

<http://dx.doi.org/10.17703/JCCT.2023.9.5.737>

JCCT 2022-9-89

열화상 영상 데이터 기반 배전반 화재 발생 판별을 위한 딥러닝 모델 설계

Design of a deep learning model to determine fire occurrence in distribution switchboard using thermal imaging data

박동준*, 김민영**

Dongjoon Park*, Minyoung Kim**

요약 본 논문은 열화상 이미지를 활용하여 배전반 화재 발생을 감지하기 위한 인공지능 모델을 개발하는 연구에 대해 다룬다. 연구의 목표는 수집한 열화상 이미지를 전처리하여 객체 탐지 모델에 적합한 데이터로 가공하고, 이를 이용하여 배전반 내 화재 발생 여부를 판단하는 모델을 설계하는 것이다. 연구에서는 AI-HUB의 산업단지 내 학습용 열화상 이미지 데이터를 활용하였으며, CNN 기반 딥러닝 객체 검출 알고리즘 중 대표적인 모델인 Faster R-CNN과 RetinaNet을 사용하여 모델을 구축하고 두 개의 모델을 비교 분석하여 최적의 모델을 제안하고 있다.

주요어 : 배전반, 열화상 영상, 화재 감지, Faster R-CNN, RetinaNet

Abstract This paper discusses a study on developing an artificial intelligence model to detect incidents of fires in distribution switchboard using thermal images. The objective of the research is to preprocess collected thermal images into suitable data for object detection models and design a model capable of determining the occurrence of fires within distribution panels. The study utilizes thermal image data from AI-HUB's industrial complex for training. Two CNN-based deep learning object detection algorithms, namely Faster R-CNN and RetinaNet, are employed to construct models. The paper compares and analyzes these two models, ultimately proposing the optimal model for the task.

Key words : Distribution Switchboard, Thermal imaging, Fire detection, Faster R-CNN, RetinaNet

1. 서론

소방청 국가화재정보시스템의 화재통계 자료에 따르면 2022년 한 해 동안 발화 지점이 가장 높았던 곳은 설비 또는 저장공간의 화재이다. 특히 보일러실을 제외한 대부분의 화재는 전기적 단락으로 발생한다. 이러한

전기화재는 현재 우리나라에 매우 많이 발생하고 있다. (그림 1)은 국가화재정보시스템의 발화 시점 중 설비와 저장공간의 화재 건수를 나타내는 그래프이다[1].

배전반은 주로 빌딩이나 공장 등의 대형 시설에서 전력 회사에서 보내오는 고압의 전기를 받을 수 있는 시설이다. 이 배전반이 전기화재의 원인 중 가장 높은

*정회원, 동의대학교 ICT융복합연구소 연구원 (제1저자)
**정회원, 동의대학교 ICT융복합연구소 조교수 (교신저자)
접수일: 2023년 8월 22일, 수정완료일: 2023년 8월 31일
게재확정일: 2023년 9월 5일

Received: August 22, 2023 / Revised: August 31, 2023
Accepted: September 5, 2023
*Corresponding Author: kmyco@deu.ac.kr
Research Institute of ICT Fusion and Convergence, Dong-eui Univ., Republic of Korea

비율을 차지하고 있다. 대형 시설에서 사용하다 보니 화재 발생 시 인명, 재산 피해도 크다. 전기화재의 가장 큰 비율을 차지하는 배전반 화재를 예방할 수 있다면 우리나라 화재 피해를 많이 감소시킬 것이라 볼 수 있다.




그림 1. 시설 그리고 저장공간의 발화지점 화재 건수
Figure 1. Number of hot topics related to ignition points in facilities and storage spaces

본 논문에서는 위에서 언급한 내용을 배전반의 열화상 이미지 데이터와 객체 인식 인공지능을 활용하여 배전반 화재 발생 관별을 위한 인공지능 모델을 설계하였다.

II. 관련 연구

1. 열화상 기술

열화상 카메라는 적외선 영역의 에너지를 감지하여 물체의 온도를 정확하게 측정하고 이를 시각적으로 나타내는 고급 기술이다. 이러한 카메라는 물체의 온도 변화를 미세하게 감지하고 이를 전기 신호로 변환하여 열화상 이미지를 생성한다. 이러한 이미지는 물체의 온도 분포를 명확하게 시각화하여 운영자나 기술자가 눈으로 확인할 수 있게 도와준다.

