

パターン分析・合成型連想メモリ
 Pattern Analysis/Synthesis-Type Associative Memory

小川 剛史[†] 時田 洋輔[‡] 横井 博一[†]
 Takeshi Ogawa Yosuke Tokita Hirokazu Yokoi

1. まえがき

人間は思考過程において連想を多く用いている。連想とは、長期記憶の中で概念と概念が互いに連合し、一方の概念が与えられた時にもう一方の概念が想起されることをいう。現在、このような連想をモデル化した連想メモリの研究が盛んである。初期の連想メモリは、概念をパターンで表し、概念間の連合をパターン間の相関行列によって実現するものが一般的であった。Associatron[1]から始まって、双方向連想メモリ[2]、多方向連想メモリ(Multidirectional Associative Memory: MAM)[3]など、様々なモデルが提案された。

これらは相関行列を用いているため、第1に記憶容量が極めて低い。第2に、想起時に入力されるキーパターンに雑音が含まれている場合、想起能力が著しく低下する。この第2の問題点を解決するために、雑音を除去する砂時計型ニューラルネットワークをMAMに付加した、改良型多方向連想メモリ(Improved Multidirectional Associative Memory: IMAM)が提案された[4]。一方、第1の問題点を解決するため、相関行列の代わりに階層型ニューラルネットワークを用いて連合を実現する階層型連想メモリが提案された[5],[6]。本論文ではこれを階層型連想メモリと呼ぶ。しかし、この場合でも記憶容量はまだ十分でない。そのため筆者らは、階層型ニューラルネットワークの学習能力をさらに向上させるために、各層間に介在素子を付加することを提案した[7]-[9]。

ところで、人間の思考過程においては分析と合成が繰り返行なわれている。思考過程で重要な役割を演ずる連想においても、分析と合成が基礎過程として関与している場合が多いと考えられる。すなわち、分析と合成過程で得られる情報が連合や想起過程で積極的に用いられ、それによって高い記憶容量と耐雑音能力、また高度な連想機能が実現されているものと推測される。分析と合成を行うには、砂時計型ニューラルネットワークが最適である。上木らは、5層の砂時計型ニューラルネットワークに、顔表情の集合上の恒等写像を学習させることにより、表情の分析と合成が可能であることを示した[10]。したがって、連想メモリにおいて、あらかじめ入力パターン集合上の恒等写像を砂時計型ニューラルネットワークに学習させておけば、学習後このネットワークにパターンを入力した時、入力パターンの分析と合成が行われ、その過程で得られる情報が連合や想起過程で利用できる。

そこで、本論文では、人間のような連想能力を持った連想メモリを実現することを最終目標として、砂時計型ニューラルネットワークを付加することにより、入力パターンの分析と合成が行えるパターン分析・合成型連想メモリを提案し、次に、計算機実験により介在素子を付加した階層

型連想メモリと記憶容量について比較し、提案連想メモリの有効性を検討することを目的とする。

2. 提案連想メモリ

2.1 全体の構成

2.1.1 記銘部

提案するパターン分析・合成型連想メモリは、記銘部と連合部の二つの部分から成る。記銘部には、図1に示すように5層の砂時計型ニューラルネットワークを用いる。入力層と出力層の素子数は等しくなっており、第2層と第4層の素子数は入出力層より少し多く、第3層については他の層に比べて素子数が極めて少なくなっている。各層間には、ネットワークの学習能力を高めるために介在素子が付加されている。図の中の大きい丸は、一般に用いられる基本学習しきい素子である[11]。小さい黒丸で表された介在素子には、ネットワークの学習能力が最も高くなることが示されている基本学習距離素子を用いる[11]。この素子の入出力関係はベクトル式(1)と(2)で表される。

$$u = \|W - X\| \quad (1)$$

$$z = \exp[-(\rho u)^2] \quad (2)$$

ここで、 X は入力ベクトル、 W は基準ベクトル、 ρ は選択度である。ただし、本論文では選択度は固定とする。




図1. 記銘部に用いる砂時計型ニューラルネットワーク

図1のネットワークに、入力パターン集合上の恒等写像を学習させる。すなわち、入力パターンを入力すると同時にそれを教師として最終層に与えて学習させ、入力パターンの記銘を行う。したがって、このネットワーク自体、一種の自己想起方式の連想メモリと考えられる。ネットワークの学習においては、各層の素子である基本学習しきい素子および介在素子である基本距離素子すべてについて、そのパラメータがすべて修正される。ただし、選択度は除く。学習則は最終層の各素子の出力信号と教師信号の誤差2乗和を評価関数として、勾配降下法により導出している[12]。

