

修士論文の和文要旨

研究科・専攻	大学院 情報理工学研究科 機械知能システム学専攻 博士前期課程		
氏名	掬川 伊織	学籍番号	2032033
論文題目	ブレインマシンインターフェースのための α 波の周波数解析法の応用に関する研究		
要旨	<p>近年、人の生体信号を活用した身体障害者のためのサポートツールの開発・研究が進められている。なかでも脳情報を用いたブレインマシンインターフェース (BMI) は、麻痺などによって身体を動かすことができなくなった肢体不自由者の運動機能の補助に役立っている。吉岡らは、肘の屈曲伸展運動における周期パワースペクトルを用いて脳波と肘関節トルクとの間の線形モデルを構築し、脳波から肘関節トルクの推定およびその有効性を示した。</p> <p>卒業論文では、この研究を応用し、肘の屈曲伸展による上肢運動だけでなく、手部の握りや開きといった把握動作に適用し、同様に周期パワースペクトルに変化が生じることが明らかとなった。</p> <p>そこで、本論文では、周期パワースペクトルを利用したロボットハンドの制御に向け、手部の基本動作である把握動作における安静状態、握り状態、開き状態をそれぞれ識別するため、サポートベクタマシン (SVM) を用いた判別器を構築し、その判別器の識別精度を評価した。</p>		

令和3年度 修士論文



ブレインマシンインターフェースのための
 α 波の周波数解析法の応用に関する研究

主任指導教員 横井浩史 教授

指導教員 中村友昭 准教授

電気通信大学大学院 情報理工学研究科 機械知能システム学専攻

学籍番号 2032033

掬川 伊織

Iori Kikukawa

目次

第1章 序論	9
1.1 研究背景.....	10
1.2 関連研究.....	11
1.2.1 前腕義手.....	11
1.2.2 筋電制御方式.....	12
1.3 研究目的.....	14
1.4 本論文の構成.....	15
第2章 先行研究	17
2.1 はじめに.....	18
2.2 ブレインマシンインターフェース.....	19
2.2.1 BMIの概要.....	19
2.2.2 脳活動情報の計測手法.....	20
2.2.3 脳波に関する研究.....	22
2.2.4 周期パワースペクトル解析法.....	23
2.3 解決すべき課題.....	24
2.4 おわりに.....	25
第3章 データ解析手法	27
3.1 はじめに.....	28
3.2 周波数解析法.....	29
3.2.1 高速フーリエ変換.....	29
3.2.2 短時間フーリエ変換.....	31
3.2.3 周期パワースペクトル.....	33
3.3 状態判別器.....	36
3.3.1 サポートベクタマシン.....	36
3.3.2 マルチクラス判別.....	39
3.3.3 マハラノビス距離.....	41
3.3.4 交差検証.....	42
3.4 おわりに.....	43
第4章 実験および解析	45
4.1 はじめに.....	46
4.2 実験目的および概要.....	47
4.3 計測機器.....	49
4.3.1 脳波計.....	49
4.3.2 脳波解析ソフトウェア.....	51
4.4 周期パワースペクトルをもちいた状態判別.....	52
4.4.1 システム概要.....	52

4.4.2 安静状態と握り状態の2クラス判別	53
4.4.3 安静状態と握り準備状態の2クラス判別	54
4.4.4 構築したシステムの再考	55
4.4.5 デシベル変換および平滑化をもちいた2クラス判別	57
4.4.6 握りおよび開き動作の2クラス判別	60
4.4.7 把握動作のマルチクラス判別	61
4.5 マハラノビス距離をもちいた状態判別	64
4.5.1 安静状態と握りまたは開き状態の2クラス判別	64
4.5.2 握りおよび開き状態の2クラス判別	66
4.5.3 把握動作のマルチクラス判別	67
4.6 おわりに	70
第5章 考察	71
5.1 はじめに	72
5.2 考察	73
5.3 おわりに	76
第6章 結論	77
6.1 はじめに	78
6.2 結論	79
6.3 今後の展望	81
謝辞	83
参考文献	85

第1章 序論

1.1 研究背景.....	10
1.2 関連研究.....	11
1.3 研究目的.....	14
1.4 本論文の構成.....	15

1.1 研究背景

日本における身体障害者の総数は昭和 26 年から現在まで増加し続けている。厚生労働省によると平成 28 年の身体障害者数は 428 万人を超え、そのうち肢体不自由の割合が最も高く全体の 45%を占めている[厚生労働省 2019]。そのような身体障害者の QoL(Quality of Life)の向上を目的として、運動補助や身体機能の代替を担うさまざまな機器が開発されてきている。特に、近年では人の生体信号を利用した技術が注目されており、筋電義手はそのひとつである。筋電義手とは、主に表面筋電位(sEMG: surface electromyography)を入力信号として扱い、モータ駆動によって握りや開きといった手部の運動を再現する機能をもつ義手である。他の義手に比べ、把持力が大きく、体勢に影響されることなく直観的な操作が可能であることから日常生活動作においてより実用的である[浅見 2013]。しかしながら、使用者の欠損レベルによって残存筋の位置や形状が健常者と異なる場合や断端部周辺に麻痺を伴う場合が報告されており[生田 2003]、十分な sEMG が計測できないことによって筋電義手を操作できないという問題が懸念される。そこで、人の脳活動から運動情報を抽出することによって欠損による残存筋の状態や麻痺による影響を受けずにハンドを操作することができると考えられる。このように脳活動情報を利用して直接的に外部機器を操作する技術をブレインマシンインターフェース(BMI:Brain Machine Interface)と呼ぶ。脳活動情報の計測手法はいくつか存在するが、なかでも脳波(EEG: electroencephalography)は非侵襲性や可搬性などの特徴から関心を集めている。最近の研究では、脳波を用いた電動車いすの移動制御[田中 2012]や、 α 波と β 波のパワースペクトルの周期性を利用した外骨格ロボットアームの制御[Yoshioka et. al 2016]などの試みがある。

先行研究では、把握動作と α 波の周期パワースペクトルとの関連性が報告された[掬川 2019]。このことから、この周期パワースペクトル解析法を用いて電動義手やロボットハンドといった外部機器を制御できると期待される。しかしながら、この手法を用いたハンド制御を試みた文献は我々の知る限り見られない。また、周期パワースペクトルを用いて実用的なハンドの制御をするにあたり、把握動作について握りや開きなどの複数の状態を識別する必要がある。

1.2 関連研究

1.2.1 前腕義手

義手とは、病気や事故などが原因で失った上肢の機能や形を復元する器具である。上肢の欠損レベルによって種類が異なり、そのうち切断部が肘から手首の間である前腕欠損者が使用する義手を前腕義手と呼ぶ。その種類は、機能や操作方法によって装飾義手・作業用義手・能動義手・電動義手に大きく分類される。

装飾義手は、外観を補うために健常な上司に近い外見を持つ義手である。他の義手と比べ軽量かつ非常に装飾性が高いが、可動部を持たないため失われた上肢の運動機能を代替することはできない。

作業用義手は、ある特定の作業をするために特化した形状をしている義手である。作業効率や剛性を重視して製造されるため、装飾性の低さや作業ごとに異なるハンドを付け替える必要がある。

能動義手は、体動を動力源として上肢の運動を代替する機能を持つ義手である。ハンドの開閉などの機能を有するが、義手を操作するために身体の余剰動作が必要である。また、体勢が把持動作に影響することや、自由に使えるようになるために長い訓練が必要になるなど多くの制約がある。

電動義手は、モータによって駆動する上肢の運動機能を代替する機能を有する義手である。特に、筋電センサをもちいて表面筋電位(sEMG)を入力信号として作動する電動義手を筋電義手と呼ぶ。筋電義手は、体勢による影響を受けることなく大きな把持力を発揮できるため、日常生活動作においてより実用的である[浅見 2013]。一方で、使用者によって残存筋の位置や形状が健常者と異なる場合や、麻痺を伴う場合がある[生田 2003]。その場合、離断肢から十分なsEMGを取得することは困難であり、筋電義手を操作することができない

という問題が懸念される。

また、上肢切断者に対するアンケート調査によると、回答者のうち 76%が筋電義手の使用を希望していることがわかっている。その理由は、主に直観的な操作や強い把持力が可能であることが挙げられている。さらに、使用者の意見として義手の軽量化や装飾性に加え、把持動作の多様化が望まれている[川村ら 1999]。このことから、義手使用者は義手に対して把握動作をはじめとする、機能性を求めていることが読み取れる。

1.2.2 筋電制御方式

前節では、義手のなかでも筋電位を制御信号として動作する筋電義手についての特徴を、他の義手と比較しながら説明した。ひとくちに筋電義手と言っても、その制御方式はさまざまである[横井 2014]。ここでは、筋電位をもちいた制御方式を大きく 3 つの分け、それらについて説明する。

1) 閾値判別による制御

閾値処理によって筋電位から入力の有無を判別し、スイッチとしての機能を有する制御方式である。時間応答性に乏しいが、簡単な電子回路で実現できるほか、筋電信号の ON/OFF を符号化することによってさまざまなパターンをつくり出し、多くの種類を判別することができる。このスイッチ機能は、筋電義手における開閉動作の制御にもちいられ、前腕の伸筋と屈筋の差について閾値処理をおこないハンドの開閉を決定する。

2) 比例制御

比例制御は、筋電信号の大きさに比例して力や速さなどの出力を対応づける制御方式である。運動意図に伴う筋電信号を直接制御に反映できるため時間応答性が高く、また最も直観的な操作を実現できる。筋電義手のハンドの開閉スピードの制御にもちいられ、筋電信号の強さと義手のモータ回転速度を対応させる。筋の収縮強度の増加に伴い筋電信号の大きさも増加することが報告されているが[木村 1992]、筋疲労や計測する筋ごとの特性、センサの接触状態などによって影響を受けるといった問題がある。

3) 波形パターン識別

筋電信号の特徴量には、振幅強度だけでなく空間周波数も含まれ、手指の動作ごとに波形の特徴が異なる。このことから、周波数解析と機械学習を組み合わせ、筋電の波形パターンから手指の動作を識別することが可能である。パターンによる識別であることから複数の動作意図を抽出することができるほか、利用者ごとに異なる筋電信号であっても適応することができる。そのため、長期間のトレーニングを必要とせず、初心者でも容易に利用することが可能である。

このように、筋電をもちいた制御方式は複数存在し、それぞれに特徴があることがわかった。本研究では、入力信号を筋電ではなく脳波としてハンドの制御することを目指している。そこで、本節で紹介した筋電による制御方式を脳波による制御に応用することを検討する。なお、脳波については次章にて説明する。

1.3 研究目的

本研究では, 脳波を用いた BMI ロボットハンド制御システムの開発に向け, 先行研究において把握動作との関連性が報告された脳波のうち最も反応を示した α 波に着目し, その周期パワースペクトルから把握動作を識別するための状態判別システムの構築を目的とする. そのために, まず脳波から手部の運動に関連する α 波の周期パワースペクトルを算出する. 次に, その周期パワースペクトルをサポートベクタマシンに学習させ, 運動状態を識別する判別器の構築を行う.

1.4 本論文の構成

本章では, 研究背景および目的を述べた.

第 2 章では, BMIの概要および脳波に関する研究やその計測手法について述べる.

第 3 章では, データの解析について述べる.

第 4 章では, 実験および解析結果について述べる.

第 5 章では, 考察を述べる.

第 6 章では, 本論文のまとめを述べる.

第2章 先行研究

2.1 はじめに.....	18
2.2 ブレインマシンインターフェース	19
2.3 解決すべき課題.....	24
2.4 おわりに.....	25

2.1 はじめに

本章では, 脳活動情報を利用した技術である BMI とその先行研究について説明する. 2.2 節では, BMI の概要および脳波に関する先行研究について述べる. 2.3 節では, 本研究で解決すべき課題を述べる. 最後に, 2.4 節では本章をまとめる.

