

การพัฒนาโปรแกรมคัดแยกรูปภาพอุปกรณ์ไฟฟ้าในระบบส่งจ่ายกำลังไฟฟ้าด้วยระบบปัญญาประดิษฐ์
Development of Image Classification Software for Electrical Equipment in Power Distribution Systems
using Artificial Intelligence

นิธิภูมิ ยศสอน, ชวลิต แก้วเลิศ, ณัฐพงษ์ ตันthanuch และ นภดล อุชาพิชชาต

Nithipoom Yossorn, Chawalit Kaewlert, Nutthaphong Tanthanuch and Nopadol Uchaipichat

ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ จังหวัดปทุมธานี 12120

บทคัดย่อ

ในระบบการจัดส่งไฟฟ้าเพื่อจำหน่ายแก่ประชาชนนั้น การซ่อมบำรุงรักษาอุปกรณ์ไฟฟ้าในระบบสายส่งนั้นมีความจำเป็นอย่างมากเพื่อรักษาเสถียรภาพและประสิทธิภาพของการจัดส่ง ในปัจจุบันระบบการจำหน่ายไฟฟ้านั้นมีโครงข่ายที่ครอบคลุมทั่วภูมิภาคของประเทศ ดังนั้นการจัดทำฐานข้อมูลอุปกรณ์ไฟฟ้าในระบบสายส่งนั้นจึงมีความจำเป็นอย่างมาก งานวิจัยนี้ได้นำเสนอวิธีการปัญญาประดิษฐ์มาใช้ในการคัดแยกภาพถ่ายอุปกรณ์ไฟฟ้าที่มีความสำคัญในระบบจำหน่ายที่ถูกจัดเก็บไว้ในฐานข้อมูลได้แก่ หม้อแปลงแรงดันไฟฟ้าแบบสามเฟส หม้อแปลงแรงดันไฟฟ้าแบบสามเฟสที่มีถังน้ำมัน หม้อแปลงแรงดันไฟฟ้าแบบซิงเกิลเฟส และโหลดเบรกสวิตช์ ผู้วิจัยได้นำเทคนิค Faster-RCNN มาใช้เป็นแบบจำลองในการแยกแยะภาพถ่ายของอุปกรณ์ไฟฟ้า โดยในการสอนระบบปัญญาประดิษฐ์ได้มีการฝึกฝนตั้งแต่ 10,000 – 300,000 รอบ จากผลการทดลองพบว่าการใช้จำนวนรอบในการฝึกฝนตั้งแต่ 50,000 รอบขึ้นไปจะให้ความแม่นยำในการคัดแยกอุปกรณ์ไฟฟ้าทั้ง 4 ชนิดที่ค่าความไวและค่าจำเพาะมากกว่า 95%

คำสำคัญ : ปัญญาประดิษฐ์ ฐานข้อมูล อุปกรณ์ไฟฟ้า ระบบสายส่ง

Abstract

The maintenance of electrical equipment in the transmission line system is required to maintain the stability and efficiency of the delivery. Currently, the electricity distribution system has a large network that covers the entire region of the country. Therefore, the electrical equipment database in the transmission system is very necessary. This research proposed a method of artificial intelligence (AI) for categorized electrical types of equipment in the distribution system, including three-phase transformer, three-phase transformer with oil tank, single-phase transformer, and load brake switch. The Faster-RCNN is a technique employed to train the AI model. In the experiment, the range of training epoch was from 10,000 to 300,000 epochs. As the results, it is found that the training with over 50,000 epochs gave the accuracy of classification with sensitivity and specificity more than 95%.

