

# 動的自己想起型ニューラルネットにおけるパターン識別性能の学習条件依存性

道法 浩孝

(高知大学人文社会科学系教育学部門)

Dependence of Pattern Identification Performance on Pattern Storage Conditions  
in Dynamic Autoassociative Neural Networks

Hiroataka DOHO

*Education Unit, Humanities and Social Sciences Cluster, Kochi University*

**Abstract** : In the conventional stationary Hopfield memory model, the interaction with the external system is restricted only in the initial state, in which the external information is acquired. The subsequent transitions of network states are alleviation process which converges to the lower energy point attractor of network state internally as a closed system. This limits the model's application as the scheme of memory model. So, we have extended the conventional static memory model to an input-output system that can provide interaction with the external world, and we have proposed a new model of dynamic retrieval in associative memory based on temporal I/O correlations. In our former works, we verified that our model has sufficient capability for pattern information identifications in the case of random and correlated patterns. In this work, we analyze the performance of our pattern identification mechanism under the increase of stored patterns by tuning the stability coefficient of pattern storing. As a result, we have confirmed the region of the parameter which our proposed model indicates a high performance of signal identification independent of the number of stored patterns.

Key words : Dynamic Autoassociative Neural Network, Input-Output Correlation, Pattern Identification Performance, Pattern Storage Condition, Stability coefficient of Pattern Storing

## 1. はじめに

パターン認識, 連想記憶等生物に見られる柔軟で総合的な情報処理は, 脳を構成する個々の神経細胞の性質とその集合体である神経回路網における神経細胞間の創発作用によって基本的に担われている [1, 2]. この神経細胞には, 他の神経細胞からの信号電位の影響を総和し (線形加算性), その総和が神経興奮のためのしきい値を越えなければ何事も起こらず, 越えれば信号を出す (非線形しきい値性) という 2 つの特徴が確認されている [3]. ニューラルネットワークは, このような特徴を持つ脳の神経細胞を多入力・1 出力の非線形素子 (ニューロンモデル) として数理的にモデル化し (以降, ニューロンと呼ぶ), そのニューロンを多数個結合させた神経回路網 (ニューラルネット) の相互作用によって情報処理を人工実現させようとするものである. 実際, 脳は自己組織化, 環境適応, 並列分散処理などの機能を備えている. ニューラルネットワークは, この脳に学ぶことでノイマン型コンピュータに代わる新しい情報処理機構の構築をめざすものである [4, 5, 6].

このニューラルネットワークの基礎となるネットワークモデルのなかで, ニューロンの対称相互結合ネットワークによって, 記憶の機能を簡明に記述したものにホップフィールドによる連想記憶モデル [7] が知られている. ニューラルネットにエネルギーの概念を導入し, 記憶の記録・想起の機能をニューラルネット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意義深いものである. そして, この性質に着目して, 連想記憶のみならず組み合わせ最適化問題等の課題に適用され, 工学的モデルとしての利用が進められてきた [4].

しかしながら, このモデルでは, ネットワーク外部との接触は初期状態としての外部情報取得時のみに限られ, その後のネットワーク状態の遷移は閉じた系としてエネルギーの低い安定平衡点 (ポイントアトラクタ) へ移行する緩和過程であり, このままでは記憶と想起のモデルの枠組みとしては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 [8, 9].

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の同定可能性を確認してきた [10, 11, 12].

また, 入力情報としてランダムパターンに加え非直交パターンに対する応答性の評価も行い [13], 両パターン信号に対する高い信号識別・同定性能を確認してきた.

ところで, これまでの研究は, 記録パターン数を比較的小さい値に固定して実施したものであるが, モデルのロバスト性, 汎用性を考慮すると, 記録パターン数の増加に対する識別性能の分析が次なる課題となる. 記録パターン数の増加に対しては, 各記録パターンの引力圏が相互に密になり, ネットワーク応答性が劣化することが予想される. そこで本研究では, この課題に対し, ネットワーク構造の決定処法すなわちパターン記録時の学習条件の制御を通して, 本提案モデルによるパターン識別性能の分析を行うとともにその改善を図る. 具体的には, パターン記録時の記憶の安定度および結合荷重更新単位の設定値に対する本モデルの信号識別性能を, 入力信号とそれに対するネットワーク応答との時間相互相関に基づいて評価・分析を行う.

