

딥러닝 기반 객체 탐지를 활용한

배전공가 이상 탐지 모델 연구

(Research or Anomaly Detection Model for Distribution

Grids Using Deep Learning-Based Object Detection)

이훈제*, 김진성**, 정세훈***, 심춘보****

(Hun Jea Lee, Jin Sung Kim, Se Hoon Jung, Chun Bo Shim)

요약

현대 사회에서 전력 인프라는 필수적인 에너지 공급망으로, 그 안정성과 효율적 관리는 매우 중요한 과제로 대두되고 있다. 최근 배전 공가에 무단으로 통신 설치 하는 사례가 급증하면서, 전력 설비의 구조적 안정성을 위협하는 위험 요소로 인식되고 있으며, 현재 전력 설비의 이상 여부는 주로 육안 점검에 의존하고 있어 효율적인 정비에 어려움이 있다. 본 연구는 컴퓨터 비전과 딥러닝 기술을 활용하여 배전 공가의 이상을 탐지하는 모델을 제안한다. 특히, 기존의 객체 탐지 기술이 전선처럼 얇고 복잡한 구조를 가진 객체를 정확히 식별하지 못하는 한계를 극복하기 위해, YOLOv11-seg와 2DCNN을 결합한 이상 탐지 시스템을 제안한다. 본 연구는 Segmentation 기반의 레이블링과 데이터 증강 기법을 적용하여 다양한 환경에서의 탐지 성능을 높였으며, YOLOv8l-seg, YOLOv9c-seg, YOLOv11-seg, Mask R-CNN+ResNet50+FPN, ConvNeXT 등 다양한 모델과의 비교 실험을 통한 우수성을 검증했다. 연구 결과, 제안한 YOLOv11-seg 기반 모델은 전력 설비의 구조적 변화와 이상을 효과적으로 탐지하였으며, 전력 인프라 관리의 효율성 향상과 안정성을 확보한 딥러닝 기반 기술의 실용적 가능성을 제시한다.

■ 중심어 : 객체 탐지 ; YOLO ; 컴퓨터 비전 ; 배전 공가

Abstract

In the modern society, power infrastructure is an essential energy supply chain, and its stability and efficient management are emerging as very important tasks. Recently, as the number of cases of unauthorized communication installations in distribution workplaces has increased rapidly, it is recognized as a risk factor that threatens the structural stability of power facilities, and the current abnormality of power facilities mainly relies on visual inspection, making it difficult to efficiently maintain them. This study proposes a model for detecting abnormalities in distribution workplaces using computer vision and deep learning technology. In particular, in order to overcome the limitations of the existing object detection technology accurately identifying objects with a thin and complex structure like wires, we propose an abnormality detection system that combines YOLOv11-seg and 2DCNN. This study improved the detection performance in various environments by applying segmentation-based labeling and data augmentation techniques, and verified the excellence through comparative experiments with various models such as YOLOv8l-seg, YOLOv9c-seg, YOLOv11-seg, Mask R-CNN+ResNet50+FPN, and ConvNeXT. As a result of the study, the proposed YOLOv11-seg-based model effectively detects structural changes and abnormalities in power facilities and presents the practical possibility of deep learning-based technology that improves the efficiency and stability of power infrastructure management.

■ keywords : Object Detection ; YOLO ; Computer Vision ; Distribution Substation Management

I. 서 론

현대의 전력은 우리 생활에 필수적인 에너지로

* 준회원, 순천대학교 인공지능공학과

** 정회원, 순천대학교 T-Bio 융합시스템전공학과

*** 종신회원, 순천대학교 컴퓨터공학과

**** 종신회원, 순천대학교 인공지능공학과

This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. RS-2025-00407739).

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-지역지능화혁신인재양성사업의 지원을 받아 수행된 연구임 (IITP-2025-RS-2020-II201489)

접수일자 : 2025년 05월 08일

수정일자 : 2025년 06월 16일

게재 확정일 : 2025년 07월 02일

교신저자 : 심춘보 e-mail : cbsim@scnu.ac.kr

전력 인프라의 안정성과 효율 관리는 핵심 과제로 부상하고 있다. 최근 배전 공가에서 무단 통신 설비 설치 문제가 대두되며, 단순한 불법 점유를 넘어 전력 설비의 구조적 안정성을 위협하는 위험 요소로 인식되고 있다. 전국에 무단으로 설치된 통신선은 약 4만km이며, 이는 약 38만 개의 전선에 해당한다[1]. 이러한 현상은 전력 인프라의 안전성에 대한 심각한 위험이 되고 있다. 현재 전력 설비 모니터링은 육안 점검에 의존하는 비효율적인 방식을 사용하고 있다. 이러한 수작업 기반의 점검 방식은 설치된 전주의 현황 파악과 효율적인 정비가 어려우며, 특히 미세한 구조 변형이나 지속적인 하중 증가와 같은 잠재적 위험 요소를 식별하는 데 어려움이 있어, 지속적인 관리의 한계가 있다. 따라서 전력 인프라의 안전성을 확보하기 위해 보다 체계적이고 효율적인 기술적 접근이 필요한 실정이다.

전력 설비 모니터링은 육안점검 외에 드론을 활용한 영상 촬영, 센서 기반 모니터링 등 다양한 방식을 활용하고 있다[2,3]. 드론 촬영 방식은 기상 조건의 영향과 전주의 구조적 변화를 정밀하게 분석하기 어려운 한계가 있었고, 센서 기반 모니터링 경우, 수많은 전주에 높은 초기비용과 유지보수 비용이 요구되며, 센서의 오작동이나 통신 장애로 인해 여러 문제점이 있었다. 이러한 문제를 해결하고자 최근에는, 컴퓨터 비전(Computer Vision)과 딥러닝(Deep learning)을 활용한 전력 설비 시스템에 관한 연구가 진행되고 있다[14].

컴퓨터 비전은 이미지 및 영상 데이터에서 정보를 추출하는 기술로, 다양한 산업 분야에서 활용되고 있다. 그중, 전력 설비 모니터링에는 객체 탐지(Object Detection), 이미지 분할(Image Segmentation), 이상 탐지(Anomaly Detection) 등의 기술이 핵심적으로 적용되며, 기존의 전통적인 이미지 처리 기법보다 높은 정확도를 제공한다[17,18]. 대표적인 딥러닝 모델로는 이미지 내 패턴을 계층적으로 학습하여 빠른 속도와 높은

정확도를 보여주는 CNN(Convolutional Neural Network)이 있다.

기존 딥러닝과 컴퓨터 비전 기술을 활용한 모델들은 전선이 가늘고 복잡한 형태로 배경과 대비가 부족하여 기존의 경계 상자(Bounding Box) 방식으로 교차하거나 겹치는 객체를 정확히 구분하기 어려웠으며, 단순히 객체를 탐지하는 것만으로는 통신 설비의 시간에 따른 이상을 효과적으로 탐지하기 어려워 YOLOv11-seg(You Only Look Once version11 large-segmentation)[4]의 객체 탐지와 2DCNN(2D Convolutional Neural Network)[5]의 특징 학습 능력을 결합하여 단순 객체 탐지가 아닌 전력 설비의 구조적 변화와 이상을 효과적으로 탐지한다.

기존 전력 설비 모니터링 방식들의 한계점을 극복하기 위해, 본 연구는 YOLOv11-seg과 2DCNN을 결합한 모델을 제안한다. YOLOv11-seg은 실시간 객체 탐지와 Segmentation에서 뛰어난 성능을 보이나, 단순한 객체 탐지만으로 통신 설비의 변화를 탐지하는데 한계가 있어, 2DCNN을 결합해 단순 객체 탐지뿐만 아니라 효과적인 이상 탐지 모델을 구축했다. 2DCNN의 Residual Connection과 Batch Normalization을 활용하여 객체의 특징을 안정적으로 추출하고 분류하였으며, Convolution 연산을 통해 계층적 특징 학습으로 미세한 변화를 탐지한다. 이러한 기술들의 장점을 결합하여, 통신 설비의 이상 자동 탐지를 목표로 한다.

