

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† 宮島 廣美‡

† 久留米工業高等専門学校 ‡ 鹿児島大学工学部

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用いられていたが、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。本報告では、不応期を有するニューロンを用いた回路網において、回路網の収束を保証しながら、記憶率に依らず不応しきい値が自動的に設定される回路網を提案する。まず、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、この回路網の活動度に基づいて、適応的に不応しきい値を制御する方法をとる。数値実験により、提案手法が高い想起能力を有することを示す。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説明し、未知パターンの逐次学習則を提案する。

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

Mikio ODA† Hiromi MIYAJIMA‡

†Kurume National College of Technology

‡Faculty of Engineering, Kagoshima University

In the present paper, we 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 a special linear neuron based on the network activity. The optimal network activity, then, is obtained by a static association model and the value is used to control the threshold. Finally, using network activity, the network with on-line learning mechanism is also proposed and it is shown that the network can detect unknown patterns and memorise them.

1 はじめに

1972年に自己相関連想記憶が提案され [1]、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浴び、その後、神経回路網による連想記憶の研究が盛んに行われてきた。

動的な連想記憶の基本モデルは、いわゆる Hopfield モデルであるが、回路網の安定性の立場から、主として符号関数やシグモイド関数などの単調関数を活性化関数としていたが、記憶容量が小さいなどの欠点があった。これに対して、森田ら [2] 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は、部分反転法、連続時間モデルに対しては、活性化関数に非単調関数を用いた記憶モデルを提案した。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。

著者らは、単調な活性化関数を用いながら、膜電位の絶対値がしきい値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、非同期回路網に対して、想起能力が向上することを数値実験で示した。

本報告では、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に対して、動的な不応しきい値をもつ回路網を提案する。まず、静的な連想による数値実験から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を不応しきい値の制御に用い、回路網の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。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示し、その有効性を数値実験により明らかにする。

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. t 時刻のニューロン i の出力を $x_i(t)$ とすると, 回路網の状態は,

$$X(t) = (x_1(t), x_2(t), \dots, x_n(t))^T \quad (1)$$

と定義され (T 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 t 時刻のニューロン 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, 例えば, 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 $S^1, \dots, S^\nu, \dots, S^m$ ($S^\nu = (s_1^\nu, \dots, s_n^\nu)^T$) 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

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

の自己相関行列が用いられる. また, 回路網の想起の様子をマクロに捉えるために, 想起すべき記憶パターン S と入力パターンまたは出力パターン X との類似度として方向余弦

$$a(X, S) = \frac{1}{n} \sum_{i=1}^n x_i s_i \quad (5)$$

を定義する. 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 つと最も近い入力, 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.

3 不応期をもつニューロンによる連想記憶

3.1 記憶モデル

本報告で扱う連想記憶モデルは, Hopfield モデルに不応期をもつニューロンを用いたものである. 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もつニューロンの数学的なモデルはあったが, このモデルは, ニューロンが発火後に一様に不応期に入るものであった. ここでは, 発火した時の膜電位 u_i が許容量を越えたときにのみ, 絶対不応期にいるものとする. すなわち, ニューロン i への入力総和

$$|u_i| > \theta_{inact} \quad (6)$$

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. θ_{inact} は不応期にいる膜電位の閾値で, 不応しきい値である.

3.2 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

$$\gamma \equiv \text{回路網の活動度} \quad (7)$$

と定義する. 動的な連想記憶において 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に評価する. まず, 記憶パターン S^μ 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. つぎに, $|u_i|$ 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 γ 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, 回路網の活動度を減少させる.

