

열화상 이미지를 이용한 배전 설비 검출 및 진단

김주식* · 최규남** · 이형근** · 강성우**

*한국수력원자력(주) · **인하대학교 산업공학과

Detection and Diagnosis of Power Distribution Supply Facilities Using Thermal Images

Joo-Sik Kim* · Kyu-Nam Choi** · Hyung-Geun Lee** · Sung-Woo Kang**

*Korea Hydro & Nuclear Power Co.,Ltd.,

**Department of Industrial Engineering, INHA University

Abstract

Maintenance of power distribution facilities is a significant subject in the power supplies. Fault caused by deterioration in power distribution facilities may damage the entire power distribution system. However, current methods of diagnosing power distribution facilities have been manually diagnosed by the human inspector, resulting in continuous pole accidents. In order to improve the existing diagnostic methods, a thermal image analysis model is proposed in this work. Using a thermal image technique in diagnosis field is emerging in the various engineering field due to its non-contact, safe, and highly reliable energy detection technology. Deep learning object detection algorithms are trained with thermal images of a power distribution facility in order to automatically analyze its irregular energy status, hereby efficiently preventing fault of the system. The detected object is diagnosed through a thermal intensity area analysis. The proposed model in this work resulted 82% of accuracy of detecting an actual distribution system by analyzing more than 16,000 images of its thermal images.

Keywords : Power distribution supply facility, Thermal image, Object detection

1. 서론

전력 공급 설비 분야의 배전 시스템에서 이슈는 전기 장비의 단자 접합, 절연 균열 및 불균형 부하와 같은 문제들을 개선하기 위해 유지보수 및 신뢰성을 관리하는 것은 매우 중요한 일이다. 이러한 유형의 문제들은 전류를 증가시켜 저항 가열을 향상시키며 이로 인해 에너지가 열을 생성하는데 소비되어 불필요한 손실을 초래하고 에너지 효율을 떨어뜨린다. 또한 열이 점진적으로 증가하면 연결부가 회로를 녹이거나 끊을 수 있고 즉시 화재를 일으킬 수도 있다. 따라서 전력 장비의 고장을 방지하기 위해 전력 장비의 열 이상에 대한 초기 예방 조치가 필수적이다. 전기 장비의 열 장애는 고장 및 수리의 시간을 증가시키고

저항의 증가로 인한 불균형 부하와 같은 문제가 축적되면 전체 송배전 시스템 네트워크에 장애가 발생한다.

열화상 기술은 적외선 에너지를 감지하여 전자 신호로 변환한 다음 열화상을 생성하고 온도 범위를 측정할 수 있는 기술이다. 기계 및 전기 분야의 시스템의 상태를 모니터링하고 고장 징후를 검출하기 위해 사용된다. 예측 기반 유지보수에서 주로 사용되는 진동, 소음이 아닌 적외선 에너지를 이용한 기술로 전력 설비의 진단에서 전자기 간섭이 적어 신뢰할 수 있는 큰 검사 범위를 제공한다는 점과 비접촉식 검사가 가능하여 안전하다는 장점을 갖고 있다.

본 논문에서는 열화상 이미지와 객체 검출 알고리즘을 이용하여 배전 설비의 예측 진단 시스템을 제안하고자 한다. 시스템은 실시간 고해상도 이미지를 제공하는 적외선

†본 연구는 인하대학교 지원에 의하여 연구되었음.

†Corresponding Author: Sung-Woo Kang, Industrial Engineering, INHA UNIVERSITY, 100, inha-ro, Nam-gu, Incheon, MP: 010-6343-9721, E-mail: kangsungwoo@inha.ac.kr

Received: February 14, 2020; Revision: February 14, 2020; Accepted: March 02, 2020

카메라를 통해 배전 설비의 열화상 이미지 데이터를 수집한다. 수집된 데이터는 딥러닝 기반의 객체 검출 알고리즘을 이용하여 열화상 이미지 내의 배전 설비의 종류와 상태를 감지한다. 시스템을 통해 검출되는 장비들은 산출된 데이터를 기반으로 유지보수 계획 수립이 용이해지고, 초기 단계에서 오류를 감지하여 송배전 시스템 네트워크에 심각한 장애가 발생하기 전에 예방이 가능하다. 따라서 고장 시간, 장비 유지관리 비용을 감소시키고, 장비의 작동 시간을 늘릴 수 있다.

