

# 太陽光発電のための深層学習を用いた雲の挙動予測に関する研究

## A Study of Cloud Image Prediction using Deep Learning for Photovoltaic

堀田 忠義, 高田 慶太, 清水 洋隆, 秋葉 将和

Tadayoshi Horita, Keita Takada, Hirotaka Shimizu and Masakazu Akiba

### 1. はじめに

地球温暖化問題などへの対策として、再生可能エネルギー発電の導入が世界中で拡大している。わが国では、2018年7月に閣議決定された「第5次エネルギー基本計画」において、再生可能エネルギーの主力電源化が明言された<sup>[1]</sup>。また、同計画では、わが国の再エネの中心である太陽光発電（Photovoltaic：以下 PV）を2030年度までに6400万[kW]導入する目標が掲げられた。これは、2019年3月までの累積導入量4870万[kW]<sup>[2]</sup>と比較すると約3割増となる量であり、今後も活発にPVが導入される見込みである。

PVを含んだシステムの需給制御を行うとき、PVの出力変動を前もって予測できると都合がよい。そこで、PVの発電出力や発電量を予測する研究、また、それに関連して、日射強度や日射量を予測する研究は、電気工学分野では1990年代後半から行われてきた。研究されている代表的な予測手法は、以下の3種類のデータのいずれかを用いている。

- 数値予報（計算機を用いた大気のシミュレーションに基づく気象予報）
- 衛星画像（気象衛星により撮影された雲の画像）
- 天空画像（地上から撮影された雲の画像）

天空画像は基本的に、撮影地点における、長くても数分先までの日射量・日射強度を予測することに向けたデータである。そのため、発電計画に活用する目的では通常、用いられない。同じ理由から、天空画像を用いた研究事例はこれまで少なかったが、最近になり増加してきた。

その理由としてはまず、近年、発電計画や発電機運用方法の改善といった電力供給の制御に関する研究だけでなく、EMSを用いた電力需要の制御に関する研究が進展したことが挙げられる。今までに、需要家側の機器を供給側から制御する手法によりシステムの安定化をシミュレーションした事例<sup>[3][4]</sup>がある。また、高コストな蓄電池ではなく空調用ヒートポンプを、再生可能エネルギー発電の出力変動を平滑化するための可制御負荷として考え、その最適な運用法について検討した事例<sup>[5][6][7]</sup>がある。このような需給制御を行うときには、需要家側の機器や

負荷の制御遅れを考慮する必要がある。例えば参考文献[5]では、空調用ヒートポンプの消費電力応答特性に関して、消費電力が最小の状態から最大の状態まで移行するのに70秒から100秒を要することが指摘されている。そこで、数分先までのPV発電出力や日射強度を予測し、変動が生じる前に制御を開始することが検討されている<sup>[8][9]</sup>。この場合の予測は、発電設備がある一地点について行えばよく、地理的に広い範囲を対象とする必要はない。そこで、これらの条件を満たす予測が可能な天空画像の価値が見直され、研究が活発化している。

第二の理由として、新たな画像認識技術・機械学習技術が登場し、研究に活用できるようになったことが挙げられる。特に、これまで課題とされてきた雲の変形や消滅などの予測に対して、近年飛躍的に進展した技術である深層学習（ディープラーニング）がどの程度有効であるか、注目されている<sup>[10][11][12]</sup>。

