ISSN 1975-8359 [Print] / ISSN 2287-4364 [Online]
The Transactions of the Korean Institute of Electrical Engineers, vol. 75, no. 10, pp. 2411~2416, 2026
https://doi.org/10.5370/KIEE.2026.75.10.2411

Investigation of AI-Based Detection Methods for AC and DC Series Arc Faults in Three-Phase DC/AC Inverters

3상 DC/AC 인버터의 AC 및 DC 직렬 아크 고장에 대한 인공지능 기반 검출 기법 연구

Jin-Hyung Ahn · Yong-Heon Kim · Sang-Shin Kwak
안진형* · 김용헌* · 곽상신†

Abstract

Series arc faults occurring at the AC output and DC input sides of a three-phase pulse-width modulation inverter can degrade system reliability and increase the risk of electrical accidents. Because the effects of an arc on the output-current waveform vary depending on the fault location and operating condition, the diagnostic characteristics of AC and DC series arcs should be evaluated separately. In this study, the performance of several artificial-intelligence models was compared using a single A-phase output-current signal measured under various inverter operating conditions. The measured current was used as a time-domain sequence and was also transformed into a frequency-domain magnitude spectrum using the fast Fourier transform. The experimental results showed that the CNN-Transformer achieved the highest diagnostic accuracy for both AC and DC arc faults with both input representations. In particular, the frequency-domain input provided high precision and recall for both AC and DC arc conditions. These results demonstrate that both AC output-side and DC input-side series arcs can be effectively diagnosed from the output-current characteristics, while the diagnostic performance depends on the fault location, input representation, and model structure.

Key Words

AC series arc fault, DC series arc fault, Three-phase inverter, Artificial intelligence, Fast Fourier Transform

1. 서 론

직렬 아크는 배선 단선, 접속부 이완, 압착 불량 및 절연 열화 등으로 인해 전류 경로가 불완전해질 때 발생한다. 아크가 지속되면 국부적으로 고온의 플라즈마가 형성되어 전력변환 장치와 배선의 열화를 가속하고, 전기 화재와 전자파 간섭 등의 2차 피해를 유발할 수 있다. 특히 직렬 아크의 고장 전류는 부하에 의해 제한되므로 일반적인 과전류 보호장치의 동작 기준을 초과하지 않는 경우가 많다. 따라서 전류 파형의 변화를 이용하여 정상 상태와 아크 상태를 구분하는 별도의 진단 기법이 필요하다.

아크 검출 방법은 방전 과정에서 발생하는 광, 음향 및 전자기 방사 신호를 이용하는 방법과 전압 또는 전류 신호를 분석하는 방법으로 구분할 수 있다. 자외선 또는 음향 신호를 이용하면 아크를 직접 검출할 수 있으나, 별도의 센서와 설치 공간이 필요하며 센서 위치와 주변 환경의 영향을 받을 수 있다. 반면 전류 신호는 인버터의 제어와 보호를 위해 일반적으로 계측되므로 추가 센서의 사용을 줄일 수 있다. 이에 따라 웨이블릿 변환, 주파수 스펙트럼 및 희소 표현 등을 이용하여 전류 신호에서 아크 특징을 추출하는 방법이 제안되었다 [1], [2].

신호처리 기반 방법은 분석 주파수 대역, 특징량 및 판정 임계값을 사전에 선정해야 하며, 운전 조건이 달라지면 해당 기준을 조정해야 할 수 있다. 3상 PWM 인버터에서는 출력 기본파 주파수, 스위칭 주파수, 부하 인덕턴스 및 변조지수 등의 운전 조건이 달라지므로, 특정 조건에서 설정한 특징과 임계값을 다른 조건에 동일하게 적용하기 어렵다. 따라서 다양한 운전 조건을 포함한 데이터 기반 진단 방법이 필요하다. 최근에는 수작업 특징 설계에 대한 의존도를 줄이기 위해 데이터로부터 분류 특징을 학습하는 머신러닝 및 딥러닝 기법이 적용되고 있다. 시간 영역 전류를 영상으로 변환한 후 CNN으로 분류하는 방법 [3], 원시 전류를 직접 입력하여 교류 직렬 아크를 검출하는 ArcNet [4], 그리고 CNN의 국부 특징 추출과 Transformer의 시퀀스 학습을 결합한 구조 [5] 등이 제안되었다. 이러한 방법은 입력 신

† Corresponding Author : School of Electrical and Electronics Engineering, Chung-Ang University, Seoul, Korea
E-mail:sskwak@cau.ac.kr
https://orcid.org/0000-0002-2890-906X
* School of Electrical and Electronic Engineering, Chung-Ang University, Korea.
https://orcid.org/0009-0003-0204-5704 https://orcid.org/0009-0000-1232-4692
Received: Aug. 19, 2026 **Revised:** Aug. 21, 2026 **Accepted**: Aug. 21, 2026

Copyright © The Korean Institute of Electrical Engineers
This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/4.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

호에 포함된 비선형 특징을 자동으로 학습할 수 있으나, 모델 구조와 데이터 표현 방식에 따라 분류 성능이 달라질 수 있다.

