

FIR/IIR ニューラルネットワークによる風速の時系列信号の予測に関する研究

星 文伸、松 坂 知 行、木村 昭穂

Time Series Prediction of Wind Speed with FIR/IIR Neural Network

○星 文伸, 松坂 知行, 木村 昭穂

Fuminobu Hoshi, Tomoyuki Matsuzaka, Akio Kimura

八戸工業大学

Hachinohe Institute of Technology

キーワード : FIR/IIR Type Neural Network , Time Series Prediction, Wind Speed

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 松坂研究室

星文伸, Tel.: (0178)25-3111, Fax.: (0178)25-1691, E-mail: m03208@hi-tech.ac.jp

1. まえがき

近時、自然エネルギーの導入が進んでおり、中でも風力エネルギーは最も有望なエネルギーである。しかし、出力変動が大きいこと、現在 NEDO を中心に、ウインドパーク全体の出力変動を抑える研究が進められている。出力変動の抑制のためには風速の予測が必要であり、もし風速の変動を予測できれば、短期的にはウインドパーク内に設置されたバッテリー、フライホイールなどの蓄電装置の予測制御、中期的には調整電力のスケジュール運転が可能になり、電力システムの運用上有力な手法となると考えられる。

風速の予測を行う研究としては、Kalman Filter を用いる方法¹⁾、ARMA モデルを用いる方法¹⁾、ニューラルネットワークを用いる方法^{3),4),5),6),7)}などが提案されてきた。しかし、Kalman Filter、ARMA モデルなどのシステム理論や古典的な統計的モデルは予測誤差が大きいことが報告されている¹⁾。これに対して、ニューラルネットワークは柔軟な処理能力を有するため、風速のような非線形信号の処理に適しており、

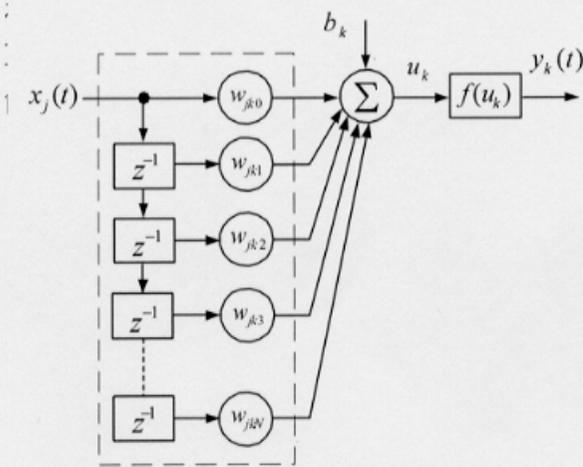
近時、時系列信号の予測に対する試みが進められている。

筆者らは、FIR/IIR 型ニューラルネットワークを提案し、時系列信号の予測、システム同定、形状最適化問題などに適用してきた^{8),9),10)}。FIR/IIR は、フィルタ理論に見られる Finite Impulse Response/Infinite Impulse Response を略したもので、その構造はフィルタの構造と同じである。本稿では、まず、2つのニューラルネットワークの構成法と学習則について述べ、つぎに風速の予測に適用した結果について述べる^{11),12)}。

2. ニューラルネットワークの構成¹²⁾

2.1 FIR 型ニューラルネットワークの構成

本研究で用いた FIR 型ニューラルネットワークの基本要素を図 1 に示す。入力側に遅延要素をもっており、各遅延要素の出力は重みを介して加算され、シナプスの出力関数の入力となる。遅延要素の数は、これまでいろいろなシステムに適用した経験からすると、実用上 3 個あ



z^{-1} : 遅れ演算子 w_{jkl} : 重み b_k : バイアス
 u_k : k 番目のニューロンの入力
 $f(u_k)$: k 番目のシナプスの出力関数

