

## 인공지능 기반 전력설비 고장 예측 및 예방 시스템 구축

이근우\* 장창민\* 김유진\*  
한국전력공사\*

### Implementation of an AI-Based Predictive Maintenance System for Power Equipment

Geun Woo Lee\* Chang Min Jang\* Yu Jin Kim\*  
KEPCO

**Abstract** - 본 연구는 AI 기반 예측 정비 시스템을 제안하여 전력설비에서 발생할 수 있는 고장을 사전에 예측하고 이를 바탕으로 예방 정비를 수행하는 체계를 구축한다. 기존의 정기 예방정비와 고장 후 복구 방식은 설비 상태를 충분히 반영하지 못해 정전 사고와 과도한 유지보수 비용을 초래하고 있었다. 이에 따라 본 연구는 SCADA 시스템과 IoT 센서를 활용하여 실시간 데이터를 수집하고, 수집된 데이터를 AI 모델을 통해 분석하여 고장 확률을 예측한다. 예측된 고장 확률에 따라 경고 시스템이 작동하며, 이를 바탕으로 운영팀은 정비 우선순위를 조정하고 예방 정비를 수행한다. 또한, 현장 점검 결과는 AI 모델에 피드백되어 모델 성능을 지속적으로 향상시킨다. 본 연구는 디지털 전환을 위한 기술적 기반을 제공하며, 향후 현장 적용을 통해 실효성을 검증할 예정이다.

## 1. 서 론

### 1.1 연구 배경 및 필요성

전력설비의 안정적인 운영은 대규모 정전 예방과 전력 품질 유지를 위해 필수적인 요소이다. 그러나 기존의 예방 정비는 설비 상태와 관계없이 정기적인 점검을 실시하거나, 고장 발생 후 복구 방식에 의존하고 있어 고장 예방에는 한계가 있다. 특히, 돌발 고장으로 인한 정전 사고는 사회적, 경제적 피해를 초래하며, 설비의 운영 효율성을 저하시킬 수 있다. 이러한 문제를 해결하기 위해 AI 기반 예측 정비 시스템이 필요하며, 이 시스템은 실시간으로 수집된 데이터를 바탕으로 고장 확률을 예측하고, 예방 정비를 통해 고장의 발생을 사전에 방지할 수 있다.

### 1.2 연구 목적

본 연구의 목적은 AI 기반 예측 정비 시스템을 설계하고, 이를 통해 전력설비에서 발생할 수 있는 고장 예측과 예방 정비를 실현하는 것이다. 구체적으로, SCADA 시스템과 IoT 센서를 통해 실시간 데이터를 수집하고, 이를 AI 모델에 입력하여 고장 확률을 예측한다. 예측된 고장 확률에 따라 경고 시스템이 작동하고, 정비 우선순위 조정을 통해 예방 정비가 이루어진다. 또한, 현장 점검 결과는 모델 재학습에 사용되어 시스템의 예측 성능을 지속적으로 향상시킨다. 본 연구는 이론적 모델을 바탕으로 한 성능 평가를 통해 디지털 전환을 위한 기술적 기반을 마련하는 것을 목표로 한다.

## 2. 본 론

### 2.1 시스템 개요

제안된 시스템은 하드웨어, 소프트웨어, 운영 프로세스의 세 가지 주요 계층으로 구성된다. 하드웨어 계층에서는 SCADA 시스템과 IoT 장치를 통해 전력설비의 실시간 데이터를 수집한다. 소프트웨어 계층에서는 수집된 데이터를 AI 모델에 입력하여 고장 확률을 예측한다. 예측된 고장 확률을 바탕으로 경고 시스템이 작동하여 운영팀에 경고를 전달하며, 운영 프로세스 계층에서는 정비 우선순위를 조정하고, 점검 후 점검 결과를 AI 모델에 피드백하여 모델 성능을 향상시킨다.



<그림 1> 시스템 개념도

### 2.2 시스템 모델 구성

본 연구에서는 Random Forest, XGBoost, LSTM, CNN을 포함한 다양한 AI 모델을 사용하여 고장 예측을 수행한다. 각 모델은 전력설비에서 수집되는 센서 데이터(온도, 진동, 전류 등)를 학습하여 고장 발생 가능성을 예측한다. 모델 학습은 Python을 사용하여 TensorFlow 또는 scikit-learn과 같은 라이브러리로 진행하며, 훈련된 모델은 Flask나 FastAPI와 같은 웹 프레임워크를 통해 API 형태로 배포된다. 이를 통해 실시간 예측을 제공하고, 예측된 고장 확률을 바탕으로 경고를 발생시킨다.

