

深層学習と物理学を融合した日射量予測技術の開発

Development of Physics-informed machine learning models for solar irradiance prediction

佐々木 潤*

1. はじめに

太陽光発電は、天候の変化によって発電出力が大きく変動する。このような変動電源を電力ネットワークに接続する場合には、電力の安定供給のためにも発電量を事前に正確に予測することが必須となっている。特に、太陽光発電の導入が拡大するにつれて、高精度な日射量予測情報の必要性が増している。

電力ネットワークの需給運用の際には、各時間帯における日射量・発電出力の予測情報が使われている（図1）。発電量の実況監視、過去の傾向を分析するためには、発電量自体の測定値に加えて、日射量の推定値が活用される。電力市場からの電力の調達のためには、日射量の短時間先の予測が用いられる。さらに、前日の需給計画には、気象モデルによる翌日予測結果が利用される。また、需給運用以外にも、インバランスの低減、蓄電池の最適制御等にも日射量の予測情報が活用されている。

以上のように、様々な予測時間帯において日射量・発電出力の予測情報が必要とされているが、予測時間に応じて、要求される精度や日射量の変動を支配する物理過程が異なるために、採用する予測手法も

異なる場合が多い。例えば、実況推定には、気象衛星画像から日射量を推定する手法が主に用いられる。短時間先予測（数時間先までの予測）では気象衛星画像の変化傾向を用いて日射量を予測する手法が一般的である。翌日予測や長期予測には、物理方程式に基づいた気象モデルが採用されることが多い。これらの日射量推定・予測においては、近年、物理学的手法とともに機械学習や深層学習を含む統計手法も積極的に使われ始めている。

現在筆者らは、NEDO（国立研究開発法人新エネルギー・産業技術総合開発機構）の委託研究の中で日射量予測技術の高度化に関する研究を進めている。研究テーマは以下の2つがある。

- ①日射量の短期予測に関する研究開発
- ②翌日および翌々日程度先の日射量予測技術の開発

①は、6時間程度先までの高精度な日射量予測を行うために、気象衛星画像と深層学習を用いて大気力学と雲物理過程を考慮した予測モデルを構築するプロジェクトである。また、数時間程度先予測において信頼幅情報の作成手法、効果を検証している。

②は、太陽光発電出力の予測誤差による電力系統への影響を緩和するために、翌日および翌々日程度先の日射量予測について大外しの低減と大外しリスクを把握可能な信頼度情報を開発するプロジェクトである。日射量の系統誤差低減のために深層学習を用いている。

本稿では、上記のNEDOの研究開発において、深層学習を活用した予測精度向上に関する部分を中心に解説する。




図1 電力会社における日射量（発電出力）予測時間と用途の例。

*一般財団法人日本気象協会

(〒170-6055 東京都豊島区東池袋3-1-1 サンシャイン60 55階)

e-mail: sasakijun@jwa.or.jp

2. 深層学習と日射量推定

日射量は通常、日射計によって観測されるが、観測器の設置やメンテナンスにかかる費用や手間から、任意の地点に日射計を設置することは現実的ではない。そのため、日射計の代わりに日射量の推定情報が求められる。前述した発電量の実況監視や過去事例の分析といった用途を踏まえると、即時性が高く、かつ高精度な推定データが必要とされる。

従来、気象衛星ひまわり 8 号の観測データを用いた統計モデルによって日射量の推定が行われてきた¹⁾。しかし、これらの標準的なモデルは、可視画像や一部の赤外画像など少ないバンド情報のみを活用した簡易的なモデルである。

実際には、日射量と衛星画像との関係は雲の多様性を介して非常に複雑であり、ひまわり 8 号の多バンド観測情報を有効に活用し、この複雑な関係性を表現できれば、より高精度な推定が可能と考えられる。このためには、深層学習によるモデリングが適している。深層学習を用いれば、観測データに適合した形で複雑な関係性を表現できる上に、高速な推論計算が可能であるため、即時性の確保も可能となる。

