

脳波判別のための信号源分離を用いたアンサンブル学習

西納 修一^{1,a)} 吉川 大弘^{1,b)} 古橋 武^{1,c)}

受付日 2017年11月13日, 再受付日 2017年12月30日,
採録日 2018年1月27日

概要: 近年, Brain-Computer Interface (BCI) が注目を集めている. BCI では, ユーザの脳波を計測・判別することで, 外部機器の操作や他者とのコミュニケーションを行う. しかしながら, 脳波の S/N 比がきわめて低いため, 個々の脳波を判別することは困難であり, 判別に先立ってノイズを低減させるための前処理が必要となる. 脳波におけるノイズ低減の手法としては, ブラインド信号源分離がある. 本論文では, 脳波の特徴の 1 つである事象関連電位の抽出に適したブラインド信号源分離の手法を提案する. さらに, 信号源分離とアンサンブル学習を組み合わせることによって, 脳波における判別に有効な成分を抽出し, 判別を行う手法について提案する.

キーワード: Brain Computer Interface, ブラインド信号源分離, アンサンブル学習, 特徴量抽出

Ensemble Learning for EEG Signal Discrimination Using Blind Source Separation

SHUICHI NISHINO^{1,a)} TOMOHIRO YOSHIKAWA^{1,b)} TAKESHI FURUHASHI^{1,c)}

Received: November 13, 2017, Revised: December 30, 2017,
Accepted: January 27, 2018

Abstract: Recently Brain-Computer Interface (BCI) has been paid attention. BCI allows a user to control external devices and to communicate with other people by measuring and discriminating EEG. However, it is very difficult to discriminate EEG in a single trial because of low signal-to-noise ratio of them. Thus, preprocessing for noise reduction is used. Blind source separation is useful for the noise reduction. This paper proposes about blind signal separation method for extracting event-related potential that is one of the EEG features. This paper also proposes an EEG discrimination method which extracts useful features and discriminates them by combining ensemble learning with blind source separation.

Keywords: brain computer interface, blind source separation, ensemble learning, feature extraction

1. はじめに

近年, Brain Computer Interface (BCI) [1] についての研究が注目を集めている. BCI とは, ユーザの脳活動を計測することで, ユーザが筋肉を用いずに思考のみで外部機器の操作を可能にするシステムのことである. BCI では, 脳信号計測を行い, そこから抽出した特徴量を用いて思考判別を行うことで, コンピュータや車いすといった

外部機器を操作する. 脳活動を計測する手段としては, 非侵襲であり, 計測機器が比較的安価であることから, 脳波 (EEG, Electroencephalogram) [2] が用いられることが多く, 特定の周波数帯域や事象関連電位 (ERP, Event-Related Potential) といった特徴量に着目することで思考判別を行う.

しかしながら, 脳波の S/N 比がきわめて低いため, 判別に先立ってノイズを低減させるための前処理が必要となる. 有効な前処理として, 独立成分分析 (ICA, Independent Component Analysis) [3] 等のブラインド信号源分離 (BSS, Blind Source Separation) があり, 脳波解析に用いられている [4], [5]. しかしながら ICA は, 優決定問題 (チャネ

¹ 名古屋大学
Nagoya University, Nagoya, Aichi 464-8603, Japan
a) nishino@cmplx.cse.nagoya-u.ac.jp
b) yoshikawa@cse.nagoya-u.ac.jp
c) furuhashi@cse.nagoya-u.ac.jp

ル数 $\geq$ 信号源の数) にしか適用できないため、多様な信号が重畳した脳波に適用するには、計測チャンネルの数を増やす必要がある。

一方で、信号源の数に比べてチャンネルの数が少ない劣決定問題の場合にも適用できるブラインド信号源分離の手法が研究されており、音源分離として提案された Duong らの手法 [6] について、スパース性を仮定したもの [7] を脳波に適用した例が報告されている [8], [9]。本論文では、BCI の実応用で想定される少数チャンネルの環境を想定して、劣決定ブラインド信号源分離手法を扱う。

劣決定ブラインド信号源分離の従来手法 [8], [9] では、時間周波数領域においては信号源がスパースにアクティブになるという仮定に基づき、信号を短時間フーリエ変換し、局所的な時間周波数領域ごとに信号源を推定している。しかしながら、各局所時間周波数領域において個別に信号源を推定しているため、複数の時間周波数領域にわたって連続して出現する成分が、複数の信号成分に分離されてしまうという問題がある。本論文では、局所時間周波数領域の隣接関係を利用することで、この問題を軽減する手法を提案し、脳波からの事象関連電位の抽出に適用する。

