

ニューラルネットワークを用いた 風速予測における気圧データの導入

Introduction of Atmospheric Pressure to Wind Speed Forecast
with Artificial Neural Network

桶 真一郎 *¹ 伊藤 陽平 *² 見目 喜重 *³ 滝川 浩史 *⁴ 榊原 建樹 *⁵
Shinichiro OKE Yohei ITOH Yoshishige KEMMOKU Hirofumi TAKIKAWA Tateki SAKAKIBARA

Abstract

The mean wind speed of 6 hours is forecasted using the artificial neural network (ANN). The forecasted target site is Omaezaki, Shizuoka prefecture. The weather data from 1999 to 2003 at Omaezaki and other 8 sites around it are inputted into the ANN. The ANN is constructed every season. Three kinds of the weather data inputted into the ANN as follows: Case A-1; wind speeds of two and hours before the forecast timing, Case A-2; atmospheric pressure of two and one hours before the forecast timing in addition to Case A-1, Case B; mean atmospheric pressure of six hours after the forecast timing in addition to Case A-2. Case B is based on the fact that atmospheric pressure has been forecasted very accurately. Forecast error is evaluated by the root mean square error. The forecasted results show that the forecast error of Case B is 0.8 to 1.2 m/s through a year while that of Case A-1 is 1.0 to 1.6 m/s and that of Case A-2 is 1.0 to 1.4, and the forecast error of Case B is smaller than those of Case A-1 and Case A-2 in the wind speed range larger than 5 m/s. These results indicate that the atmospheric pressure data is important in the wind speed forecast.

キーワード：風速予測，ニューラルネットワーク，入力データの種類，気圧データ

Key Words: Wind speed forecast, Artificial neural network, Kind of input data, Atmospheric pressure data

1 はじめに

我が国では，2010年度における風力発電の導入容量を300万kWとすることが目標とされ[1]，2005年3月現在の導入容量は約93万kWに達している[2]。風力発電は，風況の変化に伴いその発電電力が大きく変動するので，電力系統への風力発電の連系量が増大すると，その出力変動により系統からの見かけの負荷変動が増大し，系統全体に悪影響を与えるおそれがある。そのため，ウィンドファームへの蓄電設備の導入[3,4]や風力発電の出力変動を吸収するための供給予備力としての可変電源の増強が検討されている。ただし後者においては，大容量の風力発電出力に対応した供給予備力を常に待機させておく必要があり，設備コスト・運用コストがともに増加してしまう。この問題を解決するために，系統運用者または発電事業者の系統運用計画における風速予測の利用

が検討されている[5]。これまでに，さまざまな風速予測手法が提案されてきた([6,7]など)。我々の研究グループではニューラルネットワークを利用した風速予測に注目し，有効な入力データの選定や予測モデルの構築法について検討を進めてきた。そこでは，風力発電量の予測に基づく可変電源の準備・立ち上げを想定し，1～6時間先までの平均風速予測を行ってきた[8-10]。その中で，特に6時間先までの平均風速の予測には，2時間前からの気象データが有効であることが分かっている[10]。一方，同じようにニューラルネットワークを利用する日射量予測において，予測期間の気圧を用いると，その予測精度が飛躍的に向上することが示されている[11,12]。また，予測期間の気圧を用いる場合に前提となる気圧予測においても，ニューラルネットワークの利用により高い予測精度が実現されている[13]。

本研究では，ニューラルネットワークを用いた風速予測に適した気象データを検討する。6時間先までの平均風速の予測において，2時間前からの気象データを用いる場合と，それに加えて予測期間の気圧データを用いる場合とを比較する。

2 気象データ

1999～2003年の地上気象官署の観測データ(SDPデータ)を基礎データとし，それに収録されている10分ごとの平均

*1 豊橋技術科学大学工学部教務職員
(〒441-8580 豊橋市天伯町雲雀ヶ丘1-1)
e-mail: oke@eee.tut.ac.jp

*2 豊橋技術科学大学大学院工学研究科学生

*3 豊橋創造大学経営情報学部助教授

*4 豊橋技術科学大学工学部助教授

*5 豊橋技術科学大学工学部教授
(原稿受付：2006年4月3日)





Fig. 1 Forecast site and other SDP sites around it.

