

# 환경데이터 기반 전압-전류 곡선 시뮬레이션 및 태양광 스트링 인공지능 고장진단 방법

고석환<sup>1\*</sup> · 신우균<sup>2</sup> · 주영철<sup>3</sup> · 황혜미<sup>1</sup> · 손기호<sup>4</sup> · 김한기<sup>5</sup> · 최의성<sup>6</sup>

<sup>1</sup>한국에너지기술연구원 태양광연구단, 책임연구원

<sup>2</sup>한국에너지기술연구원 태양광연구단, 연구원

<sup>3</sup>한국에너지기술연구원 태양광연구단, 선임연구원

<sup>4</sup>한국서부발전주식회사 신재생총괄실, 차장

<sup>5</sup>한국서부발전주식회사 평택발전본부, 과장

<sup>6</sup>(주)네오에너지커넥터 신재생사업부, 부사장

## Voltage - Current Curve Simulation Using the Environmental Data and Artificial Intelligence Fault Diagnosis Method for PV Strings

Ko Suk Whan<sup>1\*</sup> · Shin Woo Gyun<sup>2</sup> · Ju Young Chul<sup>3</sup> · Hwang Hye Mi<sup>1</sup> · Son Ki Ho<sup>4</sup> · Kim Han Gi<sup>5</sup> · Choi Ui Seong<sup>6</sup>

<sup>1</sup>Principal Researcher, Photovoltaic Laboratory, Korea Institute of Energy Research

<sup>2</sup>Researcher, Photovoltaic Laboratory, Korea Institute of Energy Research

<sup>3</sup>Senior Researcher, Photovoltaic Laboratory, Korea Institute of Energy Research

<sup>4</sup>Assistant Director, Renewable Energy Division, Korea Western Power Co., Ltd.

<sup>5</sup>Manager, Pyeongtaek Generation Headquarters, Korea Western Power Co., Ltd.

<sup>6</sup>Vice President, Renewable Energy Business Division, Neo Energy Connector Co., Ltd.

\*Corresponding author: korea19@kier.re.kr

OPEN ACCESS



Journal of the Korean Solar Energy Society  
Vol.43, No.6, pp.181-189, December 2023  
<https://doi.org/10.7836/kjes.2023.43.6.181>

pISSN : 1598-6411

eISSN : 2508-3562

Received: 5 December 2023

Revised: 7 December 2023

Accepted: 7 December 2023

Copyright © Korean Solar Energy Society

This is an Open-Access article distributed under the terms of the Creative Commons Attribution NonCommercial License which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

### Abstract

This paper focuses on the development and analysis of a solar photovoltaic (PV) combiner box equipped with a module capable of obtaining Voltage – Current (I-V) characteristic curves to evaluate the performance degradation and faults in a solar power plant. A deep learning algorithm was proposed for the analysis of I-V curves. Direct Current circuit breakers were applied to obtain the I-V curves of each string circuit inside the combiner box. The fault dataset was labeled through classification based on the shape of I-V characteristic curves. The fault data were directly collected through field diagnosis at the power plant, amounting to a dataset of 3,200. A GoogLeNet transfer deep learning model with a convolution neural network (CNN) was used to develop a fault diagnosis algorithm, achieving training and validation accuracies of more than 95%. Empirical research was conducted at a 1.5 MW solar power plant site. Shading and bypass diode short-circuit faults were simulated in solar PV strings to evaluate the accuracy of the algorithm. The artificial intelligence algorithm demonstrated accuracy rates of 98.67% for shading simulation and 95.06% for bypass diode short-circuit fault simulation.

**Keywords:** 태양광접속함(Solar combiner box), 실증연구(Empirical research), 딥-러닝(Deep learning), 발전량 추정(Power estimation), 음영(Shading)

## 기호 및 약어 설명

- $I$  : 태양전지 출력전류
- $I_{ph}$  : 태양전지 광전류
- $I_0$  : 초기 다이오드전류(역 바이어스 전류)
- $T$  : 절대온도
- $V$  : 태양전지 출력전압
- $R_s$  : 태양전지 직렬저항
- $R_{sh}$  : 태양전지 병렬저항
- K : 보상 정수 값

