

BCIにおける多チャネル脳波の特徴抽出法の検討

On Feature Extraction from Multi-Channel Brain Waves Used for Brain Computer Interface

齋藤宏哉[†] 中山謙二[†] 平野晃宏[†]
[†] 金沢大学大学院 自然科学研究科 電子情報工学専攻

Hiroya SAITO[†] Kenji NAKAYAMA[†] Akihiro HIRANO[†]

[†]Graduate School of Natural Science and Technology, Kanazawa Univ.

E-mail: nakayama@t.kanazawa-u.ac.jp

アブストラクト

脳波のフーリエ変換と、階層形ニューラルネットワーク (MLNN) を用いるブレイン・コンピュータ・インターフェイス (BCI) に関して、脳波から多くの情報を得るために頭部の複数個所（多チャネル）で測定される場合が多く、多チャネルのデータから如何に特徴を抽出するかという問題がある。特徴抽出法に、統計的に独立な成分を抽出する独立成分解析 (ICA) があるが、抽出後に特徴成分が並べ変わる問題 (Permutation 問題) があることから、単に1回の多チャネル測定データを MLNN の入力とするだけではうまく分類できないことが分かっている。本稿では、ICA の Permutation 問題の影響を受けない MLNN の構成について検討する。また、多次元データのクラスタリング手法に自己組織化特徴マップ (SOFM) がある。SOFM をフーリエ変換による特徴抽出と組み合わせることで、入力データの情報量を操作し、分類性能の向上を図る。

ABSTRACT

FFT and Multilayer Neural Networks (MLNN) have been applied to 'Brain Computer Interface' (BCI). In the BCI systems, how to extract individual features of mental tasks from multi-channel brain waves is an important problem. Independent Component Analysis (ICA) is one of feature extraction methods. However, there exists a Permutation Problem, that is, feature extracting order is easily changed data by data. Therefore, ICA cannot be effectively used for generating the MLNN input data.

In this paper, we try to develop MLNN structures, which can reduce effects of the permutation problem. Furthermore, Self-Organizing Feature Map (SOFM) is applied to generating the MLNN input data. Classification performance can be improved by increasing dimension of the SOFM output.

1 まえがき

近年、人間とコンピュータをつなぐインターフェイスとして様々な新しいインターフェイスが検討されており、その中で、人間の脳波を解析して、コンピュータとのインターフェイスとする、ブレイン・コンピュータ・インターフェイス (BCI) が注目されている。BCI の基本原理は、被験者の脳波や脳磁波を多チャネルで測定し、そのデータの特徴を解析して、被験者がイメージしたこと (メンタルタスク) を推定し、それに基づいてコンピュータや機械を操作することである [1][2]。

BCI の方式としては、帯域のパワースペクトルと非線形分類、AR モデルと線形分類、空間パターンと線形分類、隠れマルコフモデル、などを用いる方法がある [3], [4]。また、ニューラルネットワークの BCI への応用も活発に検討されている [5]-[9]。これまでの研究で脳波のフーリエ変換と階層形ニューラルネットワークを用いる方法について、有効な前処理の方法が提案され、ある程度の分類性能を持つ BCI が構築されている [11]-[12]。しかし、脳波の特徴抽出に独立成分解析 (ICA) を用いると、従来の方法ではチャネル毎の特徴成分の並べ変えがおきることから、うまく分類できないことが分かっている [13]。

本稿では、分類に用いる階層形ニューラルネットワークの構成を変更し、ICA の特徴抽出による並べ変え問題 (Permutation 問題) を解消することで分類性能の向上を図る。また、多次元データのクラスタリング手法である自己組織化特徴マップ (SOFM) を特徴抽出に取り入れ、脳波の特徴量を射影する特徴空間の大きさを変更することで、情報量を操作し、分類性能にどのような影響があるか調査する。

2 脳波の測定とメンタルタスク

本稿では、コロラド州立大学が Web 上で公開している脳波データを用いる [10]。脳波の測定の際に、用いられた

メンタルタスクは、次の5つである。

- できるだけリラックスする (Baseline)
- 掛け算を暗算でする (Multiplication)
- 手紙の文を考える (Letter-composing)
- 回転する3次元物体を想像する (Rotation)
- 数字を順番に書くことを想像する (Counting)




