

2019年度 博士学位論文
上肢のパワーアシストにおける
脳波を用いた関節トルクの推定に関する研究

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

1656504

梁 宏博

Hongbo LIANG

審査員

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

謝辞

本論文は、筆者が前橋工科大学大学院工学研究科博士後期課程環境・生命工学専攻在学中に朱研究室において行った研究をまとめたものです。本論文を終えるにあたり、本研究に関して終始ご指導ご鞭撻を頂きました本学朱赤教授に心より感謝致します。担当教員である朱赤教授は研究の初歩からお教えくださるとともに、その着眼点や重要性を説いてくださり、多くの面から立派な研究者になる心得を教えてくださいました。さらに、研究遂行するにあたっての脳波計測に必要な研究設備や実験環境を揃えていただき、論文執筆にあたっては多くの助言やサポートもいただきました。その貴重な時間、アイデア、研究費用のすべての大きな貢献に誠に感謝いたします。朱赤教授の学生であったことは大変光栄なことであり、その献身で勤勉な姿勢は常に私を励ましてくださりました。

また本論文を審査して頂いた審査委員会の王鋒教授、今村一之教授、田中恒夫教授、横井浩史教授、朱赤教授に深く感謝いたします。多忙な委員会の先生方から生理学、神経学、電気制御、機械構造に関する知識の教示や丁寧なご指導、励ましを頂き、私の研究の進展に大いに役立てることができました。特に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やアドバイスをいただきました。ここに深く感謝を申し上げます。

本論文の執筆にあたってご助言、また本研究に対し多大な支援を頂きました朱研究室の学生諸氏に深く感謝いたします。また、本研究に関して一緒に学び研究を行った、前殿翔太氏、郁迎新氏、上田直哉氏、李沛讓氏、青木真孝氏、持田美佳氏、劉暢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工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。

最後に家族や友人からの無条件の愛とサポートに感謝致します。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15K00362）研究助成金や公益財団法人大塚敏美育英奨学財団からのご支援によって，研究が大きく進展したことをここに御礼申し上げます。

概要

障害者の数が増加するとともに、介護者の負担も増加していく。特に重い荷物を持ち上げる荷役動作や介護者が患者を抱えての移動の際、上肢の肩と肘の関節に大きな負担がかかる。したがって、肩と肘関節の屈曲と伸展方向でパワーアシストを行うことは非常に有意義である。そのため現在は、世界中多くの国が外骨格ロボットによる様々なパワーアシスト装置を開発している。これまでのパワーアシスト装置の制御信号は、主に力/トルクセンサーと筋電センサーを用いて取得していた。しかし、一般的な力センサーは高価であり、また筋電センサーの場合、肩関節・股関節などの多関節機構において、各筋肉の動作を高精度に推定するためには、多数のセンサーを用いなければならない。さらに、加齢に伴う筋力の減衰により、これらのセンサーの効果も大幅に低下していき、現在に至るまで、これらの問題に対する適切な解決策はない。一方、近年脳活動をデコードして、運動意図の指令を生成することで、外部の装置を制御する Brain-Machine Interface (BMI) 技術が大きな注目を集めており、その研究が進められている。BMI 技術は筋肉以外の通信方法を提供するため、脳の完全性を利用して外部装置を制御することにより、体の欠陥を補い、または体の機能を高めることができる。これによって、BMI 技術は、筋電やその他の信号に基づく制御技術よりも正確で自然な制御方法である。初期の BMI 技術はヒトの失われた、もしくは麻痺している運動機能の代行、あるいは復元を目的として、様々な装置が開発された。現在、BMI 技術を用いてコンピューターのカーソル、車椅子、キーボード、リハビリテーション機器、外骨格ロボットなどの制御が実現されている。体を動かすことができない障害者のために、将来的には医療リハビリテーションや福祉分野でより広く使用されることが期待されている。近年、ヒトの意思に係る脳活動を制御信号に変

える事を目的とし研究が進められている。しかし、現時点では重労働従業員や介護スタッフなどの健常者向けのBMI製品はほとんどない。このため、本研究では上記の問題をBMI技術を用いて解決するため、脳活動から関節トルク情報を抽出および推定する手法を提案し、健常者のQoL (Quality of Life) 向上と作業現場における作業効率の向上を目指す。私たちの研究チームは2016年に脳波信号から肘関節のトルクを推定することに成功した。そのため、本論文では主に肩関節のトルクの推定に着目し、また肩と肘関節の連動動作時の特徴の抽出と運動パターンの認識手法を検証することにより、BMI技術に基づく上肢パワーアシストシステムの構築を行う。本論文は、BMI技術に基づいた肩関節の屈曲と伸展運動においてパワーアシストを適用する世界初の研究報告である。

本論文では、まず擬似拮抗筋の概念を導入することにより、脳波に基づくパワーアシストシステムの構築する手法を提案する。具体的には、まず主成分分析により特徴を抽出し、脳波-トルクの線形モデルを構築、そして肩関節のアシストに必要なトルクを推定する。実験結果より、本BMI技術を用いて健常者にパワーアシストを行うことが可能となることが示された。また、肩関節の屈曲と伸展運動による脳波の変化部位や特徴も明らかにした。この特徴を用いたモデルを構築することにより、パワーアシストに必要なトルクの推定に成功した。さらに特徴を抽出する際に、注目する脳波の周波数帯域を以前の肘関節の研究方法よりも広く、そして細かくすることで、この手法の汎用性をも同時に示した。これらの内容について第5章にて述べる。

次に、脳波信号は時変信号であることを考慮した上で、時変信号によるシステムへの影響を減らすために、脳波の変化と運動の間の遅延を考慮した線形モデルを再構築し、肩関節のパワーアシストに必要なトルクを推定した。実験結果より提案した手法の有効性を示している。またこの手法により、連続動作のトルクの推定にも成功したため、この手法に基づくリアルタイムでのパワーアシストを行える可能性が示された。これを第6章にて述べる。

また肩と肘関節の連動を実現するためには、まず様々な運動パターンの脳波の

変化の特徴を明確化し、抽出する必要がある。したがって第7章では、特徴を効果的に抽出できるいくつかの手法について説明し、検証した。実験結果より、これらの手法の有効性を確認し、また抽出された特徴を用いて、脳波に基づく肩と肘の運動パターンの識別を実現することが可能となることを示唆した。

BMIには2つの絶対的な課題がある。1つ目は、脳から適切な情報を取得する手法である。つまり「脳から機械へ」の流れであり、脳の出力信号をキャプチャし、ニューロンが何をしているかを理解することである。本論文の第7章まではこれに関する究明である。2つ目は、正しい情報を脳に入力する手法である。つまり「機械から脳へ」の流れであり、機械を用いて脳に情報を入力することで刺激し、脳の変化を促すことを示す。したがって第8章にて、2つ目の課題に対する手法の試行と検討を行う。まず脳の可塑性を検証するためにBMIユーザーを訓練し、訓練の有効性とそれに基づく脳活動の変化について検討した。実験結果より、視覚フィードバックを用いた訓練による特定の脳波成分の変化分の増強を観測することができたため、新たな特徴量として有用できる可能性を見出した。これらの結果は、BMI技術が今後の我々の生活に広く浸透するための将来性の高さを証明するものだと断言できる。

最後に第9章にて、まとめを行い、今後の展望について述べる。本論文の構成を図1に示す。

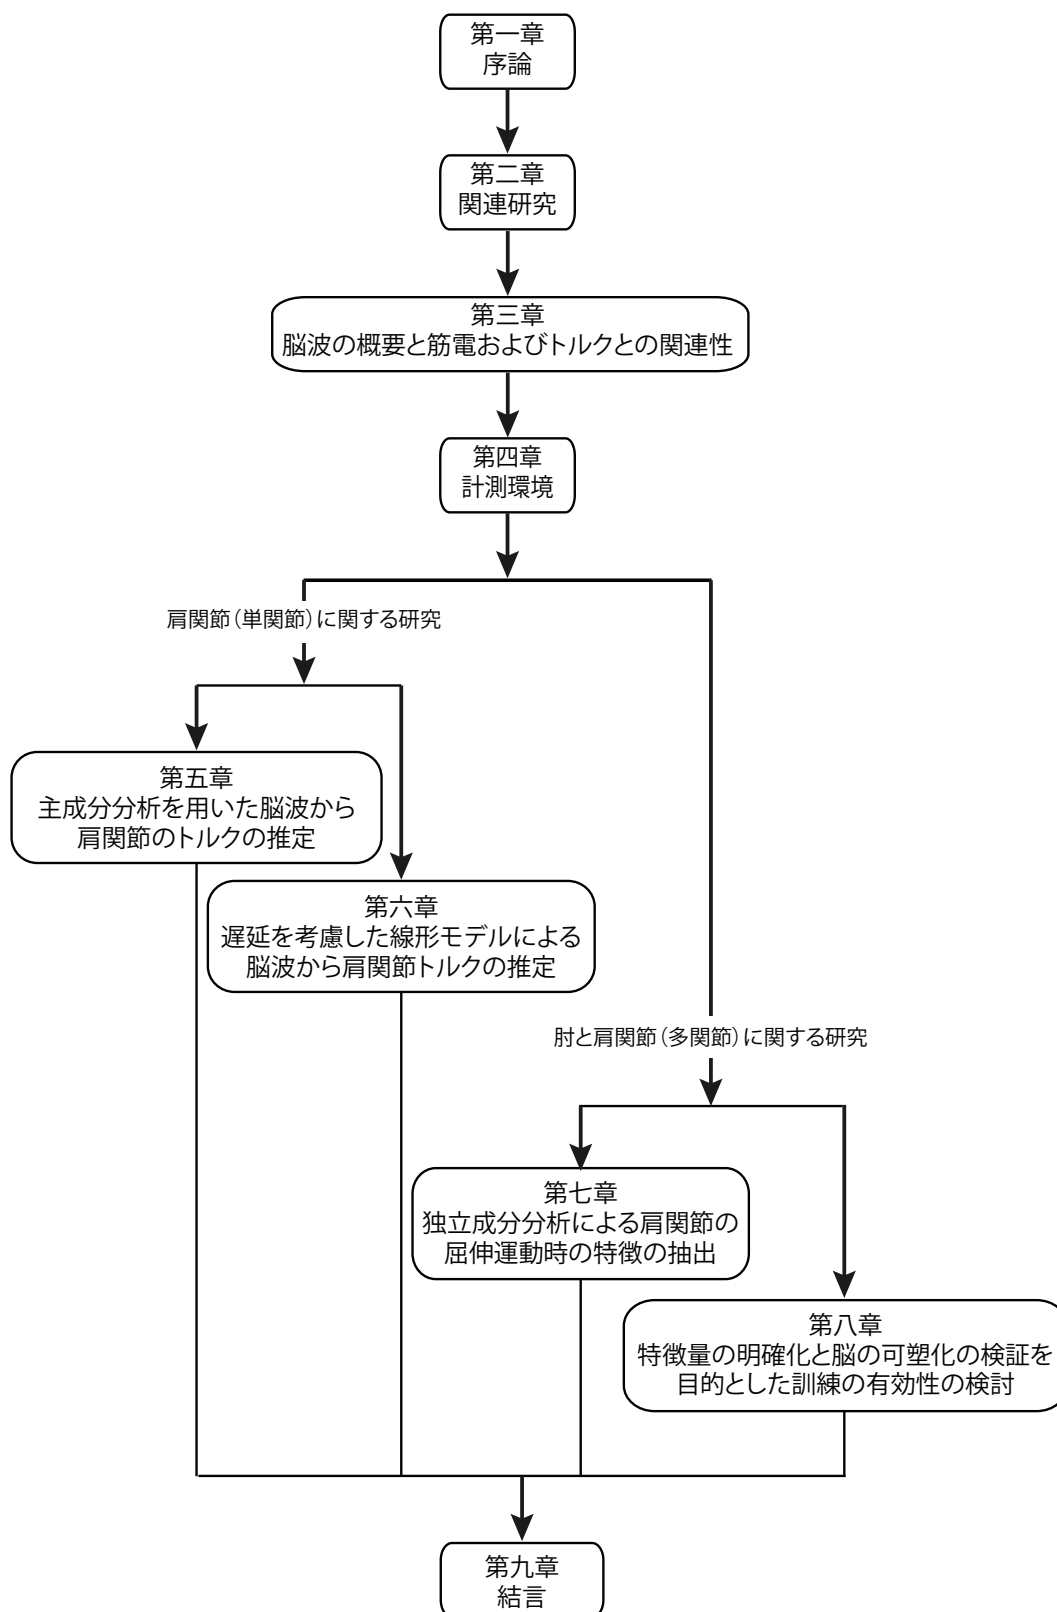


図 1: 本論文の構成

Abstract

Currently, the increased number of aged people with disabilities has been a more serious problem. Thus, the care burden associated with this problem also has increased dramatically. Especially, in the case of transferring a patient or goods in the field of caregiving and daily life, it puts a great burden on the shoulder and elbow joints of the upper limbs. Therefore, the power augmentation of flexion and extension of the shoulder and elbow joints are necessary and meaningful. At present, many countries have developed various power augmentation exoskeleton robots to solve those problems. Force/torque sensors and electromyography (EMG) sensors are mainly used to obtain the control signals for the exoskeleton power augmentation devices. However, the prices of various types of sensors are expensive, and the sensors are not suitable for complex joints (such as the shoulder joint or hip joint), which involves the polyarticular muscles, especially in the case of EMG sensors. Moreover, the number of motor nerves will decrease with age, and then the motor unit will reduce and cause muscle atrophy, which results in low muscle strength and weak EMG signals or no accurate EMG signals at all. Unfortunately, there is no good solution to those problems so far.

On the other hand, in recent years, Brain-Machine Interface (BMI) has attracted many researchers. BMI is a technique that uses brain activities or other brain function measurements to decode the neural activities into motion intention and generate the control commands for the control of external devices. As the BMI system provides a non-muscle communication channel that can use the integrity of the brain to control external devices to compensate for physiological

defects and hypokinesia, BMI is a more accurate and natural control method than the EMG-based control method. Initially, BMI technology was applied in the field of rehabilitation and medical care to help people with physical disabilities restore social interaction or movement function. At present, it can be considered as a new and unique way of communication to help patients carry out rehabilitation and support them in daily life. For example, control of keyboards, wheelchairs, rehabilitation devices, exoskeleton robots, etc. have been realized. Meanwhile, it really reduces the cost and the burden of care. In the future, it is expected to be used more widely in medical rehabilitation and welfare fields. However, there are still very few BMI products for supporting the daily life of healthy people, such as people who do hard physical labor, nursing and so on.

Therefore, this study focuses on solving the aforementioned problems and proposes a method that to extract and estimate the joint's torque information from the brain activities directly to construct an upper limb power augmentation system through BMI technology to improve the quality of life and increase the efficiency of work for healthy users.

Since our research team has successfully estimated the torque of the elbow joint from the electroencephalogram(EEG) signal in 2016, in this paper, firstly, we focus on the estimation of shoulder joint's torque, and secondly, we verify the methods of feature extraction and motion pattern recognition to construct and improve an upper limb power augmentation system based on BMI technology when the shoulder and elbow joints moved. So far, this paper is the first research report in the world on power augmentation for flexion and extension of shoulder joint based on BMI technology.

In this paper, we proposed a method of constructing a power augmentation system based on EEG signals by introducing the concept of virtual muscle at first. Specifically, features are extracted by principal component analysis, a linear model

of the EEG-torque is constructed, and the torque required for power augmentation of the shoulder joint is estimated. From the results, it shows the possibility that BMI technology can provide power augmentation to healthy people. At the same time, the feature of EEG signals and the active parts of the brain during flexion and extension of the shoulder joint are also clarified. These features are effectively extracted for the construction of the EEG-torque model. Moreover, since the range of frequency of the EEG signals which focused on and used for feature extraction is wider compared with the previous research method of the elbow joint, the proposed method has better robustness. These contents will be covered in Chapter 5.

Considering that the EEG signal is a time-varying signal, we reconstruct a linear model that considers the delay between EEG signals and motion to reduce the impact of the time-varying signal on the system. The results show that the effectiveness of the proposed method is verified. Moreover, we also realize the estimation of the torque for continuous actions by the proposed method, which shows the possibility of estimation in real-time. These contents will be described in Chapter 6.

In order to achieve the coordination of the shoulder and elbow joints, it is necessary to clarify and extract the features of EEG signals in various patterns firstly. In Chapter 7, we discussed and validated several methods that can effectively extract these features. From the results, it shows the possibility to realize the recognition of the shoulder-elbow motion pattern based on EEG signals.

BMI contains two basic questions. The first one is how to get the right information from the brain. That is, "from the brain to the machine", to capture the output signal of the brain and try to understand what the neurons are doing. So until Chapter 7, we are trying to clarify this question. The second one is how to send the right information to the brain. That is, "from the machine to the brain", to use the machine to stimulate or input information to the brain to change the

natural state of the brain. In Chapter 8, we trained the users of BMI to verify the plasticity of the brain, and then discussed the effectiveness of training. As a result, we observed changes in EEG signals after training. At the same time, through training and visual feedback system we constructed, we found that some features of EEG signals are enhanced, and even some new features are generated after training. These results further demonstrate the potential of BMI technology to be widely used in future life.

Finally, Chapter 9 summarizes this study and discusses future works.

目次

謝辞	i
概要	iii
Abstract	vii
第1章 序論	1
1.1 研究背景	1
1.2 目的	3
1.3 本文の構成	3
第2章 関連研究	5
2.1 Brain-Machine Interface(BMI) の定義およびその応用	5
2.2 BMI による運動情報の再構築	8
2.2.1 侵襲型 BMI	8
2.2.2 非侵襲型 BMI	11
2.3 本研究グループの先行研究の成果	17
2.3.1 ロボットアームを制御するための運動判別	17
2.3.2 脳波を用いた筋電推定によるパワーアシストシステムの構築 に関する基礎研究	18
2.4 本研究の位置付け	19
2.4.1 非侵襲型 BMI 計測手法の選定	20
2.4.2 運動タスクの指定	20
2.5 本研究の内容	21

第3章	脳波の概要と筋電およびトルクとの関連性	22
3.1	脳波とは	22
3.2	筋電とは	29
3.3	脳波と筋電の関連性	29
3.3.1	発生のメカニズム	29
3.3.2	脳波と筋電間のコヒーレンス	30
3.4	筋電とトルクの関連性	33
3.5	関連性のまとめ	35
第4章	計測環境	36
4.1	脳波の計測装置	36
4.1.1	電極	36
4.1.2	ヘッドキャップ	37
4.1.3	生体アンプ	37
4.2	表面筋電位の計測装置	39
4.2.1	電極	39
4.2.2	増幅アンプ	40
4.3	インターフェイスボード	41
4.4	オペレーティングシステム	42
4.5	本研究の計測システム	43
第5章	主成分分析を用いた脳波から肩関節のトルクの推定	44
5.1	提案手法	44
5.1.1	運動に参与する脳波成分の抽出	44
5.1.2	脳波－表面筋電位の線形モデルの作成	45
5.2	実験設計	47
5.2.1	計測点に関する研究まとめ	47
5.2.2	タスク設計および計測内容	50

5.3	データ処理	52
5.3.1	脳波信号の処理	52
5.3.2	筋電信号の処理	53
5.4	データ解析と推定結果	54
5.4.1	脳波信号の前処理の結果	54
5.4.2	短時間フーリエ変換 (STFT) の結果	54
5.4.3	主成分分析の結果-運動関連脳波の抽出	57
5.4.4	推定結果と考察	60
5.5	まとめ	64
第 6 章	遅延を考慮した線形モデルによる脳波から肩関節のトルクの推定	65
6.1	線形モデルの作成手法	65
6.2	実験設計	67
6.3	脳波信号の解析結果	69
6.3.1	脳波の各周波数帯域成分の分布	69
6.3.2	各独立成分の特性	72
6.3.3	目の動きに関する成分	74
6.3.4	運動に関連する脳波の成分	75
6.4	推定結果および考察	79
6.4.1	単一試行の推定結果	79
6.4.2	連続運動時の推定結果と考察	79
6.5	まとめ	81
第 7 章	独立成分分析による肩関節の屈伸運動時の特徴の抽出	82
7.1	運動と関連する脳波成分の抽出手法の提案	83
7.2	実験内容	85
7.3	信号処理	86
7.3.1	筋電信号の処理および動作の開始時刻の検出	86

7.3.2	脳波信号の処理	88
7.4	実験結果	89
7.4.1	独立成分分析の結果および各成分の定義	89
7.4.2	眼電位成分の特徴および生データに与える影響	94
7.4.3	脳波の運動に関連する特徴成分の抽出結果および考察	94
7.4.4	筋電と脳波の特徴との関係および考察	98
7.5	まとめ	99
第 8 章 特徴量の明確化を目的とした脳の可塑性の検証と訓練の有効性の検討		100
8.1	ニューロフィードバック訓練の原理と歴史	102
8.1.1	原理	102
8.1.2	歴史	102
8.2	一般健常者におけるニューロフィードバック訓練の有効性	104
8.3	脳波ニューロフィードバック訓練の利点	107
8.4	実験内容	108
8.4.1	計測部位	108
8.4.2	実験タスク	109
8.5	処理手法	110
8.6	実験結果および考察	111
8.6.1	各周波数帯域の結果	111
8.6.2	訓練による効果	114
8.6.3	訓練の結果に関する考察	129
8.7	まとめ	130
第 9 章 結言		131
9.1	まとめ	131
9.2	今後の展望	132

参考文献	133
業績	150
付録	158
付録 A デジタルフィルタ	158
A.1 バターワースフィルタの設計	159
付録 B 短時間フーリエ変換	162
B.1 窓関数	162
B.1.1 オーバーラップ処理	168
B.1.2 振幅回復係数の考慮	168
付録 C 主成分分析	170
付録 D 独立成分分析	174
付録 E 加算平均処理	177
付録 F 表面筋電信号の一般処理手法	179
F.1 整流平滑化	179
F.2 移動平均法	179
付録 G 前処理による独立成分分析の結果の違いの検討	183
G.1 ハイパスフィルタによる相違の検討	184
G.2 ICA とエポックの処理順番による違いの検討	184

目 次

1	本論文の構成	vi
1.1	本論文の構成	4
2.1	判別器による判別結果 [46]	17
2.2	処理手順 [48]	18
2.3	推定結果 [48]	18
3.1	運動関連電位の概念図	28
3.2	脳から筋への出力	31
4.1	g.GAMMAsys	36
4.2	国際 10-20 法	38
4.3	EEG ヘッドキャップ (g.GAMMAcap ²)	38
4.4	10-10 電極配置法 [83]	38
4.5	脳波計アンプ (g.BSamp)	38
4.6	筋電の電極	39
4.7	筋電計アンプ (The Bagnoli-2 EMG System)	40
4.8	本研究の計測環境の概観	43
5.1	推定手法の概要図	45
5.2	関連研究の計測点のまとめ	49
5.3	脳波と筋電の計測タスク	51
5.4	脳波の信号処理の流れ	52
5.5	筋電の信号処理の流れ	53

5.6	筋電の信号処理結果	53
5.7	脳波信号の前処理結果	55
5.8	STFT の解析結果	57
5.9	主成分分析の解析結果	58
5.10	EEG 信号から推定された EMG 信号の結果. (a) , (b) および (c) は, 被験者 A, B, および C の結果を表す.	61
5.11	被験者 A, B および C の交差検定の結果	62
5.12	モデルの推定結果の平均値と標準誤差	63
6.1	脳波と筋電の計測環境とタスク	68
6.2	各電極の周波数特性 1	70
6.3	各電極の周波数特性 2	71
6.4	脳波の各周波数帯域の頭皮上の分布	72
6.5	独立成分分析結果 (成分 1-8)	73
6.6	独立成分分析による信号分離結果 (波形)	74
6.7	目の動きの確認	75
6.8	開眼と閉眼の波形	75
6.9	眼電位や眼球運動成分の除去の前後 (青 : 除去前, 赤 : 除去後)	75
6.10	運動に関連する脳波成分 (IC1) と筋電の比較	76
6.11	図 6.10 の一部の拡大図 (但し EEG を正規化している)	76
6.12	独立成分分析の IC1 の FFT 変換結果	77
6.13	10-13 秒の 3 秒間の単一試行データを用いたモデルの推定結果	79
6.14	先行研究の手法の検証	80
7.1	脳波と筋電の計測環境とタスク	85
7.2	運動開始時刻の定義と検出	87
7.3	被験者の三人の ICA の結果	90
7.4	被験者 A の各実験における各独立成分の波形	91

7.5	被験者 B の各実験における各独立成分の波形	92
7.6	被験者 C の各実験における各独立成分の波形	93
7.7	被験者 A (a), B (b) および C (c) の各独立成分 (IC) の頭皮上 の分布	95
7.8	ICA によって測定された EEG 信号から分解された瞬きによる電位 変化の特徴的な波形.	96
7.9	瞬き成分と EEG 信号間の関係と影響. 青い線は測定された EEG 信 号であり, 赤い線は図 7.8 の瞬き成分である.	96
7.10	被験者 A(a), B(b) および C(c) の運動に関連する脳波成分から抽出 した各チャンネル毎の特徴.	97
7.11	脳波の運動に関する特徴信号の遷移図.	98
8.1	訓練の実験環境	109
8.2	信号処理の流れ	110
8.3	運動と関連成分の各チャンネルの各周波数帯域の波形	112
8.4	運動に関連する成分 (δ , θ , α 帯域の平均値)	113
8.5	被験者 A と B の肘関節の異なる訓練日の独立成分の結果	114
8.6	肘動作時の特徴的な成分の変化 (被験者 A)	117
8.7	肘動作時の特徴的な成分の変化 (被験者 B)	118
8.8	被験者 A と B の肩関節の異なる訓練日の独立成分の結果	121
8.9	被験者 A の肩関節の異なる訓練日の特徴的な成分の結果	122
8.10	被験者 B の肩関節の異なる訓練日の特徴的な成分の結果	123
8.11	訓練による各被験者の肘と肩関節の成分の変化	126
8.12	被験者 A の七日目の肘と肩関節の成分の違い	127
8.13	被験者 B の七日目の肘と肩関節の成分の違い	128
A.1	バターワースフィルタの振幅特性と次数 N の関係	159
B.1	短時間高速フーリエ変換の概要	163

B.2	窓関数の役目	164
B.3	窓関数	165
B.4	窓関数の比較1	166
B.5	窓関数の比較2	167
B.6	振幅回復係数 [137]	169
C.1	主成分分析 (PCA) の概念図	171
C.2	主成分分析の手順	172
D.1	2 入力 2 出力の ICA の問題	175
F.1	ARV 使用前後	180
G.1	ハイパスフィルタによる ICA 結果の違い	185
G.2	ICA とエポックの処理順番による結果	187
G.3	ICA とエポックの処理順番による結果 : 成分がかなり違う場合 . . .	187

第1章 序論

1.1 研究背景

日本の高齢化率を先進諸国と比較すると、1980年代までは下位、90年代にはほぼ中位であったが、2005年には最も高い水準となった。現在は3.6人に1人が65歳以上、7.2人に1人が75歳以上であることが分かっており [1]、2060年には、2.5人に1人が65歳以上、4人に1人が75歳以上であることが予測されている [2]、

この高齢化社会の突入に伴い、自力で行動できない人の増加とそれに伴う介護の問題が深刻になりつつある。これに加え介護者の高齢化も伴うので、介護者への負担は増加していくばかりである。

このような問題を解決するための手法として、障害者の自立支援や介護者の肉体的負担軽減を行うパワーアシスト装置が注目されている。現在、世界各国では様々なパワーアシスト装置、特に筋電など人の生体信号を用いた装置が開発されている [3-15]。

今まで人の生体信号の一つである筋電を用いて、介護者の負担の軽減や筋力の弱った人へのサポートを目的として開発されているパワーアシスト装置の制御が行われてきた [4-6, 11-13, 15]。これは人が筋力を発揮する際に発生する筋電の大きさに応じた力を機械が推定し、援助することで、人間の負担を減らすものである。筋電は筋肉を収縮させる電気信号であり、その大きさから筋肉にかかる負荷を推定することができる。また、個人差と筋の種類によって異なるが、筋活動が始まり、筋収縮によって力が発生するまでには 40-90 ms 程度の時間差があるため、動作よりも早く計測可能なことが利点とされている [16]。パワーアシスト装置を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、作業の効率化を図ること

ができるため、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。

しかし、運動神経に障害を持つ場合は、麻痺側での筋電の生成が微弱、または生成不可能な場合が存在する。その場合、筋電信号によるパワーアシストは不可能になってしまう。このような障害者に対して有効な手法として、脳活動情報を用いる Brain-Machine Interface(BMI) が挙げられる [17]。

BMI は脳の神経ネットワークに流れる微弱な電流や血管に流れる血流を身体の内外から計測し、デコードすることによって、人の動作意図や感情の推定、そしてそれに基づくロボットなどの外部機器の制御を実現するものの総称である。そのため身体的な疾患がある場合でも利用することが可能である。BMI の活用により、今後の高齢化社会において人の身体機能の代替や回復が大いに期待される。

この BMI 研究は、脳神経科学のみならず、ロボット工学、情報工学等、最新の科学的知見が融合された技術ゆえに、従来の脳神経科学に留まらない倫理的な問題を孕んでいる。そのため、2010 年に川人らは以下の BMI 論理 4 原則を提案している [18]。

1. 戦争や犯罪に BMI を利用してはならない
2. 何人も本人の意思に反して BMI 技術で心を読まれてはいけない
3. 何人も本人の意思に反して BMI 技術で心を制御されてはいけない
4. BMI 技術は、その効用が危険とコストを上回り、それを使用者が確認するときのみ利用されるべきである

そこで、本研究ではその原則を踏まえて行う。また身体的な障害をもつ人だけではなく、高齢者や介護者などの健常者をも対象する。そして、脳活動で機械を操作し身体的な負担の軽減が可能なパワーアシストシステムの構築を目指す。

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表面筋電位や力・トルクセンサーの代わりに BMI 技術を用いた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、自らの意思でその装置を制御し、日常生活の補助を目指す。

1.3 本文の構成

本論文の構成を図 1.1 に示す。第 2 章では関連研究として、これまでの BMI の研究の流れ、そして脳活動モデルの作成および運動情報の再構築に関する研究と本研究の位置付けについて述べる。第 3 章では、本研究で BMI によるパワーアシストを行う際に必要となる制御信号（脳波信号と筋電信号とトルク）とそれらの関係について述べる。第 4 章では、脳波・表面筋電位の計測手法をまとめるとともに、本研究用の計測環境について述べる。そして、第 5 章と第 6 章では肩の単関節動作時のパワーアシストを行う際に、運動に関する脳波の特徴量を解析し、必要となるトルクの推定手法を提案して、実験で検証する。第 5 章では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パワーアシストに必要なトルクの推定を行う。また、第 6 章では遅延を考慮した線形モデルによるトルクの推定結果を示す。次に第 7 章と第 8 章では、肘と肩の二関節連動動作時の運動パターンの識別について述べる。第 7 章では、特徴を効果的に抽出できる手法について説明し、検証する。第 8 章では、脳の可塑性を検証するために、BMI ユーザーを訓練し、訓練の有効性と脳の可塑性について説明する。最後に第 9 章にて、まとめを行い、今後の展望について述べる。

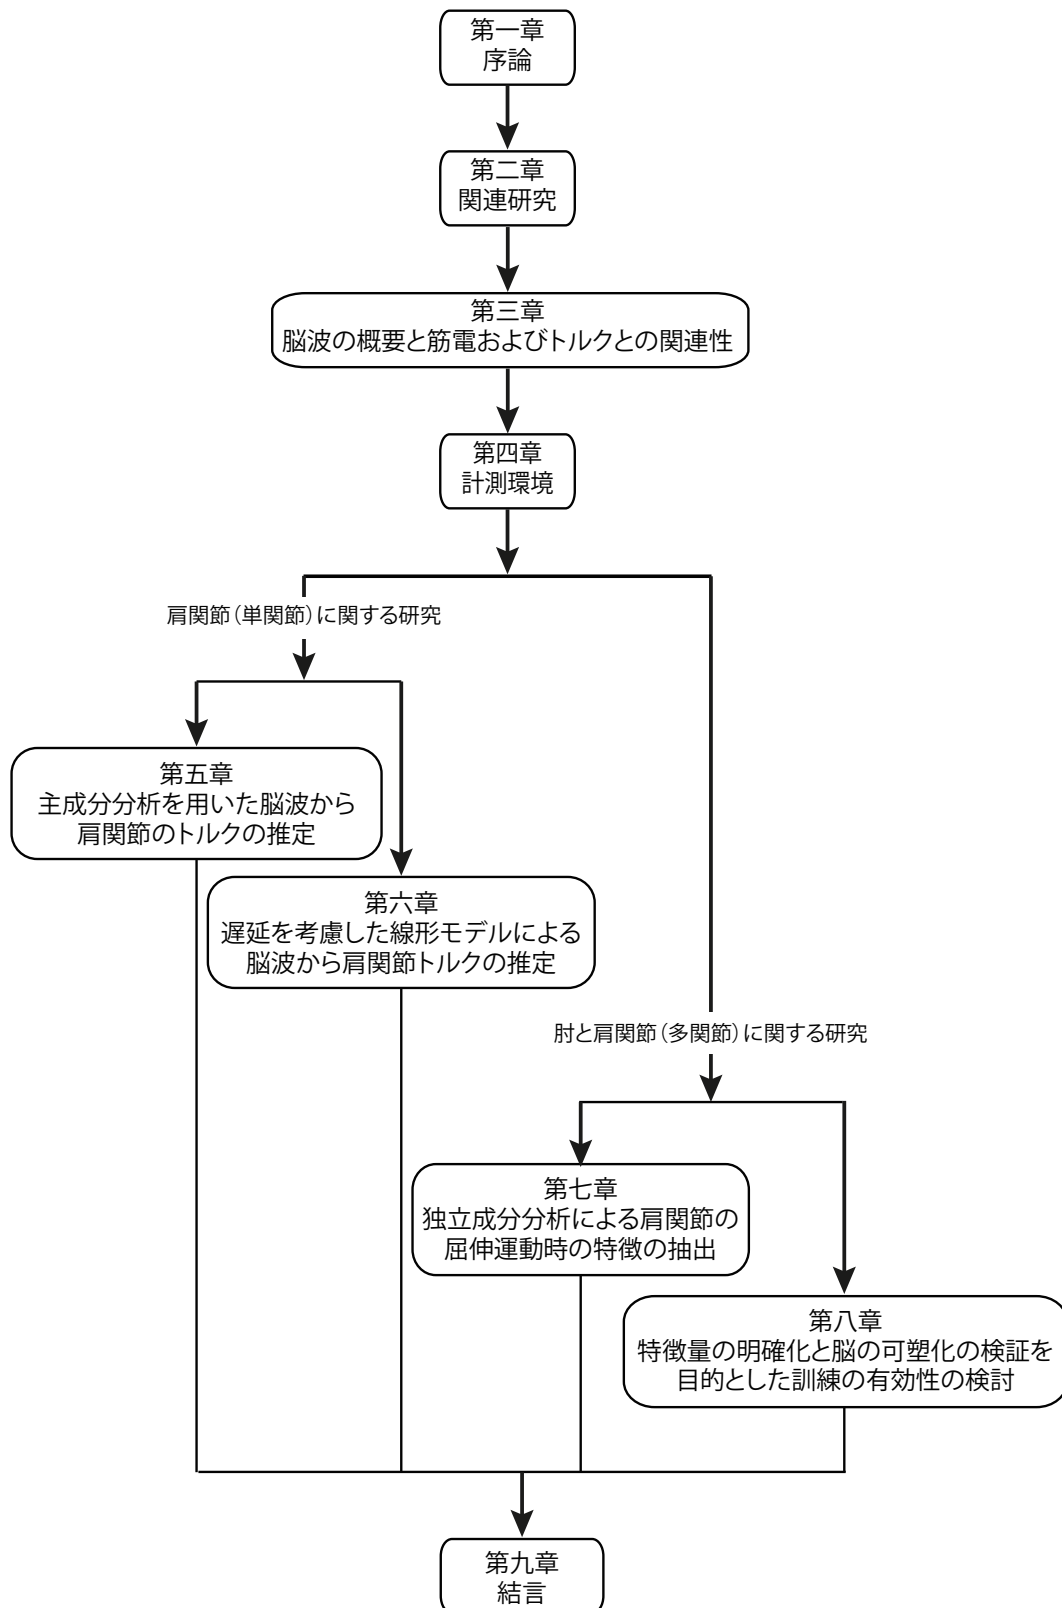


図 1.1: 本論文の構成

第2章 関連研究

2.1 Brain-Machine Interface(BMI)の定義およびその応用

Brain Machine Interface とは，脳の信号を用いてロボットアームなどの機械を操作したり，カメラ映像などを脳への直接刺激によって感覚器を介さずに入力することを可能にする．信号源および操作対象である脳と機械を直接結ぶもの，つまり脳波を読み取る脳波センサーや脳波を解析するプログラムなどを総称して BMI と呼ぶ．BMI の基礎概念が明らかになったのは 1980 年代 [19] であるが，実際に動作する BMI システムが報告されたのは 2000 年代に入ってからである．その後，BMI に関連する研究や論文が飛躍的に増加している [20]．この BMI が実現すれば「念じるだけ」で勝手に機械が動いてくれることになる．

BMI を分類する際に，侵襲型と非侵襲型に分けることができる [21]．前者は脳に直接にマイクロ電極を埋め込んでニューロンの活動を記録し，それをもとに外部にある機械を操作するシステムである．脳の手術が必要なので侵襲的 BMI と呼ばれる．後者は脳波など体外から間接的に計測する方法で，手術を必要としない非侵襲的 BMI である．侵襲型と非侵襲型という区分は対立的な概念ではなく，使用する目的によりどちらを念頭に置くかを決定すべきであり，また，研究開発の過程では両者の組合せが重要である．

侵襲型 BMI は神経細胞の活動を直接計測するため，環境や生体からのノイズが少なく，信号の処理過程も少ないことから，高い精度で素早く脳内の情報を得ることが可能である．代表的な侵襲式 BMI は細胞外記録 (Single-Unit Activity : SUA,

Multi-Unit Activity : MUA, Local Field Potential : LFP) と皮質脳波 (Electrocorticography : ECoG) が挙げられる。しかし、電極の経年劣化、手術による感染症や脳の損傷といったリスクなど、被験者への負担が問題とされている。一方、非侵襲型 BMI は脳情報の精度、信号の解析速度は侵襲型 BMI に劣るものの、生体の外部から脳情報を得るため、被験者に対しての負担がほとんどなく、健常者を対象とした実験も容易である。

このような理由から非侵襲型 BMI の研究は盛んに行われており、様々な計測方法による非侵襲型 BMI システムが開発されている。現在の代表的な非侵襲型 BMI の計測方法としては、脳波 (Electroencephalography : EEG) [22], 脳磁図 (Magnetoencephalography : MEG) [23], NIRS (Near-Infrared Spectroscopy) [24], fMRI (functional Magnetic Resonance Imaging) [25] が挙げられる。EEG はヒトをはじめとする動物の脳から生じる電気活動を、頭皮上、蝶形骨底、鼓膜、脳表、脳深部などに置いた電極により細かい時間精度で記録したものである。MEG は脳の電氣的な活動によって生じる磁場を超伝導量子干渉計 (Superconducting Quantum Interference Device : SQUIDs) と呼ばれる非常に感度の高いデバイスを用いて計測するイメージング技術である。NIRS は近赤外光の透過性を指標として用い血中ヘモグロビン濃度を測定することである。fMRI は血流量の増減を間接的指標として脳の広い領域の活動パターンを視覚化する方法の一つであり、最近のニューロイメージングの中でも最も発達した手法の一つである。

その中でも脳波を用いた BMI は、すでに商品化もされているものもある。例えば、2003 年にスウェーデンの Interactive Productline 社がマインドボール (Mindball) を、2009 年にはアメリカ合衆国のベンチャー企業 NeuroSky 社が脳波の強弱を測定できるマインドセット (MindSet) を販売した。マインドボールに関しては、これに対応する玩具も販売されている。また、注目した文字を認識してコンピュータに文字を入力する脳波キーボード [26] や、家電製品に設置したタグに注目してスイッチの ON/OFF を行う [27] ものなどの製品化が行われている。

しかし、障害者の会話や意思疎通のためのコミュニケーションツールとして開

発されるものが多く，日常生活動作（Activities of Daily Living：ADL）の改善や介護者の身体的負担を軽減するような機器はまだ研究段階なものが多い．次節では，人の動作を支援する BMI の研究について紹介する．

2.2 BMIによる運動情報の再構築

2.2.1 侵襲型 BMI

2.2.1.1 動物実験

2.2.1.1.1 ラットの実験

1999年に Nicoletis グループは、ラットが水を飲むためにレバーを押す際の脳活動を利用し、簡単な訓練により、ラットがレバーを押さず運動野のニューロン集団の活動だけで、ロボットアームを前足の動作でレバーの操作をする場合と同じように動作させることに成功した [28].

