

論文

動的自己想起型ニューラルネットによる相関パターン識別

Recognition for Correlated Pattern Signals by
Dynamic Autoassociative Neural Networks

道法 浩孝 (高知大学教育学部)

長尾 夏樹 (神戸ファッション造形大学ファッション造形学部)

堅田 尚郁 (兵庫県立大学大学院応用情報科学研究科)

Hirotaka DOHO, Natsuki NAGAO, Naofumi KATADA

*Faculty of Education, Kochi University**Faculty of Fashion and Design, Kobe University of Fashion and Design**Graduate School of Applied Informatics, University of Hyogo*

ABSTRACT

In the Hopfield static associative memory model, the contact with the external system is restricted only in the initial state, in which external information is acquired. The subsequent transition of network states is an alleviation process converging with the lower energy stable state of the network internally as a closed system. This limits the model's application to memory. In this paper, we extend the conventional static memory model to an input-output system that can provide interaction with the external world, on which the dynamic memory model and its extended chaotic dynamic model are based. We analyzed and investigated the response of the network to correlated pattern signals from the viewpoint of the time correlation between the input signal and the network output. As a result, the response difference of the network to stored, non-stored, and mixed stored pattern signals was clearly shown and verified, thus we have indicated that our model has sufficient capability for three kinds of signal discrimination. We verified the alternating appearance of the patterns composing the MSPS results from chaotic properties and clarified the ability of pattern identification. Furthermore, a mechanism that can discriminate and identify pattern signal information is constructed by combining the dynamic memory model and its extended chaotic dynamic model, thus suggesting the versatility of our proposed model.

Key words : Dynamic Autoassociative Neural Network, Correlated Pattern, Input-Output Correlation, Pattern Recognition, Chaos

1. はじめに

ニューロコンピューティングは、脳の構造・機能の解明およびその工学的応用を目的とする学際的研究分野であり、カオス、ファジィとともにソフトコンピューティングの1領域として位置づけられている。その研究手法は、生体の神経細胞(ニューロン)を模擬した人工の素子およびそれを多数結合させた人工神経回路網(ニューラルネットワーク)を構成し、それによる情報処理の可

能性を計算機シミュレーションを通して探るものである。そして、従来のノイマン型コンピュータとは異なるスキームで、学習、連想記憶、パターン認識等の精密性や正確性のみに囚われない柔軟でロバスト性に富んだ情報処理機能の実現をめざしている。

このニューロコンピューティングの基礎となるニューラルネットワークのなかで、神経細胞を多入力・1出力の非線形入出力関数(ニューロ素子)としてモデル化し、

記憶の記録・想起の機能をその相互結合による回路網における力学系問題として定式化する考えは、ホップフィールドによる連想記憶モデル[1]として知られている。これは、ニューラルネットワークにエネルギー関数の概念を導入し、記憶すべき対象をそのエネルギー関数の局所安定状態に対応させるというものである。記憶という機能をニューラルネットワークにおける力学系の平衡点の安定性問題として定式化できることを示した点で、このモデルは意義深いものである。

しかしながら、このモデルでは、外部情報がネットワークの初期状態として扱われ、いずれの初期状態に対しても最寄りの局所安定状態に収束することになる。時間発展後の静止（収束）状態が想起されるべき既知パターンであるという発想から生まれたこのモデルでは、外部情報に対する既知と未知の識別能力がもとから前提とされていないともいえる、その点で記憶のモデルとして適用できる課題に限界がある。この点に関しては、外部からの情報をネットワーク状態に持続的に作用し続ける入力信号のような存在として位置づけ、開放系としての動的なシステム化を図るのがより現実的なモデリングであると考えられる[2], [3].

そこで我々は、このモデルを外部との相互作用が可能な入出力系へ拡張した動的記憶想起モデルを提案し、既知・未知信号の識別可能性および既知混合パターンを構成するパターン同定の可能性を確認してきた[4]. 具体的には、従来の静的記憶想起モデルでネットワーク初期状態として扱われていた外部情報をこの入出力系への外部入力項としてネットワークの内部状態に直接かつ経時的に付加し、その効果をネットワーク内の各ニューロンに対する内部状態変化として扱うものである。そして、入力信号に対するネットワークの応答性を入出力間の時間相関に基づいて評価し、3種類の信号に対する応答性の違いを信号識別のプロセスに反映させる。さらに、この動的記憶想起モデルを拡張したカオス化動的モデルの導入を通して、本モデルを用いたパターン情報の識別・同定機構を提案してきた[5], [6], [7].

