

この資料は、私が大学院の授業の課題として提出したものです。脳マシンインターフェイスについて解説していますが、たぶん、間違いも多々あります。全てを信用せず、参考文献としてあげている論文を必ずあたってください。質問や間違いの指摘などがありましたら [higashi@sip.tuat.ac.jp](mailto:higashi@sip.tuat.ac.jp) まで連絡下さい。

脳マシンインターフェイスのための  
信号処理

東 広志

東京農工大学 大学院工学府  
電子情報工学専攻

2012年2月

## 概要

脳マシンインターフェイス (BMI; Brain Machine Interface) は、脳信号を入力としたインターフェイスである。本稿では、現在研究されている主要な BMI として、認知を用いたもの、点滅刺激を用いたもの、運動想起を用いたものを取り上げる。それらの BMI について、パラダイム・脳活動・信号処理について述べる。

# 目次

|     |              |    |
|-----|--------------|----|
| 第1章 | はじめに         | 2  |
| 第2章 | 脳波           | 4  |
| 第3章 | 脳マシンインターフェイス | 6  |
| 第4章 | 認知を用いた BMI   | 9  |
| 4.1 | パラダイムと脳活動    | 9  |
| 4.2 | 信号処理         | 12 |
| 第5章 | 点滅刺激を用いた BMI | 15 |
| 5.1 | パラダイムと脳活動    | 15 |
| 5.2 | 信号処理         | 16 |
| 第6章 | 運動想起を用いた BMI | 19 |
| 6.1 | パラダイムと脳活動    | 19 |
| 6.2 | 信号処理         | 20 |
| 第7章 | その他の信号処理     | 22 |
| 第8章 | まとめ          | 23 |

# 第1章 はじめに

脳マシンインターフェイス (BMI; Brain Machine Interfaces) は、脳信号を入力としたインターフェイスである [1,2]. BMI は、外部刺激 (視覚刺激や聴覚刺激など) やメンタルタスク (ある事象の出現回数を数える、手足の運動を想像するなど) による脳の神経活動の変化を捉え、その変化に対して何らかのコマンドを対応づけることでインターフェイスを構築する. BMI を使うユーザは、コマンドを入力する際に外部刺激に注意を向けたり、メンタルタスクを行うのみである [2]. したがって、現在使われているようなインターフェイス、例えば、ハンドル、キーボード、マウスや音声などに対して、BMI では入力のために筋肉を動かす必要がない. このような BMI の特徴から、筋萎縮性側索硬化症の患者や高齢者といった体の不自由な人のための新たなコミュニケーションチャンネルとして BMI は注目されている. また、ヴァーチャル・リアリティ技術におけるコントローラとして BMI を用いる研究も行われている [3]. さらに、リハビリテーションへの応用も進められている. 例えば、脳卒中後の神経系機能の再構築を目指した機能回復型の BMI の研究が行われている [4,5]. このように BMI の応用分野は多岐にわたる.

脳活動の観測方法によって、BMI は侵襲型と非侵襲型に分けることができる [6]. 侵襲型計測装置では、開頭手術などにより頭蓋内電極を設置して、神経活動を計測する. 侵襲型 BMI は手術を要するというデメリットがあるが、非侵襲型 BMI と比べて極めて雑音の少ない信号を計測することができる. 非侵襲型 BMI では、ラットによるレバーの操作 [7], サルによるロボットアームの操作 [8], 脊髄損傷による四肢麻痺患者によるコンピュータカーソル操作を行わせることに成功している [9]. 非侵襲型 BMI は、脳波計 (EEG; Electroencephalography) [10], 脳磁計 (MEG; Magnetoencephalography) [11], 機能的核磁気共鳴装置 (fMRI; functional Magnetic resonance imaging) [12], 近赤外分光法測定装置 (NIRS; Near-Infrared Spectroscopy) [13] などを脳活動の観測に用いる BMI である. 侵襲型と異なり、このような脳活動の取得方法は手術を必

要としない。BMIにおける利用では、計測の簡易性と時間分解能の高さから、脳波が有利である [14]。非侵襲型の BMI では、注意喚起や運動想起といったメンタルタスクを用いたパラダイムで文字入力 [15-17] がいくつか提案されている。また、画面上の物体のコントロール [18,19] を行ったり、実際の車椅子 [20] やロボット [21,22] を操作する BMI も開発されている。

本稿は、脳波計を使った非侵襲型 BMI に着目し、まず、BMI に用いられる脳波計について第 2 節で述べる。さらに、BMI の基本的な構成を第 3 節にて示す。次に、(1) BMI に用いられる外部刺激やメンタルタスク（パラダイム）と (2) それらを効果的に抽出し、識別するための信号処理について論じる。(1) については、刺激認知、点滅刺激、運動想起が現在、BMI 実現に有望なパラダイムとして知られている [1,14]。これらのパラダイムを、第 4, 5, 6 節でそれぞれ論じ、それらの節中で各パラダイムにおける (3) について論じる。

## 第2章 脳波

脳を構成する神経細胞は、神経細胞へ入力刺激が入ってきたときに活動電位を発生させ他の細胞に情報を伝達する [23]。したがって活動電位を観察することで脳の状態を知ることができる。

脳波計は電極によって神経細胞の電気活動を観測する装置である [24]。脳波計は電極近傍あるいは遠隔部の神経細胞集団の電気活動の総和を観測する。電極は頭皮上、蝶形骨上、脳表、脳深部などに設置される。ただし、頭皮上に設置した場合は非侵襲の計測であるが、頭皮以外に設置した場合は侵襲、もしくは低侵襲の計測である。ここでは、頭皮上に電極を設置した場合について述べる。電極は頭皮に導電性ペーストや特殊なキャップによって頭皮に固定される。

BMI への利用では複数の電極を使って脳波を観測する 경우가多い [1, 14, 25]。複数の電極を使って観測する場合、国際 10-20 法 [26]、拡張 10-20 法 [27]、10-10 法 [28]、10-5 法 [29, 30] と呼ばれる電極配置が一般的に用いられている。これらの配置方法は頭蓋骨上の特徴的な目印を基準とした相対的な距離を用いて頭皮上の位置を記述する。電極配置の例を図 2.1 に示す。

実際に脳波を記録する際には、対象となる電極と参照電極との電位差を記録する。耳朶は電氣的に不活性と見なせるため、参照電極を耳朶に設置し電位差を記録する方法を単極導出 (Referential recordings) と呼ぶ。それに対して、双極導出 (Bipolar recordings) は、頭皮上電極同士の電位差の変動を記録する [26]。

脳波計は MEG, fMRI, NIRS と比べて小型化が可能であり、時間分解能を高く設定することができる。しかし、脳波においては、硬膜、脳脊髄液、頭蓋骨、皮膚などを通して観測することによる空間分解能の低さ、高周波活動の低減、頭皮との接触不良による雑音混入、筋電 (EMG; Electromyography) や眼電位 (EOG; Electrooculography) の混入などが BMI への利用の上で問題となる。

最近では、アクティブ電極と呼ばれる電極に増幅器を組み込むことで雑




図 2.1: 国際 10-20 法, 国際 10-10 法の電極配置. 円で示される場所が国際 10 - 20 法の配置, 円と十字で示される場所が国際 10 - 10 法の配置である.

音を軽減する電極が発売されている. アクティブ電極は Guger Technology 社 (<http://www.gtec.at>) や Neuroscan 社 (<http://www.neuro.com/>) のものが多くの研究で用いられている. また, このような電極には導電性のジェルを使う必要があるが, ドライ電極と呼ばれるジェルが不要なタイプの電極も発売されている. また, ゲームなどへの商業製品への利用を考慮して作られた, 電極数の少ない安価な脳波計も発売されている (例えば, Emotive (<http://emotiv.com/>) や Neurosky (<http://neurosky.com/>)).

脳波計で観測される特徴的な成分として, 特定の周波数帯域で振動する律動成分 (基礎律動) がある. 脳波には複数の律動成分が観測され, それらは周波数帯域ごとに  $\delta$  波,  $\theta$  波,  $\alpha$  波,  $\beta$  波と呼ばれている [24]. 律動成分はそれぞれ生理学的な意義を有している. 例えば, 一般に健常者では, 安静・閉眼状態では後頭部を中心に  $\alpha$  波が多く出現する. BMI で用いられる脳波の特徴は, このような律動成分に加えて, 点滅する視覚刺激によって誘発される定常的視覚誘発電位や, 高頻度な刺激と低頻度な刺激を同時に与えたときの注意喚起によって誘発される事象関連電位などがある. 現在, 主に研究されている BMI において用いられる脳波特徴に関しては, 4.1, 5.1, 6.1 節で詳細を述べる.



