線形不等式の求解による動的連想メモリの性能改善

非会員 朴 正 泌 (神戸大学大学院自然科学研究科)

正 員 小 澤 誠 一 (神戸大学大学院自然科学研究科)

正 員 阿 部 重 夫 (神戸大学大学院自然科学研究科)

Performance Improvement of Dynamical Associative Memories by Solving Linear Inequalities

Jungpil Park, Non-member, Seiichi Ozawa, Member, Shigeo Abe, Member (Graduate School of Science and Technology, Kobe University)

A main problem with dynamical associative memories (DAMs) is that when memory patterns are stored, pseudo-memories (false fixed points and limit cycles) are also generated and they hinder proper association of input patterns. To overcome this problem, Hassoun proposed a heuristic method of reducing pseudo-memories. In this method, DAMs are constructed such that a zero vector called "ground state" as well as stored patterns is stabilized and sparsely activated states (sparse patterns) converge to the ground state. Such dynamical properties of neural networks can be described with linear inequalities, and connection weights of networks are obtained by solving these inequalities using the Ho-Kashyap algorithm. In this paper, we propose an extended Hassoun model in which network dynamics are modified such that dense patterns, mixture patterns and inhibition patterns are also converged to the ground state. In simulations, we compare association performance of this extended Hassoun model with conventional associative memory models, and demonstrate the usefulness of our proposed model as a dynamical associative memory.

キーワード：連想メモリ，偽メモリ，ニューラルネット，線形不等式，Ho-Kashyap アルゴリズム

1. はじめに

ニューロン間が相互結合されたニューラルネットに対し、Hopfield はエネルギーが時間と共に減少するようにネットワークの動特性を定義する方法を提案した。また、ネットワークの不動点を記憶パターンに対応させることで、幾つか記憶されたパターンの中から検索キーに応じて1つのパターンを取り出す連想メモリに利用できることを示した⁽¹⁾。これ以後、ネットワークダイナミクスを利用したニューラル連想メモリ (以後、動的連想メモリと呼ぶ) はニューラルネットの重要な研究対象となり、動作や学習に対する数々のアルゴリズムが提案されている^{(2)~(5)}。

動的連想メモリは Hopfield ネットなどフィードバック結合をもつリカレント型ニューラルネットで構成され、その状態はあらかじめ定められたダイナミクスに従って変化する。特に離散時間型ダイナミクスをもった自己想起型連想メモリの場合、状態は不動点またはリミットサイクルに引き込まれることが知られている⁽⁴⁾。通常、一つの記憶パターンを一つの不動点に対応づけて連想メモリを実現するため、リミットサイクル (以後、振動メモリと呼ぶ) を想起することは望ましくない。また不動点に収束したとして

も、それが記憶パターンに必ず一致するわけではなく、記憶パターンでない「偽の不動点」が生成されることも多い。このような偽の不動点および振動メモリは、本来記憶したいメモリでないという意味で「偽メモリ」とよばれ、これらを抑制する数々の手法がこれまで提案されている^{(6)~(9)}。

Hassoun は線形不等式を解く Ho-Kashyap アルゴリズム⁽¹⁰⁾を連想メモリの学習に適用して偽メモリを抑制する方法を提案している⁽¹¹⁾⁽¹²⁾。このアプローチでは、ネットワークが記憶パターン上で安定化される条件を不等式で記述し、それを解くことでニューラルネットの結合荷重が求められる。また Hassoun は、1ビットのみ '1' で残りがすべて '0' であるパターン (以後、疎パターンと呼ぶ) をすべてのビットが '0' のパターン (これをグラウンドパターンと呼ぶ) に収束させて偽メモリを抑制する方法を提案している⁽³⁾⁽¹¹⁾。これは、記憶パターンが疎パターンとなることが稀であるため、これらを不安定化することで偽メモリを抑制できると期待したものである。ただし、一般に Ho-Kashyap アルゴリズムで得られる結合荷重は対称行列ではなく、ネットワークに漸近安定性が保証されるわけではない。つまり振動メモリも生成される可能性があるが、上述の疎パターン

の不安定化によって、経験的には生成されないことが報告されている⁽³⁾。Hassounは偽メモリの抑制に疎パターンの不安定化を行ったが、実際には記憶パターンの論理和も偽メモリとなり得る。そこで、これらを不安定化させることで、偽メモリをさらに抑制できる可能性がある。

本論文では、Ho-Kashyap アルゴリズムに基づいた線形不等式の求解により、自己想起型連想メモリにおいて偽メモリを抑制する方法を提案する。またシミュレーション実験を通して、提案モデルにおける偽メモリの抑制効果について調べる。

