

手続き的知識を獲得する連想記憶モデル

郷古 学[†] 菅谷 至寛[†] 阿曾 弘具[†]

[†] 東北大学大学院工学研究科電気・通信工学専攻 〒980-8579 仙台市青葉区荒巻字青葉 05

E-mail: †{gouko,sugaya,aso}@aso.ecei.tohoku.ac.jp

あらまし 従来の連想記憶モデルを用いた知的システムは予め用意された知識を学習後に利用する．そのため，与えられた知識を逸脱するような環境に対する適応能力はきわめて低い．そこで本研究では，周囲の環境から逐次的に手続き的知識を獲得することが可能な連想記憶モデルを提案する．提案モデルに関して計算機実験を行い，環境に適応した手続き的知識が獲得可能であることを検証した．

キーワード 連想記憶モデル，手続き的知識，ニューラルネットワーク

Associative Memory Model to Acquire Procedural Knowledge

Manabu GOUKO[†], Yoshihiro SUGAYA[†], and Hirotomo ASO[†]

[†] Department of Electrical and Communication Engineering,

Graduate School of Engineering, Tohoku University

05 Aoba, Aramaki, Aoba-ku, Sendai, 980-8579, Japan

E-mail: †{gouko,sugaya,aso}@aso.ecei.tohoku.ac.jp

Abstract Intelligent systems using conventional associative memory model learn the knowledge which is prepared in advance. Therefore they have poor adaptability to the environment different from what the knowledge assumes. In this study, we propose an associative memory model to acquire procedural knowledge sequentially from surroundings of the model. We carried out computer simulations and confirmed that the proposed model acquires procedural knowledge which is suitable for the environment.

Key words associative memory model, procedural knowledge, neural network

1. ま え が き

情報化社会の高度化に伴い，人間の持つ情報処理能力をモデル化し，工学的に応用した知的システムの構築への注目が高まっている．このようなシステムの構築を目的として，人工知能，ファジィ，ニューラルネットワークなどの工学分野のみならず，認知科学の知見も取り入れた，非常に学際的な研究がなされている [1]．

知的システムの構築に関する従来の研究の多くは，システムの持つ各機能をモジュールに分解して考えていた．しかし近年，事前知識をシステムに学習させることが容易であることや，汎化性の高さ，更にはシステムの柔軟性という観点からニューラルネットワークを用いた研究も盛んに行われている [2]～[4]．

知的システムの構築は，我々人間の持つ知識をシステムにインプリメントすることにより実現される．人間の持つ知識は宣言的知識と手続き的知識の二種類に分類出来る．宣言的知識は様々な事実に関する知識であり，手続き的知識は手順に関する知識である．Newellの提案したプロダクションシステムをはじめ

めとして，これまでに手続き的知識を利用した多くのシステムが提案されてきた [5] [6]．

ニューラルネットワークにより知識を表現する場合は一般に連想記憶モデルが用いられる．連想記憶モデルは学習により情報（知識）をネットワークに蓄えることが可能であり，これまでに多くの連想記憶モデルが提案されてきた [7] [8]．連想記憶モデルにより手続き的知識を表現する場合，現在実行中の手続き A と，その次に実行すべき手続き B の間の連合を作ることで表現することが可能である．すなわちモデルに対して，入力 A に対し，次の手続きである B を想起（出力）するように記憶（相互連想記憶）を形成することで表現可能である．また得られた出力情報を入力としてフィードバックすることで，複数の手順から構成される手続き的知識を表現することも可能である．平井は連想処理モデル HASP (Human Associative Processor) を用いて，手続き的知識の表現を行なった [9]．

従来の連想記憶モデルを応用した知的システムの多くは，予め記憶する情報，つまり知識が準備されており，システムの利用はそれらの知識の学習が完了した時点で開始される．そのた

めに、学習した知識を逸脱する環境においてはシステムが機能しないという問題が生じる。このような問題に対する一つの解決法として、システムが周囲の環境から得られる情報を基に、逐次的に追加学習を行って新しい知識を獲得し、環境に適応していく方法が考えられる。

