

# 生物的な認識ダイナミクスを利用した 文字認識ニューラルネットワーク

## A Neural Network for Character Recognition Based on the Dynamics of Biological Recognition

○鎌内 俊行\*, 本間 経康\*, 阿部 健一\*

○Toshiyuki Kamauchi\*, Noriyasu Homma\*, KenichinAbe\*

\* 東北大学

\*Tohoku University

キーワード：文字認識 (character recognition), I don't know 状態 (I don't know state),  
カオス (chaos), カオスの辺縁 (edge of chaos)

連絡先：〒980 仙台市青葉区荒巻字青葉 東北大学 工学部 電気工学科 阿部研究室  
鎌内俊行, Tel.:(022)217-7074, Fax.:(022)263-9290, E-mail:kama@abe.ecei.tohoku.ac.jp

### 1 はじめに

ニューラルネットワークを用いた文字認識の代表的なものに階層型ネットワーク<sup>1</sup>や、連想記憶ネットワーク<sup>2,3,4</sup>が提案されている。これらはいずれも静的な識別面をもとにパターンを分類する手法である。これらのネットワークモデルに未学習パターンを入力すると、それらは最も近いパターンに分類されてしまうことが知られている。一方, Freemanらの生物の認識についての実験結果によると<sup>5</sup>, a) 入力がないときは脳波はカオスを示し, b) 既知の入力があるときはリミットサイクルかそれに近い形を示し, c) 未学習パターンが入力されたときは I don't know 状態を示した後, この未学習パターンを新しいパターンとして学習することが報告されている。

本稿では Freemanらが指摘した認識課程におけるカオスの果たす役割が本質的に重要であるとの立場から, カオスダイナミクスを発生するリカレントニューラルネットワーク (RNN) を用いた認識モデルを提案する。提案モデルが, 入力がないときはカオスの状態にあり, 未学習パターンが入力されたときには I don't know 状

態になることを示す。I don't know 状態を実現することのネットワークは“知らない”ということ認識しているという意味で, 従来のニューラルネットワークモデルとは本質的に異なり, より生物的な認識ダイナミクスをもつネットワークが構成されることを示す。

### 2 ネットワークの構成

ネットワークの構造としては, 入力層と中間層と出力層の3層からなる階層型のニューラルネットワークを用いる。ただし, 入力層には相互の結合をもたせたりカレントニューラルネットワークを用い, 結合重みと閾値は予め弱いカオス (edge of chaos) を発生するように構成しておく (2.1節)。中間層, 出力層については相互結合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を用いる (Fig.1)。ネットワークをこのように構成すると, 入力層から入力された信号は以下に示すように, 中間層を経て出力層へと伝搬していく。

$$X_i(t) = G\left(\sum_j U_{ij} \cdot X_j(t-1) + S \cdot I_i(t) + \theta_i(t)\right),$$
$$H_k(t) = G\left(\sum_i V_{ki} \cdot X_i(t) + \phi_k(t)\right),$$

$$O_i(t) = G\left(\sum_k W_{ik} \cdot H_k(t) + \Psi_i(t)\right),$$

$$G(z) = \frac{1}{1 + \exp\left(-\frac{z}{\alpha}\right)}.$$

ただし,  $X_i$  は入力層の  $i$  番目のニューロンの出力値,  $U_{ij}$  は入力層のニューロン  $i, j$  間の結合の重み,  $S$  は入力パターンを入力するときの重み,  $I_i$  は入力層における  $i$  番目のニューロンへの入力値,  $\theta_i$  は入力層における  $i$  番目のニューロンの閾値,  $H_k$  は中間層の  $k$  番目のニューロンの出力値,  $V_{ki}$  は中間層の  $k$  番目のニューロンと入力層の  $i$  番目のニューロンとの結合重み,  $\phi_k$  は中間層の  $k$  番目のニューロンの閾値,  $O_i$  は出力層の  $i$  番目のニューロンの出力値,  $W_{ik}$  は出力層の  $i$  番目のニューロンと中間層の  $k$  番目のニューロンとの結合重み,  $\Psi_i$  は出力層の  $i$  番目のニューロンの閾値,  $G(z)$  はシグモイド関数,  $\alpha$  はシグモイド関数の傾きである (Fig.1).

### 2.1 RNN からのカオスの発生

RNN からカオスを発生させる方法の概要を述べる.

