

Development of daily three-layer neural networks to estimate PV power from global horizontal irradiation

Takahiro BANDO^{*1‡} Tsubasa ITO^{*2} Hayate WAKISAKA^{*2}
Atsushi FUKUDA^{*2} Hiroki KOBAYASHI^{*2} Toru HARIGAI^{*2}
Hirofumi TAKIKAWA^{*2} Motohisa HIRATSUKA^{*3} Shiro MAKI^{*3}

水平面全天日射強度から PV 発電電力推定を行う 日別 3 層ニューラルネットワークの開発

坂東 隆宏^{*1‡} 伊藤 翼^{*2} 脇坂 颯^{*2}
福田 敦史^{*2} 小林 宏規^{*2} 針谷 達^{*2}
滝川 浩史^{*2} 平塚 元久^{*3} 真木 志郎^{*3}

Abstract

In this study, a daily three-layer artificial neural network (ANN) which converts from global horizontal irradiation (GHI) to photovoltaic (PV) power is developed. Here, each ANN estimates PV power of a specific day after the ANN learns the data from days around the specific day. Though the three-layer ANN has small numbers of the weight in the ANN, daily ANNs are expected to include the seasonal dependence which appears in the conversion from GHI to PV power. In addition to GHI, temperature, humidity, and solar azimuth are given as input variables. As a result of applying the developed daily ANN to a sunny day, a cloudy day, and a rainy day, it was confirmed that the PV power generation in these object days could be accurately estimated. The estimation errors were also evaluated for one year and effectiveness of daily three-layer ANNs with proposed input parameters was shown.

Keywords: Estimation of photovoltaic power, Solar irradiation, Clearness index, Artificial neural network, Optimization
キーワード: 太陽光発電における発電電力推定, 日射強度, 晴天指数, 人工ニューラルネットワーク, 最適化

1. はじめに

太陽光発電の経済的有効運用に向け、発電電力量（発電量）を精度良く予測し、実績値との差を小さくすることが必要不可欠である。太陽光発電量（PV 発電量）の予測手法に関する研究は、近年精力的に行われており^{1,2)}、気象モデルによる手法、衛星観測による手法、全天球カメラや日射センサを用いた地上観測による手法³⁻⁶⁾の開発が進められている。

さて、PV 発電量は太陽光パネル（PV パネル）面に対する日射強度に強く依存する⁷⁾ため、実質的には日射強度を予測することが重要である。このような観点から、本研究グループでは、地上観測に基づく特定点太陽光発電所（PV 発電所）における水平面全天日射強度（GHI）を予測するシステムを開発してきた⁸⁻¹²⁾。本システムでは、特定点 PV 発電所の周囲に全天球カメラおよび日射センサを設置す

る。全天球カメラにより特定点 PV 発電所へ向かう雲の推定を行い、そして、日射センサにより雲影による GHI の減衰量および雲影移動速度を推定する。これら推定量を用いて、特定点 PV 発電所での GHI を予測する。

本システムでは、予測 GHI から非線形回帰により予測 PV 発電量を得る。この非線形回帰には、人工ニューラルネットワーク（ANN）を用いる。ANN を用いることで内部がブラックボックスになるが、JIS C 8907「太陽光発電システムの発電電力量推定方式」で求められるような、地表面のアルベド、PV パネルの設置角度（方位角）、PV パネル温度などを評価せずに PV 発電量へ変換できる点に優位性がある。ANN による発電量予測¹³⁻¹⁵⁾は広く行われており、それぞれ、入力層に与えるデータの違いやネットワーク構造の違い（画像解析に有用な畳み込み ANN、時系列データに有用なリカレント ANN など）がある。

本研究では、GHI から PV 発電電力推定を行う 3 層 ANN

*1 Assistant Professor, Toyohashi University of Technology, 1-1 Hibarigaoka, Tempaku, Toyohashi, Aichi 441-8580, Japan

‡e-mail: bando.takahiro.pd@tut.jp

*2 Toyohashi University of Technology

*3 AIM Co., Ltd.

Received: November 13, 2023, Accepted: March 28, 2024

*1 豊橋技術科学大学 助教 (〒441-8580 愛知県豊橋市天伯町雲雀ヶ丘 1-1)

‡e-mail: bando.takahiro.pd@tut.jp

*2 豊橋技術科学大学

*3 株式会社エイム

(原稿受付: 2023 年 11 月 13 日, 受理日: 2024 年 3 月 28 日)

