

# 広域の気象データを利用した翌日の風速予測

METHOD OF FORECASTING WIND VELOCITY OF NEXT DAY  
USING WEATHER DATA OVER WIDE AREA.

見目喜重 \*<sup>1</sup>  
Yoshishige KEMMOKU

石井弘樹 \*<sup>1</sup>  
Hiroki ISHII

滝川浩史 \*<sup>1</sup>  
Hirofumi TAKIKAWA

河本映 \*<sup>2</sup>  
Teru KAWAMOTO

榊原建樹 \*<sup>1</sup>  
Tateki SAKAKIBARA

## Abstract

Methods of forecasting the wind velocity using weather data over a wide area are proposed, and the mean wind velocity from the present time to 12 hours later is forecasted by the methods. A multiple regression analysis (MRA) and a neural network (NN) are adopted as basis of methods of forecasting. The forecast error are discussed, the kinds of weather data and the area size (expressed by radius from a target site) being parameters. Two cases of weather data are input to the learning of MRA and NN. Radius from the target site is changed from 0 to 500 km around the target site. In case A, weather data before the forecast period are input. In case B, mean values of pressure at the forecast period are added to the input data of case A. Forecast error is estimated in term of %RMSE which is defined by RMSE (Root Mean Square Error) divided by mean wind velocity for each season. Omazaki, Shizuoka prefecture, is selected as the target site. The result shows that, in case A, forecast error can be reduced to 27% in winter and 32% in other seasons when the radius of area size is 200 km and wind velocity, pressure and temperature before the forecasted period are input to NN. In case B, forecast error can be reduced to 15% in winter, 20% in spring · autumn and 25% in summer when the radius is 100 km and pressure at the forecasted period, wind velocity and pressure before the forecasted period are input to NN.

キーワード：風速予測，重回帰分析，ニューラルネットワーク，気象データ，広域

**Key Words:** wind velocity forecast, multiple regression analysis, neural network, weather data, wide area

### 1. はじめに

近年，日本においても大規模な風力発電施設の導入が積極的に進められてきている。例えば，1999年11月に北海道苫前町で初の民間大規模ウィンドパーク(1 MW × 20機)が運転を開始し，その隣接地に電源開発(株)が1.65 MW × 14機，1.5 MW × 5機を着工している<sup>(1)</sup>。それらを含めて，北海道では，北海道電力管内の最大電力需要の10%に相当する総計500 MWの風力発電施設の導入が計画されている。また，三重県久居市で750 kW × 4機が運転を開始し，さらに20機の増設を計画している。それらはすべて電力系統に連系されている。

このように風力発電が大量に電力系統に導入された場合，風力発電は出力変動が大きいため，その需給制御に及ぼす影響が懸念されている。例えば，電力系統

に最大電力の10%程度の容量の風力発電が導入された場合，負荷追従率の低い原子力発電が主に発電している深夜において風力発電出力が急激に変動したときに，その出力低下分を原子力が追従できず，系統が不安定になる恐れがある。しかし，深夜時間帯の風力発電出力が予測できれば，原子力発電出力をあらかじめ抑制し，代わりに負荷追従率の高い電源で発電を行うよう対策を執ることができる。このように，翌日の最大電力需要の予測が重要であると同様，深夜の軽負荷時の風力発電出力の予測は特に重要となる<sup>(2)</sup>。

また，離島などの電力系統から独立した地域に導入されている風力/蓄電池/ディーゼル発電システムにおいては，風力エネルギーを有効に利用するためには，風力発電出力が負荷電力を上回る場合には，その余剰を全て充電できるように蓄電池の充電状態をあらかじめ低く設定するようなシステムの運用が望まれる。そ

\*1 豊橋技術科学大学工学部電気・電子工学科  
Technology.

\*2 静岡大学工学部電気・電子工学科  
(原稿受理 平成13年8月11日)

Dept. of Electrical and Electronic Engineering, Toyohashi Univ. of

Dept. of Electrical and Electronic Engineering, Shizuoka Univ.

