

事象関連電位を用いた
ブレイン-コンピュータ・インタフェース
のための集合識別器に関する研究

博士(工学)学位論文

大西 章也

九州工業大学大学院
生命体工学研究科
脳情報専攻
神経回路情報処理講座

2015年3月

目次

第1章 序論	1
1.1 研究背景	1
1.2 改善すべき点	2
1.3 研究目的及び研究内容	2
1.4 論文構成	2
第2章 ブレイン-コンピュータ・インタフェース	5
2.1 ブレイン-コンピュータ・インタフェース (BCI) とは	5
2.2 脳信号の侵襲計測と非侵襲計測	6
2.3 非侵襲計測手法の種類	7
2.3.1 脳波	7
2.3.2 磁気共鳴機能画像法	8
2.3.3 脳磁図	9
2.3.4 近赤外線分光法	9
2.3.5 陽電子造影法	10
2.4 脳波計測法	10
2.4.1 脳波と脳波計	10
2.4.2 脳波の導出	12
2.4.3 脳波の発生原理	15
2.5 脳波を用いた BCI の種類	17
2.5.1 ERP-based BCI	17
2.5.2 SSVEP-based BCI	19
2.5.3 ERD/ERS-based BCI	21
2.6 性質による BCI の分類	21
2.6.1 非同期型 BCI と同期型 BCI	21
2.6.2 注意の種類と依存型 BCI と独立型 BCI	22
2.6.3 まとめ	23

第3章	ERP-based BCIの構成	25
3.1	ERP-based BCIシステムに使用される装置	25
3.2	刺激提示部	25
3.3	計測部	28
3.4	刺激の制御とデータ構造	29
3.4.1	P300とオドボール課題	29
3.4.2	命令を入力するまでの流れ	33
3.4.3	ERP-based BCIのデータ構造	33
3.5	信号処理・識別部	35
3.5.1	前処理	35
3.5.2	線形判別分析による脳波識別	36
3.5.3	意思決定	39
3.6	出力部	40
3.7	まとめ	41
第4章	オーバーラップト・パーティショニングを用いたERP-based BCIの集合識別器	43
4.1	ERP-based BCIに用いられる識別器と集合識別器の動向	43
4.2	実験方法	46
4.2.1	データセット A: 独自のERP-based BCIデータセット	48
4.2.2	データセット B: BCI competition III data set II	51
4.2.3	集合識別器の学習	52
4.2.4	比較方法	58
4.3	結果	63
4.3.1	1/10 交差確認法によるデータセット A の評価	63
4.3.2	9/10 交差確認法によるデータセット A の評価	67
4.3.3	制限された訓練データを使用した場合のデータセット B の評価	71
4.3.4	すべての訓練データを使用した場合のデータセット B の評価	73
4.4	考察	77
4.4.1	訓練データが少ない場合	77
4.4.2	次元削減による影響	77
4.4.3	訓練データが多い場合	79

4.4.4	オーバーラップト・パーティショニングのパラメータ決定方法 . . .	80
4.4.5	識別器の数を変化させた場合	80
4.4.6	刺激シーケンス数、訓練データ数の決定方法	80
4.4.7	オーバーラップト・パーティショニングを用いて性能が向上した理由	81
4.4.8	オーバーラップト・パーティショニングが標準偏差に与える影響 . .	82
4.4.9	ステップワイズ法によって選ばれる次元数とオーバーラップト・パー ティショニングの関係	84
4.4.10	主成分分析を用いた場合に使用する次元数、累積寄与率と識別精度 の関係	86
4.4.11	オーバーラップト・パーティショニングがステップワイズ法と弱学 習器に与える影響	90
4.4.12	展望	97
4.5	まとめ	97
第5章	結語	99
	謝辞	101
	参考文献	102

表目次

4.1	データセット A、B それぞれの刺激提示、データ計測、前処理に用いたパラメータ	60
4.2	データセット A を評価する際のオーバーラップト・パーティショニングを用いた集合識別器のパラメータ	61
4.3	データセット B を評価する際のオーバーラップト・パーティショニングを用いた集合識別器のパラメータ	62
4.4	データセット A について 1/10 交差確認法を用いて OSWLDA、OPCALDA、OLDA を評価した際の平均識別精度 (%)	66
4.5	データセット A について 9/10 交差確認法を用いて OSWLDA、OPCALDA、OLDA を評価した際の平均識別精度 (%)	70
4.6	データセット B について制限された訓練データを用いて OSWLDA を評価した際の識別精度 (%)	71
4.7	データセット B について制限された訓練データを用いて OPCALDA を評価した際の識別精度 (%)	72
4.8	データセット B について制限された訓練データを用いて OLDA を評価した際の識別精度 (%)	72
4.9	データセット B について全訓練データを用いて OSWLDA を評価した際の識別精度 (%)	74
4.10	データセット B について全訓練データを用いて OPCALDA を評価した際の識別精度 (%)	75
4.11	データセット B について全訓練データを用いて OLDA を評価した際の識別精度 (%)	76

目次

2.1	BCI システムの構成	6
2.2	10-20 法による計測位置の決定方法	11
2.3	単極導出法	13
2.4	連結双極導出法	14
2.5	神経細胞	15
2.6	活動電位	16
2.7	聴覚オドボール課題の例	18
2.8	SSVEP-based BCI を用いた二次元平面上のレーシングカーの制御	20
3.1	ERP-based BCI の構成	26
3.2	ERP-based BCI の刺激提示器 (P300 スペラー)	27
3.3	ERP-based BCI で頻繁に用いられるモニタージュ	28
3.4	ERP-based BCI データの標的波形と標準波形	29
3.5	ERP-based BCI データのトポグラフィ	30
3.6	ERP-based BCI の刺激提示方法	32
3.7	ERP-based BCI のデータの切り取り	34
4.1	実験の流れ	47
4.2	p/q 交差確認法	50
4.3	集合識別器の構成	53
4.4	オーバーラップト・パーティショニングの具体例	55
4.5	データセット A を 1/10 交差確認法で評価した際の各被験者の識別精度	65
4.6	データセット A を 1/10 交差確認法で評価した際の平均識別精度	66
4.7	データセット A を 9/10 交差確認法で評価した際の各被験者の識別精度	68
4.8	データセット A を 9/10 交差確認法で評価した際の平均識別精度	69
4.9	データセット A を 1/10 交差確認法で評価した際の主要な結果	78
4.10	データセット B を制限された訓練データで評価した際の主要な結果	79

4.11	提案集合識別器における標準偏差	83
4.12	オーバーラップ・パーティショニングとステップワイズ法により選択される次元数との関係	85
4.13	使用する主成分の数と識別精度の関係	88
4.14	使用する主成分の数と累積寄与率	89
4.15	OSWLDA におけるオーバーラップ・パーティショニングとステップワイズ法の影響範囲	91
4.16	ステップワイズ法外出し型 OSWLDA	92
4.17	ステップワイズ法 (SW) 外出し型 OSWLDA の識別精度	93
4.18	LDA 全データ学習型 OSWLDA	95
4.19	LDA 全データ学習型 OSWLDA と提案手法との比較	96

第1章 序論

1.1 研究背景

我が国は人口の21%が高齢者である超高齢社会を迎えており、高齢者や障害者を支援する福祉介護機器の必要性がより一層高まっている [1]。そのうち、脊髄の最上位である頸髄を損傷するなどにより四肢が不自由になる重度の運動機能障害を患う人の支援は重要な課題の一つである。重度運動機能障害の程度は個人差があるものの、残存機能は口や目、首の動きなどの極めて限られたものしか利用できないと考えられ、それらを活かした福祉介護機器の開発が進められている。

近年、脳信号を読み取り、それを装置の制御命令に変換するブレイン-コンピュータ・インタフェース (brain-computer interface; BCI) [2] の研究が盛んに進められ、重度の運動機能障害者のための新しい運動出力経路となりうると注目を集めている。BCI の一例として、ある刺激に対する脳波における反応である事象関連電位 (event-related potential; ERP) を用いた BCI、すなわち ERP-based BCI がある。ERP-based BCI には、低頻度と高頻度の視覚刺激を提示した際に低頻度の刺激に対するの ERP には刺激定時後から約 300 ミリ秒後に見られる正のピーク、すなわち P300 が多用される。P300 を含む ERP を用いた BCI (P300-based BCI と呼ばれる) によりワープロや環境を制御することができる [3]。

脳波を命令に変換する際に、脳波のパターン認識を行う必要があるため、BCI の性能はパターン認識技術に依存する。したがって BCI で使用する脳波に効果的な識別器を開発することが望まれる。与えられた訓練データを元に試験データをいかに分類できるかを競う BCI competition III data set II が開かれ、ERP-based BCI の部門において集合識別器を用いたアルゴリズムが優勝した [4]。集合識別器は複数の識別器を内部に持ち、その結果を統合して意思決定を行うものであり、これを用いることで ERP の変動による影響を抑え、高い識別精度を示すことができる。そのため集合識別器を用いたアルゴリズムは ERP-based BCI に最適であると考えられ、その後盛んに研究が行われてきた。

1.2 改善すべき点

以上のように Rakotomamonjy らが提案する集合識別器 [4] は実用的であると期待できる。しかし、その識別器とその評価方法には下記の改善すべき点がある。

- 訓練データ数が多すぎるため、訓練データが少ない実際的な条件で動作するか不明である。
- 集合識別器を学習する際に訓練データサンプルを分割するが、その分割のための手法が BCI competition III data set II の訓練データに特化した形で提案されており、汎用性がない。

したがってこれらの改善すべき点を踏まえて、問題を顕在化し、それを克服することで ERP-based BCI のための集合識別器の価値がより高まると考える。

1.3 研究目的及び研究内容

上記の改善すべき点を踏まえ、本研究では大きさの異なる訓練データが与えられた場合でも高い性能で動作する ERP-based BCI のための集合識別器を開発することを目的としている。集合識別器はこれまで 1,000 波形以下で評価されていないため、特に少ない訓練データでより良く動作する集合識別器の開発に重点を置いた。本研究では下記の研究を行った。

- 訓練データサンプルを分割する方法を一般化し、少ないデータから多いデータに幅広く適応できる手法であるオーバーラップト・パーティショニングを提案し、その有効性について評価した。
- 提案する手法について、約 3 分で計測できる 900 波形の訓練データサンプルで集合識別器を学習した場合と、8,000 波形以上を使用して学習した場合で評価した。

1.4 論文構成

本論文は全 5 章で構成される。各章の内容はそれぞれ以下の通りである。

第 2 章では BCI で使われる脳信号計測手法や、脳波の種類、BCI の種類と応用について述べる。計測手法の分類として外科手術などにより人体を害する手法と、害しない方法に区分できる。BCI ではとりわけ人体を害しない方法が用いられるが、その中でも時間分解

能が高く安価である脳波が盛んに使われる。脳波により BCI を駆動させる方法は数多く提案されているが、そのうちの主要なものについて述べる。

第3章では、本研究で着目した事象関連電位を用いた BCI の動作原理について説明する。装置を構成する方法から始め、脳波計測部位や刺激提示方法、識別器の学習方法、意思決定方法について述べ、どのように事象関連電位を装置制御命令に変換するかについて説明する。

第4章では、事象関連電位を用いた BCI の識別器を集合識別器に拡張し、オーバーラップ・パーティショニングにより学習した場合の性能の評価について述べる。同時に次元削減法による影響も評価するために、ステップワイズ法、主成分分析を用いて次元削減した場合、次元削減しなかった場合の3つの条件でオーバーラップ・パーティショニングの効果を調べた結果について述べる。

第5章では、本論文を総括し、得られた成果について結論する。

第2章 ブレイン-コンピュータ・インタフェース

2.1 ブレイン-コンピュータ・インタフェース (BCI) とは

今日、脳波などの人間の脳から発せられる信号をロボットアームやコンピュータなど他の装置を制御する命令に変換するインタフェースが盛んに研究されている。それがブレイン-コンピュータ・インタフェース (brain-computer interface; BCI) である。近年、脳科学は盛んな進展を見せているが、人間が考えていることを脳信号から完全に読み取る技術は現段階では知られていない。しかし、人間がある心理的な課題 (メンタルタスク) を行った際の脳活動はよく調べられている。例えばある事象に関連した脳活動や、ある点滅刺激を見た際に脳の視覚野で起こる脳波などがある。BCI はこのような解明されている脳活動をメンタルタスクにより発生させ、その際に得られる脳信号を解析することで動作するものが多い。

BCI は図 2.1 のようなシステムである。まず人間から脳信号を計測する。そして BCI は得られた信号をデジタル信号に変換し、特徴抽出や翻訳アルゴリズムなどの信号処理を経て装置を制御する命令に変換する。このような信号の入力から装置命令に変換する一連の処理を行うシステムが BCI である。

BCI を用いて重度の運動機能障害者の脳波を読み取り、電動車いすやロボットアームなどの福祉介護機器を制御する取り組みが数多くなされている。従来は口や目、首などの残存機能を使用した福祉介護機器が開発され、実用化されてきた。しかしながら BCI は筋電等を一切使用せずに装置を操作することができるため、新しい運動出力となる次世代のインタフェースとなりうると期待できる。これまで筋萎縮性側索硬化症 (amyotrophic lateral sclerosis; ALS) の患者が BCI をどの程度制御できるかなど、重度の運動機能障害者が実際に BCI を使えるか検証されてきた。BCI をより洗練することで、重度の運動機能障害者の生活の質 (quality of life; QOL) を向上させることに貢献することができると考える。

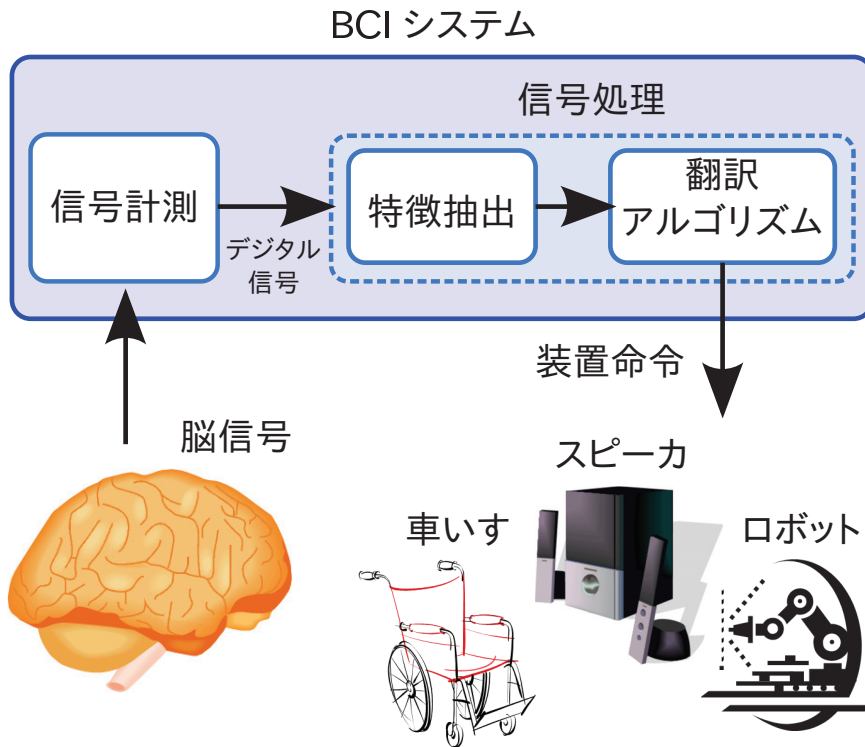


図 2.1: BCI システムの構成

人間の脳から発生する信号を脳波計などで計測し、特徴抽出や翻訳アルゴリズムなどの信号処理を行い装置命令に変換する装置が BCI システムである。脳信号を車いすやスピーカ、ロボットの装置命令に変換することで筋電などを使わずに外部の装置を制御することができる。

2.2 脳信号の侵襲計測と非侵襲計測

BCI を動かすために脳信号を計測するのだが、その計測種類は大きく分けて侵襲計測と非侵襲計測がある [5]。侵襲計測とは外科手術を施すなど人体に害を及ぼして計測する手法である。例えば頭蓋内脳波 (intracranial EEG; IC-EEG) を計測する皮質電図 (electrocorticogram; ECoG) は侵襲計測の代表的なものである。一方で非侵襲計測は人体に害を及ぼさずに計測する手法である。たとえば頭皮上脳波 (scalp EEG) のように頭皮に電極をつけて計測する手法がある。本論文では以降、単に脳波 (EEG) と書かれている場合は頭皮上脳波を指す。

頭蓋内より脳波を計測する手法は頭皮より計測する手法に比べて明瞭な信号を取ることができるため、信号から情報を読み取りやすいという利点がある。先行研究ではラット [6] や猿 [7] の ECoG を計測し、ロボットを制御するという研究がなされている。しかしながら倫理的問題から人間の頭蓋内で脳波を計測することは難しいなどの理由で侵襲計測を用いる研究はそれほど多くなされていない。その反面、非侵襲計測を用いる BCI の研究は非

常に多い。

侵襲計測により得られた脳信号を装置の命令に変換するインタフェースをブレイン-マシン・インタフェース (brain-machine interface; BMI) と呼び、非侵襲計測により得られた脳信号を装置命令に変換するインタフェースを BCI 呼ぶなど、計測手法による用語の使い分けがしばしば見られる [5]。しかしながらこの用法はそれほど厳密ではなく、近年は計測方法にかかわらず BMI もしくは BCI とひとまとめに呼ぶ傾向がある。本論文では非侵襲計測を主に使うため、計測手法を問わず脳信号を装置制御命令に変換するインタフェースを BCI と呼ぶ。また、本論文では以降、人間を対象とした BCI について取り上げる。

2.3 非侵襲計測手法の種類

脳信号の非侵襲計測には脳波、磁気共鳴機能画像法、脳磁図、近赤外線分光法、陽電子造影法といった手法がある [8]。ここでは各手法の動作原理と利点、欠点について述べる。その際、時間分解能と周波数分解能という用語を用いるが、これは電気電子工学におけるものとは異なる定義がなされている [9]。時間分解能とは一カ所から計測して、短時間に二度続けて活動した時に、それを区別できる最短の時間のことを言う。また、空間分解能とは2カ所が同時に活動した場合に、それらを区別できる最短の距離のことである。そのため、脳波計のカタログなどに掲載されているチャンネル数やサンプリング周波数などはあくまで装置の分解能であり、それらの分解能が高いからと言って必ずしも各非侵襲計測手法の分解能が高いとは限らない。

2.3.1 脳波

脳波 (electroencephalography; EEG) は電極を体表面に貼り付け、その電位差を測定する手法である [8]。神経や筋肉の活動により生じた電位を計測しているため、高い時間分解能を持つ (約 10^{-2} s [9])。しかしながら使用できる電極の数に制限があるため、空間分解能は高くない (約 10mm [9])。BCI の研究では小型で時間分解能が優れているなどの理由により盛んに使用されている [10]。脳波計測器には様々なものがあり、医用の高性能なものから、ヘッドセット型の簡易なものまである。

BCI の研究のための計測器としては g.USBamp (Guger Technologies OEG, Austria) がよく用いられる (例えば [11])。g.USBamp は BCI のためのソフトウェア開発キット (software development kit, SDK) が豊富に揃っており、簡単に実験を開始することができる。また、科学技術計算のためのソフトウェアである MATLAB/Simulink によく対応しており、追加

のソフト (Toolbox) を用いることなく実時間でデータを計測し、即座に解析するなどできるため、研究の用途では非常に便利である。その他、128 チャンネル以上の脳波を計測するなど医用目的には ActiveTwo (BioSemi, Netherland) などが用いられる (例えば [12])。一般の脳波計は BCI 構築の前段階の基礎的な脳波データ計測には最適であるが、実時間でデータを処理する BCI を構築するには SDK が揃っていないと苦勞することが多い。BNC 端子で A/D コンバータに接続することで任意の脳波計から信号を計測するシステムを構築できるが、その場合には MATLAB/Simulink に Data Acquisition Toolbox を追加する必要がある。

また、BCI に簡易な脳波計測器が用いられることが多くなっている。典型的には MindSet (Neurosky, Inc., USA) や EPOC (Emotiv Systems, Australia) などのように 1 万円~10 万円程度と廉価で簡易なワイヤレス脳波計測器が BCI に用いられることが増えている [13]。それらの計測器のための SDK など多数用意されており、実時間で動作する BCI システムの構築が簡単になっている。また、MindSet は金属を皮膚に直接当てて計測できるドライ電極を採用しており、EPOC も電極フェルトに生理食塩水を染み込ませて使用するようになっており、従来の電界ペーストを使用するものより準備や後処理が簡単になっている。他にも頭皮と電極の間にゲル状のものを用いる電極が開発されており [14]、こちらも電解ペーストと比較して簡易に計測することができる。現在は研究の用途で高性能な計測器や電解性のペーストを使用する電極などが多用されるが簡易に計測できる電極に移行しつつある。

2.3.2 磁気共鳴機能画像法

磁気共鳴機能画像法 (functional magnetic resonance imaging; fMRI) は外部から強力な静磁場と電磁波を作用させ、スピンの向きを強制的に揃える磁気共鳴現象を観測し、元の状態に戻るまでの速度、すなわち緩和速度の違いにより還元型ヘモグロビン濃度を調べる手法である。fMRI は高い空間分解能を持つ (約 1~10mm[9]) が、高次機能そのものを測定しているのではなく、生じた脳血流の変化を調べている。そのため神経活動から数秒遅れて脳血流が変化する可能性があるため時間分解能は低いとされる (約 10¹s[9])。

fMRI は BCI でもしばしば用いられる。例えば BCI に関連する神経科学的知見を得るために fMRI による解析が行われる [15]。また、実時間で fMRI を計測して解析することで動作する BCI (fMIR-BCI) なるものが、少数ではあるが提案されている。Sitaram らは fMRI-BCI でロックト・イン状態の患者の感情状態を実時間で判別し、被験者にフィードバックする研究を行った [16]。画像データの画素値はピクセル (pixel) で表示されるが、fMRI の 3 次元

計測データは体積の画素値に当たる単位、すなわちボクセル (voxel) で表現される。fMRI のサンプリング周波数は高くないものの、計測されたデータは膨大になる。そのため実時間で処理するためには高次元データをうまく扱うことのできるシステムを開発する必要がある。

2.3.3 脳磁図

脳磁図 (magnetoencephalography; MEG) は超電導体を用いて作られた高感度コイルである SQUID を用いて神経や筋肉の活動により生じた電流から発生する電界を捉える手法である [8]。MEG は直接活動を計測しているため高い時間分解能を持つ (約 10^{-2} s[9])。しかしセンサの個数に物理的制限があり、空間分解能は低い (約 10mm[9])。

MEG と EEG の発生機序は同じであり、空間分解能・時間分解能ともに同等であるが、EEG に対する MEG の利点は下記の 3 つがある [9]。

- より正確な電流源の推定が可能である。EEG は主に細胞外電流を計測しているのに対し、MEG は主に細胞内電流を計測しており、また生体の透磁率は一樣なため磁場分布が歪まないからである。
- 基準電極の活性化の問題がない。EEG は基準電極が活性化した場合に正確な振幅・電位分布が得られないのに対し、MEG は磁束密度の絶対量を計測しているためである。
- 高周波数まで計測できる。EEG は組織の導電率の不均一によりローパスフィルタがかかり、高周波成分が減衰してしまうが MEG では磁束密度を計測しているため MEG のほうが γ 帯域などの高周波帯域で有利と考えられている。

BCI では主に安価で安全な EEG が用いられているが、上記のような EEG に対する MEG の利点があり、MEG を代用することでコミュニケーションをより速くすることができると考えられ、MEG を用いた BCI が提案されている [17]。

2.3.4 近赤外線分光法

近赤外線分光法 (near-infrared spectroscopy; NIRS) は波長が 700nm~900nm 程度の光である近赤外光を生体に照射し、透過・反射光から酸化型・還元型ヘモグロビンの濃度変化を検出する手法である [8]。本手法は神経活動の結果生じた血流循環や酸素の供給量であるため時間分解能は低い (約 10^1 s[9])。また、測定点数が少ないため空間分解能も高くない (約 10~100mm[9])。しかしながらプローブによる計測が可能のため、fMRI や PET と比較

して場所による制約が少なく、運動中の脳活動を計測するのに長けている [18]。また脳波のような電氣的計測ではないので、運動による筋電に影響されないという利点がある。

近年、NIRS が BCI に用いられる例が増えている。従来の NIRS 計測装置は冷蔵庫ほどの大きさのものからプローブを伸ばして計測するものであった。しかしながら NIRS は小型化されつつある。例えば OEG-16 (Spectratech Inc., Japan) はノートパソコンの半分ほどの大きさで、移動しながら計測できる。OEG-16 を使ったポータブルな NIRS-BCI はすでに提案されている [19]。また NIRS は脳波と同時計測可能であり、それらを用いて運動想起により動作する BCI が提案されている [20]。このような技術の進展が発端となり、今後 BCI のために NIRS が盛んに用いられる可能性がある。

2.3.5 陽電子造影法

陽電子造影法 (positron emission tomography; PET) は陽電子を放出する C_{11} 、 N_{13} 、 C_{15} 、 F_{18} などの放射性元素を体内に導入し、陽電子と電子が結合する際に生じる放射線 (ガンマ線) を計測し、断層画像を得る手法である [8]。細胞の活動そのものではなく、活動の結果使われるブドウ糖の分布を調べていることになる。このように 2 次的な量を計測しているため時間分解能が低い (約 10^3 s[9])。しかし PET は高い空間分解能を持つという利点がある (約 $1\sim 10$ mm[9])。また、有機化合物 (薬剤) が利用可能であり、特定の細胞の活動のみを得ることができる。サイクロトロンが必要になるため大掛かりな装置が必要になる。また放射性元素を用いるため、わずかではあるが被曝する。

2.4 脳波計測法

脳信号の非侵襲計測手法には様々なものがあり、近年その進化に目を見張るものがあるが、2.3.1 で前述したように脳波は安価でかつ高い時間分解能で簡易に測定できるという利点から BCI に最もよく用いられている。そのため本研究でも脳波を用いた BCI を主に取り扱う。本節では脳波の計測手法や発生メカニズムについて述べる。

2.4.1 脳波と脳波計

生きている人間の頭部表面に 2 つの電極を取り付けると、その間に数十マイクロボルト (μ V) 程度の電圧が生じるが、これを脳波という [21]。脳波計はその微弱な脳波を増幅して計測する装置である。計測の際には電極に電解ペーストをつけて頭部に貼り付け、電位を




図 2.2: 10-20 法による計測位置の決定方法

鼻根から後頭極までの長さ、右耳から左耳までの長さなど、ある基準となる長さを 10%または 20%の間隔で区切り、電極位置を決める方法である。

測定する。脳波は国際的に決められた電極位置より計測する。その国際的な基準として 10-20 法がある [21](図 2.2)。鼻根から後頭極までに頭頂を通る曲線を引き、その長さを 100%として、それを 10%または 20%ごとに印をつける。その後、左耳から右耳まで頭頂を通る曲線を引き、その長さを 100%として、同様に 10%または 20%ごとに印をつける。その 2本の曲線をもとにクモの巣のように間に線を引き、同様に 10%または 20%ごとに印をつける。このように 10%または 20%ごとに印をつけ、電極の位置を決めるのが名前の由来である。

各部位は葉を表す頭文字とは前頭葉と、脳半球の場所を特定する数字と記号から成る。前頭極 (frontal pole)、前頭部 (frontal)、側頭葉 (temporal)、中心部 (central)、頭頂葉 (parietal)、後頭葉 (occipital) の頭文字である Fp、F、T、C、P、O が用いられる。耳 (auricular) には A が用いられる。半球を表す数字と記号は、鼻根から頭頂部を通り後頭極までを通る直線

を中心とし、その部分に乗る半球の位置を z と書き、そこから左半球に離れていくごとに 1、3、5、7 と奇数が割り振られ、右半球に離れていくごとに 2、4、6、8 と偶数が割り振られていく。そのため、名前の付け方を覚えれば、記号と数字を見るだけでどの位置から測定したのか簡単に想像がつく。

また、この方法を派生させ、10%ごとに電極を配置したものを 10%法や拡張 10-20 法と呼ぶ [21]。10-20 法で用いた記号 (Fp、F、T、C、P) に加え、10%法では前前頭部 (anterior frontal)、前頭-中心部 (fronto-central)、前頭-側頭部 (fronto-temporal)、中心-頭頂部 (centro-parietal)、頭頂-後側頭部 (parieto-occipital)、側頭-後頭部 (temporal-posteriori temporal) の頭文字を表す AF、FC、FT、CP、PO、TP が追加された。

2.4.2 脳波の導出

脳波を計測するために、ある二点に付けられた電位の差を記録することを導出という [22]。その際に用いる一対の電極は異なる意味合いを持つ。計測時に理想的には電位ゼロの基準となる点においた電極を参照電極 (reference electrode; REF) という。一方で脳はそのものを捉えるための頭皮の電極を探索電極 (exploring electrode) と呼ぶ。これらの電極を用いて脳波を導出することになる。

脳波の導出法には大きく 2 種類ある [23]。基準電極と探索電極の差を用いて脳波を捉える方法を基準導出法という (図 2.3)。基準導出法ではある一つの基準電極を用いる場合や、二つの基準電極の平均を用いる方法がある。それに対し、探索電極はいくら取り付けてもよい。BCI では専ら基準導出法が用いられる。また、基準電極を使わず、探索電極同士を組み合わせる方法を双極導出法というものもある (図 2.4)。特に探索電極の列に従って連結し、左右でそれぞれ探索電極が循環するように連結して双極導出する方法を連結双極導出法と呼ぶ。

探索電極、参照電極の他に接地電極 (ground electrode; GND) がある脳波計が多い¹[22]。脳波計は一般に差動増幅器を用いており、入力信号のうちの同相信号は弱められ、逆相信号は増幅されるという性質がある。そのため探索電極と接地電極の差の信号と、参照電極と接地電極の差の信号を入力すれば商用交流 (ハム) などの雑音が入りにくくなる。接地電極は漏洩電流を考慮し心臓より上部に設置することになっており、一般の脳波記録では額や鼻尖に接地電極を置いて計測することが多い [22]。BCI の研究では Fz や AFz などの位置に接地電極を置いて計測することが多い (例えば [24, 25])。

¹脳波計により仕組みの違いがあり、ActiveTwo などのように接地電極をつける必要がない計測器もある。




図 2.3: 単極導出法

探索電極と参照電極を組み合わせて脳波を導出する手法である。左半球では $Fp_1 - A_1$ 、 $F_3 - A_1$ のように左半球の参照電極 A_1 との間の電位を測定している。右半球についても同様に各探索電極は A_2 との間の電位を測定している。

