

非同期ポリクロナスリザーバネットワークを用いた心電図波形の分類

KATO, Naoki / 加藤, 直輝

(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)

4

(発行年 / Year)

2023-03-24

(URL)

<https://doi.org/10.15002/00026338>

非同期ポリクロナスリザーバネットワーク を用いた心電図波形の分類

CLASSIFICATION OF ECG WAVEFORMS USING POLYCHRONOUS RESERVOIR NETWORK
BASED ON ASYNCHRONOUS CELLULAR AUTOMATON DYNAMICS

加藤直輝

Naoki KATO

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

A novel hardware-efficient polychronous reservoir network whose dynamics is designed based on asynchronous cellular automaton is proposed. The proposed network is implemented by an FPGA and experiments validate its classification function. It is shown that the network can be implemented by fewer circuit elements than a conventional polychronous reservoir network and that the network can classify electrocardiogram (ECG) waveforms.

Key Words : Asynchronous cellular automaton, reservoir network, ECG

1. はじめに

近年, 深層学習は医療, 機械, 通信などの様々な分野で, IoT(Internet of Things)での次世代技術としての応用が期待されている. 深層学習には様々な種類のネットワークが用途に応じて用いられており, 例えば, 画像認識や信号分類などに用いられる CNN[1]-[3]や, 時系列データの分類などに用いられる回帰型ニューラルネットワークなどが挙げられる. リザーバネットワークは回帰型ニューラルネットワークから派生したネットワーク[4],[5]の中の一つであり, レーザーやスピントルク振動子を利用したリザーバコンピューティング[6],[7]の実装の研究などもなされている.

ニューロンは, 主に, 樹状突起, 細胞体, 軸索, シナプスから構成される. 樹状突起で受け取った入力刺激が, 細胞体で処理され, 発火する. 発火によって発生した電気的信号は軸索を通り, 他のニューロンに伝播していく. この伝播を再現するため, 本稿では非同期セルオートマトン[8]を用いる. この手法はニューロンを多数の区画に分割して表し, 区画毎に膜電位の動きを実装するものである. この非同期セルオートマトンは, 生物などの行動の経過を理解するために用いられ, 微分方程式が不要のため, 乗算器などの演算装置などを用いないことから, 実装しやすいことなどが特徴として挙げられる.

以上の強みに着目し, 本稿では, この手法を用いた, 伝達遅延を有するポリクロナイゼーションを用いたリザーバネットワーク[9][10]を規模や入力信号を増やして分類機能を有することを示す. また, field programmable gate array (以下, FPGA)に実装しオライナー法(Izhikevichモデル)との比較を行い, 少ない回路素子数で実装可能であること

を示す. そして畳み込みニューラルネットワーク(Convolutional Neural Network 以下, CNN)との使用電力の比較を行う. さらに, リザーバネットワーク内のニューロンの結合率やスパイクタイミング依存性のシナプス可塑性(Spike-timing-dependent plasticity, 以下 STDP)を有するスパインユニットの割合を変化させることで, 正弦波や心電図波形を正しく分類できることを示し, パラメータ毎の正答率を検証する.

2. 非同期セルオートマトンを用いたニューロンモデル

本稿では, 伝達遅延を有するリザーバネットワークの膜電位モデル[8]の構造を示す. 図 1[8]に膜電位ユニット M_i の構造を示す.

$$V_i \in \{0, 1, \dots, M-1\} = M, \quad (1)$$

$$U_i \in \{0, 1, \dots, N-1\} = N. \quad (2)$$

ここで, 整数パラメータ $M > 0, N > 0$ は離散の膜電位 V_i と U_i の分解能をそれぞれ決定する. また, 各ニューロンは, 非同期の内部クロック C_{V_i} と C_{U_i} を持つ.

$$C_{V_i}(t) = \begin{cases} 1 & \text{if } t \in \{t_{V_i}^{(1)}, t_{V_i}^{(2)}, \dots\}, \\ 0 & \text{otherwise.} \end{cases} \quad (3)$$

$$C_{U_i}(t) = \begin{cases} 1 & \text{if } t \in \{t_{U_i}^{(1)}, t_{U_i}^{(2)}, \dots\}, \\ 0 & \text{otherwise.} \end{cases} \quad (4)$$

ここで, $t_{V_i}^{(n)}, t_{U_i}^{(n)}$ は, クロックの立ち上がり時刻を表す.




