Deep Decoder を用いた聴覚誘発反応の電流源推定* ☆山名莉央, 矢野肇, 高島遼一, 滝口哲也 (神戸大), 中川誠司 (千葉大)

1 はじめに

脳磁図(magnetoencephalography:MEG)と 脳波(electroencephalography:EEG)は時間分 解能に優れた非侵襲な脳機能計測手法であり、こ れらの発生源は脳内の電流でモデル化される. MEG・EEGの脳内電流源の推定は、脳機能の 解明や、脳疾患の診断に応用されている.しかし ながら、脳内の電流分布の推定は、電流源のパ ラメータ数に対して MEG / EEG センサの数が 少ない劣決定問題であるため、本質的に困難で ある.

電流源推定の代表的な手法である Minimum Norm Estimation (MNE) [1] や Standardized Low Resolution Brain Electro-magnetic Tomography (sLORETA)[2] では、明示的に電流源の事 前部分を与えることでこの問題を解決する. し かしながら、実際の電流源の事前分布を得るこ とは困難で、誤った事前分布に基づく推定では大 きな誤差を生じる可能性もある.

我々は、畳み込み構造を持つ未学習の深いネッ トワークによって表現される暗黙的な事前分布 (Deep Prior) に着目し、これを用いた MEG・ EEG の逆問題の解法を提案した [3]. シミュレー ションデータを用いて行った電流源推定の結果か ら、畳み込みネットワークが電流源の事前分布 を表現可能であることが示された一方で、Deep Prior 用いて推定された解は、ネットワークの初 期値や学習回数によって大きく変化し、安定しな いことが明らかとなった.

本研究では, Deep Prior による電流源推定の 安定性を向上させるため, Deep Decoder [4] を 用いた手法を提案する. Deep Decoder は, 畳み 込み構造を持たないことで, Deep Prior よりパ ラメータ数を削減し, ノイズへの過適合を避ける ことができる. また, Deep Decoder は, 画像分 野の逆問題において, 出力画像の次元数よりも少 ないパラメータ数であるにもかかわらず, Deep Prior と同等の性能を示した. Deep Decoder を 電流源推定に用いることで, Deep Prior よりも 最適化パラメータを削減し, より安定した解が 得られることが期待される.MEGのシミュレー ションデータを用いて,Deep Decoder による電 流源の事前分布の獲得の可否を検証した.また, 提案手法の推定結果を従来手法と比較した.

2 電流源推定の定式化

2.1 MEG / EEG の順問題

脳内の活動源が与えられたときに、センサ観測 される MEG・EEG を推定する問題は順問題で ある.本稿では、脳内の領域がメッシュ化され、 活動源は各メッシュ点上に配置された微小電流で 表されるものとする.微小電流はベクトル量であ り、N個のメッシュ点における微小電流のx、y、 z 成分を並べたベクトルを $q \in \mathbb{R}^{3N}$ と表す.ま た、頭外に設値された M 個の MEG / EEG セ ンサでの磁場/電位を $q \in \mathbb{R}^{M}$ とすると、MEG / EEG の順問題は以下のように定式化される.

$$b = Lq \tag{1}$$

ここで, Lはリードフィールド行列と呼ばれ, メッ シュ点に置いた電流源の1成分の大きさが1の ときに測定される各センサにおける出力を並べ たベクトルである. Lはメッシュ点とセンサの位 置, 頭内の導電率から求めることができ, 本研究 では既知とする.

2.2 MEG / EEG の順問題

一般的に, 脳内をメッシュ化した場合, 電流源 のパラメータ数は, センサ数に対して非常に大 きくなる. したがって, 式(1)においてbが与え られた場合でも, qを一意に求めることはできな い. MNE や sLORETA では, qに制約を与え, 式(1)の順問題と観測値の間の誤差を最小化する ことでqを一意に求める. qの推定値 \hat{q} は以下で 与えられる.

$$\hat{q} = \arg\min_{q} \left[(b_{obs} - Lq)^T C^{-1} (b_{obs} - Lq) \right]^T$$

$$+ \lambda q^{T} S^{-1} q] \tag{2}$$

$$=SL^{T}(LSL^{T}+C)^{-1}b\tag{3}$$

^{*}Current source estimation of auditory evoked response using deep decoder, by YAMANA, Rio, YANO, Hajime, TAKASHIMA, Ryoichi, TAKIGUCHI, Tetsuya (Kobe Univ.) and NAKAGAWA, Seiji (Chiba Univ.).