を日別に開発した。3層 ANN は畳み込み ANN やリカレント ANN などと比較しネットワークが簡易であるため、(i) 準備すべき学習データが少なく済む、(ii) 学習時間を抑制できる、など、開発コストを小さくできることが期待できる。一方で、ANN の重みの数が少ない分、GHI から PV 発電電力への非線形回帰に含まれる季節依存性への対応が課題となる。季節依存性の例として、太陽高度の季節依存性がある。GHI と PV パネル上の傾斜面日射強度との関係は太陽高度に依存するため、同じ GHI でも季節により傾斜面日射強度を介して PV 発電電力との関係式が変わる。また、太陽高度・太陽方位角によっては建物の影が PV パネルにかかってしまい、その影の分だけ PV 発電電力を低く推定する必要がある。3層 ANN を日別に開発することで、これら季節依存性を個々の日別 ANN に取り込むことができる可能性がある。日別 ANN の学習に対する具体的な例は第 3 章第一段落に示す。

なお、先に述べたように、予測 GHI から太陽光発電電力を推定する手法を本システムでは提案している。しかしながら本研究では、システムの一部の開発を念頭に、GHI から太陽光発電電力を推定する部分に対象を絞って検討する。そのため、予測 GHI ではなく実測 GHI を用いる。

本稿第 2 章では ANN の学習・評価用のデータに加え、ANN の構造・入力データ・その他のハイパーパラメータについて述べる。第 3 章で年間を通して評価した推定誤差を示し、本研究で開発した手法の有効性を示す。第 4 章で結論を述べる。

2. ANN の学習・評価用データの取得および ANN の構造について

2.1 学習・評価用データの取得

本研究で用いたデータは、豊橋技術科学大学（愛知県豊橋市）の研究棟の屋上（緯度 34.7 度、経度 137.4 度）での観測で取得した。ANN の入力層は、GHI、気温、湿度、太陽方位角とし、出力層は PV 発電電力として、これらの学習・評価用データを取得した。気温、湿度、太陽方位角を入力層に与える理由は次節で述べる。GHI は水平面全天日射計（英弘精機、MS-601）、気温および湿度は湿温度計（英弘精機、MT-063-A）を用いて測定した。太陽方位角は文献 [16] の式 1、式 2 から評価した。太陽方位角の評価に必要な太陽赤緯、均時差は文献 [12] の Appendix A で記した手法により計算した。PV 発電電力を評価した PV パネルは、Si 多結晶太陽電池であり、定格直流出力 4.86 kW、面積 32.8 m² である。PV パネルの設置傾斜角は 35 度、設置方位角は 171 度である。GHI、気温、湿度および PV パネルにおける発電電力は、1 秒サンプリングで取得し、ANN 学習時の計算時間を抑えるため 1 分ごとの瞬時値となるようにダウンサンプリングした。雲影による日射強度の変動は 1 分より短い間隔で起きるため、実際の予測システムで

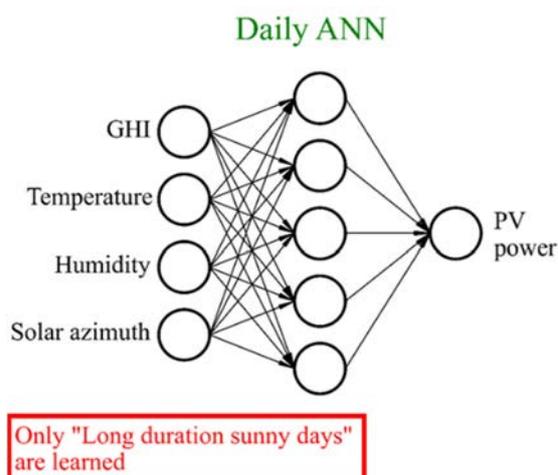


Fig. 1 Structure of the daily ANN.

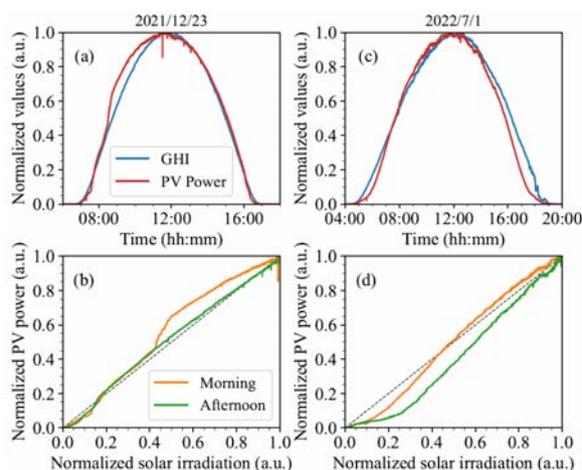


Fig. 2 (a) Normalized GHI and PV power at 2021/12/23. (b) Relationship between normalized GHI and PV power at 2021/12/23. (c) Normalized GHI and PV power at 2022/7/1. (d) Relationship between normalized GHI and PV Power at 2022/7/1. In (a), the sudden change of the gradient of PV power in the morning is due to the disappearance of the shadow on the PV panels.