## 그리스 기호 설명

- $q$  : 전자 전하량( $1.602 \times 10^{-23}$  [C])
- $n$  : 이상계수로서  $n = 1$  임,  $k = 1.38 \times 10^{-23}$  [J/K]

## 1. 서론

탄소중립 정책 등의 보급정책으로 인해 누적 태양광 설비용량이 급격히 증가되고 있다. 탄소중립 정책에 따른 태양광설비 보급 시나리오에 따르면 2050년까지 누적용량 기준 약 460 GW 이상의 많은 설비가 설치될 계획이다. 누적 설비용량이 증가됨에 따라 운영비용 절감을 위한 태양광발전소의 유지관리 기술이 개발되고 있다. 태양광 모듈이나 스트링의 성능 및 고장을 가장 정밀하게 평가가 가능한 기술은 전압-전류 특성곡선(이하 I-V 곡선)을 이용한 분석 방법이다. 다른 열화상 이미지나, 전기자계이미지 등은 고장의 정도 파악은 가능하지만 성능저하를 명확히 평가할 수는 없다. 이와 같은 이유로 태양광 유지보수 기업은 태양광 스트링의 성능이나 고장여부를 확인하기 위해 I-V 곡선을 주로 측정한다. 중국의 H社의 경우 스트링인버터 기반의 전압-전류 특성곡선을 이용한 태양광 어레이 고장원격 인공지능 분석진단 기술개발로 태양광발전소의 이용률을 12.43% 향상시켰다고 발표를 한 바 있다<sup>1)</sup>. 해당 기술은 스트링인버터가 각 스트링에서 I-V 곡선을 수집하고, 약 7가지의 태양광모듈의 고장 라벨 데이터를 딥-러닝 학습하여 I-V 곡선 이미지를 알고리즘에 입력할 경우 고장을 판정한다. 이후 인근에 있는 서비스 엔지니어가 출동하여 고장을 해결하게 된다. 이와 유사한 기술을 국내에서도 개발을 하였는데, 태양광 모듈 및 스트링의 I-V 곡선 데이터를 이용한다. 해당 장치는 중앙집중식 인버터 시스템을 갖는 태양광 발전소의 접속함에서 동시에 I-V 곡선을 측정하여 각 스트링의 성능을 평가하고 성능저하 스트링의 판정이 용이한 장치<sup>2,3)</sup>이다. 동시에 일사량과 모듈 온도를 측정하고 시뮬레이션을 실시하여 성능저하 분석도 가능하다. 본 논문에서는 장기간 태양광발전소의 성능진단 평가를 통해 취득한 다양한 고장 I-V 곡선 데이

터를 이용한 고장진단 평가를 수행코자 하였다. 이를 위해 일사량과 모듈온도 데이터를 이용하여 I-V 곡선을 시뮬레이션하고, 고장 I-V 데이터를 정규화 라벨링 하는 방법을 제안하였다. 또한, 딥-러닝 생성모델을 이용해 I-V 수집 데이터의 고장여부에 대한 평가검증을 실시하였다.

## 2. 전압-전류 곡선 시뮬레이션 및 인공지능 알고리즘 개발

### 2.1 환경센서 기반의 전압-전류 곡선 시뮬레이션

일사량에 따른 시뮬레이션은 직렬저항과 병렬저항은 갖는 태양전지 등가 모델식<sup>4)</sup>을 이용하였다. 태양전지의 출력전류의 식(1)과 같이 정의된다. 출력전류  $I$ 를 연산하기 위해서 식(1)의 우변에 있는  $I$ 를 제거하면 연산처리가 용이하다. 태양전지에서 등가회로에서  $R_s \cong 0$ 으로 가정하면 식(2)와 같이 재 정의할 수 있다.

