี้มีวัตถุประสงค์เพื่อศึกษาปัจจัยที่มีผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์ และเปรียบเทียบผลความแม่นยำในการตรวจจับวัตถุในงานระบบไฟฟ้า และพื้นที่อาคารในแบบก่อสร้าง จากแบบจำลอง 3 ประเภท ได้แก่ Mask R-CNN, YOLOv9 และ U-Net โดยแบ่งผลการวิจัยเป็นทั้งหมด 2 หัวข้อ ดังนี้

หัวข้อที่ 1 ปัจจัยที่ส่งผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์

หัวข้อที่ 2 เปรียบเทียบผลความแม่นยำจากการถอดปริมาณด้วยแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ

4.1 ปัจจัยที่ส่งผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์

4.1.1 จำนวนรอบการฝึกและขนาดของรูปภาพที่เหมาะสม

หลังจากที่ดำเนินการรวบรวมข้อมูลภาพ เตรียมข้อมูลสำหรับการฝึกแบบจำลอง และฝึกฝนแบบจำลองปัญญาประดิษฐ์ตามหัวข้อที่ 3.2 แล้ว ขั้นตอนแรกคือการวิเคราะห์ความแม่นยำของแบบจำลอง จากการฝึกด้วยภาพ และจำนวนรอบการฝึกที่ต่างกัน


ทั้ง 3 แบบจำลองถูกฝึกโดยใช้ชุดข้อมูลที่มีจำนวนรูปสำหรับการฝึก 100 รูป โดยแบ่งเป็นชุดฝึก (Training Set) 90 รูป ชุดตรวจสอบ (Validation Set) 10 รูป กำหนดอัตราการเรียนรู้ (Learning Rate) ที่ 0.001 ฝึกด้วยรูปภาพ 3 ขนาด ได้แก่ 850×600, 1133×800 และ 1700×1200 พิกเซล และจำนวนรอบการฝึก (Epochs) 40, 60, 80, 100, 120 และ 140 รอบ ดังภาพที่ 4-1 เพื่อประเมินขนาดรูปภาพและจำนวนรอบการฝึกที่เหมาะสมสำหรับการฝึกแบบจำลองในขั้นตอนต่อไป

```
# Configurations
image_dir = r'C:\Users\knite\Desktop\code\Unet\trainimage\Roomred\ima2'
mask_dir = r'C:\Users\knite\Desktop\code\Unet\trainimage\Roomred\Ma3'
learning_rate, epochs, img_size = 0.001, 100, (1700,1200)
base_filename = "Redroom"
save_every = 20
save_dir = r'C:\Users\knite\Desktop\code\Unet\weights'
```


Learning Rate	Epochs	Image size
---------------	--------	------------

ภาพที่ 4-1 การตั้งค่าพารามิเตอร์สำหรับการฝึกแบบจำลอง


การแสดงผลการตรวจจับวัตถุโดยใช้แบบจำลองแต่ละแบบมีความแตกต่างกัน โดยแบบจำลอง YOLOv9 แสดงผลเป็นกรอบสี่เหลี่ยมล้อมรอบวัตถุ (Bounding Box) ส่วนแบบจำลอง Mask R-CNN และ U-Net แสดงผลในรูปแบบการระบายสีวัตถุในภาพ (Segmentation Mask) ดังภาพที่ 4-2 ถึง 4-4



ภาพที่ 4-2 ผลลัพธ์จากแบบจำลอง Mask R-CNN




ภาพที่ 4-3 ผลลัพธ์จากแบบจำลอง YOLOv9



ภาพที่ 4-4 ผลลัพธ์จากแบบจำลอง U-Net

ผลการตรวจจับวัตถุจากชุดทดสอบ (Testing Set) จำนวน 10 รูป ดังตัวอย่างในภาพที่ 4-2 ถึง 4-4 มาหาค่า True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) ดังตัวอย่างในภาพที่ 4-5 ซึ่งจากแบบมีดวงไฟทั้งหมด 14 ดวง แต่แบบจำลองไม่สามารถตรวจจับดวงไฟได้ถูกต้องทั้งหมด โดยมีค่า True Positive เท่ากับ 12 ค่า True Negative เท่ากับ 0 ค่า False Positive เท่ากับ 2 และค่า False Negative เท่ากับ 2 เมื่อได้ค่าเหล่านี้แล้วจึงนำมาหาความแม่นยำตามสมการที่ 3-1 ในแต่ละการทดสอบ ได้ดังตารางที่ 4-1 และหาค่าเฉลี่ยของความแม่นยำแยกตามจำนวนรอบการฝึก ขนาดของรูปภาพ และประเภทของแบบจำลอง ได้ดังตารางที่ 4-2



ภาพที่ 4-5 ตัวอย่างการหาค่าสำหรับประเมินความแม่นยำ

ตารางที่ 4-1 ผลจากการตรวจจับดวงไฟทั้ง 3 แบบจำลอง จากการฝึกด้วยขนาดของรูปภาพ
และจำนวนรอบในการฝึกที่แตกต่างกัน

แบบจำลอง	จำนวนรอบการฝึก (Epoch)	ขนาดของรูปภาพที่ใช้ฝึก											
		850x600				1133x800				1700x1200			
		TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
Mask R-CNN	40	14	0	8	0	14	0	3	0	14	0	2	0
	60	14	0	4	0	14	0	3	0	14	0	2	0
	80	14	0	4	0	14	0	2	0	14	0	0	0
	100	14	0	3	0	14	0	2	0	14	0	0	0
	120	14	0	1	0	14	0	0	0	14	0	1	0
	140	14	0	0	0	14	0	0	0	14	0	0	0
YOLOv9	40	4	0	1	10	3	0	0	11	4	0	1	10
	60	4	0	0	10	11	0	0	3	11	0	0	3
	80	5	0	0	9	13	0	0	1	12	0	0	2
	100	6	0	0	8	14	0	2	0	14	0	2	0
	120	7	0	4	7	14	0	3	0	14	0	3	0
	140	7	0	2	7	14	0	2	0	14	0	3	0
U-Net	40	5	0	4	9	5	0	3	9	5	0	3	9
	60	10	0	2	4	10	0	2	4	10	0	3	4
	80	14	0	2	0	14	0	2	0	14	0	2	0
	100	14	0	2	0	14	0	2	0	14	0	2	0
	120	14	0	2	0	14	0	2	0	14	0	2	0
	140	14	0	2	0	14	0	2	0	14	0	2	0

ตารางที่ 4-2 ผลความแม่นยำเฉลี่ยจากการตรวจจับดวงไฟทั้งแบบจำลอง จากการฝึกด้วยขนาดของรูปภาพและจำนวนรอบในการฝึกที่แตกต่างกัน


แบบจำลอง	จำนวนรอบการฝึก (Epoch)	ความแม่นยำ (Accuracy) ตามขนาดของรูปภาพ		
		850x600	1133x800	1700x1200
Mask R-CNN	40	55%	57%	71%
	60	60%	67%	75%
	80	73%	74%	79%
	100	75%	77%	81%
	120	77%	78%	82%
	140	77%	78%	82%
YOLOv9	40	44%	58%	76%
	60	56%	76%	87%
	80	61%	84%	91%
	100	68%	88%	92%
	120	71%	89%	92%
	140	71%	89%	92%
U-Net	40	55%	64%	71%
	60	55%	65%	70%
	80	62%	72%	76%
	100	69%	79%	79%
	120	71%	80%	83%
	140	71%	81%	84%

ตารางที่ 4-1 และ 4-2 แสดงว่าขนาดของรูปภาพและจำนวนรอบในการฝึกมีผลต่อความแม่นยำในการตรวจจับดวงไฟ โดยแบบจำลอง Mask R-CNN เป็นแบบจำลองที่มีความสามารถในการตรวจจับวัตถุสูงที่สุด ซึ่งสามารถตรวจจับวัตถุที่มีลักษณะคล้ายกับดวงไฟทั้งหมดแต่มีค่า True Positive (TP) และ False Positive (FP) สูงตามไปด้วย

แบบจำลอง YOLOv9 มีค่า False Positive (FP) ต่ำที่สุดจากทุกแบบจำลอง แต่มีค่าของ True Positive (TP) ค่อนข้างต่ำในช่วงที่จำนวนรอบการฝึก (Epochs) น้อย ซึ่งสามารถปรับปรุงได้โดยการเพิ่มจำนวนรอบการฝึก (Epochs) และใช้ภาพขนาดใหญ่ขึ้นในการฝึกฝนแบบจำลอง

แบบจำลอง U-Net แสดงผลลัพธ์การตรวจจับที่มีลักษณะใกล้เคียงกับ Mask R-CNN แต่มีค่าของ False Positive (FP) ต่ำกว่า จากการฝึกด้วยขนาดของรูปภาพและจำนวนรอบการฝึกที่เท่ากัน

เมื่อนำผลการตรวจจับดวงไฟของแต่ละแบบจำลอง โดยใช้รูปภาพขนาด 1700×1200 พิกเซล ซึ่งเป็นขนาดของรูปภาพที่ให้ผลความแม่นยำสูงที่สุด มาเปรียบเทียบกับระยะเวลาที่ใช้ในการฝึกฝนดังภาพที่ 4-6 พบว่า ความแม่นยำเพิ่มขึ้นมากกว่า 10% ทุกๆ รอบการฝึก (Epoch) ที่เพิ่มขึ้น 10 รอบ ในช่วงรอบการฝึกไม่เกิน 40 รอบ และค่าความแม่นยำเพิ่มขึ้นไม่เกิน 5% ทุกๆ รอบการฝึกที่เพิ่มขึ้น 10 รอบ ในช่วงรอบการฝึกระหว่าง 40–80 รอบ และค่าความแม่นยำเพิ่มขึ้นเพียงเล็กน้อยหรือแทบไม่เพิ่มขึ้นเลยในช่วงรอบการฝึกตั้งแต่ 80 รอบขึ้นไป ในขณะที่ระยะเวลาในการฝึกแปรผันโดยตรงกับจำนวนรอบการฝึก ดังนั้นจากผลการทดสอบดังกล่าว จึงเลือกใช้ขนาดรูปภาพ 1700×1200 พิกเซล และจำนวนรอบการฝึก 80 รอบ สำหรับการฝึกและวิเคราะห์ความแม่นยำของแบบจำลองในหัวข้อต่อไป




ภาพที่ 4-6 แผนภาพเปรียบเทียบความแม่นยำและระยะเวลาที่ใช้ในการฝึกฝนของทั้ง 3 แบบจำลอง จากการฝึกด้วยรูปภาพขนาด 1700×1200 พิกเซล

4.1.2 จำนวนรูปภาพที่ใช้ในการฝึก

หลังจากที่ได้กำหนดขนาดของรูปภาพและจำนวนรอบการฝึก (Epochs) ที่เหมาะสมแล้ว ขั้นตอนต่อไปคือ การประเมินความแม่นยำของแบบจำลองจากการฝึกด้วยจำนวนรูปภาพที่ต่างกัน เพื่อวิเคราะห์ความแม่นยำจากการเพิ่มปริมาณรูปภาพในการฝึก โดยแบ่งเป็น 2 หัวข้อ ดังนี้

4.1.2.1 การตรวจจับวัตถุระบบไฟฟ้า

ในการฝึกแบบจำลองเพื่อตรวจจับวัตถุในแบบระบบไฟฟ้า ได้กำหนดค่าไฮเปอร์พารามิเตอร์ที่ใช้สำหรับการฝึกทั้ง 3 แบบจำลองได้แก่ อัตราการเรียนรู้ (Learning Rate) ที่ 0.001 จำนวนรอบการฝึก (Epochs) 80 รอบ ขนาดของรูปภาพ (Image size) 1700x1200 พิกเซล และการทดสอบนี้ดำเนินการกับวัตถุทั้งหมด 3 ประเภทได้แก่ ดวงไฟ สวิตช์ไฟ และเต้ารับไฟฟ้า โดยใช้ชุดข้อมูลที่มีจำนวนรูปตั้งแต่ 100 ถึง 350 รูป ในการฝึกแบบจำลองและได้ผลลัพธ์การตรวจจับดังตัวอย่างในภาพที่ 4-7 ถึง 4-9



ภาพที่ 4-7 ตัวอย่างผลลัพธ์จากการตรวจจับดวงไฟ




ภาพที่ 4-8 ตัวอย่างผลลัพธ์จากการตรวจจับสวิตช์ไฟ




ภาพที่ 4-9 ตัวอย่างผลลัพธ์จากการตรวจจับเตารีดไฟฟ้า

หลังจากที่ได้ผลลัพธ์จากการตรวจจับจากชุดทดสอบ (Testing Set) จำนวน 20 รูปแล้ว ทำการเก็บค่าจากการทดสอบ 4 ตัว ได้แก่ True Positive (TP), True Negative (TN), False Positive (FP) และ False Negative (FN) และคำนวณหาความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) ค่ารีคอล (Recall) และค่าเอฟวัน (F1 Score) เฉลี่ย ตามสมการที่ 3-1 ถึง 3-4 จากหัวข้อที่ 3.5.2 โดยรายละเอียดผลการทดสอบแสดงในภาคผนวก ข และผลความแม่นยำของแต่ละแบบจำลองแสดงดังภาพที่ 4-10 ถึง 4-12 ตามประเภทของวัตถุที่ใช้ในการฝึก




