

# On-Device AI를 활용한 실시간 DC 직렬 아크 고장 검출

김완\*, 윤근호\*\*, 박화평\*

\*한국에너지공과대학교 차세대그리드

\*\*금오공과대학교 전자공학부

e-mail:a103203@kentech.ac.kr

## Real-Time Detection of DC Series Arc Faults Using On-Device AI

Wan Kim\*, Cheol-Soo Kim\*\*, Hwa-Pyeong Park\*

\*Grid Modernization, Korea Institute of Energy Technology

\*\*electronic engineering, Kumoh National Institute of Technology

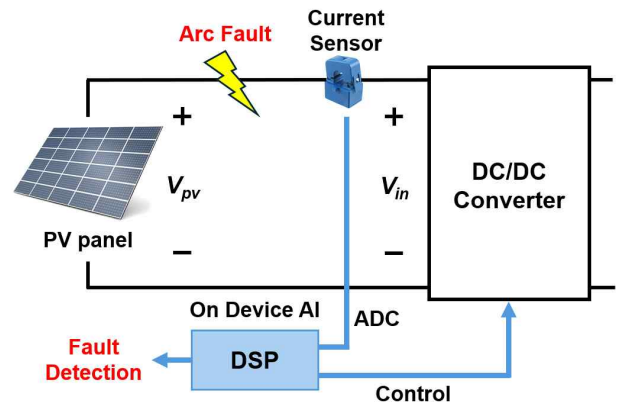
### 요약

재생에너지 확산으로 DC 직렬 아크 고장의 발생 빈도가 증가하면서 신속-정확한 검출의 필요성이 커지고 있다. 기존 AI 기반 검출법은 외부 하드웨어에 의존해 비용과 지연이 발생하는 한계가 있다. 본 논문은 DSP 기반 온디바이스 AI를 활용해 전류 신호를 직접 처리하고 랜덤 포레스트 모델로 실시간 고장을 분류하는 방법을 제안한다. 시뮬레이션과 실험을 통해 99.83%의 정확도와 UL 1699B 기준에 부합하는 속도를 달성하여 PV 시스템의 안정성과 신뢰성 향상 가능성을 입증하였다.

### 1. 서론

산업 및 기술의 발전과 세계 인구의 급격한 증가는 전력 에너지 수요를 지속적으로 증가시켰다<sup>[1]</sup>. 과거에는 비재생 에너지원에 의존했으나, 비재생 에너지원은 에너지 고갈 및 환경 오염과 연관되어 있어 지속적인 전력 에너지 수요를 충족시키기 어렵다는 단점이 있다. 따라서 재생 에너지원은 자원 고갈 및 환경 오염 측면에서 비재생 에너지원에 비해 더 나은 선택이 될 수 있다<sup>[2]</sup>. 태양 에너지는 이러한 새로운 재생 에너지원의 60%를 차지할 것으로 예상된다<sup>[3]</sup>. 그러나 태양에너지 중, PV 시스템은 DC 아크 고장이 발생할 가능성이 있다. DC 아크 고장은 전류가 DC 회로 내 전극 사이에 형성된 에어 갭을 통해 흐르는 원인으로 발생한다<sup>[6]</sup>. DC 아크 고장은 전기 회로 내 전류 경로의 위치에 따라 직렬 아크 고장과 병렬 아크 고장으로 분류된다<sup>[4]</sup>. DC 직렬 아크 고장은 DC 회로의 전류 경로를 따라 직렬로 발생하는 아크 고장을 의미하며, 전류 변화가 미미하여 감지하기가 어렵다. 반면, 병렬 아크 고장은 발생 시 전류에 상당한 변화를 일으키므로 비교적 감지하기 쉽다<sup>[5]</sup>.

기존 DC 직렬아크 고장 검출 기술은 PV 전력량 저해와 외부 기기 필요와 같은 단점이 있었다. 본 논문에서는 이러한 단점을 극복하고자 그림 1와 같이 DSP 기반 On-device AI를 활용하여 DC 직렬 아크 고장을 실시간으로 검출하는 과정을 제안한다.




[그림 1] On Device AI를 활용한 DC 직렬 아크 고장 검출 .

On-device AI란, 센서로부터 입력된 데이터를 FPGA나 DSP와 같은 On-device에서 처리하여 외부 기기 없이 실시간으로 추론을 수행하는 방식을 의미한다. On-device AI는 PV 시스템 내 DC/DC 컨버터 제어를 위한 DSP에 직접 탑재되어 AI 추론을 수행할 수 있으므로, 별도의 하드웨어나 비용 증가 없이 구현할 수 있다. 또한, 추론이 DSP 내부에서 실시간으로 수행되므로, 고장 발생 시점부터 검출까지의 지연 시간이 상대적으로 짧다.