일반적으로, 부품 또는 시설의 잠재적인 문제나 화재 발생 전에 온도 변화가 발생한다. 그러나 이러한 변화는 종종 미세하거나 눈에 띄지 않아서 시각적으로 확인하기 어렵다. 여기서 열화상 카메라가 그 임무를 수행한다. 이 카메라는 물체의 표면 온도를 실시간으로 기록하고, 이전의 온도와 비교하여 어떤 부분에서 온도 변화가 발생하는지 빠르게 감지할 수 있다.

또한, 열화상 카메라는 비접촉식 검사에 이상적이다.

예를 들어, 배전반과 같은 고전압 시설에서는 연결 부식, 단락 등의 문제가 발생할 수 있으며, 이를 해결하기 위해 접촉식으로 접근하는 것은 매우 위험하다. 하지만 열화상 카메라를 사용하면 비접촉식 검사를 통해 시설의 안전성을 확보할 수 있다. 이 기술을 활용하면 고전압 시설에서도 안전하게 문제를 진단하고, 물체의 온도 분포를 실시간으로 확인할 수 있어 예방 조치를 빠르게 취할 수 있다[2].

김순식[3]과 이형근[4]은 배전설비의 열화상 이미지 데이터와 이미지 분석 알고리즘을 활용하여 객체를 검출하고 배전설비의 안정성을 공정능력지수를 통해 판단하는 시스템을 개발하는 연구를 진행하였다. 인공지능 알고리즘인 YOLO를 사용하여 객체를 특정하고 검출된 객체의 온도를 추출하여 공정능력지수를 도출해 내 배전설비의 안정성을 판단하였다. 해당 연구를 통해 열화상 카메라만을 활용하여 배전설비의 안전상태를 효율적으로 판단할 수 있다는 것을 증명하였다[3-4].

본 논문에서 역시 화재 발생 전의 미세한 온도 변화를 빠르게 감지하고, 작업자의 안전을 고려하여 열화상 카메라로 얻은 열화상 이미지를 배전반 화재관별 시스템의 데이터 세트로 선정했다. 이형근 등의 논문에서는 공정능력지수를 활용하여 안전성을 판단해왔다면, 본 논문에서는 열화상 이미지의 색조 변화를 객체 검출 인공지능 알고리즘을 활용하여 검출해 배전반의 안전성을 판단하는 시스템을 연구해보려고 한다. 이를 통해 안정성과 정확성을 결합한 화재 예방 시스템을 구축하고, 산업 시설의 안전성을 향상하는 데 이바지하고자 한다.

2. 딥러닝 인공지능 알고리즘

1) Faster R-CNN

Faster R-CNN은 기존의 R-CNN과 Fast R-CNN의 성능을 개선한 CNN 기반 대표적인 딥러닝 객체 검출 알고리즘이다. Faster R-CNN의 핵심 아이디어는 Region Proposal Network (RPN)과 앵커박스이다. 기존의 Fast R-CNN 구조를 그대로 계승하면서 후보 영역 검출을 위해 원래 사용했었던 Selective Search 기법을 제거하고 RPN을 통해서 Roi를 계산하게 된다. RPN에서 Region Proposals를 더 정교하게 추출하기 위해 다양한 크기와 가로세로비를 가지는 박스 형태인 앵커 박스를 사용하게 된다. 앵커 박스는 슬라이딩 윈도우 방

식으로 움직이며, 사전에 크기와 비율, 개수를 정의한다. Faster R-CNN은 RPN을 통해 Region proposals를 추출하고 이를 계승한 Fast R-CNN 네트워크에 전달하여 객체의 클래스와 위치를 예측한다. 이를 통해 모델 전체가 GPU 상에서 동작하여 동시에 계산이 가능하게 되면서 속도도 증가하고 정확도 역시 증가하게 되었다. (그림 2)는 Faster R-CNN의 구조이다[5-6].




그림 2. Faster R-CNN 아키텍처
 Figure 2. Faster R-CNN Architecture

객체 검출 알고리즘은 Faster R-CNN 외에도 다양한 알고리즘이 있으며 가장 많이 비교되는 대표적인 알고리즘은 YOLO가 있다. 이용환 등은 객체 검출을 위해 CNN 기반 알고리즘과 YOLO 알고리즘의 성능을 비교하는 연구를 진행하였다. 공용적으로 활용되는 PASCAL VOC 데이터 셋과 COCO 데이터 셋을 통해 학습을 수행하였고 평가 지표로 mAP와 처리 속도를 사용하였다[5-6].