は 1 秒サンプリングデータを用いて ANN による推定を行う。

なお、本計測システムで得られた GHI、気温、PV 発電電力の月変化については、文献 [12] で紹介している。

2.2 ANN の構造、入力データ、ハイパーパラメータ

本研究で使用した ANN の構造を Fig.1 に示す。ANN は 3 層の全結合型ニューラルネットワークであり、中間層のノード数は 5 とした。ANN の構造は同一とし、学習データを変えることで 2022/06/01 から 2023/05/31 までの日別モデルを開発した。ここで、各日別モデルの学習日は、前年同日±14 日および同年-14 日とした。各日別モデルの周辺日のデータを学習することで、GHI の傾斜面日射強度への寄与などを学習できると期待できる。また、日射がある時間帯のみ PV 発電電力を推定すれば十分であるので、

GHI が 50 W/m^2 を超える時間帯のみ学習した。ANN の学習・評価には、Python 言語のライブラリである PyTorch を用いた。

入力層には GHI, 気温, 湿度, 太陽方位角を与える。以降, これらの変数を単に「4 変数」と記載する。ここで, 入力層にこれら 4 変数を選択した理由を述べる。まず, ある一日に限ったとしても, GHI と PV 発電電力は一般に非線形であることを確認する。Fig. 2 に示すように, 太陽高度が最も低くなる冬至付近, 太陽高度が最も高くなる夏至付近において, 午前と午後で GHI と PV 発電電力は比例係数が異なることがわかる。この理由はたとえば, PV 発電電力には, PV パネル温度の変化による効率変化も寄与し, かつ, 雲がない晴天でも気温は午前・午後で一致しないからである。そこで, GHI に加えて, PV パネル温度に寄与しうるとされる気温¹⁷⁾, 湿度¹⁸⁾, そして, 午前と午後を識別するため太陽方位角を加えた。太陽方位角は GHI から傾斜面日射強度を推定する式⁷⁾にも含まれており, この観点からも推定精度向上が期待できる。GHI のみ入力層に用いた場合と 4 変数を入力層に用いた場合の推定誤差の比較を第 3 章で述べる。なお, ANN に 4 変数および PV 発電電力を与える際に, それぞれの値が 0~1 に収まるように規格化した。

実際の PV 発電電力の推定では, 晴天で日射強度が強い時ほど推定精度が高いことが求められる。そこで, 学習対象とする期間の全日を学習するのではなく, 晴天指数を用いて「晴天長時間継続日(Long duration sunny day)」のみを抽出し学習データとして用いた。具体的には, 晴天指数が 0.6 以上かつ 0.9 以下の値を 200 分継続したときに「晴天長時間継続日」と判定し, 1 日分のデータを学習した。本研究における晴天指数の評価方法は, 文献[12]の Appendix A に示した手法に基づく。Fig. 3 に(a)晴天長時間継続日と判定した日と(b)晴天長時間継続日から除外した日の GHI, 大気外水平面日射強度, 晴天指数, 気温, 湿度の時間変化を示した。本研究を行った愛知県豊橋市では, 雲のない晴天時における晴天指数はおよそ 0.7~0.8(Fig.3(a))であり, 晴天指数が 0.6 以下であれば曇天であると想定できる。また, 太陽周辺に多少の雲が存在する場合には, 晴天指数が瞬時的に増大する Cloud enhancement event (CEE)¹⁹⁾が発生し, 晴天指数が 0.9 を超えることがある(Fig.3(b))。雲があるときの条件を除外するため, 晴天指数が 0.9 以下であることを晴天長時間継続日の判定条件に含めた。Fig. 4 に, 各月での晴天長時間継続日の日数を示すが, 冬季に多く, 夏季に少ない。

最後に, ANN のその他のハイパーパラメータについて述べる。中間層の活性化関数としては ReLU²⁰⁾を用いた。損失関数は平均二乗誤差とし, 重みの初期化手法として He の初期化²¹⁾を用いた。最適化手法としては Adam²²⁾ (学習率 0.005, beta1=0.9, beta2=0.999) を用いた。学習にはミニバッチ学習を採用し, バッチサイズは 2⁶とした。これらハイパーパラメータについては, 事前にいくつかの条件で

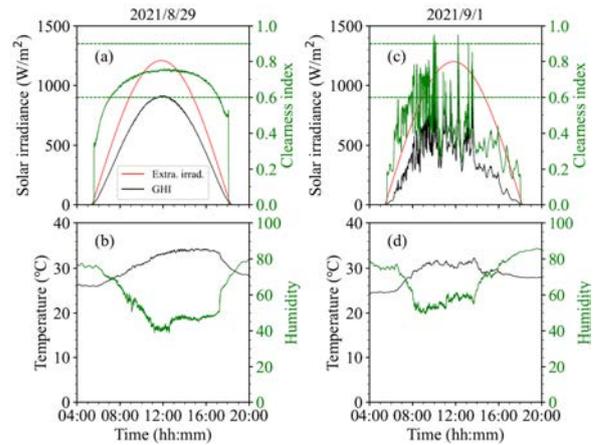


Fig. 3 GHI, the extra-terrestrial solar irradiance, the clearness index, the temperature, the humidity of “Long duration sunny day” ((a) and (b)) and the day which is not “Long duration sunny day” ((c) and (d)). When the extra-terrestrial solar irradiance was $<50 \text{ W/m}^2$, the clearness index was set to zero.