2. 이론적 배경

2.1 배전 설비의 유지보수

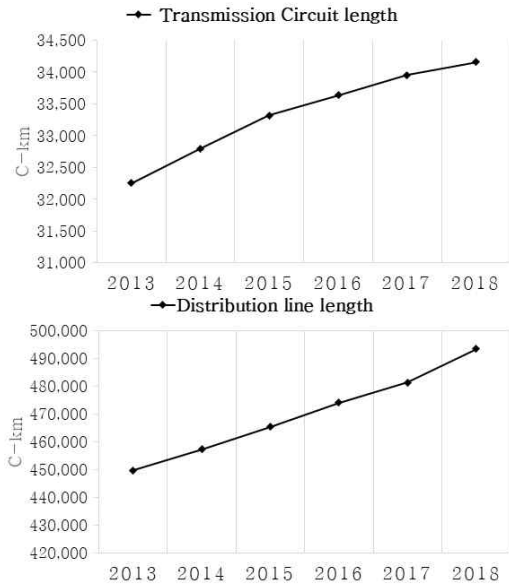
2.1.1 한국전력공사의 송배전 설비 관리 현황

한국전력공사(이하 한전)에는 배전설비의 성능저하에 따라 설비를 교체 및 보강하는 예산과 배전설비의 이상 유무를 점검 및 수선하는 예산으로 구분하여 매년 배전설비 유지보수에 많은 비용을 투자하고 있다. 그러나 배전설비의 고장 및 유지보수 현황만을 파악할 수 있는 수준으로 예측 및 분석 기능이 미약한 상태이다. 또한 단순히 고장 발생과 설비 사용 기간만을 이용하여 분석하여 고장의 원인을 파악하여 분석하지 못하고 있다. 전력연구원은 이를 보완하기 위하여 배전설비의 신뢰성 및 건전성 상태를 주기적 또는 비주기적으로 평가하는 시스템을 도입하여 배전설비에 대한 객관적이고 체계적인 평가가 가능하도록 하고, 통계적인 분석방법을 통해서 최적의 교체주기를 산정하여 설비의 재고관리를 효율적으로 할 수 있는 정보를 제공하기 위해서 “배전설비의 신뢰도 향상을 위한 최적 교체 주기 분석 시스템 개발”과제를 통하여 RCM(reliability centered maintenance, 신뢰성 중심 유지보수) 시스템을 개발하였다.[1] 그러나 한전에서는 설비들의 고장데이터를 2004년 이후부터 전산화하여 관리를 하고 있기 때문에, 그 이전 데이터는 존재하지 않거나 관리되지 못하고 있다. 따라서 송배전 설비 관리를 위하여 계획적이고 체계적인 유지보수 시스템을 구축하려고 노력 중이다.

2.1.2 한전의 송배전 전력 설비 통계

한전에서 작성하는 한국전력통계에 의하면 2018년 설비통계의 송전회선길이는 2017년 대비 200C-km증가한 34,155C-km로 최근 6년 동안 매년 증가하였다. 또한 2018년 배전선로 길이 추이를 살펴보면 2017년 대비 11,966C-km 증가한 493,331C-km로 고압, 저압부분

모두 매년 증가하였다. 이는 한전의 판매 전력량이 상승함에 따라 송배전 설비가 증가함을 나타내고, 이에 따라 배전설비 유지보수의 중요성 또한 증가하고 있다는 것을 나타낸다. [Figure 1]은 2013년부터 2018년까지의 송전회선길기와 배전선로길이의 추이를 나타낸 그림이다.[2]



[Figure 1] Trends in Transmission Circuit & Distribution Line Length[2]

또한 한전의 경우 매년 1조원이 넘는 예산과 막대한 인력을 투입하여 배전선로 정전 예방 활동을 전개하고 있으나, 유사한 원인의 고장이 반복되고 있는 실정이다. <Table 1>은 2014년부터 2018년까지 배전설비 유지보수 예산 집행실적을 나타낸 표이다. 한전이 작성한 2012년~2016년의 5년간 배전선로 정전 분석 보고서에 의하면 고장원인, 정전시간 등 20개 항목 26,500여개의 데이터를 이용하여 현황을 분석하였으나, 대부분 고장 빈도의 산술평균 확인 수준에 미치고 있어 체계적인 정전 원인 분석을 고려하지 못하고 있다. 배전설비의 효율적이고 계획적인 유지보수 시스템을 구축을 통하여 유지보수 시간, 인력의 감소를 통해 궁극적으로 배전설비 유지보수 비용감소가 필요한 실정이다.