ภาพที่ 4-10 แผนภาพแสดงค่าชี้วัดของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200

และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับวงไฟ



ภาพที่ 4-11 แผนภาพแสดงค่าชี้วัดของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200 และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับสวิตช์ไฟ



ภาพที่ 4-12 แผนภาพแสดงค่าชีวิตของทั้ง 3 แบบจำลองจากการใช้ภาพขนาด 1700x1200

และจำนวนรอบในการฝึก 80 รอบ ในการตรวจจับตัวรับไฟฟ้า


ภาพที่ 4-10 ถึง 4-12 แสดงให้เห็นว่า การเพิ่มจำนวนรูปภาพที่ใช้ในการฝึก ส่งผลต่อค่าความแม่นยำ (Accuracy) และค่ารีคอล (Recall) ซึ่งมีแนวโน้มเพิ่มขึ้นมาก หรือเพิ่มขึ้นมากกว่า 20% ในช่วงรูปภาพที่ใช้ในการฝึก 100 ถึง 250 รูป และมีการเพิ่มขึ้นเพียงเล็กน้อยหรือน้อยกว่า 10% ในช่วงรูปภาพ 250 รูปขึ้นไป ส่วนค่าความเที่ยงตรง (Precision) และค่าเอฟวัน (F1 Score) มีการเปลี่ยนแปลงน้อยหรือน้อยกว่า 10% จากค่าก่อนหน้านี้ โดยค่าความแม่นยำ (Accuracy) เฉลี่ยของทั้ง 3 แบบจำลอง ได้แก่ Mask R-CNN, YOLOv9 และ U-Net ในการตรวจจับวัตถุทั้ง 3 ประเภท อยู่ในระดับมากกว่า 80% เมื่อใช้จำนวนรูปภาพฝึก 250 รูปขึ้นไป และมีการเพิ่มขึ้นเพียงเล็กน้อยในช่วง 250 ถึง 350 รูป

4.1.2.2 การแบ่งพื้นที่ห้อง


หลังจากที่ทำการฝึกแบบจำลองเพื่อตรวจระบบไฟฟ้าในแบบก่อสร้างแล้ว ขั้นตอนต่อไปคือการฝึกแบบจำลองเพื่อแบ่งพื้นที่ห้อง โดยกำหนดค่าไฮเปอร์พารามิเตอร์สำหรับการฝึกแบบจำลองเหมือนกับการตรวจจับวัตถุที่ ได้แก่ อัตราการเรียนรู้ (Learning Rate) ที่ 0.001 จำนวนรอบการฝึก (Epochs) 80 รอบ และขนาดของรูปภาพ (Image Size) 1700x1200 พิกเซล

4.1.2.2.1 ค่า IOU จากการแบ่งพื้นที่ห้อง

ในหัวข้อนี้ได้ใช้แบบจำลองในการแบ่งพื้นที่ห้องจากรูปแบบก่อสร้าง โดยใช้ชุดข้อมูลในการฝึก 100 ถึง 350 รูป ในการฝึกแบบจำลอง จากนั้นทำการคำนวณค่า IOU เฉลี่ยจากการทดสอบด้วยรูปจำนวน 20 รูป ตามสมการที่ 3-5 โดยการนำพื้นที่จริงซ้อนทับกับพื้นที่ทำนาย ดังภาพที่ 4-13 และ 4-14




ภาพที่ 4-13 ตัวอย่างผลลัพธ์จากการแบ่งพื้นที่ห้อง



ภาพที่ 4-14 ตัวอย่างพื้นที่จริงสำหรับการหาค่า IOU


การเพิ่มจำนวนรูปภาพที่ใช้ในการฝึกแบบจำลอง ส่งผลต่อค่า IOU ซึ่งมีแนวโน้มเพิ่มขึ้นตามจำนวนรูปภาพที่ใช้ในการฝึกดังภาพที่ 4-15 โดยค่า IOU เฉลี่ยของทั้ง 3 แบบจำลองเพิ่มขึ้นปานกลางหรือเพิ่มขึ้นระหว่าง 10-20% ในช่วงรูปภาพที่ใช้ในการฝึก 100 ถึง 250 รูป และเพิ่มขึ้นน้อยหรือเพิ่มขึ้นน้อยกว่า 10% ในช่วงรูปภาพที่ใช้ในการฝึก 250 ถึง 350 รูป ซึ่งได้ผลลัพธ์คล้ายกับการฝึกแบบจำลองเพื่อตรวจจับอุปกรณ์ระบบไฟฟ้า



ภาพที่ 4-15 แผนภาพแสดงค่า IOU จากการแบ่งพื้นที่ห้อง

4.1.2.2.2 การหาความแม่นยำจากการเปรียบเทียบตารางเมตร


แบบที่ผ่านการประมวลผลด้วยแบบจำลองดังภาพที่ 4-16 แสดงในรูปแบบการระบายสีบนรูป และได้ค่าพื้นที่เป็นหน่วยพิกเซลตามขนาดของภาพ โดยการนำข้อมูลดังกล่าวไปประยุกต์ใช้ในการทำงานจริง จำเป็นต้องแปลงหน่วยจากพิกเซลเป็นตารางเมตร ซึ่งสามารถดำเนินการได้ โดยมีทั้งหมด 3 ขั้นตอนดังนี้



ภาพที่ 4-16 ผลการแบ่งพื้นที่จากแบบจำลอง

ขั้นตอนที่ 1 นับจำนวนพิกเซลทั้งหมดจากพื้นที่ที่ผ่านการตรวจจับจากแบบจำลอง

ขั้นตอนที่ 2 นำวิธี EasyOCR มาใช้ในการตรวจหาตัวเลขที่ปรากฏบนแบบ เช่น 1.00, 2.00, 3.00 เป็นต้น จากนั้นระบบจะทำการค้นหาเส้นที่อยู่ใกล้กับตัวเลขโดยอัตโนมัติจำนวน 3 ครั้ง และให้ผู้ใช้งานกรอกระยะจริงของเส้นที่ตรวจจับได้ เพื่อใช้เป็นข้อมูลอ้างอิงในการคำนวณอัตราส่วนพิกเซลต่อเมตร (Pixels Per Meter) ดังภาพที่ 4-17



ภาพที่ 4-17 ผลการตรวจหาตัวเลขและค้นหาเส้นจากแบบ

ขั้นตอนที่ 3 นำค่าพิกเซลต่อเมตร (Pixels Per Meter) ที่ได้จากการค้นหาเส้นและการกรอกระยะจริงจากผู้ใช้งาน มาคำนวณร่วมกับจำนวนพิกเซลที่ตรวจจับได้จากแบบจำลอง โดยการนำจำนวนพิกเซลหารด้วยค่าพิกเซลต่อเมตรตามสมการที่ 3-7 เพื่อแปลงจากพิกเซลที่แบบจำลองตรวจจับให้เป็นตารางเมตร ดังภาพที่ 4-18


```
Enter real-world length (meters) for line 2.20:: 2.2
Enter real-world length (meters) for line 4C0:: 4
Enter real-world length (meters) for line 3.0=: 3
```

```
Average pixels_per_meter: 123.84
pixels detected: 945796
Area: 61.67 m2
Results saved.
```

ภาพที่ 4-18 การกรอกระยะจริงของเส้นที่ตรวจจับได้และการแปลงหน่วยเป็นตารางเมตร

หลังจากที่แปลงพื้นที่เป็นหน่วยตารางเมตรแล้ว ทำการทดสอบความแม่นยำโดยนำค่าพื้นที่ที่มาหารด้วยพื้นที่จริงของแบบ โดยทำการทดสอบกับรูปจำนวน 20 รูป เหมือนกับการทดสอบ IOU และเปรียบเทียบผลลัพธ์เพื่อวิเคราะห์ความแตกต่างของความแม่นยำหลังการแปลงหน่วยดังตารางที่ 4-3

ตารางที่ 4-3 เปรียบเทียบความแม่นยำเมื่อแปลงเป็นหน่วยตารางเมตรกับค่า IOU

แบบจำลอง	ความแม่นยำในการแบ่งพื้นที่ห้องเฉลี่ย		
	การแปลงตารางเมตร	ค่า IOU	% ความแตกต่าง
Mask R-CNN	74.4%	75.4%	1.0%
YOLOv9	79.4%	80.3%	0.9%
U-Net	83.4%	84.0%	0.6%


ผลการทดสอบความแตกต่างของความแม่นยำเฉลี่ยระหว่างค่า IOU ที่ทำนายจากแบบจำลองซึ่งผ่านการฝึกด้วยภาพขนาด 1700x1200 พิกเซล จำนวนรูปภาพที่ใช้ในการฝึก 350 รูป และการแปลงพื้นที่เป็นตารางเมตร อยู่ในช่วง 0.6% ถึง 1.0% โดยแบบจำลอง Mask R-CNN มีความแตกต่างอยู่ที่ 1.0% แบบจำลอง YOLOv9 มีค่าความแตกต่างอยู่ที่ 0.9% และแบบจำลอง U-Net มีค่าความแตกต่างอยู่ที่ 0.6% ดังนั้น จากผลการทดสอบดังกล่าวจึงสามารถสรุปได้ว่าการแปลงค่าจากพิกเซลเป็นตารางเมตรให้ผลลัพธ์ที่ใกล้เคียงกับค่า IOU

4.1.3 ปัจจัยอื่นที่ส่งผลต่อความแม่นยำ

นอกจากความสามารถของแบบจำลองและปัจจัยในการฝึกที่ส่งผลต่อความแม่นยำของแบบจำลองแล้ว ยังมีปัจจัยจากแบบก่อสร้างที่สามารถส่งผลต่อความแม่นยำได้ ดังนี้


1) ขนาดและรายละเอียดของวัตถุที่แตกต่างกัน เช่น สัญลักษณ์สวิตช์ไฟกับดวงไฟจะมีขนาดเล็กกว่าตัวรับ เช่น สัญลักษณ์สวิตช์ไฟมีตัว S ตัวรับไฟฟ้าที่เป็นรูปวงกลมมี 2 ขีด เป็นต้น โดยรายละเอียดเหล่านี้ส่งผลให้ความแม่นยำของแบบจำลองต่างกัน และทำให้เกิดข้อผิดพลาดในการตรวจจับ

2) การเขียนสัญลักษณ์ที่อยู่ติดกันหรือการซ้อนทับวัตถุอื่นในแบบ ทำให้แบบจำลองสามารถตรวจจับได้เพียงแค่ 1 ตัวหรือไม่เกิดการตรวจจับดังภาพที่ 4-19




ภาพที่ 4-19 วัตถุที่วางติดกันและวัตถุที่ซ้อนทับเฟอร์นิเจอร์

3) วัตถุที่ปรากฏในแบบคล้ายกับวัตถุที่ต้องการตรวจจับ โดยสัญลักษณ์บางประเภทมีลักษณะคล้ายกับวัตถุอื่นในแบบ ทำให้แบบจำลองสับสนในการจำแนกประเภทของวัตถุ ส่งผลให้เกิดข้อผิดพลาดในการตรวจจับหรือเกิด False Positive (FP) ดังภาพที่ 4-20



ภาพที่ 4-20 แบบจำลองตรวจจับวัตถุอื่นที่ไม่ใช่สัญลักษณ์ที่ต้องการตรวจจับ

4) ความแม่นยำที่ต่างกันระหว่างค่า IOU กับการแปลงค่าพื้นที่จากหน่วยพิกเซลเป็นตารางเมตร มีสาเหตุมาจากการตรวจจับเส้นที่ไม่สมบูรณ์ โดยระบบ OCR บางครั้งไม่สามารถตรวจจับเส้นขอบได้อย่างครบถ้วนหรือเต็มความยาวของเส้น ทำให้เกิดข้อผิดพลาดในการคำนวณค่าพิกเซลต่อเมตร ดังภาพที่ 4-21



ภาพที่ 4-21 การตรวจจับเส้นบอกระยะที่ไม่สมบูรณ์

4.2 ผลการเปรียบเทียบการถอดปริมาณด้วยแบบจำลองกับการถอดปริมาณด้วยมือ

ข้อมูลจากแบบทดสอบและแบบสอบถามทั้งหมดจากเว็บ www.psytoolkit.org จะถูกจัดเก็บโดยอัตโนมัติในรูปแบบไฟล์ .xlsx ซึ่งสามารถโหลดจากทางเว็บได้โดยตรง เพื่อนำไปวิเคราะห์และเปรียบเทียบความสามารถในการถอดปริมาณวัตถุและการแบ่งพื้นที่ ระหว่างกลุ่มผู้ที่มีประสบการณ์ทำงานกับแบบจำลองปัญญาประดิษฐ์ที่ฝึกฝนแล้ว โดยแบ่งออกเป็น 4 หัวข้อ ดังนี้

