

## カオスニューラルネットワークによる記憶探索モデルの記憶パターンに対する敏感性及その改善

海老原 智哉<sup>†1</sup> 岩井 俊 哉<sup>†1</sup>

多くのカオスシステムのダイナミクスはパラメータ値に対する鋭敏性を示す。同様に、自己想起型カオスニューラルネットワークに基づいた記憶探索モデルの探索性能も記憶パターンに鋭敏である。したがって、記憶探索モデルは記憶パターンを変更するたびに最適なパラメータ値を探す必要があると考えられる。本研究では、自己想起型カオスニューラルネットワークモデルの動的性質を利用して、そのモデルにパラメータダイナミクスを導入することで記憶探索モデルを提案する。次に、提案モデルの探索性能が記憶パターンに鋭敏であることを示す。最後に、pseudo-inverse approachを用いてシナプス結合を形成することで、提案モデルは記憶パターンを変えてもパラメータを変更する必要がない汎用性を持つことを示す。

### Stored Pattern Sensitivity of Memory Search Model by Chaotic Neural Network and Its Improvement

TOMOYA EBIHARA<sup>†1</sup> and TOSHIYA IWAI<sup>†1</sup>

The dynamics of various chaotic systems shows the sensitivity to system parameter values. The searching ability for the memory search model which is based on the auto-associative chaotic neural network model is also sensitive to stored patterns. Thus, we think that parameter tuning for the model is necessary for most of the memory search models to perform well, when patterns stored in the network are changed. First, using dynamical features of the auto-associative chaotic neural network model, we propose a memory search model by introducing the parameter dynamics into the auto-associative chaotic neural network model. Next, the searching ability for our proposed model is shown to be sensitive to stored patterns. Finally, the proposed model with synaptic couplings produced by pseudo-inverse approach has such a versatility that parameter tuning is not needed when stored patterns are changed.

### 1. はじめに

人間や生物の脳・神経系における活動においてカオス的な応答が観測されている<sup>1)-3)</sup>。Skarda ら<sup>1)</sup> はラットの臭い応答の実験を行い、ラットが既知の臭いを嗅いでいるとき嗅球の集合電位がリミットサイクルに落ち込んだような周期応答を示し、未知の臭いを嗅いでいるときカオス的な応答を示し、未知の臭いを繰り返し嗅ぐことで新たなリミットサイクルへ落ち込むような周期応答に変化することを見出した。この結果より、Skarda らは記憶や想起過程においてカオスが何らかの機能的な役割を果たしていると考えた。また、ヤリイカの巨大軸策の膜電位応答実験<sup>2)</sup> においてカオス的な応答が見出され、入力の時空間加算と相対不応性を考慮して Aihara ら<sup>4)</sup> は単一ニューロンでカオス応答を示すカオスニューロンモデルを提唱した。このカオスニューロンを用いて、自己想起の問題に適応した自己想起型カオスニューラルネットワークモデルが Adachi ら<sup>5)</sup> によって提唱された。自己想起型カオスニューラルネットワークは複数の記憶したパターンをカオス的に想起したり、周期的に想起したり、ホップフィールドモデル<sup>6)</sup> のように1つの記憶したパターンを想起したりする等、様々な動的な挙動を示すことが確認されている<sup>5),7),8)</sup>。記憶したパターンをめぐるカオス的な状態とホップフィールド的に記憶パターンに収束する状態を利用し、カオス的な状態で記憶の探索を行いホップフィールド的な状態で探索対象の記憶パターンに収束させるいくつかの記憶探索モデルが考案されている<sup>9)-14)</sup>。これらの記憶探索モデルでは、動的状態間の遷移を制御する必要があり、モデル間の相違点は制御の方法にある。出口ら<sup>9),10)</sup> はシナプス前抑制を想定しシナプス結合度を制御信号で抑制し、記憶探索モデルを提案している。彼らはバックプロパゲーションネットワークを用いて、探索対象の記憶パターンと出力の類似性を表す制御信号を作成した。また、彼らはネットワークの記憶パターンが異なると探索の成功率が変わることを示し、成功率は記憶パターン間の相関の度合いに依存していることを示唆している。伊藤ら<sup>11)</sup> は、非単調な出力関数を用いたカオスニューラルネットワークを提案し、探索したい記憶パターンの一部である特徴ベクトルを用いて特徴ベクトルに近い解空間での探索を行う動的制御と特徴ベクトルと出力の類似度である制御信号によるカオス制御を行うことで、出口らの提案したモデルに比べ探索成功率が高いことを示した。さらに、彼らのモデルではパターン間の相関の度合いによる想起の偏りが少なく、記憶パターンとは

<sup>†1</sup> 日本大学  
Nihon University

異なる安定状態（以下、文献 15）に従い混合状態と記述する）に陥ることが少ない探索が可能である。Kushibe<sup>12)</sup>らは、探索対象の記憶パターンの一部分であるサンプルと出力の類似度を制御信号としてサンプルの大きさと探索対象の記憶パターンを想起する度合いの関係を調べた。これらの研究<sup>9)-12)</sup>では、記憶パターンの一部を利用して記憶パターンに収束する探索能力に着目しているが、本研究では上述した Skarda らの実験結果<sup>1)</sup>のように、ネットワークの出力の初期値として表されるパターンがネットワークにとって既知であるか未知であるかを判別して、既知ならばそのパターンに収束させ、未知ならばカオス的に探索を続けるパターン識別能力に着目している。長名ら<sup>13)</sup>は時間的に変化する刺激を自己想起型カオスニューラルネットワークに与え、Skarda らの実験を定性的に再現する追加学習モデルを提案している。また、He ら<sup>14)</sup>は遅延フィードバック制御法を用いてカオスコントロールを行い、特定の記憶パターンに収束させる方法について報告している。

一方、カオスを発生するシステムは、一般的にパラメータ値に対する鋭敏性を持つ。自己想起型カオスニューラルネットワークモデル（以下、本論文では自己想起型カオスニューラルネットワークモデルをカオスニューラルネットワークモデルと略記する）においてネットワークに記憶したパターンはシナプス結合に埋め込まれるため、記憶パターンが異なるとシナプス結合の値が変化することになり、ネットワークの動的状態が変化する<sup>7),8)</sup>。したがって、カオスニューラルネットワークモデルを用いた記憶探索モデルの動作も記憶パターンに鋭敏に依存すると考えられ、ネットワークに埋め込む記憶パターンに適するシステムパラメータを選ぶ必要があると考えられる。上述したように出口ら<sup>10)</sup>のモデルでは探索成功率が記憶パターンに依存することを報告している。彼らは探索成功率が高い内部パターンに記憶パターンを変換し内部パターンで探索を行う方法を提案し、探索成功率を向上させた。伊藤ら<sup>11)</sup>は上述した 2 種類の制御により、記憶パターン間相関が強くても対象パターンの探索ができ、かつ記憶できるパターン数の多いメモリーサーチモデルを提案した。しかしながら、伊藤らのモデルでも記憶パターン間相関の強さに依存してパラメータ値を変更している。

