

## 自己組織化マップを用いた風況予測に関する研究

### A Study on Wind Forecast using Self-Organizing Map

藤松 誠一郎・鷺見 育亮・植田 拓也・小林 飛鳥・築谷 隆雄\*・副井 裕\*\*

FUJIMATSU Seiichiro, SUMI Yasuaki, UETA Takuya, KOBAYASHI Asuka,  
TSUKUTANI Takao, FUKUI Yutaka

**和文要旨：**現在、パワーアシスト型小型風力発電機が開発されている。我々はより効率の良いパワーアシストを目指し、狭域の気象観測データと自己組織化マップ(SOM)を利用した風況予測の研究を行っている。本論文では予測率向上を目指し、双方向SOMとElman型フィードバックSOMを使用した風況予測の検討を行った。実験では気象観測データや学習データを変更し予測、及び評価を行った。その結果、双方向SOMとElman型フィードバックSOMでの差はごく僅かであった。しかし、学習データに風速差分値を利用することで僅かではあるが予測率が向上することが分かった。また、気象観測データの平均時間幅を狭めることで大幅に予測率が向上することが分かった。

**【キーワード】** 風力発電機、風況、予測、自己組織化マップ

**Abstract :** Now a small wind generator with the power assistance is developed. In order to aim at the power assistance with good efficiency or more, we have studied wind forecast based on the weather observation data in the narrow region using Self-Organizing map (SOM). In this paper, we have examined about the wind forecast to aim at the forecast rate improvement by using both Bi-directional SOM and Elman-type feedback SOM. In our experiment, we have forecasted and evaluated by changing the weather observation data and the learning data. As a result, there is very little difference in both bi-directional SOM and Elman-type feedback SOM. However, It has been understood that the forecast rate improves though it is a little, by using the difference value of the wind velocity for the learning data. Moreover, it has been understood that the forecast rate improves greatly by narrowing the average time width of weather observation data.

**【Keywords】** wind generator, wind condition, forecast, Self-Organizing Map

#### 1. はじめに

現在、新エネルギーが注目されている。新エネルギーの一つである風力は、枯渇の心配がなく、風力を使った発電は二酸化炭素を排出しないクリーンな発電方法として、日本でも安定した風力が得られる沿岸部を中心に大型風力発電機が導入されている。しかし、風力発電はその出力が風力によって大きく変動するという欠点がある。さらに内陸部や山岳部では風力発電機を設置することが困難であり大型風力発電機の導入が難しい。

現在、大型風力発電機の設置が困難な場所には、設置が比較的容易であり低風速でも発電が可能である小型風力発電機が導入されている。小型風力発電機は主に小屋用電源、公共施設の屋外照明などに利用されている。また、大きな風が吹かないような場所でも発電が可能なパワーアシスト型小型風力発電機が開発されている<sup>1)</sup>。パワーアシストの動作としては、1分間に6秒間バッテリーから電力を供給し、プロペラの回転を上昇させる。その後の54秒間は電力の供給は行わないが、アシスト後もプ

\* 松江工業高等専門学校

\*\* 鳥取大学工学部

ロペラは惰性で回転する。プロペラが回転している間に発電可能な風が吹けば、小型風力発電機が発電を開始することができる回転数までプロペラの回転数を早く上昇させることができる。しかし、風が吹かなければ供給した電力は無駄になってしまう。プロペラの回転をアシストする際に、次にいつ発電可能な風が吹くのか予測することができるのであれば、より効率の良いパワーアシストを行うことができるのではないかと考えた。

そのため、我々は一般的な家庭用パソコンと狭域の気象観測データを利用した風況予測の研究を行う。

## 2. 風況予測の手法

現在、風況予測は大型風力発電機を対象とした研究が行われており、重回帰分析、ニューラルネットワーク (N.N.: Neural network)、遺伝的プログラミング (GP: Genetic Programming) を使用した研究が報告されている<sup>2)~5)</sup>。これらの研究は広域な気象観測データを利用し予測を行ったものである。我々鷲見研究室では小型風力発電機を所有しており、大型発電機よりも比較的検討が容易であるため小型風力発電機をターゲットにした研究を行い、その後、大型風力発電機にも研究成果を適用しようと考えた。

風況予測は大型のコンピューターが必要であったり、風力測定点が多く必要であったりする。限られた1つの地点で風況予測を行うために、多次元データの分類に効果的な自己組織化マップ (SOM: Self-Organizing Map)<sup>6)</sup> が利用出来るのではないかと考え、風況予測に SOM を使用する手法を提案する。これまでに、基本 SOM、双方向 SOM<sup>7)</sup>、Elman 型フィードバック SOM<sup>8)</sup> を使用し風況予測を行い予測結果の評価を行った<sup>9)~11)</sup>。

尚、本論文で行う風況予測では風速値の予測を行うものである。

## 3. 自己組織化マップ (SOM)

予測に使用した3種類の SOM について説明する。実験に使用した SOM は基本 SOM、双方向 SOM、Elman 型フィードバック SOM である。

### 3-1 基本 SOM の概要

基本 SOM は T. コホネンにより考案されたニューラルネットワークの一種であり、多次元データの分類に適している。基本 SOM は入力層と競合層の2層で構成されたネットワークであり、T. コホネンは、脳における情報処理を以下のような式 (1) にまとめた。

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)] \quad (1)$$

この式 (1) は、今、神経細胞 (以下ユニット)  $i$  が時刻  $t$  で処理している情報処理能力 (以下参照ベクトル) を  $m_i(t)$  とする。外部からの入力信号 (以下入力ベクトル)  $x(t)$  が入ってきた場合に、ユニットは外部からの入力ベクトルを学習して次の時刻には入力ベクトルにより近い参照ベクトルを持つようになる。このとき  $x(t)$  が  $n$  次元の入力ベクトルであれば、参照ベクトル  $m_i(t)$  は同じ  $n$  次元の要素を持つ。そして、 $h_{ci}(t)$  は学習率係数  $\alpha(t)$  を含めた近傍関数である。なお、 $t = 0, 1, 2, \dots$  は離散時間座標である。

