

独立成分解析

池田 思朗

九州工業大学大学院 生命体工学研究科

平成 16 年 5 月 25 日

概要

独立成分解析¹(Independent Component Analysis: ICA) は 1980 年代から盛んに研究されるようになった多変量解析の手法である。90 年代後半には一通りの理論的な基礎が確立し、以後、様々な分野での応用が期待されている。しかし、それぞれの問題には特有の困難があり、単に ICA の手法を当てはめれば良いというわけにはいかない。本稿ではこれまでの ICA の研究を簡単に紹介し、ICA を用いる際、どのような困難があるのかを示し、今後の研究にはどのような可能性があるのかについて考える。

1 はじめに

ICA の研究は 1980 年代、Jutten と Herault らによるものが最初であるとされている²。その後理論的には Comon[3], Amari & Cardoso[4] などが基礎を築いたといえる。ICA の名が付けられたのは Comon の論文からである。

既存の理論としては、統計学における主成分分析 (PCA) の手法、そして projection pursuit と呼ばれる手法と密接な関係がある。特に projection pursuit と ICA とは手法自体にはそれほど差が無い。ただし、ICA が仮定する、観測は独立成分の線形な重ね合わせである、というモデルは独自のものと言ってよい。詳しくは次節に述べるが、この問題の簡単さ、理論の美しさが ICA の特徴の一つである。

¹独立成分分析と呼ばれることもあるだろう。日本語の名称は統一されていないものと思う。

²当時の論文は手に入らないが、[1] がその内容を代表するもの一つであり、また [2] に彼等のグループでの ICA に関する研究がまとめられている

実際の信号処理の問題に ICA を適用し、得られた結果は興味深いものであった。EEG データ [5] や fMRI データ [6] に対する結果では、今まで簡単には得られなかった特徴的な信号が独立性の仮定から導かれることが示された。また、自然画像に対して用いることで視覚野の細胞の受容野と同様の特徴が得られること [7, 8] が示され、さらに混合音声の分離問題に対する結果から、時間遅れを含む畳み込み混合の問題に対しても有効性が示された [9, 10]。

広く研究が行なわれるようになった要因の一つには、簡単に使えるプログラムがインターネット上で配布されたことも挙げられる。特に有名なものは、J-F. Cardoso らの JADE と呼ばれるもの [11]、A. Hyvärinen らの FastICA と呼ばれるもの [12] である。その他にも様々なものが ICA central という web page からダウンロードできるようになっている [13]。これらはほとんどが無償で配布されており Matlab という数値計算用的高级言語 (商用ソフト) があればすぐに利用可能なプログラムである。

以上のように、ICA はその問題の簡単さ、複数の問題で新しい結果得られたこと、さらに幾つかのアルゴリズムがプログラムとして利用可能な形で配布されたことにより、様々な方面から注目が集まった。当然、実用レベルの応用が期待されているが、現在も研究レベルのものが多い。これは、既存の ICA の解法が実用に対しては十分でないことを示している。

では、ICA は使えない技術なのだろうか。我々はそうではないと考えている。ICA は信号の「独立性」という概念を初めて明示し、新しい解析法を提案した。しかし「独立性」という概念は万能ではなく、この概念を正しく理解し用いなければ効力は発揮されない。本稿では、次節以降で理論的な背景を示し、応用例を

通じて ICA の使い方について述べていく。

2 解法

2.1 ICA の問題

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る。 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。 x の次元 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,

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

という線型の関係性を仮定する (図 1)。 A は $m \times n$ の実数行列である。ICA の目的は $s(t)$ の独立性の仮定から A に関する知識を持たずに $x(t)$ を n 個の独立な成分に分離することである。




図 1: 2 入力 2 出力の ICA の問題

$n \leq m$ 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 $WA = PD$ (P は各列, 各行に一つだけ 1 を持つ $n \times n$ の行列, D は $n \times n$ の対角行列) となれば良いとする。

2.2 独立性の定義と解法

ICA の解法を考える上で「信号の独立性」をどのように定義するかが問題となる。現在用いられている解法のほとんどは, 次に示す 3 つの定義のいずれかを用いている [14, 15]。順に述べていくことにする。