具体的な流れはラットの運動野 (32 箇所) と視床腹側部 (14 箇所) に電極を埋め込み、ニューロンの活動と手首の動きを同時記録した。喉の乾いたラットを小さな箱の中に入れ、ラットがレバーを押すとコントローラが作動し、一滴分の水が報酬として与えられるような実験環境を作って、ラットがレバーを押すと水滴をもらえるように訓練された。その結果、ラットは水を飲むために、ロボットアームの位置を制御するためのレバー操作を学習した。

信号処理として、ニューラルネットワーク (Neural Networks) を含む数学的な変換によって、マルチニューロン (Multi-neuron) の信号がレバーの軌跡を正確に予測できるように「ニューロン集団関数」に変換された。次に、ニューロロボティックモードに変更し、ニューロン集団関数を用いてロボットアームを実時間で動作させるための電氣的な制御信号へと変換される。すなわち、直接神経集団によってロボットアームを制御する。コントローラの入力源がニューロン集団関数に切り替わった後、6 匹中 4 匹のラット (>25 個のタスク関連ニューロン) が日常的な脳信号を用いてロボットアームの位置を制御した。ニューロロボティックモードに移行して引き続き訓練を行うことで、このラットたちはレバーを押す動作を行わなくなった。まるでラットが「意図だけで」ロボットアームを動作させているかのようになったので

ある。

2.2.1.1.2 霊長類の実験

1. ラットの実験の後，2000年に同じNicolelisグループ [29] は，サルの運動野だけでなく，運動前野と頭頂連合野からもニューロンの活動を記録し，人工ニューラルネットワーク (Artificial Neural Network: ANN) と組み合わせることで，より精巧にロボットアームをコントロールできるようにした。
2. その後，2002年にNicolelisらは，霊長類(ヨザル)を用いたBMIシステムを開発した [30]。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光ファイバーのセンサ (Fiber-Optic Sensors) で計測し，運動野に埋め込んだ約100個のマルチニューロン記録装置を使って多数のニューロンの活動を線形加算することで，数百ミリ秒前に手の動きを高精度に予測できることを示した。次に，50-100ミリ秒単位で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次元動作に変換した。そして，ヨザルが目の前にあるスクリーンの左右のランプの点灯に合わせてジョイスティックを手で左右に動かしている時の運動野のニューロンの活動でロボットアームをコントロールしたところ，ロボットアームはヨザルの腕と同じ動きをした。
3. さらに，2003年にNicolelisらは，サルの脳内に電極を埋め込む侵襲的な手法を用いて，神経の活動を入力とした線形モデルから，手の位置，速度，把持力，筋電の抽出を行った [31]。ポール (pole) 状のコントローラとディスプレイに表示させたカーソルおよび目標を用いた3つのタスクを用意している。この実験では，タスク開始から30分間をポールコントロールモード (Pole Control Mode) として，実際にコントローラを用いてカーソルの操作を行わせ，線形モデルの学習を行う。その後をブレインコントロールモード (Brain Control Mode) として，線形モデルを用いてカーソルの操作を行わせた。その結果，サルは「ブレインコントロールモード」の初期では実際にコントローラを用いてカーソルの操作を行っていたが，最終的にコントロー

ラを用いるのをやめ、腕を動かすことなくカーソルの操作を行った。さらにこの後、脳活動の情報のみで6自由度と把持機能を有するロボットアームの制御に成功している。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、筋電は、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。

2.2.1.2 人間の実験

動物の研究をきっかけに、この後の十数年間でBMIの研究は飛躍的な進展が見られ、米国のブラウン大学の研究では人への臨床試験を行った [32]。日本でもNicolelisらの動物に対しての実験成功を受け、麻痺患者に対する臨床実験が始められており、人間の運動時の脳活動情報でもロボットアームを制御して物体の把持や移動が可能であることが示された [33]。

1. 2012年のブラウン大学のDonoghueらの研究では、侵襲型の手法で少数の一次運動野(MI)ニューロンの局所的集団を96チャンネルの微小電極アレイで記録して、長期にわたる四肢麻痺の患者2人が神経インターフェースシステムを用いてロボットアームを制御し、三次元的な到達および把持動作を行うことに成功した。この研究ではニューロンの活動を入力として、直前までに得られたデータを用いて未来のデータを推定するカルマンフィルタ(Kalman Filter)を用いてロボットアームの速度と状態を推定している。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、人の意図のみで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 [32]。
2. 2012年に大阪大学の吉峰らの研究では、人が任意のタイミングで行った動作をECoG信号から推定し、ロボットアームにその動作を行わせることに成功した [33]。動作はあらかじめ決められており、グー/チョキ/パーのいずれかを出す、または、手を握る/つまむ/手を開くの6種類がある。そのためこの手法では訓練期間が用意されており、患者は3-5種類の簡単な手と肘の動

きを行い、その際に感覚皮質から ECoG 信号を記録している。取得した信号にフーリエ変換を用いて3つの周波数帯 (2-8 Hz, 8-25 Hz, 80-150 Hz) を特徴として抽出し、学習が行われる。学習後は、200 ms ごとに人が動作を行った際の信号から抽出した特徴を入力として運動の開始時刻を推定し、機械学習手法である SVM (Support Vector Machine) を用いた内容の判別を行い、脳情報のみでロボットアームの制御に成功した。

2.2.2 非侵襲型 BMI

非侵襲型 BMI の研究では、脳波を用いて機械をリアルタイムで制御することで人の動作を支援するためのシステムの開発が進められている。ユーザーが運動を想起したときに生じる EEG 内の特定の領域の周波数の変化を脳波信号の特徴として、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。1951年、脳波から明確な感覚、認知、運動活動などの反応を抽出できるようになり [34]、その後 1964 年に Sutton らが実験から P300 を発見した [35]。その後 50 年近くは、多くの研究が事象関連電位 (Event-Related Potential: ERP) の解析法を発達させるためのもので、ERP の研究はますます加速した。近年、EEG を用いて電動車椅子を制御する研究 [36] [37] [38] や、上肢のリハビリ [39]、また侵襲型のように脳活動からモデルを作り学習することで、手先の 3 次元の動作速度や筋電などの運動情報を推定また再構成する研究 [40] [41] [42]、さらには下肢の外骨格ロボットによる歩行機能の回復 [43] に関する研究も行われている。さらに、2014 年 6 月サッカーワールドカップ大会の開会式では下半身麻痺患者が脳波で制御する外骨格ロボットを装着してキックオフのデモンストレーションを行った [44]。これらの研究は、過去には不可能だった脳波による多自由度のロボットの制御の可能性を見出した。

2.2.2.1 EEG信号を用いた運動情報の推定と再構成

2010年にアメリカのライス大学のMally教授らを中心とした複数の大学が参加している研究プロジェクトでは、脳波の δ 波(0-4 Hz)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への応用を開始している。

1. 2010年にメリーランド大学が発表した研究では、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 [39]。この実験では、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。計測された脳波の前処理として、カットオフ周波数が1 Hz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。各電極間の前処理された信号に対して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、重み係数は多重回帰分析により算出されており、この重みを用いて各電極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。なお、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。

2. 東京工業大学の小池らが2011年に発表した研究では、脳波からfMRIの情報を利用して脳信号源を推定し、推定された脳信号源の信号から筋活動の再構築に成功している [40]。

EEGは時間分解能が高い生体信号である。しかしながら、多くの神経活動によって生成された電気的な情報が空間的に重畳された信号であるため、どの神経が活動した結果から得られたセンサデータと対応するのかがわからなくなってしまう。このため空間分解能が低い信号であるといえる。この問題を解決するためにfMRIなど、時間分解能は低いが、空間分解能が高い信

号を用いた研究も行われ始めている。小池らは、侵襲型と同等の空間分解能を脳波に持たせることが可能であれば、脳波から筋電が再構成することができると考え、fMRIの情報を利用した。

求めたい神経活動は計測データから推定する必要がある。MEGによる信号源の推定は容易で正確である一方、脳波の場合は脳や髄液、頭蓋骨で電位が減衰し、なおかつそれらは電極の位置によって減衰率が異なるなどの理由により信頼性は低いと一般的に考えられている。信号源の推定は順問題と逆問題を繰り返し解くことで行われる。順問題とは脳内の活動源と頭部モデルを仮定して、頭皮上で計測されるであろう電位の理論値を計算することである。逆問題とは実測された頭皮上の電位データと、順問題を解いて得られた理論値との間の誤差が最小になるように、活動源モデルのパラメータを変えながら計算を繰り返すことである。一般的に、計測データから信号源を推定する場合は逆問題であり、解くことが難しい。このため、一個あるいは数個のダイポール (Dipole) を仮定することで逆問題を解く方法が用いられていた。しかし、実際には多くの神経活動により得られた計測データであるため、少ない数の信号源では実際の計測データを解釈できず、推定誤差も大きくなってしまう。このため、信号源を分布電流源を用いて解く方法が用いられている。一般的に、センサー信号の数よりも信号源の数の方が多くなるため、いわゆる未知数が方程式の数より多く、冗長システムとなる。そこで、何らかの制約条件をつけて問題を解く必要があり、信号源のノルム最小推定やラプリアンフィルタを用いた LORETA (Low Resolution Brain Electromagnetic Tomography) などが有名である。また、信号源の時間的な変化に着目した最小分散法 (Beamformer 法) も提案されている。今回、身体の動きの時系列データを推定する試みがなされ、VBMEG (Variational Bayesian Multimodal Encephalography : <http://vbmeg.atr.jp/>) [45] と呼ばれる方法を用いて EEG から EMG を推定した。

VBMEG は、MEG や EEG のデータから皮質電流を推定するための Matlab

ツールボックスとして、ATR脳情報解析研究所からソフトウェアのパッケージとして提供されている。間接的に計測されたデータから推定した運動に関するデータと、計算された信号源の信号を用いて推定した運動に関する結果を比較し、信号源を計算した方法の結果が良ければ、この信号源の信号は運動の推定のための信号としては良いものといえる。

このことを確認するために、実験器具を用いてタスクを設計した。被験者は、強と弱の二段階の運動強度レベルに応じて手首を屈曲・伸展する。そしてその際の脳波（EEG）と等尺性収縮時の筋電信号（EMG）を同時に計測し、EEGから直接EMGを推定した結果と、EEGから信号源を推定し、それらの信号を用いてEMGを推定した結果を比較した。この実験の信号処理の概要について、まず、MRIによる個人の脳構造モデルと電極の位置を用いて信号源から電極の信号を計算するリードフィールド行列（Lead Field Matrix）を求める。次に、実験タスクをfMRI内でも行い、タスク中の脳活動の位置情報と脳活動の強度を求める。これらの情報を基にEEGから信号源を推定する逆フィルタをVBMEGにより求める。また、推定された脳信号源信号をスパース回帰モデル（Sparse Regression Model）に基づいて、計測点ごとに重みを付けて統合することで、筋電の再構成を行っている。

推定結果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。信号源を利用した場合は伸筋、屈筋の両活動を精度良く推定でき、脳波を直接用いた場合は、伸筋、屈筋の違いが推定できなかった。また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なった。

3. 2013年の国立障害者リハビリテーションセンターの神作らの研究では、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）の制御に成功した [41]。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た。

事前の準備として、あらかじめ被験者に BOTAS を装着してもらい、複数の動作を記録しておく。脳波を用いた操作では、事前に記録した動作をモニタ上にアイコンとして表示しておき、アイコンの点滅による視覚刺激を利用して得られる P300 で目的の動作を選択する。そして、ロボットアームの手首に取り付けられた LED と目標位置に取り付けられた LED の周期的な光の点滅による視覚刺激を利用して、SSVEP をトリガーとして動作を開始する。この LED の周期的な光の点滅は 6 Hz, 7 Hz, 8 Hz の 3 種類がそれぞれ異なる動作を行うために用意されており、どの LED を見ているのかは 3 秒間の脳波データにおける FFT と正準相関分析の結果を用いて特徴ベクトルを作成し、その特徴ベクトルからサポートベクターマシン (Support Vector Machine: SVM) によって 0.1 秒毎に判別される。

実験では複数回の実験の中で 3 つの LED の配置が変更されたのにもかかわらず、どの配置でも検出成功率は 80 % 以上となり、高い有効性が示されたといえる。しかし、このシステムでは判別の際に遅れが生じ、この遅れは刺激 LED の周波数に応じて異なることが明らかにされている。

4. 2013 年ヒューストン大学では、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 [42].

ロボットグリッパーで物体を掴むと、その力を外骨格がフィードバックする仕組みになっている。7 人の健常被験者に対して、被験者は力のフィードバックに基づいて外骨格によって剛性が異なる物を識別するように指示した。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 (左腕に) に装着されており、タスク 3 とタスク 4 では、対側に (右腕に) 取り付けられている。これらのタスクの中で、タスク 1 とタスク 4 では力の

フィードバックを行っている。64チャンネルで計測された脳波信号の0.01-1 Hz(δ 波)の振幅を用いて、ニューラルデコーダを開発し、ロボットグリッパを制御するためのsEMG (surface Electromyography)を再構成した。デコーダは遺伝的アルゴリズムを線形モデルに組み込み、複数のチャンネルからの脳波を用いてsEMGを再構築した。脳波から筋電を再構成するモデル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と全てのタスクで訓練した式を各タスクに使用した場合三つで評価している。評価には、計測した筋電と推定した筋電の相関係数で行っている。

この実験の結果から、タスク間の再構成精度には差がなく、中央値は0.6前後、最大で0.9前後となった。デコーダの性能は、侵襲的手法で記録した神経活動を用いてsEMGの線形包絡線を再構成した以前の研究に匹敵する可能性が見出された。また、異なるタスクで訓練を使用した場合の結果から、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。

2.3 本研究グループの先行研究の成果

2.3.1 ロボットアームを制御するための運動判別

前橋工科大学朱研究室のBMIグループは、脳波を用いてロボットアームを制御するために、ヒトの安静状態と腕の運動を行ったときの脳波をそれぞれ計測し、脳波における α 波と β 波の分布の違い（左右差）に非線形判別器であるマハラノビスの汎距離を用いることで運動判別を行っている [46] [47]。また腕の運動については、上腕二頭筋のみを動かすために被験者の前腕を固定し、その固定された腕を上げるように力を入れている。運動中の上腕二頭筋の表面筋電位を脳波と合わせて計測し、生成した判別器の判別率の評価に用いている。その結果を図2.1で示す。図2.1の上段は安静時、下段は運動時における判別率を示している。この結果では安静状態の判別率は100%，運動状態の判別率は65%であったと述べられている。

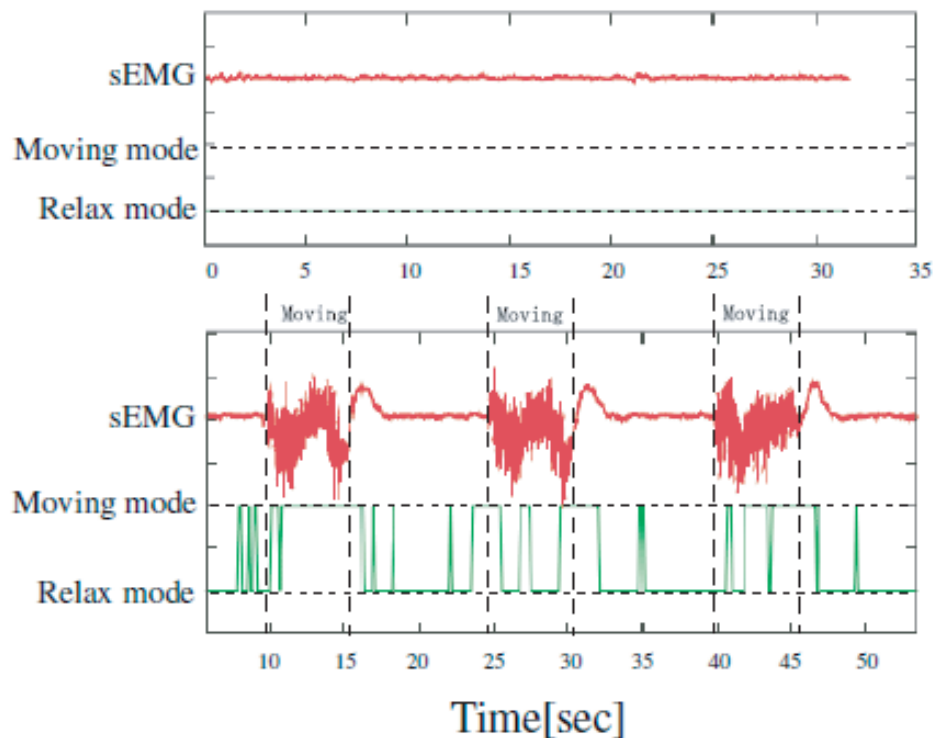


図 2.1: 判別器による判別結果 [46]

2.3.2 脳波を用いた筋電推定によるパワーアシストシステムの構築に関する基礎研究

この研究では脳波と運動時の筋電の関係性に着目し、脳波を用いて筋電を推定することによりロボットアームを制御し、腕のパワーアシストを行うことを目的としている [48]。そこで腕の屈曲/伸展運動時の脳波と筋電を計測し、主成分分析を行うことで脳波-筋電間の線形モデルを作成している。そして逐次最小二乗法 (Recursive Least Square: RLS) を用いてパラメータの更新を行い、脳波から筋電を推定している (図 2.2)。被験者 3 名に対して実験を行い、その推定結果の一例を図 2.3 で示す。実線は筋電の実測値、破線は推定値を表す。また、被験者 3 名とも筋電の実測値と推定値の相関係数は平均で 0.5 以上、最高で 0.88 となり、脳波から筋電を推定することが可能であると述べられている。

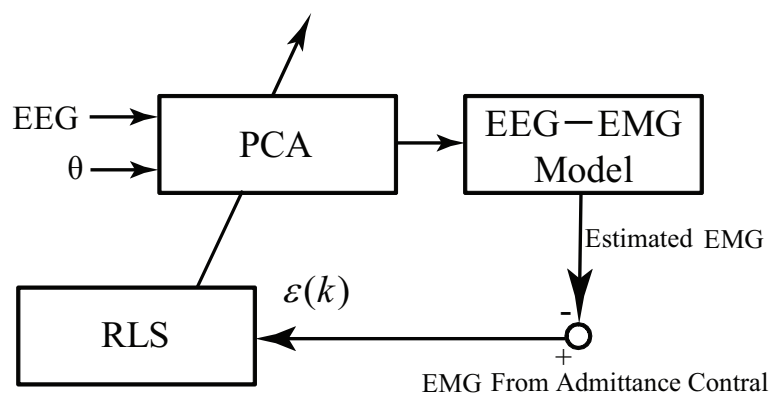



図 2.2: 処理手順 [48]



(b) Measured EMG & Estimated EMG (Moving Average)

図 2.3: 推定結果 [48]

2.4 本研究の位置付け

BMI技術を用いて機械を制御する研究は、侵襲型では20年以上前から行われている。侵襲型の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、脳内に電極を埋め込むことは脳の活動を正確に読み取れる反面、手術の安全性や電極の安定性などの問題がある。

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いる。特に脳波を用いるBMIの研究も盛んに行われて、人の動作を支援する手法が徐々に増加してきている。これらの研究は、過去には不可能だった脳波による多自由度のロボットの制御を可能にした。ただし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、脳波などの信号から抽出された特徴はロボットや外部機器の動作のON/OFF、またあらかじめ決められた数種類の動作パターン間の切り替えなど、主にトリガーとして使われ、連続的な制御が難しく、遅れも大きい。使用者の行う動作を遅れなくロボットアームに模倣させるのは困難だと言える。

上述したように、これまでの侵襲型BMIも非侵襲型BMIも主に障害者、特に半身または全身麻痺の重度障害者のリハビリテーションや機能回復のために開発され、重労働従業員や看護スタッフなどの健常者向けのBMI製品はほとんどない。現時点で人の脳活動を用いた多自由度外骨格型ロボットの連続的な制御は難しく、もちろんパワーアシストの成功例もまだ報告されていない。これまで、力・トルクまたは筋電情報を使ってパワーアシストを行う数多くの外骨格ロボットが開発されてきたが、多軸の力・トルクセンサや多数の筋電センサにかかるコストや、センサを装着する手間、そして個人差等の問題も多く残っている。したがって、本研究では、上記の問題を解決するため、これまで外骨格ロボットに使用されてきた表面筋電位や力・トルクセンサーの代わりに、脳活動内の関節に与えるトルクの情報の抽出および推定手法を提案することにより、パワーアシストを行うシス

テムの構築というこれまで未踏の領域に挑み、健常者の QoL と作業効率の向上を目指す。また本論文は、BMI 技術に基づいた肩関節の屈曲と伸展運動においてパワーアシストを適用する世界初の研究報告である。

2.4.1 非侵襲型 BMI 計測手法の選定

本研究の目的は、BMI 技術に基づく上肢アシストシステムの構築であるため、MEG、fMRI など計測装置が大型で動かすことが出来ない計測手法では、生活の支援を行うことは難しい。EEG によるシステムはその点は大丈夫である。EEG は脳の神経活動を測定するための臨床および研究環境で広く使用されており、頭皮にセンサーを配置することで、ニューロン集団によって生成されたシナプス後電位の合計が非侵襲的に記録できる [49]。また、EEG はサブミリ秒スケールまでの優れた時間分解能を提供するためリアルタイム制御にも通しており、聴覚刺激などでの急速な神経処理の時間と周波数の変化の特徴を捉えることができる [50]。本研究では運動に応じた脳活動変化の時間周波数分析とその特徴の抽出を行うため、前述した要素と本研究の目的を踏まえて、EEG は適切な非侵襲型の BMI 計測手法と考えられる。

2.4.2 運動タスクの指定

上肢パワーアシストシステムの構築のために、上肢の関節が必要とするアシストの量と方向の推定が必要不可欠である。前述したことを踏まえ、本研究は屈曲と伸展動作において、脳波に基づく肩と肘の関節のパワーアシストの実現のためのトルク情報の推定に関する基礎研究とする。

2.5 本研究の内容

本研究では外部の力センサや筋電センサを使わずに、人の脳活動のみを用いて人の行動意図を認識したうえで、脳活動とトルク間の線形モデルを作成し、人の多自由度の力情報を推定する。そして、パワーアシストが可能な脳-アシストロボットシステムの構築とその制御技術の確立および実験検証を行うことで、非侵襲型 BMI 技術の研究開発を目的とする。

本研究の BMI には 2 つの絶対的な課題がある。1 つ目は、脳から適切な情報を取得する手法である。これは、「脳から機械」への流れである。脳の出力信号をキャプチャし、ニューロンが何をしているかを理解しようとするを示す。2 つ目は、正しい情報を脳に入力する手法である。つまり、「機械から脳」までへの流れである。機械を用いて脳に情報を入力することで刺激し、脳の特性に変化を促すことを示す。

一つ目の課題に対して、私たちの研究チームは 2016 年に脳波信号から肘関節のトルクを推定することに成功した。そのため、本論文の第 6 章から第 8 章まで単関節の場合は主に肩関節のトルクの推定に着目する。また多関節の場合には肩と肘関節の連動動作時の特徴の抽出と運動パターン認識手法の検証をすることにより、BMI 技術に基づく上肢アシストシステムの構築を行う。

二つ目の課題に対して、現在の神経科学で神経コーディングのメカニズムはまだ解明されていないため、「機械から脳」への研究は「脳から機械」までの研究よりもはるかに遅れている。また「機械から脳」へのニューラルコーディングの知識のニーズは、「脳から機械」への知識よりもはるかに大きい。神経科学は、単一のニューロンの研究で徐々に明らかになってきているが、まだ説明できない現象も多い。したがって、我々は二つ目の課題に対して、本論文の第 9 章では脳の可塑性に注目し、BMI ユーザーを訓練する。そして訓練の有効性とそれによる脳の変化について検証する。

第3章 脳波の概要と筋電およびトルクとの関連性

本章では、脳波によるパワーアシストを行う際に必要となる脳波信号の概要と脳波-筋電信号-トルク間の関連性について説明する。

3.1 脳波とは

1875年、イギリスの科学者リチャード・カートン (Richard Caton) が動物の生体脳に電気現象がみられることを報告した [51]。人の脳の電気活動を最初に記録したのはドイツの Jena 大学精神科教授ハンス・ベルガー (Hans Berger) であり、1924年ヒトの脳での電気現象が発見され、1929年「人の脳電図について」という論文で発表した [52]。1946年、名古屋大学勝沼精蔵教授が「脳波」という訳語を提案し、用いられるようになった [53]。ヒト・動物の脳から生じる電気活動を頭皮上、蝶形骨底、鼓膜、脳表、脳深部などに置いた電極で記録したものを脳波 (Electroencephalography : EEG) と呼ぶ。脳波は膨大な数の神経細胞の発火を単一で見ているのではなく、神経細胞集団が発生させる電気活動の集まりを見ていると考えられる。そのため、神経細胞集団が発生する電位のばらつきの程度を反映したものが波として現れると言える [53]。

脳波の律動性波形は周波数により表 3.1 のように 4 つに分類される。また、このような周期的変化とは異なり、内的・外的刺激によって引き起こされる電位変動は事象関連電位 (ERP) と呼ばれている [53]。

● δ 波

δ 波は IFSECN（1990 年には国際脳波・臨床神経生理学学会連合（International Federation of Societies for Electroencephalography and Clinical Neurophysiology : IFSECN）が国際臨床神経生理学学会連合（International Federation of Clinical Neurophysiology : IFCN）と改称され、現在に至っている。）によると「律動波を定義する場合には、 δ 律動として 4 Hz 未満の律動を、個々の波を定義する場合には δ 波とし、1/4 秒を超える波を指す」と定義している [54].

人の覚醒時には通常 δ 波は観測されなく、発生機構は現在まだ明らかでないが、2.2.2 で紹介したライス大学を中心とした研究グループでは、 δ 波を利用して、腕の速度、筋電を再構成している。したがって運動と δ 波の関連があると考えられる。

● θ 波

θ 波は IFSECN によると θ は 4 Hz から 8 Hz 未満の周波数の律動と定義されている [54].

広汎性の θ 波は小児期では普通に観察されるが、10 歳を過ぎると少なくなり、成人から高齢になると側頭部に θ 波が見られるようになる [55].

θ 波の発生機構は十分明らかになっていないが、動物実験（ウサギ、ネコ、サル、ラット）では海馬から θ 波類似の θ 律動が記録され、最近では人でも海馬から θ 波が記録されたと報告されている。海馬が θ 律動の主な発生源と考えられている。

また θ 波と行動との関係についての研究がある。Wallace らは瞑想によって前頭部から 5-7 Hz の θ 波が記録され、この間には酸素消費量が低下していたことを報告している [56]. また Winson は、ラットの海馬からの θ 律動は探索行動や逆説睡眠の際に記録されたことを報告し [57], Arnold らはイヌの海馬で、いくつかの行動条件のうちで、より活動的な状態に移行する時に θ 帯域の活動が高まることを

表 3.1: 周波数帯の分類 [54]

δ 波 (帯) 1-3 Hz
θ 波 (帯) 4-7 Hz
α 波 (帯) 8-13 Hz
β 波 (帯) 14-35 Hz (14 Hz 以上)

報告している [58]. 人についての研究は少ないが, てんかん患者においてある行動条件に際して θ 帯域の活動が高まることを観察している [59].

● α 波

α 波は IFSECN 用語委員会では次のように定義している。「 α 律動 (alpha rhythm) とは頭部後方部分に覚醒時に現れる 8-13 Hz の律動であり, 概して後頭部で振幅が高い. 振幅はさまざまであるが, 成人では 50 μ V 以下のことが多い. 閉眼時において身体的にリラックスし, 精神的に比較的に活動していない状態でよく観察される. 注意や, とくに視覚的注意や精神的努力によって抑制あるいは減衰する」 [54].

この定義では α 律動と記述しているが, α 波と同義である. α 波は人の意識レベルで大きく変動し, リラックスしていない閉眼時または開眼時で抑制される.

● μ 律動

μ 律動は IFSECN 用語委員会によると「覚醒時に中心あるいは中心-頭頂部に観測される 7-11 Hz の律動であり, アーチ状の形をした波である. 振幅は様々であるが, 多くは 50 μ V 以下である. 対側の運動や, 運動想起, あるいは触刺激によって抑制される」と定義されている [54].

μ 律動は α 波の一部であり, 感覚運動野に相当する中心部近傍で観察される α 波成分である. 同時に, 運動 (手を握るなど) によって抑制されることが知られている.

● 事象関連 (脱) 同期

Pfurtscheller らによると, μ 律動が手指の運動で抑制されるのは運動開始の平均 1.75 秒前から起こることを観察している [60]. 帯域成分により脳波の抑制が両側性に観察されている. なお彼らは運動性の脳波の抑制を事象関連脱同期 (Event-Related Desynchronization : ERD) と呼んでいる.

自発脳波を用いる BCI では, 特に運動に関連する事象関連脱同期を動作原理としている. 運動に関する ERD は, 運動を行うことで頭皮上の特定の部分で脳波の特定の周波数領域のパワーが減少する現象である. これと似た現象として運動に関する事象関連同期 (Event-Related Synchronization, 以下 ERS) がある [61]. ERS

は運動後に頭皮上の特定の部分で脳波の特定の周波数領域のパワーが増加する現象である。実運動後の ERS は SN 比（信号とノイズの比）が高い反応である。

ERD は運動開始に向けた情報処理に関与した覚醒や皮質活性を、ERS は運動遂行直後の皮質の活性状態から静的状態への回復や次の運動に向けた皮質のアイドリング状態を反映する指標とされる [62] [63]。

μ 波の ERD, ERS に関しては、実際の運動遂行時や運動イメージの想起時に認められることが報告されている [64] [65]。また、運動想起後にも ERS 反応が出ると報告されている。以上のことから、運動想起後の ERS 反応も ERD 反応と同様に BCI に利用できると考えられる。これらの ERD, ERS の計測は、数十回にわたり同一試行を繰り返す必要がなく、より少ない試行での脳波測定で検出可能な指標である。

● β 波

β 波は IFSECN 用語委員会では次のように定義している。「一般的に 14 Hz 以上の律動を指すが、最もよくみられるのは覚醒時に前頭-中心部に記録される 13-35 Hz の律動である。特に皮質脳波では、反対側の運動や触診刺激で抑制あるいは減衰が観察される。またその他の部位で顕著であったり、広汎性に現れる β 波もある」 [54]。また、 β 波は運動と関連していると言われており、運動を維持する際には筋電との間に相関がみられるとされている。

● 運動関連脳電位 (Movement-Related Cortical Potential: MRCP)

1983 年、Libet は人間の行為の意志が脳内で発生する前に、既に脳神経系の頭頂葉に準備電位 (Bereitschafts Potential: BP) という活動が発生していることを発表した [66]。

準備電位は図 3.1 に示すように、手首を曲げるという運動が開始する時間を基準として約 550 ms (0.55 秒) 前にすでに発生しており、意志が認識される約 400 ms (0.4 秒) 前に発生している。脳の電氣的な活動を脳波計によって計測すると、身体部位の運動が実際に始まる約 1000 ms から 500 ms 前に、脳の補足運動野 (Supplementary Motor Area) で陰の電位変化が生じる。準備電位は、特定の脳の活動によって生

じる電位変化である事象関連電位の一種である [67].

運動開始点を基準に、数十回の運動に関連する脳波を加算平均して得られる脳電位に対して、時間領域の波形の特性によって3つの区間に分けられる。運動前2000-1000 ms から出現する緩やかな陰性電位を運動準備電位、運動開始前約 900 ms から BP に続いて認められ、500-600 ms 持続し、反対側優位で、運動前野で発生している電位を IS (Intermediate Slope)、運動開始の約 500 ms 前になると運動と反対側の中心前部で陰性勾配が急峻になり形成される陰性電位を NS' (Negative Slope Potential) (勾配は約 $1.0 \mu\text{V}/100 \text{ms}$)、運動前後に見られる全体のピークでもある波形は FN (Frontal Negativity) と呼ばれている。

また、BP は大脳の運動皮質や補足運動野を、IS は運動前野を、NS' は随意運動に対応する第一次運動野を起源にしていると考えられている。

以下、運動開始前の成分について説明する。

1. BP

運動開始の 1000-2000 ms 前から立ち上がり Cz を中心に左右対称性に出現する陰性緩電位である。この BP は受動的な運動では出現しない。これは広汎な大脳皮質の随意運動に対する準備状態を反映している。BP は大脳の運動皮質や補足運動野を起源にしていると考えられている。

2. IS

右利きの健康成人では、左手指の運動に伴う IS が右手の運動に伴う IS より大きく、しかも右手の運動では左半球優位であるのに対し、左手運動では Cz に最大振幅を持つ。IS は運動前野を起源にしていると考えられている。

3. NS'

随意運動における特異的な運動野皮質の準備状態を反映している。限局性が明らかなことから、一次運動野の活動とみなされている。NS' は随意運動に対応する第一次運動野を起源にしていると考えられている。

4. N-90 と P-50

NS' は運動と同側半球では運動開始前 90 ms あたりで陰性頂点 N-90 として終わり、その後に陽性頂点 P-50 を形成する。

運動開始後の成分は以下のものが含まれている。

1. N + 10

運動と反対側の中心前部に限局して運動開始後 10 ms あたりに現われる陰性頂点である。

2. N + 50

運動開始後 10 ms に前頭部のやや運動と反対側寄りにみられる鋭い陰性電位である。

3. P + 90 と P + 160

運動開始後 90 ms 後に運動と反対側の中心部から中心前部にかけて出現する陽性電位が P + 90, 160 ms 後に運動と反対側の中心部にみられる陰性電位が P + 160 である。なお, N + 50 と P + 90 は運動感覚のフィードバックを反映しているものと考えられている。

4. P + 300

運動開始後 300 ms 前後に中心前部に最大振幅を示す陽性頂点。運動感覚連合野の活動を反映しているものと考えられている。

MRCP の成分のうち、健康成人の大部分に識別可能なものは BP, NS, N + 50, P + 300 の 4 成分である。したがって、現時点での MRCP 評価はこの 4 成分を指標にしている。本研究は運動関連脳電位に注目し、肩関節運動時に関連する脳波成分の抽出を行う。

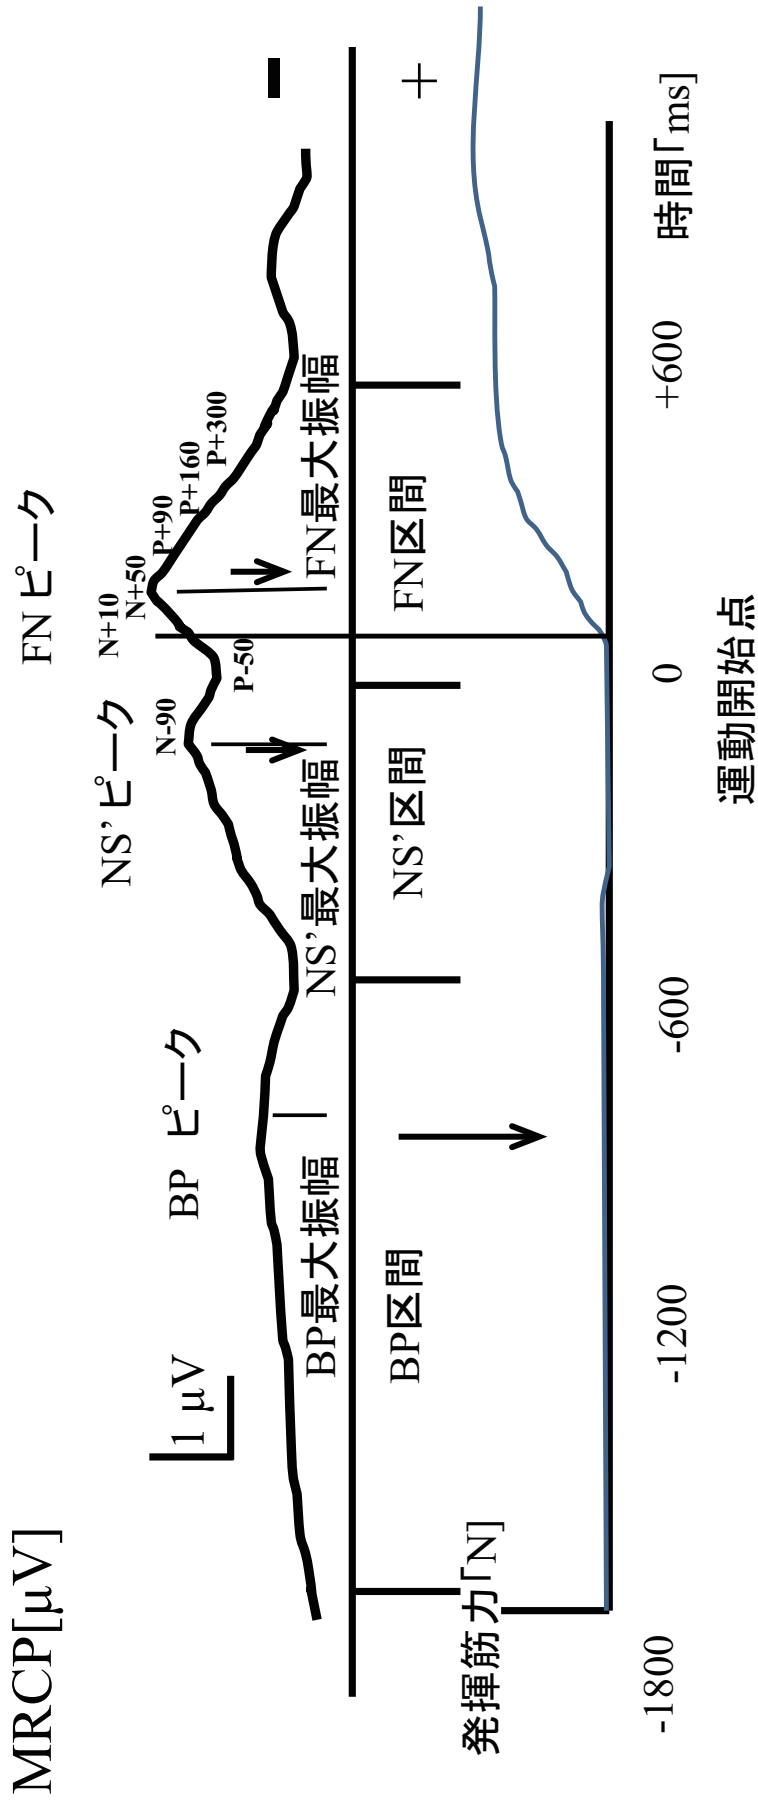


図 3.1: 運動関連電位の概念図

3.2 筋電とは

人間は筋肉を収縮させて体を動かしているが、その筋肉の収縮は数 mV の電気信号によって行われている。この筋肉を収縮させる電気信号が筋に到達して初めて観測されるものが筋電位 (Myo-Electricpotential: MEP) である。この筋電位を計測したものは筋電図 (Electromyography: EMG) と呼ばれる [68]。

3.3 脳波と筋電の関連性

3.3.1 発生メカニズム

人間が運動する時に、まず自らが置かれている状況を正確に理解し、把握していなければならない。次に身体内部の情報を元に、行動の枠組みを決め、その中で必要とされる行動を選択し、その実現の手段としての運動を選ぶ一連の手順の中で、運動の目的が決まる。そして運動を企画・構成し、準備することになる。そのため、人間の動きを決定しているのは脳と神経である。このような運動の時間的・空間的パターンや運動の手順、あるいはこれから起こることが予測される事象と運動の組み合わせなどをあらかじめ決めておく過程をまとめて運動のプログラミング過程と呼ぶ [69]。これは脳の重要な働きの1つとされる。

運動は筋肉の収縮によって実現する。運動をする為の筋肉の活動を直接的に制御するのは運動細胞 (図 3.2a) である。この運動細胞は脊髄 (図 3.2f) と脳幹 (図 3.2b) にあり、運動神経 (図 3.2c) で筋肉に接続している。運動神経は神経線維 (図 3.2d) であり、神経線維を伝わる信号で筋肉の収縮を直接に調節している。運動神経は終板という構造を介して筋肉と接続している。また、運動細胞は脊髄の神経回路網で作られる信号と、大脳の運動野 (図 3.2e) からの信号により制御される。運動細胞が活動するとその信号は運動神経を伝わり筋肉へ達し、その信号量に応じた筋収縮を生ずる。したがって、運動細胞の活動量が筋肉の活動量を決める [69]。

脊髄から骨格筋に至る運動神経線維（図 3.2c）には直径の太いアルファ（ α ）線維と細いガンマ（ γ ）線維がある（ γ 運動ニューロンは α 運動ニューロンと混在している）。 α 線維は実際の筋収縮に関与している。さらに、脊髄の神経回路網で作られる信号と大脳の運動野からの信号により運動細胞が活動すると、運動神経の 1 つである α 運動ニューロンが興奮し、その興奮インパルスが神経軸索を經由して目指す筋に伝えられる。

1 つの運動ニューロンから生じる神経軸索は筋のなかで枝分かれしており、多数の筋線維に神経筋接合部を形成する。この神経接合部は神経終板とも呼ばれ、筋によって、また個人によってさまざまな分布をしている。

筋線維（図 3.2d）は筋を構成する細長い細胞であり、1 つの筋線維上には通常 1 ヲ所の神経筋接合部が存在する。すなわち、運動ニューロン（図 3.2a）と筋線維は 1 対多の関係にある。1 つの運動ニューロンに支配された筋線維群の活動は 1 つの単位として機能し、1 つの運動ニューロンとそれに支配される筋線維群はまとめて運動単位と呼ばれる。また、運動神経の興奮は神経インパルス列として神経筋接合部に到達する。この神経筋接合部では、神経終末から化学伝達物質であるアセチルコリンが放出され、それによって筋線維側の電氣的興奮が発生する。

筋線維のほぼ中間に存在する神経筋接合部から開始した電氣的興奮は、筋線維の両端に向かって 3-6 m/s の速さで伝播していき、筋線維の末端に到達した時点で消滅する。この筋線維上の脱分極は細胞膜を通る膜電流を引き起こし、膜電流は周囲の容積導体を流れて電位変化を生じる。この電位変化を導出したものが筋電である [68]。

以上の脳から筋への出力関係を図 3.2 に示す。

3.3.2 脳波と筋電間のコヒーレンス

3.3.1 で述べた通り、細胞レベルでの脳の活動と筋電の発生についてはすでに関連づけられている。このような関係性を頭皮上で計測された脳波と皮膚上から計測された筋電から見出そうとする研究が行われており、その研究結果から脳波と筋電

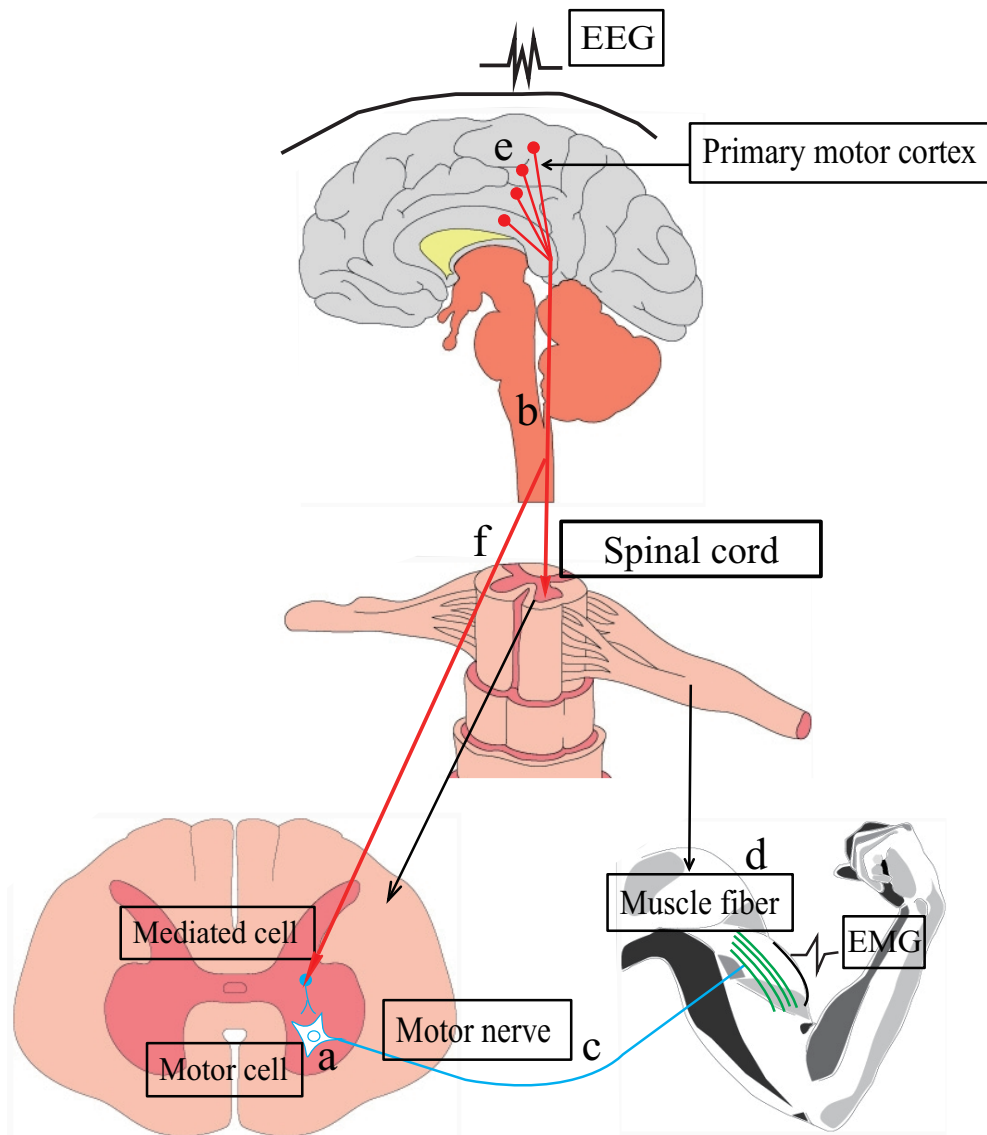


図 3.2: 脳から筋への出力

の一部の周波数帯において有意な相関があることがすでに知られている [70] [71].

静的筋収縮中，運動皮質附近の脳波と主働筋の筋電図とは 20 Hz のよく似たパターンの波形を示すことが報告され，Halliday ら [70] によって考案されたコヒーレンス解析法は両波形の相関性を評価することで，運動皮質が筋活動をいかに制御しているかを定量的に計測し得る手法として注目を集めている．またこの脳波と筋電の関係性は，Conway らが 1998 年に行った実験にて明らかにされた [71].

この実験では，健常者を被験者として手首の屈曲・伸展を行わせている．なお，

脳波計測点は運動する腕と対側半球とし、筋電は指心筋と橈側手根屈筋から計測している。Conwayらは手首の屈曲・伸展を維持する運動時の脳波と筋電に注目して、脳波と全波整流した筋電とのコヒーレンスを算出した。その結果、この2つの信号の15-35 Hzの周波数帯にコヒーレンスが有意に現れることが確認された。Conwayらはこの相関関係から、大脳での15-35 Hzの周波数帯の信号は自発的な維持運動と関連していると推測している。

また、Conwayらの研究結果ではコヒーレンスの有無に個人差がみられた。この結果をうけ、慶応大学の牛場らの研究では被験者を男性と女性、アスリートと非アスリートに分けて実験を行った [72]。その結果、男女間には差がみられず、アスリートと非アスリートではアスリートの方がコヒーレンスが低いということが明らかにされた。牛場らは、コヒーレンスは筋力調節の安定性に関与しているのではないかと述べた。

3.4 筋電とトルクの関連性

筋肉は人間の運動制御システムのコマンドを受信した後に収縮し、運動（力またはトルク）が生じる。筋肉が収縮した時に生じた電位は筋電位と呼ばれる [68].

我々はすでに入力をトルクとするアドミタンス制御を用いた上肢の装着型のパワーアシストが可能な外骨格ロボットを開発した [73]. したがって、EEG 信号からトルク情報を推定できれば、EEG 信号で上肢のパワーアシスト装置を制御することができる。

肩関節は多関節筋を含む複数の筋肉で構成されており、肩関節の動きはこれらの筋肉の共活性化の結果である。そのため、肩関節は上肢で最も複雑で、自由度が高い関節である [74]. また現在多関節筋に対してうまく制御できる手法がまだ確立されていないという事実を踏まえて、後述する肩関節の制御モデルを単純化し、多関節筋の問題を回避するために肩関節の擬似拮抗筋の概念を導入する。言い換えれば、着用可能な外骨格によってパワーアシストされる肩関節の屈曲および伸展動作に対する着用者のトルクは、擬似拮抗筋のみによって駆動されると想定されている。ここで、擬似の拮抗筋は肩関節の屈曲と伸展のためのトルクを生成するために活性化される実際に存在する複数の筋肉を表す。

関節トルクは拮抗筋によって生成されることはよく知られているが、この筋肉によって生成された EMG 信号の振幅と関節トルクは線形関係であることが分かっている [68, 75–77]. したがって、擬似拮抗筋の EMG 信号の振幅 EMG_{vm} と肩関節の屈曲および伸展時に必要なトルク τ の関係は次の線形方程式で近似的に表すことができる。

$$\tau = A \cdot EMG_{vm} + B \quad (3.1)$$

ここで、 A は肩関節のトルク τ と筋電信号の振幅との関係を表す定数であり、 B は無負荷時（腕の重量のみを保持）の筋電信号の振幅である。したがって、擬似筋肉の筋電信号の振幅を推定する場合、肩関節の屈曲および伸展に必要なトルクは

式 (3.1) によって計算できる。

一方、生理学的解剖学および多くの先行研究から、三角筋前部は肩関節の多くの筋肉の中で屈曲と伸展の主要な役割を担っていることが分かった。また、三角筋前部の筋電信号と運動によって生成されたトルクとの関係は線形であることも分かっている [74, 78–81]。したがって、三角筋前部の筋電信号 EMG_{delt} の振幅と擬似筋肉の筋電の振幅は線形になり、次の式で近似的に表すことができる。

$$EMG_{vm} = C \cdot EMG_{delt} + D \quad (3.2)$$

ここで、 C は肩の動きにおける三角筋前部の割合を表す定数であり、 D は線形関係により生じたバイアスである。

式 (3.1) および (3.2) を並べ替えることにより、トルクと三角筋前部の EMG 信号の関係は次のように表現できる。

$$\begin{aligned} \tau &= A \cdot C \cdot EMG_{delt} + (B + A \cdot D) \\ &= P \cdot EMG_{delt} + Q \end{aligned} \quad (3.3)$$

つまり、肩関節の屈曲および伸展動作に必要なトルクは、三角筋前部の筋電信号を用いて計算できることも示している。

したがって本研究では、測定やモデルの作成や評価を簡単化するために、肩関節のトルクと三角筋前部の筋電信号を区別せずに、提案した手法で推定された三角筋前部の筋電信号をパワーアシストに必要なトルクと見なす。

3.5 関連性のまとめ

本章では、現在知られている脳波の成分や発生機構、筋電の発生原理そしてお互いの関係性について述べてきた。自発的な運動の際、筋電は脳からの命令により発生し、またトルクは筋肉の収縮によって生成されるため、脳波と筋電とトルクの関係性は深いと考えられる。また運動の際は、運動した側と対側の運動野で変化が捉えられるため、左右の差を観察することも有効の手段の一つと考えられる。さらに、運動時の脳波は事象関連（脱）同期やコヒーレンスのように、周波数帯での時間変化によって捉えられることが多い。よって、本研究でもその関係性に着目し、両側の運動野から計測を行い、時間-周波数領域の解析を行う方針とする。

第4章 計測環境

4.1 脳波の計測装置

4.1.1 電極

電極にはg.tec社のアクティブ電極であるg.GAMMAsysを使用した(図4.1. A). アクティブ電極はアンプが内蔵されているため, 電極側で高インピーダンスを電気的に作り出し, SNR(Signal to Noise Ratio)を高め, アーチファクトの発生を防ぐことができる. そのため, 電極は電極接触インピーダンスに左右されにくく, コードのゆれの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た.