AC 출력단과 DC 입력단은 아크가 발생하는 위치가 서로 다르므로, 동일한 측정 신호를 사용하더라도 각 아크 클래스의 분류 성능이 다르게 나타날 수 있다. 따라서 모델의 AC 및 DC 아크별 진단 Accuracy뿐 아니라 각 클래스의 Precision과 Recall을 함께 평가할 필요가 있다.

본 논문에서는 다양한 운전 조건에서 취득한 전류 데이터를 이용하여 3상 PWM 인버터의 AC 출력단 및 DC 입력단 직렬 아크에 대한 인공지능 기반 진단 성능을 비교하였다. 입력 데이터는 원시 전류의 시간 영역 시퀀스와 FFT 기반 주파수 영역 크기 스펙트럼으로 구성하고, KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 여섯 모델에 동일한 학습·검증·시험 조건을 적용하였다. 또한 AC 및 DC 아크를 각각 진단 대상으로 설정하여 Accuracy와 정상 및 아크 클래스의 Precision과 Recall을 비교함으로써, 아크 발생 위치와 입력 데이터 표현 방식에 따른 모델별 진단 특성을 분석하였다. 이를 통해 단일 출력전류 기반의 AC 및 DC 직렬 아크 진단에서 적합한 입력 데이터 표현 방식과 인공지능 모델 구조를 검토하는 것을 목적으로 한다.

2. AC 및 DC 직렬 아크 실험과 데이터 구성

DC 입력단 및 AC 출력단에서 발생한 직렬 아크 데이터를 취득하기 위해 각 위치에 아크 발생 장치를 직렬로 삽입하였다. DC 입력단 아크 실험에서는 DC 전원과 인버터 사이의 전류 경로에 아크 발생 장치를 배치하였으며, AC 출력단 아크 실험에서는 인버터 A상 출력과 저항-인덕터 부하 사이에 동일한 장치를 연결하였다. 각 실험 회로는 그림 1(a)와 그림 1(b)에 나타내었고, 두 실험에 사용한 아크 발생기의 구조는 그림 1(c)에 제시하였다. 아크 발생기는 두 전극의 간격을 조절하여 직렬 아크를 반복적으로 발생시킬 수 있도록 구성하였다. 두 실험은 각각 독립적으로 수행하였으며, 아크 발생 위치를 제외한 계측 조건과 데이터 취득 절차는 동일하게 설정하였다.

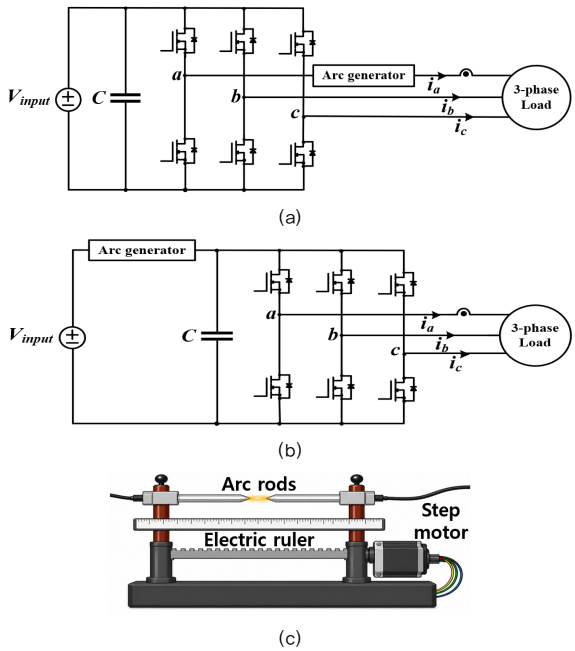


그림 1 3상 인버터의 직렬 아크 실험 구성: (a) DC 입력단 아크 실험 회로도, (b) AC 출력단 아크 실험 회로도, (c) 아크 발생기 구조

Fig. 1 Experimental configurations for series arc faults in a three-phase inverter: (a) DC input-side arc-fault circuit, (b) AC output-side arc-fault circuit, and (c) structure of the arc generator

실험 장치는 3상 인버터, 제어 보드, 아크 발생 장치, 저항-인덕터 부하, 전류 프로브 및 오실로스코프로 구성하였다. 아크 발생 장치는 투명 챔버 내부의 두 전극과 전극 간격을 조절하는 구동부로 구성하였으며, 접촉된 전극을 서서히 이격하여 직렬 아크를 발생시켰다. 정상 운전과 아크 발생 상태의 전류 신호는 전류 프로브와 오실로스코프를 이용하여 연속적으로 취득하였다. 각 실험에서 정상 운전 구간과 아크가 안정적으로 발생한 구간을 추출하여 데이터셋을 구성하였다.

