Deep Prior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。脳内の電流源の推定は、脳機能の局在性 の解明や、脳疾患の診断に応用される。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 MNE (minimum norm estimation) [1]や sLORETA (standardized low resolution brain electromagnetic tomography) [2]では、明示的に電流源の 事前分布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は不 明であり、明示的に事前分布を指定すること は必ずしも適切ではない。

近年、畳み込み構造を持つ深いニューラル ネットワークが、未学習であっても自然な画 像の事前分布の役割を果たすことが示されて いる[3]。これは Deep Image Prior と呼ばれ、 画像修復、超解像、ノイズ除去といった画像 分野の逆問題に有効であることが示されてい る。また、このような未学習の深いネットワ ークによる事前分布 (Deep Prior) は、画像か らの3 次元の形状復元[4]、構造最適化[5]、音 源分離[6]など、様々な分野の逆問題にも応用 されてきている。

本研究では、Deep Prior を用いた MEG・EEG の逆問題の解法を提案した。脳内の電流源は 広がりを持って分布していると考えられる。 Deep Image Prior における畳み込み構造は電 流源のパラメータの局所的な広がりを表現す ることが期待される。MEG のシミュレーショ ンデータと実際の聴覚誘発脳磁界を用いて、 ランダムに初期化された畳み込みネットワー クが電流源の事前分布を表現可能なことを検 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 で観測される 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、頭外に設置さ れた M 個の MEG/EEG センサでの磁場/電 位を $b \in \mathbb{R}^{M}$ 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のおける出 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 の逆問題

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 が与えられたとき、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。

$$\hat{q} = RL^T (LRL^T + C)^{-1}b \tag{2}$$

ここで、R 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である。qへの制約は、qの事前分布に平均0、

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

共分散行列 R 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、事前分布に正規分布を仮定することは必ずしも適切ではない。

3 Deep Image Prior

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。

$$x^* = \min_{x} E(x; x_0) + R(x)$$
(3)

x は生成画像、 x_0 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 Image Prior では畳み込みからなるネットワー クが自然な画像を生成するための事前分布の 役割を果たしているという考えから、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。

$$\theta^* = \operatorname*{argmin}_{\theta} E(f_{\theta}(z); x_0) \tag{4}$$

$$x^* = f_{\theta^*}(z) \tag{5}$$

 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 f_{θ} はネットワークであり、U-net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 成されている。誤差項*E*には二乗誤差を用い、 生成画像 x^* を元画像 x_0 に近づけるように θ を 更新する。畳み込み構造は自然画像の方が特 徴を表現しやすいためネットワークの出力が ノイズの重畳した画像 x_0 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 [3]。

4 Deep Prior を用いた電流源推定

畳み込みネットワークが広がった電流源の 事前分布を表現できるという仮説に基づき、 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 生成する畳み込みネットワークを用いた。z を入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 Prior を用いた MEG・EEG 逆問題の解*q*_{dp}は次の式



Fig. 1 A diagram of the proposed method

で表される。

$$\phi^* = \underset{\phi}{\operatorname{argmin}} E_C(Lq_{\phi}(z); b) \tag{6}$$

$$\hat{q}_{dp} = q_{\phi^*}(z) \tag{7}$$

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 3 次元の転置畳み込み層と活性化関数 ReLU からなる 5 層のネットワークであり、 最終層は転置畳み込み層のみとした。最終層 の出力の各要素は格子点の配置と対応させ、 チャネル数は電流源の 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 と実際の MEG 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 と比較した。

実際の MEG データとして、Brainstorm auditory tutorial dataset [7]を用いた。また、シミ ュレーションデータの測定条件もこのデータ セットのものを用いた。データセットの MEG データは CTF 社製の全頭型脳磁界計測シス テムの計 274 個の軸型グラジオメーターで計 測された。

提案手法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 [8]を用い て行った。

5.1 シミュレーションデータを用いた実験 強度が 0.1 s で 50 nAm のピークを持つよう 提案手法



Fig. 2 Current source densities estimated from simulated MEG data

Table 1 Comparison of error from the true value

Method	Localization error[mm]
MNE	49.3
sLORETA	111.3
Deep Prior	4.3

な電流源を1次聴覚野付近(右上側頭回)の 1点に配置し、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 26.2dB であった。また、信号がピークとなる 0.1 s における電流分布を推定した。提案手法 の反復回数は 100 回とした。

