

# Automatic Failure Diagnosis of PV Array by Neural Network Using String I-V Curve and Differential Data from Reference

Yoshiki TAKAHASHI<sup>\*1‡</sup>Yuzuru UEDA<sup>\*2</sup>

## ストリング I-V カーブおよび参照基準との差分データを用いたニューラルネットワークによる太陽電池アレイの自動不具合診断

高橋 芳輝<sup>\*1‡</sup>植田 譲<sup>\*2</sup>

### Abstract

This study uses string I-V curve to automatically diagnose failures in photovoltaic (PV) array. Detecting PV array failures is necessary for the safe operation of PV systems. In this study, a neural network is used to automatically determine the cause of independent and combined failures in PV array with high accuracy. Furthermore, after determining the defects, the rate of decrease of the failed cell current is detected and the series resistance value is estimated to quantitatively diagnose the failure. For this purpose, this study uses the difference data between the string I-V curve and the reference I-V curve, which is the I-V curve during normal power generation, to efficiently extract the characteristic values of the failure. As a result of verification using the measured I-V curves, the factors of single and combined failures were automatically determined with high accuracy (97.8%), and the rate of decrease of the failure cell current was successfully detected and the series resistance value was estimated.

**Keywords:** Photovoltaic, I-V curve, Failure diagnosis, Machine learning

キーワード：太陽光発電, I-V カーブ, 不具合診断, 機械学習

## 1. はじめに

2009年に開始された太陽光発電(PV)の余剰電力買取制度や2012年に開始された固定価格買取制度により、PVの導入が急拡大してきた。また、2050年のカーボンニュートラルの実現に向け、今後とも再生可能エネルギー源としてPVの導入拡大が見込まれる。一方、PVシステムを安全かつ効率的に運用していくには、システムの保守点検が必要不可欠である。しかし、システムの高経年化や導入拡大に対して、電気保安人材の高齢化が進む一方、電気保安分野への入職者は減少している。こうした課題を克服するため、電気保安分野においてはIoTやAI技術を導入することで、保安力の維持・向上と生産性の向上を両立した電気保安のスマート化への需要が高まっている。

PVシステムにおけるPVアレイに発生した不具合を検出する方法として電流-電圧特性(I-Vカーブ)を用いた手法がある。I-Vカーブは不具合に応じて特性が変化するため、PVアレイ上の詳細な不具合状況を診断することに適している。しかし、I-Vカーブの測定はPVモジュールレベルでは、配線の取り外しなどが困難であり、最小でもストリング単位での測定が現実的である。そこで、本研究ではPVアレイに発生した不具合をストリングI-Vカーブを用いることで自動診断する手法を提案する。

I-Vカーブを用いた不具合診断手法として、I-Vカーブの特性値を用いた手法がある<sup>2,9)</sup>。ここで特性値とはI-Vカーブの短絡電流( $I_{SC}$ )、開放電圧( $V_{OC}$ )、最大出力( $P_{max}$ )、最大出力動作電流( $I_{Pm}$ )、最大出力動作電圧( $V_{Pm}$ )、曲線因子( $FF$ )などを指す。 $FF$ による閾値を用いた不具合判定手法では、目視での判定が困難な僅かな不具合の検出に成功してい

\*1 Graduate School of Engineering, Tokyo University of Science, 6-3-1, Niiijuku, Katsushika-ku, Tokyo 125-8585, Japan  
‡e-mail: 4321533@ed.tus.ac.jp

\*2 Professor, Faculty of Engineering, Tokyo University of Science  
Received: January 24, 2023, Accepted: February 22, 2023

\*1 東京理科大学大学院 工学研究科  
(〒125-8585 東京都葛飾区新宿6-3-1)  
‡e-mail: 4321533@ed.tus.ac.jp

\*2 東京理科大学 工学部 教授  
(原稿受付: 2023年1月24日, 受理日: 2023年2月22日)

る<sup>2)</sup>。また、 $I_{SC}$ 、 $V_{OC}$ 、 $I_{Pm}$ 、 $V_{Pm}$ 、 $FF$ によるパターン認識手法では、短絡故障の高精度検出に成功している<sup>3)</sup>。しかし、これらの手法は正常または不具合の2値判定に留まっており、複数の不具合の要因を推定することは困難である。 $V_{OC}$ 、 $I_{Pm}$ 、 $V_{Pm}$ および近似式により算出した直列抵抗( $R_s$ )に対して、機械学習手法の一つである決定木を用いた不具合判定手法では短絡故障、直列抵抗の急激な増加、部分影およびこれらの複合不具合の判定に成功している<sup>4)</sup>。しかし、本手法は特性値のみを用いて不具合判定を行うため、概形が酷似したI-Vカーブによる不具合の判定は困難である。例えば、複数の部分影によって緩やかな段が生じたI-Vカーブと並列抵抗の低下によって $I_{SC}$ 付近の勾配が変化したI-Vカーブなどが挙げられる。したがって、以上に示した特性値のみを用いた不具合判定手法ではI-Vカーブの情報量が損失するため、I-Vカーブの形状変化がより僅かとなる不具合に対しては判定が困難となり、詳細な不具合の判定には課題があると考えられる。

そこで、I-Vカーブの情報量を落とさずに不具合を診断する手法として、ニューラルネットワーク(NN)を用いた手法が提案されており、セル割れや部分影によりI-Vカーブ上に僅かな変化が現れる不具合の検出に成功している<sup>10)</sup>。しかし、複合的な不具合の検出については十分な検討がされておらず、実用化にはまだ改善の余地があると考えられる。

以上より、本手法では複数のNNを用いることで測定したストリングI-Vカーブから単独不具合および複合不具合の要因を自動判定する手法を提案する。さらにNNによる不具合の判定結果に基づいて、不具合セル電流の低下率の検出、直列抵抗値の推定を行うことで不具合状況をより定量的に自動診断する。