본 연구의 구성은 다음과 같다. 2장에서 전력 탐지에 관한 기존 연구와 기존의 시스템에 대한 문제점을 분석하고, 3장에서 데이터 수집 및 전처리 방법, 제안하는 YOLOv11-seg와 2DCNN을 결합한 모델에 대해 기술한다. 4장에서 제안하는 모델과 다른 모델을 실험하고 평가한다. 마지막으로 5장에서 결론과 향후 계획에 대해 기술한다.

II. 관련 연구

2.1 딥러닝 기반 전력 설비 자동 탐지 기법
전력 설비 점검을 위한 딥러닝 기반 연구[6]에서는 YOLOv3를 적용하여 철탑 설비 탐지 알고리즘을 개발했다. 전력 설비의 다양한 크기를 고려하여 YOLOv3-tiny 모델을 확장한 YOLOv3-tiny-3l 모델을 제안하고, 여기에 SPP(Spatial Pyramid Pooling)를 결합하여 전역적 특징과 지역적 특징을 모두 활용할 수 있는 YOLOv3-tiny-3l-spp 모델을 개발했다. 해당 연구에서는 애자(Insulator), 스톡브리지 댐퍼(Stock Bridge damper), 스페이서Spacer), 피뢰기(Lightning Arrester) 4개 클래스에 대한 탐지를 수행하며, YOLOv3-tiny-3l-spp 구조가 mAP(mean Average Precision) 기준으로 가장 우수한 성능을 보여주었다.

송전선 인식을 위해 소벨 필터(Sobel Filter)와 임곗값 처리(Thresholding)를 활용한 영상처리 기법을 적용했다. 복잡한 배경에서도 송전선을 효과적으로 탐지하기 위해 수평 소벨(Horizontality Sobel)를 적용하고, 일정값 이하의 에지 성분을 제거하는 전처리 과정을 수행했다. 이러한 접근은 컴퓨터 비전을 활용한 송전선 상태 모니터링 자동화 연구를 제시했다.

2.2 딥러닝 기반 송전선 늘어짐 감지 기법
송전선 늘어짐을 감지하는 연구[7]에서는, 딥러닝과 컴퓨터 비전을 활용한 시스템을 제안했다. 송전선의 늘어짐은 안전사고와 전력 전송 효율 저하로 이어질 수 있어 효과적인 모니터링이 필수적이며, 기존의 송전선 모니터링 시스템은 센서 기반 측정 방식을 사용하여, 큰 비용과 유지 보수가 어렵다는 단점이 있다. 해당 연구에서는 이동형 카메라 시스템으로 촬영한 영상을 기반으로 송전선 늘어짐을 감지하는 방법을 제안했다. YOLOv3 모델을 활용하여 송전탑을 자동으로 인식하고, 영상의 화질 저하 문제를 해결하기 위해 히스토그램 평활화 기법인 CLAHE(Contrast Limited Adaptive Histogram

Equalization)[8] 기법을 적용하여 명암 대비를 개선했다. 송전선 전체 파악을 위해 파노라마 영상 스티칭(Panoramic Video Stitching) 기술을 적용하여 여러 영상을 하나로 합성해 에지 검출(Edge Detection) 기법을 통해 송전선을 감지했다. 해당 연구는 소요 시간과 정확도 측면에서 효율적인 송전선 늘어짐을 감지한 연구로 값비싼 장비 대신 컴퓨터 비전 기술을 활용한 대규모 송전선 유지보수 연구를 제시했다.

III. 제안 방법

3.1 데이터 수집 및 전처리

본 연구는 전신주의 이상을 탐지하는 배전 공가 이상 탐지 모델을 제안한다. 전신주의 이상은 크게 전선(Wire), 전주(Pole), 완철(Crossarm)의 변화가 생길 수 있다. 따라서, 3가지 클래스로 데이터를 분류하였으며, Roboflow[9], Kaggle[10], 자체 수집 데이터를 활용하여 원천 데이터[13]를 확보했다.

표 1은 모델 훈련에 사용한 훈련, 검증, 테스트 데이터의 이미지 및 객체 구성을 나타낸다. 전체 데이터는 총 4,475장의 전주 이미지로 이루어져 있으며, 훈련 데이터 3,585장, 검증 데이터 443장, 테스트 데이터 447장으로 나누었다. 이미지 크기는 모델 학습을 위해 640×640 픽셀로 조정하였다. 클래스별로 Labeling 객체 수는 총 56,797개이며, Wire 클래스가 42,084개, Crossarm 클래스가 10,280개, Pole 클래스가 4,433개로 구성된다. 이 객체들은 훈련 데이터에 45,153개, 검증 데이터에 5,906개, 테스트 데이터에 5,738개 포함된다. 데이터 세트의 다양성과 대표성을 확보하기 위해, 본 연구는 실제 배전 현장의 다양한 환경적 조건과 기장 조건을 반영했다. 배경 환경별로 도시, 자연, 하늘의 주요 환경에서 자료를 수집하였다. 도시환경 데이터는 복잡한 상가와 고층 건물 구조와 전주가 뒤섞이는 실제 환경을 반영하며, 자연환경 데이터는 나무와 산간 지역의 전주

이미지를 포함한다. 하늘 데이터는 구름이 많은 날씨와 화창한 날씨의 이미지를 포함하여, 단순 배경 조건에서의 객체 탐지 성능도 함께 고려했다. 또한 기상 조건으로 맑음, 흐림에서 촬영된 데이터를 확보하여, 맑은 날씨 데이터는 전주의 명확한 경계와 뚜렷한 특징을 가지며, 흐린 날씨 데이터는 낮은 대비의 환경에서의 전주 이미지를 포함한다. 이와 같이 조명과 명암의 변화에 따른 모델의 높은 일반화 성능을 위해 데이터를 반영했다.

표 1. Composition of Images and Annotated Objects for Training, Validation, and Testing

Data Type	Number of Images	Wire Objects	Crossarm Objects	Pole Objects	Total Objects
Training	3,585	33,239	8,365	3,549	45,153
Validation	443	4,582	884	440	5,906
Test	447	4,263	1,031	444	5,738
Total	4,475	42,084	10,280	4,433	56,797

기존의 경계 상자 레이블링(Bounding Box Labeling)은 객체의 경계를 사각형으로 표시하는 방식으로, 전선과 전주처럼 복잡한 구조를 가진 객체에서는 정확한 윤곽을 표현하는 데 한계가 있다. 특히, 전선의 경우 교차하거나 겹치는 경우가 많아 경계 상자 레이블링 방식으로는 개별 객체를 명확히 구분하기 어렵다.

얇고 복잡하게 교차하거나 겹치는 객체는 경계 상자 레이블링을 사용할 경우 객체의 실제 영역 보다 더 넓은 배경이 포함되거나, 서로 다른 객체의 영역이 침범되어 정확한 인식이 어렵다. 실제로 경계 상자 레이블링을 활용한 라벨링에서는 이러한 침범 현상으로 인해 객체 구분이 불명확해지고, 모델 학습 시 오 텀지 및 미탐지 문제 가 발생할 수 있다.

반면, 분할 레이블링은 픽셀 단위로 객체의 경계를 표현하므로, 얇고 복잡한 객체의 실제 형태를 정밀하게 반영할 수 있다. 이러한 방식은 교차, 겹침, 미세한 구조에서 경계 상자 레이블링 방식에 비해 우수한 성능을 보이며, 얇은 객체를

대상으로 한 연구 Mask R-CNN 기반 검출 성능 비교 실험[19]에서도 분할 레이블링이 더 정밀한 객체 구분과 실질적인 성능에 유리함을 확인했다.

