

## 複合ニューラルネットワークによる 効率的なカオス時系列予測に関する研究

### A Study on Efficient Hybrid Neural Network for Chaotic Time Series Prediction

濱田 翼<sup>†</sup>

Tsubasa Hamada

井上 浩孝<sup>‡</sup>

Hirotaka Inoue

#### 1. まえがき

バックプロパゲーション学習を行う一般的な階層型ニューラルネットワークと最近傍決定則を使用する単純なローカルモデルを組み合わせた複合ニューラルネットワークを提案する。この手法の特徴は階層型ニューラルネットワーク及びローカルモデルで単独に予測するよりも長期的な予測が可能になる点にある。これはそれぞれの単独の予測器によって出力された予測値を各予測器のもつ出力特性で補正することにより実現されるものである。本研究では Mackey-Glass データ [1] や 1988 年にベルギーの K.U.Leuven で開かれた時系列予測のベンチマーク問題 [2] に適応させて本提案手法の有効性を示す。

#### 2. 複合ニューラルネットワークの構造

複合ニューラルネットワークの構造は図 1 のようになる。このように階層型ニューラルネットワーク ( $c_1$ ) とローカルモデル ( $c_2$ ) のそれぞれの出力を統合して、新たな予測値としてネットワークの出力とするものである。そして、複合により出力された予測値はフィードバックされ、次の時刻における各予測器の入力値として使用される。ある時刻  $t$  の複合ニューラルネットワークの期待出力を  $x_t$  とするとネットワークの出力  $y_t$  は次式のように計算される。

$$y_t = w_{c_1} y_{c_1t} + w_{c_2} y_{c_2t} \quad (1)$$

式 (1) における  $w_{c_1}$  は階層型ニューラルネットワーク、 $w_{c_2}$  はローカルモデルそれぞれの寄与率を示すものである。寄与率とは各予測器の時系列予測問題に対する適合度合いを表すものであり、予測時刻以前の既知のデータ区間を利用して求める。具体的には扱う問題に対する  $c_1$ ,  $c_2$  それぞれの評価値を  $e_{c_1}$ ,  $e_{c_2}$  とすると、次のように表すことができる。

$$w_{c_1} = \frac{e_{c_2}}{e_{c_1} + e_{c_2}} \quad (2)$$

$$w_{c_2} = \frac{e_{c_1}}{e_{c_1} + e_{c_2}} \quad (3)$$

本研究では予測器の評価基準に誤差を利用するため、評価値が小さいほど寄与率が高くなるように式を設定して




図 1 複合ニューラルネットワークの構造

<sup>†</sup> 呉工業高等専門学校専攻科機械電気工学専攻

<sup>‡</sup> 呉工業高等専門学校電気情報工学科

いる。また、各予測器の寄与率の間には次の関係が成り立つ。

$$w_{c_1} + w_{c_2} = 1.0 \quad (4)$$

評価値の求め方には種々の方法があるが、本研究では NMSE (Normalized Mean Squared Error) を利用した。NMSE は評価を行う区間を  $T$  とすると以下の式で表すことができる。

$$e_{c_1} = \frac{\sum_{t \in T} (y_{c_1t} - x_t)^2}{\sum_{t \in T} (x_t - E[x])^2} \quad (5)$$

$$e_{c_2} = \frac{\sum_{t \in T} (y_{c_2t} - x_t)^2}{\sum_{t \in T} (x_t - E[x])^2} \quad (6)$$

式 (5), 式 (6) の  $y_{c_1t}$ ,  $y_{c_2t}$  は各予測器における出力である。これらを求めるために既知のデータを利用してテスト予測を行った。このように寄与率は扱う時系列に応じて自動的に取得することができるため、容易に複合構造を構築できる。

#### 3. 時系列予測問題への適用

複合ニューラルネットワークの性能を評価するために、Mackey-Glass のデータと 1998 年にベルギーの K.U.Leuven で開かれた時系列予測コンテストのデータで予測を行った。どちらのデータも学習として 2000 ステップを使用し、それ以降の 200 ステップを予測させた。このとき、複合ニューラルネットワークの予測値を次の時刻の入力値として使用した。これを 10 回ずつ試行させ、最良と平均の出力で評価を行った。また、このときの評価基準は NMSE、平均 2 乗誤差 (Mean Squared Error: MSE)、そして 2 乗誤差を時刻ごとに累積させた累積 2 乗誤差 (Accumulated Squared Error: ASE) とする。

##### 3.1 Mackey-Glass データ

次式で与えられる Mackey-Glass データはカオス時系列予測では多くの研究者が評価に使用しており、ベンチマーク的な問題である。

$$\frac{dx}{dt} = \frac{ax_{t-\tau}}{1 + (x_{t-\tau})^{10}} - bx_t \quad (7)$$

本研究で使用したデータは  $a = 0.2$ ,  $b = 0.1$ ,  $\tau = 17$  として発生させたものであり、これによりカオス時系列を発生させることが知られている。

