

## MEG 脳内電流源の変分ベイズ推定

吉岡 琢<sup>†,††</sup> 佐藤 雅昭<sup>††,†††</sup> 梶原 茂樹<sup>††††</sup> 外山 敬介<sup>††††</sup>

† 奈良先端科学技術大学院大学 情報科学研究科 〒630-0192 奈良県生駒市高山町 8916-5

†† ATR 人間情報科学研究所 〒619-0288 京都府相楽郡精華町光台 2-2-2

††† 科学技術振興事業団 CREST

†††† (株) 島津製作所 基盤技術研究所 〒619-0237 京都府相楽郡精華町光台 3-9-4

E-mail: †taku-y@aist-nara.ac.jp, ††masa-aki@atr.co.jp

あらまし 我々は、MEG 観測データから脳内電流源の分布を推定するための変分ベイズ法に基づく手法を提案している。本手法の事前知識として、電流源はマクロ的には脳内の複数の場所に局在しているという局在条件とミクロ的には電流分布は連続分布をしているという連続条件を同時に考慮に入れ、さらに fMRI による情報も考慮に入れる事が出来る階層事前分布を導入している。本研究では、MRI 画像データから作成した皮質構造モデルを用いたシミュレーションを行い、その有効性を確かめたので、これを報告する。

キーワード MEG, 脳内電流源推定, 変分ベイズ法, 階層事前分布

## Estimation of current distribution in brain from MEG data based on variational Bayes

Taku YOSHIOKA<sup>†,††</sup>, Masa-aki SATO<sup>††,†††</sup>, Shigeki KAJIWARA<sup>††††</sup>, and Keisuke TOYAMA<sup>††††</sup>

† Graduate School of Information Science, Nara Institute of Science and Technology 8916-5 Takayama,  
Ikoma, Nara 630-0192, Japan

†† Human Information Science Laboratories, ATR International  
2-2-2 Hikaridai, Seika, Soraku, Kyoto 619-0288, Japan

††† CREST, Japan Science and Technology Corporation

†††† Technology Research Laboratory, Shimadzu Corporation 3-9-4 Hikaridai, Seika, Soraku, Kyoto  
619-0288, Japan

E-mail: †taku-y@aist-nara.ac.jp, ††masa-aki@atr.co.jp

**Abstract** We have proposed a variational Bayes method for estimating current source distribution from MEG data. In the method, we introduce a hierarchical prior which assumes that the current sources are localized in the several brain area and the current distribution is continuous. The fMRI data can be also incorporated into the hierarchical prior. In this report, we have done computer simulation by using the cortex model obtained by MRI measurement. The simulation results shows the effectiveness of our method.

**Key words** MEG, Current source estimation, Variational Bayes method, Hierarchical prior

### 1. はじめに

MEG(脳磁計)は、脳内の神経細胞活動により発生する微弱な磁場を超伝導磁場センサにより観測し、脳内神経活動を測定する装置であり[15] fMRI や PET と比較して時間解像度が高いため、脳活動の時間変化を詳細に調べるのに適している。

しかし、MEG の観測磁場データから脳内電流源の3次元分布を推定する MEG 逆推定問題は原理的な不定性を抱えており、

何らかの事前知識無しにはこれを解決することは不可能である。この問題点を解決するために、従来は電流源が点状の電流双極子で近似できることを仮定したり[5]、あるいは生理学的な知見から電流源が存在する場所を限定して線形逆フィルタによる推定などを行っていた[10]–[12]。しかしこれらの方法は電流源が複数ある複雑な場合に推定の信頼性が悪くなることが指摘されている。

我々はこのような問題点を解決するため、脳内電流源に対す

る事前知識として、電流源はマクロ的には脳内の複数の場所に局在しているという局在条件と、ミクロ的には電流分布は連続分布をしているという連続条件を同時に考慮に入れた階層事前分布を導入し、変分ベイズ法により電流分布推定を行う方法を提案している [1], [2] .

一方、時間分解能に優れた MEG と空間分解能に優れた fMRI を組み合わせることにより、推定の精度を高める方法が、近年研究されている [18]–[23] . しかし、fMRI と MEG で得られる脳活動は必ずしもいつでも対応するものではないことが最近分かってきている . 線形逆フィルタで MEG と fMRI を組み合わせる方法は、fMRI の観測にかからない神経活動をうまく推定することが困難である . 逆に fMRI 活動が有る場所では、たとえ神経電流活動がないときでも、誤って活動電流を推定してしまう可能性がある .

