

非同期セルオートマトン多層リザーバニューラルネットワークを用いた脳波の分類

NAKATA, Kohei / 仲田, 航平

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

64

(開始ページ / Start Page)

1

(終了ページ / End Page)

5

(発行年 / Year)

2023-03-24

(URL)

<https://doi.org/10.15002/00026363>

非同期セルオートマトン多層リザーバニューラルネットワークを用いた脳波の分類

Classification of EEG by a multi-layer reservoir neural network
based on asynchronous cellular automaton neurons

仲田航平

Kohei NAKATA

指導教員 鳥飼弘幸

法政大学大学院理工学研究科電気電子工学専攻修士課程

In this paper, a multi-layer reservoir neural network is designed using an asynchronous cellular automaton neuron model. Furthermore, a learning method of the network based on the simulated annealing is proposed. It is shown that the network with reservoir layers can classify a set of several EEG. In addition, the classification performance of networks with various configurations were compared, and it is shown the best performing network is a two-layer reservoir neural network.

Key Words : Asynchronous cellular automaton, Reservoir neural network, EEG

1. はじめに

脳波や心電図、筋電位を始めとした時系列の生体データの分類は、医療の分野などにおいても、近年重要な問題となっている[1]-[4]。これらの生体データを分類する方法の1つとしてリカレントニューラルネットワークを用いた手法が多く提案されてきており、大きな成功を収めた手法も数多く存在する[5]-[7]。ニューラルネットワークにはネットワーク内に時間的な遅延を生じさせるTDNN(Time Delay Neural Network)や、リザーバ層を用いて各ニューロンを結合させるリザーバニューラルネットワークなどの手法が存在する。その中でも、リザーバを拡張したディープリザーバニューラルネットワークは、従来のニューラルネットワークと比較して、分類性能の向上が期待されている[1]。一方、本研究室では、非同期セルオートマトン型ニューロンが、従来のニューロンモデルに比べて少ない回路素子で実装でき、消費電力が低いことを明らかにしている[8]-[12]。また、非同期セルオートマトンニューロンモデルを用いたポリクロナスリザーバに伝達遅延を加えたネットワークによって、入力信号を分類できることを示した[12]。そこで、本稿では、非同期セルオートマトン型ニューロンモデルを用いて、リザーバ内のニューロンの軸索に伝達遅延を持たせた多層リザーバニューラルネットワークを設計する。このネットワークを用いてシミュレーテッドアニーリング法に基づいた学習方法を提案し、コンピュータを用いたシミュレーションによって時系列データの分類が可能であること

を示す。また、伝達遅延を含まないネットワークや、リザーバ層が1層のみのネットワークと分類能力を比較、評価することによって、伝達遅延と2層のリザーバ層の有用性を示す。その後、実際に測定された開眼時と閉眼時の脳波データについてもBSA(Bens Spike Algorithm)法やシミュレーテッドアニーリング法に基づく学習方法を提案し、分類を行うことで設計した多層リザーバニューラルネットワークの有用性を示す[13]。加えて、構成を変更した様々な種類の多層リザーバニューラルネットワークを設計し、脳波データを入力した際の分類能力を比較することで、同ネットワークの構成による分類性能を考察する。

2. 伝達遅延を含む2層リザーバニューラルネットワーク

図1に設計した2層リザーバニューラルネットワークの全体図を示す。このネットワークは入力層、リザーバ層、および出力層の3つから構成されており、ネットワークを構成する各層のニューロンは、非同期セルオートマトンに基づく膜電位モデルを用いている[12]。

ネットワーク内のリザーバ層1は、 N 個の非同期セルオートマトンニューロン($\mathcal{N}_1, \mathcal{N}_2, \dots, \mathcal{N}_N$)を持つ。各ニューロンのダイナミクスは[12]に示すものと同様であり、 n 番目のニューロンは活動電位 Y_n^1 を出力する。また、図1に示すように、各ニューロンはシナプス荷重($W_{11}^{in}, \dots, W_{kN}^{in}$)を介して入力刺激(I_1, I_2, \dots, I_k)を受け取り、次のように状