のようなシステムの運用を実現するには、将来の風力発電量予測が必要となる。

風力発電出力の予測の基になるのは、風速の予測である。風速を予測する手法についての検討は既に始められているが<sup>(1)(4)</sup>、数時間後の風速予測に関しては必ずしも十分な成果は得られていない。

本研究では、広域の気象データを利用して、予測対象地点における現時点から一定時間先までの平均風速を予測する手法を提案する。予測モデルとしては、重回帰分析およびニューラルネットワーク (NN) を使用する。それらの予測モデルを、季節ごとに構築する。

1991 ~ 1996 年の気象データを用いて静岡県御前崎における風速を予測し、その誤差率が最小となる気象データの組み合わせおよび観測地点半径に言及する。

## 2. 風速予測の概要

風速を予測する際、予測時間幅、すなわち現在からどのくらい先までの平均風速を予測するかが重要となる。ここでは、日負荷曲線が 24 時間周期で変動することに鑑み、予測時間幅を 12 時間とした。従って、現時点から 12 時間後までの期間  $T_n$  が予測対象期間となり、この期間の平均風速が予測モデルの出力データ (予測値) となる。また、現時点から 12 時間前までの期間  $T_{n-1}$  が入力対象期間となり、この期間の各気象要素の平均値が予測モデルへの入力データとなる。なお、本研究では元の気象データとして、気象官署において測定された特別値データ (SDP データ) を使用したため、入力データは 1 時間間隔でサンプリングされた平均値である。

風速は季節ごとに異なる気圧配置の影響を強く受けるため、予測モデルは季節ごとに構築した (春: 3 ~ 5 月, 夏: 6 ~ 8 月, 秋: 9 ~ 11 月, 冬: 12 ~ 2 月)。

風速予測の対象地点としては、本州のほぼ中央で、かつ 330 kW の風力発電機が稼働している静岡県御前崎を選定した。この地点における 1991 ~ 96 年の平均風速は 4.92 m/s である。

## 3. 入力データ

予測対象地点における予測対象期間の風速に影響する要因として、低気圧・高気圧および前線の位置などがある。本研究では、次の理由により、気圧、風速および気温を入力データとした。

- ① 複数地点の気圧を入力することで、気圧配置に

よる影響が考慮できる。

- ② 西側の地点のある時刻の風速は、東側の地点の数時間後の風速と大きな相関を持つことから、周辺地点の風速を入力することで、精度の高い予測が期待できる。

- ③ 気温を入力することで、気温による気圧への影響ならびに風速への影響を考慮できる。

それらの気象データおよび周辺地点の範囲 (観測地点半径) を変化させることにより、予測に有効な入力データの組み合わせおよびその観測地点半径を検討した。

まず、 $T_{n-1}$  の気象データから  $T_n$  の風速を予測するために、以下の 3 つのデータの組み合わせを入力した。

- ケース A-1 :  $T_{n-1}$  の風速
- ケース A-2 :  $T_{n-1}$  の風速・気圧
- ケース A-3 :  $T_{n-1}$  の風速・気圧・気温

予測期間  $T_n$  の風速に最も影響を与える気象要因として、その期間の気圧配置が考えられる。この  $T_n$  の気圧配置が風速にどの程度影響するのかを確認するために、 $T_n$  の平均気圧に加えて、以下の 3 つのデータの組み合わせを入力した。

- ケース B-1 :  $T_n$  の気圧
- ケース B-2 :  $T_n$  の気圧,  $T_{n-1}$  の風速
- ケース B-3 :  $T_n$  の気圧,  $T_{n-1}$  の風速・気圧

以上のような気象データの観測地点の半径を 0, 50, 100, 200, 300, 500 km と変化させた。それぞれの範囲内で採用した観測地点を表 1 に示す。

表 1 御前崎の風速予測に用いた気象データの観測地点

| 観測地点半径<br>[km] | 気象観測所           | 観測地点<br>合計 |
|----------------|-----------------|------------|
| 0              | 御前崎 (予測対象地点)    | 1          |
| 50             | 浜松, 静岡, 石廊崎     | 4          |
| 100            | 伊良湖, 岐阜, 甲府, 三島 | 8          |
| 200            | 奈良, 福井, 長野, 熊谷  | 12         |
| 300            | 洲本, 高田, 水戸      | 15         |
| 500            | 福山, 相川, 広島      | 18         |

## 4. 風速予測モデルの概要

一般に、風速の予測法には、平均値予測、持続予測などの統計的予測法がある。本研究の平均値予測とは、1991 ~ 1996 年の 6 年間の各月の平均風速が対象とす

る時点でも吹くと予測することである。従って、それら各月の平均風速が予測値となる。持続予測とは、現在の期間の風速が次の期間でも持続するというものである。従って、持続予測では、入力対象期間（現在から12時間前まで）の平均風速が予測対象期間（現在から12時間後まで）の平均風速の予測値となる。