これに対し我々は、fMRI による観測結果を事前知識として推定に利用する際に、fMRI と MEG が異なる量を観測しており時間分解能も異なるという点を考慮した階層事前分布を提案している [2] .

本稿では、MRI を用いて得られた脳構造モデルに基づいてシミュレーション用データを作成し、提案手法の有効性を検証する . 特に事前情報として、局在条件、連続条件、fMRI 情報の 3 種類の情報を用いた場合の有効性をシミュレーションによって調べる . また、提案手法の実行時間、および収束性について調べた結果を報告する .

## 2. 確率モデルと階層事前分布

脳表面近くの  $N$  点で測定した磁場を  $B = (B_1, \dots, B_N)'$  , 脳内曲面上に仮定した電流双極子に流れる電流分布を  $J = \{J_i | i = 1, \dots, I\}$  と表す . 提案手法では、電流分布  $J$  が与えられたときに磁場  $B$  が観測される確率  $P(B|J)$  が、次のような正規分布に従うと仮定する .

$$P(B|J) \propto \exp \left[ -\frac{\sigma}{2} \| B - GJ \|^2 \right] \quad (1)$$

ここで  $\sigma$  はノイズ分散の逆数である .  $G$  はリードフィールド行列と呼ばれ、双極子の位置、各双極子の電流ベクトルの方向、および磁場センサの位置と方向から計算される [9] . 磁場  $B$  を観測したときの電流分布  $J$  の事後分布は次式で与えられる .

$$P(J|B) = \frac{P(B|J)P_0(J)}{P(B)} \quad (2)$$

ここで  $P(B)$  は周辺尤度である .  $P_0(J)$  は電流分布に対する我々の事前知識を表す事前分布である . 提案手法では、次のような脳内電流源に対する局在条件と連続条件を組み合わせた階層事前分布を導入する .

$$P_0(J, \sigma) = \int d\alpha d\lambda dz d\tau P_0(J|z, \alpha, \sigma) \times P_0(z|\lambda, \sigma) P_0(\sigma|\tau) P_0(\alpha) P_0(\lambda) P_0(\tau)$$

$$P_0(J|z, \alpha, \sigma) \propto \exp \left[ -\frac{\sigma}{2} \sum_{i=1}^I \alpha_i \| J_i - (Wz)_i \|^2 \right] \quad (3)$$

$$P_0(z|\lambda, \sigma) \propto \exp \left[ -\frac{\sigma}{2} \sum_{i=1}^I \lambda_i \| z_i \|^2 \right] \quad (4)$$

$$P_0(\sigma|\tau) = \Gamma(\sigma|\tau^{-1}, \gamma_{0\sigma}) \quad (5)$$

$$P_0(\alpha) = \prod_{i=1}^I \Gamma(\alpha_i|\bar{\alpha}_{0i}, \gamma_{0\alpha}) \quad (6)$$

$$P_0(\lambda) = \prod_{i=1}^I \Gamma(\lambda_i|\bar{\lambda}_{0i}, \gamma_{0\lambda}) \quad (7)$$

$$P_0(\tau) = \Gamma(\tau|\bar{\tau}_0, \gamma_{0\tau}) \quad (8)$$

ここで  $\Gamma(x|\bar{x}, \gamma)$  はガンマ分布を表す .  $z = \{z_i | i = 1, \dots, I\}$  は連続条件を表すために導入された内部変数である .  $\gamma_{0\alpha}, \gamma_{0\lambda}$  は事前分布の信頼度を表し、電流分布のスパース (局在) 性を制御するメタパラメータである .  $\alpha_i(\lambda_i)$  は事前分布における電流の分散 (共分散) に逆比例し、 $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  はその期待値である .  $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  を小さくすることは、双極子  $i$  には電流が流れやすい、という事前情報を与えることを意味する . ただし  $\alpha_i(\lambda_i)$  の値を直接指定するのではなく、階層事前分布のメタパラメータ  $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  の値を指定することで、fMRI 情報を曖昧さを持つ情報として階層事前分布に入れることができる . 各双極子ごとに異なる  $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  を与えることによって、電流強度に関する事前情報を与えることができる . 例えば、MEG データを測定したときと同じ実験条件において、fMRI により脳の活動強度が測定されている場合、fMRI 活動強度の強い格子点では  $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  を小さく、逆に活動強度が弱ければ  $\bar{\alpha}_{0i}(\bar{\lambda}_{0i})$  を大きくすることによって、解に対する事前情報を曖昧な情報として与えることができる .