最後に本論文では不具合を模擬したストリングのI-Vカーブを測定し、これらの実測データに対して本手法を適用することで、本手法の有効性を検証する。

## 2. PVアレイの不具合とI-Vカーブ

Table 1に本研究で想定した不具合とその際に生じるI-Vカーブの形状変化を示す。セル電流( $I_{cell}$ )低下はPVモジュール内のセルに影や断線が発生することによって、ストリング内で局所的に発電電流が低下する不具合である。 $I_{cell}$ 低下が生じるとストリング内のバイパスダイオードの影響によりI-Vカーブ上には段が現れる。また、配線の接続不良や熱ストレスによる経年劣化などにより $R_s$ が増加すると $V_{OC}$ 付近の勾配が低下し、絶縁不良や水蒸気の侵入、PID現象などにより並列抵抗( $R_{sh}$ )が低下すると $I_{SC}$ 付近の勾配が増加する。Fig. 1はTable 1で想定した不具合により最大出力( $P_{max}$ )が10%低下した際のI-Vカーブと正常時のI-Vカーブである。ストリングはセル60枚を封入したPVモジュールを直列に10枚接続した構成となっている。Fig. 1に示した例よりも $P_{max}$ の低下が軽度となる不具合では、I-Vカーブの形状変化がより僅かとなり、人間による不具合の判断はより主観的かつ暗黙的となってしまう。よって、本手法ではNNを用いることで

Table 1 Expected Failure I-V Curve

Failure	Change of I-V Curve
decreased $I_{cell}$	stepped
increased $R_s$	decreased gradient near $V_{OC}$
decreased $R_{sh}$	increased gradient near $I_{SC}$

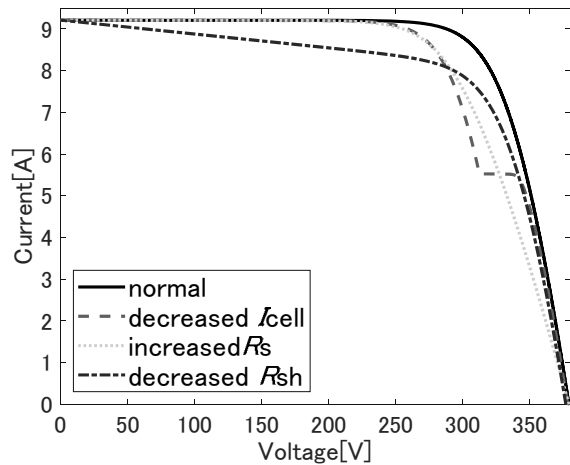


Fig. 1 Expected Failure I-V Curve

不具合を客観的かつ形式知的に自動判定する。

本手法では $R_s$ 増加および $R_{sh}$ 低下に関しては、各単独不具合により $P_{max}$ が5%以上低下するI-Vカーブを不具合として検出する。また、 $I_{cell}$ 低下は $P_{max}$ の低下率ではなく、 $I_{cell}$ の低下率が5%以上であれば不具合として検出する。これは、 $I_{cell}$ 低下率が高い場合でもストリングレベルでは $P_{max}$ 低下率が低く、PVモジュールやセルレベルにおいて深刻となる不具合が潜在化する恐れがあるためである。さらに、上記の不具合が複合した不具合に関しても検出対象とする。ただし、 $P_{max}$ が50%以上低下するような明らかな不具合に関してはあらかじめ除外する。

## 3. NNの学習

NNとは人間の神経細胞の一部を模した数理モデルであり機械学習手法の一つである。本手法ではTable 1に示した不具合を判定するのに適したNNをそれぞれ作成することで、単独不具合から複合不具合まで判定する。そこで、「正常」または「 $I_{cell}$ 低下」を判定するNN( $I_{cell}$ )、「正常」または「 $R_s$ 増加」を判定するNN( $R_s$ )、「正常」または「 $R_{sh}$ 低下」を判定するNN( $R_{sh}$ )を作成した。各NNはシミュレーションにより作成したI-Vカーブを用いて、以下の手順で学習を行った。

### 3.1 シミュレーションI-Vカーブの作成

I-Vカーブ測定時にPVアレイがさまざまな屋外条件(日射強度、モジュール温度)で動作していることを想定し、シミュレーションにより正常および不具合時のI-Vカーブを作成して、NNの学習データとして活用する。本手法では各不具合に該当するパラメータや屋外条件を変更することにより、計

225,439通りのシミュレーションI-Vカーブを作成した。

### 3.2 参照基準I-Vカーブの作成

本手法では先行研究の参照基準I-Vカーブ<sup>11)</sup>を活用することで、不具合時のI-Vカーブの特徴量を抽出する。参照基準I-Vカーブとは任意の日射強度、モジュール温度において銘板値相当の発電性能を持ったI-Vカーブであり、PVモジュールの銘板値と屋外条件情報のみで作成することが可能である。本手法では3.1節で作成したシミュレーションI-Vカーブに対して、それぞれの日射強度、モジュール温度を用いて参照基準I-Vカーブを1データずつ作成する。

### 3.3 前処理

まず、シミュレーションI-Vカーブと参照基準I-Vカーブの開放電圧( $V_{OCsim}$ ,  $V_{OCref}$ )と短絡電流( $I_{SCsim}$ ,  $I_{SCref}$ )を取得する。次に、参照基準I-Vカーブの電圧値に開放電圧比 $V_{OCsim}/V_{OCref}$ 、電流値に短絡電流比 $I_{SCsim}/I_{SCref}$ を掛け合わせることで、参照基準I-VカーブとシミュレーションI-Vカーブの短絡電流と開放電圧を完全に一致させる。最後に参照基準I-VカーブとシミュレーションI-Vカーブから、Fig. 2に示すように同電圧における差分電流( $I_d$ )を取得し $I_d$ - $V$ 特性、Fig. 3に示すように同電流における差分電圧( $V_d$ )を取得し $V_d$ - $I$ 特性を作成する。また、測定条件により異なるスケールとなるI-Vカーブにも本手法を適用するため、I-Vカーブ、 $I_d$ - $V$ 特性、 $V_d$ - $I$ 特性は電圧値を $V_{OCsim}$ 、電流値を $I_{SCsim}$ で割ることで電流、電圧を0.0~1.0の範囲に正規化する。

### 3.4 特徴量抽出

2章で述べたように不具合の種類によってI-Vカーブの形状特性は異なる。そこで、 $NN(R_s)$ 、 $NN(R_{sh})$ ではI-Vカーブの勾配変化、 $NN(I_{cell})$ ではI-Vカーブの段をそれぞれ効率的に抽出する必要があるため、異なる特徴量を抽出する。

3.4.1  $NN(R_s)$ 、 $NN(R_{sh})$ の特徴量抽出  $NN(R_s)$ 、 $NN(R_{sh})$ では以下に示す402点(201+201)の要素を持った1次元配列を特徴量として抽出する。