筆者らは、深層学習と多バンドの衛星画像を活用し、高精度かつ任意の地点に適用可能な日射量推定モデルを開発した。モデル構築の際には、物理学や気象学の知見に基づく制約を組み込むことで、地上観測値への過剰適合を回避し、汎化性能を高めている。

2.1 推定手法

開発モデルは、ニューラルネットワークをベースとしたアーキテクチャにひまわり 8 号による 16 バンドの観測データを入力し、日射量の地上観測値を真値として学習を行うことで最適化される。しかし、快晴や薄曇りの条件下では、衛星観測値に対する地表面からの反射や放出の寄与が大きく、地表面状態（都市部、森林、海、積雪など）の多様性に比べて、地上観測点は限られているため、モデルが観測地点の特性に過剰適合しやすい問題がある。そこで、放射伝達モデルと快晴確率を導入して、未知地点に対する汎化性を向上させた。

開発モデルは次の 3 つのサブモデルから構成される。

- (1) 快晴時日射量推定モデル
- (2) 全天候型日射量推定モデル
- (3) 快晴確率推定モデル

サブモデル (1) は、太陽位置と水蒸気量の平年値から快晴時日射量を計算するモデルであり、衛星観測には依存しない。サブモデル (2) は、衛星観測データから雲の光学的厚さを推定し、快晴時日射量からの減衰率として日射量の推定値を算出するものである。サブモデル (3) は、対象地点の天候を判別する深層学習ベースのモデルで、地表面の影響を軽減するために利用される。本稿では、主にサブモデル (2) について解説する。他のサブモデルについては文献 2) を参照されたい。

サブモデル (2) は、16 バンドの衛星画像から全天候型日射量を計算するモデルである。モデリングにあたって、まずは放射伝達モデルを定式化した。雲、大気および地表面から成る多層大気系に対して、快晴時日射に相当するフラックス I_{clearsky} が入射した場合、雲と地表面による多重反射を考慮すると、放射伝達の関係式が次のように表される。

$$I_{\text{allsky}} = \frac{T_c}{1 - R_s R_c} I_{\text{clearsky}} \quad (1)$$

$$I_{\text{up}} = \left(R_c + \frac{T_c^2 R_s}{1 - R_s R_c} \right) I_{\text{clearsky}} \quad (2)$$

ここで I_{allsky} は地上における下向き短波放射で全天候型日射量に相当し、 I_{up} は大気上端における上向き短波放射、 T_c 、 R_c はそれぞれ雲の透過率と反射率、 R_s は地表面アルベドを表す。 I_{clearsky} はサブモデル (1) による推定値、 R_s は直近の晴天時の可視バンド画像から推定した値を用いた。

透過率 T_c と反射率 R_c は多バンドの衛星画像を入力データとしたニューラルネットワークにより算出される。アーキテクチャは、CNN (Convolutional Neural Network) と MLP (Multi-Layer Perceptron) から構成されており、入力データは対象地点を中心とした約 20km の矩形領域における多バンドの衛星画像としている (図 2)。CNN は雲分布の空間構造に関わる特徴を抽出し、散乱日射の表現性向上に寄与する。MLP は CNN による特徴量を雲特性の物理変数 (T_c 、 R_c) に変換する役割を担う。算出した透過率 T_c と反射率 R_c は (1) 式と (2) 式を介して上向き・下向き短波放射に変換される。ここで、 I_{allsky} は地上観測値 $I_s^{(\text{obs})}$ に対応する。一方で、 I_{up} は衛星で観測される短波放射を波長領域で積分したものに相当する。これらの事実を利用して I_{allsky} および I_{up} を最適化すれば、 I_{allsky} が地上観測値へ適合すると同時に、上向き短波放射が衛星観測と矛盾しないように全体のエネルギーバランスが保たれ、観測地点への過剰




図2 日射量推定サブモデル (2) のアーキテクチャ。




図3 北海道長沼地点における2018年3月7日の事例。ひまわり8号による可視画像(左)と日射量時系列(右)。可視画像中の矢印は長沼地点を指す。時系列の点線は観測値、黒線は開発モデルによる推定値、灰色線は開発モデルからエネルギーバランスの損失を除外した場合の推定値を表す。




