

全天球カメラ画像と動画予測機械学習モデルを組み合わせた太陽光発電量予測

Deep learning-based video prediction of solar power generation by utilizing all-sky camera

今井正堯^{*1}・神山 徹^{*2}

1. はじめに

近年、気候変動リスクに対する警戒や太陽光パネルのコスト低下などから持続可能な発電方式として太陽光発電（PV）に対する期待が高まっている。国際エネルギー機関（IEA）の Annual report によると、世界の太陽光発電量は2019年末時点で電力需要の3%（627 GW）を超え、新型コロナウイルス感染症影響下の2020年も順当に導入量は増えている。

電力には「発電即消費」という特性があり、電力需要と供給量のバランスが崩れると安定した周波数維持が難しくなる。気象条件によって発電量が大きく左右されてしまうPV発電などの再生可能エネルギーは、その供給量が増えるに従ってより正確な予測が求められる¹⁾。国内では、九州電力管内において再生エネルギーの連系量が急速に増えていることから、九州全体の発電量が消費量を上回らないよう発電量を制御（出力制御）する事案も発生している。良質な電力供給を維持しつつ、火力発電などで消費される化石燃料資源の効率的な利用を実現するには、再生可能エネルギー供給量の予測精度と誤差推定の向上が重要な課題である。

PV発電の出力推定については現状、気象庁などが発表する日射量の数値予測に基づいて算出されている。しかし、1日の間に天候や雲量が大きく変化する場合には、出力推定が実績と大きく乖離してしまう。言い換えると、日々・季節ごとの“平均的な”出力推定は一定の成功を収めている一方で、ローカルな天候の変化に強く影響されるより短期の予測には改善の余地がある。極端なケースでは、一部曇りのような天候ではPV出力が数分でゼロ付近まで落ちることもあり、現在の天候での数分先の出力予測精度は、Root Mean Square Error（RMSE）で200-

400 Wm⁻²と言われている²⁻⁴⁾。

こうした問題に対処する方策のひとつとしてPV発電サイト現地で取得された気象データなどの活用がある⁵⁾。特に、近年のコンピュータ演算能力の向上によってデータ駆動型のモダン統計解析手法として機械学習（深層学習）を活用した太陽光発電量予測研究が加速している。現地の気象観測や予測データと発電量（日射量）の履歴を学習することで短期予測の改善が期待される。本研究では、PV出力の短期変動に最もクリティカルな全天の雲量や雲分布の情報に富んだ全天カメラ画像を活用し、深層学習モデルに学習させることで短期予測精度の向上を模索する。特に、従来の機械学習モデルでは、短期変動の予測にどの程度雲の分布と移動の情報が学習されているか不透明な部分がある。そこで我々は、新しく動画予測の分野で使われる機械学習モデルも活用することで、雲の移動や雲量の時間発展の再現がどこまで可能であるかを調査し、今後のモデル開発の方向性を検討する。

2. 簡易太陽照度予測モデル実験

我々はまず、機械学習モデルによる画像学習で最も一般的なConvolutional neural networks（CNN）によって、全天カメラ画像からPV出力予測を行う簡易実験を試みた。CNNを用いた同種の研究は多数存在するが、例えば、前報⁶⁾では、スタンフォード大学の学内に設置された全天カメラ画像とPV出力の相関付ける（“now-cast”）ために最適なネットワークパラメータが調査されている。本研究では、前報⁶⁾同様の時間方向に複数枚の画像を畳み込む3D-Convを使用したテストモデルを構築した（図1）。