ここで、Sは電流源のパラメータの共分散行列、 Cはセンサにおけるノイズの共分散行列、 λ は制 約の強さを制御する定数である。qへの制約は、 qの事前分布に平均0、共分散行列Sの正規分布 を仮定することに対応している。しかし、実際 の電流源の確率分布は明らかではなく、事前分布 を正規分布と仮定することは必ずしも適切では ない。

3 Deep Decoder

Deep Decoder は Deep Image Prior を応用し て考えられている。Deep Image Prior を用いた 画像修復や超解像,ノイズ除去は以下の式で表 すことができる。

$$\hat{x} = \arg\min_{x} E(x; x_0) + R(x) \tag{4}$$

x は生成画像, x₀ は元画像(修復したい画像)で あり, R は画像が自然であるかの指標(正則化), E は生成画像と元画像と誤差である. R は事前 分布として与える必要があるが,何をもって画像 が自然であるかが難しく, R を設定することは 困難であった. そこで Deep Decoder では R を ネットワークが捉える事前分布に置き換える. こ れを式で表すと以下のようになる.

$$\hat{\theta} = \arg\min_{\theta} E(f_{\theta}(z); x_0) \tag{5}$$

$$\hat{x} = f_{\hat{\theta}}(z) \tag{6}$$

 θ はネットワークのパラメータ, z はネットワー クの入力画像(ノイズ画像)である. また Deep Image Prior において f_{θ} は Unet のようなダウン サンプリングモジュール, アップサンプリングモ ジュール,スキップモジュールから構成される. 誤差項 E には二乗誤差を用い,生成画像 x* を元 画像 x₀ に近づけるようにθを更新する. ネット ワークの出力がノイズの重畳した画像 x0 にフィッ トするまでに、ノイズの少ない自然な画像が生 成される. しかし Deep Image Prior のパラメー タ数は非常に多い、そこで畳み込みを行わない ネットワークに変えることによってパラメータ数 を減らす Deep Decoder が考えられた. パラメー タ数が小さいことことにより自由度が減りノイ ズの学習が遅く、また出力の次元数よりパラメー タを少なくすることができる.





4 Deep Decoder を用いた電流源推定

従来の MEG・EEG 逆問題における電流源の 事前分布の代わりに,電流源のパラメータを生 成するニューラルネットワークを用いた. $z \in \lambda$ 力として電流源のパラメータを出力する生成ネッ トワークを q_{ϕ} とする. ここで, ϕ はネットワー クのパラメータである. Deep Decoder を用いた MEG・EEG 逆問題の解 \hat{q}_{dp} は次の式で表される.

$$\hat{\phi} = \arg\min_{\phi} (b_{obs} - Lq_{\phi}(z))^T C^{-1} (b_{obs} - Lq_{\phi}(z))$$

$$\hat{q}_{dp} = q_{\hat{\phi}}(z) \tag{8}$$

ここで、 E_C は誤差を平均 0、共分散行列 C を仮定したときの誤差関数である.

本研究では、3 次元の直交格子による脳内領 域のメッシュ化を仮定した.また入力 z は各要 素が互いに独立な標準正規分布からサンプルさ れたベクトルとした.ネットワーク q_{ϕ} は Deep Decoder と同様な構造のネットワーク σ_{ϕ} は Deep Decoder と同様な構造のネットワークである.最 終層の出力から、脳の領域の格子点の配置と対 応させ、チャンネル数は電流源のx,y,z成分に 対応させて3とした.最終層の出力から、脳の 領域内の格子点に対応する要素のみを取り出し、 ネットワーク q_{ϕ} の最終的な出力とした.今回用 いたネットワーク構造の概要を Fig. 1 に示す.

5 評価実験

提案手法を用いて、シミュレーションデータに 対して電流源推定を行った.また、提案手法の推 定結果を既存手法の MNE、sLORETA と Deep Prior を用いた手法 [3] と比較した.

シミュレーションデータの計測条件は MNE-Python[6] のサンプルデータ [6] を用いた. この シミュレーションデータは 204 個の平面型グラ ジオメーターと 102 個のマグネトメーターで構 成された 306 チャンネルの MEG システムで計 測された.

提案手法および Deep Prior のネットワークの 入力の次元数は 128 とした.提案手法の実装,お よび既存手法による電流源推定は MNE-Python を用いた.

シミュレーションデータは刺激のオンセット後 0.1sにおいて、50nAmのピーク強度を持つ電流 源を右半球の1次聴覚野付近および1次体性感 覚野付近に配置し、MEG を合成した.電流源の 配置に必要な脳の核磁気共鳴画像は、データセッ トに収録された被験者のものを用いた。合成し た MEG 波形に 80 回の加算平均に相当するノイ ズを重畳させ、加算平均波形を合成した、ノイ ズは多次元正規分布に従い、その共分散行列に は、データセットに収録された計測ノイズから 計算したものを用いた. 合成した加算平均波形 の信号対雑音比のピークは 21.6dB であった.ま た,信号のピークとなる刺激のオンセット後0.1s における電流分布を推定した。本実験での Deep Prior と Deep Decoder のパラメータ数はそれぞ れ2394285,84227である.

