

平成 30 年度 博士論文



筋電義手制御のための  
信号特徴の時変性を考慮した  
ビッグデータを用いた手指動作推定法

指導教員 加藤 龍 准教授

横浜国立大学大学院 工学府  
システム統合工学専攻 機械システム工学コース  
学籍番号 16SB103

山野井 佑介



# Abstract

上肢切断者の上肢機能を代替するものとして筋電義手というものが存在する．筋電義手は人が筋肉を収縮させる際に筋表面に生じる筋電位という微弱な電位を用いて装着者の動作意図を推定し動作する義手である．装飾義手と異なり装着者の意図に基づいて物体を把持する等のことが行えるが，筋電位は微弱な生体信号であり不安定で，日を跨いだり義手を付け外ししたりすると筋電位の信号特性が変化してしまう時変性の問題が存在する．

これに対して既存の筋電義手は時変性の影響を受けにくい単純な筋電特徴を用いるか機械学習手法を用いて義手を装着するたびに筋電位と動作の関係をモデル化するか大きく2つ方法をとってきた．しかし，前者は筋電位から得られる情報が不足してしまうため制御可能な運動自由度が限られてしまい健常の手とのギャップが大きいという問題，後者は制御可能な運動自由度を増やすほど学習コストが増大して実現性が乏しくなり，学習時間等を実現可能な範囲内に抑えようとするすると制御可能な運動自由度が減少してしまうという問題があった．

しかし，近年，計算資源の向上と新しい機械学習手法が登場しており大規模なデータを用いて汎化性の高い識別が行えるようになってきた．大規模な筋電位を収集し，筋電位の信号特性の時変性を吸収するような学習を行うことによって，義手の付け外しによる再学習を不要にできるのではないかと考えた．

そこで本研究では義手の装着し直しによる再学習が不要であり，制御可能な運動自由度の多い実用的な筋電義手制御手法の実現を目的とした．

第2章では関連研究と予備実験から本研究が扱う問題領域を定義し，第1章で定めた目標を達成するための評価基準として時変性が吸収できること・高い運動自由度が実現できること・実用性が高いことの3つを設定し詳細について記述した．また，この問題設定に対して大規模なデータを用いたアプローチについて述べた．

第3章では大規模な筋電位を用いた動作意図抽出法として、把持姿勢と把持力の両方をパターン化して扱うパターン認識型と、把持姿勢はパターン認識によって識別し、把持力は線形回帰によって推定する併用型の2つの制御方式に関してそれぞれ Deep Convolutional Neural Network (DCNN) と Selective Linear Regression Model (SLRM) の2つ手法の提案を行った。また、汎化性の高い識別器を構築するための学習データの収集とデータセットの構築方法に関して述べた。

第4章ではハイパーパラメータが識別率に対してどのような影響を与えるのか調査し最適化を行った。白色化を行ったところ、あまり大きな差はみられなかったが白色化を行わない方がわずかに識別率が高かった。筋電位の場合は相対的な違いが明確化されるよりも絶対的な値の方が情報を有しているためと思われる。また、学習日数に関してはデータ量が増えるごとに識別率は上昇し安定したが、だんだんと上昇が少なくなる傾向がみられた。学習率を高くし過ぎると発散して毎学習が収束しなくなってしまった。発散を検知して学習率を自動で変更すると学習が安定しやすかった。ドロップアウト率は50%以上にしてしまうと識別率が低下してしまい、0%が最も識別率が高かった。ミニバッチサイズは大きくすると汎化性が向上するが、大きくし過ぎると過学習により汎化性が低下してしまった。

第5章では Offline 解析として提案手法の DCNN, SLRM, そして従来手法であり3層の Artificial Neural Network (ANN) に対して大規模データを適用したものを義手の付け外しを含めた汎化性や学習時間の評価を行った。義手の付け外しによって識別率が低下することを確認した。DCNN と SLRM は従来手法と比較して義手の付け外しによる識別率の低下が抑制できていることが確認された。DCNN を用いて義手の付け外しを含む識別を行った際、把持力を考慮せずに9姿勢識別を行った場合は健常者の被験者平均で約91%、把持力を考慮して25動作識別を行った場合には約84%の識別率で識別が行えた。SLRM を用いて義手の付け外しを含む識別を行った際には把持力を連続量として推定しながら健常者の被験者平均で約84%の識別率で識別が行えた。このことから達成目標とほぼ同等の精度で筋電位の信号特性の時変性を吸収しつつ、多くの運動自由度を制御できることを示した。また、人工的にノイズを混入して評価を行い DCNN と SLRM が ANN と比較して汎化性が高いことを確認した。さらに、学習時間の評価を行い、現実的な時間で学習が行えていることを確認した。

第6章では各手法を実際に義手に実装し、Online で義手を用いて実使用環境下でタスクを行った際のタスクの達成度によって評価を行った。ノートパソコンによって10fps以上で制御可能であることを確認し、義手の Online 化と携帯化が行えていることを確認した。物体把持タスクを行い DCNN は90%、SLRM は81%の達成度でタス

クが行い，実使用環境下でも安定して制御可能であることを示した．また，把持速度に関する検証を行い，把持速度が可変となることによって把持性能が向上すること，提案手法で把持速度を適切に制御できることを示した．

以上より，義手の装着し直しによる再学習が不要であり，制御可能な運動自由度が多い実用的な筋電義手制御手法の実現という目標が達成できたことが示された．



# 目次

---

Abstract.....	3
目次 .....	7
第 1 章 序論 .....	11
1.1 義手への要求と現状 .....	12
1.2 筋電義手の制御 .....	15
1.3 筋電位の信号特性 .....	17
1.4 先行研究 .....	19
1.4.1 閾値型・単回帰型 .....	20
1.4.2 切り替え制御型 .....	20
1.4.3 パターン認識型 .....	21
1.4.4 多重回帰型 .....	22
1.4.5 併用型 .....	23
1.4.6 学習型制御における 2 つのアプローチ .....	23
1.5 研究目的 .....	26
1.6 本論文の構成 .....	27
第 2 章 問題設定: 時変性の吸収と実現すべき上肢機能 .....	29
2.1 はじめに .....	30
2.2 筋電位の信号特性の時変性 .....	31
2.3 学習型制御手法における動作意図抽出 .....	36
2.4 筋電センサ貼付位置 .....	39
2.5 動作生成 .....	41
2.6 推定すべき手指・手首動作 .....	43
2.7 推定把持力 .....	45
2.7.1 パターン認識型での把持力制御 .....	45
2.7.2 併用型での把持力制御 .....	45

---

2.8 識別率の定義 .....	47
2.9 問題設定のまとめ .....	48
2.10 アプローチと本研究の独創性 .....	50
2.11 おわりに .....	53
第3章 ビッグデータを用いた動作意図抽出法 .....	55
3.1 はじめに .....	56
3.2 変数定義 .....	57
3.3 学習型動作意図抽出法の流れと2つの提案手法 .....	59
3.4 Selective Linear Regression Model .....	62
3.4.1 特徴抽出 .....	64
3.4.2 学習 .....	66
3.4.3 識別 .....	67
3.5 Deep Convolutional Neural Network .....	72
3.5.1 特徴抽出 .....	72
3.5.2 DCNN のデータ構造 .....	75
3.5.1 学習部と識別部 .....	76
3.5.2 プーリング層 .....	79
3.5.3 畳み込み層 .....	80
3.5.4 全結合層 .....	81
3.6 Artificial Neural Network .....	83
3.7 学習データの構築方法 .....	84
3.8 おわりに .....	88
第4章 深層学習に関連するハイパーパラメータの決定 .....	89
4.1 はじめに .....	90
4.2 探索すべきハイパーパラメータ .....	91
4.3 学習データ .....	93
4.3.1 白色化 .....	93
4.3.2 学習日数 .....	94
4.4 ネットワーク構造 .....	96
4.4.1 学習率 .....	96
4.4.2 ドロップアウト率 .....	97
4.4.3 ミニバッチサイズ .....	99
4.4.4 特徴抽出フレームのサイズによる識別率と即時性 .....	101
4.5 まとめ .....	104
4.6 おわりに .....	106
第5章 推定精度と汎化性の評価 .....	107



5.1 はじめに .....	108
5.2 義手の付け外しによる時変性に対するノイズ耐性の評価 .....	109
5.2.1 短期評価 .....	109
5.2.2 長期評価 .....	113
5.3 一般的なノイズ耐性の評価 .....	117
5.4 学習時間の評価 .....	120
5.5 まとめ .....	122
5.6 おわりに .....	123
第6章 筋電義手への適用と実使用環境下での評価 .....	125
6.1 はじめに .....	126
6.2 筋電義手への実装 .....	127
6.3 平滑化フィルタの検討 .....	129
6.4 3種の把持での物体把持タスク .....	130
6.4.1 実験タスク・評価方法 .....	130
6.4.2 結果及び考察 .....	132
6.5 把持速度の制御 .....	135
6.6 まとめ .....	137
6.7 おわりに .....	138
第7章 結論 .....	139
7.1 結論 .....	140
7.2 今後の展望 .....	142
謝辞 .....	143
参考文献 .....	145
和文文献 .....	146
英文文献 .....	147
研究業績 .....	151
学術雑誌 .....	152
国際会議 .....	152
国内発表 .....	153
付録 .....	157
A. 筋電位の計測 .....	158

---



# 第1章 序論

---

1.1 義手への要求と現状 .....	12
1.2 筋電義手の制御 .....	15
1.3 筋電位の信号特性 .....	17
1.4 先行研究 .....	19
1.4.1 閾値型・単回帰型 .....	20
1.4.2 切り替え制御型 .....	20
1.4.3 パターン認識型 .....	21
1.4.4 多重回帰型 .....	22
1.4.5 併用型 .....	23
1.4.6 学習型制御における 2 つのアプローチ .....	23
1.5 研究目的 .....	26
1.6 本論文の構成 .....	27

---

### 1.1 義手への要求と現状

厚生労働省によると我が国の肢体不自由者は59万200人であり、そのうち上肢不自由者は23万9300人である[厚生労働省 2013]。上肢不自由者は上肢機能の喪失と欠損とに分けられるが、上肢切断者は多くの場合、上肢の代替として義手を用いる。義手には装飾義手・作業用義手・能動義手・電動義手の4種類が存在する。

装飾義手は上肢の外観を模して作られている義手であり、4種類の義手の中で最も多く使用されている義手である。外観の見た目は健常の手と見分けがつかないほど精巧なものも存在し、装飾性は極めて高いが、義手を動かすことは不可能であり、物体を把持するなどの健常の手の上肢機能を代替することはできない。

作業用義手は外観の見た目よりも機能性と頑丈さを重視して作られている義手であり、フックやハンマーなどの手先具を付け替えることによって様々な作業を行うことができる。ただし、作業に合わせてその都度、手先具を交換しなければならず手間がかかることや手先具を装着者の意図に基づいて能動的に動かすことはできず、反対側の手で補助をしなければ物体の把持などを行うことはできない。また、外観が健常の手とは大きく異なっており、健常の手と異なることが分かってしまうため装着者が装着を望まないことが多い。

能動義手は体幹の動きをハーネスなどを利用して手の開閉や肘の屈曲などの動作に変換し動かすことができる義手である。装着者の動作意図に基づいて義手を開閉できるため、反対側の手を補助として用いずに物体の把持などが実現可能である。しかしながら、体幹の動きなど余剰な動作を必要とするため操作しにくいといった問題や、義手以外の動作を阻害しないためには義手の動作に用いることのできる動作が限られ、実現できる義手の動作の自由度が少ないといった問題がある。また、少ない自由度でより多くの把持を実現するために装飾性よりも機能性を重視し、手先具がフック型等になっている義手が多く、健常の手とは外観が異なるという問題が存在する。

電動義手はモータを用いて把持などの運動を実現している義手である。電動義手はスイッチ等も含めて様々な入力を用いることが試みられているが、中でも筋電位と呼ばれる筋肉を収縮させる際に発生する微弱な電位を用いて装着者の動作意図を推定しそれに基づいて義手の運動を実現する筋電義手というもの

が存在し、切断した上腕の断端に残存している筋肉を用いて動作するため余剰な動作を必要としないこと、複数の筋肉の筋電位を計測することにより多くの動作が実現可能なこと、外観が健常の手を模しており 5 指を有し駆動可能であるため他の義手よりも健常の手に近いと考えられていることなどの理由により注目を集めている。

かつては義手を用いることの主目的は外観を回復することに最も重点が置かれており、装飾義手が多く開発されており、一部、仕事等で恒常的に特定の上肢機能が必要となる場合に限り作業用義手が開発されてきた。しかし、近年は義手の外観のみでなく運動機能も義手によって回復し日常的に用いることに主眼を置いて義手の研究・開発が多く行われている。特に、ロボット技術の発展に伴って、近年、電動義手が大きく発展しており、義手の機械的な要素を電気電子化することによってコンパクトにより多くのことができるようになってきている。

さらに、近年では上肢切断者の機能を回復するのみにとどまらず、義手によって健常の手以上の能力を実現しようとする上肢機能の強化や拡張肢などの健常の人間には存在しない機能を付与する上肢機能の拡張なども盛んに研究されている。

Sasaki らはユーザの腰に装着した 2 本のロボットアームを左右それぞれの足に対応図けることによってロボットアームの移動と物体の把持を実現しており、ユーザ自身の手と協調作業をすることによって身体が単独ではできない作業を実現している。[Sasaki 2017]

2016 年から 4 年おきに **Cyathlon** という最先端のアシスト技術を身にまとった選手たちによるスポーツの祭典が行われている。主催者の提議によれば **Cyathlon** とはロボット工学技術を含む高度なアシスティブデバイスを使う障害者の競技大会であり、アシスト技術の開発の促進を目的としている。パラリンピックとは異なり、人の身体能力よりもアシスト技術の進歩に主眼を置いており、6 つある競技内容の内の一つに義手の制御競技が存在する。[栗田 2018]

研究レベルでは義手の機能は上肢の外観を補うことから、運動機能も補えるものへとその代替範囲を広げているが、現実としては健常の手とのギャップは大きい。一例としてパラリンピックの競技種目を見てみると、下肢の障害者は健常の足の代替として義足を陸上競技の短距離走などで用いて競技を行うが、アーチェリーや卓球など上肢を用いる競技では義手を用いて競技せず口や足など

を代替として用いる．義手と義足の最も大きな違いはどの程度装着者の動作意図を反映する必要があるかということである．下肢は歩き始め・歩き終わり・方向転換を除いて周期運動によってかなり健常の足に近い機能を実現できるが，上肢の場合は制御すべき自由度も多く，細かい作業行うために装着者からより細かく多くの動作意図を抽出する必要がある．

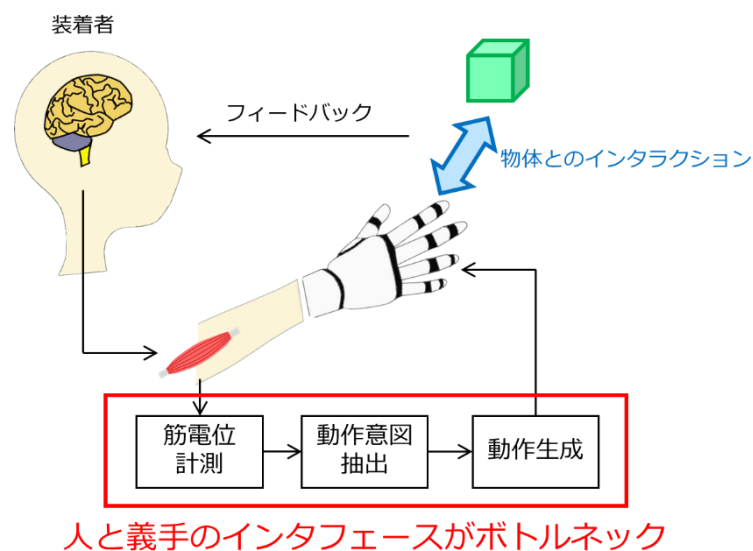
上記のように義手は時代を経るにしたがって見た目の回復から運動機能の回復へとその要求が変化してきており，また，そこに健常の手との間の最も大きなギャップが存在すると考えられ，健常の手のように多くの運動自由度を制御できるようにするために，装着者の運動意図をより多く正確に義手に伝えられるようになることが重要であるといえる．

## 1.2 筋電義手の制御

前述のように筋電義手は従来の義手と比較して装着者の動作意図に基づいて制御できるという点から上肢切断者から装着が望まれている。筋電義手の制御の概要を Figure 1.1 に示す。筋電義手は人に装着して使用するロボットであり、人と協調して動作する必要がある。そのため、必然的に装着者が制御のループに組み込まれることとなる。

装着者が手を動かそうとした際に制御信号が神経を伝って筋肉に伝達し筋表面に微弱な電位が発生し、それによって筋肉が収縮する。この筋表面を伝わる電位を筋電位といい、筋電センサを用いることによって皮膚表面から計測することが可能である。皮膚表面から計測した筋電位を特に表面筋電位と呼び、以後、筋電位という表現は表面筋電位を指す。

筋電義手の制御は筋電位を計測する「筋電位計測」、計測した筋電位から装着者が何をしたいのか判断する「動作意図抽出」、判断した動作意図に基づいて具体的にアクチュエータの制御量を決定する「動作生成」の3つからなる。この中でも動作意図抽出は人に装着して制御するロボット特有の難しい問題である。



人と義手のインタフェースがボトルネック

Figure 1.1 義手の制御

筋電義手は筋電位に基づいて手指の動作を実現するが、物体とインタラクションを行うためには、残存する上肢の動きによるアプローチや対側の手と協調する必要がある、それによってはじめて物体の把持・操作が可能となる。また、物体とのインタラクションを視覚等から装着者が観測することによって装着者は残存する上肢によるアプローチや対側の手の動きを制御し、また、筋電位自体も状況に合わせて装着者が操作する。それによって義手の動きが制御され人を含めた間接的な閉ループとして制御系が確立される。

前述のとおり手は人の身体の中でも操作すべき運動自由度がかなり多い部位であり、それらを筋電位から制御しなければならない。また、人と協調する必要があることからこれらの多くの運動自由度を瞬時に制御できなければならず、それを実現する人と義手とのインタフェースが筋電義手におけるもっとも重要な要素の一つであるといえる。



## 1.3 筋電位の信号特性

筋電センサにより計測した筋電位の波形を **Figure 1.2** に示す．この筋電位は把持力を連続的に変化させるタスクを行っている際の物であり，横軸が時間，縦軸が電位の強度を表す．筋電位は筋電センサによってフィルタリング処理されノイズが除去されており，約 8 万倍程度に増幅されている．

筋電位は中枢から神経を伝って流れてきた制御信号が筋表面に伝達し，筋収縮を誘発させる電位である．筋電位は神経信号であるためインパルス信号が重畳した微弱な信号として計測される．

筋電位の振幅強度と筋収縮量には正の相関があることが知られている．これは H・P・ボウディッチが提唱した「全か無かの法則」に基づくものであり [Cannon 1924]，各筋繊維はそれぞれ閾値を持っており，閾値を超える筋電位が流れたときに限って筋収縮を行うというものである．この閾値は筋繊維によって異なっており大きい筋繊維ほど大きな筋電位が流れないと収縮しない傾向がある．つまり，筋電位の振幅強度が小さいと少数の小さい筋繊維のみ筋収縮を誘発し，筋電位の振幅強度が大きいと大きいものまで含めた多くの筋繊維が筋収縮するため，総体として筋電位の振幅強度と筋収縮量，またそれに基づく把持力と相関がみられる．




Figure 1.2 表面筋電位の波形

また、行う手指動作によって収縮する筋が異なるため複数個所で筋電位を計測することによって把持姿勢に関する情報を得ることができる。また、表面筋電位は筋電位が筋表面に発生してから電極で計測されるまでに減衰が起こるため、周波数特性に変化が現れる。そのため皮膚表面から離れた奥深くの筋から発せられた筋ほど低周波の筋電位として計測できる。これらは重畳して計測されるため、複数個所に筋電センサを貼付し、周波数解析を行うことによってどの筋がどの程度収縮しているのかを計測することができる。

上述のように筋電位は把持力や把持姿勢など装着者の動作意図に関する情報を多く含んでいる。しかし、同時に筋電位は微弱な生体信号であるため意図しない要因によっても変化してしまう。具体的には電磁波などのノイズ、発汗、疲労、センサの接触状態などである。

義手は日常生活において長時間使用するものであるが、入浴や就寝時など頻繁に義手を外す必要がある。筋電センサを外してしまうと前述のような意図しない要因によって筋電位が変化してしまう。特に影響が大きいのは装着者の皮膚の状態やセンサの接触状態などである。このように時間が経ってしまうことによって筋電位の信号特性が変化してしまうことを本論文では「筋電位の信号特性の時変性」と呼ぶ。

筋電位は動作意図に関する多くの情報を含んでいるが、微弱でノイズに弱い信号であり、個の筋電位の信号特性の時変性によってその特性が変えられてしまうと動作意図抽出が難しくなってしまうという問題が存在する。そのため商用的に実用化されている筋電義手は筋電位に含まれる情報を満足に活かした動作意図抽出が行えておらず、その機能が制限されてしまっている。

## 1.4 先行研究

筋電義手の制御手法を大きく 6 つに分類し Table 1.1 に示す. ここで赤背景は主に単自由度義手を対象とした制御手法であり, 青背景は主に多自由度義手を対象とした制御手法である.

