

逐次記憶学習を目的とした連想記憶システムへの「記憶パターンの信頼度」の利用

芳澤 伸一[†] 道木 慎二[†] 大熊 繁[†]

Associative Memory System for Sequential Learning Using Reliability of Memorized Pattern

Shinichi YOSHIKAWA[†], Shinji DOKI[†], and Shigeru OKUMA[†]

あらまし 従来の多くの連想記憶システムにおいては、記憶すべきパターンが事前に与えられ、システムが与えられたパターンをすべて記憶学習した後に利用される。これに対して本論文では、逐次記憶学習を目的とした連想記憶システムを考える。そして、逐次入力されるパターンを逐次的に記憶し、記憶パターンを逐次的に利用するために、新たに「記憶パターンの信頼度」の尺度を導入した連想記憶システムを提案する。この尺度を用いることにより、記憶容量の制約のもとで、従来のシステムの問題点であった追加学習性の問題を解決する。また、信頼度の高い記憶パターンを優先的に想起することで、逐次的に記憶パターンを利用することも可能にする。更に、提案するシステムは、提示回数の少ないパターンの特徴をまとめて記憶するシステムとなっている。最後にシミュレーションにより提案するシステムの有効性を検証する。

キーワード 連想記憶システム, 逐次学習, ニューラルネットワーク, Oja 則

1. まえがき

従来の多くの連想記憶システムにおいては、文字認識などの例に見られるように、記憶すべきパターンが事前に与えられ、システムがこれらのパターンを記憶した後に、システムの利用が始まる [1],[2].

これに対して、記憶すべきパターンが事前に与えられない場合、参照された入力パターンから逐次的に記憶パターンを作成し、この記憶パターンを逐次的に利用する必要がある。また、大量データを扱う場合、逐次的な学習にならざるを得ない。本論文では、新しい逐次記憶学習と記憶の逐次的利用の方法を提案する。

逐次学習の問題点として、記憶パターンの追加学習性 [3] が挙げられる。メモリ容量などのハードウェアの制約のもとでは効率の良い記憶方法が望まれるうえ、蓄積した記憶パターンをできる限り保持しながら追加パターンを記憶することが要求される。また、記憶パターンを逐次的に利用する場合、学習回数が極めて少ない信頼度の低い記憶パターンをいかに取り扱うかが

重要な問題となる。

本論文では、「記憶パターンの信頼度」の尺度を導入することにより、上記の問題の解決を図る。記憶パターンの信頼度は、記憶パターンの学習回数、すなわち記憶パターンが蓄積してきた入力パターンの提示回数により決定する。提示回数の多い入力パターンはシステムの置かれた環境を大きく反映しており、これらの入力パターンを蓄積している記憶パターンは信頼度が高いと考える。

信頼度の異なる記憶パターンを区別し、新たに入力された重要なパターンを信頼度の低い記憶パターンで記憶を行うことにより、信頼度の高い記憶パターンを保持する。このようにして、記憶容量の制約のもとで追加学習性の改善を図る。また、信頼度の高い記憶パターンを優先的に利用し、信頼度の低い記憶パターンの利用を極力回避することで、記憶パターンの逐次的な利用が可能となる。更に提案するシステムは、提示回数が少なく、個々のパターンとしてあまり意味がない入力パターンに対して、パターン群としての全体の特徴をとらえ、まとめて記憶を行う。すなわち、提示回数の多いパターンだけではなく、少ないパターンも考慮したシステムとなっている。

[†]名古屋大学大学院工学研究科, 名古屋市
Nagoya University Grad. School of Eng., Furocho, Chikusa-ku,
Nagoya-shi, 464-8603 Japan

本論文では、提案する連想記憶システムの構成について述べた後、本論文の主眼である「記憶パターンの信頼度」の尺度を導入することの有効性を、記憶容量の制約のもとでの追加学習性と記憶パターンの逐次的利用の観点から示す。最後に提案するシステムの有効性をシミュレーションにより検証する。

2. 連想記憶システムの構成

提案する連想記憶システムは2層の階層型ニューラルネットワークで構成される。第1層を入力層 (input layer)、第2層を競合層 (competitive layer) と呼ぶ。図1は、入力層のユニット数、競合層のユニット数をそれぞれ $n_0 = 3$ 、 $n_1 = 3$ とした場合の例を示している。本システムでは、記憶処理と想起処理の2種類の処理モードが存在する。記憶処理で、入力パターンをシステムに自己組織的に記憶し、想起処理で、入力パターンをキーパターンとして、最適な記憶パターンを抽出する。

