

独立成分解析による脳信号処理

Brain Signal Processing Based on Independent Component Analysis Approaches

曹 建庭^{1,2}
Jianting CAO^{1,2}

1 はじめに

生体計測技術の進歩により、ヒトの脳を痛めずに脳波計 (Electroencephalography: EEG), 脳磁計 (Magnetoencephalography: MEG), 機能的磁気共鳴図 (Functional Magnetic Resonance Imaging: fMRI) などの装置或いは計測法を用いて脳神経活動を計測することが可能になっている。このような計測装置を利用して近年高次脳機能に関する研究が盛んになり、また一部の臨床診断などもよく行われている。


脳計測装置を利用して測定された信号から脳内の活動成分を再構成することが脳信号処理分野の役目である。近年脳信号処理の新しい手法として独立成分解析 (ICA: Independent Component Analysis) が注目されている [1,5-8]。ICA の基本的な考え方は、統計的に独立と看做されている脳内の誘発成分 (Evoked Fields), 自発成分 (Spontaneous), 心臓や眼球などの動き成分 (Artifacts), 電源の干渉 (Interferences) などの成分を、計測された信号から分解・再現することである。本稿では、MEG 計測と信号処理の実例を取り上げ、データの計測、解析モデル、方法及び結果について概説する。

2 脳神経活動の計測

脳神経活動の発生メカニズムは脳神経の構成から簡単に説明すると、人間の脳皮質にはたくさんの神経細胞がコラム状の網のように繋ぎ合っている。一つの神経細胞の内部は外部と違った電位を保持している。これを膜電位と呼ばれているが、例えば、ある神経細胞が「抑制」から「興奮」という状態になると膜電位が上昇し、細胞膜内部にイオン電流が流れ、神経軸索を通過してほかの神経へ伝達して行く。1個の神経で発生したイオン電流は非常に弱いであるが、そのまわりに「興奮」状態となる神経細胞がたくさんあり、ほぼ同じ方向の電流が流れていると、全体としては大きな電流が流れているように見える。この大きな電流が脳髄液や頭蓋骨などを通して頭皮上に到達し、そこに電位

分布が形成される。頭皮に直接電極をつけ、電極間の電位差を測定しているのが EEG である。また、MEG では電流が引き起こした活動磁界、これは頭皮上に垂直な磁界成分を形成するが、これを頭皮上に置かれてある超伝導量子干渉素子 (superconducting quantum interference device; SQUID) で検出される。EEG と MEG はそれぞれ脳電位、脳磁気を計測して測定する物理量が異なっているが、測定対象となっている膜電位から発生する電流は同じものである。

脳神経活動の測定能力は基本的空間分解能と時間分解能で特徴づけることができる。EEG と MEG は直接的に時々刻々変化している脳内電気活動を推定しているため時間分解能は高いと思われるが、その空間分解能は、一般的には EEG より MEG のほうが空間分解能が高くなる。それは信号が通っている脳内物質を考えると、EEG の場合には脳内髄液や頭蓋骨の導電率が不均一のため、電極で採られた電位信号と神経活動の発生源の関係を表現することが複雑になり、正確な神経活動の場所の推定は非常に難しい問題である。一方 MEG の場合には、脳内組織の透磁率が真空の透磁率とほぼ同じであるため、信号の歪みの影響が少なく、原理的には空間分解能が高いと言える。但し、MEG の弱点としては環境雑音の影響を受けやすいという問題がある。



¹ 埼玉工業大学工学部電子工学科

¹ Department of Electronics Engineering, Saitama Institute of Technology, Saitama 369-0293, Japan

² 理化学研究所 脳科学総合研究センター

² Brain Science Institute, RIKEN, Saitama 351-0198, Japan

E-mail:cao@sit.ac.jp

図 1 MEG 装置と 64 センサーの配置

カナダ CTF 社製の MEG 計測装置の一例を図 1 に示す．計測実験は外部からの磁気ノイズを遮蔽するために非磁性材料で作られた磁気シールド室で行われる．頭部上にヘルメットのような形をした部分は磁束検出コイルとそれに対応している SQUID であり，それが常時に液体ヘリウムで冷却されている．測定データの収集やデータ処理装置の部分は磁気ノイズへの配慮でシールド室外に置かれている．

