

# 딥러닝과 I-V 곡선을 이용한 태양광 스트링 고장 진단

신우균 · 오현규 · 배수현 · 주영철 · 황혜미 · 고석환\*  
태양광연구단, 재생에너지연구소, 한국에너지기술연구원, 대전, 34129

## Fault Diagnosis of PV String Using Deep-Learning and I-V Curves

Woo Gyun Shin · Hyun Gyu Oh · Soo Hyun Bae · Young Chul Ju · Hye Mi Hwang · Suk Whan Ko\*

Photovoltaics Research Department, Korea Institute of Energy Research, Daejeon, 34129, Korea

Received August 17, 2022; Revised September 6, 2022; Accepted September 7, 2022

**ABSTRACT:** Renewable energy is receiving attention again as a way to realize carbon neutrality to overcome the climate change crisis. Among renewable energy sources, the installation of Photovoltaic is continuously increasing, and as of 2020, the global cumulative installation amount is about 590 GW and the domestic cumulative installation amount is about 17 GW. Accordingly, O&M technology that can analyze the power generation and fault diagnose about PV plants the is required. In this paper, a study was conducted to diagnose fault using I-V curves of PV strings and deep learning. In order to collect the fault I-V curves for learning in the deep learning, faults were simulated. It is partial shade and voltage mismatch, and I-V curves were measured on a sunny day. A two-step data pre-processing technique was applied to minimize variations depending on PV string capacity, irradiance, and PV module temperature, and this was used for learning and validation of deep learning. From the results of the study, it was confirmed that the PV fault diagnosis using I-V curves and deep learning is possible.

**Key words:** Deep learning, Fault I-V curves, Data preprocessing, Partial shading, Voltage mismatch

### Nomenclature

$P_{mp}$  : maximum Power, W  
 $V_{oc}$  : open circuit voltage, V  
 $I_{sc}$  : short circuit current, A  
 $V_{mp}$  : maximum voltage, V  
 $I_{mp}$  : maximum current, A  
 $PV_{sr}$  : Number of PV modules connected in series, ea  
 $PV_{pr}$  : Number of PV modules connected in parallel, ea

### Subscript

O&M : operation and maintenance  
AI : artificial intelligence  
PV : photovoltaic

### 1. 서론

국내 태양광 설비용량은 2020년 기준, 누적 설비용량은 17,323 MW, 신규 설비용량은 4,648 MW로 국가의 신·재생에너지 설비용량의 66.8%, 84.7%이다.<sup>1)</sup> 이처럼 태양광의 설비용량이 지속적으로 증가함에 따라 설치된 태양광의 안정적인 운영 및 관리를 위한 유지관리(O&M) 기술이 요구되고 있는 시기이다.

O&M 기술의 목적은 태양광 발전소의 안정적인 운영, 즉 태양광 모듈 및 인버터 등과 같은 구성 기기가 정상적으로 운전되도록 관리하는 것이다.<sup>2)</sup> 이를 위해 태양광 발전소 데이터에 대한 분석을 통해 성능저하 및 고장요인을 발견하여 개선하는 일련의 과정으로 진행된다. 관습적인 O&M은 태양광 인버터 데이터 모니터링, 태양광 모듈 및 구조물의 육안 검사, 태양광 접속함 점검 등이 수행된다.<sup>3)</sup> 하지만 이와 같은 방법으로는 발전소의 현재 성능상태와 고장을 진단평가 시 어려움이 있다. 효율적인 O&M을 위해서는 태양광 발전소에서 성능 상태 분석이 가능한 유의미한 데이터 취득을 하여야 하며, 이러한 데이터 취득을 위한 장비와 취득 데이터의 분석기술이 요구된다.

최근에는 드론에 열화상 카메라를 탑재하여 태양광발전소 전반에 관한 열적 특성을 촬영하고 분석하는 기술이 적용되고

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

있다.<sup>4,5)</sup> 태양광 인버터-레벨에서의 측정된 데이터를 기반으로 한 분석 기술 및 인공지능 기술을 적용한 태양광 발전소의 발전 상태 및 고장을 진단하는 기술개발이 진행되고 있다.<sup>6,7)</sup>

이러한 기술들은 태양광 발전소의 성능저하로 인한 손실에너지 정도만 판정하는 기술이라고 할 수 있다. 진단 기술의 다양화와 진단 정확도 향상을 위해서는 스트링 단위의 상세한 진단 기술이 필요하다.

