

## 分割想起による連想記憶モデルの提案

綴木 剛†† 酒井英昭††

本論文では、連想記憶モデルの一性質を応用して、分割学習および分割想起を提案することで新しいモデルの構築を行う。ここで言う分割とは、状態ベクトルをランダムに2等分割し、記憶パターンも状態ベクトルに合わせて一対一対応で等分割する。分割することで、一つのネットワークにかかる記憶率の負荷は2倍になるが、それでも本論文で提案する分割想起が通常の連想記憶モデルよりも良い結果が出ることを示す。

### Proposal of divided association of a new associative model

JUN TSUZURUGI†† and HIDEAKI SAKAI ††

In this paper, we construct a new associative model using one of the properties of the associative memory model, and we propose a method of divided learning and association. The state vector is divided at random into two parts and the memorized patterns are divided by one to one correspondence in accordance with the state vector. Although this division makes the load two times as for the memorized rate of each network, the proposed model gives good results than the conventional associative memory model.

#### 1. はじめに

ある記憶事象の一部だけが与えられており、それをキーとして全体を想起するような心的過程があることは否定できない。このような心的過程を神経回路モデルを用いてモデル化したものを、連想記憶モデルと呼ぶ。実際に脳の海馬 CA3 ニューロン間の再帰的結合には、連想記憶に近い機能があることがわかりつつある<sup>10)</sup>。ただし本論文で提案するモデルは、現時点で海馬のネットワークに対応付けようとするものではない。

Hopfield のオリジナルの CAM(Content Addressable Memory)<sup>2)</sup> は、全ニューロンによる相互結合のネットワークである。このモデルにはさらに二つの特徴があった。

- (1) 結合荷重行列が対称結合である。
- (2) 全ニューロンの状態が想起するパターンの表現に対応している。

上記(1)は想起をエネルギー緩和過程ととらえるために都合が良いが、(1)(2)共にネットワークに強い制限を加えていることになる。海馬のモデルとしても必然性はない。

脳科学の研究は、大きく分けて3つのカテゴリーに属すると考えられる。1つ目はモデルが「脳を模倣したモデル」であることは言うまでもない。2つ目は「数学的に美しいモデル」。3つ目は「工学的に応用の利くモデル」であると言える。しかしながら、本研究はこれら3つのカテゴリーのいずれにも属さないモデルである。いわば、既存のモデルの性質を応用し、興味深いモデルを作ろうと言うものである。特に、本論文はホップフィールド型の連想記憶モデル<sup>2), 5)</sup>に工夫することで、性能の向上を図ろうと言うものである。

一般に、ホップフィールド型の連想記憶モデルにおける想起では、偽記憶<sup>5), 6)</sup>に収束することで想起に失敗する場合が存在する。これまで、様々な方法<sup>7), 9)</sup>を用いることで、あらゆる分野の研究者達が連想記憶モデルの性能の向上に努めてきた。本研究では、従来の連想記憶モデルの学習法に対して分割学習を提案する。そして、分割想起と通常の想起を比較し、分割想起の有効性を示す。

#### 2. 連想記憶モデル

はじめに、連想記憶モデルについて簡単に述べておく。時刻  $t$  における  $N$  次元のベクトルからなる状態パターンを  $S(t)$  とした場合、その要素  $S_i(t)$  の状態更新式は、以下のように定義される。

† 岡山理科大学  
Okayama University of Science  
†† 京都大学大学院情報学研究所  
Graduate School of Informatics, Kyoto University

$$S_i(t+1) = \text{sgn} \left( \sum_{j=1}^N J_{ij} S_j(t) \right) \quad (1)$$

$\text{sgn}(x)$  はステップ関数で、以下の様に定義される。

$$\text{sgn}(x) = \begin{cases} +1 & (x \geq 0) \\ -1 & (x < 0) \end{cases} \quad (2)$$