逐次学習を行う場合、今までに記憶した情報を保持しつつ、新たな情報を記憶する追加学習能力が求められる。さらに実装を考慮するならば記憶容量の制約を考える必要がある。こういった観点から、芳澤ら [10] は「記憶パターンの信頼度」という概念を導入し、限られたリソースの下で逐次学習可能な連想記憶システムを提案している。彼らは、システムへ提示されるパターンはそのシステムが置かれた環境を反映しており、特にシステムへの提示回数の多いパターンほど環境において重要なパターンであるという考えから、パターンの提示頻度により「記憶パターンの信頼度」を決定し、それをを用いることで周囲の環境において重要なパターンを優先的に記憶するシステムを提案している。

しかしながら芳澤らの提案するモデルは、提示されたパターンを記憶する自己連想記憶モデルであり、手続き的知識を表現することは出来ない。そこで本研究では、環境から提示される情報の順番、入力間隔及び頻度に依存して、逐次的に手続き的知識を獲得することが可能な連想記憶モデルを提案する。

提案モデルは、芳澤ら [10] の提案した自己連想記憶モデルを基に、新たに相互連想記憶処理を加え両者を連携させる機構を組み込んだもので、より一般性の高い手続き的知識の獲得を実現している。このモデルの構築により、環境に適応的に手続き的知識を獲得する知的システムの構築が可能となる。

以下、2. では手続き的知識とモデルへの入力情報の関係についての仮定を述べる。3. では提案モデルの構造、定式化及び動作についての説明を行う。4. では計算機実験を行い、提案モデルの動作について検証を行う。5. ではまとめを述べる。

2. 手続き的知識の構築

本稿では「 A の次に B 」というように 2 つの情報 (A, B) から構成される手順を手続き的知識の 1step と考え、「 $A \rightarrow B$ 」と表す。このような知識はモデルに対して情報 A が入力された時に、その次の手順である情報 B を出力することで表現される。従来の連想記憶モデルに、「 $A \rightarrow B$ 」という手続き的知識を記憶させる場合、入力 A に対して出力 B となるように予め学習させることで実現していたが、本研究では「 $A \rightarrow B$ 」という関係が事前に与えられない場合を考える。提案モデルは、周囲の環境から入力される情報を基に「 $A \rightarrow B$ 」という手続き的知識を自律的に獲得する。モデルが「 $A \rightarrow B$ 」という知識を獲得するにあたり、以下のような傾向があると仮定する。

- (1) モデルに対して B よりも前に A が入力される。
- (2) A が入力されてから、 B が入力されるまでの時間が短いほど、「 $A \rightarrow B$ 」という知識が獲得されやすい。
- (3) モデルに対して情報 A, B の入力頻度が高く、かつ入

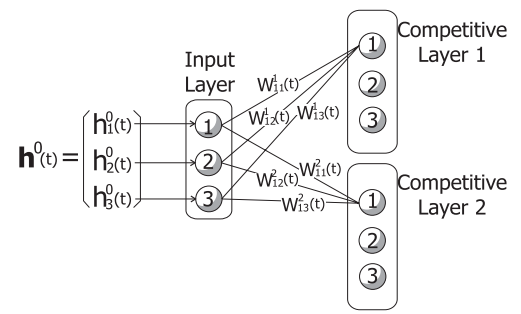


図 1 Sstructure of the proposed model ($m_0 = 3, m_1 = 3$).

力の時間的傾向が (1), (2) に従うものであれば、モデルの周囲の環境における「 $A \rightarrow B$ 」という知識の一般性が高い。

(1) は、 A と B の発生する順序を規定する。また (2) は二つの情報の入力される時間が短いほど、それらの情報の因果関係が強い傾向にあることを意味し、逆にそれぞれの情報が入力される間隔が長いほど、二つの情報の因果関係は弱く、独立した情報と考える。(3) は知識の一般性について考慮したものであり、入力頻度が高い場合は一般的な知識とし、逆に頻度が低い場合は、特別な知識と考える。本研究では、より一般的な知識ほど、獲得すべき知識と考える。

