

カオス・ニューラルネットワークにおける 動的想起・学習機構

A Scheme for Dynamic Learning and Retrieving
in Chaotic Neural Networks

兵庫教育大学

西村 治彦 (*haru@life.hyogo-u.ac.jp*)

堅田 尚郁 (*katada@life.hyogo-u.ac.jp*)

1 はじめに

記憶機能を最も簡明な形で具体的にモデル化しようとしたのが、ホップフィールド(Hopfield)による静的連想記憶モデル [1, 2] である。これは、神経細胞を1つの非線形入出力関数(ニューロ素子)として数理モデル化し、その回路網(ニューラルネットワーク)にエネルギーの概念を導入、記憶対象をそのエネルギー関数の極小値状態に対応させるというものである。記憶・想起の機能が力学系における問題として理論化され得る可能性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、時間経過とともにネットワークが初期状態からエネルギーの低い安定平衡状態へと緩和してゆくダイナミクス(ポイント・アトラクター)だけでは不十分であることも確かである。現実の脳神経系の挙動はもっと動的で活力に富んだものである。実際、イソアワモチやヤリイカの巨大神経、ラットの自己刺激時の海馬錐体細胞の活動、ウサギの嗅球脳波、ヒトの様々な状態での脳波など、神経系から取り出された神経細胞一本の電氣的応答から神経回路網の集積である脳全体の活動状態まで、いくつかの階層レベルでカオスが観測されている [3]。また、単一ニューロンレベルでのカオスの存在は、神経軸索の生理学的知見をもとに作られたホジキン-ハクスレイ(Hodgkin-Huxley)方程式の理論的考察 [4] からほぼ定量的に裏づけられている。この事実は、従来の連想記憶モデルに対して神経回路網の基本構成単位であるニューロンレベルからの再検討を迫るものである。

このような状況の中で、カオス・ダイナミクスを有するニューロ素子であるカオスニューロン及びその回路網のカオス・ニューラルネットワークモデルが提案された [5]。カオスニューロンは、実際の神経細胞に見られる不応性(ニューロンの発火(興奮)状態が続くと、それに応じてニューロンが発火(興奮)しにくくなる性質)とアナログ的な入出力特性、および時間とともに指数関数的に減衰する履歴性を有している。また、その応答特性にカオス解が存在することは数値実験を通して具体的に検証されている。このカオス・ニューラルネットワークを用いた記憶機能に関する最初の研究は、ネットワークに内在するカオス・ダイナミクスが起こすカオスの遍歴現象 [8] を記憶の動的(時系列的)な想起現象に対応させようとするものであった [6, 7]。そして、カオス・ダイナミクスに同様の役割を担わせようとする取り組みは、他のモデルでも行われている [9, 10, 11]。ただ、そこでの検討は主として閉じたネットワーク内での自律的振舞いと強カオス現象を対象とするものであった。

そこで我々は、外界との相互作用を前提とし、弱カオス現象(カオスの震動/カオスの突発)にも注目する新たなモデル化を行なった [12, 13]。そして、外界との相互作用がないときにはカオスの基準モードにあり、外部刺激に応じて(カオスの)想起モードへ移行するという動的記憶想起機構(図1)の可能性を確認している。しかし、その対象は主として記憶の想起過程だけで

あり、記憶機能が記銘、想起、忘却という3つの基本過程から成ることを考えると、次なる課題としてカオス・ニューラルネットワークにおける動的記銘学習過程の検討が必要となる。本論文では、カオス・ニューラルネットワークに対して、シナプス結合荷重が可塑的に変化し得る刺激-応答機構を導入し、外界からの刺激情報を受ける中でネットワークがどのように記憶形成(記銘)を進行させ得るかを分析することにする [14, 15]。カオス・ニューラルネットワークが有する不応性と履歴性の調節を通して、カオス・ダイナミクスが記銘学習に果たす役割についても検討する。その際、ネットワークに不応性と履歴性が無い場合はホップフィールド型ニューラルネットに一致するので、従来の静的連想記憶モデルの対比も容易である。さらに、力学的性質の違う確率的ニューラルネットワークを取り上げてカオス・ニューラルネットワークの場合と比較し、カオス・ダイナミクスの性質と有効性についての更なる理解を目指す。その中で、カオス・ニューラルネットワークによる動的記銘学習の実時間的機構の可能性と方向性を模索できればと考えるものである。