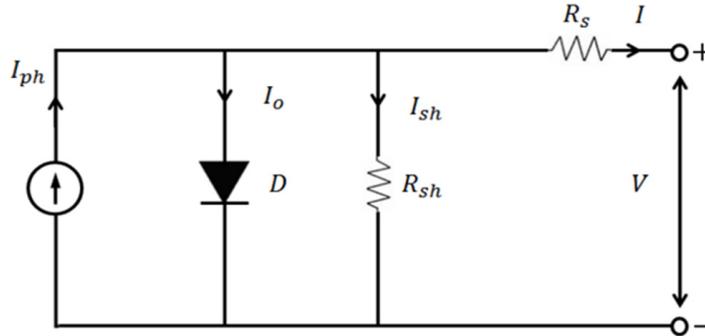


Fig. 1 Equivalent circuit for photovoltaic cell

$$I = I_{ph} - I_0 \exp \left[ \frac{qV}{nkT} \right] - \frac{(V - IR_s)}{R_{sh}} \tag{1}$$

$$I = I_{ph} - I_0 \exp \left[ \frac{qV}{nkT} \right] - \frac{V}{R_{sh}} \tag{2}$$

태양전지 셀의 종류나 버스바에 따라서 I-V곡선의 충전률(Fill Factor)이 달라지며, 이로 인해 I-V 곡선이 차이가 발생된다. 이는 Fig. 1의 태양전지 등가모델에서  $R_s$ 의 값 차이로 발생하는 것으로 추정할 수 있다.  $R_s$ 는 일사량 변경에 따라 미세하게 변경이 될 수 있다. I-V 곡선의 최대전력지점에서 미세한 차이는  $R_s$ 로 인해 발생이 된다. 즉, 태양전지 셀의 종류나 버스바가 직렬저항 성분의 특성으로 표현된다. 등가모델에서 보면 직렬저항 성분 요소는 전압 값의 변화를 일으킨다. 정밀한 I-V 곡선 시뮬레이션을 위해서는  $R_s$ 론 인한 전압 변동에 대한 보상이 가능한  $K$  보상계수를 추가한 모델 식을 식(3)과 같이 제안하였다.  $K$  보상계수의 변동은 I-V 곡선의 최대 전력동작점이 변동되는 것을 시뮬레이션 모델을 이용해 확인이 가능하다.

$$I = I_{ph} - I_0 \exp \left[ \frac{q(V - K)}{nkT} \right] - \frac{(V - K)}{R_{sh}} \quad (3)$$

태양광 모듈에 따라 차이가 발생되는데, 다양한 모듈의  $K$ 값은 STC 상태에서 0.4 ~ 0.6 사이에 분포한다는 것을 시뮬레이션을 통해 확인하였다. 확인 방법은  $K$ 값을 변경해가며, 모듈제조사가 제공한 최대전력지점이 가장 유사한 값을 찾는 것이다. 일사량이 가변됨에 따라  $K$ 값이 변경되는데, 이를 해결하기 위해 다양한 태양전지 및 버스바 수에 따른  $K$  값을 측정하였다. 측정된  $K$ 값을 일사량에 따른 회귀방정식을 유도하여 I-V 곡선을 보다 정확하게 시뮬레이션이 가능하다.

### 2.2 I-V 곡선 수집이 가능한 태양광 접속함

I-V 곡선을 수집하기 위해 발전소 현장에 설치할 접속함을 제작하였다. Fig. 2는 제작이 완료된 I-V 곡선 수집이 가능한 태양광 접속함의 내·외부 사진을 나타낸다. 일반적인 접속함의 구조와 다른 것은 각 스트링 + 및 - 단에 DC 개폐기를 설치한 것이며, DC 개폐기를 On/Off 하면서 각 스트링에 대한 I-V 곡선을 측정한다. 제어기에서는 각 스트링의 개폐기 제어뿐만 아니라 일사량 및 모듈온도 값도 측정을 한다. 해당 접속함은 DC 1500 V에서 측정이 가능토록 제작이 되었다. 제어보드에서 아날로드 전압, 전류데이터를 디지털화하여 데이터를 저장하게 된다. ADC의 샘플링 률은 144 kS/sec로 보다 정밀한 I-V 곡선데이터를 수집할 수 있다. 이후 분석에 사용되는 I-V 데이터의 포인트는 1024개로 이동 평균화하여 생성된다. 접속함은 1.5 MW 태양광발전소 내 일부 접속함과 교체공사를 통해 설치가 되었다. 본 연구에서 사용된 태양광발전소의 DC 스트링 및 상세한 태양광 모듈 정보는 Table 1과 같다. 중앙집중식 인버터의 용량은 250 kW이며, 스트링은 20개의 250 W 모듈이 직렬로 연결되어 있다.