まず, 筋電義手の制御手法を分類する要素として非学習型か学習型かという観点がある. 非学習型の制御とは筋電位の発現の有無や振幅強度情報に着目して, それらに対してゲインや閾値を用いて制御を行う手法である. これらの制御手法は筋電位の発現の有無や強弱情報を用いていることから, ノイズなどの影響を受けにくいというメリットがあるが, 使用できる情報が限られているため実現可能な動作が少ない. そのため, ハンドの開閉のみが制御可能な単自由度義手の制御によく用いられる. また, ノイズの影響を受けにくい信号特徴を用いていることから, 義手を装着してそのまますぐに使用できるといったメリットもある. 商用的に実用化されている義手のほとんどが非学習型の制御手法を用いている.

それに対して学習型の制御手法は筋電位から抽出した特徴量を入力として機械学習を用いて筋電位と動作との関係性をモデル化し制御する手法のことである. 健常の手のような多くの運動自由度を制御しようとする, チューニングすべきパラメータが膨大になってしまうため, 機械学習を用いてこれらを自動的に行う. そのため多自由度義手の制御に主に用いられる. 入力としては筋電位の発現の有無や強弱に限らず, より細かな筋電位情報も活用するため, 非学習型と比較して多くの動作が実現可能である. しかしながら, 前述のとおり, 筋電位は微弱な生体信号であるため, センサを一度外してしまうと筋電位の信号特性が変わってしまう. そのため, 学習型の制御手法を用いた筋電義手は義手を装着後, 筋電位と動作との関係性をモデル化するための学習を行う必要がある.

Table 1.1 制御方法と制御対象

	非学習型	学習型
離散	閾値型	パターン認識型
連続	単回帰型	多重回帰型
離散+連続	切り替え制御型	併用型

まとめると非学習型の制御ではゲインや閾値などのパラメータを手動で設定しているのに対して、学習型の制御ではより多自由度の義手の制御を目的とするとチューニングすべきパラメータが膨大になってしまうため、それを機械学習手法を用いて自動的にチューニングする。学習型の制御の方が制御可能な運動自由度が多いがその分ノイズに弱く、義手を装着するたびに時間をかけて筋電位と動作の関係性をモデル化しなければならない。

非学習型か学習型かという観点に加えて制御対象が離散量か連続量かまたはそれら 2 つを組み合わせたものかによって分類することができる。それぞれの制御方式について以下に詳細を述べる。

### 1.4.1 閾値型・単回帰型

閾値型制御とは筋電位の振幅強度に閾値を設けてそれによってハンドの開閉の 2 状態を制御する手法である。ハンドの開閉の 1 つの運動自由度しか有しない単自由度義手の制御手法として用いられる。また、単回帰型制御とは振幅強度にゲインを掛けた値を用いてハンドの開き角や開閉の動作速度と対応付ける制御手法である。筋収縮量に応じた筋電位の発現の有無や強弱の情報は他の要素による筋電位の変化と比較してオーダが大きくノイズに埋もれにくい情報のため安定した制御を行いやすい。一方で得られる情報量が限られているため、実現可能な動作数が少なく、多自由度義手で用いられることはない。

Ottobock 社の筋電義手は世界で最も使用されている筋電義手の一つである。その中でも Myobock は Ottobock 社の代表的な単自由度義手である。オプションによって制御を選択することができ、閾値型制御や単回帰型制御を実現している。[Ottobock 2014]

### 1.4.2 切り替え制御型

切り替え制御型の制御手法は前述の閾値型、単回帰型の制御を組み合わせることによって多自由度を制御できるようにしたものである。筋トリガーやボタンなどによって握りや摘みといった把持姿勢を遷移させ、把持しているか否かを閾値や回帰によって制御する。筋トリガーとは通常の把持では発現しない符号化された筋活動のことであり、屈筋と伸筋の両方が筋収縮する、短時間に 2 回筋活動が発現するといったものが筋トリガーとしてよく用いられる。

Steeper 社の BeBionic は人間と同じ 5 指を有する多自由度義手であり，屈筋・伸筋の 2 極の電極によって義手の比例制御を行っており，ボタンや筋トリガーによって把持姿勢を遷移させている．[BeBionic 2017]

touch bionics 社の i-limb quantum は人間と同じ 5 指駆動型の多自由度義手であり，事前にプログラムしカスタマイズすることによって 36 動作を実現することができる．動きによって自動で制御されるジェスチャ制御，アプリによる app 制御，筋電位の筋トリガーによる筋制御，grip chips というデバイスと Bluetooth 通信することによって動作を変更する近接制御の 4 つの制御によって動作する．[touch bionics 2018]

Controzzi らが開発した SSSA-MyHand は 3 モータを有する多自由度義手であり，握力把持，精密把持，側面把持の日常生活動作において最も発現する 3 つの把持機能を実現しつつ，できるだけ簡潔な機構にすることをコンセプトとしている．機構を簡潔化することによって低コスト化・高ロバスト性・低重量を実現しつつ，機能性・擬人観・美容観を高めている．[Controzzi 2016]

### 1.4.3 パターン認識型

パターン認識型の制御手法は学習型の代表的な例である．閾値型の制御手法が閾値によってハンドの開閉を制御していたのと同様に，事前に義手の様々な動作の形態とその時の筋電位を用意し，その関係性を学習した後に，現在の筋電位が学習した度のパターンに近いかを評価して動作を実現する．多自由度義手は単自由度義手と異なりパラメータが膨大になり，また，筋電位自体も発現の有無や強弱のみならずより細かい筋電位の変化を用いて動作を実現する必要があることから Linear Discriminant Analysis (LDA)や Artificial Neural Network (ANN), Support Vector Machine (SVM)といった機械学習が用いられる．また，非学習型の制御手法と比較してより多くのセンサを用いる傾向にある．

Cipriani らは 8 個の筋電センサから 7 動作の識別を行っている．Cyberglove を利用して対側の手から各指の関節の角度を計測し，ロボットハンドのパラメータを決定している．筋電特徴量として筋電位の振幅強度を意味する特徴量である Mean Absolute Value (MAV)を用いており，k-nearest neighbor (k-NN)によるパターン識別によって Online 制御を行っている．[Cipriani 2011]

加藤らは ANN を用いたパターン識別によって 3ch の筋電センサから 11 動作を 85%以上の識別精度で識別を行っている．特徴量としては MAV と周波数情報である Power Spectrum (PS)を用いている．また,義手を操作しながら Online 学習を行うことによって訓練データを自動的に修正し, 人が持つ時变的特性を吸収し長期安定的な制御を実現している．[加藤 2008]

### 1.4.4 多重回帰型

多重回帰型制御は指の一つ一つの関節角度などと筋電位との関係を機械学習によってモデル化し, 制御する手法である．パターン認識型と比較してさらに制御対象の自由度が高いため, 実現が難しく多重回帰型制御を行っている研究は少ない．より細かな筋電位の違いを計測したり, 教師信号となるその際の関節角度等を計測しなければならず装置が大型化しやすい．筋電センサに関しては高密度筋電位(HD-EMG)と呼ばれる, アレイ型センサを用いて計測された筋電位を使用した研究が多数存在する．また, 機械学習に関してもパターン認識型と比較して複雑化し, 学習にかかる時間が長くなってしまったため, 実際に義手を動かしている研究は少なく, 様々な動作とその時の筋電位を収集し, 後で時間をかけて対応関係をモデル化して評価を行うオフライン解析を行っている研究がほとんどである．このように装置が大型化しやすく, また即時性の問題からオンライン制御が困難であることから筋電義手としての実用性は低く, 筋電位からどれほど動作意図を抽出できるかに重きを置いている研究が多い．また, 商用的に実用化している多重回帰型制御の筋電義手は存在しない．

Hioki らは ABS 樹脂を用いた軽量で高把持力な筋電義手を開発している．制御としては ANN の一種である Recurrent Neural Network (RNN)を用いて時系列情報を学習しており 4ch の筋電センサから拇指以外の 4 指の屈曲伸展を回帰して制御している．センサ数も少なく識別器としては各指の回帰を Online で行えているが, 指の屈曲伸展の 2 状態しか学習しておらず, 検証も 2 状態しか制御していないためパターン識別と同程度の制御自由度しか制御できることを示せていない．[Hioki 2011]

Celadon らは前腕の 192ch の HD-EMG を用いることによって拇指以外の 4 指の屈曲伸展に対してどちら方向にどの程度力が入っているかを回帰モデルを構築しその精度を検証している．[Celadon 2016]

### 1.4.5 併用型

併用型制御手法はパターン認識と回帰を併用している制御手法である。通常時はパターン認識を行い、物体の把持を検知するなどした際に回帰モデルに切り替える方法とある特定の動作に限り回帰制御が可能となるようなパターン認識を行っている方法の主に 2 つがある。

辻らは筋シナジーと呼ばれる動作の基本単位を識別し、その複合動作として多様な動作を実現している。モータにかかる負荷をモニタリングしており、そこから物体を把持しているか否かを検知して、物体把持を検知した場合に限り、筋活動量に比例して把持力を変化させる把持力制御に切り替わる。[辻 2010]

永田らは多チャンネルの表面筋電位を用いて安静、握り、開き、手首の掌屈、背屈の 5 動作を識別している。また、線形回帰モデルを用いて握力の推定を行っている。しかしながら、把持力が弱い時には握りが安静と識別されるなど、把持力を変化させると別の動作に誤識別してしまうといった問題があった。[永田 2010]

辻内らは円錐モデルを用いた手の開き、握り、摘み、手首の掌屈、背屈の 5 動作の識別を行っている。また、手首動作に関しては重回帰モデルを角速度を生成し、角速度制御を行っている。[辻内 2010]

Sikdek らは ANN を用いて 4 極の筋電センサから拇指の角度と力の回帰を行っている。力と姿勢それぞれ 4 段階の計 16 段階に関して検証を行い非常に高い精度で推定を行えている。[Sidek 2012]

### 1.4.6 学習型制御における 2 つのアプローチ

制御対象の観点から学習型制御の分類を行ってきたが、別の観点としてそれぞれの制御手法が目指している方向性からこれらを分類することも可能である。すなわち、実用的な制約条件の下でどこまでのことが可能かを検証する「実用性重視」なアプローチと筋電位からどこまでの情報が抽出可能かを検証する「性能重視」なアプローチの 2 つである。

筋電義手の研究は Online 制御による研究と Offline 解析による研究の 2 つの研究手法がある。Online 制御による研究とは義手が人に装着された状態で義手

の評価を行う研究であり、**Offline** 解析による研究とは人からは筋電位の計測のみを行い、そのあとで同じ筋電位データを用いて様々な識別器の比較等を行う。

実用性重視のアプローチは手法を筋電義手に実装し **Online** 制御することを前提条件としてその制約下で性能向上をさせようとするアプローチである。必然的に **Online** 制御を行うために、人に義手を装着したまま学習に数時間かけるといったことはできないため、簡素で学習時間が短い識別器を用いる、人に装着することを想定して装置のウェアラブル化・小型化がなされている、即時性や装置の小型化などの観点から制御する運動自由度が少ないといった傾向にある。これらの特徴から実用性重視のアプローチ手法は前述のパターン認識型の制御手法を採用している場合が多い。

それに対して性能重視型のアプローチは義手への実装を一旦度外視して筋電位からどこまで動作意図抽出を行うことができるのか検証するアプローチである。特徴として大型の装置や多次元の入力を用いて膨大なデータを収集する、学習に数時間から数日かかるような複雑な識別器を用いて **Offline** 解析を行う、より細かな筋電位を用いるため制御できる運動自由度が多いといった傾向にある。これらの特徴から実用性重視のアプローチ手法は前述の多重回帰型の制御手法を採用している場合が多い。

このように学習型の制御には時間をかけて多くの入力を用いて学習を行えばより細かな制御自由度を制御できるが、義手は人に装着するロボットであり、大きさや重さ、即時性に制限があるため実用的でなくなってしまうというトレードオフの関係が存在する。

しかし、このトレードオフの関係は筋電位が不安定であるため、義手を装着し直すと再学習しなければならないという「筋電位の信号特性の時変性」が大きな要因である。つまり、モデルを学習する段階と実際に義手を使用する段階の間で常に義手を装着したままにしておかなければならないという制約があり、実用性の観点から短時間で学習が完了しなければならず、複雑な識別器を使用することができない、ひいては制御対象の自由度が制限されてしまうという問題がある。

もしも筋電義手を付け直した際に変化してしまう筋電位の信号特性の時変性を吸収できるような制御手法を開発することが出来れば、学習と推定の分離を行うことが可能になり、事前に大規模なデータを取っておいて筋電位と動作の



複雑な関係性をモデル化しておき，義手を使用する際には義手を装着するだけで非学習型の制御手法と同様に使用できるということが可能となる．また，それによって **Online** 化と制御可能な運動自由度の高自由度化の両立が可能となる．

### 1.5 研究目的

非学習型の制御手法は安定した信号特徴を用いるため義手を装着してすぐに使用できるというメリットが存在するが、ほとんどが単自由度義手を対象としており、多自由度義手を対象としたものでも制御可能な運動自由度が少なく健常の手とのギャップが大きい。

学習型の制御手法は細かな筋電位の変化を用いるため義手を装着した後に使用するためには筋電位と動作の関係を学習する必要がある、学習は時間を要するものであり装着者にとって煩わしい。学習時間を短くすると制御可能な運動自由度が少なくなってしまう、学習時間を長くかけると細かい制御が可能になるが実用的でなくなってしまう。

学習型制御手法が義手を装着するたびに学習をし直さなければならないのは筋電位の信号特性の時変性によるものであり、この影響を抑えることが出来れば事前に時間をかけてモデルを学習しておき、付けてすぐに使用するということが可能になる。

近年、計算資源が向上し、また、汎化性の高い機械学習手法が登場してきており、大規模な筋電位データを用いることによって筋電位の時変性を吸収できる可能性がある。

そこで本研究では

義手の装着し直しによる再学習が不要であり、  
制御可能な運動自由度の多い実用的な筋電義手制御手法の実現

を目的とする。

そのために筋電位の信号特性の時変性を吸収する制御手法の開発を行う。また、筋電位の信号特性の時変性が筋電義手の制御にどのような影響を与えるのか調査する。さらに手法の実機への実装を行い、実使用環境下で評価を行うことによって実用的でかつ制御可能な運動自由度が多い制御が行えていることを示す。

## 1.6 本論文の構成

本章では本研究の背景として筋電義手への要求と現状、及び筋電義手の制御手法と問題点を整理し、そこから本研究の目的を明らかにした。

第 2 章では関連研究と事前検証から本研究が扱う問題領域を定義し、本章で定めた目標を達成するための評価基準の設定を行う。

第 3 章では大規模な筋電位データを用いて筋電位の信号特性の時変性を吸収するための制御手法を提案し、その詳細について述べる。また、提案手法の学習を行うために必要なデータセットの構築の仕方に関しても述べる。

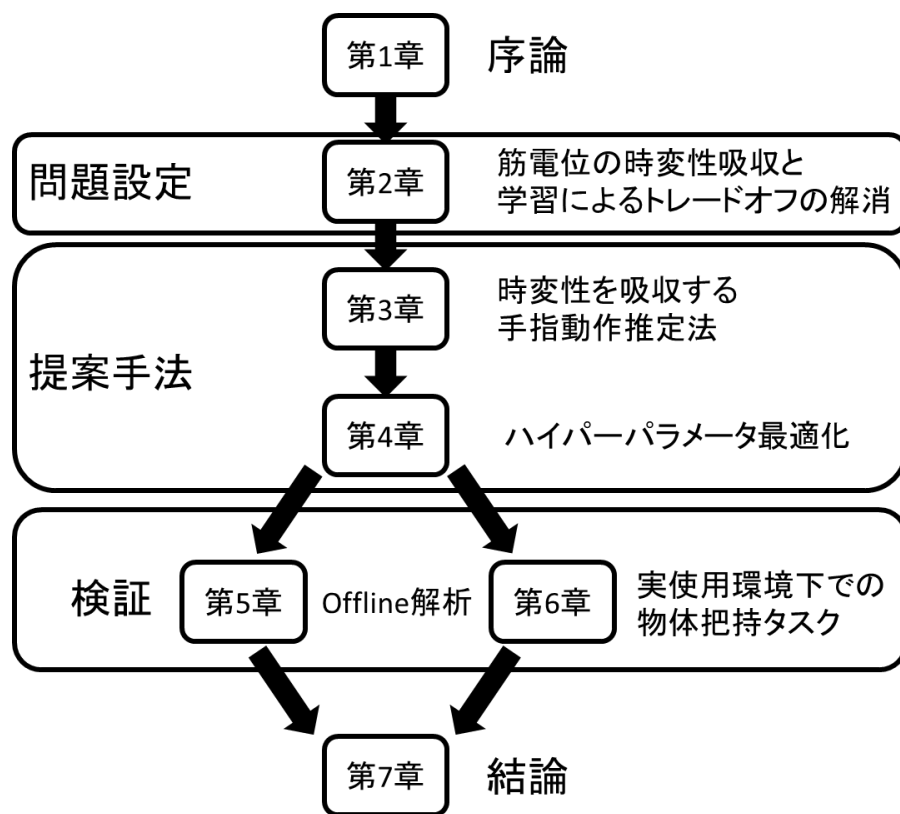
第 4 章では 3 章で提案した手法に関してそれぞれのパラメータを変更して、識別率を用いてその制御性能を比較検討し、手法のパラメータの最適化を行う。

第 5 章では提案手法と比較手法についてロバスト性、把持姿勢識別率、把持力推定精度、学習時間の観点からそれぞれの手法を比較し、それぞれの **Offline** 解析による性能の検証を行う。

第 6 章では提案手法の義手への実装を行い、物体把持タスクを行うことによって、実使用環境下での把持性能に関して検証を行う。

第 7 章では本論文のまとめと今後の課題について述べる。

Figure.1.3 に本論文の構成の概要を示す。



## 第2章 問題設定：時変性の吸収と 実現すべき上肢機能

---

2.1 はじめに .....	30
2.2 筋電位の信号特性の時変性 .....	31
2.3 学習型制御手法における動作意図抽出 .....	36
2.4 筋電センサ貼付位置 .....	39
2.5 動作生成 .....	41
2.6 推定すべき手指・手首動作 .....	43
2.7 推定把持力 .....	45
2.7.1 パターン認識型での把持力制御 .....	45
2.7.2 併用型での把持力制御 .....	45
2.8 識別率の定義 .....	47
2.9 問題設定のまとめ .....	48
2.10 アプローチと本研究の独創性 .....	50
2.11 おわりに .....	53

