

## 風況の時系列予測に関する研究 Time Series Prediction of Wind Conditions

○松坂知行\* 星文伸\*\*

○Tomoyuki Matsuzaka, Fuminobu Hoshi

\*八戸工業大学、\*\*ケイヒン・エレクトロニクス

\*Hachinohe Institute of Technology, \*\*Keihin Electronics Technology

キーワード：時系列予測(time series prediction), 風速(wind speed), 風向(wind direction), 風力エネルギー(wind energy)

連絡先：〒031 八戸市大字妙字大開 88-1 八戸工業大学システム情報工学科

松坂 知行 Tel.: (0178)25-3111, Fax.: (0178)25-1691, E-mail: tom@hi-tech.ac.jp

### 1. まえがき

風力エネルギーは環境を汚染せず、資源が枯渇しないという観点から、近時わが国でも導入されてきている。しかし、風力発電は変動する自然風からエネルギーを取り出すため、本質的に出力の持続性と変動を伴う。風速の変化は、一般に予測困難であるため、風力発電機を単独運転する場合には、出力変動に備えてディーゼル発電機を併用運転する必要があり、このため燃料費がかさむ。さらに、系統連系された風力発電機においても、近時ウィンドファーム全体の出力変動の抑制が課題になっている。このような背景から、風速の時系列予測を正確に行うことが可能ならば、離島などの単独系統では、風速に応じてディーゼル発電機の起動停止、出力の予測制御が可能になり燃料費の節約につながる。また、系統連系された風力発電機においても出力の予測制御ができ、出力変動の抑制につながると考えられる。本研究は、このような観点から、10分～1時間先の風速の短期時系列予測を行う方法を研究したものである。風速の

短期予測に関しては、これまで、Kalmanフィルタ<sup>1)</sup>を用いる予測する方法、統計的な手法で予測する方法、<sup>1)</sup>ニューラルネットワークを用いる方法<sup>2)-8)</sup>などが研究されてきた。しかしながら、未だ予測精度の定量的な評価が明確に報告されていない。本研究は、ニューラルネットワークを用いて風況の時系列予測を行う方法を研究し、風向と風速を併用することにより予測精度が向上することが分かったので報告する。

### 2. 風況データ

風況データの採取は、八戸港湾のポートアイランド(2003年11月～2004年10月)と洋上の中央防波堤(2004年2月～2004年10月)において行った。ポートアイランドでは、地上高20m、30m、40m、中央防波堤では海面上15m、24mの高さに風況観測機器を設置した。前者は沿岸の風況データの採取を目指し、後者は洋上の風況データの採取を目的としたものである。風況観測機器としては、観測用に標準的に用いられているNRG製の風向・風速計を使用した。



図1 風速 (地上高 40m)

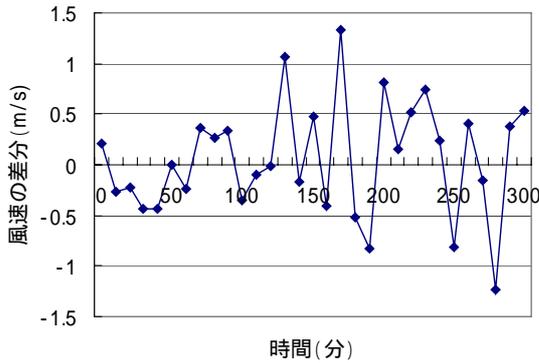


図2 風速の差分 (地上高 40m)

図1は観測された風速の一部である。この生データをそのまま用いると、季節分、トレンド分を含むので統計的な時系列処理に向かない。そこで、風速の差分  $\Delta x(k) = x(k) - x(k-1)$  を用いてこれらの成分を除く。図2はこのようにして処理した風速の差分である。なお、風況観測では、通常 10 分間平均を用いているので、サンプリング時間は 10 分間隔である。また、図3

