

FIR 型ニューラルネットワークによる風速の予測

松坂知行*・降矢順治**

Wind Speed Prediction by Using FIR Neural Network

Tomoyuki MATSUZAKA and Jyunji FURUYA

Abstract

Effective prediction of wind speed and direction is the basis for a wind energy conversion system aiming at economical fuel control of a stand alone wind energy conversion system. There are several methods for prediction of time step signal such as statistical approach, linear estimation and Kalman filter approach. However, it is difficult to treat such non-linear prediction problems as wind speed estimation with conventional methods. This paper presents a prediction method using FIR type neural networks, and that the neural networks perform better short-term prediction of wind speed.

キーワード：ニューラルネットワーク，風速予測，風力発電 (neural network, wind speed prediction, wind energy)

1 はじめに

風力エネルギーは、環境を汚染せずまた資源が枯渇しないため、欧州、米国をはじめとして近時急速に導入が進んでいる。また、我が国においても系統連系および発生電力の売買電に関する技術的基準、導入時の補助金制度の法的整備などに伴い、自治体、電力会社、民間企業を中心にして導入の気運が盛んになってきた。ところで風力エネルギーを導入する際最初に検討すべき事項は、風力発電を導入しようとする対象地域の風力エネルギーの賦存量である。風力エネルギーの賦存量の評価尺度としては、通常は年間の平均的な賦存量が用いられ、当該地域にどの程度年平均賦存量が存在するかが問題になる。当該期間の平均的な賦存量の推定方法として挙げられる代表的な手法は、WASP¹⁻³⁾、AVENUである。一方、既存電力系統と有機的に連携運転するためには、賦存量の時系列的な変化に着目する必要がある。特に容量の小さい独立系統で大容量の風力発電を導入する場合には、風力エネルギーの時系列的な変動を事前に把握しておき、既存電力系統と連携して運転しないと系統電圧、周波数に影響を与えることになる。このような影響を事前に予測し、系統電圧、周波数に与える影響を少なくするためには、風力エネルギーの時系列的な予測手法の研究が必要である。

このような観点から近時風力エネルギーの時系列予測手法に関する研究が行われ、これらは Kalman Filter を用いたもの⁴⁾、ARMA モデルを用いたもの⁴⁾、ニューラルネットワークを用いたもの⁵⁻⁹⁾などである。しかし、いずれも予測精度に関して十分定量的な検討が行われていな

い。本稿もニューラルネットワークを用いたものであるが、風速の前処理にウェーブレット変換を適用し、生データの不規則雑音を除いてニューラルネットワークを学習させたところ、予測能力が極めて向上したので報告する。

2. ニューラルネットワーク

予測に用いるニューラルネットワークとしては、大きく分けて内部に記憶をもたないフィードフォワード型、内部に記憶をもつリカレント型がこれまで用いられてきた。本稿で用いるニューラルネットワークも内部に記憶をもってはいるが、リカレント型とは異なる FIR 型 (Finite Impulse Response) を提案している¹⁰⁾。

2.1 FIR 型ニューラルネットワーク

図 1 に FIR 型ニューラルネットワークの構成を示す。入力層に入る信号 $x(n)$ ($n=1, 2, \dots, N$) は遅延要素 D で結ばれ、各遅延要素の出力は中間層の重みを介して中間層の関数の入力となる。また、中間層の関数の出力は、遅延要素 D と中間層と出力層の重みを介して出力層の関数の入力となる。FIR 型ニューラルネットワークは当然多層、多入力構成をとることができるが、風速の予測に関しては入力層、中間層、出力層の 3 層があれば充分であるので、以下 3 層から成る FIR 型ニューラルネットワークの順方向と逆方向の計算方法を述べる。

(1) 順方向の計算

(a) 出力層

内部ポテンシャル

$$u^{(o)} = \sum_{j=0}^L W_j^{(o),(h)} X^{(h)} z^{-j} + b^{(o)} \dots\dots\dots (1)$$