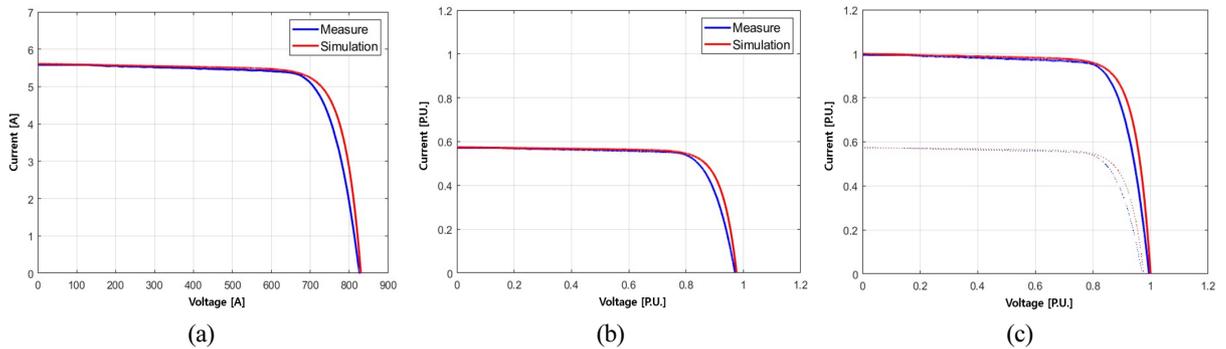
Fig. 2 Internal and external figure of the PV combiner box (left: external, right: internal)

**Table 1** PV sting and PV module information in solar plant

Item	Specification	Value
PV module information	Maximum power	250 [W]
	Voltage on maximum power point	29.9 [V]
	Current on maximum power point	8.37 [A]
	Open circuit voltage	37.1 [V]
	Short circuit current	8.76 [A]
String information	Number of series connections	20 [EA]
	Number of Parallel connections	50 [EA]
Inverter	Capacity	250 [kW]

### 2.3 딥-러닝 인공지능 알고리즘의 구현

딥-러닝 인공지능 알고리즘은 I-V 곡선 이미지의 특징을 이용한 고장진단 방법이다. 해당 알고리즘은 구글 넷(Google Net) 전이학습<sup>5,6)</sup>을 통해 생성하였다. 학습에 사용된 고장 I-V곡선 데이터는 발전소 현장진단을 통해 고장 스트링의 데이터를 정규화 하여 사용하였다. 다양한 발전소의 스트링 데이터와 측정 시 다른 일사량 데이터로부터 수집된 I-V 곡선 데이터를 분석하기 위해 정규화과정을 거치게 되었다. 정규화 과정은 태양광모듈의 정격데이터로 전압, 전류 값을 나눠 전압, 전류 값이 0 ~ 1 범위가 되도록 하는 것이다. 이를 위해 일사량 측정 및 온도 데이터를 이용하여 I-V 곡선 시뮬레이션이 필요하게 된다. 시뮬레이션 값과 측정값을 이용해 Fig. 3의 과정을 거쳐 정규화 하게 된다. 정규화 된 데이터는 각 고장에 따라 라벨링하고, 라벨링 한 데이터를 이용해 학습하게 된다.



**Fig. 3** I-V curve normalization procedure

#### (1) I-V 곡선 정규화 방법

정규화 과정은 Fig. 3과 같다. 가로축은 전압이고, 세로축은 전류 값이다. I-V 곡선 측정 시 측정된 일사량 및 온도데이터를 이용하여 Fig. 3의 (a)와 같이 시뮬레이션을 수행한다. 이후 전압, 전류 데이터를 어레이 전압 및 전류 값으로 나눠주면 (b)의 곡선으로 변경이 된다. 마지막으로 모듈 제조사의 STC 상태의 I-V 곡선과 동일하

게 되는 전압 축 방향 이동 값과 전류 축 방향 이동 값을 측정값에 적용해 정규화 할 수 있다. Fig. 3의 (c)에서 흐린 부분은 (b)의 단위화(PU) 한 이미지인데, 단위화한 시물레이션 곡선이 STC 상태로 변경될 때, 이동된 가로 축과 세로축 이동변경 크기만큼, (b)의 측정 I-V 데이터에 이동변경 된 크기의 값을 더해 줌으로서 정규화 과정이 끝나게 된다. 이와 같은 정규화 과정을 이용해 태양광발전소 스트링에서 측정된 고장 I-V 데이터를 데이터베이스화 하였다.