2. 動的連想メモリの構成

〈2・1〉 線形不等式による安定化条件の記述 図1(a)に自己想起型の動的連想メモリの構成をブロック図で示し、点線部の詳細を図1(b)に示す。動的連想メモリはフィードバック結合をもつリカレント型ニューラルネット構成され、その出力が記憶パターンに等しくなったとき安定となるよう結合荷重の学習を行う。いま、時刻 k におけるフィードバック信号 ($k = 0$ のときは外部からの初期入力) に閾値用の入力 (常に 1) を加えたものを $\mathbf{x}(k) = \{x_1(k), \dots, x_n(k), 1\}'$ とし、これを連想メモリの入力とする。ここで l は行列およびベクトルの転置を表す。入出力間の結合行列を $\mathbf{W} = \{\mathbf{w}_1', \dots, \mathbf{w}_n'\}'$, $\mathbf{w}_i = \{w_{i1}, \dots, w_{i,n+1}\}$ で表したとき、入力 $\mathbf{x}(k)$ に対する出力 $\mathbf{y}(k) = \{y_1(k), \dots, y_n(k)\}'$ は次式で与えられる。

$$y_i(k+1) = f(\mathbf{w}_i \mathbf{x}(k)) = f\left(\sum_{j=1}^n w_{ij} x_j(k)\right) \quad (1)$$

$$\mathbf{x}(k+1) = \{\mathbf{y}(k+1)', 1\}' \quad (2)$$

ただし、ニューロンの出力関数 $f(u)$ は次式で与えられる。

図 1 動的連想メモリの構成。(a) ブロック図。(b) ネットワーク結合。

Fig.1. Architecture of a dynamical associative memory. (a)block diagram. (b)network connections.

$$f(u) = \begin{cases} 1 & : u \geq 0 \\ 0 & : \text{otherwise} \end{cases} \quad (3)$$

動的連想メモリでは、初期状態 $\mathbf{x}(0)$ を外部から与えて (1),(2) 式に基づいて出力を繰り返し求める。この出力が安定して定常状態になったとき、一回の想起が終了したとする。なお、いつまでも状態が安定しないとき振動メモリを想起したとする。ネットワークの安定平衡状態は不動点と呼ばれ、これが M 個の記憶パターン $\mathbf{p}^\mu = \{p_1^\mu, \dots, p_n^\mu\}'$ ($\mu = 1, \dots, M$) のいずれかに等しいとき想起が成功したとする。これより、状態が記憶パターンで安定であるためには、以下の等式がすべての μ に対して成り立つ必要がある。

$$p_i^\mu = f(\mathbf{w}_i \mathbf{x}^\mu) \quad (i = 1, \dots, n; \mu = 1, \dots, M) \quad (4)$$

ただし、 $\mathbf{x}^\mu = (\mathbf{p}^\mu, 1)'$ である。(3) 式から、この関係を不等式で表すと以下になる。

$$p_i^\mu = 1 \text{ に対して } \mathbf{w}_i \mathbf{x}^\mu \geq 0 \quad (5)$$

$$p_i^\mu = 0 \text{ に対して } \mathbf{w}_i \mathbf{x}^\mu < 0 \quad (6)$$

これらの不等式を満たす結合荷重 $\mathbf{w}_i$ ($i = 1, \dots, n$) を求めればよいが、簡単のため以下の不等式に置き換えて求めることにする。

$$(2p_i^\mu - 1)\mathbf{w}_i \mathbf{x}^\mu > 0 \quad (\mu = 1, \dots, M) \quad (7)$$

(7) 式を満たす $\mathbf{w}_i$ は (5), (6) 式も同時に満たすことに注意する。したがって、 M 個の記憶パターン $\{\mathbf{p}^1, \dots, \mathbf{p}^M\}$ をすべて記憶するためには次の不等式を満足すればよい。

$$\mathbf{A}_i \mathbf{w}_i' > \mathbf{0} \quad (i = 1, \dots, n) \quad (8)$$

ここで $\mathbf{0}$ は M 次の零ベクトル、 $\mathbf{A}_i$ は以下の $M \times (n+1)$ 行列で与えられる。

$$\mathbf{A}_i = \{(2p_i^1 - 1)\mathbf{x}^1, \dots, (2p_i^M - 1)\mathbf{x}^M\}' \quad (9)$$

(8) 式の不等式は等式化することで、次項の Ho-Kashyap アルゴリズムより結合荷重 $\mathbf{w}_i$ を求めることができる。

〈2・2〉 Ho-Kashyap アルゴリズムによる結合荷重の決定 まず、全ての要素が正である任意のマージンベクトル $\mathbf{b}_i$ を導入して、(8) 式を等式 $\mathbf{A}_i \mathbf{w}_i' = \mathbf{b}_i$ に変換する。この等式が満たされるためには二乗誤差 $(\mathbf{b}_i - \mathbf{A}_i \mathbf{w}_i')'(\mathbf{b}_i - \mathbf{A}_i \mathbf{w}_i')$ が最小化されればよいので、これを目的関数として最急降下法を適用する。これによって導出された $\mathbf{w}_i$ と $\mathbf{b}_i$ の求解アルゴリズムは Ho-Kashyap アルゴリズムと呼ばれる⁽¹⁰⁾。このアルゴリズムでは、 $\mathbf{b}_i$ の各要素に対する修正量が負とならないようにすれば、(8) 式の解が有限回の繰り返して得られることがわかっている。