2.2 ブレインマシンインターフェース

2.2.1 BMI の概要

ブレインマシンインターフェース(Brain-Machine Interface: BMI)とは、脳の神経活動を入力信号として利用し、外部機器を直接的に操作する技術のことを指す。この技術は、身体障害者の運動機能を補助するさまざまなサポートツールに応用され、使用者の QoL の向上に役立っている。最近では、日常生活の支援する技術として、電動車いすを脳波によって操作し、自由に移動することができない肢体不自由者でも自分で移動することが可能となった[田中 2012]。また、電動車いすと解析システムの一体化による携帯性の向上や障害物との衝突回避、使用者ごとの最適なイメージング脳波の選択アルゴリズムなどのシステム開発が提案されている。

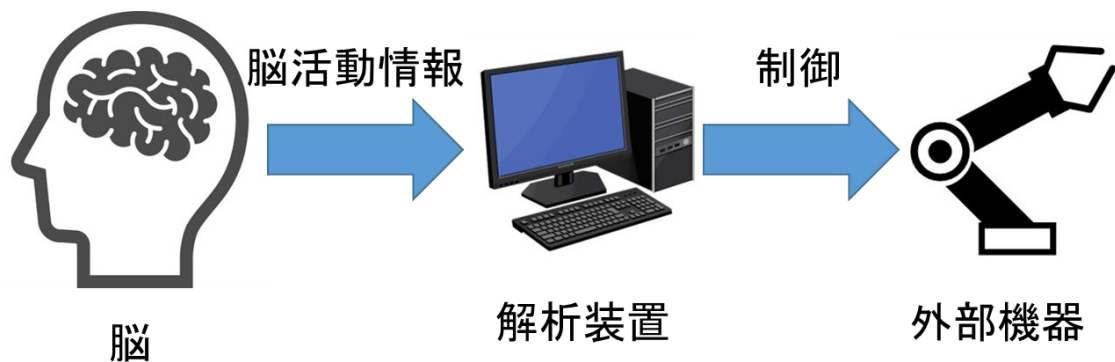


Fig. 2.1 ブレインマシンインターフェースの概要図

2.2.2 脳活動情報の計測手法

脳は各部位ごとに機能を分担しており、それらの相互作用によって脳局所が連携することで一連の身体運動を形成していることが知られている。これを脳機能局在論と呼ぶ [L.J.Garey 1994]。このことから、脳において運動に関する部位を中心に脳活動情報を計測することで運動意図を抽出することができる。

脳の活動情報を計測する方法は様々であり、観測する情報の違いや侵襲性などによって分類される[宮内 2013]。近赤外線分光法 (functional Near Infrared Spectroscopy: fNIRS) は代謝活動に伴って変化する血中の酸化ヘモグロビン量を光学的に計測する。また、機能的磁気共鳴画像法 (functional Magnetic Resonance Imaging: fMRI) は脳の血流量の変化を電磁氣的に計測する方法である。これらの方法は、血流変化などの脳内の代謝活動から脳神経の活動を間接的に計測することから二次的な計測手法に分類される。そのため、実際に脳活動が生じた時刻と代謝活動を観測した時刻との間に時間遅れが発生する。

これに対し脳活動情報を直接的に計測する手法として、磁氣的な方法である脳磁図 (Magnetoencephalography: MEG) と電氣的な方法である脳波 (Electroencephalography: EEG)、硬膜下皮質脳波 (Electrocorticographic: ECoG)、皮質内における針電極での計測などが挙げられる。これらは、二次的な計測方法と比べて時間分解能に優れている。しかしながら、MEG は計測装置が大規模であることから可搬性が低く、日常生活を支援する機器を構築するには適していない。

脳波、ECoG、大脳皮質電位はどれも脳活動情報を電氣的に取得するものであるが、電極の留置場所が異なる。脳波は頭皮上に留置した電極からその周辺の電位を計測するものである。また、ECoG は硬膜下に留置したシート状の電極から 2 点間の電位差を計測するものである。さらに、大脳皮質電位は剣山状の微小電極を脳皮質に直接刺し込み皮質上からシナプスの発火を観測する。脳波、ECoG、大脳皮質電位の順に電極の留置する位置が脳に近くなる。脳に近づくほど信号の精密性や時間応答性が高いため、高機能ロボットを操作することに非常に有用である。一方で、体内に電極を留置するため、埋め込み電極の適合性や施術の必要性とその安全性、倫理的な問題などのさまざまな問題がある。

そこで本研究では、日常生活における支援を目的としたシステム開発に向け、装置の可搬性、着脱の容易性、時間応答性、非侵襲性といった観点から脳波を計測手法として選択した。

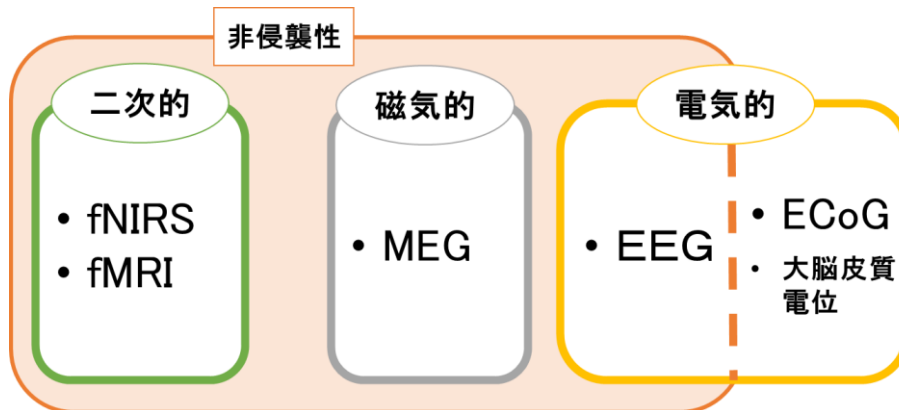


Fig. 2.2 脳情報の計測手法

2.2.3 脳波に関する研究

脳波は、脳神経の活動によって発生した電気的特性が生体組織を通して波形として現れた生体信号である。頭皮上から観測した電位の波形にはさまざまな周波数の脳波が含まれるため、一般に周波数帯によって分類して解析を行う。このうち α 波帯(μ 律動)と β 波帯の周波数帯域は、自発的な運動およびその想起に関して特定の脳波が発現することがわかっている[McFarland et. al 2000]。このように、ある事象に関して一過性に生じる脳波は事象関連電位(Event-Related Potential: ERP)と呼ばれ、運動や心理活動に関するさまざまな研究がなされている[入戸野 2000]。このERPは意図的に与えられた外的刺激に対しても発現することがあり、その場合には外的要因があることを明確に示すために誘発電位とも呼ばれる。誘発電位は、刺激の回数を数えたり予測したり刺激を認識することで変化が大きくなるという特徴をもつ。代表的な誘発電位として、光の刺激で発現する視覚誘発電位(VEP)、音の刺激で発現する脳幹聴覚誘発電位(BAEP)、体性感覚誘発電位(SEP)などが挙げられる[Bashashati et. al 2007]。なかでも、点滅刺激を注視した際に点滅周波数と同じ周波数の律動が視覚野において観測されることが知られており、これを定常的視覚誘発電位(Steady-State Visually Evoked Potential: SSVEP)と呼ぶ。SSVEPは訓練を必要とすることなく比較的安定して観測できるため、運動支援システムに利用されている[坂井 2016]。しかしながら、刺激に対して集中し続けることが必要となり、ハンド操作において手先や対象となる物品以外に意識を向けることは望ましくない。したがって、自発的な運動に関する脳波を利用した制御システムを開発する。

2.2.4 周期パワースペクトル解析法

吉岡らは、 α 波と β 波から肘の屈曲伸展運動に関する特徴量を抽出し、線形モデルの構築および関節トルクの推定を行い、ロボットアームの制御に成功している [Yoshioka et.al 2016]。吉岡らは、まずマハラノビス距離を用いて α 波および β 波のパワースペクトルの2次元分布に対する2クラス判別器を構築し、運動の有無を識別した。個人差によって多少のばらつきが存在するが、4名の被験者の平均識別率は61%であった。これまで脳波と運動は線形関係が乏しいとされていたが、吉岡らは脳波のパワースペクトルの周期の変化と肘関節トルクが線形関係であることを示し、ロボットアームの制御のための線形モデルを構築した。吉岡らによって提案されたパワースペクトルの周期性に関して周波数解析したものを周期パワースペクトル、この新たな解析手法を周期パワースペクトル解析法と呼ぶことにする。

また卒業研究では、この研究を応用し、肘の屈曲伸展による上肢運動だけでなく、手部の握りや開きのような把握動作に適用したところ、同様に周期パワースペクトルに変化が生じることが明らかとなった [掬川 2019]。しかしながら、周期パワースペクトルに関する研究は数少なく、ロボットハンドの制御に活用した事例は我々の知る限り見当たらない。

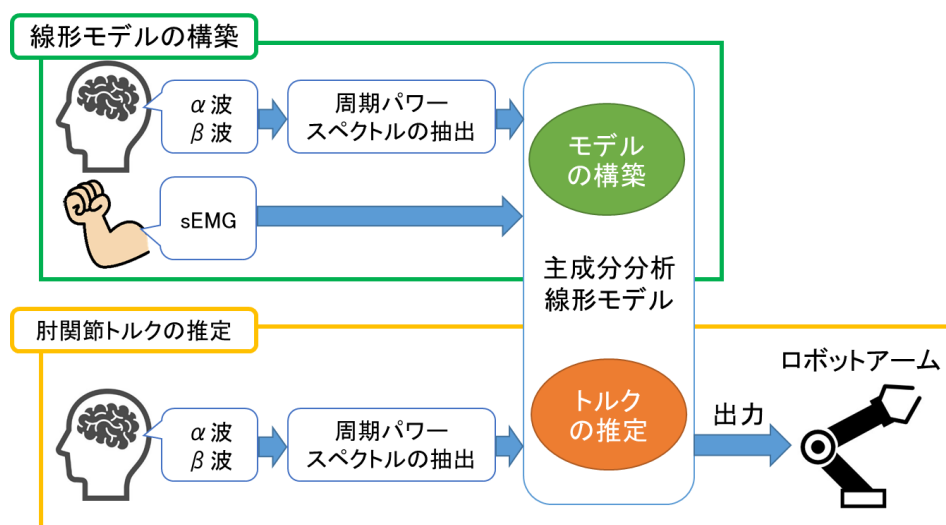


Fig. 2.3 吉岡らによる開発システムの概要

2.3 解決すべき課題

本章では、先行研究について説明を述べた。先行研究では、肘の屈曲伸展を伴う上肢運動だけでなく、把握動作と周期パワースペクトルとの関連性が報告された。しかしながら、周期パワースペクトルをもちいてロボットハンドの制御するためには、さまざまな課題が存在する。まず始めに、周期パワースペクトルから手部の運動意図を検出するシステムが必要である。さらに、手部の動作や姿勢は非常に多く存在する。また、手部の動作に伴う筋活動と周期パワースペクトルに線形関係があることも未だ明確ではない。

そこで本研究では、手部動作のうち基本的な動作である握りや開きといった把握動作について周期パワースペクトルをもちいて各状態を識別することを解決すべき課題とする。

2.4 おわりに

本章では, 脳情報をもちいた技術であるブレインマシンインターフェースについて説明した. 2.2 節では, BMI の概要および脳波に関する先行研究やその計測手法について述べた. 2.3 節では, 本研究で解決すべき課題について述べた.

第3章 データ解析手法

3.1 はじめに	28
3.2 周波数解析法	29
3.3 状態判別器	36
3.4 おわりに	43

3.1 はじめに

本章では、観測データの解析方法について述べる。3.2 節では、脳波の解析にもちいる周波数解析として、基本となる高速フーリエ変換および短時間フーリエ変換、その応用手法である周期パワースペクトル解析法について順を追って述べる。3.3 節では、2 クラス判別をするための学習アルゴリズムであるサポートベクタマシンについて述べ、その応用としてマルチクラス判別を説明する。最後に、3.4 節で本章を簡単にまとめる。

3.2 周波数解析法

脳波は、脳から生体組織を介して頭皮上で波形として観測される生体信号である。その波形には複数の周波数成分が含まれるため複雑な波形をしている。また、様々な事象に伴って周期性が変化することが知られているが、波形のままでは脳波の変化を把握することは難しい。そこで、脳波の解析にはしばしば周波数解析法がもちいられる。周波数解析法では、時系列データである波形信号を時間領域から周波数領域へと変換し、信号の周波数特性を捉えることができる。また、フィルタリングによって特定の周波数帯だけを取り出したり、不要な周波数成分を除去したりといった処理も可能である。本研究では、脳波の周波数特性について時系列解析を行うため、短時間フーリエ変換 (short-time Fourier transform: STFT) とその応用手法である周期パワースペクトル解析法をもちいて解析をおこなう。

3.2.1 高速フーリエ変換

高速フーリエ変換 (fast Fourier transform: FFT) はフーリエ解析のひとつで、離散時間信号を離散的な周波数領域に変換する離散フーリエ変換 (discrete Fourier transform: DFT) を高速な計算処理によって実現したものである。時間処理が短いため、制御信号の生成などに優れている。

