

비지도 학습 기반 오토인코더 모델을 활용한 다중 분산자원 아크 고장 감지 연구

김태민*¹, 주승세*², 배지훈**³, 성윤동***⁴

Study on Multi-Distributed Resource Arc Fault Detection using Unsupervised Learning-based Autoencoder Model

Taemin Kim*¹, SeungSae Joo*², Ji-Hoon Bae**³, and Yoondong Sung***⁴

본 연구는 한국에너지기술연구원의 기본사업(C4-2427)을 재원으로 수행한 연구개발과제의 결과임

요약

최근 기후변화에 대응하기 위해 친환경 에너지에 대한 관심이 높아지고 있으며, 분산자원에 대한 수요도 증가하고 있다. 분산자원은 중앙 집중식 시스템 대비 전력망 안정성을 높이는 데 중요한 역할을 하지만 고장 발생시, 전력망의 건전성과 공급 신뢰성을 크게 해치게 된다. 특히 분산자원 내 전력변환 장치 고장 중 아크 고장은 장치의 손상과 화재를 야기하는 가장 대표적인 현상이다. 이에, 분산자원 내 아크 고장을 감지하기 위해 본 논문에서는 비지도 학습 모델인 오토인코더 기반 에너지 저장 시스템(ESS, Energy Storage System) 및 태양광 발전 시스템(PV, Photovoltaic) 아크 고장 감지 모델들을 제안하고 결과를 비교분석한다. 실험 결과, 변이형 오토인코더 모델이 98.71%의 정확도로 가장 높은 성능을 제공하는 것을 실험적으로 관찰하였다.

Abstract

In recent years, there has been a growing interest in green energy to response to climate change, and the demand for distributed resources is increasing. Distributed resources significantly enhance power grid stability compared to centralized systems, but they can compromise the safety of the grid in the event of a fault. In particular, among power conversion device faults within distributed resources, arc fault is the most representative phenomenon that causes damage to the device and fire hazards. Therefore, to detect arc faults in distributed resources, this paper proposes an unsupervised learning models based on autoencoder for Energy Storage System(ESS) and Photovoltaic (PV) arc fault detection and analyzes the results. Experimental results showed that the variational autoencoder model provided the highest performance with an accuracy of 98.71%.

Keywords

arc fault detection, autoencoder, unsupervised learning, deep neural network, energy storage system, photovoltaic system

* 대구가톨릭대학교 AI빅데이터공학과
- ORCID¹: <https://orcid.org/0009-0005-8881-9110>
- ORCID²: <https://orcid.org/0009-0001-1623-5424>
** 한국교원대학교 컴퓨터교육과 조교수(교신저자)
- ORCID: <http://orcid.org/0000-0002-0035-5261>
*** 한국에너지기술연구원 에너지ICT연구단 선임연구원
(교신저자)
- ORCID: <https://orcid.org/0000-0002-5621-6770>

• Received: Jun. 26, 2024, Revised: Sep. 10, 2024, Accepted: Sep. 13, 2024
• Corresponding Author 1: Ji-Hoon Bae
Dept. of Computer Education, 250 Taeseongtabyeon-ro,
Gangnae-myeon, Heungdeok-gu, Cheongju-si, Chungbuk, Korea
Tel.: +82-43-230-3705, Email: baejh@knue.ac.kr
• Corresponding Author 2: Yoondong Sung
Dept. of Energy ICT Convergence Research, Korea Institute of
Energy Research (KIER), 152 Gajeong-ro, Daejeon, Korea
Tel.: +82-42-860-3206, Email: syd9035@kier.re.kr

I. 서 론

최근 기후변화에 대응하기 위해 친환경 에너지에 대한 관심이 높아지고 있으며, 태양광 발전 시스템(PV, Photovoltaic) 및 에너지 저장 시스템(ESS, Energy Storage System)과 같은 분산 자원에 대한 수요도 증가하고 있다. 분산자원은 에너지 소비지역 인근에 위치하며, 전력 수요와 공급의 불균형으로 인한 주파수와 전압 변동에 대응하는 등 전력망 안정성을 향상하는 데 중요한 역할을 한다[1]. 하지만 고장 발생 시 정전과 같은 사고를 야기하여 전력망 건전성과 공급 신뢰성을 크게 저하시킨다. 특히, 분산 자원 고장 중 아크 고장은 순간적으로 수천 도에 도달하는 열과 빛을 방출하는 전기적 현상으로, 가장 대표적인 분산 자원 화재 원인이다[2]. 전선의 손상, 절연체의 노화와 열화, 부적절한 유지보수에 의해 주로 발생하며 내부 시스템 구성 요소를 손상시킨다[3]. 따라서 다중 분산자원의 아크 고장 발생을 감지하기 위해 정확하고 빠른 검출 기법 개발이 필수적으로 요구된다.