図1 膜電位ユニット M_i の離散状態の非同期状態遷移[8]

内部クロック C_{V_i} , C_{U_i} はそれぞれ膜電位ユニット M_i の離散状態 V_i と U_i の非期遷移を引き起こす。

$$V_i(t^+) = V_i(t) + D_V(V_i, U_i) \text{ if } C_{V_i}(t) = 1, \quad (5)$$

$$U_i(t^+) = U_i(t) + D_U(V_i, U_i) \text{ if } C_{U_i}(t) = 1. \quad (6)$$

ここで $D_V(V_i, U_i)$, $D_U(V_i, U_i)$ は離散状態 V_i , U_i によって定義される離散ベクトル場関数であり、次式で表される。

$$D_V(V_i, U_i) = \begin{cases} 1 & \text{if } (V_i, U_i) \in S_i^{++} \cup S_i^{+-}, \\ -1 & \text{if } (V_i, U_i) \in S_i^{-+} \cup S_i^{--}, \\ 0 & \text{if } (V_i, U_i) \in S_i^0, \end{cases} \quad (7)$$

$$D_U(V_i, U_i) = \begin{cases} 1 & \text{if } (V_i, U_i) \in S_i^{++} \cup S_i^{+-}, \\ -1 & \text{if } (V_i, U_i) \in S_i^{-+} \cup S_i^{--}, \\ 0 & \text{if } (V_i, U_i) \in S_i^0, \end{cases} \quad (8)$$

$$\begin{aligned} S_i^{++} &\equiv \{(V_i, U_i) | U_i < f_V(V_i), U_i \leq f_U(V_i)\}, \\ S_i^{-+} &\equiv \{(V_i, U_i) | U_i \geq f_V(V_i), U_i < f_U(V_i)\}, \\ S_i^{+-} &\equiv \{(V_i, U_i) | U_i \leq f_V(V_i), U_i > f_U(V_i)\}, \end{aligned} \quad (9)$$

$$S_i^{--} \equiv \{(V_i, U_i) | U_i > f_V(V_i), U_i \geq f_U(V_i)\},$$

$$S_i^0 \equiv \{(V_i, U_i) | (V_i, U_i) \notin S_i^{++} \cup S_i^{+-} \cup S_i^{-+} \cup S_i^{--}\}.$$

ここで、 f_V , f_U は離散の関数であり、以下で定義される。

$$\begin{aligned} f_V(V_i) &= [k_1(V_i)^2 + k_2V_i + k_3], \\ f_U(V_i) &= [k_4V_i + k_5], \\ k_1 &= \frac{f_1M}{N^2}, \quad k_2 = -2k_1[f_2N], \\ k_3 &= k_1([f_2N])^2 + [f_3M], \quad k_4 = \frac{f_4M}{N}, \\ k_5 &= ([f_5M])^2. \end{aligned} \quad (10)$$

ただし、 $[\cdot]$ は床関数である。図1より、スパインユニット S_i はシナプス荷重を保持するレジスタを持つ。

$$W_i \in \{W_{min}, \dots, 1, 2, \dots, W_{max}\}. \quad (11)$$

ここで、整数パラメータ $W_{max} > 0$ 及び $W_{min} \leq 0$ は離散シナプス荷重 W_i の分解能を決定する。図1より、スパインユニット S_i は入力刺激 I_i を受け取る。

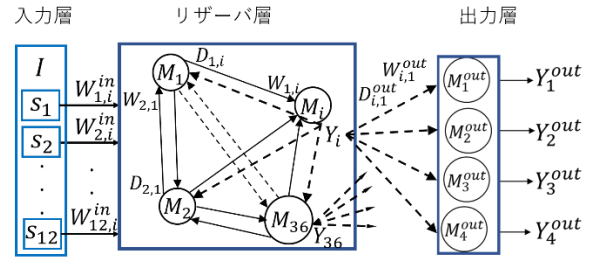


図2 ネットワークの全体図

$$I_i(t) = \begin{cases} 1 & \text{if } t \in \{t_{I_i}^{(1)}, t_{I_i}^{(2)}, \dots\}, \\ 0 & \text{otherwise.} \end{cases} \quad (12)$$