平成 11 年 12 月 21 日受理

* 八戸工業大学 システム情報工学科 教授

** 城西国際大学 経営情報工学科 教授

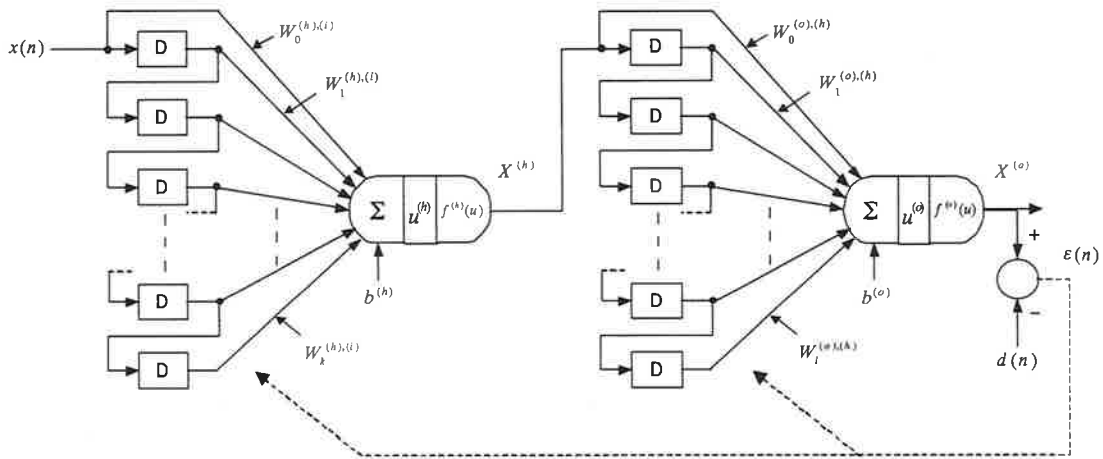


図1 FIR型ニューラルネットワークの構成

出力

$$X^{(o)} = f^{(o)}(u^{(o)}) \dots\dots\dots (2)$$

ここで $f^{(o)}$ は線形ニューロン, $W_j^{(o),(h)}$ は中間層と出力層間の重み, $b^{(o)}$ はバイアス, z^{-1} は遅れ演算子である。

(b) 中間層

内部ポテンシャル

$$u^{(h)} = \sum_{j=0}^k W_j^{(h),(i)} x(n) z^{-j} + b^{(h)} \quad (n=1, 2, \dots, N) \dots\dots (3)$$

出力

$$X^{(h)} = f^{(h)}(u^{(h)}) \dots\dots\dots (4)$$

ここで $f^{(h)}$ はシグモイドニューロン, $W_j^{(h),(i)}$ は入力層と中間層間の重み, $b^{(h)}$ はバイアスである。シグモイド関数 $f^{(h)}$ は, 下限 a , 上限 b を設定できるようにし

$$f^{(h)}(u^{(h)}) = a + \frac{(b-a)}{1 + \exp(-u^{(h)})} \dots\dots\dots (5)$$

の形としている。図2にシグモイド関数 $f^{(h)}$ を示す。

(2) 逆方向の計算

ここでは逆誤差伝播法による計算を行うための逆方向計算方法を述べる。出力層の出力 $X^{(o)}$ と教師信号 $d(n)$ との二乗誤差 E は

$$\left. \begin{aligned} E &= \frac{1}{2} \sum_{n=1}^{N_p} (d(n) - X^{(o)})^2 \\ &= \frac{1}{2} \sum_{n=1}^{N_p} e_n^2 \end{aligned} \right\} \dots\dots\dots (6)$$

ここで N_p は教師データのパターンの数である。

(a) 出力層の重みの更新

出力層の重み $W_k^{(o),(h)}$ の更新は以下のようにして行われる。




図2 シグモイド関数

$$\left. \begin{aligned} \Delta W_k^{(o),(h)} &= -\alpha \frac{\partial E}{\partial W_k^{(o),(h)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(o)}} \cdot \frac{\partial u^{(o)}}{\partial W_k^{(o),(h)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(o)}} \cdot X^{(h)} z^{-k} \end{aligned} \right\} \dots\dots\dots (7)$$