基本 SOM の構成を図 3-1 に示す。基本 SOM は階層型のネットワークであり、入力層と競合層の2層で構成されている。第1層は  $n$  次元の入力層  $x(t)$  であり、第2層の競合層は出力を視覚的に見るために多くは2次元に配列されている。競合層のユニットは  $m_i(t)$  で表され、入力層に合わせ  $n$  次元の参照ベクトルを持っている。

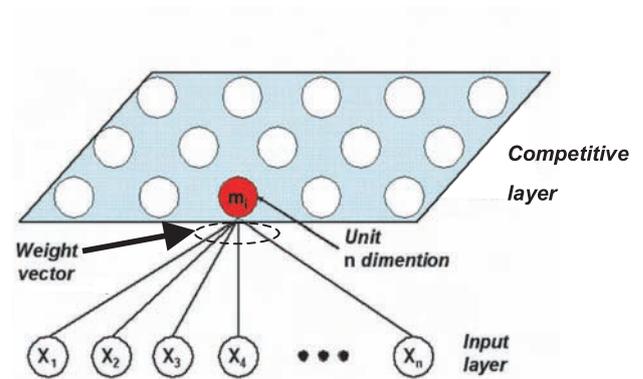


図 3-1 基本 SOM の構成図

Fig. 3-1 Composition chart of Fundamental SOM

### 3-1-1 基本 SOM のアルゴリズム

基本 SOM の学習ではまず、距離測度にユークリッド距離を用いる。他の距離測度もあるが、基本 SOM ではユークリッド距離を用いる。

入力ベクトル  $x(t)$  が提示された時、ユークリッド距離  $|x - m_i|$  を最小にするユニット  $i$  を探し、それに添え字  $c$  を付けた以下の式 (2) で表すことが出来るユニットを勝者ユニットと呼ぶ。

$$|x - m_c| = \min |x - m_i| \quad (2)$$

勝者ユニットの周りに近傍が形成され、競合層のユニットすべてが式 (1) に従って学習を行い、学習率係数に応じて入力ベクトルに参照ベクトルを近づける。この時、近傍範囲内では  $h_{ci}(t) = \alpha(t)$  となり、近傍範囲外では  $h_{ci}(t) = 0$  となるため、入力ベクトルを学習するユニットは勝者ユニットを含む近傍範囲内のユニットに限られ、近傍範囲外のユニットは結果的に学習を行わないことになる。この学習を繰り返すことで類似度の高い参照ベクトルを持つユニット同士が集まり分類される。

また、近傍のサイズは学習回数  $t$  と共に減少する。同様に学習率係数  $\alpha(t)$  も減少する。

### 3-2 双方向 SOM の概要

双方向 SOM<sup>8)</sup> の構成を図 3-2 に示す。双方向 SOM は入力層、競合層、出力層の 3 層で構成され、入力層-競合層間と競合層-出力層間で、すべてのユニットは各々参照ベクトルをもって全結合する。双方向 SOM は、競合層に位相保持マッピングを形成することで、近傍関係を保持する特性を持つ。また、教師信号を用いた一般的な写像関係の学習が可能である。更に順方向写像に加え、入力-出力関係を逆転し、出力層側に入力することで、出力から入力への逆方向写像を得ることができ、双方向連想記憶装置としても動作する。この双方向 SOM はアームの制御などに利用されている<sup>7)</sup>。

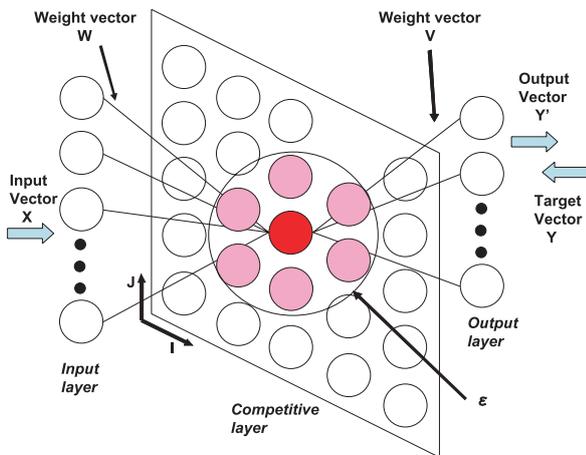


図 3-2 双方向 SOM の構成図

Fig. 3-2 Composition chart of Bi-directional SOM

#### 3-2-1 双方向 SOM のアルゴリズム

学習過程において、入力ベクトル  $X$  と教師ベクトル  $Y$  の学習セット  $(X, Y)$  を与えた場合、基本 SOM と同様競合層上で勝者ユニットを求める。勝者ユニット  $ij^*$  は式 (3)、(4) に示すように、入力ベクトル  $X$  と参照ベクトル  $W_{ij}$  とのユークリッド距離  $D_{ij}$  の最も小さいユニットとする。

$$D_{ij} = |X(t) - W_{ij}(t)| \quad (3)$$

$$|X(t) - W_{ij^*}(t)| = D_{ij^*} = \min \{D_{ij}\} \quad (4)$$

双方向 SOM では、1 回の学習過程において、勝者ユニット  $ij^*$  とその近傍領域  $\varepsilon$  内の全ユニットに対して、参照ベクトルの更新を行う。1 回の学習ごとに勝者ユニットと入力層間および出力層間の参照ベクトルを同時に更新する。

