

ニューラルネットワークのリザーバー層における収束性の一検討

A Study on Convergence in the Reservoir Layer of Neural Networks

○山口明伸¹, 佐々木芳樹²

*Akinobu Yamaguchi¹, Yoshiki Sasaki²

Abstract: In recent years, reservoir computing, which excels in parallel processing of time series data, has been attracting attention, but the network constructed using the neuron model we proposed earlier has not been examined for use as a reservoir layer. In this paper, we investigated the convergence of the output pattern when an arbitrary pattern is input, using the correlation coefficient calculated from the voltage waveform and the number of firings. As a result, it is reported that the output pattern convergence, which is one of the characteristics of the reservoir layer, was found to have convergence in the number of firing occurrences.

1. まえがき

近年, 生体における脳の情報処理能力を工学的に再現する脳型コンピュータの研究が進んでいる[1]. なかでも, 時系列データの並列処理に対してリザーバーコンピューティングが注目されており, ニューラルネットワークをリザーバー層として用いる研究が進められている[2]. 先に我々は, Δ 形負性抵抗素子を用いたニューロンモデルを提案しているが, 本モデルを用いて構築したネットワークをリザーバー層として用いる検討を行っていない. リザーバー層が持つべき特性について定義は行われていないが, 一般的に過去の履歴情報に関わらず任意の入力に対して一定の出力パターンへの収束性 (echo state propaty) や, 異なる入力パターンに対してそれぞれの出力パターンに異なる特徴を与えることが出来る明瞭区別性が必要であると考えた.

本稿では, 先に提案しているパルス型ハードウェアカオスニューロンモデル(以下 P-HCNM) [3]を用いてリザーバー層を構築し, 任意のパターンを入力した際の出力パターンが持つ収束性を, 電圧波形および発火生起回数により算出した相関係数を用いて検討したので報告する.

2. 本論




図1 リザーバー層の構成(一部)

図1に, 本稿で検討したリザーバー層の構成の一部を示す. 同図は, 108個の P-HCNM から構成しており,

1: 日大理工・学部・電子 2: 日大理工・教員・電子

P-HCNM 同士を興奮性および抑制性シナプスモデルで接続している. 図中, P-HCNM は黒丸で示す. 各 P-HCNM はすべて同じパラメータであり, 興奮性シナプスモデルおよび抑制性シナプスモデルも同様に結合荷重値も同一のパラメータとして構成した.

図2に, シナプスモデルの回路構成を示す. 同図は図1中に示した. 興奮性および抑制性のシナプスモデルに相当する. 同図は OTA をベースに, 外部信号により出力の ON および OFF を制御可能としたモデルである. 図中において, Pch-MOSFET のバルクは V_{DD} に, Nch-MOSFET のバルクはグランドに接続している. なお, 今回用いた OTA の入力電圧範囲は $0.7 \leq V_A \leq 1.1$ である. 興奮性シナプスモデルとして用いる場合, OTA の入力電圧 V_A は $0.9 \leq V_A \leq 1.1$ の範囲内で, 抑制性シナプスモデルとして用いる場合, $0.7 \leq V_A \leq 0.9$ の範囲内で, 任意の電圧値を入力した. なお, 今回 I_{ref} には $50\mu A$ を設定した.




図2 シナプスモデルの回路構成

本稿で検討する際に用いた正規化相互相関(以下 NCC)を算出する際に用いる式を以下の(1)に示す.

$$NCC = \frac{\sum_y \sum_x A(x, y) B(x, y)}{\sqrt{\sum_y \sum_x A(x, y)^2 \sum_y \sum_x B(x, y)^2}} \quad (1)$$

式(1)中における A は比較元の範囲, B は比較対象の範囲である. 比較元の範囲は正弦波 2 周期目 (1ms~2ms) を入力した際の各 P-HCNM の出力電圧および発火回数, 比較対象の範囲は正弦波 1~5 周期目 (0ms~5ms) を入力した際の各 P-HCNM の出力電圧および発火回数である. x は P-HCNM の番号, y は時間であり, 範囲は 1ms 間である.