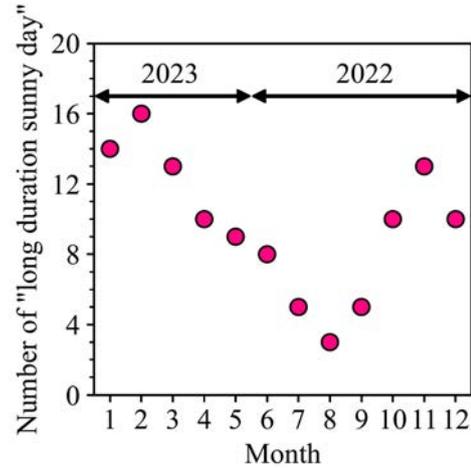


Fig. 4 Number of “long duration sunny day” for each month from 2022/06 to 2023/05.

調査し, 本研究に最適なものを決定している。

3. ANN による PV 発電電力への推定誤差の評価

各日別モデルの推定精度は, 対象日の PV 発電電力の測定値と ANN による推定値の二乗平均平方根誤差(RMSE) を評価することで検証した。具体的な例として, 2022/12/15 の ANN モデルを開発し, 推定誤差を評価する手順を示す。

- (1) 前年同日 ± 14 日および同年-14 日を選択。今回は, 2022/12/01~2022/12/14 および 2021/12/01~2021/12/29 である。
- (2) この期間において晴天長時間継続日を判定する。晴天長時間継続日で, GHI が 50 W/m^2 を超える時間帯のデータをを用いて学習する。

Table 1 Comparison of RMSE on the sunny day, the cloudy day, and the rainy day.

	RMSE with “Only GHI”	RMSE with “Four params.”
Sunny day (2023/05/01)	0.20 kW	0.14 kW
Cloudy day (2022/06/06)	0.30 kW	0.31 kW
Rainy day (2022/07/03)	0.29 kW	0.35 kW

(3) 学習した ANN を用いて、2022/12/15 の GHI 他 の データから PV 発電電力を推定する。この推定した PV 発電電力と実測の PV 発電電力とを比較し、RMSE を評価する。

本手順の元では、前年度のデータがない場合や晴天長時間継続日が少なく、十分な日数の学習データが得られない場合があります。そのような場合は、同年-20 日を選択するなど、選択する期間を調整することを推奨する。

Fig. 5 に(a) 晴れの日、(b)曇りの日、(c)雨の日における PV 発電電力の推定結果を示す。比較のため、GHI のみ入力層に用いた場合 (Only GHI) と 4 変数を入力層に用いた場合 (Four params.) の結果を示す。晴れの日、曇りの日、雨の日で、GHI のみ入力層に用いた場合、4 変数を入力層に用いた場合の両ケースで、PV 発電電力を推定できていることがわかる。

前段落では晴れの日、曇りの日、雨の日のある一日を取り出し、入力層に与える変数による RMSE の違いを示した。ここでは、より傾向をはっきりとつかむため、1 年間を通して日別モデルそれぞれで RMSE を評価し、その頻度分布を比較する。Fig. 6 では入力層に GHI のみ用いた場合の ANN と入力層に 4 変数を用いた場合の ANN について、2022/06/01 から 2023/05/31 の 1 年間に対する RMSE を示す。なお、この期間中、データ欠損日が、2 月に 1 日、3 月に 2 日、5 月に 3 日、6 月に 2 日、8 月に 3 日、11 月に 1 日ある。ここでは、季節ごとの PV 発電電力の変化が RMSE の変動に含まれることを防ぐため、4 季節にわけて比較する。季節依存性は見られるものの、おおよそ RMSE が 0.2 kW 付近に最頻値がある。Table. 1 の曇りの日の RMSE が 0.3kW であることを考えると、Fig.5 の PV 発電電力の変動を再現可能である程度には推定できていることがわかる。また、GHI のみ用いた場合と 4 変数を用いた場合を比べてみると、4 変数の場合で最頻値がより低 RMSE 側にあることがわかる。次に、学習に用いた晴天長時間継続日を対象として RMSE を評価した場合の結果を Fig.7 に示す。こちらでも、4 変数を用いた場合で最頻値がより低 RMSE 側にあることがわかる。これらより、年間を通して評価することで、GHI 単体より、GHI、気温、湿度、太陽方位角を入力層に用いた場合で RMSE の最頻値がより低