入力層-競合層間において、近傍内ユニットが持つ参照ベクトル  $W_{ij}$  は入力ベクトル  $X$  に近づくように式 (5) に従い更新する。同様に競合層-出力層間ではネットワーク出力ベクトル  $Y'$  が教師ベクトル  $Y$  に近づくよう、近傍内ユニットの持つ参照ベクトル  $V_{ij}$  を式 (6) に従い更新する。

$$W_{ij}(t+1) = W_{ij}(t) + \alpha(t) \cdot f(B(ij)) \cdot |X(t) - W_{ij}(t)| \quad (5)$$

$$V_{ij}(t+1) = V_{ij}(t) + \alpha(t) \cdot f(B(ij)) \cdot |Y(t) - V_{ij}(t)| \quad (6)$$

for  $i, j \in \text{Neighborhood area}$

$$f(x) = 1 - 1 / (1 + \exp\{(x - R/2) / T\}) \quad (7)$$

ここで  $B(ij)$  は近傍内ユニット  $ij$  と勝者ユニット  $ij^*$  間のユークリッド距離を示す。 $R$  は勝者ユニット近傍領域  $\varepsilon$  の半径、 $T$  は定数である。

### 3-3 Elman 型フィードバック SOM の概要

Elman 型フィードバック SOM の構成を図 3-3 に示す。

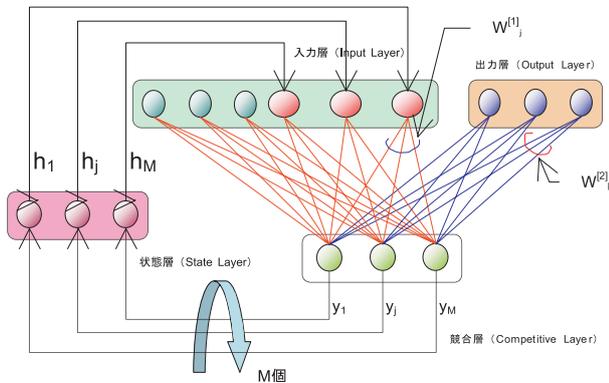


図 3-3 Elman 型フィードバック SOM の構成図

Fig. 3-3 Composition chart of Elman-type

#### Feedback SOM

この構成は、過去の履歴情報を参照できるように、通常の基本 SOM にフィードバック結合を付加し、第 2 候補や定量的な信頼性を表現する出力層を競合層の後段に設けたものである。状態層は競合層からの情報を保持し、その情報を入力層にフィードバックする。競合層からの情報をどの程度保持するかは式 (11) により決定する。

このモデルは入力層  $x$ 、競合層  $y$ 、状態層  $h$ 、出力層  $z$  の四つの層から構成され、それぞれのユニット数は  $(L + M)$  個、 $M$  個、 $M$  個、 $N$  個である。この“入力層 → (競合層 + 状態層) → 出力層”という構造は、リカレントネットワークの一つである Elman 型のモデルと類似点が多いため、Elman 型フィードバック SOM と呼ばれている。

この Elman 型フィードバック SOM は点字認識などに利用されている<sup>8)</sup>。

#### 3-3-1 Elman 型フィードバック SOM のアルゴリズム

Elman 型フィードバック SOM の動作原理について説明する。競合層の  $j$  番目のユニット  $y_j$  は、入力層のすべてのユニットに対して結合しており、その参照ベクトルは  $w_j^{[1]}$  と表される。同様に出力層の  $k$  番目のユニット  $z_k$  は競合層の全てのユニットとの間に参照ベクトル  $w_k^{[2]}$  を持つ。この時、時刻  $t$  の各ユニットの出力信号は下記の式で定義される。ただし、 $x$  と  $h$  からなる入力信号は事前に規格化しておく。

$$u_j(t) = \sum_{i=1}^L w_{ji}^{[1]} x_i(t) + \sum_{i=1}^M w_{i,t+i}^{[1]} \beta h_i(t) \quad (8)$$

$$j^* = \arg \max u_j(t) \quad (9)$$

$$y_j(t) = \begin{cases} 1, & j = j^* \\ 0, & j \neq j^* \end{cases} \quad (10)$$

$$h_j(t) = (1 - \gamma) y_j(t) + \gamma h_j(t - 1) \quad (11)$$

$$z_k(t) = \sum_{j=1}^M w_{kj}^{[2]} y_j(t) \quad (12)$$

ここで、 $j^*$  は競合層の勝者ユニットの番号、 $\beta$  は競合層において過去の履歴情報を参照する程度を表す定数、 $\gamma$  は状態層において過去の情報を保持する程度を表す定数である。Elman 型フィードバック SOM の中で状態層のみがダイナミクスを有し、上述の  $\gamma$  は 1 次遅れ特性の時定数と等価な意味をもつ。よって  $\gamma$  を大きくすれば保持できる過去の履歴情報は多くなるが、逆に現在の入力情報を新たに取り込むことができなくなるため、一般に最適な値が存在する。

## 4. 実験・評価

本論文では、予測向上を目指し双方向 SOM と Elman 型フィードバック SOM を使用した風況予測を行う。実験は 4-2 以降で述べる 3 種類の方法で行い、検討する。

### 4-1 SOM による予測方法

実験の詳細を述べる前に、SOM による予測方法について説明する。

基本 SOM は、 $n$  次元の入力ベクトルより特徴づけられたユニットから構成されており、入力ベクトルの特徴により競合層のユニットが分類されている。予測時点までの既知データを入力することにより、以後の予測したいデータを得ることが出来る。すなわち、既知の入力ベクトルと競合層上のユニットが持つ参照ベクトルを比較し、その差が最小となる参照ベクトルを持つユニットの値が予測値となる。