## 第3章 脳マシンインターフェイス

本節では、BMIの基本的な構成について述べ、信号処理がBMIにおいてどのような役割を担っているか述べる。

図3.1にBMIの基本的な構成を示す [1, 14]。これに示すように、BMIは、1. メンタルタスクや外部刺激による脳活動の誘発、2. 脳信号の取得、3. 特徴抽出、4. パターン認識、5. デバイス命令への変換というステップに分けることができる。これらのステップを経て、BMIは車椅子やコンピュータカーソルなどを操作する。ここでは、2コマンド（コマンドAとコマンドB）を入力可能なBMIを考える。例えば、車椅子の操作を想定した場合、コマンドAが「左に曲がる」、コマンドBが「右に曲がる」というように対応する。BMIにおけるコマンド判別は、識別問題と考えられるため、これらのコマンドはクラスとも呼ばれる。この例を用いて、それぞれのステップの詳細を述べる。

1. 脳活動の誘発 ユーザがメンタルタスクを行ったり、外部刺激を注視することで特徴的な脳波を誘発させる。一般的にコマンド数と同数のメンタルタスク、もしくは外部刺激を用意する。外部刺激として2つの視覚刺激（刺激1と刺激2）を与えた場合、ユーザが刺激1を見た場合、BMIはコマンドAを出力し、刺激2を見た場合、コマンドBが出力されるようなインターフェイスを設計することができる。このようなメンタルタスク/刺激と出力コマンドを対応づける枠組みをパラダイムと呼ぶ。
2. 脳信号の取得 侵襲型・非侵襲型の計測装置によって脳活動を観測する。メンタルタスクや外部刺激の種類によっては特徴的な脳活動を観測できる脳部位がある程度知られていることもあるため、目的の部位を重点的に測定する場合もある。一般に、以降の取得信号の処理はデジタルで行われるため、電位差などのアナログな信号を、増

幅・フィルタリングし、A/Dコンバータなどでデジタル信号に変換する。

3. 特徴抽出 信号に含まれる雑音や不要成分の除去や信号の次元削減などを行い、所望の成分のみを抽出する。特徴された信号は特徴ベクトルと呼ばれるベクトルに格納される。
4. パターン認識 脳信号が観測されたときに、「ユーザが、どのメンタルタスクを行ったか/どの刺激に注意を向けたか」を判別する。すなわち、特徴ベクトルからコマンドAかコマンドBを決定する。判別する方法は特徴ベクトルから経験的に求める方法と機械学習を用いる方法がある。経験的に求める方法では、何らかのしきい値によって判別する方法がある。しかし、脳信号（特に脳波などの非侵襲型計測装置）は個人差や測定環境によるゆらぎが大きいため、経験的な方法では識別精度が低いことがある。したがって、クラスが既知の学習データを用いて識別器のパラメータを学習する機械学習的手法が有効である [2,31]。
5. デバイス命令への変換 コマンドの判別結果を操作したい機器の操作命令に変換する。車椅子の例を考えると識別結果がコマンドAのときは、「左に曲がる」という操作命令に変換する。

上記のように、特徴抽出やパターン認識のステップにおいて信号処理を行う。非侵襲の脳波計などで脳信号を取得した場合、観測される成分自体がある領域における神経活動の総和であることに加え、観測信号は雑音や不要な成分を多く含むため、適切な信号処理が必要である [32,33]。特徴抽出ステップでは、どのようなメンタルタスク・外部刺激を用いるかによって、抽出すべき脳活動が異なる。したがって、このステップではパラダイムによって適した処理が異なる。この処理に関しては、それぞれのパラダイムに対して、4.2, 5.2, 6.2節で述べる。パターン認識のステップでは、判別の対象が特徴ベクトルであるため、音声認識や画像認識でも用いられる識別器、例えば、フィッシャー線形判別 (FLDA; Fisher's Linear Discriminant Analysis [34] やサポートベクタマシン (SVM; Support Vector Machine) [35,36], ニューラルネットワーク (NN; Neural Network) 識別器 [37] などを用いることができる。

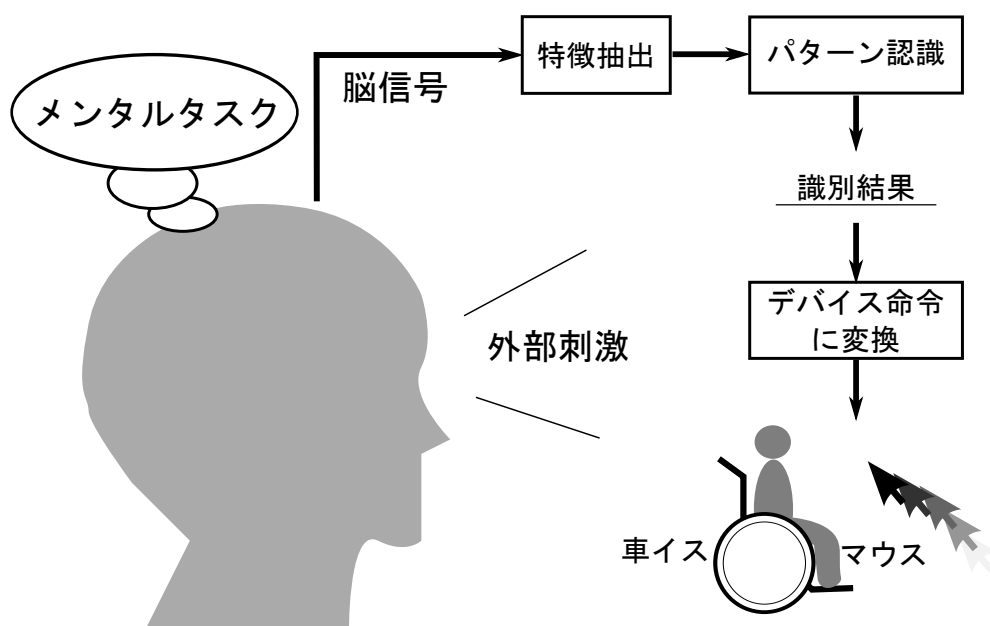


図 3.1: BMI の基本的な構成

## 第4章 認知を用いたBMI

認知を用いたBMIは、ユーザが刺激に対する認知を行うことで、事象関連電位（ERP; Event-Related Potential）と呼ばれる脳活動を誘発させる。このERPを用いたBMIでは、特に文字入力に関して広く研究されており、アルファベットの入力において、一分間に1.5文字程度の入力速度を達成している [17,38,39]。4.1節にて、このBMIがどのようなパラダイムでERPを誘発させ、特徴として用いるかを述べる。4.2節にて、このBMIで用いられる信号処理について述べる。

### 4.1 パラダイムと脳活動

ERPは思考や認知による脳波における電位の変化である [40]。P300はERPの一種で、刺激（視覚、触覚、聴覚、嗅覚、味覚など）提示後、300ms後に観測される反応である [40]。P300は、刺激から300ms後の緩やかな電位の揺れとして観測される。特に、オドボール課題と呼ばれる課題を被験者に課したとき、強いP300が観測される [41,42]。

簡単のために、2つの刺激のみを使ったオドボール課題について述べる。これらの刺激として、「ピ」という短い音や、短期間のみ光る光源などを用いることができる。これらの刺激をランダムな順番で提示する。このとき、どちらか一方の出現頻度を高くする。例えば、「ピ」と「プ」という2つの刺激を用いて、「プ」という刺激の出現頻度を高くする場合、ランダムな順番で「ピ・プ・プ・プ・ピ・プ・プ・プ・ピ」と提示する。刺激間の間隔は等間隔でも異なっても良い。高頻度で現れる刺激を高頻度刺激、もう一方の刺激（2つしかないので低頻度で現れることになる）を低頻度刺激と呼ぶことにする。被験者に課せられる課題は、低頻度刺激が提示された回数を数えることである。この数を数えるという行為が認知にあたる。低頻度の刺激が提示された300ms後にP300が誘発される。

このように、ある刺激を提示した後のP300の有無を判別することで、その刺激に着目していたかがわかる。このような脳活動に対する




図 4.1: P300 による電話かけるインターフェイス.

BMI パラダイムには次のようなものが挙げられる. まず, 3つ以上の短い刺激を用意する. それらをランダムな順序で出現頻度が同程度になるようにユーザに提示する. 各刺激に対してそれぞれコマンドが割り当てられている. ユーザは所望のコマンドに対応する刺激が現れた回数をカウントする. 同頻度で出現する刺激が3つ以上提示されることから, カウントする刺激が低頻度刺激になり, その他の刺激が高頻度刺激の役割を担う. したがって, このパラダイムはオドボール課題となり, 刺激がカウントされた 300ms 後に P300 が誘発される. 刺激提示後の P300 の有無を検出することで, どの刺激に着目したかが分かるため, 脳波からユーザの入力したいコマンドを判別することができる.