図 1 FIR 型ニューラルネットワークの基本要素

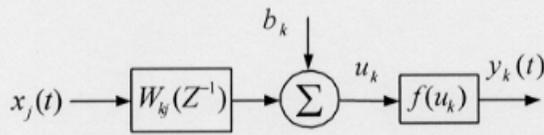


図 2 FIR 型ニューラルネットワークの簡略表示

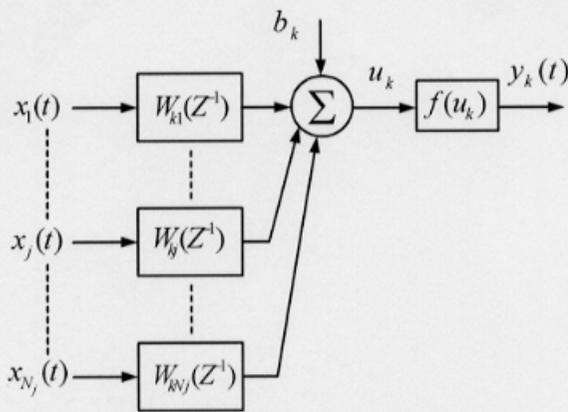
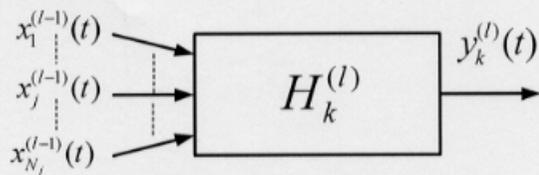


図 3 多入力 FIR 型ニューラルネットワーク



l : 階層数

図 4 多入力、多階層 FIR 型ニューラルネットワークの簡略表示

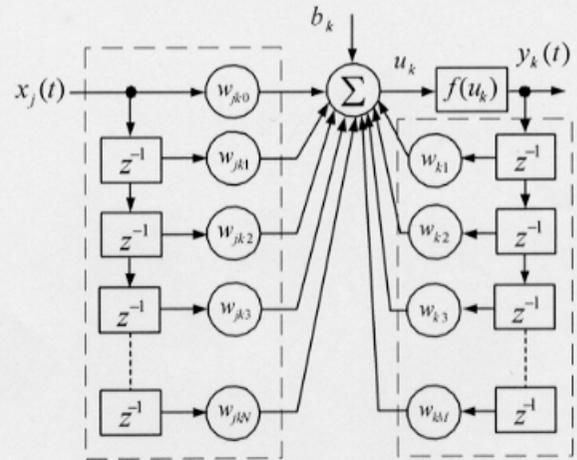


図 5 IIR 型ニューラルネットワークの基本要素

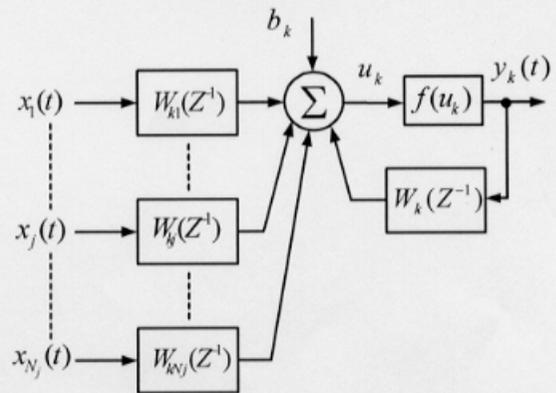


図 6 IIR 型ニューラルネットワークの簡略表示

れば十分である。多入力の FIR 型ニューラルネットワークは、図 3 のように表示される。また、多入力、多階層の FIR 型ニューラルネットワークを図 4 のように簡略表示することにする。

2-2 IIR 型ニューラルネットワークの構成

IIR 型ニューラルネットワークの基本要素を図 5 に示す。また、点線部分を簡略表示すると、図 6 のようになる。多入力、多階層の IIR 型ニューラルネットワークは、図 4 と同様に簡略表示することにする。

