

PQN モデルにおけるパラメータフィッティング

数理工学専攻 48-206216 酒井 大門
指導教員 河野 崇 教授

1 概要

Piecewise Quadratic Neuron(PQN) モデルは神経細胞の電位変化を再現するスパイクニューロンモデルであり、デジタル演算回路として実装した際のコストが低い上に、様々な神経細胞の発火現象を正確に再現することができるというメリットがある。本論文では、この PQN モデルの各パラメータの性質に基づいた、先行研究よりも実行時間の短いパラメータフィッティング手法を提案し、実際の神経細胞の計測データに対してその手法を適用する実験を行った。実験結果では、フィッティングの結果、平均二乗誤差 (MSE) を削減できたことが示された。将来この手法を slow dynamics を含む PQN モデルに拡張することで、より幅広い神経細胞の発火現象に対応したパラメータフィッティングが行えるようになることが期待される。

2 PQN モデル

PQN モデルは以下のような微分方程式で表される [1]。

$$\begin{aligned}\frac{dv}{dt} &= \frac{\phi}{\tau}(f(v) - n + I_0 + I_{\text{stim}}), \\ \frac{dn}{dt} &= \frac{1}{\tau}(g(v) - n), \\ f(v) &= \begin{cases} a_{fn}(v - b_{fn})^2 + c_{fn} & (v < 0) \\ a_{fp}(v - b_{fp})^2 + c_{fp} & (v \geq 0) \end{cases}, \\ g(v) &= \begin{cases} a_{gn}(v - b_{gn})^2 + c_{gn} & (v < r_g) \\ a_{gp}(v - b_{gp})^2 + c_{gp} & (v \geq r_g) \end{cases}.\end{aligned}$$

変数 v は神経細胞の膜電位に相当する変数、 n は回復変数である。パラメータ ϕ, τ は時定数、 I_{stim} は入力電流、 I_0 は偏差電流、パラメータ a_x, b_x, c_x, r_g (x はそれぞれ fp, fn, gp, gn) は v -ナルクライン、 n -ナルクラインの形状を調整するパラメータである。

3 実験

3.1 パラメータフィッティング手法

先行研究 [2][3][4] ではパラメータフィッティングとしてメタヒューリスティックな手法が提案されていて、フィッティングに平均して 340 分を要している。本研究では、パラメータフィッティングを素早く効率的に

行うために、スパイクの最小値と閾値の間隔、閾値と最大値の間隔、発火時間間隔 (interspike interval) の 3 つの値に注目した (図 1)。スパイクの最小値と閾値の間隔は、 v が負の領域におけるナルクラインの勾配、すなわち a_{fn} によって制御される。 a_{fn} が大きくなるとナルクラインの勾配が大きくなり、最小値と閾値の間隔は小さくなる。また、閾値と最大値の間隔は ϕ によって制御される。また、発火時間間隔の間隔は I_0 によって制御される。




図 1. 典型的なスパイクを表した図。最大値、閾値、最小値、発火時間間隔を算出することができる。

3 つのパラメータの性質を踏まえ、以下のようなフィッティングを提案した。

1. パラメータの初期値を設定する。
2. 観測データとシミュレーションによって得られたデータの二乗誤差が収束するまで以下のフィッティングを行う。
 - (a) a_{fn} のフィッティング

観測データとシミュレーションデータの、閾値と最小値の間隔を計算する。それぞれの間隔を比較し、観測データの方が大きい場合は a_{fn} を大きくし、小さい場合は a_{fn} を小さくする。なお、その際に分岐構造を維持するため、 $a_{fp}, a_{gn}, a_{gp}, b_{fn}, b_{gn}, c_{fn}, c_{gn}$ も併せて以下のように更新する。この更新を間隔が一致するまで繰り返す。

$$\begin{aligned}a'_{fn} &= r a_{fn}, \\ a'_{gn} &= r a_{gn}, \\ b'_{fn} &= b_{fn}/r, \\ b'_{gn} &= r_g - (r_g - b_{gn})/r, \\ c'_{fn} &= a_{fn} b_{fn}^2 + c_{fn} - a'_{fn} b_{fn}^2, \\ c'_{gn} &= a_{gn} (r_g - b_{gn})^2 + c_{gn} - a'_{gn} (r_g - b'_{gn})^2.\end{aligned}$$

なお、 x' (x は $a_{fn}, a_{gn}, b_{fn}, b_{gn}, c_{fn}, c_{gn}$) は更新後の x を表していて、 r は a_{fn} を変化させる比率であり本実験では $r = 0.9, 1.1$ とした。

(b) ϕ のフィッティング

観測データとシミュレーションデータの振幅を計算し、観測データの方が大きい倍は ϕ を大きくし、小さい場合は ϕ を小さくすることでフィッティングを行う。変化の比率 r は a_{fn} と同様、 $r = 0.9, 1.1$ とした。

(c) I_0 のフィッティング

観測データとシミュレーションデータの発火周波数を計算し、観測データの方が大きい倍は I_0 を大きくし、小さい場合は I_0 を小さくすることでフィッティングを行う。変化の比率 r は a_{fn} と同様、 $r = 0.9, 1.1$ とした。

3. 得られたパラメータを出力する。

3.2 電気生理学的データ

本研究では Allen Brain Atlas[5] で公開されている、神経細胞に定常刺激を与えた際の電気生理学的データをフィッティングの対象データとして用いた。

4 結果

図 2 はパラメータフィッティングによる波形の比較図である。また、図 3 はパラメータフィッティングによる MSE の変化グラフである。また、パラメータフィッティングに要した時間は平均 61.2 秒であった。




図 2. パラメータフィッティングによる波形の結果図。




図 3. 各データに対する MSE の変化グラフ。

表 1. パラメータフィッティングに要した時間

cell id[5]	フィッティング時間 [sec]
613438337	40.4
614635228	120.0
614726150	41.1

5 考察

本実験では、全てのデータに対して MSE を削減することができた。今後の展望として、スパイクが閾値を超えてから最大値に達するまでの時間と、最大値に達してから最小値に至るまでの時間をフィッティングする手法を研究することが挙げられる。また、3次元に拡張した PQN モデルに手法を拡張することで、Regular Spiking や bursting のような、より複雑な神経細胞のダイナミクスに対応できるようにすることが今後の展望として挙げられる。

参考文献

- [1] Takashi Kohno and Kazuyuki Aihara. Digital spiking silicon neuron: concept and behaviors in gj-coupled network. In *Proceedings of International Symposium on Artificial Life and Robotics*, volume 2007, 2007.
- [2] Takuya Nanami. *Qualitative-modeling-based digital silicon neuronal network models*. PhD thesis, The University of Tokyo, 3 2019. An optional note.
- [3] Takuya Nanami, Filippo Grassia, and Takashi Kohno. A metaheuristic approach for parameter fitting in digital spiking silicon neuron model. *Journal of Robotics, Networking and Artificial Life*, 5(1):32–36, 2018.
- [4] Takuya Nanami and Takashi Kohno. An fpga-based cortical and thalamic silicon neuronal network. *J. Robotics Netw. Artif. Life*, 2(4):238–242, 2016.
- [5] Allen Brain Atlas. <https://celltypes.brain-map.org/data>.