図1 2層リザーバニューラルネットワークの構成




図2 リザーバ層1内のニューロンの状態遷移図

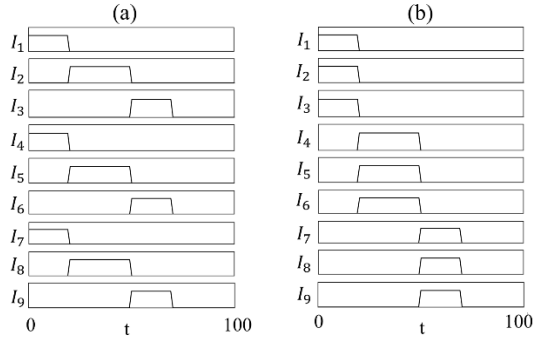


図3 使用した時系列データ (a) 入力データ1 (b) 入力データ2

状態遷移する。

$$V_n^1(t^+) = V_n^1(t^-) + W_{kn}^1 \text{ if } I_k(t) = 1 \quad (1)$$

このとき、 W_{kn}^1 は整数とする。また、図1に示すように、リザーバ層1内のニューロンはシナプス荷重

$$\begin{pmatrix} W_{11}^1 & W_{12}^1 & \cdots & W_{1N}^1 \\ W_{21}^1 & W_{22}^1 & \cdots & W_{2N}^1 \\ \vdots & \vdots & \ddots & \vdots \\ W_{N1}^1 & W_{N2}^1 & \cdots & W_{NN}^1 \end{pmatrix}$$

と伝達遅延

$$\begin{pmatrix} D_{11}^1 & D_{12}^1 & \cdots & D_{1N}^1 \\ D_{21}^1 & D_{22}^1 & \cdots & D_{2N}^1 \\ \vdots & \vdots & \ddots & \vdots \\ D_{N1}^1 & D_{N2}^1 & \cdots & D_{NN}^1 \end{pmatrix}$$

を介して接続されており、次のように状態遷移する。

$$V_n^1(t^+) = \begin{cases} V_n^1(t^-) + W_{pn}^1 & \text{if } Y_p^1(t) = 1, \\ V_n^1(t^-) - Z^1 & \text{otherwise.} \end{cases} \quad (2)$$

表1 学習前後の出力層ニューロン発火数 (a)入力データ1入力時 (b)入力データ2入力時

	(a)		(b)			
	入力データ1	$F_1 (Y_1^{out})$	$F_2 (Y_2^{out})$	入力データ2	$F_1 (Y_1^{out})$	$F_2 (Y_2^{out})$
学習前	127	127	125	125		
学習後	124	68	67	119		

表2 各構成のネットワークとの分類性能の比較

		伝達遅延を含む2層リザーバ		伝達遅延を含まない2層リザーバ		伝達遅延を含む1層リザーバ	
		$F_1 (Y_1^{out})$	$F_2 (Y_2^{out})$	$F_1 (Y_1^{out})$	$F_2 (Y_2^{out})$	$F_1 (Y_1^{out})$	$F_2 (Y_2^{out})$
		発火回数	124	68	91	82	96
入力データ1	$F_{target}^1 / F_{other}^1$	1.82		1.11		1.68	
入力データ2	発火回数	67	119	82	158	60	101
	$F_{target}^2 / F_{other}^2$	1.78		1.93		1.68	
	$F_{target}^{1/2} / F_{other}^{1/2}$ 平均値	1.80		1.52		1.68	

ここで、 Z^1 は漏れ電流を表し、整数値とする。結果としてリザーバ層1は活動電位(Y_1^1, \dots, Y_N^1)を出力する。このときの状態遷移の様子を図2に示す。本稿では、シナプス荷重 W^1 と伝達遅延 D^1 はランダムに決定されるものとする。

リザーバ層1以外の層の構造及び状態遷移については、修士論文にて記述する。

3. 2層リザーバニューラルネットワークを用いた学習

この項では、多層リザーバニューラルネットワークを用いた学習によって、図3に示す入力データ1と2を分類する。入力データ1と2を分類するために、次の評価関数Fを用いる。

$$F = F_{target}^1 - F_{other}^1 + F_{target}^2 - F_{other}^2$$

ここで、 F_{target}^1 は入力データ1がネットワークに入力されたときの出力 Y_1^{out} の発火回数を示し、 F_{other}^1 は入力データ1が入力されたときの出力 Y_2^{out} の発火回数を示す。同様に、 F_{target}^2 は入力データ2がネットワークに入力されたときの出力 Y_2^{out} の発火回数を示し、 F_{other}^2 は入力データ2が入力されたときの出力 Y_1^{out} の発火回数を示す。この評価関数Fを用いて、シミュレーテッドアニーリング法によってリザーバ層2から出力層へのシナプス荷重 W^{out} を探索し、学習を行う。探索に関する詳細は、修士論文にて記述する。