P300 を用いた BMI として, 文字入力を行うインターフェイスが提案されている [43]. このインターフェイスは P300-Speller と呼ばれている [2, 44, 45]. 例として, 電話をかける際のダイアル入力を想定した, 数字を入力するインターフェイスを示す. このような数字と記号がならんだ表をディスプレイ等に表示し, ユーザは入力したい文字を注視する (図 4.1). そして, 1列/1行のみを変化 (光らせる・色を変えるなど) させ, 刺激を与える. このような刺激を図 4.2 のように, 変化させる行・列を変えてランダムな順序で繰り返す. 刺激の間隔は 500–1000ms 程度に設定する [44]. ユーザは, 自分が入力したい文字が変化するときのみ, その変化した回数を数える. 例えば, ユーザが入力したい数字を「8」とする. 図 4.2 の

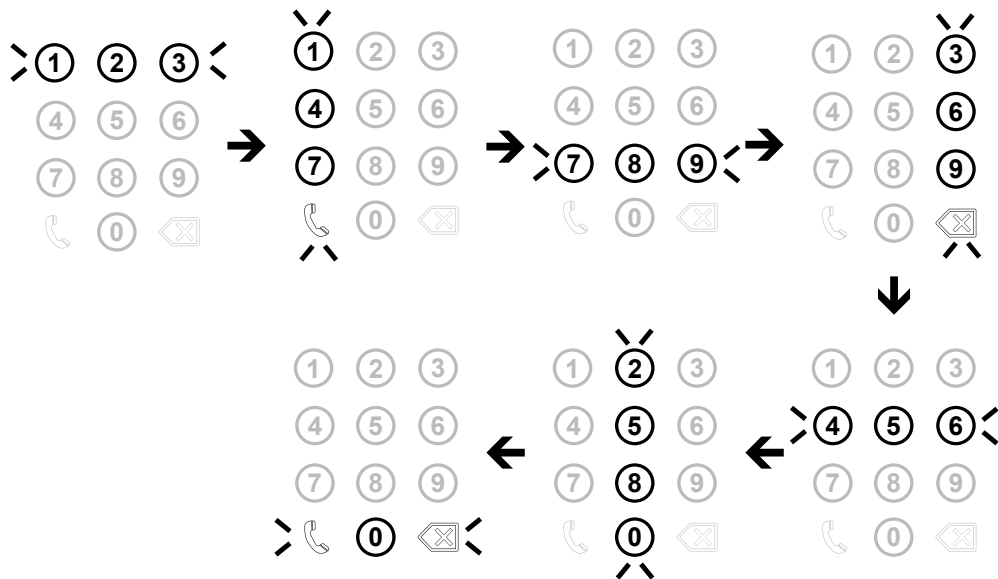


図 4.2: P300 ダイヤル入力インターフェイスにおける刺激提示. 矢印の順番に行と列を一つずつ変化 (光らせる・色を変えるなど) させる.

例では, 3 番目と 6 番目の刺激提示時に「8」が変化している. このとき, ユーザは 3 番目と 6 番目の刺激提示時にカウントを行うため, これらの刺激提示後, 約 300ms 後に P300 が誘発される. 各刺激提示後の P300 の有無を調べ, ユーザの見ている行と列 (3 行目, 2 列目) を推定する. 行と列が分かれば, それに対応する文字 (「8」) が分かるので, BMI はユーザの見ている数字を「8」と判別する.

P300-Spiller における刺激提示後の波形を図 4.3 に示す. これは, BCI Competition [46–48] で公開されている BCI Competition Date set II というデータである. 図 4.3 の凡例の「Targets」が所望の文字が変化したときの波形で, 「NonTargets」がそれ以外の文字が変化したときの波形である. 刺激提示は横軸の 0 秒で行われている. 刺激提示後, 200–400ms で「Targets」と「NonTargets」の非常に大きい違いを観測することができる.




図 4.3: 刺激提示後 1 秒間の信号を加算平均したもの. “Targets” が低頻度刺激を提示したときの脳波, “NonTargets” が高頻度刺激を提示したときの脳波,

## 4.2 信号処理

図 4.3 は 85 回の刺激提示後の波形を加算平均したものである. 加算平均は単純にローパスフィルタリング後の信号を足しあわせ, ランダムに観測される背景雑音を消す方法である. 1 回の刺激で誘発される P300 が背景脳波や雑音に埋もれているため, このような信号処理が必要になる. したがって P300 を観測するためには, ターゲットとなる文字における刺激を複数回繰り返す必要がある. 判別に要する刺激の繰り返し回数は, 1 つの文字を入力するのに要する時間に対応するため, 繰り返す回数が少ないほうがより早く文字入力を行うことができる. したがって, 入力速度を改善するためには, 加算平均より効率的な信号処理が必要である. 本節では,

P300-Speller における脳波識別に有効な方法である Linear Discriminant Analysis (LDA) [35,49] に基づく信号処理手法について述べる [17,50,51].

図 4.2 のような一連の刺激提示を考える. 図 4.2 で示すような一つの間・列が変化するような刺激を 1 刺激とする. これ以降では簡単のために行・列を考えずに,  $T$  回の刺激が提示される間に, ユーザが 1 回だけ刺激を認知した場合を考え, その認知した刺激がどれであることを観測脳波から推定する問題を考える.

まず, 前処理として, 観測脳波に対しローパスフィルタとダウンサンプリングを適用する. P300 の電位の揺れは低周波数成分なので, カットオフ周波数 10 Hz 程度のローパスフィルタ適用後, 20 Hz 程度にダウンサンプリングを行う.

ある刺激が提示されて,  $n$  サンプル後の離散信号を  $x_c[n]$ ,  $c = 1, \dots, N_C$ ,  $n = 0, \dots, N_S - 1$  とする. つまり,  $n = 0$  のときに刺激が提示されたとする. ここで, 添字の  $c$  はチャンネルのインデックス,  $N_C$  はチャンネル数,  $N_S$  はサンプル数である. P300 は刺激提示後 300ms 後から 600ms 後に観測されるため, 刺激提示後, 約 800ms 程度の信号を識別に用いる [50,51]. したがって,  $N_S = \lceil 0.8F_s \rceil$  程度とする. ここで,  $F_s$  はサンプリング周波数,  $\lceil a \rceil$  は実数  $a$  以上の最小の整数をとる天井関数である. ある刺激に対する特徴ベクトルを次のように定義する:

$$\mathbf{z} = [x_1[0], \dots, x_1[N_S-1], x_2[0], \dots, x_2[N_S-1], \dots, x_{N_C}[0], \dots, x_{N_C}[N_S-1]]^T. \quad (4.1)$$

$\mathbf{z} \in \mathbb{R}^{N_C N_S}$  は, 全てのチャンネルにおける観測信号をベクトルに縦に並べたものである.

$T$  回の刺激に対する特徴ベクトル  $\mathbf{z}$  を, それぞれ  $\mathbf{z}_1, \dots, \mathbf{z}_T$  とする. 刺激を認知していたときのみ P300 が発生するとし, 認知していた刺激を次のように検知する:

$$P = \operatorname{argmax}_{i=1, \dots, T} \mathbf{w}^T \mathbf{z}_i. \quad (4.2)$$

つまり,  $P$  回目の刺激のときにユーザが刺激を向けたと決定する. 式 (4.2) で用いられる  $\mathbf{w}$  は, 学習データを用いて LDA を用いて次のように求める.

学習データとして, ユーザが刺激を認知したときの特徴ベクトル  $\mathbf{z}$  とユーザが刺激に認知していないときの  $\mathbf{z}$  を複数個用意する. 学習データなので, ユーザが刺激を認知したか, 認知していないかは既知である. このような学習データは, あらかじめ認知を行う刺激を指示しておくことなので用意することができる. 認知刺激に対する  $\mathbf{z}$  の集合を  $\mathcal{Z}_1$  とし,



それ以外の刺激に対する  $z$  の集合を  $\mathcal{Z}_2$  とする。特徴ベクトルの  $\mathcal{Z}_1$  と  $\mathcal{Z}_2$  内の平均は、

$$\mathbf{m}_i = \frac{1}{|\mathcal{Z}_i|} E_{z \in \mathcal{Z}_i} [z] \quad (4.3)$$

と書ける。さらに、クラス内変動行列を、

$$\mathbf{S}_w = \sum_{i=1,2} \frac{1}{|\mathcal{Z}_i|} E_{z \in \mathcal{Z}_i} [(z - \mathbf{m}_L)(z - \mathbf{m}_L)^T], \quad (4.4)$$

と求める。  $\mathbf{w}$  を、

$$\hat{\mathbf{w}} = \mathbf{S}_w^{-1}(\mathbf{m}_1 - \mathbf{m}_2), \quad (4.5)$$

と求め、さらに、式(4.2)で P300 が観測される刺激において  $\mathbf{w}^T z$  が大きな値になるように、

$$\mathbf{w} = \begin{cases} \hat{\mathbf{w}} & \hat{\mathbf{w}}^T \mathbf{m}_1 \geq \hat{\mathbf{w}}^T \mathbf{m}_2 \\ -\hat{\mathbf{w}} & \text{otherwise} \end{cases} \quad (4.6)$$

とする [37, 43].