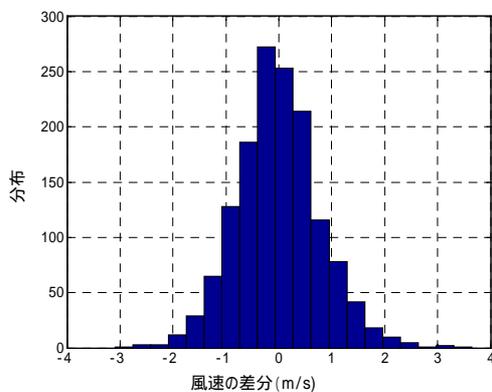


図3 風速の差分の分布

は1ヶ月分のデータ 1439 個の差分を用いてその分布を調べたものである。この結果、平均値は、ほぼ零 (約  $9 \times 10^{-18}$ )、分散 1.0(m/s)の正規分布と見なしうる事が分かった。したがって、時点  $k$  から時点  $k + 1$  の風速の変化は零に留まる確率が高く、大きく変化する確率が低い。さらに、他の月の風速および風向のデータを処理した場合においても同様な分布が得られた。そこで、短期的な時系列の予測が可能であると考えられる。

### 3. 風況の予測手法

風速の短期時系列信号の予測に関して、これまで取り上げられた研究は、統計的モデル<sup>1)</sup>、Kalmanフィルタ<sup>1)</sup>、ニューラルネットワーク<sup>1)-8)</sup>を用いた手法が用いられていた。これらの手法は風況モデルを以下のARモデルで表し、

$$y(k) + a_1 y(k-1) + a_2 y(k-2) + \dots + a_{NA} y(k-NA) = w(k) \quad (1)$$

過去の風速データ  $y(k-1), y(k-2), \dots, y(k-NA)$  を用いてパラメータ  $a_1, a_2, \dots, a_{NA}$  を逐次推定し、次のステップの風速  $y(k)$  を予測するものである。しかし、風速の変化は局所的定常でないため、統計的モデル、Kalman フィルタでは予測精度が良くないことが報告されている。本稿ではニューラルネットワークを用いて予測を試みた。

