

# 簡易脳波計を用いた脳波の計測と識別

M2019SC003 河合大樹

指導教員：大石泰章

## 1 はじめに

Brain Machine Interface (BMI) とは脳機能信号にもとづいてコンピュータを制御する技術であり、医療や福祉の場などでの活用が期待されている。BMI には侵襲的なものと非侵襲的なものがある。侵襲的なものは、特定の脳領域に直接アクセスすることができるため、高い精度での脳情報の入出力が可能であるが、安全性の面から容易に取り入れることはできない。一方、非侵襲的なものは体の外から脳活動を間接的に測定するため、侵襲的なものと比べて精度は落ちるものの安全性が高く、健常者を対象とした実験も容易に行うことができる [1]。非侵襲的なものの中でも脳波計を用いて脳情報を取得することは、導入のしやすさ、実験自由度の高さといった点で優れている。

また、脳波計により取得できる脳波は複数の周波数帯域の成分を含んでおり、それぞれ覚醒状態の変化や感覚受容、運動意図などによって振幅や位相が変化することが知られている [2]。BMI では特定の周波数帯域の自発脳波活動をユーザが意図的に変化させることで指示を行うものがある。

本研究では、低コストで手に入る簡易脳波計 EMOTIV EPOC+ を用いて脳波の計測を行い識別することで、低コストの BMI 開発を目指す。具体的には、通常時の脳波と運動時の脳波を計測し、脳波の周波数成分の中でも運動と関連が深いとされる  $\alpha$  波と  $\beta$  波を取り出して特徴量とする [3]。そして、Support Vector Machine (SVM) を用いて 2 つの脳波の識別を行う。

## 2 使用する脳波計

本研究では、脳波の計測に EMOTIV 社の EMOTIV EPOC+ (図 1) を使用する。EMOTIV EPOC+ は脳波計の中でも比較的安価であり、低コストの BMI 開発に適していると考えられる。また、あらかじめ電極の配置が決まっているため電極位置の調整を行う必要がなく、電極フェルトを用いるためジェルを用いる脳波計と比べて準備の手間が少ないなど、扱いやすい脳波計である。



図 1 EMOTIV EPOC+ の概観

### 2.1 脳波計のセットアップ

最初にフェルトパッドに入っている電極フェルトに生理食塩水をかける (図 2)。このときセンサの感度が悪くならないように、電極フェルトに十分な量の生理食塩水をかける必要がある。次に電極フェルトを脳波計のそれぞれの電極の位置に取り付け、頭に装着する。脳波計の装着例を図 3 に示す。装着するときは、基準電極が乳様突起の位置にくるように電極の位置調整を行う。その後、脳波計の電源を入れコンピュータと接続することで脳波の計測ができる。コンピュータとの接続は Bluetooth 通信を使用することにより、ワイヤレスで行うことができる。



図 2 生理食塩水と電極フェルト



図 3 脳波計装着例

### 2.2 脳波計の電極配置

EMOTIV EPOC+ では、AF3, AF4, F3, F4, F8, FC5, FC6, T7, T8, P7, P8, O1, O2 の 14 チャンネルの電極で脳波を計測できる。図 4 にこれら 14 チャンネルの電極の配置を示す。この図での CMS と DRL は電位変動のベースラインとして用いられる基準電極を表している。EMOTIV EPOC+ の電極配置は、脳波計測で広く使われている国際 10-20 法 (図 5) と比べて頭頂部の電極がない配置となっているが、前頭葉、側頭葉、後頭葉と脳の広い範囲をカバーできている。