3. 提案モデル

提案モデルの構造を図 1 に示す。モデルは m_0 個のニューロンからなる入力層、それぞれ m_1 個のニューロンからなる 2 つの競合層からなり、入力層の各ニューロンは各競合層の全てのニューロンと全結合している。時刻 t における入力層の i 番目のニューロンと、競合層 $n (= 1, 2)$ の j 番目のニューロンとの結合重みを $W_{ji}^n(t)$ と表す。 j 番目のニューロンへの結合重みをベクトル表現し、 $\mathbf{W}_j^n(t) = (W_{j1}^n(t), W_{j2}^n(t), \dots, W_{jm_0}^n(t))$ とおく。提案モデルにおいて、自己連想記憶情報及び、相互連想記憶情報はそれぞれ競合層 1, 2 のニューロンの結合重みに蓄えられる。

また、各競合層の全てのニューロンは、記憶パターンの信頼度 $R_j^n(t)$ と角度閾値 $\theta_{max,j}^n(t)$ の 2 つのパラメータを持つ。さらに各競合層の j 番目のニューロンは、共通の発火パラメータ $p_j(t)$ を持つ。競合層 1 から 2 へは発火パラメータを通じて影響を与える。

提案モデルは想起処理と記憶処理の 2 つの処理から成る。

3.1 想起処理

入力パターンはベクトルとして扱う。時刻 t における入力パターンベクトルを $\mathbf{h}^0(t) = (h_1^0(t), h_2^0(t), \dots, h_{m_0}^0(t))$ とする。入力層では正規化処理を行う。すなわち、入力層のニューロン i の出力 $V_i^0(t)$ は次式で定まる。

$$V_i^0(t) = \frac{h_i^0(t)}{\|\mathbf{h}^0(t)\|} \quad (i = 1, 2, \dots, m_0) \quad (1)$$

競合層 $n (= 1, 2)$ では、各ニューロン j の出力 $V_j^n(t)$ を次式で決める。

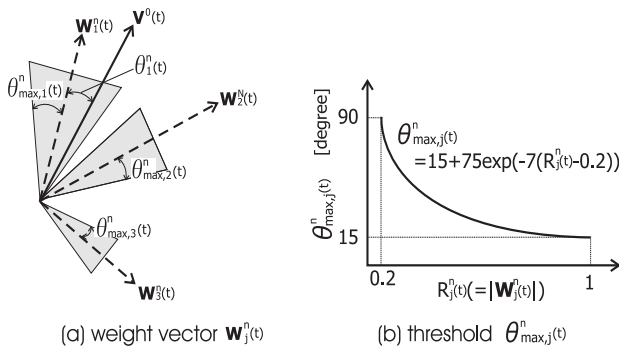


図 2 Weight vector $\mathbf{W}_j^n(t)$ and threshold $\theta_{max,j}^n(t)$.

$$V_j^n(t) = \sum_{i=1}^{m_0} W_{ji}^n(t) V_i^0(t) \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (2)$$

重みベクトル $\mathbf{W}_j^n(t)$ の大きさをニューロン j の記憶パターンの信頼度 $R_j^n(t)$ と呼ぶ。

$$R_j^n(t) = \|\mathbf{W}_j^n(t)\| \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (3)$$

入力層の出力をベクトル表現し、 $\mathbf{V}^0(t) = (V_1^0(t), V_2^0(t), \dots, V_{m_0}^0(t))$ とおく。 $\mathbf{V}^0(t)$ と $\mathbf{W}_j^n(t)$ のなす角度 $\theta_j^n(t)$ は以下の式で表される。

$$\theta_j^n(t) = \cos^{-1} \left(\frac{V_j^n(t)}{R_j^n(t)} \right) \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (4)$$

これらを用いると、 $V_j^n(t)$ は以下の式で表せる。

$$V_j^n(t) = R_j^n(t) \cos \theta_j^n(t) \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (5)$$

連想出力のためにニューロン j^r を競合層 1 において、次の手順により決定し、選択ニューロンと呼ぶ (図 2(a) 参照)。

- (1) 式 (2) において $V_j^1(t)$ を最大とする j を選択する。
- (2) $\theta_j^1(t) \leq \theta_{max,j}^1(t)$ ならば、 $j^r = j$ とする。
- (3) そうでない場合は j を除いて、(1)、(2) の操作を繰り返し、選択ニューロンを決定する。
- (4) 全ての j で $\theta_j^1(t) > \theta_{max,j}^1(t)$ ならば、記憶パターンの想起を行わず、後述の重みベクトルの更新も行わない。