2 モデリング

2.1 ニューラルネットワークモデル

まず、本論文の主たるテーマである動的記憶形成過程とそのダイナミクスを検討する上で中心的な位置を占めるカオス・ニューラルネットワーク (Chaotic Neural Network CNN) [5] について述べる。各ニューロンへの他ニューロンからのフィードバック入力に対しても不応性の場合と同様に指数ベキ減衰の履歴効果を認めると、 i 番目のニューロンの発展方程式は

$$X_i(t+1) = f\left(\sum_{j=1}^N w_{ij} \sum_{d=0}^t k_f^d X_j(t-d) - \alpha \sum_{d=0}^t k_r^d X_i(t-d) - \theta_i\right) \quad (1)$$

で与えられる。ただし、

w_{ij} : j 番目のニューロンから i 番目のニューロンへの結合荷重

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 ($0 \leq k_f < 1$)

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 ($0 \leq k_r < 1$)

α : 不応性項のスケーリング・パラメータ ($\alpha \geq 0$)

θ_i : i 番目のニューロンのしきい値

であり、厳密には文献 [5] におけるニューロン値 x_i ($0 \leq x_i \leq 1$) を X_i ($\equiv 2x_i - 1$) に変更して定式化 [13, 15] している。時刻 $t+1$ におけるニューロン状態値はその前の時刻 t の状態値だけから決定されるのではなく、時刻 0 から時刻 t までの過去の全ての状態の影響を受けることになる。

(1) 式の内部状態のフィードバック入力に関する項と不応性に関する項をそれぞれ

$$\eta_i(t+1) = \sum_{j=1}^N w_{ij} \sum_{d=0}^t k_f^d X_j(t-d) \quad (2)$$

$$\zeta_i(t+1) = -\alpha \sum_{d=0}^t k_r^d X_i(t-d) - \theta_i \quad (3)$$

と置き、その変形を行うと

$$\eta_i(t+1) = k_f \eta_i(t) + \sum_{j=1}^N w_{ij} X_j(t) \quad (4)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha X_i(t) + a \quad (5)$$

が得られる(ここで簡単のために $-\theta_i(1-k_r) \equiv a$ と表した.)。そして、(1)式は、

$$X_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1)) \quad (6)$$

に帰着される。つまり、ニューロンの(外部)状態値 X_i だけでなく内部状態にも着目すれば、時刻 $t+1$ における状態値は前の時刻 t のみの内部状態 $\eta_i(t), \zeta_i(t)$ と(外部)状態値 $X_i(t)$ を用いて決定されることがわかる。(4), (5)式への書き換えにより、コンピュータ上での時間発展シミュレーションは容易になるが、このような変形ができたのは、フィードバック入力および不応性効果の履歴性が指数関数的に時間減衰すると仮定したこと起因している。

(4), (5)式において $k_f = k_r = \alpha = 0$ と設定すると(6)式は、

$$X_i(t+1) = f\left(\sum_{j=1}^N w_{ij} X_j(t) - \theta_i\right) \quad (7)$$

となる。これはホップフィールド型ニューラルネットにおける従来のニューロンの発展方程式に一致する。すなわち、カオス・ニューラルネットワークは $k_f = k_r = \alpha = 0$ (以降、これをホップフィールド極限(Hopfield Limit HFL)と呼ぶ。)のときは従来の静的連想記憶ホップフィールドモデルと等しいが、これらのパラメータを0から増加させることにより、従来の静的連想記憶モデルには存在しないカオス・ダイナミクスを容易に導入することができる。

また、ホップフィールド型ニューラルネットでのニューロン状態は(7)式に従って決定論的(非確率的)に更新されるが、これに対してニューロン状態を以下のように確率的に更新させる確率的ニューラルネットワーク(Stochastic Neural Network SNN)を考えることができる。

$$\begin{cases} \text{Prob}\{X_i = f(h_i)\} = g_H(|h_i|) \\ \text{Prob}\{X_i = -f(h_i)\} = 1 - g_H(|h_i|) \end{cases} \quad (8)$$

ただし、

$$g_H(h) = \frac{1}{1 + e^{-h/H}} \quad (9)$$

ここで、 $\text{Prob}\{\}$ は $\{\}$ が生じる確率を意味する。また、ニューロン状態値の転移(+1 \leftrightarrow -1)の出現確率を左右するパラメータ H を温度と呼び、この温度による確率的影響を熱的ノイズと呼ぶことにする。 $H \rightarrow 0$ の極限では $g_H \rightarrow 1$ となるので(8)式はホップフィールド型ニューラルネットの決定論的な発展方程式(7)に一致する。

ニューロン状態への熱的ノイズは、それが大きい場合には何らかのニューロン異常に起因する信号発生の誤動作として否定的に解釈されることが多いが、小さい場合には系の振舞いに柔軟性を持たせる自発的ゆらぎ(良い意味での確率的活性)としての積極的な役割を担う可能性が