ここで、 $t_{I_i}^{(n)}$ は入力刺激 I_i の立ち上がり時刻を示す。

図1より、スパインユニット S_i への入力刺激 I_i は膜電位ユニット M_i の離散状態 V_i の以下のような非同期状態遷移を引き起こす。

$$V_i(t^+) = V_i(t) + W_i \text{ if } I_i(t) = 1. \quad (13)$$

また、膜電位ユニット M_i は内部ノイズ N_i を受け取ることを考慮する。

$$N_i(t) = \begin{cases} 1 & \text{if } t \in \{t_{N_i}^{(1)}, t_{N_i}^{(2)}, \dots\}, \\ 0 & \text{otherwise.} \end{cases} \quad (14)$$

ここで、 $t_{N_i}^{(n)}$ は内部ノイズ N_i の立ち上がり時刻を示す。この内部ノイズ N_i は膜電位ユニット M_i の離散状態

V_i の以下のような非同期状態遷移を引き起こす。

$$V_i(t^+) = V_i(t) + 1 \text{ if } N_i(t) = 1. \quad (15)$$

図1より、膜電位ユニット M_i の離散状態 V_i は、 $V_i = M - 1 \cap C_{V_i}(t) = 1$ の時に活動電位 $Y_i = 1$ を生成し、 $V_i = B$ にリセットされる。

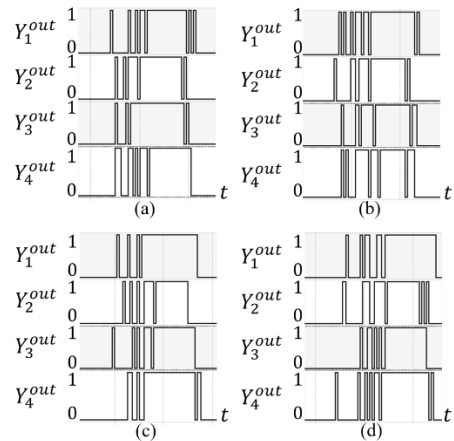


図3 各入力信号における出力波形(a)入力信号1. (b)入力信号2. (c)入力信号3. (d)入力信号4

3. 伝達遅延を有する非同期ポリクロナスリザーバネットワークと FPGA 実装

本章では、前章で紹介した、膜電位モデルを用いて、伝達遅延を有するリザーバネットワークを設計する。図2は同ネットワークの全体図である。このネットワークは入力層、 N 個のニューロンを有するリザーバ層、 Q 個のニューロンを有する出力層から構成される。入力層は12bitの入力信号 $I = (s_1, s_2, \dots, s_{12}) \in \{0,1\}^{12}$ を受け取る。この章では4つの入力信号を教師信号として用いる。

$I_1 = (0,1,0,1,0,0,0,0,1,1,0,0)$, $I_2 = (0,1,0,1,0,0,0,0,0,1,0,1)$, $I_3 = (1,1,0,0,0,0,0,0,1,1,0,0)$, $I_4 = (1,1,0,0,0,0,0,0,0,1,0,1)$. リザーバ層は入力信号 I に応答して複雑な発火パターン(ポリシンクロナイゼーション)を示す。リザーバ層ニューロン M_i の出力 y_i は伝達遅延 $D_{i,j}$ とシナプス荷重 $W_{i,j}$ を介して出力層ニューロン M_j^{out} に伝達される。出力ニューロン M_j^{out} が出力ニューロンの中で最も早く発火した場合、ネットワークは入力信号 I を教師信号 I_j として分類するとみなす。本研究では、伝達遅延 $D_{i,j}$ とシナプス荷重 $W_{i,j}$ を探索させ、分類機能を有することを示す。図3にネットワークをFPGAに実装した際のオシロスコープの波形を示す。

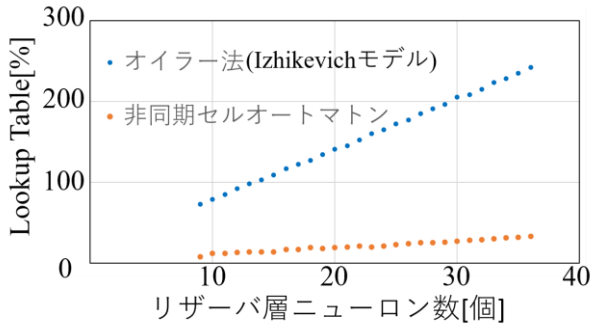


図4 リザーバ層ニューロン数と Lookup Table 使用率の関係

図3からネットワークが入力信号を正しく分類できていることが確認できる。

次に、非同期セルオートマトンとオイラー法 (Izhikevich モデル) において、リザーバ層のニューロン数の個数と Lookup Table の使用率の関係を図4に示す。図4より、どちらもどちらの手法もリザーバ層のニューロン数と Lookup Table の使用率は比例関係にある。表1にリザーバ層のニューロン数が36個の時の非同期セルオートマトンとオイラー法 (Izhikevich モデル) の回路素子数を示す。表1より、非同期セルオートマトンの合計素子数は28713、Izhikevich モデルの合計素子数169213であった。