2.1 記憶処理

本システムでは、競合層の各ユニットは個々の記憶パターンを意味し、このユニットに結合している層間重みで入力パターンを蓄積する (図1)。記憶処理は2段階で行う。第1段階で、入力パターンを記憶する競合層ユニットを決定する。第2段階で、層間重みを更新することで入力パターンをシステムに蓄積する。本システムでは、入力パターンを記憶する競合層ユニットを決定する際に、角度しきい値 θ_{max} を導入する。この角度しきい値は、同一パターンとして認識し記憶する入力パターンの範囲を決定するパラメータである。この値が小さい場合、わずかに異なる入力パターンでも区別して記憶することになる。




図1 提案する連想記憶システムの構成 (入力層ユニット数3、競合層ユニット数3の場合)

Fig.1 Proposed associative memory system. ($n_0 = 3$, $n_1 = 3$)

入力パターン情報を競合層に伝搬する。入力パターンをベクトル表現し、ベクトルの大きさを正規化した後、入力層に入力して、以下の式に従い入力情報を競合層に伝搬する。

$$V_i^0 = h_i^0, \quad V_j^1 = h_j^1 \tag{1}$$

$$h_j^1 = \sum_i W_{ji} V_i^0 \tag{2}$$

$$(i = 1, 2, \dots, n_0 \quad j = 1, 2, \dots, n_1)$$

ここで、 h_i は i ユニットの入力値、 V_j は j ユニットの出力値、肩の添字の0、1はそれぞれ入力層、競合層を表し、 n_0 、 n_1 はそれぞれ入力層、競合層のユニット数を表す。また、 W_{ji} は入力層 i ユニットの競合層 j ユニットの層間重みを表す。

第1段階として、入力パターンを記憶する競合層ユニットを決定する。図2のように競合層ユニットに結合している層間重みをベクトル表現する。このベクトルを重みベクトル (weight vector) と呼ぶ。本システムでは、重みベクトルの大きさは記憶パターンの信頼度に直結している。図2には、入力パターンベクトル \vec{h}^0 、重みベクトル \vec{W}_1 、 \vec{W}_2 、 \vec{W}_3 が示されている。各重みベクトルは角度しきい値 $\theta_{max,j}$ ($j = 1, 2, \dots, n_1$) をもち、しきい値範囲内の入力パターンベクトルのみを記憶することが可能であるとする。角度しきい値により記憶パターンの粗さの上限を決定することができる。しきい値を用いたシステムとして適応共鳴理論 (ART) [4] がある。このシステムは記憶パターンを作成するユニットの数を必要に応じて増加させるものであり、記憶容量の制約を考慮していない。入力パターンを記憶する重みベクトル \vec{W}_j^* のことを更新重みベクトル (updated weight vector) と呼び、以下のアルゴリズムに従い更新重みベクトルを決定する。




図2 記憶処理 (入力層ユニット数3、競合層ユニット数3の場合)

Fig.2 Memorization process. ($n_0 = 3$, $n_1 = 3$)

(1) 入力パターンベクトル \vec{h}^0 との内積が最大値である重みベクトル \vec{W}_j ($0 \leq j \leq n_1$) を選択する。

(2) 入力パターンベクトル \vec{h}^0 と重みベクトル \vec{W}_j のなす角が角度しきい値 $\theta_{max,j}$ の範囲内であれば \vec{W}_j を更新重みベクトル \vec{W}_{j^*} とする。範囲外の場合はその重みベクトルを除いた重みベクトルの中で (1), (2) の操作を繰り返し、更新重みベクトルを決定する。図 2 の例では \vec{W}_1 が更新重みベクトルである。

本システムでは、記憶容量の制約のもとで効率の良い記憶処理を行うために、角度しきい値 $\theta_{max,j}$ ($j = 1, 2, \dots, n_1$) を記憶パターンの信頼度、すなわち重みベクトルの大きさの関数としている。このことについては 4. で詳しく述べる。

第 2 段階として、入力パターン \vec{h}^0 を更新重みベクトル \vec{W}_{j^*} に記憶する。重みベクトルと入力パターンベクトルのなす角を記憶学習を行うごとに徐々に小さくして、入力パターンを更新重みベクトルに記憶する。その際、重みベクトルの大きさは徐々に大きくなる。重み更新則には Oja 則を用いる [5], [6].