風速および1時間ごとの平均気圧データから、本研究で用いた風速および気圧データを作成した。予測対象地点は、静岡県御前崎（年平均風速：4.9 m/s）とした。


これまでにニューラルネットワークを用いた風速予測の入力データとしては、予測対象地点から半径150 kmの範囲の気象データが有効であることが明らかになっている[6]。図1に、御前崎を中心とする半径150 kmの円内にある気象観測地点を示す。全国には155地点のSDP観測地点があり、御前崎から半径150 kmの範囲には御前崎を含めてそのうち12地点がある。ただし、そのうち三島および石廊崎については必要な平均風速データの欠測が多いので、割愛した。また全国には約1,300箇所のAMeDASがあり、そのうち約850箇所では風速を計測している。御前崎から半径50 kmの範囲には風速を観測している4箇所のAMeDAS（天竜、磐田、菊川牧ノ原および松崎）があるが、これまでの研究でAMeDASデータの導入効果はそれほど高くはないことが分かっている[8]。ことに加え、SDPに比べてデータ精度が低いため、それらも割愛した。したがって、本研究で気象データを用いた地点は、御前崎、静岡、浜松、伊良湖、大島、名古屋、津、飯田および甲府の9地点である。なお、図1からも分かるように、御前崎は静岡県の太平洋沿岸部に位置するため、南方向の気象データは無い。

ここで図2に、御前崎、伊良湖の気圧および御前崎の風速の時系列データを示す。図中の P_o および P_i はそれぞれ御前崎および伊良湖の6時間ごとの平均気圧、 W_o は御前崎の6時間ごとの平均風速である。同図(a)から、1月は気圧、風速の変動がともに激しく、気圧が高くなったときには風が弱く、気圧が低くなったときには風が強くなり、また、気圧が高くて御前崎と伊良湖との気圧差が大きくなったときには風が強くなることが分かる。同図(b)から、7月には気圧の変動が小さく、風速の変動との関係が1月ほどは明確でないことが分かる。また、2地点間の気圧差が1月に比べて小さいことが分かる。

これらのことから、予測用データへの気圧の追加は、特に冬季における予測誤差の低減に資すると考えた。



(a) January



(b) July

Fig. 2 Time series of atmospheric pressures P_o , P_i at Omaezaki and Irigo, and wind speed W_o at Omaezaki.

3 予測モデル

ニューラルネットワークを用いて、6時間先までの平均風速を予測した。本章では、ニューラルネットワークの構造と学習・予測の方法および学習・入力データについて説明する。

3.1 ニューラルネットワーク

ニューラルネットワークは、脳の情報処理方式を模倣した数値モデルのひとつで、気象予測の分野などにおいて多くの利用実績がある[14,15]。本研究で使用するニューラルネットワークは3層構造で、入力層、1つの中間層および出力層から成る。図3にその構成を示す。ニューラルネットワークの入力（学習）データは、各データ使用地点の気象データであり、出力（教師）データは予測対象地点における6時間先までの平均風速である。使用するニューラルネットワークの各層のユニット数を以下に示す。

入力層ユニット数：(データ種類) × (データ使用地点数)

中間層ユニット数：(入力層ユニット数) × 1/3

出力層ユニット数：1

ニューラルネットワークの学習時には、入力層には学習データが、出力層には教師データが設定される。学習用データと教師データとの対応関係に基づいて、ユニット間の重み




Fig. 3 Artificial neural network used in this study.

および中間層の値が最適化される。このとき、ネットワークの習熟度はその学習回数に大きく影響される。本研究では、学習回数の上限を3万回とした。ニューラルネットワークの学習はバックプロパゲーションにより行った。ただし通常のバックプロパゲーションでは、各学習回ごとに誤差を急速に減少させる最急降下法を用いるため、誤差がローカルミニマムに陥るおそれがある。本研究では、その学習回に求めた勾配方向だけで重みを修正するのではなく、その前の学習回で求めた勾配方向と共役な勾配方向により重みを修正する共役勾配法 [16] を採用した。共役方向の生成には、Polak-Ribiere の公式 [17] を用いた。