表1は、学習前後の出力層ニューロンの活動電位 Y_1^{out} と Y_2^{out} の発火回数を示している。学習前は、出力層ニューロンの活動電位 Y_1^{out} と Y_2^{out} の発火回数に違いは見られない。これは、ネットワークが入力データ1と2の分類ができていないことを示している。一方で、学習後は入力データ1を入力したとき、活動電位 Y_1^{out} の発火回数が活動電位 Y_2^{out} の発火回数に比べて明らかに多くなっている。




図 4 同一被験者の脳波データ (a) 閉眼時 (b) 開眼時




図 5 スパイク列変換後の脳波データ (a) 閉眼時 (b) 開眼時




図 5 スパイク列変換後の脳波データ (a)閉眼時 (b)開眼時

同様に、学習後に入力データ 2 を入力したとき、活動電位 Y_2^{out} の発火回数は活動電位 Y_1^{out} の発火回数に比べて明らかに多くなっている。これは、ネットワークが入力データ 1 と 2 の分類に成功していることを示している。このときのニューロンの発火の様子やパラメータに関しては、修士論文にて記述する。

表 2 は学習後の他のネットワークとの比較を示している。比較する方法として、入力データ 1,2 を入力した際の F_{other} に対する F_{target} の比率を用いた。入力データ 1,2 それぞれを入力した際のこの比率の平均を求めることによって、ネットワークの分類能力の指標とする。したがって表 2 より、リザーバ層が 2 層で伝達遅延を含むネットワークは、リザーバ層が 2 層で伝達遅延を含まないネットワーク、リザーバ層が 1 層で伝達遅延を含むネットワークと比べてこの比率が最も高くなっており、分類性能が高いと言える。

2 層リザーバニューラルネットワークにノイズを含むデータを入力した際の分類能力の変化についても検証を行った。詳細は修士論文にて記述する。

4. 多層リザーバニューラルネットワークを用いた脳波データの分類

この項では、様々な構成の多層リザーバネットワーク




図 7 閉眼時データ入力時のニューロンの発火の様子




図 8 開眼時データ入力時のニューロンの発火の様子

を用いて、実際に測定された脳波データを分類しその性能を比較する。図 4 に示す同一の被験者から測定された開眼時と閉眼時の脳波データを、設計した多層リザーバネットワークを用いて分類し、比較することを目的とする。

脳波データを設計した多層リザーバニューラルネットワークに入力データとして入力するためには、スパイク列の入力データに変換する必要がある。ここで、アナログ波形をスパイク列に変換する方法として、BSA(Bens Spike Algorithm)法を用いた[13]。BSA 法を用いることにより、波形の変化量が大きい部分に対応したスパイク列を得ることができる。使用した脳波データに対してダウンサン

プリングを行い、BSA 法を適用することで得られたスパイク列を、図 5 に示す。図 5 のように、BSA 法を用いることで異なる 2 つの波形の発火頻度を調節しつつスパイク列に変換することが出来る。

脳波データを分類するにあたり、2 層リザーバニューラルネットワークの他に、3 層および 4 層のリザーバニューラルネットワーク、リザーバ層を並列に配置した並列 2 層リザーバニューラルネットワークを設計した。ネットワークの構造や発火の様子に関しては、修士論文にて記述する。

ネットワークの学習を行うために、教師データとテストデータを用いた。図 5 に示したスパイク列変換した脳波データにノイズを加えたものを教師データおよびテストデータとした。開眼時データ 30 本、閉眼時データ 30 本の計 60 本を教師データとし、その他に用意した 60 本のテストデータを分類した際の正答率を求めた。各種ネットワークについて検証を行い、正答率を比較したグラフを図 6 に示す。図 6 から分かるように、2 層リザーバニューラルネットワークの正答率が最も高くなっており、リザーバ層数を増やすほどネットワークの性能が向上するわけではないということが分かった。学習を行う際の詳細なアルゴリズムについては、修士論文にて記述する。

また、学習後の 2 層リザーバニューラルネットワークに、開眼時および閉眼時の脳波データを入力した際の各層のニューロンの発火の様子を図 7,8 に示す。図 7,8 では、リザーバ層 1 とリザーバ層 2 のニューロンから 30 個を抜粋したものと、2 個の出力層ニューロンを示している。図 7 より、2 つの出力層ニューロンは、開眼時データを入力した際には出力層ニューロン 1、図 8 より閉眼時データを入力した際には出力層ニューロン 2 の発火回数が多くなっており、データの分類に成功していることが読み取れた。