周期 T の連続時間信号 $x_T(t)$ に対して複素フーリエ級数は次のように定義される。

$$x_T(t) = \sum_{k=-\infty}^{\infty} C_k e^{jk\Omega_0 t}, \quad \Omega_0 = \frac{2\pi}{T} \quad (3.1)$$

$$C_k = \frac{1}{T} \int_{T/2}^{-T/2} x(t) e^{-jk\Omega_0 t} dt \quad (3.2)$$

しかしながら、コンピュータ上で処理するデータは離散信号である必要があるため、

上式を適用することはできない。そこで、離散時間信号 $x[n]$ に対するフーリエ変換である離散時間フーリエ変換(discrete-time Fourier transform: DTFT)を適用する。




Fig. 3.1 10Hz, 15Hz, 20Hz の合成波形

$$X(e^{j\omega}) = \sum_{k=-\infty}^{\infty} x[k] e^{-j\omega k} \quad (3.3)$$

Eq.3.3 によって離散時間信号を周期的な連続スペクトルに変換することが可能となった。さらに、連続スペクトルを離散化し、離散時間信号から離散的なスペクトルへの変換を行うことで、コンピュータ上での高速な解析処理を可能とする。したがって、観測した脳波データ $x[n]$ の高速フーリエ変換(FFT)は次のようになる。

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}kn} \quad (k = 0, 1, \dots, N-1) \quad (3.4)$$

このとき、 $X[k]$ はスペクトル、 k は周波数の番号、 n は時間の番号、 N は変換データ点数とする。また、 $|X[k]|$ を振幅スペクトル、 $|X[k]|^2$ をパワースペクトルと呼ぶ。

いま、Eq.3.5(Fig.3.1)のような 10Hz, 15Hz, 20Hz の理想的な混合波形を考える。

$$y = 5 \sin(2\pi \cdot 10 \cdot t) + \sin(2\pi \cdot 15 \cdot t) + 3 \sin(2\pi \cdot 20 \cdot t) \quad (3.5)$$

この合成波について FFT を行った結果を Fig.3.2 に示す. パワースペクトルの大きさは $10\text{Hz} > 20\text{Hz} > 15\text{Hz}$ となっており, 各正弦波における係数の大きさの序列と一致する. このことから, 時系列データから各周波数成分を抽出できたことが確かめられた.




Fig. 3.2 合成波 (Eq.3.5) の FFT 結果

3.2.2 短時間フーリエ変換

刻々と変化していく脳情報を解析し, 義手などの外部機器を制御するためには時間情報は必要となる. しかしながら, FFTでは時間領域から周波数領域への変換がなされ, 時間に関する情報が失われてしまう. そこで, 時系列データをある一定の時間幅の窓で切り出し, FFT を実行することで周波数解析をする短時間フーリエ変換(short-time Fourier transform: STFT) を導入する. 切り出す窓をずらしながら繰り返しSTFTを行うすることで, 時刻ごとの周波数解析が可能となる.

いま, Fig.3.3のような0~1 秒で30Hz, 1~2 秒で10Hz, 2~3 秒で15Hz と時間の経過に伴って周波数に変化する波形信号を考える. なおサンプリングレートは2048Hzとする.

$$y = \begin{cases} \sin(2\pi \cdot 10 \cdot t) & (0 \leq t \leq 1.0) \\ \sin(2\pi \cdot 30 \cdot t) & (1.0 \leq t \leq 2.0) \\ \sin(2\pi \cdot 15 \cdot t) & (2.0 \leq t \leq 3.0) \end{cases} \quad (3.6)$$

この信号を窓関数にガウス窓をもちいて変換窓幅500msec, 変換周波数2048HzでSTFT を実行するとFig.3.4 のようになる. これは底面に周波数軸, 時間軸を, 縦軸にパワースペクトルを表した3次元マップである. 時間の経過とともにパワースペクトルのピークをもつ周波数が10Hz, 30Hz, 15Hzと変化していることがわかる. また, 周波数分解能と時間分解能はトレードオフの関係にあることに注意しなければならない.




Fig. 3.3 波形 (Eq.3.6) の STFT 結果

3.2.3 周期パワースペクトル

2.2 節で述べたように、脳波の α 波と β 波の周波数帯域におけるパワースペクトルは、上肢運動および手部の運動に伴って時間的な変化を生じることがわかっている。さらに、吉岡らはこのパワースペクトルの変化の周期性に着目し、筋活動との線形関係を明らかにしロボットアームの制御に利用した。すなわち、脳波について STFT で得た解析データから特定の周波数パワースペクトルを時系列データとして切り出し、その切り出した時系列データに対して再び STFT を実行することで対象のパワースペクトルの周波数解析が可能となる。このように、観測した脳波データから 2 度の STFT によって得られたパワースペクトルを周期パワースペクトルと呼ぶ。周期パワースペクトルは、信号の周波数を観測するのではなく、その信号の振幅の周期的な増減、いわゆる揺らぎと呼ばれるような周波数特性を抽出している。

いま、Fig.3.5 (Eq.3.7) に示すような 5Hz の揺らぎを伴う波形を例に考える。

$$y = 3 \sin(2\pi \cdot 20 \cdot t) + \sin(2\pi \cdot 25 \cdot t) \quad (3.7)$$

この信号に対して、窓関数にガウス窓をもちいて変換窓幅 500msec、変換周波数 2048Hz の条件で STFT を行うと Fig.3.6 が得られる。20Hz のピークが時間と共に周期的に変動していることが読み取れる。次に、これを時系列データとして Fig.3.7 のように切り出し、同様の条件で STFT を行ったものを Fig.3.8 に示す。グラフにおいて高さは周期パワースペクトルの大きさを表している。確かに 5Hz にピークが現れていることが読み取れ、揺らぎ成分を検出していることがわかる。




Fig. 3.5 揺らぎを伴う合成波

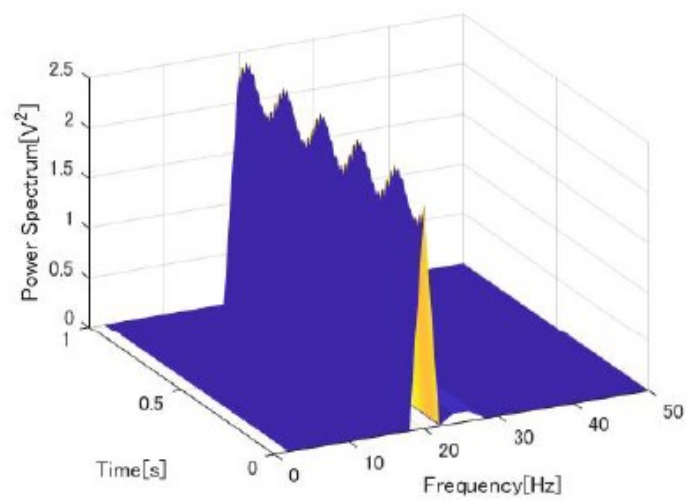


Fig. 3.6 1度目の STFT 実行結果




Fig. 3.8 切り出した 20Hz におけるパワースペクトルの時間変化

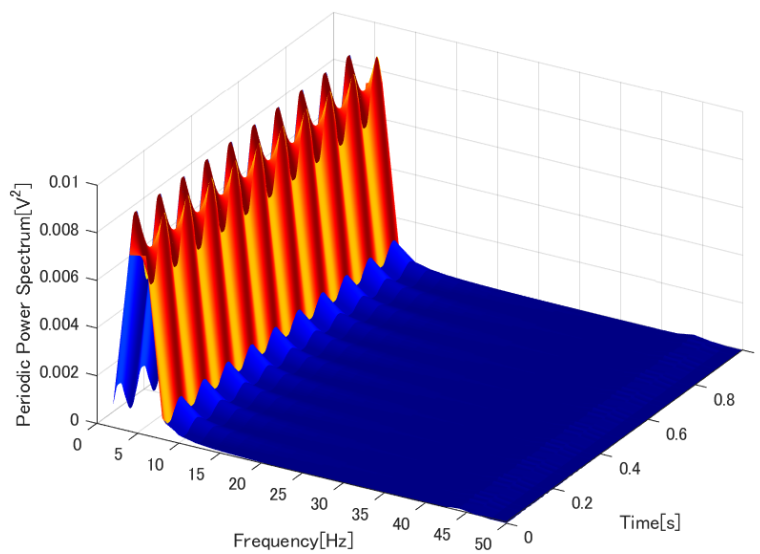


Fig. 3.7 周期パワースペクトル解析による揺らぎ成分の検出

3.3 状態判別器

ある入力データをいくつかに分けられたクラスへ分類する時、これを判別問題という。入力データをベクトル \mathbf{x} とすると、一般に入力データ \mathbf{x} はそれぞれある境界によってひとつのクラスに分離されている。判別問題は、観測データをもとにこのクラス分けのための境界を決めることである。決定境界が \mathbf{x} である線形式は、

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 \quad (3.8)$$

で表すことができるモデルを線形判別モデルという。

\mathbf{x} が2次元の場合は線形式で表現可能な境界は直線、 \mathbf{x} が3次元の場合は線形式で表現可能な境界は平面となる。これは高次元の場合でも同様に説明ができ、 \mathbf{x} が N 次元であるとき $N - 1$ 次元の部分空間が境界となる。このような平面の概念を高次元に拡張させたものを超平面と呼ぶ。また、超平面によって分割可能である場合、線形分離可能であるという。

本研究では、線形判別モデルのひとつであるサポートベクタマシン (support vector machine: SVM) と、マハラノビス距離の2種類の判別アルゴリズムをもちいてそれぞれ分類を行う。

3.3.1 サポートベクタマシン

サポートベクタマシン (SVM) は、マージンが最大となるように判別境界を決定する教師あり学習アルゴリズムである。マージンとは、判別境界まで最も近いデータ点から判別境界までの距離のことを指す。また、そのマージン境界上の点をサポートベクタという。このマージンが最も広くなるような判別境界であることは、すなわちクラス間をより広く分離しているということである。サポートベクタマシンは、2クラス判別を得意とし、データの次元が大きくなっても比較的よい識別精度を発揮するなど、高い汎化性能を有す

る.

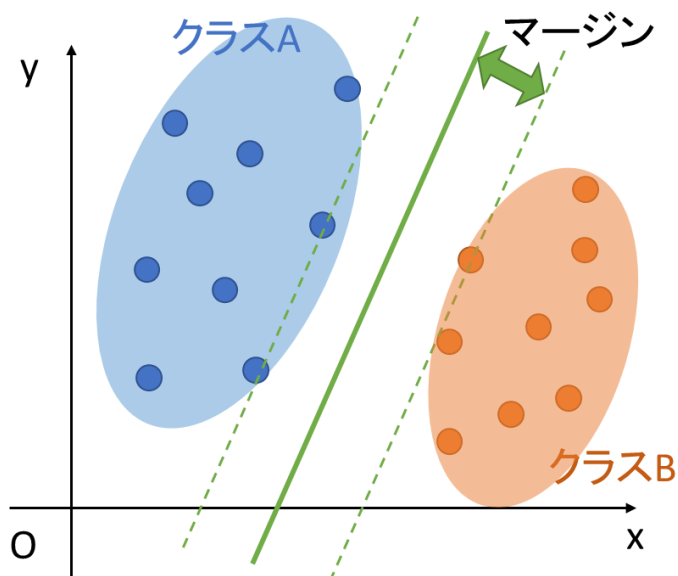


Fig. 3.9 サポートベクタマシンによるクラス判別の概要

まず、データ \mathbf{x}_n から判別境界 $y(\mathbf{x}) = 0$ までの距離は、 \mathbf{x}_n を $y(\mathbf{x}) = 0$ に正射影した垂線の長さとして求めることができる。したがって、 \mathbf{x}_n から $y(\mathbf{x}) = 0$ へ下ろした垂線の足を \mathbf{x}_\perp とすると、

$$\mathbf{x} = \mathbf{x}_\perp + d \frac{\mathbf{w}}{\|\mathbf{w}\|} \quad (3.9)$$

と書ける。ここで、 d は \mathbf{x}_n を $y(\mathbf{x}) = 0$ に正射影した垂線の長さに対応したスカラー値であり、境界 $y(\mathbf{x})$ に対する \mathbf{x}_n の存在する領域の符号に対応している。