(1) 正規化後の $I_d$ - $V$ 特性に対し、 $V = 0.0 \sim 1.0$ まで等間隔に電流差分値 $I_d = (I_{d1}, I_{d2}, \dots, I_{d201})$ を201点抽出する。

(2) 正規化後の $V_d$ - $I$ 特性に対し、 $I = 0.0 \sim 1.0$ まで等間隔に電圧差分値 $V_d = (V_{d1}, V_{d2}, \dots, V_{d201})$ を201点抽出する。

3.4.2  $NN(I_{cell})$ の特徴量抽出  $NN(I_{cell})$ では以下に示す600点(200+200+200)の要素を持った1次元配列を特徴量として抽出する。

(1) 正規化後のI-Vカーブに対し、 $V = 0.0 \sim 1.0$ まで等間隔に電流値 $I = (I_1, I_2, \dots, I_{201})$ を201点抽出する。抽出した電流値 $I$ に対し、次式を用いて電流微分値 $I' = (I'_1, I'_2, \dots, I'_{200})$ を200点抽出する。

$$I'_n = I_n - I_{n+1} \quad (n = 1, 2 \dots 200) \quad (1)$$

(2) 参照基準との電流差分値 $I_d$ に対し、次式を用いて電流差分微分値 $I'_d = (I'_{d1}, I'_{d2}, \dots, I'_{d200})$ を200点抽出する。

$$I'_{dn} = I_{dn} - I_{dn+1} \quad (n = 1, 2 \dots 200) \quad (2)$$

(3) 参照基準との電圧差分値 $V_d$ に対し、次式を用いて電圧差分微分値 $V'_d = (V'_{d1}, V'_{d2}, \dots, V'_{d200})$ を200点抽出する。

$$V'_{dn} = V_{dn} - V_{dn+1} \quad (n = 1, 2 \dots 200) \quad (3)$$

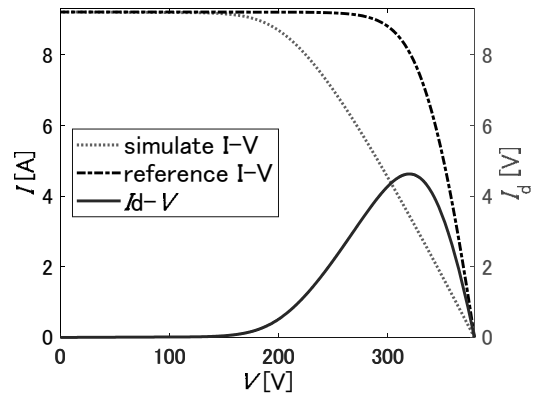


Fig. 2  $I_d$ - $V$  Characteristics

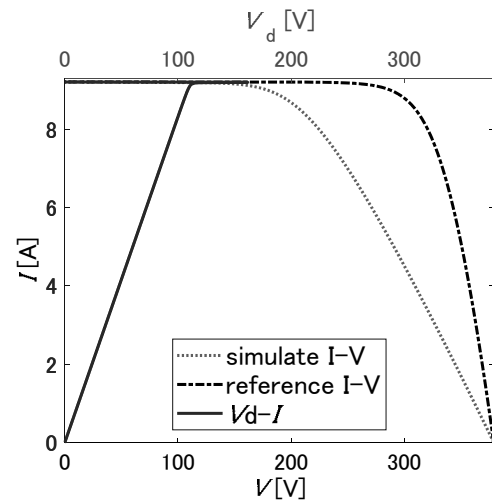


Fig. 3  $V_d$ - $I$  Characteristics

最後に全学習データから抽出した上記の各微分データ配列の最大値を用いて、抽出した各微分データ配列を正規化する。

### 3.5 NNの学習

まず、NNの構成について説明する。 $NN(I_{cell})$ 、 $NN(R_s)$ 、 $NN(R_{sh})$ はいずれも入力層から出力層までが一方向であるフィードフォワードニューラルネットワーク(FFNN)である。各層は、入力層・隠れ層・出力層まで3層で構成され、活性化関数にはシグモイド関数とソフトマックス関数、誤差関数には交差エントロピー誤差を用いた。また、隠れ層のユニット数は学習時間と学習精度を考慮し20ユニットと設定した。

次に、NNの学習方法について説明する。NNの学習はMATLABの学習関数であるスケリング共役勾配法(`trainscg`)を用いた。また、3.1節で述べたシミュレーションI-Vカーブ計225,439データの内の90%を訓練データ、10%を検証データとして使用した。最大エポック数は2000とし、30エポックの反復学習の間に検証データの誤差が連続して増加し続けた場合、訓練データに過適合していると判断して学習を停止する。

最後に $NN(R_s)$ 、 $NN(R_{sh})$ に関しては、 $I_{cell}$ 低下が生じたI-Vカーブを学習したNN、それ以外を学習したNNのそれぞれ2種類を作成する。これは、実際に不具合を判定する際に $NN(I_{cell})$ で先に $I_{cell}$ 低下を判定するためである。これにより、 $I_{cell}$ 低下の有無で使用する $NN(R_s)$ 、 $NN(R_{sh})$ を使い分けることで、不具合の判定精度が向上する。

#### 4. PV アレイの不具合診断フロー

Fig. 4 に PV アレイの不具合診断フローを示す。まず、3 章で作成した  $NN(I_{cell})$ ,  $NN(R_s)$ ,  $NN(R_{sh})$  を用いて不具合の判定を行う。次に  $NN(I_{cell})$  で  $I_{cell}$  低下と判定された場合、 $I_{cell}$  低下率の検出を行う。最後に  $NN(R_s)$  で  $R_s$  増加と判定された場合、 $R_s$  増加値の推定を行う。

##### 4.1 NN による不具合判定

3 章で作成した  $NN(I_{cell})$ ,  $NN(R_s)$ ,  $NN(R_{sh})$  により Fig. 4 に示す流れで不具合判定を行う。まず、 $NN(I_{cell})$  により「正常」、 $I_{cell}$  低下」の判定を行う。次に、 $NN(I_{cell})$  の判定結果が「正常」であれば  $I_{cell}$  低下時の I-V カーブを学習していない  $NN(R_s)$ ,  $NN(I_{cell})$  の判定結果が「 $I_{cell}$  低下」であれば  $I_{cell}$  低下時の I-V カーブを学習した  $NN(R_s)$  により、「正常」、「 $R_s$  増加」の判定を行う。同様に  $NN(R_{sh})$  についても  $NN(I_{cell})$  の判定結果を基に使用する  $NN(R_{sh})$  を使い分けて、「正常」、「 $R_{sh}$  低下」の判定を行う。最後に以上の判定結果を組み合わせることで、「正常」、「 $I_{cell}$  低下」、「 $R_s$  増加」、「 $R_{sh}$  低下」、「 $I_{cell}$  低下+ $R_s$  増加」、「 $I_{cell}$  低下+ $R_{sh}$  低下」、「 $R_s$  増加+ $R_{sh}$  低下」、「 $I_{cell}$  低下+ $R_s$  増加+ $R_{sh}$  低下」のいずれかの不具合として判定する。

