

2 段階独立成分分析の混合画像分離への応用

白崎 宏一・井上 卓・伊東 一良・一岡 芳樹*

大阪大学大学院工学研究科応用物理学専攻, *物質生命工学専攻 〒565 吹田市山田丘 2-1

Two-Stage Independent Component Analysis and Its Application to Extraction of Original Images from the Mixtures

Kohichi SHIRASAKI, Takashi INOUE, Kazuyoshi ITOH and Yoshiki ICHIOKA*

Graduate Course of Applied Physics, *Material and Life Science, Osaka University, 2-1, Yamadaoka, Suita 565

In signal processing, observed signals are usually mixtures of the sources. If these sources are statistically independent and the dimensions of source signals are equal to that of the mixed signals, the independent component analysis (INCA) can extract the original signals from the mixtures. In this paper, we propose a two-stage algorithm for INCA. This method combines the principal component analysis (PCA) and INCA. We also present the experimental results that show how this two-stage INCA works more effectively than the conventional INCA.

1. はじめに

認知心理学の分野において、カクテルパーティ効果という現象が知られている。例えば、パーティ会場では、多くの話し声が混じり合って聞こえてくるが、ある特定の相手の声のみに注目すると、かなりの程度、その相手の声を聞き取ることができるというものである。このようにわれわれは、複数の信号が混在した信号から特定の信号を分離することを日常生活の中で意識せずに行っている。しかし、電波による情報通信、ソナーアレイ信号処理、生体内システムの解析などの工学的分野においても、複数の信号の混在した信号から単一の信号を分離する問題が登場するが、容易にこの問題を解くことはできず、信号源分離問題と呼ばれている。近年、この信号源分離問題の解法のひとつとして、互いに独立な信号が混合した観測信号から、もとの独立な信号を抽出する方法¹⁻³⁾がいくつか提案されている。これらは、独立成分分析 (INCA: independent component analysis) と呼ばれ、混合前の信号は互いに独立であり、かつ、混合が決定論的に行われているという2つの仮定のみで独立成分を抽出するものであり、多次元信号に対して独立な信号に着目する新しい特徴抽出法として期待されている。

独立成分分析と同様、多次元信号に対する特徴抽出法の代表的なものに主成分分析 (PCA: principal compo-

nent analysis) がある。主成分分析は、信号間の分散の大きな成分を抽出し、それを信号の特徴とする手法である。主成分分析は、よく独立成分分析と比較され、主成分分析と独立成分分析との関係や、相違点などについて議論されている。しかし現在までのところ、主成分分析と独立成分分析を組み合わせることについての議論はされていない。主成分分析は、観測信号の統計的性質の多くを保持したまま観測信号次元数を削減できるので、独立成分分析を実行するにあたって、前処理として主成分分析を行えば、処理時間を大幅に短縮することができると思われる。

本論文では、汎用的、かつ効率よく独立成分分析を実行することを目的とし、主成分分析と独立成分分析を組み合わせた手法を考案し、混合画像からもとの画像を抽出する実験を報告する。主成分分析を実行するアルゴリズムとしては、従来の Jacobi 法を用い、独立成分分析を実行するアルゴリズムとしては、Burel のアルゴリズム⁴⁾、Oja の非線形型 PCA 学習アルゴリズム⁵⁾を用い、それぞれ比較、検討し、上述の組合せ手法の有効性を確認した。

2. 独立成分分析

複数の信号源から発信された互いに統計的に独立な信

号の和を、複数のセンサーで受信する場合を考える。\$i\$ 番目の信号源の出力値を確率変数 \$\xi_i\$ とし、これを要素とするベクトルを \$\xi\$ とする。各センサーが受信する値を \$x_i\$ とし、それを要素とするベクトルを \$\mathbf{x}\$ とおく。各センサーは線形的に重畳した信号を受信すると仮定すると、観測信号 \$\mathbf{x}\$ は

$$\mathbf{x} = A\xi \quad (1)$$

と表すことができる。\$A\$ は信号源群から観測信号への変換行列で未知である。信号源の出力 \$\xi_i\$ は互いに独立であるという条件のもとで、観測信号 \$\mathbf{x}\$ の集合より、\$\xi\$ を推定することを独立成分分析という。ただし、\$\xi\$ は直接求めることができないので、実際には \$\xi\$ の要素の順序が入れ替えられ、個々の要素が定数倍されたベクトル \$\mathbf{s}\$ を求めることになる。ベクトル \$\mathbf{s}, \xi, \mathbf{x}\$ の関係は

$$\mathbf{s} = P A \xi = H \mathbf{x} \quad (2)$$

と表すことができる。ただし、\$P\$ は任意の置換、\$A\$ は任意の対角行列である。独立成分分析は、行列 \$H\$ を推定する問題と考えることができる。つまり、ベクトル \$\mathbf{s}\$ の要素間の統計的従属性を最小にする線形変換 \$H\$ を求めることである。\$H\$ が求めれば、観測信号 \$\mathbf{x}\$ に作用させることによって、独立成分ベクトル \$\mathbf{s}\$ が得られることになる。