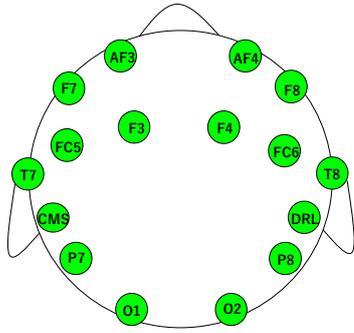


図 4 EMOTIV EPOC+の電極配置

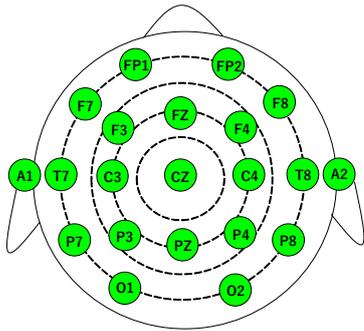


図 5 国際 10-20 法による電極配置

### 3 使用するソフトウェア

脳波の計測には EMOTIV 専用のソフトウェアである EMOTIV PRO を用いる。EMOTIV PRO の画面を図 6 に示す。EMOTIV PRO では脳波計測の前に電極の接触状態を確認することができる。脳波の計測を始めると、図 6 のように各チャンネルにおける脳波の変化を観測することができる。このとき、イベントマーカを用いてイベントが行われた時刻を記録することも可能である。

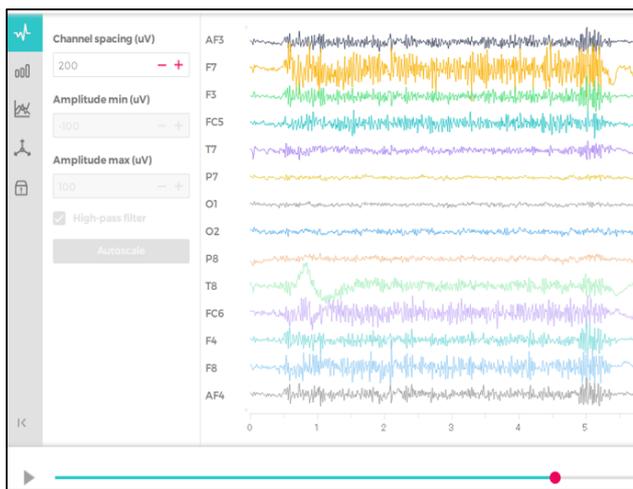


図 6 EMOTIV PRO

### 4 識別の手順

本研究で行う識別の手順を図 7 に示す。本研究では、通常時の脳波と運動時の脳波を識別することを目的とする

ため、初めに 2 つの脳波の計測を行う。次に、計測した脳波データから使用する時間区間を決めてデータを抜き出し、抜き出した区間の脳波データから特徴量の抽出を行う。そして、抽出した特徴量を用いて SVM で 2 つの脳波の識別を行い、どの時間区間のデータを用いると最も良い識別率が得られるかを求める。

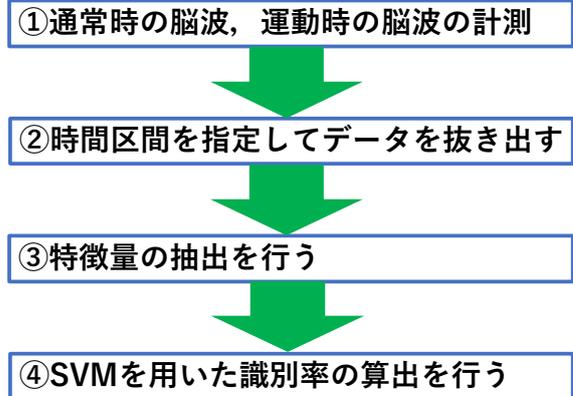


図 7 識別の手順

#### 4.1 脳波の計測

脳波の計測は、静かな部屋で椅子に座った状態で行った。リラックスした状態で椅子に座っているときの脳波を通常時の脳波、左足のつま先を上げ下げする動作を行っているときの脳波を運動時の脳波とする。運動時の脳波は 5 秒の運動と 10 秒の休憩を 1 セットとして繰り返し、100 セットのデータを取得した。この時、10 セットごとに長めの休憩を挟んで行った。また、通常時の脳波も 5 秒間のデータを 100 セット取得した。

計測した 5 秒間のデータ 100 セットのうちの 1 つを図 8、図 9 に示す。図 8 は通常時の脳波、図 9 は運動時の脳波を表したものである。この 2 つの図から、通常時の脳波と運動時の脳波の波形を比較してもはっきりとした違いは見られない。

