

2016 年度 博士学位論文

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
一周期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
指導教員 朱 赤 教授



前橋工科大学大学院
環境・生命工学専攻 博士後期課程

1356504

吉岡 将孝

Masataka YOSHIOKA

審査員

主査	今村 一之	教授
委員	朱 赤	教授
	王 鋒	教授
	田中 恒夫	教授
	横井 浩史	教授

謝辞

本論文を審査して頂いた審査委員会の今村一之教授，朱赤教授，王鋒教授，田中恒夫教授，横井浩史教授に深く感謝いたします。また，本研究を行うにあたってご指導，ご助言を頂きました朱赤教授，ならびに朱研究室の学生諸氏に深く感謝いたします。

担当教員である朱赤教授は研究の初歩からお教えいただき，またその着眼点や重要性を説いていただきました。さらに，研究遂行するにあたっての研究設備や脳波計測に必要な実験環境を揃えていただきました。論文執筆にあたっては多くの助言やサポートをいただき，誠に感謝いたします。

また，前橋工科大学システム生体工学科の今村一之教授と王鋒教授には，Brain Machine Interface 研究の当初から医学や工学の様々な知見のアドバイスをいただき深く感謝を申し上げます。

朱研究室の大学院生，学部生諸氏には快く脳波の計測に関して協力していただき感謝いたします。また，本研究に関して一緒に学び研究を行った，吉川裕一郎氏，上本和広氏，梁宏博氏，上田直哉氏，田野氏，岩田悠氏には大変感謝をしております。また，数多くの指導をしていただいたシステム生体学科および専攻の先生の方々，そして，前橋工科大学の事務局員の方々に心から感謝の気持ちと御礼を申し上げます。

最後に本研究を進めるにあたり，独立行政法人日本学術振興会科学研究費基盤研究C（課題番号 22303）によって大きく進展したことをここに御礼申し上げます。

研究概要

近年、人の脳情報を活用した Brain Machine Interface (BMI) によるロボット制御の研究が進められている。光や音による刺激に対する脳の反応や運動想起などの自発的な脳活動を利用したコンピュータカーソル・電動車いす・ロボットアームの操作の研究および実用化されている。そして、体が動かすことが出来なくなった肢体不自由者に対して、BMI を活用して脳情報を用いて外骨格ロボットを操作し、歩行や物体把持、また、まひ部位のリハビリテーションを実現しており、医療・福祉分野での応用が期待されている。本研究では、このような外骨格ロボットに BMI 技術を用いて、健常者および身体障害者の動作支援を行う BMI パワーアシストシステムの構築を目的とする。これまでの外骨格パワーアシスト装置を操作する信号は力/トルクセンサや筋電位センサから取得されているのが主流であったが、身体障害者ではその信号となる力や表面筋電位を十分に発生させることは困難であるため、外骨格パワーアシストを行うことが出来ない。そこで、表面筋電位の代わりに脳波から関節トルク情報を抽出し、外骨格ロボットの制御信号として使用することで、身体障害者でもパワーアシストを実現することが可能となると考えられる。

本論文では、まず脳波から運動に関する特徴量の抽出を行い、閉眼時、開眼時、運動時の α 波・ β 波におけるパワースペクトルの変化を観測する。そこで得られた α 波・ β 波のパワースペクトルの変化は計測点 1 点による解析ではタスク間で異なる変化を見せ、脳の左右差の解析においても、左腕の運動に関するタスク時で脳波のパワースペクトルに左右差があることを観測した。これを第 4 章に述べる。そして、得られたパワースペクトルの特徴をマハラノビスの汎距離を用いて判別器を生成し、運動の有無の判別を行った。これを第 5 章に述べる。

次に、それらの得られた脳波の特徴量と人の運動と関連している表面筋電位の振幅（筋活動）を主成分モデルを用いて脳波-関節トルク間の線形モデルを作成し、脳波から関節トルクの推定を行う。これまでの運動情報の推定には脳波との線形モデルを用いられてきたが、作成されたモデルは時系列線形モデルとなっており、歩行などの周期性のある運動にしか適応せず、また、多くのパラメータが必要となっていた。さらに、これまでの手法ではタスクごとにパラメータを学習しており、学習したタスクと異なるタスクを行った場合は再構成の精度が落ちる傾向がある。そのため、タスクに影響されないパラメータの逐次更新方法を導入する必要がある。したがって、得られた線形モデルを障害者に適応させるための手法として、ロボットアームから得られる角度情報を用いて逐次最小二乗法の教師信号を生成し、脳波-関節トルク間の線形モデルの更新を行ったところ、オフライン推定で計測された筋活動と高い相関を得ることが出来た。これを第6章に述べる。

そして、脳波-関節トルク間の線形モデルを生成するためには、脳波から関節トルクとの線形関係のある特徴量が必要であることがわかった。波・波のパワースペクトルは運動に関連していることが分かったが、線形関係のある信号とは言えなかった。そこで、本研究では波・波のパワースペクトルの周期の変化に着目し、新たな特徴量を算出を行うため、運動に関する脳波に対して新たな解析手法となる周期パワースペクトル解析し、その特徴を抽出した。その結果、筋活動を使ってロボットアームを動かした際に波と波の変動は各計測点において

波では 20-25Hz、波では 10-15Hz の帯域で運動に関連していることが確認された。そして、主成分分析による脳波の周期パワースペクトル-関節トルク間の線形モデル作成手法を作成し、さらに、本手法を用いた脳波からの関節トルク推定、また得られたトルクからロボットアームを動かす実験を行い、その有効性を確認した。これを第7章に述べる。

Abstract

Recently, the research on robot manipulation technology by Brain Machine Interface(BMI) utilizing human brain information is developed. In this technology, it is possible to support the machine performs motion instead of human motion and communicate using monitor and/or sounds without action. And, for disabilities whose body can not be moved, walking and object grasping are performed by exoskeleton robot using brain information. Also, applications of rehabilitation to move the part of paralysis by exoskeleton robot are developed, these technologies are utilized by various devices and expected to be applied in medical, assistive and rehabilitation fields.

To support daily life by BMIs, it is necessary to reconstruct the motion information by measured electroencephalogram(EEG) signals. Signals for operating the exoskeleton power assist device have been mainly acquired from force/torque sensors and/or electromyography(EMG) sensors. Although, because it is difficult for disabilities to sufficiently generate force and EMG, they can't use exoskeleton power assist devices. Therefore, our purpose is to estimate the force/torque information from the brain activity to help and support the human's daily life.

At first, in this study, four different tasks corresponding to different brain excitation degrees are designed. Their EEG spectra are analyzed with short-time Fast Fourier Transform(FFT), their features of alpha and beta rhythms corresponding to the different tasks are extracted. And, in the analysis of the left and right difference of the brain, it was also observed that the power spectrum on the left brain side becomes large at the task related to the movement of the left arm.

Next, a linear model between EEG and joint torque is created by the principal component model of the obtained EEG features and the EMG related to human motion, and the joint torque is estimated by the EEG features.

Linear models with brain waves have been used to estimate motion information so far, but the created model is a time series linear model, it can adapt only to periodic exercise such as walking, and Many parameters were required. Furthermore, in the conventional methods, the parameters are learned for each task, and the accuracy of reconstruction tends to decrease when tasks different from the learned tasks are performed. It is necessary to introduce a method of sequential updating of parameters that is not affected by tasks. Therefore, as a method for adapting the obtained linear model to disabilities, the teaching signals of the sequential least squares method are generated by angle information obtained from the robot arm to update the linear model between the EEG and the joint torques. And the estimated EMG had high correlation with EMG measured in offline.

Finally, in order to generate a linear model between EEG and joint torques, it was found that a feature amount having a linear relationship with the joint torque is required from the EEG. Although it was found that the power spectrum of alpha and beta waves is related to motion, it can not be said that the signals are in a linear relationship. Therefore, it was difficult to obtain a convergent solution of the linear model by the sequential least squares method. We analyze the measured EEGs in movement to extract the relationship between EEGs and EMG signals, and further estimate the joint torque from the EEGs. The results show that the periodicity of alpha and beta wave variations at each measurement point have strong associations with the subject's movement. Based on this, we build a linear model representing the relationship between EEGs and EMG by PCA, and the EMG signals are successfully estimated from EEGs. This implies a great potential to use EEGs for supporting human's activities. Periodic changes of the power

spectra relates to human moving at 20-25Hz in alpha band and 10-15Hz in beta band. From these results, the linear model between the EEGs and the joint torque which developed by principal component analysis are confirmed and it is used to estimate the joint torque. The validity of this approach is verified by experiments.

目次

第1章	緒論	17
1.1	研究背景	17
1.2	目的	19
1.3	本文の構成	19
第2章	関連研究	21
2.1	Brain Machine Interface	21
2.1.1	侵襲型 BMI	21
2.1.2	非侵襲型 BMI	26
2.1.3	脳活動からの特徴抽出	31
2.2	問題提起および本研究の概要	38
第3章	計測環境および信号処理	39
3.1	脳活動の計測の仕方	39
3.2	脳波 (ElectroEncephaloGraphy: EEG)	44
3.3	運動に関連する脳波	45
3.4	脳波及び筋電計測システム	46
3.5	脳波の周波数領域の解析	47
3.5.1	高速フーリエ変換	47
3.5.2	短時間フーリエ変換 (Short-Time Fourier Transform; STFT)	50
3.6	表面筋電位と関節トルクの関係	52
3.7	整流平滑化 (Average Rectified Value:ARV)	55

3.8	まとめ	57
第4章	運動・運動想起に関する脳波の調査	58
4.1	運動時の計測点1点での α 波および β 波の左右差の解析	58
4.1.1	測定手法および実験タスク	59
4.1.2	運動想起判別のためのタスク設計	59
4.1.3	各タスクのパワースペクトルの特徴	62
4.2	運動時の計測点2点での α 波および β 波の左右差の解析	65
4.2.1	計測環境	65
4.2.2	タスク設計	66
4.2.3	各タスクにおける α 波と β 波の左右差	68
4.3	運動に関する脳波の α 波と β 波の考察	71
4.4	まとめ	72
第5章	運動の2値判別	74
5.1	2値判別器について	74
5.2	マハラノビスの汎距離	74
5.3	運動判別手順	77
5.4	運動判別結果, 及び考察	83
5.5	筋収縮数理モデルによるロボットアーム目標角の決定	89
5.5.1	筋収縮数理モデル	89
5.5.2	ロボットアーム目標角の決定	90
5.6	まとめ	92
第6章	主成分モデルを用いた脳波筋活動モデルの構築	93
6.1	主成分モデルによる脳波筋活動モデル	93
6.2	主成分モデルの構築	94
6.2.1	2次元での主成分分析	94
6.2.2	N 次元での主成分分析	97

6.2.3	主成分モデルを用いた脳波筋活動モデル	97
6.2.4	逐次最小二乗法によるパラメータの更新	99
6.2.5	パラメータ更新のための教師信号	100
6.3	脳波から筋活動推定の実験	102
6.3.1	脳波および筋電位計測	102
6.3.2	信号の処理手順	104
6.3.3	推定結果および考察	105
6.3.4	まとめ	108
第7章 運動時における α 波および β 波の周期パワースペクトルの変化の解析		110
7.1	試行間の筋活動と脳波の解析	110
7.1.1	筋電位及び脳波計測, 信号処理	110
7.1.2	20 試行の計測結果	112
7.1.3	相関係数に基づいた解析	116
7.2	筋活動と線形関係を持つ脳波の特徴量の抽出	118
7.2.1	振幅の周期性の抽出	118
7.2.2	ロボットアーム操作時の脳波計測	118
7.2.3	脳波計測と処理手法	119
7.2.4	周期パワースペクトル	124
7.2.5	α 波・ β 波の周期パワースペクトルの変動	127
7.3	周期パワースペクトル-関節トルク間の線形モデルによる推定	132
7.4	関節トルクの推定結果	134
7.5	まとめ	140
第8章 結言		141
8.1	まとめ	141
8.2	今後の展望	142

目 次

1.1	発展するニューロサイエンスの分野と Brain Machine Interface の社会貢献 [5]	18
1.2	本論文の構成	20
2.1	(a) 閉ループ制御のブレインマシンインターフェースをテストするマカザルのモータ制御 [8], (b) 手の位置 (x, y) と速度 (V_x, V_y) および把持力 (GF) の実際の出力 (青色) と線形モデルから得られた予測 (赤線) [7]	22
2.2	ヒトでの侵襲型 BMI [11]	23
2.3	ブラウン大学での研究 [14]	23
2.4	手の動作の機械学習 [16]	24
2.5	ECoG を用いた侵襲型 BMI におけるロボットアーム動作 [16]	25
2.6	BCI2000 の概要 [28]	27
2.7	BCI2000 を用いた BCI (A: 運動関連電位を用いた変数の選択, B: 簡単なスペルの選択, C: 2 値の選択, D: P300 を用いた文字選択) [28]	28
2.8	(a) 注目した方向に移動する脳波車いす [29], (b) 運動想起で操作する電動車いす [30], (c) レーザーレンジファインダと組み合わせた脳波車いす [31]	29
2.9	(a) NeuroRex [33], (b) Walk Again Project [34] による World Cup 2014 のキックオフのデモンストレーション	30
2.10	BOTAS の概要図	30

2.11 MAHI-Exo-II による脳波を用いた腕の操作 [36]	31
2.12 屈曲伸展動作の実験装置 [51]	33
2.13 MRI・fMRI・脳波による筋活動の再構成の処理概要 [51]	34
2.14 筋電再構成結果 [51]	35
2.15 指の位置・速度を計測する実験機器	35
2.16 脳の賦活領域	35
2.17 速度の再構成結果	36
2.18 実験装置	37
2.19 タスクごとの結果	37
3.1 脳機能局在論に基づいたブロードマンの脳地図 (東京大学 生命科学構造化センター / 生命科学ネットワークより)	40
3.2 (a) 人の運動野に用いられる針電極 [11], (b) Electrocorticogram (ECoG) [17]	40
3.3 大型非侵襲型脳活動計測機器, (a) PET, (b) fMRI, (c) Magneto Encephalo Graphy [56]	42
3.4 小型非侵襲型脳活動計測機器, (a) NIRS, (b) 脳波	43
3.5 実験システムの構成	46
3.6 50Hz, 20Hz, 10Hz の合成 sin 波 $y = 5\sin 2\pi \cdot 50 \cdot t + 3\sin 2\pi \cdot 20 \cdot t + \frac{1}{2}\sin 2\pi \cdot 10 \cdot t$ ($t=0 \sim 1[\text{sec}]$)	48
3.7 50Hz, 20Hz, 10Hz の合成 sin 波 (図 3.6) の FFT	48
3.8 閉眼時と開眼時の脳波を FFT をかけた例	49
3.9 短時間高速フーリエ変換概念	51
3.10 時間によって周波数が変わる sin 波 0~1 秒:50Hz, 1~2 秒:20Hz, 2~3 秒:10Hz	52
3.11 (a) 式 (3.8) の STFT (変換窓幅 $N:512\text{msec}$, ずれ幅 $\Delta t:100\text{msec}$) (b) (a) を時間軸で見た場合 (c) 変換窓幅 $N:256\text{msec}$, ずれ幅 $\Delta t:100\text{msec}$ (d) 変換窓幅 $N:512\text{msec}$, ずれ幅 $\Delta t:200\text{msec}$	53

3.12 (a) 閉眼時の脳波データと (b) STFT (サンプリング周期:1kHz, 変換点数 N :1024, ずれ幅 Δt :100msec) を掛けた結果	54
3.13 (a) 開眼時の脳波データと (b) STFT (サンプリング周期:1kHz, 変換点数 N :1024, ずれ幅 Δt :100msec) を掛けた結果	54
3.14 筋電位と重りの線形関係	55
3.15 筋電信号	56
3.16 全波整流を行った筋電信号	56
3.17 ARV 処理した筋電信号 (筋活動)	56
4.1 運動に関する脳の興奮度の違いを考慮した4つのタスク	60
4.2 閉眼時 (Task 1) の短時間フーリエ変換の結果	62
4.3 開眼時 (Task 2) の短時間フーリエ変換の結果 (“A”は瞬きによるアーティファクト)	62
4.4 運動想起時 (Task 3) の短時間フーリエ変換の結果	63
4.5 運動時 (Task 4) の短時間フーリエ変換の結果	63
4.6 各タスク24回のパワースペクトルの平均	64
4.7 各タスク24回の α 波・ β 波パワースペクトルの平均	64
4.8 腕を固定した状態での計測環境	66
4.9 筋電を検知した時のロボットアームの動き	67
4.10 Task 3 と Task 4 のタイムチャート	67
4.11 被験者 A の C_3 と C_4 における α 波と β 波	68
4.12 被験者 B の C_3 と C_4 における α 波と β 波	69
4.13 被験者 C の C_3 と C_4 における α 波と β 波	70
4.14 被験者 D の C_3 と C_4 における α 波と β 波	70
4.15 計測点 C_3 と C_4 の α 波および β 波のパワースペクトルの差の平均と標準偏差	72
5.1 マハラノビスの汎距離を用いた判別	76

5.2	運動判別手順	78
5.3	被験者 A の判別の境界線と，リラックスモードと運動モードのマハラノビスの汎距離	79
5.4	被験者 B の判別の境界線と，リラックスモードと運動モードのマハラノビスの汎距離	80
5.5	被験者 C の判別の境界線と，リラックスモードと運動モードのマハラノビスの汎距離	81
5.6	被験者 D の判別の境界線と，リラックスモードと運動モードのマハラノビスの汎距離	82
5.7	被験者 A の各タスクの判別結果，上段：Task 1-閉眼時 中段：Task 2-閉眼時 下段：Task 3-運動直前，および Task 4-運動時	85
5.8	被験者 B の各タスクの判別結果，上段：Task 1-閉眼時 中段：Task 2-閉眼時 下段：Task 3-運動直前，および Task 4-運動時	86
5.9	被験者 C の各タスクの判別結果，上段：Task 1-閉眼時 中段：Task 2-閉眼時 下段：Task 3-運動直前，および Task 4-運動時	87
5.10	被験者 D の各タスクの判別結果，上段：Task 1-閉眼時 中段：Task 2-閉眼時 下段：Task 3-運動直前，および Task 4-運動時	88
5.11	単収縮曲線	90
5.12	運動時のロボットアーム目標角変化（上から，表面筋電位，筋電から得られた関節トルク，運動判別，筋張力，ロボットアーム目標角）	91
6.1	主成分分析のデータの広がりを考慮した軸変換	94
6.2	新しい軸への垂線	94
6.3	軸の直交回転	94
6.4	脳波と筋活動から主成分モデル生成手順	98
6.5	逐次最小二乗法によるモデルの更新	99
6.6	人の肘関節のアドミッタンスモデル	101
6.7	筋活動推定およびパラメータモデルのブロック図	102

6.8	主成分モデル作成のための脳波・筋電位計測環境	103
6.9	筋活動推定のための信号処理手順	105
6.10	被験者 A の 1 回の屈曲伸展運動の推定結果	106
6.11	被験者 A の 2 回の屈曲伸展運動の推定結果	106
6.12	被験者 B の 1 回の屈曲伸展運動の推定結果	107
6.13	被験者 B の 2 回の屈曲伸展運動の推定結果	107
6.14	被験者 C の 1 回の屈曲伸展運動の推定結果	108
6.15	被験者 C の 2 回の屈曲伸展運動の推定結果	108
6.16	2 回の屈曲伸展運動一回目と二回目の試行の相関係数平均値の比較	109
7.1	計測環境	112
7.2	計測タイムチャート	113
7.3	20 試行の筋活動	113
7.4	20 試行の α 波のパワースペクトル	114
7.5	20 試行の β 波のパワースペクトル	115
7.6	各計測点の相関係数別にマーカー付	117
7.7	(a) 波の減衰と周期性 (b) 閉眼時のパワースペクトルの 2 次元プロット (横軸: α 波, 縦軸: β 波)	119
7.8	2 回の短時間フーリエ変換による周期パワースペクトルの算出	120
7.9	(a) 周期が変わる 10 Hz の信号, (b) 短時間フーリエ変換の結果, (c) 周期パワースペクトル	122
7.10	(a) C_3 における 1 試行の α 波の時系列パワースペクトル, (b) (a) を短時間フーリエ変換した結果	124
7.11	(a) C_3 における 1 試行の β 波の時系列パワースペクトル, (b) (a) を短時間フーリエ変換した結果	125
7.12	被験者 A の各計測点の 10 試行の周期パワースペクトルの平均	126
7.13	被験者 B の各計測点の 10 試行の周期パワースペクトルの平均	127
7.14	被験者 A の (a) 安静時と (b) 運動時の周期パワースペクトルの分布	128

7.15	被験者 B の運動時の周期パワースペクトルの分布	129
7.16	被験者 C の運動時の周期パワースペクトルの分布	129
7.17	被験者 D の運動時の周期パワースペクトルの分布	130
7.18	被験者 E の運動時の周期パワースペクトルの分布	130
7.19	被験者 A-E の安静時と運動時の周期パワースペクトルの分布の比較	131
7.20	脳波-関節トルクモデルの生成手法	133
7.21	被験者 A-C の関節トルク推定結果	134
7.22	被験者 A の推定関節トルクを用いた 1 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度	135
7.23	被験者 A の推定関節トルクを用いたロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度	136
7.24	被験者 B の推定関節トルクを用いた 1 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度	137
7.25	被験者 B の推定関節トルクを用いた 2 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度	138
8.1	BMI パワーアシストシステムの展望	143
8.2	実験システムの構成	164
8.3	HRP Interface Board 07-0003-1 (有) 図工製	164
8.4	g.BSamp	166
8.5	g.GAMMAsys	167
8.6	国際 10-20 法	168
8.7	脳波ヘッドキャップ g.GAMMAcap ² (g.tec)	168
8.8	EMG アンブ Bagnoli Desktop EMG System (Delsys, inc.)	169

8.9 ロボットアーム 171

第1章 緒論

1.1 研究背景

現在，日本では急速に少子高齢化が進んでおり，2050年には人口の約40%の人が高齢者になることが予測されている [1]．また，厚生労働省の5年ごとの調査によると平成23年の身体障害者数は386万人で，50人に1人が体に障害を持っている．そのため，自立行動が出来ない人の増加とそれに伴う介護者への負担が大きくなる問題がある．したがって，これらの問題を解決するために，医療・福祉機器の開発が急務となっている．そこで近年，人の生体信号を利用した機器が注目されており，様々な機器が開発されてきている．その中の一つに介護者の負担の軽減や筋力の弱った人へのサポートとして開発されている表面筋電位 (sEMG: surface electromyography) を用いたパワーアシスト装置が挙げられる [2]．これは人が筋力を発揮するために発生させる sEMG の大きさに応じた力を機械が発揮し，人の負担を減らすものである．介護者が装着することで介助動作の肉体的負担を軽減し，介護者の体の故障防止や作業の効率化を図るために，現在は介護現場への導入が進められている．また，パワーアシスト装置を被介護者自身が装着することで，衰えた運動能力を補うことも可能であり，自立支援やリハビリテーションの現場にも用いられている．

これまで外骨格ロボットのパワーアシストでは，力/トルクセンサや筋電位センサで運動情報を読み取る手法が使われている [2]-[4]．これらのセンサから読み取られた使用者の運動を増幅して出力することで，ボタンやジョイスティックなどのコントローラによる操作と比べて，より感覚的に外骨格ロボットを操作することが出来る．しかし，片まひ患者などの体の一部または全身の運動が出来ない重度障

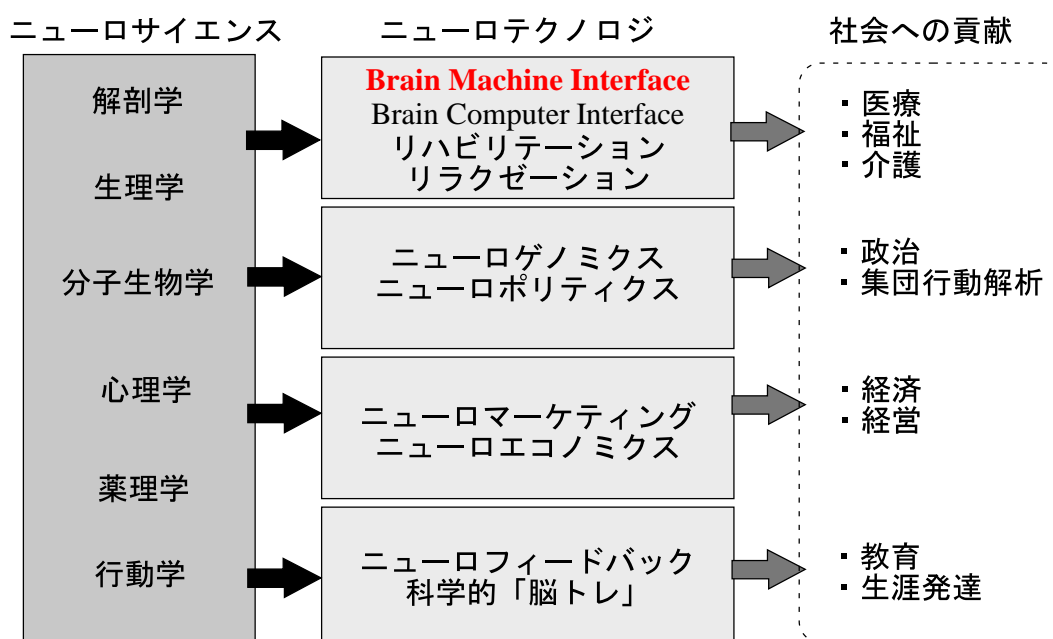


図 1.1: 発展するニューロサイエンスの分野と Brain Machine Interface の社会貢献 [5]

患者たちでは、これらのセンサを使用して外骨格ロボットを使用することが出来ない。そこで、人の脳から運動情報を抽出してその推定を行うことにより、重度障害者でも外骨格ロボットを自分の意思で動かすことができ、QoL (Quality of Life) の向上に繋がると考えられる。このような脳情報を活用した外部機器を操作する技術は BMI (Brain-machine Interface) と呼ばれ、重度障害者の支援技術として近年注目されている。

医工学分野において、計測機器やその周辺機器の発達による脳科学の飛躍的な発展と共に、脳情報を活用して機械を操作する BMI が近年研究・開発が進められている。BMI は基礎的な脳科学である「脳を理解する」ためのニューロサイエンス (Neuroscience) から発展した「脳を活用する」ためのニューロテクノロジー (Neurotechnology) の分野である (図 1.1)。このニューサイエンスは生理学や心理学などの基礎学問分野の融合領域であるが、ニューロテクノロジーはそれを社会に結び付ける役割を持っている。特に BMI は、人間の司令塔である脳と機械をつなげる技術であり、医療介護福祉分野への貢献に期待されている。

1.2 目的

本研究では、これまで外骨格ロボットに使用されてきた sEMG の代わりに障害者の脳波を用いた BMI 外骨格パワーアシスト装置を開発することが目的であり、障害者自らその装置を制御し、日常生活の補助を目指す。そのために、まず運動に関する脳活動の解析を行い、外骨格ロボットを動かすための特徴量を算出する。そして、得られた特徴量を用いて、運動とその特徴量と関係をモデル化し、外骨格ロボットの制御信号を生成することで BMI パワーアシストシステムの構築を行う。

1.3 本文の構成

本論文の構成を図 1.2 に示す。第 2 章では関連研究として、BMI のこれまでの研究の流れ、そして、BMI によるロボットの操作手法についての分析、脳波による運動判別器の生成手法および運動モデルの生成に関する研究について述べる。第 3 章では、脳活動の計測手法をまとめると共に、脳波・sEMG の計測手法および脳波の周波数領域での解析手法を解説する。そして、第 4 章では運動および運動想起に関する脳波の特徴量を解析し、第 5 章で運動および運動想起の線形判別を行いその結果を示す。次に第 6 章で主成分分析による線形モデルの生成手法を構築し、運動時の脳波を用いて sEMG 振幅（筋活動）の推定を行う。第 7 章では、運動および運動想起に関する脳波の新たな特徴量として、周期パワースペクトルの観点で解析を行い、第 6 章で用いた主成分分析による線形モデル手法による脳波周期パワースペクトル-関節トルクモデルを生成し、関節トルクの推定を行い、ロボットアームの操作を実現する。最後に、第 8 章にて、まとめを行い、今後の展望について述べる。

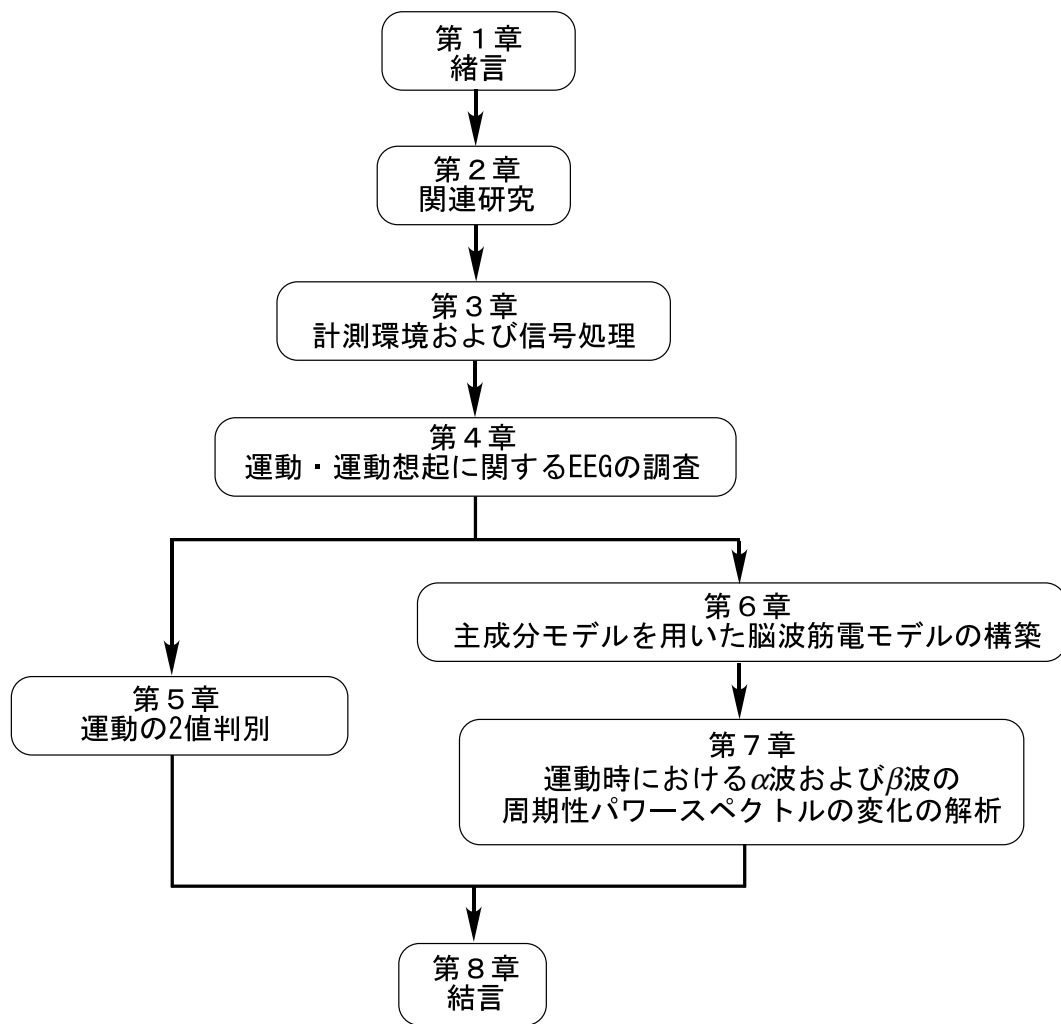


図 1.2: 本論文の構成

第2章 関連研究

脳は感覚神経から情報を読み取り、処理、そして運動神経を介して筋肉を動かしている。そして、BMIは脳で処理された時に発生する神経活動を入力信号とし、機器へ出力する装置である。脳情報を用いたBMIにより、これまで体が動かすことが出来なくなった障害者がコンピュータの操作、電動車いすの制御、外骨格ロボットによる動作再現を行うことで、ユーザーが本人の意思で行動することができ、QOL (Quality of Life) を向上させることが出来るようになった。本章では、これまでの侵襲型BMIおよび非侵襲型BMIの関連研究と、これまで使用されてきた脳情報の信号処理について紹介し、それらの問題の提示と本研究の概要について述べる。

2.1 Brain Machine Interface

Brain Machine Interface (BMI) は Brain Computer Interface (BCI) と呼ばれるが、そこに明確な区別はないため本論文では総じてBMIと呼ぶこととする。BMIは脳内活動を取得する方法によって、主に二つに分類される。一つは脳内に電極を埋め込み、神経活動を直接取得する侵襲型BMIと、もう一つは脳の外部から脳内活動の変化を観察する非侵襲型BMIがある。以下にこれらについて述べる。

2.1.1 侵襲型BMI

侵襲型BMIは脳に細い電極を多数刺し、多数の神経細胞の活動を観測し、機械制御信号に変換し、ロボットなどを動かす技術である。多数のニューロン活動を直接的に取得することができるため精密性が高い。そして、ほぼリアルタイムで

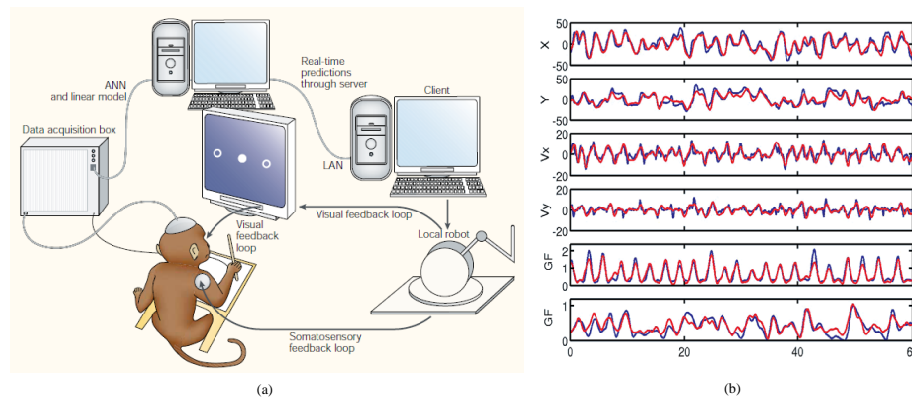


図 2.1: (a) 閉ループ制御のブレインマシンインターフェースをテストするマカケザルのモータ制御 [8], (b) 手の位置 (x, y) と速度 (V_x, V_y) および把持力 (GF) の実際の出力 (青色) と線形モデルから得られた予測 (赤線) [7]

検出できるため動作の自由度が高いロボットを高精度に操作するのに適している。まず、侵襲型 BMI はラットやサルなどの動物での研究が進められている。ラットによるレバー操作時の脳に差し込まれた電極から得られた信号をスイッチとして水を供給したところ、ラットが脳活動だけでのレバー操作を覚えたことから始まる [6]。デューク大学の Nicolelis らは、ヨザルの脳の一次運動野に約 100 個のニューロンを同時に測定できるワイヤ電極を埋め込み、マルチニューロン記録システムを用いた BMI の開発を行った [7]。そして、ヨザルの多数ニューロンの活動から、手の動きを予測し、ロボットアームの 3 次元動作を制御する信号に変換することが出来た [8][9]。さらに、一次運動野だけでなく頭頂連合野や運動前野からも多数のニューロン活動を同時記録することで、腕の動作をより正確にロボットアームで再現出来ることを証明した [10]。

まず、ヨザルが手を伸ばしてフルーツ片をつかみ、口元に運ぶ際の手首の動きをセンサで計測し、一次運動野のニューロン活動と対応させ解析を行った [8][9]。そして、多数ニューロンの活動を単純に線形加算すると、手の動きを数 100msec 前に高精度に予測できることが分かった。そこで、多数のニューロン活動をリアルタイムに検出するインターフェースを組み込むことことで、50 ~ 100msec 単位で



図 2.2: ヒトでの侵襲型 BMI[11]




図 2.3: ブラウン大学での研究 [14]

マルチニューロン活動を積分し、それをロボットアームの3次元動作を制御する信号に変換するようにした。そして、ヨザルが目の前にあるスクリーン上の左右のランプ点灯に合わせ、ジョイスティックを手で左右に動かしている時、運動野の多数ニューロンの活動でロボットアームを制御したところ、ロボットアームはヨザルの腕と同じ動作をした。さらに、一次運動野だけでなく頭頂連合野や運動前野からも多数のニューロン活動を同時記録することで、腕の動作をより正確にロボットアームで再現出来ることを証明した [10]。また、図 2.1 ではこの実験においてよく訓練されたサルの場合、実際に得られた手の位置、速度、把持力、sEMG 振幅は線形モデルから高い精度で予測することが可能であることが示されている。

次に、人の侵襲型 BMI が応用された例として、頸部損傷により首から下部が麻

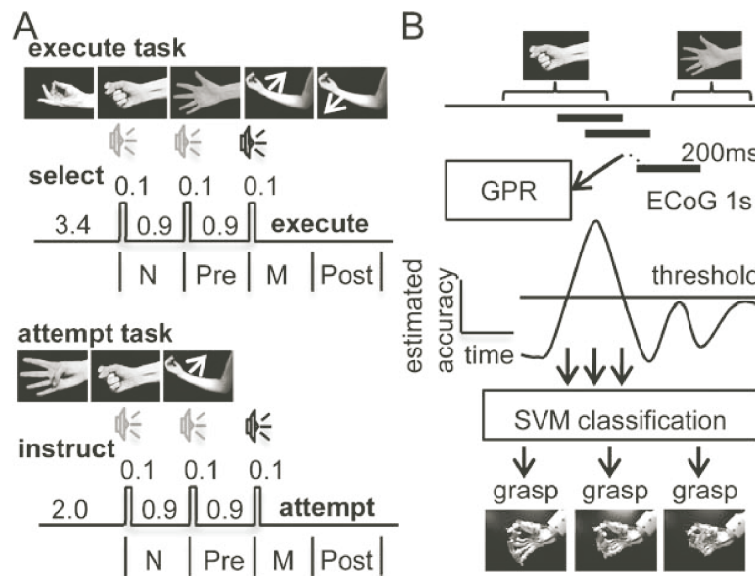


図 2.4: 手の動作の機械学習 [16]

痺した被験者（C4 レベル脊損患者）の脳皮質第一次運動野に多重電極を埋め込み、十数時間の訓練を行うことにより、コンピュータのカーソルを動かす、かつ、マウスのクリック動作を侵襲型 BMI を介して行うことが出来た [11]-[13]。さらに、2012 年に発表されたブラウン大学の Donoghue らの研究では、人の脳に刺した電極からニューロンの活動を読み取り、手の速度と開閉の状態を推定している [14]。これにより、ロボットアームの移動と把持動作が可能となり、図 2.3 に示すようにヒトの脳神経活動を用いて、ロボットアームで水筒を掴んで水を飲むことに成功している。

Nicolelis らの研究では実験対象として、ヨザルを用いている。この理由としてヨザルの脳の運動皮質には皺が滑らかであり、多数のワイヤを並べ同じ深さに埋め込みやすいためである。しかし、ヒトなどの知能が発達した動物では、実際には皺が多くあり、狙ったところに電極を埋め込むのは難しいことが問題となる。したがって、多くの被験者の実験データを取ることは難しくなる。また、侵襲型 BMI は神経活動の記録電極を埋め込む必要があるため、手術や感染のリスクが高いという問題がある。

それら刺入電極に対して、長期間の臨床使用実績のある脳の表面に電極を置く

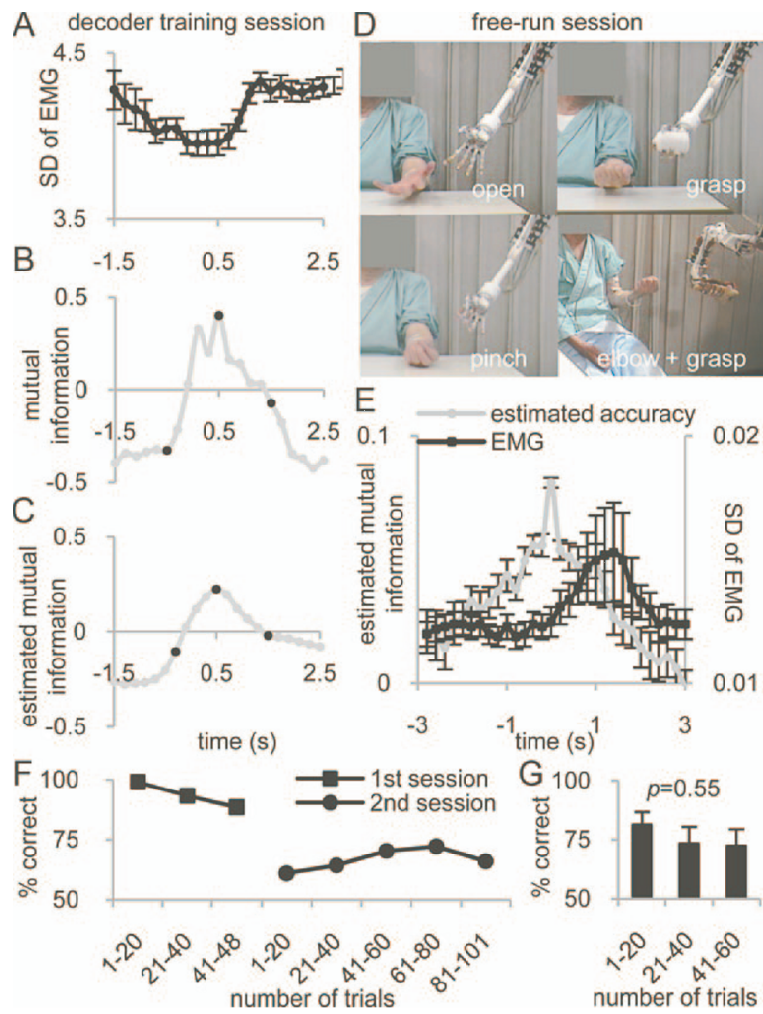


図 2.5: ECoG を用いた侵襲型 BMI におけるロボットアーム動作 [16]

硬膜下電極で皮質脳波を記録する ECoG (Electrocorticographic) を用いた低侵襲型 BMI の開発が試みられている [15]-[19] . 大阪大学の吉峰らは難治性の神経因性疼痛に対する運動野電気刺激療法を行う患者に、いくつかの運動課題を行ってもらい、その時の ECoG を記録した . その時の ECoG と運動課題との関連を SVM (Support Vector Machine) と呼ばれる機械学習アルゴリズムを用いることにより、手の状態と肘の屈曲伸展動作の種類を弁別出来た (図 2.4) . 吉峰らはこの BMI を用いて、ECoG の情報のみで運動課題をロボットアームで模倣することが出来た (図 2.5) .

