

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^{†1} 岩井 俊 哉^{†1}

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敏感である。同様に、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性能も記憶パターンに敏感である。従って、記憶探索モデルは記憶パターンを変更する度に最適なパラメータ値を探さなければならない。本研究では、まずカオスニューラルネットワークにパラメータダイナミクスを導入して記憶探索モデルを提案する。次に、そのモデルの性能が記憶パターンに敏感であることを示す。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^{†1} and TOSHIYA IWAI^{†1}

The dynamics of various chaotic systems shows the sensitivity to system parameter values. The ability for the memory search model which is based on the chaotic neural network model is also sensitive to stored patterns. Thus, we have to choose proper parameter values for the memory search model, when patterns stored in the network are changed. First, we propose a memory search model by introducing the parameter dynamics into the chaotic neural network. Next, the ability for the model is shown to be sensitive to stored patterns. Finally, the proposed model with synaptic couplings produced by pseudo-inverse approach have 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^{1),2)}。Skarda ら¹⁾ はラットの臭い応答の実験を行い、ラットが未知の臭いを嗅いでいるとき嗅球の集合電位がカオス的な応答を示し、既知の臭いを嗅いでいるときリミットサイクルに落ち込むような応答を示すことを見出した。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、ヤリイカの巨大軸索の膜電位応答実験²⁾ 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合原ら³⁾ 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のネットワークを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安達らによって提唱された⁴⁾。本稿では安達らのモデルをカオスニューラルネットワークと略記する。カオスニューラルネットワークモデルでは、カオス的・周期的など様々な動的挙動が確認されている^{4),5)}。この性質を用い、カオス的に記憶を巡る動的状態で記憶の探索を行い、ホップフィールド的に記憶に収束する状態でターゲットパターンに収束させる記憶探索モデルが考案されている⁶⁾⁻⁹⁾。これらの記憶探索モデルの相違点はネットワークの動的状態を遷移させるための制御の方法にある。

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敏感性をもつ。カオスニューラルネットワーク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⁵⁾。従って、記憶探索モデルの動作も記憶パターンに敏感に依存すると考えられる。

本研究では、カオスニューラルネットワークを用いシナプス結合のスケールパラメータを動的に変化させネットワークの動的状態を遷移させることにより記憶探索モデルを提案する。シナプス結合を変化させるという発想は出口ら⁶⁾ と同じであるが、動的状態を遷移させる方法は私の知る限り既存モデルとは異なる。提案モデルの数値実験より、未知と既知のパターンを区別して記憶探索ができることが示された。次に、パラメータ値を変えずに記憶パターンのみを変更して数値実験することで、提案モデルの探索能力が記憶パターンに敏感に依存することを分かった。そこで、pseudo-inverse approach¹⁰⁾ によりシナプス結合を形成することにより記憶パターンに対する敏感さを無くし、パラメータ変更の必要のない汎用性を実現できた。

^{†1} 日本大学
Nihon University

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次式の安達ら⁴⁾により提案されたカオスニューラルネットワークモデルを基礎とする．

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

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

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

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

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値であり、式 (4) の出力関数を用い (0, 1) 間の連続値を取る．膜電位は減衰定数の異なる 2 つの効果 $\eta_i(t)$ と $\zeta_i(t)$ の和で表される． $\eta_i(t)$ は、 i 番目のニューロンの膜電位の他のニューロンからの入力の効果であり、 $\zeta_i(t)$ は i 番目のニューロンの膜電位の相対不応性効果である． k_m , k_r は減衰定数であり、 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．式 (3) 右辺第二項が相対不応性効果であり、 α 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． $k_r = k_f = \alpha = a_i = 0$ のとき、カオスニューラルネットワークはホップフィールドモデルに帰着する．従って、式 (2) 右辺第二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⁵⁾．その性質を用いるため、我々はホップフィールド的な挙動のスケールパラメータ λ を導入した．シナプス結合度は、記憶パターンを用いて次式で定義される．