$W$  は空間フィルタを表す行列であり、次のように与えられる .

$$W_{ij} = \exp \left[ -(d_{ij}/R)^2 \right] \quad (9)$$

ここで  $d_{ij}$  は双極子  $i$  と  $j$  の、脳内曲面 (皮質) に沿った距離である .  $W$  をこのように与えることで、事前分布 (3) は、脳内曲面上で近い距離にある双極子同士の電流強度は近くなるという連続条件を表す . 連続性はフィルタ半径  $R$  によって制御され、このパラメータは生理学的な知見に基づいて決められる .  $W$  を恒等的に 0 とした場合には、局在条件のみを入れることになる .

階層事前分布を決めるメタパラメータ ( $\bar{\alpha}_{0i}, \bar{\lambda}_{0i}, \gamma_{0\alpha}, \gamma_{0\lambda}, \gamma_{0\sigma}, \bar{\tau}_0, \gamma_{0\tau}$ ) と観測磁場  $B$  が与えられると、電流分布  $J$  を含む未知パラメータの事後分布は変分ベイズ法により推定される . 変分ベイズ法は自由エネルギーを最大化する逐次アルゴリズムとして実現される . その詳細については文献 [2] を参照されたい .

## 3. 皮質構造データを用いたシミュレーション

シミュレーションのために、MRI 画像データから得られた、視覚野 (V1, V2, V5) 周辺の皮質構造を用いた . V1, V2, V5 周辺の 633 の格子点 ( $I = 633$ ) から構成される皮質構造モデルを推定用のモデルとして用いた (図 1) . 各格子点から最も近い格子点までの距離は、0.5mm から数 mm 程度である (図

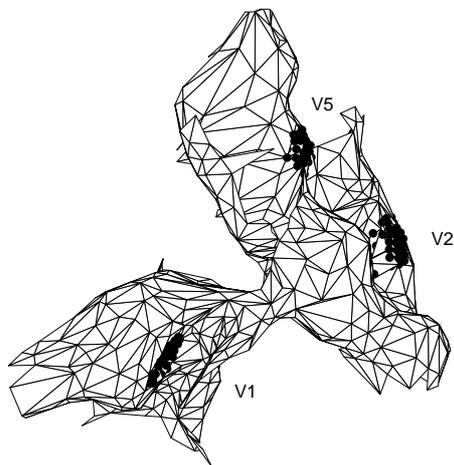


図 1 推定用の皮質モデル．黒い点は V1, V2 および V5 近傍の電流源に対応する，推定用の双極子はメッシュの格子点に配置される．

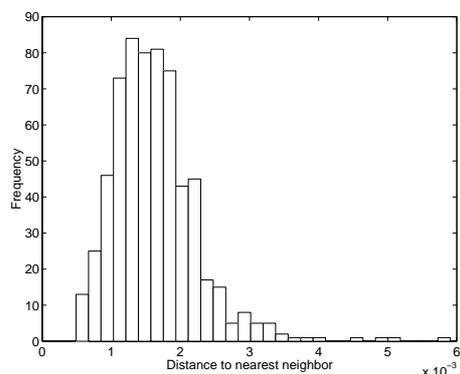


図 2 各格子点から最も近い格子点までの距離のヒストグラム．

2) . これらの格子点上に電流双極子が配置されていると仮定して，サルパスの式を用いて [9] リードフィールド行列を作成した．皮質の法線方向に電流が流れると仮定し，各双極子の電流方向を MRI 画像データに基づいて得られた皮質の法線ベクトルで与えた．また 201 チャンネルの磁場センサ ( $N = 201$ ) が頭蓋骨の周囲に配置されているとして，リードフィールド行列を計算した．推定モデルの各格子点の深さ，および方位角と仰角を図 3 に示す．V1 と V2 は方位角と仰角は近いが (図 3 右)，V1 の方がかなり深い位置にあることが分かる (図 3 左) . このため，V1 電流と V2 電流を分離して推定することは困難である．特に V1 電流を正しく推定することは難しい．そこで，この点を検討するために 3 種類の電流分布を用意した．すなわち，V1, V2, V5 に対応する格子点に対して  $J_1 = (1.0, 1.0, 0.5)$  ,  $J_2 = (1.0, 0.0, 0.5)$  ,  $J_3 = (0.0, 1.0, 0.5)$  という 3 種類の電流強度を与えて，シミュレーション用 MEG データを作成した．電流源として用いた格子点は，推定用モデルよりも高い解像度を用いた．このためノイズが全くない場合でもシミュレーション用 MEG データを推定用モデルで完全に再現することはできないことに注意する．