図 4.1: g.GAMMAsys
(A) アクティブ電極, (B) 耳朶用アクティブ電極,
(C) アクティブ電極用インターフェース/ドライバーボックス, (D) 電解ゲル

4.1.2 ヘッドキャップ

脳波計測ではどの計測点で計測したのかが非常に重要であり、一般的に 10-20 電極配置法が用いられる。これはカナダの Jasper H. H. ら [82] によって行われていた方法が国際的にも承認され広く用いられたものである。基準点は前後方向では鼻根部 (Nasion) と後頭結節 (Inion) であり、左右では耳介前点である。頭部の半円が 10 % と 20 % に分割され部位が決められることから、10-20 法と呼ばれる。IFCN [83] では電極数を増やし、10-20 法における 10 % 分割の部位に電極を置く配置法を提案している (10-10 法または拡張 10-20 法)。本研究では図 4.4 に示す国際 10-10 法を基に作成された g.tec 社の g.GAMMAcap² ヘッドキャップを用いた (図 4.3)。これを用いて計測すると、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できるので、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。

4.1.3 生体アンプ

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 4.5 に示す g.tec 社製の 8 チャンネル増幅アンプ g.BSamp を用いた。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。

- ・ Lowpass filter : 100 Hz or 1000 Hz
- ・ Highpass filter : 0.5 Hz or 2 Hz
- ・ Sensitivity : ± 500 mV or ± 5 mV
- ・ Notch filter : 50 Hz (or 60 Hz) [on or off]
- ・ Configurations : 8 or 16 bipolar/real differential input channels (2 sep. GNDs)
- ・ ± 5 V analog output signal range

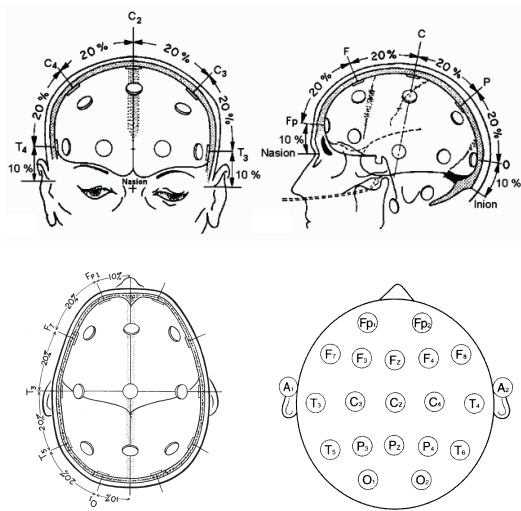


図 4.2: 国際 10-20 法



図 4.3: EEG ヘッドキャップ (g.GAMMAcap²)




図 4.4: 10-10 電極配置法 [83]



図 4.5: 脳波計アンプ (g.BSamp)

4.2 表面筋電位の計測装置

4.2.1 電極

本研究では DELSYS 社のアクティブ電極を用いた。電極を図 4.6 に示す。電極の中で差動増幅回路が設置されている。



2-Slot Adhesive Skin Interface



Dermatode Reference Electrode

図 4.6: 筋電の電極

(A). DE-2.1 Single Differential Surface EMG Sensor.

(B). Dermatode Reference Electrode.

4.2.2 増幅アンプ

筋電計測用のアンプは DELSYS 社のアンプを用いた。アンプ本体を図 4.7 に、仕様を表 4.1 に示す。




図 4.7: 筋電計アンプ (The Bagnoli-2 EMG System)

表 4.1: DELSYS 社アンプ仕様

チャンネル数	2 チャンネル
1 チャンネルあたりの総合的な増幅	1000 倍 10000 倍
出力電圧範囲	$\pm 5 \text{ V}$
周波数特性	20 Hz to 450 Hz $\pm 10\%$
所要電力	9V DC, 10mA
運転温度	0 °C ~ 40 °C
本体の寸法	100mm × 65mm × 40mm
重さ	0.3kg

4.3 インターフェースボード

計測された信号の同期のため、本研究では図工社のインターフェースボード (HRP Interface Board 07-0003-1) を使用した。インターフェースボードは、PCI バス (Peripheral Component Interconnect Bus) 規格のボードにアナログ入力 16 チャンネル、アナログ出力 16 チャンネル、デジタル入力 16 点、デジタル出力 16 点、エンコーダ・カウンタ入力 16 チャンネル (TTL, ラインレシーバ 4 チャンネル毎切替可)、外部電源によるエンコーダデータバックアップを搭載している。なお、アナログ入力レンジは ± 10 V である。

D/A 変換器として 13 ビット/8 チャンネル (ただし使用ビットは 12 ビット) の AD7839 (ANALOG DEVICES 社製) を 2 個搭載している。A/D 変換器は 12 ビット/8 チャンネルの AD7891 (ANALOG DEVICES 社製) を 2 個搭載している。エンコーダ入力は 24 ビット/2 チャンネルの PCC160 (コスモテックス社製) を 8 個搭載している。デジタル入出力 32 点は TE7753 (東京エレクトロン社製) を 1 個搭載している。

4.4 オペレーティングシステム

オペレーティングシステム (Operating System, OS) は, Linux と RTAI (Real-Time Application Interface) の組み合わせで構築した. RTAI は Linux カーネルのリアルタイム拡張であり, Linux 上で厳密な時間制限に対応可能なアプリケーションを開発できる. RTAI は, POSIX 互換タスク, ネイティブ RTAI リアルタイムタスク, 割り込みの応答時間を一定時間にする. 通常, Linux 上のタイマー割り込みはソフトな割り込みであるが, RTAI のタイマー割り込みはハード (強固) な割り込みであり, 規定の時間間隔内での周期実行性が保証されており, 割り込みの応答速度が規定時間内に保証されている. それにより, RTAI を搭載した OS はリアルタイム処理を可能にする OS として利用できる.

本研究のパワーアシストシステムは, 人間の生体信号を制御信号としているので, 介護現場で使うことを踏まえ, 安全性や信頼性においてもこの実行時間が保証されていることは非常に重要である. 以上を理由に, この OS を利用した.

4.5 本研究の計測システム

これらの機器を組み合わせて構成した本研究の計測システムを図 4.8 で示す。本研究では g.BSamp から A-D 変換を含む多機能のインターフェースボード内蔵のコンピュータを介して脳波を取得する。コンピュータの OS には Linux と RTAI を用いている。脳波を取得するために、国際 10-10 法に基づいて作られた g.GAMMAcap² を用い、測定部位にアクティブ電極である g.GAMMAsys を装着し、電解ゲルを注入する。筋電の測定部位に DELSYS 社の電極を貼り付ける。計測された表面筋電位はアンプを増幅して、A-D 変換ボード内蔵のコンピュータを介して記録される。測定部位の詳細は実験設計の項目で述べるが、例えば C3, C4 とし、A2 との単極誘導としている。サンプリング周波数は 1000 Hz である。




図 4.8: 本研究の計測環境の概観

第5章 主成分分析を用いた脳波から 肩関節のトルクの推定

本章では，主成分分析を用いた脳波から三角筋前部の筋電の推定手法を提案し，実験によりその有効性を評価する．そこで，前述した筋電とトルクの関連性によって，脳波から肩関節のトルクの推定ができることにより，脳波を用いた肩関節の屈曲/伸展動作においてパワーアシストを行うことが実現できる．

5.1 提案手法

本推定手法は図5.1に示すように Step1, Step2 と Step3 の3段階に分かれている．Step1では，脳波の各計測点の短時間フーリエ変換後のパワースペクトルの積分値を入力信号として，主成分分析を用いて肩関節運動に関連する脳波成分を抽出する．Step2ではStep1から得られる運動に関連する脳波成分と1点の筋電を入力信号として，主成分分析を用いて脳波－筋電間の線形モデルを作成する．Step3では筋電を未知信号として，新たに計測した脳波のみを入力信号とすることで，Step2で作成されたモデルと脳波から筋電を推定する．

5.1.1 運動に関与する脳波成分の抽出

まず，入力として m 箇所の計測点から脳波データ $s_i (i = 1, 2, \dots, m)$ を与えることとする．この時，入力間の分散共分散行列の固有値問題を解くことで得られる固有値を脳波の固有ベクトル e_i とすると，運動時の脳波の主成分 \mathbf{Z} は以下のように

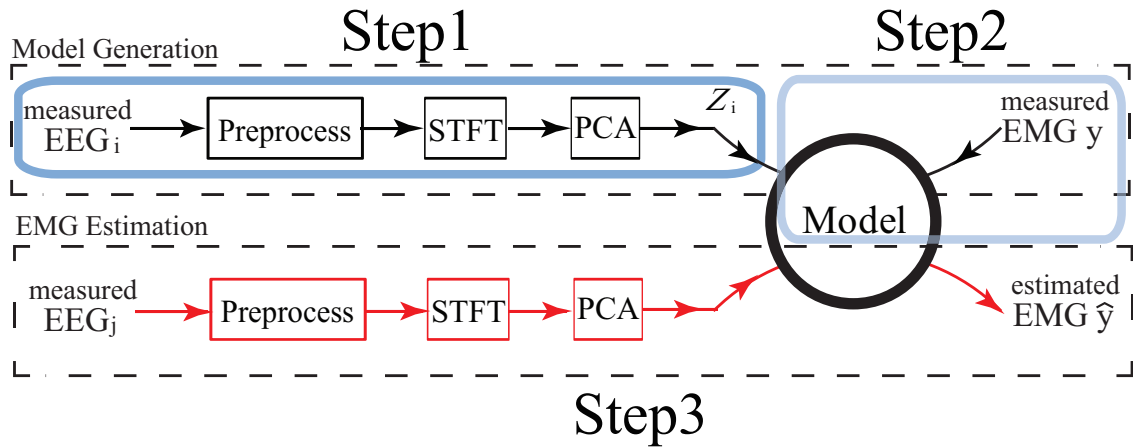


図 5.1: 推定手法の概要図

記述される.

$$\mathbf{Z} = \mathbf{E} \cdot \mathbf{S} \quad (5.1)$$

ここで、 $\mathbf{Z} = [z_1, z_2, \dots, z_m]^T$ の z_i は各主成分であり、 $\mathbf{E} = [\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_m]^T$ 、 $\mathbf{e}_i = [e_{i1}, e_{i2}, \dots, e_{im}]$ 、 e_{ij} は脳波信号の固有ベクトルである (i 個目電極 $i = 1, 2, \dots, m$ 、第 j 主成分 $j = 1, 2, \dots, m$)。 $\mathbf{S} = [s_1, s_2, \dots, s_m]^T$ は脳波の計測点のデータである。

5.1.2 脳波一表面筋電位の線形モデルの作成

次に、入力として、式 (5.1) より得られた運動時の特徴的な脳波データ z_u ($u = 1, 2, \dots, m$)、1箇所計測点から筋電 y を与えるとする。脳波信号の固有ベクトルが E_{vu} ($v = 1, 2, \dots, m$ 、 $u = 1, 2, \dots, m$) で、筋電信号の固有ベクトルを E_{vy} とすると、主成分 F_v は固有ベクトルを重み値とした脳波と筋電の線形結合となり、以下のように記述される。

$$F_v = E_{v1}z_1 + E_{v2}z_2 + \dots + E_{vm}z_m + E_{vy}y \quad (5.2)$$

この式を脳波から推定筋電 \hat{y} を求める式に変換すると,

$$\hat{y}_v = \frac{F_v - \sum_{v=1}^m E_{vu} z_v}{E_{vy}} \quad (5.3)$$

となり, 推定された筋電信号 \hat{y} は

$$\hat{y} = \sum_{v=1}^m \hat{y}_v \eta_v \quad (5.4)$$

となる. ここで, η_v は各主成分の寄与率であり, 以下の式で表す.

$$\eta_i = \frac{\lambda_i}{\sum_{j=1}^m \lambda_j} \quad (5.5)$$

ここで, λ_i は固有値である.

式 (5.4) を脳波-筋電モデルとして, 脳波から筋電の推定を行う.

5.2 実験設計

提案手法の有効性を確認するため、実験を行った。本実験は、被験者を20代の健康な右利き男性3名とし、あらかじめ実験内容を説明して同意を得た上で行った。

5.2.1 計測点に関する研究まとめ

脳波の計測部位について、事前調査を行った。特に成功した上肢の運動と脳波の関連研究でよい成果をおさえたものの計測点を参考にしたうえで、計測点を決定した。まずは計測すべき位置を決定した。

I. 侵襲型

i. Friedら [84] が被験者が運動の決定をする前に、補足運動野 (Supplementary Motor Area: SMA) で運動ニューロンが進行性的な増加が1500 msを超えたと報告している。

ii. また、もう一つの皮質脳波記録 (ElectroCorticoGraphy: ECoG) の研究で、Ballら [85] が運動が始まる前にと運動の前後の200 msに活動が存在すると報告している。

II. 非侵襲型

i. 運動ニューロンと自発的な運動意向が関連していると報告したのはKornhuberとDeeckeである [86]。彼らは早ければ運動を実行する1.5 s前に、遅い負電位の一つを検出した。この遅い皮質電位 (Slow Cortical Potential: SCP) はBereitschafts電位 (Bereitschafts potential: BP) と命名された。この準備電位は主に二つの成分が含まれている。一つは自発運動する1.5 s前に始まる遅い負電位である。この負の関連は中央内側頭皮のところがより顕著である。後期成分が反対側の一時運動野で運動前の400 msの時、急な傾きの状態で発生する [87]。上部皮質層で同期発火によって引き起こされる頂端樹状突起の脱分極で遅い電位が生じる。主に視床皮質求心性神経から、負の遅い電位のローカル興奮モビリゼーションを示す [88]。

ii. Libetらがこの準備電位の存在をさらに分析する研究を行った [89] [90]。これ

らの研究は脳の無意識的な準備活動を示すものであり、その準備活動は意識的な行動を実行する 1 s 前もしくは 1s 後に始まる。また、脳損傷の患者らからはこの類似した負の成分も発見された。

iii. EEG と運動準備及び実行に関係ある事象関連脱同期 (ERD) の報告がある [91]。この研究では反対側の一時運動野で、 μ 波と β 波 (8-30 Hz) のパワースペクトルの減少を確認した。

iv. Bai らは ERD の分析に基づいて、自分のペースでの手首運動の開始が実際の運動前平均 0.62 ± 0.25 s に検出した [92]。

v. Awwad Shiekh Hasan らの研究 [93] [94] では μ 、 β と γ (0-45 Hz) 周波数領域の脳波信号を用いて、自分のペースでの手首の伸展運動の開始動作の検出を行った。

次に、計測部位や解析用の電極の数や位置などを表 5.1 にまとめた。

表 5.1: 調査結果のまとめ

参考文献	解析用電極位置	周波数領域	動作
[95]	C3 C4 P3 P4	8-30 Hz	中指動作の想像
[96]	C3 C4	16-18 Hz	両手と足の動作の想像
[97]	F3 F4 (Fp1)	15-19 Hz	上肢, 把持
[98]	64 チャンネル	0.01-1 Hz	上肢 (肘), 把持
[99]	64 チャンネル	0.01-1 Hz	上肢 (肘) 伸展/屈曲
[100]	5 チャンネル	25-28 Hz	カーソルの制御
[101]	FC3 FC4 C3 C4 CP3 CP4	μ 波	FES 肘伸展/屈曲
[102]	27 チャンネル	全帯域	カーソルの制御
[103]	15 チャンネル	全帯域	カーソルの制御
[104]	21 チャンネル	1 Hz 以下	手と肘の移動
[105]	F3 F4 C3 C4 P3 P4 O1 O2	0-70 Hz	手の閉め, 腕の屈曲
[106]	16 チャンネル	0.2-1 Hz	腕の到達運動
[107]	C1 Cz C2 CP1 CPz CP2	0.1-1 Hz	腕の到達運動

空間分解能を上げるため、64 点などの大量の計測点を導入している研究が多い。しかし結果として、解析用の計測点は数個、あるいは十数個しかない。入力としての計測点が多すぎると、回帰のオーバーフィッティング問題が起こりやすく、計算の負担も増えるため、計測の電極の数を減らしたい。調査結果を図で表すと、図 5.2 のようになる。ここで色が濃いほどよく計測されており、かつ成功した計測点で

ある。その結果と眼球運動や眼電位などのアーチファクトになりやすい計測点を除いて、計測点を決定した。それは前頭葉の Fz, 頭頂葉の C3, C4, CP1, CP2, と後頭葉の O1, O2 であり, それぞれ耳朶との差動増幅を行った。





図 5.2: 関連研究の計測点のまとめ

5.2.2 タスク設計および計測内容


図 5.3 のようにリラックスした状態でヘッドキャップを装着した。下肢の動作の影響を回避するために、椅子に座り実験を行った。被験者は外骨格ロボットを装着し、開眼状態で、15 秒以内に肩の屈曲と伸展運動を行う。実験タスクとして、15 秒間の間に

- 安静状態
- 90°までの屈曲
- 約 2 秒間の維持動作
- 最初の位置に戻る伸展動作

が含まれる。また、筋肉の疲労を回避するために、一連の動作終了後に、15 秒の休み時間を挟んでいる。その後、また任意のタイミングで（随意動作のため）動作を行ってもらおう。以上の実験タスクを繰り返して、計 15 試行を実行した。この時脳波信号と筋電信号をインタフェイスボード (HRP Interface Board 07-0003-1, ZUCO. Co.) を用いて同時に計測し、記録した。脳波の記録には g.tec 社製の g.BSamp 増幅アンプを使用し、サンプリング周波数を 1000 Hz、バンドパスフィルタの通過帯域を 0.5-1000 Hz に設定した。筋電は肩関節の三角筋前部を計測点として計測を行い、右手首をボディーアースとした。筋電の記録には DELSYS 社製の増幅アンプ (Bagnoli Handheld EMG System) を使用し、設定はバンドパスフィルタの通過帯域を 20-450 Hz、増幅倍率は 1 万倍とした以外は脳波計測と同条件とした。なお、本研究では日常生活での BMI の利用を目的とするためシールドルームは設けていない。



(a)



Relax

Flexion and Keep

Extension and Relax

(b)

図 5.3: 脳波と筋電の計測タスク

5.3 データ処理

5.3.1 脳波信号の処理

脳波信号の処理として、図 5.4 に示すような流れで行われた。まずこの 7 点の計測点から計測した EEG 信号を A/D 変換後、ベースラインドリフトを除去するために、その信号をカットオフ周波数が 0.1 Hz のバターワースハイパスフィルター (HPF) を介して処理した。次に、眼球運動の成分とノイズを独立成分分析 (ICA) によって除去した。その後、カットオフ周波数が 45 Hz のバターワースローパスフィルター (LPF) を用いて 0.1-45 Hz の EEG 信号を抽出し、その成分のパワースペクトルを短時間フーリエ変換 (Short-time Fourier Transform: STFT) によって算出した。脳波信号解析に STFT を使用する理由は、信号のパワースペクトルを取得しながら重要な時間情報を保持できるため、パワーアシストシステムをリアルタイムで制御できると考えられるからである。STFT では、幅が 1024 点のハンニング窓関数を使用し、各データセグメントの長さも 1024 点に設定した。フィルターによる合計グループ遅延は約 9 ミリ秒であるため、システムはこれよりわずかに長い更新時間を必要とする。以上の理由により、オーバーラップの値は 99 % に設定し、構築されたシステムは 10.24 ms ごとに更新した。最後に、パワースペクトルの積分値を後続のモデリングのために計算した。



図 5.4: 脳波の信号処理の流れ

5.3.2 筋電信号の処理

筋電信号の処理は以下の手順で行った (図 5.5)。まずは取得した A/D 変換された筋電信号を全波整流し, 20 点の移動平均後, さらに 0.7 Hz の 4 次バターワースローパスフィルタを通して平滑化を行った。そして, 元の振幅を復元するために回復係数を 2 に設定した。処理後の信号は図 5.6 の赤い線のようになる。




図 5.5: 筋電の信号処理の流れ




図 5.6: 筋電の信号処理結果

5.4 データ解析と推定結果

5.4.1 脳波信号の前処理の結果

測定された EEG 信号に含まれるノイズ成分（体動，眼球運動/瞬き，および測定中の環境に起因するノイズなど）を除去するために，最初に測定された EEG 信号を ICA で処理した．図 5.7 に示すように，測定された EEG データは 7 つの独立した成分に分解された．この図では，赤くなるほど，その点において EEG 信号に含まれる特定の独立成分の割合が大きくなると示す．したがって，位置と振幅を用いて成分を識別および定義すると同時に，不要なノイズ成分（たとえば，被験者 A の 2 番目の成分と被験者 B の 5 番目の成分は眼球運動電位に関連する成分である）を削除し，研究目的に必要な成分のみが保留できる．被験者のそれぞれの各試行の結果から，分布が同じまたは類似した成分を観察できた．図 5.7 に示すように，主に $CP1$ からの信号で構成される成分は緑色のボックスで囲まれている（被験者 A の 6 番目の成分 $IC6$ ，被験者 B の 4 番目の成分 $IC4$ ，被験者 C の 5 番目の成分 $IC5$ ）．同様に，主に $CP2$ ， $O1$ ，および $O2$ からの信号で構成される成分は，それぞれ赤，オレンジ，青のボックスで囲まれている． $CP2$ の信号をベースした成分は被験者 A の 4 番目，被験者 B の 7 番目，被験者 C の 3 番目となった． $O1$ の信号をベースした成分は被験者 A の 7 番目，被験者 B の 3 番目，被験者 C の 2 番目となった． $O2$ の信号をベースした成分は被験者 A の 5 番目，被験者 B の 6 番目，被験者 C の 4 番目の成分となった．これらの結果を表 5.2 にまとめた．

これらの結果から，肩関節の屈曲と伸展に関連する特徴はこれらの成分の中に含まれていると考えられる．これらの独立成分の存在は運動に関連する特徴を効果的に抽出することができるだけでなく，ノイズ成分の除去も容易になる．

5.4.2 短時間フーリエ変換（STFT）の結果

図 5.8 は STFT の解析結果であり，左上からそれぞれ Fz ， $C3$ ， $C4$ ， $CP1$ ， $CP2$ ， $O1$ ， $O2$ の STFT 結果を示している．各計測点の結果は，3 つの図で構成されている．一番

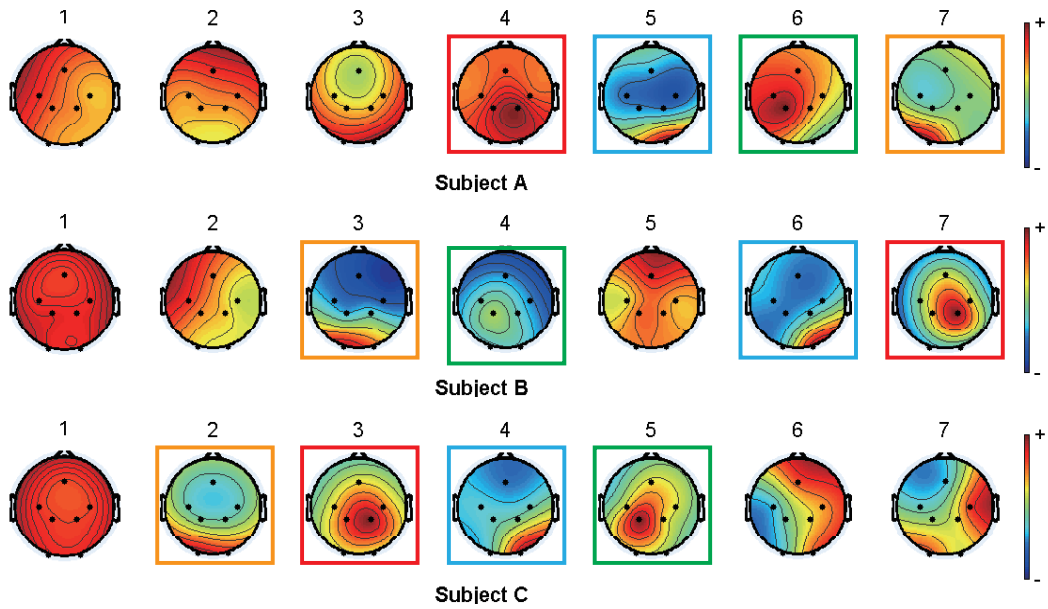


図 5.7: 脳波信号の前処理結果

表 5.2: ICA による前処理の結果や共通の成分

成分/信号源	被験者 A	被験者 B	被験者 C
眼球運動	IC2	IC5	/
<i>CP1</i>	IC6	IC4	IC5
<i>CP2</i>	IC4	IC7	IC3
<i>O1</i>	IC7	IC3	IC2
<i>O2</i>	IC5	IC6	IC4

上の図は STFT 結果の 3 次元空間の表示であり、右側の軸は時間、左側の軸は周波数、縦軸は解析された信号のパワースペクトルである。中央の図は STFT の 2 次元グラフであり、3 次元のグラフから変換された結果となる。実際にこれは 3 次元のグラフを垂直方向から見下ろした結果である。したがって、横軸は時間、縦軸は周波数、パワースペクトルの振幅は青から赤への色でマッピングされている。色が赤くなるほど振幅の値が大きくなり、色が青くなるほど振幅の値が小さくなることを意味する。一番下の図は、処理された筋電信号の結果である。横軸は時間であり、縦軸は処理された EMG 信号の振幅である。緑の波形は測定された EMG 信号の全波整流の結果であり、赤の包絡線は緑の波形に移動平均と平滑化の処理を施した結果である。これらの結果から、この赤い包絡線は EMG 信号の変化を完全に反映および置換できることが分かった。したがって、EMG 信号の処理手法は有効であることを示している。同時に、EMG 信号と STFT の結果を比較することにより、STFT は時間情報を保存できるだけでなく、動作のタイミングと合わせて比較することにより、特徴を効果的に抽出できることも分かった。また、一番下の EMG 信号の結果から見ると、運動が約 2.5 秒の時点で開始することが分かった。この時を動作の開始時刻とすると、動作開始時刻の約 1-2 秒前と動作開始時では、運動計画領域 Fz と運動野の $C3, C4$ の低周波数帯域と μ 帯域のパワースペクトルは明らかに増強されていることが分かった。これらの変化は MRCP により生じたと考えられる。また運動の開始後、低周波帯域のパワーは短期的に増強されることも見受けられ、同時に、 $Fz, C3, C4, CP1, CP2$ などの運動皮質部位の μ 帯域のパワースペクトルが減衰し始めることを確認した。さらに、運動中の β 帯域のパワースペクトルも静止状態と比較して増強されており、 β 波と運動の相関関係も示される結果となった。運動終了の後、低周波数帯域のパワースペクトルが先に短期的に増強され、その後通常のレベルに戻っている。またその時、被験者がリラックス状態になり始めるので、 μ 帯域のパワースペクトルは上昇し始め、 β 帯域のパワースペクトルは運動時より減少していることも分かった。また、視覚領域に属する $O1$ と $O2$ という計測点の結果は、他の計測点と少し異なり、低周波

数帯域と μ 帯域に大きな変化は見られないが, β 帯域に運動開始時のパワースペクトルの増加と運動終了後の減少が観測できた. 以上から, STFT を用いて, 計測されたデータの時間情報を保留することができるだけでなく, MRCP と μ 律動または ERD による EEG 信号の変化から特徴を抽出できることを確認できた.

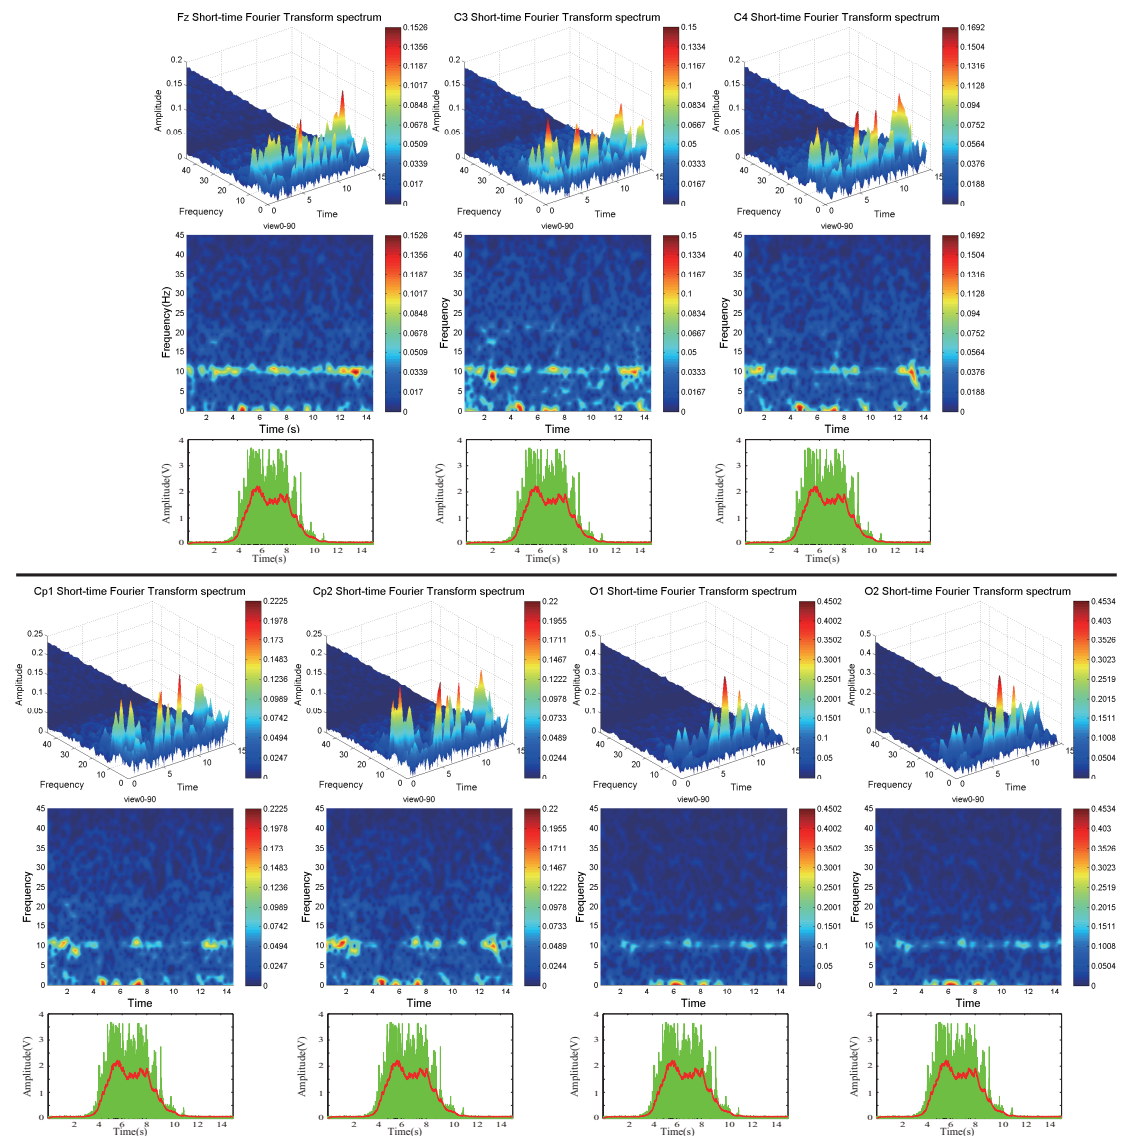


図 5.8: STFT の解析結果

5.4.3 主成分分析の結果-運動関連脳波の抽出

主成分分析の結果を図 5.9 に示す.

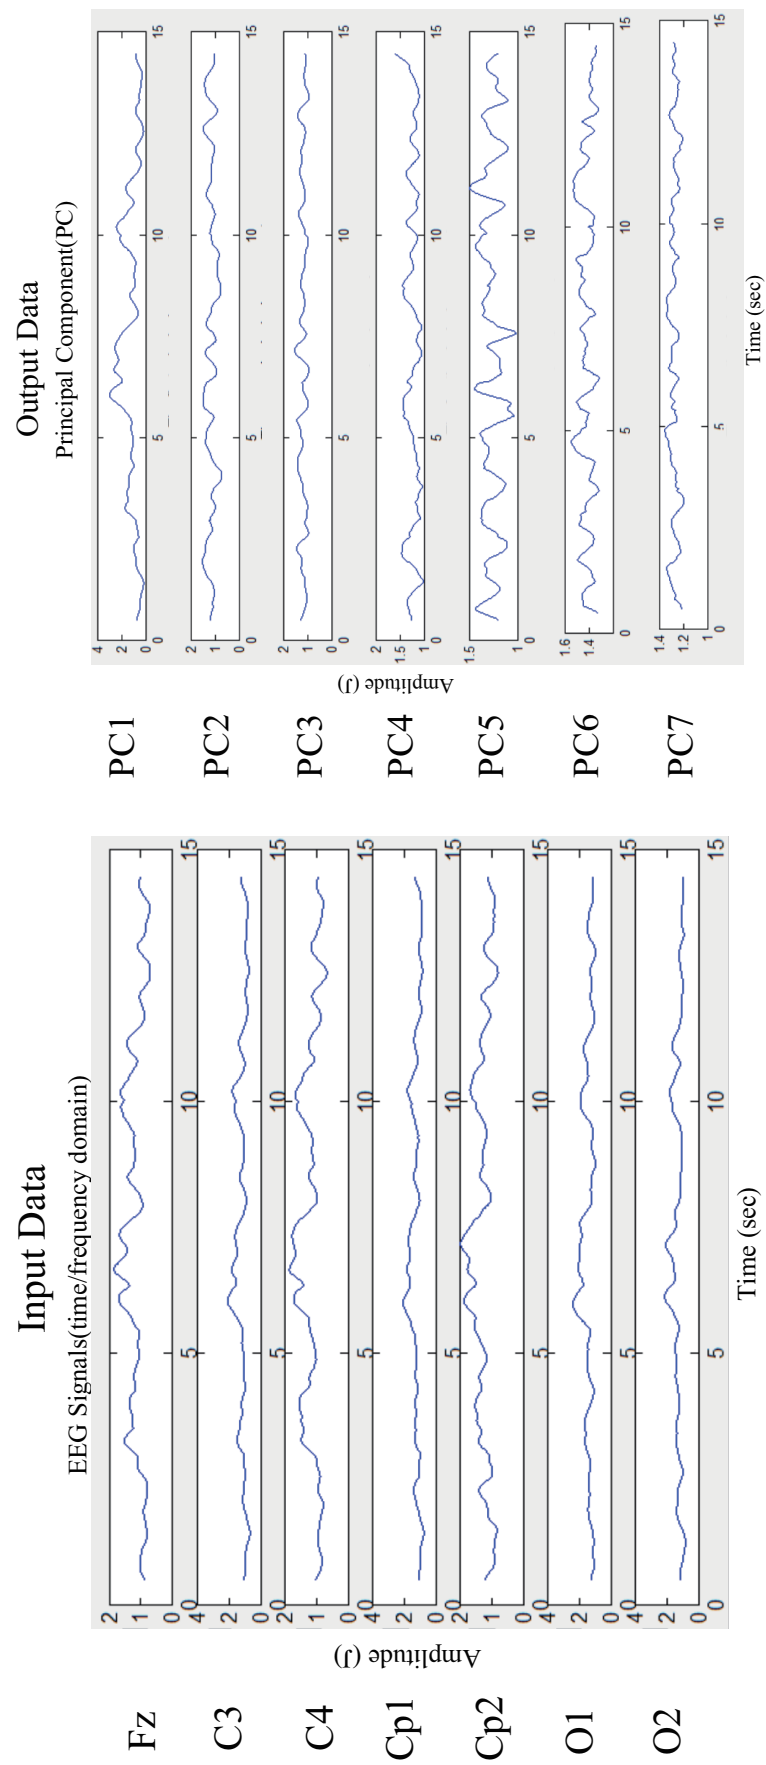


図 5.9: 主成分分析の解析結果

図の左半分は、各チャンネルの STFT により得られたパワースペクトルの積算の結果である。横軸は時間であり、縦軸は各時間における STFT 後の 0 Hz から 45 Hz までのパワースペクトルの積分値である。右半分は、左半分のデータの PCA の結果であり、7つの主成分 (PC) である。横軸は時間で、縦軸は振幅である。各成分の意味は、固有ベクトルによって決まる。そこで、各被験者の第一、第二主成分の寄与率および累積寄与率 (Cumulative Contribution Ratio) を表 5.3 にまとめた。

		PC1	PC2	Cumulative Contribution Ratio (PC1 & PC2)
		Subject A	Max.	91.19
	Min.	58.26	6.23	82.01
	Avg.	73.70 ± 10.12	16.08 ± 6.00	89.78 ± 5.26
		PC1	PC2	Cumulative Contribution Ratio (PC1 & PC2)
		Subject B	Max.	92.11
	Min.	50.59	2.93	70.03
	Avg.	73.48 ± 11.22	13.91 ± 6.15	87.38 ± 6.32
		PC1	PC2	Cumulative Contribution Ratio (PC1 & PC2)
		Subject C	Max.	82.71
	Min.	47.55	8.41	66.01
	Avg.	63.99 ± 12.06	17.80 ± 5.42	81.79 ± 9.01

表 5.3: 各被験者の PCA の結果

被験者 A の第一主成分 (PC1) の寄与率の最大値は 91.19 %、最小値は 58.26 %で、15回の試行の平均値は 73.70 ± 10.12 %であった。第二主成分 (PC2) の寄与率の最大値は 24.97 %、最小値は 6.23 %で、15回の試行の平均値は 16.08 ± 6.00 %であった。また PC1 と PC2 の累積寄与率の値の最大値は 97.58 %、最小値は 82.01 %で、15回の試行の平均値は 89.78 ± 5.26 %であった。同様に被験者 B と C の結果もその表にまとめている。測定された EEG 信号の第一と第二主成分のみで 80 %以上の情報を占めているため、変化が小さい他の成分はモデルの構築と精度に大きな影響を与えず、システムを 7次元から 2次元空間へ圧縮することができ

ると考えられる。したがって、ここで第三主成分から第七主成分までを放棄した。

5.4.4 推定結果と考察

EEG 信号から推定された EMG 信号を図 5.10 に示す。図 5.10 の上から、それぞれ被験者 A, B, C の結果を示す。黒い実線と赤い実線は、それぞれ計測された EMG 信号と推定された EMG 信号を表している。横軸は時間、縦軸は EMG 信号の振幅である。提案手法で構築したシステムの推定精度を評価するために、推定値と測定値の相関係数 (R) を計算した。相関係数が 1 に近いほど、推定値と測定値の相関が強くなることを意味する [108]。

また、構築されたシステムを評価し、かつ信頼性と安定性を高めるために、交差検定を行った。1 試行目のデータをモデル生成のための訓練データ、残りの 14 試行のデータをテストデータとして使用し、推定結果の相関係数を計算した。テストデータの推定結果の相関係数の平均は、モデルの推定精度を評価するための指標として扱った。交差検定の結果を図 5.11 に示す。図中の (a), (b), (c) は被験者 A, B, C の結果を表している。横軸は試行/モデルの番号、縦軸は推定された EMG 信号と測定 EMG 信号の間の相関係数であり、各モデルで推定された結果の相関係数の標準誤差も計算し、グラフにプロットしている。

210 回のテスト結果の中では、被験者 A の R の最小値は 12 番目のモデルからのものであった。また、12 番目のモデルの相関係数の平均値と標準誤差は 0.08 と 0.03 となった。このときの訓練データを見ると、EEG 信号は前処理されているにもかかわらず、ノイズやその他の高周波数成分の影響を受けているため、EEG 信号の特徴を効果的に抽出できず、モデルを正常に生成できないことと考えられる。したがって、他のテストデータに対して推定がうまくされないのは当然といえる。さらに、提案手法の有効性を確認するため、15 個のモデルの推定精度の平均を計算したものを図 5.12 に示す。横軸は被験者、縦軸は相関係数の平均である。黒い実線はすべてのモデルの相関係数の平均であり、赤い実線は失敗したモデルを削除した後の相関係数の平均である。そして、それらの標準誤差もグラフにプロット



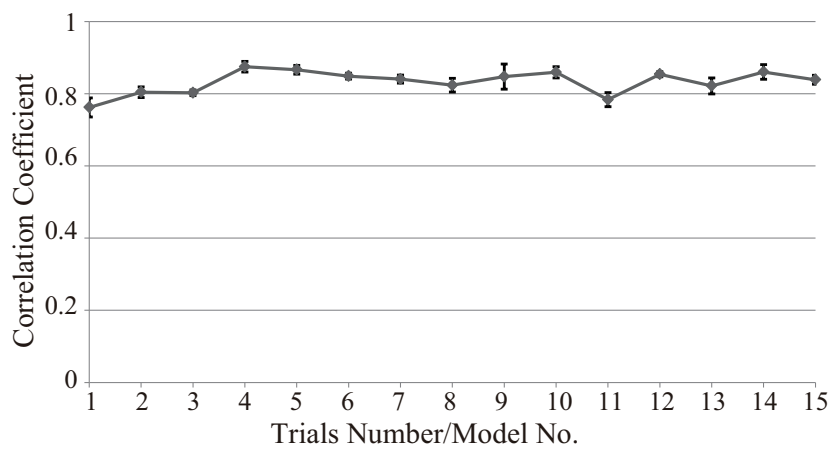


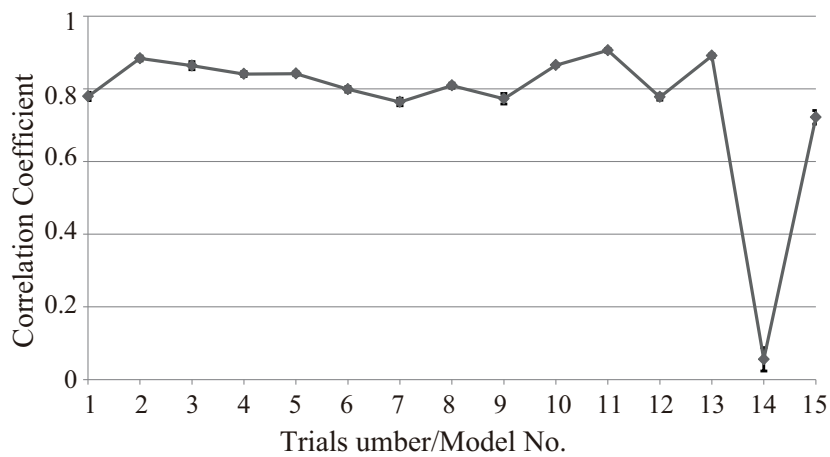
図 5.10: EEG 信号から推定された EMG 信号の結果. (a), (b) および (c) は, 被験者 A, B, および C の結果を表す.