<Table 1> Distribution Facility Maintenance Budget Execution Performance[2]

	2014	2015	2016	2017	2018
Equipment replacement	8,258	14,992	15,219	15,675	11,470
Equipment inspection	2,282	2,452	2,731	2,943	2,948
	10,540	17,444	17,950	18,621	14,418

2.1.3 배전설비 재해 현황

고용노동부에서 작성한 2000년부터 10년 간 전기공업과 관련된 재해사례를 보면 송배전공사의 연도별 사망률은 줄어들지 않고 있으며 근로손실일수가 3개월 이상인 중상 및 사망자는 전체 재해자의 61.9%를 점유하고 있다. 이러한 사고는 전주에서 가장 많이 발생하고 있으며 3,917개의 사례 중 배전관련 작업만 83.4%를 점유하고 있다.[3] 사고발생 시 중상 및 사망에 이르는 비율이 높은 배전설비 관련 유지보수 작업의 개선이 필요한 실정이다.

2.2 열화상 이미지를 이용한 설비 진단

열화상은 산업 응용 분야에서 유용한 진단 도구 중 하나로 발전했다. 열화상 기술은 가시광선보다 높은 파장을 갖는 전자기 방사선인 적외선을 기반으로 한다. 온도가 절대 영도를 초과하는 모든 물체가 적외선을 방출하기 때문에 열화상 검사는 가시 조명이 없는 환경에서도 물체를 잘 식별한다는 장점이 있다. 물체가 발생시키는 열은 육안으로 식별이 어렵기 때문에 열화상 카메라를 사용하여 전기 신호를 생성하고 이를 열화상 이미지로 변환한다. 일반적인 카메라로 얻는 가시 이미지는 장면의 반사된 빛으로 구성되는 반면, 적외선 이미지에서는 빛을 고려하지 않고 물체를 관찰할 수 있다. 따라서 열화상 검사를 통해 육안으로는 보이지 않는 이상 현상을 감지함으로써 값비싼 시스템 장애가 발생하기 전에 예방이 가능하다.[4]

또한 열화상 기술은 열원과의 직접적인 접촉이 없는 비접촉 진단 기술이다. 전류가 흐르는 송배전 설비와 같은 배전설비는 장비의 느슨한 연결, 부식 및 불균형 부하와 같은 문제들에서 유지보수 및 신뢰성을 관리해야 한다. 이러한 배전설비의 유지보수에 열화상 기술을 이용하면 비접촉식 진단으로 인해 작업자의 안정성이 향상되고, 일반 비디오카메라, 디지털카메라처럼 이용이 간편하여 실시간 고해상도 이미지를 생성하는 것이 가능하다. 전기 정전을 방지하고 송전 및 배전 시스템의 전기 장비 손상을 줄이기 위해서 중요한 기능을 수행한다. 열화상 기술은 열이 발생하는 영역을 신속하게 찾아 고장을 해결하고 장비 상태에 대해 운영자에게 최적의 결과를 제공할 수 있다. 이러한 장점으로 인해 시스템 안정성이 향상되고 유지관리 비용이 절감된다.[5]

Ha, Han, Lee(2011)는 주변 소음으로부터 음성 입력을 추출하는 마이크 장비와 열화상 이미지를 이용하여 송전선의 결함을 찾는 연구를 진행하였다. 통합 센서가 장착된 모바일 로봇을 사용하여 결함이 있을 때 특정 패턴의 소리를 생성하는 아크 방전을 마이크 장비가 파악하고, 패

턴이 감지되면 열화상 카메라가 결함이 있는 절연체의 이미지를 캡처하는 방식이다. 이를 통해 사람을 대신하는 결합 절연체를 감지 기법을 제안하였다.[6]