本論文では、信号源分離の結果を用いて脳波を判別する手法についても検討する。判別対象となる脳波に現れる、判別に有効な電位は単一とは限らない。このため、判別精度の向上のためには、信号源分離によって得られた複数の特徴量の中から、ノイズと思われるものを除去したうえで、判別に有効な成分をいかに組み合わせて判別に用いるかが重要となる。本論文では、アンサンブル学習の手法に着目することで、判別精度の向上を試みる。

また本論文では、P300 Speller 課題を用いた被験者実験によって、提案手法の有効性を示す。P300 speller 課題は、脳波によって文字入力を行う BCI を想定した課題であり、N200 と P300 と呼ばれる事象関連電位を誘発する。実験によって収集された 8 名分の脳波データを用いて判別実験を行い、提案手法を用いることで、従来手法と比較し、判別精度が向上することを示す。

2. 従来の信号源分離手法

従来手法 [8], [9] におけるブラインド信号源分離のモデルを説明する。

時間ステップ n 、周波数ステップ f の局所時間周波数領域における複素振幅値ベクトルを $\mathbf{x}(n, f)$ とおく。ここで、各局所時間周波数領域の複素振幅値は、ただ 1 つの信号源から得られるというスパース性を仮定し、 $s(n, f)$ を $\mathbf{x}(n, f)$ の生じた信号源の番号とする。 $s(n, f)$ は観測されない潜在変数である。

$\mathbf{x}(n, f)$ は、信号源に依存するゼロ平均複素正規分布に従って生成されるとする。 $\mathbf{x}(n, f)$ が j 番目の信号源から得られるとき、その生起確率は次のようになる。

$$\begin{aligned} P(\mathbf{x}(n, f)|v, \mathbf{R}) \\ &= \mathcal{N}_c(\mathbf{x}(n, f); 0, v_j(n, f)\mathbf{R}_j) \\ &= \frac{\exp\left\{-\mathbf{x}(n, f)^H (v_j(n, f)\mathbf{R}_j)^{-1} \mathbf{x}(n, f)\right\}}{\pi^I \det(v_j(n, f)\mathbf{R}_j)} \end{aligned} \quad (1)$$

ここで、 I はベクトル $\mathbf{x}(n, f)$ の長さで、脳波の計測に用いたチャンネル数を表す。行列 $\mathbf{R}_j$ は信号源 j からチャンネルまでの伝達特性を表現した空間相関行列である。 $v_j(n, f)$ は信号源 j の時間と周波数に依存する活性度を表す。

すべての局所時間周波数領域の複素振幅値ベクトルをまとめて $\mathbf{X}$ 、すべての信号源の空間相関行列と活性度をそれぞれまとめて $\mathbf{R}$ 、 $\mathbf{v}$ と表記する。観測信号全体の尤度 $P(\mathbf{X}|\mathbf{v}, \mathbf{R})$ は、以下の混合正規分布モデルで表される。ここで、 J は推定する信号源の数であり、 π_j は j 番目の信号源がアクティブになる生起確率である。

$$P(\mathbf{X}|\mathbf{v}, \mathbf{R}) = \prod_{f,n} \sum_{j=1}^J \pi_j \mathcal{N}_c(\mathbf{x}(n, f); 0, v_j(n, f)\mathbf{R}_j) \quad (2)$$

上記の尤度が最大になるようにパラメータを推定し、多チャンネルウィナーフィルタを構成することで信号源分離が可能となる。

尤度の最大化には EM アルゴリズムが用いられ、その更新式は以下のようになる。

E-step

$$m_j(n, f) = \frac{\pi_j \mathcal{N}_c(\mathbf{x}(n, f); 0, v_j(n, f)\mathbf{R}_j)}{\sum_{j'=1}^J \pi_{j'} \mathcal{N}_c(\mathbf{x}(n, f); 0, v_{j'}(n, f)\mathbf{R}_{j'})} \quad (3)$$

M-step

$$\hat{\pi}_j = \frac{\sum_{n,f} m_j(n, f)}{\sum_{n,f,j'} m_{j'}(n, f)} \quad (4)$$

$$\hat{v}_j(n, f) = \frac{1}{I} \mathbf{x}(n, f)^H \mathbf{R}_j^{-1} \mathbf{x}(n, f) \quad (5)$$

$$\hat{\mathbf{R}}_j = \frac{\sum_{n,f} \frac{m_j(n, f)}{\hat{v}_j(n, f)} \mathbf{x}(n, f) \mathbf{x}(n, f)^H}{\sum_{n,f} m_j(n, f)} \quad (6)$$

$m_j(n, f)$ は、 $\mathbf{x}(n, f)$ が j 番目の信号源から得られる確率 $P(s(n, f) = j)$ を表す。

求まったパラメータを用いて、多チャンネルウィナーフィルタを構成することで、以下のように信号源における信号 $\hat{\mathbf{c}}_j(n, f)$ を推定できる。ここで、 $\mathbf{R}_{\mathbf{x}(n, f)} = E[\mathbf{x}(n, f) \mathbf{x}(n, f)^H]$ である。

$$\hat{\mathbf{c}}_j(n, f) = m_j(n, f) v_j(n, f) \hat{\mathbf{R}}_j \mathbf{R}_{\mathbf{x}(n, f)}^{-1} \mathbf{x}(n, f) \quad (7)$$