Ho-Kashyap アルゴリズムを用いた結合荷重の修正手順は以下の通りである。

- (1) $i = 1$ とする。
- (2) $\mathbf{A}_i^+ = (\mathbf{A}_i' \mathbf{A}_i)^{-1} \mathbf{A}_i'$ として、Moore-Penrose の

擬似逆行列 A_i^+ を求める。ここで $A_i' A_i$ が特異でその逆行列が求まらないときは、特異値分解⁽¹³⁾により求めた擬似逆行列 $(A_i' A_i)^+$ を用いる。

- (3) $b_i(0) > 0$ を満たすよう適当に初期値を設定し、 $w_i(0) = A_i^+ b_i(0)$ から解ベクトル w_i の初期値を求める。 k を反復回数とし、 $k = 0$ とする。
- (4) $e(k) = A_i w_i'(k) - b_i(k)$ で誤差ベクトル $e(k)$ を求め、 $e(k) = 0$ または $e(k)$ の全ての要素が負となればステップ(7)へ。そうでなければ次へ進む。
- (5) $b_i(k+1) = b_i(k) + \rho(e_i(k) + |e_i(k)|)$ にしたがってマージンベクトルを更新する。ただし、 $|e_i(k)|$ は $e_i(k)$ の各要素に絶対値をとることを示し、 ρ は $0 < \rho < 1$ を満たす正定数である。これからわかるように、マージンベクトルは、誤差が正である要素に対してのみ修正量を与えられる。
- (6) $w_i(k+1) = A^+ b_i(k+1)$ により結合荷重を修正し、 $k = k+1$ としてステップ(4)に戻る。
- (7) $i < n$ であれば $i = i+1$ としてステップ(2)へ戻る。そうでなければ終了する。

3. 連想性能の改善方法

〈3・1〉 偽メモリの生成メカニズム 前節では、ネットワークの状態が記憶パターンで安定化される条件を不等式で記述し、その解を求めることで動的連想メモリを構成した。しかし、このとき記憶パターン以外の不動点やリミットサイクルなどのアトラクタも形成されることが多く、これは偽メモリの生成につながる。偽メモリの生成メカニズムについて、簡単な例を通して以下で考察する。

いま2つの2次元記憶パターン $(1, 1)$, $(1, 0)$ を考える。(7)式より、これらが不動点となるためには、結合荷重は

$$\begin{aligned} w_{11} + w_{12} + w_{13} &> 0 \\ w_{21} + w_{22} + w_{23} &> 0 \\ w_{11} + w_{13} &> 0 \\ -w_{21} - w_{23} &> 0 \end{aligned}$$

を満たす必要がある。いま簡単のため $w_{13} = w_{23} = 1$ を仮定すると、記憶パターン $(1, 1)$, $(1, 0)$ で安定化される結合荷重は、図2 灰色部の任意の点で表される。ここで記憶パターンではない $(0, 1)$ が安定化される領域を求め、これと先に求めた2つの記憶パターンが安定化される領域との重複領域を図2の斜線部で表す。この斜線部では、2つの記憶パターンだけでなく記憶パターンではない $(0, 1)$ も同時に安定化される。よって、結合荷重 w_{11} , w_{12} , w_{21} , w_{22} のすべてがこの領域にあるとき $(0, 1)$ は偽メモリとなる。

前述の Ho-Kashyap アルゴリズムによって上記の不等式を満足する結合荷重が一つ求められるが、図2の灰色部におけるどの点が解として得られるかは、与えられた結合荷重やマージンベクトルの初期値に依存する。つまり、 $(0, 1)$ が

図2 不等式の解領域。灰色部は $(1, 1)$, $(1, 0)$ を記憶パターンとするときの (a) w_{11} と w_{12} , (b) w_{21} と w_{22} の解領域を表す。斜線部は $(0, 1)$ が記憶パターンとともに安定化される解領域を表す。

Fig.2. Solution areas of linear inequalities. Shaded regions correspond to solution areas of (a) w_{11} and w_{12} , (b) w_{21} and w_{22} , when memory patterns are $(1, 1)$ and $(1, 0)$. Diagonal regions correspond to solution areas where $(0, 1)$ are stabilized as well as two stored memories.