このような背景のもと、本研究では天空画像を用いて、雲の挙動を予測する手法を検討した。雲の挙動を予測に関する初期の研究では、天空画像から目視で雲を抽出した上で、雲全体の動きを1つのベクトルで代表させていた<sup>[13]</sup>。その後、目視を必要とせず、画像を複数の小領域に分割して各領域の動きのベクトルを自動的に求める手法が提案された<sup>[14]</sup>。これらの手法では、雲の直線的移動を予測することはできるものの、雲の変形、発生、消滅を予測できない点が課題であった。そこで最近では、雲領域の拡散や縮小など、雲の直線的移動以外の変化も把握するために機械学習が用いられている<sup>[10][11][12]</sup>。参考文献[10][11][12]で提案された手法はいずれも、予測可能な時刻が30秒先の一点のみであり、動きベクトルを算出する従来手法に比べて短い。例えば、参考文献[13]の提案手法では、日射強度が変動するタイミングを2分程度先まで予測可能である。前述の空調用ヒートポンプの消費電力を最小の状態から最大の状態に変化させるケースでは、応答の遅れが最長で100秒発生する<sup>[5]</sup>。この点を考慮すると、機械学習を用いる手法についても、2分程度先を予測できることが必要である。

ここで、本研究の目的および独自性を述べる。雲の挙動を2分程度先まで予測するため、下記の手法を提案し、その有効性を検証することを目的とする。提案手法は、

雲の動きベクトルを求めて直線的移動を検出するとともに、機械学習アルゴリズムである「自己符号化器 (Auto Encoder)」<sup>[15]</sup>を併用することにより雲の変形を加味し、数分先まで天空画像を予測するものである。検証は、動きベクトルのみに基づき雲の位置を動かす従来手法との比較により行う。自己符号化器を用いた未来画像の作成は既に知られた手法である<sup>[16]</sup>。本研究の独自性は、同手法を天空画像の予測に適用した点および動きベクトルを求める手法と組み合わせた点である。

## 2. 雲の挙動予測

### 2.1 データの収集方法

デジタルカメラ [オリンパス社製 TG-5 (撮影解像度 3840×2160 ピクセル)] を用い、東京都小平市にある職業能力開発総合大学校 2 号館 4 階の北向きの窓辺から、天空画像を撮影した。

上記カメラは、設定を行うことにより、5 秒おきに 299 枚の画像を連続して撮影することができる。そこで、この連続撮影を 4 日間 (2018 年 1 月 15 日, 19 日, 24 日, 26 日)、各日に 1 度ずつ行い、計 1,196 枚の天空画像を撮影した。撮影した画像は、グレースケール画像に変換し、400×400 ピクセルに縮小した。ここで、縮小した後の画像を「実験用画像」と呼ぶこととする。また、1 回の連続撮影によって得た 299 枚の実験用画像のセットを「データセット」と呼ぶ。

### 2.2 自己符号化器を用いた予測天空画像の作成方法

本研究で使用する自己符号化器の構成を、図 1 に示す。これは、Zhou らの方法<sup>[16]</sup>を参考にしている。

ここでは、2018 年 1 月 26 日のデータセットについて、220 枚目以降の天空画像を予測作成する方法について述べる。データセットの 219 枚目を時刻 0[s]、すなわち予測開始時刻とする。自己符号化器はこの時点までの 219

層種名称	カーネルサイズ	ストライド	カーネルの個数	出力データサイズ	活性化関数	パラメータ数
input	-	-	-	224×224×1	-	-
conv1	3×3×1	1	16	224×224×16	ReLU	160
pool1	2×2×1	2	1	112×112×16	-	-
conv2	3×3×16	1	8	112×112×8	ReLU	1160
pool2	2×2×1	2	1	56×56×8	-	-
conv3	3×3×8	1	8	56×56×8	ReLU	584
pool3	2×2×1	2	1	28×28×8	-	-
conv4	3×3×8	1	8	28×28×8	ReLU	584
upsampling4	2×2×1	2	1	56×56×8	-	-
conv5	3×3×8	1	8	56×56×8	ReLU	584
upsampling5	2×2×1	2	1	112×112×8	-	-
conv6	3×3×8	1	16	112×112×16	ReLU	1168
upsampling6	2×2×1	2	1	224×224×16	-	-
conv7(output)	3×3×16	1	1	224×224×1	sigmoid	145