연구 결과 Faster R-CNN이 YOLO에 비해 높은 정확도를 보였으나 속도 측면에서는 성능이 떨어지는 것을 볼 수 있었다. 본 논문에서는 배진반의 화재 상황을 보다 정확하고 확실하게 판단하기 위해 처리 속도보다는 정확도에 더 강점이 있는 Faster R-CNN을 객체 검출 모델로 선정하였다.

1) RetinaNet[7]

RetinaNet은 YOLO와 함께 1-stage 객체 탐지 모델 중에서 주목되고 있는 모델 중 하나로 꼽힌다. 이 모델은 이전 1-stage 탐지 모델의 낮은 정확도 문제를 해결하기 위해 Focal Loss와 Feature Pyramid Network

(FPN)이라는 두 가지 기술을 활용한다.

Focal Loss는 클래스 불균형 문제를 대응하기 위해 개발된 새로운 손실 함수이다. 기존의 손실 함수는 Cross Entropy loss라는 손실함수가 있었고 해당 함수는 모든 샘플에 대한 예측 결과를 동등하게 가중치를 두었다. Cross Entropy Loss의 수식은 아래와 같다.

$$CE(p, y) = \begin{cases} -\log(p), & \text{if } y = 1 \\ -\log(1-p), & \text{otherwise} \end{cases}$$

$$pt = \begin{cases} p, & \text{if } y = 1 \\ 1-p, & \text{otherwise} \end{cases}$$

이에 따라 샘플이 쉽게 분류될 수 있음에도 불구하고 작지 않은 loss를 유발하게 되었다. 또한 샘플의 균형 맞지 않으면 많은 쪽의 sample의 loss가 압도적으로 많아지며 불균형이 더 심해지는 문제가 있었다.

이에 Tsung-Yi Lin 등은 easy 샘플의 영향을 줄이고 hard negative 샘플에 집중하여 학습하는 손실함수인 Focal Loss를 만들어냈다. 기존의 교차 엔트로피 함수에 변동 인자 $(1-pt)^\gamma$ 와 조정 가능한 집중 파라미터 γ 를 추가한 형태를 가진다.

$$FL(p_i) = -(1-p_i)^\gamma \log(p_i)$$

이를 통해 Focal Loss의 두 가지 특성을 확인할 수 있다.

첫 번째는 예측값과 변동 인자와의 관계이다. 샘플이 잘못 분류되고 예측값이 작아지면 변동인자는 1과 가까워지며, loss의 영향을 받지 않는다. 반대로 pt 값이 크면 변동 인자는 0에 가까워지고, 잘 분류된 샘플의 loss의 영향을 감소시킨다.

두 번째는 집중파라미터 γ 의 역할이다. 집중 파라미터는 예측하기 쉬운 샘플의 영향을 감소시키는 정도를 부드럽게 조정한다. $\gamma=0$ 인 경우, Focal loss는 crossentropy와 같으며, γ 가 상승할수록 변동 인자의 영향력이 커지게 된다. Tsung-Yi Lin 등은 $\gamma=2$ 일 때 가장 좋은 결과를 보였다고 했다.

다시 정리하면 변동인자는 예측하기 쉬운 샘플의 기여도를 줄이고 샘플이 작은 loss를 받는 범위를 확장시킨다. 이로 인해 모델은 예측하기 쉬운 샘플이나 이미 잘 분류된 샘플의 손실에 덜 민감해지며, 예측이 어려

운 작은 객체와 같은 어려운 샘플의 손실을 확대시켜 클래스 불균형 문제를 해결한다.

또한, RetinaNet은 서로 다른 크기의 객체를 효과적으로 감지하기 위해 기존의 FPN을 확장한 형태를 사용한다. 이러한 확장된 FPN은 upsampling 및 top-down 접근법을 결합하여 객체를 다양한 크기로 효율적으로 인식한다. 이러한 기술들의 조합으로 RetinaNet은 작은 객체를 예측하는 데 뛰어난 성능을 보이며, 정확도 면에서 다른 1-stage 탐지 모델인 YOLO나 SSD보다 우수하다. (그림 3)은 RetinaNet의 구조이다.




