

광섬유 복합가공 지선(OPGW) 설비 안전점검을 위한 VGGNet 기반의 이상 탐지

강건하*, 손정모^o, 손도현**, 한정호**

^{*}(주)이포즌 기업부설연구소,

^o(주)이포즌 기업부설연구소,

^{**}한국전력공사 인천본부 전력관리처 전자제어부

e-mail: zxcvbnm9931@epozen.com*, jmsohn@epozen.com^o,

dohyun.son@kepcoco.kr**, jeongho.han@kepcoco.kr**

Anomaly Detection using VGGNet for safety inspection of OPGW

Gun-Ha Kang*, Jung-Mo Sohn^o, Do-Hyun Son**, Jeong-Ho Han**

^{*}Epozen's research institute,

^oEpozen's research institute,

^{**}Regional Headquarters KEPCO Incheon Transmission & Substation Department Electronic Control Team

● 요약 ●

본 연구는 VGGNet을 사용하여 광섬유 복합가공 지선 설비의 양/불량 판별을 수행한다. 광섬유 복합가공 지선이란, 전력선의 보호 및 전력 시설 간 통신을 담당하는 중요 설비로 고장 발생 전, 결함의 조기 발견 및 유지 관리가 중요하다. 현재 한국전력공사에서는 드론에서 촬영된 영상을 점검원이 이상 여부를 점검하는 방식이 주로 사용되고 있으나 이는 점검원의 숙련도, 경험에 따른 정확성 및 비용과 시간 측면에서 한계를 지니고 있다. 본 연구는 드론에서 촬영된 영상으로 VGGNet 기반의 양/불량 판정을 수행했다. 그 결과, 정확도 약 95.15%, 정밀도 약 96%, 재현율 약 95%, f1 score 약 95%의 성능을 확인하였다. 결과 확인 방법으로 는 설명 가능한 인공지능(XAI) 알고리즘 중 하나인 Grad-CAM을 적용하였다. 이러한 광섬유 복합가공 지선 설비의 양/불량 판별은 점검원의 단순 작업에 대한 비용 및 점검 시간을 줄이며, 부가가치가 높은 업무에 집중할 수 있게 해준다. 또한, 고장 결함 발견에 있어서 객관적인 점검을 수행하기 때문에 일정한 점검 품질을 유지한다는 점에서 적용 가치가 있다.

키워드: 딥러닝(Deep Learning),

광섬유 복합가공 지선(OPGW, Composite Overhead Ground Wire with Optical Fiber),

VGGNet, XAI, Grad-CAM

I. Introduction

최근 정부 주도 하의 스마트 제조의 도입으로 4차 산업 기술이 적용됨에 따라 설비 예지 보전 관련 연구들이 지속해서 진행되고 있다. 특히 설비의 결함 조기 발견은 설비 예지 보전에 필수적인 요소이다. 그 때문에 설비의 결함 여부 판단을 위하여 이전에는 작업자가 직접 설비에서 촬영된 이미지나 영상 등 육안 검사를 통해 설비의 결함 여부를 판단했다. 그 예로, 2016년 한국전력공사에서는 드론을 이용하여 설비의 영상을 촬영하고 촬영된 영상을 점검원이 이상 여부를 직접 점검 및 관리했다. 이는 점검원의 숙련도, 경험, 단순반복 작업으로 인한 점검원의 피로로 인한 집중력 저하 등 점검 품질이

달라지며, 비용이나 시간 측면에서도 문제가 발생한다. 이런 인적 점검 방식을 개선하기 위해 최근에는 인공지능을 결합하여 이상 탐지를 수행하는 연구들이 진행되고 있다. 그 예로, LSTM 기반 AutoEncoder를 결합한 모델을 사용하여 회전기계(Rotating Machine)의 진동 데이터 이상 탐지 등의 연구가 있다[1].

따라서, 본 연구에서는 드론에서 촬영된 영상에서 광섬유 복합가공 지선(OPGW) 데이터를 활용하여 딥러닝 기반의 이상 탐지를 수행한다. 알고리즘으로는 VGGNet 기반의 모델을 사용하고, 결과 확인을 위해 설명 가능한 인공지능(XAI) 알고리즘 중 하나인 Grad-CAM을

적용했다.

이러한 VGGNet을 활용한 이상 탐지는 OPGW 설비를 점검에 있어서 점검원의 단순 작업에 대한 비용 및 시간을 줄이며, 부가카치가 높은 업무에 집중할 수 있게 해준다. 또한, 설비 불량 점검에 있어서 객관적인 점검을 수행하기 때문에 일정한 점검 품질 유지할 수 있게 된다.