図 1: 電極の位置

脳波を測定する際の電極の位置を、図 1 に示す、C3, C4, P3, P4, O1, O2, EOG の 7 チャンネルである。EOG は、まばたきなどの眼球の運動による信号を検出する電極である。各メンタルタスクに対して、10 秒間測定し、250Hz でサンプリングされたので、1 チャンネルあたり $250\text{Hz} \times 10\text{sec} = 2,500$ サンプルのデータがある。7 チャンネル分のデータが、1 つのデータセットとなる。

3 脳波データの特徴抽出

脳波データをニューラルネットワークに入力するにあたり、有用な特徴量を抽出するために以下のような処理を行う [11]-[12]。

- フーリエ変換による特徴量抽出
- 平均化によるサンプル数低減
- データの非線形正規化

以上のような特徴抽出を経て、ニューラルネットワークの入力データとしては、7 チャンネル分並べたものを用いる。

4 階層形ニューラルネットワークによるメンタルタスクの分類

メンタルタスクの分類には隠れ層が 1 層の 2 層形ニューラルネットワークを用いる。活性化関数として、シグモイド関数を用いる。入力ユニット数が 1 チャンネルあたり、10 サンプルを 7 チャンネル分用意するので、合計 70 個であり、出力ユニットは 5 種類のメンタルタスクに対応して 5 個用いる。目標出力としては、該当するメンタルタスクに対応する出力ユニットに 1、その他は 0 を割り当てる。最も大きな値を持つ出力ユニットに該当するメンタルタスクを推定結果とする。もし、出力が全体的に小さい値のときは、判定不能 (リジェクト) とする。結合荷重の学習はバックプロパゲーション (BP) 法で行った。

4.1 シミュレーション条件

5 種類のメンタルタスクに対して、10 秒間の測定を各被験者について、10 回ずつ行ったので、合計 50 組のデータセットがある。そのうち、40 セットを学習に、残りの 10 セットをテストに用いる。テストに用いるデータセットの選択方法を 5 回変えて、分類を行い、その平均値で推定能力を評価する [3]。ニューラルネットワークの各種パラメータは以下のように設定する。正答率の向上を目的に分類性能を比較するため、リジェクトのための閾値は 0 とする。

- ・活性化関数: シグモイド関数
- ・隠れ層のユニット数: 20
- ・セグメント分割: 無し
- ・学習係数: 0.01
- ・学習回数: 30000 回
- ・結合荷重の初期値: ± 0.1 の範囲でランダム
- ・リジェクトする閾値: 0

以下の表 1 が、フーリエ変換と誤差逆伝搬 MLNN により、ある被験者の測定データを分類したものである。以降はこの分類性能と比較して特徴抽出法を検討する。

タスク	B	M	L	R	C	平均
正答率 [%]	90	90	60	80	100	84

表 1: 従来法による分類結果

5 脳波の独立成分解析 (Independent Component Analysis: ICA)

独立成分解析 (ICA) は、多変量データ解析の手法の一つで、変数の独立性に基づいた確率変数の分解手法である。

独立な n 個の信号源から発生する未知の信号を

$$\mathbf{s}(t) = (s_1(t), \dots, s_n(t))^T$$

とし、この原信号が線形に混ぜ合わされ n 箇所から観測されたとする。観測信号

$$\mathbf{x}(t) = (x_1(t), \dots, x_n(t))^T$$

は、行列 A を時間 t によらない線形作用素とすると

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

と仮定できる。ICA とは、このような条件のもとで、原信号 $\mathbf{s}(t)$ 及び作用素 A に関する知識を一切持たずに、観測信号から原信号を復元することと定義される。

原信号 $\mathbf{s}(t)$ も線形作用素 A も未知なことから、復元される独立成分の大きさや順序は一意ではなくなる。ICA のこの性質が、7 チャンネル 7 成分のデータを 1 つのデータセットとする本研究において最もネックとなる。

ICA のアルゴリズムとして様々なものが提案されているが、本研究では、尖度を用いた不動点反復法アルゴリズムにより独立成分を推定する FastICA を用いる。 [14]

6 複合形 MLNN 構成

6.1 7NN 並列方式

ICA の Permutation 問題を解決するため、提案法として NN を 7 つ用いる方式で分類を行なう。7 つの成分に対してそれぞれ固有の NN を用意し、入力データに 1 成分のみのデータを用いることで、成分順の影響を受けずにメンタルタスク固有の特徴量を分類し正答率の向上を期待する。この方式を図 2 に図示する。