ある。一方、カオス・ニューラルネットワークの場合は(1)式に従って決定論的に状態更新が行われるが、そこにはカオス挙動が出現し、熱的ノイズ同様、ネットワークに柔軟性を与える自発的ゆらぎ(良い意味での(決定論的)カオス活性)として作用する可能性がある。記憶形成過程に及ぼす両者の影響について検討し、その違いを明らかにすることが必要である。

2.2 刺激-応答機構の導入

生体は、その機能を維持するために、外界からの入力情報に対して自らの状態を適応的に更新できる自己組織的なシステムである。認知、記憶、思考などの脳の知的機能にとっても脳内神経細胞群と外界との相互作用は重要な役割を担っていると考えられる。そこで、ここではニューラルネットワークモデルを外界との接触が可能な形に拡張し、しかも外部入力に対してシナプス結合荷重 w_{ij} が可塑的に変化し得る刺激-応答機構を導入する。

まず、外部刺激(記号では Se と表す)の寄与は、カオス・ニューラルネットワークの発展方程式(6)に対して、 Se の持続時間に応じて内部状態に一時的に外部刺激項 $\{\sigma\}$ ($i = 1, \dots, N$) を付加する形 ($\eta_i + \zeta_i \rightarrow \eta_i + \zeta_i + \sigma_i$) で考慮することにする:

$$X_i(t+1) = f(\eta_i(t+1) + \zeta_i(t+1) + \sigma_i) \quad (10)$$

これは、外部刺激 Se の効果をネットワーク内の各ニューロンに対する一時的なしきい値変化として取り扱うものであり、外部刺激によるニューロン発火性(興奮/抑制)への影響のモデル化としては簡明かつ有効な形式の1つである。

さらに、外部刺激下での結合荷重は固定的ではなく、

$$w_{ij}(t+1) = w_{ij}(t) + \beta X_i(t) X_j(t) \quad (11)$$

に従って時間的に可塑的に変化するものとする。ただし、無刺激時の結合荷重は無変化($\beta = 0$)とする。ここで β は結合荷重の可塑性の度合いに関するパラメータであり、可塑パラメータとよぶことにする。また、シナプス強度が無限に成長し(大きくなり)続けることを防ぐため、結合荷重のノルム


$$\|w_i(t+1)\| \equiv \left(\sum_{j=1}^N w_{ij}^2(t+1) \right)^{1/2} \quad (12)$$

の成長には上限 K_i が存在し、到達後は

$$w_{ij}(t+1) \times \frac{K_i}{\|w_i(t+1)\|} \rightarrow w_{ij}(t+1) \quad (13)$$

によって規格化されるものとする。(11)式は、ニューロンが興奮したときにそのニューロンに同時に興奮性の入力を与えたシナプスの結合荷重が強化されるというヘブ(Hebb)の学習則 [16] の一般化である。言い換えれば、入力ニューロン j と出力ニューロン i の積(AND)演算によって $i-j$ 間の結合が強化されるというものである。

次に、外部刺激の印加時間の過程構成としては、外部刺激 Se が T_s (刺激持続時間) の間印加され、その後、次の刺激が印加されるまで無刺激状態をとるという繰り返しが時間間隔 T_I で行われることとする。図示すると、



のようになる。ただし、外部刺激に複数種類がある場合には、一つの T_s の間は同一の刺激が継続印加され、次の T_I の T_s で別刺激に変更されるものとする。

3 計算機実験における具体的設定

2.2節で導入した刺激-応答機構に基づき記憶形成過程に関する実験を計算機上で具体的に展開するために、ニューラルネットワークを構成する全ニューロン数は $156 (N = 156)$ とし、記銘パターンとしては $12 \times 13 (= 156)$ のユニット構成で、アルファベット $A \sim Z$ の 26 文字を用意した。これらのパターン間の重なり ($q_{\mu\nu} \equiv (1/N) \sum_{i=1}^N \xi_i^\mu \xi_i^\nu$) は $-0.667 (I \text{ vs } M) \leq q_{\mu\nu} \leq 0.859 (F \text{ vs } P)$ の範囲に分布しており、互いに相関をもつ非直交パターン群である。本論文では [R, Z, Q, Y, X, A, T, H] の 8 パターン記銘実験の場合の結果についてのみ取り上げることにする。(10) 式の外部刺激項 σ_i への記銘パターン情報 ξ_i^μ の反映方法としては

