

Independent Component Analysis を用いた MEG データの解析

池田 思朗

村田 昇

理化学研究所脳科学総合研究センター情報創成システム研究チーム

〒 351-0198 埼玉県和光市広沢 2-1 Email: {shiro,mura}@brain.riken.go.jp

あらまし MEG (Magnetoencephalography, 脳磁計) は, 脳外から無侵襲で脳活動を捉える計測法として注目を集めているが, 脳から発生される磁場は極めて微弱 (地磁気の数億分の一程度) であるため, 雑音除去が重要な問題となる. 従来の方法ではシールドルーム, 別センサーによる外部磁場の測定 (リファレンスチャンネル), 及び加算平均を併用し, 脳内活動の計測を行っている. 本研究では Molgedey & Schuster が提案した相関関数を用いた時間構造に基づく独立成分分析 (Independent Component Analysis) により, 外部雑音, 地磁気の変化, 電源ノイズ等の除去し, 抽出されたノイズと独立な成分を用いることにより, 従来に比べ少い加算平均回数でダイポール推定を行う. 島津製作所製の MEG によって計測されたデータを用いて行った実験の結果を報告する.

脳磁計, 独立成分分析, ダイポール推定

MEG data analysis using ICA

Shiro Ikeda

Noboru Murata

Lab. For Info. Synthesis, Brain Science Institute, RIKEN

2-1 Hirosawa, Wako, Saitama 351-0198 Email: {shiro,mura}@brain.riken.go.jp

Abstract MEG (Magnetoencephalography) is one of the promising ways to analyze the activity of the brain. One of the problems in analyzing MEG is the noise. Since the signals from the brain is extremely small compared to the earth magnetism (10^{-9}), it is important to remove the noises. Usually MEG is recorded in a shielded room, and also some external sensors are used to estimate the background noise(reference channels) and a digital band passed filter and averaging are applied to the data. In this technical report, we applied ICA (Independent Component Analysis) to the data. The algorithm for ICA is the one propose by Molgedey and Schuster. As the result, we can remove the earth magnetism and the noise from electric power supply. Using the extracted source signal, we estimated the location of the dipole with very high accuracy. We used the data from Shimadzu.

MEG, ICA, dipole estimation

1 はじめに

MEG (Magnetoencephalography, 脳磁計) は、非侵襲で脳内の神経活動を捉える方法として注目を集めている。現在稼働している機器では時間分解能にして 500Hz-1000Hz 程度、空間分解能にして 5mm-1cm 程度の情報が得られると考えられている。

例えば MRI (Magnetic Resonance Imaging, 磁気共鳴画像) を脳内活動の観測に応用した場合は空間分解能は 5mm 以下と優れるが、脳内の神経活動を直接捉えている訳ではなく神経活動により消費された酸素を供給する過程を副次的に観測しているため、時間分解能は数秒ないし数十秒と遅く、神経活動の起こる部位と酸素の供給の多い部位とは必ずしも一致しない。このため活動部位の推定を行なう上では注意が必要であるという指摘もある。また外部から強力な磁場を作用させるため、厳密には非侵襲と言えない。PET (Positron Emission Computed Tomography, 陽電子造影法) も MRI とほぼ同様な時空間分解能ではあるが、ポジトロン核種と呼ばれるラジオアイソトープ (RI) で標識された放射性医薬品を体内に入れるため複数回に渡る計測には問題がある。EEG (Electroencephalography, 脳波) は時間分解能は MEG と同程度であるが、透磁率が物質によらずほぼ一定で真空中と大差がないのに対し、導電率が物質により大幅に異なるためその伝達特性は極めて複雑となる。したがって計測値から逆問題として信号源の推定を行なう解析に際して、3 層あるいは 4 層で頭蓋の構造を近似し境界要素法を用いるといった非常に複雑な計算が必要される。また電極の配置等の問題から、通常は計測点数が数十程度に限られる等の精度の点でも問題がある。

以上のようにその他の計測法と比べ MEG は時間分解能と空間分解能を実用上十分に両立しつつ、信号の伝達機構が比較的単純なためその解析が容易であるという利点を持つ。