## 2. モデリング

### 2.1 動的記憶想起モデル

$N$  個のニューロン ( $i = 1, \dots, N$ ) が, シナプス結合  $w_{ij}$  (ただし,  $w_{ii} = 0$ ) で結ばれたニューラルネットワークを考える. 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 ( $w_{ij} = w_{ji}$ ) である. このモデル [7] 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, その後のネットワーク状態の遷移は, 閉じた系として内部的に進行する. すなわち, 外部情報取得後の各ニューロンの時間発展は,

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

で与えられる. ただし,  $f(y) = \tanh(y/2\epsilon)$ , ニューロン値  $X_i$  は  $-1 \leq X_i \leq 1$  で定式化されている.  $\theta_i$  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を次のように, (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.

$$X_i(t+1) = f\left(\sum_{j=1}^N w_{ij} X_j(t) - \theta_i + S_i(t)\right) \quad (2)$$

これは, 外部入力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取り扱うものであり, 図示すると Fig.1 のようになる. 閉じたシステムとしての静

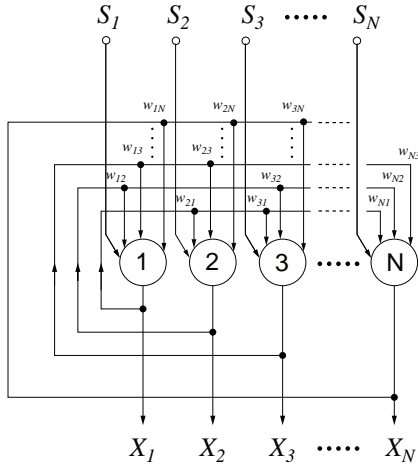


Fig.1 Recurrent neural network extended to an input-output system.

動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

$$E(\mathbf{X}) = -\frac{1}{2} \sum_{i,j} w_{ij} X_i X_j + \sum_{i=1}^N \theta_i X_i \quad (3)$$

(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、

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

であることを考慮すると、(2) 式は

$$X_i(t+1) = f\left(-\frac{\partial E(\mathbf{X})}{\partial X_i} + S_i(t)\right) \quad (5)$$

となる。

(5) 式は、入力信号が与えられると、ネットワークの振る舞い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  $\partial E(\mathbf{X})/\partial X_i$  両者の競合に依存することを示している。具体的には、Fig.2 に示すように、既知パターン(記憶パターン)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(非記憶パターン)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

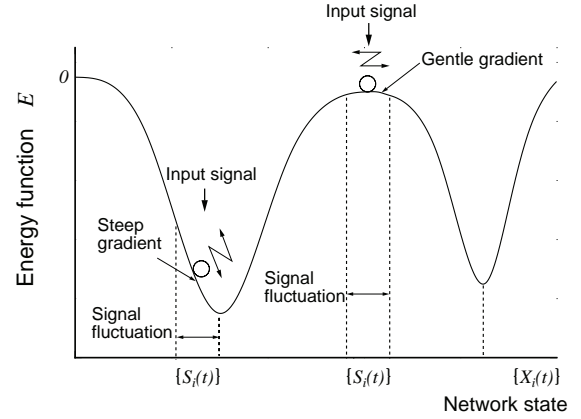


Fig.2 Scheme of dynamic associative memory model.