#### 2.2.1 고장 예측 임계값 설정 기준

고장 예측 임계값은 AI 모델이 출력한 고장 확률을 기준으로 설정되며, 이 값이 특정 수치를 초과할 경우 경고를 발생시킨다. 임계값 설정은 과도한 경고(오탐)와 경고 누락(미탐) 사이의 균형을 고려하여 조정된다. 본 연구에서는 F1 스코어가 최대화되는 지점을 기준으로 임계값을 80% 수준으로 설정하였으며, 이는 모델이 예측한 고장 확률이 0.80을 초과할 경우 실제 고장 가능성이 높다고 판단하여 경고를 발령하도록 설계하였다. 이와 같은 임계값 설정은 이후 정비 우선순위 판단의 기초 데이터로 활용된다.

#### 2.2.2 정비 우선순위 조정 로직

정비 우선순위는 AI 모델이 예측한 고장 확률 값을 기반으로 계층적으로 조정된다. 고장 확률이 85% 이상인 설비는 즉시 점검 대상으로 분류되며, 70~85% 구간은 예방 정비 대상, 50~70%는 정기 점검의 우선순위로 설정된다. 이러한 분류는 단순히 임계값 초과 여부만을 기준으로 하지 않고, 전체 자원 배분과 정비 일정 최적화를 반영하여 결정된다. 또한, 정비 수행 후 점검 결과는 모델의 재학습에 반영되어, 추후 고장 예측의 정확도를 높이기 위한 피드백 루프를 형성한다.

### 2.3 성능 평가 지표

본 연구에서는 고장 예측 모델의 성능을 정량적으로 분석하기 위해 분류 모델의 성능 평가 지표를 적용하였다. 모델 평가에 사용된 주요 지표로는 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 스코어, AUC (ROC Curve)가 있으며, 이는 분류 모델의 예측 성능을 다각도로 평가하는데 유용하다. 정확도는 전체 예측 중 정답 비율을 나타내며, 정밀도는 모델이 고장이라고 예측한 설비 중 실제 고장 비율을 의미한다. 재현율은 실제 고장 설비 중에서 모델이 올바르게 예측한 비율을 의미하며, F1 스코어는 정밀도와 재현율의 조화 평균으로 두 지표 간 균형을 평가한다. ACU는 ROC 곡선 아래의 면적으로, 값이 1에

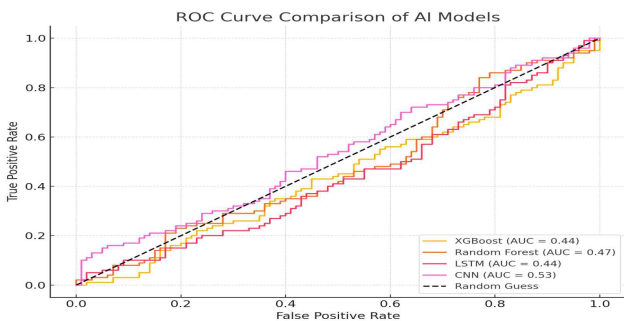
가까울수록 우수한 분류 성능을 의미한다. 본 논문에서는 이들 지표를 바탕으로 AI모델의 고장 예측 능력을 정량화하여 성능을 비교하였다.

### 2.3.1 모델 성능 비교 절차

본 연구에서는 실제 설비 데이터를 확보하기 어려운 보안 환경을 고려하여, 가상의 센서 데이터를 구성하고 이를 기반으로 4개의 AI 모델에 동일한 입력을 제공하였다. 각 모델은 해당 입력값을 통해 고장 확률을 예측하였으며, 정확도, 정밀도, 재현율, F1 스코어, AUC와 같은 성능 지표는 이 가상 데이터 기반 예측 결과를 정량적으로 분석하여 도출하였다.

모든 모델은 Python 기반 환경에서 scikit-learn, TensorFlow, XGBoost 등의 오픈소스 라이브러리를 활용하여 구현되었으며, 모델 학습과 성능 평가는 동일한 조건에서 수행되었다. 입력값은 온도, 진동, 유증가스 농도, 부하 전류 등 전력설비에서 일반적으로 수집 가능한 센서 데이터를 기반으로 가상 생성하였고, 목표 변수는 이진 분류 형태의 고장 여부로 설정되었다.

AI 모델 훈련은 전체 데이터 중 80%를 훈련 데이터로, 20%를 테스트 데이터로 사용하여 수행되었으며, 성능 평가는 테스트 데이터셋에 대해 예측한 결과와 실제 값을 비교함으로써 이루어졌다. 각 성능 지표는 scikit-learn의 classification\_report 및 roc\_auc\_score 함수 등을 활용하여 계산하였다. ROC 곡선은 모델별 분류 임계값 변화에 따른 TPR(True Positive Rate)과 FPR(False Positive Rate)의 관계를 시각화한 것으로, 곡선 아래 면적인 AUC(Area Under Curve)가 클수록 모델의 고장 예측 능력이 뛰어나다는 의미이다.