(a)



(b)



(c)

図 5.11: 被験者 A, B および C の交差検定の結果

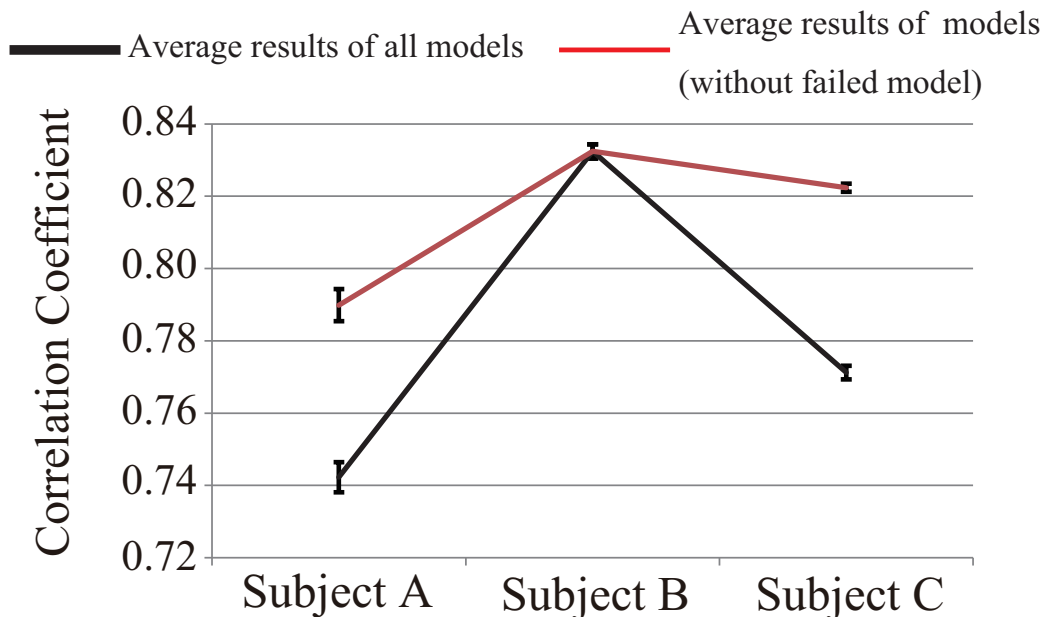


図 5.12: モデルの推定結果の平均値と標準誤差

している。被験者 A の場合，すべてのモデルの推定結果の相関係数の平均は 0.74 であり，標準誤差は 0.004 となった。モデル 12 の結果を削除した後，すべてのモデルの推定結果の相関係数の平均は 0.79 となり，標準誤差は 0.004 となった。モデルを正常に生成できない場合があったが，モデル作成の成功率は 93.3 % を超える結果となった。

同様に，被験者 B と被験者 C の結果を図 5.11 と図 5.12 に示す。被験者 B では，210 回のテスト結果で R の平均は 0.83 であり，標準誤差は 0.002 であった。また，被験者 C の R の最小値は 14 番目のモデルの結果であった。また，14 番目のモデルの推定結果の相関係数の平均値と標準誤差はそれぞれ 0.05 と 0.03 となった。すべての推定結果の相関係数の平均は 0.77 で，標準誤差は 0.002 であった。モデル 14 の結果を削除した後，すべての推定結果の相関係数の平均は 0.82 で，標準誤差は 0.001 となった。モデル作成の成功率は 93.3 % 以上であった。

推定結果についてまとめると，被験者 A と被験者 C の両方がモデルの生成に失敗した例があっても，成功率は 93.3 % を超えていた。さらに，3 人の被験者の結果を統計すると，R の平均は 0.79， R^2 は 0.62 を超えることが分かった。これは，推定された EMG 信号と測定された EMG 信号の間に高い相関があることを意味す

る。つまり、推定された EMG 信号と実際に測定された EMG 信号の適合度はかなり高いと考えられ、提案された方法が効果的でかつ信頼性の高いことを証明する。これらの結果は、EEG 信号を使用して EMG 信号を推定し、外骨格ロボットを制御して人間の日常生活をサポートする可能性を示しているといえる。

5.5 まとめ

本章では、擬似拮抗筋を導入することにより、脳波を用いたパワーアシストシステムの構築手法を提案し、PCA を用いて、脳波と筋電の関係を線形モデルで表すことができ、構築された線形モデルで肩関節のトルクの推定に成功し、実験でその有効性を検証した。さらに STFT を用いて、運動に関連する脳波の変化および分布を明らかにした。

第6章 遅延を考慮した線形モデルによる脳波から肩関節のトルクの推定

前章では主成分分析を用いることで脳波—トルク間の線形モデルを導出し、屈伸動作を行った際の脳波を入力とすることで、トルクの推定に成功し、線形モデルの有効性が確認できた。しかし、脳波信号は時間に伴って変化する信号のため、脳波とトルク間の時間遅延の考慮が必要となる。本章では、遅延を考慮した上でリアルタイム制御に向けた線形モデルの作成を行うことにより、脳波から肩関節の屈曲/伸展動作時のパワーアシストを実現する。

6.1 線形モデルの作成手法

モデルの式を以下のように提案する。

$$Y_{EMGM} = a + \sum_{k=0}^L \sum_{n=1}^N (b_{nk} X_{EEGM}(t-k)) \quad (6.1)$$

ここで、タイムラグと言うパラメータを導入する。Lはタイムラグの数であり、Nは計測する電極の数、Mは計測したサンプルの番号である。ただし、このタイムラグは計測や制御システム上の遅延ではなく、運動したときの脳波の変化の最大値の時刻と発生した筋電の最大値の時刻の差を意味する。この式の係数を求めれば、モデルが作成できる。今回は最小二乗法を用いて、式(6.1)の方程式を解

く、モデルは以下のような式で書き換えることができる。

$$Y_M = \Phi_M \cdot \theta + \varepsilon_M \quad (6.2)$$

ここで、 Y_M は M 個のサンプルの筋電信号の振幅である。 ε_M は誤差であり、 Φ_M は以下の式である。

$$\Phi_M = \begin{bmatrix} X_{EEG1.e_1} & X_{EEG1.e_2} & \cdots & X_{EEG1.e_i} & 1 \\ X_{EEG2.e_1} & X_{EEG2.e_2} & \cdots & X_{EEG2.e_i} & 1 \\ & & \vdots & & \\ X_{EEGM.e_1} & X_{EEGM.e_2} & \cdots & X_{EEGM.e_i} & 1 \end{bmatrix} \quad (6.3)$$

ここで、 $X_{EEGM.e_i}$ は計測された脳波であり、その中の e_i は各電極の番号である。 θ は係数の行列であり、以下の式となる。

$$\theta = \begin{bmatrix} \mathbf{b}_{1k} & \mathbf{b}_{2k} & \dots & \mathbf{b}_{nk} & a \end{bmatrix}^T \quad (6.4)$$

ここで、 \mathbf{b}_{nk} は n 個目の電極の k 個目のラグに対応するベクトルである。

次に、最適解を得るため、目標関数 $J(\theta)$ を以下のように定義する。

$$J(\theta) = \frac{1}{2} \varepsilon_M^T \cdot \varepsilon_M = \frac{1}{2} (Y_M - \Phi_M \cdot \theta)^T (Y_M - \Phi_M \cdot \theta) \quad (6.5)$$

そして、 θ に対する偏微分が 0 の時、残差が最小となり、最適解を求められる。すなわち、以下の式となる。

$$\frac{\partial J}{\partial \theta} = - \cdot \Phi_M^T (Y_M - \Phi_M \cdot \theta) = 0 \quad (6.6)$$

これにより、 θ の最適解が以下のように求められる。

$$\hat{\theta} = (\Phi_M^T \cdot \Phi_M)^{-1} \cdot \Phi_M^T \cdot Y_M \quad (6.7)$$

6.2 実験設計

提案手法を確認するため、実験を行った。本実験は、被験者を20代の健常な右利き男性3名とし、あらかじめ実験内容を説明して同意を得た上で行った。

● 脳波の計測部位

第5章の結果より、運動時は脳全体が協調し、動作を実現する結論に至った。したがって、計測時にはもできるだけ測定範囲を広げることでより多くの情報を取得し、結果的に精度の向上につながると考え、本実験ではCP1とCP2の二点をP3とP4に変更した。そして、新たな計測点として、Czを選定し、Fpzをグランド電極とした。したがって、最終的な計測点はFz, C3, C4, Cz, P3, P4, O1, O2の8点となる。

● 肩関節の表面筋電位の計測部位

第5章と同じく、筋電は肩関節の三角筋前部を計測点として用いた。

● 計測内容

図6.1のように、被験者は開眼状態で、5分間以内に連続で3 Kgの重りを持ちながら肩の屈曲と伸展運動を行った。肩の屈曲と伸展運動を合わせて1試行とした。脳波計測点は先ほど述べたようにFz, C3, C4, Cz, P3, P4, O1, O2の8点として、それぞれ耳朶との差動増幅（単極誘導）を行った。同時に、肩動作時に働く三角筋前部を計測点として筋電計測を行い、右手首をボディーアースとした。試行回数は約80回である。実験内容を確認のため実験中ビデオを録していた。




図 6.1: 脳波と筋電の計測環境とタスク

6.3 脳波信号の解析結果

6.3.1 脳波の各周波数帯域成分の分布

まず、全ての計測データをフーリエ変換し (フーリエ変換データ長さ 1024 点), 各電極における周波数特性, すなわちパワースペクトルの分布を調べた。

ここで、8つの計測点 Fz, C3, C4, Cz, P3, P4, O1, O2 はそれぞれ Channel 1, 2, ..., 8 に対応している。図 6.2 と 6.3 の中で、a の部分は脳波データの時間領域上の振幅の変化である。5 分間のデータの量は非常に膨大なため、データを 200 に分割した。そのため、横軸は時間、縦軸は 200 のデータを示しており、脳波信号の振幅を色付きで表している。b の部分は脳波のパワースペクトルの周波数分布である。横軸は周波数であり、縦軸はパワースペクトルである。図 6.2 と 6.3 の各チャンネルのフーリエ変換の結果にマルがついているところを比べると、8-14 Hz の帯域に変化が見受けられた。さらに、前頭葉に比べ後頭葉における変化量が大きいことが分かった。

さらに肩関節が運動するときの脳波の各周波数帯域の分布を図 6.4 に示す。この図を見ると、まず低周波数帯域 (1-8 Hz) が前頭葉や中心部に分布し、高周波数帯域 (10-70 Hz) が後頭葉に分布していることが分かった。

次に、8 チャンネルのパワースペクトルの周波数分布の曲線を見ると、すべての電極において 11 Hz を中心とする 8-14 Hz の帯域の振幅に激しい変化が見られる。8-14 Hz の変化において、8-10 Hz の成分が中央部と後部に分布し、11-14 Hz の成分は完全に後頭部に分布していることが分かった。

ここで、4 Hz のパワースペクトルでは前頭葉の部分に分布していることが分かり、その成分はおそらく眼電位やまばたきだと推測される。その成分の確認については、後で述べる。また、脳波アンプは 50 Hz のノッチフィルタを有しているため、50 Hz の成分は減少し、また、50 Hz の整数倍 (100 Hz) の成分に影響が出ていることが確認された。

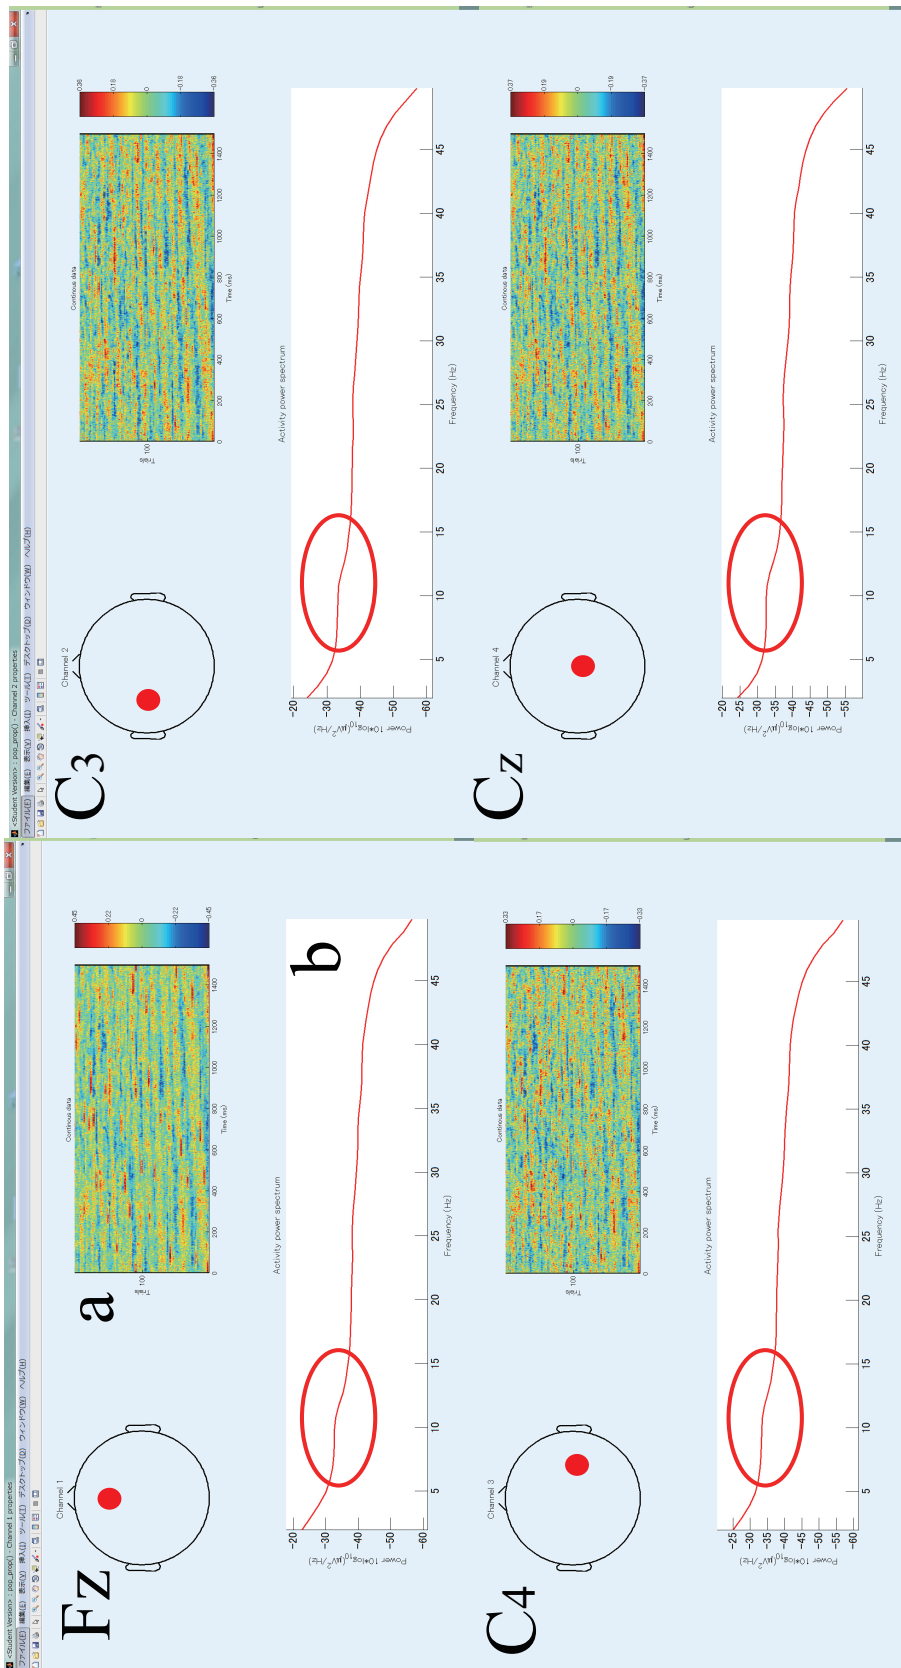


図 6.2: 各電極の周波数特性 1

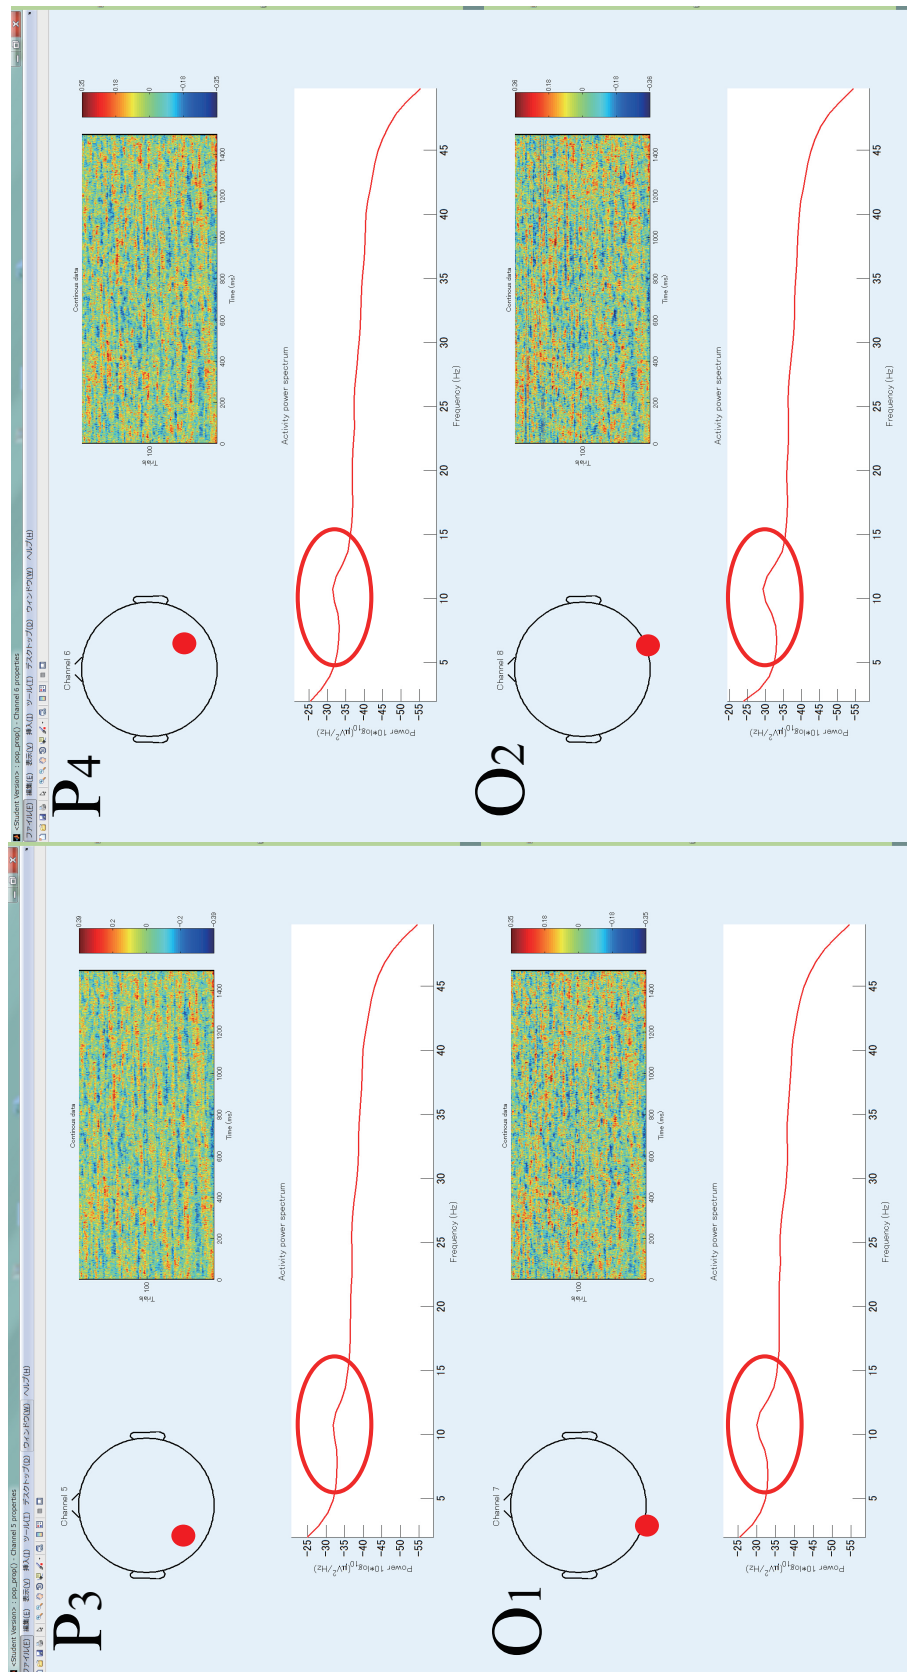


図 6.3: 各電極の周波数特性 2




図 6.4: 脳波の各周波数帯域の頭皮上の分布

6.3.2 各独立成分の特性

計測された脳波信号は、脳内で複数の異なる部位で発生した電位を観測したものであるため、必ずしも独立とは言えない。ただし、脳細胞の活動により発生した電位の信号源は独立で、また計測された信号はこれらの独立した信号源が線形結合したものと考えられる。そのため、計測した脳波信号に対して独立成分分析を行った。その結果を図 6.5 に示す。a, b はそれぞれ各独立成分における頭皮上の分布とその独立成分が対応する脳波データの時間軸上の変化を示している。横軸は時間、縦軸は 300 秒のデータを 200 回に分割したものを示しており、振幅の強さを色付きで表している。c は各独立成分のフーリエ変換後のパワースペクトルの周波数分布である。横軸は周波数であり、縦軸はパワースペクトルである。

これらの独立成分に生理学的な意味をつけることは難しい。我々は脳波の中の有用な成分のみを抽出し、制御に使用する。ゆえに、脳機能の観点から見て解釈できるもののみを用いて、モデルの作成を行う。また、計測環境に起因するノイズも同時に計測されるため、各独立成分の特徴を見て、脳波成分ではないと考えられるノイズ成分の除去を行うことも可能である。(例：全部のセンサーに共通の雑音地磁気などと各センサーで独立な雑音など。)

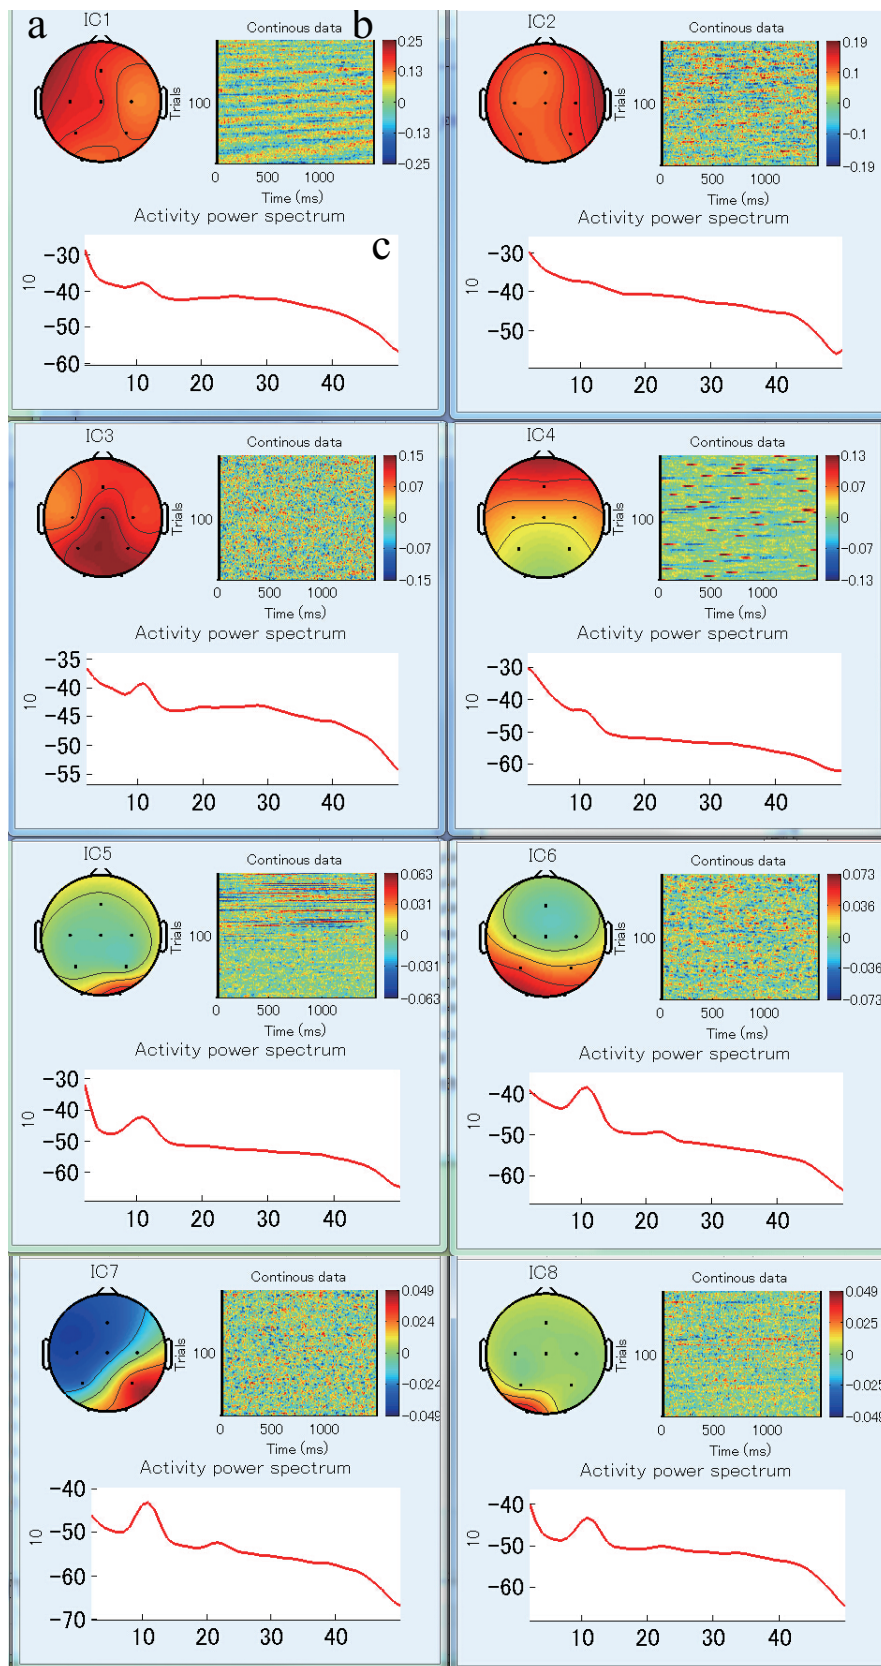


図 6.5: 独立成分分析結果 (成分 1-8)




図 6.6: 独立成分分析による信号分離結果 (波形)

ここで、脳活動と眼球運動は解剖学と生理学上の観点からみて独立であると仮定する。そして、第四独立成分 (IC4) の b の部分を見ると、この成分の時間領域の波形では連続的な変化が見られないため、ノイズと考えられる。また、発生する部位は前頭葉のため、それは眼電位や眼球運動の成分と推測される。さらに分かりやすくするため、各独立成分の時間領域の詳しい情報を図 6.6 に示す。まず、IC4 のデータを見ると、いくつかのスパイクが生じていることが分かった。また、この成分の発生する部位は前頭葉であり、この成分はまばたきと考えられる。

また、図 6.6 の波形の大きさを見ると、IC4 以下の成分のパワースペクトルの振幅は小さいため、それらの成分は微小な成分やノイズなどと考えられる。一方で、IC1 から IC3 までは、運動に伴い発生した信号と考えられる。

6.3.3 目の動きに関する成分

図 6.5 の 4 番目の成分 (IC4) が眼電位または眼球運動である可能性を確認するため、実験の様子をビデオに記録し目の動きと計測時間を参考しながら、データを確認した。結果として、IC4 は目の動きと完全に一致していることを確認した。

図 6.7 のマル部分を拡大したものが図 6.8 である。ビデオより、被験者がまばたきを行った時刻とスパイクが生じた時刻は一致していた。

また、眼電位や眼球運動の成分を除去した波形 (第四成分を削除) と除去前の

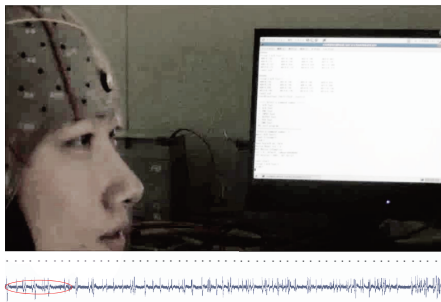


図 6.7: 目の動きの確認




図 6.8: 開眼と閉眼の波形




図 6.9: 眼電位や眼球運動成分の除去の前後（青：除去前，赤：除去後）

各電極の波形を図 6.9 に示す。図 6.9 中のマル部分を見て明らかなように、大幅なノイズ除去ができたといえる。

6.3.4 運動に関連する脳波の成分

運動に関連する脳波成分を特定するため、IC4 以外のデータを確認した。

本実験ではタスクに動作の制限を加えているため、脳波成分の中でも運動に関連する成分は大きく現れてくると予想できる。したがって、図 6.6 の中でパワースペクトルが大きい IC1, IC2, IC3 に注目した。さらに、IC1 では周期的な変動があるのに対し、IC2 と IC3 ではそれが見られないので、中でも IC1 に注目し、データの解析や特徴の抽出を行った。

まず、IC1 を各試行毎の加算平均し正規化すると、筋電の変化との関連性が見られた。IC1 と筋電を比較したものを図 6.10 に示す。さらに、結果を見やすくする




図 6.10: 運動に関連する脳波成分 (IC1) と筋電の比較




図 6.11: 図 6.10 の一部の拡大図 (但し EEG を正規化している)

ために、その中の一部を拡大し、IC1の各チャンネルの平均を正規化した波形と筋電信号を比較した結果を図 6.11 に示す。

この成分の周波数特性を分析すると、図 6.12 に示す結果が得られた。この結果を見ると、主な成分は低周波数帯域の 0-2 Hz にあることが確認できた。

以上の結果から、主に低周波数帯域を用いた線形モデルを作成した。具体的には、計測された脳波に対して遮断周波数 2 Hz の 4 次バターワースローパスフィルタをかけ、正規化し、入力データとした。筋電信号は事前実験の結果より、遮断周波数 45 Hz の 4 次バターワースローパスフィルタをかけ、ARV 処理をし、入力データとする。また最初の脳波は不安定であるため、最初の三秒間のデータを使用しない。図 6.11 のデータを確認すると、筋電が最大値になる約 1 秒前に脳波の変化が最大になったため、タイムラグを 1 秒間に設定した。また、今回は脳波の 0-2 Hz、筋電信号の 0-45 Hz の帯域に注目するため、標本化定理により、サンプリング周波数を 90 Hz 以上の高い周波数で標本化すれば元の信号を完全に復元することができる。したがって今回 1000 Hz から 100 Hz にダウンサンプリングした。




図 6.12: 独立成分分析の IC1 の FFT 変換結果

タイムラグは1秒間に設定してあるので、これは実質100点に相等する。

6.4 推定結果および考察

6.4.1 単一試行の推定結果

単一試行の3秒間のデータを用いてモデルを作成し、筋電を推定した結果を図6.13に示す。この結果を見ると、推定された筋電は実測値の変動と一致していることが分かった。

6.4.2 連続運動時の推定結果と考察

モデル作成用のデータは一度に十個ずつ抽出した。その際のオーバーラップは0%とし、データを重複では使用しない。しかし、タイムラグの数によって、脳波信号のサンプリング周波数と推定したい信号（筋電、位置情報など）のサンプリング周波数が異なることがある。例えば、タイムラグを10に設定し、サンプリング周波数を10 Hzとすると、モデルを作成する時に、推定したい信号が10個のデータに対して1個が対応する、すなわち推定された信号のサンプリング周波数が1 Hz




図 6.13: 10-13 秒の 3 秒間の単一試行データを用いたモデルの推定結果

になってしまうことがある。このメリットとしてデータを重複することがなくなるが、デメリットとして推定したい信号が高周波数信号の場合は有効ではないことが挙げられる。今回の場合は肩関節の運動は5分間で80回を行われているため、問題はない、または線形補間で対応できると考えられる。今回3秒から300秒までのデータを用いて、モデルの作成を行った。

その推定結果を図6.14に示す。今回はデータ量の多さを考慮し、0秒から150秒までの推定結果とした。この結果を見ると、推定された筋電と計測された筋電は非常に類似していることが分かった。

この結果より、単一動作でも連続的な動作でもこのモデルで対応できると考えられる。同時に、線形モデルの有効性も確認でき、BMI技術によるパワーアシストの可能性が示されたといえる。今後はモデルを作成した際に、係数行列のPE (Persistently Exciting) 性および条件数 (Condition Number) の問題も考慮するために、最小二乗法のような学習手法を用いて逐次パラメータを更新していく手法を導入することでリアルタイム制御を目指す。




図 6.14: 先行研究の手法の検証

6.5 まとめ

本章では脳波信号と筋電信号の最大の変化の時刻の差を遅延と定義し、その遅延を定量的に解析した。また第5章で線形モデルの有効性が確認されたうえ、脳波信号と筋電信号の関係を線形モデルで表すことができた。さらに脳波信号と筋電信号の遅延を考慮し、遅延に関する変数を線形モデルに導入し、モデルを作成した。このモデルにより、脳波から筋電信号の推定に成功した。そして擬似拮抗筋を導入することにより脳波から肩関節のトルクの推定が可能となり、脳波を用いた肩関節の屈曲/伸展動作においてパワーアシストを行う可能性を示唆した。

第7章 独立成分分析による肩関節の 屈伸運動時の特徴の抽出

前章の結果により独立成分分析（ICA）を用いて信号の前処理を行い，信号の中に独立性がある成分において分離が可能であることを確認した．そのため，上肢の肘と肩関節の連動に関してそれぞれの特徴が抽出できれば，上肢のパワーアシストができると考えられる．ここで，肘関節に関しては同グループの吉岡らがすでに研究を進めているため，本章では計測された脳波成分の中で肩関節の屈伸運動時の信号源を特定し，特徴を抽出する．同時に，時間領域で関節トルクの変化と運動に関する脳波成分の関係も確認することにより，屈伸運動での肩関節に必要なトルクを推定する線形モデルの遅延パラメーターの理論的基礎となり，EEG信号に基づくトルク情報の推定が可能であることを示唆する．また提案した手法は実験によって検証され，EEG信号を用いたBMIを介して人間の日常生活をサポートできる可能性を示す．

7.1 運動と関連する脳波成分の抽出手法の提案

肩関節の動作に関する成分を見つけるために、頭皮チャンネルで記録されたデータから信号源を特定する必要がある。頭皮で記録された1チャンネルのデータは、伝達と減衰後の信号源の投影と基準チャンネル間の電圧差と見なされる。したがって、各電極で測定されるいわゆる EEG 信号は、実際にはさまざまな非皮質信号源（例えば、眼球の動きによって誘発される電位や単一の筋肉活動によって生成される電位など）およびその他の非生理学的信号（線形ノイズ、機器ノイズ、環境ノイズなど）などの様々な信号を体積伝導させたものである。そして一般的に、この過程（体積伝導過程）で他の信号は混入しない [109]。しかし、体積伝導された信号同士がお互いに干渉し合い、信号源での影響をあいまいにしてしまう。ここでは、ICA を用いて信号源をノイズから分離する。ICA は、EEG をはじめとする信号処理の分野で混合された信号を分離または特定の信号成分を抽出するために広く使用されている [110]。これは、時間相関に基づいた高次の統計または独立性を用いた、信号分離のための多次元信号分析手法であり、信号源が統計的に独立しているという仮定のみに基づいて信号を分離する。このため、ブラインドソース分離（Blind Source Separation: BSS）とも呼ばれる。計測された信号（運動に関連する信号源、非皮質信号源、その他の非生理学的信号源）が独立している場合、EEG 信号からの特徴抽出問題は BSS の問題と同等である。したがって本研究では、取得した EEG データに ICA を適用して、肩関節の動きに関連する成分を抽出する。

信号源 $\mathbf{s}(t)$ は次のベクトルで与えられると仮定する。

$$\mathbf{s}(t) = (s_1(t), s_2(t), \dots, s_n(t))^T \quad t = 0, 1, 2, \dots \quad (7.1)$$

$\mathbf{s}(t)$ の各信号源の平均は 0 であり、各信号源は互いに独立している。 $(\cdot)^T$ は転置演算を表す。測定された信号は次のように表示される。

$$\mathbf{x}(t) = (x_1(t), x_2(t), \dots, x_m(t))^T \quad t = 0, 1, 2, \dots \quad (7.2)$$

これらの信号は、 m 個のセンサーで観測される信号と見なすことができる。ここでは、 $\mathbf{s}(t)$ と $\mathbf{x}(t)$ の線形関係は次のとおりである。

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) \quad (7.3)$$

\mathbf{A} は $m \times n$ の実数行列である。BSS の問題は、 $\mathbf{s}(t)$ および \mathbf{A} の確率分布に関する事前情報なしで、 $\mathbf{x}(t)$ を n 個の独立した信号に分離することである。 $n \leq m$ の場合、解が存在する。つまり、相互に独立した特定の $n \times m$ の実行列 \mathbf{W} が存在する。 $\mathbf{y}(t)$ は次のように定義される。

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t). \quad (7.4)$$

$\mathbf{W}\mathbf{A} = \mathbf{I}$ の場合 (\mathbf{I} は $n \times n$ の単位行列)、 $\mathbf{s}(t)$ は $\mathbf{y}(t)$ に等しくなる。したがって ICA では、独立成分フィルターを用いて観測されたデータ $\mathbf{x}(t)$ の中で利用可能な最大の時間独立信号 $\mathbf{s}(t)$ を生成する。本論文では、情報量を最大化するロジスティック Infomax ICA アルゴリズムを使用する [111]。また EEG 信号の処理は MATLAB 環境によって行う。

7.2 実験内容

本実験は、被験者を20代の健常な右利き男性3名とし、あらかじめ実験内容を説明して同意を得た上で行った。図7.1のように、被験者は開眼状態で、3 Kgの重りを持ちながら、5分間の中で任意のタイミングで肩の屈曲と伸展運動を行った。肩の屈曲と伸展運動を合わせて1試行とした。脳波計測点は国際10-10法電極配置に基づき、Fz, C3, C4, Cz, P3, P4, O1, O2の8点として、それぞれ耳朶との差動増幅を行った。同時に、運動の開始時刻を検知するため、肩動作時に働く三角筋を計測点として筋電計測を行い、右手首をボディーアースとした。試行回数は被験者毎に少し異なるが、おおよそ約80回である。成分の確認のため実験中ビデオを録していた。




図 7.1: 脳波と筋電の計測環境とタスク

7.3 信号処理

7.3.1 筋電信号の処理および動作の開始時刻の検出

随意運動の動作時間の基準がないため，ここではEMG信号の振幅の変化時刻に基づいて，随意運動の開始時刻を決定した．EMG信号処理の手順を以下に説明する．A/D変換後のEMG信号は最初に全波整流器によって処理され，20点の移動平均で平滑化その後カットオフ周波数0.7 Hzのバターワースローパスフィルターに介した．元の信号と比較して，平滑化およびフィルタリング後のEMG信号の振幅はかなり減少することが分かっている．そこで元の振幅に復元するために，回復係数を4に設定した．また個人差を考慮するために，各データセットの筋電の最小値 x_{min} と最大値 x_{max} を用いて正規化を行った．

$$y = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7.5)$$

ここで， x と y はそれぞれ正規化前と後の値を表す．また移動平均フィルターとローパスフィルターを使用したため，フィルター処理された波形と元のデータの間には約250 msの遅延が発生した．ここで，制御信号の一つとして，EMG信号をステップ信号の過渡応答と見なすことができるので，ここでは，曲線の最大値の10%を動作の開始時刻と定義した．EMG信号は正規化されているため，曲線の最大値の10%はEMG包絡線の0.1の値である．したがって図7.2に示すように，EMG信号の包絡線の値の0.1となる時刻の250 ms前の時刻が動作を開始する時刻として見なすことができる．なお，抽出された時刻は実際の動作の開始時間と一致することを確認した．

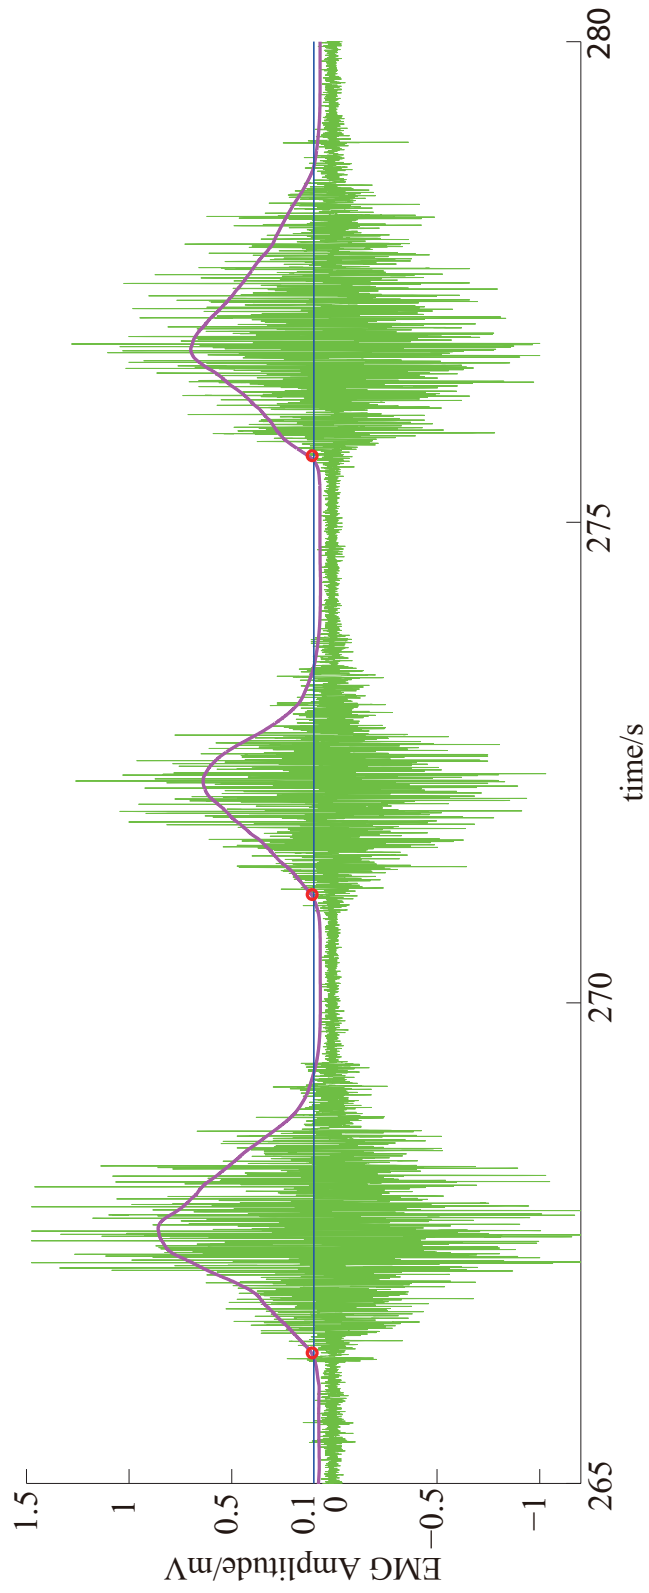


図 7.2: 運動開始時刻の定義と検出

7.3.2 脳波信号の処理

A/D変換後、ベースラインのドリフトを除去するため、EEG信号をカットオフ周波数1 Hzのバターワースハイパスフィルターに介して処理した。次に、EEG信号はICAによって処理し、独立成分を生成した。上記のように、動作の開始時刻を0秒と仮定すると、すべての独立した成分から動作開始の1秒前から2秒後までの合計3秒を1エポック（Epoch）として切り取った。最後に、試行総数の加算平均処理をEEGデータに適用し、脳波の変化の傾向性を算出した。

7.4 実験結果

7.4.1 独立成分分析の結果および各成分の定義

まず、被験者の三人の EEG 信号の ICA の結果を図 7.3 に示す。8 つの EEG 信号チャンネルを用いて測定したため、データを最大 8 つ独立成分に分解できる。ここで、測定された EEG データの中に含まれる正確な成分の数は分からないので、ICA によって取得された 8 つの成分すべてを確認し、特徴的な変動を参考にして脳波成分を判断しなければならない。データ量が膨大中で詳細を表示できないため、図 7.3 には 1 分間のデータのみが示されている。横軸は時間、縦軸は独立成分の振幅である。1 から 8 までの番号は、8 つの独立した成分を指す。3 人の被験者の ICA 結果の波形から、これらの成分を大まかに次の種類に分類できる。

1. 変動の傾向が類似し、周期性のある成分。これらは最も運動に関連する成分の可能性が高い、言い換えれば、この成分は運動実行中の EEG 信号の特徴的な成分と判断できる。
2. 非周期的かつ瞬間的なパルス成分。これは瞬きや眼球運動によって生じるノイズと見なされる断続的なパルス成分と判断できる。
3. 振幅が小さく、変動の少ない成分。これらはバックグラウンド EEG 信号とその他の小さなノイズ成分と判断できる。

各成分の物理的意味を明確にするために、独立成分信号から各測定データを復元し、各試行毎の各独立成分の波形をプロット後、独立成分の特徴を調査した。復元された結果を図 7.4–7.6 に示す。三つの図中には 8 つのサブパネルがあり、それぞれ 8 つの独立した成分に対応している。各サブパネルの上部は、試行総数における独立成分の波形である。横軸は時間、縦軸は試行回数であり、各独立成分の振幅を色付きで表している。また、横軸の黒の縦線は 0 秒を意味する（動作開始時刻である）。またサブパネル中部（IC 部分）は、加算平均された波形であり、サブパネル下部は加算平均された筋電信号である。EEG 信号の変化をより直感的