일반적으로 아크 고장의 특성 추출을 위해 단시간 푸리에 변환(STFT, Short Time Fourier Transform)과 이산 웨이블릿 변환(DWT, Discrete Wavelet Transform) 등과 같은 주파수 변환을 통한 신호처리 기법이 사용된다[4][5]. 이러한 신호처리 기법이 적용된 아크 고장 감지 알고리즘은 뛰어난 성능을 보여주지만 많은 연산량과 높은 시간 복잡도로 인해 실시간 감지에는 부적합하다.

최근, 인공지능 기술이 크게 발전함에 따라 딥러닝 기술을 활용하여 아크 고장을 검출하기 위한 연구가 진행되고 있다[6][7]. 딥러닝 기술은 입력 데이터의 복잡한 패턴을 학습하여 효율적인 특징 추출이 가능하기 때문에 다양한 산업 분야에서 생산성의 향상을 이끌어 내고 있지만, 많은 양의 학습 데이터와 정답 레이블이 요구된다는 문제점이 존재한다. 특히, 실제 현장에 설치되는 재생 에너지원의 특성상 여러 환경적 요인들이 고장 데이터의 특성에 반영이 되기 때문에 상대적으로 환경에 덜 민감한 정상 데이터에 비해 실험 환경을 모의하고 정합성 높은 데이터를 수집하기 어렵다[8].

따라서, 비지도 학습 모델인 오토인코더 기반 아크 고장 감지 모델을 제안한다. 시계열 데이터를 그대로 활용하였고, 서로 다른 다섯 가지 종류의 오토인코더 기반 모델을 구현하고 성능을 비교하였다.

본 논문의 2장에서는 학습 데이터 수집과 전처리 방법에 대해 설명한다. 3장에서는 오토인코더 모델의 구조와 실험 모델에 대해 소개하며, 4장에서는 실험 모델과 다른 오토인코더 기반 모델별 성능 결과를 분석한다. 마지막으로, 5장에서는 본 논문의 결론 및 향후 연구에 대하여 기술한다.

II. 데이터 수집 및 전처리

본 논문에서는 그림 1과 같은 환경을 구축하여 분산자원 고장 환경을 모의하였다. Regatron 사의 ESS 및 PV 에뮬레이터와 EKOS 사의 계통 연계형 상용 인버터를 사용하였으며, UL 1699B 표준[9]에 따라 아크 발생기 및 고장환경을 구성하였다.

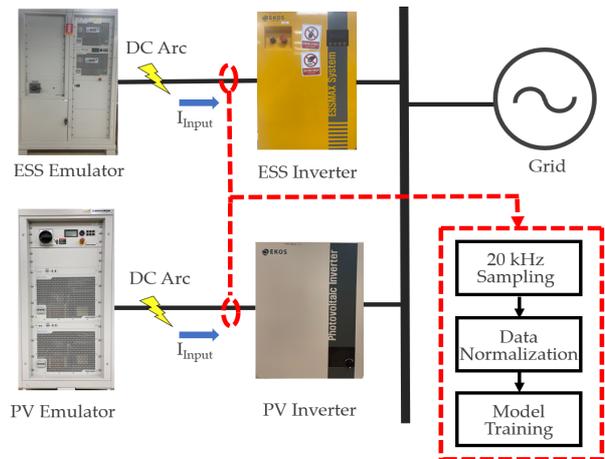


그림 1. 실험 데이터 수집 환경
Fig. 1. Experimental data acquisition environment

분산 전원에서 인버터로 공급되는 직류 전압은 500-700 V로, 전류는 5-10 A로 설정하였다. 전류 센서를 통해 20 kHz의 샘플링 주파수로 데이터를 수집하였고, 그 결과 1,000개의 샘플 포인트를 가진 50 ms 단위의 ESS 정상 데이터 12,246개, ESS 고장 데이터 1,997개, PV 정상 데이터 17,535개, PV 고장 데이터 2,284개를 습득하였다. 분산자원별 정상 및 고장 데이터 세트는 표 1과 같다.

표 1. 수집된 실험 데이터 세트
Table 1. Collected experimental data sets

| Data set | Normal | Arc fault |
|----------|--------|-----------|
| ESS | 12,246 | 1,997 |
| PV | 17,535 | 2,284 |

그림 2는 분산 자원별 정상 및 아크 고장 시계열 데이터의 파형을 보여준다. 수집된 데이터는 평균 차감 정규화 기법(MSN, Mean Subtraction Normalization)을 적용하여 전체적인 신호 파형을 유지한 채, 데이터를 중심화하였다[10]. 기존 신호처리 기법 중 하나인 고속 푸리에 변환(FFT, Fast Fourier Transform)은 주파수 변환을 통해 특정 주파수에서도 출되는 아크 특징을 추출하는 데 효과적이다[11]. 하지만, $O(N)$ 의 선형적인 계산 복잡도를 가지는 시계열 데이터와 다르게 FFT는 $O(N \log N)$ 의 증가된 계산 복잡도를 가진다[12]. MSN만을 적용한 전처리 방식이 FFT를 수행하는 것보다 복잡도 측면에서 우수하고[13], FFT를 적용한 방식은 원시 데이터의 시간적 특성을 잃을 가능성 또한 발생한다[14].