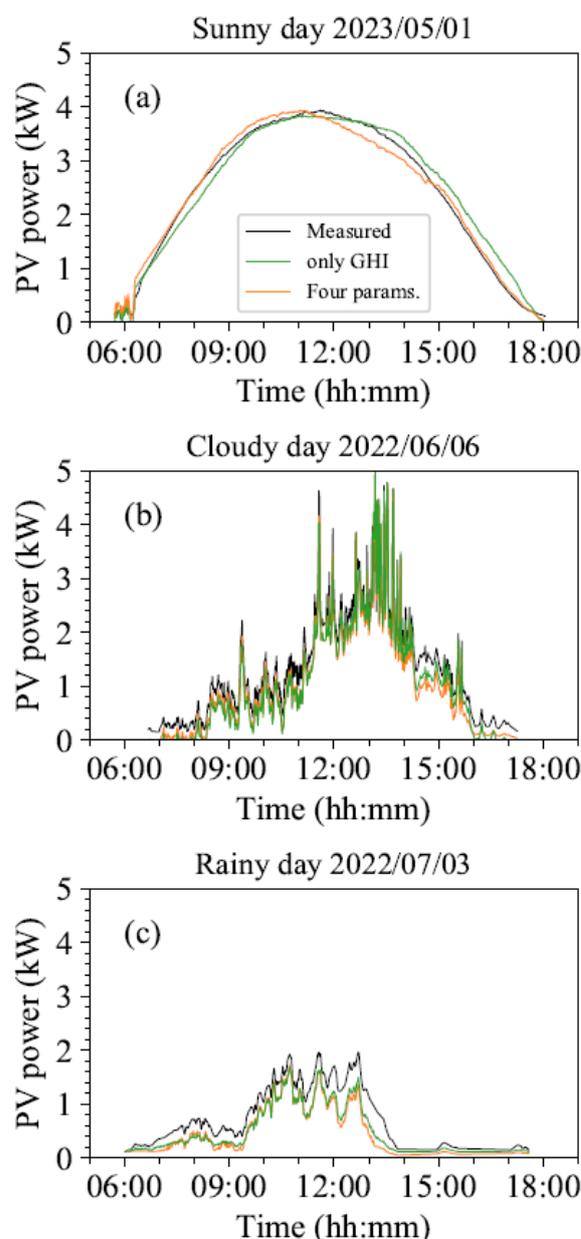


Fig. 5 Results of regression by ANNs for a sunny day (2023/05/01), a cloudy day (2022/06/06), a rainy day (2022/07/03). Here, “Measured” means the measured PV power, “Only GHI” means the result of an ANN only with GHI as the input parameter, and “Four params.” means the result of an ANN with GHI, temperature, humidity, solar azimuth as the input parameters.

くなることが確認できた。

Fig. 6, Fig. 7 では 4 季節に対して頻度分布を示したが、月毎および年間の RMSE も評価した。2022/06/01~2023/05/31 における月毎の RMSE を Fig. 8(a)、晴天長時間継続日のみを対象として評価した月毎の RMSE を Fig.8(b)に示す。Fig. 8(a)は Fig. 6 と、Fig. 8(b) は Fig. 7 と対応する。Fig. 8(a)では、GHI を用いた場合と 4 変数を用いた場合とで明確な RMSE の差異は見られない。

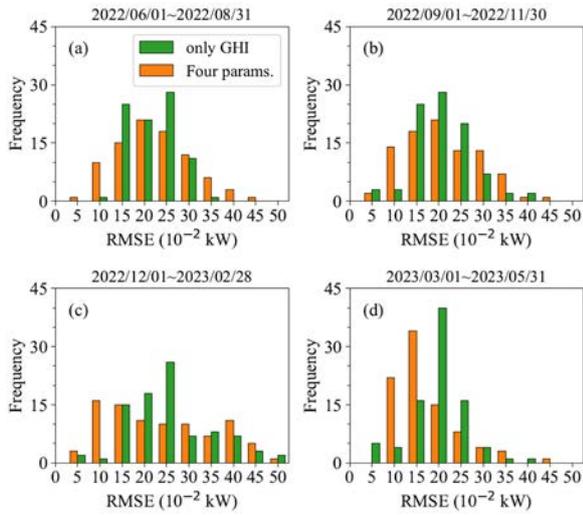


Fig. 6 Distribution of RMSE on all days in four seasons; (a) 2022/06/01 ~ 2022/08/31, (b) 2022/09/01 ~ 2022/11/30, (c) 2022/12/01 ~ 2023/02/28, (d) 2023/03/01 ~ 2023/05/31. Definition of “Only GHI” and “Four params.” are explained in the caption of Fig. 5.