学習後、このネットワークにパターンを入力すると、第2層と第3層の素子からは入力パターンの分析情報が得ら

[†]九州工業大学大学院 生命体工学研究科

[‡]早稲田大学 理工学総合研究センター

れ、第4層の素子からは分析情報に基づいて入力パターンと同じパターンを合成するのに必要な情報が出力される。本論文では、これを合成情報と呼ぶ。第3層から得られる分析情報と第4層から得られる合成情報は、砂時計型ニューラルネットワークの出力パターンすなわち入力パターンと共に連合部に送られ、連合および想起に用いられる。

なお、砂時計型ニューラルネットワークは、記録したパターンそのものだけでなく、それに似たパターンやその一部が欠けたパターンを入力しても、記録パターンが出力される。したがって、このネットワークは入力パターンの修復や復元にも役立つ。また、雑音をわずかに含んだ記録パターンを入力しても、その雑音が除去されて出力されるので、IMAMで用いられたように、連想メモリの耐雑音能力を高めることにも役立つ。

2.1.2 連合部

連合部には、図2に示すように3層の階層型ニューラルネットワークを用いる。記録部と同様、各層には基本学習しきい素子を、ネットワークの学習能力を高めるための介入素子には基本学習距離素子を用いる。




図2. 連合部に用いる階層型ニューラルネットワーク

図2のネットワークに、連合させようとする二つのパターンの一方を入力すると同時に、もう一方を教師として最終層に与えて学習させ、両パターンをネットワーク上で連合させる。したがって、このネットワーク自体、一種の相互想起方式の連想メモリと考えられる。ただし、このネットワークに入力されるのは、記録部における砂時計型ニューラルネットワークの出力パターンすなわち入力パターンだけでなく、その分析情報と合成情報も含んでいる。したがって、連合部では砂時計型ニューラルネットワークからの出力パターンと連合部への教師パターンだけを連合するのではなく、前者の分析情報と教師パターン、前者の合成情報と教師パターンの連合も同時に実現する。人間の連想においても、概念間だけではなく、概念に含まれる属性との間でも連合が行われていると推測される。連合部でこのように、1つのパターン対に対して3通りの連合を実現することにより、連想メモリのパターン想起能力が向上するものと期待できる。

ネットワークの学習においては、記録部の砂時計型ニューラルネットワークと同じく、すべての素子についてパラメータがすべて修正される。ただし、選択度は除く。学習則も記録部と全く同じである。

学習後、連合部に、記録部から出力されるすべての情報を入力すると、記録部への入力パターンと連合しているもう一方のパターンが連合部から出力され、想起が行われる。

なお、記録部から出力されるパターンが、連合させた一方のパターンそのものでなく、それに似たパターンやその一部が欠けたパターンであったとしても、また、そこに雑音が多含まれていたとしても、それを連合部に入力したとき、もう一方のパターンが出力される。したがって、たとえ記録部の出力が不完全であっても、連合部で回復可能である。

2.2 連想過程

2.2.1 記録過程

パターン分析・合成型連想メモリの連想過程は、図3に示すように記録過程、連合過程、想起過程の三つに分けることができる。本論文では、連想メモリ上で連合させる二つのパターンをプロトタイプパターン1とプロトタイプパターン2と呼ぶ。また、連合が完了した後、想起過程で連想メモリに入力されるパターンをキーパターン、出力されるパターンを想起パターンと呼ぶ。

まず、連合すべきプロトタイプパターン1とプロトタイプパターン2の対を複数用意する。記録過程では、2.1.1で述べた方法にしたがって、すべてのプロトタイプパターン1を記録部の砂時計型ニューラルネットワークに順番に提示して学習させる。これを1サイクルとし、このサイクルを何回も繰り返す。こうしてプロトタイプパターン1だけをすべて記録部に記録する。