이에 본 연구에서는 Roboflow의 Data Annotation Tool을 활용하여 분할 레이블링 (Segmentation Labeling) 방식으로 레이블링을 수행한다. 분할 레이블링 방식을 사용하여 픽셀 단위의 마스크를 생성함으로써 객체의 윤곽을 정확히 분석하고 교차하는 부분에 대해서 개별 객체 인식을 가능하게 한다. 경계 상자 레이블링과 분할 레이블링을 적용한 예시는 그림 1에서 확인할 수 있다.

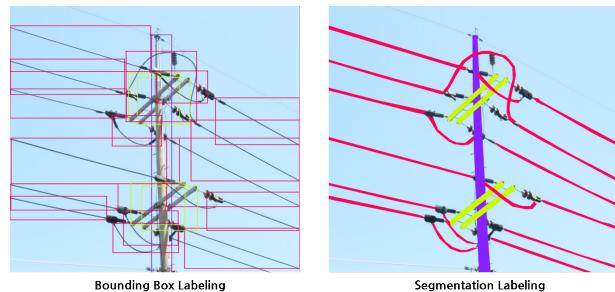


그림 1. Comparison Between Bounding Box Labeling and Segmentation Labeling for Power Line Infrastructure Detection

정확한 객체 탐지를 위한 데이터 레이블링의 품질을 높이기 위해, 다양한 상황에서 전선과 전주를 정확히 인식하고자 한다. 이를 위해 모델의 일반화 성능을 향상하고 다양한 환경에서 높은 정확도를 유지할 수 있도록 데이터 증강(Data Augmentation) 기법을 적용했다. 데이터 증강 기법의 예는 그림 2와 같다. 증강 방법으로 수평 반전(Horizontal Flip), 기울기 변환(Shear Transformation), 채도 변환(Saturation Transformation)을 사용했다. 수평 반전은 전선과 전주가 좌우로 대칭되는 상황을 모사하여 모델의 방향 불변성을 보장한다. 기울기 변환은 다양한 촬영 각도와 위치에 따른 객체의 여러 시점에서 객체 인식을 높이기 위해 적용했다. 채도 변환은 햇빛이 강한 날과 흐린 날과 같이 서로 다른 조명 환경을 반영하여 적용했다. 이러한 데

이터 증강 기법들을 통해 레이블링 과정에서 발생할 수 있는 편향을 최소화하고, 단순한 데이터 증가가 아닌 단순한 데이터 증강 기법을 넘어서, 실제 현장 환경을 반영한다.

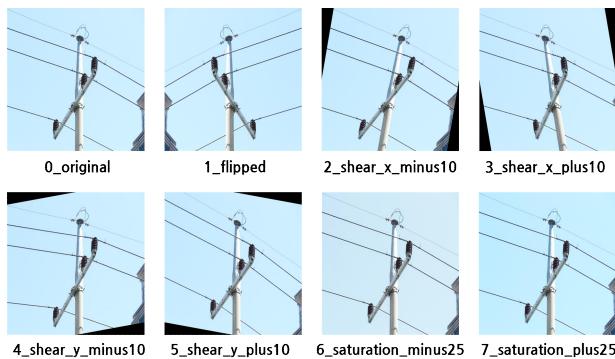


그림 2. Data Augmentation Techniques Applied to Utility Pole Images for Training Enhancement

3.2 객체 탐지 모델

본 연구는 전선을 탐지하기 위해 딥러닝 기반 객체 탐지 모델 사용한다. 전선은 복잡하고 불규칙한 형태를 가지며, 크기가 작고 배경과 명확한 대비가 부족한 경우가 많아 탐지하는 데 어려움이 있다. 본 연구에서는 전선 탐지 성능을 극대화할 수 있는 객체 탐지 모델을 선정하고 딥러닝 모델 간 분석을 통한 최적의 모델을 도출한다. 전선 탐지 성능을 비교하기 위해 YOLO 계열 객체 탐지 모델과 Transformer[15,16] 기반 모델을 포함한 5가지 모델을 선정하여 성능을 비교한다.

YOLO 계열 모델은 실시간 객체 탐지와 작은 객체 탐지에 강점이 있는 FPN(Feature Pyramid Network)과 PAN(Path Aggregation Network) 구조를 사용한다. FPN은 전주의 다양한 스케일의 객체를 효과적으로 탐지하기 여러 해상도와 특징 맵(Feature Map)을 생성하는 구조로 되어 있다. Bottom-UP Pathway에서 추출된 다양한 특징들을 Top-down Pathway를 통해 결합하여, 저해상도 특징 맵을 생성하는 구조이다. 이는 전선과 같이 다양한 복잡한 형태의 객체 탐지에 효과적이다. PAN은 FAN의 확장 구조로, 전선의 위치 정보와 연결 상태를 더욱 효과적으로 결합하여 정확한 객체 탐지가 가능하다.

이는 전선의 교차와 같은 복잡한 객체 탐지에 유리하다.

Mask R-CNN+ResNet50+FPN은 정확한 객체 경계 검출에 특화된 모델이다. 전선과 같이 복잡한 객체 구조를 정밀하게 탐지할 수 있어 비교 모델에 사용했다. 특히 픽셀 수준의 Segmentation이 가능하여 전선의 정확한 위치와 형태를 파악하는 데 유리하다. Mask R-CNN은 Object Detection과 Instance Segmentation을 동시에 수행하는 Two-stage 탐지 모델이다. 객체의 위치와 클래스를 예측하는 기준의 Faster R-CNN에서 객체의 픽셀 수준의 마스크를 생성하는 모델로 특정 맵의 양자화로 인한 정보 손실을 최소화하고, 정확한 공간 정보를 유지함으로써 정밀한 마스크 생성이 가능하다. ResNet50은 Residual Connection을 통해 깊은 네트워크에서도 기울기 소실 문제(Vanishing Gradient Problem)를 해결하고 효과적인 특징 추출이 가능하여, 복잡한 시각적 패턴을 학습할 수 있어 사용했다.

ConvNeXT은 CNN 기반의 Vision Transformer 구조를 적용한 모델로, 대규모 데이터 세트에서 학습 및 복잡한 특징 추출에 강점이 있다. 기존의 CNN의 지역적 특징 추출 능력과 Transformer의 전역적인 관계 모델링 능력을 결합하여 CNN을 통해 추출된 특징을 Transformer Encoder에 전달하여 긴 전선의 특징을 효과적으로 판단한다. Self-Attention을 사용하여 이미지의 서로 다른 부분 간의 관계를 학습하여 전역적인 특징을 포착한다. 이는 전선의 연속적인 구조를 탐지하는데 유용하다.

3.3 이상 탐지 모델

본 연구는 복잡한 환경에서의 실제 응용 가능성을 평가하기 위해 사전 학습된 YOLO, Mask R-CNN, ConvNet 모델을 활용해 객체를 탐지하고, 2DCNN을 이용해 탐지된 객체의 이상을 판별한다. 알고리즘의 설계 과정은 다음과 같다. 먼

저 이상 탐지가 필요한 두 시점의 이미지를 회색조(Grayscale)로 변환하여 불필요한 색상 정보를 제거하여 객체의 형태와 구조적 특징을 확인한다. 이후 사전 학습된 객체 탐지 모델을 적용하여 전주 설비 객체를 탐지하고, 탐지된 객체의 중심 좌표를 추출하여 이상 변화 분석의 기준점으로 활용한다. 특징점 매칭(Feature Point Matching)을 통해 두 이미지 간 객체의 대응 관계를 확인한다. 매칭된 객체들의 중심 좌표를 비교하기 위해 유클리드 거리 기반 분석을 수행하여 위치 변화를 계산한다. 추출된 특징 맵은 2DCNN에 입력되어 심층적인 특징 학습과 패턴 인식된다. 2DCNN은 공간적 특징을 효과적으로 포착하여 미세한 구조를 감지할 수 있으며, Convolution Layer를 통해 이미지의 계층적 특징을 추출함으로써 이상 탐지의 정확도를 향상한다. CLAHE 기법으로 이미지 대비를 향상 후 이미지 차분 분석을 통해 변화 영역을 검출하고, 이를 히트맵(Heat map)으로 시각화하여 변화 정도를 직관적으로 파악한다. 최종적으로 기존 이미지와 새로운 이미지 간의 IOU(Intersection Over Union)와 차이 비율을 계산함으로써 객체의 형태 변화를 평가하고 전력 설비의 이상 상태를 효과적으로 탐지한다.