一方脳から発生される磁場は極めて微弱 (地磁気の数億分の一程度、表 1 参照) であるため、MEG においては雑音除去が重要な問題となる。主な雑音源としては地磁気、商業電源、ブレインノイズと呼ばれる注目していない脳部位の神経活動、SQUID (super quantum interference device) の量子力学的雑音があげられるが、シールドルーム、別センサーによる外部磁場の測定 (リファレンスチャンネル) を併用しながら、同一条件下で複数回計測されたデータを加算平均することにより信号雑音比を上げるのが従来のやり方であった。

本稿では異った信号源から発生され重畳して観測された信号を、統計的な独立性に基づいて分析する手法である独立成分分析 (Independent Component Analysis, ICA) を応用し、計測された信号の中から着目する信号成分を分離・抽出し解析する可能性を探る。島津製作所製の

表 1: 信号および雑音の強度と周波数

	強さ T	周波数 Hz
信号		
脳磁場	$\sim 10^{-14}$	a few ~ 20
全センサーに共通な雑音		
地磁気	$\sim 10^{-4\sim-5}$	a few ~ 10
(シールドルーム内)	$\sim 10^{-11}$	
商業電源	$\sim 10^{-13}$	50 or 60
各センサーで独立な雑音		
量子力学的雑音	\sim 信号	白色雑音

MEG によって計測されたフォントムデータ (生理食塩水に満たされた球内に置かれたダイポール) に信号の時間構造に着目し相関関数を利用した独立成分分析を適用し独立な成分をノイズとダイポールによる信号成分に分けることにより、従来に比べ少ない加算平均回数でダイポール位置推定を行ないうることを示す。また被験者を用いた実験では平常時の計測磁場から加算平均を行なうことなしに α 波や β 波などによる信号成分を抽出することができることを示す。

2 相関関数に基づく独立成分分析

主成分分析 (Principal Component Analysis, PCA) がその強さに基づいて信号を幾つかの成分に分解するのに対し、独立成分分析は複数の異なる観測から原信号間の独立性によって複数の信号を分離する手法であり、画像処理における加法的な雑音の除去、通信分野における混線信号 (crosstalk) の分離、音声認識の前処理、多点計測されたレーダー・ソナー信号の前処理といった場面で応用が考えられている。

我々が問題としている MEG データの場合、着目したい情報に比して雑音成分が大きいため、主成分分析を観測された信号にそのまま適用することは妥当ではなく、通常は加算平均などの前処理により雑音成分を減衰させてから主成分分析を行なうといった方法が取られる。加算平均をするためには音や光、あるいは特定の動作などの外部刺激によって、特定の脳内活動を誘発する必要があるが、こうした活動は厳密に一樣な時間構造で誘発されるとは限らず、加算平均は本来着目しようとしている信号波形を崩す可能性もある。また外部刺激による誘発を行なうことが難しい場合には、単発信号は雑音により乱されておりそのままでは解析が難しく、癲癇の発作など信号が著しく強いものに限られている。したがって信号の解析にあたっては、加算平均等の処理をできる限り用いないことが望ましい。

本稿では以下の手続きにしたがい、観測された信号を統計的に独立性の高い信号に分解する。

信号を

$$s(t) = (s_1(t), \dots, s_n(t))^T, \quad t = 0, 1, 2, \dots \quad (1)$$

で表わし、その各成分は相互に独立であるとして条件

$$p(s_i(t), s_j(t')) = p(s_i(t))p(s_j(t')), \quad \forall t, t', i, j (i \neq j). \quad (2)$$