両辺に左から \mathbf{w}^T をかけると

$$\mathbf{w}^T \mathbf{x} = \mathbf{w}^T \mathbf{x}_\perp + \mathbf{w}^T d \frac{\mathbf{w}}{\|\mathbf{w}\|} \quad (3.10)$$

$$y(\mathbf{x}) - w_0 = y(\mathbf{x}_\perp) - w_0 + d \frac{\mathbf{w}^T \mathbf{w}}{\|\mathbf{w}\|} \quad (3.11)$$

$$y(\mathbf{x}) = 0 + d \|\mathbf{w}\| \quad (3.12)$$

$$d = \frac{y(\mathbf{x})}{\|\mathbf{w}\|} \quad (3.13)$$

となる。また、 \mathbf{x}_n が $y(\mathbf{x}) > 0$ のとき $t_n = +1$ 、 \mathbf{x}_n が $y(\mathbf{x}) < 0$ のとき $t_n = -1$ であるから、

$$d' = \frac{t_n y(\mathbf{x}_n)}{\|\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \mathbf{x}_n + w_0)}{\|\mathbf{w}\|} \quad (3.14)$$

とすると、 d' は常に正の値をとり、判別境界との距離として取り扱うことができる。

マージン最大化を目的とする場合、 d' を最大化する \mathbf{w} および w_0 を求めればよい。したがって、以下のように定式化できる。

$$\arg \max_{\mathbf{w}, w_0} \left[\frac{1}{\|\mathbf{w}\|} \min_n \{t_n (\mathbf{w}^T \mathbf{x}_n + w_0)\} \right] \quad (3.15)$$

また、パラメータ \mathbf{w} および w_0 をスカラー倍しても、距離 d' は不変である (Eq.3.16)。

$$\frac{t_n (k\mathbf{w}^T \mathbf{x}_n + kw_0)}{\|k\mathbf{w}\|} = \frac{t_n (\mathbf{w}^T \mathbf{x}_n + w_0)}{\|\mathbf{w}\|} \quad (3.16)$$

すなわち、最も判別境界に近いデータ点 \mathbf{x}_n について、

$$t_n (\mathbf{w}^T \mathbf{x}_n + w_0) = 1 \quad (3.17)$$

が成立するようにパラメータを決定しても問題ないと言える。このとき、 \mathbf{x}_n は最も判別境界に近いデータ点であるとしているから、全てのデータ点に対して次の式が成立する。

$$t_n (\mathbf{w}^T \mathbf{x}_n + w_0) \geq 1 \quad (n = 1, 2, \dots, N) \quad (3.18)$$

このことから、Eq.3.15 は次のように変形される。

$$\arg \max_{\mathbf{w}, w_0} \frac{1}{\|\mathbf{w}\|} \quad (3.19)$$

このとき、 $\frac{1}{\|\mathbf{w}\|}$ の最大化は、 $\frac{1}{2} \|\mathbf{w}\|^2$ の最小化と等価である。すなわち、マージン最大化

問題は、次の制約付き最小化問題に帰着する。

$$\arg \min_{\mathbf{w}, w_0} \frac{1}{2} \|\mathbf{w}\|^2 \quad (3.20)$$

$$\text{subject to } t_n (\mathbf{w}^T \mathbf{x}_n + w_0) \geq 1 \quad (3.21)$$

サポートベクタマシンは、この制約付き最小化問題について、ラグランジュの未定乗数法などを用いて最適化問題に置き換え、これを解くことによって得られる判別モデルである。

3.3.2 マルチクラス判別

前節では、2 クラスの線形判別手法としてサポートベクタマシンについて説明した。しかしながら、実際には解決すべき問題によって 2 クラス以上の状態が存在する場合もある。そのような判別問題をマルチクラス判別と呼ぶ。2 クラス以上の場合であっても、複数の 2 クラス判別器を組み合わせることによって対応することが可能であるが、その組み合わせの種類によっていくつか問題が生じる。

N クラスの判別問題において、ある特定のクラスに属するデータ点と、それ以外のクラスに属するデータ点とを 2 クラス判別する線形判別モデルを N 個生成してマルチクラス問題を解く判別器を、1 対他判別器 (one-vs-the-rest classifier) と呼ぶ。1 対他判別器の概要を Fig.3.10 に示す。

一方で、 N クラスから任意の 2 つのクラスをペアとして選び、2 クラス判別の結果を多数決によって決定する判別器を 1 対 1 判別器 (one-vs-one classifier) と呼ぶ。1 対 1 判別器の場合、生成する判別器の数は $\frac{N(N-1)}{2}$ となり、分類したいクラス数が大きくなるほど計算量が膨大になる。また、最終的な分類の決定は多数決によって決めるとされる。1 対 1 判別器の概要を Fig.3.11 に示す。

どちらの判別手法においても、判別不可能な領域が発生してしまうケースがあることに注意しなければならない。

本研究では、ハンドへの実装を前提に、計算処理の早さや操作時の誤分類による意図せぬ動作を避ける目的として曖昧な分類の際に識別不可能として判別しやすい 1 対他判別器を採用する。

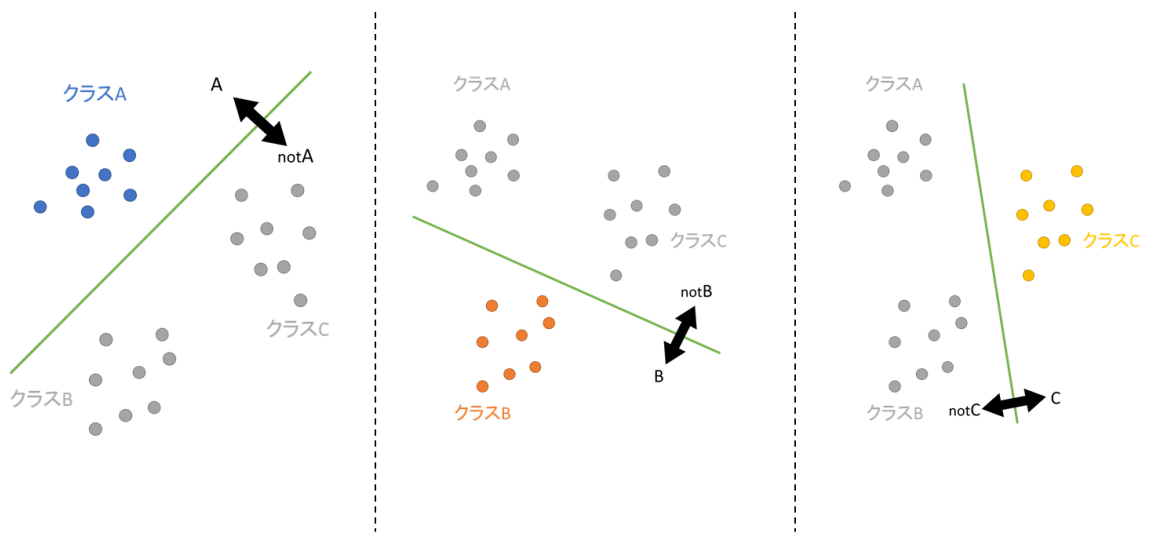


Fig. 3.10 1対他判別器の概要図




Fig. 3.11 1対1判別器の概要図

3.3.3 マハラノビス距離

マハラノビス距離とは、相関がある多変数に対して平均と相関関係をもちいて一元化した距離尺度である。その距離の大きさによって対象とする集合との分布の近さを表す。したがって、複数の集合が存在する時、あるデータについてそれぞれの集合に対してのマハラノビス距離を求めることでどの集合に最も近いかを評価し、どの集合に属するかの判別が可能である[Yoshioka et.al 2017]。

データ点 x についてのマハラノビス距離 D は次のように求めることができる。

$$D = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (3.22)$$

このとき、 μ は x の平均値、 Σ は集合の共分散行列である。

いま、クラス A とクラス B について判別することを考える。あるデータ点について各クラスに対するマハラノビス距離をそれぞれ D_A 、 D_B とすると、判別条件は次のようになる。

$$\begin{cases} \text{クラス A:} & D_A < D_B \\ \text{クラス B:} & D_A > D_B \\ \text{判別境界:} & D_A = D_B \end{cases} \quad (3.23)$$

ここでは、2 クラス判別を例に挙げたが、同様にして 3 クラス以上の場合であってもそれぞれのマハラノビス距離をもちいることで、最も近い集合を選択することができる。

3.3.4 交差検証

機械学習における学習モデルの汎化性能を評価する方法に、交差検証がある。これは、データを学習データとテストデータに分割し、学習データをもちいてモデルの学習を行ったあと、テストデータによる正解率によってそのモデルの性能を評価するものである。さらに、 K -分割交差検証は、データを K 個に分割し1つをテストデータ、残りの $K - 1$ 個を学習データとして学習モデルを生成し、テストデータとする分割データを変えながらこの操作を K 回繰り返すものである (Fig.3.12)。モデルの精度は最終的に K 回の結果を平均化して求められる。

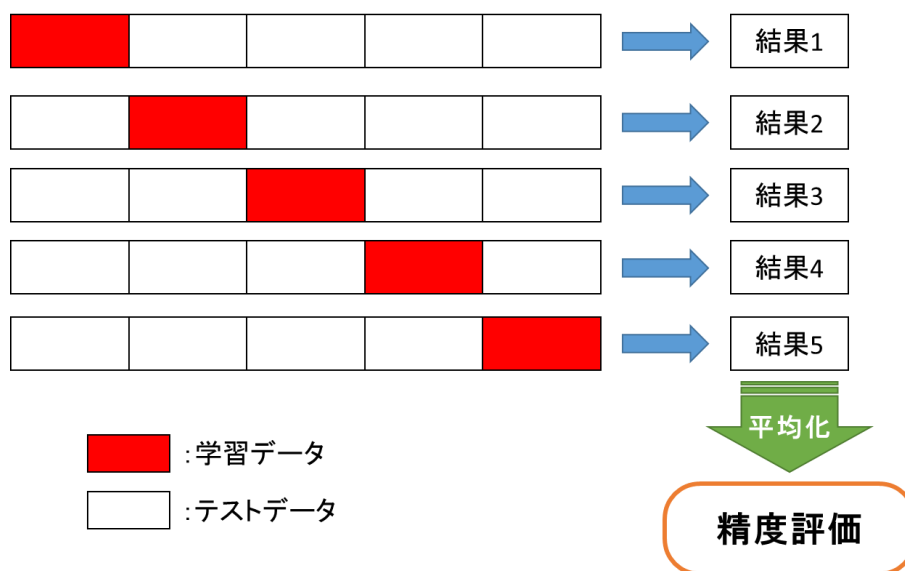


Fig. 3.12 K -分割交差検証の概要図 ($K=5$)

3.4 おわりに

本章では、観測データの解析方法について述べた。3.2 節では、周波数解析法である高速フーリエ変換および短時間フーリエ変換、その応用手法である周期パワースペクトル解析法について述べた。3.3 節では、2 クラス判別をするための学習アルゴリズムであるサポートベクタマシンについて述べ、その応用としてマルチクラス判別を説明した。

第4章 実験および解析

4.1 はじめに	46
4.2 実験目的および概要	46
4.3 計測機器	49
4.5 おわりに	70

4.1 はじめに

本章では、実験概要および観測データをもちいた解析とその結果について述べる。4.2 節では、実験目的や実験に関する概要、計測環境、解析ソフトウェアなどについて述べる。4.4 節では、本実験で観測した脳波データをもちいたサポートベクタマシンによる解析結果について述べる。4.5 節では、マハラノビス距離による解析結果について述べる。最後に 4.6 節では、本章を簡単にまとめる。

4.2 実験目的および概要

本研究の目的は、周期パワースペクトルを利用したサポートベクタマシンによる把握動作における状態判別器を構築し、状態判別およびその識別精度の評価である。

被験者は20代の健常男性5名である。実験は電磁シールド室の中で行う。被験者は開眼状態で椅子に座り、胸の高さに合わせた前方のテーブルの上に右腕を乗せ、国際10-20法によって定められた計測点が配置されたヘッドキャップを装着する。脳波の計測箇所は先行研究に従い、Fp2をreference電極としてF3, F4, C3, C4, Cz, P3, P4の7点とする。各電極から観測された信号は、脳波計を通して増幅され、USBケーブルで接続されたPCに送信される。なお、前腕部に取り付けられた電極からは、タスクにおける脳波（EEG）と把握動作における筋活動とを同期させるためにsEMGを計測した。実験環境の概要をFig.4.1に示す。

本研究では、テーブル上に乗せた右腕を脱力した状態を安静状態、拳を握った状態または手を開いた状態を動作状態、その直前を動作準備状態と呼ぶことにする。実験タスクは、安静5秒、動作準備3秒、動作3秒、再び安静10秒の計21秒を1試行として、握りと開きの運動に対し各30試行を記録した。なお、タスク中における各状態の切り替えのタイミングはビープ音をもちいて被験者に提示した。