重み更新則 (Oja 則)

$$\Delta W_{j^*i} = \eta_1 V_j^1 (V_i^0 - V_j^1 W_{j^*i}) \quad (3)$$

$$(i = 1, 2, \dots, n_0)$$

j^* : 更新重みベクトルに結合している競合層ユニット番号

η_1 : 学習係数

最終的に重みベクトルは、重みベクトルのもつ角度しきい値の範囲内の入力パターンをすべて考慮したとき、競合層での出力の 2 乗平均が最大になる方向を向く。また重みベクトルの大きさは徐々に大きくなり 1 に収束する。図 3 に、重みベクトルの大きさが 1 に収束する様子を示す。入力パターンベクトルと重みベクトルのなす角の初期値として $\theta_0 = 0, 20, 40, 80 [^\circ]$ となるように入力パターンベクトルを決定し、この場合における学習回数に対する、重みベクトルの大きさの変化と、入力パターンベクトルと重みベクトルのなす角の変化について図示した。図中の数字は学習回数を表示しており、30 [回] ごとに結果をプロットしている。その際、後に行うシミュレーション条件に合わせて $\eta_1 = 0.01$, $n_0 = 225$ とし、初期重みベクトルの大きさを 0.1 とした。

2.2 想起処理

記憶パターンを逐次的に利用する場合、学習回数が




図 3 Oja 則
Fig. 3 The Oja rule.

極めて少ない信頼度の低い記憶パターンをいかに取り扱うかが問題となる。そこで、記憶パターンの信頼度の尺度を用いて、信頼度の高い記憶パターンを優先的に想起し、信頼度の低い記憶パターンの想起を極力回避することで、記憶パターンの逐次利用を可能にする。

提示された入力パターンに対して、記憶処理と同様に競合層ユニットの出力値を決定する。ユニット出力値は、入力パターンベクトルと重みベクトルのなす角のみではなく、重みベクトルの大きさ、すなわち記憶パターンの信頼度を考慮した値となっている。言い換えると、信頼度の高い記憶パターンは大きな出力値をもつ。そこで、競合層ユニットで最大出力値をもつ記憶パターンを想起することで、信頼度の高い記憶パターンを優先的に利用することが可能となる。想起パターン y_i は以下の式に従い生成する。

$$y_i = W_{j^*i} \quad (i = 1, 2, \dots, n_0) \quad (4)$$

j^* : 最大出力値をもつ競合層ユニット

3. 記憶パターンの信頼度

入力されたパターンとその提示回数は、システムが置かれている環境に存在するパターン群の性質を反映している。ここで提示回数の多い入力パターンを蓄積している記憶パターンは、環境の代表的な特徴を表現していると考えられる。逆に提示回数の少ない入力パターンを蓄積している記憶パターンは、環境の特徴を反映していない。これより、提示回数が少ない入力パターンに対する記憶と、提示回数が多い入力パターン

に対する記憶を区別する必要が生じる。この考え方は、逐次記憶学習と記憶の逐次利用を行うにあたり極めて重要である。

そこで本論文では、記憶パターンを区別する指標として「記憶パターンの信頼度」という尺度を導入する。記憶パターンの信頼度は、各記憶パターンに対応する入力パターンの提示回数により決定する。これより各記憶パターンは、それぞれ対応する入力パターンの提示回数に応じた信頼度をもつことになる。本システムでは、重みベクトルの大きさにより記憶パターンの信頼度を表現している。この尺度は、環境に存在する入力パターンのうち、記憶パターンに類似したパターン数を反映しており、記憶パターンが環境の特徴を十分表現しているか否かを決定する尺度となっている。

重みベクトル \vec{W}_i ($1 \leq i \leq n_1$) が表す記憶パターンの信頼度 R_i ($1 \leq i \leq n_1$) を以下の式により計算する。

$$R_i = |\vec{W}_i| \quad (i = 1, 2, \dots, n_1) \quad (5)$$

提案する連想記憶システムでは、記憶パターンの信頼度を利用することにより、以下のような特徴をもたせることが可能となる。

- 新たに入力された重要なパターンを信頼度の低い記憶パターンで記憶を行うことで、追加学習性が改善される。
 - 信頼度の高い記憶パターンを優先的に利用することにより、記憶パターンの逐次的な利用が可能となる。
 - 提示回数の多いパターンだけではなく、少ないパターンも考慮したシステムの構築が可能となる。
- 次章でその具体的な実現方法について述べる。

4. 追加学習性の改善と提示回数の少ない入力パターンに対する記憶方法

本システムでは、信頼度の低い記憶パターンに対して、広範囲の入力パターンをまとめて記憶させ、信頼度の高い記憶パターンに対して、記憶パターンに類似する限られた範囲の入力パターンのみを記憶させる。