4.2.1 การวิเคราะห์ด้านความแม่นยำ

การวิเคราะห์ความแม่นยำจากการถอดปริมาณด้วยมือ ดำเนินการผ่านแบบทดสอบออนไลน์ โดยให้ผู้เข้าร่วมที่มีประสบการณ์ในการทำงาน ทำการนับจำนวน ดวงไฟ สวิตช์ไฟ เต้ารับไฟฟ้า และแบ่งพื้นที่จากแบบที่กำหนดให้ โดยในหัวข้อนี้มีผู้เข้าร่วมทั้งหมด 22 คนและสามารถสรุปผลได้ดังนี้

4.2.1.1 ข้อมูลทั่วไปของผู้ทดสอบ


จากการรวบรวมข้อมูลชื่อ ประสบการณ์ทำงาน และตำแหน่งงานของผู้เข้าร่วมการทดสอบ พบว่ามีผู้เข้าร่วมทั้งหมดจำนวน 22 คน ซึ่งสามารถจำแนกระดับประสบการณ์ในการทำงานได้ดังตารางที่ 4-4

ตารางที่ 4-4 ข้อมูลประสบการณ์ทำงานของผู้ทดสอบ

ประสบการณ์ทำงาน	จำนวนคน	ร้อยละของกลุ่มตัวอย่าง
1-5 ปี	10	45%
5-10 ปี	6	27%
10 ปีขึ้นไป	6	27%


4.2.1.2 ผลความแม่นยำจากการทดสอบ

ผลจากแบบทดสอบในการนับจำนวนดวงไฟ สวิตช์ไฟ เต้ารับ และการหาพื้นที่จากบ้านชั้นเดียวจำนวน 2 หลัง และบ้านสองชั้นจำนวน 1 หลัง รวมแบบทั้งหมด 16 แบบ ได้นำมาคำนวณค่าความแม่นยำและจำแนกตามประสบการณ์ของผู้ทดสอบดังภาพที่ 4-22 พบว่าประสบการณ์ในการทำงานมีผลต่อค่าความแม่นยำ โดยแนวโน้มความแม่นยำจะเพิ่มขึ้นตามระดับประสบการณ์ที่มากขึ้น ซึ่งกลุ่มผู้ทดสอบที่มีประสบการณ์ทำงานตั้งแต่ 10 ปีขึ้นไป มีค่าความแม่นยำสูงกว่ากลุ่มที่มีประสบการณ์ 5-10 ปี และ 1-5 ปี ในทุกหมวดงาน



ภาพที่ 4-22 แผนภาพความแม่นยำในการนับจำนวนวัตถุและแบ่งพื้นที่ของผู้ตอบแบบสอบถาม

เมื่อนำค่าความแม่นยำเฉลี่ยจากแบบจำลองที่ดีที่สุดมาเปรียบเทียบกับความแม่นยำจากการถอดปริมาณด้วยมือดังภาพที่ 4-23 พบว่าแบบจำลองที่ได้รับการฝึกฝนด้วยจำนวนรอบการฝึกจำนวน 80 รอบ ด้วยภาพขนาด 1700×1200 พิกเซล ในหมวดของการตรวจจับดวงไฟ มีความแม่นยำใกล้เคียงกับผู้ที่มีประสบการณ์ทำงานในช่วง 5-10 ปี โดยมีค่าความแม่นยำอยู่ที่ 93% และการตรวจจับปลั๊กไฟมีความแม่นยำใกล้เคียงกับผู้ที่มีประสบการณ์ทำงานในช่วง 10 ปีขึ้นไป โดยมีค่าความแม่นยำอยู่ที่ 99% แต่ในหมวดของการตรวจจับสวิตช์ไฟ และการแบ่งพื้นที่ห้องมีความแม่นยำต่ำกว่าการถอดปริมาณด้วยมือ




ภาพที่ 4-23 แผนภาพเปรียบเทียบความแม่นยำของแบบจำลองกับการถอดปริมาณด้วยมือ


4.2.2 การวิเคราะห์ด้านระยะเวลา

การวิเคราะห์ระยะเวลาในการดำเนินการนับจำนวนวัตถุและการแบ่งพื้นที่จากแบบบ้านทั้ง 3 หลัง เป็นการวิเคราะห์ต่อเนื่องจากผลความแม่นยำ โดยผู้วิจัยได้ทำการคำนวณระยะเวลาเฉลี่ยที่ใช้ในการนับจำนวนวัตถุ ได้แก่ ดวงไฟ สวิตช์ไฟ เต้ารับไฟฟ้า และการหาพื้นที่ห้อง ตามประสบการณ์การทำงาน เพื่อเปรียบเทียบกับระยะเวลาที่ใช้ในการดำเนินการของแบบจำลองปัญญาประดิษฐ์ในการตรวจนับวัตถุแต่ละประเภท


ภาพที่ 4-24 ถึง 4-27 แสดงให้เห็นถึงระยะเวลาที่ใช้ในการถอดปริมาณด้วยมือมีความแตกต่างกันตามลักษณะของงาน และประสบการณ์ในการทำงานส่งผลโดยตรงต่อระยะเวลา ทั้งในด้านการนับจำนวนวัตถุและการหาพื้นที่ โดยกลุ่มผู้ที่มีประสบการณ์ทำงานตั้งแต่ 10 ปีขึ้นไป ใช้ระยะเวลาในการดำเนินงานใกล้เคียงกับกลุ่มที่มีประสบการณ์ 5-10 ปี ในหัวข้อ การนับดวงไฟ และสวิตช์ไฟ และใช้เวลาน้อยกว่ากลุ่มที่มีประสบการณ์ 1-5 ปี ในทุกหัวข้อที่ทำการทดสอบ




ภาพที่ 4-24 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับดวงไฟจากแบบทดสอบ



ภาพที่ 4-25 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับสวิตช์ไฟจากแบบทดสอบ



ภาพที่ 4-26 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการนับเต้ารับจากแบบทดสอบ



ภาพที่ 4-27 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการแบ่งพื้นที่จากแบบทดสอบ

หลังจากการวิเคราะห์ระยะเวลาในการถอดปริมาณด้วยมือแล้ว ขั้นตอนต่อไปคือการเปรียบเทียบผลกับระยะเวลาในการตรวจจับของแบบจำลองดังตารางที่ 4-5 จากผลการเปรียบเทียบพบว่าแบบจำลองปัญญาประดิษฐ์ใช้ระยะเวลาในการตรวจจับใกล้เคียงกันในทุกประเภทของงาน แต่ใช้เวลาแตกต่างกันตามชนิดของแบบจำลอง โดยแบบจำลอง Mask R-CNN ใช้เวลาในการตรวจจับเฉลี่ย 22 วินาที YOLOv9 ใช้เวลา 38 วินาที และ U-Net ใช้เวลาเพียง 8 วินาทีต่อรูป ซึ่งเร็วกว่าการถอดปริมาณด้วยมือจากการทำงานประเภทเดียวกัน

ตารางที่ 4-5 ผลระยะเวลาของแบบจำลองปัญญาประดิษฐ์กับระยะเวลาในการถอดปริมาณด้วยมือ

	ระยะเวลาที่ใช้ (วินาที)			
	ดวงไฟ	สวิตช์ไฟ	เต้ารับ	แบ่งพื้นที่
แบบจำลอง				
Mask R-CNN	23	23	22	21
YOLOv9	40	38	38	39
U-Net	8	7	8	8
การถอดปริมาณด้วยมือ				
ประสบการณ์ 1-5 ปี	54	38	31	97
ประสบการณ์ 5-10 ปี	43	31	25	73
ประสบการณ์ 10 ปีขึ้นไป	31	24	21	64

4.2.3 การประเมินความสามารถในการถอดปริมาณได้อย่างต่อเนื่อง

เนื่องจากการดำเนินงานถอดปริมาณด้วยมือจะเกิดความล้าจากการทำงานอย่างต่อเนื่องเป็นระยะเวลานาน ผู้วิจัยจึงได้ดำเนินการทดสอบความสามารถในการถอดปริมาณอย่างต่อเนื่อง โดยให้ผู้ทดสอบทำการนับจำนวนดวงไฟ สวิตช์ไฟ และเต้ารับไฟฟ้า อย่างละ 20 แบบ รวมทั้งสิ้น 60 แบบ


จากผู้ทดสอบทั้งหมด 8 คน มีจำนวน 5 คน ที่สามารถดำเนินการถอดปริมาณได้จนเสร็จ และมีผู้ที่ไม่สามารถทำแบบทดสอบได้ครบถ้วน ประกอบด้วยผู้ที่มีประสบการณ์ 1-5 ปี จำนวน 2 คน ที่สามารถทำได้เพียง 6 แบบ และผู้ที่มีประสบการณ์ 5-10 ปี จำนวน 1 คน ที่สามารถทำได้ 19 แบบดังตารางที่ 4-6 โดยผลลัพธ์ดังกล่าวแสดงให้เห็นว่า การถอดปริมาณด้วยมืออย่างต่อเนื่อง

ก่อให้เกิดความล่าช้า ส่งผลให้มีผู้ที่ไม่สามารถดำเนินการได้ครบทุกแบบ ส่วนผู้ที่สามารถทำได้จนเสร็จ อาจมีปัจจัยหลายประการ เช่น ความตั้งใจที่จะทำแบบทดสอบให้สมบูรณ์ ความคุ้นเคยกับการถอดปริมาณ หรือระยะเวลาในการทำแบบทดสอบ

ตารางที่ 4-6 ผลการถอดปริมาณได้อย่างต่อเนื่องตามประสบการณ์ทำงาน

ประสบการณ์ทำงาน	จำนวนแบบที่สามารถถอดปริมาณได้อย่างต่อเนื่อง	จำนวน (คน)
1-5 ปี	6	2
5-10 ปี	19	1
	60	2
10 ปีขึ้นไป	60	3

ผลจากการทดสอบพบว่า ผู้เข้าร่วมสามารถถอดปริมาณได้รวดเร็วในช่วงแรก แต่เมื่อจำนวนแบบเพิ่มขึ้นเป็น 20 และ 40 แบบ จะมีระยะเวลาที่เพิ่มขึ้นอย่างชัดเจน แสดงให้เห็นถึงความล่าช้าจากการทำงานต่อเนื่องและความจำเป็นในการหยุดพักดังภาพที่ 4-28



ภาพที่ 4-28 แผนภาพเปรียบเทียบระยะเวลาที่ใช้ในการถอดปริมาณอย่างต่อเนื่องตามประสบการณ์

4.2.4 ผลความคิดเห็นและข้อเสนอแนะจากผู้ใช้งาน

หลังจากการวิเคราะห์ผลความแม่นยำและระยะเวลาจากการถอดปริมาณด้วยมือแล้ว ในหัวข้อนี้ได้เสนอผลลัพธ์จากการตอบแบบสอบถามจำนวน 3 ข้อ ที่เกี่ยวกับความแม่นยำ การนำไปใช้งาน และการปรับปรุงแบบจำลอง จากกลุ่มตัวอย่าง 22 คน ซึ่งได้สรุปความคิดเห็นรายบุคคล เพื่อให้เห็นถึงความแตกต่างของความคิดเห็นต่อการประยุกต์ใช้แบบจำลองในการตรวจจับวัตถุและแบ่งพื้นที่ ดังตารางที่ 4-7

4.2.4.1 การยอมรับผลความแม่นยำของแบบจำลอง

ในคำถามที่ 1 ที่เกี่ยวข้องกับความแม่นยำของแบบจำลอง มีผู้ตอบแบบสอบถาม 20 คน หรือคิดเป็น 91% ที่ยอมรับผลลัพธ์ของแบบจำลองซึ่งมีความแม่นยำอยู่ในช่วง 80% ถึง 90% ขณะที่ผู้ตอบแบบสอบถาม 2 คนที่ไม่ยอมรับผลลัพธ์ เนื่องจากว่าการถอดปริมาณด้วยวิธีการแบบดั้งเดิมมีความแม่นยำสูงกว่า ซึ่งแนวโน้มดังกล่าวสะท้อนให้เห็นว่าแบบจำลองมีระดับความแม่นยำที่เพียงพอสำหรับการนำไปใช้ในการถอดปริมาณจากแบบก่อสร้าง