*1 京都産業大学 理学部 日本学術振興会 特別研究員（PD）

*2 産業技術総合研究所 人工知能研究センター 主任研究員

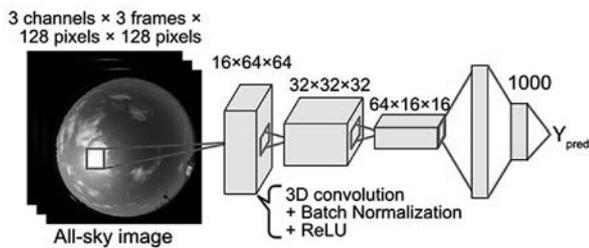


図1 簡易 3D-Conv モデルのネットワーク構造

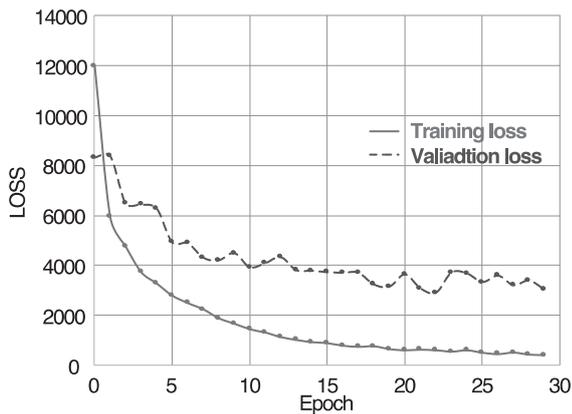


図2 学習過程における Loss の推移

PV パネルの設置サイト上空をモニターした画像データは意外と少ないため、今回は学習データに北海道大学附属天文台に設置された全天監視カメラ画像と、気象記録モジュールで取得された太陽照度を用いた。実験に用いる全天画像は、Nikon D3100 カメラと $f = 4.5\text{mm}$, $F2.8$ の魚眼レンズによって昼間 (6-18 時) に取得されたもので、カメラの撮像設定 (露出時間, F 値と ISO) 昼間時間は全天の雲がサチュレーションせず映るよう自動調整されている。2672 × 2672 ピクセルのトリミング済みオリジナル jpeg 画像を計算コスト軽減のため 128 × 128 にダウンサイジングし、連続する 3 frame 分の画像を入力として扱う。太陽照度は、全天画像の取得と同時刻のデータを抽出し、撮像インターバルと同じ 1 分値として整理したものを用いる。今回の実験では、欠測のなくデータが揃っていた 2013 年 8 月の 1 ヶ月間を解析期間として選択し、うち Validation 用の 3 日を除く 28 日分のデータを学習とした。図 2 に学習過程における Loss 推移を示す。今回のケースでは、Validation データに対する Loss がほぼ横ばいとなった 29 Epoch で学習を終えている。

まず、1 分先 (“now-cast”) の予測の結果について、日中快晴が続いた 8/3 と絶えず間なくパッチ状の雲が流れていて一部曇りの天候が続いた 8/7 で比較する (図 3)。

