

部分反転法を用いたリカレントネットワークの動作解析

大槻昭馬¹ 岡田真人² 原一之¹

東京都立工業高専¹ 理化学研究所 BSI²

1. はじめに

森田らによって提案された部分反転法[1]は，出力関数を従来の符号関数から，その出力の一部を反転したものに変更したモデルである．この変更により，離散同期モデルでは従来，約 $0.14N$ であった記憶容量を約 $0.24N$ にまで改善できるとしている．掛谷・岡田らは離散時間同期型の部分反転法の神経統計力学を求め，S/N 解析である SCSNA の結果と比較した[2]．彼らはオーバーラップを用いてその記憶容量，引き込み領域などを解析している．我々は，部分反転法が出力を反転する閾値をユニットの入力ポテンシャルとしている点に注目し，その分布を調べることにより，部分反転法の効果を明らかにする．

2. 部分反転法

リカレントネットワークは層構造を持たないネットワークであり，ユニットは相互に結合していることから，フィードバックループを持つ．結合荷重行列は次式で与えられる．

$$J_{ij} = \frac{1}{N} \sum_{\mu=1}^P \xi_i^{\mu} \xi_j^{\mu} \quad (1)$$

ただし ξ_j^{μ} は記憶パターン，自己結合は $J_{ii}=0$ とする．

本論文では離散時間非同期形について議論する．非同期モデルではユニット数を N とするとある離散時刻に 1 個のユニットが選ばれ，その入力ポテンシャルに応じて出力が決定される．時刻 t に選ばれたユニットの番号を i とすると，時刻 $t+1$ における状態 $S_i(t+1)$ は

$$S_i(t+1) = \text{sgn}\left(\sum_{j=1}^N J_{ij} S_j(t)\right) = \text{sgn}(u_i) \quad (2)$$

で与えられる．ここで $\text{sgn}(u)$ は $u > 0$ なら 1 を， $u < 0$ なら -1 を返す符号関数である．部分反転法とは符号関数の代わりに以下の関数を用いたモデルである．

$$S_i(t+1) = \text{sgn}(u_i): \quad \text{if } -h < u_i < h \quad (3)$$

$$S_i(t+1) = -\text{sgn}(u_i): \quad \text{if } |u_i| > h \quad (4)$$

文献[1]および[2]では $h=1.5$ としているので，本論文でも同じ値を用いる．

3. 入力ポテンシャルによる解析

式(2)の u_i を入力ポテンシャルと呼ぶ．

記憶パターンが 1 個の場合，記憶パターン $\xi_j = \{1, -1\}$ ，初期状態 $S(0)$ を記憶パターンとした場合，式(1)，(2)より，時刻 $t=1$ の入力ポテンシャルは記憶パターン ξ_i となる．

$$u_i(1) = \sum_{j=1}^N J_{ij} S_j(0) = \frac{\sum_{j=1}^N \xi_i \xi_j \xi_j}{N} = \xi_i \quad (5)$$

ここで $\xi_j^2=1$ を使った．

一方，記憶パターンが 2 個ある場合，結合荷重は式(1)より

$$J_{ij} = \frac{1}{N} (\xi_i^1 \xi_j^1 + \xi_i^2 \xi_j^2) \quad (6)$$

となる．したがって入力ポテンシャルは

$$u_i(1) = \frac{\sum_{j=1}^N \xi_i^1 x_j^1 x_j^1 + \xi_i^2 \xi_j^2 \xi_j^1}{N} = \xi_i^1 + \Delta_i \quad (7)$$

$$\Delta_i = \frac{\sum_{j=1}^N \xi_i^2 \xi_j^2 \xi_j^1}{N} \quad (8)$$

となり， ξ_i^1 からずれる．式(8)は想起を妨害

するためノイズ成分でと呼ばれ，この分散が想

Analysis of associate memory using partial inverse method
Shoma Ohtsuki¹, Masato Okada², Kazuyuki Hara¹

¹ Tokyo Metropolitan College of Technology

² Brain Science Institute, Riken

起できるか否かを決定する。

ユニット数 1000,パターン数 240 でネットワークを動作させずに入力ポテンシャルの分布を調べた結果を図 1 に示す。この場合, ホップフィールドモデルでは記憶したパターンを正しく想起できないことが知られている。図のように, パターン数が増えるに従って, 入力ポテンシャルの分散が大きくなった。