4.2.4.2 การนำไปใช้งานจริง

จากคำถามที่ 2 ที่เกี่ยวกับการนำแบบจำลองไปใช้งานจริง พบว่า มีผู้ตอบแบบสอบถาม 4 คน หรือ 18% ระบุว่าจะนำไปใช้งานโดยตรงในการถอดปริมาณวัสดุและพื้นที่ มีผู้ตอบแบบสอบถาม 12 คน หรือ 54% ระบุว่าจะนำไปใช้งานโดยมีการตรวจสอบเพิ่มเติม มีผู้ตอบแบบสอบถาม 4 คน หรือ 18% ระบุว่าจะนำไปใช้เฉพาะการถอดปริมาณวัสดุ และมีผู้ตอบแบบสอบถาม 2 คน หรือ 9% ระบุว่าจะไม่นำไปใช้งาน เนื่องจากเหตุผลที่เกี่ยวข้องกับลักษณะงานของผู้ตอบ ซึ่งแนวโน้มดังกล่าวแสดงให้เห็นว่า แบบจำลองมีศักยภาพในการนำไปใช้งานจริงได้ แต่ผู้ใช้งานยังคงต้องตรวจทานข้อมูลก่อนนำผลลัพธ์ไปใช้งาน

4.2.4.3 ข้อเสนอแนะในการปรับปรุงและพัฒนาในอนาคต

ในส่วนของคำถามที่ 3 ที่เกี่ยวกับการปรับปรุงและพัฒนาแบบจำลอง ผู้ตอบแบบสอบถามได้เสนอให้มีการพัฒนาระบบให้สามารถตรวจจับวัตถุหรือถอดปริมาณงานประเภทอื่นในแบบก่อสร้างเพิ่มเติม เช่น พื้น ผนัง หรือคาน รวมถึงปรับปรุงให้ระบบให้มีความสะดวกต่อการใช้งาน สามารถส่งออกข้อมูลไปใช้ร่วมกับโปรแกรมอื่นได้ และมีการแนะนำให้เพิ่มการฝึกแบบจำลองเพื่อให้ได้ผลลัพธ์ที่มีความแม่นยำใกล้เคียง 100%

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผลการศึกษา

จากการนำปัญญาประดิษฐ์มาประยุกต์ใช้กับงานก่อสร้าง โดยใช้ในการถอดปริมาณงานระบบไฟฟ้าในแบบก่อสร้างบ้านพักอาศัย ผ่านแบบจำลองโครงข่ายประสาทเทียม 3 แบบจำลองได้แก่ Mask R-CNN, YOLOv9 และ U-Net เพื่อประเมินประสิทธิภาพและความแม่นยำในการตรวจจับดวงไฟ สวิตช์ไฟ เต้ารับไฟฟ้า และแบ่งพื้นที่ห้อง จากแบบก่อสร้างในรูปแบบภาพถ่าย สามารถสรุปผลได้ดังนี้

5.1.1 ปัจจัยที่มีผลต่อความแม่นยำของแบบจำลองปัญญาประดิษฐ์

ผลการวิจัยแสดงให้เห็นว่าความแม่นยำในการตรวจจับวัตถุและแบ่งพื้นที่จากแบบก่อสร้างขึ้นกับหลายปัจจัย ซึ่งแบ่งได้เป็น 2 กลุ่มดังนี้

5.1.1.1 ปัจจัยที่เกี่ยวกับการตั้งค่าการฝึกฝนแบบจำลอง

ในขั้นตอนการฝึกแบบจำลองจากแบบก่อสร้างจะต้องกำหนดค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม ซึ่งเป็นสิ่งที่สำคัญเพื่อให้ได้ผลลัพธ์ที่แม่นยำและมีประสิทธิภาพ โดยค่าที่ควรพิจารณามีดังนี้

- 1) ขนาดของภาพที่ใช้ฝึก (Image Size) ควรมีขนาดอย่างน้อย 1700x1200 พิกเซลหรือมากกว่า เพื่อให้แบบจำลองสามารถเรียนรู้รายละเอียดของวัตถุในภาพได้อย่างครบถ้วน
- 2) จำนวนรอบในการฝึก (Epoch) ควรมากกว่า 80 รอบ เพื่อให้แบบจำลองสามารถเรียนรู้ลักษณะของข้อมูลหรือสัญลักษณ์ได้อย่างครบถ้วน
- 3) จำนวนรูปภาพตัวอย่างที่ใช้ฝึก (Training Samples) ควรมีมากกว่า 300 รูป เพื่อให้แบบจำลองสามารถเรียนรู้ความหลากหลายของข้อมูล และรูปแบบของวัตถุจากรูปภาพที่แตกต่างกัน

5.1.1.2 ปัจจัยที่เกี่ยวกับลักษณะของแบบก่อสร้าง

- 1) ขนาดและรายละเอียดของวัตถุ เช่น สัญลักษณ์สวิตช์ไฟ ดวงไฟ และเต้ารับ มีขนาดและรูปแบบแตกต่างกัน
- 2) การวางสัญลักษณ์ติดกันหรือซ้อนกับวัตถุอื่นทำให้แบบจำลองตรวจจับวัตถุไม่ครบหรือไม่สามารถตรวจจับได้

3) วัตถุอื่นในแบบที่มีลักษณะคล้ายกับวัตถุเป้าหมาย ส่งผลให้เกิดการตรวจจับผิดพลาด หรือเกิด False Positive

4) การแปลงหน่วยพิกเซลเป็นตารางเมตรจากการแบ่งพื้นที่ให้ความแม่นยำไม่เท่าเดิม เกิดจากการตรวจจับเส้นบอกระยะที่ไม่สมบูรณ์ ซึ่งกระทบต่อความแม่นยำในการแปลงพื้นที่

5.1.2 ผลความแม่นยำจากการประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ ในการตรวจจับวัตถุในงานระบบไฟฟ้าและการแบ่งพื้นที่อาคารในแบบก่อสร้าง

แบบจำลองปัญญาประดิษฐ์ที่นำมาใช้ในการศึกษานี้มีคุณลักษณะที่แตกต่างกัน ทั้งในด้านการเรียนรู้ แนวทางการประมวลผล และความเหมาะสมต่อประเภทของงานที่แตกต่างกัน ซึ่งส่งผลให้แต่ละแบบจำลองมีข้อดีและข้อจำกัดสามารถสรุปได้ดังตารางที่ 5-1 และเมื่อเปรียบเทียบผลความแม่นยำในการตรวจจับอุปกรณ์ระบบไฟฟ้าและการแบ่งพื้นที่ห้องพบว่า แบบจำลองที่ให้ผลลัพธ์ดีที่สุดจำแนกตามประเภทของวัตถุและการแบ่งพื้นที่ แสดงดังตารางที่ 5-2

ตารางที่ 5-1 เปรียบเทียบความแม่นยำและลักษณะของแบบจำลองที่ฝึกด้วยภาพขนาด 1700x1200 พิกเซล จำนวน 350 รูป และจำนวนรอบในการฝึก 80 รอบ

แบบจำลอง	ความแม่นยำและลักษณะของแบบจำลอง
Mask R-CNN	- แบบจำลอง Mask R-CNN มีความแม่นยำในการตรวจจับดวงไฟ 83% สวิตช์ไฟ 86% ปลั๊กไฟ 95% และค่า IOU จากการแบ่งพื้นที่ 75% - แบบจำลอง Mask R-CNN ให้ความแม่นยำในการระบุตำแหน่งของอุปกรณ์ระบบไฟฟ้ามากกว่าแบบจำลองอื่น ในกรณีที่มีข้อมูลฝึกที่น้อย เช่น 100 ถึง 200 รูป แต่มีค่า FP ที่เยอะกว่าแบบจำลองอื่นเนื่องจากการตรวจจับวัตถุอื่นที่ไม่เกี่ยวข้องมาด้วย และแบบจำลองนี้ต้องใช้งานร่วมกับ Python ที่เป็นเวอร์ชันเก่า ซึ่งส่งผลให้ขั้นตอนการเรียนรู้ซับซ้อนกว่าแบบจำลองอื่น
YOLOv9	- แบบจำลอง YOLOv9 มีความแม่นยำในการตรวจจับดวงไฟ 96% สวิตช์ไฟ 89% ปลั๊กไฟ 99% และค่า IOU จากการแบ่งพื้นที่ 80% - แบบจำลอง YOLOv9 มีประสิทธิภาพในการตรวจจับอุปกรณ์ระบบไฟฟ้าสูงที่สุด เมื่อมีชุดข้อมูลในการฝึกมากกว่า 250 รูป แต่ในกรณีที่วัตถุในภาพมีขนาดเล็กมากหรือมีการบดบังบางส่วน อาจทำให้เกิดการตรวจจับผิดพลาดหรือไม่สามารถตรวจจับวัตถุได้

ตารางที่ 5-1 (ต่อ)

แบบจำลอง	ความแม่นยำและลักษณะของแบบจำลอง
U-Net	- แบบจำลอง U-Net มีความแม่นยำในการตรวจจับดวงไฟ 78% สวิตช์ไฟ 81% ปลั๊กไฟ 86% และค่า IOU จากการแบ่งพื้นที่ 84% - แบบจำลอง U-Net มีความเหมาะสมสำหรับการจำแนกพื้นที่จากแบบเมื่อมีชุดข้อมูลในการฝึกมากกว่า 250 รูป เนื่องจากโครงสร้างของแบบจำลองถูกออกแบบมาให้ประมวลผลภาพด้วยความละเอียดหลายระดับ

ตารางที่ 5-2 แบบจำลองที่ดีที่สุดสำหรับการตรวจจับวัตถุและแบ่งพื้นที่ จากการฝึกด้วยรูปภาพขนาด 1700x1200 พิกเซล จำนวน 350 รูป และจำนวนรอบการฝึก 80 รอบ

ประเภทของวัตถุ	แบบจำลองที่ดีที่สุด (Best Model)	Accuracy (%)	IOU (%)
ดวงไฟ	YOLOv9	96%	-
สวิตช์ไฟ	YOLOv9	89%	-
เต้ารับ	YOLOv9	99%	-
พื้นที่ห้อง	U-Net	-	84%

5.1.3 การเปรียบเทียบแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ

1) การเปรียบเทียบความแม่นยำของแบบจำลองปัญญาประดิษฐ์กับการถอดปริมาณด้วยมือ พบว่าความแม่นยำมีแนวโน้มเพิ่มขึ้นตามระดับประสบการณ์ทำงานที่เพิ่มขึ้นและระยะเวลาในการดำเนินการมีแนวโน้มลดลงตามประสบการณ์ทำงานที่เพิ่มขึ้น โดยความแม่นยำในการนับจำนวนดวงไฟ สวิตช์ไฟ และเต้ารับ ของผู้ทดสอบเฉลี่ย 95% และมีความแม่นยำในการถอดปริมาณพื้นที่ของแบบบ้านเฉลี่ย 90%

เมื่อนำผลความแม่นยำที่ได้จากแบบจำลองมาเปรียบเทียบ พบว่าในหมวดของการตรวจจับดวงไฟมีความแม่นยำใกล้เคียงกับผู้ที่มีประสบการณ์ทำงานในช่วง 5-10 ปี ที่ 95% และการตรวจจับปลั๊กไฟมีความแม่นยำใกล้เคียงกับผู้ที่มีประสบการณ์ทำงานในช่วง 10 ปีขึ้นไป ที่ 98% แต่ในหมวดของการตรวจจับสวิตช์ไฟ และการแบ่งพื้นที่ห้อง แบบจำลองมีความแม่นยำอยู่ในช่วง 84% ถึง

89% ซึ่งต่ำกว่าความแม่นยำของการถอดปริมาณด้วยมือที่มีมากกว่า 90% แสดงให้เห็นว่ายังมีความจำเป็นที่จะต้องพัฒนาความสามารถของแบบจำลองเพิ่มเติมเพื่อให้ผลลัพธ์ใกล้เคียงกับการถอดปริมาณด้วยมือ

2) การเปรียบเทียบระยะเวลาในการทำงาน พบว่าแต่ละแบบจำลองใช้เวลาในการตรวจจับอุปกรณ์ระบบไฟฟ้าที่ใกล้เคียงกันในทุกประเภทของงาน โดยแบบจำลอง U-Net ใช้ระยะเวลาน้อยที่สุดในการตรวจจับ รองลงมาคือ Mask R-CNN และ YOLOv9 ซึ่งใช้เวลา 8 วินาที 22 วินาที และ 38 วินาที ตามลำดับ

3) ผลจากการตอบแบบสอบถามสามารถสรุปได้ว่า แบบจำลองปัญญาประดิษฐ์ที่มีความแม่นยำ 80% ถึง 90% ในการถอดปริมาณงานจากแบบก่อสร้าง มีศักยภาพในการนำไปใช้งานจริงได้ และได้รับการยอมรับจากผู้ที่มีประสบการณ์ทำงานถึง 91% อย่างไรก็ตามผู้ใช้งานยังคงต้องตรวจทานข้อมูลก่อนนำผลลัพธ์ที่ได้ไปใช้งาน

4) จากการทดสอบความสามารถในการถอดปริมาณได้อย่างต่อเนื่อง พบว่าผู้ทดสอบสามารถถอดปริมาณได้อย่างรวดเร็วในช่วงแรกแต่จะต้องหยุดพักหลังจากถอดปริมาณทุกๆ 20 แบบ