정상 운전 데이터와 함께 AC 출력단 15개 조건 및 DC 입력단 4개 조건에서 아크 데이터를 취득하였다. AC 출력단 데이터는 출력 기본파 주파수, 스위칭 주파수, 부하 인덕턴스 및 변조지수를 변화시킨 조건으로 구성하였다. 출력 기본파 주파수는 30, 60, 90 및 120 Hz, 스위칭 주파수는 5, 10, 15 및 20 kHz, 부하 인덕턴스는 2, 10, 15 및 18 mH로 설정하였다. DC 입력단 데이터는 출력 기본파 주파수 60 Hz, 스위칭 주파수 10 kHz 및 부하 인덕턴스 10 mH의 조건에서 변조지수를 달리하여 4개 조건으로 취득하였다. 모든 조건에서 동일한 계측 장비와 데이터 취득 절차를 적용하였다.

모델 입력에는 정상 및 아크 상태에서 취득한 A상 출력전류를 사용하였다. 해당 신호를 일정 길이의 구간으로 분할한 후 시간 영역 데이터와 주파수 영역 데이터로 구성하였다. 시간 영역 데이터는 구간 내 샘플 순서를 유지한 원시 전류 시퀀스이며, 주파수 영역 데이터는 동일한 시퀀스에 고속 푸리에 변환(Fast Fourier Transform, FFT)을 적용하여 산출한 크기 스펙트럼이다. 최종 비교에는 2.5 kHz로 재표본화한 데이터를 사용하였으며, 두 데이터에 동일한 학습·검증·시험 인덱스를 적용하여 데이터 표현 방식 이외의 조건을 동일하게 유지하였다.

상태 라벨은 정상, AC 출력단 아크 및 DC 입력단 아크로 구분하였다. 정상 데이터는 학습 21,434개, 검증 4,763개 및 시험 142개로 구성하였으며, AC 아크 데이터는 학습 22,724개, 검증 5,049개 및 시험 2,130개를 사용하였다. DC 아크 데이터는 학습 6,525개, 검증 1,450개 및 시험 568개로 구성하였다. 모든 모델에 동일한 데이터 분할을 적용하였으며, 데이터 불균형의 영향을 줄이기 위해 학습 과정에서 클래스 가중치를 적용하였다. 성능 평가지표로는 Accuracy, Precision 및 Recall을 사용하였다.

3. 인공지능 모델 비교 방법

비교 대상은 KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 여섯 모델이다. KNN은 입력 샘플과 학습 샘플 간의 거리를 계산한 후 가장 가까운 k개 이웃의 라벨을 이용하여 클래스를 결정하는 비모수 분류기이다. 본 논문에서는 k를 5로 설정하였다. 그림 2는 입력 샘플과 학습 샘플 간의 거리 계산, 이웃 선택 및 최종 분류 과정을 나타낸다. GB는 여러 의사결정트리를 순차적으로 학습하여 이전 트리의 오차를 보완하는 앙상블 모델이다. 시간 영역 및 주파수 영역 데이터를 고정 길이의 특징 벡터로 사용하였으며, 100개의 의사결정트리와 0.1의 학습률을 적용하였다. MLP는 하나의 은닉층과 100개의 은닉 뉴런으로 구성하였고, 완전연결층을 통해 입력 특징 간의 비선형 관계를 학습하였다.

딥러닝 기반 모델로는 CNN, SE-IR 및 CNN-Transformer를 사용하였다. CNN은 16, 32 및 64개의 필터를 갖는 1차원 합성곱 블록을 순차적으로 배치하여 인접한 샘플 또는 주파수 성분의 국부 특징을 추출한다. SE-IR은 inverted residual block [6]을 이용하여 특징 전달 경로를 구성하고, squeeze-and-excitation block [7]을 통해 채널별 특징의 중요도를 조정한다. CNN-Transformer는 64, 128 및 256개의 합성곱 필터로 국부 특징을 추출한 후 두 개의 Transformer 인코더에 입력하여 시퀀스 내 장거리 상관관계를 학습한다. 그림 3은 GB, MLP, CNN, SE-IR 및 CNN-Transformer의 주요 구조를 나타낸다.

표 1 인공지능 비교 모델의 주요 구성

Table. 1 Main configurations of the compared artificial-intelligence models.