本論文では、これまでのランダムパターン事例ではなく、互いに相関をもつ非直交パターンに対するネットワーク応答性について検討する。本モデルの実用的な側面を考慮すると、文字や画像など実際の外部情報に対処する必要が出てくる。それらを入力情報に変換する際、互いに直交関係にあるようにできるとは限らず、むしろ互いに相関を持つ非直交パターン群として構成される場合が多いと考えるべきである。そこで、非直交パターン群の一例としてアルファベット文字群を入力パターン情報とし、それに対する本モデルの性能分析および検討を行い、本提案機構の工学的適用可能性を追求する。

2. モデリング

2.1 動的記憶想起モデル

シナプス結合 w_{ij} (ただし, $w_{ii} = 0$) で結ばれた N 個のニューロン ($i = 1, \dots, N$) を考える。ホップフィールドによる連想記憶モデルは、 N 個のニューロンの可能な結合をすべて認める対称相互結合型ニューラルネットワークである。このモデル[1]においては、外部情報はネットワーク初期状態 $\{X_i(0)\}$ として扱われ、その後の各ニューロンの時間発展は、

$$X_i(t+1) = f(h_i(t)) \quad (1)$$

$$h_i(t) = \sum_{j=1}^N w_{ij} X_j(t) - \theta_i \quad (2)$$

で与えられる。ただし、 $f(y) = \tanh(y/2\varepsilon)$ 、ニューロン値 X_i は $-1 \leq X_i \leq 1$ で定式化されている。 θ_i はしきい値である。

この静的記憶想起モデルを外部との相互作用が可能な形に拡張する。具体的には、外部からの入力信号の寄与は次のように、(1)式の内部状態に外部入力項 $\{S_i\}$ ($i = 1, \dots, N$) を付加する形で考慮する。

$$X_i(t+1) = f(h_i(t) + S_i(t)) \quad (3)$$

閉じたシステムとしての静的記憶想起モデルの場合と異なり、 $\{S_i(t)\}$ と $\{X_i(t+1)\}$ が互いに入出力の関係にある。

ネットワークのエネルギー関数形式

$$E(\mathbf{X}) = -\frac{1}{2} \sum_{ij} w_{ij} X_i X_j + \sum_{i=1}^N \theta_i X_i \quad (4)$$

(外部入力が存在する系では厳密な意味でのエネルギー関数ではないが、静的記憶想起モデルとの対応上エネルギー関数と呼ぶことにする) に対して、 $w_{ij} = w_{ji}$ のとき、

$$\frac{\partial E(\mathbf{X})}{\partial X_i} = -\sum_{j=1}^N w_{ij} X_j(t) + \theta_i = -h_i(t) \quad (5)$$

であることを考慮すると、(3)式は

$$X_i(t+1) = f\left(-\frac{\partial E(\mathbf{X})}{\partial X_i} + S_i(t)\right) \quad (6)$$

となる。

このことから、入出力系への拡張により以下のような性質が系に現れると考えられる。入力信号が与えられると、ネットワークは与えられた入力信号の力 $S_i(t)$ と、その状態に対応するエネルギー関数勾配による引き込み力 $\partial E(\mathbf{X})/\partial X_i$ の双方から影響を受け、その振る舞いは両者の競合に依存することになる。すなわち、既知パターン（記録パターン）に近い信号が入力された場合には、ネットワーク状態は対応する局所安定状態付近に誘導され、そこでのエネルギー関数勾配が大きいため入力

信号の影響力が弱められる。一方、未知パターン（非記録パターン）に近い信号が入力された場合には、その誘導先の状態でのエネルギー関数勾配は小さく、入力信号の影響力が支配的となる。この違いは、入力信号に対するネットワーク状態の経時変化（ネットワーク応答）に反映されることになる。しかも、信号にゆらぎ（一定の範囲内の変動ノイズ）をもたせることにより、ネットワーク応答の差異はより顕在化すると期待される。図1(a)は、このような過程をエネルギー関数を通して表現したものである。図1(b)に示した従来の静的記憶想起モデルの場合の、外部情報（＝初期状態）が既知パターンから如何なる距離にあらうと既知に行きつく機構とは全く違う仕組みであると言えよう。このネットワーク応答性の違いに着目して既知信号と未知信号の識別を行うモデルが、我々が提案する動的記憶想起モデルである。

2.2 カオス化動的モデル

現実の脳神経系の挙動には、単一ニューロンのレベルから神経回路網およびその集積である脳全体の活動状態まで、いくつかの階層でカオスが観測されている。このカオスの生成に寄与するファクターを、時間とともに指数関数的に減衰しながらも影響が残存する履歴性効果の形で、2.1の動的記憶想起モデルに導入し、カオスニューラルネットワークに拡張する。これによって、2つの記録パターン間の交代現象が可能になる。

2.1の連想記憶型ニューラルネットの拡張としてのカオスニューラルネットワーク（Chaotic Neural Network: CNN）[8, 9]の発展方程式は

$$X_i(t+1) = f(\eta_i(t) + \zeta_i(t) + S_i(t)) \quad (7)$$

$$\eta_i(t) = \sum_{j=1}^N w_{ij} \sum_{d=0}^t k_f^d X_j(t-d) \quad (8)$$

$$\zeta_i(t) = -\alpha \sum_{d=0}^t k_r^d X_i(t-d) - \theta_i \quad (9)$$


で与えられる。ただし、 k_f : 他のニューロンからのフィードバック入力に関する履歴性の時間減衰定数、 k_r : i 番目のニューロン自身の不応性に関する履歴性の時間減衰定数、 α : 不応性項のスケーリング・パラメータ ($\alpha \geq 0$) である。(8), (9)式は履歴効果の指数ベキ (k^d) 性のため

$$\eta_i(t) = k_f \eta_i(t-1) + \sum_{j=1}^N w_{ij} X_j(t) \quad (10)$$


$$\zeta_i(t) = k_r \zeta_i(t-1) - \alpha X_i(t) - \theta_i (1 - k_r) \quad (11)$$