본 논문에서는 태양광 DC 스트링-레벨에서의 고장 진단을 위해 고장 I-V 곡선을 딥러닝에 학습하여 모델의 정확도를 평가하는 연구를 수행하였다. 딥러닝 모델의 학습용 I-V 특성곡선 데이터 수집을 위해 태양광 발전시스템에서 I-V 곡선을 측정하였다. 측정 시 일사량 및 모듈온도 값이 다르고, 측정된 데이터 셋의 수와 의 학습모델의 정확도를 고려하여 측정된 I-V 곡선을 다른 환경조건(일사량 및 모듈표면온도)에서도 적용될 수 있도록 전처리 과정을 수행하였다. 마지막으로, 전처리 된 I-V 곡선을 딥러닝에 학습시킨 후, 학습 및 검증에 사용되지 않은 외부 데이터를 입력하여 딥러닝 모델에 대한 평가를 수행하였다.

## 2. I-V 곡선 학습 데이터 생성

### 2.1 I-V 곡선 측정 시스템

다양한 고장 I-V 곡선 데이터를 이용하여 학습 모델을 훈련시켜야 되기 때문에 고장 I-V 곡선 데이터 셋이 필요하다. 고장 I-V 곡선을 수집하기 위해 Fig. 1과 같이 연구원 내 구축된 10kW 태양광시스템을 이용하였다. 10 kW 태양광시스템은 5 kW 태양광 스트링 2회로가 병렬로 연결되어 있으며, 5 kW 태양광 스트링은 450 W급 하프컷 셀 태양광 모듈이 11장이 직렬로 연결되어 있다. 태양광 모듈의 사양은 Table 1과 같다.



Fig. 1. 10 kW PV System in KIER

Table 1. Spec. of PV module

Pmp [W]	450
Voc [V]	49.97
Isc [A]	11.40
Vmp [V]	42.01
Imp [A]	10.72

학습용 I-V 데이터는 0에서 개방전압까지 변화될 때 매칭되는 전류데이터 셋, 측정 시 일사량, 모듈 표면온도로 구성된다. 데이터를 수집하기 위해 10 kW 태양광시스템에 설치된 I-V 곡선 측정 장비 및 센서를 이용하였으며, 장비 및 센서에 사양은 설명은 Table 2, 3, 4와 같다.

I-V 곡선 데이터 수집은 국내 NEO ENERGY Connect社의 어레이 테스트 장비를 사용하였으며, 해당 장비는 커패시터 부하에 순간적으로 충전 되는 전압, 전류 값을 측정한다. I-V 곡선 측정을 위한 장치는 태양광 접속함에 내장되어 있다.

일사량은 모듈의 설치 각도와 동일한 각도로 설치되었으며, 모듈 표면 온도 데이터 수집은 대표 모듈 후면에 열전대 센서를 설치해 수집되었다.

### 2.2 태양광 스트링 고장 모의

2.1 절의 데이터 수집 시스템을 이용하여 태양광 스트링의 고장 I-V 곡선을 측정하였다. 모의된 고장은 2가지로 태양광 스트링에서 주요 고장 요소인 부분 음영과 전압 미스매치이다. 부분 음영은 태양광 스트링 주변의 구조물, 스트링 간 이격거리, 태양광 모듈 표면의 오염 등 다양한 주변 원인에 흔히 발생하여 출력 손실을 발생하는 고장 요소이다. 부분 음영은 Fig. 2와 같이 태양광 모듈 위에 검은색 시트지를 올려 모의하였으며, 검은색 시트지의 수를 1장, 2장, 3장으로 증가시켰다.

전압 미스매치는 태양광 스트링의 개방 전압이 감소하는 경우로 정의하였으며, 개방 전압이 감소하는 원인으로 바이패스 다이오드의 쇼트 고장, 태양광 스트링의 오결선 등이 있다. 전압 미스매치는 Fig. 3과 같이 태양광 스트링 내 태양광 모듈을 1장

Table 2. Spec. of I-V measurement equipment

DC Input Voltage [V]	< 1,000
DC Input Current [A]	< 40
Sampling [kS/s]	144
Measurement time[ms/ch]	260
Measurement accuracy [%]	< ±1
Number of measurement channels	20

Table 3. Spec. of pyranometer

Wavelength range [nm]	285 to 2800
Measurement range [W/m <sup>2</sup> ]	0 to 1600
Response time [s]	0.7 ≤ (63%)
	2 ≤ (95%)
Non linearity [%]	< 0.5

Table 4. Spec. of thermocouple

Measurement Temperature range [°C]	-200 to 1250
Measurement standard error[%]	0.75



Fig. 2. Simulated partial shading using black sheets



Fig. 3. Simulated Voltage mismatch using MC4 cable

또는 2장을 MC4 케이블을 이용해 건너뛰어 태양광 스트링을 연결해 모의하였다.