図 7.3: 被験者の三人の ICA の結果

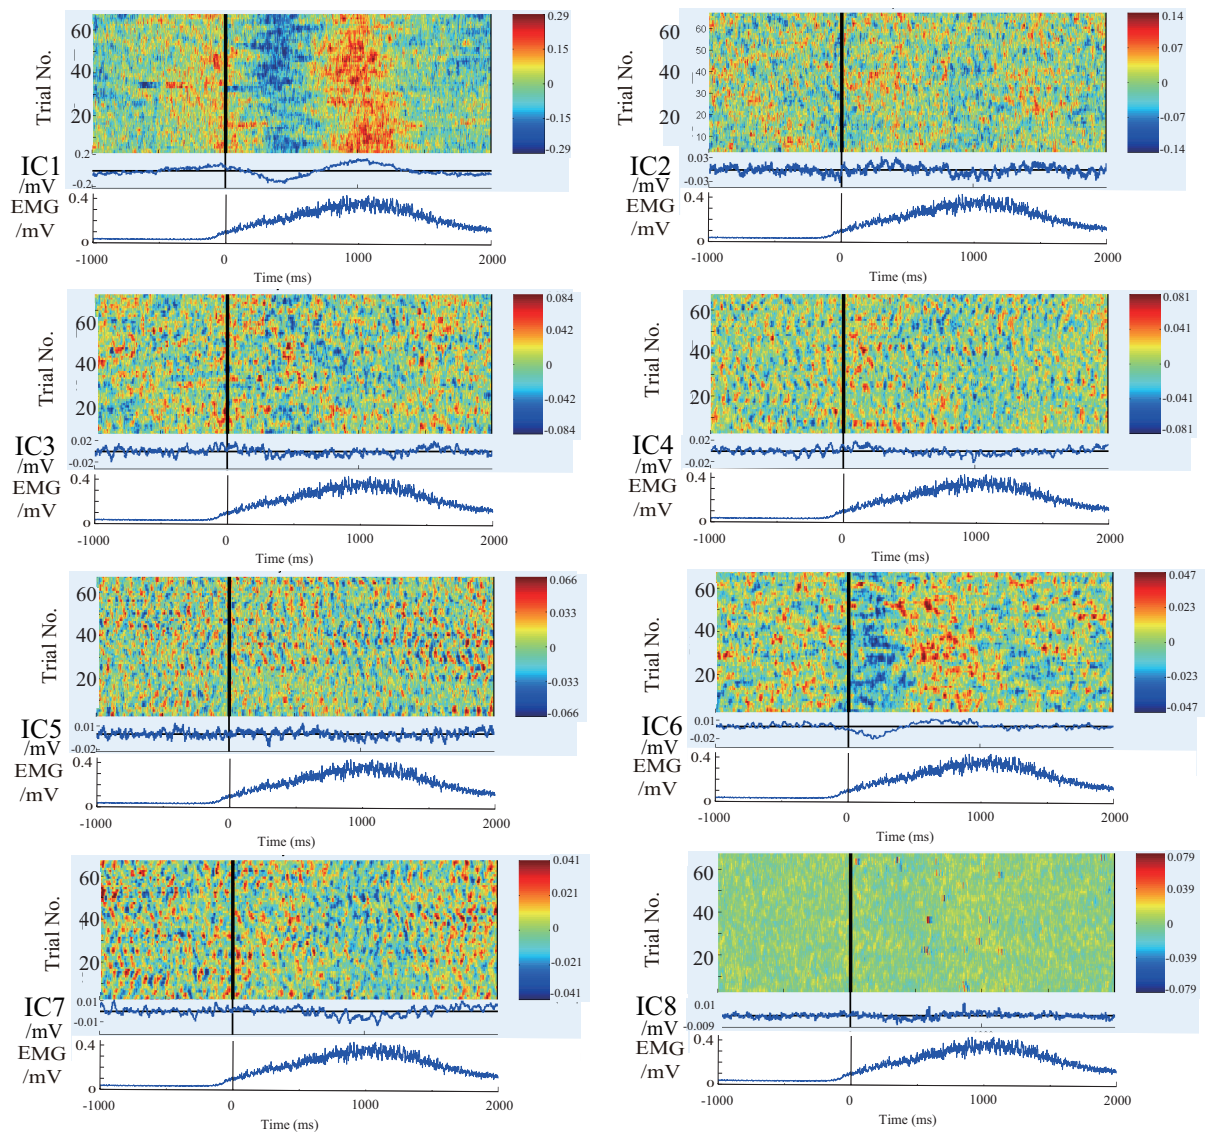


図 7.4: 被験者 A の各実験における各独立成分の波形

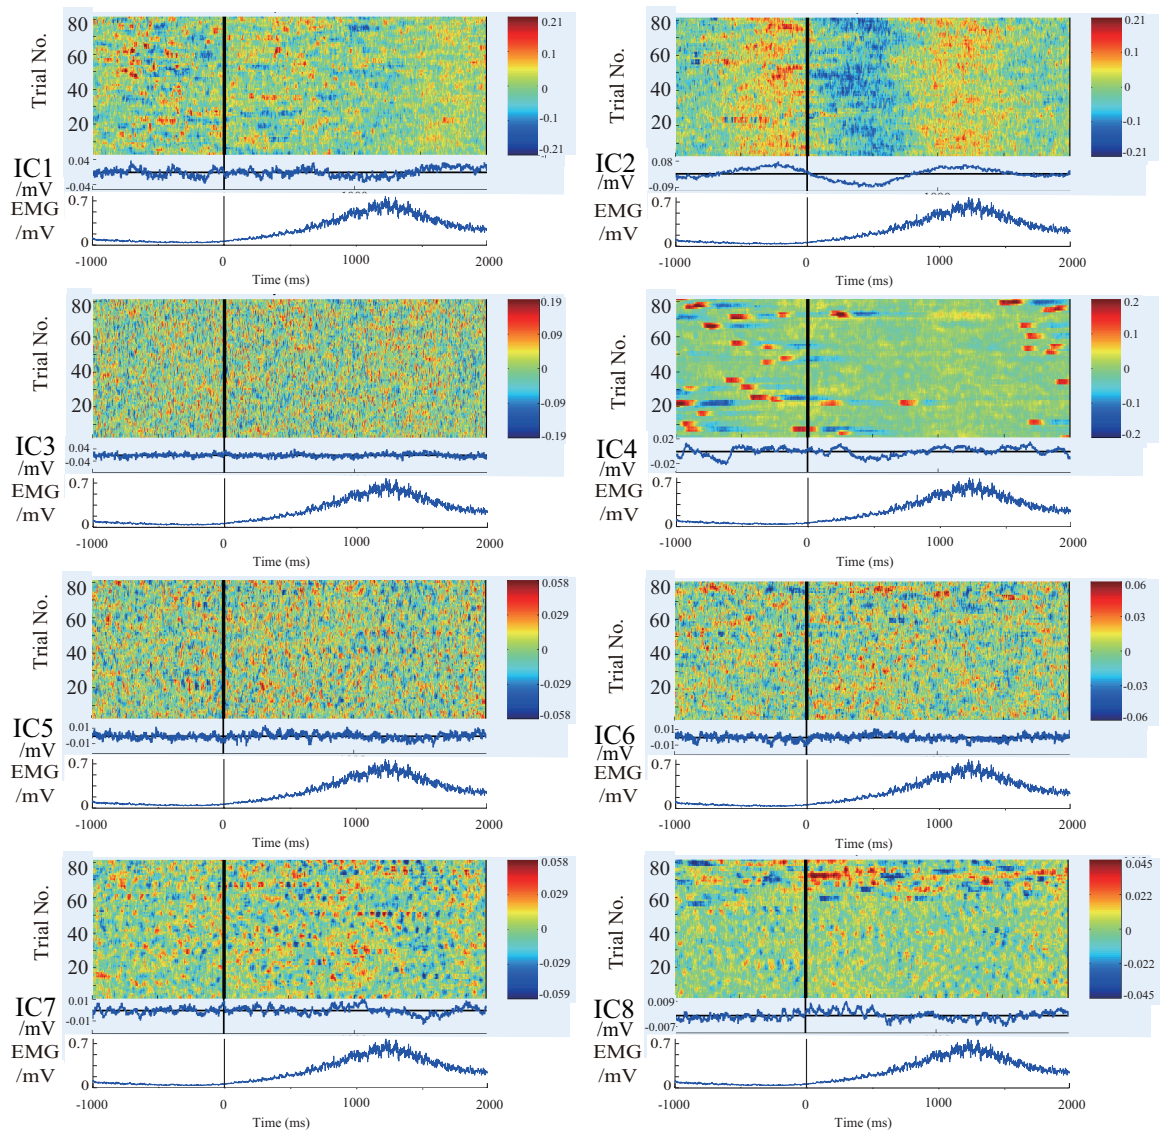


図 7.5: 被験者 B の各実験における各独立成分の波形

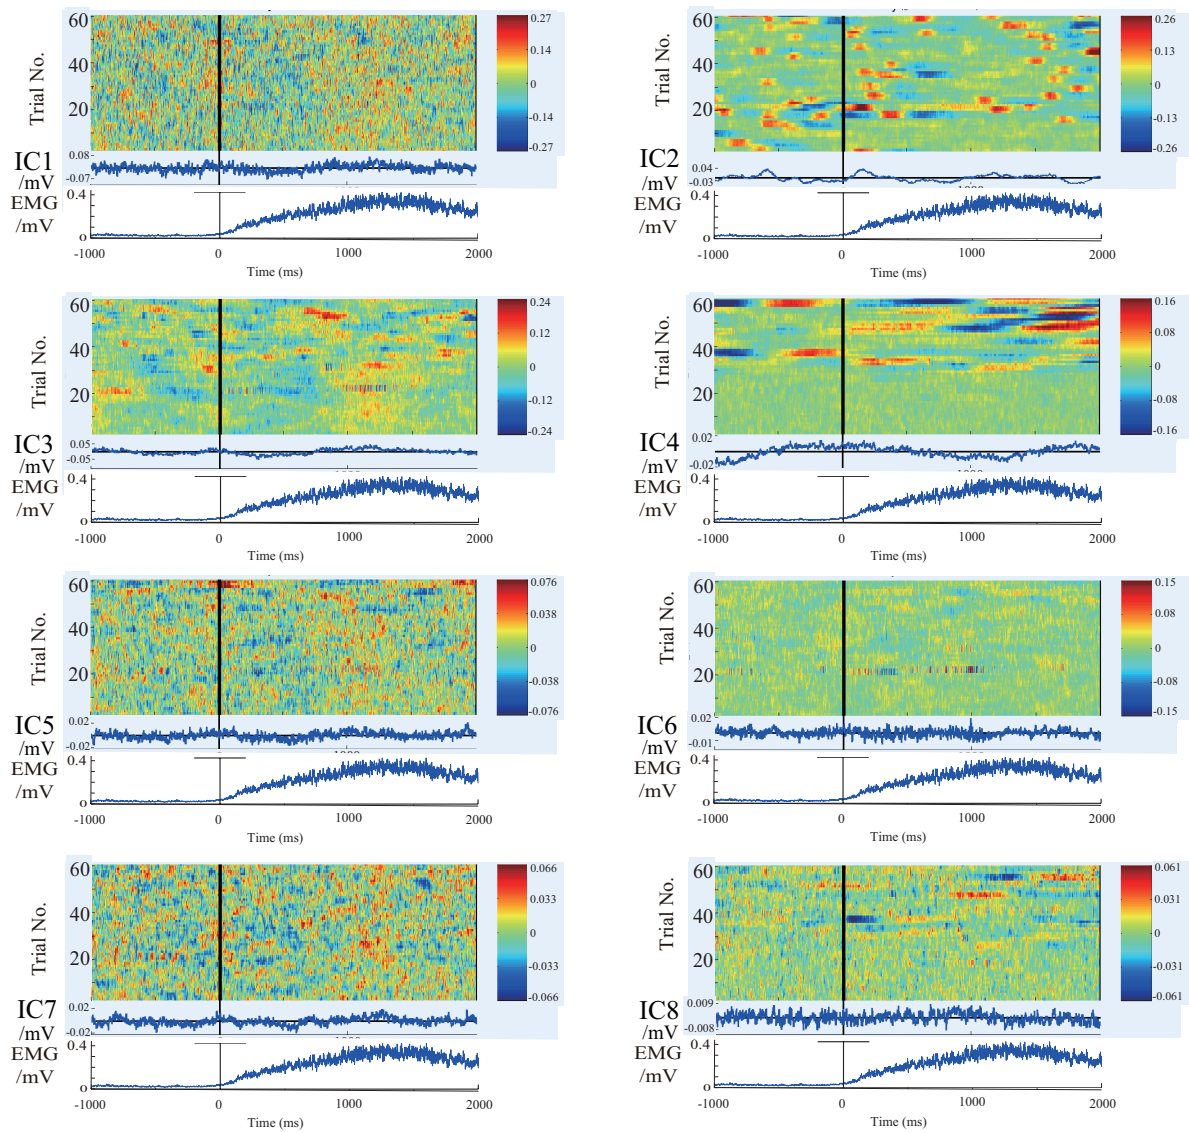


図 7.6: 被験者 C の各実験における各独立成分の波形

に知るために、図 7.4–7.6 のデータに基づいて作成した頭皮上の分布を図 7.7 に示している。まずこれら 4 つの図を通して、各独立成分の脳機能的な意味を解釈できる。そして、それを踏まえ、運動に関連する成分を特定できる。また、図 7.7 から、すべての被験者で同様の成分が確認でき（被験者 A の IC1, 被験者 B の IC2, 被験者 C の IC3）、変化の傾向性も類似していることが分かった。具体的には、動きが始まる前に EEG 信号の強度が徐々に増加し、動きが始まるとすぐに弱まる。そして動きが始まってから再び増加し、最後に元に戻っている。変化する時間は運動開始の時間にのみ依存し、またこの変化は毎回同じであるため、この成分は運動に関連する脳波信号と判断できた。

7.4.2 眼電位成分の特徴および生データに与える影響

次に、眼球運動や瞬きに関連する成分を明確にする。実験を終えた後、被験者 A 運動の前後で極力まばたきを行わないようにしており、一方で被験者 B と被験者 C では特に意識はしていなかったとのフィードバックを頂いた。これは図と脳波の生データを見ても明らかで、被験者 A では瞬きのような成分が見受けられないが、被験者 B, C ではそれぞれ IC4 と IC2 がそれにあたると考えられる。かつこれらの成分は多数の瞬間的なスパイクが主な変動であり、前頭葉よりに分布が集中していたため、これらの成分が瞬きに関連する成分と考えられる。確認のために、瞬きの時刻と実験中のビデオに記録された目の動きの時刻を比較すると、2 つの時刻が完全に一致していることを確認できた。これらの結果から、瞬きによる電位変化の特性と発生位置を把握できた。瞬きによる電位変化の特徴的な波形を図 7.8 に示し、瞬き成分と EEG 信号の関係と影響を図 7.9 に示す。

7.4.3 脳波の運動に関連する特徴成分の抽出結果および考察

前述したように、運動に直接関連すると考えられる脳波成分を選別した。次はこの成分から運動に関連する特徴を抽出する。被験者 A, B, C の試行回数はそれ

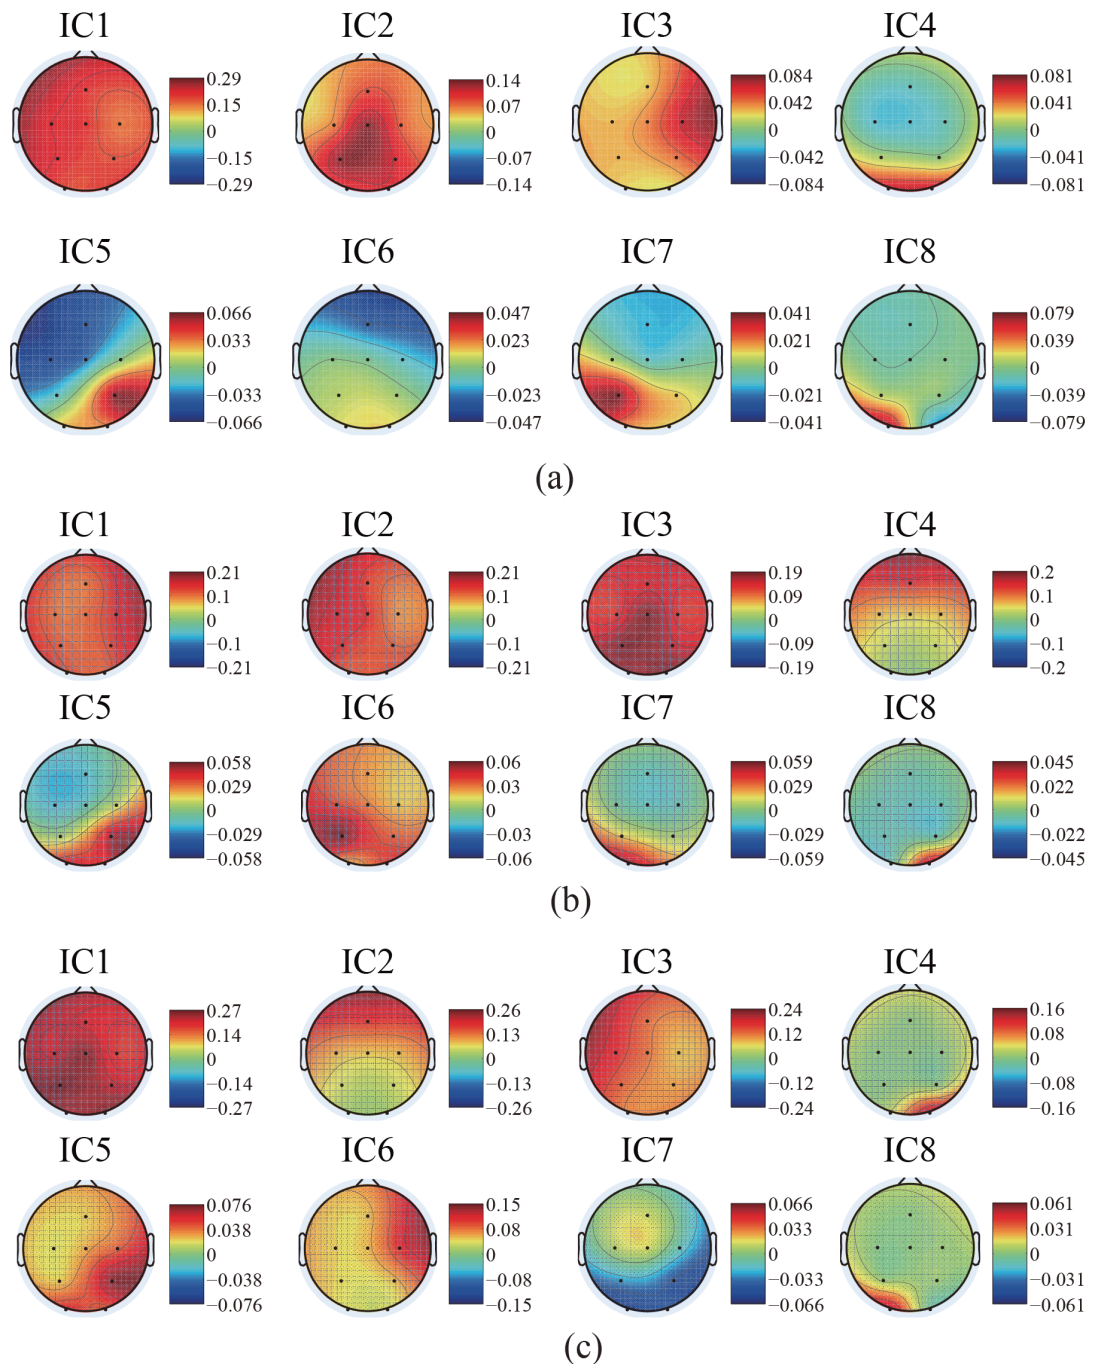


図 7.7: 被験者 A (a), B (b) および C (c) の各独立成分 (IC) の頭皮上の分布




図 7.8: ICA によって測定された EEG 信号から分解された瞬きによる電位変化の特徴的な波形.

それぞれ 68, 80, 61 である. 任意のタイミングで動作する随意運動であるため, 5 分間の動作回数は被験者毎に異なる. 加算平均法により運動に直接関連する脳波成分から抽出した特徴の結果を図 7.10 に示す. 被験者 3 人のこの特徴の傾向性と分布は非常に類似していることが分かった. さらに, 運動と伴う特徴信号の変化は 1 つのチャンネルではなく全てのチャンネルで観測された. つまり, この結果は人間が運動を行うとき, その運動に対する処理をある程度の脳領域で行うのではなく, 脳全体が協同して行う特性があることを意味しており, これは第 5 章で述べた考察と一致する. また, 左半球の特徴の振幅が右半球の振幅よりも大幅に大きいことが分かった. これは, 3 人の被験者が全員右利き, かつ右手での運動だったため,







図 7.9: 瞬き成分と EEG 信号間の関係と影響. 青い線は測定された EEG 信号であり, 赤い線は図 7.8 の瞬き成分である.



(a)



(b)



(c)

図 7.10: 被験者 A(a), B(b) および C(c) の運動に関連する脳波成分から抽出した各チャンネル毎の特徴.

脳の対側性の影響が波形に顕著に現れたのだと考えられる。

7.4.4 筋電と脳波の特徴との関係および考察

EEG 信号の特徴の変化の遷移を明確にするために、図 7.11 に示すように、100 ms 毎に脳波の運動に関する特徴信号の遷移図をプロットした。(a), (b), (c) はそれぞれ被験者 A, B, C の結果を指す。

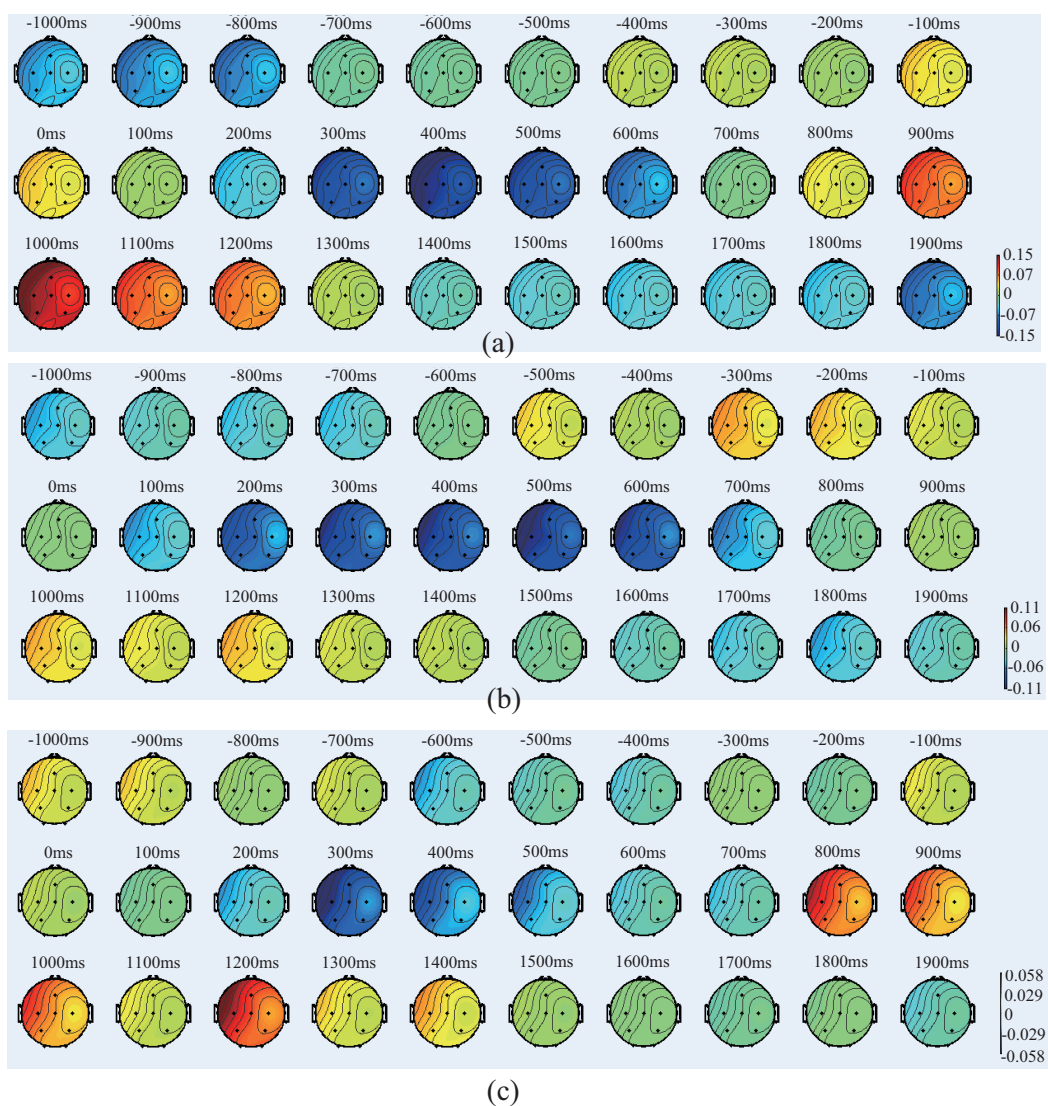


図 7.11: 脳波の運動に関する特徴信号の遷移図。

各被験者の 3 秒間のデータは動作開始を 0 秒として、-1~0 秒, 0~1 秒, 1~2 秒

に対応する3つの行に分割されている。図の色は、処理された EEG 信号の振幅を指す。図 (a) では、運動開始前の 400 ms あたりから運動開始時刻 0 秒まで EEG 信号は増加を続ける。その後、振幅は減少し、運動後の 400 ms の時点で負の最大振幅となる。その後また振幅は徐々に増加し、そして運動後の 1 秒の時点で正の最大振幅となる。被験者 B, C の場合も同様に、運動前の 300 ms から動作開始時刻 (0 秒) まで振幅が単調増加する。そして、被験者 B では運動後の 500 ms, C では 300 ms の時点で負の最大振幅を示し、それぞれ運動後 1100 ms, 1200 ms で正の最大振幅となる。

したがって、特徴信号は動作の 300-400 ms 前に増加し始め、その後動作の開始まで減衰し続ける。そして、動作後 300-500 ms ごろ負方向の最大振幅に到達してから、徐々に増加し、動作後 1-1.2 秒ごろに正方向の最大振幅に到達した。これらの結果から、まずは EMG 信号が生成される 300-400 ms 前に EEG 信号が変化し始めることを明らかにした。これで、脳波と筋電の時間上の順序関係は明らかになった。またこれらの変化に関して、運動前の変化は運動計画に関連している可能性が高く、運動後の変化は出力トルクの大きさの調整またはフィードバックに関連している者と推測できる。今後、そちらの変化の原理を究明していく。

7.5 まとめ

本章では独立成分分析を用いて肩関節の屈伸動作に関連する脳波信号の特徴を抽出し、動作に関する脳波の特徴の時間的変化の遷移を明確にした。筋電が生成される 300-400 ms 前に脳波が変化し始め、さらに脳の対側性の影響を受けていることを確認した。これらの結果により運動に対する処理は特定の脳領域のみで観測できるのではなく、脳全体で観測できる特性があることを示唆した。

第8章 特徴量の明確化を目的とした 脳の可塑性の検証と訓練の有 効性の検討

人間は誰しも「学ぶ」ことができる。これは、脳自身が生まれながらに持つ絶対的な能力であり、この「学ぶ」という過程で脳は変化を遂げ続ける。脳機能および構造は様々な学習と経験の刺激および遺伝的かつ環境的な要因に基づいて、その機能的な神経回路を形成する。このように、学習と経験により脳機能および構造が変化する現象は神経可塑性 (Neuro-plasticity) と呼ばれる。脳が情報を処理するとき、多くのニューロンが協調して発火するために、ニューロン間の生化学的な結合は強化され、新しいシナプス結合 (シナプスは2つの神経細胞間の接合部である) の形成、または既存のシナプス結合の作業効率の向上がなされる。この現象は、ヘップの法則と呼ばれている (Hebb's rule: fire together, wire together)。これは学習と記憶のコアメカニズムの1つであり、神経可塑性のメカニズムでもある。よく知られた例は、ロンドンのタクシー運転手の脳における機能的核磁気共鳴 (fMRI) の研究である [112]。この研究では、位置、空間、記憶などの能力を駆使するタクシードライバーの脳内の海馬体のサイズは、運転年齢に比例、つまりドライバーの運転経験が長くなるほど海馬体が大きくなるとの結論が出された。言い換えれば、タクシーを運転した経験は、タクシー運転手の脳に構造的な変化を引き起こしたということになる。しかしこの研究は、学習と経験が脳の構造を変えた後に確認されたため、脳の学習過程に関しては未だ不明点が多い。学習と経験が脳に入力された後に観察できる出力は言語と動作であり、この間に脳が入力

された情報に対して行われた処理と変化の過程は不明である。言い換えれば、これまでの学習は効率的な閉ループシステムではなかったといえる [113]。

脳イメージング技術の発展，神経科学の基礎研究および臨床研究の進展により，学習効率の促進や学習過程中的エラーの修正を目的として，人々は脳の学習および思考時に関連する神経信号を記録し，リアルタイムで脳に信号をフィードバックして学習させる閉ループシステムを構築する試みを始めた。これらの試みは，ニューロフィードバックと呼ばれる。ニューロフィードバック訓練の技術は，脳科学と行動科学の学習理論に基づいた脳機能と構造を解明するための非侵襲的な方法である。ニューロフィードバック訓練の技術を適切に用いることで，脳機能の改善，また脳疾患による脳機能障害が治療できる。臨床での応用が期待され，1968年にカリフォルニア大学ロサンゼルス校の Serman 教授はあるニューロフィードバック訓練を提案した。それは脳波に基づいたニューロフィードバック訓練で，主に δ 波から β 波 (1-40 Hz) の信号を用いて行われた。この訓練をきっかけに，ニューロフィードバック訓練の分野では多数の基礎研究と臨床試験が実施され，認知能力とタスクパフォーマンスの向上，さらには注意欠陥および多動性症候群など，自閉症の治療や認知老化の防止に関する多くの成果が得られた。

しかし，BMI に基づく運動制御の学習とフィードバックに関する研究と試みは非常に少ない。前章までで述べた主成分分析と独立成分分析の結果から，脳内のニューロンが協調作業を行う可能性を見出した。また，BMI 技術に基づく制御の場合，脳から外部の機械を制御する部分だけでなく，外部の機械から脳へのフィードバックする部分も考慮し，より良い性能を提供するための閉ループシステムを構築すべきだと考えられる。

したがって本章では，外部機械から脳へのフィードバックする観点から，BMI ユーザーに対し，ニューロフィードバック訓練を行い，脳の可塑性を検証する。また上肢動作における運動機能を訓練することで，運動時既存の，または訓練による新たに誘発された脳波の特徴を明確化し，抽出することを目的とする。最終的にこれらの特徴を用いて BMI システムのパフォーマンス向上を図る。

8.1 ニューロフィードバック訓練の原理と歴史

8.1.1 原理

ニューロフィードバック訓練手法は、神経科学と行動科学における3つの重要な発見に基づいている。ドイツの科学者ハンスベルガーが1924年に初めて記録した脳波、19世紀末にロシアのノーベル賞受賞者パブロフが提案した古典的条件付け理論、そして1938年にアメリカの行動主義者のスキナーによって提案された操作条件付け理論である。ニューロフィードバック訓練の流れは、脳波の自己調節（成功または失敗）にタイムリーなフィードバック/報酬を提供し、学習効果を形成することで、神経可塑性を通じて神経回路の接続と効率を改善または強化することである。具体的な方法は、特定の機能に関連する脳神経活動を測定し、特定の訓練手段（視覚的、聴覚的、触覚的など）によりリアルタイムで測定結果を訓練者にフィードバックすることである。この方式はある訓練手段（報酬メカニズム）を通して、訓練者がターゲットとする脳の神経活動の自己調節と改善を学習することに役立つ。またターゲットとする脳神経活動の改善により、それに対応する脳機能が改善または強化される。つまり、ニューロフィードバック訓練は脳機能を強化するツールであるといえる。

8.1.2 歴史

1968年、ニューロフィードバック訓練の先駆者であるSerman教授はカリフォルニア大学ロサンゼルス校（UCLA）医学部の実験室でネコの大脳皮質に記録電極を埋め込み、ボタンを押すとスナック餌という報酬が得られるように訓練した。その後、音の要素を導入した、音が鳴っている間にネコがレバーを押すと何も起こらず、レバーを押す前に音が止まるのを待つとスナックが得られると認識するように訓練した。その結果、Sermanは音が止まるまですべてのネコが極度に集中した状態になり、完全に静止かつ非常に警戒している状態になることを発見した。またネコが聴覚の刺激の後レバーを押すと報酬が得られることを学習した。この

行動の特異性はネコの脳波にも反映され、音が止まるのを待っている間に、ネコの脳の感覚運動皮質において、12 Hz から 15 Hz の脳波成分の記録ができた。現在それは感覚運動リズム (Sensorimotor Rhythm: SMR) と呼ばれており、多角的に解析が続けられている。

次に、彼らはニューロフィードバック訓練の分野で最も重要な実験を実施した。この実験では、ネコは脳が強い SMR 波を生成した場合にのみスナックの報酬を得ることができる環境を構築した。つまり、体は静止した状態で脳の SMR 波が閾値に達しない場合、スナックの報酬を得ることができない。しかしながら 2-4 週間の訓練の後、ネコは SMR を自己調節することで報酬を得ることができるというシステムを学習した。即ち「報酬が得られる」と「報酬が得られない」という 2 つのフィードバック信号を通じて、報酬を得るために SMR 波を調節するというスキルを身につけた。この研究成果は 1970 年に Science 誌に掲載され、ネコに関するこれらの発見はすぐにサルで再現された。さらに、他の研究では、動物と人間の両方が単細胞の神経活動と脳波の特定の帯域を自己調節できる能力を備えていることを発見した [113]。たとえば、ラットは聴覚フィードバックを通じて神経細胞のカルシウムイオンの活動を自主的に調節することができる（神経細胞の間では主にカルシウム、ナトリウム、塩素、その他のイオンの流れによって信号が伝達され、神経インパルスと脳波の変化を生成する）[114]。また報酬課題を通じて、ラットは運動皮質内の特定のニューロンの放電頻度を増加させ、周辺のニューロンの活動を減少させることも可能である [115,116]。他にも、片麻痺患者が脳の一次運動野皮質の活動を変化させることにより、ロボットアームやコンピューターマウスなどの外部機器を制御できることが既に結果として証明されている [117-119]。

これまで紹介した研究は、すべて侵襲的な手法に基づく実験結果である。このような侵襲型の研究は、神経フィードバックと BMI 技術の科学的な原理を研究するために広く行われている。

8.2 一般健常者におけるニューロフィードバック訓練の有効性

前節では主にラットやネコをはじめとする動物に対するニューロフィードバック訓練の成果を述べた。本節では、対象を一般健常者として行われた研究成果についてまとめる。ニューロフィードバック訓練における人間の認知能力および感情調節の改善における有効性は、さまざまな国の研究者による多くの研究によって証明されている。

1. 1990年代に、NASA (The National Aeronautics and Space Administration) の研究者である Alan Pope は、宇宙飛行士の仕事の効率を改善するために脳波ニューロフィードバック訓練を始めた。
2. 2002年に発表された結果では、偽のフィードバックをプラセボ対照群として使用し、 α 、 β 、および θ 波に基づくニューロフィードバック訓練を使用する訓練グループが優れたパフォーマンスを得られ、認知的負担がより低いことが分かった [120]。
3. イギリスでの2004年の研究では、SMRベースのニューロフィードバック訓練が知覚感度を向上できる一方で、 β 波のフィードバック訓練が注意力と応答速度を向上させられることが分かった [121]。
4. ドイツの研究者は、より厳密な対照群を設計した実験で、SMR訓練が応答速度と視覚処理能力を改善できることを発見した [122]。
5. また、同じく厳密な偽フィードバック対照群を使用した台湾の研究では、前頭葉の θ 波に対するフィードバック訓練により、高齢者の注意力と作業記憶が改善され、若者では脳の実行機能の改善ができることが判明した [123]。
6. MRI スキャンにより、前額葉-頭頂葉で β 波によるニューロフィードバック訓練を行ってから1週間後、脳の灰白質量が増加し、白質経路の接続性が増

加したことが示された [124].

7. Megumi らは、ニューロフィードバック訓練を通じて頭頂外側皮質 (Lateral parietal Cortex) と一次運動皮質の間に新しい機能的な接続を形成されることを示唆した。またこの接続は少なくとも2か月間維持できることを発見した (いわゆる機能的な接続は、同じタスクを実行中、異なる脳領域によって形成される同時変化で協同で働くネットワークを指す) [125].
8. プラセボ対照群を用いた前頭葉での β 波神経フィードバック訓練に関する研究では、 β 波の変化が少なくとも3年間維持されていることが分かった [126]. 大規模なサンプル (N = 523) に基づく研究では、成人は脳波強度の自己調節能力を約1分間で学習できることが分かった [127].

ニューロフィードバック訓練による脳全体のレベルでの神経可塑性は、脳の機能的結合の変化として現れる。Ros らは、EEG ニューロフィードバック訓練を使用して α 波を低減し、偽フィードバック対照グループと比較すると、30分間の訓練により、脳の salience network 内の機能的な接続を増加し、脳のデフォルトモードのネットワーク DMN 内の機能的な接続を削減し、タスクを実行する際に被験者の集中力が大幅に向上したと報告した [128]. さらに、別の脳源定位法を使用した研究では、ニューロフィードバック訓練グループは、偽フィードバック対照グループと比較すると、左脳の言語領域の活性化レベルを高めることに成功した [129].

ニューロフィードバック訓練には、複数の脳領域が含まれる。Emmert らは2016年に12個のfMRIの研究を分析し、ニューロフィードバック訓練に関与する脳領域には、前島皮質 (Anterior Insular Cortex: AIC), 前部帯状回 (Anterior Cingulate Cortex: ACC), 前頭前皮質背外側部 (DorsoLateral Prefrontal Cortex: dlPFC), 前頭前皮質腹部, (Inferior Parietal Lobe: IPL), 大脳基底核 (Basal Ganglia), 視床 (Thalamus) が含まれることを発見した。

1. 前頭前皮質は、ニューロフィードバック訓練でとても重要な役割を果たしていた [130].

2. またニューロフィードバック報酬処理, 制御, および学習ネットワークに関して, フィードバックが視覚的に提示されるときに, 一般的な神経フィードバック中に, AIC, dlPFC, ACC および PPC (Posterior Parietal Cortex) が活発な状態になる [131].
3. 視覚フィードバックの場合, 信号への注意は LOC (Lateral Occipital Complex) によって支配される.
4. dlPFC と PPC はタスクの実行に関与している.
5. ACC と AIC は Salience ネットワークの一部を形成し, フィードバックと報酬の意識的な認識に関与している.
6. DS はニューロフィードバック学習に関与されている.
7. 無意識の報酬処理には, VS が含まれる.

そのため, これらの結果は, ニューロフィードバックには報酬処理ネットワーク (ACC, AIC, および VS を含む), 制御ネットワーク (LOC, dlPFC, PPC, および視床を含む), および学習ネットワーク (DS) が含まれることを示唆している.

8.3 脳波ニューロフィードバック訓練の利点

現在、脳波に基づくニューロフィードバック訓練は臨床診療で広く使用されている唯一の訓練方法であり、他の手法はまだ研究段階にある。そのようなニューロフィードバック訓練技術と比較すると、脳波には顕著な利点が存在する。まず、脳波の時間分解能はすべての非侵襲的記録法の中で最もよく、約1ミリ秒に達するため、脳の電氣的活動がリアルタイムで記録できる。fMRIおよびNIRSで計測される血液動態は神経活動の代謝を反映しており、その信号は比較的遅く、対応する血液中の酸素量はタスク開始後約5秒で変化のピークに達する。さらに重要なことは、脳波信号はシナプス周辺の電位の変化により生成されるため、シナプス活動の直接的な記録だといえる [132]。かつシナプス活動の変化は学習と記憶の最も基本的なメカニズムである [133]。そのため、脳波は認知能力の変化（訓練や介入による向上、または疾患による損傷）の測定・評価をする多く手法の中で最も感度の高い方法である [134, 135]。

一方、fMRIやMEGは大きな装置を専用の実験室に置くことしかできず、多くの教育、家庭の場面などで使用できない。一方で携帯式かつ装着型のEEG装置はすでに商品化され、信頼性と利便性が向上し、コストも大幅に低下した。これにより、従来のニューロフィードバック訓練の時間と費用を大幅に減少できる。人工智能に支えられた精密医療の時代において、大量の科学的証拠に基づく安全で非侵襲的な脳神経訓練の脳情報として、脳波は間違いなく、より効果的になるものだと考えられる。

本来脳における肘と肩の対応領域は非常に狭く、密接している。さらに肩の単関節動作は日常ではあまり使わない運動と言うこともあり、特徴的な成分が出にくい。そのため、本章では上記の理論に基づいて、脳波によるニューロフィードバック訓練の概念をBMIに基づく上肢のパワーアシストシステムに導入する。具体的には、運動に伴う脳波の変化を視覚的情報に変換して、被験者にフィードバックすることで、運動時既存の、または訓練による新たに誘発された脳波の特徴を明確化した上で抽出する。

8.4 実験内容

8.4.1 計測部位

視覚フィードバックの場合、信号への注意喚起はLOC（後頭部）、運動タスクの実行はdlPFCとPPC（前頭部と頭頂部）によって行われている。またACC（前頭部）はsalience networkの一部を形成し、フィードバックと報酬の意識的な認識に関与している。このように、随意運動の訓練では前頭葉から後頭葉までの全ての領域におけるニューロンの集団が連携して各処理を行っているため、脳波の計測点もこれらの領域を覆うように設計すべきである。ただし、前部に近いほど眼電位の影響を受けやすく、被験者には常に瞬きをしないように意識させる必要があるため、極力避けるべきである。よって、前述したニューロフィードバックと関連部位と運動との関連部位を踏まえて考慮し、本実験での計測点はFC1, FC2, C3, C4, CP1, CP2, Cz, Pzの計8箇所とした。グラウンド(GND)は被験者の右耳の乳様突起上にディスク電極を用い、レファレンス(REF)は左の耳朶にクリップ型電極を用いた。なお、脳波計のサンプリング周波数は1000 Hzとした。今回の訓練では筋電の計測部位は二関節筋である上腕二頭筋を計測部位とした。なお、筋電計のサンプリング周波数は1000 Hzとした。

今回運動に関連ある脳波成分を増強させるため、視覚フィードバック(Visual-Feedback: VF)を用いた訓練を行う。計測された脳波データをシリアル通信で(通信のボーレートは115200 bps)外部のノートパソコンに送信する。そのパソコン上のProcessingでは常にロボットアームが描写されており、運動と関連が強いとされている α 帯域のパワーの大きさに応じて肘もしくは肩が屈伸するようになっている。被験者はその屈曲角度が自身の運動とリンクするように意識することで、それぞれの運動に関連する成分の増減を図る。図8.1は本実験における計測環境である。

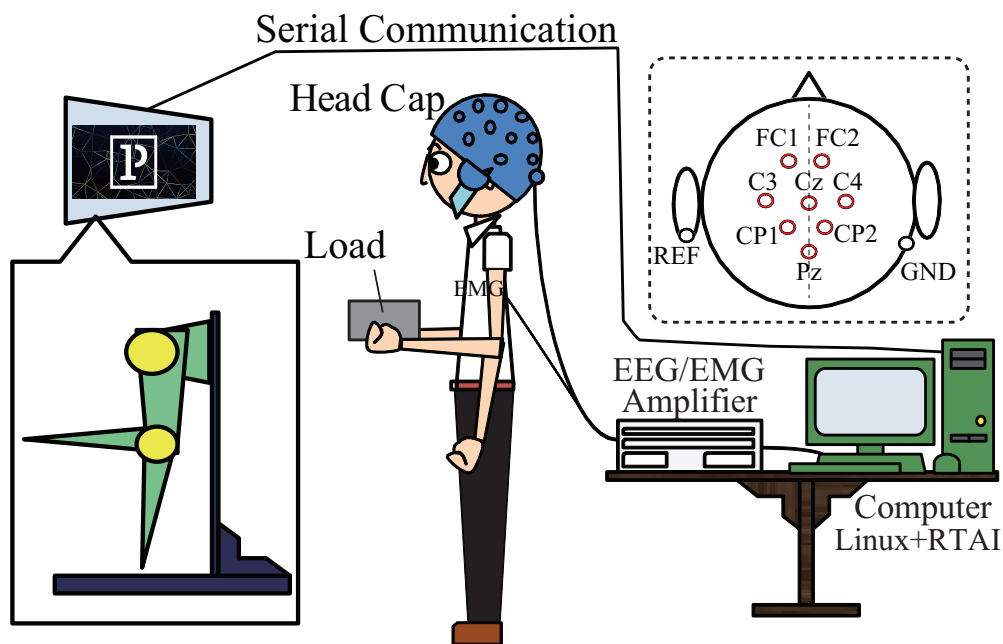


図 8.1: 訓練の実験環境

8.4.2 実験タスク

被験者は直立姿勢かつ肘および肩の力を抜いた状態で約 1 m 先のモニタを注視する。なお、用いる荷物の外観および重量に関する情報は一切与えない工夫を施した。また、本実験では動作開始のタイミングは被験者に一任させた。ただし、連続での動作や筋肉疲労の防止を目的として、動作終了後は最低でも 3 秒ほど一定の時間を設けるように指示した。加えてまばたきや姿勢調整をはじめとする体動はこの時間で行ってもらった。動作の総試行回数は肘と肩の屈伸動作それぞれ 40 回で、何回動作を行ったかは Processing 上に表示した。なお、屈伸角度は 90°とした。

8.5 処理手法

本実験では随意運動に伴う脳波の変動を観察したいため、被験者の動作開始時刻に合わせた解析が必要となる。そこで荷物の底部にスイッチを取り付け、荷物が置き台から離れた時刻(スイッチの出力が切り替わった時刻)を動作開始時刻(0秒)とみなし、その2秒前から3秒後までの計5秒間を解析範囲としてデータを分割した。その分割されたデータに対し独立成分分析を行い、8個の独立成分を求めた。そしてこれらの独立成分に対してフィルタを介し、各周波数帯域(δ (1-4 Hz), θ (4-7 Hz), α (7-13 Hz), β (13-40 Hz))の成分を算出した。最後に、総試行回数である40回の加算平均を施し、その波形から傾向性を調査した。図8.2に一連の処理を示した図を示す。

なお付録にて、生データに対するハイパスフィルタの有無やデータの分割とICAの処理順番の違いによる影響に関して検討を行っているため、参照していただきたい。




図 8.2: 信号処理の流れ

8.6 実験結果および考察

8.6.1 各周波数帯域の結果

訓練による特徴の周波数帯域の特性を明確にするため、運動に関連する成分の各周波数帯域のデータを抽出した。結果を図 8.3 に示す。なお、これらのデータは既に加算平均されたものである。横軸は時間であり、縦軸は振幅である。各チャンネルのデータを色付きで全て表示している。

この結果を見ると、チャンネル毎の波形は類似していることが分かる。特に δ 波の変動は特徴的で、運動前に振幅は減少し、その後は増加している。 θ 波に関しては、運動前後でリズムが変わっており、運動前は θ 波の中でも低周波、運動後は高周波が主な成分となっている。また、動作後は振幅が減衰していることも見てとれる。 α 波に関しては、運動の直前に振幅が減少し、運動後に振幅が増加している。 β 波に関しては、この手法により特徴的な変動は見られていない。以上より、特徴成分は 13 Hz までの帯域に見られやすいことから、遮断周波数は 13 Hz のローパスフィルタによって特徴の抽出ができるものと考えられた。13 Hz のローパスフィルタにより抽出された各チャンネルのデータの平均値を図 8.4 に示す。この結果を見ると、訓練による運動開始に関する特徴の変動は平均として -0.05 mV から 0.06 mV まで上昇することが分かった。