侵襲型 BMI は高精度で安定した脳内情報を取得することが可能であるが、電極を埋め込む手術をする必要があり、BMI 使用者への負担やリスクが大きいという問題がある . また、ECoG は、日常臨床に取り入れられており手術技法が容易で、臨床実績により長期的安全性が保障されている . しかし、短所として手術が必要であることと、電極を埋め込むため、ワイヤレス通信を長期的に行うための電源確保する必要がある [20] . それに対して、そのリスクがほとんどない非侵襲型 BMI の研究が進められており、次に非侵襲型 BMI について述べる .

2.1.2 非侵襲型 BMI

非侵襲型 BMI は脳内の活動を頭皮の外側から観測し、その活動を検出してインターフェースに入れ機械制御信号に変換し、ロボットなどを動かす方式である . 非侵襲型 BMI の場合、電極などを埋め込む手術を必要としないため、電気刺激療法などを必要とする身体障害者の脳内活動だけではなく、健常者でも脳内活動を計測することが可能である . また、その計測方法は様々あり、PET (ポジトロン断層撮影法: Positron Emission Tomography), fMRI (機能的核磁共鳴イメージング法: functional Magnetic Resonance Imaging), MEG (脳磁図: Magneto Encephalography), EEG (脳波: Electro Encephalography) が現在非侵襲的方法として認められている計測法である . その中で EEG は大規模な装置が必要なく、比較的計測しやすい計測手法である . EEG は、頭皮の上に電極を乗せ、脳内の多数のニューロン活動による計測部位の電位変動を計測するもので、電極の着脱は容易で、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

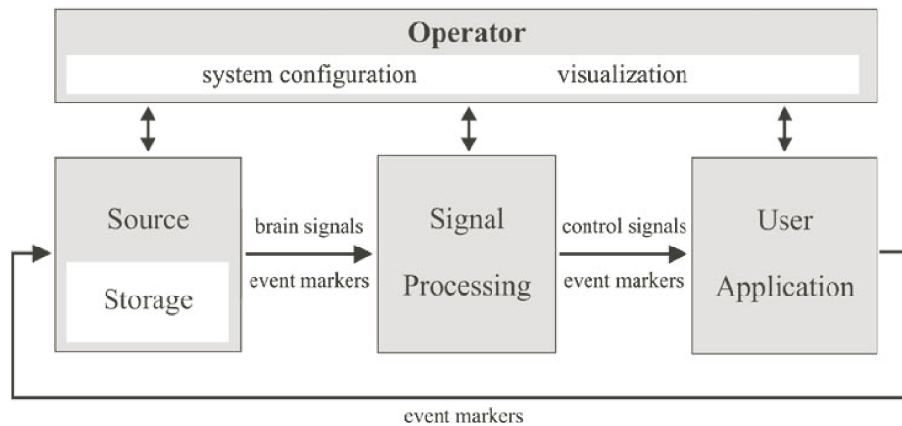


図 2.6: BCI2000 の概要 [28]

号を取得する方法は電位変動を増幅するだけなので小規模で、かつ安価に脳内活動を計測することが可能である。そのため、EEG を用いた非侵襲型 BMI は多くの研究がなされている [5]。

非侵襲型 BMI による操作機器

まず、コンピュータを操作する非侵襲型 BMI の開発が進められ、点滅する文字を使用者が見た時に発生する P300 と呼ばれる事象関連電位を利用して脳波キーボード [21]-[23] や運動想起時に生じる運動感覚電位 (sensorimotor rhythm: SMR) を用いてカーソルをコントロールする手法 [24]-[27] が提案された。そして、これらの技術を用いて Wolpaw らは BMI システムの開発ツールとして BCI2000 の開発を行った [28] (図 2.6)。BCI2000 は BCI2000 プロジェクトでニューヨーク州 Wadsworth Center が行っている BCI の研究・開発プログラムの一環で、その中で開発された汎用 BMI 構築のためのソフトウェアプラットフォームである。このシステムには BMI 設計に必要な基本的な機能 (脳波の所得、信号処理、ユーザへの出力など) が用意されており、Wolpaw らはこのシステムを用いて、カーソルのコントロールや、簡単なスペルを選択するアプリケーション、2 択の選択、キーボードの操作などのコンピュータを操作する BMI を開発した (図 2.7)。

次に、この非侵襲型 BMI の技術は日常生活を支援する研究が進められており、

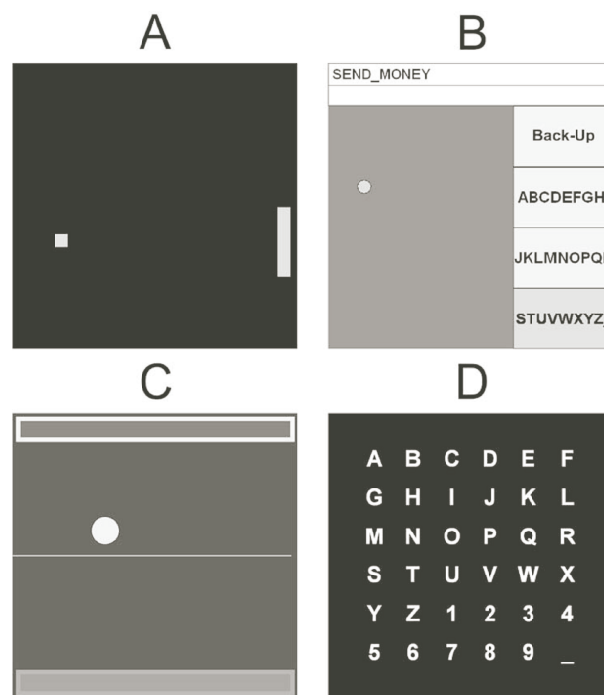


図 2.7: BCI2000 を用いた BCI (A : 運動関連電位を用いた変数の選択, B : 簡単なスペルの選択, C : 2 値の選択, D : P300 を用いた文字選択) [28]

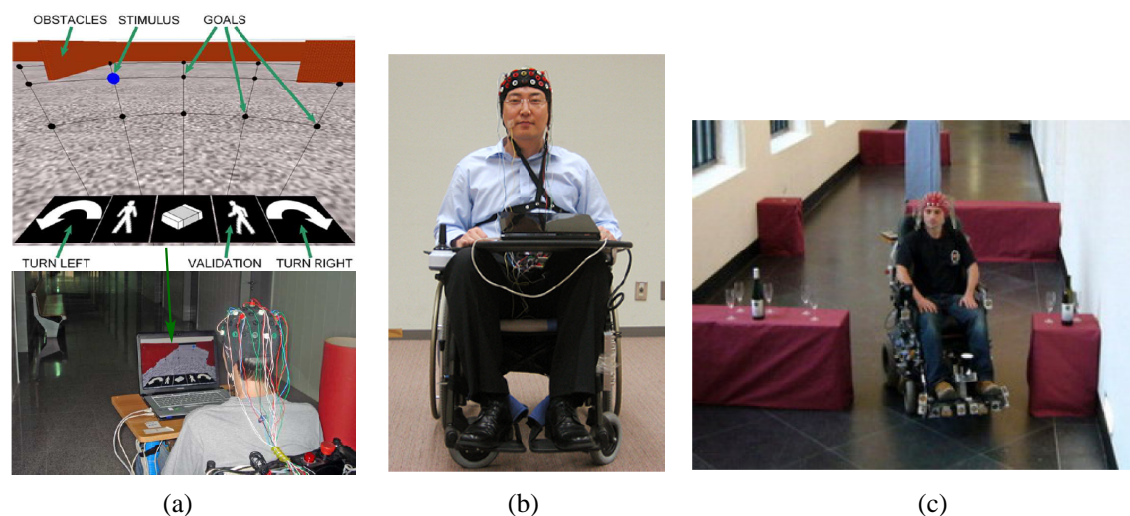


図 2.8: (a) 注目した方向に移動する脳波車いす [29], (b) 運動想起で操作する電動車いす [30], (c) レーザーレンジファインダと組み合わせた脳波車いす [31]

電動車いすを脳波を用いて操作し、全身まひ患者でも自分で移動することが可能となった。図 2.8.(a) はモニターから使用者に進行方向を示した誘発脳波を発生させる刺激を送り、注目した方向に移動する脳波車いす [29] であり、図 2.8.(b) は左右の手と足の運動を想起した時の脳波を用いて電動車いすを操作するものである [30]。また、図 2.8.(c) では脳波から左手の運動、言葉の連想、安静を判別し、判別された状態を車いすの左折、右折、前進の指令とし、レーザーレンジファインダで環境を観測し進行方向の補正を行う動作環境と組み合わせた手法が提案された [31][32]。

そして、非侵襲型 BMI を用いてロボットアームや外骨格ロボットを操作する研究が行われている。まず、下肢の外骨格ロボットでは、脳波から抽出した歩行意図（前進、旋回）を入力信号として、そのパターン動作を行う Houston 大学の NeuroRex (図 2.9.(a)) [33] や Nicoletis らの Walk Again Project [34] で作成された外骨格ロボット (図 2.9.(b)) がある。これまで下肢のまひにより車いすでの生活をしてきた障害者が下肢の外骨格ロボットを用いることにより、再び歩行を行うことが出来るようになる。

次に、上肢の外骨格では、国立障害者リハビリテーションセンターの神作らの

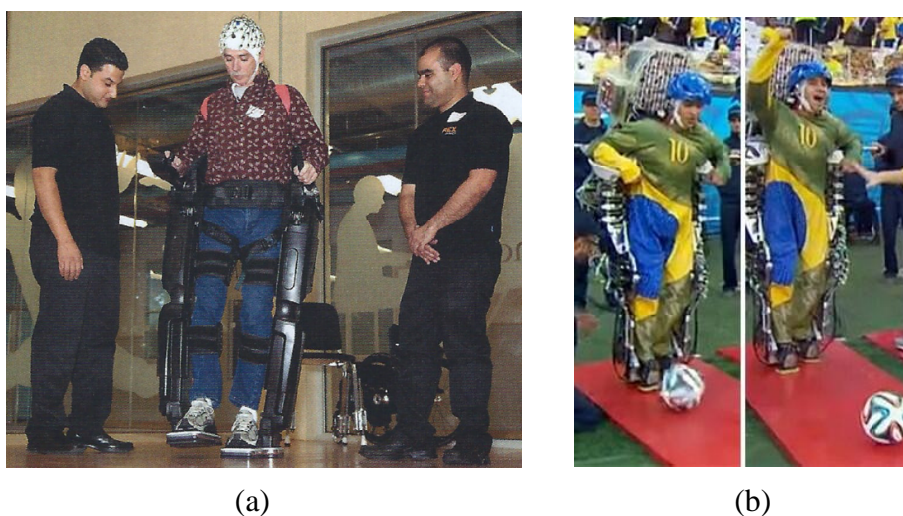


図 2.9: (a)NeuroRex[33] , (b)Walk Again Project[34] による World Cup 2014 のキックオフのデモンストレーション

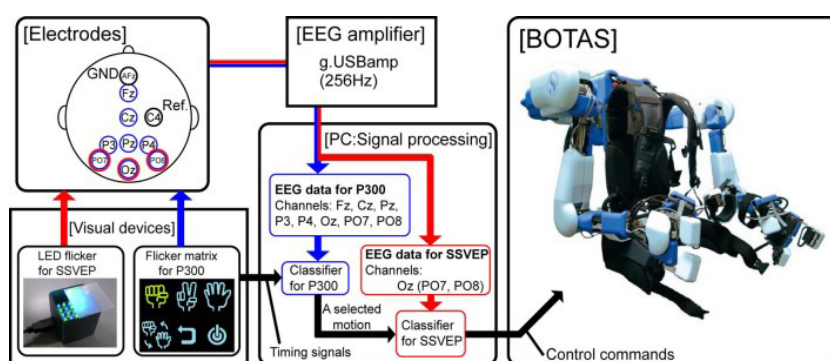


図 2.10: BOTAS の概要図

研究では、健常者と障害者の脳波を用いて装着型多自由度ロボットアーム（BMI-based occupational therapy assist suit:BOTAS）の制御に成功している [35] . この研究では、光の点滅を刺激として与えた時に視覚野周辺に発生する P300 と定常状態視覚誘発電位（Steady State Visual evoked potentials : SSVEP）を用いてロボットアームの制御を行っている（図 2.10）. また、Houston 大学の MAHI-Exo-II では、運動想起による腕部外骨格ロボットの操作によるリハビリテーションを行っている [36] .

このように、非侵襲型 BMI はコンピュータの操作から始まり、外骨格ロボットを装着して動かすことが困難であったまひ部位を動かすことが出来るようになった




図 2.11: MAHI-Exo-II による脳波を用いた腕の操作 [36]

た．そして，非侵襲型 BMI を用いて失われた脳から運動までの神経経路を再構築するリハビリテーションの手法も提案された．これまで外骨格ロボットは力/トルクセンサや表面筋電位センサによるパワーアシスト装置として開発されてきた．その入力信号を脳情報から得ることで，日常動作の支援だけでなくリハビリテーションにも応用することが出来る．しかし，脳波による外骨格ロボットでのパワーアシスト技術はまだ報告されていない．

2.1.3 脳活動からの特徴抽出

このような BMI で機械を動かすために脳情報から特徴を抽出し，制御信号を生成する必要がある．そこで，脳情報の変化は脳内の複雑なニューロン活動によってもたらされ，その中から特徴的な変化を探す手法が提案されている．その手法は主に，複数個の脳活動のパターンを抽出して使用者の意図を判別を行う手法と，脳活動と動作をモデル化し使用者の動作を再構築する手法の二つがある．判別を行う手法では，キーボードや車いすの操作などパターン化しやすい動作に用いられており，ヒトが運動したり，運動をイメージした際に，脳の運動感覚野において，7-15Hz の α 波の中にある μ 律動 (8-13Hz) や，15-30Hz の β 波と呼ばれる脳波の変化が見られ [37][38]，それらの脳波が判別する方法として，様々な手法が提案

されている [39]-[41] .

線形判別手法

まず、線形判別手法である特徴量の変化に閾値を設定し、2 値化処理を行う手法 [42] や、多次元特徴量に対してその境界となる直線を作成し、判別器とする線形判別分析 (LDA: Liner Discrimination Analysis)[43][44] がある。これらの手法は生成アルゴリズムが非常にシンプルで扱いやすいため、多くの BMI 研究の判別器として多く使用されてきた [39]。しかし、これらの手法は EEG などの非線形に変化する信号では、正確なパラメータの調整が必要であり、また、ノイズに弱いという問題がある。そこで、その生体信号の特徴量を非線形な手法で判別することが行われている。

非線形判別手法

次に、その非線形な手法では SVM (Support Vector Machine)[45][46] や NN (Neural Network)[48][49] などが BMI 研究で取り入れられている。SVM は各特徴量に存在するの多くの境界面から、もっともよい境界面を選択する手法で、NN は脳の神経網を模した数学アルゴリズムで、学習によって適切なニューロン網を形成しデータの判別を行う手法である [39]。これらの非線形判別手法は、各特徴量を高次元に変換することにより、非線形な生体信号に対して線形判別手法より高い判別能力を持つことが出来る [49]。しかし、これらの手法は特徴を高次元に変換するため、その生体信号の解析や評価が困難になってしまう問題がある。その信号の評価の観点から、統計的な手法を用いるものがあり、その一つにマハラノビスの汎距離がある [50]。マハラノビスの汎距離はいくつかの集合に対して、どの集合に最も近いものかを判別することができ、かつ、異なる特徴の変化に対応することが出来る評価指標である。この指標を用いることにより、ノイズの多い生体信号の特徴量の中から運動に関連する EEG の判別を行うことが出来る。しかし、このマハラノビスの汎距離を用いた BMI はまだ少ない [39]。




図 2.12: 屈曲伸展動作の実験装置 [51]

脳波から運動情報の推定

そして、脳波から運動情報を再構成することで、人の動作に適したロボットアームの操作を行おうとする研究では、東京工業大学の小池らは、脳波から fMRI の情報を利用して脳信号源を推定し、推定された脳の信号源信号から筋活動の再構築に成功している [51]。小池らは、侵襲型の計測と同様の空間分解能を脳波に持たせることが可能であれば、脳波から sEMG 振幅が再構成することができると考え、fMRI の情報を利用した。

この実験では、運動タスクを強い運動と弱い運動に分けており、図 2.12 に示す実験器具を用いて腕を固定し、手首の屈曲と伸展を行った際の、屈筋と伸筋の計測をしている。この実験の処理の概要を図 2.13 に示す。

まず、脳波から脳皮質上の信号を、fMRI による脳活動の位置情報と MRI による個人の脳構造モデルを事前情報としたベイズ推定を用いることで推定している。次に、推定された脳信号源信号をスパース回帰モデルを用いて、計測点ごとに重みを付けて統合することで、sEMG 振幅（筋活動）の再構成を行っている。また、結果では、直接脳波から sEMG 振幅を推定する場合と、脳信号源信号を推定する際に fMRI の事前情報を用いる場合と用いない場合の 3 つを比較している。この評価には計測された筋電と再構成された筋電の間の決定係数が用いられた。その結

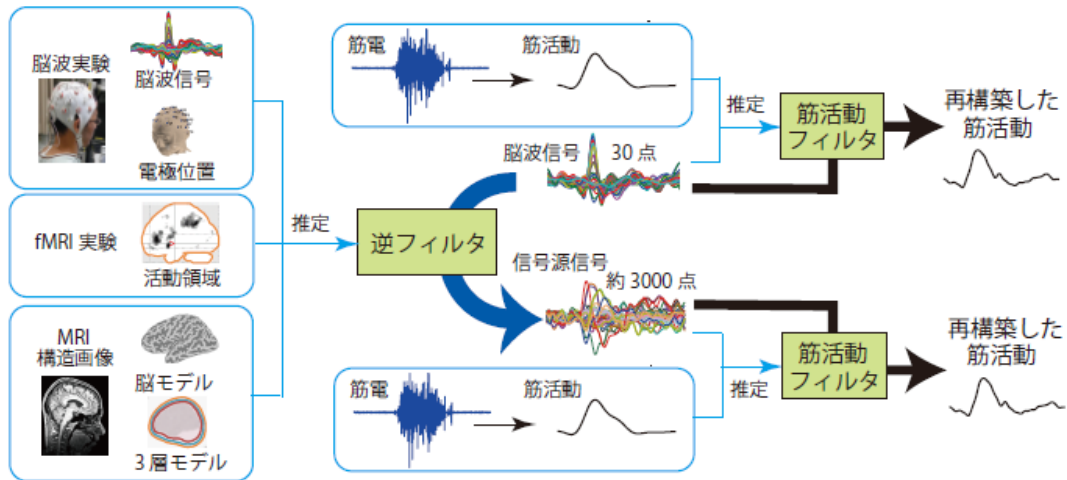


図 2.13: MRI・fMRI・脳波による筋活動の再構成の処理概要 [51]

果，脳信号源信号を推定する際に fMRI の事前情報を用いる場合が最も精度が高く，脳波から直接推定した場合が最も低い結果となっている。

小池らの研究と同様に，脳波から筋電を再構成しようと試みている研究は国外でも行われている．アメリカのライス大学の Mally らを中心とした複数の大学が参加している研究グループでは，脳波の 波と呼ばれる周波数帯域の信号を用いて，ロボットアームの制御を行い，リハビリテーションに応用を開始している．

参加大学のひとつであるメリーランド大学が 2010 年に発表した研究では，脳波から腕の 3 次元の速度を再構成することに成功している [52]．この実験では，図 2.15 に示す装置を用いて指の位置変化を計測しており，同時に脳波の計測を 10-20 法に基づいて 55ヶ所から行っている．この計測された脳波には前処理として，カットオフ周波数が 1Hz のローパスフィルタに通された後に標準化が行われている．そして，この信号に対してセンサ間に重みを付けて加算し，さらに過去のデータを加えることで指の 3 次元の移動速度を再構成している．

また，電極間の重みは多重回帰分析により算出されており，さらに，この重みを用いて各センサの寄与度を脳画像にマッピングすることで賦活領域の特定も行われている．この手法によって再構成された腕の速度と実際に計測された腕の速度は相関係数により評価されており，最大で約 0.5 となっている（図 2.16）．また，




図 2.14: 筋電再構成結果 [51]




図 2.15: 指の位置・速度を計測する実験
機器

図 2.16: 脳の賦活領域

マッピングにより、この実験で行われた動作では、移動させた腕と対側の運動野上にある CP3 が最も賦活することが明らかにされている（図 2.17）。

さらに、ヒューストン大学の同研究チームでは、メリーランド大学の研究結果を基に、腕の屈曲時の脳波から筋電を再構築した [53]。この研究では、図 2.18 に示す実験装置を用いており、図 2.18 A のロボットハンドで物体を掴むと、その力を図 2.18 B の外骨格がフィードバックする仕組みになっている。この実験では 4 つのタスクが設計されており、外骨格は全てのタスクで左腕に装着されている。タスク 1 とタスク 2 では、ロボットハンドと外骨格が同じ側に装着されており、タスク 3 とタスク 4 では、対側に取り付けられている。これらのタスクの中で、タ

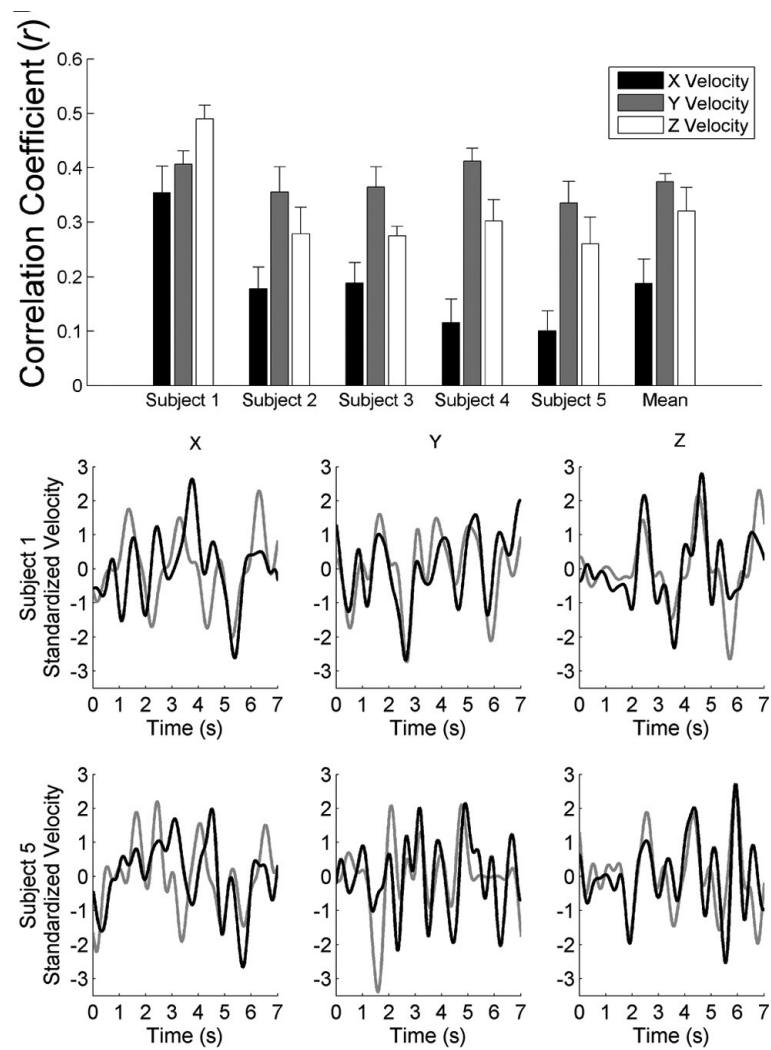


図 2.17: 速度の再構成結果




図 2.18: 実験装置

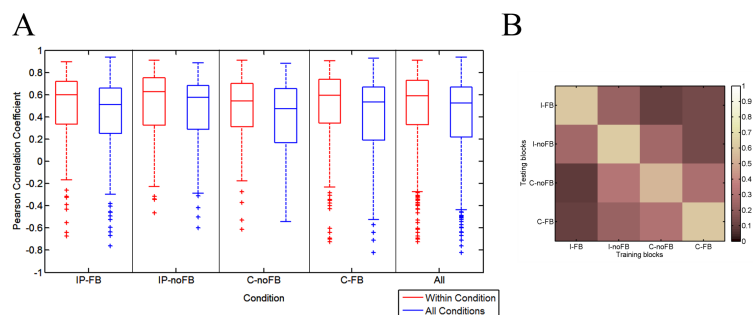


図 2.19: タスクごとの結果

スク 1 とタスク 4 では把持力のフィードバックを行っている．脳波から筋電を再構成する式は，各タスクごとに訓練され，同一のタスクのデータに使用した場合と，異なるタスクに使用した場合，また，全てのタスクで訓練した式を各タスクに使用した場合で評価している．評価には，計測 sEMG 振幅と推定 sEMG 振幅の相関係数で行っている．

この実験の結果を図 2.19 に示す．図 2.19 A は，タスクごとの相関係数のばらつきを表しており，赤が同じタスクで訓練した式を使用した場合，青が全てのタスクで訓練した場合の結果である．この結果を見ると，タスク間の再構成精度には差がなく，中央値は 0.6 前後となり，最大で 0.9 前後であることが分かる．また，図 2.19 B は異なるタスクで訓練を使用した場合の結果で，同一タスク以外に訓練データを用いると，再構成の精度が悪くなることが示されている．

2.2 問題提起および本研究の概要

BMIにより脳情報で機器を制御する研究は、侵襲型では10年以上前から行われている。侵襲型BMIの推定手法では、ニューロンの活動から線形モデルと学習を用いて、腕の速度や、筋電を再構成することで、人の動作をロボットアームに模倣させることが可能となっている。しかし、侵襲型は手術の必要があり、使用者の負担が大きいため、健常者を対象とすることが難しい。

また、非侵襲型においても、人の動作を支援する手法が徐々に増加している。事象関連脱同期や事象関連電位等を用いる手法によってロボットを制御する場合、あらかじめ決めた動作をパターン化し、特徴の判別をして制御を行うため、連続的な制御が出来ず、使用者の行う動作をロボットアームに模倣させるのは困難だと言える。近年の研究では、侵襲型のように脳活動から線形的なモデルを作り、学習することで、運動情報を推測する方法が非侵襲型にも取り入れられており、脳波から運動情報を推測することに成功している。しかし、現在の研究では、この手法を用いて多自由度のロボットアームを制御したパワーアシストの研究はなく、その可能性も示されていない。


そこで本研究では、外骨格ロボットを制御するBMIシステム構築し、健常者および身体障害者の運動のアシストを行うBMIを開発することを目的とする。そのために、本論文ではまず運動に関する脳波についての特徴量を選択し、複数のタスクを行った時の脳波の解析を行う。そして、得られた特徴における線形的な集合をマハラノビスの汎距離による判別器を生成し、その性質を捉えると共に、脳波から運動を判別を行う。また、ロボットアームを操作する制御信号を生成するために脳波 - 筋電間の線形のモデルを作成し、逐次学習に加え、パワーアシスト理論を導入することで脳波から筋電を推定する。さらに、その線形モデルをより良くするために、脳波の α 波および β 波のパワースペクトルの周期的変化に着目した人の関節トルクと線形関係のある特徴量を抽出する手法を提案し、脳波から人の関節トルクを推定する線形モデルの生成について述べる。

第3章 計測環境および信号処理

3.1 脳活動の計測の仕方

脳はブロードマンの脳地図(図3.1)に示されるように,脳機能局在論(Theory of localization of brain function)[54]により,脳の部位ごとに機能を担っている事が分かっており,各部位の相互作用によって脳が働き,運動を形成する.このように,脳は一つのタスクに対し,局所ごとの連携し,脳全体が活動し実行している.したがって,BMIを構築する際には,脳で考えた意思決定・運動計画を実行に移す運動野・補足運動野の脳活動を計測する事により,運動に関連する脳情報を抽出する事が出来る.

脳の活動を計測する手法として,侵襲型,低侵襲型,非侵襲型の三つに分けられる.まず,侵襲型の脳活動の計測手法では,脳内に針状の電極を差し込み(図3.2.(a)),シナプスのパルス状の電位変化を見る手法がある.脳の電気活動には興奮性シナプス活動,抑制性シナプス活動,グリア細胞活動などがあり,侵襲型の計測方法ではこれらの信号を直接得ることが出来る.侵襲型のBMIでは,ラットの実験から始まり,ラットが給水ボタンを脳活動によって操作する事に成功している[6].続いて,サルによるロボットアームの操作を実現しており[7]-[10],人では四肢まひ患者に運動野に電極を挿入し(図3.2),カーソルの操作やロボットアームの操作に成功した[11]-[13].侵襲型の計測方法では,直接シナプス活動を計測出来ることから,計測精度の精度が高い利点を持つが,脳に電極を差し込むため,局所的な部位の脳活動しか捉えることが出来ない.また,電極で捉えられるスパイク活動は,計測されるシナプス活動が日々変わるため,そのたびに調節を必要とし,長期になると計測率が低下するなどの問題がある.



© CSLS University of Tokyo

図 3.1: 脳機能局在論に基づいたブロードマンの脳地図 (東京大学 生命科学構造化センター / 生命科学ネットワークより)

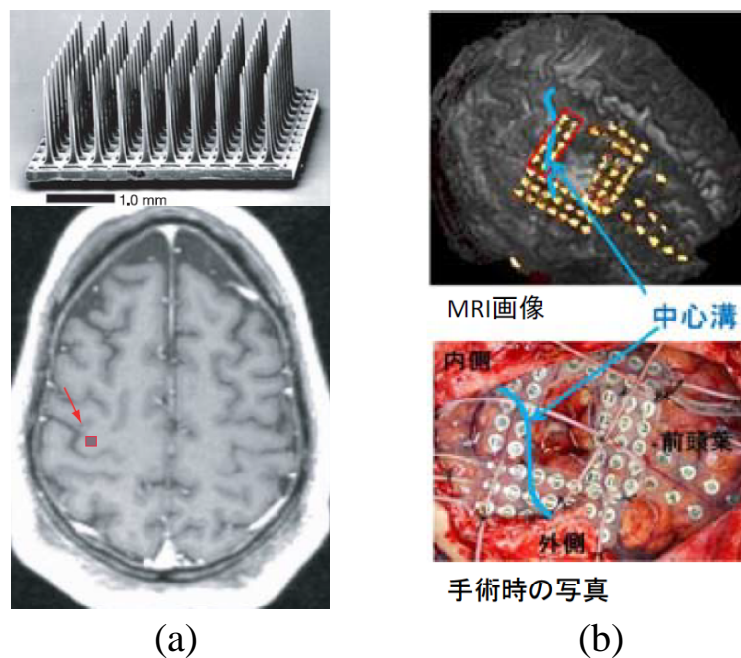


図 3.2: (a) 人の運動野に用いられる針電極 [11], (b) Electrocorticogram (ECoG) [17]

次に、低侵襲型の計測方法では、脳表面に電極を張り、計測を行う硬膜下皮質表面電位 (Electrocorticogram: ECoG) がある (図 3.2.(b))。脳表面にシール状の電極を張り、2 点間の電位差を取ることにより、脳活動を観測する手法で、侵襲型に比べて分解能は落ちる。しかし、脳活動を計測箇所が近い複数点の信号を組み合わせることにより、脳活動の複合化を可能としている。また、脳を傷つける事なく多くの電極を脳表面に張ることが出来る。これらのことから ECoG は、時間分解能と空間分解能に優れており、じゃんけん動作 (グー、チョキ、パー) の識別やロボットアーム操作を実現している [19]。しかし、低侵襲型は侵襲型と同様に、電極を取り付けるための手術が必要であり、使用者の対象が限られてしまう。

最後に、非侵襲型では、その計測方法は様々あり、第 2 章に述べたようにポジトロン断層撮影法 (Positron Emission Tomography: PET)、機能的核磁共鳴イメージング法 (functional Magnetic Resonance Imaging: fMRI)、脳磁図 (Magneto Encephalography: MEG)、近赤外分光法 (Near Infra- Red Spectoroscopy: NIRS)、脳波 (ElectroEncephalography: EEG) が現在非侵襲的方法として認められている。

非侵襲型は、上記の侵襲型・低侵襲型と比べて使用者を限定せずに、体を傷つける事なく脳活動を観測することが出来る。まず、PET は、体内に取り込まれた放射性医薬品が体内で蓄積または沈殿して放出する放射性同位元素の γ 線を体外から検出し、画像化する手法である (図 3.3.(a))。脳内で活性化した部位で代謝量や血流量が増大することで、脳内の放射性同位元素が多くなり、脳のどの部位で活性化したのかを計測する事が出来る。次に、fMRI は強力な磁場を体に加えて、体内の水素原子の磁気的な性質を測定し、画像化する手法で、あらかじめ画像化した脳内画像と比較を行うことで、脳のどの部位が活性化したかを見ることが出来る (図 3.3.(b))。そして MEG では、神経活動に伴って電流が発生した際に電流が流れ、その電流によって発生する微小な磁場の観測を行い、MRI などであらかじめ計測した画像と組み合わせることにより、脳の活性部位を観測する事が出来る (図 3.3.(c))。これらの紹介した非侵襲型の計測方法のうちの PET・fMRI・MEG は、空間分解能が非常に優れており、脳の活動領域を正確に特定する事が出来る。




図 3.3: 大型非侵襲型脳活動計測機器，(a)PET，(b)fMRI，(c)Magneto Encephalo Graphy[56]

しかし，装置が非常に大型で一回の計測にかかるコストが非常に高く，日常生活を支援する BMI を構築するには難しい [55] ．

BMI を構築するためには，安全で比較的安価で，小型な計測手法が求められ，NIRS や脳波の小型化が進められてきている．NIRS は頭皮上から近赤外光を照射し，その反射光を計測する手法である（図 3.4.(a)）．血液成分のヘモグロビンは光を散乱されるが，それに結合している酸素の量によってその吸収・散乱の度合いが変化する．脳内の活性化すると共に酸素が消費され，酸化ヘモグロビンの量が減少し，そこに近赤外光を当て反射光の変化を観測する事で，脳の活性部位を推定する事が出来る．最後に，本研究で扱う脳波は，頭皮上に電極を装着し，侵襲型・低侵襲型と同様に 2 点間の電位差を計測する手法である（図 3.4.(b)）．発生源を取り囲む電導性生体組織（脳，脳髄液，血管，頭骨，頭皮）の外側から間接的に記録したもので，侵襲性が極めて低いが，多数の細胞の活動集合を記録しているという性質を持つ．

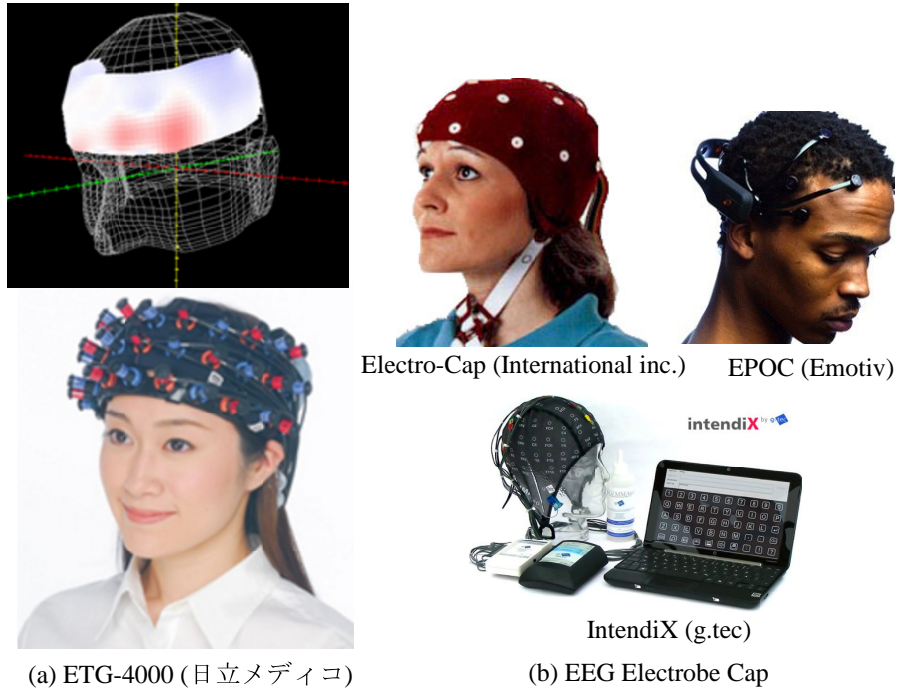


図 3.4: 小型非侵襲型脳活動計測機器, (a)NIRS, (b)脳波

表 3.1: 脳活動計測手法

	Invasive	Min-Invasive	Non-Invasive				
	針電極	ECoG	PET	fMRI	MEG	NIRS	EEG
計測される 信号の種類	シナプスの発火	電位変動	放射性同位 元素の変動	水素原子の 変動	神経活動の電流 による磁場変動	酸素ヘモグロビンの 変動	電位変動
大きさ	小	小	大	大	大	小	小
時間分解能							
空間分解能							
長期使用	×		×				
一回の計測に かかるコスト	低	低	高	高	高	低	低

脳活動計測手法について，表 3.1 にまとめる．計測される信号の種類としては主に，神経活動の電気的特性を計測するものと，その活動によって変動する分子や血液を計測するものがある．前者では常に神経活動が起こっておりその信号が複雑に変化している．神経活動の電気的特性では，動作に対してどのような変化があるのかを観測する必要がある．一方，後者では脳の脳機能局在論により，どの部位が活性化したのかを判断する事が出来る．しかし，分子や血流量が変化するまでの時間遅れがあるため，時間分解能が落ちるという問題がある．

日常的な支援を行う BMI を構築するためには，装置が小型でコストの低い長期的に計測が出来る手法が必要である．また，容易に着脱でき，安全に使用する事が出来る手法となると NIRS，もしくは脳波が適切であると考えられる．特に脳波は時間分解能に優れており，かつ大規模な装置が必要なく，比較的計測が容易な計測手法である．また，侵襲型や低侵襲型と比べて分解能は劣るものの，安全に電極の着脱は容易であり，信号を取得する方法は電位変動を増幅するだけなので小規模で，かつ安価に脳内活動を計測することが可能である．

3.2 脳波 (ElectroEncephaloGraphy: EEG)

脳波は，脳から生体組織通して，波形として現れ，その周波数の分類は表 3.2 のように徐波と速波に分けられ，さらに 6 つの周波数帯に分けられる．また，それとは別に脳波の発生事象として，外部の刺激によって発生する誘発脳波があり，図形が何らかの形で変化する光の刺激に発生する視覚誘発電位 (Visually Evoked Potential: VEP)，体感部の刺激に発生する体性感覚誘発電位 (Somatosensory Evoked Potential: SEP)，高周波の音や低周波の音の耳に対する刺激に発生する刺激を聴覚脳幹誘発電位 (Brainstem Auditory Evoked Potential: BAEP) などがある [57]．誘発脳波は，刺激に対する生理的な応答ではなく，その刺激を認識したかによって変化する．つまり，視覚や聴覚に刺激を与えるだけでは誘発脳波による変化は小さくなり，刺激を受けている人がその刺激の数を数えたり，予測する事によって

表 3.2: 周波数帯の分類

● 徐波	● 速波
δ 波 (帯) 0.5 ~ 3Hz	β 波 (帯) 15 ~ 30Hz
θ 波 (帯) 4 ~ 7Hz	γ 波 (帯) 30Hz 以上
α 波 (帯) 8 ~ 15Hz	

大きく変化するという特性をもっている．この特性から，誘発脳波はキーボードやアイコンの選択，電動車いすやロボットアームの先端部の進行方向の操作に用いられている．誘発脳波を用いると刺激に対する応答であるため，検出がしやすいというメリットがある．しかし，デメリットとして，刺激物に集中する必要あり，電動車いすやロボットアームの操作対象物以外の物を注目または集中しなければいけない．外骨格ロボットを操作する BMI を構築するためには，人の運動に関する脳波を検出する必要がある．

3.3 運動に関連する脳波

人は運動をする際，その運動を想像し，筋肉に命令を送り，目や皮膚感覚でその運動のフィードバックを行っている．そのフィードバックは，体性感覚感覚刺激，運動行動や運動想起によるもので，事象関連脱同期 (event-related desynchronization: ERD) や事象関連同期 (event related synchronization: ERS) として主に 8-30Hz の周波数帯域が脳波として現れる [58]-[61]．これらの ERD と ERS は主に α 波帯域に存在する μ 律動 (7-13Hz) と β 波の周波数帯域が関係している [62][63]．そして，運動に関連する感覚および認知の処理によりこれらの脳波の変化は複雑な時空間パターンを形成している．Pfurtscheller らは手首の運動感覚野の領域において，随意運動を行った際に少なくとも 3 つのタイプの脳波の変化があると述べている [60]．まず，運動前の 2.5 秒において 10-12Hz の μ 律動が，減衰する ERD を観測しており，数秒以内に復調していることが分かっている．一方，14-18Hz の β

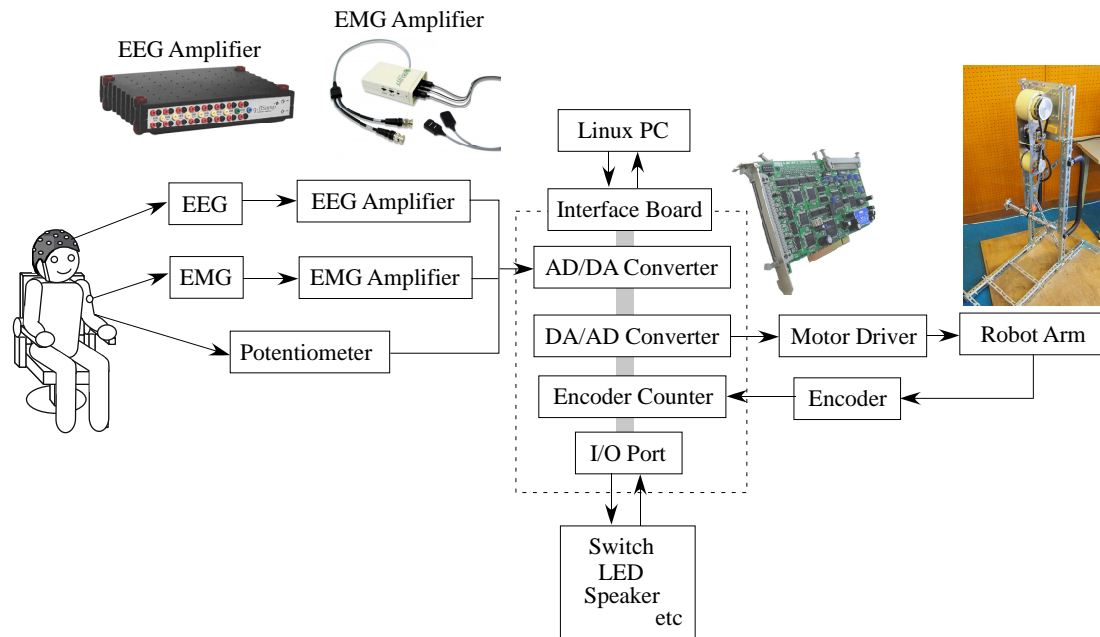


図 3.5: 実験システムの構成

波においては、運動実行後に増幅する ERS を観測した後、ERD が見られた。

このように、運動に関連する脳波は α 波帯域の徐派と β 波帯域の速波が強く関連しており、その変化を観測し、モデルを構築する事で本研究が目指す BMI を構築する事が出来る。

3.4 脳波及び筋電計測システム

本研究で用いる実験システム全体の構成を図 3.5 に示す。まず、被験者の腕の角度はポテンショメータを用い、脳波と筋電は生体アンプを介して増幅し、それぞれインターフェースポート (HRP Interface Board 07-0003-1 (有) 図工製) で AD 変換を行い、Linux PC にてデータの記録する。そして、Linux PC で信号処理し、DA 変換によりモータドライバに指令値を送り、ロボットアームの駆動させる。ロボットアームの角度はエンコーダ、エンコーダカウンタを介して、Linux PC にデータが送られる。また、IO ポートにて、スイッチや LED、スピーカーの入出力を行う (各機器の詳細は付録を参照)

3.5 脳波の周波数領域の解析

脳波は事象に対して周期的な波形が変化することから，その前処理として周波数解析手法が用いられる．周波数解析の手法では，シンプルなバンドパスフィルタを用いた手法や高速フーリエ変換 (Fast Fourier transform; FFT) やウェーブレット変換 (wavelet transformation; WT) などがあげられる．本論文では，ロボット制御のためにリアルタイムで出力することが出来る FFT を応用した時系列解析を行う短時間フーリエ変換 (Short-time Fourier transform; STFT) を用いて，脳波の解析を行う．

3.5.1 高速フーリエ変換

FFT は，時系列データを周波数領域に変換する手法で，時系列データでは見えない周波数の変化を捉えることができ，また，その処理時間が早いことからロボットの制御信号を生成するのにも優れている．複素フーリエ級数展開において，次のような式が定義される．

$$x(t) = \sum_{k=-\infty}^{\infty} C_k e^{jk\omega_0 t} \quad (3.1)$$

$$C_k = \langle x(t), e^{jk\omega_0 t} \rangle = \frac{1}{T} \int_{-T/2}^{T/2} x(t) e^{-jk\omega_0 t} dt \quad (3.2)$$

この式 (3.1) 式 (3.2) を $-t = \omega$, $T/2 = \pi/T_s$, $k = i$ として，標本化周期 T_s の離散信号 x_i に対する離散時間フーリエ変換は，次のように定義される．

$$X(\omega) = \sum_{i=-\infty}^{\infty} x_i e^{j\omega i T_s} \quad \omega = -\frac{\pi}{T_s} \sim \frac{\pi}{T_s} \quad (3.3)$$

これは $[-\frac{\pi}{T_s} \sim \frac{\pi}{T_s}]$ において， ω に関してフーリエ級数展開したものとなる．増幅され得られた脳波 (x_n) の高速フーリエ変換 (FFT) の式は以下ようになる．

$$X_k = \sum_{n=0}^{N-1} x_n W^{kn} \quad (3.4)$$




図 3.6: 50Hz , 20Hz , 10Hz の合成 sin 波 $y = 5\sin 2\pi \cdot 50 \cdot t + 3\sin 2\pi \cdot 20 \cdot t + \frac{1}{2}\sin 2\pi \cdot 10 \cdot t$ ($t=0 \sim 1[\text{sec}]$)




図 3.7: 50Hz , 20Hz , 10Hz の合成 sin 波 (図 3.6) の FFT

ここで $W = e^{-j\frac{2\pi}{N}}$, X_k は複素データ (スペクトル) , k は周波数の番号 , n は時間番号 ($n=0,1,\dots,N-1$) , N は変換点数 (窓) とする [64] .