6 結果と考察

1次聴覚野付近に電流源を配置した時の MEG から推定した電流源の強度分布を Fig. 2 に手法 ごとに示す. 左から順に推定した電流源の強度が 最も高い位置の y 座標, x 座標, z 座標を通る xz, yz, xy 平面上の電流源の分布である. 各画像の 青い点は真の電流源の位置を示している. また, 推定された電流の強度が最大となる点を電流源 の位置の推定値とし,真の電流源の位置とのユー クリッド距離を位置の推定誤差とした. 各手法の 位置の推定誤差を Table 1 に示す.

Fig. 2より,いずれの手法でも電流源を配置した右半球に電流が推定されていることが分かる.

MNE は他の手法と比べ電流源が浅く推定され ており,かつ推定誤差が最も大きかった.MNE が電流源を浅い位置に推定することは知られて おり [7],この結果は電流源の事前分布の分散を 重みづけることで緩和することができる [7].

sLORETA では他の手法と比べ電流が推定される範囲が広く、またより深い位置にも推定されている。sLORETA は、推定された電流分布を電流源の空間におけるノイズの分散で正規化する。このようなノイズ正規化によって深い位置

の電流源の推定が可能になるとされている [8].

Deep Prior および Deep Decoder を用いた電 流源推定は、他の手法と異なり、明示的に事前分 布を与えることなくセンサ上の誤差の最小化だ けで真の電流源の周辺に電流を推定した.しかし Deep Decoder による電流源の位置の推定誤差は Deep Prior と比べ2倍以上であった. ネットワー クのパラメータ数の削減によって、ネットワーク が表現可能な電流分布の空間が狭まったために、 真の電流源の位置に大きな電流を推定できなかっ た可能性が考えられる。また、MEG・EEGの逆 問題における Deep Decoder の最適化は, Deep Decoderの出力となっている電流源のパラメータ 空間上での誤差ではなく、そこからリードフィー ルド行列 L によって写像された,より低次元の センサ空間上での誤差を最小化している。この ため, Deep Decoder のパラメータ数は畳み込み 構造を持つ Deep Prior よりも少ないものの、セ ンサ数に対しては依然として非常に大きいまま である. したがって, Deep Decoder による画像 の逆問題でみられるノイズに適合しにくいとい う特性は、MEG・EEGの逆問題では十分に得ら れない可能性がある。

Table 1Localization error of a single dipole inthe primary auditory cortex

Method	Localization Error [mm]
MNE	112.9
sLORETA	2.5
Deep Prior	7.3
Deep Decoder	18.1

次に,1次体性感覚野付近に電流源を配置した ときの各手法の電流源分布をFig.3に示す.ま た各手法の位置の推定誤差をTable2に示す.

Fig. 2よりいずれの手法でも1次体性感覚野 付近に推定できており,ほとんどの手法におい て1次聴覚野に電流源を配置した時よりも推定 誤差が小さくなっていることが分かる.これは, 1次体性感覚野の電流源の位置が1次聴覚野と比 べて浅く,推定が容易だったためと考えられる. また,それぞれの手法によって推定された電流分 布のパターンは,1次聴覚野に電流源を配置した 時と同様の傾向が見られる.

MNE



Fig. 2 Current source densities estimated from simulated MEG data in the primary auditory cortex

7 おわりに

本研究では、畳み込み構造を持たず、パラメー タ数が少ない Deep Decoder を用いて MNE・EEG の逆問題を解く手法を提案した。シミュレーショ ンデータによる電流源の推定結果から、畳み込 み構造を持たないネットワークでも電流源の事 前分布を表現可能であることが示された。その 一方で、Deep Image Prior の推定結果と比較し て、Deep Decoder による精度の向上は見られな かった。電流源推定に適したネットワーク構造の さらなる検討が必要である。

Table 2Localization error of a single dipole inthe primary somatosensory cortex

Method	Localization Error [mm]
MNE	11.4
SLORETA	4.6
Deep Prior	2.8
Deep Decoder	4.6



Fig. 3 Current source densities estimated from simulated MEG data in the primary somatosensory cortex

参考文献

- M. Hamalainen et al., Technical Report TKK-F-A559, Helsinki University of Technology, 1984.
- [2] R. Pascual-Marqui et al., Methods and Findings in Experimental and Clinical Pharmacology, 24(D):5-12, 2002.
- [3] 山名ら, 音講論(春), 679-682, 2021.
- [4] R. Heckel et al., arXiv preprint arXiv:1810.03982, 2018.
- [5] D. Ulyanov et al., International Journal of Computer Vision, 128:1867?1888, 2020
- [6] A. Gramfort et al., Frontiers in Neuroscience, vol. 7, 267, 2013.
- [7] R. Grech et al., Journal of NeuroEngineering and Rehabilitation, Article number: 25,2008.
- [8] O. Hauk et al., Neuroimage, 54(3),2011