

High-Precision Diagnosis of Degradation and Soiling in Photovoltaic Power Plants Using Machine Learning : Evaluation Through Real-World Deployment

Yutaka MORI^{*1‡} Takuya FUJIMOTO^{*2} Shintaro MURAKAMI^{*3} Masahiro HARADA^{*4}

機械学習を用いた太陽光発電所の劣化・汚損診断の 高精度化と実運用案件での評価

森 豊^{*1‡}

藤本 卓也^{*2}

村上 伸太郎^{*3}

原田 真宏^{*4}

Abstract

This study presents a machine learning-based method for diagnosing degradation and soiling in photovoltaic (PV) systems. Using meteorological and operational data from the first year of operation, the model predicts expected power generation and compares it with actual values to detect anomalies. Validation across multiple PV sites shows that this approach identifies performance losses more accurately and promptly than traditional performance ratio (PR) methods. It also detects recovery after panel cleaning and sudden failures. Although training data is required, the method enables effective remote monitoring and supports improved reliability and efficiency in solar power generation.

Keywords: Photovoltaic, Deterioration diagnosis, Machine learning

キーワード：太陽光発電，劣化診断，機械学習

1. 緒言

2050 年にカーボンニュートラルを実現するため，太陽光発電（以下，PV）の導入が世界的に進められている．特に日本においては，2009 年に固定価格買取制度（以下，FIT : Feed-in-Tariff）が導入されて以降，住宅用から産業用に至るまで様々な規模での PV が設置されてきた．PV の導入促進・維持には経済合理性が求められるが，機器の故障や劣化，汚損等が発生した場合，PV 発電量が低下するため，経済性の低下につながる．機器の故障としては，PV モジュールの破損や焼損，パワーコンディショナ（以下，PCS : Power conditioning system）の動作不良等が挙げられるが，その影響は突発的かつ急激に PV の電圧や電流，発電量の変化に現れることから，これら計測値の監視により検知は比較的容易である．一方で，劣化や汚損等による PV

発電量の低下は，PV モジュールが，長期にわたり紫外線や熱，湿気，機械的ストレス等の影響を受けて劣化することや，近隣から飛来する砂や土埃，工業的な排気ガスに含まれる油や煤煙等により汚損することで引き起こされる．劣化や汚損等による PV 発電量の低下は，機器の故障と比較して徐々に進行するため，PV 発電量を単純に監視するのみでは検知することが困難である．また，いずれの要因であっても，継続的な発電量の低下を引き起こした場合，PV 発電所の運用期間全体での経済性に大きな影響を及ぼす可能性がある．そこで，PV 発電所の長期的な安定運用を実現するためには，早期に出力低下を検知し，適切なタイミングでの PV モジュールの清掃や修繕等を実施することが望ましい．

PV 発電所の発電状態を監視する手法として，これまでストリング監視およびシステム出力係数（以下，PR 値 : Performance Ratio）を用いた評価の 2 つが活用されてきた．

*1 Construction Technology Research Center, Daiwa House Industry Co. Ltd., 6-6-2, Sakyo, Nara, 631-0801, Japan
‡e-mail: m00433871@daiwahouse.jp

*2 Researcher, Construction Technology Research Center, Daiwa House Industry Co. Ltd.

*3 Senior Research Engineer, Construction Technology Research Center, Daiwa House Industry Co. Ltd.

*4 Manager, Construction Technology Research Center, Daiwa House Industry Co. Ltd.

Received: September 29 2025, Accepted: December 23 2025

*1 大和ハウス工業株式会社 建築技術研究所
(〒631-0801 奈良市左京六丁目 6-2 総合技術研究所)
‡e-mail: m00433871@daiwahouse.jp

*2 大和ハウス工業株式会社 建築技術研究所 研究員

*3 大和ハウス工業株式会社 建築技術研究所 主任研究員

*4 大和ハウス工業株式会社 建築技術研究所 グループ長

(原稿受付: 2025 年 9 月 29 日, 受理日: 2025 年 12 月 23 日)