図4 日射量時系列のモデル間比較。左はつくばにおける2018年8月15日の時系列、右は岐阜における2018年10月11日の時系列を表す。

適合が抑制される。実際、エネルギーに関する制約を外して最適化すると、積雪の上空に薄雲がかかっているような複雑な条件下で異常値が出力される場合がある(図3)。

2.2 推定モデルの精度検証結果

深層学習と多バンドデータ活用の有効性を示すために、薄曇りと層雲の2つの事例を取り上げる。

まず、薄曇りの事例として、つくばにおける2018年8月15日の例を挙げる。この日、つくば周辺には薄雲が存在しており、日射量の観測値は低下している。しかし、標準モデルでは10:00付近において日射量が過大に推定されている(図4左)。これは、可視バンドでは薄曇りの条件下で地表面からの反射が強く観測され、その結果、雲の厚さが過小評価されたためと考えられる。一方で、開発モデルは薄雲による日射量の低減を正確に捉えており、良好な推定結果を示していることが分かる。

この事例において、開発モデルで可視バンドのみを使用した場合、標準モデルと同様に日射量の過大推定が発生した。開発モデルでは、近赤外バンドと赤外バンドのデータを組み合わせることで、上層雲を構成する氷粒子の屈折率や鉛直構造に関する情報が抽出され、雲の厚さを正確に推定することが可能となり、推定精度の向上につながったと推察される。このように多バンドの観測データは雲の特性と複雑に関係しており、深層学習を用いたモデリングにより関係性を正確に表現することができる。

次に、層雲の事例として、2018年10月11日における岐阜の例を挙げる。図4右に示された通り、この日の午前中、岐阜周辺には層雲が発生しており、雲の厚さが場所ごとに細かく異なるために日射量が激しく変動している。標準モデルと比較すると、開発モデルの推定値は、この変動を正確に捉えていることが分かる。開発モデルは、CNNにより作成された対象地点周辺の雲分布に関連する特徴量を説明変数としており、層雲の細かい空間構造に由来する散乱日射が表現されたことで、推定精度が向上したと推察される。

開発モデルの性能を標準モデルと定量的に比較するために、2018年を対象にRMSE(二乗平均平方根誤差)を算出した。地上観測値には1分平均値、推定日射量には各時刻の衛星観測データから推定した瞬間値を用いた。なお、精度検証には学習に利用していない5地点(長沼、鳥栖、つくば、岐阜、沖永良部)を選定している³⁾。図5は地点別のRMSEである。開発モデルは標準モデルに比べて全地点で改善傾向があり、特に沖永良部を除けば10%以上の改善効果が確認された。

以上の結果から、開発モデルが標準モデルを上回る性能を有することが確認された。主な改善要因として、深層学習を利用したことにより、多バンド観測データの情報を有効活用できたこと、CNNを活用して雲の空間構造を考慮したこと、放射伝達モデルと快晴確率の導入により、積雪など多様な地表面

状態に対して汎化性能を向上させた点が挙げられる。

3. 深層学習と日射量短時間予測

短時間予測においては、需給調整を迅速に行うために、モデルの初期値に最新の衛星観測データを取り込んで計算することが肝要である。しかし、通常の数値予報モデル（NWP）では、衛星データを取り込む同化プロセスの計算コストが高いために、モデルの更新頻度が低下し、結果として最新の観測を反映した予測が困難となる。一方、衛星画像を初期値として利用する移動予測手法⁴⁾では、最新観測データの反映が可能であるものの、風速の変化や雲の生成・消滅といった複雑な物理過程を考慮することが難しい。