Ibarra-Castaneda등(2004)는 비파괴검사의 일종인 적외선 열화상 검사에서 결함을 검출할 때 전처리 방법과 열화상 이미지 분석에 필요한 다양한 데이터 분석 방법을 제시했다. 그리고 실시간 열화상 검사를 통해 더욱 미세한 결함을 잡아내기 위해서는 복잡한 알고리즘과 대용량 데이터를 처리할 수 있는 컴퓨터 계산 능력과 성능이 좋은 열화상 카메라가 뒷받침 되어야 한다고 설명한다.[7]

2.3 Faster R-CNN을 이용한 객체 검출

2.3.1 Faster R-CNN

Faster R-CNN은 R-CNN과 Fast R-CNN의 성능을 개선하며 제안된 대표적인 딥러닝 기반 객체 검출 알고리즘이다. 기존 R-CNN 알고리즘은 입력 이미지가 들어오면 selective search 기법을 사용해서 후보영역을 추출하였다. 후보영역을 추출하기 위하여 selective search를 사용한 기존의 R-CNN, Fast R-CNN모델들은 정확도는 높았으나, 많은 연산을 필요로 하는 단점이 있다. 또한 병렬 연산에 적합하지 않은 구조이기 때문에 GPU를 활용한 실시간 이미지처리에 어려움이 많았다. Faster R-CNN은 이러한 후보영역 검출 단계에서 selective search기법이 아닌 CNN의 컨볼루션 맵과 공유하는 Region Proposal Networks를 제시하였다. RPN은 이미지를 입력 받고 박스형태의 객체의 후보영역을 예측하는 역할을 한다. 후보영역 예측에 사용되는 앵커 박스는 슬라이딩 윈도우 방식으로 움직이고 크기와 비율 그리고 개수는 사전에 정의된다. 기존 R-CNN 알고리즘이 총 3단계의 학습 과정을 사용하는 것과 달리 Faster R-CNN알고리즘은 RPN을 이용하여 검출과 분류를 위한 네트워크를 동시에 학습이 가능하게 하였으며 연산량 또한 단축시켰다. 따라서 Faster R-CNN은 기존 객체 검출 알고리즘들 보다 수행 속도를 감소시키고 GPU를 활용한 병렬연산의 적용을 수월하게 하였다.[8]

2.3.2 객체 검출알고리즘을 이용한 진단 사례


최근 많은 산업 분야에서 딥러닝 기반 객체 검출 알고리즘을 다양한 진단에 적용하고 있다. Shihavuddin등(2019)은 드론을 이용한 실시간 풍력 발전기 표면 손상 감지 기법을 제안하였다. 접근이 제한된 풍력 발전기를 최근 드론 기술의 발전에 따라 실시간으로 풍력 발전기의 고

해상도 이미지를 얻는 것이 가능하다. 이미지를 얻은 이후 딥러닝 기반의 객체 검출 알고리즘을 이용하여 표면 손상을 검출하는 방법을 고안하였다. 이는 인간 수준의 정밀도를 달성하였으며, 상대적으로 작은 훈련 데이터 세트의 경우 데이터 보강 기법을 통해 모델을 일반화 시키면 정밀도를 크게 향상시킬 수 있음을 증명했다.[9]

Zhang등(2019)은 고속도로 교량의 구조적 안전과 신뢰성을 유지하기 위해 중요한 작업인 콘크리트 표면 손상 감지에 관한 연구를 실시하였다. 콘크리트 표면 손상 검사의 대부분은 수동으로 수행되었으며 시간과 비용이 많이 드는 작업이다. 콘크리트 표면을 균열, 돌출, 폭열, 철근 돌출의 네 가지 유형의 손상으로 구분된 학습 데이터를 이용하여 딥러닝 기반의 객체 검출 알고리즘을 훈련시켰다. 이를 통해 표면 검사 과정을 자동화시키는 동시에 유지보수 시간과 비용 또한 절약하는 결과를 보였다.[10]

3. 방법론

이번 장에서는 본 논문에서 제안하는 딥러닝 객체 검출 알고리즘을 기반으로 전력 공급 설비를 진단하는 시스템에 대하여 설명한다. 시스템은 총 3단계로 구성되며, [Figure 2]은 시스템을 도식화한 자료이다.



