

カオス複素連想メモリ*

中田 正雄[†]

東京工科大学大学院
バイオ情報メディア研究科

長名 優子[‡]

東京工科大学
コンピュータサイエンス学部

1 はじめに

近年、ニューラルネットワークの分野において連想メモリに関する研究は盛んに行われており、ホップフィールドネットワーク [2], 双方向連想メモリ [1] などが提案されている。しかし、これらの連想メモリでは多値パターンを扱うことができない。また、自己組織化特徴マップを用いた連想メモリ [3] では実数値を扱うことができるが、学習パターンを局所表現で記憶するため、ニューロンの破壊に対してロバスト性がない。

多値情報を扱うことができるモデルとして複素ニューロンモデルが提案されており、連想メモリに複素ニューロンモデルを導入した複素連想メモリ [4]-[6] では多値パターンの連想が実現されているが、カオスニューラルネットワーク [7] に見られる動的な想起は実現されていない。

本研究では、複素連想メモリにカオスを導入したカオス複素連想メモリを提案する。提案モデルではニューロンのとる値を複素数値にすることで多値パターンの記憶を、カオスを導入することでパターンの動的な想起を実現している。

2 カオス複素ニューロンモデル

本研究で提案するカオス複素ニューロンモデルのダイナミクスは以下のように表される。

$$x(t+1) = f \left(A(t) - \alpha \sum_{d=0}^t k^d x(t-d) - \theta \right) \quad (1)$$

$$A(t), x(t), \theta \in \mathbb{C} \quad k, \alpha \in \mathbb{R}$$

ここで $x(t)$ は時刻 t におけるニューロンの出力、 $A(t)$ は時刻 t における外部入力、 α は不応性のスケーリングファクタ ($\alpha > 0$)、 k は時間減衰定数 ($0 \leq k < 1$)、 θ はニューロンの閾値である。また $f(\cdot)$ は出力関数であり、以下の式で与えられる。

$$f(u) = \frac{\eta u}{\eta - 1.0 + |u|} \quad \eta \in \mathbb{R} \quad (2)$$

ここで η は $\eta > 1$ を満たす定数である。

3 カオス複素連想メモリ

提案するカオス複素連想メモリはホップフィールドネットワークと同じように、 N 個のニューロンが相互結合した構造をしている。また、ニューロンはすべてカオス複素ニューロンモデルである。また、学習は以下の式に基づいて行われる。

$$w = \sum X^{(p)} X^{(p)*} - P I_n \quad (3)$$

ここで P は学習パターン数、 $X^{(p)}$ ($p = 1, 2, \dots, P$) は p 番目の学習パターン、 I_n は n 次の単位行列、 $*$ は共役転置を表している。

提案モデルにおいて、 n 番目のニューロンのダイナミクスは以下のように表される。

$$x_n(t+1) = f \left(\sum_{d=0}^t k_s^d A_n(t-d) + \sum_{j=1}^N w_{nj} \sum_{d=0}^t k_m^d x_j(t-d) - \alpha \sum_{d=0}^t k_r^d x_n(t-d) \right) \quad (4)$$

$$w_{nj}, x_n(t), A_n(t) \in \mathbb{C} \quad k_s, k_m, k_r, \alpha \in \mathbb{R}$$

ここで $x_n(t)$ は時刻 t における n 番目のニューロンの出力、 $A_n(t)$ は時刻 t における n 番目の外部入力の大きさ、 w_{nj} は j 番目のニューロンから n 番目のニューロンへの重みであり、これらは複素数値をとる。また、 k_s, k_m, k_r は時間減衰定数、 α は不応性のスケーリングファクタであり、これらは実数値をとる。

4 計算機実験

4.1 動的な想起の実現

カオス複素連想メモリに図 1 に示す 3 つの 4 値パターンを学習させ、想起を行った。ここでは、 $N = 400, k_s = 0.0, k_m = 0.1, k_r = 0.9, \alpha = 70, \eta = 1.1$ 、外部入力は 0 とした。パターン 2 を入力したときのカオス複素連想メモリの想起結果を図 2 に示す。カオス複素連想メモリの出力は複素平面上において $|x_n| < \eta$ を満たす点をとるが、図 2 では出力を量子化して表示している。量子化は以下のように行う。

$$\hat{x}_n = \underset{\omega^s}{\operatorname{argmin}} (\omega^s - x_n)^* (\omega^s - x_n) \quad (5)$$


$$s = 0, 1, \dots, S-1$$

ここで \hat{x}_n は量子化された n 番目のニューロンの出力、 S は量子化した結果の出力がとる状態の数で、この実験で

*Chaotic Complex-valued Associative Memory

[†]Masao Nakada, Graduate School of Bionics, Computer and Media Science, School of Computer Science, Tokyo University of Technology