PV モジュールは、PCS への入力電圧および入力電流の範囲に合致するように複数枚をまとめて PCS に接続する。PCS に接続する PV モジュール群をストリングと呼び、ストリング監視では、PCS に接続されるストリング毎に電圧値や電流値を監視し、極端な異常値の検出により、短時間で発生する機器故障等を検知する。また PR 値は、実際の PV 発電量を日射量や PV モジュール容量から算出した理想的な状態での発電量で除した値で、PV 発電所の稼働率を表す指標であり、式 (1) により算出される。

$$PR = \frac{E_{PCO} \times G_s}{(H_A \times P_{AS})} \quad \dots (1)$$

ここで示す E_{PCO} は PV 発電量[kWh]、 G_s は標準試験条件における日射強度[kW/m²] (=1.0)、 H_A は評価期間におけるアレイ面日射量[kWh/m²]、 P_{AS} は PV モジュールの定格出力合計[kW]である。

ストリング監視に関する既往研究として、有松ら¹⁾は、ストリングの電圧値および電流値から PV モジュールの異常兆候を予測するために、I-V 特性上に出現する計測点の頻度分析による手法を提案している。また、機械学習を用いた PV 発電量の評価も検討されており、五井ら²⁾は、PV 発電所の各ストリングの電圧値や電流値について機械学習を用いることで、高精度で異常検知が可能であることを示した。一方 PR 値に関する既往研究として、柘ら³⁾は、火山灰による発電効率の低下について分析を行っており、火山灰の堆積量に比例して PR 値が低下することを確認している。鶴崎ら⁴⁾は、PR 値による PV 発電所の評価を実施し、長期的な発電効率の評価において有効な指標であることを示した。しかしながら、鶴崎らの手法は、長期的な PR 値の低下傾向を捕捉するために、計測期間として 12 か月程度は必要であると考えられる。

以上の既往研究から、ストリング監視により異常の兆候を検知することが可能であり、機械学習等の手法を組み合わせることで、より高精度な異常検知が可能であることが示された。しかしながら、各ストリングの評価には、各ストリングの膨大なデータ抽出および評価が必要である。一方 PR 値を用いた評価では、PV 発電所全体の代表的な発電量や日射量のみで長期的な発電量の低下を検知することが可能であることが示された。ただし、PR 値による異

常検知には、数か月～1 年程度の評価期間が必要であり、評価期間中における発電量損失が避けられない。今後、数多くの PV 発電所を汎用的に評価・管理していくためには、PV 発電所全体の発電量や日射量といった一般的な管理項目のみで評価でき、かつより高精度で発電量の低下傾向を検知可能な発電量の評価手法が求められる。

そこで筆者らは、PR 値による評価方法を基に、理想的な発電量を算出する手法として、運転開始時の日射量や気温等の気象データおよび発電量データを用いて、劣化や汚損がない状態時に期待される発電量（以下、期待発電量）を算出する発電量診断モデルを検討した。この発電量診断モデルを用いて、実際の運用期間における気象データを入力して算出される期待発電量を実際の発電量と比較することで、従来の PR 値を用いた評価に比べ、より高精度に劣化や汚損等を検知する手法を考案した。本稿では、実際に運用している発電所のデータを用いて、提案手法を評価した結果について述べる。

2. PR 値による異常検知

Table 1 に、対象とする PV 発電所の情報を示す。当該 PV 発電所は、2017 年 3 月から運用を開始しており、PV 容量は 677.16kW、PCS 容量は 630kW である。なお、PV 発電所の現地日射量取得には、水平面に設置した全天日射計を使用している。日射計の維持管理については、明らかな異常が見られていないため校正や清掃は行っていない。また当該 PV 発電所については、近隣の工場排煙による PV モジュールの汚損が確認されており、2019 年 3 月および 2021 年 7 月に洗浄を実施し、2020 年 8 月には PCS の故障による交換を実施している。