式(1)の右辺に初期状態ベクトル  $S(0)$  を代入し、右辺を計算することで次の状態ベクトル  $S(1)$  が求まる。この様に次々に式(1)で状態ベクトル  $S(t)$  を更新することで連想を行う。

次に  $J_{ij}$  を決めるための学習則について述べる。学習則には以下に述べるヘップ則を用いる。 $\mu$  番目の  $N$  次元ベクトルからなる記憶パターンを  $\xi^\mu$  と定義する。このとき、 $\xi^\mu$  の要素  $\{\xi_i^\mu\}$  を用いることにより、結合荷重  $J_{ij}$  は次のヘップ則により与えられる。

$$J_{ji} = \frac{1}{N} \left( \sum_{\mu=1}^P \xi_i^\mu \xi_j^\mu \right) \quad (3)$$

ここで、 $P$  は記憶させるパターン数である。本論文では記憶させるパターンを以下の様なランダムパターンにする。

$$\text{Prob}(\xi_i^\mu = \pm 1) = \frac{1}{2} \quad (4)$$

$N = 100$ ,  $P = 5$  とした場合の実際の想起の様子を図1に示す。ここでは記憶パターンの  $\xi^1$  の作成には、式(4)を用いずに、人工的に作ったアルファベット「A」のパターンを用いた。他の記憶パターン  $\xi^2, \xi^3, \xi^4, \xi^5$  は式(4)に従ってパターンを作成した。アルファベット「A」のパターンにノイズを加え、式(1)により想起した。




図1 通常の想起の様子。  $N = 100$ ,  $P = 5$  とした場合。

例えば、 $\xi^1$  を想起させるべき目的パターンとしたとき、状態ベクトル  $S(t)$  と  $\xi^1$  とのオーバーラップ  $m(t)$  は以下のように定義される。

$$m(t) = \frac{1}{N} \sum_{i=1}^N \xi_i^1 S_i(t) \quad (5)$$

$m(t) = 1$  の場合は、目的パターン  $\xi^1$  と状態ベクトル  $S(t)$  が完全に一致することを意味し、 $m(t) = 0$  の場合は、目的パターン  $\xi^1$  と状態ベクトル  $S(t)$  が完全に

無相関であることを意味する。

図2に、 $N = 1000$ ,  $P = 100$  とした場合における、横軸が式(1)の時刻  $t$ 、縦軸がオーバーラップ  $m(t)$  のグラフを示す。図2に示すように、いずれも  $t = 0$




図2 通常想起の様子。  $N = 1000$ ,  $P = 100$  とした場合の時刻  $t$  に対するオーバーラップ  $m(t)$ 。

から  $t = 1$  にかけて  $m(t)$  は一旦上昇しているが、 $m(0) \leq 0.4$  では、 $m(\infty) = 1$  に収束せず、想起に失敗していることが分かる。 $m(0) \geq 0.5$  では、 $m(\infty) = 1$  に収束し、想起が成功していることが分かる。本論文では、分割想起を用いることで、 $m(0) \leq 0.4$  の想起失敗範囲でも想起を成功させることを目指す。

### 3. 分割想起

最終的に連想に失敗する場合、すなわち偽記憶に収束する場合でも、 $t = 0$  付近の更新では  $m(t)$  が一旦上昇することが知られている<sup>1)</sup>。本稿では、この  $t = 0$  から  $t = 1$  にかけての  $m(t)$  の上昇を連想記憶モデルの想起に応用する。ここからは、その応用の手段について説明する。

まず、状態ベクトル  $S(t)$  を  $S_1(t)$  と  $S_2(t)$  の2つに分割する。このとき、分割するにおいては、図3の様に、2つのパターンはランダムに素子を選択することで同数に二分割を行い、 $S(t)$  には完全に無相関な2つのパターン  $S_1(t)$ ,  $S_2(t)$  をそれぞれ作る。