## (2) 딥-러닝 전이학습 알고리즘 생성

딥-러닝 알고리즘은 MatLab Machine learning tool box의 심층 신경망 디자이너를 이용하여 생성하였다. Fig. 4는 구글 넷 딥러닝 학습모델의 레이어 층을 나타낸다. 사전 훈련된 영상 신경망 구글 넷 인공지능(CNN) 모델에서 fullyConnectedLayer 및 classificationLayer을 변경해 모델을 생성이 가능하다. 고장진단 종류의 설정과 데이터 라벨링 이름을 설정하고, 출력 클래스의 수를 지정하여 학습하여 모델을 생성 할 수 있다. 본 연구에서는 라벨링을 정상상태, 고장 8가지 상태로 정의하였다.

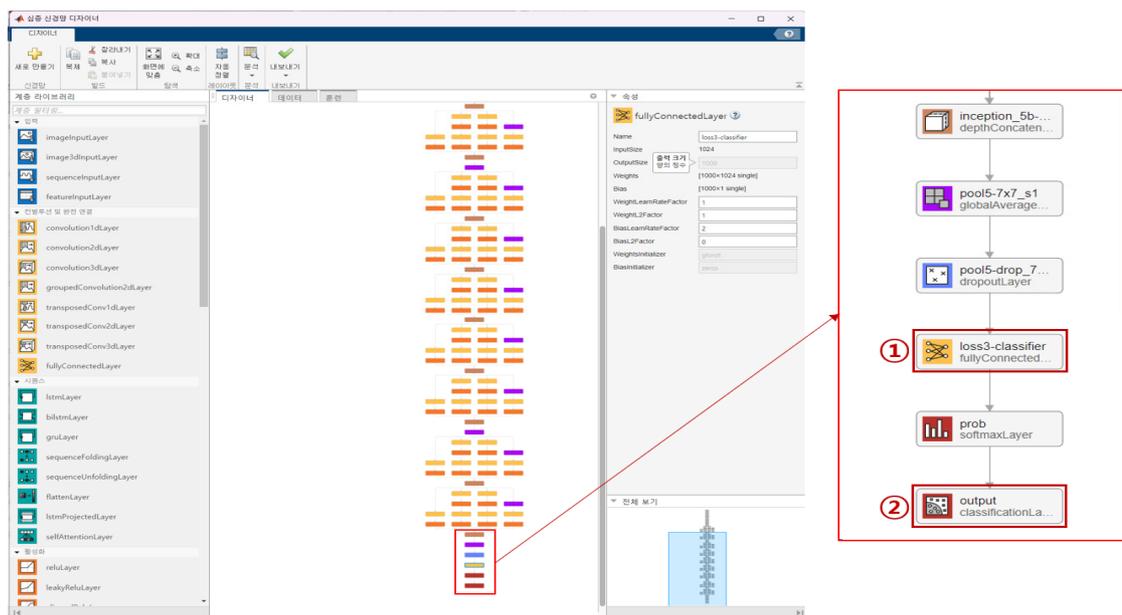


Fig. 4 Transfer learning method for Deep-learning model using Matlab tool box

Fig. 5는 라벨링을 위한 정규화 과정과 인공지능 모델의 절차도를 나타낸다. 사전에 라벨링 된 데이터 셋을 이용해 모델을 생성하였는데, 딥-러닝 모델은 총 데이터 수(3,600 Set)의 70% 학습데이터로부터 생성되었고, 30%의 검증 데이터를 이용해 혼동행렬로 정확도 평가를 실시하면 95.0% 결과 값을 나타냈다. Fig. 5는 데이터의 라벨링과 딥-러닝 모델의 구성도를 나타낸다. 발전소 현장에서도 웹에서 데이터를 입력해 분석하기 위해서 서버에 고장-I-V 데이터 셋을 이용해 파이썬 언어로 구현을 완료하였다.