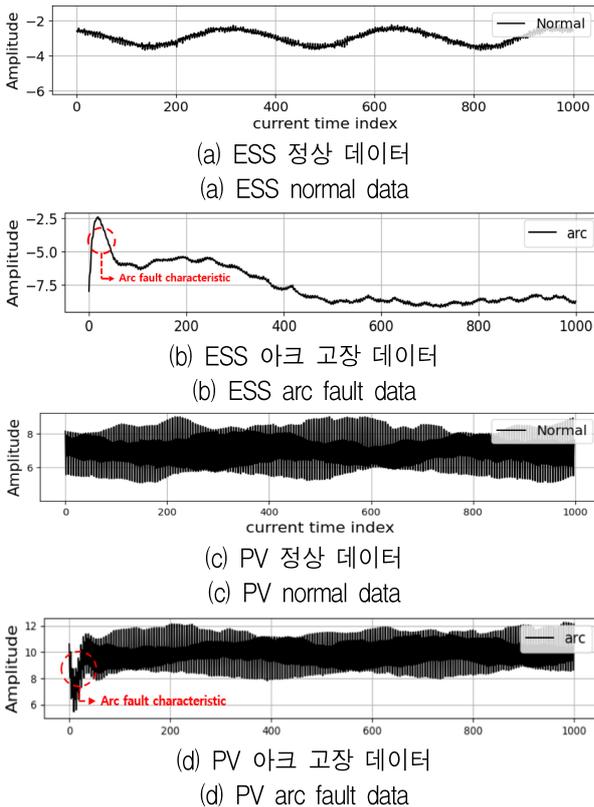


그림 2. 수집된 정상 및 아크 고장 시계열 데이터
Fig. 2. Collected normal and arc fault time series data

따라서, 본 논문에서는 아크 신호의 시간적 특성과 파형을 보존하기 위하여 고장 신호를 그대로 사용하고 전처리로 MSN 기법만을 적용한 고장 감지 모델을 제안하였으며, 이를 FFT 기법을 적용한 모델과 성능을 비교하였다.

III. 오토인코더 기반 아크 고장 탐지 모델

3.1 오토인코더 모델 구조

오토인코더는 비지도 학습 인공 신경망으로, 데이터를 압축하고 다시 복원하는 과정을 통해 입력과 유사한 출력을 생성하도록 학습하는 모델이다 [15]. 그림 3과 같은 구조를 가지는데, 입력 데이터를 저차원의 잠재 표현 Z로 압축하는 인코더와 압축된 표현을 원본 입력으로 재구성하여 출력하는 디코더로 구성된다. 입력 데이터와 출력 데이터의 재구성 손실을 계산하고 해당 손실을 줄이는 방향으로 학습한다. 잠재 표현 Z를 중심으로 대칭을 이루며, 은닉층이 깊어질수록 인코더에서 좁아졌다가 디코더에서는 넓어지는 형태를 나타낸다.

본 논문에서는 심층 신경망(Deep Neural Network, DNN), 1차원 합성곱 신경망(One-dimensional Convolution Neural Network, 1D CNN)[16], 1차원 깊이별 분리 합성곱 신경망(1D Depthwise Separable CNN, 1D DSCNN), 장단기 메모리(Long Short Term Memory, LSTM)[17], 그리고, 변이형 오토인코더(Variational Autoencoder, VAE) [18][19]의 다섯 가지 신경망 구조를 적용한 오토인코더 모델을 구현하였다.

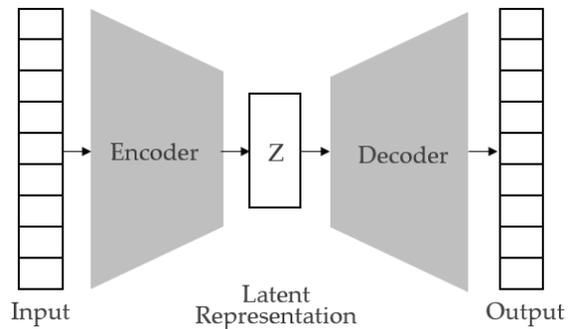


그림 3. 오토인코더 모델 구조
Fig. 3. Structure of autoencoder model

3.2 임계값을 이용한 아크 고장 판별

본 논문에서는 PV와 ESS 환경에서 수집한 정상 데이터만을 이용하여 다섯 가지 구조의 오토인코더 모델을 학습하였으며, 지정된 임계값을 기준으로 정상과 아크 고장을 판별하는 모델을 구현하였다. ESS 고장, ESS 정상, PV 고장, PV 정상 총 네 가지 상황에서 데이터를 수집하고 학습하였지만, 모델의 출력은 고장, 정상 두 가지 클래스로 분류할 수 있도록 설계하였다.

