

Deep Prior を用いた脳波からの Forward model と電流源の同時推定*

☆北条直樹, 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. 近年, 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, 脳内の電流分布の推定は, 電流源の総パラメータ数に対して MEG・EEG のセンサ数が少ない劣決定問題であるため, 本質的に困難である. そのため, 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 Electromagnetic Tomography (sLORETA)[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の解決を図っている. しかし, 電流源の事前分布を実際には得ることは困難で, 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.

そこで我々は, 未学習の畳み込み構造を持つ深いネットワークによる事前分布 (Deep Prior) を用いて MEG の逆問題の解法を提案し, 畳み込みネットワーク (Convolutional Neural Network : CNN) が電流源の事前分布を表現可能であることを示した [3, 4]. しかし, これらの手法は, 測定時間が長く, 被験者の負担も大きい核磁気共鳴画像 (Magnetic Resonance Imaging : MRI) や大規模装置が必要な MEG の測定を必要とする. このことから, より簡単に測定ができる EEG のみで電流源を推定できることが望ましい.

そこで本研究では, Deep Prior を用いて, EEG のみから脳内の電流分布を推定する手法を提案する. 提案手法では, 電流源と Forward model を推定する 2 つの CNN を用いることで, 被験者本人の MRI を用いずに電流源を推定する. このとき, リードフィールド行列はあらかじめ複数被験者の平均的な MRI データから算出したものを使用した. 脳内に単一電流源を仮定して人工的に作成した EEG データを用いて, 平均的なものと被験者本人のもの, それぞれの MRI データを用いた場合の提案手法, および平均的な MRI

データを用いた場合の既存手法の電流源推定位置の比較を行った.

2 電流源の定式化

2.1 MEG・EEG の順問題

脳内に活動源が与えられた時に, センサで観測される MEG・EEG を推定する問題を MEG・EEG の順問題という. 本稿では, シミュレーション実験のため, 脳内の領域をメッシュ化し, 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 $\mathbf{q} \in \mathbb{R}^{3N}$ と表す. また, 頭皮に設置された M 個の MEG・EEG センサで観測される磁場・電位を $\mathbf{v} \in \mathbb{R}^M$ とすると, MEG・EEG の順問題は以下のように定式化される.

$$\mathbf{v} = \mathbf{L}\mathbf{q} \quad (1)$$

ここで, \mathbf{L} はリードフィールド行列と呼ばれる. リードフィールド行列 \mathbf{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, MRI の測定が必要である. そこで本研究では, CNN を用いてリードフィールド行列 \mathbf{L} も推定する.

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多くなる. そのため, 式 (1) の \mathbf{v} においてセンサの観測値 \mathbf{v}_{obs} が与えられた場合でも, 電流源 \mathbf{q} を一意に求めることはできない. MNE や sLORETA では, \mathbf{q} に制約を与え, 式 (1) の順問題と観測値 \mathbf{v}_{obs} の間の誤差を最小化することで, \mathbf{q} を一意に求めている. \mathbf{q} の推定値 $\hat{\mathbf{q}}$ は以下で与えられる.

$$\hat{\mathbf{q}} = \underset{\mathbf{q}}{\operatorname{argmin}} E_C(\mathbf{L}\mathbf{q}; \mathbf{v}_{obs}) + \lambda \mathbf{q}^\top \mathbf{S}^{-1} \mathbf{q} \quad (2)$$

$$= \mathbf{S}\mathbf{L}^\top (\mathbf{L}\mathbf{S}\mathbf{L}^\top + \lambda \mathbf{C})^{-1} \mathbf{v} \quad (3)$$

ここで, $E_C(\mathbf{x}; \mathbf{y})$ は, 誤差ベクトル $\mathbf{y} - \mathbf{x}$ の分散が \mathbf{C} の時の誤差関数で, $E_C(\mathbf{x}; \mathbf{y}) = (\mathbf{y} -$

* Simultaneous estimation of forward model and current source from EEG using Deep Prior. by HÔJÔ, Naoki, YANO, Hajime, TAKASHIMA, Ryôichi, TAKIGUCHI, Tetsuya (Kobe Univ.) and NAKAGAWA, Seiji (Chiba Univ.).