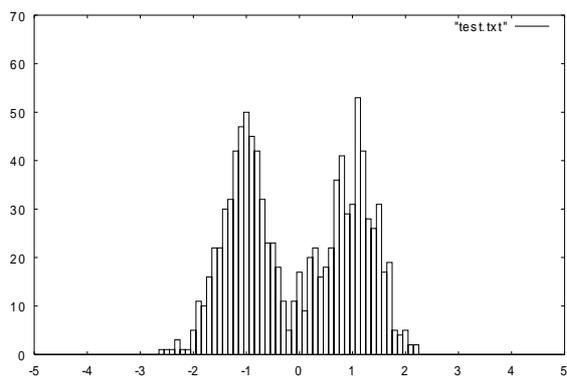


図 1 記憶パターン数 240 のときの入力分布

4. 結果

ユニット数 1000, 記憶パターン数 240 で, 図 1 を初期状態として 10000 回動作させた時の入力分布を図 2, 図 3 に示す。初期状態から動作させた結果である。横軸は入力ポテンシャル、縦軸はユニット数である。その結果, 部分反転法のオーバーラップは 0.91, ホップフィールドモデルのオーバーラップは 0.516 となった。

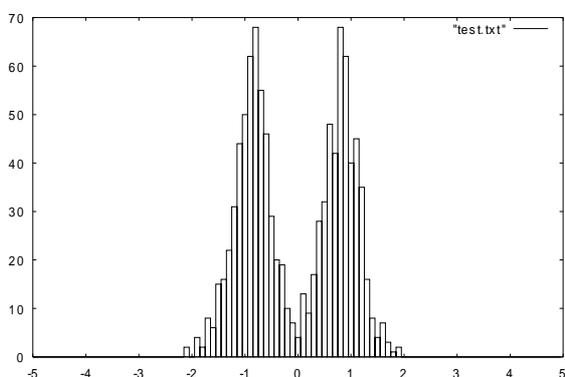


図 2 部分反転法の入力分布

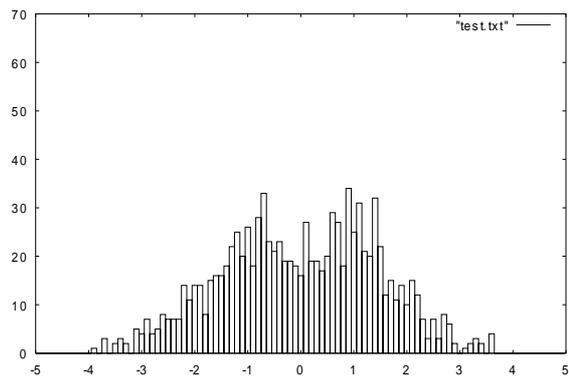


図 3 ホップフィールドの入力分布

図 2 の部分反転法は全ユニットの入力ポテンシャルが 1, -1 付近に集中しているという特徴が見受けられるのに対し, 図 3 のホップフィールドモデルは分散が大きくなっている。

次に, 入力ポテンシャルが閾値 h を超えるユニットのみを選択して状態更新を行った場合の入力ポテンシャルの分布を前例と同じ条件で調べた。結果を図 4 に示す。

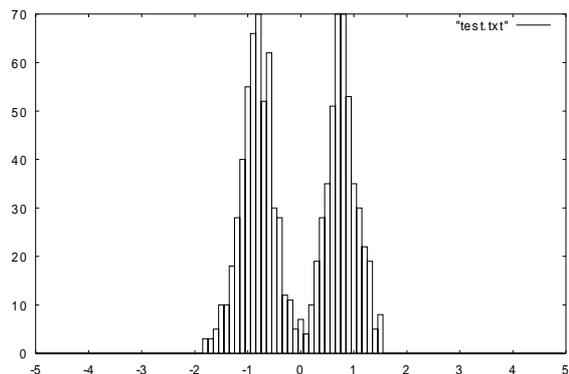


図 4 閾値を超えるユニットのみ状態更新

図 4 は図 2 の分布に類似しているが, 入力ポテンシャルの分散は小さくなった。これらの結果から部分反転法を用いることで, 入力ポテンシャルの分散が小さくなり, 結果として記憶の想起につながっていると予想される。

参考文献

[1] Morita M, "Associate Memory with non-monotone dynamics", Neural Networks, 6, pp. 115

(1993).

[2] 掛谷, 岡田, 岡部, "部分反転法の統計神経力学", 信学技報 NC96-127, pp. 111 (1997).