3. 局所時間周波数領域における隣接関係の利用

3.1 提案手法

前章の手法においては、各局所時間周波数領域において

個別に信号源を推定しているため、複数の時間周波数領域にわたって連続して出現する成分が、複数の信号成分に分離されてしまうという問題がある。この問題を解決するには、2章で示した信号源分離手法において、時間領域から時間周波数領域への変換手法を工夫する方法と、変換後のアルゴリズムを工夫する方法が考えられる。

時間領域から時間周波数領域への変換手法の工夫については、成分の出現する時間に合わせ、フーリエ変換の窓の幅と位置を調整することが必要となる。窓の幅については、ウェーブレット変換を用いて調整することが考えられるが、ウェーブレット変換はあくまで時間分解能と周波数分解能の両立の観点からの調整であり、ハムノイズやアルファ波、ベータ波のような長期にわたって連続して現れる脳波成分・ノイズに対して、これらの出現時間に合致した窓の幅を設定することは困難である。また、窓の位置の調整についても、目的成分が出現する時間を推定する必要がある、困難な課題となる。

本節では、信号源分離手法において、時間周波数領域への変換後のアルゴリズムを工夫することを考える。局所時間周波数領域の隣接関係を利用することで、出現時間の長い成分に対して効果的な信号源分離の手法を提案する。

各 $\mathbf{x}(n, f)$ の生じた信号源の番号を表す潜在変数 $s(n, f)$ をまとめて $\mathbf{s}$ とおき、変数 $\mathbf{s}$ が得られるときの観測信号全体の尤度を、従来手法にならって、以下のようにモデル化する。

$$P(\mathbf{X}|\mathbf{s}, \mathbf{v}, \mathbf{R}) = \prod_{f=1}^F \prod_{n=1}^N \mathcal{N}_c(\mathbf{x}(n, f); 0, v_{s(n, f)}(n, f) \mathbf{R}_{s(n, f)}) \quad (8)$$

続いて、図1に示すような正方格子状のマルコフネットワークによって潜在変数 $\mathbf{s}$ をモデル化する。隣接する隠れ変数どうしにエッジを仮定することで、隣接する時間周波数領域における依存関係を表現する。このネットワークに基づき、 $\mathbf{s}$ は以下のように生成される。




図1 潜在変数のネットワーク
Fig. 1 Network of latent variables.

$$P(\mathbf{s}) = \frac{1}{y} \prod_{\{(n, f), (l, k)\} \in \epsilon} w(s(n, f), s(l, k)) \quad (9)$$

ここで、 y は正規化定数であり、 ϵ はグラフにおけるエッジの集合、 $\{(n, f), (l, k)\}$ はノード (n, f) とノード (l, k) の間のエッジを表す。 $w(s(n, f), s(l, k))$ はエッジ $\{(n, f), (l, k)\}$ の結び付きの強さを表すポテンシャル関数であり、以下のように定義される。

$$w(\xi, \xi') = \exp(\delta_{\xi, \xi'} - 1) \quad (10)$$

$\delta_{\xi, \xi'}$ はクロネッカーのデルタであり、 $\xi = \xi'$ のときに1を、それ以外のときにはゼロをとる。このため、ポテンシャル関数 $w(\xi, \xi')$ は、2つのノードの信号源の種類が等しいとき1を、それ以外のときにはより小さな値をとり、隣接するスロットにおける同種の信号源の出現確率が高いネットワークを表現する。

次に、尤度 $P(\mathbf{X}|\mathbf{v}, \mathbf{R}) \propto \sum_{\mathbf{s}} P(\mathbf{X}|\mathbf{s}, \mathbf{v}, \mathbf{R})P(\mathbf{s})$ が最大になるように、パラメータを推定する。パラメータの推定アルゴリズムには、EM アルゴリズムと確率伝搬法の繰返しを用いる。EM アルゴリズムに確率伝搬法を組み込むため、前章で示した EM アルゴリズムの E-step において、 $m_j(n, f)$ を以下の式で近似する。

$$m_j(n, f) \simeq m'_j(n, f) \propto \mathcal{N}_c(\mathbf{x}(n, f); 0, v_j(n, f) \mathbf{R}_j) \prod_{(k, l) \in \partial(n, f)} \mu_{(k, l) \rightarrow (n, f)}(j) \quad (11)$$

