

# 独立成分解析の信号処理への応用

さきがけ研究 21 「情報と知」領域 池田 思朗

## 1 まえがき

独立成分解析 (ICA, Independent Component Analysis) は主成分分析 (PCA, Principal Component Analysis) と同様、多次元信号の解析手法である。PCA では信号の 2 次の相関のみに注目し、それらを無相関にする変換を求める。これに対し ICA は高次の統計量、あるいは時間的な相関に基づく独立性により信号を分離する変換を求める。正規分布以外の確率分布に対しては一般に無相関と独立性とは一致しない。したがって PCA と ICA は異なる結果を与える。

この ICA が近年注目されるようになったのは、問題の単純さとその応用の可能性からである。ICA では信号源が独立であるという仮定のみを置く。このことから Blind Source Separation と呼ばれ、この仮定に基づいて信号を分離する。

例えば脳計測によって得られたデータを考える。脳内では様々な部位が活動しており、それらが混合されて観測される。さらに外部からのノイズが加わる場合が多い。これらが独立だと考えられれば ICA の仮定が当てはまる。この他にも雑音の加わった画像、また複数の話者が同時に発声している信号を分離する問題などが挙げられる。ICA の手法を用いれば、これらが自動的に独立な成分として分離できるのである。

本稿では近年盛んに研究されている ICA について問題の定式化、代表的な解法、応用の現状について述べる [2]。

## 2 ICA の問題

本章では ICA の問題について説明する。ICA は Blind Source Separation (BSS) と Blind Source Deconvolution を含む総称として用いられる。BSS は時間遅れなく混合された信号に対して用いられ、Blind Source Deconvolution は時間遅れがある場合に用いられる。

まず BSS の問題を示す。信号源が次のベクトルで与えられるとする。

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

$s(t)$  の各成分の平均は 0、各成分は互いに独立であるとす。  $T$  は転置を表わす。観測は、

$$x(t) = (x_1(t), \dots, x_m(t))^T \quad t = 0, 1, 2, \dots$$

で表すものとする。これは  $m$  個のセンサーで観測された信号だと考えればよい。センサーの数  $m$  と信号源の数  $n$  は必ずしも一致しない。ここで  $s(t)$  と  $x(t)$  との間に、

$$x(t) = As(t), \quad (1)$$

という線型の関係を仮定する。 $A$  は  $m \times n$  の実数行列である。BSS の問題は  $s(t)$  の確率分布の形と  $A$  に関する知識を持たずに  $x(t)$  を  $n$  個の独立な信号成分に分離することである。

$n \leq m$  であるならば解は存在する。すなわち、ある  $n \times m$  の実数行列  $W$  が存在し、

$$y(t) = Wx(t), \quad (2)$$

によって互いに独立な  $y(t)$  を再構成できる。 $WA = I$  ( $I$  は  $n \times n$  の単位行列) となれば  $y(t)$  と  $s(t)$  は一致する。しかし、 $y(t)$  の成分の順番を入れ替えても独立性は保たれ、各成分の大きさも独立性には影響しないことから permutation と amplitude の 2 つの任意性は許容した上で独立な信号成分に分離できればそれを解とする。

$n > m$  の場合、実数行列では原理的に分離できない。信号の性質によっては非線型なフィルタリングによってある程度のことのできる場合もある [11]。また、

$$x(t) = As(t) + n(t), \quad (3)$$

のように観測に  $n$  次元のノイズが加わる問題を考える場合もある。このように (1) 式の問題を基に問題を拡張できる。以下、本稿では  $m = n$  が成り立ち、ノイズの無い場合を扱う。

一方 Blind Source Deconvolution の問題は、

$$\begin{aligned} x(t) &= A(t) * s(t) \\ x_i(t) &= \sum_k a_{ik}(t) * s_k(t), \\ a_{ik}(t) * s_k(t) &= \sum_{\tau=0}^{\infty} a_{ik}(\tau) s_k(t - \tau), \end{aligned} \quad (4)$$