II. Preliminaries

1. Related works

1.1 VGGNet

Computer Vision 분야에서 이미지의 일부 영역에 대한 특징을 추출하고 분류를 수행하는 모델인 Convolutional Neural Network (이하 CNN)의 활용도가 증가하면서, 더 좋은 성능을 위해 기본 구조를 변형시키는 시도가 증가했다. VGGNet은 그중 하나이다. 주요 특징으로는 깊은 네트워크를 쌓을 수 있으며, Conv 필터 크기를 3x3으로 통일하여 중첩으로 사용하여 계산 비용을 줄이고, 성능을 향상했다[2].

Fig 1은 VGGNet-16의 구조로, 위의 주요 특징들이 적용되어있다.




Fig. 1. VGGNet-16 구조[3]

1.2 Grad-CAM

인공지능(Artificial Intelligence) 기술은 빅데이터 및 복잡한 알고리즘 등을 기반으로 사용자에게 의사결정, 추천, 예측 등의 다양한 용도로 여러 분야에서 사용되고 있다. 하지만, 일부 머신러닝(딥러닝 등)은 알고리즘의 복잡성으로 인해 도출한 최종 결과의 근거, 도출과정의 타당성 등을 제공하지 못하는 이슈가 존재한다[4]. 그 예로, 인공지능 바둑 기사 알파고와 이세돌의 대결이 있다[5]. 이를 해결하고자 미국 방위 고등 연구계획국(DARPA)가 추진한 프로젝트 중 하나인 XAI(eXplainable AI)라는 기술이 등장했다[6]. XAI란 설명가능한 인공지능으로, 도출한 최종 결과에 근거나 도출과정의 타당성 등을 제공하여, 올바른 해석이 가능하게 해주는 기술이다.

CAM(Class Activation Map)은 XAI 알고리즘 중 하나로, CNN 계열의 이미지 분류 모델에서 FC layer(Fully Connected) 대신 GAP(Global Average Pooling)를 적용하여 이미지의 어느 부분을 보고 class를 예측했는지를 시각화해주는 알고리즘이다[7].

Grad-CAM(Gradient Class Activation Map)은 CAM의 단점을 보완하고 발전시킨 알고리즘이다. CAM에서는 GAP를 무조건 사용

해야 하므로 모델의 구조를 바꿔야만 하는 단점이 있었다. Grad-CAM에서는 feature map channel에 대한 gradient를 구해서 channel 별 가중치를 구함으로써, 모델의 구조를 바꾸지 않고 객체의 위치를 추출할 수 있다. CAM과 마찬가지로 모델이 예측할 때 집중된 부분을 heatmap 형식으로 시각화한다[8].

III. The Proposed Scheme

1. 데이터 세트

모델 학습에 사용된 데이터 세트는 송전선로 최상부에 설치된 통신선 내장 복합 케이블인 광섬유 복합가공 지선 데이터 세트이다. 고압선로를 보호하는 기능과 광섬유를 이용한 통신선로 기능을 복합적으로 수행하고 안정적인 전력공급과 전력망 운영에 필요한 전력 ICT 핵심 설비이다.

본 연구에서는 해당 OPGW 설비의 정상, 아마로드 폴립, 댐퍼 밀립 등 주로 발생하는 결함을 포함하는 3가지로 이미지가 구성되어있다. 모델 학습 시 사용된 데이터 세트는 128x256 크기의 1채널 이미지로 학습에 사용된 데이터는 총 5276개이며, 정상 2311개, 아마로드 폴립 2240개, 댐퍼 밀립 725개의 데이터가 사용되었다. 테스트에 사용되는 데이터는 총 1320개의 데이터로 정상 578개, 아마로드 폴립 560개, 댐퍼 밀립 182개의 데이터가 사용되었다.

학습에 사용된 양/불량 광섬유 복합가공 지선 이미지들은 다음 Fig 2와 같다.



Fig. 2. 양/불량 광섬유 복합가공 지선 이미지

2. 전처리

전처리 과정은 드론에서 촬영된 영상을 이미지(프레임)로 추출하는 과정과 추출된 이미지 중 필요한 이미지를 선별하는 과정으로 나뉜다. 첫 번째 과정에서는 OpenCV 라이브러리를 활용하여 영상에서 초당 6장의 이미지를 추출했다. 두 번째 과정에서는 추출된 이미지에 대해서 정상 가공지선과 결함(댐퍼 불량, 댐퍼 밀립, 아마로드 폴립) 가공지선을 선별했다. 선별 기준은 Fig 3과 같으며, 선별된 이미지는 128x256 크기로 축소하여 NumPy 파일로 변환하였다.