図 1 自己符号化器の構成

枚の実験用画像を用いて、5 秒間の雲の変形を学習する。

学習データとして、入力画像と目標出力画像のペアが必要である。本研究では、実験用画像から、大気の流れによって移動したと推定される、同一の小領域を切り出して学習データとする。

ここで、2 枚の画像を比較し、画像に写されたものがどのように移動したかをベクトルの形で求めることを、動きベクトルの推定という。本研究では、Gunnar Farneback 法<sup>[17]</sup>により動きベクトルを推定する。

大気の流れを、次の手順で算出できるものと考え、求めることとする。データセットの 1 枚目から 2 枚目への動きベクトル、2 枚目から 3 枚目への動きベクトル、… というように、219 枚目までの動きベクトルをすべて求めて平均を取る。計算の結果、2018 年 1 月 26 日のデータセットにおいて、1 枚ごとの大気の流れは「右方向に 5 ピクセル、下方向に 5 ピクセル」のベクトルとなった。

本実験では、学習データとなる小領域のサイズを 224×224 ピクセルとする。入力および目標出力の範囲を図 2 のように定めて、これらの領域を切り出す。そして、1 枚目から切り出した領域 (入力) と 2 枚目から切り出した領域 (目標出力)、というように、入力と目標出力のペアを計 218 組作成する。こうした方法を取ることで、小領域内における雲の位置が、入力と目標出力との間で変わらないため、雲の変形の学習に集中することができる。これを以下では「提案手法」と呼ぶ。

小領域のサイズを 224×224 ピクセルとしたのは次の理由による。予測画像の作成は、まず、219 枚目 (時刻 0[s]) の実験用画像の左上の小領域を、学習を終えた自己符号化器に入力することから始まる。すると、時刻 5[s] の予測画像が出力される。予測画像のサイズは 224

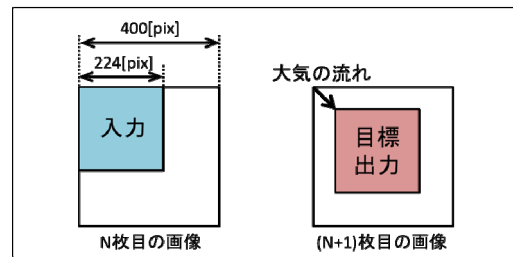


図 2 入力および目標出力の範囲




図 3 実験用画像に占める予測領域の推移

×224 ピクセルである. 自己符号化器は次に, 只今出力された時刻 5[s]の予測画像を入力として, 時刻 10[s]の予測画像を出力する. 予測画像はその後, 時刻 15[s], 20[s], ……というように次々と作成される. ここで, これらの予測画像が, 実験用画像 (400×400 ピクセル) のどこに位置するかを考えると, 図 3 のようになる.

大気の流れは 5 秒間につき右方向および下方向へ 5 ピクセルであるため, 予測した領域が実験用画像の範囲を超えない最長予測時刻は 175[s]となる. これは, 先行研究 (参考文献[4][5][6]) と比較して十分な長さである. 以上の理由から, 小領域のサイズを 224×224 ピクセルとした.

### 2.3 比較対象

#### 2.3.1 手法 1: 算出した大気の流れに基づき入力画像をスライドさせる手法

第一の比較対象は, 自己符号化器による機械学習を用いない方法とした. すなわち, 雲の変形については予測せず, 移動のみを予測する方法である. この方法では, 前節で算出した大気の流れに従って, 入力画像をスライドさせる. すなわち, 図 3 において灰色の位置で示された予測領域が, 時刻 0[s]から 175[s]まで変わらない状態であると考え. これを以下では「手法 1」と呼ぶ.

#### 2.3.2 手法 2: すべてのデータセットを用いて雲の変形の学習を行う方法

第二の比較対象は, すべてのデータセットを用いて雲の変形の学習を行った上で, 予測画像を作成する方法とした. この方法では, 2018 年 1 月 26 日のデータセットだけでなく, 1 月 15 日, 1 月 19 日, 1 月 24 日のデータセットを使用して学習データを作成・追加し, 機械学習を行う.