[Figure 2] Distribution Facility Diagnosis System Using Thermal Image

3.1 데이터 수집 및 전처리

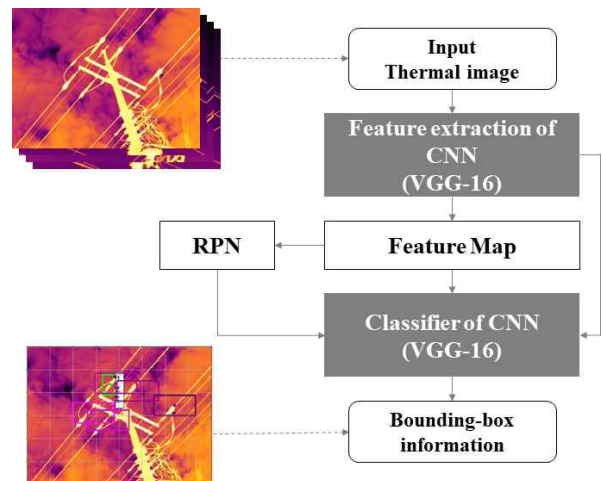
본 논문에서는 전력 설비 중에서도 배전 설비의 진단을 위한 시스템을 제안한다. 배전 설비의 비정상적인 열화현상을 발견하는 시스템을 만들기 위해 배전 설비의 모습이 담긴 열화상 이미지를 수집한다. 다음으로 수집된 열화상 이미지 데이터에서 열화로 인한 고장을 야기하는 배전 설비의 부품인 변압기, 피뢰기, 현수애자 등의 검출 대상 객체를 선정한다. 검출 대상 객체 선정 시 수집된 열화상 이미지 데이터에 해당 객체가 충분하지 못하면 객체 검출 모

델 훈련 시 다른 객체에 비해 상대적으로 정확도가 낮아질 수 있다. 따라서 검출 대상 객체 선정 시 수집된 데이터에 해당 객체의 수를 검토하여야 한다.

배전 설비의 열화상 이미지가 수집되면 객체 검출 모델에 입력시키기 위해 라벨링 작업을 실시한다. 라벨링은 각 이미지에 대해 사각형 박스 좌표 정보와 객체의 종류로 구성되어 있다.

3.2 객체 검출 모델

본 논문에서는 Faster R-CNN을 활용하여 열화상 이미지에서 배전 관련 설비를 검출하는 시스템을 제안한다. 딥러닝 기반 객체 검출 YOLO 모델에 비해 상대적으로 이미지 처리 속도가 느리지만 정확도가 높다는 특징이 있다. 제안하는 시스템은 전력 공급 설비를 진단하는 모델이므로 처리 속도보다는 검출의 정확도 및 신뢰도를 고려하여 Faster R-CNN을 객체 검출 모델을 선정하였다. 또한 이미지의 특징을 추출하는 CNN 모델은 레이어의 누적이 쉬운 VGGNet을 사용하였다. [Figure 3]은 열화상 이미지에서 배전 설비를 검출하는 객체 검출 모델을 도식화한 것이다.



[Figure 3] Object Detection Algorithm Using Thermal Image

시스템 훈련 시 열화상 이미지와 객체명이 포함된 박스 좌표정보를 입력 받는다. 입력된 열화상 이미지는 CNN 모델에서 특징을 추출한다. 추출된 특징을 이용하여 이미지 내에서 2개의 레이어로 나뉘어 박스 내의 물체가 검출하고자 하는 물체인지 아닌지 판별하는 분류 레이어와 박스의 좌표를 찾아내는 회귀 레이어를 RPN상에서 훈련이 이루어진다. RP(Region proposals)는 CNN 모델에서 추출된 특징 지도를 바탕으로 슬라이딩 윈도우 형식으로 예측

을 진행한다. RP를 예측하기 위해 ‘앵커’라고 부르는 박스를 미리 지정한다. 앵커박스는 3개의 서로 다른 크기와 3개의 서로 다른 중첩비로 조합되어 9개로 구성된다. RPN에서 분류 레이어는 앵커 하나당 2개의 예측을 출력하며, 이는 해당 앵커 안의 객체가 객체인지 객체가 아닌 배경인지의 확률이다. 회귀 레이어는 각 앵커 당 4개의 값을 출력하며 이는 박스의 좌표이다. RPN으로부터 얻은 앵커들의 결과가 출력되면 이는 라벨링 작업이 실시된 박스좌표와 함께 마지막 분류기로 입력된다. CNN의 분류기는 RPN과 마찬가지로 2개의 레이어로 나뉘어 훈련이 진행되며 훈련이 완료된 모델은 열화상 이미지 내의 예측된 객체명과 객체가 포함될 확률이 가장 높은 영역의 좌표를 출력한다.