$$\sigma_i = s \xi_i^\mu \quad (\{\sigma\} = s\{\xi^\mu\}) \quad (14)$$

という最も簡単な設定を採用する。ただし、 s はパターン刺激の強さを左右する強度パラメータである。

次に各パラメータの設定であるが、時間設定としてはプロセスが始まって $t = t_0 (= 100)$ 目にパターン刺激の印加が開始され、その後持続時間 $T_s = 10$ の 1 パターン刺激が時間間隔 $T_I = 100$ 毎に対象とする刺激パターン群の 10 巡に相当する時間繰り返されるものとする。パターン数を p とすると全体の時間は $T = t_0 + 10pT_I$ となる。また、ネットワークの初期状態は無結合、すなわち、すべての結合荷重に対して $w_{ij}(t = 0) = 0$ とし、刺激下での (11) 式の可塑パラメータは $\beta = 0.1/N$ とする。各ニューロンの結合荷重ノルムの上限 K_i は、一組のパターン刺激が一巡し終わった後の結合荷重 $w_{ij}(t = t_0 + pT_I)$ を用いて (12) 式により決定する。なお、ニューロンのしきい値と入出力関数の傾きについては、本実験を通して全ニューロンに対して $a = 0 (\theta_i = 0)$, $\varepsilon = 0.015$ とする。

また、記憶形成能力やそのダイナミクスについて定量的に評価を進めるための尺度として、重なり度、エネルギーマップ、安定度および(最大)リアプノフ指数の 4 つの量を導入する。まず、

時刻 t におけるネットワーク状態 $\{X(t)\}$ と μ 番目のパターン $\{\xi^\mu\}$ との重なり度は

$$m^\mu(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \xi_i^\mu, \quad (15)$$

時刻 t におけるエネルギーマップは

$$E(t) = -\frac{1}{2} \sum_{i,j} w_{ij} X_i(t) X_j(t) \quad (16)$$

で与えられる。記録パターンの記憶としての安定性(記憶の引力圏)を評価する尺度として安定度 Γ_i^μ およびそれを結合荷重ノルム $\|w_i\|$ ((12)式)で割った規格化安定度 γ_i^μ を導入する。

$$\Gamma_i^\mu = \xi_i^\mu \sum_{j=1}^N w_{ij} \xi_j^\mu, \quad \gamma_i^\mu = \Gamma_i^\mu / \|w_i\|. \quad (17)$$

ニューロン数分ある $\{\Gamma^\mu\}$ ($\{\gamma^\mu\}$)の分布が正領域を占めれば占めるほど(7)式に対する μ 番目のパターンは安定に近づく(記録度は向上する)。ネットワークの振舞いがカオス性を有するかどうかの尺度としてはリアプノフ指数[17]を導入する。リアプノフ指数は一般に対象とする系の自由度数だけあるが、その中で最も大きい値を与える最大リアプノフ指数は

$$\lambda_1 = \lim_{n \rightarrow \infty} \frac{1}{n\tau} \sum_{i=0}^{n-1} \log \frac{|d_i(\tau)|}{|d_i(0)|}, \quad (18)$$

ただし

$$d_i(0) = d_{i-1}(\tau) \cdot \frac{|d_0(0)|}{|d_{i-1}(\tau)|}$$

で定義される。ここで、 τ は時間間隔、 d_i は基準軌道からのズレのベクトル、 $|\quad|$ はベクトルの大きさを表す。実際のシミュレーション実験では、ネットワークを構成する $N = 156$ 個のニューロンの内部状態 η_i, ζ_i を成分とする $312 (= 156 \times 2)$ 次元ベクトル軌道に対して(18)式を適用する。そのとき、1時刻ごとにズレを評価する($\tau = 1, i = t$)ことにすると、ズレのベクトルは

$$d_t = (\delta\eta_1(t), \dots, \delta\eta_N(t), \delta\zeta_1(t), \dots, \delta\zeta_N(t))$$

で与えられる。計算では、基準軌道に与える初期のズレの大きさは全ニューロンとも同じ $\delta\eta_i = \delta\zeta_i = 10^{-8}$ とした。

4 結果および分析

図2はパラメータが $[k_f = 0.1, k_r = 0.7, \alpha = 0.6]$ のネットワークにおける刺激-応答過程の経時変化を、ネットワーク状態 $\{X\}$ のパターンIとの重なり度 m^I を用いて図示したものである。刺激強度は $s = 2.20$ に設定されている。 $[R \rightarrow Z \rightarrow Q \rightarrow Y \rightarrow X \rightarrow A \rightarrow T \rightarrow H]$ の順に $Ts = 10$ のパターン刺激が $T_I = 100$ ごとにネットワークに印加される。これを1巡として10巡までのネットワークの振舞いが観測されている。外部刺激による結合荷重の成長とともに、ネットワーク