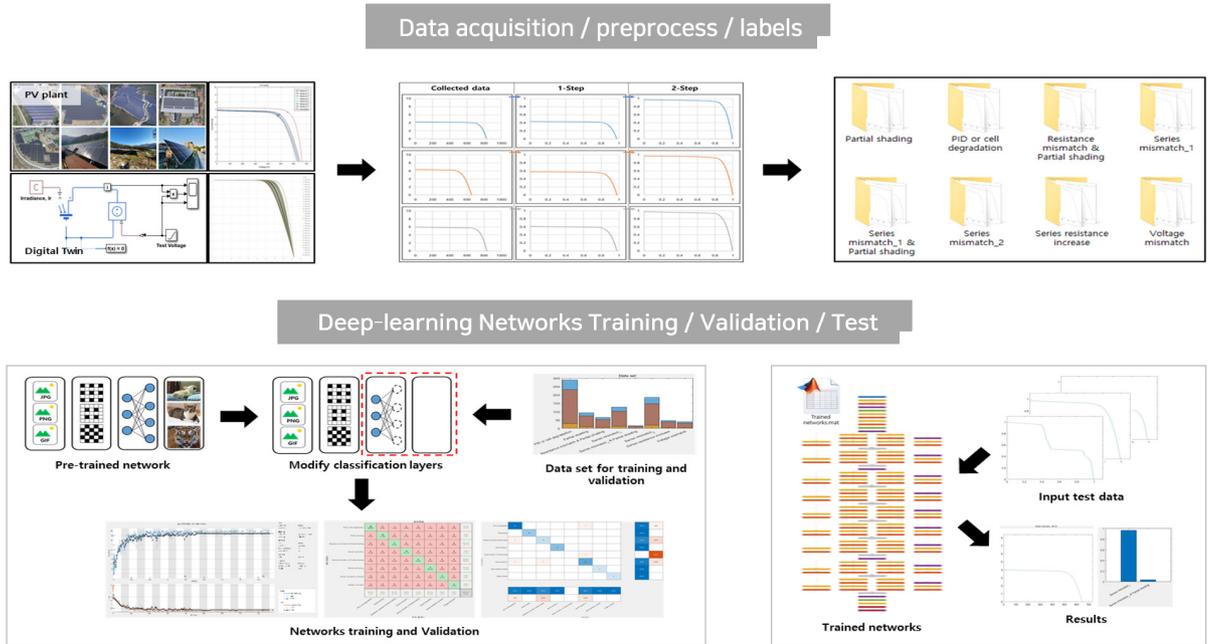


Fig. 5 Schematic diagram for Deep-learning model

### 3. 실험 및 고찰

본 연구에서는 1.5 MW 태양광발전소의 기존 설치되었던 접속함을 I-V 곡선 측정이 가능한 개발 접속함으로 교체하고 I-V 데이터를 수집하였다. 딥-러닝 모델 기반의 태양광 I-V 곡선 고장진단 모델의 성능 검증을 위해 태양광 스트링에 인위적인 고장을 인가한 후 데이터를 수집하고, 분석을 학습모델이 구현된 서버에서 실행하였다. 우선 첫 번째 고장은 20장의 모듈이 직렬로 연결이 되어 있는 스트링에서 2장의 모듈에 70% 투과차단 필름을 붙여 Fig. 6과 같이 음영상태를 모의하였다. Fig. 6에서와 같이 투과필름의 온도가 약 63°C까지 상승하는 것을 확인할 수 있었다. 측정 당시 일사량은 900 W/m<sup>2</sup>인 상태였다.



Fig. 6 Induce the Partial shading condition

현장에 설치된 접속함에서 수집된 데이터를 알고리즘 구현 서버에 접속해 분석을 실시하였다. 분석결과는 Fig. 7과 같다. 인공지능 모델의 예측결과 98.65% 음영으로 추론하였다. 또한, 1.325% 확률은 저항부식으로 인한 고장으로 추론하였다. 이러한 이유는 저항부식에 대한 고장 I-V곡선 학습데이터가 유사하게 라벨링 되었기 때문이다. 두번째 실험에서는 스트링의 바이패스다이오드의 단락 고장을 모의하였다. 바이패스다이오드를 단락고장을 인위적으로 현장에서 발생시키기 어렵기 때문에 모듈 2장을 단락상태로 연결시킨 후 데이터를 수집하였다. 분석 결과는 Fig. 8과 같다. 다이오드 단락고장 모의실험 결과는 94.93%였다.