この処理により、確立された信頼度の高い記憶パターンにおいて、新たな入力パターンの影響により記憶が失われることがなく、信頼度の低い記憶パターンにおいて新たな重要なパターンを記憶することが可能になる。

また、提示回数の少ない入力パターンで個々のパ

ターンとしてあまり意味をもたないものに対して、まとめて記憶を行うことで、パターン群としての全体の特徴をとらえ、提示回数の多いパターンだけではなく、少ないパターンも考慮したシステムの構築が可能となる。

更に、記憶パターンの信頼度に応じて、記憶可能な入力パターンの範囲を徐々に小さくすることにより、入力パターンのばらつきを吸収しながら記憶パターンを作成することが可能となる。

4.1 実現方法

本システムでは、記憶処理における角度しきい値を記憶パターンの信頼度の関数として表現する (図 4)。この角度しきい値は、類似した入力パターンを同一の記憶パターンとして記憶するか否かを決定するものである。本システムでは、記憶パターンの信頼度は重みベクトルの大きさに直結していて、提示回数の多い入力パターンを蓄積している記憶パターンほど、Oja 則により、その記憶のもつ重みベクトルの大きさは大きくなる。このことは、信頼度の高い記憶パターンは、大きさの大きい重みベクトルをもつことを意味する。

図 4 に示すように、記憶パターンの信頼度が低いとき、すなわち重みベクトルの大きさが小さいときに角度しきい値を大きくする。この処理により、重みベクトルの学習可能な入力パターンベクトルの範囲を大き

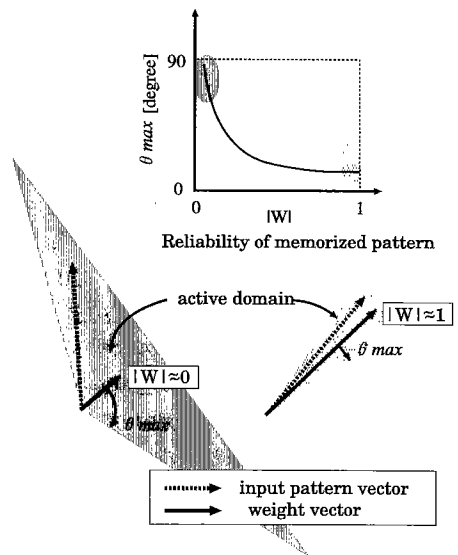


図4 記憶パターンの信頼度 ($|W|$) と角度しきい値 θ_{max}
 Fig.4 Reliability of memorized pattern ($|W|$) and threshold θ_{max} .

くする。このことは、広範囲の入力パターンを同一の記憶パターンとしてまとめて記憶することを意味し、提示回数の少ない入力パターンの特徴を素早くとらえ記憶することが可能となる。また、信頼度の低い記憶パターンは角度しきい値が大きいため、新たな入力パターンにより修正されやすく、信頼度の低い記憶パターンを意味もなく保持し続けることを回避する。例えば、システムに数回提示され、以後提示されなかった入力パターンを蓄積している記憶パターンは、提示回数の多い新たな入力パターンにより置き換えられ新たな記憶となる。記憶容量の制約のもとでは、この処理は極めて重要である。逆に、記憶パターンの信頼度が高いときは角度しきい値を小さくする。これより、信頼度の高い記憶パターンは新たな入力パターンに対して頑健になる。このように、角度しきい値を記憶パターンの信頼度の関数とすることで、記憶容量の制約のもとでの追加学習性の改善が図られる。

4.2 記憶パターンの信頼度と角度しきい値の関係

角度しきい値を記憶パターンの信頼度に対して一定の値にする場合と比較する。角度しきい値は記憶パターンの詳細さを決定するので、必要に応じて小さな値をとる必要がある。しかし、角度しきい値を小さな値にすることは、記憶パターンの入力パターンに対する学習可能領域を小さくすることを意味する。学習回数の極めて少ない未学習の記憶パターンが存在するにもかかわらず、角度しきい値から外れているため、新たな入力パターンを記憶することが不可能であるという状況が生じることになる。これに対して、本システムでは記憶パターンの信頼度が低いときに角度しきい値を十分大きくとっているため、このような状況を回避することが可能である。この処理は、記憶容量の制約のもとで記憶容量を有効利用するという観点から極めて重要である。