を満たすと仮定する。センサーにより観測される値

$$x(t) = (x_1(t), \dots, x_n(t))^T. \quad (3)$$

は、伝達経路の違いにより異なる減衰を受けながら重畳され、ある正則な行列 A により

$$x(t) = As(t), \quad (4)$$

なる変換を受けるとする。独立成分分析の目標は行列 A を知ることなく、

$$y(t) = Bx(t) \quad (5)$$

により分解された信号 $y(t)$ の各要素が相互に独立となるような行列 B を探すことである。理想的には $B = A^{-1}$ となることが望ましいが、 s の大きさ、および順序に関しては不定性が残り、結局ある置換行列 P と対角行列 D を用いて

$$BA = PD \quad (6)$$

を満たす B を推定することになる。

主な手法としては

- y の同時分布と各成分の周辺分布が独立性の条件を満たすように行列 B を決定する [1, 2, 4, 5],
- y の各成分の相関のみに着目して、任意の時間において相互に無相関となるように行列 B を決定する [6],
- y を定常過程とみて、その相互相関関数が 0 となるように行列 B を決定する [7],

等の手法が提案されている。本稿では、このうち相互相関関数に着目した方法を用いる。

信号 s は弱定常過程であると仮定する。観測値 x の相互相関行列は

$$\begin{aligned} & \langle x(t)x(t+\tau)^T \rangle \\ &= A \langle s(t)s(t+\tau)^T \rangle A^T \\ &= A \begin{pmatrix} R_{s_1}(\tau) & 0 & \dots & 0 \\ 0 & R_{s_2}(\tau) & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & R_{s_n}(\tau) \end{pmatrix} A^T, \quad (7) \end{aligned}$$

と表わされる。ここで $R_{s_i}(\tau)$ は原信号 $s_i(t)$ の自己相関関数とする。適当な行列 B により (6) が満たされるとすると、再現された信号 y の相関行列は

$$\begin{aligned} & \langle y(t)y(t+\tau)^T \rangle \\ &= \langle (PDs(t))(PDs(t+\tau))^T \rangle \\ &= \begin{pmatrix} \lambda_{1'}^2 R_{s_{1'}}(\tau) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_{n'}^2 R_{s_{n'}}(\tau) \end{pmatrix} \quad (8) \end{aligned}$$

となる。ただし $1', 2', \dots, n'$ は置換行列 P による添字 $1, 2, \dots, n$ の適当な置換を表わし、 λ_i は対角行列 D の第 i 要素を表わす。行列 P 、 D の不定性はあるものの、最適な行列 B は全ての時間差 τ において相関行列を対角化するものとして特徴付けられる。

Molgedey と Schuster [7] はこの考えに基づいていくつかの時間差において相関行列を対角化する行列 B をある行列の族から選ぶ問題として定式化した。

$$B \langle x(t)x(t+\tau_i)^T \rangle B^T = A_i, \quad i = 1, \dots, r, \quad (9)$$

ここに A_i は対角行列である。

具体的に (9) を求めるアルゴリズムとして、Molgedey と Schuster は損失

$$L(B) = \sum_{i=1}^r \sum_{j \neq k} |B \langle x(t)x(t+\tau_i)^T \rangle B^T|_{jk}^2 \quad (10)$$

を最小化する最急降下法に基づいた方法を提案している。また繰り返し演算によらない方法としては“sphering” (図 1) と “rotation” (図 2) を用いる次の方法がある [8, 9]。

