

パラメータの自動調整が可能なカオス複素連想メモリ

～多値 (S 値) パターンの S の値を変えた場合～

唐鎌大輔 片村紀仁 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

カオスニューロンモデルは、実際の神経細胞において見られる時空間加算、不応性、連続値出力を考慮することでカオスを導入したモデルであり、カオスニューロンモデルから構成される連想メモリでは記憶したパターンを動的に想起できることが知られている [1]。しかしながら、カオスニューロンモデルやカオスニューロンモデルに基づいたモデルから構成される連想メモリでは、動的な想起能力が不応性のスケーリングファクタなどのカオスニューロンモデルのパラメータに依存するという問題がある。適切なパラメータの値は、ニューロン数や層の数などネットワークの大きさによって異なるため試行錯誤によってパラメータを決定しなくてはならない。

それに対し、試行錯誤によりパラメータの調整を行わなくても十分な動的想起能力が得られるモデルも提案されている。そのような手法の1つとして、パラメータの自動調整が可能なカオス複素連想メモリ [2] が提案されている。このモデルでは4値パターンを記憶させた場合に、パラメータを手動で調整したカオス複素連想メモリ [3] と同等の動的な想起能力が得られることが示されている。しかし、カオス複素連想メモリ [3] では、多値 (S 値) パターンの S の値が異なると大きく性質が異なることが分かっている。そのため、4値パターンのときのパラメータの自動調整方法をそのまま利用することはできない。なお、このモデルでは、図1に示すように複素平面上の単位円を S 等分した位置にある点を多値 (S 値) に対応させることで多値パターンを表現する。

本研究では、パラメータの自動調整が可能なカオス複素連想メモリにおいて6値と8値パターンの場合に自動調整を行う方法について検討する。

2 パラメータの自動調整が可能なカオス複素連想メモリ

ここでは、パラメータの自動調整が可能なカオス複素連想メモリ [2] について説明する。このモデルはカオス複素連想メモリ [3] に基づいたモデルであり、多値パターンの動的な想起を実現することができる。

2.1 構造

パラメータの自動調整が可能な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 [4] と同様の構造を持つ。各ニューロンはカオス複素ニューロンモデルであり、ニューロン同士は相互結合している。自己結合はなく、ネットワークの状態の更新は非同期に行われる。カオス複素連想メモリでは、カオス複素ニューロンモデルの出力がカオスによって変化することで動的な想起が実現される。

2.2 学習過程

パラメータの自動調整が可能なカオス複素連想メモリにおいて、重み行列 w は相関学習で以下のように決定する。

$$w = S(N) \left(\sum_{p=1}^P x^{(p)} x^{(p)*} - P I_N \right) \quad (1)$$

ここで、 P は学習パターンの数、 $x^{(p)}$ は学習パターン p 、 $x^{(p)*}$ は学習パターン p の共役転置ベクトル、 I_N は N 次の単位行列を表す。ここで、 N はニューロン数である。また、式 (1) において、 $S(N)$ はニューロン数 N に応じて決まる正規化のための係数を表して




図 1: 多値 (8 値) パターンの表現

いる。 $S(N)$ を掛けることでカオス複素ニューロンモデルの内部状態のとり得る範囲がニューロン数に依存しないようにすることができる。このモデルでは、内部状態の値に応じてパラメータを変化させることで自動調整を実現しているため、内部状態の値がニューロン数に依存しないように重みを正規化している。

2.3 想起過程

パラメータの自動調整が可能なカオス複素連想メモリでは、時刻 $t + 1$ におけるニューロン i の出力 $x_i(t + 1)$ は

$$x_i(t + 1) = f \left(\sum_{j=1}^N w_{ij} \sum_{d=0}^t k_m^d x_j(t - d) - \alpha(t, I(t)_{\max}) \sum_{d=0}^t k_r^d x_i(t - d) \right) \quad (2)$$