に帰着される。(10), (11)式において $k_f = k_r = \alpha = 0$ とすると(7)式は

$$X_i(t+1) = f\left(\sum_{j=1}^N w_{ij} X_j(t) - \theta_i + S_i(t)\right) \quad (12)$$



(a) 動的記憶想起モデルの場合



(b) 静的記憶想起モデルの場合

図1 動的記憶想起モデルと静的記憶想起モデルの相違

となり、入出力系に拡張されたこれまでの発展方程式(3)に一致する。以降では、(3)式(12)式に基づく動的記憶想起モデルに対して、(7)式に基づくモデルをカオス化動的モデルと呼ぶことにする。

2.3 パターン記録（既知パターン生成）の学習則

パターン記録、すなわち、 $\{w_{ij}\}$ の決定処方としては、従来の静的記憶想起モデルでの静的記憶の埋め込みと同様である。ネットワークに記憶させたいパターン R^μ (成分表示: $\{\xi_i^\mu\}$) がネットワークの局所安定状態 (すなわち、 $\{X_i(t+1)\} = \{X_i(t)\} = \{\xi_i^\mu\}$) に一致するための必要十分条件は、全ニューロンに対して

$$\gamma_i^\mu \equiv \xi_i^\mu \sum_{j=1}^N w_{ij} \xi_j^\mu > \kappa (> 0) \quad (13)$$

なる条件が成立すればよいことが知られている[10]。正のパラメータ κ の導入により、局所安定な $\{\xi_i^\mu\}$ の引力圏が形成され、ネットワーク状態 $\{X_i(t)\}$ が記録パター

ン $\{\xi_i^\mu\}$ から多少変位していても最終的に $\{\xi_i^\mu\}$ の状態をとるようになる。その意味で γ_i^μ は記憶の安定度、その下限 κ は記憶の引力圏パラメータと呼ばれている。

ディーデリッヒ (Diederich) とオPPER (Oppen) [11] は、与えられた M 個の記憶パターン ($\mu = 1 \sim M$) に対して(13)式が成立するまで

$$w_{ij}^{new} = w_{ij}^{old} + \delta w_{ij}^\mu \quad (\delta w_{ij}^\mu = \frac{1}{N} \xi_i^\mu \xi_j^\mu) \quad (14)$$

によって結合荷重を徐々に変更する逐次型の学習則 (以後、逐次学習則と呼ぶ) を提出し、その収束性を証明した。この方法を用いれば、通常の文字パターンのように互いに相関を持つ非直交なパターン群もネットワーク上で局所安定状態とすることが可能である (記憶対象が直交パターン群の場合には、この学習則はよく知られたヘブ則[12]に一致)。

3. 計算機シミュレーション

3.1 パターンデータと既知パターン生成

計算機上でシミュレーションを展開するにあたって、ネットワークを構成する全ニューロン数を156 ($N=156$) とし、ニューロンのしきい値と入出力関数の傾きのパラメータを $\{\theta_i\}=0$, $\varepsilon=0.015$ (全ニューロン共通) と設定した。パターン情報としては、図2のように 12×13 (=156)のユニット構成でアルファベット文字パターン ($A \sim Z$) を用意し、そのうちの10パターン $A \sim J$ を記憶パターンとした。これらのパターン $A \sim Z$ 間の重なり $q_{\mu\nu} \equiv (1/N) \sum_{i=1}^N \xi_i^\mu \xi_i^\nu$ は $-0.667 (I vs M) \leq q_{\mu\nu} \leq 0.859 (F vs P)$ の範囲に分布しており、互いに相関を持つ非直交パターン群であることがわかる。

図3 (a)は、 $A \sim J$ の10パターンを記憶対象に、2.3の逐次学習則を $\kappa=1$ という条件の下で実行したときの安定度 γ_i^μ の度数 (count) 分布である。記憶成立後の安定度 γ_i^μ ($156 \times 10 = 1560$ 個) の度数 (count) 分布 (区分の幅 $\Delta\gamma_i^\mu = 0.1$) は、10パターンすべてが $\gamma_i^\mu > 1$ を満たすまで逐次更新した結果、値の上限は3付近にまで及んでいる。これは、互いに相関があるパターン群に2.3の逐次学習則を適用した場合、パターン間でそれぞれの安定性確保に競合が生じやすくなり、その結果すべての






図2 実験で用いた文字パターンの例 ($\xi_i = 1$ が黒, $\xi_i = -1$ が白に対応)