のように畳み込みを用いて定義する．音声信号などを複数のマイクで録音した場合がこれにあたる．この問題では  $y(t)$  の各成分が独立となるようなフィルター  $W(t)$  を求めることになる．

$$y(t) = W(t) * x(t) \quad (5)$$

この問題も BSS の場合と同様に  $m$  と  $n$  の関係，ノイズの有無，さらに  $A(t)$  の特性によって問題を拡張できる．

### 3 ICA の解法

本章では ICA の代表的な解法について述べる．まず PCA (Principal Component Analysis, 主成分分析) と ICA の関係について述べ (3.1), 次に BSS の解法について代表的な二つの解法の概要を説明する．1つは確率分布の独立性に基づく分離法 (3.2) であり，多くの解法はこれに含まれる．この手法の特徴は gradient を用い，信号の時間構造を用いない点である．他の1つは時間相関に基づく分離法である (3.3)．これは信号の時間構造を積極的に用いる．さらに，Blind Source Deconvolution の代表的な解法についても概要を述べる (3.4)．

#### 3.1 PCA と ICA




図 1: Source signals

PCA では多次元の観測信号の共分散行列を用い，その行列の固有値ベクトルの方向へ信号を写像する．多次元の信号  $s(t)$  が (1) 式のように，線型な行列を通して混合された関係を持ち  $x(t)$  として観測されたとする (例えば図 1 のような 2 つの音声信号が図 2 のように混ざって観測されたとする．各図の左側は時系列として，右側では時間を無視し，2 次元平面に信号を表わした．図中の楕円は共分散行列に対応する)．

観測信号の共分散行列を，

$$V = \frac{1}{N} \sum_{t=1}^N x(t)x(t)^T, \quad (6)$$




図 2: Observed signals

とする．任意の正定値実対称行列  $R$  に対する平方根行列  $\sqrt{R}$  を  $\sqrt{R}^T \sqrt{R} = R$  となる行列として定義する． $V^{-1}$  の平方根行列  $\sqrt{V^{-1}}$  によって観測ベクトル  $x(t)$  を変換し  $x'(t) = \sqrt{V^{-1}}x(t)$  とすると  $x'(t)$  の各成分は互いに無相関である．

$$\frac{1}{N} \sum_{t=1}^N x'(t)x'(t)^T = \sqrt{V^{-1}}V\sqrt{V^{-1}}^T = I, \quad (7)$$

PCA ではこのように信号を無相関にする．信号が正規分布にしたがえば，無相関であれば独立であるが，一般には無相関であっても必ずしも独立ではない．




図 3: Applying PCA on observed signals

例えば図 2 の信号は PCA によって図 3 のように変換される．共分散行列が単位円となり，相関は無いが信号は依然として混ざっており，回転の任意性が残っている．この回転まで含めて信号を独立にしようというのが ICA である．ICA の処理を行なった結果を図 4 に示す．




図 4: Result of solving ICA problem

次節以降で ICA の解法について説明する．実際に ICA を行う場合，まず PCA の前処理をすることが多い．ICA ではこの前処理を特に Whitening または Sphering と呼

ぶことがある．これは必要な処理ではなく，前処理の有無は次節以降の議論に影響しない．ただし前処理を行えば ICA によって求めるべき行列が回転行列に限られることから，収束が速い場合がある．

### 3.2 確率分布の独立性に基づく分離法

この手法では，信号源の各成分  $s_i(t)$  が正規分布ではない確率分布にしたがっていると仮定する．ただし確率分布は未知である．今， $\mathbf{y}(t)$  の同時分布密度関数を，

$$p(\mathbf{y}) = p(y_1, \dots, y_n)$$

と置く．行列  $W$  によって観測信号  $\mathbf{x}(t)$  が正しく分離できたならば  $\mathbf{y}$  の各成分  $y_i$  は独立になる．このとき  $p(y_i)$  を  $y_i$  についての周辺分布密度関数とすれば  $p(\mathbf{y})$  はこの周辺分布密度関数の積として  $p(\mathbf{y}) = \prod_{i=1}^n p(y_i)$  とかける．そこで， $p(\mathbf{y})$  と  $\prod_{i=1}^n p(y_i)$  とが一致するように  $W$  を求めるのがこの手法である．多くの手法では評価関数として  $p(\mathbf{y})$  と  $\prod_{i=1}^n p(y_i)$  との間の Kullback-Leibler divergence (別の言葉を使えば  $\{Y_i\}$  ( $i = 1, \dots, n$ ) の相互情報量) を小さくするように  $W$  を求める．K-L divergence の定義は次の通りである，

$$\begin{aligned} KL(W) &= \int p(\mathbf{y}) \log \frac{p(\mathbf{y})}{\prod_{i=1}^n p(y_i)} d\mathbf{y} \\ &= -H(\mathbf{Y}; W) + \sum_{i=1}^n H(Y_i; W). \end{aligned} \quad (8)$$