安定にならない領域[†]が求まるよう、 $(0, 1)$ の不安定化条件を考慮して解を求めない限り、偽メモリが生成される可能性は残る。振動メモリについても同様のことがいえる。つまり記憶パターン以外の2点がともに不安定となり、互いを想起するような結合荷重の領域で学習アルゴリズムが停止したとき、記憶パターンおよび振動メモリを想起する動的連想メモリが構成されてしまう。

これら偽メモリの生成を抑制する最も単純な方法は、記憶パターンを安定化するだけでなく、記憶パターン以外のパターンを不安定化する条件を不等式で記述し、その解を求めることである。上記の例のように記憶パターンの次元数が小さいときは、この方法で偽メモリが生成されないようにすることは比較的容易である。しかし次元数が高い一般的なケースでは、偽メモリになり得るパターンは記憶パターン数に比べてはるかに多いため、この方法は現実的でない。そこで、Hassoun は偽メモリのすべてを不安定化させるのではなく、記憶パターンとは大きく異なるいくつかの状態を不安定化してすべての要素が '0' の状態 (グランド状態と呼ぶ) に収束させる方法を提案している。これについて

[†] w_{11} , w_{12} , w_{21} , w_{22} のすべてが図2の斜線部に入らなければ、 $(0, 1)$ は偽メモリにならない。よって、このケースでは w_{11} , w_{12} が図2(a)における斜線部以外の灰色部にあればよい。

図3 記憶パターンと不安定化パターンの分布図。縦軸はグランドパターンからの距離を表している。細字の×および○は記憶パターンとそれらの吸引領域、太字の×は不安定化パターンを表す。
Fig. 3. Distribution of stored patterns and unstable patterns. Vertical axis means Hamming distance from the ground pattern. Fine crosses and circles correspond to stored patterns and their basins of attractions, respectively. Thick crosses represent unstable patterns.

次項で簡単に述べた後、Hassounの手法を拡張して連想能力を向上する方法を提案する。

〈3・2〉拡張Hassounモデル 第1節で既に述べたが、Hassounは連想能力を向上する方法として l ($1 \leq l \leq n$) 番目の要素のみが'1'で、その他が'0'である疎パターン $p_s^l = (0, \dots, 0, 1, 0, \dots, 0)$ をグランドパターン p_g に収束させる方法を提案している。これはニューラルネットの入出力間に $p_s^l \rightarrow p_g$ という写像を成り立たせることで実現できる。つまり(6)式より、以下の不等式を満足すればよい。

$$w_i x_s^l < 0 \quad (i = 1, \dots, n; l = 1, \dots, n) \quad \dots \dots (10)$$

ただし、 $x_s^l = (p_s^l, 1)'$ である。

この方法によって連想性能が向上する理由は、図3を用いて定性的に説明できる。図3は、記憶パターンの分布とその距離関係を概念的に表したものであり、グランドパターン p_g からのハミング距離(すなわちパターン中の'1'の数)を縦軸としている。つまり、上にいけばいくほどグランドパターンから離れ、パターン中の'1'の数が増える。また横軸方向は、同一のハミング距離をもつパターンの分布を表している。図3における細字の×は記憶パターン、○はその吸引領域を一例として示している。またAおよびCはパターンの要素に'1'が多い領域と少ない領域であり、Bはその中間領域を表している。文字など通常よく用いられる記憶パターンはBに存在することが多く、その場合、AまたはCの大部分は偽メモリが存在する領域と考えられる。Hassounが用いた疎パターンはCの底辺部分にあるパターンに相当し(太字の×で表している)、これらを不安定化することでCの領域にグランドパターンを不動点とする吸引領域(図3斜線部、 Ω_g で表記)が形成される。このようなアトラクタによる引き込み効果が、Hassounの手法による連想性能の向上につながったものと考えられる。

しかしながら、偽メモリはCのみに存在しているわけではなく、一般にAやBの領域にも存在する。そこで、Aの領域やBで記憶パターンへの吸引領域に重複しない領域、つまり記憶パターンから十分離れた領域を Ω_g とすることで、連想性能をさらに向上できる可能性がある。Aに Ω_g を形成する一つの方法には、すべての要素が'1'であるパターン p_d (密パターンと呼ぶ、図3上部にある太字の×)を不安定化することが考えられる。つまり、写像 $p_d \rightarrow p_g$ が成り立つための条件を以下の不等式で記述すればよい。

$$w_i x_d < 0 \quad (i = 1, \dots, n) \quad \dots \dots \dots (11)$$

ただし、 $x_d = (p_d, 1)'$ である。

次にBの領域に対してであるが、ここで生成する Ω_g は記憶パターンの吸引領域になるべく重複しないようにする必要がある。しかし、記憶パターンの吸引領域がどの程度の大きさをもつかかわらないことが多く、 Ω_g の中心位置やその大きさを最適に決定することは非常に困難である。そこで、試行錯誤的に見出された以下の手順により、 Ω_g の中心位置に相当する点 q^k を求めることにした。