今 , 式 3.5(図 3.6) のような 50Hz , 20Hz , 10Hz の混合波形があるとき ,

$$y = 5\sin 2\pi \cdot 50 \cdot t + 3\sin 2\pi \cdot 20 \cdot t + \frac{1}{2}\sin 2\pi \cdot 10 \cdot t \quad (t = 0 \sim 1[\text{sec}]) \quad (3.5)$$

FFT を行うと図 3.7 のようになる . パワースペクトルの大きさは 50Hz > 20Hz > 10Hz となっており , 式 3.5 のそれぞれの sin 波に掛けられた係数と対応しており , 各周波数成分を抽出していることが分かる .

次に , 脳波データを FFT に掛けた例を図 3.8 に示す . 図 3.8(a) は閉眼時の脳波

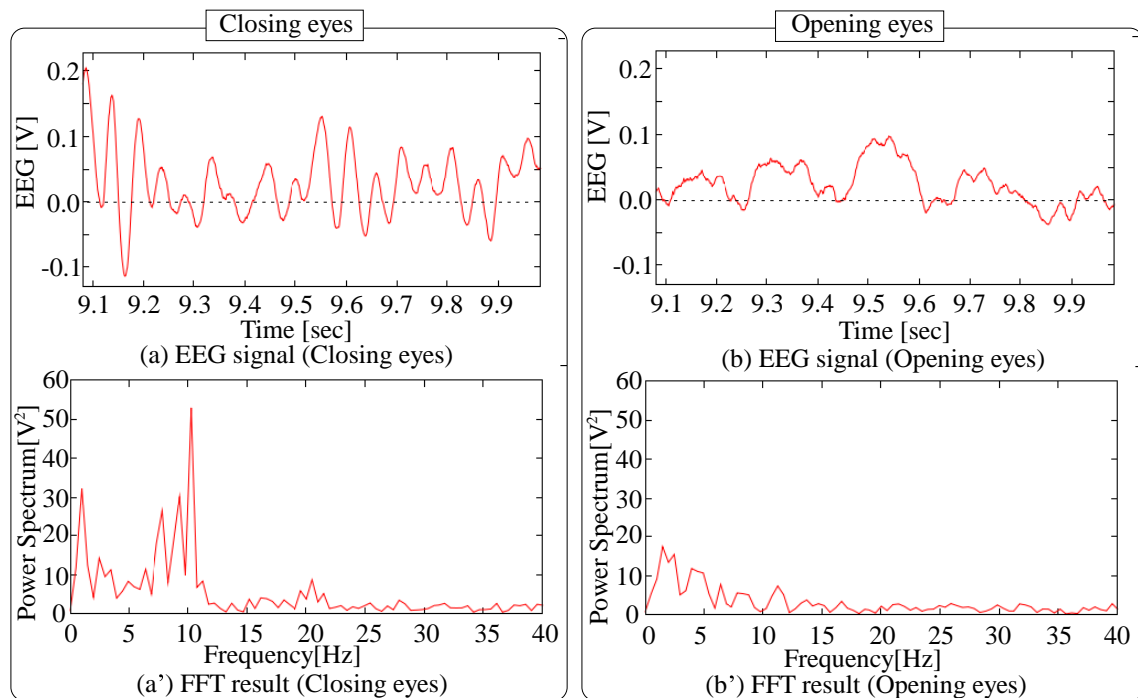


図 3.8: 閉眼時と開眼時の脳波を FFT をかけた例

の約 1 秒間のデータであり，図 3.8(a') はそのデータを FFT (window: 1024msec) に掛けた結果である．同様に，図 3.8(b) は開眼時の脳波，および図 3.8(b') を FFT (window: 1024msec) に掛けた結果である．閉眼時の脳波は α 波帯域 (8 ~ 13Hz) が強く出てくるのがわかっており，その特徴がパワースペクトルとして図 3.8(a') の 10Hz 付近に出てきている．そして，脳波の一つに， α 波減衰という現象があり，目を開くことにより閉眼時で観測された α 波が開眼時の FFT では減衰していることが分かる．このように，脳波データに対して FFT を用いることにより，脳波の特徴を見ることが出来る．

3.5.2 短時間フーリエ変換 (Short-Time Fourier Transform; STFT)

BMIでロボットを操作するためには、運動に関する脳波の特徴を抽出する必要がある。しかし、前述のフーリエ変換では、時系列データは周波数領域に変換されており、そのため時系列の情報は失われてしまう。そこで、式(3.6)式(3.7)で表すように、時系列データから一定の窓(変換点数: N)を切り出しFFTを行い、周波数スペクトル値を算出する短時間フーリエ変換(Short-Time FT; STFT)を行う。そして、窓の時間軸(t)をずらし、再びFFTを行う。以上を繰り返すことにより時間軸で周波数スペクトル値を見ることが出来る。

$$n = t, t + 1, \dots, t + (N - 1) \quad (3.6)$$

ここで t は時間軸のずれであり、例： $t = 0, 10, 20, \dots$ [msec] とすると

$$X_k = \{X_{(k,10)}, X_{(k,20)}, \dots, X_{(k,t)}\} \quad (3.7)$$

窓の時間軸をずれを小さくすることで、時間分解能が高くなる。また、一定の窓の幅を狭めることにより、生体信号のような非線形性信号を線形性として捉えることが出来る。

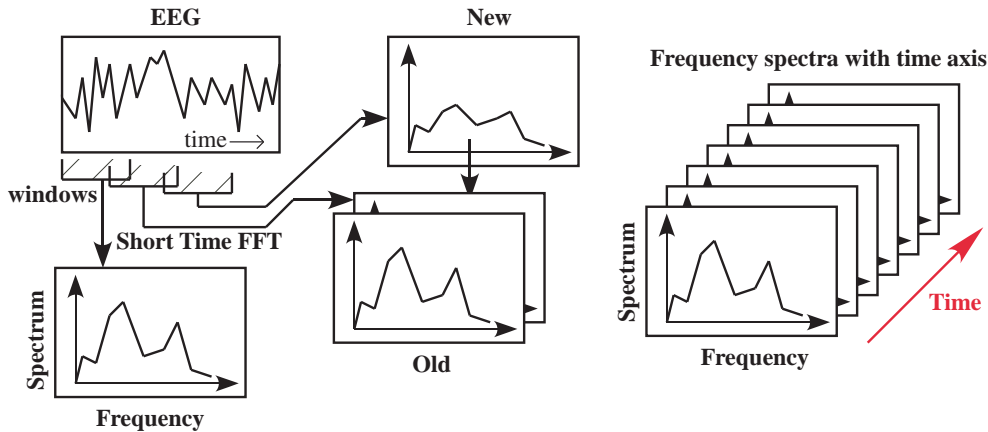


図 3.9: 短時間高速フーリエ変換概念

今，図 3.10 のような 0～1 秒では 50Hz，1～2 秒 20Hz，2～3 秒 10Hz の経過時間によって周波数が変わる sin 波がある．(サンプリング周期 1kHz)

$$y = \begin{cases} \sin 2\pi \cdot 50 \cdot t, & (0 \leq t < 1.0) \\ \sin 2\pi \cdot 20 \cdot t, & (1.0 \leq t < 2.0) \\ \sin 2\pi \cdot 10 \cdot t, & (2.0 \leq t < 3.0) \end{cases} \quad (3.8)$$

これを変換窓幅 $N:512\text{msec}$ ，ずれ幅 $\Delta t:100\text{msec}$ の条件で STFT を行くと図 3.11(a) のようになる．図 3.11(a) は周波数軸，時間軸を底として，スペクトル値を高さとした 3 次元立体図である．そして，図 3.11(b) は図 3.11(a) を時間軸から見た時のものであり，時間経過によって各周波数のパワースペクトルが切り替わっていることが分かる．一方，式 (3.8) の信号は時間によって周波数が変化する非定常な信号となっており，周期が切り替わる前後でそれぞれのパワースペクトルは減衰していることが分かる．これは変換窓幅 N を小さくすることにより，非定常な窓の部分減らすことができ，図 3.11(c) の変換窓幅 $N:258\text{msec}$ ではパワースペクトルの山の平坦部分が長くなっており，周期が切り替わり部分が明確となっている．次に，変換窓幅 $N:512\text{msec}$ は変えずに，ずれ幅 Δt を 200msec に増やした時の結果を図 3.11(d) に示す．図 3.11(b) と比べても，図 3.11(d) では，ずれ幅を変更しても




図 3.10: 時間によって周波数が変わる sin 波 0～1 秒:50Hz, 1～2 秒:20Hz, 2～3 秒:10Hz

大きな変化はないことが分かる．このことから STFT は，ずれ時間を変更してもパワースペクトル値に影響を与えないため，ロボットの制御周期に合わせて設定することができ，リアルタイムでの周波数解析を可能としている．しかし，FFT の特性で変換窓幅と周波数分解能はトレードオフの関係があるため，抽出する周波数帯域に合わせて設定する必要がある．

この STFT を，閉眼時と開眼時の脳波データに対して行った結果を示す（図 3.12，3.13）．各データともに約 15 秒間の解析を行い，閉眼時の脳波では α 波帯域（8～13Hz）の 10Hz のパワースペクトルが強く出てきており，そのパワースペクトルが時系列データとして見る事が出来る．また，開眼時ではその 10Hz のパワースペクトルが無くなっており， α 波減衰を確認することが出来る．

3.6 表面筋電位と関節トルクの関係

次に，被験者の関節トルクを筋電位から推定する手法について述べる．人が運動をしようとする際，表面筋電位と共に関節トルクを発揮することから，表面筋電位には人間の運動情報が含まれていることは良く知られている [65]．また，筋電位は運動細胞に支配されており，この運動細胞は脳の運動野により制御されて

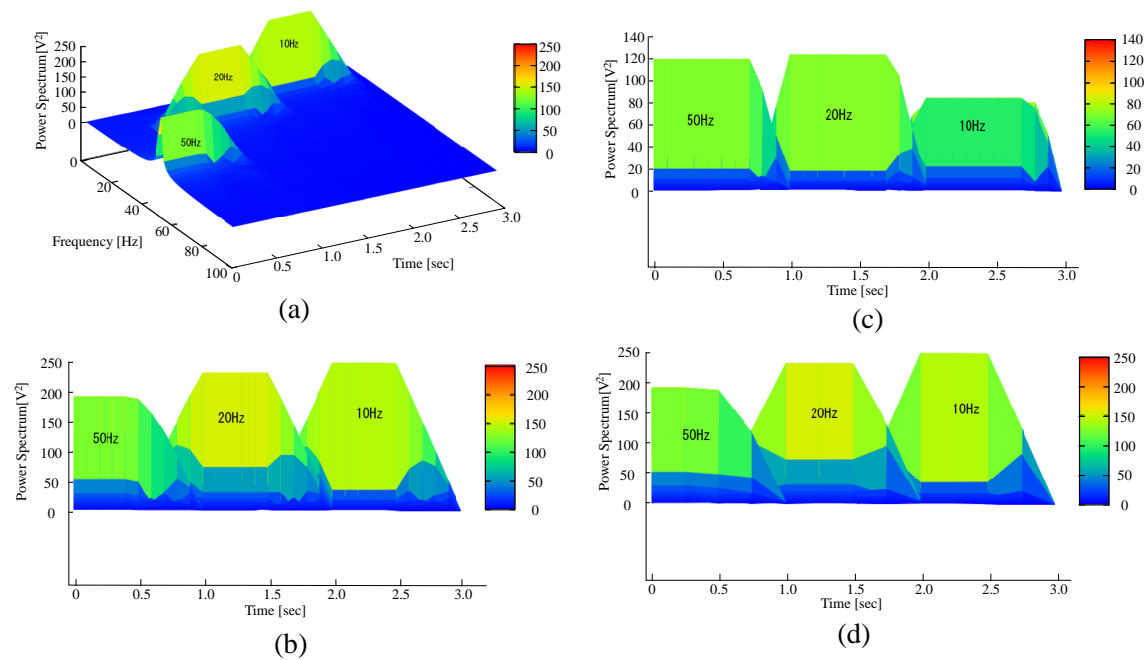


図 3.11: (a) 式 (3.8) の STFT(変換窓幅 N :512msec , ずれ幅 Δt :100msec) (b)(a) を時間軸で見た場合 (c) 変換窓幅 N :256msec , ずれ幅 Δt :100msec (d) 変換窓幅 N :512msec , ずれ幅 Δt :200msec

いるため、運動における脳の活動と表面筋電位の発生には深い関係があると言える [57] .

図 3.14 は重り (0-5kg) を 90 度で維持した時の上腕二頭筋の筋電と負荷の関係を示しており、近似線形関係となっている。関節トルクは筋肉から発生する筋電位の振幅 (筋活動) と線形関係があることが分かっており [66] , 肘関節は複数の筋肉の拮抗により関節トルクを発生しているが、そのほとんどは主動筋である上腕二頭筋の影響が大きい [67] . したがって、本研究では肘関節トルクと上腕二頭筋から計測できる筋活動 v_{EMG} を一次の線形近似式で、以下の式で表す。

$$\tau = Av_{emg} - B \quad (3.9)$$

ここで、 A は肘関節のトルクと筋電の関係を表す定数であり、 v_{emg} は筋活動の大きさ、 B は無負荷時 (腕の自重を維持する時) の筋電の大きさである。本論文では筋活動と肘関節のトルクの区別をせず、肘関節トルクは式 (3.9) より筋活動から

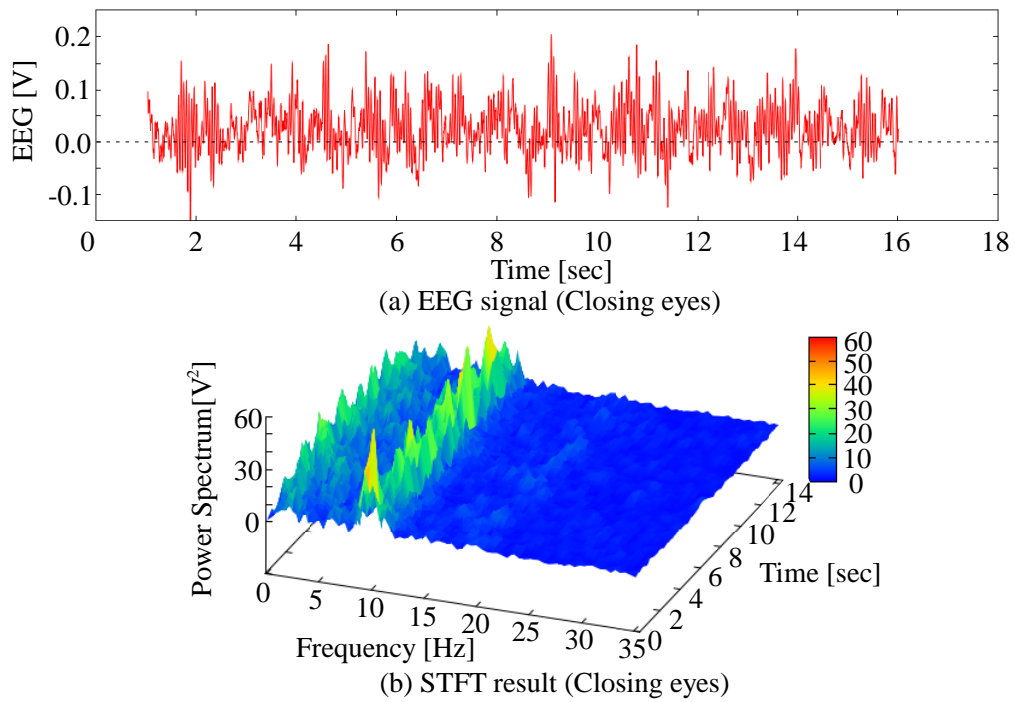


図 3.12: (a) 閉眼時の脳波データと (b) STFT (サンプリング周期:1kHz, 変換点数 N :1024, ずれ幅 Δt :100msec) を掛けた結果




図 3.13: (a) 開眼時の脳波データと (b) STFT (サンプリング周期:1kHz, 変換点数 N :1024, ずれ幅 Δt :100msec) を掛けた結果




図 3.14: 筋電位と重りの線形関係

求める。

3.7 整流平滑化 (Average Rectified Value:ARV)

筋活動が関節のトルクと関係していたことから、筋活動を算出するために筋電位に対し整流平滑化 (Average Rectified Value:ARV) 処理を行う。整流波を一定の時間範囲で積分するかローパスフィルタをかけて平滑化したものが ARV である。対象とする区間を少しずつ時間的にずらしながら ARV を計算することにより、ARV の時間変化が得られる。離散の N 個の数 $e(t-i)$ について ARV を式で書くと、以下のようなになる [65]。

$$V_{ARV}(t) = \frac{1}{N} \sum_{i=0}^{N-1} |e(t-i)| \quad (3.10)$$

図 3.15 から図 3.17 に筋電から ARV 筋電までの結果を示す。生の筋電位信号が図 3.15 であり、整流化すると図 3.16 が得られる。そして、ARV(整流化+平滑化+0.5[Hz]LP) をかけたグラフが図 3.17 となり、筋活動を得ることができ、関節トルクを推定することが出来る。




図 3.15: 筋電信号




図 3.16: 全波整流を行った筋電信号

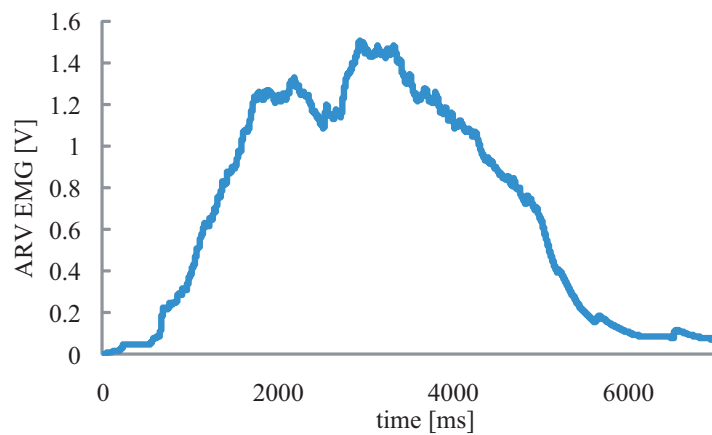


図 3.17: ARV 処理した筋電信号 (筋活動)

3.8 まとめ

第3章では、脳情報の侵襲型、低侵襲型、非侵襲型のそれぞれの計測手法についてまとめ、本研究で用いる運動に関する脳波について述べた。そして、運動に関する脳波は、主に α 波帯域と β 波帯域が関連していることがわかった。さらに、BMI構築のための脳波および筋電を計測する実験環境とそれぞれの信号処理について述べた。脳波では周波数解析が必要であるため、ロボットアームの制御に適した時系列周波数解析手法である短時間フーリエ変換(STFT)を導入する。また、筋電位ではその振幅(筋活動)が関節トルクとの相関を持つことから、整流平滑化(ARV)処理を導入することにより、人の関節トルクを推定することが出来ることを示した。

第4章 運動・運動想起に関する脳波 の調査

脳波から外骨格ロボットを操作するための制御信号取得するために，人の運動に関する脳波（運動時，運動想起）を調査する必要がある．音や光，触ることによる刺激を提示し，その刺激を注意することによって脳波は変化する．そのときの変位として，もっとも見つけやすいのがP300である．しかし，P300は刺激を行わなければ発生しないという欠点を持っている．そこで本研究では，P300のような受動的な脳波とは別の，自発的な運動による脳波の解析する．この章では，腕に関する運動について解析を行うため，まず計測点1点における解析を行い，次に計測点2点間における左右差の調査する．

4.1 運動時の計測点1点での α 波および β 波の左右差の 解析

人の運動に関する脳波の特徴を得るために，本研究では左腕の運動想起の脳波を計測し，その時得られた脳波を短時間の窓で区切り，STFTを用い周波数パワースペクトル値を算出する．そして，STFTを用いて一定周期で短時間の窓をずらし，再び高速フーリエ変換を行うことにより，パワースペクトルを得ると同時に，時間情報を持たせる．

運動想起時発生する脳波には，まず7-11Hzの α 波帯(8-13Hz)の一部である μ 律動と呼ばれる覚醒時に中心，あるいは中心-頭頂部に観測される7-11Hzの律動であり，アーチ状の形をした波である[75]．振幅は様々であるが，多くは $50\mu\text{V}$ 以下

であり、対側の運動や、運動することを想像したり、あるいは触刺激によって抑制される。次に、運動を起こす際、脳の中で「運動形成」のための興奮が起こる。これは、人が自身の体を動かす際にどの筋肉をどのくらいの力を出すのかを脳の中で考える際にその対応個所で 18-30Hz の β 波帯が変化する。人の運動想起時では、 μ 律動の減衰、 β 波が関連しており、その関連性を導出することで人の運動に関する脳波を抽出することが出来る。

4.1.1 測定手法および実験タスク

脳波を計測するにあたり、被験者(健常者)に椅子に座ってもらいリラックスした状態で計測を行う。なお、日常生活で用いることなどを考慮し、シールドルームは用いない。

4.1.2 運動想起判別のためのタスク設計

本研究では、運動想起の μ 律動、 β 波の特徴抽出をするため 4 つのタスクを作成した。この 4 つのタスクでは、人のリラックス状態から運動興奮状態までの動作における脳波の生成を目的としている。以下にそのタスクを説明する。被験者はヘッドキャップをつけて椅子に座り、椅子の高さは被験者に合わせて調節する。

Task 1: Idling State

Task 1 は閉眼時のリラックスした状態の脳波を計測するためのタスクである(図 4.1. task 1)。被験者は目を閉じた安静状態で脳波の計測した。このタスクは被験者が覚醒時にもっともリラックスしている時の脳波を取得するために設計され、もっとも μ 律動が大きく発生するようになっていると予想される。

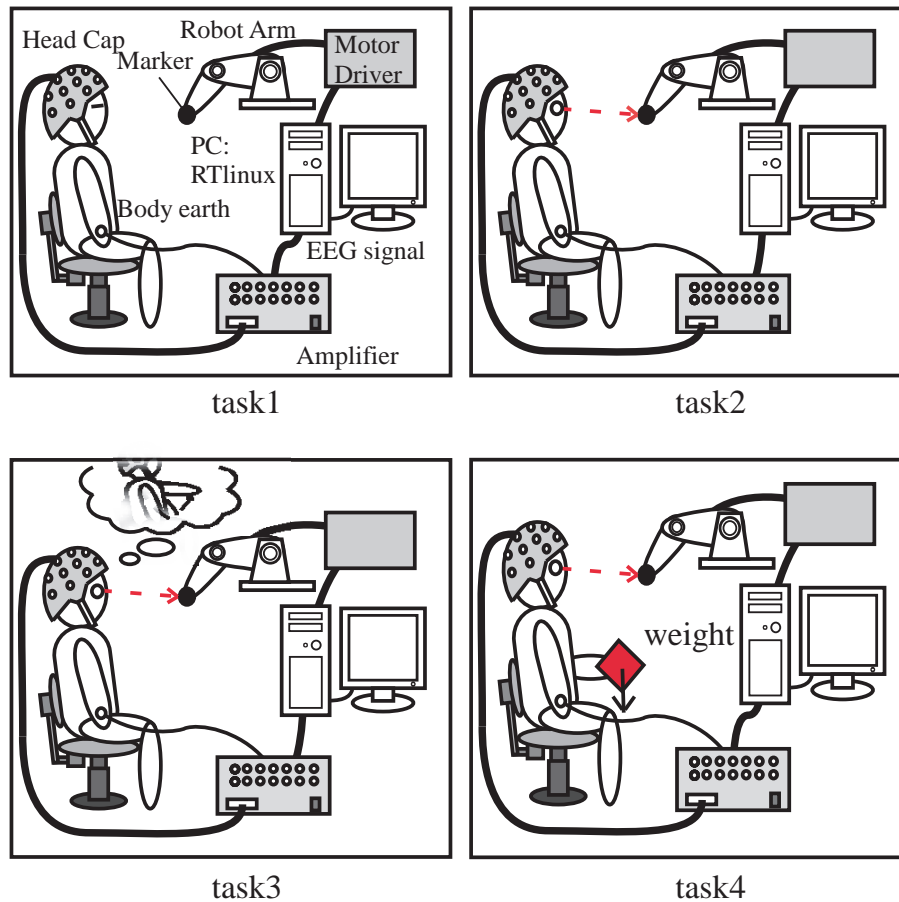


図 4.1: 運動に関する脳の興奮度の違いを考慮した4つのタスク

Task 2: Gazing State

Task 2 は開眼時のリラックスした状態の脳波を計測するためのタスクである (図 4.1. task 2) . 被験者は目を開けて, ロボットアームの先端に取り付けられたマーカに注視し, この間被験者はマーカだけに集中し, 何も動作を行わず, 何も考えないようにする. このタスクは, Task 1 に比べ脳の覚醒度は高くなるように, また被験者の開眼時の無行動状態の脳波を取得するために設計され, Task 1 より α 波は減少すると予想される .

Task 3: Motion Imagery State

Task 3 は開眼時の左腕の屈曲運動を想起した時の脳波を計測するためのタスクである (図 4.1. task 3) . 被験者は Task 2 と同様に目を開きマーカに注視し, 左手

を動かそうと運動を想起する。この時、左腕は動かさず、頭の中で左腕が上がるイメージのみの脳波の β 波の変化を見るために設計した。

Task 4: Motion and Motion Imagery State

Task 4 は開眼時の左腕の運動を動かした時の脳波を計測するためのタスクである (図 4.1. task 4)。被験者は目を開き、マーカに注視する。被験者はマーカを見つつ、左手に 4Kg の重りを持ち、腕を 90 度曲げた状態を保持する。この時同時に左腕を頭の中で左腕を強くイメージを持つ。これは脳の運動興奮時の脳波を計測するために設計し、 μ 律動は減少し、 β 波の変化が出ると予想される。




図 4.2: 閉眼時 (Task 1) の短時間フーリエ変換の結果




図 4.3: 開眼時 (Task 2) の短時間フーリエ変換の結果 (“ A ”は瞬きによるアーティファクト)

4.1.3 各タスクのパワースペクトルの特徴

Task 1 ~ 4 において、被験者の閉眼、開眼、運動の有無に差を設けることにより、Task 1 から Task 4 にかけて μ 律動のスペクトルは減衰し、 β 波のスペクトルは増幅すると予想し、各タスクを 30 秒間行い、その時の脳波を測定した。得られた脳波を前節の STFT を用いて解析を行った結果を図 4.2 ~ 図 4.5 に示す。また、この結果から各タスクにおいて次のことが分かった。

- Task 1 では α 波が他のタスクと比べ最も大きく常に発生している (図 4.2)。
- Task 2 では Task 1 と比べ α 波が減少している。また、図 4.3 に示されて




図 4.4: 運動想起時 (Task 3) の短時間フーリエ変換の結果.




図 4.5: 運動時 (Task 4) の短時間フーリエ変換の結果

いる“ A ”はまばたきのアーティファクトによるものである (図 4.3) .

- Task 3 は Task 2 と同様に α 波は減少している . それと同時に β 波帯の脳波が一定の周波数ではないが発生している (図 4.4) .
- Task 4 も Task 2 と同様に α 波は減少しており , 他のタスクより多く β 波帯が強く出ている (図 4.5) .

各タスクを 30 秒間 , 24 回行った時の C_4-A_2 間の脳波をパワースペクトル解析を行った時の平均値を図 4.6 に示す . また , α 波・ β 波帯域のパワースペクトルの加算値の平均値を図 4.7 に示す . α 波は Task 1 の閉眼時が大きく出てきている .




図 4.6: 各タスク 24 回のパワースペクトルの平均

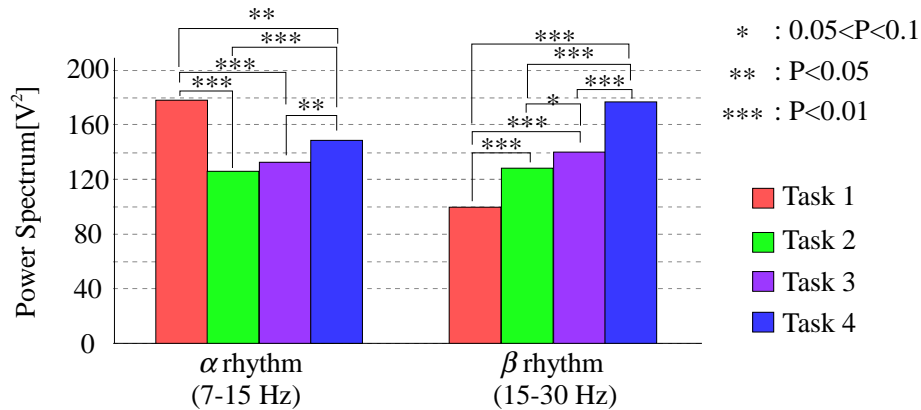


図 4.7: 各タスク 24 回の α 波・ β 波パワースペクトルの平均

一方で他の3つのタスクの α 波は抑制されており、Task 4の腕の力を入れるタスクでTask 2, 3との有意差が出た。 β 波では閉眼時から運動時にかけて、その興奮度によってスペクトル値が上がっていくことが分かる。特に運動時の β 波では大きく出ていることが確認でき、Task 1とTask 4は他のタスクとの有意差が出た。

4.2 運動時の計測点 2 点での α 波および β 波の左右差の解析

前節において、計測点 C_4 のペンフィールドのホムンクルスにおける左腕の運動野での α 波および β 波の閉眼時・開眼時・運動想起時・運動時の脳波の変化を観測した。ペンフィールドのホムンクルスで示した様に、人の運動野は対称性を持っており、左腕の運動は右脳に、右腕の運動は左脳にある。このことから、複数の計測点の特徴量を用いることで、運動に関する脳波をより明確に抽出することが出来る。したがって、前節の得られた α 波および β 波の特徴量を右腕の運動野のある C_3 にも適用し、その変化の観測を行う。

4.2.1 計測環境

被験者は健常者の 20 代男性各 4 名（被験者 A, B, C, D）で、彼らには異なるタスクを行ってもらう。図 4.8 に、実験環境の概要を示す。各被験者は椅子に座り、左腕前腕部を椅子に固定する。この時、左腕を固定するのは、筋肉を動かした際の基線動揺などのアーティファクトの影響を抑えるためである。脳波の取得には国際 10-20 法に基づいて設計されたヘッドキャップ電極 (ELECTRO-CAP, Electro-Cap 社) を用い、測定箇所は脳の感覚運動野の 2 点 C_3-A_1 , C_4-A_2 を測定する。これらの計測点 C_3-A_1 は右腕に関連し、 C_4-A_2 は左腕に関連する感覚運動野である。また、基準電極を頭頂部 (C_z) とした。ここで、筋肉に力を入れるタイミングを観測するために、EMG は被験者の固定された左腕の上腕二頭筋に電極を配置し、その EMG が強く出る 3 秒前から 3 秒後の脳波の取得を行う。計測された 2 点の脳波はそれぞれ Short-Time FFT によって、時間-周波数スペクトルに変換され、運動に関連する α 波と β 波の周波数スペクトル値を抽出する。また、EMG は ARV (Average Rectified Value) で運動の強さの抽出を行い、それに応じて、被験者の隣に置かれたロボットアームの角度が変動し、被験者は左腕の運動を観測することが出来る。したがって、処理された EMG は運動の開始の指標とロボットアームの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




図 4.8: 腕を固定した状態での計測環境

動作に用いられ、その時の脳波の周波数スペクトルの変化の観測を行う。

4.2.2 タスク設計

脳波の変化を見るため、次の被験者の2つのモード (A. リラックスモード, B. 運動モード) における4つのタスクを設計する。

A. リラックスモード (Relaxation Mode)

- Task 1 - 閉眼時：図 4.8 の椅子に座った状態で被験者は目を閉じ、リラクセスする。その間、何も考えず、何も動作を行わないように努める。これは閉眼時のリラクセス状態の脳波を計測するためのタスクである。
- Task 2 - 開眼時：図 4.8 の椅子に座った状態で被験者は目を開きリラクセスする。この時、被験者は何も考えず、何も動作を行わないように努め、一点の

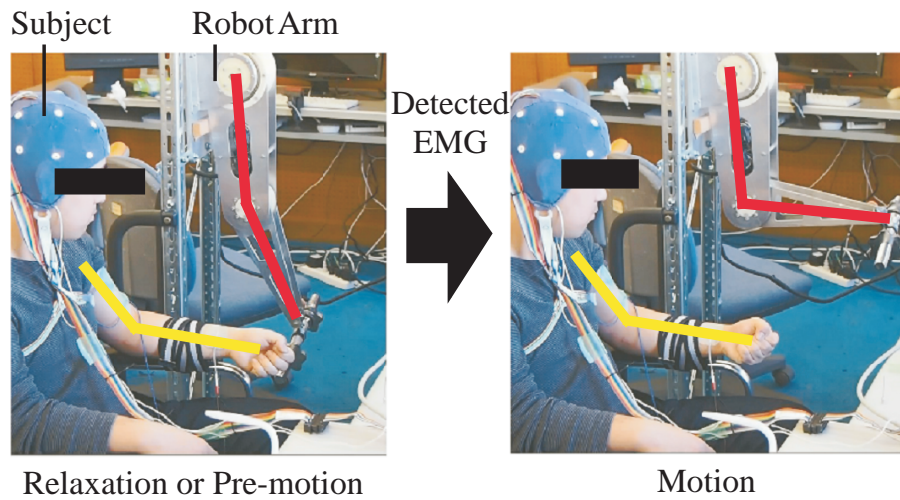


図 4.9: 筋電を検知した時のロボットアームの動き

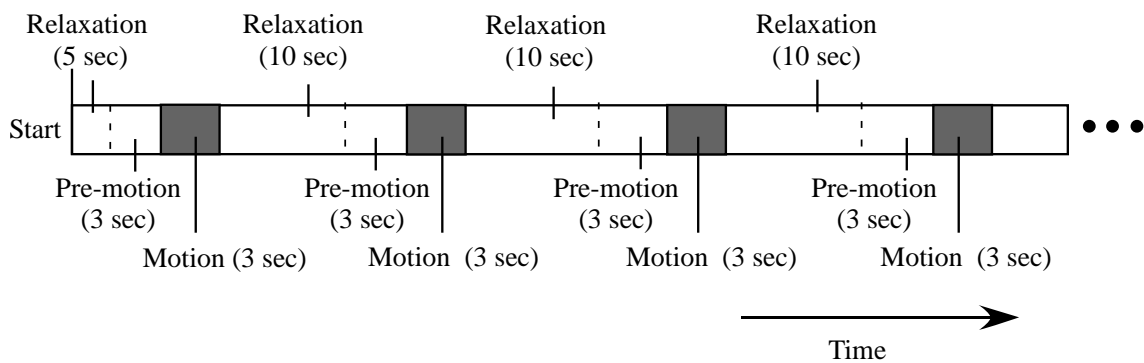


図 4.10: Task 3 と Task 4 のタイムチャート

みを注視するようにする。これは開眼時の行動していない時の通常のリラックス状態の脳波を計測するためのタスクである。

B. 運動モード (Motion Mode)

被験者は図 4.9 に示すように椅子に座っている状態で、固定された左腕を約 3-6 秒間持ち上げるように左上腕二頭筋に力を入れる。その後、約 10 秒間の休憩を取り、再び腕に力を入れる。これを図 4.10 に示すように数回繰り返す。そして、この運動状態を次の 2 つのタスクに分ける。

- Task 3 - 運動直前 (Pre-motion) : EMG が発生する前の $-3 \sim 0$ [sec] の 3 秒間。これは被験者が運動を想像し、実行するまでのタスクである。本研究では、

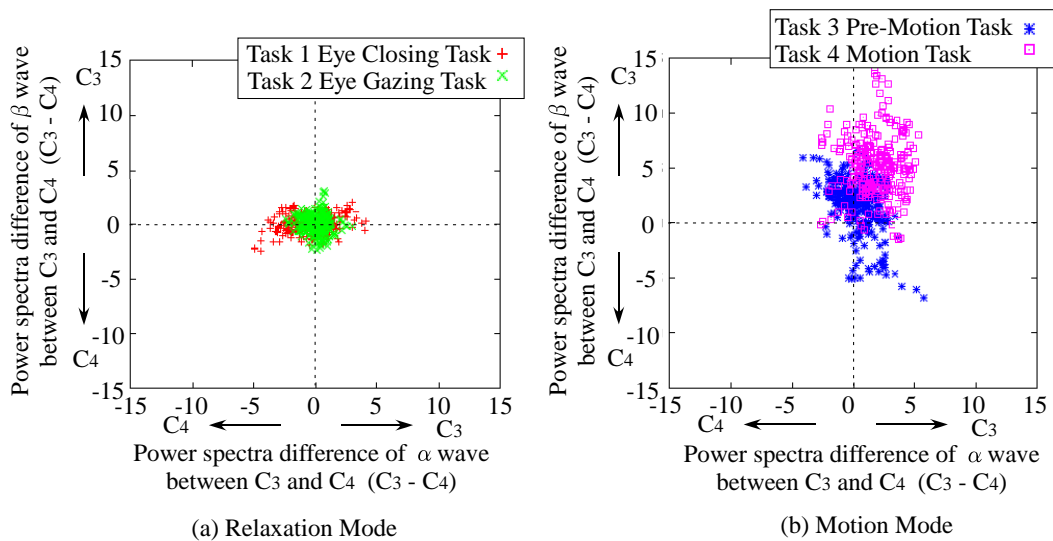


図 4.11: 被験者 A の C_3 と C_4 における α 波と β 波

このタスクを運動想起状態として設計した。

- Task 4 - 運動時 (Motion) : EMG が発生してからの 0~3[sec] の 3 秒間 . これは実際に運動を行うタスクである .