그림 3. RetinaNet 아키텍처
Figure 3. RetinaNet Architecture

(그림 4)는 RetinaNet 논문에서 COCO 데이터 세트에 대한 Average Precision (AP)와 시간을 나타내는 그래프이다. 이를 통해 RetinaNet이 YOLO와 SSD에 비해 속도는 다소 느리지만 훨씬 높은 정확도를 제공한다는 것을 확인할 수 있다. 또한 2-stage detector인 Faster R-CNN 보다는 속도 측면이나 정확도 측면 모두 성능이 높은 것을 확인할 수 있다[8].




그림 4. COCO Dataset을 이용한 성능 평가(속도, 정확성)
Figure 4. Performance evaluation (speed, accuracy) using COCO Dataset

RetinaNet은 배전반이 고정된 물체를 탐지하고 화재 상황을 정확하게 판단하기 위한 연구에 적합하다. 또한, 해당 연구에서 사용되는 열화상 이미지에서 배전반 객체의 크기가 작고 다양하므로 작은 객체를 효과적으로

탐지할 수 있는 RetinaNet을 선택했다.

III. 딥러닝 인공지능 모델 설계

1. 데이터 수집

배전반의 이상 현상을 판별하기 위한 시스템을 만들기 위해 배전반이 포함되어 있는 열화상 이미지를 수집한다. 본 논문에서는 AI-HUB에서 제공하는 '산업단지 내 다양한 객체들에 대한 학습용 열화상 이미지 데이터'[9]를 사용하였다. 해당 데이터 세트 중에서 배전반을 대상으로 한 열화상 이미지 데이터와 라벨링 데이터를 다운받아 사용하였다. 데이터는 정상상황 약 76,000장, 이상 상황 약 26,000장 총 10,000장이며 크기는 (640,480)이다. 데이터 세트의 구성이 열화상 카메라로 여러 군데의 공장에 있는 배전반을 시간대별로 촬영하고 그 영상을 프레임 단위로 잘라 이미지로 구현된 것이기 때문에 시간대별로 사진들을 선별하여 사용하였다.

배전반은 사각형의 외함만으로 정의하였으며, 선별하는 과정에서 배전반의 형태가 명확하지 않거나 배경과 배전반의 경계면이 불명확한 사진은 제외하였으며, 해상도가 낮아 판단할 수 없는 사진도 제외하였다. (그림 5)는 제외된 이미지 파일의 예시들이다.




그림 5. 제외된 이미지 데이터 사례
Figure 5. Example of excluded image data

해당 기준을 통해서 정상상황 이미지 2500장, 이상상황 이미지 2500장, 총 5000장을 선별하여 학습 데이터로 사용하였다.

데이터를 선별한 후 해당 이미지에서 객체인 배전반을 인식하기 위한 라벨링 작업을 진행하였다. 라벨링

작업은 (표 1)의 기준에 따라서 라벨링 작업이 진행되었다. 클래스는 총 2가지이며 평소 상태인 정상 상황과 화재 발생을 뜻하는 이상 상황으로 분류하였다.

표 1. 데이터 라벨링 기준
 Table 1. Data labeling criteria

	정상 상황	이상 상황
공통 기준	1. 열화상 이미지 식별이 가능한가 2. 객체가 명확하게 확인되는가 3. 배전반은 외함만으로 정의 4. 열반사에 의한 객체는 제외 5. 타객체와 겹침 최소화 6. 배전반과 배경의 경계면 구분	
개별 기준	1. 배전반 외형에 온도변화에 의한 색조 차이가 없는 경우	1. 고온이 발생하여 배전반 내부에 색조 차이가 생긴 경우 2. 고온이 발생하는 부분을 모두 포함하는 경우

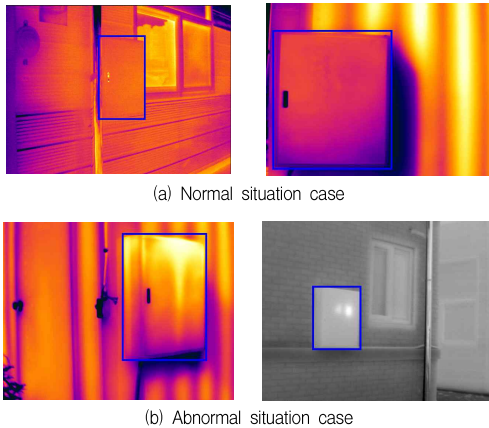


그림 6. 라벨링한 이미지 샘플
 Figure 6. Labeled image samples

앞서 말했다시피 배전반은 사각형 형태의 외함만으로 정의하였고, 사각형 형태인 배전반의 경계면을 구분하여 명확하게 확인할 수 있게 라벨링 하였다. 또한 배전반 형태를 모두 포함하되 타 객체와의 겹침을 최소화하여 라벨링 하였다.