ここで α は学習係数である。いま最急降下法を用いて $W_k^{(o),(h)}$ の更新を行う。さらに

$$\left. \begin{aligned} \delta^{(o)} &= -\frac{\partial E}{\partial u^{(o)}} \\ &= -\frac{\partial E}{\partial X^{(o)}} \cdot \frac{\partial X^{(o)}}{\partial u^{(o)}} \\ &= (d(n) - X^{(o)}) f'^{(o)}(u^{(o)}) \end{aligned} \right\} \dots\dots\dots (8)$$

のようにおく。よって

$$\Delta W_k^{(o),(h)} = \alpha \delta^{(o)} X^{(h)} z^{-k} \dots\dots\dots (9)$$

となる。計算の安定化のため慣性項 $\gamma \Delta W_k^{(o),(h)}|_{old}$ を加えると

$$\Delta W_k^{(o),(h)} = \alpha \delta^{(o)} X^{(h)} z^{-k} + \gamma \Delta W_k^{(o),(h)}|_{old} \dots\dots\dots (10)$$

となる。したがって更新則は以下ようになる。

$$W_k^{(o),(h)}|_{new} = W_k^{(o),(h)}|_{old} + \Delta W_k^{(o),(h)} \dots\dots\dots (11)$$

(b) 中間層の重みの更新

中間層の重み $W_k^{(h),(i)}$ の更新は以下のようにして行われる。

$$\left. \begin{aligned} \Delta W_k^{(h),(i)} &= -\alpha \frac{\partial E}{\partial W_k^{(h),(i)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(h)}} \cdot \frac{\partial u^{(h)}}{\partial W_k^{(h),(i)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(h)}} \cdot x(n)z^{-k} \end{aligned} \right\} \dots\dots\dots (12)$$

ここで以下のようにおく。

$$\left. \begin{aligned} \delta^{(h)} &= -\frac{\partial E}{\partial u^{(h)}} \\ &= -\frac{\partial E}{\partial u^{(o)}} \cdot \frac{\partial u^{(o)}}{\partial X^{(h)}} \cdot \frac{\partial X^{(h)}}{\partial u^{(h)}} \\ &= f'(u^{(h)})\delta^{(o)} \sum_{j=1}^l W_j^{(o),(h)} z^{-j} \end{aligned} \right\} \dots\dots\dots (13)$$

よって

$$W_k^{(h),(i)} = \alpha \delta^{(o)} \cdot x(n)z^{-k} \dots\dots\dots (14)$$

となり、慣性項 $\gamma \Delta W_k^{(o),(h)}|_{old}$ を加えると以下のようなになる。

$$\Delta W_k^{(h),(i)} = \alpha \delta^{(o)} \cdot x(n)z^{-k} + \gamma \Delta W_k^{(o),(h)}|_{old} \dots\dots\dots (15)$$

よって更新則は以下ようになる。

$$W_k^{(h),(i)}|_{new} = W_k^{(h),(i)}|_{old} + \Delta W_k^{(h),(i)} \dots\dots\dots (16)$$

(c) 出力層のバイアスの更新

$$\left. \begin{aligned} \Delta b^{(o)} &= -\alpha \frac{\partial E}{\partial b^{(o)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(o)}} \cdot \frac{\partial u^{(o)}}{\partial b^{(o)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(o)}} \end{aligned} \right\} \dots\dots\dots (17)$$

$$\left. \begin{aligned} \delta^{(o)} &= -\frac{\partial E}{\partial u^{(o)}} \\ &= -\frac{\partial E}{\partial X^{(o)}} \cdot \frac{\partial X^{(o)}}{\partial u^{(o)}} \\ &= (d(n) - X^{(o)})f'(u^{(o)}) \end{aligned} \right\} \dots\dots\dots (18)$$