### 2. 본론

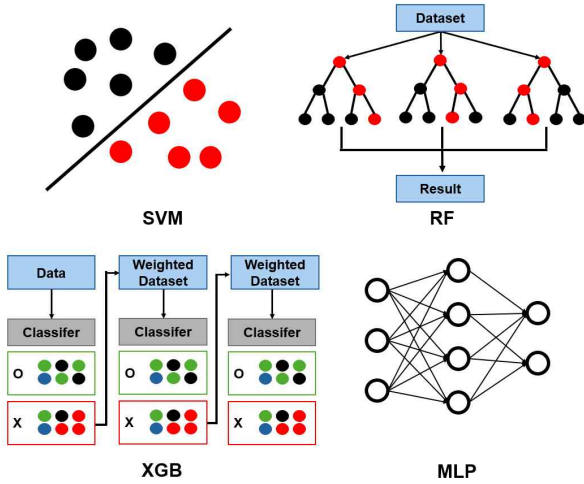
그림 2와 같이 Current Sensor를 통해 전류를 받아들인 후 시간 도메인 상에서 특징 추출을 진행한다. STM32H74I-DISCO 보드로 Nano Edge AI Studio를 통해 최댓값(Max), 최솟값(Min), 평균값(Mean), 평균 ± 표준 편차(Mean ± Std Dev)의



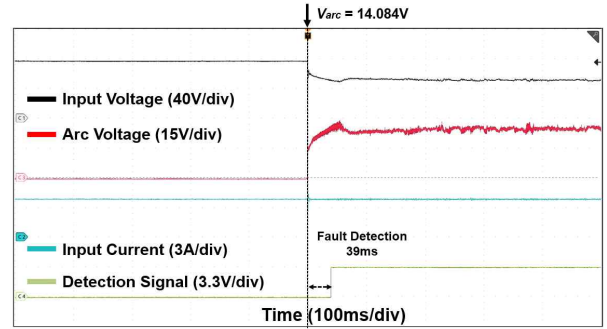
[그림 2] On-Device AI를 통한 아크 고장 검출 과정.

[표 1] ML MODEL별 정확도

Model	RAM	Flash	Accuracy
RF	4.2 KB	1.7 KB	98.83%
XBG	8.6 KB	2.8 KB	99.67%
SVM	14.7 KB	103 KB	98.16%
MLP	11.5 KB	6.1 KB	96.79%



[그림 3] 머신러닝 모델.



[그림 4] 제안된 알고리즘을 통한 아크 고장 검출

5가지 특징을 추출한다. 평균과 표준 편차에 대한 수식은 다음과 같다.

$$\mu = \frac{1}{N} \sum_{n=1}^N I_{pv}(n) \quad (1)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{n=1}^N (I_{pv}(n) - \mu)^2} \quad (2)$$

(1)의  $\mu$ 는 평균, N은 전체 샘플수,  $I_{pv}(n)$ 은 n번째 시점에서의 PV 전류로, 모든 샘플의 전류 값을 더한 후 샘플 수로 나누어 평균을 계산하는 수식이다. (2)의  $\sigma$ 는 표준편차로, 각 샘플 값이 평균으로부터 얼마나 떨어져 있는지를 나타내며, 편차를 제공하여 평균한 후 제곱근을 취하는 방식으로 전류 신호의 변동성을 계산하는 수식이다. (1)과 (2) 그리고 최대 최소를 통해 입력 전류 데이터의 시간 도메인 상의 특징 추출이 가능하다.

특징 추출이 완료되고 해당 데이터를 ML 모델로 학습하기 전에 전처리 과정이 진행된다. 입력받은 데이터의 끝부분에는 잡음과 불안정한 구간이 포함될 수 있는데, 이 부분을 제거하기 위해 Cut-Off End 기법을 적용한다. Cut-Off End 기법은 다음과 같은 수식으로 표현된다<sup>[6]</sup>:

$$X(W) = \{x_1, \dots, x_{T-W}\} \quad (3)$$

여기서 T는 전체 데이터 길이이며, W는 제거할 샘플 수를 의미

한다. 위 수식을 기반으로, 시간 도메인에서 끝부분의 W개 구간을 제거함으로써 모델 입력의 안정성과 신뢰도를 향상시킨다.

Machine Learning (ML)은 주어진 학습 데이터(training data)를 기반으로 의미 있는 패턴과 구조화된 지식을 도출하는 과정이다<sup>[25]</sup>. 이러한 ML에는 그림 3와 같이 대표적으로 Random Forest (RF), Multi-Layer Perceptron (MLP), Support Vector Machine (SVM), Extreme Gradient Boosting (XGB)등의 알고리즘이 포함된다. RF는 여러 개의 결정 트리를 앙상블로 구성하여, 다수결 방식으로 최종 예측하는 방식이다<sup>[7]</sup>. RF에 대한 수식은 다음과 같이 나타낼 수 있다<sup>[8]</sup>.