記憶パターンの信頼度と角度しきい値の関係は、Oja則の性質を考慮することにより決定される。図5に記憶パターンの信頼度と角度しきい値の関係を示す。図5は、図3に角度しきい値を重ねた図である。図5には角度しきい値 $\theta_{max} = 15 + 75 \exp(-7(|W| - 0.1))$ が例として描かれている。重みベクトルを更新するとき、重みベクトルの大きさが増加し角度しきい値が小さくなる。このとき、提示されているパターンを継続的に記憶できるように角度しきい値の減少量を十分小さくする。また、角度しきい値の最終的な値、すなわち記憶パターンの信頼度が高くなったときの角度しき

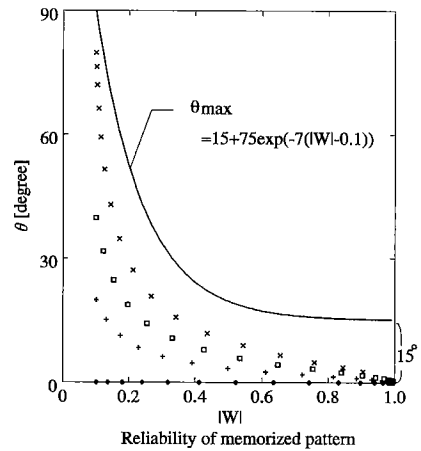


図5 角度しきい値
Fig.5 Threshold θ_{max} .

い値の値は、許容される記憶パターンの粗さの上限とする。

5. シミュレーション

提示パターンとして漢字を用いた場合を例にとり、シミュレーションにより本システムの有効性を検証する。具体的には、(1) 記憶容量の制約と追加学習性、(2) 記憶パターンの逐次的な利用、(3) 提示回数の少ないパターンに対する記憶パターンという観点から本システムの有効性を検証する。

本論文で対象としている環境は、記憶すべきパターンは事前に与えられるものではなく、逐次的にシステムに提示されるものである。このような状況の中で、逐次的に提示パターンを記憶パターンとして蓄積し、逐次的に記憶パターンを想起する場合を想定し、シミュレーションを行う。

比較対象として、入力パターンと記憶パターンとのなす角だけで、記憶、想起処理を行うシステムを用いる。このシステムは、入力パターンとのなす角が最小である記憶パターンに入力パターンを記憶し、その記憶パターンを想起するものであり、本システムとの対応を考えると、角度しきい値を記憶パターンの信頼度に依存させず $\theta_{max} = 90$ [度] と一定にしたものである。このシステムは、入力パターンと記憶パターンのユークリッド距離で、記憶するユニットを決定し想起パターンを決定する自己組織化マップ (SOFM) [7] と類似した動作を行う。

提案するシステムは、記憶パターンの信頼度を導入

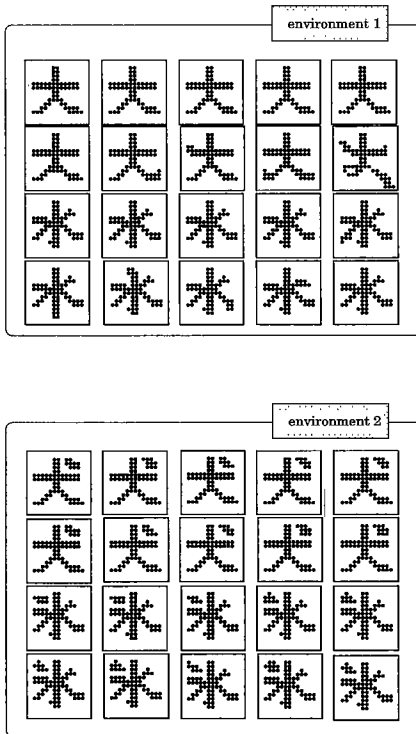


図6 提示パターン：環境1，環境2
Fig. 6 Presented patterns: environment 1, 2.

