

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 古橋 武¹

概要: 近年, Brain-Computer Interface (BCI) が注目を集めている. BCI では, ユーザーの脳波を計測・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 比が極めて低いため, 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す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. 本稿では, 脳波の特徴の一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

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

Brain Computer Interface (BCI) とは, ユーザーの脳活動を計測することで, ユーザー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である. 脳活動を計測する手段としては, 脳波 (EEG, Electroencephalogram) [1] が用いられることが多い. 脳波計測は非侵襲であり, 計測機器が比較的安価という利点がある. 一方, 脳波の S/N 比は極めて低いため, 判別に先立ってノイズを低減するための前処理が必要となる. 有効な前処理として, 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.

ブラインド信号源分離手法の従来手法 [2][3] においては, 前処理に短時間フーリエ変換を用いるため, フーリエ変換

の窓幅よりも周期の長い成分が, 複数の信号成分に分離されてしまうという問題があった. 本稿では, 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.

本稿では, 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上で, 判別に有効な成分をいかに組み合わせるかが重要となる. 本稿では, 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, 5人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.

¹ 名古屋大学 工学研究科 計算理工学専攻

^{a)} nishino@cse.cmplx.nagoya-u.ac.jp

2. 従来の信号源分離手法

従来手法 [2][3] におけるブライント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、ただ一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。

$$P(\mathbf{x}(n, f)|v, \mathbf{R}) = \mathcal{N}_c(\mathbf{x}(n, f); 0, v_j(n, f)\mathbf{R}_j) \quad (1)$$

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

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

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。




図1 潜在変数のネットワーク

Fig. 1 Network of latent variables

求め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。

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

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

前節の手法においては、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、フーリエ変換の窓幅よりも周期の長い成分が、複数の信号成分に分離されてしまうという問題がある。本節では、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。

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。

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

続いて、図1に示すような正方形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。隣接する隠れ変数同士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。

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

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 $\{(n, f), (l, k)\}$ の結びつ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 $P(\mathbf{X}|\mathbf{v}, \mathbf{R}, \alpha) \propto \sum_{\mathbf{s}} P(\mathbf{X}|\mathbf{s}, \mathbf{v}, \mathbf{R})P(\mathbf{s}|\alpha)$ 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り返しを用いる。EM アルゴリズムに確率伝搬法を組み込むため、前節で示した 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上で演算を繰り返し、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。

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上で、判別に有効な成分をいかに組み合わせるかが重要となる。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) [4] を用いた。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、二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当てはめることで、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クラスするとき、線形回帰を最小二乗法で行うのと同じ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ーを作成する。この共通フィルターを用いて、学習データに対して信号源分離を行い、各信号源ごとの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ー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、一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。

5. 実験

5.1 P300 Speller 課題

本稿では、事象関連電位を利用した BCI の具体例として P300 Speller を取り上げる。

P300 Speller は、事象関連電位の一つである 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 [5]。P300 は、オドボール課題 [6] と呼ばれる頻度の異なる二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、インター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ーに

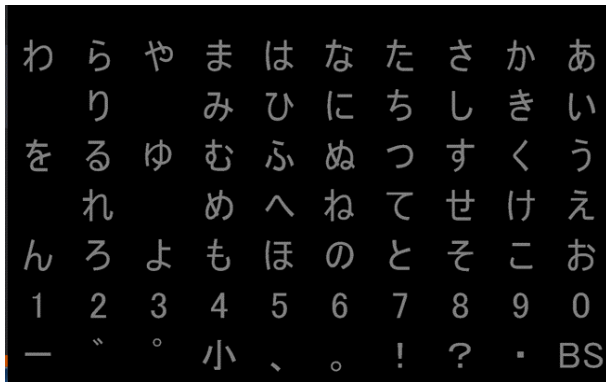


図 2 行列型 P300 Speller のインターフェース
Fig. 2 Matrix interface of P300 Speller

呈示する。ユーザー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、これを捉えることで、ユーザーの選択したい文字（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 [5] が、後に N200 も判別に寄与することが報告されている [7]。P300 は刺激呈示の約 300ms~600ms 後に、N200 は約 200ms 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ーフェースが一般的であり、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 [8] 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 5 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 [9] に従った 5 箇所 (Fz, Cz, Pz, O1, O2)、および基準電極として両耳朶の A1, A2 に貼付した。サンプリング周波数 1000Hz とし、0.1Hz のハイパスフィルタを通した後、100Hz にダウンサンプリングして記録した。各刺激の刺激呈示間隔は 175ms(点灯時間 75ms, 消灯時間 100ms) とした。

5.3 信号源分離の比較

従来研究における信号源分離 (bss1) と局所時間周波数領域の隣接関係を考慮して信号源分離を行う提案手法 (bss2) の比較を行った。実験で収集された脳波に対して、信号源




図 3 事象関連電位の抽出精度
Fig. 3 Qualities of ERP extraction

分離による N200 および P300 成分の抽出を試み、抽出精度によって従来手法と提案手法を比較した。

検討には、P300 Speller 課題で収集した被験者 5 名分のデータのうち、1 名分を用いた。第一に、ターゲット文字の点灯直後から 800ms 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。しかしながら、その形状は波形ごとにそれぞれ異なり、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作成して、これを正解として用い、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。まず、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た。次に、スタンダード波形のうち 100 波形をランダムに選択した。そして、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上で、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 150ms から 300ms 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 300ms から 550ms 以外の振幅をゼロとした波形を用いた。