状態は $m^I = 0$ の無結合状態から急速に動的になり、刺激2巡目以降も少しずつその応答挙動が変化していくのがわかる。さらに図中には、ネットワーク状態の経時変化に対応させて、各区間(全80区間)での最大リアプノフ指数 λ_1 の値がプロットされている。これらは、刺激-応答過程におけるネットワークのカオス性を評価するために、(18)式の λ_1 をパターン刺激間の各無刺激(自律)挙動区間(具体的には $T_I - T_S - 25$ の各65ステップ時間)に対して計算したものである。刺激-応答の繰り返しの刻々のネットワーク挙動の性質の変化が各区間の λ_1 値変化によく反映されている。これはパターン刺激下で、ネットワークの結合荷重が成長し変化することにもなるものである。全過程を通じてのネットワークのカオス性保持の度合い(以後、カオス活性とよぶ)については、 λ_1 が正である区間の数 $\#(\lambda_1 > 0)$ を一つの目安にすることができる。

このようにして外部から時系列的に加えられたパターン刺激が、刺激-応答過程終了後のネットワーク上にどの程度記憶として定着したかを分析する必要がある。そのためには最終結合荷重 $w_{ij}(t = 8100)$ を用いて各パターンに対する(17)式の規格化安定度 γ_i^d を計算し、その分布を調べるのが有効である(以降、この γ_i^d のことを最終安定度とよぶ)。図3は履歴性のパラメータは $[k_f = 0.1, k_r = 0.7]$ に固定し、不応性を左右する α 値のみの変更に対する最終安定度(特に、負領域に残存する γ_i^d の個数 $\#(\gamma_i^d < 0)$) の変化を示したものである。データはパラメータ α が異なる(刻みステップ1/128)ネットワーク毎に図2と同様の[R, Z, Q, Y, X, A, T, H]8パターン記銘実験を実施し、その結果得られたものである。 $\#(\gamma_i^d < 0)$ は α 値に大きく依存しており、しかも0.4から0.8あたりの特定の α 領域において少なくなっている。このように刺激パターンの定着(記銘)にとって不応性は有効であるが、あまり大きすぎると逆に刺激を拡散させ、その定着を阻害することがわかる。同時に、各刺激-応答過程に対して求められた $\#(\lambda_1 > 0)$ の結果からは、記銘能が高い($\#(\gamma_i^d < 0) \rightarrow$ 小)領域ではカオス活性が高く($\#(\lambda_1 > 0) \rightarrow$ 大)なる傾向が見られる。この傾向は、履歴性パラメータ k_f, k_r の変更に対する $\#(\gamma_i^d < 0)$ と $\#(\lambda_1 > 0)$ の関係においても確認されている。このように、カオス・ニューラルネットワークが示す記銘能の向上は、その不応性と履歴性によって生み出されるカオス活性というネットワークの力学的性質(カオス・ダイナミクス)によって支えられている。

次に、 α 値を記銘が良好な上記の領域内の値に固定し、パターン刺激強度 s に対する記銘能(記憶定着能力)の依存性について検討する。すなわち、履歴性・不応性のパラメータを $[k_f = 0.1, k_r = 0.7, \alpha = 0.6]$ に固定し、 s 値のみの変更に対する最終安定度 (γ_i^d) 分布の変化を調べる。刺激強度 $s = 1.70 \sim 2.90$ の範囲を、刻みステップ1/256でデータ取得した結果が図4である。履歴性と不応性を有するCNNは、刺激強度 s の増大に対して記銘能をすみやかに向上させる大局的な性質とともに、局所的にはカオス的な刺激強度感性を保持している。そして、HFLでの結果に比べて、広い刺激強度範囲でその記銘能はきわめて高いことがわかる。それに対して、SNNにおける $\#(\gamma_i^d < 0)$ の大局的な変化は緩慢で、CNNのような刺激強度に対する記銘能の感性は見られない。また、 $s = 2.0$ 以下の弱刺激側では $\#(\gamma_i^d < 0)$ はSNNの方がCNNを下回っているものの、強刺激側では値を下げる事が出来ずCNNと逆転している。このような結果の違いは、図5の最終結合荷重 $w_{ij}(t = 8100)$ による各刺激パターンのエネルギーマップ値 E の s 依存性にも現れている。CNNに関する(b)図からは、全パターンの E 値の $E = 0$ からの掘り下げは刺激強度 s の増大とともにすみやかに可能となり、 E 値全体はほぼ $-75 \sim -110$ の幅に落ち

着いているのがわかる。しかし、HFLに関する(a)図では、多くのパターンの E 値の掘り下げが刺激強度 s が弱い場合にはうまく実現せず、 $s = 2.6$ 以上でやっとCNNと同じエネルギー幅にまで掘り下げられるといった様子である。(c)図のSNNでは、 s に対する $\#\{\gamma_i^\mu < 0\}$ の依存性と同様、刺激感性が大局的にも局所的にもほとんど見られない。各パターンの E 値の掘り下げも s の増加とともに徐々に深くなってはいるものの、CNNとHFLの結果に比べて半分以下の深さに達するに停まっている。