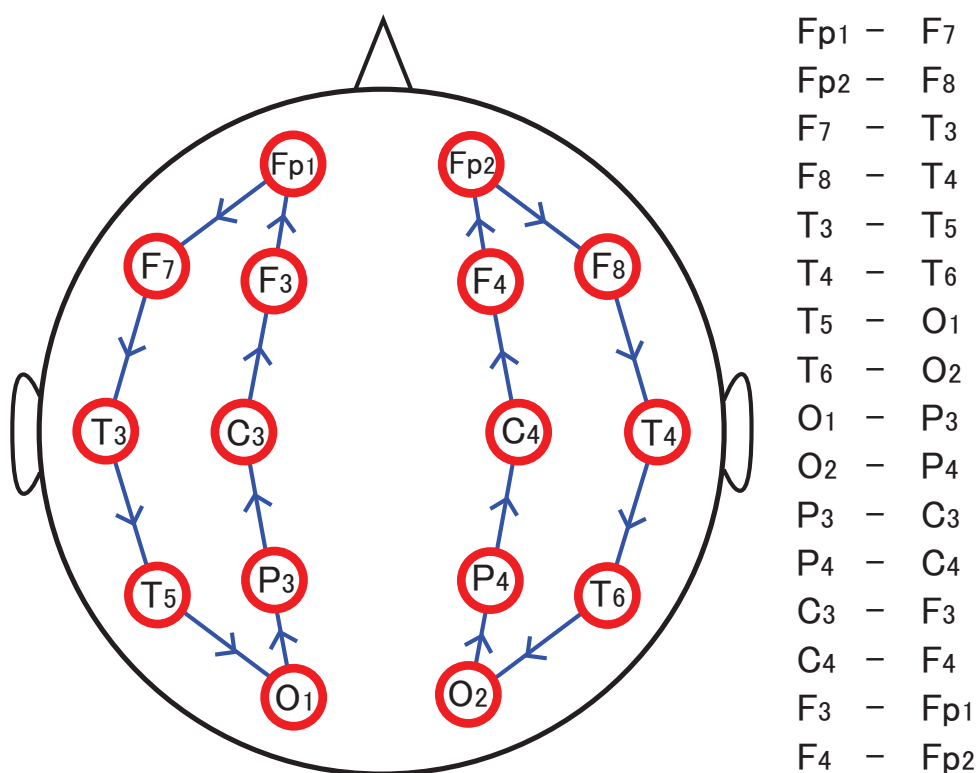


図 2.4: 連結双極導出法

探索電極を左右それぞれの半球で列またはリング状に連結して脳波を導出する手法である。図の左半球の電極に着目すれば、 $Fp_1 - F_7$ 、 $F_7 - T_3$ と続き、 $F_3 - Fp_1$ となり、リング状に電位を測定していることがわかる。右半球についても同様である。




図 2.5: 神経細胞

神経細胞は樹状突起から他の神経細胞からの情報を受け取り、統合した結果を軸索から出力する。神経細胞は膨大な数が互いに繋がりネットワークを構築しており、複雑な情報処理を行っている。

2.4.3 脳波の発生原理

脳波の発生には神経細胞 (ニューロン)[26] が深く関わっている。神経細胞は図 2.5 のように細胞体 (cell body, soma)、核 (core)、樹状突起 (dendrite)、ミエリン鞘 (myelin sheath)、軸索 (axon)、軸索終末 (axon terminal) から成る。細胞の電位は、細胞外を基準とした時の細胞内部との電位差で表されるが、これを膜電位と呼ぶ。通常、膜電位は約-70mV となっており、これを静止膜電位と呼ぶ。神経細胞の膜にはナトリウム-カリウムポンプという機構があり、細胞内外でイオンのやりとりを行うことによって静止膜電位が発生する。樹状突起は他の神経細胞からの神経伝達物質を受け取る入力側であり、軸索は他の神経細胞に情報を伝える出力側と考えることができる。細胞体は通常、数十の樹状突起を持ち、他の神経細胞の軸索と繋がっている。その 2 つの神経細胞間で情報伝達が行なわれる部分をシナプスという。シナプスでは送り側の軸索から神経伝達物質が分泌され、受け取り側は細胞膜のイオン透過性を変化させる。シナプス後細胞にイオンが流れこむことによって生じる電位変化をシナプス後電位という。特に Na^+ が細胞膜の外部から内部に侵入し、膜電位を上げるものを興奮性シナプス後電位 (excitatory postsynaptic potential; EPSP) と呼び、逆に Cl^- などが流入し、膜電位を下げるものを抑制性シナプス後電位 (inhibitory postsynaptic potential; IPSP) と呼ぶ。EPSP により膜電位を上げる場合を脱分極と呼ぶが、あるところまで脱分極させると振幅が 40mV を超えるパルスが見られ、1ms ほど持続する。これを活動電位 (action potential) という。このようなパルスを発生する活動のことを発火 (fire) あるいは興奮 (excite) という。その後、静止膜電位より低いところまで膜電位が下がり、しばらく反応が見られない不応期に入る。

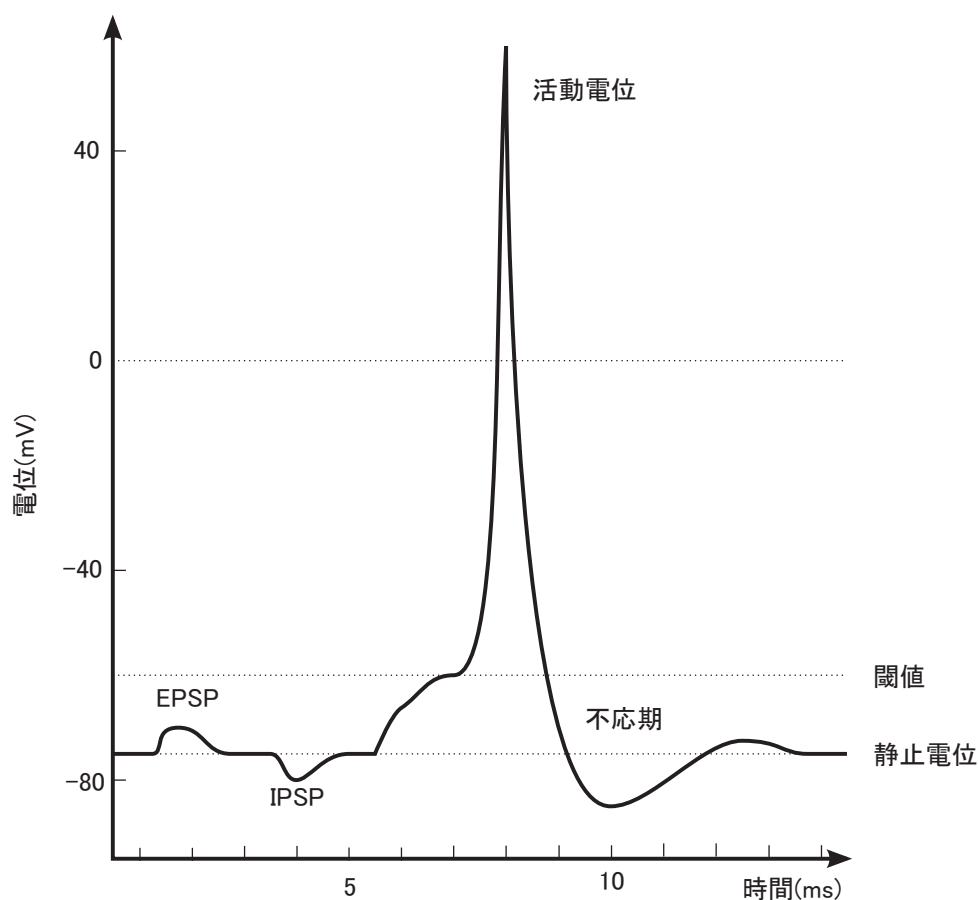


図 2.6: 活動電位

他の細胞からの入力を受けることで膜電位が上昇し、ある閾値を超えると活動電位を生じる。活動電位を出した後はしばらく活動電位を出しにくい不応期に入る。

脳波は主に大脳皮質から生じている [21]。大脳皮質は 6 層からなり、様々な神経細胞を含む。脳波の主要電源は第 V 層に細胞体があり、大脳皮質表面に向かって樹状突起を伸ばした錐体細胞であると考えられている。脳幹など皮質下の神経核で生じた電位が頭皮上で記録されることもあるが、大抵は $1\mu\text{V}$ 以下であると言われている。活動電位は振幅が大きいものの、持続時間が約 1ms と短く、IPSP で発生する電位は小さいので、両者は脳波の生成にはあまり貢献しないと考えられている。そのため EPSP が脳波の源と見なされている。

2.5 脳波を用いた BCI の種類

BCI は検出する脳波の種類により分類されることが多い。ここでは代表的な 3 つの BCI について述べる。

2.5.1 ERP-based BCI

ディスプレイから提示された音や、スピーカから発せられた音、指の曲げ伸ばし運動などの事象の後に生じる脳波が事象関連電位 (event-related potential; ERP)² である [21]。ERP は自発的に生じる脳波に重なって生じるが、ERP に着目している場合、自発的な脳波を背景脳波と呼ぶ。ERP は背景脳波に比べて振幅が小さいため、事象の生起時点にそろえて加算平均するという方法が盛んに行われる。

ERP を計測するにはある特定の実験手続き、すなわちパラダイム (paradigm) が必要になる。例えば 2 種類以上の刺激事象を用意し、刺激頻度に差をつけて提示する手続きであるオドボールパラダイムはその典型例である。低頻度の刺激事象、すなわちオドボール (oddball) が出現した際に心の中で出現する回数を数えさせたり、出現のたびにボタン押しをさせたりする。この課題をオドボール課題 (oddball task) という。オドボール課題は Squires らによって初めて使用された [27]。図 2.7 に聴覚刺激によるオドボール課題の例を示す。

ERP を用いた BCI では 6×6 行列に並ぶ灰色の文字が行ごと、列ごとに白く光る刺激が提示される。被験者はこれから入力すべき文字を決める、もしくは与えられるので、その文字が光った時に心の中で数を数える課題を行う。このとき、着目している文字が光る低頻度の刺激を標的刺激 (target stimulus)、着目している文字が光らない刺激を標準刺激 (standard stimulus) と呼ぶ。刺激を開始した時刻から後 600ms 程度の脳波を取り出し、その脳波の加算平均をとると、頭頂野付近の電極で、刺激開始時から約 300ms 後に陽性方向のピークが見られる。これを P300³ と呼ぶ。P300 を含む ERP をオドボールパラダイムを用いて巧みに惹起させ、それをパターン認識技術により検出し、実時間で装置命令を出力できるようにしたのが P300-based BCI である。この装置を世界で初めて開発したのは、P300 の課題関連性について研究し続けていた Donchin らのグループであった。その際に作成されたのがアルファベットや数字を入力する装置であったので、P300 スペラー [28] とも呼ばれる。また、その装置は開発者の名前を取り Donchin スペラー [29] などとも呼ば

²物理的の刺激が起こす脳電位反応を誘発電位 (evoked potential; EP) と呼び、心理的な属性や物理的の刺激なしに生じる脳電位反応を事象関連電位と区別することがある [21]。

³陽性方向の 3 番目のピークであるから P3 とも呼ばれる。




図 2.7: 聴覚オドボール課題の例

1,000Hz の低音刺激と 2,000Hz の高音刺激の 2 種類の刺激を用意する。低音刺激は高頻度 (確率 $p = 0.8$) で、高音刺激は低頻度 (確率 $p = 0.2$) で提示される。この場合、高頻度で提示される低音刺激が標準刺激であり、低頻度で提示される高音刺激が標的刺激となる。被験者は高音刺激の出現回数を心の中で数えるというメンタルタスクを行う。このような課題を行った際の標的刺激後 700ms 程度の波形の加算平均を取ると、頭頂付近の電極で刺激提示より約 300ms 後に正のピーク、すなわち P300 を観測することができる。このオドボール課題の例は [21] を参考にして作成した。

れる。ERP を用いているが P300 以外の要素が識別に貢献していると考えられる場合などもあるため、より一般化した呼び方として ERP-based BCI[30] と呼ばれることがある。本研究でそれらを区別する必要がない限り、まとめて事象関連電位を用いた BCI、すなわち ERP-based BCI と呼ぶことにする。

2.5.2 SSVEP-based BCI

定常状態視覚誘発電位 (steady-state visual evoked potential; SSVEP) はある特定の周波数の視覚刺激に対する神経反応である [31]。網膜が 3.5–75Hz の視覚刺激により発火させられると、その周波数と同じ、もしくはその倍周波数で同期する脳波が視覚野で観測できる。複数の装置命令と周波数を対応付ければ、被験者が脳波から特定した SSVEP の周波数によりどの装置命令を入力したのかを特定することができる。例えば Martinez らは図 2.8 のようにコンピュータの画面上に表示されているレーシングカーを上から眺めてサーキット上を運転するのに、レーシングカーの上下左右に配置されたフリッカー (上に 12Hz、左に 13.3Hz、下に 15Hz、右に 17Hz のチェッカーボードフリッカー) を割り当て、2 次元上を移動させる SSVEP を開発した [32]。

SSVEP-based BCI のための刺激方法は様々なものが考えられる。SSVEP の刺激提示にはコンピュータのディスプレイを用いたものや、発光ダイオード (light emitting diode; LED) を用いたものなどがある [33]。コンピュータのディスプレイを用いれば点滅刺激として様々な図形を提案することができる。一般的には白と黒の単色四角のフリッカーや、白と黒のチェッカーボードによるフリッカーが用いられることが多いが、識別精度自体は白と黒の四角を用いたほうがチェッカーボードより高い [34]。上記のようなシンプルなパターン反転刺激以外にも、情動的顔画像を用いたものもある [35]。

SSVEP-based BCI のパターン認識には高速フーリエ変換 (fast Fourier transform; FFT) を行った際のパワースペクトル密度 (power spectrum density; PSD)[36] を用いる方法や、正弦波群と脳波の正準相関分析 (canonical correlation analysis; CCA)[37] などが盛んに用いられる。また、SSVEP-based BCI は他の BCI に比べ情報伝達率が高く、訓練時間も短いという特徴がある [38]。一方で視覚刺激が強力で光過敏性てんかんの発生が危惧されるため、通常は過度に強烈な視覚刺激を与えないような条件下で実験が行われる [39]。SSVEP は明らかに視覚刺激に依存するため、視線を自由に動かせない被験者に対する性能低下が懸念されるが、近年はロックト・イン状態の患者のための SSVEP-based BCI が提案されている [40]。



図 2.8: SSVEP-based BCI を用いた二次元平面上のレーシングカーを制御する方法の例

画面上に表示されているレーシングカーを二次元平面上で上下左右に制御するために SSVEP-based BCI を用いている。レーシングカーの上下左右にチェッカーボードフリッカーが配置されており、それぞれ異なる周波数で点滅する。例えばレーシングカーを上を動かしたいのであれば被験者はレーシングカー上部の 12Hz で点滅するフリッカーを見つめる。すると被験者の視覚野の脳波には 12Hz とその倍周波数である 24Hz、36Hz のパワー値が高くなる。システムはそれを検出したらレーシングカーを上を動かす。レーシングカーの移動に伴いフリッカーも移動し、常にレーシングカーの上下左右にフリッカーが現れるようになっている。図は [32] を参考にして作成した。

2.5.3 ERD/ERS-based BCI

右手や左手、足、舌の動運をした際や、運動を想起した際に、頭頂付近にある運動野で、運動に関連する感覚運動リズム (somatosensory motor rhythm; SMR) である μ 波の周波数パワー値が減少する。このように事象に関連して同期しなくなる現象を事象関連脱同期 (event-related desynchronization; ERD) と言い、これを検出することで BCI を駆動させることができる [41]。このような BCI を ERD-based BCI と呼ぶ。事象に関連して同期する事象関連同期 (event-related synchronization; ERS) と合わせて捉えることができるため、ERD/ERS-based BCI と呼ぶことや [42]、運動想起を用いることから運動想起を用いた BCI (motor-imagery-based BCI) と呼ぶことがある [43]。感覚運動リズム (SMR) を用いているため、SMR-based BCI とも呼ばれる [44]。ERD/ERS-based BCI の検出には共通空間パターン (common spatial pattern; CSP) を用いて特徴抽出し、線形判別分析で判別する方法 [45] が盛んに用いられる。

2.6 性質による BCI の分類

BCI はその性質により様々に分類されることがある。それにより課題が浮き彫りにすることができ、その課題を解決する方向に研究を進めていくことができる。

2.6.1 非同期型 BCI と同期型 BCI

BCI は脳信号より命令を解析するだけでなく、命令を出していないときに誤作動しないようにするのが望ましい。セルフ・ペースド (self-paced) BCI、もしくは非同期型 (asynchronous) BCI は連続的に脳信号を解析するシステムであるが、意図した制御 (intended control; IC) 状態に加え、制御しない (non-control; NC) 状態を検出するシステムである [46]。一方で NC を検出せず IC 状態のみを考えているものを同期型 (synchronous) BCI という。

BCI システムは簡単のために同期型 BCI で評価することが多い。Donchin らが開発した初期の ERP-based BCI も同期型 BCI であり、ユーザが他のことを考えている時や、休憩している時でも脳波を解析し、何らかの命令を出すようになっている [47]。特に何も断りが無い場合は同期型 BCI について議論している論文が多い。

近年、非同期型 BCI の開発が進められている。例えば SSVEP を用いて IC と NC を検出し、P300 を検出して命令を出力するハイブリッド型 BCI が提案されている [48]。また、

ERD/ERS-based BCIにおける非同期型 BCI では IC と NC を検出するのに統計的な排除基準や SSVEP を用いる方法など数多く提案されている [49]。

2.6.2 注意の種類と依存型 BCI と独立型 BCI

前述した BCI を動作させるには刺激に対して注意が必要になるが、注意にはいくつかの種類がある [50]。刺激発生源に視線を動かして注意する方法を顕在的注意 (overt attention) と呼び、視線を向ける必要がなく心の中で注意する方法を潜在的注意 (covert attention) と呼ぶ。顕在的注意を行うためには眼球を動かす筋肉が必要であるが、重度の運動機能障害を患うと、眼球運動が制限されてしまう可能性がある。そのため、重度の運動機能障害者を対象とするのであれば顕在的注意ではなく潜在的注意により得られた脳信号を検出し動作する BCI システムのほうが望ましい場合がある。

BCI は依存型 (dependent) BCI と独立型 (independent) BCI に分類されることがある [51]。視覚誘発電位 (visual evoked potential; VEP) を用いた BCI は、注視するために眼球の筋肉を使うため依存型 BCI に分類される [52]。一方で slow cortical potentials や P300、 μ 波や β 波などを用いたものは独立型 BCI に分類されると考えられている [52]。顕在的注意を用いる BCI は依存型 BCI であり、それ以外は独立型 BCI であると解釈することができる。

依存型、独立型 BCI の区分はシステムによるため一概に分類することは難しい。SSVEP-based BCI は文字通り VEP を使用しているが、潜在的注意を用いても動作するので [53] 依存型 BCI に分類されるとは限らない。P300-based BCI は、P300 が心理的に発生する電位であるから潜在的注意のみによって動作すると考えられるが、近年、P300-based BCI は視線を動かさなければ性能が低下することが報告されており、視線に依存する部分があるのではないかと指摘されている [54]。この理由としては視覚野に多くの探索電極が割り振られており、特徴にも P300 のみならずすべての電極から発生した脳波を特徴として用いているためである。そのため、顕在的注意を用いたほうが視覚誘発電位などの判別しやすい成分を併用できるため識別精度が高くなる。しかし視覚に依存すると、眼球をうまく制御できない重度の運動機能障害者が使用した場合に性能が低下する恐れがある。そのような背景もあり視線に依存しない P300-based BCI が開発されている [50]。また、P300 や α 波、SSVEP を用いたハイブリッド型の視線に依存しない独立型 BCI が開発されている [55]。このようにある BCI システムを依存型、独立型の BCI どちらかに分類するよりも、両側面を持つと捉えることもできる。

2.6.3 まとめ

本章では BCI に関連する計測器や、BCI に最もよく使われている脳波の測定方法について述べ、その後 BCI の種類について言及した。重度の運動機能障害者に応用する場合のことを考え、本研究ではごくわずかに残った視線による潜在的注意により動作することのできる ERP-based BCI に着目した。次章では ERP-based BCI の詳細なメカニズムについて述べる。

第3章 ERP-based BCIの構成

ERP-based BCIは2.5.1で説明したとおり、ある特定のERPを誘発する刺激を提示し、その刺激に応じて得られたERPを認識することにより動作するBCIのことである。ERPを検知する方法は数多く考えることができるが、本章ではERP-based BCIの研究で一般的に使用されている検出方法について述べる。具体例としてBCI competition III data set IIや、それとほぼ等価の独自で開発したERP-based BCIで用いられている36種類の文字入力ができるP300スペラーを例にして説明する。

3.1 ERP-based BCIシステムに使用される装置

ERP-based BCIは図3.1のように、ERPの刺激を提示するための刺激提示部、刺激提示時の脳波を測定する計測部、得られた信号を処理し認識する信号処理・識別部、認識した結果を元に画面やロボットへの出力やフィードバックを行う出力部から構成される。

3.2 刺激提示部

ERP-based BCIの刺激提示方法には視覚、聴覚、触覚からの刺激が考えられるが、その中でも視覚刺激が盛んに使用されている[57]。刺激提示部には典型的にコンピュータのディスプレイが用いられることが多く、黒地に灰色の文字が表示されているものがよく使用される[38]。提示される刺激に対してあるメンタルタスクを行うことによりERPを得ることができるので、その際の脳波を被験者の頭皮より計測する。

視覚刺激を提示する装置としてはコンピュータのディスプレイの他にヘッドマウントディスプレイ[58]やスマートフォンのディスプレイ[59]などが用いられる。SSVEP-based BCIにおいては発光ダイオード(LED)が盛んに用いられている[33]が、ERP-based BCIではLEDはあまり使用されない。

視覚刺激の他にも聴覚や触覚を使用したERP-based BCIがある。例えばスピーカーからの音による聴覚刺激を用いたオドボール課題を用いるBCIや[60]、モーターの回転により触覚刺激を与える振動子を用いて動作するBCI[61]などが提案されている。視覚と聴覚

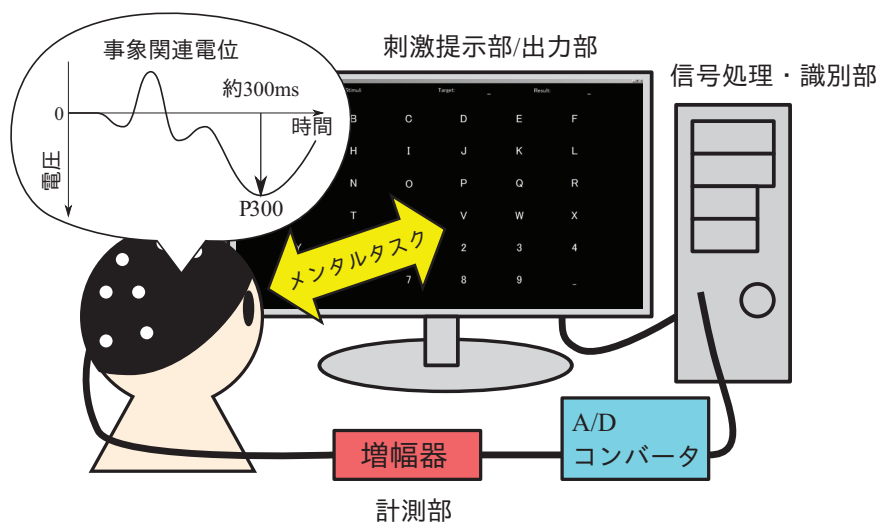


図 3.1: ERP-based BCI の構成

ERP-based BCI は刺激提示部、計測部、信号処理・識別部、出力部から構成される。図で示した ERP-based BCI ではディスプレイが刺激提示部、出力部、頭皮から脳波を計測してデジタル信号に変換するまでが計測部、コンピュータで信号処理をして装置制御命令に変換する部分が信号処理・識別部となっている。図は [56] を一部改変したものである。

刺激の両方を用いたシステム [62] なども構成できる。視覚、聴覚、触覚それぞれについて ERP-based BCI の性能が違い、視覚刺激を用いた場合に性能が高いことが報告されている [63]。

典型的な P300 スペラーは図 3.2 のようにコンピュータのディスプレイを用いる。出力命令はアルファベット A~Z、数字 1~9、アンダーバーの 36 種類で構成されている。それらの文字は画面上に 6 行 6 列で並べられており、灰色の文字が行ごと列ごとに一瞬だけ白くなるような刺激が提示される。

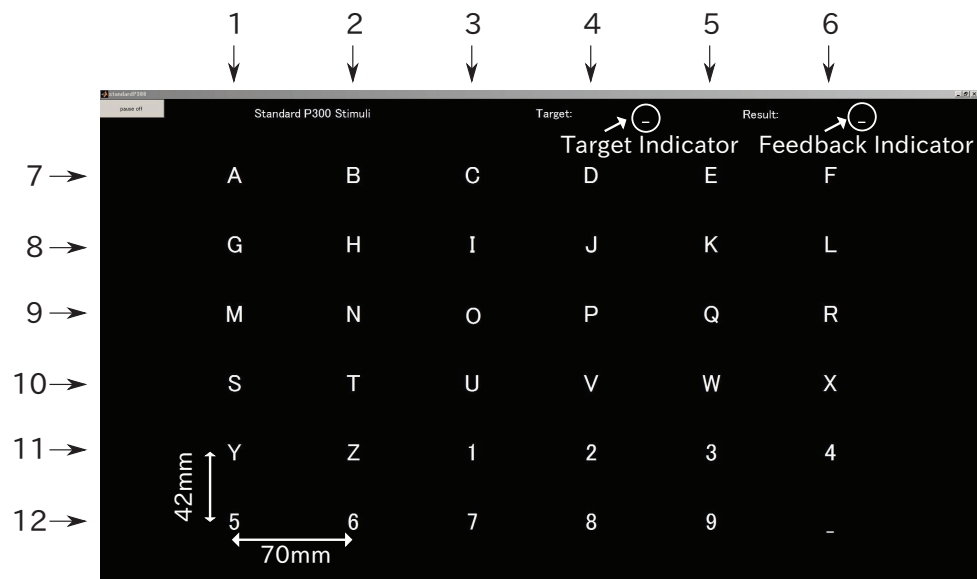


図 3.2: ERP-based BCI の刺激提示部 (P300 スペラー)

ERP-based BCI の刺激提示部にはコンピュータディスプレイがよく使われる。そのディスプレイに図のような 36 種類の文字が 6 行 6 列の行列状に配置し BCI により文字入力を行うものが典型的に ERP-based BCI の性能評価に用いられる。このような装置を P300 スペラーと呼ぶ。文字は通常は灰色になっており、図中矢印で示す行または列のうちのいずれかに対応する文字が一瞬白く光る刺激を用いる。文字入力装置であるため、出力はそのままコンピュータのディスプレイ上に提示される。図は [56] を一部改変したものである。




図 3.3: ERP-based BCI で頻繁に用いられるモンタージュ

図は頭部を真上から見て鼻が上側になるような視点で見た時の人間の頭部を円、鼻を三角で表しており、電極の大まかな位置を示している模式図である。

3.3 計測部

脳波は被験者の頭皮に脳波測定用の電極を取り付けて計測する。ERP-based BCI の脳波計測では図 3.3 のように国際 10-20 法に従い Fz、Cz、P3、Pz、P4、PO7、Oz、PO8 の 8 チャンネルから単極導出法を用いて計測されるモンタージュを使用することが多い [64, 65]。接地電極を AFz にし、参照電極を両耳の乳様突起 (mastoids)、もしくは耳朶に取り付け結線する場合 [56] や、参照電極を右耳朶に、接地電極を左耳朶に取り付ける場合 [64] や参照電極を Fpz に、接地電極を AFz にする場合 [65] などがある。

脳波は脳波計測を通じて測定するが、その際にハードウェアフィルタをかけ、信号を増幅する。ERP-based BCI では 0~30Hz 程度の帯域を用いて妥当な識別精度が出ることが報告されているので、ハードウェアフィルタもしくはソフトウェアフィルタでその帯域が残るようにすればよい。例えば Townsend らは 0.5~30Hz 帯域 [66] を、Akram らは 0.1~25Hz 帯域 [67] を使用している。脳波計で計測した微弱な脳波信号を増幅する際の増幅率は 20,000 倍 [64] や 25,000 倍 [56] で正常に検出できることが確認できる。

フィルタリングし、増幅したアナログ信号を A/D 変換器を用いてデジタル化する。その際のサンプリングレートは 256Hz 以下がよく用いられる [64, 65, 66]。これは P300 を含む ERP の検出のために 30Hz 以下の情報しか使わないため、もしくは実時間処理の負荷低減

のためである。

3.4 刺激の制御とデータ構造

3.4.1 P300 とオドボール課題

P300 は Sutton らにより発見された ERP の成分である [68]。ERP-based BCI より計測された P300 を含む標的波形と、P300 を含まない標準波形を図 3.4 に示す。また、標的波形と標準波形の差を取り、トポグラフィーを用いて表したものを図 3.5 に示す。




図 3.4: ERP-based BCI データの標的波形と標準波形

図は BCI competition III data set II の被験者 A の訓練データ (85 文字分) の Cz より計測された標的波形、標準波形の平均値を描画したものである。標的波形は刺激から 300ms 後付近で大きく正に振れており、標準波形とは大きく異なっている。

オドボール課題とは 2.5.1 でも述べたように、高頻度の刺激 (標準刺激) と低頻度の刺激 (標的刺激) の 2 種類を用意し、それらを被験者にランダムに提示し、高頻度の刺激が現れたらボタンを押すか、心の中で数を数える課題である。オドボール課題を行うことで大きな P300 の振幅が得られることが知られている。ERP-based BCI で P300 を検出するためには




図 3.5: ERP-based BCI データのトポグラフィー

BCI competition III data set II の被験者 A の標的波形及び標準波形それぞれの平均波形を求め、その差を用いてトポグラフィー (地勢図) を作成したものである。図は刺激提示より 300ms 後の状態を示している。人間の頭部を真上から眺めたときに鼻が上になるような視点より図が作成されている。