$H(\mathbf{Y}; W)$  は同時分布のエントロピー， $H(Y_i; W)$  は周辺分布のエントロピーである． $p(\mathbf{y})d\mathbf{y} = p(\mathbf{x})d\mathbf{x}$ ， $p(\mathbf{y}) = p(\mathbf{x})/|W|$  ( $|W|$  は  $W$  の行列式) に注意すると，(8) 式の  $H(\mathbf{Y}; W)$  と  $H(Y_i; W)$  は  $p(\mathbf{x})$  と  $W$  によって書き直せる．

$$\begin{aligned} H(\mathbf{Y}; W) &= - \int p(\mathbf{y}) \log p(\mathbf{y}) d\mathbf{y} \\ &= - \int p(\mathbf{x}) (\log p(\mathbf{x}) - \log |W|) d\mathbf{x} \\ &= H(\mathbf{X}) + \log |W|, \end{aligned} \quad (9)$$

$$\begin{aligned} H(Y_i; W) &= - \int p(\mathbf{y}) \log p(y_i) d\mathbf{y} \\ &= - \int p(\mathbf{x}) \log p(y_i) d\mathbf{x} \end{aligned} \quad (10)$$

である．信号源が正規分布でないという仮定から  $KL(W)$  は  $p(y_i)$  が互いに独立な場合に限り 0 となる． $W$  を求めるには  $KL(W)$  の  $W$  に関する勾配を求め，最急降下

法を行なえば良い．

$$\begin{aligned} \Delta W &\propto - \frac{\partial KL(W)}{\partial W} \\ &= ((W^T)^{-1} - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{x}^T]) \\ &= (I - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{y}^T]) (W^T)^{-1} \end{aligned} \quad (11)$$

$$\varphi(\mathbf{y}) = - \left( \frac{\partial \log p(y_1)}{\partial y_1}, \dots, \frac{\partial \log p(y_n)}{\partial y_n} \right)^T \quad (12)$$

と更新していくことで  $W$  を求められる．計算上 (11) 式中の逆行列  $(W^T)^{-1}$  が問題となる．収束性に関しては正定値行列を掛けても構わないことから  $W^T W$  を掛けて [5]，

$$\Delta W \propto (I - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{y}^T]) W \quad (13)$$

を新たな学習則とする．この方が計算量も少なく，収束も速い [4]．信号に強定常性の仮定が置ける場合，アンサンブル平均を時間平均に置きかえ， $\eta$  を正の定数とし，データが観測される毎に (14) 式にしたがってパラメタを更新すれば収束点として  $W$  が得られる．

$$W_{t+1} = W_t + \eta (I - \varphi(\mathbf{y})\mathbf{y}^T) W_t. \quad (14)$$

この更新則は  $\varphi(\mathbf{y})$  を含んでおり，これは密度関数の形が分らなければ計算できない．しかし，適当なパラメトリックな非線型関数や統計的な展開法によって近似しても正しく  $W$  が求まる [3]．近似の具体的な方法によって，様々な手法が提案されている．Cardoso と Souloumiac [9]，また Jutten と Herault [18] の手法は多項式を用いてこれを近似したことに対応している．Bell と Sejnowski [7] は sigmoid 関数を用いている．Common [12] は後者の手法を調べ，Edgeworth 展開に基づく手法を提案した．甘利らは Gram-Charlier 展開を用いている [5]．他にも混合正規分布を用いる方法など [6] 様々な手法が提案されている．一般に，正規分布より裾が“重い” (sub-Gaussian) 場合は多項式などで近似し，正規分布より裾が“軽い” 場合 (super-Gaussian) Sigmoid 関数などで近似するのがよいとされている．

### 3.3 時間構造に基づく分離法

ここでは音声信号のように強定常ではない信号を考える．時間構造に基づく手法にも複数の手法がある．河本，松岡らは音声信号などのもつ非定常性に基づき，

$$Q = \frac{1}{2} \left\{ \sum_{i=1}^n \log E[y_i^2(t)] - \log \det E[\mathbf{y}(t)\mathbf{y}(t)^T] \right\}, \quad (15)$$

( $E[\cdot]$  は各時刻での平均を表わす) という関数を最小化する形で BSS の問題を定式化した [21, 19] .