유클리드 거리 계산 수식은 (1)과 같이 사용했다. 사전 학습된 모델에서 과거 이미지의 중심 좌표와 현재 이미지의 중심 좌표를 추출한다. 과거 이미지에서 중심 좌표와 현재 이미지의 중심 좌표를 비교하여 분석한다. 계산식에 제곱을 사용하는 이유는 전선의 큰 변화에 더 민감하게 반응하고 음수 거리를 방지하여, 미분 가능성을 확보한다. 최종적으로 값은 두 이미지 간의 이동 거리로 이 값이 임곗값이 초과하면, 객체가 이동으로 판단해 이상 감지를 한다. 이는 전선의 늘어짐이나 끊어짐으로 인한 구조적 변형을 객체 중심 좌표의 변화로 감지한다.

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (1)$$

본 연구에서는 이상 영역을, 2DCNN으로 활용하여 단순한 픽셀 차이의 분석이 아닌, 변화된 영역의 구조적 특성을 비교한다. 전선은 일반적으로 가늘고 길게 이어진 선형 구조를 가져 이를 탐지하기 위해 입력 이미지에 특징 맵을 생성한다. 이후 에지 강조(Edge Enhancement) 기법을 추가하여 미세한 이상을 탐지한다. 이 과정에서 필터링된 특징 맵을 직접 분석하고 대비 차이가 발생하는 여부를 확인한다.

추출된 특징을 더욱 정교하게 조정하고, 구조적 일관성을 유지하기 위해 BatchNormalization2D와 ReLU(Rectified Linear Unit) 활성화 함수를 적용하여 특징 맵의 표현력을 극대화하였다. Convolution Layer를 적용하여 지역적인 특징을 정제하고, 이후 BatchNormaliation2D를 사용하여 조명의 변화나 이미지 잡음에 대한 영향을 최소화했다. 이를 통해 전선과 전주와 같은 구조적 객체의 특징을 안정적으로 유지한다. 변화 영역을 검출하는 과정에 강도를 계산하여 변화 임곗값을 적용하여 최종 변화 영역을 결정한다. 이 과정에서 Sigmoid 활성화 함수를 추가하여 변화 강도를 0~1 범위로 매핑(Mapping)했다.

2DCNN을 활용하여 이상 탐지 영역에 대한 강도를 계산하여 히트맵으로 변환한다. 히트맵은 전선, 전주, 완철 객체의 변화를 시각화하며, 이상 탐지에 변화된 영역을 쉽게 식별한다. 히트맵 수식은 (2)와 같이 사용했다. 는 변화의 강도를 나타내는 값으로, 각 객체의 에서 변화량을 나타낸다. 은 1부터 까지 합으로 은 탐지된 객체의 수이다.는 각 객체의 가중치를 부여하며, 가중치가 높을수록 중요도를 나타낸다. 값은 자연로그의 밑수로 약 2.718… 의 값을 가진다. 이는 거리에 따라 영향력이 급격히 감소하지 않고 자연스럽게 감소하게 된다. 값은 유클리드 거리의 제곱 값으로 히트맵을 생성할 때 멀리 있는 객체의 영향력을 감소한다. 은 가우시안 커널(Gaussian Kernel) 폭을 결정하는 값으로 객체 주변의 영역

변화를 탐지하며 전선은 얇은 형태로 이루어져 있어 전주와 완철에 비해 낮은 값으로 설정했다.

$$H = \sum_{i=1}^n w_i e^{-\frac{(x_2 - x_1)^2 + (y_2 - y_1)^2}{2\sigma^2}} \quad (2)$$

최종적으로 기존의 이미지와 새로운 이미지 간의 IOU와 차이값을 계산하여 객체의 형태 변화를 평가하고 전력 설비 이상 상태를 녹색으로 오버레이 하여 객체의 이상 탐지를 평가한다.

IV. 실험 및 결과

4.1 객체 탐지 성능 평가

제안하는 배전 공기 탐지에 사용될 모델로 YOLOv8l-seg, YOLOv9c-seg, YOLOv11l-seg, ConvNeXT, Mask R-CNN+, ResNet50+FPN 총 5개의 모델을 비교했다. 모델 별 학습 조건의 일관성을 위해 모든 모델에 동일한 하이퍼 파라미터를 적용했다. 모델 훈련 시 에폭 수는 100, 200, 300, 400, 500으로 설정하여 실험을 진행하였으며, 그 결과 500 에폭에서 가장 우수한 성능을 확인할 수 있었다. 배치 사이즈는 8로 고정하였고, 입력 이미지 크기는 640×640으로 통일하여 실험을 진행하였다. Early Stopping 기법의 patience는 30으로 설정하여 모델이 검증 데이터에서 더 이상 개선되지 않을 경우 학습을 중단했다. 데이터 로딩 속도 향상을 위해 DataLoader의 worker 수는 4로 조정하였다. 이 외의 다른 하이퍼파라미터(optimizer, learning rate 등)는 기준값으로 고정하였으며, 동일한 설정을 다른 모델 실험에도 일관되게 적용하여 결과의 신뢰성을 높였다. 이러한 조건으로 훈련된 모델들을 성능 평가하기 위해, 정밀도(Precision), 재현율(Recall), mAP50(Mean Average Precision), mAP50-95, F1-score를 평가 지표로 사용했다. 표 2는 모델 성능 비교 환경을 나타낸다.

표 2. Hardware and Software Specifications

Component	Details
Operating System	Windows 10
Central Processing Unit	Intel Core i9 12900KF
Programming Language	Python3.8.16
Deep Learning Library	PyTorch 2.3.1+cu118
Random Access Memory	64GB(DDR4-3600 16GB*4)
Graphics Processing Unit	NVIDIA GeForce RTX 3080 TI 12GB

본 연구는 5가지 모델 성능 비교를 위해 다양한 지표를 활용하여 수행했다. 전선과 같이 작은 객체 탐지 성능을 정확하게 평가할 수 있도록 정밀도, 재현율, mAP50, mAP50-95, F1 Score를 사용했다. 정밀도는 탐지된 객체 중 올바른 객체 비율을 측정하여 FP(False Poitive)를 줄이는 모델 성능을 평가하며, 재현율은 실제 객체의 올바른 탐지 비율을 측정하여 FN(False Negative)을 줄이는 모델 성능을 평가한다. mAP50는 50% 이상에서 평균 정밀도를 계산하여 객체 탐지 성능을 평가하고 F1 Score로 모델의 종합적인 성능을 평가한다. 이러한 평가 지표를 바탕으로 모델 별 성능을 비교 분석하고, 전선 탐지에 적합한 모델을 선정하여 실제 응용 가능성을 검증한다.