基本 SOM に出力層を付加えた構成になっている双方向 SOM、及び Elman 型フィードバック SOM でも同様に既

知の入力ベクトルと競合層上ユニットが持つ入力層-競合層間の参照ベクトルを比較し、その差が最小となる参照ベクトルを持つユニットが決まる。このユニットの出力する値が予測値となる。

#### 4-2 実験・評価1: 双方向 SOM による風速予測

双方向 SOM を使用し風速を予測した。双方向 SOM を用いることで、基本 SOM では不可能であった、教師信号を用いた一般的な入出力関係の学習が可能になる。この実験では双方向 SOM を実装したモデルを季節ごとに作成し、風速の予測を行い、結果を検討した。

##### 4-2-1 気象データ

風速の予測に用いる気象データは気象庁のホームページを参照し抽出したものである。気象データは1時間間隔でサンプリングされた平均値である。データは1999年3月から2006年2月までの6年間の気象データを抽出した。季節により風況が異なることを考慮して、気象データを季節別に分類した。季節は春季:3~5月、夏季:6~8月、秋季:9~11月、冬季:12~2月とした。観測地点としては鳥取市を対象地点とした。

##### 4-2-1 入力データ

入力ベクトル 12次元と教師ベクトル 1次元を一つの学習セットとした。

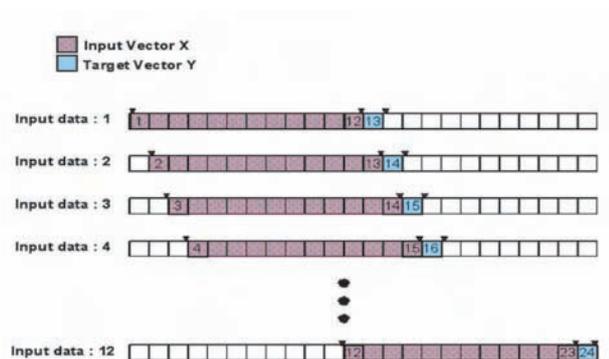


図4-1 入力データ  
Fig. 4-1 Input data

観測データは1時間間隔でサンプリングされた平均値である。1時から12時までに観測された値を入力ベクトル  $X$  とし、その1時間後の13時の平均値を教師ベクトル  $Y$  とした。同じように2時から13時までの値を入力ベクトル  $X$  とするときは14時の平均値を教師ベクトル  $Y$  とした。図4-1に一日の観測データと入力ベクトル  $X$ 、教師ベクトル  $Y$  の関係を示す。図4-1では一つの□が1時間の風速平均値を表す。

##### 4-2-3 予測の評価方法

予測結果の評価は、下記の式 (13) に示す2乗平均平方根誤差 (RMSE: Root Mean Square Error) を使用した。

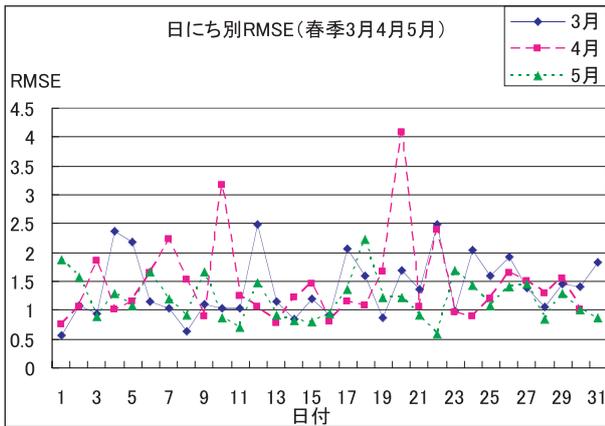
$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f(i) - .I(i))^2}{N}} \quad (13)$$

$f(i)$ : 予測値     $.I(i)$ : 実測値     $N$ : 予測回数

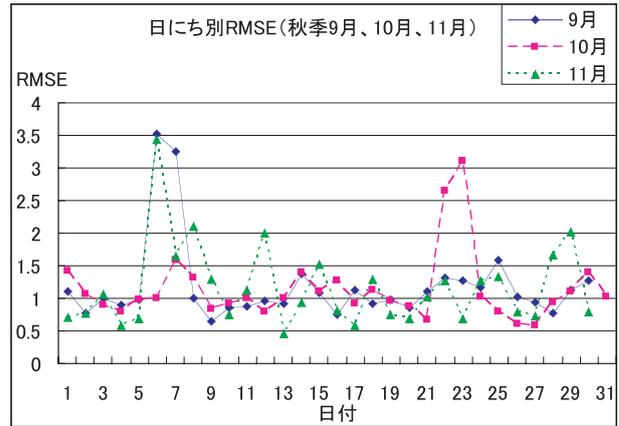
RMSE は常に正の値となり、予測誤差の標準的な大きさを示す指数である。値が小さく0に近いほど予測精度が高いことを表す。

##### 4-2-4 予測と評価結果

季節ごとに学習を行い風速の予測を行った。図4-2に月別の一例として春季と秋季の RMSE を示す。季節別の平均 RMSE は春季:1.35、夏季:1.05、秋季:1.16、冬季:1.32であった。

