

データ駆動型アプローチに基づく 神経ダイナミクスのオンライン推定と制御

Online estimation and control of neural dynamics based on data-driven approach

深見 修平*
Shuheï Fukami

大森 敏明*
Toshiaki Omori

1. まえがき

近年の神経科学分野における計測・刺激技術の発展に伴い、神経システムの制御技術の確立が求められている。これに関連して、単一ニューロンに刺激を加える際にベイズ統計学に基づいて推定されたニューロンの状態から単一細胞への刺激を決定する方法が提案されている [1]。しかしながら、従来の枠組み [1]では、モデルパラメータが既知として扱われているという問題点が存在する。未知のパラメータが存在する状況で実際に運用する際には、推定された状態変数からフィードバック制御信号を決定するために、パラメータと状態を同時にオンライン推定する必要がある。

本研究では、神経ダイナミクスを定めるモデルパラメータと状態を同時に推定し、推定された値に基づく制御信号を動的に決定するデータ駆動型手法を提案する。非線形ダイナミクスの状態とパラメータのオンライン推定を実現するために、逐次モンテカルロ法と確率的EMアルゴリズムに基づく手法を構築する。提案手法によって観測値からより正確な制御が可能であることを示す。

2. 提案手法

2.1. 神経ダイナミクスモデルの状態空間モデルへの適用と潜在変数推定

本研究では、ノイズを含んだ観測値から非線形神経ダイナミクスモデルの推定のために、神経システムのモデルを確率モデルに拡張し、それらを基に状態空間モデルを構成する。まずシステムモデルを定式化する。神経モデルの一つであるMorris Lecarモデル [2]において、膜電位 V とチャンネル変数 n は次に示す微分方程式(1),(2)に従う。

$$C_m \frac{dV}{dt} = -g_L(V - E_L) - g_{Ca}m_\infty(V)(V - E_{Ca}) - g_K n(V - E_K) + I + I_{feedback} \quad (1)$$

$$\tau_\infty(V) \frac{dn}{dt} = \phi(n_\infty(V) - n) \quad (2)$$

ここで、 I は入力電流、 g_L , g_{Ca} , g_K はそれぞれリーク電流、カルシウムイオン電流、カリウムイオン電流のコンダクタンス、 E_L , E_{Ca} and E_K はそれぞれの平衡電位、 ϕ は定数 $\tau_\infty(V)$, $m_\infty(V)$, $n_\infty(V)$ は膜電位 V に関する非線形関数を表す。また、 $I_{feedback} = G \cdot \hat{V}_t$ は制御信号、 G はゲインを表す。システムモデルのパラメータを $\theta = \{g_K, g_{Ca}, g_L, E_K, E_{Ca}, E_L\}$ で表す。これらの式を時間 t に関して離散化を施し、さらに確率モデルを構成する。ガウス分布を仮定すると、 V , n を潜在変数とするシステムモデルの確率モデルは次のように表される。

$$p(V_t | V_{t-1}, n_{t-1}, \theta) = \mathcal{N}(V_t | F_V(V_{t-1}, n_{t-1}, \theta), \sigma_{s_V}^2) \quad (3)$$

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

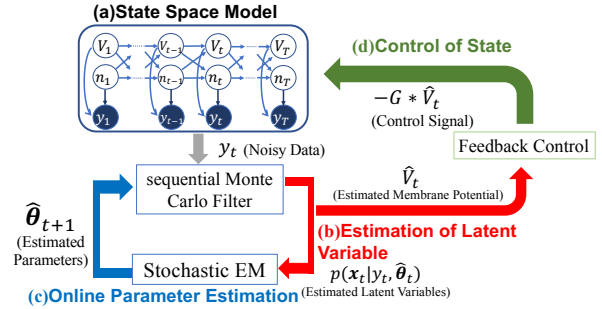


図1. 提案手法の概要図。潜在変数 $\mathbf{x}_t = \{V_t, n_t\}$ とパラメータ θ を同時かつオンラインで推定する。観測値 y_t は潜在変数の一つである膜電位 V_t を介して得られる。逐次モンテカルロ法により、 y_t から潜在変数のフィルタ分布 $p(\mathbf{x}_t | y_t, \hat{\theta}_t)$ を得る。この分布を用いて、パラメータの推定値 $\hat{\theta}_t$ を更新する。さらに、推定された膜電位 \hat{V}_t に基づき制御信号を決定する。

$$p(n_t | V_{t-1}, n_{t-1}, \theta) = \mathcal{N}(n_t | F_n(V_{t-1}, n_{t-1}, \theta), \sigma_{s_n}^2) \quad (4)$$