非正規性

ここでは JADE や FastICA でも用いられており, ICA の手法の大部分を占める考え方について述べる。

信号 s_i が正規分布でない (非正規な) 未知の確率分布にしたがっていると仮定する。仮に正規分布にしたがうものがあっても高々一つだとする。行列 W によって観測信号 x を分離し, y を得たとする。この y 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 によって独立成分に分離できたのであれば y の各成分 y_i は独立になる。 $p(y_i)$ を y_i についての周辺分布密度関数とすれば

$$p(\mathbf{y}) = \prod_{i=1}^n p(y_i)$$

とかけることになる。そこで, 非正規性を用いて $p(\mathbf{y})$ 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。

$p(\mathbf{y})$ と $\prod_{i=1}^n p(y_i)$ とが一致するかどうかは Kullback-Leibler 情報量 (この場合は相互情報量と一致する) を用いて測るのが一般的である。KL 情報量の定義は次の通りである,

$$\begin{aligned} KL(W) &= \int p(\mathbf{y}) \log \frac{p(\mathbf{y})}{\prod_{i=1}^n p(y_i)} d\mathbf{y} \quad (3) \\ &= -H(\mathbf{Y}; W) + \sum_{i=1}^n H(Y_i; W). \end{aligned}$$

$H(\mathbf{Y}; W)$ 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。 $p(\mathbf{y})d\mathbf{y} = p(x)dx$, $p(\mathbf{y}) = p(x)/|W|$ ($|W|$ は W の行列式) であるので, $H(\mathbf{Y}; W)$ と $H(Y_i; W)$ は $p(x)$ と W によって書き直

せる .

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

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 . $KL(W)$ を最小化する手法は数多く存在する . ここではそのうちの一つ , 最急降下法を行なう手法を示す . すなわち ,

$$\begin{aligned}
\Delta W &\propto - \frac{\partial KL(W)}{\partial W} \\
&= ((W^T)^{-1} - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{x}^T]) \\
&= (I - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{y}^T]) (W^T)^{-1} \quad (4) \\
\varphi(\mathbf{y}) &= - \left(\frac{\partial \log p(y_1)}{\partial y_1}, \dots, \frac{\partial \log p(y_n)}{\partial y_n} \right)^T
\end{aligned}$$

と更新していくことで W を求められる . ここで (4) 式中の逆行列 $(W^T)^{-1}$ の計算が問題となる . 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 [16] ,

$$\Delta W \propto (I - E_{\mathbf{x}}[\varphi(\mathbf{y})\mathbf{y}^T]) W \quad (5)$$

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 [17] . 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 , η を正の定数とし , データが観測される毎に次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 .

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

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 [4] . W を推定するには $\varphi(\mathbf{y})$ を正確に推定する必要はなく , 任意な非線型関数を用いても良い点が ICA の特徴である . このような推定法はセミパラメトリック推定と呼ばれる .

時間相関

信号の自己相関関数を用いる手法もある . まず , $\mathbf{x}(t)$ の自己相関行列を定義する .

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

$\langle \cdot \rangle$ 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 . 信号の独立性から $\mathbf{s}(t)$ の自己相関行列は τ に無関係に常に対角行列となる . このことが , ここでの独立性の定義となる .

各信号源 $s_i(t)$ のスペクトル密度が異なるとする . 正しく W を求めたとすると $\mathbf{y}(t)$ の相関関数は ,

$$\begin{aligned}
\langle \mathbf{y}(t)\mathbf{y}(t+\tau)^T \rangle &= \langle (W A \mathbf{s}(t)) (W A \mathbf{s}(t+\tau))^T \rangle \\
&= \begin{pmatrix} \lambda_1^2 R_{s_{1'}}(\tau) & & 0 \\ & \ddots & \\ 0 & & \lambda_{n'}^2 R_{s_{n'}}(\tau) \end{pmatrix},
\end{aligned}$$

となる . $1', 2', \dots, n'$ は $1, 2, \dots, n$ の置換を表し , λ_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ならば , 最適な W は全ての τ に対し $\mathbf{y}(t)$ の自己相関行列を対角行列とする . したがって $\mathbf{x}(t)$ の自己相関行列を複数の時間差 τ_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 [18] .

$$W \langle \mathbf{x}(t)\mathbf{x}(t+\tau_i)^T \rangle W^T = \Lambda_i, \quad i = 1, \dots, r, \quad (6)$$

Λ_i は対角行列である . 行列の数が 2 の場合はこの問題は行列の同時対角化問題に帰着され , 代数的に一意に W が求まる [18] . 有限時間の平均によって自己相関行列を推定する場合 , 2 つ以上の τ_i を選び , 自己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 , 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 [15] .