代表的な独立成分分析の解法として、Burel によって提案されている2層階層型ニューラルネットワークを用いた手法⁴⁾がある。これは、ネットワークに観測信号を入力として与え、自己組織化により独立成分を出力するようにニューラルネットワークの重みを学習させる。ネットワークの出力を与える最終層のニューロンを \$S_1, \dots, S_n\$ とし、その出力値を \$s_1, \dots, s_n\$ とする。ネットワークの出力 \$S_1, \dots, S_n\$ が互いに独立であるとき、

$$p_{s_1 \dots s_n}(s_1, \dots, s_n) = p_{s_1}(s_1) \dots p_{s_n}(s_n), \forall s_1, \dots, s_n \quad (3)$$

が成立する。ただし、\$p\$ は確率密度関数である。したがって評価関数として次の独立性を示す関数を用いる。

$$\int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} \left([p_{s_1 \dots s_n}(s_1, \dots, s_n) - p_{s_1}(s_1) \dots p_{s_n}(s_n)] \right)^2 * \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_i}} \exp(-s_i^2/2\sigma_i^2) ds_1 \dots ds_n \quad (4)$$

ここで記号*はコンボリューションを表す。現実の測定を考えると、高次のモーメントにおけるノイズ等の影響で正しい解が得られないことも考えられるので、ガウシアンフィルターを導入し、確率密度関数の平滑化を行っている。Burel のアルゴリズムは、誤差逆伝搬法を用い、この評価関数を減少させるようにニューラルネット

ワークの重みを変化させ、独立成分分析を実行する。

Burel のアルゴリズムは、独立な信号源の数と観測信号の数が等しくなければならないという制約があるが、独立な信号源の数よりも観測信号の数が多く場合でも、次のように拡張することができる。まず、観測信号ベクトルを独立要素数の小ベクトルに分割する。独立要素数は、主成分分析を用いることにより推定することができる。分割後、それぞれの小ベクトルに対する処理系では、独立要素数と観測信号次元数が一致しているため、独立成分分析が可能である。個々の処理系で独立成分分析を行った後、出力信号の小ベクトルの要素間の対応関係を調べ、順序の入替えと定数倍の補正を行う。以上に示した方法で、独立な信号源の数よりも観測信号の数が多く場合でも、Burel のアルゴリズムを適用し、独立成分分析を実行できる。拡張方法についての詳細は、本論文の主旨からはずれるので、この程度にとどめておく。

Karhunen らは、主成分分析をニューラルネットワークで実行する PCA 学習アルゴリズム⁶⁾に、非線形性を導入した非線形型 PCA 学習アルゴリズムを提案している。非線形性の導入は、もともと Oja らによって示唆されたもの⁷⁾なので、このアルゴリズムを、Oja の非線形型 PCA 学習アルゴリズムと呼ぶことにする。2層階層型ニューラルネットワークにおいて、入力層ニューロンの観測信号をベクトル \$\mathbf{x}\$ とする。出力層ニューロンの出力値をベクトル \$\mathbf{y}\$ とする。\$j\$ 番目の入力層ニューロンと、\$i\$ 番目の出力層ニューロンとの間の重みを \$w_{ij}\$ とする。このとき、非線形型 PCA 学習アルゴリズムは次式のように表される。

$$W_{k+1} = W_k + \alpha_k [\mathbf{x}_k - W_k f(W_k^T \mathbf{x}_k)] f(\mathbf{x}_k^T W_k) \quad (5)$$

ただし、\$k\$ は反復回数、\$W\$ は \$w_{ij}\$ を要素とする重み行列、\$\alpha\$ は利得係数、\$f\$ は非線形関数である。Karhunen らは、この学習アルゴリズムでは非線形性の導入によって、出力間の独立性が高められると報告している⁸⁾。これは非線形関数によって、出力 \$\mathbf{y}\$ の高次モーメントを計算しているからである。もし、この非線形関数がテイラー展開できると仮定すると、この非線形関数の導入により、出力 \$\mathbf{y}\$ の2次モーメントである相関のみならず、より高次のモーメントが計算に自動的に含まれることが容易に理解できる。