(a) $\gamma_i^\mu > 1$ という条件で実行した場合



(b) $1 < \gamma_i^\mu \leq 2$ という条件で実行した場合

図3 パターン ($A \sim J$) 逐次学習後の安定度 (γ_i^μ) 度数分布

γ_i^μ が $\gamma_i^\mu > 1$ を獲得するまでの更新回数が増加し、それともなう γ_i^μ 値の押し上げが許容されるためである。こうして得られた γ_i^μ 分布がネットワーク応答の信号強度依存性を大きく左右することになる。そこで、 γ_i^μ 値の増加が2付近で抑えられる ($1 < \gamma_i^\mu \leq 2$ となる) ように学習アルゴリズムを変更して記憶を行った。図3 (b)がその結果である。 γ_i^μ の各値に対する度数にややばらつきがみられるものの一定の安定度を確保している。

図4は、学習終了後の結合荷重 $\{w_{ij}\}$ に基づいて20パターンそれぞれのエネルギー値 E を求めたものである。ネットワークに記憶させた $A \sim J$ の10パターン (以降、既知パターンと呼ぶ) はいずれもほぼ-120付近のエネルギー値に抑り下げられているが、記憶対象としなかった $K \sim T$ の10パターン (以降、未知パターンと呼ぶ) は、それより高値に留まっている。各パターン状態 $\{\xi_i^\mu\}$ に対応するエネルギー値は、(4)式に(13)式を考慮すると、 $E^{(\mu)} = -(1/2) \sum_{i,j} w_{ij} \xi_i^\mu \xi_j^\mu = -(1/2) \sum_{i=1}^N \gamma_i^\mu$ であり、これに既知パターンの γ_i^μ の平均が概ね1.5である (図3より) ことを適用すると、 $\overline{E^{(\mu)}} \sim -(1/2) \times N \times 1.5 = -(1/2) \times 156 \times 1.5 = -117$ が得られる。

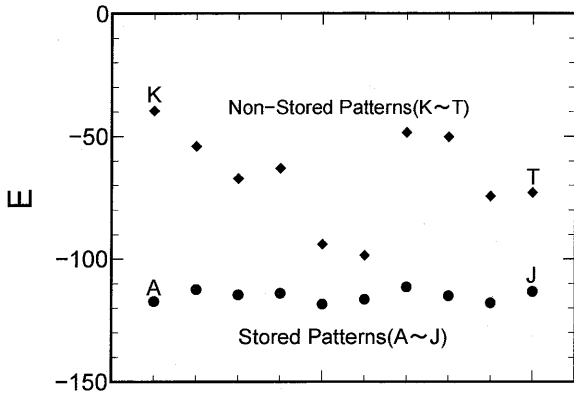


図 4 記録パターン (A~J) と非記録パターン (K~T) のエネルギー値

3.2 ネットワーク応答性の評価法

入力パターン情報としては、3.1で導入した既知パターン群 (A~J)、未知パターン群 (K~Z) から適当なパターンを選び、そのパターンに対し、一定レベルのゆらぎを持たせて入力信号を作成する。ゆらぎ生成の具体的な手順を以下に述べる。パターン情報 R^μ (成分表示: $\{\xi_i^\mu\}$) を構成する156個の要素から幾つかの要素をランダムに抽出し、その要素の値を反転させる ($1 \rightarrow -1$, $-1 \rightarrow 1$)。そのときの抽出個数は、設定されたゆらぎレベルに応じてランダムに決定される。ゆらぎレベル (Fluctuation Level: FL) は抽出個数の許容最大値を示すもので、 $FL=1$ のときは78個 (全体の半数 $N/2$) まで、 $FL=0$ のときは0個ということになる。例えば、ゆらぎレベルが $FL=0.3$ のときは、 $(N/2) \times 0.3 = 78 \times 0.3 \sim 23$ であるので、 $0 \sim 23$ 個の範囲内で要素が反転することになる。時間的に継続する入力情報 $\{\xi_i^\mu(t)\}_{FL}$ は、設定されたゆらぎレベルの下で一定の切替時間間隔 (T_i) ごとに対象となる個数と要素をランダムに変更して生成した。今、パターンAに対してゆらぎレベルを $FL=0.3$ とすると入力情報は、例えば、 $\{\xi_i^A(t)\}_{FL=0.3} = [\{\xi_{i(0.03)}^A\} \rightarrow \{\xi_{i(0.15)}^A\} \rightarrow \{\xi_{i(0)}^A\} \rightarrow \{\xi_{i(0.21)}^A\} \rightarrow \dots]$ となる。ここで各 $\{\xi_{i(z)}^A\}$ の z は、 $0 \sim 0.3$ の範囲内でランダムに決められたその時々ゆらぎであり、反転個数は $78 \times z$ で与えられる。また、各 $\{\xi_{i(z)}^A\}$ の持続時間は T_i である。入力信号は、こうして作られる入力情報 $\{\xi_i^\mu(t)\}_{FL}$ に信号としての強さを左右するパラメータ s (これを信号強度と呼ぶ) を乗じて、

$$\{S_i(t)\} = s \{\xi_i^\mu(t)\}_{FL} \quad (15)$$

の形で構成され、(3)式に作用させられることになる。

また、異なる2つの既知パターンを混合した既知混合パターン情報の場合も取り上げる。具体的には、既知パターンとしてネットワークに記録されているBとCを用いて、Bの上半分とCの下半分を組み合わせると既知混合

