

風力発電設置箇所における機械学習を用いた風予測 Wind Prediction at Sites for Wind-power Installation using Machine Learning

佐藤 江里子[†]
Eriko Sato

寺本 やえみ[†]
Yaemi Teramoto

清水 正明[†]
Masaaki Shimizu

鯨井 俊宏[†]
Toshihiro Kujirai

1. はじめに

近年、再生可能エネルギーが大量に導入されている。再生可能エネルギーは天候に大きく左右されるため、電力の安定供給のためには発電電力予測に基づく需給バランスの調整が必要とされる。再生可能エネルギーの代表的な発電方式の一つである風力発電の発電電力を予測するためには、風力発電設備の位置における風速の推定が必要となる。従来は、この風速推定のために地形情報などの土地条件や気象の物理モデルを用いた風況シミュレータで精緻な解析を行ってきた。しかし、精緻な解析には複数の複雑なモデル化が必要であり、これらシミュレータを使用して計算するには時間もコストもかかる[1][2]。そこで本研究では、低コストに風速を推定するため、気象データと機械学習を用いて、5km メッシュ格子点の気象予報データから格子内の任意の点における風速を推定する手法を検討した。

2. 問題設定と検証手法

風力発電が設置された点の風速を推定する問題を想定し、ある特定点における風速を、周囲 4 地点のメッシュ気象予報値から推定する。本検討では、風速の正解値が得られる気象庁の観測所を、仮に風力発電が設置された箇所と見なし、推定対象の特定点として推定精度を評価した。

2.1 データ

学習データは、気象庁で提供している 5km メッシュ単位の気象 GPV(Grid Point Value)データである Meso Scale Model (以下、MSM)と、各気象台の観測所データを使用する。MSM は 5km 格子単位の 39 時間先までの 1 時間ずつの予測値であり、3 時間ごとに発表されている。気象予報データは、京都大学生存圏研究所が運営する生存圏データベースによって収集・再構成後配布されているデータを使用した[3]。この MSM を入力データとし、同時間における 1 時間の観測所データを推定対象とする。なお、MSM データは、気圧面、地表面データの二種類あるが、地表面データの風速のみを用いた。具体的には、入力を、観測所を囲む直近格子点 4 点における 1 時間平均の、東西風、南北風、また、これを合成したスカラー値からなる 4 地点 3 要素の 12 次元、出力を観測所の 1 時間平均風速のスカラー値とした。

推定対象の観測所は、太平洋沿岸の銚子、日本海沿岸の新潟、内陸で山に囲まれた地域の一宮の 3 地点とした。学習データ期間は、季節が異なっても同じ土地であれば同じモデルで推定できるか確認するため、2015 年 4 月～6 月の 3 か月間、テスト期間は 2016 年 1 月～2 月の 2 か月間とし、各地域における推定精度を検討した。図 1 に各 MSM 格子点と観測所の位置関係を、表 1 に各観測所の風速の平均と分散を示す。

[†] 日立製作所 Hitachi, Ltd., Research & Development Group

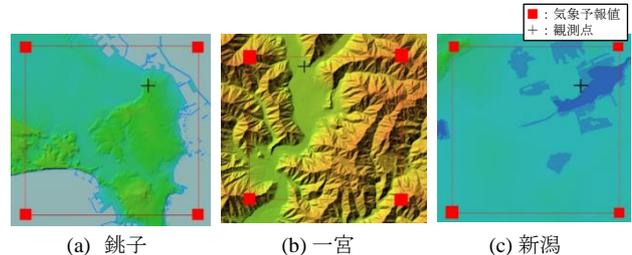


図 1 MSM 格子点と観測所の位置

※(a)～(c) 国土地理院の電子地形図 (タイル) に各観測所と MSM 格子点の位置を追記して掲載

表 I 各観測所における風速の平均・分散

Location	Train term		Test term	
	Average[m/s]	Variance	Average[m/s]	Variance
銚子	5.17	8.24	5.50	9.03
一宮	1.59	1.49	1.39	1.16
新潟	3.04	3.84	3.38	3.25