本研究では、Adachi ら<sup>5)</sup>の考案したカオスニューラルネットワークモデルの動的性質を利用して、出口ら<sup>9),10)</sup>のシナプス前抑制と同様の発想でシナプス結合のスケールパラメータに時間依存性を導入することで記憶探索モデルを提案する。提案モデルでは、ネットワークは初期に提示されたパターンを記憶しており、それと現在の出力パターンとの一致度により制御信号を決定する。これをパラメータダイナミクスとしてモデルに組み込み、ネットワークに提示するパターンがネットワークにとって既知であるか未知であるかを判別して、既知ならば対象のパターンに収束し、未知ならばカオス的に探索を続ける記憶探索モ

デルを実現する。出口ら<sup>9),10)</sup>のモデルではバックプロパゲーションネットワークを用いて、探索パターンと出力の類似度を判別し、ネットワークの動的状態の制御を行っているが、本研究ではシナプス結合のスケールパラメータを独立変数としてカオスニューラルネットワークにカップルさせた非線形ダイナミクスモデルで動的状態を遷移させている。次に、記憶パターンを変えた 3 種類の数値実験を行い、提案モデルの探索性能としてパターン識別能力に着目し、パターン識別能力が記憶パターンに鋭敏に依存することを示す。さらに、pseudo-inverse approach<sup>15)</sup>によりシナプス結合を形成することで、パターン識別性能の記憶パターンに対する鋭敏な依存性をなくし、パラメータ調節をしなくても良い汎用性を持つモデルを提案する。

## 2. カオスニューラルネットワークモデルとその性質

### 2.1 カオスニューラルネットワークモデル

本研究で提案する記憶探索モデルは Adachi ら<sup>5)</sup>により提案された次式で表されるカオスニューラルネットワークモデルを基礎とする。

$$x_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)), \quad (1)$$

$$\eta_i(t+1) = k_m \eta_i(t) + \sum_{j=1}^N w_{ij} x_j(t), \quad (2)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (3)$$

$$f(x) = \frac{1}{1 + \exp(-2\beta x)}, \quad (4)$$

ここで、 $x_i(t)$  は時刻  $t$  ステップでの  $i$  番目のニューロンの出力であり、式 (4) の出力関数を用い (0, 1) 間の値をとる。膜電位は異なる減衰定数  $k_m$  と  $k_r$  を持つ 2 つの効果  $\eta_i(t)$  と  $\zeta_i(t)$  の和で表される。 $\eta_i(t)$  は、時刻  $t$  ステップでの  $i$  番目のニューロンの膜電位への他のニューロンからの入力の効果であり、式 (2) 右辺第 2 項が他のニューロンからの入力である。 $w_{ij}$  は  $j$  番目のニューロンから  $i$  番目のニューロンへのシナプス結合である。他方の  $\zeta_i(t)$  は  $i$  番目のニューロンの膜電位の相対不応性効果を表す。式 (3) 右辺第 2 項が相対不応性効果であり、 $\alpha$  はその度合いを調節するパラメータである。また、 $a_i$  は  $i$  番目のニューロンへの外部入力と閾値の和を表している。シナプス結合度は、次式で定義される。

$$w_{ij} = \frac{1}{P} \sum_{\mu=1}^P (2\xi_i^{(\mu)} - 1)(2\xi_j^{(\mu)} - 1), \quad (5)$$

ここで、 $P$  はネットワークに記憶させたパターン数であり、 $\xi_i^{(\mu)}$  が記憶パターン  $\mu$  の  $i$  成分であり、0 または 1 の値をとる．全ニューロンで出力  $x_i(t)$  が  $\xi_i^{(\mu)}$  と等しくなったとき、ネットワークは記憶パターン  $\mu$  を完全想起したことになる．本論文では、ネットワークに埋め込んだ  $P$  個の記憶パターンをまとめて『記憶パターン集合』と呼ぶ．

カオスニューラルネットワークモデルは、 $k_m=k_r=\alpha=a_i=0$  のときホップフィールドモデルに帰着する．したがって、式 (2) 右辺第 2 項の外部入力項が他の項に比べ大きい場合、ネットワークはホップフィールド的な挙動を示す<sup>7),8)</sup>．その性質を用いるため、我々は式 (2) にホップフィールド的な挙動のスケーリングパラメータ  $\lambda$  を導入し、式 (2) の代わりに次式を用いる．

$$\eta_i(t+1) = k_m \eta_i(t) + \lambda \sum_{j=1}^N w_{ij} x_j(t). \quad (6)$$

カオスニューラルネットワークモデルのパラメータには、ニューロン単体の性質を表したパラメータとニューロン間の結合を表したパラメータがある． $k_m, k_r, \alpha, \beta$  は前者に、 $w_{ij}, \lambda$  は後者に属する． $a_i$  は閾値と外部入力という両面の性質を持つパラメータである．現実のニューロンを考えた場合、前者のニューロン固有のパラメータは時間的にほぼ一定の値をとるが、後者のニューロン間の結合に関するパラメータはシナプス可塑性やアセチルコリン等の神経修飾物質の調節により時間的・空間的に変化しうる．そこで、我々の先行研究<sup>7),8)</sup> では、前者のニューロン固有の性質から決まるパラメータを Adachi ら<sup>5)</sup> の研究で用いられている値に固定し、後者のパラメータのうち  $\lambda$  と  $a$  を  $0 \leq a \leq 0.5, 0 < \lambda \leq 3$  の範囲で変化させて、ネットワークの動的性質を数値的に解析した．ただし、 $a_i$  はニューロン番号  $i$  によらず一定と仮定し  $a$  と表している．その結果、 $(a, \lambda)$  の 2 次元パラメータ空間上で  $a$  方向よりも  $\lambda$  方向に対し動的状態の変化が豊富であることが分かった．そこで、本研究ではニューロン固有のパラメータについては Adachi ら<sup>5)</sup> の研究で用いられている値  $k_m = 0.2, k_r = 0.9, \alpha = 1, \beta = 20$  を用い、ニューロン間の結合に関するパラメータ値は我々の先行研究<sup>7),8)</sup> から  $a = 0.5$  と選んだ．また、 $\lambda$  の値を変化させてネットワークの動的状態を調べる．ニューロン数を  $N = 32$ 、記憶パターン数を  $P = 4$  とした．

## 2.2 カオスニューラルネットワークモデルの性質

我々は、カオスニューラルネットワークモデルの動的性質がパラメータ  $\lambda$  の値にどのように依存するか調べるため、動的性質を特徴付ける測定量としてパターン  $A$  の想起率  $R_A$  を