図 2(a) の例では、 $j^r = 1$ となる。

競合層 1 の想起パターン $y_i^1(t)$ は、自己連想記憶パターンであり、選択ニューロン j^r の重みベクトルとする。すなわち、

$$y_i^1(t) = W_{j^r i}^1(t) \quad (i = 1, 2, \dots, m_0) \quad (6)$$

競合層 2 の想起パターン $y_i^2(t)$ は、相互連想記憶パターンであり、選択ニューロン j^r の重みベクトルとする。すなわち、

$$y_i^2(t) = W_{j^r i}^2(t) \quad (i = 1, 2, \dots, m_0) \quad (7)$$

3.2 記憶処理

記憶処理では、入力パターンを記憶するために、各競合層のニューロンの重みを更新する自己連想記憶処理及び、相互連想記憶処理に加え、忘却処理、更に角度閾値と発火パラメータの更新が行われる。

自己連想記憶情報は、競合層 1 のニューロンの結合重みに蓄えられる。選択ニューロン j^r について、式 (8) に示す Oja 則 [11] を用いて、重みベクトルを更新する (自己連想記憶処理)。

$$W_{j^r i}^1(t+1) = W_{j^r i}^1(t) + \eta_1 V_{j^r}^1(t) (V_i^0(t) - V_{j^r}^1(t) W_{j^r i}^1(t)) \quad (i = 1, 2, \dots, m_0) \quad (8)$$

ここで、 η_1 はある定数で、学習係数である。更新により重みベクトルと入力パターンベクトルのなす角は減少する。つまり入力パターンは重みベクトルの向きとして記憶される。重みベクトルの大きさは、重みベクトルが (8) 式で更新されるごとに増加し 1 に収束する [11]。すなわち、記憶パターンの信頼度 $R_j^1(t)$ は入力パターンの提示回数に対応して増加する。

相互連想記憶情報は競合層 2 のニューロンの結合重みに蓄えられる。入力パターンにより重みの更新が行われるニューロン j^u を競合層 2 において、次の手順により決定し、選択ニューロンと呼ぶ。

- (1) $j = j^r$ を除く全ての競合層 2 のニューロンにおいて、発火パラメータ $p_j(t)$ が最大である j を選択する。
- (2) $\theta_j^2(t) \leq \theta_{max,j}^2(t)$ ならば、 $j^u = j$ とする。
- (3) そうでない場合は j を除いて、(1)、(2) の操作を繰り返し、選択ニューロンを決定する。
- (4) 全ての j で $\theta_j^2(t) > \theta_{max,j}^2(t)$ ならば、後述する重みベクトルの更新を行わない。

選択ニューロン j^u は、発火パラメータが角度条件付きで最大となるニューロンであり、競合層 1 のニューロン j^u は、一時刻前に入力されたパターンを記憶したニューロンであることが期待されている。そこで、重みベクトル $\mathbf{W}_{j^u}^2(t)$ を次式で更新する (相互連想記憶処理) ことにより、一時刻前の入力パターンに対して想起すべき今回の入力パターンを記憶させる。

$$W_{j^u i}^2(t+1) = W_{j^u i}^2(t) + \eta_2(t) p_{j^u}(t) V_{j^u}^2(t) (V_i^0(t) - V_{j^u}^2(t) W_{j^u i}^2(t)) \quad (i = 1, 2, \dots, m_0) \quad (9)$$

ここで η_2 は定数で学習係数である。

記憶パターンの学習により信頼度が増していくと、新しい環境に適應できなくなる。そこで、次の忘却処理を導入する。ただし ($j = j^r, j^u$ に対しては、次式の右辺の $\mathbf{W}_{j^r}^1(t), \mathbf{W}_{j^u}^2(t)$) は、既に更新した $\mathbf{W}_{j^r}^1(t+1), \mathbf{W}_{j^u}^2(t+1)$ を意味し、忘却処理により更に更新するものとする。

$$W_j^n(t+1) = \begin{cases} \frac{R_j^n(t) - R_{red}}{R_j^n(t)} W_j^n(t) & \text{if } R_j^n(t) > R_{min} \\ \frac{R_{min}}{R_j^n(t)} W_j^n(t) & \text{otherwise} \end{cases} \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (10)$$