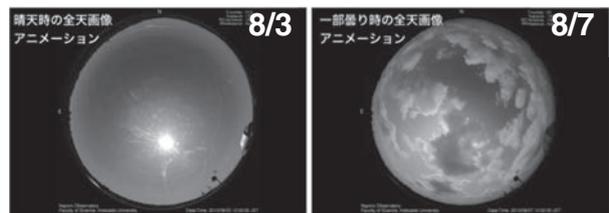


図3 全天カメラ画像サンプル (左) 快晴, (右) 一部曇

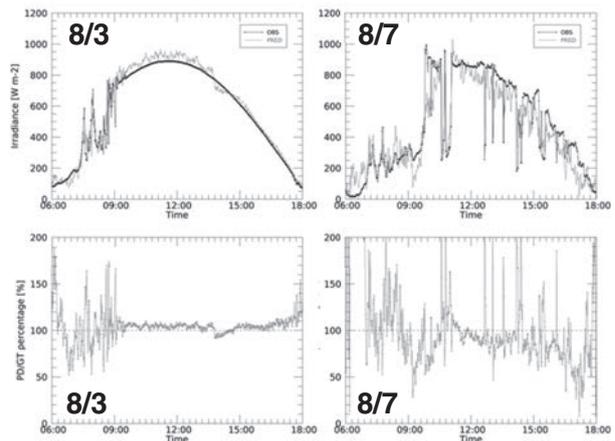


図4 太陽照度予測結果の一例 (上図)。黒線が実際の測定量, 灰色線が予測量を表す。下図は予測の相対誤差。

8/3 は日中の照度が太陽高度でおおよそ決まり、一方の 8/7 は絶えず大小さまざまなスケールの雲が太陽を覆うことで照度がスパイク状に低下していた。図 4 に実際の照度の時間変化と予測モデルによる推定結果を示す。一見すると両日も全体の傾向をモデルはよく再現しているように見えるが、RMSE で見ると 8/3 (快晴) が平均して $\sim 50 \text{ W m}^{-2}$ に対して、8/7 (一部曇) は $\sim 140 \text{ W m}^{-2}$ と 3 倍程度大きくなっていった。特に、8/7 は瞬間的に 50% 以上の予測誤差が発生するだけでなく、9:00 過ぎや 12:00 頃に予測の実測に対する大小関係が変わるなど 10 分から 1 時間スケールの傾向についても再現性が悪いことが分かる。次に、同様の実験を予測ステップ数を 1-10 frame (分) の間で変化させながら予測誤差の変化を調査した。結果、予測ステップ数を増加させた場合、RMSE は単調増加し、曇りのケースでは 10 分先では 2 倍以上と顕著に予測精度が悪化することが分かった。

以上の簡易実験の結果から、3D-Conv モデルを用いた場合の画像と太陽照度の相関には先行研究同様 1 日平均で $> 200 \text{ W m}^{-2}$ の誤差があり、全天で雲の移動や雲量・分布の時間発展と太陽位置との関係を効果的に学習できているとは考えにくい結果が得られた。実際、興味深いことに前報⁶⁾の研究ではイメー

サイズによる予測誤差についての調査にて、64 × 64 pixel 付近から画像サイズを大きくすることによる恩恵が見られないという結果が出ている。つまり、一部曇や急に雲量が増えるような天候の変化を捉えて日射量の短期予測のために短期予測の精度を向上するには抜本的なネットワーク構造を見直す必要があると考えられる。

3. 動画予測モデルによる全天雲分布再現

3D-Conv モデルでは太陽とその周囲に位置する雲分布など空間周波数の高い構造が効果的に学習されず、より低周波数の情報に基づいて太陽照度が予測されている可能性がある（例えば太陽と空のコントラスト差など）。そこで、動画予測の機械学習分野で最先端のモデルを導入し、太陽と全天に写る雲位置の時間変化の再現をタスクとする機械学習モデルの構築し、雲分布の可視化を試みた。今回は、最先端の動画予測モデルのひとつである Eidetic 3D LSTM (E3D-LSTM)⁷⁾ のネットワークを利用し、全天カメラ画像の予測再現を行なった。

E3D-LSTM は、複数枚の入力画像から時間発展する特徴的な空間構造を抽出し、将来の予測画像を出力する。LSTM (Long Short Term Memory)⁸⁾ とは、Recurrent Neural Network (RNN) の一種で入力ゲート、出力ゲート、および忘却ゲートと呼ば

れる3種類のゲートによってセルへの“記憶”の蓄積をコントロールし、勾配消失問題として知られる長期記憶の劣化を回避することで、時系列データに内在する長・短期のパターン認識を得意とするネットワークである。E3D-LSTM では、この LSTM の構造の内部に空間的特徴を抽出するために 3D-Conv が埋め込まれており、かつ従来1つだった“記憶”セルを複数用意することができるよう工夫されたネットワーク構造となっている。今回の実験では、3D-Conv を 2×5×5 (time×height×width)、E3D-LSTM 層数を 4、時間方向のスライドを 2 としている。また、微細雲構造の再現度を向上するため Loss には正解画像と予測画像の間の平均絶対誤差 (L1 Loss) を使用している。先の実験同様、北海道大学附属天文台で 2013 年 8 月の 1 ヶ月間に取得された 128 × 128 pix の画像 (Training : 27 日分, Test 4 日分) を用い、10 frame (10 分間) の連続画像を入力とし、続く 5 frame を正解画像 (予測対象) として E3D-LSTM による再現実験を行なった。

図 6 に予測が比較的うまくいったケースを示す。今回の実験では計算時間の都合上 100000 epoch まで学習を進めたが、50000 epoch と比較すると雲の微細な模様再現が進んでいる。上記の例では太陽近くのサチュレーション気味の領域を除くと全体の雲分布がおおよそ再現されている。現時点では、予測を 10 frame 先まで伸ばすと、同じ実験設定でも予測画像全体の再現性が悪くなるのが分かっており、予測ステップ数をより大きくするには課題があるが、約 1 ヶ月分の画像を用いた学習でもおおよその全天雲分布とその時間発展が予測されている。