### 3.1 観測ノイズがない場合

最初に観測ノイズがない場合の推定結果を示す．まず，局在階層事前分布を用いて推定を行った．メタパラメータを

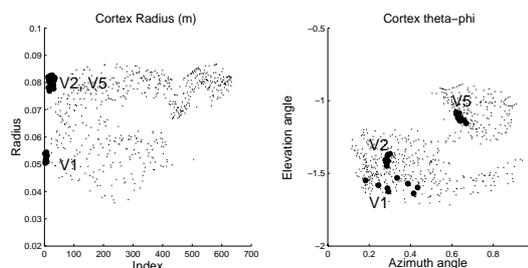


図 3 シミュレーション皮質モデルの構造情報．左は各格子点のインデックスと深さのプロット．右は方位角と仰角のプロット．

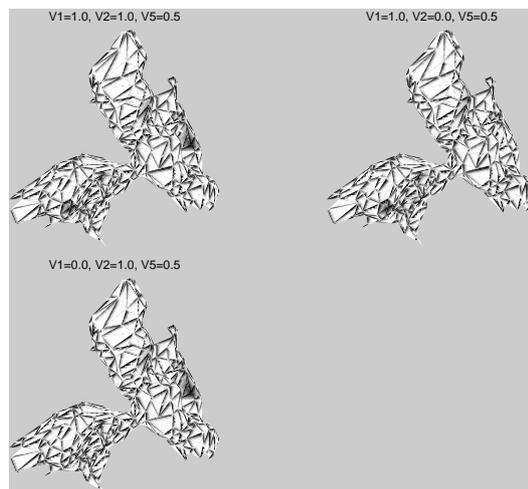


図 4 観測ノイズがない場合に．局在条件を用いて電流源を推定した結果．

$\gamma_{\alpha 0} = \gamma_{\lambda 0} = 0.1$  ,  $\bar{\alpha}_{0i} = \bar{\lambda}_{0i} = 10.0$  とし，学習ステップ数を 500 としたときの，3 種類の電流強度分布に対応する推定結果を図 4 に示す．図の左上，右上，左下は真の電流分布としてそれぞれ  $J_1$  ,  $J_2$  ,  $J_3$  を与えた場合に対応する．図より，電流源の位置について正しく推定できていることが分かる．ただし，推定された電流源は一点に集中しており，その広がりまでは正しく推定できていない．

次に，局在条件に加えて連続条件を導入した場合の結果を示す． $\gamma_{\alpha 0}$  ,  $\gamma_{\lambda 0}$  と  $\bar{\alpha}_{i0}$  ,  $\bar{\lambda}_{0i}$  は同じ値を用いた．フィルタ半径  $R$  を 5mm，および 9mm としたときの結果をそれぞれ図 5, 6 に示す．いずれのフィルタ半径を用いても電流源の位置を正しく推定できるが，電流源の広がりにはフィルタ半径に依存して若干の違いが見られる．図 7 は，電流強度分布  $J_1$  に対する推定電流強度のヒストグラムであり，左上，右上，右下はそれぞれ局在条件のみ， $R = 5\text{mm}$  ,  $R = 9\text{mm}$  とした場合に対応する．局在条件のみを用いた場合，電流強度の高い数点を除いたすべての点で電流が 0 になっていることが分かる．連続条件を加えると，推定電流強度の分布が広がる事が分かる．

### 3.2 観測ノイズがある場合

次に，観測ノイズとして SN 比 0.1，および 0.2 のガウスノイズを加えた場合のシミュレーションを行なった．推定には局在条件と連続条件を組み合わせた階層事前分布を用いた．階層事前分布のメタパラメータ，および学習回数はノイズがない場合

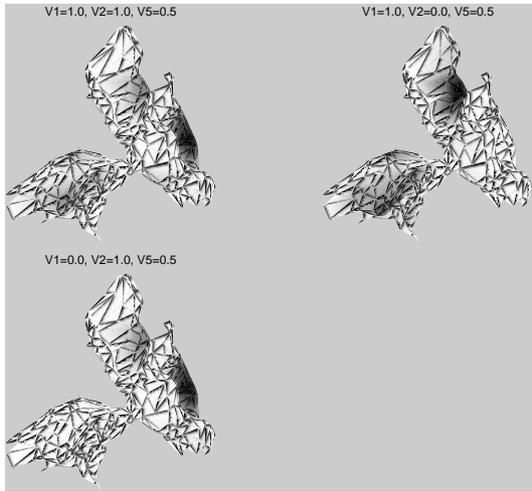


図 5 局在条件と連続条件を用いて電流源を推定した結果 ( $R = 5\text{mm}$ ) .