3.3 열화상 온도 분석 모델

딥러닝 기반의 객체 검출 모델에 의해 열화상 이미지에서 물체가 속한 영역을 찾아내면 그 결과를 바탕으로 해당 이미지 속 배전 설비 부품의 결함을 진단한다. 본 논문은 특정 영역의 광도(intensity)를 분석하여 장비의 결함 유무를 판단하고자 TIAA(Thermal Intensity Area Analysis) 모델을 제시한다. 먼저 광도 및 열화상 이미지의 메타 정보를 바탕으로 온도 값을 추출하게 되며 해당 부품별 결함 진단 규칙을 적용하여 최종 결과를 도출한다. TIAA의 결함 진단 과정은 분석하고자 하는 열화상 이미지, 배전 설비의 종류에 따라 달라지는데 그 이유는 다음과 같다.

3.3.1 카메라 제조사 별 온도 추출 계산식 상이

열화상 카메라는 제조사마다 광도에서 온도 값을 계산하는 방법이 다르다. 광도, 반사 계보기 온도, 상대 습도, 피사체 거리 등 모든 카메라 제조사들이 공통적으로 측정하는 변수도 있지만 flank 상수의 종류(FLIR 제조사의 경우 R1, B, F, O, R2)와 같은 변수들은 측정 방법이 다르기 때문에 온도 추출 알고리즘을 한 가지 방법으로 통일할 수 없다. 따라서 TIAA의 진단 과정에서 온도 추출은 제조사마다 따로 적용할 수 있도록 분리할 필요성이 있다.

3.3.2 결함 진단 규칙 축적에 따른 진단 수준 고도화

진단하고자 하는 장비에 대한 규칙을 꾸준히 누적하여 데이터베이스화 한다면 TIAA의 진단 정확도가 향상될 수 있다. 데이터베이스에 축적된 진단데이터가 많아질수록 다양한 종류의 설비에 대하여 수준 높은 진단을 수행할

수 있는 모델이 된다.

본 논문에 적용된 TIAA의 진단 알고리즘은 열화상 이미지 내의 부품과 해당 부품의 관리 기준 온도 값 비교를 바탕으로 설계되었다. 현재 작동중인 장비의 온도와 장비의 정상 온도 범위를 비교하고 분석하여 장비의 결함 유무를 진단한다.

4. 실험

본 논문에서 제안한 시스템의 성능을 평가하기 위해 사용된 PC는 Intel Core i7-7700HQ CPU, 16G Byte RAM, NVIDIA GeForce GTX 1070이다. 개발 환경은 Python, Keras, Tensorflow을 이용하여 구현하였다.

4.1 데이터 수집 및 전처리


본 논문에서는 배전 설비의 비정상적인 열화현상을 발견하는 시스템을 만들기 위해 640*480 해상도의 16,843장의 열화상 이미지를 수집하였다. 열화상 이미지 데이터는 모두 배전 설비로 이루어져있으며, 열화상 이미지 촬영 과정에서 시간에 따른 그림자와 조도의 차이로 배경의 차이가 존재한다. 배전 설비에서 열화로 인한 고장을 야기하는 부품으로 변압기, 피뢰기, 현수애자, 컷아웃스위치 총 4가지를 선정하였다. 수집된 열화상 이미지로 라벨링을 실시한 결과 변압기 2,841개, 피뢰기 11,439개, 현수애자 72,242개, 컷아웃스위치 6,793개로 총 93,315개의 검출 대상 객체가 검출되었다. 본 논문에서는 8:2의 비율로 이미지 데이터를 훈련세트와 테스트세트로 분리하였다.