これとは別に Molgedey と Schuster は, 自己相関関数に基づく手法 [23] を提案している . ここでは信号にエルゴード性を仮定し, 各信号源のスペクトル密度が異なるとする . 観測データの相関関数は信号源の独立性より,

$$\begin{aligned} \langle \mathbf{x}(t)\mathbf{x}(t+\tau)^T \rangle &= A \langle \mathbf{s}(t)\mathbf{s}(t+\tau)^T \rangle A^T \\ &= A \begin{pmatrix} R_{s_1}(\tau) & & 0 \\ & \ddots & \\ 0 & & R_{s_n}(\tau) \end{pmatrix} A^T, \end{aligned} \quad (16)$$

とかける .  $\langle \cdot \rangle$  は  $\mathbf{x}(t)$  の確率分布での平均を表わし,  $R_{s_i}(\tau)$  は信号源  $s_i(t)$  の自己相関関数である . 一方正しく  $W$  を求めたとすると  $\mathbf{y}(t)$  の相関関数は,

$$\begin{aligned} \langle \mathbf{y}(t)\mathbf{y}(t+\tau)^T \rangle &= \langle (WAs(t))(WAs(t+\tau))^T \rangle \\ &= \begin{pmatrix} \lambda_1^2 R_{s_{1'}}(\tau) & & 0 \\ & \ddots & \\ 0 & & \lambda_n^2 R_{s_{n'}}(\tau) \end{pmatrix}, \end{aligned} \quad (17)$$

となる .  $1', 2', \dots, n'$  は  $1, 2, \dots, n$  の置換を表し,  $\lambda_i$  は大きさの任意性を考慮したものである . ノイズがなく各信号が完全に独立であるならば, 最適な  $W$  は全ての  $\tau$  に対し  $\mathbf{y}(t)$  の相関関数を対角行列とする ((17) 式) . したがって  $\mathbf{x}(t)$  の相関関数を複数の時間差  $\tau_i$  に対して求め, 同時に対角化する行列として  $W$  を求めれば良い .

$$W \langle \mathbf{x}(t)\mathbf{x}(t+\tau_i)^T \rangle W^T = A_i, \quad i = 1, \dots, r, \quad (18)$$

$A_i$  は対角行列である . 行列の数が 2 つの場合はこれは行列の固有値問題に帰着され, 代数的に一意に  $W$  が求まる [23] . ノイズのある場合には 2 つ以上の  $\tau_i$  を選び, 相関行列を同時対角化する解を求めたほうがロバストな解が得られる . ただし, ノイズの影響で完全に対角化ができないので, 何か別の評価関数を考える必要がある [16, 30] . この同時対角化の考え方と前節の確率分布の独立性に基づく分離法との関係は甘利によって示されている [1] .

### 3.4 Blind Source Deconvolution

時間遅れのある混合に対しては, 3.2, 3.3 節の手法を拡張する必要がある .

1 つの拡張の方法は, 分離行列を線型な FIR フィルターとして拡張し, BSS の問題を解くときに用いた評

価関数を基に FIR フィルターの係数を求める方法である . このような手法には K-L divergence に基づく方法 [13] や (15) 式の関数に基づく方法 [19] がある .

もう 1 つの拡張としては, 信号を時間周波数方向に展開し, 各周波数軸で ICA を行なう方法がある [17, 26] . (5) 式の  $\mathbf{x}(t)$ ,  $\mathbf{s}(t)$ ,  $A(t)$  を Fourier 変換したものを  $\omega$  を周波数としてそれぞれ  $\hat{\mathbf{x}}(\omega)$ ,  $\hat{\mathbf{s}}(\omega)$ ,  $\hat{A}(\omega)$  と置くと,

$$\hat{\mathbf{x}}(\omega) = \hat{A}(\omega)\hat{\mathbf{s}}(\omega),$$

という関係が成り立つ . 特に音声信号は数 10msec では定常と見なせるが, それ以上長い時間では定常では無いと考えられるので, 信号が短い時間ではある種の定常性があり, 長い時間では非定常性が強いと仮定し, 近似的に,

$$\hat{\mathbf{x}}(\omega, t_s) = \hat{A}(\omega)\hat{\mathbf{s}}(\omega, t_s), \quad (19)$$