열화상 이미지는 온도 변화에 따라서 색조의 차이가 발생한다. 과전류나 단락 등의 이유로 화재가 발생하면 배전반 내부의 온도가 올라가게 되고 열화상 이미지 역시 그 부분의 색조가 배경 색조와 다르게 나타나게 된다. 이를 통해서 라벨링한 배전반의 외형 안에 온도 변

화로 인한 색조 차이가 없고 같은 색조를 띄는 경우를 정상 상황으로 정의하였다. 반대로 화재가 발생하여 배전반 외형 안에 색조 차이가 생겼을 경우를 이상 상황으로 정의하였으며, 이상 상황을 라벨링 할 때 고온으로 인한 색조 차이가 발생한 부분을 모두 포함할 수 있게 라벨링 작업을 수행하였다.

(그림 6)은 라벨링 기준을 따라 라벨링 한 이미지 데이터의 예시이다. 해당 사진에서 볼 수 있듯이 정상 상황에서는 배전반 전체에 색조 차이가 나타나지 않고 일정하다. 하지만 이상 상황으로 판단된 배전반 같은 경우에는 예시 사진 1의 배전반 상단이나 사진 2의 배전반 중간처럼 고온이 발생한 부분이 흰색으로 드러나 있는 것을 볼 수 있다. 이렇게 객체 이미지가 명확한 데이터를 선별하고 라벨링을 통해 클래스 분류 작업을 완료하여 학습 데이터 세트를 만들었다.

2. 딥러닝 기반 객체 판별 모델

앞서 설명한 Faster R-CNN과 RetinaNet을 활용하여 열화상 이미지 데이터에서 배전반의 상태를 판별하는 모델을 만들려고 한다. 정확도가 우수한 Faster R-CNN과 RetinaNet을 사용함으로써, 배전반의 화재 상황 검출의 정확도 및 신뢰도를 높이려고 한다.

1) Faster R-CNN

이미지에서 특징을 뽑아내는 CNN 모델로는 VGG16을 선정하였다. (그림 7)은 배전반의 이상 현상을 판별하기 위한 Faster R-CNN 기반 모델의 진행 흐름을 나타낸다.

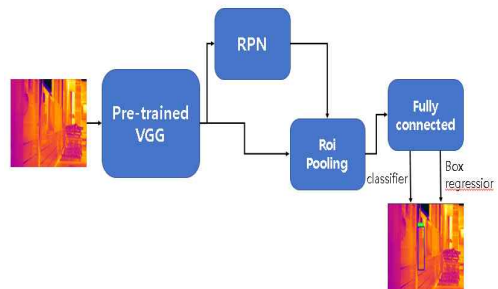


그림 7. Faster R-CNN 기반 모델 진행 흐름
 Figure 7. Faster R-CNN based model progress flowchart

시스템 훈련 시 열화상 이미지 데이터와 박스 좌표 정보를 입력받는다. 입력받은 열화상 이미지 데이터는

선정된 CNN 모델을 통해 특징 맵을 추출한다. 추출된 특징 맵은 RPN을 통해 앵커 박스에 대한 2개의 층으로 나뉘는데 박스 좌표 안에 검출된 사물이 맞는지 아닌지 판단하는 분류 층과 박스의 좌표를 찾아내는 회귀 층으로 나뉘게 된다. Region proposals를 추출하기에 앞서 언급했던 원본 이미지에 대한 앵커 박스를 생성하는 과정을 거친다. 각 셀에 앵커 박스를 각각 3개의 다른 크기와 다른 중첩비로 조합하여 9개의 박스로 구성한다. 이때 구성된 앵커 박스값과 실제 박스값을 비교하여 IOU(Intersection over Union)가 0.7 이상인 박스와 0.3 이하인 박스를 positive와 negative sample로 나누어 선정한다.