パターンB/C (成分表示: $\{\xi_i^{B/C}\}$) を作成し、上記の処方でゆらぎをもつ既知混合パターン信号を用意する。

これらの入力信号に対するネットワーク応答の定量的な評価には、各時刻の入力信号とそれに対するネットワーク状態をそれぞれ N 次元ベクトルと考え、以下のような両ベクトル間の時間相互相関と時間平均重なり度を導入する[13]。入力信号 $\{S_i(t)\}$ とそれに対するネットワーク状態 $\{X_i(t)\}$ (以降、ネットワーク出力と呼ぶこともある) のベクトルをそれぞれ $\tilde{S}(t) = (S_1(t), S_2(t), \dots, S_N(t))$, $X(t) = (X_1(t), X_2(t), \dots, X_N(t))$ とすると、時間相互相関 r は、

$$r = \frac{C(\tilde{S}(t), X(t+1))}{[C(\tilde{S}(t), \tilde{S}(t))]^{1/2} [C(X(t+1), X(t+1))]^{1/2}} \quad (16)$$

時間平均重なり度 n は、

$$n = \frac{1}{N} \overline{\tilde{S}(t) \cdot X(t+1)} \quad (17)$$

で定義される。ただし、 $C(Y, Z) = \overline{(Y - \bar{Y}) \cdot (Z - \bar{Z})}$, $\bar{S} = \bar{S}/s$, $-$ は時間平均を示す。 r と n は、ともに -1 から $+1$ の範囲の値を取り、その値が $+1$ に近い場合には、ゆらぎを持つ入力信号の動きに対してネットワーク出力の追従性がよいことを意味している。

以上のような評価法に基づいて、動的記憶想起モデルのネットワーク応答性を信号強度 s を変化させて評価する。

4. 動的記憶想起モデルによる信号識別・同定

4.1 ネットワーク応答性の経時変化と信号強度依存性

まず、ゆらぎレベルを $FL=0.3$ 、各ゆらぎの切替間隔を $T_i=50$ に設定した既知パターン信号 (Stored Pattern Signal: SPS) および未知パターン信号 (Non-Stored Pattern Signal: NSPS) に対して分析を進める。

図5は、既知パターンにA、未知パターンにKを用いたときの入力情報 $\tilde{S}(t) = \{\xi_i^A(t)\}_{FL}$, $\{\xi_i^K(t)\}_{FL}$ の経時変化を、それぞれのパターン (ゆらぎ無し) との重なり度

$$m_i^\mu(t) = \frac{1}{N} \sum_{i=1}^N \tilde{S}_i(t) \xi_i^\mu = \frac{1}{N} \tilde{S}(t) \cdot \xi^\mu \quad (18)$$

と、対応するエネルギー値 $E(\tilde{S}(t))$ を用いて3次元的に図示したものである。 $m-t$ 平面上への射影は(18)式による $m_i^A(t)$, $m_i^K(t)$ の時系列に相当するが、ゆらぎ生成法が同じなので入力情報 $\tilde{S}(t)$ のA, Kそれぞれのパターンに対する重なり度は一致している ($m_i^A(t) = m_i^K(t)$)。しかしながら、対応するエネルギー値としては既知パターン (SP)、未知パターン (NSP) の間で明確な差が見られる。すなわち、NSPにおいては、 $FL=0$ に対応する状態のエネルギー値は -40 付近に位置し、ゆらぎによるエネルギー変動は20程度であるのに対し、SPでは -120




図5 既知 (SP) および未知 (NSP) の入力情報ゆらぎとそのエネルギー対応 ($FL=0.3, T_i=50$ の場合)

から-60の広い範囲に及んでいる。同一ゆらぎでも両者にこのような違いが生じるのは、2.1の図1で説明したようにエネルギー関数の勾配差によるものである。このことは、各パターンに応じた入力情報の重なり度 m_i^A とエネルギー値 E との関係を示す図6からも確認できる。同じ m_i^A 値を与える入力情報状態が複数存在し得ることから、対応するエネルギー値は帯状になっている。図5の $FL=0.3$ の場合には、 $0.7 < m_i^A < 1.0$ の範囲の勾配差が該当する。

これらの入力情報 (SP, NSP) を信号強度 $s=1.25$ でネットワークに入力した場合のネットワーク出力 $\{X_i(t)\}$ の $m_i^A(t) = (1/N) X_i(t) \cdot \xi_i^A$ と $E(X(t))$ は、図7のようになる (図中の点線は図5の入力情報のものである)。既知パターン信号 (SPS) の場合、ゆらぎに対応するエネルギー変位が大きいため、ネットワーク出力が入力情報をトレースできていない。一方、未知パターン信号 (NSPS) においては、入力情報に比べ低いエネルギー状態 (-60付近) に誘導されるものの、ゆらぎに対するエネルギー変動幅が小さいため、ネットワーク出力は入力情報に応じた変動を示している。しかしながら、ランダムパターンの場合[5]と比較するとネットワーク応答は劣化している。