ここで R_{red} は入力パターンが 1 回提示されたときの重みベクトルの減少量であり、 R_{min} は重みベクトルの大きさの下限である。この処理の導入により、一度、あるパターンが頑健な記憶として形成されたとしても、その後、そのパターンの提示回数が減少した場合、記憶パターンの信頼度は徐々に低下し、新たに重要な入力パターンを記憶することが可能となる。このことにより記憶容量の制限下においても、効率の良い記憶を行うことが可能となる。 R_{red} 、 R_{min} は適切な値を設定する必要があり、本研究では文献 [10] において述べられているこれらの値の設定指針を参考にし、 $R_{red} = 0.0003$ 、 $R_{min} = 0.2$ とした。

次に、各競合層の全てのニューロンの持つ角度閾値 $\theta_{max,j}^n(t)$ を次式に従って更新する。

$$\theta_{max,j}^n(t+1) = f(R_j^n(t)) \quad (j = 1, 2, \dots, m_1, n = 1, 2) \quad (11)$$

ただし、 f は $f(x) = 15 + 75\exp(-7(x - 0.2))$ という関数である。概形を図 2(b) に示す。これにより、信頼度が高い記憶パターンは信頼度が低い記憶パターンと比較して小さな角度閾値を持つため、新しい入力パターンに対して影響を受けにくく頑健になる。また初期状態 ($t = 0$) において、全ての角度閾値は 90 度とする。

続いて、発火パラメータ $p_j(t)$ を更新する。

$$p_j(t+1) = \begin{cases} R_j^1(t) & \text{if } j = j^r \\ p_j(t) - e & \text{otherwise} \end{cases} \quad (j = 1, 2, \dots, m_1) \quad (12)$$

ただし、 $p_j(t+1) < 0$ の場合は、0 に再設定する。この更新は、モデルに入力されたパターンに対して、競合層 1 の選択ニューロン j^r の持つ発火パラメータを、その記憶パターンの信頼度 $R_{j^r}^1(t)$ に一致させ、そのほかのニューロンの発火パラメータを減衰パラメータ e により減衰させている。また初期状態において、全ての発火パラメータは 0 とする。従って $p_j(t)$ は 0 から 1 の値とる。 $p_j(t) > 0$ である時、ニューロン j を発火状態と呼ぶ。

初期状態のモデルに対して、2 つの異なるパターンが続いて入力される場合を例に、モデルの動作について説明する。まず最初に入力されたパターンに対して自己連想および相互連想が行われる。続いて、競合層 1 のニューロン j^r の持つ重みベクトルが更新される。また同時に相互連想記憶処理が行われる。しかし ($j = j^r$) を除く全てのニューロンにおいて $p_j(t) = 0$ であるために、競合層 2 の重みベクトルの更新は行われない。続いて忘却処理、更に角度閾値と発火パラメータの更新を行う。モデルに対して入力終了し、次の入力となされるまでの間、式




図 3 Series of input patterns.

入力層のサイズ	$m_0 = 49$ neurons
競合層のサイズ	$m_1 = 2$ neurons
学習係数	$\eta_1 = \eta_2 = 0.01$
減衰パラメータ	$e = 0.1$

表 1 Parameters.