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

ここで、 P は記憶パターン数である． $\xi_i^{(\mu)}$ は記憶パターン μ の i 成分であり、0 または 1 の値を取る．以下では 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．本項を通して用いるパラメータ値は、 $k_r = 0.9$, $k_m = 0.2$, $\alpha = 1$, $\beta = 20$ 全ての i で $a_i = 0.5$ である．また、ニューロン数を $N = 32$ とし、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

パラメータ λ の値によってカオスニューラルネットワークの動的性質がどのように変化す

るか特徴付けるためにパターン μ の想起率 R_μ を導入する．カオスニューラルネットワークの数値実験の過渡的時間を除いた各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する．数値実験の全計測ステップ T 中で記憶パターン μ とその反転パターンを想起したステップ数 T_μ を計測し、 $R_\mu = T_\mu/T$ でパターン μ の想起率を定義する．ただし、本稿では記憶パターン μ とその反転パターンの両者を併せて『パターン μ 』と呼ぶ．また、パターン μ を想起したかを次の条件で判定する．

想起条件『次式で定義する出力パターンと記憶パターン μ との規格化したハミング距離 $HD(\mu)$ を用い、 $HD(\mu) < 0.05$ が成立したときネットワークは記憶パターン μ を想起したと判定する．従って、 $HD(\mu) > 0.95$ が成立したならば、ネットワークは反転パターン μ を想起したと判定する』

$$HD(\mu) = \frac{1}{N} \sum_{i=1}^N [x_i(t)(1 - \xi_i^{(\mu)}) + \xi_i^{(\mu)}(1 - x_i(t))]. \quad (6)$$

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を調べるために複数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と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、それぞれ各記憶パターンの成分値を表し、黒が 1 白が 0 を意味する．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考える．

$$\xi^{(\mu)} \cdot \xi^{(\nu)} = \sum_{i=1}^N (2\xi_i^{(\mu)} - 1)(2\xi_i^{(\nu)} - 1). \quad (7)$$

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 3 に λ に対して 4 つの記憶パターンの想起率を示す．図より、 $\lambda < 0.8$ では全てのパターンが同頻度で想起されていることが分かる．この領域では、出力パターンが非周期的にパターンを巡りながら変化している．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、記憶パターン 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的に振る舞い、出力の初期値とした記憶パターン A を自己想起したことを意味する．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 λ が小さいと遷移状態でカオス的に記憶パターンを巡り、大きいと自己想起状態で

ホップフィールド的に一つの記憶パターンに収束することが分かる．




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




図 2 相関パターン集合
 Fig.2 Correlated pattern set




図 3 直交パターン集合の想起率 (○ : R_A , △ : R_B , × : R_C , + : R_D)
 Fig.3 Recall Ratio for orthogonal 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

図 2 に示す 2 つ目の記憶パターン集合は、直交パターン集合に弱い相関を加えた記憶パターンからなる。記憶パターン E と A 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。そこで、この記憶パターン集合を『相関パターン集合』と呼ぶ。相関パターン集合での想起率を図 4 に示す。図 4 より、 $\lambda < 0.91$ では 4 つのパターンの非周期的な想起が見られ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。また $0.91 \leq \lambda < 1.03$ では、他のパターンと直交しているパターン B と C のみを遷移して想起している。また $1.03 \leq \lambda \leq 1.32$ では、 λ の値によってパターン B または C に想起率 1 で収束している。さらに $1.32 < \lambda < 1.36$ 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。そして $1.36 \leq \lambda$ では、出力の初期値である記憶パターン A を想起率 1 で想起する自己想起状態が見られる。図 3 と図 4 の比較より、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変化すること、特に記憶パターン間に相関を含めることで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敏感性がある。

3. 提案モデル

2.2 節で示したように、パラメータ λ が小さいとき全てのパターンを遷移して想起する遷移状態が見られ、 λ が大きいとき出力の初期値である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ターゲット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ターゲット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 λ の値を動的に変化させることで、次式の記憶探索モデルを提案する。

$$x_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)), \quad (8)$$

$$\eta_i(t+1) = k_f \eta_i(t) + \lambda(t) \sum_{j=1}^N w_{ij} x_j(t), \quad (9)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a, \quad (10)$$

$$\lambda(t+1) = \lambda(t) - M \left\{ \frac{\partial U(\lambda(t))}{\partial \lambda} - F(t) \right\}, \quad (11)$$