これらの 2 つのタスクは運動前及び , 運動中に関する脳波を取得するためのタスクである . このタスクの間 , 被験者は駆動するロボットアームの先端に注目してもらう .

4.2.3 各タスクにおける α 波と β 波の左右差

α 波と β 波の変化に着目し , 左右の計測点 C_3 と C_4 の 2 点において , どちらが α 波と β 波が強く出てくるかを観測する . 図 4.11 ~ 4.14 は被験者ごとの計測点 C_3 と C_4 の 2 点における α 波と β 波のそれぞれのタスクの 300 点の分布を表わしたものである . 横軸は α 波 , 縦軸は β 波の C_3 と C_4 のどちらに強く出ているかを示しており , + 側にあると C_3 に強く出ており , - 側にあると C_4 に強く出てきていることを表わしている .

まず , 被験者 A の図 4.11 では , リラックス状態の閉眼時 , 開眼時ではプロット

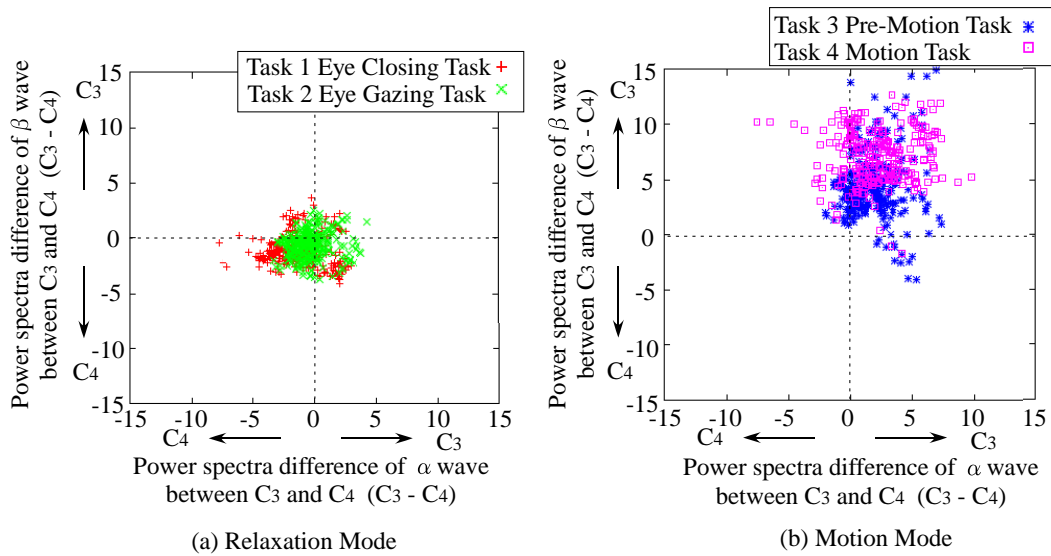


図 4.12: 被験者 B の C_3 と C_4 における α 波と β 波

された点は中心に集まっており、 α 波と β 波の左右差は小さいことが分かる。一方、運動モードでは、Task 3 の時は β 波が強く C_3 側に出ており、 α 波も同様に比較的 C_3 側出ている。そして、Task 4 では、Task 3 と比べて左右差は小さくなっているが、 C_3 側に分布していることが分かる。被験者 B の図 4.12 でも同様の分布を見ることが出来た。

次に、被験者 C と D では、リラクスマードにおいて、 α 波が C_4 側に多く分布する傾向が得られた。そして、運動モードでは Task 3, 4 とともに左右差は見られず、この二つのタスク間の差は見れなかった。被験者 C と D でも、被験者 A, B で見られた様に、リラクスマードと比べて運動モードは C_3 側に出てくることが分かる。

そして、図 4.15 に被験者各 4 名 (Subject A ~ D) が Task 1 ~ 4 を実行した際の計測した計測点 C_3 , C_4 の α 波と β 波のパワースペクトル値の差の平均と標準偏差を示す (Task 1, Task 2: 30 秒間 1 試行. Task 3, Task 4: 3 秒間 10 試行)。図 4.15 は各パワースペクトルが C_3 が強い場合は右側に、 C_4 が強い場合は左側に現れ、その差の大きさを表わしている。この図 4.15 から、リラクスマード (Task 1, Task 2) と左腕の運動前 (Task 3) および運動時 (Task 4) では、どの被験者でも左腕

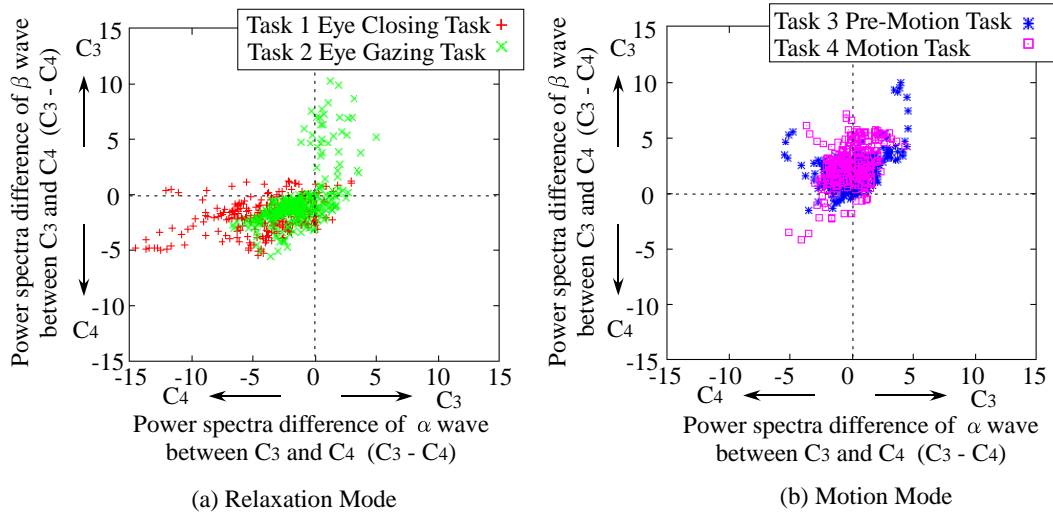


図 4.13: 被験者 C の C_3 と C_4 における α 波と β 波

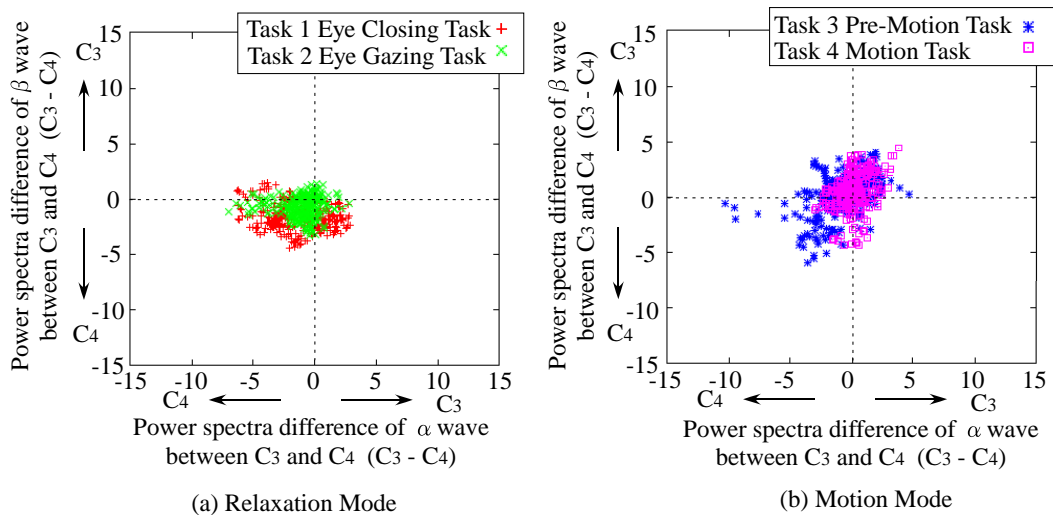


図 4.14: 被験者 D の C_3 と C_4 における α 波と β 波

の運動状態時はリラックス状態時と比べて α 波と β 波のスペクトル値が C_3 側に出ていることが分かる．すべての被験者において，Task 3の運動直前とTask 4の運動時に α 波と β 波のどちらか，もしくは両方が C_3 側に分布していることが明らかになり， C_4 側の α 波と β 波は抑制されていることが言える．また，Task 2において，ほとんど左右差は見られなかった．Task 1では α 波では左右差が見られるところがあるが， β 波に関してはほとんど差が見られなかった．

左腕の運動をするタスク (Task 3, Task 4) で C_3 と C_4 の α 波と β 波は C_3 側に強く出てきている．運動に関連する脳波の変化は運動する部位の対側に現れるといわれており， α 波帯域 (7-15Hz) では，この帯域に含まれる7-11Hzの μ 律動と呼ばれる律動が，運動したり，運動を想像することによって抑制される．また，Pfurtschellerらによると，この μ 律動は運動する-1.75秒前に抑制されることを観察した [59]． β 波帯域 (15-30Hz) でも同様に運動をしたり，運動を想像することによって対側の β 波の抑制または減衰される [75]．左腕の運動によって， C_4 の α 波と β 波は抑制されたため， C_3 側が強くなるような脳波の分布が見られ，運動をしないタスク (Task 1, Task 2) と運動をするタスク (Task 3, Task 4) の違いが現れたと考えられる．

4.3 運動に関する脳波の α 波と β 波の考察

運動に関する脳波は左腕の運動野にあたる計測点 C_4 の解析では， α 波減衰および μ 律動の抑制により， α 波のパワースペクトルは閉眼時と開眼時で大きな差を見ることが出来た．一方， β 波では閉眼，開眼，運動想起，運動に掛けてパワースペクトルが上がっていることが分かる．また，左右差で見た時に， α 波のパワースペクトルは運動をしていないタスクの閉眼時や開眼時では左右差はない，もしくは C_4 側に多く分布する傾向が得られた．そして，運動に関するタスクで運動をしていないタスクと比べて C_3 側に出てきた．これは α 波減衰および μ 律動の影響で左腕の運動野にあたる計測点 C_4 の α 波のパワースペクトルが減衰したためと考えら

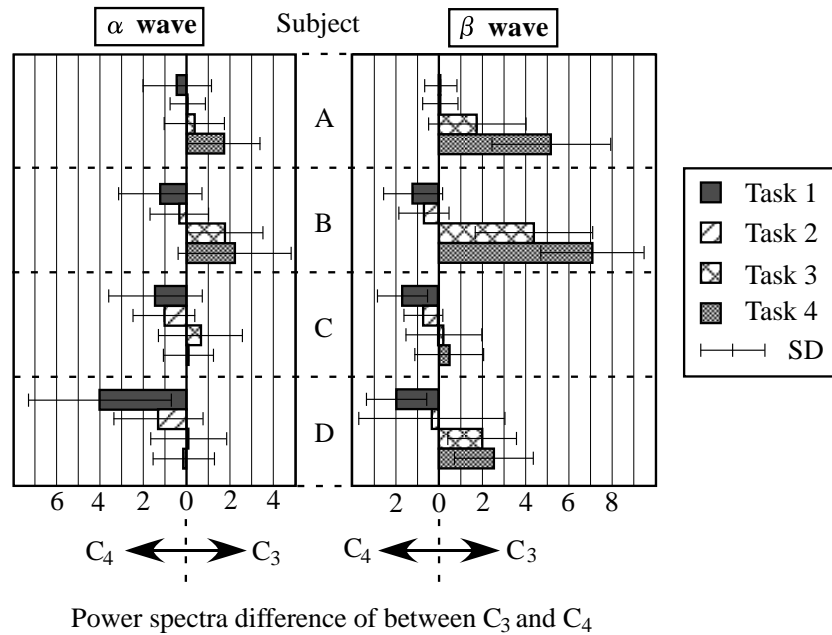


図 4.15: 計測点 C_3 と C_4 の α 波および β 波のパワースペクトルの差の平均と標準偏差

れ、計測点 1 点で得られた結果と同様の結果が得られた。しかし、 β 波では、左右差で見た際に運動に関するタスクで同側である C_3 側に多く出る傾向が得られ、計測点 1 点で見た結果と差異が見られた。このことから、運動に関する脳波の β 波は C_4 のパワースペクトルだけではなく、 C_3 のパワースペクトルも強くなり、さらに、 C_3 の方がより強く出てくるということが分かる。

4.4 まとめ

第 4 章では、腕に関する運動に関する脳波の特徴を抽出するために、短時間フーリエ変換を用いて周波数領域での解析を行った。まず、 α 波では計測点 C_4 において閉眼時のパワースペクトルは大きく、開眼時、運動想起時、運動時では差は見られなかった。また、計測点 C_3 と C_4 の左右差では、被験者によって異なり、運動をしていないタスクの閉眼時や開眼時には左右差はない、もしくは C_4 側に多く分布する傾向が得られた。そして、運動に関するタスクでは運動していないタスク

と比べて、 C_3 側にパワースペクトルが出るのが分かった。一方、 β 波では、計測点 C_4 において、閉眼、開眼、運動想起、運動に掛けてパワースペクトルが上がるのが分かった。そして、計測点 C_3 と C_4 の左右差では、運動をしていないタスクでは左右差はあまり見られず、運動に関するタスクで α 波と同様に C_3 側にパワースペクトルが出るのが分かった。これらの結果に基づいて、 α 波や β 波のパワースペクトルの変化を脳の全体で観測することにより、使用者の運動を脳波から検知することが可能である。

第5章 運動の2値判別

前章において、左右の計測点 C_3 と C_4 の2点で、 α 波と β 波の強さの左右差を見ることが出来た。このことを用いて、逆問題として運動を行っていないときのリラックスモードと、運動を行っているときの運動モードの二つに判別する判別器の生成を行う。

5.1 2値判別器について

この逆問題は2クラスの判別分析を行うことであり、2つのデータ群のグループがある時に新しく得られたデータがどちらのデータ群に属するのかを分析することにある。前章で、 α 波と β 波のパワースペクトルを軸として2次元に表すことにより、運動の有無でそれぞれの集合を見ることが出来た。これらの集合を2つのグループに分けて分析することで、2値判別器を生成することが可能となると考えられる。次に、判別分析における2次判別関数であるマハラノビスの汎距離 (Mahalanobis' distance) について述べる。

5.2 マハラノビスの汎距離

マハラノビスの汎距離とは、複数の項目の間に相関がある場合に注目している対象の平均から距離と相関関係からのずれを合わせて一元化した値であり、その値が小さいとその集合に近いとし、大きいとその集合から遠くに分布するとする判別の評価指標である。マハラノビスの汎距離は平均と標準偏差また相関係数から求めることができ、比較的シンプルで、かつ多次元の利用が可能で計測データ

の多い脳波データでも応用することが出来る．

ここで， α 波のスペクトル値を $x_{\alpha i}$ ， β 波のスペクトル値を $x_{\beta i}$ ($i = 1, 2, 3, \dots, N$) とすると，2次元におけるマハラノビスの汎距離 D の式は次のように表わされる．

$$D = \sqrt{\frac{u_1^2 - 2ru_1u_2 + u_2^2}{1 - r^2}} \quad (5.1)$$

$$u_1 = \frac{x_{\alpha i} - \bar{x}_\alpha}{\sigma_\alpha}, \quad u_2 = \frac{x_{\beta i} - \bar{x}_\beta}{\sigma_\beta} \quad (5.2)$$

ここで， r は $x_{\alpha i}$ ， $x_{\beta i}$ の相関係数， \bar{x}_α ， \bar{x}_β は $x_{\alpha i}$ ， $x_{\beta i}$ のそれぞれの平均値， σ_α ， σ_β は $x_{\alpha i}$ ， $x_{\beta i}$ のそれぞれの標準偏差を表わしている． D は集合からの距離を表わしており，リラックスモードの集合と運動モードの集合のそれぞれのマハラノビスの汎距離を求め，その距離がどちらの集合に近いかでどの集合に属するのかの判別することが出来る．

図 5.1 にマハラノビスの汎距離を用いた判別の概要を示す．図 5.1 の A のデータ群と B のデータ群がある時，それぞれのマハラノビスの汎距離を求め，等距離に位置 ($D = 1, 2, 3$) を表すとデータ群の平均値を中心としたデータの広がりやを考慮した楕円が得られる．そして，2つのデータ群を組み合わせると，それぞれのデータ群のマハラノビスの汎距離が同じ位置で線を引くことで，判別境界線を引くことができ，2値判別器として用いることが出来る．

したがって，ここでリラックスモードの集合からのマハラノビスの汎距離を $D_{Relaxation}$ とし，運動モードの集合からのマハラノビスの汎距離を D_{Motion} としたとき，判別条件は次のようになる．

$$\text{RelaxationMode} : D_{Relaxation} < D_{Motion} \quad (5.3)$$

$$\text{MotionMode} : D_{Relaxation} > D_{Motion} \quad (5.4)$$

この境界線は $D_{Relaxation} = D_{Motion}$ の時である．また，ここで運動モードに重み k_m を持たせることにより，どちらのモードを優先するかを設定できる．したがって，判別条件は次のようになる．

$$\text{RelaxationMode} : D_{Relaxation} < k_m \cdot D_{Motion} \quad (5.5)$$

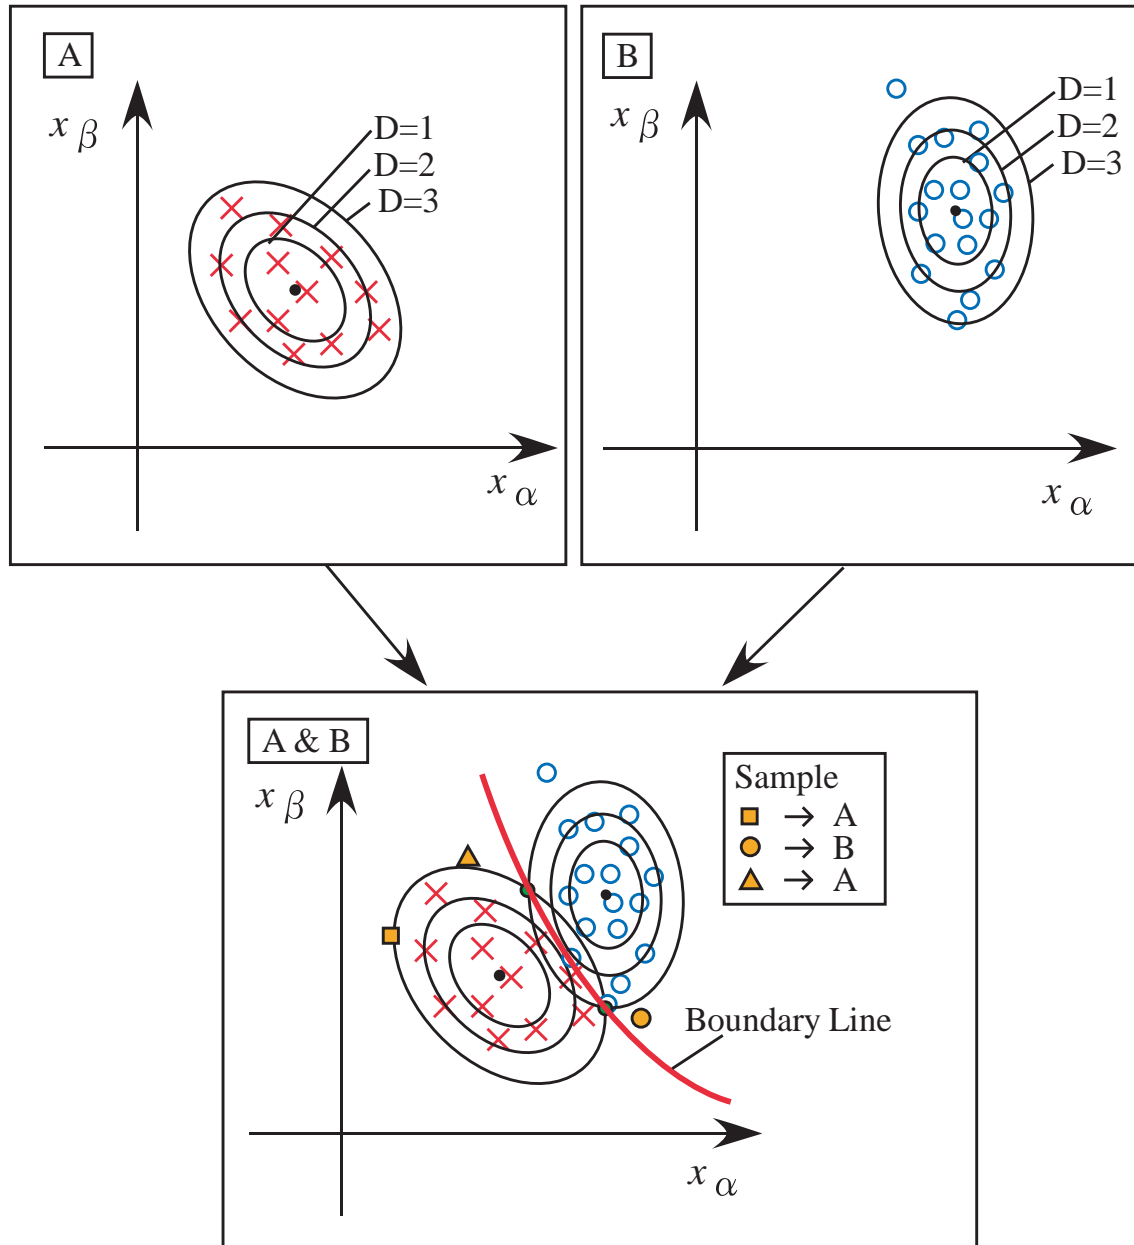


図 5.1: マハラノビスの汎距離を用いた判別

$$\text{MotionMode} : D_{\text{Relaxation}} > k_m \cdot D_{\text{Motion}} \quad (5.6)$$

この境界線は $D_{\text{Relaxation}} = k_m \cdot D_{\text{Motion}}$ となり, k_m の値が大きくなるにつれ, 優先度は低くなる. 閉眼時や開眼時ではロボットアームは動かないことは望ましい. したがって, 今回は運動モードの優先度の重みを大きくして, 閉眼時や開眼時での誤判別を少なくするように運動モードの重み係数を大きくする. なお, 重み係数の決定には, Task 1 と Task 2 を完全にリラックスモードに判別できるような値に設定した.

5.3 運動判別手順

運動を判別する手順を図 5.2 に示す. まず, 実験タスク (Task 1 ~ Task 4) を行った時の生体増幅アンプから得られた脳波を STFT を用いて時間-周波数変換を行い, 時系列データを含んだ α 波帯 (7-15Hz) と β 波帯 (15-30Hz) のパワースペクトルを抽出する. また, この時の筋電も取得する. 次に, Task 1 の閉眼時と Task 2 の閉眼時に得られた C_3 と C_4 の α 波の差と β 波の差を取りだし, α 波の差と β 波の差の 2 次元データにおけるマハラノビスの汎距離の式のパラメータを算出する. 同様に, Task 3 の運動直前と Task 4 の運動時のマハラノビスの汎距離の式のパラメータを算出する. そして, この算出された二つのマハラノビスの汎距離の導出式をそれぞれリラックスモードと運動モードとして判別器の境界線の式を作成する. また, 得られた境界線の式で, 入力に用いた Task 1 と Task 2 の脳波データを代入し, リラックスモードと 95 % 以上判別できるか判別し, もし出来ていないようなら運動モードの重み k_m をあげて, 運動モードの優先度を下げる. ここで, このリラックスモード 95 % 以上とするのは, 経験的に得られたものである. 最後に, 作成された判別器に各実験タスクを行った時の脳波を用いて運動判別の評価を行う. この時, 評価に用いる脳波と筋電データは判別器の作成に用いたデータと別のデータを用いる. また, 運動時の評価は筋電が発生している時のみ運動モードであるとして, 正答率を計算した. この判別手法を用いて, 各被験者ごとのマハ

ラノビスの汎距離と境界線は図 5.3～5.6 のようになる．本研究では，この判別器を用いて，オフラインでの各タスクにおける運動判別の検証を行った．

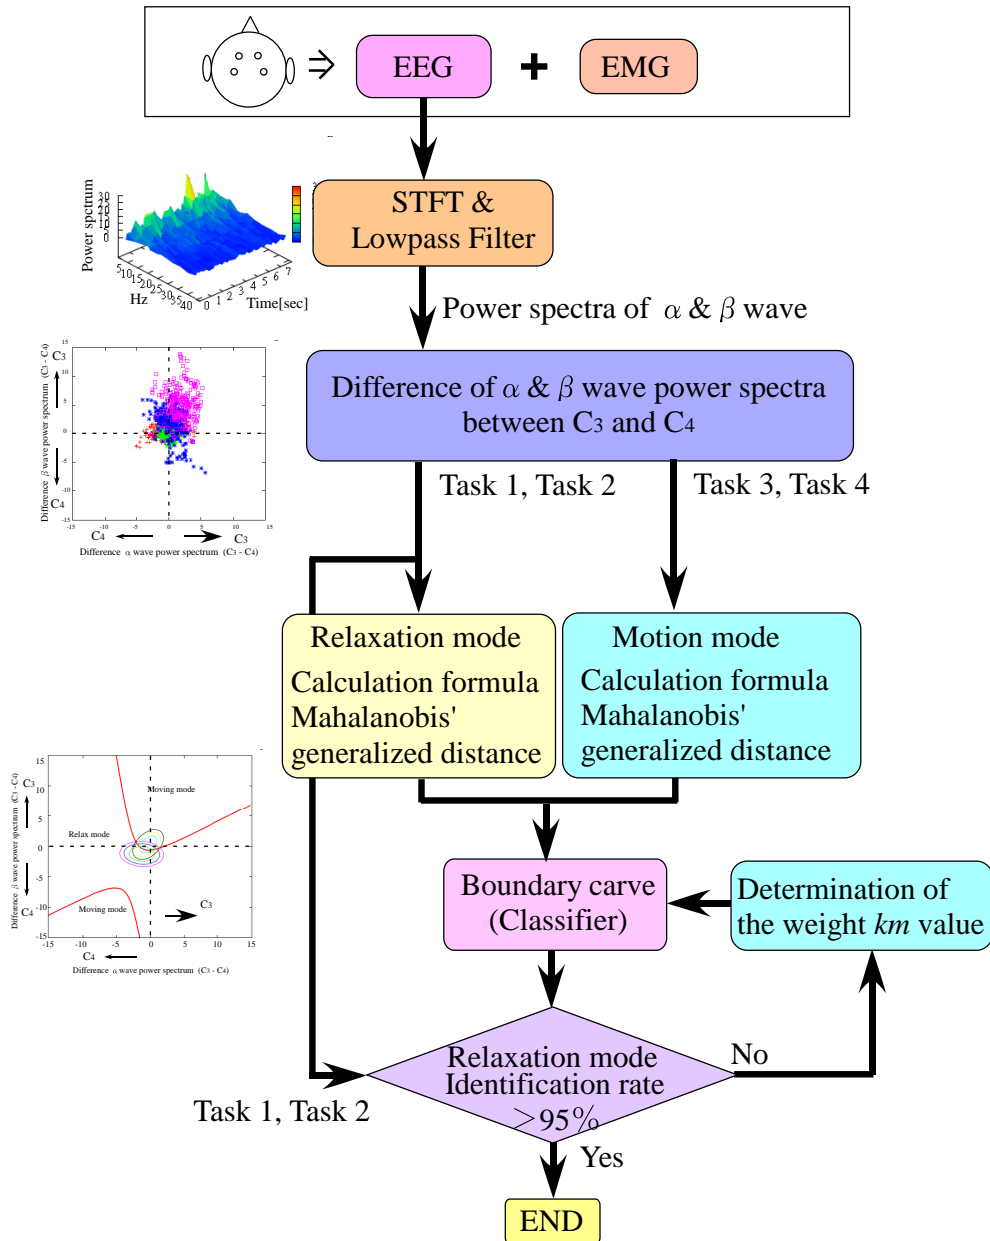


図 5.2: 運動判別手順




図 5.3: 被験者 A の判別の境界線と、リラックスモードと運動モードのマハラノビスの汎距離

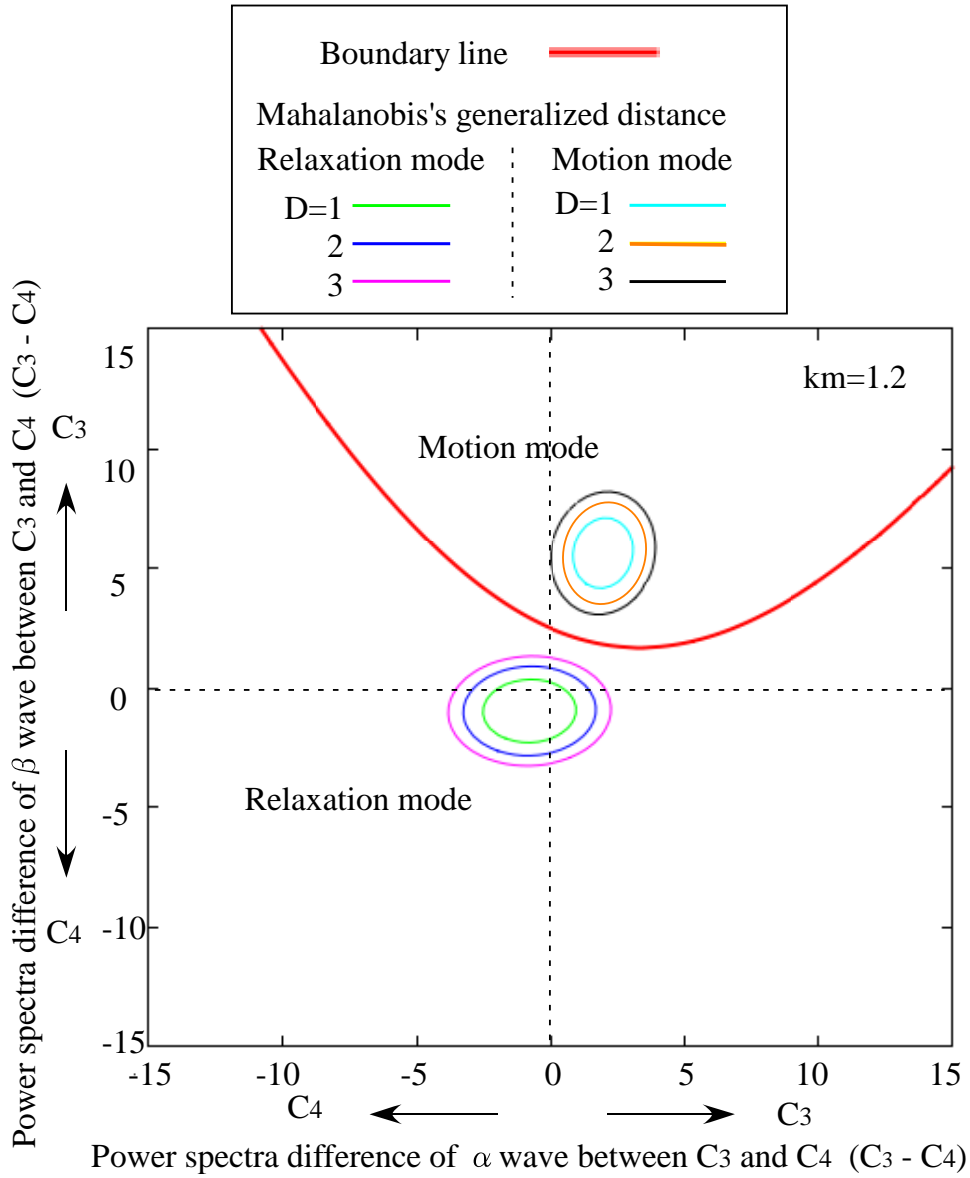


図 5.4: 被験者 B の判別の境界線と、リラックスモードと運動モードのマハラノビスの汎距離




図 5.5: 被験者 C の判別の境界線と、リラックスモードと運動モードのマハラノビスの汎距離




図 5.6: 被験者 D の判別の境界線と、リラックスモードと運動モードのマハラノビスの汎距離

5.4 運動判別結果，及び考察

前節で設定した判別器を用いて，各タスクを行った時の判別結果を図 5.7～5.10 に示す．上段が Task 1 の閉眼時の sEMG とその時の脳波の運動判別結果，中段が Task 2 の開眼時の sEMG とその時の脳波の運動判別結果，下段が Task 3 の運動直前と Task 4 の運動時の sEMG とその時の脳波の運動判別結果を表わしている．Moving は左腕の上腕二頭筋に力を入れ，ロボットアームを動かしている時である．また，その各タスクにおける判別の識別率を表 5.1 に表す．

図 5.7～5.10 の上段と中段の Task 1 の閉眼時と Task 2 の開眼時では，全ての被験者でリラックスモードとなっている．Task 1 の閉眼時と Task 2 の開眼時では，体を動かさずリラックスしている状態であり，脳の運動に関連する C_3 と C_4 部分の左右差は少ない．したがって，リラックス時の C_3 と C_4 の α 波の差と β 波の差は小さくなり，リラックスモードのマハラノビスの汎距離は小さくなる．したがって，運動モードの集合よりリラックスモードの集合に近づくためリラックスモードとなったと考えられる．さらに，運動モードのマハラノビスに汎距離に優先度の下げる重みを掛けたため，被験者 4 人の Task 1 の閉眼時と Task 2 の閉眼時における判別の識別率は 84 % 以上と非常に高い結果となった．

図 5.7～5.10 の下段の Task 3 の運動直前と Task 4 の運動時では，被験者によって異なる結果となった．被験者 A では（図 5.7），運動していないときはリラックスモードとなり，左腕の運動とともに運動モードと判別された．また，運動モードの判別の識別率は 86 % と被験者 4 人の中で一番高い結果となった．これは被験者 A の Task 4 の運動時の α 波の差と β 波の差は他の被験者と比べて C_3 側に一番大きく出てきており，また，Task 1 の閉眼時と Task 2 の開眼時では α 波の差と β 波の差がほとんどないことが作成された判別器で判別出来た理由だと考えられる．被験者 B では運動の前後に運動モードと判別されていたり，運動中にリラックスモードと判別されている個所が見られる．これは被験者 B は，Task 3 の運動直前の α 波の差と β 波の差は Task 4 の運動時のものと同じくらい C_3 側に一番大きく出てきており，今回作成した判別器ではその違いを判別することは難しく，運動

直前から運動への α 波と β 波の時間軸の変化を見る必要があると考えられる。被験者 C では、Task 3 の運動直前と Task 4 の運動時ではモードの切り替わりの変化は見られた。しかし、筋肉の運動の関係性は見られなかった。これは、被験者 C は C_3 と C_4 の α 波の差と β 波の差が小さいため、判別器の境界線がうまく生成できなかったと考えられる。被験者 D では、Task 1 の閉眼時と Task 2 の開眼時の違いは最も顕著にみられた。これは被験者 D は Task 1 の閉眼時と Task 2 の開眼時において C_3 と C_4 の α 波の差と β 波の差が大きく出てきていることにより、その変化に合わせて判別器が作成されたためだと考えられる。

これらのタスクでの判別結果は各被験者によって異なることが見られた。これは運動モードの優先度の重みを与えて境界線を算出する際に、その値の決定は運動をしないタスクを十分に判別できているかによって決定するため、運動をするタスクでのことは考慮されていない。今後、重みの決定を運動するタスクでの判別結果も考慮に入れ、自動的に重みを決定する学習機能を取り入れる必要がある。

表 5.1: マハラノビスの汎距離を用いた運動判別の結果

Mode	Relaxation Mode		Motion Mode	
	Task 1	Task 2	Task3	Task 4
Tasks				
Relaxation- > R	Task 1	Task 2	Task3	Task 4
Motion- > M	R:M	R:M	R:M	R:M
Subject A	98:2	97:3	63:33	14:86
Subject B	100:0	99:1	63:47	28:72
Subject C	95:5	86:14	64:36	47:53
Subject D	100:0	98:2	54:46	65:35




図 5.7: 被験者 A の各タスクの判別結果, 上段: Task 1-閉眼時 中段: Task 2-閉眼時 下段: Task 3-運動直前, および Task 4-運動時




図 5.8: 被験者 B の各タスクの判別結果, 上段: Task 1-閉眼時 中段: Task 2-閉眼時 下段: Task 3-運動直前, および Task 4-運動時




図 5.9: 被験者 C の各タスクの判別結果, 上段: Task 1-閉眼時 中段: Task 2-閉眼時 下段: Task 3-運動直前, および Task 4-運動時




図 5.10: 被験者 D の各タスクの判別結果, 上段: Task 1-閉眼時 中段: Task 2-閉眼時 下段: Task 3-運動直前, および Task 4-運動時

5.5 筋収縮数理モデルによるロボットアーム目標角の決定

前節において， α 波帯域と β 波帯域のパワースペクトルを観測することで運動の判別を行うことが出来ることが分かった．ロボットアームの入力信号は α 波帯と β 波帯のパワースペクトルが変化によって決定する．その信号は ON/OFF の変化であるため，ロボットアームの動作を生成しなければならない．したがって，今回は人の筋収縮の数値モデル [68][69] を用いてパルス信号から人の関節トルクを算出する

5.5.1 筋収縮数理モデル

人間の動きは筋肉の張力を発生させることによって動いている．その筋肉の張力は運動ニューロンからの刺激により一定の収縮を発生する．この一回の収縮を単収縮と言い，刺激から 50 ~ 200m 秒で筋肉が素早く収縮し，その後緩やかに張力が下がり元の状態となる（図 5.11）．この単収縮の筋張力曲線は下記の式のような筋張力増加曲線と筋張力減少曲線を合わせた式となり，

$$f(t) = A \left\{ \frac{1 - e^{-k_1 t}}{1 + e^{-k_1(t-t_1)}} - \frac{1 - e^{-k_2 t}}{1 + e^{-k_2(t-t_2)}} \right\} \quad (5.7)$$

この時， A は発生する張力の大きさを表す [69]．また，筋張力は刺激が起こるたびに重畳的に発生するため，実際に出る筋張力は

$$F(t) = \sum_{i=0}^t f(t - T_i) \quad (5.8)$$

となる．この時， T_i は神経からの刺激が来たときの時間である．今回はこの式を用いて，脳から腕を動かすというコマンドが来た時に，筋張力を発生するようにし，ロボットアームに動かすように仮定した．




図 5.11: 単収縮曲線

5.5.2 ロボットアーム目標角の決定

ロボットアームの目標角を決定するまでの結果を図 5.12 に示す。(a) は表面筋電位を表しており、大きく出ているところが上腕二頭筋に力を入れている時である。(b) は表面筋電位から算出された関節トルクを表している。(c) は前節の運動判別結果を示しており、ロボットに与えられる信号を表している。ON の時はロボットアームの入力信号となる。(d) はロボットアームの関節トルクを表している。ON と判別した後、式 (5.8) の筋張力曲線が発生する。最後に、(e) は上記の (d) から得られたロボットアームの目標角度を表しており、判別された結果に基づいてロボットアームの目標角度が算出出来ていることが分かる。

