

テストデータのない場合の効率的な時系列予測

福永 好伸・井上 浩孝*・成久 洋之**

岡山理科大学大学院工学研究科修士課程情報工学専攻
*岡山理科大学大学院工学研究科博士課程システム科学専攻

**岡山理科大学工学部情報工学科

(2000年11月1日 受理)

1 まえがき

ニューラルネットワーク (Neural Network: 以下, NN と記す) を用いた場合に限らず, 時系列予測では時系列に潜む隠れた特徴をいかに読み取るかが大きな問題となる. NN は過去の時系列データを学習させることによりその特徴を掴むことができる. 但し, 学習によって時系列の特徴を掴めたからといって正確な予測ができるわけではない. それは NN が既知のパターンを認識させる場合には高い精度を誇るが, 未知パターンの認識は困難であり, NN への入力パターンによっては全く見当違いな予測値を出力するからである. その為, NN による時系列予測には時系列の学習を行う訓練データと予測時の入力となるテストデータが必要である. しかし, 現実の予測問題にはテストデータが存在せず, このような状況での NN による予測は非常に困難である [1].

本研究では時系列予測を効率的に行う NN の構築法を提案する. 本提案は予測時のテストデータを訓練データから擬似テストデータとして作り出し, 予測を行うというものである. そしてこれを NN の代表的な学習アルゴリズムである誤差逆伝播 (Back Propagation: 以下, BP と記す) 法に適用した場合の有効性について検討する.

2 NN による時系列予測の概要

NN は脳の神経細胞のネットワークを工学的にモデル化したものであり, 文字や音声等のパターン認識および予測などの認知的な仕事を最も得意とし, それらの分野において実用的な応用事例がでていいる. また, 時系列とはデータが時間に依存して出力されるものであり, 例えばデパートの1日の売上高や円の相場などである. この時系列における予測とは過去の時系列のデータを元に, 未来におけるデータの動向を占うというものである.

時系列予測を NN に行わせる場合, まずは時系列の特徴を掴むために訓練データが必要になる. これは予測を行う地点よりも過去の時間におけるデータの動向であり, 先程の例で考えると, デパートの過去数ヶ月間もしくは数年間の売上状況となる. この訓練データを用いてネットワークを学習させることにより, この時系列に適用する NN が構築できる. そして, このネットワークを使用して予測を行うが, このときにテストデータがある場合 (図1) とない場合 (図2) では予測の仕方が大きく違ってくる.

テストデータとは予測時にネットワークへの入力となるデータであり, これは予測を行う時刻よりも過去の正確なデータである. その為, あらかじめテストデータが用意されている場合は, ある程度の予測波形は保証される.

一方, テストデータがない場合, NN の構造は図3のように時刻 t の出力 (予測値) y_{t+1} を時間遅延させて次の時刻の入力に利用するというものである. しかし, このようなネットワーク構造で逐次予測を行っていくと, 予測を行う度に予測値に微妙なずれが生じ, 誤差が蓄積されていくことになる. すると, いずれは入力が訓練データに存在しない未知のパターンになってしまい, 正確な予測はおろか, 一定の値しか出力しないようになる (図4).

本研究ではテストデータがない場合に起こるこのような状態を防ぐ為に、訓練データから擬似的にテストデータを導出し、テストデータのない場合の予測でも効率的に予測が行える手法を提案する。

