

MEG における機械学習による機能的ネットワークに関する検討 Study on Functional Networks by Machine Learning in MEG

前田 泰希[†] 塚原 彰彦[†] 田中 慶太[†]
Taiki Maeda Akihiko Tsukahara Keita Tanaka

1. はじめに

脳磁図(Magnetoencephalography, MEG)は、大脳皮質ニューロンの神経活動によって生じる微小な磁場をミリ秒オーダーで記録する時間分解能と、信号の発生源を数ミリオーダーで推定する空間分解能を有する非侵襲な脳計測技術であり、視覚・体性感覚・聴覚・運動などに関する様々な脳機能解析において応用されている[1].

MEG の優れた時空間分解能は、グラフ理論と併せて、アルツハイマー病やてんかんにおける脳領域間の構造的・機能的ネットワークの解析に利用されている[2]. しかし、グラフ理論を用いたアプローチは、同じ母集団を対象とした研究であっても、重み付きグラフを構築するためのいくつかの相違があるために、結果として得られるネットワーク構造が大きく異なることがあり、クラスタリング係数の変化については、その増減に関して統一性がないことが報告されている[3].

本研究では、グラフの重みが時系列データの特徴量から得られる予測された MEG 信号との類似度によって算出されることを前提に、信号を離散フーリエ変換した複素ベクトルを入力とする複素ニューラルネットワークによって、特徴量を効率的に獲得する手法を提案する. 提案手法の比較対象として、ニューラルネットワークの構成と学習するパラメータの総数を変更せずに、入力を実数ベクトルに変更したネットワークを構成し、複素ニューラルネットワークの有効性を評価した.

2. 実験方法

全ての実験において、乱数生成に用いるシード値は、全て同じ値を使用した.

2.1 疑似信号の作成

図 1 に、乱数によって作成した疑似 MEG 信号と刺激(Stimulation, STIM) 信号の一例を示した. 作成した信号は、サンプリング周波数 600 Hz, 実際の MEG 信号の定数倍を想定した.

信号 STIM のトリガが立ち上がる時刻の前後 250 ms に相当するサンプル 300 個を一区分とする. s 個目の区分における信号 $MEG_1(s)$ が反応を示す条件は、 $s-1$ 個目の区分における信号 $MEG_1(s-1)$ と $MEG_2(s-1)$ の反応有無(1/0)を入力とした、XNOR の出力値に従った. また、 s 個目の区分における信号 $MEG_2(s)$ が反応を示す条件は、 s 個目の区分における信号 $STIM_1(s)$ と $STIM_2(s)$ のトリガ有無(1/0)を入力とした、XOR の出力値に従った.

2.2 ニューラルネットワークの構成

図 2 に、ニューラルネットワークの構成図を示した. こ




図 1 疑似 MEG 信号と刺激信号の例

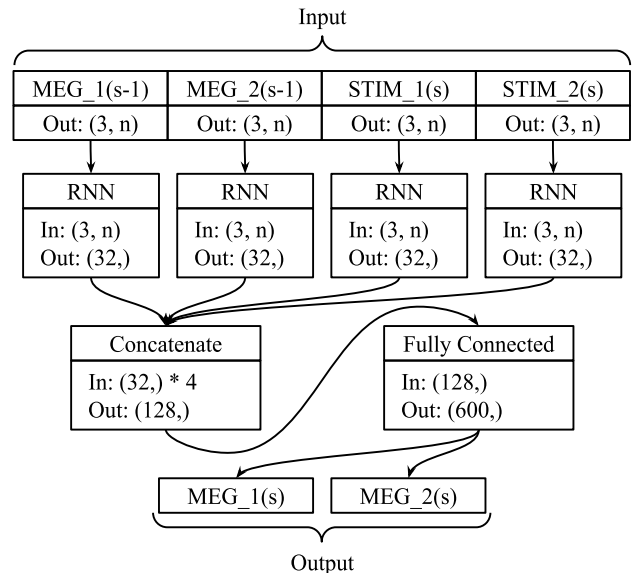


図 2 ニューラルネットワークの構成図

のとき n は、 s 個目または $s-1$ 個目の区分から得られる実数ベクトルまたは複素ベクトルの次元数とする.

