

N 3 ニューラルネットワークによる連想記憶

近藤 稔明 佐々木 修己 鈴木 孝昌 王 向朝
新潟大学 工学部

1. はじめに

人間は、複数の感覚器より外部から入力情報を受けて物事を連想、認識する。この時、必ずしも、入力情報および連想情報は、1つとは限らない。

本研究では、外部刺激を2つとし、入力側のネットワークを2つに分け、2つの異なった事柄に関する入力パターンにより、1つの出力パターンを想起させる。図1のように、2層型のニューラルネットワークを用いる。それぞれのネットワークは、相互結合型であり、入力側ネットワークと出力側ネットワークの間に結合がある。学習させるパターンの組み合わせは、図2である。1対多の連想が2つ存在し、その2つの出力を重ね合わせることで出力パターンを得ている。2つの入力側のネットワークの入力パターンを1つの入力パターンと考え、類似性の高い入力パターンからの連想となる。このニューラルネットワークの連想記憶について、カオスニューロンを用いシミュレーションを試みる。

2. カオスニューロンモデル

次式で表されるカオスニューロンモデルを用いる。

$$x_i(t+1) = f\{\eta_i(t+1) + \xi_i(t+1)\} \quad (1)$$

$$\eta_i(t+1) = \sum_{j=1}^N W_{ij} x_j(t) + K_m \eta_i(t) \quad (2)$$

$$\xi_i(t+1) = -\alpha x_i(t) + K_r \xi_i(t) - \theta_i \quad (3)$$

ここで、 x_i は、 i 番目のニューロンの出力値であり、関数 f は、 ε を温度パラメータとすると、

$$f(y) = \frac{1}{1 + \exp(-y/\varepsilon)} \quad (4)$$

と表されるシグモイド関数である。

N はニューロン数であり、 W_{ij} はニューロン j からニューロン i へのシナプス結合の強さである。




図1 ネットワークの構成

α はパラメータ、 K_r は不応性に関する減衰定数、 K_m は入力に関する減衰定数、 θ_i はしきい値である。

3. ネットワークの構成

図1に示すネットワークを構成する。入力側ネットワークA、入力側ネットワークBがある。図2に示されるパターンを各ネットワークに学習させる。

入力側ネットワークA、Bで学習されるパターンを、 U_A^o ($o=1\sim3$)、 U_B^p ($p=1\sim3$) とし、その i 番目の要素を、 u_{Ai}^o 、 u_{Bi}^p とする。入力側ネットワークA、Bの結合係数は、相関学習を用いて、

$$W_{ij}^A = \frac{1}{3} \sum_{o=1}^3 u_{Ai}^o u_{Aj}^o \quad (5)$$

$$W_{ij}^B = \frac{1}{3} \sum_{p=1}^3 u_{Bi}^p u_{Bj}^p \quad (6)$$

となる。入力側ネットワークは、外部刺激を与えない時には、ネットワーク内に記憶されているパターンをダイナミクスに想起し、外部刺激を受けた時には、ネットワーク内に記憶されているパターンを想起する。外部刺激は、ネットワークに記憶されているパターンを与えるものとする。

出力側ネットワークで学習されるパターンを V^q 、($q=1\sim9$) とし、その i 番目の要素を v_i^q とする。

出力側ネットワークの結合係数は、

$$W_{ij} = S \sum_{q=1}^9 v_i^q v_j^q \quad (7)$$

となる。 S は、結合の強さを調整するパラメータである。




図2 パターンの学習

次に、入力側ネットワークA、Bの出力に応じて、出力側ネットワークに V^q のパターンが出力されるようにするために、入力側ネットワークA、Bより、出力側ネットワークへの結合係数 W_{Aij} 、 W_{Bij} をそれぞれ次式のように定める。

$$W_{Aij} = S_A \left(\sum_{q=1}^3 v_i^q u_{Aj}^1 + \sum_{q=4}^6 v_i^q u_{Aj}^2 + \sum_{q=7}^9 v_i^q u_{Aj}^3 \right) \quad (8)$$

$$W_{Bij} = S_B \left(\sum_{q=1,4,6} v_i^q u_{Bj}^1 + \sum_{q=2,5,8} v_i^q u_{Bj}^2 + \sum_{q=3,6,9} v_i^q u_{Bj}^3 \right) \quad (9)$$