平均値予測では予測時間幅が短い場合に誤差が大きくなり、逆に、持続予測では予測時間幅が長い場合に誤差が大きくなる傾向にある。

本研究で提案する予測手法は、重回帰分析およびニューラルネットワーク (NN) をベースにしている。

重回帰分析では、ある変数  $y$  (目的変数) とそれに影響すると考えられる変数  $x_1 \cdot \dots \cdot x_p$  (説明変数) との関係を表式(1)のように表現する。

$$y = b_0 + b_1 \cdot x_1 + b_2 \cdot x_2 + \dots + b_p \cdot x_p \quad (1)$$

ここで、 $b_0$  : 切片  
 $b_1, \dots, b_p$  : 回帰係数

目的変数は、予測対象地点における予測対象期間の平均風速であり、説明変数は、予測対象地点および周辺の観測地点の気象データである。

NN は非線形問題にも柔軟に対応できることから、多くの予測モデルに使用され、成果を上げている<sup>(12)-(19)</sup>。本研究において使用した NN を用いた予測モデルの構成を図1に示す。NN の出力 (教師) データは、予測対象地点における  $T_n$  の平均風速であり、入力データは予測対象地点とその周辺の気象データである。本研究では、NN の中間層を1層とし、各層のユニット数を次のように設定した。

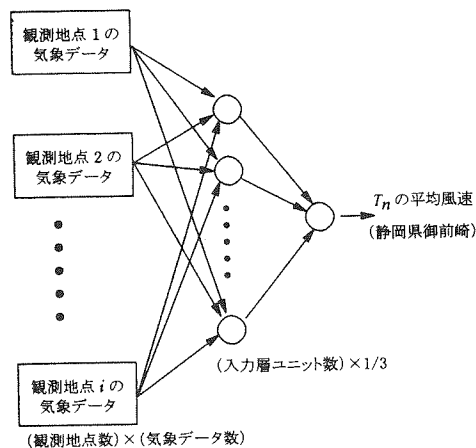


図1 風速予測のためのニューラルネットワークの構成

- ・入力層ユニット数：(観測地点数) × (気象データ数)
- ・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

NN の学習はバックプロパゲーション (BP)<sup>(10)</sup> により行った。BP は、階層型 NN で広く用いられている学習アルゴリズムで、誤差成分を出力層から入力層へ逆伝搬して各ニューロンユニット間のウェイトを修正する。通常の BP では、最急降下法により誤差を急速に減少させるようにウェイトを調整するため、ローカルミニマムに陥いるおそれがある。そこで、本研究では、新しい勾配方向に進むのではなく、古い勾配方向と共役な方向に進ませることのできる共役勾配法<sup>(10), (11)</sup>を採用した。共役方向の生成には、Polak - Ribiere<sup>(10)</sup>の公式を用いた。

### 5. 予測の評価方法

NN あるいは重回帰分析を使用して予測モデルを構築する際、ネットワークの学習効果や推定回帰係数の妥当性および汎化能力の有無を評価しなければならない。そのためには、ネットワークの学習や回帰係数の推定に用いていないデータと比較して、その妥当性を評価する必要がある。しかし、データ数が少ない場合や、データの入出力間に何らかの不確定要素がある場合、単に一部のデータを評価用データとする方法では、評価用データの選択次第で評価が大きく変わる可能性がある。そのような問題に対処する有効な評価方法として Cross Validation (CV) 法<sup>(12)</sup>がある。ここでは、その中でも計算負荷が軽減できる  $\nu$ -fold CV 法を用いた。以下にその適用手順を示す。

- (1) 所有するデータをほぼ同じ大きさの  $\nu$  個の部分集合に分割する。
- (2) このうち1つを評価用に、残り ( $\nu - 1$ ) を学習用として割り当て、予測モデルを構築する。
- (3) この操作を  $\nu$  通りあるデータの残し方について繰り返す。
- (4) 各予測モデルによる予測結果を総合的に評価する。

本研究では、1991 ~ 1996 年までの6年間の気象データを用いた関係上、 $\nu = 6$  (各年の気象データを1つの部分集合として分割) とした 6-fold CV 法を採用した。

予測誤差は、式(2)に示す %RMSE (Root Mean Square Error) により評価した。この%RMSE は、2乗誤差の平均値の平方根を実測値の平均値で規格化したものである。

$$\text{予測誤差: \%RMSE} = \frac{\sqrt{\frac{1}{m} \sum_{j=1}^m (W_{pj} - W_j)^2}}{\frac{1}{m} \sum_{j=1}^m W_j} \times 100 \text{ [\%]} \quad (2)$$