---

## 2.1 はじめに

本章では関連研究と予備実験から本研究が扱う問題領域を定義し、第 1 章で定めた目標を達成するための評価基準の設定を行うとともに、それに対する本研究でのアプローチについて述べる。

2.2 節では筋電センサを付け外しした際に生じる筋電位の信号特性の時変性について述べ、時変性と動作意図がそれぞれの程度筋電位に影響を与えるのか明らかにする。

2.3 節では学習型の動作意図抽出手法がどのように行われているのか整理し、定式化を行う。

2.4 節では動作意図抽出の入力となる筋電位計測に関して議論し、筋電位を計測する筋電センサの貼付位置を決定する。

2.5 節では抽出した動作意図を用いて動作生成において実際にどのように義手を制御するのかについて述べる。

2.6 節では動作意図の一要素である把持姿勢に関して筋電位からの推定の対象とすべき識別姿勢に関して議論し決定する。

2.7 節では動作意図の一要素であり把持力に関して筋電位からの推定対象とする把持力に関してパターン認識型と併用型のそれぞれについて議論し決定する。

2.8 節では評価に用いる識別率の定義に関して述べる。

2.9 節では 2.2 節から 2.8 節までの内容を踏まえて、第 1 章で定めた目標を達成するための評価基準の設定を行う。

2.10 節では 2.9 節で設定した問題に対して本研究でのアプローチについて述べる。

## 2.2 筋電位の信号特性の時変性

1.3 節で述べたように筋電位は装着者の動作意図に関する情報を多く含んでいる．一方で筋電位は変化しやすく動作意図以外の多くの要因によっても変化する．筋電位信号の変化の要因について以下に整理する．

- ・神経信号としての特性
  - ・インパルス信号
- ・動作意図
  - ・把持姿勢
  - ・把持力
- ・時変性
  - ・センサ位置
  - ・把持戦略の変化
  - ・生理的要因(疲労・発汗)
- ・ノイズ
  - ・Artifact(人為的雑音)

筋電位はインパルス信号であるため一定の電圧値を維持することが難しく大きな分散を有している．そのため、一般的には特徴抽出によって抽出された筋電特徴を用いて学習・識別を行う．

手の一義的な意義は物体の把持であることから把持について考えると、この動作意図は把持力と把持姿勢の 2 つの要素から構成されている．把持力は各筋の筋活動の強さを意味しており、把持姿勢はどの筋がどのような順で活動しているかを意味する．筋電位の振幅強度は筋収縮量に対して相関があると言われるため、そこから実際に物を把持しようとしているときの把持力を求めることができる．また、行う手指動作によって活動する筋が異なり、筋電センサの貼付位置や周波数特性からどの筋をどの程度動かそうとしているのか推定することが可能であるため、そこから把持姿勢を推定することができる．以後、手首動作など把持以外に関しても述べるが、筋活動の強さを把持力、どの筋が活動しているのかを把持姿勢として統一し、把持力と把持姿勢を包含する語として動作を用いる．

装着者の意図と無関係に変化してしまう要因として時変性とノイズが存在する．時変性は筋電義手を装着し直すことによって変化してしまう要因であり、筋

電センサの傾き・ズレ・方向などの接触状態の変化, 装着者自体の把持戦略の変化, 疲労や発汗などの生理的要因などがあげられる. 特に筋電センサの接触状態は変化しやすい問題であり, 一般的に筋電位はバイポーラセンサという 2 か所の電位差を用いて信号を計測するセンサ構成となっているが, この計測点が筋繊維に対して正確に沿っていないとうまく筋電位を計測することが出来なくなってしまう. そのため, センサがズレて同一筋繊維上に配置できていなかったり, 配置されていても発汗等でそれぞれの電極のインピーダンス特性が大きく異なっていたりした場合, 計測される筋電位の信号特性が変化してしまう.

もう一つ, **Artifact** と呼ばれる人為的ノイズが存在する. これは電磁波などの環境ノイズ, 義手が机などに接触した際に生じるインパルスノイズなどが挙げられる.

時変性による筋電位の信号特性の変化は把持力や把持姿勢といった動作意図による筋電位の変化と比較すると小さな変化である. そのため, 単自由度義手の開閉を閾値や回帰によって制御するような制御方法ではこのような筋電位の信号特徴の時変性はあまり大きな問題にはならない. しかし, 学習型の動作意図抽出によってより細かい筋電位の変化を用いて, より多くの運動自由度を制御しようとした場合に, この時変性による筋電位の変化は無視できなくなってくる.

動作意図による筋電位の信号特性の変化に比べると時変性による変化は小さいため, 時変性の影響を吸収しつつ動作意図の抽出が行えると考えられる. 一方でノイズに関しては動作意図の影響よりも大きく筋電位を変化させてしまうため, 信号処理では吸収困難であるためハードウェア的に回路によって低減することや後述する平滑化フィルタによって影響を抑えることを考える.

筋電位がそれぞれの要因によって実際にどの程度変化するものなのか検証を行った. **Figure 2.1** に筋電位を周波数分解しレーダチャートとして表現したものを示す. 筋電センサを前腕 5 か所に貼付し, 指定した把持姿勢と把持力を維持している際の 5 秒間の筋電位を 3 回計測した. 画像の 5 つの領域がそれぞれの筋電センサを意味しており, それぞれの領域内では時計回り方向に 0 から 400Hz の周波数成分を意味している. つまり, 外に広がっている箇所はその周波数領域の筋電位が強く発現していることを意味する. 実線が平均値を意味し, 濃い色の領域が標準偏差  $1\sigma$ , 薄い領域が  $2\sigma$  を意味する. つまり, 濃い領域にデータの約 68%, 薄い領域にデータの約 95%が集まっていることを意味する.





Figure 2.1 日を跨ぐことによる筋電位の信号特性の変化

画像を見比べると姿勢によって発現する筋電位の傾向が変化していることが分かる。しかし、同時に筋電位は分散が大きく不安定な信号であり、閾値のような単純なルールでは各筋が収縮しているかはわかっていても、それぞれの姿勢に細かく分類することは難しいということが分かる。また、日を跨ぐことによって同じ姿勢を行っているときでもおおむね同様の傾向を示しているが、一部の周波数帯で信号特性が大きく変化する場面があることが分かる。

このように筋電位は手指の姿勢によって同じような信号特性の傾向を示すが、微弱な生体信号でありもともと不安定な信号特性であることと、日を跨いでセンサを付け外すと一部の信号特性が大きく変化してしまう場合があることから、一般的に学習型の筋電義手の制御は義手を装着するたびに筋電位と動作の関係のモデル化を行わなくてはうまく制御することができない。

例として 1 日目の握力把持と精密把持のときに得られた筋電位のそれぞれ周波数における平均値の差の二乗和平方根を求めると  $0.78V$  であるのに対して、1 日目と 2 日目の握力把持の平均値の差の二乗和平方根を求めると  $0.35V$  である。握力把持と精密把持の筋電位の特徴は非常に近い動作動詞ではあるものの、義手を付け外したことによる筋電位の信号特性の変化が把持姿勢の違いとして現れる筋電位の変化の半分ほどの大きさを有している。今回の実験は被験者に筋電位を可視化して提示しながら厳密に筋電位の計測を行っているが、実際義手を使用する際には同じ把持力を維持しているつもりでも変化してしまったり、同じ把持姿勢をしているつもりでも力の入れ方が異なって違う筋が強めに収縮したりすることが起こるなど、時間経過に伴う装着者の把持戦略の変化も起こってしまうためより識別することが難しくなってしまう。

また、把持力の違いによる筋電位の信号特性の違いを Figure 2.2 に示す。画像を見比べると把持力を増加させると全体的に筋電位が強くなっていることが分かる。筋電位を変化させる要因の中でも把持力は最も大きく筋電位を変化させる要因であるが、義手の制御としては同一の把持姿勢では把持力の違いによらず一つの姿勢として認識したい。また、同一把持姿勢において把持力の増加に対して筋電位は相似関係を保ちながら拡大するのではなく、把持力によって信号特性が一部変化してしまう場合がある。これらを同一の把持姿勢として認識できるような識別器を構成しなくてはならない。

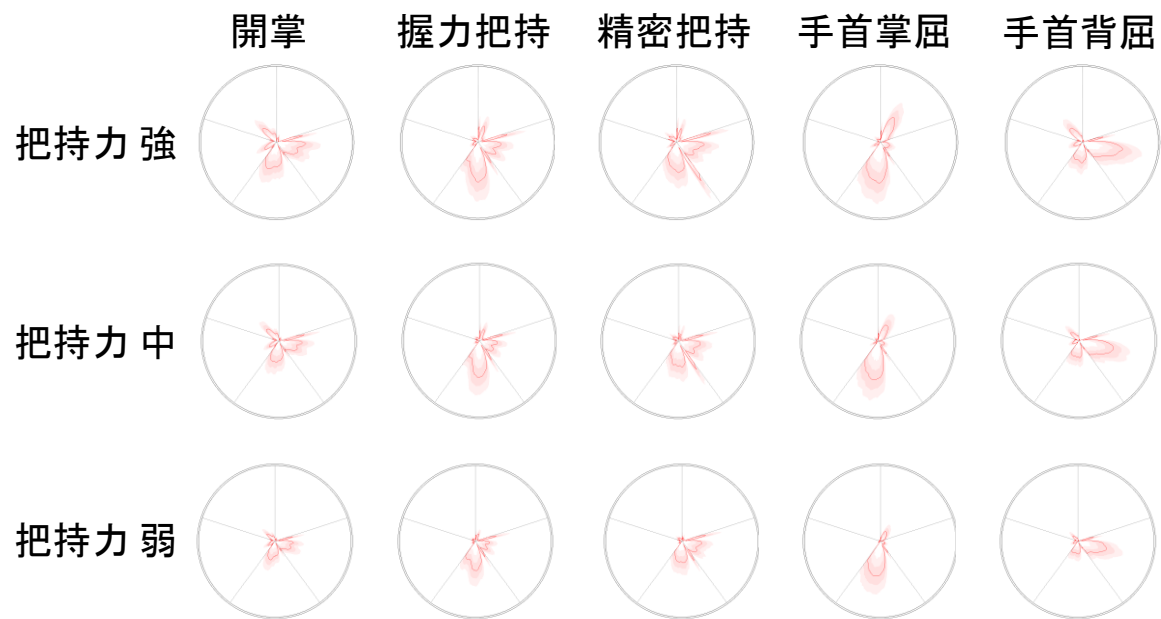


Figure 2.2 把持力による筋電位の変化

## 2.3 学習型制御手法における動作意図抽出

1.4 節において義手の制御手法を 6 つに分類した。非学習型の 3 つの制御手法は安定した制御が行いやすいが、制御可能な運動自由度が少なく人の手とのギャップが大きい。本研究では健常の手に近い制御可能な運動自由度が高い実用的な筋電義手の実現を目指しているため、非学習型の制御手法は不適當である。学習型の制御手法はパターン認識型・多重回帰型・併用型の 3 つに分類できるが多重回帰型は筋電義手の入力としてよりも人の手の運動解析に重きを置いている研究が多く、義手として実装するためには計測装置や筋電センサ、識別器などまだまだ解決すべき問題が多く実用的ではない。そのため本研究ではパターン認識型と併用型の制御手法それぞれで時変性を吸収する識別器を開発し、そのパフォーマンスを検証する。

学習型の筋電義手制御手法の概要を Figure 2.3 に示す。1.2 節で述べたように義手の制御手法は筋電位計測・動作意図抽出・動作生成の 3 つから構成される。ある時刻  $t$  において計測された筋電位ベクトルを  $\mathbf{emg}_t$  とし、その時の装着者の実際の動作意図を  $\Psi_t$ 、義手によって推定された動作意図を  $\hat{\Psi}_t$  とする。ここで動作意図  $\Psi$  は把持姿勢  $\omega$  と把持力  $y$  の 2 項組であると定義する。筋電位計測では筋電センサを用いて筋電位ベクトル  $\mathbf{emg}_t$  を取得する。また、動作生成では推定された動作意図  $\hat{\Psi}_t$  を用いて実際にアクチュエータの操作量を決定する。動作意図抽出では動作意図抽出関数  $G(\mathbf{W}, \mathbf{emg}_t)$  を用いて  $\mathbf{emg}_t$  から  $\hat{\Psi}_t$  を推定することとなる。

$$\Psi = \langle \omega, y \rangle \quad (2.1)$$

$$\hat{\Psi}_t = G(\mathbf{W}, \mathbf{emg}_t) \quad (2.2)$$

ここで  $\mathbf{W}$  は筋電位と動作意図の関係のモデルのパラメータ行列である。学習型の制御手法は大量の筋電位ベクトル  $\mathbf{emg}_t$  と動作意図  $\Psi_t$  の組を用いてパラメータ行列  $\mathbf{W}$  を得る学習フェーズとパラメータ行列  $\mathbf{W}$  を用いて筋電位ベクトル  $\mathbf{emg}_t$  から動作意図  $\hat{\Psi}_t$  を推定する推定フェーズの 2 つのフェーズからなる。また、筋電位はノイズの多い信号であるため、実際には筋電位ベクトル  $\mathbf{emg}_t$  から特徴抽出によって抽出された特徴ベクトル  $\mathbf{X}_t$  を用いて学習・推定を行うことになる。

$$\mathbf{X}_t = G_{FE}(\mathbf{emg}_t) \quad (2.3)$$

$$\mathbf{W} = G_{Lea}(\mathbf{X}, \mathbf{\Psi}) \quad (2.4)$$

$$\hat{\Psi}_t = G_{Ext}(\mathbf{W}, \mathbf{X}_t) \quad (2.5)$$

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_t \\ \vdots \\ \mathbf{X}_{N_{Lea}} \end{bmatrix} \quad (2.6)$$

$$\mathbf{\Psi} = \begin{bmatrix} \Psi_1 \\ \Psi_2 \\ \vdots \\ \Psi_t \\ \vdots \\ \Psi_{N_{Lea}} \end{bmatrix} = \begin{bmatrix} \langle \omega_1, y_1 \rangle \\ \langle \omega_2, y_2 \rangle \\ \vdots \\ \langle \omega_t, y_t \rangle \\ \vdots \\ \langle \omega_{N_{Lea}}, y_{N_{Lea}} \rangle \end{bmatrix} \quad (2.7)$$

$G_{FE}(\mathbf{emg}_t)$ ,  $G_{Lea}(\mathbf{X}, \mathbf{\Psi})$ ,  $G_{Ext}(\mathbf{W}, \mathbf{X}_t)$ はそれぞれ特徴抽出関数, 学習関数, 推定関数を意味する.  $\mathbf{X}$ 及び $\mathbf{\Psi}$ はそれぞれ $\mathbf{X}_t$ ,  $\Psi_t$ のベクトルでありそれぞれ $N_{Lea}$ の長さを持っておりこれは学習データの総数を意味する.

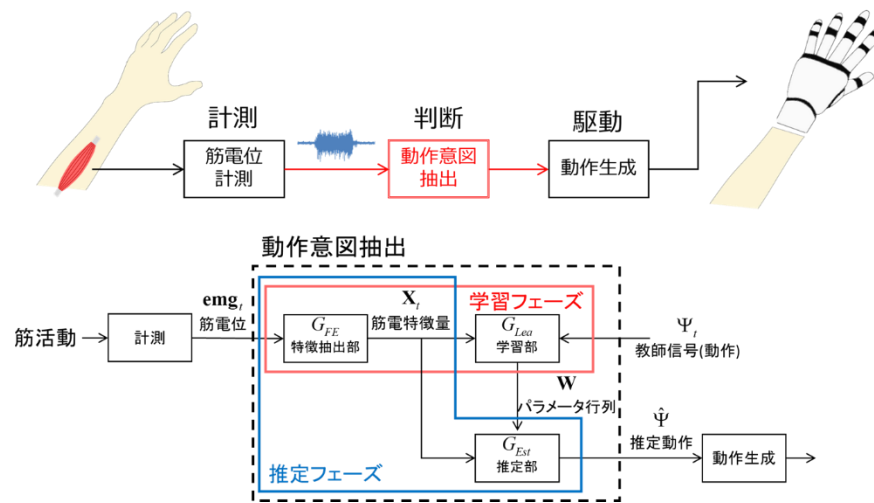


Figure 2.3 学習型制御手法の動作意図抽出

## 2.4 筋電センサ貼付位置

$\mathbf{emg}$  は時刻  $t$  において  $N_{ch}$  個の筋電センサから計測された筋電位信号列  $s_t^h$  のベクトルである.

$$\mathbf{emg}_t = \begin{bmatrix} s_t^1 \\ s_t^2 \\ \vdots \\ s_t^h \\ \vdots \\ s_t^{N_{ch}} \end{bmatrix} \quad (2.8)$$

本研究では前腕切断の患者に筋電義手を適用することを想定している. そのため, 筋電センサの貼付位置の条件として以下の 3 つを満たすものを計測対象筋とする.

1. 手指の動作にかかわる筋である
2. 断端部に存在する筋である (手掌部や対側の腕の筋等はいない)
3. 外部から触診によって位置の同定が可能な筋である

健常者の場合は上記の 3 つの条件を満たす筋として浅指屈筋・総指伸筋・超拇指外転筋・示指伸筋・小指伸筋の 5 つがありこれらを計測対象筋とする. これらの筋が支配している動作を Table 2.1 に示す. 上肢切断者の場合は解剖学的に健常者と筋配置が異なっている場合が多い. そのため, 触診によって上記の 3 つの条件を満たす筋を探索し筋電センサを貼付する. なお, 貼付する筋電センサ数は健常者と同数の 5 つとする.

