

階層型ニューラルネットワークを用いた 短時間先の簡易風速予測法

曾利 仁* 安野 卓**

Simple Wind Speed Prediction Method after A Short Time using Hierarchical Neural Network

Hitoshi SORI and Takashi YASUNO

This paper describes a simple wind speed prediction method after a short time using a hierarchical neural network (NN). To reduce the prediction error of the wind speed, deciding a suitable combination of weather informations as the input of the NN is very important. Therefore, we investigate three combinations (Case A, Case B, and Case C) of weather data. Case A is a mean wind speed before the prediction term. Case B is an amount of the the mean wind speed change in addition to the data of Case A. Case C is a mean wind direction in addition to the data of Case B. Some computer simulation results demonstrate the usefulness of the proposed prediction system and the effectiveness of the selection of suitable weather data.

Keywords : Wind Speed Prediction Method, Hierarchical Neural Network, Weather Informations

1 まえがき

1990 年以降、化石燃料の枯渇や地球温暖化問題等によって、無尽蔵でクリーンな自然エネルギーが注目されている。なかでも、風力発電は我が国においても 1990 年代から導入量が急増し、2005 年末で約 100 万 kW に達している。政府としても、2010 年までに 300 万 kW の風力発電導入量を目標としている¹⁾。しかし、風力発電の出力は風速および風向によって大きく変動するため、電力系統と連系された風力発電機が増加した場合の周波数変動等の電力品質に与える影響が懸念されている²⁾。現在は、電力各社が電力系統への風力発電導入量の上限を制限している。

これらの背景を踏まえ、資源エネルギー庁で設置された電力系統連系対策小委員会では、周波数変動対策の一つとして、気象予測に基づく風力発電量予測システムの導入を目標に掲げている。もし、一定期間先の風速を予測することで風力発電出力を事前に把握できれば、電力系統の安定性確保や発電電力の計画的な運用が実現できる。風力発電の導入が進んでいる欧米ではすでに風力発電量予測システムが実用化され、電力系統の安定運用のために風力発電以外の発電源での調整に要する費用が、年間約 60 億円節約できたとの報告もある³⁾。

我が国においては、日本特有の地形の影響で風況が欧米のように安定しておらず、風速・風向の予測は容易でない。しかしながらこれまで、大きく分けて二つのアプローチにより風力発電の出力予測手法の研究・開発が進

められている。一つは、数値予報モデルに基づいて風速を予測し、風力発電機の数学モデルを用いて風力発電の出力を予測する手法である³⁾。この手法は、規則正しく並んだ格子で大気を細かく覆い、格子点における気圧、気温、風速・風向などを世界中から送られてくる気象データを使って予測するものである。このように、数値予報モデルを用いた風速・風向予測では、多くの気象観測データや地形因子などを用い、流体力学や物理学をベースとした複雑な運動方程式を解析する必要がある。それゆえ、多くの時間とスーパーコンピュータのような高性能なコンピュータを必要とする。もう一つのアプローチは、気象庁および気象観測装置から得られる気象データのみを用いて、ニューラルネットワーク（以下、NN と略す。）^{4, 5)}やファジィ推論といったソフトコンピューティング手法を用いたものである。ソフトコンピューティング手法は、風速・風向データなどの気象データを入力情報として与えるだけで、複雑な運動方程式の解析や計算を必要とせず、風速・風向を予測するのが特徴である。近年、NN を用いた風速予測法に関する研究も幾つか行われている^{6, 7, 8)}。

筆者らもこれまで、対象地点における一定時間先の風速を、対象地点の局地的気象データを用いた階層型 NN により予測する手法を提案してきた⁹⁾。本論文では、気象庁から 10 分毎に提供される気象データのみを用いて、簡単な構造の階層型 NN により短時間先（ここでは 10 分先）の風速を予測するシステムを提案している。また、ソフトコンピューティング手法を用いた場合にこれまであまり検討されていなかった予測精度についても、定量的な評価と考察を行っている。さらに、風速の予測