### 2.3 고장 I-V 곡선 측정 및 전처리

고장 I-V 측정을 위한 측정 장비와 계측기 및 고장 모의 방법이 준비되어 I-V 곡선을 측정하기 위한 실험을 진행하였다. 실험은 2022년 7월 29일 10시 30분부터 16시 00분까지 진행하였으며, 측정 당시 기상은 구름이 다소 있었으나, 전반적으로 맑은 날씨였다. 일사량은 360 ~ 700 W/m<sup>2</sup>과 800 ~ 900 W/m<sup>2</sup>이었으며, 모듈 온도는 47 ~ 63°C이었다.

Fig. 4는 부분 음영을 모의한 경우로 I-V 곡선의 패턴은 계단식 I-V 곡선으로 나타난다. 시트지 개수에 따라 부분 음영을 1, 2,

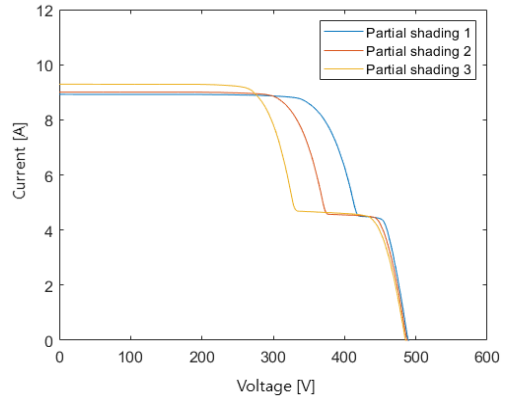


Fig. 4. I-V curves of partial shading according to number of black sheets




Fig. 5. I-V curves of voltage mismatch


3으로 나누어 보면, 시트지 개수가 증가함에 따라 계단의 길이가 길어졌다. 하지만, 계단식 I-V 곡선의 시작 부분은 검은색 시트지 모의한 부분 음영 면적이 동일하므로 같은 위치였다.

Fig. 5는 전압 미스매치를 모의한 경우로 I-V 곡선의 패턴은 개방 전압이 감소한 형태로 나타난다. 전체 태양광 스트링에서 태양광 모듈의 수가 1개 없는 경우와 2개 없는 경우를 비교하면 모듈의 수가 증가할수록 모듈 1장의 개방 전압만큼 전체 태양광 스트링의 개방 전압이 감소하는 특성을 보였다.

Fig. 4와 Fig. 5의 I-V 곡선은 일사량은 약 800 W/m<sup>2</sup>과 약 900 W/m<sup>2</sup>, 모듈 온도는 약 50°C와 약 60°C에서 측정되었다. 그 결과, I-V 곡선 간의 약간의 편차는 있지만 개방 전압과 단락 전류 지점이 유사하다.

하지만, 일사량과 모듈 온도가 다른 조건에서 측정된다면, 같은 고장이라도 Fig. 6과 같이 전압과 전류의 범위가 달라진다. 모든 경우의 수를 고려한 많은 양의 데이터가 있다면, 일사량과 모듈 온도가 다르더라도 인공지능의 학습 정확도는 어느 정도 확보할 수 있다.

또한, 많은 양의 데이터를 확보하기 위해서는 시간적·경제적 비용이 필요할 뿐만 아니라 많은 데이터로 인한 인공지능의 과도한 학습 시간 등의 문제가 발생할 수 있다.



**Fig. 6.** Difference between I-V curves according to irradiance and module temperature


I-V 곡선과 인공지능을 결합한 연구의 초기 단계로, 데이터를 수집해 나아가는 과정 속에서 데이터의 양으로 인한 학습 결과의 영향을 최소화하기 위해 측정된 데이터에 전처리 과정을 적용하였다. I-V 곡선의 전처리는 태양광 스트링의 정격 용량, 측정 당시의 일사량과 모듈 온도 차이에 따른 전압과 전류 값을 0 과 1 사이에 데이터가 구획되도록 정규화 하는 과정이다.