実際は、単一の刺激だけでは、式(4.2)で識別するのは難しい場合がある。そこで、何度か同一の刺激を提示し、同一の刺激に対する  $\mathbf{w}^T z$  を平均してから、判別する手法が取られる [43, 50, 51]. このような、複数の試行を用いて識別する方法は Stepwise LDA (SWLDA) と呼ばれる。

## 第5章 点滅刺激を用いたBMI

点滅刺激を用いたBMIは、ユーザが点滅する刺激を注視することでコマンド入力を行うインターフェイスである [52-54]。このようなBMIは、コマンド数は少ないが、非常に反応速度が早いインターフェイスを構築することが可能である [2, 14]。ただし、非常に早い点滅刺激はてんかんの発作などを引き起こす可能性があるため、使用には十分注意が必要である [55, 56]。5.1節にて、このBMIがどのようなパラダイムで、どのような脳活動を誘発するか述べる。5.2節にて、このBMIで用いられる信号処理について述べる。

### 5.1 パラダイムと脳活動

点滅刺激を用いたBMIでは、刺激を提示するものとしてLED光源 [57] や液晶モニタ上のチェッカーボード [58] などを用いる。点滅刺激の点滅周波数が3-70 Hz程度するとき、それを注視すると視覚野において、点滅周波数と同じ周波数で振動する成分が観測される [56]。これを定常的視覚誘発電位 (SSVEP; Steady-State Visually Evoked Potentials) と呼ぶ。図5.1に8 Hzで点滅するチェッカーボードを15秒間注視したときと、していないときの信号のパワースペクトルをそれぞれ示す。点滅するチェッカーボードを見ているとき、パワースペクトルは8 Hzのピークを持つことが分かる。また、点滅のような、短い刺激を繰り返すことによって誘発される定常的な誘発電位は視覚だけではなく、触覚 [59] や聴覚 [60, 61] でも誘発されることが分かっている。

SSVEPを用いたBMIパラダイムは以下のようなものである。刺激として、モニター上にいくつかのチェッカーボードを配置し (図5.2)、それらをそれぞれ異なる周波数で、図5.3のように白・黒を反転させる。ユーザが左上の点滅刺激を注視した場合、 $F_1$  HzのSSVEPが発生するため、脳波からユーザのしている刺激を判別することが可能である。したがっ

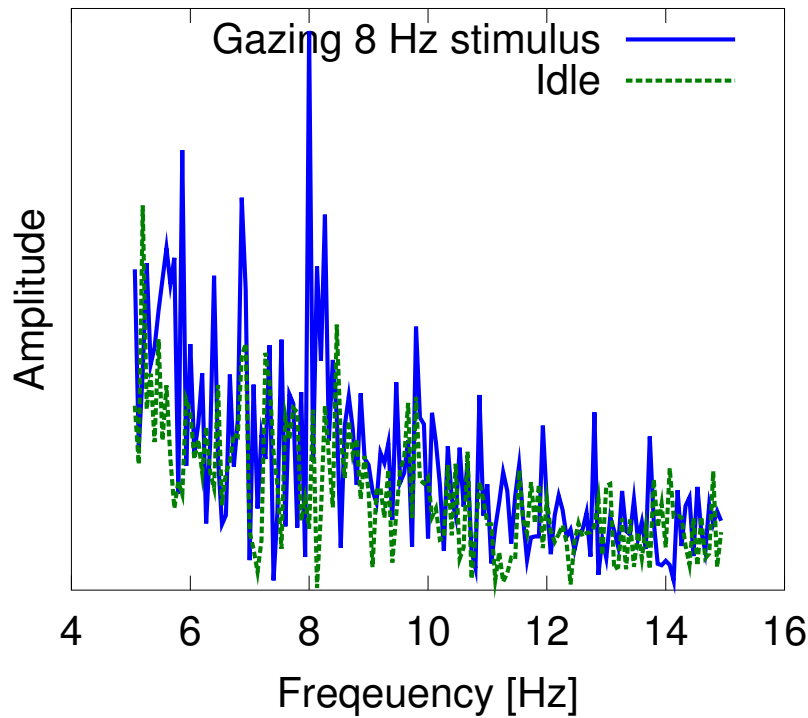


図 5.1: 8Hz で点滅するチェッカーボードを 15 秒間注視したときの脳波のパワースペクトル。

て、各チェッカーボードにコマンドを割り当てることで、インターフェイスを構築することができる。図 5.2 の例は、6 コマンドの BMI である。

しかし、刺激の点滅周波数が 25 Hz 以上になると、誘発される SSVEP は非常に弱くなる [62]。また、刺激点滅周波数の倍音成分の振動成分も同時に誘発されるため、ある刺激の点滅周波数における倍音成分を異なる刺激の点滅周波数として用いると識別精度が低下する [58]。さらに、液晶ディスプレイなどで刺激提示を行う場合、ディスプレイのリフレッシュレートによって点滅できる周波数が限られる。したがって、SSVEP を使った BMI では、コマンド数を増やすことが難しい。

## 5.2 信号処理

SSVEP は点滅周波数と同じ周波数成分で振動する成分なので、離散フーリエ変換を用いることで検出することができる。さらに、正準相関分

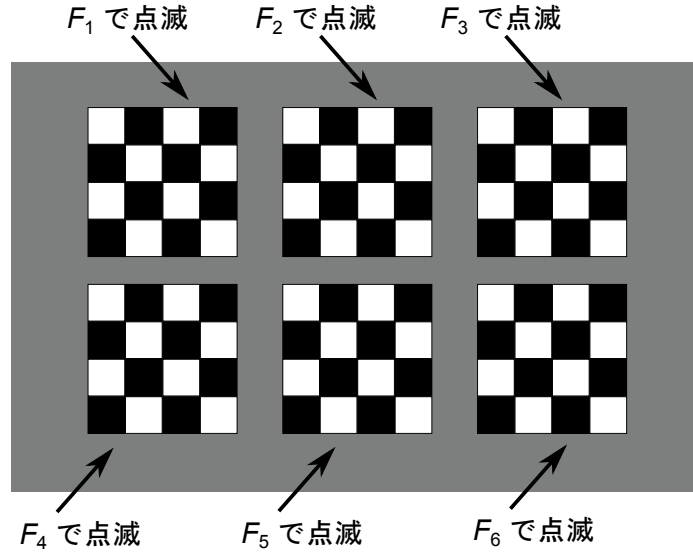


図 5.2: SSVEP-BMI におけるインターフェイス. 液晶モニタなどにチェックカーボートの配置する. それぞれ, 左上 → 右上, 左下 → 右下の順番で,  $F_1$  Hz,  $F_2$  Hz,  $F_3$  Hz,  $F_4$  Hz,  $F_5$  Hz,  $F_6$  Hz で点滅しているとする.

析 (CCA; Canonical Correlation Analysis) を用いた方法によって, フーリエ変換より精度の高い識別を行うことができる [63]. 本節では, CCA を用いた SSVEP-BMI の識別手法を述べる.

CCA は, 多チャンネル信号からなる 2 つのデータセットの間の相関を測る解析手法である [64, 65]. CCA は, 各データセットの信号の重み付き線形和からなる正準変量に対して, それらの間の相関係数を最大化するような重みベクトルを求める. 2 つの多チャンネル信号を  $\mathbf{x}(t)$ ,  $\mathbf{y}(t)$  ( $t$  は時間を表す) とすると, 正準変量はそれぞれ  $X(t) = \mathbf{w}_X^T \mathbf{x}(t)$ ,  $Y(t) = \mathbf{w}_Y^T \mathbf{y}(t)$  と定義される. CCA は, 次の最大化問題を解いて  $\mathbf{w}_X$  と  $\mathbf{w}_Y$  を求める:

$$\max_{\mathbf{w}_X, \mathbf{w}_Y} \rho = \frac{E[X(t)Y(t)]}{\sqrt{E[X(t)^2]E[Y(t)^2]}} \quad (5.1)$$

$$= \frac{\mathbf{w}_X^T E[\mathbf{x}(t)\mathbf{y}(t)^T] \mathbf{w}_Y}{\sqrt{\mathbf{w}_X^T E[\mathbf{x}(t)\mathbf{x}(t)^T] \mathbf{w}_X \mathbf{w}_Y^T E[\mathbf{y}(t)\mathbf{y}(t)^T] \mathbf{w}_Y}}. \quad (5.2)$$

ここで,  $E[\cdot]$  は  $t$  に関する期待値を表し,  $\rho$  は正準相関と呼ばれる. この最大化問題は一般化固有値問題に帰着する.