(12) により発火パラメータの更新のみを行う。これにより全ての発火パラメータが減衰していく。

続いてモデルに対して別のパターンが入力されたときの記憶処理では、競合層 1 において自己連想記憶処理が実行され、競合層 2 において、先に入力されたパターンに対して発火していたニューロンの発火パラメータが $0 < p_j(t)$ を保っている場合、そのニューロンの持つ重みベクトルが式 (9) により更新される。つまり、先に入力されたパターンに対して競合層 1 で発火したニューロン番号と同じ番号の競合層 2 のニューロンの持つ重みベクトルが後から入力されたパターンに更新されることになる。この様にして提案モデルでは、入力されるパターンの入力間隔に応じて、過去の入力パターンに対応するニューロンの位置に、現在の入力パターンを競合層 2 に記憶する、つまりモデルは手続きの知識の 1step を獲得したことになる。

4. 実験結果及び考察

提案モデルが周囲の環境から入力される情報の順番、入力間隔及び頻度に依存して、手続きの知識を獲得することを数値実験により検証する。

4.1 情報の入力間隔と知識の獲得

提案モデルは、異なる情報が続けて入力される場合、それらの情報間の因果関係は、情報が入力される時間間隔 (以下 interval と呼ぶ) に依存する。具体的には「 $A \rightarrow B$ 」という手続きの知識を獲得する場合を考えると、2 つの情報 (A, B) がモデルに対して入力されるにあたり、interval が短いほど、少ない記憶処理回数で、信頼度の高い相互連想記憶が形成されることが期待され、逆に interval が長いほど、相互連想記憶が形成されにくくなる。そこで interval の長さが相互連想記憶の形成に及ぼす影響について実験を行った。

実験では提案モデルに対して図 3 に示す 7×7 の 2 種類のドットパターンを $A \rightarrow B \rightarrow A \rightarrow B \rightarrow \dots$ と、交互に繰り返し入力する。各パターンの入力となされると、モデルは記憶処理を 1 回行うとする。すなわち、パターン A がモデルに対して入力された場合、モデルは記憶処理を 1 回行い、その後、次の入力 (B) がなされるまでの間、すなわち interval の間はモデルは発火パラメータの更新のみを行うとする。interval = l であるならば、interval 間に発火パラメータの更新を l 回行うとする。次にパターン B が入力されると、モデルは記憶処理を 1 回行




図 4 Change of Reliability of memorized patterns.

い、次の入力 (A) がなされるまで発火パラメータの更新だけを行う。このような動作を繰り返し行い、相互連想記憶の形成の様子について調べた。実験で用いたパラメータを表 1 に示す。なお、 $A \rightarrow B$ 間と $B \rightarrow A$ 間の interval は等しいとした。

結果を図 4 に示す。このグラフは横軸に記憶処理回数 N 、縦軸を競合層 2 の各ニューロンの記憶パターンの信頼度の平均値としたものである。記憶処理回数の増加に従って信頼度も増加していくことが分かるが、interval が増加する従い、記憶処理回数に対する信頼度の増加率が低下していることが分かる。これは、入力情報間の interval の大きさが、それらの情報間の因果関係に対応し、知識の獲得に影響を与えるというモデルの特徴を表している。さらに interval が 6 以上においては、信頼度の増加が見られない。つまり、記憶されたパターンは信頼度が低く不安定な記憶でしかない。

4.2 情報の入力頻度と知識の獲得

提案モデルは、入力情報の頻度に応じて手続き的知識を獲得すること、すなわち、モデルのおかれた環境に複数の手続き的知識が存在する場合、その中で最も存在比率が高い知識を獲得することが期待される。そこで、情報の入力頻度と手続き的知識の獲得について数値実験を行った。尚、ここで存在比率が高いとは、モデルに対して入力される頻度が高いということの意味する。

実験で用いたネットワークは $m_0 = 49, m_1 = 4$ とし、そのほかのパラメータは表 1 に示したものをを用いた。実験では図 5 に示す 5 種類のドットパターン (A, B, C, D, E) を用い、モデルに対して $A \rightarrow B \rightarrow C \rightarrow D$ (入力セット 1) と、 $A \rightarrow B \rightarrow E \rightarrow D$ (入力セット 2) の、2 つの入力セットを用いて学習を行った。それぞれの入力セットは、異なる手続き的知識を表現している。実験では各パターンの入力に伴い記憶処理を 1 回行うとし、パターン間の interval は全て 0 とした。すなわち、入力セット 1 の場合、モデルに A を 1 回入力した後、 B を 1 回入力し、続いて C を 1 回入力し最後に D を 1 回入力する。つまり 4 ステップで 1 つの入力セットの入力を終了する。これに続く入力セットは確率 s_1 で入力セット 1 を、確率 s_2 で入力セット 2 を選択する。実験は $t = 0$ から 30000 まで行った。実験では $t = 0$ から 15000 (以下 env1 と呼ぶ) では、 $(s_1, s_2) = (0.8, 0.2)$ とし、 $t = 15001$ から 30000 (以下 env2 と呼ぶ) では、 $(s_1, s_2) = (0.2, 0.8)$ とした。この様にすることで、2 つの手続き的知識が異なる頻度で存在する環境を作り出している。env1 は入力セット 1 が主な手続き的知識として存在する環境を表しており、env2 は入力セット 2 が主な手続き的知識