なお , この同時対角化の考え方と KL 情報量に基づく分離法との関係は [19] に示されている .

非定常性

一方、信号 $s_i(t)$ が非定常な確率過程にしたがっているとして分離する手法がある [20]。松岡らは信号の非定常性に基づき、

$$Q(t) = \frac{1}{2} \left\{ \sum_{i=1}^n \log E[y_i^2(t)] - \log \det E[\mathbf{y}(t)\mathbf{y}(t)^T] \right\}, \quad (7)$$

($E[\cdot]$ は各時刻での平均を表わす) という関数を定義し、この Q を最小化することで ICA の問題を定式化した。

Q は $E[\mathbf{y}(t)\mathbf{y}(t)^T]$ が対角行列となった時点で 0 となり、 W はそれ以上更新されない。信号が定常であれば、信号を無相関とする変換 W は Q を 0 とするので、行列の回転の不定性が残り、解が得られない。しかし、信号が非定常であれば、全ての時刻で Q を最小化する行列として回転の任意性もなく W を求めることができる。

3 脳の計測データの解析

合成されたデータに対して ICA を使うと、前節で示したどのアルゴリズムを用いても、大抵は問題なく分離できる。しかし、実際の信号を分離しようとするとなかなかうまくいかない。理由はデータに依存するが、単に ICA を当てはめただけでは解けない問題もある。本節と次節では、実際のデータではどのような困難があるのかを応用例と共に考えてみる。

3.1 ノイズ

ここでは MEG のデータについて考える [21, 22]。MEG のデータでは、脳内の活動を脳のまわりの 100 ~ 200 程度のセンサーを用いて磁場の変化として捉え、活動の様子とその部位を推定する。MEG は他の手法と比べ、時間的 (1msec) にも空間的 (数 mm) にも比較的高い分解能で測定が行なえることが特徴である。

脳活動が作る磁場は非常に小さく (10^{-14} T), MEG の測定では脳活動以外の信号 (ノイズ) の方がはるかに大きい (表 1)。脳の活動が一回の測定から直接観測できる場合は、てんかんなどの特殊なケースに限られ

る。表 1 を見ると分るが、考えられるノイズには幾つ

| | 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) | $\sim 10^{-11}$ | |
| 商用電源 | $\sim 10^{-13}$ | 50 or 60 |
| 各センサーで独立な雑音 | | |
| センサーノイズ | $\sim 10^{-14}$ | 白色雑音 |

表 1: 信号およびノイズの強度と周波数

かの種類がある。地磁気やセンサーノイズは周波数的にも脳活動による信号と重なっており、Low-Pass フィルターなどでは除去ができない。そこで、視覚刺激や聴覚刺激に対する応答を見る場合、同様の実験を 50 ~ 100 回程度繰り返し行ない、その平均を使うことでノイズを軽減することが多い。




図 2: 視覚刺激の応答の MEG による観測: 100 回の加算平均後のデータ。約 120 のセンサーの観測信号から 3 つを示す。刺激を与えたのは時刻 0 であり、刺激前 100msec から刺激後 412msec までの反応を記録

100 回の加算平均後の信号を図 2 に示す。この信号を見ると、0msec において刺激を与えたのちの反応が観測できるが、依然としてノイズが多い。この問題のモデルを考えてみる。ICA の問題はセンサーへの入力 x が

$$x = As$$

と表されるというモデルであった。表 1 の成分をあてはめるならば、 s には脳磁場、地磁気、商用電源が含

まれるとして良いだろう。しかし、このモデルでは、センサー毎に独立なノイズ成分というのは含まれていない。センサーノイズを含め、ICA のモデルとして次のようなものを考える。

$$x = As + \epsilon$$

ϵ は各センサーに独立に加わるノイズである。

この問題は変形すれば

$$x = As + \epsilon = A's' = (A, I) \begin{pmatrix} s \\ \epsilon \end{pmatrix}$$