SSVEP の識別では, CCA は以下のように適用する [63]. チャンネル




図 5.3: チェッカーボードの反転.

$c$ , 時刻インデックス  $n$  における離散の観測脳波を  $x_c[n]$ ,  $c = 1, \dots, N_C$ ,  $n = 1, \dots, N_S$  とする. ここで,  $N_C$  は総チャンネル数,  $N_S$  はサンプル数である. これらの値を行列で表すと, サイズ  $N_C \times N_S$  の行列  $[\mathbf{X}]_{i,j} = x_i[j]$  とかける.  $[\cdot]_{i,j}$  は, 行列の  $j$  列  $i$  行の要素を表す. また, 図 5.2 のように並んだ  $T$  個の点滅刺激の点滅周波数を, それぞれ  $F_1, \dots, F_T$  Hz とする. CCA における一つのデータセットを  $\mathbf{X}$  として, 他方のデータセット  $\mathbf{Y}_k$  を,

$$\begin{aligned} [\mathbf{Y}_k]_{i-1,j} &= \sin(i\pi F_k j / S_R), \quad i = 2, 4, 6, \quad j = 0, \dots, N_S - 1 \\ [\mathbf{Y}_k]_{i,j} &= \cos(i\pi F_k j / S_R), \quad i = 2, 4, 6, \quad j = 0, \dots, N_S - 1 \end{aligned} \quad (5.3)$$

とする. ここで,  $S_R$  は観測信号のサンプリング周波数である.  $\mathbf{X}$  と  $\mathbf{Y}_k$  の正準相関  $\rho_k$  を,

$$\rho_k = \operatorname{argmax}_{\mathbf{w}_X, \mathbf{w}_Y} \frac{\mathbf{w}_X^T \Sigma_{XY} \mathbf{w}_Y}{\sqrt{\mathbf{w}_X^T \Sigma_X \mathbf{w}_X \mathbf{w}_Y^T \Sigma_Y \mathbf{w}_Y}} \quad (5.4)$$

と定義する. ここで,  $\Sigma_{XY} = \mathbf{X}\mathbf{Y}^T$ ,  $\Sigma_X = \mathbf{X}\mathbf{X}^T$ ,  $\Sigma_Y = \mathbf{Y}\mathbf{Y}^T$  である. 各刺激の点滅周波数に対する正準相関を求め, 特徴ベクトルを

$$\mathbf{z} = [\rho_1, \rho_2, \dots, \rho_K]^T \quad (5.5)$$

と定義する. この特徴ベクトルを, しきい値処理や識別器を用いて判別し, ユーザが見ている刺激の点滅周波数を推定する.

## 第6章 運動想起を用いたBMI

運動想起を用いたBMIは、ユーザがある身体の運動を想像することでコマンド入力を行うインターフェイスである [2]。P300-BMI や SSVEP-BMI と比べて、刺激を提示する装置が要らないという利点がある。6.1 節にて、このBMIのパラダイムと利用される脳活動を述べる。6.1 節にて、このBMIで用いられる信号処理について述べる。

### 6.1 パラダイムと脳活動

運動想起を用いたBMIでは、ユーザはある身体部位の運動を想起することでコマンド入力を行う。身体部位とは、右手、左手、足、舌などである。例えば、右手運動を想起が1つのコマンドに対応する。

運動想起は感覚運動野において、 $\mu$ 波 (8–14 Hz) や  $\beta$ 波 (14–30 Hz) と呼ばれる律動成分を減少させる。これは事象関連脱同期 (ERD; Event Desynchronization) と呼ばれる [32, 66]。運動する部位によってERDが発生する脳部位が異なることが知られている [66–68]。したがって、ERDが誘発される部位を検出することで、脳波からどの身体部位の運動を想像したかを推定することができる。ERDは健常者のみならず、身体麻痺患者の運動想起時の脳波でも観測されるため、体が不自由な人でも、運動想起を用いたBMIは利用することができる [69]。

また、P300 や SSVEP といった脳活動をBMIに用いる場合、ディスプレイやLEDなどの刺激呈示装置が必要である。しかし、運動想起を用いる場合は、ユーザが運動を想起するのみなので、このような装置が不要である。また、そのような刺激を見るための視点の移動も不要である。

運動想起BMIはトレーニングによって、識別精度が上昇することが知られている [70]。このトレーニングは次のように行われる [2, 25]。まず、ユーザは運動想起を行うと同時に、ERDの度合いを示す指標（例えば、 $\mu$ 波帯域のパワーなど）をユーザにフィードバックする。ユーザは指標が大きくなるように運動想起を行う。このようなトレーニングによって、

誘発される ERD が強くなるため、BMI の識別精度が向上する。さらに、このようなトレーニングは身体障害者の脳機能回復の効果が期待されている [4, 5].

## 6.2 信号処理

運動想起によって誘発される特徴は、ある部位における振動成分の変化である。したがって、BMI の信号処理では、複数の電極で運動野・感覚運動野を測定し、 $\mu$  波や  $\beta$  波の周波数帯域におけるパワーの変化を検出する必要がある。このような処理は離散フーリエ変換やバンドパスフィルタリングなどの古典的な方法でも可能であるが、本節では、2 クラスの運動想起 BMI の識別に有効な Common Spatial Pattern (CSP) [71–73] と呼ばれる手法について述べる。

時刻インデックス  $n$  における  $m$  番目のチャンネルの観測信号を  $x_m[n]$  ( $m = 1, \dots, M, n = 1, \dots, N$ ) と書くことにする。ここで、 $M$  はチャンネル数 (電極数)、 $N$  はサンプル数である。観測信号を表す行列を  $\mathbf{X} \in \mathbb{R}^{M \times N}$  とすると、 $\mathbf{X}$  の要素は  $[\mathbf{X}]_{m,n} = x_m[n]$  である。 $[\cdot]_{i,j}$  は行列の  $i$  行・ $j$  列の要素を指す。実際に CSP を脳波に適用する際は、観測信号  $\mathbf{X}$  を直接使わずに、運動想起に関連する周波数成分を抽出するバンドパスフィルタ  $\mathcal{H}$  を適用した信号を用いる。ここで、フィルタ  $\mathcal{H}$  を適用した観測信号を  $\hat{\mathbf{X}} = \mathcal{H}(\mathbf{X})$  とし、 $\hat{\mathbf{X}}$  の列ベクトルを、 $\hat{\mathbf{X}} = [\hat{\mathbf{x}}_1, \dots, \hat{\mathbf{x}}_N]$ ,  $\hat{\mathbf{x}}_n \in \mathbb{R}^M$  と書く。CSP は空間重み  $\mathbf{w} \in \mathbb{R}^M$  によって特徴抽出を行う。抽出信号  $\mathbf{w}^T \hat{\mathbf{X}}$  の時間軸に沿った分散は、

$$\sigma^2(\mathbf{X}, \mathbf{w}) = \frac{1}{N} \sum_{n=1}^N |\mathbf{w}^T (\hat{\mathbf{x}}_n - \boldsymbol{\mu})|^2, \quad (6.1)$$

と書ける。ここで、時間平均  $\boldsymbol{\mu}$  を  $\boldsymbol{\mu} = N^{-1} \sum_{n=1}^N \hat{\mathbf{x}}_n$  と定義し、 $\cdot^T$  は行列・ベクトルの転置を表す。CSP は  $\mathbf{w}$  を以下のように求める。

$\mathcal{C}_d$ ,  $d = 1, 2$  を学習データの集合とする。ここで、 $\mathcal{C}_d$  は、クラス  $d$  に属する信号の集合であり、 $\mathcal{C}_1 \cap \mathcal{C}_2 = \emptyset$  が成り立つ。CSP は、全ての抽出信号の分散の期待値を正規化する条件のもと、 $\mathcal{C}_c$  における抽出信号のクラス内分散を最小にする重みベクトルを求める。具体的には、クラス  $c$  を指定し、最適化問題;

$$\begin{aligned} \min_{\mathbf{w}} \quad & E_{\mathbf{X} \in \mathcal{C}_c} [\sigma^2(\mathbf{X}, \mathbf{w})], \\ \text{subject to} \quad & \sum_{d=1,2} E_{\mathbf{X} \in \mathcal{C}_d} [\sigma^2(\mathbf{X}, \mathbf{w})] = 1, \end{aligned} \quad (6.2)$$

を解くことで  $\mathbf{w}_c$  を決定する. ここで,  $E_{\mathbf{X} \in \mathcal{C}_d}[\cdot]$  は  $\mathcal{C}_d$  における期待値である. さらに, (6.2) は,

$$\min_{\mathbf{w}} \mathbf{w}^T \boldsymbol{\Sigma}_c \mathbf{w}, \quad \text{subject to} \quad \mathbf{w}^T (\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2) \mathbf{w} = 1, \quad (6.3)$$

と書ける. ここで,  $\boldsymbol{\Sigma}_d$  を,

$$\boldsymbol{\Sigma}_d = E_{\mathbf{X} \in \mathcal{C}_d} \left[ \frac{1}{N} \sum_{n=1}^N (\hat{\mathbf{x}}_n - \boldsymbol{\mu})(\hat{\mathbf{x}}_n - \boldsymbol{\mu})^T \right], \quad (6.4)$$

と定義する. (6.3) の解は, 一般化固有値問題;

$$\boldsymbol{\Sigma}_c \mathbf{w} = \lambda (\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2) \mathbf{w}, \quad (6.5)$$

の最小一般化固有値に対応する一般化固有ベクトルとして求めることができる [73].