MEG の信号と環境雑音はどのぐらいレベルのものを見てみると，脳内活動によって発生する磁気は約 10^{-13} Tesla で，それはほぼ地球磁気の 1 億分の 1 程度のもので，極めて微弱な磁気信号と言える．一般都市環境に存在するいろいろな磁気雑音は数 10^{-6} Tesla であるが，これと比べて約数百万分の 1 程度ということになる．また，センサーの方から見れば，脳内活動の磁場強度より更に 1 オーダー下の高感度の SQUID センサーにとっては数 10^{-6} Tesla の環境雑音は非常に大きいと言える．実例として Phantom 実験による計測した信号を図 2 に示す．Phantom 実験とはプラスチック製の人頭模型の中に生理食塩水と電極を入れて，電極に正弦波電流を流し，ちょうど脳磁界と同じぐらいの磁場が発生するようにして測定したものである．この実験で測定したデータは全部で 256 試行 (1 試行 = 1 秒間) あり，第一試行のデータだけを図 2 に表示している．横軸は時間で，縦軸は 64 チャンネルのセンサーの出力強度を表している．この図を見れば，外れ値 (outlier) や雑音のパワーは信号より遥かに強いことが判る．Phantom 実験はもともと脳磁計システムの校正として採られている手段であるが，ここでは MEG 実験やアルゴリズムの検証など手段として使おうと考えている．




図 2 Phantom 実験による計測信号

3 脳信号解析のモデル

MEG 脳計測実験を行うある時刻に，脳内の複数箇所に神経群が活動している．これらの活動源は電源などの周囲の干渉源と互いに重なり合い，頭皮上に置かれたセンサーによって録られているとすると，図 3 に示しているように，脳計測・解析のモデルは次式のように表現できる．




図 3 脳信号解析のモデル

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \boldsymbol{\xi}(t), \quad t = 1, 2, \dots, \quad (1)$$

ここで，時刻 t における m 個チャンネルの観測信号を $\mathbf{x}(t) = [x_1(t), \dots, x_m(t)]^T$ とし，各々のチャンネルの観測信号 $x_i(t)$ は n 個の共通成分 $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$ (信号源) 及び一つの独自成分 $\boldsymbol{\xi}(t) = [\xi_1(t), \dots, \xi_m(t)]^T$ (雑音源) による構成される．MEG 計測の場合には，頭蓋骨や脳内組織の透磁率が真空の透磁率とほぼ同じであるため，共通成分に比例係数 $\mathbf{A} \in \mathbb{R}^{m \times n} = (a_{ij})$ は i 番目のセンサーと j 番目の信号源との物理距離に関係する一つの定量と考えられる．上記のモデルに対して次の説明を付き加える．

- 実験内容や状況に応じて，共通成分 $\mathbf{s}$ は刺激による誘発反応，脳内自発成分 (例えば α 波)，心臓や眼球などの動き成分 (Artifacts)，環境干渉成分 (例えば 50/60Hz の電源干渉) などの成分を含んでいる．これらの成分の高次モーメント (尖度 kurtosis) を調べてみると，誘発反応や Artifacts のような成分は正の kurtosis を持ち，電源干渉の成分は負の kurtosis を持つ．また，脳内自発成分の kurtosis は 0 に近づく．このことから，それぞれの共通成分が持っている高次統計性質が異なり，ICA による共通成分の分解には十分な可能性がある．また，super-Gaussian, sub-Gaussian 及び Gaussian が混在するため，それに応じる ICA アルゴリズムの適用が必要である．
- 式 (1) の定義から，信号源或いは共通成分 $\mathbf{s}$ の特徴は少なくとも二つ以上のセンサーに寄与することである．信号源 $\mathbf{s}$ のなかよく雑音 (脳内背景雑音や電源干渉源) と呼ばれているものがあっても，共通成分に属すれば信号源と名づけている．一方，独自成分 (雑音源) $\boldsymbol{\xi}$ の場合には，多くても一つのセンサーにしか寄与しない．独自成分は個別のセンサーの熱雑音によるものと考えられる．共通成分と独自成分は式 (1) または成分がセンサーへ寄与する数で区別することができる．また，共通成分と独自成分に対する処理方法も異なっていることが多い．

