

FIR/IIR 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

星 文 伸*・松 坂 知 行**・木 村 昭 穂***

Prediction of Time Series Signal with FIR/IIR Neural Network

Fuminobu HOSHI*, Tomoyuki MATSUZAKA** and Akio KIMURA***

Abstract

This paper treats a prediction method of time series signal using neural networks. The conventional feed forward neural network is not appropriate for time series prediction since they do not contain the delay elements which act as memory function. The authors proposed FIR/IIR neural networks which have memory action of time series signal, and found that they have good prediction ability.

Key words : neuralnetwork, prediction, time series signal

1. ま え が き

ニューラルネットワークは柔軟な情報処理能力をもっているため、これまで、パターン認識、制御、予測問題などの分野に利用されてきた。パターン認識などの問題に対しては、内部に記憶要素をもたないフィードフォワード型のニューラルネットワークで対処できるが、制御、予測問題ではダイナミックシステムを取り扱う必要があるので、内部に記憶要素をもったニューラルネットワークが必要になる¹⁾。特に、非線形ダイナミクスをもったシステムにはニューラルネットワークが有効である。

筆者らは、これまで、非線形システムの同定や形状最適化問題を解くために FIR 型、IIR 型ニューラルネットワークを用いることを提案してきた^{2),3)}。FIR/IIR 型ニューラルネットワーク

は、バックプロパゲーションに基づいた通常の階層型ニューラルネットワークの重みを FIR/IIR シナプスに置き換えた階層型ニューラルネットワークである。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る。つぎに、2つのニューラルネットワークの同定能力を比較する。最後に、FIR ニューラルネットワークを予測問題に適用し、予測能力を検討したので報告する。

2. ニューラルネットワークの構成

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

平成 15 年 12 月 19 日受理

* 大学院工学研究科電気電子専攻博士前期課程・1 年

** システム情報工学科・教授

*** システム情報工学科・助教授

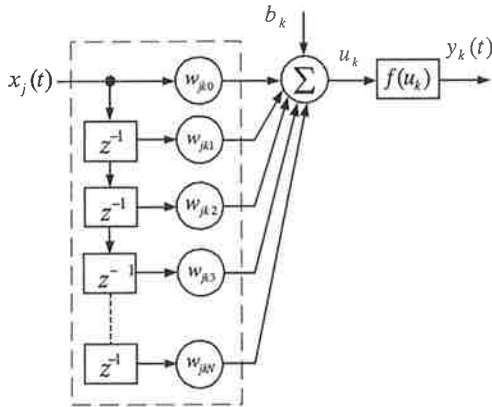


図1 FIR型ニューラルネットワークの基本要素




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

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個あれば十分である。図1の点線部分をまとめると、FIR型ニューラルネットワークは図2のように簡略表示される。また、図2の記号を用いると、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。




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

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。

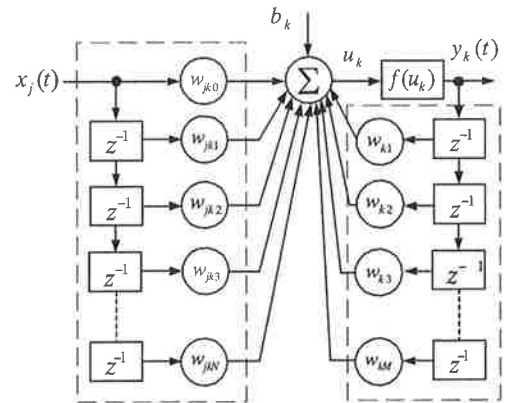


図5 IIR型ニューラルネットワークの基本要素




図6 IIR型ニューラルネットワークの簡略表示

3. 学 習 則

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^{2),3)}。

(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。

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

また, 出力は (2) 式のようにになる。

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

ここで f はシグモイド関数

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

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。

$$u_j^{(l-1)}(t) = \sum_{n=1}^{N_l} \sum_{i=0}^N w_{jni}^{(l-1)} y_n^{(l-2)}(t) Z^{-i}$$