ここで $\partial(n, f)$ は、ノード (n, f) の周辺ノードの集合を意味する。 $\mu_{(k, l) \rightarrow (n, f)}(j)$ は確率伝搬法によって求まるメッセージであり、以下の式を用いて再帰的に定義される。

$$\mu_{(k, l) \rightarrow (n, f)}(j) \propto \sum_{j'=1}^J w(j, j') \mathcal{N}_c(\mathbf{x}(k, l); 0, v_{j'}(k, l) \mathbf{R}_{j'}) \prod_{(k', l') \in \partial(k, l) \setminus \{(n, f)\}} \mu_{(k', l') \rightarrow (k, l)}(j') \quad (12)$$

実装上は、適当な初期値を与えたうえで演算を繰り返し、収束した値を用いる。この演算によって、 $m_j(n, f)$ を求める際に、周辺ノードの各信号源への所属確率の影響を受けることになり、局所時間周波数領域の隣接関係を意識したパラメータ推定が可能となる。

推定したパラメータを用いて、式(7)を用いて信号源分離を行う。

3.2 関連研究

マルコフネットワークを事前確率として用いる手法は画像処理の分野等で適用例がある。画像処理のタスクの1つである領域分割においては、色調の似ているピクセルをそ

の隣接関係を考慮しながらクラスタリングする必要がある。本章で提案した手法と同様にマルコフネットワークを用いる手法が Tanaka らによって提案されている [10]。

4. アンサンブル学習による判別

4.1 提案手法

判別対象となる脳波において、判別に有効な電位は単一とは限らない。このため、判別精度の向上のためには、信号源分離によって得られた複数の脳波波形の中から、ノイズと思われるものを除去したうえで、判別に有効な成分をいかに組み合わせて判別に用いるかが重要となる。そのため、ここではアンサンブル学習を行い、2 クラス分類を対象として検討を行う。

アンサンブル学習におけるベース学習器には、SWLDA (Stepwise Linear Discriminant Analysis) [11] を用いる。SWLDA では、通常の線形判別分析 (LDA, linear discriminant analysis) と同じように、学習データから重みを作成し、得られた脳波と重みとの積をとることで判別得点を求め、判別に利用する。まず学習においては、SWLDA によって、2 つのクラスの脳波における判別得点の分布が、できるだけ分離するように重みが調整される。続いて、判別においては、判別得点の分布をガウス分布にあてはめることで、クラス所属確率が計算可能となり、これを比較して、どちらのクラスに所属するかを決定できる。

SWLDA が LDA と異なるのは、段階的な変数選択が行われる点である。LDA は 2 クラスのとき、線形回帰を最小二乗法で行うのと同じのアルゴリズムとなり、各変数について統計的検定の枠組みに基いて p 値を計算することが可能となる。SWLDA はこの p 値について閾値を設け、基準値 p_{enter} より小さいものは追加、基準値 p_{remove} より大きいものは削除することを交互に行い、変数の追加と削除を繰り返して、判別性能の向上を実現している。

SWLDA をベースとして、信号源分離によって得られた各信号に対するアンサンブル学習を行う手順を以下に示す。

(学習時) 学習時には、学習データ内の脳波について、チャンネルごとに全データの加算平均をとり、事象関連電位を強調した加算平均波形を作成する。続いて、加算平均波形に対して、信号源分離のアルゴリズムを適用することで、共通の信号源分離フィルタを作成する。この共通フィルタを用いて、学習データに対して信号源分離を行い、各信号源で波形データセットを作成する。それぞれの波形データセットにおいて、SWLDA の学習を行い、各信号源に対応した判別器を学習させる。

(判別時) 得られた未知の脳波に対して、学習で作成した共通フィルタによる信号源分離を行い、各信号源の波形を得る。この各信号源の波形に対して、対応する学習済みの SWLDA を適用することで、各信号源についてクラス所属確率が計算できる。クラスごとに、クラス所属確率の積を

とり、その値が大きいクラスへ判別を行う。

学習時の SWLDA の変数選択において、1 つも変数が選択されなかった信号源の波形については、判別に寄与しないノイズと考え、判別時には利用しないものとして除去を行う。

4.2 関連研究

脳波判別にアンサンブル学習を適用することで精度を向上させる手法は報告されている [12], [13]。Onishi らは、学習データセットを重複分割し、それぞれについて判別器を構成するアンサンブル学習の手法で、P300 の判別精度が向上することを確かめている [14]。また、運転タスクにおける脳波判別について、ICA とアンサンブル学習を組み合わせた手法が提案されている [15]。