5. 結論

本稿では、非同期セルオートマトンニューロンモデルを用いて、多層リザーバニューラルネットワークを設計した。さらに、シミュレーテッドアニーリングに基づくネットワークの学習方法を提案した。その結果、2 層のリザーバを持つネットワークが 2 つの時系列データを分類できることを示した。また、ほかのネットワークとの比較を行い、伝達遅延を含むリザーバ層が 2 層のネットワークの分類性能が最も高いことを示した。次に、脳波データをスパイク列に変換し、ネットワークにデータを入力する方法を示した。その入力データをシミュレーテッドアニーリング法に基づく別の手順によって分類する方法を示した。最後に、リザーバ層数やネットワークの構造を変化させた際のネットワークの分類性能について考察を行った。畳み込みニューラルネットワークなどの非同期セルオートマトンに基づくニューロンモデルを用いていないネットワークとの分類能力の比較や、ハードウェア実装

時の電力消費や回路素子数の比較は行っていないため、今後の課題として挙げられる。

参考文献

- 1) Rahma Fourati, Boudour Ammar, Yaochu Jin, and Adel M. Alimi, EEG feature learning with Intrinsic Plasticity based Deep Echo State Network, Proc. IEEE IJCNN, 2020.
- 2) J. Jeong, B. Lee, D. Lee, Y. Yun and S. Lee, EEG Classification of Forearm Movement Imagery Using a Hierarchical Flow Convolutional Neural Network, in IEEE Access, vol. 8, pp. 66941-66950, 2020.
- 3) G. Xu et al., A Deep Transfer Convolutional Neural Network Framework for EEG Signal Classification, in IEEE Access, vol. 7, pp. 112767-112776, 2019.
- 4) T. Wen and Z. Zhang, Deep Convolution Neural Network and Autoencoders-Based Unsupervised Feature Learning of EEG Signals, in IEEE Access, vol. 6, pp. 25399-25410, 2018.
- 5) Charles R. Day, Edward K. Chadwick, and Dimitra Blana, A comparative evaluation of time-delay, deep learning and echo state neural networks when used as simulated transhumeral prosthesis controllers, Proc. IEEE IJCNN, 2020.
- 6) S. U. Amin, M. Alsulaiman, G. Muhammad, M. A. Bencherif and M. S. Hossain, Multilevel Weighted Feature Fusion Using Convolutional Neural Networks for EEG Motor Imagery Classification, in IEEE Access, vol. 7, pp. 18940-18950, 2019.
- 7) J. X. Chen, P. W. Zhang, Z. J. Mao, Y. F. Huang, D. M. Jiang and Y. N. Zhang, Accurate EEG-Based Emotion Recognition on Combined Features Using Deep Convolutional Neural Networks, in IEEE Access, vol. 7, pp. 44317-44328, 2019.
- 8) N. Shimada and H. Torikai, A novel Asynchronous Cellular Automaton Multi-Compartment Neuron Model, IEEE Trans. CAS-II, vol. 62, no. 8, pp. 776-780, 2015.
- 9) T. Matsubara and H. Torikai, An Asynchronous Recurrent Network of Cellular Automaton-based Neurons and its Reproduction of Spiking Neural Network Activities, IEEE Trans. NNLS, vol. 27, no. 4, pp. 836-852, 2016.
- 10) K. Isobe and H. Torikai, A novel Hardware-Efficient Asynchronous Cellular Automaton Model of Spike-Timing Dependent Synaptic Plasticity, IEEE Trans. CAS-II, vol. 63, no. 6, pp. 603-607, 2016.
- 11) K. Takeda and H. Torikai, A Novel Asynchronous CA Neuron Model: Design of Neuron-Like Nonlinear Responses Based on Novel Bifurcation Theory of Asynchronous Sequential Logic Circuit, in IEEE Transactions on Circuits and Systems I: Regular Papers, vol. 67, no. 6, pp. 1989-2001, 2020.
- 12) M. Ishikawa and H. Torikai, A Novel Design Method of Multi-Compartment Soma-Dendrite-Spine Model having Nonlinear Asynchronous CA Dynamics and its Applications

to STDP-based Learning and FPGA Implementation, Proc. IEEE IJCNN, 2020.

- 13) Natt Nuntaild, Kshitij and Nikola Kirilov Kasabov, EEG Classification with BSA Spike Encoding Algorithm and Evolving Probabilistic Spiking Neural Network, International Conference on Neural Information Processing, pp. 451-460, 2011.