Sphering は主成分分析に基づいて原信号を直交化する変換である。まず以下のように観測値の相関行列を定義する。

$$V = \langle x(t)x(t)^T \rangle, \quad (11)$$

行列 V は正定であるから、適当な直交行列 S と対角行列 A により

$$V = SAS^T, \quad (12)$$

と書けるが、これを用いて行列 V の平方根を

$$\sqrt{V^{-1}} = \sqrt{A^{-1}}S^T \quad (13)$$

により定義する。ただし $\sqrt{A^{-1}}$ は対角行列 A^{-1} の各成分の平方根をその値とする対角行列である。観測値を

$$x'(t) = \sqrt{V^{-1}}x(t), \quad (14)$$

により変換することにより、変換後の信号 $x'(t)$ は直交化される、すなわち I を単位行列として

$$\langle x'(t)x'(t)^T \rangle = \sqrt{V^{-1}}V\sqrt{V^{-1}}^T = I, \quad (15)$$

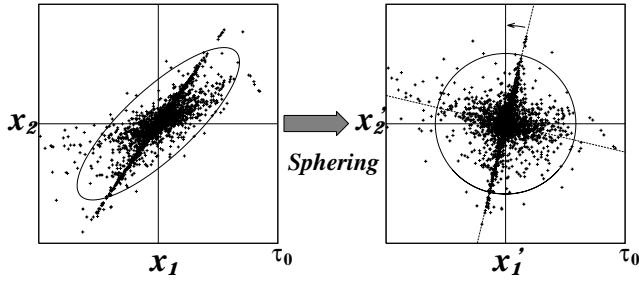


図 1: Sphering

となる。

Sphering 後も信号は回転に関する不定性を持つが、この不定性はいくつかの時間差における相関行列の非対角成分を小さくすることにより解消される (図 2)。実際には適当な回転行列 C により

$$\sum_{k=1}^r \sum_{i \neq j} |(CM_k C^T)_{ij}|^2, \quad (16)$$

を最小化することにより実現される。ただし

$$M_k = \langle \mathbf{x}'(t) \mathbf{x}'(t + \tau_k)^T \rangle, \quad k = 1, \dots, r. \quad (17)$$

とし、 $(CM_k C^T)_{ij}$ は行列 $CM_k C^T$ の ij 成分を表わすとする。回転行列はユニタリー行列であるので、任意の行列 Q に対し、 $\sum_{i,j} |(CQC^T)_{ij}|^2$ は保存される。したがってこの条件下で (16) 式を最小化すれば良い。この最小化においては Jacobi 型のアルゴリズムが存在することが Cardoso と Souloumiac [3] により示されている。

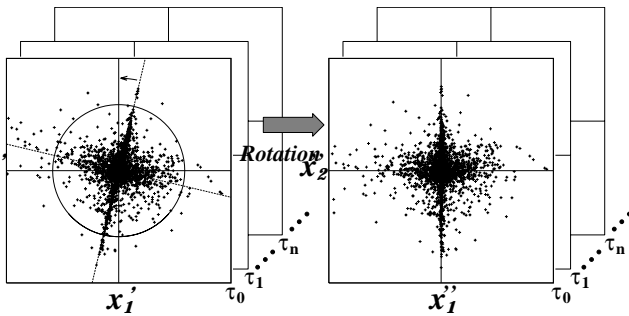


図 2: Rotation

以上の 2 つの手続きを経て行列 B は

$$B = C\sqrt{V^{-1}} \quad (18)$$

により与えられることになる。

この方法の利点は 2 次の統計量しか使わないことであり、そのため離れ値や雑音に対してロバストな推定が行なえる。また上記説明においては原信号に弱定常性を仮定したが、実際には適当な T と τ_k に対して

$$\frac{1}{T} \sum_{t=0}^T \langle \mathbf{x}'(t) \mathbf{x}'(t + \tau_k)^T \rangle \sim \frac{1}{T} \sum_{t=0}^T \mathbf{x}'(t) \mathbf{x}'(t + \tau_k)^T \quad (19)$$

が満たされれば十分である。

得られた B を用いることにより $\mathbf{y}(t) = B\mathbf{x}(t)$ によって信号を独立な成分に分離できる。しかしこの $\mathbf{y}(t)$ を原信号 $\mathbf{s}(t)$ と比べると、大きさと順序の入れ換えの任意性は残ったままである。MEG のデータの解析においては脳内に適当なダイポールを仮定し各センサー上で理論的に得られる信号の強度と実際に各センサーで観測された信号の入力強度の差異を最小化するようにしてその信号源の位置を推定するのが一つの代表的な手法である。したがって得られた独立成分がどこから発生したものであるかを推定するためには、それがそれぞれのセンサーでどのような大きさで観測されたかを知る必要がある。この問題は B^{-1} を用いることにより解決する。すなわち、

$$\mathbf{z}_i(t) = B^{-1} \begin{pmatrix} 0 \\ \vdots \\ y_i(t) \\ \vdots \\ 0 \end{pmatrix} \quad (20)$$