- 数値行列の要素 a_{ij} は一般瞬時空間モデルのようなランダム数値と設定されることなく，センサー配置の物理制約により比例係数と考えられる．このことから，理想状態で計測した信号は局所的

に滑らかな分布をしているはずである．逆に局所の計測信号の振幅は極端に不均一な分布であるとき、余計な成分がセンサーに加えられたということを意味する．この余計な成分は式 (1) のモデルから独自成分 (雑音源) しか考えられない．一例を挙げると、図 2 に示すような Phantom 実験の計測信号および図 1 のセンサー配置図を対照的にみると、センサー L11 の信号は高い振幅を持つが、L11 近所のセンサー L12 と L21 の信号は比較的弱い．これはセンサー L11 に雑音成分が寄与したことを示している．このような識別の方法を利用すると、モデルの設定やアルゴリズムの適用などに効果的である．

- センサーの数は MEG 装置により固定されている．信号源の数は未知であるため、例えば交差確認法 (the cross-validation technique) などの方法を用いて理論上に推定を行うことができるが、脳内の神経活動源を考えると、その数は無限個になるかもしれないことから、現実では観測信号からパワーが大きな脳内成分を限定して複数個の有用なものを抽出することが多い．
- 式 (1) においては、信号源 s とその数 n 、雑音源 ξ および行列 A が未知で、計測信号 x が既知である．信号源 s の各成分は互いに独立で、雑音源 ξ とともに独立であるとする．更に雑音源 ξ の各成分も互いに独立であると仮定する．この条件のもとに、計測信号 x だけを利用して脳内活動を再構成する．

4 脳信号処理の方法

本節では、同期平均加算、主成分解析法 (PCA: principal component analysis)、因子解析法 (FA: factor analysis) 及び独立成分解析 (ICA: Independent Component Analysis) などの方法を、Phantom データの処理例を付き加えて概説する．




図 4 同期平均処理．左図：256 秒の生データを秒ごと同期平均加算した信号．右図上：原信号のマップ；右図中：電流双極子の理論マップ；右図下：誤差マップ．

図 2 に示すような単試行の計測信号 (生データ) は非常に雑音が多く、望ましい成分を直接に読み取ることはできない．こうした信号を処理する典型的な方法では、同じ条件のもとで同一実験を複数回繰り返し、計測信号を同期平均加算する処理が行われる．一例としては Phantom の生データを秒ごと平均加算すれば、ラン

ダム性の雑音が相殺され、図 3 に示す結果が得られる．なお、この例では全ての非ランダム性の外れ値成分が予め手動で取り除いていた．

次に平均加算された信号に対する位置推定を行うときに、ダイポール推定法はよく使われている．この方法は脳内に電流双極子を配置し、この電流双極子を作る磁場分布の理論値と計測値の差を計算し、残差を最小にするように電流双極子の位置と大きさを少しずつ更新しながら求めるというものである．この例では電流双極子が中心位置に推定されている．

脳信号処理では常に少試行データと高精度の解析が要求されている．同期平均加算法の適用ではランダム性の雑音を除去することができるが、平均加算をするとは脳活動のダイナミックなどの有用な情報が失われてしまう恐れがある．そのため、雑音が多い単試行データを対象に効果的な解析法の開発が求められている．次に PCA, FA, ICA のデータ解析法について述べる．

式 (1) を書き直すと、計測信号は

$$X_{(m \times N)} = A_{(m \times n)} S_{(n \times N)} + \Xi_{(m \times N)}, \quad (2)$$