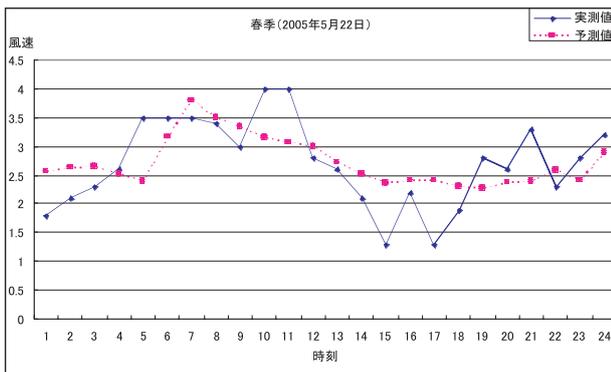


(a) 春季の RMSE  
(a) RMSE in spring

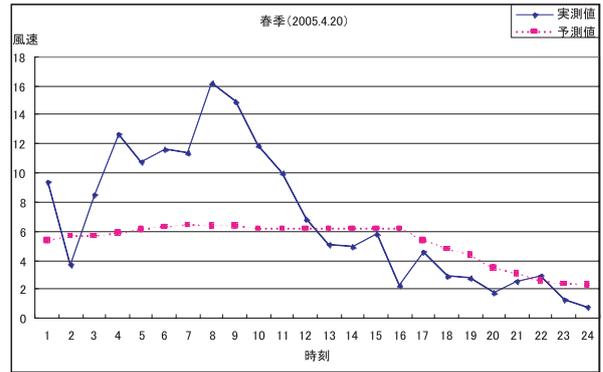


(b) 秋季の RMSE  
(b) RMSE in autumn

図4-2 季節別の RMSE  
Fig. 4-2 RMSE each season

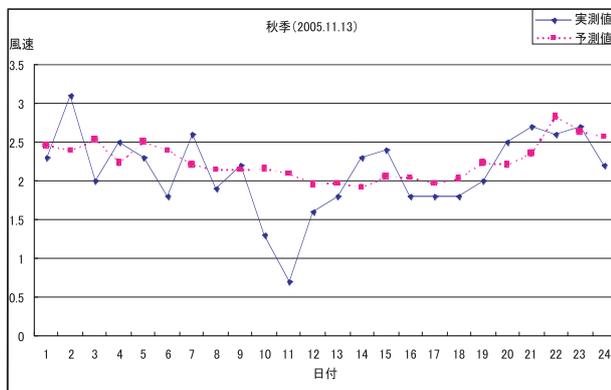


(a) 春季の最小値 RMSE:0.59 (2005/05/22)  
(a) Min RMSE in spring:0.59 (2005/05/22)

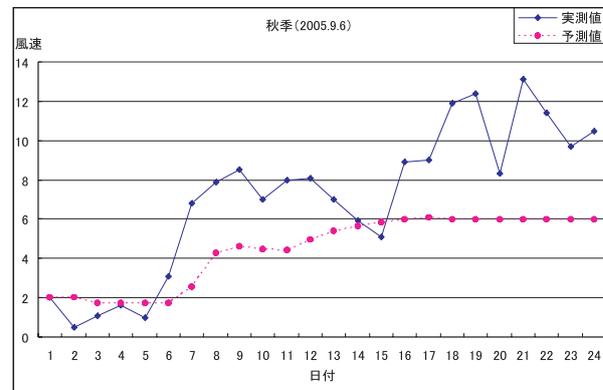


(b) 春季の最大値 RMSE:4.07 (2005/04/20)  
(b) Max RMSE in spring:4.07 (2005/04/20)

図4-3 春季の風速予測値  
Fig. 4-3 Wind forecast value in spring



(a) 秋季の最小値 RMSE:0.46 (2005/11/13)  
(a) Min RMSE in autumn:0.46 (2005/11/13)



(b) 秋季の最大値 RMSE:3.53 (2005/09/06)  
(b) Max RMSE in autumn:3.53 (2005/09/06)

図4-4 秋季の風速予測値  
Fig. 4-4 Wind forecast value in autumn

一例で示した図4-2 (a) 春季のRMSEでは3月、4月、5月の月別平均RMSEを示す。RMSEの値は3月:1.4、4月:1.44、5月1.2、となった。図4-2(b)秋季のRMSEでは9月、10月、11月の月別RMSEを示す。RMSEの値は9月:1.18、10月1.13、11月1.16となった。秋季は春季よりも0.3ポイントほど評価値が0に近い値となっている。

図4-3に春季において、RMSEが最大であった日と最小であった日の一日の予測結果を示す。同様に図4-4は秋季において、RMSEが最大であった日と最小であった日の一日の予測結果を示す。

このグラフから予測値が大きくなってしまった日は普段吹かないような強風が吹いていることが分かる。予測値の最高は6m/sであるが、風速の実測値は10m/sの風が吹いている。そのため評価値が大きくなったと考えられる。

#### 4-2-5 基本SOMとの評価比較

双方向SOMを用いた予測結果のRMSEと、基本SOMを用いた予測結果のRMSEを比較した。図4-5に比較図を示す。

評価結果を比較した結果、ごく僅かではあるが、双方向SOMを使用した予測結果ほうが評価値が小さい値になる季節があったが、ほぼ基本SOMと双方向SOMでの差はないという結果になった。

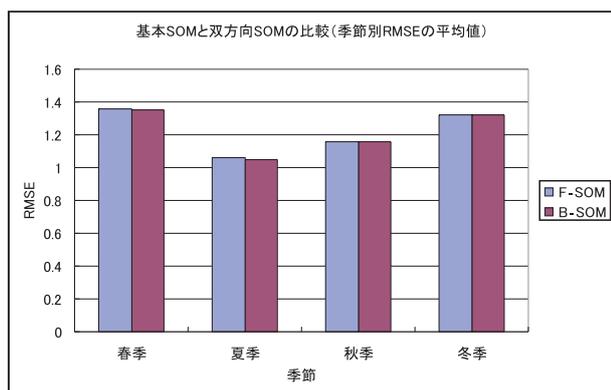


図4-5 双方向SOMと基本SOMの比較

Fig. 4-5 Comparison between

Bidirectional SOM and Fundamental SOM

#### 4-3 実験・評価2: 風速の差分値を用いた予測

これまで、SOMへの学習データには観測された風速をある時間毎に平均処理し、平均処理された値をそのまま使用していた。この実験では平均処理された値から風速の差分値を求め、その差分値を学習データに使用する。