$$+ \sum_{m=1}^M w_{jm}^{(l-1)} y_j^{(l-1)}(t) z^{-m} + b_j^{(l-1)} \quad (4)$$

中間層の出力 $y_j^{(l-1)}(t)$ は以下のようにになる。

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

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

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

ここで,

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

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

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

と定義される。時系列信号では, t は t_1, t_2, \dots ,

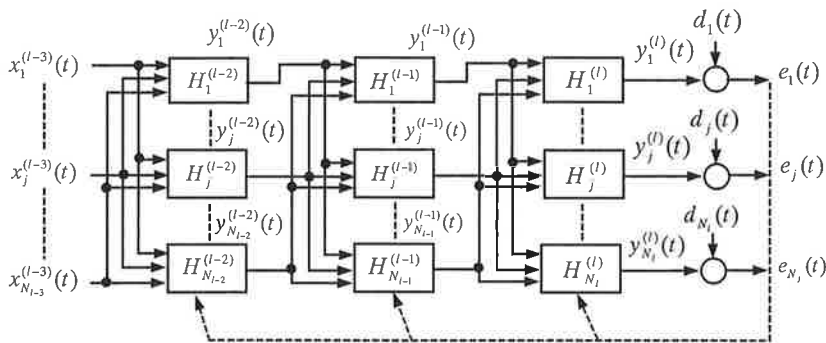


図7 ニューラルネットワークの全体の構成

t_n で表され、各時点の二乗誤差の和を用いる。

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

(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。

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

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。

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

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

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

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。

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

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。

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

(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。

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

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

簡略化のため、第2項を省略し、次式で表す。

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

(14) 式は、(10)、(16) 式を用いて、次式のように表される。

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

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。

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

ここで、

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

である。

したがって、重みは次式のようにして更新される。

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

(c) 出力層の閾値 $b_k^{(l)}$ の更新

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

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

簡略化のため上式の第2項を省略し、次式で表す。

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

(20) 式は, (10), (22) 式から, 次式のようになる。

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

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 $\alpha \cdot \Delta b_k^{(l)}|_{old}$ を加えると修正量は, 次式のように表される。

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

したがって, 閾値は次式のようにして更新される。

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

(2.2) 中間層の重みと閾値の更新

(a) 中間層の重み $w_{jni}^{(l-1)}$ の更新

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

$$\begin{aligned} \frac{\partial u_j^{(l-1)}(t)}{\partial w_{jni}^{(l-1)}} &= y_j^{(l-2)}(t) z^{-i} \\ &+ \sum_{m=1}^M w_{jm}^{(l-1)} \frac{\partial y_j^{(l-1)}(t) z^{-m}}{\partial w_{jni}^{(l-1)}} \dots (27) \end{aligned}$$

簡略化のため, 第2項を省略し, 次式で表すものとする。

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

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。

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

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

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

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 $\alpha \cdot \Delta w_{jni}^{(l-1)}|_{old}$ を加えると修正量は, 次式のように表される。

$$\begin{aligned} \Delta w_{jni}^{(l-1)}|_{new} &= \eta \cdot \delta_j^{(l-1)}(t) \cdot y_j^{(l-2)}(t) z^{-i} \\ &+ \alpha \cdot \Delta w_{jni}^{(l-1)}|_{old} \dots\dots\dots (31) \end{aligned}$$

したがって, 重みは次式のようにして更新される。

$$w_{jni}^{(l-1)}|_{new} = w_{jni}^{(l-1)}|_{old} + \Delta w_{jni}^{(l-1)}|_{new} \dots\dots (32)$$

(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。

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

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

簡略化のため, 第2項を省略し, 次式で表す。

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

(33) 式は, (29), (35) 式を用いて, 次式のように表される。

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

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 $\alpha \cdot \Delta w_{jm}^{(l-1)}|_{old}$ を加えると修正量は, 次式のように表される。

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

(c) 中間層の閾値 $b_j^{(l-1)}$ の更新

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

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

簡略化のため上式の第2項を省略し、次式で表す。

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

(38) 式は、(29)、(40) 式から、次式のようにになる。

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

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 $\alpha \cdot \Delta b_j^{(l-1)}|_{old}$ を加えると修正量は、次式のように表される。