とかける。ノイズも信号とみなせば、信号源の数がセンサーの数よりも多いことが分る。したがってこのまま ICA の問題を解こうとしても必ずしもうまくいかない。

我々はこの問題に対し、 ϵ に正規性を仮定し、分離するアルゴリズムを提案した [22]。詳しくは述べないが、因子分析と ICA の手法を組み合わせることで行列 A を推定し、信号の分離を行なった。この場合 ϵ に正規性を仮定することで、ICA の解法を拡張できた。推定された独立成分を図 3 に示す。提案した手法では、同時に独立成分の数も推定している。同様の手法に関しては [23, 24] などとも参考になるだろう。

3.2 信号の独立性

図 3 の結果を詳しく考えてみる。これらは独立成分であるが、それぞれはどのような信号だろうか。

脳の計測データを ICA によって解析する場合、解析結果をどのように理解するかが問題となる。MEG データの場合、観測信号には脳内の活動による信号と脳の外からの信号 (artifact) が混ざっていると考えられる。それぞれの artifact は互いに独立であり、脳磁場とも独立として良いだろう。

例えば、図 3 中の y_9 を周波数解析をすると 180Hz の成分が大きい。これは脳が発生する信号とは考え難く、商用電源の高周波成分とみなせる。また、 y_{11} は 412msec のところでピークを持つ信号で、これも脳が作り出した信号ではなく、信号処理の過程で混ざった信号だと考えられる。このように明らかにノイズ成分と分る信号もあるが、そうでない信号も数多く含まれている。これらは何であろうか。




図 3: 推定された独立成分

脳の内部で複数の部位が活動したとする。異なる部位からの信号であっても、これらは必ずしも統計的に独立ではない。図 3 の結果でも、脳の複数の部位からの信号が、独立性に基づいて分離され、複数の独立成分となっているはずである。したがって各独立成分に生理学的な意味付けをするのは難しい。




図 4: ノイズ成分を除去し、復元された視覚刺激の応答

我々は、明らかに脳以外から発生したと考えられる信号は取り除き、それ以外の脳が信号源であると考

られる信号を全て用いて MEG の信号を復元する手法を取っている．その結果得られた信号を図 4 に示す．図 2 と比べると，刺激を与える前 (-100msec ~ 0msec) のノイズと思われる信号が無くなり，刺激による反応 (特に 80msec ~ 150msec) の波形がはっきりとした形で示されている．

我々はさらに，外山らが提案した MEG に対する空間フィルター法 [25] を用い，脳内の活動を図示する手法を取り入れている．図 5 は ICA による図 4 の結果を空間フィルター法によって処理したものである．空間フィルター法では脳の活動を脳内に仮定した球面上の電流分布として再合成する．この実験では脳の左後方，視覚野が中心となるように球面を設定した．図ではその結果を fMRI によって得られた脳表面の図と重ねて描画してある．図中の矢印は推定された電流を示している．

図 5 の上の二つは，視覚刺激を与える前の脳表面の電流分布である．刺激前の脳の活動は，ほとんどがノイズと思われる．左側の加算平均 (処理前) データでは脳表面に様々な電流が推定されているが，ICA によって処理し，ノイズを除去すると，ほとんど電流は流れていないことが分る．

下の二つは視覚刺激後 150msec の電流分布である．以前の実験により，視覚刺激後 80 ~ 150msec に反応が大きく出ることが分っている．図は視覚野を中心とした電流分布を表わしており，図の中心である V1 の周りにうずまくように電流が流れているのが分る．これは処理前，処理後ともに一致した特徴を示している．一方図の境界付近の信号は空間フィルター法の性質よりノイズが多いことが知られている．図から ICA の処理によってこのノイズの成分が取り除かれていることが分る．

我々の取った方法は一つの例にすぎないが，ICA を用いる場合，信号にどのような独立性が仮定できるのかを考慮することが重要である．特に生理学的な部位の独立性はそれぞれの信号の統計的独立性とは必ずしも一致しないことを考慮し解析を行なう必要がある．