- RNN の結合重み  $U_{ij}$  をランダムで初期化する.
- 閾値  $\theta_i$  を次式で設定する.

$$\theta_i = -\frac{1}{2} \sum_j U_{ij}.$$

- 入力の分散と分散の平均値を次式で定義する.

$$\sigma_i^2 = \frac{1}{12} \sum_j U_{ij},$$

$$\bar{\sigma}^2 = \frac{1}{N} \sum_i \sigma_i^2.$$

ここで  $\bar{\sigma}^2$  を変化させると, 所望のリヤブノフ指数  $\lambda$  をもつ RNN を構成することが可能となる<sup>6,7</sup>(Fig.2).

### 3 学習法

Fig.1 における  $U_{ij}$  および  $\theta_i$  は弱いカオスを発生する値で固定しておき,  $V_{ki}, W_{ik}, \phi_k$  および  $\Psi_i$  をバックプロパゲーション法<sup>8</sup>によって学習させる. 以下にバックプロパゲーション法の概要を述べる. 出力層の出力を  $O_i$  とし, 望ましい出力値を  $T_i$  とすると, 出力層における誤差は次のように求められる.

$$\delta_i = (O_i - T_i) \cdot O_i \cdot (1 - O_i).$$




Fig. 1 ネットワークの構成




Fig. 2  $\sigma^2$  と  $\lambda$  の関係 (横軸:  $\sigma^2$ , 縦軸:  $\lambda$ )

この誤差を中間層に伝搬すると、中間層における誤差は中間層の出力を  $H_k$  として、

$$\sigma_k = \sum_l \delta_l \cdot W_{lk} \cdot H_k \cdot (1 - H_k),$$

と求められる。これより、結合係数と閾値の修正量が次のように求まる。

$$W_{lk} = W_{lk} + \alpha \cdot \delta_l \cdot H_k,$$

$$\Psi_l = \theta_l + \beta \cdot \delta_l,$$

$$V_{ki} = V_{ki} + \alpha \cdot \sigma_k \cdot I_i,$$

$$\phi_k = \phi_k + \beta \cdot \sigma_k.$$

ここで、 $\alpha, \beta$  は学習係数である。また、入力は一学習の間一定とする ( $I_i(t) = I_i(0) (t = 0, 1, 2, \dots)$ )。つぎにこの方法によって学習したネットワークの振る舞いを示す。

## 4 シミュレーション結果

ネットワークは入力層・中間層・出力層をそれぞれ  $64 \cdot 128 \cdot 64$  素子とし、学習パターンとして「C」「A」「S」「E」という、4つの文字パターンを用いた (Fig.3)。この4つの文字パターンを3節の方法で5ステップの間ネットワークに学習させた。なお、入力パターンにかかる重み  $S$  の値を 0.05 とした。




Fig. 3 学習させた文字パターン

### 4.1 入力がないとき

入力があるとき間 ( $t = 2$ ) で打ち切ったあとの状態を、入力がない状態とした。入力を打ち切ったあと (3ステップ目以降) はカオスの振舞いをした (Fig.4)。100