という関係が成り立つとする .  $\hat{\mathbf{x}}(\omega, t_s)$  と  $\hat{\mathbf{s}}(\omega, t_s)$  は  $\mathbf{x}(t)$ ,  $\mathbf{s}(t)$  を windowed Fourier 変換したものである . 周波数を固定するとこの式は BSS の問題と等しい . すなわち各周波数で独立に BSS を行ない, その結果をまとめれば分離できるように見える . しかし, このままでは分離した結果を周波数でまとめ, 時間信号に復元するときに問題が生じる . permutation と amplitude の任意性があることから, 単に周波数毎に並べても大きさと順番の入れ違いが起ってしまうからだ . この問題を解決すれば, 以上の方法で Blind Source Deconvolution を行なえる . 我々はこの 2 つの問題を解く 1 つの手法を提案している [17] .

## 4 信号処理への応用

### 4.1 脳計測データ

脳研究の分野では盛んに ICA が用いられている . 代表的なものは EEG (Electroencephalogram, 脳波計), MEG (Magnetoencephalography, 脳磁計), MRI (Magnetic Resonance Imaging, 磁気共鳴画像) のデータ解析である [27, 20, 8, 16, 28] . この他にも optical recording への応用や多数の Photo-detector による同時計測 (Multi-unit Recording) に対し ICA を用いた解析がされている . ここでは EEG, MEG と MRI について説明する .

まず EEG, MEG について説明する . EEG と MEG では脳内の活動を, EEG では電位によって, MEG では磁場によって外部から複数のセンサーで時系列として

観測する．脳内ではいくつかの活動部位が独立に活動を行っていると考えられる．また，脳からの電位，磁場とは別に，外部からのノイズや脳自体が発生するノイズ（心電やまばたきなど解析する上で必要のない信号・ブレインノイズ）が加わって観測される．これらはそれぞれ独立だと考えられる．また電場も磁場も時間遅れなく伝わるとして良いことから EEG, MEG は BSS の問題と等しい．




図 5: 観測信号




図 6: 独立成分

MEG データの例を示す [16]．MEG データは非常に微弱な信号を測定しており，地磁気や商用電源，量子力学的効果によるノイズを取り除くために通常は 100 回程度の加算平均を行なう．図 5 には加算平均を行なわない信号を示す<sup>1</sup>．この MEG 測定器には全部で 129channel のセンサーがある．図にはこのうち 5 つのみを示した．図は生理食塩水で満たされた球状の模型に電線を埋めこみ，微小な三角波電流を流したもので，視覚的には信号が確認できない．これに対し ICA を行なった結果，図 6 のように地磁気 (Source 1) 商用電源 (Source 2,3) 入力信

<sup>1</sup>このデータは島津製作所によって測定された

号 (Source 4) などが加算平均無しに得られる．

MRI データの解析にも ICA が応用されている [22]．MRI では観測される信号は画像の時系列である．時間方向のサンプル数は画素数に比べれば少ない．したがって  $x(t)$  の各成分を画素とし，時系列として問題を定式化するとサンプル数が足りず問題が解けない．このような問題には  $x(t)$  の  $t$  方向には画像をスキャンし ( $t = 1, \dots, \text{画素数}$ )， $x(t)$  の成分  $x_i(t)$  はある時刻での画像をとる ( $i = 1, \dots, \text{時間方向のサンプル数}$ )．この結果得られる各独立成分は画像となり，独立な画像が混ざって各時刻で観測されることになる．

このように EEG, MEG の解析では ICA によって加算平均の回数が減り，ノイズを軽減する可能性がある．また MRI においても今までとは異なるデータ解析の結果が得られている．しかし ICA は信号を統計的に独立に分離することが目的であり，分離された信号の物理的な意味は与えない．この解釈については，脳の研究と合わせて考える必要がある．

## 4.2 画像処理，音声信号

工学的な応用として，画像や音声信号を ICA の手法で解析しようという試みもある．

以前から ICA の例として人工的に混合された画像がしばしば用いられていた [10]．このような例では MRI の処理と同様に変数を作り，ICA を用いている．これとは別に自然画像を小さな部分に切り，その中での sparse coding [25] と同様の画像表現を ICA の考え方に基づいて導こうというものがある [15]．