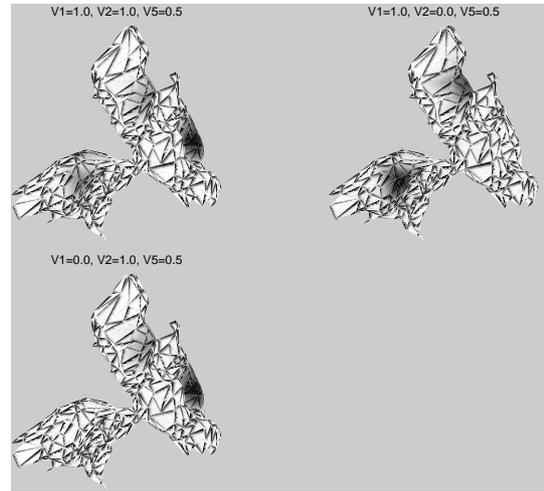


図 8 SN 比 0.1 のノイズを加えたシミュレーション用観測データに対して、局在条件と連続条件を用いて電流源を推定した結果 .

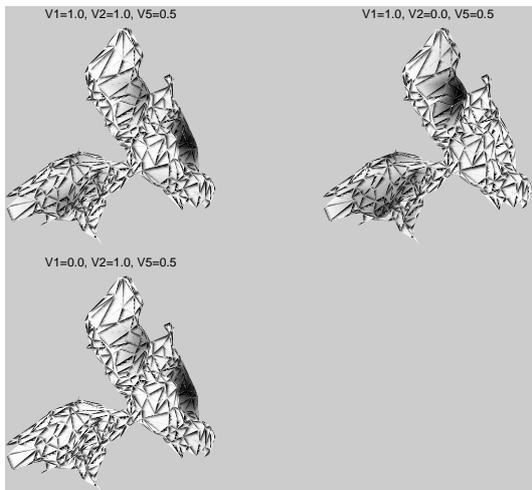


図 6 局在条件と連続条件を用いて電流源を推定した結果 ( $R = 9\text{mm}$ ) .

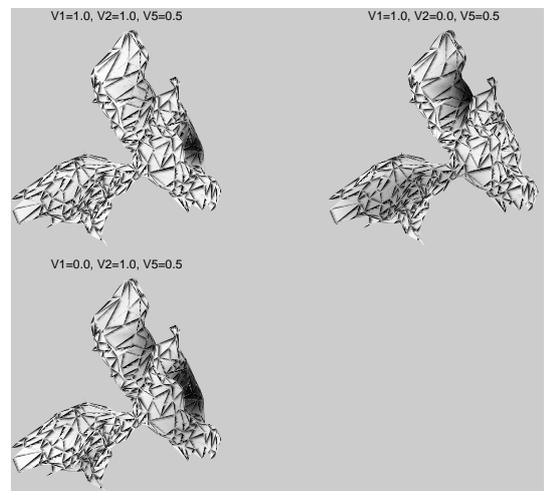


図 9 SN 比 0.2 のノイズを加えたシミュレーション用観測データに対して、スパース事前分布と連続条件を用いて電流源を推定した結果 .

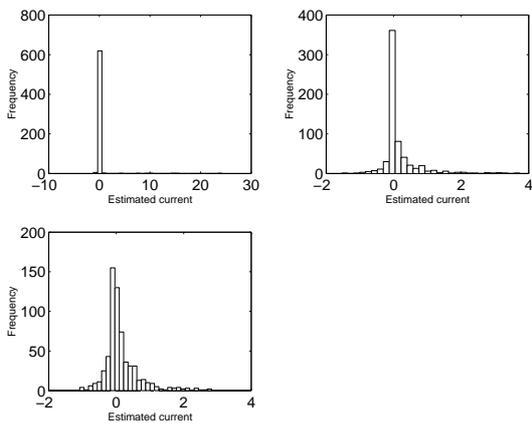


図 7 推定電流強度のヒストグラム .