임계값은 학습된 모델에 의해 재구성된 입력 데이터의 분포를 기준으로 설정되었다[20]. 비지도 학습 분류 문제에서 임계값을 구하는 방식으로는 정상 상태와 비정상 상태 데이터의 평균을 각각의 표준편차 비로 내분하는 점을 임계값으로 지정하여 판별하는 방법과 건전성 인자의 분포와 입력 데이터의 분포를 비교하는 방식 등이 있다[21][22]. 본 연구에서는 (1) 및 식 (2)과 같이 입력 데이터와 출력 데이터 오차의 평균과 표준편차의 합으로 정의되고, 해당 재구성 오차 값이 임계값을 초과하면 고장, 그렇지 않으면 정상으로 판별하는 구조를 제안한다.

$$M = \mu(|x - \hat{x}|) \tag{1}$$

여기서, M은 실제 입력 데이터와 모델이 출력한 재구성 데이터의 오차 평균을 의미한다.

$$T = \mu(M) + \sigma(M) \cdot \alpha \tag{2}$$

여기서, T는 임계값으로 식 (1)의 M의 평균과 α 를 곱한 표준편차의 합으로 나뉜다. 이때, α 는 모델이 최적의 성능으로 분류할 수 있도록 실험적으로 설정한 변수이다. 본 논문에서 제안한 아크 고장 판별 알고리즘의 전체 구조는 그림 4와 같다. 20 kHz의 샘플링 주파수로 수집된 50 ms 단위의 데이터를 MSN 기법을 통해 전처리한 후, 모델을 학습시키고 학습된 모델에 입력 데이터를 제공하여 재구성 데이터를 출력한다. 식 (1)을 사용하여 실제 데이터와 재구성 데이터 간의 오차의 절대 평균 M을 구하고, M의 평균과 표준편차를 이용하여 식 (2)와 같이 임계값 T를 계산한다. 계산된 T를 기준으로 모델이 아크고장을 판별하는 구조를 갖는다.

IV. 실험 결과

본 연구에서는 ESS 12,246개, PV 17,535개의 정상 데이터에서 무작위로 10,000개씩 뽑아 총 20,000개의 학습 데이터 셋을 구성하였다. ESS와 PV의 나머지 정상 데이터에서 각 1,977개씩, 고장 데이터에서 1,977개씩 뽑아 총 7,988개의 평가 데이터 셋을 구성하였다. 학습 데이터 셋과 평가 데이터 셋의 구성 요소는 그림 5와 같다. 학습을 위해 배치 사이즈는 64, 에포크는 300, 학습률은 0.0001로 설정하였으며, Adam(Adaptive Moment Estimation) 옵티마이저를 사용하여 학습을 최적화하였다. 이때, 복원 성능 평가 지표로 평균절대오차(MAE, Mean Absolute Error)를 채택하였다. MAE는 식 (3)과 같이 정의된다.

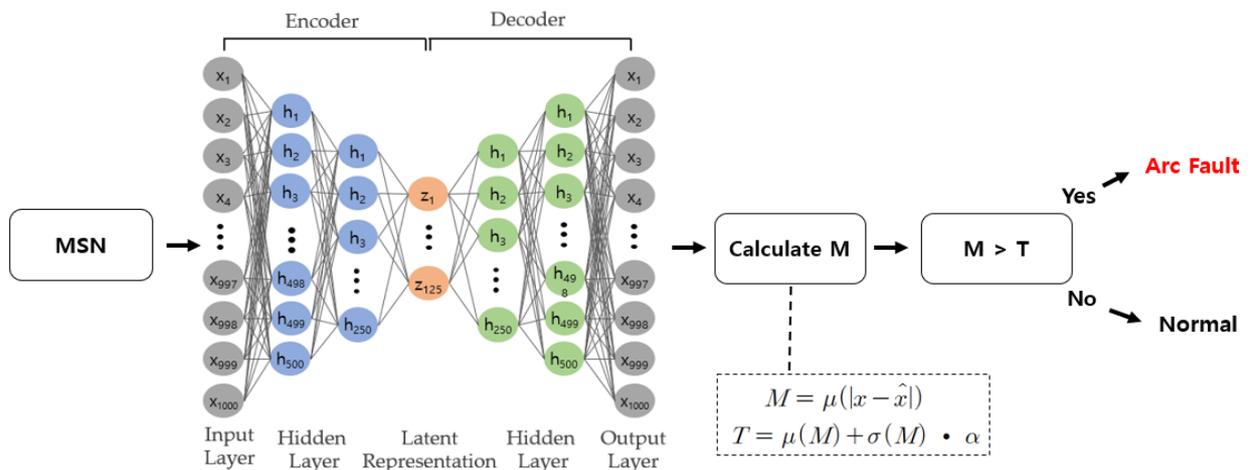


그림 4. 아크 고장 탐지 알고리즘
Fig. 4. Arc faults detection algorithm

$$MAE = \frac{\sum |x - \hat{x}|}{n} \quad (3)$$

모델 학습은 Intel Core i7-7700 CPU, 32GM 메모리, Samsung SSD 850 EVO 250GB, NVIDIA GeForce RTX 3090 GPU를 탑재한 PC 환경에서 수행되었다.