よって

$$\Delta b^{(o)} = \alpha \delta^{(o)} + \gamma \Delta b^{(o)}|_{old} \dots\dots\dots (19)$$

$$b^{(o)}|_{new} = b^{(o)}|_{old} + \Delta b^{(o)} \dots\dots\dots (20)$$

(d) 中間層のバイアスの更新

$$\left. \begin{aligned} \Delta b^{(h)} &= -\alpha \frac{\partial E}{\partial b^{(h)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(h)}} \cdot \frac{\partial u^{(h)}}{\partial b^{(h)}} \\ &= -\alpha \frac{\partial E}{\partial u^{(h)}} \end{aligned} \right\} \dots\dots\dots (21)$$

$$\left. \begin{aligned} \delta^{(h)} &= -\frac{\partial E}{\partial u^{(h)}} \\ &= -\frac{\partial E}{\partial u^{(o)}} \cdot \frac{\partial u^{(o)}}{\partial X^{(h)}} \cdot \frac{\partial X^{(h)}}{\partial u^{(h)}} \\ &= f'(u^{(h)})\delta^{(o)} \sum_{j=1}^l W_j^{(o),(h)} z^{-j} \end{aligned} \right\} \dots\dots\dots (22)$$

$$\Delta b^{(h)}|_{new} = \alpha \delta^{(h)} + \Delta b^{(h)}|_{old} \dots\dots\dots (23)$$

$$b^{(h)}|_{new} = b^{(h)}|_{old} + \Delta b^{(h)} \dots\dots\dots (24)$$

2.2 学習データと教師データ

本稿では時系列データ

$x(n), x(n-1), x(n-2), \dots, x(n-k)$ を用いて風速の予測値を求める。学習データは予測のステップに依存し、 m ステップ先を予測するための学習データとしては

$$x(n), x(n-m), x(n-2m), \dots, x(n-km)$$

という飛び飛びの値を用いる。この理由は連続的な過去の時系列データよりも、 m ステップで飛び飛びの値を用いた方がより予測精度が高いことが分かったためである。これに対する教師データは $x(n+m)$ である。なお k の値は試行錯誤的に決定する。

2.3 ニューラルネットワークの計算手順

ニューラルネットワークの全体の計算手順は以下のようになる。

- (i) 生データ $x(n)$ ($n=1, 2, \dots, N_p$) を読む。
- (ii) 予測ステップ m , 下限 a , 上限 b を決める。
- (iii) 予測ステップ m による学習データ, 教師データを決める。
- (iv) (1)~(5) 式を用いて前方向の計算を行う。
- (v) 教師データ $d(n)=x(n+m)$ とニューラルネットワークの出力 $X^{(o)}$ との差 $\epsilon(n)$ を基にして, (6)~(24) 式を用いて逆方向の計算を行う。
- (vi) 二乗誤差 E が設定値以下になるかまたは教師データが無くなるまで, (iv)~(v) を繰り返す。

3. 信号の前処理

本稿では対象とする信号として風速を用いる。ところで風速は不規則な雑音を含んでいるので、生データを学習データや教師データとしてそのまま用いると、ニューラルネットワークがうまく学習されない。そこで何らかの前処理が必要となる。本稿ではウェーブレット変換のノイズ除去特性に着目し、前処理の方法としてウェーブレット変換を用いることにした。

信号をウェーブレット変換し、展開係数を比べると、真の信号の展開係数の絶対値は、ほとんどの場合、ノイズの展開係数の絶対値より大きい。したがって、適当なしきい値を定めて、そのしきい値より小さい展開係数を0

にして、再構成すればノイズ信号の除去された信号が再構成できる。しきい値の決定法には種々提案されているが、最も簡単なものは次式で示される。

$$T = \sigma \sqrt{2 \ln N_p} \dots\dots\dots (25)$$

ここで σ はノイズの分散の平方根、 N_p は信号のサンプル数である。本稿ではDaubechiesの数列 $N=2$ のウェーブレット変換を用いている。

したがって前処理の手順は以下のようになる。

- (i) 信号を入力 ($N_p=2^L$) する。
- (ii) 信号をレベル1~ J ($J < L$) まで高速ウェーブレット変換する。
- (iii) 絶対値がしきい値 T より小さい展開係数を0にする。
- (iv) 高速ウェーブレット逆変換し、信号を時間領域に戻す。

