

する新しい手法を提案した. その手法は, MEG 計測データの生成モデルを観測データから推定し, その最適推定モデルを用いて, MEG データの推定値を得る方法である. すなわち, まず MEG データの生成モデルを次のように与える.

$$m_t = s_t + \tau_t + p_t + e_t + n_t$$

ここで m_t はあるチャンネルにおける時刻 t での MEG 計測値であり, s_t は誘発脳磁場成分, τ_t は 1Hz 未満のベースラインドリフト成分, p_t は交流電源由来の定常周期成分, e_t は l_s 次元の線形システムから生成される背景雑音成分 n_t は確率的に揺らぐセンサ雑音及びモデル化誤差成分であり, 平均 0, 分散 σ_n^2 のガウス過程である. ここで, e_t は次に示すような自己回帰過程であると仮定する.

$$e_{t+1} = \sum_{i=0}^{l_s} a_i e_{t-i} + v_t$$

ただし, v_t は平均 0, 分散 σ_e^2 , のガウス過程である. τ_t, p_t 成分は特殊な自己回帰過程で記述できる. 提案手法は, ターゲットとする脳活動が含まれていないデータのプレ区間 (s_t が 0 の区間) を利用して, 背景雑音モデルを学習する. 最適モデルを決定するときの評価関数として, 赤池情報量基準(AIC)を用いる. その定義式は次式である.

$$AIC = -2 \log p(m_1, \dots, m_t | \theta) + 2M$$

ここで $p(m_1, \dots, m_t | \theta)$ は, モデルパラメータ θ が与えられたときの対数尤度である. また, M はモデルパラメータ数である. ここでのモデルパラメータベクトル θ は具体的には, e_t の回帰係数 $\{a_1, \dots, a_{l_s}\}$ とその入力となるガウス過程の分散 σ_e^2 ,

センサノイズの分散 σ_n^2 から構成される. 一般に条件付き同時確率密度 $p(m_1, \dots, m_t | \theta)$ の評価は難しいが, 本手法のような時間構造を仮定することにより成立する観測値 m_t のマルコフ性を利用して, 次のように書き下すことができる.

$$p(m_1, \dots, m_t | \theta) = \prod_{i=1}^t p(m_i | M_{i-1}, \theta)$$

ここで, M_i は観測時系列 $\{m_1, \dots, m_i\}$ を表す. この式の右辺は, カルマンフィルタを用いることで非常に効率的に評価できる[1]. 最適な背景雑音の近似モデルを探索するには, AIC を評価関数としてグリッドサーチ, 非線形最適化を順次行い, モデルパラメータとその次数を決定すればよい. これらの背景雑音モデルを学習した後に, 信号を含む区間データにおいて, 同様に信号モデルを推定する. ここでは単純に AR 過程を仮定し,

$$s_{t+1} = \sum_{i=0}^{l_s} b_i s_{t-i} + w_t$$

で与える. ここで, w_t は平均 0, 分散 σ_s^2 のガウス過程である.

この手法を確かめるためにシミュレーションを行った. 利用したデータセットは実ノイズデータに信号を加算したものである. 信号は 20Hz と 70Hz にピークを持つような AR モデルに白色ガウス雑音を入力として与えた時の出力を, 電流双極子のモーメントとし, その磁束を求めたものを使用した. また, 本手法の性能を評価するために, Fast ICA を用いたノイズ除去法と比較を行った[2]. この結果としては, 提案手法は ICA と比較して SN 比の改善がよいことが示された(図 1). また, 本手法は各チャンネルを独立に処理する線形フィルタであるので ICA モデルを変化させないことか

ら、本手法の後処理として ICA を適用できる。これにより、さらなる SN 比の改善ができることを示した。さらに推定されたノイズモデルのパワースペクトルの consistency から提案した背景ノイズモデルが適切であることを示した。