上記のオドボール課題を巧みに使用した刺激提示法が用いられる。図 3.2 に示す P300 スペラーにおける刺激提示の流れを図 3.6 に示す。行・列ごとに文字を 100ms 程度の間だけ白くする刺激提示を行い、被験者は入力すべき文字が白くなった時に数を数えるなどメンタルタスクを行う。この時、ある時間における刺激はランダムに選ばれる。行・列それぞれ光らせる方法で入力すべき 1 文字を特定するにはすべての行・列を光らせた 12 刺激が最低限必要である。この 12 刺激を行うことをシーケンス (sequence)、あるいは反復 (repetition) というが、通常の ERP-based BCI では 15 シーケンスの刺激提示を行う。入力すべき文字を含まない行・列の 10 刺激が高頻度の標準刺激に該当し、入力すべき文字を含む行・列の 2 刺激が標的刺激となる。このように標準刺激と標的刺激の比率は 5:1 となっていることがわかる。また先行研究でこのような刺激を行った際に大きな P300 の振幅が得られている (例えば [69]) ことから実用的に P300 を検出することができるように改良されていることがわかる。

上記のように ERP-based BCI において、刺激を行列表に並べ、行ごと、列ごとに刺激提

示を行う方法を行・列パラダイム (row column paradigm) と呼び [66, 71]。一つの文字ごとに刺激提示する方法を単一文字パラダイム (single character paradigm) と呼ぶ [71]。これらのパラダイムの性能を向上させるためにチェッカーボードパラダイム [66] や、ある命令の集合ごとに刺激し、それを2階層にしたもの [72] など派生したものが提案されている。




図 3.6: ERP-based BCI の刺激提示方法

ERP-based BCI の刺激は灰色の文字を行ごと、列ごとに一瞬白く変化するものである。図の上部のように各行、各列に黄色で示すような番号をつけるとわかりやすい。BCI competition III data set II の仕様 [70] に習い、列刺激を左から右へ 1、2、...、6、行刺激を上から下へ 7、8、...、12 と番号をつける。標的提示期間に上部に標的の文字が表示されるので、被験者は標的の文字を探す。その後 15 シーケンス分の刺激が提示される。刺激の制御は図下の刺激信号で扱って整理しやすい。刺激信号の縦軸、すなわち振幅を刺激番号とする。ただし振幅が 0 の時はどの行も列も刺激されていない状態である。刺激信号の横軸は時間を表す。図中に青色の縦線で現在時刻を示しているが、その時は刺激番号が 9 であるので、対応する 3 行目の文字が白くなっている。その状態が一定時間 (100ms 間) 続き、0 に戻っており、全ての文字が灰色の状態になる (75ms 間)。一般に ERP の解析窓 (約 700ms) は刺激の持続時間 (100ms) より長いので、最後の刺激後の ERP が十分取れるように調整時間を設ける。ERP-based BCI のパターン認識はその後瞬時に行われ、推定した結果を画面上部に表示する。

3.4.2 命令を入力するまでの流れ

被験者がある命令を入力するまでの過程は以下ようになる [73]。ここでは図 3.2 に示す P300 スペラーを例にして説明するので、命令は文字入力となる。

1. 刺激提示器 (図 3.2) の右上に標的文字が提示されるので確認する。
2. 標的文字を画面中央の刺激提示部の文字の中から素早く探し、視線を向ける。ある時間が経過すると刺激提示が始まるので、標的文字が白色に変わったら心の中で数を数えるメンタルタスクを行う。
3. すべての刺激が終わるまで上記の動作を繰り返す。
4. 刺激終了後、右上の文字出力部に文字が出力されるので確認する。

P300 スペラーは典型的に命令が 36 文字であり、1 文字特定するのに 6 行 6 列の 12 刺激が必要になる。刺激シーケンス回数を 15 回とすると、刺激回数は 180 回¹である。そのうち標的文字が白く変化する回数は全刺激回数の 1/6 となるので 30 回である。

3.4.3 ERP-based BCI のデータ構造

ERP-based BCI により得られた脳波データを図 3.7 のように刺激信号を用いて ERP データに書き換える必要がある。まず、ある標的文字を特定する場合のデータ構造を考えよう。

得られる波形の数は刺激提示数と同じである。刺激提示番号の集合を I とする。刺激提示器を図 3.2 のように構成した場合は $I \in \{1, 2, \dots, 12\}$ である。したがって一回のシーケンスでの刺激提示数は $n(I) = 12$ である。ERP-based BCI はより高い識別性能を得るために上記の刺激を 15 回ほど繰り返す。刺激のシーケンス数を N_s とすると、標的 1 文字を特定するための刺激の総提示回数は $N_{\text{stim}} = N_s \times n(I)$ となる。

文字の総数を N_{letter} 、チャンネル数を N_{ch} 、刺激より切り出すサンプル数を N_{sample} とすると一連の脳波データより刺激信号を用いて切り出した ERP データは

$$\mathbf{X}_{i,j,n} \in \mathfrak{R}^{N_{\text{ch}} \times N_{\text{sample}}}, i \in I, j \in \{1, 2, \dots, N_s\}, n \in \{1, 2, \dots, N_{\text{letter}}\} \quad (3.1)$$

となる。それぞれのデータは標的刺激、標準刺激によるものであり、それぞれラベル付けされている。例えば図 3.2 において N が入力すべき文字であったとしよう。この場合、刺激番号 i が 2 番と 9 番になるデータが標的刺激であり、それ以外は標準刺激である。

¹12 刺激 × 15 シーケンス = 180 回

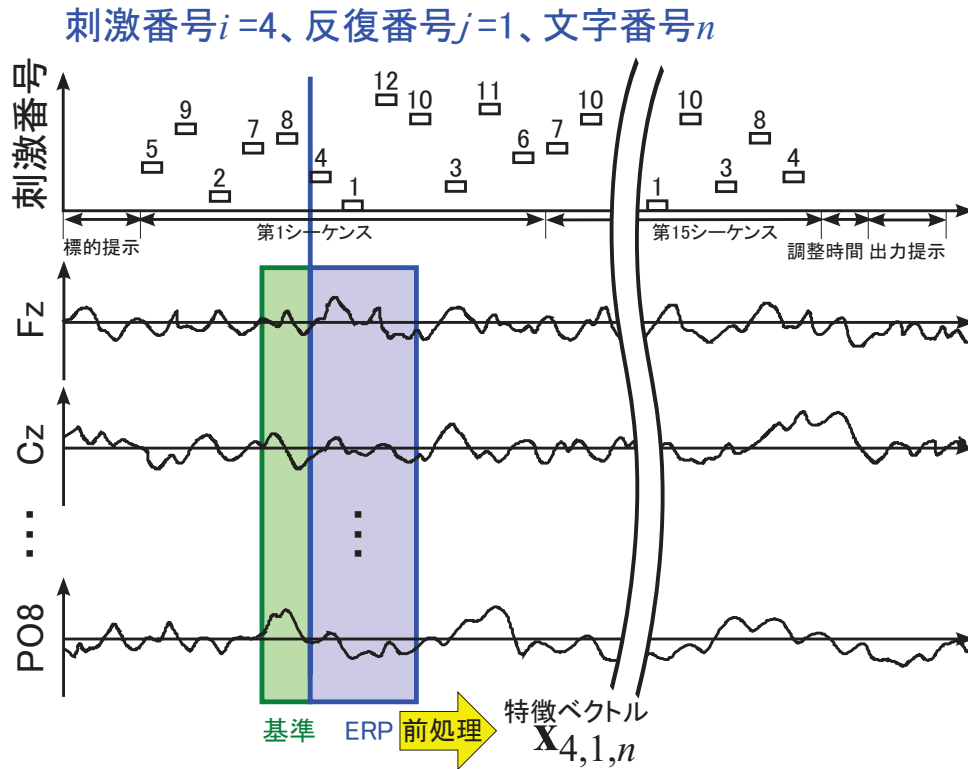


図 3.7: ERP-based BCI のデータの切り取り

刺激提示の際に用いた刺激信号を頼りに ERP データを切り出す。例えば図のように n 番目の標的文字について得られた脳波のうち、第1シーケンスの刺激番号4 (4列目の刺激) に対応する ERP を取り出すには、まずその刺激信号の開始時刻より後 700ms の ERP を取り出す。例えば図中の第1シーケンスに属する刺激番号4番の場合は青色の線で示す時刻で切り出す。またベースラインを差し引くために刺激開始前 100ms の ERP も合わせて取り出しておく。その後、ベースラインの統一や平滑化、ダウンサンプリング、ベクトル化といった前処理を行って、対応する特徴ベクトル $x_{4,1,n}$ を得る。同様にしてすべての刺激に対応する特徴ベクトルを得る。

3.5 信号処理・識別部

信号処理・識別部では取り込んだデジタル信号のノイズを除去し、はっきり見えるようにして識別を行う。

3.5.1 前処理

ERP-based BCIにより計測されたERPは時空間情報を含むが、その特徴が時間領域に顕著に出ることから各空間の時間領域に対して適切な前処理をかける。その点は周波数領域で顕著な特徴が出る事象関連脱同期/同期や定常状態視覚誘発電位とは大きく異なる点である。ERP-based BCIに対する前処理は様々であるが[74, 75]、ERP-based BCIの前処理には

- ベースラインの統一
- 平滑化 (もしくはフィルタリング)
- ダウンサンプリング
- ベクトル化

が用いられる。

時間領域における脳波の電圧は絶えず変動しており、特にERPを500~1,000ms分だけ取り出した時に基準電圧(直流成分)が取り出す時間によって大きく変化することが予想される。そこでベースラインをある事象が起こる前100ms間の脳波電圧データの平均値をERPから差し引く。これによりベースラインを事象の前100ms分のデータの平均値に統一することができる。ベースラインを統一することでほぼ同じ電圧の範囲のERPについて識別することが可能になる。

またERP-based BCIのデータは多チャンネルより計測された高分解能の時系列データであるためそのままでは次元が大きくなりすぎる可能性がある。このことにより実時間処理を行うための計算負荷が増大するなどの欠点が生じる。そのためサンプリング周波数を低く変換するダウンサンプリングを行う。

ダウンサンプリングを行うとデータの時間分解能が低下するため脳波の高周波成分は見えなくなる。しかし、ダウンサンプリングする際に高周波成分に含まれる雑音に影響する可能性がある。そのため各チャンネルの時系列データについて、各データ点の前後で平均値を取る平滑化処理やフィルタリングを行う。これを行うことでダウンサンプリングするときに大きなノイズに影響されにくくしている。

一般にダウンサンプリングするだけでは次元は十分に削減されないため、主成分分析やステップワイズ法による特徴選択を行うことで次元削減する方法を追加で用いることが多い。主成分分析やステップワイズ法による次元削減方法は 4.2.3 で述べる。

以上のように前処理されたデータをパターン認識するために行列で表現される時空間データをベクトルに変換する作業を行う。これをベクトル化という。ベクトル化する方法は簡単で、行列を行または列ごとのベクトルに分解し、それらのベクトルを順につなぎ合わせればよい。ベクトル化は 2 次元画像をパターン認識する際などにも用いられる。

3.5.2 線形判別分析による脳波識別

一般に ERP-based BCI のデータは標準刺激と標的刺激の 2 クラスデータである。そのため 2 クラス識別器が用いられる。ERP-based BCI の識別には線形判別分析 (LDA) やそれを派生した機械学習アルゴリズムが盛んに用いられる。LDA の導出にはフィッシャーの評価基準を最大化する最適化問題を解く方法 [76] や、マハラノビス距離の差を用いて導出する方法 [76, 77] などもあるが、ここでは [78] を参考にし、正規分布を仮定し事後確率を最大にする方法で LDA を導出する。

LDA を用いるためにはまずその識別器を訓練する必要がある。その訓練に用いるデータを訓練データと呼ぶ。一般のパターン認識の問題では学習した LDA を用いて、得られた未知の試験データがどのクラスのデータかを推定する。しかし、ERP-based BCI では刺激と対応した試験データの集合が与えられ、そこからどの刺激のときに被験者がメンタルタスクを行ったかを推定し、意思決定を行う。

ERP データは式 (3.1) のように書けるが、訓練データについては何番目の刺激の何番目のシーケンスといった情報は必要ない。そのため、訓練データの文字数を N_{H} とすると、単に訓練データ数を $N_{\text{train}} = N_{\text{H}} \times N_{\text{stim}}$ として、式 (3.1) の i, j を省略し

$$\mathbf{X}_n^{\text{train}}, n = 1, 2, \dots, N_{\text{train}} \quad (3.2)$$

と表記しても差し支えない。これに前処理を行いベクトル化し、必要に応じて次元削減した N_{train} 個の d 次元訓練データを $\mathbf{x}_n^{\text{train}} \in \mathcal{R}^d$ とし、それぞれにクラスを表すラベル L_n が割り振られているとする。クラスを y で表し、各クラスに N_y 個のデータが含まれているとする。この時、未知のデータ $\mathbf{x}_{i,j,n}^{\text{test}}$ がどのクラスに属するかを考える。ここでは表記が煩雑になるのを避けるため $\mathbf{x}_{i,j,n}^{\text{test}}$ を単に \mathbf{x} と表記することにする。特に 2 クラスの場合は

$$y = \text{sgn}(\mathbf{x}^T \mathbf{w} + b) \quad (3.3)$$

のように未知のデータ \mathbf{x} が属するクラスを推定することができるような \mathbf{w} と b を求める。

パターン認識において、クラスの事後確率を最大にするクラスを選択する MAP 推定と呼ばれる方法がある。あるデータ \mathbf{x} が与えられた時にそのデータが属するクラスが y である確率、すなわちクラス y の条件付き確率 $p(\mathbf{x}|y)$ は推定することができるので、これをベイズの定理を用いてクラスの事後確率を求める。

クラス y の条件付き確率 $p(\mathbf{x}|y)$ はガウスモデルを用いると下記のように推定することができる。

$$\hat{p}(\mathbf{x}|y) = \frac{1}{(2\pi)^{d/2} \det(\hat{\Sigma}_y)^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \hat{\boldsymbol{\mu}}_y)^T \hat{\Sigma}_y^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y)\right) \quad (3.4)$$

ここで、 $\boldsymbol{\mu}_y$, Σ_y はそれぞれクラス y の平均ベクトル、共分散行列である。乗法定理より、

$$p(y|\mathbf{x})p(\mathbf{x}) = p(\mathbf{x}|y)p(y) \quad (3.5)$$

であるため、計算の便宜上、対数を取った対数事後確率は

$$\log p(y|\mathbf{x}) = \log p(\mathbf{x}|y) + \log p(y) - \log p(\mathbf{x}) \quad (3.6)$$

である。ここで確率変数 y の確率関数の推定値 $\hat{p}(y)$ は次のように訓練データを用いて求められる。

$$\hat{p}(y) = \frac{N_y}{N_{\text{train}}} \quad (3.7)$$

各クラス y に属するデータの平均値 $\boldsymbol{\mu}_y$ と共分散行列 Σ_y を以下のように訓練データを用いて推定することができる。

$$\hat{\boldsymbol{\mu}}_y = \frac{1}{N_y} \sum_{n:L_n=y} \mathbf{x}_n^{\text{train}} \quad (3.8)$$

$$\hat{\Sigma}_y = \frac{1}{N_y - 1} \sum_{n:L_n=y} (\mathbf{x}_n^{\text{train}} - \hat{\boldsymbol{\mu}}_y)(\mathbf{x}_n^{\text{train}} - \hat{\boldsymbol{\mu}}_y)^T \quad (3.9)$$

これより次のようにクラス y の対数事後確率を下記のように求めることができる。

$$\begin{aligned} \log \hat{p}(y|\mathbf{x}) &= \log \hat{p}(\mathbf{x}|y) + \log \hat{p}(y) - \log \hat{p}(\mathbf{x}) \\ &= -\frac{d}{2} \log(2\pi) - \frac{1}{2} \log(\det(\hat{\Sigma}_y)) \\ &\quad - \frac{1}{2} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y)^T \hat{\Sigma}_y^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y) \\ &\quad + \log N_y - \log N_{\text{train}} - \log p(\mathbf{x}) \\ &= -\frac{1}{2} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y)^T \hat{\Sigma}_y^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y) - \frac{1}{2} \log(\det(\hat{\Sigma}_y)) \\ &\quad + \log N_y - \frac{d}{2} \log(2\pi) - \log N_{\text{train}} - \log p(\mathbf{x}) \end{aligned} \quad (3.10)$$

クラス y と無関係の定数を

$$C = -\frac{d}{2} \log(2\pi) - \log N_{\text{train}} - \log p(\mathbf{x}) \quad (3.11)$$

と置くと、結局、対数事後確率は

$$\begin{aligned} \log \hat{p}(y|\mathbf{x}) &= -\frac{1}{2} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y)^T \hat{\boldsymbol{\Sigma}}_y^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y) - \frac{1}{2} \log(\det(\hat{\boldsymbol{\Sigma}}_y)) \\ &\quad + \log N_y + C \end{aligned} \quad (3.12)$$

となる。

各クラスの共分散行列が等しいと仮定する。すなわち、全クラスの数 N_{class} とすると

$$\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \dots = \boldsymbol{\Sigma}_{N_{\text{class}}} = \boldsymbol{\Sigma} \quad (3.13)$$

である。このとき、 $\boldsymbol{\Sigma}$ の最尤推定量 $\hat{\boldsymbol{\Sigma}}$ は

$$\hat{\boldsymbol{\Sigma}} = \sum_{y=1}^{N_{\text{class}}} \frac{N_y}{N_{\text{train}}} \hat{\boldsymbol{\Sigma}}_y \quad (3.14)$$

である。これを用いて対数事後確率を書きなおすと

$$\begin{aligned} \log \hat{p}(y|\mathbf{x}) &= -\frac{1}{2} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y)^T \hat{\boldsymbol{\Sigma}}^{-1} (\mathbf{x} - \hat{\boldsymbol{\mu}}_y) - \frac{1}{2} \log(\det(\hat{\boldsymbol{\Sigma}})) \\ &\quad + \log N_y + C \\ &= -\frac{1}{2} \left\{ \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \mathbf{x} - 2\mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y + \hat{\boldsymbol{\mu}}_y^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y \right\} \\ &\quad - \frac{1}{2} \log(\det(\hat{\boldsymbol{\Sigma}})) + \log N_y + C \\ &= \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y - \frac{1}{2} \hat{\boldsymbol{\mu}}_y^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y + \log N_y \\ &\quad - \frac{1}{2} \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \mathbf{x} - \frac{1}{2} \log(\det(\hat{\boldsymbol{\Sigma}})) + C \end{aligned} \quad (3.15)$$

となる。再びクラス y と無関係の項を

$$C' = -\frac{1}{2} \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \mathbf{x} - \frac{1}{2} \log(\det(\hat{\boldsymbol{\Sigma}})) + C \quad (3.16)$$

と置くと、対数事後確率は

$$\log \hat{p}(y|\mathbf{x}) = \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y - \frac{1}{2} \hat{\boldsymbol{\mu}}_y^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y + \log N_y + C' \quad (3.17)$$

となる。

判別関数は対数事後確率の定数項 C' を除いたもの、すなわち

$$F_{\text{LDA}}(\mathbf{x}, y) = \mathbf{x}^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y - \frac{1}{2} \hat{\boldsymbol{\mu}}_y^T \hat{\boldsymbol{\Sigma}}^{-1} \hat{\boldsymbol{\mu}}_y + \log N_y \quad (3.18)$$

である。従って得られた未知のデータに対し、 $F_{\text{LDA}}(\mathbf{x}, y)$ を最大にするクラスを推定したクラス \hat{y} とするなどして識別することができる。特に 2 クラスの場合 ($N_{\text{class}} = 2$)、判別境界は $F_{\text{LDA}}(\mathbf{x}, y = 1)$ と $F_{\text{LDA}}(\mathbf{x}, y = 2)$ の差を 0 にするものであるから

$$\begin{aligned} & F_{\text{LDA}}(\mathbf{x}, y = 2) - F_{\text{LDA}}(\mathbf{x}, y = 1) \\ &= \mathbf{x}^T \hat{\Sigma}^{-1} (\hat{\mu}_2 - \hat{\mu}_1) - \frac{1}{2} (\hat{\mu}_2^T \hat{\Sigma}^{-1} \hat{\mu}_2 - \hat{\mu}_1^T \hat{\Sigma}^{-1} \hat{\mu}_1) + \log \frac{N_2}{N_1} \\ &= 0 \end{aligned} \quad (3.19)$$

となる。ここで

$$\mathbf{w} = \hat{\Sigma}^{-1} (\hat{\mu}_2 - \hat{\mu}_1) \quad (3.20)$$

$$b = -\frac{1}{2} (\hat{\mu}_2^T \hat{\Sigma}^{-1} \hat{\mu}_2 - \hat{\mu}_1^T \hat{\Sigma}^{-1} \hat{\mu}_1) + \log \frac{N_2}{N_1} \quad (3.21)$$

と置くと、判別境界は

$$\mathbf{x}^T \mathbf{w} + b = 0 \quad (3.22)$$

と書くことができる。このように各クラスのデータ分布がガウス分布に従い、各クラスの共分散行列が等しいと仮定して判別境界を求める方法を線形判別分析 (LDA) という。

3.5.3 意思決定

ERP-based BCI の多くは被験者がどの文字を入力したかを特定するために LDA の重み \mathbf{w} と試験データとの内積を足しあわせたスコアを計算し、それが最大になるものに決定する [73]。通常の 2 クラス識別問題では式 (3.3) を用いるだけで十分であるが、ERP-based BCI は 2 クラス識別器を巧みに使って 36 クラス以上の多クラス識別問題を解いている。

n 番目の標的文字に対応する試験データは $n(I)$ 種類の刺激を N_s シーケンスだけ反復して得られたもので、それに前処理を施してベクトル化したものを

$$\mathbf{x}_{i,j,n}^{\text{test}}, i \in I, j \in \{1, 2, \dots, N_s\} \quad (3.23)$$

とする。これについて LDA の重み \mathbf{w} と $\mathbf{x}_{i,j,n}^{\text{test}}$ との内積をすべてのシーケンスについて計算し、足しあわせたものをスコアと呼ぶ。 n 番目の標的文字の i 番目の刺激のスコアは

$$s_{i,n} = \sum_{j=1}^{N_s} \mathbf{w} \cdot \mathbf{x}_{i,j,n}^{\text{test}} \quad (3.24)$$

と計算できる。

ERP-based BCI には行ごと列ごとに文字を光らせる行・列パラダイム (row/column paradigm) と、ひとつずつ文字を光らせる単一文字パラダイム (single character paradigm) と、

が用いられる [71]。行・列パラダイムの場合は 6 行 6 列の文字を持つ P300 スペラーのために 12 種類の刺激を用いるのに対し、単一文字パラダイムでは 36 種類の刺激を用いる。そのため行・列パラダイムのほうが刺激回数自体は少なく済む。単一文字パラダイムは実装が簡単であり、刺激が行列表になっていない場合や命令数が少ない場合によく用いられる [79]。それら二者のパラダイムは別々の意思決定方法を用いる。

行・列パラダイムの場合は意思決定を行うために、行、列それぞれスコアが最大になる刺激番号 i を求める。列の集合を $C = \{1, 2, \dots, 6\}$ 、行の集合を $R = \{7, 8, \dots, 12\}$ とすると、 n 番目の文字に対応する試験データについての意思決定則は

$$\mathbf{d}_n = \arg \max_{c \in C, r \in R} (s_{c,n}, s_{r,n}) \quad (3.25)$$

となる。 \mathbf{d}_n は n 番目の文字について推定した行、列の刺激番号を表すベクトルである。例えば $\mathbf{d} = (2, 9)$ は文字「N」と読み替えられる。単一文字パラダイムの場合は更に単純で、刺激集合 I の中から単に最大になる刺激番号を 1 つ選び出せば良いので、 n 番目の文字に対応する試験データより推定した結果は

$$d_n = \arg \max_{i \in I} (s_{i,n}) \quad (3.26)$$

と書くことができる。

3.6 出力部

出力部で意思決定の結果に応じて装置制御命令を出力する。例えば典型的な 6×6 行列状に文字が並ぶ P300 スペラーの場合、 $\mathbf{d}_n = (2, 9)$ となると前述のとおり「N」が選ばれるが、これを画面右上の出力部に表示するなどすることができる。インタフェースを変更すれば現在文字を入力するソフト上のカーソル位置に文字を入力することもできる。また、入力された文字から入力したい単語を予測し、より短い入力で効率よく文字入力することもできる。文字入力のみならず、ロボットアームや電動車椅子の制御命令などを割り当てることもできるため、単に文字入力の部分を別の命令に置き換えるだけでも装置の制御は可能になる。

出力を被験者に返すことをフィードバックするという。出力を被験者に見せることで何らかの影響がある。フィードバックには単純に文字を出力して正解か不正解かを知らせることによっても動機づけされることが知られている [80]。ERP-based BCI においても被験者に単純に推定された文字を伝えることでそれによって動機づけされると予想する。また、動機付けとして金銭的なものを用いた場合などの影響についても調べられている [81]。

3.7 まとめ

本章では ERP-based BCI の詳細な動作メカニズムについて説明した。装置の構成、刺激提示、線形判別分析器の構成方法と意思決定方法、命令の出力について述べた。次章では ERP-based BCI のための識別器として注目されている集合識別器について取り上げ、その問題点と、解決策や、その実験的評価について述べる。

第4章 オーバーラップト・パーティショニングを用いた ERP-based BCI の集合識別器

本章では ERP-based BCI のための集合識別器を訓練する際に用いる訓練データ分割法 (パーティショニング) について述べる。本研究では訓練データを重複して分割する手法であるオーバーラップト・パーティショニング (overlapped partitioning) を提案し、それを用いた集合識別器が ERP-based BCI のパターン認識を行う際の性能評価を行った。本章で述べる内容は修正点を除き [56] と同一のものである。

4.1 ERP-based BCI に用いられる識別器と集合識別器の動向

ERP-based BCI は前述したように計測した ERP を LDA などの識別器を用いて意思決定することで動作する BCI であるが、単なる LDA より性能の高い識別器を用いることが多い。ERP-based BCI には主にステップワイズ法により次元削減を行った LDA であるステップワイズ LDA (SWLDA) が盛んに用いられている。SWLDA は Farwell らによって初めて ERP-based BCI に使用された [47]。また、Schalk らにより BCI2000 という BCI のプラットフォームが開発され [82]、その中でも SWLDA が使用された。BCI2000 には感覚運動リズム (sensorimotor rhythm) を用いたカーソル制御や文字入力、緩変動電位 (slow cortical potential; SCP) を用いたカーソル制御、ERP-based BCI による文字入力などの応用が実装されており、多くの研究者が簡単に BCI に関する研究が始められるようになった。その中の ERP-based BCI 向けに SWLDA が開発されており、そのプラットフォームを用いた ERP-based BCI に関する研究では SWLDA が盛んに用いられている (例えば [83])。Krusienski らは ERP-based BCI 向けの識別器の比較を行った [64]。その比較にはピアソンの相関法 (Pearson's correlation method)、LDA、SWLDA、線形サポートベクトルマシン (support vector machine; SVM)、ガウシアンカーネル SVM が用いられた。その結果、LDA と SWLDA が他のアルゴリズムより高い識別性能を示した。以上のように SWLDA

は幅広く用いられ、ERP-based BCI において高い識別精度を示すことが知られている。

近年、ERP-based BCI のために様々な識別器が応用または提案されている。ERP-based BCI のデータは2クラスの高次元データであることと、意思決定則が特殊であるため単純に応用できない場合があることを考慮すると、どのような識別器が ERP-based BCI に対して有効であるかを議論するのは容易ではない。そのため、ERP-based BCI に機械学習の分野で提案された様々な手法を応用する研究や、その BCI に最適な新しい識別器や特徴抽出に関する研究などが行われてきた。Blankertz らは正則化した LDA (regularized LDA) を提案した [84]。Hoffmann らはベイズ理論を応用することで、訓練データが高次元でかつ少量しか与えられていない場合に生じる問題に対処した Bayesian LDA (BLDA) を提案した [85, 74]。また、遺伝的アルゴリズムや、時間遅れニューラルネットワークなど既存のアルゴリズムを ERP-based BCI に応用することなどが試みられた [86]。Lotte らは主成分分析 (principal component analysis; PCA) や正準相関分析 (canonical correlation analysis; CCA) により前処理を行った LDA や、それらを正則化したものを提案した [87]。Onishi らはテンソル分解を前処理に用いた識別方法を提案した [88]。

前述のような識別器の他に、複数の識別器の結果を統合して意思決定を行う集合識別器が提案された。Rakotomamonjy らは SVM を用いた集合識別器 (ensemble of SVMs) を提案した [4]。Ensemble of SVMs は複数の異なる SVM を用意し、各 SVM が出した結果を統合して最終的な意思決定を行うものである。そのため信号のばらつき具合による影響が緩和されるため、ERP を取り扱う BCI のための有効な識別器として期待できる。共通の BCI データをオフライン解析し、その識別精度を競う BCI competition が開かれたが、Ensemble of SVMs は 2004 年 12 月から 2005 年 5 月に開催された BCI competition III data set II (ERP-based BCI) で最も優秀な性能を示した。従って Ensemble of SVMs は ERP-based BCI のための強力な識別器の一つと考えられる。それ以降、ブースティングを用いた集合識別器 [89] や、LDA の集合識別器 [90]、SWLDA の集合識別器 [91] などが提案されている。このように集合識別器を BCI に応用する取り組みが行われてきた。

しかしながら、Rakotomamonjy らが提案する Ensemble of SVMs を始めとする集合識別器が ERP-based BCI に効果的であることを示すには二つのことについて検証する必要がある。一つは訓練データが少ない場合に動作するかどうかである。先行研究では訓練データが膨大にある場合でしか評価されていない。BCI competition III data set II の訓練データには ERP が 85 文字分含まれている。その訓練データを計測するには約 52 分¹かかる。

¹コンペティションの条件では刺激が提示される時間が 100ms、次の刺激までの間隔が 75ms であり、6 行 6 列の 12 刺激を行ごと列ごとに光らせる行・列パラダイムを使用している。1 文字分の ERP を得るための刺激のシーケンス回数は 15 回である。標的文字提示時間および推定文字出力時間は 2.5s である。また、最後の刺激提

85 文字分の訓練データがある場合でしか高い性能を示さないのであれば、訓練データを計測する時間が長過ぎるため実用的ではない。そのため訓練データを少なくした場合の集合識別器の性能を検証する必要がある。