ここで、 λ を時間依存するパラメータとし、パターン探索時に抑制がかかるシナプス前抑制を表現する。変数 $\lambda(t)$ の時間更新式 (11) 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、 λ の変化しやすさを表す量である。式 (11) 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。

$$U(\lambda) = (\lambda - \lambda_W)^2 \times (\lambda - \lambda_A)^2, \quad (12)$$

ここで、 λ_W と λ_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 λ の値に定める。 λ 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力は、 $\lambda = (\lambda_A + \lambda_W)/2 \pm \sqrt{3}(\lambda_A - \lambda_W)/6$ でそれぞれ最小値と最大値 $\mp \sqrt{3}(\alpha_A - \alpha_W)^3/9$ を取る (複合同順)。ここで $F_0 = \sqrt{3}(\alpha_A - \alpha_W)^3/9$ とおき、バイアス $F(t)$ を次式で定義する。

$$F(t) = F_0(1 + \Delta) \left\{ 2 \tanh^2 \left(\gamma \frac{\mathbf{x}(0) \cdot \mathbf{x}(t)}{N} \right) - 1 \right\}, \quad (13)$$

ここで、 γ 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。バイアス $F(t)$ は、内積値 $\mathbf{x}(0) \cdot \mathbf{x}(t)$ に従って時間変化する。このモデルの動作について概説する。まず、初期提示パターン $\mathbf{x}(0)$ を記憶パター

ンの一つと仮定する．初期提示パターンと出力 $x(t)$ の類似度が大きいとき， $x(0) \cdot x(t) \sim N$ が成立する．このとき， λ は自己想起状態の値に変化し，初期提示パターンである記憶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記憶パターンを想起して収束することができる．一方，初期提示パターンと出力 $x(t)$ の類似度が小さいとき， $x(0) \cdot x(t) \sim 0$ が成立する．このとき， λ は遷移状態の値にとどまり，初期提示パターンである記憶パターンを探索する．次に，初期提示パターンがどの記憶パターンとも異なる場合を考える．初期提示パターンと出力 $x(t)$ の類似度が小さいときは， λ は遷移状態の値にとどまり，初期提示パターンである未知パターンを探索する．もし，初期提示パターンと出力の類似度が大きくなったとしたら， λ は自己想起状態の値に変化するが，記憶パターンや反転パターンなどに収束すると $|x(0) \cdot x(t)|$ の値が小さくなるため，ネットワークは再び遷移状態へ移行して未知パターンを探索する．すなわち初期提示パターンが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．ただし，本研究では記憶パターンの反転パターンに出力状態が似ている場合には， $x(0) \cdot x(t) \sim -N$ が成立し，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は濃淡が反転しているが，形自体は類似しているため，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．

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，ターゲットパターンの探索能力を評価するためにパターンへの収束率を導入する．ネットワークがパターンに収束したかを次の条件で判定する．
収束条件 『全数値ステップを 2000 ステップとし，2000 ステップ内に同一のパターンを連続 1000 ステップ想起し，その間 $\lambda > \lambda_B$ が成立する』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， λ_B は自己想起状態へ移行する境界付近の λ の値であり，不等式 $\lambda > \lambda_B$ 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．初期提示パターン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．ターゲットパターンとノイズを加える成分数 n を一定にして，ノイズを加える位置をランダムに変えて 1000 回の数値実験を行い，記憶パターン μ に収束した割合とその反転パターンに収束した割合の合計をパターン μ の収束率と定義する．

式 (5) のように自己相関型でシナプス結合を定義して，直交パターン集合と相関パターン集合での数値実験を行う．4 つの記憶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 個に変えて，各パターンへの収束率を測定する．さらに，4 つの記憶パターンとの相関が少ないパターンを未知パターンと想定し，未知パターンをターゲットパターンとした数値実験も行う．未知パターンとして用いたパターン J は，奇数成分が 1 偶数成分が 0 を取る．従って，パターン J は直交パターン集合の全ての記憶パターンと直交する．