この原因としては、文字パターンの場合は各パターン間でかなりの相関があるため、未知パターンがいずれかの既知パターンの影響を受けざるを得ないこと、及び逐次学習時の更新回数の増加によって、既知パターン状態以外の局所安定状態が多く形成され、そこに捕捉されることなどが考えられる。

次に、異なる s ごとに図7と同様の時系列データ ($t=6000$ まで) を取得し (シミュレーションでの s の刻み幅は $1/16$)、それぞれの場合の時間相互相関 r 及び時間平均重なり度 n を求め、それらを s に対してグラフ化した




図6 既知および未知の各入力情報におけるエネルギー関数勾配の違い




図7 既知および未知信号 (SPS, NSPS) に対するネットワーク応答 ($s=1.25$ の場合)

のが図8の信号強度依存性である。 $s > 1.0$ のある程度の広い範囲 ($s \sim 1.5$ 辺りまで) で、SPS(A), NSPS(K) に対するネットワーク応答性に違いが確認できる。 n 値の変化から、信号強度 s が 1.0 より小さい (信号強度が弱い) 領域では、ネットワークは初期状態の最寄りの局所安定状態に停留したままで、入力信号を反映していない。 s が 1.0 を越える (信号強度が強い) と、入力信号の影響で局所安定状態を脱することが可能になり、ネットワーク状態は入力信号に近い状態へ導かれることになる。

入力信号状態付近でのネットワーク挙動としては、入力信号が未知信号の場合には信号ゆらぎに対するエネルギー変位が小さいために信号への追従性が良くなり、その結果 r 値は高い値 ($0.7 < r < 1.0$) を示す。一方、既


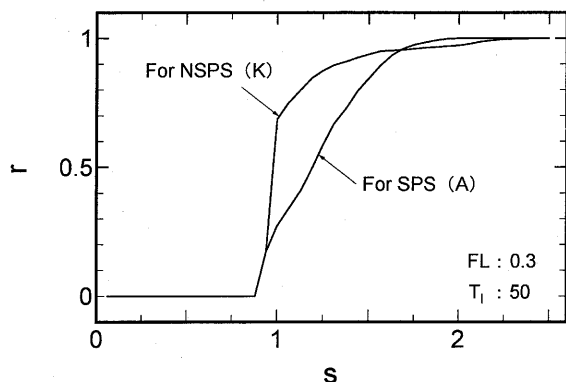


図8 既知および未知信号 (SPS, NSPS) に対するネットワーク応答性の信号強度依存性

知信号の場合には、信号に誘導された先が新たな局所安定状態 (= 既知パターン(A)状態) 付近であるため、エネルギー関数の勾配が急でゆらぎを持つ信号への追従性が悪くなり、 r 値は低くなっている。そして、 r 値は信号強度の増加とともに大きくなり、 s 値が2.0付近ではほぼ1.0に至る。以上のように既知・未知信号に対するネットワーク応答の r 値に信号強度 $s > 1.0$ の広い範囲 ($s = 1.0 \sim 1.5$) で明確な違いが現れており、この領域で信号の識別が可能であることがわかる。

4.2 既知混合信号に対するネットワーク応答性

4.1 では、既知信号と未知信号に対するネットワークの応答性について分析した。ところで、入力信号としては、これらの信号が幾つか混合されたものも存在し得る。そこで本節では、異なる2つの既知パターンを混合した既知混合パターン信号 (Mixed Stored Pattern Signal: MSPS) に対するネットワーク応答性の評価を取り上げる。

図9は、4.1と同様に信号強度を $s = 1.25$ 、ゆらぎレベルを $FL = 0.3$ 、ゆらぎ切替間隔を $T_1 = 50$ に設定したときのネットワーク応答の経時変化データを表示したものである。既知混合パターン信号 (B/C) に対応するエ




図9 既知混合信号 (MSPS) に対するネットワーク応答 ($s = 1.25$ の場合)

ネルギー関数値 $E(\tilde{S}(t))$ は -90 から -40 の範囲に存在しており (図中の点線)、既知パターンと未知パターン信号の場合の中間よりやや低い領域に位置している。このあたりのエネルギー関数の勾配は未知パターン付近よりは急であるが、既知パターン付近よりはゆるやかであることから、ネットワーク出力 (図中の実線) としては既知パターンの場合に比べ、入力信号のトレースの度合いは良い (両者の差が小さい) と見受けられる。

図9の経時変化を基に、 r の信号強度依存性を求め、それを図8の既知・未知パターン信号に対する結果とともに図示したものが、図10である。3者の信号に対する r 値には、信号強度 $s > 1.0$ の広い範囲 ($s = 1.0 \sim 1.5$) で明確な違いが現れており、この領域で信号の識別が可能であることがわかる。

