

# 不応期を用いた自己相関連想記憶の想起能力と逐次学習

小田 幹雄<sup>†</sup> 宮島 廣美<sup>††</sup>

自己相関連想記憶は、回路網の安定性の立場から、単調な活性化関数がいわれていたが、単純な構造である一方、記憶容量が小さい、偽記憶が存在するなどの欠点があった。本論文では、不応期を有するニューロンを用いた回路網において、回路網の収束をつねに保証しながら、記憶率にかかわらず不応しきい値を自動的に設定する回路網を考える。まず、静的な想起による数値実験により、想起能力が最も高くなる回路網の活動度を求める。この結果を利用し、回路網の活動度に基づいて不応しきい値を適応的に制御する手法を提案し、高い想起能力を有することを数値実験により示す。さらに、回路網の活動度が入力パターンの未知/既知パターンの判定に利用できることを明らかにし、未知パターンの逐次学習則を提案する。この逐次学習則を非同期離散時間回路網に適用し、その有効性を示す。

## Autoassociative Memory Using Refractory Period of Neurons and Its On-line Learning

MIKIO ODA<sup>†</sup> and HIROMI MIYAJIMA<sup>††</sup>

In the present paper, we, first, propose a novel autoassociative memory model of the neural network consisting of neurons which enter refractory period according to an adaptive threshold. The refractory threshold is adaptively and autonomously controlled by an additional linear neuron based on the network activity. The optimal network activity, then, is obtained by static recalls and the value is used to control the threshold. Secondly, using the network activity, the network with on-line learning mechanism is also proposed and it is shown that the network can detect novel patterns to be memorized and memorize them correctly.

### 1. はじめに

1972年に Nakano<sup>1)</sup>, Kohonen<sup>2)</sup>らをはじめ複数の研究者らにより独立に自己相関連想記憶が提案され、並列処理、分散記憶、局所的な素子の破壊に対するロバスト性などの観点、そして神経回路網との類似点から多くの興味を呼び、その後、神経回路網による連想記憶の研究がさかに行われてきた<sup>3)</sup>。神経回路網による連想記憶は、静的な想起と動的な想起に大別できるが、静的な想起に関して、上坂ら<sup>4)</sup>は、自己相関連想記憶をはじめいくつかのモデルの想起確率を理論的に導き出した。一方、動的な想起に関して、Hopfield<sup>5)</sup>は、量子力学のスピングラスによるエネルギー関数の概念を導入し、対称結合のいわゆる Hopfield モデルを提案し、回路網の安定性を示した。その後、Hopfield モデルについて、非対称結合を含め、回路網の安定性、

収束性に関する研究が行われた<sup>6)~8)</sup>。

また、Hopfield モデルの記憶容量について、Hopfield<sup>5)</sup>は、記憶容量が  $0.15n$  であることを数値実験により示した。ここで、 $n$  は回路網のニューロン数である。Amit ら<sup>9)</sup>は、レプリカ法を用いて記憶容量が  $0.14n$  であることを示し、Amari ら<sup>10)</sup>は、想起過程を理論的に解析し、近似値  $0.16n$  の記憶容量を導出した。この理論的解析は、膜電位中のノイズが正規分布をなしているとの仮定によるものであり、この成果に刺激され、ノイズの分布に注目した解析が試みられた<sup>11),12)</sup>。パターン系列を記憶する連想記憶については、矢内ら<sup>13)</sup>によりその性質が明らかにされた。

記憶すべきパターンの観点から考えると、各々確率  $1/2$  で  $1$  か  $-1$  をとる無相関なパターンが一般に用いられるが、相関行列を用いることにより偽記憶が存在することや記憶容量が小さいなどの欠点がある。これを改善する方法として、多値への拡張、相関パターンによるコーディング法が提案された<sup>14)~16)</sup>。特に、希薄で偏ったランダムパターンであるスパースコーディング法により記憶パターンを生成すると、大幅な記

<sup>†</sup> 久留米工業高等専門学校

Kurume National College of Technology

<sup>††</sup> 鹿児島大学工学部

Faculty of Engineering, Kagoshima University

憶容量の増加が図れることが分かった<sup>16)~19)</sup>。また、Hebb 学習則と等価な従来の相関行列に代わる結合加重行列を用いて記憶容量を増加する試みも行われている<sup>20)~23)</sup>。

ダイナミクスの観点から考えると、回路網の安定性の立場から、活性化関数として主として符号関数やシグモイド関数などの単調関数が用いられていたが、これに対して、森田ら<sup>24),25)</sup>は、従来の単調な活性化関数に代わるダイナミクスを考え、離散時間モデルに対して部分反転法、連続時間モデルに対して非単調活性化関数を用いた記憶モデルを提案した。部分反転法では、膜電位の2段階の計算過程を経て出力を計算し、疑似的な非単調活性化関数を実現している。すなわち、これらのモデルは、想起能力を向上させるために、活性化関数の非単調性を間接、直接に利用していることになる。その後、非単調活性化関数モデルの想起能力について、理論的な解析も進められ<sup>26)~28)</sup>、時系列パターン<sup>29)</sup>の記憶に適應する試みもなされた。また、カオスニューロンや活性化関数に周期関数を用いた記憶モデルも提案され、想起能力が向上することが示されている<sup>30),31)</sup>。しかしながら、これらの改良モデルは、想起能力が向上する一方、系が必ず平衡状態に落ち着く保証はない。

著者ら<sup>32)</sup>は、単調な活性化関数を用いながら、膜電位または入力信号の絶対値がしきい値(以下、不応しきい値と呼ぶ)より大きいときにのみ一定期間不応期に入るニューロンを用いた回路網を提案し、想起能力が向上することを数値実験で示した。非同期離散時間回路網では、記憶率によらず一定の不応しきい値を設定することが可能であり、記憶容量  $0.27n$  を得た。しかしながら、同期離散時間回路網では、適切な不応しきい値が記憶率により異なるため、記憶率が分からないければしきい値を設定できない問題点がある。

本論文では、不応期を有するニューロンを用いた同期離散時間回路網および連続時間回路網において、不応しきい値を動的に設定する回路網を提案する。まず、提案する回路網は、自己相関連想記憶に従来の単調な活性化関数を用いるため、Hopfield モデルと同様、不応期間を十分長くとれば、必ず収束することを証明する。次に、静的な連想による数値実験により、想起能力が最も高くなる回路網の活動度を求め、最適な回路網の活動度が記憶率にかかわらず一定であることを示す。この結果を利用し、回路網の活動度に基づいて不応しきい値を適応的に制御する回路網を提案し、想起能力が向上することを数値実験により明らかにする。また、連続時間回路網に対しても、動的な不応しきい

値を適用し、想起能力が向上することを示す。

さらに、回路網の活動度が入力パターンの未知/既知パターンの判定に利用できることを明らかにし、未知パターンの逐次学習則を提案する。最後に、非同期離散時間記憶モデルに対して提案学習則を適用し、数値実験によりその有効性を示す。

## 2. 自己相関連想記憶

$n$  個のニューロンが相互に結合した同期的な離散時間離散値の自己相関連想記憶を考える。時刻  $t$  のニューロン  $i$  の出力を  $x_i(t)$  とすると、回路網の状態は、

$$X(t) = (x_1(t), x_2(t), \dots, x_n(t))' \quad (1)$$

と定義され(ダッシュは転置を表す)、回路網のダイナミクスは、

$$x_i(t+1) = f(u_i(t)) = f\left(\sum_{j=1}^n w_{ij}x_j(t)\right) \quad (2)$$

となる。ここで、 $u_i(t)$  は時刻  $t$  のニューロン  $i$  の膜電位、 $w_{ij}$  はニューロン  $j$  からニューロン  $i$  への結合加重であり、活性化関数  $f$  として、たとえば、符号関数

$$f(u) = \text{sgn}(u) = \begin{cases} 1 & (u > 0 \text{ のとき}) \\ 0 & (u = 0 \text{ のとき}) \\ -1 & (u < 0 \text{ のとき}) \end{cases} \quad (3)$$

が用いられる。連想記憶モデルに  $m$  個のパターン  $S^1, \dots, S^\nu, \dots, S^m$  ( $S^\nu = (s_1^\nu, \dots, s_n^\nu)'$ ) を記憶させる場合、結合加重行列として、Hebb 学習則と等価な

$$W = \frac{1}{n} \sum_{\nu=1}^m S^\nu S^{\nu'} \quad (4)$$

の自己相関行列が用いられる。ただし、自己結合はないものとし( $w_{ii} = 0$ )、記憶するパターンの各要素  $s_i^\nu$  は、

$$\text{Prob}(s_i^\nu = \pm 1) = \frac{1}{2} \quad (5)$$

により独立に決定されるものとする。

$m$  個のパターンを記憶した回路網を用意し、どの記憶パターンとも一致しないが、記憶パターンの1つと最も類似した入力、すなわち記憶パターンにノイズを加えたパターンを入力すると、回路網は、望ましくはその記憶パターンを出力する状態に収束する。時刻  $t$  における回路網の想起の様子をマクロにとらえるた