선정된 앵커 박스와 RPN에서 나온 두 개의 층을 사용하여 Region proposals를 추출한다. 분류 층에서 얻은 값을 높은 순으로 정렬한 다음 정해진 개수의 앵커만 추려낸다. 추려낸 앵커들과 실제 박스를 비교한 IOU 값이 0.5 이상인 경우 positive, 0.1~0.5 사이일 경우 negative sample로 라벨링 한다. 이 과정을 통해 얻은 sample을 앞서 추출한 특징 맵과 함께 사용하여 Roi Pooling을 수행한다. 이를 통해 추출된 고정된 크기의 특징 맵을 Fully Connected 층과 앞서 출력된 분류 층과 회귀 층을 통해 새로운 분류 층과 회귀 층으로 나누어 출력한다. 추출된 분류 층은 객체를 판별하게 되고 회귀 층에서 추출된 데이터로 객체의 위치를 파악하게 된다. 이렇게 훈련이 완료된 모델은 열화상 이미지 내의 예측된 배전반의 상태와 객체가 포함될 확률이 가장 높은 영역의 좌표를 출력한다.

2) RetinaNet

(그림 8)는 배전반의 이상 현상을 판별하기 위한 RetinaNet 기반 모델의 진행흐름을 나타낸다.

RetinaNet은 특징맵을 추출하는 CNN 모델로 ResNet50을 사용한다. ResNet에서 추출한 특성맵에서 Input image의 1/8, 1/16, 1/32/의 크기를가지는 c3, c4 c5의 특성을 뽑아내어 FPN으로 보내진다. 이 때의 채널수는 각각 512, 1024, 2048개이다.

FPN에서는 top-down pathway를 통해 ResNet으로부터 전달받은 각각의 특성맵에 1x1 합성곱 연산을 적용하여 모두 256채널을 가지도록 조정한 후 upsampling을 수행한다. 마지막으로 lateral connections 과정을 통해 pyramid level 바로 아래있는

특성 맵과 element-wise addition 연산을 수행하고 이를 통해 얻은 5개의 다른 특성 맵에 다시 한번 3x3 합성곱 연산을 적용한다. 생성된 5개의 피라미드 특성 맵은 바운딩 박스를 특징하는 박스 헤드와 클래스를 특징하는 분류 헤드로 나뉘어서 각각 들어가게 된다. 각각 들어간 5개의 피라미드 특성맵은 각각 헤드를 거쳐 Faster R-CNN과 동일하게 3개의 크기와 3개의 중첩비를 가진 9개의 앵커 형태로 나타나게 된다. 분류 헤드를 통해 객체의 클래스를 파악하게 될 것이고, 박스 헤드를 통해 해당 객체의 위치를 특정할 수 있게 된다. 최종적으로 계층별로 나온 피라미드 특성 맵을 이어 붙여 해당 객체의 최적 위치를 찾아낸다.

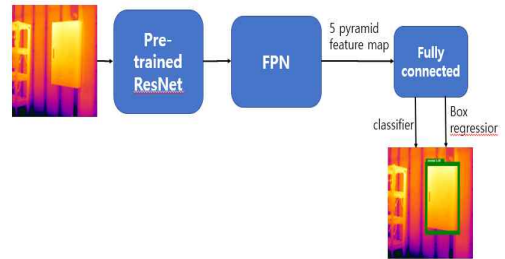


그림 8. RetinaNet 기반 모델 진행 흐름
Figure 8. RetinaNet based model progress flowchart

IV. 구현 및 결과

선별한 학습데이터와 인공지능 모델을 통해 학습을 진행하고 검증 결과를 비교해본다.

배전반 화재판별을 위한 모델의 Faster R-CNN과 RetinaNet 학습 테스트 설계 구현을 위한 컴퓨터 사양은 아래와 같다.

- CPU: Intel core i7-12700
- RAM: 64GB
- GPU : Nvidia Tesla P40 24GB,
- O/S : Window 10 Pro
- Nvidia CUDA : v11.6
- Nvidia cuDNN: 8.7
- PyTorch : v1.13.1

인공지능 모델의 구현을 위해 Faster R-CNN과

RetinaNet 모델을 활용해 성능을 비교해보았다.