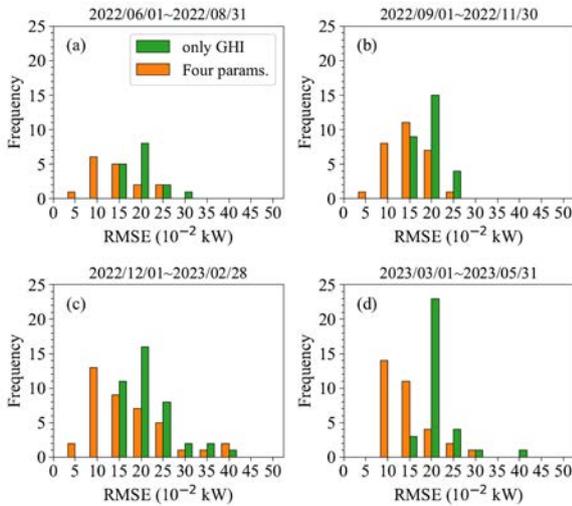


Fig. 7 Distribution of RMSE on “Long duration sunny day’s in four seasons; (a) 2022/06/01 ~ 2022/08/31, (b) 2022/09/01 ~ 2022/11/30, (c) 2022/12/01 ~ 2023/02/28, (d) 2023/03/01 ~ 2023/05/31. Definition of “Only GHI” and “Four params.” are explained in the caption of Fig. 5.

一方で、Fig. 8(b)では、4変数を用いた場合で明確にRMSEが小さい。この傾向は、Fig. 6とFig. 7との比較と符合する。年間のRMSEを評価すると、2022/06/01~2023/05/31の全日を対象とすれば、GHIを用いた場合では0.23 kWとなり、4変数を用いた場合では0.23 kWとなり、両者の差は明確ではない。一方で、晴天長時間継続日のみを対象とすれば、GHIを用いた場合では0.21 kWとなり、4変数を用いた場合では0.17 kWとなり4変数を用いた場合の方が小さい。これは、Fig.8の結果と符合する。

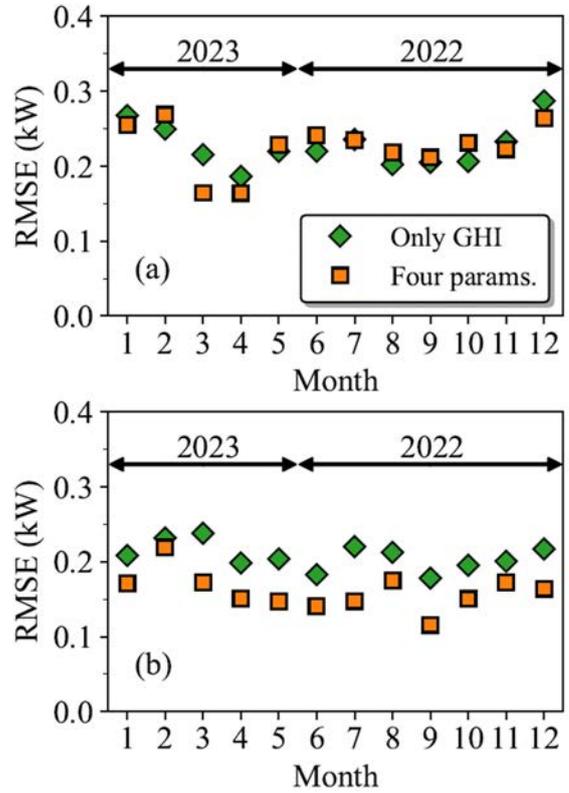


Fig. 8 (a) Monthly data of RMSE on all days for 2022/06/01 ~ 2023/05/31. (b) Monthly data of RMSE on “Long duration sunny day’s for 2022/06/01 ~ 2023/05/31. Definition of “Only GHI” and “Four params.” are explained in the caption of Fig. 5.

さて、日別モデルを開発する理由として、第1章では、日別モデルが季節依存性を取り込むことができる可能性を指摘した。これを、2022/11/08を対象に、前年同日±14日および同年-14日を選択し学習したモデルで検討した。Fig.9では、2022/11/08を対象に学習したANNモデルを用いて、GHIからPV発電電力への推定を、2022/11/08と2022/06/11に対して行った結果を示す。2022/11/08ではPV発電電力を問題なく推定できている(RMSE=0.11 kW)が、2022/06/11では大きく外れている(RMSE=0.93 kW)ことがわかる。同様の処理を2022/11/08を中心として1年間計算することで、2022/11/08付近でRMSEが最小になることを確認している。以上より、日別モデルを開発することで、対象日で特にPV発電電力の推定誤差を低減し、すなわち、対象日が持つ季節性を取り込めたことが示唆される。