次に記憶パターンの分割を考える。以下に述べる方法で  $\xi^\mu$  を分割された記憶パターン  $\xi^{\mu 1}, \xi^{\mu 2}$  に分ける。状態ベクトル  $S(t)$  を分割したとき、すなわち、 $S_{1i}(t)$  と  $S_{2j}(t)$  に分けた方法と全く同じ手順で、図3の様に、記憶パターン  $\xi^\mu$  を  $\xi^{\mu 1}$  と  $\xi^{\mu 2}$  に分ける。つまり、状態ベクトル  $S(t)$  を分割するときにはランダムに二分割するが、記憶パターン  $\xi^\mu$  を分割するときには、状態ベクトルを二分割したときに選択した位置と一対一で対応させて、全ての記憶パターンにおいて同

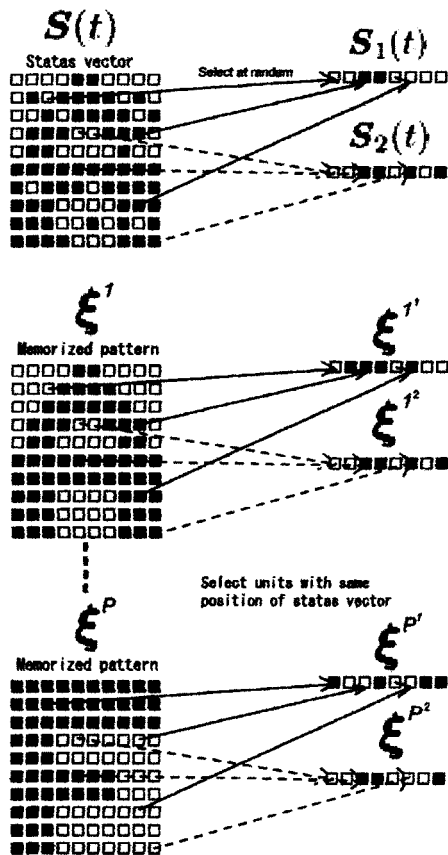


図3 分割の様子。分割する際に、状態ベクトル  $S(t)$  で選択した場所と同じ一対一対応の場所を  $\xi^1$  から  $\xi^P$  の全ての記憶パターンにおいて選択する。

じ手法でそれぞれ二分分割する。そして、以下のように二つに分割してヘップ則による学習を行う。すなわち、

$$J_{ji}^1 = \frac{2}{N} \left( \sum_{\mu^1=1}^P \xi_i^{\mu^1} \xi_j^{\mu^1} \right) \quad (6)$$

$$J_{ji}^2 = \frac{2}{N} \left( \sum_{\mu^2=1}^P \xi_i^{\mu^2} \xi_j^{\mu^2} \right) \quad (7)$$

と、分割した2つの記憶パターン  $\xi^{\mu^1}$ ,  $\xi^{\mu^2}$  を以下の二つの式にしたがい想起する。

$$S_{1i}(t+1) = \text{sgn} \left( \sum_{j=1}^{N/2} J_{ij}^1 S_{1j}(t) \right) \quad (8)$$

$$S_{2i}(t+1) = \text{sgn} \left( \sum_{j=1}^{N/2} J_{ij}^2 S_{2j}(t) \right) \quad (9)$$

式(8), (9)にしたがい、想起はそれぞれ一度だけ行う。想起が終われば、二分分割したパターンを合体させる。その後、再度新たに状態ベクトルと記憶パターンを上記の手段で分割および学習し、再び想起をする。これを何度も繰り返す。この分割想起のイメージを図4に示す。分割学習と想起の様子を図5に示す。




図4 分割想起のイメージ




図5 分割学習と想起の様子。

この想起の度に学習をしなければならない点が、本論文で提案しているモデルが脳のモデルとは言えない理由の一つである。また、工学的にも応用のきくモデルではないし、数学的に美しいモデルではない。しかしながら、 $t=0$  から  $t=1$  において  $m(t)$  が上昇する性質を利用して、どこまで連想記憶モデルの性能を向上できるかを観察するのは興味深いし、この性質を利用する手段を考えついたという点も本論文が価値を持つ所である。