Keywords: Artificial Intelligence, Database, Electrical Equipment, Transmission Line

1. บทนำ

ในระบบการจัดส่งไฟฟ้าเพื่อจำหน่ายแก่ประชาชน การซ่อมบำรุงรักษาอุปกรณ์ไฟฟ้าในระบบสายส่งมีความจำเป็นอย่างมากในรักษาเสถียรภาพและประสิทธิภาพของการจัดส่ง ในปัจจุบันระบบการจำหน่ายไฟฟ้านั้นมีโครงข่ายที่ครอบคลุมทั่วภูมิภาคของประเทศ เพราะเหตุนี้จึงชี้ให้เห็นว่ามีแนวโน้มที่อุปกรณ์ต่าง ๆ ที่อยู่ในระบบไฟฟ้าจะเพิ่มจำนวนขึ้นอย่างรวดเร็ว ทำให้ต้องมีการตรวจสอบการติดตั้งและการซ่อมบำรุงอุปกรณ์ มากขึ้น ส่งผลให้ต้องมีการเก็บข้อมูลหน้างาน ทั้งก่อนและหลังการทำงานเพิ่มขึ้น ทั้งในด้านรายละเอียดจำเพาะและภาพถ่ายเพื่อเก็บเป็นหลักฐาน ไม่ว่าจะเป็นภาพถ่ายอุปกรณ์ที่ชำรุด การติดตั้งอุปกรณ์ต่าง ๆ ซึ่งภาพถ่ายเหล่านี้จะถูกจัดเก็บรวบรวมไว้ในระบบฐานข้อมูล จำนวนภาพถ่ายอุปกรณ์ที่มีมากนั้นส่งผลให้เกิดความลำบากในการค้นหารูปภาพอุปกรณ์ไฟฟ้าชิ้นนั้น ๆ หากให้ผู้ที่ไม่มีความรู้มาทำการคัดแยก ดังนั้นเมื่อมีความต้องการใช้รูปภาพและข้อมูลของอุปกรณ์ไฟฟ้าในการวิเคราะห์และวางแผนจะต้องทำโดยวิศวกรหรือผู้เชี่ยวชาญ ทำให้สิ้นเปลืองทั้งเวลาและบุคลากรไปโดยไม่จำเป็น การนำเทคโนโลยีมาปรับใช้เพื่อความสะดวก ประหยัดเวลาในการค้นหา และเกิดศักยภาพสูงสุดนั้นสามารถทำได้หลากหลายวิธี เช่น การนำซอฟต์แวร์ Cloudera มาใช้ในการจัดเก็บข้อมูลขนาดใหญ่บนระบบปฏิบัติการ Apache Hadoop [1] หรือ การนำปัญญาประดิษฐ์ (Artificial Intelligence, AI) มาใช้ในการจำลองการทำงานต่างๆเลียนแบบขั้นตอนการทำงานของมนุษย์ เป็นต้น

งานวิจัยฉบับนี้นำเสนอการประยุกต์ใช้ปัญญาประดิษฐ์ในการคัดแยกภาพถ่ายอุปกรณ์ไฟฟ้าที่มีความสำคัญในระบบจำหน่ายกำลังไฟฟ้าที่จัดเก็บในฐานข้อมูล ได้แก่ หม้อแปลงแรงดันไฟฟ้าแบบสามเฟส หม้อแปลงแรงดันไฟฟ้าแบบสามเฟสที่มีถังน้ำมัน หม้อแปลงแรงดันไฟฟ้าแบบหนึ่งเฟส และ โหลดเบรกสวิตช์ ด้วยวิธี Faster R-CNN จากนั้นนำแบบจำลองที่ได้มาใช้ในการฝึกหัดระบบปัญญาประดิษฐ์ พร้อมกับศึกษาจำนวนรอบที่เหมาะสมในการฝึกฝนระบบตามขั้นตอนของ Machine Learning เพื่อให้ได้ผลการคัดแยกรูปภาพอุปกรณ์ไฟฟ้าที่มีความแม่นยำสูง

2. ทฤษฎีที่เกี่ยวข้อง

2.1 Faster Region-based Convolution Neural Networks (Faster R-CNN) [3]

เป็นวิธีการประยุกต์แบบจำลอง Convolution Neural Networks (CNN) ซึ่งเป็นวิธีการเรียนรู้แบบ supervised learning โดยแบบจำลอง CNN เป็นระบบที่ได้รับความนิยมในการตรวจหาวัตถุที่อยู่ในรูปภาพ โดย Faster R-CNN เป็นเทคนิคการเพิ่มความเร็วในการประมวลผลรูปภาพ ซึ่งแบ่งกระบวนการทำงานออกเป็น 2 ส่วน คือ