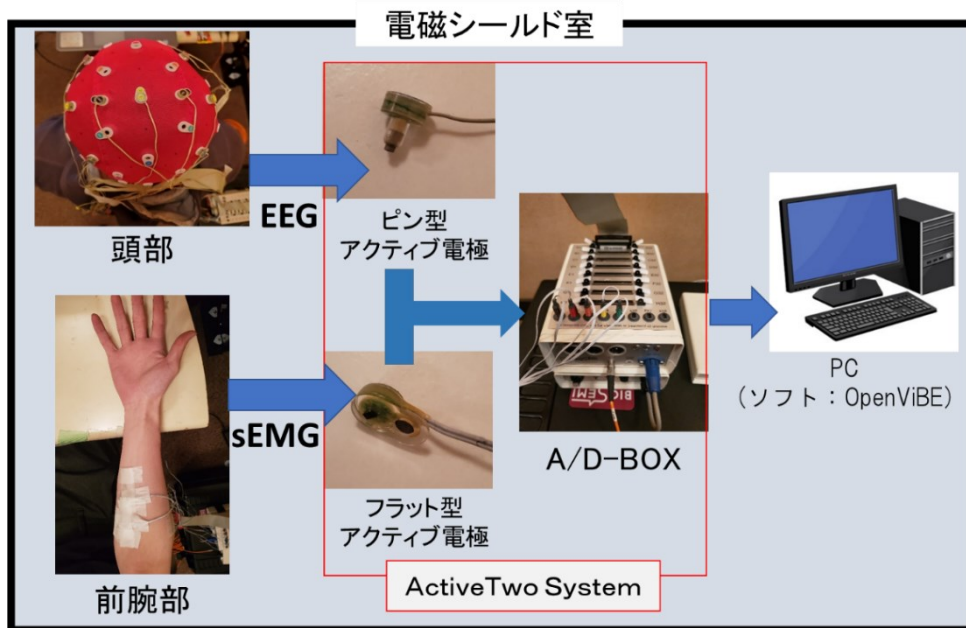


Fig. 4.1 実験環境の概要

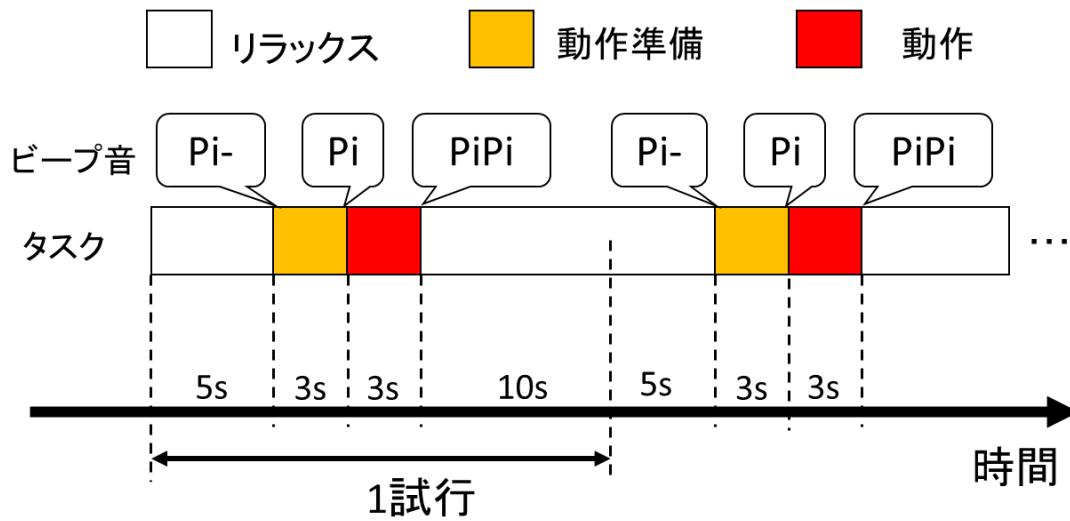


Fig. 4.2 実験タスクのタイムチャート

4.3 計測機器

4.3.1 脳波計

脳波計には Biosemi 社の ActiveTwo をもちいる。ActiveTwo のシステム概要を Table4.1 に示す。このシステムの電極はすべて湿式電極であり、取り付けには Parker 社の Signa gel という電解質ゲルを使用する (Fig.4.3)。被験者は、国際 10-20 法で定められた計測点にピン型アクティブ電極用のソケットが取り付けられたヘッドキャップを装着し、ピン型のアクティブ電極を取り付ける。なお、国際 10-20 法は、鼻根と後頭結節および左右の耳介前点の中点を Cz とし、鼻根と後頭結節間および左右の耳介前点間を 10, 20, 20, 20, 20, 10% に分割した位置に電極を配置する方法である。本実

Table 4.1 ActiveTwo のシステム概要

項目	詳細
サンプリングレート	2048Hz
チャンネル数	32+8
ハードウェアフィルタ LP	5 次 sinc デジタルフィルタ
ハードウェアフィルタ HP	フル DC カップル
離散化	24bit, 64 倍 5 次 $\Delta\Sigma$ 変調, 1conveter/ch
サンプリングスキュー	10ps
絶対サンプリングレート精度	0.1Hz
相関サンプリング精度	<200ps
量子化分解能	LSB-31.25nV
ゲイン精度	0.30%
アンチエイリアシングフィルタ	修正 1 次アナログフィルタ, -3dB at 3.6KHz
全体ノイズ	0.8uVRMS
アンプ電流ノイズ	40fArms 未満
入力インピーダンス	300Mohm at 50Hz(10120hm//11pF)
DC オフセット	<0.5mV
DC ドリフト	<0.5uV/C
入力範囲	+262mV to -262mV
歪み	<0.1%
チャンネル分散度	>100dB

験では、そのうち F₃, F₄, C₃, C₄, Cz, P₃, P₄ の7点を計測点に設定する。各計測点の位置は Fig.4.4 に示す。



Fig. 4.4 ActiveTwo (左) と電解質ゲル (右)

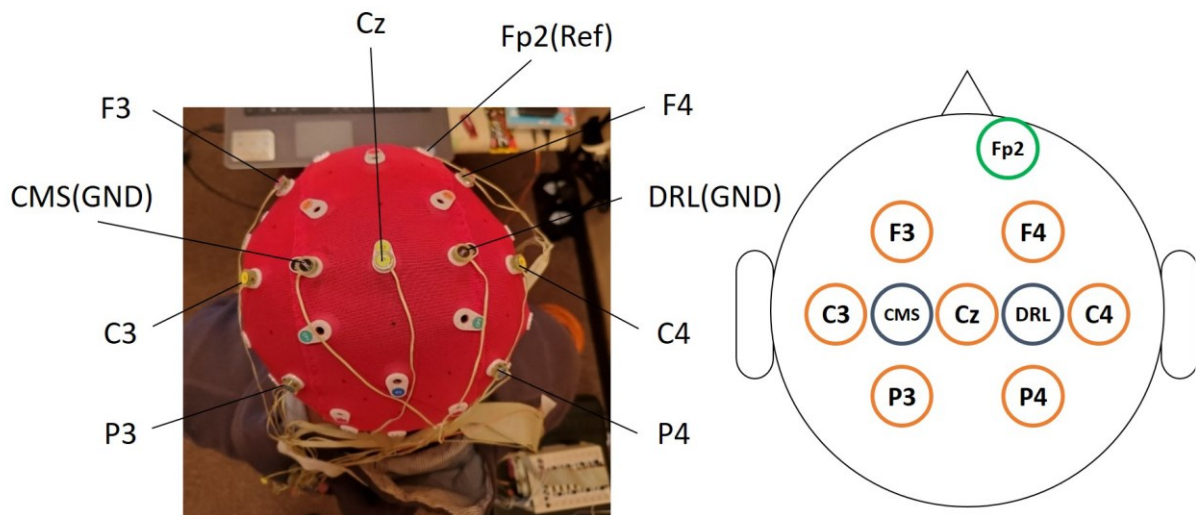


Fig. 4.3 脳波計測位置と概略図

4.3.2 脳波解析ソフトウェア

本研究では、脳波と筋電信号の取得および信号処理のためのソフトウェアとして OpenViBE をもちいる。このソフトウェアは、INRIA (Institut National de Recherche en Informatique et en Automatique: フランス国立情報学自動制御研究所) が開発したオープンソフトウェアプラットフォームである。様々な脳波計との互換性を持ち、取得した信号をリアルタイムに解析することが可能である。また、解析のためのプログラムの構築にはブロック図を繋げたフローチャートで作成することができるため、非常に直観的かつ容易に利用することが可能である。本実験では、主に観測データの取得や基本的な処理および記録のためにこのソフトウェアをもちいた。

OpenViBE を介して記録した観測データは、MATLABをもちいてオフラインで解析した。主に、STFTおよび周期パワースペクトル解析のための周波数解析、それらを学習データとしたサポートベクタマシンの判別器の構築および精度の評価を行った。

4.4 周期パワースペクトルをもちいた状態判別

4.4.1 システム概要

本研究の解析システムは、周波数解析パートと状態判別器パートの大きく2つの部分に分けられる。まず始めに、脳波の観測データにSTFTを行った。窓幅は500 msec、ガウス窓をもちいて、変換周波数 2048 Hz で窓をずらしながらパワースペクトルを算出した。このうち7~15 Hz を含む周波数帯を時系列データとして切り出し、その代表値をもちいて同条件でもう一度STFTを行った。この操作によって得られた周期パワースペクトルについて対象の状態 3 秒間のデータを学習データとして切り出し、サポートベクタマシンをもちいた状態判別器で学習および判別を行い、その識別精度は5分割交差検証によって評価した。

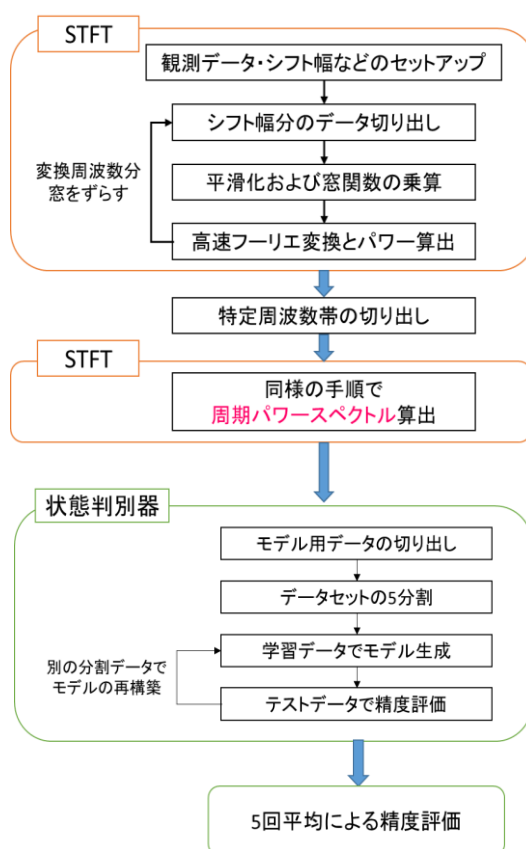


Fig. 4.5 システムの概要図

4.4.2 安静状態と握り状態の2クラス判別

タスクにおける一連の周期パワースペクトルから安静状態および動作状態のそれぞれ3秒間のデータを切り出し、ひとまとまりの学習データセットとした。このデータをサポートベクタマシン状態判別器に学習させた。その識別結果をTable4.1に示す。正解率は最大でも55%であり、十分な識別とは言えない結果となった。また、計測位置や左右による特徴は見られなかった。

Table 4.1 安静状態と握り状態の2クラスに関する正解率（%）

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	50.49	51.31	50.84	52.54	50.31
F4	50.75	50.82	52.85	50.97	50.31
C3	50.27	51.58	52.44	59.64	50.24
C4	50.02	50.40	50.79	56.33	50.24
Cz	50.48	50.39	53.26	53.90	50.29
P3	50.20	49.90	51.33	56.47	50.28
P4	50.68	50.67	50.54	55.68	50.29
平均	50.41	50.72	51.72	55.08	50.28

4.4.3 安静状態と握り準備状態の2クラス判別

安静状態と握り状態における2クラス判別は、十分に識別することができなかった。そこで、動作準備状態において運動想起などによる事象関連電位の発現が周期パワースペクトルへの影響を与えると仮定し、安静状態と握り準備状態について同様に状態判別を行った。その結果をTable4.2に示す。握り動作における動作状態と大きな差はなく、うまく判別することができなかった。したがって、このシステムでは動作状態および動作準備状態のどちらにおいても運動をうまく検出できないことがわかった。