原稿受付 平成 19 年 8 月 31 日

*情報工学科

**徳島大学大学院 ソシオテクノサイエンス研究部

精度向上のために必要となる、階層型 NN の入力として与えるべき気象データの適切な組み合わせについても考察している。

2 風速予測システム

2.1 システム構成

Fig.1 に、階層型 NN を用いた簡易風速予測システムの構成図を示す。本予測システムは、気象庁から提供される気象データから、階層型 NN により現時点 x から 10 分先までの平均風速の予測値 $\hat{v}_a(x+1)$ を出力する。予測期間は、予測した風速情報の利用目的によって任意に設定できるが、ここでは、風速・風向データが 10 分毎に提供されることから、予測期間を 10 分に設定している。




Fig.1 Proposed wind speed prediction system

Fig.1 に示すように、用いた階層型 NN は中間層 1 層の 3 層型であり、各層のユニット数は以下になっている。


入力層ユニット数 : 気象データ数

中間層ユニット数 : 入力層ユニット数と同数


出力層ユニット数 : 1

NN を用いた時系列予測では、NN でダイナミクスを表現するための工夫が必要である。その方法には、Fig.2(a), (b) に示すように、NN の入力として過去の時系列情報や時間微分情報を与え、NN を単なる静的な写像関数として用いる方法と、NN の出力を NN の入力にフィードバックすることにより、NN (この場合は特に、リカレント NN と呼ぶ) 自体でダイナミクスを表現する方法がある。本論文では前者の方法に基づいて、Fig.1 に示すように、NN の入力として気象データの過去の時

系列情報と時間微分 (差分) 情報を与えることにより、階層型 NN で静的な写像関数を学習し、風速の時系列予測を行う。



(a) Temporal derivation NN



(b) Recurrent NN

Fig.2 Dynamics representation by NN

2.2 気象データ

一般に、風速予測に相関のある気象データとしては、風速、風向、気圧、気温などが考えられる。これらの気象データは、気象庁より容易に入手可能である。本論文では、簡易の風速予測システムの実現を目的とし、風速予測に直接関係のある風速および風向データを気象データとして用いている。風速および風向は、風力発電機導入時に必ず設置される風速・風向計から容易に得られることができる。そのため、これら気象データは、提案する風速予測システムの実用化には有用な気象情報といえる。また、風のダイナミクスを提案する風速予測システムで表現するために、風速および風向データから予測時刻までに得られる以下に示す 14 の気象データを生成し、それを階層型 NN の入力情報として与える。

Fig.3 に NN の入力データと予測期間の関係を示す。図中、例えば x は 12 月 31 日の 23:50~1 月 1 日の 0:00 の 10 分間を表し、 $x+1$ は 1 月 1 日の 0:00~1 月 1 日の 0:10 までの 10 分間を表している。

- 現時点から 50 分前までの 10 分間平均風速

$$v_a(x-m) \quad (m=0\sim4) \quad (1)$$

- 現時点から 50 分前までの 10 分間平均風速変化量

$$\Delta v_a(x-m) = v_a(x-(m+1)) - v_a(x-m) \quad (m=0\sim 3) \quad (2)$$

- 現時点から 50 分前までの 10 分間平均風向

$$d_a(x-m) \quad (m=0\sim 4) \quad (3)$$

ここで、 m はサンプリング数を表している。

また、入力データの数と組み合わせが予測精度にどの程度影響を与えるかを確認するために、以下に示す 3 つの入力データの組み合わせを検討している。

Case A : 平均風速

(入力データ総数 : 5)

Case B : 平均風速, 平均風速変化量

(入力データ総数 : 9)

Case C : 平均風速, 平均風速変化量, 平均風向

(入力データ総数 : 14)

