


การประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อตรวจสอบสถานะ
ของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน

APPLYING CONVOLUTIONAL NEURAL NETWORK FOR CONDITION
MONITORING IN ELECTRICAL EQUIPMENT USING INFRARED
THERMOGRAPHY



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมการวัดคุม

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2562

KMITL-2019-EN-M-060-069

การประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อตรวจสอบสถานะ
ของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน

APPLYING CONVOLUTIONAL NEURAL NETWORK FOR CONDITION
MONITORING IN ELECTRICAL EQUIPMENT USING INFRARED
THERMOGRAPHY



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมการวัดคุม

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2562

KMITL-2019-EN-M-060-069

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

APPLYING CONVOLUTIONAL NEURAL NETWORK FOR CONDITION
MONITORING IN ELECTRICAL EQUIPMENT USING INFRARED
THERMOGRAPHY



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN INSTRUMENTATION ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2019

KMITL-2019-EN-M-060-069

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2019

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อตรวจสอบสถานะของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน
นักศึกษา	นายศุภณัฐ รกรากทอง
รหัสประจำตัว	60601008
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมการวัดคุม
พ.ศ.	2562
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ. ดร.ทวิพล ชี้อัสตย์
อาจารย์ที่ปรึกษาวิทยานิพนธ์(ร่วม)	ผศ. ดร.นรินทร์ ธรรมารักษ์วัฒน์

บทคัดย่อ

วิทยานิพนธ์ฉบับนี้ นำเสนอวิธีการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network , CNN) เพื่อทำการจำแนกประเภทอุปกรณ์ไฟฟ้า และตรวจสอบสถานะการทำงานด้วยการประมวลผลภาพถ่ายความร้อน โดยการใช้เทคนิคการถ่ายโอนข้อมูล (Transfer Learning) เพื่อสร้างโมเดลในการทำนายชนิดและตำแหน่งของอุปกรณ์ไฟฟ้าภายในตู้ควบคุม โดยในงานวิจัยนี้ใช้ระบบควบคุมมอเตอร์เหนี่ยวนำ 3 เฟส เป็นกรณีศึกษา จากผลการทดลองโปรแกรมที่พัฒนาขึ้นมีความแม่นยำในการตรวจสอบสถานะของอุปกรณ์เฉลี่ยอยู่ที่ 86.67 % นอกจากนี้ยังสามารถตรวจสอบสถานะของอุปกรณ์ไฟฟ้าได้พร้อมกันหลายอุปกรณ์ ทำให้สามารถทำการซ่อมบำรุงได้อย่างทันเวลาและไม่ส่งผลเสียต่ออุปกรณ์ วิธีการนี้สามารถนำมาประยุกต์ใช้กับการสร้างระบบแจ้งเตือนอัตโนมัติสำหรับอุปกรณ์อื่นๆ ที่มีความไวต่อความร้อนได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต่ออ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis Title	Applying Convolutional Neural Network for Condition Monitoring in Electrical Equipment using Infrared Thermography
Student	Mr. Suppanut Rokrakthong
Student ID.	60601008
Degree	Master of Engineering
Program	Instrumentation Engineering
Year	2019
Thesis Advisor	Assoc. Prof. Dr Taweepol Suesut
Thesis Co-Advisor	Asst. Prof. Dr. Narin Tammarugwattana

ABSTRACT

This thesis proposes a method to apply the convolutional neural network to classify the type of electrical equipment in control panel as well as to monitor the operating status by thermal image processing. The transfer learning technique was used to create the model for predicting the type and the position locating in the control panel. In this research, the electrical control system for 3 phase induction motor was used as a case study. According to the experimental results, the developed program can achieve an accuracy of 86.67 %. Moreover, this method can check the operating status of multiple electrical equipment. This technique can be implemented to an automatic alarm annunciation system for other dangerous equipment with sensitive to thermal as well.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

ขอขอบพระคุณ รศ.ดร.ทวีพล ชี้อัสตัย และ ผศ.ดร.นรินทร์ ธรรมารักษ์วัฒน์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ให้ความรู้และคำแนะนำที่ตีเสมอมา

ขอขอบคุณ รศ.ดร.นงนัทธา หนูนาถ อาจารย์ประจำภาควิชาวิศวกรรมอาหารที่ให้คำแนะนำสำหรับการปรับปรุงแก้ไขวิทยานิพนธ์นี้สำเร็จลุล่วงไปได้ด้วยดี รวมไปถึงคณาจารย์ประจำภาควิชาวิศวกรรมการวัดคุม ได้แก่ ผศ.เชื้อ นกอยู่ รศ.ดร.สุพรรณ กุลพาณิชย์ ที่สนับสนุนทางด้านอุปกรณ์ในการทดลอง และอาจารย์ท่านอื่นๆ ที่มีได้เอ่ยนาม

ขอขอบพระคุณ ศูนย์พัฒนานวัตกรรมและบริการทางวิศวกรรม Engineering Innovative Development and Technology Services (EIDTs) สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ที่ให้การสนับสนุนทางด้านอุปกรณ์ในการทำวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณพ่อแม่ รวมทั้งเพื่อน พี่ น้องที่คอยให้คำปรึกษาทั้งในด้านความรู้และกำลังใจในการแก้ไขปัญหาต่างๆ

สุดท้ายนี้สำหรับคุณประโยชน์ที่เกิดจากวิทยานิพนธ์ฉบับนี้ ผู้เขียนขอมอบให้แก่ผู้มีพระคุณทุกท่านและให้ทุกท่านจงพบเจอแต่ความสำเร็จตลอดไป

ศุภณัฐ รกรากทอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และตัดอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป.....	VIII
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของวิทยานิพนธ์.....	2
1.3 ขอบเขตของวิทยานิพนธ์.....	2
1.4 ขั้นตอนการดำเนินงาน.....	2
1.5 ประโยชน์ที่ได้รับ.....	3
1.6 รายละเอียดของวิทยานิพนธ์.....	3
1.7 งานวิจัยที่เกี่ยวข้อง.....	4
บทที่ 2 ทฤษฎีและหลักการที่เกี่ยวข้อง.....	6
2.1 กล้องถ่ายภาพความร้อน.....	6
2.1.1 หลักการทำงานของกล้องถ่ายภาพความร้อน.....	6
2.1.2 ปัจจัยที่มีผลต่อการแสดงผลของกล้องถ่ายภาพความร้อน.....	6
2.2 ภาพดิจิทัล.....	7
2.2.1 ภาพขาว-ดำ.....	7
2.2.2 ภาพระดับสีเทา.....	7
2.2.3 ภาพสี.....	8
2.2.3.1 ภาพสีแบบ RGB.....	8
2.2.3.2 ภาพสีแบบดัชนี.....	8
2.2.3.3 ภาพถ่ายความร้อน.....	9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และดัดแปลงอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
2.3 การประมวลผลภาพดิจิทัล.....	9
2.3.1 การได้มาของภาพ.....	9
2.3.2 การปรับปรุงภาพ.....	10
2.3.2.1 Histogram Equalization.....	10
2.3.2.2 การใช้ตัวกรอง.....	11
2.3.3 การแบ่งส่วนภาพ.....	11
2.3.3.1 การทำการเทรสโฮล.....	11
2.3.3.2 การทำ K-mean Clustering.....	12
2.4 การเรียนรู้ของเครื่อง.....	13
2.4.1 การเรียนรู้แบบมีผู้สอน.....	13
2.4.2 การเรียนรู้แบบไม่มีผู้สอน.....	14
2.5 โค้รข่ายประสาทเทียม.....	15
2.5.1 หลักการทำงานของโครงข่ายประสาทเทียม.....	15
2.5.2 โค้รข่ายประสาทเทียมแบบคอนโวลูชัน.....	17
2.5.2.1 โครงสร้างสถาปัตยกรรมของ Faster-RCNN.....	19
2.5.2.1.1 Region Proposal Network.....	19
2.5.2.1.2 Fast-RCNN.....	21
2.5.2.2 โครงสร้างสถาปัตยกรรมของ SSD.....	22
2.5.3 เทคนิค Transfer Learning.....	23
2.6 การบำรุงรักษา.....	24
2.6.1 การบำรุงรักษาเชิงรับ.....	25
2.6.2 การบำรุงรักษาเชิงป้องกัน.....	25
2.6.3 การบำรุงรักษาตามสภาพ.....	25
2.6.4 การบำรุงรักษาเชิงรุก.....	26

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และดัดแปลงอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
บทที่ 3 วิธีการดำเนินงาน.....	27
3.1 ชุดอุปกรณ์ที่ใช้ในการออกแบบการทดลอง.....	27
3.1.1 อุปกรณ์ภายในตู้ควบคุมมอเตอร์สามเฟส.....	27
3.1.2 อุปกรณ์สำหรับชุดการทดลอง.....	28
3.1.3 การออกแบบการทดลอง.....	29
3.2 การออกแบบโปรแกรมเบื้องต้น.....	30
3.2.1 การสร้างโมเดลในการระบุชนิดและตำแหน่งของอุปกรณ์.....	30
3.2.1.1 การเตรียมข้อมูลเพื่อฝึกสอน.....	32
3.2.2 การเตรียมภาพ.....	34
3.2.3 การประมวลผลภาพถ่ายความร้อน.....	35
3.2.4 การประมวลผลเพื่อตรวจสอบสถานะของอุปกรณ์ไฟฟ้า.....	36
3.3 ขั้นตอนการทดลอง.....	41
3.3.1 การทดสอบโมเดลที่ใช้ในการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้า.....	41
3.3.2 การประมวลผลภาพถ่ายความร้อน.....	41
3.3.3 การตรวจสอบสถานะของอุปกรณ์ไฟฟ้า.....	42
บทที่ 4 ผลการทดลองและการวิเคราะห์ผลการทดลอง.....	44
4.1 การทดสอบโมเดลที่ใช้ในการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้า.....	44
4.2 การทดสอบหาตำแหน่งของจุดที่เกิดความผิดปกติด้วยภาพถ่ายความร้อน.....	47
4.3 การทดสอบหาอุปกรณ์ที่เกิดความผิดปกติ.....	48
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	53
5.1 สรุปผลการวิจัย.....	53
5.2 ข้อเสนอแนะ.....	54
เอกสารอ้างอิง.....	55
ภาคผนวก.....	58
ประวัติผู้เขียน.....	63

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และดัดแปลงอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
3.1 แสดงคุณสมบัติทางเทคนิคของกล้องถ่ายภาพความร้อน.....	29
3.2 แสดงการจำแนกสถานะของอุปกรณ์ด้วยภาพถ่ายความร้อนตามมาตรฐาน NETA.....	36
4.1 แสดงค่าเฉลี่ยความแม่นยำที่แต่ละจำนวนรอบการเรียนรู้.....	44
4.2 แสดงประสิทธิภาพของโมเดลในการตรวจจับวัตถุที่จำนวนรอบการเรียนรู้ 20000.....	45
4.3 แสดงค่าอนุมัติเมื่อเปรียบเทียบกับค่าที่วัดได้จากกล้องถ่ายภาพความร้อน.....	48
4.4 แสดงผลการทดลองตรวจสอบสถานะของอุปกรณ์ไฟฟ้า.....	52



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และตัด vii อ่างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่		หน้า
2.1	แสดงผลการแปลงค่าฟังก์ชันที่ได้จากเมทริกซ์มาแสดงด้วยค่าที่แตกต่างกันในแต่ละพิกเซล.....	7
2.2	แสดงตัวอย่างของการแสดงผลภาพดิจิทัล.....	8
2.3	แสดงภาพถ่ายความร้อนแบบต่างๆ.....	9
2.4	แสดงขั้นตอนของการประมวลผลภาพดิจิทัล.....	10
2.5	แสดงตัวอย่างผลลัพธ์ของการทำ histogram equalization.....	11
2.6	แสดงตัวอย่างการทำ threshold image ของภาพระดับสีเทา.....	12
2.7	แสดงตัวอย่างภาพของการแบ่งส่วนภาพด้วยการใช้ k-means.....	13
2.8	แสดงความแตกต่างระหว่างการประมวลผลแบบเก่ากับการเรียนรู้ของเครื่อง.....	13
2.9	แสดงแผนผังการทำงานเบื้องต้นของการเรียนรู้แบบมีผู้สอน.....	14
2.10	แสดงตัวอย่างการทำงานของการเรียนรู้ของเครื่องแบบไม่มีผู้สอน.....	14
2.11	แสดงองค์ประกอบของโครงข่ายประสาทเทียม.....	15
2.12	แสดงการทำงานของโครงข่ายในแต่ละโหนด.....	17
2.13	แสดงตัวอย่างของตัวกรองในชั้น Convolutional Layer ของ Krizhevsky.....	18
2.14	แสดงการใช้ตัวกรองแบบ Max Operation เพื่อลดขนาดตัวแปร.....	18
2.15	แสดงโครงสร้างอย่างง่ายของโครงข่ายประสาทเทียมแบบคอนโวลูชัน.....	19
2.16	แสดงสถาปัตยกรรมของ Faster-RCNN.....	20
2.17	แสดงโครงสร้างการทำงานของ RPN.....	21
2.18	แสดงโครงสร้างการทำงานของ Fast R-CNN.....	21
2.19	แสดงโครงสร้างสถาปัตยกรรม SSD.....	22
2.20	แสดงการใช้เทคนิค Transfer Learning ด้วยการ ใช้ Pre-trained Model.....	23
2.21	แสดงกราฟเส้นโค้งรูปร่างของวงจรชีวิตเครื่องจักร.....	24
2.22	แสดงแผนผังประเภทของการซ่อมบำรุง.....	25
2.23	แสดงช่วงเวลาที่เหมาะสมในการทำการบำรุงรักษาประเภทต่างๆ.....	26

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และตั้ง **viii** อ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป(ต่อ)

รูปที่	หน้า
3.1	แสดงอุปกรณ์ภายในตู้ควบคุมระบบไฟสำหรับการควบคุมมอเตอร์สามเฟส..... 27
3.2	แสดงคอมพิวเตอร์ที่ใช้ในการประมวลผล..... 28
3.3	แสดงกล้องถ่ายภาพความร้อนชนิดพกพารุ่น FLUKE Ti-400..... 28
3.4	แสดงชุดทดลอง..... 30
3.5	แสดงอัตราส่วนของพื้นที่ซ้อนทับต่อพื้นที่ทั้งหมด..... 31
3.6	แสดงตรวจจับวัตถุของสถาปัตยกรรมใน 3 รูปแบบ Faster-RCNN SSD และ YOLO.... 31
3.7	แสดงการระบุตำแหน่งและชนิดของวัตถุด้วยโปรแกรม Labellmg..... 32
3.8	แสดงตัวอย่างของข้อมูลหลังถูกแปลงค่าเป็นตาราง..... 33
3.9	แสดงผลลัพธ์ของการแสดงผลที่ได้จากการใช้โมเดลในการระบุชนิดและตำแหน่งของวัตถุ..... 34
3.10	แสดงตัวอย่างการผลลัพธ์ที่ได้จากการปรับโพลีของกล้องถ่ายภาพความร้อน..... 34
3.11	แสดงขั้นตอนการทำงานเบื้องต้นของโปรแกรมหาพิกัดของตำแหน่งที่เกิดความผิดปกติ..... 36
3.12	แสดงการบอกพิกัดทั้ง 4 จุดของตำแหน่งวัตถุ..... 38
3.13	แสดงผลการทดสอบการระบุตำแหน่งของอุปกรณ์ไฟฟ้าแต่ละชนิดด้วยการกำหนดค่าเทรโฮล..... 38
3.14	แสดงอัลกอริทึมการตรวจสอบสถานะของอุปกรณ์ไฟฟ้า..... 39
3.15	แสดงอัลกอริทึมการตรวจสอบสถานะของอุปกรณ์ไฟฟ้า(ต่อ)..... 40
3.16	แสดง Interface ของโปรแกรมตรวจสอบสถานะของอุปกรณ์..... 43
3.17	แสดงตัวอย่างการแสดงผลของโปรแกรมตรวจสอบสถานะของอุปกรณ์..... 43
4.1	แสดงกราฟผลของ mAP @ 0.5:0.05:0.95 ของสถาปัตยกรรม SSD..... 45
4.2	แสดงกราฟผลของ mAP @ 0.5:0.05:0.95 ของสถาปัตยกรรม Faster-RCNN..... 45
4.3	แสดงผลการทดสอบโมเดลของสถาปัตยกรรม Faster-RCNN..... 46
4.4	แสดงผลการทดสอบโมเดลของสถาปัตยกรรม SSD..... 46
4.5	แสดงภาพถ่ายความร้อนที่แสดงผลเป็นภาพถ่ายแบบระดับสีเทาขนาด 8 บิต..... 57
4.6	แสดงตัวอย่างการอ่านค่าอุณหภูมิ..... 59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และดัดแปลงอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป(ต่อ)

รูปที่		หน้า
4.7	แสดงผลการทดลองหาตำแหน่งและประมวลผลค่าอุณหภูมิของจุดร้อน.....	50
4.8	แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยไม่มีอุปกรณ์ที่มีสถานะผิดปกติและ อุปกรณ์อยู่ภายนอกของตู้ควบคุมมอเตอร์.....	51
4.9	แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยมีอุปกรณ์ที่มีสถานะผิดปกติ 1 อุปกรณ์.....	51
4.10	แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยมีอุปกรณ์ที่มีสถานะผิดปกติ 3 อุปกรณ์.....	51



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

ในงานซ่อมบำรุงอุปกรณ์ไฟฟ้าการวางแผนเพื่อทำการซ่อมบำรุงหรือที่เรียกว่าการซ่อมบำรุงรักษาเชิงป้องกันนั้นมีความจำเป็นอย่างมากในอุตสาหกรรมทุกชนิด เนื่องจากการซ่อมบำรุงเชิงป้องกันสามารถช่วยลดความเสียหายที่จะเกิดขึ้นต่อกระบวนการต่างๆ และยังสามารถเพิ่มอายุการใช้งานของอุปกรณ์ไฟฟ้าให้ยาวนานมากขึ้น [1] โดยในงานซ่อมบำรุงโดยทั่วไปนั้นจะเป็นการดูความผิดปกติของสัญญาณทางไฟฟ้าที่เกิดขึ้นเช่นค่ากระแส ค่าแรงดัน หรือค่าความต้านทาน ซึ่งหากจะทำการสังเกตการณ์และเฝ้าระวังอุปกรณ์เหล่านี้จำเป็นต้องใช้เครื่องมือจำนวนมาก หรือหากวางแผนเพื่อเข้าไปทำการสำรวจอุปกรณ์เหล่านี้จำเป็นที่จะต้องหยุดการทำงานของอุปกรณ์ก่อน เพื่อเข้าไปติดตั้งเครื่องมือวัดเพื่อลดอันตรายที่จะเกิดขึ้นกับผู้ปฏิบัติงาน สำหรับอุตสาหกรรมขนาดใหญ่การหยุดการทำงานของอุปกรณ์เพียงหนึ่งตัวอาจส่งผลกระทบต่อกระบวนการทั้งหมด ดังนั้นในการตรวจสอบอุปกรณ์เพื่อวางแผนในการซ่อมบำรุงจึงมีการพัฒนาอุปกรณ์สามารถตรวจสอบความผิดปกติโดยไม่สัมผัส (Non-Contact Testing) [2] เพื่อลดความเสี่ยงของผู้ทำการทดสอบอุปกรณ์และสามารถทำการทดสอบอุปกรณ์ในขณะที่ยังมีการทำงานอยู่ โดยหนึ่งในวิธีที่ได้รับความนิยมเป็นอย่างมากคือการใช้กล้องถ่ายภาพความร้อน

กล้องถ่ายภาพความร้อนเป็นอุปกรณ์ที่สามารถแปลงค่าพลังงานที่แผ่ออกมาจากตัววัตถุ [3] เป็นค่าอุณหภูมิได้ ซึ่งความผิดปกติส่วนใหญ่ที่เกิดขึ้นบนตัวอุปกรณ์ล้วนเป็นเหตุที่นำมาซึ่งความร้อน เช่น การไม่สมดุลของโหลด การติดตั้งอุปกรณ์ที่ไม่ถูกต้อง และ การหลวมของจุดเชื่อมต่อบนอุปกรณ์ไฟฟ้า [4] และในปัจจุบันมีการใช้การวิเคราะห์ภาพถ่ายอินฟราเรดด้วยซอฟต์แวร์เพื่อลดการใช้ปริมาณคนและเพื่อเพิ่มให้เกิดความอัตโนมัติของระบบมากขึ้น โดยท้าววิธีการวิเคราะห์ความผิดปกติด้วยภาพถ่ายความร้อนนั้นจะทำการวิเคราะห์ได้เพียงสถานะของอุปกรณ์เท่านั้นว่ามีอุณหภูมิสูงจนเกิดความผิดปกติหรือไม่ หากจะทำให้ระบบเกิดความอัตโนมัติมากขึ้น จึงควรที่จะสามารถระบุชนิดของอุปกรณ์ได้ด้วย

การระบุชนิดของวัตถุด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันได้รับความนิยมอย่างมาก [5] ในการประมวลผลภาพเพื่อตรวจจับหรือระบุชนิดของวัตถุ เนื่องจากโครงข่ายประสาทเทียมแบบคอนโวลูชันเป็นการสร้างโมเดลเพื่อทำการทำนายชนิดของอุปกรณ์และสามารถระบุชนิดของอุปกรณ์ได้มากกว่า 10 ชนิด [6] และเมื่อทำการสร้างโมเดลเพื่อทำการทำนายแล้วไม่จำเป็นต้องสร้างโมเดลใหม่หากทำการทำนายด้วยวัตถุที่มีลักษณะหรือรูปแบบเดิม ซึ่งจะช่วยให้การทำงานของกระบวนการประมวลผลภาพมีความเป็นอัตโนมัติมากขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในงานวิจัยนี้นำเสนอการตรวจสอบสถานะของอุปกรณ์ไฟฟ้าด้วยการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันในการระบุชนิดของอุปกรณ์ไฟฟ้าและสามารถระบุตำแหน่งของอุปกรณ์ไฟฟ้าได้ โดยเป็นการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันชนิดใช้เพื่อตรวจจับวัตถุภายใต้สถาปัตยกรรมของ Faster Region based convolutional neural network (Faster R-CNN) ด้วยการใช้นิเทศ Transfer Learning และใช้การวิเคราะห์ความผิดปกติของอุปกรณ์ด้วยภาพถ่ายความร้อนโดยอ้างอิงสถานะของอุปกรณ์ไฟฟ้าจากมาตรฐานการทดสอบอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อนของอุปกรณ์ International electrical testing association (NETA)

1.2 วัตถุประสงค์ของวิทยานิพนธ์

1.2.1 เพื่อศึกษาการประเมินสถานะของอุปกรณ์ไฟฟ้าภายในตู้ควบคุมมอเตอร์ 3 เฟสด้วยภาพถ่ายความร้อน โดยอ้างอิงจากมาตรฐานของการทดสอบอุปกรณ์ไฟฟ้า International Electrical Testing Association (NETA)