5. 実験

5.1 P300 Speller 課題

本論文では、事象関連電位を利用した BCI の具体例として P300 Speller [16] を取り上げる。

P300 Speller は、事象関連電位の 1 つである P300 を利用して文字入力を行う BCI であり、Farwell らによって提案された [16]。P300 は、オドボール課題 [17] と呼ばれる頻度の異なる 2 種類以上の刺激呈示に対し、低頻度の刺激呈示に意識を向けることにより誘発される陽性電位である。P300 Speller では、インタフェースに表示された文字をランダムに点灯させることで、視覚的な刺激をユーザに呈示する。ユーザが選択したい文字に対して意識を集中することで、選択したい文字の点灯時に事象関連電位が誘発され、これをとらえることで、ユーザの選択したい文字 (ターゲット文字) を特定し、文字入力が可能となる。判別に利用される事象関連電位としては P300 が着目されていた [16] が、後に N200 も判別に寄与することが報告されている [18]。P300 は刺激呈示の約 300 ms ~ 600 ms 後に、N200 は約 200 ms 後にそれぞれ誘発される電位である。

P300 Speller では、図 2 のような行列型インタフェー




図 2 行列型 P300 Speller のインタフェース

Fig. 2 Matrix interface of P300 Speller.

スが一般的であり、行もしくは列ごとに点灯して刺激呈示が行われることが多い。P300 Speller は、筋委縮性側索硬化症 (ALS) 患者 [19] のような、全身の筋肉を動かさない人々のコミュニケーション手段として注目されている。

5.2 データ収集

被験者 8 名から P300 Speller 課題に対する反応脳波を収集した。被験者は 21 歳から 24 歳の健康な日本人男性である。図 2 に示した日本語文字盤（ひらがな + 記号，7 行 10 列）を用い、文字盤の行または列ごとにランダムに点灯させ、被験者に指示した文字（ターゲット文字）を含む点灯をカウントさせた。ターゲット文字は、文字盤からランダムに選んだ 1 文字とした。1 文字につき、すべての行と列を 10 回ずつ点灯させ、100 文字のデータを計測した。

脳波計測にはデジテックス研究所の Polymate AP216 を用いた。電極は国際 10-20 法 [20] に従った 5 カ所 (Fz, Cz, Pz, O1, O2)，および基準電極として両耳の A1, A2 に貼付した。各刺激の刺激呈示間隔は 175 ms（点灯時間 75 ms，消灯時間 100 ms）とし、各刺激後 800 ms の脳波を収集した。また、サンプリング周波数 1,000 Hz とし、0.1 Hz のハイパスフィルタを通した後、100 Hz にダウンサンプリングして記録した。

5.3 信号源分離の比較

従来研究における信号源分離 (bss1) と隣接関係を利用して信号源分離を行う提案手法 (bss2) の比較を行った。検討には、P300 Speller 課題で収集した被験者 8 名分のデータを用いた。

第 1 に、周期の長い成分を効果的に抽出できるという提案手法の特徴を具体例で示す。まず、ターゲット文字の点灯直後から 800 ms の区間を抽出し、ターゲット波形とした。ターゲット波形には N200 および P300 が含まれることが期待されるが、個々の波形にはノイズが含まれるため、明瞭ではない。ターゲット波形について、チャンネルごとに加算平均をとることで、N200 および P300 を強調したテンプレート波形を作成し、提案手法および従来手法を適用した。

推定する信号源の数を 5 とし、3 チャンネル (Fz, Cz, O1) を用いたときの結果を図 3 に示す。事象関連電位の図示における慣例に従って、縦の軸の正負を天地反転してプロットしている。プロットされた原波形から、P300 Speller 課題によって N200 および P300 が誘発されたことが分かる。信号源分離の結果、N200 は従来手法 Sig.1、提案手法 Sig.5 において、P300 は従来手法 Sig.3 および Sig.4、提案手法 Sig.2 において抽出された。従来手法においては、P300 が 2 つの異なる成分として信号源分離されたが、提案手法においては、1 つの成分として抽出できたことが分かる。

続いて、定量的な比較を行う。脳波に対し、信号源分




図 3 信号分離の例

Fig. 3 Result of signal separation.

離による N200 および P300 成分の抽出を試みた。個別のターゲット波形では、N200 や P300 の形状がそれぞれ異なり、抽出すべき正解の波形を定義できない。そこで、N200 と P300 が強調されたテンプレート波形を正解として用い、そこに人工的に加えられたノイズをどの程度除去できるかで、抽出精度を算出した。ノイズとしては、非ターゲット文字の点灯直後から 800 ms の区間の各反応脳波（スタンダード波形）を用いた。また信号源分離の手法として、劣決定ブラインド信号源分離の従来手法と提案手法、ICA の 3 つの手法を用いて、抽出精度の比較を行った。ICA としては、白色化を前処理とし、非ガウス性指標としてネグエントロピーを用いた fastICA [3] を用いた。