모델	주요 구성	학습 방식	비고
KNN	k=5	거리 기반 분류	비모수 분류기
GB	의사결정트리 100개, 학습률 0.1, 최대 깊이 3	순차적 앙상블 학습	의사결정트리 기반 앙상블
MLP	은닉층 1개, 뉴런 100개	완전연결층 기반 학습	기본 신경망
CNN	합성곱층 16/32/64	국부 특징 추출	합성곱 신경망
SE-IR	SE block + inverted residual block	채널별 특징 가중 및 국부 특징 추출	SE 기반 채널 가중 구조
CNN-Transformer	합성곱층 64/128/256 + Transformer 인코더 2개	합성곱 특징 추출 및 self-attention 기반 학습	CNN-Transformer 결합 구조

모든 모델에는 동일한 데이터 분할을 적용하였다. AC 및 DC 아크의 진단 성능을 각각 독립적으로 비교하기 위해, 평가 단계에서 AC 아크와 DC 아크 클래스를 각각 진단 대상으로 설정하였다. 정상 상태와 각 아크 클래스의 세부 분류 특성은 Precision과 Recall을 이용하여 평가하였다. Precision은 해당 클래스로 예측한 샘플 중 실제로 그 클래스에 속하는 샘플의 비율이며, Recall은 실제 해당 클래스의 샘플 중 올바르게 분류된 샘플의 비율이다.

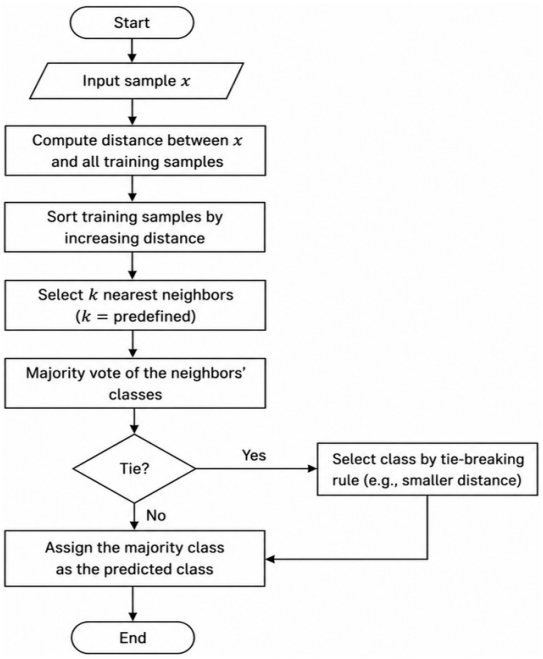
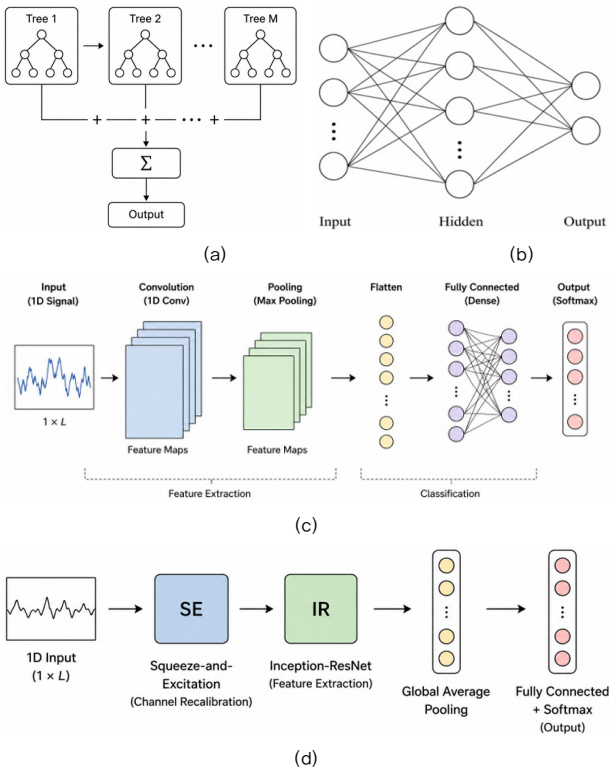
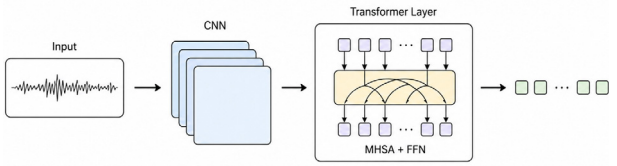


그림 2 KNN 알고리즘 흐름도

Fig. 2 Flowchart of the KNN algorithm





(e)

그림 3 인공지능 모델별 구조도 (a) GB (b) MLP (c) CNN (d) SE-IR (e) CNN-transformer

Fig. 3 Structures of the compared artificial-intelligence models: (a) GB, (b) MLP, (c) CNN, (d) SE-IR, and (e) CNN-Transformer

