

興奮性・抑制性ニューロンの役割分化を理解するための RNN モデリングアプローチ

下坂碧* 山口裕**

(福岡工業大学 *大学院工学研究科 **情報工学部)

1 はじめに

脳において、ニューロン活動の振動現象は基本的な生理学的脳機能を提供していると考えられている[1]. 特に、海馬において観察されるシータ波は時系列記憶の生成に重要な働きがあると考えられている. また、脳を構成する興奮性と抑制性のニューロンはそれぞれ異なった働きを担っていることが知られている.

神経科学分野においては近年、神経ネットワークをモデル化した Recurrent Neural Network (RNN) を用いるアプローチが脳のメカニズムを理解するための有力な手段として注目されている. 本研究では、興奮性・抑制性ニューロンの性質の違いを取り入れた RNN[2] を用いて、ニューロン活動の振動を再現しながら情報処理を行うモデルを構築し、その振る舞いを解析する. とくに、海馬や大脳皮質にみられるような興奮性・抑制性細胞の役割の分化がモデルで再現できるか検討する.

2 手法

2.1 モデル

RNN は、生物の脳をモデル化して作られたニューラルネットワークの一種である. 本実験で使用されるモデルは、文献[2]を参考にしており、興奮性と抑制性を明示的に区別して構成されている(図1). つまり細胞の出力結合重みを興奮性細胞は 0 以上、抑制性細胞は 0 以下に制限する.

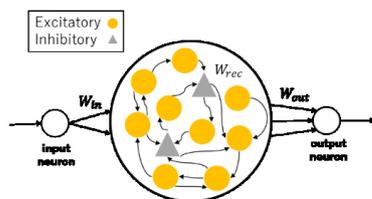


図 1 ネットワークモデル

2.2 手法

シータ波を想定して、周期的に入力される情報を処理するネットワークを考える. MNIST の画像を 1 枚 120×28 ピクセルに拡張し、28 次元ごと 120 時間ステップ入力し、120 ステップ目の出力を使ってクラス識別をさせる. さらにこれを 10 文字並べ連続的な識別を行わせる.

学習後のモデルを用いて、各細胞発火率の入力クラスと振動位相への依存性をそれぞれ調べた.

位相への依存性については、1 文字にあたる 120 ステップを 1 周期とみなし、1 周期内の位相ごとに発火率の平均と標準偏差をニューロン毎に調べる.

入力クラスへの依存性については、入力クラスへの感受性の指標として個々の細胞出力のクラス間/クラス内分散比(F 値)を計算する.

3 結果

位相への依存性についての結果を図 2 に示す. ただし、図 2 は、10 個の学習後のモデルからそれぞれ得られた個々の細胞の 1 周期内における平均発火率の変化を、興奮性、抑制性ごとに全細胞平均した結果である. 抑制性細胞の方がより振幅が大きい傾向があり、位相が後方にずれていることがわかった.

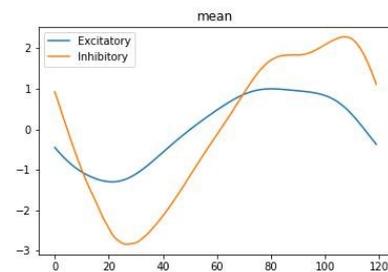


図 2 一周期内の平均発火の推移

分散比(F 値)と発火率の振幅の分布を図 3 で示す. 10 個の学習後のモデルから得られた全結果を描画した. 振幅は抑制性細胞が平均的には高く、一方 F 値の分布は興奮性細胞のほうが分布の範囲が広がる傾向がみられる.

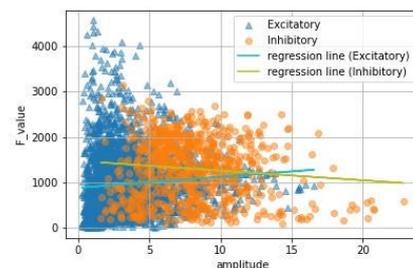


図 3 振幅と F 値の分布

4 まとめ

本研究では興奮性と抑制性を区別したモデルを用いて周期的にクラス識別学習をさせた際の興奮性・抑制性細胞の傾向の違いを分析した. ニューロンの発火タイミングは、興奮性・抑制性ニューロン間で位相と振幅、クラスへの依存性について分布に違いがみられ、ある程度の役割分化が起こっていることが示唆された.

参考文献

- [1] ジェルジ・ブザーキ: 脳のリズム, みすず書房, 2019 年
- [2] H. Francis Song, Guangyu R. Yang, Xiao-Jing Wang : PLOS Computational Biology , 1004792, 2016