2.2 手法

本報告では、実データに 3 種の機械学習手法を適用して風速推定モデルを作成し、精度を検証する。推定モデルの学習には、重回帰分析、Random Forest (以下、RF)、深層学習の一つである Long Short Term Memory(LSTM)の 3 種の機械学習手法を適用した。特に、LSTM は時系列的に連続した情報を扱うことが可能であり、大気は連続的に風は前ステップの影響をうけると想定されるため、この学習方法を選択している。

各学習手法の誤差評価には Root Mean Squared Error (以下、RMSE)を用いた。重回帰分析では誤差が最小となるように各説明変数の重みを計算する。RF では交差検証をしながら、学習データ全体の中から重複や欠落を許して複数個の学習データセットを抽出し、その一部の属性を使って決定木 (弱学習器) を生成し、弱学習器の出力結果の平均によって推定結果を算出する。また、LSTM は、誤差関数の勾配を確認しながらパラメータを調整してネットワークを作成する。なお、LSTM は Recurrent Neural Network (以下、RNN) の一種であり、内部にループを持ち、系列情報を扱うことができる。

3. 結果

表 II 及び図 3 に、各学習地点と手法における RMSE を示す。また、比較対象として、距離による重みづけ加重平均 (Weighted average) の精度も示す。距離による重みづけ加重平均との比較により、距離以外のファクターを機械学習によって学習しているかを考察することが可能と考える。図 4 に銚子でのテスト期間における観測と各学習手法による推定風速について、風速が (a) 低い、(b) 高い傾向のある一週間を示す。

表II 各学習手法のRMSEと相関係数

Location	Method	RMSE (Train)[m/s]	RMSE (Test)[m/s]	Correlation coefficient(Test)
銚子	(※) 加重平均	1.57	1.79	0.818
	重回帰	1.48	1.71	0.828
	RF	1.30	1.74	0.816
	LSTM	1.59	1.69	0.836
一宮	(※) 加重平均	1.13	1.21	0.568
	重回帰	0.87	0.87	0.610
	RF	0.48	0.84	0.626
	LSTM	0.92	0.89	0.558
新潟	(※) 加重平均	1.52	1.80	0.714
	重回帰	1.27	1.32	0.743
	RF	1.03	1.26	0.727
	LSTM	1.18	1.36	0.705

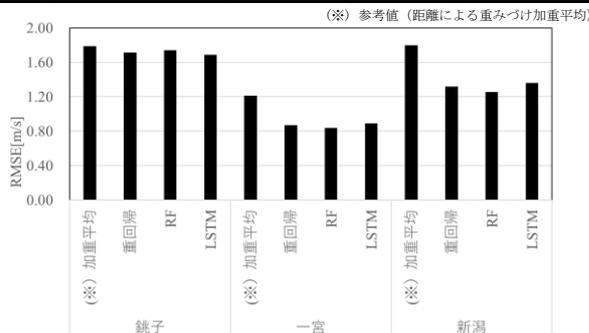


図3 各地点及び手法別のRMSE(Test term)