1.2.2 เพื่อศึกษาการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันสำหรับตรวจจับวัตถุและทำการเปรียบเทียบประสิทธิภาพของโครงข่ายที่มีลักษณะการทำงานที่แตกต่างกัน

1.2.3 เพื่อนำเสนอเทคนิคการตรวจสอบสถานะของอุปกรณ์ไฟฟ้าภายในตู้ควบคุมมอเตอร์ 3 เฟสที่สามารถตรวจจับวัตถุภายในภาพและสามารถระบุถึงชนิดของอุปกรณ์ที่มีสถานะผิดปกติได้โดยการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันสำหรับการตรวจจับด้วยโปรแกรม LabVIEW 2018

1.3 ขอบเขตของวิทยานิพนธ์

1.3.1 อุปกรณ์ภายในตู้ควบคุมมอเตอร์ 3 เฟสประกอบด้วยเซอร์กิตเบรกเกอร์ชนิด 1 เฟส เซอร์กิตเบรกเกอร์ชนิด 3 เฟส สวิตช์แบบแม่เหล็กและโอเวอร์โวลต์รีเลย์

1.3.2 ห้องที่ควบคุมอุณหภูมิ 25 องศาเซลเซียส

1.3.3 กล้องถ่ายภาพความร้อนแบบพกพา ยี่ห้อ FLUKE รุ่น Ti400

1.3.4 โปรแกรมสำหรับใช้ในการออกแบบส่วนประมวลผลภาพ LabVIEW 2018

1.3.5 โปรแกรมสำหรับสร้างโมเดลเพื่อระบุชนิดของวัตถุด้วยภาษา Python Anaconda3

1.4 ขั้นตอนการดำเนินงาน

1.4.1 ศึกษาการใช้นิเทศ Convolutional neural network สำหรับการตรวจจับวัตถุ การวิเคราะห์ภาพถ่ายความร้อน การวิเคราะห์สถานะของอุปกรณ์ด้วยความร้อนที่เกิดขึ้นบนตัวอุปกรณ์ด้วยภาพถ่ายความร้อน การประมวลผลภาพ การใช้งานภาษา Python และการใช้งานโปรแกรม

LabVIEW

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.4.2 ทบทวนงานวิจัยที่เกี่ยวข้องกับการตรวจจับวัตถุต่างชนิดและวัตถุที่มีลักษณะภายนอกคล้ายคลึงกันและการวิเคราะห์สถานะของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน

1.4.3 ทำการออกแบบโปรแกรมการตรวจจับและระบุชนิดของวัตถุโดยการใช้เทคนิค Transfer Learning ของสถาปัตยกรรม Faster Region based Convolutional neural network (Faster-RCNN) และสถาปัตยกรรมแบบ Single Shot Detection (SSD) เพื่อเปรียบเทียบประสิทธิภาพ

1.4.4 ทำการออกแบบโปรแกรมในส่วนการวิเคราะห์สถานะของอุปกรณ์ด้วยภาพถ่ายความร้อน

1.4.5 ทำการออกแบบโปรแกรมตรวจสอบสถานะของอุปกรณ์ไฟฟ้าด้วยการประยุกต์ใช้การตรวจจับวัตถุร่วมกับการวิเคราะห์ด้วยภาพถ่ายความร้อน

1.4.6 ดำเนินการทดลองตามขั้นตอนที่ออกแบบ

1.4.7 วิเคราะห์และสรุปผลการทดลอง

1.5 ประโยชน์ที่ได้รับ

1.5.1 เพิ่มประสิทธิภาพของการตรวจสอบสถานะของอุปกรณ์ไฟฟ้าให้มีความหลากหลายในการใช้งานมากขึ้น เช่น สามารถบ่งบอกถึงชนิดของอุปกรณ์ที่เกิดความผิดปกติ

1.5.2 การนำเทคนิคโครงข่ายประสาทเทียมมาประยุกต์ใช้เพื่อเพิ่มความสามารถให้โปรแกรมในการตรวจสอบสถานะของอุปกรณ์ไฟฟ้า

1.6 รายละเอียดของวิทยานิพนธ์

ในเนื้อหาของวิทยานิพนธ์ฉบับนี้ประกอบด้วยเนื้อหาทั้งหมด 5 บท โดยในแต่ละบทมีรายละเอียดดังนี้

บทที่ 1 ประกอบด้วยที่มาและความสำคัญ ความมุ่งหมายและวัตถุประสงค์ของงานวิจัย ขอบเขตของงานวิจัย ขั้นตอนการดำเนินงานวิจัย ประโยชน์ที่ได้รับ รายละเอียดของวิทยานิพนธ์ และการทบทวนงานวิจัยที่เกี่ยวข้อง

บทที่ 2 ประกอบด้วยทฤษฎีและหลักการที่เกี่ยวข้องกับงานวิจัย ได้แก่ กล้องถ่ายภาพความร้อน ภาพถ่ายความร้อน การเรียนรู้ของเครื่อง ภาพดิจิทัล การประมวลผลภาพ โครงข่ายประสาทเทียมแบบคอนโวลูชัน การใช้เทคนิค Transfer Learning โครงสร้างของ Faster R-CNN และการซ่อมบำรุงรักษา

บทที่ 3 ประกอบด้วยการออกแบบวิธีการทดลองและอุปกรณ์ที่ใช้ในการทดลอง การออกแบบโปรแกรมเบื้องต้น ได้แก่ โปรแกรมการระบุชนิดและระบุตำแหน่งของอุปกรณ์ การเปรียบเทียบประสิทธิภาพของการตรวจจับวัตถุด้วยสถาปัตยกรรมที่แตกต่างกัน การประมวลผลความ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผิดปกติด้วยภาพถ่ายความร้อน การทดสอบความคลาดเคลื่อนของความสัมพันธ์ระหว่างค่าสีและค่าอุณหภูมิและการประมวลผลเพื่อตรวจสอบสถานะของอุปกรณ์ไฟฟ้าและขั้นตอนการทดลอง

บทที่ 4 ประกอบด้วยผลการทดลองแบ่งออกเป็น การทดสอบโมเดลที่ใช้ในการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้า การทดสอบการระบุตำแหน่งของอุปกรณ์ไฟฟ้าด้วย LabView การทดสอบหาตำแหน่งของจุดที่เกิดความผิดปกติด้วยภาพถ่ายความร้อน การทดสอบหาอุปกรณ์ที่เกิดความผิดปกติ

บทที่ 5 ประกอบด้วยการสรุปผลการทดลองและแนวทางการประยุกต์ใช้เพื่อพัฒนาให้โปรแกรมที่ออกแบบมีประสิทธิภาพมากขึ้น

1.7 งานวิจัยที่เกี่ยวข้อง

Ross Girshick (2015) [7] นำเสนอวิธีการตรวจจับวัตถุด้วยแบบใหม่ Fast R-CNN (Region based Convolutional neural network) จุดมุ่งหมายของงานวิจัยเพื่อเพิ่มความเร็วในการอบรมของการสร้างโมเดลในการตรวจจับวัตถุ และเปรียบเทียบประสิทธิภาพกับวิธีการแบบเก่า R-CNN โดยใช้ข้อมูล Pascal VOC 2012 ซึ่งเป็นฐานข้อมูลที่ถูกระบุชนิดของวัตถุในภาพและมีวัตถุมากกว่า 1000 ชนิด

Shaoqing Ren et al. (2016) [8] นำเสนอวิธีการใหม่ Faster R-CNN ซึ่งเป็นการทำงานรวมกันของโครงข่ายที่สร้างมาใหม่ Region proposal network (PRN) ร่วมการใช้ Fast R-CNN เพื่อเพิ่มความเร็วในการตรวจจับวัตถุให้มีความเร็วใกล้เคียงกับกับตรวจจับแบบเรียลไทม์ และทำการทดสอบกับชุดข้อมูล Pascal VOC 2007-2012 และ MS COCO โดยใช้เวลาในการตรวจจับ 198 มิลิวินาทีต่อภาพ

Kai Han et al. (2017) [9] นำเสนอการใช้ faster r-cnn ด้วยการปรับเปลี่ยนในส่วนของการสกัดคุณลักษณะจาก VGG-16 เป็น ResNet-101 และทำการทดสอบประสิทธิภาพของการตรวจจับตำแหน่งที่เกิดขึ้นบนผิวของล้อสองแบบประกอบด้วยตำแหน่งแบบรอยขีดและแบบจุดด้วยโมเดลที่สร้างขึ้นใหม่ นอกจากนี้ยังมีการปรับค่าพารามิเตอร์คือจำนวนรอบในการอบรมเพื่อทดสอบความแม่นยำ โดยผลการทดสอบมีความแม่นยำถึง 86.31 %

Hui Zou et al. (2015) [10] นำเสนอวิธีการตรวจสอบความผิดปกติบนอุปกรณ์ไฟฟ้าด้วยการใช้ภาพถ่ายอินฟราเรด โดยใช้วิธีการ K-mean และทำการเลือกใช้ค่าทางคณิตศาสตร์ เพื่อทำการกำหนดพื้นที่ที่สนใจบนภาพถ่ายความร้อน หลังจากนั้นใช้ Support vector machine ในการจำแนกสถานะของอุปกรณ์ไฟฟ้าโดยแบ่งออกเป็น 4 สถานะคือ ปกติ เริ่มผิดปกติ ผิดปกติมาก และ สถานะฉุกเฉิน ซึ่งวิธีการที่นำเสนอให้ความแม่นยำในการจำแนกสถานะของอุปกรณ์ไฟฟ้าสูงสุดที่ 97.8495%

Emil Mechkov (2017) [11] นำเสนอการใช้กล้องถ่ายภาพอินฟราเรดสำหรับการจำแนกสถานะของหม้อแปลงไฟฟ้าที่เกิดความผิดปกติที่เกิดจากจุดเชื่อมต่อที่ไม่แน่น โดยใช้มาตรฐานของ

NETA สำหรับการทดสอบอุปกรณ์ไฟฟ้าด้วยกล้องถ่ายภาพอินฟราเรด ซึ่งในทดลองจะใช้จุดที่อุณหภูมิเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สูงสุดเป็นตัวชี้วัดสถานะของอุปกรณ์ไฟฟ้า โดยสามารถจำแนกสถานะของอุปกรณ์ไฟฟ้าเป็นสองสถานะคือ ปกติและผิดปกติ

Nazmul Huda (2013) [12] นำเสนอวิธีการใช้กล้องถ่ายภาพอินฟราเรดเพื่อใช้ในการวางแผนในการซ่อมบำรุงเชิงป้องกันโดยการตรวจสอบความบกพร่องที่เกิดขึ้นบนอุปกรณ์ไฟฟ้า และใช้โครงข่ายประสาทเทียมและทำการเลือกใช้คุณสมบัติที่เหมาะสมกับการใช้โครงข่ายประสาทเทียม เพื่อใช้ในการระบุชนิดของสถานะโดยแบ่งออกเป็น มีจุดบกพร่องและไม่มีจุดบกพร่องและทำการเปรียบเทียบกับการใช้โครงข่ายประสาทเทียมปกติ โดยวิธีที่นำเสนอมีประสิทธิภาพดีกว่าโดยมีความแม่นยำอยู่ที่ 82.40%

Maria A. et al. (2017) [13] ได้นำเสนอการประยุกต์ใช้ภาพถ่ายอินฟราเรดร่วมกับการประมวลผลภาพ โดยการกำหนดพื้นที่ที่สนใจด้วยการทำ morphological และประเมินสถานะอัตโนมัติของชิ้นส่วนของอุปกรณ์ไฟฟ้าที่ใช้ในการควบคุมมอเตอร์ ประกอบด้วย พิวส์ เซอร์กิตเบรกเกอร์ และสวิตช์อิเล็กทรอนิกส์ โดยใช้การชี้วัดสถานะด้วยมาตรฐานการตรวจสอบอุปกรณ์ไฟฟ้าด้วยกล้องถ่ายภาพความร้อนของ NETA และทำการแบ่งสถานะออกเป็น 2 สถานะ คือ ปกติและผิดปกติ ซึ่งวิธีการที่นำเสนอมีประสิทธิภาพในการชี้วัดสถานะได้สูงถึง 94 %

บทที่ 2

ทฤษฎีและหลักการที่เกี่ยวข้อง

2.1 กล้องถ่ายภาพความร้อน

กล้องถ่ายภาพความร้อน (infrared thermography) คือ เครื่องมือที่ใช้ในการวัดค่าอุณหภูมิของผิวสัมผัสของวัตถุ ซึ่งอาศัยการแผ่รังสีอินฟราเรด (infrared radiation) ของวัตถุโดยวัตถุทุกชนิดที่มีอุณหภูมิสูงกว่าค่าศูนย์องศาสัมบูรณ์จะมีการแผ่รังสีความร้อนออกมาจากตัววัตถุ โดยอาศัยหลักการของการแผ่รังสีความร้อนของวัตถุ ทำให้การใช้กล้องถ่ายภาพความร้อนอินฟราเรดเป็นเทคนิคหนึ่งของการตรวจสอบหรือวิเคราะห์ห่ออุปกรณ์โดยไม่สัมผัส (Non-contact testing) [15]

2.1.1 หลักการทำงานของกล้องถ่ายภาพความร้อน

องค์ประกอบหลักของกล้องถ่ายภาพความร้อนประกอบด้วย เลนส์ (Lens) เซนเซอร์ตรวจจับอินฟราเรด (infrared detector) วงจรอิเล็กทรอนิกส์สำหรับแปลงค่ารังสี (Electronic Circuit) และหน้าจอแสดงผล (Display) โดยหลักการทำงานมีดังนี้ เซนเซอร์ตรวจจับอินฟราเรดจะรับรังสีที่แผ่ออกมาจากวัตถุเป้าหมาย (Target) ผ่านเลนส์ของกล้องถ่ายภาพความร้อน จากนั้นวงจรอิเล็กทรอนิกส์แปลงค่ารังสีเป็นค่าสัญญาณทางไฟฟ้าและนำค่าไปแสดงผลในรูปแบบ ตัวเลข เคนสี กราฟ หรือสามารถแสดงผลได้ทั้ง 3 รูปแบบ โดยอาศัยหลักการการแผ่รังสีของ Stefan-Boltzmann

2.1.2 ปัจจัยที่มีผลต่อการแสดงผลของกล้องถ่ายภาพความร้อน

ปัจจัยที่ส่งผลต่อการความแม่นยำในการวัดของกล้องถ่ายภาพความร้อนประกอบด้วย ชนิดและลักษณะพื้นผิวของวัตถุ ระยะห่างระหว่างกล้องถ่ายภาพความร้อนกับวัตถุเป้าหมาย สภาพแวดล้อม และพื้นที่การวัด

- ชนิดและลักษณะพื้นผิวของวัตถุ สำหรับวัตถุต่างชนิดกันจะมีความสามารถในการแผ่รังสี (emissivity, ϵ) ที่แตกต่างกัน ในการใช้กล้องถ่ายภาพความร้อนจึงจำเป็นที่จะต้องกำหนดค่าสัมประสิทธิ์การแผ่รังสีให้สัมพันธ์กับวัตถุ

- สภาพแวดล้อม เนื่องจากไม่เพียงวัตถุเป้าหมายเท่านั้นที่สามารถแผ่รังสีอินฟราเรดออกมาได้ แต่วัตถุภายนอกยังสามารถแผ่รังสีอินฟราเรดได้เช่นกันหรือเกิดการดูดซับพลังงานของตัวกลางต่างๆ เช่น ฝุ่นละออง คิวบิก และแก๊ส รวมไปถึงการสะท้อนรังสีของผิววัตถุอื่นๆ ที่ไม่ใช่วัตถุเป้าหมาย ทำให้พลังงานที่วัดได้เกิดความคลาดเคลื่อนและส่งผลกระทบต่อค่าของอุณหภูมิที่วัดได้

- พื้นที่การวัด หรือ ค่าขอบเขตการมองเห็น (Field of View, FOV) โดยพื้นที่การวัด มีความเกี่ยวข้องโดยตรงกับระยะห่างของวัตถุเป้าหมายซึ่งหากภายในภาพเห็นขนาดวัตถุเล็กเกินไปจะทำให้ค่าอุณหภูมิที่วัดได้เกิดความคลาดเคลื่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2 ภาพดิจิทัล

ภาพดิจิทัล (Digital images) คือ การแสดงค่าของฟังก์ชัน $f(x, y)$ ในแต่ละตำแหน่งของภาพซึ่งค่าฟังก์ชันจะขึ้นอยู่กับชนิดของภาพ เพื่อแสดงออกมาเป็นค่าสีหรือระดับความเข้ม (intensity) โดยสามารถเขียนเป็นเมทริกซ์ได้ดังนี้ [16]

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0,N-1) \\ f(1,0) & f(1,1) & \cdots & f(1,N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \cdots & f(M-1,N-1) \end{bmatrix}$$



รูปที่ 2.1 แสดงผลการแปลงค่าฟังก์ชันที่ได้มาแสดงด้วยค่าที่แตกต่างกันแต่ละพิกเซล [16]

2.2.1 ภาพขาว-ดำ

ภาพขาว-ดำ (Binary images) คือ ภาพที่ถูกถอดรหัส(encoded) จากเมทริกซ์สองมิติโดยค่าที่ถูกถอดออกมาจะถูกแทนด้วยสี ค่า 1 จะถูกแทนด้วยสีขาว และค่า 0 จะถูกแทนด้วยสีดำโดยส่วนมากภาพขาว-ดำมักถูกนำไปใช้ภาพที่เกี่ยวข้องกับตัวอักษรและภาพที่รายละเอียดของภาพไม่มาก

2.2.2 ภาพระดับสีเทา

ภาพระดับสีเทา (Gray scale images) คือ ภาพที่ถูกถอดรหัสเช่นเดียวกับภาพขาว-ดำ แต่จะมีการกระจายของค่าสีมากกว่าโดยไล่ระดับของความเข้มตั้งแต่สีดำไปยังสีขาว ภาพระดับสีเทานิยมใช้จะเป็นภาพระดับสีเทา แบบ 8 บิต ซึ่งจะไล่ระดับความเข้มตั้งแต่ 0 ถึง 255

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2.3 ภาพสี

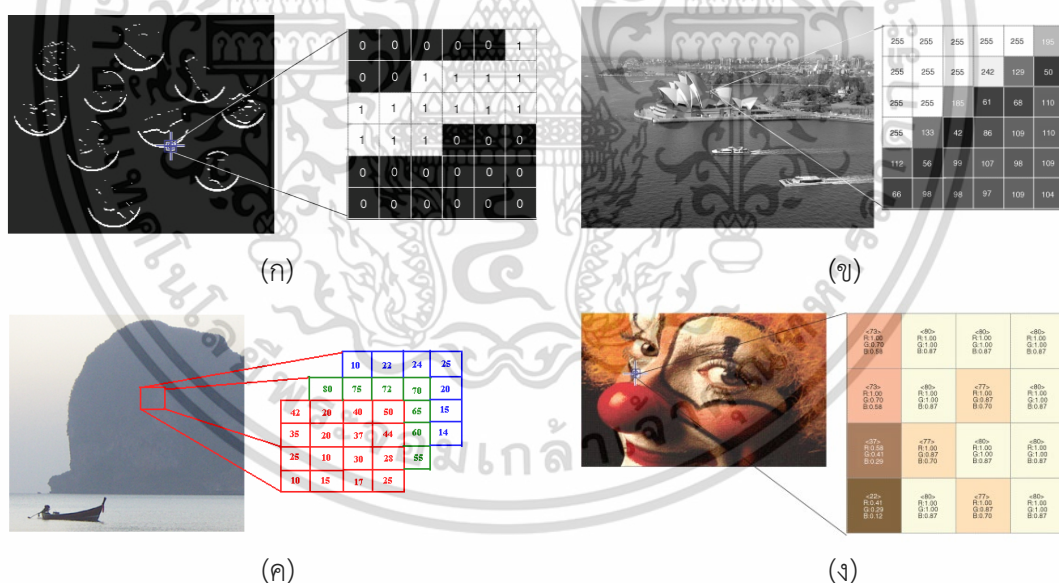
ภาพสี (Color images) คือ ภาพที่มีความซับซ้อนของการไล่ระดับสีที่มากขึ้นโดยการแสดงค่าสีจะถูกแบ่งออกเป็น 2 แบบ คือ การแสดงผลแบบ แดง-เขียว-น้ำเงิน (RGB) และการแสดงผลแบบดัชนี (index)

2.2.3.1 ภาพสีแบบ RGB

ภาพสีแบบ RGB คือ ภาพที่แสดงค่าสีตามระดับความเข้มของแม่สีหลักในแต่ละพิกเซล คือ แดง เขียว และ น้ำเงิน โดยในแต่ละแม่สีหลักจะมีระดับการกระจายของแต่ละสีอยู่ที่ 8 บิต (0-255) จากการรวมกันของแม่สีหลักทั้ง 3 สีทำให้ภาพสีแบบ RGB มีความละเอียดของสีอยู่ที่ 24 บิต หรือ 16,777,216 ระดับ

2.2.3.2 ภาพสีแบบดัชนี

ภาพสีแบบดัชนี คือ ภาพที่แสดงค่าสีในรูปแบบดัชนีและค่าดัชนีไปเทียบกับค่าในตารางสี (Color Table) โดยค่าตารางสีที่ใช้จะเป็นค่าที่ถูกกำหนดขึ้นเฉพาะภาพนั้น ๆ ส่วนมากการใช้ภาพสีแบบดัชนีจะใช้ค่าแทนดัชนีเป็นจำนวนเต็มตั้งแต่ 0-255




รูปที่ 2.2 แสดงตัวอย่างของการแสดงผลภาพดิจิทัล [16] (ก) ภาพขาว-ดำ (ข) ภาพระดับสีเทา (ค) ภาพสีแบบ RGB (ง) ภาพสีแบบดัชนี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.2.3.3 ภาพถ่ายความร้อน

ภาพถ่ายความร้อน คือ ภาพที่เกิดจากการแปลงค่าอุณหภูมิที่วัดได้จากกล้องถ่ายภาพความร้อนและทำการแสดงผลออกมาเป็นเฉดสี ซึ่งสามารถแสดงได้ในหลายรูปแบบ เช่น ภาพระดับสีเทารวมไปถึงการใช้สีบ่งบอกช่วงของอุณหภูมิ โดยทั่วไปสีโทนสว่างจะบ่งบอกถึงอุณหภูมิสูงและสีโทนมืดจะบ่งบอกถึงอุณหภูมิต่ำ [17]



รูปที่ 2.3 แสดงภาพถ่ายความร้อนแบบต่างๆ (ก) ภาพถ่ายความร้อนแบบ ironbow (ข) ภาพถ่ายความร้อนแบบระดับสีเทา

2.3 การประมวลผลภาพดิจิทัล

การประมวลผลภาพดิจิทัล (Digital image Processing) คือ การนำภาพมาประมวลผลด้วยวิธีการทางคณิตศาสตร์ผ่านคอมพิวเตอร์ เพื่อให้ได้รับข้อมูลทั้งเชิงปริมาณและเชิงคุณภาพเพื่อนำผลที่ได้มาทำการวิเคราะห์ข้อมูลต่างๆ เช่น การหาค่าตำแหน่งของวัตถุบนภาพ การวิเคราะห์ขนาดของวัตถุ และการหาจำนวนของวัตถุบนภาพ เป็นต้น ซึ่งการได้มาของข้อมูลที่จะนำมาวิเคราะห์ต้องผ่านกระบวนการต่างๆ เช่น การทำให้ภาพมีความคมชัดมากขึ้น การกำจัดสัญญาณรบกวนบนภาพ การแบ่งพื้นที่ที่สนใจในภาพ [16]