ニューラルネットワークによる予測時には、学習により最適化されたネットワークに入力データを設定し、出力として6時間先までの平均風速を得る。

3.2 学習および入力データ

6時間先までの平均風速を予測する場合には2時間前からの気象データが重要であることが分かっている。本研究では、入力データに2時間前からの風速データのみを用いた場合と、それに2時間前からの気圧データを加えた場合とを比較した。これらをそれぞれ、ケース A-1、ケース A-2 とした。なお、これらの風速・気圧データは全て1時間平均値とした。

ケース A-1 : 2時間前からの1時間ごとの平均風速

ケース A-2 : 2時間前からの1時間ごとの平均風速
2時間前からの1時間ごとの平均気圧

また、すでに高精度な気圧予測が実現されている [13] ことから、予測期間である6時間先までの平均気圧を既知とし、それを予測用データに追加した。これをケース B とした。

ケース B : 2時間前からの1時間ごとの平均風速
2時間前からの1時間ごとの平均気圧
6時間先までの平均気圧

図4に本研究で用いた気象データの組み合わせを示す。こ




Fig. 4 Combination of input data in each data case.

これらのデータを各データ使用地点ごとに抽出し、予測に用いた。本研究でのデータ使用地点数は9地点であるから、各層のユニット数はそれぞれ表1のようになる。ニューラルネットワークの学習においては、一般にユニット数が多いほど学習に要する時間が長くなる。学習には季節ごとに分類した気象データを用い、季節ごとに独立したネットワークを構築した。

Table. 1 The number of units of the neural network.

Data case	Input layer	Hidden layer	Output layer
Case A-1	18	6	1
Case A-2	36	12	1
Case B	45	15	1

4 結果の評価

予測モデルを構築する際、そのモデルの学習効果の妥当性および汎化の有無を評価するためには、学習用データと評価用データとを別に用意する必要がある。しかし、単に所有するデータの一部を評価用とする場合、そのデータの選択次第で評価が大きく変わる恐れがある。そのような事態を回避するために、 ν -fold CV 法を用いて予測結果を評価した。 ν -fold CV 法は、所有するデータをほぼ同じ大きさの ν 個の部分集合に分割し、そのうち一つを評価用に、残りの $\nu-1$ 個を学習用に割り当てて合計 ν 通りの組み合わせで評価を行う方法である。本研究では1999~2003年の5年分の気象データを用いた関係上、1年分の気象データを1つの部分集合として分割した5-fold CV 法を採用し、5年分のデータのうち1年分を評価用、残りの4年分を学習用に割り当てた。全体的な結果の評価には、年ごとに計算される5年分の予測誤差を平均したものを用いた。

予測誤差は、式(1)で表される RMSE とした。




Fig. 5 Time series of forecasted and measured wind speed in case of A-1.




Fig. 6 Time series of forecasted and measured wind speed in case of B.

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (W_f(i) - W_m(i))^2} \quad [\text{m/s}] \quad (1)$$

ここで、 E_{RMSE} : RMSE [m/s], N : 評価用データ数 [-], $W_f(i)$: 予測風速 [m/s], $W_m(i)$: 実測風速 [m/s] である。

5 予測結果の検討

5.1 予測時系列例

学習および予測用データとして、2時間前からの風速のみを用いた場合（ケース A-1）の風速予測の時系列結果を図 5 に示す。風速の変動が激しく平均風速の大きい 1 月および平均風速の小さい 7 月のどちらにおいても、予測値と実測値とが極端に異なることは少ない。ただし、風速が急激に変動する場合などには、予測値と実測値とがやや大きく異なることもある。

予測用データとして、2時間前からの風速および気圧に予測期間の気圧を加えた場合（ケース B）の風速予測の時系列結果を図 6 に示す。1 月および 7 月のどちらにおいても、予測値と実測値とはよく合っている。図 5 に示すケース A-1 においてずれが目立つ 3, 7, 14 日でも、予測値と実測値とのずれは小さくなっている。

なお、これらのことは 1, 7 月以外のどの月においても同様である。

5.2 ν -fold CV 法の効果

評価用データを入れ替えて計算した年ごとの RMSE を表 2 に示す。同表から、入力データの種類によって評価用データとする年の RMSE が異なることが分かる。たとえばケース A-1 においては、2003 年を評価用データ、それ以外の年を学習用データとした場合に RMSE が最小となるが、ケース B においてはその場合の RMSE が最大となっている。このことから分かるように、 ν -fold CV 法を用いないと、評価用データの選択次第で予測結果の評価が変わってしまう。これは、年によって気象の変動の様子などが異なることに起因している。

Table. 2 Yearly RMSE of each data case.