Fig. 1 に、算出した PR 値の結果を示す。PR 値による診断期間は、2017 年 10 月～2021 年 10 月とし、発電量を日射量と PV 容量で除すことで算出した。この時、雨天等で PV 発電量が少ない日においては PR 値が大きく算出される場合がある。そこで、晴天時のみを対象とすることとした。晴天時の判定は、季節による影響を低減するため、水平面大気外日射量に対する水平面全天日射量の割合（以下、晴天指数）が 0.7 以上の時間帯とした。




Fig. 1 Evaluation by PR value

Table 1 Targeted solar power plant

Location	Aichi prefecture
PV capacity	677.16 kW
PCS capacity	630 kW
Start to PV operation	2017/3
Install type	On the roof
Azimuth	0 °
Tilt angle	1.7 °

Fig. 1 に示すように、PR 値で評価を行った場合、2020 年 9 月頃から大きく PR 値が低下していることが確認できる。一方で、当該発電所では 2018 年末に現地に PV モジュールの汚損が確認されたことから、2019 年 3 月に清掃を実施しているが、PR 値のみでは汚損による発電量低下を確実に検知ができない場合があると言える。PR 値を用いた評価について以下にまとめる。

① PR 値の数値的特性

PR 値は発電量と日射量の比で算出するため、朝夕の日射量が少ない時間帯や、日射量の変動が大きいタイミング等では大きく値が変動する。また、例えば運転開始時の性能保証値のような基準となる値が定まっていないため、その絶対値や相対変化から発電所の状態変化を検知することは難しい。

② 発電所固有特性

発電所毎に立地条件や設置方式、汚れや劣化の傾向等が異なることから、発電や劣化の特性に違いが生じるため、発電量と日射量の比である簡易的な PR 値の評価では発電所固有の要因を考慮した評価は難しい。

3. 劣化診断方法の構築

3.1 発電量診断モデルの構築

前述の通り、各発電所は固有の特性をもっており、特に多数の太陽光発電所を運営する際には、すべての情報を把握することが難しいと考えられる。そこで今回、これらの固有の特性を反映させるため、斜面日射量や気温といった気象データに対する発電量の特性を発電所毎に構築することとした。実際の PV 発電所における PV 発電量が適正であるか診断する手法として、劣化等により発電量の低下が比較的少ないと想定される運用開始から 1 年間の実績データを機械学習の学習データとして利用する手法を検討した。なお気温は、後述の通り PV モジュール温度へ換算して使用した。Table 2 に本手法で提案するモデルの諸元を示す。

まず対象となる PV 発電所の運転開始から 1 年間の PV 発電量、斜面日射量および PV モジュール温度を学習データとして、機械学習による発電量診断モデルを構築した。機械学習のアルゴリズムには Prophet⁵⁾を用いた。Prophet は Meta 社が開発した加法モデル型時系列予測アルゴリズム

Table 2 Information of forecast model

Learning period	1 year from the start of operation
Explanatory variable	・ Inclined solar irradiance ・ Panel temperature
Algorithm	Prophet
Forecast interval	30 minutes

であり、トレンドや季節性、曜日特性等を分離して推計が可能となっている。予測値 $y(t)$ は、式 (2) により算出される。

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad \dots (2)$$

ここで示す $g(t)$ はロジスティック成長曲線、 $s(t)$ はフーリエ級数による季節性、 $h(t)$ は曜日特性、 ε_t はガウス分布に従う誤差項である。

また、本稿では PV モジュール温度 T_{PA} [deg] は、式 (3) により算出される⁶⁾。

$$T_{PA} = T_A + \left(\frac{A}{B \times V^{0.8+1}} + 2 \right) \times G_A - 2 \quad \dots (3)$$

ここで示す T_A は外気温 [deg]、 A および B は PV モジュール温度推定係数 ($A=46$, $B=0.41$)、 V は風速 (1.5 m/s で一定とした)、 G_A は斜面日射量 [kW] である。

3.2 発電量診断モデルを用いた評価方法

Fig. 2 に、発電量診断モデルを用いた診断手法を示す。発電診断モデルでは、運転開始から 1 年間のデータを学習データとしていることから、劣化等の少ない発電特性での発電量の推計が可能である。発電量診断モデルに診断対象期間の気象実績データを入力することで、診断対象期間の