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。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 パターン記憶(既知パターン生成)の学習則

パターン記憶、すなわち、 $\{w_{ij}\}$  の決定処方としては、従来の静的記憶の埋め込み方法およびそれを拡張した以下のような手法を導入し、学習条件の制御を行う。ネットワークに記憶させたいパターン  $R^\mu$ (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

$$\gamma_i^\mu \equiv \xi_i^\mu \sum_{j=1}^N w_{ij} \xi_j^\mu > 0 \quad (6)$$

なる条件が成立すればよいことが知られている [4]。ここで、(6) 式を満足する十分条件

$$\gamma_i^\mu \equiv \xi_i^\mu \sum_{j=1}^N w_{ij} \xi_j^\mu > \kappa_{min} (> 0) \quad (7)$$

により、 $\gamma_i^\mu$  の下限値  $\kappa_{min} (> 0)$  を導入し、その値の調節を通して局所安定な  $\{\xi_i^\mu\}$  の引力圏の形成およびその制御を行う。 $\kappa_{min}$  は、その値が大きくなるほどそれに対応する記憶パターン状態が形成する引力圏が拡大され、ネットワーク状態  $\{X_i(t)\}$  が記憶パターン  $\{\xi_i^\mu\}$  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  $\gamma_i^\mu$  は記憶の安定度、 $\kappa_{min}$  は記憶の引力圏パラメータと呼ばれている。さらに、 $\gamma_i^\mu$  に上限値  $\kappa_{max}$  を導入し、 $\kappa_{min} < \gamma_i^\mu \leq \kappa_{max}$  という条件を設定することにより、記憶成立後の各記憶パターンが形成する引力圏すなわち各パターン状態のエネルギー関数値  $E$  の分布を調節する。

ディーデリッヒ (Diederich) とオPPER (Oppen) [14] は、与えられた  $M$  個の記録パターン ( $\mu = 1 \sim M$ ) に対して (6) 式が成立するまで

$$w_{ij}^{new} = w_{ij}^{old} + \delta w_{ij}^{\mu} \quad (\delta w_{ij}^{\mu} = \frac{c}{N} \xi_i^{\mu} \xi_j^{\mu}) \quad (8)$$

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。ここで、 $c$  は記録学習時の重み付け (結合荷重更新単位) であり、この値を調節することにより、学習条件の細かい制御が可能となる。

### 3. 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

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、Fig.3 のように  $12 \times 13 (= 156)$  のユニット構成でランダムパターンを 50 個 ( $R^1 \sim R^{50}$ ) 用意した。これらのパターンはいずれも  $\xi_i = 1$  と  $\xi_i = -1$  のユニットが半々であり、 $R^1 \sim R^{50}$  間の互いの重なり  $q_{\mu\nu} \equiv (1/N) \sum_{i=1}^N \xi_i^{\mu} \xi_i^{\nu}$  は  $-0.24 \leq q_{\mu\nu} \leq 0.26$  の範囲に分布している。

Fig.4 は、 $R^1 \sim R^{10}$  を既知パターン対象として、2.2 で説明した逐次学習則を  $\gamma_i^{\mu} > 1.0$  ( $\kappa_{min} = 1.0$ )、 $c = 1.0$  という条件の下で実行したときの、記録成立後の安定度  $\gamma_i^{\mu}$  ( $156 \times 10 = 1560$  個) の度数 (count) 分布 (区分の幅  $\Delta\gamma_i^{\mu} = 0.1$ ) である。

Fig.5 は、学習終了後の結合荷重  $\{w_{ij}\}$  に基づいて各パターン状態のエネルギー値  $E$  を求めたものである。ネットワークに記録させた  $R^1 \sim R^{10}$  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掘り下げられているが、記録対象としなかった  $R^{11} \sim R^{20}$  の 10 パターン (以降、未知パターンと呼




Fig.3 Examples of the used random patterns(white and black pixels represent  $\xi_i = -1$  and  $+1$ , respectively.).




Fig.4 Distribution of the stability coefficients after the iterative learning for  $R^1 \sim R^{10}$ .