3. 2段階独立成分分析

観測信号次元数が大きい場合、独立成分分析を直接行うと膨大な時間を要する。時間的効率を向上させるためには、何らかの前処理が必要と考えられる。本論文で

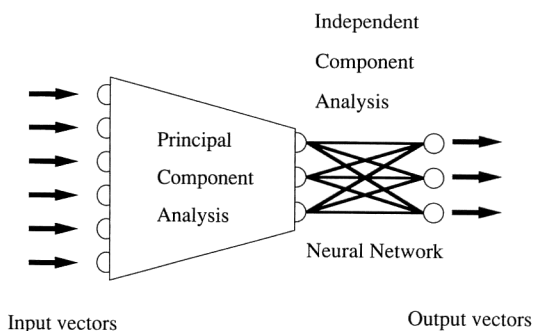


Fig. 1. Architecture of the two-stage independent component analysis.

は、Fig. 1 に示す、前段で主成分分析、後段で独立成分分析を行う手法を提案する。主成分分析は、入力信号の統計的性質をできる限り多く保持したまま次元削減を行うことができるので、前処理としては有効な手段と考えられる。

4. 計算機実験

本論文では、独立成分分析による混合画像からオリジナル画像の抽出を行った。基本的には、次のような考え方を利用する。互いに相関のない、画素値の平均がゼロの2つの画像から、決められた手順で双方の画素の値を順次取り出していくと、これらの2つの過程は独立な過程とみなせること、また相関があれば、これらは独立な過程とはみなせないことを利用する。

まず、独立成分分析の混合画像への適用の手順を説明する。 p を入力混合画像の枚数、 n をオリジナル画像の枚数とする($p \geq n$)。 i 番目の入力混合画像の、画素 t ($t = 1, 2, \dots, m$) における画素値を $x_i(t)$ とし、 $x_i(t)$ を要素にもつベクトルを $\mathbf{x}(t)$ (p 次元ベクトル) とする。 j 番目のオリジナル画像の、画素 t における画素値を $\xi_j(t)$ とし、 $\xi_j(t)$ を要素にもつベクトルを $\xi(t)$ (n 次元ベクトル) とする。 $\mathbf{x}(t)$ は、 $\xi(t)$ を用いて

$$\mathbf{x}(t) = A\xi(t) \quad (6)$$

と表せる。ただし、 A は t に依存しない未知の混合係数行列 ($p \times n$ 行列) である。この入力混合画像 $\mathbf{x}(t)$ に独立成分分析を適用すると

$$\mathbf{s}(t) = H\mathbf{x}(t) = PA\xi(t) \quad (7)$$

を満たす独立成分 $\mathbf{s}(t)$ を得ることができる。ただし、 P は任意の置換、 A は任意の対角行列である。得られた独立成分 $\mathbf{s}(t)$ は P, A の影響で $\xi(t)$ とは一致しない。しかし、混合画像からもとのオリジナル画像を抽出する




Fig. 2. Original images. (a) field in terraces, (b) jungle, (c) redwood forest.

場合、オリジナル画像同士の順番や画素値全体の値域の変化は本質的な問題ではない。

実験に用いたオリジナル画像を Fig. 2(a)~(c) に示す。画像のサイズ (m) は、 320×207 で、各画素の階調は256階調である。このオリジナル画像から Fig. 3(a)~(f) に示す入力混合画像を作成した。それぞれの混合画像におけるオリジナル画像の混合比 (式(1)の A に相当する) はランダムに選んだ。この実験では、独立要素数 (n) が3であり、観測信号ベクトルの次元数 (p) は6である。

独立成分分析を実行する前に、各入力混合画像に対して以下のような前処理を施しておく。まず、画素の平均値がゼロになるように、各画素値から平均画素値を引く。次に各混合画像の画素値を各混合画像の最大画素値




Fig. 3. Input images that were made by mixing the original images in random proportion.

で割り規格化しておく。

Burelのアルゴリズム、Ojaの非線形型PCA学習アルゴリズムをこれらの入力混合画像に適用して、オリジナル画像の推定を行うが、各手法の評価は、実行時間と式(8)に示す平均画素値誤差を用いた。

$$\text{error} = \frac{\sum_{t=1}^{\nu} |\hat{\xi}(t) - \xi(t)|}{\nu} \quad (8)$$

ただし、 t は画素番号、 ν は画素総数、 $\xi(t)$ はオリジナル画像、 $\hat{\xi}(t)$ は抽出された独立画像である。

Burelのアルゴリズムを適用する際、式(4)をそのまま評価関数として適用することはできない。式(4)をフーリエ変換し、それをゼロのまわりでテイラー展開する。これは、出力におけるさまざまな次数のモーメントを評価することに相当し、計算可能である⁴⁾。本実験で