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

したがって、閾値は次式のようにして更新される。

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

4. FIR/IIR ニューラル ネットワーク の 比較^{4),5)}

本節では、FIR/IIR ニューラルネットワークを具体的な問題に適用し、能力の比較を行う。

まず、正弦波を入力し余弦波を出力する信号変換を考える。学習データとして正弦波、教師データとして余弦波を用いた。学習データ、教師データともに、0.01 刻みで $0 \sim 2\pi$ までの範囲のデータ 629 個用いることとした。

次に、両信号ともシグモイド関数を用いるので、それにあわせて以下の式で正規化した。

$$\frac{X}{3} + 0.5 \dots \dots \dots (44)$$

ここで、 X は生の学習データ、教師データを示す。この正規化した学習データ $x(1), x(2), x(3), \dots, x(j)$ と正規化した教師データ $d(1), d(2), d(3), \dots, d(j)$ を用いてニューラルネットワークを学習させた。ニューラルネットワークの構成は、1 入力、1 出力である。




図8 2乗誤差の比較

図8は階層型 (FF 型) ニューラルネットワーク、FIR 型ニューラルネットワーク、IIR 型ニューラルネットワークとの比較を示す。2乗誤差は、各計算段階での教師信号とニューラルネットワークの推定出力との差の2乗である。この結果を見ると、遅延要素を有するニューラルネットワークは、階層型ニューラルネットワークよりも2乗誤差が少ない。特に、IIR 型ニューラルネットワークは、FIR 型ニューラルネットワークよりも2乗誤差が少ないことが分かる。ただし、計算時間はIIR 型の場合、FIR 型の約2倍の時間を要した。本研究で用いたIIR 型ニューラルネットワークは、基本要素の遅延要素が5個、中間層1, 2とも15個の基本要素をもっている。また、FIR 型ニューラルネットワークは、基本要素の遅延要素が3個、中間層1, 2とも15個の基本要素をもっている。この相違により、2乗誤差の大小が生じ、また計算時間の相違になっている。遅延要素数は、ニューラルネットワークに要求される性能によって異なるので、試行錯誤で求める以外に今のところ決定方法が見つからない。

さらに、ニューラルネットワークの収束性について述べると、初期値によって収束しない場合があるので、これを避ける方法を今後検討する必要がある。学習則の計算では、学習定数 α は0.3、慣性項の γ は0.5とした。

以上の比較から、提案する FIR/IIR ニューラルネットワークは、通常の FF 型ニューラルネットワークに比較して信号変換能力が高いことが明らかになった。特に、FIR 型ニューラルネットワークは安定で収束速度も速く、2 乗誤差も少ないことが分かった。

5. 予測問題への応用

本節では、FIR/IIR ニューラルネットワークを時系列信号の予測に適用してみた。時系列信号には、株価、天候などさまざまなデータがあるが、本節では風速の予測を取り上げる。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、変動が大きいので、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。風速の変動を事前に予測できれば、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データとなる。そこで、青森県津軽海峡で観測された風況データを用いて風速の予測方法を検討した。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にする。

5.1 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 9 は竜飛崎灯台の実風速と移動平均値を示す。

5.2 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




図 9 竜飛崎灯台の風速

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。

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

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

図 9 には移動平均したデータも示してある。

5.3 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 10 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




図10 風速の変化分 $\Delta x(t)$, $\Delta^2 x(t)$




図12 1ステップ先の風速の予測誤差

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である。そこで，中間層数を変えて実験してみたのが図11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11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，教師データとして1ステップ先の風速を用いた。データの半分を学習に用い，残りの半分为汎化能力の検査に用いた。図12はFIRニューラルネットワークで1ス

テップ先の風速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8 m/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13はニューラルネットワークの学習の収束状況を示す。300回の繰り返して十分収束し




図11 中間層数と2乗誤差




図13 ニューラルネットワークの収束状況
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はFIR型、IIR型ニューラルネットワークおよび線形予測法との予測誤差の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。

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
鱸作埼	10 月	3.841E-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
尻屋埼	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

6. 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、津軽海峡全域の風況予測に役立てたいと考えている。

参 考 文 献

- 1) J. Wesley Hines: Fuzzy and Neural Approaches in Engineering MATLAB Supplement, 63/101, John Wiley and Sons (1997)
- 2) 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), 121-C-3, 662/672 (2001)
- 3) 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, 122-4, 366/374 (2002)
- 4) 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第209回研究 (2003.6.12), 資料番号209-8
- 5) 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