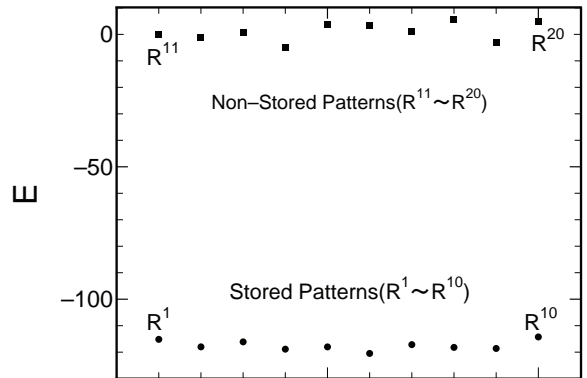


Fig.5 Comparison of the energy function values between stored patterns  $R^1 \sim R^{10}$  and non-stored patterns  $R^{11} \sim R^{20}$ .

ぶ) は、0 付近 ( $\pm 5$ ) のエネルギー値に留まっている。各パターン状態  $\{\xi_i^{\mu}\}$  に対応するエネルギー値は、(3) 式に (6) 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  $\gamma_i^{\mu}$  の平均が概ね 1.5 である (Fig.4 より) ことを適用すると、 $\overline{E^{(\mu)}} \simeq -(1/2) \times N \times 1.5 = -(1/2) \times 156 \times 1.5 = -117$  が得られる。

#### 3.2 ネットワーク応答性の評価

入力パターン情報としては、Fig.3 の各パターンに対し、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  $R^{\mu}$  (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、 $FL = 1$  のときは最大 78 個 (全体の半数



$N/2$ ),  $FL = 0.3$  のときは,  $(N/2) \times 0.3 = 78 \times 0.3 \simeq 23$  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. このゆらぎを, 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発生させ, 時間的に継続する入力情報  $\{\xi_i^\mu(t)\}_{FL}$  を生成した. なお, 各  $\{\xi_i^\mu(t)\}_{FL}$  の継続時間は  $T_I$  である.

Fig.6 は,  $R^1 \sim R^{10}$  の 10 個のパターンを記録後, 既知パターン (Stored Pattern: SP) に  $R^8$ , 未知パターン (Non-Stored Pattern: NSP) に  $R^{27}$  を用いたときの入力情報  $\tilde{S}(t) = \{\xi_i^8(t)\}_{FL}, \{\xi_i^{27}(t)\}_{FL}$  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

$$m_I^\mu(t) = \frac{1}{N} \sum_{i=1}^N \tilde{S}_i(t) \xi_i^\mu = \frac{1}{N} \tilde{S}(t) \cdot \xi^\mu \quad (9)$$

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. 学習条件は Fig.4 と同じであり, 入力情報のゆらぎレベルは  $FL = 0.3$ , 各ゆらぎの切替時間間隔は  $T_I = 50$  に設定している.  $m-t$  平面上への射影はゆらぎ生成法が同じなので, 既知パターン (SP), 未知パターン (NSP) の間で一致している ( $m_I^8(t) = m_I^{27}(t)$ ). しかしながら, 対応するエネルギー値としては, 両パターン間で顕著な差が存在する. すなわち, NSP においてはエネルギー値は 0 付近に位置しているのに対し, SP では  $-120$  から  $-60$  の広い範囲に及んでいる.

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,




Fig.6 Time series of stored and non-stored pattern input signals with the same fluctuation, shown by the energy function and the overlap.

$$\{S_i(t)\} = s\{\xi_i^\mu(t)\}_{FL} \quad (10)$$

の形で構成され, (2) 式の内部状態に作用させられることになる.

Fig.6 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  $m_o^\mu(t) = (1/N)\mathbf{X}(t) \cdot \xi^\mu$  と  $E(\mathbf{X}(t))$  を, Fig.6 の入力情報 (図中の破線) とともに示したものが, Fig.7 である. 未知パターン信号 (Non-Stored Pattern Signal: NSPS) においてはゆらぎによるエネルギー - 変位が小さいため, ネットワーク出力はほぼ Fig.6 の NSP ( $R^{27}$ ) に一致している. 一方, 既知パターン信号 (Stored Pattern Signal: SPS) の場合には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 Fig.6 の SP ( $R^8$ ) をトレースできていない.