- การประมวลผลรูปภาพและการหาขอบเขตวัตถุในรูปภาพ เป็นการนำข้อมูลรูปภาพเข้ามาประมวลผลในกระบวนการ CNN เพื่อหาลักษณะสำคัญ (Feature extraction) ของข้อมูลรูปภาพ หรือ Feature map [3-4] โดยนำข้อมูลรูปภาพเข้าไปประมวลผลทั้งภาพ จากนั้นทำการจำแนกหาขอบเขตไหนที่น่าจะมีวัตถุอยู่ ด้วยวิธี Region proposal network (RPN) ซึ่งขอบเขตที่ RPN นำมาพิจารณา คือ ขอบเขตพื้นที่หลายๆขนาดที่ครอบคลุม Feature map ในทุกพิกเซล

- การจำแนกวัตถุที่อยู่ในรูปภาพ เริ่มต้นด้วยการปรับขนาดของขอบเขตพื้นที่หลายๆขนาดที่ถูกพิจารณาว่าเป็นขอบเขตที่น่าจะเป็นวัตถุให้มีขนาดเท่ากัน จากนั้นนำส่งข้อมูลที่ได้ออกไปทำการประมวลผลด้วยกระบวนการ CNN อีกครั้ง เพื่อทำการจำแนกวัตถุที่อยู่ในขอบเขตพื้นที่พิจารณาว่าเป็นอุปกรณ์ไฟฟ้าอะไร

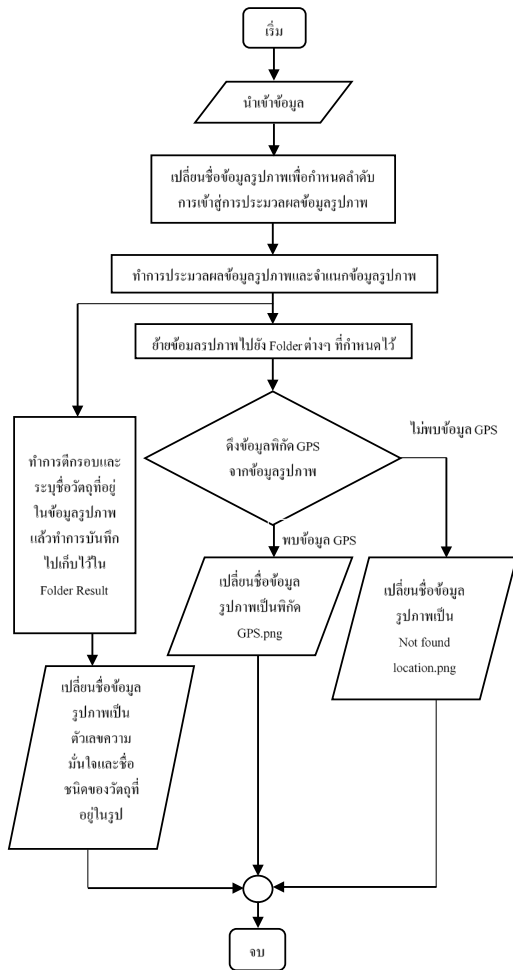
2.2 Object Detection

ขั้นตอนตรวจจับวัตถุในงานด้าน Computer vision ที่จำแนกชนิดและตรวจจับวัตถุที่ต้องการให้ตรวจจับที่อยู่ภายในรูป โดยการที่จะทำให้ระบบสามารถตรวจจับวัตถุหรือจำแนกชนิดได้นั้นต้องให้ระบบเรียนรู้และจดจำวัตถุเหล่านั้นจากการใช้ Machine Learning ซึ่งสามารถทำได้หลายวิธี ได้แก่ วาดกล่องรอบวัตถุ (Bounding Box) หรือ ถมสีให้ทุก Pixel ของวัตถุนั้น [5]