4. ニューラルネットワークによる風速の予測結果

信号としては竜飛ウインドパークで1996年7月に採取された10分間平均の風速を用いた。30日で4,320個のサンプル数になるので、これを半分に分け $N=2,048$ とした。また前半の半分でニューラルネットワークを学習させ、後半の半分で汎化能力の検証に用いている。また汎化能力の検証には同じ年の1996年1月のデータも併用している。

4.1 3階層ニューラルネットワーク (中間層シグモイド, 出力層線形ニューロン)

(1) 1ステップ先の風速の予測

中間層の時間遅れ要素の数を5個($k=5$)、出力層の時間遅れ要素の数を4個($l=4$)とした。また、Daubechiesの数列 $N=2$ によるウェーブレット変換で風速の前処理を行った。

図3は適合性の検証を示す。教師信号とネットワーク

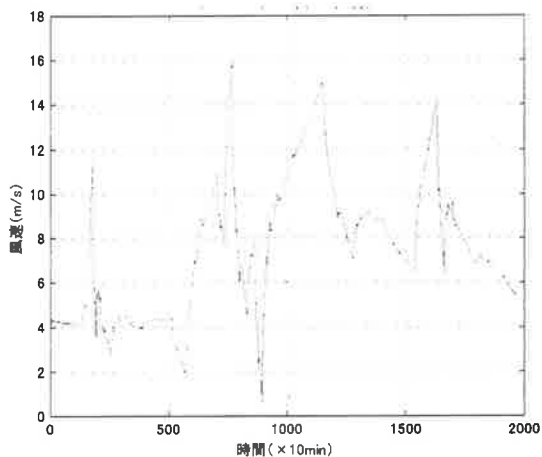


図3 適合性の検証 (3階層, 1ステップ先の予測)

の出力はほとんど重なり、グラフ上では区別ができない。また図4は汎化能力の検証を示す。学習に用いたデータと重ならないデータを用いたものであるが、二つのデータはほとんど重なり、グラフ上では区別ができない。図5は、図4と同じデータによる予測値と教師データを比較したとき誤差の分布を示し、誤差が非常に少ないことが分かる。

図6は時間軸にそった予測誤差を示す。この図から分




図4 汎化能力の検証 (3階層, 1ステップ先の予測)




図5 誤差の分布 (3階層, 1ステップ先の予測)




図6 誤差 (3階層, 1ステップ先の予測)

かるように、風速が急に増加したり減少したりする場合には予測誤差が大きくなる。すなわち勾配の変化が大きいときは予測誤差が大きい。このことは、勾配の変化もニューラルネットワークの入力として加えてやればより予測誤差の小さい予測器が実現できる可能性を示しており、今後検討したいと考える。