そこで筆者らは、深層学習と物理方程式を組み合わせ、初期値に衛星観測データを取り込んだ新しい気象モデルを開発し、日射量の予測精度向上を実現

した。本モデルは以下の3つの機能から構成される。

- (1) 衛星画像を利用した初期値作成
- (2) 大気力学による雲の移流予測
- (3) 雲物理過程による雲の生成・消滅予測

全体のアーキテクチャは図6に示される通りである。

3.1 衛星画像を利用した初期値作成

初期値は、ひまわり8号から得られたデータを基に作成される。まず、以下の式により曇天指数を定義し、モデルの入力、および出力変数として利用する。

$$\text{曇天指数} = 1 - \frac{\text{日射量}}{\text{快晴時日射量}}$$

曇天指数は、快晴時日射量の雲による減衰度を示し、雲の厚さに対応する変数である。ここで、日射量と快晴時日射量は前節のモデルによる推定値を用いる。

通常、衛星観測データは二次元の空間情報であるが、実際には雲は三次元に分布している。一方で衛星観測から得られる赤外画像には雲の高さに関する情報が含まれており、赤外線強度に基づいて曇天指数を鉛直方向に分離することができる。本モデルでは、深層学習技術を用いた semantic segmentation⁵⁾により、曇天指数を4つの鉛直層に分離した。

1時間程度の非常に短い時間スケールでは、雲の変化は主に移流によって引き起こされ、これは風速と気圧に依存する。そのため、各鉛直層の風速と気圧の空間分布は、曇天指数分布の時間変化から逆推定することができる。本モデルでは vision transformer⁶⁾を用いて、直近1時間の曇天指数分布から初期場の風速と気圧を推定した。

こうして算出された鉛直層毎の曇天指数、気圧、風速を初期値として、以降に示す方法で各変数の時間発展を計算する。




図5 日射量推定精度のモデル間比較。2018年を対象とした5地点のRMSE。

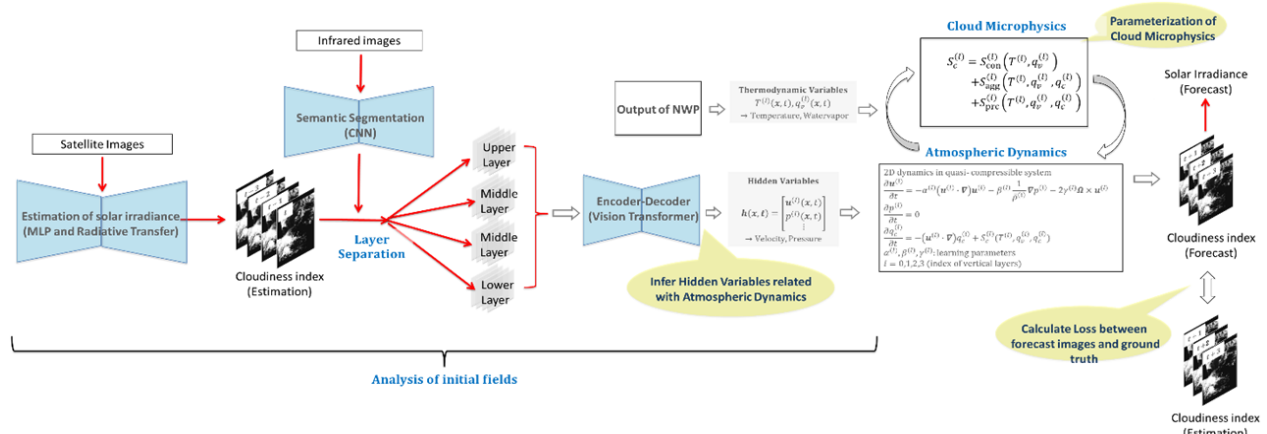


図6 短時間予測モデルのアーキテクチャ。

3.2 大気力学による雲の移流予測

雲の時間変化は、主に移流と生成・消滅により説明できる。本節では移流に関する時間発展計算の方法を解説する。

雲の移流を記述するため、大気力学の方程式を導入した。ここでは、準圧縮近似を適用し、簡略化のため鉛直運動と気圧の時間変化は無視している。支配方程式は次の通りである。

$$\begin{aligned}\frac{\partial \mathbf{u}}{\partial t} &= -\alpha(\mathbf{u} \cdot \nabla) \mathbf{u} - \beta \nabla p' - \gamma \boldsymbol{\Omega} \times \mathbf{u} \\ \frac{\partial p'}{\partial t} &= 0 \\ \frac{\partial q_c}{\partial t} &= -(\mathbf{u} \cdot \nabla) q_c + S_c(T, q_v)\end{aligned}$$