3. ระเบียบวิธีวิจัย

ในหัวข้อนี้จะกล่าวถึงรายละเอียดของการจัดเตรียมและการจัดการข้อมูลรูปภาพอุปกรณ์ไฟฟ้า 4 ชนิดที่ใช้ในการวิจัย โดยภาพรวมของกระบวนการจำแนกสามารถแสดงได้ดังรูปที่

1



รูปที่ 1 Flow chart ของการกระบวนการจำแนกอุปกรณ์


3.1 การจัดเตรียมข้อมูลรูปภาพ

ข้อมูลรูปภาพที่นำมาใช้ออกแบบระบบปัญญาประดิษฐ์ในการจำแนกอุปกรณ์ไฟฟ้า 4 ชนิด ได้แก่ หม้อแปลงแรงดันไฟฟ้าแบบเฟสเดียว หม้อแปลงไฟฟ้าแบบสามเฟส หม้อแปลงไฟฟ้าแบบสามเฟสแบบมีถังน้ำมัน และ โหลดเบรกสวิตช์ โดยมีการนำกระบวนการ Data Augmentation เช่น การบิดรูป หมุนรูป เป็นต้น มาใช้ในการเพิ่มจำนวนรูปภาพอุปกรณ์ไฟฟ้าโดยข้อมูล 1 รูป สามารถสร้างรูปภาพใหม่ที่ไม่ซ้ำกันได้ประมาณ 20 รูป ดังตัวอย่างที่แสดงในรูปที่ 2 ซึ่งมีผลทำให้ระบบปัญญาประดิษฐ์ที่ออกแบบมีประสิทธิภาพมากขึ้น

เท่านั้น หลังจากผ่านกระบวนการ Data Augmentation รูปภาพที่ใช้ในการออกแบบระบบมีจำนวนดังนี้ คือ รูปภาพของหม้อแปลงแรงดันไฟฟ้าแบบเฟสเดียวจำนวน 2,493 รูป หม้อแปลงไฟฟ้าแบบสามเฟสจำนวน 4,246 รูป หม้อแปลงไฟฟ้าแบบสามเฟสแบบมีถังน้ำมันจำนวน 5,190 รูป และ โหลดเบรกสวิตช์จำนวน 2,876 รูป จากนั้นรูปภาพทุกรูปจะถูกลดขนาดเพื่อให้มีขนาดไฟล์ไม่เกิน 300 KB ซึ่งทำให้ระบบสามารถเรียนรู้ได้เร็วและลดการทำงานของคอมพิวเตอร์

3.2 การแบ่งชุดข้อมูล [10]

ในการแบ่งชุดข้อมูลจะทำการแบ่งรูปภาพอุปกรณ์ออกเป็น 2 กลุ่ม คือ กลุ่มข้อมูลที่มีไว้สำหรับการเรียนรู้ (กลุ่ม Train) และกลุ่มข้อมูลที่มีไว้สำหรับทดสอบความแม่นยำ (กลุ่ม Test) สัดส่วนข้อมูลระหว่างกลุ่ม Train และกลุ่ม Test เท่ากับ 9 ต่อ 1 เพื่อให้ขั้นตอนการฝึกสอนมีความถูกต้อง ข้อมูลรูปภาพที่อยู่ในกลุ่ม Train จะถูกแบ่งข้อมูลไว้ใน Folder Train และ Folder Validation เพื่อให้ระบบปัญญาประดิษฐ์ที่ออกแบบสามารถแยกแยะอุปกรณ์ได้ดีขึ้นจึงมีการเพิ่มเติมรูปภาพอื่นๆเข้าไปชุดข้อมูลด้วย โดยรายละเอียดของจำนวนข้อมูลในกลุ่ม Train และกลุ่ม Test แสดงในตารางที่ 1 และตารางที่ 2 ตามลำดับ