ここで、 $m$  : 評価用データ数  
 $W_j$  : 風速の実測値 [m/s]  
 $W_{pj}$  : 風速の予測値 [m/s]

## 6. 風速予測結果


### 6.1 入力データケース A の場合

季節ごとに式(1)ないし図1のNNを学習させ、式(1)の切片および回帰係数、NNのユニット間のウェイトを決定した。その際の学習データとして、前述したようにケースAないしケースBの場合を取り扱った。そのようにして決定した重回帰ないしNNを用いて12時間ごとに風速を予測した。予測結果の一例を図2に示す。同図はケースA-2の入力データを用いたNNによる風速予測の時系列結果である。図中の観測地点半径0 km は、御前崎の気象データだけを用いた場合である。同図のような時系列結果からは、観測地点半径を100 kmに拡大した予測値と、対象地点の気象データだけを用いた予測値との有意な差が読みとれない。


図2は10日間の予測結果であるが、実際には季節

ごと(約90日間)に時系列結果が得られる。そのような結果に対し、 $n$ -fold CV法を適用し、季節ごとに%RMSEの値を計算することができる。入力データとしてケースA、季節として冬の場合について、観測地点半径を0から500 kmと変えて予測した風速の%RMSEの値を図3に示す。比較のために、平均値予測および持続予測により予測を行った場合の%RMSEを同図中に示す。

同図から次のようなことが分かる。(1)観測地点半径が0 km、すなわち予測対象地点(御前崎)だけの



(a) 1994年1月



(b) 1994年7月

図2 NNによる風速予測の時系列結果(ケースA-2)




図3 風速の予測誤差率の観測地点半径依存性(入力データ: ケースA, 冬)

気象データを用いた場合、重回帰分析ないし NN による予測誤差は、平均値予測ないし持続予測による予測誤差よりも小さい。(2)重回帰分析ないし NN による予測誤差は、入力データとして風速のみを用いる(ケース A-1)よりも、風速と圧力とを用いる方(ケース A-2)が小さい。しかし、入力データに温度を加えても(ケース A-3)、予測誤差は小さくならない。(3)重回帰分析ないし NN による予測誤差は、観測地点半径を拡大すると減少するが、200 km を超えるとそれ以下には減少しない。(4)重回帰分析による予測誤差と NN による予測誤差との差はほとんど無い。(5)代表的な予測誤差の数値は、平均値予測:42%、持続予測:40%、NN による予測:27%(観測地点半径が200 km のとき)である。

図3は冬季に関する予測誤差の観測地点半径依存性であるが、他の季節のものを示すと図4となる。

同図は、入力データをケース A-2 とし、NN を使用した場合である。どの季節においても、観測地点半径を200 km まで拡大することによって、予測誤差が削減できていることが分かる。予測誤差は、冬季では27%、その他の季節では33%である。




図4 NNによる季節ごとの風速の予測誤差 (ケース A-2)

### 6.2 入力データケース B の場合

次に、予測対象期間の平均気圧を入力データとして用いるケース B の場合の予測結果について述べる。


風速予測の時系列結果の代表例として、ケース B-2 の入力データを用いた NN によるものを図5に示す。同図から、予測期間の気圧を入力データとして用いても、対象地点のみの気象データだけでは、予測値はケース A の場合とほとんど変わらないが、観測地点半

径を拡大することにより、実測値により接近していることが分かる。特に、1月6、7日や7月1、2、3、4日の予測値は、図2と比較して実測値に大幅に接近していると言える。


図6には、入力データとしてケース B を用いた場合の予測誤差を示す。

図6から次のようなことが分かる。(1)観測地点半径を拡大すると、NN による予測誤差と重回帰分析による予測誤差との差が明確となり、前者が後者よりも明らかに小さくなる。(2)両者は、観測地点半径を拡大すると急激に減少するが、100 km を超えるとそれ以下には減少しない。(3)重回帰分析による予測誤差は、入力データの種類を多くするのに伴って(B-1 から B-2 へ、B-2 から B-3 のように)、減少する傾向にあるが、NN による予測誤差にはそのようなことはない。(4)予測誤差が最小となるのは、入力データがケース B-2 ないし B-3 で、かつ、観測地点半径が100 km のときであり、そのときの予測誤差は15%となる。