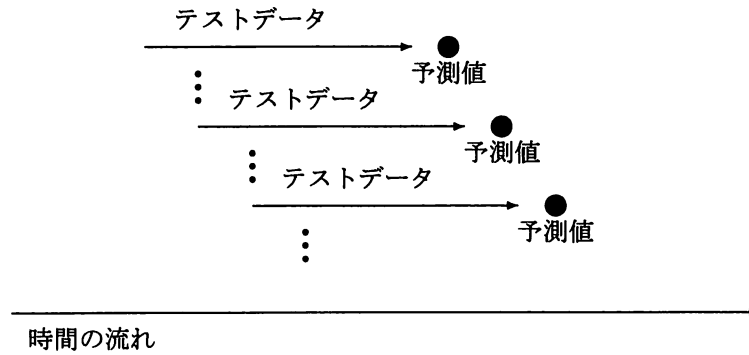


図 1 テストデータがある場合の予測

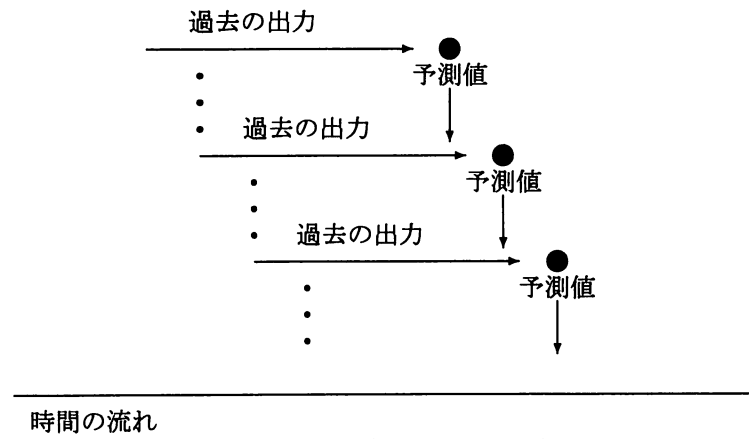


図 2 テストデータがない場合の予測




図 3 テストデータがない場合の NN の構造




図 4 テストデータがある場合とない場合の Mackey-Glass の予測波形の比較

3 擬似テストデータの導出

本研究で行った擬似テストデータの導出方法はまず、訓練データ分の NN を作成し、それを予測時に比較して最も近い NN を選び出して、予測を行うというものであり、具体的には以下のように行われる (図 5)。

- step1: 時刻 t ごとの重み w_{tij} を訓練データ $D(d_{t_0}, d_{t_1}, \dots, d_{t_N})$ を用いて学習させ、訓練データ分の NN を作成する。
- step2: 予測時刻 t_p のネットワークへの入力パターンを訓練データ時刻 $t_0 \sim t_N$ のときの入力パターンと比較し、最も近い入力パターンを持つ時刻 t_c を選出する。
- step3: 時刻 t_c のときの重み $w_{t_c,ij}$ を持つ NN_{t_c} を用いて、擬似的な予測をすることにより、擬似テストデータを作成する。

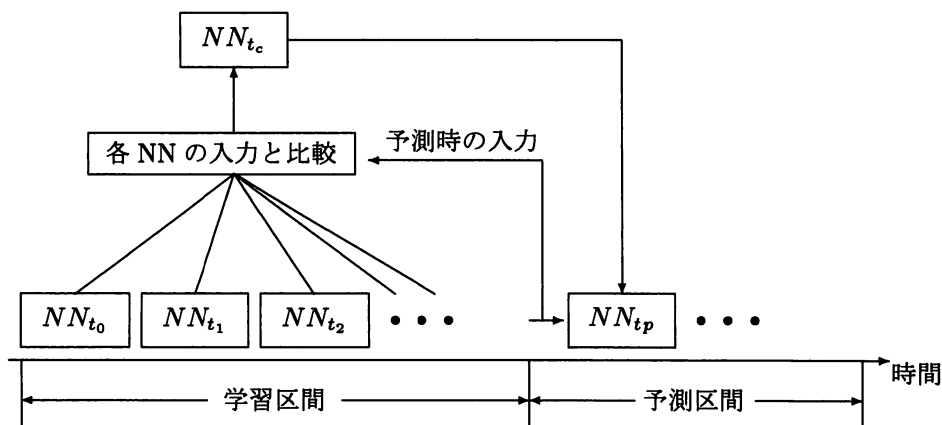


図 5 擬似テストデータ作成のイメージ

4 BP について

NN の学習には与えられた問題に対して正しい答えを示唆する教師あり学習と正しい答えを示唆しない教師なし学習があるが、BP は前者の代表的な学習アルゴリズムである。これはネットワークを進んでいく信号の流れとは逆方向に向かって再帰的に誤差の修正が行われていくので BP 法と呼ばれている。学習の仕方を具体的に説明すると以下ようになる。