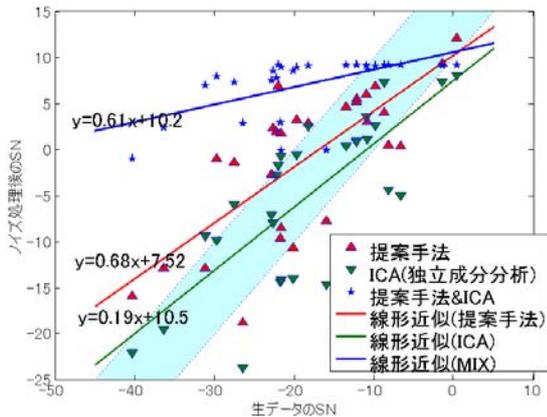


図 1 解析結果(28ch 分を表示, 全ての図で同一スケール), 左上: 原データ, 右上: 用いた信号, 左下: 提案手法による処理結果, 右下: ICA による処理結果

第三章では、実際の誘発脳磁場の近似モデルとして、定常AR過程は適切でないということを示し誘発脳磁場モデルの拡張を行った。定常AR過程のパワースペクトル $p(f)$ とモデルパラメータとの関係は

$$p(f | \{a_1, \dots, a_m\}, \sigma^2) = \frac{\sigma^2}{\|1 - \sum_{j=1}^m a_j e^{-2\pi i f j}\|^2}$$

で書けるので、定常AR過程では誘発脳磁場のパワーの時間変化を適切に扱えないことがわかる。そこで、誘発脳磁場の近似モデルを、ARモデルへの入力の確率構造が時変である非定常モデルに拡張した。ここで導入した動的に変化するより複雑なモデルを推定するために、演算効率の観点からパーティクルフィルタ(PF)を利用した[3][4]。PFは一般の確率分布を、その分布の標本の集まりで

近似を行い、その時間発展と新たな観測値を用いたフィルタ分布を逐次的に計算するアルゴリズムであり、並列計算に向けたものである。そこで、このPFのGPU上での実装を行った。

第四章では、本手法の有効性を検証するため、2次の線形モデルで生成した誘発脳磁場信号と実ノイズを合成したデータから、信号を抽出出来ることを示した(図2, 3)。続いて被験者がボタン押しをしている際に計測されたMEGの同期加算信号と実ノイズを合成したデータから信号を抽出出来ることを示した。先行する手法との比較も行った。

第五章では、実際のMEG計測によって得られた単一試行データに対して本手法を適用した。本手法においては自発活動のモデルを導入していないため、誘発活動の推定には条件が悪いが、それでも10試行程度の同期加算を行うことで、明瞭な誘発脳磁場を得ることができた。

第六章では、本手法をMEGデータに適用するとき問題となる、演算の効率性について考察を行った。GPUを用いて非常に高度な並列化を行うことで、Matlab上での実装と比較して約1000倍高速に実行する

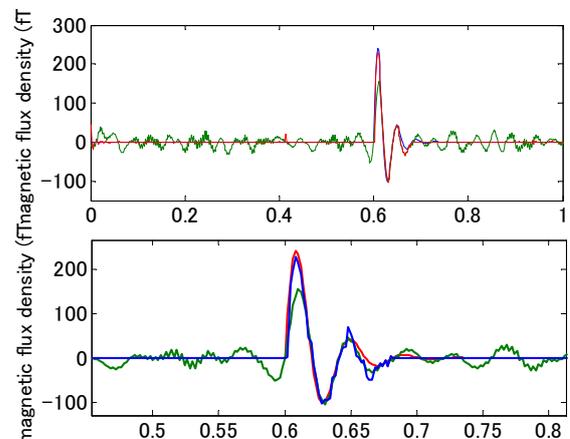


図 2 定常 AR モデルと時変分散 AR モデルの推定 緑線が定常 AR モデルの推定, 青線が時変分散 AR モデルの推定,

赤線が真の信号波形. 定常モデルは上図から信号ゼロの区間でも振動している. さらに下図から定常 AR モデルはピーク位置での推定も悪いことがわかる.