次に、観測モデルを定式化する。膜電位 V_t にガウス分布に従うノイズが重畳された観測値 y_t のみが観測される状況を想定すると、観測モデルの確率モデルは次のように表される。

$$p(y_t | V_t) = \mathcal{N}(y_t | V_t, \sigma_o^2) \quad (5)$$

これらの確率モデルを用いて、ノイズが含まれた観測値 y_t から膜電位 V_t とチャンネル変数 n_t を推定する。潜在変数 $\mathbf{x}_t = \{V_t, n_t\}$ に関する予測分布とフィルタ分布は、観測値 y_t を用いて、次のように表される。

$$p(\mathbf{x}_t | y_{1:t-1}) = \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | y_{1:t-1}) d\mathbf{x}_{t-1} \quad (6)$$

$$p(\mathbf{x}_t | y_{1:t}) = \frac{p(y_t | \mathbf{x}_t) p(\mathbf{x}_t | y_{1:t-1})}{p(y_t | y_{1:t-1})} \quad (7)$$

本研究では、神経システムモデルの非線形性に対応するために、推定手法として逐次モンテカルロ法 [3] [4]を適用する。

2.2. モデルパラメータのオンライン推定とフィードバック制御

本研究ではフィードバック制御を実現するために、逐次的に得られるデータに対するオンラインパラメータ推定が必要となる。そのためパラメータの推定手法として、EMアルゴリズムを基に逐次的な計算を可能にした手法の一つである確率的EMアルゴリズム(Stochastic EM) [5]を用いる。時刻 t におけるEステップでは、時刻 $t-1$ における十分統計量 μ_{t-1} と式(7)で表されるフィルタ分布を用いて対数尤度の期待値を以下のように計算する。

$$Q(\Theta(s) | \Theta(\mu_{t-1})) = \langle \log p(y_t, \mathbf{x}_t | \Theta(s)) \rangle_{p(\mathbf{x}_t | y_t, \Theta(\mu_{t-1}))} \quad (8)$$

ここで、パラメータの推定値 $\hat{\theta}_t$ は十分統計量の関数である Θ を用いて次のように求められる。

$$\hat{\theta}_t = \Theta(\mu_t) \quad (9)$$

Mステップでは、次のように十分統計量の平均値を指数移動平均 s_t を保持することによって近似し、十分統計量 μ_t を




図 2. ノイズを含んだ観測値 y_t から直接膜電位を制御した結果. 緑色の実線が制御された真の膜電位 V_t ($G \neq 0$), オレンジ色の実線が観測値 y_t , 青色の実線が制御信号を加えなかった際の V_t ($G = 0$) を表す.

再計算する.

$$s_t = \arg \max_s Q(\Theta(s)|\Theta(\mu_{t-1})) \quad (10)$$

$$\mu_t = (1 - \eta_t)\mu_{t-1} + \eta_t s_t \quad (11)$$

ここで, ステップサイズ η_t は次を満たす.

$$\sum_{t=0}^{\infty} \eta_t = \infty, \sum_{t=0}^{\infty} \eta_t^2 < \infty \quad (12)$$

確率的EMアルゴリズムでは, 各時刻で上記のEステップとMステップを繰り返すことでパラメータを逐次的に推定する.