は、4次までのすべてのモーメントを計算し、これらを用いて式(4)の近似値を求めた。ただし、 σ_i は1とした。また、誤差逆伝搬法だけではネットワークの収束が遅いため、学習方程式に慣性項を付加し、さらにその慣性係数を学習途中に変えることにより、学習時間の短縮に成功している。学習のときに用いたパラメータは、学習係数が0.5、慣性係数が0.1(学習初期段階)、0.9(学習終了段階)である。学習は、前述の評価関数の近似値の低減率が、 1.0×10^{-5} を下回ったときに終了とした。

Ojaの非線形型PCA学習アルゴリズムを適用するにあたって、学習時に用いたパラメータは、結合荷重の初期値が、区間 $(-1, 1)$ のランダム値とし、利得係数の初期値を0.03とし、その後ゆっくり減少させ、反復回数は、 $300 \times$ 画素数とした。また、式(5)における非線

形関数 f としては、Karhunen らの論文⁵⁾で最もよく使われていた非線形関数 $f(\eta) = \text{sgn}(\eta) \ln(1 + 5|\eta|)$ とした。これは、提案されている非線形型 PCA 学習アルゴリズム⁵⁾では、出力を非線形処理しているが、本実験では、オリジナル画像の混合が線形に行われているため、線形出力 $y = W_k^T x_k$ とした。

Burel のアルゴリズムを Fig.3 に示した入力混合画像群に適用した結果、オリジナル画像を抽出することができ、人間の目では、もとのオリジナル画像と得られた独立画像を区別することができなかった。各画像に関する平均画素値誤差は、段々畑 (Fig. 2(a)) が 5.65, ジャングル (Fig. 2(b)) が 3.18, 森 (Fig. 2(c)) が 7.04 であった。実行時間は、Sun Microsystems 社製の SPARC

station 5 を用いて約 1 週間である。

次に筆者らの提案した手法を用いた結果を示す。Fig. 3 に示した 6 枚の入力混合画像に主成分分析を実行し、固有値の大きい順に第 3 主成分までの画像を得る。この得られた 3 枚の主成分画像を入力信号として独立成分分析を実行する。

独立成分分析を実行するアルゴリズムとして Burel のアルゴリズムを用いた場合、各画像に関する平均画素値誤差は、段々畑が 4.78, ジャングルが 2.64, 森が 7.44 であった。実行時間は、5 時間 45 分である。主成分分析を前段で実行することによって、平均画素値誤差をあまり変化させずに、処理時間効率を約 30 倍向上させることができた。




Fig. 4. Results of principal component analysis using Jacovi method. (a) first principal component, (b) second principal component, (c) third principal component.




Fig. 5. Results of two-stage independent component analysis using Oja's nonlinear PCA learning algorithm. (a) field in terraces, (b) jungle, (c) redwood forest.

Table 1. Comparison of results of (a) 6 images, (b) 3 images.

Algorithms		Processing time	Mean errors		
PCA part	INCA part		Field in terraces	Jungle	Redwood forest
(a) No processing	Burel's algorithm	approximately 1 week	5.65	3.18	7.04
Jacobi method	Burel's algorithm	5 h 45 min	4.78	2.64	7.44
Jacobi method	Oja's nonlinear PCA type learning algorithm	20 min 17 s	5.53	2.33	9.94
(b) No processing	Burel's algorithm	35 h 20 min	5.75	3.31	7.63
Jacobi method	Burel's algorithm	14 h 29 min	5.49	3.39	7.53

次に独立成分分析を実行するアルゴリズムとして Burel のアルゴリズムを用いる代わりに、Oja の非線形型 PCA 学習アルゴリズムを適用した。各画像に関する平均画素値誤差は、段々畑が 5.53、ジャングルが 2.33、森が 9.94 であった。実行時間は、20 分 17 秒である。Burel のアルゴリズムを直接適用する場合と比較して、平均画素値誤差はあまり変化せず、処理時間効率率は約 500 倍向上している。主成分分析を実行して得られた画像を Fig. 4 (a)~(c) に示し、抽出された独立成分画像を Fig. 5 (a)~(c) に示す。上に記したいずれの手法を用いても、Fig. 5 (a)~(c) の画像とほとんど変わらない独立画像を得ることができる。

主成分分析が、観測信号次元数の削減のみに有効であるか確認するため、独立信号数と観測信号次元数が等しい場合の実験を行った。入力混合画像には、Fig. 3 の (a), (b), (f) の 3 枚の画像を用いた。