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を導入する [15]. 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  $\mathbf{S}(t) = (S_1(t), S_2(t), \dots, S_N(t))$ ,  $\mathbf{X}(t) = (X_1(t), X_2(t), \dots, X_N(t))$  とすると, 時間相互相関  $r$  は,

$$r = \frac{C(\tilde{S}(t), \mathbf{X}(t+1))}{[C(\tilde{S}(t), \tilde{S}(t))]^{1/2} [C(\mathbf{X}(t+1), \mathbf{X}(t+1))]^{1/2}} \quad (11)$$

で定義される. ただし,  $C(\mathbf{Y}, \mathbf{Z}) = \overline{(\mathbf{Y} - \bar{\mathbf{Y}}) \cdot (\mathbf{Z} - \bar{\mathbf{Z}})}$ ,  $\tilde{S} = \mathbf{S}/s$ ,  $-$  は時間平均を示す. Fig.7 の SPS および




Fig.7 Time series of the network responses to stored and non-stored input signals in  $M = 10$  case.

NSPS に対するネットワーク応答の違いをここで導入した時間相互相関  $r$  を通して評価すると、SPS( $R^8$ ) に対しては  $r = 0.619$ ，NSPS( $R^{27}$ ) に対しては  $r = 0.997$  となり、出力が入力をトレースできない度合に応じて  $r$  値が小さくなっている。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。

Fig.8 は、Fig.6 と同じ学習条件で記録パターン数を 20 ( $M = 20$ ) としたときのネットワーク応答の時系列変化を表したものである。記録パターン数の増加すなわち安定平衡点の増加に伴い、未知パターン状態付近でもいづれかの安定平衡点の引力圏に属するネットワーク状態が多数存在するようになり、エネルギー関数勾配の影響が強まっている。設定した信号強度 ( $s = 1.25$ ) では、未知パターン信号が信号に対応するネットワーク状態付近までネットワークを誘導することができておらず、応答性の劣化が顕著になっている。既知・未知それぞれの入力信号に対する時間相互相関  $r$  は、SPS( $R^8$ ) に対しては  $r = 0.635$ ，NSPS( $R^{27}$ ) に対しては  $r = 0.759$  である。

これらの時系列データ ( $t = 6000$  まで) を異なる  $s$  ごとに取得し(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  $r$  を求め、それらを  $s$  に対してグラフ化したのが Fig.9 の信号強度依存性である。記録パターン数を 10( $M = 10$ ) に設定した場合、 $s$  が 1.0 より小さい領域ではネットワークは最寄りの局所安定状態(入力パターン情報とは離れた状態)に停留したままで、入力情報を反映していない( $r = 0$ )。  $s$  が 1.0 を超えるとネットワークは初期状態の最寄りの局所安定状態を脱することが可能になり、入力信号に近い状態に導か



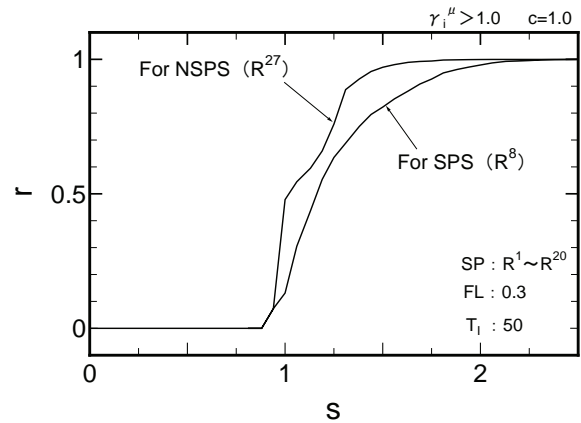


Fig.8 Time series of the network responses to stored and non-stored input signals in  $M = 20$  case.



(a)  $M = 10$



(b)  $M = 20$

Fig.9 Dependence of the network response on the signal strength in the case of (a)  $M = 10$  and (b)  $M = 20$ .