と表記できる．上式にサンプル数 N は十分多いとき、生成モデルの共分散行列は

$$\Sigma = AA^T + \Psi, \quad (3)$$

となる．ここで、 $\Sigma = XX^T/N$ で、 $\Psi = \Xi\Xi^T/N$ である．上式に独立条件 $SS^T/N \rightarrow I$ と $S\Xi^T/N \rightarrow 0$ を利用した．便宜上 X を $\sqrt{N}$ により正規化し、計測信号の共分散行列 $C = XX^T$ を利用する．

信号対雑音比率 (SNR: the signal-to-noise ratio) が比較的に高い場合には、例えば平均加算をした信号、その雑音分散 Ψ が無視できる．この場合、評価関数は AA^T を C に近づくように設定することが出来る． AA^T の解は主成分解析による求められる．ここでは、固有値分解法を用いた n 個の主成分は

$$\hat{A}\hat{A}^T = U_n \Lambda_n U_n^T \quad (4)$$

により求められる．ここで、 Λ_n は対角行列で、その要素はデータの共分散行列 C の n 個の固有値であり、 U_n は固有ベクトルである．上式から可能な推定値 $\hat{A}$ として

$$\hat{A} = U_n \Lambda_n^{1/2} \quad (5)$$

が得られる．ここで、 $\hat{A}^T \hat{A} = \Lambda_n$ となるので、 $x = \hat{A}z$ から、主成分の得点 (直交変換された信号) は

$$z = \Lambda_n^{-1/2} U_n^T x \quad (6)$$

により求められる．ここで、共分散 $E\{zz^T\} = \Lambda_n$ であることから、変換されたデータ z の各成分は互いに無相関であることが判る．

次に直接測定された単一試行信号の場合には、SNR が低いため Ψ が無視できない．PCA の考え方にやや異なるが、この場合には AA^T をデータの共分散行列 C に近似するではなく、データの共分散行列から雑音の共分散を引いたもの $C - \Psi$ に近づくように設定しなければならない．これは因子解析の角度から解釈すると、独自因子のパワー (分散) を抑えて、共通因子の無相関を求めることになる．但し、雑音の共分散 Ψ は未知であるため、 A を推定すると同時に Ψ の推定

も必要がある．この場合の評価関数は次のように定義する．

$$L(\mathbf{A}, \Psi) = \text{tr}[\mathbf{A}\mathbf{A}^T - (\mathbf{C} - \Psi)][\mathbf{A}\mathbf{A}^T - (\mathbf{C} - \Psi)]^T \quad (7)$$

上記の評価関数を最小化にして， $\frac{\partial L(\mathbf{A}, \Psi)}{\partial \Psi} = 0$ により，雑音の共分散 Ψ は次式のように

$$\hat{\Psi} = \text{diag}(\mathbf{C} - \hat{\mathbf{A}}\hat{\mathbf{A}}^T) \quad (8)$$

推定される．推定値 $\hat{\mathbf{A}}$ は式 (7) を最小化にして求められるが，式 (4)-(5) に示す固有値分解法による推定値 $\hat{\mathbf{A}}$ を求めることも出来る．一旦推定値 $\hat{\mathbf{A}}$ と $\hat{\Psi}$ が得られたら，一般化された逆行列は

$$\mathbf{Q} = [\hat{\mathbf{A}}^T \hat{\Psi}^{-1} \hat{\mathbf{A}}]^{-1} \hat{\mathbf{A}}^T \hat{\Psi}^{-1} \quad (9)$$

により求められる．それにより，共通因子は $\mathbf{z} = \mathbf{Q}\mathbf{x}$ で求められる．

上記の PCA や FA では信号源の無相関を求めているが，互いに独立な信号源を求めているわけではない．独立成分を求めるために，前回基礎シリーズで論じたように独立成分解析法を適用する必要がある．ここでは，直交変換された信号 $\mathbf{z}$ を用いて各成分が互いに独立な復元信号

$$\mathbf{y}(t) = \mathbf{W}\mathbf{z}(t) \quad (10)$$

により再構成させることを考えている．独立成分解析のアルゴリズム

$$\Delta W(t) = \eta(t)[I - \varphi(\mathbf{y}(t))\mathbf{y}^T(t)]W(t) \quad (11)$$