のシミュレーションと同じにし、フィルタ半径は  $5\text{mm}$  とした . 図 8, 9 にその推定結果を示す . ノイズが小さい場合 ( $\text{SN}=0.1$ ) は電流源が正しく推定されている . しかし、ノイズが大きい場合 ( $\text{SN}=0.2$ ) は、真の電流分布  $J_1, J_2$  に対して、深い位置にある  $V1$  上の電流源が正しく推定されていない . そこで、MEG 観測に対応する fMRI データが得られたという状況を想定して、

電流強度に関する事前知識を導入して推定を行った . 電流源付近から  $10\text{mm}$  以内に含まれる格子点 (図 10) に対して階層事前分布のメタパラメータを  $\bar{\alpha}_{0i} = \bar{\lambda}_{0i} = 1.0$  とし、それ以外の格子点では  $\bar{\alpha}_{0i} = \bar{\lambda}_{0i} = 10.0$  とした . その結果、 $V1$  にある電流源の位置と広がりを正しく推定することができた (図 11) . このシミュレーション結果から次のようなことが分かる . (1). 真の活動領域よりも広い領域に活動があるという情報を入れても、MEG データから電流の広がりが正しく推定できた . (2). 電流活動がない場所に活動があるという誤った情報を与えても ( $J_2$  と  $J_3$ ) , 電流が無い場所に誤って電流を推定することはなかった .

### 3.3 アルゴリズムの実行時間と収束性

推定アルゴリズムの計算量は双極子数の三乗のオーダーであり、双極子数が大きい場合には多くの計算量を必要とする . 推定アルゴリズムの 1 ステップの計算を  $2.4\text{GHz}$  の Pentium4 で測定した . 双極子数が 597 と 1400 のモデルに対する平均計算時間は、それぞれ 2.1 秒、37.1 秒であった . したがって、1400

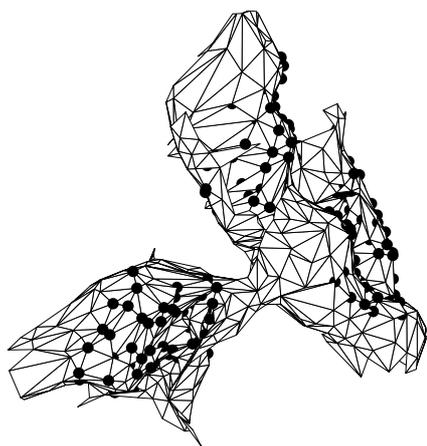


図 10 事前電流強度を大きくした ( $\alpha_{0i}$  を小さくした) 双極子の位置 .

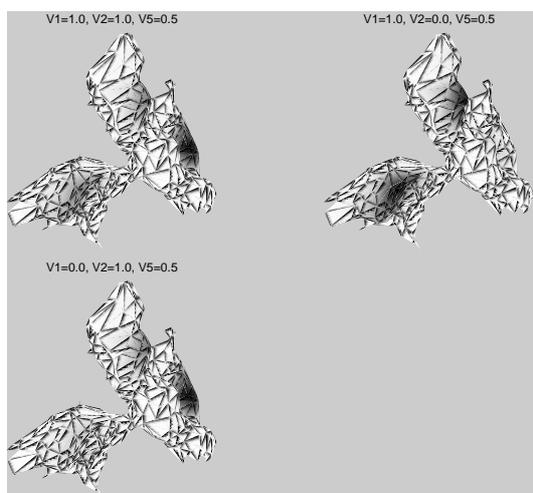


図 11 SN 比 0.2 のノイズを加えたシミュレーション用観測データに対して、局在条件、連続条件、電流強度情報を用いて電流源を推定した結果 .

点のモデルに対する 100 回の学習には約 1 時間かかる . しかも、これは 1 時刻における MEG 観測データに対する推定にかかる時間であり、時系列データに対して推定を行う場合には、解析する時間ステップ数に比例した時間が必要になる . そこで、妥当な推定結果が得られるまでに必要な学習回数について調べた .

上で示したシミュレーション結果では、いずれも 500 回の学習で妥当な結果が得られているので、推定電流強度が 500 回学習後の推定電流強度に収束するまでの挙動を調べる . 各学習回数における推定電流強度と 500 回学習後の推定電流強度との正規化二乗誤差を、図 12 に示す . また、学習回数に対する自由エネルギーの収束性を図 13 に示す . ノイズが無い場合に局在条件のみを用いて推定した場合、約 50 回で収束している . 一方、フィルタ半径 9mm でノイズが無い場合が最も収束が遅い . 局在条件のみを用いた場合、電流強度が強い数個の双極子のみを用いた推定になるので収束が早くなり、一方フィルタ半径を大きくすると解の不定性のために (データを完全に復元する解はないことに注意する) 性能的に似たような解が多くあり、緩やかに収束していると解釈できる . ノイズがある場合には、200