図 5 Input sets.




図 6 Memorised patterns.

として存在する環境を表している。提案モデルは env1 においては入力セット 1、env2 においては入力セット 2 で表される手続き的知識を獲得することが期待される。実験結果を図 6 に示す。この図は重みベクトルの各成分の大きさを、信頼度で正規化して得られた記憶パターンを表したものである。各パターンの下に記した数字は、その記憶パターンの信頼度である。各時刻の結果で、上段が競合層 1 の記憶パターン (自己連想記憶)、下段が競合層 2 の記憶パターン (相互連想記憶) である。上下の各パターンは同じ番号のニューロンを表しており、図中の括弧内の数字がニューロンの番号である。モデルは上段のパターンが入力として与えられた場合、下段の記憶パターンは次に入力されるはずのパターンを記憶できるようになることが期待されている。

$t = 1000$ を見ると、各ニューロンにおいて、まず自己連想記憶の形成が行われている様子が分かる。相互連想記憶に関しては、自己連想記憶の信頼度が低いことから、記憶の形成がほとんど進んでいない。またパターン A, B, D に関する自己連想記憶の信頼度が、パターン C に関する信頼度に比べて高くなっているのが分かる。これはパターン A, B, D に関しては 2 つの入力セットに共通して含まれているパターンであり、提示回数が入力セットの選択確率に依存せず、パターン C に比べ入力頻度が高いためであると考えられる。

次に $t = 3000$ を見ると、各ニューロンの自己連想記憶及び、相互連想記憶パターンの信頼度が高くなっているのが分かる。




図7 Change of parameter $p_n(t)$.

またニューロン2に着目すると、自己連想記憶としてパターンB、相互連想記憶として期待されるパターンCではなく、パターンDを記憶している。これはパターンDが入力された時の相互連想記憶処理において、ニューロン3ではなくニューロン2が選択ニューロンになるためである。その原因として、パターンCに関する自己連想記憶の信頼度が低いことから、ニューロン3の発火パラメータが小さかったためと思われる。図7はモデルに対してパターンDが入力された時のニューロン2,3の発火パラメータの変化を示したものである。横軸はtであり、図は400ステップ毎の平均値をプロットしている。この図を見ると、 $t=3300$ 付近までは、ニューロン3に比べニューロン2の発火パラメータの方が常に高い値を示している。つまりパターンD入力時に、相互連想記憶処理においてニューロン2が選択ニューロンとして選択されることを意味する。そのためニューロン2の相互連想記憶としてパターンDが形成される。またパターンCもしくはEが入力された時にも、相互連想記憶処理においてニューロン2が選択ニューロンとして選択される場合があるが、パターンC,Eの入力頻度が、パターンDと比べて低いこと、さらにintervalが0であり、発火パラメータの減少量が少ないことなどの要因により、パターンC,EではなくパターンDがニューロン2の相互連想記憶として形成されたと考えられる。相互連想記憶の形成におけるこのような性質は、手続き的知識を獲得する上で、直後に続く手順（この場合パターンC,E）があいまいな場合でも、さらに、その後続く可能性の高い手順（この場合パターンD）により手続きを表現していることになる。つまり、自己連想記憶の信頼度が高いパターンを優先的に相互連想記憶として記憶することで手続き的知識の表現が可能である。このことは、モデルに入力される情報（手順）にあいまいな部分が存在し、知識の獲得が難しい場合に有効に働くと考えらる。