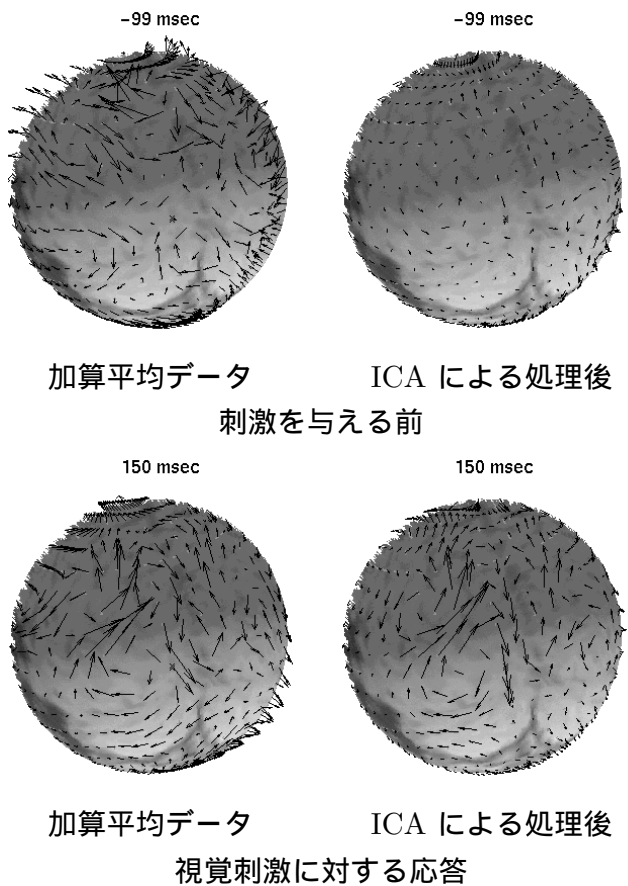


図 5: 空間フィルター法による MEG データの図示

4 音声信号の分離

前節では，信号の性質を考えることによって，既存の ICA の問題を拡張したこと，解析結果をどのように理解するのかについて，我々がとった立場を説明した．本節では，ICA を音声信号分離の問題へ拡張する手法について説明する．

本稿の読者は，多くが脳の研究に何らかの形で関わっているはずである．MEG, EEG, fMRI などの脳の計測信号は多くの場合，信号源から観測までの時間遅れを考えなくても良い．したがって線形混合の問題で十分である．しかし，音声信号や無線信号などでは信号源から観測点までの到達時間の遅れを考えなければ

ばいけない．すなわち，問題は

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

のように畳み込みを用いて定義することになる (図 6) . フィルターとしては無限のインパルス応答をすることもできるが，現実的には有限のインパルス応答を (FIR フィルター) を考えれば十分であろう .




図 6: 2 入力 2 出力の音声信号の分離

時間遅れを含む混合の場合，分離のためには線形の行列 W ではなく， $y(t)$ の各成分が独立となるようなフィルター $W(t)$ を求める必要がある .

$$y(t) = W(t) * x(t)$$

$W(t) = \{w_{ij}(t)\}$ はフィルターを成分とする行列の形をしており，推定しなければならない変数の数は非常に多い .

この問題の解を求めるためには，信号の独立性をどのように考えるかと同時にフィルターをどのように設計するかが問題となる . 一つの考え方は直接 FIR の係数を推定し，逆フィルタを構成して分離する手法である . (4) 式や (7) 式の関数を畳み込み混合の場合に拡張し，問題を解くことができる [10, 26] .

一方，時間周波数方向に展開し，問題を解くこともできる [27, 15, 28] . 以下で説明する .

$x(t)$, $s(t)$, $A(t)$ を Fourier 変換したものを ω を周波数としてそれぞれ $\hat{x}(\omega)$, $\hat{s}(\omega)$, $\hat{A}(\omega)$ と置くと，

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

という関係が成り立つ . 特に音声信号は数十 msec で定常とみなせるが，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いう仮定をし近似的に，

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

という関係が成り立つとする . ここで $\hat{x}(\omega, t_s)$ と $\hat{s}(\omega, t_s)$ は $x(t)$, $s(t)$ を windowed Fourier 変換したものである . ω を無視してこの式をながめると，これは (1) 式と等しい . したがって，各周波数で (1) 式の問題を解けば，分離ができる .