#### (3.1) 風速のみを用いた場合のニューラルネットワークの構成

本稿で用いたニューラルネットワークを図4に示す。図中の記号は以下の通りである。

$V(k-1)$  : 時点  $k-1$  の風速

$\Delta V(k-1) = V(k-1) - V(k-2)$

$z^{-1}$  : 遅延要素  $NN_j$  : 中間層、出力層の  $j$  番

目のフィードフォワード型ニューロン

$d_j$  : 教師データ  $y_j$  : 出力

学習データは

$$\{\Delta V(k-l), l=1 \dots 4\}, \{\Delta^2 V(k-l), l=1 \dots 4\}$$

教師データは

$$\{\Delta V(k-l+1), l=1 \dots 4\}, \{\Delta^2 V(k-l+1), l=1 \dots 4\}$$

を用いた。

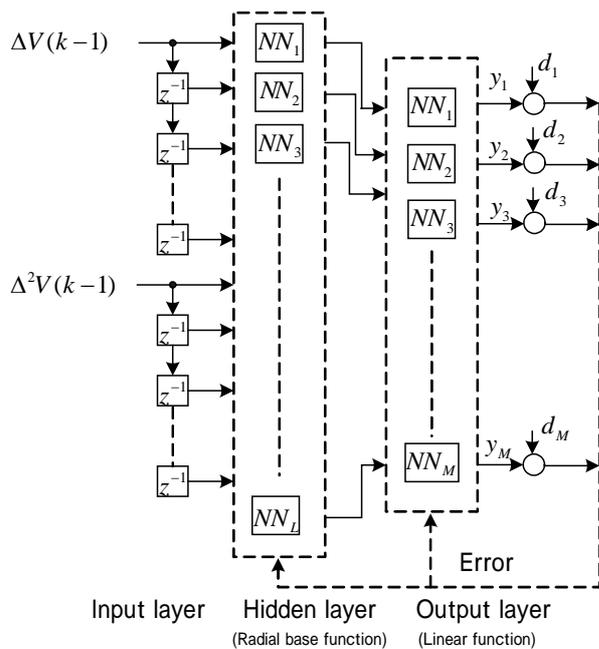


図4 風速のみを用いた場合の予測のニューラルネットワーク

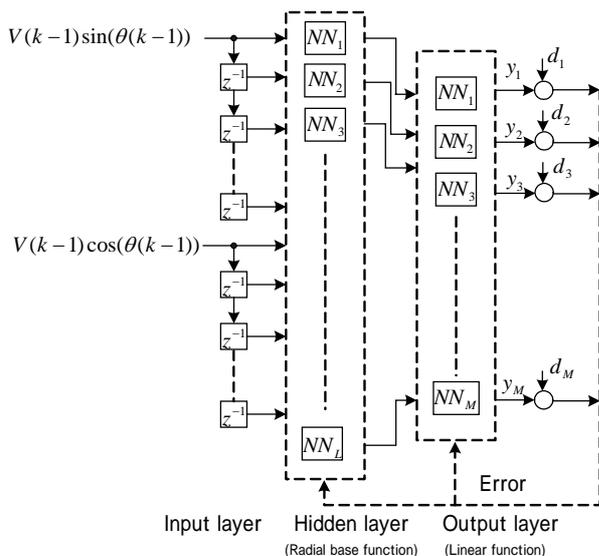


図5 風速と風向を併用した場合の予測のニューラルネットワーク

つぎに、現在の風速は、数ステップ前の風速に依存すると考えられる。そこで、過去の風速を記憶させ、ニューラルネットワークに取り込むため、図示のように遅延要素を用いている。遅延要素の数は、試行錯誤の結果3個あれば十分であることが分かったので、本研究では3個としている。また、中間層の出力関数は、種々試

行した結果、ラジアルベース関数が適当であることが分かった。出力層の出力関数は線形関数である。また、中間層はラジアルベース関数を15個、出力層は線形ニューロン4個用いている。

(3.2) 風速と風向を併用した場合のニューラルネットワークの構成

図5は風速と風向を併用した場合のニューラルネットワークの構成図である。

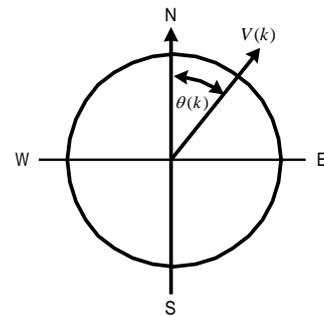


図6 風速と風向の関係

しかし、観測データを検討した結果、平均風速が高いところでは風向が安定し、平均風速が低いところでは風向の変動が大きいことが分かった。つまり、風速の変化と風向の変化が関係することが分かったので、N極を方位の基準とし、風速を正弦成分と余弦成分に分け、学習データとして用いることを試みた。いま、図6のように、 $t$ における風速を $V(t)$ とする。このとき、北を基準として風向の角度を $\theta(t)$ とする。そこでニューラルネットワークの学習データを