を利用することができる．但し，非線形関数 $\varphi(\cdot)$ の各成分 $\varphi_i(y_i) = -\frac{\dot{p}_i(y_i)}{p_i(y_i)}$ は信号の確率密度関数 $p_i(\cdot)$ に依存している． $p_i(\cdot)$ は通常未知であるので，適当な方法で非線形関数の近似が必要である．

上記の情報理論に基づいた独立成分解析アルゴリズム [2,9] を利用するほかに，近年高次統計に基づいた多種類の独立成分解析アルゴリズムを脳信号処理に適用することができる [3,4]．計算アルゴリズムの MATLAB コードも公開されている．

上述した PCA, FA 及び ICA を適用し，図 2 に示す第一試行信号 (1 秒間) に対する処理結果を図 5 に示す．PCA を利用する場合には，雑音の分散が正弦信号の分散より大きい場合，見つけれられた第一成分は当然雑音を主軸に射影したものになってしまう．FA を利用する場合には，雑音の分散を低減させ，共通因子から正弦波の成分を見つけたが，時間 0.2 ~ 0.3 間にある外れ値成分が分解し切れないことが判る．それに ICA を適用すると，外れ値成分が完全に分解され，よりが正確な正弦波が得られたことが判る．




図 5 PCA, FA 及び ICA による単試行 Phantom 信号の処理結果

上記の例においては，ICA では原信号の時系列波形を求めたが，原信号の位置を求めるためには分解された原信号の成分が何らかの形でセンサー上に戻らなければならない．独立成分解析で述べられたように，ICA で分解された成分の順番やスケールは一般的に原信号と異なっている．ICA で分解された成分のスケールがセンサー上の強度に影響されるかどうかについては簡単に説明すると， $\mathbf{G}$ を分解ための合成行列， $\mathbf{y}$ を推定された独立成分とすると，

$$\mathbf{A}\mathbf{s}(t) = \mathbf{x}(t) = \mathbf{G}^{-1}\mathbf{y}(t) \quad (12)$$

から判るように $\mathbf{G}$ が正しく推定されれば， $\mathbf{y}$ と $\mathbf{s}$ の大きさが異なっても $\mathbf{x}$ の強度に影響しない．

一つの独立成分だけを選択してセンサー上に射影する場合には，注目する独立成分 y_i とそれに対応して

いる G の逆行列の列ベクトル $\hat{g}_i$ を利用して

$$\hat{x}(t) = \hat{g}_i y_i(t) \quad (13)$$

のように算出することができる．例えば，図 5 の下段に示す IC3 の正弦波成分をセンサー上に射影すると，図 6 の左側に示す結果となる．




図 6 左図：分解された正弦波の投影，右図：位置推定

図 6 の結果を図 4 と比較すると，使用データ数においては ICA が 1 秒間のサンプルに対して平均加算の場合には 256 秒間のサンプル数を使用した．位置推定結果においては ICA が適される場合の累計誤差が 2.705% に対して平均加算の場合には 3.61% になった．少なめのサンプル数に対する高精度の推定結果を得たのは ICA の計算効果に対して高い評価ができる．

5 単試行聴覚誘発の信号処理例

単試行の Phantom 信号の解析は MEG 計測システムの校正やアルゴリズムの検証などに非常に役に立つ．このような解析手法を実際の脳計測信号に生かせば，ダイナミックな脳活動が可視になるのが有望である．本節では聴覚誘発信号処理について検討する．

聴覚誘発実験による測定信号は 0.6 秒間を 1 試行として全部で 630 試行ある．各試行開始から 0.2 秒の時刻に 1kHz の純音を両耳に与える．第 1 試行の信号を図 7 に示す．