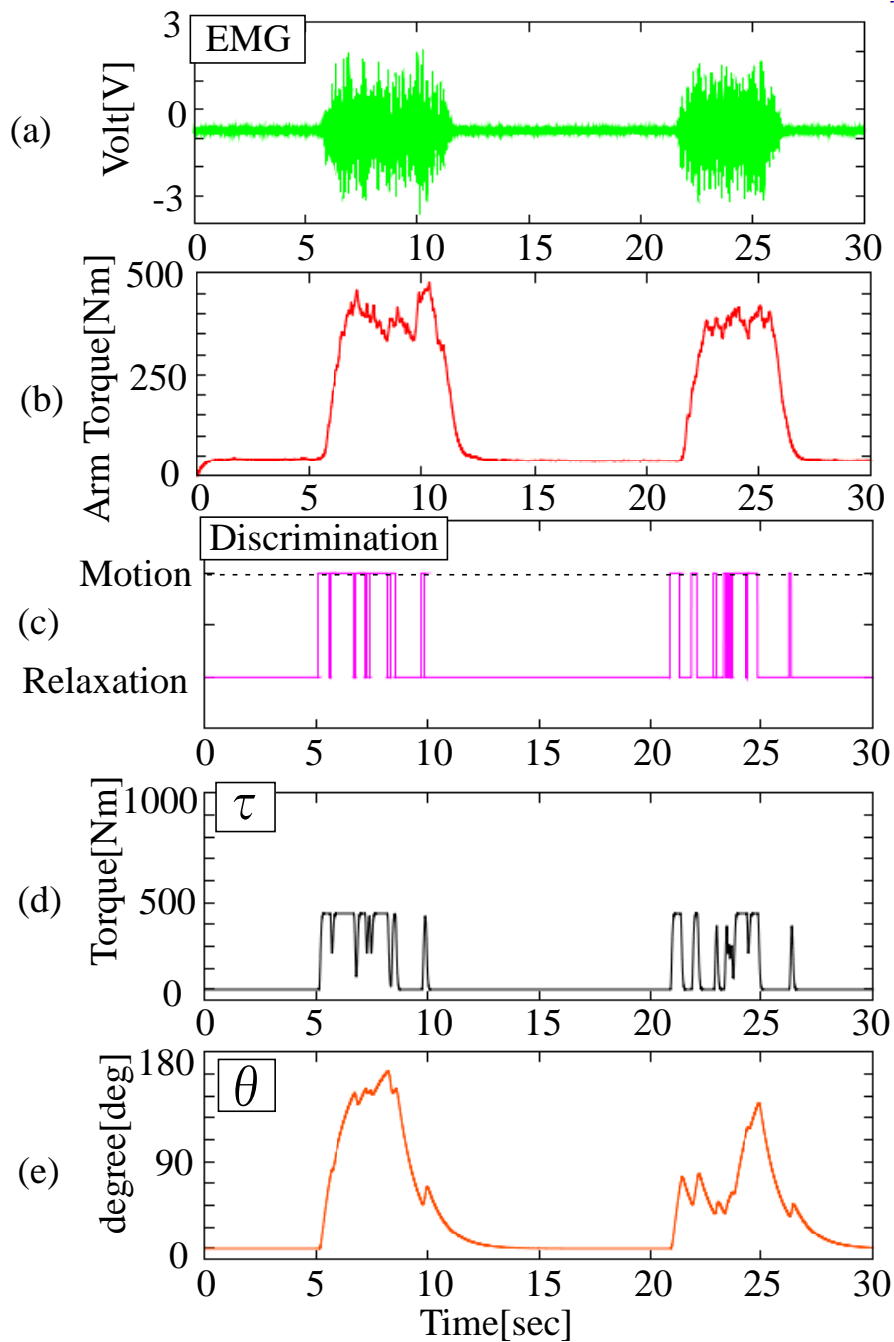


図 5.12: 運動時のロボットアーム目標角変化 (上から, 表面筋電位, 筋電から得られた関節トルク, 運動判別, 筋張力, ロボットアーム目標角)

5.6 まとめ

本章では，ロボットアームを制御する BMI システムを構築するために，まず腕の運動に関連する脳波の変化を抽出し，その判別器の生成を行った． α 波帯域と β 波帯域のパワースペクトルの左右差を 2 次元の分布にし，マハラノビスの汎距離を応用した 2 値判別手法を用いて運動を判別する判別器を生成した．そして，これらの判別結果を用いてロボットアームを制御する手法として，人の筋収縮の数値モデルを用いてパルス信号から人の関節トルクを算出する手法の提案を行った．

第6章 主成分モデルを用いた脳波筋活動モデルの構築

前章において、 α 波帯域と β 波帯域のパワースペクトルを観測する事で運動の判別を行う事が出来ることが分かった。これらの ON/OFF 信号を用いてロボットアームを制御する手法として、人の筋収縮の数値モデルを用いてパルス信号から人の関節トルクを算出する手法の提案を行った。しかし、パルス信号から関節トルクを生成する手法は使用者の運動と共にロボットアームを動かすことは出来るが、角度の維持をすることが難しかった。ロボットアームを動かす制御信号はパルス信号ではなく、運動と関連するリニアな線形信号である必要があると考えられる。したがって、本章では関節トルクと関連している筋活動と α 波および β 波との関係を主成分分析によって線形モデルの生成を行う。

6.1 主成分モデルによる脳波筋活動モデル

主成分分析とは、多変量の入力に対して、各変量を重みを付けて統合することにより、データの総合指標である主成分を算出する手法である [70]。図 6.1 のように多数の変量がグラフ上にプロットされているとする。主成分分析ではこのようなデータの広がりを情報量の大きさとみなして分散として表現し、この分散を最大にするように作られる軸を第一主成分と呼ぶ。また、第一主成分だけでは表せない広がりに対して次に分散が大きくなる方向に第一主成分と直交する軸を作り、これを第二主成分とし、以下同様に第三、第四…と軸を定義していく [71]。この性質を利用して、情報量が小さな軸を切り捨てることで無駄な情報を省き、より大きな情報の理解と処理の効率を改善することが可能である [72]。

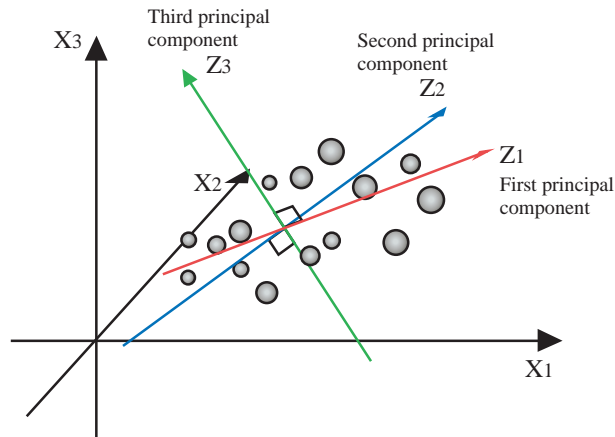


図 6.1: 主成分分析のデータの広がりを考慮した軸変換

6.2 主成分モデルの構築

6.2.1 2次元での主成分分析




図 6.2: 新しい軸への垂線




図 6.3: 軸の直交回転

2次元での主成分分析について説明する [72] . まず , 図 6.2 のように直線に近い状態で点 P_i が分布しているとする . 各点 $P_i (i = 1, 2, \dots, n)$ を z 軸に下ろした点を Z_i とする . 元の点の位置を損なわずに z 軸を定めるには , Z_i と原点の距離の 2

乗の総和が最大になればよい。

$$OZ_1^2 + OZ_2^2 + \cdots + OZ_n^2 \rightarrow \text{最大} \quad (6.1)$$

また、 z 軸上の各点を $x-y$ 座標系で表現すると (図 6.3)、 z 軸は x 軸が θ 回転した X 軸といえる。 Z_i の各点は X 軸上にあるため、 $x-y$ 座標系で表現すると、

$$Z_i = (\cos\theta)x_i + (\sin\theta)y_i \quad (6.2)$$

と表現できる。ここで $\cos\theta = l_1, \sin\theta = l_2$ と置き換えると、

$$Z_i = l_1x_i + l_2y_i \quad (6.3)$$

になる。これを行列で表すと、

$$\mathbf{z} = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_n \end{bmatrix} = \begin{bmatrix} l_1x_1 + l_2y_1 \\ l_1x_2 + l_2y_2 \\ \vdots \\ l_1x_n + l_2y_n \end{bmatrix} \quad (6.4)$$

$$\mathbf{z} = \mathbf{X} \cdot \mathbf{L} \quad (6.5)$$

となる。ここで式 (6.1) の 2 乗の総和とは z 軸上の分散を考えることに等しく、式 (6.5) の分散を最大にすることを問題とすればよい。ベクトル z の分散 (S_{zz}) をベクトルで表現すると、

$$S_{zz} = \frac{1}{n} \mathbf{z}^T \mathbf{z} \quad (6.6)$$

となる。ただし T は転置を表す。したがって、この式 (6.6) を最大となる時のベクトル \mathbf{L} を求めれば、新しい z 軸が求まる。ベクトル \mathbf{L} は三角関数なので、

$$\mathbf{L}^T \mathbf{L} = 1 \quad (6.7)$$

となり，これは式 (6.6) を最大とする問題の制約条件である．よってラグランジュの未定乗数法より，次式が求まる．

$$F = \frac{1}{n} \mathbf{z}^T \mathbf{z} - \lambda (\mathbf{L}^T \mathbf{L} - 1) \quad (6.8)$$

さらに，分散共分散行列 S は，以下の式で表される．

$$\mathbf{S} = \frac{1}{n} \mathbf{X}^T \mathbf{X} \quad (6.9)$$

式 (6.5) と式 (6.8) を式 (6.7) に適応すると，

$$\begin{aligned} F &= \frac{1}{n} (\mathbf{X}\mathbf{L})^T (\mathbf{X}\mathbf{L}) - \lambda (\mathbf{L}^T \mathbf{L} - 1) \\ &= \mathbf{L}^T \mathbf{S} \mathbf{L} - \lambda \mathbf{L}^T \mathbf{L} + \lambda \end{aligned} \quad (6.10)$$

となる．この式をベクトル \mathbf{L} について偏微分して 0 とおくと，

$$F_l = 2\mathbf{S}\mathbf{L} - 2\lambda\mathbf{L} = 0 \quad (6.11)$$

$$\mathbf{S}\mathbf{L} = \lambda\mathbf{L} \quad (6.12)$$

と表せる．この式の λ は固有値をベクトル \mathbf{L} は固有行列を表している．この固有値 λ が最大の時の固有ベクトル \mathbf{L} が第一主成分の重みとなり，主成分は，

$$z_1 = l_{11}x + l_{12}y \quad (6.13)$$

と表せる．以下固有値の大きさ順に第 2，第 3 … 成分となる．

6.2.2 N 次元での主成分分析

あるデータ $x_i (i = 1 \sim N)$ がそれぞれ n 個の要素を持っているとする．このときの主成分 z は，

$$\begin{aligned}
 \mathbf{z} &= \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{bmatrix} = \begin{bmatrix} l_{11}x_1 + \cdots + l_{1N}x_N \\ l_{21}x_1 + \cdots + l_{2N}x_N \\ \vdots \\ l_{N1}x_1 + \cdots + l_{NN}x_N \end{bmatrix} \\
 &= \begin{bmatrix} l_{11} & \cdots & l_{1n} \\ \vdots & \ddots & \vdots \\ l_{N1} & \cdots & l_{NN} \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_N \end{bmatrix} \\
 &= \mathbf{X} \cdot \mathbf{L}
 \end{aligned} \tag{6.14}$$

と表せる．この時， \mathbf{L} はデータ間の分散共分散行列の固有ベクトルである．

6.2.3 主成分モデルを用いた脳波筋活動モデル

主成分モデルを用いることでノイズを多く含んだ運動に関連する脳波の特徴量と EMG 信号を組み合わせると、主成分を算出することで、より特徴的な特徴量を算出することが出来る．この主成分は、入力データ間の分散共分散行列の固有値問題を解くことによって得ることが可能である．本研究では、この主成分分析を利用して脳波-筋活動間の線形モデルを作成する．

今、入力信号として N ヶ所の計測点より得られた μ 律動から β 波帯域の脳波のパワースペクトル $x_i (i=1, 2, \dots, N)$ 、1ヶ所の計測点から得られた筋活動 v_{emg} を与えるとする．この時の脳波と筋活動間の主成分 Z は次のように表わされる．

$$Z = l_1x_1 + l_2x_2 + \cdots + l_Nx_N + l_{emg}v_{emg} = \sum_{i=1}^N l_i x_i + l_{emg} v_{emg} \tag{6.15}$$

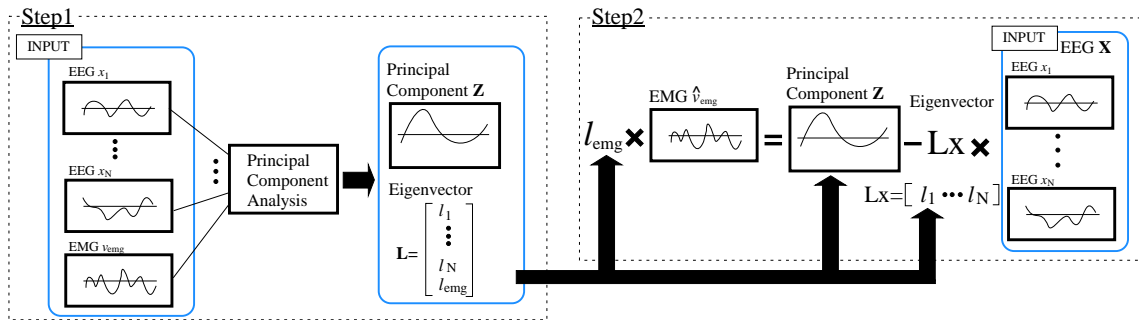


図 6.4: 脳波と筋活動から主成分モデル生成手順

ここで, l_i ($i=1,2,\dots,N$) と l_{emg} は N 個の脳波データと 1 個の筋活動の入力データ間の分散共分散行列の最大固有値に対応する固有ベクトルである．これにより, 主成分 Z は固有ベクトルを重み値とした脳波と筋活動の線形結合で表わすことが出来る．式 (6.15) において, 筋活動 v_{emg} について解くと,

$$\hat{v}_{emg} = \frac{Z - \sum_{i=1}^N l_i x_i}{l_{emg}} \quad (6.16)$$

となり, 式 (6.16) は推定筋活動 \hat{v}_{emg} の求める式となる．ここで, 脳波データと筋活動の主成分と固有ベクトルが既知の場合, N 個の脳波データから筋活動 \hat{v}_{emg} を推定する線形モデルを得ることが出来る．

式 (6.16) を用いた脳波から筋活動の推定手法の概要を図 6.4 に示す．まず, 同対象における複数点の脳波と 1 点の筋活動を入力信号として, 主成分分析を用いて脳波 - 筋活動間の線形モデル (式 6.15) を作成する (図 6.4. Step 1)．次に筋活動を未知信号として, 新たに計測した脳波のみを入力信号とすることで, 作成されたモデル (式 6.15) と式 (6.16) より, 脳波から筋活動を推定する (図 6.4. Step 2)．この手法を用いて脳波 - 筋活動間の線形モデルで, 脳波から筋活動を推定することにより, パワーアシスト装置への入力信号に用いることが出来る．次に線形モデルのパラメータの更新について述べる．




図 6.5: 逐次最小二乗法によるモデルの更新

6.2.4 逐次最小二乗法によるパラメータの更新

脳波と筋活動は時間やその時の被験者の状態と共に変化する．したがって，それらを考慮していない式(6.16)のみで推定を行うと誤差が次第に大きくなり，結果として推定不可能となってしまう．そのため作成されたパラメータを更新する必要があり，その脳波筋活動間の線形モデルの修正の手法として最小二乗法 (least-squares method, LS 法) を応用した逐次最小二乗法 (recursive least-squares method, RLS 法) を導入する [73]．最小二乗法は，多くのデータ集合から最も確からしい関係を推測する方法であり，複数の入力から，入力と出力関係をパラメトリックモデルと呼ばれる離散時間系での差分方程式に表し，パラメータを推測を行う．そして，逐次最小二乗法はリアルタイム性が高く，パラメータを修正する手法として収束速度が速いという利点を持つ (図 6.5)．

まず，式(6.16)による更新するパラメータ $\phi(k)$ を明記すると以下のようなになる．

$$\hat{v}_{emg}(k) = \phi(k)^T \hat{\eta}(k-1) \quad (6.17)$$

$$\phi(k) = [1 \ x_1(k) \ \cdots \ x_M(k)]^T \quad (6.18)$$

$$\hat{\eta}(k-1) = \left[\begin{array}{ccc} Z(k-1) & -l_1(k-1) & \cdots & -l_M(k-1) \\ l_{\hat{v}_{emg}}(k-1) & l_{\hat{v}_{emg}}(k-1) & \cdots & l_{\hat{v}_{emg}}(k-1) \end{array} \right]^T \quad (6.19)$$

ここで $\phi(k)$ は時刻 k の入力， $\hat{\eta}(k-1)$ は 1 つ前の時刻に推定されたパラメータを表す．逐次最小二乗法では，教師データ v_{emg} と推定値 \hat{v}_{emg} の誤差 $\epsilon(k)$ の 2 乗和を最小とするパラメータを逐次推定するように，ゲイン $G(k)$ を決定する．RLS の

アルゴリズムは以下の式で表される [74] .

$$\hat{\boldsymbol{\eta}}(k) = \hat{\boldsymbol{\eta}}(k-1) + G(k)\boldsymbol{\epsilon}(k) \quad (6.20)$$

$$\boldsymbol{\epsilon}(k) = v_{emg}(k) - \hat{v}_{emg}(k) \quad (6.21)$$

$$\mathbf{G}(k) = \frac{\mathbf{P}(k-1)\boldsymbol{\phi}(k)}{\lambda + \boldsymbol{\phi}^T(k)\mathbf{P}(k-1)\boldsymbol{\phi}(k)} \quad (6.22)$$

$$\mathbf{P}(k) = \frac{1}{\lambda} \{\mathbf{P}(k-1) - \mathbf{C}\} \quad (6.23)$$

$$\mathbf{C} = \frac{\mathbf{P}(k-1)\boldsymbol{\phi}(k)\boldsymbol{\phi}^T(k)\mathbf{P}(k-1)}{\lambda + \boldsymbol{\phi}^T(k)\mathbf{P}(k-1)\boldsymbol{\phi}(k)} \quad (6.24)$$

ここで、 \mathbf{P} は入力分散共分散行列であり、初期値 $\mathbf{P}(0)$ 、 $\boldsymbol{\eta}(0)$ は PCA より算出する。また、 λ は可変忘却要素である。本研究では、入力信号を脳波、出力信号を筋活動としているため、式 (6.16) の脳波 - 筋活動モデルは時間と共に動特性が変化する時変システムと考えることが出来る。そのため、可変忘却要素 λ を与えることで、過去の入力信号の影響を減らすことにより、適応処理を実現する。この可変忘却要素 λ は以下の式により定義される [74] .

$$\lambda(k) = \frac{1}{2} \left\{ \mu(k) + \sqrt{\mu(k)^2 + 4\xi(k)} \right\} \quad (6.25)$$

$$\mu(k) = 1 - \xi(k) - \frac{\epsilon^2(k)}{\mathbf{I}^*} \quad (6.26)$$

$$\xi(k) = \boldsymbol{\phi}^T(k)\mathbf{P}(k-1)\boldsymbol{\phi}(k) \quad (6.27)$$

ここで、 \mathbf{I}^* は、任意で指定可能なパラメータであり、推定の追従性と安定性を調節することが可能である。

6.2.5 パラメータ更新のための教師信号

健康者や、力は衰えているが筋活動の生成が出来る人は直接実際の筋活動を用いることができるため、筋活動の推定は必要ない。しかし、運動神経に障害を持つ筋活動の生成が困難な障害者の場合、教師データである筋活動 $v_{emg}(k)$ を用いることは出来ないため、脳波から筋活動を推定する別の情報を用いて RLS で更新す

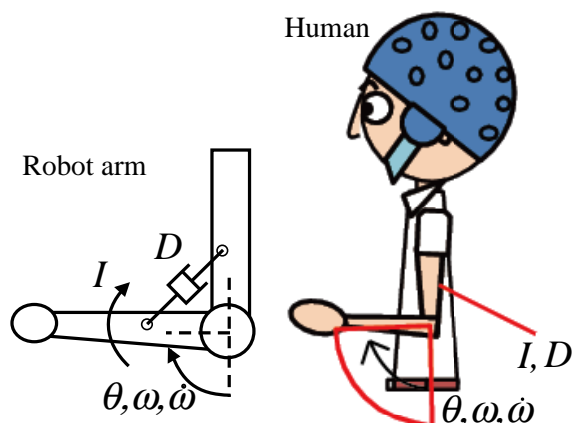


図 6.6: 人の肘関節のアドミッタンスモデル

る必要がある．そこで，本研究では人の腕を図 6.6 に示すような慣性モーメントとダンパーで構成される Admittance モデルに近似し，人間の運動から関節の駆動トルクを推定し，その推定された駆動トルクを実際の筋活動として教師信号として利用する．

先行研究の拡張 Admittance 制御によるパワーアシスト理論 [67] によると，パワーアシストは式 (3.9) の筋活動 v_{emg} から計算された肘のトルク τ を用いて目標角速度 ω ，目標角加速度 $\dot{\omega}$ を算出し，ロボットアームに与えることで実現される．この時，肘関節のトルクと目標角速度・角加速度の関係式は以下のように表すことが出来る．

$$\tau - \tau_0 = I\dot{\omega} + D\omega \quad (6.28)$$

$$\tau_0 = b\tau_{max} \sin \theta \quad (6.29)$$

ここで， τ_{max} は試行中に得られた肘の最大トルク， I と D は人間と外骨格ロボットの仮想慣性モーメントと仮想ダンピング係数である．また， τ_0 は維持時の関節トルクを表わしており， b は維持時の関節トルクと最大関節トルクの関係を表す定数である．この維持時の関節トルク τ_0 内の係数 b の決定に関しては，先行研究の文献 [67] を参考に 0.8 とした．本研究では，図 6.6 に示すような外骨格を装着していない場合には， I と D はそれぞれ人間の肘関節の慣性モーメントとダンピング

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

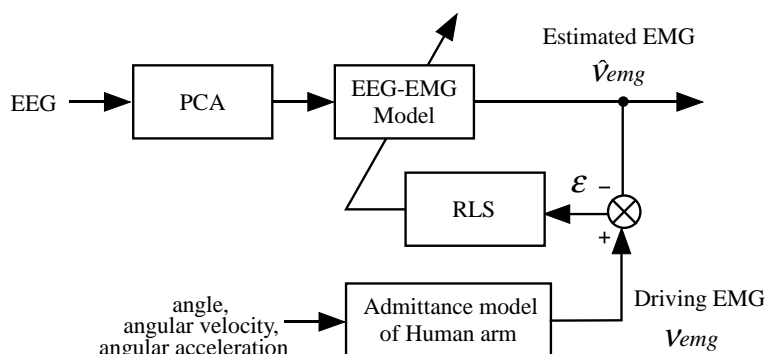


図 6.7: 筋活動推定およびパラメータモデルのブロック図

係数として入れ替えることにより，人間の肘関節を Admittance モデルとして見なし，パワーアシスト理論をそのまま適用することができる．

脳波から筋活動を推定するための処理手順を図 6.7 に示す．まず，脳波データ (EEG) は PCA を介して得られた脳波-筋活動モデルに代入され，推定筋活動を得ることが出来る．次に，RLS の教師信号の筋活動 v_{emg} は肘関節の角度・角加速度・角加速度を用いて式 (3.9)，式 (6.28)-(6.29) より，

$$v_{emg} = \frac{\tau_0 + I\dot{\omega} + D\omega + B}{A} \quad (6.30)$$

となる．肘の関節角度 θ は，肘に取り付けられたエンコーダまたはポテンシオメータより得ることが可能であるため， θ から角速度 ω ，角加速度 $\dot{\omega}$ の算出ができ，筋活動の推定が可能となる．この教師信号を RLS に与えることにより，脳波-筋活動モデルの更新を行う．

6.3 脳波から筋活動推定の実験

6.3.1 脳波および筋電位計測

本実験はあらかじめ前橋工科大学のインフォームドコンセントにおける倫理委員会の了承の下で，被験者を 20 代の健常な右利きの男性 3 名として，被験者に対して実験内容を十分に説明し，脳波・筋電位計測の同意を得た．被験者は図 6.8 に




図 6.8: 主成分モデル作成のための脳波・筋電位計測環境

示すように目を開けて椅子に座り、手を回外位の状態で重りを持ち、肩は床と垂直な状態で肘関節の約 90 度まで屈曲、屈曲状態での維持、および伸展運動を行う。また、被験者の左腕の肘関節角度をポテンショメータを用いて計測し、全てのデータの記録にはデータロガーを用い、サンプリング周波数を 1000 Hz とした。

この実験では、被験者は屈曲伸展運動を 1 回行う場合と 2 回行う場合の 2 パターンの試行を行い、音や光などの刺激による脳波への影響を無くすため、これらの運動は被験者の任意のタイミングで行った。脳波計測点は国際 10-20 法電極配置に基づき、運動に関連する脳の運動野付近の C_3 , F_3 , C_4 , F_4 の 4 点 (図 6.8) として、それぞれ耳朶 (A_2) との差動増幅を行った。また、アース電極は額とした。同時に、左腕の上腕二頭筋を計測点として筋電位計測を行い、筋電位のアース電極は左手首とした。

脳波と筋電位の増幅アンプには g.BSamp (g.tec 社) を使用した。さらに、脳波の電極には g.LADYbird (g.tec 社) のアクティブ電極を使用した。アクティブ電極は、電極側でインピーダンス変換アンプを内蔵することにより、増幅アンプに直接つなげるパッシブ電極比べて皮膚と電極間のインピーダンスの影響を無くし、アーティファクトを抑えることが出来る。このアクティブ電極で脳波を取得することにより、頭皮上の電極接触インピーダンスの影響や体を動かした際のコード

の揺れによるノイズの混入を防いでいる。

6.3.2 信号の処理手順

信号の処理の流れを図 6.9 に示す。本実験ではオフラインで筋活動推定を行い、計測した脳波 (Raw EEG) を 256 点の窓幅 (256 msec)、50 % のオーバーラップで高速フーリエ変換 (FFT) を行い、7-30 Hz のパワースペクトルを算出した。これにより、128msec ごとに各周波数帯域のパワースペクトルを得ることができ、周波数分離することで体動などの影響で発生する低周波領域 (5 Hz 以下) のノイズや生体アンプでの電源ノイズ (50 Hz) を分離することが出来る。脳波は各計測点 (C_3, F_3, C_4, F_4) の μ 波帯域 (8-13 Hz) と β 波帯域 (13-30 Hz) の低周波領域を含んだ 7-30 Hz のパワースペクトルを入力信号とした。

本実験では、脳波パワースペクトルと肘関節の Admittance モデルから得られた推定筋活動 \hat{v}_{emg} を用いて、PCA で窓幅 4096 msec の 50 % のオーバーラップ (≈ 0.5 Hz) に脳波-筋活動モデルの生成を行う。ここで、モデルの生成の窓幅を 4096 msec にするのは、肘関節を伸ばした状態から 90 度屈曲状態までの脳波と筋活動および関節トルクの変化をモデルに反映させるためである。次に、入力信号の脳波と筋活動は変化の特性が時変であると考えられるため、モデルの更新が必要となる。今回、各計測点 (C_3, F_3, C_4, F_4) のパワースペクトルから推定された筋活動 \hat{v}_{emg} と、被験者の肘関節の角度から推定された筋活動 v_{emg} と比較し、RLS を用いてパラメータを更新し、筋活動を推定していく。また、結果の比較のために計測された筋活動 v_{emg} は整流平滑化 (20 点の移動平均 + 0.7 Hz の一次ローパスフィルタ) を行い、推定された筋活動 \hat{v}_{emg} もローパスフィルタ (5 点 (窓幅 640msec) の移動平均) を用いて平滑化し、その相関係数による評価を行う。

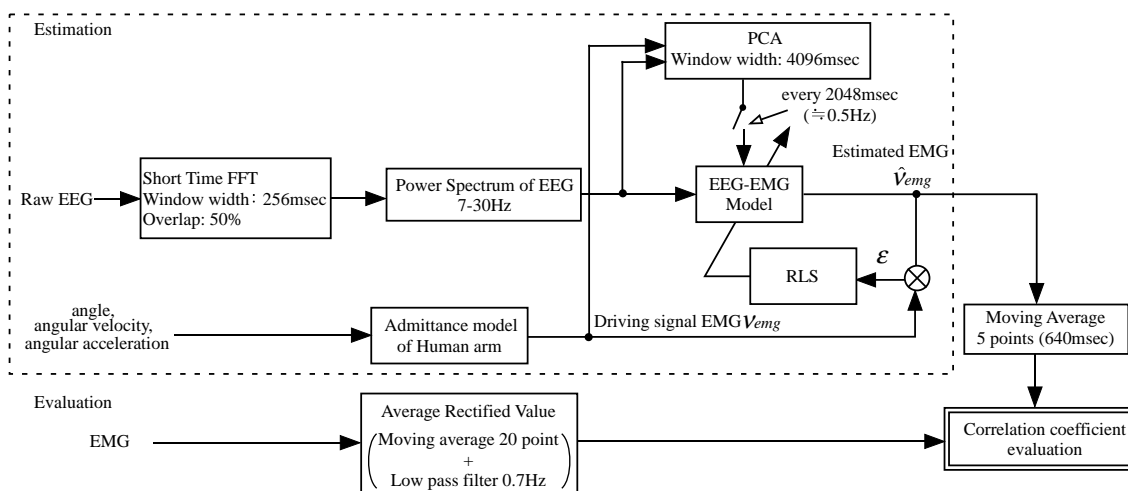


図 6.9: 筋活動推定のための信号処理手順

6.3.3 推定結果および考察

提案した手法を確認するため、被験者 3 人での検証実験を行った。被験者 A が 1 試行の肘の屈伸運動を行った時の筋活動推定結果を図 6.10 に示す。ここで、実線（青線）は計測された筋活動、破線（赤線）は脳波から推定された筋活動を表わしている。計測された筋活動が大きく増加する瞬間から被験者 A は肘の屈曲運動 (Flexion) をし始め、一定時間の維持運動 (Keeping) を行った後、筋活動が大きく降下するタイミングに伸展運動 (Extension) をしている。この屈曲運動から伸展運動までの区間を運動状態 (Motion) とし、それ以外の区間を安静状態 (Rest) とした。この図から、推定された筋活動は計測された筋活動が大きくなると共に上がり、逆に小さくなると下がっていることが分かり、相関係数 r は 0.94 となった。また、被験者 A はこの 1 試行の肘の屈伸運動を 10 試行行い、その相関係数は平均で 0.85 となった。

そして、図 6.11 に被験者 A の連続して 2 回の屈伸運動を 10 試行行った時の相関係数が最も高かった時の推定結果を示す。このうち、1 試行目の屈伸運動 (Motion) では相関係数は 0.79 となり、2 回目では 0.88 と高くなった。そして、2 回の屈曲運動と安静状態 (Rest) を含めた全体の計測筋活動との相関係数は 0.89 であった。また、この 2 試行の屈伸運動 10 試行の全体の相関係数の平均は 0.85 となった。

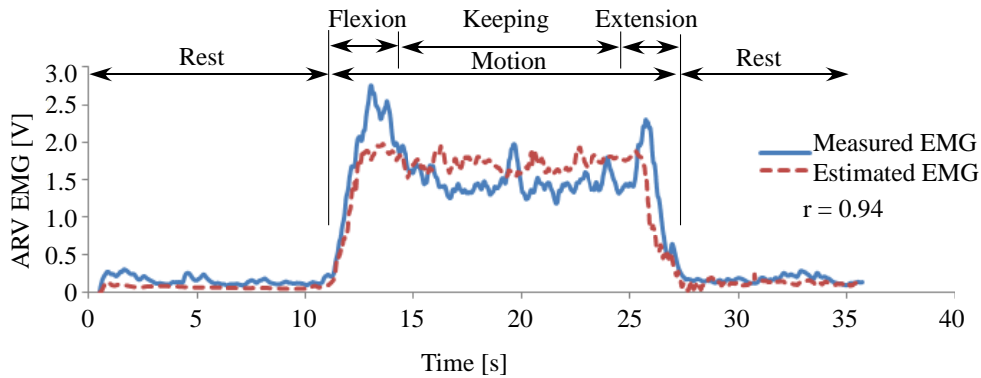


図 6.10: 被験者 A の 1 回の屈曲伸展運動の推定結果




図 6.11: 被験者 A の 2 回の屈曲伸展運動の推定結果

次に、図 6.12 に被験者 B が肘の屈伸運動を 1 回行った時の相関係数が最も高い推定結果を示す。この時の相関係数は 0.83 であり、6 試行の計測を行った時の計測筋活動との相関係数の平均は 0.75 だった。また、図 6.13 は、2 試行の肘の屈伸運動を行った時の結果で、1 試行目の屈伸運動 (Motion) の相関係数は 0.83 となり、2 試行目では 0.85 であることから、1 試行目より 2 試行目の相関係数が上がっていることが分かる。そして、2 回の屈曲運動と安静状態 (Rest) を含めた全体の相関係数は 0.86 であった。さらに、これらの推定筋活動の昇降は計測された筋活動と同じタイミングであることが分かる。また、6 試行の計測を行った時の相関係数の平均は 0.79 であった。

次に、被験者 C の実験結果について述べる。被験者 C では 8 試行分のデータを解析した。その結果、肘の屈伸が 1 試行の場合、相関係数の平均は 0.72 となり、最高で 0.80 であった。その時の結果を図 6.14 に示す。また、2 試行連続屈伸した場合には、1 試行目の相関係数は 0.55、2 試行目は 0.78 となり、ほかの被験者と同様に 2 試行目の相関係数が高いことがわかった。その結果を図 6.15 に示す。2 回の




図 6.12: 被験者 B の 1 回の屈曲伸展運動の推定結果




図 6.13: 被験者 B の 2 回の屈曲伸展運動の推定結果

屈曲運動と安静状態 (Rest) を含めた全体の相関係数の平均は 0.67 となり、最高で 0.76 となった。被験者 C では、計測された筋活動に比べて、少し遅れて上昇し、2 試行目の推定された筋活動は計測された筋活動とほぼ一致している。また、筋活動の変化が安定している時は、推定筋活動も安定していることが見られた。

これらの結果を表 6.1 に、3 人の被験者の肘の屈曲・伸展運動時の脳波から筋活動を推定した結果をまとめる。また、推定の精度の数値評価には計測筋活動の積分値 S_{emg} と推定筋活動の積分値 $S_{estimate}$ の差を計測筋活動の積分値で次式のように割合を表わし、その平均を算出した。

$$error = \frac{|S_{estimate} - S_{emg}|}{S_{emg}} \times 100[\%] \quad (6.31)$$

その結果、計測した筋活動と推定した筋活動の相関係数は最高で 0.94 となった。そして、それぞれの積分値の差の割合の平均は被験者 A と C は 10 % 以下となり、被験者 B において平均値が最大の 10.5 % となった。本手法により、安静状態からの




図 6.14: 被験者 C の 1 回の屈曲伸展運動の推定結果




図 6.15: 被験者 C の 2 回の屈曲伸展運動の推定結果

屈曲，屈曲状態の維持，維持状態からの伸展と，時間と共に状態が変わる場合でも，推定可能であり本手法の有効性が示されたと言える．そして，図 6.16 に各被験者が 2 試行続けて行った時の 1 回目と 2 回目の屈曲運動のそれぞれの相関係数の平均を示す．被験者 C において 1 回目の試行より 2 回目の方が相関係数が高くなっており，有意差が見られた．これは，計測筋活動と推定筋活動との誤差が肘の角度・角加速度から得られた教師信号に基づいた逐次最小二乗法によりパラメータの値が補正され，推定精度が向上したと考えられる．また，被験者 A と B では 1 試行目および 2 試行目がそれぞれ推定精度が高かったため，パラメータの補正が小さかったと考えられる．

6.3.4 まとめ

本章では，脳活動と運動情報の線形モデルと学習手法を使用することで，脳波からの筋活動推定を試みた．まず，肘関節の屈曲運動時における μ 波および β 波

表 6.1: 計測筋活動と推定筋活動の相関係数および誤差

		Subject A	Subject B	Subject C
Once Elbow f/e	Mean	0.85	0.76	0.72
	(SD)	(0.04)	(0.06)	(0.08)
R	Max	0.94	0.81	0.80
Error [%]	Mean	9.77	10.50	5.51
	(SD)	(6.48)	(6.36)	(3.72)
Twice Elbow f/e	Mean	0.85	0.793	0.66
	(SD)	(0.04)	(0.05)	(0.08)
R	Max	0.89	0.86	0.76
Error [%]	Mean	5.30	6.42	4.45
	(SD)	(5.64)	(2.41)	(2.28)




図 6.16: 2 回の屈曲伸展運動一回目と二回目の試行の相関係数平均値の比較

のパワースペクトルの変化を主成分分析を用いて、筋活動との線形モデルを作成した。そして、その線形モデルを逐次最小二乗法で更新する際の教師信号として、肘の角度、角速度、角加速度を用いた人の肘の Admittance モデルから推定された筋活動を用いた。その結果、脳波から推定された筋活動は計測された筋活動との相関係数が最大 0.94 となり、試行を増やすことで低い推定精度を向上させることができ、脳波を用いたパワーアシストの有効性を示した。

第7章 運動時における α 波および β 波 の周期パワースペクトルの変 化の解析

前章において、 μ 波および β 波のパワースペクトルの変化と筋活動を主成分分析を用いて線形モデルを作成し、逐次最小二乗法を用いてモデルのパラメータを更新することで筋活動の推定を行うことが出来た。線形モデルを作成する際に重要となるのは、入力信号と出力信号が相関性を持つ信号であることと、入力信号の試行間での差が小さいことである。これらの二つのことが保たれないと逐次最小二乗法によって更新されたパラメータは発散しやすく、かつ収束しにくいと言う欠点を持つ。そのため、本章ではまず、被験者が運動を行った時の筋活動と脳波の試行間での差を相関係数で評価した後、運動した時の脳波のパワースペクトルの特徴を新たな解析手法で解析し、筋活動との相関性のある入力信号を脳波から抽出を行う。そして、新たに得られた脳波の特徴量と前章の主成分モデルを作成し、関節トルクの推定を行う。

7.1 試行間の筋活動と脳波の解析

7.1.1 筋電位及び脳波計測，信号処理

本実験は、被験者を20代の健常な男性1名とし、前章の実験同様、あらかじめ実験内容を説明して、同意を得た上で行った。被験者は図7.1に示すように椅子に座り、目を開けた状態で腕の屈曲、及び伸展運動を行う。全てのデータの記録に

はインターフェースボード (HRP Interface Board 07-0003-1 (有) 図工製) で AD 変換し, Linux の RTAL でサンプリング周波数を 1000 Hz とした. 被験者は左腕をロボットアームのすぐ横には配置し, 手でロボットアームの先端に取り付けられた棒を掴むようにしてもらった. さらに, 上腕二頭筋の筋電位を取得し, その筋活動の大きさに応じてロボットアームの角度は変動する. なお, 今回はこのロボットアームの目標角 θ は次の式に表わされる.

$$\theta = A \cdot v_{emg-arv} \quad (0 < \theta < 90[deg]) \quad (7.1)$$

ここで, $v_{emg-arv}$ は得られた筋電位を全波整流した後, 50 点の移動平均と 7 Hz の 1 次ローパスフィルタを通した整流平滑化 (ARV: Average Rectified Value) 行った筋活動である. これは被験者が筋肉を動かした際に発生する力の大きさを示している. A は比例定数であり, 被験者が筋活動を使ってロボットアームを 90 度まで上げられるように値の調節を行う. また, ロボットアームは P 制御によって制御されており, 一定角速度以上でないように電圧制限も制御で行っている.

被験者がロボットアームを上げるタイミングは音によって提示され, そのタイムチャートを図 7.2 に示す. まず, 15 秒のリラックス (初回のみ 5 秒) の後, 0.1 秒のビープ音が鳴り, その 3 秒後再びビープ音が鳴る. それと同時に被験者はロボットアームの角度を上げ, 3 秒後再びビープ音が 2 回なり, 被験者は力を入れることを止め, ロボットアームを下げる. この動作を 20 回繰り返し行う.

脳波の計測ヶ所には, 運動に関連している国際 10-20 法の F_3, C_3, F_4, C_4 の 4 点であり, 増幅アンプには g.BSamp (g.tec 社) を使用し, バンドパスフィルタの通過帯域を 0.5-100 Hz に設定した. さらに, 脳波の電極には g.LADYbird (g.tec 社) のアクティブ電極を利用した. アクティブ電極で取得することにより, 頭皮上の電極接触インピーダンスの影響や体を動かした際のコードの揺れによるノイズの混入を防いでいる.