これらの方程式において、 $\mathbf{u}$, p' , q_c , q_v , T , S_c , $\boldsymbol{\Omega}$ はそれぞれ、風速、気圧、雲水量、水蒸気量、気温、雲生成率、コリオリパラメータを表す。また、 α , β , γ は地形や緯度の影響を考慮した補正係数であり、学習によって最適化される。理想的には、対流雲の生成といった現象を正確に記述するためには鉛直運動を考慮すべきであるが、ここでは雲生成率を推定する際に高解像度数値予報モデル（HRES-NWP）の予測気温と水蒸気量を使用することで、間接的に鉛直運動を考慮している。

3.3 雲物理過程による雲の生成・消滅予測

雲の生成・消滅を表す生成率 S_c を計算するために雲物理過程を定式化する必要があるが、そのプロセスは非常に複雑である。ここでは、簡単のために、雲物理過程を3つのサブモデルとして定式化した。アーキテクチャを図7に示す。

最初のサブモデルは凝縮に関するものである。低気圧や地形性対流によって湿った空気塊が上昇すると、凝縮によって雲が形成される。凝縮過程による生成率 S_c は、気温、水蒸気量、および地形因子をMLPに入力することで計算される。ここで地形因子は、地形画像の畳み込みを通じて生成された特徴マップとして定義している。




図7 雲物理過程のモデリング。凝縮過程（左）、凝集・粒成長・蒸発過程（中）、降水過程（右）のアーキテクチャと入力データ。

第2のサブモデルは凝集過程などを表現するものである。雲粒子は衝突して凝集し、雲の成長が促進される。この凝集効果は、狭い受容野を持つCNNを通じて計算グリッドの畳み込みとして表現される。気温、水蒸気量、および雲水量が入力として使用され、凝集過程による生成率 S_c が計算される。ここで、入力する雲水量は、曇天指数の線形変換を通じて推定した。このモデルは、凝集過程と同時に水蒸気吸着による雲粒子の成長や蒸発プロセスも表現することができる。

最後のサブモデルは降水に関するものである。このモデルのアーキテクチャは、凝集過程と同様であるが、出力は降水強度に対応しており、レーダー観測から作成された降水量解析値に対して最適化される。これにより、降水の表現が強化され、雲の過剰な成長が抑制される。最終的に、これらのサブモデルの出力を累積して全体の雲生成率を計算する。

3.4 短時間予測モデルによる精度検証結果

開発モデルの予測精度を検証するために、6時間先までの予測計算を行い、HRES-NWP および Conv-LSTM と比較を行った。ここで、Conv-LSTM は深層学習による標準的な動画予測手法である⁷⁾。各モデルのRMSE および ME（平均誤差）を予測時間ごとに示した結果が図8に示されている。

RMSE に着目すると、本モデルは全ての予測時間において HRES-NWP を上回り、特に予測時間の短い領域で顕著な差異が確認された。これは、




図8 6時間先までの予測精度のモデル間比較。左図は予測時間ごとのRMSE、右図はME。

NWP の初期値の精度が低いためであると考えられる。実際、特定のイベントにおける曇天指数の時間変化を観察すると、HRES-NWP は初期場の精度が低く、その後の予測に悪影響を及ぼしていることが分かる（図 9）。

Conv-LSTM との比較においても、RMSE に関して開発モデルは 2 ～ 3 時間以降の予測時間帯で優れた性能を示した。また、Conv-LSTM では ME に著しい低下が見られる。特定のイベントに着目すると、Conv-LSTM は雲の生成および消滅を正確に再現できないことが分かる（図 9）。さらに、Conv-LSTM では移流の表現が不十分である、降水時に雲の厚さを過大評価するなど、予測誤差の大きい事象が観察された。これらの結果は、雲の多様な変化を表現できるほど十分な学習データが存在しないことを示唆している。その結果、Conv-LSTM は事例間の平均的なばやけた分布を出力し、ME の顕著な低下を招いたと推察される。