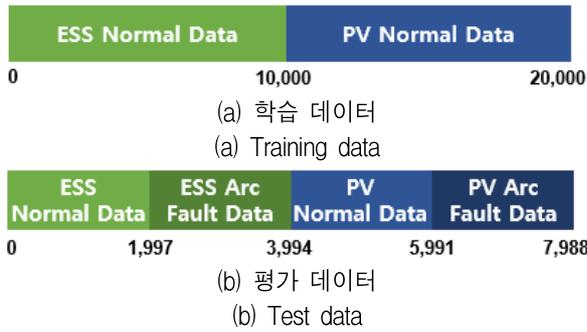


그림 5. 학습 데이터 및 평가 데이터 구성 요소
Fig. 5. Training data and test data components

표 2. 오토인코더 기반 아크 탐지 모델의 정확도 및 신호 복원 성능

Table 2. Accuracy and signal restoration performance of arc detection model based on autoencoder

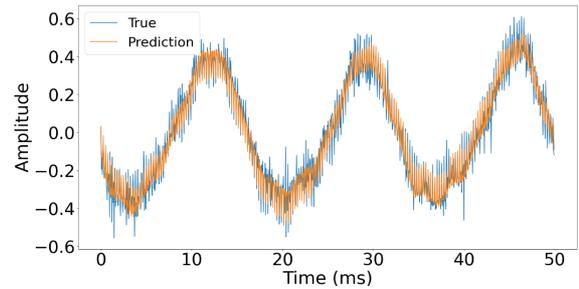
| Model | MAE | Accuracy (%) |
|----------|---------------|--------------|
| DNN | 0.2551 | 96.32 |
| 1D CNN | 0.0043 | 93.97 |
| 1D DSCNN | 1.7621 | 88.10 |
| LSTM | 0.3171 | 86.55 |
| VAE | 0.2766 | 98.71 |

표 2는 MSN 기법만 적용한 데이터로 학습한 각 오토인코더 모델의 정확도 및 판별 성능을 나타낸다. 실험 결과, 표 2에서 1D CNN 기반 오토인코더 모델이 MAE 지표에서 0.0043의 수치를 보여주며 가장 높은 복원 성능을 보여주었던 반면, 판별 성능은 VAE 기반 모델이 98.71 %로 가장 우수했다. 표 3은 판별 성능이 가장 뛰어났던 VAE 기반 모델에 FFT 적용 유무에 따른 성능 비교를 나타낸다. MAE와 Accuracy 평가 모두 0.2766, 98.71 %의 수치로, FFT 적용 모델 대비 더 뛰어난 성능을 보여주는 것을 관찰하였다. 이러한 결과는 VAE 모델이 시계열 데이터는 확률적 분포를 학습하여 시간에 따른 패턴을 잘 반영할 수 있지만[23], FFT를 적용한 데이터는 주파수 영역으로 변환되어 원본 데이터의 시간적 연속성이 손실될 수 있다는 점을 보여준다.

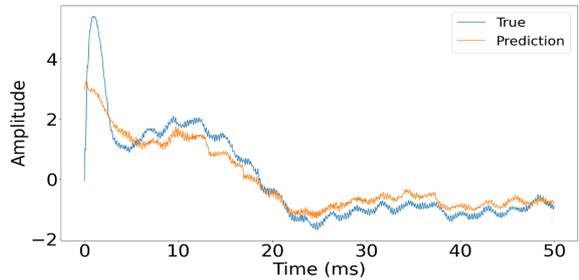
표 3. FFT 적용 유무에 따른 VAE 모델 정확도 및 신호 복원 성능 비교

Table 3. Compare VAE model accuracy and signal restoration performance with and without FFT

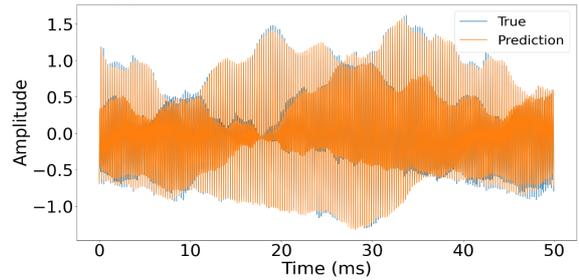
| Model | MAE | Accuracy (%) |
|-------------|---------------|--------------|
| VAE w/o FFT | 0.2766 | 98.71 |
| VAE w/ FFT | 3.5077 | 95.34 |