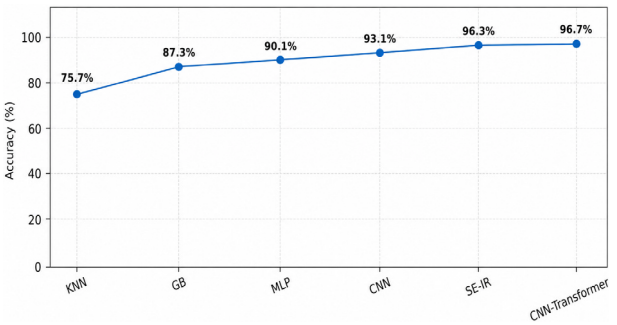


그림 4 시간 영역 입력을 이용한 AC 아크 진단의 인공지능 모델별 평균 진단 정확도

Fig. 4 Average accuracy of artificial-intelligence models for AC arc diagnosis using time-domain input.

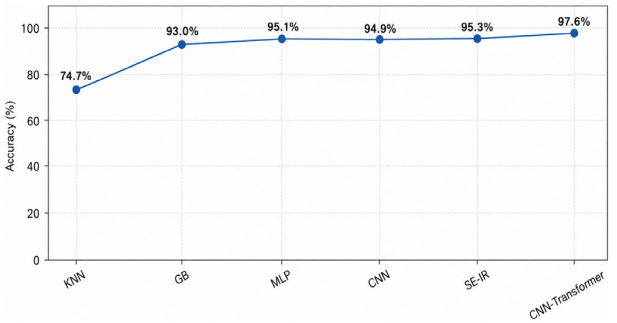


그림 5 주파수 영역 입력을 이용한 AC 아크 진단의 인공지능 모델별 평균 진단 정확도

Fig. 5 Average accuracy of artificial-intelligence models for AC arc diagnosis using frequency-domain input.

4. 실험 결과

AC 아크 진단에서 시간 영역 데이터를 입력으로 사용한 경우의 모델별 Accuracy는 그림 4와 같다. KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 Accuracy는 각각 75.7%, 87.3%, 90.1%, 93.1%, 96.3% 및 96.7%로 나타났다. CNN-Transformer가 96.7%로 가장 높은 Accuracy를 기록하였 으며, SE-IR이 96.3%로 그 뒤를 이었다. 반면 KNN은 75.7%로가장 낮은 진단 성능을 나타냈다.

주파수 영역 데이터를 입력으로 사용한 AC 아크 진단 결과는 그림 5와 같다. KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 Accuracy는 각각 74.7%, 93.0%, 95.1%, 94.9%, 95.3% 및 97.6%였다. CNN-Transformer는 주파수 영역에서도 97.6%로 가장 높은 Accuracy를 기록하였다. GB와 MLP는 시간 영역 대비 각각 5.7%p와 5.0%p 향상되었으며, CNN도 1.8%p 증가하였다. 반면 KNN과 SE-IR은 각각 1.0%p 감소하였다. 이러한 결과는 입력 데이터의 표현 방식에 따른 AC 아크 진단 성능의 변화가 모델 구조에 따라 서로 다르게 나타남을 보여준다. 각 아크에 대한 진단 Accuracy만으로는 정상 상태와 아크 상태에서 발생하는 오검출 및 미검출 특성을 구체적으로 확인하기 어렵다. 따라서 정상 상태와 AC 및 DC 아크 클래스의 Precision과 Recall을 추가로 비교하였다.

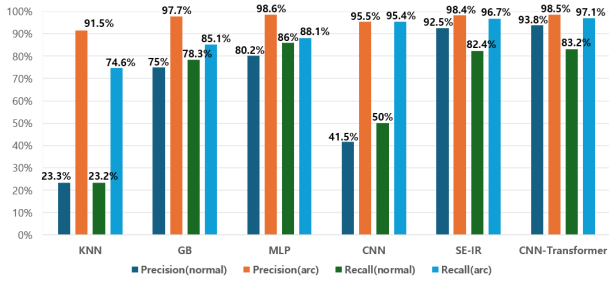


그림 6 시간 영역 입력에서 정상 및 교류 아크 클래스의 모델별 Precision과 Recall

Fig. 6 Model-wise precision and recall for the normal and AC arc classes using time-domain input

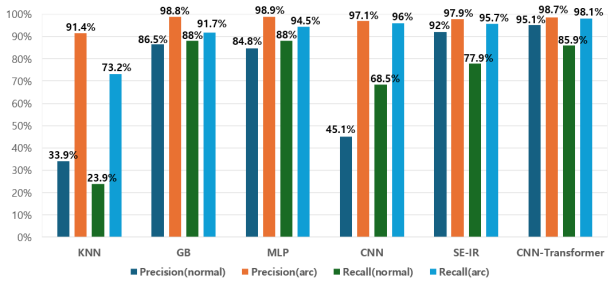


그림 7 주파수 영역 입력에서 정상 및 교류 아크 클래스의 모델별 Precision과 Recall

Fig. 7 Model-wise precision and recall for the normal and AC arc classes using frequency-domain input