전처리 과정에는 측정 당시 일사량과 모듈 온도를 이용하여 시뮬레이션 된 정상 상태의 I-V 곡선이 사용된다. Fig. 7은 측정 및 시뮬레이션 I-V 곡선이다. Fig. 7의 태양광 모듈 사양은 Table 1과 같으며, 태양광 모듈이 직렬로 11개 연결된 태양광 스트링이다.


I-V 곡선의 전처리는 2단계로 진행되는데 1단계는 측정 및 시뮬레이션 I-V 곡선의 전압과 전류 값을 식 (1)~(4)과 같이 태양광 스트링의 정격용량으로 나누어주는 것이다. 이 과정을 거치게 되면 Fig. 7의 측정 및 시뮬레이션 I-V 곡선은 Fig. 8과 같이 0 과 1 사이의 범위에 놓이게 된다.

$$V_{1차, 측정} = V_{측정} / (V_{oc} \cdot PV_{sr}) \quad (1)$$

$$V_{1차, 시뮬} = V_{시뮬} / (V_{oc} \cdot PV_{sr}) \quad (2)$$



**Fig. 7.** Measurement and simulation I-V curves



**Fig. 8.** Measurement and simulation I-V curves after 1st pre-processing

$$I_{1차, 측정} = I_{측정} / (I_{sc} \cdot PV_{pr}) \quad (3)$$

$$I_{1차, 시뮬} = I_{시뮬} / (I_{sc} \cdot PV_{pr}) \quad (4)$$


전처리 2단계는 1차 전처리 과정을 거친 시뮬레이션 I-V 곡선의 단락 전류와 개방 전압을 1로 만드는 계수를 계산하고(식 (5), (6)), 그 값을 1차 전처리 과정을 거친 측정 I-V 곡선의 전압과 전류 값에 곱해준다(식 (7), (8)). 시뮬레이션 I-V 곡선의 개방 전압과 단락 전류를 1로 만들어 줌으로써, 측정 환경에서의 기준 값이 되어 일사량과 모듈 온도가 달라져도 같은 범위 내에서 I-V 곡선이 위치할 수 있다.

$$V_{factor} = 1 / V_{oc, 1차 시뮬} \quad (5)$$

$$I_{factor} = 1 / I_{sc, 1차 시뮬} \quad (6)$$

$$V_{2차, 측정} = V_{1차, 측정} \cdot V_{factor} \quad (7)$$

$$I_{2차, 측정} = I_{1차, 측정} \cdot I_{factor} \quad (8)$$



**Fig. 9.** Measurement and simulation I-V curves after 2nd pre-processing

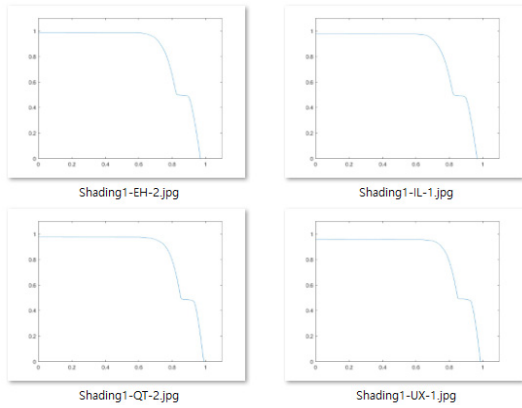


Fig. 10. I-V curves saved as image files after pre-processing

측정된 고장 I-V 곡선은 2단계의 전처리 과정을 거친 후, Fig. 10과 같이 이미지 파일로 저장이 되고, 이미지 데이터를 이용하여 딥러닝 학습에 사용된다.

### 3. 딥러닝 모델의 학습, 검증 및 시험

#### 3.1 딥러닝 모델의 학습 및 검증

인공지능 분야 중 딥러닝은 머신러닝의 인공지능망(Artificial Neural Network)이 발전한 기술로 이미지나 영상 데이터를 학습하고 분석하는데 널리 사용되고 있다. 본 연구에서도 고장 I-V 곡선을 이미지 파일 형태로 저장하고, 이미지 데이터를 이용해 딥러닝 모델을 생성하고, 모델의 성능을 평가하는 연구를 수행하였다.