##### 4.2 $I_{cell}$ 低下率の検出

$NN(I_{cell})$  で「 $I_{cell}$  低下」と判定された場合、式(3)より取得した参照基準 I-V カーブとの電圧差分微分値  $V_d'$  を横軸、対応する正規化後の電流値  $I_n$  を縦軸とした  $I_n - V_d'$  特性を利用して  $I_{cell}$  低下率の検出を行う。ここで、 $I_{cell}$  低下率とはストリング I-V カーブ全体の  $I_{SC}$  に対する、ストリング内において最も発電電流が低下したセルの  $I_{SC}$  の低下割合とする。よって、 $I_{cell}$  低下が発生した I-V カーブ上において、最も電流値が低下した段の位置を検出することで、 $I_{cell}$  低下率の検出が行える。

Fig. 5 に  $I_{cell}$  低下時の正規化後の I-V カーブと参照基準 I-V カーブ、 $I_n - V_d'$  特性をそれぞれ示す。Fig. 5 より  $I_n - V_d'$  特性において、 $V_d'$  の極大値となる点が I-V カーブの段の位置である。したがって、 $V_d'$  が極大値となる際の電流値  $I_{peak}$  を取得するこ

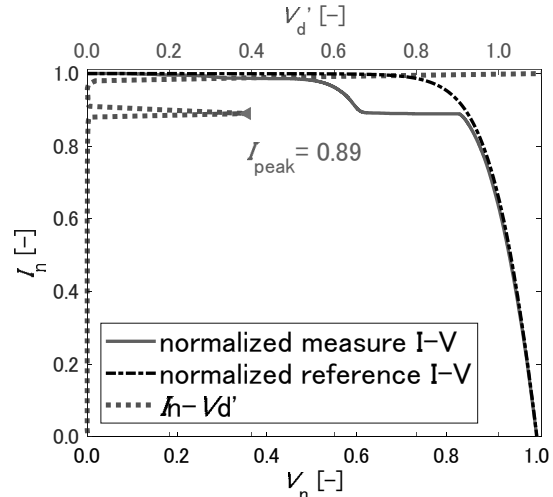


Fig. 5 Detect  $I_{cell}$  decrease rate

とで、次式により  $I_{cell}$  低下率を検出する。

$$I_{cell} \text{ decrease rate} = (1 - I_{peak}) \times 100 \quad [\%] \quad (4)$$

ここで、 $V_d'$  の極大値は連続する  $V_d'$  データ配列において、着目した  $V_d'$  の要素が隣接する要素よりも大きい場合に極大値とする。なお、ノイズ等の影響を考慮して閾値 0.02 を超えたデータのみを極大値とする。以上の手法を用いることで、Fig. 5 の例で  $I_{cell}$  低下率は、 $(1 - 0.89) \times 100 = 11 \%$  と検出される。

##### 4.3 $R_s$ 増加値の推定

$NN(R_s)$  で「 $R_s$  増加」と判定された場合、正常時である参照基準 I-V カーブの直列抵抗値 ( $R_{sref}$ ) に対する実測 I-V カーブの  $R_s$  増加値を推定する。これにより対象ストリングの  $R_s$  増加不具合を定量的に評価することが可能となる。

2 章で述べたように  $R_s$  が増加すると  $V_{OC}$  付近の勾配が低下する。本手法では 3.2 節で作成した参照基準 I-V カーブを実測 I-V カーブに対して  $V_{OC}$  付近でフィッティングさせ、フィッティング後の参照基準 I-V カーブの  $R_s$  を実測 I-V カーブの  $R_s$  として推定する。Fig. 6 に  $R_s$  増加値の推定フローを示す。

まず、参照基準 I-V カーブを実測 I-V カーブにフィッティングするために両者の電圧差分  $V_d$  を利用する。また、 $V_{OC}$  付近でのフィッティングを目的とするため、 $V_d$  の取得範囲を最初に決定する。 $V_d$  の取得範囲は、4.2 節で検出した  $I_{cell}$  低下率により決定する。 $V_d$  に対応する電流値を  $I$  として  $V_d$  の取得範囲は、 $I_{cell}$  低下率が 20%未満の場合、

$$0 < I < 0.8 \times I_{SCref} \quad (5)$$

$I_{cell}$  低下率が 20%以上の場合、

$$0 < I < I_{peak} \times I_{SCref} \quad (6)$$

とする。これは、 $I_{cell}$  低下により発生した I-V カーブ上の段部分の  $V_d$  を取得してしまうとフィッティングが収束しないため、段よりも  $V_{OC}$  側の  $V_d$  を用いてフィッティングを行うためである。

次に、 $R_{sref}$  から  $R_s$  を微増させることで参照基準 I-V カーブを再作成する。ここで、本手法では  $R_s$  の増加値は  $R_{sref}$  の 1% と設定した。そして、再算出した参照基準 I-V カーブと実測 I-V カーブとの  $V_d$  を式(5)または式(6)の範囲で取得する。参照基準 I-V カーブが実測 I-V カーブにフィッティングすると取得した