で与えられる。ここで、 $x_i(t)$ は時刻 t におけるニューロン i の出力、 w_{ij} はニューロン i と j の間の重みであり、これらは複素数値をとる。また、 k_m, k_r は時間減衰定数、 N はニューロン数を表している。 $\alpha(t, I(t)_{\max})$ は時刻 t の不応性のスケーリングファクタであり、時刻 t だけではなく、時刻 t までの内部状態の絶対値の最大値に基づいて値が決まるようになっている。 $\alpha(t, I(t)_{\max})$ は

$$\alpha(t, I(t)_{\max}) = a(I(t)_{\max}) + b(\alpha(I(t)_{\max})) \sin \left(c \frac{\pi}{12} t \right) \quad (3)$$

のように変化させる。ここで、 $I(t)_{\max}$ は時刻 t までの内部状態の絶対値の最大値を表しており、

$$I(t)_{\max} = \max \{ I(t), I(t - 1)_{\max} \} \quad (4)$$

で与えられる。ここで、 $I(t)$ は時刻 t における内部状態の絶対値を表しており、

$$I(t) = \frac{1}{N} \sum_{i=1}^N \left| \sum_{j=1}^N w_{ij} \sum_{d=0}^t k_m^d x_j(t - d) \right| \quad (5)$$

で与えられる。また、式(3)において、 $\alpha(t, I(t)_{\max})$ は、時刻 t までの内部状態の絶対値の最大値に応じて決まる不応性のスケーリングファクタを変化させる範囲(振幅)を決める係数であり、どのような方法で決定するかは3で述べる実験によって決める。 $b(a(t, I(t)_{\max}))$ は $a(t, I(t)_{\max})$ のときの不応性のスケーリングファクタの平均値を決める係数であり、これも同様の実験により決定する。 c は不応性のスケーリングファクタの変化する周期を決める係数である。また、 $f(\cdot)$ は出力関数であり、以下のように表される。

$$f(u) = \frac{\eta u}{\eta - 1.0 + |u|} \quad (6)$$

ここで、 u は内部状態の値、 η は 1.0 より大きい係数である。

3 パラメータの自動調節方法の検討

パラメータの自動調整を行う方法は以下の手順で決定する。

- (1) カオスが生成されやすい η の値を決定する。
- (2) 重み行列 w の正規化を行うための係数 $S(N)$ を決定する。
- (3) カオス複素連想メモリにおいて高い想起率が得られるカオス複素ニューロンモデルのパラメータ k_m, k_r, α を決定する。
- (4) 時間的に変化する不応性のスケーリングファクタを有するカオス複素連想メモリにおいて高い想起率が得られるパラメータを決定する。このモデルでは、不応性のスケーリングファクタを時間的に変化させるが、変化させる範囲(振幅)を決める a と平均値を決める b を変化させ、最も高い想起率が得られるパラメータを決定する。
- (5) (4) で高い想起率が得られたパラメータ a, b の組み合わせにおける内部状態の絶対値を調べ、内部状態の絶対値に基づいて a, b を決定する方法を決定する。

4 計算機実験

計算機実験を行い、4 値パターンを記憶させた場合よりも想起率は劣るものの、6 値パターンや8 値パターンを記憶させた場合においてもパラメータの自動調整が行えることを確認した。

参考文献

- [1] K. Aihara, T. Takabe and M. Toyoda : “Chaotic neural networks,” *Physics Letter A*, Vol.144, No.6 & 7, pp.333–340, 1990.
- [2] 中野 千具早, 長名 優子 : “パラメータの自動調整が可能なカオス複素連想メモリ,” 情報処理学会 第 79 回全国大会, 2017.
- [3] M. Nakada, and Y. Osana : “Chaotic complex-valued associative memory,” *Proceedings of International Symposium on Nonlinear Theory and its Applications*, Vancouver, 2007.
- [4] J. J. Hopfield : “Neural networks and physical systems with emergent collective computational abilities,” *Proceedings of the National Academy of Sciences of the USA*, Vol.79, pp.2554–2558, 1982.