G-009

引込み半径の制御が可能な連想記憶モデルとその意義
Associative memory model that can control size of the basin of attraction

千賀 大輔 [1]　**矢内 浩文** [2]
Daisuke Senga　Hiro-Fumi Yanai

1 はじめに

連想記憶の神経回路モデル [1] では, 記憶量と想起の引込み半径が強い関連を持ち, 記憶量が大きいと記憶パターンの引込み半径が小さくなり, 記憶量が小さいと引込み半径が大きくなる [2]. 記憶と大きくかけ離れている大きなノイズが入力された場合であっても, 記憶量が小さい場合には, いずれかの記憶パターンへと想起してしまうのである．これは人の記憶性質として不自然といえる．なぜなら, 人は自分の記憶に無いものについて, “知っていない” ことを自覚できるはずである [3]. 引込み半径が大きいことは記憶装置として重要なことであるが, 過度な大きさの引込み半径は人の記憶性質として望ましくない.

そこで本報告では, 離散型非単調ニューロン [4] を拡張した, 2 段ダイナミクスニューロンからなる相関学習型自己連想記憶モデル [5] を用いることで引込み半径の制御可能性を調べる．非単調ニューロンとは内部状態と出力の関係が非単調となっている応答関数がダイナミクスに組込まれたモデルである．今回は, シナプス結合荷重行列の対角成分, 即ち自己結合荷重を可変パラメータとしてシミュレーションを行った．その結果, 自己結合荷重を調整することで, 引込み半径の大きさを制御することができた.

2 モデルの定式化

連想記憶モデルのニューロン数を n 個, i 番目のニューロンの状態 (± 1) を x_i とし, モデルの状態を$\boldsymbol{x} = (x_1, x_2, \cdots, x_i, \cdots, x_n)^T$ と表す．さらに, m 個の記憶パターン $\xi^\mu (\mu = 1, 2, 3, \cdots, m)$ を記憶させた際の, j 番目と i 番目のニューロンを結ぶ結合荷重 w_{ij} を成分とする $n \times n$ 行列を$\boldsymbol{W}$とすると, 時刻 t から $t+1$ への素子の更新は以下のダイナミクスに従う.

$$\begin{cases} \boldsymbol{u} = \boldsymbol{W}\boldsymbol{x}_t \\ \tilde{\boldsymbol{u}} = \boldsymbol{u} + \boldsymbol{W} f(\boldsymbol{u}) \\ \boldsymbol{x}_{t+1} = \mathrm{sgn}(\tilde{\boldsymbol{u}}) \end{cases} \tag{1}$$

式 (1) のダイナミクスを持つモデルにおいて, $\boldsymbol{W}$の対角成分が 0, かつ記憶負荷率 $r = m/n$ が大きくない場合, 応答関数を $f(u) = -au - (1-2a)\mathrm{sgn}(u)$, ただし $a > 0$ とすることで, $f(u)$ が最適条件式となり引込み半径が大きくなることが知られている [5]. 特に $a = 1/2$ とすることで, 線形な応答関数を用いたダイナミクスは, 直交射影行列を, 擬似逆行列を用いたノイマン展開の第 2 項までで近似した行列を用いたものに等しくなる．つまり, 以下の式 (2) で $\tau = 1, \alpha = 0.5$ とおいた場合となる．そこで本報告では, 式 (2) で $\tau = 5, \alpha = 0.5$ とおいてシミュレーションを行った.

$$\begin{cases} \boldsymbol{u}_t = \boldsymbol{W}\boldsymbol{x}_t \\ \tilde{\boldsymbol{u}}_t^{(\tau)} = \sum_{k=0}^{\tau} (I - \alpha \boldsymbol{W})^k \alpha \boldsymbol{u}_t \\ \boldsymbol{x}_{t+1} = \mathrm{sgn}\left(\tilde{\boldsymbol{u}}_t^{(\tau)} - \boldsymbol{w}\boldsymbol{x}_t\right) \end{cases} \tag{2}$$

$$w_{ij} = \begin{cases} \frac{1}{n} \sum_{\mu=1}^{m} \xi_i^\mu \xi_j^\mu & (i \neq j) \\ \beta r & (i = j) \end{cases} \tag{3}$$

このとき I は単位行列, $\boldsymbol{w}$ は自己結合荷重行列, α は定数である．ただし, 自己結合荷重 w_{ii} には重みとして β を与える.

また, 現在のモデルの状態の指標として類似度を用いる．時刻 t における状態パターン$\boldsymbol{x}$と, ある記憶パターン$\boldsymbol{\xi}^\mu$ の方向余弦を類似度と定義する.

$$l_t = \frac{1}{n} \sum_{i=1}^{n} \xi_i^\mu x_i(t) \tag{4}$$

l_t は $-1 \leq l_t \leq 1$ の値を取り, $l_t = 1$ の場合, 時刻 t において$\boldsymbol{x}$と$\boldsymbol{\xi}^\mu$ は完全に一致している．さらに, $l_t \simeq 1 (t \to \infty)$ となるような l_0(初期類似度) の最小値を引込み閾 l_{th}, 引込み閾の場合のモデルの状態と記憶パターンの距離を引込み半径 d_{th} と呼ぶ．引込み閾と引込み半径は $d_{th} = (1 - l_{th})/2$ の関係を持つ.