Fig. 2 Operating flow of model

気象条件における運転開始当初の特性を保持した場合の発電量を算出することができることから、本稿では、発電量診断モデルの出力を期待発電量とし、期待発電量と実際の発電実績量の30分毎の乖離率(R_d)を用いて評価した。乖離率については、期待発電量と発電実績量を用いて、式(4)により算出される。

$$R_d = \left(\frac{P_r - P_e}{P_e} \right) \times 100 \quad \dots (4)$$

ここで示す P_r は実績発電量[kWh]、 P_e は発電量診断モデルから出力される期待発電量[kWh]である。

算出した乖離率が連続して一定以下の負の値を示している場合、PV 発電量の低下が生じていると判断する。ただし、この乖離率は期待発電量で除するため、PR 値の評価の場合と同様に、雨天等で PV 発電量が少ない日において乖離率が大きく算出される場合がある。そのため、乖離率による評価は、晴天時のみを対象とした。晴天時の判定は、季節による影響を低減するため、晴天指数が 0.7 以上の時間帯とした。

Fig. 3 に、Table 1 に示す PV 発電所における 2017 年 10 月～2021 年 10 月までの乖離率算出結果を示す。2018 年 4 月頃から多くの期間で乖離率が負の値を示し、PV 実績発電量が期待発電量より小さい傾向であることがわかる。この乖離率が負の傾向は継続していることから、2018 年 4 月時点で発電量が低下していると考えられ、Fig. 1 に示す PR 値での評価では困難であった 2019 年 3 月 2 日に行われた一度目の清掃前におきた汚損による影響を検知できる可能性があることを確認した。また Fig. 1 の PR 値による評価と比較して、一度目の清掃により発電量が明確に回復していることも確認できる。加えて、2019 年 6 月以降についても同様に、乖離率が負の状態が続いており、一度目の清掃後、期間を置かず汚損による影響があることも確認した。この時、2021 年 7 月 30 日に行われた二度目の清掃については、乖離率の回復傾向は確認できたが、清掃以降も乖離率が負の状態が続く結果であった。これは、2020 年 10 月頃からの乖離率の低下は、以前よりも悪化した汚損状態を示しており、一度の清掃では対処が困

難だった可能性があると考えられる。さらに、2020 年 8 月の PCS 故障による突発的かつ急激な出力低下も含め、実際の異常や汚損による影響が、今回のシステムによる乖離率の傾向に関係性があることを確認した。

3.3 提案手法による劣化診断方法

本稿での PV モジュールの劣化診断方法では、Fig.3 より、劣化や異常が起こっていない正常な期間では、正の乖離率のみ、あるいは正負の乖離率が繰り返して生じる。一方で、劣化や汚損等が生じ、期待発電量に対し発電実績量が少ない場合、恒常的に負の乖離率が生じる。この傾向から、本手法では、一定期間負の乖離率が連続する場合に劣化や汚損が起きており、具体的には、4 日以上に亘り -5% を下回る乖離率が継続し、かつ正の乖離率が生じなかった場合に劣化や汚損等が生じていると判定することとした。

3.4 晴天時の判定方法

本稿では、雨天時に発電量の絶対値が小さいことによる乖離率の極端な増減を抑制するため、晴天指数が一定以上の場合にのみ乖離率による評価を行った。2 章および 3.2 では、晴天指数を 0.7 として評価したが、劣化および汚損等による影響を判定する上で、評価に必要となるデータ数を確保しつつ、阻害要因となるデータを除去するためには、閾値を決定することが重要である。

Fig. 4 に、晴天指数のヒストグラムを示す。Fig.4 に示すように、晴天指数が 0.9 以上となる時間帯はなかった。これは、雲のない晴天時においても水平面大気外日射量のうち 20% は大気等で吸収され、地表面には到達しないことを示している。また、晴天指数が 0.75 以上の割合は 2%、晴天指数が 0.7 以上の割合は 17%、晴天指数が 0.2 以上の割合は 82% であった。