5.2 実際のデータを用いた実験

データセットに収録されている MEG は、 1人の被験者に 440 Hz のビープ音を 200 回、 554.4 Hz のビープ音 40 回をランダムに呈示 したときの聴覚誘発脳磁界である。本研究で は 440 Hz のビープ音を呈示した時の MEG の うち 80 回の試行を用いて加算平均波形を計 算した。また、活動のピークが見られる 0.1 s における電流分布を推定した。また、提案法 提案手法



Fig. 3 Current source densities estimated from an auditory evoked field



Fig. 4 Errors during optimization of q_{ϕ} , and estimated current density using the proposed method after 10, 100, and 500 iterations.

の反復回数を 50 回、100 回、500 回とした時 の電流分布を比較した。

6 結果と考察

6.1 シミュレーションデータを用いた実験

真の電流源の座標の周辺で推定された電流 分布を Fig.2 に手法ごとに示す。左から順に、 真の電流源の位置の y 座標、x 座標、z 座標に おける xz、yz、xy 平面上の電流源の分布であ 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 わかる。また、提案手法と sLORETA は真の 電流源の座標付近で、大きな電流が推定され ていることが分かる。しかしながら、提案法 による電流源の位置の推定誤差は sLORETA のと比べ約 10 倍となった。

MNE は他の手法と比べ電流源が浅く推定 されており、かつ位置の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 ことはよく知られており[9]、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[9]。

sLORETA 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[10]。

Deep Prior 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。このことは、畳 み込み構造を持つ深い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を示唆して いる。

6.2 実際のデータを用いた実験

実際の聴覚誘発脳磁界から推定した電流分 布を Fig. 3 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大となる位置の y 座標、x 座標、z 座標における xz、yz、xy 平 面上の電流分布である。

Fig.3 より、いずれの手法でも左聴覚野周辺 に高い強度の電流源が推定されていることが わかる。また、推定された電流源にはシミュ レーションデータを用いた時と同様の傾向が 見られる。これらの結果は、提案手法は実際 の MEG データに対しても適用可能であるこ とを示している。

Fig. 4 に反復回数 500 回までの提案手法の 誤差関数の推移と、反復回数が 50 回、100 回、 500 回の時の推定された電流分布を示す。Fig. 4 より、反復回数が増えるにつれてより広い 範囲に電流源が推定されていく傾向があるこ とがわかる。これは、誤差が小さくなるにつ れてネットワークが観測信号に含まれるノイ ズを表現するようになることを示している。 また、定期的な誤差の上昇も観測されている。Deep Image Prior においても同様の現象が 報告されており、誤差が大きく上昇するとき、 生成される画像が劣化するということが報告 されている。また、この現象は Adam による 最適化で発生するという報告もある[3]。いず れにしても、Deep Prior を用いて良い電流源 の推定結果を得るためには適切な反復回数で 計算を打ち切る必要がある。

7 おわりに

本研究では、畳み込み構造からなる深いニ ューラルネットワークを明示的な事前分布の 代わりに用いて MEG・EEG の逆問題の解く 手法を提案した。シミュレーションデータと 実際の聴覚誘発脳磁界から提案手法を用いて 電流源を推定した結果、畳み込みのネットワ 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。今後は、電流源の推定の精度 をより高めるため、より良い事前分布となる ネットワーク構造や、ネットワークのパラメ ータの最適化方法を検討していく必要がある。

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] D. Ulyanov *et al.*, International Journal of Computer Vision, 128:1867–1888, 2020
- [4] M. Gadelha et al., ICCV, pp.22-30、2019.
- [5] S. Hoyer *et al.*, arXiv:1909.04240, 2019.
- [6] V. Narayanaswamy *et al.*, arXiv:2005.13769, 2020.
- [7] E. Bock *et al.*, Computational Intelligence and Neuroscience, vol. 2011, 13 pages, 2011.
- [8] A. Gramfort *et al.*, Frontiers in Neuroscience, vol. 7, 267, 2013.
- [9] R. Grech *et al.*, Journal of NeuroEngineering and Rehabilitation, Article number: 25,2008.
- [10] O. Hauk et al., Neuroimage, 54(3),2011