#### 4. 結 果

図6に分割想起した場合における  $m(t)$  の変化の様子を示す。図6より、通常の想起では失敗していた初期状態  $0.3 \leq m(0) \leq 0.4$  において、連想が成功していることが分かる。本論文の分割想起では、想起のときに記憶率  $\alpha = P/N$  において  $N$  が半分になってしまうために、二倍の負荷がかかる。 $m(0) \leq 0.2$  において想起が失敗しているのは、そのためであると考えられる。しかしながら、通常の想起では失敗していた初期状態  $0.3 \leq m(0) \leq 0.4$  において、連想が成功していたのは、興味深い。

#### 5. ま と め

分割想起により、通常の想起では連想に失敗していた初期状態  $0.3 \leq m(0) \leq 0.4$  において、想起が成功した。想起のときに二倍の負荷が分割した各モデルにかかるのにも関わらず、 $0.3 \leq m(0) \leq 0.4$  において、

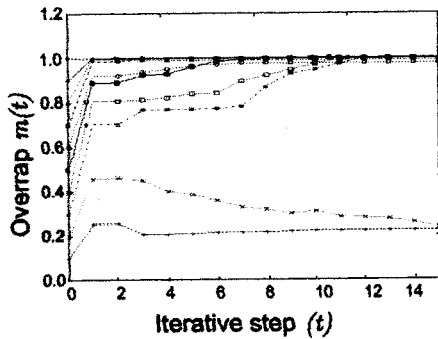


図6 分割想起した場合における、各初期条件からの時間に対するオーバーラップ。N=1000, P=100の時とした。

想起が成功したのは意義深い。

### 参 考 文 献

- 1) S. Amari and K. Maginu :Statistical neuro-dynamics of associative memory; Neural Networks, Vol.1, pp.63-73 (1988)
- 2) J.J. Hopfield, :Neural networks and physical system with emergent collective computational abilities; Proc. Natl. Acad. Sci. USA, Vol.79, April., pp.2554-2558 (1982)
- 3) J.J. Hopfield, :Neurons with graded response heve collective computational properties like those of two-state neurons; Proc. Natl. Acad. Sci. USA, Vol.81, May, pp.3088-3092 (1984)
- 4) D. Amit, H. Gutfreund, and H. Sompolinsky, :Statistical mechanics of neural networks near Saturation; Annals of Physics, 173, pp.30-67 (1987)
- 5) J. Bruck and V.P. Roychowdhury, :On the number of spurious memories in the Hopfield model; IEEE Trans. Information Theory, Vol.36, No.2, pp.393-397, Mar (1990)
- 6) T. Fukai and M. Shiino :Comparative study of spurious-state distribution in analogue neural networks and Boltzmann machine; Jurnal of Physics A:Mathematical and General, Vol.25, pp.2873-2887 (1992)
- 7) E. Hartman, :A high storage capacity neural network content-addressable memory; Network, Vol.2, pp.315-334 (1991)
- 8) J.J. Hopfield, D.I. Feinstein, and R.G. Palmer, :'Unlearning' has a stabilizing effect in collective memories; Nature, Vol.304, No.14, July,

pp.158-159 (1983)

- 9) 緩木 嗣, 高橋規一, 石井 信, ハイブリッド型学習による隠れ素子付き連想記憶モデル, システム制御情報学会論文誌 Vol. 15, No.11, Nov, (2002)
- 10) 利根川 進, :Use of knockout mice for the studies on neural plasticity and memory; 第 29 回日本神経科学大会, 招待講演, 横浜, 9月 (2000)

(平成?年?月?日受付)

(平成?年?月?日採録)