ML Model의 정확도 결과는 Table I와 같이 나타난다. RF 모델이 99.83%로 가장 높은 정확도를 나타냈으며, 그다음으로 XGB, SVM, MLP 순으로 정확도가 낮아졌다. 한편, Table I의 RAM은 모델이 추론 시 사용하는 동적 메모리를, Flash는 MCU에 저장되는 모델 자체의 크기를 의미한다. Table I의 결과를 보면, RF 모델은 가장 높은 정확도를 가지면서도 RAM과 Flash 사용량이 가장 낮은 것으로 나타난다. 이는 RF 모델이 복잡한 수치 연산이나 계층적 구조 없이, 단순한 비교와 조건 분기를 반복하는 방식으로 결과를 도출하기 때문이다. 내부적으로는 여러 개의 결정 트리를 독립적으로 구성하고, 각 트리의 결과를 종합하여 최종 판단을 내리는 구조이므로 연산 부담이 낮고 저장 공간도 효율적으로 사용된다.

그림 4는 제안된 On-Device AI를 활용한 실시간 아크 고장 검출 과정을 보여준다. 아크 발생부터 검출까지 약 39ms가 걸리고 이는 UL1966B의 검출 조건을 만족시킴을 알 수 있다.

### 3. 결론

본 논문에서는 On-Device AI를 활용한 실시간 DC 직렬 아크 고장 검출 방안을 제안한다. 제안된 방식은 PV 시스템 내 DSP에서 전류 데이터를 직접 센싱하여, 외부 연산 장치 없이도 실시간으로 아크 고장을 검출할 수 있도록 설계되었다. 여러 ML 모델을 학습시켜 비교한 결과, 가장 높은 99.83%의 정확도를 보인 RF 모델을 선택하였다. 실제 아크 고장 실험 결과, 고장 발생 후 약 39ms 이내에 고장을 검출하여, UL1699B의 기준을 만족함을 확인하였다. 또한, 일사량 변화와 같은 정상상태에서의 전압과 전류 변화에 대해서 아크고장으로 오검출하지 않음을 실험으로 입증했다. 본 논문에서 제안된 방법은 태양광(PV) 시스템을 위해 설계되었으며, DSP 내부에서 추론을 실시간으로 수행하므로 추가적인 하드웨어나 비용 증가 없이 구현할 수 있으며, 외부 기기 없이 동작하므로 고장 발생 시점부터 검출까지의 지연 시간이 짧다는 장점이 있다. 이러한 접근 방식은 실제 PV 시스템에서 비용 효율성을 향상시킬 수 있다.

#### 참고문헌

- [1] M. Hammoud, B. Shokr, A. Assi, J. Hallal, and P. Khoury, "Effect of dust cleaning on the enhancement of the power generation of a coastal PV-power plant at Zahrani Lebanon," *Solar Energy*, vol. 184, pp. 195–201, May 2019.
- [2] H.-L. Dang, S. Kwak, and S. Choi, "Different domains based machine and deep learning diagnosis for DC series arc failure," *IEEE Access*, vol. 9, pp. 166249–166261, 2021.
- [3] H. Oufettoul, N. Lamdihine, S. Motahhir, N. Lamrini, I. A. Abdelmoula, and G. Aniba, "Comparative performance analysis of PV module positions in a solar PV array under partial shading conditions," *IEEE Access*, vol. 11, pp. 12176–12194, 2023.
- [4] H.-S. Lee and H.-P. Park, "Arc fault detection with output filter design for EV charger," *The Transactions of the Korean Institute of Power Electronics*, vol. 28, no. 5, pp. 397–407, 2023.
- [5] J.-B. Ahn, J.-H. Lee, J. Lee, and H.-J. Ryu, "DWT-based parameter and iteration algorithm for preventing arc false detection in PV DC arc fault detector," *The Transactions of the Korean Institute of Power Electronics*, vol. 27, no. 2, pp. 100–105, 2022.
- [6] G. Iglesias, E. Talavera, and Á. González-Prieto, "Data augmentation techniques in time series domain: a survey and taxonomy," *Neural Computing and Applications*, vol. 35, pp. 10123–10145, 2023.
- [7] S.-H. Shin, S.-R. Lee, and J.-H. Kim, "Random forest-based training dataset supplementation and prediction of lithium-ion battery capacity," *The Transactions of the Korean Institute of Power Electronics*, vol. 28, no. 5, pp. 353–360, 2023.
- [8] D. A. Devyatkin and O. G. Grigoriev, "Random kernel forests," *IEEE Access*, vol. 10, pp. 77962–77979, 2022.