2.3.1 การได้มาของภาพ

การได้มาของภาพ (Image acquisition) คือ ขั้นตอนการนำภาพที่ได้รับเข้าสู่ระบบคอมพิวเตอร์หรือส่วนประมวลผลเพื่อใช้ในการวิเคราะห์โดยการได้มาของภาพ จะมีการนำภาพมาทำการประมวลผลขั้นต้น (Pre-processing) ด้วยการปรับขนาดภาพ เพิ่มความคมชัดของภาพ ลดสัญญาณรบกวน เป็นต้น

2.3.2 การปรับปรุงภาพ


การปรับปรุงภาพ (image enhancement) คือ ขั้นตอนการปรับปรุงภาพให้มีคุณภาพดีขึ้นหรือการเน้นรายละเอียดในส่วนของภาพที่ต้องการเพื่อนำภาพที่ได้ไปใช้งานในการประมวลผลซึ่ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

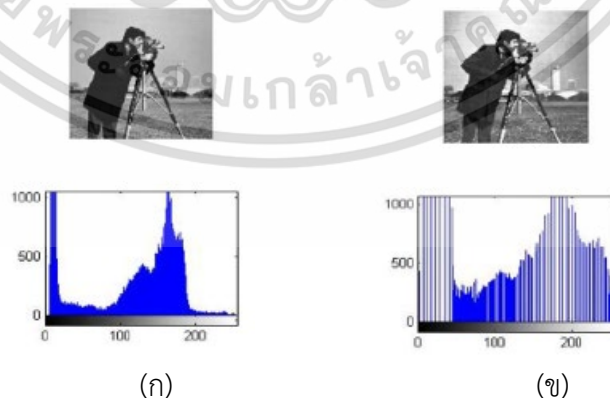
ประกอบด้วยหลายวิธีการในการปรับปรุงภาพเช่น การทำ Histogram Equalization การใช้ตัวกรองชนิดต่าง ๆ เพื่อเน้นในรายละเอียด

2.3.2.1 Histogram Equalization

การทำ Histogram Equalize เป็นการสร้างภาพใหม่ให้มีการกระจายกันอย่างสม่ำเสมอ โดยจะยึดจากการแจกแจงความถี่หรือจำนวนจุดภาพของ โดยบริเวณภาพที่มีค่าหรือจุดภาพใกล้เคียงกัน จะถูกขยายค่าให้มีความละเอียดของค่ามากขึ้นส่วนที่มีความแตกต่างของค่าน้อยจะถูกทำให้ค่าที่ต่างกันมีค่าลดลง



รูปที่ 2.4 แสดงขั้นตอนของการประมวลผลภาพดิจิทัล [16]



รูปที่ 2.5 แสดงตัวอย่างผลลัพธ์ของการทำ histogram equalization (ก) ภาพของข้อมูลเริ่มต้นก่อน

ทำ การ histogram equalization (ข) ภาพหลังจากการทำ histogram equalization [16]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.2.2 การใช้ตัวกรอง

การใช้ตัวกรอง (filter) เป็นการแปลงข้อมูลเพื่อใช้ในการสกัดข้อมูลที่ต้องการ (Sliding Window) [18] ทำให้สามารถจัดส่วนที่ไม่ต้องการออกไปจากภาพได้เช่นสัญญาณรบกวนหรือการเพิ่มรายละเอียดของภาพให้เด่นชัดขึ้นเช่นเน้นขอบของวัตถุ เป็นต้น ซึ่งการใช้ตัวกรองนั้นจะส่งผลต่อข้อมูลเดิมทำให้ข้อมูลที่ได้มีความแตกต่างจากข้อมูลเดิมอย่างสิ้นเชิง การใช้ตัวกรองนั้นมีหลายชนิด เช่น ตัวกรองแบบค่าเฉลี่ย (Mean filter) ตัวกรองแบบค่ากลาง (Median filter) ตัวกรองความถี่ต่ำ (Low-pass filter)

2.3.3 การแบ่งส่วนภาพ

การแบ่งส่วนภาพ (Image segmentation) ใช้หลักการความไม่ต่อเนื่องของค่าความสว่างของสี บนภาพดิจิทัลส่วนใหญ่วัตถุกับพื้นหลังจะมีความแตกต่างของสีที่ชัดเจนทำให้เกิดความไม่ต่อเนื่องของสี ณ ตำแหน่งนั้นๆ [17]


2.3.3.1 การทำเทรชโฮล

การทำเทรชโฮล (threshold image) เป็นวิธีการหนึ่งที่ถูกใช้เพื่อแยกส่วนของพื้นหลังกับวัตถุ หรือ การแยกส่วนของพื้นที่ที่สนใจ (Region of interest) ซึ่งการ threshold image นั้นคือการกำหนดค่าที่เป็นค่า threshold และทำการเปรียบเทียบกับค่าสีของแต่ละพิกเซลหากมีค่ามากกว่าค่า threshold จะถูกเปลี่ยนเป็น 1 หรือสีขาว และค่าน้อยกว่า threshold จะถูกเปลี่ยนเป็น 0 หรือสีดำ

$$g(x, y) = \begin{cases} 1 & \text{if } f(x, y) > T \\ 0 & \text{if } f(x, y) \leq T \end{cases}$$

โดย	$g(x,y)$	คือ	ค่าของฟังก์ชันเมื่อผ่านการทำ threshold image ที่ตำแหน่ง x,y
	$f(x,y)$	คือ	ค่าของฟังก์ชันของภาพเริ่มต้นที่ตำแหน่ง x,y
	T	คือ	ค่า threshold
	x	คือ	ตำแหน่งของแถว
	y	คือ	ตำแหน่งของคอลัมน์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.6 แสดงตัวอย่างการทำ threshold image ของภาพระดับสีเทา (ก) ภาพข้อมูลขาเข้า (ข) กราฟแสดงค่าความเข้มของของระดับสีเทา (ค) ผลลัพธ์ของการทำ threshold image

2.3.3.2 การทำ K-means Clustering

การทำ K-means Clustering ถูกใช้เพื่อแบ่งส่วนของภาพเป็นจำนวน k ส่วน ด้วยข้อมูลทางคณิตศาสตร์เพื่อใช้ในการกำหนดพื้นที่ที่สนใจ (Region of Interest) โดยแบ่งกลุ่มโดยการคำนวณระยะห่างของค่าในแต่ละพิกเซลของภาพใช้ระยะห่างจากจุดศูนย์กลางเรขาคณิต (Centriod) หรือจุดที่กำหนดขึ้นโดยระยะห่างระหว่างจุดมีค่าใกล้กับจุดศูนย์กลางเรขาคณิตจุดใดมากที่สุดกำหนดให้ค่านั้นอยู่ในกลุ่มเดียวกันและทำการคำนวณซ้ำจนกว่าจุดศูนย์กลางเรขาคณิตจะไม่เปลี่ยนแปลง[19]


$$d = \|p(x, y) - c_k\|$$

$$c_k = \frac{1}{k} \sum_{y \in c_k} \sum_{x \in c_k} p(x, y)$$

โดย $p(x, y)$ คือ ค่าของฟังก์ชันของรูปในพิกเซลตำแหน่ง x, y
 c_k คือ ค่าของจุดศูนย์กลางเรขาคณิต
 d คือ ระยะห่างระหว่างจุด

โดยข้อดีของการแบ่งส่วนภาพด้วย K-means คือ สามารถแบ่งภาพออกเป็นส่วนที่ต้องการได้มากกว่า 2 กลุ่มทำให้สามารถลดการคำนวณของส่วนที่ไม่ได้การในภาพออกไปได้

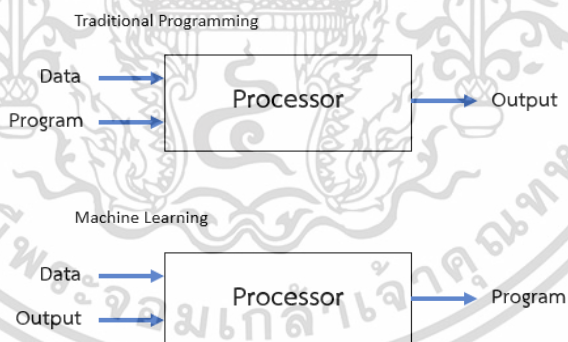
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.7 แสดงตัวอย่างภาพของการแบ่งส่วนภาพด้วยการใช้ k-means (ก) แบ่งกลุ่มภาพเป็น 3 กลุ่ม (ข) แบ่งกลุ่มภาพเป็น 5 กลุ่ม [10]

2.4 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง (Machine Learning) คือ การทำให้ส่วนประมวลผลสามารถเรียนรู้ข้อมูลเพื่อทำการทำนายผลข้อมูลได้โดยใช้ข้อมูลและผลลัพธ์เป็นข้อมูลขาเข้าเพื่อสร้างอัลกอริทึมในการทำนายผลลัพธ์ โดยการเรียนรู้ของเครื่องจะแบ่งได้ตามลักษณะของข้อมูลฝึกหรือข้อมูลขาเข้าได้ 2 รูปแบบ คือการเรียนรู้แบบมีผู้สอนและการเรียนรู้แบบไม่มีผู้สอน [20]




รูปที่ 2.8 แสดงความแตกต่างระหว่างการประมวลผลแบบเก่ากับการเรียนรู้ของเครื่อง

2.4.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

หลักการของการเรียนรู้แบบมีผู้สอนคือการนำข้อมูลที่ถูกต้องและต้องมีการบ่งบอกคุณสมบัติที่ใช้ในการฝึกสอนมาใช้เป็นข้อมูลฝึกสอนเพื่อใช้ในการสร้างเป็นโมเดลเพื่อใช้ในการทำนาย ซึ่งในการสร้างโมเดลจะมีการตรวจสอบความแม่นยำ (Validation) และมีการนำค่าผลลัพธ์มาใช้ในการปรับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ค่าตัวแปรเพื่อให้โมเดลมีความแม่นยำมากขึ้นโดยวิธีการที่นิยมสำหรับการเรียนรู้แบบมีผู้สอนคือ Support Vector Machine Linear Regression และ Convolutional neural network



รูปที่ 2.9 แสดงแผนผังการทำงานเบื้องต้นของการเรียนรู้แบบมีผู้สอน

2.4.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

หลักการการทำงานของการเรียนรู้แบบไม่มีผู้สอนจะมีลักษณะที่แตกต่างจากการเรียนรู้แบบมีผู้สอนคือชุดข้อมูลที่ใช้ในการเรียนรู้นั้นไม่มีการบ่งบอกถึงความถูกต้องของข้อมูล โดยใช้ความเหมือนกันหรือความคล้ายคลึงกันข้อมูลเป็นตัวชี้วัดผลของผลลัพธ์เช่นระยะห่างของข้อมูลที่เท่าๆ กัน นอกจากนี้ข้อแตกต่างของการเรียนรู้แบบไม่มีผู้สอนกับการเรียนรู้แบบมีผู้สอนคือไม่มีการตรวจสอบความแม่นยำของโมเดล โดยการเรียนรู้แบบไม่มีผู้สอนที่ได้รับความนิยมคือ K-means clustering Hierarchical clustering และ Apriori algorithm

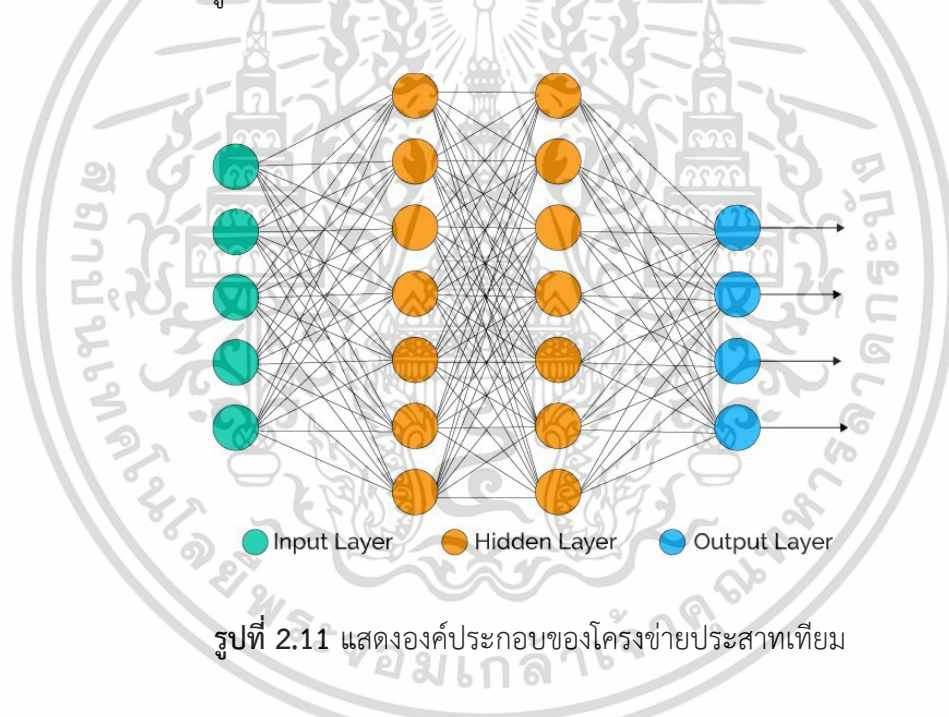


รูปที่ 2.10 แสดงตัวอย่างการทำงานของเครื่องแบบไม่มีผู้สอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural network) เป็นระบบที่ได้แรงบันดาลใจมาจากการเรียนแบบการทำงานของโครงข่ายประสาทของมนุษย์ กล่าวคือใช้ระบบการเรียนรู้โดยไม่มีโปรแกรมหรือสั่งการเป็นลำดับเพื่อพิจารณาผลลัพธ์ต่างๆ เช่นการระบุชนิดของภาพ การตัดสินใจต่างๆ โดยอ้างอิงข้อมูลพื้นฐานจากการเรียนรู้ที่ผ่านมา โดยโครงข่ายประสาทเทียมประกอบด้วย 3 ส่วนหลักคือ ส่วนอินพุต(Input node) ส่วนฮิดเดน (Hidden node) และส่วนเอาต์พุต (Output node) โดยส่วนสำคัญคือส่วนของฮิดเดนซึ่งเป็นส่วนที่จะส่งผลต่อผลลัพธ์การประมวลผลซึ่งในส่วนของฮิดเดนนี้จะประกอบด้วยฟังก์ชันที่ใช้ในการแปลงค่า (Activation) เพื่อใช้ในการคำนวณในส่วนต่อไปหากมีส่วนของฮิดเดนมากกว่า 1 ชั้น โดยโครงข่ายประสาทเทียมแบ่งได้ตามลักษณะโครงสร้าง เช่น single-layer feed forward multi-layer feed forward หรือการแบ่งตามลักษณะการทำงาน เช่น convolutional neural network โดยในวิทยานิพนธ์นี้จะกล่าวเพียงส่วนของ convolutional neural network ซึ่งถูกใช้สำหรับงานประเภทการประมวลผลภาพ



รูปที่ 2.11 แสดงองค์ประกอบของโครงข่ายประสาทเทียม

2.5.1 หลักการทำงานของโครงข่ายประสาทเทียม

หลักการทำงานของโครงข่ายประสาทเทียมเริ่มต้นโดยการนำข้อมูลอินพุตมาทำการคำนวณกับค่าน้ำหนัก (weight) จากนั้นทำการแปลงเป็นค่าฟังก์ชันทางคณิตศาสตร์ด้วย (Activation function) และทำการส่งข้อมูลต่อไปยังส่วนต่อไปเพื่อประมวลผลดังสมการที่ 2.1 โดยค่าฟังก์ชันทางคณิตศาสตร์ที่ได้รับความนิยมอย่างมากคือ Sigmoid tanh และ ReLU (Rectified linear unit) ซึ่งในแต่ละฟังก์ชันจะถูกใช้ในงานที่มีลักษณะแตกต่างกันออกไป โดยเมื่อทำการเรียนรู้ให้กับโครงข่ายจะมีการปรับค่าน้ำหนักในแต่ละโหนดเพื่อใช้ในการทำนายในกรณีที่เป็นโครงข่ายแบบมีผู้สอนและมีการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เพิ่มฟังก์ชันในการตัดส่วนที่มีผลมากในการทำนาย (Dropout) เพื่อลดผลกระทบต่อการใช้ข้อมูลที่มีผลต่อการทำนายมากเกินไป (Over-fitting)

$$\text{output} = f\left(\sum_{i=1}^n x_i \times w_i\right) \quad (2.1)$$

โดย


f คือ activation function

x คือ อินพุต


w คือ ค่าน้ำหนัก

สมการ Activation function เช่น ReLU tanh และ Sigmoid ดังแสดงตามสมการที่ 2.2 2.3 และ 2.4

$$\text{ReLU} \quad f(x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases} \quad (2.2)$$





$$\text{tanh} \quad f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sigmoid $f(x) = \frac{1}{1 + e^{-x}}$ (2.4)



รูปที่ 2.12 แสดงการทำงานของโครงข่ายในแต่ละโหนด

ที่มา: <https://medium.com/@sarankhotsathian/machine-learning-ann>


2.5.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional neural network) คือ โครงข่ายประสาทเทียมแบบที่ถูกสร้างขึ้นโดยใช้หลักการของการคอนโวลูชันเชิงพื้นที่ (Spatial Convolution) เพื่อใช้ในการสกัดคุณลักษณะโดยใช้ตัวกรอง (Sliding window) สำหรับการใช้เป็นข้อมูลในการทำนายผลลัพธ์ โดยส่วนประกอบสำคัญของโครงข่ายประสาทเทียมแบบคอนโวลูชันประกอบด้วย Convolution Layer Pooling Layer และ Fully-Connected Layer [26] โดยแต่ละส่วนจะถูกเชื่อมต่อกันด้วยการแปลงฟังก์ชันทางคณิตศาสตร์ในลักษณะเดียวกับการทำงานของโครงข่ายประสาทเทียมโดยทั่วไป แตกต่างโดยในส่วนของอดีตนั้นจะมีการทำคอนโวลูชันเชิงพื้นที่ที่ก่อนและทำการแปลงค่าเป็นค่าฟังก์ชันทางคณิตศาสตร์เพื่อใช้ในการประมวลผลในส่วนต่อไป

Convolutional Layer จะมีการสร้างตัวกรองขึ้นมาเพื่อใช้ในการสกัดคุณลักษณะ (Feature Extraction) ของภาพเพื่อสร้างแผนผังคุณลักษณะ (Feature map) เช่น สี ขอบ รูปทรงของวัตถุ เพื่อ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ใช้ในการจำแนกชนิดของวัตถุโดยอ้างอิงจากข้อมูลฝึกสอนโดยในแต่โครงข่ายจะมีลักษณะเฉพาะของแต่ละตัวกรองทั้งทางด้านจำนวนชั้นและขนาดของตัวกรอง



รูปที่ 2.13 แสดงตัวอย่างของตัวกรองในชั้น Convolutional Layer ของ Krizhevsky [22]

Pooling Layer จะมีการสร้างตัวกรองเพื่อใช้ในการลดตัวแปรเพื่อให้ง่ายต่อการคำนวณและลดปัญหา overfitting ของโครงข่ายวิธีที่นิยมใช้ในการลดขนาดของตัวแปรด้วยการใช้เมทริกซ์ขนาด 2x2 มาใช้ในลดขนาดของภาพด้วย Max Operation หรือที่เรียกว่า Max Pooling




รูปที่ 2.14 แสดงการใช้ตัวกรองแบบ Max Operation เพื่อลดขนาดตัวแปร

Fully Connected Layer คือส่วนสุดท้ายที่เป็นการเชื่อมต่อระหว่างจุดเชื่อมต่อทุกจุดของโครงข่ายเพื่อใช้ในการคำนวณตามค่า bias เพื่อหาผลลัพธ์ของโครงข่าย

โดยการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชัน คือ การแปลงค่าพิกเซลของรูปภาพในแต่ละชั้นด้วยการใช้ตัวกรองเพื่อให้ได้ผลลัพธ์สุดท้ายเป็นชนิดหรือกลุ่มที่จำแนกไว้ โดยค่าของฟังก์ชันในแต่ละชั้นอาจมีการเปลี่ยนแปลงตามลักษณะที่ต้องการสกัดเช่นในของ Convolution Layer และ Fully-Connected Layer ในทางกลับกันในส่วนของ Pooling Layer ที่เป็นการลดตัวแปรเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แปรเพื่อให้โครงข่ายใช้ทรัพยากรน้อยลงจะเป็นการใช้ฟังก์ชันคงที่เช่นการใช้ Max Pooling เป็นต้น โดยตัวแปรในชั้นของ Convolution Layer และ Fully-Connected จะถูกฝึกสอนด้วยการใช้ Gradient Descent Algorithm เพื่อทำการคำนวณและทำการจำแนกชนิดเพื่อให้สอดคล้องกับชุดข้อมูลฝึกสอน [23]



รูปที่ 2.15 แสดงโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

2.5.2.1 สถาปัตยกรรม Faster R-CNN

Faster R-CNN (Region-based Convolutional Neural Network) เป็นโมเดลของการตรวจจับวัตถุ ถูกสร้างขึ้นโดยใช้หลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน และแยกส่วนของการทำงานเป็นสองส่วนโดยคือส่วน RPN (Region Proposal Network) และส่วนของ Fast R-CNN โดยในส่วนแรกจะเป็นการใช้เพื่อตรวจหาวัตถุภายในภาพและส่วนที่สองจะเป็นส่วนที่ใช้ในการทำนายชนิดของวัตถุ [8]

2.5.2.1.1 Region Proposal Network

เป็นส่วนที่สร้างขึ้นเพื่อรับข้อมูลขาเข้าเป็นภาพไม่จำกัดขนาดและสร้างขอบเขตบนภาพโดยใช้คุณลักษณะของภาพ (Feature) เพื่อทำนายว่าพื้นที่ในการทำสร้างขอบเขตนั้นใช้วัตถุหรือไม่ และทำการส่งค่าเป็นตำแหน่งของขอบเขต เพื่อทำการกำหนดพื้นที่ที่สนใจ (Region of Interest) ให้กับส่วนทำนายชนิดของวัตถุ