図 7 聴覚誘発実験による第 1 試行信号 (刺激：0.2 秒)

全記録 630 試行の信号を同期して平均加算すれば，図 8 の左側に示す結果が得られる．この結果を見ると，付

加雑音や背景雑音の成分が低減され，100 ミリ秒のところに大きな誘発成分が現れていることが判った．また，平均加算したデータを利用して 2 個のダイポールで位置推定を行うと，図 8 の右側に示すマップが得られている．このマップを見ると，側頭葉に左右対称の二つの誘発磁界があり，刺激に対する最大の活動強度は 330fT であることが判った．




図 8 左：630 試行の平均加算，右：平均誘発磁界

上図の活動強度は平均化されたもので，630 回刺激のうちに何回目の刺激によるものではない．それは平均加算の問題点であり，即ちデータを平均化処理すると，信号対雑音の比率 (SNR) は確かに上がるが，一部の有用な情報も無くなってしまいう可能性がある．この場合には各試行間の強度変化の情報が失われ，各刺激に対応する誘発活動成分の強度は見ることができない．そのために単一試行データの解析が必要であると考えられる．また，同じ単試行データ解析と言っても，脳データ処理の目的は Phantom データ処理のとはやや違い，脳信号処理の場合には脳活動の位置情報だけでなく，誘発成分の強度や強度変化の情報を可視化することも重視している．

単試行聴覚誘発信号前処理においては，まず観測雑音の低減や信号間の相関除去と次元縮約などの手続きを行い，前処理したデータを利用して信号源の独立成分に分解を行った．これらの処理で求められた第 1 試行信号に対する結果を図 9 (上) に示す．この結果を見れば，IC1 と IC3 は 100 ミリ秒附近に大きなピークがあり，誘発磁界である可能性が高い．IC2 の周波数は約 10Hz で，アルファ波である可能性が高い．IC4 は高い周波数の成分で脳外の共通雑音源と考えられる．IC1 ~ IC3 をそれぞれセンサー上に射影し，ダイポール位置を推定した結果を図 9 (下) に示します．これらの結果を見れば，IC2 は後頭部にあり，アルファ波が典型的に現れている場所に当たる．IC1 と IC3 の位置は平均化マップ (図 8 右) に示している側頭葉左右二つの誘発磁界とそれぞれ対応しているが，IC1 と IC3 の活動強度は平均化されたものと異なり，IC1 の最大強度は 184fT で，IC3 の最大強度は 721fT である．即ち，第 1 回目の刺激を両耳に与えた後，試験者の左側頭葉の反応 (IC3) が最も大きく，右側頭葉の反応 (IC1) が平均値より下回ることが判った．




図9 第1試行データの処理結果．上図：分離した独立成分の波形；左図：IC1の位置と活動強度；中図：IC2の位置と活動強度；右図：IC3の位置と活動強度．

次に平均処理された成分と独立成分解析による分解された成分からそれぞれ推定された電流双極子の位置を図10に示す．




図10 電流双極子の位置図．上図：座標系；2段目の図：平均加算した成分から推定された電流双極子の位置図；3段目の図：IC1から推定された電流双極子の位置図；

位置図；下図：IC3から推定された電流双極子の位置図．

頭のかたちを球で近似し、球中心座標を $[x, y, z] = [0, 0, 0]$ とすると、図10に示している左右側頭葉二つの電流双極子の位置座標はそれぞれ $[\hat{x}, \hat{y}, \hat{z}]_L^{ave} = [-0.6, 4.9, 6]^{ave}$ と $[\hat{x}, \hat{y}, \hat{z}]_R^{ave} = [1.7, -5.6, 6]^{ave}$ である．これに対応しているIC3の位置座標は $[\hat{x}, \hat{y}, \hat{z}]_{IC3}^{Tr1} = [-1.2, 3.9, 4.7]_{IC3}^{Tr1}$ で、IC1の位置座標は $[\hat{x}, \hat{y}, \hat{z}]_{IC1}^{Tr1} = [0.5, -1.8, 7.3]_{IC1}^{Tr1}$ である．IC1とIC3の位置座標を平均化されたものと比較すれば、やや離れているが、IC1とIC3は第1試行から分解された成分であり、それぞれ右側頭葉、左側頭葉の聴覚情報処理による磁場分布に相当していると考えられる．