本論文では、風力発電機を多く設置している北海道留萌市の留萌測候所で測定された特別値データ（アメダスデータ）を使用している。




Fig.3 Relation between input data and prediction term

2.3 NN の学習アルゴリズム

Fig.4 に、ニューラルネットワークの構成要素であるニューロンのモデルを示す。図中、 net_j : (4) 式で表されるニューロン j への入力の総和、 u_{ji} : 前層ニューロン i とニューロン j の間の重み、 x_i : 前層ニューロン i の出力、 I : 前層ニューロン数、 y_j : (5) 式で表されるニューロン j の出力、 $f(net_j)$: (6) 式で表されるシグモイド関数を表している。

$$net_j = \sum_{i=1}^I u_{ji} x_i \quad (4)$$

$$y_j = f(net_j) \quad (5)$$

$$f(net_j) = \frac{1}{1 + \exp(-net_j)} \quad (6)$$

階層型 NN の学習は、逆誤差伝播（BP : Back Propagation）法により行う。




Fig.4 Neuron model

まず、入力情報が入力層に入力され、それが中間層を経て出力層に伝達される。そして、出力層ニューロンの出力 $\hat{v}_a(x+m)$ は教師信号 $v_a(x+m)$ と比較され、(7) 式で二乗誤差を定義する。

$$E = \frac{1}{2} \{v_a(x+m) - \hat{v}_a(x+m)\}^2 \quad (7)$$

ここで、出力層ニューロンの出力 $\hat{v}_a(x+m)$ は、

$$\hat{v}_a(x+m) = f_o(net_o) \quad (8)$$

出力層ニューロンへの入力の総和 net_o は、

$$net_o = \sum_{j=0}^J v_j z_j \quad (9)$$

$f_o(net_o)$ は出力層ニューロンの入出力関数、 v_j は出力層ニューロンの重み、 z_j は中間層ニューロン j の出力、 J は中間層ニューロン数である。

次に、最小二乗平均の原理を利用して、出力層ニューロンの重み v_j の更新量 Δv_j を (10) 式より求める。

$$\begin{aligned} \Delta v_j &= -\eta \frac{\partial E}{\partial v_j} \\ &= -\eta \frac{\partial E}{\partial \hat{v}_a(x+m)} \frac{\partial \hat{v}_a(x+m)}{\partial net_o} \frac{\partial net_o}{\partial v_j} \\ &= \eta \{(v_a(x+m) - \hat{v}_a(x+m))\} f'_o(net_o) z_j \end{aligned} \quad (10)$$

ここで、 η は正の定数である。

中間層ニューロンの重み u_{ji} の更新量 Δu_{ji} は、中間層ニューロン j の出力 z_j 、中間層ニューロン j への入力 net_{mj} がそれぞれ

$$z_j = f_m(net_{mj}) \quad (11)$$

$$net_{mj} = \sum_{i=1}^I u_{ji} y_i \quad (12)$$

と表されることを考慮すると、

$$\begin{aligned} \Delta u_{ji} &= -\eta \frac{\partial E}{\partial u_{ji}} \\ &= -\eta \frac{\partial E}{\partial \hat{v}_a(x+m)} \frac{\partial \hat{v}_a(x+m)}{\partial net_o} \frac{\partial net_o}{\partial z_j} \frac{\partial z_j}{\partial net_{mj}} \frac{\partial net_{mj}}{\partial u_{ji}} \\ &= \eta \{(v_a(x+m) - \hat{v}_a(x+m))\} f'_o(net_o) v_j f'_m(net_{mj}) y_i \end{aligned} \quad (13)$$

と求めることができる．ここで、 $f_m(net_{mj})$ は、中間層ニューロンの入出力関数、 y_i は入力層ニューロン i の出力、 I は入力層のニューロン数である．

以上の操作を設定回数繰り返すことにより、(7) 式で定義した二乗誤差は減少し、NN の学習は完了する．

3 学習結果

入力データの組み合わせ Case A～Case C のそれぞれに対し、留萌測候所で 2000 年～2004 年に測定された 10 分間平均風速を教師データとして 10 万回学習した．その結果を二乗誤差の推移として Fig.5 に示す．Case A の場合、二乗誤差は約 6 万回で約 0.40 まで減少し、一定値に収束しており、Case B, C の場合、二乗誤差は約 8 万回で約 0.36 まで減少し、一定値に収束していることがわかる．