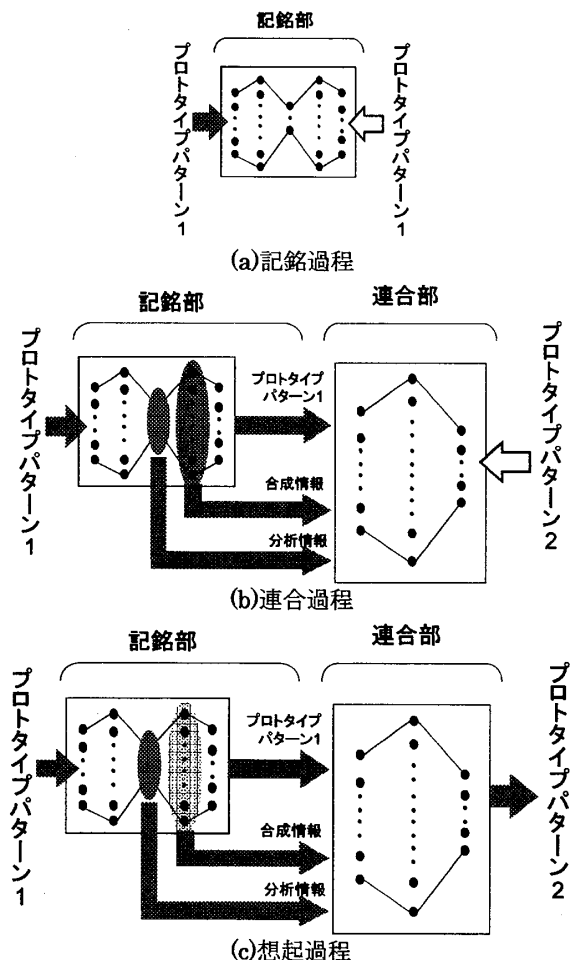


図3. パターン分析・合成型連想メモリの連想過程

2.2.2 連合過程

すべてのプロトタイプパターン 1 が記銘された後、プロトタイプパターン 1 の 1 つをまず記銘部に入力する。その時、記銘部からはプロトタイプパターン 1 とその分析情報、合成情報が出力される。これらを入力とし、それと対をなすプロトタイプパターン 2 を教師として、2.1.2 で述べた方法にしたがって、連合部の階層型ニューラルネットワークに学習させる。この学習をすべての対に対して行う。これを 1 サイクルとし、このサイクルを何回も繰り返す。こうしてプロトタイプパターン 1 とプロトタイプパターン 2 のすべての対を、プロトタイプパターン 1 の分析情報と合成情報も含めて連合部に連合する。

2.2.3 想起過程

記銘と連合が完了した後、記銘したプロトタイプパターン 1 の 1 つを記銘部にキーパターンとして入力する。その時の記銘部のすべての出力は、連合部に入力され、連合部からはキーパターンと対をなすプロトタイプパターン 2 が想起される。なお、キーパターンとして用いるプロトタイプパターン 1 に雑音が多少含まれている場合や、一部が欠けている場合でも、それが記銘したプロトタイプパターン 1 に似ていれば、それと対をなすプロトタイプパターン 2 が想起される。

3. 計算機実験

3.1 方法

提案連想メモリの記銘部における砂時計型ニューラルネットワークの素子数は、入力層と出力層がそれぞれ 100、第 2 層および第 4 層がそれぞれ 150、第 3 層が 20、介在素子についてはどの層間も 10 とする。連合部における階層型ニューラルネットワークの素子数は、入力層が 270、中間層が 300、出力層が 100、介在素子についてはどの層間も 45 とする。一方、介在素子を付加した階層型連想メモリでは、提案連想メモリの連合部と同様の階層型ニューラルネットワークを用い、その素子数は、入力層と出力層がそれぞれ 100、中間層が 300、介在素子についてはどの層間も 45 とする。

計算機実験に用いるプロトタイプパターン対の例を図 4 に示す。プロトタイプパターン 1 は英大文字、プロトタイプパターン 2 は日本語の仮名とし、連合させるパターン対の数は 26 と 52 の 2 通りとする。前者の場合には英大文字と平仮名を対とし、後者の場合には、前者の場合のパターン対に、変形した英大文字と片仮名の対を 26 個加える。これらすべてのプロトタイプパターンは 10×10 のドットパターンで、白いドットを -1 、黒いドットを $+1$ として 100 次元のベクトルで表現する。