จากผลการศึกษา พบว่าแบบจำลองปัญญาประดิษฐ์สามารถนำไปเป็นแนวทางสำหรับการพัฒนาระบบถอดปริมาณงานอัตโนมัติในอุตสาหกรรมก่อสร้างได้ เพื่อลดความผิดพลาดในการตรวจสอบแบบแปลน ลดความล่าช้าในการทำงานซ้ำและเพิ่มประสิทธิภาพในการบริหารงานก่อสร้าง

5.2 ข้อเสนอแนะ

5.2.1 การประยุกต์ใช้งานในอนาคต

สามารถนำแบบจำลองไปปรับใช้ในการตรวจจับวัตถุประเภทอื่นในแบบก่อสร้างได้ เช่น ประตู หน้าต่าง เฟอร์นิเจอร์ สุขภัณฑ์ หรือระบบอื่นๆ ซึ่งการตรวจจับวัตถุเหล่านี้จะช่วยให้การถอดปริมาณและประมาณราคางานระบบต่างๆ มีความแม่นยำและครอบคลุมมากยิ่งขึ้น นอกจากนี้ยังสามารถใช้แบบจำลองที่มีความสามารถในการประมวลผลที่ซับซ้อนมากขึ้น เช่น YOLOv11 DeepLabV3 และ Segment Anything Model (SAM)

การใช้แบบจำลองปัญญาประดิษฐ์ในการตรวจจับวัตถุ ไม่รับประกันความถูกต้องหรือมีความแม่นยำ 100% เนื่องจากมีข้อผิดพลาดจากปัจจัยหลายประการ เช่น คุณภาพภาพแบบ ความซับซ้อนของวัตถุหรือการจัดวางวัตถุ ดังนั้นจึงมีความจำเป็นที่จะต้องมีการตรวจสอบและยืนยันผลลัพธ์โดยผู้เชี่ยวชาญหรือเจ้าหน้าที่ก่อนที่จะนำข้อมูลไปใช้งาน โดยเฉพาะในงานที่เกี่ยวข้องกับการประมาณราคา

แบบจำลองปัญญาประดิษฐ์สามารถนำไปประยุกต์ใช้ในงานลดปริมาณจากแบบก่อสร้างในกรณีที่มีแบบจำนวนมากได้ เช่น โครงการหมู่บ้านจัดสรร อาคารชุด หรือโครงการอาคารขนาดใหญ่ที่มีการทำซ้ำ ซึ่งช่วยลดภาระของวิศวกรในการดำเนินงานซ้ำซ้อน และลดระยะเวลาการทำงาน

5.2.2 การปรับปรุงผลของปัญญาประดิษฐ์

เพื่อให้แบบจำลองปัญญาประดิษฐ์มีประสิทธิภาพมากยิ่งขึ้น สามารถนำภาพถ่ายจากกล้อง โทรศัพท์มือถือ หรือแบบที่สแกนจากกระดาษมาใช้เป็นชุดข้อมูลในการฝึกแบบจำลอง เพื่อเป็นการยกระดับและประยุกต์ใช้ในสภาพงานจริง

ปัจจัยสำคัญที่ส่งผลต่อความแม่นยำของแบบจำลอง ได้แก่ ขนาดของภาพ จำนวนรอบการฝึก (epochs) และจำนวนรูปภาพที่ใช้ในการฝึกฝน โดยขนาดภาพที่ใหญ่ขึ้น การเพิ่มจำนวนรอบการฝึก และการเพิ่มจำนวนรูปภาพ ส่งผลให้แบบจำลองสามารถเรียนรู้รายละเอียดของวัตถุได้แม่นยำมากยิ่งขึ้น แต่มีระยะเวลาในการฝึกแบบจำลองที่มากขึ้น และขนาดของภาพที่ใหญ่เกินไปบางครั้งจะไม่สามารถประมวลผลได้ เนื่องจากข้อจำกัดด้านหน่วยความจำของการ์ดจอ (VRAM) เพื่อแก้ไขปัญหาดังกล่าวจึงแนะนำให้ใช้การ์ดจอ (GPU) ที่มีสมรรถนะสูง เพื่อให้สามารถรองรับขนาดภาพที่ใหญ่ขึ้น ลดระยะเวลาในการฝึก และเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลอง

การแปลงค่าพิกเซลจากหน่วยพิกเซลเป็นตารางเมตรอาจเกิดความคลาดเคลื่อน เพื่อแก้ไขปัญหาดังกล่าวจึงต้องทำการปรับปรุงคุณภาพของแบบก่อสร้างให้มีความคมชัด และเพื่อให้การแปลงค่าระยะทางจากพิกเซลไปเป็นเมตรมีความแม่นยำมากยิ่งขึ้น ควรดำเนินการคำนวณโดยการตรวจจับเส้นและให้ผู้ใช้งานกรอกระยะจริงหลายๆ เส้น แทนการอ้างอิงเพียงเส้นเดียว เพื่อช่วยลดความผิดพลาดเฉพาะจุดและเพิ่มความแม่นยำในการคำนวณพื้นที่

5.2.3 งานวิจัยในอนาคต

สามารถนำแบบจำลองที่ผ่านการฝึกแล้วไปพัฒนาต่อเพื่อเพิ่มความแม่นยำในการตรวจจับและปรับปรุงให้สามารถระบุรายละเอียดที่ซับซ้อนมากขึ้น นอกจากนี้ยังสามารถนำไปสร้างเป็นซอฟต์แวร์ที่ตรวจจับวัตถุในแบบก่อสร้างแบบอัตโนมัติ เช่น การสร้างแอปพลิเคชันบนมือถือ แท็บเล็ต หรือเว็บไซต์ออนไลน์ เพื่อลดเวลาการทำงานของวิศวกร และเพิ่มความสะดวกในการใช้งาน

บรรณานุกรม

ภาษาไทย

กระทรวงมหาดไทย. (2555). คู่มือการประมาณราคา. กรมโยธาธิการและผังเมือง.

กรรวิ มีมุข และกวิน ตันติเสวี. (2561). การศึกษาเชิงเปรียบเทียบแบบจำลองในการประมาณราคาต้นทุนค่าก่อสร้างอาคารพักอาศัยของภาครัฐ. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 23.

กิตตากร วิริยะศาสตร์, วรากร เลื่องลือวุฒิ, วิชัย แผ้วเกษม, พันธุ์เทพ แก้วมงคล, สัญญา มิตรเอม และพันศักดิ์ เทียนวิบูลย์. (2567). การวิเคราะห์แบ่งส่วนพื้นที่ภาพถ่ายทางอากาศด้วย Generative Adversarial Networks. วารสารวิชาการเทคโนโลยีป้องกันประเทศ ปีที่ 6.

คณบดี ศรีสมบุรณ์. (2565). การเรียนรู้ของเครื่อง (Machine Learning) (Vol. 1). มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ: ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์.

ชูพันธุ์ รัตนโกคา. (2559). เอกสารคำสอนวิชา ความรู้เบื้องต้นทางปัญญาประดิษฐ์. ภาควิชาเทคโนโลยีวิศวกรรมอิเล็กทรอนิกส์, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ.

ฐิติพัฒน์ ประทานทรัพย์. (2554). มาตรฐานการเขียนแบบก่อสร้าง (Vol. 1). บริษัท พลัส เพรส จำกัด: สมาคมสถาปนิกสยาม ในพระบรมราชูปถัมภ์.

ณิศวรา ศรีแก้ว, กอปร ศรีนาวัน และวุฒิพงษ์ กุศลคุ้ม. (2566). การประยุกต์ใช้การเรียนรู้ของเครื่องเพื่อตรวจจับภาพชิ้นส่วนที่มีสนิมของโครงสร้างเหล็กอาคารโกดังสินค้า. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 28.

เทชฤทธิ์ ศรีธนาวิหะนนท์. (2565). การศึกษาต้นทุนโครงการอาคารพักอาศัยคอนโดมิเนียมประเภทอาคารสูงในพื้นที่กรุงเทพฯ ชั้นใน. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 27.

พรทิพย์ ที. พุนายัน. (2566). กลยุทธ์การเตรียมความพร้อมต่อการเปลี่ยนแปลงสู่เทคโนโลยีปัญญาประดิษฐ์ของพนักงานอสังหาริมทรัพย์. ปริญญากิจการมหาบัณฑิต. วิทยาลัยการจัดการ มหาวิทยาลัยมหิดล.

เมธาสิทธิ์ จันทร์พิทักษ์ และ ธนิต ธงทอง. (2565). การประยุกต์ใช้แบบจำลองสารสนเทศอาคารเชิงพารามิเตอร์เพื่อการลดปริมาณวัสดุผนังอิฐก่อ. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 27.

วรรณวรงค์ รัตนานิคม และสยาม ยิ้มศิริ. (2563). การศึกษาปัญหาในการบริหารงานก่อสร้างประเภทอาคารในขั้นตอนการออกแบบและประมาณราคา. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 25.

วรพันธ์ ปัญญาภาศ, พรพจน์ นุเสน, ขนิษฐา ไชยพันธุ์ และมานพ แก้วโมราเจริญ. (2567). การเปรียบเทียบปัญญาประดิษฐ์และคอมพิวเตอร์วิทัศน์ สำหรับกระบวนการก่อสร้างในระหว่างการก่อสร้าง ระหว่างโมเดล YOLOv9 และ ACF. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ ครั้งที่ 29.

วิเชียร ปัญญาจักร. (2545). การประมาณราคาก่อสร้าง 1. สาขาวิชาช่างก่อสร้าง แผนกวิชาช่างก่อสร้าง กระทรวงศึกษาธิการ: วิทยาลัยเทคนิคเชียงใหม่.

สันติภูมิ สิทธิราษฎร์. (2565). การประมาณราคาเบื้องต้น สำหรับงานก่อสร้างอาคารด้วยวิธีเทคนิคโครงข่ายประสาทเทียม. สาขาวิศวกรรมศาสตรมหาบัณฑิต. ภาควิชาวิศวกรรมและการบริหารการก่อสร้าง. มหาวิทยาลัยเชียงใหม่.

สงว บุนรอด. (2555). ความรู้เบื้องต้นเกี่ยวกับระบบไฟฟ้า. วิทยาลัยเทคโนโลยีพัฒนการอยุธยา. แผนกวิชาสามัญสัมพันธ์ (วิทยาศาสตร์ – คณิตศาสตร์).

สุนันท์ มนต์แก้ว, ชูเกียรติ ชูสกุล และไพศาล สุขสม. (2566). การศึกษาสัดส่วนของปริมาตรคอนกรีตต่อปริมาณเหล็กเสริมในงานโครงสร้างพื้นไร้คานของอาคารขนาดใหญ่. วารสารสถาปัตยกรรม การออกแบบและการก่อสร้าง.

สุรศักดิ์ แสงแก้ว. (2562). เขียนแบบไฟฟ้า. คณะครุศาสตร์อุตสาหกรรม. มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี.

ภาษาอังกฤษ

Al-Khalil, M. I., & Al-Ghafly, M. A. (1999b). Important causes of delay in public utility projects in Saudi Arabia. *Construction Management & Economics*, 17(5)

- Agustiansyah, P., Nurmaini, S., Nuranna, L., Irfannuddin, I., Sanif, R., Legiran, L., Rachmatullah, M. N., Florina, G. O., Sapitri, A. I., and Darmawahyuni, A. (2022). Automated precancerous lesion screening using an instance segmentation technique for improving accuracy. *Sensors*, 22(15), 5489.
- Bubeck, S., Chandrasekaran, V., Eldan, R., Gehrke, J., Horvitz, E., Kamar and Zhang, Y. (2023). Sparks of artificial general intelligence: Early experiments with GPT-4. arXiv preprint arXiv:2303.12712.
- Chen, Y.C., Wu, R.T. and Puranam, A. (2024). Multi-task deep learning for crack segmentation and quantification in RC structures. *Automation in Construction*, 166, 105599.
- Chowdhury, A. and Moon, S. (2023). Generating integrated bill of materials using mask R-CNN artificial intelligence model. *Automation in Construction*, 145, 104644.
- Ding, Y. and Luo, X. (2023). VCVW-3D: A Virtual Construction Vehicles and Workers Dataset with 3D Annotations. *Engineering Applications of Artificial Intelligence*, Volume 133, Part A.
- Gallagher, J. and Skalski, P. (2024). How to train YOLOv9 on a Custom Dataset. [สืบค้นวันที่ 15 มกราคม 2568]. จาก <https://blog.roboflow.com/train-yolov9-model/>
- He, K., Gkioxari, G., Dollár, P. and Girshick, R. (2017). Mask R-CNN. *Computer Vision (ICCV), 2017 IEEE International Conference*, 2980-2988.
- Mei X., Zhou, X., Xu F. and Zhang, Z. (2022). Human Intrusion Detection in Static Hazardous Areas at Construction Sites: Deep Learning-Based Method. *Journal of Construction Engineering and Management*, 149(1).
- Perez, N.M., Segura, T.G., Domingo, L.M., Sanz, A., Mansanet, J. and Pellicer, E. (2024). Artificial Intelligent Techniques to Improve Pavement Maintenance Management. 1097-1106.