計測された脳波には, 前処理として瞬きやアーティファクトを除去するために各計測点の平均値を基準とする CAR(Common Average Reference) を行った. そ




図 7.1: 計測環境

して、脳波信号を窓幅 512 msec とした高速フーリエ変換を行う。一つの窓によって区切られた脳波信号は低周波領域のサイドロープの影響を減らすため、一つの窓幅の平均値を基準として、さらにガウス窓を通す。この短い窓幅 (512 msec) で高速フーリエ変換を 50 msec ごと (200 Hz) に行い、時系列データのパワースペクトル値の算出を行う。これにより、50 msec ごと (200 Hz) に各周波数帯域のパワースペクトルを得ることができ、体動などの影響で発生する低周波領域 (5 Hz 以下) のノイズや生体アンプでの電源ノイズ (50 Hz) を分離することが出来る。脳波は各計測点 (C_3 , F_3 , C_4 , F_4) の α 波帯域 (7-15 Hz) と β 波帯域 (15-35 Hz) のパワースペクトルを算出した。さらに、得られた α 波帯域 (7-15 Hz) と β 波帯域 (15-35 Hz) の時系列パワースペクトルに対して 1 Hz のローパスフィルタに通した。

7.1.2 20 試行の計測結果

運動開始する 3000 msec 前 (運動準備) から、運動終了してから 3000 msec まで切り出した 20 回の筋電位に ARV を施した筋活動の結果を図 7.3 に示す。3000

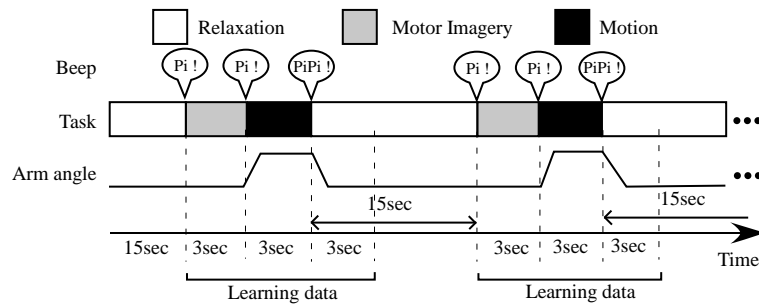


図 7.2: 計測タイムチャート


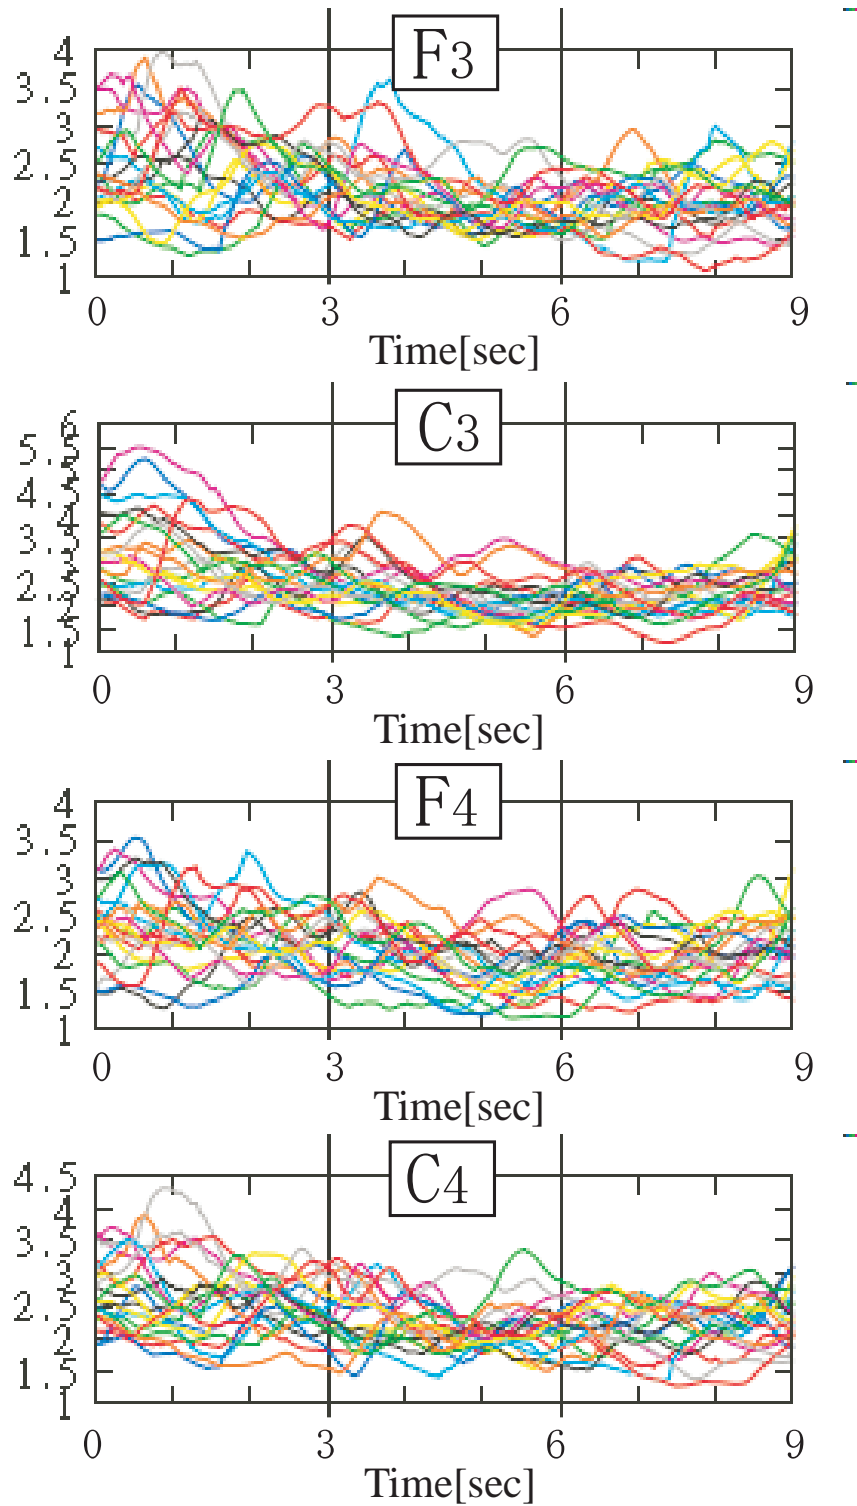


図 7.3: 20 試行の筋活動

msec の音提示から数百 msec 後に筋活動が上昇しており、被験者がリラックス状態から運動状態かに入ったことが分かる。そして、6000 msec の音提示から筋活動が下がっており、運動状態からリラックス状態に入ったことが分かる。

次に、この筋活動と同じ時間の脳波 (α 波帯域と β 波帯域) のパワースペクトルの変動を図 7.4 (α 波) と図 7.5 (β 波) に示す。この結果、Fig.7.3 のように同様の筋活動の動きを示しているのに対して、脳波の α 波と β 波は一様の変化が見られないことが分かる。そのため、このような複雑な変化の中から同様の変化を示している信号を相関の観点から解析を行った。

α wave図 7.4: 20 試行の α 波のパワースペクトル

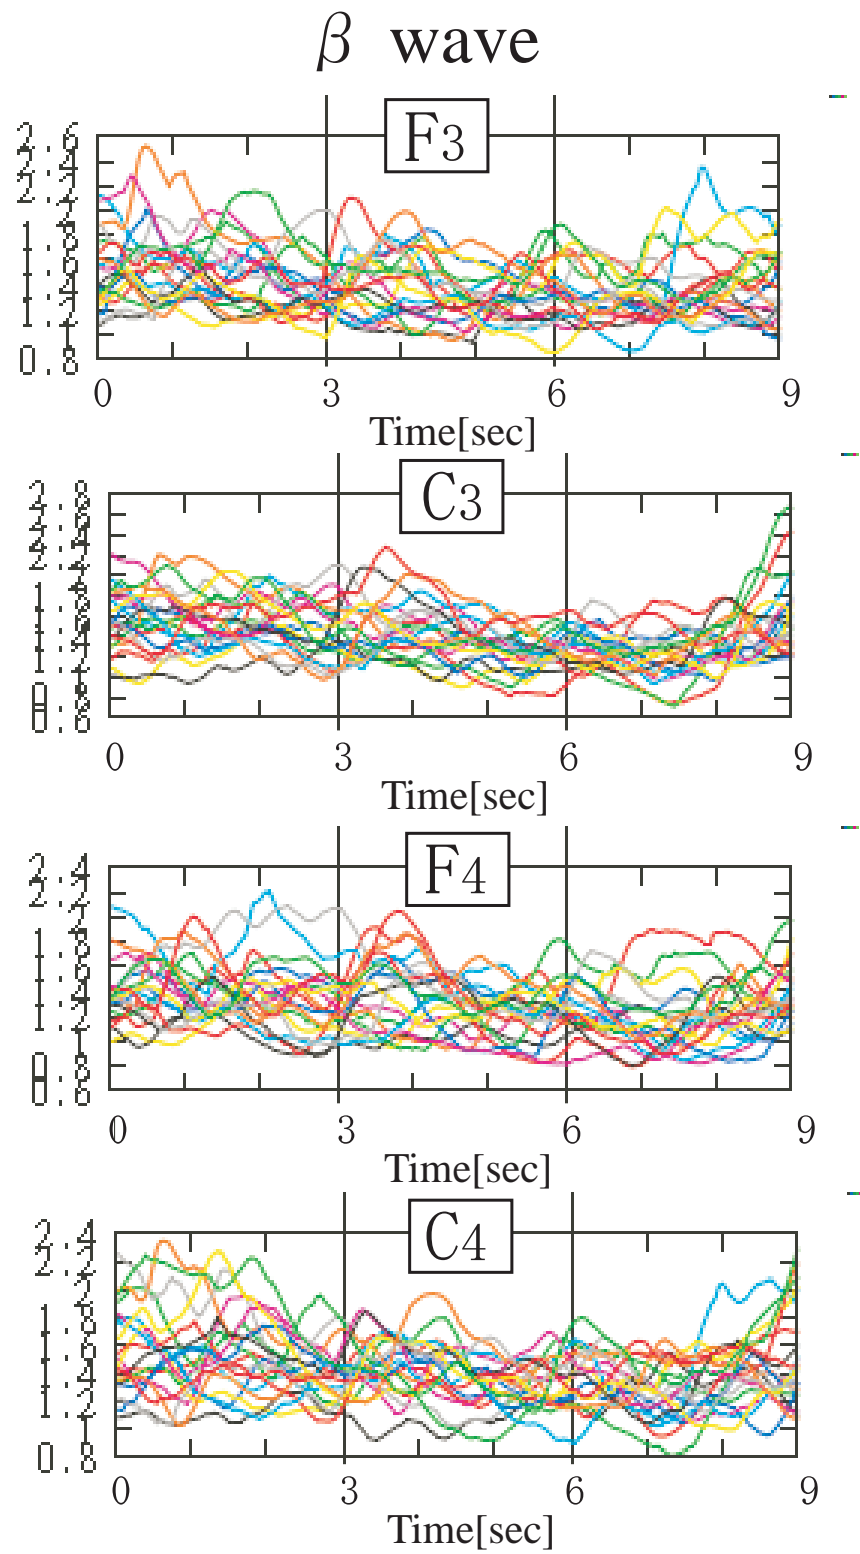


図 7.5: 20 試行の β 波のパワースペクトル

7.1.3 相関係数に基づいた解析

計測において1試行ごと α 波と β 波の変化は一定の変化を示すものではなかった。そこで、各計測点で1試行ごとの相関関係の調査を行った。

相関係数とは2つの信号の間の相関を示す統計学的指標である。単位は無く、 -1 から 1 の間の実数値をとり、 1 に近いときは2つの確率変数には正の相関があるといい、 -1 に近ければ負の相関がある。 0 に近いときはもとの確率変数の相関は弱い。 1 もしくは -1 となる場合は2つの確率変数は線形従属の関係にある。その相関係数 r を求める式は以下ようになる。

$$r = \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_{1i} - \bar{x}_1)^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{2i} - \bar{x}_2)^2}} \quad (7.2)$$

ここで、 x_{1t} と x_{2t} ($t = 1 \cdots n$) は入力信号、 \bar{x}_1 と \bar{x}_2 はそれぞれの平均を表わしている。これらを全信号間で行うことにより、相関行列を得ることが出来る。

図7.6に各計測点の試行ごとの相関行列から、試行間の相関係数 r が $-0.3 \leq r$ 、 $0.3 \leq r \leq 0.5$ 、 $0.5 \leq r$ の3つに色別のマーカーを付けた。赤マーカーの $-0.3 \leq r$ は信号間で負の相関を持った信号であり、黄色マーカーの $0.3 \leq r \leq 0.5$ は信号間である程度正の相関を持っている。そして、青マーカー $0.5 \leq r$ は信号間で強い正の相関を持っていることを示している。また、同一信号間では必ず相関は 1 となるのでマーカーは付けておらず、相関行列は対称行列となるため転置成分にはマーカーは付けていない。

図7.6から分かるように、腕を曲げるという同一試行に対して、脳波信号で正の相関を持つ信号、負の相関を持つ信号、無相関の信号が混在していることが分かる。このことから、実際の運動を行った時の脳波のスペクトルの時間変化は増減を繰り返しており、運動と脳波の直接的な関連性は見られない。運動を行った時、瞬間的に脳波のスペクトルは減衰するが、再び増加することが繰り返され、その特徴を見るには強いローパスフィルタや積分などが必要である。このような強いローパスフィルタなどを通してしまうとその性質上、時間の遅延や情報の損失が非常に大きくなってしまいう問題がある。

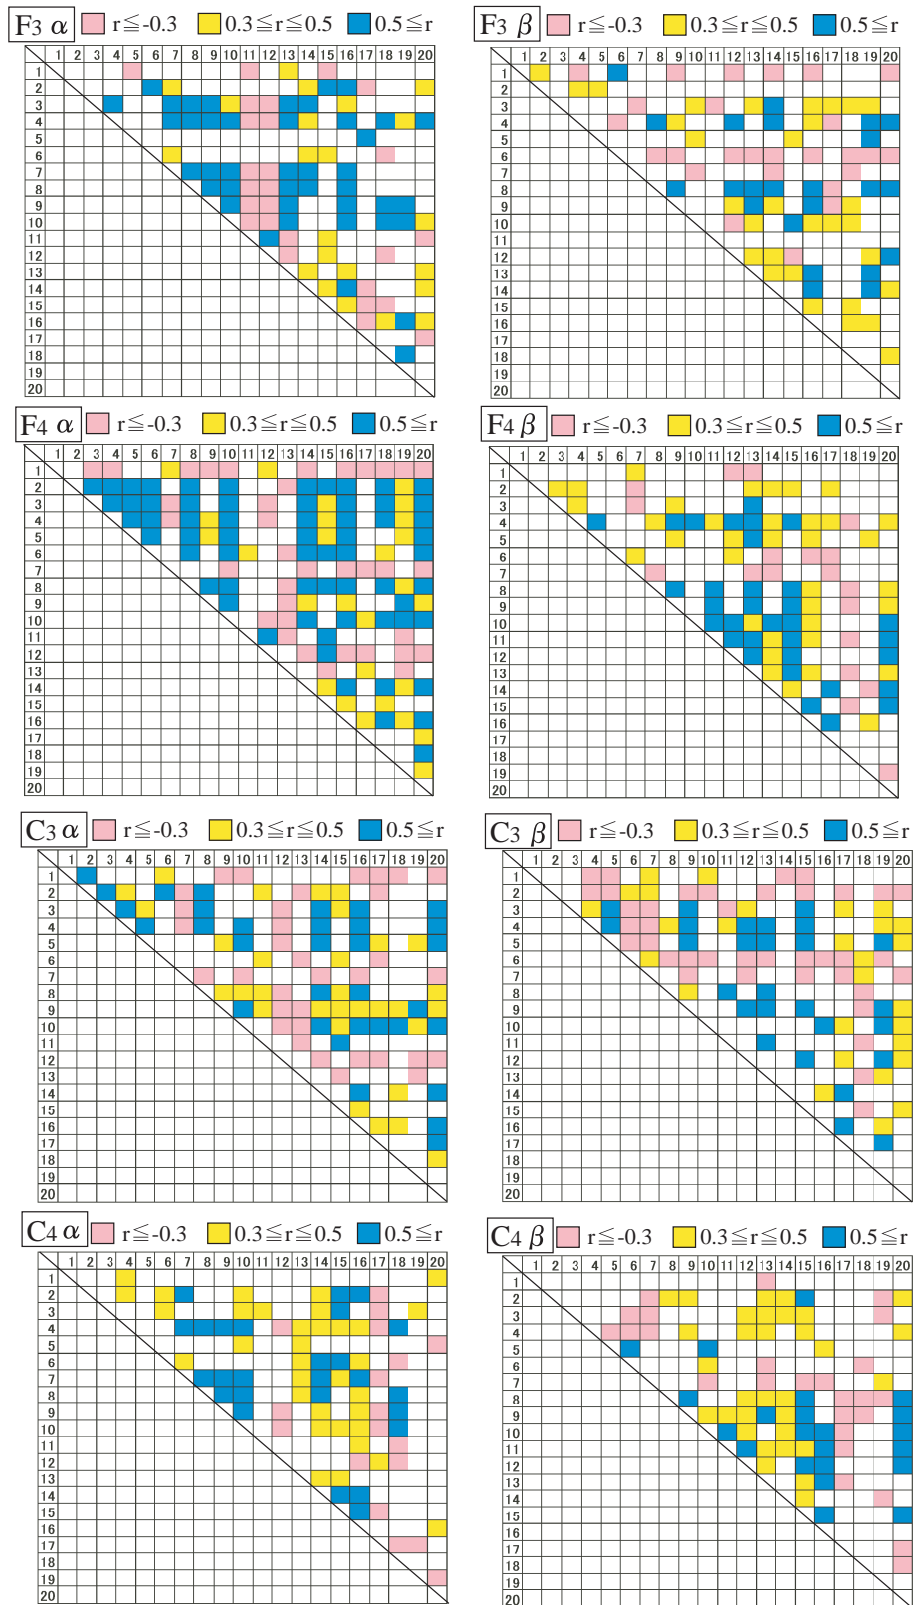


図 7.6: 各計測点の相関係数別にマーカー付

7.2 筋活動と線形関係を持つ脳波の特徴量の抽出

前節から，脳波のパワースペクトルは人の関節トルクに関連する筋活動との相関関係が見られないことと試行ごとの信号の形が複数のパターンに別れることが分かった．これは，運動の有無を判別するには問題にならないが，線形モデルを生成するには問題となることから，運動に線形関係を持つ脳波の特徴量の抽出を行う必要がある．そこで，本研究ではパワースペクトルの周期の変化に着目し，脳波の特徴量の算出を行う．

7.2.1 振幅の周期性の抽出

これまでの脳波の解析の中で，閉眼時において α 波が大きく出てくることが分かっている（図 4.2）．そして，開眼時には α 波が減衰することが分かっているが，閉眼時のパワースペクトルは常に大きい訳ではなく，1-2 Hz の周期で増減している（図 7.7.(a)）．図 7.7.(b) は閉眼時のパワースペクトルを横軸に α 波，縦軸に β 波で 2 次元プロットした図であり，図中の矢印はプロットされた点の時間変化による移動方向を表している．このように，脳波の短時間フーリエ変換によるパワースペクトルは一定の値ではなく，周期性を持っており，本研究ではこのような変化が運動時にも変化があると仮定し，解析を行った．

7.2.2 ロボットアーム操作時の脳波計測

ロボットアーム操作時の脳波を得るために，前回と同様に図 7.1 に示すような環境で計測する．今回の計測ではロボットアームは，上腕二頭筋の筋活動によって動き，拡張 Admittance 制御によるパワーアシスト理論 [67] に基づいて，1~2kg の重りを持っているような負荷感覚を与えるようにしている．なお，今回被験者を 20 代の健常な男性 5 名（被験者 A~E）とした．

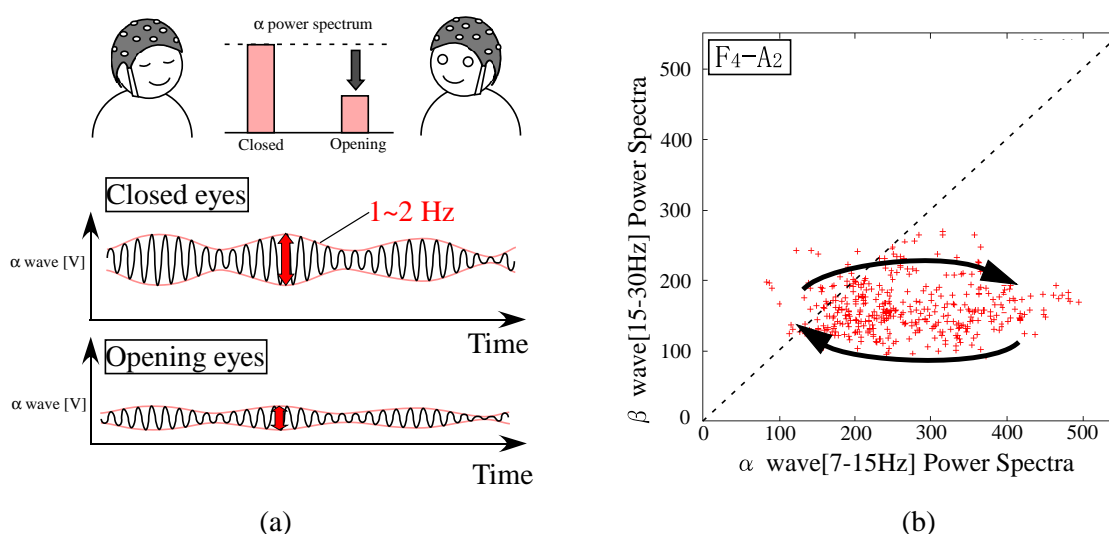


図 7.7: (a) 波の減衰と周期性 (b) 閉眼時のパワースペクトルの2次元プロット (横軸： α 波，縦軸： β 波)

7.2.3 脳波計測と処理手法

脳波の計測箇所は，運動に関連している国際 10-20 法の F_3 , C_3 , P_3 , C_z , F_4 , C_4 , P_4 の 7 点とし，増幅アンプには g.BSamp (g.tec 社) を使用し，サンプリング周波数を 1000 Hz とした．さらに，脳波の電極には g.LADYbird (g.tec 社) のアクティブ電極を使用した．アクティブ電極により，頭皮上の電極接触インピーダンスの影響や体を動かした際のコードの揺れによるノイズの混入を防いでいる．また，予備実験においてロボットアーム動作時にモータから発生するノイズは脳波には混入していないことが確認されている．

次に脳波の信号処理手法として，脳波信号を窓幅 512 msec とした短時間フーリエ変換 (Short-time Fourier transform: STFT) を行う．1 つの窓によって区切られた脳波信号は低周波領域のサイドロープの影響を減らすため，1 つの窓幅の平均値を基線とし，さらにガウス窓に通す．この短い窓幅 (512 msec) で高速フーリエ変換を 10 msec ごと (100 Hz) に行い，時系列データのパワースペクトル値を算出する．これにより，10 msec ごとに各周波数帯域のパワースペクトルを得ることができ，体動などの影響で発生する低周波領域 (5 Hz 以下) のノイズや生体アンプ

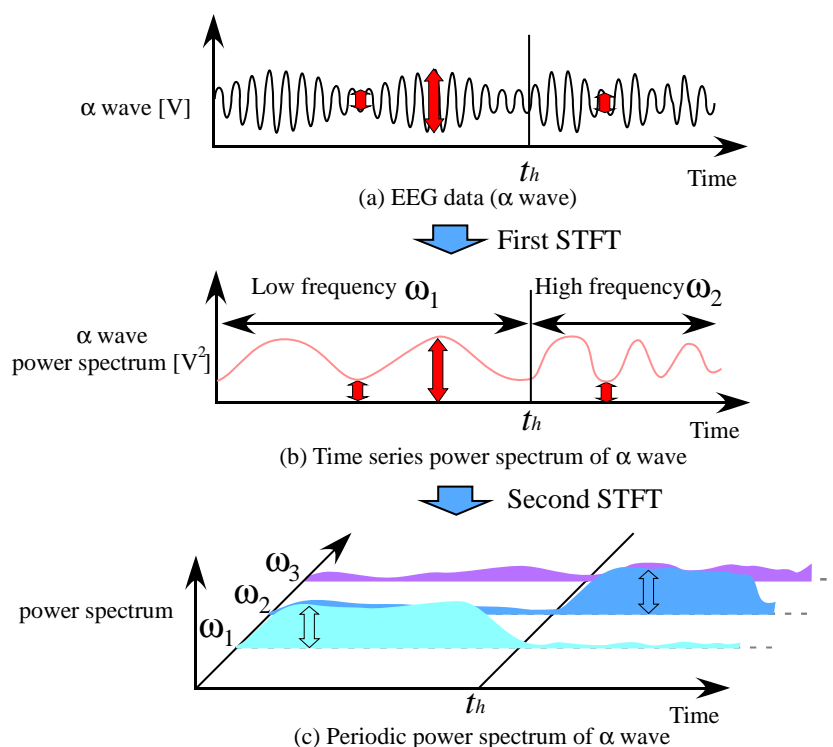


図 7.8: 2 回の短時間フーリエ変換による周期パワースペクトルの算出

での電源ノイズ (50 Hz) を分離することが出来る。脳波は各計測点 ($F_3, C_3, P_3, Cz, F_4, C_4, P_4$) の α 波 (7-15 Hz) と β 波 (15-35 Hz) の計 14 個のパワースペクトルを算出する。

次に、 α 波 (7-15 Hz) と β 波 (15-35 Hz) のパワースペクトルの周期の変化を観測するために、得られた時系列パワースペクトルデータに対し、再び STFT を行う。その流れを図 7.8 に示す。まず、図 7.8.(a) のような α 波に対して STFT を行うと、図 7.8.(b) の時系列パワースペクトルを得ることが出来る。そして、図 7.8.(b) に示すようにその時系列データ内で時刻 t_h で遅い波 ω_1 から早い波 ω_2 に切り替わった際に、その変化を 1 回の STFT で検出することは出来ない。そこで、その時系列パワースペクトルに対してもう一度 STFT を行うことにより、図 7.8.(c) のようにパワースペクトルの周期の変化を見ることが出来る。このように 2 回の STFT を行うことにより得られるパワースペクトル値は、 α 波および β 波の減衰・復調の周期とその振幅の大きさを表しており、本研究ではこのパワースペクトルを周期

パワースペクトルと呼ぶ。

ある時刻 t における脳波を $X(f, t)$ (f :周波数) とした時, 短時間フーリエ変換のある周波数帯域 ($f_1 - f_2$) のパワースペクトル $P(t)$ は次のように表わされる。

$$P(t) = \int_{t-D_1}^t \int_{f_1}^{f_2} |X(f, t)| df dt \quad (7.3)$$

ここで, D_1 は短時間フーリエ変換における窓幅である。そして, 短時間フーリエ変換によって得られるパワースペクトル $P(t)$ は時系列信号と考えることができ, 脳波と同様に周波数帯域を持つ $P(f, t)$ (f :周波数) と表すことが出来る。したがって, ある周波数帯域 ($f_{s1} - f_{s2}$) の周期パワースペクトル $P_s(f_{s1}, f_{s2}, t)$ は2回の短時間フーリエ変換より得られるため, 次のように表わされる。

$$P_s(f_{s1}, f_{s2}, t) = \int_{t-D_2}^t \int_{f_{s1}}^{f_{s2}} |P(f, t)| df dt \quad (7.4)$$

ここで, D_2 は2回目の短時間フーリエ変換における窓幅である。短時間フーリエ変換でのパワースペクトルは言い換えると, ある周波数帯域のバンドパスフィルタを通したある時間窓の絶対値の積分値である。その値に対して, 短時間フーリエ変換を行うことで得られる周期パワースペクトルはその絶対値の変動の周期を表している。

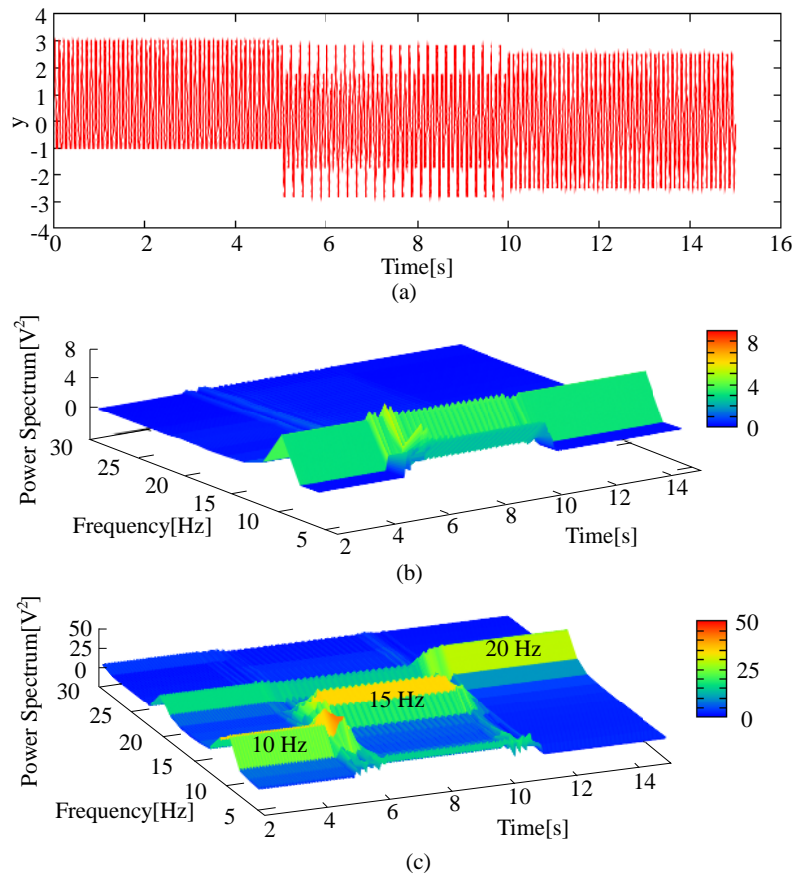


図 7.9: (a) 周期の変わる 10 Hz の信号 , (b) 短時間フーリエ変換の結果 , (c) 周期パワースペクトル

今 , 図 7.9.(a) に示すように 10 Hz の基信号に周期が 10 Hz , 15 Hz , 20 Hz に変わる 10 Hz の信号を加算された次の式 (7.5) の信号ある時 (サンプリング周期 1k Hz) ,

$$y = \begin{cases} 2\sin 2\pi \cdot 10 \cdot t + \sin(2\pi \cdot 10 \cdot t) \cdot \sin(2\pi \cdot 10 \cdot t), & (0 \leq t < 5.0) \\ 2\sin 2\pi \cdot 10 \cdot t + \sin(2\pi \cdot 10 \cdot t) \cdot \sin(2\pi \cdot 15 \cdot t), & (5.0 \leq t < 10.0) \\ 2\sin 2\pi \cdot 10 \cdot t + \sin(2\pi \cdot 10 \cdot t) \cdot \sin(2\pi \cdot 20 \cdot t), & (10.0 \leq t < 15.0) \end{cases} \quad (7.5)$$

この信号を , STFT を行うと図 7.9(b) のパワースペクトルが得られ , 10 Hz のパワースペクトルが大きくなっていることが分かる . この 10 Hz のパワースペクトルの時系列データに対し , もう一度 STFT を行った結果は図 7.9(c) となり , 時系

列で各周期 (10 Hz , 15 Hz , 20 Hz) のパワースペクトルの大きさが変化しており , 周期パワースペクトルで周期の変化を観測する事が出来る .

最後に , 運動の計測と負荷感覚を提示するロボットアーム制御のために , 被験者の上腕二頭筋の筋電位を計測する . 計測機器は Delsys 社の Bagnoli を使用し , 脳波と同様にサンプリング周波数 1000 Hz で取得する . そして , 得られた上腕二頭筋の筋電位は全波整流を行った後 , 200 点の移動平均と 0.7 Hz のローパスフィルタを組み合わせた整流平滑化 (ARV:Average Rectified Value) し , 筋活動を得る .

また , 被験者がロボットアームを上げるタイミングはビープ音によって提示される . まず , 15 秒のリラックス (初回のみ 7 秒) の後 , 0.1 秒のビープ音が鳴り , その 3 秒後再びビープ音が鳴る . それと同時に被験者はロボットアームの角度を上げ , 3 秒後再びビープ音が 2 回鳴り , 被験者は力を入れるの止め , ロボットアームを下げる . この 1 回目のビープ音が鳴ってから 9 秒間 (運動前 3 秒 , 運動 3 秒 , 運動後 3 秒) を 1 試行とし , この動作を繰り返し行う .

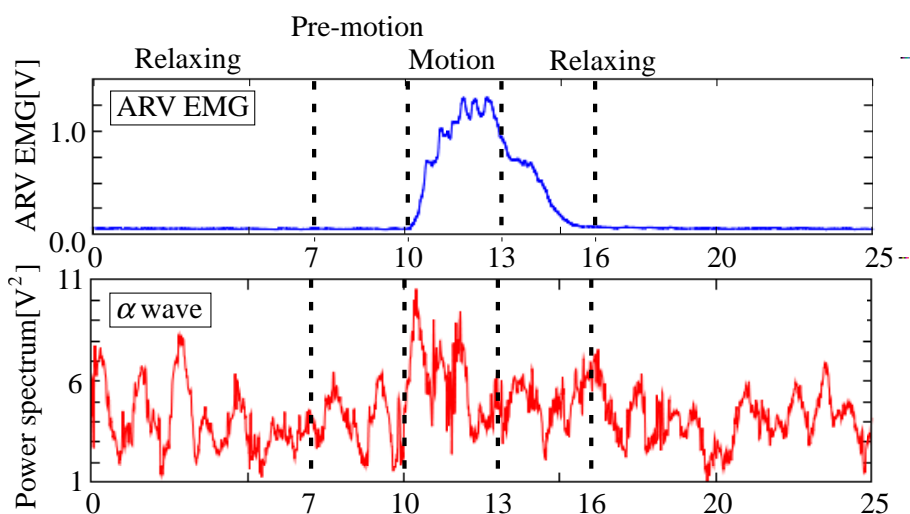

(a) ARV EMG & Power spectrum of α wave(b) Periodic power spectrum of α wave

図 7.10: (a) C_3 における 1 試行の α 波の時系列パワースペクトル, (b) (a) を短時間フーリエ変換した結果

7.2.4 周期パワースペクトル

図 7.10 に被験者 A の 1 試行を行った時の筋電位を整流平滑化した筋活動と計測点 C_3 での α 波のパワースペクトル (1st Short-time FFT, 図 7.10.(a)), また, その短時間フーリエ変換による周波数解析 (2nd Short-time FFT, 窓幅 1280 msec, 10 msec ごと, 図 7.10.(b)) の結果を示す. 開始 7 秒で運動準備の合図が被験者に提示され (Pre-motion), その 3 秒後運動を 3 秒間行い (Motion), その後安静状態に移る (Relaxing). まず, 図 7.10.(a) において, α 波のパワースペクトルは増減を

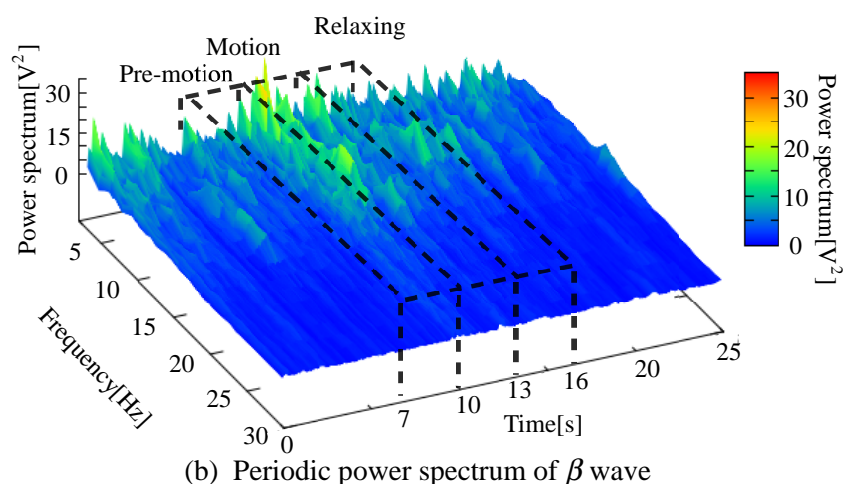



図 7.11: (a) C_3 における 1 試行の β 波の時系列パワースペクトル, (b) (a) を短時間フーリエ変換した結果

繰り返し 5 Hz 以下の波が見られ, 2 回目の STFT の結果 (図 7.10.(b)) によって 5 Hz 以下のパワースペクトルとして出てきている. そして, その周期は運動前から運動後にかけて変化しており, 図 7.10(b) の周波数解析結果の 20-25 Hz に着目すると, α 波のパワースペクトルは Pre-motion 時に減少している. そして, Motion 時には α 波のパワースペクトルの変化は 20-25 Hz の振幅は大きく増加していることが見られた. その後, リラックス状態で減少している. 同様に, 被験者 A の 1 試行行った時の計測点 C_3 における β 波の解析も行い, その結果を図 7.11 に示す. 一方, β 波でも, α 波と同様に 5 Hz 以下の波が見られ, Motion 時に周期が変化し

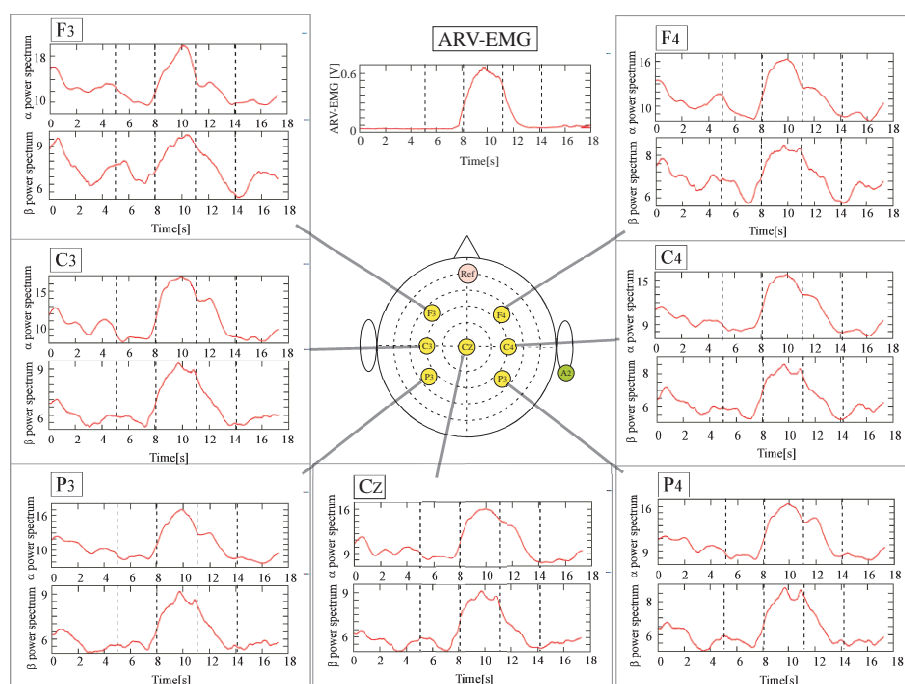


図 7.12: 被験者 A の各計測点の 10 試行の周期パワースペクトルの平均
 ている (図 7.11.(a)) . 図 7.11.(b) の 2 回の STFT の結果を見ると β 波では α 波と
 異なり, その周期の変化は 10-15 Hz の部分が運動と関連している .

次にこの結果を踏まえ, 被験者 A と B が 10 試行行った時の各計測点での運動
 と関連性が高かった振幅の変動の α 波では 20-25 Hz, β 波では 10-15 Hz の時系列
 変化を確認した . 周波数解析によって得られた各周期パワースペクトルを加算し,
 10 試行分の平均をした結果を図 7.12 (被験者 A) と図 7.13 (被験者 B) に示す . 中
 央の上部に筋活動を示し, 各計測点の α 波と β 波の周期パワースペクトルの変化
 を示している .

まず, 被験者 A ではどの計測点でも, 運動時に最大値を取っていることが分か
 る . また, 運動開始直前 (8 秒直前) に α 波と β 波が減少しており, 運動終了後,
 緩やかに減少していることが分かる . この時, 各計測点での左右差は見られず, 同
 様の変化をしており, 前頭葉側 (F_3 , F_4) では 0 ~ 5 秒の間で周期パワースペクト
 ルの上昇が見られた .