ERP-based BCI の訓練データはどの程度の数が必要であろうか。オフライン解析では過去に行われたコンペティションのデータを用いて比較的多くの訓練データが用いられることが多い。例えば Salvaris らは LDA の集合識別器と SVM の集合識別器の性能を BCI competition III data set II と BCI competition II data set IIb (7,560 波形) を用いて評価した [92]。また、彼らは 6 つの線形 SVM より構成される集合識別器を用いた BCI データを 16-fold 交差確認法により評価した [93]。Johnson らは独自にデータを計測し、6,480 波形の訓練データを用いて SWLDA の集合識別器を評価した [91]。Arjona らは 3,024 波形の訓練データを用いて LDA の集合識別器を評価している [90]。オンライン解析では訓練時間を短縮し、より実践的に評価される傾向にある。Townsend らは行・列パラダイムの実験に 3,230 波形の訓練データを用い、チェッカーボードパラダイムの実験には 4,560 波形の訓練データを使用した [66]。Guger らは電極の性能を評価するために 1,125 波形を用いて LDA を学習した [94]。これらの傾向を見ると多くの ERP-based BCI の訓練データは 3,000 波形程度あれば十分である。BCI competition III data set II に含まれている訓練データは極端に数が多く、それにより評価された BCI では訓練データが少ない場合での検証が不十分になる可能性がある。そのため、より訓練時間を少なくして 1,000 波形以下で評価するのが望ましい。本研究では 5 文字分の訓練データ (900 波形) を用いて学習するが、BCI competition III data set II と同じ計測条件の場合、計測時間は約 3 分 (185.125s) で計測することができるうえ、他の一般的に ERP-based BCI で使われる訓練データ数より少ない。そのため、本研究では 900 波形の訓練データを与えたときに実用的な識別精度を示すことを明らかにする。

集合識別器のもうひとつの検証すべき点はそれをどのように少ない訓練データに適応するかである。先行研究では与えられている訓練データを与えられている順に当分割する手法であるナイーブ・パーティショニング (naive partitioning) を適用し、分割した訓練データ (パーティション) を用いて異なる SVM を複数用意している。しかし、ナイーブ・パーティショニングが BCI competition III data set II に特化されて定義されており、データが

示後すぐに結果を出すことはできず、最後の刺激が開始してから識別に必要な ERP の長さ分だけ計測し、その後の推定文字出力のための計算にかかる時間を追加しなければならない。ERP の長さ、つまり ERP のバッファ長を 700ms、計算時間は極めて短い (0s) とすると、1 文字分の刺激を行う時間は 1 文字入力するまでの時間=標的
文字提示時間+(刺激オン時間+刺激オフ時間) \times (刺激数 \times シーケンス数-1) +ERP バッファ長+計算時間+推定文字
出力時間=2,500+(100+75) \times (12 \times 15-1)+700+0+2,500=37,025ms である。訓練データが 85 文字あるので、休憩な
しで 85 文字分の ERP(15,300 波形) を計測すると約 52 分かかることになる。

多く与えられている場合、少なく与えられている場合にどのように応用すればいいのか不明である。彼らの使い方によるとナイーブ・パーティショニングは訓練データを重複させずに順に5文字分とっていき、85文字のデータを17個のパーティションに分割する方法であると解釈できる。しかし実際にオンラインシステムに集合識別器を実装する際には訓練データが少なくなるため、上記の方法に従うと各パーティションに含まれる訓練データがさらに少なくなり、性能が低下することが考えられる。実際、JohnsonらはSWLDAを用いた集合識別器を上記の方法を用いて学習したが、パーティションの数を増やすと訓練データが小さくなることからパフォーマンスが低下したと考察している[91]。しかしながら、集合識別器の学習をするためのパーティショニング手法では訓練データが小さい時にどのように応用すればいいのか、また、訓練データを重複して使用した場合に何か問題があるのかが不明である。この点を明確にしてパーティショニング手法を定義することでより集合識別器の有効性を示すことができると考える。

以上を踏まえ、本研究では訓練データ分割法をより一般化して定義したオーバーラップト・パーティショニング (overlapped partitioning) を提案し、約3分で計測できる900波形の訓練データを用いて線形判別分析器を用いた集合識別器を評価した。特に異なる次元削減法を用いた場合、パーティションに使用するデータの重複具合がどのように影響を与えるのかを調べた。

4.2 実験方法

本研究ではオーバーラップト・パーティショニングを用いて集合識別器を学習し、単一の識別器を用いた場合とナイーブ・パーティショニングを用いた集合識別器と識別精度を比較した。また、次元削減法を用いなかった場合と次元削減法であるステップワイズ法、主成分分析を用いた場合の識別精度の変化を調べた。実験の流れは図4.1に示すとおりである。集合識別器を評価するために、独自に測定したERP-based BCIのデータセット(データセットA)及びBCI competition III data set II(データセットB)を用いた。データセットA、Bそれぞれ訓練データが900波形の場合、8,100波形以上の場合で識別精度を求め、実際に900波形だけで十分訓練することができるか検討した。

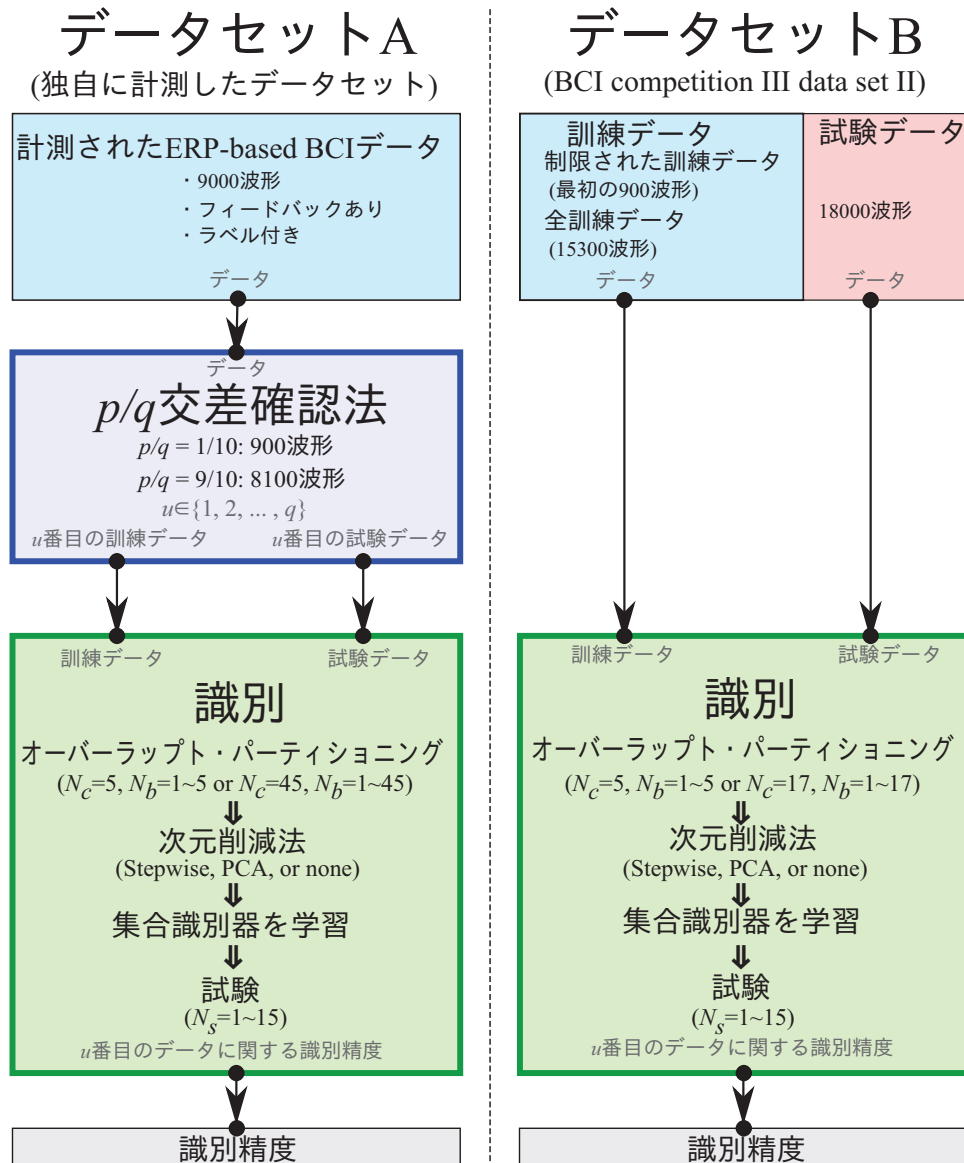


図 4.1: 実験の流れ

図は本実験全体の流れを示したものである。本研究では2種類のERP-based BCIデータを解析した。独自に計測したERP-based BCIのデータをデータセットAと呼び、またBCI competition III data set IIをデータセットBと呼ぶ。データセットAは訓練データと試験データに分かれていないので p/q 交差確認法を用いた。データセットBでは与えられた訓練データを用いて識別器を訓練し、識別精度を求めた。 p/q 交差確認法の詳細は図4.2、識別方法の詳細は図4.3を参照していただきたい。図は[56]を一部改変したものである。

4.2.1 データセット A: 独自の ERP-based BCI データセット

被験者

本実験には健常な男性 10 名、女性 1 名の 11 人が参加した。参加者の年齢の範囲は 22 歳から 28 歳である。そのうち 1 名は体調不良により実験データを完全に計測できなかったため、解析データから除外した。どの参加者も過去に ERP-based BCI を制御した経験がない。参加者は実験の概要、行うメンタルタスク、実験に要する時間、実験により被ると考えられるリスクを十分説明した後に、被験者に実験参加の同意書に署名していただき、インフォームド・コンセントを得たうえで実験を行った。本実験は九州工業大学の倫理委員会の承諾を得て実験を行った。

脳波計測

脳波は脳波計測用ボックス BA1008 (TEAC Co. Ltd., Japan) により記録された。脳波計測には皿電極を用い、国際 10-20 法に従い Fz、Cz、P3、Pz、P4、PO7、Oz、PO8 より計測した (図 3.3)。ただし接地電極を AFz とし、参照電極を両耳の裏にある乳様突起に取り付け、結線したものをを用いた。この際、ハードウェアによりバンドパスフィルタがかけられ、0.11-30 Hz の信号を記録した。脳波の増幅率は 25,000 倍である。計測された信号は AIO-163202FX-USB analog I/O unit (CONTEC Co. Ltd., Japan) によりデジタル信号に変換された。その際のサンプリングレートは 128 Hz であった。取り込まれたデジタル信号はコンピュータ上で MATLAB/Simulink (Mathworks Inc., USA) を用いて処理された。

刺激提示とメンタルタスク

ERP-based BCI の刺激は TFT LCD ディスプレイ (HTBTF-24W、24.6 インチ、1,920 × 1,080 dpi; Princeton Technology Ltd., Japan) に提示された。なお、ディスプレイは被験者の約 60cm 前に設置した。本研究における刺激提示器は、図 3.2 に示す盛んに研究されている古典的な ERP-based BCI に用いられるものをを用いた。右上に標的文字を表示する標的文字表示部、及び脳波から推定した文字を出力する文字出力部からなる。ディスプレイには灰色の 36 文字が 6 × 6 行列状に並べられており、刺激が開始すると 1 つの行または列が一斉に白色に変化する。

標的文字の提示時間は 3s である。文字が白色になっている状態が 100ms 間持続され、その後どの文字も白色になっていない状態が 75ms 間持続される。シーケンス回数は 15 回と

し、オフライン解析で1回から15回まで変化させて文字の識別精度を計算した。結果の出力時間は1sである。そのため、1文字入力するためには36.025sかかる²。

本研究ではERP-based BCIのデータをオフライン解析で使用するためにデータ収集を行った。一つのセッションを15シーケンスの条件で5文字分収集するものとし、被験者に出力結果をフィードバックしながら10セッション分(50文字分)のデータを収集した。データ収集時には被験者を動機づけさせるため、被験者が刺激に慣れるため、また実験者が正しく識別できるデータが取れていることを確認するために訓練セッションを事前に1回行い、そのデータを含めてフィードバックありの脳波データを10セッション分計測した。オフライン解析ではその10セッション分のデータを使用した。識別器は線形判別分析を用い、各セッション開始前まで訓練セッションを含む事前のデータをすべて使って学習しながら実験を進めた。

前処理

オンラインでのデータ計測及びオフライン解析で脳波に下記の前処理を施した。まず各刺激提示の開始時刻から700ms後までのERP(8チャンネル×89サンプル)を取り出し、対応する刺激提示時刻より100ms前までの脳波の平均値をベースラインとして差し引いた。そのようにして取り出したERPを窓長3サンプルの移動平均により平滑化し、43Hzにダウンサンプリングし(8チャンネル×30サンプル)、各チャンネルのデータをひとつのベクトルに結合するベクトル化を行った(240次元ベクトル)。

p/q 交差確認法

本研究では少ない訓練データでどの程度の識別精度が得られるかを明らかにしたい。しかし、BCI competition III data set IIに習って訓練データ85文字分と試験データ100文字分を計測すると被験者に膨大な負担がかかってしまう。そこで、本研究では被験者の負担を減らすために訓練データ、試験データを分けずに50文字分だけデータ収集し、交差確認法を派生した方法である p/q 交差確認法によりオフライン解析することを試みた。提案手法を用いることで訓練データを任意に減らすことができるため実際的な評価を十分な数の試験データについて行うことができる。

p/q 交差確認法の手順は下記のようになる。また、本研究で使用した1/10交差確認法の手順を図4.2に示す。

²標的提示3,000ms+(刺激オン100ms+刺激オフ75ms)×(12刺激×15シーケンス-1)+バッファ長700ms+出力1,000ms=36,025msである。

1. 与えられたデータを計測した順に並べ、 q 等分し q 個のグループを作る。この時、ある文字に対応する脳波セットが分割されて複数のグループに属してしまうと試験データとなったときに文字を推定できなくなる。そのためある文字に対応する脳波は必ず1つのグループにのみ属するようにする。
2. 分割された q 個のグループは循環しているとする。この時、連続する $p + 1$ 個のグループを取り出す。合計 q ペアだけ取り出すことができる。
3. 各ペアの最初の p グループを訓練データとし、残りの 1 グループを試験データとして識別を行う。これを q 個すべてのペアに対して行い、最終的に正しく推定できた文字数を全文字数で割り、識別精度を求める。

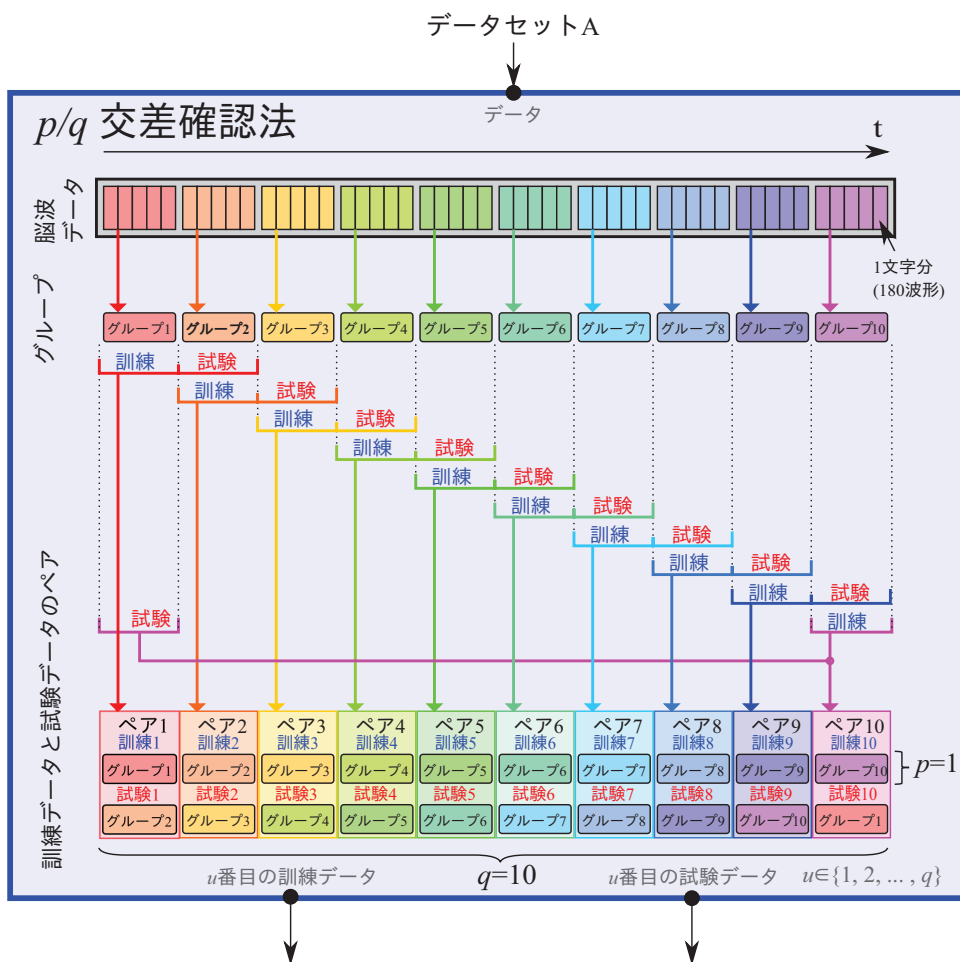


図 4.2: p/q 交差確認法

通常の q -fold 交差確認法の訓練データに使うデータを削減して評価する方法である。図は $p = 1$ かつ $q = 10$ の場合を示している。図は [56] を一部改変したものである。

4.2.2 データセット B: BCI competition III data set II

データ構造

BCI competition III data set II は 2005 年に開かれた BCI competition III で ERP-based BCI のための識別器の性能を競争するために用いられたデータセットである [70]。BCI competition III data set II には被験者 A、B のデータが含まれている。それぞれの被験者に対し訓練データと試験データが与えられている。訓練データには対応するクラスラベルが与えられており、訓練データと対応するクラスラベルを用いて教師あり識別器を学習することができる。試験データのクラスラベルは与えられておらず、これを訓練データとそのクラスラベルを用いて推定しなければならない。なお、このコンペティションは終了しているため、試験データのクラスラベルも同様に入手可能である。試験データの出力を推定し、正解のクラスラベルとどの程度合致しているかを調べることで識別精度を計算した。

訓練データは 85 標的文字分、試験データは 100 標的文字分だけ用意されている。刺激提示器には 36 文字の命令が用意されており、6×6 行列状に配置されている。刺激は行ごと、列ごとに点滅させるものであり、すべての行、列を刺激するのに 12 回の刺激が必要である。その 12 回の刺激を全て提示するのがシーケンス (反復) である。データ計測時のシーケンス数は 15 回である。そのため、訓練データに含まれる ERP は 15,300 波形 (12 刺激×15 シーケンス×85 文字) であり、試験データに含まれる ERP は 18,000 波形 (12 刺激×15 シーケンス×100 文字) である。脳波データは 64 チャンネルよりサンプリングレート 240Hz で計測されている。また、バンドパスフィルタ (0.1–60Hz) がかけられている。刺激に関しては刺激点灯が 100ms、刺激消灯時間が 75ms、標的文字提示時間が 2.5s、出力文字提示時間が 2.5s である。そのため、1 文字入力するためには 37.025s かかる³。

本研究では BCI competition III data set II を単にデータセット B と呼ぶことにする。

前処理

データセット B には下記の前処理を施した。まず各刺激提示時刻から 700ms 後までの ERP (64 チャンネル×168 サンプル点) を取り出し、対応する刺激提示時刻より 100ms 前までの脳波の平均値をベースラインとして差し引いた。その後 ERP を窓長 18 サンプルの移動平均により平滑化し、20Hz にダウンサンプリングし (64 チャンネル×14 サンプル点)、

³標的提示 2,500ms+(刺激オン 100ms+刺激オフ 75ms)×(12 刺激×15 シーケンス-1)+バッファ長 700ms+出力 2,500ms=37,025ms となる。

各チャンネルのデータをひとつのベクトルに結合するベクトル化を行った (896 次元ベクトル)。

4.2.3 集合識別器の学習

集合識別器の構成

集合識別器は図 4.3 のように複数の識別器から成り、それらの出力を総合的に用いて出力を決める識別器である。集合識別器に含まれる個々の識別器を弱学習器 (weak learner) と呼ぶ⁴。それらの個々の弱学習器を学習させる方法は数多く存在するが、Rakotomamonjy らは訓練データを一定の手続きにより分割し、各分割されたデータを用いて異なる複数の識別器を学習した。本研究でもそれに習い訓練データを分割し、それらを用いて識別器を学習する方法を試みた。

オーバーラップト・パーティショニング

集合識別器が持つ識別器の数を N_c 個とすると訓練データも N_c 個に分割する必要がある。Rakotomamonjy らは与えられたデータを重複なしでデータを与えられた順に分割する方法であるナイーブ・パーティショニングを用いた。データセット B の訓練データは 15,300 波形もあるためこの方法で良いが、近年の BCI は訓練データを 1,000 波形程度まで減らすものなどが報告されており、この手法を用いて少ない訓練データでも十分学習できるか不明である。そこで本研究では同じデータを再利用して使用することで一つのパーティションに多くの訓練データを含ませることができるオーバーラップト・パーティショニング (overlapped partitioning) を提案する。

オーバーラップト・パーティショニングは下記のように実行される。まず訓練時の ERP データを計測された順に並べ、 N_c 個のブロックに分割する。その分割したブロックが循環するように並べられていると見なして、 v 番目のブロック ($v \in \{1, 2, \dots, N_c\}$) より連続して N_b 個のブロックを取り出し、ひとつのパーティションに入れる。これをすべての v に対して N_c 個すべてのブロックに対して行うことで N_c 個のパーティションが用意できる。

図 4.4 にオーバーラップト・パーティショニングの例を示す。ERP-based BCI の訓練用データが 50 文字分あり、それを用いて識別器を 5 つ持つ集合識別器をオーバーラップト・パーティショニングで訓練することを考える ($N_c = 5$)。まず、50 文字分の ERP が計測された順に 5 つのブロックに分割される。したがってひとつのブロックには 10 文字分の ERP

⁴弱学習器のことを文献によっては仮説 (hypothesis) と呼ぶこともある (例えば [95])。

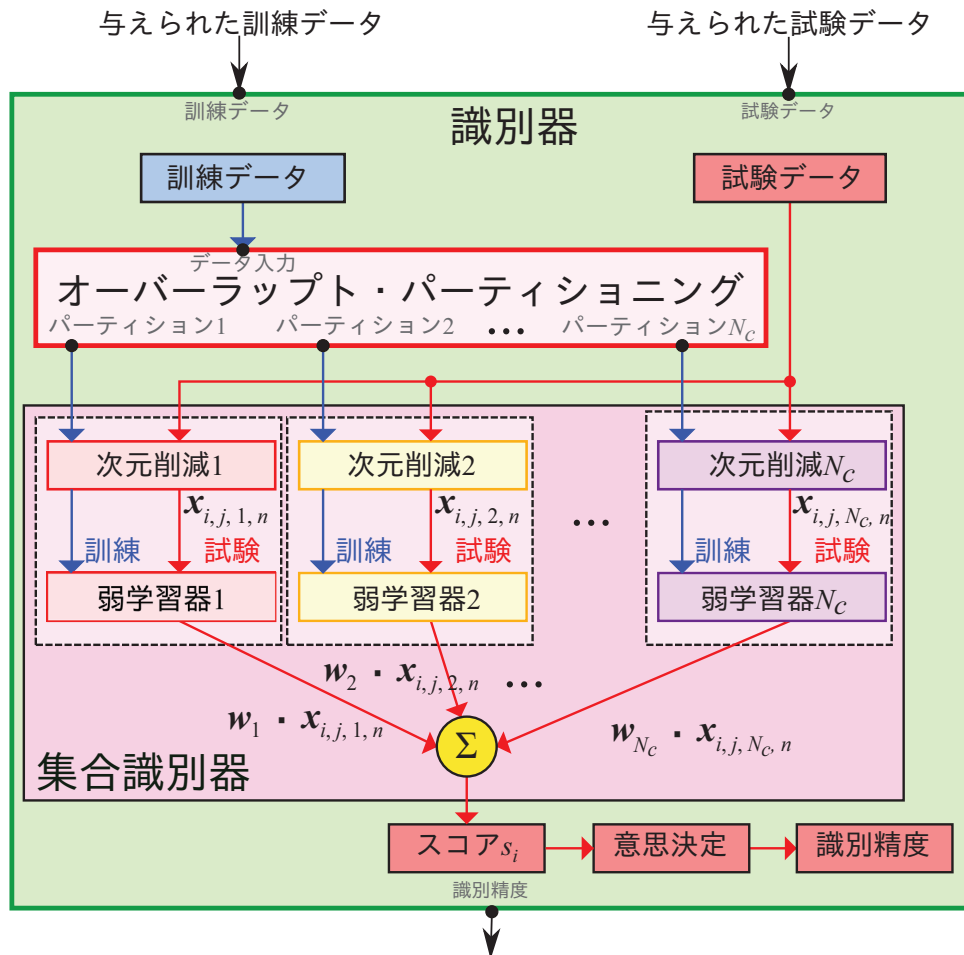


図 4.3: 集合識別器の構成

提案する集合識別器は図のようにオーバーラップト・パーティショニングにより訓練データをリサンプリングし、複数の識別器 (弱学習器) を学習することで構成される。試験時にはそれら複数の識別器が出す結果を統合して一つの出力を出す。図は [56] を一部改変したものである。

データ⁵が含まれることになる。ここで識別器を3ブロック分のデータで訓練する場合を考える ($N_b = 3$)。1番目のブロック ($v = 1$) を選択して、そこから3ブロックを順に取るのでパーティション1にはブロック1、2、3が使用される。同様にパーティション2にはブロック2、3、4、パーティション3にはブロック3、4、5を取る。パーティション4に関してはブロック4、5をとり、ブロックが循環しているとみなし、ブロック1を取る。同様にパーティション5はブロック5、1、2を使用する。このようにして作成したパーティション1~5のデータにそれぞれ次元削減を行い、識別器を学習した。

ERP-based BCI の ERP データはある標的文字に対応する ERP データ集合として扱うため、訓練に使用した標的文字数を割り切れるような識別器の数にするのが望ましい。ただし、ERP-based BCI のデータは標的刺激、標準刺激のいずれかにラベル付されていれば他の標的文字の脳波を用いても問題ないため、標的文字数で割り切れない場合は標的データと標準データの数が偏らないよう波形単位で N_c 個のブロックに分割してもよい。

⁵10 文字 × 180 波形 = 1,800 波形分である。

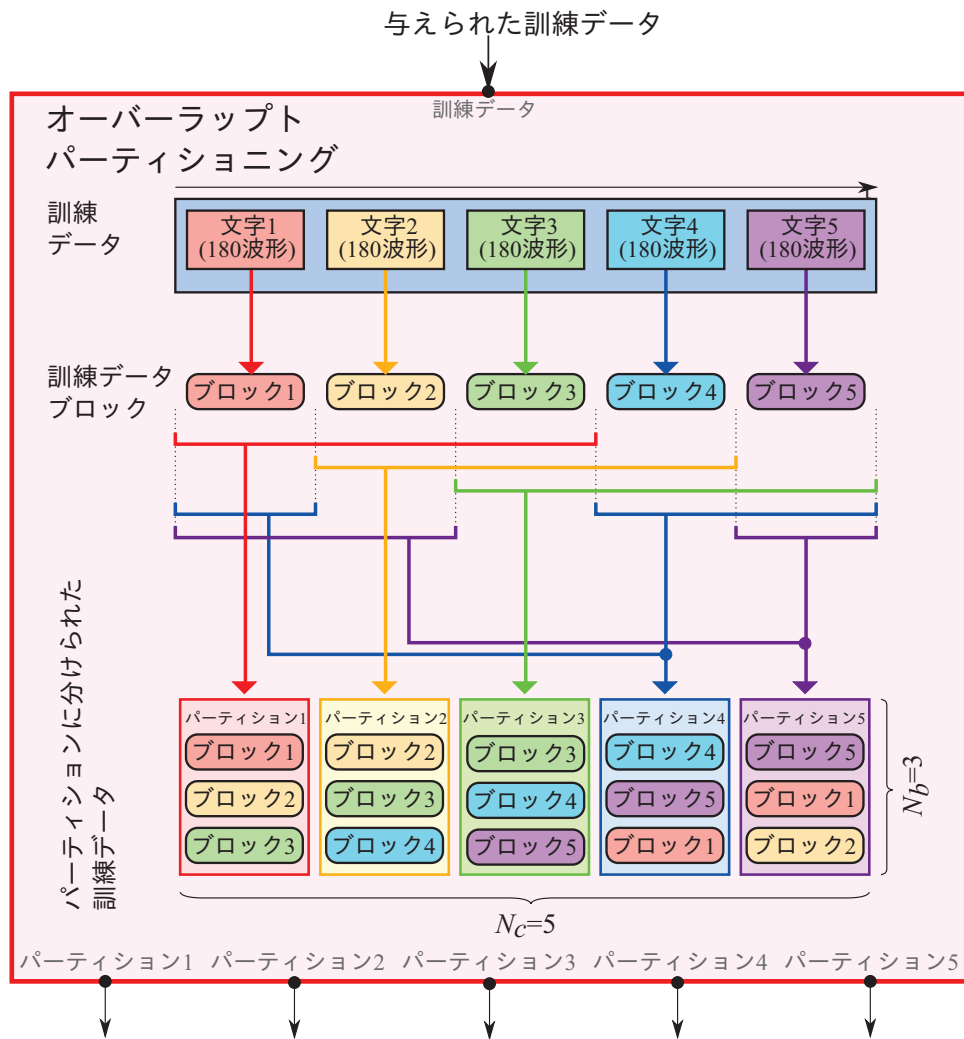


図 4.4: オーバーラップ・パーティショニングの具体例

オーバーラップ・パーティショニングは与えられた訓練データを図のように文字単位で区切りブロックに分割し、それらのブロックを連続して選択することによりパーティションを作成する方法である。図は [56] を一部改変したものである。

集合識別器の意思決定

k 番目のパーティションに属するデータに次元削減を施し、そのデータにより学習したデータにより学習した線形判別器の識別器を \mathbf{w}_k とする。通常の ERP-based BCI の意思決定では識別器はひとつしかなく、式 (3.24) を用いて意思決定を行った。集合識別器の場合は複数の識別器の結果を統合的に用いるので、 n 番目の文字の意思決定のためのスコアは

$$s_{i,n} = \sum_{j=1}^{N_s} \sum_{k=1}^{N_c} \mathbf{w}_k \cdot \mathbf{x}_{i,j,k,n}^{\text{test}}, i \in I \quad (4.1)$$

となる。このスコアを用いて式 (3.25) より意思決定を行う。

オーバーラップト・パーティショニングと他の手法との関係

オーバーラップト・パーティショニングを用いた集合識別器は特殊な条件になるとナイーブ・パーティショニングを用いた集合識別器、もしくは単一の識別器と等価になる。

オーバーラップト・パーティショニングにおいて重複度合いに相当するパラメータ N_b を 1 とし、識別器の数 N_c を 1 以上にすれば重複のないパーティショニングで集合識別器が学習されるため、ナイーブ・パーティショニングを用いた集合識別器と等価になることは自明である。