まず先ほどと同様に、ターゲット文字に対する反応脳波のテンプレート波形を作成した。さらに、スタンダード波形のうち 100 波形をランダムに選択した。選択された各スタンダード波形について、振幅の分散値をテンプレート波形の分散値と等しくなるように調整したうえで、1 波形ずつテンプレート波形に足し合わせることで、ノイズの付与された 100 波形を作成した。ノイズを付与した 100 波形に対し、提案手法と従来手法をそれぞれ適用し、N200 および P300 の抽出精度を比較した。抽出精度としては、抽出された N200, P300 成分の振幅とそれぞれの正解波形の間での RMSE を用いた。N200 の正解波形については、テンプレート波形において N200 が見られる 150 ms から 300 ms 以外の振幅をゼロとした波形を用いた。同様に P300 の正解波形については、テンプレート波形において P300 が見られる 300 ms から 550 ms 以外の振幅をゼロとした波形を用いた。時間インデックス t (最大 n) における抽出波形の




図 4 事象関連電位の抽出精度

Fig. 4 Qualities of ERP extraction.

表 1 対応のある t 検定

Table 1 The result of the paired t-test.

信号源の数	手法 1	手法 2	p 値
3	bss1	bss2	0.490
5	bss1	bss2	*0.000
5	ica	bss1	*0.000
5	ica	bss2	*0.000
10	bss1	bss2	*0.000
15	bss1	bss2	*0.000

振幅値を y_t , 正解波形の振幅値を $\hat{y}_t$ としたとき, RMSE の定義は次のようになる.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (13)$$

5 チャンネル (Fz, Cz, Pz, O1, O2) を用い, 劣決定ブラインド信号源分離の従来手法 (bss1) と提案手法 (bss2) では, 信号源の数を 5, 10, 15 と変えて評価を行った. ICA で推定される信号源の数は, 入力チャンネル数と等しい 5 である.

信号源の数を変えたときの RMSE の全被験者平均を図 4 に示す. ここで, 信号源の数が 1 のときの RMSE は, 信号源分離をまったく行わないときの RMSE を表す. また, P300 の抽出精度について, 各信号源数で, 対応のある t 検定を実施した結果を表 1 に示す. 多重比較を考慮して, ボンフェローニ法で調整した有意水準 ($p < 0.05/6$) を下回ったときを*で示している. 図 4 および表 1 から, ICA と比較して, 劣決定ブラインド信号源分離手法 (bss1, bss2) の方が, 特に信号源数を大きく設定したときに, RMSE を抑えられることが分かる. また, 周期の長い P300 において, 従来手法 (bss1) と比較して, 提案手法 (bss2) では RMSE をやや低く抑えられていることが分かる. なお, 図 4 で示した P300 の抽出精度において, bss1 と bss2 の RMSE 平均値の差は分散に比べてわずかであるように見えるが, 実験に用いた波形についてノイズ除去のしやすさが被験者間・各波形間で大きく異なり, RMSE の分散が大きくなったためである. 対応のある t 検定では, 波形ごとに bss1 による RMSE と bss2 による RMSE の差をとって検定を行っ

たため, 小さな p 値が算出されている.

5.4 判別精度の比較

作成したデータセットを用いて, ターゲット波形とスタンダード波形の判別実験を行った.

実験は, SWLDA 単体で判別した場合 (swlda), 2 章で示した信号源分離とアンサンブル学習を組み合わせた場合 (ensemble+bss1+swlda), 3 章で示した信号源分離とアンサンブル学習を組み合わせた場合 (ensemble+bss2+swlda), 3 章で示した信号源分離の結果を SWLDA 単体へ直接入力した場合 (bss2+swlda) の 4 パターンについて行った.

実験においては, 5 チャンネル (Fz, Cz, Pz, O1, O2) を用い, 信号源分離において推定する信号源の数は 10 とした. SWLDA 単体での判別 (swlda) では, 5 チャンネル分のデータを並べて単一のベクトルとしたものを入力とし, 単一の判別器での学習・判別を行った. また, 信号源分離の結果としては, 式 (7) を用いて, 時間周波数領域における信号源分離の結果を得た後, 逆短時間フーリエ変換を用いて, 時間領域の波形を計算したものをを用いた. 信号源の数を 10 とする信号源分離の結果, チャンネルごとに 10 個の波形が得られるが, 信号源分離の結果を SWLDA 単体へ直接入力する場合 (bss2+swlda) については, 全チャンネル全信号源の 50 波形を並べて単一のベクトルとしたものを入力とし, 単一の判別器での学習・判別を行った. 信号源分離とアンサンブル学習を組み合わせた場合 (ensemble+bss1+swlda, ensemble+bss2+swlda) については, 各信号源に対応する 10 個の判別器での学習・判別を行い, アンサンブル学習によって結果を統合した. 各判別器では, 5 チャンネル分の波形を並べて単一のベクトルとしたものを入力データとして用いた.

