

ロジスティック回帰を用いた PVS の故障検出

Detection Method of String Failures Including Shorted or Opened Cluster Using Logistic Regression

石倉規雄 *

1. 太陽光発電の位置づけと長期運用への課題

エネルギー問題を解決する手段として、再生可能エネルギーが注目されている。PVS の利点は、再生可能エネルギーである太陽光をエネルギー源とすることのみならず、他の発電方法で多く用いられる回転機などの機械的な消耗を伴わず、摩耗部品の交換が不要である点である。日本においては政府の事業「2050 年カーボンニュートラルを目指す日本の新たな「エネルギー基本計画」」により、2030 年までに全発電電力のうち 14～16% を太陽光発電に

よって賄うことを計画しており、さらなる普及が望まれている¹⁾。図 1 に、国内における住宅用（10kW 未満）の PVS 設置数の年次変化を示す²⁾。図 1 に示す通り、累積設置数が増加し、2010 年から 2019 年までの 10 年間に約 3.6 倍に増加していることがわかる。

PVS が急速に普及する一方、事故や火災に繋がる故障が増加し、事故要因の解明が進められている。図 2 に、2020 年度から 2022 年度に、製品評価技術基盤機構へ報告された PVS の不具合件数を示す³⁾。年間約 180 件の不具合が報告されており、今後の世界的な PVS の増加と共に、不具合の件数も増加することが懸念される。国内における具体例として、2017 年に消費者庁より発表された「住宅用太陽光発電システムから発生した火災事故等⁴⁾」がある。このような背景を受け、事故を未然に防ぐことを目的に、新 FIT では 50kW 以下の発電もメンテナンスが義務化された。また、近年の研究によって実際は定期的な PVS の保守・メンテナンスが必要であることが明らかになってきた。しかしながら、一般的な PVS のメンテナンスは手作業で行うことが多く、時間と労力を要する。また、発電者側が発電所の電力モニターや致命的な故障を通知できるアプリは多く利用されているが、リアルタイムに電気的で総合的な異常を知ることが難しい。これらの課題を解決するため、近年の機械学習の発展に伴い PVS の故障診断へ機械学習を用いた方法が提案され、その有効性が示されている⁵⁾。一方、精度よく異常検出するためには、追加のセンサや高性能なマイコン等のデバイスが必要であるため、既設の大型 PVS への導入にはハードルがある。

そこで著者らは、精度は劣るが追加のセンサや高




図 1 住宅用（10kW 未満）太陽光発電導入累積件数の年次変化²⁾




図 2 PVS 不具合の報告数³⁾

* 米子工業高等専門学校 准教授

性能なマイコン等を必要としない，ロジスティック回帰分析による異常検出方法を提案している⁶⁾．

本稿では，大島商船高専における実測データを基にデータ数を増やし，故障の有無と環境条件を変化させた学習データを生成した．データを増やす際は簡易な太陽光発電システムのモデルを計算機シミュレーションにより作成した．実際に発生していたクラスタ故障を76.4%で推定でき，その有用性を示すとともに，今後の展望について述べる．

2. 保守・メンテナンスを補助する手法の研究

これまでに，PVSの保守・メンテナンスに関する研究が多く報告されてきた．保守・メンテナンスにおいて最も一般的なものは，目視あるいはカメラによる外観検査である．さらに，架台の様子，ボルト類の増し締め，除草等がある．熱的な観点からは，赤外線カメラ画像を用いて，ホットスポット等を検出する場合もある．定点カメラを用いて一定時間毎に検出する方法や，定期メンテナンスにより人が立ち入って検査を実施する方法，ドローンを用いる方

法等，PVSが設置されている状況に応じて保守・メンテナンスの方法が異なる．専門的な作業を伴うものとして，測定器類を用いた検査があり，発電特性の測定（IVカーブ測定），絶縁抵抗測定，接地抵抗測定等がある．