$N_b = N_c$ の場合は、各パーティションにすべての訓練データが属するため、すべての識別器の結果は等しくなるので単一の識別器と等価になる。意思決定則 (式 (3.25)) を見ると、スコアに任意の定数 $K > 0$ をかけても変わらないことがわかる。

$$\mathbf{d}_n = \arg \max_{c \in C, r \in R} (s_{c,n}, s_{r,n}) \quad (4.2)$$

$$= \arg \max_{c \in C, r \in R} (Ks_{c,n}, Ks_{r,n}) \quad (4.3)$$

また、 $N_b = N_c$ の場合、各パーティションのデータは訓練データの複製そのものになるため、前処理に何らかのランダムな処理が含まれていない限りはすべての識別器の重みは等しくなる。

$$\mathbf{w} = \mathbf{w}_1 = \mathbf{w}_2 = \dots = \mathbf{w}_{N_c} \quad (4.4)$$

したがって前処理・次元削減を施した試験データも等しくなる。

$$\mathbf{x}_{i,j,n} = \mathbf{x}_{i,j,1,n} = \mathbf{x}_{i,j,2,n} = \dots = \mathbf{x}_{i,j,N_c,n} \quad (4.5)$$

これらを用いて集合識別器のスコア (式 (4.1)) を書き換えると次のようになる。

$$s'_{i,n} = N_c \sum_{j=1}^{N_s} \mathbf{w} \cdot \mathbf{x}_{i,j,n}^{\text{test}} \quad (4.6)$$

ここで、単一の識別器の一般的なスコアは下記ようになる。

$$s''_{i,n} = \sum_{j=1}^{N_s} \mathbf{w} \cdot \mathbf{x}_{i,j,n}^{\text{test}} \quad (4.7)$$

よって、 $N_b = N_c$ の場合のオーバーラップト・パーティショニングを用いた集合識別器と、単一の識別器のスコアの関係は下記のように表現できる。

$$s'_{i,n} = N_c s''_{i,n} \quad (4.8)$$

このことから、 $N_b = N_c$ の場合の集合識別器のスコアは単一の識別器の単なる定数倍になっていることがわかり、式 (4.3) より、両者は等価になることがわかる。本研究では後述するように N_c を固定して、 N_b を変化させて集合識別器の効果を評価したが、上記の特殊な条件により同時に単一の識別器 ($N_b = N_c$) とナイーブ・パーティショニングを用いた集合識別器 ($N_b = 1$) との比較を行った。

オーバーラップト・パーティショニングを用いて評価する利点は下記のとおりである。

- 識別器の数 (N_c) を一定にしたまま訓練データの重複度合い (N_b) を変化させることができるので識別器の個数の違いによる影響を考えずに済む。
- 従来手法であるナイーブ・パーティショニングを用いた集合識別器や単一の識別器と互換性があり、訓練データの重複度合い (N_b) を変化させるだけで同時に比較できる。
- 訓練データを重複してリサンプリングする手法であるバギング [96] を ERP-based BCI に特化した形であると解釈できるため、統計的機械学習の手法と絡めて考察することができる。

次元削減法

ERP-based BCI のデータは平滑化、次元削減、ベクトル化といった前処理をしただけでは高次元データになり、通常はそのデータを識別器で分類しても高い識別精度は得られない。このような現象は次元の呪いとして知られている [78]。そのため次元削減をすることで識別精度を向上させる。本研究では ERP-based BCI で盛んに用いられているステップワイズ法と、機械学習全般で幅広く用いられている主成分分析を次元削減として使用し、次元削減を行わない場合と合わせて、オーバーラップト・パーティショニングを用いた集合識別器の識別性能に次元削減法が与える影響を調べた。

• ステップワイズ法

ステップワイズ法は前方法と後方法から成り、統計的検定により相応しい時空間の特

徴⁶を選択する手法である。まず、空の回帰モデルを用意する。そして、ある特徴を追加し F 検定を行う。その結果算出された p 値があるしきい値 p_{in} より大きければ特徴をモデルに追加する。このように特徴を追加する方法を前方法と呼ぶ。前方法をどの特徴も追加されなくなるまで繰り返す。その後、モデルの中のある特徴を減らし、F 検定を行う。その結果の p 値があるしきい値 p_{out} 以下であれば特徴をモデルから削除する。以上のように特徴を取り除く方法を後方法と呼ぶ。後方法をどの特徴も削除されなくなるまで繰り返す。このように前方法、後方法を繰り返し、どの特徴も追加も削除されなくなった時のモデルが最終モデルであり、そこで用いられた特徴のみを用いるのがステップワイズ法による次元削減である。条件分岐が煩雑であるが、MATLAB の `stepwisefit` 関数を使うことで簡単に実装することができる [97]。ステップワイズ法に関するより詳しい説明は [98, 64] をご覧頂きたい。本研究では先行研究でよく用いられるパラメータである $p_{in} = 0.10$ 、 $p_{out} = 0.15$ を用いた [64]。

- 主成分分析

主成分分析は固有値分解に基づく手法により分散が最大となる方向を見つける手法である [99, 100]。訓練データの共分散行列を固有値分解し、固有値が最大となる固有ベクトルを元のデータにかけることで求めたデータを第1主成分という。同様に固有値が2番目、3番目に大きい固有ベクトルを用いて第2、第3主成分を求めることができる。データセット A については第1-140主成分を、データセット B については第1-400主成分を用いて評価した。

4.2.4 比較方法

本研究ではオーバーラップト・パーティショニングを用いて学習した集合識別器がどのように影響を与えるかを、重複するブロックの数 N_b を変化させて調べた。また、次元削減法による影響も同時に調べた。オーバーラップト・パーティショニングを用いて学習したステップワイズ LDA (SWLDA) の集合識別器を `overlapped ensemble of SWLDAs (OSWLDA)`、主成分分析 LDA (PCALDA) の集合識別器を `overlapped ensemble of PCALDAs (OPCALDA)`、そして次元削減なしで LDA の集合識別器を `overlapped ensemble of LDAs (OLDAs)` と呼ぶことにする。

評価に用いるパラメータ及び手法は図 4.1 に記載した通りである。上記の3つの識別器をデータセット A (独自に計測した ERP-based BCI のデータ) と、データセット B (BCI

⁶特徴ベクトルの要素のことである。場合によっては変数という言葉を使うこともある。ERP-based BCI の特徴ベクトルは時空間情報を含む行列をベクトル化したものである。

competition III data set II) の二つを用いて評価した。各データセットの刺激提示、データ計測とその前処理方法について表 4.1 にまとめている。データセット A は訓練データと試験データを区別せずに 50 文字分 (9,000 波形) の ERP-based BCI データが含まれているので、これを 1/10 交差確認法と 9/10 交差確認法により評価した。訓練データの数は 1/10 交差確認法の場合は 5 文字分 (900 波形)、9/10 交差確認法の場合は 45 文字分 (8,100 波形) となる。また、データセット B は訓練データ 85 文字分と試験データ 100 文字分が含まれているので、実験の再現性を考えて最初の 5 文字分の訓練データを用いて制限された訓練データにより、また、全訓練データにより識別器を学習し、すべての試験データを識別した時の性能を評価した。ここで、制限された訓練データを用いた場合は 900 波形分のデータで、全訓練データを用いた場合は 15,300 波形のデータで識別器を学習する。

データセット A、B それぞれに用いたオーバーラップト・パーティショニングのパラメータ及び対応する弱識別器学習のための訓練データ数を表 4.2 及び表 4.3 に示す。本研究ではオーバーラップト・パーティショニングの特別な場合になる条件を利用し、単一の識別器とナイーブ・パーティショニングを用いた集合識別器との比較を行った。オーバーラップト・パーティショニングの性質より、 $N_c > 1$ かつ $N_b = 1$ の時はナイーブ・パーティショニングを用いた集合識別器となる。ここで、ナイーブ・パーティショニングを用いた SWLDA の集合識別器は Johnson らによって提案されたものと等価である [91]。また、 $N_c = N_b$ となる時は単一の識別器と等しくなる。そのため ERP-based BCI で盛んに用いられている単一の SWLDA とも比較を行っている。

データセット A についてはシーケンス回数 N_s 、次元削減法 (ステップワイズ法、PCA、なし)、オーバーラップト・パーティショニングで使用するブロックの数 N_b について繰り返しあり三元配置分散分析を用いて評価した。また、ポストホックテストにはボンフェローニの方法を用いた。データセット B は被験者数が 2 名であるため統計解析を行わなかった。

表 4.1: データセット A、B それぞれの刺激提示、データ計測、前処理に用いたパラメータ

[56]

	データセット A	データセット B
命令数	36	36
行数	6	6
列数	6	6
刺激シーケンス回数	15	15
刺激オン時間 (ms)	100	100
刺激オフ時間 (ms)	75	75
標的文字提示時間 (s)	3	2.5
推定文字出力時間 (s)	1	2.5
被験者数	10	2
計測された文字数	50	訓練用:85、試験用:100
電極数	8	64
サンプリングレート (Hz)	128	240
バンドパスフィルタ (Hz)	0.11-30	0.1-60
ERP バッファ長 (ms)	700	700
ベースライン計算用のバッファ長 (ms)	前 100	前 100
移動平均の解析窓長 (サンプル)	3	18
ダウンサンプリング (Hz)	43	20

表 4.2: データセット A を評価する際のオーバーラップ・パーティショニングを用いた集合識別器のパラメータ [56]

評価方法	訓練文字数	試験文字数	N_c	N_b	各弱学習器の 訓練データ数 (波形)
1/10 交差確認法	5 文字 (全 900 波形)	50 文字	5	1	180
			5	2	360
			5	3	540
			5	4	720
			5	5	900
9/10 交差確認法	45 文字 (8,100 波形)	50 文字	45	1	180
			45	5	900
			45	10	1,800
			45	15	2,700
			45	20	3,600
			45	25	4,500
			45	30	5,400
			45	35	6,300
			45	40	7,200
			45	45	8,100

表 4.3: データセット B を評価する際のオーバーラップト・パーティショニングを用いた集合識別器のパラメータ [56]

評価方法	訓練文字数	試験文字数	N_c	N_b	各弱学習器の 訓練データ数 (波形)
制限された訓練データ	5 文字 (900 波形)	100 文字	5	1	180
			5	2	360
			5	3	540
			5	4	720
			5	5	900
全訓練データ	85 文字 (15,300 波形)	100 文字	17	1	900
			17	2	1,800
			17	3	2,700
			17	4	3,600
			17	5	4,500
			17	6	5,400
			17	7	6,300
			17	8	7,200
			17	9	8,100
			17	10	9,000
			17	11	9,900
			17	12	10,800
			17	13	11,700
17	14	12,600			
17	15	13,500			
17	16	14,400			
17	17	15,300			

4.3 結果

提案する OSWLDA と OPCALDA、OLDA をデータセット A、B を用いてその識別性能を評価した。本研究では訓練 ERP データ約 1,000 波形より少ない場合での評価を行うことを目的としている。なお、識別器の性能がランダムに与えられる場合の確率、すなわち偶然確率は $1/36$ となっている。

4.3.1 1/10 交差確認法によるデータセット A の評価

OSWLDA、OPCALDA、OLDA それぞれについて $N_c = 5$ に固定した状態で N_b を 1 から 5 まで変化させた場合の各被験者の識別精度を図 4.5 に示す。 $N_b = 1$ の時にナイーブ・パーティショニングを用いた集合識別器、 $N_b = N_c$ の時には単一の集合識別器となる。集合識別器に与えられているデータは 900 波形で等しいが、オーバーラップト・パーティショニングのパラメータにより集合識別器の中の弱学習器に割り振られる訓練データ数が異なる。詳しくは表 4.2 を参照していただきたい。図 4.5 の縦軸は識別精度であり、横軸は出力を計算するために使った刺激シーケンスの数 N_s である。 N_b は線の種類を変えて表示している。全体的に性能は N_s が増えるにつれて性能が向上していることがわかる。被験者 7 はいずれの識別器でも低いシーケンス回数から高い識別精度を示している。被験者 6 は他の被験者よりも低い性能を示している。 $N_b = 1$ ではいずれの識別器でも最も低い識別性能を示しているが、特に次元削減されていない OLDA では $N_b = 1$ の時に識別精度がほぼ偶然確率になることがわかった。

図 4.6 は図 4.5 における 10 人の被験者の識別精度の平均を取ったものである。いずれの識別器でも $N_b = 3, 4, 5$ で高い識別精度が得られた。 $N_b = 4$ の時にシーケンス回数 N_s が低い場合でも高い識別精度を示し立ち上がりやすい。その傾向は OSWLDA の $N_b = 4$ かつ $3 \leq N_s \leq 7$ で顕著に見られた。この結果は集合識別器のパラメータ次第では単一の識別器より性能が高くなることを示している。特に ERP-based BCI では SWLDA が盛んに使われており、基準となる識別器として用いられることが多いが、本研究ではそのアルゴリズムを集合識別器とし、オーバーラップト・パーティショニングを用いて学習することで性能が高くなることを示している。OPCALDA についても $N_b = 4$ かつ $6 \leq N_s \leq 9$ において単一の識別器より性能が高くなっている。また、ナイーブ・パーティショニングを用いて集合識別器を学習した場合、すなわち $N_b = 1$ の場合は性能が最も低く、特に次元削減されていない OLDA では性能が著しく低くなり、900 波形程度の少ない訓練データを用いて識別器を学習することは難しいことを示している。

表 4.4 に具体的な平均識別精度を示す。OSWLDA について $N_s = 5$ のとき、 $N_b = 4$ の場合の識別精度が $N_b = 1$ の場合より 11.2% 高く、 $N_b = 5$ の場合より 4.8% 高いことがわかる。しかしながら OPCALDA や OLDA は単一の識別器と集合識別器の差はごく僅かであった。

シーケンス回数 N_s 、次元削減法、オーバーラップト・パーティショニングで使用するブロックの数 N_b を要因とする三元配置の反復測定分散分析を行った。その結果、反復回数 ($F(14, 126) = 166.6, p < 0.01$)、次元削減法 ($F(2, 18) = 614.6, p < 0.01$)、ブロック数 ($F(4, 36) = 1356, p < 0.01$)、そして交互作用 (全て $p < 0.01$) に主効果が見られた。ボンフェローニの方法を用いたポストホックテストにより、次元削減法 (全て $p < 0.01$)、 $N_b = 3$ と 5 を除く N_b のペア (全て $p < 0.01$) で有意差が見られた。

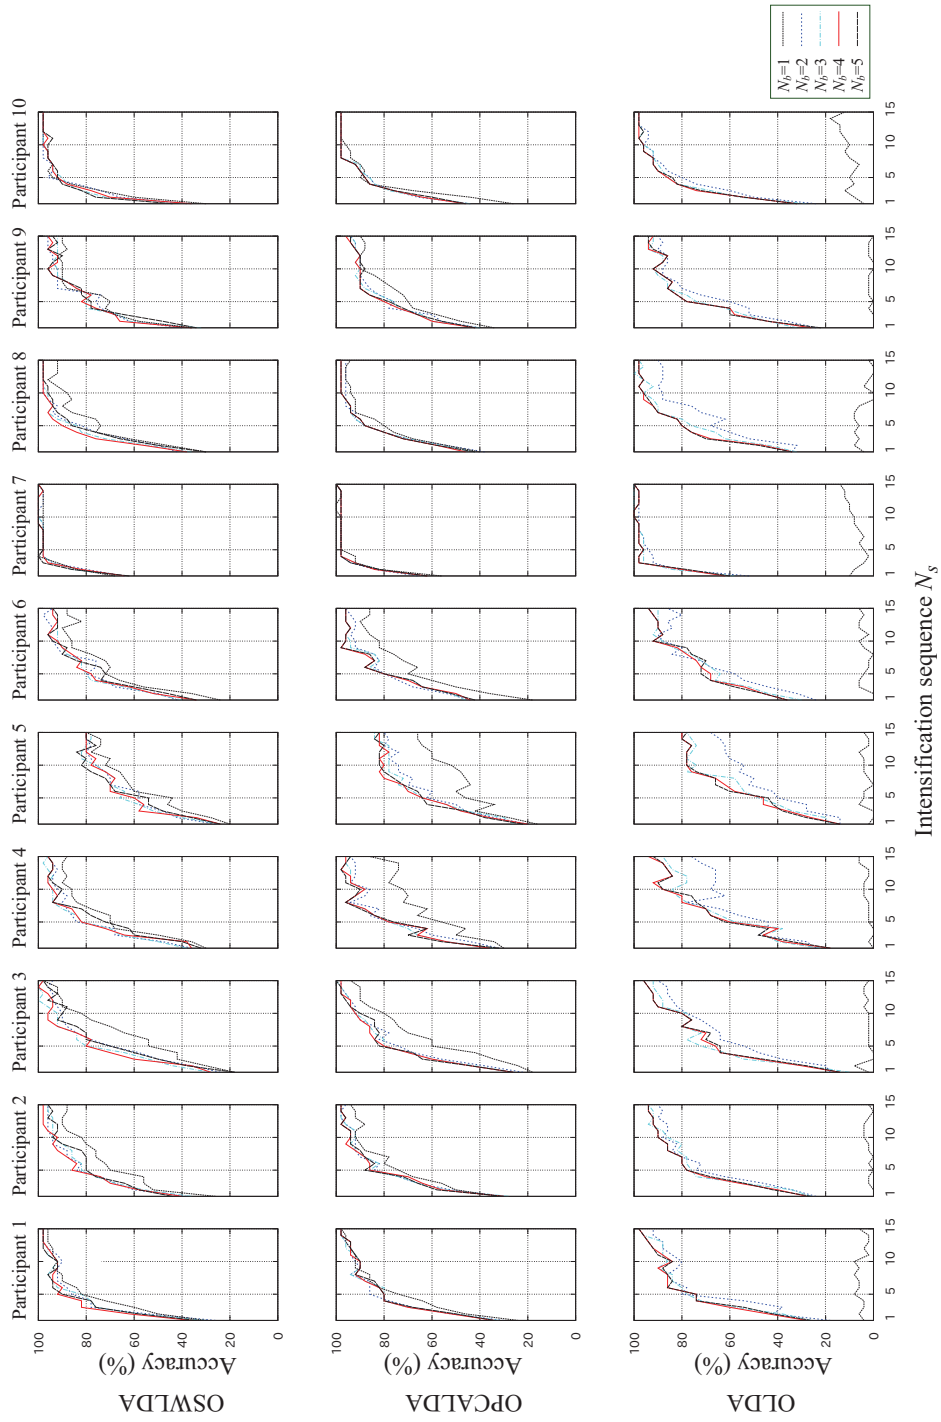


図 4.5: データセット A を 1/10 交差確認法で評価した際の各被験者の識別精度

図は [56] を一部改変したものである。




図 4.6: データセット A を 1/10 交差確認法で評価した際の平均識別精度

図は [56] を一部改変したものである。

表 4.4: データセット A について 1/10 交差確認法を用いて OSWLDA、OPCALDA、OLDA を評価した際の平均識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

識別器	N_c	N_b	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
OSWLDA	5	1	<u>31.2</u>	<u>48.0</u>	<u>60.0</u>	<u>68.4</u>	<u>72.8</u>	<u>75.4</u>	<u>80.8</u>	<u>83.6</u>	<u>86.0</u>	<u>87.4</u>	<u>89.8</u>	<u>91.4</u>	<u>90.0</u>	<u>90.6</u>	<u>91.8</u>
		2	37.6	54.8	68.0	74.0	81.4	82.4	87.6	89.8	91.2	92.4	93.8	94.2	94.4	95.2	95.0
		3	36.4	57.4	69.4	77.2	82.4	85.0	87.8	90.0	91.4	92.6	94.6	94.6	94.6	95.0	94.8
		4	37.2	55.4	71.4	77.6	84.0	85.4	87.6	90.2	92.2	93.6	93.8	94.6	95.0	95.2	95.6
		5	35.6	53.6	66.8	74.8	79.2	83.4	85.6	89.4	91.6	93.0	93.0	94.4	94.0	94.2	95.2
OPCALDA	5	1	<u>29.4</u>	<u>44.6</u>	<u>57.6</u>	<u>63.6</u>	<u>71.8</u>	<u>74.6</u>	<u>76.8</u>	<u>80.6</u>	<u>82.6</u>	<u>84.8</u>	<u>87.6</u>	<u>88.0</u>	<u>88.6</u>	<u>88.4</u>	<u>90.6</u>
		2	36.6	53.4	66.4	75.0	81.2	84.2	85.6	89.6	90.8	91.0	92.6	92.4	93.8	94.2	95.0
		3	38.2	54.4	67.6	75.2	81.6	84.2	87.4	90.4	92.0	91.8	93.2	93.6	94.4	95.6	96.0
		4	38.6	55.8	67.8	74.4	82.2	85.8	88.0	91.4	93.0	92.4	94.0	93.6	95.0	95.6	96.0
		5	37.8	55.4	68.6	74.8	82.2	85.2	87.4	90.4	92.0	92.4	93.8	94.4	94.8	95.8	95.8
OLDA	5	1	<u>2.6</u>	<u>4.0</u>	<u>3.4</u>	<u>3.8</u>	<u>4.0</u>	<u>4.2</u>	<u>3.2</u>	<u>4.0</u>	<u>4.4</u>	<u>4.6</u>	<u>4.6</u>	<u>5.2</u>	<u>4.6</u>	<u>5.0</u>	<u>5.4</u>
		2	25.6	37.0	49.8	56.8	65.2	69.6	75.2	79.8	80.0	82.6	83.6	83.6	85.2	85.4	88.0
		3	28.2	43.2	57.8	65.8	72.8	76.4	79.4	82.4	86.2	88.0	89.0	89.4	91.0	91.8	92.8
		4	29.2	44.8	59.8	67.8	73.2	78.8	80.8	84.2	86.8	89.6	91.0	90.6	91.8	93.2	94.4
		5	28.2	44.4	59.8	67.6	73.2	78.8	80.4	83.4	85.4	89.6	91.0	90.4	91.6	93.2	94.2

4.3.2 9/10 交差確認法によるデータセット A の評価

訓練データ数を増やして評価した場合に 4.3.1 と同様の傾向が見られるのかを調べた。OSWLDA、OPCALDA、OLDA それぞれについて $N_c = 45$ に固定した状態で N_b を 1, 5, 10, ..., 45 と変化させた場合の各被験者の識別精度を図 4.7 に示す。集合識別器に与えられているデータは 8,100 波形となるが、オーバーラップト・パーティショニングのパラメータにより集合識別器の中の弱学習器に割り振られる訓練データの数が異なる。オーバーラップト・パーティショニングと弱学習器の訓練データの数の関係は表 4.2 にまとめてある。図 4.7 の縦軸は識別精度、横軸は刺激シーケンスの数 N_s を示している。 N_b は線の種類を変えて表示した。9/10 交差確認法における各被験者の最大識別精度は 1/10 交差確認法のものより早く立ち上がり、識別精度が 95% 近くまで達した。OSWLDA 及び OPCALDA については N_b により大きな変化が見られないが、被験者 2 と 4 は N_b に依存することがわかる。OLDA に関しては $N_b = 1$ の場合に性能がほぼランダムになることがわかる。

図 4.8 は 9/10 交差確認法により求めた OSWLDA、OPCALDA 及び OLDA の 10 人の被験者の平均識別精度である。表 4.5 は各識別器の平均識別精度の具体的な値を示している。 $N_b = 1$ の時に最低の識別精度になることが見て取れる。 N_b を増やすと識別精度は向上したが、 $N_b = 45$ 、すなわち単一の識別器とほぼ同等の精度しか得られなかった。

反復回数 N_s 、次元削減法、オーバーラップト・パーティショニングで使用するブロックの数 N_b を要因とする三元配置の反復測定分散分析を行った。その結果、反復回数 ($F(14, 126) = 135, p < 0.01$)、次元削減法 ($F(2, 18) = 510.9, p < 0.01$)、ブロック数 ($F(9, 81) = 197.9, p < 0.01$) そしてそれらの交互作用 (それぞれ $p < 0.01$) で主効果が見られた。ボンフェローニの方法を用いたポストホックテストでは、次元削減手法 (全て $p < 0.05$)、 $N_b = 1, 5, 10, 15$ を含むペア (全て $p < 0.01$) で有意差が見られた。




図 4.7: データセット A を 9/10 交差確認法で評価した際の各被験者の識別精度

図は [56] を一部改変したものである。

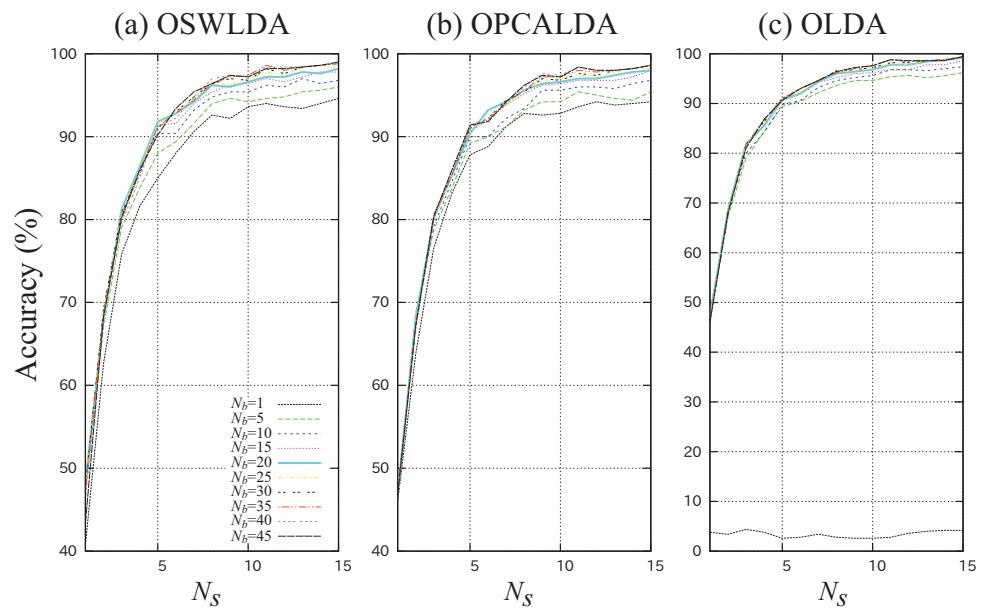


図 4.8: データセット A を 9/10 交差確認法で評価した際の平均識別精度

図は [56] を一部改変したものである。

表 4.5: データセット A について 9/10 交差確認法を用いて OSWLDA、OPCALDA、OLDA を評価した際の平均識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

識別器	N_c	N_b	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
OSWLDA	45	1	<u>40.8</u>	<u>62.6</u>	<u>75.8</u>	<u>81.6</u>	<u>85.0</u>	<u>88.0</u>	<u>90.6</u>	<u>92.6</u>	<u>92.2</u>	<u>93.6</u>	<u>94.0</u>	<u>93.6</u>	<u>93.4</u>	<u>94.0</u>	<u>94.6</u>
		5	47.4	67.0	79.0	83.8	88.0	89.4	91.6	94.0	94.6	94.2	94.6	94.8	95.4	95.6	96.0
		10	47.2	68.2	80.4	86.2	90.4	90.4	93.2	94.8	95.4	95.4	96.2	96.0	97.0	96.4	96.8
		15	47.8	68.6	80.6	85.4	91.4	91.6	94.0	95.4	96.2	96.4	97.0	96.6	97.2	97.8	97.8
		20	48.4	68.0	81.2	86.4	91.8	92.8	94.2	96.2	96.0	96.6	97.2	97.2	97.8	97.6	98.2
		25	47.8	69.0	81.0	86.2	91.6	92.8	94.6	96.6	96.2	97.0	97.8	97.4	98.4	98.6	98.2
		30	47.8	69.2	80.8	85.6	91.0	93.0	94.8	96.4	97.0	96.8	98.2	97.6	98.4	98.6	98.8
		35	47.4	68.8	80.0	85.8	91.2	92.8	94.4	96.4	97.2	97.4	98.6	98.0	98.4	98.6	98.8
		40	46.2	68.0	79.6	85.0	91.2	92.2	94.8	97.0	97.4	97.2	98.4	98.4	98.4	98.6	98.8
		45	43.4	68.2	80.2	86.0	90.2	93.4	95.4	96.4	97.4	97.2	98.2	98.2	98.4	98.6	99.0
OPCALDA	45	1	<u>46.0</u>	<u>63.8</u>	<u>76.6</u>	<u>83.2</u>	<u>87.8</u>	<u>88.8</u>	<u>91.2</u>	<u>92.8</u>	<u>92.6</u>	<u>92.8</u>	<u>93.6</u>	<u>94.2</u>	<u>93.8</u>	<u>94.0</u>	<u>94.2</u>
		5	<u>46.0</u>	68.8	78.8	83.8	89.2	90.0	<u>91.2</u>	93.2	94.2	94.2	95.4	95.0	94.6	94.4	95.4
		10	46.4	67.6	79.2	84.6	90.0	90.0	92.2	93.4	95.6	95.6	96.0	96.0	95.8	96.4	96.8
		15	47.4	68.2	80.0	86.0	90.6	92.0	93.8	95.2	96.2	96.4	96.8	96.8	96.8	97.2	98.0
		20	47.0	68.2	80.2	85.4	90.4	93.2	94.2	95.6	96.4	96.6	97.0	97.0	97.4	97.8	98.0
		25	47.0	66.6	80.2	85.4	91.0	92.4	93.8	95.6	96.6	97.0	97.4	97.2	97.8	98.2	98.2
		30	47.4	67.0	80.6	85.4	91.0	92.2	94.4	95.4	97.0	96.8	97.6	97.4	98.0	98.2	98.6
		35	47.0	67.4	80.2	85.4	91.2	92.0	94.0	95.6	97.2	97.2	98.0	97.8	98.0	98.2	98.6
		40	46.6	67.0	80.6	85.4	91.4	92.2	94.2	96.0	97.6	97.4	98.4	98.0	98.0	98.2	98.6
		45	46.8	67.2	80.4	86.0	91.4	91.8	94.2	96.2	97.4	97.2	98.4	98.0	98.0	98.2	98.6
OLDA	45	1	<u>3.8</u>	<u>3.4</u>	<u>4.4</u>	<u>3.8</u>	<u>2.6</u>	<u>2.8</u>	<u>3.4</u>	<u>2.8</u>	<u>2.6</u>	<u>2.6</u>	<u>2.8</u>	<u>3.6</u>	<u>4.0</u>	<u>4.2</u>	<u>4.2</u>
		5	46.6	67.2	79.0	84.4	89.4	90.4	92.2	93.6	94.6	94.6	95.4	95.6	95.2	95.6	96.2
		10	47.8	68.4	80.0	84.2	89.8	90.6	93.2	94.6	95.2	95.6	96.8	96.8	96.6	97.0	97.4
		15	47.6	68.6	81.8	85.4	90.6	91.8	94.2	95.2	96.0	96.2	96.8	96.8	97.8	97.8	98.6
		20	47.2	68.6	81.8	85.6	90.8	92.0	94.4	96.0	96.4	96.8	97.8	97.8	98.4	98.8	99.2
		25	46.8	68.2	82.0	86.2	91.2	92.2	94.8	96.4	96.6	97.0	98.0	97.8	98.6	98.8	99.6
		30	46.4	67.4	81.8	86.4	91.0	93.0	94.6	96.6	96.8	97.2	98.2	98.2	98.6	98.8	99.4
		35	46.4	68.0	81.6	86.8	91.0	93.0	94.6	96.2	97.0	97.6	98.8	98.4	98.6	98.8	99.4
		40	46.0	68.0	81.4	86.8	90.8	93.0	94.6	96.4	97.2	97.6	98.8	98.4	98.6	98.6	99.4
		45	46.0	68.0	81.0	86.8	90.6	93.0	94.6	96.4	97.2	97.6	98.8	98.6	98.6	98.6	99.4