- Raghavendra, R., and Busch, C. (2014). Novel image fusion scheme based on dependency measure for robust multispectral palmprint recognition. Pattern Recognition, 47(6), 2205-2221.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. Medical image computing and computer-assisted intervention – MICCAI 2015 (Vol. 9351, pp. 234–241).
- Russell, S.J. and Norvig, P. (2003). Artificial Intelligence: A Modern Approach (Vol. 2nd Edition). Prentice Hall, New Jersey.
- Sengupta, S., Basak, S., Saikia, P., Paul, S., Tsalavoutis, V., Atiah, F. and Peters, A. (2020). A review of deep learning with special emphasis on architectures, applications and recent trends. Knowledge-Based Systems, Volume 194.
- Shahinfar S., Meek, P., and Falzon, G. (2020). How many images do I need? Understanding how sample size per class affects deep learning model performance metrics for balanced designs in autonomous wildlife monitoring. Ecological Informatics, Volume 57.
- Wang, C. Y., Yeh, I. and Liao, H.Y.M. (2024). Yolov9: Learning what you want to learn using programmable gradient information. arXiv preprint arXiv:2402.
- Xiao, B. and Kang, S.C. (2021). Development of an Image Data Set of Construction Machines for Deep Learning Object Detection. Journal of Computing in Civil Engineering, 35(2), 05020005.
- Zhou, J. Ning, j. Xiang, Z. and Yin, P. (2024). ICDW-YOLO: An Efficient Timber Construction Crack Detection Algorithm. Sensors, 24(13).

ภาคผนวก ก

แบบทดสอบการถอดปริมาตรด้วยมือ



ตัวอย่างแบบทดสอบการถอดปริมาณด้วยมือเพื่อเปรียบเทียบกับปัญญาประดิษฐ์

แบบทดสอบนี้เป็นส่วนหนึ่งของวิทยานิพนธ์ เรื่อง การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบก่อสร้างอาคารบ้านพักอาศัย โดยนักศึกษาระดับปริญญาโท สาขาวิศวกรรมโยธา มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือโดยแบ่งออกเป็น 3 ส่วน ดังนี้

- ส่วนที่ 1 ข้อมูลทั่วไป
- ส่วนที่ 2 แบบทดสอบการนับจำนวนวัตถุและถอดปริมาณพื้นที่
- ส่วนที่ 3 ถามความคิดเห็นในการนำแบบจำลองมาใช้ตรวจนับวัตถุและแบ่งพื้นที่ในแบบก่อสร้าง

ขอขอบพระคุณทุกท่านที่กรุณาสละเวลาให้ข้อมูลอันเป็นประโยชน์ต่อการวิจัยครั้งนี้

ส่วนที่ 1: ข้อมูลทั่วไป

1. ชื่อ

2. ประสบการณ์ทำงานในสายงานก่อสร้าง/ถอดปริมาณ

- ☐ น้อยกว่า 5 ปี
- ☐ 5-10 ปี
- ☐ มากกว่า 10 ปี

3. สาขาวิศวกรรมที่สำเร็จการศึกษา

- ☐ วิศวกรรมโยธา
- ☐ วิศวกรรมเครื่องกล
- ☐ วิศวกรรมไฟฟ้า
- ☐ วิศวกรรมอุตสาหการ
- ☐ อื่นๆ


ตำแหน่งงานปัจจุบัน (เช่น วิศวกรสนาม, ผู้ควบคุมงาน, ผู้ประมาณราคา)

ส่วนที่ 2: แบบทดสอบการนับจำนวนวัตถุและถอดปริมาณพื้นที่


ในส่วนนี้เป็นการทดสอบการนับจำนวนและถอดปริมาณจากบ้าน 3 หลัง โดยแบ่งเป็น 4 ข้อ ได้แก่ ดวงไฟ, สวิตช์ไฟ, ปลั๊กไฟ และพื้นที่ ระบบจะบันทึกคำตอบและเวลาที่ใช้ในการตอบในแต่ละภาพโดยอัตโนมัติ

ข้อ 1 นับจำนวนดวงไฟ

นี่คือตัวอย่างสัญลักษณ์ดวงไฟที่ต้องนับ




โปรดนับจำนวนและกรอกคำตอบที่ปรากฏอยู่ในภาพต่อไปนี้ให้ถูกต้อง
ภาพที่ 1




จำนวนดวงไฟในบ้านหลังที่ 1

ภาพที่ 2




จำนวนดวงไฟในบ้านหลังที่ 2 (ชั้น 1)

ภาพที่ 3



จำนวนดวงไฟในบ้านหลังที่ 2 (ชั้น 2)

ภาพที่ 4



จำนวนดวงไฟในบ้านหลังที่ 3


ข้อ 2 นับจำนวนสวิตช์ไฟ

นี่คือตัวอย่างสัญลักษณ์สวิตช์ไฟที่ต้องนับ




โปรดนับจำนวนและกรอกคำตอบที่ปรากฏอยู่ในภาพต่อไปนี้ให้ถูกต้อง

ภาพที่ 1




จำนวนสวิตช์ไฟในบ้านหลังที่ 1

ภาพที่ 2




จำนวนสวิตช์ไฟในบ้านหลังที่ 2 (ชั้น 1)

ภาพที่ 3



จำนวนสวิตช์ไฟในบ้านหลังที่ 2 (ชั้น 2)

ภาพที่ 4



จำนวนสวิตช์ไฟในบ้านหลังที่ 3


ข้อที่ 3 นับจำนวนปลั๊กไฟ

นี่คือตัวอย่างสัญลักษณ์ปลั๊กไฟที่ต้องนับ




โปรดนับจำนวนและกรอกคำตอบที่ปรากฏอยู่ในภาพต่อไปนี้ไปให้ถูกต้อง

ภาพที่ 1




จำนวนสวิตช์ไฟในบ้านหลังที่ 1

ภาพที่ 2




จำนวนสวิตช์ไฟในบ้านหลังที่ 2 (ชั้น 1)

ภาพที่ 3



จำนวนสวิตช์ไฟในบ้านหลังที่ 2 (ชั้น 2)


ภาพที่ 4



จำนวนสวิตช์ไฟในบ้านหลังที่ 3

ข้อที่ 4 ถอดปริมาณจากแบบก่อสร้าง


นี่คือตัวอย่างการถอดปริมาณจากแบบก่อสร้างในหน่วยตารางเมตร



$$8.8 \times 9.3 = 81.84 \text{ ตารางเมตร}$$


โปรดถอดปริมาณพื้นที่ ที่ปรากฏอยู่ในภาพต่อไปนี้ให้ถูกต้อง

ภาพที่ 1




พื้นที่ของบ้านหลังที่ 1

ภาพที่ 2




พื้นที่ของบ้านหลังที่ 2 (ชั้น 1)

ภาพที่ 3



พื้นที่ของบ้านหลังที่ 2 (ชั้น 2)

ภาพที่ 4



พื้นที่ของบ้านหลังที่ 3

ส่วนที่ 3: ความคิดเห็นเพิ่มเติม

แบบสอบถามฉบับนี้จัดทำขึ้นเพื่อศึกษาความคิดเห็นของท่านเกี่ยวกับการถอดปริมาณวัสดุในงานก่อสร้าง โดยใช้แบบจำลองปัญญาประดิษฐ์ (AI)

ก่อนตอบแบบสอบถามกรุณารับชมวิดีโอที่ลิงก์ <https://www.youtube.com/watch?v=SWZLJbZUPPA> เพื่อให้เห็นถึงขั้นตอน ระยะเวลา และผลลัพธ์จากแบบจำลอง

หลังจากชมวิดีโอแล้ว กรุณาตอบคำถามตามความรู้สึกและความคิดเห็นของท่านลงในช่องว่างที่กำหนด ข้อมูลที่ท่านให้จะถูกเก็บเป็นความลับ ใช้เพื่อการวิจัยทางวิชาการเท่านั้น ไม่มีผลกระทบใดๆ ต่อผู้ตอบแบบสอบถาม

ขอขอบคุณที่สละเวลาให้ความร่วมมือ

จากตัวอย่างการใช้งานแบบจำลองปัญญาประดิษฐ์ในการถอดปริมาณ ท่านมีความคิดเห็นอย่างไรเกี่ยวกับระดับความยุ่งยาก ความสะดวกในการใช้งาน รวมถึงประโยชน์ที่คาดว่าจะได้รับ เมื่อเปรียบเทียบกับ การถอดปริมาณด้วยมือ และท่านยอมรับระดับความน่าเชื่อถือของผลลัพธ์ได้หรือไม่ หากแบบจำลองมีความแม่นยำอยู่ในช่วงร้อยละ 80–90 ?

ท่านคาดว่าจะใช้แบบจำลองปัญญาประดิษฐ์ในการประมาณราคาหรือไม่ เพราะเหตุใดหรือมีเงื่อนไขได้ที่ท่านจะใช้ ?

ท่านมีข้อเสนอแนะเพิ่มเติมเพื่อการปรับปรุงหรือพัฒนาระบบนี้หรือไม่?

ภาคผนวก ข

ผลการตรวจจับวัตถุและค่า IOU ของทั้ง 3 แบบจำลองจากการฝึกด้วยจำนวนรูปภาพที่แตกต่างกัน



ตารางที่ ข-1 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	14	0	4	0	7	0	0	7	14	0	7	0
2	16	0	7	2	12	0	0	6	12	0	1	6
3	17	0	8	2	14	0	0	5	14	0	1	5
4	28	0	3	0	26	0	0	2	27	0	2	1
5	13	0	9	1	1	0	0	13	10	0	3	4
6	13	0	7	0	1	0	0	12	12	0	3	1
7	23	0	28	3	7	0	0	19	15	0	5	11
8	7	0	2	4	2	0	0	9	8	0	2	3
9	25	0	5	4	3	0	0	26	14	0	0	15
10	24	0	7	0	24	0	0	0	13	0	3	11
11	15	0	5	0	12	0	0	3	11	0	1	4
12	8	0	2	0	5	0	0	3	7	0	1	1
13	27	0	5	1	26	0	1	2	20	0	0	8
14	29	0	9	1	25	0	0	5	19	0	1	11
15	17	0	6	0	17	0	0	0	13	0	0	4
16	16	0	6	4	11	0	0	9	13	0	1	7
17	28	0	9	0	22	0	0	6	20	0	1	8
18	16	0	1	0	16	0	0	0	14	0	0	2
19	65	0	2	20	39	0	0	46	17	0	1	68
20	21	0	1	0	20	0	0	1	6	0	0	15

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-2 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	14	0	1	0	11	0	0	3	14	0	7	0
2	16	0	4	2	13	0	0	5	14	0	2	4
3	18	0	5	1	15	0	1	4	14	0	0	5
4	28	0	0	0	27	0	0	1	26	0	1	2
5	13	0	4	1	9	0	0	5	13	0	1	1
6	13	0	2	0	10	0	1	3	11	0	2	2
7	18	0	14	8	9	0	0	17	13	0	4	13
8	7	0	1	4	7	0	0	4	3	0	2	8
9	12	0	0	17	7	0	1	22	17	0	1	12
10	24	0	3	0	24	0	1	0	21	0	3	3
11	14	0	2	1	14	0	1	1	13	0	4	2
12	6	0	2	2	8	0	0	0	8	0	2	0
13	27	0	4	1	26	0	1	2	24	0	0	4
14	29	0	4	1	26	0	0	4	24	0	0	6
15	17	0	4	0	17	0	0	0	13	0	1	4
16	8	0	0	12	14	0	0	6	15	0	2	5
17	28	0	6	0	26	0	0	2	23	0	2	5
18	16	0	0	0	16	0	0	0	16	0	2	0
19	49	0	1	36	55	0	1	30	32	0	0	53
20	20	0	0	1	21	0	0	0	7	0	1	14

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-3 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	14	0	4	0	11	0	0	3	13	0	5	1
2	16	0	3	2	16	0	0	2	15	0	2	3
3	18	0	3	1	18	0	0	1	17	0	0	2
4	28	0	2	0	28	0	0	0	28	0	0	0
5	14	0	5	0	9	0	0	5	9	0	6	5
6	13	0	5	0	10	0	1	3	13	0	6	0
7	21	0	3	5	12	0	0	14	8	0	4	18
8	9	0	0	2	5	0	0	6	5	0	1	6
9	25	0	0	4	18	0	0	11	18	0	0	11
10	23	0	3	1	24	0	0	0	21	0	2	3
11	14	0	5	1	14	0	0	1	14	0	0	1
12	5	0	1	3	8	0	0	0	8	0	3	0
13	27	0	7	1	27	0	0	1	26	0	0	2
14	28	0	3	2	28	0	1	2	25	0	4	5
15	17	0	6	0	17	0	0	0	17	0	1	0
16	12	0	2	8	16	0	1	4	11	0	0	9
17	28	0	5	0	28	0	0	0	26	0	1	2
18	16	0	0	0	16	0	0	0	16	0	0	0
19	65	0	4	20	65	0	0	20	37	0	1	48
20	20	0	1	1	21	0	0	0	6	0	0	15