図 3 に, 図 1 に示した P-HCNM の発火波形を示す. シミュレーション条件として, 本稿で検討したリザバー層における任意の 2 個の P-HCNM に周波数 1kHz 波高値 $900\mu\text{A}$ の正弦波を入力した. その際, 任意の $100\mu\text{s}$ 間の発火波形を示したものである. 同図に示す通り, 縦軸は出力電圧, 横軸は時間である. 各 P-HCNM の出力電圧より NCC を算出する際は, 位相のずれによる相関値の誤差発生を防ぐため, 比較対象である範囲 B において $10\mu\text{s}$ ずつ y の時間をずらし, NCC の算出を行った. 同様に各 P-HCNM の発火生起回数により NCC を算出する際は, 同図に示す通り, $50\mu\text{s}$ ごとに $\pm 25\mu\text{s}$ 間に発火回数のカウントを行った. 範囲 B における比較対象において, 出力電圧より算出する際と同様, $50\mu\text{s}$ ずつ y の時間をずらし, NCC の算出を行った.




図 3 任意のニューロンの発火波形

図 4 に, 任意の 25 個の P-HCNM の出力電圧および発火生起回数により, 正規化相互相関(以下 NCC とする)を算出した結果を示す. シミュレーション条件として, 本稿で検討したリザバー層における任意の P-HCNM 2 個に $1\text{kHz}900\mu\text{A}$ の正弦波を 5 周期入力した. 同図に示す通り, 同一波形入力時における NCC を各ニューロンの出力電圧により算出した際, 比較対象と比較元の入力信号が同位相時に NCC の値が高くなっているが, 0.5 を下回る低い相関性であった. 一方, 各ニューロンの発火回数により算出した際, 比較対象

と比較元の入力信号が同位相時に 0.9 を上回る高い相関性であった. これは, 本稿で検討したネットワークは, リザバー層の特徴の一つである収束性を有することを示している.

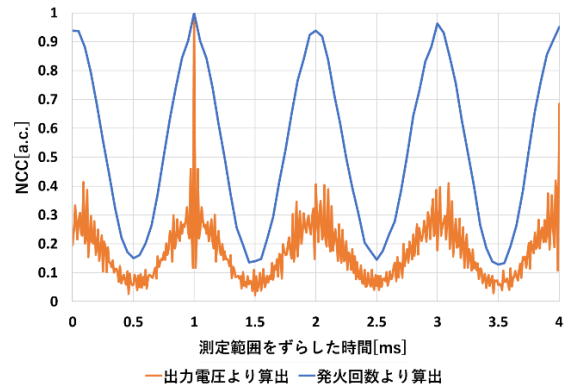


図 4 任意の 25 個のニューロンの NCC 算出結果

3. まとめ

今回, 先に提案している P-HCNM を用いてリザバー層を構築し, 任意のパターンを入力した際の出力パターンが持つ収束性を, 電圧波形および発火生起確率により算出した相関係数を用いて検討を行った. その結果, 発火生起確率においてリザバー層が持つべき特徴である収束性を持つことを明らかにした.

今後は, 形状や位相が異なる信号を入力させた際の出力を測定することで, 入力信号が区別可能なリザバー層の構築を行う予定である.

謝辞

本研究は東京大学大規模集積システム設計教育センターを通し, シノプシス株式会社, 及び日本ケイデンス株式会社の協力で行われたものである.

参考文献

- [1] 堀尾喜彦「脳型コンピュータハードウェア：進展・停滞と期待」, 日本神経回路学会誌, Vol.22, No.4, pp149-151, 2015
- [2] 井上理哲人, 福田佳祐, 堀尾喜彦:「カオスニューラルネットワークリザバーの音声認識への応用」, 電子情報通信学会技術研究報告, NLP2019-103, pp95-98, 2020
- [3] 佐々木芳樹, 佐伯勝敏:「自動補正機構を有するパルス形カオスニューロンモデル」, 電子情報通信学会論文誌エレクトロニクス, VoL.J104-C, No.8, pp.233-239, 2021