一方で、全天画像の再現が完全に失敗しているケースも見られた。図 7 の 2 例では太陽位置の再現度は高いものの、全天に雲が存在するにも関わらず予測画像では 1 ステップ目でわずかに見られた薄雲が消え快晴となってしまっている。これらの例には

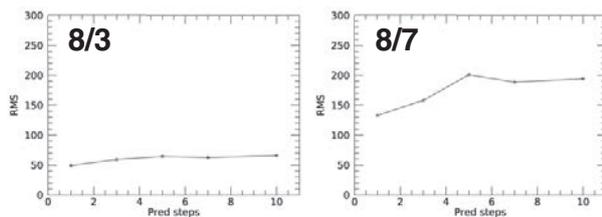


図 5 予測ステップ数による予測誤差の変化。

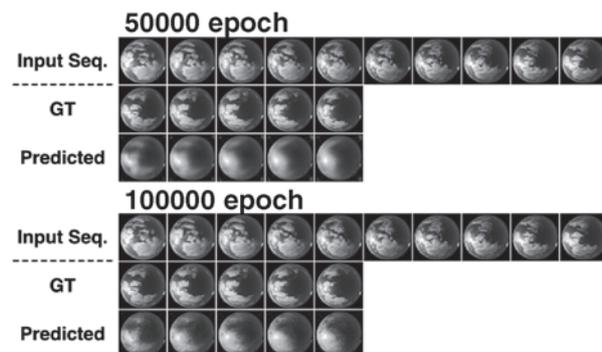


図 6 動画予測モデルによる全天雲分布再現が比較的うまくいったケース。上段から順に入力画像が 10 frame、続く正解画像が 5 frame、予測画像が 5 frame あり、左から右に 1 分毎の画像が並ぶ。

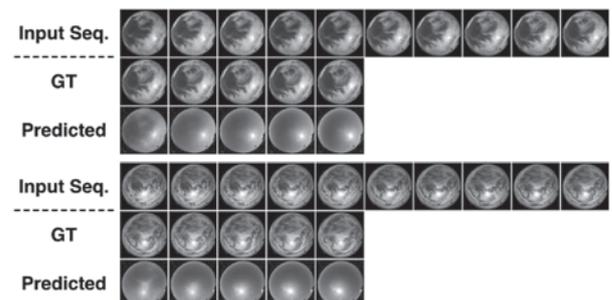


図 7 雲の特徴量を抽出できていないためか全天で快晴と予測されうまくいっていないケース。

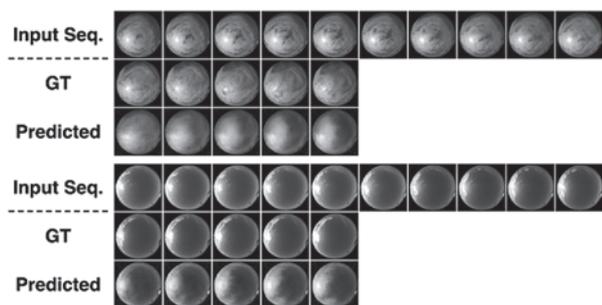


図8 予測画像内に雲の描写があるものの時間発展がうまく再現できていないケース。

共通して、うまくいったケースに比べ雲の輪郭がぼやけており独立した大きいサイズ雲に乏しい特徴がある。

また別のケースとして、図8で示すように全天が継続して曇もしくはほぼ快晴であるにも関わらず、予測画像の1ステップ目で再現された雲分布が時間発展と共に実際から外れていくこともあった。これらについては、学習データ内で類似した雲分布の“記憶”に引っ張られ誤った予測に繋がった可能性があると考えている。