予測には1999年3月から2005年2月までの6年間に観測された風速の値を使用する。値は1時間毎に平均処理されたものである。差分値を求めることで、季節分、トレンド分を除くことができる。また季節別に差分値の分布図を求めた。一例として春季の風速差分値の分布を図4-6に示す。

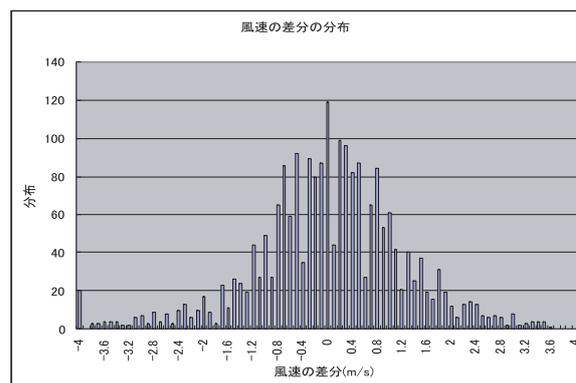


図4-6 風速の差分値分布

Fig. 4-6 Difference value distribution of wind velocity

分布図を求めた結果、風速の差分値が正規分布になっていることがわかった。よって時点 $k$ から時点 $k+1$ の風速変化は0に留まる確率が高く、大きく変化する確率が低いと考えられる。他の季節や年でも同様な分布が得られたため、短期的な時系列の予測が可能であると考えられる。さらに実測値をそのまま学習に使用するよりも、差分値を使うことで学習データ数を減らすことができる。

#### 4-3-1 気象データ

データは1999年3月から2005年2月までの6年間の気象データを抽出した。春季:3~5月、夏季:6~8月、秋季:9~11月、冬季:12~2月の季節別にデータを分け、風速の差分値を求める。

実験では、5分毎、10分毎でも平均処理した風速の差分値も求め予測に使用する。

#### 4-3-2 SOMへの入力データと学習条件

求めた差分値をSOMへ学習させる。今回の実験で使用した双方向SOMは入力層が4次元、出力層を1次元に設定した。よって入力ベクトル4次元と教師ベクトル1次元を1つの学習セットとする。

入力ベクトルに用いた差分値の一時間後の差分値を教師ベクトルの値とする。

使用した双方向SOMの構造は入力層を4次元、競合層

のユニット数を  $10 \times 10$  の 100 ユニット、出力層を 1 次元とした。また経験則により、初期状態の学習率係数を 0.5、近傍のサイズを 10 とした。学習回数は 3 万回とし学習を行った。

#### 4-3-3 予測風速の求め方

4-3-2 で述べたように教師ベクトルとして 1 時間後の差分値を与えている。既知の入力ベクトルを与えると出力層から一時間後の予測差分値を得ることができる。この予測差分値を現在の風速値に加え算出された値を一時間後の予測風速とする。学習データに 10 分間隔、または 5 分間隔で差分値を求め学習に利用した場合においても同じ予測方法は同じである。

#### 4-3-4 予測値の評価方法

予測結果の評価には 4-2-3 で用いた評価方法と同じ 2 乗平均平方根誤差 (RMSE : Root Mean Square Error) を使用する。更に、RMSE とは異なる評価方法である平均誤差 (ME : Mean Error) も求めた。

ME は予測の系統的な偏りを示す指数である。指数を求めることで、予測値が正負どちらに偏っているのかが分かる。従って、平均誤差 ME が 0 のとき、予測値は正にも負にも偏っていないことを示す。ME は下記の式 (14) で求めることができる。

$$ME = \frac{\sum_{i=1}^N (f(i) - A(i))}{N} \quad (14)$$

$f(i)$  : 予測値     $A(i)$  : 実測値     $N$  : 予測回数

#### 4-3-5 予測結果

実験は 1 時間毎、10 分毎、5 分毎ごとに平均処理された風速の差分値を利用し予測を行った。それぞれの予測結果を図 4-7、図 4-8、図 4-9 に示す。図 4-7 は 1 時間間隔で平均処理した風速値から求めた差分値を予測に使用した結果である。同様に図 4-8 は 10 分間隔、図 4-9 は 5 分間隔で平均処理した風速値から求めた差分値を予測に使用した結果である。実線が実際の風速値、大きな破線が予測風速、小さい破線は差分値ではなく従来法である実測値を学習に用いた予測結果をそれぞれ表す。