被験者ごとに 4 パターンの判別実験を学習データ数を変えながら行い, それぞれ 10 分割交差検証によって性能を評価した. 学習データおよびテストデータにおけるターゲット文字点灯時のデータとそれ以外のデータの比率は 2:15 であり, 偏りがあるため, 性能評価の指標としては F 値 (F-measure) を用いた. F 値は適合率 Precision と再現率 Recall を用いて以下のように定義される.

$$F = \frac{2 \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (14)$$

結果を図 5 に示す. 図 5 より, SWLDA を単体で用いる手法 (swlda) に比べて, subject 2 を除いた 7 名において, 信号源分離を前処理に用いた手法 (bss2+swlda, ensemble+bss1+swlda, ensemble+bss2+swlda) の性能が高く, 信号源分離によるノイズ除去が有効に働いていると考えられる. 全被験者平均では, アンサンブル学習を用いなかった場合 (bss2+swlda) に比べて, アンサンブル学習を用いた場合 (ensemble+bss2+swlda) では, データ数が 1,000 未満の少ない状況において, 高い判別率を示した. この傾向




図 5 判別精度

Fig. 5 Discrimination accuracy.

は個別の被験者においても, Subject 2 と subject 8 を除いた 6 名において確認できた. このことから, アンサンブル学習の利用は, BCI において学習データの記録時間を短縮するうえで有効だと考えられる. また, 全被験者において, 従来の信号源分離を用いてアンサンブル学習を行う手法 (ensemble+bss1+swlda) に比べて, 本論文で提案した局所時間周波数領域の隣接関係を利用した信号源分離を用いてアンサンブル学習を行う手法 (ensemble+bss2+swlda) の方が高い性能を示した. これは, 5.3 節で検討したとおり, 局所時間周波数領域における隣接関係を用いることで, 事象関連電位の抽出精度が向上したためであると考えられる.

6. 結論

脳波におけるノイズ低減の手法として, 信号源分離を取り上げ, その改良手法を提案した. また BCI における脳波判別の精度向上を目的とし, 信号源分離の結果を用いたアンサンブル学習法を提案した. また, 実際の BCI を想定した被験者実験によって収集された 8 名分の脳波データを用いて実験を行い, 提案手法を用いることで, 従来手法と比較して判別精度が向上することを示した.

今後の課題としては, 推定する信号源数の調整方法があげられる. 本論文では, 少数チャネルの環境を想定し, 劣決定問題に適用できる信号源分離の手法について検討を行ったため, 推定する信号源の数を設定する必要性が生じた. 5.3 節で示したように, 信号源の数はノイズ除去性能に影響する重要なパラメータであり, 高い特徴量抽出精度を得るためには最適な信号源数の調整方法が求められる. また, 本論文で提案した信号源分離において, 局所時間周波数領域の隣接関係を利用するために設定したマルコフネットワークは, ポテンシャル関数において平滑化の強さを定める必要がある. 本論文では固定で行ったが, 抽出・除去の対象となる脳波成分の形状とフーリエ変換の窓幅・シフトによって平滑化の強さの最適値が異なることが考えられ, どのようにチューニングすべきかについては今後の課題である. なお, 画像処理の分野において, マルコフネットワークの平滑化の強さをハイパーパラメータとしてチューニングする手法が提案されており [10], 最適値の探索に利用できる可能性がある. また, 本論文では信号源分離の応用として BCI における脳波判別を扱ったが, 信号源分離の脳波解析への応用も大きな課題である. 一例として, 本論文で検討した信号源分離手法では, 各信号源の時間に依存しない空間相関行列 $\mathbf{R}$ が求まるため, これを用いて各信号源で頭皮上マップ (topography) を計算することが考えられる.

謝辞 本研究の一部は, 独立行政法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーション (COI) プログラム」の支援によって行われた.