提案モデルの双安定ポテンシャルの 2 つの安定状態 λ_W, λ_A と収束判定に使う自己想起状態の閾値 λ_B を想起率の図から次の値に定めた．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， $\lambda_W = 0.7$ ， $\lambda_A = 1.6$ ， $\lambda_B = 1.4$ とした．提案モデルの探索能力が記憶パターン集合の違いでどのように変化するか調べるため，その他のパラメータ値は共通の $M = 1.0$ ， $\gamma = 4.3$ ， $\Delta = 0.2$ とした．この値は直交パターン集合で，探索能力がよいパラメータ値である．

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：直交パターン集合で，ターゲットパターンを記憶パターン A とした場合の全パターンの収束率を図 5 に示す．図から， $n \leq 6$ あるいは $26 \leq n$ で，パターン A の収束率がほぼ 1 となり， $9 < n < 23$ ではパターン A の収束率は 0 と分かる．初期提示パターンは $n \leq 7$ で記憶パターン A に似たパターンであり， $25 \leq n$ では記憶パターン A の反転パターンに似たパターンで， $7 < n < 25$ ではパターン A に似ていない未知パターンであると考えれば，ネットワークは既知パターンと未知パターンの判別が出来たことになる．この既知と未知の境界であるノイズ数 8 は，私たちの主観的な判断から決定した．記憶パターン B, C, D はターゲットパターンである記憶パターン 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， $7 < n < 24$ のノイズで 0.01 未満の小さな収束率を取る部分がある．その理由は記憶パターン B, C, D と記憶パターン A 間のハミング距離は 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 に類似することもあるためと考えられる．ターゲットパターンに記憶パターン B, C, D を用いた場合，定量的に図 5 と同様の結果が得られたので省略する．未知パターン J をターゲットパターンとした時の全パターンの収束率を図 6 に示した．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見られたのは，図 5 でパターン B, C, D の小さな収束率が生じた理由と同様と考える．以上より，直交パターン集合ではネットワークは初期提示パターンを既知か未知か判断し，記憶探索モデルが正しく機能した．




図5 直交パターンの収束率:ターゲットパターンは記憶パターン A, (○: C_A , △: C_B , ×: C_C , +: C_D)
 Fig.5 Convergent rate for orthogonal pattern set: target pattern is stored pattern A,




図6 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 , △: C_B , ×: C_C , +: C_D)
 Fig.6 Convergent rate for orthogonal pattern set: target pattern is unknown pattern J,




図7 相関パターンの収束率:ターゲットパターンは記憶パターン A, (○: C_A , △: C_B , ×: C_C , +: C_E)
 Fig.7 Convergent rate for correlated pattern set: target pattern is stored pattern A,




図8 相関パターンの収束率:ターゲットパターンは記憶パターン B, (○: C_A , △: C_B , ×: C_C , +: C_E)
 Fig.8 Convergent rate for correlated pattern set: target pattern is stored pattern B,

相関パターン集合での実験: 相関パターン集合で, ターゲットパターンを記憶パターン A とした場合の全パターンの収束率を図7に示す. $n \leq 10$ と $22 \leq n$ で, パターン A の収束率が 0.8 以上であるが, 記憶パターン A と E の間に相関があるため, パターン E への収束がノイズの全ての領域で見られる. また $10 < n < 22$ では, パターン A, B, C の収束率はほぼ等しく, 図5と比べるとその値はほぼ1桁大きい. 図8に, ターゲットパターンが記憶パターン B のとき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 と他のパターンは直交しているため, 他のパターンの収束率は約 0.1 より小さなほぼ等しい値を取っているが, 図5と比べると収束率が大きい. 図9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. パターン J と記憶パターン A, B, C は直交しているが, 記憶パターン E とは内積値 8 を取る. そのため, パターン E の収束率が最も大きく, 他のパターンの収束率はほぼ同程度の値となった. どのパターンの収束率も図6に比べて大きい. 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は既知パターンの収束率は小さくなり, 未知パターンの収束率は大きくなっている. 従って, 直交パターン集合に適したパラメータを用いて, 相関パターン集合の記憶探索を行うと探索能力が悪化すると考えられる. 実際, 相関パターン集合で提案モデルの探索能力がよいパラメータ値は $M = 0.9$, $\gamma = 2.8$, $\Delta = 0.2$ であり, このパラメータ値で計算した収束率は, 相関の影響を除くと直交パターン集合の結果と定量的に同等であることが分かった.




