

スパースモデリングに基づく神経細胞非線形ダイナミクスの推定

Estimation of Nonlinear Neural Dynamics by Sparse Modeling

大塚 慎也*
Shinya Otsuka

大森 敏明*
Toshiaki Omori

1 はじめに

我々の記憶, 判断, 感情などの脳機能は, 脳の異なる領域で行われており, 様々な電気的応答特性 (神経ダイナミクス) がその実現に重要であると考えられている. しかし, 神経ダイナミクスには, 多数の種類の膜電流の候補が存在しており, 計測データから神経細胞の電気回路モデルを決定することは非常に困難な問題である [1].

本研究では, 計測データからの神経細胞ダイナミクスの精緻な推定を実現するために, スパースモデリングに基づいた推定法を提案する. 神経細胞の電気回路モデルとスパースモデリングを融合することにより, 多くの種類のモデルの候補から, 必要なモデルのみを抽出する方法を実現する. 数値実験を用いた検証により, 提案法の有効性を示す.

2 神経細胞の電気回路モデル

神経細胞の電気回路モデルは, 一般的に図 1 のように表される. 細胞膜をコンデンサ, イオンチャネルを動的な抵抗素子と考え, ナトリウム, カリウム, カルシウム の 3 種と, 漏れ出す電流が流れる漏れ素子があり, 各々の素子の中でも多くの種類が存在する [2].

$$I_i(t) = g_i m_i(t)^{M_i} h_i(t)^{H_i} (V(t) - E_i) \quad (1)$$

式 (1) における g_i はコンダクタンスで, 電流の有無を表し, E_i は平衡電位で, イオンの種類が同じ場合は同じになるが, モデルが異なれば別の値となる. また, m_i, h_i の式は, モデル, イオンごとに異なり, その次数 M_i, H_i も異なる. m_i, h_i の一般形は, 以下の式に示す.

$$\frac{dx(t)}{dt} = \alpha_x(V)(1 - x(t)) - \beta_x(V)x(t) \quad (2)$$

ここで, $\alpha_x(V), \beta_x(V)$ はそれぞれ膜電位 $V(t)$ の指数関数で与えられ, 式の形は異なる.

細胞内に電極から流れ込む電流 (入力電流) $I(t)$ と膜電位 $V(t)$

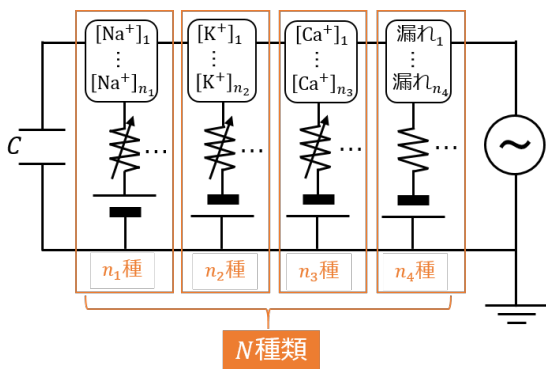


図 1. N 種類の膜電流の候補がある一般形モデル

の関係は, 以下の式で与えられる.

$$C \frac{dV(t)}{dt} = - \sum_{i=1}^N \{I_i(t)\} + I(t) \quad (3)$$

C は膜容量, N は膜電流の種類の数を表す. この式から, 膜電流の種類によって, モデルを決定することができる.

3 推定問題の定式化とアルゴリズム

本節では, 推定問題の定式化を行い, その定式における推定アルゴリズムをスパースモデリングに基づいて提案する.

3.1 推定問題の定式化

図 1 における膜電位 $V(t)$ と電流の関係式 (3) を変形すると,

$$C \frac{V(t+1) - V(t)}{\Delta t} - I(t) = - \sum_{i=1}^N \{I_i(t)\} \quad (4)$$

と書き換えられる. 式 (4) は, 左辺に $V(t+1)$ だけを残せば, 現時刻の膜電位 $V(t)$ を与えることで次時刻の膜電位 $V(t+1)$ を得ることができる.

次に, 式 (4) の右辺に式 (1) を代入し, 機械学習的な観点から g_i を係数と見ると, 以下のように定式化でき, 図 2 のような枠組みとなる.

$$\mathbf{y} = \mathbf{A} \mathbf{g} \quad (5)$$

$$\mathbf{y} = \begin{pmatrix} C \frac{V(2) - V(1)}{\Delta t} - I(1) \\ C \frac{V(3) - V(2)}{\Delta t} - I(2) \\ \vdots \\ C \frac{V(T) - V(T-1)}{\Delta t} - I(T) \end{pmatrix} \quad (6)$$

$$\mathbf{A} = \begin{pmatrix} I_1(t) & \cdots & I_N(1) \\ \vdots & \ddots & \vdots \\ I_1(T-1) & \cdots & I_N(T-1) \end{pmatrix} \quad (7)$$

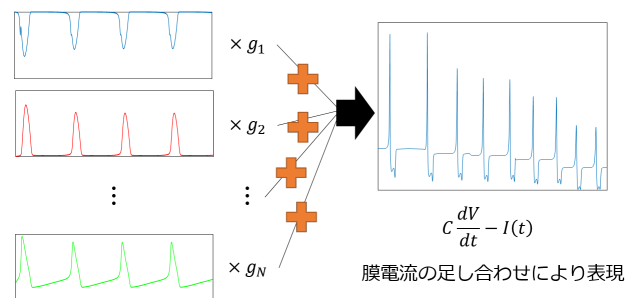


図 2. 提案法の枠組み

提案法では, \mathbf{g} にスパース性を導入することで必要な膜電流のみを抽出し, モデルを決定する.