図 8.3: 運動と関連成分の各チャンネルの各周波数帯域の波形

図 8.4: 運動に関連する成分 (δ , θ , α 帯域の平均値)

8.6.2 訓練による効果

被験者は2名であり，計7日間訓練を行った．その間に得られた肘と肩動作のデータから算出された八個の独立成分の脳地図，各試行の波形の変化傾向性，周波数特性（全て672個評価項目）を確認し，運動に関連する成分を判断し，特定した．結果について，次の各節にまとめた．

8.6.2.1 肘関節の特徴

まずは肘動作を行った際の特徴の変化について述べる．訓練日毎の独立成分の加算平均をした結果（上部）と成分の脳地図（下部）を図8.5に示す．

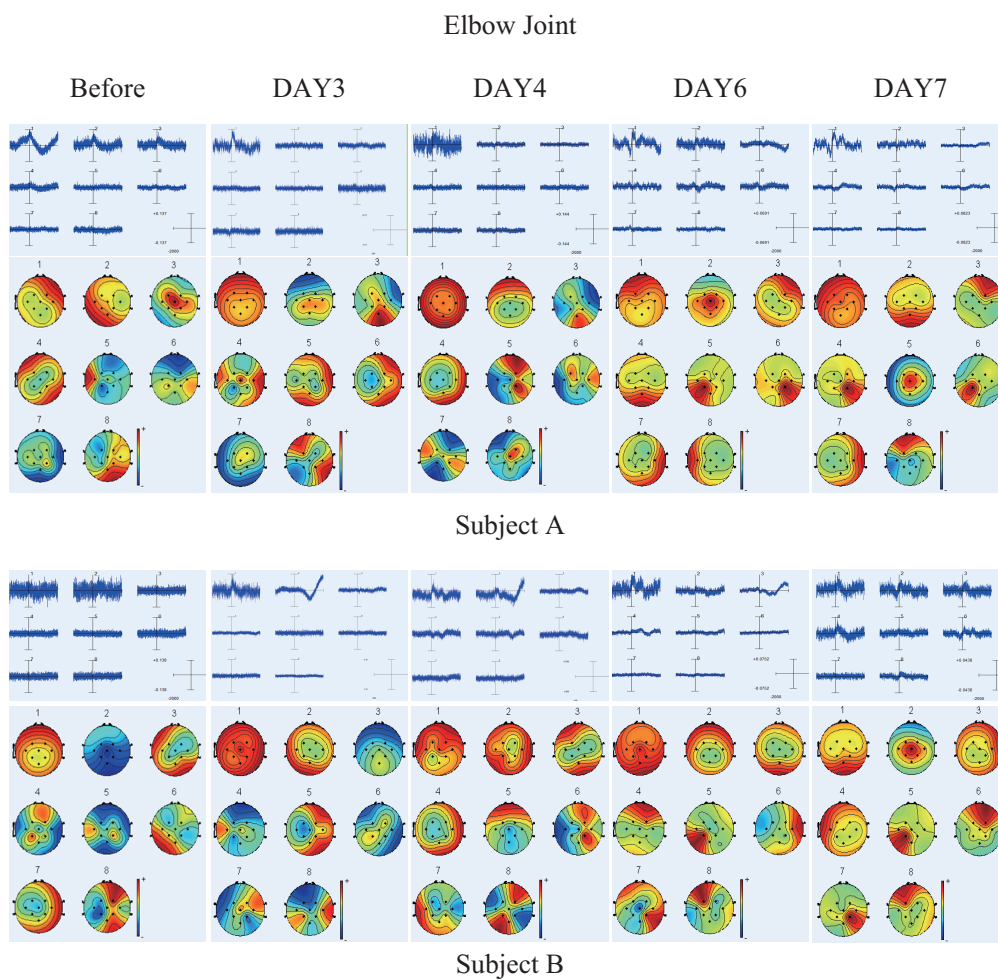


図 8.5: 被験者 A と B の肘関節の異なる訓練日の独立成分の結果

これらの結果を見ると、二名とも訓練により特徴成分が少しずつ明瞭になり、波形も特徴が見られるようになる傾向になってくることが分かった。同時に、一つの特徴成分だけではなく、他の特徴的な波形や成分も現れた。即ち、訓練を継続するにつれ、脳波の中に運動に関連する成分は増強され、特徴と見受ける成分が増えてくることが分かった。

より分かりやすく見るために、被験者 A と B の特徴的な独立成分の脳地図（上部左側）、各試行の脳波（上部右側）、周波数領域の分布（中央）、と加算平均のデータ（下部）を図 8.6 と 8.7 にまとめた。

1. 特徴成分の各試行の脳波波形を見ると、屈曲動作における毎回同じ変化が起こっている、すなわち特徴の再現性があるため、これらの成分は肘の屈曲動作の特徴成分と言える。
2. 訓練により、肘関節の屈曲動作の直前に変化する脳波の成分は明らかになった（被験者 A : IC1, IC5 ; 被験者 B : IC2, IC6, IC8）。この成分の動作直前に振幅が減少する傾向が見受けられるが、訓練を受ける前のデータではそれが分かりにくい。訓練を行ったことで成分が増強し、七日目ではその特徴がはっきり見えるようになった。
3. さらに、動作前や動作が始まってからや動作終了後における特徴的な成分を表 8.1 にまとめた。これらの成分を用いて、肘の屈曲動作の検知ができれば、強度の推定を行うことにより、最終的には脳波から肘動作の再現ができると考えられる。

表 8.1: 肘動作に関連する成分（七日目）

被験者	動作前	動作中	動作後
A	IC1, IC5	IC1, IC4, IC6	IC1, IC4, IC6
B	IC2, IC6, IC8	IC1, IC2, IC4	IC2, IC4, IC6

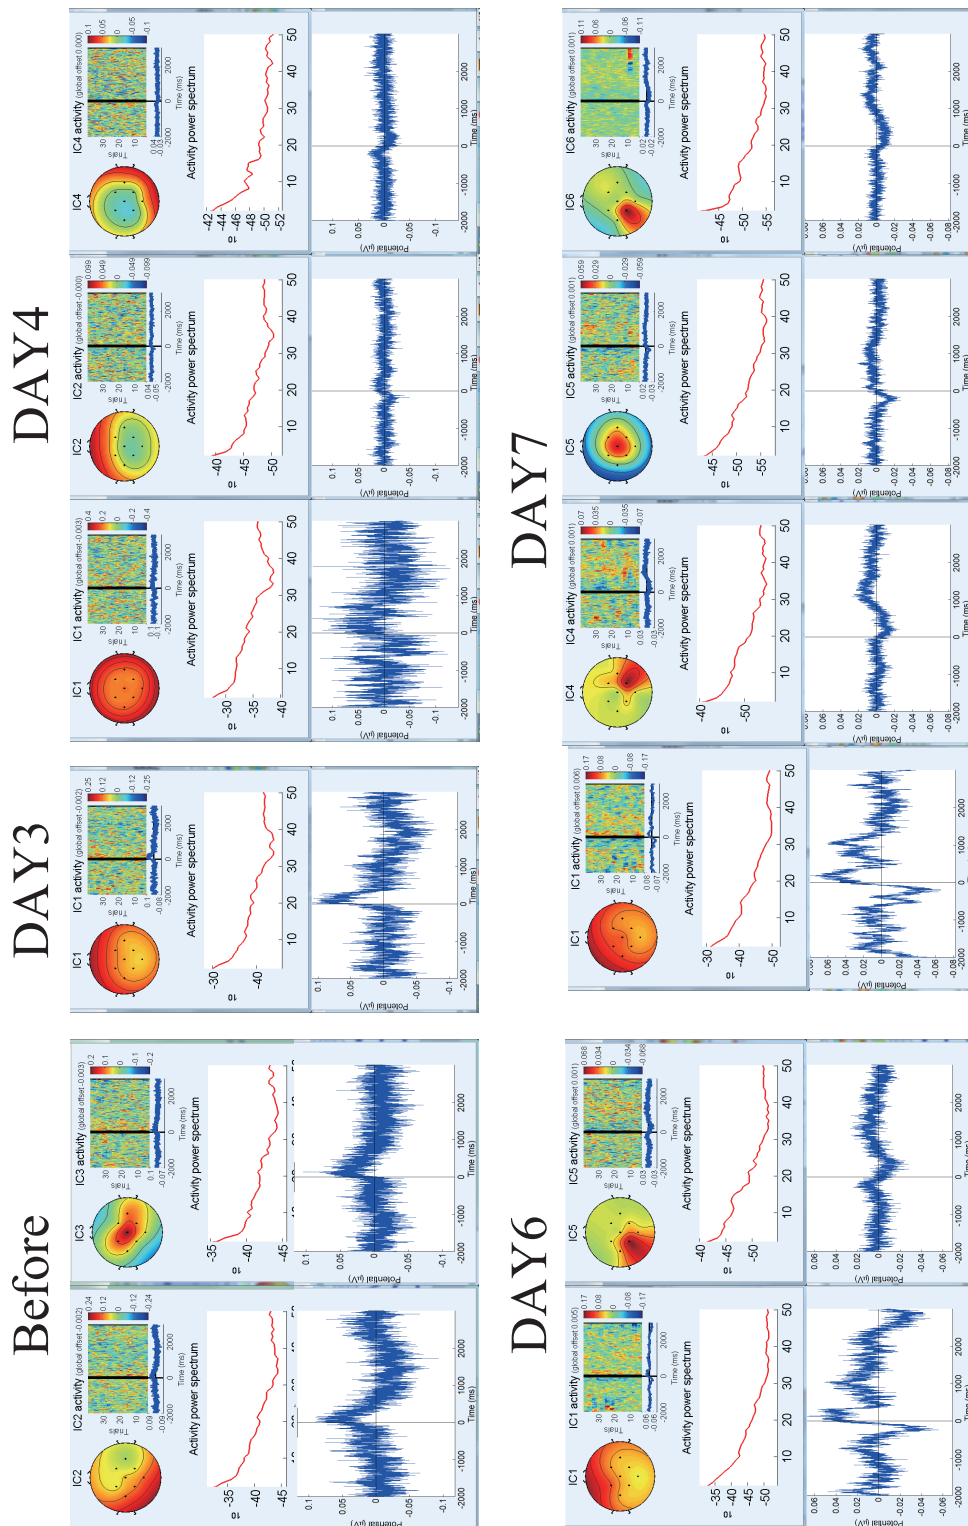
4. また肩関節動作の訓練により、被験者が異なっても、非常に類似している特

徴があることも分かった。例えば，表 8.2 にて 7 日目の結果に関して被験者 A も B も同じまたは類似な成分（波形の変化の傾向性や頭皮上の分布が一致している成分）が観測できた。そのため，肘関節の動作の特徴は，訓練によるより安定に誘発できることが分かった。

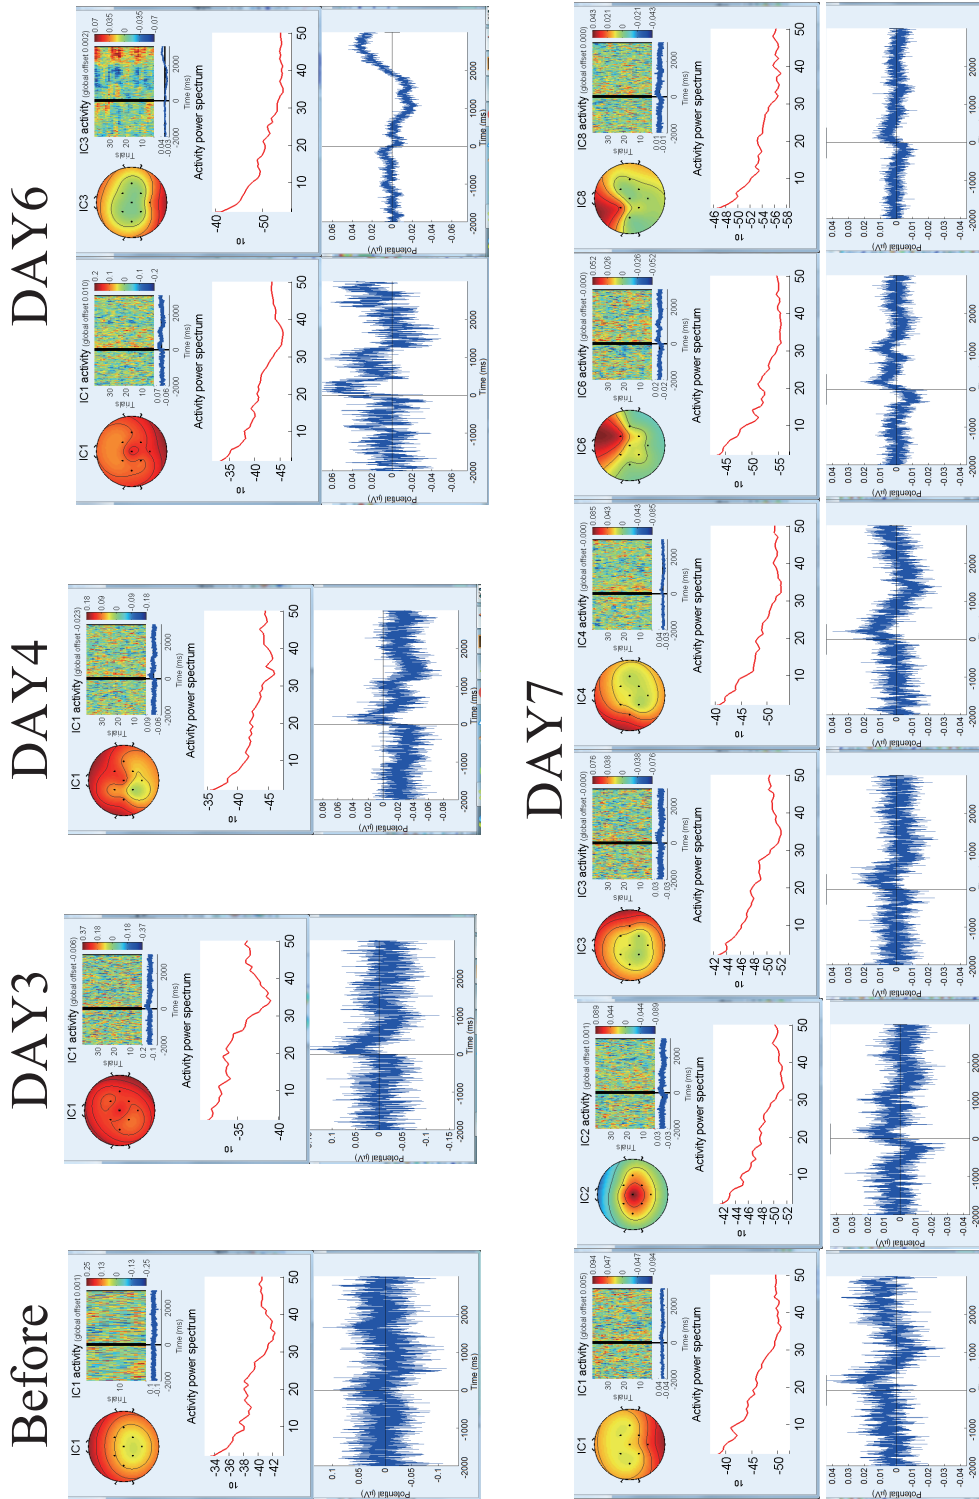
表 8.2: 肘動作際の類似な成分（七日目）

被験者	類似な成分	
A	IC1	IC5
B	IC1	IC2

以上の結果より，肘関節に対して訓練の効果があると言える。



Subject A Elbow Joint
 図 8.6: 肘動作時の特徴的な成分の変化 (被験者 A)



Subject B Elbow Joint
 図 8.7: 肘動作時の特徴的な成分の変化 (被験者 B)

8.6.2.2 肩関節の特徴

肩関節の考察は肘関節の考え方と同様で、これから示す図 8.8～図 8.10 も先程と見方は同じである。これらの結果を見ると、

1. 二名とも訓練により肩関節動作時の特徴成分が少しずつ明瞭になり、波形も特徴が見られるようになる傾向になってくることが分かった。
2. 同時に、一つの特徴成分だけではなく、他の特徴的な波形や成分も現れた。即ち、訓練を継続するにつれ、脳波の中に運動に関連する成分は増強され、特徴と見受ける成分が増えてくることが分かった。
3. 特徴成分の各試行の脳波波形を見ると、屈曲動作における毎回同じ変化が起こっている、すなわち特徴の再現性があるため、これらの成分は肩の屈曲動作の特徴成分と言える。
4. 訓練により、肩関節の屈曲動作の直前に変化する脳波の成分は明らかになった（被験者 A:IC1, IC6；被験者 B:IC1, IC6）。この成分の動作直前に振幅が減少する傾向が見受けられるが、訓練を受ける前のデータではそれがとても分かりにくい。訓練を行ったことで成分が増強し、七日目ではその特徴がはっきり見えるようになった。
5. さらに、動作前や動作が始まってからや動作終了後における特徴的な成分を表 8.3 にまとめた。

表 8.3: 肩動作に関連する成分（七日目）

被験者	動作前	動作中	動作後
A	IC1, IC6	IC1, IC4, IC5	IC1, IC4, IC5, IC6, IC7
B	IC1, IC7	IC1, IC3, IC5, IC6,	IC3, IC5, IC6, IC7

これらの成分を用いて、肩関節の屈曲動作の検知ができれば、強度の推定を行うことにより、脳波から肩の屈伸動作の再現ができると考えられる。

6. 肩関節動作の訓練により，被験者が異なっても，非常に類似している特徴があることも分かった．例えば，表 8.4 にて 7 日目の結果に関して被験者 A も B も同じまたは類似な成分（波形の変化の傾向性や頭皮上の分布が一致している成分）が観測できた．そのため，肩関節の動作の特徴は，訓練によるより安定に誘発できることが分かった．またここで，被験者 A より被験者 B の変化の振幅が小さいことにより，個人差があることも明らかにした．

表 8.4: 肩動作際の類似な成分（七日目）

被験者	類似な成分	
A	IC7	IC4
B	IC5	IC7

以上の結果より，肩関節に対して訓練の効果があると言える．

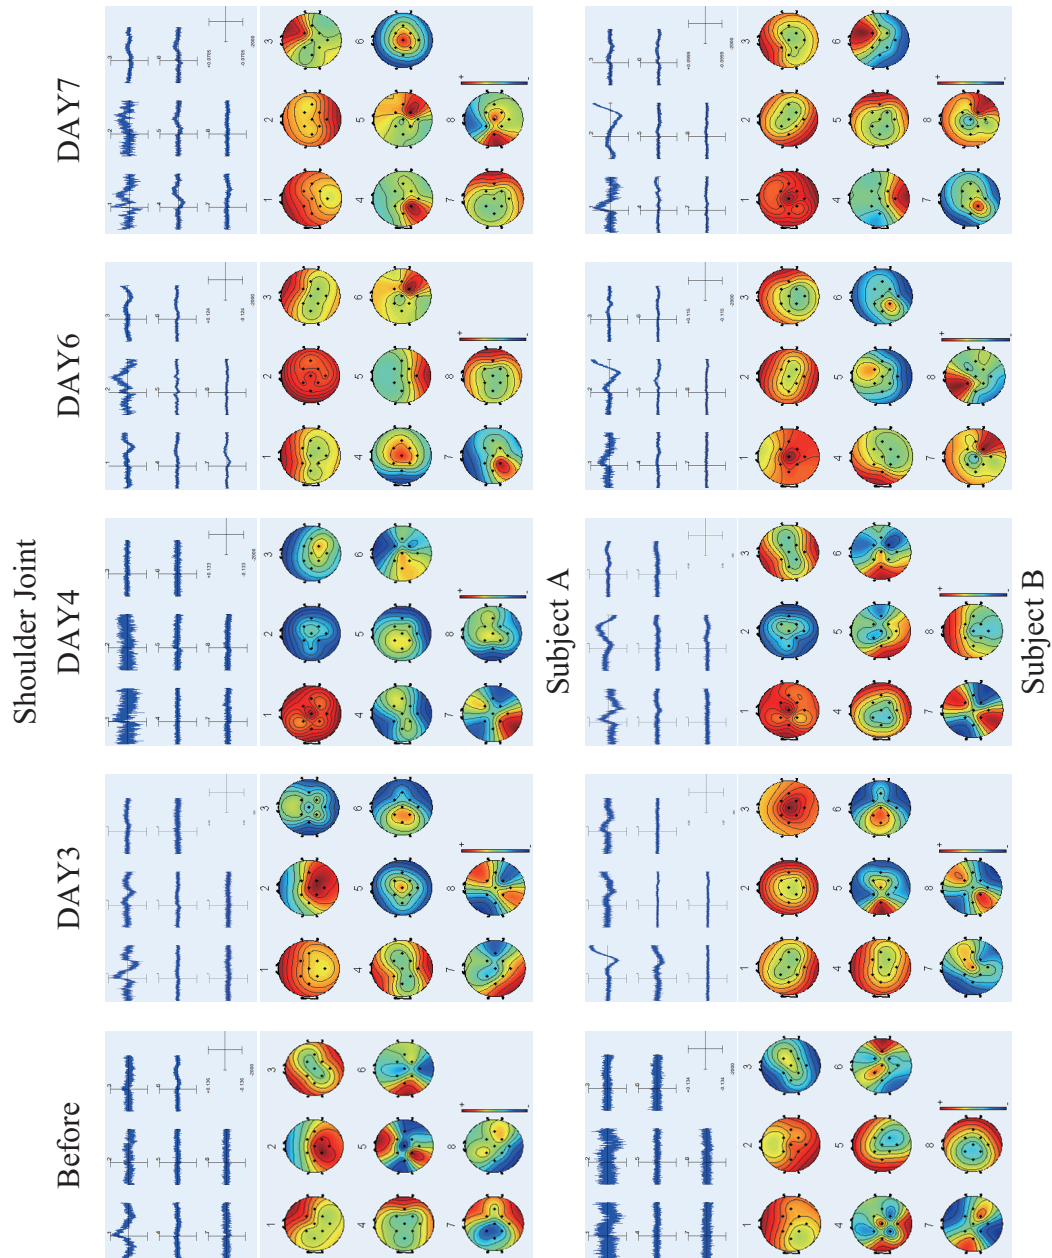


図 8.8: 被験者 A と B の肩関節の異なる訓練日の独立成分の結果

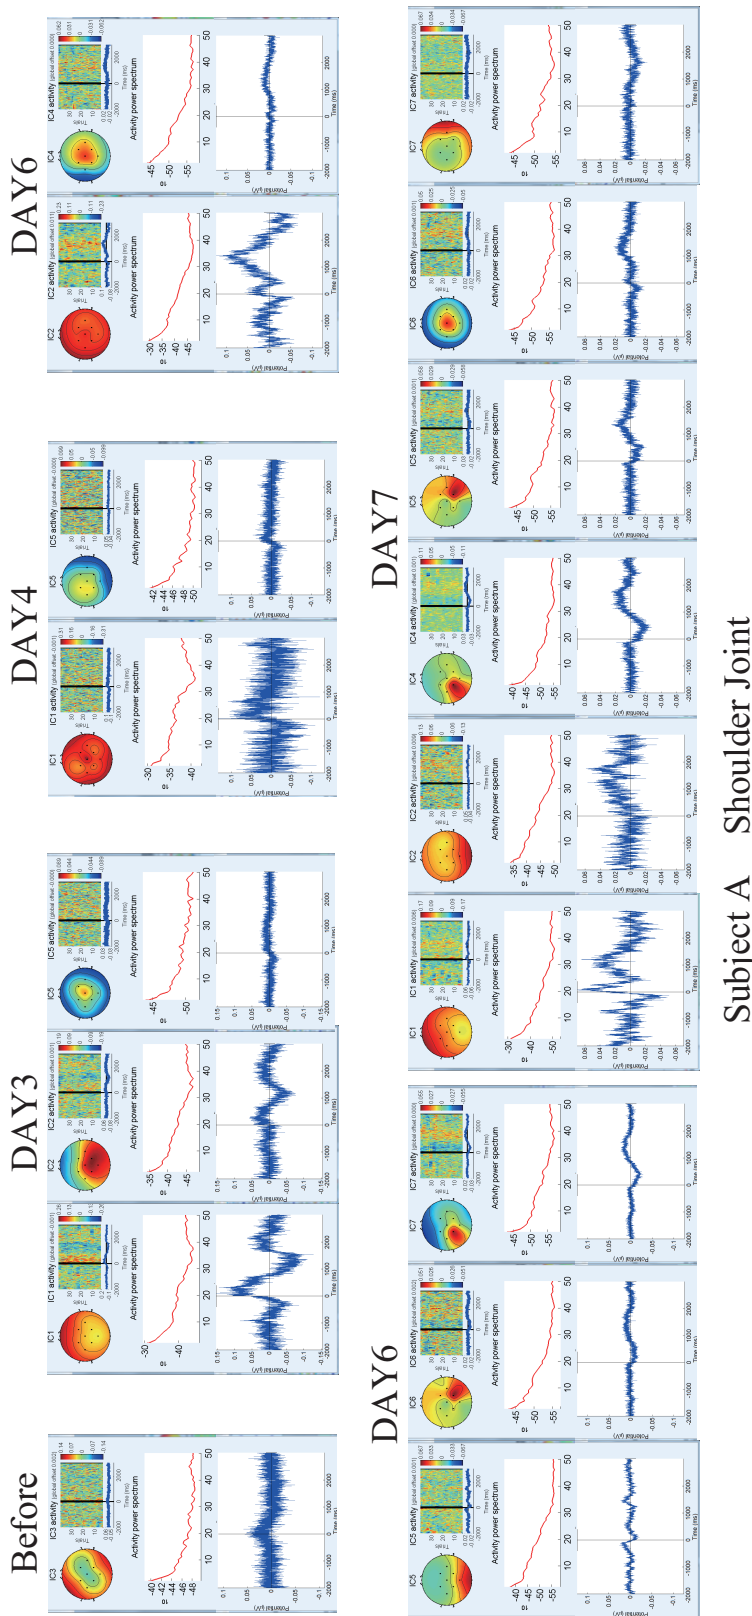
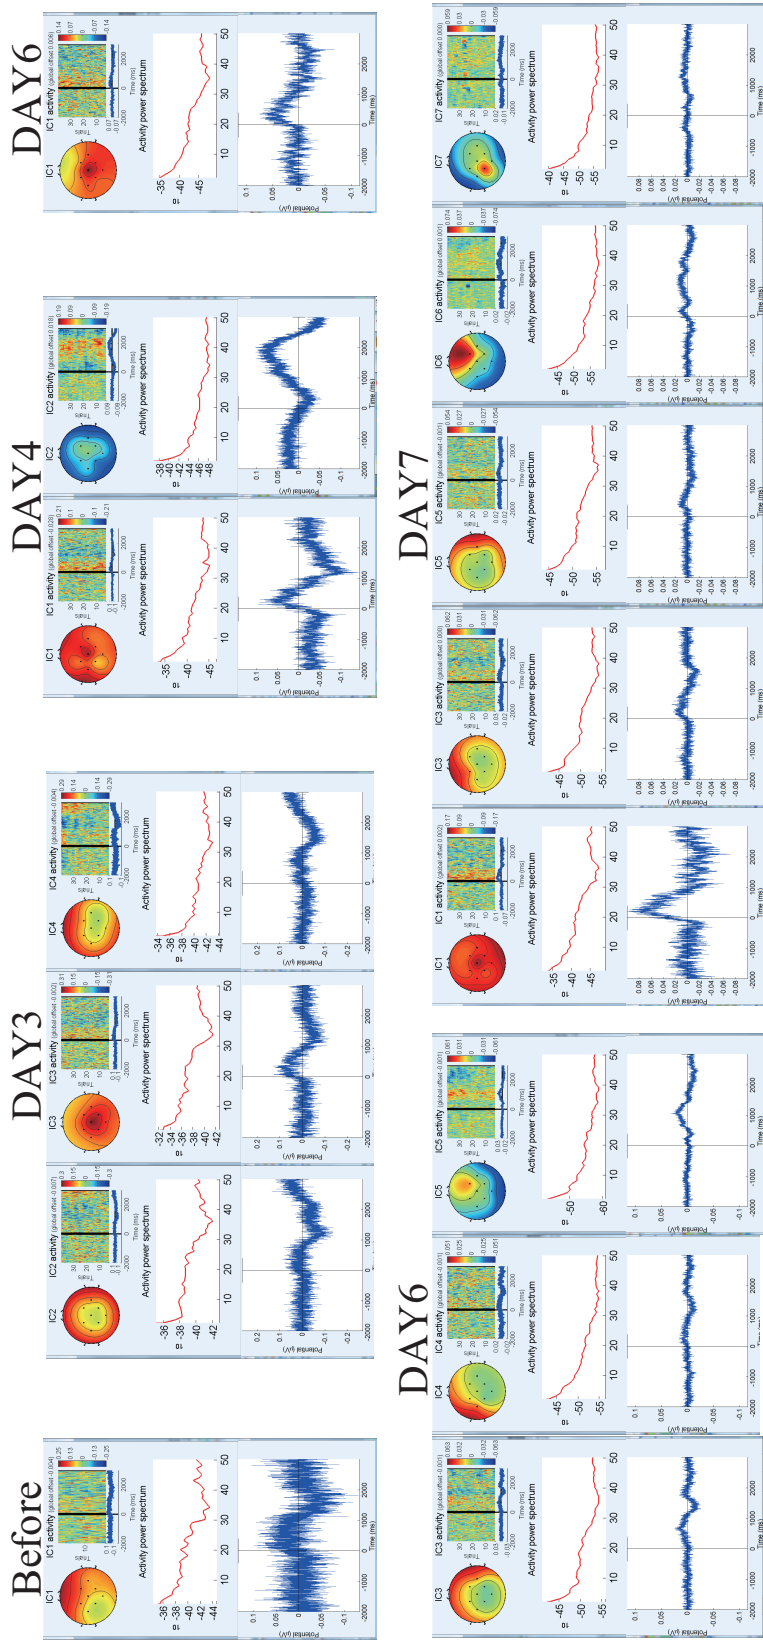


図 8.9: 被験者 A の肩関節の異なる訓練日の特徴的な成分の結果



Subject B Shoulder Joint

図 8.10: 被験者 B の肩関節の異なる訓練日の特徴的な成分の結果

8.6.2.3 肘と肩関節の特徴の比較

次は被験者毎の肘と肩関節の運動時の特徴について述べる。被験者 A と B の肘と肩関節の異なる訓練日の独立成分の加算平均の結果を図 8.11 に示している。この結果から訓練によって肘関節も肩関節も運動時の変化の特徴が明瞭になることが分かった。

また、被験者 A と B の訓練の最終日における肘と肩動作時の際に特徴的な独立成分の脳地図（上部左側）、各試行の脳波のデータ（上部右側）、独立成分の周波数領域の分布（中央）、加算平均後の波形（下部）を図 8.12 と 8.13 にまとめた。

まずは被験者 A のデータを確認すると、肘と肩の屈曲動作に対して、類似した成分があることが分かった。例えば、表 8.5 に示したような肘の IC1 と肩の IC1、肘の IC4 と肩の IC5、肘の IC5 と肩の IC6、肘の IC6 と肩の IC4 である。これらの成分は波形も似ており、その成分の頭皮上の分布に関しては一致していることが分かった。

表 8.5: 被験者 A の肘と肩の屈曲動作時の類似した成分

肘動作	IC1	IC4	IC5	IC6
肩動作	IC1	IC5	IC6	IC4

同様に、被験者 B の場合にも類似した成分があることが分かった。例えば、表 8.6 に示したような肘の IC1&IC2 と肩の IC1、肘の IC3 と肩の IC5、肘の IC4 と肩の IC3、肘の IC6 と肩の IC6 である。これらの成分は波形も似ており、その成分の頭皮上の分布も一致していることが分かった。これらのデータと実験タスクを踏まえて考えると、これらの共通の成分は屈曲動作の指令信号だと考えられる。

表 8.6: 被験者 B の肘と肩の屈曲動作時の類似した成分

肘動作	IC1, IC2	IC3	IC4	IC6
肩動作	IC1	IC5	IC3	IC6

肘と肩関節の連動を実現するため、各関節それぞれの特有的な成分を抽出すべきである。そこで、肘と肩関節動作時生じた異なる成分を注目する。そして、肩動作の方では運動の1秒後に変化する成分（被験者Aの場合はIC2，被験者Bの場合はIC7）が見られた。このような変化は、肘関節運動時に観測できなかった。この成分の特徴として、まずは発生時間は全部運動開始の1秒後の時点であり、観測できた領域に関しては被験者A被験者Bの二名でPzとCP1をはじめとする後頭部であることが分かった。この場所はホムンクルスのヒトの一次運動野における体部位局在の地図の肩関節の所属部位と一致していることが分かった。


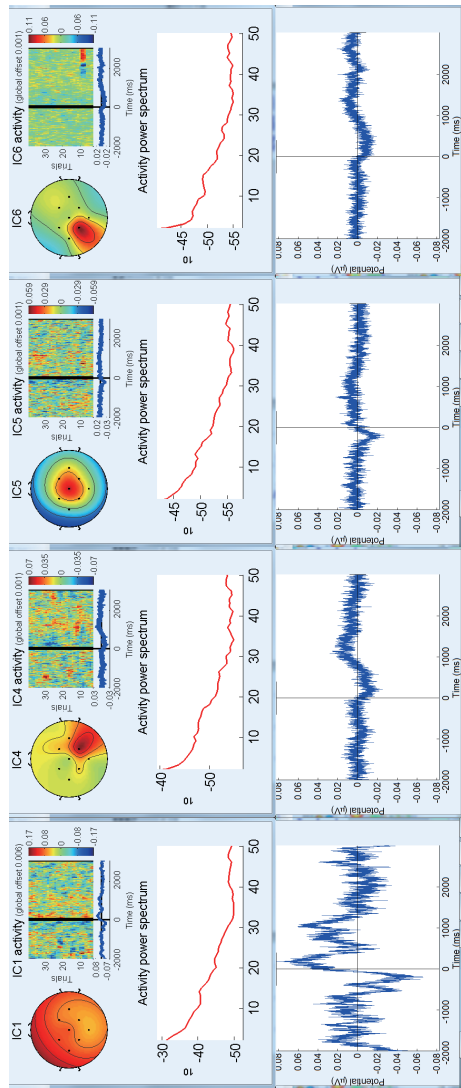
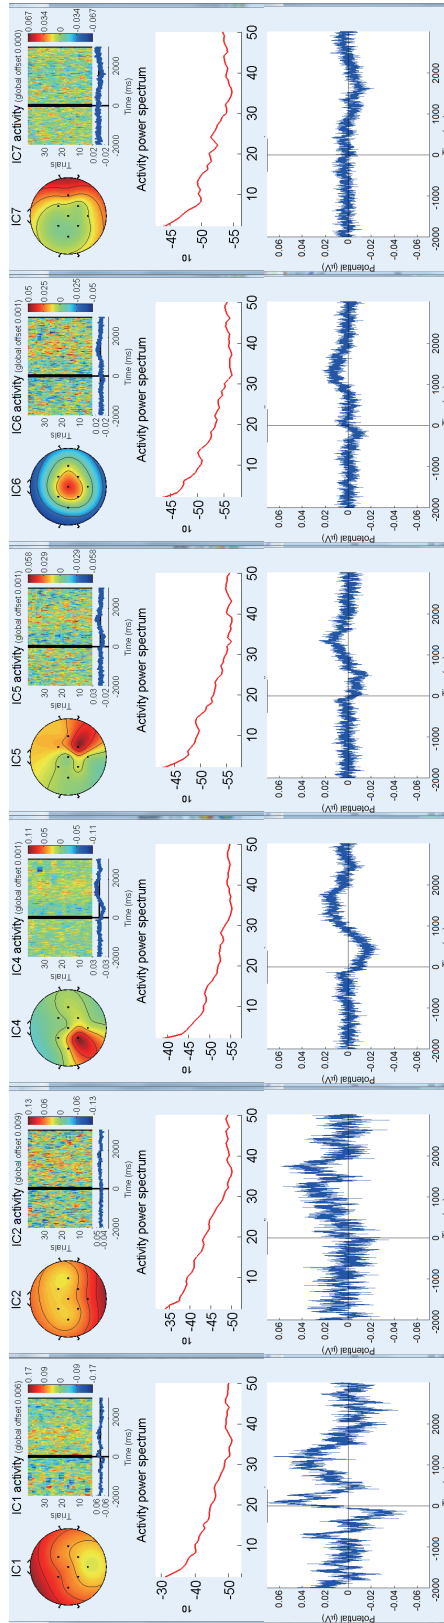


図 8.11: 訓練による各被験者の肘と肩関節の成分の変化



Subject A DAY7 Elbow Joint



Subject A DAY7 Shoulder Joint

図 8.12: 被験者 A の七日目の肘と肩関節の成分の違い

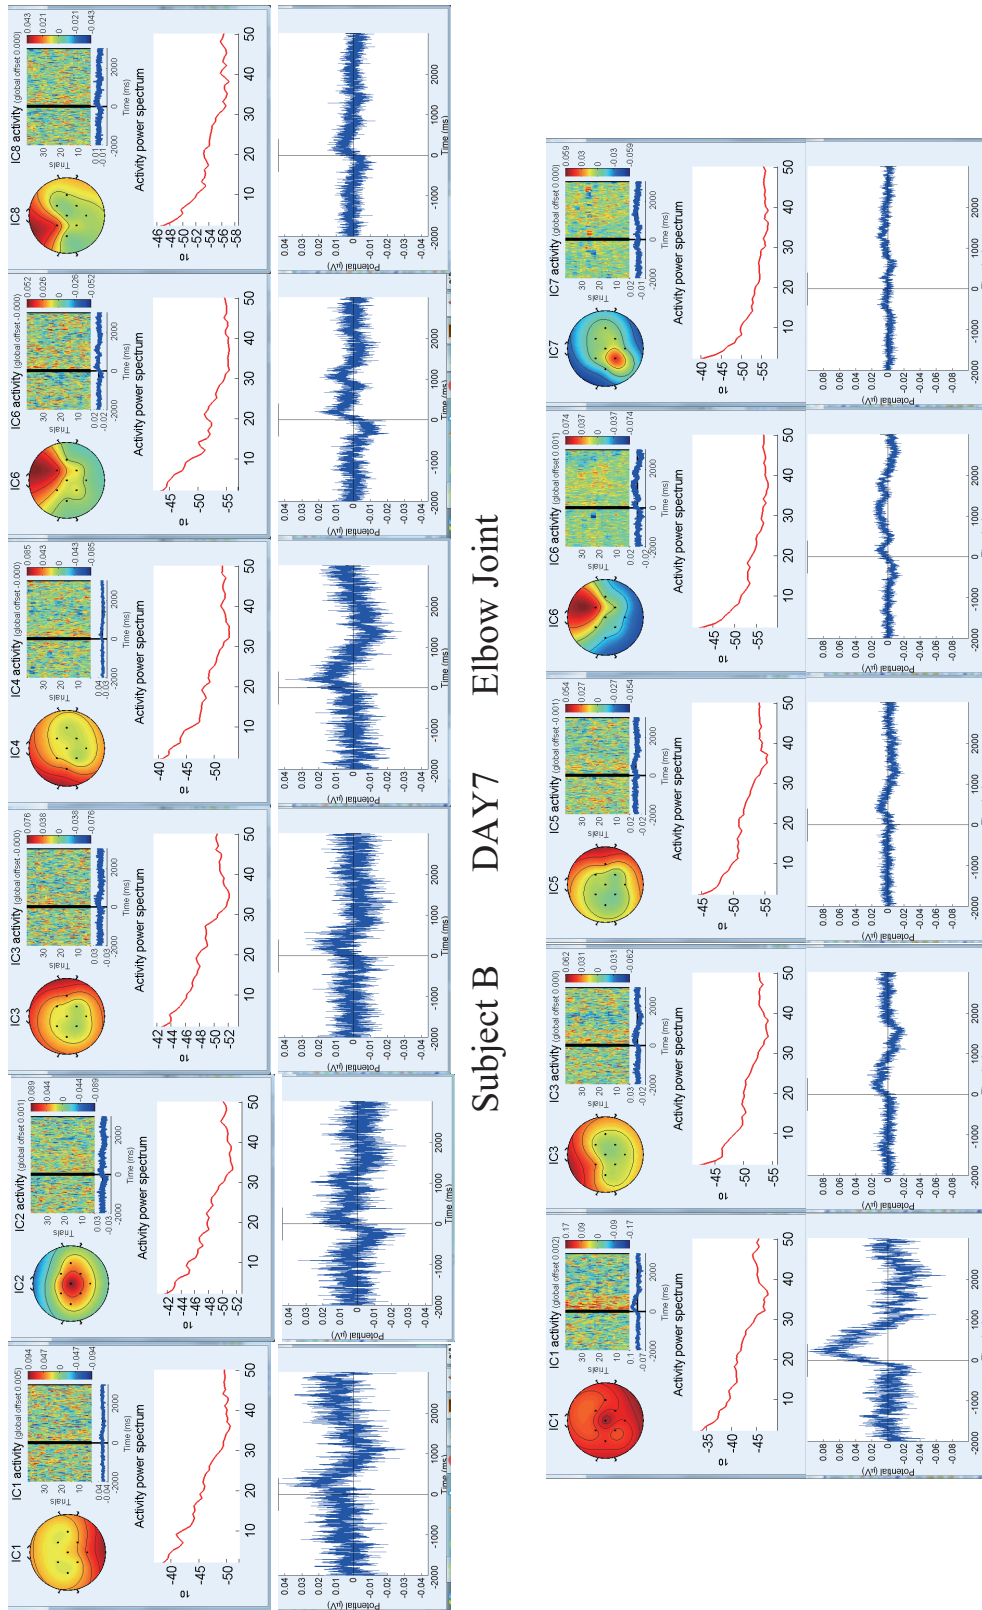


図 8.13: 被験者 B の七日目の肘と肩関節の成分の違い

8.6.3 訓練の結果に関する考察

これらの結果より、訓練による運動時の特徴が明らかになる傾向があることが分かった。また特徴と言える成分も訓練により増強されることも分かった。さらに、運動の直前の変化は C_z に集中していることが分かった。その他に、特徴成分の周波数特性を確認すると、最終日に α 帯域の増加に伴い、 β 帯域のパワーが減少する変動も観察された。次の段階でその詳細について調査する。

また、肘も肩も訓練による屈曲運動時に共通の成分が見られた。これらの特徴のデータや観測された（もしくは発生する）場所に関しては波形も似ており、その特徴の頭皮上の分布も運動野周辺に偏っていたことが分かった。そして、肘と肩関節の運動を区別するための運動後の1秒のときの成分は、 P_z と $CP1$ などに分布することが分かった。今後はこれらの成分を用いて、運動に関する特徴の周波数帯域の特定と発生部位（観測部位ではなく、すなわち信号源の特定）を行っていく。

8.7 まとめ

本章のまとめとして，訓練の継続により運動時の特徴が明瞭となる傾向があり，特徴と見受けられる特徴成分も訓練の日数によって増えていくことが分かった．またこれらの特徴を確認すると，運動の直前の変化は Cz に集中していることも分かった．さらに，これらの特徴成分が運動前と運動中と運動後に再現性もあるため，動作に関連する成分と言える．すなわち，訓練の継続により，パワーアシストの制御に有用な成分を安定に誘発することができる．また肘と肩関節の運動1秒後の成分は識別用の特徴成分として異なっており， Pz と $CP1$ などに分布することが分かった．この結果は従来のヒトの一次運動野における体部位局在の部位と一致しており，訓練により肘関節と肩関節の連動動作を実現するための各関節に特有な成分の誘発と抽出ができることが分かった．そのため，訓練により脳の可塑性の検証ができ，肘関節と肩関節に対して特徴量の明確化を目的とした訓練が有効である．

第9章 結言

本研究では、脳波から各関節におけるトルクの情報抽出および推定する手法を提案し、パワーアシストを実現することで、健常者の生活の質の改善と作業効率の向上を目指した。本論文では、まず擬似拮抗筋の概念を提案することで、二関節筋による問題を解決し、脳波から肩関節のトルクの推定が可能となることに着目した。本論文は、BMI技術に基づいた肩関節の屈伸運動にパワーアシストを適用した世界初の研究報告である。次に肘と肩関節の連動動作を実現するために、脳の可塑性を用いた訓練を行い、各関節運動時の特徴の抽出手法を提案および検証することにより、BMI技術に基づく上肢のパワーアシストシステムの構築を行った。最後に、本論文をまとめ、今後の展望について述べる。

9.1 まとめ

本論文では、まず擬似拮抗筋を導入することにより、二つの方法により脳波に基づくパワーアシストシステムの構築手法を提案した。一つ目の方法として、主成分分析により特徴を抽出し、その特徴を用いて脳波-トルクの線形モデルを構築し、肩関節のパワーアシストに必要なトルクを推定した。この手法により、肩関節の屈伸運動における脳波の変化部位や特徴を明らかにした。その特徴を用いたモデルを構築することにより、パワーアシストに必要なトルクの推定に成功し、BMI技術により健常者をパワーアシストをすることが可能となることを示した。二つ目の方法として、脳波信号の時変性を考慮した上で、脳波の変化と運動の間の遅延を考慮した線形モデルを構築し、肩関節のパワーアシストに必要なトルクを推定した。実験結果から、提案した手法の有効性が確認でき、この手法に

より単一動作だけに限らずに、連続的な動作のトルクの推定にも成功し、リアルタイムでパワーアシストを行える可能性が示された。

次に肩と肘関節の連動を実現するための脳波の変化の特徴を明確化し、抽出した。実験結果より手法の有効性が確認でき、抽出された特徴により、脳波に基づく肘と肩関節の運動の識別が可能となった。

最後に、ニューロフィードバックに基づく視覚フィードバックを用いて脳を刺激し、BMIユーザーを訓練することにより、訓練の有効性と特徴の変化、さらに脳の可塑性に関して検証を行った。実験結果より、訓練と視覚フィードバックを通じて、特定の脳波成分の変化特性を強化し、さらに脳の可塑性により特徴量として扱える新しい成分を複数誘発できた。

以上の結果は、BMI技術が将来の生活で広く利用される可能性を示している。

9.2 今後の展望

本研究では、脳波の中のトルク情報を解析することで、関節のトルク情報の抽出・推定手法の確立および多関節の連動動作のための特徴の明確化を目指し、BMIに基づいた上肢のパワーアシスト技術の開発を進めてきた。この技術を用いることで、推定された人の多自由度のトルク情報による外骨格ロボットでのパワーアシストシステムの構築が可能となる。今後、学習手法を導入し、リアルタイムで脳波と関節トルク間のモデルの更新を行うと同時に制御モデルをも更新することにより、人とロボットとの相互適応システムの開発を行う。さらに、脳の可塑性を利用し、人とロボットとの相互適応により、ロボットの適切な運動方式やパターンを設計したのち、健常者におけるパワーアシストに限らずに、障害者や高齢者などの利用者に運動刺激を与えることで、脳神経運動機能の回復や再生の促進が可能となると考えられる。そこでBMI技術によって様々な日常動作の支援や生活の質の向上の実現を目指していく。

参考文献

- [1] 厚生労働省: “平成 30 年版厚生労働白書 ー障害や病気などと向き合い、
全ての人活躍できる社会に ー (100 人でみた日本、日本の 1 日) ”,
<https://www.mhlw.go.jp/wp/hakusyo/kousei/18-3/>, 2019/10/21 閲覧.
- [2] 内閣府政策統括官 (共生社会政策担当): “平成 30 年度高齢化の状況及び高
齢社会対策の実施状況”, 令和元年版高齢社会白書, 2019.
- [3] 加藤一郎ほか: “電油式多自由度前腕義手 (ワセダハンド-9H3)”, バイオメカ
ニズム, 4, pp. 139, 1978.
- [4] 西岡研一: “前腕用筋電義手ワイムハンド (WIME HAND) ”, 日本義肢装具
学会誌, 9(4), pp. 347, 1993.
- [5] 伊藤宏司ほか: “超音波モータを用いた 3 自由度前腕筋電義手”, 計測自動制
御学会論文集, 27(11), pp. 1281, 1991.
- [6] 原田電子工業株式会社: http://www.h-e-i.co.jp/products_list.html,
2019/12/8 閲覧.
- [7] 山本圭治郎ほか: “パワーアシストスーツの開発: システムの改良”, 社団法人日本機械学会論文集, No.07-8, 2007.
- [8] kawasaki: <http://response.jp/article/2011/10/20/164099.html>, 2019/12/8 閲
覧.
- [9] Y.Muramatsu: “Improvement and Quantitative Performance Estimation of
the Back Support Muscle Suit”, Proceedings of the 35th Annual Interna-

- tional Conference of the IEEE Engineering in Medicine and Biology Society, pp. 2844-2849, 2013.
- [10] 遠山茂樹ほか：“パワーアシストスーツとその要素開発”, 精密工学会誌, 73(3), 2007.
- [11] Kiguchi Kazuo: “Mechanism and Control of a 7DOF Upper-Limb Power-Assist Robot”, Proceedings of the JSME annual meeting (7), pp. 345-346, 2009.
- [12] CYBERDYNE: <http://www.cyberdyne.jp/products/HAL/>, 2019/12/8 閲覧.
- [13] 中井隆雄: “表面筋電位を用いたパワーアシスト制御手法の開発と歩行支援用パワーアシスト脚 HAL-3 の構築”, 筑波大学大学院博士課程修士論文 2004.
- [14] Berkeley Robotics and Human Engineering Laboratory: <http://bleex.me.berkeley.edu/research/exoskeleton/bleex/>, 2019/12/8 閲覧.
- [15] TechCrunch: <http://www.crunchgear.com/2010/09/27/sarcos-xos2-the-real-life-iron-man/>, 2019/12/8 閲覧.
- [16] 米国立産業安全保健研究所: “表面筋電位の人間工学応用”, 労働科学研究所出版部, 2004.
- [17] A. Kübler, B. Kotchoubey, J. Kaiser, J. R. Wolpaw, and N. Birbaumer: “Brain-computer communication: unlocking the locked in”, *Psychology Bulletin*, May, 127(3), pp. 358-375, 2001.
- [18] 川人光男, 佐倉統: “ブレイン・マシン・インターフェース BMI 倫理 4 原則の提案”, 現代化学, No. 471, 東京科学同人, pp. 21-25, 2010.
- [19] A. P. Georgopoulos, A.B. Schwartz, and R.E. Kettner: “Neuronal population coding of movement direction”, *Science*, 26(233), pp. 1416-1419, 1986.