(6.3) の解は, (6.5) の最小固有値に対応する固有ベクトルとして与えられるが, (6.5) によって得られる他の固有ベクトルも特徴抽出に有効である [74–76]. 具体的には, 次の手順で特徴ベクトルを抽出する. (6.5) によって得られる  $M$  個の固有ベクトルを  $\hat{\mathbf{w}}^{(1)}, \dots, \hat{\mathbf{w}}^{(M)}$  とする. また, 固有ベクトルは固有値の大きい順に並んでいるとする.  $2r$  個の固有ベクトルを未知データ  $\mathbf{X}$  の特徴抽出に用いる場合, 特徴ベクトル  $\mathbf{y}$  を

$$\mathbf{y} = [\sigma^2(\mathbf{X}, \hat{\mathbf{w}}^{(1)}), \dots, \sigma^2(\mathbf{X}, \hat{\mathbf{w}}^{(r)}), \sigma^2(\mathbf{X}, \hat{\mathbf{w}}^{(M-r+1)}), \dots, \sigma^2(\mathbf{X}, \hat{\mathbf{w}}^{(M)})]^T. \quad (6.6)$$

と定義する.  $\mathbf{y}$  を識別器に入力し, 未知データの識別を行う.

一般的にフィルタ  $\mathcal{H}$  として 7–30 Hz の通過帯域を持つバンドパスフィルタが選ばれる. この帯域は,  $\mu$  波,  $\beta$  波の帯域を含んでいる. しかし, 最適な帯域は個人差や測定環境によって変わるため [72], 最適な帯域を決定するための手法がいくつか提案されている [74, 76–80].



## 第7章 その他の信号処理

4, 5, 6 節で述べた方法以外にも様々な信号処理のテクニックが開発されている。以下にいくつか例を挙げる。

独立成分分析 (ICA; Independent Component Analysis) [81, 82] は、多変量信号から互いに独立な成分を抽出する方法である。ICA は、脳信号における、信号源推定 [83, 84] や雑音除去 [85–87] に用いられる [88]。

ウェーブレット変換は、ウェーブレットと呼ばれる関数を拡大・縮小・平行移動したものの線形和で元の信号を表現する変換である [89]。短時間フーリエ変換と比べ、ウェーブレット変換は各周波数成分の詳細な時間変化を知ることができる。ウェーブレット変換は脳信号解析や特徴抽出法に用いられている [90, 91]。

経験的モード分解 (EMD; Empirical Mode Decomposition) は、時間-周波数解析法の一つで、複数の周波数成分を持つ信号を狭帯域の信号に分解する手法である [92–94]。EMD は脳波の雑音除去 [95, 96] や特徴抽出 [97] に用いられる。

多次元配列信号処理は、3つ以上の配列次元を持つ信号のための信号処理である [98, 99]。このような信号はテンソルと呼ばれ、多数のインデックスを持つデータ (周波数, 時間, チャンネル) を表すことができる。多次元信号処理によって、多数のインデックスを持つ脳信号を効率的に分解・変換・特徴抽出する手法が提案されている [91, 100, 101]。また、異なるユーザのよるデータから、ユーザ間で共通の特徴を取り出すといった手法も提案されおり [102, 103]、脳信号解析などに用いられている。

## 第8章 まとめ

本稿では，最近のBMI研究の主要なパラダイムとそれらに用いられる信号処理について述べた．BMIパラダイムとして，認知を用いたもの，点滅刺激を用いたもの，運動想起を用いたものを上げ，それらに対して広く用いられる信号処理としてSWLDA, CCA, CSPを挙げた．これ以外にも，集中の度合いによるBMI [104] や聴覚によるもの [61] があり，信号処理も様々な方法が提案されている [2]．

BMIはまだ実用レベルに達していないと言える．BMI実用化のためには，信号処理手法の改善による識別精度の向上のみならず，脳信号測定機器の改良によるユーザの身体的負担の軽減や，パラダイムやインターフェイスの見直しによるユーザビリティの向上が必要である．

## 参考文献

- [1] 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, Jun. 2002.
- [2] G. Dornhege, J. d. R. Millan, T. Hinterberger, D. McFarland, and K.-R. Muller, Eds., *Toward brain-computer interfacing*. The MIT Press, Cambridge, MA, Massachusetts, London, England, 2007.
- [3] Y. Hashimoto, J. Ushiba, A. Kimura, M. Liu, and Y. Tomita, “Change in brain activity through virtual reality-based brain-machine communication in a chronic tetraplegic subject with muscular dystrophy,” *BMC neuroscience*, vol. 11, no. 1, p. 117, 2010.
- [4] G. Pfurtscheller, G. R. Muller-Putz, R. Scherer, and C. Neuper, “Rehabilitation with Brain-Computer Interface Systems,” *Computer*, vol. 41, no. 10, pp. 58–65, 2008.
- [5] J. J. Daly and J. R. Wolpaw, “Brain computer interfaces in neurological rehabilitation,” *The Lancet Neurology*, vol. 7, no. 11, pp. 1032–1043, 2008.
- [6] 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.
- [7] J. K. Chapin, K. A. Moxon, R. S. Markowitz, and M. A. 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.

- [8] M. Velliste, S. Perel, M. C. Spalding, A. S. Whitford, and A. B. Schwartz, “Cortical control of a prosthetic arm for self-feeding,” *Nature*, vol. 453, no. 7198, pp. 1098–1101, 2008.
- [9] L. R. Hochberg, M. D. Serruya, G. M. Friehs, J. A. Mukand, M. Saleh, A. H. Caplan, A. Branner, D. Chen, R. D. Penn, and J. P. Donoghue, “Neuronal ensemble control of prosthetic devices by a human with tetraplegia.” *Nature*, vol. 442, no. 7099, pp. 164–71, 2006.
- [10] E. Niedermeyer and F. H. L. Da Silva, *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins, 2005.
- [11] J. Mellinger, G. Schalk, C. Braun, H. Preissl, W. Rosenstiel, N. Birbaumer, and A. Kbler, “An MEG-based brain computer interface (BCI),” *NeuroImage*, vol. 36, no. 3, pp. 581–593, 2007.
- [12] R. Sitaram, A. Caria, R. Veit, T. Gaber, G. Rota, A. Kuebler, and N. Birbaumer, “fMRI brain-computer interface: a tool for neuroscientific research and treatment,” *Intell. Neuroscience*, vol. 2007, pp. 1:1—1:10, 2007.
- [13] S. M. Coyle, T. E. Ward, and C. M. Markham, “Brain—computer interface using a simplified functional near-infrared spectroscopy system,” *Journal of Neural Engineering*, vol. 4, no. 3, p. 219, 2007.
- [14] D. J. McFarland and J. R. Wolpaw, “Brain-computer interfaces for communication and control,” *Commun. ACM*, vol. 54, no. 5, pp. 60–66, 2011.
- [15] K.-R. Müller, M. Tangermann, G. Dornhege, M. Krauledat, G. Curio, and B. Blankertz, “Machine learning for real-time single-trial EEG-analysis: From brain—computer interfacing to mental state monitoring,” *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 82–90, Jan. 2008.
- [16] R. Scherer, G. R. Muller, C. Neuper, B. Graimann, and G. Pfurtscheller, “An asynchronously controlled EEG-based virtual