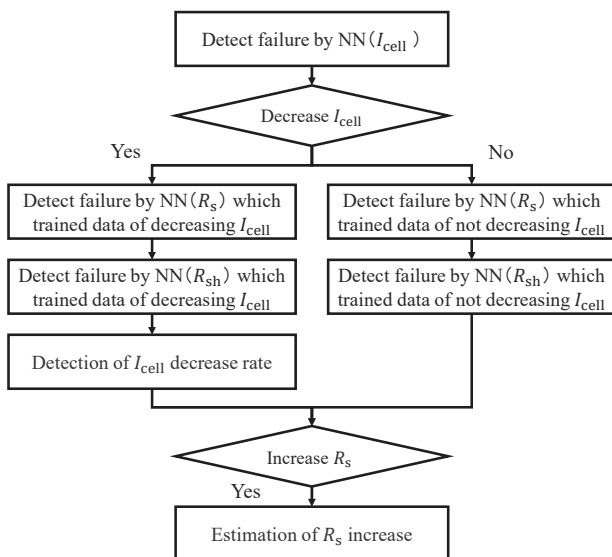


Fig. 4 Failure Diagnosis Flow



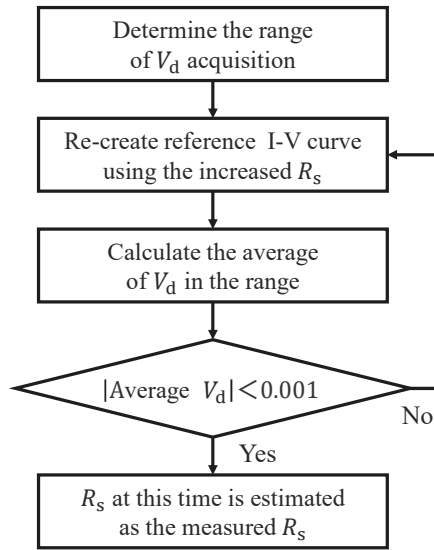


Fig. 6 Estimation flow of  $R_s$

$V_d$  の平均値が 0 に近づくため、 $V_d$  の平均値が 0.001 未満となるまで上記の手順を繰り返す。

以上より、十分にフィッティングが完了した際の $R_s$ を実測 I-V カーブの直列抵抗値 ( $R_{s_{est}}$ ) として推定する。よって、 $R_{s_{est}}$  と  $R_{s_{ref}}$  の差を取ることで $R_s$ 増加値の推定が完了する。

これまでにも、太陽電池等価回路式を用いた手法など実測 I-V カーブから $R_s$ を推定する手法が提案されている<sup>12-13)</sup>。その中でも本手法は $I_{cell}$ 低下率を検出することで、 $R_s$ 増加によって変化する $V_{oc}$ 側の I-V カーブを最大限活用して $R_s$ を推定することが可能である。そのため、本手法は $I_{cell}$ 低下と $R_s$ 増加が併発した場合や $V_{oc}$ 付近にノイズや欠測値が発生した場合においても $R_s$ を推定できるという利点を持っている。

## 5. 実測データを用いた検証

### 5.1 使用データ

本手法の検証のため、東京理科大学葛飾キャンパス屋上にて I-V カーブの測定を行った。Fig. 7 のように三菱電機製の単結晶シリコン PV モジュール (PV-MA1100KH) を 2~5 枚直列に接続したストリングを構成し、日射強度は日射計、モジュール温度は中央の PV モジュール背面に取り付けた熱電対、I-V カーブは I-V カーブトレーサを PV モジュール端子に接続しそれぞれ測定した。




Fig. 7 Measurement Environment

Failure Class	Number of Data
normal	126
decreased $I_{cell}$	258
increased $R_s$	59
decreased $R_{sh}$	230
decreased $I_{cell}$ & increased $R_s$	68
decreased $I_{cell}$ & decreased $R_{sh}$	60

本検証では Fig. 7 のストリングを用いて、「正常」, 「 $I_{cell}$ 低下」, 「 $R_s$ 増加」, 「 $R_{sh}$ 低下」, 「 $I_{cell}$ 低下+ $R_s$ 増加」, 「 $I_{cell}$ 低下+ $R_{sh}$ 低下」の 6 種類の実測データを取得した。 $I_{cell}$ 低下は PV モジュール内のセルを遮光し、遮光する割合やセル数、セルの位置を変化させて測定した。 $R_s$ 増加はセメント抵抗回路 (抵抗値:0.04, 0.06, 0.09, 0.15, 0.27, 0.40, 0.50, 0.63, 0.90, 1.00, 1.10, 1.40, 1.51, 1.60, 1.91, 1.99, 2.10Ω) を直列に接続することで測定した。 $R_{sh}$ 低下は可変抵抗器をストリングに並列接続することによって、10Ω~100Ωまで 5Ω刻みで測定した。Table 2 は測定データを 2 章で述べた不具合の閾値である $I_{cell}$ 低下率と $P_{max}$ 低下率によりラベル付けを行ったものである。Table 2 に示す使用データを用いて本手法の検証を行った。

### 5.2 NN による不具合判定結果

3 章で述べた手法と同様に実測データに対して、参照基準 I-V カーブの作成、前処理、特徴量抽出を行った後、3 章で作成した学習済みの NN によって不具合判定を行った。Fig. 8 に  $NN(I_{cell})$ ,  $NN(R_s)$ ,  $NN(R_{sh})$  による不具合判定結果および各 NN

Classification Result	Actual Class					
	normal	$I_{cell}$	$R_s$	$R_{sh}$	$I_{cell}R_s$	$I_{cell}R_{sh}$
normal	123	0	0	0	0	0
$I_{cell}$	0	256	0	2	0	10
$R_s$	3	0	59	0	1	0
$R_{sh}$	0	0	0	228	0	0
$I_{cell}R_s$	0	0	0	0	67	0
$I_{cell}R_{sh}$	0	2	0	0	0	50

All Classification Results by NN

normal $I_{cell}$		normal $R_s$		normal $R_{sh}$	
normal	413	1	normal	671	0
$I_{cell}$	2	385	$R_s$	3	127
			$R_{sh}$	2	278

Fig. 8 Confusion Matrix

から導き出した最終的な不具合判定結果を混同行列として示す。なお、混同行列の行が各 NN の判定結果を、列が実際の不具合を表している。また、「 $R_s$ 増加+ $R_{sh}$ 低下」、「 $I_{cell}$ 低下+ $R_s$ 増加+ $R_{sh}$ 低下」不具合に関しては実験データを取得しておらず、NN の判定結果にも含まれていないことから Fig. 8 の混同行列では省いている。Fig. 8 の最終的な不具合判定結果より、NN によって「正常」126 データ中、123 データが「正常」に正しく判定され、3 データが「 $R_s$ 増加」に誤判定された。

「 $I_{cell}$ 低下」は 258 データ中、256 データが「 $I_{cell}$ 低下」に正しく判定され、2 データが「 $I_{cell}$ 低下+ $R_{sh}$ 低下」に誤判定された。「 $R_s$ 増加」は 59 データ全てが「 $R_s$ 増加」に正しく判定された。「 $R_{sh}$ 低下」は 230 データ中、228 データが「 $R_{sh}$ 低下」に正しく判定され、2 データが「 $I_{cell}$ 低下」に誤判定された。