図6 NNの入出力の構造

いま, 図6のように入力ユニットに p 番目のパターンを提示するものとして, i 番目の入力ユニットへの入力信号を x_{pi} , j 番目の出力ユニットからの出力信号を y_{pj} , j 番目の出力ユニットに対して提示する教師信号を T_{pj} とする. また, w_{ij} はユニット i からユニット j への重みを表し, s_{pj} は p 番目のパターンのときのユニット j の内部状態を表す. NN の入出力は次式で表される.

$$y_{pj} = f_j(s_{pj}) \quad (4.1)$$

$$s_{pj} = \sum_i w_{ij} x_{pi} \quad (4.2)$$

$$x_{pi} = \begin{cases} u_{pi} & \text{if } i \in I \\ y_{pi} & \text{if } i \in H \cup O \end{cases} \quad (4.3)$$

ここで, I, O はそれぞれ入力ユニット, 出力ユニットの集合を表し, H はそれ以外のユニットを表す. ここで $f_j(\cdot)$ はニューロンの入出力関数であり, 一般的に次式で表されるシグモイド関数が用いられる.

$$x_i = \frac{1}{1 + \exp(-\alpha s_i)} \quad (4.4)$$

このときに誤差測度 E_p を,

$$E_p = \frac{1}{2} \sum_j e_{pj}^2 \quad (4.5)$$

$$\text{ただし, } e_{pj} = \begin{cases} y_{pj} - T_{pj} & \text{if } j \in \text{Output layer} \\ 0 & \text{otherwise} \end{cases} \quad (4.6)$$

のように定義すると,

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial s_{pj}} \frac{\partial s_{pj}}{\partial w_{ij}} = \frac{\partial E_p}{\partial s_{pj}} x_{pi} \quad (4.7)$$

が成り立つ。従って、

$$\delta_{pj} \stackrel{\text{def}}{=} \frac{\partial E_p}{\partial s_{pj}} \quad (4.8)$$

とすると、

$$\frac{\partial E_p}{\partial w_{ij}} = \delta_{pj} x_{pi} \quad (4.9)$$

となり、 p 番目のパターンに対して、重み w_{ij} を、

$$w_{ij}^{NEW} = w_{ij}^{OLD} + \Delta_p w_{ij} \quad (4.10)$$

$$\Delta_p w_{ij} = -\eta \delta_{pj} x_{pi} \quad (4.11)$$

のように修正することができる。また、このときの δ_{pj} は、

$$\begin{cases} \text{ユニット } j \text{ が出力層:} & \delta_{pj} = f'_j(s_{pj}) e_{pj} \\ \text{ユニット } j \text{ が出力層以外の層:} & \delta_{pj} = f'_j(s_{pj}) (\sum_k \delta_{pk} w_{jk}) \end{cases} \quad (4.12)$$

とする。

5 実験内容及び結果

本実験では時系列データとして、次式で表される Mackey-Glass の微分方程式及び、Sunspot と Stock Price を使用した。

$$\frac{dx(t)}{dt} = -bx(t) + a \frac{x(t-\tau)}{1+x(t-\tau)^{10}} \quad (5.1)$$

Mackey-Glass の各種パラメータは $a = 0.2$, $b = 0.1$, $\tau = 17$ とし、このパラメータにおいて波形はカオスの振る舞いを見せる [2]。Sunspot は 1700 年から 1999 年までの年間平均発生量 [3] で、Stock Price は 1985 年 1 月から 1987 年 12 月までの S&P500 の各週末の終値である [4]。予測に使用した学習区間及び予測区間は表 1 のとおりである。また、ネットワーク構造及び学習パラメータは共に、入力層 10, 中間層 10, 出力層 1, 学習係数 0.05, シグモイド関数の傾き 0.5, 慣性項の係数 0.5 とした。