3. 学習則¹²⁾

つぎに、学習則について述べる。FIR 型と IIR 型の式の相違は、出力層からの帰還の有無によ

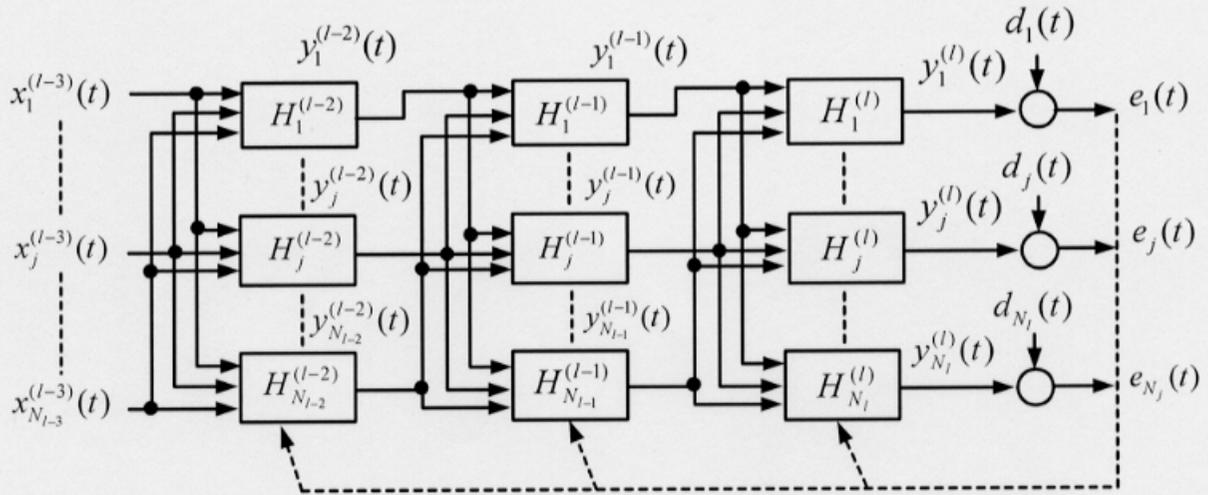


図7 ニューラルネットワークの全体の構成

り決まるので、FIR 型の場合は、出力層からのフィードバックの重みを除いて考えればよい。図7は、多入力、多階層の FIR/IIR 型のニューラルネットワーク全体の構成と、後述する誤差逆伝播法による学習の概念を示す¹²⁾。

(1) 順方向の伝播の計算

(a) 出力層

内部ポテンシャルは、(1)式のようにになる。

$$u_k^{(l)}(t) = \sum_{j=1}^{N_j} \sum_{i=0}^N w_{kji}^{(l)} y_j^{(l-1)}(t) z^{-i} + \sum_{m=1}^M w_{km}^{(l)} y_k^{(l)}(t) z^{-m} + b_k^{(l)} \quad (1)$$

また、出力は(2)式のようにになる。

$$y_k^{(l)}(t) = f(u_k^{(l)}(t)) \quad (2)$$

ここで f はシグモイド関数

$$f(u(t)) = \frac{1}{1 + \exp(-u(t))} \quad (3)$$

である。

(b) 中間層の出力 $y_j^{(l-1)}(t)$

中間層 $(l-1)$ の j 番目の内部ポテンシャル

$u_j^{(l-1)}(t)$ は以下のように表される。

$$u_j^{(l-1)}(t) = \sum_{n=1}^{N_j} \sum_{i=0}^N w_{jmi}^{(l-1)} y_n^{(l-2)}(t) z^{-i} + \sum_{m=1}^M w_{jm}^{(l-1)} y_j^{(l-1)}(t) z^{-m} + b_j^{(l-1)} \quad (4)$$

中間層の出力 $y_j^{(l-1)}(t)$ は以下のようにになる。

$$y_j^{(l-1)}(t) = f(u_j^{(l-1)}(t)) \quad (5)$$

ただし、中間層 $(l-2)$ が入力層の場合には(4)式の第1項の $y_n^{(l-2)}(t)$ は、学習データに相当するので、遅延を考慮する必要がなく、遅延の個数 N を零とする。

(2) 逆方向の伝播の計算

FIR/IIR 型シナプスの出力層、中間層、閾値の更新には、最急降下法を適用し、以下のようにして求める。

(2.1) 出力層の重みと閾値の更新

(a) 出力層の重み $w_{kji}^{(l)}$ の更新

$$\begin{aligned} \Delta w_{kji}^{(l)} &= -\eta \frac{\partial E(t)}{\partial w_{kji}^{(l)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_k^{(l)}(t)} \frac{\partial u_k^{(l)}(t)}{\partial w_{kji}^{(l)}} \end{aligned} \quad (6)$$

ここで、

$$j=1,2,\dots,N_j, k=1,2,\dots,N_l, i=1,2,\dots,N$$

であり、 η は学習係数である。

また、 $E(t)$ は出力層の出力 $y_k^{(l)}(t)$ と教師データ $d_k(t)$ との二乗誤差であり

$$E(t) = \frac{1}{2} \sum_{k=1}^{N_l} (d_k(t) - y_k^{(l)}(t))^2 \quad (7)$$

と定義される。時系列信号では、 t は t_1, t_2, \dots, t_n で表され、各時点の二乗誤差の和を用いる。

$$\frac{\partial u_k^{(l)}}{\partial w_{kji}^{(l)}} = y_j^{(l-1)} z^{-i} + \sum_{m=1}^M w_{km}^{(l)} \frac{\partial y_k^{(l)}}{\partial w_{kji}^{(l)}} z^{-m} \quad (8)$$