$X(0)$  は、回路網に入力されるパターンを表すものとする。

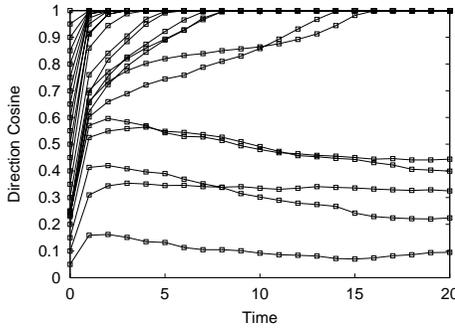
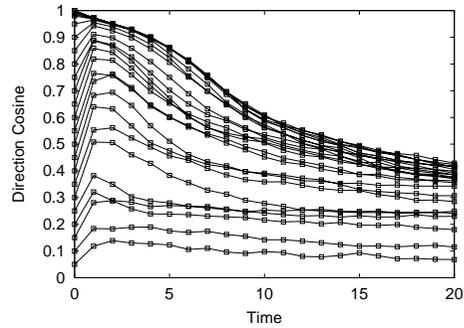
(a) 記憶率  $r = 0.08$  における想起過程(b) 記憶率  $r = 0.2$  における想起過程

図1 符号関数を活性化関数に用いた連想記憶モデルの想起過程 (Hopfield モデル)  
 Fig.1 Recalling process of autoassociative memory using signum activation function (Hopfield type model).

めに、想起すべき記憶パターン  $S^\mu$  と入力パターンまたは出力パターン  $X(t)$  との類似度として方向余弦

$$a(X(t), S^\mu) = \frac{1}{n} \sum_{i=1}^n x_i(t) s_i^\mu \quad (6)$$

を定義する。ただし、活性化関数  $f(u_i)$  が連続関数のときは、式(6)中の  $x_i(t)$  の代わりに、 $\text{sgn}(x_i(t))$  が用いられる。また、想起可能な入力パターンのうち、方向余弦が最も小さいものを臨界方向余弦と呼び、 $a_c$  で表す。これは、想起可能なパターンと想起不可能なパターンとの境界を表し、引き込み領域の大きさに対応する。

記憶パターン  $S^\nu$  ( $1 \leq \nu \leq m$ ) は、回路網のとりうる状態数  $2^n$  個から式(5)に基づき等確率で選ばれたため、 $n$  が十分大きいと仮定すると、

$$E \left[ \frac{1}{n} \sum_{j=1}^n s_j^\mu s_j^\nu \right] = 0 \quad (\mu \neq \nu) \quad (7)$$

となる。ここで、 $E[x]$  は  $x$  の期待値である。記憶パターンの1つ  $S^\mu$  と同一または若干異なるパターン  $S^{\mu'}$  ( $= (s_1^{\mu'}, \dots, s_n^{\mu'})$ ) を回路網に入力すると、時刻  $t = 1$  のときのニューロン  $i$  の膜電位は、

$$\begin{aligned} u_i(1) &= a(S^{\mu'}, S^\mu) s_i^\mu + \frac{1}{n} \sum_{j \neq i} \sum_{\nu \neq \mu} s_i^\nu s_j^\nu s_j^{\mu'} \\ &= \text{signal}_i + \text{crosstalk}_i \end{aligned} \quad (8)$$

となる。 $\text{crosstalk}_i$  は、ニューロン  $i$  の膜電位に含まれる記憶パターン間の相互干渉成分であり、式(7)の性質と活性化関数の非線形性により除去されることが期待できる。

回路網の記憶率  $r$  を

$$r = \frac{m}{n} \quad (9)$$

と定義すると、記憶率が小さい場合、すなわち総ニューロン数と比較して記憶パターン数が少ない場合は、入力パターン  $X(0)$  と想起すべき記憶パターン  $S^\mu$  との類似度が小さい(方向余弦  $a$  が小さい)場合でも想起可能であるが、記憶率が大きくなると、次第に臨界方向余弦  $a_c$  が上昇し、引き込み領域が小さくなる。さらに記憶率を上げると、記憶パターンはもはや安定平衡点とはならず、記憶パターン自体を入力しても、記憶していないパターンである偽記憶パターンなどの異なるパターンに収束する。

符号関数を活性化関数に用いた離散時間連想記憶モデルの想起過程を図1に示す。記憶率  $r = 0.08$  のとき、方向余弦が  $a(X(0), S^\mu) > 0.3$  のパターン  $X(0)$  を入力すると、回路網は記憶パターン  $S^\mu$  を正しく想起する。一方、記憶率  $r = 0.2$  のときは、たとえ記憶パターン自体 ( $a(X(0), S^\mu) = 1$ ) を入力しても、パターン  $S^\mu$  にはとどまらず正しく想起されない。活性化関数に単調関数である符号関数やシグモイド関数を用いる従来の離散時間による連想記憶の場合、想起可能な記憶率の上界は  $r \approx 0.16$  と知られている。

連続時間連続値モデルの場合、式(2)に代わる回路網のダイナミクスは、

$$\tau_u \frac{du_i(t)}{dt} = -u_i(t) + \sum_{j=1}^n w_{ij} f(u_j(t)) \quad (10)$$

となる。ここで、 $\tau_u$  は膜電位の時定数である。また、想起パターン  $X(t)$  を求めるときは、ニューロン  $i$  に対して  $\text{sgn}(u_i(t))$  が用いられる。活性化関数にシグモイド関数を用いる従来の連続時間モデルの想起可能な記憶率の上界は、離散時間モデルと同様、 $r \approx 0.16$

である。

### 3. 不応期を持つニューロンによる連想記憶

#### 3.1 非単調活性化関数モデル

自己相関連想記憶モデルの想起可能な記憶率の上界は、活性化関数に単調関数である符号関数やシグモイド関数を用いると、離散時間モデル、連続時間モデルともに  $r \approx 0.16$  であった。記憶パターンへの引き込み領域を広げ、記憶容量を改善する手法として、活性化関数に注目しダイナミクスを改良した森田らの記憶モデルがある<sup>(24),(25)</sup>。森田らは、離散時間モデルに対して部分反転法、連続時間モデルに対して非単調活性化関数モデルを提案した。

部分反転法は、状態遷移のたびに一部のニューロンの出力を反転させるアルゴリズムである。具体的には、以下の2つのフェーズからなる。

フェーズ 1 ニューロンの膜電位、つまり入力荷重和

$$u_i = \sum_{j=1}^n w_{ij} x_j(t) \quad (11)$$

を求める。

フェーズ 2 式(11)で求められた  $u_i$  のうち、 $|u_i| > h$  ( $h > 0$ ) であるようなニューロンに対する荷重和

$$v_i = \sum_{j=1}^n w_{ij} \phi(u_j) \quad (12)$$

を求める。ただし、

$$\phi(u) = \begin{cases} -1 & (u < -h \text{ のとき}) \\ 0 & (-h \leq u \leq h \text{ のとき}) \\ 1 & (u > h \text{ のとき}) \end{cases} \quad (13)$$

である。求めた  $u_i, v_i$  を用いて、 $t+1$  時刻の回路網の出力

$$x_i(t+1) = \text{sgn}(u_i - \lambda v_i) \quad (14)$$

を求める。

数値実験により、定数  $\lambda$  は 2.7 前後、 $h$  は記憶率  $r$  が分かっているのであれば、

$$h = 1 + r + k\sqrt{r} \quad (k \approx 2) \quad (15)$$

にするのがよい<sup>(24)</sup>。部分反転法は、いい換えれば、 $|u_j|$  が  $h$  を超えるニューロンからの入力は、 $w_{ij}u_j$  の代わりに  $w_{ij}(u_j \pm 1)$  としたアルゴリズムで、非単調関数を2フェーズで実現する手法といえる。

連続時間モデルに対する改良モデルである非単調活性化関数モデルは、ニューロンの活性化関数に

$$f(u) = \frac{1 - e^{-cu}}{1 + e^{-cu}} \cdot \frac{1 + \kappa e^{c(|u|-h')}}{1 + e^{c(|u|-h')}} \quad (16)$$

の非単調関数を用いるものである。ここで、 $c, c', \kappa, h'$  は定数であり、 $\kappa < 0$  のとき非単調関数となる。

部分反転法および非単調活性化関数モデルは、符号関数やシグモイド関数を用いた記憶モデルと比較し、記憶容量を飛躍的に向上させたが、一方、活性化関数が単調関数ではないため、これらの回路網が想起成功、不成功を問わず必ず平衡状態に落ち着く保証はない。

#### 3.2 不応期を持つニューロンによる記憶モデル

本論文で扱う連想記憶モデルは、従来の Hopfield モデルと同様、式(5)に従うランダムパターン  $S^\nu$  ( $1 \leq \nu \leq m$ ) を式(4)により記憶し、単調な活性化関数を用いることを前提とする。したがって、結合荷重は対称であり、自己結合はない。Hopfield モデルと異なる点は、ニューロンが不応期を有する点である。ニューロンには、絶対不応期と相対不応期があることが生理学的に発見されている。ここでは、発火後に一定期間発火が起こらなくなる絶対不応期に注目する。