図1に提案手法の概要図を示す. まず時刻 t において式(3), (4), (5) によって表される状態空間モデルに基づき観測値 y_t が得られる. その時刻におけるパラメータ $\hat{\theta}_t$ に基づいて, 逐次モンテカルロ法を用いてフィルタ分布 $p(x_t|y_t, \hat{\theta}_t)$ を求める. 次に, 得られたフィルタ分布から確率的EMアルゴリズムを用いてパラメータを更新する. ここで, フィルタ分布を用いて, 式(8)の $Q(\Theta(s)|\Theta(\mu_{t-1}))$ を計算する. このように, 潜在変数 x_t とパラメータ θ の同時推定を逐次的に行う. 同時に, 推定された膜電位 \hat{V}_t から制御信号を決定する. 以上の手順を繰り返すことで, パラメータが未知の状態でも神経細胞ダイナミクスの推定と推定値からの正確な制御を行う.

3. 推定結果

提案手法の有効性を検証するためにシミュレーションデータを用いて検証する. 評価のため, 提案手法を用いない場合と, 提案手法を用いた場合の2つの状況を考える. まず, ノイズの重畳した観測値から直接フィードバック制御信号を生成する状況を考える. 実験では, $t > 15000$ で神経システムに制御信号を印加する. 次に, 提案手法を用いて, モデルパラメータ θ , 潜在変数 x_t を同時に推定し, 推定した膜電位 \hat{V}_t を基にフィードバック制御を同時に行う状況を考える. ここでは, $0 \leq t \leq 15000$ では潜在変数とパラメータの推定のみを行い, $t > 15000$ で潜在変数, パラメータの推定とフィードバック制御を同時に行う. どちらの状況でも膜電位 V_t を安定化することを目的にフィードバック制御を行う.

図2では, ノイズが重畳された観測値に直接基づいたフィードバック制御下の膜電位の様子を示す. 膜電位 V_t が安定化するどころかノイズの影響を受けて不安定になっていることがわかる. 一方, 図3では膜電位の推定値から制御信号を決定することで, ノイズの影響を小さくし安定した制御が可能になることがわかる. さらに, パラメータ推定の結果の一部を図4に示す. これらの図より, 初期値から真の値に収束していることから, パラメータ推定に関しても良好な結果が得られていることがわかる.




図 3. 提案手法を用いて, ノイズを含んだ観測値 y_t から推定した潜在変数 \hat{V}_t に基づき膜電位を制御した結果. 赤色の実線がフィードバック制御下の真の膜電位 V_t ($G \neq 0$), オレンジ色の実線が観測値 y_t , 青色の実線が制御信号を加えなかった際の V_t ($G = 0$), 紫色の実線が膜電位の推定値 \hat{V}_t を表す.




図 4. モデルパラメータの推定結果. オレンジ色の破線, 青色の実線がそれぞれ真値 V_t と推定値 \hat{V}_t を表す.

4. まとめ

本研究では, 神経細胞の非線形ダイナミクスの状態とパラメータのオンライン推定を行うためにベイズ統計に基づく推定手法を提案した. 提案手法により, 潜在変数とパラメータの同時オンライン推定が可能であることを示した. また, 推定値をもとにフィードバック制御を行うことで, パラメータが未知の状態でもノイズを含む観測値からより正確な制御が可能であることを示した.

謝辞

本研究の一部は, 文部科学省科学研究費補助金国際共同研究加速基金(国際共同研究強化) [No. 15KK0010], 科学技術振興機構戦略的創造研究推進事業CREST [Nos. JPMJCR1755, JPMJCR1914] の支援のもとで行われた.

参考文献

- [1] Ghanim Ullah and Steven J Schiff: Physical Review E **79**, 040901 (2009)
- [2] Eugene M Izhikevich: IEEE Transactions on Neural Networks **15**, 1063–1070 (2004)
- [3] M Sanjeev Arulampalam, Simon Maskell, Neil Gordon, and Tim Clapp: IEEE Transactions on Signal Processing **50**, 174–188 (2002)
- [4] Toshiaki Omori, Tatsu Kuwatani, Atsushi Okamoto, and Koji Hukushima: Physical Review E **94**, 033305 (2016)
- [5] Olivier Cappé and Eric Moulines: Journal of the Royal Statistical Society: Series B **71**, 593–613 (2009)