Table 4.2 安静状態と握り準備状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	51.11	49.68	50.23	50.60	56.07
F4	51.11	50.12	50.18	50.64	58.60
C3	50.36	50.71	51.58	50.82	56.29
C4	51.04	50.59	51.98	50.37	53.29
Cz	50.67	50.55	51.11	52.69	54.48
P3	50.80	50.38	52.07	50.80	55.73
P4	50.73	51.74	53.61	50.33	53.39
平均	50.83	50.54	51.54	50.89	55.41

4.4.4 構築したシステムの再考

先行研究では、 α 波の周期パワースペクトルについて安静時と動作時で有意な変化が生じることが報告された。しかしながら、前節ではサポートベクタマシンをもちいた判別器によって十分に識別することができず、その報告とは異なる結果を示した。そこで、本研究で構築したシステムの再考を行った。サポートベクタマシンの特性として適切なスケリングを行わないと、大きな値の範囲をとる特徴量に引っ張られてしまう可能性がある。脳波の観測データを2回STFTすることによって得られた周期パワースペクトルについて着目したところ、そのままのスケールでは低周波数帯に存在する大きなパワースペクトルによって、他の周波数帯に存在する微小な変化が埋もれてしまうというプログラム上の欠陥が明らかとなった。そこで、周期パワースペクトルを対数スケールで取り扱い、絶対デシベル値に変換することで問題の解決をはかった。なお、デシベル変換は次の通りである。

$$L = 10 * \log P \quad (4.1)$$

変換前後の周期パワースペクトルの違いを Fig.4.6 に示す。




Fig. 4.6 握りタスクにおける α 波の周期パワースペクトル (左) とデシベル値 (右)
(Sub1, 計測点 C3)

また、信号に含まれるノイズ成分を除去するために、移動平均によるデータの平滑化を行った。本研究では、400点移動平均をもちいて周期パワースペクトルの平滑化をおこなったところ、動作時に α 波の周期パワースペクトルの沈み込みが発生していることを視覚的に捉えることができた(Fig.4.7)。したがって、状態判別の前処理として、デシベル変換および400点移動平均をおこなう新たなシステムを構築し、以降の解析ではこの改良したシステムをもちいることにする。

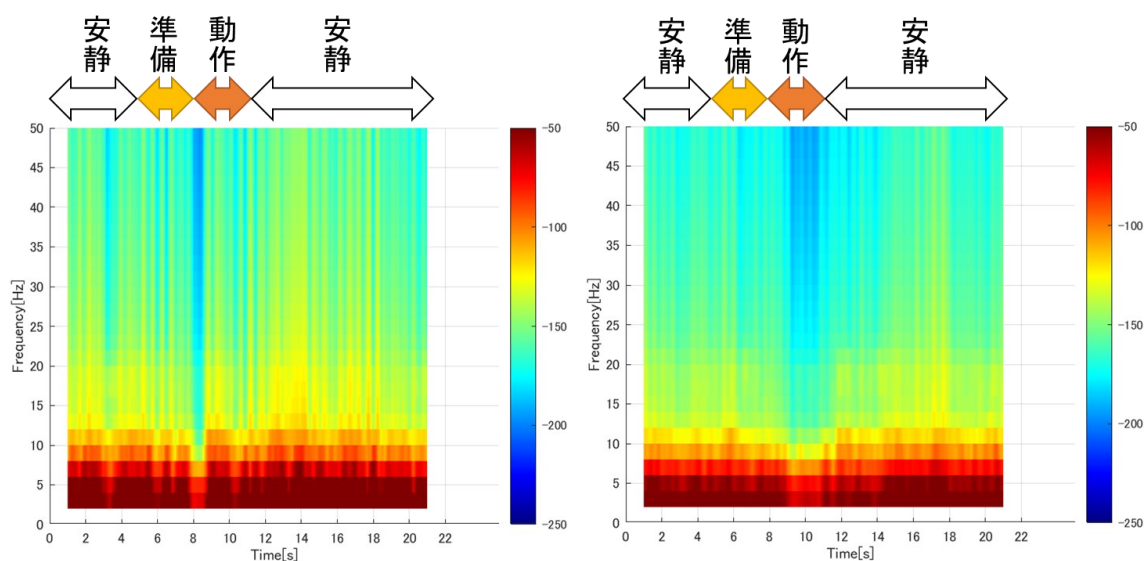


Fig. 4.7 握りタスクにおける α 波の周期パワースペクトルの変化
(Sub1 (左), Sub4 (右), 計測点 C₃, 400点移動平均)

4.4.5 デシベル変換および平滑化をもちいた 2 クラス判別

4.4.1 節と同様に安静状態と握り状態についての 3 秒間の学習データを切り出し、デシベル変換および、デシベル変換と平滑化処理をおこなった 2 つ場合において 2 クラス判別を行った。デシベル変換をもちいた結果を Table4.3、デシベル変換と平滑化処理したデータをもちいた結果を Table4.4 に示す。デシベル変換によって、識別結果が著しく向上したことは明らかである。さらに、平滑化処理をおこなうことによって、すべての被験者において最も良い識別結果を示した。デシベル変換はサポートベクタマシンのスケーリングに対して、平滑化はノイズ除去に対して効果的に作用したと考えられる。また、同様にして安静状態と開き状態についての 2 クラス判別も行った。開き動作においても、デシベル変換と平滑化による識別性能の向上を確認することができた。握り・開きのどちらも 58%以上の識別率を示し、被験者によっては 70%を上回った。この識別結果は、吉岡らが行った運動判別と同程度であり、周期パワースペクトルをもちいた安静-動作についての 2 クラス判別器としての有効性を示した。

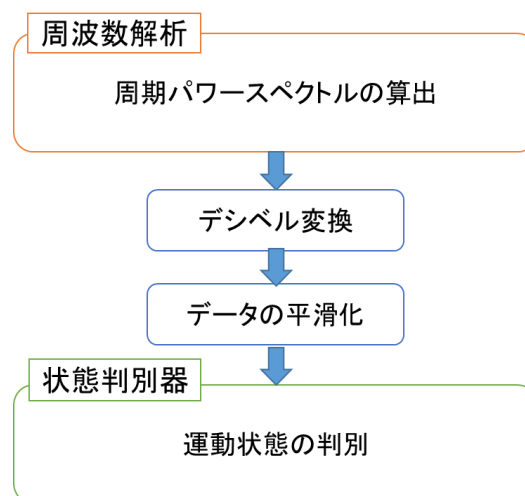


Fig. 4.8 改良した新システムの概略

Table 4.3 デシベル変換のみによる安静状態と握り状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	57.56	56.90	60.79	68.40	57.54
F4	57.59	56.59	64.63	66.14	60.85
C3	57.34	54.47	63.72	75.52	58.90
C4	68.53	56.37	65.43	69.98	62.40
Cz	63.67	55.62	66.55	67.21	61.26
P3	64.55	54.30	63.94	70.46	58.87
P4	64.66	56.93	64.39	69.71	63.36
平均	61.99	55.88	64.21	69.63	60.45

Table 4.4 デシベル変換と平滑化データによる安静状態と握り状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	62.01	61.13	65.20	69.78	60.21
F4	60.04	61.75	68.59	68.64	62.21
C3	60.30	60.21	65.81	74.47	62.09
C4	68.65	58.79	67.65	70.34	64.74
Cz	65.35	59.53	68.32	69.73	64.19
P3	65.50	58.06	67.08	70.93	61.05
P4	65.45	59.91	68.52	71.67	66.50
平均	63.90	59.91	67.31	70.79	63.00

Table 4.5 デシベル変換のみによる安静状態と開き状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	56.90	60.41	57.52	68.87	57.66
F4	55.67	58.31	60.33	71.51	55.00
C3	57.03	58.98	62.29	72.26	56.76
C4	57.44	60.54	61.26	70.21	55.78
Cz	54.47	58.37	62.33	70.35	55.49
P3	58.40	57.77	60.20	67.37	56.90
P4	56.46	56.84	60.50	69.32	56.45
平均	56.62	58.75	60.63	69.98	56.29

Table 4.6 デシベル変換と平滑化データによる安静状態と開き状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	60.82	63.05	63.54	71.60	60.52
F4	59.01	62.05	63.56	74.64	58.26
C3	60.64	61.89	66.69	71.92	59.69
C4	54.32	63.07	66.09	71.13	59.70
Cz	58.76	62.04	66.16	71.27	57.52
P3	59.93	62.35	65.09	70.99	59.91
P4	58.98	59.69	66.37	73.90	59.45
平均	58.92	62.02	65.36	72.21	59.29

4.4.6 握りおよび開き動作の2クラス判別

前節では、手部運動における安静一動作の2クラス判別としての有効性を述べた。しかしながら、ロボットハンドを制御するためには、握り動作と開き動作を別の動作として区別できる必要がある。よって、握り動作と開き動作についての2クラス判別を行った。その結果をTable4.7に示す。安静一動作の2クラス判別と比較して、正解率は劣る結果となった。このことから、サポートベクタマシンによる判別器では、安静状態と動作状態を2クラスに識別することが可能であるが、一方で手部動作の握りと開きをそれぞれ区別するには十分に学習がなされず、マルチクラスでの判別やハンドへの実装には不安が残る結果となった。

Table 4.7 握り状態と開き状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	61.27	60.38	56.48	60.00	60.73
F4	58.88	62.70	59.65	63.73	62.50
C3	52.83	58.96	58.21	57.56	64.42
C4	61.31	59.16	57.71	61.28	63.89
Cz	59.34	58.47	57.59	55.84	64.23
P3	62.25	59.38	59.01	57.09	63.42
P4	59.93	56.91	54.56	59.33	63.06
平均	59.40	59.42	57.60	59.26	63.18

4.4.7 把握動作のマルチクラス判別

これまでは、各状態における 2 クラス判別を行った。実用的なシステムとするには、入力信号から安静状態・握り状態・開き状態の 3 状態のうちどれに分類されるかを判別しなければならない。しかしながら、本システムのサポートベクタマシン判別器は 2 クラスの分類を行うものである。よって、本節ではある状態とその他の状態という 2 クラス判別を各状態についておこない、それらの複数の識別結果を総合して 1 つの情報を決定する手法をもちいることにする。学習データには、握り動作における安静状態と動作状態、および開き動作における安静状態と動作状態について各 3 秒間のデータをもちいた。複数の予測に関して、2 状態以上の識別結果が競合した場合や、すべての状態について当てはまらない(不明)と予測した場合についてはすべて誤分類として正解率を算出した。各被験者の識別結果を以下に示す。左から 3 クラス判別の正解率、不明を含めた分類したクラスの割合、各状態についての 1 対他 2 クラス判別の正解率を示した。正解率は最大で 32%、どの被験者でも 50%以上が識別不明と判別した。

Table 4.8 Sub.1 の把握動作における 3 クラス判別の結果 (%)
(左から正解率, 分類したクラスの割合, 1 対他判別の正解率)

計測点	正解率	不明	安静	握り	開き	安静-他	握り-他	開き-他
F3	28.69	50.87	49.13	0	0	58.34	75.96	73.94
F4	25.55	57.00	42.99	0.01	0	58.10	76.00	74.00
C3	31.53	47.25	52.75	0	0	60.31	76.49	73.51
C4	33.33	46.63	53.37	0	0	63.30	76.96	73.03
Cz	25.54	55.96	44.04	0	0	56.92	76.04	74.08
P3	30.41	49.73	50.27	0	0	60.51	76.51	73.53
P4	29.11	51.85	48.15	0	0	60.02	75.51	74.54
平均	29.17	51.33	48.67	0	0	59.64	76.21	73.80

Table 4.9 Sub.2 の把握動作における3クラス判別の結果 (%)
 (左から正解率, 分類したクラスの割合, 1 対他判別の正解率)

計測点	正解率	不明	安静	握り	開き	安静-他	握り-他	開き-他
F3	28.69	50.87	49.13	0	0	58.34	75.96	73.94
F4	25.55	57.00	42.99	0.01	0	58.10	76.00	74.00
C3	31.53	47.25	52.75	0	0	60.31	76.49	73.51
C4	33.33	46.63	53.37	0	0	63.30	76.96	73.03
Cz	25.54	55.96	44.04	0	0	56.92	76.04	74.08
P3	30.41	49.73	50.27	0	0	60.51	76.51	73.53
P4	29.11	51.85	48.15	0	0	60.02	75.51	74.54
平均	29.17	51.33	48.67	0	0	59.64	76.21	73.80

Table 4.10 Sub.3 の把握動作における3クラス判別の結果 (%)
 (左から正解率, 分類したクラスの割合, 1 対他判別の正解率)