常時監視できる簡易的な手法として実装されている一般的な故障診断システムの概要を図3に示す．太陽電池モジュールで発電された電力は，パワーコンディショナに含まれるインバータを用いて，直流から交流へ電力変換される．このとき，一般的なパワーコンディショナは，電力変換を自動制御するために直流側の電圧および電流を検出する．多くの場合は，パワーコンディショナにて得られたこれらのデータを用いて異常を監視していると考えられる．経済的な観点から，発電事業者はPVS全体における売電された電力量（金額）をアプリの通知やメールにより確認できる仕組みが普及している．場合によっては，パワーコンディショナ単位やストリング単位の電圧値，電流値，電力量，日射量，温度等の通知も想定される．これらの情報を活用することで故障を診断できるが，明らかに正常値を逸脱した場合のみ通知されるため，総合的な劣化等の不具合を判定するためには，太陽光発電に関する専門的な知見が必要になる．

これらを踏まえて，近年は機械学習を用いた故障診断に関する研究が報告されている．図4に，機械学習を用いたPVS故障診断の研究動向を示す．年間日照時間が1,900時間以上，あるいは年間降水量が1,500mm未満の比較的日照条件がよい中東，アジア，オセアニア，アメリカの各地で研究が進めら




図3 一般的な故障診断システムの概要




図4 機械学習を用いたPVS故障診断の研究の動向

れており、2015 年頃から論文数が増加している⁷⁻¹⁴⁾。これらの論文を調査したところ、アルゴリズムは SVM(Support Vector Machine)と CNN(Convolutional Neural Network) がそれぞれ 4 件ずつで最多であった。

3. ロジスティック回帰を用いた PVS の故障検出

2 章に示した通り、多様な機械学習のアルゴリズムが存在する。代表的なアルゴリズムに、線形回帰、決定木、ランダムフォレスト、SVM、CNN、RNN (Recurrent Neural Network) 等がある。機械学習を故障検出へ適用する際に、多くの場合は SVM が用いられる。SVM は、少ない教師データを用いて故障の種類をある程度推定できることが特長である。これは、限られた実測データを教師データとして用いること、故障の種類が多岐にわたること等の PVS の故障検出には相性が良いと考えられる。一方で、学習および故障診断を演算するために大きな計算機負荷がかかるため、別途データセンター等のビッグデータを処理する設備が必要となる。

そこで著者らは、簡易的に故障の疑いの有無のみの判定になるが、計算機負荷を軽減できるアルゴリズムとして、ロジスティック回帰を用いている。ロジスティック回帰は、教師あり学習の 2 クラス分類を解くアルゴリズムである。複数の定量的な環境条件を用いて、事象が発生する確率を算出可能である。(1) 式に、ロジスティクス回帰により、ある事象が発生する確率 p を算出する一般式を示す。

$$p = \frac{1}{1 + \exp(-w_0 - \sum_{i=1}^n w_i x_i)} \quad (1)$$

ここで、 x_i は 2 値データの目的変数 ($y = 0, 1$) に対する説明変数、 w_0 は定数項、 w_i は回帰係数である。ロジスティック回帰では、これらの定数項 w_0 と回帰係数 w_i の最適値を勾配法によって算出する。

図 5 に、本研究で用いたロジスティクス回帰を用いた PVS の故障診断を示す。まず教師データとして、太陽光発電のパラメータである発電電圧、電流、電力、日射量、故障の有無のデータセットを用意する。これらの教師データから、定数項と回帰係数を算出し、故障が発生する確率を求めるための定数項 w_0 と w_i を繰り返し学習により推定する。学習がある程度完了した後に、教師データと同じ要素の種類を有するテストデータを用いて、故障の正答率を確認できる。計算機シミュレーション太陽光による確率の算出式を (2) 式に示す。

$$p = \frac{1}{1 + \exp(-w_0 - w_J x_1 - w_P x_2 - w_V x_3 - w_I x_4 - w_T x_5)} \quad (2)$$

ここで、 p は故障が存在する確率、 x_1 は日射 J [W/m^2]、 x_2 はシステム全体の出力電力 P [W]、 x_3 は出力電圧 V [V]、 x_4 は出力電流 I [A]、 x_5 はパネル温度 T [$^{\circ}\text{C}$]、である。 w_0 は回帰式における切片、 $w_J \sim w_T$ はそれぞれの変数に係る重みに相当する。