次に, 被験者 B ではどの計測点においても, 運動開始時から運動終了時につ

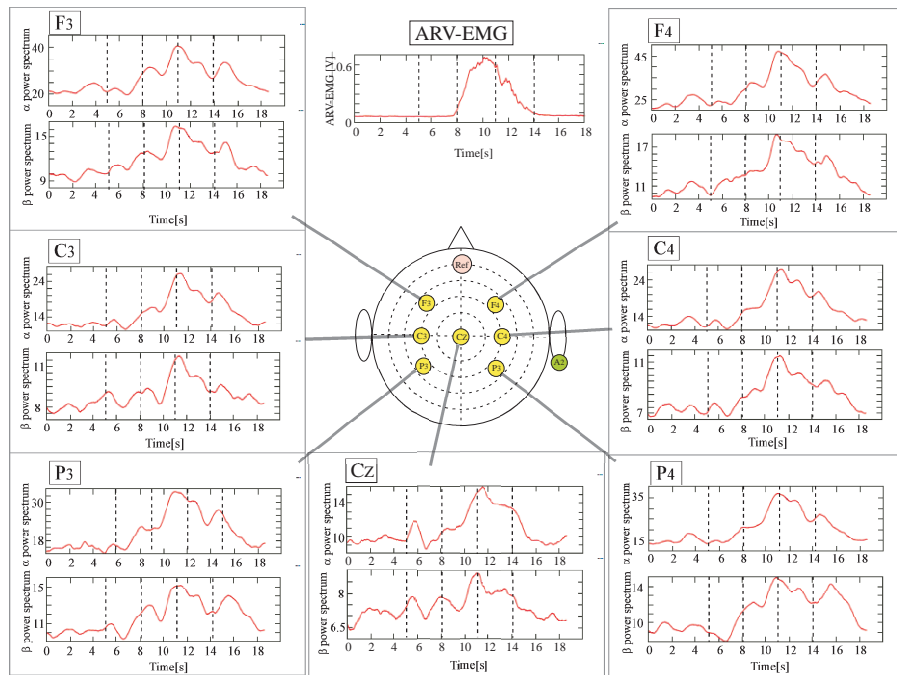


図 7.13: 被験者 B の各計測点の 10 試行の周期パワースペクトルの平均

て周期パワースペクトルは上昇し，運動終了の合図時に最大値となっていることが分かる．そして，安静状態での周期パワースペクトルの変化は見られなかった．また，被験者 B の Cz の β 波の変化は他の計測点と比べて小さいことが見られた．被験者 B は被験者 A と同様に，左右差は見られなかったが，前頭葉側 (F₃, F₄) では 0~5 秒の間でパワースペクトルの上昇はなかった．これらの結果から，各計測点の α 波と β 波のパワースペクトルの周波数解析によって個人差は見られたが運動に大きく関連する結果が得られた．

7.2.5 α 波・ β 波の周期パワースペクトルの変動

図 7.14 は，被験者 A の (a) 安静時と (b) 1 試行中における運動の 3 秒前から 12 秒間の α 波・ β 波の 2 回の STFT を行った周期パワースペクトルの分布を示している．また，他の被験者 B ~ E の運動時の周期パワースペクトルの分布は，図 7.15-7.18 に示す．上部に筋活動，下部に α 波と β 波の 20-25 Hz と 10-15 Hz の周期パワースペクトルの各計測点における分布を表している．これらの表示には，計測点が

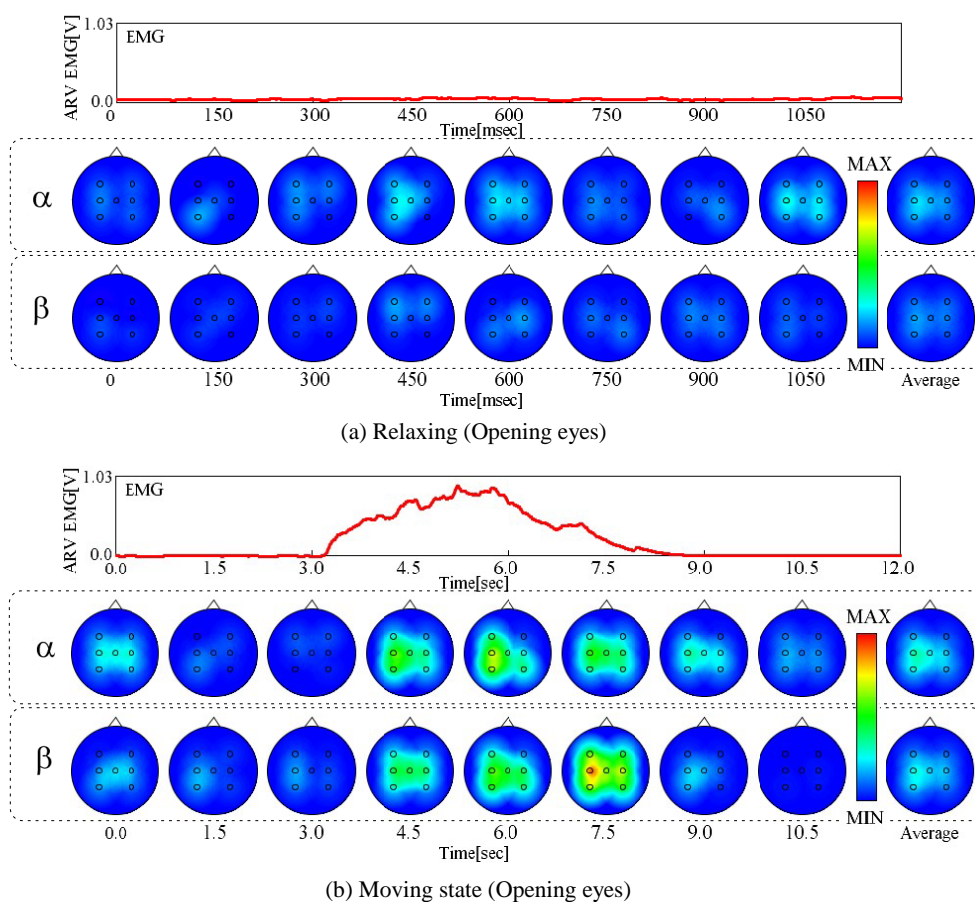


図 7.14: 被験者 A の (a) 安静時と (b) 運動時の周期パワースペクトルの分布

らの距離と周期パワースペクトル大きさに応じて、青を最小、赤を最大とした色調でプロットし Processing を用いて表示している。また、周期パワースペクトルの分布はそれぞれ 1.5 秒ごとに表示している。さらに、右端にこの 1 試行中の各計測点のパワースペクトルの変動の平均分布を示している。図 7.14.(b) の運動前の 3 秒間 (Pre-motion) と運動後の安静時 (Relaxing) では α 波・ β 波は小さくなっている。また、運動中 (Motion) では α 波・ β 波のパワースペクトルの変動の分布は大きくなっており、脳全体で α 波・ β 波の周期が変化しており、他の被験者でも同様の変化が見られた。

次に、目を開いた安静状態を 20 秒間維持した時 (Relaxing) の α 波と β 波のパワースペクトルの変動の平均分布と、運動中 (Motion) の分布を図 7.19 に示す。どの被験者においても、安静時と比べて運動中の方が大きく増加している。これら

のことから， α 波と β 波は運動時においてその周期が変化し， α 波では 20-25 Hz， β 波では 10-15 Hz のパワースペクトルの周期の変化が大きく運動との関連性が高いことが分かる．

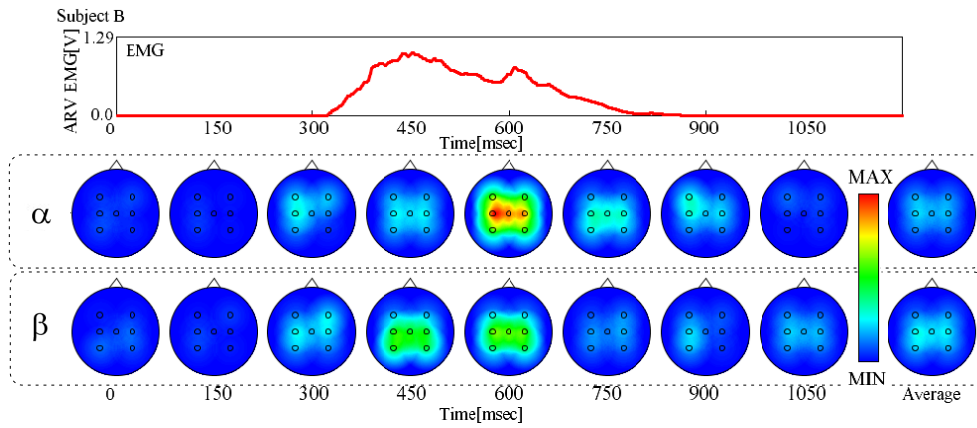


図 7.15: 被験者 B の運動時の周期パワースペクトルの分布

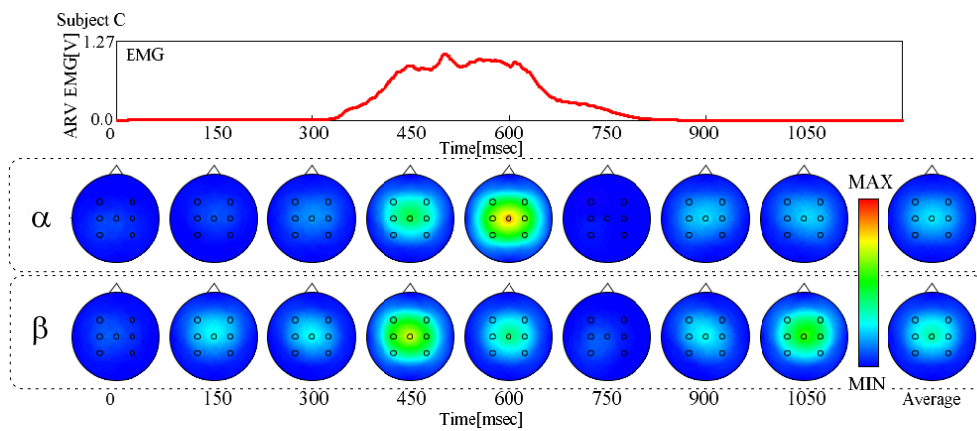


図 7.16: 被験者 C の運動時の周期パワースペクトルの分布

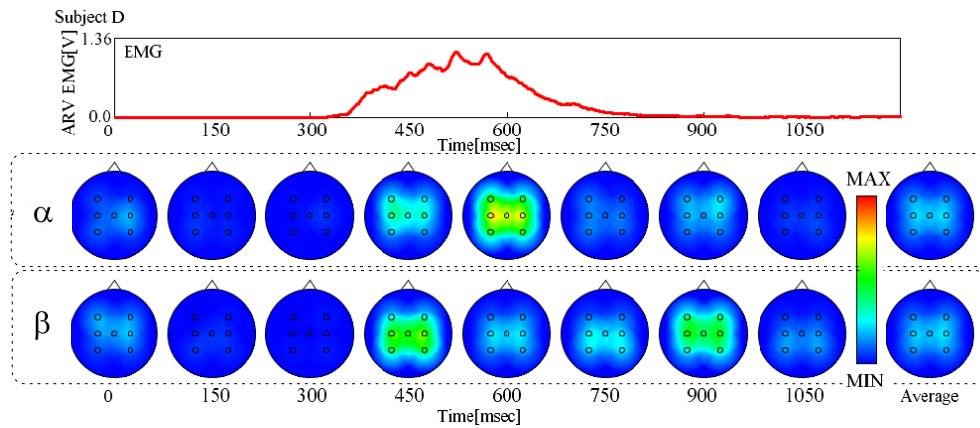


図 7.17: 被験者 D の運動時の周期パワースペクトルの分布

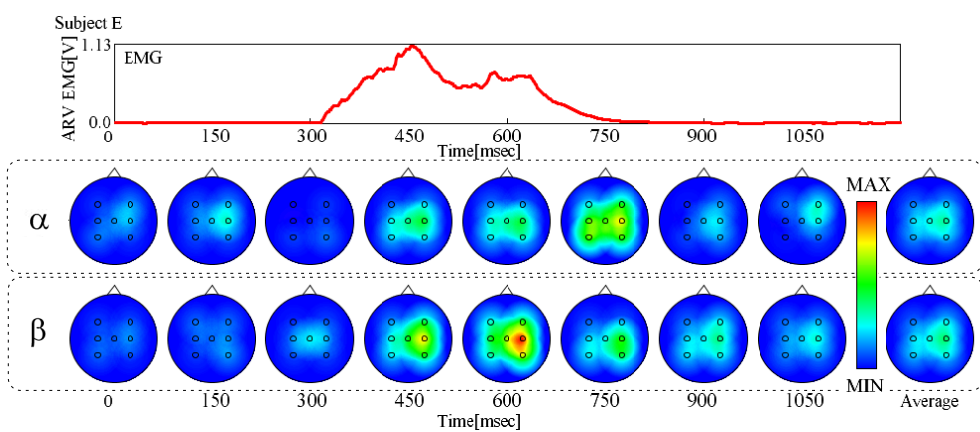


図 7.18: 被験者 E の運動時の周期パワースペクトルの分布

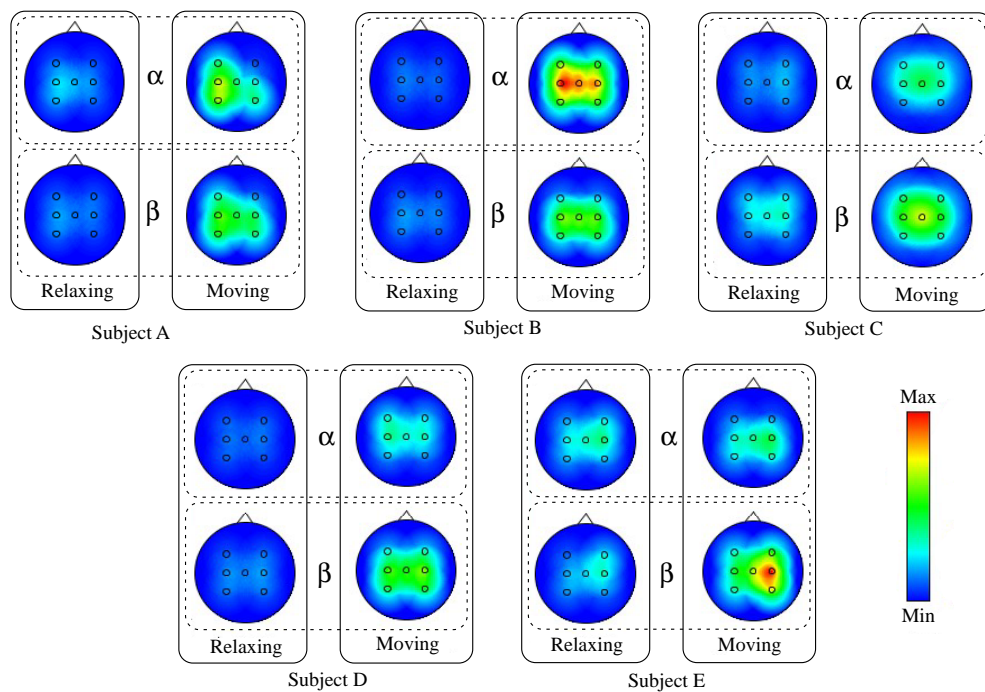


図 7.19: 被験者 A-E の安静時と運動時の周期パワースペクトルの分布の比較

7.3 周期パワースペクトル-関節トルク間の線形モデルによる推定

前節により，筋活動と線形関係の強い脳波の特徴量を算出することが出来た．そして，この前章の主成分モデルを利用して脳波周期パワースペクトル-関節トルク間の線形モデルを作成する．入力として前述の7ヶ所の周波数解析によって得られた各計測点の α 波と β 波のパワースペクトルの変化のデータ $x_{\alpha i}, x_{\beta j}$ ($i=1, 2, \dots, N, j=1, 2, \dots, N$ ($N=7$))，関節トルク情報として1ヶ所の計測点から得られた筋活動 y を与えるとする．この時の脳波と筋活動間の主成分 z は次のように表される．

$$z = \sum_{i=1}^N l_{\alpha i} x_{\alpha i} + \sum_{j=1}^N l_{\beta j} x_{\beta j} + l_y y \quad (7.6)$$

ここで， $l_{\alpha i}, l_{\beta j}, l_y$ は脳波データ $x_{\alpha i}, x_{\beta j}$ と筋活動 y の入力データ間の分散共分散行列の固有値が最大となる固有ベクトルである．これにより，主成分 z は固有ベクトルを重み値とした脳波と筋活動の線形結合で表すことが出来る．この式(7.6)において，筋活動 y について解くと，

$$\hat{y} = \frac{z - (\sum_{i=1}^N l_{\alpha i} x_{\alpha i} + \sum_{j=1}^N l_{\beta j} x_{\beta j})}{l_y} \quad (7.7)$$

となり，式(7.7)は推定筋活動 \hat{y} を求める式となる．ここで，脳波データと筋活動の主成分と固有ベクトルが既知の場合，脳波データ $x_{\alpha i}, x_{\beta j}$ から筋活動(関節トルク) \hat{y} を推定する線形モデルを得ることが出来る．

式(7.7)を用いた脳波-関節トルクモデルの生成手法の概要を図7.20に示す．まず，同事象における複数点の脳波に対して短時間高速フーリエ変換(STFT)を2回行い，1回目は α 波と β 波の時系列パワースペクトルを算出し，2回目は時系列の α 波と β 波の変動を各周波数帯域に分離したパワースペクトルを得る．そして，関節トルク情報の1点の筋活動を入力信号として，主成分分析を用いて脳波-関節トルク間の線形モデルを作成する(図7.20. Step 1)．次に関節トルクを未知信号として，新たに計測した脳波のみを入力信号とすることで，作成されたモデルと脳波から関節トルクを推定する(図7.20. Step 2)．この手法を用いて，脳波から筋

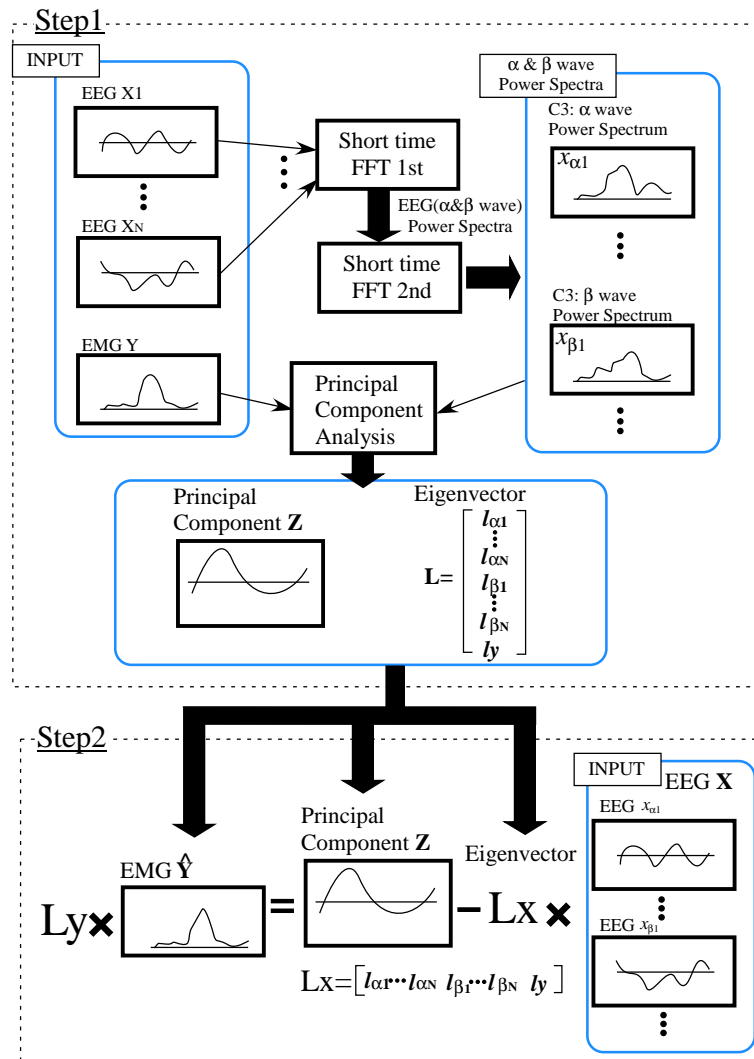


図 7.20: 脳波-関節トルクモデルの生成手法

活動を推定することにより，パワーアシスト装置への入力信号に用いることが出来る．




図 7.21: 被験者 A-C の関節トルク推定結果

7.4 関節トルクの推定結果

先述の α 波・ β 波のパワースペクトルの周期の変化に基づき、主成分分析による脳波-関節トルクモデルを生成した。モデル作成の入力データは、ロボットアーム操作を 15 試行行った時の α 波・ β 波のパワースペクトルの変動と筋活動を用いた。そして、作成されたモデルから、被験者がロボットアームの屈曲・伸展を複数回行った時の脳波を計測し、筋活動を推定した。今回、被験者 A ~ C の 3 人の計測筋活動と推定された筋活動を図 7.21 に示す。破線（黒）は計測された筋活動、実線（赤）は推定された筋活動である。この図により、どの被験者においても、計測

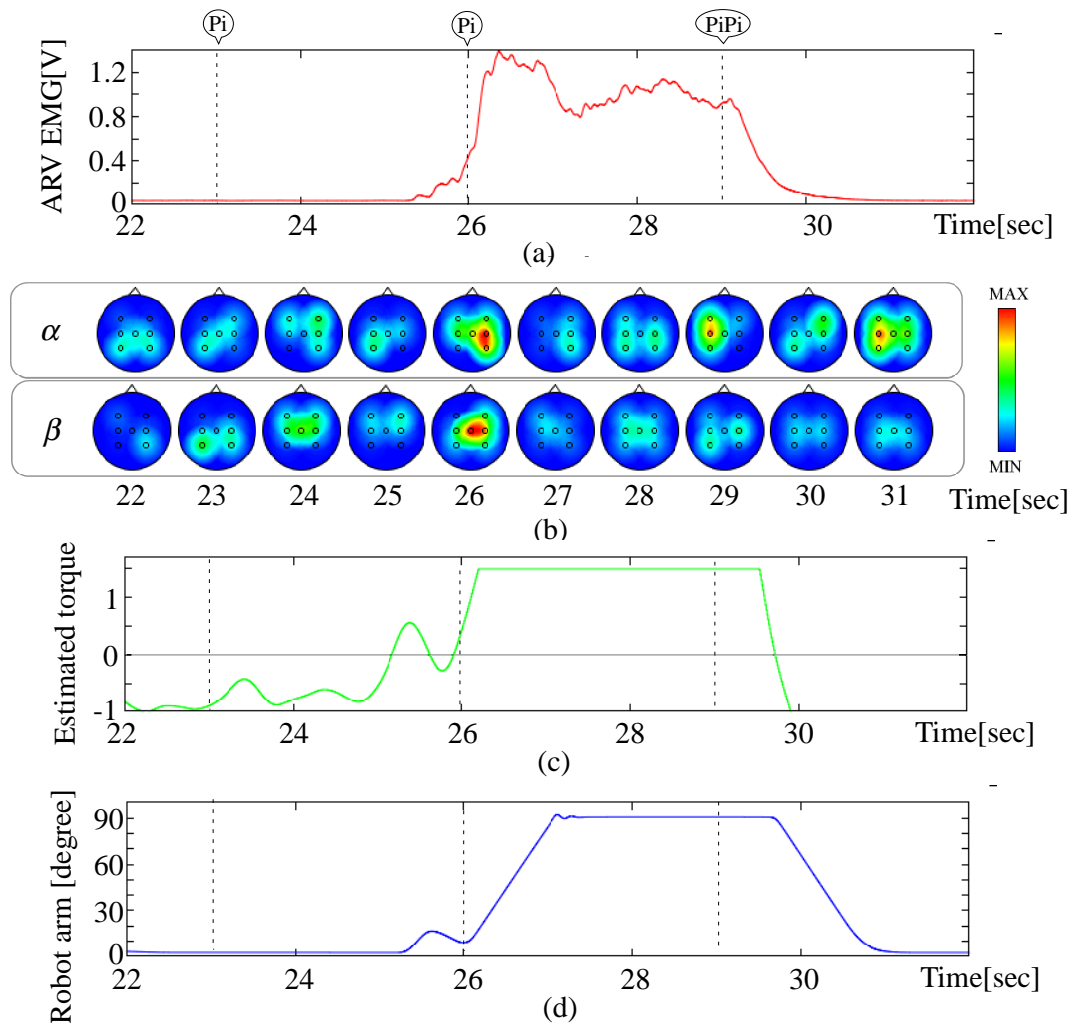


図 7.22: 被験者 A の推定関節トルクを用いた 1 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度

された筋活動の周期的な動きに合わせて, 推定された筋活動が変化している. 特に, 被験者 B では計測された筋活動と推定筋活動の相関係数は 0.80 となり, 推定出来ていることが確認された. しかし, 18 秒付近で推定筋活動の値が減少している. これは計測された筋活動もスパイク状に出てきていることから, システム全体に大きなノイズが混入したと考えられる. 他の被験者 A, C の計測筋活動と推定筋活動の相関係数はそれぞれ 0.72 と 0.68 となり, 主成分分析を用いた脳波 - 関節トルク間の線形モデルの有効性が確認出来た.

そして, 最後に脳波より推定された関節トルクを入力信号として, ロボットアーム

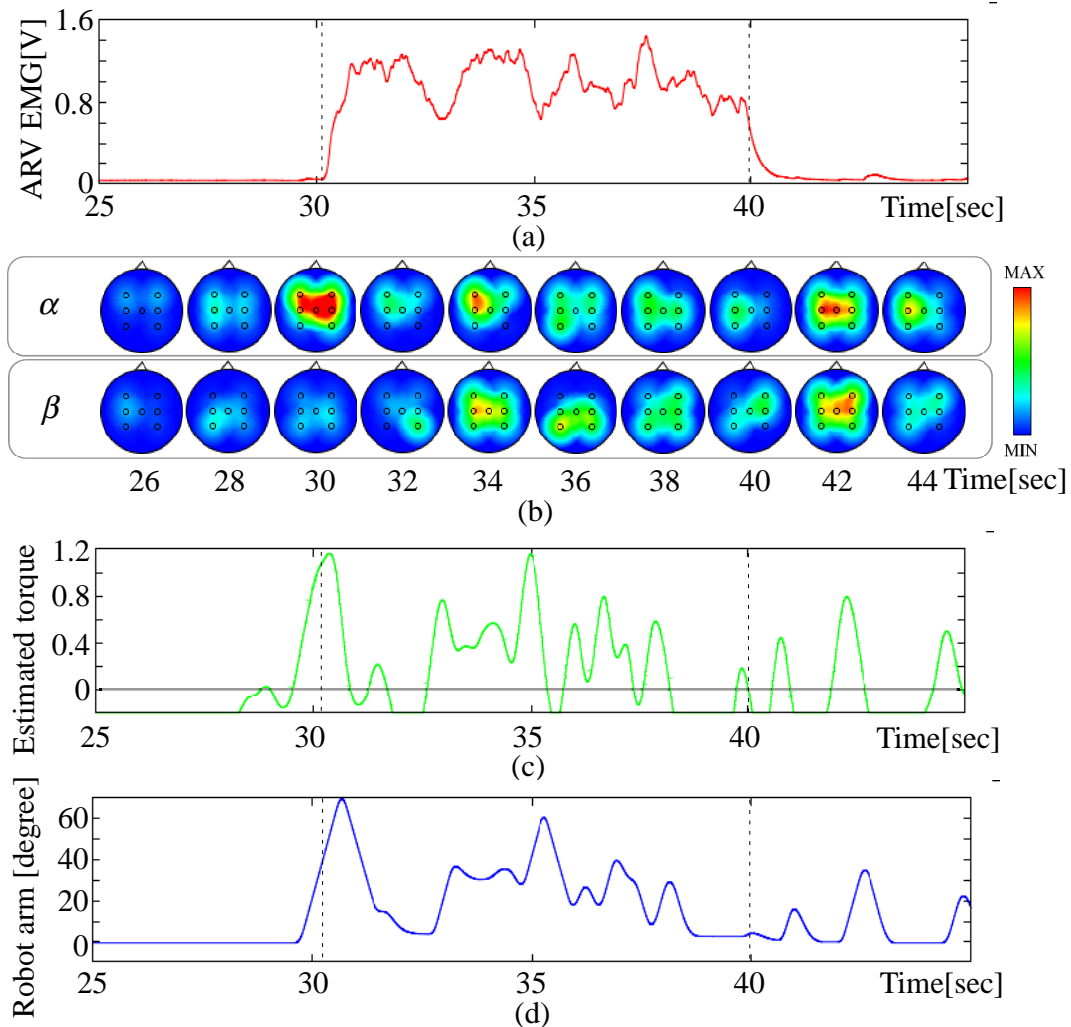


図 7.23: 被験者 A の推定関節トルクを用いたロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度

ムの操作を行った。ロボットアーム角度の域値を 0-90 度に設定し、被験者はロボットアームの先端を掴んだ状態で肘の屈曲運動を行う。また、推定関節トルクの域値は-1.0-1.5 に設定した。今回は被験者 A と B の二人で実験を行い、その結果を図 7.22-7.25 に示す。図 7.22 と図 7.24 は実験タスクと同じ 3 秒間の力を入れる動作を 1 試行実行している被験者 A と被験者 B の結果である。被験者 A が力を入れると共に脳波から関節トルクが推定され、ロボットアームの角度が上がり、被験者が力を抜くとロボットアームの角度も下がっていることが分かる。また、図 7.23 は、被験者 A が 10 秒間力を出し続けた時の結果である。ロボットアームは力を出し始

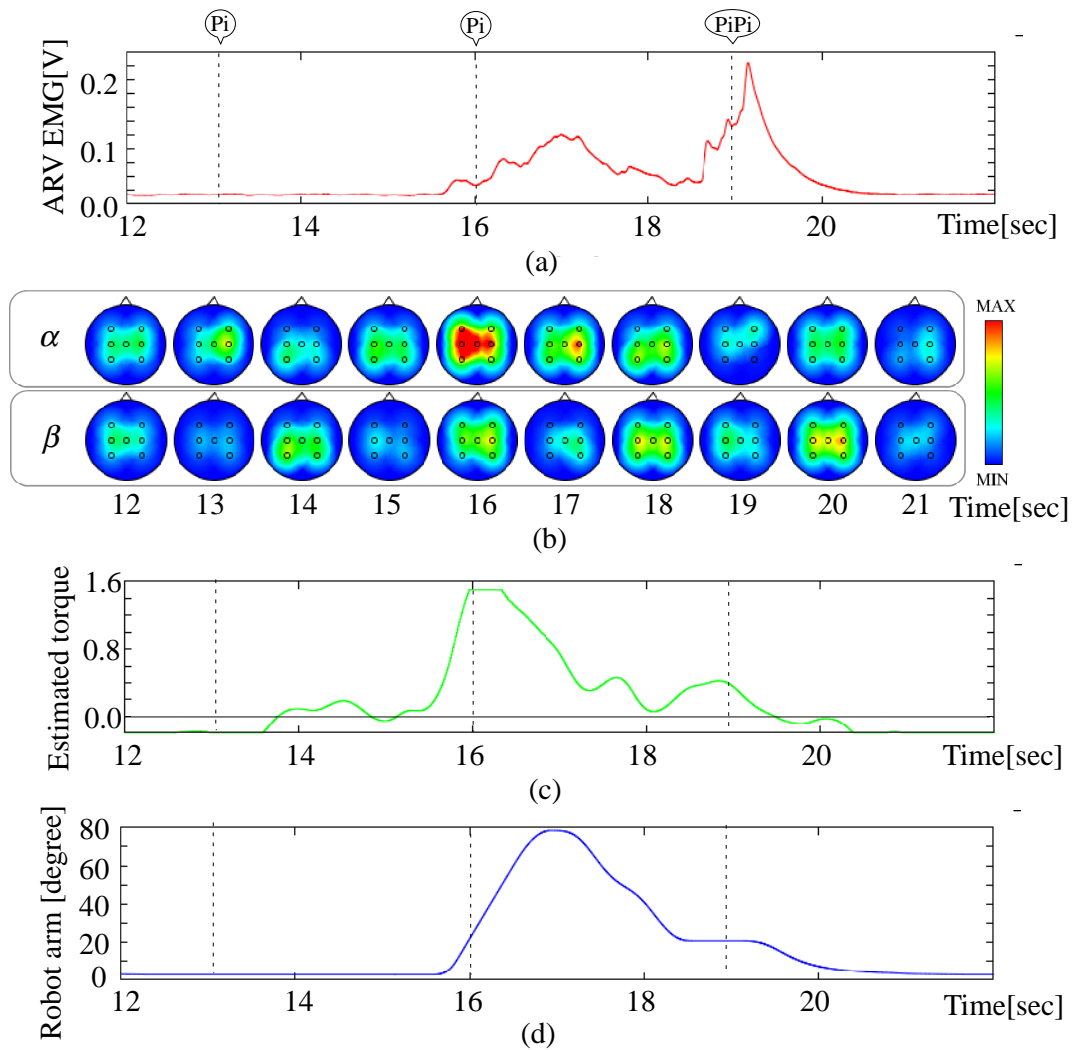


図 7.24: 被験者 B の推定関節トルクを用いた 1 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度

めるタイミングで屈曲した後に伸展し, 40 度付近で維持した後に緩やかに減少した. 次に, 被験者 B でも同様に, 力を出し始めるタイミングでロボットアームが屈曲していることが分かる. そして, 図 7.25 は被験者 B の 2 試行行った時の結果であり, この結果では運動終了の直前でロボットアームが上がり始めた. 被験者たちはロボットアームを持った状態で実験を行っているため, ロボットアームの角度の変動が被験者の運動のタイミングがずれてしまうため, 被験者に違和感を与える可能性があるため, 今後これらの影響を調査する必要があると考えられる. これらの事から α 波の 20-25 Hz と β 波の 10-15 Hz の増減について, 安静時は減

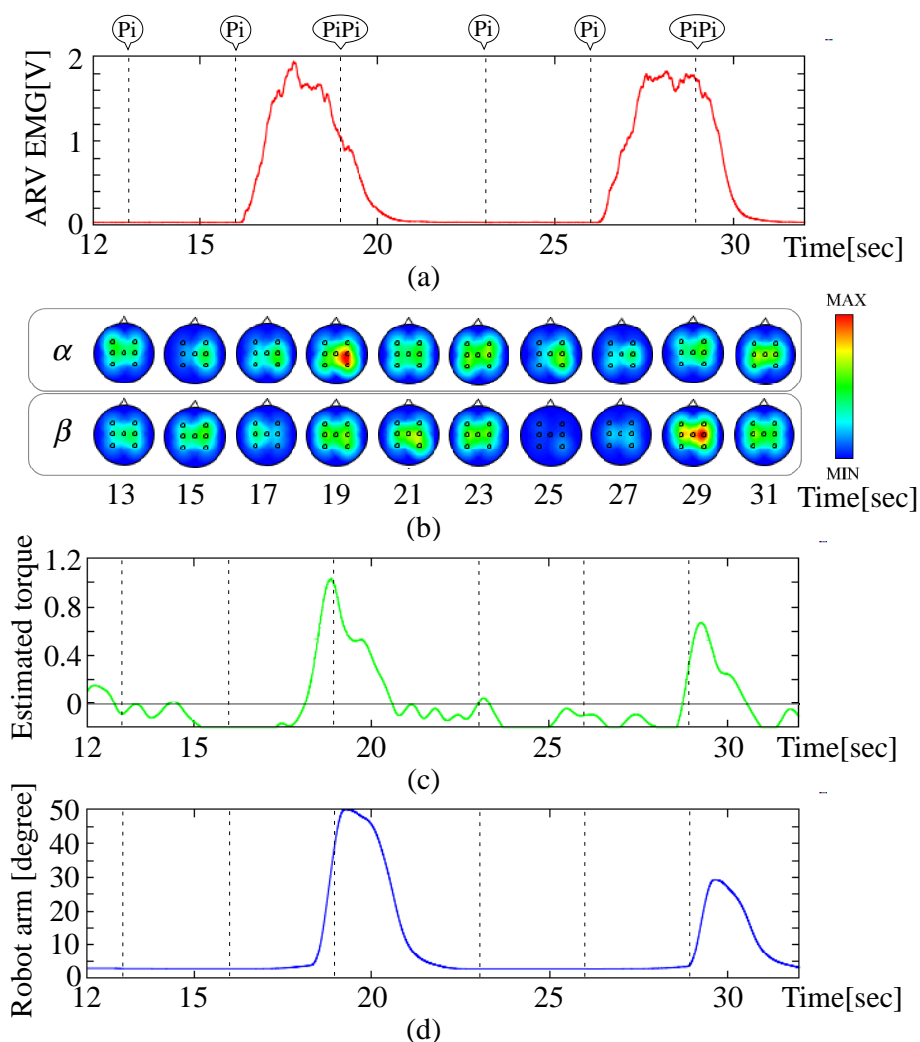


図 7.25: 被験者 B の推定関節トルクを用いた 2 試行のロボットアーム操作 (a) 筋活動, (b) 周期パワースペクトル, (c) 推定トルク, (d) ロボットアーム角度

少し、運動中に増加する傾向が得られ、脳波と上腕二頭筋から得られる関節トルクの関連性が見られたため、脳波から関節トルク（筋活動）を推定することが出来た。さらに、オンラインで推定することによりロボットアームの制御を行うことが出来た。

α 波は閉眼時に多く観測され、開眼によって抑制されることが良く知られている。しかし、閉眼時の α 波のパワースペクトルは常に開眼時より強く発生しているのではなく、1-3 Hz の増減を繰り返している。本研究では、その変化は運動にも関連があるという予測の下、解析を行った。 α 波帯域の μ 律動と β 波は運動と運動想起に関連していることが分かっている [26][60]。しかし、これらの運動の事

象に関する α 波や β 波の変動については調査されてきたが、その増減の周期に関する議論はなされていなかった。今回、 α 波の 20-25 Hz と β 波の 10-15 Hz の増減について、安静時は減少し、運動中に増加する傾向が得られ、脳波と上腕二頭筋から得られる関節トルクの関連性が見られたため、脳波から関節トルク（筋活動）を推定することが出来た。今後、これらの増減の周期性について深く調査を行い、脳波を用いたロボットアームのパワーアシストシステムの実現を目指す。

7.5 まとめ

本章では、運動に関する脳波を解析し、関節トルクとの関係性を分析し、脳波から関節トルクの推定を行った。被験者が筋活動を使ってロボットアームを動かした際に α 波と β 波の変動は各計測点において α 波では 20-25 Hz、 β 波では 10-15 Hz の帯域で運動に関連していることが確認された。その結果から、本手法である主成分分析を用いた脳波 - 関節トルク間の線形モデルで関節トルクの推定を行い、その有効性を示すことが出来た。このことから運動に関連する脳波を検出し、その脳波を用いてロボットアームでのパワーアシストの有効性が示唆された。今後、被験者数を増やし α 波と β 波の変動をより深く調査すると共に、オンラインでの脳波から筋活動の推定を行い、脳波を用いたパワーアシスト実現を目指す。

第8章 結言

本論文では、これまで外骨格ロボットに使用されてきた筋電位や力/トルクセンサの代わりに脳波から運動情報を用いたBMI外骨格パワーアシストシステムを構築するために、脳波から運動に関する特徴量を抽出し、そこから運動の判別器と推定モデルの生成手法について述べ、脳波から人の関節トルクを推定した。健常者だけではなく障害者でも外骨格ロボットによるパワーアシストを行うことが出来る。そのために、脳波の解析に用いられている基本的な周波数領域を短時間フーリエ変換による時系列領域まで展開し、その特徴を観測して、統計的手法で用いられるマハラノビスの汎距離を使って運動の判別器の作成を行い、脳波から安静時の状態と運動の状態を判別することが出来た。そして、人の運動意図である筋活動と脳波の関係を主成分分析によって、線形モデルを構築することで脳波から筋活動を推定出来ることを示した。さらに、これまで運動との線形関係が乏しいと言われていた脳波データはパワースペクトルの周期の変化と線形関連があることを突き止めた。この結果を応用し、主成分分析による線形モデルで学習される入力信号を周期パワースペクトルを用いることで、モデルの更新が必要としない推定モデルを作成し、その有効性を示すことが出来た。最後に、本論文をまとめ、今後の展望について述べる。

8.1 まとめ

本論文において、人の運動に関する脳波の特徴を抽出するために、人の状態と運動に関する4つのタスクを設計し、時系列で周波数領域を観測することが出来る短時間フーリエ変換を用いて解析を行った。そして、人の状態が α 波と β 波帯

域に関連していることを見つけ、各計測点によって差が出ることを明らかにした。そこで得られた α 波の左右差と β 波の左右差を 2 次元にプロットすることで、安静状態と運動状態の違いを視覚的に捉え、そのデータの広がりに対してマハラノビスの汎距離を用いることで運動の判別器を生成することが出来た。

次に、その得られた脳波の特徴的な変化を主成分分析によって学習を行い、脳波と筋活動の線形モデルの構築を行った。そして、体を動かすことが出来ない障害者でもパラメータの更新を可能とするために、ロボットアームの角度情報から使用者が感じている関節トルクを推定し逐次最小二乗法の教師信号とするパラメータ更新手法の提案を行い、その有効性を示した。

さらに、提案した主成分分析による線形モデルは、脳波から関節トルクとの線形関係のある特徴量が必要であることから、これまで用いられてきた脳波の周波数パワースペクトルではモデルの更新が不可欠であった。そこで、パワースペクトルの増減について着目すると、運動時にその揺らぎが変化することが見られたため、短時間フーリエ変換を 2 回掛けることによって得られる周期パワースペクトルの解析を行った。そして、 α 波と β 波の変動は各計測点において α 波では 20-25 Hz、 β 波では 10-15 Hz の帯域で運動に関連していることが確認された。その結果から、本手法である主成分分析を用いた脳波 - 関節トルク間の線形モデルで関節トルクの推定を行い、その有効性を示すことが出来た。このことから運動に関連する脳波を検出し、その脳波を用いてロボットアームでのパワーアシストの有効性が示唆された。

8.2 今後の展望

本研究では、脳波の中の力・トルク情報を解析し、1 関節の力・トルク情報の抽出・推定手法の確立を目指して進めてきた。この技術を拡張し、人の多自由度の力・トルク情報を推定し、推定された力・トルク情報を用い、外骨格ロボットで上肢および腰のパワーアシスト技術を開発する。そして、人間のタスクの遂行能

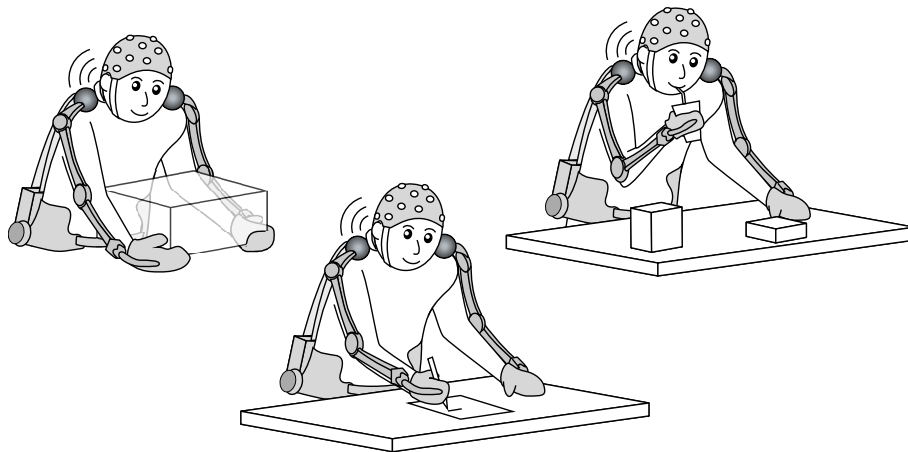


図 8.1: BMI パワーアシストシステムの展望

力を表す評価関数を作成し，その人間の遂行能力に応じ，人間とロボットの共同作業でのそれぞれの貢献度を適応的に決める必要があると考えられる．また，熟練者の動作を解析し，各動作の基本特徴を表すデータベースを作成し，作業者の実際の動作と比べ，学習手法を用いて，作業者の実際の動作が熟練者の動作に近付くように外骨格ロボットで技量のアシストを行う．そして，図 8.1 に示すような BMI パワーアシストシステムを作成し，様々な日常動作の支援の実現を目指す．

参考文献

- [1] 厚生労働省社会・援護局障害保健福祉部，“平成23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”，2013．
- [2] H. Kawamoto and Y. Sankai, “Power assist method based on Phase Sequence and muscle force condition for HAL”, *Journal of Advanced Robotics*, Vol. 19, pp. 717-734, 2005.
- [3] H. Quintero, R. Farris, C. Hartigan, I. Clesson, and M. Goldfarb, “A Powered Lower Limb Orthosis for Providing Legged Mobility in Paraplegic Individuals”, *Topics in Spinal Cord Injury Rehabilitation*, vol. 17, no. 1, pp. 25-33, 2011.
- [4] H. Herr, “Exoskeletons and orthoses: classification, design challenges and future directions”, *Journal of NeuroEngineering and Rehabilitation*, pp. 6-21, 2009.
- [5] 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, pp. 1066-1067, 2008.
- [6] J. K. Chapin, K. A. Moxon, R. S. Markowitz and M. A. L. Nicolelis, “Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex”, *Nature neuroscience*, Vol. 2, No. 7, pp. 664-670, 1999.
- [7] J.M. Carmena, M.A. Lebedev, R.E. Crist, J.E. O’Doherty, D.M. Santucci, D.F. Dimitrov, P.G. Patil, C.S. Henriquez, M.A. L. Nicolelis : “Learning to

- control a brain-machine interface for reaching and grasping by primates”, *PLoS Biology*, Vol. 1 , pp. 193-208, 2003.
- [8] Miguel A. L. Nicolelis, “Brain-machine interfaces to restore motor function and probe neural circuits”, *Nature Reviews Neuroscience*, Vol. 4, pp. 417-422, 2003.
- [9] Meel Velliste, Sagi Perel, M. Chance Spalding, Andrew S. Whitford, Andrew B. Schwartz, “Cortical control of a prosthetic arm for self-feeding”, *Nature*, Vol. 453, pp. 1098-1101, 2008.
- [10] A. K. Bansal, W. Truccolo, C. E. Vargas-Irwin, and J. P. Donoghue, “Decoding 3D reach and grasp from hybrid signals in motor and premotor cortices spikes multiunit activity and local field potentials” *Journal of Neurophysiol*, Vol. 107, pp. 1337-1355, 2012.
- [11] Leigh R. Hochberg, Mijail D. Serruya, Gerhard M. Friehs, Jon A. Mukand, Maryam Saleh, Abraham H. Caplan, Almut Branner, David Che, Richard D. Penn and John P. Donoghue, “Neuronal ensemble control of prosthetic devices by a human with tetraplegia”, *Nature*, Vol. 442, pp. 164-171, 2006.
- [12] J. D. Simeral, S. P. Kim, M. J. Black, J. P. Donoghue and L. R. Hochberg, “Neural control of cursor trajectory and click by a human with tetraplegia 1000 days after implant of an intracortical microelectrode array”, *Journal of Neural Engineering*, Vol. 8, pp. 1-24, 2011.
- [13] S. P. Kim, J. D. Simeral, L. R. Hochberg, J. P. Donoghue, G. M. Friehs and M. J. Black, “Point-and-click cursor control with an intracortical neural interface system by humans with tetraplegia” *IEEE Trans. Neural Syst. Rehabil. Eng*, Vol. 19, No. 2, pp. 193-203, 2011.