หลักการทำงานเบื้องต้นของ RPN จะเริ่มจากการสร้างขอบเขต (anchor) ด้วยอัตราส่วนที่กำหนดเช่นความกว้างต่อความยาวของขอบเขตเป็น 2:1 1:1 และ 1:2 เป็นต้นและใช้ขอบเขตที่สร้างขึ้นเป็นตัวกรองและทำการเลื่อนเพื่อสกัดคุณลักษณะ (Sliding-window) และนำคุณสมบัติที่สกัดได้ไปทำการทำนายว่าพื้นที่ในภาพเป็นวัตถุหรือไม่โดยทำการกำหนดสัดส่วนพื้นที่ซ้อนทับของพื้นที่ทำนายเปรียบเทียบกับ Ground truth ต้องมีค่าไม่น้อยกว่า 0.7 และทำการส่งค่าพิกัดของขอบเขตที่สร้างขึ้นเพื่อใช้ในการจำแนกชนิดของวัตถุต่อด้วยส่วนการจำแนกชนิดวัตถุ ซึ่งเราสามารถคำนวณค่า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความสูญเสีย (Loss function) ได้ตั้งสมการที่ 2.5 และในส่วนของ การฝึกสอนเพื่อให้เกิดค่าความสูญเสียต่ำที่สุดโดยอาศัยหลักการการ back-propagation และ stochastic gradient descent และทำการคำนวณในทำนองเดียวกันทั้งทั้ง 4 พิกัดของกรอบที่ทำการประมาณค่า

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (2.5)$$

โดย p_i คือ ความน่าจะเป็นของการทำนายในกรอบที่ i t_i คือ เวกเตอร์บอกตำแหน่งของ พิกัดในการทำนาย t_i^* คือ เวกเตอร์บอกตำแหน่งของ ground truth L_{cls} คือ logarithm loss ของ การ classification L_{reg} คือ regression loss

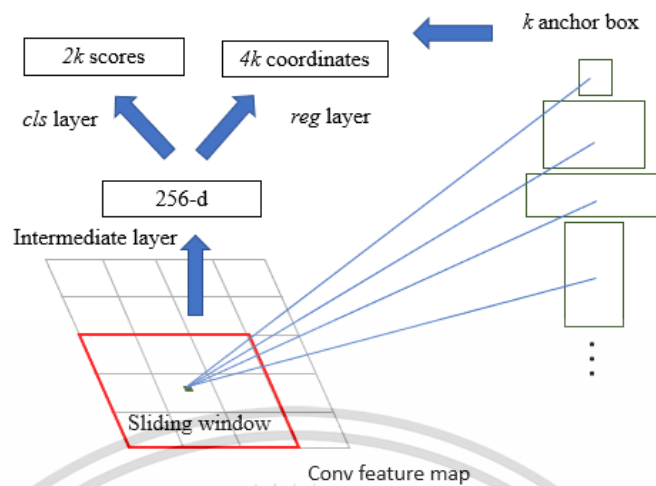


รูปที่ 2.16 แสดงสถาปัตยกรรมของ Faster-RCNN

โดยการประมาณค่าพิกัดจุดของทั้ง 4 จุดของกรอบบนภาพอ้างอิงจากสมการที่ 2.6

$$\begin{aligned} t_x &= (x - x_a) / w_a, t_y = (y - y_a) / h_a \\ t_w &= \log(w / w_a), t_h = \log(h / h_a) \\ t_x^* &= (x^* - x_a) / w_a, t_y^* = (y^* - y_a) / h_a \\ t_w^* &= \log(w^* / w_a), t_h^* = \log(h^* / h_a) \end{aligned} \quad (2.6)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.17 แสดงโครงสร้างการทำงานของ RPN

2.5.2.1.2 Fast R-CNN Architecture

เป็นส่วนที่ใช้จำแนกชนิดของวัตถุภายในพื้นที่ที่สนใจ โดยใช้ข้อมูลของภาพที่ถูกสกัดคุณสมบัตินั้นแล้วเป็นข้อมูลในการจำแนกชนิดของวัตถุ ซึ่งมีข้อเสียคือการกำหนดพื้นที่ที่สนใจด้วยอัลกอริทึมจากภายนอกทำให้การจำแนกด้วยวิธีนี้มีความล่าช้า จึงมีการนำมาประยุกต์ใช้ร่วมกับ Region proposal network เพื่อเพิ่มประสิทธิภาพให้สามารถจำแนกชนิดของวัตถุได้รวดเร็วมากขึ้น [7]

โดยการทำงานเบื้องต้นของ Fast R-CNN จะเริ่มต้นโดยการสกัดคุณลักษณะของภาพและทำการกำหนดพื้นที่ที่สนใจด้วยอัลกอริทึมต่างๆ จากนั้นทำการลดขนาดตัวแปรด้วยในชั้นของ Pooling Layer ด้วยตัวกรองเช่น Max Operation และทำการนำค่าที่ได้ไปทำการประมวลผลเพื่อจำแนกชนิดของวัตถุ




รูปที่ 2.18 แสดงโครงสร้างการทำงานของ Fast R-CNN [7]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.2.2 สถาปัตยกรรม SSD

SSD (Single Shot MultiBox Detector) เป็นสถาปัตยกรรมที่มีโครงสร้างพื้นฐานมาจาก feed-forward convolutional neural network โดยจะทำการสร้างกล่องที่มีขนาดคงที่ภายในภาพ และทำการจำแนกชนิดของวัตถุภายในกล่องนั้นๆ โดยทำการเพิ่มในส่วน of ชั้น Convolution ในแต่ละชั้นที่ถูกลดขนาดลงเพื่อให้มีการจำแนกชนิดของวัตถุภายในกล่องที่ขนาดแตกต่างกันดังรูปที่ 2.19

ในส่วนของการฝึกสอนของ SSD จะมีข้อแตกต่าง Faster R-CNN คือไม่มีการฝึกสอนในส่วนของการกำหนดกรอบของวัตถุ จึงเป็นเหตุผลที่ทำให้การตรวจจับวัตถุของ SSD ทำได้รวดเร็วกว่า Faster R-CNN ในส่วนของการสร้างกล่องล้อมรอบวัตถุจะมีการปรับขนาดไปตามแต่ละตำแหน่งด้วยอัตราส่วนภาพ และทำการทำนายชนิดของวัตถุภายในกล่องที่สร้างขึ้นโดยใช้เกณฑ์คล้ายคลึงกับ Faster R-CNN คือให้มีส่วนซ้อนทับของพื้นที่ Ground truth และส่วนที่ทำนายเป็นอัตราส่วนกันมากกว่า 0.5 แตกต่างกันในส่วนของ SSD มีการทำนายในทุกผลลัพธ์ของชั้น Convolution และทำการเลือกผลลัพธ์ที่ดีที่สุดมาใช้เพียงผลลัพธ์เดียวและสามารถคำนวณค่าความสูญเสีย (Loss function) ได้ตามสมการที่ 2.3



รูปที่ 2.19 แสดงโครงสร้างสถาปัตยกรรม SSD [34]

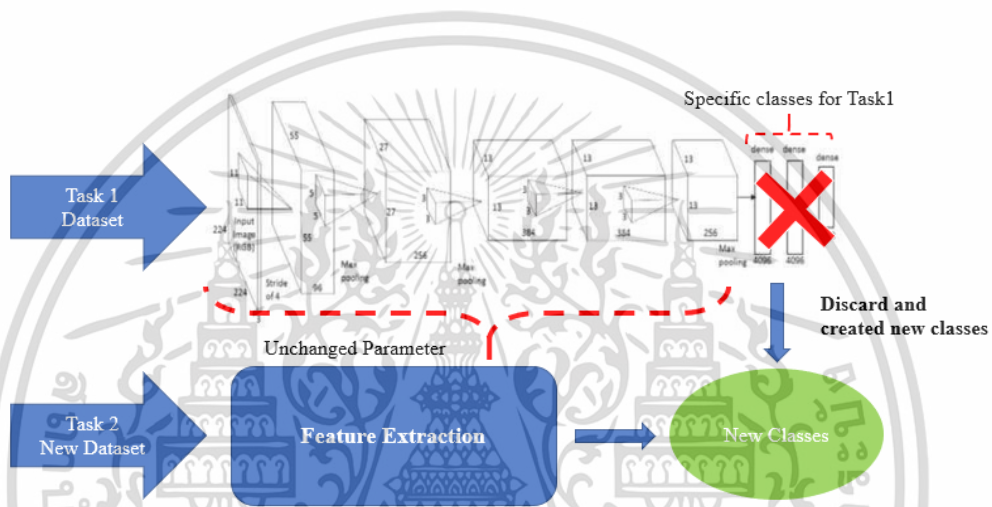
$$L_{loc}(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, l, g)) \quad (2.3)$$

โดย N คือ จำนวนของกล่องที่ทำนายถูก L_{loc} คือ ค่าความสูญเสียที่เกิดจากการระบุตำแหน่งของการทำนายและ Ground truth l คือตำแหน่งของการทำนาย g คือ ตำแหน่งของ Ground truth L_{conf} คือ ค่าความสูญเสียที่เกิดจากความผิดพลาดในการทำนายชนิดวัตถุ c คือ ความน่าจะเป็นของแต่ละชนิดวัตถุ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.3 Transfer Learning

โดยทั่วไปการเรียนรู้ของเครื่องสำหรับการจำแนกชนิดของวัตถุหรืองานประเภทการประมวลผลภาพ จะมีการสกัดคุณลักษณะของภาพที่คล้ายคลึงกันเช่น ขอบหรือสี เป็นต้น ดังนั้นจึงมีแนวคิดที่ว่าหากในชั้นของ Convolution Layer มีการใช้คุณลักษณะที่คล้ายคลึงกันในการจำแนกชนิดของวัตถุจึงมีการใช้องค์ความรู้ที่ถูกฝึกสอนมาแล้วมาใช้ในการแก้ปัญหาเพื่อลดระยะเวลาในการสร้างโมเดล โดยเทคนิค Transfer Learning มีด้วยกันหลากหลายวิธีเช่น การใช้โมเดลที่มีการฝึกฝนมาแล้วในการแก้ปัญหาที่มีลักษณะคล้ายคลึงกัน การฝึกฝนโมเดลด้วยข้อมูลใหม่โดยใช้การสกัดคุณลักษณะที่ได้รับการฝึกฝนมาแล้ว การสร้างส่วนสกัดคุณลักษณะเพิ่มเพื่อให้เหมาะสมกับงาน [24]

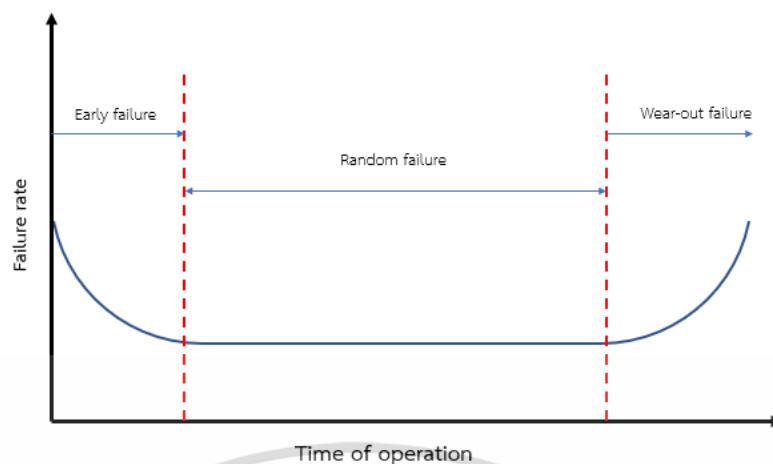


รูปที่ 2.20 แสดงการใช้เทคนิค Transfer Learning ด้วยการใช้ Pre-trained Model

2.6 การบำรุงรักษา

การบำรุงรักษา (Maintenance) คือการบำรุงรักษาอุปกรณ์เพื่อไม่ให้เกิดความเสียหายต่อตัวอุปกรณ์หรือการค้นหสาเหตุของการเกิดความเสียหายของอุปกรณ์ เพื่อรักษาเสถียรภาพของระบบเพื่อให้ระบบทำงานได้อย่างมีประสิทธิภาพ และเพื่อขยับยั้งไม่ให้เกิดการลุกลามของปัญหา นอกจากนี้ยังช่วยลดความเสียหายที่อาจเกิดต่อตัวผู้ปฏิบัติการเมื่ออุปกรณ์เกิดความเสียหาย [25] โดยทั่วไปเครื่องจักรหรืออุปกรณ์จะมีวงจรชีวิตในช่วงเวลาต่างๆ โดยเริ่มตั้งแต่การเริ่มต้นติดตั้งอุปกรณ์ การเสื่อมสภาพ การชำรุดและการหมดสภาพการใช้งาน ซึ่งจะอธิบายเป็นกราฟเส้นโค้งรูปร่างน้ำ (Bathtub curve) ดังรูปที่ 2.21


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.21 แสดงกราฟเส้นโค้งรูปร่างอ่างน้ำของวงจรชีวิตเครื่องจักร (Bathtub Curve)

จากกราฟจะเห็นได้ว่าระยะเวลาถูกแบ่งออกเป็น 3 ช่วง คือ ช่วงเริ่มต้นการใช้งาน ช่วงใช้งานปกติ และช่วงระยะการสึกหรอ ในช่วงเริ่มต้นการใช้งานนั้นอาจเกิดความเสียหายได้จากหลายสาเหตุ เช่น การใช้อุปกรณ์ที่ไม่เหมาะสมกับเครื่องจักร การออกแบบที่ไม่ถูกต้องและการติดตั้งเครื่องจักรที่ไม่ถูกต้อง ในช่วงของการใช้งานปกติเมื่อผ่านช่วงเริ่มต้นการใช้งานของเครื่องจักรมาแล้วจะมีการปรับปรุงและดูแลอุปกรณ์ในเบื้องต้นทำให้ในช่วงของการทำงานปกติมีอัตราการเสียหายที่ต่ำลง แต่ความเสียหายก็ยังมีโอกาสเกิดขึ้นจากปัจจัยภายนอกหลายอย่าง เช่น การใช้งานที่ไม่เหมาะสมกับการออกแบบของอุปกรณ์ สภาพแวดล้อมไม่เอื้ออำนวยต่อการปฏิบัติงาน และในช่วงสุดท้ายของกราฟเป็นช่วงที่อุปกรณ์มีความชำรุดเนื่องจากการใช้งานเป็นระยะเวลานาน โดยทั้ง 3 ช่วงที่กล่าวมานี้จะเห็นได้ว่ามีโอกาที่จะเกิดความเสียหายขึ้นต่อตัวอุปกรณ์ทั้งสิ้นดังนั้นการซ่อมบำรุงรักษาจึงมีความจำเป็นเพื่อให้การทำงานของระบบมีเสถียรภาพมากขึ้น โดยการซ่อมบำรุงรักษาแบ่งออกเป็น 4 ตามการแนวทางและวิธีการ คือ การบำรุงรักษาเชิงรับ (Reactive maintenance) การบำรุงรักษาเชิงป้องกัน (Preventive maintenance) การบำรุงรักษาเชิงรุก (Proactive maintenance) และการบำรุงรักษาตามสภาพ (Condition based maintenance)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.22 แสดงแผนผังประเภทของการซ่อมบำรุง

ที่มา <https://www.wbdg.org/resources/reliability-centered-maintenance-rcm>

2.6.1 การบำรุงรักษาเชิงรับ

การบำรุงรักษาเชิงรับ (Reactive maintenance) คือการบำรุงรักษาหลังจากเกิดความเสียหายที่ตัวอุปกรณ์หรือเครื่องจักรแล้วโดยไม่สามารถวางแผนในการซ่อมบำรุงหรือเปลี่ยนอุปกรณ์ได้ล่วงหน้าและอาจส่งผลเสียต่อการทำงานของระบบ โดยการบำรุงรักษาเชิงรับเป็นการซ่อมบำรุงรักษาที่ง่ายที่สุดและมีข้อจำกัดในการบำรุงรักษาคือการซ่อมบำรุงรักษากับอุปกรณ์ที่ไม่ส่งผลกระทบต่อภาพรวมของระบบและมีข้อดีคือทำให้ใช้งานอุปกรณ์ได้อย่างคุ้มค่า

2.6.2 การบำรุงรักษาเชิงป้องกัน

การบำรุงรักษาเชิงป้องกัน (Preventive Maintenance) คือ การบำรุงรักษาอุปกรณ์ในขณะที่อุปกรณ์ยังไม่เกิดความเสียหาย โดยทั่วไปการซ่อมบำรุงรักษาเชิงป้องกันทางตรงมักถูกควบคุมโดยใช้กรอบเวลา ระยะเวลาการทำงานของอุปกรณ์ การเปลี่ยนชิ้นส่วนของอุปกรณ์เมื่อใช้งานเป็นเวลา 100 ชั่วโมง การเปลี่ยนน้ำมันหล่อลื่นตามระยะเวลาของเครื่องจักรและการซ่อมใหญ่ เพื่อไม่ให้เกิดการหยุดการทำงานของอุปกรณ์แบบฉุกเฉินและช่วยในการยืดระยะเวลาการใช้งานของอุปกรณ์ โดยมีข้อเสียอุปกรณ์ที่ทำการซ่อมบำรุงอาจยังไม่เกิดความเสียหายทำให้เกิดความสิ้นเปลืองของทรัพยากร

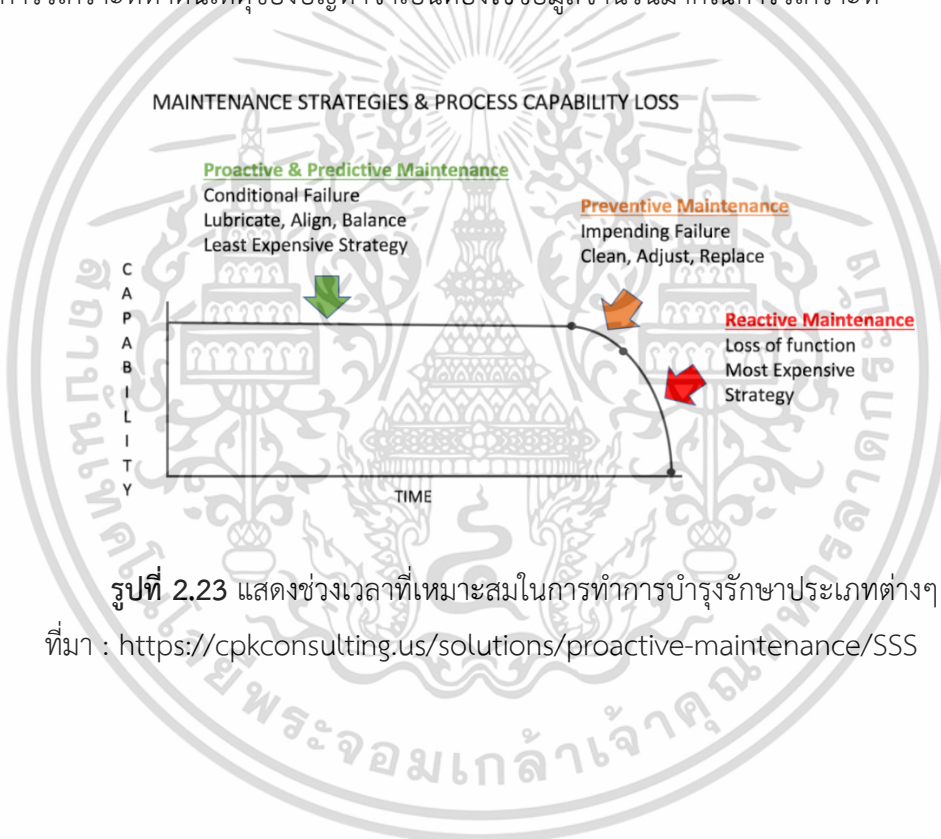
2.6.3 การบำรุงรักษาตามสภาพ

การซ่อมบำรุงรักษาตามสภาพ (Condition Based Maintenance) คือ การซ่อมบำรุงตามสภาพของอุปกรณ์ การซ่อมบำรุงนั้นจะขึ้นอยู่กับสภาพของอุปกรณ์หรือชิ้นส่วนโดยส่วนมากเมื่ออุปกรณ์ที่เกิดความผิดปกติขึ้นหรือมีแนวโน้มที่จะเกิดความผิดปกติจะเกิดความเปลี่ยนแปลงเช่น เกิดการสั่นสะเทือน เกิดความร้อนที่ตัวอุปกรณ์และค่าสัญญาณทางไฟฟ้าผิดปกติ โดยจะสังเกตสภาพของเอกสารนี้เป็นเอกสารที่สวอนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อุปกรณ์ด้วยการใช้อุปกรณ์สำหรับการตรวจสอบ เช่น การใช้ประสาทสัมผัส การใช้เครื่องมือในการวัด หรือการใช้กล้องถ่ายภาพความร้อน โดยใช้ช่วงเวลาที่เหมาะสมแก่การซ่อมบำรุงรักษาตามสภาพคือ ช่วงเวลาที่เครื่องจักรมีสถานะการทำงานต่ำลงหรือประสิทธิภาพของเครื่องจักรต่ำลง

2.6.4 การบำรุงรักษาเชิงรุก

การบำรุงรักษาเชิงรุก (Proactive Maintenance) คือ การบำรุงรักษาที่จะมุ่งเน้นแนวทางการบำรุงรักษาเชิงป้องกันและการบำรุงรักษาตามสภาพเพื่อป้องกันไม่ให้เกิดความเสียหายที่ตัวอุปกรณ์รวมถึงการวิเคราะห์เพื่อหาต้นเหตุของความเสียหายที่เกิดขึ้น เพื่อดำเนินการแก้ไขปัญหาและป้องกันไม่ให้เกิดปัญหาเกิดขึ้นอีกในอนาคต โดยการบำรุงรักษาเชิงรุกมีข้อดีคือทำให้สามารถทราบปัญหาที่แท้จริงของการเกิดความเสียหายและหาแนวทางในการป้องกันไม่ให้เกิดขึ้น แต่ยังมีข้อเสียคือในการวิเคราะห์หาต้นเหตุของปัญหาจำเป็นต้องใช้ข้อมูลจำนวนมากในการวิเคราะห์



รูปที่ 2.23 แสดงช่วงเวลาที่เหมาะสมในการทำการบำรุงรักษาประเภทต่างๆ

ที่มา : <https://cpkconsulting.us/solutions/proactive-maintenance/SSS>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3


วิธีการดำเนินงาน

ในส่วนนี้จะกล่าวถึงการออกแบบวิธีการทดลองทั้ง 3 ส่วนประกอบด้วยส่วนของการระบุชนิด และตำแหน่งของอุปกรณ์ไฟฟ้าบนตู้ควบคุมมอเตอร์ และการทดลองเพื่อหาตำแหน่งของความผิดปกติที่เกิดขึ้นบนอุปกรณ์ไฟฟ้า รวมไปถึงการนำผลการทดลองทั้งสองมาวิเคราะห์ร่วมกันโดยเริ่มจากการนำเสนออุปกรณ์ไฟฟ้าและอุปกรณ์ที่ใช้ในการทดลอง การเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้ในการตรวจจบบัต์ การออกแบบโปรแกรมทั้งในส่วนของการตรวจจบบัต์และการวิเคราะห์ความผิดปกติด้วยภาพถ่ายความร้อน และวิธีการทดลองตามลำดับ

3.1 ชุดอุปกรณ์ที่ใช้ในการออกแบบการทดลอง

3.1.1 อุปกรณ์ภายในตู้ควบคุมระบบไฟฟ้าสำหรับการควบคุมมอเตอร์

อุปกรณ์ที่ใช้ภายในตู้ควบคุมมอเตอร์ประกอบด้วยอุปกรณ์ 4 ชนิด จำนวน 5 ชิ้น ประกอบด้วยเซอร์กิตเบรกเกอร์ชนิด 3 เฟส จำนวน 1 ชิ้น เซอร์กิตเบรกเกอร์ชนิด 1 เฟส จำนวน 1 ชิ้น สวิตช์แบบแม่เหล็ก จำนวน 2 ชิ้น และโอเวอร์โวลต์รีเลย์ จำนวน 1 ชิ้น ดังรูปที่ 3.1