$$\{V(k-l)\sin\theta(k-l), V(k-l)\cos\theta(k-l), l=1\cdots 4\}$$

とする。また、教師データとして

$$\{V(k-l+1)\sin\theta(k-l+1)$$

$$V(k-l+1)\cos\theta(k-l+1), l=1\cdots 4\}$$

を用いることにした。中間層はラジアルベース関数を15個、出力層は線形ニューロン8個である。

(3.3) ニューラルネットワークの学習

ニューラルネットワークの学習に際し、ネットワークを1ステップ先の予測を行うように訓練するため、前述のように学習データ、教師デー

タを以下のように与えた。

学習データ

$$V(k-l)\sin(\theta(k-l)) \quad \text{for } l=1,2\cdots 4$$

$$V(k-l)\cos(\theta(k-l)) \quad \text{for } l=1,2\cdots 4$$

教師データ

$$d_j: V(k-l+1)\sin(\theta(k-l+1)) \quad \text{for } l=1,2\cdots 4$$

$$: V(k-l+1)\cos(\theta(k-l+1)) \quad \text{for } l=1,2\cdots 4$$

ここで、正弦成分、余弦成分各 4 個与えているのは、入力正弦成分、余弦成分の遅延要素をそれぞれ 3 個用いているためである。また、逆誤差伝播を行う信号 *Error* は 1 個でも可能であるが、複数個用いて逆誤差伝播した方が、予測結果が良かったので 8 個用いている。

上記の学習データと教師データを与えて、予測を行った結果、中間層のニューロンの数は 15 個程度が適当であることが分った。出力層のニューロン数は、教師データに対応し 8 個である。また、学習アルゴリズムはモーメントムを用いた誤差逆伝播法を用い、時系列信号を 1 個入力するごとに逐次重みを更新する方法を用いた。最初、30 回程度は重みの訓練が十分でないので予測誤差が大きいが、この回数を超えると、重みが訓練され予測誤差が小さくなる。また、逐次学習法は前回までの訓練結果が生かされるので、つぎの時系列信号を入力したときの重み更新に要する計算時間は少なくなり、オンライン処理向きである。

ニューラルネットワークの訓練が進み、予測を行うときは、誤差逆伝播のフィードバックを除き、訓練した重みによって予測の計算を行う。予測計算の終了後、実際の観測データを用いて、重みを更新する。

#### 4. 風速の予測結果

予測結果を時系列で直接比較すると、どの程度の予測信頼度があるかが明確でない。そこで、以下のようにして予測信頼度を表すことにした。まず、横軸に以下のように定義する誤差をとる。

$$\text{誤差} = |(V_R - \hat{V}_m) / V_R| \times 100 (\%)$$

$V_R$  : 風速の観測値

$\hat{V}_m$  : 風速の予測値

縦軸には、上記の誤差以下になるような予測値の累積出現割合をとる。図 7 はこのようにして表した 2004 年 2 月の風速の予測結果を示す。例えば、横軸 20(%)のところで見ると、風速だけで予測した場合は、地上高 40m で約 73(%)であるが、風向と風速を併用した場合は、約 86(%)になり、予測信頼度が 10 数パーセント向上することが分かる。他の観測データでも同様に予測信頼度が高まることが確認された。図 8 は平均風速が小さくなる 4 月の予測である。この場合にも風向と風速を併用した場合の方が予測精度が高いことが分かる。

なお図 9 は実風速と予測風速、図 10 は実風向と予測風向を示す。予測風速は実風速に比較して位相が遅れているが、予測風速は実風向に比較して位相が進んでいることが分かる。

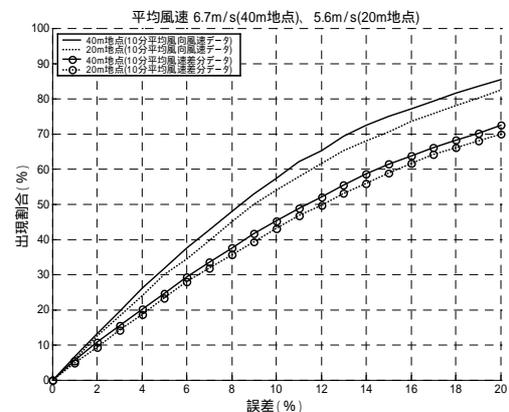


図 7 風速の予測結果(2004 年 2 月)