従来、絶対不応期や相対不応期を持つニューロンの数学的なモデルはあったが<sup>(33),(34)</sup>、これらのモデルは、ニューロンが発火後に一様に不応期に入るものであり、また、カオスニューラルネットワークでは、不応性の自己結合を持つが、その不応条件は初期設定から変わらない。ここでは、これらの方法とは異なり、ニューロンが発火すると必ず不応期に入るのではなく、発火したときの膜電位  $u_i$  (離散時間モデル) または入力  $\sum_j w_{ij} f(u_j)$  (連続時間モデル) が許容量を超えたときにのみ、絶対不応期に入るものとする。すなわち、時刻  $t$  におけるニューロン  $i$  への入力総和が、離散時間モデルのとき

$$|u_i(t)| > \theta_{inact}, \quad (17)$$

連続時間モデルのとき

$$\left| \sum_{j=1}^n w_{ij} f(u_j(t)) \right| > \theta_{inact} \quad (18)$$

となると、その後  $T$  時間はいかなる入力に対しても興奮しない不応期に入るものとする。 $\theta_{inact}$  は不応期に入る膜電位または入力信号のしきい値で、不応しきい値と呼ぶ。膜電位または入力信号と不応との関係を活性化関数とともに図2に示す。したがって、ニューロン  $i$  の活性は、離散時間モデルに対して、

$$f'_i(u_i(t)) = \begin{cases} f(u_i(t)) & (\text{活動期のとき}) \\ 0 & (\text{不応期のとき}) \end{cases} \quad (19)$$

となる。連続時間モデルに対しては、不応期間中、膜電位は、

$$u_i(t) = 0 \quad (20)$$

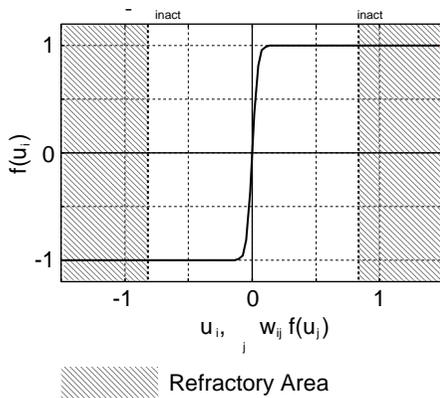


図2 ニューロンの不応と活性化関数

Fig. 2 Neuron's activation function and its refractory area.

となる。  $f$  は活性化関数であり、離散時間記憶モデルに対して符号関数、連続時間記憶モデルに対してシグモイド関数を用いられ、ともに単調関数である。ただし、想起パターンを計算するときのみ、不応期間中 ( $t_2 \leq t < t_2 + T$ ) のニューロン  $i$  について、離散時間モデルに対して、

$$x_i(t) = \begin{cases} 1 & (u_i(t_2) > \theta_{inact} \text{ のとき}) \\ -1 & (u_i(t_2) < -\theta_{inact} \text{ のとき}) \end{cases} \quad (21)$$

と見なす。また、連続時間モデルに対しても同様の扱いをする。

### 3.3 回路網の収束性

Hopfield ネットワークのように、自己結合がなく相互の結合が対称である条件のもとに、活性化関数に単調関数を用いると、ある1つの平衡状態に落ち着くことが知られている。非単調活性化関数モデルは、活性化関数に単調関数を用いていないため、想起能力は高いが収束は必ずしも保証されないという性質がある。

以下に、提案モデルが Hopfield モデルと同様、つねに収束を保証するかを調べるために、提案モデルの収束時間を求める。時刻  $t$  における活動するニューロンからなる回路網を

$$PN(t) \equiv \{i\} \quad (22)$$

( $i$  : 活動期にあるすべてのニューロン番号)

と定義する。すなわち、 $PN(t)$  は、時刻  $t$  の活動期にあるすべてのニューロンとそれらを結合する結合荷重からなる部分回路網を表す。特別な場合として、

$$PN(0) = \{1, 2, \dots, n\} \quad (23)$$

である。さらに、時刻  $t$  における回路網  $PN(t)$  の工

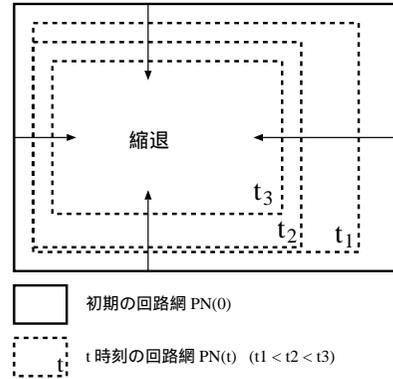


図3 回路網  $PN(t)$  の縮退の様子を示す模式図

Fig. 3 Schematic diagram showing degeneration of network  $PN(t)$ .

ネルギー関数を

$$E(t) \equiv -\frac{1}{2} \sum_{i \in PN(t)} \sum_{j \in PN(t)} w_{ij} x_i(t) x_j(t) \quad (24)$$

と定義する。また、収束時間(収束すると仮定して)に比べて不応期間  $T$  が十分大きくなるように、 $T = \infty$  とおく。

どのニューロンも活動期から不応期へ変化しない期間  $t_1 \leq t' < t_2$  は、同一の回路網  $PN$  で動作する。この期間は、Hopfield モデルと同様の動作となり、状態が変化するたびに必ずエネルギー関数  $E$  は減少する。このため、回路網  $PN(t')$  のニューロン数を  $n'$  とすると、時刻  $t'$  のときにとりうる状態数は  $2^{n'}$  であり、しかも以前の状態へは戻らない。このことより、期間  $t_1 \leq t' < t_2$  での状態遷移の回数は、 $O(2^{n'})$  となる。

次に、時刻  $t_2$  で1つ以上のニューロンが不応期に入る場合を考える。仮定  $T = \infty$  より、

$$PN(t_2) \subset PN(t) \quad (t < t_2) \quad (25)$$

である。これは、ニューロンが不応期に入るときは、回路網は、必ず以前の回路網の部分回路網となり縮退し、以前の回路網には戻らないことを示している。回路網の縮退の様子を表す模式図を図3に示す。このことより、 $PN$  の変遷回数  $O(n)$  が得られる。したがって、同一の  $PN$  における状態変化の回数は  $O(2^n)$ 、 $PN$  の変遷回数は  $O(n)$  であるので、提案モデルの状態変化の回数は  $O(2^n)$  となる。以上のことにより、回路網の規模に対して不応期間  $T$  が十分大きい場合に限り、不応期を有するニューロンからなる回路網はつねに収束を保証する。

### 3.4 静的想起による基礎実験

静的な連想記憶回路網を用いて、ニューロンの不応

と想起能力との関係を調べ、ニューロンに不応性を採り入れることが有効であることを明らかにするとともに、不応しきい値を適応的に制御する手法を示唆する。活動期にあるニューロンの全体のニューロンに対する割合を

$$\gamma \equiv \text{回路網の活動度} \quad (26)$$

と定義する。また、誤想起の確率を論ずるとき、信号項と雑音項の比が問題となるので、式(8)の項を用いて、ニューロン  $i$  の膜電位  $u_i$  の雑音信号比を

$$\text{Noise}_i = \frac{\text{crosstalk}_i}{\text{signal}_i} \quad (27)$$

とする。動的な想起において  $n$  個のニューロンから  $(1-\gamma)n$  個のニューロンを不応させることを考え、これを静的な連想記憶のモデルで以下のように評価する。

### 3.4.1 ランダムにニューロンを不応にした場合

まず、ランダムに選んだニューロンを不応期へ入れる場合の想起能力を考える。動的な連想記憶の想起過程において、ニューロン  $i$  が不応すると出力  $x_i = 0$  となるため、静的な回路網モデルでは、対応する入力信号を  $x_i(0) = 0$  ( $1 \leq i \leq (1-\gamma)n$ ) として回路網の能力を評価する。

記憶パターン  $S^\mu$  と同一または若干異なるパターン  $S^{\mu'}$  を回路網に入力した場合、ニューロン  $i$  の膜電位は、

$$u_i(1) = \gamma a(S^{\mu'}, S^\mu) s_i^\mu + \frac{1}{n} \sum_{j \neq i, j \in PN} \sum_{\nu \neq \mu} s_i^\nu s_j^\nu s_j^{\mu'} \quad (28)$$

となる。回路網  $PN$  に含まれるニューロンは  $\gamma n$  個であるため、中心極限定理を用いて式(28)は、

$$u_i(1) = \gamma a(S^{\mu'}, S^\mu) s_i^\mu + \sqrt{\gamma r} \epsilon \quad (29)$$

と計算でき、ニューロン  $i$  の膜電位の雑音信号比は、

$$\text{Noise}_i = \frac{1}{a(S^{\mu'}, S^\mu) s_i^\mu} \sqrt{\frac{r}{\gamma}} \epsilon \quad (30)$$

となる。ここで、 $\epsilon$  は、標準正規確率変数であり、

$$\text{Noise}_i \leq -1 \quad (31)$$

のとき、ニューロン  $i$  は誤ったパターンの要素を出力する。

記憶パターン  $S^\mu$  を回路網に入力した場合について、記憶率と誤想起の確率との関係を図4に示す。同図より、回路網の活動度  $\gamma$  が低いほど、誤想起の確率は大きくなる。式(30)より、膜電位の雑音信号比の

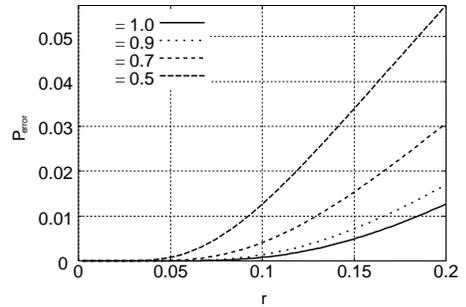


図4 回路網の活動度による記憶率と誤想起の確率

Fig. 4 Relation between memory ratio and probability of failed recalls.