また、この収束値の違いが風速予測誤差にも現れており、Case A の場合、NN では十分学習できないことが確認できる．つまり、平均風速のみを入力とする NN では、風のダイナミクスを十分表現できないと考えられる．よって、今回提案するシステムのように NN でダイナミクスを表現するためには、Fig.2 で示すシステム構成を用いることが必要であると確認できる．





Fig.5 Response of learning error


4 風速予測結果

学習によって得られた重み係数を用いて、学習時の教師データには使っていない 2005 年 1 月～12 月における 10 分ごとの平均風速の予測を行った．

Fig.6(a), (b)～Fig.8(a), (b) は、各入力データの組み合わせごとに 2005 年 2 月における 10 分間ごとの平均風速の予測結果と予測誤差を示している．これらの結果から、いずれの入力データの組み合わせにおいても、実測値と予測値はよく一致していることがわかる．しかし、風速の時間的変化が大きいときや風速そのものが大きいときに、予測誤差が顕著に現れていることもわかる．予測期間における最大絶対予測誤差は、Case A : 5.35m/s, Case B : 5.47m/s, Case C : 6.66m/s となり、平均予測誤差率では Case A : 17.50%, Case B : 15.65%, Case




(a) Prediction results of wind speed (February, 2005)




(b) Prediction error of wind speed (February, 2005)

Fig.6 Prediction results (Case A)




(a) Prediction results of wind speed (February, 2005)




(b) Prediction error of wind speed (February, 2005)


Fig.7 Prediction results (Case B)




(a) Prediction results of wind speed (February, 2005)



(a) Case A



(b) Prediction error of wind speed (February, 2005)



(b) Case B


Fig.8 Prediction results (Case C)

C : 16.01%であった。Case A は、他の入力パターンと比べて最大絶対予測誤差を最も小さく抑えているものの、平均して予測誤差が大きく現れることが平均予測誤差率から確認できる。

Fig.9 は、Case A～Case C のそれぞれに対し、2005 年 2 月の風速予測時における実測値と予測値の誤差分布を示している。この結果から、誤差が $-1\text{m/s} \sim 1\text{m/s}$ に収まる予測値が、Case A : 70.24%, Case B : 73.12%, Case C : 73.39%を占めており、いずれの入力データの組み合わせにおいても予測精度が十分高いことがわかる。しかし、Case A の場合は、誤差が 2m/s 以上となる総数が他の入力データの組み合わせより多くなり、また、Case C の場合は誤差が -2m/s 以上となる総数が他の入力パターンより多くなることがわかる。

Fig.10 は、Case A～Case C のそれぞれに対し、2005 年 1 月～12 月までの 1 年間の平均風速予測時における実測値と予測値の誤差分布を示している。誤差が $-1\text{m/s} \sim 1\text{m/s}$ に収まる予測値が、Case A : 78.72%, Case B : 80.53%, Case C : 78.85%を占めることから、ニューラルネットワークの入力に Case B を用いた場合が、年間を通じて予測精度が最も高いことがわかる。

最後に、予測誤差を定量的に評価するために、(14) 式で定義される二乗平均平方根誤差: RMSE (Root Mean



(c) Case C

Fig.9 Distribution of prediction errors (February, 2005) Square Error) を用いる。RMSE は予測誤差の標準的な大きさを示す指数として用いられ、RMSE の値が 0 に近いほど予測精度が高いことを示している。

$$RMSE = \sqrt{\frac{1}{n} \sum_{m=1}^n \{\hat{v}_a(x+m) - v_a(x+m)\}^2} \quad (14)$$