시간 영역 데이터에서 정상 상태와 AC 아크 클래스에 대한 모델별 Precision과 Recall은 그림 6과 같다. CNN-Transformer의 AC Arc Precision과 Recall은 각각 98.5%와 97.1%였으며, SE-IR은 각각 98.4%와 96.7%를 기록하였다. CNN은 Precision 95.5%와 Recall 95.4%를 나타냈다. 반면 GB와 MLP의 AC Arc Precision은 각각 97.7%와 98.6%로 높았으나 Recall은 85.1%와 88.1%로 상대적으로 낮았다. 따라서 GB와 MLP는 AC 아크로 분류한 샘플의 정확성은 높았지만 일부 아크 샘플을 다른 클래스로 분류하는 경향을 보였다. 주파수 영역 데이터에서 정상 상태와 AC 아크 클래스에 대한 결과는 그림 7과 같다. CNN-Transformer는 AC Arc Precision 98.7%와 Recall 98.1%를 기록하였다. GB와 MLP의 Precision은 각각 98.8%와 98.9%였으며, Recall은 시간 영역 데이터보다 각각 6.6%p와 6.4%p 증가하였다. SE-IR은 Precision 97.9%와 Recall 95.7%를 기록하였다. GB와 MLP는 주

파수 영역 데이터에서 시간 영역 데이터보다 높은 Recall을 나타냈다. 시간 영역 데이터에서 CNN, SE-IR 및 CNN-Transformer는 AC 아크 클래스에 대해 높은 Recall을 기록하였다. CNN-Transformer는 두 데이터 표현에서 모두 높은 Precision과 Recall을 나타냈으며, KNN은 AC Arc Recall이 75% 이하로 나타나 상대적으로 낮은 분류 성능을 보였다.

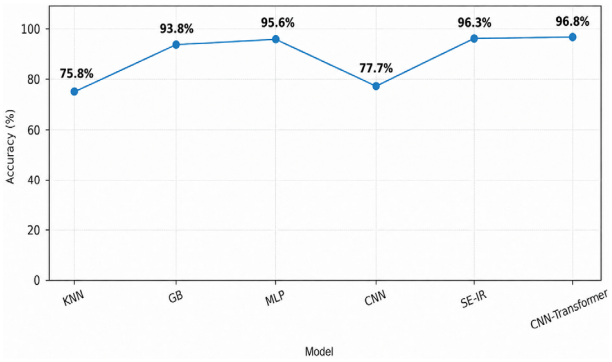


그림 8 시간 영역 입력을 이용한 DC 아크 진단의 인공지능 모델별 평균 진단 정확도

Fig. 8 Average accuracy of artificial-intelligence models for DC arc diagnosis using time-domain input.

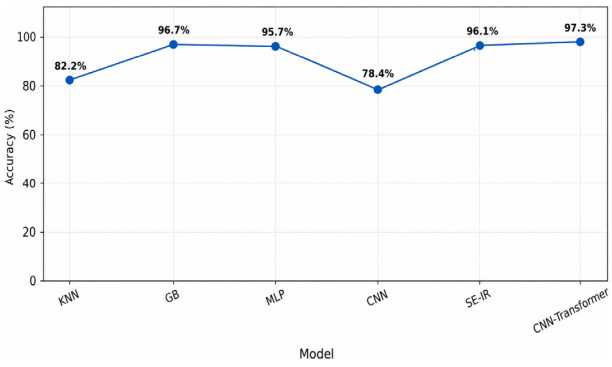


그림 9 주파수 영역 입력을 이용한 DC 아크 진단의 인공지능 모델별 평균 진단 정확도

Fig. 9 Average accuracy of artificial-intelligence models for DC arc diagnosis using frequency-domain input.

DC 아크 진단에서 시간 영역 데이터를 입력으로 사용한 경우의 모델별 Accuracy는 그림 8과 같다. KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 Accuracy는 각각 75.8%, 93.8%, 95.6%, 77.7%, 96.3% 및 96.8%로 나타났다. CNN-Transformer가 96.8%로 가장 높은 Accuracy를 기록하였으며, SE-IR과 MLP가 각각 96.3%와 95.6%로 높은 성능을 나타냈다. 반면 KNN과 CNN은 각각 75.8%와 77.7%로 상대적으로 낮은 진단 성능을 보였다.