計測点	正解率	不明	安静	握り	開き	安静-他	握り-他	開き-他
F3	25.08	63.12	36.88	0	0	63.33	74.47	75.48
F4	30.20	55.69	44.31	0	0	66.04	75.02	75.03
C3	28.36	58.64	41.36	0	0	65.41	74.00	75.94
C4	27.92	59.92	40.08	0	0	65.75	74.55	75.47
Cz	27.92	59.92	40.08	0	0	65.75	74.55	75.47
P3	24.59	66.51	33.48	0	0	65.60	74.61	75.48
P4	27.42	62.21	37.79	0	0	67.03	74.54	75.48
平均	27.36	60.86	39.14	0	0	65.56	74.53	75.48

Table 4.11 Sub.4 の把握動作における 3 クラス判別の結果 (%)
 (左から正解率, 分類したクラスの割合, 1 対他判別の正解率)

計測点	正解率	不明	安静	握り	開き	安静-他	握り-他	開き-他
F3	30.96	57.09	42.91	0	0	69.59	75.43	74.47
F4	31.97	57.02	42.98	0	0	70.17	74.60	75.36
C3	35.41	52.90	47.09	0.01	0	73.63	76.84	73.26
C4	32.25	54.23	45.77	0	0	68.79	76.28	73.65
Cz	29.98	59.67	40.33	0	0	69.62	75.42	74.59
P3	32.72	55.18	44.82	0	0	70.66	75.84	74.11
P4	32.72	55.18	44.82	0	0	70.66	75.84	74.11
平均	32.29	55.90	44.10	0	0	70.45	75.75	74.22

Table 4.12 Sub.4 の把握動作における 3 クラス判別の結果 (%)
 (左から正解率, 分類したクラスの割合, 1 対他判別の正解率)

計測点	正解率	不明	安静	握り	開き	安静-他	握り-他	開き-他
F3	26.74	51.56	48.44	0	0	55.09	75.88	74.07
F4	25.70	53.83	46.17	0	0	55.36	74.47	75.39
C3	19.70	66.00	34.00	0	0	55.35	74.52	75.53
C4	26.33	51.32	48.68	0	0	53.92	75.95	74.11
Cz	21.23	62.23	37.77	0	0	54.63	76.54	73.52
P3	14.84	74.73	25.27	0	0	54.43	74.52	75.46
P4	21.23	62.23	37.77	0	0	54.63	76.54	73.52
平均	22.25	60.27	39.73	0	0	54.77	75.49	74.51

4.5 マハラノビス距離をもちいた状態判別

4.4 節では、状態判別器にサポートベクタマシンをもちいてそれぞれの状態に対して判別を行い、その識別結果を述べた。しかしながら、先行研究における判別器はマハラノビス距離をもちいたものであったため、直接的に比較することはできない。そこで、本節では、マハラノビス距離を判別器として再構築した新たな判別システムをもちいて手部の運動に関する判別を行うことにする。なお、判別にもちいる実験データおよび信号処理は同様である。

4.5.1 安静状態と握りまたは開き状態の2クラス判別

4.4 節と同様に、各状態における3秒間の学習データを切り出し、安静状態と握り状態および安静状態と開き状態の2パターンの組み合わせについてマハラノビス距離をもちいて安静一動作に関する2クラス判別を行った。その識別結果を Table4.13-4.14 に示す。安静一握りに関しては4名、安静一開きに関しては3名がサポートベクタマシンによる判別と比較して、識別性能が向上したことが確認できた。また、マハラノビス距離を利用した先行研究の判別結果が平均61.5%であったのに対し、握りおよび開きのどちらの動作においても運動の有無に関して平均64%以上の識別性能を示した。一方で、被験者3のように大きく識別性能が低下する結果も見られた。

Table 4.13 マハラノビス距離による安静状態と握り状態の2クラス判別の正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	66.10	68.06	56.96	73.35	66.81
F4	67.66	70.32	57.24	68.60	67.60
C3	64.83	62.74	57.60	78.02	66.24
C4	63.77	64.69	58.71	72.87	67.41
Cz	69.84	64.82	58.75	70.34	68.30
P3	64.65	65.57	57.33	73.18	64.71
P4	63.11	60.29	56.88	70.03	67.87
平均	65.71	65.21	57.64	72.34	66.99

Table 4.14 マハラノビス距離による安静状態と開き状態の2クラス判別の正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	65.74	66.65	65.31	69.28	63.59
F4	65.93	68.14	58.60	70.77	63.77
C3	64.83	66.71	61.38	75.33	65.53
C4	65.17	64.90	59.68	73.52	63.55
Cz	63.58	63.08	57.69	70.93	65.34
P3	61.00	56.83	60.42	70.62	64.90
P4	65.37	53.18	60.50	71.59	63.22
平均	64.52	62.78	60.51	71.72	64.27

4.5.2 握りおよび開き状態の2クラス判別

次に、握り状態と開き状態についてマハラノビス距離をもちいて2クラス判別を行った。その識別結果をTable4.15に示す。サポートベクタマシンによる判別と比較すると、各被験者によって識別結果の変化が異なった。しかしながら、低下の度合いに対して、向上した度合いの方が大きく、全体的には識別性能が向上したと言える。

Table 4.15 マハラノビス距離による握り状態と開き状態の2クラスに関する正解率 (%)

計測点	SUB1	SUB2	SUB3	SUB4	SUB5
F3	63.43	59.92	64.11	61.23	66.46
F4	59.02	58.39	59.24	60.29	67.84
C3	51.54	57.00	63.98	63.36	69.10
C4	59.18	57.47	63.99	66.22	69.08
Cz	58.85	58.69	61.18	60.64	69.86
P3	61.44	57.10	63.60	62.62	68.26
P4	60.48	59.43	61.22	63.32	68.55
平均	59.13	58.29	62.47	62.53	68.45

4.5.3 把握動作のマルチクラス判別

最後に、把握動作についてマハラノビス距離をもちいてマルチクラス判別を行った。その識別結果を Table4.16-4.20 に示す。左から順に、各計測点の正解率、正解率の内訳、分類の選択割合である。サポートベクタマシンによる判別と比べ、正解率は著しく向上した。この理由として、サポートベクタマシンをもちいた判別では、1 対他判別器を繰り返すことによってマルチクラスでの判別を行っていたため、全ての判別器において他クラスとして分類されてしまった場合に識別不明として判別されてしまうという欠点があり、本システムでは多くが識別不明として分類されてしまったが、マハラノビス距離をもちいた判別では各集合との距離が等しくならない限り、必ずどれかの集合に分類されたためであると考えられる。最もよく判別された状態は安静状態であり、周期パワースペクトルをもちいた判別器の識別結果と同様の結果を示した。しかしながら、その識別性能は芳しくなく、ハンドへの実装を考えると更なる精度の向上が必要である。

Table 4.16 Sub.1 の把握動作におけるマハラノビス距離による 3 クラス判別の結果(%)

計測点	正解率	正解率の内訳			不明	選択割合		
		安静	握り	開き		安静	握り	開き
F3	55.48	23.01	13.62	18.84	0	24.51	29.04	46.45
F4	52.57	20.04	12.28	20.26	0	22.27	23.88	53.84
C3	53.17	19.69	16.51	16.97	0	21.34	38.78	39.88
C4	52.16	18.06	15.44	18.66	0	18.78	32.69	48.53
Cz	55.16	21.14	15.65	18.38	0	22.72	33.30	43.98
P3	50.76	17.42	16.00	17.35	0	18.59	36.40	45.00
P4	58.47	26.39	16.66	15.41	0	30.17	35.05	34.78
平均	53.97	20.82	15.17	17.98	0	22.63	32.74	44.64

Table 4.17 Sub.2 の把握動作におけるマハラノビス距離による3クラス判別の結果(%)

計測点	正解率	正解率の内訳			不明	選択割合		
		安静	握り	開き		安静	握り	開き
F3	57.55	31.42	18.81	7.33	0	38.37	47.76	13.88
F4	59.10	33.19	20.02	5.89	0	39.40	49.93	10.67
C3	52.92	25.05	23.44	4.43	0	26.05	66.59	7.37
C4	54.92	27.68	21.42	5.82	0	30.56	58.78	10.66
Cz	56.93	29.73	17.60	9.60	0	33.51	45.09	21.40
P3	54.78	28.98	21.70	4.10	0	34.20	58.77	7.03
P4	57.23	32.87	17.04	7.31	0	42.69	42.69	14.62
平均	56.21	29.85	20.00	6.35	0	34.97	52.80	12.23

Table 4.18 Sub.3 の把握動作におけるマハラノビス距離による3クラス判別の結果(%)

計測点	正解率	正解率の内訳			不明	選択割合		
		安静	握り	開き		安静	握り	開き
F3	60.83	41.41	10.40	9.02	0	60.11	23.66	16.23
F4	58.94	35.39	17.40	6.16	0	45.79	40.33	13.88
C3	62.17	38.31	13.63	10.23	0	51.20	30.68	18.12
C4	60.71	42.10	12.52	6.09	0	62.22	27.67	10.11
Cz	61.27	43.79	11.01	6.47	0	64.44	23.16	12.39
P3	58.14	42.09	8.99	7.06	0	64.69	22.16	13.15
P4	57.05	45.49	8.37	3.19	0	74.48	19.33	6.19
平均	59.87	41.23	11.76	6.89	0	60.42	26.71	12.87

Table 4.19 Sub.4 の把握動作におけるマハラノビス距離による3クラス判別の結果(%)

計測点	正解率	正解率の内訳			選択割合			
		安静	握り	開き	不明	安静	握り	開き
F3	55.50	26.43	7.60	21.47	0	28.80	15.54	55.66
F4	59.45	31.97	7.48	20.00	0	36.42	14.65	48.93
C3	59.96	30.59	11.47	17.90	0	34.16	21.42	44.41
C4	58.80	27.43	15.29	16.08	0	30.34	32.89	36.77
Cz	60.70	34.21	9.77	16.72	0	40.65	19.48	39.87
P3	58.87	31.67	9.47	17.73	0	38.85	18.48	42.67
P4	64.00	38.22	10.78	14.99	0	47.89	18.75	33.36
平均	59.61	31.50	10.27	17.84	0	36.73	20.17	43.10

Table 4.20 Sub.5 の把握動作におけるマハラノビス距離による3クラス判別の結果(%)

計測点	正解率	正解率の内訳			選択割合			
		安静	握り	開き	不明	安静	握り	開き
F3	55.50	23.10	13.56	18.84	0	24.62	28.92	46.46
F4	52.65	20.05	12.36	20.24	0	22.31	24.05	53.63
C3	53.11	19.66	16.51	16.94	0	21.31	38.90	39.79
C4	52.11	18.03	15.48	18.60	0	18.75	32.89	48.36
Cz	55.11	21.14	15.65	18.32	0	22.76	33.45	43.79
P3	50.81	17.43	16.06	17.33	0	18.60	36.47	44.93
P4	58.47	26.40	16.62	15.45	0	30.16	34.97	34.86
平均	53.97	20.83	15.18	17.96	0	22.64	32.81	44.55

4.6 おわりに

本章では、実験概要および観測データをもちいた解析とその結果について述べた。4.2 節では、実験目的や実験に関する概要、計測環境、解析ソフトウェアなどについて述べた。4.4 節では、本実験で観測した脳波データをもちいたサポートベクタマシンによる解析結果について述べた。4.5 節では、マハラノビス距離による解析結果について述べた。

第5章 考察

5.1 はじめに.....	72
5.2 考察.....	73
5.3 おわりに.....	76

5.1 はじめに

本章では, 前章において述べた実験および解析結果を踏まえ, その考察を述べる.