(8)式の第2項は、出力の遅延要素数 m を大きな数としない限り、第1項と比較して極めて小さい値であるので、シナプスの出力に大きな値を与えない。また、ニューラルネットワークは、学習を重ねる過程で学習誤差が零になるように重みの更新を行うので、第2項を省略しても、ニューラルネットワークの学習に大きな支障をきたさない。中間層の場合についても、同様のことが言える。そこで、上式の第2項を簡略化のため省略すると、次式のようになる。

$$\frac{\partial u_k^{(l)}}{\partial w_{kji}^{(l)}} = y_j^{(l-1)}(t) z^{-i} \quad (9)$$

出力層 l から中間層 $(l-1)$ に向かって帰還される学習信号 $\delta_k^{(l)}(t)$ は、次式から求められる。

$$\begin{aligned} \delta_k^{(l)}(t) &= -\frac{\partial E(t)}{\partial u_k^{(l)}(t)} \\ &= -\frac{\partial E(t)}{\partial y_k^{(l)}(t)} \frac{\partial y_k^{(l)}(t)}{\partial u_k^{(l)}(t)} \\ &= (d(t) - y_k^{(l)}(t)) \cdot f'(u_k^{(l)}(t)) \end{aligned} \quad (10)$$

ただし、 $f'(u_k^{(l)}(t))$ は、 $f(u_k^{(l)}(t))$ の $u_k^{(l)}(t)$ に関する微分を表す。

以上の式から、(6)式の重みは

$$\Delta w_{kji}^{(l)} = \eta \cdot \delta_k^{(l)}(t) \cdot y_j^{(l-1)}(t) z^{-i} \quad (11)$$

と表される。

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta w_{kji}^{(l)}|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta w_{kji}^{(l)}|_{new} = \eta \cdot \delta_k^{(l)}(t) \cdot y_j^{(l-1)}(t) z^{-i} + \alpha \cdot \Delta w_{kji}^{(l)}|_{old} \quad (12)$$

ただし、 α は安定化係数である。

したがって、重みは次式のようにして更新される。

$$w_{kji}^{(l)}|_{new} = w_{kji}^{(l)}|_{old} + \Delta w_{kji}^{(l)}|_{new} \quad (13)$$

(b) 右辺第2項の重み $w_{km}^{(l)}$ の更新

FIR型ニューラルネットワークの場合には、

$w_{km}^{(l)} = 0$ であるので以下の計算は不要である。

$$\begin{aligned} \Delta w_{km}^{(l)} &= -\eta \frac{\partial E(t)}{\partial w_{km}^{(l)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_k^{(l)}(t)} \frac{\partial u_k^{(l)}(t)}{\partial w_{km}^{(l)}} \end{aligned} \quad (14)$$

$$\frac{\partial u_k^{(l)}(t)}{\partial w_{km}^{(l)}} = y_k^{(l)}(t) z^{-m} + \sum_{m=1}^M w_{km}^{(l)} \frac{\partial y_k^{(l)}(t) z^{-m}}{\partial w_{km}^{(l)}} \quad (15)$$

簡略化のため、第2項を省略し、次式で表す。

$$\frac{\partial u_k^{(l)}(t)}{\partial w_{km}^{(l)}} = y_k^{(l)}(t) z^{-m} \quad (16)$$

(14)式は、(10)、(16)式を用いて、次式のように表される。

$$\Delta w_{km}^{(l)} = \eta \cdot \delta_k^{(l)}(t) \cdot y_k^{(l)}(t) z^{-m} \quad (17)$$

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta w_{km}^{(l)}|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta w_{km}^{(l)} \Big|_{new} = \eta \cdot \delta_k^{(l)}(t) \cdot y_k^{(l)}(t) z^{-m} + \alpha \Delta w_{km}^{(l)} \Big|_{old} \quad (18)$$

ここで、

$$k = 1, 2, \dots, N_l, \quad m = 1, 2, \dots, M$$

である。

したがって、重みは次式のようにして更新される。

$$w_{km}^{(l)} \Big|_{new} = w_{km}^{(l)} \Big|_{old} + \Delta w_{km}^{(l)} \Big|_{new} \quad (19)$$

(c) 出力層の閾値 $b_k^{(l)}$ の更新

$$\begin{aligned} \Delta b_k^{(l)} &= -\eta \frac{\partial E(t)}{\partial b_k^{(l)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_k^{(l)}(t)} \frac{\partial u_k^{(l)}(t)}{\partial b_k^{(l)}} \end{aligned} \quad (20)$$

$$\frac{\partial u_k^{(l)}(t)}{\partial b_k^{(l)}} = 1 + \sum_{m=1}^M w_{km}^{(l)} \frac{\partial y_k^{(l)}(t) z^{-m}}{\partial b_k^{(l)}} \quad (21)$$