また、第 4.1 節のシミュレーション条件から、以下のパラメータを変更する。

・学習係数：0.04

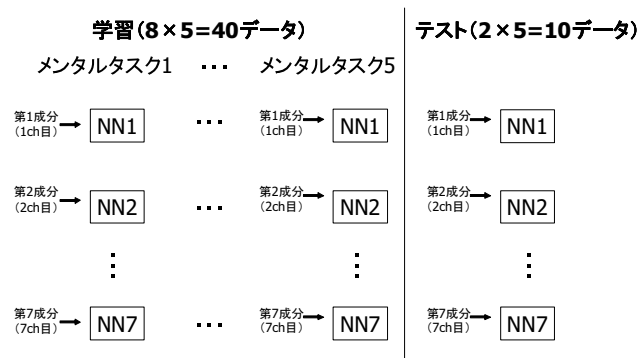


図 2: 7NN 並列方式

並列な MLNN の分類結果を統合する評価方式として、以下の 3 通りを考える。

多数決方式 各 NN でメンタルタスクを分類し、分類された回数が最も多いメンタルタスクを分類結果とする。ただし、メンタルタスク数の最大値が 2 つ以上あった場合はリジェクトとし、どちらにも含まない。

加算方式 各 NN の出力を各出力ノード毎に加算し、加算後の 5 個の出力の最大値で分類する。

2 段 7NN 方式 (NN 数)7×(NN の出力数)5 = 35 個の出力を入力データとして、更に 2 段目の NN により分類する。7 個の NN の出力が正しくない場合でも、それを入力として NN で分類することにより、分類性能の向上を図る。2 段 7NN 方式を図 3 に示す。

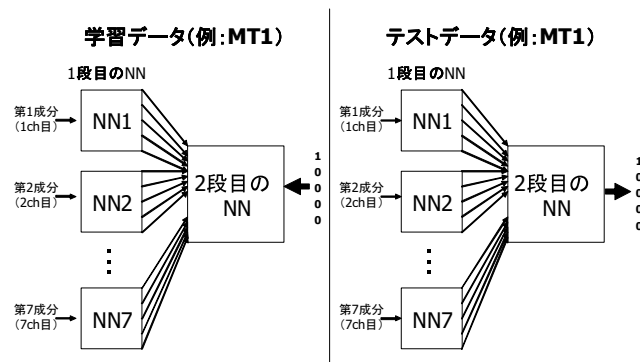


図 3: 2 段 7NN 方式

正答率 [%]	B	M	L	R	C	平均
多数決	60	70	50	70	40	58
加算	60	70	90	90	40	70
2 段 7NN	60	60	80	80	50	66

表 2: ICA しない場合の分類結果 (7NN 並列方式)

正答率 [%]	B	M	L	R	C	平均
多数決	40	20	0	40	0	20
加算	50	40	30	30	10	32
2 段 7NN	50	30	40	40	10	34

表 3: ICA を用いた場合の分類結果 (7NN 並列方式)

ICA を用いない元データでは、従来の方式よりは正答率は下がっているが、65% 前後の値は保っているのに対し、ICA を用いた場合は 30% 前後と、全く分類出来ない。これは、フーリエ変換と MLNN を用いたメンタルタスクの分類に成分順の特徴が大きく関係していることが原因であると考えられる。

6.2 1NN 並列方式

前節では、7 個の NN を用い成分ごとに分類を行なったが、同じ特徴が違う成分に現れることになり、Permutation の影響が残る。

そこで、1 個の NN に全ての成分を独立に入力する方式を検討する。一つのメンタルタスクに対して 7 個の成分があるが、1 個の成分を NN に入力して、その出力が目標値に近づくように NN を学習する。これを全てのメンタルタスク、7 個の成分に対して行う。テストでは、1 個の成分を NN に入力して出力を求める。1 つのメンタルタスクにおいて 7 個の成分に対する 7 個の出力を求めて、7NN と同様な分類を行う。出力の統合には、多数決方式と加算方式を用いる。