新たなデータセットについても 1 月 26 日のものと同様, まず, 前節で述べた方法により大気の流れを求める. 次に, 実験用画像から, 大気の流れのベクトル分をずらして小領域を切り出し, 入力画像と目標出力画像のペアを作成する. 新たなデータセットは, すべての画像を学習に用いることとする. すると, それぞれ 298 組の画像の

表 1 実験環境

OS	Ubuntu 16.04 LTS
CPU	Intel® Core2 Quad Processor Q8400
GPU	NVIDIA GeForce GTX 770
GPU メモリ	4 GB
GPGPU プラットフォーム	CUDA 8.0 / cuDNN 6.0
言語	Python 3.5.2
機械学習ライブラリ	TensorFlow 1.3.0 Keras 2.0.8
画像処理ライブラリ	OpenCV 3.3.0

表 2 機械学習条件

損失関数	画素値の平均二乗誤差
最適化手法	AdaDelta
バッチサイズ	10
エポック数	1000

ペアを作成することができる. 結果として, 学習データは 4 日分で計 1,112 組となった. これを以下では「手法 2」と呼ぶ.

### 3. 計算機実験

表 1 に, 計算機実験における環境を示す. また機械学習における条件を, 表 2 に示す.

予測時刻の実際の天空画像と, 作成した予測画像との比較を図 4 に示す. 実際の天空画像を見ると, 時間の経過とともに, 薄い雲が右上に向かって広がっていることが分かる.

提案手法, 手法 1 および 2 により作成した予測画像と, 学習に使用しなかった 1 月 26 日のデータセットの 220 枚目以降の画像とを比較し, 検討を加える. ただし, 本実験で作成した画像は, 大気の流れに従って移動する小領域について予測したものである. そこで, 使用しなかった実験用画像からも, 図 3 と同じ位置の小領域を切り出す. 図 3 にある通り, 時刻 5[s]から 175[s]までの画像を用いるため, 切り出す画像は 35 点となる. この 35 点の小領域の画像を, 予測画像との比較対象とする.

比較については, 画像類似度の比較指標として一般的に用いられる画素値の平均二乗誤差 (以下 MSE) を用いて行う. 天空画像から切り出した小領域に対して, それぞれの手法による予測画像の MSE を計算し, その時間的推移をグラフ化したものを, 図 5 に示す. 一般的に, 2 枚の画像の MSE が大きいほど, 両者の類似度が低いことを意味する.

図 4 および図 5 より, 以下が分かる.

- 手法 2 の MSE は, 時間の経過とともに他の 2 手法のそれよりも増大している. この理由についてであるが, 例えば図 4 の予測画像では, 時刻 60[s]頃から, 左にある雲が大きく, 厚くなり, 右方向へ拡散していく様子が予測されている. しかし実際の画像では, そのような雲の挙動は確認されない.
- つまり, 機械学習によって雲の変形を学習する場合, 日付を問わずに多くのデータを集めて学習を行うよりも, 予測開始時刻直前のデータに限定して学習を行う方が有効である.

手法 1 と提案手法を比較する. 図 5 より, 時刻 135[s]までは, 手法 1 の MSE の方が提案手法のそれよりも小さい. しかし, 時刻 140[s]以降は逆転し, 提案手法の MSE の方が手法 1 のそれよりも小さくなった. この比較結果

時刻 [s]	実際の画像	手法1	提案手法	手法2
5				
30				
60				
90				
120				
150				
175				

図4 各手法による画像と実際の画像

は次のように解釈できる。

- 提案手法では、時間経過に伴う雲の変形度合いを、実際の変形よりも過大に学習したと考えられる。換言すれば、予測開始直後の実際の天空画像には大きな雲の変形が発生していないにもかかわらず、大きく雲が変形すると予測したと考えられる。それゆえ予測開始直後は、手法1による画像の方が、実際の画像に近かった。
- 一方で、実際の天空画像において雲の変形が生じ始める時刻に達すると、手法1による画像の誤差が大きくなり、時刻140[s]において、提案手法による画像の誤差を上回った。