簡略化のため上式の第2項を省略し、次式で表す。

$$\frac{\partial u_k^{(l)}(t)}{\partial b_k^{(l)}} = 1 \quad (22)$$

(20)式は、(10)、(22)式から、次式のようになる。

$$\Delta b_k^{(l)} = \eta \cdot \delta_k^{(l)}(t) \quad (23)$$

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta b_k^{(l)} \Big|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta b_k^{(l)} \Big|_{new} = \eta \cdot \delta_k^{(l)}(t) + \Delta b_k^{(l)} \Big|_{old} \quad (24)$$

したがって、閾値は次式のようにして更新される。

$$b_k^{(l)} \Big|_{new} = b_k^{(l)} \Big|_{old} + \Delta b_k^{(l)} \Big|_{new} \quad (25)$$

(2.2) 中間層の重みと閾値の更新

(a) 中間層の重み $w_{jmi}^{(l-1)}$ の更新

$$\begin{aligned} \Delta w_{jmi}^{(l-1)} &= -\eta \frac{\partial E(t)}{\partial w_{jmi}^{(l-1)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_j^{(l-1)}(t)} \frac{\partial u_j^{(l-1)}(t)}{\partial w_{jmi}^{(l-1)}} \end{aligned} \quad (26)$$

$$\frac{\partial u_j^{(l-1)}(t)}{\partial w_{jmi}^{(l-1)}} = y_j^{(l-2)}(t) z^{-i} + \sum_{m=1}^M w_{jm}^{(l-1)} \frac{\partial y_j^{(l-1)}(t) z^{-m}}{\partial w_{jmi}^{(l-1)}} \quad (27)$$

簡略化のため、第2項を省略し、次式で表すものとする。

$$\frac{\partial u_j^{(l-1)}(t)}{\partial w_{jmi}^{(l-1)}} = y_j^{(l-2)}(t) z^{-i} \quad (28)$$

中間層 $(l-1)$ から中間層 $(l-2)$ に向かって帰還される学習信号 $\delta_j^{(l-1)}$ は、次式より求められる。

$$\begin{aligned} \delta_j^{(l-1)}(t) &= -\frac{\partial E(t)}{\partial u_j^{(l-1)}(t)} \\ &= -\frac{\partial E(t)}{\partial y_k^{(l)}(t)} \frac{\partial y_k^{(l)}(t)}{\partial u_k^{(l)}(t)} \frac{\partial u_k^{(l)}(t)}{\partial y_j^{(l-1)}(t)} \frac{\partial y_j^{(l-1)}(t)}{\partial u_j^{(l-1)}(t)} \\ &= \sum_{k=1}^{N_l} \delta_k^{(l)} \cdot w_{kji}^{(l)} \cdot f'(u_j^{(l-1)}(t)) \end{aligned} \quad (29)$$

(26)式の重みの修正量 $\Delta w_{jmi}^{(l-1)}$ は、次式のように表される。

$$\Delta w_{jmi}^{(l-1)} = \eta \cdot \delta_j^{(l-1)}(t) \cdot y_j^{(l-2)}(t) z^{-i} \quad (30)$$

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta w_{jmi}^{(l-1)} \Big|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta w_{jmi}^{(l-1)} \Big|_{new} = \eta \cdot \delta_j^{(l-1)}(t) \cdot y_j^{(l-2)}(t) z^{-j} + \alpha \cdot \Delta w_{jmi}^{(l-1)} \Big|_{old} \quad (31)$$

したがって、重みは次式のようにして更新される。

$$w_{jmi}^{(l-1)} \Big|_{new} = w_{jmi}^{(l-1)} \Big|_{old} + \Delta w_{jmi}^{(l-1)} \Big|_{new} \quad (32)$$

(b) 右辺第2項の重み $w_{jm}^{(l-1)}$ の更新

FIR 型ニューラルネットワークの場合には、 $w_{jm}^{(l-1)} = 0$ であるので以下の計算は不要である。

$$\begin{aligned} \Delta w_{jm}^{(l-1)} &= -\eta \frac{\partial E(t)}{\partial w_{jm}^{(l-1)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_j^{(l-1)}(t)} \frac{\partial u_j^{(l-1)}(t)}{\partial w_{jm}^{(l-1)}} \end{aligned} \quad (33)$$

$$\frac{\partial u_j^{(l-1)}(t)}{\partial w_{jm}^{(l-1)}} = y_j^{(l-1)}(t) z^{-m} + \sum_{m=1}^M w_{jm}^{(l-1)} \frac{\partial y_j^{(l-1)}(t) z^{-m}}{\partial w_{jm}^{(l-1)}} \quad (34)$$