れる。そして、既知・未知信号に対応するネットワーク状態におけるエネルギー関数勾配の違いにより、両信号に対するネットワーク応答性に、顕著な違いが表れている。両者の違いは、 $s = 1.5$  付近まで維持されており、この領域で既知と未知の信号識別が可能であることがわかる。

一方、記録パターン数を 20 とした場合は、未知パターン信号に対する  $r$  の信号強度依存性に大きな劣化が表れ、既知・未知両信号に対するネットワーク応答に差が見られなくなっている。このことは、すなわち記録パターン数の増加に伴い入力信号の既知と未知の信号識別が困難になっていることを示している。この信号識別性能の劣化に対し、信号切替時間間隔 ( $T_I$ ) およびゆらぎレベル (FL) の影響を考察した。

Fig.10 は、 $T_I$  を 1 に設定し、同様のシミュレシヨ




Fig.10 Dependence of the network response on the signal strength in  $T_I = 1$  case.

ンを行った結果である．未知信号に対するネットワーク応答の向上，既知信号に対するネットワーク応答の劣化が生じ，両者間の差が増大している．ゆらぎによる未知信号の変動に対し，ネットワークはそれに応じた応答を示している．これが，ゆらぎの周波数の増加に伴い顕著に表れたためであると考えられる．一方，既知信号に対しては，ネットワークがゆらぎの変化に追従できなくなり，既知パターン状態に対応する安定平衡点に停留する傾向が強くなったためと考えられる．

Fig.11は，さらにゆらぎレベルを小さく設定し ( $FL = 0.1$ )， $r$  値の信号強度依存性を調べた結果である．ゆらぎレベルが小さくなることにより，安定平衡点へのネットワークの停留傾向は一層強まっている．一方未知信号に対しては，ゆらぎ変動幅の減少によりネットワークの動きが鈍化されているが，一定強度 ( $s = 1.5$  付近) の信号が与えられると入力信号の影響が強まり，ネットワーク応答は逆に向上している．




Fig.11 Dependence of the network response on the signal strength in  $T_I = 1$  and  $FL = 0.1$  case.

#### 4. 学習条件の変更に対するネットワーク応答性の評価

以上の結果から，記録パターン数の増加に対し， $T_I$  の減少すなわち信号の切り替え周波数を増加させることにより，既知・未知両信号に対するネットワーク応答の差が拡大され，信号識別性能に一定の向上がみられることが明らかになった．しかしながら，信号識別に十分機能するレベルに達していない．特に未知信号に対するネットワーク応答の一層の改善が必要である．実際 Fig.8 の時系列データからもネットワーク状態が入力信号（未知信号）付近に誘導されておらず，信号に対し大きなエネルギー関数の変動を生じており，それが  $r$  値の劣化に影響している．そこで，ネットワークに対する入力信号の影響が支配的となる信号強度領域を高くすることにより，信号に対する追従性の向上を図る．このことは，記録パターンに対応するネットワーク状態のエネルギー関数値を小さくすること，すなわち記憶の安定度  $\gamma_i^\mu$  を大きく設定することになる．

Fig.12は，20個の記録パターン ( $R^1 \sim R^{20}$ ) を  $2.0 < \gamma_i^\mu \leq 3.0$ ， $c = 0.5$  という学習条件でネットワークに記憶させ，信号切替時間間隔とゆらぎレベルを Fig.10 と同様の値に設定して ( $T_I = 1$ ， $FL = 0.3$ )，ネットワーク応答の信号強度依存性を取得した結果である． $\gamma_i^\mu$  を大きく設定するとともに， $\kappa_{max}(= 3.0)$  を与え， $\gamma_i^\mu$  を一定の領域に制限した．また， $w_{ij}$  の更新単位を細かく設定した ( $c = 0.5$ )．学習条件変更の影響がネットワーク応答に表れており，信号識別性能の著しい向上がみられる．既知・未知両信号に対するネットワーク応答に差が確認できる信号強度 ( $s$ ) の範囲は， $s = 2.0 \sim 2.75$  で




Fig.12 Dependence of the network response on the signal strength in  $2.0 < \gamma_i^\mu \leq 3.0$  and  $c = 0.5$  case.