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-4 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	14	0	3	0	13	0	0	1	14	0	5	0
2	16	0	5	2	16	0	0	2	14	0	2	4
3	18	0	3	1	17	0	0	2	16	0	3	3
4	28	0	2	0	28	0	0	0	28	0	3	0
5	14	0	4	0	13	0	1	1	13	0	4	1
6	13	0	5	0	12	0	0	1	13	0	1	0
7	24	0	4	2	18	0	0	8	11	0	7	15
8	8	0	2	3	11	0	0	0	4	0	3	7
9	21	0	1	8	27	0	1	2	15	0	0	14
10	24	0	6	0	24	0	0	0	23	0	4	1
11	14	0	1	1	15	0	0	0	14	0	5	1
12	7	0	0	1	8	0	0	0	8	0	0	0
13	27	0	4	1	27	0	0	1	26	0	2	2
14	28	0	3	2	28	0	0	2	24	0	4	6
15	17	0	4	0	17	0	0	0	17	0	2	0
16	14	0	5	6	16	0	1	4	17	0	0	3
17	28	0	3	0	28	0	0	0	25	0	2	3
18	16	0	0	0	16	0	0	0	16	0	1	0
19	64	0	2	21	64	0	0	21	32	0	2	0
20	20	0	1	1	21	0	0	0	19	0	1	2

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-5 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	13	0	3	1	14	0	0	0	14	0	4	0
2	16	0	2	2	16	0	0	2	15	0	1	3
3	16	0	2	3	18	0	0	1	17	0	2	2
4	28	0	2	0	28	0	0	0	28	0	2	0
5	14	0	1	0	13	0	0	1	13	0	2	1
6	13	0	2	0	12	0	1	1	13	0	2	0
7	20	0	10	6	19	0	0	7	17	0	4	9
8	6	0	0	5	11	0	0	0	4	0	2	7
9	22	0	0	7	28	0	0	1	16	0	0	13
10	24	0	2	0	24	0	0	0	22	0	2	2
11	14	0	1	1	15	0	0	0	15	0	4	0
12	7	0	0	1	8	0	0	0	7	0	0	1
13	26	0	0	2	27	0	0	1	25	0	0	3
14	26	0	2	4	28	0	0	2	24	0	3	6
15	16	0	1	1	17	0	0	0	17	0	3	0
16	14	0	0	6	19	0	0	1	18	0	4	2
17	28	0	1	0	28	0	0	0	27	0	2	1
18	16	0	0	0	16	0	0	0	16	0	0	0
19	55	0	1	30	66	0	0	19	36	0	0	49
20	18	0	0	3	21	0	0	0	20	0	0	1

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-6 ค่า TP,TN,FP,FN ในการตรวจจับดวงไฟจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป

หน่วย: ดวง

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	13	0	2	1	14	0	0	0	13	0	2	1
2	15	0	3	3	16	0	0	2	15	0	1	3
3	17	0	3	2	18	0	0	1	17	0	2	2
4	28	0	2	0	28	0	0	0	28	0	2	0
5	14	0	1	0	13	0	0	1	13	0	2	1
6	13	0	2	0	12	0	0	1	13	0	0	0
7	20	0	9	6	21	0	0	5	15	0	4	11
8	7	0	0	4	11	0	0	0	5	0	0	6
9	24	0	2	5	29	0	0	0	16	0	0	13
10	24	0	2	0	24	0	0	0	22	0	2	2
11	13	0	0	2	15	0	0	0	13	0	4	2
12	7	0	0	1	8	0	0	0	7	0	0	1
13	27	0	1	1	27	0	0	1	25	0	0	3
14	27	0	3	3	29	0	0	1	24	0	3	6
15	17	0	1	0	17	0	0	0	17	0	3	0
16	14	0	0	6	18	0	0	2	18	0	4	2
17	28	0	1	0	28	0	0	0	27	0	2	1
18	16	0	0		16	0	0	0	16	0	0	0
19	58	0	1	27	68	0	0	17	41	0	0	44
20	19	0	0	2	21	0	0	0	20	0	0	1

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-7 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	2	0	0	5	2	0	0	5	3	0	3	4
2	4	0	2	4	2	0	0	6	1	0	0	7
3	4	0	2	6	4	0	0	6	1	0	0	9
4	1	0	0	9	3	0	0	7	1	0	0	9
5	1	0	5	9	2	0	0	8	1	0	0	9
6	1	0	6	6	1	0	0	6	1	0	0	6
7	7	0	8	0	4	0	0	3	2	0	0	5
8	4	0	4	0	2	0	0	2	4	0	3	0
9	5	0	12	2	2	0	0	5	5	0	1	2
10	5	0	1	10	7	0	0	8	1	0	0	14
11	3	0	1	6	3	0	0	6	2	0	0	7
12	0	0	0	3	1	0	0	2	0	0	0	3
13	1	0	0	5	2	0	0	4	4	0	0	2
14	1	0	3	8	1	0	0	8	3	0	1	6
15	9	0	0	5	7	0	0	7	1	0	0	13
16	6	0	4	3	4	0	0	5	3	0	1	6
17	3	0	1	7	2	0	0	8	8	0	2	2
18	3	0	0	4	2	0	0	5	1	0	0	6
19	0	0	22	4	1	0	0	3	0	0	4	2
20	3	0	3	8	3	0	0	8	4	0	1	7

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-8 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	5	0	0	2	2	0	0	5	5	0	1	2
2	6	0	1	2	2	0	0	6	4	0	0	4
3	4	0	0	6	4	0	0	6	6	0	0	4
4	8	0	0	2	6	0	0	4	7	0	0	3
5	8	0	0	2	3	0	0	7	6	0	3	4
6	6	0	0	1	1	0	0	6	4	0	2	3
7	7	0	2	0	5	0	0	2	6	0	3	1
8	3	0	1	1	4	0	0	0	4	0	3	0
9	5	0	4	2	3	0	0	4	7	0	3	0
10	12	0	0	3	5	0	0	10	4	0	0	11
11	5	0	1	4	3	0	0	6	5	0	0	4
12	3	0	0	0	2	0	0	1	0	0	0	3
13	4	0	2	2	4	0	0	2	6	0	0	0
14	2	0	1	7	4	0	0	5	5	0	0	4
15	8	0	0	6	6	0	0	8	9	0	0	5
16	7	0	1	2	1	0	0	8	7	0	0	2
17	3	0	0	7	2	0	0	8	8	0	0	2
18	4	0	0	3	5	0	0	2	5	0	0	2
19	1	0	5	3	2	0	0	2	0	0	1	4
20	3	0	1	8	3	0	0	8	8	0	2	3

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-9 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	6	0	1	1	4	0	0	3	6	0	2	1
2	6	0	2	2	6	0	0	2	5	0	0	3
3	8	0	0	2	4	0	0	6	6	0	0	4
4	8	0	0	2	7	0	0	3	8	0	0	2
5	8	0	0	2	2	0	0	8	8	0	1	2
6	6	0	0	1	3	0	1	4	6	0	7	1
7	7	0	2	0	6	0	2	1	7	0	4	0
8	4	0	0	0	4	0	2	0	4	0	3	0
9	5	0	2	2	5	0	0	2	5	0	2	2
10	8	0	0	7	4	0	0	11	12	0	0	3
11	3	0	1	6	5	0	0	4	3	0	2	6
12	3	0	0	0	3	0	0	0	3	0	0	0
13	4	0	1	2	6	0	1	0	4	0	1	2
14	8	0	0	1	8	0	0	1	8	0	1	1
15	13	0	0	1	6	0	0	8	11	0	0	3
16	8	0	0	1	4	0	0	5	8	0	2	1
17	7	0	0	3	5	0	0	5	8	0	0	2
18	5	0	0	2	6	0	0	1	5	0	0	2
19	1	0	3	3	3	0	5	1	1	0	5	3
20	3	0	0	8	6	0	0	5	3	0	2	8

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-10 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	7	0	1	0	6	0	0	1	6	0	1	1
2	6	0	2	2	7	0	0	1	7	0	0	1
3	9	0	0	1	8	0	0	2	9	0	0	1
4	9	0	0	1	9	0	0	1	9	0	0	1
5	8	0	0	2	9	0	0	1	8	0	0	2
6	6	0	0	1	6	0	1	1	5	0	2	2
7	7	0	2	0	6	0	2	1	7	0	1	0
8	4	0	0	0	4	0	2	0	4	0	2	0
9	5	0	2	2	5	0	0	2	4	0	0	3
10	14	0	0	1	12	0	0	3	12	0	0	3
11	8	0	0	1	7	0	0	2	7	0	2	2
12	3	0	0	0	3	0	0	0	3	0	0	0
13	4	0	1	2	6	0	1	0	4	0	0	2
14	7	0	0	2	8	0	0	1	6	0	0	3
15	13	0	0	1	9	0	0	5	13	0	0	1
16	8	0	1	1	8	0	0	1	8	0	0	1
17	8	0	0	2	9	0	0	1	9	0	0	1
18	6	0	0	1	7	0	0	0	5	0	0	2
19	2	0	2	2	3	0	5	1	2	0	2	2
20	9	0	0	2	10	0	0	1	7	0	2	4

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-11 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	7	0	1	0	6	0	0	1	7	0	2	0
2	6	0	0	2	7	0	0	1	6	0	0	2
3	10	0	0	0	10	0	0	0	9	0	0	1
4	9	0	1	1	10	0	0	0	9	0	0	1
5	9	0	0	1	10	0	0	0	8	0	0	2
6	6	0	0	1	7	0	3	0	5	0	0	2
7	7	0	0	0	7	0	5	0	7	0	3	0
8	4	0	0	0	4	0	1	0	4	0	2	0
9	6	0	1	1	4	0	2	3	6	0	1	1
10	14	0	0	1	15	0	2	0	12	0	1	3
11	8	0	0	1	7	0	0	2	7	0	1	2
12	3	0	0	0	3	0	0	0	3	0	0	0
13	5	0	1	1	6	0	1	0	4	0	0	2
14	8	0	1	1	9	0	0	0	7	0	0	2
15	13	0	0	1	14	0	1	0	13	0	0	1
16	8	0	1	1	8	0	0	1	8	0	1	1
17	9	0	0	1	9	0	3	1	9	0	0	1
18	7	0	0	0	7	0	0	0	6	0	0	1
19	3	0	3	1	4	0	4	0	3	0	2	1
20	10	0	0	1	10	0	2	1	10	0	2	1

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-12 ค่า TP,TN,FP,FN ในการตรวจจับสวิตช์ไฟจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	7	0	1	0	6	0	0	1	7	0	1	0
2	6	0	0	2	8	0	0	0	6	0	0	2
3	10	0	2	0	10	0	0	0	9	0	0	1
4	10	0	1	0	10	0	0	0	9	0	0	1
5	10	0	0	0	10	0	0	0	9	0	0	1
6	6	0	0	1	7	0	1	0	7	0	0	0
7	7	0	1	0	7	0	2	0	6	0	3	1
8	4	0	0	0	4	0	2	0	4	0	1	0
9	6	0	1	1	4	0	0	3	6	0	0	1
10	14	0	0	1	15	0	0	0	12	0	0	3
11	8	0	0	1	9	0	2	0	9	0	1	0
12	3	0	0	0	3	0	0	0	1	0	0	2
13	5	0	1	1	6	0	1	0	6	0	2	0
14	8	0	0	1	9	0	0	0	7	0	1	2
15	13	0	1	1	14	0	0	0	14	0	0	0
16	8	0	1	1	8	0	0	1	9	0	0	0
17	9	0	0	1	9	0	0	1	9	0	0	1
18	7	0	0	0	7	0	0	0	5	0	0	2
19	3	0	2	1	4	0	4	0	3	0	0	1
20	9	0	0	2	11	0	0	0	8	0	0	3

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-13 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	5	0	4	3	8	0	0	0	5	0	0	3
2	6	0	3	0	6	0	0	0	6	0	0	0
3	7	0	2	2	8	0	0	1	4	0	3	5
4	7	0	2	2	6	0	0	3	2	0	1	7
5	6	0	0	0	4	0	0	2	2	0	0	4
6	18	0	6	9	8	0	0	19	9	0	3	18
7	11	0	2	1	10	0	0	2	6	0	1	6
8	6	0	2	0	6	0	0	0	3	0	0	3
9	6	0	0	0	6	0	0	0	5	0	0	1
10	14	0	0	0	14	0	0	0	14	0	0	0
11	10	0	1	1	11	0	0	0	9	0	0	2
12	7	0	1	2	2	0	0	7	3	0	3	6
13	15	0	1	0	8	0	0	7	11	0	0	4
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	7	0	0	1	8	0	0	0
16	35	0	2	21	6	0	0	50	24	0	0	32
17	18	0	0	1	12	0	0	7	19	0	2	0
18	10	0	0	1	10	0	0	1	9	0	0	2
19	14	0	0	0	14	0	0	0	7	0	0	7
20	14	0	0	0	7	0	0	7	14	0	0	0