4. 計算機シミュレーション

4.1 全ての教師データとテストデータが計算機シミュレーションにより生成される場合

図 6 に、計算機シミュレーションで対象とした PVS の構成を示す。図中の太陽電池モジュールの記号はクラスタを示しており、1 モジュール 2 クラスタである。モジュールは 1 枚当たり 100W、




図 5 ロジスティック回帰を用いた PVS の故障診断

17.7V, 5.7A を想定し、モジュールは1ストリングに4枚, 5ストリングのシステムを想定した。セルの直列抵抗は $50\ \mu\Omega$, 並列抵抗は $500\ \Omega$ とした。故障はクラスタ脱落とした。ここで, 図6に示すとおり, 故障が発生しうるクラスタを3つ設定した。このとき教師データは, 故障が存在しない場合, 故障が1か所のみ存在する場合, 故障が2か所同時に存在する場合, 故障が3か所同時に存在する場合の4パターン用意し, 各々同数のデータ数を用意した。シミュレーションを用いて加えたデータセットは, パワーエレクトロニクス用シミュレータ PSIM (Altair 社製) を用いて, 日射量 $0 \sim 1,000\ \text{W/m}^2$ となるように一様乱数で与えた。表1に, シミュレーションに用いたパラメータを示す。本研究の機械学習では python に含まれる Scikit-learn のライブラリより, sklearn.linear model の Logistic Regression を用いた。機械学習を実装できる開発環境は多く存在するが, 本研究では Google Colaboratory (Colab)




図6 計算機シミュレーション上で想定する PVS の構成

表1 シミュレーション条件

item		value
standard light intensity	S_0	$1000\ \text{W/m}^2$
temperature of the ambient	T	$25\ ^\circ\text{C}$
short circuit current of each solar cell at 25°C	I_{SC0}	$8.45\ \text{A}$
band energy of each solar cell	E_g	$1.12\ \text{eV}$
ideality factor of each solar cell (emission coefficient)	A	2
temperature coefficient	C_t	$0.0024\ \text{A}/^\circ\text{C}$
coefficient	K_s	0

を用いた。図7に, 実装時の画面を示す。ある程度簡素な機械学習であれば, ブラウザ上のコンソール画面から開発でき, 近年は環境が揃えやすくなっている。

図8に, 学習回数を変化させた場合の診断結果を示す。横軸は学習回数, 縦軸は診断精度であり, 学習回数を10回から1,000,000回へ変化させた場合の診断精度の変化を示している。図8より, 概ね100回の学習で診断精度が81.2%で飽和したことがわかる。ただし, 内部パラメータである回帰係数 $w_j \sim w_T$ は10,000回程程度の学習で収束していることを確認している。

4.2 一部の教師データとテストデータが実測により生成される場合

実測結果を用いた故障診断も実施している。本稿では, 大島商船高専にて実測されたデータを活用した。図9にPVSの概観を, 図10にPVSで取得したデータの一部を, それぞれ示す。実験に用いたモジュールは1枚当たり145W, 19.9V, 7.29A, 1ストリングに15枚, 20ストリング, 28kWのパワーコンディショナがつながるシステムである。セルの直列抵抗は $8\text{m}\Omega$, 並列抵抗は $1\text{k}\Omega$ とした。故障診断を実施するために, 20ストリング中の2ストリングを取り上げて評価した。故障は1か所のみセルストリングが断線し, 1クラスタ分の発電電力が低