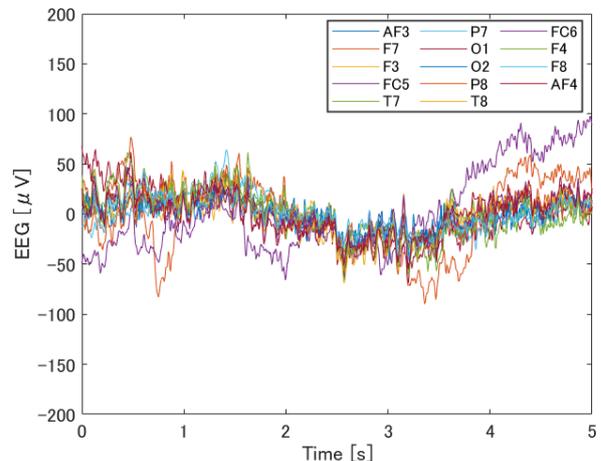


図 8 通常時の脳波

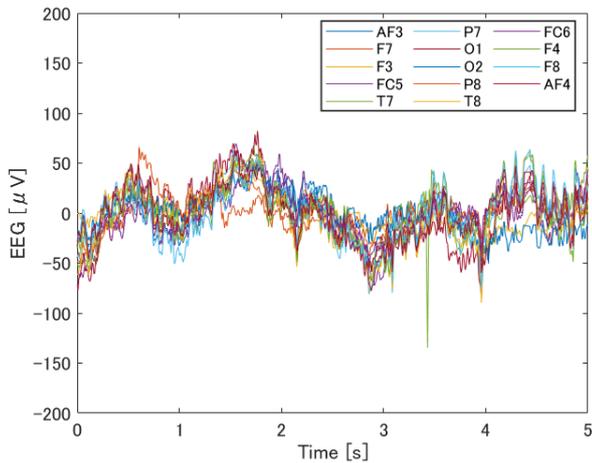


図9 運動時の脳波

#### 4.2 データの抜き出し

計測した5秒間の脳波データから開始時刻と時間幅を指定して特定の区間のデータの抜き出しを行う(図10)。開始時刻は運動開始の合図から0秒後、0.5秒後、1秒後の3種類とし、時間幅は1秒間、1.5秒間、2秒間の3種類とする。これらの組み合わせにより9種類の脳波データが得られるが、そのそれぞれに対して、特徴量の抽出とSVMによる識別を行う。

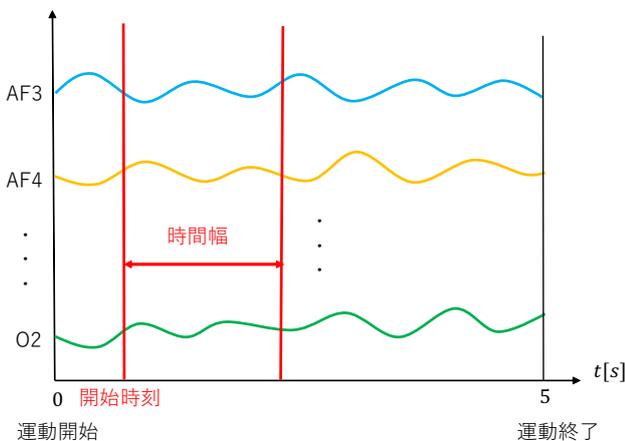


図10 データを抜き出す時間区間

#### 4.3 特徴量の抽出方法

特徴量の抽出では、運動に関係する脳波である $\alpha$ 波と $\beta$ 波に着目する。 $\alpha$ 波の周波数帯域は8~13[Hz]、 $\beta$ 波の周波数帯域は13~30[Hz]である。そこで、抜き出したデータに対してそれぞれ8~13[Hz]と13~30[Hz]を通過帯域とするバンドパスフィルタをかけ、得られたデータを二乗して平均をとったものを特徴量として使用する。 $\alpha$ 帯域のものも $\beta$ 帯域のものもそれぞれ脳波データは14チャンネルで計測されているため、特徴量の数は28個となる。