(2) 2ステップ先の風速の予測

図7～図9に予測結果を示す。傾向は(1)とほぼ同様であるが、図9に見られるように誤差の分布がばらついている。

(3) 3ステップ先の風速の予測

図10～図12に予測結果を示す。傾向は(1)、(2)と同様であるが、図12に見られるように一層誤差の分布がばらついている。

4.2 2階層ニューラルネットワーク（出力層線形ニューロン）

参考までに2階層ニューラルネットワークで同様な処理を行った。この場合出力層の時間遅れ要素の数を4個 ($l=4$)とした。

(1) 1ステップ先の風速の予測

図13～図15に予測結果を示す。図15を見ると2階層ニューラルネットワークに比較して、誤差のばらつきが大きくなっている。

(2) 2ステップ先の風速の予測

図16～図18に予測結果を示す。

(3) 3ステップ先の風速の予測

図19～図21に予測結果を示す。

以上の結果から

- (a) 同じ階層のニューラルネットワークの場合、予測ステップ数が増えると、適合性の評価尺度を示す二乗誤差は増える。
- (b) 同じ階層のニューラルネットワークの場合、予測ステップ数が増えると、汎化能力の評価尺度を示す平均値（予測値と教師データのずれの平均値）の絶対値が増える。
- (c) 同じ階層のニューラルネットワークの場合、予測ステップ数が増えると、汎化能力の評価尺度を示す標準偏差（予測値と教師データのずれの標準偏差）は増える。
- (d) 3階層と2階層ニューラルネットワークの適合性を比較した場合、3階層の方が二乗誤差が少ない。これは3階層の場合出力層の時間遅れ要素が機能しているためと思われる。
- (e) 3階層と2階層ニューラルネットワークの適合性を比較した場合、3階層の方が平均値の絶対値が少ない。また標準偏差も少ない。これは(d)で述べたことと同様、3階層の場合出力層の時間遅れ要素が機能しているためと思われる。




図7 適合性の検証（3階層，2ステップ先の予測）




図8 汎化能力の検証（3階層，2ステップ先の予測）




図9 誤差の分布（3階層，2ステップ先の予測）

その他図6に見られるように、風速が急に变化する部分での誤差が大きいため、風速の変化分を入力層に入れることが予測誤差を減少させることにつながると考えられるので今後の検討課題としたい。




図10 適合性の検証 (3階層, 3ステップ先の予測)




図13 適合性の検証 (2階層, 1ステップ先の予測)




図11 汎化能力の検証 (3階層, 3ステップ先の予測)




図14 汎化能力の検証 (2階層, 1ステップ先の予測)




図12 誤差の分布 (3階層, 3ステップ先の予測)




図15 誤差の分布 (2階層, 1ステップ先の予測)




図 16 適合性の検証 (2 階層, 2 ステップ先の予測)




図 19 適合性の検証 (2 階層, 3 ステップ先の予測)




図 17 汎化能力の検証 (2 階層, 2 ステップ先の予測)




図 20 汎化能力の検証 (2 階層, 3 ステップ先の予測)




図 18 誤差の分布 (2 階層, 2 ステップ先の予測)




図 21 誤差の分布 (2 階層, 3 ステップ先の予測)

表1 3階層, 2階層ニューラルネットワークの適合性, 汎化能力の比較

予測ステップ	適合性			汎化能力					
	二乗誤差			平均値			標準偏差		
	1ステップ	2ステップ	3ステップ	1ステップ	2ステップ	3ステップ	1ステップ	2ステップ	3ステップ
3階層 ($k=5, l=4$)	0.0099453	0.0369199	0.0767979	-0.0045	-0.0103	-0.0176	0.0888	0.1720	0.2495
2階層 ($l=4$)	0.0126105	0.043442	0.0900773	-8.653e-004	-0.0022	-0.0037	0.1017	0.1884	0.2707




図22 実風速による汎化能力の検証 (3階層, 1ステップ先の予測)




図23 実風速を用いた場合の誤差の分布 (3階層, 1ステップ先の予測)

4.3 実風速を加えた場合の3階層ニューラルネットワークの汎化能力の検証

本節では, 3階層ニューラルネットワークに実風速を加えた場合の汎化能力について検討する。1996年7月のデータをウェーブレット変換し, 3階層ニューラルネットワークを訓練した。また汎化能力の検証は同年1月の実風速を用いた。

図22~図27にこの結果を示す。図22を見ると, 大局的傾向ではほぼ予測が行なわれているが, 細部については予測誤差が現れている。これをグラフ表示したのが図23である。このグラフの形が正規分布に近いことから, 平均値的な予測がほぼ行われているものと考えられる。

予測ステップ数を2, 3と増やした場合も同様な傾向が見られる。表2はこれらを定量的に比較したものである。平均値の絶対値, 標準偏差ともに予測ステップ数が増えるにつれて大きくなっており, 予測誤差が増加することを示している。