記憶率 r と想起可能な回路網の活動度 γ の範囲との関係を図 1 に示す. 想起パターンに 0.5% の誤差 ($a(X(1), S^\mu) \geq 0.99$) 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 $\gamma > 0.65$ では想起が成功する. 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伴い小さくなる. 以上のことから, 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. 以上の結果により, 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

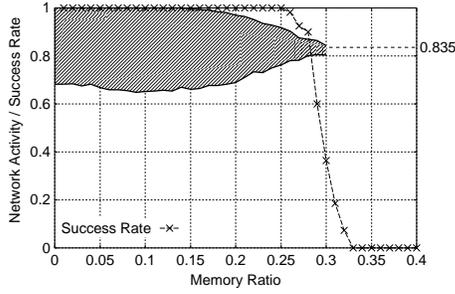


図 1: 想起可能な回路網の活動度と記憶率との関係 (斜線部は想起可能な回路網の活動度の範囲, ×印は想起可能な回路網の活動度が存在する確率)

うにすれば想起能力が最も高くなると予想される。

3.3 回路網の活動度に基づく動的な不応しきい値

前節の結果を踏まえ, 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. 提案回路網は, 不応しきい値 θ_{inact} を回路網の活動度に応じて適応的に変化させることを特徴とする. 回路網の活動度

$$\gamma = \frac{1}{n} \sum_{i=1}^n |x_i(t)| \quad (8)$$

とその目標値 γ_{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 θ_{inact} を増減する. $\theta_{inact}(t)$ は,

$$\tau_{\theta}(\theta_{inact}(t+1) - \theta_{inact}(t)) = \gamma_{tar} - \gamma(t) \quad (9)$$

に基づき変化するものとする. ここで, τ_{θ} は, 不応しきい値の時定数である.

4 数値シミュレーション

同期型の離散時間記憶モデルについて, 提案モデルの数値実験を行なった. 以下, ニューロン数 $n = 1000$ とし, 記憶パターンの 1 つ S^{μ} との方向余弦が $a(X, S^{\mu})$ ($0 < a \leq 1$) であるパターン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常に 0.99 以上の場合に想起成功とした. 回路網の活動度の目標値を $\gamma_{tar} = 0.835$ とした.

まず, 不応期の期間 T を変えて提案モデルの想起能力を調べたが, 不応期の期間 T は想起能力には影響しないことがわかった. したがって, 回路網の収束を保証する $T = \infty$ の提案モデルは, 回路網の

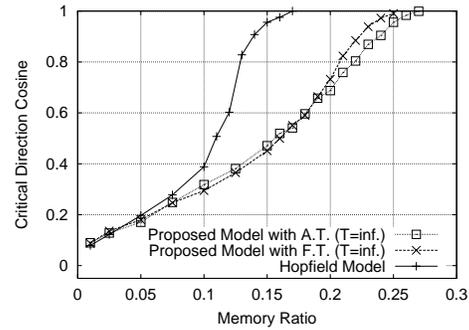


図 2: 動的な不応しきい値と固定な不応しきい値をもつ回路網の想起能力の比較 (離散時間モデル)

収束を保証しない他のいかなる不応期間をもつ提案モデルと同等の能力を持つ.

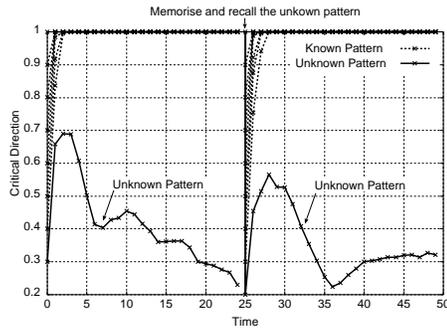
つぎに, 動的な不応しきい値 (A.T.) をもつ記憶モデルと固定的な不応しきい値 (F.T.) をもつ記憶モデルの想起能力を比較し, 図 2 に示す. 提案した不応ニューロンモデルでは, 動的な不応しきい値をもつ記憶モデルが固定的な不応しきい値をもつ記憶モデルよりやや想起能力が高い結果となったが, ほぼ同程度の能力といえる. ただし, 固定型のモデルは, 記憶率に応じてその度に不応しきい値を決定しなければならないが, 一方, 変動型のモデルは, 回路網の活動度を利用して, 自動的に不応しきい値が決定される利点がある.