#### 4. まとめ

提案手法では、予測開始から140秒後～175秒後については、直線的移動のみを考慮する手法1よりも良好に、未来の天空画像を予測できた。よって、少なくとも、時




図5 各手法のMSEと予測時刻との関係

刻175[s]までの予測画像を作成できることが示された。175秒先までの予測が可能であれば、PVの出力変動を平滑化するための可制御負荷である空調用ヒートポンプの制御を、十分な余裕を持って完了できる。したがって、提案手法により天空画像を予測することが可能な時間は、十分に長いといえる。

一方で、予測開始から5秒後～135秒後については手法1よりも予測精度が悪い。この区間における予測の正確性を高める方法の1つとして、提案手法と手法1とを併用することが考えられる。すなわち、雲の変形が比較的小さい予測開始直後については手法1を適用し、「ある程度の時間」が経過した後は提案手法を適用するという方法である。その「時間」は、本実験では140秒となったが、他の日のデータを用いた場合には異なる値になる可能性がある。従って、今後の課題として、その手法の切り替えるべき時間についての更なる考察が挙げられる。

Keywords: Deep Learning, Cloud Image Prediction, Photovoltaic

#### 謝辞

本研究の一部で、開発環境として「Google Colaboratory」を利用した。提供元であるGoogle社に謝意を表す。

#### 参考文献

[1] 資源エネルギー庁：「第5次エネルギー基本計画」, [https://www.enecho.meti.go.jp/category/others/basic\\_plan/pdf/180703.pdf](https://www.enecho.meti.go.jp/category/others/basic_plan/pdf/180703.pdf) (2018年7月3日公表)

[2] 資源エネルギー庁：「再生可能エネルギーの主力電源化に向けた制度改革の必要性と課題」, 第1回再生可能エネルギー主力電源化制度改革小委員会資料, [https://www.enecho.meti.go.jp/committee/council/basic\\_policy](https://www.enecho.meti.go.jp/committee/council/basic_policy)