S_A, S_B は、結合の強さを調整するパラメータである。

4. 出力側ネットワークの動作

入力側ネットワークA, Bの*i*番目のニューロン出力を x_{Ai}, x_{Bi} とし、出力側ネットワークの*i*番目のニューロン出力を y_i とする。

出力側ネットワークの*i*番目のニューロンの内部状態は、次の3つの式のと和で表される。 S, S_A, S_B は、省略する。

$$\begin{aligned} \sum_{j=1}^N W_{Aij} x_{Aj} &= (v_i^1 + v_i^2 + v_i^3)(U_A^1 \cdot X_A) \\ &+ (v_i^4 + v_i^5 + v_i^6)(U_A^2 \cdot X_A) \\ &+ (v_i^7 + v_i^8 + v_i^9)(U_A^3 \cdot X_A) \end{aligned} \quad (10)$$

$$\begin{aligned} \sum_{j=1}^N W_{Bij} x_{Bj} &= (v_i^1 + v_i^4 + v_i^7)(U_B^1 \cdot X_B) \\ &+ (v_i^2 + v_i^5 + v_i^8)(U_B^2 \cdot X_B) \\ &+ (v_i^3 + v_i^6 + v_i^9)(U_B^3 \cdot X_B) \end{aligned} \quad (11)$$

$$\sum_{j=1}^N W_{ij} y_j = \sum_{q=1}^9 v_i^q (V^q \cdot Y) \quad (12)$$

X_A, X_B は、入力側ネットワークA, Bの出力パターン。Yは、出力側ネットワークの出力パターンである。 $(U \cdot X), (V \cdot Y)$ は、内積を表す。

内積される2つのパターンが等しいときの値をKとすると、すべての記憶パターンに対し、Kは、内積される2つのパターンが異なるときの内積の値より非常に大きな値となる。パターンが異なるときの内積の和は、Kよりも十分小さいため雑音 (noise) とみなすことができる。

今、 $X_A = U_A^1, X_B = U_B^1$ となつたとする。

式(10)+式(11)の値 Q_i は、

$$Q_i = K(2v_i^1 + v_i^2 + v_i^3 + v_i^4 + v_i^7) + noise \quad (13)$$

となる。 v_i^q ($q=1 \sim 4, 7$) は、1か-1の値であるので、 Q_i の約8割が、 v_i^1 の符号と同じ符号になる。従って、出力側ネットワークの出力は、 v_i^1 に近いパターンとなる。

出力Yによって、式(12)の $(V^1 \cdot Y)$ の値が、Kとなり、他の内積の和は、雑音となる。出力側ネットワークの*i*番目のニューロンの内部状態 \bar{Q}_i は、

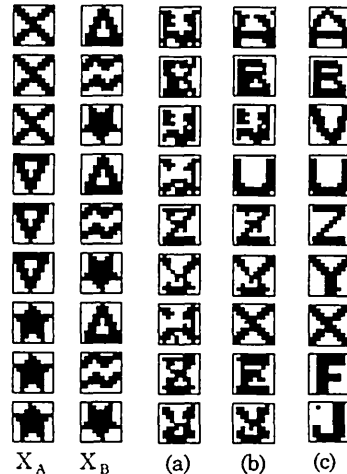
$$\bar{Q}_i = K(3v_i^1 + v_i^2 + v_i^3 + v_i^4 + v_i^7) + noise \quad (14)$$

となる。 \bar{Q}_i の符号は、 v_i^1 の符号とほぼ一致するため、出力Yは、より一層 v_i^1 に近いパターンとなる。 v_i^1 のパターン以外についても同様である。

また、カオスニューロンを用いることにより、ローカルミニマムに陥ることなく、出力側ネットワークの出力パターンを完全に想起できる。

5. シミュレーション

入力側ネットワークA, Bの出力パターンを固定した時の、出力側の内部結合 W_{ij} の有無、カオスニューロン有り無しにおけるシミュレーション結果を図3に示す。結合なし ($W_{ij} = 0$)、結合あり ($W_{ij} \neq 0$)、カオスニューロン使用の順に出力パターンがよくなっていることが分かる。



- (a) $W_{ij} = 0$, カオスニューロン不使用
- (b) $W_{ij} \neq 0$, カオスニューロン不使用
- (c) $W_{ij} \neq 0$, カオスニューロン使用

図3 入力を固定した時の出力パターン

6. まとめ

2層型のネットワークを構成し、入力側のネットワークを2つに分け、入出力の両方のネットワークに相互結合型のニューラルネットワークを用いた。また、カオスニューロンを用いて、2つの異なった事柄に関する入力パターンより、1つの出力パターンの連想が可能であることを明らかにした。

7. 参考文献

- [1] 長名、服部、萩原：カオス双方向連想メモリ 電学論C、116巻7号、平成8年