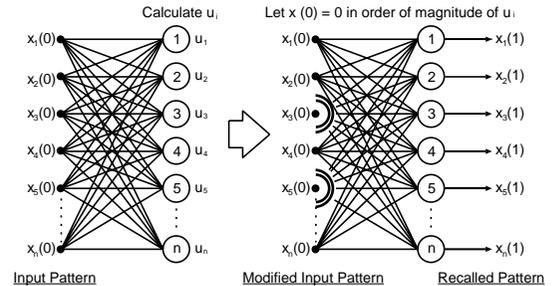


図5 膜電位の大きさによるニューロンの不応設定

Fig. 5 Scheme of setting neurons refractory based on the magnitude of membrane potential.

分散が、 $r/\gamma = m/(\gamma n)$  と表せることから、ランダムにニューロンを不応させ、回路網の活動度を  $\gamma$  とした回路網の想起能力は、 $\gamma n$  個のニューロンからなる回路網の能力と等価であるといえる。結論として、ランダムにニューロンを不応期に入れても、想起能力は  $\gamma n$  個のニューロンからなる回路網と等価になり低下する。

### 3.4.2 膜電位の大きさによりニューロンを不応にした場合

次に、不応させるニューロンをランダムに選択するのではなく、以下の基準により選択することを考える。これは、部分反転法<sup>24)</sup>と類似の手法である。図5に示すように、まず、記憶パターン  $S^\mu$  を入力したときのニューロン  $i$  の膜電位  $u_i$  を計算する。次に、 $|u_i|$  が大きい順にニューロンを不応させることを考える。回路網の活動度を  $\gamma$  にするために、 $|u_i|$  が大きい順にニューロンを  $(1-\gamma)n$  個を不応させる。静的な連想では、 $(1-\gamma)n$  個の入力を  $x_i(0) = 0$  とすることに对应する。

ニューロン数  $n = 1000$  とした回路網を用いて数値実験により、想起パターン  $X(1)$  と想起すべき記憶パターン  $S^\mu$  との類似度を調べ図6に示す。図中、記

ランダムなパターンが記憶されているため、一般性を失うことなく、不応するニューロンは1番目のニューロンから  $(1-\gamma)n$  個選ぶことができる。

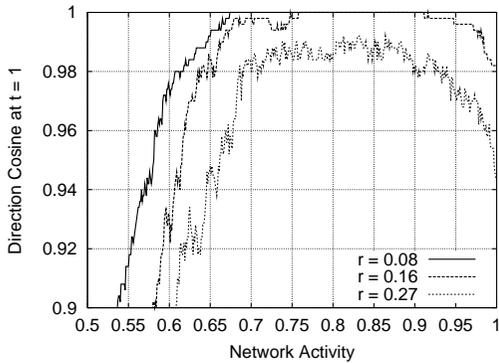


図6 回路網の活動度による想起パターンと記憶パターンの類似度  
Fig. 6 Examples of overlap between recalled and target patterns as a function of the network activity.

憶率がそれぞれ  $r = 0.08, 0.16, 0.27$  のときの想起パターンと記憶パターンの類似度の一例が示されている。記憶率  $r = 0.08$  のとき、ニューロンを不応させなくとも回路網は記憶パターン  $S^\mu$  を完全想起する。一方、記憶率  $r = 0.16$  では、活動度  $\gamma = 1$  の回路網では、もはや完全想起が成功しない。しかしながら、活動度  $0.76 < \gamma < 0.91$  では完全想起が成功する。このことは、ニューロンを不応させ活動度を  $\gamma < 1$  とすることにより、回路網の想起能力が向上することを示唆している。さらに記憶率を上げ、 $r = 0.27$  では、完全想起に成功する活動度  $\gamma$  の範囲がない。すなわち、記憶率  $r = 0.27$  ではいかなる活動度  $\gamma$  においても完全想起が不可能となる。ただし、想起パターンに  $0.5\%$  ( $a(X(1), S^\mu) \geq 0.99$ ) の誤差を許すとすれば、 $\gamma = 0.84$  付近で想起が成功するといえる。

次に、記憶率  $r$  と想起可能な回路網の活動度  $\gamma$  の範囲との関係を図7に示す。想起パターンに  $0.5\%$  の誤差を許すとすると、記憶率およそ  $r \leq 0.15$  では、回路網の活動度が  $\gamma = 1$  を含めおよそ  $\gamma > 0.65$  の範囲で想起が成功する。一方、記憶率  $r > 0.16$  のとき、回路網の活動度  $\gamma = 1$  では想起不可能となり、活動度  $\gamma = 0.835$  を中心に想起可能な回路網の活動度の範囲が記憶率の上昇にともない小さくなる。そして、記憶率  $r = 0.3$  付近でその範囲は消滅する。以上の結果より、回路網の最適な活動度 ( $\gamma \sim 0.835$ ) は、記憶率に関係なくほぼ一定であるといえる。また、図中、想起可能な回路網の活動度が存在する確率を  $\times$  印で示す。記憶率  $r > 0.28$  では、想起可能な回路網の活動度が存在する確率が急激に低下し、もはやこの手法で

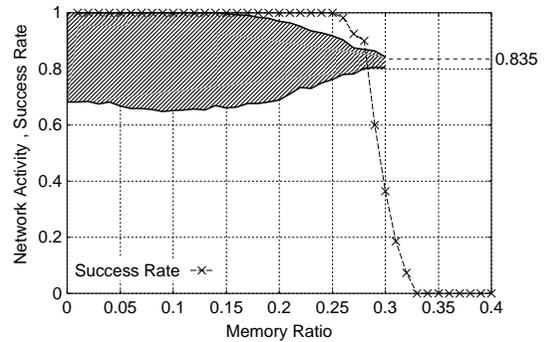


図7 想起可能な回路網の活動度と記憶率との関係(斜線部は想起可能な回路網の活動度の範囲、 $\times$ 印は想起可能な回路網の活動度が存在する確率)

Fig. 7 Relation between memory ratio and the activity level of the networks which recalled target patterns successfully.

は想起は不可能となることが分かる。

以上の静的な想起の実験により、ニューロンを不応させることにより、Hopfieldモデルでなしえなかった  $0.16n$  を越える記憶容量が実現でき、簡単な手法により想起能力の向上が図れることが示唆された。また、膜電位の絶対値  $|u_i|$  の大きさに基づきニューロンを不応期に入れることが有効な方法の1つであると結論する。不応期を回路網に導入する場合、回路網の活動度が  $\gamma = 0.835$  になるようにすれば想起能力が最も高くなると予想される。また、この静的な想起に関する実験結果は、従来の改良手法である部分反転法や非単調活性化関数モデルにおける想起能力の向上の根拠にもなっていると思われる。

### 3.5 回路網の活動度に基づく動的な不応しきい値

前節の結果をふまえ、回路網の活動度に基づきニューロンが不応期に入る回路網を提案する。提案する回路網は、不応しきい値  $\theta_{inact}$  を想起中、適応的に変化させる回路網であり、この一例を図8に示す。この回路網では、通常のHopfield回路網に加えて、特別な線形ニューロンが1つ追加されており、各ニューロンは、この特別なニューロンの信号に従い不応しきい値を増減させる。特別な線形ニューロンは、結合荷重  $1/n$  を通して、各ニューロンの出力の絶対値を入力とする。すなわち、この線形ニューロンは、回路網の活動度

$$\gamma(t) = \frac{1}{n} \sum_{i=1}^n |x_i(t)| \quad (32)$$

を入力とし、回路網の活動度の目標値  $\gamma_{tar}$  との誤差に従って、すべてのニューロンの不応しきい値  $\theta_{inact}$  を一様に増減する。

この不応しきい値を制御するニューロンにより、各

各記憶率における想起可能な回路網の活動度の中心を求め、その平均をとった。

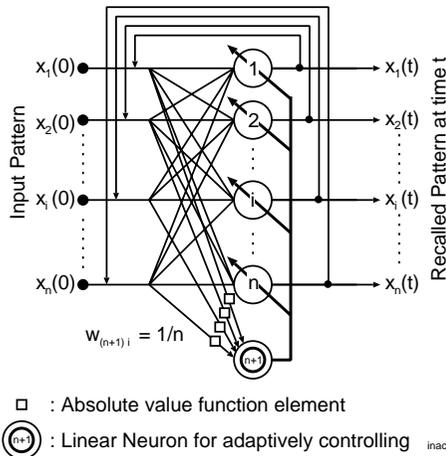


図 8 動的な不応しきい値を持つ回路網  
Fig. 8 An example of the network having adaptive refractory threshold.