図9 相関パターンの収束率:ターゲットパターンはパターン J, (○: C_A , △: C_B , ×: C_C , +: C_E)
 Fig.9 Convergent rate for correlated pattern set: target pattern is stored unknown pattern J,




図10 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記憶パターン A, (○: C_A , △: C_B , ×: C_C , +: C_E)
 Fig.10 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is stored pattern A,

4.3 Pseudo-inverse approach を用いた実験結果

4.2 節で示したように, 記憶パターン集合を変更すると提案モデルのパラメータ値も変更しなければならない. この性質は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の多くが持っている問題と考えられる. 様々な記憶パターンの記憶探索を行うためには, 記憶パターン集合を変更してもホップフィールドモデルのようにパラメータ調節なしで探索できる汎用性のあるモデルが望ましい. この問題点の解決のため, シナプス結合の生成方法を変

えて、提案モデルの数値実験を行う。相関が強い記憶パターンを埋め込んでもホップフィールドモデルがうまく機能するためのシナプス結合の生成方法に pseudo-inverse approach¹⁰⁾がある。この方法は、記憶パターンが1次独立ならば使用可能で、次式で表現される。

$$\mathbf{Q}_{\nu\mu} = \frac{1}{N} \sum_{j=1}^N \xi_j^{(\nu)} \xi_j^{(\mu)}, \quad (14)$$

$$w_{ij} = \frac{1}{P} \sum_{\nu} \sum_{\mu} \xi_i^{(\nu)} (\mathbf{Q}^{-1})_{\nu\mu} \xi_j^{(\mu)}. \quad (15)$$

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 (15) でも同じ値を取る。相関パターン集合に対し式 (5) の代わりに式 (15) でシナプス結合を生成し、提案モデルの数値実験を行った。 $\lambda_W, \lambda_A, \lambda_B, M, \gamma, \Delta$ のパラメータ値は、直交パターン集合で定めた値に固定する。図 10, 11, 12 は、ターゲットパターンがそれぞれ記憶パターン A, B, E の収束率である。図 10 と図 11 は、パターン A, E 間の相関の影響を除くと 4.2 節の直交パターン集合の図 5 と定性的に同様で、提案モデルは既知と未知の識別ができると考えられる。また、記憶パターン E と J の内積値は 8 であるが、未知パターン J を初期提示パターンとした図 12 も直交パターン集合の図 6 と定性的に同様であり、パターン J は未知パターンと判断されたと考えてよいだろう。

5. おわりに

本稿では、安達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、カオス的にパターンを巡る遷移状態とホップフィールド的にパターンに収束する自己想起状態を遷移させることで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敏感性という性質が、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、その改善策としてシナプス結合生成に pseudo-inverse approach を用い、記憶探索モデルの汎用性を高めた。

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 pp62-166 (1989).
- 3) Aihara, K., Takabe, T. and Toyoda, M.: Associative Dynamics in a Chaotic Neural




図 11 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記憶パターン B, (○: C_A , △: C_B , ×: C_C , +: C_E)
 図 12 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. 11 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is stored pattern B,
 Fig. 12 Convergent rate for correlated pattern set by pseudo-inverse approach: target pattern is unknown pattern J,

Network, Physics Letters A, Vol144 pp333 (1990).

- 4) Adachi, M. and Aihara, K.: Associative Dynamics in a Chaotic Neural Network, Neural Networks, Vol10 pp.83-98 (1997).
- 5) 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).
- 6) 出口利憲, 石井直宏: カオスニューラルネット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).
- 7) Kushibe, K., Liu, Y. and Ohtsubo, J.: Associative Memory with Spatiotemporal Chaos Control, Phys. Rev. E, Vol.53 pp.502-4508 (1996).
- 8) 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).
- 9) 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 (2004) pp.1765-1771.
- 10) Hertz, J. A., Krogh, K. and Palmer, R. G.: Introduction to the theory of neural computation, Addison-Wesley Pub. Co., pp.49-52 (1991)