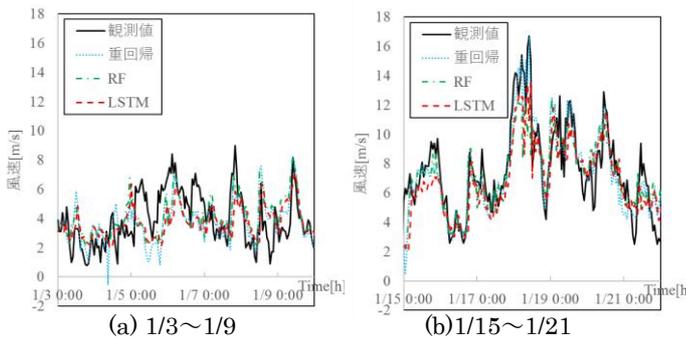


図4 銚子における観測及び各手法の推定風速

4. 考察

4.1 加重平均と機械学習手法の比較

比較的滑らかな土地である太平洋沿岸の銚子、日本海沿岸で東側には山脈が連なる新潟、内陸で山に囲まれた地域の一宮の3地点について、距離による重みづけ加重平均と機械学習手法の精度を比較する。まず、地域別に距離による重みづけ加重平均を比較する。図3より、メッシュ内に山などの障害物が比較的少ない銚子では、他の機械学習手法と比較してもRMSEに大きな差はない。一方、同様にメッシュ内に障害物が比較的少ない新潟では、他の機械学習手法と比較しても、距離による重みづけ加重平均のRMSEは大きい。この新潟のRMSEが大きくなる原因は、メッシュの外の環境に大きく由来するものと考えられる。例えば、メッシュの外に連なる山脈にぶつかった海風が折り返し、風が重ねあわさった結果の値が格子点の風速となる。この格子点の風速を使って特定地点の風速を推定するには、メッ

シユ内の距離による重みづけだけでは説明ができなく、RMSEが大きくなったと考えられる。よって、たとえメッシュ内が平地であっても、単純な距離による重みづけ加重平均だけでなく、各格子点の距離以外のファクターを学習できる手法の適用が必要であると考えられる。機械学習を用いた場合では、表IIより、いずれの地域も重みづけ加重平均よりRMSEが小さくなっていることがわかる。また、実測値と推定値の相関係数は最大で、山間の(b)一宮は0.626、一方海沿いの地域である太平洋側の(a)銚子は0.836、日本海側の(b)新潟は0.743であり、特に比較的風況の安定した海沿いの地域では相関が高いことが確認できた。

4.2 各機械学習の特性

重回帰分析について、図4より、(a)の特に風が弱い時には大きく外す一方で、(b)の風が強い時には他手法と同様にフィッティングしている様子がみられる。つまり、風の強弱によって、格子点と推定点との関係性が異なる場合においては、RFやLSTMに優位性があると考えられる。例えば、図3より、一宮のような周囲が山間になる箇所では、RFのRMSEが低い。これは、RFでは単純な重みづけとなる重回帰に比べて、各格子点の風の強弱別に風速を推定できることで、“風が弱い時には、ある格子点からの風は、特定地点との間の地形に遮蔽されやすくなる”、“など、暗黙的に土地形状を加味した学習ができるため”と考えられる。なお、時系列を加味できるLSTMのRMSEの大きさは地域によってばらつき、RFからの優位性は殆どみられない。これは、本問題設定のように同時間の周囲格子点の風速で、特定地点の風速を説明可能なため、あらためて時系列情報を加味する必要がないことを示すと考えられる。

これらの検証結果から、特にメッシュ内外で風の動きを複雑にする要因があるような地域であれば、機械学習を用いた風速推定が有効であることが示された。また、特にメッシュ内に比較的遮蔽物のない海沿いの地域であれば、従来の精緻なシミュレータなしに、機械学習を用いた低コストで高速な風速推定が可能であると示唆される。

5. まとめ

本報告では、風力発電の発電電力予測を安価高速で実現するために、風力発電設備の設置された地点での風速を機械学習の手法を用いて推定する方式について検討した。この結果から、実用可能性のある機械学習の手法と各地点の特徴を踏まえた精度について議論した。この結果、風力発電設備を設置するような周囲に遮蔽物のない海沿いの地点において、機械学習を用いた低コストで高速な風速推定の可能性を確認した。今後の課題として、風速の他に加味すべき入力の見直しや、多地点に適用可能な風速推定モデルの検討が必要である。

参考文献

- [1] 橋本, “複雑地形上でのメソ気象モデルMM5の風況計算精度と高解像度化の限界に関する検討”, 日本風工学論文集第30号, 平成17年7月
- [2] 門倉, “電中研ウインドファーム風力発電出力予測システムの開発”, 電力中央研究所研究報告書, 平成21年6月
- [3] 京都大学生存圏研究所, “生存権データベース”, <http://database.rish.kyoto-u.ac.jp>