「 $I_{cell}$ 低下+ $R_s$ 増加」は 68 データ中、67 データが「 $I_{cell}$ 低下+ $R_s$ 増加」に正しく判定され、1 データが「 $R_s$ 増加」に誤判定された。「 $I_{cell}$ 低下+ $R_{sh}$ 低下」は 60 データ中、50 データが「 $I_{cell}$ 低下+ $R_{sh}$ 低下」に正しく判定され、10 データが「 $I_{cell}$ 低下」に誤判定された。また、Table 3 に各 NN の正解率（正解データ数/全データ数）および最終的な不具合判定結果の正解率を示す。Table 3 より各 NN の正解率は 98.3%以上となっており、全体の正解率としても 97.8%と高精度に不具合の判定に成功していることが確認できる。

Fig. 9(a)~(f)に実際に NN によって不具合の判定に成功した実測 I-V カーブデータ A~F を示す。Fig. 9(a)の実測データ A はストリング内のセル 1 枚の発電電流が低下した $I_{cell}$ 低下 ( $P_{max}$ 低下率：1.7%)、(b)の実測データ B はストリング内のセル複数枚の発電電流が低下した $I_{cell}$ 低下 ( $P_{max}$ 低下率：1.3%)、(c)の実測データ C は $R_s$ 増加 ( $P_{max}$ 低下率：5.8%,  $R_s = 0.40 \Omega$ )、(d)の実測データ D は $R_{sh}$ 低下 ( $P_{max}$ 低下率：6.9%,  $R_{sh} =$

NN	Accuracy [%]
NN( $I_{cell}$ )	99.6
NN( $R_s$ )	99.6
NN( $R_{sh}$ )	98.3
ALL Classification Result	97.8

100  $\Omega$ )、(e)の実測データ E は  $I_{cell}$ 低下と $R_s$ 増加の複合不具合 ( $P_{max}$ 低下率：9.4%,  $R_s = 0.40 \Omega$ )、(f)の実測データ F は $I_{cell}$ 低下と $R_{sh}$ 低下の複合不具合 ( $P_{max}$ 低下率：22.3%,  $R_{sh} = 100 \Omega$ )である。Fig. 9(b)の実測データ B と Fig. 9(d)の実測データ D に関しては形状が似ている I-V カーブであり、I-V カーブの特性値のみを用いた不具合の判定手法では判定が困難と想定される。しかし、本手法では特性値のみでなく I-V カーブ全体のデータを活用し、参照基準 I-V カーブにより抽出した特徴量を用いて I-V カーブ上の緩やかな段部分の形状変化を顕在化させたことで、不具合の判定に成功している。一方で誤判定したデータは、主に正常と不具合を分ける閾値付近のデータとなっており、閾値の設定方法や特徴量の抽出方法を改善することで、不具合の判定精度は向上すると考えられる。

### 5.3 $I_{cell}$ 低下率の検出結果

5.2 節で「 $I_{cell}$ 低下」または「 $I_{cell}$ 低下+ $R_s$ 増加」、「 $I_{cell}$ 低下+ $R_{sh}$ 低下」と正しく判定された 385 データに対して、4.2 節の手法を用いて $I_{cell}$ 低下率の検出を行った。Fig. 9 の実測データの内、 $I_{cell}$ 低下が発生している実測データ A, B, E, F における $I_{cell}$ 低下率の検出結果を Fig. 10(a)~(d)に示す。Fig. 10 より、実測データ A, B, E, F の $I_{cell}$ 低下率は、それぞれ 7%、10%、7%、32%と検出された。いずれの実測データも I-V カーブ上