4.3.3 制限された訓練データを使用した場合のデータセット B の評価

データセット B についても同様に 900 波形の ERP で集合識別器を訓練し、その性能を評価した。OSWLDA、OPCALDA 及び OLDA の識別精度を表 4.6、4.7、4.8 に示す。ここでは $N_c = 5$ に固定して N_b を 1 から 5 まで変化させて識別精度を求めた。OSWLDA 及び OPCALDA については $N_b = 4$ と 5 の場合に識別精度が最大になることがわかる。特に $N_s = 6$ の場合に OSWLDA($N_b = 5$) は単一の SWLDA($N_b = 5$) より 15%高い識別精度が得られることがわかる。OPCALDA に関しても $N_b = 5$ 、 $N_s = 12$ のときに単一の識別器 (SWLDA) より 5.5%高い識別精度が得られている。この結果は $N_b = 4$ で高い識別精度を出すことから 4.3.1 に示すデータセット A の 1/10 交差確認法で得られた結果と似ている。一方で OSWLDA 及び OPCALDA に関しては $N_b \leq 2$ 、OLDA については全条件で識別精度が偶然確率になった。

表 4.6: データセット B について制限された訓練データを用いて OSWLDA を評価した際の識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
5	1	A	5	3	7	8	9	11	6	7	7	10	8	10	7	11	
		B	5	4	8	9	9	8	7	8	5	9	9	9	11	15	13
		平均	5.0	3.5	7.5	8.5	9.0	9.5	6.5	7.5	6.0	9.5	8.5	9.5	10.5	11.0	12.0
5	2	A	6	2	6	9	7	4	6	10	7	9	10	10	13	10	
		B	3	3	3	7	5	5	1	2	1	3	3	1	0	1	0
		平均	<u>4.5</u>	<u>2.5</u>	<u>4.5</u>	<u>8.0</u>	<u>6.0</u>	<u>4.5</u>	<u>3.5</u>	<u>6.0</u>	<u>4.0</u>	<u>6.0</u>	<u>6.5</u>	<u>5.5</u>	<u>5.0</u>	<u>7.0</u>	<u>5.0</u>
5	3	A	14	17	24	30	24	33	36	37	40	47	54	56	61	65	67
		B	20	23	34	40	49	51	53	49	59	61	65	67	67	72	74
		平均	17.0	20.0	29.0	35.0	36.5	42.0	44.5	43.0	49.5	54.0	59.5	61.5	64.0	68.5	70.5
5	4	A	10	24	21	32	28	36	39	43	51	53	57	59	64	63	67
		B	18	28	41	44	60	67	62	63	66	68	74	79	81	80	82
		平均	14.0	26.0	31.0	38.0	44.0	51.5	50.5	53.0	58.5	60.5	65.5	69.0	72.5	71.5	74.5
5	5	A	3	14	20	26	23	24	31	38	41	53	50	57	53	62	68
		B	15	24	36	37	50	49	50	48	49	56	58	61	66	70	71
		平均	9.0	19.0	28.0	31.5	36.5	36.5	40.5	43.0	45.0	54.5	54.0	59.0	59.5	66.0	69.5

表 4.7: データセット B について制限された訓練データを用いて OPCALDA を評価した際の識別精度 (%) [56]

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
5	1	A	4	7	6	5	6	6	10	8	6	7	4	6	6	4	4
		B	4	7	2	4	4	5	3	3	4	6	5	5	4	4	3
		平均	4.0	7.0	4.0	4.5	5.0	5.5	6.5	5.5	<u>5.0</u>	6.5	4.5	5.5	5.0	4.0	3.5
5	2	A	0	2	1	1	3	3	3	1	4	4	4	3	3	4	4
		B	7	4	1	2	4	3	4	4	6	5	4	4	2	2	2
		平均	<u>3.5</u>	<u>3.0</u>	<u>1.0</u>	<u>1.5</u>	<u>3.5</u>	<u>3.0</u>	<u>3.5</u>	<u>2.5</u>	<u>5.0</u>	<u>4.5</u>	<u>4.0</u>	<u>3.5</u>	<u>2.5</u>	<u>3.0</u>	<u>3.0</u>
5	3	A	12	17	22	22	31	36	37	41	47	57	55	60	59	60	65
		B	10	24	29	34	39	34	41	39	46	48	53	54	59	61	61
		平均	11.0	20.5	25.5	28.0	35.0	35.0	39.0	40.0	46.5	52.5	54.0	57.0	59.0	60.5	63.0
5	4	A	7	17	17	19	30	31	42	41	48	53	56	57	57	62	65
		B	11	26	27	33	40	39	46	49	49	49	51	59	63	64	62
		平均	9.0	21.5	22.0	26.0	35.0	35.0	44.0	45.0	48.5	51.0	53.5	58.0	60.0	63.0	63.5
5	5	A	7	16	17	18	26	27	36	38	43	48	49	53	53	56	60
		B	7	23	25	32	42	40	45	44	50	47	48	52	60	63	60
		平均	7.0	19.5	21.0	25.0	34.0	33.5	40.5	41.0	46.5	47.5	48.5	52.5	56.5	59.5	60.0

表 4.8: データセット B について制限された訓練データを用いて OLDA を評価した際の識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
5	1	A	1	3	5	4	2	2	4	5	3	3	2	3	3	5	3
		B	6	3	2	3	4	6	6	4	6	4	4	4	8	7	8
		平均	3.5	3.0	3.5	3.5	3.0	4.0	5.0	4.5	4.5	3.5	3.0	3.5	5.5	6.0	5.5
5	2	A	3	4	7	4	6	3	2	3	2	2	1	1	2	2	2
		B	2	7	6	6	4	6	10	11	7	8	8	10	11	9	11
		平均	2.5	5.5	6.5	5.0	5.0	4.5	6.0	7.0	4.5	5.0	4.5	5.5	6.5	5.5	6.5
5	3	A	2	1	0	0	1	2	1	1	1	1	1	1	1	1	1
		B	2	3	5	5	4	2	1	4	3	5	3	3	1	1	2
		平均	2.0	2.0	2.5	2.5	<u>2.5</u>	<u>2.0</u>	<u>1.0</u>	<u>2.5</u>	<u>2.0</u>	<u>3.0</u>	<u>2.0</u>	<u>2.0</u>	<u>1.0</u>	<u>1.0</u>	<u>1.5</u>
5	4	A	0	1	2	2	3	3	1	1	2	2	2	2	1	4	2
		B	2	1	2	2	3	2	3	4	4	4	4	3	3	5	4
		平均	<u>1.0</u>	<u>1.0</u>	<u>2.0</u>	<u>2.0</u>	3.0	2.5	2.0	<u>2.5</u>	3.0	<u>3.0</u>	3.0	2.5	2.0	4.5	3.0
5	5	A	7	8	5	8	5	5	6	10	8	6	8	8	7	8	8
		B	4	3	4	7	7	6	8	9	11	9	8	8	5	8	6
		平均	5.5	5.5	4.5	7.5	6.0	5.5	7.0	9.5	9.5	7.5	8.0	8.0	6.0	8.0	7.0

4.3.4 すべての訓練データを使用した場合のデータセット B の評価

データセット B を 15,300 波形全ての ERP で集合識別器を訓練し、4.3.3 と同等の傾向を示すのか確認した。OSWLDA、OPCALDA 及び OLDA の識別精度を表 4.9、4.10、4.11 に示す。ここでは $N_c = 17$ に固定して N_b を 1 から 17 まで変化させて識別精度を求めた。OSWLDA、OPCALDA 及び OLDA はナイーブ・パーティショニングを用いた集合識別器 ($N_b = 1$)、もしくは単一の識別器 ($N_b = 17$) と同等か、それよりわずかに性能が高くなることがわかった。最大の平均識別精度は OSWLDA ($N_s = 15$, $N_b = 7, 9, 11$) が達成した 98%であった。この結果は BCI competition III data set II の勝者 [4] より 1.5%高い識別精度である。また、OSWLDA は単一の SWLDA より高い識別性能を示しているが、しかし 4.3.3 の訓練データが少ない場合の傾向と比較してごくわずかにしか識別精度が向上しなかった。その点で 4.3.2 のデータセット A を多くの訓練データを用いて評価した場合と同様の傾向が見られた。

表 4.9: データセット B について全訓練データを用いて OSWLDA を評価した際の識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
17	1	A	17	28	49	53	60	62	65	72	79	82	83	85	86	91	90
		B	45	62	66	70	77	84	87	89	91	93	94	97	96	97	96
		平均	<u>31.0</u>	45.0	<u>57.5</u>	61.5	<u>68.5</u>	<u>73.0</u>	<u>76.0</u>	<u>80.5</u>	<u>85.0</u>	<u>87.5</u>	<u>88.5</u>	<u>91.0</u>	<u>91.0</u>	94.0	<u>93.0</u>
17	2	A	19	30	48	59	64	68	75	76	82	86	85	88	91	94	96
		B	46	63	67	70	79	87	90	92	91	94	94	97	97	98	98
		平均	32.5	46.5	<u>57.5</u>	64.5	71.5	77.5	82.5	84	86.5	90	89.5	92.5	94	96	97.0
17	3	A	21	38	59	62	69	76	81	82	85	85	85	92	93	97	96
		B	49	64	69	73	81	86	87	91	93	95	94	95	96	97	97
		平均	35.0	51.0	64.0	67.5	75.0	81.0	84.0	86.5	89.0	90.0	89.5	93.5	94.5	97.0	96.5
17	4	A	19	36	54	65	67	71	79	80	81	85	85	90	89	94	96
		B	51	64	71	70	80	85	86	91	93	95	94	95	96	94	97
		平均	35.0	50.0	62.5	67.5	73.5	78.0	82.5	85.5	87.0	90.0	89.5	92.5	92.5	94.0	96.5
17	5	A	21	37	59	63	64	72	80	79	82	85	87	91	92	94	97
		B	49	64	69	71	78	86	87	92	93	95	94	96	96	96	97
		平均	35.0	50.5	64.0	67.0	71.0	79.0	83.5	85.5	87.5	90.0	90.5	93.5	94.0	95.0	97.0
17	6	A	20	37	54	60	61	73	77	78	85	87	87	89	91	94	96
		B	46	63	69	70	82	86	88	92	94	95	95	95	96	95	97
		平均	33.0	50.0	61.5	65.0	71.5	79.5	82.5	85.0	89.5	91.0	91.0	92.0	93.5	94.5	96.5
17	7	A	22	39	55	63	63	74	79	78	84	87	86	91	93	95	99
		B	48	63	70	70	81	87	88	92	94	95	94	95	96	96	97
		平均	35.0	51.0	62.5	66.5	72.0	80.5	83.5	85.0	89.0	91.0	90.0	93.0	94.5	95.5	98.0
17	8	A	22	36	52	59	64	72	76	79	81	87	87	90	94	94	98
		B	46	68	69	70	81	88	89	92	94	95	95	95	95	95	97
		平均	34.0	52.0	60.5	64.5	72.5	80.0	82.5	85.5	87.5	91.0	91.0	92.5	94.5	94.5	97.5
17	9	A	27	37	51	60	65	73	77	80	83	89	89	93	95	95	99
		B	45	64	69	69	79	87	89	92	94	95	95	95	95	95	97
		平均	36.0	50.5	60.0	64.5	72.0	80.0	83.0	86.0	88.5	92.0	92.0	94.0	95.0	95.0	98.0
17	10	A	22	35	54	62	63	72	74	77	83	88	87	93	95	94	98
		B	48	66	70	69	80	85	91	92	93	95	94	95	96	96	97
		平均	35.0	50.5	62.0	65.5	71.5	78.5	82.5	84.5	88.0	91.5	90.5	94.0	95.5	95.0	97.5
17	11	A	22	36	56	59	65	75	76	79	83	88	86	91	94	95	99
		B	44	66	71	70	80	87	91	92	94	94	94	95	96	95	97
		平均	33.0	51.0	63.5	64.5	72.5	81.0	83.5	85.5	88.5	91.0	90.0	93.0	95.0	95.0	98.0
17	12	A	22	34	55	62	66	75	74	77	82	88	87	93	95	96	98
		B	43	67	71	72	83	86	91	92	94	95	95	96	95	96	97
		平均	32.5	50.5	63.0	67.0	74.5	80.5	82.5	84.5	88.0	91.5	91.0	94.5	95.0	96.0	97.5
17	13	A	23	34	53	59	65	74	75	77	83	87	93	95	97	97	
		B	42	63	69	70	81	86	92	92	94	94	94	95	95	96	97
		平均	32.5	48.5	61.0	64.5	73.0	80.0	83.5	84.5	88.5	90.5	90.5	94.0	95.0	96.5	97.0
17	14	A	24	37	53	60	67	73	74	79	82	87	89	93	95	95	97
		B	43	65	69	71	82	86	91	92	93	95	94	95	95	95	97
		平均	33.5	51.0	61.0	65.5	74.5	79.5	82.5	85.5	87.5	91.0	91.5	94.0	95.0	95.0	97.0
17	15	A	23	34	52	61	66	71	74	78	81	87	87	91	92	95	96
		B	44	62	69	72	81	86	92	92	94	95	94	95	95	95	97
		平均	33.5	48.0	60.5	66.5	73.5	78.5	83.0	85.0	87.5	91.0	90.5	93.0	93.5	95.0	96.5
17	16	A	22	34	49	60	67	70	73	79	81	88	87	90	94	95	96
		B	45	65	69	72	83	87	93	92	94	95	94	95	95	95	97
		平均	33.5	49.5	59.0	66.0	75.0	78.5	83.0	85.5	87.5	91.5	90.5	92.5	94.5	95.0	96.5
17	17	A	21	32	51	51	60	65	68	76	79	86	85	89	94	93	94
		B	42	62	69	70	82	84	88	91	92	95	94	94	94	94	97
		平均	31.5	47.0	60.0	<u>60.5</u>	71.0	74.5	78.0	83.5	85.5	90.5	89.5	91.5	94.0	<u>93.5</u>	95.5

表 4.10: データセット B について全訓練データを用いて OPCALDA を評価した際の識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
17	1	A	16	<u>34</u>	50	54	62	66	72	76	79	84	86	91	90	95	95
		B	39	57	64	73	80	86	89	91	91	94	93	94	93	94	94
		平均	<u>27.5</u>	<u>45.5</u>	57.0	<u>63.5</u>	71.0	<u>76.0</u>	<u>80.5</u>	<u>83.5</u>	85.0	89.0	89.5	92.5	<u>91.5</u>	94.5	<u>94.5</u>
17	2	A	21	32	49	57	64	69	73	76	78	86	84	91	92	95	97
		B	43	63	69	75	81	85	89	91	90	93	95	96	94	95	96
		平均	32.0	47.5	59.0	66.0	72.5	77.0	81.0	<u>83.5</u>	<u>84.0</u>	89.5	89.5	93.5	93.0	95.0	96.5
17	3	A	18	37	50	60	65	72	74	76	79	87	88	91	94	95	96
		B	44	62	63	75	79	86	89	92	90	94	94	98	96	96	97
		平均	31.0	49.5	56.5	67.5	72.0	79.0	81.5	84.0	84.5	90.5	94.5	95.0	95.5	96.5	96.5
17	4	A	19	37	50	61	64	72	76	78	79	86	88	92	94	95	96
		B	42	62	62	77	78	85	88	90	90	94	94	96	95	97	97
		平均	30.5	49.5	56.0	69.0	71.0	78.5	82.0	84.0	84.5	90.0	91.0	94.0	94.5	96.0	96.5
17	5	A	19	36	52	62	65	72	76	78	80	85	88	92	94	95	96
		B	42	62	63	75	78	85	88	90	90	94	94	97	95	96	97
		平均	30.5	49.0	57.5	68.5	71.5	78.5	82.0	84.0	85.0	89.5	91.0	94.5	94.5	95.5	96.5
17	6	A	19	34	51	63	64	73	75	81	80	86	87	92	94	95	97
		B	43	60	62	75	78	85	88	90	90	94	94	96	95	97	97
		平均	31.0	<u>47.0</u>	56.5	69.0	71.0	79.0	81.5	85.5	85.0	90.0	90.5	94.0	94.5	96.0	97.0
17	7	A	19	35	50	63	65	73	75	81	80	87	87	92	94	95	97
		B	43	61	62	75	79	86	89	91	89	94	94	95	95	96	96
		平均	31.0	48.0	56.0	69.0	72.0	79.5	82.0	86.0	84.5	90.5	90.5	93.5	94.5	95.5	96.5
17	8	A	18	34	50	62	62	70	76	81	80	86	87	92	94	95	97
		B	44	61	61	75	79	86	89	90	89	94	93	95	94	96	96
		平均	31.0	47.5	55.5	68.5	70.5	78.0	82.5	85.5	84.5	90.0	90.0	93.5	94.0	95.5	96.5
17	9	A	19	34	50	62	60	68	76	82	80	86	87	92	94	94	97
		B	44	61	61	74	79	86	89	90	89	94	93	95	94	95	96
		平均	31.5	47.5	55.5	68.0	69.5	77.0	82.5	86.0	84.5	90.0	90.0	93.5	94.0	94.5	96.5
17	10	A	19	34	50	61	60	67	76	82	80	86	87	92	94	94	97
		B	44	62	61	74	80	87	89	91	89	93	93	95	93	94	96
		平均	31.5	48.0	55.5	67.5	70.0	77.0	82.5	86.5	84.5	89.5	90.0	93.5	93.5	94.0	96.5
17	11	A	20	33	51	59	58	66	76	82	80	86	87	92	94	94	97
		B	44	61	61	73	81	87	89	91	89	93	93	95	93	95	96
		平均	32.0	47.0	56.0	66.0	69.5	76.5	82.5	86.5	84.5	89.5	90.0	93.5	93.5	94.5	96.5
17	12	A	19	33	51	60	57	65	76	81	80	86	88	92	94	94	97
		B	44	61	61	73	81	87	90	91	89	93	93	95	93	95	96
		平均	31.5	47.0	56.0	66.5	69.0	76.0	83.0	86.0	84.5	89.5	90.5	93.5	93.5	94.5	96.5
17	13	A	18	33	51	59	56	65	75	81	80	86	88	92	92	94	96
		B	44	62	61	73	81	88	90	90	89	93	93	95	93	95	97
		平均	31.0	47.5	56.0	66.0	<u>68.5</u>	76.5	82.5	85.5	84.5	89.5	90.5	93.5	92.5	94.5	96.5
17	14	A	18	33	50	58	56	65	76	80	81	86	87	92	92	94	96
		B	44	62	61	73	81	88	91	90	89	93	93	94	93	95	97
		平均	31.0	47.5	55.5	65.5	<u>68.5</u>	76.5	83.5	85.0	85.0	89.5	90.0	93.0	92.5	94.5	96.5
17	15	A	18	35	49	57	56	64	76	80	81	86	84	92	92	93	95
		B	44	63	61	73	81	90	91	90	89	93	93	95	93	95	97
		平均	31.0	49.0	<u>55.0</u>	65.0	<u>68.5</u>	77.0	83.5	85.0	85.0	89.5	<u>88.5</u>	93.5	92.5	94.0	96.0
17	16	A	18	35	49	56	56	64	76	79	80	86	84	91	92	93	95
		B	44	63	62	73	81	90	91	90	90	93	93	94	93	95	97
		平均	31.0	49.0	55.5	64.5	<u>68.5</u>	77.0	83.5	84.5	85.0	89.5	<u>88.5</u>	92.5	92.5	94.0	96.0
17	17	A	18	34	49	56	56	63	76	78	79	84	84	91	92	92	95
		B	46	64	62	73	81	90	91	90	90	93	93	93	93	95	97
		平均	32.0	49.0	55.5	64.5	<u>68.5</u>	76.5	83.5	84.0	84.5	<u>88.5</u>	<u>88.5</u>	<u>92.0</u>	92.5	<u>93.5</u>	96.0

表 4.11: データセット B について全訓練データを用いて OLDA を評価した際の識別精度 (%) [56]

各識別器があるシーケンスで達成した最大の値を太字で、また最小の値を下線で示している。

N_c	N_b	被験者	N_s														
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
17	1	A	3	4	2	4	4	5	8	9	11	9	8	14	11	12	15
		B	0	4	4	1	0	1	0	1	4	0	2	2	3	3	3
		平均	<u>1.5</u>	<u>4.0</u>	<u>3.0</u>	<u>2.5</u>	<u>2.0</u>	<u>3.0</u>	<u>4.0</u>	<u>5.0</u>	<u>7.5</u>	<u>4.5</u>	<u>5.0</u>	<u>8.0</u>	<u>7.0</u>	<u>7.5</u>	<u>9.0</u>
17	2	A	20	36	48	55	59	64	73	78	78	90	87	92	92	93	95
		B	35	52	63	63	69	78	82	81	83	88	91	93	89	91	95
		平均	27.5	44.0	55.5	59.0	64.0	71.0	77.5	79.5	80.5	89.0	89.0	92.5	90.5	92.0	95.0
17	3	A	24	39	53	54	62	67	75	77	81	87	88	92	95	95	97
		B	43	65	67	74	78	85	87	87	88	94	94	94	93	93	94
		平均	33.5	52.0	60.0	64.0	70.0	76.0	81.0	82.0	84.5	90.5	91.0	93.0	94.0	94.0	95.5
17	4	A	25	35	52	56	62	68	76	78	82	87	89	95	97	95	97
		B	43	67	67	75	79	85	87	89	89	94	94	94	93	93	94
		平均	34.0	51.0	59.5	65.5	70.5	76.5	81.5	83.5	85.5	90.5	91.5	94.5	95.0	94.0	95.5
17	5	A	25	33	51	55	62	69	76	77	81	87	89	96	96	95	97
		B	43	68	70	75	79	84	87	89	89	94	95	94	94	95	93
		平均	34.0	50.5	60.5	65.0	70.5	76.5	81.5	83.0	85.0	90.5	92.0	95.0	95.0	95.0	95.0
17	6	A	25	31	52	58	64	69	75	78	82	86	91	96	96	96	97
		B	43	67	69	75	79	84	88	89	89	94	95	94	94	94	93
		平均	34.0	49.0	60.5	66.5	71.5	76.5	81.5	83.5	85.5	90.0	93.0	95.0	95.0	95.0	95.0
17	7	A	25	31	51	58	62	69	75	78	82	86	91	96	97	96	97
		B	41	67	70	73	79	85	88	90	89	94	95	94	94	94	93
		平均	33.0	49.0	60.5	65.5	70.5	77.0	81.5	84.0	85.5	90.0	93.0	95.0	95.5	95.0	95.0
17	8	A	24	32	49	59	63	68	76	79	82	86	91	96	95	96	97
		B	40	67	71	73	79	84	88	90	88	94	95	94	94	94	93
		平均	32.0	49.5	60.0	66.0	71.0	76.0	82.0	84.5	85.0	90.0	93.0	95.0	94.5	95.0	95.0
17	9	A	26	34	49	60	63	67	76	79	81	85	91	96	95	96	97
		B	41	66	71	73	79	85	87	90	88	93	95	94	94	93	93
		平均	33.5	50.0	60.0	66.5	71.0	76.0	81.5	84.5	84.5	89.0	93.0	95.0	94.5	94.5	95.0
17	10	A	25	34	48	60	62	67	76	80	81	85	92	96	95	97	97
		B	40	65	70	71	79	86	87	90	88	93	95	94	94	93	94
		平均	32.5	49.5	59.0	65.5	70.5	76.5	81.5	85.0	84.5	89.0	93.5	95.0	94.5	95.0	95.5
17	11	A	24	33	48	60	61	65	77	80	81	86	92	96	96	96	96
		B	40	65	69	71	79	86	87	90	88	93	94	94	94	93	95
		平均	32.0	49.0	58.5	65.5	70.0	75.5	82.0	85.0	84.5	89.5	93.0	95.0	95.0	94.5	95.5
17	12	A	24	31	48	59	59	64	77	81	80	86	92	96	96	95	95
		B	39	65	69	70	80	85	87	90	89	93	92	94	94	92	95
		平均	31.5	48.0	58.5	64.5	69.5	74.5	82.0	85.5	84.5	89.5	92.0	95.0	95.0	93.5	95.0
17	13	A	25	31	48	58	58	64	77	80	80	86	91	96	96	95	95
		B	39	65	69	69	80	85	87	89	88	93	92	94	94	93	95
		平均	32.0	48.0	58.5	63.5	69.0	74.5	82.0	84.5	84.0	89.5	91.5	95.0	95.0	94.0	95.0
17	14	A	25	31	48	59	58	65	76	80	80	84	90	95	96	95	95
		B	40	65	69	70	80	85	87	89	88	93	92	94	93	93	95
		平均	32.5	48.0	58.5	64.5	69.0	75.0	81.5	84.5	84.0	88.5	91.0	94.5	94.5	94.0	95.0
17	15	A	22	31	47	59	59	65	76	80	80	84	89	94	96	95	95
		B	40	65	70	69	80	85	87	89	88	93	92	94	93	92	95
		平均	31.0	48.0	58.5	64.0	69.5	75.0	81.5	84.5	84.0	88.5	90.5	94.0	94.5	93.5	95.0
17	16	A	22	30	47	59	59	65	76	80	80	84	88	94	95	95	95
		B	40	65	70	69	80	85	87	89	88	93	92	94	93	92	95
		平均	31.0	47.5	58.5	64.0	69.5	75.0	81.5	84.5	84.0	88.5	90.0	94.0	94.0	93.5	95.0
17	17	A	22	30	46	59	58	65	76	80	80	83	88	93	95	95	95
		B	40	65	70	69	80	85	87	89	88	93	92	94	93	92	95
		平均	31.0	47.5	58.0	64.0	69.0	75.0	81.5	84.5	84.0	88.0	90.0	93.5	94.0	93.5	95.0

4.4 考察

本研究ではオーバーラップト・パーティショニングを用いて集合識別器を学習する効果を調べるにあたり、従来手法であるナイーブ・パーティショニングを用いた集合識別器と、単一の識別器との識別精度を比較した。特にこれらの識別器の性能の差は 1,000 波形以下の実用的な訓練データ数の時に顕著に現れると想定し、900 波形の訓練データを用いて識別精度を比較した。本研究では独自に取得した ERP-based BCI のデータであるデータセット A と、様々なアルゴリズムの検証に用いられているデータセット B (BCI competition III data set II) を用いて比較した。比較にはステップワイズ法 (SW)、主成分分析 (PCA) と何も施さない状態の 3 つで学習した LDA の集合識別器 (OSWLDA、OPCALDA 及び OLD A) を用い、次元削減による影響も調べた。オーバーラップト・パーティショニングはパラメータによっては、ナイーブ・パーティショニングを用いた集合識別器や単一の識別器と等価になることから、この性質を利用してこれらの識別器との比較も同時に行った。

4.4.1 訓練データが少ない場合

提案手法は訓練データが 900 波形の小さい場合に対して有効であった。データセット A を用いて評価した結果、OSWLDA は 900 波形の訓練データで学習させた場合 (4.3.1)、単一の SWLDA やナイーブ・パーティショニングで学習した SWLDA の集合識別器より性能が高くなった。その傾向は図 4.9 に示すように $N_b = 4$ 、 $N_s = 5$ の場合に単一の識別器 (SWLDA) より 4.8%、ナイーブ・パーティショニングで学習した SWLDA の集合識別器より 15% 高い識別精度を示した。データセット B を用いて評価した場合にも図 4.10 のように同様の結果が見られ、900 波形の訓練データを用いて評価した場合、OSWLDA 及び OPCALDA では $N_b = 3, 4$ において最大の平均識別精度を示した (4.3.3)。これらの結果はオーバーラップト・パーティショニングを用いて訓練した識別器は小さい訓練データに対して効果的であることを示唆する。

4.4.2 次元削減による影響

訓練データが少ない場合に性能が向上したが、これはオーバーラップト・パーティショニングと次元削減法の両者の影響を受けていると考える。図 4.6 に示すデータセット A の平均識別精度曲線は N_b を変化させることで識別精度が変化するが、次元削減法によりその変化の具合も異なった。また、図 4.6(c) に示す OLD A は次元削減をしていない集合識別