ก) รูปต้นฉบับ



ข) รูปที่ผ่านการทำ Data Augmentation

รูปที่ 2 ตัวอย่างข้อมูลรูปภาพที่ผ่านกระบวนการ Data Augmentation

ตารางที่ 1 จำนวนข้อมูลรูปภาพในกลุ่ม Train

รูปภาพ	จำนวน	
	Folder Train	Folder Validation
หม้อแปลงเฟสเดียว	1,531	718
หม้อแปลงสามเฟส	2,649	1,185
หม้อแปลงสามเฟสแบบมีถังน้ำมัน	3,316	1,358
โหมลเบรกสวิชต์	1,787	805
ไมโครอุปกรณ์ไฟฟ้า	2,644	1,043

ตารางที่ 2 จำนวนข้อมูลรูปภาพในกลุ่ม Test

รูปภาพ	จำนวนใน Folder Test
หม้อแปลงเฟสเดียว	244
หม้อแปลงสามเฟส	412
หม้อแปลงสามเฟสแบบมีถังน้ำมัน	516
โหมลเบรกสวิชต์	284
ไมโครอุปกรณ์ไฟฟ้า	398

3.3 การติดกรอบข้อมูลรูปภาพ (Label Image)

ข้อมูลรูปภาพที่อยู่ในกลุ่ม Train ที่อยู่ใน Folder Train และ Folder Validation ทุกรูปจะถูกทำการติดกรอบ กำหนดตำแหน่ง และชนิดของอุปกรณ์ไฟฟ้าที่อยู่ภายในรูปภาพนั้นผ่านโปรแกรม LabelImg เพื่อให้ระบบปัญญาประดิษฐ์เรียนรู้และจดจำอุปกรณ์ไฟฟ้าเหล่านั้นได้ ดังตัวอย่างที่แสดงในรูปที่ 3

3.4 การฝึกสอนและทดสอบระบบ (Training and Testing)

ในการฝึกสอนระบบจะเป็นการนำข้อมูลรูปภาพในกลุ่ม Train ทั้งหมดที่ผ่านการจัดการข้อมูลเรียบร้อยแล้ว เข้าสู่การประมวลผล ซึ่งมีขั้นตอนดังนี้


- 1) จัดการข้อมูลที่ได้จากขั้นตอนการติดกรอบรูปภาพ แปลงให้เป็นชุดข้อมูลจัดเก็บไว้ใน Training folder และ Validation folder
- 2) นำข้อมูลที่ได้จากขั้นตอนก่อนหน้าเข้าสู่กระบวนการฝึกฝนระบบด้วยวิธี Faster-RCNN
- 3) ทำการฝึกฝนระบบตามจำนวนรอบที่กำหนดไว้ในแต่ละการทดลอง

ส่วนการทดสอบการจำแนกผลของแบบจำลองนั้นจะใช้ข้อมูลรูปในกลุ่ม Test ดังตารางที่ 2 เพื่อนำไปหาจำนวนรอบในการ Train ที่ให้ผลการจำแนกดีที่สุด ซึ่งจำนวนรอบที่ใช้


การฝึกฝนนั้นแบ่งเป็น 10 ค่า คือ 10,000 20,000 30,000 40,000 50,000 100,000 150,000 200,000 250,000 และ 300,000 รอบ โดยประสิทธิภาพในการคัดแยกรูปภาพจะพิจารณาจากค่าความไว (sensitivity) และค่าจำเพาะ (specificity) [6] ดังแสดงในสมการที่ (1) และ (2) ซึ่งในงานวิจัยนี้ใช้หลักเกณฑ์ความแม่นยำที่ค่าความไวและค่าจำเพาะไม่ต่ำกว่า 95%

$$Sensitivity = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (1)$$

$$Specificity = \frac{True\ Negative}{True\ Negative + False\ Positive} \quad (2)$$