この方式により、成分順の影響を一切受けなくし Permutation 問題の改善を図った。この方式を図 4 に図示する。

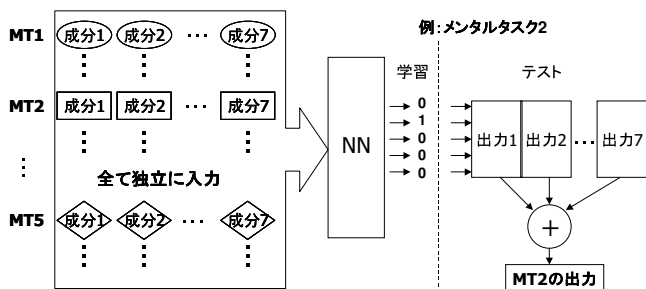


図 4: 1NN 直列方式

第 4.1 節のシミュレーション条件から、以下のパラメータを変更する。

- ・学習係数：0.04
- ・学習回数：60000 回

正答率 [%]	B	M	L	R	C	平均
多数決	0	50	20	30	40	28
加算	30	50	30	30	30	34

表 4: ICA しない場合の分類結果 (1NN 直列方式)

正答率 [%]	B	M	L	R	C	平均
多数決	10	30	20	30	30	24
加算	10	50	30	60	70	44

表 5: ICA を用いた場合の分類結果 (1NN 直列方式)

7NN 方式に比べて Permutation の影響を低減できるため、ICA を用いた場合での正答率が向上したが、依然として高い正答率は得られていない。一方、ICA を用いない場合は正答率は低下した。これらの理由として、各成分に分離することにより、7個を同時に用いる場合に比べて、NN の入力データの特徴が弱くなっていることや、分類すべき入力データの数が増えていること等が考えられる。

6.3 チャンネル位置による ICA を用いたメンタルタスクの分類

これまでの結果から、1 測定データにおける 7 成分全てを ICA することで、各成分固有の特徴が失われていることが推測できる。そこで、図 1 で表される電極の内、前頭葉と頭頂葉の間の中心溝 (central) に位置するチャンネル C3・C4、頭頂葉 (parietal lobe) に位置するチャンネル P3・P4、後頭葉 (occipital lobe) に位置するチャンネル O1・O2 の 3 組の 2 チャンネルでそれぞれ FastICA より独立成分の推定を行ない、その第一成分のみを並べ、更にはまばたきなどによる目の筋電を検出するチャンネル EOG の成分を付け加えたものを、1 入力データとして、メンタルタスクの分類を行なう。これにより、脳のチャンネル位置固有の特徴を抽出し、Permutation の影響を受けずに分類することが可能である。

第 4.1 節のシミュレーション条件から、以下のパラメータを変更する。

- ・隠れ層のユニット数：8

タスク	B	M	L	R	C	平均
正答率 [%]	40	70	60	80	80	66

表 6: チャンネル位置による ICA を用いた分類結果

本稿における ICA を用いた BCI においては最も高い正答率を示したが、従来法に比べると 20% も低い為、特徴抽出の効果は表れていない。これは、ICA による特徴量の損失、もしくは成分数が減ったことによる情報量の減少が原因だと考えられる。しかし、測定におけるチャンネル数が無数にあり、特徴量を保ちながら情報量を削減したい場合には有効であると思われる。その際には、体性感覚野や運動野といった脳の活動部位とメンタルタスクとの対応を考慮する必要がある。

7 自己組織化特徴マップと階層型ニューラルネットワークによるメンタルタスクの分類

7.1 自己組織化特徴マップ (Self-Organizing Feature Map: SOFM)

自己組織化特徴マップ (SOFM) は、ニューラルネットワークの一種で、中間層の無い 2 階層型の教師無し競合学習モデルである。

SOFM は入力層と出力層であるマップ層の二つの層から構成されている。マップ層には M 個のノードが直線状、格子状や球状等 (本稿では 2 次元の格子状) に配置され、 n 次元の入力層は、入力データの次元と等しい数の入力ノードから構成されている。マップ層の各ノードと入力層に属する全てのノードの間には結合荷重 w_j , $j = 1, 2, \dots, M$ が与えられている。図 5 に SOFM の概念図を示す。