$x)^\top C^{-1}(y - x)$ である。また、 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である。 q への制約は、 q の事前分布に平均 $\mathbf{0}$ 、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 Prior を用いた Forward model と電流源の同時推定

Deep Prior を用いた Forward model と電流源の同時推定の概要を Fig. 1 に示す。Deep Prior を用いた電流源推定では、電流源 q を潜在変数 z を入力としたニューラルネットワーク $f_\phi(z)$ により生成し、観測誤差を最小化するようなネットワークのパラメータ ϕ を推定する。本研究では、式(2)の q を電流源推定ネットワークの出力 $f_\phi(z_q)$ に、 L をリードフィールド行列推定ネットワークの出力 $g_\phi(z_l)$ に置き換える。Deep Prior による MEG・EEG 逆問題の解 \hat{q} は、次式で表される。

$$\hat{\phi} = \underset{\phi}{\operatorname{argmin}} \|v_{obs} - g_\phi(z_l)f_\phi(z_q)\|_2^2 \quad (4)$$

$$\hat{L} = g_{\hat{\phi}}(z_l) \quad (5)$$

$$\hat{q} = f_{\hat{\phi}}(z_q) \quad (6)$$

ここで、潜在変数 z_l, z_q の各要素は互いに独立な標準正規分布からサンプルする。

本研究では、脳内の領域を3次元の直交格子状にメッシュ化して電流源を配置した。ネットワーク $f_{\hat{\phi}}(z_q), g_{\hat{\phi}}(z_l)$ は同じ構造で、3次元畳み込み層とバッチ正規化層、アップサンプリング層を積み重ねた U-Net 構造または Decoder 構造を用いた。また、U-Net と Decoder は、それぞれ活性化関数を用いた非線形構造と、活性化関数を用いない線形構造を比較した。

リードフィールド行列推定ネットワーク $g_{\hat{\phi}}(z_l)$ は、FreeSurfer の平均的な被験者の MRI データ [5] から求めたリードフィールド行列 L_a を用いて事前学習を行った。

Forward model と電流源の同時推定では、リードフィールド行列推定ネットワークの出力 $g_{\hat{\phi}}(z_l)$ がリードフィールド行列のから大きく変化することを防ぐために、バッチ正規化層のみの更新とした。また、推定した電流源のばらつきを防ぐために、電流源推定ネットワーク $f_{\hat{\phi}}(z_q)$ の最終層

に、最大値の 50 % を閾値 T とする次式の hard shrinkage 関数 $H(x)$ を用いた。

$$H(x) = \begin{cases} x & (|x| \geq T) \\ 0 & (|x| < T) \end{cases} \quad (7)$$

Hard shrinkage 関数の出力から、脳の領域内の格子点に対応する要素のみを取り出し、電流源推定ネットワーク $f_{\hat{\phi}}(z_q)$ の最終的な出力として電流源を推定した。

4 評価実験

シミュレーション EEG データに対して、提案手法を用いて電流源推定を行い、推定結果を既存手法の sLORETA と比較した。EEG データを作成する際に用いた脳波の計測環境は、MNE-Python のサンプルデータ [6] に収録されているものを用いた。このサンプルデータの EEG 計測システムは、合計 60 個のセンサを持つ。

まず、脳内の活動源として、50 nAm のピーク強度を持つような電流源を、右半球の 1 次聴覚野、および 1 次体性感覚野の中心に配置し、EEG データを合成した。次に、合成した EEG 波形に、信号対雑音比 (Signal-to-Noise Ratio) が 20, 5, 2, 0 dB となるようにノイズを重畳させた。重畳させたノイズは多次元正規分布に従い、平均を $\mathbf{0}$ 、分散共分散行列 C をデータセットに収録された計測ノイズから計算した値とした。

提案手法で用いるネットワークとして、線形・非線形 U-Net 構造、線形・非線形 Decoder 構造を比較した。本実験で用いた U-Net 構造と Decoder 構造のパラメータ数はそれぞれ 442,024 と 57,716 であった。電流源推定の学習回数は 100 回とした。ここで、ネットワークの初期値依存性やパラメータのランダム性を考慮するために、電流源推定を 20 回試行し、20 回推定した電流源の分布の平均を推定結果とした。

提案手法および既存手法による電流源推定の実装には MNE-Python を用いた。各手法で推定された電流の強度分布が最大となる位置を、各手法の単一電流源の推定位置とした。推定位置と真の位置のユークリッド距離を推定誤差とし、それぞれの手法で 10 回推定した時の平均値を評価値とした。平均的な MRI データを用いた場合と被験者本人の MRI データを用いた場合の提案手法、および平均的な MRI データを用いた場合の sLORETA の比較を行った。

