

V2Hの普及に向けた 太陽光発電量予測システムの構築

AE16045 高橋諒

指導教員 藤田吾郎

1. はじめに

近年、脱炭素社会に向けた取り組みや災害時の緊急電源として、太陽光発電(Photovoltaic = PV)が大量に導入されている。しかし、PVは気象条件に出力変動が起きるため、周波数変動など電力系統へ悪影響を及ぼすことが予想される。さらに、2019年11月にはFIT(Feed-in Tariff)買取期間が終了し始め、卒FIT電源が続々と出てき始めている。

そこで、PVや電気自動車、蓄電池を組み合わせたエネルギーマネジメントシステムの1つであるV2H(Vehicle to Home)と呼ばれる、電気自動車に蓄えられた電力を家庭内で有効活用する考えが提案されている。その際、安定的なPVの制御を行うため、太陽光発電量の予測システムに注目が集まっている。しかし予測モデルは未だ完全でないため予測値には必ず誤差が伴うという現状がある^[1]。

2. 研究目的

一般的な太陽光発電量の予測では、NN(Neural Network)を用いた日射量予測を基にした予測手法がある。そこで本研究では、上記の手法に代わり、NNの一種であり誤差の低下が期待できるDL(Deep Learning)を用いた、太陽光発電量予測システムを開発することを目的とする。

3. 発電量予測システム

3.1 Neural Network

NNとは、人間の脳神経細胞の繋がりを数理的にモデル化したものである。多次元量のデータで線形分離不可能な問題に対して、小さい計算量で解を得られるという特徴を有する。NNは3つの層から構成され、各ニューロン間の結合強度の重要度を示す「重み」が存在する。重みを最適値へ更新していくことで、正確な出力が行えるようになる。図1にNNの構成を示す。




図1 NNの構成

3.2 Long Short Term Memory

RNN(Recurrent Neural Network)と呼ばれるNNは、長期依存の系列の学習において情報が伝搬されないという欠点がある。この欠点を克服するために、考案されたのがLSTM(Long Short Term Memory)であり、長期的な依存関係を学習できるRNNの一種である。RNNとの違いは、中間層の各ユニットがメモリユニットに置き換えられている点である。これにより、どの程度の入力を取り込むかなどの柔軟性を持つため、より長期のデータを伝搬できる^[2]。

3.3 予測システムの概要

太陽光発電量予測システムは、3.2節で述べたLSTMを用いて構築した。用いるデータセットは、30日間の日射強度と気温の30分間隔データである。本研究では、学習と予測のバランスから20日間のデータを用いて学習を行い、2日間の日射量を予測する。予測は1日ごとにずれていき、その都度予測を行う。LSTMブロックのノード数を $96(=2(\text{日間}) \times 48(1\text{日間のデータ数}))$ とし、構築したネットワークを図2に示す。




図2 本研究でのネットワークの構成

最後に、予測した日射量を用いて、太陽光発電量を算出する。式(1)に、太陽光発電量の算出式を示す。本研究では、システム損失係数を0.85と仮定し、算出を行う。

$$E = K \times H \times P \div 1 \quad (1)$$

E : 太陽光発電量予測値 [kWh]

K : システム損失係数 = 0.85

H : 日射量予測値 [kWh/m²]

P : システム容量 [kW]

1 : 標準状態における日射強度 [kW/m²]

3.4 評価指標

本研究では、予測結果を評価するにあたり、 R^2 (決定係数)、 $RMSE$ (平均平方二乗誤差)、 MAE (平均絶対誤差)を用いた。 R^2 は予測精度を示し、予測値と実測値の相関係数を表す。1に近いほど精度が高い。 $RMSE$ と MAE はどちらも誤差を表し、0に近いほど精度が高いことを示す。しかし、 $RMSE$ は誤差を、平方根の中で二乗しているため、外れ値(他の値から大きく外れた値)により値が大きくなる。式(2)~(4)に、それぞれの算出式を示す。

$$R^2 = 1 - \frac{\sum_i (y_{i,for} - y_{i,act})^2}{\sum_i (y_{i,for} - y_{act,ave})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_i (y_{i,for} - y_{i,act})^2}{n}} \quad (3)$$

$$MAE = \frac{1}{n} \sum_i |y_{i,for} - y_{i,act}| \quad (4)$$

n : データ数, $y_{act,ave}$: 実測発電電力の平均[kW],
 $y_{i,act}$: 実測発電電力[kW], $y_{i,for}$: 予測発電電力[kW]

4. 結果と考察

2015年6月のデータにおいて、20日間を訓練データ、6日間をテストデータとする。今回、対象とする予測日は6/27~6/30とし、計3回2日ごとに、日射量の予測を行った。また、季節専用のデータセットによる予測精度の変化を確認するため、気象庁から天気概況を取得し、梅雨時用のデータセットを用いて同日の予測を行った。図3~5に各日射量の予測結果(左: 通常のデータセット、右: 梅雨時用のデータセット)の比較のグラフを示す。

通常のデータセットでの予測について、図3~5より、6/27,28の予測では R^2 は0.835、6/28,29では0.690、6/29,30においては0.459と、予測を繰り返すごとに精度が低下していることが分かる。図3と図4より、6/28の予測において、1時間程度で実測値が激しく上下する箇所が見られ、予測はその変動に対応できていないことがわかる。これは急な天候の変動によるものだと考えられる。そのため、外れ値が多くなり、 $RMSE$ が MAE よりも大きくなり、予測精度が低下したと考えられる。

梅雨時用のデータセットでの予測について、図3~5の右図より、6/27,28の予測では R^2 は0.913、6/28,29では0.874、6/29,30においては0.950と、安定した予測であるといえる。これらの各評価結果を表1に示す。通常のデータセットにおいて、大きい誤差を生じた6/28,29の予測と比較すると、予測精度が向上したことが分かる。これは、データセットの変化が、実測値の激しい上下に対応するよう働いたためである。




図3 6月27,28日の予測結果




図4 6月28,29日の予測結果




図5 6月29,30日の予測結果

表1 各予測結果に対する評価

	6/27,28		6/28,29		6/29,30	
	通常	梅雨	通常	梅雨	通常	梅雨
R^2	0.835	0.913	0.690	0.874	0.459	0.950
$RMSE$	0.106	0.077	0.175	0.111	0.201	0.061
MAE	0.046	0.040	0.100	0.058	0.114	0.038

5. まとめ

本研究では、LSTMを用いた太陽光発電量予測の構築を提案した。季節や日ごとの特徴を捉えるため、通常のデータセットに加え、梅雨時用のものを用いた予測を行った。その結果、予測精度は向上し、本手法は天候の変化に対し非常に有効な策であることが確認できた。

しかし、天候の変化が起きる期間は年ごとによって異なる。そのため、その期間の学習を行い、対策をする必要があると考えられる。また、オプティマイザーのパラメータは初期値ではなく、適切な値を検討することにより、更なる予測精度向上が見込まれる。

参考文献

- [1] 大竹秀明, 高島工, 大関崇, Joao Gari da Silva Fonseca Jr, 山田芳則 “局地モデルから出力される日射量予測とその予測精度の検証”: 一般社団法人 エネルギー・資源学会, vol.36, No.4 (2015)
- [2] Antonio Gulli, Sujit Pal (訳:大串正矢 ほか) (2018) “直感Deep Learning”: 株式会社オライリージャパン