ステップ学習させたネットワークについても同様のことが確認できた。

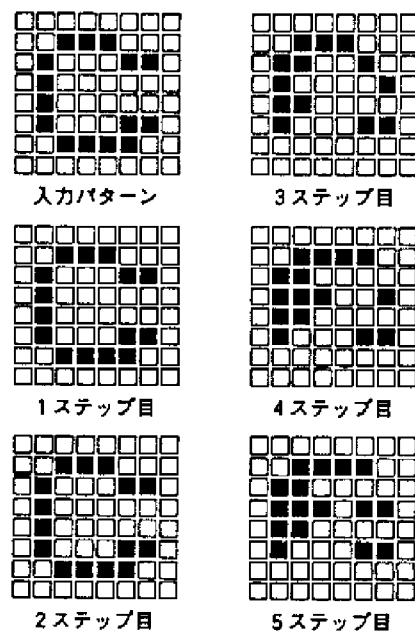


Fig. 4 入力がないときの出力例

### 4.2 学習済みのパターンを入力したとき

この場合、通常の階層型ニューラルネットワークのように学習済みのパターンへと収束した (Fig.5)。100ステップ学習させたネットワークについても確認できた。

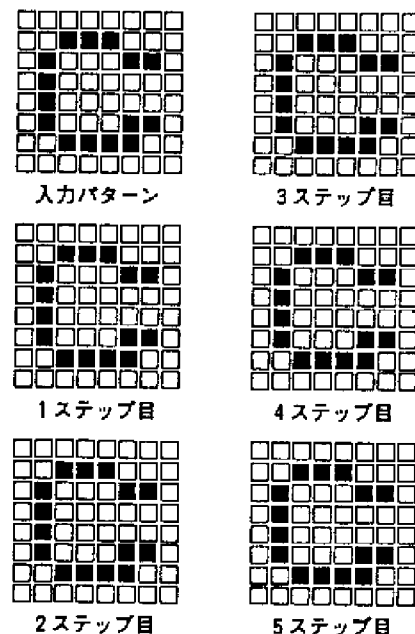


Fig. 5 学習パターンを入力したときの出力例

### 4.3 入力パターンから少し離れたパターンを入力したとき

学習済みのパターンから数ビット離れたパターンを入力したところ、観測期間において(5ステップ)、学習パターンに収束した(Fig.7). 同様の結果が100ステップ学習させたネットワークについても得られた。しかし、学習パターンからのずれを大きくするに従って、学習パターンを示す回数が少なくなった。




Fig. 6 学習パターンから3ビット離れたパターンを入力したときの出力例

### 4.4 未学習のパターンを入力したとき

この場合、一つのパターンへは収束せずにいろいろな出力パターンをとった(Fig.6). 同様の結果が100ステップ学習させたネットワークについても得られた。

以上から、入力が入っているにも関わらずいろいろな出力パターンをとる状態を I don't know 状態と解釈すると、Freemanらの実験結果に近いネットワークが構成できたことが示される。

## 5 おわりに

本稿で構成したネットワークが実際の動物実験の結果に近い振る舞いをするを示した。このように“知らない”ことを認識することにより、その新たなパターンを学習できるアルゴリズム(例えばBPTT法)を与えておけば、自動的に新しい文字を覚えることが可能

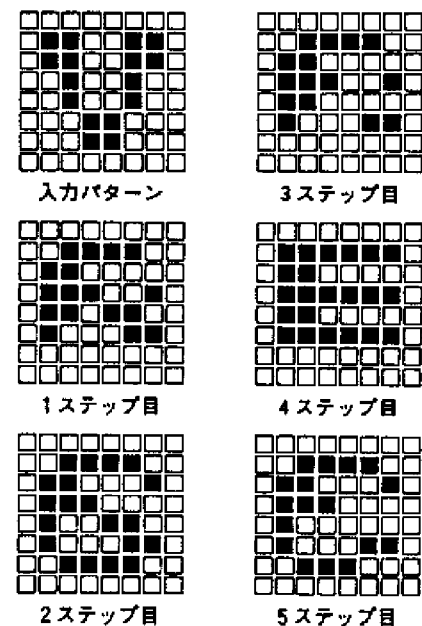


Fig. 7 未学習パターンを入力したときの出力例

となると考えられる。新しい文字を覚えさせる方法の検討は今後の課題である。

## 参考文献

- 1) D.E.Rumelhart, et al: Parallel Distributed Processing, The MIT Press, 1(1986)
- 2) K.Nakano: Associatron - A model of associative memory, IEEE Trans, SMC-2, 380/388(1972)
- 3) T.Kohonen: Correlation matrix memories, IEEE Trans., C-21, 353/359(1972)
- 4) J.A.Anderson: A simple neural network generating an interactive memory, Math. Biosciences, 14, 197/220(1972)
- 5) C.A.Skarda, W.J.Freeman: How brains make chaos in order to make sense of the world, BEHAVIORAL AND BRAIN SCIENCES, 10, 161/195(1987)
- 6) 喜多川 健, 本間 経康, 阿部 健一: リカレントニューラルネットワークの創発的学習手法, 計測自動制御学会論文集, 33-11, (1997 掲載予定)
- 7) Noriyasu Honma, Ken Kitagawa, Kenichi Abe and Hiroshi Takeda: An Autonomous Criterion of Learning Methods for Recurrent Neural Networks, Proc. of the 2nd ASCC, vol.II, 219/222 (1997)
- 8) D.E.Rumelhart, G.E.Hinton, R.J.Williams: Learning representations by back-propagating errors, Nature, 323, 533/536(1986)