4. 結論

本研究では、GHIからPV発電電力を推定する3層の日別ANNを開発した。3層ANNは畳み込みANNや再帰性ANNなどと比較しネットワークが簡易であるため、開発コストが小さくなることが期待できる。重みが少ない3層ANNゆえに学習が上手くいかない可能性があるが、日別

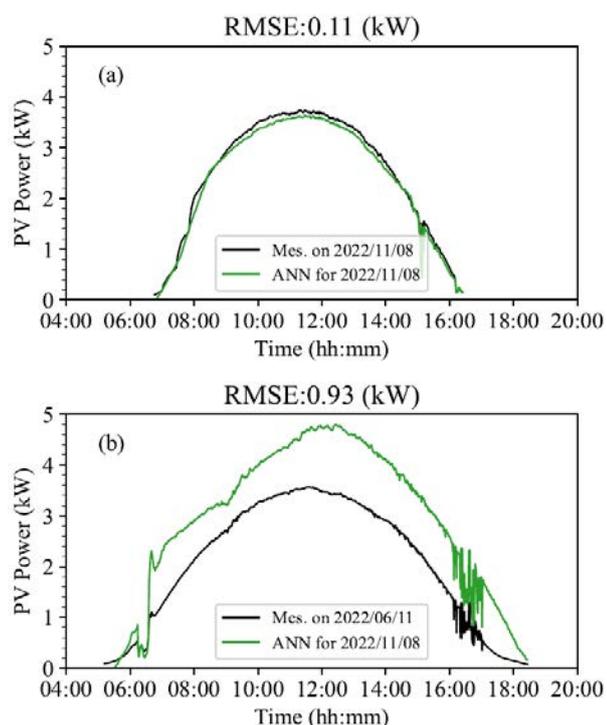


Fig. 9 Results of regression by the ANN learning for 2022/11/08. The black lines show the measured PV power. The green lines show the estimated PV power by the ANN learning for 2022/11/08. (a) Results on 2022/11/08. (b) Results on 2022/06/11.

に学習する ANN を開発することで、GHI から PV 発電電力へ変換する際に現れる季節依存性を取り込めることを期待した。実際、開発した日別 3 層 ANN により晴れの日、曇りの日、雨の日においては PV 発電電力をある程度再現することができた。また、入力変数として、GHI 単体を用いた場合と、GHI に加えて気温、湿度、太陽方位角を用いた 4 変数の場合とで、年間を通して RMSE を評価した。その結果、4 変数を入力変数とした場合の方が、RMSE の頻度分布の最頻値が小さく、推定誤差をより小さくできることが示唆された。これは、PV パネル効率に寄与する気温などで、GHI と発電電力との非線形関係を表現できたためと考えられる。以上より、本研究で用いた日別 3 層 ANN が PV 発電電力の推定に有効であることを示した。ただし、より詳細な考察のため、絶対平均パーセント誤差など他の指標での推定精度評価が今後も不可欠である。

一方で、本手法の課題として、ANN の学習・推定用データを取得するために計測機器の設置が必要な点が挙げられる。特に、時間的変動が激しい GHI については測定機器を設置する必要がある。比較的変動が緩やかな温度・湿度については、近接するアメダス観測所の計測データを用いることで、代替できる可能性がある。アメダス観測所でのデータによる代替可能性は、今後の研究課題の一つである。

また、本研究では予測 GHI ではなく実測 GHI により

推定誤差を評価した。第 1 章で述べた通り、開発中のシステムでは予測 GHI を用いて PV 発電電力を推定する。そのため、システム全体における予測誤差は、本研究で示した推定誤差より大きくなる可能性がある。この点にも注意が必要である。