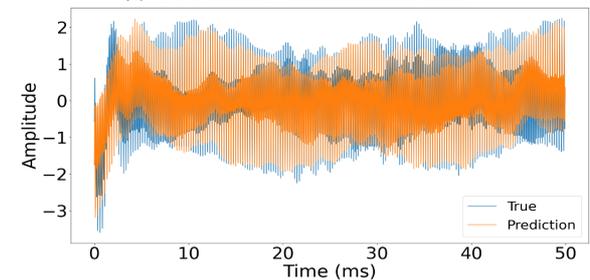
(a) ESS 정상 복원 데이터
(a) ESS normal reconstruction data



(b) ESS 아크 고장 복원 데이터
(b) ESS arc fault reconstruction data



(c) PV 정상 복원 데이터
(c) PV Normal reconstruction data



(d) PV 아크 고장 복원 데이터
(d) PV arc fault reconstruction data

그림 6. 변이형 오토인코더 모델의 신호 복원 결과
Fig. 6. Signal reconstruction results of the variational autoencoder model

가장 뛰어난 판별 정확도를 보여준 VAE 모델의 재구성된 분산자원별 정상 및 아크 고장 입력 데이터를 그림 6과 같이 시각적으로 표현하였다. 파란색 선은 실험을 통해 수집된 전류 신호를, 주황색 선은 재구성된 신호를 각각 나타낸다. 정상 데이터의 경우 그림 6(a),(c)와 같이 입력 데이터와 유사하게 복원되는 것을 확인할 수 있는 반면, 아크 고장 데이터의 경우 그림 6(b),(d)와 같이 입력 데이터와 크게 다른 것을 보여준다. 이는 오토인코더 모델이 정상 데이터의 특징을 잘 이해하고 학습함으로써, 정상 데이터와 분포가 다른 고장 데이터를 효과적으로 구분할 수 있음을 의미한다.

VAE 모델의 추가 성능 분석을 위해 혼동 행렬 (Confusion matrix)을 작성하였다. 평가 데이터를 사용하여 예측한 결과로 작성하였으며 그림 7에 제시하였다. 평가를 위해 정밀도(Precision), 재현율 (Recall), 그리고 F1 점수(F1 Score) 이 세 가지 지표를 사용하였다. 정밀도는 모델이 정상 데이터로 예측한 것 중 실제 정상인 비율을 나타내며, 식 (4)와 같이 표현된다. 여기서, TP는 진실 양성(TP, True Positive)을, FP는 거짓 양성(FP, False Positive)을 뜻한다. 재현율은 실제 정상 데이터로 예측한 것 중 모델이 정상으로 예측한 비율을 나타내며, 식 (5)과 표현할 수 있다. 여기서, FN은 거짓 음성(FN, False Negative)을 뜻한다. F1 점수는 정밀도와 재현율의 조화평균으로 정의되며, 식 (6)과 같다.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

상기 표 4는 VAE 모델의 정밀도와 재현율, F1 점수를 나타낸다. 정밀도는 0.9739, 재현율은 0.9987, F1 점수는 0.9861로 높은 수치를 보여준다. 특히, 재현율이 0.9987로 매우 높다는 점은 모델이 실제 고장을 정상으로 예측하는 2중 오류의 비율이 낮다는 것을 의미한다. 아크 고장을 정상으로 잘못 분류할 경우, 시스템의 손상과 화재 위험이 증가하기 때문에 아크 고장 탐지에서 높은 재현율은 필수적으로 요구되는 지표이다. 실험 결과를 통해 본 연구에서 제안한 모델이 이러한 요건을 잘 충족하고 있음을 확인할 수 있었다.

표 4. VAE 모델의 혼동 행렬 평가 지표

Table 4. Comparison of confusion matrix assessment indicators for VAE model

| Model | Precision | Recall | F1 score |
|-------|-----------|--------|----------|
| VAE | 0.9739 | 0.9987 | 0.9861 |

V. 결론 및 향후 과제

본 논문에서는 ESS와 PV를 포함한 다중 분산자원의 아크 고장을 감지하기 위해 비지도 학습 기반 오토인코더 계열 모델들을 구현하고, MSN 기법만 적용한 시계열 데이터를 사용하여 성능 결과를 비교하였다. 고장 판별을 위해 실제 값과 예측 값의 오차 분포를 이용한 임계값 T를 설정하였으며, 재구성 오차 값이 T보다 크면 고장으로 판별하도록 설계하였다. 추가로, 판별 성능이 가장 뛰어났던 VAE 모델에 FFT 신호처리 기법을 적용한 결과를 비교하였다. 실험 결과, MSN 기법만 적용한 시계열 데이터를 학습시킨 VAE 모델이 98.71%의 가장 높은 성능을 보여주었고 높은 재현율을 충족하며 실제 고장을 정상으로 예측하는 2중 오류의 비율이 낮다는 것을 실험적으로 확인할 수 있었다.