#### 4.4 SVMを用いた脳波の識別

抽出した特徴量を用いて2つの脳波の識別を行う。識別にはSVMを用いる[4]。SVMは教師あり学習により識別を行う手法の1つで主に2クラスの分類に用いられるものであり、2クラスを分離する最適な超平面を見つけてデータを分類する。SVMではまず学習データが線形分離可能な場合について考える。線形分離可能な場合のSVMのイメージ図を図11に示す。 $p$ 次元の変数 $\mathbf{x} = (x_1 \ x_2 \ \dots \ x_p)^T$ からなる $n$ 個の学習データ $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ が与えられ、これらの学習データは2つのクラス $G_1, G_2$ のどちらに属するかわかっているとす。このとき、2クラスを分離する超平面:

$$\mathbf{w}^T \mathbf{x} + b = 0 \quad (1)$$

を構成することが目的である。この最適な分離超平面はマージン最大化問題:

$$\min_{\mathbf{w}} \frac{1}{2} \|\mathbf{w}\|^2, \quad \text{制約条件 } y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1, i = 1, 2, \dots, n \quad (2)$$

を解くことにより求められる。ここで $y_i$ はラベル変数であり、

$$y_i = \begin{cases} 1, & \mathbf{x}_i \text{ が } G_1 \text{ に属するとき;} \\ -1, & \mathbf{x}_i \text{ が } G_2 \text{ に属するとき} \end{cases} \quad (3)$$

で表される。

次に線形分離可能でない学習データについて考える。線形分離可能でない学習データにはスラック変数 $\xi_i \geq 0$ を導入して制約式を緩める。スラック変数 $\xi_i$ を導入したときのマージン最大化問題は

$$\min_{\mathbf{w}, \xi} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + \lambda \sum_{i=1}^n \xi_i \right\}, \quad \text{制約条件 } y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \xi_i \geq 0, i = 1, 2, \dots, n \quad (4)$$

と定式化される。ここで $\lambda$  ( $\lambda > 0$ )は制約式を緩めることに対するペナルティを調整するためのパラメータである。この問題を解くことで最適な分離超平面を構成し、データの分類を行う。

また、SVMによる識別率の算出には4分割交差検証を用いる[5]。4分割交差検証の様子を図12に示す。4分割交差検証では、抽出した特徴量データを4つの同じサイズのデータに分割する。次に分割したデータをテストデータと訓練データに分けてモデルの訓練を行う。最初のモデルは分割2~4を訓練データとして用いてモデルを構築し、分割1をテストデータとして用いて識別率を算出する。次のモデルでは分割2をテストデータとし、残りを訓練データとして用いる。同様の過程を分割3, 4をテストデータとして行うことで、4つの識別率が得られる。この平均値を取ったものを最終的な識別率とする。

SVMの識別モデルの作成、識別率の算出はMATLABのStatistics and Machine Learning Toolbox内の分類学習機アプリを用いて行う[6]。