↓ หลังจากการติดกรอบ



รูปที่ 3 ผลการติดกรอบรูปภาพด้วยโปรแกรม LabelImg

4. ผลการทดลอง


จากขั้นตอนการออกแบบการทดลองที่ได้กล่าวในข้างต้น เมื่อนำระบบมาทดสอบกับรูปภาพอุปกรณ์ไฟฟ้าที่จัดเตรียมไว้ ระบบจะทำการติดกรอบอุปกรณ์ไฟฟ้าที่ตรวจจับได้พร้อมแสดงเปอร์เซ็นต์ความเชื่อมั่น โดยการแยกแยะอุปกรณ์แต่ละชนิดจะใช้หลักเกณฑ์ความเชื่อมั่นต้องมีค่าไม่น้อยกว่า 60% ดังแสดงตัวอย่างผลการตรวจจับหม้อแปลงแรงดันไฟฟ้าหนึ่งเฟสที่ค่าความเชื่อมั่น 99% ในรูปที่ 4



รูปที่ 4 ผลการตรวจจับหม้อแปลงแรงดันไฟฟ้า 1 เฟส

ในกรณีที่ระบบตรวจจับอุปกรณ์ได้มากกว่า 1 ชนิด ระบบ จะทำการเลือกอุปกรณ์ที่มีผลความเชื่อมั่นสูงสุด ดังตัวอย่าง ที่แสดงในรูปที่ 5 ระบบตรวจจับอุปกรณ์ออกมาได้ 2 ชนิด คือ หม้อแปลงแรงดันไฟฟ้าสามเฟส และหม้อแปลงแรงดันไฟฟ้า สามเฟสแบบมีถังน้ำมัน ด้วยความเชื่อมั่น 95% และ 99% ตามลำดับ ดังนั้นระบบจึงคัดแยกอุปกรณ์ดังกล่าวเป็นหม้อแปลง แรงดันไฟฟ้าสามเฟสแบบมีถังน้ำมัน


ผลการทดสอบรูปภาพทั้งหมดกับระบบที่ผ่านการฝึกฝน ด้วยจำนวนรอบทั้ง 10 ค่า แสดงในรูปที่ 6 พบว่าค่าจำเพาะใน การตรวจจับอุปกรณ์ไฟฟ้าจะมีค่าสูงกว่า 95 % ในทุกจำนวน รอบของการฝึกฝน และค่าความไวของการคัดแยกอุปกรณ์จะมีค่าเพิ่มขึ้นตามจำนวนรอบและสูงเข้าเมื่อจำนวนรอบมีค่า มากกว่า 50,000 รอบ ยกเว้นรูปภาพหม้อแปลงแรงดันไฟฟ้า แบบสามเฟสแบบมีถังน้ำมันที่มีค่าความไวมากกว่า 95% ใน ทุกจำนวนรอบของการฝึกฝน แต่มีค่าจำเพาะน้อยกว่า 95% เมื่อจำนวนรอบน้อยกว่า 50,000 รอบ โดยมีสาเหตุจากรูปภาพ ของหม้อแปลงแรงดันไฟฟ้าแบบสามเฟสแบบมีถังน้ำมันมี ส่วนที่คล้ายหม้อแปลงแรงดันไฟฟ้าแบบสามเฟส ก่อนข้างมากดังแสดงในรูปที่ 5 ซึ่งมีค่าความเชื่อมั่นในการคัด แยกใกล้เคียงกัน ดังนั้นทำให้เกิดโอกาสในการทำนาย ผิดพลาดระหว่าง 2 อุปกรณ์ก่อนข้างสูงหากระบบได้รับการ ฝึกฝนด้วยจำนวนรอบที่น้อยเกินไป