導入する．ただし、本論文では記憶パターンをアルファベットの小文字で表し（たとえば、記憶パターン  $a$ ）、その反転パターンを対応する小文字のアルファベットに上線をつけて表す（たとえば、記憶パターン  $a$  の反転パターンを  $\bar{a}$ ）．また、記憶パターン  $a$  とその反転パターン  $\bar{a}$  をあわせて表記するときには、対応するアルファベットの大文字で（たとえばパターン  $A$ ）と表現する．したがって、以下では記号で記憶パターン・反転パターン・その両者を区別できる場合には、単にパターン  $a$ 、パターン  $\bar{a}$ 、パターン  $A$  等と記述する．数値実験の全ステップを過渡的ステップと計測ステップに分け、計測ステップで記憶パターンと反転パターンの想起率を測定する．各計測ステップでネットワークがどのパターンを想起したか判定し、全計測ステップ  $T$  中でパターン  $a$  あるいは  $\bar{a}$  を想起したステップ数  $T_A$  から、次式で『パターン  $A$  の想起率  $R_A$ 』を定義する．

$$R_A = \frac{T_A}{T}. \quad (7)$$

ただし、パターン  $a$  の想起判定は次の想起条件で行う．

想起条件『式 (8) で定義する出力とパターン  $a$  との規格化したハミング距離  $HD(a)$  を用い、 $HD(a) < 0.05$  が成立したときネットワークはパターン  $a$  を想起したと判定する』．したがって、 $HD(a) > 0.95$  が成立したならば、ネットワークはパターン  $\bar{a}$  を想起したことになる．

$$HD(a) = \frac{1}{N} \sum_{i=1}^N [x_i(t)(1 - \xi_i^{(a)}) + \xi_i^{(a)}(1 - x_i(t))]. \quad (8)$$

さらに、シナプス結合を構成する記憶パターン集合が異なるとネットワークの動的な性質がどのように変化するか調べるために、3 通りの記憶パターン集合を用いて数値実験を行った．以下では、それぞれの記憶パターン集合を説明し、その記憶パターン集合での数値実験で得られた想起率の性質について述べる．

1 つ目の記憶パターン集合を図 1 に示した．図中の 1 列に並んだ 32 個のセルは各記憶パターンの成分であり、黒が 1 を白が 0 を表している．図中の 4 つの記憶パターンは互いに相関を持たない．パターン間の相関は次式で表す内積の絶対値で評価し、値が小さいほど相関が小さいと表現する．

$$\xi^{(\mu)} \cdot \xi^{(\nu)} = \sum_{i=1}^N (2\xi_i^{(\mu)} - 1)(2\xi_i^{(\nu)} - 1). \quad (9)$$




図1 直交パターン集合  
Fig.1 Orthogonal pattern set.




図2 直交パターン集合の想起率 (○:  $R_A$ , △:  $R_B$ , ×:  $R_C$ , +:  $R_D$ )  
Fig.2 Recall ratio for orthogonal pattern set (○:  $R_A$ , △:  $R_B$ , ×:  $R_C$ , +:  $R_D$ ).

この式では、0以上1以下の成分値をとるベクトルをホップフィールドモデルのような成分値が-1以上1以下の双極型のベクトルに変換して内積を定義している。図1の記憶パターン集合中の任意の2つの記憶パターン間の内積値は0であるので、この記憶パターン集合を『直交パターン集合』と名付ける。図2に4つのパターンA, B, C, Dの想起率を $\lambda$ に対してプロットしたグラフを示す。この実験では、出力の初期値である初期提示パターンをパターンaとした。図より、想起率の乱れている $\lambda = 0.9$ 近傍を除いた $\lambda < 1.03$ の領域ではすべてのパターンが同頻度で想起されていることが分かる。 $\lambda < 1.03$ での想起の様子を具体的に調べてみると、出力が全記憶パターンと全反転パターンをめぐることが分かる。この領域でのネットワークの動的状態がカオス的であることを調べるため計測ステップを100万ステップとしてリアブノフ次元を測定したところ、 $0.03 < \lambda \leq 0.64$ でリアブノフ次元が正となるため、カオス的であることが分った<sup>7),8)</sup>。カオスの判定の指標として最大リアブノフ指数を用いる場合が多いが、最大リアブノフ指数が正すなわちカオスである場合はリアブノフ次元も正となり、最大リアブノフ指数が負すなわち非カオスである場合はリアブノフ次元は0である。文献7)では、リアブノフ次元が0である場合を「リアブノフ次元が定義できない」と表現しているが、「リアブノフ次元が0である」と同じ意味であることに注意してほしい。また、 $(\eta_1, \eta_2)$ と $(\zeta_1, \zeta_2)$ の2次元リターンプロットから数値的に情報次元を計算しカオスを生む変数 $\zeta$ の情報次元が $0.03 < \lambda < 1.03$ で約2の一定の値をとった。したがって、この領域で変数 $\{\zeta_i\}$ が軌道不安定性を引き起こしていること示唆され




図3 相関パターン集合  
Fig.3 Correlated pattern set.




図4 相関パターン集合の想起率 (○:  $R_A$ , △:  $R_B$ , ×:  $R_C$ , +:  $R_E$ )  
Fig.4 Recall ratio for correlated pattern set (○:  $R_A$ , △:  $R_B$ , ×:  $R_C$ , +:  $R_E$ ).

る<sup>7)</sup>。さらに、時間的に局所的なりアブノフ次元が $0.64 \leq \lambda \leq 0.75$ の領域で正となったので<sup>8)</sup>、この領域は短時間で局所的に軌道不安定性を生じる弱いカオス的な状態であることが示唆される。以上より $\lambda < 1.03$ では、いわゆるカオスの遍歴<sup>16)-18)</sup>の状態が実現されていると考えられる。そこで、この領域のネットワークの状態を『遷移状態』と呼ぶ。また $\lambda \geq 1.03$ ではパターンaのみを想起率1で想起していることが分かる。これはネットワークがホップフィールドモデルのように振る舞い、初期提示パターンaを自己想起したことを意味する。想起率が1であるのは、過渡的時間内にネットワークの出力がパターンaに収束したためである。そこで、この領域のネットワークの状態を『自己想起状態』と呼ぶ。このようにパラメータ $\lambda$ が小さいとネットワークはカオス的にパターンをめぐり遷移状態をとり、 $\lambda$ が大きいとホップフィールド的に1つの記憶パターンや反転パターンに収束する自己想起状態をとることが分かる。

2つ目の記憶パターン集合は、図1の直交パターン集合に弱い相関を加えた図3に示す記憶パターンから構成される。図3の4つの記憶パターンは直交パターン集合中のパターンdをパターンeに変えたものである。パターンaとeが内積値8の相関を持つが、他の任意の2つの記憶パターン間の内積値は0である。つまりパターンaとe間だけに相関を入れた。この記憶パターン集合を『相関パターン集合』と呼ぶ。相関パターン集合を用いた数値実験で測定した想起率を図4に示す。これは初期提示パターンをパターンaとした実験の結果である。図4より、 $\lambda < 1.03$ の領域は全記憶パターンと全反転パターンを想起