図7 アルゴリズムの実装




図8 計算機シミュレーション結果

下した場合を想定した。ここで、故障が発生しうるモジュールを4つ設定した。実測は2022年11月3日の測定結果を用いた。図10に示す通り、2つのストリングのうち一方は正常に動作しており、その発電量は P_1 である。他方のストリングは1クラスタ分の発電電力が低下しており、その発電電力は P_2 である。実測値を用いた機械学習では、多くの場合に学習データが不足するため、データ拡張（水増し）をする。本研究では、前節の計算機シミュレーションを応用して学習データを拡張した。図11に、データ拡張に用いた計算機シミュレーションの回路図を示す。実機の条件を考慮し、正常なストリングと、セルストリング断線が発生するストリングを設定し、日射量が $0 \sim 1,000 \text{ W/m}^2$ となるように一様乱数で発電の条件を与え、日射量と発電量のデータセットを拡張した。教師データのうち、故障が存在するデータと故障が存在しないデータセット数は、それぞれ実測値4,770セット、シミュレーション値4,896セットを用意した。テストデータは4,834セット、正常・異常のデータ数の比は1:1とした。前節と同様に、pythonに含まれるScikit-learnのライブラリより、sklearn.linear modelのLogistic



図9 実機を用いた学習データの測定




図10 実機を用いた学習データの一例

Regression を用いて故障検出の精度を検証した。

図12に、学習回数を変化させた場合の診断結果を示す。横軸は学習回数、縦軸は診断精度であり、学習回数を10回から10,000回へ変化させた場合の診断精度の変化を示している。図12より、概ね100回の学習で診断精度が76.4%で飽和したことがわかる。

前節で示した通り、データセットを全て計算機シミュレーションにより生成し、本研究と同様に学習回数100回程度で診断精度が81.2%で飽和した。実測値を含んだ本研究においても、診断精度は4.8%低下するが、同様の学習の傾向があり、故障を検出可能である。

5. まとめ

本稿では、近年のPVSの普及に対する保守・メンテナンスの需要が高まっていること、さらに世界各地でPVSの故障検出を自動化するための研究が実施されており、注目されていることを紹介した。

さらに、著者らが進めているロジスティック回帰を




図11 想定するPVSの構成




図12 実機データを用いた故障診断

用いた PVS の故障検出について、その大まかな特徴と具体的な適用例を示した。その結果、教師データとテストデータを全て計算機シミュレーション上で用意し、ロジスティック回帰により故障診断を実施した場合は、故障診断の正答率が 81.2% になることを確認した。教師データとテストデータの一部に実測結果を含め、不足分のデータを計算機シミュレーション上で拡張し、ロジスティック回帰により故障診断を実施した場合は、故障診断の正答率が 76.4% になることを確認した。

一般的なアルゴリズムである SVM は正答率が 90% 程度であることに對し、ロジスティック回帰は正答率が下がること、学習回数はロジスティック回帰の方が少ない傾向あることをそれぞれ想定通り確認している。これらの結果から、SVM 等のアルゴリズムより精度は劣るが追加のセンサや高性能なマイコン等を必要としない、ロジスティック回帰を用いた故障検出の有効性を確認している。

今後のエネルギー問題の解決手段として、世界的に PVS は必要不可欠であり、PVS 設置数が増加することが予想される。設置後の保守・メンテナンスも必要不可欠である。近年の機械学習やビッグデータ解析が太陽光発電の分野にも活用できれば、その一助になると考えられる。本稿ではロジスティック回帰を用いた手法について紹介したが、これらの知見を持ち寄り手を動かして、次の世代のために長期間安全に稼働させる仕組みを如何につくるかが私達の世代に課せられた使命ではないかと感じる。今後も研究室の学生達と共に研究を進めていく所存である。

