

G-019

カオスニューラルネットワークの遅延制御手法と記憶パターン間の重なりの影響 Delay Feedback control method in Chaotic Neural Network model and Influence of overlap among memory pattern

寺本 晃太† 黒岩 丈介† 小倉 久和† 小高 知宏† 白井 治彦‡
Kouta Teramoto Jousuke Kuroiwa Hisakazu Ogura Tomohiro Odaka Haruhiko Shirai

1 はじめに

近年、カオスが生物の情報処理に関係している可能性が高まり、脳の情報処理とカオスの関わりについて研究されている [1]-[3]. Aihara らは、ヤリイカの巨大軸索実験により、周期的な電流刺激によって発生するカオス応答を明らかにし、カオス的なニューロンモデル、及びカオスニューラルネットワークモデルを提案した [1]. Freeman らは、ラットの嗅球における臭いの応答実験より、生物の嗅覚系における機能的役割にカオスが重要な役割を担っている可能性を示している [2]. 本研究では、このカオス状態と記憶探索との関わりに注目する。カオスを用いて記憶パターン空間の探索を行なう際、カオスニューラルネットワークシステムにおけるカオス状態を様々に変化させ、その変化を柔軟に行うカオス制御法の確立が重要となる。我々は、これまでに、遅延制御手法を用いてカオス遍歴状態の CNN (Chaotic Neural Network) モデルの制御実験を行ってきた [4]-[6]. その結果、提案する遅延制御手法は、カオス状態に至るまでに不安定化した周期軌道を安定化するカオス制御法として有効であることが分かった。更に、提案手法によって制御される状態には、記憶パターン間の重なりが大きさが影響していた。そこで、本研究では、このような特性が記憶パターンの大きさ、個数等に依存しないことを示す。

2 Adachi & Aihara らの CNN モデル

Adachi & Aihara らの CNN モデルについて簡単に説明する [3]. N 個のニューロン素子からなる CNN の出力は、以下のように入力される。

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

ここで、 t は離散時刻 ($t = 0, 1, 2, 3, \dots$), $x_i(t)$ は i 番目の素子の時刻 t の出力である。関数 $f(\cdot)$ は出力関数と呼ばれ、本研究では $[0, 1]$ の連続的な値を与える以下のようなものを用いる。

$$f(x) = \frac{1}{1 + \exp(-x/\epsilon)} \quad (2)$$

ここで、 ϵ は勾配パラメータである。また、 $\eta_i(t)$ はネットワーク内の他の素子からの入力における内部状態、 $\zeta_i(t)$ は素子の不応性における内部状態を表わし、各々以下のように与えられる。

$$\eta_i(t+1) = k_f \eta_i(t) + \sum_{j=1}^N w_{ij} x_j(t) \quad (3)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) + a_i \quad (4)$$

ここで、 α は素子の不応性の強度に関するパラメータ、 a_i は i 番目の素子のバイアス入力、 k_f は他の素子からの入力項に対する減衰定数 ($0 \leq k_f < 1$), k_r は素子の不応性に対する減衰定数 ($0 \leq k_r < 1$) である。 w_{ij} は、 j 番目の素子から i 番目の素子へのシナプス結合強度である。 w_{ij} を適切に与えることで、CNN

モデルに記憶を埋め込むことが可能となる。本研究では、 w_{ij} を以下のように決定する。

$$w_{ij} = \frac{1}{n} \sum_{p=1}^n (2\xi_i^p - 1)(2\xi_j^p - 1) \quad (5)$$

ここで、 ξ_i^p は記憶させる p 番目パターンの i 番目の素子の値である。本研究で用いる記憶させるパターンを、図 1 に与える。各記憶パターンは、 20×20 の計 400 個からなる 0 または 1 のビットパターンであり、図 1 では、 $\xi_i^p = 1$ の場合 “■” で、 $\xi_i^p = 0$ の場合 “□” で表している。

3 カオス遍歴状態の CNN モデルにおける遅延制御

本研究では、遅延制御方法として以下のような方法を用いる [5].