このように、HFLでは記銘が全く不可能な弱刺激でもCNNとSNNはそれぞれのカオス活性および確率的活性により記銘を促進し得る。しかし、刺激強度の増大にともなうSNNの記銘能の向上は鈍く、強刺激側では何の活性も持たないHFLを下回ることになる。カオス活性と異なりこの領域では、確率的活性はもはや活性ではなくノイズの意味を持つようになる。このことをより明確にするために、刺激-応答過程後の最終結合荷重 $w_{ij}(t = 8100)$ を持つ(相互結合型)ネットワークのパターン想起過程を直接調べることにする。ネットワークの発展方程式はHFLの場合と同じ(7)式で与えられる(ただし、本研究ではしきい値 $\{\theta\} = 0$)。図6は、[R, Z, Q, Y, X, A, T, H]の各刺激パターンそのものをネットワークの初期状態($\{X(t = 0)\} = \{\xi^\mu\}$)とし、 $t = 50$ ステップまでその状態の変化を初期パターン状態との重なり度 m^μ の推移として追跡したものである。これまでの実験で記銘能が高いと考えられた刺激強度 $s = 2.70$ の場合の最終結合荷重 $\{w_{ij}\}$ によるものであるが、HFL, CNN, SNNいずれの場合も刺激パターン状態すべてが完全に安定となるには至っていない。このことは安定度の負領域残存数 $\#\{\gamma_i^\mu < 0\}$ ($= \#\{\Gamma_i^\mu < 0\}$)の存在からも予想されることである。ただ、(b)図のCNNの場合は4パターン状態がほぼ完全で、他のパターン状態も $m^\mu \geq 0.7$ を保っているのに対して、(c)図のSNNでは2パターン状態以外は全く不安定である。このような両者の顕著な差は、刺激強度がかなり大きい場合にも残存している。

以上の検討により、CNNとSNNでは記銘能の必要条件的尺度である刺激パターンに対する最終的 $\#\{\gamma_i^\mu < 0\}$ と E 値の間にほぼ倍の差が存在し、それが直接的な想起性の評価において決定的な違いを生むものであることが明らかとなった。このことは、確率的活性よりもカオス活性の方が刺激-応答過程での記銘に関して有効であることを意味する。それは、ネットワークに内在する(力学的)活性の違いがパターン刺激に対するバランスの取れた彫り(刻み)込みと特定のパターンに偏った掘り下げという応答性の差を生み出すためであると考えられる。

5 おわりに

本研究では、単一でもカオス性を持ち得るカオスニューロンで構成されるカオス・ニューラルネットワークに対して、可塑的結合荷重に基づく動的な刺激-応答過程での記憶形成と定着能力を分析した。その結果は動的記銘学習機構の構築の可能性を十分に支持するものである。

ところで、記銘能が一番高いカオス・ニューラルネットワークの場合でも、本実験におけるパターン刺激に対する記銘はすべてが完全に安定な域まで達しているわけではない($\#\{\gamma_i^\mu < 0\} = 17$)。その原因は、外部刺激のパターン情報に非直交パターン群を用いていることにある。もし、パターン情報として直交パターン群を用意するならば、パターン刺激はすべて完全な安定状態としてネットワークに記銘されるものと推測される。実際、本実験でのカオス・ニューラルネット

ワークの記銘能は、各パターン情報の重ね合わせで構成される結合荷重 $w_{ij} = (1/N) \sum_{\mu=1}^p \xi_i^{\mu} \xi_j^{\mu}$ による記銘能にほぼ到達している。つまり、全記銘パターン情報を同時的に一括処理することで記銘を成立させていたこれまでのやり方に対して、記銘パターン情報を外界から逐次的に作用させる実際の生物の学習過程に近い方法が可能となったのである。このような、ネットワークが外界との相互作用を通して自ら結合荷重を獲得してゆく実時間記憶形成の成立は、動的記銘学習機構の構築を大きく前進させるものである。


今後の課題としては、本研究では主として記憶形成(記銘)過程に焦点を当て検討を進めてきたが、その成果をこれまでの研究で既に明らかになっている想起過程に関するものと結びつけてゆく作業がある。記憶機能を支える記銘、想起、忘却の3つの過程は本来、同時的で不可分な関係にあることを考えると、統合的見地からの動的連想記憶機構の構築が最終的な目標となる。それに向けての具体的課題の1つとして、カオス・ニューラルネットワークにおけるカオス活性が記憶容量の限界(臨界記銘パターン数)に与える影響についての検討がある。その際、新たな記銘形成により古い記銘が失われてしまう忘却過程や新たな記銘と古い記銘の共存や再編成も重要な検討項目である。