Step 1 記憶パターン p^μ ($\mu = 1, \dots, M$)と p^ν ($\nu \neq \mu; \nu = 1, \dots, M$)とのハミング距離 $d_1^{\mu\nu}$ を求め、次式で与えられる記憶パターン間の平均ハミング距離 $\bar{d}$ を求める。

$$\bar{d} = \frac{1}{M} \sum_{\mu=1}^M \max_{\nu \neq \mu} \{d_1^{\mu\nu}\}$$

Step 2 $d_1^{\mu\nu} \geq \bar{d}$ となる記憶パターン対 (p^{μ_k}, p^{ν_k}) ($k = 1, \dots, K$)を求め、その個数を K とする。

Step 3 Step 2で求めた記憶パターン対から次式で求められる混合パターンを q^k とする。

$$q^k = p^{\mu_k} + p^{\nu_k} \quad (k = 1, \dots, K)$$

ここで+は論理和を表す。

Step 4 Step 3で求めた混合パターン q^k ($k = 1, \dots, K$)と q^l ($l \neq k; l = 1, \dots, K$)のハミング距離 d_2^{kl} を求め、 $d_2^{kl} \geq \bar{d}$ となる q^k, q^l を探す。これらのうち記憶パターン p^μ ($\mu = 1, \dots, M$)とのハミング距離が $\bar{d}/2$ 以上のものを不安定化する[†](図3中央部にある太字の×)。

Step 5 Step 4で不安定化する混合パターンが見つからない場合、 d_2^{kl} が最大となる q^k, q^l のうち、記憶パターン p^μ とのハミング距離の大きい方を不安定化する。

[†]ここで $\bar{d}/2$ 以上とするのは、混合パターンとそれを生成した2つの記憶パターンとの距離が、記憶パターンどうしの距離や混合パターンどうしの距離のほぼ半分程度になるためである。

ここで Ω_g の中心位置として混合パターンが用いられるのは、複数の記憶パターンの論理和をとったパターンが偽メモリになるという知見に基づいている⁽⁴⁾。

最後に連想能力の改善方法をもう一つ取り上げる。与えられた記憶パターンセットによっては、常に'0'となる要素(以下ではゼロ要素と呼ぶ)が存在するときがある。この場合、このゼロ要素に対応するユニットは常に不活性でなければならない、これらの活性を積極的に抑制することで偽記憶を減らせる可能性がある。個別の記憶パターンを安定化する線形不等式によって、これらゼロ要素の活性は抑制されるはずであるが、ゼロ要素以外の要素がほとんど活性していない状態ではうまく機能しない可能性がある。これは例えば、不安定化点をグランドパターンに収束させる過程で、活性しているユニットの数が少なくなったときに生じやすい。そこでゼロ要素の活性を抑制するため、以下で示されるパターン $\bar{q}$ を不安定化する。

$$\bar{q} = \overline{p^1 + p^2 + \cdots + p^M} \cdots \cdots (12)$$

ここで + は論理和、 $\overline{}$ は否定を表す。この $\bar{q}$ を以下では抑制パターンと呼ぶが、これは全記憶パターンの混合パターンを反転したものに对应する。

以上で求められた不安定化点がグランドパターンに収束するよう不等式を導き、記憶パターンを安定化するための不等式とともに解くことで、ニューラルネットの結合荷重が決定される。

4. シミュレーション実験

〈4・1〉 実験方法 評価に用いた 2 種類のパターンを図 4(a) に示す。1 つは 26 個のアルファベット文字パターンで、もう 1 つは 10 個の数字パターンである。ともに 8×8 ピクセルのデータであり、64 次元の 2 値ベクトルで表される。想起開始時に与える初期状態には、記憶パターンからハミング距離 D が 2 (2016 個), 3 (41664 個), 4 (39711 個) だけ離れた状態、つまり D 個のピクセル値を反転した状態を用いる。ただし、() 内は調べた初期状態の個数である。 $D = 2, 3$ では反転するピクセルのすべての組み合わせに対して調べたが、 $D = 4$ では組み合わせ数が膨大とな

図 4 (a) 2 種類の記憶パターン (26 文字のアルファベットと 10 個の数字)。それぞれ 64 次元の 2 値ベクトルで与えられる。(b) 抑制パターン。全パターンの混合パターンを反転して得られる。

Fig. 4. (a) Two types of stored memory patterns (26 alphabets and 10 numerals) given by a 64-dimensional binary vector. (b) Inhibition patterns. These are given by reversing mixture patterns of all stored memories.

表 1 (a) アルファベットと (b) 数字パターンに対する擬似逆行列モデル (PIM) と Hassoun モデル (HM) の想起成功率 [%]

Table 1. Recall accuracy [%] of pseudoinverse model (PIM) and Hassoun model (HM) for (a) alphabet and (b) numeral patterns.