- [14] 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.
- [15] T. N. Lal, T. Hinterberger, G. Widman, M. Schröder, J. Hill, W. Rosenstiel, C. E. Elger, B. Schölkopf and N. Birbaumer, “Methods Towards Invasive Human Brain Computer Interfaces”, *Advances in Neural Information Processing Systems*, No. 17, pp. 737-744, 2005.
- [16] Takufumi Yanagisawa, Masayuki Hirata, Yuichi Saitoh, Haruhiko Kishima, Kojiro Matsushita, Tetsu Goto, Ryohei Fukuma, Hiroshi Yokoi, Yukiyasu Kamitani, Toshiki Yoshimine, “Electrocorticographic Control of a Prosthetic Arm in Paralyzed Patients”, *ANN NEUROL*, Vol. 71, pp. 353-361, 2012.
- [17] 平田雅之, 柳澤琢史, 後藤哲, 齊藤洋一, 福間良平, 横井浩史, 神谷之康, 吉峰俊樹, “脳表脳波計測に基づく運動制御の実時間復号化”, *BPES*, 2008.
- [18] T. Yanagisawa, M. Hirata, Y. Saitoh, A. Kato, D. Kishima, R. Fukuma, H. Yokoi, Y. Kamiyama, T. Yoshimine, “Neural decoding using gyral and intrasulcal electrocorticograms”, *Neuroimage* Vol. 45, pp. 1099-1106, 2009.
- [19] Takufumi Yanagisawa, Masayuki Hirata, Yuichi Saitoh, Tetsu Goto, Haruhiko Kishima, Ryohei Fukuma, Hiroshi Yokoi, Yukiyasu Kamitani, Toshiki Yoshimine, “Real-time control of a prosthetic hand using human electrocorticography signals”, *Journal of Neurosurg*, Vol. 114, pp. 1715-1722, 2011.
- [20] 平田雅之, 柳澤琢史, 松下幸次郎, Morris Shayne, 神谷之康, 鈴木隆文, 吉田毅, 佐藤文博, 齊藤洋一, 貴島晴彦, 後藤哲, 影山悠, 川戸光男, 吉峰俊樹, “ブレイン・マシン・インターフェースによる機能支援：リアルタイム口

- ロボットアーム制御とワイヤレス完全体内埋込装置の開発”, *Japan Journal of Neurosurg*, Vol. 21, No. 7, 2012.
- [21] 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, pp. 510-523, 1988.
- [22] 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, 2000.
- [23] E. W. Sellers and E. Donchin, “A P300 based brain-computer interface: initial tests by ALS patients”, *Clinical Neurophysiology*, Vol. 117, pp. 538-548, 2006.
- [24] J.R. Wolpaw and D.J. McFarland, “Multichannel EEG-based brain-computer communication”, *Electroencephalography and Clinical Neurophysiology*, Vol. 78, pp. 252-259, 1991.
- [25] J.R. Wolpaw and D.J. McFarland, “An EEG-based brain-computer interface for cursor control”, *Electroencephalography and Clinical Neurophysiology*, Vol. 90, pp. 444-449, 1994.
- [26] D. J. McFarland, W. A. Sarnacki and J. R. Wolpaw, “Brain-computer interface (BCI) operation: optimizing information transfer rates”, *Biological Psychology*, Vol. 63, pp. 237-251, 2003.
- [27] J.R. Wolpaw and D.J. McFarland, “Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans”, *Proc. Natl. Acad. Scis. (USA)*, Vol. 101, pp. 17849-17854, 2004.
- [28] Gerwin Schalk, Dennis J. McFarland, Thilo Hinterberger, Niels Birbaumer, Jonathan R. Wolpaw, “BCI2000: A General-Purpose Brain-Computer Inter-

- face (BCI) System”, *IEEE Transactions on Biomedical Engineering*, Vol. 51, No. 6, 2004.
- [29] I. Iturrate, J. Antelis and J. Minguez, “Synchronous EEG Brain-Actuated Wheelchair with Automated Navigation”, *ICRA’09 Proceedings of the 2009 IEEE international conference on Robotics and Automation*, pp. 2530-2537, 2009.
- [30] 独立行政法人理化学研究所: “脳波で電動車いすをリアルタイム制御 - Brain Machine Interface (BMI) の新しい脳信号処理技術を開発 - ”, <http://www.riken.jp/pr/press/2009/20090629/>, 2016/12/01 閲覧.
- [31] J. R. Millan, F. Renkens, J. Mourino and W. Gerstner, “Noninvasive brain-actuated control of a mobile robot by human EEG”, *IEEE Transactions Biomedical Engineering*, Vol. 6, pp. 1026-1033, 2004.
- [32] J. R. Millan, F. Galan, D. Vanhooydonck, E. Lew, J. Philips and M. Nuttin, “Asynchronous Non-Invasive Brain-Actuated Control of an Intelligent Wheelchair”, *2009 Annual International Conference Of The Ieee Engineering In Medicine And Biology Society*, Vol. 20, pp. 3361-3364, 2009.
- [33] J. L. Contreras-Vidal and R. G. Grossman, “NeuroRex: A Clinical Neural Interface Roadmap for EEG-based Brain Machine Interfaces to a Lower Body Robotic Exoskeleton ”, *Annual International Conference Engineering in Medicine and Biology Society (EMBC)*, pp. 1579-1582, 2013.
- [34] I. Sample, “Mind-controlled robotic suit to debut at World Cup 2014”, *The Guardian*, 2014.
- [35] T. Sakurada, T. Kawase, K. Takano, T. Komatsu, K. Kansaku: “A BMI-based occupational therapy assist suit: asynchronous control by SSVEP”, *Frontiers in Neuroscience*, Vol. 7, pp. 1-10, 2013,

- [36] N. A. Bhagat, J. French, A. Venkatakrisnan, N. Yozbatiran, G. E. Francisco, M. K. O Malley and J. L. Contreras-Vidal, “Detecting Movement Intent from Scalp EEG in a Novel Upper Limb Robotic Rehabilitation System for Stroke”, *Conf Proc IEEE Eng Med Biol Soc. 2014*, pp. 4127-4130, 2014.
- [37] G. Pfurtscheller and F.H. Lopes da Silvab, “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clinical Neurophysiology*, Vol. 110, pp. 1842-1857, 1999.
- [38] D. J. McFarland, L. A. Miner, T. M. Vaughan, J. R. Wolpaw, “Mu and Beta Rhythm Topographies During Motor Imagery and Actual Movements”, *Brain Topography*, Vol. 12, No. 3, pp. 177-186, 2000.
- [39] F. Lotte, M. Congedo, A. Lecuyer, F. Lamarche and B. Arnaldi, “A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces”, *Journal of Neural Engineering*, No. 4, pp. 1-24, 2007.
- [40] A. Bashashati, M. Fatourehchi, R. K. Ward, and G. E. Bricht, “A Survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals”, *Journal of Neural Engineering*, Vol. 4, pp. 32-57, 2007.
- [41] K. Shindo K, K. Kawashima, J. Ushiba, N. Ota, M. Ito, T. Ota, A. Kimura, M. Liu, “Effects of neurofeedback training with an electroencephalogram-based brain-computer interface for hand paralysis in patients with chronic stroke: a preliminary case series study”, *J Rehabil Med*, Vol. 43, pp. 951-957, 2011.
- [42] G. Pfurtschellera, G. R. Muller-Putz, J. Pfurtscheller and R. Rupp, “EEG-Based Asynchronous BCI Controls Functional Electrical Stimulation in a Tetraplegic Patient”, *Journal on Applied Signal Processing*, No. 19, pp. 3152-3155, 2005.

- [43] J. Long, Y. Li, H. Wang, T. Yu, J. Pan, and F. Li, "A Hybrid Brain Computer Interface to Control the Direction and Speed of a Simulated or Real Wheelchair", *IEEE Transaction on Neural Systems and Rehabilitation Engineering*, Vol. 20, No. 5, pp. 720-729, 2012.
- [44] C. L. Maeder, C. Sannelli, S. Haufe, and B. Blankertz, "Pre-Stimulus Sensorimotor Rhythms Influence Brain-Computer Interface Classification Performance", *IEEE Transaction on Neural Systems and Rehabilitation Engineering*, Vol. 20, No. 5, pp. 653-662, 2012.
- [45] M. Schroder, T. N. Lal, T. Hinterberger, M. Bogdan, N. J. Hill, N. Birbaumer, W. Rosenstiel, and B. Scholkopf, "Robust EEG Channel Selection across Subjects for Brain-Computer Interfaces", *Journal on Applied Signal Processing*, No. 19, pp. 3103-3112, 2005.
- [46] Y. Liu, W. Zhou, Q. Yuan, and S. Chen, "Automatic Seizure Detection Using Wavelet Transform and SVM in Long-Term Intracranial EEG", *IEEE Transaction on Neural Systems and Rehabilitation Engineering*, Vol. 20, No. 6, pp. 749-755, 2012.
- [47] T. Felzer and B. Freisleben "Analyzing EEG Signals Using the Probability Estimating Guarded Neural Classifier", *IEEE Transaction on Neural Systems and Rehabilitation Engineering*, Vol. 11, No. 4, pp. 361-371, 2003.
- [48] G. Garcia, T. Ebrahimi, and J. M. Vesin, "Classification of EEG Signals in The Ambigutty Domain for Brain Computer Interface Applications", *14th International Conference on Digital Signal Processing (DSP2002)*, 2002.
- [49] D. Garrett, D. A. Peterson, C. W. Anderson and M. H. Thaut, "Comparison of Linear and Nonlinear Methods for EEG Signal Classification", *IEEE*

- Transaction on Neural Systems and Rehabilitation Engineering*, Vol. 11, No. 2, pp. 141-144, 2003.
- [50] G. Garcia, T. Ebrahimi and J. Vesin, “Joint Time-Frequency-Space Classification of EEG in a Brain-Computer Interface Application”, *Journal on Applied Signal Processing*, No. 7, pp. 713-729, 2003.
- [51] 吉村奈津江, ダサーラ チャールズ・サヨ, 花川隆, 佐藤雅昭, 小池康晴: “信号源推定を用いた脳波からの筋活動信号の再構築,” 信学技報, Vol. 111, No. 315, pp. 35-40, 2011.
- [52] T. J. Bradberry, R. J. Gentili, and J. L. Contreras-Vidal, “Reconstructing Three-Dimensional Hand Movements from Noninvasive Electroencephalographic Signals”, *The Journal of Neuroscience*, Vol. 30, No. 9, pp. 3432-3437, 2010.
- [53] T. J. Bradberry, R. J. Gentili, and J. L. Contreras-Vidal: “Reconstructing surface EMG from scalp EEG during myoelectric control of a closed looped prosthetic device”, *Engineering in Medicine and Biology Society, 2013 35th Annual International Conference of the IEEE*, pp. 5602-5605, 2013.
- [54] L. J. Garey, “Brodmann’s Localisation in the cerebral cortex”, *Springer*, 1994.
- [55] D. Broetz, C. Braun, C. Weber, S. R. Soekadar, A. Caria and N. Birbaumer, “Combination of Brain-Computer Interface Training and Goal-Directed Physical Therapy in Chronic Stroke: A Case Report”, *Neurorehabil Neural Repair*, Vol. 24, No. 7, pp. 674-679, 2010.
- [56] N. Birbaumer and L. G. Cohen, “Brain-computer interfaces: communication and restoration of movement in paralysis”, *Journal of Physiology*, Vol. 579, No. 3, pp. 621-636, 2007.

- [57] Bashashati, A., Fatourech, M., Ward, R. K. and Birch, G. E., "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals" , *Journal Neural engineering*, Vol. 4, pp. 32-57, 2007.
- [58] G. Pfurtscheller and A. Aranibar, "Event-related cortical desynchronization detected by power measurements of scalp EEG", *Electroencephalography and Clinical Neurophysiology*, Vol. 42, pp. 817-826, 1977.
- [59] G. Pfurtscheller, A. Berghold, "Patterns of cortical activation during planning of voluntary movement", *Electroencephalography Clinical Neurophysiology*, Vol. 72, pp.250-258, 1989.
- [60] G. Pfurtscheller and F. H. L da Silva, " Functional meaning of event-related desynchronization (ERD) and synchronization (ERS), " *Event-related desynchronization. Handbook of electroencephalography and clinical neurophysiology. Revised Series*, Vol. 6, pp. 51-65, 1999.
- [61] G. Pfurtscheller and C. Neuper, "Motor Imagery and Direct Brain-Computer Communication", *Proceedings of the IEEE*, Vol. 89, No. 7, 2001.
- [62] V. V. Nikulin and T. Brismar, "Phase synchronization between alpha and beta oscillations in the human electroencephalogram", *Neuroscience*, Vol. 137, pp. 647-657, 2006.
- [63] D. J. Krusienski, G. Schalk, D. J. McFarland, J. R. Wolpaw, " μ -Rhythm Matched Filter for Continuous Control of a Brain-Computer Interface", *IEEE Transactions on Biomedical Engineering*, Vol. 54, No. 2, pp. 406-415, 2007.
- [64] W. H. Press, S. A. Teukolsky, W. T. Vetterling, B. P. Flannery, 訳者 丹慶勝市, 奥村晴彦, 佐藤俊郎, 小林誠, "Numerical Recipes in C[日本語版]C言語による数値計算のレシピ", pp. 379-391, 1993.

- [65] 木塚朝博, 増田正, 木竜徹, 佐渡山亜兵, “表面筋電図”, バイオメカニズム学会 (編), 東京電機大学出版局, 2008.
- [66] Clancy, E. A. and Hogan, N., “Relating Agonist-Antagonist Electromyograms to Joint Torque During Isometric, Quasi-Isotonic, Nonfatiguing Contractions”, *IEEE Transactions on Biomedical Engineering*, Vol. 41, No. 10, pp. 1024-1028, 1997.
- [67] Zhu, C., Okada, Y., Yoshioka, M., Yamamoto, T., Yu, H., Yan, Y. and Duan, F., “Power Augmentation of Upper Extremity by Using Agonist Electromyography Signals Only for Extended Admittance Control”, *IEEJ Journal of Industry Applications*, Vol. 3, No. 3, pp.260-269, 2014.
- [68] Matsubara H, Araki J, Takaki M, Nakagawa ST, Suga H, “Logistic Characterization of Left Ventricular Isovolumic Pressure-Time Curve”, *Japanese Journal of Physiology*, Vol. 45, pp. 535-552, 1995.
- [69] 北脇知己, 渡辺彰吾, 岡久雄, “ハイブリッドロジスティックモデルを改良した単収縮発揮張力曲線の新しい数理モデル”, 生体医工学会誌, Vol. 47, No. 2, pp. 199-208, 2009.
- [70] Jolliffe, I. T., ”Principal Component Analysis. 2nd ed.”, *Springer*, 2002.
- [71] 井上勝雄, “パソコンで学ぶ多変量解析の考え方”, 筑波出版会, 茨城, 1998.
- [72] 相良和彦, 田中靖人, 竹市博臣, 山下宙人, 長谷川良平, 岡部達哉, 前田太郎, “ブレインコミュニケーション 脳と社会の通信手段 ” (社) 電子情報通信学会 (編) (社) 電子情報通信学会, 東京, 2011.
- [73] 足立修一, “システム同定の基礎”, 東京電機大学出版局, 2009 .
- [74] Haykin, S., “Adaptive Filter Theory, Third Ed.l”, Upper Saddle River, NJ, Prentice-Hall, 1996.

- [75] 一條貞雄, 高橋系一, 脳波判別に関する 101 章 [第 2 版], pp. 28-39, 2009.
- [76] メディカルシステム研究所: “3.5 脳波とはなにか”, [http:// www.kenn.co.jp/text/eeg_text.pdf](http://www.kenn.co.jp/text/eeg_text.pdf), 2016/10/17 閲覧.

研究業績

学術論文

- M. Yoshioka, C. Zhu, K. Imamura, F. Wang, H. Yu, F. Duan and Y. Yan, "Experimental design and signal selection for construction of a robot control system based on EEG signals", *Robotics and Biomimetics*, pp.1-22, 26 November 2014.
- C. Zhu, Y. Okada, M. Yoshioka, T. Yamamoto, H. Yu, Y. Yan, F. Duan, "Power Augmentation for Upper Extremity only by Agonist's EMG with Extended Admittance", *IEEEJ Transactions on Industry Applications*, Vol.133, No.4 (2014), pp. 260-269.
- M. Yoshioka, C. Zhu, K. Uemoto, H. Liang, H. Yu, F. Duan, and Y. Yan, "Motion Classifier Generation by Mahalanobis Distance for BMI Robotic Arm Control System", *Journal of Neuroscience and Neuroengineering*, Vol.4, No.1, pp.1-8, June 2016.
- K. Uemoto, M. Yoshioka, H. Liang, and C. Zhu, "Effect of Motor Intensity on Motion Imagery with EEG Signal Analysis in Mirror Neuron System", *Journal of Neuroscience and Neuroengineering*, Vol.4, No.1, pp.31-36, June 2016.
- M. Yoshioka, H. Liang, N. Ueda, Y. Tian and C. Zhu "Construction of BMI Power Assistance System with EEG-Torque Model", *Neuroscience and Biomedical Engineering*, Volume 4, No.3, pp.1-6, 26 July 2016.

- 吉岡将孝, 吉川裕一郎, 上本和広, 梁宏博, 朱赤, “ パワーアシストシステムにおける脳波を用いた筋電推定手法の提案 ”, 日本機械学会論文誌, Vol. 83, No. 846, 2017.

国際学会

- M. Yoshioka, H. Lianga, N. Ueda, Y Tian and C. Zhu, ”Construction of BMI Power Assistance System with the EEG-Torque Model”, The 10th International Conference on Complex Medical Engineering, OS6-3, Tochigi, Japan, Aug, 2016.
- H. Liang, C. Zhu, Y. Yoshikawa, M. Yoshioka, K. Uemoto, H. Yu, Y. Yan and F. Duan, ”EMG Estimation from EEGs for Constructing a Power Assist System”, Proceedings of the 2014 IEEE International Conference on Robotics and Biomimetics, pp. 419-424, Dec, 2014.
- M. Yoshioka, C. Zhu, K. Uemoto, Y. Yuichiro, H. Yu, Y. Yan and F. Duan, ”Motion Classifier Generation Using EEG for Robot Control”, The 6th International IEEE EMBS Neural Engineering conference, ThET7, San Diego, USA, Nov. 2013.
- K. Uemoto, M. Yoshioka, C. Zhu, Y. Yuichiro, “ Analysis of the Relationship between Load and EEG by Wavelet Transform for BMI ”, Brain and Health Informatics, pp.459-468, Gunma, Japan, Nov. 2013.
- Y. Yoshikawa, C. Zhu, M. Yoshioka, K. Uemoto, Y. Yan, H. Yu and F. Duan, ”Muscular Activity Estimation From EEGs Using Principal Component Analysis for Brain Machine Interface”, Fifth International Brain-Computer Interface Meeting, Poster Presentarion1 - 93, ID138, San Francisco, USA, 2013.

- Y. Okada, C. Zhu, S. Shota, T. Suzuki, M. Yoshioka, Y. Yoshikawa, Y. Yan, H. Yu and F. Dung, "Motion Support of Upper Extremity with Agonist alone under Negative Admittance Control", Robotics and Biomimetics (ROBIO), 2012 IEEE International conference, Guangzhou, China, pp.1924-1929. Dec. 2012.
- T. Suzuki, C. Zhu, M. Yoshioka, S. Simazu, Y. Yoshikawa, Y. Okada, Y. Yan, H. Yu and F. Dung, "Motion Support of Upper Extremity with Agonist alone under Negative Admittance Control", Robotics and Biomimetics (ROBIO), 2012 IEEE International conference, Guangzhou, China, pp.974-979. Dec. 2012.
- M. Yoshioka, C. Zhu, Y. Yoshikawa, T. Nishikawa, S. Shimazu, K. Imamura, F. Wang, H. Yu, and Y. Yan, "Construction of Real-time BMI Control System Based on Motor Imagery", Robotics and Biomimetics (ROBIO), 2011 IEEE International conference, Phuket, Thailand, pp.198-203. Dec. 2011.
- C. Zhu, M. Suzuki, M. Oda, M. Yoshioka, T. Nishikawa and Y. Yan, "Real-time Control of Power Assist Device for Human Elbow Motion Support Using EMG Signal" The Proceedings of the 8th France-Japan and 6th Europe-Asia Congress on Mechatronics, Yokohama, Japan, Nov. 2010.

国内学会（査読付き）

- 吉岡将孝, 梁宏博, 岩田悠, 上田直哉, 田野, 朱赤, "脳波-筋電モデルによる関節トルク推定およびロボットアーム操作の実現", 第22回ロボティクスシンポジア, 4D3, 2017年3月(査読付き)
- 高林佑介, 石原昂亮, 吉岡将孝, 朱赤, "滑りを防ぐための2足歩行ロボットの足裏摩擦の拘束に関する検討", 第22回ロボティクスシンポジア, 1D4, 2017

年 3 月 (査読付き)

- 梁宏博, 朱赤, 吉岡将孝, 上田直哉, 田野, 岩田悠, “ 外骨格ロボットのパワーアシストを実現するための主成分分析を用いた肩関節屈曲伸展動作における脳波から表面筋電位の推定 ”, 第 22 回ロボティクスシンポジア, 5B1, 2017 年 3 月 (査読付き)
- 劉暢, 朱赤, 吉岡将孝, 梁宏博, 千葉遼平, “ 筋電信号による軽量腕型外骨格パワーアシストスーツの開発 ”, 第 22 回ロボティクスシンポジア, 5B2, 2017 年 3 月 (査読付き)
- 吉岡 将孝, 梁 宏博, 上田 直哉, 田 野, 朱 赤, “ 主成分分析を用いた脳波-トルクモデルによる BMI パワーアシストシステムの構築 ”, 第 21 回ロボティクスシンポジア, pp.38-43, 2016 年 3 月 (査読付き)
- 岡田 有司, 朱 赤, 島津 翔太, 吉岡 将孝, 鈴木 俊活, 吉川 裕一郎, “ ネガティブアドミッタンス制御による主動筋のみの EMG を用いた腕のパワーアシスト ”, 第 18 回ロボティクスシンポジア, pp.169-174, 2013 年 3 月 (査読付き)
- 吉岡 将孝, 吉川 祐一郎, 島津 翔太, 西川 知宏, 今村 一之, 王 峰, 朱 赤, “ 運動および運動想起時の脳波によるリアルタイム BMI を用いたロボット制御システムの構築 ”, 第 17 回ロボティクスシンポジア講演資料集, p224-229, 2013 年 3 月 (査読付き)

口頭発表 (学会全国大会, 研究会, ワークショップ)

- 吉岡将孝, 梁宏博, 上田直哉, 田野, 朱赤, “ Brain-Machine Interface パワーアシストシステムのための運動と関連する脳波の特徴を用いた筋電推定 ”, 第 34 回日本ロボット学会 学術講演会, 3W1-05, 2016 年 9 月

- 梁宏博, 朱赤, 吉岡将孝, 上田直哉, 田野, 岩田悠, “ Brain-Machine Interface によるロボット制御のための肩関節運動時の特徴情報の抽出 ”, 第 34 回日本ロボット学会 学術講演会, 1E2-07, 2016 年 9 月
- 吉岡 将孝, 梁 宏博, 上田 直哉, 田 野, 朱 赤, “ パワーアシストシステムの構築のための脳波を用いた筋電推定手法の提案 ”, 平成 28 年電気学会産業応用部門大会, HC-2-2-31, 2016 年 8 月
- 梁 宏博, 朱 赤, 吉岡 将孝, 上田 直哉, 田 野, “ 上肢のパワーアシストシステムを実現するための脳波を用いた肩関節の表面筋電位の推定 ”, 平成 28 年電気学会産業応用部門大会, PB-1-5-17, 2016 年 8 月
- 劉 暢, 朱 赤, 吉岡 将孝, 梁 宏博, 村田 吉孝, “ 筋電信号による装着可能な軽量腕型外骨格パワーアシスト装置の開発 ”, 平成 28 年電気学会産業応用部門大会, PB-1-5-18, 2016 年 8 月
- 上田 直哉, 吉岡 将孝, 梁 宏博, 田 野, 岩田 悠, 朱 赤, “ 前屈・後屈運動時における脳波の振幅変動解析 ”, 平成 28 年電気学会産業応用部門大会, Y-86, 2016 年 8 月
- 田 野, 朱 赤, 吉岡 将孝, 梁 宏博, 上田 直哉, “ Mirror Neuron System に基づいた運動情報の抽出に関する実験手法の検討 ”, 平成 28 年電気学会産業応用部門大会, Y-88, 2016 年 8 月
- 高林 佑介, 朱 赤, 吉岡 将孝, 森 裕和, “ 2 足歩行ロボットにおける高速歩行実現のための足底摩擦の拘束に関する基礎研究 ”, ロボティクス・メカトロニクス講演会 2016, 1P1-06a1, 2016 年 5 月
- 田 野, 朱 赤, 吉岡 将孝, 梁 宏博, 上田 直哉, “ Mirror Neuron System に基づいた運動情報の抽出に関する実験手法の検討 ”, ロボティクス・メカトロニクス講演会 2016, 1P1-12a7, 2016 年 5 月

- 梁 宏博, 朱 赤, 吉岡 将孝, 上田 直哉, 田 野, “ パワーアシストシステムを実現するための主成分分析を用いた脳波から肩関節の筋電位の推定 ”, ロボティクス・メカトロニクス講演会 2016, 2A2-01b6, 2016 年 5 月
- 吉岡 将孝, 梁 宏博, 上田 直哉, 田 野, 朱 赤, “ 脳波によるパワーアシストシステム実現のための筋電推定 ”, 第 33 回日本ロボット学会 学術講演会, 2L2-07, 2015 年 9 月
- 劉 暢, 朱 赤, 山本 多聞, 梁 宏博, 吉岡 将孝, “ 筋電信号による装着可能な装着可能な軽量腕型外骨格パワーアシスト装置の開発 ”, ロボティクス・メカトロニクス講演会 2015, 1A1-Q01, 2015 年 5 月
- H. Liang, Y. Yoshikawa, M. Yoshioka, K. Uemoto and C. Zhu, “EMG Estimation from EEGs for Constructing a Power Assist System”, 第 32 回日本ロボット学会学術講演会, 1P1-03, 2014 年 9 月
- 吉岡 将孝, 吉川 裕一郎, 上本 和広, 梁 宏博, 朱 赤, “ パワーアシストシステムの構築のための脳波を用いた筋電推定手法の提案 ”, 平成 26 年電気学会産業応用部門大会, 2-21, pp.II - 167 - 172, 2014 年 8 月
- 渡辺 瑛介, 吉岡 将孝, 朱 赤, “ 調理支援システムにおける画像処理を用いた調理動作認識 ”, 平成 26 年電気学会産業応用部門大会, Y-127, 2014 年 8 月
- 上本 和広, 吉岡 将孝, 吉川 裕一郎, 朱 赤, “ ミラーニューロンシステムに基づいた Brain-Machine Interface における脳波と運動強度 ”, ロボティクス・メカトロニクス講演会 2014, 3P2-P04, 2014 年 5 月
- 吉岡 将孝, 吉川 裕一郎, 上本 和広, 岡田 有司, 鈴木 俊活, 朱 赤, “ ロボットアーム制御における脳波によるマハラノビスの汎距離を用いた運動判別の提案 ”, 第 31 回日本ロボット学会学術講演会, 1E1-08, 2013 年 9 月
- 上本 和広, 朱 赤, 吉岡 将孝, 吉川 裕一郎, “ Brain-Machine Interface にお

けるウェーブレット変換を用いた脳波 (EEG) による運動識別に関する基礎研究 ”, ロボティクス・メカトロニクス講演会 2013, 1P1-B02, 2013 年 5 月

- 鈴木 俊活, 吉岡 将孝, 稲垣 和夫, 中山 武, 吉川 裕一郎, 岡田 有司, 朱 赤, “ 全方向移動支援ロボットの開発 第 4 報 ”, 第 30 回日本ロボット学会学術講演会講演概要集, 1K2-6, 2012 年 9 月
- 岡田 有司, 朱 赤, 島津 翔太, 西川 知宏, 吉岡 将孝, 鈴木 俊活, 吉川 裕一郎, “ ネガティブアドミッタンス制御を用いた 1 関節 1 センサで実現する腕のパワーアシスト技術の開発 ”, 第 30 回日本ロボット学会学術講演会講演概要集, 2K3-6, 2012 年 9 月
- 吉川 裕一郎, 吉岡 将孝, 朱 赤, 上本 和広, 島津 翔太, 岡田 有司, “ Brain-Machine Interface によるロボット制御のための主成分分析を用いた脳波からの筋活動推定 ”, 第 30 回日本ロボット学会学術講演会講演概要集, 4C2-6, 2012 年 9 月
- 吉岡 将孝, 吉川 裕一郎, 上本 和広, 島津 翔太, 西川 知宏, 岡田 有司, 鈴木 俊活, 朱 赤, “ 運動および運動直前に関する EEG を用いた腕型ロボットアームの角度決定 ”, 第 30 回日本ロボット学会学術講演会講演概要集, 4C2-7, 2012 年 9 月
- 吉岡 将孝, 吉川 裕一郎, 島津 翔太, 西川 知宏, 鈴木 俊活, 岡田 有司, 伊藤 貴庸, 朱 赤, “ 運動または運動想起における特徴変化を用いたロボットアームの制御 ”, ロボティクス・メカトロニクス講演会 2012 概要集, No.12-3, pp.157-162, 2012 年 5 月
- 吉岡 将孝, 吉川 裕一郎, 島津 翔太, 西川 知宏, 今村 一之, 王 峰, 朱 赤, “ 運動および運動想起時の脳波を用いたリアルタイム BMI 制御システムの構築 ”, 第 29 回日本ロボット学会学術講演会講演概要集, p204-207, 2011 年 9 月

- 小田 真史, 朱 赤, 西川 知宏, 吉岡 将孝, 島津 翔太, “ 全方向移動支援ロボットの開発 (第 2 報) -アドミッタンス制御を用いたロボット操作- ”, 第 28 回ロボット学術講演会, 1J3-4, 2010 年 9 月
- 島津 翔太, 朱 赤, 西川 知宏, 吉岡 将孝, 小田 真史, 鈴木 将之, “ 筋電位信号を用いた腕型パワーアシスト装置の開発 ”, 第 28 回ロボット学術講演会, 2J1-3, 2010 年 9 月
- 小田 真史, 朱 赤, 西川 知宏, 吉岡 将孝, 島津 翔太, “ アドミッタンス制御を用いた車椅子型全方向移動支援ロボットにおける歩行支援及びパワーアシストに関する研究 ”, 第 31 回バイオメカニズム学術講演会, 1A1-1, 2010 年 4 月
- 島津 翔太, 朱 赤, 西川 知宏, 吉岡 将孝, “ アドミッタンスおよび筋電位信号を用いた腕型パワーアシスト装置の開発 ”, 第 31 回バイオメカニズム学術講演会, 2C4-2, 2010 年 4 月

附録

脳波及び筋電計測環境

本研究で用いる実験システム全体の構成を図 8.2 に示す。まず、被験者の腕の角度はポテンシオメータを用い、脳波と筋電は生体アンプを介して増幅し、それぞれインターフェースボード (HRP Interface Board 07-0003-1 (有) 図工製) (図 8.3) (スペックは表 8.1) の AD 変換を行い、Linux PC にてデータの記録する。そして、Linux PC で信号処理し、DA 変換によりモータドライバに指令値を送り、ロボットアームの駆動させる。ロボットアームの角度はエンコーダ、エンコーダカウンタを介して、Linux PC にデータが送られる。また、IO ポートにて、スイッチや LED、スピーカーの入出力を行う。

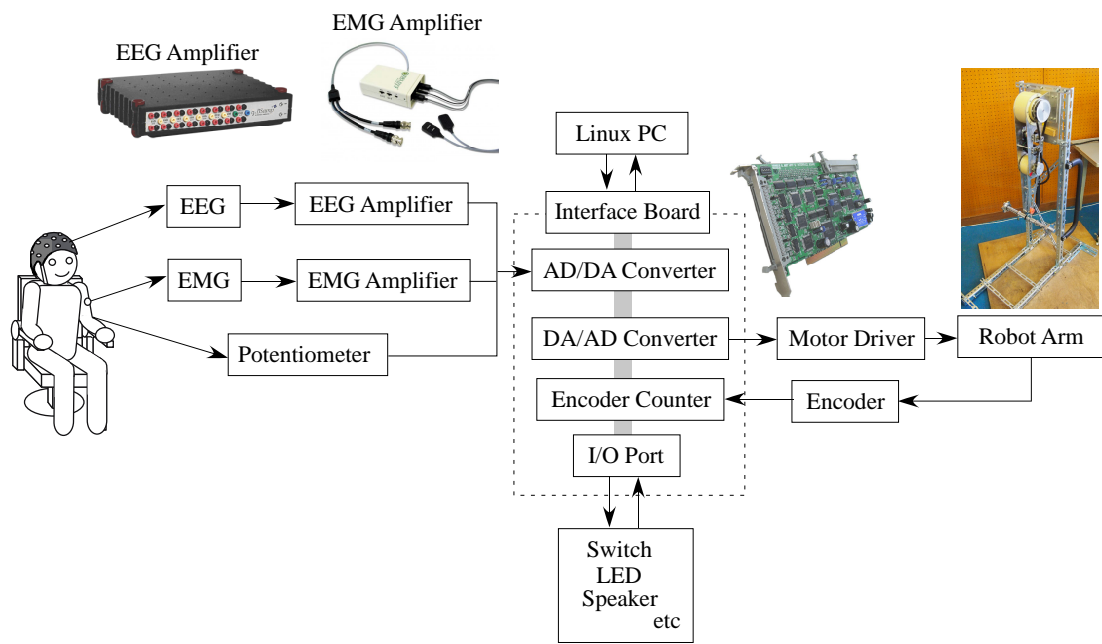


図 8.2: 実験システムの構成




図 8.3: HRP Interface Board 07-0003-1 (有) 図工製

表 8.1: HRP Interface Board 07-0003-1 (有) 図工製) のスペック

A/D	12[bit], 16[ch], $\pm 10[V]$
D/A	12[bit], 16[ch], $\pm 10[V]$, 30[us](typ)
PIO	TTL、IN16[ch] / OUT16[ch]
エンコーダ カウンタ	24[bit], 16[ch], 4[MHz](max) TTL・ラインレシーバ両対応

次に、各機器について紹介する．

脳波アンプ

人の皮膚上から計測可能な生体信号は、非常に小さく増幅するために生体アンプが用いられる．本研究では脳波を計測するために、図 8.4 に示す g.tec 社製の 8 チャンネル増幅アンプ g.BSamp を用いる．g.BSamp には複数のフィルターが搭載されており、使用者が設定を行うことが可能である．その仕様を以下に記載する．

- Configurations : 8 channels (2 sep. GNDs)
- Sensitivity : $\pm 500 \mu\text{V}$ or $\pm 5 \text{ mV}$
- Notch filter : 50 Hz (or 60 Hz) [on or off]
- Highpass filter : 0.5 Hz or 2 Hz
- Lowpass filter : 100 Hz or 1k Hz

本研究では、センサビリティを $\pm 500 \mu\text{V}$ 、50Hz のノッチフィルタとバンドパスフィルタの通過帯域を 0.5-100Hz に設定し、エリアシングの影響を除去した．



図 8.4: g.BSamp

脳波電極

電極には同社 (g.tec 社) のアクティブ電極である g.GAMMAsys を使用する (図 8.5)。アクティブ電極はアンプを内蔵しており、通過帯域は 0.1-10kHz であり、電極接触インピーダンスに左右されにくく、コードのゆれるような装着環境下でも高精度の測定が可能なることから運動時の測定にも利用することが可能である。また、電極と身体が直接接触する部分は Ag/AgCl 製で、電気抵抗を下げるため電解ゲルを注入して用いる。その仕様を以下に記載する。




図 8.5: g.GAMMAsys

(A) アクティブ電極 ,(B) 耳朶用アクティブ電極 ,(C) アクティブ用インターフェース/ドライバーボックス (D) 電解ゲル

脳波ヘッドキャップ

脳波ヘッドキャップには国際的な計測点である図 8.6 に示す国際 10-20 法を基に作成された g.GAMMAcap² ヘッドキャップ (g.tec 社) を用いる (図 8.7) . 国際 10-20 法では頭部を 10 % もしくは 20 % の等間隔に分割して位置を定めるため, 複数回の検査や使用者の変更があっても, 同一部位につけることが出来るので位置に関して再現性のある結果を得ることが可能である [76] .




図 8.6: 国際 10-20 法



図 8.7: 脳波ヘッドキャップ
g.GAMMAcap² (g.tec)

筋電位 (electromyogram: EMG) の計測

また、本研究では筋電位 (electromyogram: EMG) の計測を同時に行う。EMG は筋肉が収縮する際に発生する微弱な 0.1-10mV の電位変動を増幅しスパイク状の信号である。この信号は、人の運動と関連しており、筋肉の収縮・伸長を定量的に判定することが出来る。本研究ではEMGのアンプに DELSYS 社製の 2 CH の筋電アンプ 8.2 を用いる。また、その仕様を表 8.2 にまとめる。



図 8.8: EMG アンプ Bagnoli Desktop EMG System (Delsys, inc.)

表 8.2: EMG アンプの仕様

チャンネル数	2 ch
1 チャンネルあたりの総合的な増幅	100 倍, 1000 倍, 10000 倍
出力電圧範囲	$\pm 5V$
周波数特性	20 \pm 5Hz to 450 \pm 50Hz,12dB

ロボットアーム

本研究で用いるロボットアームの仕様は以下のように設計されている。

1. 各リンクの長さ：30cm
2. 負荷 30kg . 負荷をかける場所は第 1 リンクの真中と想定
3. モータと回転関節の間は，タイミングベルトとプリーを介す
4. プリーの減速比（モータ軸：関節軸）：関節 1 ， 1 : 3 ; 関節 2 ， 1 : 5
5. モータは，Maxon 社の RE40(150W) の DC モータ
6. 関節 1 のハーモニックギア：CSG-20-160-2A-GR

関節 2 のハーモニックギア：CSG-32-160-2A-GR

減速比（モータ軸：関節軸）：関節 1 ， 1 : 1 6 0 ; 関節 2 ， 1 : 1 6 0

このロボットアームは負荷 30[kg] のものを持ち上げられるように設計されている。




図 8.9: ロボットアーム