あり、10パターンを記録させた場合 ( $s = 1.0 \sim 1.5$ ) に比べ、広い範囲でネットワーク応答の違いが維持されている。

記憶の安定度の増加は、エネルギー関数勾配も増加させ、(5) 式の、入力信号  $S_i(t)$  とエネルギー関数勾配による引き込み力  $\partial E(\mathbf{X})/\partial X_i$  双方を増加させることになる。しかし、両者の競合関係は、既知と未知および記憶の安定度  $\gamma_i^\mu$  の設定値によって大きく異なることが予想される。すなわち、 $\gamma_i^\mu$  が小さい領域では、既知・未知両入力信号に対し、エネルギー関数勾配の影響が支配的となり ( $|\partial E(\mathbf{X})/\partial X_i| > |S_i(t)|$ )、入力信号がネットワーク応答に反映されない。 $\gamma_i^\mu$  の増加に伴い、未知信号に対しては、初期状態から入力信号状態付近に誘導後、信号の影響が支配的となり ( $|\partial E(\mathbf{X})/\partial X_i| < |S_i(t)|$ )、未知信号に対する  $r$  値が増加する。一方、既知信号に対しては、エネルギー関数勾配の増加に対する入力信号強度の増加が十分ではなく ( $|\partial E(\mathbf{X})/\partial X_i| > |S_i(t)|$ )、入力信号の影響がネットワーク応答に反映されない。したがって、この領域において、既知・未知両入力信号に対するネットワーク応答に差が表れると考えられる。

Fig.13 は、記憶の安定度 ( $\gamma_i^\mu$ ) の設定域を変化させて ( $\kappa_{max} - \kappa_{min} = 1.0$ )、ネットワークの応答性を評価した結果である。 $\gamma_i^\mu$  の設定域の増加に伴い、未知信号に対しては入力信号の影響が支配的となり、ネットワークは高い相関を示すようになる。一方、既知信号に対しては、 $r$  の信号強度依存性にほとんど変化はみられない。すなわち、 $\gamma_i^\mu$  の増加とともに既知・未知両信号に対するネットワーク応答の差が増大している。この傾向は、Fig.12 の学習条件  $2.0 < \gamma_i^\mu \leq 3.0 (\kappa_{min} = 2.0)$  付近まで続いて




Fig.13 Dependence of the network response on the signal strength in each region of stability of coefficient in  $M = 20$  case.

いる。 $\gamma_i^\mu$  をさらに高い領域に設定すると、既知信号に対しても信号強度の増加に伴う入力信号の影響が表れ、既知信号に対する  $r$  値が高くなりネットワーク応答の差が小さくなっている。

ここで、 $\gamma_i^\mu$  の設定域に対する既知と未知の信号識別性能を定量的に評価する指標として、以下に示す  $sum(\Delta r(s))$  を導入する。

$$sum(\Delta r(s)) = \sum_{s=s_1}^{s_2} \Delta r(s) \cdot \Delta s \simeq \int_{s_1}^{s_2} \Delta r(s) ds \quad (12)$$

ただし、 $\Delta r(s)$  は、各信号強度ごとの既知・未知それぞれの入力信号に対する時間相互相関  $r$  の差、すなわち  $\Delta r(s) = r_{R^{27}}(s) - r_{R^8}(s)$ 、 $\Delta s$  は信号強度の刻み幅である。

Fig.14 は、 $sum(\Delta r(s))$  を用いて  $\gamma_i^\mu$  の設定域 ( $\kappa_{max} - \kappa_{min} = 1.0$ ) ごとに、信号識別性能を評価した結果である。学習条件  $2.0 < \gamma_i^\mu \leq 3.0 (\kappa_{min} = 2.0)$  で、 $sum(\Delta r(s))$  値は最大となっており、この領域でネットワークは高い信号識別性能を有していることがわかる。