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

$$F_i(t+1) = k_d F_i(t) + \beta x_i(t - \tau) \quad (7)$$

$F_i(t)$ が、遅延制御法による制御信号である。CNN モデルの出力を表す式 (1) に、制御信号 $F_i(t)$ を加えている。 β は制御信号の強さを表す制御パラメータ、 τ は遅れ時間係数である。 k_d は制御入力信号の減衰定数 ($0 \leq k_d < 1$) である。

4 遅延制御手法の制御状態における記憶パターン間の重なりの影響

CNN モデルの遅延制御における制御状態への記憶パターン間の相関の影響を、参照とする記憶パターンとのハミング距離における、各記憶パターンの想起頻度を算出した。CNN モデルにおける各パラメータは $\alpha = 9.0$, $k_r = 0.8$, $k_f = 0.3$, $a_i = 1$,




図 1: 記憶させるパターン

	p=1	p=2	p=3	p=4	p=5	p=6
p=1	1	-0.28	0.24	-0.04	-0.04	0.16
p=2	-0.28	1	0	0	0	0.16
p=3	0.24	0	1	0.2	0.08	0.04
p=4	-0.04	0	0.2	1	0.28	0.04
p=5	-0.04	0	0.08	0.28	1	-0.12
p=6	0.16	0.16	0.04	0.04	-0.12	1

表 1: 記憶パターン間の重なり

† 福井大学大学院工学研究科

‡ 福井大学工学部

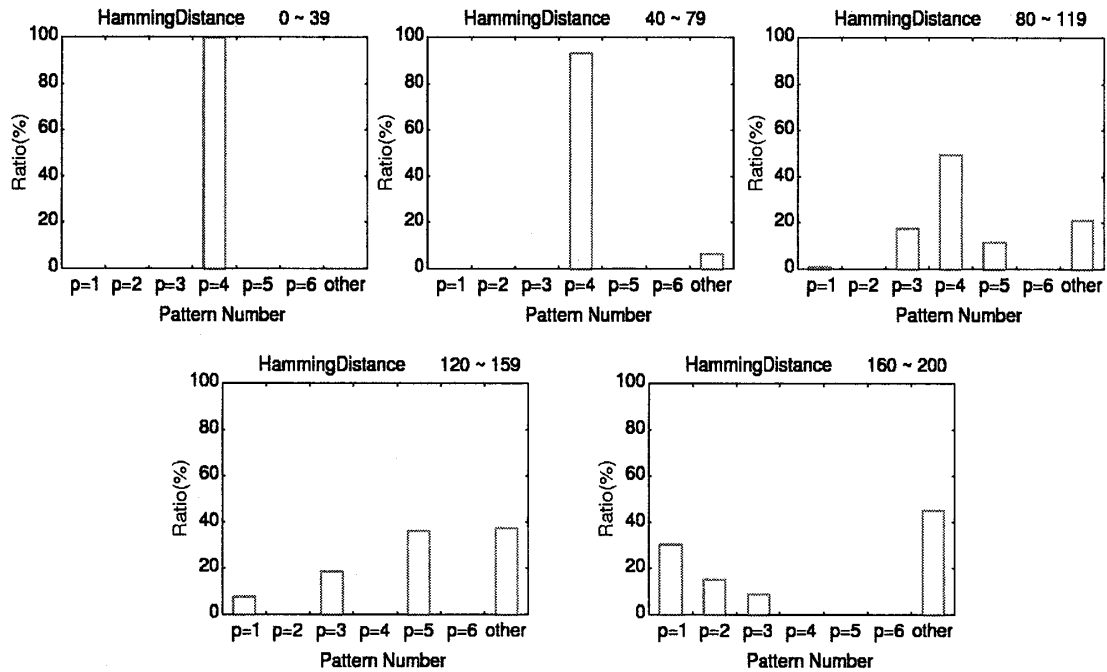


図2: 参照パターン (p=4) との各ハミング距離における想起頻度

及び, $\epsilon = 0.1$ と設定し, 遅延制御手法に用いる各制御パラメータを $\beta = 6.0$, $k_d = 0.8$, $\tau = 1$ とした.