Evaluation data	RMSE [m/s]		
	A-1	A-2	B
1999	1.30	1.21	0.97
2000	1.29	1.21	0.96
2001	1.26	1.11	0.91
2002	1.33	1.16	0.94
2003	1.25	1.20	0.98

5.3 月ごとの予測誤差

図 7 に月ごとの RMSE を示す。同図から、2時間前からの気象データのみを用いたケース A-1 および A-2 では年間を通して RMSE が 1.0 m/s 以上であることが分かる。また、特に




Fig. 7 Monthly RMSE.

Table. 3 Mean wind speed in each season in Omaezaki.

Season	Mean wind speed [m/s]
Spring (Mar. Apr. May)	4.96
Summer (Jun. Jul. Aug.)	3.91
Autumn (Sep. Oct. Nov.)	4.58
Winter (Dec. Jan. Feb.)	6.35

風が強い12月～3月にかけてのRMSEは1.5 m/s程度まで大きくなるのが分かる。これに対して、予測期間の気圧データを加えたケースBでは、年間を通してRMSEが1.0 m/s程度あるいはそれ以下である。全体的に冬季におけるRMSEが大きくなるのは、表3に示すように冬季には平均風速が大きくなるためである。

5.4 風況と予測誤差

本研究で用いた風速データの風速の発生頻度および風速ごとのRMSEを図8に示す。同図から、風速の発生頻度はよく知られているとおりほぼワイブル分布に従うことが分かる。

2時間前からの気象データのみを用いた場合（ケースA-1, A-2）は、風速が4 m/s以下の場合を除き、風速が大きくなるにつれてRMSEが大きく増加している。2時間前からの気圧データを加えたケースA-2の方がややRMSEが小さいが、全体としてはほぼ同じ傾向を示している。

予測期間の気圧データを加えた場合（ケースB）も、風速が大きくなるとRMSEは大きくなる。ただしケースA-1およびA-2の場合とは異なり、風速6～11 m/sの範囲ではRMSEがほぼ一定となる。風速ごとの発生頻度が最も高いのは風速2～5 m/sの弱中風であるが、風速5～12 m/sの中強風の発生頻度は全体に対して60%程度あるため、それらの風速域での予測誤差の低減が全体の予測誤差の低減につながっていると考えられる。

5.5 発電量の推定

予測風速を用いて風力発電量を推定し、予測誤差が発電量の推定精度に与える影響を検討した。図9に愛知県田原市の




Fig. 8 RMSE and frequency distribution.




Fig. 9 Power-wind speed characteristic of a wind mill.

蔵王山に設置されている定格出力：300 kW（定格風速：14.5 m/s）の発電用風車の出力－風速特性曲線を示す。この特性曲線は、2003年度の1時間ごとの発電実績データから求めた近似式(2)から得た。なお、この風車のカットイン風速は3 m/sである。

$$\begin{aligned}
 P &= 0 & (W \leq 3.0) \\
 P &= -0.037W^4 + 1.16W^3 - 10.5W^2 + 46.8W - 75.1 & (3.0 < W \leq 14.5) \\
 P &= 300 & (W > 14.5)
 \end{aligned} \quad (2)$$

ここで、 W ：風速 [m/s]、 P ：発電電力量 [kWh/h] である。

本研究では、上式の W に予測6時間平均風速を代入して6時間先までの発電電力量を推定し、実測6時間平均風速を用いて推定した発電電力量と比較して、発電量の推定におけるRMSEを計算した。

図10に予測風速および推定発電量のRMSEを示す。同図から、2時間前からの気象データのみを用いた場合（ケースA-1, A-2）より予測期間の気圧データを加えた場合（ケースB）の方が予測風速および推定発電量のRMSEが小さいことが分かる。風速がカットイン風速以下の場合には推定発電量




Fig. 10 RMSE of forecasted wind speed and estimated electricity.