4. まとめと今後

より短期のPV出力予測精度の向上のために、発電サイト上空の雲分布の情報を得ることが可能な全天カメラの画像を活用し、従来研究で広く用いられる3D-Convネットワークによる画像から発電量(日射量)を直接推定する簡易モデル実験を行なった。その結果、画像と太陽照度の相関には“now-cast”の場合でも1日平均で $>200 \text{ Wm}^{-2}$ の誤差が存在し、予測ステップ数を増加させると顕著に誤差が大きくなった。そこで、より未来の予測精度を向上させるために、全天での雲の移動や雲量・分布の時間発展を効果的に学習できるモデルとして動画予測の機械学習モデルであるE3D-LSTMを用いた全天カメラ画像の再現性確認の実験を行なった。Lossの工夫などの結果、全天の雲分布が比較的良好に再現できるケースがあり、このような再現画像を活用することで、短期予測の精度の向上や予測画像から視覚的にも学習モデルの信頼性確認・PV出力変動が推定に繋がる結果を得た。ただし、薄く広がった雲や多数のサイズの小さい雲が広く全天を占める場合には、学習過程で空との区別が失敗し、太陽位置のみを再現した画像を生成してしまうなど現状の全天画像再現には課題が残っている。

今後は、より微細な雲構造を捉え輪郭がぼやけた

雲の特徴が抽出できるようにモデル構造の調整や入力画像の工夫に取り組む。具体的には、E3D-LSTM内に組み込まれた3D-Convのパラメータ調整、全天画像に代わり雲位置の2値化処理後の画像の入力、降雨モニターのデータや太陽照度の時系列曲線から比較的天候条件に近い学習データセットの整理、といった方法を検討している。

また、今回は1ヶ月という限られた学習データでの実験であったため、計算コストとのバランスを取りつつ、より豊富な学習データを用意することで予測精度の改善を試みる。将来的には、全天画像だけでなく気象予測データなどを学習データとして取り込み、PV出力予測の精度向上への貢献を目指す。

参考文献

- 1) 遠藤隆幸, 電力需給運用における数値予報の活用と今後の期待. 日本気象学会機関誌「天気」, 65 (2018), 469.
- 2) A. Sfetsos, A.H. Coonick, Univariate and Multivariate forecasting of hourly solar radiation with artificial intelligence techniques, *Solar Energy*, **68**, 169-178 (2000).
- 3) S. Cao, J. Cao, Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis. *Appl. Therm. Eng.*, **25** (2-3), 161-172 (2005).
- 4) P. Lauret, C. Voyant, T. Soubdhan, M. David, P. Poggi, A benchmarking of machine learning techniques for solar radiation forecasting in an insular context, *Solar Energy*, **112**, 446-457 (2015).
- 5) S.-G. Kim, J.-Y. Jung, and M. K. Sim, A Two-Step Approach to Solar Power Generation Prediction Based on Weather Data Using Machine Learning, *Sustainability*, **11** (5), 1501-1516 (2019).
- 6) Y. Sun, G. Szűcs, A. R. Brandt, Solar PV output prediction from video streams using convolutional neural networks, *Energy & Environmental Science*, **11** (7), 1811-1818 (2018).
- 7) Y. Wang, L. Jiang, M.-H. Yang, L.-J. Li, M. Long, and L. Fei-Fei, Eidetic3D LSTM: A model for video prediction and beyond, *Proc. 2018 ICLR Conf.* (Sep. 2019), New Orleans, Louisiana,

USA.

- 8) S. Hochreiter, J. Schmidhuber, Long Short-Term Memory, *Neural Computation*, **9** (8), 1735–1780 (1997).

著者略歴



今井正亮 (イマイ マサタカ)
京都産業大学 日本学術振興会 特別
研究員 (PD)
2018年3月北海道大学大学院理学院・
宇宙理学専攻博士後期課程修了 (博士
(理学)).
同年6月 産業技術総合研究所入職 人工知能研究セ

ンターにて地球観測衛星の校正研究や太陽光発電量
予測研究に従事.

2021年4月より現職. 現在は金星をはじめとする
惑星気象研究に取り組む.



神山徹 (コウヤマ トオル)
産業技術総合研究所 デジタルアーキ
テクチャ研究センター 主任研究員
2012年3月東京大学大学院理学系研
究科・地球惑星科学専攻 後期課程修
了 (博士 (理学)).
同年4月 産業技術総合研究所入所 地球観測衛星
の校正研究や衛星画像解析への人工知能技術の導入
に関する研究に従事.