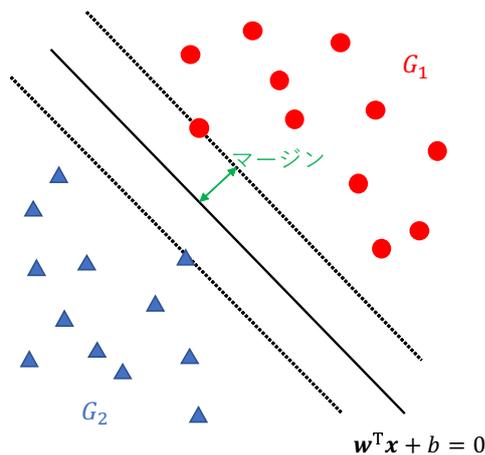


図 11 SVM のイメージ図

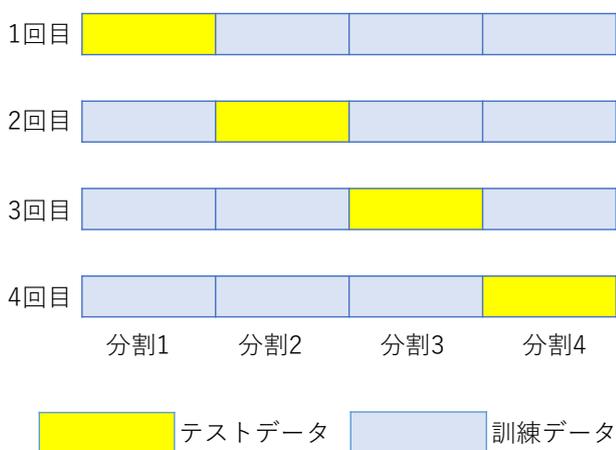


図 12 4分割交差検証

## 5 識別結果

4章の手順に従って識別率を算出し、時間区間ごとにまとめたものを表1に示す。9つの時間区間で識別率の算出を行った結果、最も良い識別率を得られたのは開始時刻を0.5[s]、時間幅を1.5[s]としたときであり識別率は74.5%となった。この時間区間で作成したモデルを通常時の脳波と運動時の脳波を識別する最終的なモデルとする。

表 1 抜き出した時間区間ごとの識別率

| 開始時刻 [s] | 時間幅 [s] | 識別率 [%] |
|----------|---------|---------|
| 0        | 1.0     | 61.5    |
|          | 1.5     | 62.0    |
|          | 2.0     | 71.5    |
| 0.5      | 1.0     | 65.5    |
|          | 1.5     | 74.5    |
|          | 2.0     | 73.5    |
| 1.0      | 1.0     | 65.0    |
|          | 1.5     | 73.0    |
|          | 2.0     | 71.5    |

## 6 運動想起時の脳波の識別

運動時の脳波を用いて作成したモデルが運動想起を行った時の脳波の識別にも有効であるかを調べる。運動想起時の脳波には、運動時の脳波を計測したときと同じ運動である左足のつま先を上げ下げする動作をイメージしたときの脳波を使用する。運動想起時の脳波の計測では5秒の運動想起と10秒の休憩を1セットとして繰り返し、50セットのデータを取得した。そして、計測した5秒間のデータから開始時刻を0.5[s]、時間幅を1.5[s]としてデータを抜き出し、特徴量を抽出してモデルにより識別を行った。その結果、得られた識別率は42%となり、運動時の脳波を用いて作成したモデルは運動想起時の脳波の識別には有効でないことがわかった。

## 7 おわりに

本研究では、簡易脳波計を用いて通常時の脳波と運動時の脳波の計測を行い、運動時の脳波では $\alpha$ 波、 $\beta$ 波に変化があることに注目して特徴量の抽出を行った。そして、抽出した特徴量を用いてSVMによる識別を行い、運動開始後のどの区間で最も良い識別率が得られるかを調べた。その結果、運動開始後の0.5~2[s]の区間で最も良い識別率(74.5%)が得られることがわかった。また、作成した識別モデルが運動想起時の脳波の識別にも有効であるかを調べたが、識別率は42%と低く運動想起時の脳波の識別には用いることはできないという結果になった。

今後の課題として、運動時の脳波の識別モデルを作成した時と同様の手順を運動想起時の脳波を用いて行い、識別モデルを作成することで、運動想起時の脳波を識別することができるか調べることが挙げられる。

## 参考文献

- [1] 長谷川良平:「ブレイン-マシン インターフェースの現状と将来」. 電子情報通信学会誌, vol.91, no.12 (2008) pp.1066-1075.
- [2] 小野弓絵:「MATLABで学ぶ生体信号処理」. コロナ社, 東京, 2019.
- [3] 吉岡将孝:「脳波分析に基づいた Brain-Machine Interface パワーアシストシステムの構築-周期性パワースペクトルによる運動に関する脳波の解析および関節トルクの推定-」. 前橋工科大学研究紀要, 20 卷 (2017) pp.61-62
- [4] 小西貞則:「多変量解析入門」. 岩波書店, 東京, 2019.
- [5] アンドレアス・C・ミュラー, サラ・ガイド著, 中田秀基訳:「Pythonではじめる機械学習-scikit-learnで学ぶ特徴エンジニアリングと機械学習の基礎」. オーム社, 東京, 2017.
- [6] 分類学習機アプリ - MATLAB & Simulink - MathWorks 日本  
<https://jp.mathworks.com/help/stats/classification-learner-app.html> (2021年1月現在)