รูปที่ 5 ตัวอย่างผลการตรวจจับอุปกรณ์ได้มากกว่า 1 ชนิด

5. สรุปผล


งานวิจัยนี้ทำการพัฒนาระบบปัญญาประดิษฐ์เพื่อใช้คัด แยกอุปกรณ์ไฟฟ้าที่สำคัญในระบบจำหน่ายไฟฟ้า ได้แก่ หม้อแปลงแรงดันไฟฟ้าแบบสามเฟส หม้อแปลง แรงดันไฟฟ้าแบบสามเฟสแบบมีถังน้ำมัน หม้อแปลง แรงดันไฟฟ้าแบบหนึ่งเฟส โหลดเบรกสวิตช์ โดยใช้ แบบจำลอง Faster R-CNN มาใช้ในการคัดแยกอุปกรณ์ซึ่ง วิธีการ Faster R-CNN เป็นวิธีการที่ได้รับความนิยมอย่าง แพร่หลายในการคัดแยกภาพถ่าย โดยบทความนี้ได้ศึกษา จำนวนรอบในการฝึกฝนระบบเพื่อให้ผลการคัดแยก รูปภาพมีความถูกต้องที่ค่า Sensitivity และ Specificity ไม่น้อยกว่า 95% จากการทดลองพบว่าการฝึกฝนระบบที่ จำนวนรอบมากกว่าหรือเท่ากับ 50,000 รอบ สามารถให้ผล การทดสอบตามที่กำหนดไว้ ผลจากระบบปัญญาประดิษฐ์ ที่ได้สามารถนำไปพัฒนาระบบฐานข้อมูลร่วมกับข้อมูล พิกัดตำแหน่งของอุปกรณ์ไฟฟ้าในการติดตาม ค้นหาและ วางแผนการซ่อมบำรุง ทำให้เกิดความสะดวกรวดเร็ว ในการทำงาน สร้างความมั่นใจให้กับระบบส่งจ่ายไฟฟ้า




ก) หม้อแปลงแรงดันไฟฟ้า 1 เฟส



ข) หม้อแปลงแรงดันไฟฟ้าสามเฟส



ค) หม้อแปลงแรงดันไฟฟ้าสามเฟสแบบมีถังน้ำมัน



ง) โหลดเบรกสวิตช์

รูปที่ 6 ผลการทดสอบการคัดแยกอุปกรณ์ไฟฟ้า

เอกสารอ้างอิง

[1] Krish Krishnan. Infrastructure and technology, Building Big Data Applications. Academic Press; 2020.

[2] Oliver Theobald. Machine Learning for Absolute Beginners: A Plain English Introduction. 2nd ed. Amazon Digital Services LLC.

[3] J. Redmon, S. K. Divvala, R. B. Girshick and A. Farhadi, "You Only Look Once: Unified Real-Time Object Detection", Computer Vision and Pattern Recognition, pp. 779-788, 2016.

[4] Yu Peng Chen, Ying Li, Gang Wang. An Enhanced Region Proposal Network for object detection using deep learning method. PLOS ONE 13(9): e0203897. <https://doi.org/10.1371/journal.pone.0203897>

[5] Navneet Dalal and Bill. Triggs, "Histograms of oriented gradients for human detection", Computer Vision and Pattern Recognition, pp. 886-893, 2005.

[6] Abdul Ghaaliq Lalkhen, MB ChB FRCA, Anthony McCluskey, BSc MB ChB FRCA. Clinical tests: sensitivity and specificity. Continuing Education in Anaesthesia Critical Care & Pain. 2008; 8(6): 221-223.

[7] Xiu Li, Min Shang, H. Qin and Liansheng Chen, "Fast accurate fish detection and recognition of underwater images with Fast R-CNN," OCEANS 2015 - MTS/IEEE Washington, Washington, DC, 2015, pp. 1-5, doi: 10.23919/OCEANS.2015.7404464.

[8] S. Hsu, Y. Wang and C. Huang, "Human Object Identification for Human-Robot Interaction by Using Fast R-CNN," 2018 Second IEEE International Conference on

- Robotic Computing (IRC), Laguna Hills, CA, 2018, pp. 201-204, doi: 10.1109/IRC.2018.00043.
- [9] S. Hsu, C. Huang and C. Chuang, "Vehicle detection using simplified fast R-CNN," 2018 International Workshop on Advanced Image Technology (IWAIT), Chiang Mai, 2018, pp. 1-3, doi: 10.1109/IWAIT.2018.8369767.
- [10] Watson J.N., Uchaipichat N., Addison P.S., Clegg G.R., Robertson C.E., Eftestol T., and Steen P.A., "Improved prediction of defibrillation success for out-of-hospital VF cardiac arrest using wavelet transform methods", Resuscitation, Vol. 63, pp. 269-275, 2004.