- keyboard: improvement of the spelling rate,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 979–984, 2004.
- [17] 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, Jul. 2010.
- [18] F. Galán, M. Nuttin, E. Lew, P. W. Ferrez, G. Vanacker, J. Philips, and J. d. R. Millán, “A brain-actuated wheelchair: Asynchronous and non-invasive Brain—computer interfaces for continuous control of robots,” *Clinical Neurophysiology*, vol. 119, no. 9, pp. 2159–2169, Sep. 2008.
- [19] R. Leeb, D. Friedman, G. R. Müller-Putz, R. Scherer, M. Slater, and G. Pfurtscheller, “Self-paced (asynchronous) BCI control of a wheelchair in virtual environments: a case study with a tetraplegic,” *Intell. Neuroscience*, vol. 2007, pp. 7:1—7:12, 2007.
- [20] K. Choi and A. Cichocki, “Control of a Wheelchair by Motor Imagery in Real Time,” in *Intelligent Data Engineering and Automated Learning —IDEAL 2008*, ser. Lecture Notes in Computer Science, C. Fyfe, D. Kim, S.-Y. Lee, and H. Yin, Eds. Springer Berlin / Heidelberg, 2008, vol. 5326, pp. 330–337.
- [21] C. J. B. Rao, P. Shenoy, R. Chalodhorn, and R. P. N., “Control of a humanoid robot by a noninvasive brain—computer interface in humans,” *Journal of Neural Engineering*, vol. 5, no. 2, p. 214, 2008.
- [22] D. J. McFarland and J. R. Wolpaw, “Brain-Computer Interface Operation of Robotic and Prosthetic Devices,” *Computer*, vol. 41, no. 10, pp. 52–56, 2008.
- [23] R. Llinas, “Neuron,” *Scholarpedia*, vol. 3, p. 1490, 2008.
- [24] P. L. Nunez and R. Srinivasan, “Electroencephalogram,” *Scholarpedia*, vol. 2, p. 1348, 2007.

- [25] J. R. Wolpaw and D. J. McFarland, “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans,” *The National Academy of Sciences*, vol. 101, no. 51, pp. 17 849–17 854, 2004.
- [26] J. Malmivuo and R. Plonsey, *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, 1995, vol. 20, no. 6.
- [27] M. R. Nuwer, “Recording electrode site nomenclature,” *Journal of Clinical Neurophysiology*, vol. 4, no. 2, p. 121, 1987.
- [28] E. Suarez, M. D. Viegas, M. Adjouadi, and A. Barreto, “Relating induced changes in EEG signals to orientation of visual stimuli using the ESI-256 machine.” *Biomedical sciences instrumentation*, vol. 36, p. 33, 2000.
- [29] R. Oostenveld and P. Praamstra, “The five percent electrode system for high-resolution EEG and ERP measurements,” *Clinical Neurophysiology*, vol. 112, no. 4, pp. 713–719, 2001.
- [30] V. Jurcak, D. Tsuzuki, and I. Dan, “10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems.” *NeuroImage*, vol. 34, no. 4, pp. 1600–1611, 2007.
- [31] K. R. Müller, C. W. Anderson, and G. E. Birch, “Linear and non-linear methods for brain-computer interfaces,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 165–169, 2003.
- [32] S. Sanei and J. Chambers, *EEG signal processing*. Wiley-Interscience, 2007.
- [33] A. Cichocki and S. Sanei, “EEG/MEG Signal Processing,” *Computational intelligence and neuroscience*, p. 97026, 2007.
- [34] M. Welling, “Fisher Linear Discriminant Analysis,” *Science*, vol. 1, no. 2, pp. 1–3, 2009.

- [35] C. M. Bishop, *Pattern Recognition and Machine Learning*, ser. Information science and statistics. Springer, 2006.
- [36] R. G. Brereton and G. R. Lloyd, “Support Vector Machines for Classification and Regression,” *The Analyst*, vol. 135, no. 2, pp. 230–267, 2010.
- [37] C. M. Bishop, *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- [38] D. B. Ryan, G. E. Frye, G. Townsend, D. R. Berry, S. Mesa-G, N. A. Gates, and E. W. Sellers, “Predictive Spelling With a P300-Based Brain—Computer Interface: Increasing the Rate of Communication,” *International Journal of Human-Computer Interaction*, vol. 27, no. 1, pp. 69–84, Dec. 2010.
- [39] A. Lenhardt, M. Kaper, and H. J. Ritter, “An Adaptive P300-Based Online Brain Computer Interface,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 16, no. 2, pp. 121–130, 2008.
- [40] S. J. Luck, *An introduction to the event-related potential technique*, ser. Cognitive neuroscience. MIT Press, 2005.
- [41] W. S. Pritchard, “Psychophysiology of P300.” *Psychological Bulletin*, vol. 89, no. 3, pp. 506–540, 1981.
- [42] S. A. Hillyard and M. Kutas, “Electrophysiology of Cognitive Processing,” *Annual Review of Psychology*, vol. 34, no. 1, pp. 33–61, Jan. 1983.
- [43] 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, Dec. 1988.
- [44] E. W. Sellers and E. Donchin, “A P300-based brain—computer interface: Initial tests by ALS patients,” *Clinical Neurophysiology*, vol. 117, no. 3, pp. 538–548, Mar. 2006.

- [45] 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.
- [46] P. Sajda, A. Gerson, K.-R. Müller, B. Blankertz, and L. Parra, “A data analysis competition to evaluate machine learning algorithms for use in brain-computer interfaces,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 184–185, 2003.
- [47] B. Blankertz *et al.*, “The BCI competition 2003: progress and perspectives in detection and discrimination of EEG single trials,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1044–1051, 2004.
- [48] B. Blankertz, G. Dornhege, S. Lemm, M. Krauledat, G. Curio, and K.-r. Müller, “The Berlin Brain-Computer Interface: machine learning based detection of user specific brain states,” 2006.
- [49] N. R. Draper and H. Smith, *Applied Regression Analysis*, J. Wiley, Ed. Springer-Verlag, 1998.
- [50] D. J. Krusienski, E. W. Sellers, F. Cabestaing, S. Bayouthe, 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, p. 299, 2006.
- [51] 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.
- [52] D. Zhu, J. Bieger, G. G. Molina, and R. M. Aarts, “A survey of stimulation methods used in SSVEP-based BCIs,” *Intell. Neuroscience*, vol. 2010, pp. 1:1—1:12, 2010.
- [53] F.-B. Vialatte, M. Maurice, J. Dauwels, and A. Cichocki, “Steady-state visually evoked potentials: Focus on essential paradigms and



- future perspectives,” *Progress in Neurobiology*, vol. 90, no. 4, pp. 418–438, Apr. 2010.
- [54] Y. Wang, X. Gao, B. Hong, C. Jia, and S. Gao, “Brain-Computer Interfaces Based on Visual Evoked Potentials,” *IEEE Engineering in Medicine and Biology Magazine*, vol. 27, no. 5, pp. 64–71, 2008.
- [55] D. Regan, “Some characteristics of average steady-state and transient responses evoked by modulated light,” *Electroencephalography and Clinical Neurophysiology*, vol. 20, no. 3, pp. 238–248, 1966.
- [56] —, “Steady-state evoked potentials,” *Journal of the Optical Society of America*, vol. 67, no. 11, pp. 1475–1489, 1977.
- [57] X. Gao, D. Xu, M. Cheng, and S. Gao, “A BCI-based environmental controller for the motion-disabled,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 137–140, 2003.
- [58] M. Middendorf, G. McMillan, G. Calhoun, and K. S. Jones, “Brain-computer interfaces based on the steady-state visual-evoked response,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 211–214, 2000.
- [59] G. R. Muller-Putz, R. Scherer, C. Neuper, and G. Pfurtscheller, “Steady-state somatosensory evoked potentials: suitable brain signals for brain-computer interfaces?” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 1, pp. 30–37, 2006.
- [60] D. S. Goodin, K. C. Squires, and A. Starr, “Long latency event-related components of the auditory evoked potential in dementia.” *Brain : a journal of neurology*, vol. 101, no. 4, pp. 635–648, Dec. 1978.
- [61] H. Higashi, T. M. Rutkowski, Y. Washizawa, A. Cichocki, and T. Tanaka, “EEG auditory steady state responses classification for the novel BCI,” in *Proceedings of 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2011, pp. 4576–4579.

- [62] H. Bakardjian, T. Tanaka, and A. Cichocki, “Optimization of SSVEP brain responses with application to eight-command Brain—Computer Interface,” *Neuroscience Letters*, vol. 469, no. 1, pp. 34–38, Jan. 2010.
- [63] 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. 53, no. 12, pp. 2610–2614, 2006.
- [64] H. Hotelling, “Relations between two sets of variates,” *Biometrika*, vol. 28, no. 3/4, pp. 321–377, 1936.
- [65] T. W. Anderson, *An introduction to multivariate statistical analysis*. Wiley New York, 1958, vol. 2.
- [66] G. Pfurtscheller, C. Neuper, D. Flotzinger, and M. Pregenzer, “EEG-based discrimination between imagination of right and left hand movement,” *Electroencephalography and Clinical Neurophysiology*, vol. 103, no. 6, pp. 642–651, Dec. 1997.
- [67] G. Dornhege, B. Blankertz, G. Curio, and K.-R. Müller, “Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms,” *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 993–1002, 2004.
- [68] M. Grosse-Wentrup and M. Buss, “Multiclass Common Spatial Patterns and Information Theoretic Feature Extraction,” *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 8, pp. 1991–2000, 2008.
- [69] A. Kübler, F. Nijboer, J. Mellinger, T. M. Vaughan, H. Pawelzik, G. Schalk, D. J. McFarland, N. Birbaumer, and J. R. Wolpaw, “Patients with ALS can use sensorimotor rhythms to operate a brain-computer interface,” *Neurology*, vol. 64, no. 10, pp. 1775–1777, May 2005.
- [70] K.-R. Müller and B. Blankertz, “Toward noninvasive brain-computer interfaces,” *IEEE Signal Processing Magazine*, vol. 23, no. 5, pp. 126–128, 2006.