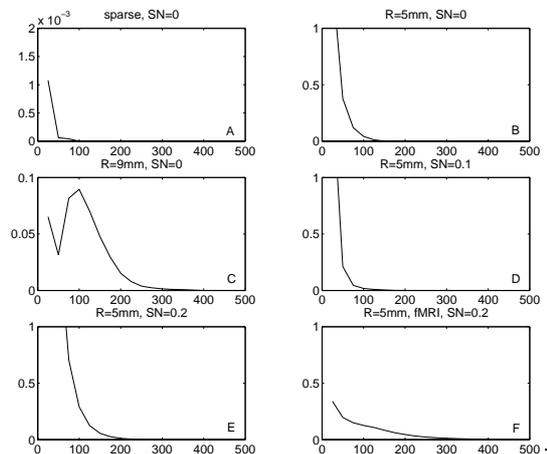


図 12 推定アルゴリズムの収束性を示すプロット . 横軸は学習回数、縦軸は 500 回学習後の推定結果に対する正規化二乗誤差を表す . A から F は、図 4 から 11 に結果を示したシミュレーションにそれぞれ対応する .

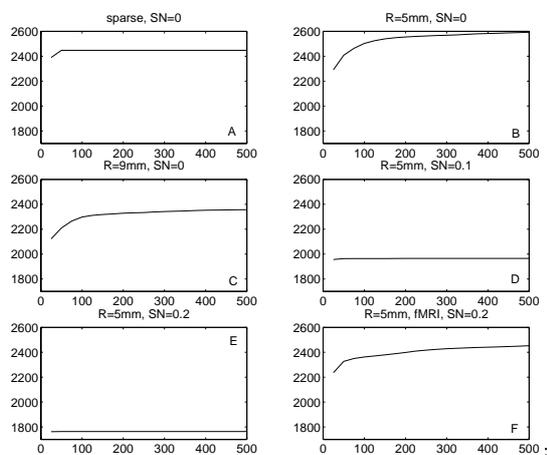


図 13 シミュレーションにおける自由エネルギーの変化 .

回までには学習がほぼ収束している . ノイズがある場合の変分ベイズ推定では、ノイズ分散以上に誤差を小さくしようとしないので、ノイズが無い場合よりも収束が早くなると考えられる .

#### 4. ま と め

本稿では、我々が提案する変分ベイズ法による MEG 電流推定の有効性を検証するために行ったシミュレーション結果について説明した .

局在条件と連続条件を組み合わせた階層事前分布を用いることによって、MRI から得られた皮質構造モデルを用いたシミュレーションにおいて、電流源の位置とその広がり方を正しく推定することができた . また、fMRI による情報を模した電流強度に対する事前情報を曖昧な形で階層事前分布に与えることにより、観測ノイズが大きい場合でも、皮質の深い位置にある電流源の位置と広がり方を正しく推定でき、特に以下の事が示された .

- (1). 真の活動領域よりも広い領域に活動があるという情報を入れても、MEG データから電流の広がり方が正しく推定できた .
- (2). 電流活動がない場所に活動があるという誤った情報を与えても、電流が無い場所に誤って電流を推定することはな

かった。

この事は、fMRI と MEG で得られる脳活動が一致していないときでも、本手法を用いて安全に推定が出来ることを示唆している。

実際の観測データを用いて本手法の有効性を検証することは今後の課題である。

謝辞 本研究に有益な議論をして下さった ATR 人間情報科学研究所、川人光男室長と銅谷賢治博士に感謝します。本研究は通信・放送機構の研究委託により実施したものである。