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-14 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	7	0	3	1	7	0	0	1	7	0	2	1
2	6	0	2	0	5	0	0	1	6	0	1	0
3	8	0	1	1	9	0	0	0	7	0	2	2
4	6	0	0	3	9	0	0	0	9	0	2	0
5	6	0	0	0	5	0	0	1	2	0	0	4
6	18	0	7	9	19	0	0	8	15	0	6	12
7	11	0	2	1	11	0	1	1	9	0	2	3
8	6	0	2	0	6	0	0	0	6	0	2	0
9	6	0	0	0	6	0	0	0	6	0	0	0
10	14	0	0	0	12	0	0	2	14	0	0	0
11	10	0	0	1	11	0	0	0	10	0	0	1
12	7	0	1	2	2	0	0	7	5	0	3	4
13	15	0	1	0	13	0	0	2	11	0	1	4
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	7	0	0	1	8	0	0	0
16	39	0	0	17	40	0	0	16	32	0	0	24
17	19	0	0	0	16	0	0	3	19	0	3	0
18	11	0	0	0	10	0	0	1	10	0	0	1
19	14	0	0	0	13	0	0	1	12	0	0	2
20	14	0	0	0	12	0	0	2	14	0	2	0

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-15 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	8	0	2	0	8	0	0	0	6	0	2	2
2	6	0	0	0	6	0	0	0	6	0	0	0
3	8	0	1	1	9	0	0	0	9	0	3	0
4	8	0	2	1	9	0	0	0	9	0	1	0
5	6	0	0	0	6	0	0	0	3	0	0	3
6	20	0	4	7	18	0	1	9	18	0	5	9
7	12	0	1	0	12	0	0	0	10	0	0	2
8	6	0	0	0	6	0	0	0	6	0	2	0
9	6	0	0	0	6	0	0	0	6	0	0	0
10	14	0	1	0	14	0	0	0	14	0	0	0
11	11	0	0	0	11	0	0	0	11	0	0	0
12	8	0	1	1	4	0	0	5	6	0	2	3
13	15	0	1	0	15	0	0	0	13	0	3	2
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	8	0	0	0	8	0	0	0
16	30	0	0	26	45	0	1	11	36	0	0	20
17	19	0	0	0	18	0	0	1	19	0	2	0
18	11	0	0	0	11	0	0	0	10	0	0	1
19	14	0	0	0	14	0	0	0	14	0	0	0
20	14	0	0	0	14	0	0	0	13	0	0	1

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-16 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	8	0	0	0	8	0	0	0	8	0	0	0
2	6	0	0	0	6	0	0	0	6	0	0	0
3	8	0	1	1	9	0	0	0	9	0	1	0
4	9	0	1	0	9	0	0	0	9	0	0	0
5	6	0	0	0	6	0	0	0	3	0	0	3
6	23	0	2	4	19	0	0	8	16	0	0	11
7	12	0	2	0	12	0	0	0	12	0	3	0
8	6	0	0	0	6	0	0	0	6	0	1	0
9	6	0	0	0	6	0	0	0	6	0	0	0
10	14	0	0	0	14	0	0	0	14	0	0	0
11	11	0	0	0	11	0	0	0	11	0	0	0
12	9	0	0	0	7	0	0	2	8	0	3	1
13	15	0	0	0	15	0	0	0	13	0	0	2
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	8	0	0	0	8	0	0	0
16	42	0	0	14	50	0	1	6	32	0	0	24
17	19	0	0	0	19	0	0	0	19	0	1	0
18	11	0	0	0	11	0	0	0	10	0	0	1
19	14	0	0	0	14	0	0	0	14	0	0	0
20	14	0	0	0	14	0	0	0	14	0	0	0

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-17 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	8	0	0	0	8	0	0	0	8	0	0	0
2	6	0	0	0	6	0	0	0	6	0	0	0
3	8	0	1	1	9	0	0	0	9	0	1	0
4	9	0	1	0	9	0	0	0	9	0	0	0
5	6	0	0	0	6	0	0	0	3	0	0	3
6	23	0	2	4	26	0	1	1	16	0	0	11
7	12	0	2	0	12	0	0	0	12	0	3	0
8	6	0	0	0	6	0	0	0	6	0	1	0
9	6	0	0	0	6	0	0	0	6	0	0	0
10	14	0	0	0	14	0	0	0	14	0	0	0
11	11	0	0	0	11	0	0	0	11	0	0	0
12	9	0	0	0	9	0	0	0	8	0	3	1
13	15	0	0	0	15	0	0	0	13	0	0	2
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	8	0	0	0	8	0	0	0
16	42	0	0	14	54	0	0	2	32	0	0	24
17	19	0	0	0	19	0	0	0	19	0	1	0
18	11	0	0	0	11	0	1	0	10	0	0	1
19	14	0	0	0	14	0	0	0	14	0	0	0
20	14	0	0	0	14	0	0	0	14	0	0	0

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-18 ค่า TP,TN,FP,FN ในการตรวจจับตัวรับจากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป

หน่วย: ตัว

รูปที่	Mask R-CNN				YOLOv9				U-Net			
	TP	TN	FP	FN	TP	TN	FP	FN	TP	TN	FP	FN
1	8	0	0	0	8	0	0	0	8	0	0	0
2	6	0	1	0	6	0	0	0	6	0	0	0
3	8	0	0	1	9	0	0	0	9	0	1	0
4	9	0	0	0	9	0	0	0	9	0	1	0
5	6	0	0	0	6	0	0	0	3	0	0	3
6	26	0	2	1	26	0	0	1	20	0	1	7
7	12	0	2	0	12	0	0	0	12	0	0	0
8	6	0	0	0	6	0	0	0	6	0	1	0
9	6	0	0	0	6	0	0	0	6	0	0	0
10	14	0	0	0	14	0	0	0	14	0	0	0
11	11	0	0	0	11	0	0	0	11	0	0	0
12	9	0	0	0	9	0	0	0	7	0	3	2
13	15	0	0	0	15	0	0	0	13	0	1	2
14	7	0	0	0	7	0	0	0	7	0	0	0
15	8	0	0	0	8	0	0	0	8	0	0	0
16	43	0	0	13	55	0	0	1	34	0	0	22
17	19	0	0	0	19	0	0	0	19	0	2	0
18	11	0	0	0	11	0	0	0	11	0	0	0
19	14	0	0	0	14	0	0	0	14	0	0	0
20	13	0	0	1	13	0	1	1	12	0	0	2

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-19 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 100 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	69.52%	81.72%	83.38%
2	4.58%	69.37%	56.79%
3	88.23%	72.14%	79.18%
4	85.98%	89.12%	94.35%
5	31.28%	44.41%	9.88%
6	9.27%	53.01%	11.45%
7	0.00%	28.61%	7.11%
8	9.83%	15.75%	4.74%
9	34.42%	65.62%	48.66%
10	20.13%	57.93%	81.51%
11	38.83%	51.76%	41.22%
12	16.34%	29.96%	19.64%
13	32.43%	64.02%	7.95%
14	37.88%	81.77%	25.98%
15	14.31%	50.68%	0.17%
16	19.53%	50.14%	1.63%
17	11.09%	69.59%	77.72%
18	20.04%	86.79%	45.93%
19	9.35%	68.54%	45.27%
20	18.40%	73.39%	11.96%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-20 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 150 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	65.68%	64.13%	64.24%
2	9.53%	69.85%	73.68%
3	87.52%	58.08%	87.53%
4	86.58%	90.90%	92.14%
5	60.29%	38.42%	18.39%
6	22.39%	53.14%	55.12%
7	1.35%	40.52%	7.12%
8	13.18%	47.44%	12.70%
9	35.24%	74.98%	74.35%
10	15.74%	68.27%	63.69%
11	52.82%	61.89%	74.88%
12	17.11%	57.10%	24.02%
13	52.10%	62.20%	62.29%
14	51.81%	64.25%	32.99%
15	17.18%	58.98%	39.13%
16	26.55%	72.72%	14.07%
17	30.16%	73.86%	62.92%
18	41.62%	50.61%	37.11%
19	28.96%	54.83%	25.36%
20	16.05%	92.95%	56.58%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-21 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 200 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	61.78%	87.04%	81.60%
2	18.87%	75.16%	74.21%
3	89.60%	70.23%	87.17%
4	87.27%	90.66%	96.08%
5	69.64%	83.53%	36.88%
6	50.22%	88.13%	65.21%
7	70.76%	56.71%	16.52%
8	60.08%	44.87%	21.32%
9	56.28%	88.95%	71.30%
10	33.68%	81.95%	79.33%
11	49.68%	86.86%	71.94%
12	58.69%	66.42%	64.68%
13	58.87%	71.59%	91.39%
14	64.43%	59.08%	57.01%
15	49.35%	43.58%	34.97%
16	74.58%	53.06%	37.52%
17	45.66%	67.52%	77.37%
18	38.80%	66.47%	58.85%
19	24.21%	26.25%	30.43%
20	75.45%	93.79%	78.82%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-22 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 250 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	60.02%	84.52%	79.24%
2	12.60%	84.76%	50.51%
3	89.82%	71.43%	82.95%
4	85.95%	90.82%	92.28%
5	76.62%	49.29%	82.29%
6	81.41%	89.59%	95.67%
7	90.82%	74.00%	94.35%
8	65.62%	43.40%	58.00%
9	71.25%	95.02%	88.89%
10	41.09%	83.26%	67.80%
11	69.38%	88.68%	82.72%
12	92.06%	74.10%	97.71%
13	78.64%	91.36%	95.41%
14	67.53%	57.08%	73.88%
15	54.68%	44.30%	52.59%
16	83.88%	88.35%	90.10%
17	60.38%	68.53%	80.26%
18	48.12%	83.21%	51.18%
19	34.02%	35.39%	52.89%
20	86.46%	89.19%	91.55%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-23 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 300 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	61.62%	81.40%	69.45%
2	17.60%	75.00%	45.09%
3	81.14%	82.06%	77.76%
4	77.35%	79.25%	92.63%
5	66.53%	71.00%	89.96%
6	81.35%	84.50%	97.93%
7	93.04%	87.00%	97.06%
8	70.03%	46.20%	68.06%
9	84.05%	66.54%	96.48%
10	40.18%	87.16%	66.71%
11	87.25%	95.66%	83.56%
12	94.01%	79.62%	96.99%
13	86.81%	95.38%	98.20%
14	67.81%	68.48%	81.04%
15	51.70%	45.87%	65.97%
16	85.16%	94.67%	92.20%
17	57.88%	67.46%	90.56%
18	38.56%	86.52%	65.74%
19	44.90%	42.72%	67.16%
20	85.74%	94.35%	96.47%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ตารางที่ ข-24 ค่า IOU จากการฝึกแบบจำลองด้วยรูปภาพ 350 รูป

	Mask R-CNN	YOLOv9	U-Net
รูปที่	IOU	IOU	IOU
1	61.62%	94.98%	69.45%
2	17.60%	76.69%	45.09%
3	84.80%	92.95%	81.55%
4	87.28%	80.46%	92.63%
5	75.52%	96.96%	89.96%
6	81.35%	92.83%	97.93%
7	93.04%	87.00%	97.06%
8	70.03%	95.44%	68.06%
9	88.40%	66.54%	96.48%
10	40.18%	87.16%	66.71%
11	87.25%	89.19%	83.56%
12	94.01%	79.62%	96.99%
13	86.81%	72.44%	98.20%
14	67.81%	68.48%	81.04%
15	80.61%	69.56%	65.97%
16	85.16%	89.14%	92.20%
17	82.88%	77.41%	92.66%
18	89.92%	88.69%	50.37%
19	87.31%	59.28%	87.00%
20	89.53%	74.92%	95.84%

หมายเหตุ จำนวนรอบการฝึก 80 รอบ ขนาดของรูปภาพ 1700x1200 อัตราการเรียนรู้ 0.001

ประวัติผู้เขียน

ชื่อ	นาย เมธัส ชินศิริณ
ชื่อวิทยานิพนธ์	การประยุกต์ใช้ปัญญาประดิษฐ์ในการถอดปริมาณวัสดุและพื้นที่งานระบบไฟฟ้าในแบบก่อสร้างอาคารบ้านพักอาศัย
สาขาวิชา	วิศวกรรมโยธา
ประวัติ	เกิดวันที่ 1 เมษายน พ.ศ. 2541 การศึกษามัธยมศึกษา โรงเรียนโยธินบูรณะ พ.ศ. 2558 ระดับปริญญาตรี วิศวกรรมศาสตรบัณฑิต (วิศวกรรมโยธา) มหาวิทยาลัยเกษตรศาสตร์ พ.ศ. 2563