Fig. 3. 이미지 선별 기준

3. 모델 학습 수행

본 연구는 Google Colab Pro 환경에서 수행되었으며, GPU는 Tesla P100-PCI-E-16GB를 사용했다. 학습 모델은 Tensorflow 2.6.0을 사용하였다. Conv 필터 크기는 3x3으로 모두 구성되어있다. 손실 함수로는 Mean Squared Error, 최적화 함수로는 Adamax를 사용했다. Batch size는 64, Epoch는 30으로 학습을 진행했다.

성능 평가 척도로는 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), 조화평균(f1 score)를 기준으로 평가하였다. 성능 평가에 사용된 지표들은 다음 Table 1과 같다.

Table 1. 성능 평가 지표[9]

성능 지표	설명
정확도	전체 샘플 데이터 중 맞게 예측한 샘플 데이터 수의 비율을 뜻한다. 높을수록 좋은 모형이다. 그러나, 편향된 데이터의 경우 잘못된 결과가 입증될 수 있는 단점이 있다.
정밀도	양성 클래스에 속한다고 출력한 샘플 중 실제로 양성 클래스에 속하는 샘플 수의 비율을 뜻한다.
재현율	실제 양성 클래스에 속한 표본 중에 양성 클래스에 속한다고 출력한 표본의 수의 비율을 뜻한다.
F1-Score	정밀도와 재현율의 조화평균으로, 데이터가 불균형일 때 편향되지 않고 모델이 얼마나 효과적인지 설명 가능한 지표이다.

4. 모델 성능 평가 결과

모델의 성능 평가에는 테스트 이미지 200장이 사용되었다. 정확도, 정밀도, 재현율, f1 score라는 성능지표들을 통해 해당 모델의 성능을 평가하였다.

Table 2는 성능 평가 결과를 나타낸 것이다. 성능 평가 결과, 정확도 95.15%, 정밀도 95.60%, 재현율 94.44%, f1 score 94.99%의 성능을 보였다.

Table 2. 모델 성능 평가 결과

정확도	정밀도	재현율	f1 score
95.15%	95.60%	94.44%	94.99%

IV. Conclusions

본 연구는 VGGNet을 사용한 딥러닝 모델을 통해 광섬유 복합가공 지선의 양불량을 판별했다. 이후 학습된 모델의 성능을 분석하였으며, Grad-CAM으로 결과에 대한 근거를 확인했다. 그 결과, 정확도 약 95.15%, 정밀도 약 96%, 재현율 약 95%, f1 score 약 95%의 성능을 보였다. 이를 통해 본 연구에서 적용한 광섬유 복합가공 지선 양불량 판정 방법은 불량 점검에 있어서 객관적인 점검을 수행하는 것으로 보이며, 어느 정도 효과가 있음을 알 수 있었다.

본 연구에서는 이미지 선별 시, 사람이 직접 분류했으며, 복합 결합 혹은 그 외의 결함에 대해서는 고려하지 않았기 때문에 결과에 있어서 한정적이라는 점에서 추후 개선해야 할 점들이 있다.

ACKNOWLEDGEMENT

This research was supported by Regional Headquarters KEPSCO Incheon.

REFERENCES

- [1] Sabtain Ahmad, Kevin Styp-Rekowski, Sasho Nedelkoski, Odej Kao, (2020). Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines, DOI:10.1109/BigData50022.2020.9378015
- [2] K. Simonyan, A. Zisserman. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. International Conference on Learning Representations (ICLR). DOI:10.1109/ACPR.2015.7486599
- [3] <https://neurohive.io/en/popular-networks/vgg16/>, Neurohive, VGG16 - Convolutional Network for Classification and Detection
- [4] 금융보안원. (2018). 설명 가능한 인공지능[eXplainable AI, XAI] 소개.
- [5] Wojciech Samek, Thomas Wiegand, Klaus-Robert Müller. (2017). Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models. arXiv:1708.08296v1,
- [6] Defense Advanced Research Projects (DARPA). (2017). Explainable Artificial Intelligence (XAI). DARPA presentation.
- [7] Bolei Zhou, Aditya Khosla, Agata Lapedriza, Aude Oliva, Antonio Torralba. (2015). Learning Deep Features for Discriminative Localization. arXiv:1512.04150v1,
- [8] Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra. (2019). Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. arXiv:1610.02391v4,
- [9] <https://datascienceschool.net/03%20machine%20learning/09.04%20%EB%B6%84%EB%A5%98%20%EC%84%B1%EB%8A%A5%ED%8F%89%EA%B0%80.html>. 데이터 사이언스 스쿨, 5.4 분류 성능평가.