最後に、本論文では互いに独立に扱ってきたカオス・ニューラルネットワークと確率的ニューラルネットワークを融合し、カオス活性と確率的活性の複合ダイナミクスを持つ確率的カオス・ニューラルネットワークを考えることもできる。現実の脳の情報処理能力が両者の力学的性質の適当なスイッチングで担われている可能性も多いに有り得ることである。いずれにしても、各種パラメータの設定の違いが生み出すニューラルネットワークの多様な性質を一つの動的機構としてまとめ上げるには、今後、カオス制御を含む自律的システム制御の新しい処方を探求してゆく必要がある。

参考文献

- [1] J.J.Hopfield, Neural Networks and Physical Systems with Emergent Collective Computational Abilities, Proc. Natl. Acad. Sci. USA, 79(1982)2554-2558.
- [2] B.Müller and J.Reinhardt, Neural Networks: An Introduction, Springer-Verlag (1990).
- [3] 合原一幸編著, ニューラルシステムにおけるカオス, 東京電気大学出版局(1993).
- [4] 高橋智晴, 合原一幸, 松本元, ホジキン-ハクスレイ方程式のパルス列刺激に対する応答性, 電子情報通信学会論文誌, J71-A, 3(1988)744-750.
- [5] K.Aihara, T.Takabe and M.Toyoda, Chaotic Neural Networks, Phys.Lett., A144(1990) 333-340.
- [6] 安達雅春, 合原一幸, カオスニューロンモデルとそのネットワークダイナミクス, ニューラルシステムにおけるカオス(合原一幸編著), 東京電気大学出版局(1993)158-188.
- [7] M.Adachi, K.Aihara and M.Kotani, An analysis of associative transient dynamics in Chaotic Neural Network, in Towards the Harnessing of Chaotic(ed.M.Yamaguchi)(1994)335-338, Elsevier.

- [8] K.Kaneko, Clustering, coding, switching, hierarchical ordering, and control in a network of chaotic elements, *Physica D*41(1990)137-172.
- [9] I.Tsuda, Dynamic Link of Memory-Chaotic Memory Map in Nonequilibrium Neural Networks, *Neural Networks*, 5(1992)313-326.
- [10] S,Nara, P.Davis and H.Totsuji, Memory Search Using Complex Dynamics in a Recurrent Neural Network Model, *Neural Networks*, 6(1993)963-973.
- [11] 井上政義, カオスニューロ・コンピュータ, 応用カオス(合原一幸編著), サイエンス社(1994)97-120.
- [12] 西村治彦, 藤田嘉人, 藤田成隆, カオス・ニューラルネットワークによる動的記憶想起過程とその安定性, システム制御情報学会第38回研究発表講演会要旨集(1994)143-144.
- [13] 西村治彦, 藤田嘉人, 藤田成隆, カオス・ニューラルネットワークによる動的記憶想起機構の検討, 日本神経回路学会第5回全国大会講演論文集(1994)104-105.
- [14] 西村治彦, 堅田尚郁, 藤田嘉人:カオス・ニューラルネットワークによる動的連想記憶モデルの検討, 第39回システム制御情報学会研究発表講演会講演論文集(1995)115-116.
- [15] 西村治彦, 堅田尚郁:カオス・ニューラルネットワークにおける動的記銘学習過程, 日本神経回路学会第6回全国大会講演論文集(1995)117-118.
- [16] D.Hebb, *Organization of Behaviour*, Wiley, New York(1949).
- [17] 長島弘幸, 馬場良和, カオス入門, 培風館(1992).



CNM : カオスの基準モード (Chaotic Normal Mode)

CTM : カオスの震動モード (Chaotic Trembling Mode)
[[$\lambda_1 > 0$) かつ ($m^\mu \cong 1$)]

図1 カオス・ニューラルネットワークによる動的想起メカニズムのモデル概念図
(ただし, λ_1 は最大リアプノフ指数, m^μ は記録パターン状態との重なり度.)




図2 刺激-応答過程におけるネットワーク状態の経時変化と各無刺激区間における最大リアプノフ指数(λ_1)変化




図3 不応性パラメータ(α)に対する $\#(\gamma_i^\mu < 0)$ と $\#(\lambda_1 > 0)$ の依存性




図4 刺激強度(s)に対する最終安定度(γ_i^μ)の負領域残存数の依存性.