音声信号の分離は Cocktail Party 効果との関係から，また音声認識などの応用と直ちに結びつけられることから [14] 注目されている．しかし第 3 章にある通り Blind Source Deconvolution は BSS に比べ解法が難しく，処理に時間がかかる．我々は音声信号の分離を目指したアルゴリズムを提案し [24] いくつかの例を公開している．興味があれば URL を辿って聞いて頂きたい<sup>2</sup>．

1999 年 1 月に初めての ICA に関する国際会議 ICA'99 がフランスにおいて開かれた．この中で，それぞれのアルゴリズムを比べるためのデータを作る計画が議論された．音声信号に関しては少ないながらも幾つかのデータが用意され始めた<sup>3</sup>．ICA の研究を行なう場合には配布されているデータを用いるのも良いだろう．

<sup>2</sup><http://www.islab.brain.riken.go.jp/~shiro/>

<sup>3</sup><http://www.ele.tue.nl/ica99/>

## 5 まとめ

本稿では ICA の問題, 代表的な解法, 応用の概要を示した. 理論的な研究としては, センサーの数と信号源の数が一致しない場合 [29], ノイズのある状況下での信号分離について考えていく必要がある. ICA'99 においてもこれらの問題が議論されていた.

応用での問題の 1 つは, 例として挙げた MEG データ解析のように, ICA の結果得られた独立成分の物理的な解釈である. 脳のデータに関しては生理学的な知見と合わせて, 正しい解釈を行なっていく必要がある. Blind Source Deconvolution の問題はまだ未解決の部分も多く, 実用を可能にするためには, 実時間で分離を行なえる on-line アルゴリズムが必要である.

ICA は, 主成分分析と同様に多変量データ解析の基礎的操作としての位置を確立しつつある. 正しく ICA を理解し, 様々な分野で積極的に ICA が用いられていくことを期待する. 文献や MATLAB で書かれたプログラムなどは公開されているものも多い<sup>4</sup>. 参考にして頂きたい.

## 参考文献

- [1] S. Amari. ICA of temporally correlated signals – learning algorithm. In *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'99)*, pp. 13–18, January 1999.
- [2] 甘利 (編). 独立成分解析. Computer Today (サイエンス社), 9月 1998. 1999年4月現在 連載中.
- [3] S. Amari and J.-F. Cardoso. Blind source separation – semiparametric statistical approach. *IEEE Trans. Signal Processing*, 45(11):2692–2700, November 1997.
- [4] S. Amari, T. Chen, and A. Cichocki. Stability analysis of learning algorithms for blind source separation. *Neural Networks*, 10(8):1345–1351, August 1997.
- [5] S. Amari, A. Cichocki, and H. H. Yang. A new learning algorithm for blind signal separation. In D. S. Touretzky, M. C. Mozer, and M. E. Hasselmo eds., *Advances in Neural Information Processing Systems*, Vol. 8, pp. 757–763. The MIT Press, Cambridge MA, 1996.
- [6] H. Attias. Independent factor analysis. *Neural Computation*, 11(4):803–851, May 1999.
- [7] A. J. Bell and T. J. Sejnowski. An information maximization approach to blind separation and blind deconvolution. *Neural Computation*, 7(6):1129–1159, 1995.
- [8] J. Cao, N. Murata, S. Amari, A. Cichocki, and T. Takeda. ICA approach with pre & post-processing techniques. In *Proceedings of 1998 International Symposium on Nonlinear Theory and its Applications (NOLTA'98)*, Vol. 1, pp. 287–290, September 1998.
- [9] J.-F. Cardoso and A. Souloumiac. Blind beamforming for non Gaussian signals. *IEE-Proceedings-F*, 140(6):362–370, December 1993.
- [10] A. Cichocki, W. Kasprzak, and S. Amari. Multi-layer neural networks with a local adaptive learning rule for blind separation of source signals. In *Proceedings of 1995 International Symposium on Nonlinear Theory and its Applications (NOLTA'95)*, pp. 61–65, 1995.
- [11] P. Common and O. Grellier. Non-linear inversion of underdetermined mixtures. In *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'99)*, pp. 461–465, January 1999.
- [12] P. Comon. Independent component analysis, a new concept? *Signal Processing*, 36(3):287–314, April 1994.
- [13] S. C. Douglas and A. Cichocki. Neural networks for blind decorrelation of signals. *IEEE Trans. Signal Processing*, 45(11):2829–2842, November 1997.
- [14] F. Ehlers and H. Schuster. Blind separation of convolutive mixtures and an application in automatic speech recognition in noisy environment. *IEEE Transactions on Signal Processing*, 45(10):2608–2609, 1997.
- [15] A. Hyvärinen, P. Hoyer, and E. Oja. Denoising of nongaussian data by independent component analysis and sparse coding. In *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'99)*, pp. 485–489, January 1999.
- [16] 池田, 村田. Independent component analysis を用いた MEG データの解析. 電子情報通信学会技術研究報告, NC98-28:19–36, June 1998.
- [17] S. Ikeda and N. Murata. An approach to blind source separation of speech signals. In *Proceedings of 1998 International Conference on Artificial Neural Networks (ICANN'98)*, pp. 761–766, September 1998.
- [18] C. Jutten and J. Herault. Separation of sources, part i. *Signal Processing*, 24(1):1–10, July 1991.
- [19] M. Kawamoto, K. Matsuoka, and N. Ohnishi. A method of blind separation for convolved nonstationary signals. *Neurocomputing*, 22(1-3):157–171, 1998.
- [20] S. Makeig, T.-P. Jung, and T. J. Sejnowski. Using feedforward neural networks to monitor alertness from changes in EEG correlation and coherence. In D. S. Touretzky, M. C. Mozer, and M. E. Hasselmo eds., *Advances in Neural Information Processing Systems*, Vol. 8, pp. 931–937. The MIT Press, Cambridge, MA, 1996.
- [21] K. Matsuoka, M. Ohya, and M. Kawamoto. A neural net for blind separation of nonstationary signals. *Neural Networks*, 8(3):411–419, 1995.