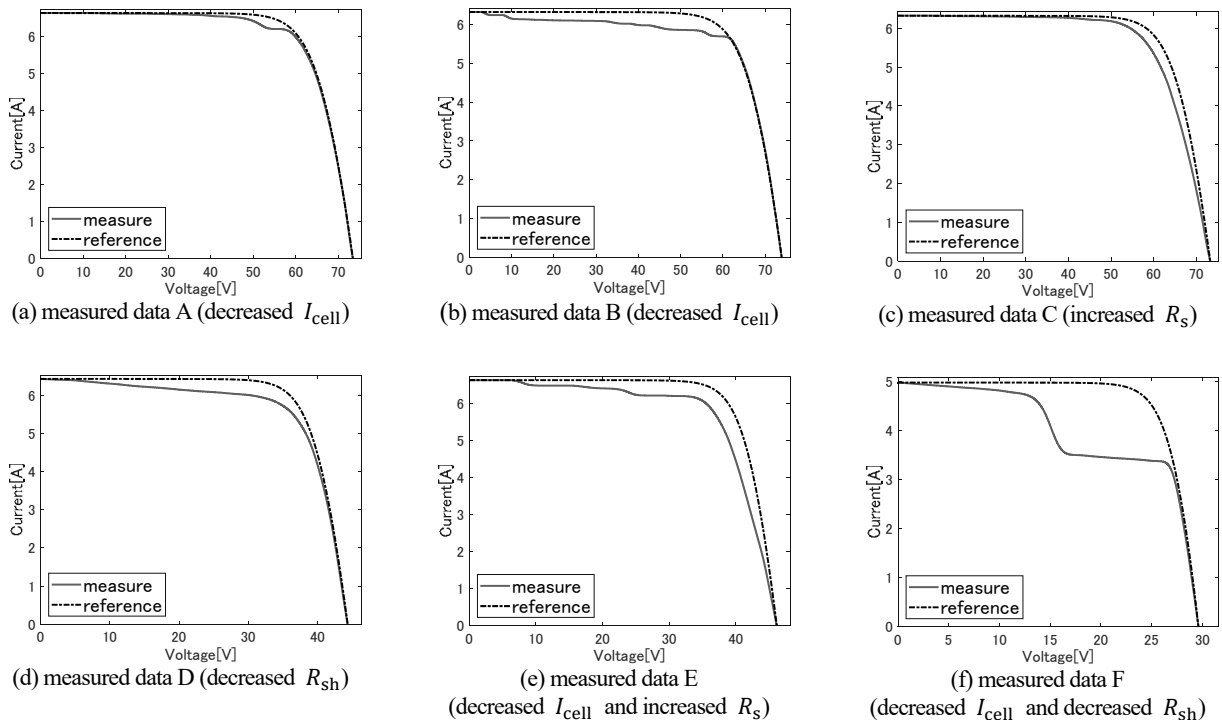


Fig. 9 Classification Success Data

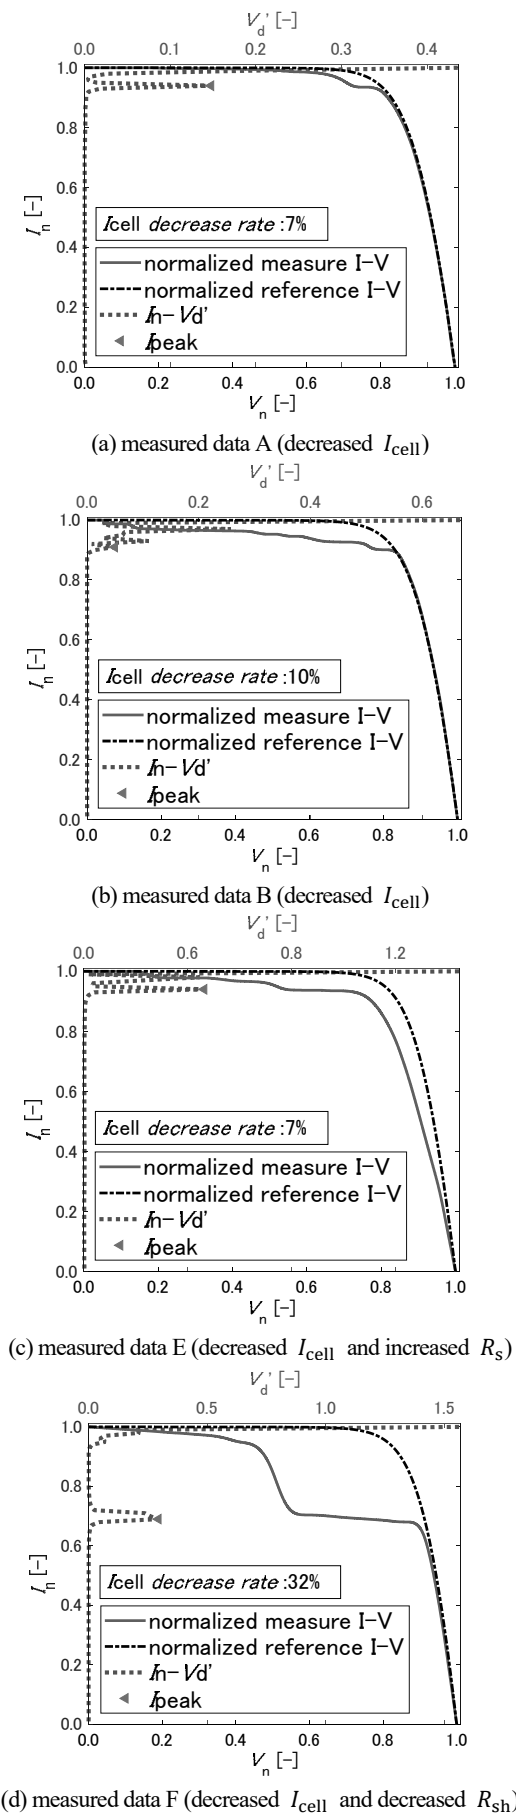


Fig. 10 Detection Results of  $I_{cell}$  decrease rate

の段部分と $I_{peak}$ の位置が一致していることから、 $I_{cell}$ 低下率の検出に成功していることが確認できる。したがって、本手法により不具合セルの発電電流を定量的に診断することが可能となる。そのため、実際の現場ではPVアレイ内のPVモジュール交換の判断材料として活用できることが想定される。

#### 5.4 $R_s$ 増加値の推定結果

5.2節で「 $R_s$ 増加」または「 $I_{cell}$ 低下+ $R_s$ 増加」と正しく判定された127データに対して、4.3節で述べた手法を用いることで、 $R_s$ 増加値の推定を行った。Table 4に実際にストリングに直列接続した抵抗値( $\Delta R_{sact}$ )、データ数、各抵抗値における $\Delta R_{sact}$ と $\Delta R_{s_{est}}$ の平均絶対誤差(MAE)を示す。Table 4より「 $R_s$ 増加」または「 $I_{cell}$ 低下+ $R_s$ 増加」に正しく判定された127データのMAEは、 $0.07\Omega$ と高精度に推定することに成功した。

$\Delta R_{sact}$ [ $\Omega$ ]	Number of Data	MAE [ $\Omega$ ]
0.27	4	0.01
0.40	10	0.06
0.50	16	0.05
0.63	2	0.09
0.90	5	0.06
1.00	22	0.05
1.10	1	0.05
1.40	5	0.15
1.51	18	0.09
1.60	1	0.03
1.91	27	0.06
1.99	15	0.14
2.10	1	0.04
All	127	0.07

一方で、配線の内部抵抗値や劣化などを考慮すると、実際に接続した抵抗値には多少の誤差が考えられる。そのため、 $R_s$ 増加値の推定精度に関しても多少の誤差はあるものと考えられる。

Fig. 11に実際に参照基準I-Vカーブを実測I-Vカーブにフィッティングさせ、 $R_s$ 増加値を推定した例を示す。Fig. 11(a), (b)はそれぞれFig. 9の実測データC, 実測データEである。Fig. 11(a),(b)より単独不具合、複合不具合ともに $V_{oc}$ 付近でのフィッティングに成功しており、 $R_s$ 増加値の推定結果 $\Delta R_{s_{est}}$ と実際に接続した抵抗値 $\Delta R_{sact}$ との絶対誤差は両者ともに $0.06\Omega$ と高精度に推定できている。また、Fig. 11(c)の実測データGは、 $I_{cell}$ 低下と $R_s$ 増加の複合不具合の中でも、 $I_{cell}$ 低下率が高く、I-Vカーブ上の段部分の影響が顕著に現れた例となっている。本データに関しても、絶対誤差は $0.05\Omega$ と高精度に推定できている。このように、本手法では $I_{cell}$ 低下率を検出した上