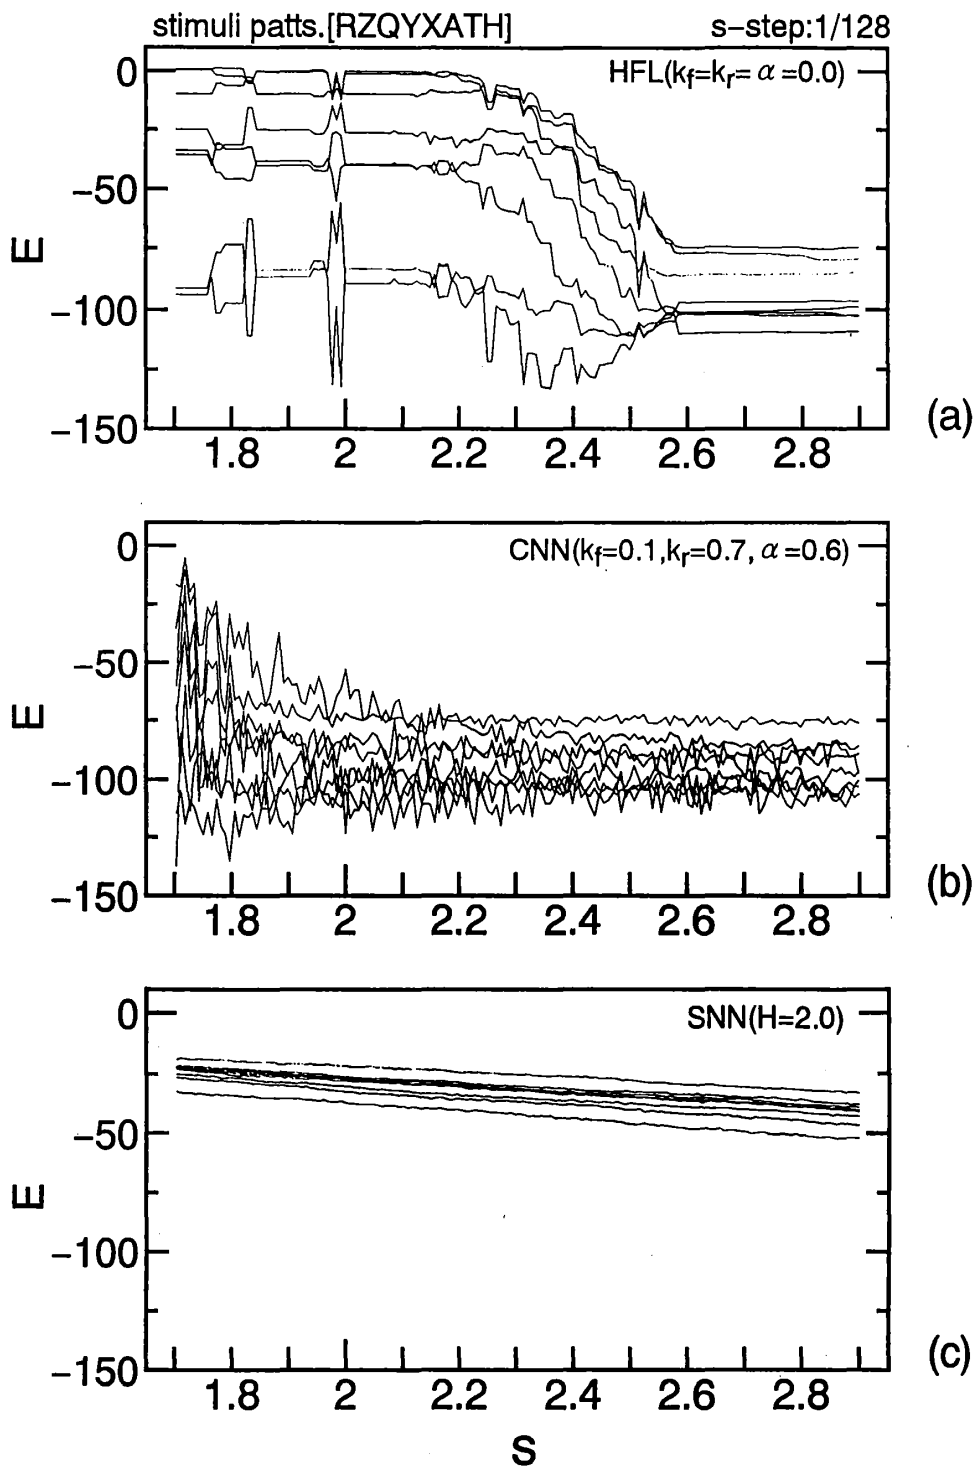


図5 刺激パターンの最終エネルギーマップ (E) 値の刺激強度 (s) 依存性. それぞれ (a) HFL, (b) CNN, (c) SNN の場合.




図6 ネットワーク状態更新に対する刺激パターン状態の推移. それぞれ(a) HFL, (b) CNN, (c) SNNでの最終結合荷重による場合.