Fig.15 は、 $2.0 < \gamma_i^\mu \leq 3.0, c = 0.5$  という学習条件で、記録パターン数を、10、15、20、25 と変化させて、信号識別性能を評価した結果である。記録パターン数を 10 および 15 に設定した場合、入力信号の影響が支配的となる信号強度  $s = 2.0$  において、未知パターン信号に対する  $r$  値はほぼ 1.0 に近い値を示しており ( $M = 10 : r = 0.998, M = 15 : r = 0.959$ )、学習条件変更の効果が確認できる。記録パターン数が 20、25 と増加するに伴い、未知信号に対する  $r$  値の劣化が顕著になる。しかしながら、記録パターン数を 25 に設定した場合でも、既知と未知の信号識別性能は維持されている。




Fig.14 Dependence of the signal identification performance on the stability of coefficient in  $M = 20$  case.






Fig.15 Dependence of the network response on the signal strength in each number of stored patterns in  $2.0 < \gamma_i^\mu \le 3.0$  and  $c = 0.5$  case.

## 5. おわりに

本論文では、従来の連想記憶モデルを拡張し、開放系としてのシステム化を図った動的記憶想起モデルにおいて、記銘パターン数の増加に伴うパターン識別性能劣化に対して、パターン記銘時の学習条件の制御を通してその分析を行うとともに改善を図った。その結果、入力信号に対するネットワーク応答は、記憶の安定度  $\gamma_i^\mu$  の設定値に対し、高い依存性を有していることが明らかになった。この依存性は、既知・未知両入力信号間で異なっており、信号識別性能が著しく向上する  $\gamma_i^\mu$  の領域 ( $2.0 < \gamma_i^\mu \le 3.0$ ) の確保が確認できた。この学習条件においては、記銘パターン数の広い設定値 ( $M = 10 \sim 25$ ) に対し、既知・未知パターン信号の高い識別性能を確認でき、本提案モデルのロバスト性および汎用性を示すことができた。

今後の課題としては、まず、文字、画像等の非直交パターンに対する学習条件依存性の分析が挙げられる。非直交パターンを記銘させた場合、既知と未知のパターン間の相関により、一層の性能劣化が予想される。そのため、記憶の安定度  $\gamma_i^\mu$  のより細かな調節が必要となる。また、本論文では、既知・未知それぞれ1つのパターンについてのみ評価・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っていく必要がある。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。

## 謝 辞

本研究遂行にあたり、有益なご指導を賜りました兵庫県立大学大学院西村治彦教授に深甚なる謝意を表します。

## 参考文献

- [1] M. A. Arbib (ed.): The Handbook of Brain Theory and Neural Networks (2nd Edition); The MIT Press (2002)
- [2] M. Minsky: The Emotion Machine -Commonsense Thinking, Artificial Intelligence, and the Future of the Human Mind-; Simon & Schuster (2007)
- [3] 松村道一: ニューロサイエンス入門; サイエンス社 (1995)
- [4] B.Müller and J.Reinhardt: Neural Networks: An Introduction; Springer-Verlag(1990)
- [5] 中野馨: 人間情報工学 - バイオニクスからロボットまで - ; コロナ社 (1996)
- [6] 甘利俊一: 神経回路網モデルとコネクショニズム (新装版); 東京大学出版会 (2008)
- [7] J.J.Hopfield: Neural networks and physical systems with emergent collective computational abilities; Proc. Natl. Acad. Sci. USA, Vol. 79, pp. 2554-2558(1982)
- [8] 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)
- [9] 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)
- [10] 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)
- [11] 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)

- [12] 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)
- [13] 道法浩孝, 長尾夏樹, 堅田尚郁: 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; 高知大学教育学部研究報告, 第70号, pp.119-128(2010) .
- [14] S.Diederich and M.Opper: Learning of Correlated Patterns in Spin-Grass Networks by Local Learning Rules; Phys.Rev.Lett., Vol. 58, pp. 949-952(1987)
- [15] 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)

平成22年 (2010) 12月14日受理  
平成22年 (2010) 12月31日発行