4.3 カオス化動的モデルによる既知混合パターンの同定

これまでの検討で、既知混合のパターン情報を“混合”として他の情報 (既知と未知の単独パターン) とは識別するが、既知パターンの“何”と“何”が混合しているのかについては同定するに至っていない。ネットワーク出力にこの“何”に相当する2つのパターンが経時下で (交互に) 現れることが望ましいが、2.1の動的記憶想起モデルではこれは実現できない。実際、図10の n 値の結果からも伺えるように、信号強度が $s > 1.0$ ではネットワーク出力は入力の混合パターンとほぼ一致し、 $s < 1.0$ では、初期状態の最寄りの局所安定状態に停留したままだからである。 $s > 1.0$ の領域で r 値を取得 (そして、“既知混合”と確認) した後に $s = 0$ としても、ネットワーク出力は既知混合パターン状態を離れ、2つの構成パターンのうちのどちらかの既知パターン (局所安定状態) に収束するだけである。そこで、2つの構成パターン間での交代現象を可能にすることを目的に、2.2のカオス化動的モデルに拡張し、その振る舞いを動的にする。

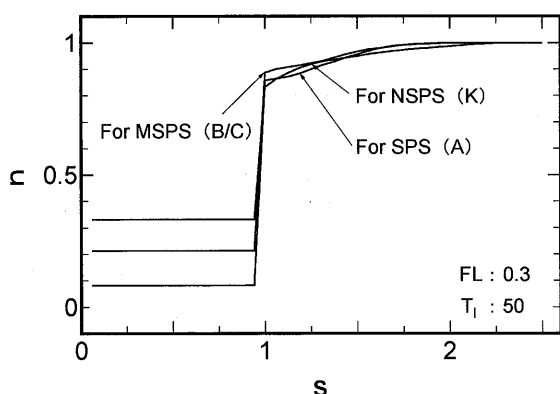



図10 既知, 未知, 既知混合信号 (SPS, NSPS, MSPS) に対するネットワーク応答性の信号強度依存性

図11は, 履歴性と不応性のパラメータを $[k_f=0.1, k_r=0.7, \alpha=0.2]$ に設定したカオス化動的モデルに対し既知混合パターン信号 (MSPS (B/C)) を入力したときのネットワーク応答の経時変化である。ゆらぎレベルとゆらぎ切替間隔は 4.1 と同様の $FL=0.3, T_1=50$ に設定し, 信号強度を $s=0.75$ とした場合の結果である。なお, 図中の non-chaotic case は, 図9の動的記憶想起モデルにおける MSPS に対する経時変化 (信号強度 $s=1.25$ の場合) である。ネットワークのカオス化により, 信号強度が 1.0 より小さい (信号強度が弱い) 領域においてもネットワークは初期状態の最寄りの局所安定状態を脱し, 入力信号に応じた動的な挙動が可能になり, その結果 MSPS を構成する 2 パターン間の交代現象 ($B \rightleftharpoons C$) が生じている。

次に, このようなパターン間の交代現象とカオス性との関係について吟味しておくことにする。図12は, 図11と同じパラメータ設定のカオス化動的モデルにおける最大リアプノフ指数 λ_1 [14] を各信号強度ごとに取得し, 既知混合信号に対してその依存性を調べた結果である。最大リアプノフ指数 λ_1 の評価 [3] は, ネットワークの内部状態 η_i と ζ_i を成分とする $312 (=156 \times 2)$ 次元




図11 既知混合信号 (MSPS) に対するネットワーク応答




図12 カオス化動的モデルにおける最大リアプノフ指数の信号強度依存性

ベクトル軌道に対してなされた。図では信号強度 s が 0.7~1.2 のあたりで λ_1 は正になっており, ネットワークの応答にカオス性が確認できる。MSPS を構成するパターン間の交代現象が現れた図11の場合の信号強度 $s=0.75$ はこの範囲内にあり, その最大リアプノフ指数は $\lambda_1=0.0043 > 0$ でカオスを有することがわかる。このカオスによる交代現象で, 多義図形認知を説明できるとする研究結果も報告されている [15], [16]。

また, 同様の評価を動的記憶想起モデル $[k_f=k_r=\alpha=0]$ の条件下で行った場合, いずれの信号強度においても λ_1 は負の値をとり, カオス性は見られなかった。

以上の結果から, 2 で導入した動的記憶想起モデル及びそれを拡張したカオス化動的モデルは, 互いに相関をもつ非直交パターン信号に対し, 既知・未知・既知混合の識別及び既知混合信号を構成するパターンの同定に十分な機能を有することが明らかになった。そこで, 提示情報の識別 (認識) ・同定を行うことのシステム化を視野に入れて, 本提案モデルを図13のような機構として表現した。信号識別・同定のフローは以下ようになる。まず, 動的記憶想起モデル ($k_f=k_r=\alpha=0$) における r 値に基づいてパターン R に対して既知, 未知, 既




図13 カオス化を導入したパターン情報識別・同定の機構

知混合の識別を行う。そして、この段階で R が既知混合パターンの場合には、 k_f , k_r および α を導入してモデルをカオス化するとともに信号強度 s を調節し、その時の交代的ネットワーク出力から直接的に R の構成パターンの同定を行う。