表1 回路素子数の比較

	非同期セルオートマトン	Izhikevichモデル (オイラー法)
Lookup Table	20660	152973
Flip Flop	8053	16240




図5 スパインユニット S_i の離散状態 STDP の遷移

非同期セルオートマトンはオイラー法 (Izhikevich モデル) の16.97%の素子数であることがわかった。

4. STDP と伝達遅延を有する非同期ポリクロナスリザーバネットワークと心電図波形分類

スパインユニット S_i は離散状態を保持する以下のレジスタ、 $P_i \in \{0,1, \dots, P_{max}\}$, $D_i \in \{0,1, \dots, D_{max}\}$ を持つ。ここで、整数パラメータ $P_{max} > 0$ と $D_{max} > 0$ は離散状態 LTP(P_i)と離散状態 LTD(D_i)の分解能をそれぞれ決定する。LTP $\{0,1\}$ と LTDE $\{0,1\}$ は次式で定義される。

$$LTP(P) = \begin{cases} 1 & \text{if } P = 0, \\ 0 & \text{if } P > 0, \end{cases} \quad (16)$$

$$LTD(D) = \begin{cases} 1 & \text{if } P = 0, \\ 0 & \text{if } P > 0. \end{cases} \quad (17)$$

スパインユニット S_i は以下の内部クロックを持つ。

$$C_{S_i}(t) = \begin{cases} 1 & \text{if } t \in \{t_{S_i}^{(1)}, t_{S_i}^{(2)}, \dots\}, \\ 0 & \text{otherwise.} \end{cases} \quad (18)$$

ここで、 $t_{S_i}^{(n)}$ は内部クロック C_{S_i} の立ち上がりを示し、他の内部クロック C_{V_i}, C_{U_i} とは非同期である。図5に STDP によるスパインユニットの状態遷移を示す。離散状態 LTP と離散状態 LTD は内部クロック C_{S_i} 、入力刺激 I_i 、活動電位 Y_i によって、次式に示すような遷移を引き起こす。

$$P_i(t^+) = \begin{cases} P_{max} & \text{if } I_i(t) = 1, \\ P_i(t) - 1 & \text{if } C_{S_i}(t) = 1, \end{cases} \quad (19)$$

$$D_i(t^+) = \begin{cases} D_{max} & \text{if } Y_i(t) = 1, \\ D_i(t) - 1 & \text{if } C_{S_i}(t) = 1. \end{cases} \quad (20)$$

スパインユニット S_i への入力刺激 I_i (シナプス前電位)と膜電位ユニット M_i からの活動電位 Y_i (シナプス後電位)はお互いの到達時間により、シナプス荷重 W_i の以下のような遷移を引き起こす。また、シナプス荷重 W_i の取りうる範囲は初期値によって変化する。初期値のシナプス荷重 $W_i(0) > 0$ の時、 $W_i \in \{1,2, \dots, W_{max}\}$ となり、

