

# 活動電位に対するニューラルネットワークや トレーニングデータの影響

## Influence of Neural Networks and Training Data to an Action Potential

高橋正明 (P)<sup>1)</sup>, 夏目季代久<sup>2)</sup>

Masaaki Takahashi (P) and Kiyohisa Natsume

九州工業大学大学院生命体工学研究科脳情報専攻

{takahashi-masaaki@edu.<sup>1)</sup>, natume@<sup>2)</sup>}brain.kyutech.ac.jp

**Abstract** — Automatic estimation of neuronal dynamics using channel conductances has been so far studied. For the estimation, fully-connected, and elman-type recurrent neural network and time-delayed neural network can be used. For learning the network various training data by manipulating fixed potentials can also be chosen. In this study, we investigate influences of used the neural networks and the training data to estimate a neuronal dynamics.

**Keywords** — Channel Dynamics, Hodgkin-Huxley Model, Neural Network

### 1 はじめに

神経細胞の電氣的活動は神経細胞膜にある数多くのチャンネルにより引き起こされる。神経活動をシミュレートする方法は2つ考えられる。1つ目は神経細胞膜電位の時系列データを用いてチャンネルのダイナミクスを推定しシミュレートする方法である[1]。これはトップダウン的アプローチである。それに対し2つ目は実験から得られたコンダクタンスの時系列を用いてチャンネルダイナミクスを推定する方法であり、これはボトムアップ的アプローチと呼ばれる。我々は様々な種類のチャンネルを選択し、自由に神経細胞を設計し、その膜電位をシミュレートしたいと考えているので、ボトムアップ的アプローチをこれまで取ってきた。

ボトムアップ的アプローチを行うには、電位固定法の実験により実際の神経細胞からチャンネルのコンダクタンス-電圧曲線の時間変化を得て、それを微分方程式で定式化し、チャンネルダイナミクスを求めることが必要である。しかし、その定式化はとても難しい。そこで、その定式化を自動的に推定するために、ダイナミクスを学習できるニューラルネットワーク(NN)の使用が有効ではないかと考えた。しかしながらダイナミクスを学習できる NN として完全相互結合型ネットワーク(FRNN)、Elman ネットワーク[2]、時間遅れ NN(TDNN)[3]等があり、また学習に用いるトレーニングデータも様々なパターンが考えられる。

本研究の目的はNNの違いやトレーニングデータの

違いによる、推定される神経活動への影響を調べることである。

### 2 方法

本研究では推定する神経活動として Hodgkin-Huxley (HH)モデル[4]を用いた。HHモデルとはヤリイカの巨大軸索のモデルであり、その膜電位は  $\text{Na}^+$ ,  $\text{K}^+$ , leak電流を計算することで得られる。各電流値は各チャンネルコンダクタンスにイオンの平衡電位と膜電位との差を掛け合わせることで計算できる。 $\text{Na}^+$ ,  $\text{K}^+$ について、そのコンダクタンスは微分方程式を用いて計算されるが、本研究ではNNを用いてそれぞれ2つのコンダクタンス計算を行った。

チャンネルダイナミクスの自動推定のためのNNとしてFRNN, Elman, TDNNを用いた。学習則は誤差逆伝播法[5]を用いた。各ネットワークへの入力は膜電位の値で、出力はコンダクタンスの値とした。すなわち学習後、NNは現在の膜電位の値を用いて次の時間のコンダクタンスの値を出力する。そのようなチャンネルコンダクタンスを再現しているNNをion-NN(ionは $\text{Na}^+$ もしくは $\text{K}^+$ , NNはFRNN, ElmanもしくはTDNN)と呼ぶ。また、チャンネルダイナミクスにNNを用いて計算した神経をNN-neuron (NNはFRNN, ElmanもしくはTDNN)と呼ぶ。なお、そのダイナミクスを4次のルンゲクッタ(RK)法で計算した神経をRK-neuronと呼ぶ。

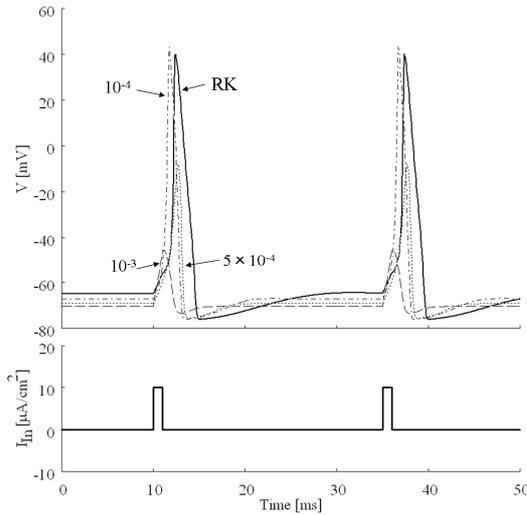
NNの学習データとしては実際に固定電圧実験で用いられる電流値を用いるが、固定電位を操作することで様々なパターンが得られる。本研究では、-65 mVからステップ的に電位が変化するパターン1、パターン1に-40 mVからステップ的に電位を変化させるパターンを加えたパターン2、およびステップ的ではなく滑らかに電位が変化するパターン3、の3種を用いた。