Table 2.1 計測対象筋と支配動作

対象筋	支配動作
浅指屈筋	示指から小指の四指の屈曲
総指伸筋	示指から小指の四指の伸展, 手首の伸展
長拇指外転筋	拇指の外転・伸展
示指伸筋	示指の伸展
小指伸筋	小指の伸展




Figure 2.4 健常者の筋電センサ貼付位置




Figure 2.5 切断者の筋電センサ貼付位置



## 2.5 動作生成




Figure 2.6 ワイヤ駆動型多自由度義手及び牽引モータ

動作生成においては動作意図抽出において抽出された動作意図  $\hat{\Psi}_t$  を用いて実際のアクチュエータの操作量を決定する．本研究では制御対象としてワイヤ牽引型の多自由度筋電義手を想定する．本義手は 13 個のサーボモータを有しており，各指の屈曲・伸展，拇指の対立・並立・外転・内転，手首の掌屈・背屈・回内・回外を制御することが可能である．

動作生成は以下の数式に基づいて行う．

$$\begin{aligned}\Theta_{t+1} &= \Theta_t + \Delta\Theta \\ \Delta\Theta &= \alpha \hat{y} \times \frac{\Theta_{\hat{\omega}} - \Theta_t}{|\Theta_{\hat{\omega}} - \Theta_t|}\end{aligned}\tag{2.9}$$




Figure 2.7 インクリメンタル制御概要

ここで  $\Theta_t$  は時刻  $t$  における各ワイヤの牽引量であり  $\Delta\Theta$  は制御周期ごとの変化量である。  $\Delta\Theta$  は推定把持力  $\hat{y}$  と推定把持姿勢  $\hat{\omega}$  によって求まる。動作意図抽出はパターン認識型か併用型のどちらかを用いて行うため、推定される把持姿勢は離散値である。事前に推定される把持姿勢に対応した義手の終端姿勢を複数定義しておき、それぞれの終端姿勢を実現させるためのワイヤの牽引量  $\Theta_{\omega}$  を義手が有している。一度、ある姿勢  $\hat{\omega}$  が識別されるとその終端姿勢に向かって  $\Delta\Theta$  ずつモータを近づけるという制御を行う。この近づける量は把持力  $\hat{y}$  に比例して変化させる。  $\alpha$  は比例定数である。つまり、動作意図  $\hat{\Psi}_t$  は推定把持姿勢  $\hat{\omega}$  と推定把持力  $\hat{y}$  からなるが、  $\hat{\omega}$  によってモータの制御方向を決定し、  $\hat{y}$  によって制御量を決定するということになる。そのため、同じ姿勢が識別され続けると義手はその終端姿勢に近づいていき、最終的にその姿勢が実現される。  $\Theta_t$  と  $\Theta_{\omega}$  が一致している場合は変化量  $\Delta\Theta$  は  $0$  とする。このような制御をすることによって識別結果に誤識別が混ざった場合でもその影響を小さく抑えることができる。

また、把持に関する姿勢に関しては終端姿勢のほかに中間姿勢も定義しておく。この中間姿勢は物体を把持する前の準備姿勢であり、把持に関する姿勢が識別された際にはモータはまず中間姿勢に近づいていき実現したのちに、終端姿勢を実現する。これはハンドの機構が干渉することを防ぐとともに把持の準備姿勢をとることによって装着者が物体と義手の空間認知がしやすくなるという目的がある。

## 2.6 推定すべき手指・手首動作

Controzzi らによると日常生活動作(ADL)において出現する把持の内、握力把持が約 40%、精密把持が約 30%、側面把持が約 10%を占めると報告されている [Controzzi 2016]。握力把持は物を掌で握りこむ把持、精密把持は指先で物を摘まむ把持、側面把持は鍵やカードなど平らな物体を拇指と示指で挟む把持である。これはすなわち、3 つの把持姿勢を実現することによって日常生活における約 80%の把持が可能になるということであり、本研究ではこの基本 3 種の把持姿勢の実現を目指す。また、先の報告では一日の内、最大で約 40%の時間は物体の把持などを行わず手は安静状態を保っているということが報告されている。そこで本研究で実現すべき姿勢としては何もしていないときにハンドが邪魔にならない姿勢を保つ「安静」、把持している物体を離す「開掌」、そして基本 3 種の把持姿勢である「握力把持」、「精密把持」、「側面把持」の 5 つの手指姿勢を実現する。

また、物体の把持を行うためには装着者が把持物体に対して義手をアプローチさせるがその際に手首の動作が重要になってくる。物体に対して義手を適切な方向からアプローチしなければ物体を把持することは難しい。健常の手首の自由度としては掌屈背屈、回内回外、撓屈尺屈の 3 自由度が存在する。しかし、3 自由度を制御しようと思うと機構が大型化してしまう一方で、アプローチ方向に関しては残存している肘や上腕の動きによって補うことが可能であることから、今回は「掌屈」、「背屈」、「回内」、「回外」の手首 4 自由度を実現すべき姿勢とする。

以上をまとめると本研究では安静、開掌、握力把持、精密把持、側面把持、手首掌屈、手首背屈、手首回内、手首回外の手指 5 動作、手首 4 動作の計 9 動作を識別姿勢とする。実現する姿勢を Figure 2.8 に示す。




Figure 2.8 識別対象動作

- a) 安静(rst), b) 開掌(opn), c) 握力把持(pwg), d) 精密把持(prg), e) 側面把持(ltg),  
f) 手首掌屈(flx), g) 手首背屈(ext), h) 手首回内(prn), i) 手首回外(spn)

## 2.7 推定把持力

本研究ではパターン認識型と併用型の 2 つでそれぞれ動作意図を抽出する方法を考える。それぞれの推定対象はパターン認識型は離散量であり，併用型は把持姿勢が離散量，把持力が連続量である。そのため把持力の達成目標に関してはパターン認識型と併用型でそれぞれ別々に設定する。

### 2.7.1 パターン認識型での把持力制御

Rojas-Martínez らは前腕と上腕の 350ch の高密度筋電位(HD-EMG)を用いて肘の屈曲・伸展・回内・回外の 4 動作の識別を行っており，またそれぞれ 3 段階の力の識別を行っている。[Rojas-Martínez 2012]

Kauppi らは前腕の 128ch の HD-EMG を用いて 5 指の屈曲・伸展の識別を行っている。それぞれの力を 3 段階に変化させて学習データを構築しているが，力の変化を識別することは行っていない。[Kauppi 2015]

上記の研究は HD-EMG を用いて Offline 解析を行っている研究であり，筋電位から人の動作意図をどこまで取り出せるかということに重きを置いている研究である。しかし，このような研究でも複数の動作の力を推定することは難しい課題である。そこで本研究では力を変化させる最低限の段階としてそれぞれの動作での 3 段階の力の識別を目的とする。

### 2.7.2 併用型での把持力制御

辻らは筋シナジーと呼ばれる手の動作の基本単位を識別しその基本動作を組み合わせた複合動作として多様な把持姿勢を実現している。また，モータの負荷から物体の把持を検知し把持姿勢制御から把持力制御に制御を切り替えることによって力と姿勢の制御を両立している。[辻 2010]

永田らは多チャンネル表面筋電位を用いて手の安静，握り，開き，手首の掌屈，背屈の 5 動作を実現しており，握りに関してのみは線形回帰モデルを用いて把持力制御を実現している。しかし，把持力が一定以下の場合は握りが安静と識別される場合があることや把持力を変化させると他の姿勢に誤識別してしまう場合があるといった問題があった。[永田 2010]

辻内らは円錐モデルを用いて手の開き，握り，摘み，手首の伸展，屈曲の5動作を識別しており，また，手首動作に関しては重回帰モデルを用いることによって手首の動作速度を装着者が制御することができる．[辻内 2010]

上記の研究の制御対象と制御方法を以下の Table 2.2 にまとめる．これらの研究は大きく把持姿勢と把持力の制御をモードによって切り替えているか，特定の動作のみ把持力制御を行っている研究かの2つに分けられ，把持姿勢と把持力の同時制御を満足に行えている研究はない．しかし，健常の手のように巧みな把持を行うためには把持姿勢と把持力の両方を同時に制御できる必要があるため，本研究では把持姿勢に依らず把持力を連続的に制御できることを達成目標とする．

Table 2.2 併用型制御での制御対象と制御手法

	把持姿勢	把持力
[辻 2010]	シナジー動作 10 動作 (基本 5 動作 複合 5 動作)	把持の検知による 切り替え制御
[永田 2010]	安静・握り・開き 掌屈・背屈	握りのみ把持力制御
[辻内 2010]	握り・開き・摘み 掌屈・背屈	手首のみ動作速度制御

## 2.8 識別率の定義

手法の評価は主に識別率を用いて行う．提案手法の学習・識別に用いる筋電位のデータセットの構築方法に関しては 3 章にて詳述するが，指定した把持姿勢と把持力を維持している際の筋電位を計測し，筋電位と把持姿勢・把持力の対応のとれたデータセットを構築する．

筋電位を識別器を用いて識別することによって識別クラスの時系列データを得ることになる．この際に姿勢と力を維持している全区間のうち，正しく識別されている時間の割合から識別率を算出する．

$$\text{識別率} P = \frac{T_{\text{Correct}}}{T_{\text{All}}} \quad (2.10)$$

ここで  $T_{\text{All}}$  は識別を行っている全区間の時間， $T_{\text{Correct}}$  はそのうち正しく識別されている時間を意味する．




Figure 2.9 パターン認識における識別

識別率の達成目標に関しては 85%以上を達成目標とする．理由としては多くの筋電義手に関する研究において 90%前後を達成目標としており義手として有用な把持機能を実現するためには妥当な目標であること，またその上で対象とする動作が増えるもしくは手指動作など細かな違いの動作を対象とする場合その分識別が難しくなるが，本研究では多くの運動自由度を制御できることを目的としているため，実用的かつ多くの動作を実現できる目標として 85%以上を設定する．

## 2.9 問題設定のまとめ

本研究では学習型の動作意図抽出手法を用いて筋電位の信号特性の時変性を吸収する制御手法を開発し、義手を付け直した際の再学習を不要とすることにより、実用性が高く制御可能な運動自由度が多い制御手法の実現を目指す。

動作意図抽出法としてはパターン認識型と併用型の 2 つでそれぞれ時変性の吸収を目指しそのパフォーマンスを比較する。筋電センサ貼付位置は前腕 5 か所とし、制御対象はワイヤ駆動型の多自由度義手とする。

識別器の汎化性として筋電位の信号特性の時変性に由来する変化を含む信号を入力とした際にも十分な精度で推定が行えることを目指す。十分な精度とは以下に定義する達成目標が達成できることを意味する。

制御自由度として識別姿勢は基本 3 種の把持姿勢を含む手指 5 動作、手首 4 動作の計 9 動作が識別可能であるとする。また、パターン認識型の場合にはそれぞれの把持姿勢で 3 段階以上で把持力が識別可能であること、併用型の場合には把持姿勢に依らずに連続量として把持力が推定可能であることとする。またこの際に、把持力と把持姿勢は切り替え制御を行わず姿勢と力の同時制御が可能であるとする。これらの識別率が 85%以上の精度で達成できることを目指す。識別率は被験者が一定時間指定された動作を行っている際に目的の動作が発現した頻度が全体に占める割合によって求める。

また、実用性としてオンライン化が可能であること、つまり義手に実装して使用することが可能であり実使用環境下で評価が行えることとする。そのためには学習を行うために義手を装着したまま装着者を長時間拘束することがないこと、遅延なくリアルタイムで義手が制御できること、人が装着するための重量や大きさの制限を満たすことが求められる。また、モバイル性があり、装着したまま移動できる必要がある。

以上の問題設定を Table 2.3 にまとめる。



Table 2.3 問題設定のまとめ

		パターン認識型	併用型
時変性の 吸収	識別率	85%以上	
	汎化性	義手を付け外しても上記識別率を保つ	
高い 運動自由度	識別姿勢数	9 姿勢(手指 5 姿勢・手首 4 姿勢)	
	把持力	3 段階以上	連続値
実用性	実機に実装して評価が可能		
	Online 化	(長時間拘束せずに学習, リアルタイム制御)	
	小型化	携帯可能 (可搬な程度に小型・軽量)	

### 2.10 アプローチと本研究の独創性

本研究は義手を再装着して再学習の不要な多自由度筋電義手の開発を目指す。筋電位の信号特性の時変性の影響によって従来の筋電義手の制御手法は時変性の影響を受けにくい筋電位特徴を用いるか、義手を装着するたびに筋電位と動作との対応関係のモデルを毎回学習するかのどちらかを行っていた。しかしながら、前者は単純な特徴のみを入力として用いるため健常の手と比較して実現可能な動作が少なくなってしまう、後者はより細かい動作まで実現しようと思うと装置が大型化したり、学習時間が長大化して実用性がなくなってしまう、逆に実現性を高くしようとするると実現可能な動作数が減ってしまうというジレンマが存在していた。

実用的で制御可能な運動自由度が多い制御手法の実現に対して筋電位の信号特性の時変性が大きな問題となる。2.2 節で示したように動作意図による筋電位の変化と比較して筋電位の信号特性の時変性による筋電位の変化は小さい。近年、計算資源の向上や大規模なデータを扱う機械学習手法の登場によって汎化性の高い識別器を構成できるようになってきた。これらを用いることによって動作意図である把持姿勢や把持力を統制しつつ複数日にわたる長期的な筋電位を収集し、学習データセットを構築することによって筋電位の信号特性の時変性の影響を受けずに動作意図を抽出可能な識別器を構築することができるのではないかと考えた。

大規模なデータを扱う機械学習手法として Deep Convolutional Neural Network (DCNN)がある。DCNN は畳み込み層を用いて Artificial Neural Network (ANN)を多層に拡張した深層学習の一種であり、Hinton らが画像認識コンテストにおいて従来手法をはるかに上回る識別性能を示したことによって注目を集めた[Krizhevsky 2012]。ネットワーク構造を大きくすると複雑なモデルも表現できるようになるが、通常、ANN を多層化すると特定のデータに特化して学習を行ってしまう、逆に汎化性が低下する「過学習」という現象が起こる。それに対して DCNN では Hinton らが提案した段階的に学習を行う Autoencoder [Hinton 2006]や Lecun らが提案したネットワークの結合を局所化する Convolutional Network [Lecun 1989]によって過学習を防止している。また、近年の計算資源の向上や Glorot らが提案した ReLU[Glorot 2011]のような学習の効率化手法の提案も DCNN を含めた深層学習が実現可能になった大きな要因である。

汎化性の高いDCNNを用いることによって筋電位の信号特性の時変性を吸収できる可能性が考えられる。現状、DCNNを含めた深層学習は画像認識や音声認識など安定していて明瞭な信号に対して用いられることが多く、脳波や筋電位のような不安定な生体信号に用いられる例は少ない。しかし、Shimらは深層学習の一種であるDeep Belief Network (DBN)を用いて筋電位による手首動作の動作伝達[Shim 2015]を行っていたり、AtzoriらはDCNNを用いて筋電位から平均50の手動作の識別[Atzori 2016]を行っていたりと生体信号に対しても汎化性の高い識別が行える可能性が示されている。

そこで本研究ではパターン認識型の制御手法として、筋電位を周波数と時間を軸とする2次元画像に変換しそれをDCNNの入力とすることによって筋電位の信号特性の時変性を吸収することを試みる。本手法は学習に長大な時間を要するが1度学習してしまえば再学習が不要となるため、装着者の負担が低減できる。また、識別にはそれほど演算能力が要求されず実用的な範囲内での計算機によって実装可能であると考えられる。

また、筆者は過去に併用型の制御手法として選択的線形回帰モデル(SLRM)という把持姿勢と把持力の両方を同時に推定する手法を提案している[Yamanoi 2017]。本手法は筋電位の特性を考慮したシンプルな構造によって多くの運動自由度の制御を実現しているが、筋電位の信号特性の時変性に対する検証が行われていなかった。そのため、DCNNとSLRMの2つの手法を用いて筋電位の信号特性の時変性に対する検証を行う。

既存研究において義手の付け外しに伴う筋電位の信号特性の時変性に関して検証を行っている研究はほとんど存在しない。これは計算コストが膨大であり複数日にわたるような長期的な筋電位の検証はほとんど行えていなかったからである。しかし本研究では筋電位の信号特性の時変性を吸収することによって学習と推定を別々に行えるようにしたことにより、複数日にわたる長期的な筋電位を用いて学習を行い、実機を用いてその性能を検証することを可能としている。

現状の筋電義手は学習が装着者の負担となってしまうことから学習型の制御手法が商用的な筋電義手に用いられることはほとんどなく、非学習型の制御手法を用いることによって操作可能な運動自由度が制限されてしまっていた。しかし、本研究によって義手の付け直しに伴う再学習が不要となることによって装着者の負担とならずに学習型の制御手法を用いることが可能となり、より実

用的で制御可能な運動自由度が多い筋電義手可以实现できることになる.

## 2.11 おわりに

本章では関連研究と予備実験から本研究が扱う問題領域を定義し、第 1 章で定めた目標を達成するための評価基準の設定を行うとともに、それに対する本研究でのアプローチについて述べた。

2.2 節では筋電センサを付け外しした際に生じる筋電位の信号特性の時変性について述べ、時変性と動作意図がそれぞれの程度筋電位に影響を与えるのか明らかにした。

2.3 節では学習型の動作意図抽出手法がどのように行われているのか整理し、定式化を行った。

2.4 節では動作意図抽出の入力となる筋電位計測に関して議論し、筋電位を計測する筋電センサの貼付位置を決定した。

2.5 節では抽出した動作意図を用いて動作生成において実際にどのように義手を制御するのかについて述べた。

2.6 節では動作意図の一要素である把持姿勢に関して筋電位からの推定の対象とすべき識別姿勢に関して議論し決定した。

2.7 節では動作意図の一要素であり把持力に関して筋電位からの推定対象とする把持力に関してパターン認識型と併用型のそれぞれについて議論し決定した。

2.8 節では評価に用いる識別率の定義に関して述べた。

2.9 節では 2.2 節から 2.8 節までの内容を踏まえて、第 1 章で定めた目標を達成するための評価基準の設定を行った。

2.10 節では 2.9 節で設定した問題に対して本研究でのアプローチについて述べた。



# 第3章 ビッグデータを用いた動作 意図抽出法

---

3.1 はじめに .....	56
3.2 変数定義 .....	57
3.3 学習型動作意図抽出法の流れと 2 つの提案手法 .....	59
3.4 Selective Linear Regression Model .....	62
3.4.1 特徴抽出 .....	64
3.4.2 学習 .....	66
3.4.3 識別 .....	67
3.5 Deep Convolutional Neural Network .....	72
3.5.1 特徴抽出 .....	72
3.5.2 DCNN のデータ構造 .....	75
3.5.1 学習部と識別部 .....	76
3.5.2 プーリング層 .....	79
3.5.3 畳み込み層 .....	80
3.5.4 全結合層 .....	81
3.6 Artificial Neural Network .....	83
3.7 学習データの構築方法 .....	84
3.8 おわりに .....	88

---

### 3.1 はじめに

本章では大規模な筋電位を用いた動作意図抽出法について述べる．パターン認識型と併用型の動作意図抽出手法の 2 つのアプローチとしてそれぞれ畳み込みニューラルネットワークと選択的線形回帰モデルを提案し，また，比較手法としてパターン認識型の動作意図抽出法であるフィードフォワード型の 3 層ニューラルネットワークについても述べる．また，本章の始めにはこれらの手法に共通する部分として学習型動作意図抽出法の流れと入力である筋電センサから計測された筋電位に関して詳しく述べる．また，本章の終わりにはこれらの提案手法を学習するための学習データの質を高めるために大規模な筋電位を収集するプロトコルと学習データの構築法に関して述べる．

3.2 節では本論文で扱う変数についてまとめる．

3.3 節では学習型動作意図抽出法の流れとして特徴抽出，学習部，識別部を定義して，2 つの提案手法と比較手法について述べる．

3.4 節では併用型の動作意図抽出方法である選択的線形回帰モデルに関して詳しく述べる．

3.5 節ではパターン認識型の動作意図抽出方法である畳み込みニューラルネットワークに関して詳しく述べる．

3.6 節では比較手法としてパターン認識型の動作意図抽出方法であるフィードフォワード型の 3 層ニューラルネットワークについて述べる．

3.7 節では質の高い大規模な筋電位を収集するプロトコルに関して述べ，開発したアプリケーションと学習データの構築法に関して述べる．



## 3.2 変数定義

本論文で扱う変数について Table 3.1 にまとめる.