ニューロンの不応しきい値  $\theta_{inact}(t)$  は、離散時間の場合、

$$\tau_{\theta}(\theta_{inact}(t+1) - \theta_{inact}(t)) = \gamma_{tar} - \gamma(t) \quad (33)$$

連続時間の場合、

$$\tau_{\theta}(t) \frac{d\theta_{inact}(t)}{dt} = \gamma_{tar} - \gamma(t) \quad (34)$$

に基づき変化させることとする。また、連続時間による回路網では、回路網の安定性の立場から、時定数  $\tau_{\theta}$  は、

$$\tau_{\theta}(t) = \frac{1}{\alpha \exp(-t) + \frac{1}{\beta}} \quad (35)$$

とし、 $\lim_{t \rightarrow \infty} \tau_{\theta}(t) = \beta$  の性質を持つようにする、すなわち、時定数は、変動率  $\alpha$  で  $\beta$  に収束する。

また、不応期間は乱数によりゆらぎが加えられ、不応期間を  $T = T_{inact}$  と表すときは、 $T_{inact} = \infty$  を除いて、各々のニューロンは、不応期に入るたびに

$$T = T_{inact}(1 + 0.3\epsilon) \quad (36)$$

に従い確率的に決定された値を不応期間とする。

## 4. 数値実験

同期型の離散時間記憶モデルおよび連続時間記憶モデルについて、提案モデルの数値実験を行った。

### 4.1 離散時間離散値記憶モデル

以下、ニューロン数  $n = 1000$  とし、記憶パターンの 1 つ  $S^{\mu}$  との方向余弦が  $a(X(0), S^{\mu})$  ( $0 < a \leq 1$ ) であるパターン  $X(0)$  を回路網に入力した後、すべてのニューロンに同期的に 100 単位時間遷移させ、最後の 10 単位時間を通して想起すべき記憶パターンとの方向余弦が つねに 0.99 以上の場合に想起成功とした。

3.4.2 項の結果より、式 (33) の回路網の活動度の目標値を  $\gamma_{tar} = 0.835$  とし、不応しきい値の初期値は、 $\theta_{inact}(0) = 1.6$  とした。また、 $\tau_{\theta}$  は、不応しきい値の変動により回路網の活動度が振動し不安定にならないように、記憶率に応じて  $0.5 < \tau_{\theta} < 20$  の範囲から選択した。

記憶率  $r = 0.2$ 、不応期間  $T_{inact} = \infty$  のときの提案モデルの想起過程と回路網の活動度  $\gamma(t)$  の推移を図 9 に示す。同図 (b) より、回路網の活動度  $\gamma(t)$  が目標値  $\gamma_{tar}(= 0.835)$  に収束することが示され、記憶率 0.2 において臨界方向余弦  $0.6 < a_c \leq 0.7$  を得た。

次に、不応期間  $T_{inact}$  を変えて提案モデルの想起能力を調べたが、不応期間  $T_{inact}$  は想起能力には影響しないことが分かった。すなわち、回路網の収束をつねに保証する  $T_{inact} = \infty$  の提案モデルは、回路網の収束をつねに保証しない他のいかなる不応期間を持つ提案モデルと同等の能力を持つ。

最後に、動的な不応しきい値 (A.T.) を持つ記憶モデルと固定的な不応しきい値 (F.T.) を持つ記憶モデルならびに従来の記憶モデルの想起能力を図 10 に示す。不応期を持つ記憶モデルの中では、動的な不応しきい値を持つ記憶モデルが固定的な不応しきい値を持つ記憶モデルよりやや想起能力が高い結果となったが、ほぼ同程度の能力といえる。ただし、固定型のモデルは、記憶率に応じてそのたびに不応しきい値を決定しなければならない。一方、変動型のモデルは、回路網の活動度を利用して、自動的に不応しきい値が決定される利点がある。さらに、従来の記憶モデルと比較しても、回路網の収束をつねに保証するモデルとしては高い想起能力を示すことが分かった。この実験により、記憶容量について表 1 に示す結果が得られた。ここで、収束の保証とは、想起成功、不成功にかかわらずつねに収束を保証することを意味する。

### 4.2 連続時間記憶モデル

用いる活性化関数はシグモイド関数

$$f(u) = \frac{1 - e^{-100u}}{1 + e^{-100u}} \quad (37)$$

とした。ニューロン数  $n = 1000$  とし、記憶パターンの 1 つ  $S^{\mu}$  との方向余弦が  $a(X(0), S^{\mu})$  ( $0 < a \leq 1$ ) であるパターン  $X(0)$  を回路網に入力した後、30 単位時間遷移させ、最後の 1 単位時間を通して想起すべき記憶パターンとの方向余弦が つねに 0.99 以上の場

動的想起の数値実験でも  $\gamma_{tar} = 0.835$  付近が最適という結果を得た。  
部分反転法では、自己結合を有するものとし、 $w_{ii} \neq 0$  とした。

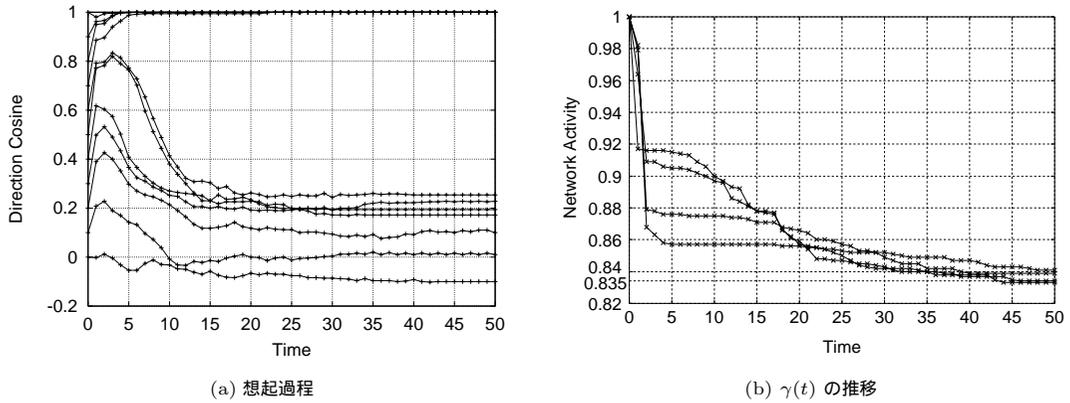


図9 動的不应しき値を持つニューロンによる回路網の想起過程とその活動度(同期離散時間離散値モデル,  $r = 0.2$  ( $n = 1000, m = 200$ ),  $\gamma_{tar} = 0.835, T_{inact} = \infty$ )  
 Fig.9 Recalling process and network activity of the network using the adaptive refractory threshold (Synchronous discrete-time model).

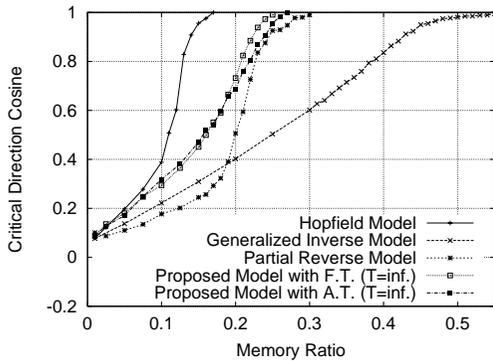


図10 提案モデルと従来モデルの想起能力の比較(離散時間モデル)  
 Fig.10 Comparison of basin of attraction between the proposed models and conventional models (Discrete-time models).

表1 離散時間離散値記憶モデルの記憶容量

Table 1 Memory capacity of the discrete-time memory models.

