

カオス・ニューラルネットワークにおける 自己組織的適応

Self-Organizing Adaptation 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 Introduction

ホップフィールド(Hopfield)による静的連想記憶モデル¹⁾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、記銘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。記銘・想起の機能が力学系問題として定式化され得る可能性を示した点で意義深いモデルといえる。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想起のダイナミクスは、エネルギー面の形状が事前に固定、すなわち、ニューロン間の結合荷重がなんらかの外部操作によって計算され固定されていることを前提にしている。つまり、この場合、学習と想起は互いに独立した全く別の力学的プロセスとして扱われている。一方、実際の生体は、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による自己組織化が重要な役割を担っていると考えられる。そして、より自然で現実味のあるモデルでは学習と想起が一つのプロセス内の二つの局面(モード)として現れる²⁾ことが期待される。

ところで、現実味という点では、脳神経系の挙動はかなり動的で活力に富んだものであることが知られている。事実、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, 4)}。このことは、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。これを受けて、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⁵⁾、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⁶⁾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考えが提出された⁷⁾。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^{8, 9, 10)}。我々も、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提案している¹¹⁾。そこでは、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の可能性が検討された。

本論文では、学習と想起に関する脳のダイナミクスの理解を目指して、可塑的シナプスを持つカオス・ニューラルネットワークが外界との刺激-応答下で自己組織的に環境適応する適応型強化のモデル¹²⁾について分析することにする。

2 Model and Methods

2.1 Chaotic Neural Network

実際のニューロンにみられる不応性効果(ニューロンの発火(興奮)状態が続くと、それに応じて発火(興奮)しにくくなる性質)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効果の形で取り入れたのがカオスニューロンモデルである。その応答特性にカオスが容易に現れ得ることからこのように呼ばれている。このカオスニューロンの相互結合系がカオス・ニューラルネットワーク (Chaotic Neural Network CNN)⁵⁾である。

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

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

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

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

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, $f(y) = \tanh(y/2\epsilon)$, すなわち, ニューロン値 X_i を $-1 \leq X_i \leq 1$ で定式化¹¹⁾している。(2),(3) 式は時間履歴効果の指数ベキ (k^d) 性のため

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

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

に帰着される(ここで簡単のために $-\theta_i(1-k_r) \equiv a$ と表した.)。

また, (4), (5) 式において $k_f = k_r = \alpha = 0$ と設定すると (1) 式は,

$$X_i(t+1) = f\left(\sum_{j=1}^N w_{ij} X_j(t) - \theta_i\right) \quad (6)$$

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ネット・ポイント (Hopfield Network Point HNP) 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。

2.2 Modeling

まず、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。

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(1)に対して、 Se の持続中は内部状態に外部刺激項 $\{\sigma_i\} (i = 1, \dots, N)$ 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：

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

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。

外部刺激下での結合荷重は固定的ではなく、

$$w_{ij}(t+1) = w_{ij}(t) + \beta X_i(t) X_j(t) \quad (8)$$

に従って常時可塑的に変化し得るものとする¹³⁾。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

$$\|w_i(t+1)\| \equiv \left(\sum_{j=1}^N w_{ij}^2(t+1) \right)^{1/2} \quad (9)$$

の成長には上限 K_i が存在し、到達後は

$$w_{ij}(t+1) \times \frac{K_i}{\|w_i(t+1)\|} \rightarrow w_{ij}(t+1) \quad (10)$$

によって規格化されるものとする。(8)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¹⁴⁾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、自己適応型強化については、図1のように考える。外部(環境)からの刺激(入力)に対して神経細胞群は応答(出力)を示す。その応答が成功であったかどうかの情報(評価信号)のみが環境からフィードバックされる。そして、ニューロン間の結合荷重は集団応答が成功であった場合に強化される。具体的には(8)式において、集団としてのI/O関係が成功のときは $\beta > 0$ 、そうでないときは $\beta = 0$ ($\beta < 0$ も考えられる) が全ニューロンに対して平等に適用される。学習と想起はこの適応型強化の進行の中で自己組織的に生み出されることになる。




図1 自己適応型強化の概念図

3 Simulations and Results

2章のモデリングに基づく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、I/Oタスクパターンとしては $12 \times 13 (= 156)$ のユニット構成で、アルファベット($A \sim Z$)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。本稿では[A, B, J, K]の4パターンを用いた場合の結果についてのみ取り上げる。(7)式の外部刺激項 σ_i へのパターン情報 $\{\xi_i^\mu\}$ の反映方法としては

$$\sigma_i = s \xi_i^\mu \quad (\{\sigma\} = s \{\xi^\mu\}) \quad (11)$$

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。

ネットワークの初期状態では[A, B, J, K]の4パターンがHNPで静的記憶となるよう結合荷重 $w_{ij}(t=0) = (1/N) \sum_{\mu}^{ABJK} \xi_i^\mu \xi_j^\mu$ とし、その後I/OタスクとしてA/J, B/Kという刺激-応答関係を課すことにする。タスクが成功かどうかは、時刻 t におけるネットワークの応答(出力)状態 $\{X(t)\}$ とそのときの出力期待パターン $\{\xi^\mu\}$ との重なり度

$$m^\mu(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \xi_i^\mu \quad (12)$$