5 回路網の活動度を利用した逐次学習

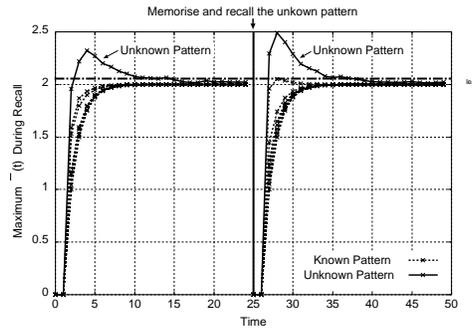
本章では, さらに, 不応期をもつニューロンによる非同期離散時間回路網の逐次学習を提案する. 逐次学習が可能な記憶モデルの場合, 想起中に既知パターンと未知パターンとの判定基準が必要となる. ここでは, 想起過程中の回路網の活動度 $\gamma(t)$ の変化量に注目し, 時刻 t までの回路網の活動度 $\gamma(t)$ の変化量の重み付け和を

$$\bar{\gamma}(t) = \sum_{t'=2}^t \frac{1}{2^{(t-t')}} \frac{1 - \gamma(t')}{1 - \gamma(t'-1)} \quad (10)$$

と定義する. ある想起例における $\bar{\gamma}(t)$ の推移を図 3 に示す. パターンが回路網に入力された後, 既知パターンが入力された場合は, $\bar{\gamma}(t)$ は, 2 に漸近するように増加し, 2 を大きく越えない. 一方, 未知パターンが入力された場合は, 一度 2 を上回った後に 2 に漸近する結果となった. また, 数値実験の



(a) 出力パターンの推移



(b) $\bar{\gamma}$ の推移

図 4: 想起中の出力パターンと $\bar{\gamma}$ の推移 (時刻 $t = 0$ でパターン X ($X|0.3 \leq a(X, S^\mu) \leq 1$) を入力し, 時刻 $t = 24$ で未知パターンと判定されたパターン X' ($X'|a(X', S^\mu) = 0.3$) を追加学習し, 時刻 $t = 25$ でパターン X'' ($X''|0.2 \leq a(X'', X') \leq 1$) を入力した.)

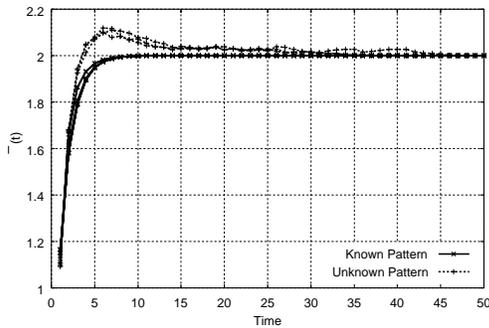


図 3: 想起中の回路網の活動度の変化量と $\bar{\gamma}(t)$

結果から, 既知パターンの入力に対する想起過程での $\bar{\gamma}(t)$ の最大値が, 記憶率に依らず 2 の近傍となることがわかった. したがって, 記憶率の大きさに関わらず, 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,

$$\bar{\gamma}(t) > \theta_{learn} \quad (11)$$

のとき, 入力パターン X を未知パターンと判定する.

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. θ_{learn} は 2.05 とした. 図 4 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, 図 4(a) は想起中の出力パターンを, 図 4(b) は想起中の $\bar{\gamma}(t)$ の値を示すものである. 時刻 $t = 24$ までに未知パターン X' ($X'|a(X', S^\mu) = 0.3$) が正しく検出され, 時刻 $t = 24$ で未知パターン X' が

Hebb 則により学習された. さらに, 時刻 $t = 25$ で未知パターン X' とその類似パターンを回路網に入力すると学習された未知パターン X' が正しく想起されている. さまざまな記憶率による数値実験の結果, 引き込み領域の近傍を除けば, 既知/未知パターンの判定がほぼ 100% 成功した.

6 まとめ

本報告では, 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, 記憶率に依らず, 最適な回路網の活動度に基づき, 不応しきい値が動的に設定される回路網を提案し, 想起能力が向上することを数値実験により確かめた. 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, 未知パターンの逐次学習則を提案し, その有効性を数値実験により示した. 今後の課題として, 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が挙げられる.

参考文献

- [1] Kaoru Nakano: "A Model of Associative Memory", *IEEE Trans. on Systems, Man and Cybernetics*, SMC-2, pp.380-388 (1972)
- [2] 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, J75-D-II, 11, pp.1884-1891 (1992 年 11 月)