$t=15000$ を見ると、env1に主に存在する、 $A \rightarrow B \rightarrow C \rightarrow D$ という手続き的知識を獲得している。 $t=3000$ の時点でニューロン2の相互連想記憶パターンはDであったが、ニューロン3において自己連想記憶パターンCの信頼度の増加したことで、Bの次のパターンであるCを記憶することが出来た。

続いてenv2における記憶パターンについて見ていく。env2では $A \rightarrow B \rightarrow E \rightarrow D$ という手続き的知識が主に存在する環境である。 $t=20000$ の記憶パターンを見ると、パターンCを記憶していたニューロン3の自己連想記憶の信頼度が低下しているのが分かる、これはenv2においてパターンCより

もEの方が入力頻度が高いためである。このように信頼度が低下した記憶パターンのニューロンで新たに重要な入力パターンを記憶することは、記憶容量に制限がある場合に非常に有効である。またパターンBを自己連想記憶として持つニューロン2の相互連想記憶が、パターンDになっている。図7を見ると、 $t=15000$ から22000の間で、ニューロン3の持つ発火パラメータの値がニューロン2のもつ発火パラメータの値を下回っていることから、 $t=3000$ の時と同様の理由であると考えられる。この場合のニューロン3の発火パラメータの減少は、ニューロン3の自己連想記憶がCからEに変化する際に、信頼度の減少を伴うことが原因である。

$t=25000$ を見ると、ニューロン3の自己連想記憶がパターンEに変化し、その信頼度も高くなっていることが分かる。それに伴いニューロン2の相互連想記憶もパターンDからEへ変化し始める。 $t=30000$ を見ると、env2に主に存在する、 $A \rightarrow B \rightarrow E \rightarrow D$ という手続き的知識を獲得している。

以上の実験より、提案モデルは入力情報の頻度に応じて手続き的知識の獲得が可能であることが分かった。さらに知識の獲得過程において、自己連想記憶の信頼度が高いパターンを優先的に相互連想記憶として記憶することが分かった。

5. ま と め

本稿では、適応的に環境から手続き的知識の獲得が可能な連想記憶モデルを提案した。提案モデルが、モデルに入力される情報の順序、入力間隔及び頻度に応じて、手続き的知識を獲得していくことを数値実験により確認した。特に環境の変化に適応して、手続き的知識が獲得できることが示された。

文 献

- [1] 計測自動制御学会編, "ニューロファジィAIハンドブック," オーム社, 1994.
- [2] 山口亨, 高木友博, 田鍋実, "ファジー連想記憶による知的センサアーキテクチャ," 信学論(C-), vol. J74-C- , No. 5, pp289-299, 1991.
- [3] 橋本智己, 秋田幸治, 山口亨, 宮道壽一, "知的エージェントの基礎認識学習," 電学論(C), vol. 119-C, No. 1, pp124-135, 1999.
- [4] K. T. Blackwell, T. P. Vogl, S. D. Hyman, G. S. Barbour and D. L. Alkon, "A NEW APPROACH TO HAND-WRITTEN CHARACTER RECOGNITION," Pattern Recognit, vol. 25, No. 6, pp655-666, 1992.
- [5] 前田隆, 青木文夫, "新しい人工知能 基本編," オーム社, 1999.
- [6] 市川伸一, "岩波講座 認知科学 5 記憶と学習," 岩波書店, 1994.
- [7] Bart KOSKO, "Bidirectional Associative Memories," IEEE Trans. on Systems, Man, and Cybernetics, vol. 18, No. 1, pp49-60, 1988.
- [8] M. Hagiwara, "Multidirectional Associative Memory," International Joint Conf. on Neural Networks, No. 1, pp. 3-6, Jan. 1990.
- [9] 平井有三, "連想処理モデル HASP による手続き的知識の表現," 信学論(D), vol. J69-D, No. 11, pp1743-1753, 1986.
- [10] 芳澤伸一, 道木慎二, 大熊繁, "記憶容量の制約下での追加学習を目的とする新しい連想記憶システムの提案," 信学論(D-), vol. J82-D- , No. 6, pp1072-1081, 1999.
- [11] J.Hertz, A.Krogh, R.G.Palmer 著, 笹川辰弥, 吳勇 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," トップラン, 1994.