인공지능 모델은 Faster R-CNN과 RetinaNet을 사용하였으며, Batch size는 4로 고정하였고, 이미지 사이즈는 원본 이미지 사이즈인 (640,480)으로 지정하였다. 객체를 판단하기 위한 임계값(threshold)은 실험 결과의 신뢰도를 좀 더 높이기 위해 0.8로 지정하였다. 에폭수는 Faster R-CNN과 RetinaNet 각각 100, 200, 300 에폭으로 차이를 뒤서 학습을 시키고 결과값을 비교하였다. 배전반은 고정된 물체이기 때문에 기존의 데이터 세트에서 학습데이터 세트를 제외한 나머지 열화상 이미지에서 추출하여 사용해도 무방하다고 판단하여 해당 데이터 세트로 검증을 진행하였다. 각각 검증에 사용된 사진은 정상상황 100장, 이상상황 100장으로 총 200장의 이미지 데이터를 검증에 사용하였다. (표 2)은 위의 내용들을 표로 정리하여 나타낸 것이다.

표 2. 각 모델 학습 과정 분류표
 Table 2. Classification of each model learning process


Case No.	Model	Epochs	Image size
1	Faster R-CNN	100	(640,480)
2		200	
3		300	
4	RetinaNet	100	
5		200	
6		300	

(그림 9)와 (그림 10)은 (표 2)의 학습과정 분류표에 분류된 모델별로 학습한 후 나타난 loss 그래프이고 (표 3)과 (그림 11)은 각각의 모델이 임계값 이상에서 검증을 수행하여 객체를 식별해낸 비율과 예시 사진을 나타낸 표이다.


Faster R-CNN 같은 경우에는 loss가 0.002이하까지 떨어지는 것을 볼 수가 있었고, RetinaNet 같은 경우에는 loss가 0.0005이하까지 떨어지는 것을 볼 수가 있었다. 그래프 모양도 RetinaNet이 Faster R-CNN에 비해 완만한 경사의 그래프를 그리는 것을 보아 RetinaNet의 성능이 좀 더 나은 것을 확인할 수 있다.

Faster R-CNN 같은 경우에는 이상 상황에 대해서는 정확도가 98퍼센트 이상 나오며 잘 검출해 내는 것을 확인할 수 있었지만 정상 상황 이미지 데이터에 대


해서는 전혀 검출해내지 못하는 것을 볼 수 있다. 하지만 RetinaNet 같은 경우에는 정상 상황과 이상 상황 이미지 데이터 모두 정확도가 98퍼센트 이상 나오며 명확하게 검출해 내는 것을 확인할 수 있었다. 그 중에서도 case6인 300epoch 학습시킨 모델 같은 경우에는 정확도가 99~100퍼센트에 달하는 것을 볼 수 있으며 이 모델이 가장 정확한 모델인 것을 알 수 있다.



(a) epoch 100



(b) epoch 200



(c) epoch 300

그림 9. Faster R-CNN 학습 결과
 Figure 9. Faster R-CNN learning results

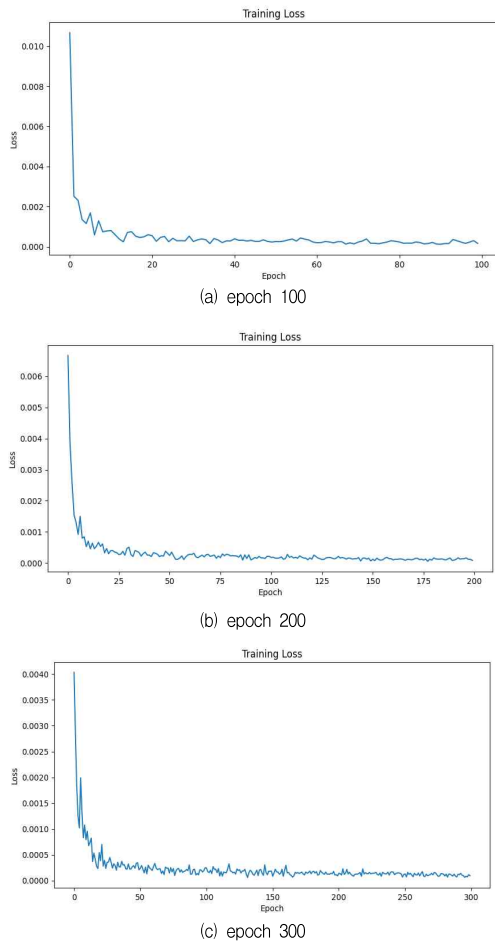


그림 10. RetinaNet 학습 결과
Figure 10. Faster R-CNN learning results

표 3. 각 클래스별 검증된 비율
Table 3. Simulation Parameters

Case No.	정상 상황	이상 상황
1	0.05	0.34
2	0.10	0.94
3	0.10	0.98
4	0.95	0.97
5	0.95	0.99
6	1.00	1.00