し、記憶処理では、信頼度の尺度とこの尺度に応じた角度しきい値を用いて入力パターンを記憶するユニットを決定する。想起処理では、信頼度の尺度を用いて想起パターンを決定する。

両者を比較することで、記憶パターンの信頼度の有効性を明確にする。

シミュレーション条件として、 $\eta_1 = 0.01$, $\theta_{max} = 15 + 75 \exp(-7(|W| - 0.1))$, 初期重みベクトルは $|W| = 0.1$ のランダムな値とした。 η_1 , θ_{max} は図5を考慮しながら経験的に決定した。

5.1 記憶容量の制約と追加学習性

新たに入力された重要なパターンを信頼度の低い記憶パターンで記憶を行うことにより、追加学習性の改善が図られることをシミュレーションにより検証する。

システムに提示するパターンを図6に示す。提示パターンとして 15×15 次元のものを用いた。提示パターンにおいて、ドットが存在する画素の濃度値は1、存在しない画素の濃度値は0である。はじめの150[step]で、環境1のパターンを提示し、次の150~200[step]で、環境2のパターンを提示する。そこで

環境2のパターンに対する追加学習性について考察する。ここで1[step]とは、環境に存在するすべてのパターンを1回ずつシステムに提示し記憶処理を行うこととする。

本システムを用いた場合の結果を図7に、記憶パターンの信頼度を利用しないシステムを用いた場合の結果を図8、図9に示す。ここでは、競合層ユニット数を $n_1 = 5$ とした。シミュレーション結果における記憶パターンの各画素のドットの大きさは、重みベクトルの各成分の大きさを信頼度 R で正規化した値を表している。

図7には、本システムに対する記憶パターンの推移と信頼度の大きさの推移が示されている。信頼度の推移図における番号は、記憶パターンの番号を示している。図7より学習ステップ数が150[step]で「大」と「水」が記憶され、信頼度がともに1.00と高くなっていることがわかる。同時に、「大」に似たパターンも記憶されているが、提示回数が少ないため、信頼度は0.17と低くなっていることがわかる。この記憶パターンはシステムにとって不必要である。但し、もしこの入力パターンの提示回数が増加し続けた場合、この入力パターンは提示回数が多くなり環境の特徴を表現するパターンとなるため、必要なパターンとなる。150[step]経過した後、環境が1から2へ変化する。150~170[step]で信頼度の低い不必要な記憶パターンが素早く消え去り、新たな記憶パターンに変更されていることがわかる。この処理は記憶容量に制約があるときは極めて重要である。また、信頼度の高い記憶の「大」、「水」は保持され、信頼度の低い記憶パターンが消え去り新たな入力パターン「犬」、「氷」を記憶していることがわかる。更に、本システムは入力パターンのばらつきを吸収し、かつ重みベクトルの初期値依存性が少ない。

図8、図9には、信頼度の尺度を利用しないシステムに対する記憶パターンの推移が示されている。シミュレーション結果は重みベクトルの初期値にかなり依存したものとなる。多くの場合が図8のような結果となり、「大」と「水」を同じ記憶パターンで記憶するため、混同した記憶パターンが生成されてしまう。これは、入力パターンを記憶する記憶パターンを決定するときに、記憶パターンの信頼度に応じた角度しきい値を利用していないためである。また、初期重みベクトルによっては、図9の結果となる。このときの追加学習性についてみると、信頼度に応じた角度しきい

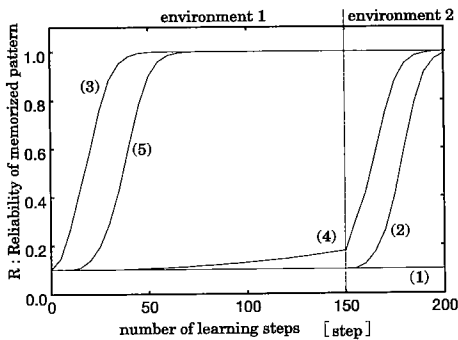
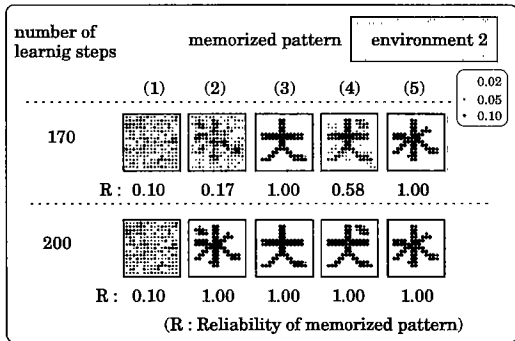
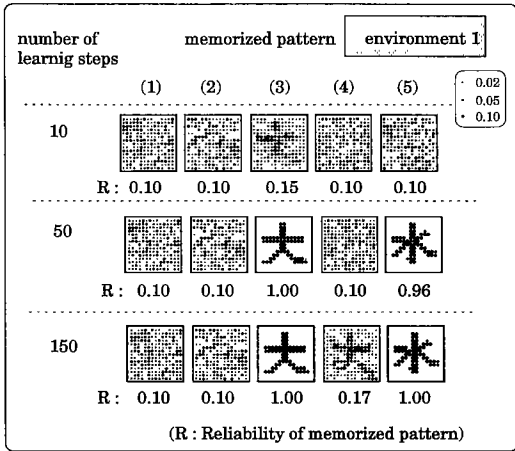


図7 追加学習性
Fig.7 Supplemental learning.