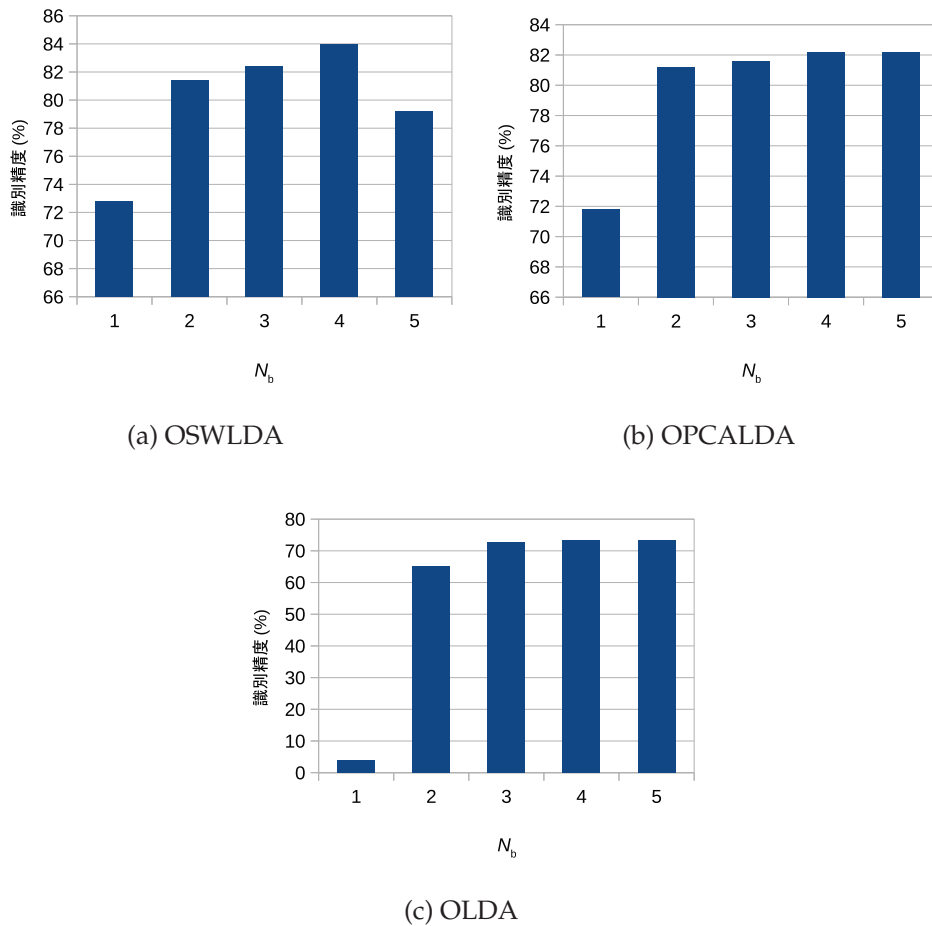


図 4.9: データセット A を 1/10 交差確認法で評価した際の主要な結果
 図は (a) OSWLDA、(b) OPCALDA、(c) OLDA でそれぞれデータセット A を 1/10 交差確認法を用いて解析した際の $N_s = 5$ における平均識別精度である。

器であるが、この場合、識別精度はオーバーラップト・パーティショニングを用いて学習した集合識別器であるにも関わらず単一の識別器の性能を大きく上回ることはなかった。一方で OSWLDA、OPCALDA 及び OLDA の $N_b = 1$ はナイーブ・パーティショニングを用いて集合識別器を学習した場合の性能であるが、この結果からも次元削減法だけでは集合識別器の性能向上を測れないことがわかる。データセット B に関しても表 4.6、4.7、4.8 から読み取れるように、次元削減なしでオーバーラップト・パーティショニングのみを用いて訓練した OLDA や、 $N_b = 1$ のナイーブ・パーティショニングを用いた OSWLDA や OPCALDA は偶然確率に近い識別精度を示した。以上より、識別精度向上の理由は単にオーバーラップト・パーティショニングを用いて集合識別器を訓練したことや、次元削減法を用いたこと単体ではなく、その両方による効果であるといえる。




図 4.10: データセット B を制限された訓練データで評価した際の主要な結果
 図は (a) OSWLDA、(b) OPCALDA、(c) OLDA でそれぞれデータセット B を制限された訓練データを用いて解析した際の $N_s = 12$ における平均識別精度である。

4.4.3 訓練データが多い場合

8,000 波形以上を訓練データとして計測するのは記録時間が長くなりすぎて実用的ではないが、そのような場合に集合識別器はどのような振る舞いをするのかを検討した。データセット A、B それぞれ大きな訓練データを用いて評価したが、データセット A については単一の識別器とほぼ同程度の性能、データセット B に関しては単一の識別器より 3% 程度の識別精度向上しか見られなかった。データセット A を 9/10 交差確認法で評価した場合、集合識別器を学習するための訓練データ数は 8,100 波形となる。この場合、訓練データ数が十分にあり、次元削減前の特徴ベクトルの次元も 240 次元程度であるため過学習が生じずオーバーラップ・パーティショニングを用いた集合識別器は単一の識別器と同程度の識別精度しか達成できなかった可能性がある。また、データセット B を 15,300 波形全

てを利用して学習した場合、訓練データ数が十分にあるものの、次元削減前の特徴ベクトルの次元が 896 次元であるためわずかに過学習が生じていたために 3%程度の識別精度向上が見られたと考える。

4.4.4 オーバーラップト・パーティショニングのパラメータ決定方法

オーバーラップト・パーティショニングのパラメータである N_c と N_b の決め方は訓練データの数や特性に依存するため、通常の交差確認法を用いてパラメータを決定するのがよい。しかしながらこの方法だと、脳波を記録してから識別器を訓練するまでに時間が生じてしまう。そこで、本研究で比較的高い識別精度を出した N_b と N_c の比率 (N_b/N_c) が 0.8 になるように決める方法を提案する。訓練データが十分与えられている場合は理想的な状況ではあるが、実際にそのような場合は少ない。そのため、900 波形で評価した場合に高い識別精度を達成するパラメータを設定するのがよい。また、次元削減手法とオーバーラップト・パーティショニングの相互作用の考察から、次元削減手法が使用されている OSWLDA と OPCALDA でよい識別精度が出るようにパラメータを調整するのが良い。データセット A では $N_c = 5$, $N_b = 4$ 、データセット B では $N_c = 5$, $N_b = 3$, 4 で単一の識別器より高い識別精度が得られていた。そのため $N_b/N_c \approx 0.8$ となるように N_c と N_b を選ぶことで妥当な識別結果が得られると考える。

4.4.5 識別器の数を変化させた場合

本研究では識別器の数 N_c は固定したまま、 N_b を変化させてオーバーラップト・パーティショニングの効果を調べたが、先行研究では N_c の数によっても識別器を変化させた場合の SWLDA の集合識別器が評価されている [91]。しかしながらその手法ではナイーブ・パーティショニングが用いられており、 N_c を増やすに連れて識別性能が低下するという結果を示している。オーバーラップト・パーティショニングを用いて、かつ識別器の数 N_c を増やすことであるパーティションに含まれる訓練データ数が極端に少なくなる場合がなくなり、さらなる性能の向上が見込まれる。本研究では N_b を変化させた場合における性能の変化を調べることが目的であるので N_c の数を変化させることによる影響の調査は行っていない。

4.4.6 刺激シーケンス数、訓練データ数の決定方法

本研究では従来の ERP-based BCI のための集合識別器を学習するためのナイーブ・パーティショニングを実用的な訓練データ数である 900 波形で評価したが、ナイーブ・パーティ

ショニングは LDA の集合識別器を学習するには不十分であることがわかった。もしナイーブ・パーティショニングを用いて LDA の集合識別器を学習するのであれば 900 波形より多くの訓練データが必要になることを示唆する。

オーバーラップト・パーティショニングによる改善効果はシーケンス数が中間 (5~10 程度) で顕著に見られた。図 4.6 の識別精度曲線で N_b を変化させた際に N_s が中間の時に高い識別精度が得られる様子が伺える。この結果は試験データが 1、2 シーケンス分程度であれば識別精度が非常に低いが、3~7 シーケンス分を使えば識別器によってはそれでも十分識別できるようになり、それ以降で全ての識別器が十分な識別精度を出せるようになり識別精度がシーケンス数に依存しなくなることを示す。この特性から早く立ち上がるものほど少ない試験データで動作することになり、命令を出力するまでの時間を短縮できるため、よりよい識別器であると判断できる。

ERP-based BCI におけるシーケンス数の決定は、応用する際にどの程度の識別性能または出力時間が必要かに依存する。シーケンス数は識別精度と出力時間に関するパラメータである。例えば精密さを要するロボットを BCI で制御する際は出力時間がかかっても良いので高い識別精度が必要である。一方で正確さはそこそこでも早く入力できる方がよいという場合もある。したがって反復回数の決定はどのようなものに応用するかによって変えるのが良い。

必要な訓練データ数もやはり何に応用するかによって決めるのが良い。訓練データ数は訓練時間と識別精度に関わるパラメータである。訓練時間を十分取れる場合は、当然多くの訓練データを取得すれば識別精度が高くなる。一方で訓練時間をあまり取れないのであれば、目的の識別精度を得られる最低限の訓練データ数を確保すれば良い。識別精度を犠牲にしてまで無理に訓練データを少なくする必要はない。

4.4.7 オーバーラップト・パーティショニングを用いて性能が向上した理由

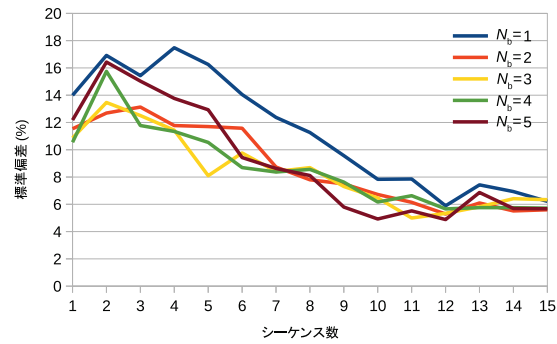
オーバーラップト・パーティショニングは訓練データを文字単位 (ある標的文字に対応する 180 波形) のブロックに分割した上でランダムではない手法で重複を許してリサンプリングすることによって新たな訓練データの部分集合 (パーティション) を作成して集合識別器を学習する手法である。機械学習におけるバギング [96] は訓練データを重複してランダムにリサンプリングすることで多様な識別器を学習させる手法であるため、提案手法はバギングと類似する手法であると解釈することができる。バギングはデータ集合の選び方による平均値のずれ、すなわちバリエーション誤差 [78] を低下させる手法である。オーバーラップト・パーティショニングはバギングとは異なり標的文字単位でデータをリサンプリング

しているため、標的文字の違いにより生じたわずかな脳波の違いを考慮して誤差を低減させることができると考える。そのためオーバーラップ・パーティショニングを用いることで ERP-based BCI に特有で生じる誤差を低下させる効果があると考えられる。通常、LDA は安定的であり集合識別器に用いてもバリエーション誤差を減らすことに貢献しないと考えられている。ところが ERP-based BCI の訓練データ数は標的 ERP に比べて標準 ERP のほうが圧倒的に多く、またデータのばらつき具合も異なるクラス不均衡問題でもある。さらに次元削減法も訓練データの違いにより異なる学習結果が得られるが、オーバーラップ・パーティショニングによる影響は次元削減法にも及ぶ。そのため過学習が起きやすいデータを扱っており、その状況でオーバーラップ・パーティショニングが次元削減法と弱学習器に作用して識別精度が向上したと考える。


4.4.8 オーバーラップ・パーティショニングが標準偏差に与える影響

本研究で用いたオーバーラップ・パーティショニングは標準偏差を下げるのに貢献している可能性がある。そのため本研究で用いた3つの識別器のそれぞれの条件での標準偏差の平均値を可視化した。


図 4.11(a) に OSWLDA の標準偏差を示す。図よりシーケンス数が1回から5回までは単一の識別器より標準偏差が小さくなっているが、それ以降では単一の識別器とほぼ同等の標準偏差になっている。図 4.11(b) に OPCALDA を用いた場合を示すが、シーケンス数が6回から9回においてはわずかに標準偏差が減少しているが、集合識別器と単一の識別器の間に大差は見られない。図 4.11(c) に示す次元削減を用いなかった場合 (OLD) も同様であるが、むしろ過学習により偶然確率となった場合の標準偏差のほうが小さいことがわかる。また標準偏差の変化は、図 4.6 に示す平均識別精度と反比例して変化している傾向が読み取れる。以上よりステップワイズ法を用いた場合にシーケンス数が3回から5回で標準偏差が小さくなっている傾向が確認できたが、提案手法により標準偏差が劇的に減少しているわけではない。



(a) OSWLDA



(b) OPCALDA



(c) OLDA


図 4.11: 提案集合識別器における標準偏差

データセット A を 1/10 交差確認法で評価した際、(a) OSWLDA、(b) OPCALDA、(c) OLDA の標準偏差の平均値を各重複度合い (N_b) ごとに求めた。


4.4.9 ステップワイズ法によって選ばれる次元数とオーバーラップト・パーティショニングの関係

ステップワイズ法を各パーティションのデータに用いると、選ばれる特徴量の数が多い、または少ないことにより識別器の性能が変化する可能性がある。ステップワイズ法は訓練データより学習を行うが、データの性質や被験者、データの数などにより選ばれる特徴量や、選択される次元数が異なるため、オーバーラップト・パーティショニングでパーティションを変化させた時に次元数が変化したことが識別精度向上の原因になりうる。そこで OSWLDA について、オーバーラップト・パーティショニングの重複度合い (N_b) ごとに選ばれた特徴量の数の影響について調べた。

データセット A について 900 波形の訓練データを用いて OSWLDA を学習し、識別精度を評価した際、ステップワイズ法により選択された特徴量の数を全被験者について求め、その平均値をそれぞれオーバーラップト・パーティショニングの重複度合い (N_b) ごとに計算した。データセット B についても同様に解析を行った。図 4.12(a) よりデータセット A では、ステップワイズ法に選ばれた特徴量の数は N_b の増加により単調に増加することがわかった。また、識別精度が良かった $N_b = 4$ ではその次元の数が最大、最小となっておらず、他の条件と比較して特殊な状況になっていなかった。図 4.12(b) よりデータセット B ではデータセット A の結果とは逆に、ブロック数が増える選ばれる特徴量が減っていくことがわかる。識別精度は $N_b = 4$ の時に最良であったが、その時に次元が最大、最小となっていなかった。従って本研究の成果は単にステップワイズ法による次元削減による特徴量の数の変化によりもたらされた効果だけではないと考える。



(a) データセット A



(b) データセット B

図 4.12: オーバーラップト・パーティショニングとステップワイズ法により選択される次元数との関係

図はオーバーラップト・パーティショニングの重複度合い (N_b) ごとにステップワイズ法により選ばれる次元の数の平均値を示している。(a) はデータセット A を 1/10 交差確認法で評価した際、各訓練データより得られたステップワイズ法により選択される次元の数を全ての被験者について平均値をもとめたものを示す。ここで、エラーバーは標準偏差を示す。(b) はデータセット B を制限された訓練データでステップワイズ法を学習させた際に選ばれる次元の数の平均値を示す。データセット B は被験者が 2 名であるためエラーバーを表示していない。

4.4.10 主成分分析を用いた場合に使用する次元数、累積寄与率と識別精度の関係


本研究で用いた OPCALDA では主成分分析を併用して次元削減したが、その際に使用する主成分の数をデータセット A では第 140 主成分まで、データセット B では第 400 主成分までを用いた。そのパラメータは経験的に決めたものであるが、使用した主成分の数は妥当であったかを検討する必要がある。そこで使用する主成分の数と識別精度の関係を調べた。

使用する主成分の数と識別精度の関係をデータセット A、B それぞれについて求めた。その結果を図 4.13 に示す。データセット A についての解析結果を図 4.13(a) に示すが、それを見ると主成分の数を変化させると主成分の数が N_b による識別精度の違いが観測できた。今回用いた使用する主成分の数が 140 個の場合は N_b による識別精度の違いは観測できなかったが、例えば 120 個、130 個の場合には $N_b = 4$ の時が他の N_b 値の識別精度に比べ大きくなっていった。図 4.13(b) にデータセット B について解析した結果を示すが、こちらも同様に主成分の数を変化させることによって N_b による識別精度の違いが現れた。以上の結果から、主成分の選び方によってはオーバーラップト・パーティショニングの効果が見られた顕著に見られることがわかった。


図 4.12 に示すステップワイズ法による次元数と、図 4.13 より読み取れる最適な主成分の数を比較すると、ステップワイズ法により選ばれる次元数が主成分分析を用いた解析の場合より少ないことがわかる。このことは最適な次元数は次元削減法に依存することを意味する。また、図 4.13 で最大の識別精度が得られる主成分の数が N_b により異なる事がわかる。加えて図 4.12 よりステップワイズ法において選ばれる次元の大きさも N_b により変化する。従って N_b の変化によっても最適な次元数が変化することがわかる。これより最適な次元数の決定にも次元削減法とオーバーラップト・パーティショニングの両者が共に影響するため、オーバーラップト・パーティショニングの効果は必ずしも次元削減の方法によるものではないと考える。

また、使用する主成分の数を累積寄与率により決定できるかどうかを検討するため、使用する主成分の数と累積寄与率の関係を調べた。図 4.14(a) にデータセット A、被験者 1 の累積寄与率と使用する主成分の数の関係を示す。主成分の数が 140 個の場合は累積寄与率が約 98% となっている。使用する主成分の数が 140 個のときの累積寄与率とほとんど変わらない 120 個、130 個の場合では、オーバーラップト・パーティショニングの効果が見られた。図 4.14(b) にデータセット B の被験者 A の累積寄与率を示す。使用する主成分の数

が 200 個を超えると累積寄与率は 100% 近くまで飽和してしまうが、図 4.13(b) では N_b の変化により識別精度の差が見られた。以上よりオーバーラップ・パーティショニングの効果は必ずしも累積寄与率と関係があるわけではない。また図 4.14(a) と図 4.13(a) を比較すると、累積寄与率を 98% より下げると単に識別精度が低下する。また、98% 以上であればよいわけではなく、使用する主成分の数を例えば 200 個に増やすとより明らかに性能が低下することがわかる。図 4.14(b) と図 4.13(b) を比較しても同様な結果が得られる。このように識別精度と使用する次元の数の関係が図 4.13 のように山なりになっているため、累積寄与率より次元を決定するのは難しいと考える。識別精度と使用する次元の数の関係が山なりになる理由は、使用する主成分の数が少なくモデルが簡素過ぎる場合の性能低下と、使用する主成分の数が多くモデルが複雑過ぎる場合の過学習による性能低下によるものと考えられる。従って累積寄与率を求めても最適な次元数の決定の指標にはならないと考える。




(a) データセット A




(b) データセット B

図 4.13: 使用する主成分の数と識別精度の関係

OPCALDA において使用する主成分の数を変化させて、(a) データセット A、(b) データセット B それぞれに訓練データが 900 波形の場合の識別精度を求めた。使用する主成分は第 1 主成分から使用する主成分の数まで連続して選択した。



(a) データセット A



(b) データセット B

図 4.14: 使用する主成分の数と累積寄与率

OPCALDA において使用する主成分の数を変化させて、(a) データセット A、被験者 1、1/10 交差確認法の始めの訓練データについて、(b) データセット B、被験者 A の制限された訓練データについての累積寄与率を求めた。

4.4.11 オーバーラップト・パーティショニングがステップワイズ法と弱学習器に与える影響

OSWLDA で顕著な識別精度の向上が見られたが、オーバーラップト・パーティショニングはどのようにステップワイズ法や弱学習器に影響していたのかについて考察する。その際、ステップワイズ法も後続する弱学習器に影響を及ぼすため、影響の関係が煩雑になる。図 4.15 は提案する OSWLDA において、オーバーラップト・パーティショニングとステップワイズ法がどのように影響を及ぼすのかを示したものである。オーバーラップト・パーティショニングは次元削減法と弱学習器それぞれを学習する際に、パーティションに分割するため、ステップワイズ法に影響する。そして各パーティションのデータに個々のステップワイズ法を用いたもので LDA を学習する。そのためオーバーラップト・パーティショニングはステップワイズ法と弱学習器に影響する。また、各ステップワイズ法は後続する弱学習器に影響する。この構造から明らかなように、OSWLDA で効果があったのはオーバーラップト・パーティショニングとステップワイズ法の両方の効果が複雑に絡み合っており、どちらがどれだけ効果を及ぼしたかを考察することは困難である。しかし、オーバーラップト・パーティショニングがステップワイズ法と弱学習器にどの程度影響を与えるかについて考察することができる。

OSWLDA においてステップワイズ法にオーバーラップト・パーティショニングを用いないようにすることは可能であるため、ステップワイズ法にオーバーラップト・パーティショニングを用いない場合の考察を行うことができる。その学習の流れを図 4.16 に示す。この状態で $N_b = 4$ と、 $N_b = 5$ を比較することでステップワイズ法にオーバーラップト・パーティショニングが影響せず、弱学習器にのみ影響する場合の識別精度をデータセット A、1/10 交差確認法を用いて計算した。

以上の解析より、オーバーラップト・パーティショニングは弱学習器にあまり影響しないことがわかった。図 4.17 にその結果を示す。図を見ると $N_b = 4$ と、 $N_b = 5$ であまり変化がない事がわかる。この結果は集合識別器のバリエーション誤差を減らす効果が弱学習器に起因するバリエーション誤差に対して低いことを示している。これより集合識別器のバリエーション誤差を減らす効果がステップワイズ法に対して大きいと予想できる。

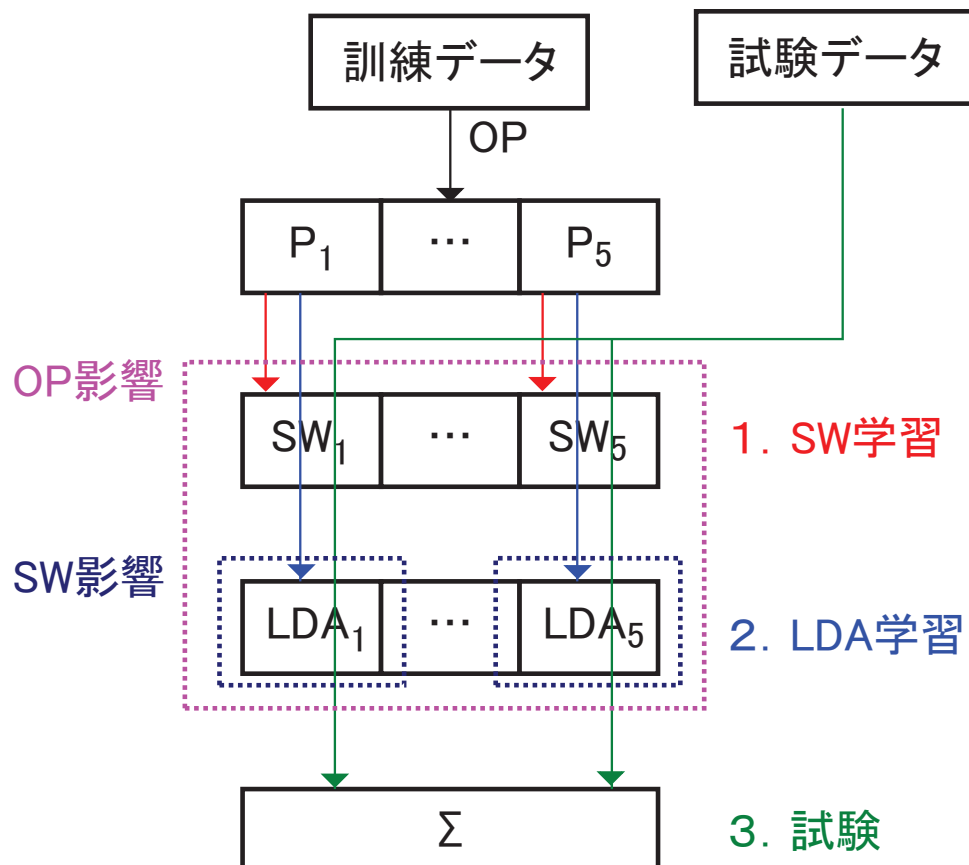


図 4.15: OSWLDA におけるオーバーラップト・パーティショニングとステップワイズ法の影響範囲

図は OSWLDA においてオーバーラップト・パーティショニング (OP) とステップワイズ法 (SW) の影響範囲を示している。図中の P はパーティション、 Σ は結果の統合を指す。各 SW と各 P はそれぞれ互いに異なるため、添字でその違いを示している。赤、青、緑の線はそれぞれ SW、LDA、試験時のデータの流れを示す。桃色、紺色の破線はそれぞれ OP と SW の影響範囲を示す。

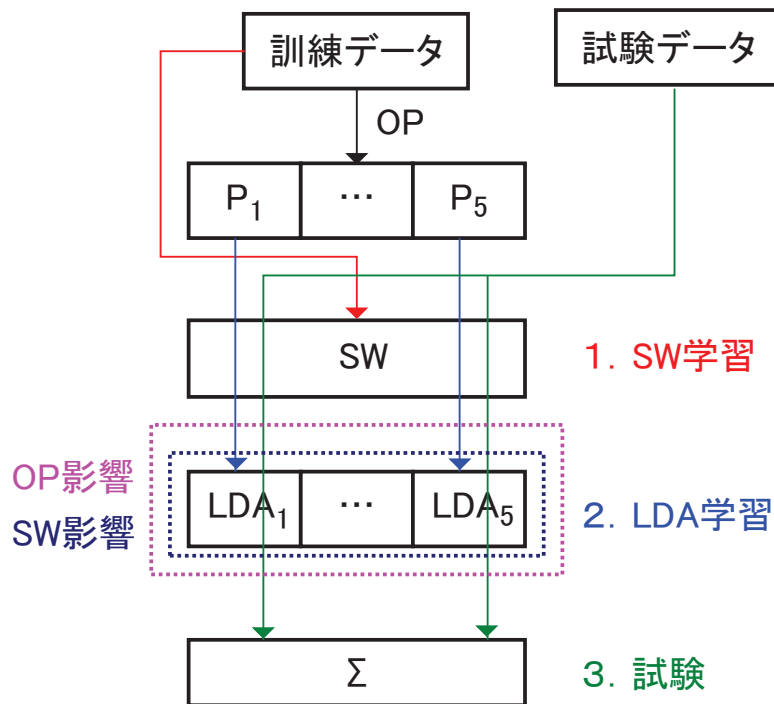


図 4.16: ステップワイズ法 (SW) 外出し型 OSWLDA の識別精度

提案する OSWLDA を変形し、パーティションではなく全訓練データでステップワイズ法 (SW) を学習させることにより SW にオーバーラップト・パーティショニング (OP) が影響しない場合での評価が可能である。

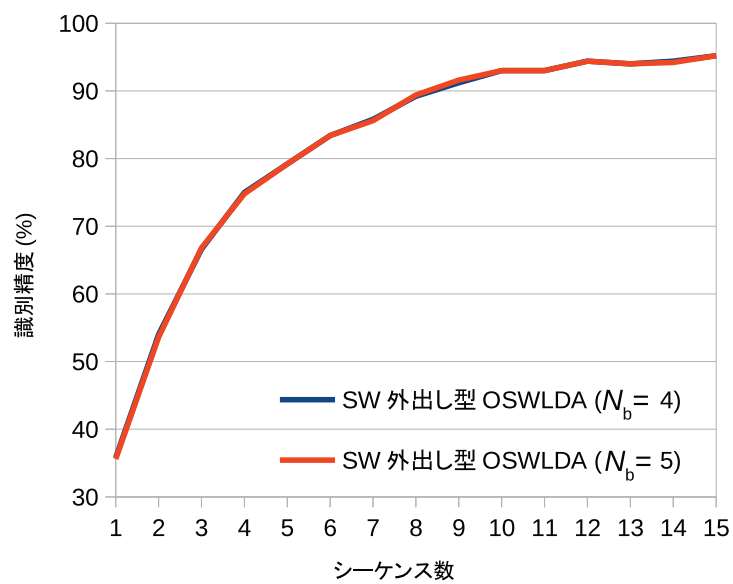


図 4.17: ステップワイズ法 (SW) 外出し型 OSWLDA の識別精度

SW 外出し型 OSWLDA の識別精度において、 $N_b = 4$ と、 $N_b = 5$ を比較した。なお $N_b = 5$ の場合は単一の SWLDA と等価になる。

提案手法においてオーバーラップト・パーティショニングをステップワイズ法に作用させることが重要であることがわかったが、識別精度向上には下記の2つの可能性が考えられる。

- オーバーラップト・パーティショニングがステップワイズ法に作用し、ステップワイズ法に加えさらにオーバーラップト・パーティショニングによるパーティション内のデータの違いが LDA に大きく作用している。
- オーバーラップト・パーティショニングがステップワイズ法に作用し、オーバーラップト・パーティショニングによるパーティション内のデータの違いではなくステップワイズ法により選ばれた特徴の違いが主に LDA に影響している。

これを明らかにするため、まず図 4.18 に示す LDA 全データ学習型 OSWLDA と、図 4.15 に示す提案手法との比較を行い、ステップワイズ法で次元削減した全データを用いて LDA を学習させる場合と、パーティショニングしたデータを用いて LDA を学習させる場合を比較した。なお、どちらもオーバーラップト・パーティショニングが作用したステップワイズ法を用いているため、どちらも LDA にオーバーラップト・パーティショニングが作用していることになる。

その結果、図 4.19 のように提案手法がより高い識別精度を示すが、LDA 全データ学習型 OSWLDA と大差がないことがわかった。オーバーラップト・パーティショニングを用いたほうがわずかに良いので弱学習器にパーティショニングされたデータを入れるほうがよいのだが、それほど識別精度が改善されていない。従ってオーバーラップト・パーティショニングをステップワイズ法に作用させた後では、オーバーラップト・パーティショニングによるパーティション内のデータの違いの影響は直接的に LDA に対して少なく、ステップワイズ法により選ばれた特徴の違いが主に LDA に影響していると考えられる。

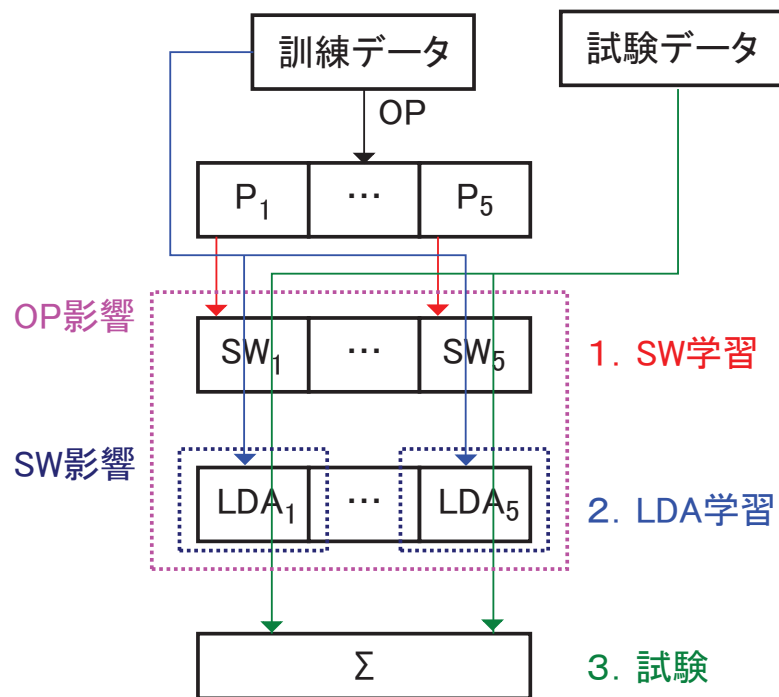


図 4.18: LDA 全データ学習型 OSWLDA

LDA 全データ学習型 OSWLDA はまずオーバーラップト・パーティショニング (OP) により得られたパーティション ($P_1 \sim P_5$) で複数のステップワイズ法 (SW) を学習し、その後、全訓練データを各 SW で次元削減した上で LDA を学習させる。SW には OP が影響しているため、全訓練データを使用しても SW を個別に用いているため LDA に OP の影響が及んでいる。

