

ニューラル予測器とカオス

○安達雅春^{*}, E. Klerman^{**}, K. Judd^{**}, 合原一幸^{*}

^{*}東京電機大学・工学部・電子工学科

^{**}日本学術振興会外国人特別研究員

1. はじめに

本研究では、3層パーセプトロン型ニューラルネットワークにバックプロパゲーション学習則^[1]を適用したもの（以下、バックプロパゲーション・ニューラルネットワーク：BPニューラルネットワークと記述する。）を、カオスニューラルネットワーク（CNN）^[2]によるカオスアトラクタの学習及びカオス時系列の短期予測に適用した。

2. 2個のニューロンから成るカオスニューラルネットワーク

本研究で、アトラクタの学習及び時系列予測の対象とした、2個のニューロンから成るカオスニューラルネットワークは、次の式（1）－（3）で定義される。

$$y_1(t+1) = k_1 y_1(t) - \alpha_1 x_1(t) + w_{12} x_2(t) + A_1(t) + \theta_1 \quad (1)$$

$$y_2(t+1) = k_2 y_2(t) - \alpha_2 x_2(t) + w_{21} x_1(t) + A_2(t) + \theta_2 \quad (2)$$

$$x_i(t+1) = f(y_i(t+1)) \quad (i=1, 2) \quad (3)$$

ここで、各変数及び定数は、

$y_i(t)$: 時刻 t における i 番目ニューロンの内部状態

$x_i(t)$: 時刻 t における i 番目ニューロンの出力 ($0 \leq x_i(t) \leq 1$)

$A_i(t)$: 時刻 t における i 番目ニューロンのネットワークの外部からの入力

k_i : i 番目ニューロンの不応性の時間的減衰定数 ($0 \leq k_i < 1$)

α_i : i 番目ニューロンの定数パラメータ ($\alpha_i > 0$)

θ_i : i 番目ニューロンのしきい値

w_{ij} : j 番目ニューロンから i 番目ニューロンへの結合係数

f : ニューロンの内部状態 $y_i(t)$ と出力 $x_i(t)$ との関係を与える関数

ここでは、ロジスティック関数

$$f(y) = 1 / (1 + \exp(-y / \varepsilon_i))$$

を用いる。 ε_i は i 番目ニューロンにおけるこの関数の傾きの急峻さを表す。

3. BPニューラルネットワークによるカオスアトラクタの学習と再生

上述の2個のカオスニューロンから成るCNNのアトラクタの学習のためのパーセプトロンでは、入力層と出力層には、それぞれ2個のニューロンを用意し、中間層には適当な数のニューロンを用意する。このネットワークが時刻 t における各々

のニューロンの内部状態 $y_1(t)$, $y_2(t)$ の値を入力すると次の時刻 $t+1$ におけるニューロンの内部状態 $y_1(t+1)$, $y_2(t+1)$ を出力するように B P 則を用いて学習を行なう (図 1)。この学習は、50, 200, 500 タイムステップの 3 通りについて行い、中間層のニューロン数 9 の場合には、RMS 誤差 (二乗平均誤差) にして 0.03 程度の精度まで収束した。




図 1 B P ネットワークによるアトラクタの学習




図 2 リカレント型ネットワークによるアトラクタの再生

CNN のアトラクタを学習済みのネットワークの出力が入力にフィードバックするように修正し、図 2 に示すようにリカレント型ネットワークを構成し、この入力に初期値のみを与えて、順次出力される値を 2 次元平面上にプロットして、学習したデータのプロットと比較する。この結果、適当な条件のもとでは、学習データにかなり類似したプロットが得られることが判明した。学習データのプロットを図 3 に、リカレント型ネットワークの出力のプロットの例を図 4 にそれぞれ示す。




図 3 CNN のアトラクタ (学習データ)





図 4 リカレント型ネットワークの出力プロットの例

4. B P ニューラルネットワークによるカオス時系列の短期予測

2. で述べた CNN において、2 個のカオスニューロンのうちの片方のみの内部状態 $y_1(t)$ のカオス時系列データを学習し、この時系列の短期予測を行った。図 5 に示すように、2 入力 2 出力の B P ニューラルネットワークに、 $y_1(t)$ と時間 TL 後のデータ $y_1(t+TL)$ を入力として、 $y_1(t+1)$, $y_1(t+TL+1)$ を望ましい出力として提示し、この入出力関係を学習させる。



学習済みのネットワークを用いて、学習データとして200タイムステップ分の y_1 の時系列を用い、その後の1000タイムステップについての短期予測を行った。ここで、予測時間を次のように定義した。

図5 BPニューラルネットワークによる時系列学習

予測時間1：フィードフォワード型ネットワークに $y_1(t')$, $y_1(t'+TL)$ を入力し、出力層に予測値 $y_1(t'+TL+1)$ を得る。

予測時間2：リカレント型ネットワークに $y_1(t')$, $y_1(t'+TL)$ を入力し、イテレーション1回の後に予測値 $y_1(t'+TL+2)$ を得る。

予測時間 n ：リカレント型ネットワークに $y_1(t')$, $y_1(t'+TL)$ を入力し、イテレーション $n-1$ 回の後に予測値 $y_1(t'+TL+n)$ を得る。

予測値の評価には、相関、MSE (Mean Square Error)、RMSE (Relative Mean Square Error) を用いた。中間層のニューロン数9のネットワークにおける予測時間と相関との関係を表に示す。

表 BPニューラルネットワークによる時系列の短期予測の予測時間と相関

学習時 RMS 誤差	相 関 (%)			
	予測時間 1	予測時間 2	予測時間 3	予測時間 4
0. 0 3	9 7. 2 5	6 2. 9 2	3 6. 9 4	4. 2 0
0. 0 5	9 3. 6 5	5 1. 0 0	2 4. 1 6	0. 6 5

5. おわりに

2個のニューロンから成るカオスニューラルネットワークのカオスアトラクタは、BPニューラルネットワークによって学習可能であり、学習済みのネットワークをリカレント型にすることにより、アトラクタを再生できることも確認できた。さらに、時系列のカオスデータを学習することにより、この時系列の短期予測に適用し、この手法がある程度有効であることが判明した。今後は、ヤリイカ巨大軸索の電気生理実験で得られるカオスデータなどについても短期予測を行っていく予定である。

【参考文献】

- [1] D.E.Rumelhart et al.: Nature 323, 533-536 (1986)
- [2] K.Aihara, T.Takabe and M.Toyoda: "Chaotic Neural Networks", Phys.Lett.A. Vol.144, No.6,7, pp333-340