手法	記憶容量	収束
不应ニューロンモデル (動的不应しき値)	$0.26n$	
不应ニューロンモデル (固定不应しき値)	$0.24n$	
Hopfield モデル	$0.16n$	
部分反転法	$0.29n$	×
疑似逆行列モデル	$0.54n$	×

合に想起成功とした。連続時間記憶モデルの場合は、離散時間記憶モデルと異なり、3.4.2 項の結果を直接適用することができない。したがって、実験的に良い結果が得られたものを用い、式(34)中の活動度の目標

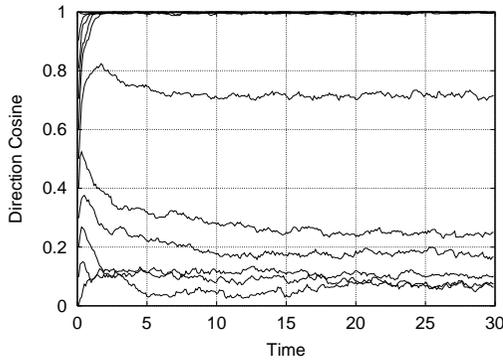
値を  $\gamma_{tar} = 0.66$  とした。また、不应しき値の変動により、回路網の活動度が振動して不安定にならないように、式(35)中の  $\beta$  は 2.0 とし、 $\alpha$  は記憶率に応じて  $4.0 < \alpha < 40$  の範囲から選択した。

記憶率  $r = 0.4$ , 不应期間  $T_{inact} = 3$  のときの提案モデルの想起過程と回路網の活動度および不应しき値の推移を図11に示す。同図(b)より、回路網の活動度が目標値に収束することが示され、記憶率 0.4 において臨界方向余弦  $0.5 < a_c \leq 0.6$  を得た。

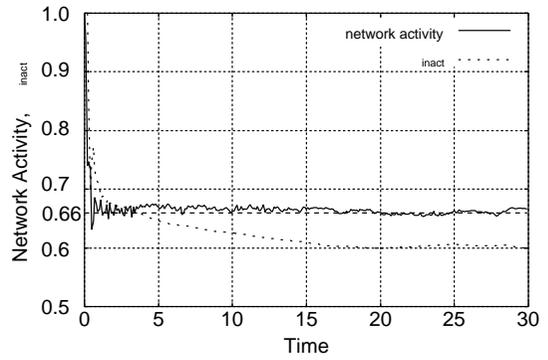
さらに、不应期間  $T_{inact}$  を変えると、離散時間記憶モデルの場合と異なり、 $T_{inact}$  が大きくなるにつれて、想起能力が低下することが分かった。また、回路網の収束を保証する  $T_{inact} = \infty$  の回路網では、記憶容量は  $0.33n$  となり、離散時間記憶モデルより大きい容量を有する。

最後に、提案モデルと従来モデルの想起能力の比較を図12に示す。動的しきい値(A.T.)を有し、想起能力が高い回路網および収束を保証する回路網として、それぞれ  $T_{inact} = 3, \infty$  の回路網を示した。また、固定不应しき値(F.T.)を持つ回路網として能力が高い  $T_{inact} = 3$  の回路網も示した。この実験により、記憶容量について表2に示す結果が得られ、提案モデルは、不应期間が短い場合は、疑似逆行列記憶モデルと比較し、記憶容量は小さいが引き込み領域が大きく、森田らの非単調活性化関数モデルより大きい記憶容量を有する。また、 $\tau = \infty$  の提案モデルの記憶容量は  $0.33n$  となり、収束がつねに保証されるモデルとしては優れているといえる。さらに、不应しき値固定型の回路網の場合は、記憶容量は  $0.40n$  となった。

3.4 節の実験結果から推測すると、連続時間記憶モ



(a) 想起過程



(b)  $\gamma(t)$  と  $\theta_{inact}(t)$  の推移

図 11 動的な不応しき値を持つニューロンによる回路網の想起過程と活動度の推移 (連続時間モデル,  $r = 0.4$  ( $n = 1000, m = 400$ ),  $\gamma_{tar} = 0.66, T_{inact} = 3$ )

Fig. 11 Recalling process of the network using the adaptive refractory threshold, its network activity and refractory threshold during the recall (Continuous-time model).

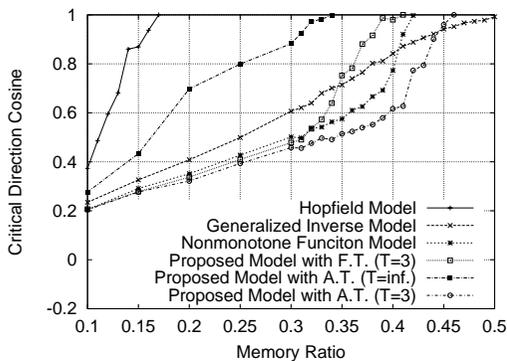


図 12 提案モデルと従来モデルの想起能力の比較 (連続時間モデル)

Fig. 12 Comparison of basin of attraction between the proposed models and conventional models (Continuous-time models).

表 2 連続時間記憶モデルの記憶容量

Table 2 Memory capacity of the continuous-time memory models.

手法	記憶容量	収束
不応ニューロンモデル (動的な不応しき値, $T_{inact} \neq \infty$ )	$\leq 0.45n$	x
不応ニューロンモデル (動的な不応しき値, $T_{inact} = \infty$ )	$0.33n$	
不応ニューロンモデル (固定な不応しき値)	$\leq 0.40n$	x
Hopfield モデル	$0.16n$	
非単調関数モデル ( $w_{ii} = 0$ )	$0.41n$	x
疑似逆行列モデル	$0.50n$	x

デルの場合でも記憶率に依存しない最適な回路網の活動度が存在すると考えられる。このことにより、記憶

率に無関係に回路網の活動度の目標値  $\gamma_{tar}$  が決定でき、実験結果より、回路網の活動度を利用して記憶率に応じた不応しき値を自律的に決定できることが示された。

### 5. 回路網の活動度を利用した逐次学習

この章では、さらに、回路網の活動度  $\gamma$  を利用した逐次学習則を提案する。一般に、Hopfield 型の連想記憶回路網は、あらかじめ Hebb 学習則によりパターンが一括学習され、学習と想起の過程が分離されている。すなわち、これらの連想記憶モデルは、オフライン学習の記憶モデルといえる。しかしながら、連想記憶回路網は、記憶したパターンあるいはその類似パターンが入力されたときは、その記憶パターンを想起し、未知のパターンが入力されたときは、記憶容量の上限までパターンを追加記憶することが望ましい場合がある。これは、オンライン学習、すなわち逐次学習可能な記憶モデルといえる<sup>35),36)</sup>。

逐次学習が可能な記憶モデルの場合、既知パターンと未知パターンとの判定機構が必要となる。以下に、不応期を有するニューロンからなる回路網に対して、既知パターンと未知パターンの判定に回路網の活動度を利用する。3.5 節で提案した動的な不応しき値を用いた回路網の場合は、回路網の活動度を目標値  $\gamma_{tar}$  となるように不応しき値が制御されるため、回路網の活動度を用いて既知/未知パターンの判定ができない。したがって、ここでは、 $T_{inact} = \infty$  を持つ固定的な不応しき値を用いた非同期離散時間記憶モデルを用いるものとする。固定的な不応しき値を用いた

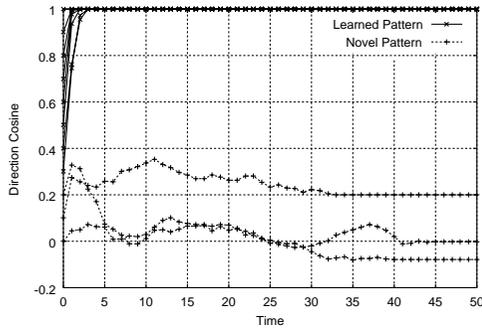


図 13 既知パターンと未知パターンの入力に対する想起過程(非同期離散時間離散値モデル,  $r = 0.1$  ( $n = 1000$ ,  $m = 100$ ),  $\theta_{inact} = 1.05$ ,  $T_{inact} = \infty$ )

Fig. 13 Recalling processes triggered by learned and novel patterns (Asynchronous discrete-time memory model).

非同期離散時間記憶モデルは, Hopfield 型回路網と比較し, 高い想起能力を示すことがすでに数値実験により示されている<sup>32)</sup>. この高い想起能力に加え, 逐次学習を以下のように実現する.

まず, 固定的な不応しきい値を有する非同期離散時間記憶回路網の想起過程を図 13 に示す. この例は, 記憶率  $r = 0.1$  であり, 記憶パターンの一つ  $S^\mu$  と相関または無相関なパターン  $X(0)$  ( $X(0)|0 \leq a(X(0), S^\mu) \leq 1$ ) を入力した場合の想起過程である. また, 不応しきい値は, 実験で得られた最も良い値  $\theta_{inact} = 1.05$  を用いた. 図中, 実線で示された想起過程は, 記憶パターン  $S^\mu$  の想起に成功した場合であり, 点線で示された想起過程は, 記憶パターン  $S^\mu$  の想起に失敗した場合である. いい換えれば, 実線で示された想起過程は, 記憶パターン  $S^\mu$  の引き込み領域内のパターンが入力された場合であり, 点線で示された想起過程は, 引き込み領域外のパターンが入力された場合といえる. ただし, 想起成功の条件として, 0.5% の誤差までを許容するものとする.

この場合, 入力パターンが引き込み領域の内にある場合は, 既知パターンと見なし, 一方, 引き込み領域の外にある場合は, 未知パターンと見なし, 新規パターンとして追加学習することが妥当と考えられる. すなわち, 記憶パターンと無相関なパターンのみではなく, 引き込み領域外の想起不可能な相関を持つパターンをも新規パターンとして学習することを目的とする. なぜならば, 記憶容量の限界付近を除けば, すでに記憶されたパターンと相関を持つパターンも記憶が可能であるからである. 図 13 の例では, 入力パターン  $X(0)$  ( $X(0)|0 \leq a(X(0), S^\mu) \leq 0.2$ ) の一つが追加学習すべき未知パターンとなる.