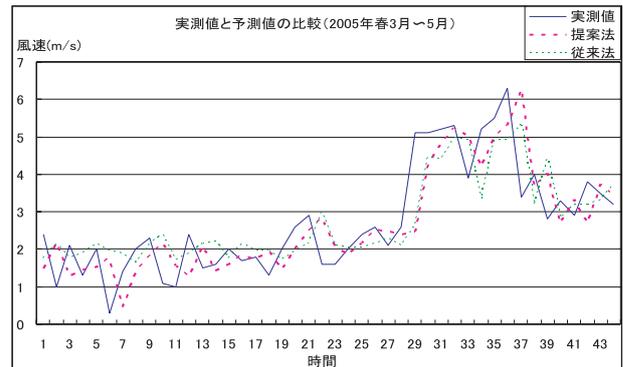


図 4-7 1 時間間隔での予測

Fig. 4-7 Forecast every one hour

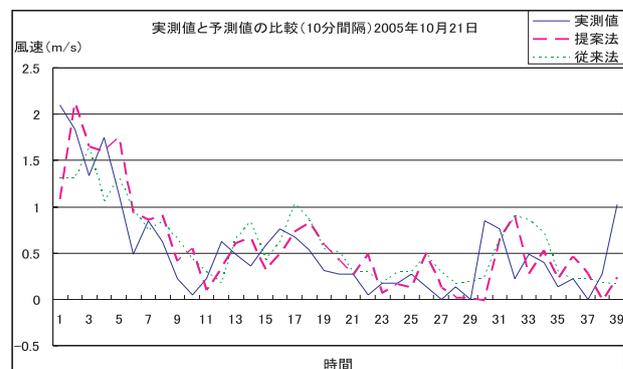


図 4-8 10 分間隔での予測

Fig. 4-8 Forecast every ten minutes

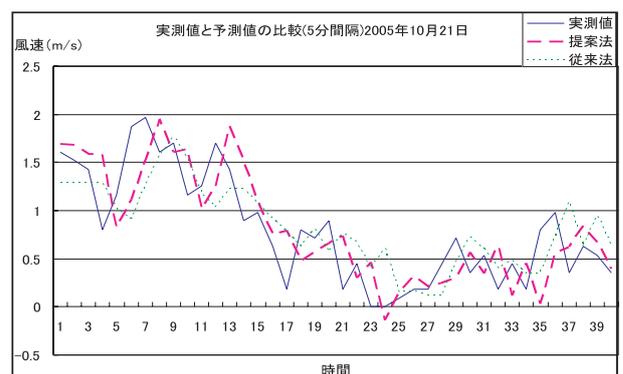


図 4-9 5 分間隔での予測

Fig. 4-9 Forecast every five minutes

予測結果から実測値と同じ風速の変化をたどっているが、実測値と差分値は位相がずれる結果となっていることが分かった。

#### 4-3-6 従来法との評価比較

観測された風速のそのままの値を双方向 SOM へ学習させ風速予測を行う従来法と、差分値を用いた予測結果の RMSE を比較した。図 4-10 に ME の比較結果を示す。青色の棒グラフが差分値を使用した予測の評価である。赤色の棒グラフは従来法の実測値を使用した予測結果の ME を表した図である。

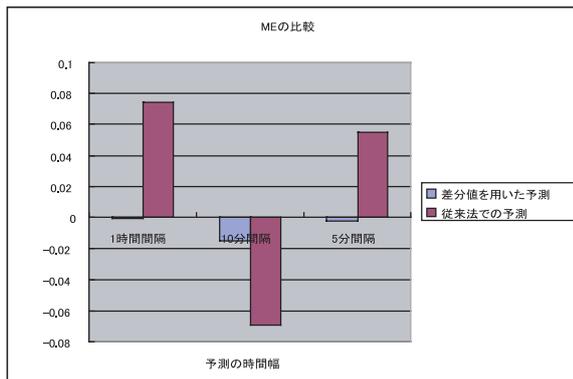


図 4-10 ME の比較

Fig. 4-10 Comparison of ME

従来法に比べ、差分値を用いた予測結果のほうが大幅に予測値に偏りが少ないことが分かる。

次に図 4-11 に RMSE の比較結果を示す。

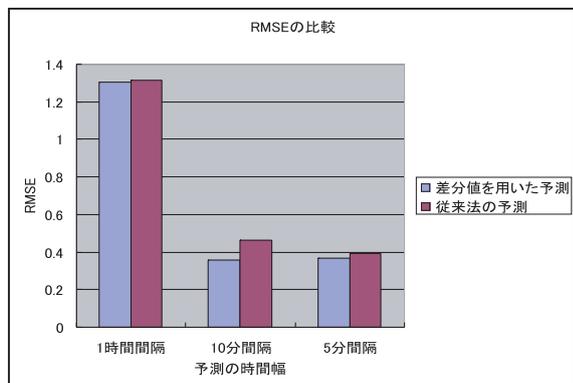


図 4-11 RMSE の比較

Fig. 4-11 Comparison of RMSE

左の棒グラフが差分値を使用した予測の評価である。右の棒グラフは従来法の実測値を使用した予測結果の RMSE を表した図である。

極僅かであるが、従来法よりも差分値を用いた予測結果の方が 0 に近い値となっていることが分かる。また、1 時間間隔で平均処理された風速の値を使用した予測結果よりも、10 分間隔、5 分間隔で平均処理された風速の値を利用した予測結果の方が大幅に予測精度が向上してい

ることが分かった。

#### 4-4 実験・評価 3: Elman 型フィードバック SOM を用いた予測

4-4 の実験では Elman 型フィードバック SOM を利用し風速の予測を行った。通常の SOM はダイナミクスをもたないために時系列情報を扱うことができない。そこで時系列情報を扱う方法の一つとして考え出された SOM が Elman 型フィードバック SOM である。今回の実験ではこの Elman 型フィードバック SOM を用いて予測を行い、双方向 SOM で行った予測結果と比較を行った。

##### 4-4-1 気象データ

今回の実験では 2005 年 12 月 1 日～2006 年 1 月 31 日までの 2 ヶ月に 1 分間隔で観測された風速値を使用した。

##### 4-4-2 SOM への学習データと学習条件

4-3 の実験結果から差分値を使用することで学習データ数を減らすことができると考え、学習に使用する風速データを 2005 年 12 月の 1 ヶ月間とする。

学習データには、1 分間隔で観測された風速の値を 10 分間隔で平均処理する。平均処理された値から季節分、トレンド分を除くために風速値の差分  $\Delta x(k) = x(k) - x(k-1)$  を求める。求めた差分値を以下の式 (15) を使い正規化する。

$$X_{nr}(i) = \frac{X(i) - X_l}{X_h - X_l} \quad (15)$$

$X_{nr}(i)$  : 正規化データ  $X(i)$  : 差分値

$X_l$  : 差分値の最低値  $X_h$  : 差分値の最高値

正規化した差分値を入力ベクトル 4 次元と教師ベクトル 1 次元を一つの学習セットする入力ベクトルを作成する。

本研究で使用した Elman 型フィードバック SOM の構造は、入力層を 4 次元 + 100 次元 (状態層のユニット数と同数の次元)、競合層のユニット数を  $10 \times 10$  の 100 ユニットの、状態層のユニット 100、出力層を 1 次元とする。また経験則により、初期状態の学習率係数を 0.8、近傍のサイズを 20、学習回数を 1 万回、定数  $\beta$  を 0.5、定数  $\gamma$  を 0.5 とした。