(a) alphabet patterns				
	D = 2	D = 3	D = 4	Ave.
PIM	49.19	31.60	18.91	25.98
HM	97.70	82.17	60.82	72.38

(b) numeral patterns				
	D = 2	D = 3	D = 4	Ave.
PIM	67.69	52.16	13.52	34.13
HM	78.63	64.83	51.03	58.59

るため $D = 3$ のケースとはほぼ同数の初期状態を選択して調べた。比較のため、従来型の動的連想メモリと最近傍連想メモリの性能を調べた。なお動的連想メモリには、結合行列を記憶パターン行列の擬似逆行列から求める方法⁽²⁾と Ho-Kashyap アルゴリズムを用いた Hassoun モデル⁽¹²⁾の 2 種類を採用した。

〈4・2〉 連想性能の評価

〈4・2・1〉 擬似逆行列モデルと Hassoun モデル 擬似逆行列モデルの結合行列 W は、記憶パターン p^μ ($\mu = 1, \cdots, M$) を並べた行列 $A = \{p^1, \cdots, p^M\}$ とその擬似逆行列を用いて、以下で与えられる。

$$W = AA^+ \cdots \cdots (13)$$

擬似逆行列モデルおよび Hassoun モデルの結果を表 1(a)(b) に示す。ここで Ave. は想起成功率の平均値を表している。これらからわかるように、擬似逆行列モデルの連想性能は Hassoun モデルに比べて文字、数字ともに低い。しかし Hassoun モデルにおいても、記憶パターンからのハミング距離 D の増加によって連想性能が著しく劣化している。

〈4・2・2〉 拡張 Hassoun モデル 〈3・2〉では、偽メモリを抑制するために密パターン、混合パターン、そして抑制パターンを不安定化する拡張 Hassoun モデルを提案した。これらを不安定化する効果を調べるため、不安定化するパターンの組み合わせにより以下の 4 つの拡張モデルに対する連想性能を評価する。

- 拡張モデル 1: 密パターンのみ
- 拡張モデル 2: 密パターン + 混合パターン
- 拡張モデル 3: 密パターン + 抑制パターン
- 拡張モデル 4: 密パターン + 混合パターン + 抑制パターン

記憶パターンの安定化条件と疎パターンの不安定化条件に、密パターン、混合パターン、抑制パターンの不安定化条件を追加して線形不等式を導出し、その解を Ho-Kashyap アルゴリズムで求めた。このときマージンベクトル b の初期値はすべて '1' の要素をもつベクトルとした。なお、〈3・2〉のアルゴリズムで実際に生成された混合パターンは、アルファベットパターンの連想において $(A + S)$ と $(J + M)$ 、数字パターンの連想において $(4 + 5)$ であった。ただし、数

字パターンの (4+5) は Step 4 で混合パターンが見つからず、Step 5 で求められたものである。

拡張モデル 1~4(EHM1~EHM4) の連想性能を表 2(a)(b) に示す。Hassoun モデルの結果 (表 1) との比較から、拡張モデル 2 を除いて文字の種類に関係なく連想性能が改善しており、 D の増加にともなう性能劣化の程度も小さくなっているのがわかる。拡張モデル 2 に対する結果は、記憶パターン間に存在する混合パターンを単純に不安定化すると、混合パターンの吸引領域によって記憶パターンの吸引領域が縮小してしまうことを表している。このことは、各パターンごとの想起成功率を調べてみたとき、アルファベットパターンの場合、'J' と 'M' の平均成功率が 32.64% ($D=2$), 22.10% ($D=3$), 18.76% ($D=4$) と他に比べて劣化の程度が著しいことから窺える。また数字パターンに比べてアルファベットパターンの劣化の程度が著しいことから、不安定化させる混合パターンの数が増えるほど連想性能が劣化するようである。この結果だけでは混合パターンの不安定化は効果がないように見えるが、拡張モデル 4 の結果より、混合パターンを抑制パターンと同時に不安定化することで連想性能の改善が行えることがわかる。拡張モデル 3 の結果より、抑制パターンの不安定化だけでは十分な改善が見られないことから、混合パターンと抑制パターンを同時に不安定化することで生じる相乗効果が、記憶パターン間にある偽記憶の抑制に貢献すると考えられる。ただ、アルファベットパターンと数字パターンに対する拡張モデル 1 および 4 の結果を比較すると、数字パターンの方が不安定化の効果が小さいことがわかる。この原因としては、記憶パターン間の平均ハミング距離がアルファベットパターンで 23.9、数字パターンで 19.4 であり、パターン間がより近接しているために混合パターンの不安定化で記憶パターンの吸引領域が小さくなりやすいことが考えられる。

〈4・2・3〉最近傍連想メモリ 最近傍連想メモリ⁽¹⁴⁾は、ハミング距離が最小となる記憶パターンを想起結果とするモデルであり、前の動的連想メモリとは異なりダイナミッ

表 2 (a) アルファベットと (b) 数字パターンに対する拡張 Hassoun モデル (EHM1~EHM4) の想起成功率 [%]

Table 2. Recall accuracy [%] of extended Hassoun models (EHM1~EHM4) for (a) alphabet and (b) numeral patterns.