주파수 영역 데이터를 입력으로 사용한 DC 아크 진단 결과는 그림 9와 같다. KNN, GB, MLP, CNN, SE-IR 및 CNN-Transformer의 Accuracy는 각각 82.2%, 96.7%, 95.7%, 78.4%, 96.1% 및 97.3%로 나타났다. CNN-Transformer가 97.3%로 가장 높은 Accuracy를 기록하였으며, GB가 96.7%로 그 뒤를 이었다. KNN과 GB는 시간 영역 대비 각각 6.4%p와 2.9%p 증가하였으며, CNN-Transformer도 0.5%p 향상되었다. 반면 SE-IR은 두 입력 방식에서 거의 유사한 성능을 나타냈다.

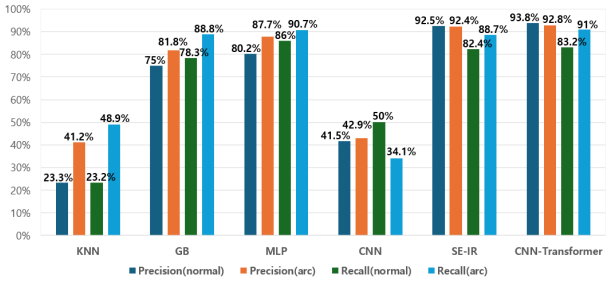


그림 10 시간 영역 입력에서 정상 및 직류 아크 클래스의 모델별 Precision과 Recall

Fig. 10 Model-wise precision and recall for the normal and DC arc classes using time-domain input

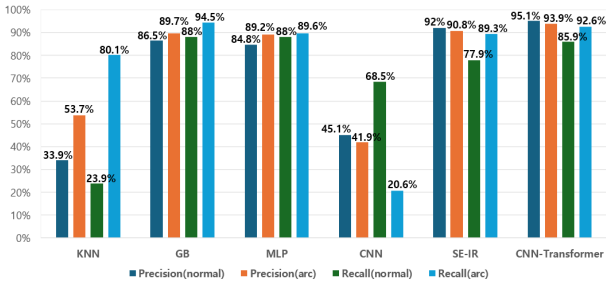


그림 11 주파수 영역 입력에서 정상 및 직류 아크 클래스의 모델별 Precision과 Recall

Fig. 11 Model-wise precision and recall for the normal and DC arc classes using frequency-domain input

시간 영역 데이터에서 정상 상태와 DC 아크 클래스에 대한 모델별 Precision과 Recall은 그림 10과 같다. CNN-Transformer의 DC Arc Precision과 Recall은 각각 92.8%와 91.0%였으며, SE-IR은 각각 92.4%와 88.7%를 기록하였다. MLP는 Precision 87.7%와 Recall 90.7%, GB는 Precision 81.8%와 Recall 88.8%를 나타냈다. 반면 KNN과 CNN의 DC Arc Precision은 각각 41.2%와 42.9%였고, Recall은 각각 48.9%와 34.1%로 낮게 나타났다. 따라서 시간 영역 데이터에서 CNN-Transformer, SE-IR 및 MLP는 상대적으로 안정적인 DC 아크 분류 성능을 보인 반면, KNN과 CNN은 오검출과 미검출이 상대적으로 크게 나타났다.

주파수 영역 데이터에서 정상 상태와 DC 아크 클래스에 대한 Precision과 Recall은 그림 11과 같다. CNN-Transformer는 DC Arc Precision 93.9%와 Recall 92.6%를 기록하였다. GB는 Recall이 94.5%로 가장 높았으며 Precision은 89.7%로 나타났다. MLP는 Precision 89.2%와 Recall 89.6%, SE-IR은 Precision 90.8%와 Recall 89.3%를 기록하였다. KNN은 Recall이 80.1%까지 증가하였으나 Precision은 53.7%였으며, CNN은 Precision 41.9%와 Recall 20.6%로 가장 낮은 성능을 보였다.

데이터 표현에 따른 DC 아크 분류 성능의 변화는 모델별로 상이하였다. GB는 주파수 영역에서 Recall이 5.7%p, Precision이 7.9%p 증가하였으며, CNN-Transformer도 Precision과 Recall이

각각 1.1%p와 1.6%p 증가하였다. 반면 CNN의 Recall은 34.1%에서 20.6%로 감소하였다. 따라서 주파수 영역 데이터가 모든 모델의 DC 아크 분류 성능을 일관되게 향상시키는 것은 아니며, 모델 구조에 따라 데이터 표현 방식의 영향이 달라짐을 확인하였다. CNN-Transformer는 AC 및 DC 아크 진단에서 모두 높은 Accuracy와 Precision 및 Recall을 기록하였다. 특히 주파수 영역 입력에서 AC 아크와 DC 아크 진단 Accuracy가 각각 97.6%와 97.3%로, 비교한 모델 중 가장 높은 성능을 나타냈다.