성능 지표로 정밀도는 모델이 탐지한 객체 중에 실제 객체인 비율을 의미하며, TP(True Positive)는 모델이 객체를 정확하게 탐지한 경우를 나타내며, FP는 모델이 존재하지 않는 객체를 잘못 탐지한 경우를 나타낸다. 수식 (3)과 같다. 재현율은 전체 객체 중에서 모델이 올바르게 탐지한 비율이며, 재현율 값이 크면 실제 객체를 놓치는 경우가 적음을 의미한다. FN은 모델이 탐지하지 못한 실제 객체를 의미한다. 수식 (4)와 같다. F1 Score는 Precision과 Recall 사이의 균형을 평가하는 지표로 Precision과 Recall을 모두 고려한 성능을 평가한다. 수식은 (5)와 같다.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1 Score = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

크mAP는 모든 클래스에 대한 AP의 평균으로 수식(6)과 같다. $\int_0^1 P(r)dr$ 는 정밀도 함수 $P(r)$ 의 변수 r 에 대해서 0부터 1까지 적분한다. $P(r)$ 는 재현율 값 r 에서의 정밀도를 나타낸다. (7)은 mAP로 $\frac{1}{N}$ 은 전선, 전주, 완철에 대한 클래스에 대한 쿼리를 구하기 위한 항이다. $\sum_{i=1}^N AP_i$ 은 각 클래스에 쿼리에 대한 AP값의 합을 의미한다. mAP50-95는 IoU를 0.5부터 0.95까지 0.05 간격으로 평균하여 계산한 값으로 IoU 값이 클수록 더 정확한 위치를 요구하므로 전선과 같은 높은 정확도가 있어야 하는 모델의 평가에 적합하다.

$$AP = \int_0^1 P(r)dr \quad (6)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (7)$$

$$mAP_{50-95} = \frac{1}{10} \sum_{t=0.5}^{0.95} mAP_t \quad (8)$$

정량적 평가 결과 전선, 전주, 완철에 대한 전체적인 성능 평가로 YOLOv11l-seg는 최신 모델임에도 불구하고 YOLOv8-seg 모델이 미세하게 우수한 성능을 보였다. 이는 YOLOv11l-seg는 더 높은 confidence threshold 적용하여 일부 작은 객체를 놓쳐 Precision과 Recall 값이 다소 낮게 측정된 것으로 보이며, YOLOv8l-seg는 다수의 작은 객체를 탐지하여 Precision과 Recall 값이 측정된 것으로 보인다. 전주, 전선, 완철과 같은 복잡하고 세밀한 구조의 객체를 탐지하는 과정 중 특정 객체 인식에서 과적합이 발생하여 전체적인 성능 저하로 이어진 것으로 판단된다. 그럼에도 불구하고 YOLO 계열 모델 YOLOv9c-seg, YOLOv11l-seg에서도 전반적으로 높은 성능을 보였다. 반면에 Mask R-CNN+ResNet50+FPN, Two-stage 구조로 인해 가늘고 교차하는 전선에 대한 특징 추출 과정

에서 정보 손실이 발생했을 가능성이 있으며, ConvNeXT는 Transformer 구조로 전역적 특징 추출에는 강점이 있으나 전선과 같은 지역적 특징이 중요한 객체 탐지에는 낮은 성능을 보여준 것으로 분석된다.

Transformer 기반 모델은 YOLO 기반 모델보다 상대적으로 저조한 성능을 보여줬으며 이는 YOLO 기반 모델이 배전 공기 탐지 모델에 접합함을 시사한다.

그러나 정량적 평가만으로는 실제 이상 탐지 성능을 완전히 평가하기 어려우므로, 정성적 평가를 통한 검증이 필요하다. 그림 3은 배전 공기 객체 탐지 모델의 전체적인 성능 결과를 방사형 그래프와 막대그래프로 나타낸 것이다. 표 3은 배전 공기 객체 탐지 모델의 전체적인 성능 결과를 표로 나타낸 것이다.

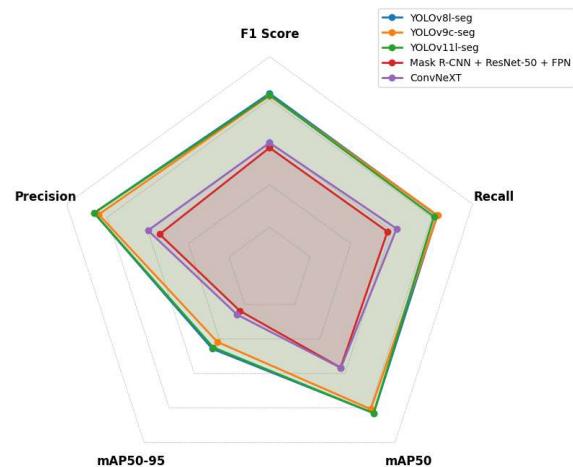
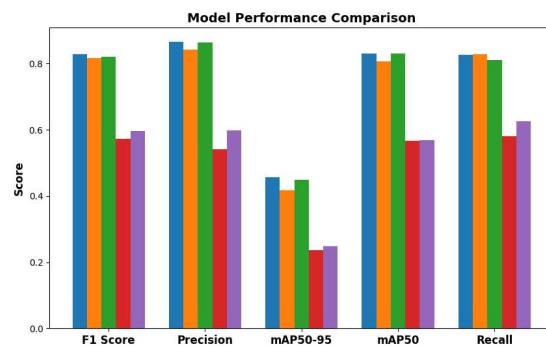


그림 3. Performance Comparison of Different Object Detection Models for Power Line Infrastructure Monitoring

표 3. Hardware and Software Specifications

Model	F1 Score	Precision	Recall	mAP50	mAP50-95
	PHR[%]	PHR[%]	PHR[%]	PHR[%]	PHR[%]
Mask R-CNN	0.573	0.542	0.581	0.566	0.237
ConvNeXT	0.596	0.599	0.626	0.568	0.249
YOLOv8l-seg	0.828	0.865	0.826	0.83	0.457
YOLOv9c-seg	0.817	0.842	0.828	0.807	0.417
YOLOv11l-seg	0.820	0.864	0.81	0.83	0.449

4.2 이상 탐지 성능 평가

배전 공가 관리 모델을 위한 이상 탐지 평가를 정성적 평가로 진행한다. 그림 4는 특징 정보를 단계별로 추출한 이미지이다. 1. Original Image는 원본 이미지로 기존 이미지와 현재 이미지를 보여주어 변화 탐지를 위한 기준을 제공한다. 2. Gray Scale Image는 원본 이미지를 흑백으로 나타내어 색상 정보를 제거하고 밝기 기반으로 이미지 처리하여 특징 추출을 개선한다. 3. Object Detection은 학습된 모델로 원본 이미지를 객체 탐지하여 객체를 구별하고 녹색 윤곽선으로 객체를 표시한다. 4. Image Difference는 두 이미지 간의 차이를 계산한다.

강조된 영역을 시각화하여 변화된 영역의 움직임을 탐지하는 데 사용한다. 5. Heat map Change Analysis로 변화된 영역을 표시하여 6. Final Analysis 단계에서 이전 단계에서 추출한 정보를 종합하여, 변화를 시각화해 배전 공가 관리 모델을 구축한다.

그림 5는 제안한 모델과 비교 대상 모델들의 이상 탐지 결과를 시각적으로 비교한 결과다. 기존 이미지에서 추가된 전선을 녹색으로 시각화 했다. YOLOv8l-seg 모델과 YOLOv9c-seg 모델의 경우 변화가 발생한 전선의 주위 인접한 전선까지 잘못 분류하는 오 탐지가 발생했다. 이는 Heat map Change Analysis 을 실행한 결과 Segmentation 영역이 지나치게 많이 생성되었고, 이에 따라 불필요한 영역까지 탐지하는 오 탐지가 발생한 것으로 보인다. 반면에 Mask R-CNN+

ResNet50+FPN과 ConvNeXT는 전선의 이상 영역을 탐지하지 못하는 모습을 보여주었다. 이는 객체 탐지 결과와 일치하는 경향을 보였으며, R-CNN+ResNet50+FPN과 ConvNeXT의 경우 영역 기반 분할 방식을 사용하여, 연속적인 선 형태의 영역을 효과적으로 탐지하지 못했을 가능성으로 보인다. 이러한 결과를 종합하면, 배전 공가 이상 탐지를 위해서 YOLOv11l-seg 모델이 가장 효과적이었으며, 전선의 이상 영역만을 정확하게 탐지하는 능력을 보였다.