Table 3.1 変数定義

記号	意味	次元
$\omega$	把持姿勢	スカラー(自然数)
$y$	把持力	スカラー(非負の実数)
$\Psi$	動作	$\omega$ と $y$ の2項組
$\hat{\Psi}_t$	推定動作	$\omega$ と $y$ の2項組
$\alpha$	動作生成の比例定数	定数(実数)
$I_p$	補間幅	定数(自然数)
$N_{Lea}$	学習データ数	定数(自然数)
$N_{ch}$	チャンネル数(センサ数)	定数(自然数)
$N_{FL}$	解析データ長	定数(自然数)
$N_{time}$	抽出窓の時間長	定数(自然数)
$N_{ext}$	時間抽出点数	定数(自然数)
$N_{spct}$	周波数抽出点数	定数(自然数)
$N_p, N_q$	フィルタサイズ	定数(自然数)
$x_{ik}$	特徴量	スカラー(実数)
$\hat{x}_i$	モデルの特徴量	スカラー(実数)
$a_{\omega i}, b_{\omega i}$	モデルの特徴量の パラメータ	スカラー(実数)
$\bar{s}_t$	ゼロ基準バイアス	スカラー(実数)
$E_\omega$	姿勢 $\omega$ のモデルとの誤差	スカラー(非負の実数)
$\Theta_t$	ワイヤ牽引量ベクトル	ベクトル(実数)
$\Delta\Theta$	ワイヤ牽引量変化量	ベクトル(実数)
$\Theta_{\hat{\omega}}$	終端姿勢ベクトル	ベクトル(実数)
$s_t^h$	筋電位信号列	ベクトル(実数)
$\mathbf{T}_k$	教師信号	ベクトル(0, 1)
$\mathbf{o}$	出力層ベクトル	ベクトル(実数)
$\mathbf{W}$	パラメータ行列	多次元配列 (手法により異なる)
$\mathbf{X}_t$	特徴ベクトル	多次元配列 (手法により異なる)

$\mathbf{emg}_i$	筋電位ベクトル	$s_i^h$ を要素に持つベクトル
$\mathbf{X}$	学習データセット	$\mathbf{X}_i$ を要素に持つベクトル
$\Psi$	動作ベクトル	$\Psi$ を要素に持つベクトル

### 3.3 学習型動作意図抽出法の流れと 2 つの提案手法

1.2 節で述べたように筋電義手の制御は計測・動作意図推定・動作生成の 3 つの段階からなる．本章では主に計測された筋電位  $\mathbf{emg}_t$  から推定動作  $\hat{\Psi}$  を得る動作推定関数  $G(\mathbf{W}, \mathbf{emg}_t)$  とパラメータ行列  $\mathbf{W}$  の学習方法に関して述べる．

$$\hat{\Psi} = G(\mathbf{W}, \mathbf{emg}_t) \quad (3.1)$$

動作意図抽出の概要を Figure 3.1 に示す．一般的に，義手が学習を行い装着者個人の筋電位の特性に合わせる学習型動作推定手法は，主に学習フェーズと推定フェーズの 2 つのフェーズを有する．筋電位は微弱で変化しやすい生体信号であることから，計測された筋電位  $\mathbf{emg}_t$  はまず特徴抽出関数  $G_{FE}(\mathbf{emg}_t)$  によって筋電特徴ベクトル  $\mathbf{X}_t$  として抽出され，動作意図を反映しやすい値に変換される．

$$\mathbf{X}_t = G_{FE}(\mathbf{emg}_t) \quad (3.2)$$

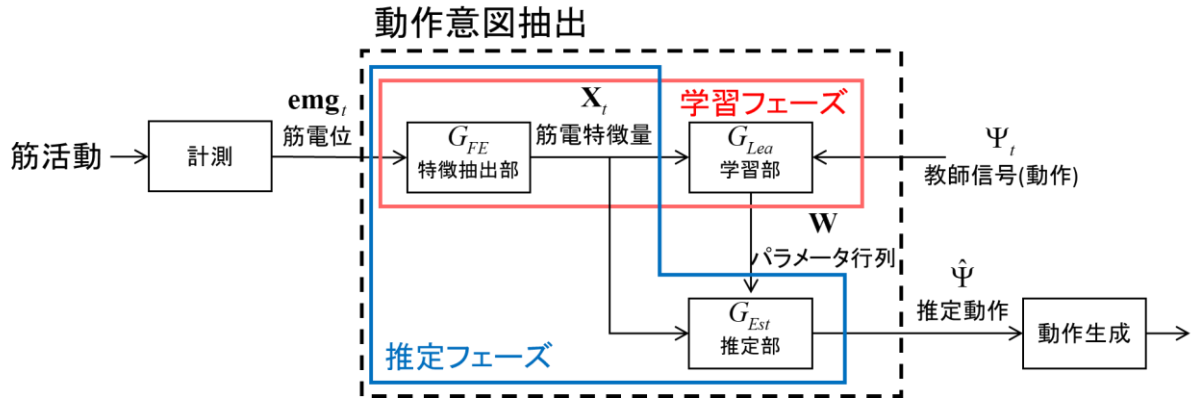


Figure 3.1 動作意図抽出の流れ

学習フェーズにおいて装着者の筋電位  $\mathbf{emg}_t$  から抽出された複数の筋電特徴量  $\mathbf{X}_t$  からなるベクトル  $\mathbf{X}$  と動作  $\Psi_t$  からなるベクトル  $\Psi$  の対応関係を学習し、パラメータ行列  $\mathbf{W}$  を得る.

$$\mathbf{W} = G_{Lea}(\mathbf{X}, \Psi) \quad (3.3)$$

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_t \\ \vdots \\ \mathbf{X}_{N_{Lea}} \end{bmatrix} \quad (3.4)$$

$$\Psi = \begin{bmatrix} \Psi_1 \\ \Psi_2 \\ \vdots \\ \Psi_t \\ \vdots \\ \Psi_{N_{Lea}} \end{bmatrix} \quad (3.5)$$

ここで、学習データセット  $\mathbf{X}$  はデータ長  $N_{Lea}$  の筋電特徴ベクトル  $\mathbf{X}_t$  のベクトルであり、教師信号ベクトル  $\Psi$  は同じくデータ長  $N_{Lea}$  の動作  $\Psi_t$  のベクトルであり、 $\mathbf{X}_t$  と  $\Psi_t$  はお互いに同じ時刻  $t$  での対応関係を持っている.

その後、推定フェーズでは装着者の筋電位  $\mathbf{emg}_t$  から抽出された筋電特徴ベクトル  $\mathbf{X}_t$  とパラメータ行列  $\mathbf{W}$  を用いて推定動作  $\hat{\Psi}$  を推定する.

$$\hat{\Psi} = G_{Ext}(\mathbf{W}, \mathbf{X}_t) \quad (3.6)$$

本論文では動作推定関数  $G(\mathbf{W}, \mathbf{emg}_t)$  として以下の 3 つの手法について提案し、それぞれの性能を比較することによって、大規模な筋電位データを用いた動作識別手法の検討を行った。

- a) 選択的線形回帰モデル(Selective Linear Regression Model : SLRM)
- b) 畳み込みニューラルネットワーク(Deep Convolutional Neural Network : DCNN)
- c) フィードフォワード型 3 層ニューラルネットワーク(Artificial Neural Network : ANN)

選択的線形回帰モデルは筆者が修士課程において提案した手法であり、複数の線形回帰モデルを組み合わせることによって把持姿勢と把持力を同時に推定するための手法である。修士課程では大規模な筋電位データでの検証が行われていなかったため、それに合わせて識別器を改良し検証を行った。

畳み込みニューラルネットワークは深層学習の一種であり、多層のレイヤのネットワークと大規模なデータによって汎化性の高い識別を実現している。この汎化性の高さをを用いて筋電位の信号特性の時変性を吸収することを考え、一般的に画像認識に用いられる DCNN を筋電位に適用するための仕組みを検証する。

フィードフォワード型 3 層ニューラルネットワークは学習型動作推定手法として従来用いられている手法である。先の 2 手法に対して比較手法として単純に大規模な筋電位データを用いて学習した場合、どのような性能を示すのか検討する。ネットワークの構造などは DCNN の畳み込み層・プーリング層を除いた後半 3 層の全結合層と等しい。

### 3.4 Selective Linear Regression Model

本手法で用いる筋電特徴量は把持力の増加に対して単調に増加しており，また，その増加の様相が把持姿勢によって異なる．このことを利用してそれぞれの姿勢を  $n$  次元空間上における直線として定義して，それぞれの直線が把持姿勢の違いを，直線上の位置が把持力の違いを表現しているものとする．筋電特徴量と把持力の関係と本手法の概要をそれぞれ Figure 3.2 と Figure 3.3 に示す．




Figure 3.2 各把持姿勢での筋電特徴量の値と把持力の関係




Figure 3.3  $n$  次元特徴空間における各姿勢のモデルの概念図

計測された筋電位は  $n$  次元特徴空間においては点として表現される．この点と各モデルとの距離を求めて、最も近いものを推定された把持姿勢と把持力として動作意図抽出を行う．より具体的に議論をするために書く筋電特徴量をレーダチャートとして表現したものを Figure 3.4 に示す．

各軸が筋電特徴量を表しており、外に行くほどその筋電特徴量が大きいとす．  $n$  次元空間上の点は各軸の値が 1 つに定まるためレーダチャート上にある定まった形を持つ．計測データは  $n$  次元空間上の点であり図中の黒線がそれを表す．それに対して  $n$  次元空間上の直線は 1 つの変数である把持力  $y$  によって変化し、レーダチャート上ではある形が把持力  $y$  によって拡大縮小されるように表現される．各姿勢のモデルは  $n$  次元空間上の直線であり、図中の赤線や青線がそれを表す．

計測データと各モデルの各軸の値の差をその筋電特徴量における誤差として、各筋電特徴量における誤差の二乗和平方根をモデル全体と計測データとの誤差  $E$  とし、これが最も小さくなるような把持姿勢と把持力の組み合わせを考える．言い換えれば、レーダチャート上の形が最も近くなるような姿勢と力を探索することになる．




Figure 3.4 筋電特徴量のレーダチャートと誤差の求め方

### 3.4.1 特徴抽出

本手法では特徴量として Mean Absolute Value (MAV) と Power Spectrum (PS) の 2 つを用いる．筋電位  $\mathbf{emg}_t$  から特徴ベクトル  $\mathbf{X}_t$  を求める特徴抽出関数  $G_{FE}(\mathbf{emg}_t)$  を以下に定める．

$$\mathbf{X}_t = G_{FE}(\mathbf{emg}_t) = \begin{bmatrix} f_{FE}(s_t^1) \\ f_{FE}(s_t^2) \\ \vdots \\ f_{FE}(s_t^h) \\ \vdots \\ f_{FE}(s_t^{N_{ch}}) \end{bmatrix} \quad (3.7)$$

ここで  $s_t^l$  は時刻  $t$  にセンサ  $h$  で計測された筋電位信号列であり， $f_{FE}(s)$  は各チャンネルの特徴抽出関数である． $N_{ch}$  はチャンネル数を意味し用いる筋電センサ数と対応する．

各チャンネル特徴抽出関数  $f_{FE}(s)$  は計測された筋電位信号列から MAV と PS の 2 つの特徴量を抽出する．

$$f_{FE}(s) = \begin{bmatrix} f_{MAV}(s) \\ f_{PS}(s) \end{bmatrix} \quad (3.8)$$

ここで  $f_{MAV}(s)$  と  $f_{PS}(s)$  はそれぞれ MAV と PS を算出する特徴抽出関数を意味する．MAV と PS は筋電位の時間領域と周波数領域の特徴量であり，装着者の動作意図に関する情報を多く含んでいる．

MAV は信号の絶対値平均であり信号の平均振幅強度を意味する．筋電位の振幅強度と筋収縮量に相関があることが知られており，MAV は把持力に関する情報を含んでいる．ある時刻  $t$  にセンサ  $h$  で計測された筋電位信号列  $s_t^h$  から特徴量 MAV を抽出する関数  $f_{MAV}(s)$  を以下のように定義する．

$$f_{MAV}(s_t^h) = \frac{1}{N_{FL}} \sum_{\tau=t-N_{FL}+1}^t |s_t^h(\tau) - \bar{s}_t| \quad (3.9)$$



$$\bar{s}_h = \frac{1}{N_{FL}} \sum_{\tau=t-N_{FL}+1}^t s^h(\tau) \quad (3.10)$$

ここで  $N_{FL}$  は解析データ長であり  $\bar{s}_h$  は信号のゼロ基準バイアスである。

表面筋電位は複数の筋から発せられた筋電位が皮膚表面へと伝わり、電極でそれぞれの筋電位が重畳した信号として計測される。筋電位が筋から電極へと伝わる間に筋と脂肪によって筋電位が減衰し周波数成分が変化する。そのため、計測された筋電位を周波数解析することによって複数の筋の情報を得ることができ、少ないセンサ数で多くの情報を得ることができる。そのため、筋電義手で多くの動作を実現しようとする研究では **PS** がよく用いられる。また、各周波数の振幅強度を積分すると信号の振幅が得られるため、**PS** も把持力に関する情報を含んでいる。

**PS** は短時間フーリエ変換(Short-Time Fourier Transform (**STFT**))を用いて算出する。フーリエ変換は無限の区間にわたって積分を行わなければならないが、**STFT** は信号列に対して窓関数を掛けながらずらしていき、その範囲ごとにフーリエ変換を行う手法である。時間で区切った際に生じる不連続性を排除し、ある周波数精度を保ちながら高速に特徴量を抽出することができる。

ある時刻  $t$  にセンサ  $h$  で計測された筋電位信号列  $s_t^h$  から特徴量 **PS** を抽出する関数  $f_{PS}(s)$  を以下のように定義する。

$$f_{PS}(s_t^h) \equiv \begin{bmatrix} f_{PS}^1(s_t^h) \\ f_{PS}^2(s_t^h) \\ \vdots \\ f_{PS}^k(s_t^h) \\ \vdots \\ f_{PS}^{N_{spect}}(s_t^h) \end{bmatrix} \quad (3.11)$$

$$f_{PS}^k(s_t^h) = \frac{1}{2I_P + 1} \sum_{n=k-I_P}^{k+I_P} |F(n, s_t^h)| \quad (3.12)$$

$$F(n, s_t^h) = \frac{1}{N_{FL}} \sum_{m=1}^{N_{FL}} s^h(t - N_{FL} + m) \cdot \exp \left\{ -j \frac{2\pi}{N_{FL}} n(m-1) \right\} \quad (3.13)$$

where  $n = 0, 1, \dots, N_{FL} - 1$

ここで  $N_{FL}$  は解析データ長であり,  $N_{spect}$  は抽出点数である. また, 前後  $I_p$  点で補間処理を施し, 信号を安定化させている.

### 3.4.2 学習

学習データセット  $\mathbf{X}$  と動作ベクトル  $\Psi$  を用いてパラメータ行列  $\mathbf{W}$  を求める学習部  $G_{Lea}(\mathbf{X}, \Psi)$  を定義する.

$$\mathbf{W} = G_{Lea}(\mathbf{X}, \Psi) \quad (3.14)$$

時刻  $k$  における動作ベクトル  $\Psi$  の要素  $\Psi_k$  は姿勢  $\omega_k$  と把持力  $y_k$  の 2 つからなる 2 項組である. また, その時の  $n$  次元特徴量は以下のようにあらわされる.

$$\Psi_k = \langle \omega_k, y_k \rangle \quad (3.15)$$

$$\mathbf{X}_k = \langle x_{1k}, \dots, x_{ik}, \dots, x_{nk} \rangle \quad (3.16)$$

姿勢  $\omega$  において把持力  $y$  のときの筋電特徴量を以下のように定義し, 線形近似した際のパラメータ  $a_{oi}, b_{oi}$  を最小二乗法により求める.

$$\hat{\mathbf{X}} = \begin{bmatrix} \hat{x}_1 \\ \hat{x}_2 \\ \vdots \\ \hat{x}_i \\ \vdots \\ \hat{x}_n \end{bmatrix} \quad (3.17)$$

$$\hat{x}_i(\omega, y) = a_{oi}y + b_{oi} \quad (3.18)$$

姿勢  $\omega_k = \omega$  である  $N$  個のデータ組  $\langle y_k, x_{1k}, \dots, x_{ik}, \dots, x_{Nk} \rangle$  を用いて以下のように連立方程式を作る.

$$\begin{cases} b_{\omega i} \sum_{k=1}^N y_k^0 + a_{\omega i} \sum_{k=1}^N y_k^1 = \sum_{k=1}^N y_k^0 x_{ik} \\ b_{\omega i} \sum_{k=1}^N y_k^1 + a_{\omega i} \sum_{k=1}^N y_k^2 = \sum_{k=1}^N y_k^1 x_{ik} \end{cases} \quad (3.19)$$

作成した連立方程式を以下のように行列式にし, 行基本変形することによってパラメータ  $a_{\omega i}, b_{\omega i}$  を求めることができる.

$$\begin{aligned} & \begin{bmatrix} \sum_k y_k^0 & \sum_k y_k^1 & \sum_k y_k^0 x_{ik} \\ \sum_k y_k^1 & \sum_k y_k^2 & \sum_k y_k^1 x_{ik} \end{bmatrix} \\ & \Rightarrow \begin{bmatrix} 1 & 0 & b_{\omega i} \\ 0 & 1 & a_{\omega i} \end{bmatrix} \end{aligned} \quad (3.20)$$

得られたパラメータ  $a_{\omega i}, b_{\omega i}$  を用いてパラメータ行列  $\mathbf{W}$  を以下のように定義する.

$$\mathbf{W} = \begin{bmatrix} \langle a_{11}, b_{11} \rangle & \cdots & \langle a_{1n}, b_{1n} \rangle \\ \vdots & \langle a_{\omega i}, b_{\omega i} \rangle & \vdots \\ \langle a_{m1}, b_{m1} \rangle & \cdots & \langle a_{mn}, b_{mn} \rangle \end{bmatrix} \quad (3.21)$$

ただし, ここで  $m$  は姿勢数であり,  $n$  は特徴次元数である.

### 3.4.3 識別

パラメータ行列  $\mathbf{W}$  と時刻  $t$  における特徴ベクトル  $\mathbf{X}_t$  を用いて推定動作  $\hat{\Psi}$  を推定する推定部  $G_{Ext}(\mathbf{W}, \mathbf{X}_t)$  を以下のように定義する.

$$\hat{\Psi} = \langle \hat{\omega}, \hat{y} \rangle = G_{Ext}(\mathbf{W}, \mathbf{X}_t) = \arg \min_{\langle \omega, y \rangle} E_{\omega}(y, \mathbf{X}_t) \quad (3.22)$$

ここで  $E_\omega(y, \mathbf{X}_t)$  は動作  $\langle \omega, y \rangle$  のモデル  $\hat{\mathbf{X}}(\omega, y)$  と特徴ベクトル  $\mathbf{X}_t$  との誤差であり以下のように定義される.

$$\begin{aligned} E_\omega(y, \mathbf{X}_t) &= \sqrt{\sum_{i=1}^n \{\hat{x}_{\omega i}(y) - x_i\}^2} \\ &= \sqrt{y^2 \sum_{i=1}^n a_{\omega i}^2 + 2y \sum_{i=1}^n a_{\omega i} (b_{\omega i} - x_i) + \sum_{i=1}^n (b_{\omega i} - x_i)^2} \end{aligned} \quad (3.23)$$

$$\hat{\mathbf{X}}(\omega, y) = \langle \hat{x}_{\omega 1}(y), \hat{x}_{\omega 2}(y), \dots, \hat{x}_{\omega i}(y), \dots, \hat{x}_{\omega n}(y) \rangle \quad (3.24)$$

$$\mathbf{X}_t = \langle x_1, x_2, \dots, x_i, \dots, x_n \rangle \quad (3.25)$$

ここで根号内の2次方程式の判別式を  $D$  とおく.

$$D = \left( 2 \sum_i^n \{a_i (b_i - x_i)\} \right)^2 - 4 \sum_i^n a_i^2 \cdot \sum_i^n \{b_i - x_i\}^2 \quad (3.26)$$

この時, 判別式  $D$  と誤差  $E$  の関係を **Figure 3.5** に示す. 姿勢  $\omega$  における誤差  $E_\omega$  が最小となるときの力  $y$  を求めたい. 判別式  $D$  によって場合分けを行い, 最小の誤差  $E_\omega$  を求めることになるが, 判別式  $D$  は以下の式より必ず  $D \leq 0$  となる.