しかし，時間周波数毎に別の問題として分離を行い，全ての周波数の結果をまとめて信号を復元する際，新たな問題が生じる . ICA の解法では順番の入れ違いと大きさの任意性が取り除けない . しかし，各周波数の分離結果を合成する際には周波数毎に同じ信号源の信号をまとめる必要がある . また，各周波数で正しい大きさにそろえなければ，再構成された音が不自然となる .

大きさの任意性を解くには，推定された分離行列 $W(\omega)$ の逆行列を用いればよい . $W(\omega)^{-1}$ は $A(\omega)$ にあたるものだが， $W(\omega)$ によって分離された信号の各成分を $W(\omega)^{-1}$ によって再構成すれば，再構成された信号は観測点における信号の大きさを推定したことになり，大きさの任意性は取り除ける .

順番の入れ違いに関しては，他の知識を使う必要がある . 我々は音声信号の非定常性を用いる手法を提案した [28, 15] . 他にもよりよい手法はあるだろう . 重要なことは時間遅れを含む混合を時間周波数方向へ変換することで簡単に解を求められるようになる一方，新たな問題が生じたこと，その問題をなんらかの方法で解かなければ満足する結果が得られないことである . 問題によっては，このように基本となる ICA では解けなかった順番と大きさの任意性を解く必要がある .

5 これからの話題

多次元信号を独立な成分に分離することが ICA の目的である . その際，ことさらに信号に関する知識を持たなくても良いことが特徴である . しかし，3 節，4 節のように，目的の結果を得るためには，単に ICA によって分離を行なうだけでは不十分であり，ICA 以

外の部分が重要であることが分る．そのためには信号や混合過程に関する知識を用いる必要がある．これはICAの特徴と矛盾するようであるが，対象の情報をより多く使えばより良い結果が得られるのは当然のことである．

現在のICAに関わる研究の全ては把握できないが，理論的にも応用としても様々な方向で数多くの研究が行なわれている．その中には以上のように対象の情報をとりいれることで分離を良くしようというものが数多く見られる．すなわち，今までは未知としていた信号 s の確率分布や混合行列 A に関する知識を積極的にモデルに組み込む手法の研究である．

問題によっては信号源 s に関して，ある程度確率分布の形が分かっている場合も多い．そのような知識を用いる手法は多く提案されている．また，時間周波数方向での音声分離の手法では， s_i に関して面白い仮定をしている手法がある．音声や楽器などの調音構造を持つ信号を時間周波数方向に展開すると，周波数方向には疎である．これを利用し，2つのマイクロフォンで得た信号を時間周波数方向に展開し，各周波数において2つの信号源の分離をすることで，全体としては2つ以上の音信号を分離することが可能となることが示されている[29]．このように，信号に関する情報を積極的に用いることで，より良い分離が可能となる．

混合行列 A に関する知識を用いる手法も提案されている． A に確率分布を仮定する手法[30, 8]は自然画像の解析の際には良く用いられている手法である．これにより，単純細胞や複雑細胞の受容野が再現できることが示されている．今後は積極的に信号源から観測点までの物理的な構造を入れ，ICAの問題を解くこともできると考える．

一方で，信号源の知識を用いない手法としても，理論的に様々な研究が行なわれている．確率分布の近似手法[31]，コスト関数としてKL情報量を拡張したものをを用いる手法[32, 33]，あるいは既存のコスト関数をもとにアルゴリズム自体の高速化法などが提案されている[34]．アルゴリズムの性能の向上のためには，まだまだ研究することは多く残されている．

6 最後に

様々な分野でICAを利用できないかという期待が増えている．プログラムはwebを通じて得られるし，理論的背景を知るための教科書的な本の出版も最近になって相次いでいる[35, 36, 37]³．また，様々な研究をまとめて本の形にしたものもあり[38, 39]，最新の研究を効率よく知るためには良いものと思う．様々な分野でICAが使われるようになればと考える．