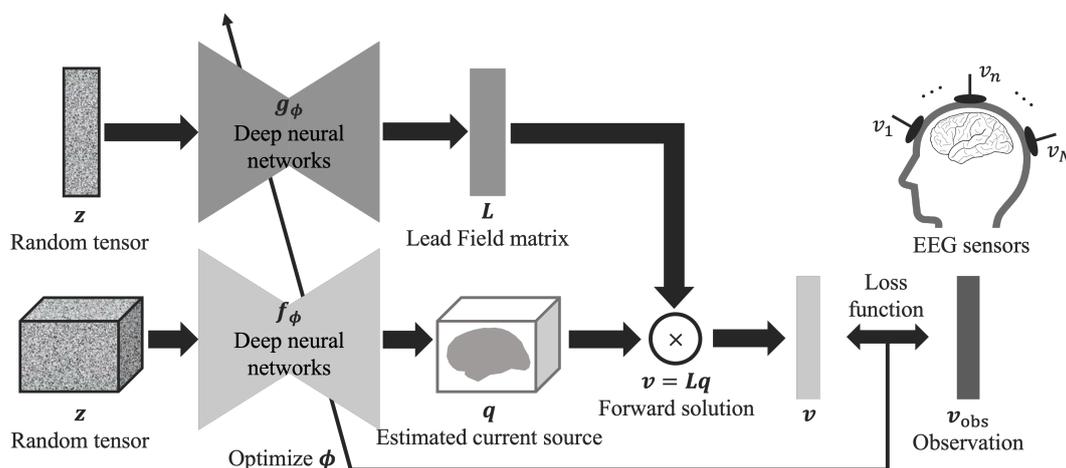


Fig. 1 Diagram of simultaneous estimation of forward model and current source using Deep Prior

5 結果と考察

右1次聴覚野に電流源を配置し、0 dBのノイズを加えてEEGデータを合成したときの、学習回数10, 100, 300, 500回における推定されたセンサ上の電位分布をFig. 2に示す。Fig. 2のTrueはノイズを付与しなかった場合のセンサの観測値の分布、Observationは推定の際に与えたセンサの観測値の分布である。学習回数を500回とすると、損失関数は連続的に減少していることがわかる。学習回数が100回目ときの予測したセンサの観測値の分布は、0 dBのノイズが重畳した観測値を教師として学習したにも関わらず、ノイズを付与しなかった場合の観測値の分布に近づいていることが分かる。また、学習回数が300回を超えると、教師とした0 dBのノイズが重畳された観測値の分布に近づいていることがわかる。これは、Deep Priorによるノイズ除去の効果で、信号に多く含まれる低周波成分を先に学習し、高周波成分を持つノイズが後から学習されることを示している。これにより、損失関数が減少していても学習を途中で止めることで、ノイズなしの信号を推定できたと考えられる。

右1次聴覚野に電流源を配置して合成したEEGデータに対して電流源推定を行った時の提案手法とsLORETAの推定位置の誤差の比較をTable 1に示す。最も精度が良かったのは、提案手法で活性化関数を用いない線形U-Net構造を用いた場合(DP(Linear U-Net))であり、既存手法のsLORETAと比べても精度が良いことがわかる。また、提案手法において、被験者本人のMRIデータを用いた場合の結果(DP(LF known))と

比べても同等の精度が得られた。

ここで、提案手法のネットワークにおいて、活性化関数を用いない線形U-Net構造が最も精度が良かったのは、線形ニューラルネットワークの正則化効果[7]が影響していると考えられる。また、一般的なCNNにおけるタスクでは、非線形な活性化関数を用いられるが、本研究で想定している電流分布は必ずしも自然画像のような複雑な構造を持っていない。このことから、より簡単に表現できる線形構造が適していると考えられる。

また、ノイズが大きくなった時でも推定誤差が大きく上昇しないことがわかる。これは、Deep Priorによるノイズ除去の効果により、提案手法はノイズの影響を受けにくいと考えられる。

次に、右1次体性感覚野に電流源を配置して合成したEEGデータに対して電流源推定を行った。この時の提案手法とsLORETAの推定位置の誤差の比較をTable 2に示す。右1次聴覚野に電流源を配置した場合と同様に、提案手法で活性化関数を用いない線形U-Net構造を用いた場合(DP(Linear U-Net))はsLORETAより高精度の推定ができることがわかる。また、提案手法において、被験者本人のMRIデータを用いた場合の結果(DP(LF known))と比べても同等の精度が得られた。