図6は冬の予測誤差であるが、他の季節のものを図7に示す。同図は、入力データとしてケース B-2 を用い、NN によって予測した場合である。どの季節においても、観測地点半径を100 km まで拡大することにより、予測誤差を大幅に低減できることが分かる。その低減ポイントは、最も小さい夏季でも約10ポイント、その他の季節では約15ポイントである。そのと



(a) 1994年1月



(b) 1994年7月

図5 NNによる風速予測の時系列結果(ケース B-2)




図6 風速の予測誤差率の観測地点半径依存性 (入力データ: ケース B, 冬)




図7 NNによる季節ごとの風速の予測誤差 (ケース B-2)

きの予測誤差は、夏では24%、秋では22%、春では20%、冬では15%である。

7. まとめ

本研究では、広域の気象データを用いて、予測対象地点における現時点から一定時間先までの平均風速を予測する手法を提案し、予測誤差の低減に有効な気象データの組み合わせならびに広域の範囲(観測地点半径)を検討した。ここで、気象データとしては、予測対象期間より前の気象データを用いた場合(ケース A)および予測対象期間の平均気圧を用いた場合(ケース B)について検討した。また、予測モデルとして、重回帰分析およびNNを使用した。

その結果、重回帰分析およびNNによる予測誤差は、

予測対象地点だけの気象データを用いた場合でも平均値予測および持続予測による予測誤差よりも小さくなり、さらに観測地点半径を拡大することで予測誤差が低減できた。誤差の低減に効果的な観測地点半径は、ケース A の場合で200 km、ケース B の場合で100 km となった。

ケース A の場合、風速・気圧・気温を組み合わせることで、予測誤差を冬季で27%、その他の季節で32%に低減できた。なお、NN による予測誤差と重回帰分析による予測誤差とは有意な差は見られなかった。

これに対して、ケース B の場合、予測期間の気圧・その前の期間の風速・気圧を組み合わせさせた NN による予測誤差は冬季では15%、春・秋季では20%、夏季では25%まで低減できた。

このように、予測対象期間の気圧を入力データに加えれば半径100 km 以内の範囲の気象データを用いて、より高い精度での風速予測が可能となることが分かった。

なお、予測対象期間の気圧を入力データとして用いたことの意味は、将来、予測対象期間の気圧が予測誤差率0%で予測されることを想定している。現状でも気圧の予測はなされているが、その予測誤差率は約10%である。今後、数%以下になれば、それら気圧の予測値を入力データとして用いることができ、本研究で提案した手法が有効になるものと信じる。

参考文献

(1) 井田:「苫前の風力発電と北海道電力の取組」, 風力エネルギー, Vol.23, No.4, pp.38-48, 1999

- (2) 七原：「海外における風力発電の導入状況と電力システムへの影響」, 電学論 B, Vol.120, No.3, pp.321-324, 2000
- (3) M.C.Alexiadis, et al. : "Wind Speed and Power Forecasting based on Spatial Correlation Models" , IEEE Transactions on Energy Conversion, Vol.14, No.3, September 1999
- (4) Shuhui Li, et al. : "Using Neural Networks to Predict Wind Power Generation" , Solar Engineering-1997, pp.415-420, 1997
- (5) 織田 他：「多段型ニューラルネットを用いた日射量予測」, 電学論 B, vol.117, No.8, pp.1146-1151, 1997
- (6) 落合 他：「ニューラルネットワークを用いた気象レーダによる降雨・降雪予測」, 電子情報通信学会誌 D-II, Vol.J81-D-II, No.7, pp.1631-1638, 1998
- (7) 小野田 他：「翌日最大電力需要における最適なニューラルネットワーク構成の決定法」, 電学誌 B, Vol.118, No.5, pp.497-504, 1998
- (8) 灰田 他：「電力需要予測」, J.IEE Japan, Vol.117, No.9, pp.596-599, 1997
- (9) Takashi Hiyama : "Neural Network Based Estimation of Maximum Power Generation from PV Module Using Environmental Information" , IEEE Transaction on Energy Conversion, Vol.12, No.3, September 1997
- (10) 嘉数 他 訳：「ニューラル・コンピューティング ー 上級編ー」, 森北出版株式会社 (1998/11/30), p.113-128
- (11) W.H.Press 他/丹慶 他 訳：「Numerical Recipes in C [日本語版]」, 株式会社技術評論社 (平成 6 年 8 月 25 日), p.282-312
- (12) 喜多一：「ニューラルネットワークの汎化能力」, システム/情報/制御, Vol.36, No.10, pp.625-633, 1992