してめぐる遷移状態であるが、パターン  $a$  と  $e$  の間に相関があるためパターン  $B, C$  と比較して  $A, E$  の想起率が大きいことが分かる。この領域でのネットワークの動的状態がカオス的であるかを調べるためリアプノフ次元を測定したところ<sup>7),8)</sup>,  $0.03 < \lambda \leq 0.69$  でリアプノフ次元が正で、カオス的であることが分った。また、 $(\eta_1, \eta_2)$  と  $(\zeta_1, \zeta_2)$  の2次元リターンプロットから数値的に情報次元を計算し変数  $\zeta$  の情報次元が  $0.03 < \lambda < 1.03$  で約2の一定の値をとった。したがって変数  $\{\zeta_i\}$  が軌道不安定性を引き起こしていると示唆される<sup>7)</sup>。さらに、時間的に局所的なりリアプノフ次元が  $0.69 \leq \lambda \leq 0.78$  の領域で正となるので、この領域では弱いカオス的な状態であることが示唆される。以上より、遷移状態はいわゆるカオスの遍歴状態であると考えられる。  $1.03 < \lambda \leq 1.32$  の領域では、 $\lambda$  の値によってパターン  $B$  または  $C$  が想起率1で収束していることが分かる。この状態を詳しく調べると、想起判定をしていない過渡的時間でネットワークはパターン  $B$  と  $C$  を遷移し、やがて  $b, \bar{b}, c, \bar{c}$  のどれかのパターンに収束していることが分かる。過渡的時間内で収束しているため想起率は1となっている。さらに  $1.32 < \lambda < 1.36$  の領域では、互いに相関を持つパターン  $A$  と  $E$  を遷移して想起していることが分かる。そして  $1.36 \leq \lambda$  の領域では、初期提示パターン  $a$  を想起率1で想起する自己想起状態が現れる。図2と図4を比較すると、記憶パターンを少し変えただけでもネットワークの動的状態が異なり、豊富な動的状態が現れることが分かる。このようにカオスニューラルネットワークには、記憶パターンの違いに対する鋭敏性が存在することが分かった。

上述の2つの記憶パターン集合は、記憶パターン間の相関値を定めて作成したという意味で特殊な記憶パターン集合である。後述する記憶探索の提案モデルをこれらの特殊な記憶パターン集合だけで性能評価しても一般性を欠くことになる。そこで、3つ目の記憶パターン集合として図5に示した半数発火ランダムパターンで、想起率の解析結果を示す。なお、リアプノフ次元等のカオスの指標の数値的解析をランダムパターン集合では行っていない。以下では、この3つ目の記憶パターン集合を『ランダムパターン集合』と名付ける。4つの記憶パターン間の内積値は、パターン  $f$  と  $i, g$  と  $i$  間では0であり、パターン  $f$  と  $g$  間は4であり、パターン  $f$  と  $h, g$  と  $h$  間では8であり、パターン  $h$  と  $i$  間では12である。ランダムパターン集合の想起率を図6に示す。この実験では初期提示パターンをパターン  $f$  とした。図より  $\lambda < 1.18$  の領域では、すべての記憶パターンと反転パターンが想起されている遷移状態である。相関が最も強いパターン  $h$  と  $i$  の想起率が他のパターンに比べて大きいことが分かる。また  $1.18 \leq \lambda < 1.65$  では、パターン  $H$  と  $I$  を想起していることが確認できる。その状態を詳しく調べると、パターン  $h$  とパターン  $\bar{i}$  を繰り返して想起する様




図5 ランダムパターン集合  
Fig. 5 Random pattern set.




図6 ランダムパターン集合の想起率  
(○:  $R_F$ , △:  $R_G$ , ×:  $R_H$ , +:  $R_I$ )  
Fig. 6 Recall ratio for random pattern set (○:  $R_F$ , △:  $R_G$ , ×:  $R_H$ , +:  $R_I$ ).

子が分かる。さらに、 $1.65 \leq \lambda$  では初期提示パターンであるパターン  $f$  のみを想起する自己想起状態が現れる。このようにランダムパターン集合でも記憶パターン間の相関に依存して様々な動的状態が現れ、ダイナミクスが記憶パターン集合に対して鋭敏であることが分かる。

### 3. 提案モデル

2.2節で示したように、パラメータ  $\lambda$  はネットワークのホップフィールド的挙動のスケールリングパラメータであり、 $\lambda$  が小さいときすべてのパターンを遷移して想起する遷移状態が見られ、 $\lambda$  が大きいとき初期提示パターンに収束する自己想起状態が見出された。カオス的な遷移状態は記憶パターンを探索する能力を持ち、ホップフィールド的な自己想起状態は探索対象の記憶パターンへの収束能力を持つと期待できる。そこでパラメータ  $\lambda$  の値を動的に変化させることで、遷移状態で探索を行い自己想起状態で収束を行う式(10)–(13)で表される記憶探索モデルを提案する。現実のニューロンを考えると、ニューロン固有の性質を表すパラメータに時間依存性を持たせるより、シナプス可塑性や神経修飾物質により時間的変化が起こりうるシナプス結合に時間依存性を導入した方が自然である。

$$x_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)), \tag{10}$$

$$\eta_i(t+1) = k_f \eta_i(t) + \lambda(t) \sum_{j=1}^N w_{ij} x_j(t), \quad (11)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i, \quad (12)$$

$$\lambda(t+1) = \lambda(t) - M \left\{ \frac{\partial U(\lambda(t))}{\partial \lambda} - F(t) \right\}, \quad (13)$$

ここで、式(10)–(12)はAdachiら<sup>5)</sup>のモデルに時間依存するパラメータ $\lambda(t)$ が導入された方程式系である。変数 $\lambda(t)$ の時間更新式(13)は、ポテンシャル $U$ による力とバイアス $F(t)$ による過減衰運動を表している。パラメータ $M$ は易動度であり、 $\lambda$ の変化しやすさを表すパラメータである。1章で述べた記憶探索モデルの関連研究における制御変数は、提案モデルでは $F(t)$ に対応する。式(13)中のポテンシャル $U$ は次式で表される双安定ポテンシャルとする。

$$U(\lambda) = (\lambda - \lambda_W)^2 \times (\lambda - \lambda_A)^2, \quad (14)$$

ここで、 $\lambda_W$ と $\lambda_A$ は2つの安定状態であり、それぞれ遷移状態と自己想起状態の $\lambda$ の値に定める。 $\lambda$ の初期値を $\lambda(0) = \lambda_W$ として、ネットワークは初期に遷移状態にあるとする。双安定ポテンシャルからの一般化力 $(-M \frac{\partial U(\lambda(t))}{\partial \lambda})$ は、 $\lambda = (\lambda_A + \lambda_W)/2 \pm \sqrt{3}(\lambda_A - \lambda_W)/6$ でそれぞれ最小値と最大値 $\mp \sqrt{3}(\lambda_A - \lambda_W)^3/9$ をとる(複合同順)。 $F_0 = \sqrt{3}(\lambda_A - \lambda_W)^3/9$ とおき、バイアス $F(t)$ を次式で定義する。

$$F(t) = F_0(1 + \Delta) \left\{ 2 \tanh^2 \left( \gamma \frac{\mathbf{x}(0) \cdot \mathbf{x}(t)}{N} \right) - 1 \right\}, \quad (15)$$

ここで、 $\gamma$ は $F(t)$ の変化しやすさを表すパラメータである。双安定ポテンシャルからの力とバイアスの合力を考えると、 $|F(t)| > F_0$ が成立するならば双安定性が崩れて単安定状態となる。このとき $F(t) > F_0$ では遷移状態が不安定になり自己想起状態中に安定状態が生じ、 $F(t) < -F_0$ では自己想起状態が不安定になり遷移状態中に安定状態が生じる。 $|F(t)| > F_0$ が成立するために、 $\Delta > 0$ が必要となる。内積 $\mathbf{x}(0) \cdot \mathbf{x}(t)$ の時間変化にともなってバイアス $F(t)$ は変化する。