- [20] Pubmed : <http://www.ncbi.nlm.nih.gov/pubmed>, 2019/12/4 検索結果.
- [21] M. A. Lebedev, and M. A. L. Nicolelis: “Brain Machine interfaces: past, present and future ” , Trends in Neurosciences, 29(9), pp. 536-546, 2006.
- [22] E. Niedermeyer, and F. H. L. Da Silva: “Electroencephalography: basic principles, clinical applications, and related fields ” , Lippincott Williams & Wilkins, 2005.
- [23] J. Mellinger, G. Schalk, C. Braun, H. Preissl, W. Rosenstiel, N. Birbaumer, and A. Kbler: “An MEG-based brain computer interface(BCI) ” , NeuroImage, 36(3), pp. 581-593, 2007.
- [24] S. M. Coyle, T. E. Ward, and C. M. Markham: “Brain-computer interface using a simplified functional near-infrared spectroscopy system ” , Journal of Neural Engineering, 4(3), pp. 219, 2007.
- [25] R. Sitaram, A. Caria, R. Veit, T. Gaber, G. Rota, A. Kuebler, and N. Birbaumer: “fMRI brain-computer interface: a tool for neuroscientific research and treatment ” , Computational intelligence and neuroscience, vol. 2007, pp. 1:1-1:10, 2007.
- [26] intendix by g.tec : <https://www.unicorn-bi.com/product/unicorn-speller-hybrid-black/>, 2019/12/5 閲覧.
- [27] 脳科学研究推進プログラム: “ブレイン・マシン・インターフェースの実用化に向けて-利用者・市民の立場から”, 脳科学研究戦略推進プログラムワークショップ報告書, http://www.nips.ac.jp/srpbs/media/publication/120929BMIWS_report.pdf, 2019/12/5 閲覧.

- [28] J. K. Chapin, K. A. Moxon, R. S. Markowitz, and M. A. Nicolelis: “Real-time control of a robot arm using simultaneously recorded neurons in the motor cortex”, *Nature Neuroscience*, pp. 664-670, 1999.
- [29] J. Wessberg, C. R. Stambaugh, J. D. Kralik, P. D. Beck, M. Laubach, J. K. Chapin, J. Kim, S. J. Biggs, M. A. Srinivasan, and M. A. Nicolelis: “Real-time prediction of hand trajectory by ensembles of cortical neurons in primates”, *Nature*, 408, pp. 361-365, 2000.
- [30] M. A. L. Nicolelis, J. K. Chapin: “Controlling robots with the mind”, *SCIENTIFIC AMERICAN-AMERICAN EDITION*, 287(4), pp. 46-55, 2002.
- [31] 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*, pp. 193-208, 2003.
- [32] L. R. Hochberg, D. Bacher, B. Jarosiewicz, N. Y. Masse, J. D. Simeral, J. Vogel, S. Haddadin, J. Liu, S. S. Cash, P. vander Smagt, J. P. Donoghue: “Reach and grasp by people with tetraplegia using a neurally controlled robotic arm”, *Nature*, pp. 372-375, 2012.
- [33] Takufumi Yanagisawa, Masayuki Hirata, Youichi Saitoh, et al, : “Electrocorticographic control of a prosthetic arm in paralyzed patients”, *Annals of Neurology*, pp. 353-361, 2012.
- [34] Dawson GD.: “A summation technique for detecting small signals in a large irregular background”, *J Physiol*, 115(1), 2p-3p, 1951.
- [35] S. Sutton, M. Braren, J. Zubin, and E. R. John: “Evoked-potential correlates of stimulus uncertainty”, *Science*, 150(3700), pp. 1187-1188, 1965.

- [36] J. R. Millan, F. Renkens, J. Mourino, et al.: “Noninvasive brain-actuated control of a mobile robot by human EEG”, *IEEE Transactions on biomedical Engineering*, 51(6), pp. 1026-1033, 2004.
- [37] Johan Philips, Jose del R. Millan, Gerolf Vanacker, Eileen Lew, Ferran Galan, Pierre W. Ferrez, Hendrik Van Brussel, and Mamix Nuttin: “Adaptive shared control of a brain-actuated simulated wheelchair”, *Proceedings of IEEE 10th International Conference on Rehabilitation Robotics*, pp. 408-414, 2007.
- [38] 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/>, 2019/12/7 閲覧.
- [39] T. J. Bradberry, R. J. Gentili, and J. L. Contreras-Vidal: “Reconstructing Three-Dimensional Hand Movements from Noninvasive Electroencephalographic Signals”, *The Journal of Neuroscience*, 30(9), pp. 3432-3437, 2010.
- [40] 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*, 111(315), pp.35-40, 2011.
- [41] 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.
- [42] 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”, *Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5602-5605, 2013.

- [43] 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”, Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 1579-1582. 2013.
- [44] Dina Fine Maron: “World Cup to Debut Mind-Controlled Robotic Suit”, Scientific American, June, 2014.
- [45] 吉岡琢, 佐藤雅昭: “階層変分ベイズ推定法 (VBMEG) の原理と応用”, 日本神経回路学会誌, 18(4), pp. 214-223, 2011.
- [46] 吉岡将孝: “ロボットアームを制御する BMI システムのための運動の判別”, 前橋工科大学大学院修士論文, 2013.
- [47] M. Yoshioka, C. Zhu, K. Uemoto, H. Liang, H. Yu, F. Duan, Y. Yan: “Motion Classifier Generation by Mahalanobis Distance for BMI Robotic Arm Control System”, Journal of Neuroscience and Neuroengineering, 2015.
- [48] 吉川裕一郎: “脳波を用いた筋電推定によるパワーアシストシステムの構築に関する基礎研究”, 前橋工科大学大学院修士論文, 2014.
- [49] S. J. Luck: “An introduction to the event-related potential technique”, MIT press, 2014.
- [50] M. Bastiaansen, A. Mazaheri, and O. Jensen: “Beyond ERPs: Oscillatory Neuronal Dynamics”, In S. J. Luck and E. S. Kappenman (Eds.), The Oxford handbook of event-related potential components, Oxford University Press, pp. 31-50.
- [51] Caton, Richard: “The electric currents of the brain”, British Medical Journal, 2, pp. 278, 1875.

- [52] Berger H.: “On the human electroencephalogram”, *Archiv fur Psychiatrie und Nervenkrankheiten* 87, pp. 527-570, 1929.
- [53] 一條貞雄, 高橋系一: “脳波判読に関する 101 章 [第 2 版]”, 医学書院, pp. 2-202, 2009.
- [54] 一條貞雄, 高橋系一: “脳波判読に関する 101 章 [第 2 版]”, 医学書院, pp. 22-47, 2009.
- [55] J. R. Knott: The theta rhythm. In; Lairy GC(ed), “Handbook of Electroencephalography and Clinical Neurophysiology”, Vol, 6A, Elsevier, Amsterdam, pp. 69-77, 1976.
- [56] R. K. Wallace, H. Benson, and A. F. Wilson: “A wakeful hypometabolic physiologic state”, *Am J Physiol*, 221(3), pp. 795-799, 1971.
- [57] J. Winson: “Patterns of hippocampal theta rhythm in the freely moving rat”, *Electroencephalography and clinical neurophysiology*, Vol, 36, pp. 291-301, 1974.
- [58] D. Arnolds, F. H. L. Da Silva, J. W. Aitink, et al.: “Hippocampal EEG and behaviour in dog. I. Hippocampal EEG correlates of gross motor behaviour”, *Electroencephalography and clinical neurophysiology*, 46(5), pp. 552-570, 1979.
- [59] D. Arnolds, F. H. L. Da Silva, J. W. Aitink, et al.: “The spectral properties of hippocampal EEG related to behaviour in man”, *Electroencephalography and clinical neurophysiology*, 50(3), pp. 324-328, 1980.
- [60] G. Pfurtscheller, and A. Berghold: “Patterns of cortical activation during planning of voluntary movement”, *Electroencephalography and clinical neurophysiology*, 72(3), pp. 250-258, 1989.

- [61] G. Pfurtscheller, and F. H. L. Da Silva: “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clinical neurophysiology*, 110(11), pp. 1842-1857, 1999.
- [62] G. Pfurtscheller, and A. Aranibar: “Event-related cortical desynchronization detected by power measurements of scalp EEG”, *Electroencephalography and clinical neurophysiology*, 42(6), pp. 817-826, 1977.
- [63] G. Pfurtscheller: “Event-related synchronization (ERS): an electrophysiological correlate of cortical areas at rest”, *Electroencephalography and clinical neurophysiology*, 83(1), pp. 62-69, 1992.
- [64] G. Pfurtscheller, and C. Neuper: “Motor imagery activates primary sensorimotor area in humans”, *Neuroscience letters*, 239(2), pp. 65-68, 1997.
- [65] G. Pfurtscheller, C. Neuper, C. Andrew, et al.: “Foot and hand area mu rhythms”, *International Journal of Psychophysiology*, 26(1-3), pp. 121-135, 1997.
- [66] B. Libet, C. A. Gleason, E. W. Wright, and D. K. Pearl: “Time of conscious intention to act in relation to onset of cerebral activity (readiness-potential)”, *Brain*, 106(3), pp. 623-642, 1983.
- [67] 中澤 栄輔 (著), 鈴木 貴之 (著), 立花 幸司 (著), 植原 亮 (著), 永岑 光恵 (著), 信原 幸弘 (編さん), 原 塑 (編さん), 山本 愛実 (編さん): “脳神経科学リテラシー”, 勁草書房, pp. 66-67, 2010/10/8.
- [68] 木塚朝博 他: “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.
- [69] 丹治順: “脳と運動-アクションを実行させる脳 第2版”, 共立出版, pp. 3-19, 2011.

- [70] D. M. Halliday, J. R. Rosenberg, A. M. Amjad, et al.: “A framework for the analysis of mixed time series/point process data-theory and application to the study of physiological tremor, single motor unit discharges and electromyograms”, *Progress in biophysics and molecular biology*, 64(2), pp. 237-278, 1995.
- [71] D. M. Halliday, B. A. Conway, S. F. Farmer, J. R. Rosenberg : “Using electroencephalography to study functional coupling between cortical activity and electromyograms during voluntary contractions in humans”, *Neuroscience Letters*, 241(1), pp.5-8, 1998.
- [72] 鈴木達也, 牛場潤一, 牛山潤一, 正門由久: “運動野脳活動と支配筋の関連およびその運動経歴による差”, *電子情報通信学会技術研究報告*, NC, 107(50), pp. 15-18, 2007.
- [73] N. Ogawa, C. Liu, R. Chiba, P. Li, and C. Zhu: “Sensorless Power Assistance Control for an Upper Limb Exoskeleton Robot”, *The 12th International Convention on Rehabilitation Engineering and Assistive Technology (i-CREATE) & HCR 2018*, pp. 329-333, 2018.
- [74] M. Schünke, E. Schulte, and U. Schumacher: *Prometheus LernAtlas der Anatomie*, Thieme, 2012.
- [75] E. A. Clancy, and N. Hogan: “Relating agonist-antagonist electromyograms to joint torque during isometric, quasiisotonic, nonfatiguing contractions”, *IEEE Transactions on Biomedical Engineering*, 41(10), pp. 1024-1028, 1997.
- [76] A. L. Hof, and J. W. Van Den Berg: “Linearity between the weighted sum of the EMGs of the human triceps surae and the total torque”, *Journal of biomechanics*, 10(9), pp. 529-539, 1977.

- [77] J. J. Kutch, and T. S. Buchanan: “Human elbow joint torque is linearly encoded in electromyographic signals from multiple muscles”, *Neuroscience letters*, 311(2), pp. 97-100, 2001.
- [78] D. Wattanaprakornkul, M. Halaki, C. Boettcher, et al.: “A comprehensive analysis of muscle recruitment patterns during shoulder flexion: an electromyographic study”, *Clinical anatomy*, 24(5), pp. 619-626, 2011.
- [79] M. Kronberg, G. Németh, L. A. Broström: “Muscle activity and coordination in the normal shoulder. An electromyographic study”, *Clinical orthopaedics and related research*, No. 257, pp. 76-85, 1990.
- [80] D. Wattanaprakornkul, I. Cathers, M. Halaki, et al.: “The rotator cuff muscles have a direction specific recruitment pattern during shoulder flexion and extension exercises”, *Journal of science and medicine in sport*, 14(5), pp. 376-382, 2011.
- [81] D. K. Kuechle, S. R. Newman, E. Itoi, et al.: “Shoulder muscle moment arms during horizontal flexion and elevation”, *Journal of Shoulder and Elbow Surgery*, 6(5), pp. 429-439, 1997.
- [82] H. H. Jasper: “The ten-twenty electrode system of the International Federation”, *Electroenceph, clin. Neurophysiol.*, Vol.10, pp. 371-375, 1958.
- [83] M. R. Nuwer, G. Comi, R. Emerson, et al.: “IFCN standards for digital recording of clinical EEG”, *Electroencephalography and clinical Neurophysiology*, 106(3), pp. 259-261, 1998.
- [84] I. Fried, R. Mukamel, and G. Kreiman: “Internally generated preactivation of single neurons in human medial frontal cortex predicts volition”, *Neuron* 69(3), pp. 548-562, 2011.

- [85] T. Ball, A. Schulze-Bonhage, A. Aertsen and C. Mehring: “Differential representation of arm movement direction in relation to cortical anatomy and function”, *J. NeuralEng.*, 6(1), 016006, 2009.
- [86] H. H. Kornhuber, and L. Deecke: “Changes in the brain potential in voluntary movements and passive movements in man: readiness potentials and reafferent potentials”, *PflügersArch. Gesamte Physiol. Menschen Tiere* 284, pp. 1-17, 1965.
- [87] H. Shibasaki, and M. Hallett: “What is the Bereitschafts potential?”, *Clin. Neurophysiol.* 117, pp. 2341-2356, 2006.
- [88] N. Birbaumer: “Slowcortical potentials: plasticity, operant control, and behavioral effects”, *Neuroscientist* 5, pp. 74-78, 1999.
- [89] B. Libet, E. W. Wright, and C. A. Gleason: “Readiness-potentials preceding unrestricted spontaneous ’ vs. pre-planned voluntary acts”, *Electroencephalogr, Clin. Neurophysiol.*, 54, pp. 322-335, 1982.
- [90] B. Libet, C. A. Gleason, E. W. Wright, and D. K. Pearl: “Time of conscious intention to act in relation to onset of cerebralactivity (readiness-potential)”, *Brain* 106, pp. 623-642, 1983.
- [91] G. Pfurtscheller, and F. H. Lopesda Silva: “Event-related EEG/MEG synchronization and desynchronization: basic principles”, *Clin. Neurophysiol.*, 110(11), pp. 1842-1857, 1999.
- [92] O. Bai, V. Rathi, P. Lin, D. Huang, H. Battapady, D. Y. Fei, L. Schneider, E. Houdayer, X. Chen, and M. Hallett: “Prediction of human voluntary movement before it occurs”, *Clin. Neurophysiol.*, 122, pp. 364-372, 2011.

- [93] B. Awwad Shiekh Hasan, and J. Q. Gan: “Unsupervised movement onset detection from EEG recorded during self-paced real hand movement”, *Med. Biol. Eng. Comput.*, 48, pp. 245-253, 2010.
- [94] B. Awwad Shiekh Hasan, and J. Q. Gan: “Temporal modeling of EEG during self-paced hand movement and its application in onset detection”, *J. NeuralEng.*, 8, pp. 1-8, 2011.
- [95] F. Cincotti, D. Mattia, C. Babiloni, et al.: “The use of EEG modifications due to motor imagery for brain-computer interfaces”, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11(2), pp. 131-133, 2003.
- [96] Pfurtscheller, Gert, et al.: “Brain oscillations control hand orthosis in a tetraplegic”, *Neuroscience letters*, 292.3, pp. 211-214, 2000.
- [97] Pfurtscheller, Gert, et al.: “EEG-based asynchronous BCI controls functional electrical stimulation in a tetraplegic patient”, *EURASIP Journal on Applied Signal Processing 2005*, pp. 3152-3155, 2005.
- [98] A. Y. Paek, J. D. Brown, R. B. Gillespie, et al.: “Reconstructing surface EMG from scalp EEG during myoelectric control of a closed looped prosthetic device”, *Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2013*, pp. 5602-5605, 2013.
- [99] N. Bhagat, J. French, A. Venkatakrishnan, et al.: “Detecting movement intent from scalp EEG in a novel upper limb robotic rehabilitation system for stroke”, *Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2014*, pp. 4127-4130, 2014.

- [100] R. T. Lauer, P. H. Peckham and K. L. Kilgore: “EEG- based control of a hand grasp neuroprosthesis”, *Neuroreport*, 10(8), pp. 1767-1771, 1999.
- [101] H. G. Tan, H. H. Zhang, C. C. Wang, et al.: “A step towards discretized motion control of the upper limb using brain-computer interface and electrical stimulation”, *Proceedings of the 13th IFESS conference*. 2008.
- [102] K. K. Ang, C. Guan, K. S. Phua, et al.: “Transcranial direct current stimulation and EEG-based motor imagery BCI for upper limb stroke rehabilitation”, *Proceedings of the 34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2012*, pp. 4128-4131, 2012.
- [103] S. W. Tung, C. Guan, K. K. Ang, et al.: “Motor imagery BCI for upper limb stroke rehabilitation: an evaluation of the EEG recordings using coherence analysis”, *Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2013*, pp. 261-264, 2013.
- [104] J. H. Kim, R. Chavarriaga, J. del R Millan, et al.: “Three-dimensional upper limb movement decoding from EEG signals”, *2013 International Winter Workshop on Brain-Computer Interface (BCI), IEEE*, pp. 109-111, 2013.
- [105] R. C. Caracillo, M. C. F. Castro: “Classification of executed upper limb movements by means of EEG”, *Proceedings of the Biosignals and Biorobotics Conference (BRC) 2013*, pp. 1-6, 2013.
- [106] N. J. Beuchat, R. Chavarriaga, S. Degallier, et al.: “Offline decoding of upper limb muscle synergies from EEG slow cortical potentials”, *Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2013*, pp. 3594-3597, 2013.

- [107] E. Lew, R. Chavarriaga, S. Silvoni, et al.: “Detection of self-paced reaching movement intention from EEG signals”, *Front. Neuroeng*, 5(13), 2012.
- [108] Moore, David S. and William I. Notz: *Statistics: Concepts and controversies*. Macmillan, 2006.
- [109] J. C. de Munck: “A linear discretization of the volume conductor boundary integral equation using analytically integrated elements”, *IEEE Trans. Biomed. Eng.* 39, pp. 986-990, 1992.
- [110] J. Hori and N. Aoki: “Equivalent dipole sources localization using cortical dipole layer imaging and independent component analysis”, *Int. J. Bioelectromagn.*, 10, pp. 100-110, 2008.
- [111] A. J. Bell, and T. J. Sejnowski: “An information-maximization approach to blind separation and blind deconvolution”, *Neural computation*, 7(6), pp. 1129-1159, 1995.
- [112] Maguire et al.: “Navigation-related structural change in the hippocampi of taxi drivers”, *Proc. Natl. Acad. Sci. USA*, 97, pp. 4398-4403, 2000.
- [113] Sitaram et al.: “Closed-loop brain training: the science of neurofeedback”, *Nat. Rev. Neurosci.*, 18, pp. 86-100, 2017.
- [114] Clancy et al.: “Volitional modulation of optically recorded calcium signals during neuroprosthetic learning”, *Nat. Neurosci.* 17, pp. 807-809, 2014.
- [115] Koralek et al.: “Corticostriatal plasticity is necessary for learning intentional neuroprosthetic skills”, *Nature* 483, pp. 331-335, 2012.
- [116] Koralek et al.: “Temporally precise cell-specific coherence develops in corticostriatal networks during learning”, *Neuron* 79, pp. 865-872, 2013.

- [117] Collinger et al.: “High-performanceneuroprosthetic control by an individual with tetraplegia”, *Lancet* 381, pp. 557-564, 2013.
- [118] Hochberg et al.: “Neuronal ensemblecontrol of prosthetic devices by a human with tetraplegia”, *Nature* 442, pp. 164-171, 2006.
- [119] Bouton et al.: “Restoring corticalcontrol of functional movement in a human with quadriplegia”, *Nature* 533, pp. 247-250, 2016.
- [120] Prinzel et al.: “Physiological Self-Regulation and AdaptiveAutomation”, *The International Journal of Aviation Psychology*, 12:2, pp. 179-196, 2002.
- [121] Egner et al.: “EEG Biofeedback of low beta band components:frequency-specific effects on variables of attention and event-related brainpotentials”, *Clinical Neurophysiology*; 115: pp. 131-139, 2004.
- [122] Doppelmayr et al.: “Effects of SMR and theta/betaneurofeedback on reaction times, spatial abilities, and creativity”, *Journal of Neurotherapy*, 15(2), pp. 115-129, 2011.
- [123] Wang et al.: “Neurofeedback training improves attention and working memoryperformance”, *ClinicalNeurophysiology*, 124, pp. 2406-2420, 2013.
- [124] Ghaziri et al.: “Neurofeedback traininginduces changes in white and gray matter”, *Clin. EEGNeurosci.* 44, pp. 265-272, 2013.
- [125] Megumi et al.: “Functional MRIneurofeedback training on connectivity between two regions induces long-lastingchanges in intrinsic functional network”, *Front. Hum.Neurosci.* 9, pp. 160, 2015.
- [126] Engelbregt et al.: “Short and long-termeffects of sham-controlled prefrontal EEGneurofeedback training in healthysubjects”, *Clin. Neurophysiol.* 127, pp. 1931-1937, 2016.

- [127] Kovacevic et al.: “ ‘ virtual dream ’ :collective neurofeedback in an immersive art environment”, PLoS ONE 10, 2015.
- [128] Ros et al.: “Mind over chatter:plastic up-regulation of the fMRI salience network directly after EEGneurofeedback”, Neuroimage65, pp. 324-335, 2013.
- [129] Bauer et al.: “EEG-based localbrain activity feedback training - tomographic neurofeedback”, Front.Hum. Neurosci. 8:1005, 2014.
- [130] Emmert et al.: “Meta-analysis of real-time fMRIneurofeedback studies using individual participant data: How is brainregulation mediated? ”, Neuroimage 124, pp. 806-812, 2015.
- [131] Sitaram et al.: “Closed-loopbrain training: the science of neurofeedback”, Nat. Rev.Neurosci., 18, pp. 86-100, 2017.
- [132] Nunez etal.: “Oxford University Press, Electric fields of the brain: the neurophysics of EEG (2nd Ed.)”, New York, pp. 163-166, 2006.
- [133] Kennedy: “Synaptic signaling in learning and memory”, Cold Spring Harb. Perspect.Biol. a016824. doi: 10.1101/cshperspect.a016824, 2013.
- [134] Cook et al.: “Synaptic dysfunction inAlzheimer’s disease: clinical assessment using quantitative EEG”, Behav BrainRes, 78, pp. 15-23, 1996.
- [135] Gouw et al.: “EEGspectral analysis as a putative early prognostic biomarker in nondemented,amyloid positive subjects”, Neurobiol Aging; 57: pp. 133-142, 2017.
- [136] Butterworth, Stephen: “On the theory of filter amplifiers”, Wireless Engineer 7.6, pp. 536-541, 1930.

- [137] X. JIAO, K. DING: “Resetting Moduli and Solutions in Windowing Spectrum Analysis”, Journal of Shantou University (Natural Science Edition), 3, pp. 4, 2003.
- [138] H. Hotelling: “Analysis of a complex of statistical variables into principal components”, Journal of Educational Psychology, 24(6), pp. 417-441, 1933.
- [139] S. Makeig, T. P. Jung, A. J. Bell, D. Ghahremani, and T. J. Sejnowski: “Blind Separation of Auditory Event-related Brain Responses into Independent Components”, Proc. Natl. Acad. Sci. USA, pp. 10979-10984, 1997.
- [140] C. J. James, and C. W. Hesse: “Independent component analysis for biomedical signals”. Physiological measurement, 26(1), R15, 2004.
- [141] M. J. Mckeown, T. P. Jung, S. Makeig, G. Brown, S. S. Kindermann, T. W. Lee, and T. J. Sejnowski: “Spatially independent activity patterns in functional magnetic resonance imaging data during the Stroop color-naming task”, Proceedings of the National Academy of Sciences, Vol. 95, pp. 803-810, 1998.
- [142] <http://www.tsi.enst.fr/icacentral/Algos/cardoso/>, 2016/2/1 閲覧.
- [143] <http://www.cis.hut.fi/projects/ica/fastica/>, 2019/12/6 閲覧.
- [144] <http://www.tsi.enst.fr/icacentral/>, 2016/2/1 閲覧.
- [145] 江原義郎: “ユーザーズ デジタル信号処理”, 東京電機大学出版局, pp28-32, 2006.

業績

学術論文

1. H. Liang, C. Zhu, Y. Iwata, S. Maedono, M. Mochita, C. Liu, N. Ueda, P. Li, H. Yu, Y. Yan, and F. Duan, “ Feature Extraction of Shoulder Joint’s Voluntary Flexion-Extension Movement Based on Electroencephalography Signals for Power Assistance”, Bioengineering, Volume 6, Issue 1, 2, 2019.
2. 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ウム論文集, pp. 267-268, 2017年3月.
3. H. Liang, C. Zhu, S. Maedono, Y. Yu, M. Mochita, Y. Lu, C. Liu, N. Ueda, P. Li, M. Aoki, H. Yu, Y. Yan, and F. Duan, “EEG Based Torque Estimation of Shoulder Joint for the Power Augmentation System of Upper Limbs”, IEEE Access, 投稿中.
4. 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(8), June 2017.
5. 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, Volume 4, Number 1, pp. 38-43(6), June 2017.

6. 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. 209 - 214, September 2016.
7. 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, pp. 16-00195, 2017.
8. 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ウム論文集, pp. 217-218, 2017年3月.
9. 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ウム論文集, pp. 269-270, 2017年3月.
10. 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ウム論文集, pp. 38-43, 2016年3月.

国際学会（査読付き）

11. H. Liang, C. Zhu, Y. Iwata, S. Maedono, M. Mochida, H. Yu, Y. Yan, and F. Duan, “Motion Estimation for the Control of Upper Limb Wearable Exoskeleton Robot with Electroencephalography Signals”, Proceedings of the 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS), pp. 228-233, October 2018.

12. H. Liang, C. Zhu, Y. Tian, Y. Iwata, S. Maedono, H. Yu, Y. Yan, and F. Duan, “Construction of Power Assistive System for the Control of Upper Limb Wearable Exoskeleton Robot with Electroencephalography Signals”, Proceedings of the 2017 IEEE International Conference on Cyborg and Bionic Systems (CBS), pp. 165-168, October 2017. (**Best Student Paper Award**)
13. H. Liang, C. Zhu, M. Yoshioka, N. Ueda, Y. Tian, Y. Iwata, H. Yu, F. Duan, and Y. Yan, “Estimation of EMG signal for shoulder joint based on EEG signals for the control of upper-limb power assistance devices”, Proceedings of the 2017 **IEEE International Conference on Robotics and Automation (ICRA)**, pp. 6020-6025, May 2017.
14. H. Liang, C. Zhu, M. Yoshioka, N. Ueda, Y. Tian, Y. Iwata, H. Yu, Y. Yan, and F. Duan, “Investigation of the EEG Scalp Distribution for Estimation of Shoulder Joint Torque in the Upper-Limb Power Assistant System”, Proceedings of the 2016 IEEE International Conference on Robotics and Biomimetics (ROBIO), pp. 1912-1917, December 2016.
15. 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 (ROBIO 2014), pp. 419-424, December 2014.
16. N. Ogawa, Y. Ueta, T. Watanabe, T. Kaneko, P. Li, C. Liu, H. Liang, N. Ueda, C. Zhu, W. Zhang, Y. Shibusawa, N. Tago, and K. Deguchi, “Sensorless Power Assistance Control for a Lumbar Assist Device”, Proceedings of the 2019 IEEE International Conference on Robotics and Biomimetics (ROBIO 2019), December 2019. (**Best Paper Finalist**)

17. R. Tajima, C. Zhu, H. Liang, C. Liu, N. Ueda, P. Li, and T. Watanabe, “A New Type of Foldable and Omnidirectional Mobile Assistive Robot” Proceedings of the IEEE International Conference on Real-time Computing and Robotics 2019, August 2019. (**Best Student Paper Award**)
18. P. Li, C. Liu, H. Liang, N. Ogawa, C. Zhu, “Development of Power Add-on Unit for Manual Wheelchair and Its Sensorless Power Assistance Control”, Proceedings of the 12th International Convention on Rehabilitation Engineering and Assistive Technology (i-CREATE) & HCR 2018, pp. 324-328, July 2018.
19. Y. Takabayashi, K. Ishihara, M. Yoshioka, H. Liang, C. Liu, C. Zhu, “Frictional Constraints on the Sole of a Biped Robot When Slipping”, Proceedings of the 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 5011-5016, Canada, September 2017.
20. C. Liu, C. Zhu, H. Liang, M. Yoshioka, Y. Murata, and Y. Yu, “Development of A Light Wearable Exoskeleton for Upper Extremity Augmentation”, Proceedings of the 2016 23rd International Conference on Mechatronics and Machine Vision in Practice (M2VIP 2016), China, A-2, November 2016. (**Best Conference Paper Award**)
21. M. Yoshioka, H. Liang, N. Ueda, Y. Tian, and C. Zhu, “Construction of BMI Power Assistance System with the EEG-Torque Model”, Proceedings of the 10th International Conference on Complex Medical Engineering, OS6-3, Tochigi, Japan, August 2016.
22. C. Zhu, T. Nakayama, M. Shibayama, M. Yoshioka, H. Liang, Y. Yan, H. Yu, J. Nakajima, H. Shibasaki, “A Novel Power Add-on Unit for Attendant Propelled Wheelchairs with Sensorless Speed Control and Power Assistance”, Proceedings of the International Conference on Rehabilitation Robotics 2015.

口頭発表（学会全国大会，研究会，ワークショップ）

23. 梁宏博, “パワーアシストのための脳波信号に基づく肩関節の随意的屈曲伸展運動の特徴抽出”, 2019年度9大学合同パワーエレクトロニクスモーションコントロール研究会.
24. 梁宏博, 前殿翔太, 岩田悠, 朱赤, “パワーアシストシステムの構築における脳波を用いた肘と肩関節の二関節の連動時の特徴抽出”, ロボティクス・メカトロニクス講演会講演概要集, 1A1-E10, 2018.
25. 梁宏博, 上田直哉, 田野, 岩田悠, 前殿翔太, 朱赤, “Brain Machine Interfaceによる上肢のパワーアシストスーツを制御するための肩関節の屈曲 / 伸展運動の推定”, 平成29年電気学会産業応用部門大会講演論文集, No. 2-23, pp. 145-146, 2017年8月.
26. 梁宏博, 朱赤, 吉岡将孝, 上田直哉, 田野, 岩田悠, “脳波を用いた肩関節の筋電の推定によるパワーアシストシステムの構築”, 日本福祉工学会第19回総会・第20回学術講演会, 2016年11月.
27. 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.
28. 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.
29. 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.

30. 梁宏博, “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肩関節の筋電推定”, 合同パワーエレクトロニクス研究会, 2015 年 10 月.
31. 梁宏博, 朱赤, 吉岡将孝, 上田直哉, 田野, “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肩関節の運動推定”, 第 33 回日本ロボット学会学術講演会, 2015 年 9 月.
32. 梁宏博, “脳波を用いた肩関節の筋電の推定によるパワーアシストシステムの構築に関する基礎研究”, 第 17 回 8 大学合同パワーエレクトロニクス研究会, 2014 年 9 月.
33. 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.
34. 岩田悠, 梁宏博, 前殿翔太, 朱赤, 吉岡将孝, “脳波による外骨格ロボット制御のための肘屈伸時における筋電推定手法の検討”, ロボティクス・メカトロニクス講演会講演概要集, 2P1-K17, 2018 年 6 月.
35. 前殿翔太, 梁宏博, 岩田悠, 朱赤, “脳波に基づく肘と肩の二関節連動の上肢パワーアシストのための運動準備電位による動作識別に関する研究”, ロボティクス・メカトロニクス講演会講演概要集, 1A1-D12, 2018 年 6 月.
36. 田野, 岩田悠, 吉岡将孝, 梁宏博, 上田直哉, 朱赤, “Mirror Neuron System を用いた μ 律動減衰による力情報の抽出に関する研究”, LIFE2017(第 33 回ライフサポート学会大会, 第 17 回日本生活支援工学会大会, 日本機械学会 福祉工学シンポジウム 2017), 2C-2-4, 2017 年 9 月. (奨励賞 Finalist)
37. 岩田悠, 吉岡将孝, 梁宏博, 上田直哉, 田野, 朱赤, “外骨格ロボット装着下での緊張による脳波変化の解析”, 平成 29 年電気学会産業応用部門大会, Y-82, 2017 年 8 月.

38. 岩田悠, 吉岡将孝, 梁宏博, 上田直哉, 田野, 朱赤, “外骨格ロボット装着下での緊張による脳波変化の解析”, ロボティクス・メカトロニクス講演会 2017, 2017年5月.
39. 田野, 朱赤, 吉岡将孝, 梁宏博, 上田直哉, 岩田悠, “Mirror Neuron Systemに用いた μ 律動減衰による運動情報の抽出に関する研究”, 日本福祉工学会第19回総会・第20回学術講演会, 2016年11月.
40. 上田直哉, 吉岡将孝, 梁宏博, 田野, 朱赤, “前屈・後屈運動時の脳波からの運動関連成分の抽出”, 日本福祉工学会第19回総会・第20回学術講演会, 2016年11月.
41. 劉暢, 朱赤, 吉岡将孝, 梁宏博, “筋電信号による軽量な装着型腕外骨格パワーアシストスーツの開発”, 日本福祉工学会第19回総会・第20回学術講演会, 2016年11月.
42. 吉岡将孝, 梁宏博, 上田直哉, 田野, 岩田悠, 朱赤, “パワーアシストのための主成分モデルを用いた脳波による関節トルク推定”, 日本福祉工学会第19回総会・第20回学術講演会, 2016年11月.
43. 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.
44. 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.
45. 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.

46. 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.
47. 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.
48. 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.
49. 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.
50. 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.
51. 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. (優秀論文発表賞 A 賞)

付録A デジタルフィルタ

信号の中から、特定の成分を取り出すもしくは除去する回路や機能をフィルタと言う。また、そのような処理や操作をフィルタリングと呼ぶ。コンピュータやDSP(Digital Signal Processor)などを用いる場合は、離散値の信号を扱うため、必ずデジタルフィルタとなる。デジタルフィルタは、線形フィルタと非線形フィルタに分類される。また、一般的な線形デジタルフィルタの入力 x と出力 y の関係は、

$$y(k) + b_1y(k-1) + \dots + b_My(k-M) = a_0x(k) + a_1x(k-1) + \dots + a_Nx(k-N) \quad (\text{A.1})$$

と表せる。

b_1, \dots, b_M が存在するときには、過去の出力が回帰的に使用され、回帰フィルタ (Recursive Filter) と呼ばれる。 b_1, \dots, b_M が全てゼロのときには過去の入力のみが使用され、非回帰フィルタ (Nonrecursive Filter) と呼ばれる。なお、フィルタ係数が有限個の場合には、回帰フィルタでは一般にフィードバックのループがあり、インパルス応答は無限に続くパルス列となるので無限インパルス応答 (Infinite Impulse Response: IIR) フィルタと呼ばれ、非回帰フィルタではフィードバックのループがなく、インパルス応答は有限個のパルスで表されるので有限インパルス応答 (Finite Impulse Response: FIR) フィルタと呼ばれる。

A.1 バターワースフィルタの設計

FIR フィルタで急峻な振幅周波数特性を実現する時は、高い次数を必要とする。この場合、IIR フィルタを用いれば低次で済む。今回 IIR のバターワースフィルタの設計を行う。まずローパスフィルタを例とし、説明する。

●振幅二乗特性

バターワースフィルタは1930年、イギリスの技術者 スティーブン・バターワースが論文「On the Theory of Filter Amplifiers」で発表した [136]。N 次のバターワース特性のローパスフィルタの振幅二乗特性の定義を以下のように示す。

$$|H_a(j\Omega)|^2 = \frac{1}{1 + (j\Omega/j\Omega_c)^{2N}} \quad (\text{A.2})$$

このフィルタの特性を決めるパラメータは次数 N とカットオフ周波数 Ω_c である。設計は図 A.1 に示すように、通過域を Ω_c で決め、阻止域における減衰量はフィルタ次数 N で調整する。




図 A.1: バターワースフィルタの振幅特性と次数 N の関係

●N の求め方

振幅は $|H(s)|$ であるため、減衰をデシベルで表すと、以下のようなになる。

$$M = 20 \log_{10} |H(s)| = -10 \log \left(1 + \left(\frac{\Omega}{\Omega_c} \right)^{2N} \right) \quad (\text{A.3})$$

ここで、 M は周波数 Ω_c ときの減衰量、つまり設計要求に応じて M と Ω を与えたとき、その要求を満たすための N が計算できる。これで、 N が求められる。

$$N = \frac{\log \left(10^{-\frac{M}{20}} - 1 \right)}{2 \log \frac{\Omega}{\Omega_c}} \quad (\text{A.4})$$

●設計の流れ

カットオフ周波数で正規化する（すなわち $\Omega_c = 1$ ）と、振幅二乗特性は以下のようなになる。

$$|H(j\Omega)|^2 = \frac{1}{1 + (\Omega)^{2N}} \quad (\text{A.5})$$

これはプロトタイプフィルタ（Prototype Filter）と呼ばれる。

アナログプロトタイプフィルタは振幅二乗特性を用いて極配置をすることで求められる。要求される設計仕様を満足するアナログプロトタイプフィルタ $|H(s)|$ は次のように表される。

$$H(s) = \prod_{k=0}^{N-1} \frac{1}{s - s_k} \quad (\text{A.6})$$

次に、アナログプロトタイプの設計で得られた式を、双1次変換法（式（A.7））を用いて変換することで、デジタルフィルタが得られる。

$$s = \frac{2}{T} \frac{1 - z^{-1}}{1 + z^{-1}} \quad (\text{A.7})$$

ここで、 T はサンプリング周期である。

●フィルタ種類の変換

任意の各周波数また任意の種類フィルタが表 A.1 の変換方法で得られる。

ここで、 ω_c は遮断周波数であり、 ω_1 , ω_2 それぞれは帯域の遮断周波数である。

表 A.1: 変換方法

通過域の種類	変換方法
低域通過	$s \rightarrow \frac{s}{\omega_c}$
高域通過	$s \rightarrow \frac{\omega_c}{s}$
帯域通過	$s \rightarrow \frac{s^2 + \omega_1 \cdot \omega_2}{s(\omega_2 - \omega_1)}$
帯域除去	$s \rightarrow \frac{s(\omega_2 - \omega_1)}{s^2 + \omega_1 \cdot \omega_2}$

●まとめ

ここでデジタルフィルタの設計手順をまとめる。

1. フィルタの仕様：

振幅特性, 位相特性, 実現の際の条件（サンプリング周波数等）。

処理方法: デジタルの指標を正規化し, アナログ周波数 ω_i に変更 ($T_s = 1$), N

と遮断周波数 ω_c を求める

2. 伝達関数の近似：

変換方法を用いて, 伝達関数を求める (アナログプロトタイプフィルタ)

3. デジタルフィルタの構築:

双一次変換法を用いて, 式 (A.7) を代入する

4. 構成と解析：

設計されたフィルタが仕様を満たすかどうかを解析し検証する。

付 録 B 短時間フーリエ変換

式 (B.1), 式 (B.2) で表すように, 短時間フーリエ変換では得られ続けている入力信号から一定の窓 (変換点数: N) で切り出し, 高速フーリエ変換 (Fast Fourier Transform : FFT) を行うことで周波数スペクトル値を算出する. また, 窓の時間軸 (t) をずらし, 再び FFT を行うこと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 (図 B.1).

$$n = t, t + 1, \dots, t + (N - 1) \quad (\text{B.1})$$

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

$$X_k = \{X_{(k,10)}, X_{(k,20)}, \dots, X_{(k,t)}\} \quad (\text{B.2})$$

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, 短時間高速フーリエ変換においても高速フーリエ変換と同様, 窓関数を用いる必要がある. それについて次の節で説明する.

B.1 窓関数

長い信号のスペクトル解析では, 信号の一部を切り出してフーリエ変換を行う. コンピュータで計算する場合は離散値のデータを用いざるを得ず, 離散フーリエ変換となる.