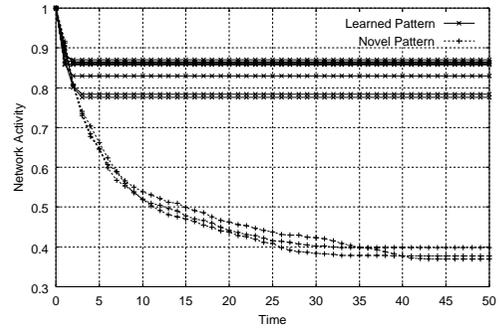


図 14 想起中の回路網の活動度

Fig. 14 Network activity during recall.

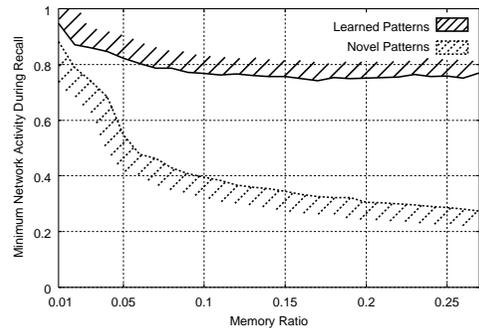


図 15 既知パターンと未知パターンに対する想起中の回路網の活動度の最小値の範囲

Fig. 15 Boundary of minimum network activity during recall between learned and novel patterns.

次に, 図 13 の想起例における回路網の活動度  $\gamma(t)$  を図 14 に示す. 同図より, 既知パターンが入力されたときの回路網の活動度が未知パターンが入力されたときの活動度より大きいことが分かる. この結果は, 回路網の活動度に対するしきい値を適切に設定することにより, 未知パターンと既知パターンの判定が可能であることを示唆している. しかしながら, 図 15 に示すように, 既知または未知パターンの入力に対する想起過程の回路網の活動度の最小値の範囲は, 記憶率により変動する. さらに, 不応期間  $T_{inact}$  を小さくすると, この性質は顕著になる. 一般に, どれくらいのパターンを記憶しているかを示す回路網の記憶率  $r$  は分からない. また, 記憶率に依存しない追加学習則を考慮することが望ましい. したがって, 既知/未知パターンの判別基準に回路網の活動度  $\gamma(t)$  を直接に用いず, 他の判定手法を以下に考える.

ここで, 想起過程の回路網の活動度  $\gamma(t)$  の変化量に注目し, 時刻  $t$  までの回路網の活動度  $\gamma(t)$  の変化量の重み付け和を

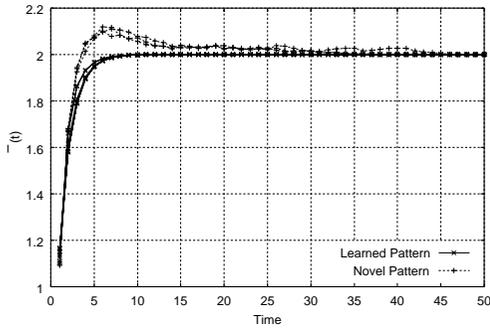


図 16 想起中の回路網の活動度の変化量と  $\bar{\gamma}(t)$

Fig. 16 Contrasted  $\bar{\gamma}(t)$  for learned and novel patterns.

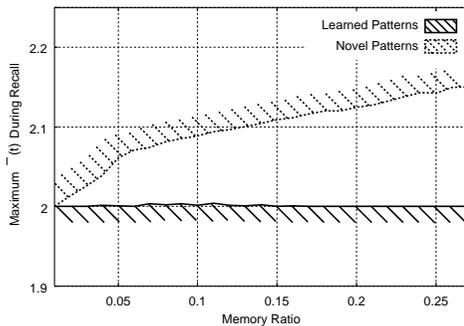


図 17 既知パターンと未知パターンに対する想起中の回路網の活動度の変化量と  $\bar{\gamma}$  の最大値の範囲

Fig. 17 Boundary of maximum  $\bar{\gamma}$  during recall between learned and novel patterns.

$$\bar{\gamma}(t) = \sum_{t'=2}^t \frac{1}{2^{(t-t')}} \frac{1 - \gamma(t')}{1 - \gamma(t' - 1)} \quad (38)$$

と定義し、図 13 に示す想起例における  $\bar{\gamma}(t)$  の推移を図 16 に示す。既知パターンが入力された場合、 $\bar{\gamma}(t)$  は 2 に漸近するように増加し、2 を大きく超えない。一方、未知パターンが入力された場合は、一度 2 を大きく超えた後に 2 に漸近する結果となった。既知パターンと未知パターンの入力に対する想起過程中的  $\bar{\gamma}(t)$  の最大値の範囲を図 17 に示す。この結果より、既知パターンの入力に対する想起過程中的  $\bar{\gamma}(t)$  の最大値が、記憶率によらず 2 の近傍となることが分かった。したがって、記憶率の大きさにかかわらず、既知/未知パターンの判定のための  $\bar{\gamma}(t)$  のしきい値が容易に設定でき、

$$\bar{\gamma}(t) > \theta_{learn} \quad (39)$$

のとき、入力パターン  $X(0)$  を未知パターンと判定し、Hebb 学習則に従い、回路網の結合加重  $w_{ij}$  ( $i \neq j$  のとき) を

$$w_{ij} + \frac{1}{n} x_i(0) x_j(0) \quad (40)$$

に更新する。

最後に、上述した逐次学習アルゴリズムが正しく動作することを数値実験により明らかにする。図 18 は、想起中に未知パターンと判定されたパターンの逐次学習の様子を示すものであり、同図 (a) は想起中の出力パターンを、(b) は想起中の  $\bar{\gamma}(t)$  の値を示すものである。ここで、図 17 の結果より、 $\theta_{learn} = 2.05$  とした。

この例では、事前に記憶されたパターンの 1 つ  $S^\mu$  自体およびその類似パターンが時刻  $t = 0$  で回路網に入力された。パターン  $S^\mu$  および  $S^{\mu'}$  ( $S^{\mu'} | 0.4 \leq a(S^{\mu'}, S^\mu) < 1$ ) を入力すると、記憶パターン  $S^\mu$  が正しく想起され、そのときの  $\bar{\gamma}(t)$  の値は、式 (39) の条件を満たさず、未知パターンとは判定されない。一方、記憶パターン  $S^\mu$  を想起しないパターン  $S^{\mu''}$  ( $S^{\mu''} | a(S^{\mu''}, S^\mu) = 0.3$ ) は、同図 (b) に示されるように、式 (39) の条件を満たし、未知パターンと正しく判定された。

次に、時刻  $t = 24$  でパターン  $S^{\mu''}$  を式 (40) に従い追加学習した。時刻  $t = 25$  に追加学習されたパターン  $S^{\mu''}$  自体およびその類似パターンを入力し、引き込み領域内のパターンからパターン  $S^{\mu''}$  が正しく想起され、かつ、同図 (b) により、引き込み領域外のパターンが未知パターンとして正しく判定されていることが分かる。他の記憶率の場合も実験を行ったが、引き込み領域の近傍を除けば、既知/未知パターンの判定は、ほぼ 100% 成功した。

## 6. まとめ

本論文では、不応期を有するニューロンを用いた連想記憶回路網において、記憶率によらず、不応しきい値が動的に設定される回路網を提案し、同期離散時間回路網および連続時間回路網に適用した。まず、提案記憶モデルは、自己相関連想記憶モデルに従来の単調な活性化関数を用いるため、Hopfield モデルと同様、不応期間を十分長くすれば、必ず収束することを証明した。次に、静的な想起による数値実験により、想起能力が最も高くなる回路網の活動度を導出した。この結果を利用し、回路網の活動度に基づき適応的に不応しきい値を制御する回路網を考え、この手法により想起能力が向上することを数値実験により確かめた。また、連続時間回路網に対しても、想起能力が向上することが確かめられた。

さらに、回路網の活動度が入力パターンの未知/既知パターンの判定に利用できることに注目し、未知パ

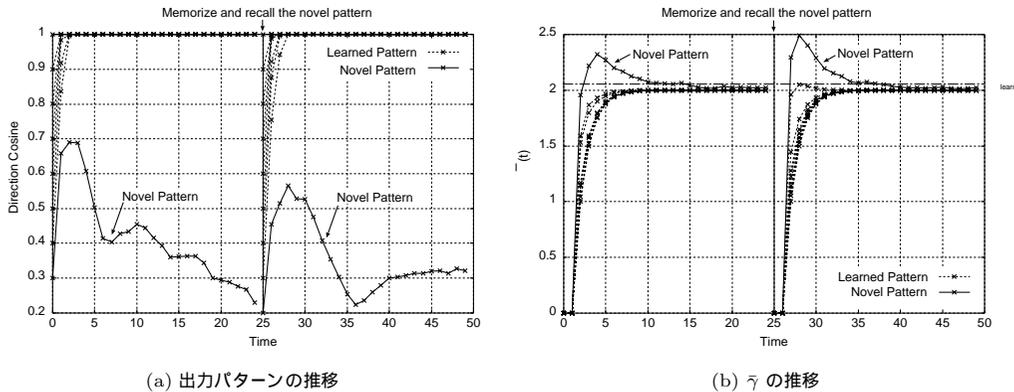


図 18 想起中の出力パターンと  $\bar{\gamma}$  の推移

Fig. 18 Two recall processes, one is a recall of one of patterns memorized off-line and the other is a recall of the pattern detected during the first recall as a novel pattern and learned at time  $t = 24$ .