一方、開発モデルは、衛星画像から作成した初期値の正確さから、予測時間の短い領域において高い精度を示している。さらに、雲の移流や生成・消滅を表現しており（図 9）、長い予測時間においても良好な予測精度を示している。これは、大気力学の物理方程式と深層学習によりモデル化した雲物理過程が適切に結合して、モデル全体として現実に即した挙動を学習できたことを示している。さらに、初期値の鉛直層分離や物理方程式の導入、雲物理過程の decoupling により、物理法則に基づいてモデルの自由度を抑え、少ない学習データで多様な雲の時間変化を表現できたことも寄与したと考えられる。これは、ME が Conv-LSTM ほど大きく低下しなかったことから裏付けられる。




図 9 2018 年 4 月 5 日 9:00 を初期時刻とする曇天指数の予測分布。白い領域は厚い雲に対応する。右側のカラーマップは、本事例における開発モデルによる雲の生成率と消滅率の分布。

4. 深層学習と日射量翌日予測

翌日予測や長期予測においては、様々な物理過程が相互に影響し合うため、その予測は非常に複雑である。NWP は、これらの物理過程をある程度正確に表現することができるが、計算コストが高く、空間解像度に限界がある。解像度が低い場合、地形の表現も粗くなり、地形性の対流によって発生する雲の生成など、特定の現象を十分に表現できないことがある。

電力会社が前日に需給計画を策定する際、日射量予測が大きく外れることは問題となるため、NWP で表現できない現象が存在することは大きな課題である。これを解消するため、NWP の出力結果を統計的に補正する手法がとられることがある。

筆者らは、深層学習を用いて、NWP の予測値を入力データとし、2 章で述べた日射量推定値を教師データとして、NWP の予測値を補正する手法を開発中である。NWP が全球モデルである場合、空間解像度は 25km 程度であるが、日射量推定値は 1km 程度の解像度を持つため、深層学習による補正を施すことにより、物理に基づいた NWP の基本的な振る舞いを維持しつつ、細かい地形性の雲の挙動を表現することが可能となる。また、細かい現象を表現するだけでなく、NWP が持つ系統的な誤差を補正することも可能であり、予測精度の向上が期待される。

従来、このような処理は気象モデルの力学的ダウンスケーリングによって実施されていたが、深層学習を用いた統計的アプローチを採用することで、計算コストを低減することができる。

4.1 補正手法

ここでは、NWP として全球モデルを取り扱い、その系統誤差改善と高解像度化を行うために U-net 層⁸⁾と逆畳み込み層を設けた深層学習モデルを使用する。図 10 にアーキテクチャを示す。




図 10 補正モデルのアーキテクチャ。

U-net は、NWP による予測値の空間分布から予測の系統誤差を補正する機能、および後続の高解像度化に必要な特徴量を抽出する機能を持つ。出力層付近の逆畳み込み層により、潜在変数を地理空間へデコードして、高解像度な日射量分布を出力している。

4.2 精度検証結果

全球モデルによる 1 日先の予測値を本モデルにより補正し、補正前後の精度比較を行った。日射量推定値を真値として RMSE を算出した結果を図 11 に示す。補正後は、対象地点の全てにおいて予測精度が改善されたことが分かる。

特定の事例について、補正前後の日射量分布を比較すると図 12 のようになる。この事例は、夏季の北海道において北部や日高山脈を中心に対流雲が発生したものである。補正後の分布から地形に沿った雲の発達が正確に表現されたことが分かる。

このように元の NWP で表現できない事象を補正処理により表現することができる。この補正は、日射量の広域分布から得られる特徴量を基に行われるものと推察され、U-net の畳み込みによる特徴量抽出が有効に機能したことを示唆している。




図 11 翌日予測の RMSE. 補正前 (NWP) と補正後 (開発中のモデル) の予測誤差の比較。




図 12 北海道地方、2021 年 8 月 5 日 11:00 における日射量分布。NWP による予測分布 (左)、開発中のモデルによる補正分布 (中)、真値に相当する日射量推定分布 (右)。