すべての RNN (Recurrent Neural Network) 層について、隠れ状態の数は 1 つ、バイアスを使用し、出力は最後のチャネルのみとした. また、活性化関数は双曲線正接関数とした. ニューラルネットワークに入力するデータは、 $s-1$ 個目の区分における信号 $MEG_1(s-1)$ と $MEG_2(s-1)$, s 個目

[†] 東京電機大学 Tokyo Denki University

の区分における信号 STIM_1(s)と STIM_2(s)の計 4 種類とし、また、出力データは s 個目の区分における信号 MEG_1(s)と MEG_2(s)のそれぞれ 300 個のサンプルを予測するように、600 次元のベクトルとした。

2.3 訓練方法

入力データは、図 2 のパラメータとして与えられている n を 300, 150, 75 に設定した 3 種類を用意し、それぞれに対してニューラルネットワークを訓練した。n=150, 75 の実数ベクトルが入力される場合、300 のサンプル数を持つ一区分から、最初の値を必ず含むように、等間隔に実数値を選択した。また、n=150, 75 の複素ベクトルが入力される場合、離散フーリエ変換によって得られた複素ベクトルの低周波成分から順に n 個の複素数を選択した。

損失関数では、ニューラルネットワークの出力である MEG_1(s)と MEG_2(s)のそれぞれについて、教師データとの相互相関係数を算出し、相互相関係数に対する教師データを 1 として 2 つの平均二乗誤差を得たのち、誤差の平均値をとった。

重みの最適化手法には、Adam を使用し、10 バッチ 100 エポックで訓練を行った。

3. 実験結果

図 3 に、入力信号を実数ベクトルにしたときの訓練用データセットに対する相互相関係数の推移を示した。5 から 10 エポックにかけて、一時的に曲線がやや緩やかになった。80 エポック以降の相互相関係数は 0.95 近傍に収束した。

図 4 に、入力信号を実数ベクトルにしたときの評価用データセットに対する相互相関係数の推移を示した。5 から 45 エポックにかけて、正の相互相関係数が 0.12 から 0.17 程度低下し、100 エポックまで上昇傾向にあったが、収束は確認されなかった。訓練を通して、各エポックにおける相互相関係数の分散の平均値は 54.9×10^{-5} となった。また、図 3 の訓練用データセットに対する相互相関係数の推移と比較すると、評価用データセットに対する相互相関係数の推移は、5 から 45 エポックにかけて相反する。このことから、過学習が起きていることが示された。

図 5 に、入力信号を複素ベクトルにしたときの評価用データセットに対する相互相関係数の推移を示した。10 エポック近傍で収束し、100 エポックにかけて相互相関係数は緩やかな上昇を続けた。訓練を通して、各エポックにおける相互相関係数の分散の平均値は 8.35×10^{-5} となった。

4. 考察

入力信号を複素ベクトルにしたときの評価用データセットに対する相互相関係数に関して、その分散の平均値は入力信号を実数ベクトルにしたときと比較して、15.2 % 小さく、また、過学習が起きていないことから、複素ニューラルネットワークは、入力信号の形状特徴を捉えていると推察される。

5. おわりに

本稿では、グラフの重みが時系列データの特徴量から得られる予測された MEG 信号との類似度によって算出されることを前提に、信号を離散フーリエ変換した複素ベクトルを入力とする複素ニューラルネットワークによって、特徴量を効率的に獲得する手法を提案した。実験結果から、




図 3 実数ベクトルの訓練用データに対する相互相関係数の推移

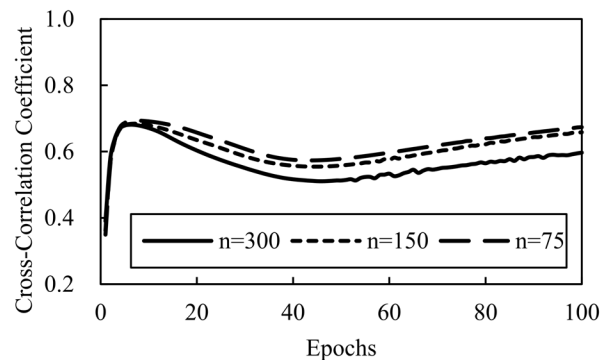


図 4 実数ベクトルの評価用データに対する相互相関係数の推移




図 5 複素ベクトルの評価用データに対する相互相関係数の推移

複素ニューラルネットワークによって安定した訓練を行うことが可能であることが示唆された。

参考文献

- [1] 萩原鋼一, 飛松省三, “脳磁図の基礎と臨床応用”, 九州大学情報リポジトリ, 福岡醫學雑誌, 第 101 巻, 第 7 号, pp. 135-141, (2010).
- [2] F. Bartolomei, G. Bettus, C.J. Stam, M. Guye, “Interictal network properties in mesial temporal lobe epilepsy: A graph theoretical study from intracerebral recordings, Clinical Neurophysiology”, ISSN 1388-2457, Vol. 124, Issue 12, pp. 2345-2353, (2013).
- [3] Haneef, Zulfi; Chiang, Sharon, “Clinical correlates of graph theory findings in temporal lobe epilepsy”, ISSN 1059-1311, Vol. 23, Issue 10, pp. 809-818, (2014).