<sup>4</sup><http://www.bmc.riken.go.jp/sensor/Allan/>  
<http://sound.media.mit.edu/~paris/>  
<http://www.cnl.salk.edu/CNL/>  
<http://www.cis.hut.fi/projects/ica/>

- [22] M. J. Mckeown, T.-P. Jung, S. Makeig, G. Brown, S. S. Kindermann, T.-W. Lee, and T. J. Sejnowski. Spatially independent activity patterns in functional magnetic resonance imaging data during the Stroop color-naming task. In *Proceedings of the National Academy of Sciences*, Vol. 95, pp. 803–810, February 1998.
- [23] 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.
- [24] N. Murata, S. Ikeda, and A. Ziehe. An approach to blind source separation based on temporal structure of speech signals. to appear in *Neurocomputing*.
- [25] B. A. Olshausen and D. J. Field. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, 381:607–609, 1996.
- [26] P. Smaragdis. Blind separation of convolved mixtures in the frequency domain. *Neurocomputing*, 22(1-3):21–34, 1998.
- [27] R. N. Vigário. Extraction of ocular artifacts from EEG using independent component analysis. *Electroenceph. clin. Neurophysiol.*, 103:395–404, 1997.
- [28] R. Vigário, V. Jousmäki, M. Hämäläinen, R. Hari, and E. Oja. Independent component analysis for identification of artifacts in Magnetoencephalographic recordings. In M. I. Jordan, M. J. Kearns, and S. A. Solla eds., *Advances in Neural Information Processing Systems*, Vol. 10, pp. 229–235. The MIT Press, Cambridge MA, 1998.
- [29] L. Zhang, S. Amari, and A. Cichocki. Natural gradient approach to blind separation of over- and under-complete mixtures. In *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'99)*, pp. 455–460, January 1999.
- [30] A. Ziehe and K.-R. Müller. TDSEP – an efficient algorithm for blind separation using time structure. In *Proceedings of 1998 International Conference on Artificial Neural Networks (ICANN'98)*, pp. 675–680, September 1998.

いけだ しろ

**池田 思朗** (正会員)

1968年12月21日生。1991年東京大学工学部計数工学科卒業。1996年東京大学大学院博士課程修了。同年理化学研究所入所。1998年より科学技術振興事業団さきがけ研究21研究員，現在に至る。主に確率モデルの学習，構造選択の研究に従事。