3つのNNの神経活動に対する影響を調べるため、それらのNNについて $\text{Na}^+$ -NNと $\text{K}^+$ -NNを各10個ずつ生成した。すなわちFRNN-neuron, Elman-neuron, TDNN-neuronを各100個ずつ生成した。この場合パターン3の学習データを学習に使用した。また、学習データの影響を調べるため、3つの学習パターンに対

しても各 10 個ずつ  $\text{Na}^+$ -NN と  $\text{K}^+$ -NN を生成した。このときは FRNN を使用した。

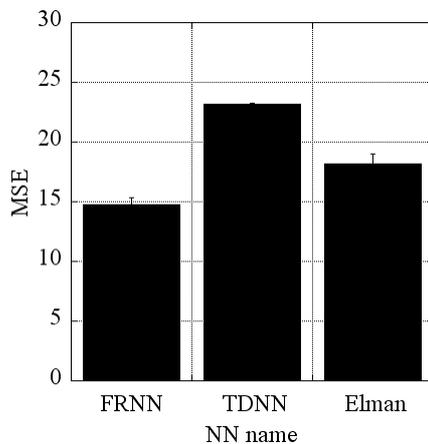
### 3 結果

NN を用いてのダイナミクス近似の評価にはその出力値とトレーニングデータの Mean square error (MSE) を用いた。Fig.1 に示すように、この誤差が小さくなればなるほど活動電位の形が RK-neuron のものと近くなっていった。



**Fig. 1.** 誤差の変化による活動電位の形の変化。図中の RK は RK-neuron を示し、矢印の根元の各数字はその時の誤差を示した。刺激は下部のトレースに示されている。

NN の違いを調べるため各 NN-neuron の活動電位を RK-neuron のものと MSE により比較した。結果を Fig.2 に示す。

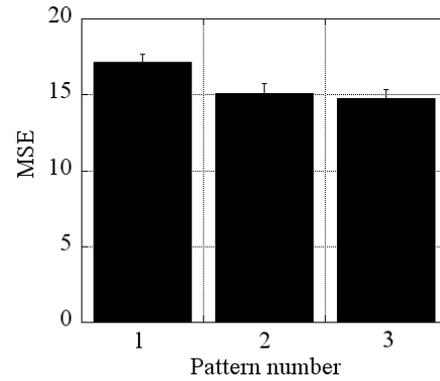


**Fig. 2.** NNの種類によるMSEの値

FRNN-neuronの結果が他の2つの場合に比べ有意に小さかった (ANOVA + Scheffe test,  $*p < 0.01$ )。

次に、学習パターンの違いについて調べた。結果を

Fig.3に示す。



**Fig. 3.** 学習データによるMSEの値

パターン2、3がパターン1と比べ有意に小さかった (ANOVA + Scheffe test,  $*p < 0.05$ )。パターン2と3とでは有意差はなかったがパターン3のほうが小さかった。

### 4 議論

本研究では NN を用いて神経活動を近似する方法としていくつかの NN を試し、訓練データの違いの影響を見た。その評価として MSE を用いた。結果に示されるように、MSE が小さいほど、RK-neuron の神経活動がよりよく再現できたので、NN の評価として用いて問題はないと考えられる。

3種の NN を用いた場合、FRNN を用いた場合が Elman や TDNN を用いた場合に比べ有意に MSE が小さかった。また、トレーニングデータは滑らかなものを用いたほうが活動電位の形が RK-neuron のものに有意に近かった。従って、FRNN でかつ滑らかな学習データを用いれば神経活動の再現がうまく出来ると示唆される。

### 参考文献

- [1] K. Doya, A. I. Silverston, and P. F. Rowat. (1994) A Hodgkin-Huxley type neuron model that learns slow non-spike oscillation. *Advances in Neural Information Processing Systems* **6**, 566-573
- [2] J. L. Elman. (1990) Finding structure in time. *Cognitive Science* **14**, 179-211.
- [3] A. Waibel, T. Hanazawa, G. Hinton, K. Shikano, and K. J. Lang. (1989) Phoneme Recognition Using Time-Delay Neural Networks. *IEEE Transactions on Acoustics, Speech, and Signal Processing* **37**, 3, 328-339.
- [4] A. Hodgkin and A. Huxley. (1952) A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology* **117**, 500-544
- [5] D.E.Rumelhart, G.E. Hinton, and R.J.Williams. (1986) Learning internal representations by error propagation. *Parallel distributed processing*, **1**, Chap.8, MIT Press.