離散フーリエ変換では, 暗黙のうちにデータの周期性が仮定されているため, 右端と左端のデータ値が大きく異なるとその部分で急峻に変化しているような影響




図 B.1: 短時間高速フーリエ変換の概要


が現れ、結果として高い周波数成分（高調波成分）の歪みが発生する。

この対策として、信号に窓関数をかけた結果を離散フーリエ変換する。その結果を図 B.2 に示す。a) は信号の整数個の周期が記録時間の間隔を満たす場合であり、正しいフーリエ変換の結果が得られていることが分かる。b) は記録されたデータの周期数が非整数の場合である。このデータをフーリエ変換した結果は、スペクトルプロットに高いサイドローブ（Side Lobe）が見られる。この現象はスペクトルの漏れと呼ばれる。c) は窓関数を適用する場合である。この時、b) の結果よりサイドローブが大幅に減衰されていることが分かる。しかし、メインローブ（Main Lobe）の幅が大きくなっていることから、周波数の分解能が低くなっていることを意味している。


信号に窓関数をかけた結果を離散フーリエ変換することにより、フーリエ変換後のスペクトルの漏れの原因となるエッジ効果を最小化できることが分かったが、その代わりにメインローブの周波数の分解能を犠牲することになる。すなわち、周波数の分解能を高くするとスペクトル漏れが大きくなり、周波数分解能を低くするとスペクトル漏れが抑えられる。

窓関数を選択する時に、主に以下の三つの指標に注目する。


- (1) 主成分（メインローブ；Main Lobe）の幅



a) The number of cycles is an integer.



b) The number of cycles is not an integer.



c) The window function is used for the signal.

図 B.2: 窓関数の役目

(2) サイドローブ (Side Lobe) の振幅

(3) 減衰率

メインローブの幅が狭いほど、主成分の周波数分解能が高くなり、サイドローブの振幅が小さいほど、小電力のスペクトルを検出する能力が高まる。さらに、第一サイドローブが小さいほど、隣の領域にスペクトルの漏れの改善効果が大きい、ただしメインローブの大きさが増大し、分解能が落ちる。減衰率は第10個サイドローブと第1個の振幅の比であり、減衰の速度を評価する指標である。

例えばこの三つの指標の定義と位置付けを図 B.3 に示す (Parzen 窓)。

同じ入力信号 (振幅が1の10 Hz 信号と、振幅が0.5の13.5 Hz 信号と、振幅が0.5の20 Hz 信号と、振幅が0.5の50 Hz 信号と、振幅が0.5の55 Hz 信号と、振幅が1の60 Hz 信号と、振幅が1の62 Hz 信号と、振幅が0.5の80 Hz 信号と、振幅が0.5の90 Hz 信号と、振幅が0.8の100 Hz 信号を混合された波形) に対して、広く用いられている窓関数をかけ、300 Hz のサンプリング周期で、256 点のフーリエ変換を行った結果を図 B.4 と図 B.5 に示す。

まず図 B.4 の (b)(c)(d)(e) の結果と (a) の結果を比べると、分解能が落ちたことが分かる。特に 60 Hz と 62 Hz の成分の分離ができなくなり、(b) が (c)(d)(e) より




図 B.3: 窓関数

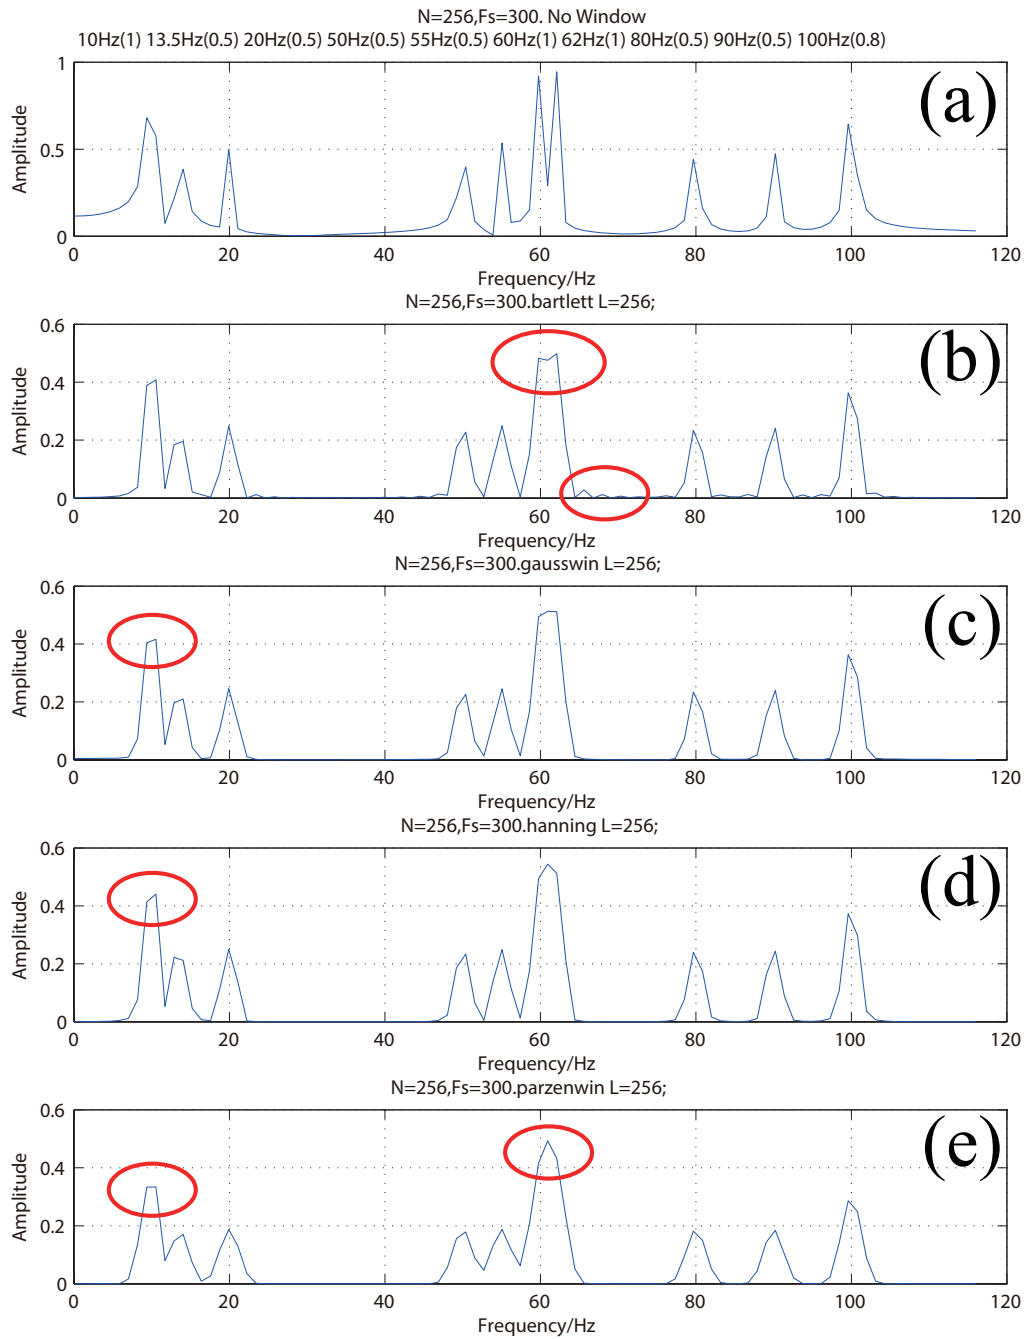


図 B.4: 窓関数の比較 1

(a) 窓関数なし, (b) bartlett 窓関数, (c) gauss 窓関数,
 (d) hanning 窓関数, (e) parzen 窓関数.

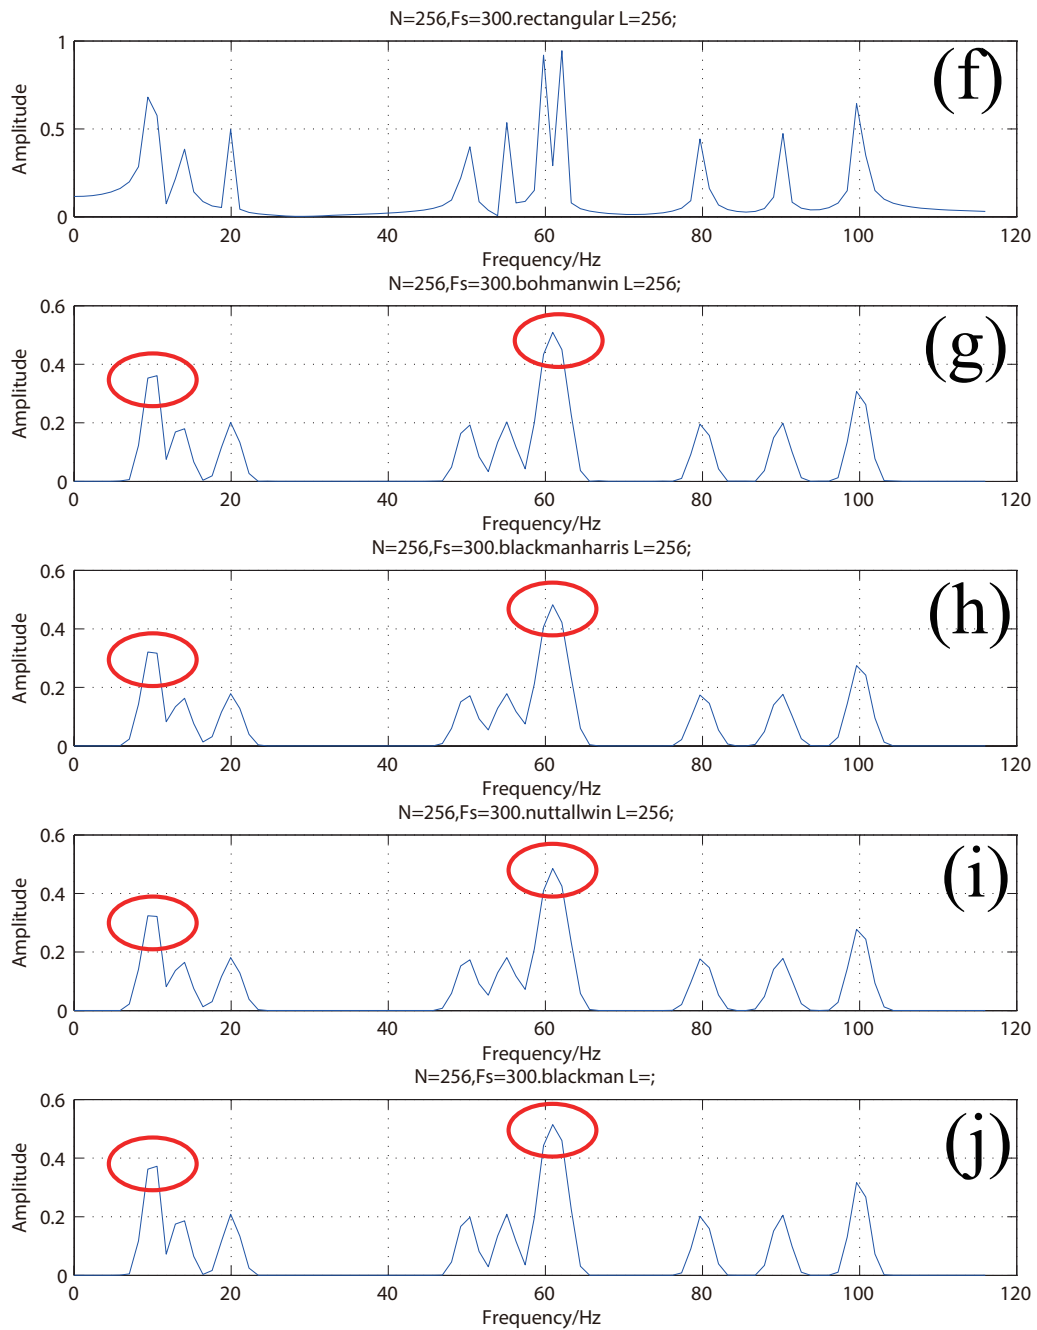


図 B.5: 窓関数の比較 2

(f) 矩形窓関数, (g) bohman 窓関数, (h) blackman-harris 窓関数,
 (i) nuttall 窓関数, (j) blackman 窓関数.

若干分離がいい。しかし，(b)では65-70 Hzのスペクトルの漏れがあることが分かり，(c)(d)(e)ではそれらが見られていない。また，(b)(c)(e)の振幅は(d)の振幅より減衰されたことも分かる。

次に，図B.5の結果と(a)を比べると，矩形窓関数と窓関数なしの結果が同じことが分かった。(g)(h)(i)(j)の結果を見ると，分解能も落ちており，振幅も減衰していた。そのため(c)と(d)がより適切であると考えられる。また，脳波信号は小さい生体信号であるため，振幅の減衰が小さい方が適すると考えられるので，今回ハニング窓関数を用いて，脳波と筋電のデータ解析を行った。

B.1.1 オーバーラップ処理

時間窓を重ねて平均処理することをオーバーラップ処理と呼ぶ。通常ハニング窓の設定では50%程度のオーバーラップが適当である。また，更新時間やどのタイミングのデータを重視するかにより，オーバーラップは適宜変更するのが望ましい。

B.1.2 振幅回復係数の考慮

図B.4と図B.5の結果を見ると，窓関数をかけた後，信号のパワースペクトルの大きさが小さくなるため，今回は振幅回復係数を考慮して，信号のパワースペクトルを元の大きさに戻す。図B.6に適用した窓関数に対する振幅回復係数を示す

窓関数	数式	振幅相同復元係数	パワー相同復元係数
矩形窓	$W(n)=1$	1	1
ハンニング	$W(n)=0.5-0.5\cos(2\pi n/N)$	2	1.633
ハンミング	$W(n)=0.54-0.46\cos(2\pi n/N)$	1.852	1.586
三角窓	$\begin{cases} W(n)=\frac{n}{N/2}, & n=1,\dots,N/2 \\ W(n)=W(N-n), & n=N/2,\dots,N-1 \end{cases}$	2	1.732
ガオス窓	$W(n)=e^{-\frac{1}{2}\left[\frac{2n}{N-1}\right]^2}$	2.396	1.840
ブラックマン窓	$W(n)=0.42-0.5\cos(2\pi\frac{n-1}{N+1})+0.008\cos(4\pi\frac{n-1}{N-1})$	2.381	1.812
<i>flat-top</i> 窓	$W(n)=\begin{cases} \frac{1}{2}[1-\cos(10\pi n/N)] & n=1,2,3,\dots,N/10 \\ 1 & n=N/10+1,\dots,9N/10-1 \\ \frac{1}{2}\{1+\cos[10\pi(n-\frac{9N}{10}/N)]\} & n=9N/10,\dots,N \end{cases}$	1.110	1.069

図 B.6: 振幅回復係数 [137]

付 録 C 主成分分析

過去数十年の間に、運動に關与する脳波信号に対して様々な統計的なデータ分解の手法が開発された。主成分分析 (Principal Component Analysis : PCA) は因子分析の領域に分類され、脳波からの情報の抽出における有効的な手法の一つと考えられている。

主成分分析は統計データから互いに無関係 (無相関) の成分を取り出して、観測値をそれらの成分の線形結合で説明することである。主成分分析は主部分空間 (Principal Subspace) と呼ばれる低次元の線形空間上へのデータ点の直交射影として定義するというものがある。この直交射影は、射影されたデータの分散が最大化されるように定める [138]。そして、取り出された成分が主成分となる。脳波信号の計測は“多変量”が当たり前のため、多くのデータを総合的に見て解釈することが求められる。このような時、情報の損失を最小限にしつつ、できるだけ少ない変数に置き換えて見ることが出来る主成分分析は有効な手法と言える。

PCA の概念図を図 C.1 に示す。 n 次元空間における主成分の軸を w_1, w_2, \dots, w_n とする。点 $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ の各軸への射影 $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$ は式 (C.1) のように与えられる。

$$\begin{cases} y_1 = w_{11}x_1 + w_{12}x_2 + \dots + w_{1n}x_n = \mathbf{w}_1^T \mathbf{x} \\ y_2 = w_{21}x_1 + w_{22}x_2 + \dots + w_{2n}x_n = \mathbf{w}_2^T \mathbf{x} \\ \vdots \\ y_n = w_{n1}x_1 + w_{n2}x_2 + \dots + w_{nn}x_n = \mathbf{w}_n^T \mathbf{x} \end{cases} \quad (\text{C.1})$$

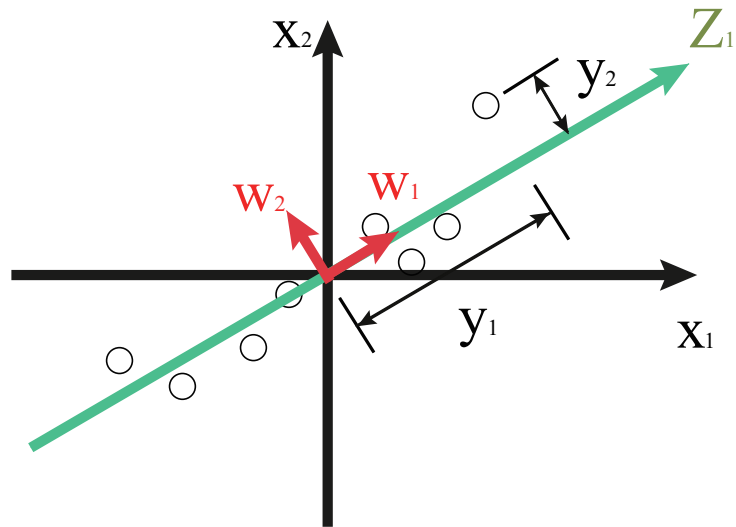


図 C.1: 主成分分析 (PCA) の概念図

但し,

$$\mathbf{w}_i^T \mathbf{w}_j = \begin{cases} 1 & (i = j) \\ 0 & (i \neq j) \end{cases} \quad (\text{C.2})$$

のため, w_i は正規直交基であることが分かる. ここで, 行列 $\mathbf{W} = [w_1, w_2, \dots, w_n]$ は変換行列とみなし, \mathbf{y} は式 (C.3) のように表記することができる.

$$\mathbf{y} = \mathbf{W}^T \mathbf{x} \quad (\text{C.3})$$

そのため, PCA とは分散が最大となる方向ベクトル w_1, w_2, \dots, w_n を求める問題である.

具体的な計算プロセスでは, 分散共分散もしくは相関係数を用いている. 主成分分析では相関係数そのものではなく「固有ベクトル」を算出するが, 情報の損失が少ない順に「第1主成分」「第2主成分」…と決めていく. 実際の計算プロセスでは, 図 C.2 のようにデータを基準化してから, 分散共分散行列もしくは相関行列を計算して, さらに相関行列の固有値と固有ベクトルを計算する.

固有値は分散共分散行列もしくは相関行列から求められ, 主成分分析では各主成分の分散に対応しており, 主成分が保持している情報の大きさを示している. 寄

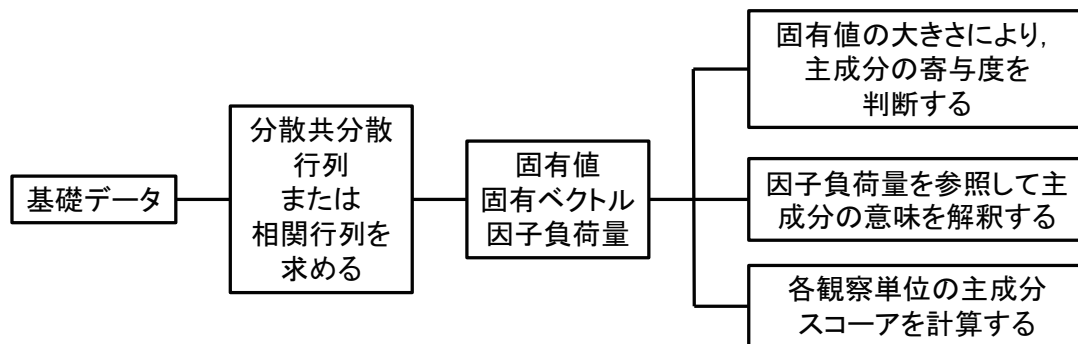


図 C.2: 主成分分析の手順

与率は、各主成分が持っている情報の大きさを比率 (%) で示したものであり、基礎データとして使った変数の持つ情報の何%を代表するかを表す量だと解釈できる。すなわち各主成分はデータ全体の情報のうち何%を説明できているのかを意味する。累積寄与率は第 n 主成分まで組み合わせて見ることで、何%かの情報をカバーすることができるかが分かり、次の式で定義される。

$$\eta = \frac{\sum_{j=1}^n \lambda_j}{\sum_{j=1}^m \lambda_j} \quad (\text{C.4})$$

ここで、 λ_j は各固有値である。 m は入力の次元数であり、 n は何番目までの主成分を採用するか番号である。

通常は「固有値が 1 以上」または「累積寄与率が 80 % 以上」までの主成分を採用し、それぞれを組み合わせ結果を解釈する。寄与率が 1 であれば、基礎データの情報が完全に総合指標で代表されることを意味する。実際の問題では 1 になることはまずないが、1 との近さが問題とされる。1 に近いほど、総合指標として有効性が高い。80 % という数値に特別な意味はなく、常にこの基準が妥当であるとは限らない。そのため、PCA の目的や適用対象に応じて採用する主成分数を適切に決定する必要がある。

また、固有値から固有ベクトルを求めることができ。主成分分析ではそれら固有ベクトルを主成分負荷量（因子負荷量）と呼び、各変数に対して係数として与えられている。この数値が大きいほど、各変数が主成分に与える影響力が大きくなる。

なる。それに基づいて得られた主成分が持つ意味を解釈することができるが、この部分は解釈のしかたによって変わってくる。

付録D 独立成分分析

近年、新しい多次元信号解析手法として独立成分分析法 (Independent Component Analysis : ICA) が注目されている。既存の理論としては、統計学における主成分分析 (PCA) の手法、そして projection pursuit と呼ばれる手法と密接な関係がある。前節で述べた従来の主成分分析法に比べると、独立成分分析法は2次以上のモーメントの非相関化を行うので、非直交的な成分の分離も可能である。特に projection pursuit と ICA とは手法自体にはそれほど差が無い。ただし、ICA が仮定する、「観測信号は独立成分の線形な重ね合わせである」というモデルは独自のものと言ってよい。この問題の簡単さ、理論の美しさが ICA の特徴の一つである。

既に生体信号処理など様々な分野に応用され、EEG データ [139] や fMRI データ [141] に対する結果では、今まで簡単には得られなかった特徴的な信号が独立性の仮定から導かれることが示され、大きな成果を挙げている。

広く研究が行なわれるようになった要因の一つには、簡単に使えるプログラムがインターネット上で配布されたことも挙げられる。特に有名なものは、J-F. Cardoso らの JADE (Joint Approximation Diagonalization of Eigen-matrices) と呼ばれるもの [142]、A. Hyvarinen らの Fast ICA と呼ばれるもの [143] である。その他にも様々なものが ICA central という web page からダウンロードできるようになっている [144]。これらはほとんどが無償で配布されており Matlab という数値計算用的高级言語 (商用ソフト) があればすぐに利用可能なプログラムである。

本研究は Matlab 中の EEGLab の独立成分分析の機能を用いて解析を行っている。以上のように、ICA はその問題の簡単さ、複数の問題で新しい成果が得られたこと、さらに幾つかのアルゴリズムがプログラムとして利用可能な形で配布されたことにより、様々な方面から注目が集まった。当然、実用レベルの応用が

期待されているが、現在も研究レベルのものが多い。これは、既存の ICA の解法が実用に対しては十分でないことを示している。

本節では、ICA の基礎理論について述べる。

信号源が次のベクトルで与えられるとする。

$$\mathbf{s}(t) = (s_1(t), \dots, s_n(t))^T, \quad t = 0, 1, 2, \dots \quad (\text{D.1})$$

ここで、 $\mathbf{s}(t)$ の各成分の平均は 0、各成分は互いに独立であるとする。 T は転置を表す。観測信号は、

$$\mathbf{x}(t) = (x_1(t), \dots, x_m(t))^T, \quad t = 0, 1, 2, \dots \quad (\text{D.2})$$

で表すものとする。 \mathbf{x} の次元 m と信号源の数 n は必ずしも一致しない。ここで $\mathbf{s}(t)$ と $\mathbf{x}(t)$ との間に、

$$\mathbf{x}(t) = A\mathbf{s}(t) \quad (\text{D.3})$$

という線型の関係を仮定する (図 D.1)。 A は $m \times n$ の実数行列である。ICA の目的は、 $\mathbf{s}(t)$ の独立性の仮定から A に関する知識を持たずに $\mathbf{x}(t)$ を n 個の独立な成分に分離することである。




図 D.1: 2 入力 2 出力の ICA の問題

$n \leq m$ であるならば解は存在する. すなわち, ある $n \times m$ の実数行列 W が存在し,

$$\mathbf{y}(t) = W\mathbf{x}(t) = W\mathbf{A}\mathbf{s}(t) \quad (\text{D.4})$$

によって互いに独立な $\mathbf{y}(t)$ を再構成できる. $WA = I$ (I は $n \times n$ の単位行列) となれば $\mathbf{y}(t)$ と $\mathbf{s}(t)$ は一致する. しかし, $\mathbf{y}(t)$ の成分の順番を入れ替えても独立性は保たれ, 各成分の大きさも独立性には影響しないことから $WA = PD$ (P は各列, 各行に一つだけ 1 を持つ $n \times n$ の行列, D は $n \times n$ の対角行列) となれば良いとする.

付録E 加算平均処理

加算平均処理とは、同じ測定を複数回行いその平均を求めることで、雑音成分を減少させるのと同時に特徴的な信号成分を抽出することのできる手法である [145]. 脳波においては、ある刺激に基づく電位の変動を抽出するために、常に発生している背景脳波や計測の度に混入するノイズを除去するために用いられる.

ある測定データを x とすると、 x を、

$$x = s + n \quad (\text{E.1})$$

と表すこととする. s は抽出したい信号成分、 n はノイズ成分である. ここで、式 (E.1) を時系列として考えると以下のようなになる.

$$x_i(k) = s_i(k) + n_i(k) \quad (\text{E.2})$$

i は測定番号 ($i = 1, 2, 3, \dots$), k は各測定データの標本 ($k = 0, 1, 2, \dots$) を表す. 例えば、 $x_i(k)$ は i 回目の測定データにおける k 番目の標本番号を示す. k は測定開始時点からの時刻と考えてさしつかえない.

ここで、毎回の測定開始時点を揃えて M 回の加算平均を行うと、加算平均後の波形 $x(k)$ は以下のようなになる.

$$\begin{aligned} x(k) &= \frac{1}{M} \sum_{i=1}^M x_i(k) \\ &= \frac{1}{M} \sum_{i=1}^M s_i(k) + \frac{1}{M} \sum_{i=1}^M n_i(k) \quad (k = 0, 1, 2, \dots) \end{aligned} \quad (\text{E.3})$$

ここで、加算平均に用いる信号は、

- 信号成分 $s_i(k)$ は, 同一時刻に同一パターンが出現する.
- ノイズ成分 $n_i(k)$ は, 測定の度にランダムに出現する.

であることを仮定するため, 式 (E.3) の右辺の信号成分は M 回の加算により振幅は M 倍となり, それを平均した値となる. すなわち, もとの振幅のままとなる.

しかし, ノイズ成分は統計的に処理しなければならない. 一般的に, ノイズの確率分布は平均 μ_n , 分散 σ_n^2 の正規分布として近似することができ, ある時刻 k におけるノイズ成分の M 回の加算平均後の値は,

$$\frac{1}{M} \sum_{i=1}^M n_i(k) \quad (\text{E.4})$$

となる. これは標本平均に相当する. 次に, すべての時刻 $k(k = 0, 1, 2, \dots)$ について M 回の加算平均を求め, その分布を考えると, 平均値 μ_n , 分散 σ_n^2/M の正規分布となる. ノイズ成分の振幅は通常, 分散の平方根で定義されるので, 加算平均後のノイズ成分の振幅は $1/\sqrt{M}$ となる.

例えば, 100 回の加算平均を行った場合, ノイズ成分を $1/\sqrt{10}$ にまで抑えることができ大幅な SN 比の改善に繋がる. 電圧利得の改善として表すと, $10 \log_{10} M$ [dB] である. 参考までに, 表 E.1 に加算平均回数と SN 比の改善をまとめたものを示す. なお, 本実験における加算平均回数は 40 回なので, ノイズ成分はおおよそ $1/6$ にまで抑えることができる.

表 E.1: 加算平均による SN 比の改善

加算回数 M [回]	SN 比の改善	
	\sqrt{M} [倍]	$10 \log_{10} M$ [dB]
10	3.2	10
20	4.5	13
40	6.3	16
50	7.1	17
60	7.7	17.8
70	8.4	18.4
80	8.9	19.0
90	9.5	19.5
100	10.0	20

付録F 表面筋電信号の一般処理 手法

F.1 整流平滑化

振幅の絶対値を求めることを整流化 (rectification), 整流化した波形を整流波 (rectified wave) という。整流波を一定の時間範囲で積分して平滑化したものが整流平滑化 (Average Rectified value: 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。ARV を式で書くと, 以下のようになる [68].

$$V_{ARV}(t) = \frac{1}{N} \sum_{i=1}^N |E_i(t)| \quad (\text{F.1})$$

実際に計測した筋電位に ARV を用いると図 F.1 のようになる。

F.2 移動平均法

波形から実験現象を解釈する際にノイズがあると分かり難い。例えばノイズが計測波形では目立たなくても, 微分や 2 回微分, 又は差動波形を求めるとノイズが顕著になるため, ノイズ除去を行う必要がある。以下に代表的な 2 つの例を示す。

◆ランダムノイズ (高周波振動を含む) であれば, 真値に対して誤差を含むデータ点が上下に存在する確率は等しいという性質を持つ。従って, 前後の時間におけるデータを加算して平均すると真値に近づく。これは移動平均法 (Moving Averages Method) と呼ばれている。手軽にノイズの除去の処理ができる。




図 F.1: ARV 使用前後

◆複雑な波形も多数の波の和で成り立っている。従って、周波数帯域に分離して不要と思える周波数を取り去った後に再合成可能であれば、真の波形に近づく。これは離散フーリエ解析・逆解析（Discrete Fourier Transform と Inverse Discrete Fourier Transform）と呼ばれている。

移動平均処理を行うと波形の急激な変化に追従できずにピークをなだらかにすることがあるため、処理後のピーク値や波形変化の評価には注意が必要となる。ノイズを含む波形に移動平均処理を加えてノイズを除去する作業は容易なので、波形処理に広く用いられる。

しかしながら、 n 点の移動平均を行ったとして、

- (1) どの程度のローパスフィルターに相当するのか
- (2) 周波数特性がどの様に変化するのか

が不明であるため、今回正弦波に移動平均処理を施して、基本的な特性変化を検討する。

標本化間隔 Δt 秒、M点の移動平均の連続時間 τ 秒 $\rightarrow \tau = M \cdot \Delta t$ のとき、周波数 f Hz の正弦波アナログ信号 $x(t) = \sin(2\pi ft)$ を τ 秒移動平均したときの出力信号は以下ようになる。

$$y^\tau(t) = \frac{1}{\tau} \int_{t-\frac{\tau}{2}}^{t+\frac{\tau}{2}} x(t) dt \quad (\text{F.2})$$

移動平均の結果は

$$y^\tau(t) = \frac{1}{\tau} \int_{t-\frac{\tau}{2}}^{t+\frac{\tau}{2}} \sin(2\pi ft) dt = \frac{1}{2\pi f\tau} \sqrt{2(1 - \cos(2\pi f\tau))} \cdot \sin(2\pi ft) \quad (\text{F.3})$$

となる。振幅は $\frac{1}{2\pi f\tau} \sqrt{2(1 - \cos(2\pi f\tau))}$ となり、位相に変化はない。すなわち移動平均後の波形は、 f, τ を変数（周波数もしくは移動平均の連続時間）とした振幅量の減衰によって実現される。

次に振幅特性と周波数の関係（周波数特性）について説明する。

振幅は $\frac{1}{2\pi f\tau} \sqrt{2(1 - \cos(2\pi f\tau))}$ となり、移動平均時間 τ が一定のとき、周波数 f が大きくなると減衰が大きくなる。また周波数 f が一定のとき、移動平均時間 τ が長くなると減衰が大きくなる。これは低域通過フィルタ特性であるため、移動平均法はローパスフィルタと考えられる。

また平均化の個数と遮断周波数について検討する。遮断周波数 f_c （3dBの減衰量となる周波数）はフィルタの特性を表す尺度である。遮断周波数では、振幅は $\frac{1}{\sqrt{2}}$ となるので、すなわち以下ようになる。

$$\frac{1}{2\pi f_c \tau} \sqrt{2(1 - \cos(2\pi f_c \tau))} = \frac{1}{\sqrt{2}} \quad (\text{F.4})$$

この時、遮断周波数 f_c とするための τ は $\tau = 0.443/f_c$ になる。

離散の場合では、 $\tau = M \cdot \Delta t$ より、 $M = 0.443/(f_c \cdot \Delta t)$ になる。またサンプリング周期 $f_s = 1/\Delta t$ の時、 $M = 0.443f_s/f_c$ になる。すなわち、希望する遮

断周波数が f_c Hz の時に $M = 0.443/(f_c \cdot \Delta t)$ より移動平均の個数 M を求めることができる。

本研究では、筋電の波形を ARV 処理する時に、全波整流の後、移動平均を用いてデータ処理を行う。

付録G 前処理による独立成分分析 の結果の違いの検討

ICA は、計測されたすべてのデータが同じ状態のものであると仮定している。たとえば、EEG の記録中に P300 タスクを実行する場合、すべてのデータが P300 タスクに関連していると仮定している。したがって、計測された脳波の連続データに対して、データを対象のイベントに分割 (Epoch) してから ICA を実行する方が望ましい。この ICA とエポック (Epoch) の処理順番による違いに関する検討を本節で述べる。

瞬きなどは間違いなく実験タスクとは関係がなく、脳とも関係ない。ただし記録中にまばたきが頻繁に発生する場合は、定常性の一部になる。また試行中、または試行の間でタスクに関連しない (イベントに関連しない) 意識あるいはランダムな思考は、ICA で処理するための定常性の仮定を妨げる可能性がある。なぜなら、そのような EEG 信号は繰り返しパターンや同様の統計的特性 (確率密度関数など) が経時的に存在しない可能性がある。したがって、ERP パラダイムは大規模な刺激/応答の同じまたは類似のタイプの繰り返しによって EEG データの定常性を強化するため、ERP パラダイムを使用することは、実際に ICA を使用するにあたって非常に良い理由となる。ICA にとって最も理想的なのは、準定常状態応答である。

第 8 章の結果からを考えると、信号の大きな振幅は ICA のデータの定常性よりも ICA の「注意を引く」ものである。単一のイベントの EEG 応答の振幅は非常に大きくなると、ICA の注意を引き付け、それを分解するために複数の独立成分 (IC) を無駄にさせることが何度もあった。したがって、明らかに高振幅信号は、

通常の振幅で安定した信号よりも，ICA にとって非常に強力な注意を引くものである．これが，ICA の前のデータクリーニングが重要である理由である（特にスパイク，ドリフトな信号）．また，これも ICA がまばたきを分解するのに非常に優れている理由を説明できる．まばたきのソースの位置は固定されており，頭皮上での電位分布の中で局在的かつ振幅は大きいためであり，第 8 章の結果はこれを十分に証明できている．

したがって，データクリーニングやエポックの順番による ICA の違いを検討し，処理の流れを定着する．

G.1 ハイパスフィルタによる相違の検討

高振幅信号は，通常の振幅で安定した信号よりも，ICA にとって非常に強力な注意を引くものであるため，ICA の前にハイパスフィルタによるデータクリーニングが必要となる．そして，遮断周波数が違う四つ（0 Hz，0.1 Hz，1 Hz，2 Hz）のフィルタで処理してから独立成分分析した結果は図 G.1 に示している．

図の中に各結果の上の部分は各成分の脳地図となり，下の部分は ICLable による推測された各成分の確率である．ICLabel の結果を見ると，違う遮断周波数のフィルタによって判断の結果が異なる．例えば遮断周波数が 2 Hz のハイパスフィルタの ICA の結果の中で，IC3 は脳波成分なのに，その他の成分と認識された．他の成分を確認すると微小な違いしかないので，今回の計測環境ではハイパスフィルタを使わずに，直接に ICA で処理する．これにより，成分の識別度が高まる上，フィルタ導入による遅延もなく，信号のタイムロックの特性がもっと正確に得られる．

G.2 ICA とエポックの処理順番による違いの検討

通常 ICA でデータ処理する時に，連続データで ICA を実行するより，データを対象のイベントに与えて（エポックさせて）から，ICA を実行する方が望ましいことが分かったが，仮にエポックを先に抽出した場合，データの連続性がなくな

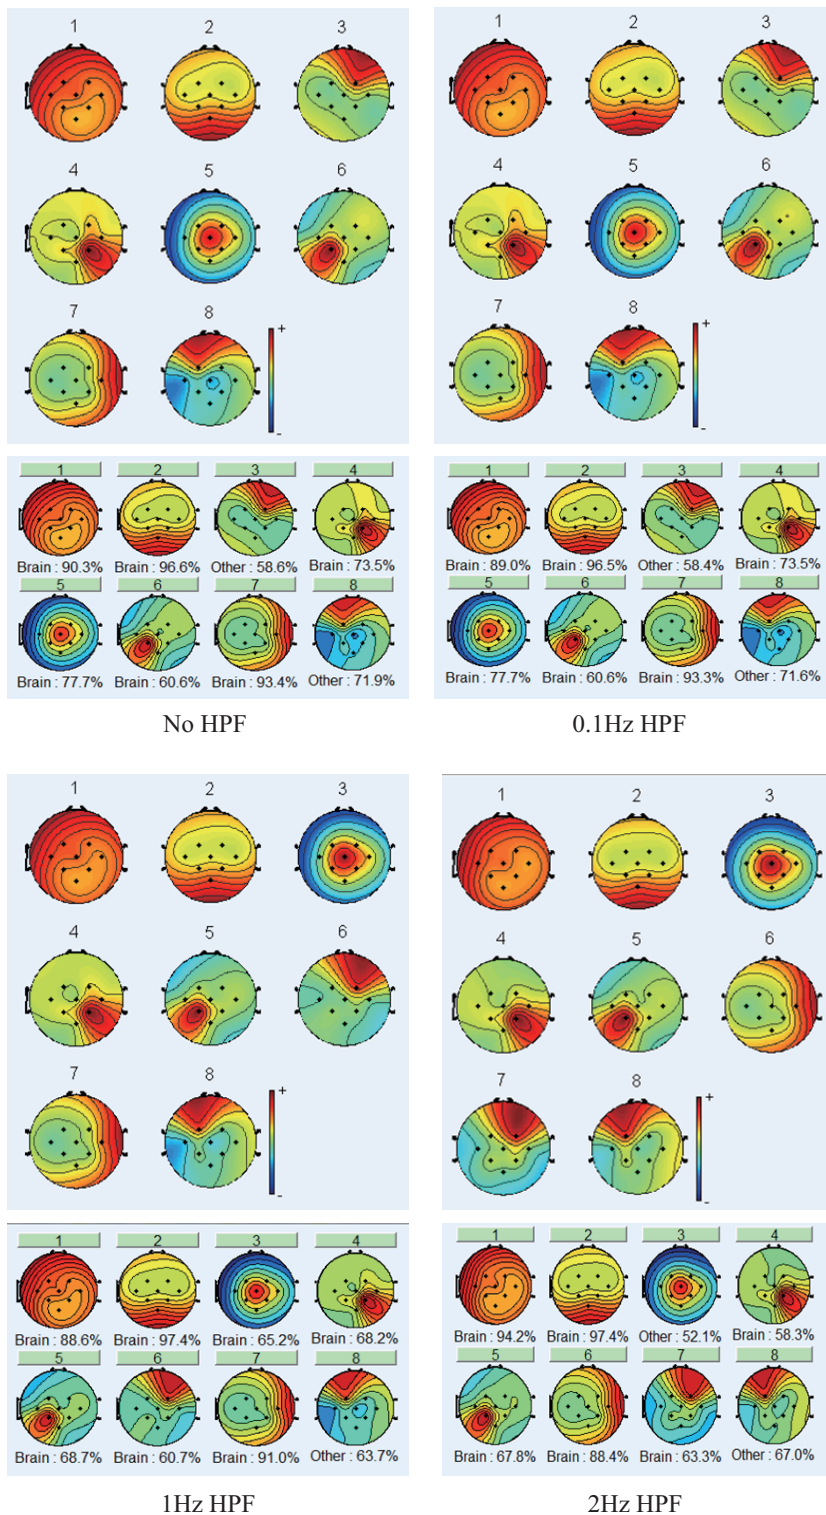
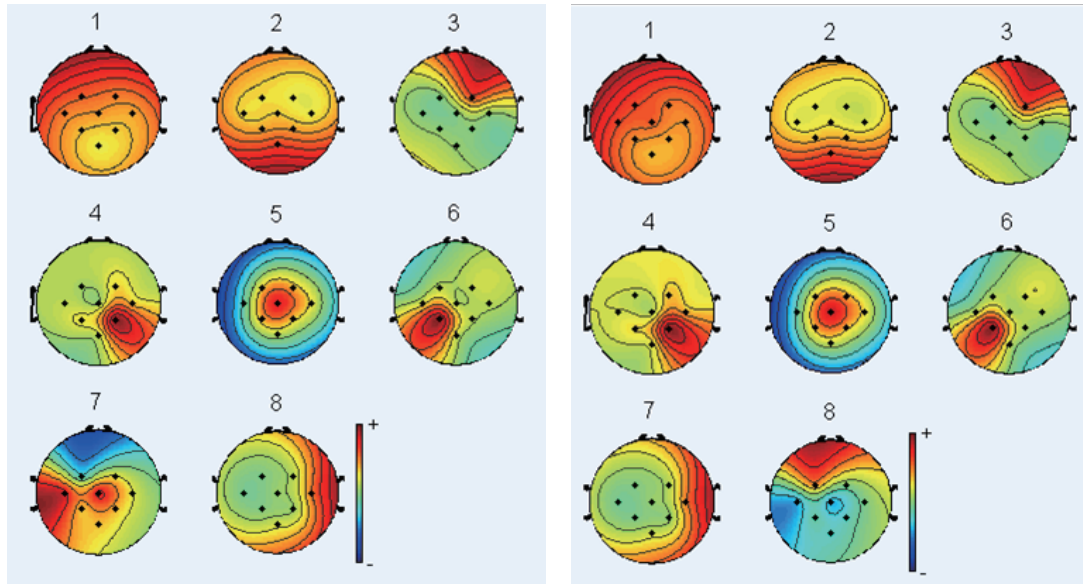


図 G.1: ハイパスフィルタによる ICA 結果の違い

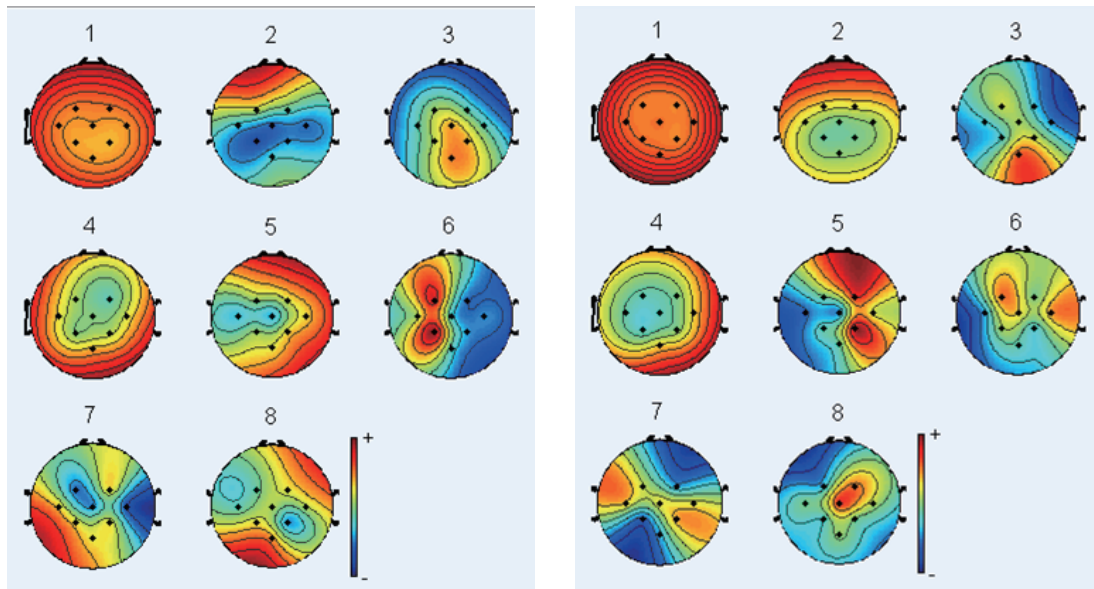
る。この処理の順番による違いがあるか、どれぐらいがあるのを解明するため、検討を行った。処理結果を図 G.2 に示している。左の図は ICA を先に処理してから、5 秒間の Epoch を抽出した結果となり、右側は先に 5 秒間の Epoch を抽出してから、Epoch のデータに対して ICA 処理を行った結果である。これらの結果を見ると、大きな差異は見られなかった。成分 7 と 8 の成分がただ反転しただけである。実験のデータに対して、5 秒× 40 セットで、200 秒間のデータ量となり、記録されたすべてのデータである 500 秒の半分もないため、500 秒のデータの半分以上はノイズや安静時のデータとなる。

Epoch を先にしてから ICA を行うのは、ノイズ成分はほとんど削除され、脳波信号をより分離できた状況になる。ただしノイズ成分が大きく削除されたため、その成分の分解や識別は少し難しくなる。最悪の場合はノイズ成分が分離できない可能性があり、ノイズ成分と特徴成分が混ざっている状態になった。図 G.3 のように成分の分布や特性が大きく違う結果にもなり得る。

したがって、ノイズ成分を除去するため、先に ICA してから Epoch を行う方が、きれいなデータが得られる。今回は訓練による運動時の脳波の特徴に注目するので、先に Epoch をしてから ICA を行った。



ICA first epoch first
 図 G.2: ICA とエポックの処理順番による結果



ICA first epoch first
 図 G.3: ICA とエポックの処理順番による結果：成分がかなり違う場合