このモデルの動作について概説する。(A)初期提示パターン $\mathbf{x}(0)$ を記憶パターンの1つと仮定する。その記憶パターンをターゲットパターンと呼ぶ。(A-1)ターゲットパターンと現在の出力の類似度が大きいとき、 $\mathbf{x}(0) \cdot \mathbf{x}(t) \sim N$ が成立する。このとき、 $F(t) > F_0$ が成立し $\lambda$ は自己想起状態の値に変化し、ターゲットパターンに収束する。すなわち初期提示パターンがネットワークにとって既知パターンであるとき、ネットワークはそのターゲッ

トパターンを想起して収束することができる。(A-2)ターゲットパターンと現在の出力 $\mathbf{x}(t)$ の類似度が小さいとき、 $\mathbf{x}(0) \cdot \mathbf{x}(t) \sim 0$ が成立する。このとき、 $F(t) < -F_0$ が成立し $\lambda$ は遷移状態の値をとり、ネットワークはターゲットパターンを探索する。探索の結果、ターゲットパターンと現在の出力の類似度が大きくなると(A-1)の状況となる。(A-3)ターゲットパターンの反転パターンと出力状態が類似しているとき、 $\mathbf{x}(0) \cdot \mathbf{x}(t) \sim -N$ が成立する。このとき $F(t) > F_0$ が成立し、 $\lambda$ は自己想起状態の値に変化し、反転パターンを想起して収束する。記憶パターンとその反転パターンの成分値は反転しているが、成分値を並べたパターンの幾何学的形状は類似しているため、提案モデルではターゲットパターンとその反転パターンを同等に扱っている。(B)初期提示パターン $\mathbf{x}(0)$ がどの記憶パターンとも類似していないと仮定する。この場合、初期提示パターンをターゲットパターンと呼ぶ。ターゲットパターンあるいはその反転パターンと現在の出力の類似度が大きいときを考える。すなわち $\mathbf{x}(0) \cdot \mathbf{x}(t) \sim \pm N$ が成立する。このとき $F(t) > F_0$ となり、 $\lambda$ は自己想起状態の値に変化する。しかし、ターゲットパターンは記憶パターンではないので、ターゲットパターンのベシンは存在しない。したがって、ネットワークはどれかの記憶パターンのベシンに入り、その記憶パターンを想起して収束する。すると、 $\mathbf{x}(0) \cdot \mathbf{x}(t) \sim 0$ すなわち $F(t) < -F_0$ が成立し、 $\lambda$ は遷移状態の値をとり、ネットワークは遷移状態に戻る。すなわち初期提示パターンがネットワークにとって未知パターンであるとき、ネットワークはカオス的な遷移状態で記憶パターンを巡り続ける。また、自己想起状態でホップフィールドモデルにおける混合状態に収束した場合も $|\mathbf{x}(0) \cdot \mathbf{x}(t)|$ の値が小さくなるためパターン間の類似度が減少し、ネットワークは再び遷移状態へ移行してターゲットパターンを探索する。このことにより、探索の間違いや混合状態への収束を回避する。

## 4. 数値実験

### 4.1 方法と評価量

提案モデルの数値実験を行いパターン識別能力が記憶パターン集合によってどのように変わるかを調べるため、評価量としてパターンへの収束率を導入する。まず、ネットワークのパターンへの収束判定を次の条件で行う。

収束条件 『全数値ステップを2,000ステップとし、2,000ステップ内にネットワークが同一のパターン(記憶パターンと反転パターンを区別する)を連続1,000ステップ想起し、その間 $\lambda > \lambda_B$ が成立すること』、ここで想起の判定は2.2節で説明した『想起条件』で行う。また、 $\lambda_B$ は遷移状態から自己想起状態へ移行する境界付近のパラメータ $\lambda$ の値であり、



図7 未知パターン  $j$   
Fig.7 Unknown pattern  $j$ .

不等式  $\lambda > \lambda_B$  の成立によりネットワークが自己想起状態にあることを判定する。数値実験では、初期提示パターン  $x(0)$  としてターゲットパターンにノイズを加えたパターンを用いる。ここで、ターゲットパターンは記憶パターンや後述する未知パターンとする。また『ノイズを加える』とは、ターゲットパターンの成分値を反転することを意味する。パターン  $a$  の収束率  $C_a$  は、ターゲットパターンとノイズを加えた成分数  $n$  によって値が変化する。パターン  $a$  の収束率  $C_a$  を次のように測定する。ターゲットパターンとノイズを加える成分数  $n$  を一定として、ノイズを加える位置をランダムに変えた 1,000 回の数値実験を行い、1,000 回中でパターン  $a$  に収束した割合を収束率  $C_a$  とする。提案モデルでは記憶パターンとその反転パターンを同等に扱っているため、以下では記憶パターンの収束率（たとえば  $C_a$ ）とその反転パターンの収束率（ $C_{\bar{a}}$ ）の和（ $C_A$ ）を示す。

式 (5) のように自己相関型でシナプス結合を定義して、直交パターン集合、相関パターン集合およびランダムパターン集合の 3 つの記憶パターン集合で数値実験を行った。各実験では、記憶パターンあるいは未知パターンをターゲットパターンとしてノイズ数  $n$  を 0 から 32 に変えて収束率を測定した。未知パターンとは、記憶パターンとの相関が少ないパターンであり、数値実験では図 7 のパターン  $j$  を使用した。パターン  $j$  は直交パターン集合のすべての記憶パターンと直交している。

提案モデルの双安定ポテンシャルの 2 つの安定状態  $\lambda_W, \lambda_A$  と収束判定に使う自己想起状態の境界値  $\lambda_B$  を想起率の図を参考にして次の値に定めた。直交パターン集合では、 $\lambda_W = 0.7$ ,  $\lambda_A = 1.2$ ,  $\lambda_B = 1.03$ , 相関パターン集合では、 $\lambda_W = 0.7$ ,  $\lambda_A = 1.6$ ,  $\lambda_B = 1.4$ , ランダムパターン集合では、 $\lambda_W = 0.9$ ,  $\lambda_A = 2.0$ ,  $\lambda_B = 1.7$  とした。その他のパラメータ値はすべての実験で次の共通の値とした。 $M = 1.0$ ,  $\gamma = 4.3$ ,  $\Delta = 0.2$ 。この  $M, \gamma, \Delta$  値は直交パターン集合で提案モデルのパターン識別能力のパラメータ依存性を調べ、パターン識別能力が良いパラメータ値である。このパラメータ値で直交パターン集合以外のパターン集合で収束率を測定し、提案モデルが記憶パターン集合の違いに対して鋭敏であるかを調べる。