が設定値 M (本実験では $M = 0.9$)に達したかどうかで常時判定される。それに応じて、成功の場合には(8)式の結合荷重の可塑パラメータは $\beta = 0.005/N$ 、そうでない場合には $\beta = 0$ をとる。1つのI/Oタスク(例えばA/J)は、その成功があらかじめ設定された達成回数(T_{AT})に至るまで印加される。 T_{AT} 回達成後には、I/Oタスク変更(A/JからB/Kへ)を行い、それが T_{AT} 回達成されるまで続ける。これを繰り返し適用し続けることとする。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 $a = 0(\theta_i = 0)$ 、 $\varepsilon = 0.015$ を採用する。

さて、実験結果であるが、図2は $[k_f = 0.3, k_r = 0.9, \alpha = 0.55]$ のネットワークでの刺激-応答過程における自己適応の挙動を、入出力達成度 m^μ (正確にはその絶対値)の経時変化として図示したものである。ただし、結合荷重に対するノルムとしては $K_i = \text{初期平均ノルム} \times 3$ (初期平均ノルム $= (1/N) \sum_{i=1}^N \|w_i(t=0)\|$)としている。入力[A] → 出力[J], [B] → [K]へのネットワークの適応がそれぞれの達成回数 $T_{AT} = 10$ 毎に切り替えられ評価が繰り返される。成功かそうでないかに応じたネットワークの結合荷重の変化とともに神経細胞群の自己組織化が進行し、ランダムに近い動きで始まる学習モードから秩序立った想起モードへその応答性が変化してゆく様子がうかがえる。

図3は図2のネットワークの挙動を時系列の区間ごとに拡大表示したものである。まず、(a)図($t = 0 \sim 1000$)では外部刺激(入力信号)が印加されているにもかかわらず、ネットワーク状態は激しく無秩序に変化している。(b)図($t = 10000 \sim 11000$)では適応的な自己組織化が進み、ネットワーク状態は少し秩序立ってきている。そして(c)図($t = 90000 \sim 91000$)においては自己組織的適応がほぼ達成され、外部刺激に対応した応答性(多少時間遅れはあるが)が出現している。このように、結合荷重の可塑性の下で神経細胞群は時間経過とともに外部刺激に対して自己組織的に学習モードから想起モードへと移行してゆく。

次に、図2と同一過程に対して途中($t = 60000$)から入出力タスク関係を変更した場合の結果が図4である。入出力タスク[A → J, B → K]の時刻 $t = 60000$ における[A →

$J, B \rightarrow J]$ への変更により、すでに学習適応が進行しほぼ想起モードに入っていたネットワーク状態が混乱とともに再度学習適応し、新たな想起モードへと落ち着く様子が見られる。その入出力タスク関係の変更前後の部分を拡大表示したのが(b)図である。変更後約2000ステップ時間の間に自律的な適応がなされ、学習モードから再び想起モード(今度の場合は応答性の時間遅れなし)へとネットワーク状態が変化しているのがわかる。

4 Concluding Remarks

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の可塑的結合集団に対して、外界との刺激-応答下での自己適応型強化の仕組みを適用し、その振舞いについて分析した。実験の結果は、カオス活性による応答(出力信号)の変動が強化を引き出し、自己組織的な適応を実現する可能性を示すものである。そこでは学習と想起が一つの動的過程における応答性の二つの局面(モード)として自律的に創発される。

ところで、本稿でのモデルとI/Oタスクは活動性の高い密結合ネットワークの形成を助長する傾向があり、必ずしもここでの強化のスキームに適しているとは言えない。疎結合で低活動なネットワーク形成の方が自律的な制御性には優れている可能性が高い。今後は、応答(出力信号)変動の原因が確率的ノイズの場合との比較も含めて、これらの点の検討を進めたい。

以上のような単純なスキームで脳機能のダイナミクス(の一つ)が理解し得るものかどうかという疑問は常にあるものの、脳機能に関するより自然で現実味のあるモデル化の模索は続けられねばならない。




図2 2入出力関係に対する達成度の経時変化




図3 図2の時間拡大図.(a) $t=0 \sim 1000$, (b) $t=10000 \sim 11000$,
(c) $t=90000 \sim 91000$




図4 (a) 図2と同一の過程が時刻60000以降のタスク変更によって受ける影響. (b) 時刻60000前後の拡大図.

References

- 1) J.J.Hopfield, Neural Networks and Physical Systems with Emergent Collective Computational Abilities, Proc.Natl.Acad.Sci.USA, 79(1982)2554-2558.
- 2) D.Stassinopoulos and P.Bak: Democratic reinforcement: A principle for brain function, Physical Review E51, (1995)5033-5039.
- 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) M.A.Arbib(Ed.): The Handbook of Brain Theory and Neural Networks; The MIT Press(1995).
- 5) K.Aihara, T.Takabe and M.Toyoda, Chaotic Neural Networks, Phys.Lett., A144(1990) 333-340.
- 6) K.Kaneko, Clustering, coding, switching, hierarchical ordering, and control in a network of chaotic elements, Physica D41(1990)137-172.
- 7) 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.
- 8) I.Tsuda, Dynamic Link of Memory-Chaotic Memory Map in Nonequilibrium Neural Networks, Neural Networks, 5(1992)313-326.
- 9) M.Inoue and A.Nagayoshi: A chaos neuro-computer; Phys. Lett., A158, (1991)373-376.
- 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) 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.
- 12) 西村治彦, 堅田尚郁: カオス・ニューラルシステムにおける自己組織化学習, 日本神経回路学会第7回全国大会講演論文集(1996)265-266.
- 13) 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.
- 14) D.Hebb, Organization of Behaviour, Wiley, New York(1949).