5. 결 론

본 논문에서는 3상 PWM 인버터의 A상 출력전류 한 채널을 이용하여 AC 출력단 및 DC 입력단 직렬 아크에 대한 인공지능 모델별 진단 성능을 비교하였다. 시간 영역과 주파수 영역 입력을 비교한 결과, 주파수 영역 입력은 전반적으로 더 높은 진단 Accuracy를 나타냈으며, 입력 데이터 표현 방식에 따른 성능 변화는 모델과 아크 발생 위치에 따라 다르게 나타났다.

모델별 비교에서는 CNN-Transformer가 AC 및 DC 아크와 두 입력 데이터 형태에서 가장 우수하고 안정적인 진단 성능을 보였으며, SE-IR이 전반적으로 그 다음으로 높은 성능을 나타냈다. 또한 GB와 MLP는 주파수 영역 입력에서 성능 향상이 두드러진 반면, CNN-Transformer와 SE-IR은 입력 형태가 달라져도 비교적 안정적인 성능을 유지하였다.

한편 일부 모델에서는 높은 Accuracy에도 불구하고 특정 클래스의 Precision 또는 Recall이 상대적으로 낮게 나타나, 직렬 아크 진단 성능을 평가할 때에는 Accuracy와 함께 클래스별 오검출 및 미검출 특성을 고려할 필요가 있음을 확인하였다. 이상의 결과는 단일 출력전류를 이용한 AC 및 DC 직렬 아크 진단의 가능성을 보여주며, 실제 적용 시 아크 발생 위치와 운전 환경을 고려하여 적절한 입력 표현 방식과 모델 구조를 선정할 필요가 있음을 시사한다.

References

[1] P. Qi, S. Jovanovic, J. Lezama, and P. Schweitzer, “Discrete wavelet transform optimal parameters estimation for arc fault detection in low-voltage residential power networks,” Electr. Power Syst. Res., vol. 143, pp. 130-139, Feb. 2017.

[2] N. Qu, J. Wang, and J. Liu, “An arc fault detection method based on current amplitude spectrum and sparse representation,” IEEE Trans. Instrum. Meas., vol. 68, no. 10, pp. 3785-3792, Oct. 2019.

[3] 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, vol. 20, no. 1, p. 162, 2019.

[4] Y. Wang, L. Hou, K. C. Paul, Y. Ban, C. Chen, and T. Zhao, “ArcNet: Series AC arc fault detection based on raw current and convolutional neural network,” IEEE Trans. Ind. Informat., vol. 18, no. 1, pp. 77-86, Jan. 2022.

[5] S. Rokocakau, G. Tresca, B. Mohammadzadeh, P. Zanchetta, G. Cirrincione, and M. Cirrincione, “Fault diagnosis using 1-D convolutional Transformer hybrid neural network for cascaded H-bridge converters,” in Proc. 2024 IEEE Energy Conversion Congress and Exposition (ECCE), pp. 3729-3736, 2024.

[6] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, “MobileNetV2: Inverted residuals and linear bottlenecks,” in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit., pp. 4510-4520, 2018.

[7] J. Hu, L. Shen, and G. Sun, “Squeeze-and-excitation networks,” in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., pp. 7132-7141, 2018.

Acknowledgements

본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원 (RS-2026-25476346) 및 정부(산업자원부)의 재원으로 한국산업기술진흥원의 지원 (RS-2026-25534585, 2026년 산업혁신인재성장지원사업)에 의하여 이루어진 연구로서, 관계부처에 감사드립니다.

저자소개



안진형 (Jin-Hyung Ahn)

Jin-Hyung Ahn received the B.S. degree in energy systems engineering from Chung-Ang University, Seoul, South Korea, in 2023. He is currently pursuing the combined Ph.D. degree in department of intelligent energy and industry with Chung-Ang University, Seoul, South Korea. His research interests include AI-based methods for arc fault and converter fault detection.



김용헌 (Yong-Heon Kim)

Yong-Heon Kim received the M.S. degree in electrical and electronics engineering from Chung-Ang University, Seoul, South Korea, in 2025. His research interests include applying real-time AI in the field of power electronics.



곽상신 (Sang-Shin Kwak)

Sang-Shin Kwak received his Ph.D. degree in Electrical Engineering from Texas A&M University, College Station, TX, USA, in 2005. From 2007 to 2010, he was an Assistant Professor at Daegu University, Gyeongsan, Korea. Since 2010, he has been working at Chung-Ang University, Seoul, Korea, where he is presently a Professor. His current research interests include the design, modeling, control, and analysis of power converters for electric vehicles and renewable energy systems as well as the prognosis and fault tolerant control of power electronics systems.