#### 4.2 自己相関型シナプス結合を用いた実験結果

##### 直交パターン集合での実験結果

まず、ネットワークの探索過程の一例として、各記憶パターン間の規格化したハミング距離

離  $HD$  の時間変化と  $\lambda$  の時間変化を図 8 に示した。図 8 の最上段が  $\lambda$  の時間変化を表しており、次に上から順番にパターン  $a, b, c, d$  と出力間の規格化したハミング距離の時間変化を表している。ただし、初期提示パターンはパターン  $a$  に  $n = 7$  のノイズを付加したパターンである。規格化したハミング距離の図より、パターン  $b$  と  $\bar{b}$  が 50 ステップ付近まで繰り返し想起され、40 ステップ付近から 170 ステップ付近までパターン  $c$  と  $\bar{c}$  が繰り返し想起され、やがて 170 ステップ付近からターゲットパターンであるパターン  $a$  と  $\bar{a}$  が想起され、445 ステップでパターン  $a$  に収束したことが分かる。 $\lambda$  のグラフからも、445 ステップより前では  $\lambda < 1.03$  が成立しネットワークは遷移状態にあることが分かり、445 ステップ以降で  $1.03 \leq \lambda$  が成立しネットワークは自己想起状態へ遷移したことが分かる。

次に、全パターンの収束率の結果を図 9 に示す。この図ではターゲットパターンをパターン  $a$  としている。図から、 $n \leq 6$  あるいは  $26 \leq n$  で、パターン  $A$  の収束率が 0.99 より大きくなり、 $9 < n < 23$  ではパターン  $A$  の収束率は 0 となった。初期提示パターンは、 $n \leq 7$  でパターン  $a$  に類似したパターンであり、 $25 \leq n$  ではパターン  $\bar{a}$  に類似したパターンであり、 $7 < n < 25$  ではパターン  $a$  にも  $\bar{a}$  にも類似していない未知パターンであると考えられ、提案モデルで既知パターンと未知パターンの判別ができたと考えられる。また、パターン  $b, c, d$  はターゲットパターンであるパターン  $a$  と直交しているため、パターン  $B, C, D$  への収束率はほぼ 0 となっているが、 $7 < n < 24$  で 0.01 未満の小さな収束率をとる部分がある。これはパターン  $b, c, d$  とパターン  $a$  間のハミング距離が 16 なので、 $n \sim 16$  のノイズを含む初期提示パターンが確率的にパターン  $b, c, d$  に類似することがあるためと考えられる。4 つの記憶パターンは互いに直交しているため、ターゲットパターンをパターン  $b, c, d$  とした収束率の図と図 9 は類似しているため省略する。図 7 に示した未知パターン  $j$  をターゲットパターンとしたときの全パターンの収束率を図 10 に示した。直交パターン集合の 4 つの記憶パターンはパターン  $j$  と直交するので、いずれのパターンの収束率も 0.01 未満の小さな値となった。 $7 < n < 24$  のノイズで 0.01 未満の小さな収束率が現れた原因は、図 9 でパターン  $B, C, D$  の小さな収束率が生じた原因と同じと推測する。以上より、直交パターンに対して提案モデルは初期提示パターンを既知か未知か判別できたと考えられる。

##### 相関パターン集合での実験結果

相関パターン集合での全パターンの収束率を図 11 に示す。これはターゲットパターンをパターン  $a$  とした数値実験の結果である。この図の収束率と図 9 で示した直交パターン集合の収束率は一目で特徴が異なることが分かる。図 11 では、 $n \leq 10$  と  $22 \leq n$  でパターン  $A$  の収束率が 0.8 以上であり、図 9 と比べると収束率がやや小さくなり、収束範囲が広くなっ




図 8 ハミング距離と  $\lambda$  の時間発展

Fig. 8 Time course of both  $\lambda$  and  $HD$  for patterns a, b, c and d.

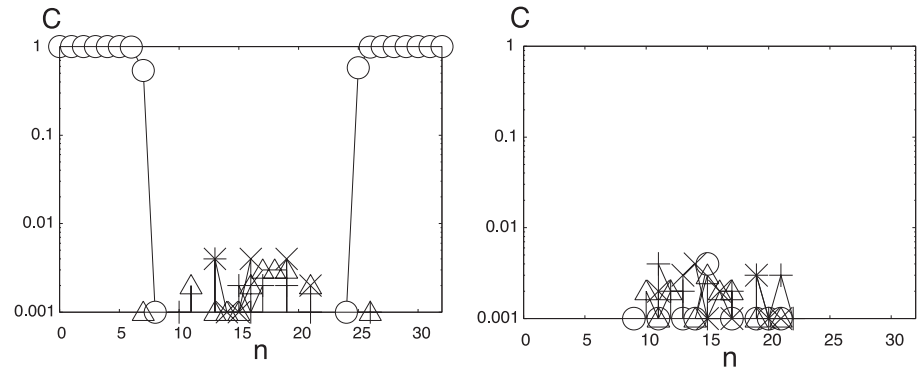


図 9 直交パターンの収束率：ターゲットパターンはパターン a (○:  $C_A$ ,  $\Delta$ :  $C_B$ ,  $\times$ :  $C_C$ , +:  $C_D$ )

Fig. 9 Convergent rate for orthogonal pattern set: target pattern is pattern a (○:  $C_A$ ,  $\Delta$ :  $C_B$ ,  $\times$ :  $C_C$ , +:  $C_D$ ).

図 10 直交パターンの収束率：ターゲットパターンは未知パターン j (○:  $C_A$ ,  $\Delta$ :  $C_B$ ,  $\times$ :  $C_C$ , +:  $C_D$ )

Fig. 10 Convergent rate for orthogonal pattern set: target pattern is unknown pattern j (○:  $C_A$ ,  $\Delta$ :  $C_B$ ,  $\times$ :  $C_C$ , +:  $C_D$ ).

た．また，パターン  $a$  と  $e$  の間に相関があるため，すべてのノイズ領域でパターン  $E$  への収束が見られる．さらに，パターン  $B, C$  への収束が  $10 < n < 22$  で見られ，収束率は図 9 と比べると約 10 倍大きくなった．このことから直交パターン集合の収束率と比べると，相関パターン集合でのパターン識別能力が低下していると考えられる．図 12 に，ターゲットパターンをパターン  $b$  とした場合の全パターンの収束率を示した． $n \leq 10$  と  $22 \leq n$  で，パターン  $B$  の収束率が 0.8 以上である．パターン  $b$  とパターン  $a, c, e$  は直交しているのに，パターン  $A, C, E$  の収束率は約 0.1 より小さく，ほぼ等しい値をとっているが，図 9 と比べると収束率が大きい．図 11 と同様に，図 9 と比べると図 12 も明らかにパターン識別能力が低くなっている．図 13 には，未知パターンであるパターン  $j$  をターゲットパターンとした場合の全パターンの収束率を示した．この図と直交パターン集合の図 10 と比べると，一見して特徴が異なる．パターン  $j$  とパターン  $a, b, c$  は直交しているが図 10 と比べると収束率は大きく，パターン  $e$  とは内積値 8 をとるため，特にパターン  $E$  の収束率が大きい．以上のように相関パターン集合の収束率と直交パターン集合の収束率を比べると既知パターンの収束率が小さくなり，未知パターンの収束率が大きくなっていることから，相関パターン集合ではパターン識別能力が下がったと考えられる．この原因は，図 11-13 の結果を与えた実験のパラメータ  $M, \gamma, \Delta$  の値は直交パターン集合で高いパターン識別能力を示し






図 11 相関パターンの収束率: ターゲットパターンはパターン a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 11 Convergent rate for correlated pattern set: target pattern is pattern a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 12 相関パターンの収束率: ターゲットパターンはパターン b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 12 Convergent rate for correlated pattern set: target pattern is pattern b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 13 相関パターンの収束率: ターゲットパターンは未知パターン j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 13 Convergent rate for correlated pattern set: target pattern is unknown pattern j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 14 相関パターンの収束率 (パラメータ調整後): ターゲットパターンはパターン a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 14 Convergent rate for correlated pattern set (after parameter tuning): target pattern is pattern a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).