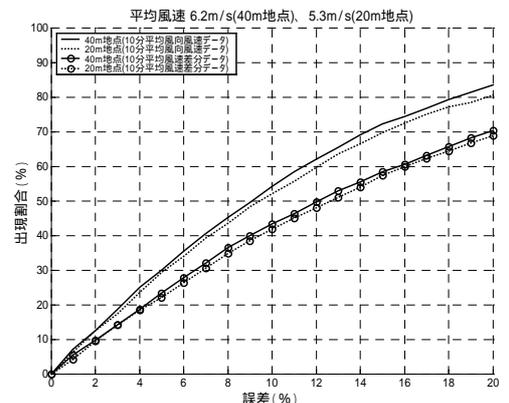


図8 風速の予測結果(2004年4月)

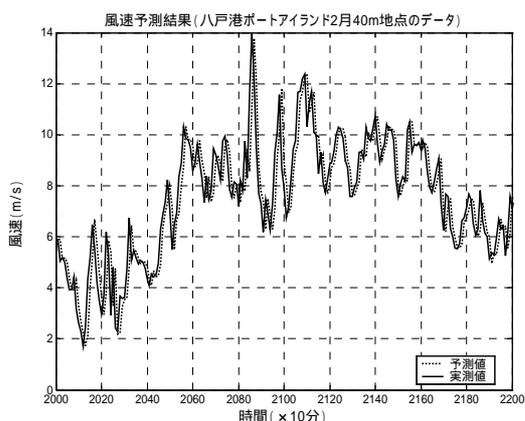


図9 風速の予測結果

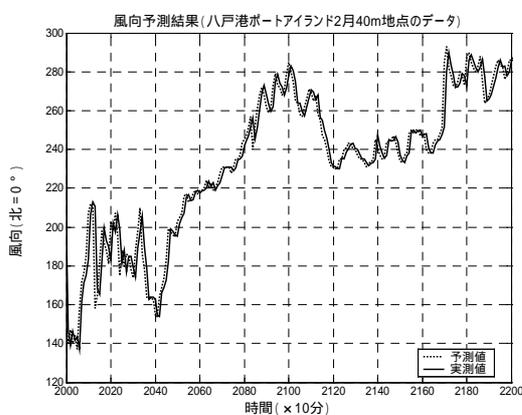


図10 風向の予測結果

## 5. まとめ

これまで、ニューラルネットワークを用いて風速の短期時系列予測を行う場合、風速のみを用いていたが、本稿では風向を併用する方法を提案し、予測信頼度が向上することを示した。風速の時系列予測の精度が上がれば、風力発電の出力変動が予測でき、系統運用の調整電源の確保や風力・ディーゼル併用システムの効率的な運転が実現され、また、燃料の節約にも繋がると思われる。

## 参考文献

1) H.M.Geerts: “Short range prediction of windspeeds: a system theoretic approach”,

European Wind Energy Conference, Hamburg, 1984, pp.594-599

2) H.G.Beyer et al: “Short term prediction of wind speed and power output of a wind turbine with neural networks”, European Wind Energy Conference, Greece, 1994, pp.349-356,

3) G.Kariniotakis et al: “A fuzzy logic and a neural network based wind power forecasting model”, EU Wind Energy Conference, Gortborg, 1996, pp.596-599,

4) G.Kariniotakis et al: “Wind power forecasting using advanced neural networks models”, IEEE Trans on EC, Vol.11, No.4, 1996, pp.762-767

5) 松坂他: 「ニューラルネットワークによる風速の時系列予測」、八戸工業大学情報システム工学研究所紀要、Vol.9、1997、pp.15-20

6) D.A.Bechrakis et al: “Wind speed prediction using artificial neural networks”, Wind Engineering, Vol.22, No.66, pp.287-295

7) 降矢, 西, 松坂: FIR型ニューラルネットワークのシステム同定への応用, 電気学会論文誌 C(電子・システム部門誌), Vol.121-C-3、2001、pp.662-672

8) 星、松坂、木村: FIR/IIR型ニューラルネットワークによる時系列信号の予測に関する研究、八戸工業大学紀要、pp.113-121、Vol.23、2004