ターンの逐次学習則を提案した。提案学習則を非同期離散時間記憶モデルに適用し、その有効性を数値実験により示した。

本論文の結果により、ニューロンに不応期を設定することにより、想起能力が向上することに加え、回路網の活動度が想起能力に重要な影響を与えられていることが明らかとなった。また、その応用として、回路網の活動度が既知/未知パターンの判定にも利用できることが示された。このことは、本論文で示した手法以外にも、回路網の活動度を積極的に利用した新しい記憶モデルの創造の可能性を示唆しており、今後の課題となるであろう。また、本提案モデルの理論的な想起能力の解析や相互相関連想記憶、双方向連想記憶への応用も課題としてあげられる。

### 参考文献

- 1) Nakano, K.: Associatron—A Model of Associative Memory, *IEEE Trans. Systems, Man and Cybernetics*, Vol.SMC-2, No.3, pp.380–388 (1972).
- 2) Kohonen, T.: Correlation Matrix Memories, *IEEE Trans. Computers*, Vol.C-21, No.4, pp.353–359 (1972).
- 3) 甘利俊一：ニューラルネットの新展開，サイエンス社 (1993).
- 4) 上坂吉則，尾関和彦：連想記憶の二，三の性質，電子情報通信学会論文誌 D，Vol.55-D, No.5, pp.323–330 (1972).
- 5) Hopfield, J.J.: Neural networks and physical systems with emergent collective computational abilities, *Proc. Natl. Acad. Sci., USA*, Vol.79, pp.2554–2558 (1982).
- 6) Perfetti, R.: Sensitivity of equilibrium points in continuous-time Hopfield's Network, *IEEE Trans. Neural Networks*, Vol.6, No.2, pp.501–504 (1995).
- 7) Xu, Z., Hu, G. and Kwong, C.: Asymmetric Hopfield-type Networks: Theory and Applications, *Neural Networks*, Vol.9, No.3, pp.483–501 (1996).
- 8) Zhenjiang, M. and Baozong, Y.: Analysis and optimal design of continuous neural networks with applications to associative memory, *Neural Networks*, Vol.12, pp.259–271 (1999).
- 9) Amit, D.J., Gutfreund, H. and Sompolinsky, H.: Storing Infinite Numbers of Patterns in a Spin-Glass Model of Neural Networks, *Physical Review Letters*, Vol.55, No.14, pp.1530–1533 (1985).
- 10) Amari, S. and Maginu, K.: Statistical Neurodynamics of Associative Memory, *Neural Networks*, Vol.1, pp.63–73 (1988).
- 11) Koyama, H., Fujie, N. and Fujiwara, T.: Analysis of the Recalling Processes of Associative Memory by an Integral Representation of the Sign Function, *Neural Networks*, Vol.9, No.5, pp.737–746 (1996).
- 12) Koyama, H., Fujie, N. and Seyama, H.: Results from the Gardner-Derrida-Mottishaw theory of associative memory, *Neural Networks*, Vol.12, pp.247–257 (1999).
- 13) 矢内浩文，沢田康次：系列を連想する神経回路網モデルの性質，電子情報通信学会論文誌 D-II，Vol.J73-D-II, No.8, pp.1192–1197 (1990).
- 14) Sal'ee, D. and Baram, Y.: High-capacity Hebbian storage by sparse sampling, *IEEE Trans. Neural Networks*, Vol.6, No.2, pp.349–

- 356 (1995).
- 15) Jankowski, S., Lozowski, A. and Zurada, J.M.: Complex-valued multistate neural associative memory, *IEEE Trans. Neural Networks*, Vol.7, No.6, pp.1491–1496 (1996).
  - 16) Tsodyks, M.V. and Feigl'mann, M.V.: The enhanced storage capacity in neural networks with low activity level, *Europhysics Letters*, Vol.6, pp.101–105 (1988).
  - 17) Buhmann, J., Divko, R. and Schulten, K.: Associative memory with high information content, *Physical Review A*, Vol.39, No.5, pp.2689–2692 (1989).
  - 18) Okada, M.: Notions of Associative Memory and Sparse Coding, *Neural Networks*, Vol.9, No.8, pp.1429–1458 (1996).
  - 19) Frolov, A.A., Husek, D. and Muraviev, I.P.: Informational Capacity and Recall Quality in Sparsely Encoded Hopfield-like Neural Network: Analytical Approaches and Computer Simulation, *Neural Networks*, Vol.10, No.5, pp.845–855 (1997).
  - 20) Mazza, C.: On the Storage Capacity of Nonlinear Neural Networks, *Neural Networks*, Vol.10, No.4, pp.593–597 (1997).
  - 21) Kakeya, H. and Kindo, T.: Eigenspace Separation of Autocorrelation Memory Matrices for Capacity Expansion, *Neural Networks*, Vol.10, No.5, pp.833–843 (1997).
  - 22) Storkey, A.J. and Valabregue, R.: The basins of attraction of a new Hopfield learning rule, *Neural Networks*, Vol.12, pp.869–876 (1999).
  - 23) Ma, J.: The asymptotic memory capacity of the generalized Hopfield network, *Neural Networks*, Vol.12, pp.1207–1212 (1999).
  - 24) 森田昌彦, 吉澤修治, 中野 馨: 自己相関連想記憶の想起過程とその改良, 電子情報通信学会論文誌 D-II, Vol.J73-D-II, No.2, pp.232–242 (1990).
  - 25) 森田昌彦, 吉澤修治, 中野 馨: 非単調ダイナミクスを用いた構造をもつパターンの連想記憶, 電子情報通信学会論文誌 D-II, Vol.J75-D-II, No.11, pp.1884–1891 (1992).
  - 26) Yoshizawa, S., Morita, M. and Amari, S.: Capacity of Associative Memory Using a Non-monotonic Neuron Model, *Neural Networks*, Vol.6, pp.167–176 (1993).
  - 27) Yanai, H. and Amari, S.: Auto-associative memory with two-stage dynamics of nonmonotonic neurons, *IEEE Trans. Neural Networks*, Vol.7, No.4, pp.803–815 (1996).
  - 28) Crespi, B.: Storage capacity of non-monotonic neurons, *Neural Networks*, Vol.12, pp.1377–1389 (1999).
  - 29) Morita, M.: Memory and Learning of Sequential Patterns by Nonmonotone Neural Networks, *Neural Networks*, Vol.9, No.8, pp.1477–1489 (1996).
  - 30) Nakagawa, M.: A Parameter Controlled Chaos Neural Network, *Journal of the Physical Society of Japan*, Vol.65, No.6, pp.1859–1867 (1996).
  - 31) Adachi, M. and Aihara, K.: Associative Dynamics in a Chaotic Neural Network, *Neural Networks*, Vol.10, No.1, pp.83–98 (1997).
  - 32) 小田幹雄, 宮島廣美: 不応期をもつニューロンによる連想記憶, 電子情報通信学会技報 CAS2000-64, CST2000-19, pp.23–30 (2000).
  - 33) 甘利俊一: 神経回路網の数理, 産業図書 (1978).
  - 34) Senn, W., Wyler, K., Streit, J., Larkum, M., Luscher, H.-R., Mey, H., Muller, L., Stainhauser, D., Vogt, K. and Wannier, T.H.: Dynamics of a Random Neural Network with Synaptic Depression, *Neural Networks*, Vol.9, No.4, pp.575–588 (1996).
  - 35) 渡辺正峰, 合原一幸, 近藤駿介: カオスニューラルネットワークによる自動学習, 電子情報通信学会論文誌 A, Vol.J78-A, No.6, pp.686–691 (1995).
  - 36) 長名優子, 萩原将文: カオスニューラルネットワークにおける逐次学習, 電子情報通信学会論文誌 D-II, Vol.J82-D-II, No.1, pp.83–90 (1999).

(平成 13 年 4 月 13 日受付)

(平成 13 年 6 月 11 日再受付)

(平成 13 年 8 月 26 日採録)



小田 幹雄

1968 年生。1993 年鹿児島大学大学院修士課程修了。同年沖電気工業(株)入社。1997 年より久留米高専勤務。現在同高専電気電子工学科助手。主として神経回路網理論の研究

に従事。



宮島 廣美(正会員)

1952 年生。1979 年東北大学大学院博士課程修了。工学博士。同年熊本電波高専, 1987 年鹿児島大学工学部勤務。現在同大学電気電子工学科教授。主としてセルオートマトン

理論, 神経回路網理論の研究に従事。