(a) alphabet patterns				
	D = 2	D = 3	D = 4	Ave.
EHM1	96.61	93.60	86.98	90.52
EHM2	71.83	57.60	44.32	51.62
EHM3	94.88	89.99	80.01	85.36
EHM4	98.87	95.96	89.83	93.11

(b) numeral patterns				
	D = 2	D = 3	D = 4	Ave.
EHM1	93.72	90.70	84.43	87.79
EHM2	87.26	80.88	72.52	77.05
EHM3	93.87	90.21	83.62	87.16
EHM4	93.40	90.55	84.68	87.82

表 3 最近傍連想メモリモデルの想起成功率 [%]

Table 3. Recall accuracy [%] of nearest-neighbor associative memory model

	D = 2	D = 3	D = 4	Ave.
Alphabets	99.94	99.82	99.31	99.58
Numerals	99.86	99.57	98.88	99.25

クスをもたない。最近傍連想メモリにおける想起手順を以下に示す。

- (1) 入力とすべての記憶パターンとのハミング距離を計算する。
- (2) ハミング距離が最小である記憶パターンを求める。
- (3) 2つ以上求められたとき想起不能とし、1つに決まればそれを想起パターンとする。

このモデルでは、複数の記憶パターンと等距離にある状態を除いて、必ず記憶パターンを想起するため偽メモリや振動メモリを生じない。よって前の動的連想メモリの吸引領域に対する上限を与えると考えられ、参考値として表 3 に想起結果を示した。但し、ほぼすべての状態を記憶パターンのいずれかに対応づける性質は、必ずしも連想メモリにとって望ましい性質とはいえないことに注意する。なぜなら記憶パターンからある程度離れた状態は、むしろ想起不能として扱った方がよい場合があるからである。想起不能とすべき領域の設定は、記憶パターン間の相関や状態空間における記憶パターンの位置関係に依存して変わるため、一般に前もって決定することは難しい。Hassoun モデルや提案した拡張 Hassoun モデルでは、少ない不安定化パターンで比較的妥当と思える想起不能領域を簡単に設定できる点で最近傍連想メモリにはない特徴をもっている。

5. おわりに

本研究では、Hassoun によって提案された動的連想メモリを拡張し、その有効性をシミュレーション実験で示した。Hassoun モデルでは、記憶パターンの安定化条件と疎パターン (一つの要素のみが '1' で他が '0' であるパターン) の不安定化条件を線形不等式で記述し、その解を Ho-Kashyap アルゴリズムで求める。本研究では、不安定化される状態として疎パターンだけでなく密パターン (すべての要素が '1' であるパターン) や記憶パターンの混合パターン、そしてゼロ要素 (常に '0' の値をもつ要素) を活性化させないための抑制パターンを追加して偽メモリの抑制を試みた。

文字パターンを用いたシミュレーション実験を行った結果、Hassoun モデルや擬似逆行列モデルなどに比べて偽メモリの生成が抑制され、連想性能が改善することを確認した。ただし混合パターンのみを不安定化したときには、逆に連想性能が著しく劣化した。これは混合パターンの不安定化で生成された吸引領域が記憶パターン間に発生し、記憶パターンの吸引領域を一部不安定化するためと考えられる。しかし、混合パターンと抑制パターンを同時に不安定化した場合、これらを不安定化しなかった場合よりも優れた連想性能が得られた。この原因については今のところよ

くわかっておらず、今後の課題としたい。また、記憶パターン間の相関が高い(距離が小さい)数字パターンに対しては、混合パターンおよび抑制パターンの不安定化の効果は小さかった。このことは、記憶パターン間の相関がさらに高いとき、密パターンの不安定化のみを行う方がよいケースもあり得ることを示唆している。ただ、パターン間の相関がどの程度強いときにこうすべきかは、今のところはっきりしない。これについても今後の課題として検討していく。