とすれば $\mathbf{z}_i(t)$ の各成分は独立成分分析によって i 番目に出てきた成分の各センサー上での推定値が得られる。このとき $\mathbf{z}_i(t)$ は次の性質を満たすことに注意する。

$$\mathbf{x}(t) = \sum_{i=1}^n \mathbf{z}_i(t) \quad (21)$$

B によって一旦独立成分に分けられた信号は各成分ごとに B^{-1} によってセンサー上の推定値として戻されるため強度の任意性は無くなっている。MEG のデータに対して上記の処理を行い、得られた $\mathbf{z}_i(t)$ を用いればその成分に対応するダイポールの位置を推定することができる。

3 実験

3.1 ファントムを用いた実験

本節では独立成分分析を用いて行った MEG データの解析実験の結果を示す。以下の実験で用いたデータは全て島津製作所の測定によるものである。

まずコントロールされた状況の下で我々の提案する方法の精度を調べるために、ファントムを用いた電気双極子の位置の推定を行なった。ファントムとはプラスチック製の球の中に生理食塩水を満たし、その中に 1cm 程度の電極を埋めこんだものである。

この電極に 20Hz 程度の周波数の三角波に従う電流を流し、MEG によって計測した。通常はこのデータに対し図 3.a のように、まず Filtering(0.5~30Hz 程度の Band-Pass フィルタ) により電源ノイズや脳からは出ていないと思われる高周波のノイズを取り除き、次に

Averaging(100~200 回程度の加算平均) によりセンサーの量子ノイズや α 波, 瞬きといった脳自体から出るノイズを取り除くといった処理が施される本研究報告では, Filtering を行わないデータを用いて実験を行った. 図 3.b のように独立成分分析を行ったあと, 分離された独立成分の中から適当なものを選び, それを用いてダイポール位置の推定を行なった. これによって Averaging の効果を実験的に調べ, ダイポール位置の推定の為にどの程度の回数の平均化が必要かを調べた.

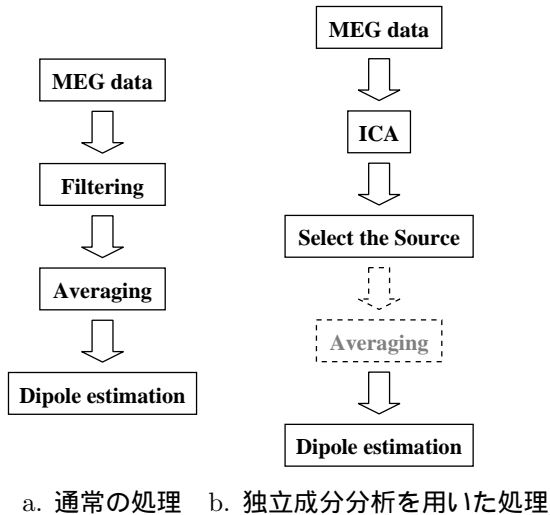


図 3: MEG データの処理の流れ

まず, 一回の観測による原信号を図 4 に示す. 図では全ての入力 126channel のうち, 5 個のみを示している. こ




図 4: 観測信号

れを見ると, 信号の強度は 1000[fT](femto Tesla, 10^{-15}

Tesla) の振れ幅を持っていることがわかる. 脳からの信号の強度はおおよそ 100[fT] の振れ幅であるので, 10 倍程度のノイズが含まれていることがわかる.

この一回の計測データから直流成分を除き, 前節で示した独立成分分析の手法を適用し, 信号を 126 の独立成分に分解した. 実際の信号には幾つの意味のある独立成分が存在するかは知ることはできない. しかしながら信号に含まれるノイズのため 126 の独立成分に分けることが可能である. 図 5 に, そのうちセンサー上での強度が最も大きい 5 つを示す. この図の上では, 全ての独立成分の平均は 0, 平均強度は等しくなっている. この結果




図 5: 独立成分

を見ると, 一番目の信号は地磁気を, 2,3 番目はその周波数を数えると 60Hz であり, 電源からくるノイズであると想像できる. 2 つ出てきているのは位相差を吸収するため位相の 90 度ずれたものが出てきたのだと考えられる. 4 番目の独立成分は 20Hz 程度であり, 電極への入力に対応するものと考えられる. 5 番目以降はノイズの成分が主であると考えられる.