- \_subcommittee/saiene\_shuryoku/001/pdf/001\_007.pdf (2019 年 9 月 19 日公表).
- [3] 千住智信・徳留元樹・與那篤史・舟橋俊久:「小規模系統に分散配置された可制御負荷による系統周波数制御法」, 電気学会論文誌 B, Vol. 129, No.9, pp. 1074-1080 (2009).
- [4] 関崎真也・青木睦・鶴飼裕之・重藤貴也・佐々木俊介:「太陽光発電大量導入時における小容量蓄電池群を用いた配電系統電圧制御手法」, 電気学会論文誌 B, Vol. 133, No. 5, pp. 439-448 (2013).
- [5] 河内駿介・萩原裕人・馬場旬平・古川慧・下田英介・沼田茂生:「空調用ヒートポンプを用いた短周期電力変動補償に関する実機検討」, 電気学会論文誌 B, Vol. 132, No. 1, pp. 77-85 (2012).
- [6] 河内駿介・馬場旬平・古川慧・下田英介:「業務用空調機消費電力制御による短周期電力変動補償のマイクログリッドにおける実証実験」, 電気学会論文誌 B, Vol. 133, No. 4, pp. 358-365 (2013).
- [7] 高橋雅仁・長谷川浩巳・上野剛:「卒 FIT の住宅用太陽光発電の活用方策に関するユースケース分析 ―ヒートポンプ給湯機を用いた PV 自家消費の有用性―」, 電力中央研究所報告 C19001 (2019).
- [8] 與那篤史・内田晃介・千住智信・舟橋俊久:「定期的日射量予測を用いたスマートハウスの運用再計画法」, 電気学会電力系統技術研究会資料, PE-11-17/PSE-11-34/SPC-11-71, pp. 7-12 (2011).
- [9] 皆木朗世・稲葉陽子・中川慶一郎・生田目崇:「日射量予測に基づくマイクログリッド運用モデル」, 経営情報学会 2010 年秋季全国研究発表大会要旨集, B4-1 (2010).
- [10] 長谷智紘・西村晃紀・森山健・前田俊二:「日射量予測のための未来天空画像の生成」, 電子情報通信学会総合大会基礎・境界/NOLTA 講演論文集, A-8-8, p. 73 (2018).
- [11] 長谷智紘・上出敦也・前田龍佑・遠藤操希・藤村優斗・西村晃紀・森山健・前田俊二:「天空画像を対象とした日射量予測における Convolutional Neural Network と Convolutional LSTM Network の比較検討」, 精密工学会秋季大会学術講演会講演論文集, D03-4, pp. 630-631 (2018).
- [12] 藤村優斗・遠藤操希・上出敦也・前田龍佑・長谷智紘・西村晃紀・森山健・前田俊二:「Convolutional LSTM Network を用いた日射量予測のための未来画像生成」, 電気学会知覚情報研究会資料, PI-18-049/IIS-18-030, pp. 1-5(2018).
- [13] 山本茂広・片木威・朴在植・橋本武・橋本岳:「雲の画像解析による太陽光発電の出力変動予測に関する基礎的研究」, 電気学会論文誌 B, Vol. 119, No. 8/9, pp. 909-915 (1999).
- [14] R. Brad, and I. A. Letia: “Cloud motion detection from infrared satellite images”, Proceedings of 2nd International Conference on Image and Graphics (Proceedings of SPIE, Vol.4875), Hefei, China, pp.408-412 (2002).
- [15] G. E. Hinton, and R. R. Salakhutdinov: “Reducing the dimensionality of data with neural networks”, Science, Vol. 313, No. 5786, pp. 504-507 (2006).
- [16] Y. Zhou, and T. L. Berg: “Learning temporal transformations from time-lapse videos”, Proceedings of 14th European Conference on Computer Vision, Amsterdam, The Netherlands, pp. 262-277 (2016)
- [17] G. Farnebäck: “Two-frame motion estimation based on polynomial expansion”, Proceedings of 13th Scandinavian Conference on Image Analysis, Halmstad, Sweden, pp. 363-370 (2003).

(原稿受付 2021/10/27, 受理 2021/11/15)

\*堀田 忠義, 博士 (工学)

職業能力開発総合大学校, 能力開発院, 〒187-0035 東京都小平市小川西町 2-32-1

Tadayoshi Horita, Faculty of Human Resources Development, Polytechnic University of Japan, 2-32-1 Ogawa-Nishi-Machi, Kodaira, Tokyo 187-0035.

Email: horita@uitech.ac.jp

\*高田 慶太, 修士 (生産工学)

三重職業能力開発促進センター, 〒510-0943 三重県四日市市西日野町 4691

Keita Takada, Mie Polytechnic Center, 4691 Nishi-Hino-Cho, Yokkaiti, Mie 510-0943

Email: takada.keita@jeed.or.jp

\*清水 洋隆, 博士 (工学)

職業能力開発総合大学校, 能力開発院, 〒187-0035 東京都小平市小川西町 2-32-1

Hiroataka Shimizu, Faculty of Human Resources Development, Polytechnic University of Japan, 2-32-1 Ogawa-Nishi-Machi, Kodaira, Tokyo 187-0035.

Email: shimizu@uitech.ac.jp

\*秋葉 将和, 博士 (工学)

職業能力開発総合大学校, 能力開発院, 〒187-0035 東京都小平市小川西町 2-32-1

Masakazu Akiba, Faculty of Human Resources Development, Polytechnic University of Japan, 2-32-1 Ogawa-Nishi-Machi, Kodaira, Tokyo 187-0035.

Email: akiba@uitech.ac.jp