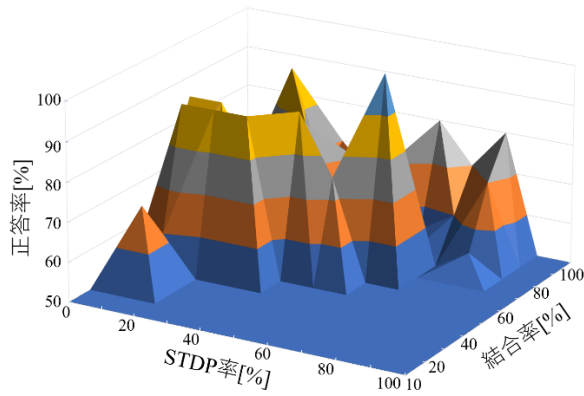


図 6 STDP 率と結合率の値による心電図信号の分類正答率

$$W_i(t^+) = W_i(t) + LTP(P_i(t)) \text{ if } Y_i = 1 \quad (21)$$

$$W_i(t^+) = W_i(t) - LTD(D_i(t)) \text{ if } I_i = 1 \quad (22)$$

$W_i(0) < 0$ の時, $W_i \in \{W_{min}, \dots, -2, -1\}$ となり,

$$W_i(t^+) = W_i(t) - LTP(P_i(t)) \text{ if } Y_i = 1 \quad (23)$$

$$W_i(t^+) = W_i(t) + LTD(D_i(t)) \text{ if } I_i = 1 \quad (24)$$

となる。シナプス荷重 $|W_i|$ は入力刺激 I_i が活動電位 $Y_i = 1$ より前(後)にスパイクユニット S_i に到達した時, シナプス荷重 $|W_i|$ は増加(減少)する。

この STDP を有するネットワークを用いて心電図波形の分類を行う。入力信号は, マサチューセッツ工科大学が出している心電図データ[11]を用いた。正常波形と異常波形をそれぞれ 10 種類ずつ教師データとして学習させ, 未学習のデータをそれぞれ 10 種類ずつ計 20 種類用意し分類を行った。教師データとして使用したデータはテストデータに含まれない。ネットワーク内の出力層の STDP を有するニューロンの割合(以下, STDP 率)とリザーバ層ニューロンと出力層ニューロンの結合の割合(以下, 結合率)を変化させ, 伝達遅延 $D_{i,j}$ とシナプス荷重 $W_{i,j}$ の探索を行う。図 6 にネットワークの STDP 率と結合率によるテストデータの分類正答率を示す。STDP 率が 60%, 結合率が 70%の時にテストデータの正答率が 100%となった。各入力信号によるネットワークのパラメータや他の入力信号の分類, CNN との電力比較については, 修士論文で説明する。

5. まとめ

非同期ポリクロナスリザーバネットワークの実装を行った。非同期セルオートマトンがオイラー法(Izhikevich モデル)の 16.97%の素子数で実装できることがわかった。ネットワーク内の STDP 率と結合率を入力信号に合った適切な値にすることで, 分類精度が向上することがわかった。これにより分類精度を保ちつつ, 回路素子数のさらなる削減が期待できる。正弦波波形など簡易的な入力信号の分類は十分な精度で行うことができる。心電図波形の分類

は今回用いたデータ, 条件では分類ができているが, 異常波形の多様な特性に対応し, 精度を保ちつつ, データを分類することが今後の課題である。

謝辞:最後に, 本研究を進めるにあたり, 研究の内容, 方針などの指導を受け賜りました法政大学の鳥飼弘幸教授には, 深く感謝いたします。

参考文献

- 1) K. Fukushima : Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, Biological Cybernetics, vol. 36, no. 4, pp. 193-202, 1980
- 2) Z. Li, et al. : A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects, in IEEE Transactions on Neural Networks and Learning Systems, vol. 33, no. 12, pp. 6999-7019, 2022
- 3) B. M. Mathunjwa, et al. : ECG arrhythmia classification by using a recurrence plot and convolutional neural network. Biomed. Signal Process. Control, vol.64, pp.102262,2021
- 4) H. Jaeger : The "echo state" approach to analyzing and training recurrent neural networks – with an Erratum note GND Technical Report 148, German National Research Center for Information Technology, 2001
- 5) W. Maass, et al. : Real-time computing without stable states : A new framework for neural computation based on perturbations, Neural Computation, vol. 14, no. 11, pp. 2531-2560, 2002
- 6) C. Sugano, et al. : Reservoir Computing Using Multiple Lasers With Feedback on a Photonic Integrated Circuit, Proc. IEEE Journal of Selected Topics in Quantum Electronics, vol. 26, no. 1, 2020,
- 7) M. Riou, et al. : Neuromorphic computing through time-multiplexing with a spin-torque nano-oscillator, Proc. IEEE IEDM, pp. 36.3.1-36.3.4, 2017
- 8) E. M. Izhikevich : Dynamical Systems in Neuroscience, The MIT Press, 2010
- 9) 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. IJCNN, pp. 1-8, 2020
- 10) Charles R. Day, et al. : A comparative evaluation of time-delay, deep learning and echo state neural networks when used as simulated transhumeral prosthesis controllers, Proc. IEEE IJCNN, #21073, 2020
- 11) The Laboratory for Computational Physiology : The WFDB Python package, <https://pypi.org/project/wfdb/>, vol. 4.0.0, 2022