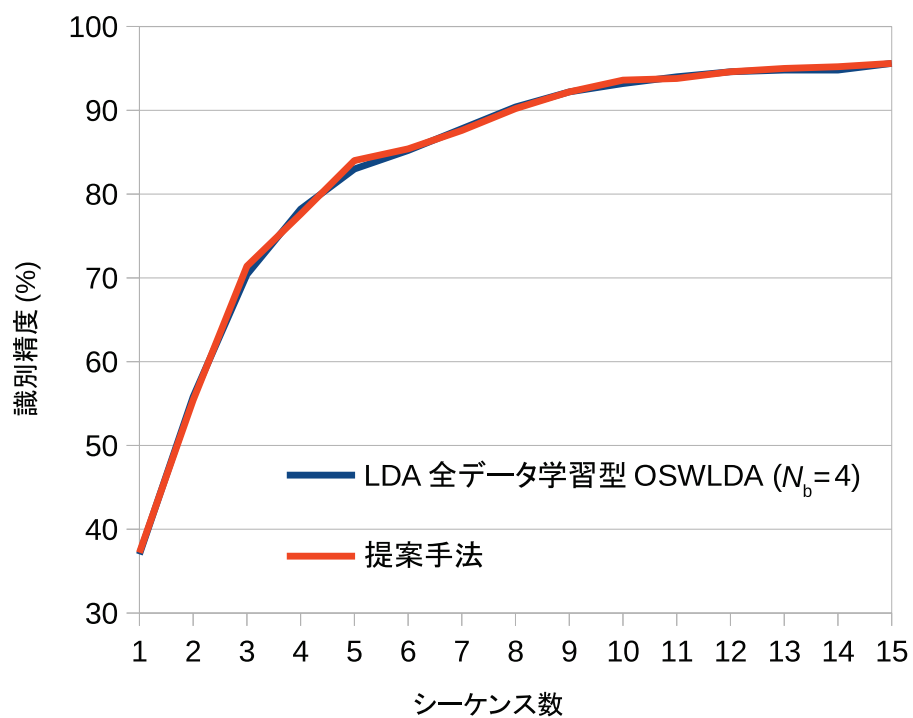


図 4.19: LDA 全データ学習型 OSWLDA と提案手法との比較

図はデータセット A を 1/10 交差確認法で評価した際の LDA 全データ学習型 OSWLDA と提案手法である OSWLDA それぞれの $N_b = 4$ における識別精度を示す。

4.4.12 展望

本研究では集合識別器の弱識別器として LDA を用いたが、他の識別器を応用することも考えられる。たとえば正則化 LDA[84] や、ベイジアン LDA[74] は LDA で用いる共分散行列を修正することで識別器が過学習することを避けるものであり、小さい訓練データや高次元データに対して効果的な手法である。これらの集合識別器はオーバーラップト・パーティショニングを用いて学習することでさらなる性能向上を見込むことができる。

また、本研究で用いたオーバーラップト・パーティショニングはあるブロックから連続する複数のブロックを選択することにより一定の数の識別器を学習する手法であった。しかしながら、連続して取り出すという制限をなくすことでより多くのパーティションを生成することができる。例えば5のブロックの中から3つのブロックを取り出してパーティションにするような組み合わせは10通りあるので、最大で10個の互いに異なる識別器を作成することができる。また、文字単位ではなく波形単位で集合識別器を作る方法を考案することも可能である。上記のような修正したオーバーラップト・パーティショニングを用いることで ERP-based BCI の識別精度が向上すると期待できる。

本研究で使用したオーバーラップト・パーティショニングを用いた集合識別器は ERP-based BCI 以外に応用することもできると考える。例えば ERD/ERS-based BCI に集合識別器を用いた先行研究があり [101]、本研究で用いたオーバーラップト・パーティショニングも同様に使用できると考える。その他にも、ガン細胞の識別 [102] や fMRI データの解析 [103] にも集合識別器が使用されており、提案手法を導入することで訓練データ数が少なくデータの次元が大きい場合に高い識別性能が得られると期待できる。

4.5 まとめ

本章では ERP-based BCI のための識別器を集合識別器に拡張し、従来の集合識別器に関する研究をより性能の高いものにするために評価する際に使用した訓練データが実際に近い 900 波形にし、また特定のデータに依存せず幅広く応用することのできるオーバーラップト・パーティショニングを提案した。本研究では識別器を訓練するためのパーティションの重複具合を変化させ、その影響について調べた。その結果、一般的に使われている訓練データ数より小さい 900 波形の訓練データで評価した際、次元削減法であるステップワイズ法や PCA と合わせた場合、オーバーラップト・パーティショニングにより改善効果が見られた。一方で、訓練データが 8,100 波形、15,300 波形と十分に与えられている場合は改善効果が見られなかった。以上の結果より、オーバーラップト・パーティショニングを

98 第4章 オーバーラップト・パーティショニングを用いた ERP-based BCI の集合識別器

用いた集合識別器は訓練データが 900 波形と小さい場合や、8,100 波形以上の大きい場合に適応可能であり特に訓練データが小さい時に見られる過学習に対する改善効果が見られることがわかった。

第5章 結語

本研究では事象関連電位を用いた BCI、すなわち ERP-based BCI のための集合識別器を学習するための手法として、与えられた少ない訓練データ (900 波形) から重複を許して訓練文字単位で分割する手法であるオーバーラップト・パーティショニングを提案し、評価した。従来手法は訓練データが 15,300 波形と多い場合でしか評価されておらず、また従来手法であるナイーブ・パーティショニングはそのデータに特化した形でしか用いられておらず、訓練データが小さい場合 (900 波形) はどのように用いるのかなどについて議論されていなかった。本研究ではそれらの問題に対処し、小さい訓練データ (900 波形)、大きい訓練データ (8,100 波形以上) に対しオーバーラップト・パーティショニングによりリサンプリングして集合識別器を訓練して評価した。また、通常の ERP-based BCI データは高次元データであるため、典型的に用いられるステップワイズ法や主成分分析を用いた場合と、次元削減しない場合での影響を評価した。評価する際は集合識別器の重複度合いに関するパラメータ (N_b) を変化させて 3 種類の次元削減条件のもとで評価した。その結果、小さい訓練データで学習した場合に、ステップワイズ法もしくは主成分分析と、オーバーラップト・パーティショニングを用いた集合識別器を用いることで性能が向上することが確認できた。特にステップワイズ法を用いた場合には顕著であった。本研究結果は ERP-based BCI の識別精度を向上させることや、訓練時間を削減することに貢献する。また、ERP-based BCI のための集合識別器を学習するための手法は小さい訓練データ (900 波形) で評価されてこなかったが、本研究で用いたオーバーラップト・パーティショニングを用いることで効果的に学習できることが明らかになり、大きい訓練データから小さい訓練データまでのパーティショニング方法が明確になった。

謝辞

本研究を多大な時間を費やし、懇切なるご指導ご鞭撻を賜りました九州工業大学大学院生命体工学研究科の夏目季代久教授に心から感謝の意を示します。また、本論文を作成するにあたり、時間を割いてご検討、ご助言を頂きました九州工業大学大学院生命体工学研究科の副査の先生方に深くお礼申し上げます。実験に協力していただいた九州工業大学大学院生命体工学研究科の夏目研究室諸氏、ならびに勉学を支えてくれた家族にも深くお礼申し上げます。

参考文献

- [1] 宇土 博 (編集), **福祉工学入門一人と福祉・介護機器の調和を科学する**. 労働調査会, 2005.
- [2] E. Donchin, K. M. Spencer, and R. Wijesinghe, "The mental prosthesis : Assessing the speed of a P300-based brain-computer interface," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 174–179, 2000.
- [3] 神作 憲司, **脳波で操作する環境制御システムの開発, 次世代ヒューマンインタフェース開発最前線**. エヌ・ティー・エス, 2013.
- [4] A. Rakotomamonjy and V. Guigue, "BCI competition III: dataset II- ensemble of SVMs for BCI P300 speller," *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 3, pp. 1147–1154, 2008.
- [5] 櫻井 芳雄, 八木 透, 小池 康晴, 鈴木 隆文, **ブレイン—マシン・インタフェース最前線 一脳と機械をむすぶ革新技術**. 工業調査会, 2007.
- [6] J. K. Chapin, K. A. Moxon, R. S. Markowitz, and M. A. L. Nicolelis, "Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex," *Nature Neuroscience*, vol. 2, no. 7, pp. 664–670, 1999.
- [7] M. A. Lebedev and M. A. L. Nicolelis, "Brain-machine interfaces: past, present and future," *Trends in Neurosciences*, vol. 29, no. 9, pp. 536–546, 2006.
- [8] 村田 昇, **入門 独立成分分析**. 東京電機大学出版, 2004.
- [9] 宮内 哲, "脳を測る : 改定ヒトの脳機能の非侵襲的計測," *心理学評論*, vol. 56, no. 3, pp. 414–454, 2013.
- [10] A. Cichocki, Y. Washizawa, T. Rutkowski, H. Bakardjian, A. H. Phan, S. Choi, H. Lee, Q. Zhao, L. Zhang, and Y. Li, "Noninvasive BCIs: multiway signal-processing array decompositions," *Computer*, vol. 41, no. 10, pp. 34–42, 2008.

- [11] M. J. Bryan, S. A. Martin, W. Cheung, and R. P. N. Rao, "Probabilistic co-adaptive brain-computer interfacing," *Journal of Neural Engineering*, vol. 10, no. 6, p. 066008, 2013.
- [12] T. S. Rached and A. Perkusich, "Emotion recognition based on brain-computer interface systems," in *Brain-Computer Interface Systems - Recent Progress and Future Prospects*. Intech, 2013, pp. 254–270.
- [13] S. Lee, Y. Shin, S. Woo, K. Kim, and H. Lee, "Review of wireless brain-computer interface systems," in *Brain-Computer Interface Systems - Recent Progress and Future Prospects*. InTech, 2013, pp. 215–238.
- [14] S. Toyama, K. Takano, and K. Kansaku, "A non-adhesive solid-gel electrode for a non-invasive brain-machine interface," *Frontiers in Neurology*, vol. 3, no. July, p. 114, 2012.
- [15] S. Ikegami, K. Takano, M. Wada, N. Saeki, and K. Kansaku, "Effect of the green/blue flicker matrix for P300-based brain-computer interface: An EEG-fMRI study," *Frontiers in Neurology*, vol. 3, p. 113, 2012.
- [16] R. Sitaram, S. Lee, S. Ruiz, M. Rana, R. Veit, and N. Birbaumer, "Real-time support vector classification and feedback of multiple emotional brain states," *NeuroImage*, vol. 56, no. 2, pp. 753–765, 2011.
- [17] J. Mellinger, G. Schalk, C. Braun, H. Preissl, W. Rosenstiel, N. Birbaumer, and A. Kübler, "An MEG-based brain-computer interface (BCI)," *NeuroImage*, vol. 36, no. 3, pp. 581–593, 2007.
- [18] 三原 雅史, 畠中 めぐみ, 宮井 一郎, "NIRS を用いた脳機能評価の現状," *脳循環代謝*, vol. 18, pp. 165–169, 2006.
- [19] S. Sanno, T. Misawa, T. Shimokawa, and S. Hirobayashi, "NIRS-based brain-computer interface for cursor control using brain activity in the prefrontal cortex," in *Proceedings of the Asia Pacific Industrial Engineering & Management Systems Conference 2012*, 2012, pp. 1440–1446.

-
- [20] B. Koo, H. G. Lee, Y. Nam, H. Kang, C. S. Koh, H. C. Shin, and S. Choi, "A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery," *Journal of Neuroscience Methods*, 2014.
- [21] 入戸野 宏, *心理学のための事象関連電位ガイドブック*. 北大路書房, 2009.
- [22] 堀 浩, 下河内 稔, 西浦 信博, 高橋 光雄, 井上 健, *脳波・筋電図用語辞典*. 永井書店, 1999.
- [23] 市川 忠彦, *脳波の旅への誘い—楽しく学べるわかりやすい脳波入門—*. 星和書店, 2006.
- [24] E. Formaggio, S. Francesca, A. Bertoldo, P. Manganotti, A. Fiaschi, and G. Maria, "Integrating EEG and fMRI in epilepsy," *NeuroImage*, vol. 54, no. 4, pp. 2719–2731, 2011.
- [25] K. Kubo and H. Nittono, "The role of intention to conceal in the P300-based concealed information test," *Applied Psychophysiology and Biofeedback*, vol. 34, no. 3, pp. 227–235, 2009.
- [26] 大西 昇 (著), 杉江 昇 (監修), *生体情報処理*. 昭晃堂, 2001.
- [27] N. K. Squires, K. C. Squires, and S. A. Hillyard, "Two varieties of long-latency positive waves evoked by unpredictable auditory stimuli in man," *Electroencephalography and Clinical Neurophysiology*, vol. 38, no. 4, pp. 387–401, 1975.
- [28] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, "A review of classification algorithms for EEG-based brain-computer interfaces," *Journal of Neural Engineering*, vol. 4, no. 2, pp. R1–R13, 2007.
- [29] L. Citi, R. Poli, and C. Cini, "Documenting, modelling and exploiting P300 amplitude changes due to variable target delays in Donchin's speller," *Journal of Neural Engineering*, vol. 7, no. 5, p. 056006, 2010.
- [30] S. M. M. Martens and J. M. Leiva, "A generative model approach for decoding in the visual event-related potential-based brain-computer interface speller," *Journal of Neural Engineering*, vol. 7, no. 2, p. 26003, 2010.
- [31] F. Beverina, G. Palmas, S. Silvoni, F. Piccione, and S. Giove, "User adaptive BCIs : SSVEP and P300 based interfaces," vol. 1, no. 4, pp. 331 – 354, 2003.

- [32] P. Martinez, H. Bakardjian, and A. Cichocki, "Fully online multicommand brain-computer interface with visual neurofeedback using SSVEP paradigm," *Computational Intelligence and Neuroscience*, vol. 2007, no. i, p. 94561, 2007.
- [33] D. Zhu, J. Bieger, G. G. Molina, and R. M. Aarts, "A survey of stimulation methods used in SSVEP-based BCIs," *Computational Intelligence and Neuroscience*, vol. 2010, p. 702357, 2010.
- [34] R. Zerafa, T. Camilleri, O. Falzon, and P. C. Kenneth, "Comparison of plain and checkerboard stimuli for brain computer interfaces based on steady state visual evoked potentials," in *Proceedings of the 6th International IEEE/EMBS Conference on Neural Engineering*, 2013, pp. 33–36.
- [35] H. Bakardjian, T. Tanaka, and A. Cichocki, "Emotional faces boost up steady-state visual responses for brain-computer interface," *NeuroReport*, vol. 22, no. 3, pp. 121–125, 2011.
- [36] M. Cheng, X. Gao, S. Gao, and D. Xu, "Design and implementation of a brain-computer interface with high transfer rates," *IEEE Transactions on Biomedical Engineering*, vol. 49, no. 10, pp. 1181–1186, 2002.
- [37] Z. Lin, C. Zhang, W. Wu, and X. Gao, "Frequency recognition based on canonical correlation analysis for SSVEP-based BCIs," *IEEE Transactions on Biomedical Engineering*, vol. 54, no. 6 Pt 2, pp. 1172–1176, 2007.
- [38] S. Amiri, A. Rabbi, L. Azinfar, and R. Fazel-rezai, "A review of P300, SSVEP, and hybrid P300/SSVEP brain-computer interface systems," in *Brain-Computer Interface Systems - Recent Progress and Future Prospects*. InTech, 2013, pp. 195–213.
- [39] H. Bakardjian, "Optimization of steady-state visual responses for robust brain-computer interfaces," Ph.D. dissertation, Tokyo University of Agriculture and Technology, 2010.
- [40] D. Lesenfants, D. Habbal, Z. Lugo, M. Lebeau, P. Horki, E. Amico, C. Pokorný, F. Gómez, A. Soddu, G. Müller-Putz, S. Laureys, and Q. Noirhomme, "An independent SSVEP-based brain-computer interface in locked-in syndrome," *Journal of Neural Engineering*, vol. 11, no. 3, p. 035002, 2014.

-
- [41] G. Pfurtscheller, C. Brunner, A. Schlögl, and F. H. Lopes da Silva, "Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks," *NeuroImage*, vol. 31, no. 1, pp. 153–159, 2006.
- [42] L. Qin and B. He, "A wavelet-based time-frequency analysis approach for classification of motor imagery for brain-computer interface applications," *Journal of Neural Engineering*, vol. 2, no. 4, pp. 65–72, 2005.
- [43] C. Neuper, R. Scherer, M. Reiner, and G. Pfurtscheller, "Imagery of motor actions: differential effects of kinesthetic and visual-motor mode of imagery in single-trial EEG," *Cognitive Brain Research*, vol. 25, no. 3, pp. 668–677, 2005.
- [44] C. Vidaurre and B. Blankertz, "Towards a cure for BCI illiteracy," *Brain Topography*, vol. 23, no. 2, pp. 194–198, 2010.
- [45] F. Lotte and C. Guan, "Learning from other subjects helps reducing Brain-Computer Interface calibration time," in *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*, 2010, pp. 614–617.
- [46] R. Scherer, R. Leeb, D. Friedman, R. Gernot, M. Slater, and G. Pfurtscheller, "Self-paced (asynchronous) BCI control of a wheelchair in virtual environments : a case study with a tetraplegic," *Computational Intelligence and Neuroscience*, vol. 2007, p. 79642, 2007.
- [47] L. A. Farwell and E. Donchin, "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.
- [48] R. C. Panicker, S. Puthusserypady, A. P. Pryana, and Y. Sun, "Asynchronous P300 BCI : SSVEP-based control state detection," *Electrical Engineering*, pp. 934–938, 2010.
- [49] A. A. Nooh, J. Yunus, and S. M. Daud, "A review of asynchronous electroencephalogram-based brain computer interface systems," in *Proceedings of the International Conference on Biomedical Engineering and Technology*, vol. 11, 2011, pp. 55–59.

- [50] F. Aloise, P. Aricò, F. Schettini, A. Riccio, M. Riseti, S. Salinari, D. Mattia, F. Babiloni, and F. Cincotti, "A new P300 no eye-gaze based interface: GeoSpell," in *Proceedings of the International Conference on Bio-inspired Systems and Signal Processing*, 2011, pp. 26–29.
- [51] Y. Wang, X. Gao, and B. Hong, "Brain-computer interfaces based on visual evoked potentials," *IEEE Engineering in Medicine and Biology Magazine*, vol. 27, no. 5, pp. 64–71, 2008.
- [52] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [53] R. M. G. Tello, M. T. M. Sandra, T. Bastos-filho, and A. Ferreira, "Comparison between wire and wireless EEG acquisition systems based on SSVEP in an independent-BCI," in *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2014, pp. 22–25.
- [54] P. Brunner, S. Joshi, S. Briskin, J. R. Wolpaw, H. Bischof, and G. Schalk, "Does the 'P300' speller depend on eye gaze?" *Journal of Neural Engineering*, vol. 7, no. 5, p. 056013, 2010.
- [55] G. M. Loughnane, E. Meade, R. B. Reilly, and C. Lalor, "Towards a gaze-independent hybrid-BCI based on SSVEPs, alpha-band modulations and the P300," in *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2014, pp. 1322–1325.
- [56] A. Onishi and K. Natsume, "Overlapped partitioning for ensemble classifiers of P300-based brain-computer interfaces," *PLoS ONE*, vol. 9, no. 4, p. e93045, 2014.
- [57] J. N. Mak, Y. Arbel, J. W. Minett, L. M. McCane, B. Yuksel, D. Ryan, D. Thompson, L. Bianchi, and D. Erdogmus, "Optimizing the P300-based brain-computer interface: current status, limitations and future directions," *Journal of Neural Engineering*, vol. 8, no. 2, p. 025003, 2011.
- [58] K. Takano, N. Hata, and K. Kansaku, "Towards intelligent environments: an augmented reality-brain-machine interface operated with a see-through head-mount display," *Frontiers in Neuroscience*, vol. 5, no. 60, 2011.

-
- [59] A. T. Campbell, T. Choudhury, S. Hu, H. Lu, M. Rabbi, R. D. S. Raizada, and M. K. Mukerjee, "NeuroPhone: Brain-mobile phone interface using a wireless EEG headset categories and subject descriptors," in *Proceedings of the Second ACM SIGCOMM Workshop on Networking, Systems, and Applications on Mobile Handhelds*, 2010, pp. 3–8.
- [60] A. Furdea, S. Halder, D. J. Krusienski, D. Bross, F. Nijboer, N. Birbaumer, and A. Kübler, "An auditory oddball (P300) spelling system for brain-computer interfaces," *Psychophysiology*, vol. 46, no. 3, pp. 617–625, 2009.
- [61] A. M. Brouwer and J. B. F. van Erp, "A tactile P300 brain-computer interface," *Frontiers in Neuroscience*, vol. 4, no. May, p. 19, 2010.
- [62] A. Belitski, J. Farquhar, and P. Desain, "P300 audio-visual speller," *Journal of Neural Engineering*, vol. 8, no. 2, p. 025022, 2011.
- [63] F. Aloise, I. Lasorsa, and F. Schettini, "Multimodal stimulation for a P300-based BCI," *International Journal of Bioelectromagnetism*, vol. 9, no. 3, pp. 128–130, 2007.
- [64] D. J. Krusienski, E. W. Sellers, F. Cabestaing, S. Bayouth, D. J. McFarland, T. M. Vaughan, and J. R. Wolpaw, "A comparison of classification techniques for the P300 speller," *Journal of Neural Engineering*, vol. 3, no. 4, pp. 299–305, 2006.
- [65] K. Takano, T. Komatsu, N. Hata, Y. Nakajima, and K. Kansaku, "Visual stimuli for the P300 brain computer interface : A comparison of white/gray and green/blue flicker matrices," *Clinical Neurophysiology*, vol. 120, no. 8, pp. 1562–1566, 2009.
- [66] G. Townsend, B. K. LaPallo, C. B. Boulay, D. J. Krusienski, G. E. Frye, C. K. Hauser, N. E. Schwartz, T. M. Vaughan, J. R. Wolpaw, and E. W. Sellers, "A novel P300-based brain-computer interface stimulus presentation paradigm: moving beyond rows and columns," *Clinical Neurophysiology*, vol. 121, no. 7, pp. 1109–1120, 2010.
- [67] F. Akram, H. S. Han, and S. Kim, "A P300-based word typing brain computer interface system using a smart dictionary and random forest classifier," in *Proceedings of the Eighth International Multi-Conference on Computing in the Global Information Technology*, no. c, 2013, pp. 106–109.

- [68] S. Sutton, M. Braren, J. Zubin, and E. R. John, "Evoked-potential correlates of stimulus uncertainty," *Science*, vol. 150, no. 3700, pp. 1187–1188, 1965.
- [69] A. Espinosa, G. Edlinger, and C. Guger, "P300 brain-computer interface performance: a dry electrode study," in *Proceedings of the Fifth International Conference on Advanced Cognitive Technologies and Applications*, no. c, 2013, pp. 34–36.
- [70] D. J. Krusienski and G. Schalk, "Documentation Wadsworth BCI Dataset (P300 Evoked Potentials) BCI Competition III Challenge 2004," pp. 1–8, 2004. [Online]. Available: <http://www.bbci.de/competition/iii/desc\..II.pdf>
- [71] C. Guger, S. Daban, E. Sellers, C. Holzner, G. Krausz, R. Carabalona, F. Gramatica, and G. Edlinger, "How many people are able to control a P300-based brain-computer interface (BCI)?" *Neuroscience Letters*, vol. 462, no. 1, pp. 94–98, 2009.
- [72] S. Ikegami, K. Takano, and K. Kondo, "A region-based two-step P300-based brain-computer interface for patients with amyotrophic lateral sclerosis," *Clinical Neurophysiology*, vol. 125, no. 11, pp. 2305–2312, 2014.
- [73] D. J. Krusienski, E. W. Sellers, D. J. McFarland, T. M. Vaughan, and J. R. Wolpaw, "Toward enhanced P300 speller performance," *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 15–21, 2008.
- [74] U. Hoffmann, J. M. Vesin, T. Ebrahimi, and K. Diserens, "An efficient P300-based brain-computer interface for disabled subjects," *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 115–125, 2008.
- [75] S. Ikegami, K. Takano, N. Saeki, and K. Kansaku, "Operation of a P300-based brain-computer interface by individuals with cervical spinal cord injury," *Clinical Neurophysiology*, vol. 122, no. 5, pp. 991–996, 2011.
- [76] 石井 健一郎, 前田 英作, 上田 修功, 村瀬 洋, *わかりやすいパターン認識*. オーム社, 1998.
- [77] 辻谷 将明, 竹澤 邦夫, 金 明哲 (編), *マシンラーニング (R で学ぶデータサイエンス 6)*. 共立出版, 2009.
- [78] 杉山 将, *統計的機械学習—生成モデルに基づくパターン認識*. オーム社, 2009.

-
- [79] A. Onishi, Y. Zhang, Q. Zhao, and A. Cichocki, "Fast and reliable P300-based BCI with facial images," in *Proceedings of the 5th International Brain-Computer Interface Conference*, 2011, pp. 192–195.
- [80] M. Koo and A. Fishbach, "Dynamics of self-regulation: How (un)accomplished goal actions affect motivation," *Journal of personality and social psychology*, vol. 94, no. 2, pp. 183–195, 2008.
- [81] D. J. McFarland, "The influence of psychological state and motivation on brain computer interface performance in patients with amyotrophic lateral sclerosis a longitudinal study," *Frontiers in Neuroscience*, vol. 4, no. July, pp. 1–13, 2010.
- [82] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, "BCI2000: a general-purpose brain-computer interface (BCI) system," *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1034–1043, 2004.
- [83] C. Escolano, A. R. Murguialday, T. Matuz, N. Birbaumer, and J. Minguéz, "A telepresence robotic system operated with a P300-based brain-computer interface: initial tests with ALS patients," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2010, pp. 4476–4480.
- [84] B. Blankertz, S. Lemm, M. Treder, S. Haufe, and K. R. Müller, "Single-trial analysis and classification of ERP components—a tutorial," *NeuroImage*, vol. 56, no. 2, pp. 814–825, 2011.
- [85] U. Hoffmann, "Bayesian machine learning applied in a brain-computer interface for disabled users," Ph.D. dissertation, Ecole Polytechnique Federale de Lausanne, 2007.
- [86] L. Sportiello, B. D. Seno, and M. Matteucci, "A comparison of three methods with implicit features for automatic identification of P300s in a BCI," in *Proceedings of the 19th International Conference on Artificial Neural Networks*, 2009, pp. 515–524.
- [87] F. Lotte and C. Guan, "An efficient P300-based brain-computer interface with minimal calibration time," in *Proceedings of the Assistive Machine Learning for People with Disabilities Symposium (NIPS'09 Symposium)*, 2009, pp. 7–10.

- [88] A. Onishi, A. H. Phan, K. Matsusoka, and A. Cichocki, "Tensor classification for P300-based brain computer interface," in *Proceedings of the 37th International Conference on Acoustics, Speech, and Signal Processing*, 2012, pp. 581 – 584.
- [89] U. Hoffmann, G. Garcia, J. M. Vesin, K. Diserens, and T. Ebrahimi, "A boosting approach to P300 detection with application to brain-computer interfaces," in *Proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering*, 2005, pp. 97 – 100.
- [90] C. Arjona, J. Pentácolo, I. Gareis, Y. Atum, G. Gentiletti, R. Acevedo, and L. Rufiner, "Evaluation of LDA ensembles classifiers for brain computer interface," *Journal of Physics: Conference Series*, vol. 332, p. 012025, 2011.
- [91] G. D. Johnson and D. J. Krusienski, "Ensemble SWLDA classifiers for the P300 speller," in *Proceedings of the 13th International Conference on Human-Computer Interaction. Part II: Novel Interaction Methods and Techniques*, 2009, pp. 551–557.
- [92] M. Salvaris and F. Sepulveda, "Wavelets and ensemble of FLDs for P300 classification," in *Proceedings of the 4th International IEEE EMBS Conference on Neural Engineering*, 2009, pp. 339–342.
- [93] M. Salvaris, C. Cinel, R. Poli, L. Citi, and F. Sepulveda, "Exploring multiple protocols for a brain-computer interface mouse," in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2010, pp. 4189–4192.
- [94] C. Guger, G. Krausz, B. Z. Allison, and G. Edlinger, "Comparison of dry and gel based electrodes for P300 brain-computer interfaces," *Frontiers in Neuroscience*, vol. 6, p. 60, 2012.
- [95] Y. Grandvalet, "Bagging equalizes influence," *Machine Learning*, vol. 55, no. 3, pp. 251–270, 2004.
- [96] L. Breiman, "Bagging predictors," *Machine learning*, vol. 140, pp. 123–140, 1996.
- [97] E. W. Sellers, D. J. Krusienski, D. J. McFarland, T. M. Vaughan, and J. R. Wolpaw, "A P300 event-related potential brain-computer interface (BCI): the effects of matrix

-
- size and inter stimulus interval on performance," *Biological Psychology*, vol. 73, no. 3, pp. 242–252, 2006.
- [98] N. R. Draper and H. Smith, *Applied regression analysis, 2nd edition*. Wiley, 1981.
- [99] 平岡 和幸, 堀 玄, *プログラミングのための確率統計*. オーム社, 2009.
- [100] K. Pearson, "On lines and planes of closest fit to systems of points in space," *Philosophical Magazine*, vol. 2, no. 6, pp. 559–572, 1901.
- [101] A. Ahangi, M. Karamnejad, N. Mohammadi, R. Ebrahimpour, and N. Bagheri, "Multiple classifier system for EEG signal classification with application to brain-computer interfaces," *Neural Computing and Applications*, vol. 23, no. 5, pp. 1319–1327, 2012.
- [102] S. B. Cho and H. H. Won, "Cancer classification using ensemble of neural networks with multiple significant gene subsets," *Applied Intelligence*, vol. 26, no. 3, pp. 243–250, 2006.
- [103] L. I. Kuncheva and J. J. Rodríguez, "Classifier ensembles for fMRI data analysis: an experiment," *Magnetic Resonance Imaging*, vol. 28, no. 4, pp. 583–593, 2010.