簡略化のため、第2項を省略し、次式で表す。

$$\frac{\partial u_j^{(l-1)}(t)}{\partial w_{jm}^{(l-1)}} = y_j^{(l-1)}(t) z^{-m} \quad (35)$$

(33)式は、(29)、(35)式を用いて、次式のように表される。

$$\Delta w_{jm}^{(l-1)} = \eta \cdot \delta_j^{(l-1)}(t) \cdot y_j^{(l-1)}(t) z^{-m} \quad (36)$$

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta w_{jm}^{(l-1)} \Big|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta w_{jm}^{(l-1)} \Big|_{new} = \eta \cdot \delta_j^{(l-1)}(t) \cdot y_j^{(l-1)}(t) z^{-m} + \alpha \Delta w_{jm}^{(l-1)} \Big|_{old} \quad (37)$$

(c) 中間層の閾値 $b_j^{(l-1)}$ の更新

$$\begin{aligned} \Delta b_j^{(l-1)} &= -\eta \frac{\partial E(t)}{\partial b_j^{(l-1)}} \\ &= -\eta \frac{\partial E(t)}{\partial u_j^{(l-1)}(t)} \frac{\partial u_j^{(l-1)}(t)}{\partial b_j^{(l-1)}} \end{aligned} \quad (38)$$

$$\frac{\partial u_j^{(l-1)}(t)}{\partial b_j^{(l-1)}} = 1 + \sum_{m=1}^M w_{jm}^{(l)} \frac{\partial y_j^{(l-1)}(t) z^{-m}}{\partial b_j^{(l-1)}} \quad (39)$$

簡略化のため上式の第2項を省略し、次式で表す。

$$\frac{\partial u_j^{(l-1)}(t)}{\partial b_j^{(l-1)}} = 1 \quad (40)$$

(38)式は、(29)、(40)式から、次式のようになる。

$$\Delta b_j^{(l-1)} = \eta \cdot \delta_j^{(l-1)}(t) \quad (41)$$

ここで、ニューラルネットワークの計算の安定化を図るため、慣性項 $\alpha \cdot \Delta b_j^{(l-1)} \Big|_{old}$ を加えると修正量は、次式のように表される。

$$\Delta b_j^{(l-1)} \Big|_{new} = \eta \cdot \delta_j^{(l-1)}(t) + \alpha \Delta b_j^{(l-1)} \Big|_{old} \quad (42)$$

したがって、閾値は次式のようにして更新される。

$$b_j^{(l-1)} \Big|_{new} = b_j^{(l-1)} \Big|_{old} + \Delta b_j^{(l-1)} \Big|_{new} \quad (43)$$

4. 予測問題への応用

本節では、FIR/AIR ニューラルネットワークを風速の時系列予測に適用してみた。風況データとしてはそこで、青森県津軽海峡で観測された風速を用い、ニューラルネットワークの風速の予測能力を検討した。もとより時系列データから予測する方法は、短期的な予測であり、長期的予測には気象データを取込むことが必要であるが、今回は、短期的な予測に焦点を絞ることとする。