時系列	Mackey-Glass	Sunspot	Stock Price
学習区間	0 ~ 999	0 ~ 269	0 ~ 139
予測区間	1000 ~ 1099	270 ~ 299	140 ~ 155

図7, 図8, 図9は Mackey-Glass, Sunspot, Stock Price における予測値の比較であり, これらには target, ① prediction1, ② prediction2, ③ prediction3 の4種類の波形が示されている. ①はBPのみで予測を行ったもので②は擬似テストデータのみを出力したもので③は②を①の入力パターンとして予測を行ったものである.

図7に示される Mackey-Glass 及び図9の Stock Price の時系列波形に対しては②が最も target に近い波形を出力していることがわかる. これは②が擬似とはいえ, これ自体が非常に精度の高い予測である為, BPを使った①や③よりも良好な結果が得られるためである. これとは逆に図8に示される Sunspot の予測波形では③が最も優れていることがわかる. これは②の手法がデータ重視の出力をするのに対し, ①は規則性や周期を重視した予測をするためである. そのため, BPによって比較的周期の掴み易い時系列では③が最も有効である.

6 まとめ

本研究ではテストデータの存在しない場合の効率的な時系列予測のために, 訓練データと予測時の入力パターンを比較することにより擬似テストデータを導出する手法を提案した. 本手法をNNの代表的な学習法であるBPに適用し, 三つの時系列データに対する予測結果より, 本手法の有効性が確認された. しかし, 扱う時系列により効果に違いがある為, 問題に応じてこの入力パターンの選出方法を変えることや, BP以外における有効性も検討する必要があると思われる.

参考文献

- [1] N. A. Gershenfeld and A. S. Weigend, "The future of time series : Learning and understanding," in TIME SERIES PREDICTION : Forecasting the future and understanding the past, Eds. A. S. Weigend and N. A. Gershenfeld, pp.1-70 (1994)
- [2] M. C. Mackey and L. Glass, "Oscillation and Chaos in Physiologist Control Systems," Science, vol. 197, pp. 287-289 (1977)
- [3] Sunspot Index Data Center, <http://sidc.oma.be/index.php3>
- [4] 今井兼範: "ニューラルネットワーク-コレクション-", 共立出版 (1990)
- [5] 西川禎一: "ニューラルネットと計測制御," 朝倉書店 (1995)
- [6] Li Lin and Jarl-Thure Eriksson, "Non-Linear Time Series Prediction Using an Optimum Neural Network Architecture," in proceedings of the International Conference on Neural Information Processing(ICONIP'96), Hong Kong, 24-27 September 1996, vol. 2, pp.737-741 (1996)




図 7 Mackey-Glass における予測値の比較




図 8 Sunspot における予測値の比較




図 9 Stock Price における予測値の比較

Effective Closed-Loop Prediction with Neural Networks

Yoshinobu FUKUNAGA, Hiroataka INOUE* and Hiroyuki NARIHISA**

Graduate School of Engineering,

** Doctoral Program in System Science,*

Graduate School of Engineering,

*** Department of Information & Computer Engineering,*

Faculty of Engineering,

Okayama University of Science,

Ridaicho 1-1, Okayama 700-0005, Japan

(Received November 1, 2000)

Recently, artificial neural network(NN) have been widely used in various fields for classification and pattern recognition mainly because of their feature extraction potential for the given input data set. Due to this feature extraction ability, there have been many papers concerning time series prediction with NN. Almost all of these papers use a preprovided test data set as a benchmark problem. However, no test data for the case of real world time series prediction problems exists. In this paper, we present an effective time series prediction with NN, by constructing pseudo test data from given training data.