4.2 객체 검출 모델 훈련 및 평가


본 논문에서는 열화상 이미지를 이용한 배전 설비 진단 시스템을 구현하기 위해 Faster R-CNN을 사용하였다. Faster R-CNN 내부의 CNN모델은 VGG-16모델을 사용하였다. Faster R-CNN을 제안한 논문에서는 VGG-16 모델의 이미지 사이즈를 600으로 사용하였으나 본 논문에서는 300으로 설정하였다. 이는 처음 논문보다 훈련에 사용되는 이미지 수가 9,000장 이상 많으며, 검출해야 하는 대상 객체의 수가 30,000개 이상 많아 훈련의 속도를 줄이기 위함이다. 열화상 이미지가 객체 검출 모델에 입력되면 CNN모델을 거쳐서 특징 지도가 생성된다. 특징 지도를 입력으로 받는 RPN과정은 박스 안의 객체가 훈련시 키고자 선정된 대상 객체가 맞는지 판단하는 분류하는 작업과 박스 좌표를 회귀하는 작업을 실시하며 해당 훈련의

손실함수는 [Figure 4]에 도식화하였다. RPN과정에서 사용하는 임곗값은 모두 Faster R-CNN을 제안한 논문에서 사용한 값을 사용하였다.


RPN의 출력으로 나온 앵커들의 결과와 함께 레이블 작업이 실시된 박스좌표를 입력으로 받아 훈련되는 CNN 분류기 모델의 손실함수는 [Figure 5]에 도식화하였다. 분류와 회귀 레이어 모두 RPN의 손실함수와 비교해보면 불안정한 경향을 보였다. 이는 사전에 정의된 앵커의 크기와 중형비에 비해 배전 설비의 열화상 이미지에 다양한 크기의 객체가 존재하기 때문이다. 객체 검출 모델을 통해 검출된 배전 설비들의 예시는 [Figure 6]에 도식화하였다.



[Figure 4] Loss of RPN classification and regression



[Figure 5] Loss of Classifier classification and regression



[Figure 6] Object Detection Results

<Table 2>은 객체 종류별 객체 검출 모델의 평가 지표를 정리해놓은 표이다. mAP(mean Average Precision)는 딥러닝 기반의 객체 검출 알고리즘에서 주로 사용되는 성능지표이다. AP(Average precision)은 precision-recall 그래프로 모델의 성능을 비교하는 것보다 하나의 숫자로 모델을 평가하기 위해 precision-recall 그래프의 면적을 계산한 값이다. 컴퓨터 비전 분야에서 객체 검출 및 이미지 분류 알고리즘의 성능은 대부분 AP로 측정되며 mAP은 검출하고자 하는 객체의 종류가 여러 개인 경우 각 객


체 별 AP를 계산하여 객체 종류의 수로 나누어준 값이다.

<Table 2> Calculated mAP on object types

Object type	AP(%)
COS	80.1
CT	67.3
INS	80.3
LA	77.1
mAP	76.2

4.3 열화상 온도 분석 모델

열화상 온도 분석 모델은 객체 검출 모델에 의해 출력된 객체를 중심으로 해당 부품의 결함을 진단한다. 본 논문에서는 열화상 카메라 제조사인 FLIR의 열화상 카메라를 이용하여 열화상 이미지의 온도를 추출하였다. TIAA모델은 검출된 설비의 명칭, 설비 종류, 열화상 이미지 파일명, 측정 온도, 기준 온도, 초과 온도를 진단 결과로 출력한다. TIAA모델의 분석 결과 예시는 [Figure 7]과 같다.



Category	Content	Remarks
Facility name	2320-472-M-CT-07PA	
Facility type	CT(Columnar Transformer)	
Image file	IR_8818.JPG	
Measurement temperature(°C)	34.4	
Reference temperature(°C)	31.0	
Excess temperature(°C)	3.4	State of caution

[Figure 7] TIAA model

5. 결론 및 향후 연구

본 논문에서는 열화상 이미지를 이용한 배전 설비 진단 시스템을 제안하였다. 현재 배전 설비의 진단은 작업자가 수동으로 접촉하고 결함을 진단을 하는데 배전 설비 관련 사고는 매년 꾸준히 발생하고 있다. 또한 열화와 같은 결

함은 작업자가 육안으로 판단하는데 어려움이 있다. 따라서 비접촉방식으로 안전하며 열화와 같은 결함을 원거리에서도 진단 가능한 열화상 이미지를 이용한 배전 설비 진단 시스템을 제안하였다.