謝辞

本研究の一部は、パワーアカデミー研究助成および JSPS 科研費 23K13310 の支援を受けて行われた。

参考文献

- 1) Dazhi Yang, Wenting Wang, Christian A. Gueymard, Tao Hong, Jan Kleissl, Jing Huang, Marc J. Perez, Richard Perez, Jamie M. Bright, Xiang'ao Xia, Dennis van der Meer, and Ian Marius Peters, A review of solar forecasting, its dependence on atmospheric sciences and implications for grid integration: Towards carbon neutrality, *Renew. Energy Environ. Sustain* **161**, 112348 (2022).
- 2) Jan Kleissl, "Solar Energy Forecasting and Resource Assessment" Elsevier (2013).
- 3) Bruno Juncklaus Martins, Allan Cerentini, Sylvio Luiz Mantelli, Thiago Zimmermann Loureiro Chaves, Nicolas Moreira Branco, Aldo von Wangenheim, Ricardo R  ther, and Juliana Marian Arrais., Systematic review of nowcasting approaches for solar energy production based upon ground-based cloud imaging, *Solar Energy Advances* **2**, 100019 (2022).
- 4) Bijan Nouri, Stefan Wilbert, Niklas Blum, Yann Fabel, Elke Lorenz, Annette Hammer, Thomas Schmidt, Luis F. Zarzalejo, Robert Pitz-Paal, Probabilistic solar nowcasting based on all-sky imagers, *Solar Energy* **253**, 285 (2023).
- 5) A. T. Lorenzo, W. F. Holmgren and, A. D. Cronin, Irradiance forecasts based on an irradiance monitoring network, cloud motion, and spatial averaging, *Solar Energy* **122**, 1158 (2015).
- 6) X. Chen, Y. Du, E. Lim, H. Wen, and L. Jiang, Sensor network based PV power nowcasting with spatio-temporal preselection for grid-friendly control, *Applied Energy* **255**, 113760 (2019).
- 7) Amit KumarYadav and S.S.Chandel, Tilt angle optimization to maximize incident solar radiation: A review, *Renew. Energy Environ. Sustain* **23**, 503 (2013).
- 8) H. Kobayashi, T. Harigai, Y. Takeuchi, H. Takikawa, K. Ito, and M. Hiratsuka, Analysis of Output Fluctuation of Solar Power Generation and Detection of Short-Time Fluctuation Period, *Journal of Japan Solar Energy Society* **47**, 59 (2021).
- 9) Y. Takeuchi, T. Harigai, H. Kobayashi, H. Takikawa, K. Ito, and M. Hiratsuka, Sensor Signal Variations during Shadow Passing in Cloud-Shadow-Behavior Estimation Method with Original Solar Irradiation Sensors, *Journal of Japan Solar Energy Society* **46**, 4 (2020).

- 10) R. Nomura, T. Harigai, Y. Suda, and H. Takikawa, Second by second prediction of solar power generation based on cloud shadow behavior estimation near a power station, *AIP Conf. Proc.* **1807**, 020024 (2017).
- 11) T. Bando, T. Ito, G. Sano, Y. Miyahara, T. Aizawa, T. Harigai, H. Takikawa, M. Hiratsuka, and S. Maki, Statistical Analysis of Cloud Layers and Derivation of Motion Directions of Two Layer Clouds, *IEEE Transactions on Power and Energy* **142**, 490 (2022).
- 12) T. Bando, T. Ito, H. Wakisaka, Y. Miyahara, T. Aizawa, T. Harigai, H. Takikawa, M. Hiratsuka, and S. Maki, Statistical analysis of cloud layers and solar irradiations for all seasons in Toyohashi city, Japan, *Renewable Energy and Environmental Sustainability* **8**, 18 (2023).
- 13) Ammar H. Elsheikh, Swellam W. Sharshir, Mohamed Abd Elaziz, A.E. Kabeelf, Wang Guilun, and Zhang Haiou, Modeling of solar energy systems using artificial neural network: A comprehensive review, *Solar Energy* **180**, 622 (2019).
- 14) Amit Kumar Yadav and S. S. Chandel, Solar radiation prediction using Artificial Neural Network techniques: A review, *Renewable and Sustainable Energy Reviews* **33**, 772 (2014).
- 15) A. Mellit, S. Sağlam, and S.A. Kalogirou, Artificial neural network-based model for estimating the produced power of a photovoltaic module, *Renewable Energy* **60**, 71 (2013).
- 16) S. Soulayman, Comments on solar azimuth angle, *Renewable Energy* **123**, 294 (2018).
- 17) S. Dubey, J. N. Sarvaiya, and B. Seshadri, Temperature Dependent Photovoltaic (PV) Efficiency and Its Effect on PV Production in the World A Review, *Energy Procedia* **33**, 311 (2013).
- 18) A. K. Tripathi, S. Ray, M. Aruna, and S. Prasad, Evaluation of solar PV panel performance under humid atmosphere, *Materials Today: Proceedings* **45**, 5916 (2021).
- 19) A.A. Piedehierro, M. Antón, A. Cazorla, L. Alados-Arboledas, and F.J. Olmo, Evaluation of enhancement events of total solar irradiance during cloudy conditions at Granada (Southeastern Spain), *Atmospheric Research* **135–136**, 1 (2014).
- 20) V. Nair and G. E. Hinton, Rectified linear units improve restricted boltzmann machines, Proceedings of the 27th International Conference on International Conference on Machine Learning (2010), 807–814, Haifa.
- 21) K. He, X. Zhang, S. Ren, J. Sun, and Microsoft Research, Deep Residual Learning for Image Recognition, Proceedings of the IEEE conference on computer vision and pattern recognition (2016), 770-778, Las Vegas.
- 22) Diederik P. Kingma and Jimmy Lei Ba, Adam: A method for stochastic optimization, arXiv preprint arXiv:1412.6980, (2014).