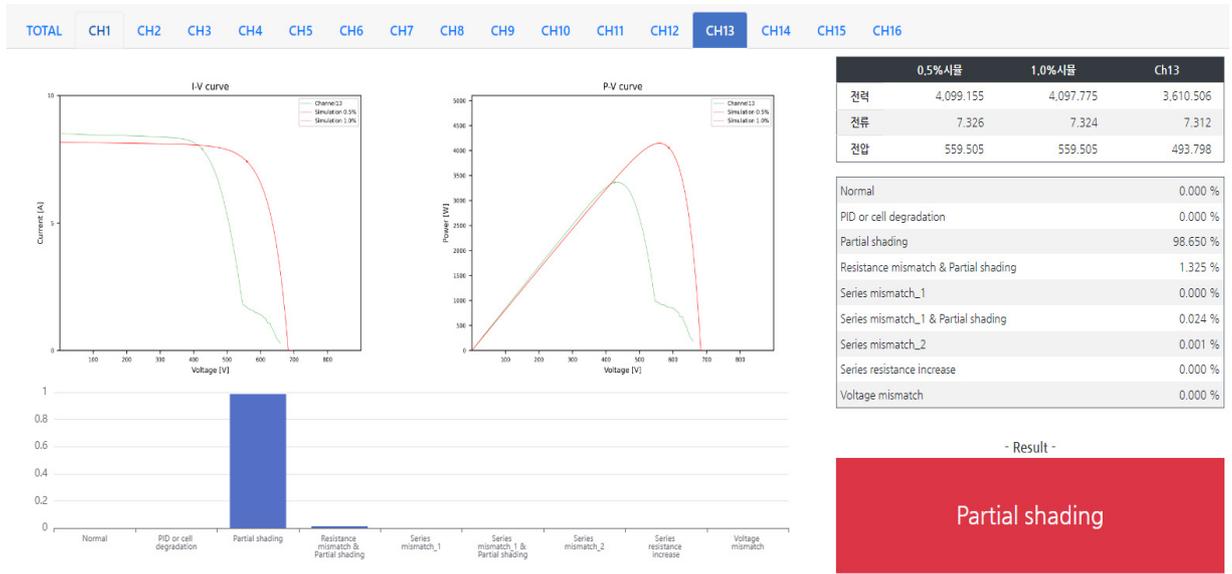


Fig. 7 Inference results for AI model (Partial shading)