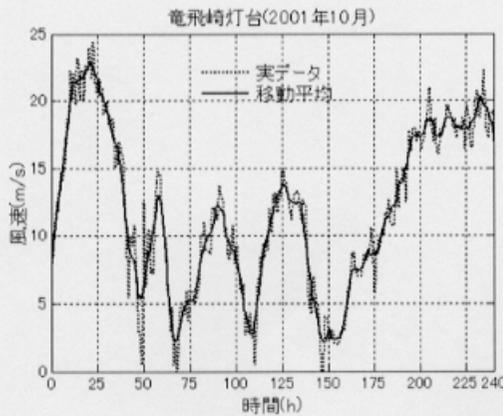


図8 竜飛崎灯台の風速

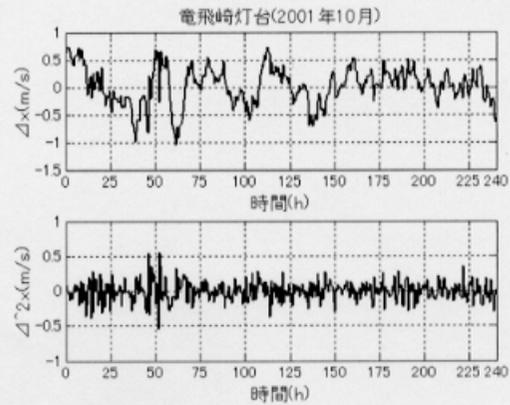


図9 風速の変化分 $\Delta x(t)$, $\Delta^2 x(t)$

4.1 風況データの採取

前述のように、風況データは青森県・津軽海峡地域の灯台で採取されたデータを用いた。具体的には、竜飛崎、松前崎、大間崎、恵山岬、尻屋崎の灯台で採取されたデータである。この中、図8は竜飛崎灯台の実風速と移動平均値を示す。

4.2 生データの雑音成分の除去

生データをそのまま入力すると雑音が大きく、ニューラルネットワークの学習がうまくいかない。そこで、線形予測法、ウェーブレット変換、移動平均法などの方法を用いて、雑音成分を取り除く試みを行った。線形予測法は、変化の大きいところで実データとの差が大きく、また、ウェーブレット変換は細かい雑音成分を除くことはできるが、波形の滑らかさが失われる。雑音成分の除去と波形の滑らかさを満たすのが移動平均法であった。そこで、本稿では以下のような移動平均式を用いて雑音成分を除いた。

$$\hat{x}_j(t) = \sum_{i=-m}^m \frac{x_{j+i}(t)}{2m+1} \quad (45)$$

$m = 5$, $\hat{x}_j(t)$: 移動平均, $x_i(t)$: 生データ

図8には移動平均したデータも示してある。

4.3 ニューラルネットワークの構成

つぎにニューラルネットワークの学習は移動

平均したデータを用いて行ったが、風速のデータそのものを用いると、学習データの変動幅が大きく学習がうまくいかない。また、トレンド分、季節成分も含まれている。そこで、これらの成分を除くために風速の差分を用いることにした。1次差分と2次差分をとったものを図9に示す。さらに、3次差分も考えられるが、かなり小さくなるので2次差分までに留めることにした。また、ニューラルネットワークは2入力、1中間層、出力層から成る構成とした。中間層のシナプス関数はシグモイド、出力層のシナプス関数は線形関数である。

(a) 中間層数の検討

ニューラルネットワークの構成は中間層数で決まる。この数は試行錯誤的に決めるのが実際的である。そこで、中間層数を変えて実験してみたのが図10である。2乗誤差は(7)式で与えられ、ニューラルネットワークの適合度を判断する目安になる。

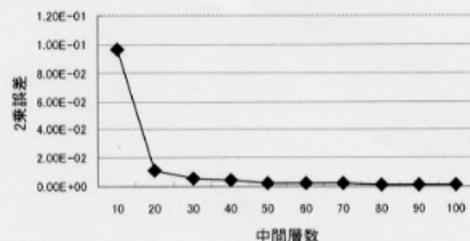


図10 中間層数と2乗誤差

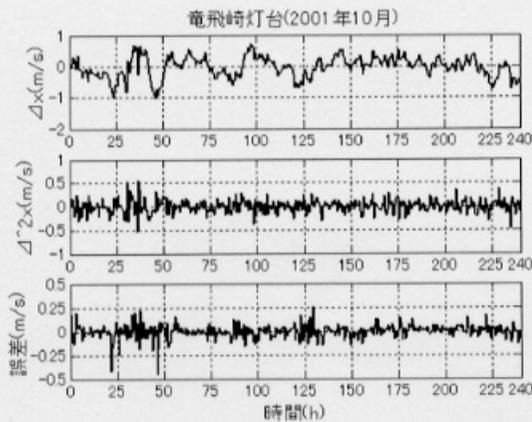


図 11 1 ステップ先の風速の予測誤差

図 10 の結果から、中間層数が 30 以上になると 2 乗誤差があまり変化しないことが分かる。そこで、本稿では中間層数を 30 とすることとした。ニューラルネットワークの学習は、学習データとして現時点の風速の 1 次差分、2 次差分、教師データとして 1 ステップ先の風速の 1 次差分を用いた。データの半分を学習に用い、残りの半分を汎化能力の検査に用いた。図 11 は FIR ニューラルネットワークで 1 ステップ先の風速の差分を予測したときの予測誤差である。図から分かるように、1 次差分、2 次差分の大きいところでは予測誤差が大きい。しかし、予測誤差は ± 0.25 (m/s) 程度であり、平均風速 8m/s では \pm 約 3 (%) の相対誤差であるので実用上十分な精度である。今回図示しないが、2 ステップ先の予測も可能である。しかし、あまり予測ステップを大きく取ろうとする場合、気象デ