딥러닝 모델은 구글넷 모델을 이용하였으며, Matworks社의 Deep Learning Toolbox을 이용하여 딥러닝 모델을 생성하였다. I-V 곡선 고장 진단을 위한 딥러닝은 사전 훈련된 인공 신경

망인 구글넷 모델을 전이 학습해 구현하였다. 전이 학습은 Fig. 11과 같이 사전 훈련된 인공 신경망의 Fully connected layer와 Classification layer를 변경한다. 검증된 인공 신경망에 사용자가 원하는 이미지 파일을 훈련시킴으로써 인공 신경망의 정확도를 확보하고 훈련 시간을 최소화할 수 있다.

딥러닝 신경망 모델의 학습 및 검증에 사용된 이미지 데이터는 부분 음영 40장, 전압 미스매치 40장 총 80장이다. 전체 80장 중 랜덤으로 80%인 64장은 학습에 사용되었고, 20%인 16장은 검증에 사용되었다.

랜덤으로 선정된 64장의 학습 데이터로 훈련된 딥러닝 모델에 16장의 검증 데이터를 입력하여 혼동 행렬로 검증한 결과는 Fig. 13과 같다. 혼동 행렬의 출력 클래스는 실제 고장을 의미하여, 목표 클래스는 훈련된 딥러닝 모델이 예측한 고장을 의미한다.

혼동 행렬을 통해 훈련된 딥러닝 모델을 분석한 결과, 검증에 사용된 데이터 16장 중 8장은 부분 음영, 8장은 전압 미스매치이며, 훈련된 딥러닝 모델은 모든 고장을 올바르게 분류하였다.

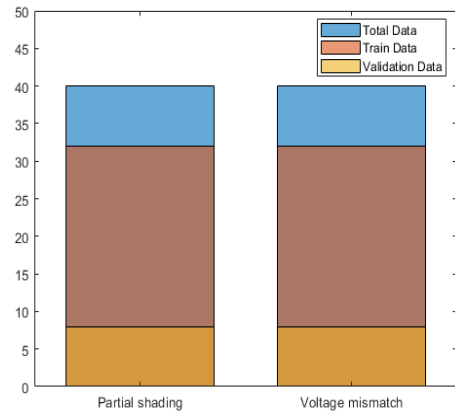


Fig. 12. Image data used for training and validation of deep learning neural networks

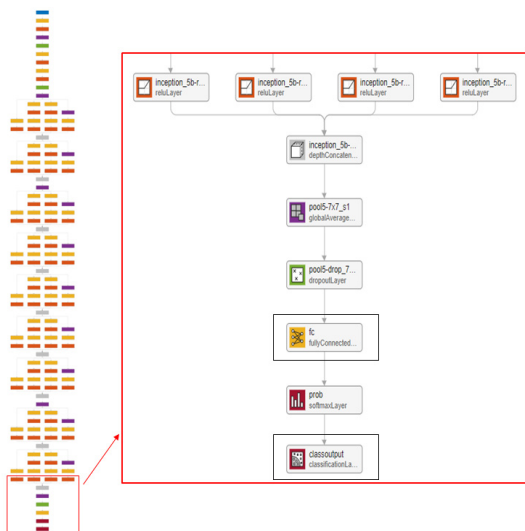


Fig. 11. Transfer learning using Google net




Fig. 13. Validating trained deep learning neural networks using confusion matrix

### 3.2 훈련된 딥러닝 모델 시험

고장 I-V 데이터를 이용한 훈련된 딥러닝 신경망 모델은 높은 정확도로 고장을 분류하였다. 하지만, 학습과 검증에 사용된 전체 데이터 수가 적기 때문에 일부를 분할하여 훈련 및 검증된 딥러닝 모델은 과적합(Overfitting)이 될 수 있다. 훈련된 신경망의 과적합을 판단하기 위해, 학습과 검증에 사용되지 않은 외부 데이터를 이용하여 훈련된 딥러닝 모델을 시험하였다.