Fig. 5 に晴天指数 0.75 以上を評価対象とした場合、Fig. 6 に晴天指数 0.2 以上を評価対象とした場合の乖離率の評価結果を示す。Fig. 5 に示すように、晴天指数を 0.75 とした場合、評価対象のデータが得られる期間に偏りが生じ、短期間での評価ができないことが示された。一方、Fig. 6 に示すように、データ数を多くした場合、日射量の変動による成分が多く含まれ、判定が困難であることが示された。




Fig. 3 Evaluation of deterioration diagnosis




Fig. 4 Evaluation of data number




Fig. 5 Evaluation check over 0.75 sunny level




Fig. 6 Evaluation check over 0.2 sunny level

以上の結果から、評価に必要となるデータ数の確保と阻害要因となるデータを除去できる晴天指数の値として 0.7 が最適であると判断した。なお、Fig. 4, 5, 6 の検討に際しては、日中時間帯である 10 時～15 時を対象に、30 分毎に判定を行った。

3.5 診断手法の適用性評価

これまでの検討では、運転開始当初のデータ取得が必須となる。本手法の適用範囲を拡大するため、運転開始 1 年間のデータが得られない発電所でも適用可能か評価するため、Table 3 に示す 4 か所の PV 発電所に対し、直近 1 年間のデータを基に乖離率の評価を行った。学習期間は 2024 年 4 月から 2025 年 3 月とし、評価期間は 2025 年 4 月の 1 か月とした。また、晴天指数は 0.7 以上を評価対象とし、乖離率の判定は、日中時間帯である 10 時～15 時を対象に、30 分毎に行った。

Fig. 7～18 に各 PV 発電所の時間毎の期待発電量と実績発電量の比較、および乖離率、PR 値の評価結果を示す。Site A (Fig. 7, Fig. 8 および Fig. 9) では、負の乖離率を検知しているが連続したものではないため、汚損等の影響は少ないと考えられる。一方 PR 値での評価を行うと、100%から 80%の間を推移しているが、基準となる PR 値

Table 3 Information of other plants

	Site A	Site B	Site C	Site D
Area	Tohoku	Tokyo	Hokuriku	Kyushu
Capacity	1.98MW	2.4MW	1.1MW	2.0MW
Install type	On the ground			On the roof
Azimuth	0°			
Tilt angle	20°	5°	15°	0°
Start to operation	2014/9	2016/10	2020/12	2013/2
Learning period	2024/4/1～2025/3/31			

が不明なため評価が難しい。Site B (Fig. 10, Fig. 11 および Fig. 12) では、特に 4 月 21 日までの期間において連続した負の乖離率を検知していることから、何らかの異常が発生していると考えられる。実際に発電所の状況を確認した結果、当該期間に通信異常が発生したことで PCS1 台分の発電量データが欠損しており、4 月 22 日以降は通信が復帰し、データが取得できていることを確認した。Site B のような事例では、乖離率で顕著な傾向の違いがみられ、PR 値でも同様に確認可能である。Site C (Fig. 13, Fig. 14 および Fig. 15) では、実績値と期待値が非常に近い傾向となっていることから、運転開始当初の発電特性が維持されていると考えられる。一方、Site D (Fig. 16, Fig. 17 および Fig. 18) では、正の乖離率と負の乖離率の双方が生じており、大きな負の乖離率が生じている。これは九州電力エリアにおける出力制御が起因していると考えられる。具体的には、負の乖離率は出力制御により、実績発電量が期待発電量より大幅に低下していることによるものである。また Site D では、学習期間に出力制御期間が含まれており、発電診断モデルに出力制御の影響が含まれていたため、期待発電量が実績発電量よりも小さくなる傾向であった。このため、Site D では正の乖離率も発生した。Site C および Site D の PR 値の傾向を確認すると、Site A および Site B と同様に顕著な傾向の変化は明確に確認できるが、基準となる PR 値が明確ではないため、正常な領域からの乖離度合いや緩やかな傾向の変化を明確に判定することが困難であると言える。