따라서, 정량적 평가에서는 YOLOv8l-seg 모델이 미세하게 우수한 성능을 보였으나, 실제 배전 공가 이상 탐지의 응용에 있어서 더 중요한 정성적 평가에서는 YOLOv11l-seg 모델이 우수한 성능을 보였다. YOLOv8l-seg 모델이 정량적 평가에서 높은 성능을 보였음에도 정성적 평가에서 오 탐지가 발생한 원인은 미세한 변화까지 반응해 정상전선도 이상으로 판단한 것으로 보인다. YOLOv11l-seg 모델이 정성적 평가에서 우수한 성능을 보인 이유는 다른 YOLO 계열 모델에 비해 정밀한 Segmentation 성능으로 판단된다. 이는 YOLOv11l-seg의 개선된 Backbone Network와 Attention 메커니즘을 통해 변화가 발생한 전선의 정확한 경계를 식별하고 주변 정상전선을 명확히 구분한 것으로 보인다.

추가적으로 Mask R-CNN+ResNet50+FPN과 ConvNeXT 모델은 아예 이상이 추가된 전선을 탐지하지 못한 이미지가 존재한다. 특히, ConvNeXT의 경우 두 이미지 모두에서 추가 전선이 전

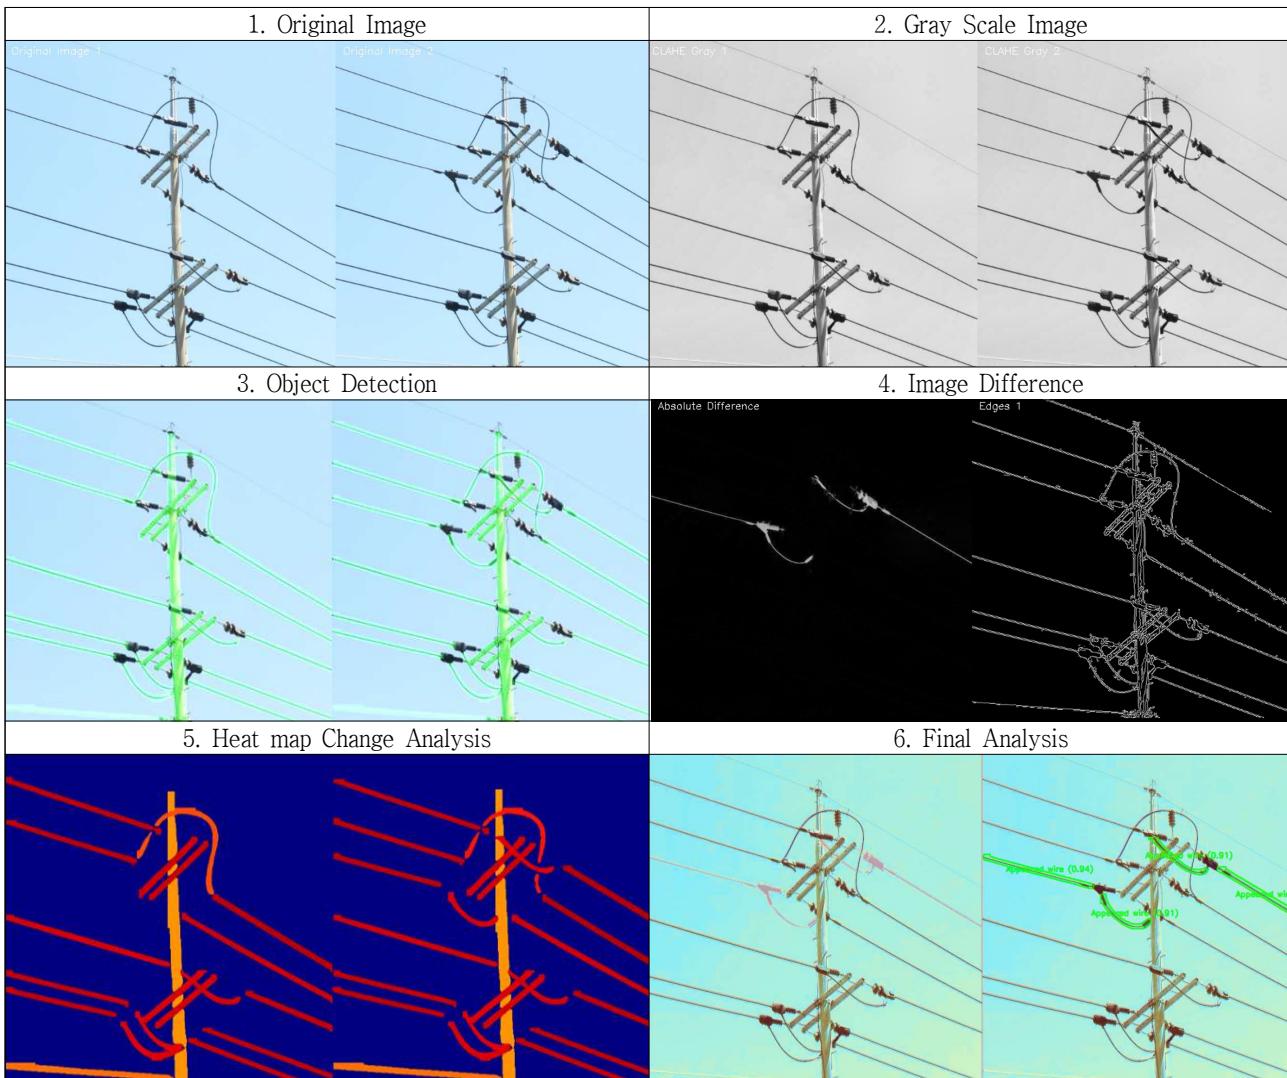


그림 4. Step-by-step Visualization of The Change Detection Process In Power Line Infrastructure

혀 탐지되지 않아, 실제 이상 탐지 응용에서는 활용이 어렵다는 점이 확인된다. 또한, YOLOv8l-seg와 YOLOv9c-seg 모델의 경우, 탐지된 이상 영역의 윤곽선이 뚜렷하지 않고, 실제 추가된 전선 외에 인접 정상전선까지 넓게 탐지하는 경향이 나타난다. 반면, YOLOv11l-seg 모델은 추가된 전선만을 명확하게 탐지하며, 탐지된 영역의 경계가 가장 뚜렷하게 나타난다. 구체적으로, YOLOv8l-seg의 경우 두 이미지 모두에서 녹색으로 표시된 탐지 영역이 실제 추가된 전선뿐만 아니라 그 위아래 인접한 다수의 정상전선까지 포함하여 탐지 영역이 수직으로 과도하게 확장되어 있다. YOLOv9c-seg는 탐지가 된 오른쪽 이미지에서도 실제 추가 전선 외에 주변 정상 전

선들까지 함께 탐지하는 오탐지 현상이 나타났다. 반면, YOLOv11l-seg는 오른쪽 이미지에서 추가된 전선의 위치와 형태를 정확히 파악하여, 해당 전선에만 국한된 탐지 영역을 보여준다. 탐지된 녹색 영역이 실제 추가 전선의 경계와 정확히 일치하며, 인접한 정상 전선들은 탐지 영역에서 완전히 제외되어 있어 높은 정밀도를 보여준다. 이러한 결과를 종합하면, 육안으로 확인했을 때 이상 탐지율이 가장 높고, 실제 추가된 전선만을 정확하게 탐지한 모델은 YOLOv11l-seg임을 알 수 있다. 반면, Mask R-CNN+ResNet50+FPN과 ConvNeXT는 이상이 있는 전선을 아예 탐지하지 못하거나, 일부 이미지는 완전히 탐지에 실패하는 한계가 있다.