시험 데이터는 실제 운영 중인 각기 다른 3개의 태양광 발전소에서 고장 I-V 곡선을 1개씩 샘플링하였다. 샘플링 된 I-V 곡선(입력,  $x$ )이 클래스(출력,  $k$ )에 속하는 확률은 식 (9)와 같이 계산된다.

$$\hat{P}(k|x) = \frac{P(x|k)P(k)}{\sum_{j=1}^K P(x|j)P(j)} \tag{9}$$

여기서,  $P(x|k)$ 는 클래스  $k$ 에 대한  $x$ 의 조건부 확률,  $P(k)$  클래스  $k$ 에 대한 사전 확률,  $K$ 는 클래스의 수이다.

첫 번째 시험 데이터는 Fig. 14로 태양광 스트링 간 이격 거리가 협소하여 특정 시간대에 앞 열로 인해 뒷 열에 부분 음영이 발

생한 I-V 곡선 데이터이다. 딥러닝 모델에 입력 시킨 결과는 Fig. 15와 같다. 훈련된 딥러닝 모델은 99.9%로 입력된 고장 I-V 곡선을 부분 음영으로 판정하였다.

두 번째 시험 데이터는 Fig. 16으로 태양광 스트링의 직렬로 연결된 모듈의 수가 정상 대비 개수가 적은 I-V 곡선 데이터이다. 딥러닝 모델에 입력 시킨 결과는 Fig. 17과 같다. 훈련된 딥러닝 모델은 99.2%로 입력된 고장 I-V 곡선을 전압 미스매치로 판정하였다.

세 번째 시험 데이터는 Fig. 18로 태양광 스트링의 다수 모듈의 전면에 국부적 오염이 많이 발생한 모듈로 부분 음영과 바이패스 다이오드 고장이 있는 I-V 곡선 데이터이다. 딥러닝 모델에 입력 시킨 결과는 Fig. 19와 같다. 훈련된 딥러닝 모델은 78.1%로 입력된 고장 I-V 곡선을 전압 미스매치로 판정하였다. 딥러닝 모델의 학습 데이터인 Fig. 4와 Fig. 5를 보면 Fig. 4는 두드러진 계단식 I-V 곡선이며, Fig. 5는 전압이 감소한 I-V 곡선이다. 학습 데이터를 기준으로 딥러닝 모델이 Fig. 18을 판단했을 때는 전압 미스매치 I-V 곡선의 패턴에 더 유사하므로 전압 미스매치에 대한 백분율이 더 큰 결과가 도출되었다.