#### 4-4-3 予測結果

予測結果を図4-12に示す。

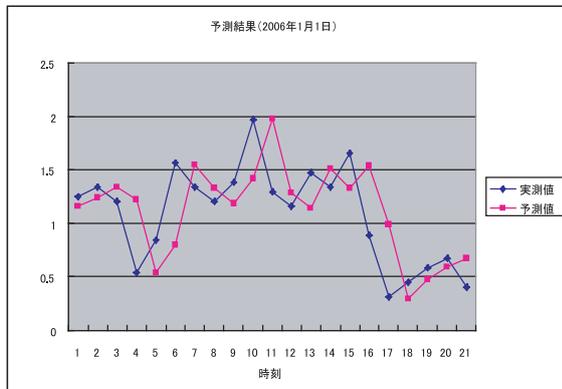


図4-12 予測結果 (2006/01/01)

Fig. 4-12 Forecast (2006/01/01)

予測は2006年1月の1ヶ月間行う。一例として1月1日の予測結果を示す。双方向SOMを使用した予測結果と同様に、実測値と予測値の位相がずれるという結果になっている。これの一つの原因として、学習時の過学習により、予測差分値が限りなく0に近い値になってしまったことが考えられる。

#### 4-4-3 評価

評価方法は3-2-4で説明した評価方法と同じ方法で行った。求めた評価を双方向SOMと比較する。

Elman型フィードバックSOMを使用した評価結果はME:0.02、RMSE:0.38という結果になった。一方、双方向SOMを用いた結果はMEが-0.01、RMSEが0.37であった。評価結果から0.1ポイント双方向SOMの方が評価値が小さい値になったが、ほとんど評価値に差がない結果になった。

### 5. まとめ

双方向SOMを用いて風速の予測を行い検討した。季節ごとに予測モデルを作成し予測を行った結果、季節別の平均RMSEは春季:1.35、夏季:1.05、秋季:1.16、冬季:1.32となった。

ごく僅かではあるが双方向SOMを使用した予測結果の方が、評価値が小さい値になる季節があった。しかし、ほとんど基本SOMと双方向SOMでの差はないという結果になった。

また、観測された風速の差分値を求め、その差分値を双方向SOMへの学習データとして利用した実験では、

予測は1時間間隔、10分間隔、5分間隔で予測を行った。従来法と比較検証指数ME及びRMSEを求め、従来法と比較した結果、差分値を利用した方が精度の高い予測をしていることが分かった。また1時間間隔よりも10分間隔、5分間隔で予測を行ったほうが精度よく予測できることが分かった。

時系列データを扱うことのできるElman型フィードバックSOMを利用し風速の予測を行った。結果、従来法の方が僅かであるが評価が良かった。

Elman型において定数 $\beta$ と定数 $\gamma$ の値が重要となる。今後はこの定数の最適値を見つけるなどの検討を行う。また予測差分値を使用した予測風速を求める別の方法も検討し、予測率向上を目指したい。

#### 注・参考文献

- 1) 川上勝史、“パワーアシスト型風力発電機の開発”、月刊エコインダストリー、Vol. 8, No. 7, pp.22-27, Jul., 2003.
- 2) 見目善重、石井弘樹、滝川浩史、河本映、榊原建樹、“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、Vol. 27, No. 1, pp.85-91, 2001.
- 3) 伊藤陽平、桶真一郎、見目喜重、滝川浩史、榊原建樹、“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検討”、太陽/風力エネルギー講演論文集、pp.349-352, Nov., 2004.
- 4) 伊藤陽平、桶真一郎、見目喜重、滝川浩史、榊原建樹、“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検討”、太陽/風力エネルギー講演論文集、pp.349-352, Oct., 2005.
- 5) 松坂知行、星文伸、“風況の時系列予測に関する研究”、計測自動制御学会東北支部第222回研究集会、資料番号222-11, Jun., 2005.
- 6) T. コホネン、徳高平蔵、他、“自己組織化マップ改訂版”、シュプリンガー・フェアラーク東京株式会社、2005.
- 7) 平野敬、佐瀬幹哉、小杉幸夫、“双方向Feature Mapによるアーム制御”、電子情報通信学会論文誌、Vol. J76-D-II, No. 4, pp.881-888, Apr., 1993.
- 8) 和久屋寛、原田浩之、信太克規、“時系列信号処理を行う自己組織化マップのアーキテクチャと点字認識課題への応用”、電子情報通信学会論文D-II Vol. J87-D-II No.3 pp.884-892, 2004年3月.
- 9) Seiichiro FUJIMATSU, Yasuaki SUMI, Takuya UETA, Takao TSUKUTANI, Yutaka FUKUI, “The study of the wind synopsis prediction system by using

- Self-Organization Map” ,ITC-CSCC 2005 Proceedings, Vol. 3, pp.957-958, Jul., 2005.
- 10) 小林飛鳥、鷺見育亮、植田拓也、藤松誠一郎、築谷隆雄、副井裕、“自己組織化マップ (SOM) を使った風力発電機の制御システムの検討”、平成 17 年電気関係学会関西支部連合大会講演論文集、G61, Nov., 2005.
- 11) 藤松誠一郎、鷺見育亮、植田拓也、小林飛鳥、築谷隆雄、副井裕、“双方向 SOM を用いた風況予測の一手法”、第 19 回回路とシステム軽井沢ワークショップ論文集 pp.51-56, Apr., 2006.

(2007 年 3 月 7 日受理)