- [71] H. Ramoser, J. Müller-Gerking, and G. Pfurtscheller, “Optimal spatial filtering of single trial EEG during imagined hand movement,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 441–446, 2000.
- [72] J. Müller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, “Designing optimal spatial filters for single-trial EEG classification in a movement task,” *Clinical Neurophysiology*, vol. 110, no. 5, pp. 787–798, May 1999.
- [73] B. Blankertz, M. Kawanabe, R. Tomioka, F. Hohlefeld, V. Nikulin, and K. R. Müller, “Invariant common spatial patterns: Alleviating nonstationarities in brain-computer interfacing,” *Advances in Neural Information Processing Systems*, vol. 20, pp. 113–120, 2008.
- [74] S. Lemm, B. Blankertz, G. Curio, and K.-R. Müller, “Spatio-spectral filters for improving the classification of single trial EEG,” *IEEE Transactions on Biomedical Engineering*, vol. 52, no. 9, p. 1541, 2005.
- [75] G. Dornhege, B. Blankertz, M. Krauledat, F. Losch, G. Curio, and K.-R. Müller, “Combined Optimization of Spatial and Temporal Filters for Improving Brain-Computer Interfacing,” *IEEE Transactions on Biomedical Engineering*, vol. 53, no. 11, pp. 2274–2281, 2006.
- [76] R. Tomioka, G. Dornhege, G. Nolte, B. Blankertz, K. Aihara, and K. R. Müller, “Spectrally weighted common spatial pattern algorithm for single trial eeg classification,” *Dept. Math. Eng., Univ. Tokyo, Tokyo, Japan, Tech. Rep*, vol. 40, 2006.
- [77] Q. Novi, C. Guan, T. H. Dat, and P. Xue, “Sub-band Common Spatial Pattern (SBCSP) for Brain-Computer Interface,” in *Proceedings of 3rd International IEEE/EMBS Conference on Neural Engineering*, 2007, pp. 204–207.
- [78] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, “Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface,” in

- Proceedings of The 2008 International Joint Conference on Neural Networks (IJCNN)*, 2008, pp. 2390–2397.
- [79] H. Higashi and T. Tanaka, “Classification by weighting for spatio-frequency components of EEG signal during motor imagery,” in *Proceedings of 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2011, pp. 585–588.
- [80] ———, “Optimal design of a bank of spatio-temporal filters for EEG signal classification,” in *Proceedings of 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2011, pp. 6100–6103.
- [81] A. Hyvärinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, ser. Adaptive and learning systems for signal processing, communications, and control, S. Haykin, Ed. Wiley-Interscience, 2001, vol. 21, no. 1.
- [82] A. Cichocki and S. Amari, *Adaptive blind signal and image processing: learning algorithms and applications*. Wiley, 2002.
- [83] B. B. Biswal and J. L. Ulmer, “Blind Source Separation of Multiple Signal Sources of fMRI Data Sets Using Independent Component Analysis,” *Journal of Computer Assisted Tomography*, vol. 23, no. 2, 1999.
- [84] V. D. Calhoun, T. Adali, L. K. Hansen, J. Larsen, and J. J. Pekar, “ICA of Functional MRI Data: An Overview,” in *Proceedings of the International Workshop on Independent Component Analysis and Blind Signal Separation*, 2003, pp. 281–288.
- [85] Y. L. Chai, P. Cao, J. Sun, J. Wang, L. Li, Q. Ren, Y. Chen, and Xinyu, “Using independent component analysis to remove artifacts in visual cortex responses elicited by electrical stimulation of the optic nerve,” *Journal of Neural Engineering*, vol. 9, no. 2, p. 26002, 2012.
- [86] T.-P. Jung, C. Humphries, T.-W. Lee, S. Makeig, M. J. McKeown, V. Iragui, and T. J. Sejnowski, “Extended ICA removes artifacts from electroencephalographic recordings,” in *Proceedings of*

*The 1997 conference on Advances in neural information processing systems*, ser. NIPS '97. Cambridge, MA, USA: MIT Press, 1998, pp. 894–900.

- [87] T.-P. Jung, S. Makeig, C. Humphries, T.-W. Lee, M. J. McKeown, V. Iragui, and T. J. Sejnowski, “Removing electroencephalographic artifacts by blind source separation,” *Psychophysiology*, vol. 37, no. 02, pp. 163–178, 2000.
- [88] A. Delorme and S. Makeig, “EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis,” *Journal of Neuroscience Methods*, vol. 134, no. 1, pp. 9–21, Mar. 2004.
- [89] S. Mallat, *A Wavelet Tour of Signal Processing*. Academic Press, 1998.
- [90] W. Ting, Y. Guo-zheng, Y. Bang-hua, and S. Hong, “EEG feature extraction based on wavelet packet decomposition for brain computer interface,” *Measurement*, vol. 41, no. 6, pp. 618–625, Jul. 2008.
- [91] A. H. Phan and A. Cichocki, “Tensor decompositions for feature extraction and classification of high dimensional datasets,” *IEICE Nonlinear Theory and Its Applications*, vol. 1, no. 1, pp. 37–68, 2010.
- [92] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, “The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis,” *Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 454, no. 1971, pp. 903–995, 1998.
- [93] T. Tanaka and D. P. Mandic, “Complex Empirical Mode Decomposition,” *IEEE Signal Processing Letters*, vol. 14, no. 2, pp. 101–104, 2007.

- [94] N. Rehman and D. P. Mandic, “Multivariate empirical mode decomposition,” *The Royal Society A: Mathematical, Physical and Engineering Science*, vol. 466, no. 2117, p. 1291, 2010.
- [95] T. M. Rutkowski, A. Cichocki, T. Tanaka, D. P. Mandic, J. Cao, and A. L. Ralescu, “Multichannel spectral pattern separation - An EEG processing application -,” in *Proceedings of 2009 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2009, pp. 373–376.
- [96] M. K. I. Molla, T. Tanaka, T. M. Rutkowski, and A. Cichocki, “Separation of EOG artifacts from EEG signals using bivariate EMD,” in *Proceedings of 2010 IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP)*, 2010, pp. 562–565.
- [97] T. M. Rutkowski, D. P. Mandic, A. Cichocki, and A. W. Przybyszewski, “EMD approach to multichannel EEG data—the amplitude and phase components clustering analysis,” *Journal of Circuits, Systems and Computers*, vol. 19, no. 1, pp. 215–229, 2010.
- [98] A. Cichocki, R. Zdunek, and A. H. Phan, *Nonnegative matrix and tensor factorizations: applications to exploratory multi-way data analysis and blind source separation*. Wiley, 2009.
- [99] T. G. Kolda and B. W. Bader, “Tensor decompositions and applications,” *SIAM review*, vol. 51, no. 3, pp. 455–500, 2009.
- [100] 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, pp. 34–42, 2008.
- [101] Y. Washizawa, H. Higashi, T. Rutkowski, T. Tanaka, and A. Cichocki, “Tensor Based Simultaneous Feature Extraction and Sample Weighting for EEG Classification,” in *Neural Information Processing. Models and Applications*, ser. Lecture Notes in Computer Science, K. Wong, B. Mendis, and A. Bouzerdoum, Eds. Springer Berlin / Heidelberg, 2010, vol. 6444, pp. 26–33.

- [102] A. R. Groves, C. F. Beckmann, S. M. Smith, and M. W. Woolrich, “Linked independent component analysis for multimodal data fusion,” *NeuroImage*, vol. 54, no. 3, pp. 2198–2217, 2011.
- [103] A. H. Phan and A. Cichocki, “PARAFAC algorithms for large-scale problems,” *Neurocomputing*, 2011.
- [104] E. C. Leuthardt, G. Schalk, J. R. Wolpaw, G. J. Ojemann, and D. W. Moran, “A brain—computer interface using electrocorticographic signals in humans,” *Journal of Neural Engineering*, vol. 1, no. 2, p. 63, 2004.