Fig. 14. First test data




Fig. 16. Second test data

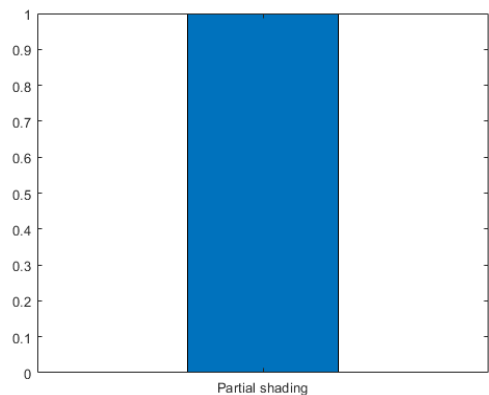


Fig. 15. First test data result using trained deep learning neural network

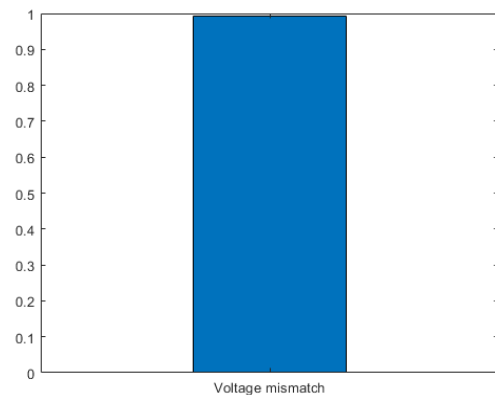


Fig. 17. Second test data result using trained deep learning neural network

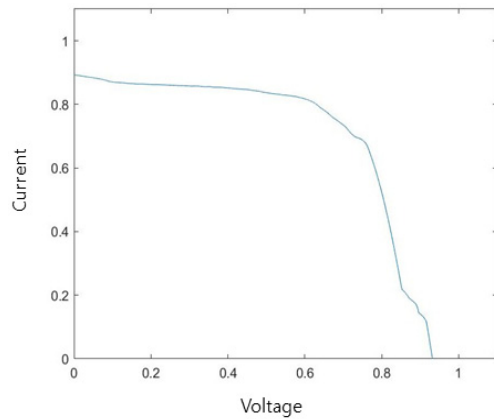


Fig. 18. Third test data

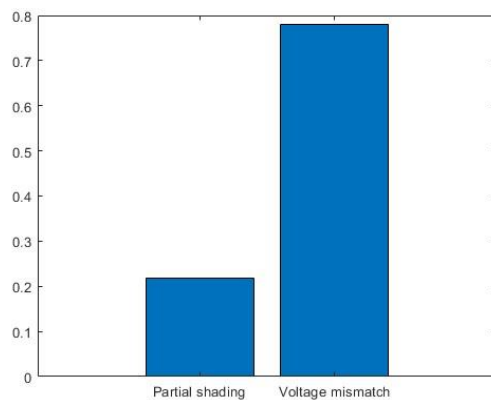


Fig. 19. Third test data result using trained deep learning neural network

## 4. 결론

본 논문에서는 태양광 발전소의 고장 진단 기술의 방법으로 태양광 스트링의 I-V 곡선 데이터와 딥러닝 기술을 이용하는 연구를 진행하였다.

딥러닝 모델의 학습에 사용되는 I-V 곡선 데이터의 스트링 용량 및 환경 조건에 따른 편차를 최소화하기 위해 데이터 전처리 기술을 개발하였으며, 이를 활용하여 모의된 고장 I-V 곡선 데이터를 변환하여 딥러닝 모델을 학습, 검증, 시험하였다.

모의된 고장 I-V 곡선 내에서 학습과 검증이 수행된 딥러닝 모델은 매우 높은 정확도로 고장을 분류함을 확인하였다. 또한, 학습과 검증에 사용된 데이터가 아닌 외부 데이터의 경우에는 학습 데이터와 유사한 I-V 곡선 패턴이면 정확히 고장을 판단하

였다.

하지만, 외부 데이터가 기존의 학습 데이터 내에서 중복이 된다면 더 유사한 쪽으로 고장을 진단함을 확인하였다.

다양한 고장 상황에서의 태양광 스트링 I-V 곡선 데이터를 충분히 수집하면서, 수집된 데이터를 활용한 딥러닝 모델의 학습 최적화를 위한 Layer에 대한 추가적인 연구가 필요하다. 지속적인 연구를 통해 향후에는 태양광 O&M 분야에서 인공지능과 결합된 진단 기술이 활용될 수 있을 것이다.

## 후 기

본 연구는 한국에너지기술평가원 에너지기술개발사업의 지원을 받아 수행되었습니다(과제번호: 20213030010340).

## References

1. 한국에너지공단 신재생에너지정책실, 2020년도 신·재생에너지 보급통계(확정치) 결과.
2. Di Lorenzo, Gianfranco, G., Araneo, R., Mitolo, M., Nicolai, A., & Grimaccia, F., Review of O&M practices in PV plants: Failures, solutions, remote control, and monitoring tools, *IEEE Journal of Photovoltaics*, 10(4), pp. 914-926 (2020).
3. Klise, Geoffrey Taylor, & Balfour, John., A Best Practice for Developing Availability Guarantee Language in Photovoltaic (PV) O&M Agreements. United States. <https://doi.org/10.2172/1227340>
4. Rezk, M., Aljasm, N., Salim, R., Ismail, H., & Nikolakakos, I., Autonomous PV Panel Inspection With Geotagging Capabilities Using Drone, ASME International Mechanical Engineering Congress and Exposition, *American Society of Mechanical Engineers*, Vol. 85611, V07AT07A040 (2021).
5. Henry, C., Poudel, S., Lee, S. W., & Jeong, H., Automatic detection system of deteriorated PV modules using drone with thermal camera, *Applied Sciences*, 10(11), 3802(2020).
6. Shin, W. G., Shin, J. Y., Hwang, H. M., Park, C. H., & Ko, S. W., Power Generation Prediction of Building-Integrated Photovoltaic System with Colored Modules Using Machine Learning, *Energies*, 15(7), 2589 (2022).
7. Kurukuru, V. S. B., Haque, A., Khan, M. A., Sahoo, S., Malik, A., & Blaabjerg, F., A review on artificial intelligence applications for grid-connected solar photovoltaic systems, *Energies*, 14(15), 4690 (2021).