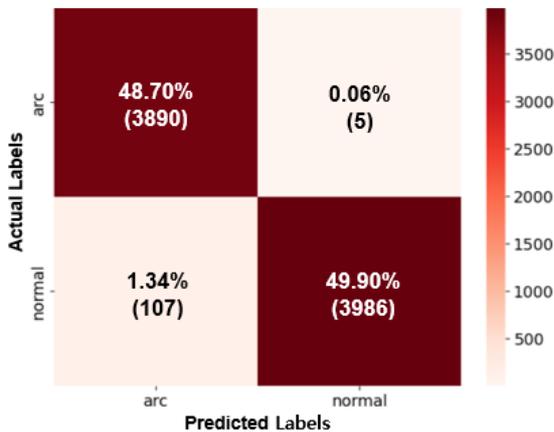


그림 7. VAE 모델의 혼동 행렬

Fig. 7. Confusion matrix of VAE model

향후 연구에서는 추가적인 부하를 포함하여 다중 분류를 위한 아크 고장 감지 알고리즘을 개발하고, 경량화 작업을 통해 실시간 적용 가능성 또한 연구할 예정이다.

Acknowledgements

본 논문은 2024년도 한국정보기술학회 하계종합 학술대회에서 발표한 “비지도 학습 기반 오토인코더 모델을 활용한 ESS 아크 고장 감지 연구”[8] 내용을 확장한 연구 결과임. 또한, 본 연구는 한국에너지기술연구원의 기본사업(C4-2427)을 재원으로 수행한 연구개발과제의 결과임.

References

- [1] Advantages and disadvantages of distributed energy, <http://www.keaj.kr/news/articleView.html?idxno=4192> [accessed: Jun. 10, 2024]
- [2] H.-K. Lee, D.-K. Kwak, K.-Y. Park, and B.-S. Lee, "A Study on Necessity of AFCI and Algorithm of Micom Design for Electric Fire Reduction", Proceedings of the KIPE Conference, Gyeongju, Korea, pp. 491-492, Jul. 2017.
- [3] Y. Yoon, "Status Diagnosis Algorithm for Optimizing Power Generation of PV Power Generation System due to PV Module and Inverter Failure, Leakage and Arc Occurrence", The Journal of The Institute of Internet, Broadcasting and Communication (IIBC), Vol. 24, No. 4, pp. 135-140, Aug. 31, 2024. <https://doi.org/10.7236/IIBC.2024.24.4.135>
- [4] S. Chen, X. Li, and J. Xiong, "Series Arc Fault Identification for Photovoltaic System Based on Time-Domain and Time-Frequency-Domain Analysis", IEEE Journal of Photovoltaics, Vol. 7, No. 4, pp. 1105-1114, Jul. 2017. <http://doi.org/10.1109/JPHOTOV.2017.2694421>.
- [5] Z. Wang and R. S. Balog, "Arc Fault and Flash Signal Analysis in DC Distribution Systems Using Wavelet Transformation", IEEE Transactions on Smart Grid, Vol. 6, No. 4, pp. 1955-1963, Jul. 2015. <http://doi.org/10.1109/TSG.2015.2407868>.
- [6] S. Lu, T. Sirojan, B. T. Phung, D. Zhang, and E. Ambikairajah, "DA-DCGAN: An Effective Methodology for DC Series Arc Fault Diagnosis in Photovoltaic Systems", IEEE Access, Vol. 7, pp. 45831-45840, Apr. 2019. <http://doi.org/10.1109/ACCESS.2019.2909267>.
- [7] K. Yang, R. Chu, R. Zhang, J. Xiao, and R. Tu, "A Novel Methodology for Series Arc Fault Detection by Temporal Domain Visualization and Convolutional Neural Network", Sensors (Basel), Vol. 20, No. 1, pp. 162, Dec. 2019. <http://doi.org/10.3390/s20010162>.
- [8] T. Kim, S. S. Joo, Y. Sung, and J.-H. Bae, "Study on ESS and PV Arc Fault Detection Using Unsupervised Learning-Based Autoencoder Model", The Proceedings of the 2024 KIIT Summer Conference, Jeju, Korea, Vol. 19, No. 1, pp. 201-205, May 2024.
- [9] U. Labs, "UL 1699B-Standard for Photovoltaic(PV) DC Arc-Fault Circuit Protection", Aug. 2018.
- [10] Y. Sung, G. Yoon, J.-H. Bae, and S. Chae, "TL-LEDarcNet: Transfer Learning Method for Low-Energy Series DC Arc-Fault Detection in Photovoltaic Systems", IEEE Access, Vol. 10, pp. 100724-100735, Sep. 2022. <http://doi.org/10.1109/ACCESS.2022.3208115>.
- [11] C.-G. Cho, et al., "DC Series Arc Fault Characteristic Comparison of A Fast Fourier Transform Result", 8th International Conference on Condition Monitoring and Diagnosis(CMD), Phuket, Thailand, pp. 218-221, Oct. 2020. <https://doi.org/10.1109/CMD48350.2020.9287251>.
- [12] WIKIPEDIA, https://en.wikipedia.org/wiki/Fast_Fourier_transform#Computational_complexity [accessed: Aug. 29, 2024]
- [13] D. Jeong, Y. Choi, and Y. Jung, "FPGA implementation of high-speed FFT processor for