た値であり相関パターン集合では適していなかったためと考えられる。実際、相関パターン集合で提案モデルのパターン識別能力が良いパラメータ値は  $M = 0.9$ ,  $\gamma = 2.8$ ,  $\Delta = 0.2$  である。このパラメータ値でパターン  $a, b$  および未知パターン  $j$  を初期提示パターンとして得られた収束率をそれぞれ図 14, 図 15, 図 16 に示した。図 14-16 と, 図 9, 10 を比較するとかなり類似していることが分かる。図 14 と図 9 の相違点は、相関パターン集合ではパターン  $E$  の収束率が大きな値を持つことである。これは、相関パターン集合ではパターン  $a$  と  $e$  が相関を持つためである。パターン  $A, B, C$  の収束率は 2 つの図で同様の傾向が見られる。また、図 15 と図 9 は定性的に等しい。これは相関パターン集合のパターン  $b$  は他のパターンと直交しており、直交パターン集合のパターン  $a$  も他のパターンと直交しているからである。同様に、未知パターン  $j$  をターゲットパターンとした図 16 と図 10 にも大きな違いが見出せない。つまり、パターン識別能力を向上させるためには記憶パターン集合に適したパラメータを選ぶ必要があることが分かる。すなわち、パターン識別能力が記憶パターンに敏感に依存することが分かった。

ランダムパターン集合での実験結果

ランダムパターン集合での実験から得た全パターンの収束率を図 17 に示す。ターゲットパターンを  $f, g, h, i$  のいずれにしても収束率のグラフに定性的な相違がないので、ター




図 15 相関パターンの収束率 (パラメータ調整後): ターゲットパターンはパターン b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 15 Convergent rate for correlated pattern set (after parameter tuning): target pattern is pattern b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 16 相関パターンの収束率 (パラメータ調整後): ターゲットパターンは未知パターン j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 16 Convergent rate for correlated pattern set (after parameter tuning): target pattern is unknown pattern j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 17 ランダムパターンの収束率：ターゲットパターンはパターン  $f$  ( $\circ$ :  $C_F$ ,  $\triangle$ :  $C_G$ ,  $\times$ :  $C_H$ ,  $+$ :  $C_I$ )  
 Fig. 17 Convergent rate for random pattern set: target pattern is pattern  $f$  ( $\circ$ :  $C_F$ ,  $\triangle$ :  $C_G$ ,  $\times$ :  $C_H$ ,  $+$ :  $C_I$ ).

ゲットパターンを  $f$  としたときの収束率を示した。図 17 と直交パターン集合での図 9 を比較すると、明らかに性質が異なることが見てとれ、図 17 ではすべてのパターンが  $n$  の全領域で収束していることが分かる。これはランダムパターン集合では記憶パターン間相関があるので、すべてのパターンへの収束が現れたと推測できる。しかし、直交パターン集合の収束率と比べると、ランダムパターン集合ではすべての  $n$  の領域でパターンの収束率がほぼ一定の値をとり、未知パターンの判別ができていないと考えられ、明らかにパターン識別能力が低い。この原因は、相関パターン集合の場合と同様に、図 17 の結果を与えた実験のパラメータ  $M$ ,  $\gamma$ ,  $\Delta$  の値は直交パターン集合で高いパターン識別能力を示した値でランダムパターン集合には適切でなかったためと考えられる。

以上、3 種類の記憶パターン集合での数値実験の結果から、記憶パターン集合が異なると式 (5) の自己相関型のシナプス結合の値が変わるため、記憶パターン集合ごとに最適なパラメータを選ばないと提案モデルのパターン識別能力が低下することが分かった。

#### 4.3 Pseudo-inverse Approach を用いた実験結果

4.2 節で示したように、記憶パターン集合が異なると提案モデルのパラメータ値をその記憶パターン集合にとって適した値に調節しなければならないことが分かった。この記憶パターンに対する探索モデルのパターン識別能力の鋭敏性は出口らのモデルでも報告されている<sup>10)</sup> ように、カオスニューラルネットワークを用いた多くの記憶探索モデルの持つ共通の問題と考えられる。記憶探索という問題の性質上、ホップフィールドモデルのように記憶

パターン集合を変更してもパラメータ調節なしで記憶が探索できる汎用性のあるモデルが望ましい。そこでシナプス結合の生成方法を変えることで、カオスニューラルネットワークを用いた記憶探索モデルでもそのような汎用性を持たせることを以下で示す。

互いの相関が強いパターンを記憶させたホップフィールドモデルでは、混合状態<sup>15)</sup>へ収束しやすくなり、記憶パターンの想起の成功率が減少する問題点が知られている。この問題の改善策としてシナプス結合を pseudo-inverse approach<sup>15)</sup> を用いて形成する方法がある。この方法は、記憶パターンが 1 次独立ならば相関があるパターンを直交パターンに変換する方法であり、次式で定義される。

$$\mathbf{Q}_{\nu\mu} = \frac{1}{N} \sum_{j=1}^N (2\xi_j^{(\nu)} - 1)(\xi_j^{(\mu)} - 1), \quad (16)$$

$$w_{ij} = \frac{1}{P} \sum_{\nu} \sum_{\mu} (2\xi_i^{(\nu)} - 1)(\mathbf{Q}^{-1})_{\nu\mu} (2\xi_j^{(\mu)} - 1). \quad (17)$$

直交パターン集合では、行列  $\mathbf{Q}$  は単位行列になるため、シナプス結合は式 (5) でも式 (17) でも同じ値をとる。相関パターン集合、ランダムパターン集合に対し式 (5) の代わりに上式のシナプス結合を用いて、提案モデルの数値実験を行った。数値実験では、 $\lambda_A$ ,  $\lambda_W$ ,  $\lambda_B$ ,  $M$ ,  $\gamma$ ,  $\Delta$  のパラメータ値は 4.1 節で示した直交パターン集合に適した値に固定し、相関パターン集合とランダムパターン集合でパターン識別能力を調べる。実験結果の収束率を図 18, 図 19, 図 20, 図 21 に示した。図 18–20 は、相関パターン集合でのターゲットパターンがそれぞれパターン  $a$ ,  $b$  および未知パターン  $j$  の収束率である。図 18, 19 は 4.2 節の図 11, 12 から改善され、直交パターン集合の図 9 と定性的に等しくなった。また、未知パターン  $j$  をターゲットパターンとした図 20 も直交パターン集合の図 10 と定性的に等しい。したがって、pseudo-inverse approach を用いたため、パターン識別能力が向上したことが分かる。さらにランダムパターン集合でターゲットパターンをパターン  $f$  とした場合の収束率を図 21 に示した。この図も図 17 から改善され、図 9 と定性的に等しく、ランダムパターン集合でもパターン識別能力が向上したことが分かる。

## 5. おわりに

本論文では、Adachi らにより提唱された自己想起型カオスニューラルネットワークの性質を用い、記憶したパターンをカオス的にめぐる遷移状態とホップフィールド的に記憶パターンに収束する自己想起状態を遷移させることで、ネットワークに提示するパターンが




図 18 pseudo inverse approach による相関パターン集合の収束率：ターゲットパターンはパターン a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 18 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is pattern a (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 19 pseudo inverse approach による相関パターン集合の収束率：ターゲットパターンはパターン b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 19 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is pattern b (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).