#### 文 献

- [1] 佐藤雅昭, 変分ベイズ法による MEG 電源推定, 信学技報, NC2001-189, 2002.
- [2] 佐藤雅昭, 吉岡琢, 梶原茂樹, 外山敬介, MEG 電源推定とベイズ推定事前分布, 信学技報 (本予稿), 2003.
- [3] Attias, H. (1999) Inferring parameters and structure of latent variable models by variational Bayes. *Proc. 15th Conference on UAI* (pp. 21-30).
- [4] Churchland, P. S., and Sejnowski, T. J. (1988) Perspectives on cognitive neuroscience. *Science* **242**, 741-745.
- [5] Hari, R. (1991) On brain's magnetic responses to sensory stimuli. *J. Clin. Neurophysiol.* **8**, 157-169.
- [6] Kajihara S, Ohtani Y, Goda N, Tanigawa M, Toyama K. (2003) Wiener filter-magnetoencephalography of visual cortical activities. *NeuroImage*, submitted.
- [7] Neal, R. M. (1996) *Bayesian learning for neural networks*. Springer-Verlag.
- [8] Sato, M. (2001) On-line Model Selection Based on the Variational Bayes. *Neural Computation*, **13**.
- [9] Sarvas, J. (1987) Basic mathematical and electromagnetic concepts of the biomagnetic inverse problem. *Phys. Med. Biol.* **32** 11-22.
- [10] Hamalainen, M., Hari, R., Ilmoniemi, R. J., Knuutila, J., and Lounasmaa, O. V. (1993) Magnetoencephalography-Theory, instrumentation, and applications to noninvasive studies of the working human brain. *Rev. Mod. Phys.* **65**, 413-497.
- [11] Toyama, K., Yoshikawa, K., Yoshida, Y., Kondo, S., Tomita, Y., Takanashi, Y., Ejima, Y. and Yoshizawa, S. (1999) A new method for magnetoencephalography (MEG) : Three dimensional magnetometer-spatial filter system. *Neuroscience* **91**, 405-415.
- [12] Wang, J.-Z., Williamson, S. J., and Kaufman, L. (1992) Magnetic source images determined by a lead-field analysis: The unique minimum-norm least-squares estimation. *IEEE Trans. Biomed. Eng.* **39**, 665-675.
- [13] Bandettini, P.A. (2000) The temporal resolution of functional MRI. in *Functional MRI*, ed. by Moonen, C.T.W. and Bandettini P.A., Springer, 205-220, 2000.
- [14] Belliveau, J. W., Kennedy, D. N., McKinstry, R. C., Buchbinder, B. R., Weisskoff, R. M., Cohen, M. S., Vevea, J. M., Brady, T. J., and Rosen, B. R. (1991) Functional mapping of the human visual cortex by magnetic resonance imaging. *Science* **254**, 716-719.
- [15] Churchland, P. S., and Sejnowski, T. J. (1988) Perspectives on cognitive neuroscience. *Science* **242**, 741-745.
- [16] Logothetis, N.K., Pauls, J., Augth, M., Trinth, T. and Oeltermann, A. (2001) Neurophysiological investigation of the basis of the fMRI signal. *Nature* **412**, 150-157.
- [17] Ogawa, S., Lee, T-M., Kay, A.R., Tank, D.W. (1990) Brain magnetic resonance imaging with contrast-dependent oxygenation. *Proc. Natl. Acad. Sci. USA* **87**, 9868-9872.
- [18] Ahlfors, S. P., Simpson, G. V., Dale, A. M., Belliveau, J. W., Liu, A. K., Korvenoja, A., Virtanen, J., Huotilainen, M., Tootell, R. B. H., Aronen, H. J., and Ilmoniemi, R. J. (1999) Spatiotemporal activity of a cortical network for processing visual motion revealed by MEG and fMRI. *J. Neurophysiol.* **82**, 2545-2555.
- [19] Dale, A. M., and Sereno, M. I. (1993) Improved localization of cortical activity by combining EEG and MEG with MRI cortical surface reconstruction: A Linear approach. *J. Cognit. Neurosci.* **5**, 162-176.
- [20] Dale, A. M., Liu, A. K., Fischl, B. R., Buchner, R. L., Belliveau, J. W., Lewine, J. D., and Halgren, E. (2000) Dynamic statistical parametric mapping: Combining fMRI and MEG for high-resolution imaging of cortical activity. *Neuron* **26**, 55-67.
- [21] Fujimaki, N., Hayakawa, T., Nielsen, M. K?sche, T.R. and Miyachi, S. (2002) An fMRI-constrained MEG source analysis with procedures for dividing and grouping. *Neuroimage* **17**, 324-343.
- [22] Heinze, H. J., Mangun, G. R., Burchert, W., Hinrichs, H., Scholz, M., Munte, T. F. Gos, A., Scherg, M., Johannes, S., Hundeshagen, H., Gazzaniga, M.S. and Hillyard, S. A. (1994) Combined spatial and temporal imaging of brain activity during visual selective attention in humans. *Nature* **372**, 543-546.
- [23] Liu, A. K., Belliveau, J. W., and Dale, A. M. (1998) Spatiotemporal imaging of human brain activity using functional MRI constrained magnetoencephalography data: Monte Carlo simulations. *Proc. Natl. Acad. Sci. USA* **95**, 8945-8950.