ことに成功した. この実装において重要な, 累積分布関数の算出, 尤度による重み付けに基づくリサンプリングを行う部分での並列実装の要点を記述した.

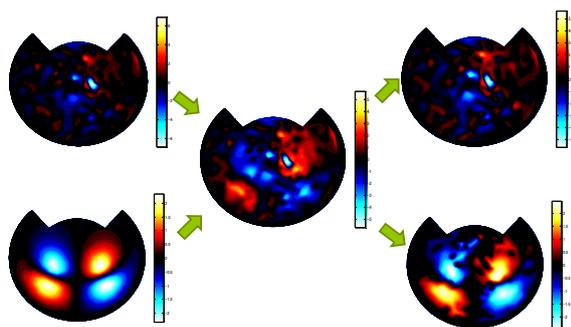


図 3 磁場マップにおける比較

左上:作成した信号 左下:真の信号 中:推定に用いたデータ 右上:推定されたノイズ成分の和 右下:推定された信号

第七章では以上二つの数値実験のまとめと総合考察, 今後の展望を述べた. MEG データの時間構造を活用することで, 単一試行データからでも誘発脳磁場の検出が可能であることを数値実験により示した. また, 提案手法と既存の手法を組み合わせることで, ノイズ除去性能の向上が図れることを数値実験により示した. 同期加算平均によって得られた誘発脳磁場を用いた数値実験でも単一試行から誘発脳磁場の検出が十分に可能である

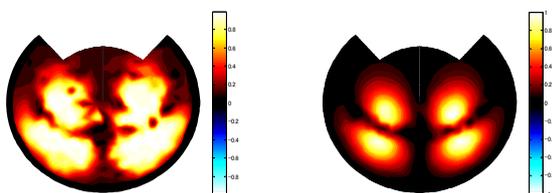


図 4 コヒーレンスマップ

左図は今回用いた 100 試行に渡る, 真の信号とのコヒーレンス関数を信号の帯域で平均したもの. 右図は真の信号の試行間平均のパワーを正規化したもの. 信号のパワーが強い領域では非常に高いコヒーレンスが得られている.

ことを示した. また, 自発活動のモデルを未導入にも関わらず, 本手法を適用後, 10 回程度の同期加算を行えば, 100 試行を用いて求められた同期加算波形成分を検出することができた.

本手法は, ノイズや誘発脳磁場に対する解析者の信念をモデルの構造に込めることにより, 観測データを最もよく説明するモデルを得ることで, 各成分の分解を得る方法である. 我々の研究の意義は, 完全とは言えないモデルでも, 単一試行 MEG データから微小な誘発脳磁場成分を抽出できる可能性が十分にあることを示した点にあると考える. 単一試行 MEG データ中の脳磁場については未知な部分が多いが, MEG 研究者が経験的に得ている仮説を今後種々取り入れることで, それらの仮説の検証が可能になるはずである. 断続的なモデルの改良を行っていくことが, MEG 研究の目標である脳という未知システムを理解する有力な手段であることを示せた点も, 我々の研究の成果である.

参考文献

- [1] Kalman, R.,E. (1960). A new approach to linear filtering and prediction problems. *Journal of Basic Engineering*, 82(1), 35-45.
- [2] Hyvärinen, A., & Oja, E. (1997). A fast fixed-point algorithm for independent component analysis
- [3] Kitagawa, G. (1996). Monte carlo filter and smoother for non-gaussian nonlinear state space models. *Journal of Computational and Graphical Statistics*, 5(1), 1-25.
- [4] Kitagawa, G. (1998). A self-organizing state-space model. *Journal of the American Statistical Association*, 93(443),
- [5] Taulu, S., and Hari, R. (2009). Removal of magnetoencephalographic artifacts with temporal signal-space separation: Demonstration with single-trial auditory-evoked responses, *Human brain mapping*, 30, 1524-1534