ここで、 n : データ数、 $\hat{v}_a$: 予測値、 v_a : 実測値、 x : 時間である。

Fig.11 は、Case A～Case C のそれぞれに対し、2005 年 1 月～12 月の 1 年間の RMSE の推移を示している。1 年間の RMSE 平均値は、Case A : 0.873, Case B : 0.828, Case C : 0.862 となり、どの月に対しても、Case B の RMSE が最も小さいことがわかる。8 月の RMSE は、入力データの組み合わせによって大きく異なっ

いるが、これは2005年8月の平均風速が、学習時の教師データとして用いた2000年～2004年の各8月の平均風速より若干低かったこと、また、風速の変動が他年と比べて激しいことなどが要因で、ニューラルネットワークの汎化能力では十分対応できなかったものと考えられる。しかし、そのような場合においてもCase BはRMSEの値が最も小さく、予測誤差を小さく抑えられていたといえる。




Fig.10 Distribution of prediction errors for one year




Fig.11 Comparison of RMSE

5 まとめ

本論文では、予測対象地点近傍で観測される気象データのみを用いて、階層型ニューラルネットワークにより10分先の平均風速を予測する手法を提案した。また、予測誤差低減に有効な気象データの組み合わせについて、Case A: 現時点から50分前までの10分間平均風速、Case B: 現時点から50分前までの10分間平均風速、現時点から50分前までの10分間平均風速変化量、Case C: 現時点から50分前までの10分間平均風速、現時点から50分前までの10分間平均風速変化量、現時点から50分前までの10分間平均風向の3つの場合について検討した。

まず、留萌測候所で2000年から2004年の各月に測定された10分間平均風速と平均風向を教師データとして用いて学習を行った。次に、学習により得られた重み係数を用いて、2005年1月～12月における10分間ごとの平均風速の予測を行った。その結果、1年間のRMSE平均値は、Case A: 0.873, Case B: 0.828, Case C: 0.862となり、風速予測システムに平均風速と風速変化量の気象データを入力することで予測精度の向上が確認できた。

今後は、更なる予測精度向上のために、気象データに新たなデータを加えることが考えられる。また、本研究手法は10分先の風速予測を対象としているため、電力会社が実施している経済負荷配分制御に組み込むことは難しい。そのため、この本手法を利用した1時間先～数日先までの風速が予測できるように、システムを拡張することが望まれる。

謝辞

本研究は、文部科学省および日本学術振興会の平成19年度科学研究費補助金と、八雲環境科学振興財団の平成18年度環境研究助成により実施したものである。ここに謝意を表す。

参考文献

- 1) 安藤晴彦:「風力発電の現状と展望」, 第28回風力エネルギー利用シンポジウム, pp.1-13, 2006
- 2) 甲斐隆章:「風力発電の系統連系について」, 電気学会誌, Vol.124, No.1, pp.27-31, 2004
- 3) 荒川忠一:「気象予測に基づく風力発電量予測システムの開発」, 第28回風力エネルギー利用シンポジウム, pp.51-57, 2006
- 4) 萩原将文:ニューロ・ファジィ・遺伝的アルゴリズム, 産業図書, 1994
- 5) 電気学会: 学習とそのアルゴリズム, 森北出版, 2002
- 6) 見目喜重, 石井弘樹, 滝川浩史, 河本映, 榎原建樹:「広域の気象データを利用した翌日の風速予測」, 太陽エネルギー学会, Vol.27, No.1, pp.85-91, 2001
- 7) Shuhui Li, Donald C. Wunsch, Edgar A. O'Hair, and Michael G. Giesselmann:「Using Neural Network to Estimate Wind Turbine Power Generation」, *IEEE*, Vol.16, No.3, pp.276-282, 2001
- 8) P.Flores, A.Tapia, and G.Tapia:「Application of a control algorithm for wind speed prediction and power generation」, *Renewable Energy*, Vol.30, No.5, pp.523-536, 2004
- 9) 曾利仁, 安野卓:「階層型ニューラルネットワークを用いた短時間先風速予測」, 平成19年電気学会全国大会, No.7-032, p.48, 2007