5 チャンネル (Fz, Cz, Pz, O1, O2) を用いて、信号源の数を 5, 10, 15 と変えたときの結果を図 3 に示す。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。図 4 から、周期の短い N200 では抽出精度に差はないが、周期の長い P300 において、従来手法と比較して、提案手法では RMSE を低く抑えられていることがわかる。

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 節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 (bss1+swlda), 3 節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 (bss2+swlda) の 3 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。

被験者ごとに 3 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 値を用いた。結果を図 4 に示す。

図 4 より、被験者 5 名のうち 4 名で、SWLDA を単体で用いる手法 (swlda) に比べて、信号源分離を前処理に加えてアンサンブル学習を行った手法 (bss1+swlda, bss2+swlda) の性能が高く、信号源分離によるノイズ除去とアンサンブル学習が有効に働いていると考えられる。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 (bss1+swlda) に比べて、本稿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 (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 5 人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挙げられる。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。

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。

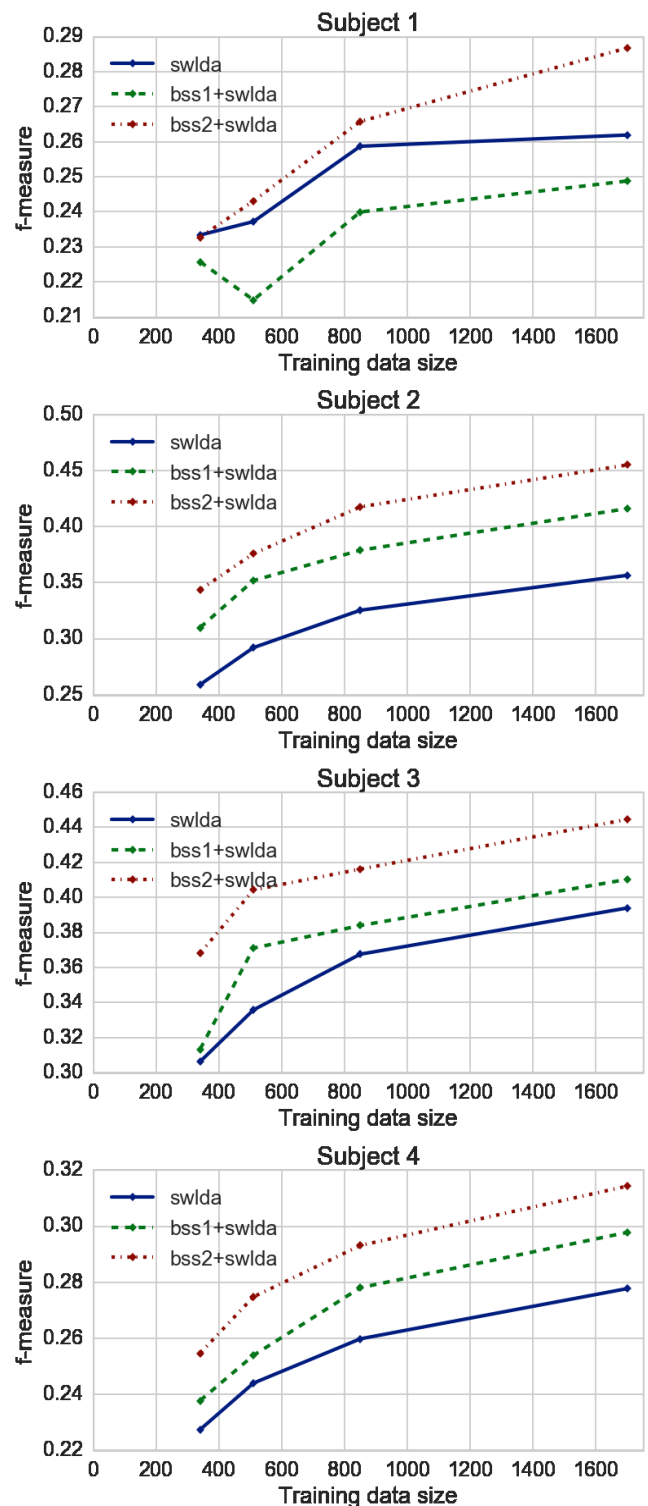


図 4 判別精度

Fig. 4 Discrimination Accuracy

参考文献

- [1] Niedermeyer, E. and da Silva, F. L.: *Electroencephalography: basic principles, clinical applications, and related fields*, Lippincott Williams & Wilkins (2005).
- [2] Kurihana, Y. et al.: Signal separation of EEG using multivariate probabilistic model, *IEICE Technical Report* (2013).
- [3] 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 Transactions on Information and Systems*, Vol. E99-D, No. 6, pp. 1410–1419 (2016).
- [4] 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. pp. 299–305 (2006).
- [5] 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).
- [6] 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).
- [7] Kaufmann, T., Hammer, E. and Kübler, A.: ERPs contributing to classification in the P300 BCI, na, pp. 136–139 (2011).
- [8] Kaub-Wittmer, D., Steinbuchel, N., Wasner, M., Laiers-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).
- [9] Jasper, H. H.: The ten twenty electrode system of the international federation, *Electroencephalography and Clinical Neurophysiology*, Vol. 10, pp. 371–375 (1958).