รูปที่ 3.1 แสดงอุปกรณ์ภายในตู้ควบคุมระบบไฟฟ้า (ก) เซอร์กิตเบรกเกอร์ชนิด 1 เฟส (ข) สวิตช์แบบแม่เหล็ก (ค) โอเวอร์โวลต์รีเลย์ (ง) เซอร์กิตเบรกเกอร์ชนิด 3 เฟส

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.2 อุปกรณ์สำหรับชุดการทดลอง

คอมพิวเตอร์ที่ใช้ในการประมวลผล ASUS K-450JN CPU intel core i7 2.4 GHz RAM 8.0 GB GPU Nvidia Geforce GT 840M 2 GB (รูปที่ 3.2) ใช้สำหรับการประมวลผลทั้งในการระบุชนิดและตำแหน่งของวัตถุและใช้ในการประมวลผลภาพถ่ายความร้อนด้วยโปรแกรม FlukeConnect รวมถึงการพัฒนาโปรแกรมที่ใช้ในการตรวจจับความผิดปกติบนอุปกรณ์ไฟฟ้าด้วย LabVIEW 2018



รูปที่ 3.2 คอมพิวเตอร์ที่ใช้ในการประมวลผล



รูปที่ 3.3 กล้องถ่ายภาพความร้อนชนิดพกพา รุ่น FLUKE Ti-400

กล้องถ่ายภาพความร้อนชนิดพกพา (FLUKE-Ti400) (รูปที่ 3.3) เป็นอุปกรณ์ที่ใช้ ในการวิเคราะห์อุณหภูมิ ซึ่งสามารถแสดงผลได้ทั้งในรูปแบบภาพถ่ายความร้อนและแสดงผลเป็นค่าอุณหภูมิ ในแต่ละตำแหน่งบนภาพนอกจากนี้ยังสามารถเก็บภาพถ่ายปกติได้ภายในการถ่ายภาพครั้งเดียว ทำให้ไม่เกิดความคลาดเคลื่อนตำแหน่งทั้งภาพถ่ายความร้อนและภาพถ่ายปกติ และยังสามารถควบคุมการ เก็บภาพด้วยการสั่งการผ่านแอปพลิเคชันทางโทรศัพท์เพื่อลดอุณหภูมิที่สะท้อนจากตัวผู้ใช้ โดยกล้อง มีคุณสมบัติทางเทคนิคดังตารางที่ 3.1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 3.1 แสดงคุณสมบัติทางเทคนิคของกล้องถ่ายภาพความร้อน [27]

	รายละเอียด
ช่วงอุณหภูมิที่วัดได้	-20 °C ถึง 1200 °C
ความแม่นยำ	± 2 °C หรือ ± 2% ของค่าที่อ่านได้
ความละเอียด	320 × 240 pixel (76,800 pixel)
ช่วงของสเปกตรัม	7.5 – 14 μm
เลนส์อินฟราเรด	
ขอบเขตการมองเห็น	24 °× 17 °
ความละเอียดของพื้นที่	1.31 mRad
ระยะโฟกัสต่ำสุด	15 cm
เลนส์เสริมภาพถ่ายปกติ	
ขอบเขตการมองเห็น	12 °× 9 °
ความละเอียดของพื้นที่	0.65 mRad
ระยะโฟกัสต่ำสุด	45 cm
ระยะซ้อนทับของภาพทั้งสองชนิด	มากกว่า 60 cm

3.1.3 การออกแบบการทดลอง

สำหรับการออกแบบการทดลอง เริ่มต้นโดยการเก็บภาพถ่ายของอุปกรณ์ภายในตู้ควบคุมมอเตอร์ เพื่อใช้ในการสร้างโมเดลในการระบุชนิดและตำแหน่งของวัตถุ และในส่วนของ การตรวจจับความผิดปกติของอุปกรณ์นั้น จะทำการทดลองในห้องทดลองที่ควบคุมอุณหภูมิ 25 องศาเซลเซียส เพื่อลดผลกระทบจากการสะท้อนอุณหภูมิจากวัตถุหรือสภาพแวดล้อม โดยทำการตั้งกล้องถ่ายภาพความร้อนด้วยขาตั้งกล้องแบบ tri-pod ให้ระยะห่างจากกล้องถ่ายภาพความร้อนกับตู้ควบคุมระบบไฟฟ้ามีระยะห่างกัน 120 เซนติเมตรเพื่อให้เห็นองค์ประกอบของอุปกรณ์ครบทั้ง 5 ชิ้น โดยทำการคลายจุดเชื่อมต่อบางจุดบนตัวอุปกรณ์ไฟฟ้าเพื่อศึกษาผลของการเปลี่ยนแปลงอุณหภูมิที่เกิดขึ้นบนตัวอุปกรณ์ จากนั้นทำการเก็บภาพถ่ายด้วยกล้องถ่ายภาพความร้อนโดยทำการควบคุมการเก็บภาพผ่านแอปพลิเคชันบนโทรศัพท์มือถือ จากนั้นนำภาพที่ได้มาทำการประมวลผลผ่านโปรแกรมที่พัฒนาด้วย LabVIEW 2018

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




3.2 การออกแบบโปรแกรมเบื้องต้น

ในการทดลองจะแบ่งออกเป็น 3 ส่วนประกอบด้วย การระบุชนิดและตำแหน่งของอุปกรณ์ การวิเคราะห์ความผิดปกติด้วยภาพถ่ายความร้อนและการวิเคราะห์สถานะของอุปกรณ์ไฟฟ้า

3.2.1 การสร้างโมเดลในการระบุชนิดและตำแหน่งของอุปกรณ์

ในส่วนของการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้าเป็นการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับการใช้เทคนิค Transfer Learning ซึ่งในการทดลองนี้จะทำการสร้างโมเดลเพื่อตรวจจับและระบุตำแหน่งของอุปกรณ์ภายในตู้ควบคุมมอเตอร์ โดยทำการสร้างโมเดลด้วยโปรแกรม Anaconda3 ซึ่งเป็นโปรแกรมที่ใช้ในการแก้ไขและรวบรวมไลบรารีของภาษา Python โดยทั่วไปการสร้างโมเดลในการตรวจจับวัตถุ นั้นักพัฒนามากมายได้ทำการเปิดเป็นโค้ดอิสระให้นักพัฒนา เพื่อนำไปใช้งานต่อและเพื่อลดระยะเวลาในการสร้างโมเดล ในการทดลองนี้ได้ทำการเลือกใช้โมเดลที่ถูกพัฒนามาแล้วมาประยุกต์ใช้คือโมเดลของ Faster R-CNN สำหรับการตรวจจับวัตถุที่และเลือกการใช้การสกัดข้อมูลของภาพด้วย Inception V-3 เนื่องจากโมเดลมีประสิทธิภาพสูงเมื่อเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เปรียบเทียบกับโมเดลอื่นเช่น SSD (Single Shot MultiBox Detector) หรือ YOLO (You Only Look Once) คือสามารถตรวจจับวัตถุได้เร็วและมีความแม่นยำสูงโดยใช้ทรัพยากรของหน่วยประมวลผลไม่สูงมาก [32] และทำการวัดผลความถูกต้องเป็นค่าความแม่นยำค่าเฉลี่ยความแม่นยำ (mean Average Precision) mAP และทำการกำหนดความถูกต้องของพื้นที่ที่ทำนายต้องเป็นสัดส่วนต่อพื้นที่ที่ถูกต้อง (Intersection Over Union) IOU ดังรูปที่ 3.5 โดยกำหนด IOU threshold ไว้ที่ 0.5 เพิ่มขึ้น 0.05 จนถึง 0.95 จากนั้นทำการหาค่าเฉลี่ยความแม่นยำ mAP [28] เพื่อเปรียบเทียบประสิทธิภาพ นอกจากความแม่นยำแล้วประสิทธิภาพยังรวมถึงความเหมาะสมกับงานเช่นความเร็วในการตรวจจับและระยะเวลาในการฝึกฝนโมเดล



รูปที่ 3.5 แสดงอัตราส่วนของพื้นที่ซ้อนทับต่อพื้นที่ทั้งหมด (Intersection Over Union)

การสร้างโมเดลโดยใช้เทคนิค Transfer Learning จะทำการปรับเปลี่ยนค่าตัวแปรให้เหมาะสมกับชนิดของวัตถุที่ใช้ในการตรวจจับอุปกรณ์ โดยตัวแปรที่ส่งผลต่อความแม่นยำและความรวดเร็วในการสร้างของโมเดลคือ จำนวนรอบในการเรียนรู้ (num step) อัตราการเรียนรู้ (Learning rate) การปรับในส่วนย่อยต่างๆของโมเดล เช่น ขนาดของตัวกรอง (Sliding window) การเลื่อนของตัวกรอง (Stride) จำนวนต่อชุดข้อมูล (Batch size) จากงานวิจัยที่ทำการทดสอบประสิทธิภาพของสถาปัตยกรรมเพื่อตรวจจับวัตถุ[34] เมื่อทำการเปรียบเทียบในแต่ละสถาปัตยกรรมจะเห็นได้ว่าสถาปัตยกรรม Faster R-CNN มีความแม่นยำใกล้เคียงกับสถาปัตยกรรม SSD ซึ่งเป็นการทดสอบกับชุดข้อมูลที่ใช้ในการแข่งขันการตรวจจับวัตถุ (Pascal VOC) ซึ่งเป็นการตรวจจับชนิดและตำแหน่งของวัตถุจำนวน 20 ชนิด

Method	mAP	FPS	batch size	# Boxes	Input resolution
Faster R-CNN (VGG16)	73.2	7	1	~ 6000	~ 1000 × 600
Fast YOLO	52.7	155	1	98	448 × 448
YOLO (VGG16)	66.4	21	1	98	448 × 448
SSD300	74.3	46	1	8732	300 × 300
SSD512	76.8	19	1	24564	512 × 512
SSD300	74.3	59	8	8732	300 × 300
SSD512	76.8	22	8	24564	512 × 512


รูปที่ 3.6 แสดงตรวจจับวัตถุของสถาปัตยกรรมใน 3 รูปแบบ Faster-RCNN SSD และ YOLO [34]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ในงานวิชาการเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์อื่นใดโดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางอ้างอิงผลงานวิจัยจะเห็นได้ว่าค่าเฉลี่ยความแม่นยำของสถาปัตยกรรม Faster R-CNN และสถาปัตยกรรม SSD มีค่าความแม่นยำใกล้เคียงกันหากเปรียบเทียบกันในเชิงความเร็วในการตรวจจับ SSD มีความเร็วที่สูงกว่าและมีเมื่อเปรียบเทียบเชิงปริมาณข้อมูลในการประมวลผลจะเห็นได้ว่า Faster R-CNN มีปริมาณตัวแปรที่น้อยกว่า ดังนั้นในการทดลองจึงได้ทำการนำโมเดลที่ใช้สำหรับการตรวจจับวัตถุทั้งสองชนิดมาทำการทดสอบและทำการปรับค่าตัวแปรเพื่อเปรียบเทียบประสิทธิภาพ

3.2.1.1 การเตรียมข้อมูลเพื่อฝึกสอน

เนื่องจากโครงข่ายประสาทเทียมแบบคอนโวลูชันเป็นการเรียนรู้ของเครื่องแบบมีผู้สอน ดังนั้นข้อมูลที่ถูกใช้เพื่อเตรียมการสร้างโมเดลจำเป็นต้องมีข้อมูลที่ต้องการเพื่อฝึกสอน โดยข้อมูลที่จะนำมาเป็นข้อมูลฝึกสอนนั้นจะถูกแบ่งออกเป็น 2 กลุ่ม คือ ข้อมูลที่ใช้เพื่อฝึกสอน และ ข้อมูลที่ใช้ในการตรวจสอบความถูกต้องของโมเดล สำหรับข้อมูลทั้งสองนี้จะเป็นภาพถ่ายโดย ทำการเก็บภาพของอุปกรณ์ไฟฟ้าบนตู้ควบคุมระบบไฟฟ้าด้วยกล้องบนโทรศัพท์เคลื่อนที่และทำการปรับขนาดภาพ เพื่อลดความสิ้นเปลืองในการใช้ทรัพยากรของหน่วยประมวลผล โดยอุปกรณ์ภายในตู้ควบคุมระบบไฟฟ้าประกอบด้วย เซอร์คิตเบรกเกอร์ชนิด 1 เฟส เซอร์คิตเบรกเกอร์ชนิด 3 เฟส สวิตช์แบบแม่เหล็ก และ โอเวอร์โวลติลตรีเลย์ ในรูปแบบต่าง จำนวน 120 ภาพ และแบ่งข้อมูลออกเป็นสองกลุ่มโดยแบ่งเป็นข้อมูลที่ใช้เพื่อฝึกสอนจำนวน 100 ภาพ และข้อมูลเพื่อใช้ในการตรวจสอบความถูกต้อง 20 ภาพ จากนั้นทำการกำหนดตำแหน่งที่ต้องการของภาพทั้งสองกลุ่มเพื่อใช้ในการทดสอบด้วยโปรแกรม Labellmg ดังรูปที่ 3.7 และทำการแปลงข้อมูลของตำแหน่งและชนิดของวัตถุให้อยู่ในรูปแบบตารางไฟล์ .csv ดังรูปที่ 3.8



รูปที่ 3.7 แสดงการระบุตำแหน่งและชนิดของวัตถุด้วยโปรแกรม Labellmg


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่หรือใช้ในการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการใช้โมเดลเพื่อทำการระบุตำแหน่งและชนิดของวัตถุ ยังต้องมีส่วนที่ใช้เพื่อแสดงผลของการตรวจจับโดยในส่วนของผลการแสดงผลนั้นใช้ภาษา Python เพื่อเรียกใช้โมเดลในการทดสอบ จากนั้นนำผลที่ได้จากการแสดงผลมาเป็นข้อมูลเพื่อใช้ในการตรวจจับความผิดปกติของอุปกรณ์ ด้วยโปรแกรมที่พัฒนาขึ้นจาก LabVIEW2018 โดยใช้เครื่องมือ PythonNode ซึ่งเป็นส่วนเชื่อมต่อระหว่างโปรแกรม LabVIEW และโปรแกรมของส่วนที่พัฒนาโดยภาษา Python จากนั้นทำการพัฒนาโปรแกรมส่วนที่รับภาพจาก PythonNode เพื่อให้โปรแกรมในส่วนของ LabVIEW สามารถรับรู้ถึงตำแหน่งและชนิดของวัตถุ โดยการกำหนดสีแทนการบอกชนิดของวัตถุโดยให้สีเขียวแทนเซอร์กิตเบรกเกอร์ชนิด 3 เฟส สีแดงแทนเซอร์กิตเบรกเกอร์ชนิด 1 เฟส สีน้ำเงินแทนสวิตช์แบบแม่เหล็กและสีฟ้าแทนโอเวอร์โวลติลตรีเลย์ ดังรูป 3.7 และใช้อัลกอริทึม DetectObject ในการใช้หาตำแหน่งของวัตถุ และทำการระบุตำแหน่งเป็นพิกัดจุด 4 พิกัด คือ X_{max} X_{min} Y_{max} Y_{min}

filename	width	height	class	xmin	ymin	xmax	ymax
640x480v2	480	640	3 Phase Circuit Breaker	239	61	340	192
640x480v2	480	640	Circuit Breaker	350	59	384	183
640x480v2	480	640	Magnetic Contactor	329	248	402	359
640x480v2	480	640	Magnetic Contactor	240	256	310	359
640x480v2	480	640	Overload Relay	242	361	312	434
640x480v2	480	640	3 Phase Circuit Breaker	256	78	326	176
640x480v2	480	640	Circuit Breaker	340	78	361	172
640x480v2	480	640	Magnetic Contactor	318	220	370	300
640x480v2	480	640	Magnetic Contactor	251	218	300	296
640x480v2	480	640	Overload Relay	252	297	301	356
640x480v2	480	640	Circuit Breaker	380	116	418	287
640x480v2	480	640	3 Phase Circuit Breaker	203	116	339	300
640x480v2	480	640	3 Phase Circuit Breaker	227	64	325	198
640x480v2	480	640	Circuit Breaker	339	63	372	187
640x480v2	480	640	Magnetic Contactor	316	257	382	368
640x480v2	480	640	Magnetic Contactor	222	258	288	365
640x480v2	480	640	Overload Relay	222	365	291	443
640x480v2	480	640	Overload Relay	318	327	385	401
640x480v2	480	640	Magnetic Contactor	316	228	385	326
640x480v2	480	640	Magnetic Contactor	205	228	273	332

รูปที่ 3.8 แสดงตัวอย่างของข้อมูลหลังถูกแปลงค่าเป็นตาราง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.9 แสดงผลลัพธ์ของการแสดงผลที่ได้จากการใช้โมเดลในการระบุชนิดและตำแหน่งของวัตถุ

3.2.2 การเตรียมภาพ

ในส่วนของการได้มาของภาพนั้นการเก็บด้วยกล้องถ่ายภาพความร้อนจะได้ภาพทั้ง 2 ชนิดคือ ภาพถ่ายความร้อนและภาพถ่ายปกติ ซึ่งในการใช้ภาพถ่ายความร้อนต้องมีการปรับค่าต่างๆ เพื่อให้เหมาะสมกับอุปกรณ์เป้าหมาย เช่น ค่าสัมประสิทธิ์การแผ่รังสีความร้อน ค่า Background temperature ช่วงกว้างของอุณหภูมิ (Level/span) ซึ่งค่าเหล่านี้มีผลต่อการอ่านค่าของอุณหภูมิที่ได้จากกล้องถ่ายภาพความร้อน เพื่อให้การวัดค่าของอุณหภูมิที่ถูกต้องในการทดลองทำการตั้งค่าสัมประสิทธิ์การแผ่รังสีความร้อนไว้ที่ 0.95 ตามค่าสัมประสิทธิ์การแผ่รังสีความร้อนของพลาสติกสีทึบ [29] และทำการตั้งค่าช่วงกว้างของอุณหภูมิให้อุณหภูมิสูงสุดที่อยู่ 120 องศาเซลเซียสและอุณหภูมิต่ำสุดที่ 20 องศาเซลเซียส และกำหนด ambient temperature ที่ 25 องศาเซลเซียส จากนั้นตั้งระยะห่างของกล้องถ่ายภาพความร้อนให้ห่างจากวัตถุเป้าหมาย 120 เซนติเมตรและทำการปรับค่าโพกัสเพื่อให้ภาพถ่ายความร้อนและภาพปกติอยู่ในตำแหน่งที่ซ้อนทับกันดังรูปที่ 3.8



รูปที่ 3.10 แสดงตัวอย่างการผลลัพธ์ที่ได้จากการปรับโพกัสของกล้องถ่ายภาพความร้อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


3.2.3 การประมวลผลภาพถ่ายความร้อน

การประมวลผลภาพถ่ายความร้อนเพื่อใช้ในการวิเคราะห์สถานะของอุปกรณ์ไฟฟ้าโดยใช้คุณสมบัติของการแผ่รังสีความร้อนที่แผ่ออกมาจากแหล่งกำเนิด โดยความร้อนที่เกิดขึ้นเกิดจากความผิดปกติของตัวอุปกรณ์ [30] ในการทดลองจะทำให้อุปกรณ์เกิดความร้อนที่จุดเชื่อมต่อจากการเชื่อมต่อที่หลวมหรือไม่แน่นสนิทระหว่างสายไฟกับจุดเชื่อมต่อของอุปกรณ์ และใช้มาตรฐานของการจำแนกสถานะของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อนของ NETA ดังตารางที่ 3.2 [31] เพื่อระบุสถานะ โดยข้อควรปฏิบัติจะถูกแบ่งเป็นทำการสังเกตการต่อเนื่องและทำการซ่อมบำรุงอย่างเร่งด่วน ดังนั้นสถานะของอุปกรณ์ไฟฟ้าในการทดลองนี้จะถูกแบ่งเป็น 2 สถานะคือ สถานะปกติและสถานะผิดปกติ ในการเขียนโปรแกรมในส่วนของการประมวลผลภาพถ่ายความร้อนเริ่มจากการนำภาพถ่ายความร้อนซึ่งเป็นภาพระดับสีเทาชนิด 8 บิต และทำการกำหนดค่าเทรสโฮล เพื่อหาตำแหน่งของจุดที่เกิดความร้อนหากอุณหภูมิสูงกว่าค่าที่กำหนดจะถูกแปลงเป็นภาพไบนารี โดยค่าของอุณหภูมิที่อ่านได้มีความสัมพันธ์กับค่าระดับสีเทาบนภาพดังสมการที่ 3.1 และเพื่อให้ภาพหลังผ่านการเทรสโฮลมาแล้วมีคุณภาพดีขึ้นจึงใช้อัลกอริทึม Vision Assistance ในการปรับปรุงคุณภาพด้วยการกรองสัญญาณรบกวนและเพิ่มส่วนที่ขาดหายของภาพจากนั้นใช้อัลกอริทึม Detect Object เพื่อหาตำแหน่งของจุดที่เกิดความร้อนโดยการทำงานเบื้องต้นของโปรแกรมเป็นไปตามรูปที่ 3.9

$$T_{(i,j)} = \frac{T_{(max)} - T_{(min)}}{255} \times g_{(i,j)} + T_{(min)} \quad (3.1)$$

เมื่อ	$T_{(i,j)}$	คือ	ค่าอุณหภูมิที่ตำแหน่ง i,j
	$T_{(max)}$	คือ	ค่าอุณหภูมิสูงสุดหลังทำการกำหนด level/span
	$T_{(min)}$	คือ	ค่าอุณหภูมิต่ำสุดหลังทำการกำหนด level/span
	$g_{(i,j)}$	คือ	ค่าระดับสีเทาที่ตำแหน่ง i,j

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.11 แสดงขั้นตอนการทำงานเบื้องต้นของโปรแกรมหาพิกัดของตำแหน่งที่เกิดความผิดปกติ

ตารางที่ 3.2 แสดงการจำแนกสถานะของอุปกรณ์ด้วยภาพถ่ายความร้อนตามมาตรฐาน NETA

(ΔT) with similar equipment ($^{\circ}\text{C}$)	(ΔT) with ambient temperature ($^{\circ}\text{C}$)	Recommended Action
1-3	1-10	Possible deficiency, warrants investigation (priority :4)
4-15	11-20	Indicate probable deficiency, repair as time permits (priority :3)
-	21-40	Monitor continuously until corrective measure can be accomplished (priority :2)
≥ 15	>40	Major discrepancy, repair intermediately (priority :1)

ซึ่งตำแหน่งของจุดที่เกิดความร้อนอาจจะเกิดขึ้นได้มากกว่าหนึ่งจุดในเวลาเดียวกัน ดังนั้นตำแหน่งของจุดที่เกิดความร้อนทั้งจะถูกนำไปใช้เพื่อประมวลผลต่อโดยทำงานร่วมกับกระบวนการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้าเพื่อวิเคราะห์ถึงชนิดของอุปกรณ์ที่เกิดความผิดปกติ