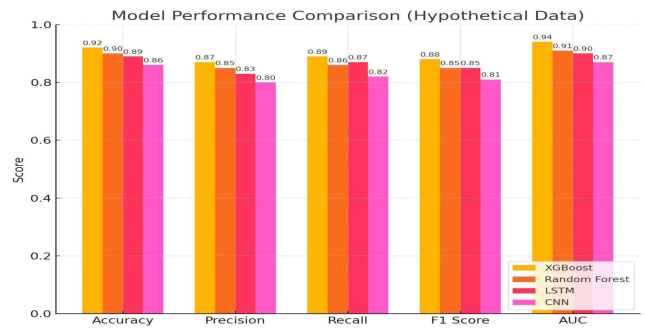
〈그림 2〉 ROC 곡선 비교 그래프

이러한 절차를 통해 도출된 결과는 2.3.2절에 제시된 성능 비교 그래프로 정리하였으며, 향후 실제 데이터 적용 시에도 동일한 방식으로 반복 적용이 가능하다.

### 2.3.2 모델 성능 비교 결과

성능 비교를 위해 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 스코어, AUC의 다섯 가지 지표를 사용하였다. 각 모델의 성능 지표는 실제 데이터가 아닌 가상의 수치로 설정되었으며, 이를 바탕으로 한 비교 결과는 다음과 같다. XGBoost 모델은 정확도 0.92, 정밀도 0.87, 재현율 0.89, F1 스코어 0.88, AUC 0.94로 모든 지표에서 가장 높은 성능을 보였다. Random Forest 모델은 정확도 0.90, 정밀도 0.85, 재현율 0.86, F1 스코어 0.85, AUC 0.91을 기록하여 XGBoost보다 약간 낮은 성능을 나타냈다.

LSTM 모델은 정확도 0.89, 정밀도 0.83, 재현율 0.87, F1 스코어 0.85, AUC 0.90로, 재현율 지표에서는 Random Forest와 유사한 수준을 보였으나 정확도와 AUC는 다소 낮았다. 반면 CNN 모델은 정확도 0.86, 정밀도 0.80, 재현율 0.82, F1 스코어 0.81, AUC 0.87로 네 모델 중 가장 저조한 성능을 나타냈다. 즉, 이번 가상 성능 비교에서는 XGBoost > Random Forest ≈ LSTM > CNN의 순으로 성능 격차가 나타났다.



〈그림 3〉 시스템 모델별 정확도, 정밀도, 재현율, F1 스코어, AUC 성능 비교

## 3. 결 론

가상의 성능 지표를 바탕으로 네 가지 모델(XGBoost, Random Forest, LSTM, CNN)의 예지정비 성능을 비교한 결과, XGBoost 모델이 전반적으로 가장 우수한 성능을 보였다. XGBoost는 정확도 0.92와 AUC 0.94 등 모든 평가 지표에서 최고 값을 기록하여, 전력설비 고장 예측에 있어 가장 효과적인 모델임을 시사한다. Random Forest와 LSTM 모델도 비교적 양호한 성능을 나타냈지만 전반적으로 XGBoost에 미치지 못하였으며, CNN 모델은 상대적으로 낮은 성능을 보였다. 이러한 결과를 종합하면, 전력설비 예지정비 시스템 구현 시 XGBoost와 같은 앙상블 기반 모델을 우선적으로 고려하는 것이 바람직하다고 판단된다.

향후 실험적 검증과 현장 적용을 통해 본 시스템의 효과를 입증하고, 전력망 운영의 안정성과 경제성을 더욱 높일 수 있을 것이다. 본 연구에서 제시한 AI 기반 예측 정비 시스템은 전력설비의 효율적 관리와 수명 연장에 기여할 수 있으며, 실제 전력설비 운영 환경에서의 적용성을 고려한 설계와 정비 우선순위 피드백 시스템 통합이라는 점에서 기존의 고장 예측 모델 연구와 뚜렷한 차별성을 지닌다.

## 참고 문헌

- [1] 한국전력공사, “전력설비 예측정비 기술개발 보고서,” 내부자료, 2021.
- [2] A. Bompard et al., “Machine Learning Approaches for Power Equipment Fault Prediction,” IEEE Transactions on Power Delivery, vol. 35, pp. 764-772, 2020.
- [3] Deloitte Consulting, “Predictive Maintenance in Utilities: ROI and Implementation,” Whitepaper, 2020.
- [4] Siemens Energy, “Digital Service for Transformer Health Monitoring: Case Study,” Whitepaper, 2019.
- [5] Exelon Corp., “AI-driven Fault Detection for Distribution Grid,” Technical Review, 2019.
- [6] K. T. Kim, H. J. Park, “Intelligent Maintenance System for Power Grid: A Case Study,” Journal of Electrical Engineering & Technology, vol. 14, no. 3, pp. 1450-1463, 2019.
- [7] J. Lee et al., “Real-Time Fault Detection and Maintenance Strategy in Power Distribution Systems Using AI,” Proceedings of the IEEE International Conference on Industrial Technology (ICIT), 2020, pp. 2225-2231.
- [8] M. A. Zavala et al., “Fault Detection and Predictive Maintenance for Power Systems Using Machine Learning Algorithms,” Journal of Modern Power Systems and Clean Energy, vol. 8, pp. 1025-1037, 2020.