Case No.	Normal	Abnormal
1		
2		
3		
4		
5		
6		

그림 11. 각 클래스별 검출된 결과 이미지
Figure 11. Detected result images by class

V. 결론

본 논문에서는 열화상 데이터와 CNN 기반 객체 탐지 모델을 이용하여 배전반의 화재 발생 가능성을 판별하고 예측하는 인공지능 모델을 설계하고 제안한다. 본 논문에서는 객체 탐지 모델로 Faster R-CNN과 RetinaNet을 활용하여 설계하고 결과를 비교 분석하였다. 분석 결과 Faster R-CNN과 RetinaNet 모두 학습 과정에서 굉장히 낮은 loss율을 보이며 학습을 성공적으로 마쳤다. 하지만 검증 데이터 세트로 검증하는 과정에서 두 모델 모두 화재가 발생한 이상 상황에서는 객체 검출을 잘 수행했으나, 정상 상황에서 RetinaNet은 객체 검출을 잘 되었지만, Faster R-CNN은 객체 검출을 제대로 수행하지 못하였다. 또한 Epoch에 따라서 정확도가 점점 높아진 것을 확인할 수 있었다.

이를 적용하여 화재가 발생하기 전에 화재 가능성을

관별하고 알려줌으로써 화재를 사전에 방지할 수 있을 것이다. 이를 통해 화재가 발생함으로써 인해 생길 수 있는 인명피해나 재산 피해를 최소한으로 줄일 수 있을 것이라 기대한다. 추후 배전반뿐만 아니라 저장탱크나 공장 내부 시스템 등과 같은 산업 시설 내에 존재하는 다양한 객체들의 데이터를 학습시켜 산업 시설에서 일어날 수 있는 각종 재난과 안전사고를 감지하는 서비스를 제공할 수 있는 시스템을 구현할 계획이다.

Detection,” Journal of the Semiconductor & Display Technology, Vol. 19, No.1, pp. 85-92, March 2020.

[9]AI Hub, Disaster Safety Environment, Thermal mager image [Internet], Available : <https://aihub.or.kr>

References

- [1]National Fire Data System, fire statistics [Internet], Available : <https://nfds.go.kr/stat/general.do>
- [2]Deepak Kumar and M.A.Ansari, “Condition monitoring of eletrical assets using digital IRT and AI technique,” Journal of Electrical Systems and information Technology, Vol. 5, No.3, pp. 623-634, Dec. 2018.
(DOI: <https://doi.org/10.1016/j.jesit.2017.10.001>)
- [3]Joo-Sik Kim, Kyu-Nam Choi, Hyung-Geun Lee and Sung-Woo Kang, “Detection and Diagnosis of Power Distribution Supply Facilities Using Thermal Images,” Journal of the Korea Safety Management & Science, Vol. 22, No.1, pp. 1-8, March 2020.
(DOI : <http://dx.doi.org/10.12812/ksms.2020.22.1.001>)
- [4]Hyung-Geun Lee, Yong-Min Hong, Sung-Woo Kang, “Identifying Process Capability Index for Electricity Distribution System through Thermal Image Analysis,” J Korean Soc Qual Manag Vol. 49, No.3, pp. 327-340, Sep. 2021.
(DOI : <https://doi.org/10.7469/JKSQM.2021.49.3.327>)
- [5]Tistory, Grinding Object Detection 4. Faster R-CNN [Internet], Available : <https://yeomko.tistory.com/17>
- [6]Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” Advances in Neural Information Processing Systems 28 (NIPS 2015), Jan. 2016.
- [7]Tsung-Yi Lin, PriyaGoayl, Ross Girchick, Kaiming He and Piotr Dollar, “Focal Loss for Dense Object Detection,” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 42, Issue 10, pp.318-327, Feb. 2020.
(DOI : [10.1109/TPAMI.2018.2858826](https://doi.org/10.1109/TPAMI.2018.2858826))
- [8]Yong-Hwan Lee and Young-Seop Kim, “Comparison of CNN and YOLO for Object