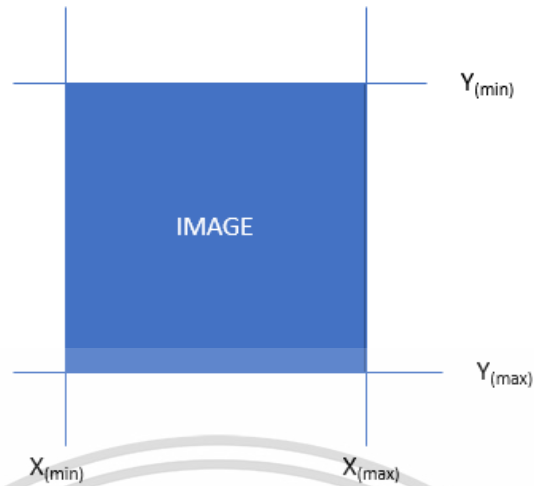
3.2.4 การประมวลผลเพื่อตรวจสอบสถานะของอุปกรณ์ไฟฟ้า

ในการพัฒนาส่วนของโปรแกรมทั้งสองให้ทำงานร่วมกัน โดยการพัฒนาจากโปรแกรมต่างชนิดกันโดยใช้โปรแกรม LabVIEW เป็นฐานและใช้ส่วนขยายของโปรแกรมใน LabVIEW เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

PythonNode เพื่อดึงผลลัพธ์ที่ประมวลผลผ่าน Anaconda3 มาใช้ประมวลผลต่อใน LabVIEW โดยเริ่มต้นโปรแกรมจะทำการรับภาพเพื่อใช้ในการประมวลผลจากนั้นข้อมูลจะถูกส่งไปประมวลผลในส่วนของ Anaconda3 และส่งภาพที่เป็นผลลัพธ์กลับมายังโปรแกรมที่พัฒนาด้วย LabVIEW และทำการประมวลผลในส่วนของการถ่ายภาพอินฟราเรดและภาพถ่ายปกติพร้อมกันโดยในส่วนของการถ่ายภาพอินฟราเรดจะใช้การ เทอร์สโวลเพื่อลดภาพให้เป็นภาพไบนารีให้ง่ายต่อการหาตำแหน่งของจุดที่เกิดความผิดปกติ จากนั้นใช้ DetectObject เพื่อหาตำแหน่งที่เกิดความผิดปกติและระบุตำแหน่งเป็นพิกัด $Xf1_{(max)}$ $Xf1_{(min)}$ $Yf1_{(max)}$ $Yf1_{(min)}$ $Xf2_{(max)}$ $Xf2_{(min)}$ $Yf2_{(max)}$ $Yf2_{(min)}$... $Xf5_{(max)}$ $Xf5_{(min)}$ $Yf5_{(max)}$ $Yf5_{(min)}$

โดยในส่วนของการกำหนดพื้นที่ที่สนใจด้วยภาพที่ได้จากการใช้โมเดลในการตรวจจับวัตถุจะมีส่วนของการกำหนดค่าเทอร์สโวลของสีเพื่อให้ทราบตำแหน่งของอุปกรณ์แต่ละชนิด ซึ่งการทดลองใช้การกำหนดค่าสีเพื่อบ่งบอกถึงชนิดของวัตถุต่างๆ โดยจะกำหนดให้สีเขียว แทน เซอร์กิตเบรกเกอร์ แบบ 3 เฟส สีแดงแทน เซอร์กิตเบรกเกอร์ สีน้ำเงินแทน สวิตช์แม่เหล็ก และสีฟ้าแทน โอเวอร์โวลตรีเลย์ เนื่องจากสีที่กล่าวมาข้างต้นเป็นสีที่มีการอิมิตัวในแต่ละระนาบสีของตัวเองทำให้การกำหนดค่าเทอร์สโวลของสีต่างๆ เป็นไปได้ง่ายขึ้น โดยจะทำการทดสอบเพื่อกำหนดค่าเทอร์สโวลที่ใช้ในการทดลอง โดยการสุ่มภาพที่ใช้ในการทดลองมา 10 ภาพ จากนั้นทำการกำหนดค่าเทอร์สโวลที่ใช้ในการทดลองในแต่ละภาพและใช้ค่าที่กำหนดขึ้นทำการทดสอบกับภาพที่เหลือ 9 ภาพ เพื่อเก็บผลการทดลองจากนั้นทำการเปลี่ยนภาพที่ใช้ในการกำหนดและทำการทดสอบซ้ำกับ 9 ภาพที่เหลือ ทำซ้ำจนครบทั้ง 10 ภาพในชุดข้อมูล จากนั้นวิเคราะห์ค่าเทอร์สโวลที่ให้ค่าความถูกต้องในการระบุตำแหน่งของวัตถุแต่ละชนิดได้ดีที่สุด โดยค่าที่ได้จากการทดลองในการระบุตำแหน่งของ เซอร์กิตเบรกเกอร์ แบบ 3 เฟสคือ R 40 G 255 B 50 เซอร์กิตเบรกเกอร์คือ R 255 G 10 B 10 สวิตช์แม่เหล็กคือ R 20 G 20 B 255 โอเวอร์โวลตรีเลย์คือ R 100 G 255 B 255 ในส่วนของภาพปกติที่ผ่านการระบุชนิดของวัตถุมาแล้วนั้นจะทำการใช้การเทอร์สโวลด้วยสีอีกครั้งเพื่อระบุตำแหน่งของวัตถุในแต่ละชนิดเป็นพิกัด $X1_{(max)}$ $X1_{(min)}$ $Y1_{(max)}$ $Y1_{(min)}$ $X2_{(max)}$ $X2_{(min)}$ $Y2_{(max)}$ $Y2_{(min)}$... $X5_{(max)}$ $X5_{(min)}$ $Y5_{(max)}$ $Y5_{(min)}$ จากนั้นนำค่าพิกัดที่ได้ในแต่ละจุดมาเปรียบเทียบเพื่อวิเคราะห์ถึงความสัมพันธ์ของตำแหน่งที่เกิดความผิดปกติกับตำแหน่งของวัตถุ เพื่อหาว่าตำแหน่งที่เกิดความผิดปกติเกิดขึ้นบนตัววัตถุใด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.12 แสดงการบอกพิกัดทั้ง 4 จุดของตำแหน่งวัตถุ

The screenshot shows a camera feed of an electrical panel with four colored bounding boxes (green, red, blue, cyan) around specific components. Below the feed is a table of probe data and a bounding box configuration panel.


Probe(s)	Value	Last Update
Alarm Edit with		
[1] Boundin	{X Left => 232, Y Top :	11/7/2019 15:00:53
[2] Boundin	{X Left => 334, Y Top :	11/7/2019 15:00:53
[3] Boundin	{X Left => 312, Y Top :	11/7/2019 15:00:53
[4] Boundin	{X Left => 226, Y Top :	11/7/2019 15:00:53
[5] Boundin	{X Left => 224, Y Top :	11/7/2019 15:00:53

Bounding Box configuration panel:

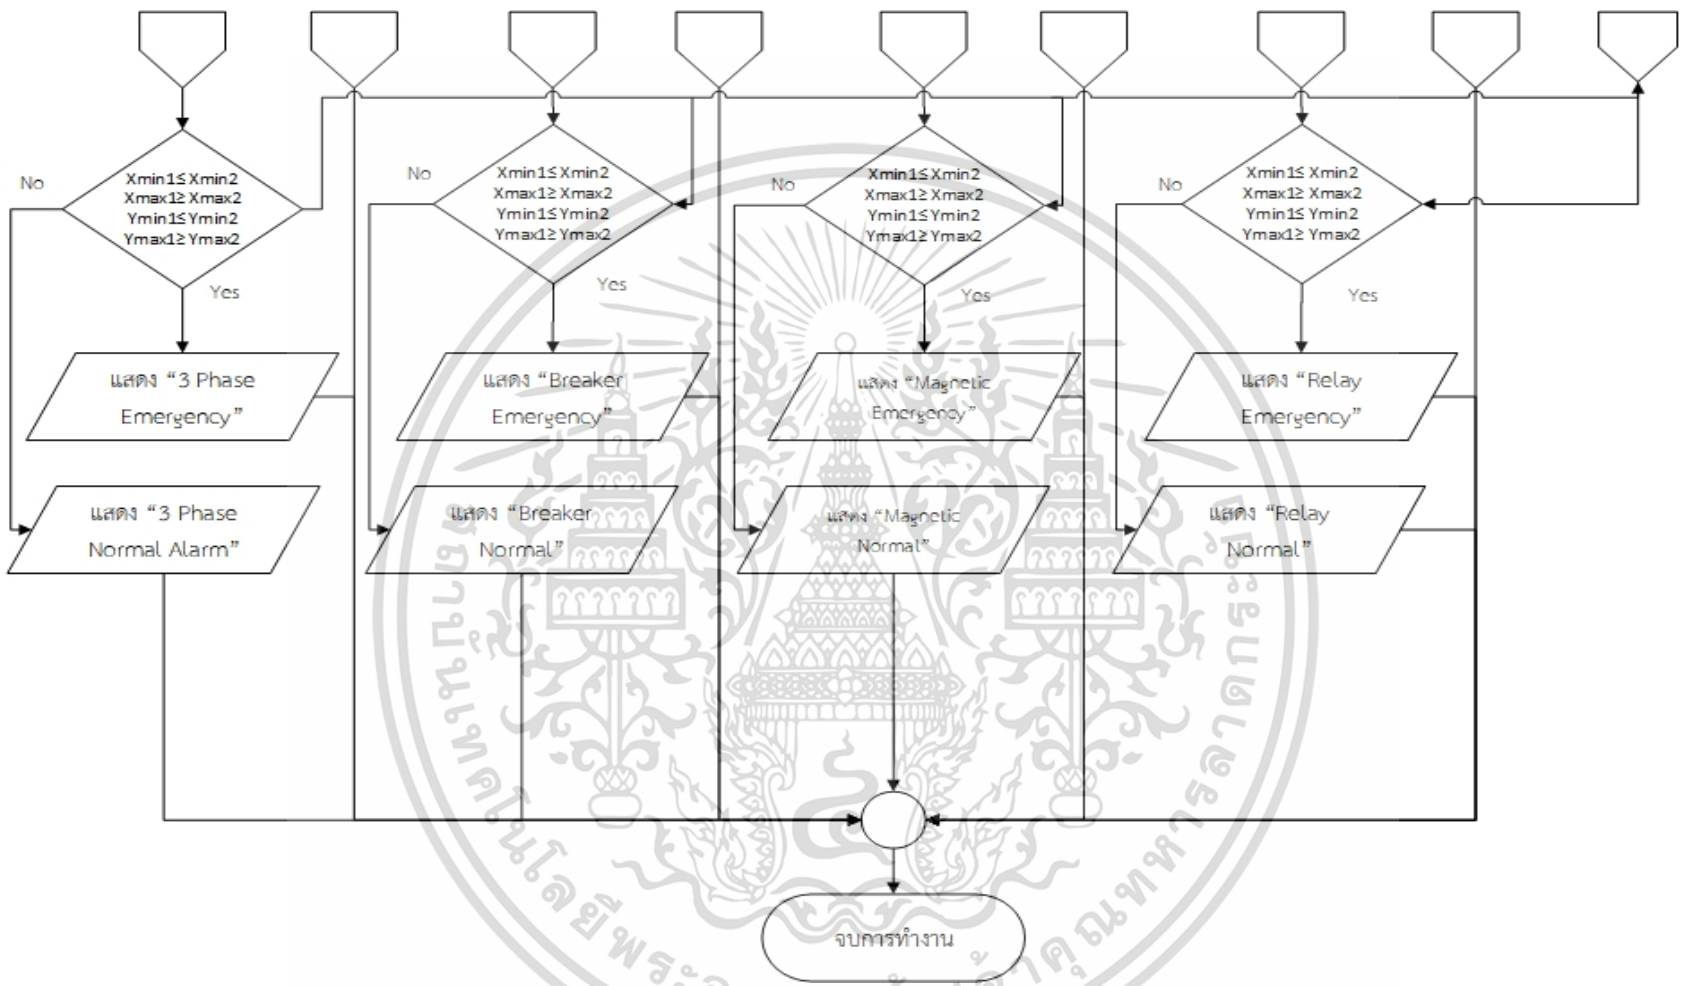
- X Left: 232
- Y Top: 70
- X Right: 324
- Y Bottom: 198

รูปที่ 3.13 แสดงผลการทดสอบการระบุตำแหน่งของอุปกรณ์ไฟฟ้าแต่ละชนิดด้วยการกำหนดค่าเทรสโไฮล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.14 แสดงอัลกอริธึมการตรวจสอบสถานะของอุปกรณ์ไฟฟ้า



รูปที่ 3.15 แสดงอัลกอริทึมการตรวจสอบสถานะของอุปกรณ์ไฟฟ้า(ต่อ)

3.3 ขั้นตอนการทดลอง

ในการทดลองจะทำการแบ่งส่วนของโปรแกรมออกเป็น 2 ส่วน เพื่อทดสอบประสิทธิภาพของโปรแกรมทั้งสอง จากนั้นจะทำการทดสอบโปรแกรมเมื่อนำทั้งสองส่วนมาทำงานร่วมกัน โดยในขั้นตอนแรกจะทำการทดสอบโมเดลที่ใช้ในการระบุชนิดของอุปกรณ์ไฟฟ้า ในส่วนของการทดสอบโมเดลที่ใช้ในการระบุชนิดของอุปกรณ์ไฟฟ้าจะเป็นการทดสอบประสิทธิภาพของสถาปัตยกรรม 2 ชนิดที่แตกต่างอ้างอิงจากประสิทธิภาพจากงานวิจัย [34] คือ สถาปัตยกรรม Faster R-CNN และ SSD และทำการกำหนดค่าตัวแปรเพื่อเปรียบเทียบในหลายปัจจัยของโมเดล ในที่นี้จะทำการปรับ Learning rate Num_step และ Batch size โดยจะเป็นการเปรียบเทียบกันทั้งความแม่นยำในการทำนายชนิดของอุปกรณ์ ความเร็วในการประมวลผลและความเร็วในการฝึกสอน จากนั้นจะทำการทดสอบการหาตำแหน่งที่เกิดความผิดปกติด้วยภาพถ่ายความร้อนโดยอ้างอิงจากมาตรฐานของ NETA สำหรับการตรวจสอบอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน ในการทดลองทำการกำหนดสถานะของอุปกรณ์ ไฟฟ้าออกเป็น 2 สถานะ คือ สถานะปกติและสถานะผิดปกติ โดยอุปกรณ์ที่เกิดความผิดปกติที่ตำแหน่งจุดร้อนจะมีอุณหภูมิสูงกว่าอุณหภูมิของสิ่งแวดล้อม 40 องศาเซลเซียส จากนั้นทำการวัดค่าความแม่นยำในส่วนของค่าอุณหภูมิของภาพถ่ายความร้อนซึ่งประกอบด้วย อุณหภูมิสูงสุดต่ำสุด และค่าเฉลี่ยของภาพและความแม่นยำในการระบุตำแหน่งของจุดร้อน จากนั้นนำทั้งสองมาประมวลผลร่วมกันผ่านโปรแกรม LabVIEW ซึ่งในส่วนของประมวลผลร่วมกันนั้นจะใช้ภาพผลลัพธ์ที่ได้จากการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้าเพื่อเป็นการกำหนดพื้นที่ที่สนใจ Region of interest (ROI) ให้กับส่วนของประมวลผลด้วยภาพถ่ายความร้อนและใช้การประมวลผลภาพถ่ายความร้อนเพื่อวิเคราะห์สถานะของอุปกรณ์ไฟฟ้า

3.3.1 การทดสอบโมเดลที่ใช้ในการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้า

การทดสอบประสิทธิภาพของโมเดลในการระบุชนิดของอุปกรณ์ไฟฟ้าด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน จะทำการเปรียบเทียบสถาปัตยกรรม Faster R-CNN และ SSD โดยสิ่งที่เปรียบเทียบประกอบด้วยความแม่นยำ ความเร็วในการทดสอบและความเร็วในการฝึกฝนด้วยข้อมูลที่ใช้ในการฝึกจำนวน 100 ภาพและภาพที่ใช้ในการทดสอบ 20 ภาพ โดยอ้างอิงประสิทธิภาพของโมเดลจากการแสดงผลของ MSCOCO โดยแสดงค่าความแม่นยำของโมเดลเป็นค่าเฉลี่ย mAP (mean Average Precision) โดยการกำหนดค่าของพื้นที่ซ้อนทับตั้งแต่ 0.5 เพิ่มขึ้นทีละ 0.05 ไปจนถึง 0.95 และกำหนดค่าจำนวนรอบการเรียนรู้ของโมเดลไว้ที่ 2 ค่าคือ 10000 และ 20000 รอบการเรียนรู้

3.3.2 การประมวลผลภาพถ่ายความร้อน

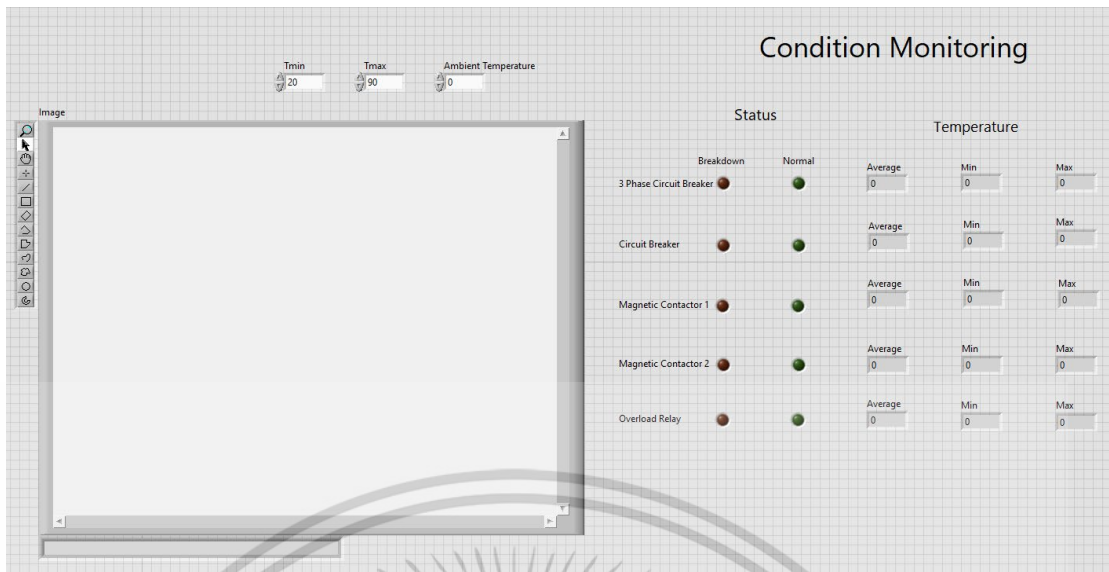
ในการทดลองการประมวลผลด้วยภาพถ่ายความร้อน เป็นการพัฒนาโปรแกรมเพื่อวิเคราะห์ค่าอุณหภูมิจากภาพถ่ายความร้อน โดยจะแบ่งการทดสอบออกเป็น 2 ส่วน ประกอบด้วยการวัดค่าเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่หรือนำไปใช้ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อุณหภูมิด้วยโปรแกรมที่พัฒนาขึ้นและการตรวจจับจุดที่เกิดความผิดปกติ โดยในส่วนของ การวัดค่า อุณหภูมิด้วยภาพถ่ายความร้อนจะเป็นการนำภาพถ่ายความร้อนมาทำการประมวลผลค่าอุณหภูมิโดย ทำการทดสอบด้วยภาพถ่ายความร้อนจำนวน 10 ภาพและทำการวัด 3 รูปแบบ คือการวัดอุณหภูมิ ของภาพถ่ายในทุกจุด การวัดอุณหภูมิภายในพื้นที่ที่กำหนด และการวัดอุณหภูมิที่ตำแหน่งหนึ่งบน ภาพถ่ายความร้อนและทำการเปรียบเทียบกับอุณหภูมิที่อ่านได้จากกล้องถ่ายภาพความร้อนโดย อุณหภูมิที่วัดจะใช้เป็นอุณหภูมิสูงสุด อุณหภูมิต่ำสุด และอุณหภูมิเฉลี่ย


ในส่วนที่สองของการประมวลผลภาพถ่ายความร้อนคือการตรวจจับตำแหน่งของจุดที่เกิด ความผิดปกติ จะทำการกำหนดค่าอุณหภูมิของวัตถุที่เกิดความผิดปกติและใช้ค่าอุณหภูมิสูงของจุดนั้น เป็นตัวชี้วัดสถานะของอุปกรณ์ ซึ่งอ้างอิงจากมาตรฐานการวิเคราะห์ภาพถ่ายความร้อนของ NETA โดยทำการทดสอบด้วยภาพถ่ายชุดเดียวกันกับส่วนก่อนหน้าคือภาพถ่ายความร้อนจำนวน 10 ภาพ และทำการเปรียบเทียบค่าอุณหภูมิสูงสุดของจุดที่เกิดความผิดปกติเปรียบเทียบกับค่าอุณหภูมิที่อ่าน ได้จากกล้องถ่ายภาพความร้อน

3.3.3 การตรวจสอบสถานะของอุปกรณ์ไฟฟ้า

ในส่วนนี้จะเป็นการทดสอบการประสิทธิภาพการทำงานของโปรแกรมเพื่อตรวจสอบสถานะ ของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน โดยในการทดลองจะทำการตั้งระยะห่างจากกล้องถ่ายภาพ ความร้อนและเป้าหมายเป็นระยะห่าง 120 เซนติเมตร จากนั้นทำการปรับค่าตัวแปรของกล้องเพื่อให้ ตรงตามโปรแกรมที่ออกแบบคือ ค่าสูงสุด ค่าต่ำสุดของอุณหภูมิและค่าสัมประสิทธิ์การแผ่รังสีความ ร้อน จากนั้นทำการเก็บภาพของอุปกรณ์ไฟฟ้าภายในตู้ควบคุม ซึ่งได้ทำการคลายจุดเชื่อมต่อให้เกิด การหลวมเพื่อให้เกิดการเปลี่ยนแปลงของอุณหภูมิและทำการแบ่งกลุ่มทดลองตามจำนวนของอุปกรณ์ ที่เกิดความผิดปกติจำนวน 60 ภาพ โดยแบ่งเป็น 6 กลุ่มคือ มี 0 1 2 3 4 และ 5 วัตถุที่เกิดความ ผิดปกติจากนั้นใช้โปรแกรมที่พัฒนาขึ้นด้วย LabVIEW เพื่อตรวจสอบสถานะของอุปกรณ์ไฟฟ้า โดย ในส่วนของการตรวจสอบสถานะของอุปกรณ์ไฟฟ้าจะเป็นการกำหนดพื้นที่ที่สนใจด้วยภาพที่ได้จาก การใช้โมเดลในการตรวจจับวัตถุและใช้การประมวลผลภาพถ่ายความร้อนเพื่อวิเคราะห์สถานะของ อุปกรณ์ไฟฟ้า