図 5: SOFM の概念図

以下に SOFM のアルゴリズムを示す。

Step1 ネットワークの初期化

入力層とマップ層の間の全ての重みの初期値 $w_j(0)$ をランダムに設定する。

Step2 入力ベクトルの入力

入力層に入力ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_n)$ を入力する。

Step3 マップ層で入力ベクトルとの距離を計算し、最小ノードを選択

マップ層では、各ノードの重みベクトルと入力ベクトルとの距離を計算する。ここで距離の算出には様々な方法があるが、本稿ではユークリッド距離を用いる。

$$|\mathbf{x} - \mathbf{w}_c| = \min |\mathbf{x} - \mathbf{w}_j| \quad j = 1, 2, \dots, M \quad (1)$$

上式より、距離が最小となるノード c を選択し、このノードを勝者ノードとする。

Step4 重みベクトルの学習

勝者ノードとその近傍ノードの重みベクトルが次式により更新される。

$$\mathbf{w}_j(t) = \begin{cases} \mathbf{w}_j(t) + \eta(t)[\mathbf{x}(t) - \mathbf{w}_j(t)] & j \in \Lambda_c \\ \mathbf{w}_j & \text{Otherwise} \end{cases} \quad (2)$$

ここで、 $\eta(t)$ は学習回数に応じて減衰する学習率であり、 Λ_c は勝者ノード c の近傍ノードの範囲を決定する近傍関数である。こちらも学習回数に応じて縮小する。本稿では、

$$\eta(0) = 0.1$$

$$\eta(t) = \eta(0) \left(1 - \left(\frac{t}{T}\right)^2\right)$$

により、学習率を決定する。 T は学習回数、 t は現在の学習回数を表す。 $T = 1000$ の学習率を図6に示す。

近傍関数は、SOFMによって様々な形状を取り入れることができるが、本稿では $(c+d, c+d)$, $(c-d, c+d)$, $(c+d, c-d)$, $(c-d, c-d)$ を頂点とする正方形形状の内部を近傍関数 Λ_c とする。 d は学習回数と共に減少し、次式で表される。

$$d(0) = \text{round}(0.3\sqrt{(M_{\text{row}})(M_{\text{cul}})})$$

$$d(t) = \text{round}\left(d(0) \left(1 - \left(\frac{d(0) - 1}{d(0)}\right) \left(\frac{t}{T}\right)^2\right)\right)$$

$\text{round}()$ は $()$ 内の数の小数点以下の四捨五入を表す。 $T = 1000$ の時の $d(t)$ を図7に示す。




図6: 学習率 $\eta(t)$




図7: 近傍距離 $d(t)$

Step5 Step2 へ戻る

Step2~Step5の動作を繰り返して、重みを学習していく。

7.2 SOFM の特徴空間における分類

以下の条件で、従来の MLNN への入力データを SOFM の特徴空間に射影する。

- ・マップ層 (正方形型) の一辺のノード数:50
- ・学習回数:500

特徴空間を図8、表7で示す。




図8: SOFM の特徴空間への写像

色	メンタルタスク
青	Baseline
赤	Multiplication
緑	Letter-composing
ピンク	Rotation
黄	Counting

表7: メンタルタスク対応表

SOFM における入力データの最近傍ノードからのユークリッド距離を、メンタルタスクの特徴量として MLNN の入力とする。入力データの一例を図9に示す。




図9: SOFM を用いた MLNN への入力データ

7.3 階層形ニューラルネットワークによるメンタルタスクの分類

以下の条件で、SOFM に前処理後の入力データを学習させ、MLNN への入力データを作成する。特徴空間の大

大きさがそのまま入力データの大きさとなるため、情報量の変更により、分類性能にどのように影響するかを検討する。

- ・マップ層(正方形型)の一辺のノード数:5, 10, 50
- ・学習回数:100

その他のパラメータは第 4.1 節と同じである。分類結果を表 8 に示す。

正答率 [%]	B	M	L	R	C	平均
5×5	90	80	70	90	90	84
10×10	100	90	70	90	90	88
50×50	100	90	70	100	90	90

表 8: SOFM を用いた場合の分類結果

従来の方式では、入力データのサンプル数は 70 サンプルであるので、 $5 \times 5 = 25$ サンプルで SOFM した場合、正答率は低下せずにサンプル数を約 36% に削減できることが分かった。また、SOFM のサンプル数を増やした場合では、サンプル数の増加に伴い、正答率も向上した。これは、特徴空間の増大により空間の分解能が上がり、分類に有効な特徴量が増加したからと考えられる。