$A = a_i \quad B = b_i - x_i$  とすると

$$\begin{aligned} D &= \left( 2 \sum_i^n AB \right)^2 - 4 \sum_i^n A^2 \cdot \sum_i^n B^2 \\ &= 4 \left\{ \left( \sum_i^n AB \right)^2 - \sum_i^n A^2 \cdot \sum_i^n B^2 \right\} \\ &= 4 \left\{ \left( \sum_i^n (AB)^2 + 2 \sum_i^n \sum_{j>i}^n A_i B_i A_j B_j \right) - \left( \sum_i^n (AB)^2 + \sum_i^n \sum_{j>i}^n \{A_i^2 B_j^2 + A_j^2 B_i^2\} \right) \right\} \\ &= -4 \left\{ \sum_i^n \sum_{j>i}^n \{A_i^2 B_j^2 + A_j^2 B_i^2 - 2 A_i B_i A_j B_j\} \right\} \\ &= -4 \left\{ \sum_i^n \sum_{j>i}^n (A_i B_j - A_j B_i)^2 \right\} \leq 0 \end{aligned} \quad (3.27)$$

よって、極値である  $\frac{dE}{dy} = 0$  となるときの  $y$  が誤差  $E_\omega$  を最小とする  $\hat{y}_\omega$  である。




Figure 3.5 判別式と誤差の関係

$$\begin{aligned} \frac{dE_\omega(y, \mathbf{X}_t)}{dy} &= \frac{1}{2} \times \frac{1}{\sqrt{\sum_{i=1}^n \{\hat{x}_{\omega i}(y) - x_i\}^2}} \times \frac{d}{dy} \left( \sum_{i=1}^n \{\hat{x}_{\omega i}(y) - x_i\}^2 \right) \\ &= \frac{\sum_{i=1}^n \{2a_{\omega i}^2 y + 2a_{\omega i}(b_{\omega i} - x_i)\}}{2\sqrt{\sum_{i=1}^n \{a_{\omega i} y + b_{\omega i} - x_i\}^2}} = 0 \end{aligned} \quad (3.28)$$

i) 分母が 0 でないとき

$$\begin{aligned} \sum_{i=1}^n \{2a_{\omega i}^2 y + 2a_{\omega i}(b_{\omega i} - x_i)\} &= 0 \\ \Rightarrow y \sum_{i=1}^n a_{\omega i}^2 &= \sum_{i=1}^n \{a_{\omega i}(x_i - b_{\omega i})\} \\ \Rightarrow y &= \frac{\sum_{i=1}^n \{a_{\omega i}(x_i - b_{\omega i})\}}{\sum_{i=1}^n a_{\omega i}^2} \end{aligned} \quad (3.29)$$

ii) 分母が 0 のとき (D=0)

$$\sqrt{\sum_{i=1}^n \{\hat{x}_{\omega i}(y) - x_i\}^2} = E = 0 \quad (3.30)$$

$$\begin{aligned}
 & \begin{cases} x_1 = \hat{x}_{\omega 1} = a_{\omega 1}y + b_{\omega 1} \\ x_2 = \hat{x}_{\omega 2} = a_{\omega 2}y + b_{\omega 2} \\ \vdots \\ x_i = \hat{x}_{\omega i} = a_{\omega i}y + b_{\omega i} \\ \vdots \\ x_n = \hat{x}_{\omega n} = a_{\omega n}y + b_{\omega n} \end{cases} \\
 & \Rightarrow \sum_{i=1}^n x_i = \sum_{i=1}^n \{a_{\omega i}y + b_{\omega i}\} \\
 & \Rightarrow \sum_{i=1}^n a_{\omega i}x_i = \sum_{i=1}^n \{a_{\omega i}^2 y + a_{\omega i}b_{\omega i}\} \\
 & \Rightarrow \sum_{i=1}^n a_{\omega i}^2 y = \sum_{i=1}^n \{a_{\omega i}x_i - a_{\omega i}b_{\omega i}\} \\
 & \Rightarrow y = \frac{\sum_{i=1}^n \{a_{\omega i}(x_i - b_{\omega i})\}}{\sum_{i=1}^n a_{\omega i}^2}
 \end{aligned} \tag{3.31}$$

ただし,  $\sum_{i=1}^n a_{\omega i}^2 = 0 \rightarrow \forall_i a_{\omega i} = 0$  のとき, 安静など把持力による筋電位の変化がないことを意味するため,  $y=0$  とする.

i), ii)より姿勢 $\omega$ における誤差 $E_\omega$ を最小とする推定把持力 $\hat{y}_\omega$ は判別式 $D$ によらず以下のように定義される.

$$\hat{y}_\omega = \frac{\sum_{i=1}^n \{a_{\omega i}(x_i - b_{\omega i})\}}{\sum_{i=1}^n a_{\omega i}^2} \tag{3.32}$$

また, 姿勢 $\omega$ における最小の誤差 $E_\omega(\hat{y}_\omega)$ は $\hat{y}_\omega$ を用いて表現できる.

$$E_\omega(\hat{y}_\omega) = \sqrt{\sum_{i=1}^n \{a_{\omega i}\hat{y}_\omega + b_{\omega i} - x_i\}^2} \tag{3.33}$$

以上より, 姿勢 $\omega$ ごとに最小の誤差 $E_\omega(\hat{y}_\omega)$ とその時の推定把持力 $\hat{y}_\omega$ が求まった.

$$\left\{ \begin{array}{l} \langle E_1(\hat{y}_1), 1, \hat{y}_1 \rangle \\ \vdots \\ \langle E_\omega(\hat{y}_\omega), \omega, \hat{y}_\omega \rangle \\ \vdots \\ \langle E_m(\hat{y}_m), m, \hat{y}_m \rangle \end{array} \right. \quad (3.34)$$

全ての姿勢の中で最も  $E$  を小さくする把持姿勢  $\omega$  と把持力  $y$  の組み合わせを推定動作  $\hat{\Psi}$  とするため,

$$\begin{aligned} \hat{\Psi} &= \langle \hat{\omega}, \hat{y} \rangle \\ \hat{\omega} &= \arg \min_{\omega} E_{\omega}(\hat{y}_{\omega}) \\ \hat{y} &= \hat{y}_{\omega} \end{aligned} \quad (3.35)$$

として推定動作  $\hat{\Psi}$  を求めることができる.

## 3.5 Deep Convolutional Neural Network

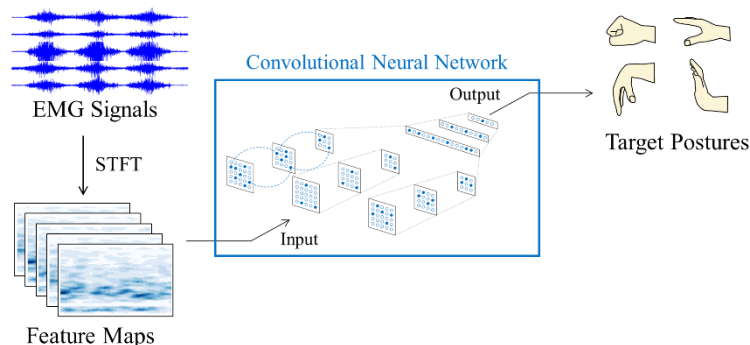


Figure 3.6 DCNN の概要

畳み込みニューラルネットワーク (DCNN) は深層学習の一種であり、ネットワークの結合を局所化することによって過学習を防ぎ、より深層なネットワーク構造を実現させ汎化性の高い識別が行える。

DCNN は画像認識や音声認識において高い汎化性を有する識別を行えることが示されているが、生体信号に対して用いている例はほとんど存在しない。そこで本手法では筋電位を短時間フーリエ変換 (Short Time Fourier Transform; STFT) によって時間と周波数のマップに変換することによって筋電位を画像として扱い DCNN の入力として用いる。

また、把持姿勢と把持力両方をパターンとして扱うことによって把持姿勢と把持力の同時制御を実現する。

### 3.5.1 特徴抽出

本手法では特徴量として時間・周波数成分を含む特徴マップとして 2 次元画像を用いて動作意図推定を行う。生体信号である筋電位を画像として扱うことによって DCNN の入力として使用できるようになり、画像認識手法を応用することができる。また、MAV を抽出し、畳み込み層・プーリング層の後で特徴量を統合し、全結合層の学習・推定に用いる。

特徴マップ及び MAV はチャンネルごとに求める。時刻  $t$  での筋電位信号列



$\mathbf{emg}_t$  から筋電特徴ベクトル  $\mathbf{X}_t$  を求める特徴抽出関数  $G_{FE}(\mathbf{emg}_t)$  を以下に定義する.

$$\mathbf{X}_t = G_{FE}(\mathbf{emg}_t) = \begin{bmatrix} f_{FE}(s_t^1) \\ f_{FE}(s_t^2) \\ \vdots \\ f_{FE}(s_t^h) \\ \vdots \\ f_{FE}(s_t^{N_{ch}}) \end{bmatrix} = \begin{bmatrix} \langle f_{MAV}(s_t^1), f_{MAP}(s_t^1) \rangle \\ \langle f_{MAV}(s_t^2), f_{MAP}(s_t^2) \rangle \\ \vdots \\ \langle f_{MAV}(s_t^h), f_{MAP}(s_t^h) \rangle \\ \vdots \\ \langle f_{MAV}(s_t^{N_{ch}}), f_{MAP}(s_t^{N_{ch}}) \rangle \end{bmatrix} \quad (3.36)$$

ここで  $f_{FE}(s_t^h)$  はチャンネルごとの特徴抽出関数を意味し, MAV と特徴マップの 2 つの値を持つ 2 項組から構成される. MAV を抽出する関数  $f_{MAV}(s_t^h)$  を以下に定義する.

$$f_{MAV}(s_t^h) = \begin{bmatrix} \frac{N_{ext}}{N_{time}} \sum_{\tau=t-\frac{(N_{ext}-1)}{N_{ext}}N_{time}+1}^{t-\frac{(N_{ext}-1)}{N_{ext}}N_{time}} H(\tau, s_t^h) \\ \frac{N_{ext}}{N_{time}} \sum_{\tau=t-\frac{(N_{ext}-2)}{N_{ext}}N_{time}+1}^{t-\frac{(N_{ext}-2)}{N_{ext}}N_{time}} H(\tau, s_t^h) \\ \vdots \\ \frac{N_{ext}}{N_{time}} \sum_{\tau=t-\frac{(N_{ext}-i)}{N_{ext}}N_{time}+1}^{t-\frac{(N_{ext}-i)}{N_{ext}}N_{time}} H(\tau, s_t^h) \\ \vdots \\ \frac{N_{ext}}{N_{time}} \sum_{\tau=t-\frac{1}{N_{ext}}N_{time}+1}^t H(\tau, s_t^h) \end{bmatrix} \quad (3.37)$$

$$H(t, s_t^h) = \frac{1}{N_{FL}} \sum_{\tau=t-N_{FL}+1}^t |s^h(\tau) - \bar{s}_h| \quad (3.38)$$

$$\bar{s}_h = \frac{1}{N_{FL}} \sum_{\tau=t-N_{FL}+1}^t s^h(\tau) \quad (3.39)$$

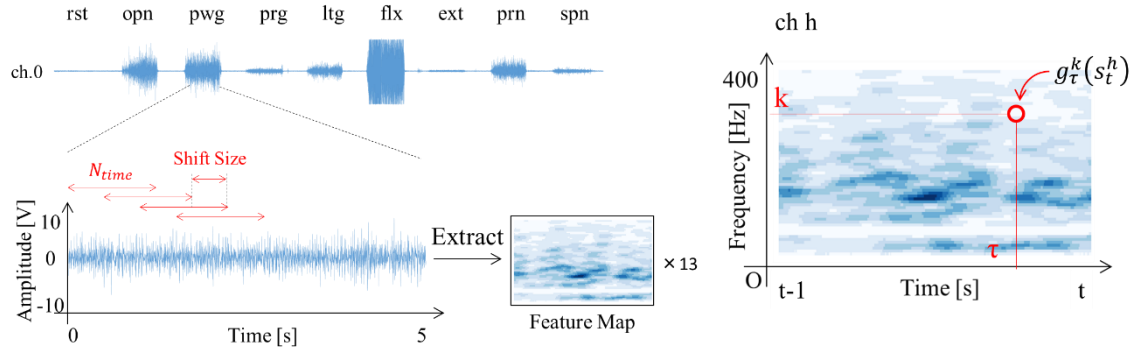


Figure 3.7 特徴マップ抽出

ここで  $N_{time}$  は抽出窓の時間長であり,  $N_{ext}$  は抽出点数,  $N_{FL}$  は解析データ長を表す.  $N_{time}$  は後述の特徴マップの時間長と等しい長さである. 具体的には本論文では  $N_{time}$  は 1 秒間, サンプル周波数が 1600Hz の場合 1600 data とし, 一度の推定に過去 1 秒間の筋電位情報を用いることとなる.  $N_{time}$  の長さを有する筋電位信号列から解析データ長  $N_{FL}$  で MAV を算出し,  $N_{ext}$  個の区間に分離し平均値を求めることによってダウンサンプリングする.  $N_{FL}$  に対して  $N_{time}$  は十分に大きな値を有する. 具体的には本論文では  $N_{FL}$  は 512data である. 結果としてチャンネル  $h$  の時刻  $t$  における MAV 特徴量として  $N_{ext}$  次元のベクトルを得る.

特徴マップは STFT を用いて構築する. 特徴マップを抽出する関数  $f_{MAP}(s_t^h)$  を以下に定義する.

$$f_{MAP}(s_t^h) = \begin{bmatrix} g_1^1(s_t^h) & \cdots & g_{N_{time}}^1(s_t^h) \\ \vdots & g_\tau^k(s_t^h) & \vdots \\ g_1^{N_{spect}}(s_t^h) & \cdots & g_{N_{time}}^{N_{spect}}(s_t^h) \end{bmatrix} \quad (3.40)$$

$$g_\tau^k(s_t^h) = \frac{1}{2I_P + 1} \sum_{n=k-I_P}^{k+I_P} |G(s_t^h, n)| \quad (3.41)$$

$$G(s_t^h, n) = \sum_{m=1}^{N_{FL}} s_{(t-N_{FL}+m)}^h \cdot e^{-i \frac{2\pi(m-1)n}{N_{FL}}} \quad (3.42)$$

Table 3.2 特徴マップ生成の実際のパラメータの値

$I_p$	$N_{FL}$	$N_{ch}$	$N_{time}$	$N_{spt}$
2	512	5	1600 (= 1 s)	64 (= 400 Hz)

ここで  $N_{FL}$  は解析データ長であり,  $N_{time}$  と  $N_{spt}$  はそれぞれ時間と周波数のサンプル数を表す.  $I_p$  は平滑化幅である. 安定的な識別を行うために, 特徴マップはお互い重なるようにシフトしながら抽出される. 本研究で使用した実際のパラメータの値を Table 3.2 に示す.

### 3.5.2 DCNN のデータ構造

DCNN のデータ構造を Figure 3.8 に示す. DCNN は 9 層のレイヤから構築されており, 畳み込み層とプーリング層と全結合層を有する. P1 層と C2 層, P3 層と C4 層, P5 層と M6 層の間の結合はプーリング層であり, C2 層と P3 層, C4 層と P5 層の間の結合は畳み込み層である. M6 層と F7 層の間の結合は各チャンネルの情報を統合する. F7 層と F8 層, F8 層と F9 層の間の結合は全結合層であり識別を担う. 最終的に F9 層で 0 から 1 の神経発火として動作を表現する. 最終層のニューロン数と識別動作数が対応しており, 最も大きな値を持つニューロンの動作を識別動作としてその動作の把持姿勢と把持力を推定把持姿勢及び推定把持力とする.




Figure 3.8 DCNN のデータ構造

### 3.5.1 学習部と識別部

ネットワークの構造が深い場合、一度に学習しようとする誤差逆伝搬がうまく機能せず学習ができなくなってしまう.そこで畳み込み層ではAutoencoderという手法を用いて入力層から順番に積み上げ式に学習を行っていく. Autoencoder とは砂時計型のニューラルネットワークを用いて入力と出力が同じ値になるように学習することによって, 中間層で次元圧縮を行う手法である. プーリング層は学習が不要であるため, 学習部では畳み込み層と全結合層のネットワークの重みを学習する.

筋電特徴ベクトル  $\mathbf{X}$  と動作ベクトル  $\Psi$  を用いてパラメータ行列  $\mathbf{W}$  を求める学習部  $G_{Lea}(\mathbf{X}, \Psi)$  を定義する.

$$\mathbf{W} = G_{Lea}(\mathbf{X}, \Psi) \quad (3.43)$$

時刻  $k$  における動作ベクトル  $\Psi$  の要素  $\Psi_k$  と筋電特徴ベクトル  $\mathbf{X}$  の要素である  $n$  次元特徴ベクトル  $\mathbf{X}_k$  は以下のようにあらわされる.

$$\Psi_k = \langle \omega_k, y_k \rangle \quad (3.44)$$

$$\mathbf{X}_k = \begin{bmatrix} \langle \mathbf{x}_{MAV}, \mathbf{x}_{MAP} \rangle_1 \\ \vdots \\ \langle \mathbf{x}_{MAV}, \mathbf{x}_{MAP} \rangle_h \\ \vdots \\ \langle \mathbf{x}_{MAV}, \mathbf{x}_{MAP} \rangle_{N_{ch}} \end{bmatrix} \quad (3.45)$$

ここで  $\omega_k$  と  $y_k$  はそれぞれ把持姿勢と把持力を表す．本研究では  $\mathbf{x}_{MAV}$  は 6 次元のベクトル，  $\mathbf{x}_{MAP}$  は  $64 \times 1089$  の 2 次元画像である．

ニューラルネットワークにおいては各動作を出力層のニューロンと対応付けて学習を行う．そこで姿勢と力の組み合わせを用いて以下のように教師信号  $\mathbf{T}_k$  を作る．

$$\mathbf{T}_k = \begin{bmatrix} o_1 \\ \vdots \\ o_{N_\omega \times N_y} \end{bmatrix} \quad (3.46)$$

$$o_i = \begin{cases} 1 & (i = y_k + \omega_k \times N_y) \\ 0 & other \end{cases} \quad (3.47)$$

$o$  は出力層のニューロンの値であり  $N_\omega$  と  $N_y$  はそれぞれ離散値である姿勢と力のパターン数を意味する．教師信号はどれか一つのニューロンのみが 1 になりそれ以外が 0 になるようなベクトルであり，畳み込み層を学習し終えた後，全結合層を学習する際に特徴ベクトル  $\mathbf{X}_k$  を入力した際に出力が  $\mathbf{T}_k$  となるようにネットワークの重みを決定する．各層の詳細は各項で述べる．

パラメータ行列  $\mathbf{W}$  は畳み込み層と全結合層のそれぞれの重みと閾値を要素に持つ．

$$\mathbf{W} = \langle \mathbf{W}_C, \mathbf{th}_C, \mathbf{W}_F, \mathbf{th}_F \rangle \quad (3.48)$$

$$\mathbf{W}_C = \begin{bmatrix} \langle \mathbf{w}^3, \mathbf{w}^5 \rangle_1 \\ \vdots \\ \langle \mathbf{w}^3, \mathbf{w}^5 \rangle_h \\ \vdots \\ \langle \mathbf{w}^3, \mathbf{w}^5 \rangle_{N_{ch}} \end{bmatrix} \quad \mathbf{w}^l = \begin{bmatrix} \mathbf{w}_1^l \\ \vdots \\ \mathbf{w}_f^l \\ \vdots \\ \mathbf{w}_{N_f}^l \end{bmatrix} \quad l = 3, 5 \quad (3.49)$$

$$\mathbf{th}_C = \begin{bmatrix} \langle \mathbf{th}^3, \mathbf{th}^5 \rangle_1 \\ \vdots \\ \langle \mathbf{th}^3, \mathbf{th}^5 \rangle_h \\ \vdots \\ \langle \mathbf{th}^3, \mathbf{th}^5 \rangle_{N_{ch}} \end{bmatrix} \quad \mathbf{th}^l = \begin{bmatrix} \mathbf{th}_1^l \\ \vdots \\ \mathbf{th}_f^l \\ \vdots \\ \mathbf{th}_{N_f}^l \end{bmatrix} \quad l = 3, 5 \quad (3.50)$$

$$\mathbf{W}_F = \langle \mathbf{w}^7, \mathbf{w}^8 \rangle \quad (3.51)$$

$$\mathbf{th}_F = \langle \mathbf{th}^7, \mathbf{th}^8 \rangle \quad (3.52)$$

$\mathbf{W}_C$  と  $\mathbf{th}_C$  は畳み込み層の重みと閾値であり、 $N_{ch}$  はチャンネル数、 $N_f$  はフィルタ数を表す。 $\mathbf{w}_f^l$  と  $\mathbf{th}_f^l$  はそれぞれ  $l$  層目のフィルタ  $f$  の重みと閾値であり 2 次元の配列である。 $\mathbf{W}_F$  と  $\mathbf{th}_F$  は畳み込み層の重みと閾値であり  $\mathbf{w}^l$  と  $\mathbf{th}^l$  はそれぞれ  $l$  層目の重みと閾値であり 1 次元の配列である。