รูปที่ 3.16 แสดง Interface ของโปรแกรมตรวจสอบสถานะของอุปกรณ์



รูปที่ 3.17 แสดงตัวอย่างการแสดงผลของโปรแกรมตรวจสอบสถานะของอุปกรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการทดลองและการวิเคราะห์ผลการทดลอง

ในเนื้อหาของบทนี้จะกล่าวถึงผลการทดลองของการหาอุปกรณ์ที่เกิดความผิดปกติด้วยภาพถ่ายความร้อนและภาพปกติ โดยในการทดลองนี้จะออกออกเป็น 3 ส่วน ประกอบด้วย การทดสอบโมเดล การทดสอบหาตำแหน่งของจุดที่เกิดความผิดปกติด้วยภาพถ่ายความร้อนและการทดสอบหาอุปกรณ์ที่เกิดความผิดปกติ


4.1 การทดสอบโมเดลที่ใช้ในการระบุชนิดและตำแหน่งของอุปกรณ์ไฟฟ้า

ในการทดสอบโมเดลที่ใช้ในการตรวจจับที่ถูกสร้างขึ้นโดยการใช้เทคนิค Transfer Learning สำหรับใช้ในการระบุชนิดอุปกรณ์ไฟฟ้าทั้ง 4 ชนิดภายในตู้ควบคุมมอเตอร์ เมื่อทำการเก็บภาพอุปกรณ์ในสภาพแวดล้อมที่แตกต่างกันไปของอุปกรณ์ และนำมาทำการทดสอบด้วยโมเดลที่สร้างขึ้น โดยอ้างอิงประสิทธิภาพของโมเดล จากการแสดงผลความแม่นยำสำหรับการแข่งขันบนข้อมูลของ MSCOCO ซึ่งเป็นการแข่งขันที่ได้รับการยอมรับจากองค์กรต่างๆมากมายเช่น Microsoft Facebook และ Mighty AI โดยจะแสดงเป็นค่าเฉลี่ยความแม่นยำ (mean Average Precision) โดยแบ่งการทดสอบเป็นการทดสอบของสถาปัตยกรรมแบบ SSD และ Faster R-CNN ผลการทดสอบเป็นไปตามตารางที่ 4.1 และ 4.2


ตารางที่ 4.1 แสดงค่าเฉลี่ยความแม่นยำที่แต่ละจำนวนรอบการเรียนรู้

Architecture	4457	8739	12190	17335	20000
SSD	0.2892	0.2821	0.3946	0.4022	0.3449
Faster R-CNN	0.4756	0.6065	0.6089	0.6180	0.6043

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.1 แสดงกราฟผลของ mAP @ 0.5:0.05:0.95 ของสถาปัตยกรรม SSD




รูปที่ 4.2 แสดงกราฟผลของ mAP @ 0.5:0.05:0.95 ของสถาปัตยกรรม Faster-RCNN


ตารางที่ 4.2 แสดงประสิทธิภาพของโมเดลในการตรวจจับวัตถุที่จำนวนรอบการเรียนรู้ 20000

Architecture	mAP	Testing Time	Training Time
Faster R-CNN	0.6043	0.35 sec	5 hr 53 min
SSD	0.3449	0.14 sec	3 hr 39 min

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 แสดงผลการทดสอบโมเดลของสถาปัตยกรรม Faster-RCNN (ก) Ground truth
(ข) 1000 รอบการเรียนรู้ (ค) 20000 รอบการเรียนรู้



รูปที่ 4.4 แสดงผลการทดสอบโมเดลของสถาปัตยกรรม SSD (ก) Ground truth
(ข) 1000 รอบการเรียนรู้ (ค) 20000 รอบการเรียนรู้

จากการทดสอบประสิทธิภาพของโมเดลตรวจจับวัตถุทั้ง 2 สถาปัตยกรรมจะเห็นได้ว่าในส่วนของสถาปัตยกรรม Faster R-CNN มีความแม่นยำในการทำนายการตรวจจับวัตถุได้ดีกว่าสถาปัตยกรรม SSD โดย Faster R-CNN มีค่าเฉลี่ยความแม่นยำอยู่ที่ 60.43% และ SSD มีค่าเฉลี่ยความแม่นยำอยู่ที่ 34.49% และหากเปรียบเทียบกันในด้านความเร็วในการประมวลผลทั้งในส่วนของระยะเวลาในการทำนายผลและระยะเวลาในการฝึกสอนจะเห็นได้ว่าสถาปัตยกรรม SSD ทำได้ดีกว่าโดย SSD มีค่าระยะเวลาในการทำนายผลต่อภาพอยู่ที่ 0.14 วินาทีซึ่งเร็วกว่า Faster R-CNN ที่มีความเร็วในการทำนายผลต่อภาพอยู่ที่ 0.35 วินาที และระยะเวลาในการฝึกสอนสำหรับข้อมูลในการฝึกสอน 100 ภาพ สถาปัตยกรรม SSD ใช้เวลาในการฝึกสอนสำหรับ 20000 รอบการเรียนรู้อยู่ที่ 3 ชั่วโมง 39 นาที และ Faster R-CNN ใช้เวลาในการฝึกสอนที่ 5 ชั่วโมง 53 นาที

จากการทดลองจะเห็นได้ว่าค่าเฉลี่ยความแม่นยำของสถาปัตยกรรมทั้ง 2 มีค่าต่ำเนื่องจากการทดสอบด้วยภาพที่มีคุณลักษณะแตกต่างกันกับข้อมูลที่ถูกใช้ในการฝึกสอนทั้งในด้าน ขนาดของวัตถุภายในภาพ ปริมาณแสงที่ไม่ได้ควบคุมและมุมของกล้องที่ใช้ในการเก็บภาพ แต่เมื่อนำมา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทดสอบกับภาพที่ทำการกำหนดระยะห่างอย่างคงที่ในการทดลอง โมเดลที่ใช้ในการตรวจจับวัตถุสามารถตรวจจับวัตถุได้ถูกต้องแม่นยำ

โดยในงานวิจัยนี้เป็นการประมวลผลจากภาพถ่ายซึ่งไม่จำเป็นต้องใช้ความเร็วในการประมวลผลต่อภาพสูงและต้องการความแม่นยำในการประมวลผลต่อภาพสูง ดังนั้นจึงใช้โมเดลตรวจจับวัตถุที่สร้างขึ้นจากสถาปัตยกรรม Faster R-CNN ที่มีความแม่นยำสูงกว่าและเมื่อเปรียบเทียบกับงานวิจัยที่อ้างอิง [34] ถึงปริมาณตัวแปรและการใช้ทรัพยากรของหน่วยประมวลผลน้อยกว่าสถาปัตยกรรม SSD

4.2 การทดสอบหาตำแหน่งของจุดที่เกิดความผิดปกติด้วยภาพถ่ายความร้อน

การทดสอบการหาตำแหน่งจุดร้อนด้วยภาพถ่ายความร้อนด้วยการประมวลผลภาพ โดยจะทำการแปลงภาพถ่ายความร้อนเป็นภาพระดับสีเทา (gray scale) ขนาด 8 บิต จากนั้นทำการแปลงค่าความเข้มสีเป็นค่าอุณหภูมิโดยอ้างอิงจากสมการในส่วนของบทที่ 3 ตามสมการที่ 3.1 และทำการเปรียบเทียบกับค่าอุณหภูมิจริงเมื่อวัดด้วยกล้องถ่ายภาพความร้อน โดยทำการเปรียบเทียบด้วยค่าเฉลี่ยของอุณหภูมิทั้งภาพ อุณหภูมิสูงสุดของภาพ อุณหภูมิต่ำสุดของภาพ อุณหภูมิของเฉลี่ยของพื้นที่ อุณหภูมิสูงสุดของพื้นที่ อุณหภูมิต่ำสุดของพื้นที่และอุณหภูมิโดยการสุ่มตำแหน่งตามตารางที่ 4.3

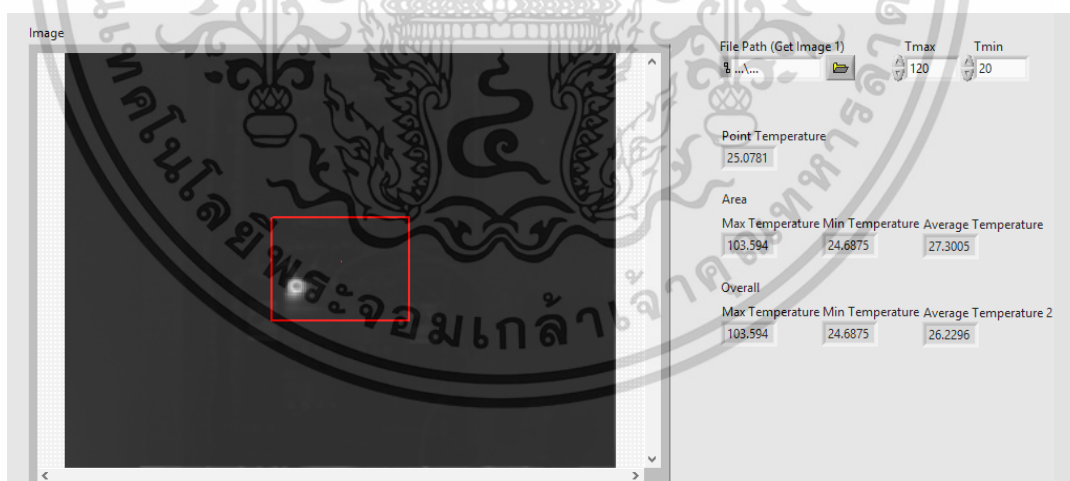


รูปที่ 4.5 แสดงของภาพถ่ายความร้อนที่แสดงผลเป็นภาพถ่ายแบบระดับสีเทาขนาด 8 บิต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.3 แสดงค่าอุณหภูมิเมื่อเปรียบเทียบกับค่าที่วัดได้จากกล้องถ่ายภาพความร้อน

	อุณหภูมิที่อ่านได้จาก กล้องถ่ายภาพความร้อน	อุณหภูมิที่อ่านได้จาก โปรแกรมประมวลผลภาพ
พื้นที่ (120,95,200,155)		
- สูงสุด	107.45	103.59
- ต่ำสุด	24.81	24.68
- ค่าเฉลี่ย	27.26	27.30
ตำแหน่ง(136,139)		
- สูงสุด	25.11	25.08
- ต่ำสุด	25.11	25.08
- ค่าเฉลี่ย	25.11	25.08
ภาพรวม		
- สูงสุด	107.45	103.59
- ต่ำสุด	24.29	24.69
- ค่าเฉลี่ย	26.00	26.23



(ก)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ข)


รูปที่ 4.6 แสดงตัวอย่างการอ่านค่าอุณหภูมิ (ก) โปรแกรมคำนวณอุณหภูมิ (ข) โปรแกรมของกล้องถ่ายภาพความร้อนที่ตำแหน่ง (160,20) และพื้นที่ของ (120,95,200,155)

จากการทดลองจะเห็นว่าเมื่อนำภาพถ่ายความร้อนมาทำการวัดค่าอุณหภูมิด้วยโปรแกรมที่พัฒนาขึ้น ค่าอุณหภูมิที่อ่านได้จากโปรแกรมเมื่อวัดค่าอุณหภูมิสูงสุด ต่ำสุด และเฉลี่ยทั้ง 3 รูปแบบ ประกอบด้วย อุณหภูมิของภาพรวม อุณหภูมิของพื้นที่ที่กำหนด และอุณหภูมิของตำแหน่งที่กำหนด โดยมีค่าเปอร์เซ็นต์ความแตกต่างอยู่ที่ 1.591 % 1.312 % และ 1.489 % ตามลำดับ โดยความคลาดเคลื่อนอาจเกิดได้จากค่าตัวแปรของการถ่ายภาพด้วยกล้องถ่ายภาพความร้อน เนื่องจากมีการวัดค่าอุณหภูมิของวัตถุที่มีพื้นผิวต่างชนิดกัน โดยค่าสัมประสิทธิ์การแผ่รังสีของพื้นผิวนั้นวัตถุไม่เท่ากันทั้งวัตถุ เช่น บนอุปกรณ์มีจุดเชื่อมต่อที่เป็นโลหะซึ่งมีค่าสัมประสิทธิ์การแผ่รังสีค่าร้อนต่ำกว่าพลาสติกที่เป็นพื้นผิวรอบข้าง ส่งผลให้ค่าอุณหภูมิที่อ่านได้จากโปรแกรมประมวลผลภาพเกิดความคลาดเคลื่อนโดยทั่วไปการตรวจสอบสถานะของอุปกรณ์ไฟฟ้าที่มีจุดเชื่อมต่อเป็นโลหะนั้นจะใช้ค่าอุณหภูมิสูงสุดที่วัดได้เป็นตัวชี้วัดความผิดปกติ ดังนั้นในการทดลองจึงใช้อุณหภูมิสูงสุดที่เกิดบนตัวอุปกรณ์เป็นตัวชี้วัดสถานะของอุปกรณ์ไฟฟ้า [2,3,33]

เมื่อทราบอุณหภูมิของจุดร้อนที่เกิดขึ้นบนภาพทำให้สามารถหาตำแหน่งของจุดที่เกิดความร้อนสูงกว่าที่กำหนดอ้างอิงจาก NETA Standard for IRT inspection โดยกำหนดให้จุดร้อนที่มีอุณหภูมิสูงกว่าค่าอุณหภูมิแวดล้อม 40 องศาเซลเซียสเป็นจุดที่เกิดความผิดปกติหรืออาจจะเกิดความ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผิดปกติ และจุดที่อุณหภูมิสูงกว่าที่กำหนดจะถูกตรวจจับและสามารถระบุตำแหน่งของจุดร้อนและแสดงค่าอุณหภูมิสูงสุดของตำแหน่งที่ระบุได้ดังรูปที่ 4.8




รูปที่ 4.7 แสดงผลการทดลองหาตำแหน่งและประมวลผลค่าอุณหภูมิของจุดร้อน

4.3 การทดสอบหาอุปกรณ์ที่เกิดความผิดปกติ


สำหรับการตรวจหาอุปกรณ์ที่เกิดความผิดปกติด้วยภาพถ่ายความร้อน เป็นการประยุกต์การตรวจจับวัตถุและการตรวจจับตำแหน่งที่ผิดปกติบนอุปกรณ์เข้าด้วยกัน เพื่อให้โปรแกรมสามารถระบุชนิดของอุปกรณ์ที่เกิดความผิดปกติได้ โดยโปรแกรมจะทำการตรวจจับชนิดและระบุตำแหน่งของอุปกรณ์ด้วยโมเดลที่ถูกสร้างขึ้นในการทดลองที่ 4.1 จากนั้นนำมาประมวลผลเพื่อทำการกำหนดพื้นที่ที่สนใจ (ROI) เพื่อกำหนดให้ส่วนของการประมวลผลภาพถ่ายความร้อนในการทดลองที่ 4.2

จากการทดลองจะเห็นได้ว่าเมื่อนำทั้งผลการทดลองของทั้งสองส่วนมาประยุกต์ใช้งานร่วมกัน สามารถระบุชนิดของอุปกรณ์ที่เกิดความผิดปกติได้ ทำให้การวิเคราะห์ความผิดปกติของอุปกรณ์ไฟฟ้ามีประสิทธิภาพมากขึ้น ดังผลการทดลองดังรูปที่ 4.9 4.10 และ 4.11 และตามตารางที่ 4.4


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.8 แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยไม่มีอุปกรณ์ที่มีสถานะผิดปกติและอุปกรณ์อยู่ภายนอกของตู้ควบคุมมอเตอร์



รูปที่ 4.9 แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยมีอุปกรณ์ที่มีสถานะผิดปกติ 1 อุปกรณ์



รูปที่ 4.10 แสดงผลการทดสอบโปรแกรมตรวจสอบสถานะโดยมีอุปกรณ์ที่มีสถานะผิดปกติ 3 อุปกรณ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 แสดงผลการทดลองตรวจสอบสถานะของอุปกรณ์ไฟฟ้า

Number of fail object	Accuracy
0	9/10
1	9/10
2	8/10
3	9/10
4	9/10
5	8/10
total	52/60 = 86.67 %

จากผลการทดลองตารางที่ 4.4 จะเห็นได้ว่าการตรวจจับอุปกรณ์ที่เกิดความผิดปกติด้วยภาพถ่ายความร้อน สามารถระบุชนิดของอุปกรณ์ที่เกิดความผิดปกติได้ในทุกอุปกรณ์ที่เกิดความผิดปกติ โดยการทดลองมีความแม่นยำในการตรวจสอบสถานะของอุปกรณ์ที่เกิดความผิดปกติเรียงตามจำนวนอุปกรณ์เกิดความผิดปกติตั้งแต่ 0 อุปกรณ์ถึง 5 อุปกรณ์โดยมีค่าความแม่นยำเฉลี่ยอยู่ที่ 86.67% ซึ่งจากผลการทดลองจะเห็นได้ว่ามีความผิดพลาดเกิดขึ้นจากทั้งในส่วนของ การตรวจจับวัตถุ ซึ่งตำแหน่งของวัตถุที่คลาดเคลื่อนจากตำแหน่งจริงที่เกิดขึ้นจากสภาพแวดล้อมที่ไม่ถูกควบคุม เช่น แสงเงาตกกระทบและการบดบังวัตถุจากวัตถุอื่น และยังอาจจะเกิดความผิดพลาดได้จากการประมวลผลค่าอุณหภูมิจากภาพถ่ายความร้อนที่เกิดความคลาดเคลื่อน เนื่องจากความละเอียดของค่าความเข้มสีที่ 8 บิตมีช่วงค่าที่ 0-255 ซึ่งเป็นจำนวนเต็มทำให้ค่าอุณหภูมิที่มีค่าทศนิยมมีความคลาดเคลื่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ในงานวิจัยนี้นำเสนอวิธีการประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับการวิเคราะห์ความผิดปกติของอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อน เพื่อให้โปรแกรมที่พัฒนาขึ้นสามารถระบุถึงชนิดของอุปกรณ์ที่เกิดความผิดปกติได้และสามารถตรวจสอบสถานะของอุปกรณ์ได้ โดยทำการสร้างโมเดลเพื่อทำนายชนิดของอุปกรณ์ไฟฟ้าบนภาพและพัฒนาโปรแกรมเพื่ออ่านค่าอุณหภูมิจากภาพถ่ายความร้อนเพื่อตรวจจับความผิดปกติที่เกิดขึ้นจากความร้อนบนอุปกรณ์ โดยทำการจำลองให้เกิดจุดร้อนขึ้นบนอุปกรณ์ต่างๆ เพื่อทำการทดสอบ

ในส่วนของการสร้างโมเดลระบุชนิดของอุปกรณ์ยังมีความผิดพลาดที่เกิดขึ้นคุณสมบัติของภาพที่ใช้ในการสร้างโมเดลเช่น ความละเอียดของภาพ ขนาดของวัตถุแต่ละชนิดบนภาพอาจมีขนาดเล็กหรือใหญ่เกินไปทำให้เกิดความผิดพลาดได้ในการระบุชนิดตำแหน่งของวัตถุ เมื่อนำข้อมูลที่ได้จากส่วนของการระบุตำแหน่งของวัตถุมาใช้ร่วมกับโปรแกรมวิเคราะห์ภาพถ่ายความร้อนที่พัฒนาขึ้นด้วย LabVIEW เพื่อให้สามารถตรวจสอบสถานะของอุปกรณ์ไฟฟ้าได้ โดยส่วนของการวิเคราะห์ภาพถ่ายความร้อนนั้นสามารถวัดค่าอุณหภูมิได้แม่นยำเมื่อทำการเปรียบเทียบกับค่าอุณหภูมิที่อ่านได้จากกล้องถ่ายภาพความร้อน นอกจากนี้โปรแกรมที่พัฒนาขึ้นยังสามารถตรวจจับตำแหน่งของจุดที่เกิดความผิดปกติด้วยภาพถ่ายความร้อนและสามารถคำนวณหาค่าอุณหภูมิของจุดที่เกิดความผิดปกติได้ โดยอ้างอิงจากมาตรฐานการตรวจสอบอุปกรณ์ไฟฟ้าด้วยภาพถ่ายความร้อนของ NETA และเมื่อนำโปรแกรมทั้งสองส่วนมาประยุกต์ใช้ร่วมกันโดยการหาใช้ตำแหน่งของอุปกรณ์ไฟฟ้าที่ตรวจจับได้มาทำการเปรียบเทียบกับตำแหน่งที่เกิดจุดร้อนทำให้สามารถระบุสถานะของอุปกรณ์ไฟฟ้าได้ โดยสถานะของอุปกรณ์ไฟฟ้าถูกแบ่งออกเป็น 2 สถานะคือสถานะปกติและผิดปกติ และในกรณีที่ไม่มีอุปกรณ์ในภาพโปรแกรมสามารถบอกได้ว่าตรวจไม่พบอุปกรณ์

โดยการทดลองมีความแม่นยำในการตรวจสอบสถานะของอุปกรณ์ที่เกิดความผิดปกติเรียงตามจำนวนอุปกรณ์เกิดความผิดปกติตั้งแต่ 0 อุปกรณ์ถึง 5 อุปกรณ์โดยมีค่าความแม่นยำเฉลี่ยอยู่ที่ 86.67% ซึ่งจากผลการทดลองจะเห็นได้ว่ามีความผิดพลาดเกิดขึ้นจากทั้งในส่วนของการตรวจจับวัตถุซึ่งตำแหน่งของวัตถุที่คลาดเคลื่อนจากตำแหน่งจริงที่เกิดขึ้นจากสภาพแวดล้อมที่ไม่ถูกควบคุมเช่น แสงเงาตกกระทบและการบดบังวัตถุจากวัตถุอื่น และยังสามารถเกิดความผิดพลาดได้จากการประมวลผลค่าอุณหภูมิจากภาพถ่ายความร้อนที่เกิดความคลาดเคลื่อน เนื่องจากความละเอียดของค่าความเข้มสีที่ 8 บิตมีช่วงค่าที่ 0-255 ซึ่งเป็นจำนวนเต็มทำให้ค่าอุณหภูมิที่มีค่าทศนิยมมีความคลาดเคลื่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2 ข้อเสนอแนะ