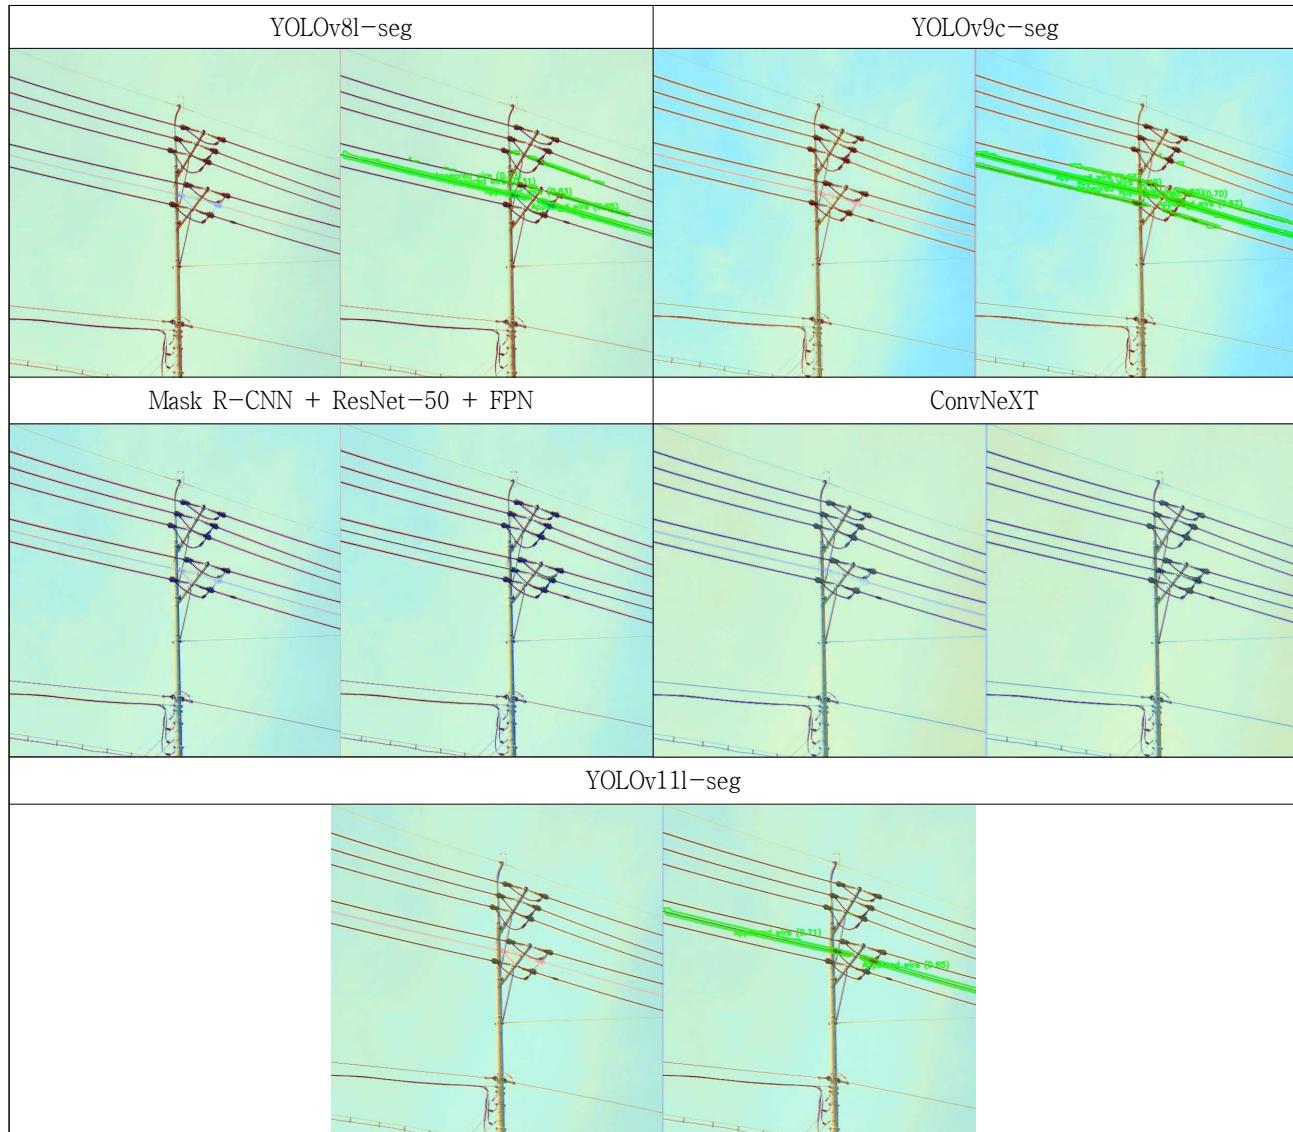


그림 5. Comparative Analysis of Object Detection Models for Power Line Infrastructure

본 연구에서는 배전 공가에서 불법 설치된 전선 탐지 모델의 정량적 평가만으로는 실제 배전 환경에서의 신뢰성 있는 판단 기준을 확보하기 어렵다고 판단하였으며, 이에 따라 정성적 평가를 실시하였다. 정성적 평가 기준으로 실제 배전 공가 환경에 적합함과 모델의 한계점 파악으로 정했으며, 이러한 정성적 평가 기준에서 YOLOv11l-seg 모델은 배전 공가 데이터세트의 특성인 밀집된 전선 환경과 미세한 이상 변화를 효과적으로 처리하며, 다른 모델들에서 나타난 정상전선을 이상으로 판단하거나 이상 전선을 탐지하지 못하는 문제를 감소시켰다. 정량적 평가 기준 가장 우수한 성능을 보였으며, 실제 현

장에서의 신뢰성과 실효성을 입증하였다.

최종적으로 정량적 평가와 정성적 평가를 종합적으로 진행한 결과, YOLOv11l-seg 모델이 배전 공가 이상 탐지에 가장 적합한 성능을 보였다. 이에 본 연구는 최종적으로 YOLOv11l-seg 모델을 선정하였다. 높은 정밀도와 낮은 오 편차율을 달성했으며, 실제 응용 환경에서의 신뢰성과 실효성을 고려할 때 가장 우수하다고 판단된다.

실제 응용 환경에서의 실시간 성능 처리와 계산 복잡도에 대한 분석이 제한적인 상황에서, 실제 배전 현장에서의 적용 가능성을 판단하기 위해 정량적 평가와 정성적 평가에서 높은 성능을

보인 YOLOv8l-seg과 YOLOv11l-seg 학습 모델의 가중치 파일 크기, 평균 추론 시간을 제시한다. YOLOv8l-seg 모델의 가중치 파일의 크기는 88MB, YOLOv11l-seg는 63MB 크기로 판단이 필요한 두 이미지에 대해 YOLOv8l-seg 모델에서는 평균 처리시간 첫 번째 이미지 19.17ms 두 번째 이미지 19.67ms 가 나왔으며, YOLOv11l-seg 모델에서는 첫 번째 이미지 21.46ms 두 번째 이미지 20.15ms로 실시간 처리 속도로 이는 0.02초 정도로 실시간 처리에 사용되는 30fps 기준에 적합함을 실험적으로 입증했다.