提案連想メモリおよび介在素子を付加した階層型連想メモリで用いられる各ニューラルネットワークの学習において、できるだけ最適値に近い学習係数を用いる。そのため、学習係数を 0.0001 から 1 まで 97 通り変化させ、それぞれの場合について、各ニューラルネットワークで 40000 サイクル学習させた後の誤差二乗和を求める。このとき、ネットワークのすべてのパラメータの初期値を 3 回変えて同じように学習を行い、40000 サイクル学習後の誤差二乗和の平均値が最小になる学習係数をそのネットワークにおける最適値とみなす。学習サイクル数 40000 は、どのニューラルネットワークにおいても誤差二乗和がほ

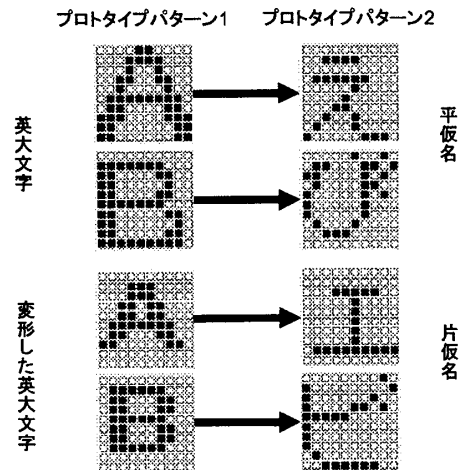


図 4. 計算機実験に用いるプロトタイプパターン対の例

ぼ一定になるのに十分な回数である。

各ニューラルネットワークの学習が完了した後、2 種類の連想メモリそれぞれにおいて、プロトタイプパターン 1 をキーパターンとして入力する。このときの想起パターンから、式(3)に示す要素想起確率 P_E と式(4)に示すパターン想起確率 P_p を求め、これらを記憶容量の指標として両連想メモリを比較する。

$$P_E = \frac{1}{n} \sum_{k=1}^n \frac{m_k}{m_e} \times 100[\%] \quad (3)$$

$$P_p = \frac{n_c}{n} \times 100[\%] \quad (4)$$

ここで、 n はプロトタイプパターン対の数で、26 または 52 である。 m_e はプロトタイプパターン 2 の要素数で、100 である。 m_k は k 番目のプロトタイプパターン 2 に含まれる正確に想起できた要素数、 n_c は正確に想起できたプロトタイプパターン 2 の数である。

3.2 結果と考察

提案連想メモリの記銘部における砂時計型ニューラルネットワークと連合部における階層型ニューラルネットワークの学習係数の最適値は、それぞれ 0.002323 と 0.002810 であった。一方、介在素子を付加した階層型連想メモリにおける階層型ニューラルネットワークの学習係数の最適値は 0.0018 であった。

表 1 は、2 種類の連想メモリそれぞれの要素想起確率を示す。パターン対の数が 26 の場合、要素想起確率はどちらも 100% であった。パターン対の数が 52 の場合には、提案連想メモリが同じく 100% であったのに対し、介在素子を付加した階層型連想メモリは 99.8% であった。両者の差は 0.2% である。表 2 は、2 種類の連想メモリそれぞれのパターン想起確率を示す。パターン対の数が 26 の場合、パターン想起確率はどちらも 100% であった。パターン対の数が 52 の場合には、提案連想メモリが同じく 100% であったのに対し、介在素子を付加した階層型連想メモリは 85.4% であった。両者の差は 14.6% である。

以上の結果から、パターン対の増加とともに、両連想メモリの想起確率、特にパターン想起確率の差が大きくなる事が示された。提案連想メモリは、パターン対の数が 52 でも 2 つの想起確率がともに 100% であるので、連合させ

表1. 要素想起確率[%]

連想メモリの種類 パターン対の数	パターン分析・ 合成型 連想メモリ	介在素子を付加した 階層型連想メモリ
26	100	100
52	100	99.8

表2. パターン想起確率[%]

連想メモリの種類 パターン対の数	パターン分析・ 合成型 連想メモリ	介在素子を付加した 階層型連想メモリ
26	100	100
52	100	85.4

るパターン対の数をさらに大きくすることが可能である。それに対し、介在素子を付加した階層型連想メモリは、パターン対の数を52よりも大きくしていくと、どちらの想起確率もさらにいっそう低下すると予想される。そのため、両連想メモリの想起確率の差はますます開くことになる。提案連想メモリと介在素子を付加した階層型連想メモリの違いは、砂時計型ニューラルネットワークで得られた分析情報と合成情報を用いるかどうかだけである。したがって、分析情報と合成情報は、連想メモリの記憶容量の増大をもたらすことが示された。これにより、提案連想メモリの有効性が確認された。