ICAの国際会議は1999年に第1回をフランスで開催した後，約1年半毎に一回のスケジュールでフィンランド，アメリカと計3回開催された．内容はその規模と同様に回を重ねる毎に広がりを見せている．その発展に際し，インターネットの便利さを有効に利用したICAであるが，ICA2001の予稿集は全てインターネットから閲覧できるようになっている[40]．通常は手に入り難い予稿集がこのように気軽に手に入ることは，研究を進める上で大変有用である．2003年4月には第4回となるICAの国際会議が日本で開催される[41]．応用も含め，幅広い内容についての活発な議論が行われるものと思う．

7 謝辞

今回執筆の機会を下さった萩原克幸先生に感謝します．この記事が何かの形で皆様の参考となることを祈ります．

参考文献

- [1] Jutten, C. and Herault, J. (1991): Separation of sources, Part I, *Signal Processing*, Vol. 24, No. 1, pp. 1–10.
- [2] Jutten, C. and Taleb, A.: Source separation: from dusk till dawn, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2000)*, pp. 15–26 (2000).
- [3] Comon, P. (1994): Independent component analysis, A new concept?, *Signal Processing*, Vol. 36, No. 3, pp. 287–314.
- [4] Amari, S. and Cardoso, J.-F. (1997): Blind Source Separation – Semiparametric Statistical Approach,

³残念ながら日本語の書籍はまだ出版されていないが，準備されているものはあるようだ．

- IEEE Transactions on Signal Processing*, Vol. 45, No. 11, pp. 2692–2700.
- [5] Makeig, S., Jung, T.-P., Bell, A. J., Ghahremani, D. and Sejnowski, T. J. (1997): Blind Separation of Auditory Event-related Brain Responses into Independent Components, *Proc. Natl. Acad. Sci. USA*, pp. 10979–10984.
- [6] Mckeown, M. J., Jung, T.-P., Makeig, S., Brown, G., Kindermann, S. S., Lee, T.-W. and Sejnowski, T. J.: 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 (1998).
- [7] Bell, A. J. and Sejnowski, T. J. (1997): The ‘independent component’ of natural scenes are edge filters, *Vision Research*, Vol. 37, pp. 3327–3338.
- [8] Olshausen, B. A. and Field, D. J. (1996): Emergence of simple-cell receptive field properties by learning a sparse code for natural images, *Nature*, Vol. 381, pp. 607–609.
- [9] Bell, A. J. and Sejnowski, T. J. (1995): An information maximization approach to blind separation and blind deconvolution, *Neural Computation*, Vol. 7, No. 6, pp. 1129–1159.
- [10] Douglas, S. C. and Cichocki, A. (1997): Neural Networks for Blind Decorrelation of Signals, *IEEE Transactions on Signal Processing*, Vol. 45, No. 11, pp. 2829–2842.
- [11] <http://www.tsi.enst.fr/icacentral/Algos/cardoso/>.
- [12] <http://www.cis.hut.fi/projects/ica/fastica/>.
- [13] <http://www.tsi.enst.fr/icacentral/>.
- [14] Cardoso, J.-F.: The three easy routes to independent component analysis; contrasts and geometry, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2001)*, pp. 1–6 (2001).
- [15] Murata, N., Ikeda, S. and Ziehe, A. (2001): An Approach to Blind Source Separation Based on Temporal Structure of Speech Signals, *Neurocomputing*, Vol. 41, No. 1-4, pp. 1–24.
- [16] Amari, S., Cichocki, A. and Yang, H. H.: A New Learning Algorithm for Blind Signal Separation, in Touretzky, D. S., Mozer, M. C. and Hasselmo, M. E. eds., *Advances in Neural Information Processing Systems*, Vol. 8, pp. 757–763, The MIT Press, Cambridge MA (1996).
- [17] Amari, S., Chen, T. and Cichocki, A. (1997): Stability Analysis of Learning Algorithms for Blind Source Separation, *Neural Networks*, Vol. 10, No. 8, pp. 1345–1351.
- [18] Molgedey, L. and Schuster, H. G. (1994): Separation of a mixture of independent signals using time delayed correlations, *Phys. Rev. Lett.*, Vol. 72, No. 23, pp. 3634–3637.
- [19] Amari, S.: 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 (1999).
- [20] Matsuoka, K., Ohya, M. and Kawamoto, M. (1995): A Neural Net for Blind Separation of Nonstationary Signals, *Neural Networks*, Vol. 8, No. 3, pp. 411–419.
- [21] Ikeda, S.: ICA on Noisy Data: A Factor Analysis Approach, in Girolami, M. ed., *Advances in Independent Component Analysis*, chapter 11, pp. 201–215, Springer-Verlag London Ltd. (2000).
- [22] Ikeda, S. and Toyama, K. (2000): Independent Component Analysis for Noisy Data –MEG data analysis, *Neural Networks*, Vol. 13, No. 10, pp. 1063–1074.
- [23] Cao, J., Murata, N., Amari, S., Cichocki, A. and Takeda, T.: A Robust ICA Approach for unaveraged single-trial auditory evoked fields data decomposition, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2001)*, pp. 445–450 (2001).
- [24] Kawanabe, M. and Murata, N.: Independent Component Analysis in the Presence of Gaussian noise based on estimating functions, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2000)*, pp. 39–44 (2000).
- [25] Toyama, K., Yoshikawa, K., Yoshida, Y., Kondo, Y., Tomita, S., Takanashi, Y., Ejima, Y. and Yoshizawa, S. (1999): A new method for magnetoencephalography: A three dimensional magnetometer-spatial filter system, *Neuroscience*, Vol. 91, No. 2, pp. 405–415.
- [26] Kawamoto, M., Matsuoka, K. and Ohnishi, N. (1998): A method of blind separation for convolved non-stationary signals, *Neurocomputing*, Vol. 22, No. 1-3, pp. 157–171.
- [27] Smaragdis, P. (1998): Blind separation of convolved mixtures in the frequency domain, *Neurocomputing*, Vol. 22, No. 1-3, pp. 21–34.
- [28] Ikeda, S. and Murata, N.: A method of blind separation based on temporal structure of signals, in *Proceedings of 1998 International Conference on Neural Information Processing (ICONIP’98)*, Vol. 2, pp. 737–742, Kitakyushu, Japan (1998).
- [29] Rickard, S., Balan, R. and Rosca, J.: Real-Time Time-Frequency Based Blind Source Separation, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2001)*, pp. 651–656 (2001).
- [30] Hyvärinen, A., Hoyer, P. and Inki, M. (2001): Topographic Independent Component Analysis, *Neural Computation*, Vol. 13, No. 7, pp. 1525–1558.