5.2 考察

まず、本研究ではサポートベクタマシンによる判別器をもちいて把握動作における各状態についての判別にくわえ、先行研究に倣いマハラノビス距離による把握動作の判別を試みた。マハラノビス距離をもちいた判別器に関して、先行研究では α 波と β 波のパワースペクトルの左右差から検出した上肢運動の有無についての識別性能は平均 61.5%であったが、本システムにおける α 波の周期パワースペクトルから検出した把握運動の有無についての識別性能は握りおよび開きのどちらにおいても平均 64%を超え、その有効性が示された。

一方で、 α 波の周期パワースペクトルとサポートベクタマシンをもちいた安静状態と運動状態に関する 2 クラス判別は、当初十分に識別することができなかったが、周期パワースペクトルに対するデシベル変換および平滑化によって平均 63%を超える識別結果が得られ、マハラノビス距離による判別と同程度の性能を示した。これは、 α 波の周期パワースペクトルが低周波帯に大きな変化を有しており、サポートベクタマシンの特性からその影響を受けたために、運動状態の識別不良が生じたと考えられる。また、平滑化によってノイズ成分が取り除かれたことでより特徴量がはっきりと現れ、最も良い判別が可能になったと言える。逆に言えば、運動に伴う α 波の周期パワースペクトルの変化は非常に小さなスケールで発現しているため、少しのノイズでも埋もれてしまい検出できなくなる可能性がある。特に、握り動作と開き動作の 2 クラス判別は、本研究の 2 種類の判別システムのどちらにおいても十分な識別をすることができなかった。この原因として第一に、握り状態と開き状態の 2 つの集合において線形分離することができなかったことが考えられる。サポートベクタマシンのアルゴリズムは線形分離可能であることを前提に分類を行うため、各集合の学習データが線形分離できない場合には十分な分類が行えない。その解決法としては、学習データをさらに高次元空間へ写像することで、変換後の空間における線形分離を可能とするカーネル法が挙げられ

る。しかしながら、データがさらに大きくなるため計算量が増大することに注意しなければならない。また、マハラノビス距離に関して各集合の距離が十分に離れていなかったことも識別不良の原因の一つとして考えられる。マハラノビス距離は一元化された値であるため、判別条件において距離に重み係数をもたせることで特定の状態の優先度を設定することが可能となる。したがって、適切な重み係数を設定すれば識別精度の向上が見込めるが、その値の探索が次の課題と言える。よって、本システムでは少なくとも握りと開きの2つの手部運動に関してサポートベクタマシンおよびマハラノビス距離をもちいて十分に分類することはできず、2つの違いをよく説明するような特徴量を抽出する他のアプローチを検討する必要がある。

さらに、把握動作における3クラス判別では、2クラス判別と同様の信号処理を施した入力であっても、サポートベクタマシン判別器による識別結果の半数以上が識別不明と分類され、この判別器を実装することは到底できない。ハンド制御を目的としたシステムであることから、安全かつ安定した挙動を実現するために曖昧な識別結果である場合には未分類とすることが望ましいが、今回の結果ではあまりにも正解率が低く、実用的ではない。この原因として、第一に握り動作と開き動作における2クラスの判別が不十分であることが挙げられる。どの被験者においても、ほとんどが安静または識別不能に分類され、その安静クラスにおける適合率は平均64%を超えた。したがって、安静を識別する性能はまずまずだが、動作状態をそれぞれ区別することが困難であるということが3クラス判別からも読み取ることができる。一方で、マハラノビス距離判別器では53%以上の識別結果を示した。これは、サポートベクタマシン判別器とは異なり、境界上を除いて必ずどれかの集合を選択するため、未分類とする判別結果が極めて少なくなったことが理由であると考えられる。しかしながら、誤分類による誤操作が懸念され、ハンドへ実装するにはまだ不十分である。

最後に、サポートベクタマシン判別器とマハラノビス距離判別器との2クラス判別に

おける識別結果に大きな差は見られなかったが、それぞれの計算量に大きな差が生じたことが明らかとなった。サポートベクタマシン判別器において計測点1点あたり1分29.3秒を計算に要したのに対し、マハラノビス距離判別器はその4.8%である4.3秒で計算処理が終了した。スムーズかつ負荷の少ない学習処理を実現するためには、マハラノビス距離判別器が適していると言える。

これらの結果から、 α 波の周期パワースペクトルをもちいたサポートベクタマシンおよびマハラノビス距離による手部の運動判別は、現時点において安静-動作についての2クラス判別をすることはできるが、3クラス以上の状態を判別するためには不十分であり、他のアプローチを検討する必要がある。したがって、本システムをもちいてロボットハンドを制御することを考えると、2クラスの運動判別によってパルス信号を生成し、ハンドを開閉するスイッチとして利用できると期待される。しかしながら、ハンドを一定の姿勢で維持したり、把持力を調整したりといったより実用的な制御は、この方法では実現できない。したがって、本システムを活用したパルス信号によるハンドの開閉制御の実現、および他のアプローチによる把握動作のマルチクラス判別が次点の課題と言える。

5.3 おわりに

本章では, 本研究の実験および解析結果についての考察を述べた.

第6章 結論

6.1 はじめに.....	78
6.2 結論.....	79

6.1 はじめに

本章では, 結論として本論文をまとめ, 今後の展望について述べる.

6.2 結論

本研究では、肢体不自由者のためのサポートツールのひとつとして、ロボットハンドの制御に向け、 α 波の周期パワースペクトルの変化を利用した手部の運動意図を検出するためのサポートベクタマシンおよびマハラノビス距離をもちいた状態判別システムの構築を試みた。まず始めに、脳波の観測データに対して 2 度の STFT によって α 波の周期パワースペクトルを得た。また、サポートベクタマシン利用した 2 クラスおよび 3 クラス判別器のシステムを作成した。このシステムをもちいて安静状態と手部の握り動作に関する 2 クラス判別を行った。しかしながら、事前の想定とは異なり、十分な識別結果を得ることはできなかった。そこで、構築したシステムを再考し、サポートベクタマシンにおいて低周波数帯の影響を抑えるため対数スケールへの変換、ノイズ除去を目的とした平滑化の処理を行ったところ、握り動作と開き動作のどちらの場合でも、識別性能の向上が確認された。これは、周期パワースペクトルをもちいた手部動作についての運動判別として初めての試みであり、これによって脳波から手部の運動意図を抽出し、状態判別器によって生成されたパルス信号をもちいたロボットハンド制御の可能性が示された。同様に、本システムをもちいて把握動作についての 3 クラス判別をおこなった。しかしながら、十分な識別結果を得ることができなかった。また、その識別結果から安静状態の適合率を評価し、本システムでは把握動作の 2 状態を区別することが困難であることを裏付けた。

また、先行研究との識別精度を比較するためにマハラノビス距離をもちいた判別システムを同様に構築し、同条件における状態判別を試みた。2 クラス判別における識別性能は、どちらの判別器においても先行研究を上回る結果を示し、その有効性を示した。一方で、3 クラス判別においては異なる識別結果を示し、どちらも実装には不十分である結果となった。さらに、それぞれの判別器の計算量を算出したところ、マハラノビス距離判別器の方が、著しく高速に処理が終了することが明らかとなった。

このことから、手部動作に関連した脳波を周期パワースペクトル解析法およびサポートベクタマシンをもちいた運動判別器によって運動の有無の検出が可能であるが、判別手法としてマハラノビス距離をもちいることでさらに高速かつ低負荷での計算が可能であることも示唆された。

6.3 今後の展望

本研究では、脳波から手部動作に関する情報を解析し、運動判別をするためのシステムの構築を目指して進めてきた。この技術を応用し、安静状態と動作状態の2クラス判別によって生成されたパルス信号をもちいたロボットハンドの開閉制御システムの開発およびリアルタイム計測システムの構築を目指す。また、様々な機能を有する手部動作を再現するロボットハンドの制御を実現するために、複数の運動状態に対してそれぞれを特徴づけるような脳波を突きとめ、脳波と把持の筋活動に関する線形モデルを構築し、ロボットハンドを制御するためのシステムを生成することを目指す。

謝辭

本論文を審査していただいた審査委員の横井浩史教授，中村友昭准教授に深く感謝いたします。また，本研究を進めるにあたってご指導，ご助言をいただきました姜銀来准教授，東郷俊太准教授，山野井佑介特任助教，吉岡将孝先生ならびに横井・東郷・姜研究室の学生諸氏に深く感謝申し上げます。

はじめに，主任指導教員である横井浩史教授には，多大なるご指導を賜りました。横井浩史教授のご指導のもと，学部4年次から修士2年次まで大変有意義な3年間を過ごせましたことを厚く御礼申し上げます。

また，姜銀来准教授，東郷俊太准教授，山野井佑介特任助教には，研究を進める上で様々な観点からご指導，ご助言をいただきました。心より感謝申し上げます。

高知工業高等専門学校吉岡将孝先生には，本研究を遂行するにあたり必要な周期パワースペクトル解析について，詳細にご教授いただきました。誠に感謝いたします。

横井・東郷・姜研究室の学生諸氏には，脳波の計測に関して快く協力していただき，またさまざまな形でお世話になりました。大変感謝しております。

そして，いつも私を支えてくれた家族および友人たちに感謝の意を表します。

参考文献

<和文文献>

[厚生労働省 2019]

厚生労働省：“平成28年 生活のしづらさなどに関する調査(全国在宅障害児・者等実態調査)結果の概要”，“https://www.mhlw.go.jp/toukei/list/seikatsu_chousa_b_h28.html”，2019年4月.

[浅見 2013]

浅見豊子：“筋電義手の実用性における課題”，日本義肢装具学会誌, Vol.29, No.2, pp.74-79, 2013.

[生田 2003]

生田義和, 土井一輝, 三浪明男：“上肢の外科”，医学書院, 2003.

[田中 2012]

田中一男：“脳波指令で動く車いすの開発”，精密工学会誌, Vol.78, No.8, pp.662-665, 2012.

[宮内 2013]

宮内哲：“脳を測る—改訂ヒトの脳機能の非侵襲的測定—”，Japanese Psychological Review, Vol.56, No.3, pp.414-454, 2013.

[掬川 2019]

掬川伊織：“周期パワースペクトル解析法を用いた把握動作のための脳波解析”，卒業論文, 2019.

[川村ら 1999]

川村次郎, 福井信佳, 中川正己, 藤下武, 青山孝, 古川宏: “上肢切断者の現状と動向—新規地区におけるアンケート調査から—”, *リハビリテーション医学*, Vol.36, No.6, pp.384-389, 1999.

[横井 2013]

横井浩史, 矢吹佳子, 關達也, 中村達弘, 森下壮一郎, 加藤龍, 高木岳彦, 高山真一郎: “筋電制御型の義手”, *バイオメカニズム学会誌*, Vol.38, No.1, 2014.

[木村 1992]

木村貞治: “筋力と筋電図”, *運動生理*, 7(3), 175-187, 1992.

[三宅 2017]

三宅晋司: “商品開発・評価のための整理計測とデータ解析のノウハウ”, *日本人間工学会PIE研究部会編*, 2017.

[吉田 2008]

吉田正俊: “細胞外電極は何をみているか”, “<http://www.hips.ac.jp/myoshi/yoshida.pdf>”, 2008.

[坂井 2016]

坂井郁也: “脳情報解読レベルに応じた運動出力型BMIシステムの提案”, *修士論文*, 2016.

[入戸野 2000]

入戸野宏, 堀忠雄: “心理学研究における事象関連電位(ERP)の利用”, *広島大学総合科学部紀要IV理系編*, Vol.26, pp.15-31.

<英文文献>

[Yoshioka et. al 2016]

M.Yoshioka, H.hongbo, N.Ueda, Y.Tian and C.Zhu: “Construction of BMI Power Assistance System with the EEG-Torque Model”, *Neuroscience and Biomedical Engineering*, Vol.4, No.3, pp.209-214(6), 2016.

[L.J.Garey 1994]

L.J.Garey, “Brodmann’s Localisation in the cerebral cortex”, Springer, pp.105-170, 1994.

[Bashashati et.al 2007]

A.Bashashati, M.Fatourechi, R.K.Ward and G.E.Birch: “survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals”, *Journal of Neural Engineering*, Vol.4, No.2, 2007.

[Yoshioka et.al 2017]

M.Yoshioka, C.Zhu, Y.Yoshikawa, K.Ueno, H.Yu, F.Duan and Y.Yan: “Motion Classifier Generation by Mahalanobis Distance for Robot Arm Control BMI System”, *Journal of Neuroscience and Neuroengineering*, Vol.4, No.1, pp. 1-8(8), 2017.

[McFarland et. al 2000]

D.J.McFarland, L.A.Miner, T.M.Vaughan and J.R.Wolpaw: “Mu and Beta Rhythm Topographies During Motor Imagery and Actual Movements”, *Brain Topography*, Vol.12, No.3, pp.177-186, 2000.

[Koike et. al 1994]

Y.Koike, M.Kawato: “Traject formation from surface EMG signals using a neural network model”, Proceedings of the 15th Annual International Conference of the IEEE Engineering in Medicine and Biology Soicet, pp.944-945, 1993.

[Hochberg et. al 2012]

L.R.Hochberg, D.Bacher, B.Jarosiewicz, N.Y.Masse, J.D.Simeral, J.Vogel, S.Haddadin, J.Liu, S.S.Cash, P.van der Smagt and J.P.Donoghue: “Reach and grasp by people with tetraplegia using a neurally controlled robotic arm”, Nature, Vol.485, pp.372-375, 2012.

[Freeman 2003]

W.J.Freema, M.D.Holmes, B.C.Burke, S.Vanhatalo:”Spatial spectra of scalp EEG and EMG from awake humans”, Clinical Neurophysiology, Vol.114, No.6, pp.1053-1068, 2003.