V. 결 론

본 연구는 배전 공가 시설물의 효율적인 이상 탐지를 위한 딥러닝 기반 모델을 제안하고 그 성능을 검증했다. 전력 인프라의 안전성과 효율적 관리가 중요한 과제로 부상하는 가운데, 무단 통신 설비 설치 문제와 같은 안전 위협에 대응하기 위한 기술적 접근으로서 YOLOv11l-seg 기반 배전 공가 이상 탐지 모델의 가능성을 검증했다. 다양한 객체 탐지 모델과의 성능 비교 결과, YOLOv8l-seg 모델이 F1 Score, mAP50, Precision, Recall 측면에서 미세하게 우수한 성능을 나타냈으나, 배전 공가의 실제 응용 가능성을 평가하기 위해 정성적 평가를 진행했을 때 오탐지가 발생하는 결과가 있었다. 반면, YOLOv11l-seg 모델에서는 기존 YOLO 계열 모델들이 가지고 있던 경계 영역의 오탐지 문제를 개선하고, 동시에 다른 CNN 기반 모델들이 놓치는 세밀한 선형 구조의 이상 영역을 효과적으로 포착했다. 특히 배전 공가 시설물의 복잡한 구조적 특성과 단순 객체 검출을 넘어 이상 영역의 정확한 위치와 형태를 식별하는 강점을 보였다.

본 연구 결과는 전력망 인프라 관리 분야에서 딥러닝 기반 이상 탐지 기술의 적용 가능성을 보여주며, 무인 드론이나 자율점검 시스템과 연계했을 때 인력 기반 점검의 한계를 극복하고 효율

적인 전력 인프라 체계에 활용될 수 있음을 시사한다. 향후 연구에서는 유클리드 거리 계산 방식을 활용하여 전봇대의 기울어짐과 전선의 처짐의 이상 탐지와 다양한 환경 조건에서의 모델 성능 검증에 관한 연구가 필요할 것으로 판단된다. 결론적으로, 본 연구에서 제안한 배전 공가 이상 탐지 시스템은 전력 인프라의 유지보수 효율성을 높일 것으로 기대된다.

REFERENCES

- [1] Y. Liu, "Fine-tune BERT for Extractive Summarization," *arXiv preprint arXiv:1903.10318*, 2019.
- [2] J. Zhang, Y. Zhao, M. Saleh, and P. Liu, "PEGA SUS: Pre-training with Extracted Gap-sentences for Abstractive Summarization," *Proceedings of the 37th International Conference on Machine Learning*, vol. 119, pp. 11328–11339, Jul. 2020.
- [3] L. Basyal, and M. Sanghvi, "Text Summarization Using Large Language Models: A Comparative Study of MPT-7b-instruct, Falcon-7b-instruct, and OpenAI Chat-GPT Models," *arXiv preprint arXiv:2310.10449*, 2023.
- [4] Team Gemma, et al. "Gemma 2: Improving Open Language Models at a Practical Size," *arXiv preprint arXiv:2408.00118*, 2024.
- [5] AI-Hub(n.d.). <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=&topMenu=&aihubDataSet=data&dataSetSn=97> (accessed May, 16, 2025).
- [6] Unsloth(n.d.). <https://docs.unsloth.ai/> (accessed May, 16, 2025).
- [7] E. J. Hu, Y. Shen, P. Wallis, Z. Allen-Zhu, Y. Li, S. Wang, and W. Chen, "Lora: Low-Rank Adaptation of Large Language Models," *International Conference on Learning Representations*, Apr. 2022.
- [8] Z. Hu, L. Wang, Y. Lan, W. Xu, E. Lim, L. Bing, X. Xu, S. Poria, and R. K. Lee, "LLM-Adapters: An Adapter Family for Parameter-Efficient Fine-Tuning of Large Language Models," *arXiv preprint arXiv:2304.01933*, 2023.
- [9] G. Adams, A. R. Fabbri, F. Ladha, E. Lehman, and N. Elhadad, "From Sparse to Dense: GPT-4 Summarization with Chain of Density Prompting," *In Proceedings of the Conference on Empirical Methods in Natural Language Processing. Conference on Empirical Methods in Natural Language Processing*, vol. 2023, no. 4, pp. 68–74, Dec. 2023.
- [10] M. S. Aissi, C. Romac, T. Carta, S. Lamprier,

- P. Oudeyer, O. Sigaud, L. Soulier, and N. Thome, "Reinforcement Learning for Aligning Large Language Models Agents with Interactive Environments: Quantifying and Mitigating Prompt Overfitting," *arXiv preprint arXiv:2410.19920*, 2024.
- [11] S. U. Park, and J. Y. Kang, "Analysis of Prompt Engineering Methodologies and Research Status to Improve Inference Capability of ChatGPT and Other Large Language Models," *Journal of Intelligence and Information Systems*, vol. 29, no. 4, pp. 287–308, Dec. 2023.
- [12] T. Zhang, V. Kishore, F. Wu, K. Q. Weinberger, and Y. Artzi, "BERTScore: Evaluating Text Generation with BERT," *arXiv preprint arXiv:1904.09675*, 2019.
- [13] D. Y. Lee, M. C. Shin, T. S. Whang, S. W. Cho, B. G. Ko, D. Lee, E. G. Kim, and J. C. Jo, "Reference and Document Aware Semantic Evaluation Methods for Korean Language Summarization," *arXiv preprint arXiv:2005.03510*, 2020.
- [14] T. Dettmers, A. Pagnoni, A. Holtzman, and L. Zettlemoyer, "QLoRA: Efficient Finetuning of Quantized LLMs," *Advances in Neural Information Processing Systems*, Vol. 36, pp. 10088–10115, 2023.
- [15] Google AI Studio(n.d.). https://aistudio.google.com/app/prompts/new_chat?model=gemma-2-9b-it (accessed May, 16, 2025).
- [16] C. Y. Lin, "ROUGE: A package for Automatic Evaluation of Summaries," *Text Summarization Branches Out*, pp. 74–81, Jul. 2004.
- [17] S. S. Lee, and S. W. Kang, "Empirical Study for Automatic Evaluation of Abstractive Summarization by Error-Types," *Korean Journal of Cognitive Science*, vol. 34, no. 3, pp. 197–226, Sep. 2023.
- [18] D. Kalajdzievski, "A Rank Stabilization Scaling Factor for Fine-Tuning with LoRA," *arXiv preprint arXiv:2312.03732*, 2023.
- [19] I. Loshchilov, and F. Hutter, "Decoupled Weight Decay Regularization," *arXiv preprint arXiv:1711.05101*, 2017.
- [20] H. Zhou, X. Lu, W. Xu, C. Zhu, T. Zhao, and M. Yang, "LoRA-drop: Efficient LoRA Parameter Pruning based on Output Evaluation," *Proceedings of the 31st International Conference on Computational Linguistics*, pp. 5530–5543, Jan. 2025.

저자 소개



이훈제(준회원)

2020년~현재 순천대학교 인공지능공학부 학사과정.

<주관심분야 : 객체탐지, 딥러닝, 컴퓨터 비전>



김진성(정회원)

2020년 순천대학교 컴퓨터공학과 학사 졸업(공학사).

2022년 순천대학교 컴퓨터공학과 석사 졸업.

2024년~현재 순천대학교 IT-Bio 융합 시스템전공 박사과정.

<주관심분야 : 컴퓨터 비전, 딥러닝, 어텐션, 데이터분석>



정세훈(정회원)

2012년 국립순천대학교 멀티미디어공학과 졸업(공학석사).

2017년 국립순천대학교 멀티미디어공학과 졸업(공학박사).

2018년 영산대학교 빅데이터융합전공 조교수.

2020년 안동대학교 창의융합학부 조교수.

2022년~현재 국립순천대학교 컴퓨터공학과 조교수.

<주관심분야 : 소프트웨어공학, 강화학습, 블록체인, 딥러닝, 데이터 마이닝, 빅데이터 분석 및 예측>



심춘보(정회원)

1996년 전북대학교 컴퓨터공학과 졸업(공학사).

1998년 전북대학교 컴퓨터공학과 졸업(공학석사).

2003년 전북대학교 컴퓨터공학과 졸업(공학박사).

2005년~현재 국립순천대학교 인공지능공학부 교수.

<주관심분야 : 빅데이터, 블록체인, 딥러닝, 생성모델, 자연어처리, 강화학습>