参考文献

- [1] Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G. and Vaughan, T.M.: Brain-computer interfaces for communication and control, *Clinical Neurophysiology*, Vol.113, No.6, pp.767-791 (2002).
- [2] Niedermeyer, E. and da Silva, F.L.: *Electroencephalography: Basic principles, clinical applications, and related fields*, Lippincott Williams & Wilkins (2005).
- [3] Hyvärinen, A. and Oja, E.: Independent component analysis: Algorithms and applications, *Neural Networks*, Vol.13, No.4, pp.411-430 (2000).
- [4] Delorme, A. and Makeig, S.: Eeglab: An open source toolbox for analysis of single-trial eeg dynamics including independent component analysis, *Journal of Neuroscience Methods*, Vol.134, No.1, pp.9-21 (2004).
- [5] Lemm, S., Curio, G., Hlushchuk, Y. and Muller, K.-R.: Enhancing the signal-to-noise ratio of ica-based extracted erps, *IEEE Trans. Biomedical Engineering*, Vol.53, No.4, pp.601-607 (2006).
- [6] Duong, N.Q. et al.: Under-determined reverberant audio source separation using a full-rank spatial covariance model, *IEEE Trans. Audio, Speech, and Language Processing*, Vol.18, No.7, pp.1830-1840 (2010).
- [7] Sakanashi, R., Miyabe, S., Yamada, T. and Makino, S.: Comparison of superimposition and sparse models in blind source separation by multichannel wiener filter, *Proc. 2012 Asia-Pacific Signal & Information Processing Association Annual Summit and Conference (APSIPA ASC)*, pp.1-6, IEEE (2012).
- [8] Kurihana, Y. et al.: Signal separation of eeg using multivariate probabilistic model, *IEICE Technical Report* (2013).
- [9] Maki, H., Toda, T., Sakti, S., Neubig, G. and Nakamura, S.: Enhancing event-related potentials based on maximum a posteriori estimation with a spatial correlation prior, *IEICE Trans. Information and Systems*, Vol.E99-D, No.6, pp.1410-1419 (2016).
- [10] Tanaka, K., Kataoka, S., Yasuda, M., Waizumi, Y. and Hsu, C.-T.: Bayesian image segmentations by potts prior and loopy belief propagation, *Journal of the Physical Society of Japan*, Vol.83, No.12, p.124002 (2014).
- [11] Krusienski, D.J., Sellers, E.W., Bayouth, S., McFarland, D.J., Vaughan, T.M. and Wolpaw, J.R.: A comparison of classification techniques for the p300 speller, *Journal of Neural Engineering*, Vol.3, No.4, pp.299-305 (2006).
- [12] Sun, S., Zhang, C. and Lu, Y.: The random electrode selection ensemble for eeg signal classification, *Pattern Recognition*, Vol.41, No.5, pp.1663-1675 (2008).
- [13] Ahangi, A., Karamnejad, M., Mohammadi, N., Ebrahimpour, R. and Bagheri, N.: Multiple classifier system for eeg signal classification with application to brain-computer interfaces, *Neural Computing and Applications*, Vol.23, No.5, pp.1319-1327 (2013).
- [14] Onishi, A. and Natsume, K.: Overlapped partitioning for ensemble classifiers of p300-based brain-computer interfaces, *PloS ONE*, Vol.9, No.4, p.e93045 (2014).
- [15] Chuang, C.-H., Ko, L.-W., Lin, Y.-P., Jung, T.-P. and Lin, C.-T.: Independent component ensemble of eeg for brain-computer interface, *IEEE Trans. Neural Systems and Rehabilitation Engineering*, Vol.22, No.2, pp.230-238 (2014).
- [16] Farwell, L. et al.: Talking off the top of your head: Toward a mental prosthesis utilizing event-related brain potentials, *Electroencephalography and Clinical Neurophysiology*, Vol.70, No.6, pp.510-523 (1988).
- [17] Debener, S., Makeig, S., Delorme, A. and Engel, A.: What is novel in the novelty oddball paradigm? functional significance of the novelty p3 event-related potential as revealed by independent component analysis, *Cognitive Brain Research*, Vol.22, No.3, pp.309-321 (2005).
- [18] Kaufmann, T., Hammer, E. and Kübler, A.: Erps contributing to classification in the p300 bci, na, pp.136-139 (2011).
- [19] Kaub-Wittermer, D., Steinbuechel, N., Wasner, M., Laier-Groeneveld, G. and Borasio, G.: Quality of life and psychosocial issues in ventilated patients with amyotrophic lateral sclerosis and their caregivers, *Journal of Pain and Symptom Management*, Vol.26, No.4, pp.890-896 (2003).
- [20] Jasper, H.H.: The ten twenty electrode system of the international federation, *Electroencephalography and Clinical Neurophysiology*, Vol.10, pp.371-375 (1958).



西納 修一

2016年3月名古屋大学工学部電気電子・情報工学科卒業。同年4月同大学大学院工学研究科博士課程前期課程計算理工学専攻進学，現在に至る。主として，ニューロエンジニアリングに関する研究に従事。人工知能学会，電子

情報通信学会各会員。



吉川 大弘 (正会員)

1997年名古屋大学大学院博士課程修了。同年カリフォルニア大学バークレー校ソフトコンピューティング研究所客員研究員。1998年三重大学工学部助手。2005年名古屋大学大学院工学研究科 COE 特任准教授。2006年10月同研究科准教授，現在に至る。主としてソフトコンピューティングとその応用に関する研究に従事。博士（工学）。IEEE，人工知能学会，日本知能情報ファジィ学会，進化計算学会各会員。



古橋 武

1985年名古屋大学大学院工学研究科博士後期課程電気系専攻修了。工学博士。2004年名古屋大学大学院工学研究科計算理工学専攻教授，現在に至る。ソフトコンピューティング，感性工学に関する研究に従事。1996年日本ファジィ学会論文賞受賞。IEEE，日本知能情報ファジィ学会，電気学会等の各会員。