*神戸大学大学院工学研究科, Graduate School of Engineering, Kobe University

$$g = \begin{pmatrix} g_1 \\ \vdots \\ g_N \end{pmatrix} \quad (8)$$

これらの式から、本研究の神経細胞モデルにおける y は、行列 A の要素 (様々な膜電流) にコンダクタンス g を掛けたものの足し合わせにより表現することができる。

3.2 Lasso に基づく推定アルゴリズム

本研究では、観測データから、不要な膜電流をゼロにし、必要な膜電流を非ゼロにすることが目標であるため、定式化した式にスパース性を導入することによって、それを実現した [3]。スパース (sparse) とは「疎」や「まばら」という意味であり、スパース性とは、係数 g の成分がゼロであるものが多く、非ゼロの成分が少ないことを表す。

本研究では、スパース性を仮定した推定法であるスパースモデリングを導入する。その中でも代表的である、最小二乗法に L1 正則化項を加えた Lasso の式を以下に示す。

$$g = \arg \min_g \|Ag - y\|_2^2 + \lambda \|g\|_1 \quad (9)$$

式 (9) の第 1 項は誤差項を表し、第 2 項は正則化項を表す。 g は N 種類のコンダクタンスで、 A は式 (7) の行列、 y は式 (6) の観測データ、 λ は正則化項の重要度を調整するパラメータである。ここでの目的は、観測データ V を与えれば既知である A, y から g を推定することである。

本研究では、スパース性を考慮しない $\lambda = 0$ の場合を従来法として、Lasso による提案法と比較し、どちらの方が有効であるかを検証した。

4 実験

本研究の提案法の有効性を検証するために、図 3 に示す人工データ $V(t)$ を用いたシミュレーション実験を行った。推定で用いた候補モデルは、膜電流 11 種類で構成されるモデルとし、そのうちの 3 種類を真のモデルの膜電流とした。人工データ $V(t)$ を式 (6) と式 (7) に与え、それらを Lasso の式 (9) に適用することで、コンダクタンス g を推定した。また、 λ は汎化誤差による交差検定を行うことで決定した (図 4)。

図 5 は、提案法と従来法のコンダクタンス g を示す。真のモデルのコンダクタンスである $g_L, g_{Na(HH)}, g_{K(HH)}$ は、提案法の方がより真値に近い値を得ている。それ以外の不要なコンダクタンス g_i は、従来法では全てのコンダクタンス g_i が非 0 となり、且つコンダクタンス g_i の値が大きくなっているが、提案法では $g_{Na(FS)}$ 以外を 0 にすることが出来ている。よって、提案法では、不要なコンダクタンス g を最大限 0 にし、必要なコンダクタンス g を選び出すことが可能となり、有効性が高い結果となった。

また、推定したコンダクタンスを用いて、膜電位 V を再計




図 3. 入力データ (上: 入力電流 $I(t)$, 下: 膜電位データ $V(t)$)

図 4. λ を変化させた際の汎化誤差の変化 (最小値の λ を選択)

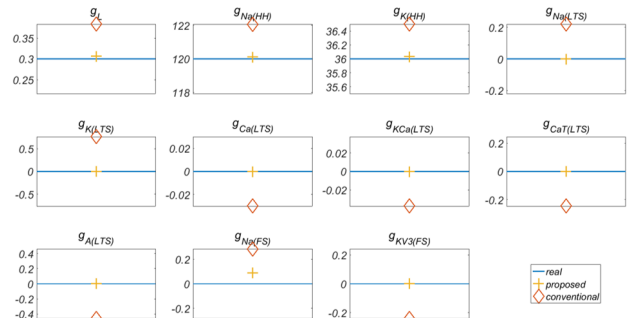


図 5. 提案法と従来法のコンダクタンスの比較 (青実線: 真値, 黄+: 提案, 赤 : 従来)




図 6. 提案法と従来法の膜電位データ V の比較 (青実線: 真値, 黄点線: 提案, 赤実線: 従来)

算したのが図 6 である。従来法の膜電位は真の膜電位からは大きく外れてしまっているが、提案法の膜電位は真の膜電位と重なり、推定したコンダクタンスによる再現性が高い。この点からも、提案法は従来法よりも有効性が高い結果であると言える。

5 おわりに

本研究では、スパースモデリングの代表的な例である Lasso を導入した、神経細胞の電気回路モデルの推定アルゴリズムを提案した。提案法では、真のシステムに含まれる膜電流のコンダクタンスのみを非 0 とし、含まれない膜電流のコンダクタンスを 0 とすることで、膜電流の候補からの精緻な抽出を可能にし、正確な神経細胞モデルの推定が実現されることを示した。

謝辞

本研究の一部は、文部科学省 科学研究費補助金 新学術領域研究「スパースモデリングの深化と高次元データ駆動科学の創成」[課題番号 JP25120010]、国際共同研究加速基金 (国際共同研究強化)[課題番号 JP15KK0010] の援助の下で、行われた。

参考文献

- [1] 甘利俊一・深井朋樹: 脳の計算論 (シリーズ脳科学 1), 東京大学出版会, 2009.
- [2] Toshiaki Omori, Koji Hukushima, "Extracting Nonlinear Spatiotemporal Dynamics in Active Dendrites Using Data-driven Statistical Approach" Journal of Physics: CS, Vol. 699, pp. 012011-1-8 (2016)
- [3] 大森敏明, "回帰問題への機械学習のアプローチ~スパース性に基づく回帰モデリング~", システム制御情報学会誌, Vol. 59, 151-156 (2015).