値がないため、信頼度の低い記憶パターンで新たな入力パターンを記憶することができず、結果的に以前に記憶した重要な記憶パターン「大」、「水」を壊すことになる。

以上の結果から、記憶パターンの信頼度を利用した本システムは、記憶容量に制約があるとき追加学習





図8 追加学習性：従来のシステムによる記憶処理 (1)
Fig.8 Supplemental learning: conventional system (1).





図9 追加学習性：従来のシステムによる記憶処理 (2)
Fig.9 Supplemental learning: conventional system (2).

性に優れていることがシミュレーションにより検証できた。

5.2 記憶パターンの逐次的な利用

記憶パターンの信頼度を利用することにより、記憶パターンの逐次的な利用が可能となることをシミュレーションにより検証する。ここでは、記憶パターンの信頼度を利用しない場合との比較検討を行う。

シミュレーション結果を図10に示す。この結果は、図7における記憶パターンの推移に対して、想起パターンを調べたものである。学習ステップ数が50[step]のときの想起パターンをみると、信頼度の尺度を利用した場合(a)は、「大」が想起されていることがわかる。それに対して信頼度の尺度を利用しない場合(b)


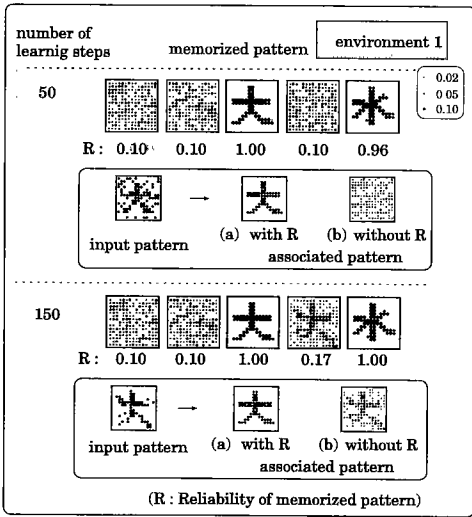


図10 記憶パターンの逐次的な利用：記憶パターンの信頼度を利用した想起処理 (a) と記憶パターンの信頼度を利用しない想起処理 (b)
 Fig.10 Supplemental association: with reliability (a) and without reliability (b).

は、意味のない記憶パターンが想起されている。また、学習ステップ数が 150 [step] のときの想起パターンをみると、信頼度の尺度を利用しない場合 (b) では、システムにとって不必要な記憶パターンが想起されていることがわかる。学習ステップ数が 170 [step] のときも同様な結果が得られている。

このことより、信頼度の尺度を利用することにより、記憶パターンの逐次的な利用が可能となることがシミュレーションにより検証できた。

5.3 提示回数の少ない入力パターンに対する記憶パターン

ここでは、提示回数の少ない入力パターンに対する記憶パターンについて考察する。本システムでは、提




図11 提示パターン：環境3
 Fig.11 Presented patterns: environment 3.

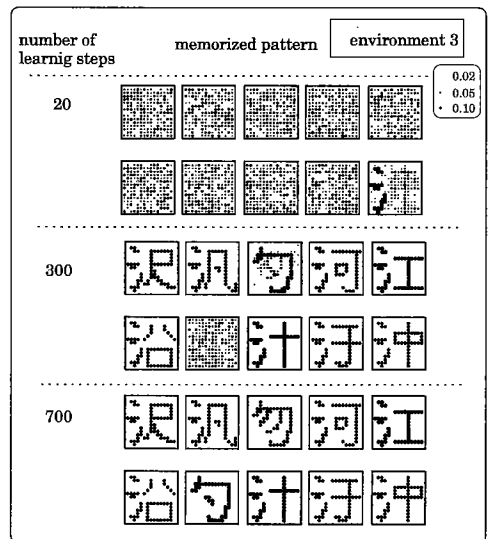


図12 提示回数の少ないパターンに対する記憶パターン
 Fig.12 Memorized patterns of input patterns presented sometimes.