- real-time SAR imaging", Summer Annual Conference of IEIE 2021, Jeju, Korea, pp. 517-518, Jun. 2021.
- [14] S. Rapuano and F. J. Harris, "An Introduction to FFT and Time Domain Window", IEEE Instrumentation & Measurement Magazine, Vol. 10, pp. 32-44, Dec. 2007. <http://doi.org/10.1109/MIM.2007.4428580>.
- [15] Z. Ghahramani, "Unsupervised Learning", Advanced Lectures on Machine Learning, Vol. 3176, pp. 72-112, 2003. https://doi.org/10.1007/978-3-540-28650-9_5.
- [16] S. Chen and J. Yu, "One-dimensional Convolutional Autoencoder-based Feature Learning for Fault Diagnosis of Multivariate Process", Journal of Process Control, Vol. 87, pp. 54-67, Mar. 2020. <https://doi.org/10.1016/j.jprocont.2020.01.004>.
- [17] H. D. Nguyen, K. P. Tran, S. Thomassey, and M. Hamad, "Forecasting and Anomaly Detection Approaches Using LSTM and LSTM Autoencoder Techniques with the Applications in Supply Chain Management", International Journal of Information Management, Vol. 57, pp. 102282, Apr. 2021. <https://doi.org/10.1016/j.ijinfomgt.2020.102282>.
- [18] J. An and S. Cho, "Variational Autoencoder based Anomaly Detection using Reconstruction Probability", Special lecture on IE, Vol. 2, No. 1, pp. 1-18, Dec. 2015.
- [19] J.-E. Jeong, H.-J. Kim, and J.-H. Chun, "Automatic Augmentation Technique of an Autoencoder-based Numerical Training Data", The Journal of The Institute of Internet, Broadcasting and Communication (IIBC), Vol. 22, No. 5, pp. 75-86, Oct. 2022. <https://doi.org/10.7236/IIBC.2022.22.5.75>.
- [20] S. J. Park, J. H. Kim, D. Y. Yeo, J. H. Lee, and J.-H. Bae, "Study on Autoencoder-based Plant Piping Leak Detection", Journal of KIIT, Vol. 21, No. 11, pp. 1-9, Nov. 2023. <http://dx.doi.org/10.14801/jkiit.2023.21.11.1>.
- [21] D. Yeo, G. Lee, and J.-C. Lee, "Pipe Leak Detection System using Wireless Acoustic Sensor Module and Deep Auto-Encoder", Journal of The Korea Society of Computer and Information, Vol. 25, No. 2, pp. 59-66, Feb. 2020. <https://doi.org/10.9708/jksci.2020.25.02.059>.
- [22] C. Lee and H. Oh, "Unsupervised-learning-based Anomaly Detection by Health Data Analysis of Construction Equipment Piston Pump", The KSME, Jeju, Korea, pp. 1700-1701, Nov. 2022.
- [23] C. Doersch, "Tutorial on Variational Autoencoders", arXiv:1606.05908, Jun. 2016. <https://doi.org/10.48550/arXiv.1606.05908>.

저자소개

김 태 민 (Taemin Kim)



2023년 8월 : 대구가톨릭대학교 AI 빅데이터공학과(공학사)
 2023년 9월 ~ 현재 : 대구가톨릭대학교 AI빅데이터공학과 석사과정
 2023년 9월 ~ 현재 : 한국에너지기술연구원

에너지ICT연구단 학생연구원

관심분야 : 이상 감지, 인공지능, 딥러닝/머신러닝

주 승 세 (SeungSae Joo)



2021년 3월 ~ 현재 : 대구가톨릭대학교 AI빅데이터공학과 학사과정
 관심분야 : 인공지능, 딥러닝/머신러닝

배 지 훈 (Ji-Hoon Bae)



2000년 2월 : 경북대학교
전자·전기공학부(공학사)
2002년 2월 : 포항공과대학교
전자컴퓨터공학부(공학석사)
2016년 2월 : 포항공과대학교
전자·전기공학과(공학박사)
2002년 1월 ~ 2019년 8월 :

한국전자통신연구원 책임연구원

2019년 9월 ~ 2024년 8월 : 대구가톨릭대학교

AI빅데이터공학과 조교수

2024년 9월 ~ 현재 : 한국교원대학교 컴퓨터교육과
조교수

관심분야 : 임베디드 AI, 컴퓨터 구조, 인공지능,
딥러닝/머신러닝

성 윤 동 (Yoondong Sung)



2010년 2월 : 국민대학교
전기 및 전자공학부(공학사)
2012년 2월 : 광주과학기술원
전기공학과(공학석사)
2023년 2월 : 한국과학기술원
전기 및 전자공학부(공학박사)
2012년 1월 ~ 현재 :

한국에너지기술연구원 선임연구원

관심분야 : 이상감지, 에너지관리시스템, 인공지능,
딥러닝/머신러닝, 신호처리 및 에너지 최적화