パラメータ行列  $\mathbf{W}$  と時刻  $t$  における特徴ベクトル  $\mathbf{X}_t$  を用いて推定動作  $\hat{\Psi}$  を推定する推定部  $G_{Ext}(\mathbf{W}, \mathbf{X}_t)$  を以下のように定義する。

$$\hat{\Psi} = \langle \hat{o}, \hat{y} \rangle = G_{Ext}(\mathbf{W}, \mathbf{X}_t) = \begin{bmatrix} G_\omega(\mathbf{o}) \\ G_y(\mathbf{o}) \end{bmatrix} \quad (3.53)$$

$$G_\omega = \text{down} \left( \frac{\arg \max_i(o_i)}{N_y} \right) \quad (3.54)$$

$$G_y = \text{mod} \left( \arg \max_i(o_i), N_y \right) \quad (3.55)$$

$$\mathbf{o} = \begin{bmatrix} o_1 \\ \vdots \\ o_i \\ \vdots \\ o_{N_o \times N_y} \end{bmatrix} = \begin{bmatrix} x_1^9 \\ \vdots \\ x_i^9 \\ \vdots \\ x_{N_o \times N_y}^9 \end{bmatrix} \quad (3.56)$$

ここで  $down()$  と  $mod()$  は切り捨て・剰余を意味する関数である．つまり  $\mathbf{W}$  と  $\mathbf{X}_l$  を用いて計算された最終出力層  $\mathbf{o}$  の内，最も値が大きいニューロン  $o_i$  に対応する姿勢と力を推定把持姿勢・推定把持力とする．各層の詳細については各項で述べる．

### 3.5.2 プーリング層

プーリングは画像処理における縮小画像の作成に相当する処理である．Figure 3.9 にプーリング層の概要を示す．過剰な次元数を削減する効果があるとともに，軽微な位置ズレを補正する効果がある．本研究ではフィルタ内の平均値を用いて **Pooling** を行う **Mean Pooling** をプーリング層として用いる．一般的な画像認識ではフィルタ内の最大値を用いて **Pooling** を行う **Max Pooling** がよく用いられるが，筋電位のような生体信号はノイズに弱く外れ値を含むことがあるため，適切ではない．**Mean Pooling** を以下に定義する．

$$x^{l+1}(p, q) = \frac{1}{N_p N_q} \sum_{n=0}^{N_p-1} \sum_{m=0}^{N_q-1} x^l(p+n, q+m) \quad (3.57)$$

ここで  $x^l(p, q)$  は  $l$  層目の水平座標と鉛直座標がそれぞれ  $p$  と  $q$  のニューロンの値を表しており， $N_p$  と  $N_q$  はそれぞれフィルタの水平方向，鉛直方向のサイズである．




Figure 3.9 画像認識におけるプーリング層の概要と各手法の違い

### 3.5.3 畳み込み層

畳み込み層ではフィルタを用いて信号の特徴を抽出し次元圧縮を行う。畳み込み層の概要を Figure 3.10 に示す。具体的にはフィルタの重みを砂時計型のニューラルネットワークを用いることによって学習する。砂時計型ニューラルネットワークは 3 層のニューラルネットワークであり、入力と出力に同じ値を持ち、中間層の数が入力層、出力層より少なくなっている。入力に対して少ない中間層を経由して入力と同じ出力を出すようにネットワークを学習することによって中間層で次元削減を行う。また、活性化関数として leaky rectified linear unit (leaky ReLU)を用いる。畳み込み層を以下に定義する。

$$x_f^{l+1}(p, q) = \text{leakyReLU} \left( \frac{1}{N_p N_q} \sum_{n=0}^{N_p-1} \sum_{m=0}^{N_q-1} w_f'(n, m) \cdot x^l(p+n, q+m) - th_f^l(p, q) \right) \quad (3.58)$$

$$\text{leakyReLU}(u) = \begin{cases} u & (u \geq 0) \\ 0.001u & (u < 0) \end{cases} \quad (3.59)$$




Figure 3.10 画像認識における畳み込み層の概要とフィルタによる特徴抽出



ここで  $x_f^l(p, q)$  は  $l$  層のフィルタ  $f$  の座標  $(p, q)$  のニューロンの値を表しており、同様に  $w_f^l(m, n)$  は  $l$  層のフィルタ  $f$  の座標  $(m, n)$  の重み、 $th_f^l(p, q)$  は  $l$  層のフィルタ  $f$  の座標  $(p, q)$  の閾値を表す。これに対して学習フェーズでは重みを学習するが以下のように重みを更新していく。

$$\begin{aligned} \mathbf{w}_f^l &\leftarrow \mathbf{w}_f^l + \eta \times \mathbf{x}^l \times \Delta^l \\ \Delta^l &= \mathbf{w}_f^{l+1} \times \Delta^{l+1} \quad \Delta^{L+1} = \mathbf{x}^L - \mathbf{T} \end{aligned} \quad (3.60)$$

$\mathbf{x}$  と  $\mathbf{w}$  はそれぞれ  $x$  と  $w$  のベクトルであり、 $\Delta$  は誤差ベクトルであり、 $\eta$  は学習率である。また  $\mathbf{T}$  は教師信号であり、砂時計型ニューラルネットワークの場合、入力と一致する。つまり、最終出力層  $\mathbf{x}^L$  と  $\mathbf{T}$  の差を誤差として誤差逆伝搬法によりこの誤差が小さくなるようにネットワークを学習する。

チャンネルごとに入力に近い層からミニバッチ処理によって学習を行っていく。ミニバッチ処理とは学習データから一部のデータを抽出して構築したミニバッチを用いて学習を行う手法であり、一定回数学習する毎にミニバッチを構築しなおして学習していく。学習データを一度に学習するのではなく少しずつ抽出して学習することによって過学習を防ぐとともに、大規模なデータの学習による計算負荷を軽減させる効果がある。誤差の二乗和平方根(RMS)を 100 回学習する毎に記録しておき、現在の RMS が記録した RMS の 2 倍以上の値になった場合には学習が発散したと判断して、学習率  $\eta$  を半分の値にして再度学習をやり直す。

### 3.5.4 全結合層

各チャンネルの情報を結合して 1 次元化した後に、全結合層によって識別を行う。活性化関数として Sigmoid 関数を用いる。全結合層を以下に定義する。

$$x^{l+1}(m) = \text{Sigmoid} \left( \sum_{n=0}^{N-1} w^l(n, m) \cdot x^l(n) - th^l(m) \right) \quad (3.61)$$

$$\text{Sigmoid}(u) = \frac{1}{1 + e^{-u}} \quad (3.62)$$

学習フェーズでは畳み込み層と同様にミニバッチ処理によって学習を行う。また、100 回学習する毎に RMS を記録しておき現在の RMS が 2 倍以上になった

場合には学習率を半分にして学習をやり直す.

$$\begin{aligned}\mathbf{w}^l &\leftarrow \mathbf{w}^l + \eta \times \Delta^l \times \mathbf{x}^l \\ \Delta^l &= \mathbf{w}^{l+1} \times \Delta^{l+1} \times devSigmoid(\mathbf{x}^l) \quad \Delta^{L+1} = \mathbf{x}^L + \mathbf{T} \\ devSigmoid(u) &= \frac{d}{du} Sigmoid(u) \\ &= Sigmoid(u) \cdot (1 - Sigmoid(u))\end{aligned}\tag{3.63}$$

## 3.6 Artificial Neural Network

比較手法として従来筋電義手のパターン認識型の制御手法としてよく用いられるフィードフォワード型の 3 層ニューラルネットワーク(ANN)を用いる。ANN の構造を Figure 3.11 に示す。

特徴量としては 3.4.1 項で定義した MAV と PS からなる特徴量を用いる。

またネットワークの構造は DCNN の全結合層と基本的に同じである。ただし、ANN の入力層、DCNN の F7 層に関しては前に畳み込み層がなく、直接特徴量が入力されるためサイズが異なる。本研究の場合は 5 チャンネルの信号を用いてチャンネルごとに MAV が 1 次元、PS が 16 次元の計 85 次元の特徴量を用いるため、入力層もそのサイズとなる。

また、入力層のサイズが小さく計算負荷が大きくないため、DCNN ではミニバッチ処理を用いていたが、ANN では全ての学習データを用いて学習を行うバッチ処理を用いる。

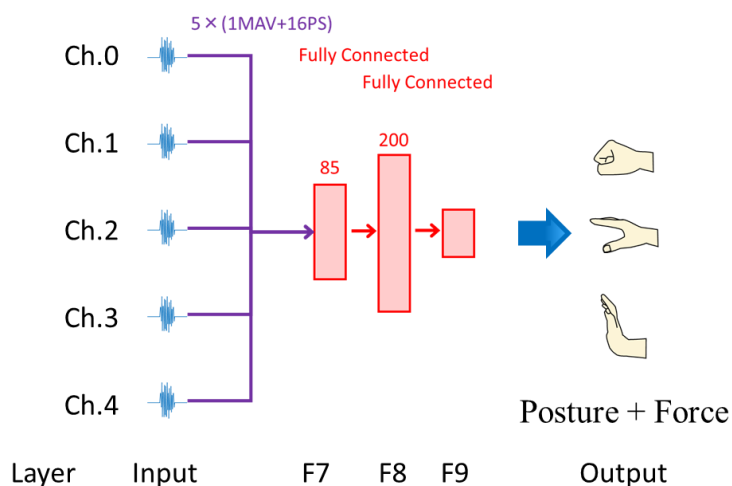


Figure 3.11 ANN のデータ構造

### 3.7 学習データの構築方法

質の高い学習データを収集するために必要なことは教師信号と筋電位の対応関係を確実にするためにしっかりと統制をとることが重要である。人は手に同じ力を入れ続けるということは苦手であり、徐々に力が弱くなっていくってしまう。また、把持姿勢に関しても装着者の把持戦略の変化によって力の入れ方が変わってしまい、見た目的には同じ姿勢でも筋電位的には大きく異なってしまうことがある。このように同じ動作意図のつもりでも筋電位が異なっており、それによって筋電位と動作意図を関係付けるモデル化が困難になってしまうという問題が発生する。

このような問題を防ぐためには装着者に適切にフィードバックを行い、本人の動作意図と実際に発現している筋電位とのずれを無くすることが有用である。そこで安定した筋電位収集を行うために、筋電位収集アプリケーションの開発を行った。アプリケーションのインタフェースを Figure 3.12 に示す。



Figure 3.12 開発した筋電位収集アプリケーションのインタフェース

インタフェースの上部中央には生の筋電位信号が、右側には筋電位の周波数特性が示されている。生の筋電位信号は最新の値を右端として過去約 5 秒間のデータが更新されチャンネル別に表示されている。周波数特性はレーダチャートとして表現されており、12 時の方向から時計回りに各チャンネルの筋電位を意味し、それぞれ STFT によって生の筋電位信号が周波数に分解され 0 から 400Hz の成分の強度として表示されている。インタフェースの下部には MAV の値の平均値が波形として表示されている。赤い線が目標波形、白い線が計測波形を意味する。被験者は計測波形が目標波形に沿うように把持力を変化させる。また、波形の上部には把持姿勢が指示されており被験者はそれに合わせて把持姿勢を変化させる。周波数特性のレーダチャートの内側の面積と MAV の平均値は数学的には比例の関係にある。左側にあるボタンによって筋電位を収集するが、画面下部の MAV の波形と対応しており、決められた時間の筋電位を正確に収集することができる。

目標波形の形とそのパラメータに関して Figure 3.13 と Table 3.3 に示す。目標波形は Rest time, Keep time, Climbing time, Peak, Repeat の 5 つのパラメータから構成されている。Rest time は動作間の休憩時間でありタスクの始めと終わりにそれぞれ 1/2 ずつ配置される。Keep time は把持力を維持し続けている時間であり、この維持している間の筋電位を抽出し学習データの構築に用いる。Climbing time は休憩状態から把持状態への遷移時間であり、急激に筋電位を変化させることを防ぎ、安定的な計測を行うためのものである。Peak は維持する把持力の強さであり把持力は筋収縮量と相関のある MAV を用いて統制を行う。Peak を複数定義することによって把持力の強さによって把持姿勢のパターンの違いの表現を防ぐことができる。例えば強い把持を握力把持、弱い把持を精密把持としてパターン認識として学習してしまうような場合である。また、Peak を複数定義することによってデータの多様性を確保し、汎化性の高い学習が行えることが期待される。Repeat は繰り返し回数であり、把持姿勢の数と同数である。全ての姿勢数分の筋電位を収集するまでを一区切りとしてこれを 1 試行とする。

識別率は把持力を維持している Keep time の間の筋電位を用いて求める。Keep time の間で把持力を維持している際にどのくらいの時間正しく識別できているかを把持姿勢ごとに求め、その姿勢間の平均値を識別率とする。例として 5 秒間把持力を維持している間に 0.5 秒間誤識別した場合はその姿勢の識別率を 90%とする。




Figure 3.13 目標波形のパラメータ

Table 3.3 実際のパラメータの値

Rest time	4 s
Keep time	5 s
Climbing time	1 s
Peak	1.5, 2.0, 2.5 V
Repeat	9 postures

収集されて 1 試行分の筋電位の例を Figure 3.14 に示す．図より計測波形が目標波形に追従しており，また，把持姿勢によって発現する筋電位が異なっていることが分かる．このうち，各姿勢で把持力を維持している筋電位を抽出して学習データを構築する．

筋電センサを付け外しせずに 9 試行分の筋電位を収集し，これを学習データ 1 日分とする．目標把持力は姿勢によってランダムに決定されており，9 試行の内に 3 段階の目標把持力がそれぞれ 3 試行ずつ出現するようになっている．そのため，本研究では 1 日分の学習データは 9 つの姿勢で 5 秒間把持力を維持している筋電位のデータが 3 段階の把持力で 3 試行ずつ含まれることになる．計測サンプリング周波数が 1600Hz であり，計測チャンネル数が 5ch なので，1 日分の学習データは 9 試行×9 姿勢×5 秒×5ch×1600Hz の 324 万 data の筋電位を有している．

本論文における以後の検証ではこの 1 日分の学習データを基本単位として用いる．

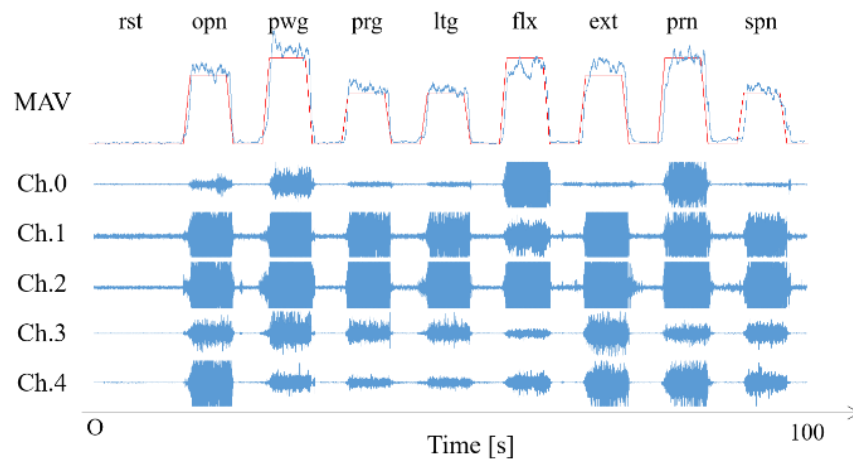


Figure 3.14 収集された筋電位の例

### 3.8 おわりに

本章では大規模な筋電位を用いた動作意図抽出法について述べた。パターン認識型と併用型の動作意図抽出手法の2つのアプローチとしてそれぞれ畳み込みニューラルネットワークと選択的線形回帰モデルを提案し、また、比較手法としてパターン認識型の動作意図抽出法であるフィードフォワード型の3層ニューラルネットワークについても述べた。また、本章の始めにはこれらの手法に共通する部分として学習型動作意図抽出法の流れと入力である筋電センサから計測された筋電位に関して詳しく述べた。また、本章の終わりにはこれらの提案手法を学習するための学習データの質を高めるために大規模な筋電位を収集するプロトコルと学習データの構築法に関して述べた。

3.2 節では本論文で扱う変数についてまとめた。

3.3 節では学習型動作意図抽出法の流れとして特徴抽出、学習部、識別部を定義して、2つの提案手法と比較手法について述べた。

3.4 節では併用型の動作意図抽出方法である選択的線形回帰モデルに関して詳しく述べた。

3.5 節ではパターン認識型の動作意図抽出方法である畳み込みニューラルネットワークに関して詳しく述べた。

3.6 節では比較手法としてパターン認識型の動作意図抽出方法であるフィードフォワード型の3層ニューラルネットワークについて述べた。

3.7 節では質の高い大規模な筋電位を収集するプロトコルに関して述べ、開発したアプリケーションと学習データの構築法に関して述べた。



## 第4章 深層学習に関連するハイパーパラメータの決定

---

4.1 はじめに .....	90
4.2 探索すべきハイパーパラメータ .....	91
4.3 学習データ .....	93
4.3.1 白色化 .....	93
4.3.2 学習日数 .....	94
4.4 ネットワーク構造 .....	96
4.4.1 学習率 .....	96
4.4.2 ドロップアウト率 .....	97
4.4.3 ミニバッチサイズ .....	99
4.4.4 特徴抽出フレームのサイズによる識別率と即時性 .....	101
4.5 まとめ .....	104
4.6 おわりに .....	106

---

### 4.1 はじめに

第3章で提案した手法のうち、選択的線形回帰モデル(SLRM)は筆者が考案した手法であり、筋電位の特性に合わせて設計されているが、畳み込みニューラルネットワーク(DCNN)は画像認識を主として様々な分野に用いられている汎化的な識別手法をもとに筋電義手の動作意図抽出に合わせて構築されている。DCNNには人が設計しなければならないハイパーパラメータといわれるパラメータが存在する。これは入力となるデータや問題設定に依存するものであり、探索的に最適なハイパーパラメータを求めなければならない。そこで本章ではハイパーパラメータを変化させた際に識別率の変化から、ハイパーパラメータが与える影響について調査しハイパーパラメータの最適化を行う。

4.2 節では探索するハイパーパラメータに関してまとめる。

4.3 節では学習データに関するハイパーパラメータに関して述べる。

4.4 節ではネットワーク構造に関するハイパーパラメータに関して述べる。

4.5 節では本章のまとめについて述べる。

## 4.2 探索すべきハイパーパラメータ

ディープラーニングなどの機械学習手法は学習データに基づいて最適なパラメータを決定してくれるが、自動探索するパラメータとは別にネットワークの構造や入力次元数など人が設計しなければならないハイパーパラメータといわれるパラメータが存在する。これは機械学習を適用する問題に依存するパラメータであり、機械学習のフレームの外にあり自動で探索することができない。また、ハイパーパラメータは問題に依存するため、明確な設計指針が定まっておらず探索的に最適なハイパーパラメータを求める必要がある。本研究の場合は筋電義手、特に日を跨いだ筋電位のデータを用いて筋電位の信号特徴の時変性を吸収するために最適なハイパーパラメータを探索しなければならない。