想起確率に関して提案連想メモリの方が高くなったのは、1つのパターン対に対して3通りの連合を実現していることが大きな原因である。すなわち、連合するパターン対の数が大きくなっても、想起過程で手がかりとなる情報が多いため正確な想起が可能となる。2種類の連想メモリの想起確率、特に要素想起確率の差が比較的小さかったのは、パターン対の数が十分大きくなかったため、比較する対象である連想メモリにおいてもそれらがかなり連合してしまったためである。記憶容量について検討するためには、連合するパターン対の数をさらに大きくする必要がある。

4. むすび

本論文では、入力パターンの分析と合成が行えるパターン分析・合成型連想メモリを提案した。計算機実験により介在素子を付加した階層型連想メモリと記憶容量について比較し、提案連想メモリの有効性を検討した。

その結果、パターン対の数が26の場合、両連想メモリの要素想起確率、パターン想起確率はともに100%であった。パターン対の数が52の場合、提案連想メモリはどちらの想起確率も同じく100%であるのに対し、介在素子を付加した階層型連想メモリは、提案連想メモリより要素想起確率が0.2%、パターン想起確率が14.6%低下した。すなわち、パターン対の増加とともに、両連想メモリの想起確率の差が大きくなった。両連想メモリは、砂時計型ニューラルネットワークで得られた分析情報と合成情報を用いるかどうかだけが異なっているので、分析情報と合成情報が連想メモリの記憶容量の増大に寄与することが示された。これにより、提案連想メモリの有効性が確認された。

想起確率に関して提案連想メモリの方が高くなったのは、1つのパターン対に対して3通りの連合を実現することにより、連合するパターン対の数が大きくなっても、想起過

程で手がかりとなる情報が多いからである。2種類の連想メモリの想起確率、特に要素想起確率の差が比較的小さかったのは、パターン対の数が十分大きくなかったためである。

今後の課題は、連合するパターン対の数をさらに大きくして、提案連想メモリの記憶容量についてさらに検討を加えることである。

文献

- [1] K.Nakano, "Associatron - A model of associative memory," IEEE Trans. Syst. Man. & Cybern., vol.SMC-2, no.3, pp.380-388, 1972.
- [2] B.Kosko, "Bidirectional associative memory," IEEE Trans. Syst. Man. & Cybern., vol.18, no.1, pp.49-60, 1988.
- [3] M.Hagiwara, "Multidirectional associative memory," Proc. IEEE and INNS International Joint Conference on Neural Networks, vol.1, no.3, pp.3-6, 1990.
- [4] 服部元信, 萩原将文, 中川正雄, "共通項を含む学習組に対する改良型多方向連想メモリ," 信学論(D-II), vol.J77-D-II, no.3, pp.591-599, 1994.
- [5] M.Morita, "Associative memory with nonmonotone dynamics," Neural Networks, vol.6, no.4, pp.114-126, 1993.
- [6] 小澤誠一, 堤一義, "モジュール化ニューラルネットワークモデルの提案とその連想記憶能力の評価," 信学論(D-II), vol.J77-D-II, no.6, pp.1135-1145, 1994.
- [7] 横井博一, 木本智幸, "介在素子を付加した階層型ニューラルネットワーク," バイオメディカル・ファジィ・システム学会誌, vol.1, no.1, pp.87-97, 1999.
- [8] 猪平栄一, 横井博一, "距離情報に基づく介在素子を持つ階層型ニューラルネットワーク," バイオメディカル・ファジィ・システム学会誌, vol.7, no.1, pp.21-31, 2005.
- [9] 時田洋輔, 横井博一, "コラムの階層的な結合による連想メモリの実現," バイオメディカル・ファジィ・システム学会誌, vol.7, no.1, pp.105-112, 2005.
- [10] 上木伸夫, 森島繁生, 山田寛, 原島博, "多層ニューラルネットワークによって構成された感情空間に基づく表情の分析・合成システムの構築," 信学論(D-II), vol.J77-D-II, no.3, pp.573-582, 1994.
- [11] 横井博一, 染井陽介, "並列分散処理ネットワーク用基本素子の比較," バイオメディカル・ファジィ・システム学会誌, vol.1, no.1, pp.99-112, 1999.
- [12] E.Inohira, H.Yokoi, "Multilayer neural networks with adjustable intermediate elements," Biomedical Soft Computing and Human Science, (Accepted)