本研究では記憶パターン p , q 間の重なりを以下の式で求めた.

$$o^{pq} = \frac{1}{N} \sum_{i=1}^N (2\xi_i^p - 1)(2\xi_i^q - 1) \quad (8)$$

式 (8) はパターン間の相関を内積で算出している. ここで, ξ_i^p , ξ_i^q は各記憶パターンの i 番目の素子である. 互いの記憶パターンが同様のパターンであれば, $o^{pq} = 1$ となり, $o^{pq} = -1$ のとき, 記憶パターンの相互関係は反転パターンであることを示している. また, パターン間の相関の重なりがない場合, $o^{pq} = 0$ となる.

実際に, 式 (8) に従い求めたパターン間の重なりを, 表 1 に与え, $p = 2$ を参照パターンとした際の各ハミング距離における, 参照パターンと各記憶パターン間の想起頻度を図 2 に与える. 図 2 の結果より, ハミング距離の値が小さい時, 提案する遅延制御手法による想起頻度は, 重なりが大きい記憶パターンへの想起頻度が高く, ハミング距離の値が大きくなると, 重なりによる影響はほとんど見られなくなった. このような, パターン間の重なりによる, 制御結果の収束先の関係は他のパターンについても見られた.

5 考察

提案する遅延制御手法はカオス遍歴現象を発現する Adachi&Aihara の CNN モデルを制御する手法として有効である. 更に, 本手法によって制御される状態は, CNN モデルの出力パターンと記憶させたパターンとのハミング距離が小さいほど, 高い頻度で対応する記憶パターンへ制御される. また, 制御信号印加時において, 参照とした各記憶パターンとのハミング距離が小さい場合, 記憶パターン間の重なりが制御状態へ変化を与えていることが分かった. この重なりによる影響は, 記憶パターン間の重なりが大きいほど, その記憶パターン

間における CNN モデルの状態遷移が頻繁にみられるためであると考えられる. つまり, 記憶パターン間の相関が, カオスニューラルネットワークの遅延制御におけるシステムダイナミクスを大きく変化させているといえる. よって, 記憶パターン間の重なりによる制御状態への影響を利用することで, 制御を階層的に行うことが可能である. このような結果は, 異なる記憶パターンを用いた場合にも同様に得られ, 記憶パターンの大きさ, 個数に依存しない.

参考文献

- [1] K. Aihara, G. Matumoto, Chaotic oscillations and bifurcations in squid giant axons in Chaos, ed. A. V. Holden (Manchester University and Princeton University Press), pp.257-269,1987.
- [2] SA. Skarda, J. K. Freeman, How brains make chaos in order to make sense of the world? Behavioral and Brain Sci., Vol.10, pp.161-195,1987
- [3] M. Adachi, K. Aihara, Associative dynamics in a chaotic neural network, Neural Networks, Vol.10, pp.83-98, 1997
- [4] G. He, J. Kuroiwa, H. Ogura, P. Zhu, Z. Cao, H. Chen, A Type of Delay Feedback Control of Chaotic Dynamics in a Chaotic Neural Network IEICE Trans. Fundamentals, Vol.E87-A(7), pp.765-1771, 2004
- [5] F. Katoh, J. Kuroiwa, I. Takahashi, T. Odaka, H. Ogura, G. He, "Delay Feedback Control in Chaotic Neural Network and Its Dynamical Properties," 2005 Int. Symp. on Nonlinear Theory and its Application (NOLTA2005, Bruges, Belgium), pp.46-49, 2005.
- [6] K. Teramoto, J. Kuroiwa, H. Ogura, T. Odaka, H. Shirai, "Delay Feedback Control to Chaotic Neural Network" IEICE Technical Report, NLP-2008-150(2009-2), pp.107-111, 2009