示回数の少ない入力パターンをまとめて記憶することで、パターン群としての全体の特徴を素早くとらえることが可能となり、記憶パターンの逐次的な利用に適している。

システムに提示するパターンを図11に示す(環境3)。また、図12に環境3における記憶パターンの推移のシミュレーション結果を示す。ここでは、競合層ユニット数を $n_1 = 10$ とした。図より学習ステップ

数が20[step]という短い時間で、環境3に存在するパターンの特徴である「さんずい」が記憶パターンとして表現されているのがわかる。また、学習ステップ数が300[step]で、「勺」と「勿」という極めて提示回数少ないパターンに対しても、共通特徴である「つつみがまえ」を抽出して記憶しているのがわかる。このことから、本システムは提示回数の少ないパターンの特徴を反映したシステムとなっていることがわかる。この結果は、即応性が要求される逐次学習における記憶パターンの逐次的利用に対して極めて重要である。

6. むすび

本論文では、逐次処理を目的とした新たな連想記憶システムを構築するため、記憶パターンの信頼度の尺度を提案した。提案したシステムについて、(1)記憶容量の制約と追加学習性、(2)記憶パターンの逐次的な利用、(3)提示回数の少ないパターンに対する記憶という観点から考察を行い、シミュレーションにより有効性を示した。

今回は提示回数により記憶パターンの信頼度を定義した上で、一度信頼度が高くなった記憶パターンは極めて重要であり維持するという立場をとったが、動的な環境を対象とした場合には問題が残る。今までに多く提示され信頼度が高くなった記憶パターンであっても、環境が変化していき、全く提示されなくなったのであるならば、この記憶パターンの信頼度は高いとは言えない場合がある。記憶容量の制約を考えると、この信頼度の高くない記憶パターンで新たな提示回数の多い入力パターンを記憶すべきである。この場合、提示回数ではなく、提示頻度に応じて信頼度を定義することが考えられ、今後検討を行う必要があると考えている。

文 献

- [1] 若山公威, 岩田 彰, “複合連想ニューラルネットワークによる手書き住所認識,” 信学技報, NC94-141, 1995.
- [2] 丹羽寿男, 山本浩司, 小島良宏, 木泰泰治, 荻嶋一弘, 丸野進, “パターンと記号の統合化処理による文字認識,” 信学論 (D-II), vol.J78-D-II, no.2, pp.263-271, Feb. 1995.
- [3] 香田敏行, 丸野 進, 小島良宏, 阪上茂生, 山本浩司, 木泰泰治, “適応増殖量子化ニューロンによるニューラルネットの追加学習性,” 信学技報, NC91-52, 1991.
- [4] G.A. Carpenter and S. Grossberg, “The ART of adaptive pattern recognition by a self-organizing neural network,” IEEE Computer, vol.21, no.3, pp.77-88, 1988.
- [5] 松岡清利, 河本 満, “反ヘブ則を用いた線形ニューラルネットの学習,” 信学論 (D-II), vol.J78-D-II, no.4, pp.661-669, April 1995.

- [6] J.ハーツ, A.クロー, R.G.パルマー著, 笹川辰弥, 呉 勇訳, “ニューラルコンピュータ:統計物理学からのアプローチ,” トッパン, 1994.
- [7] T.コホネン著, 徳高平蔵, 岸田 悟, 藤村喜久郎訳, “自己組織化マップ,” シュプリンガー・フェアラーク東京, 1996.
(平成9年7月14日受付, 12月25日再受付)



芳澤 伸一 (学生員)

1994名古屋大・工・電気卒。1996同大大学院博士課程前期課程了。現在、同大学院博士課程後期課程に在学中。ニューラルネットワークに関する研究に従事。電気学会、計測自動制御学会各会員。



道木 慎二 (正員)

1995名大大学院工学研究科博士課程後期課程電子機械工学専攻了。同年4月同助手、現在に至る。博士(工学)。主として、制御理論のモータドライブへの応用、記憶・認識システムに関する研究に従事。IEEE、電気学会、計測自動制御学会各会員。



大熊 繁

1972名大大学院修士課程電気工学専攻了。1974ケース・ウェスタン・リザーブ大学大学院修士課程システム工学専攻了。1977名大大学院博士課程電気工学専攻了。同年、名古屋大学工学部電気学科助手、講師、助教授を経て1990同教授、現在に至る。主としてロボティクス、パワーエレクトロニクス、創発型ソフトコンピュータに関する研究に従事(工博)。1992IEEE IECON Best Paper Award, 1994精密工学会論文賞, 1995電気学会論文賞をそれぞれ受賞。電気学会、システム制御情報学会、日本機械学会、日本ロボット学会、IEEE各会員。