- [31] Bach, F. R. and Jordan, M. I.: Kernel Independent Component Analysis, Technical Report UCB//CSD-01-1166, University of California, Berkeley, (2001).
- [32] Matsuyama, Y., Katsumata, N. and Imahara, S.: Convex Divergence as a Surrogate Function for Independence: The f-Divergence ICA, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2001)*, pp. 31–36 (2001).
- [33] Minami, M. and Eguchi, S.: Robust Blind Source Separation by β -Divergence, to appear in *Neural Computation* (2002).
- [34] Akuzawa, T.: New Fast Factorization Method for Multivariate Optimization and its Realization as ICA Algorithm, in *Proceedings of International Workshop on Independent Component Analysis and Blind Signal Separation (ICA2001)*, pp. 114–119 (2001).
- [35] Lee, T.-W. (1998): *Independent Component Analysis*, Kluwer Academic Publishers.
- [36] Hyvärinen, A., Karhunen, J. and Oja, E. (2001): *Independent Component Analysis*, John Wiley & Sons, Inc.
- [37] Cichocki, A. and Amari, S. (2002): *Adaptive Blind Signal and Image Processing*, John Wiley & Sons, Inc.
- [38] Girolami, M. ed. (2000): *Advances in Independent Component Analysis*, Springer-Verlag London Ltd.
- [39] Haykin, S. ed. (2000): *Unsupervised Adaptive Filtering, Volume 1, Blind Source Separation*, Vol. 1, John Wiley & Sons, Inc.
- [40] <http://www.ica2001.org>.
- [41] <http://ica2003.jp>.