5. おわりに

日射量の推定や予測には、雲の複雑な特性や時間変動が直接的に影響する。このため、複雑な関係性を定式化できる深層学習技術を導入する効果は大きく、特に推定・予測精度が電力需給の安定化や社会コストの低減に直結することを考えると、深層学習を用いた精度向上は非常に重要である。さらに、深層学習を用いたモデルは高速な推論計算が可能であり、実運用時の計算コストが抑えられる点も大きなメリットである。また、リアルタイムでの予測や即時対応が必要な場面でも、その高速な推論が大きな強みとなりうる。

しかし、画像認識や自然言語分野で開発された既存の深層学習モデルをそのまま日射量予測へ適用するだけでは、実用上の課題が残る。雲の時間変化は多様であり、学習データが相対的に少ないため、モデルが過剰適合しやすく、汎化性能に限界が生じるためである。この問題に対処するために、物理や気象学的知見を事前にモデルに組み込み、モデルの自由度を抑制することで、汎化性能を確保する必要がある。

筆者らは、このような課題を克服するために、日射量推定では放射伝達理論の導入、短時間予測では気象モデルの枠組みの活用、翌日予測では数値予報モデルの出力結果の利用といった工夫を施すことで予測精度の向上を実現した。

今後は、これらの技術の進展により、日射量の予測精度が一層向上し、電力ネットワークの安定性向上や再生可能エネルギーの効率的な利用に寄与することが期待される。

謝辞

本稿の内容は、NEDO 委託業務「太陽光発電主力電源化推進技術開発／先進的共通基盤技術開発／翌日および翌々日程度先の日射量予測技術の開発」および「太陽光発電主力電源化推進技術開発／先進的共通基盤技術開発／発電量の短期予測に向けた日射量予測技術の開発 (日射量の短期予測に関する研究開発)」の一部として実施された研究成果に基づいている。関係機関各位に深く感謝する。

参考文献

- 1) 齋藤哲彦, 佐々木寛介, 板垣昭彦, 宇都宮健志, 山口浩司, ひまわり 8 号データを用いた衛星推定日射量における雲・積雪判別の初期検討, 電気学会論文誌 B (電力・エネルギー部門誌), **138** (6), 460–465 (2018).
- 2) 宇都宮健志, 佐々木潤, 岡田牧, 吉川茂幸, 山口浩司, ひまわり 8 号データと AI 手法による日射量推定モデルの開発, 令和 4 年度 日本太陽エネルギー学会研究発表会 講演論文集, 2022
- 3) NEDO 成果報告書, 太陽光発電システムの高精度発電量評価技術の開発「日射量データベースの高度化に関する研究」, 2020
- 4) 橋本篤, 宇佐美章, 小林広武, ひまわり 8 号を用いた日射量推定・予測システムの開発 – 九州エリアにおける 1 年間の精度評価 –, 電力中央研究所報告, **N18003**, 1–22 (2019).
- 5) N. Akimoto, H. Zhu, Y. Jin, Y. Aoki, (2020). Fast soft color segmentation. Proc. IEEE/CVF conference on computer vision and pattern recognition (June. 2020), 8277–8286, Seattle, USA.
- 6) Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., and Houlsby, N. : An image is worth 16x16 words : Transformers for image recognition at scale., In International Conference on Learning Representations, 2021.
- 7) Xingjian Shi, Zhourong Chen, Hao Wang, Dit-Yan Yeung, Wai-kin Wong and Wang-chun Woo Convolutional LSTM Network : A Machine Learning Approach for Precipitation Nowcasting. In Advances in neural information processing systems, pages 802–810, 2015.
- 8) Olaf Ronneberger, Philipp Fischer, and Thomas Brox : U-Net : Convolutional Networks for Biomedical Image Segmentation , In Proceedings of 18th International Conference on Medical Image Computing and Computer-Assisted Intervention., 2015.

著者略歴



佐々木 潤 (ササキ ジュン)
2013 年 (一財) 日本気象協会入社.
事業本部 環境エネルギー事業部エ
ネルギー事業課所属. 主に太陽光・風力
発電などの予測技術開発に従事.