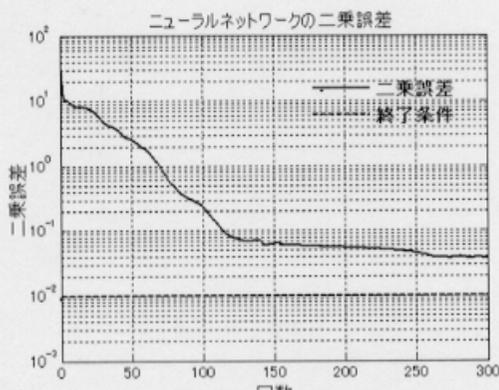


図 12 ニューラルネットワークの収束状況

ータを加えなければならないので、ニューラルネットワークの規模と計算時間が大きくなる。図 12 はニューラルネットワークの学習の収束状況を示す。300 回の繰り返しで十分収束していることが分かる。

(b) FIR/IIR ニューラルネットワークおよび線形予測法との比較

表 1 FIR/IIR ニューラルネットワークおよび線形予測法の予測誤差の 2 乗平均の比較

		FIR型	IIR型	線形予測法
鎌作埼	10月	2.841E-02	3.343E-02	4.095E-01
	11月	3.616E-02	3.636E-02	4.230E-01
	12月	3.651E-02	4.083E-02	4.390E-01
大間埼	10月	2.437E-02	2.455E-02	1.211E-01
	11月	3.746E-02	3.897E-02	3.941E-01
	12月	3.960E-02	3.879E-02	3.174E-01
灰屋埼	10月	3.602E-02	3.727E-02	3.328E-01
	11月	3.198E-02	2.984E-02	1.439E-01
	12月	4.242E-02	4.105E-02	4.755E-01
竜飛埼	10月	3.190E-02	3.322E-02	2.152E-01
	11月	4.643E-02	5.075E-02	3.243E-01
	12月	3.162E-02	3.039E-02	1.772E-01

表 1 は FIR 型、IIR 型ニューラルネットワークおよび線形予測法 (ARMA モデル) との予測誤差の 2 乗平均の比較を示したものである。表から分かるように、FIR 型と IIR 型は、ほとんど差が無いので、構成が簡潔で収束時間の少ない FIR 型ニューラルネットワークの方が好ましいと思われる。また、線形予測法と比較すると、ニューラルネットワークの方が 1 桁少ない。この結果から、統計的な手法よりもニューラルネットワークの方が予測能力が高いと云える。

5. まとめ

以上まとめると

- (1) FIR/IIR ニューラルネットワークの構成法と学習アルゴリズムを明らかにした。
- (2) FIR/IIR ニューラルネットワークの信号処理能力を評価した。
- (3) FIR/IIR ニューラルネットワークを用いた風速の短期予測法を提案し、具体的なデータに基づいて予測能力を比較した。両者の違いはほとんど無いので、構成が簡単で収束時間の少ない FIR 型の方が好ましい。

(4) FIR/IIR ニューラルネットワークと線形予測法を比較した結果、統計的な手法である線形予測法よりも、ニューラルネットワークの方が予測誤差が相当少ないことが分かった。

以上の研究結果を生かし、数ステップ先の風速の予測を行う手法を研究し、風速の予測に役立てたいと考えている。

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) LiLin et al: "Predicting wind behavior with neural networks", EU Wind Energy Conference, Gortborg, 1996, pp.15.22,
- 4) 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,
- 5) G.Kariniotakis et al: "Wind power forecasting using advanced neural networks models", IEEE Trans on EC, Vol.11, No.4, 1996, pp.762-767
- 6) 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
- 7) D.A.Bechrakis et al: "Wind speed prediction using artificial neural networks", Wind Engineering, Vol.22, No.66, pp.287-295
- 8) 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
- 9) 木村, 松坂, 加川: IIR型ニューラルネットワークの磁極形状最適化への応用, 電気学会論文誌 D、Vol.122-4、2002、pp.366-374
- 10) 星、松坂、木村: FIR型/IIR型ニューラルネットワークの構成法と応用に関する研究、計測自動制御学会東北支部209回研究集会、資料番号209-8、2003
- 11) 星、松坂、木村: FIR/IIR型ニューラルネットワークの構成に関する研究、H15年度電気関係学会東北支部連合大会、2J4、2003
- 12) 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.、Vol.、2004