これらの実験結果から、提案手法では被験者本人のMRIデータを用いずにEEG観測値のみから脳内の電流源を推定しても、被験者本人のMRIデータを用いた場合と同様の精度が得られることがわかる。また、既存手法のsLORETAと比較しても推定精度が優れていることがわかる。

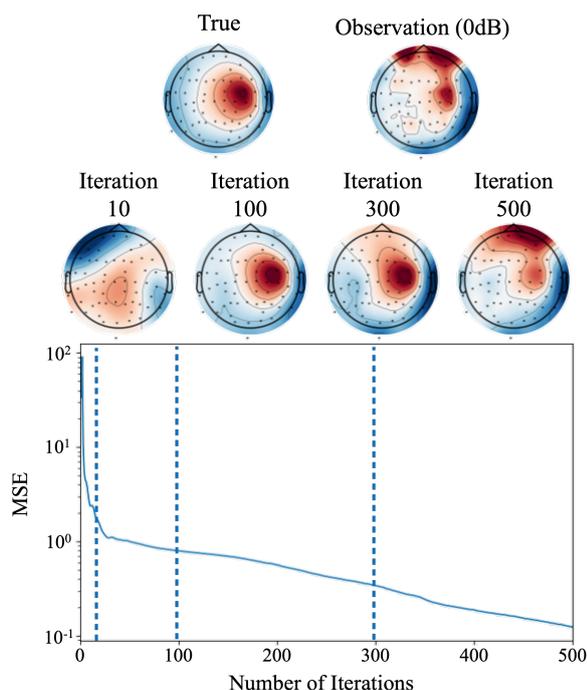


Fig. 2 Effect of noise removal by Deep Prior

Table 1 Relationships between SNR and localization error of the current dipole in the right primary auditory cortex of the proposed method and sLORETA

Method	Localization Error [mm]			
	20 dB	5 dB	2 dB	0dB
DP (LF known)	9.6	10.4	16.9	18.0
sLORETA	24.2	30.6	30.8	36.9
Ours (U-Net)	14.7	17.5	31.5	46.0
Ours (Linear U-Net)	6.7	12.0	13.5	14.5
Ours (Decoder)	7.1	15.1	15.0	21.0
Ours (Linear Decoder)	10.2	10.5	13.8	16.6

Table 2 Relationships between SNR and localization error of the current dipole in the right primary somatosensory cortex of the proposed method and sLORETA

Method	Localization Error [mm]			
	20 dB	5 dB	2 dB	0dB
DP (LF known)	7.2	10.3	12.7	15.2
sLORETA	18.1	18.1	18.1	18.1
Ours (U-Net)	8.5	27.2	44.4	56.6
Ours (Linear U-Net)	14.1	14.1	13.1	13.3
Ours (Decoder)	10.9	12.8	17.1	17.2
Ours (Linear Decoder)	14.4	38.4	60.3	83.8

6 おわりに

本研究では、Deep Priorにより、被験者本人のMRIデータを用いずEEGデータのみから電流源を推定する手法を提案した。脳内の右1次聴覚野および、右1次体性感覚野を活動源とした単一電流源を仮定したときのEEGデータを合成し、推定誤差を評価した。その結果、既存手法のsLORETAよりも推定された位置誤差は少なくなり、真の電流源の位置をより正確に推定できることが示された。また、Deep Priorのノイズ除去の効果により、ノイズが重畳している場合でもノイズのない信号を復元できることが示された。

しかしながら、Forward modelの予測については、予測されるリードフィールド行列の変化や適応などの点において、モデル構造の変更や最適なパラメータの選択方法などを検討する必要がある。また、より多様な電流源や実際のデータに対する提案手法の評価も今後の課題である。

謝辞 本研究の一部は、JSPS 科研費JP21H05596の支援を受けたものである。

参考文献

- [1] M. Hamalainen et al., Technical Report TKK-FA559, Helsinki University of Technology, 1984.
- [2] R. D. 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), 711-714, 2022.
- [4] H. Yano et al., APSIPA ASC, 1005-1008, 2022.
- [5] B. Fischl, Neuroimage, 62(2), 774-781, 2012.
- [6] A. Gramfort et al., Frontiers in Neuroscience, 7, 267, 2013.
- [7] S. Gunasekar et al., NeurIPS. 9461-9471, 2018.