4. 結言

本稿では、機械学習を用いた発電量の診断手法について検討し、実際に運用している発電所のデータを用いて評価を実施した。

診断手法については、運用開始 1 年間の実績データを基に構築した発電量診断モデルを用いて、期待発電量と実績発電量から乖離率を算出することで、PV モジュール




Fig. 7 Hourly evaluation for Site A




Fig. 8 Deviation rate for Site A




Fig. 9 PR value for Site A




Fig. 13 Hourly evaluation for Site C




Fig. 14 Deviation rate for Site C




Fig. 15 PR value for Site C




Fig. 10 Hourly evaluation for Site B




Fig. 11 Deviation rate for Site B




Fig. 12 PR value for Site B




Fig. 16 Hourly evaluation for Site D




Fig. 17 Deviation rate for Site D




Fig. 18 PR value for Site D

の汚損等による影響が顕著になった時期を推定可能であることを示した。従来の PR 値を用いた発電効率の評価と比較して、精度の高い検知が可能であることが示唆されたことから、本手法を用いることで、機器故障等の急激な出力低下に加えて、積雪や劣化・汚損等、様々な出力低下の検知も可能になると考えられる。なお本稿の事例では 4 日以上に亘って-5%を下回る乖離率が継続し、かつ正の乖離率が生じなかった場合に汚損や劣化と判定することとしたが、継続期間や閾値については条件等によって変更または最適化することも必要だと考えられる。

一方、機械学習を用いた手法の課題として、一定期間学習データの蓄積が必要であり、PV 発電所の運用開始当初は、PV 発電量の予測や診断に活用できないことが挙げられる。当該期間については、従来の PR 値を用いた診断手法を用い、学習データの蓄積に合わせて、手法の変更または併用することが望ましい。さらに、学習期間に出力抑制状態のデータが存在する場合、見かけ上の出力低下が発生しているため、発電量の実績値が期待値を上回る場合があることから、電力市場の状況を鑑みた学習データのスクリーニング等が必要である。同様に、過積載率が高いシステムの場合にも期待発電量よりも実績電力量が目減りする場合もあるが、これについては補正や学習で対応が可能とも想定される。本手法で対応可能な過積載率についても今後検討が必要である。上記内容を考慮し、PV 発電量の推計に関する従来の手法との推定精度の比較等を踏まえた更なる高精度化が今後の課題であると考えられる。

参考文献

- 1) K. Arimatsu, Y. Sekiba, and H. Haga, Study on Abnormality Sign Detection Method of Photovoltaic Power Generation Systems using Frequency Difference Distribution Index in Power Generation Region, IEEJ Transactions on Power and Energy, **143** (6), 402-410 (2023) (DOI: 10.1541/ieejpes.143.402)
- 2) M. Goi, N. Katayama, K. Morita, H. Okawa, A. Kosugi, and Y. Imai, Fault Classification of Photovoltaic Power Plants using Convolutional Neural Networks, IEEJ Transactions on Power and Energy, **141** (6), 464-472 (2021) (DOI: 10.1541/ieejpes.141.464)
- 3) K. Haji, Y. Seto, R. Nagata, and Y. Kusuvara, Evaluation by the PR method regarding the power generation ability of volcanic ash from Sakurajima on Equipment of Photovoltaic Generation, Transactions of the Institute of Electrical Installation Engineers of Japan, **41** (7), 47-52 (2021) (DOI: 10.14920/jieej.41.7_47)
- 4) T. Tsurusaki, K. Yuasa, and H. Nakagami, Field Performance Evaluation of Residential Photovoltaic Systems Based on Long-Term Measurement Data, Journal of Japan Society of Energy and Resources, **37** (3), 1-9 (2016) (DOI: 10.24778/jjser.37.3_1)
- 5) Sean J. Taylor, Benjamin Letham, Forecasting at Scale (accessed Aug.26 2025), https://facebook.github.io/prophet/static/prophet_paper_20170113.pdf
- 6) 国立研究開発法人建築研究所, 建築研究資料 第 188 号「住宅用太陽光発電システムの設計・施工ガイドライン」(accessed Aug.26 2025), <https://www.kenken.go.jp/japanese/contents/publications/data/188/3.pdf>