また、ICAを第4試行の信号に適用すると、図11に示している結果が得られる．この結果を図9と比較すれば、活動磁場源の強度、IC1は184 → 516 fTで、IC3は721 → 201 fTのように変化していることが判った．




図11 第4試行信号の処理結果．左図：IC1の位置と活動強度；右図：IC3の位置と活動強度．

この解析結果から、同様の刺激に対して右側はだんだん敏感になり、左側はだんだん鈍感になっていること（聞きなれ）が判る．正確なことを言うためにはより詳細な実験を行う必要があるが、独立成分解析による計測信号の分解によって原信号強度の経時変化を取り出すことができ、情報を処理する左右の脳の動きの違いをより詳しくみることができると考えられることを示しているといえるだろう．

6 おわりに

本稿では、MEG計測および信号処理の実例を取り上げ、データの計測、解析モデル、解析方法及び解析結果について概説した．人間の脳内聴覚野が純音に対する反応の生理学的実験に基づいて測定した信号を解析することにより、これまでほとんど重視されていない反応強度などの脳内情報が独立成分解析により、可視化になることが一歩の前進であり、今後聴覚系の情報処理における機能の解明に役に立たせることを期待している．

References

- [1] 曹 建庭：“単一試行脳磁界データの解析”，[甘利俊一・村田 昇 共編著]：“独立成分解析 - 多変量データ解析の新しい方法”，数理科学 Senior & Graduate Courses ライブラリー—18, 分担執筆：第12章 サイエンス社, p.1, p.153, pp.85-94, Nov. 2002.
- [2] A.T. Bell and T.J. Sejnowski, “An information maximization approach to blind separation and blind deconvolution,” *Neural Computation*, vol. 7, no. 6, pp.1004-1034, 1995.
Matlab code in WWW : <http://www.cnl.salk.edu/~tony/ica.html>
- [3] J. F. Cardoso and A. Souloumiac, “Jacobi angles for simultaneous diagonalization,” *SIAM J. Mat. Anal. Appl.*, vol. 17, no. 1, pp.145-151, 1996.
Matlab code in WWW : <http://sig.enst.fr/~cardoso/jointdiag.html>
- [4] A. Hyvärinen and E. Oja, “A fast fixed-point algorithm for independent component analysis,” *Neural Computation*, vol. 9, pp.1483-1492, 1997.
Matlab code in WWW : <http://www.cis.hut.fi/~aapo/>
- [5] S. Ikeda, “ICA on noisy data : A factor analysis approach,” in *Advances in Independent Component Analysis*, Edt. M. Girolami, Springer, 2000.
- [6] S. Makeig, A. J. Bell, T. -P. Jung and T. J. Sejnowski, “Independent component analysis of electroencephalographic data,” *Advances in Neural Information Processing System 8*, MIT press, pp.145-151, 1996.
- [7] R. Vigário, J. Särelä, V. Jousmäki, M. Hämmäläinen and E. Oja, “Independent component approach to the analysis of EEG and MEG recordings,” *IEEE trans. Biomed. Eng.*, vol. 47, no. 5, pp.589-593, 2000.
- [8] J. Cao, N. Murata, S. Amari, A. Cichocki and T. Takeda, “Independent component analysis for unaveraged single-trial MEG data decomposition and single-dipole source localization,” *Neurocomputing*, ELSEVIER, 49, pp.255-277, 2002.
- [9] J. Cao, N. Murata, S. Amari, A. Cichocki and T. Takeda “A robust approach to independent component analysis with high-level noise measurements,” *IEEE Trans. on Neural Networks*, May 2003.