5. おわりに

本研究では、ホップフィールドによる従来の連想記憶モデルに対して、外部情報を入力信号としてネットワークに持続的に与える動的記憶想起モデルおよびそれを拡張したカオス化動的モデルを提案し、互いに相関をもつ非直交パターン信号に対するネットワーク応答を入力信号とネットワーク出力の時間相関に基づいて分析し検討を行った。その結果、入力信号による力とその状態に対応するエネルギー関数勾配による引き込み力の両者の競合によって、ネットワーク出力には既知・未知・既知混合の3種類の信号間で明確な違いが確認された。この応答性の違いは、モデルにおける一定の信号強度の範囲で維持され、既知・未知・既知混合の3種類の信号識別に十分機能することを示すことができた。また、カオス化による既知混合信号に対するネットワーク応答に、その構成パターン間の交代現象が確認され、パターン同定が可能であることが明らかになった。このパターン間の交代現象は、最大リアプノフ指数を導入した定量的な評価から、ネットワークのカオス性に起因するものであるということが明らかになった。以上の結果に基づいて、動的記憶想起モデルとそれを拡張したカオス化動的モデルを併用することにより、信号のパターン情報識別および同定を行うという機構が構築され、本モデルの汎用化の可能性を示唆することができた。

今後の課題としては、まず、記銘パターン数の増加に対するネットワーク応答性の評価があげられる。本研究では、記銘パターン数 $M=10$ の場合のみを対象としたが、記銘パターン数の増加に対する傾向としては、未知パターン信号の場合の r 値のゆるやかな減少がわかっている。対処の方法としては、引力圏の調整(学習則の改善)、ネットワークサイズの拡大があげられる。次に、

パターン情報識別性能の評価があげられる。本論文では、既知・未知・既知混合それぞれ1つのパターンのみについて評価・分析を行ったが、全既知パターンおよびそれと同数の未知パターンに対するネットワーク応答性を基に入力情報の既知・未知判定のシステム化を図り、モデルの工学的適用性を追求していく必要がある。さらに、記銘(学習)過程と識別同定過程の融合化、顔識別や画像認識などより一般的で実用的な課題への適用の検討を進めていきたい。

参考文献

- [1] J.J.Hopfield: Neural networks and physical systems with emergent collective computational abilities; Proc. Natl. Acad. Sci. USA, Vol. 79, pp. 2554-2558 (1982)
- [2] H.Nishimura, N.Katada and Y.Fujita: Dynamic Learning and Retrieving Scheme Based on Chaotic Neuron Model; in Complexity and Diversity, ed. R.Nakamura et al., pp. 64-66, Springer-Verlag, Tokyo(1997)
- [3] 西村治彦, 堅田尚郁: 刺激-応答機構によるカオス・ニューラルネットワークの動的学習特性; システム制御情報学会論文誌, Vol. 10, No. 10, pp. 518-527(1997)
- [4] 道法浩孝, 堅田尚郁, 西村治彦: ホップフィールド型ニューラルネットにおける動的認識機構; 計測自動制御学会関西支部シンポジウム講演論文集, pp. 236-239(1999)
- [5] 西村治彦, 道法浩孝, 堅田尚郁: 連想記憶型ニューラルネットの入出力相関に基づく信号識別機構; 電子情報通信学会論文誌 (A), Vol. J84, No. 11, pp. 1366-1376(2001)
- [6] 道法浩孝, 西村治彦, 堅田尚郁: 自己想起型ニューラルネットの入出力相関によるパターン識別機構; 第46回システム制御情報学会講演論文集, pp. 581-582(2002)
- [7] 道法浩孝, 西村治彦, 堅田尚郁: 信号ゆらぎへのニューラルネット応答特性による動的パターン認識モデリング; 第18回インテリジェント・システム・シンポジウム講演論文集, pp. 491-496(2008)
- [8] K.Aihara, T.Takabe and M.Toyoda: Chaotic Neural Networks; Physics Letters A, Vol.144, pp.333-340 (1990)
- [9] M.Adachi and K.Aihara: Associative Dynamics in a Chaotic Neural Network; Neural Networks, Vol.10, No.1, pp.83-98 (1997)
- [10] B.Muller and J.Reinhardt: Neural Networks

- An Introduction; Springer-Verlag, Berlin Heidelberg (1990)
- [11] S.Diederich and M.Opper: Learning of Correlated Patterns in Spin-Glass Networks by Local Learning Rules; Phys.Rev.Lett., Vol. 58, pp. 949-952 (1987)
- [12] D.Hebb: Organization of Behaviour; Wiley, New York (1949)
- [13] H.Nishimura, N.Katada and K.Aihara: Coherent Response in a Chaotic Neural Network; Neural Processing Letters, Vol. 12, No.1, pp. 49-58, Aug. (2000)
- [14] T.S.Parker and L.O.Chua: Practical Numerical Algorithms for Chaotic Systems; Springer-Verlag, New York (1989)
- [15] 西村治彦, 長尾夏樹, 松井伸之 :ニューラルカオスに基づく認知交代モデル; 認知科学, Vol.4, No.3, pp.111-119(1997)
- [16] N.Nagao, H.Nishimura, N.Matsui: A Neural Chaos Model of Multistable Perception; Neural Processing Letters, Vol.12, No.3, pp.267-276, Dec.(2000)