予測時の各種パラメータは表 1 のように設定した。階層型ニューラルネットワークの入力層と中間層にはそれぞれバイアス項を付加してある。ここで、本研究における学習回数とは各回数ごとに学習区間からランダムに 1 点のみを選出し、学習させることを示している。また、時系列予測問題では、入力次元 (入力層のニューロン数) の設定が非常に重要になるが、我々は時系列の周期を基準にして定めた。

各予測器の寄与率は階層型ニューラルネットワークが 0.097、ローカルモデルが 0.903 となった。よって、この問題においてはローカルモデルの方が圧倒的に寄与率が

表1 Mackey-Glass 予測時のパラメータ

パラメータ	値
階層型ニューラルネットワーク	
入力層のニューロン数	20+1
中間層のニューロン数	10+1
学習率	0.01
学習回数	500000
ローカルモデル	
入力次元	20
k の数 (k-NN)	3

表3 K.U.Leuven 予測時のパラメータ

パラメータ	値
階層型ニューラルネットワーク	
入力層のニューロン数	10+1
中間層のニューロン数	10+1
学習率	0.01
学習回数	500000
ローカルモデル	
入力次元	20
k の数 (k-NN)	3

表2 Mackey-Glass データの予測精度

	NMSE(MSE)	
	average	best
feed-forward network	1.0021(0.0522)	0.7819(0.0408)
local model	0.2634(0.0137)	0.2634(0.0137)
hybrid model	0.2628(0.0137)	0.2628(0.0137)

表4 K.U.Leuven データの予測精度

	NMSE(MSE)	
	average	best
feed-forward network	2.6249(0.1503)	2.6660(0.1526)
local model	1.3009(0.0745)	1.3009(0.0745)
hybrid model	0.6974(0.0399)	0.4121(0.0236)

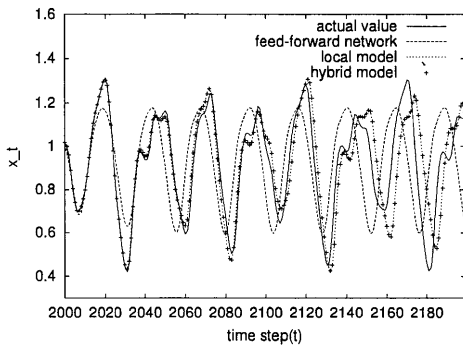


図2 Mackey-Glass データの予測波形

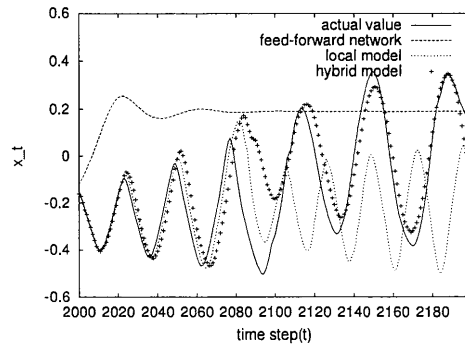


図4 K.U.Leuven データの予測波形

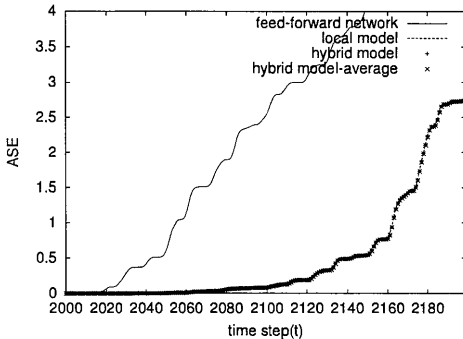


図3 予測の累積2乗誤差




図5 予測の累積2乗誤差

高く、この時系列に適応しやすい予測器といえる。

表2に各予測器における平均と最良の予測精度を比較したものを、図2に各予測器の出力波形を比較したものを、図3に各予測器の出力データ、及び複合ニューラルネットワークの平均の出力における予測の累積2乗誤差を示す。

### 3.2 K.U.Leuven competition データ

K.U.Leuven competition データは1998年のInternational Workshop(K.U.Leuven:ベルギー)において開催された時系列予測コンテストで使用された。この時系列データを予測するときの各種パラメータを表3のように設定した。寄与率は階層型ニューラルネットワークが0.346、ローカルモデルが0.654となり、Mackey-Glassデータと同様にローカルモデルの方がこの時系列に適応しやすいといえる。

表4に各予測器における平均と最良の予測精度を比較したものを、図4に各予測器の出力波形を比較したものを、

図5に各予測器の出力データ、及び複合ニューラルネットワークの平均の出力における予測の累積2乗誤差を示す。

## 4. むすび

本研究では、カオス時系列の効率的な予測を目的として、階層型ニューラルネットワークとローカルモデルにより構成された複合ニューラルネットワークを提案した。数値実験の結果、単独の予測器で行うよりも長期的な予測が可能であることを実証し、この手法の有効性を示すことができた。

## 参考文献

- [1] M.C. Mackey and L. Glass, "Oscillation and chaos in physiological control systems," Science, vol.197, pp.287-289, 1977.
- [2] J. Suykens and J. Vandewalle, "The K.U. Leuven competition data: A challenge for advanced neural networks techniques," Proc. European Symposium on Artificial Neural Network, pp.299-304, Bruges, Belgium, April 2000.