この信号を (21) 式のように B^{-1} を使い, 元のセンサーの入力に戻してセンサー上での平均強度を求めてみた. 上の 5 つの独立成分に対してその平均強度を示したのが図 6 である. これから地磁気と電源からの信号は求めたい信号よりもかなり大きいことが分る.

次に, 同様の手法を他の計測データにも適用し, 得られた結果に対して順次加算平均を行っていった. 通常は filtering したのち, 平均化するわけだが, ここでは独立成分分析を行い, 信号と思われる成分を取り出し, (21) 式でセンサー入力の推定値に戻した上で加算平均した. 図 7 はあるセンサー (channel 1) に注目し, そのセンサーの入力が平均回数によって, どのように変化していくか




図 6: 独立成分の強度

を示している．それぞれ 1,2,4,8,16,32,64 回の平均によって得られた波形である．この平均化により波形が明瞭になっていく様子がわかる．




図 7: 平均化の効果

上記の操作を全てのセンサーに対して行い，その結果を用いてダイポールの位置を推定した．表 2 にその結果を示す．表中で X,Y,Z は推定された座標を示す．また E[mm] は 64 回の平均によって得られたダイポールの位置からのずれを示している．また，図中で GOF(Goodness of Fitness) とあるのは， $B_{ex}(i)$ を channel i での計測磁場， $B_{th}(i)$ を channel i における推定ダイポールの発生磁場

とし，

$$GOF = 100 \left(1 - \sum_i \frac{(B_{ex}(i) - B_{th}(i))^2}{B_{ex}(i)^2} \right) \quad (22)$$

により定義される量である．この結果から，GOF は平均

表 2: 加算平均によるダイポールの推定位置の違い

Ave	GOF[%]	X	Y	Z[mm]	E[mm]
1	94.58	-1.9	0.8	86.9	3.89
2	96.51	0.8	-0.6	85.6	1.73
4	98.00	1.2	-0.3	85.8	1.26
8	98.84	1.4	-0.3	86.3	0.73
16	99.06	2.0	-0.4	86.5	0.44
32	99.12	1.9	-0.4	86.9	0.10
64	99.24	1.8	-0.4	86.9	0.0

回数を増やす毎に良くなっている，すなわち，計測結果と理論値が一致していくことが分る．これは独立成分分析によって分けられた結果が各試行で正しく推定していることを示していると考えられる．一回の計測から，加算平均なしに 5mm 程度の誤差でダイポールの位置を推定できる．この結果から，本手法のように独立成分分析を用いることでダイポール位置の推定が少ない加算平均回数で精度良く推定可能であることが示せた．これはこの方法は一種の線形フィルターであるが，各センサーに独立な量子力学的雑音はセンサー間での加算操作により減衰される効果があるためとも考えられる．

3.2 生体信号への応用

以上の結果から独立成分分析を用いた信号処理により脳内活動の位置を平均化の操作無しでもかなり精度良く推定できる可能性があることが分る．

次に実際の脳のデータに対し，独立成分分析を行った結果を示す．この実験では被験者にできるだけなにも考えないようにしてもらい，10,30,50 秒で目を閉じるよう合図を送った．こうして計測した 1 分間のデータに対し，独立成分分析を行った．その結果図 8 のような独立成分が得られた．

6 番目に目を閉じるのと同期した信号が得られているのがわかる．この信号の強度は図 9 の通りである．1,2 番目の独立成分が極めて強く，これらが地磁気の成分であると考えられる．さらに，図 8 の 30 秒前後の信号を図 10 に拡大して示す．この結果から，3,9 番目はおそらく電源信号であると考えられる．また，4 番目の信号は強度的にも周波数的にも α 波ではないかと考えられる．この結果から，独立成分分析を用いて，脳内ノイズの分離も可能であると考えられる．

現在、この結果に基づきダイポールの位置推定の解析を行っている。




図 8: 独立成分




図 9: 独立成分の強度

4 まとめ

本稿では独立成分分析に基づく MEG データの解析結果を報告した。ファントムを用いた実験では 64 回加算平均したものと比較して約 5mm 程度のずれはあるものの、独立成分分析により加算平均することなしに雑音成分を取り除きダイポール位置の推定が可能であることがわかった。また生体信号を用いた実験においては、特徴的な神経信号である α 波および眼球運動により生じた信号を分離することができた。