図 20 pseudo inverse approach による相関パターン集合の収束率：ターゲットパターンは未知パターン j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ )  
 Fig. 20 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is unknown pattern j (○:  $C_A$ , △:  $C_B$ , ×:  $C_C$ , +:  $C_E$ ).

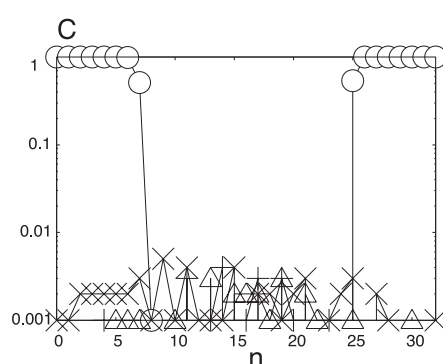


図 21 pseudo inverse approach によるランダムパターン集合の収束率：ターゲットパターンはパターン f (○:  $C_F$ , △:  $C_G$ , ×:  $C_H$ , +:  $C_I$ )  
 Fig. 21 Convergent rate for random pattern set by pseudo-inverse approach: target pattern is pattern f (○:  $C_F$ , △:  $C_G$ , ×:  $C_H$ , +:  $C_I$ ).

ネットワークにとって既知であるか未知であるかを判別して、既知ならばそのパターンに収束させ未知ならばカオス的に探索を続ける記憶探索モデルを提案した。また、カオスを発生させるシステムが共通に持つパラメータ鋭敏性という性質が、カオスニューラルネットワークを利用した記憶探索モデルの問題点であることを指摘した。そして、その改善策としてシナプス結合生成に pseudo-inverse approach を用いることで、システムパラメータの調節を行わなくても提案モデルは様々な記憶パターンに適用できる汎用性を持つことを示した。さらに、提案モデルではホップフィールドモデルでのいわゆる混合状態に収束することがないことを確認している。本研究の今後の課題として、提案モデルの記憶容量や探索速度について調べたいと考えている。

### 参考文献

- 1) Skarda, C. and Freeman, F.J.: How Brains Make Chaos in Order to Make Sense of the World, *Behavioral and Brain Sciences*, Vol.10, pp.161-195 (1987).
- 2) Matsumoto, G. and Aihara, K.: Chaotic and Phase Locking in Normal Squid Axons, *Physics Letters A*, Vol.123, pp.62-166 (1989).
- 3) Hayashi, H. and Ishizuka, S.: Instability of Harmonic Responses of Onchidium Pacemaker Neuron, *J. Phys. Soc. Jpn.*, Vol.55, pp.3372-3278 (1986).
- 4) Aihara, K., Takabe, T. and Toyoda, M.: Associative Dynamics in a Chaotic Neural Network, *Physics Letters A*, Vol.144, p.333 (1990).
- 5) Adachi, M. and Aihara, K.: Associative Dynamics in a Chaotic Neural Network, *Neural Networks*, Vol.10, pp.83-98 (1997).
- 6) Hopfield, J.J.: Neural Networks and Physical Systems with Emergent Collective Computational Abilities, *Proc. Natl. Acad. Sci. USA*, Vol.79, pp.2554-2558 (1982).
- 7) Iwai, T., Matsuzaki, F., Kuroiwa, J. and Miyake, S.: Effects of Correlation among Stored Patterns on Associative Dynamics of Chaotic Neural Network, *Physica D*, Vol.212, pp.183-194 (2005).
- 8) 亀井隆之, 岩井俊哉: カオスニューラルネットワークにおけるパラメータダイナミクスを用いた記憶探索, 電子情報通信学会技術報告, Vol.NC2006-85, pp.85-90 (2006-12).
- 9) 出口利憲, 石井直宏: カオスニューラルネットワークにおける特徴による連想ダイナミクスの制御, 電子情報通信学会論文誌, Vol.J78-D-II, pp.1223-1230 (1995).
- 10) 出口利憲, 石井直宏: 内部パターンを用いたカオスニューラルネットワークによる連想記憶の探索法, 電子情報通信学会技術報告, Vol.NC96-129, pp.127-132 (1997-03).
- 11) 伊藤一成, 高倉康弘, 斎藤博昭: 非単調活性化関数を用いたカオスニューラルネットワークとメモリサーチシステムへの適用, 電気学会論文誌 C, Vol.124, No.3, pp.897-903 (2004).
- 12) Kushibe, K., Liu, Y. and Ohtsubo, J.: Associative Memory with Spatiotemporal

121 カオスニューラルネットワークによる記憶探索モデル

Chaos Control, *Phys. Rev. E*, Vol.53, pp.502–4508 (1996).

- 13) 長名優子, 萩原将文: カオスニューラルネットワークにおける逐次学習, 電子情報通信学会論文誌, Vol.J82-D-II, pp.83–90 (1999).
- 14) He, G., Kuroiwa, J., Ogura, H., Zhu, P., Cao, Z. and Chen, H.: A Type of Delay Feedback Control of Chaotic Dynamics in a Chaos Neural Network, *IEICE Trans. Fundamentals*, Vol.E87, pp.1765–1771 (2004).
- 15) Hertz, J.A., Krogh, K. and Palmer, R.G.: *Introduction to the Theory of Neural Computation*, pp.49–52, Addison-Wesley Pub. Co. (1991).
- 16) Kaneko, K.: Chaotic but regular posi-nega switch among coded attractors by cluster size variation, *Phys. Rev. Lett.*, Vol.63, p.219 (1987).
- 17) Kaneko, K.: Pattern Dynamics In Spatiotemporal Chaos, *Physica. D*, Vol.34, pp.1–41 (1989).
- 18) Ikeda, K., Otsuka, K. and Matsumoto, K.: Maxwell-Bloch trubulence, *Prog. Theor. Phys. Suuapl.*, Vol.99, p.295 (1989).

(平成 22 年 11 月 13 日受付)

(平成 23 年 1 月 12 日再受付)

(平成 23 年 4 月 1 日再受付 (2))

(平成 23 年 4 月 14 日採録)



海老原智哉

昭和 62 年生 . 平成 23 年日本大学大学院工学研究科情報工学専攻博士前期課程修了 . 同年キャノンシステムアンドサポート入社 .



岩井 俊哉 (正会員)

昭和 37 年生 . 平成 5 年東北大学大学院理学研究科物理第二専攻博士後期課程修了 , 博士 (理学) . 平成 5 年東北大学工学部応用物理学科助手 , 平成 13 年より日本大学工学部情報工学科准教授 , 現在に至る . 非平衡物理学 , ニューラルコンピューティングの研究に従事 . 神経回路学会 , 電子情報通信学会正会員 .