수집된 배전 설비 열화상 이미지에서 객체를 검출하기 위하여 딥러닝 객체 검출 알고리즘인 Faster R-CNN을 기반으로 학습시켰다. 학습한 알고리즘을 통해 총 4종의 배전 설비 부품을 검출하는 실험을 실시한 결과 배전 설비 검출 성능은 mAP 76.2%, 배전 설비 분류 정확도는 81.9%의 결과를 보였다. 배전 설비에 관한 열화상 이미지가 다양한 환경과 조건에서 수집되고, 검출 대상 객체에 대한 열화상 이미지 진단 규칙이 고도화 된다면 배전 설비 결함 진단 시스템에 활용도가 높을 것으로 기대된다.

본 논문에서의 실험에 사용한 배전 설비 열화상 이미지에서는 검출 대상 객체의 수의 편향이 존재하였다. 데이터 수가 가장 적은 변압기는 가장 낮은 AP값인 67.3%을 보였다. 향후 연구에서는 일부 검출 대상 객체에 편향되지 않은 좋은 데이터 셋을 구축하기 위해 추가적인 배전 설비 열화상 데이터 수집이 필요하다. 또한 객체의 종류가 적은 수의 데이터를 보완하기 위해 데이터 증강을 수행하는 객체 검출 알고리즘에 관한 추가 연구가 필요하다.

검출 성능을 향상시키기 위해 Faster R-CNN의 특징 추출에 사용되는 CNN모델의 수정 및 비교를 진행할 예정이며, 실시간 모니터링을 위한 객체 검출 알고리즘의 검출 속도 향상을 위한 방법론을 추후 연구할 예정이다.

6. References

- [1] C. W. Lim, S. K. Han(2018), "A study on development of power grid fault prediction system based on big data and preceding activities to calculate optimal investment cost." *Journal of the Korean Data & Information Science Society*, 29(3):779-794.
- [2] KEPCO(2019), "Statistics of Electric Power in KOREA." Vol.88.
- [3] S. D. Choi, S. Y. Hyun, H. J. Han, W. C. Shin(2011), "The Assessment of the Risk Index of Live-line Works on Distribution Line by the Accident Analysis." *Electrical Industry Research Institute of Korea*, 26(3):8-14.
- [4] D. Kumar, M. A. Ansari(2018), "Condition monitoring of electrical assets using digital IRT and AI technique." *Journal of Electrical Systems and Information Technology*, 5(3):623-634.
- [5] V. Ramesh(2017), "A Review on Application of Deep Learning in Thermography." *International Journal of Engineering and Management Research (IJEMR)*, 7(3):489-493.
- [6] H. U. Ha, S. S. Han, J. M. Lee(2011), "Fault detection on transmission lines using a microphone array and an infrared thermal imaging camera." *IEEE Transactions on Instrumentation and Measurement*, 61(1):267-275.
- [7] C. Ibarra-Castaneda, D. Gonzalez, M. Klein, M. Pilla, S. Vallerand, X. Maldague(2004), "Infrared image processing and data analysis." *Infrared Physics & Technology*, 46(1-2):75-83.
- [8] S. Ren, K. He, R. Girshick, J. Sun (2015), "Faster r-cnn: Towards real-time object detection with region proposal networks." *Advances in neural information processing systems*: 91-99.
- [9] A. S. M. Shihavuddin, X. Chen, V. Fedorov, A. N. Christensen, N. A. B. Riis, K. Branner, A. B. Dahl, R. R. Paulsen(2019), "Wind Turbine Surface Damage Detection by Deep Learning Aided Drone Inspection Analysis." *Energies*, 12(4):676.
- [10] C. Zhang, C. C. Chang, M. Jamshidi (2019), "Concrete bridge surface damage detection using a single-stage detector." *Computer-Aided Civil and Infrastructure Engineering*, 35(4):389-409.

저자 소개



김 주 식

충북대학교 전기공학과 학사 취득
현재 한국수력원자력 중앙연구원 디지털융합
그룹
관심분야 : 딥러닝, 열화상 설비진단



최 규 남

인하대학교 산업경영공학과 학사 취득 후 현재
인하대학교 대학원 산업공학과 석사과정 중
관심분야 : 딥러닝, 이미지 마이닝, 객체 검출 등



이 형 근

인하대학교 산업경영공학과 학사 취득 후 현재
인하대학교 대학원 산업공학과 석사과정 중
관심분야 : 컴퓨터 비전, 이미지 마이닝 등



강 성 우

현재 인하대학교 산업경영공학과 조교수
관심분야 : AI, Big Data 및 PHM