[‡]Yuko Osana, School of Computer Science, Tokyo University of Technology



pattern 1 pattern 2 pattern 3

図 1: 学習パターン




図 2: パターン 2 を入力したときの想起結果

は 4 である．また， ω は以下の式で表される．

$$\omega = \exp\left(i\frac{2\pi}{S}\right) \quad (6)$$


ここで i は虚数単位である．図 2 より $t = 0$ のときに入力としてパターン 2 が入力されると $t = 1 \sim 3$ にかけてパターン 2 が想起され，その後，パターン 1 と 2 の重畳パターンが想起された．そして， $t = 9$ においてパターン 2 の回転パターンが想起された．そして，パターン 1 と 3 の重畳パターンを想起した後， $t = 46$ においてパターン 3 が想起された．その後，複数のパターンの重畳パターンとパターン 3 やその回転パターンを交互に想起する状態が続いた．図 2 から提案モデルにおいて記憶させたパターンを動的に想起できることが確認できた．

4.2 エネルギーの変化

提案モデルのエネルギー関数は式 (7) のように定義することができる [8]．

$$E(x) = -\frac{1}{2}x^*wx \quad (7)$$

ここで x はネットワークの出力， w は重み行列である．また， w はエルミート行列であるのでエネルギー $E(x)$ は実数で与えられる．図 2 における出力 x のエネルギー変化を図 3(a) に， x を量子化した出力 \hat{x} に置き換えたときのエネルギー変化を図 3(b) に示す．図 3(a) よりカオス複素連想メモリの想起時にエネルギーが不規則に増減して



(a) 出力 x のエネルギー変化 (b) 量子化した出力 \hat{x} のエネルギー変化

図 3: カオス複素連想メモリのエネルギー変化

いることが分かる．これは式 (4) に含まれる不応性の項が直前の出力から離れる方向に働くためである．

また，図 3 に含まれている点はそれぞれのパターンが想起されたときのエネルギーの値を表している．学習パターンが想起された時刻のエネルギーはその近傍における極小点になるとは限らない．これはネットワークの出力を量子化して表示しているため，同じ表示になるニューロンの出力の値に幅があるためである．また，出力を量子化してからエネルギーを計算した図 3(b) では学習パターンが想起される時刻のエネルギーがその近傍のエネルギーの中の極小点であるのが分かる．

5 むすび

本研究では，多値パターンの動的な想起を行うことができるカオス複素連想メモリを提案した．提案モデルは複素連想メモリとカオス連想メモリを組み合わせたモデルであり，複素ニューロンモデルにカオスを導入したカオス複素ニューロンモデルによって構成されている．計算機実験によって動的な想起を実現できることを確認した．

参考文献

- [1] B. Kosko: "Bidirectional associative memories," IEEE Trans. Systems Man and Cybernetics, Vol.18, No.1, pp.49–60, 1988.
- [2] J. J. Hopfield: "Neural networks and physical systems with emergent collective computational abilities," Proc. Natl. Acad. Sci. USA, Vol.79, pp.2554–2558, 1982.
- [3] H. Ichiki, M. Hagiwara and M. Nakagawa: "Kohonen feature maps as a supervised learning machine," Proc. IEEE International Conference on Neural Networks, pp.1944–1948, 1993.
- [4] 青木 宏之, 小林 幸夫: "ペナルティ項を有する複素連想記憶モデルの性質," 信学論 (A), Vol.J81-A, No.11, pp.1538–1546, 1998.
- [5] 青木 宏之: "複素数体上に拡張したホップフィールド連想記憶の平衡状態の解析," 信学論 (A), Vol.J78-A, No.9, pp.1238–1241, 1995.
- [6] S. Jankowski, A. Lozowski and J. M. Zurada: "Complex-valued multistate neural associative memory," IEEE Trans. Neural Networks, Vol.7, No.6, pp.1491–1496, 1996.
- [7] K. Aihara, T. Takabe and M. Toyoda: "Chaotic neural networks," Physics Letter A, 144, No.6, 7, pp.333–340, 1990.
- [8] 橋本 直樹, 黒江 康明, 森 武宏: "複素ニューラルネットワークに対するエネルギー関数について," 信学技報, No.NC98-152, pp.121–128, 1999.