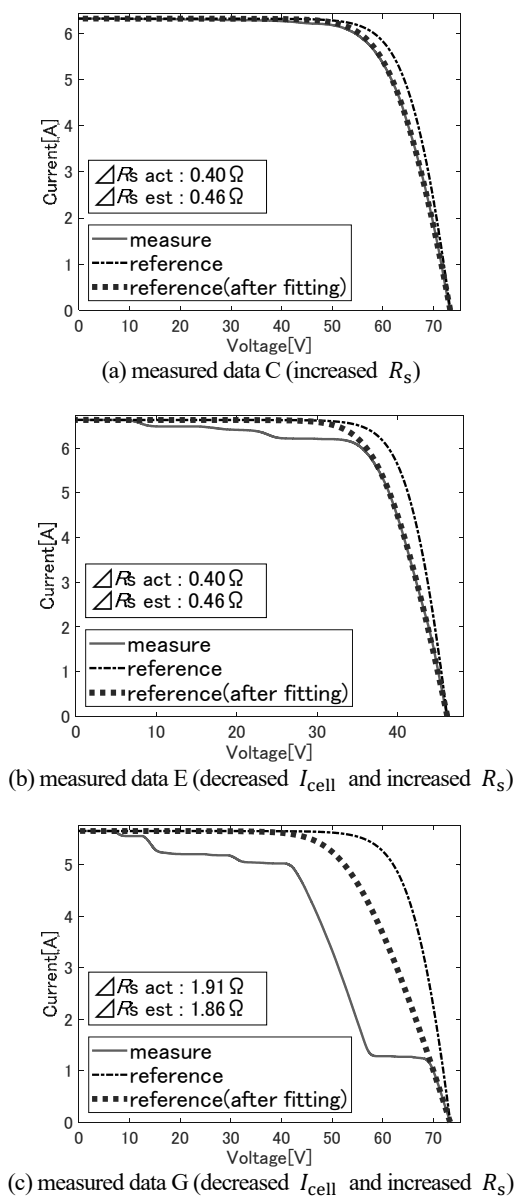


Fig. 11 Result of Estimated Increased  $R_s$

で I-V カーブ上の段よりも  $V_{OC}$  側の  $V_d$  を用いてフィッティングを行ったことで、 $I_{cell}$  低下と  $R_s$  増加の複合不具合に関しても  $R_s$  増加値の推定を可能とした。

## 6. まとめと今後の課題

本研究では、ストリング I-V カーブと参照基準 I-V カーブとの差分データを活用し、NN を用いた不具合の判定および  $V_{cell}$  低下率の検出、 $R_s$  増加値の推定手法を提案した。実測データによる本手法の検証結果から、各単独不具合および複合不具合に関して高精度に判定できることが確認できた。また参照基準 I-V カーブを活用することで、 $I_{cell}$  低下率の検出および  $R_s$  増加値の推定にも成功した。今後、実際の PV システムにおいて本手法を実用化するための課題としては、NN の学習データを現地の PV アレイ構成や PV モジュール銘板値から自動生成

することが挙げられる。また、 $I_{cell}$  低下の判定に関して、現状は I-V カーブ上の段の有無のみで判定を行っているが、今後は段部分の勾配変化を NN に学習させることで、部分影とホットスポットの判定までを行うことが課題である。 $R_s$  増加値の推定手法に関しては  $R_{sh}$  低下が併発した場合を想定する必要があると考えられる。

## 参考文献

- 1) 経済産業省, 電気保安分野におけるアクションプランの概要 (案) (accessed Jan. 24 2023), [https://www.meti.go.jp/shingikai/safety\\_security/smart\\_hoan/denryoku\\_anzen/pdf/003\\_01\\_01.pdf](https://www.meti.go.jp/shingikai/safety_security/smart_hoan/denryoku_anzen/pdf/003_01_01.pdf)
- 2) Y. Ishitoya, S. Yamanaka, Y. Aoyama, Y. Nishido, H. Kobayashi, Failure Evaluation Method of PV Array using I-V Characteristics - Evaluation Method using FF -, Journal of Japan Solar Energy Society, **44**(1), 71-77(2018)
- 3) A. Eskandari, J. Milimonfared, M. Aghaei, A. K. Vidal de Oliveira and R. R  ther, Line-to-Line Faults Detection for Photovoltaic Arrays Based on I-V Curve Using Pattern Recognition, Proceedings of PVS C (June. 2019), 503-507, Chicago, IL, USA
- 4) J. M. Huang, R. J. Wai and W. Gao, Newly-Designed Fault Diagnostic Method for Solar Photovoltaic Generation System Based on IV-curve Measurement, IEEE Access, **7**, 70919-70932(2019)
- 5) T. Yamada, S. Yamanaka, Y. Aoyama, Y. Nishido, H. Kobayashi, Study on Shape Change Detection Method of PV String I-V Characteristics, Journal of Japan Solar Energy Society, **46**(4), 64-70(2020)
- 6) M. H. Ali, A. Rabhi, A. E. Hajjaji and G. M. Tina, Real time fault detection in photovoltaic systems, Energy Procedia, **111**, 914-923(2017)
- 7) B. Zbib and H. Al Sheikh, Fault Detection and Diagnosis of Photovoltaic Systems through I-V Curve Analysis, Proceedings of ICECE (June. 2020), 1-6, Istanbul, Turkey
- 8) S. Fadhel, C. Delpha, D. Diallo, I. Bahri, A. Migan, M. Trabelsi, et al., PV shading fault detection and classification based on I-V curve using principal component analysis: Application to isolated PV system, Sol. Energy, **179**, 1-10,(2019)
- 9) Z. Chen, L. Wu, S. Cheng, P. Lin, Y. Wu and W. Lin, Intelligent fault diagnosis of photovoltaic arrays based on optimized kernel extreme learning machine and I-V characteristics, Appl. Energy, **204**, 912-931(2017)
- 10) M. W. Hopwood, T. Gunda, H. Seigneur and J. Walters, Neural Network-Based Classification of String-Level I-V Curves From Physically-Induced Failures of Photovoltaic Modules, IEEE Access, **8**, 161480-161487(2020)
- 11) H. Koshirae, K. Kawasaki, Y. Ueda, Y. Hishikawa, Modeling of Cell Performance Variation in One Diode Model for Reference I-V Curve Calculation, Proceedings of PVSEC (Nov.2019), 2344-2347, Xi'an, China
- 12) D. Pyscha, A. Mettea, S.W. Glunza, A review and comparison of different methods to determine the series resistance of solar cells, Solar Energy Materials & Solar Cells, **91**(18), 1698-1706(2007)
- 13) D. Tashima, K. Sakai, M. Otsubo, C. Honda, K. Ohtsuka, Estimation method of parameter in equivalent circuit of solar cell, Journal of Japan Solar Energy Society, **33**(1), 45-50(2007)