จากการทดลองในการเก็บภาพด้วยกล้องถ่ายภาพความร้อนไม่ได้มีการควบคุมแสงซึ่งเป็นผลให้เกิดจากการสะท้อนของอุณหภูมิของจุดเชื่อมต่อที่เป็นโลหะ จึงทำให้อุณหภูมิที่อ่านได้จากกล้องถ่ายภาพความร้อนเกิดความคลาดเคลื่อน ดังนั้นควรมีการควบคุมการสะท้อนของอุณหภูมิของวัตถุเพื่อเพิ่มประสิทธิภาพให้มากขึ้น นอกจากนี้ภาพถ่ายของตู้ควบคุมระบบไฟฟ้าไม่มีการจัดการสายไฟฟ้าที่ดีทำให้เกิดการบดบังตัวอุปกรณ์ส่งผลให้การทํานายชนิดหรือการระบุตำแหน่งของอุปกรณ์เกิดความคลาดเคลื่อน ดังนั้นจึงควรมีการจัดการสายไฟที่ดีกว่านี้เพื่อเพิ่มประสิทธิภาพการทำงานของโปรแกรมให้สูงมากขึ้น โดยงานวิจัยนี้สามารถนำไปประยุกต์ใช้ในการระบุชนิดของวัตถุที่เกิดความผิดปกติที่เกิดจากความร้อนอื่นได้และสามารถพัฒนาให้สามารถระบุชนิดของวัตถุได้มากกว่า 4 ชนิดที่อยู่ในตู้ควบคุมนี้ด้วยการเพิ่มข้อมูลสำหรับฝึกสอน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Z. Jaffery, et. al. 2014. "Design of early fault detection technique for electrical assets using infrared thermograms" **International Journal of Electrical Power & Energy Systems.** (63) : 753-759
- [2] M.R Clark, et. al. 2015. "Application of infrared thermography to the non-destructive testing of concrete and masonry bridges." **NDT & E International.**
- [3] S. Bagavathiappan, et.al. 2013 "Infrared thermography for condition monitoring – A review" **Infrared Physics & Technology** (60): 35-55
- [4] X. Zhou and T. Schoepf, 2011 "Characteristics of Overheated Electrical Joints Due to Loose Connection," **2011 IEEE 57th Holm Conference on Electrical Contacts** : 1-7.
- [5] M. D. Zeiler and R. Fergus, 2014. "Visualizing and understanding convolutional neural networks," **European Conference on Computer Vision (ECCV)**
- [6] Everingham, M. et. al. 2015. "The Pascal Visual Object Classes Challenge: A Retrospective." **International Journal of Computer Vision.** : 98-138
- [7] R. Girshick, "Fast R-CNN," **2015 IEEE International Conference on Computer Vision (ICCV).** : 1440-1448
- [8] S. Ren, K. He, R. Girshick and J. Sun, "Faster R-CNN: Towards Real-Time Objects Detection with Region Proposal Networks," **IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017** 39 : 1137-1149
- [9] K. Han, et. al. 2017. "A new method in wheel hub surface defect detection: Object detection algorithm based on deep learning," **2017 International Conference on Advanced Mechatronic Systems (ICAMechS).** : 335-338.
- [10] Z. Hui and H. Fuzhen, "An intelligent fault diagnosis method for electrical equipment using infrared images," **2015 34th Chinese Control Conference (CCC).** : 6372-6376
- [11] E. Mechkov, "Application of infrared thermography technique in transformers maintenance in distribution network," **2017 15th International Conference on Electrical Machines, Drives and Power Systems (ELMA).** : 354-357.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [12] A.S.N. Huda, et. al. 2014, "A new thermographic NDT for condition monitoring of electrical components using ANN with confidence level analysis." **ISA Transactions**, 3:717-724.
- [13] M. A. Herrera-Arellano et. al. 2017. "Infrared thermography-based automatic assessment of control components for electric machines," **2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)**. : 578-584.
- [14] S. Hayat, et. al. 2018. "A Deep Learning Framework Using Convolutional Neural Network for Multi-Class Object Recognition," **2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)**. pp. 194-198.
- [15] ยุทธพงศ์ ทัพผดุง,ทวีพล ซื่อสัตย์,นวกัทธา หนูนาถ และ อีรวัฒน์ หนูนาถ. 2555. **การใช้เทคโนโลยีภาพถ่ายความร้อนอินฟราเรดอย่างมืออาชีพ**. กรุงเทพฯ. วิศวกรรมสถานแห่งประเทศไทย ในพระบรมราชูปถัมภ์
- [16] Gonzalez, R. and Woods, R.. 2002. **Digital Image Processing 2nd Edition**. New Jersey. Prentice Hall.
- [17] N. Dhanachandra, et. al. 2015. "Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm." **Procedia Computer Science**. :764-771.
- [18] ERDAS, Inc. **ERDAS Field Guide™** . ERDAS, Inc. 5th edition. United States of America. 1999
- [19] ผศ.ดร.นวกัทธา หนูนาถ. 2555. **กล้องถ่ายภาพความร้อน** [Online].Available: <http://www.foodnetworksolution.com/wiki/word/7311/thermal-imager>
- [20] Aurélien Géron. 2019. **Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 2nd Edition. USA O'Reilly Media, Inc
- [21] B. Reagen, R. Adolf, P. Whatmough. 2017. **Deep Learning for Computer Architects**. California: Morgan & Claypool Publishers
- [22] Alex Krizhevsky, et al. 2012. "Imagenet classification with deep convolutional neural networks." **Advances in neural information processing systems**. : 1097-1105
- [23] K. Simonyan and A. Zisserman, 2015. "Very deep convolutional networks for large-scale image recognition," in **International Conference on Learning Representations (ICLR)**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [24] Stanford University. **Transfer Learning**. [Online]. Available :
<http://cs231n.github.io/transfer-learning/>. 2016.
- [25] สุภานิติ แสงธรรม. 2560. **การบำรุงรักษาเน้นความเชื่อถือได้ (Reliability Centered Maintenance)**. RCM THAI, เอ็มแอนด์อี
- [26] Stanford University. **Convolutional Neural Networks**. [Online]. Available :
<http://cs231n.github.io/convolutional-networks>. 2016.
- [27] Fluke Corporation. **Fluke detailed specification**. [Online]. Available :
<https://www.fluke.com/en-th/product/thermal-cameras/ti400>
- [28] A. Sandeep. **Object Detection -IOU-Intersection Over Union**. [Online]. Available
<https://medium.com/@nagsan16/object-detection-iou-intersection-over-union>
- [29] ผศ.ดร.พิมพ์เพ็ญ พรเฉลิมพงศ์ และ ผศ.ดร.นวกัทธา หนูนาท. 2555. **สัมประสิทธิ์การแผ่รังสีความร้อน**[Online].Available:
<http://www.foodnetworksolution.com/wiki/word/4304/emissivity>
- [30] Z. Hui and H. Fuzhen, 2015 "An intelligent fault diagnosis method for electrical equipment using infrared images," **2015 34th Chinese Control Conference (CCC)** : 6372-6376.
- [31] InterNational Electrical Testing Association. **Standard for infrared thermography for inspection**. Portage. USA. InterNational Electrical Testing Association
- [32] J. Huang et al. 2017. "Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors," **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**: 3296-3297.
- [33] T. Dutta, et. al. 2016 "Condition monitoring of electrical equipment using thermal image processing," **2016 IEEE First International Conference on Cont Measurement and Instrumentation (CMI)** : 311-315.
- [34] Liu Wei, et. al. 2016 "SSD: Single Shot MultiBox Detector," **2016 ECCV**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Lecture Notes in Engineering and Computer Science

IMECS 2019

International MultiConference of
**Engineers and Computer
Scientists 2019**



**Hong Kong
13-15 March, 2019**

S. I. Ao
Oscar Castillo
Craig Douglas
David Dagan Feng
A. M. Korsunsky (Eds.)

IA ENG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่สามารถนำออกจำหน่าย
International Association of Engineers

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ISBN: 978-988-14048-5-5

ISSN: 2078-0958

Applying CNN to Infrared Thermography for Preventive Maintenance of Electrical Equipment

S. Rokrakthong, T. Suesut and N. Tumrukwatthana

Abstract—This paper presents the new method to classify the condition of electrical equipment such as main circuit breaker, magnetic contactor, in term of thermal radiation effect using infrared thermography. The conventional neural network (CNN) is one of deep learning method which is widely used in pattern recognition and object detection. In this paper, the thermal image processing was used to determine the critical temperature on equipment and, the deep learning technology was applied to identify the type of equipment. Therefore, we can know the condition with the type of electrical equipment for maintenance purpose in real-time. An accuracy of our method is 91% for identifying type of equipment. This technique can be implemented to an automatic alarm annunciation system for other dangerous equipment with sensitive to thermal as well.

Index Terms— Object detection, Infrared Thermography, Convolutional neural network

I. INTRODUCTION

Infrared thermography is a tool to determine the temperature of any object by infrared thermal radiation wave. The object with temperature more than absolute zero, which can emit thermal energy by radiation. The higher temperature is impact to the failure of equipment such as loose connection, imbalance load, over load and improper installing. In addition, the failure can lead to many disasters like damage to equipment, injures or even death [1].

Infrared thermography is one of the non-contact testing that represent the surface temperature of object. Due to the temperature is parameter to identify the condition of equipment. Therefore, the temperature monitoring is good methodologies to analyze condition of equipment. Fuzhen Huang et al. present the novel fault diagnosis method with infrared thermography. Infrared thermography is key to classification the equipment combine with support vector machine. This work can classify condition of equipment to

Manuscript received December 20, 2018; revised January 20, 2019. This work was supported in part by Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520.

S. Rokrakthong is with department of Instrumentation and Control Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520.
(e-mail: 60601008@kmitl.ac.th)

T. Suesut is corresponding author with department of Instrumentation and Control Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520
(e-mail: taweepol.su@kmitl.ac.th)

N. Tumrukwatthana is with department of Instrumentation and Control Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, 10520
(e-mail: narn.ta@kmitl.ac.th)

four condition [1]. In addition to classification it can also scheme to maintenance by priority of condition.

Instantly maintenance is also required identifying type of equipment to quick repair. The traditional method can classify priority for maintenance but cannot identify the fault equipment. Recently, the method to identify object are developed. Convolutional neural network is technique, that commonly applied to image processing. This technique has high performance classification when compared to the other method. The advantage of this method is fewer parameters to train data with very deep architecture. Shaukat Hayat et al. has applied deep learning to identify nine different class, that has effectively with 90.12% accuracy [2]. In addition, convolutional neural network can be identified class of object and can also localized position of object. Kai Han et al. propose a new method to detect defects on wheel hub surface. The faster R-CNN is used combine with ResNet 101 for detection. This method obtains the position of defects and type of defects [3]. So, object detection is used for identifying equipment.

In this paper has propose the method to analyze condition of equipment in MDB using by deep learning and infrared thermography. The equipment in main distributor board (MDB) to start three phase motor is no fuse breaker, breaker, magnetic contactor and overload relay. In rest of this paper are followed: Section 2 is principle; Experimental setup is shown in Section3; Section 4 and Section 5 are result of experimental and conclusion,

II. RELATE WORK

A. Object detection

In field of object detection convolutional neural network become the leading method because the network can reduce parameter and complexity of network. Therefore, object detection by using convolutional is interesting to applied in this work. Faster R-CNN (Region-based Convolutional neural network) architecture is applied with RPN (Region Proposal Network) and fast R-CNN.

Region proposal network is the one of deep learning based on convolutional neural network. Which, the network can predict the area and score of objects at each position by the generated box also call anchor. Sliding window is used to extract the feature map. Shown in Figure 1. Fast R-CNN is applied with RPN to create architecture for object detection. From RPN, the region of interest is obtained, and fast R-CNN is used to classification. As shown in Figure2.[4]

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Figure 1. Region Proposal Network (RPN)

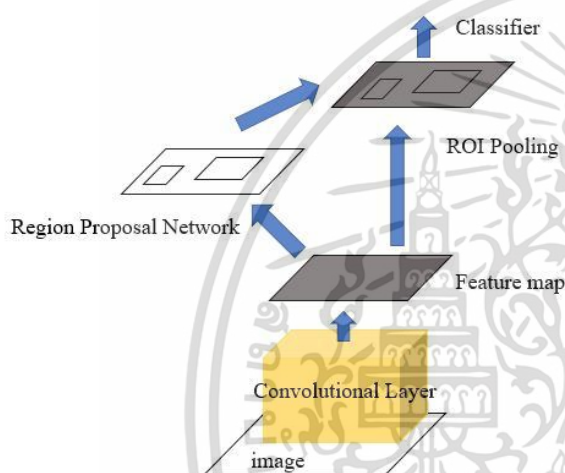


Figure 2. Faster R-CNN architecture

The model to detect object in figure 2, there are only one model but there are many models. The faster R-CNN was applied in this research because this model has efficiency to small object and has high speed training. [5]

B. Fault in electrical equipment

Avoiding fault in equipment is importance because fault in electrical equipment can affect to reliable of system and lead to catastrophic. Furthermore, the fault equipment requires a lot of budget to maintenance and manpower or in the worst case is casualties. The fault diagnosis by infrared thermography has divide to two type including internal fault and external fault. In this paper focus on external fault which, it can be directly observed on the surface of equipment. Normally, the high temperature on the surface occurs by high resistance from loose connection or any reason, the result is heat. [6] The criterions of condition of electrical equipment that detected by infrared of thermography using NETA standards for IRT base inspection of electrical equipment that define condition of equipment by differential of temperature to priority as shown in Table I [7].

C. Thermal imager

The temperature measured by thermal image camera is not only radiation emitted from the object but also radiation from ambient object and reflected on the object. Therefore, measuring temperature value to accurate need to control these conditions there are also many variants that affect to the measurement such as humidity and ambient temperature in addition to the measurement of infrared imager must be align in line with the object. And the example images of fault equipment with both of visual image and thermal image as shown in Figure 3.

TABLE I
NETA STANDARDS FOR IRT BASE INSPECTION OF ELECTRICAL EQUIPMENT IN SIMILAR EQUIPMENT

(ΔT) with similar equipment ($^{\circ}C$)	(ΔT) with ambient temperature ($^{\circ}C$)	Recommended Action
1-3	1-10	Possible deficiency, warrants investigation (priority :4)
4-15	11-20	Indicate probable deficiency, repair as time permits (priority :3)
-	21-40	Monitor continuously until corrective measure can be accomplished (priority :2)
≥ 15	> 40	Major discrepancy, repair intermediately (priority :1)




Figure 3. The example of image (a) visual image and thermal image with normal condition. (b) visual image and thermal image with abnormal condition

III. EXPERIMENT SETUP

The experiment setup consisted of infrared imager FLUKE TI-400 Portable imager (Table I), main distribution board and equipment to start motor three phase including no fuse breaker, breaker, two of magnetic contactor and overload relay. After that, both of visual image and thermal image are grabbed from fluke ti-400 at 120 cm of distance

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องสงวนลิขสิทธิ์ของเอกสารนี้ทั้งหมดไว้ด้วย

from MDB. The images are divided to 5 group including 1 fault objects, 2 fault objects, 3 fault objects, 4 fault objects and all of fault objects.

TABLE II
GENERAL SPECIFICATIONS OF FLUKE TI-400

IFOV	1.31 mRad
Detection resolution	320×240 pixels
Field of view	24 °H × 17 °V
Minimum Focus	15 cm
Optional Lens	Telephoto lens, wide angle lens
Measuring range	-20 to +1200°C (-4 to + 2192°F)
Thermal sensitivity	≤ 0.05°C at 30 °C target temp (50mK)
Built-in digital camera	5 megapixels
Fame rate	60 Hz

A. Training model to detection

The dataset containing 200 images were collected from MDB by FLUKE Ti-400 both thermal images and visual image. And randomly divide the visual image into two set by 140 images to training data and 60 images to test data to create model to identify and localize object. These images were same size but different environment such as one breaker in picture or four type of equipment in picture. After clustering group of data, the model was generated by faster R-CNN architecture.



Figure 4. The example of equipment in MDB to start three phase motor consisted of breaker, No fuse breaker, relay and magnetic contactor (from the left to right)

B. Pre-Processing Thermal images

The image is pre-processing using FLUKE software to adjust maximum and minimum temperature and convert to 8-bit gray scale image. The relative of gray level and temperature is depended on equation (1).

$$T_{(i,j)} = \frac{T_{\max} - T_{\min}}{255} \times g_{(i,j)} + T_{\min} \quad (1)$$

where $T(i,j)$ is Temperature at position (i,j) . T_{\max} , T_{\min} is range of temperature after pre-processing procedure. $g(i,j)$ is gray level at position (i,j)

C. Analyze and identify object

In this part, the program is developed by LABVIEW2018-64bit. The image both of thermal image and visual image is used to input of this program. And, the program is split in to two part. In part of visual image is used to detect type and localizing of object. In part of thermal image after the pre-

processing the images were performed threshold segmentation and sent position of fault to analyze with position from visual image as illustrated in Figure 5.

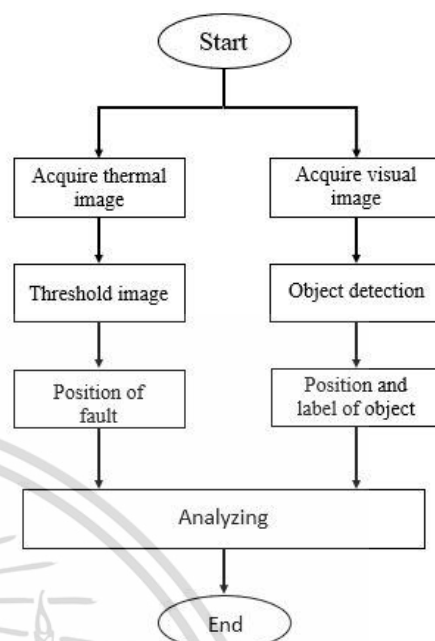


Figure 5. Procedure of the method

IV. RESULT AND DISCUSSION

In the experiment, the both of thermal image and visual image were collected to new data with different dataset of dataset to generate model to detect object. Then, the heat was simulated hot spot on each equipment that hot spot is random on each of connector (21 connector in 5 equipment). After that, the images will be randomized and used these to test data.

A. Object Detection

The dataset was rebuilt in previous step, it was randomized and used for accuracy testing of the model. The dataset to testing is divided into 5 group by each group has 20 images. the result of this step is shown in Figure 6.

B. Analyze and identify

After the object detection, the thermal image was used to diagnosis fault. The condition of equipment was considering by the different temperature of hotspot and temperature of equipment by using NETA standard for IRT inspection in electrical equipment which NETA standard has define condition of electrical equipment into 4 priority to maintenance. But, the action of priority 3 and 4 was monitoring until the equipment to be corrective processing and priority 1 and 2 the action recommends is maintenance. Therefore, in this work is divide the condition of equipment into 2 condition consisted by normal and abnormal. And the example of result as shown in Figure 5.

การศึกษานี้ใช้ข้อมูลจากชุดข้อมูลที่มีอยู่เพื่อสร้างแบบจำลองการตรวจจับและระบุตำแหน่งของข้อผิดพลาดในภาพความร้อนและภาพมองเห็น การศึกษาเหล่านี้ ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า การวิจัย หรือการเผยแพร่โดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




Figure 6. The example of result from object detection by generated model. (a) 4 equipment with 3 type in picture, (b) 2 equipment with 2 type in picture (c) 5 equipment with 4 type in picture but the system incorrect identify

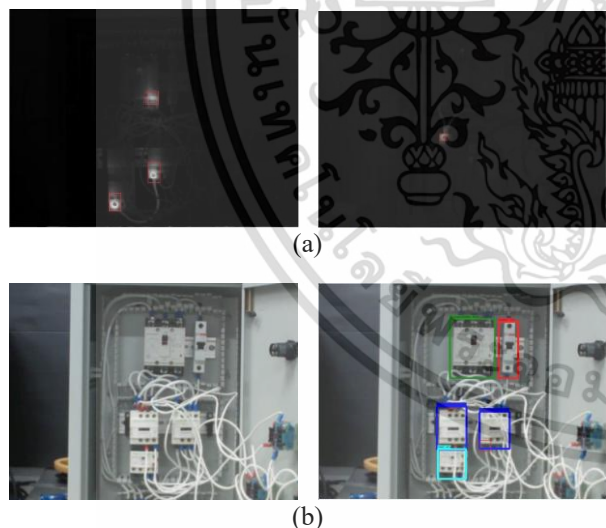


Figure 5. The result of temperature diagnosis with both of thermal image and visual image. (a) thermal image can detect hotspot on equipment. (b) When combine the result of thermal image with visual image is can classify and identify object to be failure.

TABLE III
RESULT OF THE METHOD

Number of fail objects	Accuracy (correct/total) %
1	(20/20) 100 %
2	(19/20) 95 %
3	(18/20) 90 %
4	(17/20) 85 %
5	(17/20) 85 %
Total	(91/100) 91%

TABLE III shows the result of combination of object detection and analyze fault with infrared thermography that can classify condition of each equipment by accuracy 91 %

The result is illustrating to some problem in object detection may be caused by size of object in image to retrain the model or caused by inaccurate temperature of measurement by thermal imager. Which, these problem affects to analyzing in section of analyze and identify that lead to cannot identify object to be failure or incorrect identify object to be failure.

V. CONCLUSION

In this work, the classification of condition in electrical equipment using application of deep learning and infrared thermography that illustrated to the temperature from fault is indicator to decide the equipment to be failure. So, the thermal image can be classified condition of equipment by different temperature. In addition, object detection by using convolutional neural network was applied in this work to identified type of object and location. When the combination of two section, our system can classify and identify the failure of object. However, this system still has some problems caused by thermal image and properties of visual image such as resolution and size of equipment in image. This technique can be applied to design the automatic alarm system for other dangerous equipment with sensitive to temperature changing as well.

REFERENCES

- [1] Hui Zou, Fuzhen Huang, "A novel intelligent fault diagnosis method for electrical equipment using infrared thermography", *Infrared Physics & Technology*, Volume 73 2015. Pages 29-35.
- [2] S. Hayat, S. Kun, Z. Tengtao, Y. Yu, T. Tu and Y. Du, "A Deep Learning Framework Using Convolutional Neural Network for Multi-Class Object Recognition", 2018 IEEE 3rd International Conference on Image, Vision and Computing (ICIVC), Chongqing, 2018, pp. 194-198.
- [3] K. Han, M. Sun, X. Zhou, G. Zhang, H. Dang and Z. Liu, "A new method in wheel hub surface defect detection: Object detection algorithm based on deep learning", 2017 International Conference on Advanced Mechatronic Systems (ICAMechS), Xiamen, 2017, pp. 335-338.
- [4] S. Ren, K. He, R. Girshick and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137-1149
- [5] J. Huang et al., "Speed/Accuracy Trade-Offs for Modern Convolutional Object Detectors," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, 2017, pp. 3296-3297
- [6] Li Feng, Li Jianfeng, Meng Yu, Tong Rui, Liu Ren, Zu Bo, Liu Wei, Liu Lin, Wang Zhaoxia, Cheng Xingjun, Chen Guorui and Liu Min "An Infrared Detection Method Used In Electrical Equipment Fault Diagnosis" 4th International Conference on Machinery, Materials and Computing Technology (ICMMCT 2016), pp.1447-1450
- [7] S. Bagavathiappan, B.B. Lahiri, T. Saravanan, John Philip, T. Jayakumar, "Infrared thermography for condition monitoring" *Infrared Physics & Technology*, Volume 60, 2013, Pages 35-55

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับกรใช้วงนเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่าการณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ-นามสกุล นายศุภณัฐ รกรากทอง
วัน เดือน ปี เกิด 28 กันยายน 2537
ที่อยู่ 234/4 ถนนสมุทรคงคา ตำบลปากน้ำ อำเภอเมือง จังหวัดระยอง 21000

ประวัติการศึกษา

ระดับปริญญาตรี วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมอิเล็กทรอนิกส์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ความเชี่ยวชาญ การใช้งานกล้องถ่ายภาพความร้อน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้