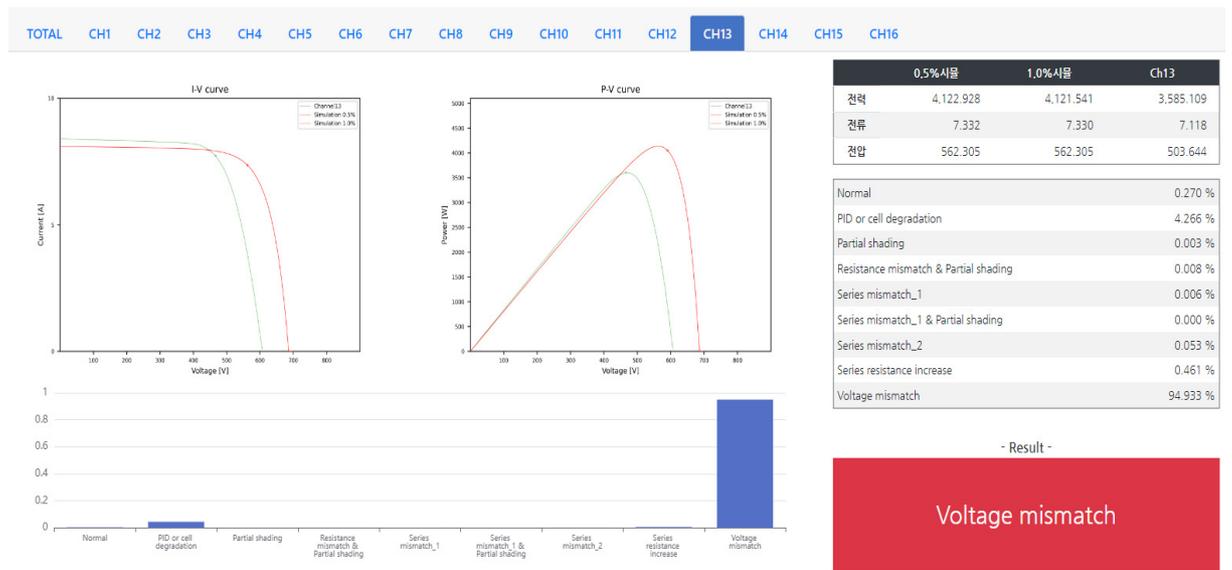


Fig. 8 Inference results for AI model

본 연구에서는 고장 I-V 데이터를 정규화 곡선으로 생성하여, 고장 종류 별로 라벨링 한 후 인공지능 모델생성을 위한 학습을 진행하였다. 모델은 웹으로 구현하였으며, I-V곡선, 일사량, 모듈온도 측정데이터 및 발전소 스트링 정보를 입력하게 되면, 인공지능모델을 통해 고장진단이 가능하다는 것을 실증연구를 통해 확인 할 수 있었다.

#### 4. 결론

16채널까지 I-V곡선 수집이 가능한 태양광 접속함을 제작하여 발전소 현장에 설치하였다. 개발된 알고리즘의 정확도를 평가하기 위해 인공지능모델에 대한 실증연구 평가를 실시하였다. 실증연구를 통해 개발된 알고리즘을 활용할 경우 태양광 스트링의 고장을 95.06% 이상으로 고장진단이 가능하다는 것을 확인할 수 있었다. 결과는 다음과 같이 정리할 수 있다.

- (1) 태양광스트링의 모듈 정보에 따라 I-V 곡선을 시뮬레이션하기 위하여 등가모델의  $R_s$  성분 보상 가능한  $K$  보상계수를 포함하는 모델 식을 제안하였다.
- (2) 고장발전소의 I-V 데이터를 고장 종류별로 라벨링 하였고, 라벨링 된 I-V 곡선 이미지 데이터를 MatLab Tool-box를 이용하여 학습한 결과 95% 이상의 정확도 결과가 도출되었다.
- (3) 음영과 바이패스다이오드 단락 고장에 대한 인공지능 모델의 정확도는 98.65%, 94.93%로 상용시스템에 적용하여 활용이 될 수 있다는 것을 확인하였다.

#### 후기

본 연구는 한국서부발전주식회사의 지원을 받아 수행한 연구 과제입니다(과제명: 태양광발전소 전기 안전성 및 이용률 향상을 위한 무정전 AI 적용 성능진단 장비, 스마트 접속함 개발 및 500 kW 발전소 실증).

#### REFERENCES

1. PR Newswire, <https://kr.prnasia.com/story/43054-9.shtml>. last accessed on the 21<sup>st</sup> January 2020.
2. Ko, S. W, Shin, W. G., and Shin, J. Y, Solar Power Plant Field Diagnosis and Evaluation Technology: Fault Diagnosis through Power Generation Simulation and Multi-Channel I-V Devices, Bulletin of the Korea Photovoltaic Society, Vol. 7, No. 2, pp. 7-15, 2021.
3. Park, Y.-N., Jang, G.-S., Ko S.-W., Kang, G.-H., So, J.-H., Hung, Y.-S., Ju, Y. C., Hwang, H.-M., and Song, H.-J., The Study of Method about the Multi-Channel Simultaneous Measurement for Measuring the I-V Curve of Photovoltaic Array, Journal of the Korean Solar Energy Society, Vol. 37, No. 4, pp 23-33, 2017.
4. Ko, S.-W., Ju, Y. C., Hwang, H. M., So, J. H., Jung, Y.-S., Song, H.-J., Song, H.-E., Kim, S.-H., and Kang, G. H., Electric and Thermal Characteristics of Photovoltaic Modules under Partial Shading and with a Damaged Bypass Diode, Energy, Vol. 128 , pp. 232-243, 2017, <http://dx.doi.org/10.1016/j.energy.2017.04.030>.
5. Mahesh, B., Machine Learning Algorithms – A Review, International Journal of Science and Reserach, Vol. 9, No. 1, pp. 381-386, 2020, <https://doi.org/10.21275/ART20203995>.
6. Machine Learning Tutorial, <https://www.geeksforgeeks.org/machine-learning/>. last accessed on the 1<sup>st</sup> January 2023.