主成分分析を行わず、Burel のアルゴリズムを直接入力混合画像群に適用した場合、各画像に関する平均画素値誤差は、段々畑が 5.75、ジャングルが 3.31、森が 7.63 であった。実行時間は、35 時間 20 分である。次に前処理として主成分分析を行い、主成分分析によって得られた画像群に対して、Burel のアルゴリズムを適用し、独立成分分析を実行した場合、各画像に関する平均画素値誤差は、段々畑が 5.49、ジャングルが 3.39、森が 7.53 であった。実行時間は、14 時間 29 分である。主成分分析を前段で実行することにより、平均画素値誤差をほとんど変えず、処理時間効率を約 2.5 倍向上させることができた。主成分分析は観測信号次元数の削減のみならず、独立成分分析の実行を容易にさせていることがわかる。

以上の実験について、各手法を比較すると、Table 1 のようになる。Burel のアルゴリズムを用いた場合、処理時間に関しては、主成分分析を前段で実行した場合のほうが約 30 倍向上している。このことは、主成分分析による観測信号次元数の削減の効果の高さを示している。Burel のアルゴリズムは、観測信号次元数が増える

につれ計算量が急速に増大するが、主成分分析によって観測信号次元数を独立信号数まで削減できるので、この問題を解決することができる。Oja の非線形型 PCA 学習アルゴリズムを独立成分分析として用いた場合、処理時間に関しては、Burel の手法を直接適用した場合と比較して、約 500 倍向上している。Burel の手法に前処理として主成分分析を実行した場合と比較しても、約 17 倍向上している。これは、Burel のアルゴリズムが、出力信号間の独立性を高めるのに、高次モーメントを直接計算しているのに対して、Oja の非線形型 PCA 学習アルゴリズムでは、非線形関数を用いているため、計算量が少なくなっていることが理由であると考えられる。

5. ま と め

本論文では、独立成分分析を混合画像分離問題に適用し、独立成分分析を実行する前に前段で主成分分析を行うことによって、平均画素値誤差をほとんど変化させずに処理時間効率を向上させることができることを確認した。

本論文では示していないが、Oja の非線形型 PCA 学習アルゴリズムのみを混合画像へ適用したところ、独立画像を抽出することはできなかった。この理由は現在のところ不明である。しかし、前段で主成分分析を実行し、後段で Oja の非線形型 PCA 学習アルゴリズムを実行した結果、既に述べたように独立画像の抽出に成功した。Burel のアルゴリズムの代わりに、この非線形型 PCA 学習アルゴリズムを適用することによって、さらに処理時間効率を向上させることが可能となった。

主成分分析をニューラルネットワークで実行する手法として、Oja の PCA 学習アルゴリズムがある。このアルゴリズムは、非線形型 PCA 学習アルゴリズムと同じ構造のネットワークの上で実行されるため、両者を組み合わせると 2 段階独立成分分析を行うことが可能である。また、両者は学習式もほぼ同じで、ただ非線形性の存在のみが異なるだけである。このため、これらの Oja の学習アルゴリズムは、2 段階独立成分分析のハードウェア

ア化を考えると魅力的なアルゴリズムである。しかし、筆者らの行った実験では、この主成分分析を実行するPCA学習アルゴリズムは収束に時間がかかり、出力結果が結合荷重の初期値に依存性を示し、良好な結果を得ることが困難であった。実用化にはかなりの改良が必要であると考えられる。

文 献

- 1) C. Jutten and J. Hraut: "Blind separation of sources, Part 1: An adaptive algorithm based on neuromimetic architecture," *Signal Process.*, **24** (1991) 1-10.
- 2) A. J. Bell and T. J. Sejnowski: "An information-maximization approach to blind separation and blind deconvolution," *Neural Comput.*, **7** (1995) 1129-1159.
- 3) P. Comon: "Independent component analysis, A new concept?," *Signal Process.*, **36** (1994) 287-314.
- 4) G. Burel: "Blind separation of sources: A nonlinear neural algorithm," *Neural Networks*, **5** (1992) 937-947.
- 5) J. Karhunen and J. Joutsensalo: "Representation and separation of signals using nonlinear PCA type Learning," *Neural Networks*, **7** (1994) 113-127.
- 6) E. Oja: "Neural networks, principal components, and subspaces," *Int. J. Neural Syst.*, **1** (1989) 61-68.
- 7) E. Oja, H. Ogawa and J. Wangviwattana: "Learning in nonlinear constrained Hebbian networks," *Int. Conf. of Artificial Neural Networks* (Amsterdam, North-Holland, 1991) pp. 385-390.