最後に今後検討すべき改善方法を以下にまとめる。まず、想起失敗時に出力される偽記憶パターンが他の記憶パターンから十分離れている場合、これを不安定化パターンに追加して逐次的に結合荷重の修正を行うことで連想性能を改善できる可能性がある。ただ、不安定化パターンを追加していくにしたがって連立不等式を満たす解領域が小さくなるため、解の収束が困難になることも考えられる。次に、Ho-Kashyap アルゴリズムはパターン認識における識別平面の学習によく用いられることから⁽¹⁵⁾、訓練データを十分に用意できれば、連想メモリにおける吸引領域の位置や大きさの制御も可能と考えられる。つまり、吸引領域の大きさの上限を図3の最近傍連想メモリモデルに近づけるよう努力するとともに、上限範囲内で必要に応じた吸引領域の制御を試みる。さらに、本論文で取り上げたニューラルネットは中間層をもたない2層のものにフィードバック結合を付加したものであった。しかし、Ho-Kashyap アルゴリズムにより3層ニューラルネットの学習も可能であることから⁽⁵⁾⁽¹⁶⁾、ここで取り上げた拡張 Hassoun モデルを3層に拡張し、さらに性能を向上することも可能と考えられる。今後、これらの改良を試みていく予定である。

謝 辞

本研究を進めるにあたり、ご助言を頂いた神戸大学工学部玉置久助教授に感謝の意を表します。

(平成12年4月11日受付、同12年12月11日再受付)

文 献

- (1) J. J. Hopfield: "Neural networks and physical systems with emergent collective computational abilities", *Proc. Natl. Sci. USA*, Vol. 79, pp. 2254-2558 (1982).
- (2) T. Kohonen: *Self-organization and associative memory*, 3rd ed. New York: Springer-Verlag (1989).
- (3) M. H. Hassoun: *Associative neural memories*, Oxford University Press (1993).
- (4) J. Hertz, A. Krogh, and R. G. Palmer: *Introduction to the theory of neural computation*, Addison-Wesley (1990).
- (5) 阿部重夫: ニューラルネットとファジィシステム-理論と応用, 近代科学社 (1995).
- (6) 森田, 吉澤, 中野: "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).
- (7) 掛谷, 金道: "符号反転記憶法による自己相関連想記憶の改良", 日本神経回路学会誌, Vol. 1, No. 1, pp. 20-26 (1994).
- (8) 池田: "偽記憶のない連想記憶システム", 日本神経回路学会誌, Vol. 3, No. 4, pp. 141-146 (1996).
- (9) S. Ozawa, K. Tsutsumi, N. Baba: "A continuous-time model of autoassociative neural memories utilizing the noise-subspace dynamics", *Neural Processing Letters*, Vol. 10, Issue 2, pp. 97-109 (1999).

- (10) Y.-C. Ho, R. L. Kashyap: "An algorithm for linear inequalities and its application", *IEEE Transactions on Electronic Computers*, EX-14, pp.683-688 (1965).
- (11) M. H. Hassoun: "Dynamic heteroassociative neural memories", *Neural Networks*, Vol. 2, pp. 275-287 (1989).
- (12) M. H. Hassoun, A. M. Youssef: "High performance recording algorithm for Hopfield model associative memories", *Optical Engineering*, Vol. 28, No. 1, pp. 46-54 (1989).
- (13) W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery: *Numerical recipes in C*, Cambridge Univ. Press (1986).
- (14) D. Casasent, B. Telfer: "High capacity recognition associative processors", *Neural Networks*, Vol. 5, pp.687-698 (1991).
- (15) R. Duda, P. Hart: *Pattern classification and scene analysis*, John Wiley & Sons (1973).
- (16) 土屋, 小澤, 阿部: "パターン認識用三層ニューラルネットの不等式の求解による高速学習方式", システム制御情報学会論文誌, Vol. 13, No. 6, pp. 276-283 (2000).

朴 正 泌 (非会員) 1997年3月釜慶大学電子工学科卒業。2000年3月神戸大学大学院自然科学研究科電気電子工学専攻博士前期課程修了。現在、同大学院自然科学研究科システム機能科学専攻博士後期課程在学中。ニューラルネット、連想記憶、パターン認識の研究に従事。

小 澤 誠 一 (正員) 1989年神戸大学大学院工学研究科修士課程(計測工学専攻)修了。同年奈良工業高等専門学校情報工学科助手、1993年大阪教育大学教育学部教養学科情報科学専攻助手、同講師を経て、2000年1月より神戸大学大学院自然科学研究科助教授となり、現在に至る。ニューラルネットによる知的情報処理の研究に従事。博士(工学)。電子情報通信学会、計測自動制御学会、システム制御情報学会、INNS等の会員。

阿 部 重 夫 (正員) 1972年京都大学大学院修士課程(電気工学専攻)修了。企業の研究所を経て1997年4月より神戸大学工学部教授、1999年4月より神戸大学大学院教授となり現在に至る。1978年から一年間米国 Texas 大学客員研究員、ニューラルネット、ファジィシステムの研究に従事。工学博士。1984年、1995年電気学会論文賞受賞。著書 Neural Networks and Fuzzy Systems: Theory and Applications (Kluwer Academic) 他。情報処理学会、計測自動制御学会、システム制御情報学会、IEEE、INNS等の会員。