3 シミュレーション

シミュレーションの条件として $n = 500$, $\tau = 5$, $\alpha = 0.5$ とした．また, 記憶させるパターン数を $5 \leq m \leq 500$ (記憶負荷率は $0.01 \leq r \leq 1.00$), パラメータ β を $0 \leq \beta \leq 1.0$ の間で共に 0.01 ずつ変化させ, それぞれの記憶量と自己結合荷重の下で, 元の記憶パターンとの初期類似度が $0 \leq l_0 \leq 1.0$ となるようなノイズ入り信号を入力した．図 1 は $m = 150$ の場合における引込み閾とパラメータ β の関係である．この範囲では, β が大

[1]茨城大学大学院 理工学研究科 メディア通信工学専攻
[2]茨城大学 工学部 メディア通信工学科

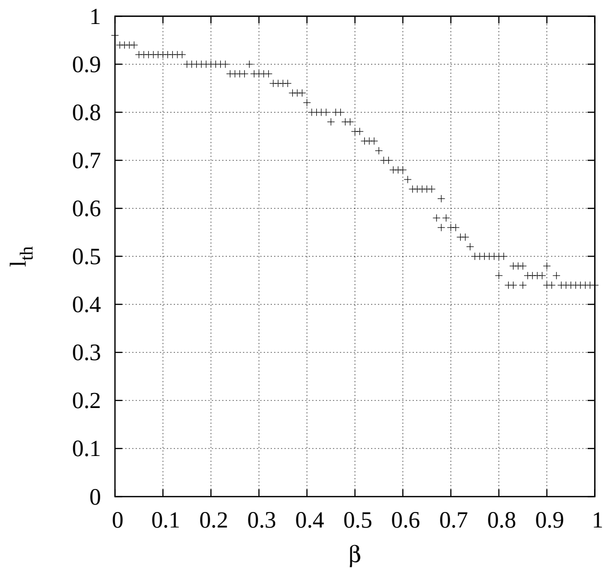

図 1: 素子数 500, 記憶パターン数 150, $\alpha = 0.5$, $\tau = 5$ の場合の引込み閾とパラメータ β の関係.

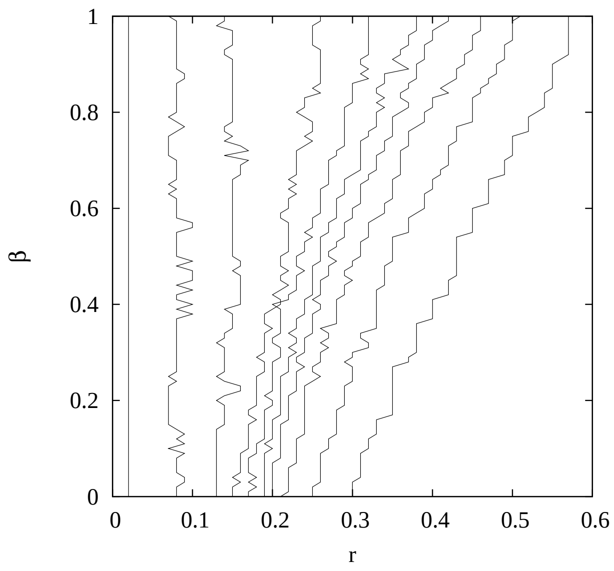

図 2: パラメータ β と記憶負荷率に対する引込み閾の等高線. 等高線は左から引込み閾が $0.1, 0.2, 0.3, \cdots, 1.0$.

きくなるにつれ, 引込み半径が大きくなることが確認できる. 図 2 は, パラメータ β と記憶負荷率に対する引込み閾の等高線である. 記憶負荷率が $0 \leq r \leq 0.57$ の場合に, 同一の記憶負荷率下でパラメータ β が大きくなるにつれ, 引込み半径が大きくなる.

4 まとめ

パラメータ β が 0 から 1.0 の範囲において, パラメータ β に応じて引込み半径が連続的に変化することが分かった. これにより, モデルに記憶させる記憶量に対して適切な自己結合荷重を設定する事で, 引込み半径を制御する事が可能である. 特に, 引込み閾 $l_{th} \simeq 1$ となるようなパラメータを設定することで, 入力された情報が予め記憶した情報と一致していなければ, 別の状態へと変化する性質が得られる. つまり, モデルの状態の変化を確認するだけで, 記憶した情報を参照せずに入力信号と記憶した情報が一致しているかどうかを判断することができるのである. このことから, ここに提案した連想記憶モデルは, 連想と同時に一致検出の性質を備えており, 記憶した情報全てを参照せずとも, 提示された情報を “知っていないと自覚” することが出来る.

参考文献

[1] Hopfield, J. J. , “Neural networks and physical systems with emergent collective computational abilities”, *Proc. Natl. Acad. Sci. USA*, **79**, 2554–2558 (1982)

[2] Amari. S. and Maginu. K. , “Statistical neurodynamics of associative memory” *Neural Networks*, **1**, 63–73 (1988)

[3] 伊達 章, 山本 浩史 “想起の成否が容易に判別できる Hopfield 2008 連想記憶モデルの簡略化”, 電子情報通信学会技術研究報告, NC, 108(480), 399–404 (2009)

[4] Morita, M. , “Associative memory with non-monotone dynamics”, *Neural Networks*, **6**, 115–126 (1993)

[5] Yanai, H. -F. and Amari, S. , “Auto-associative memory with two-stage dynamics of non-monotonic neurons”, *IEEE Transactions on Neural Networks*, **7**, 803–815 (1996)