参考文献

- 1) 経済産業省, 「新たな「エネルギーミックス」実現への道のり」再生可能エネルギー発電設備の適正な導入及び管理のあり方に関する検討会(第1回)資料3 経済産業省説明資料 (accessed Aug.8 2024), https://www.meti.go.jp/shingikai/energy_environment/saisei_kano_energy/pdf/001_03_00.pdf
- 2) 太陽光発電協会, 太陽光発電の状況—主力電源化に必要な新規案件開発継続—調達価格等算定委員会資料 (accessed Aug.8 2024), https://www.meti.go.jp/shingikai/santei/pdf/062_01_00.pdf
- 3) 製品評価技術基盤機構, 詳報公表システム (accessed Aug.8 2024), <https://www.nite.go.jp/gcet/tso/shohopub/search>
- 4) 消費者庁, 住宅用太陽光発電システムから発生した火災事故等 (accessed Aug.8 2024), https://www.caa.go.jp/policies/council/csic/report/report_012
- 5) M. Goi, N. Katayama, K. Morita, H. Okawa, A. Kosugi, Y. Imai, Fault Classification of Photovoltaic Power Plants using Convolutional Neural Networks, in *IEEE Transactions on Power and Energy*, **141** (6), 464-472, (2021) (DOI : 10.1541/ieejpes.141.464).
- 6) N. Ishikura, H. Sasaki, M. Fujii, S. Oke, I. Nanno, T. Hamada, and T. Saiki, Verification of Test Model Data for Failure Detection Using Logistic Regression Detectable String Failures Including Cluster Failures, *Proceedings of JSES Conference (2023)* (Nov. 2023), 41, Osaka, Japan.
- 7) A. Eskandari, J. Milimonfared and M. Aghaei, Fault Detection and Classification for Photovoltaic Systems Based on Hierarchical Classification and Machine Learning Technique, in *IEEE Transactions on Industrial Electronics*, **68** (12), 12750-12759, (2021) (DOI : 10.1109/TIE.2020.3047066).
- 8) S. -Q. Chen, G. -J. Yang, W. Gao and M. -F. Guo, Photovoltaic Fault Diagnosis Via Semisupervised Ladder Network With String Voltage and Current Measures, in *IEEE Journal of Photovoltaics*, **11** (1), 219-231, (2021) (DOI : 10.1109/JPHOTOV.2020.3038335).
- 9) G. G. Kim, W. Lee, B. G. Bhang, J. H. Choi and H.-K. Ahn, Fault Detection for Photovoltaic Systems Using Multivariate Analysis With Electrical and Environmental Variables, in *IEEE Journal of Photovoltaics*, **11** (1), 202-212, (2021) (DOI : 10.1109/JPHOTOV.2020.3032974).
- 10) H. P. -C. Hwang, C. C. -Y. Ku and J. C. -C. Chan, Detection of Malfunctioning Photovoltaic Modules Based on Machine Learning Algorithms, in *IEEE Access*, **9**, 37210-37219, (2021) (DOI:10.1109/ACCESS.2021.3063461).
- 11) S. Lu, T. Sirojan, B. T. Phung, D. Zhang and E. Ambikairajah, DA-DCGAN: An Effective Methodology for DC Series Arc Fault Diagnosis

- in Photovoltaic Systems, in IEEE Access, **7**, 45831-45840, (2019) (DOI: 10.1109/ACCESS.2019.2909267).
- 12) Y. Zhao, R. Ball, J. Mosesian, J. -F. de Palma and B. Lehman, Graph-Based Semi-supervised Learning for Fault Detection and Classification in Solar Photovoltaic Arrays, in IEEE Transactions on Power Electronics, **30** (5), 2848-2858, (2015) (DOI:10.1109/TPEL.2014.2364203).
- 13) Y. Zhao, R. Ball, J. Mosesian, J. -F. de Palma and B. Lehman, Graph-Based Semi-supervised Learning for Fault Detection and Classification in Solar Photovoltaic Arrays, in IEEE Transactions on Power Electronics, **30** (5), 2848-2858, (2015) (DOI:10.1109/TPEL.2014.2364203).
- 14) 本田智則, 小澤暁人, 発電実績データによる故障検知 機械学習アルゴリズムの開発

(accessed Aug.8 2024), <https://unit.aist.go.jp/rpd-envene/PV/ja/results/2020/poster/Honda.pdf>

著者略歴



石倉規雄 (イシクラ ノリオ)

2009 年 3 月山口大学大学院理工学研究科博士前期課程修了。同年 4 月横河電機株式会社入社。

2011 年 9 月山口大学大学院理工学研究科博士後期課程修了。

2013 年 4 月米子工業高等専門学校 着任, 現在に至る。

主にパワーエレクトロニクスと PVS システムの安全に関する研究に携わる。博士 (工学)。