5. まとめ

以上 FIR 型ニューラルネットワークを用いた風速の予測について述べたが, 得られた結論をまとめると




図24 実風速による汎化能力の検証 (3階層, 2ステップ先の予測)

(a) 同じ階層のニューラルネットワークの場合, 予測ステップ数が増えると, 適合性の評価尺度を示す二乗誤差は増え, 当然のことながら適合性ははずれる。

(b) 同じ階層のニューラルネットワークの場合, 予測ステップ数が増えると, 汎化能力の評価尺度を示す平均値(予測値と教師データのずれの平均値), 標準偏差(予測値と教師データのずれの標準偏差)は増え, 予測能力

汎化能力					
平均値			標準偏差		
1 ステップ	2 ステップ	3 ステップ	1 ステップ	2 ステップ	3 ステップ
0.0807	0.1790	0.2866	1.6327	2.0976	2.3899




図 25 実風速を用いた場合の誤差の分布(3 階層, 2 ステップ先の予測)




図 27 実風速を用いた場合の誤差の分布(3 階層, 2 ステップ先の予測)




図 26 実風速による汎化能力の検証(3 階層, 3 ステップ先の予測)

は下がって行く。

(c) 3 階層と 2 階層ニューラルネットワークの適合性を比較した場合, 3 階層の方が二乗誤差が少ない。これは 3 階層の場合出力層の時間遅れ要素が機能しているためと思われる。

(d) 風速が急に变化する部分での誤差が大きいことから, 風速の变化分を入力層に入れることが予測誤差を減少させることにつながると考えられる。

(e) 風速予測のニューラルネットワークを訓練する場合, 実風速で訓練すると, 不規則性が大きいため, 訓練がうまく行かない。ウェーブレット変換を用いて, 予め雑音を除いた教師データで訓練すると, ニューラルネットワークがうまく訓練される。

なお本研究は数十分～数時間の短期予測を対象としており, 数日～数十日の中期予測に対しては気象データの活用が必要と考える。今後この分野の研究も目指したいと考えている。

最後に本研究に用いたデータは竜飛ウインドパークで採取されたもので, データの提供を頂いた東北電力に感謝する。また本研究は八戸工業大学プロジェクト研究の援助を受けたものである。

6. 参考文献

- (1) Ib Troen and Erik Lundtang Petersen, "European Wind Atlas", Risoe National Laboratory, 1989
- (2) 松坂, 土屋; "ウインドパークにおける風力エネルギーの賦存量推定", 計測自動制御学会東北支部第 148 回研究集会, No. 148-6, pp. 1-8, 1994.6
- (3) 松坂; "風力エネルギーの賦存量推定プログラム WAsP の誤差要因について", 第 18 回風力エネルギー利用シンポジウム, pp. 152-155, 1996.11
- (4) M.H. Geers; "Short range prediction of wind speeds: a system-theoretic approach", Proc. of EWEC, pp. 594-599, 1984 (Hamburg)
- (5) G.N. Kariniotakis et al; "Wind power forecasting using advanced neural networks models"; IEEE Trans on EC, 99.762-767, Vol. 11, No. 4, 1996
- (6) D.A. Bechrakis et al; "Wind speed prediction using artificial neural networks", Wind Engineering, pp. 287-295, Vol. 22, No. 6, 1998
- (7) G.N. Kariniotakis et al; "A fuzzy logic and a neural network based wind power forecasting mode", Proc. of EU Wind Energy Conf., pp. 596-599, 1996
- (8) 松坂知行; "ニューラルネットによる風速の時系列予

- 測”, 情報システム工学研究所紀要, Vol. 9, pp. 15-20
- (9) 松坂知行; “ニューラルネットワークによる風速の予測能力の検討”, 情報システム工学研究所紀要, Vol. 10, pp. 9-14
- (10) 降矢順治; “FIR型ニューラルネットワークのシステム同定への応用”, 計測自動制御学会東北支部35周年記念学術講演会予稿集, pp. 43-44, 1999