今後は実際の脳計測に基づくデータを用い、本手法を適用し有効性を検証するとともに、独立成分分析とダイポール位置の推定法を直接結び付けて計算精度の向上を考える。

謝辞

MEG データを提共して下さった島津製作所に感謝致します。

参考文献

- [1] Shun-ichi Amari, Andrzej Cichocki, and Harvard Hua Yang. A new learning algorithm for blind signal separation. In David S. Touretzky, Michael C. Mozer, and Michael E. Hasselmo, editors, *Advances*

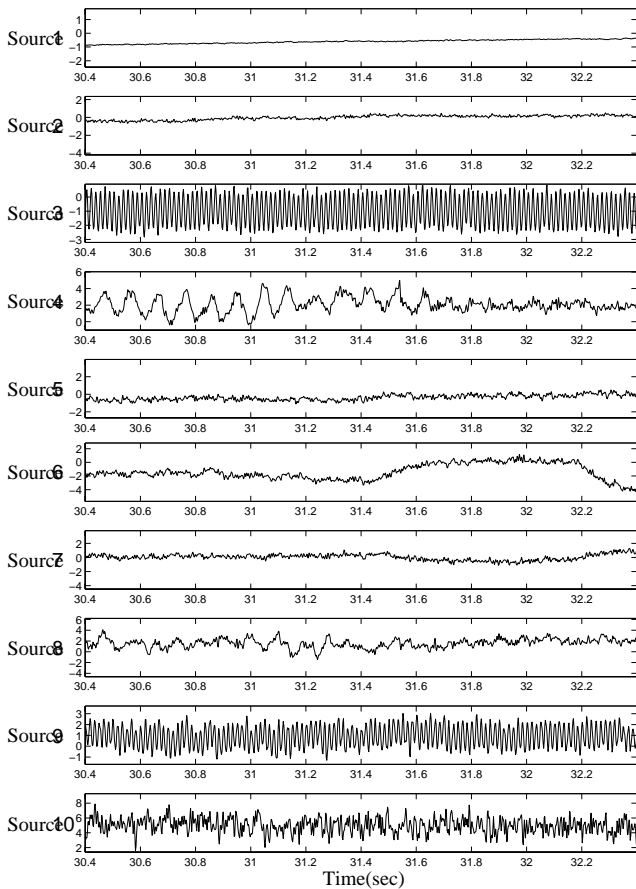


图 10: 独立成分

in *Neural Information Processing Systems 8*, pages 757–763. MIT Press, Cambridge MA, 1996.

- [2] Anthony J. Bell and Terrence J. Sejnowski. An information maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7:1129–1159, 1995.
- [3] Jean-François Cardoso and Antoine Souloumiac. Jacobi angles for simultaneous diagonalization. *SIAM J. Mat. Anal. Appl.*, 17(1):161–164, jan 1996.
- [4] Pierre Comon. Independent component analysis, a new concept? *Signal Processing*, 36(3):287–314, apr 1994.
- [5] Christian Jutten and Jeanny Herault. Separation of sources, part i. *Signal Processing*, 24(1):1–10, jul 1991.
- [6] Kiyotoshi Matsuoka, Masahiro Ohya, and Mitsuru Kawamoto. A neural net for blind separation of non-stationary signals. *Neural Networks*, 8(3):411–419, 1995.
- [7] L. Molgedey and H. G. Schuster. Separation of a mixture of independent signals using time delayed correlations. *Phys. Rev. Lett.*, 72(23):3634–3637, 1994.
- [8] A. Ziehe, K.-R. Müller, G. Nolte, B.-M. Mackert, and G. Curio. ICA analysis of MEG data. NIPS 97: Functional brain imaging workshop (workshop talk), 1997.
- [9] Andreas Ziehe. Statistische Verfahren zur Signalquellentrennung. Master’s thesis, Humboldt Universität, Berlin, 1998. (in German).