は風速にかかわらず 0 kWh/h となるため、特に中強風域での風速予測誤差を抑制できるケース B の発電量推定誤差が小さくなる傾向にある。

6 まとめ

ニューラルネットワークを用いて 6 時間先までの平均風速を予測する場合に、その入力データとして予測期間の気圧を用いることを提案した。本研究によって得られた主な結果を以下に示す。

1. 2 時間前からの気象データのみを用いた場合、予測誤差は風速の増加と共に大きくなる。
2. 風速のみを用いた場合と風速および気圧を用いた場合とでは、予測誤差はほとんど変わらない。また、それらの RMSE は年間を通して 1.0 m/s 以上で、月ごとの差は大きい。
3. 2 時間前からの気象データに予測期間の気圧データを加えると、その RMSE は年間を通して 1.0 m/s 程度に抑制され、月ごとの差は小さくなる。
4. 予測期間の気圧データを加えると予測誤差が低減されるのは、風速 5~12 m/s の中強風の発生頻度が全体に対して 60% 程度と十分に高いためである。
5. 予測風速から発電電力量を推定するとき、学習および入力データとして予測期間の気圧を加えると特に中強風域での予測誤差を抑制でき、発電電力量の推定誤差が小さくなる。

今後は、本研究において提案した風速予測に気圧データを導入する手法の御前崎以外の地点における有効性、すなわち提案手法の地域的な汎用性を確認する。また、本研究で用いた予測モデルを改良し、系統運用においてはより有用と考えられる 24 時間先までの 1 時間ごとの時系列風速を予測する。

References

- [1] 新エネルギー部会報告書，経済産業省，2001
- [2] 吉田：「風力発電導入状況の最新情報」，風力エネルギー，Vol.29，

- No.1, pp.4-8, 2005
- [3] 徳田：「苫前町でのバッテリー平準化実証試験報告」，風力エネルギー，Vol.29, No.3, pp.4-12, 2005
- [4] 矢後：「風力発電システムと系統連系対策」，風力エネルギー，Vol.29, No.3, pp.13-18, 2005
- [5] 石原：「風力発電出力予測技術の現状と課題」，風力エネルギー，Vol.29, No.3, pp.19-25, 2005
- [6] 見目 他：「広域の気象データを利用した翌日の風速予測」，太陽エネルギー，Vol.27, No.1, pp.85-91, 2001
- [7] A. Sfetsos, "A novel approach for the forecasting of mean hourly wind speed time series", Renewable Energy, Vol.27, pp.163-174, 2002
- [8] 伊藤 他：「ニューラルネットワークによる風向別風速予測法への AMeDAS データの導入」，平成 16 年電気学会電力・エネルギー部門大会，pp.37-19 - 37-20, 2004 (CD-ROM)
- [9] 伊藤 他：「ニューラルネットワークによる 1 時間平均風速予測における入力データ間隔の影響」，太陽／風力エネルギー講演論文集 2004, No.85, pp.349-352, 2004
- [10] 伊藤 他：「ニューラルネットワークによる数時間前までの風速予測における入力データの検討」，平成 17 年電気学会電力・エネルギー部門大会，pp.27-13 - 27-14, 2005 (CD-ROM)
- [11] 見目 他：「ニューラルネットワークによる日射量予測とそれを利用した太陽熱/深夜電力給湯システムの運用」，太陽エネルギー，Vol.28, No.6, pp.27-32, 2002
- [12] S. Oke et al., "Influence of Atmospheric Pressure on Insolation Forecast Using Artificial Neural Network", Proceedings of ISES Asia-Pacific, pp.121-127, 2004
- [13] 桶 他：「ニューラルネットワークを用いた翌日平均気圧の予測」，平成 16 年度電気関係学会東海支部連合大会講演論文集，O-157, 2004 (CD-ROM)
- [14] S. Li et al., "Using Neural Networks to Estimate Wind Turbine Power Generation", IEEE Transactions on Energy Conversion, Vol.16, No.3, pp.276-282, 2001
- [15] C. Marzban, "Neural Networks for Postprocessing Model Output: ARPS", MONTHLY WEATHER REVIEW, Vol.131, pp.1103-1111, 2003
- [16] 丹慶 他 訳：「Numerical Recipes in C 日本語版」，技術評論社，pp.282-312, 1994
- [17] 嘉数 他 訳：「ニューラル・コンピューティング上級編」，森北出版，pp.497-504, 1998