8 まとめ

多チャンネルの脳波のフーリエ変換と階層形ニューラルネットワークを用いた BCI について、メンタルタスクの分類に有効な特徴抽出法を検討した。

脳波の独立成分解析 (ICA) の抽出成分の並び換え問題を解決する為に、ニューラルネットワークの構成を検討したが、分類性能の改善には至らなかった。これは、ICA によりメンタルタスクに関する情報が変化しているということも考えられるので、バイズ分類器のような確率モデルに基づいた分類器の検討を含めて調査する必要がある。

また、多次元データのクラスタリング手法である自己組織化特徴マップ (SOFM) を特徴抽出に用いることにより、同程度の分類性能における入力データ量の削減、または入力データ量増加による分類性能の向上が確認できた。SOFM は、特徴空間の形状や近傍距離の算出法において改良形も提唱されている為、BCI の特徴抽出に有効な方式を検討していきたい。

参考文献

[1] G.Pfurtscheller, C.Neuper, C.Guger, W.Harkam, H.Ramoser, A.Schlögl, B.Obermaier, and M.Pregenzner, "Current trends in Graz brain-computer interface (BCI) research", IEEE Trans. Rehab.Eng., vol.8, pp.216-219, 2000.

[2] B.Obermaier, G.R.Muller, and G.Pfurtscheller, "Virtual keyboard" controlled by spontaneous EEG activity, IEEE Trans. Neural Sys. Rehab. Eng., vol. 11, no. 4, pp.422-426, Dec. 2003.

[3] C.Anderson and Z.Sijercic, "Classification of EEG Signals from Four Subjects During Five Mental Tasks," In Solving Engineering Problems with Neural Networks: Proceedings of the Conference on Engineering Applications in Neural Networks (EANN'96), ed. by Bulsari, A.B., Kallio, S., and Tsaptsinos, D., Systems Engineering Association, PL 34, FIN-20111 Turku 11, Finland, pp.407-414, 1996.

[4] G.Pfurtscheller and C.Neuper, "Motor imagery and direct brain-computer communication," Proc. IEEE, vol. 89, no. 7, pp.1123-1134, July 2001.

[5] J.R.Millan, J.Mourino, F.Babiloni, F.Cincotti, M.Varsta, and J.Heikkonen, "Local neural classifier for EEG-based recognition of metal tasks," IEEE-INNS-ENNS Int. Joint Conf. Neural Networks, July 2000.

[6] K.R.Muller, C.W.Anderson, and G.E.Birch, "Linear and non-linear methods for brain-computer interfaces" IEEE Trans. Neural Sys. Rehab. Eng., vol. 11, no. 2, pp.165-169, 2003.

[7] J.R.Millan, "On the need for on-line learning in brain-computer interfaces," Proc. IJCNN, pp.2877-2882, 2004.

[8] G.E.Fabiani, D.J.McFarland, J.R.Wolpaw, and G.Pfurtscheller, "Conversion of EEG activity into cursor movement by a brain-computer interface (BCI)," IEEE Trans. Neural Sys. Rehab. Eng., vol. 12, no. 3, pp.331-338, Sept. 2004.

[9] C.W.Anderson, S.V.Devulapalli, and E.A.Stolz, "Determining mental state from EEG signals using neural networks", Scientific Programming, Special Issue on Applications Analysis, vol.4, no.3, pp.171-183, Fall, 1995.

[10] <http://www.cs.colostate.edu/eeg/>

[11] 稲垣清人, 中山謙二, "ニューラルネットワークによる脳波に基づくメンタルタスクの分類", 電子情報通信学会, 信学技法, Vol.105 No.174 pp.25-30, SIP2005-54, 2005.07.

[12] K.Nakayama and K.Inagaki, "A brain computer interface based on neural network with efficient pre-processing", Proc.IEEE, ISPACS2006, Yonago, Japan, pp.673-676, Dec.2006.

[13] REBOLLEDO MENDEZ Jovan David, "Brain Computer Interface Based on ICA and Neural Network", 金沢大学大学院 修士論文, 2007

[14] 根本幾, 川勝真喜, "詳解 独立成分分析 信号解析の新しい世界", 東京電機大学出版局, 2005