探索すべきハイパーパラメータの数が増加するほど最適な組み合わせを見つけることは指数的に困難になっていく。つまり、一つでも不適切なハイパーパラメータが存在すると十分な精度で識別することが困難になってしまうため、いくら別のパラメータを変更してもそれによる効果が分からなくなってしまう。

そのため、本研究では経験的に得られた妥当と思われるハイパーパラメータの組み合わせを基準として、そのうち代表的なパラメータを一つずつ変化させた際の識別率を求め、それによってパラメータが識別率に与える影響について調査し、ハイパーパラメータの最適化を行う。

学習データに関しては 3.7 節で定義した収集方法をもとに構築する。

それぞれの検証とその時のパラメータについて Table 4.1 にまとめる。

Table 4.1 各検証とそれぞれのパラメータの値

		検証					
		白色化	学習 日数	学習率	ドロップ アウト率	ミニバッチ サイズ	特徴抽出 フレーム
パラ メー タ	白色化	有/無	無	無	無	無	無
	学習日数	5 日分	1-7 日分	5 日分	5 日分	5 日分	5 日分
	学習率 (C 層)	0.010	0.010	0.005 /0.010 /0.020 /0.030 /0.050 /0.100	0.010	0.010	0.010
	学習率 (F 層)	0.020	0.020	0.010 /0.020 /0.040 /0.060 /0.100 /0.200	0.020	0.020	0.020
	ドロップ アウト率	0 %	0%	0%	0%/10% /20%/30% /50%/70%	0	0
	ミニバッ チ サイズ	16	16	16	16	8/16/32/64	16
	特徴抽出 フレーム	1600	1600	1600	1600	1600	800/1600
	P1 フィルタ	2×10	2×10	2×10	2×10	2×10	2×5 /2×10

## 4.3 学習データ

### 4.3.1 白色化

本節では抽出された特徴マップに対する白色化の有無による識別率への影響に関して議論する．白色化とは平均値を 0, 分散を 1 としてスケール変換をする処理であり，一般的な画像認識においては画像の明るさ等の影響を無くし，画像の特徴を強調するための作業である．

本研究では DCNN において抽出された特徴マップを学習・推定を行う前に白色化を行った場合と行わなかった場合に関して比較を行った．第 3 章の式(3.40)によって抽出された特徴マップのうち，同じ時刻における全てのチャンネルの筋電位に対して共通して平均値と分散を求め，白色化を行った．本来畳み込み層に関しては各チャンネルで独立して学習等を行っているが，そこに入力される前に白色化を行うことによってどのチャンネルの筋電位が強いかなどといった情報が抽出されることになる．

そこで 5 日分(1620 万 data)の学習データに対して 1 日分(324 万 data)のテストデータを識別した際の白色化を行った場合と行っていない場合の 9 動作識別を行った際の識別率を求めた．その結果を Figure 4.1 に示す．




Figure 4.1 白色化の有無による識別率の変化

結果としては白色化の有無による大きな差はみられなかったが、白色化を行わない方がわずかに識別率が高いという結果になった。一般的な画像認識においては画像全体の明るさは意味を持たない情報であるが、筋電位の場合は筋活動の全体的な強さに比例する。MAV を特徴量として併用してはいるものの、白色化によって相対的な違いが明確化されるよりも、失ってしまう情報の方が多かったものと思われる。また、本来筋電位の各周波数成分の振幅の値は 100 分の 1V 程度の値であるが、白色化によってこれがスケールアップされ、計算上の誤差が大きくなった。これによってオーバーフロー等の実装上の問題が発生する場合があったため、白色化は用いないこととした。

### 4.3.2 学習日数

本節では学習データを構築する際に用いるデータの量に関して検証する。用いる学習データを増やせばその分データの多様性が増すため、汎化性が高くなることが期待できるが、学習にかかるコストが増大してしまう。また、一方で十分に汎化性を保てるだけのデータが確保できていればそれ以上データ数を増やしても意味はない。そのため、妥当な汎化性を有するのに必要な学習データのサイズを求めなければならない。

そこで、学習するデータを増やした際の識別率の推移から妥当なデータサイズの探索をおこなった。学習データに関しては 3.7 節で定義した収集方法をもとに構築する。学習データとして 1 日分(324 万 data)から 7 日分(2268 万 data)までの学習データをそれぞれ学習し、5 日分(1620 万 data)のテストデータを識別した際の識別異率を求めた。その結果を Figure 4.2 に示す。

グラフを見てみると初めは学習データに用いるデータの日数が増えると識別率が改善している傾向にあるが、ある程度のデータ数から識別率があまり変化がなくなることが分かる。学習データの増加に対して学習コストが指数的に増加してしまうため、本研究では 5 日分(1620 万 data)のデータを学習データとして用いることとした。




Figure 4.2 学習データの量と識別率の関係

## 4.4 ネットワーク構造

### 4.4.1 学習率

本節では学習率が識別率に与える影響に関して検討する。学習率は学習フェーズにおいて計算された誤差を用いてどの程度ネットワークを更新するかを決定する変数である。本研究では畳み込み層と全結合層においてそれぞれ用いられる。第3章における式(3.60)及び式(3.63)の $\eta$ がそれぞれ畳み込み層と全結合層の学習率である。学習率が小さいと学習の進む速度が遅くなってしまう。しかし、学習率が大きすぎても学習に用いたデータにのみフィットしてしまっただけで汎化性が低下してしまうか学習が起こってしまいやすくなる。また、学習率が大きいと学習が収束せずに発散してしまう問題が生じる。特に本研究は大規模な筋電位データを用いて学習を行っており、累積する誤差が大きく発散しやすいため、適切に学習率を決定することが重要である。

学習率の適切な値はデータ量に比例する傾向があるため、本研究では畳み込み層と全結合層の学習率の比を 1:2 とする。学習率を変化させた際の識別率の変化を検証した。学習率と識別率の関係を Figure 4.3 に示す。ここで学習率は畳み込み層の学習率であり、全結合層の学習率はこの 2 倍の値になっている。畳み込み層の学習率を 0.005, 0.010, 0.020, 0.030, 0.050, 0.100 として計算した。5 日分(1620 万 data)の学習データを用いて 1 日分(324 万 data)のテストデータを識別した。学習データに関しては 3.7 節で定義した収集方法をもとに構築した。

その結果、学習率が大きくなると学習が発散してしまい適切に学習できなくなってしまう。本手法では学習が発散してしまった場合に学習率を小さくして学習をし直す仕組みがあるため 0.030 以下では同等な識別が行えているものと思われる。しかし、学習率が小さい領域では 0.020 をピークとして約 0.2% ずつ識別率が下がる結果となった。学習の発散のしやすさは学習データの質に左右されるため、本研究では少し小さめの畳み込み層の学習率を 0.010、全結合層の学習率を 0.020 とした。






Figure 4.3 学習率と識別率の関係

#### 4.4.2 ドロップアウト率




Figure 4.4 ドロップアウトによるアンサンブル学習

ドロップアウトとはニューロンの一部をマスクして学習することによって疑似的にアンサンブル学習を行う手法である。一般的な画像認識においては画像の一部を欠損させて学習を行い、その欠損箇所を変更しながら繰り返し学習することによって複数のネットワーク構造を使って学習するのと同じ効果を得て

汎化性を上げる手法である。

一般的に画像認識においてはドロップアウト率を 50%程度にすると最も汎化性が高くなると言われている。そこでドロップアウト率を変更しながら識別率がどのように変化するか検証した。ドロップアウトは全結合層に対してのみ適用した。本論文では第3章における式(3.61)の  $x^l(n)$  の値をドロップアウト率に基づいてランダムにマスクし、マスクされた場合は  $x^l(n)$  の値を 0 とした。5 日分(1620 万 data)の学習データを用いて 1 日分(324 万 data)のテストデータを識別した。学習データに関しては 3.7 節で定義した収集方法をもとに構築した。ドロップアウト率は 0%, 10%, 20%, 30%, 50%, 70%とした。結果を Figure 4.5 に示す。

結果としてドロップアウト率が 50%以上になると大幅に識別率が低下してしまった。また、50%未満の場合でも識別率の改善はあまり見られず、0%のときに最も識別率が高かった。筋電位は一般的な画像認識と比較して不明瞭な信号であるため、ドロップアウトを行うと情報量が減ってしまい識別しにくくなってしまうものと思われる。ドロップアウトを行うと学習効率が下がり学習コストが増大してしまい、一方で識別率の改善の効果がみられないため、本研究ではドロップアウトは採用しないこととした。




Figure 4.5 ドロップアウト率と識別率

### 4.4.3 ミニバッチサイズ

本節では全結合層のミニバッチのサイズに関して検証を行う。ミニバッチ処理は学習データの内一部をミニバッチとして抽出して学習し、一定回数学習後にまた別のミニバッチを構築して学習するということを繰り返す学習手法である。学習データのすべてを一度に学習するのではなく少しずつ学習することによって過学習が発生することを防ぐ効果がある。また、大規模なデータを学習しようとするメモリや GPU への負荷が増大してしまい、実装上実現が困難になってしまうため、それを防ぐ効果もある。

ミニバッチのサイズを大きくすれば一度の学習に用いるデータの数が増えるため汎化性が向上することが期待されるが、大きくし過ぎると逆に過学習が発生して汎化性が低下してしまう。本研究ではミニバッチ内において全ての動作が均等に含まれるようにミニバッチを構築している。そこでこの動作当たりのデータ数を 8,16,32,64 と増やした際の識別率の変化を求めた。




Figure 4.6 ミニバッチサイズに対する識別率

Before は1日分のデータを3つに分割して2つ(216万 data)を学習データ1つ(108万 data)をテストデータとして交差検定したときの識別率である。After は5日分(1620万 data)のデータを学習データとし1日分(324万 data)のデータをテストデータとしたときの識別率である。ミニバッチサイズに対してあまり大きな差はみられなかったが、増やし過ぎた場合、減らし過ぎた場合に識別率が低下する傾向がみられる。

また、学習が進むにつれて誤差がどのように減少していくのか求めた。結果をFigure 4.7に示す。その結果、ミニバッチのサイズが大きくなるほど誤差が小さくなる傾向にあったが、それ以上にミニバッチを変化させた際の誤差が大きく、ミニバッチサイズによる効果が小さいことが分かる。




Figure 4.7 ミニバッチサイズごとの学習回数に対する誤差の収束

#### 4.4.4 特徴抽出フレームのサイズによる識別率と即時性

本節では特徴抽出の際に用いるフレームのサイズによる識別率と即時性の影響に関して検証する．特徴抽出フレームの大きさは抽出される特徴マップのサイズに影響を与える．フレームのサイズが大きくなるほど抽出される特徴マップも大きく、過去の筋電位情報も含めて学習・識別を行うことになり、識別率が向上することが期待されるが、その分応答性が低下してしまう．逆に、フレームの大きさを小さくするとより直近の筋電情報のみを用いて学習・識別を行うことになり、応答性は向上するが、識別が不安定になる可能性が高い．特に、筋電位は不安定な生体信号であり、インパルス信号である神経信号が重畳した形で計測され、ある一定の波形を維持するということが極めて困難であるため、ある程度大きなサイズにしなければならない．

そこで、1600Hz で計測した筋電位に対して 1600data(1sec)と 800data(0.5sec)のフレームサイズで特徴抽出を行った際の 2 つの場合についてそれぞれ識別率を算出した．被験者は 4 名であり、被験者 A は切断者、被験者 B,C,D は健常者である．識別率は義手を付け外しした後の識別率であり、クロスバリデーションによって 5 日分学習し 1 日分識別している．

義手の応答性に関して、操作者の動作意図がある動作から別の動作に遷移した際にフレームサイズの過半数のデータが計測されたのちに動作の切り替わりが起こると考えられる．つまり、装着者が動作を切り替えてから 1600data の際には 0.5sec, 800data の際には 0.25sec 遅れて義手が動作する．人の単純反応時間は 0.2sec 程度であると言われており、それ以上に応答性を上げることにあまり意味がないため、0.25sec は義手を使用するうえで十分に高い応答性であると考えられる．

もう一つ、義手の妥当な応答性を決める基準として運動主体感が存在する．運動主体感とはある出来事を自分が引き起こしていると感じる感覚のことである．義手の場合には義手が勝手に動いているのではなく、自分が動かしていると感じるかということである．運動主体感が低い場合には操作者が筋電位と動作の対応関係が分からなくなってしまうため義手の制御が困難になってしまう．自分が行動してから出来事が生じるまでの遅延が長くなるほど運動主体感が低下するため、遅延をどこまで許容するか of 基準となる．

山田は筋に力を入れてから義手を動くまでの時間に人為的に遅延を入れて運

動主体感の変化を評価している[山田 2017]. 被験者はコンピュータがしばしば信号の伝達を遅らせると伝えられており, コンピュータによってどの程度阻害されたかを 0 から 6pt の 7 段階で答えさせる主幹評価によって評価を行っている. また, もう一つの研究として, Minohara らは義手ではないがボタンを押すと画面に表示された正方形が動くシステムにおいて遅延と運動主体感の関係を評価している[Minohara 2016]. 被験者はしばしばコンピュータがボタンを押した信号を遮断して任意の遅延の後に勝手に正方形が動く伝えられており, 自分がボタンを押したことによって正方形が動いたかを Yes/No で回答させ, その Yes の割合を遅延ごとに求めている. 双方の実験共に 250ms 前後の遅延は認知的にはほぼ影響がないことを示している. このことは人の単純反応時間が 200ms 程度であることとほぼ一致する. また, 500ms 前後の遅延も山田の実験では 3pt 前後, Minohara の実験では 60%程度の試行で阻害されていないと感じており, 遅延の影響は小さいと思われる. 運動主体感はアプリケーションやその習熟によって変化してしまうため, 義手の遅延をどこまで許容できるかの下限を決めることは難しい問題であるが, これらの実験では被験者にコンピュータが信号を阻害する場合がありますというインタラクションをおこなうことによって疑心暗鬼にさせ, よりその効果が表れやすいしており, かなり厳しい実験設定であるため, 500ms は義手を使用するためには充分許容できる範囲の遅延であると考えられる.

また, 特徴マップのサイズが変わってしまうと最適なネットワーク構造が変わってしまう可能性があるが, 今回は特徴抽出フレームのサイズに着目するために, P1 層のフィルタサイズのみを変更しそれ以外のネットワーク構造は同じになるようにした.

Table 4.2 特徴抽出フレームのサイズによる識別率の変化

	Sbj.A		Sbj.B		Sbj.C		Sbj.D	
	1sec	0.5sec	1sec	0.5sec	1sec	0.5sec	1sec	0.5sec
day1	32	28	79	70	77	78	97	90
day2	25	27	76	75	86	86	95	92
day3	26	28	81	74	83	81	79	73
day4	35	31	74	75	82	83	87	84
day5	31	32	84	75	84	85	89	86
day6	33	33	85	81	91	91	90	91
Ave.	30	30	80	75	84	84	89	86

特徴抽出フレームのサイズを小さくすると識別率が低下してしまう被験者と変わらない被験者が存在した。これは筋電位をどの程度安定的に発揮し続けられるかが被験者によって異なるためと思われる。

基本的にフレームサイズを小さくすると識別率が向上することはなく、変わらないか低下してしまうこと、また、1sec 前までの筋電位情報を用いたとしても遅延は 0.5sec であり、義手を使用するうえでは大きな障害とならないことから以後の検証では基本的に特徴抽出フレームのサイズを 1600data とする。しかし、第 6 章の一部の実験では応答性を考慮して 800data で実験を行う。

### 4.5 まとめ

白色化による識別率の大きな変化はなかったが、白色化を行わない方がわずかに識別率が高かった。これは白色化によって画像の特徴が協調される一方で、筋電位は全体の値の大きさ(画像においては明るさに当たるもの)が筋収縮に対する大きな情報を持っており、相対的な違いが明確になるよりも全体の値の大きさを失ってしまう方が情報量の損失が大きいと思われる。

学習日数に関しては増やすほど識別率が改善し安定的に識別できるようになる傾向があったが、ある程度のところからあまり識別率が変わらなくなった。また学習するデータが増えると学習時間が長くなってしまうという問題が発生した。

学習率は小さすぎると十分に学習を行うまでに長い時間がかかってしまうようになり、大きすぎると発散してしまい学習が収束しないという問題があった。学習率の適切な値はデータによって大きく左右されてしまうため、発散した場合に学習率を小さくして学習をし直すといったことを行うと学習が行いやすい。

ドロップアウトは一般的な画像認識において汎化性を向上させるために用いられる手法であるが、筋電位は画像と比較してもともとノイズを多く含んだ不明瞭な信号であり、また今回は十分な数のデータを用意したことから、ドロップアウトによる識別率の改善は見られなかった。

ミニバッチサイズの向上によって学習の誤差である **RMS** の減少傾向がみられたもののかなり小さな差であり、ミニバッチを更新する誤差の方が大きくあまり影響がなかった。

特徴抽出フレームのサイズは被験者によって識別率が低下してしまう場合と変わらない場合が存在した。

以後の実験では **Table4.3** のパラメータを用いる。



Table 4.3 DCNN に用いるパラメータの値

白色化	なし
学習日数	5 日分
学習率(C 層)	0.010
学習率(F 層)	0.020
ドロップアウト率	0%
ミニバッチサイズ	16 file/posture
特徴抽出フレーム	1600data
P1 層フィルタ	$2 \times 10$

### 4.6 おわりに

第3章で提案した手法のうち、選択的線形回帰モデル(SLRM)は筆者が考案した手法であり、筋電位の特性に合わせて設計されているが、畳み込みニューラルネットワーク(DCNN)は画像認識を主として様々な分野に用いられている汎化的な識別手法をもとに筋電義手の動作意図抽出に合わせて構築されている。DCNNには人が設計しなければならないハイパーパラメータといわれるパラメータが存在する。これは入力となるデータや問題設定に依存するものであり、探索的に最適なハイパーパラメータを求めなければならない。そこで本章ではハイパーパラメータを変化させた際に識別率の変化から、ハイパーパラメータが与える影響について調査しハイパーパラメータの最適化を行った。

4.2節では探索するハイパーパラメータに関してまとめた。また、各検証におけるパラメータの値について述べた。

4.3節では学習データに関するハイパーパラメータに関して述べた。白色化を行ったところ、あまり大きな差はみられなかったが白色化を行わない方がわずかに識別率が高かった。筋電位の場合は相対的な違いが明確化されるよりも絶対的な値の方が情報を有しているためと思われる。また、学習日数に関してはデータ量が増えるごとに識別率は上昇し安定したが、だんだんと上昇が少なくなる傾向がみられた。また、学習データに対して学習コストが指数的に増加する問題が発生した。

4.4節ではネットワーク構造に関するハイパーパラメータに関して述べた。学習率を高くし過ぎると発散してしまい学習が収束しなくなってしまった。また、小さすぎると学習に時間がかかってしまう。発散を検知して学習率を自動で変更すると学習が安定しやすかった。ドロップアウト率は50%以上にしてしまうと識別率が低下した。また、0%の時に最も識別率が高かった。ミニバッチサイズは大きくすると汎化性が向上するが大きくし過ぎると過学習により汎化性が低下してしまった。特徴抽出のフレームサイズを小さくすると識別率が低下してしまう被験者がいた。

4.5節では本章のまとめについて述べた。

## 第5章 推定精度と汎化性の評価

---

5.1 はじめに .....	108
5.2 義手の付け外しによる時変性に対するノイズ耐性の評価 .....	109
5.2.1 短期評価 .....	109
5.2.2 長期評価 .....	113
5.3 一般的なノイズ耐性の評価 .....	117
5.4 学習時間の評価 .....	120
5.5 まとめ .....	122
5.6 おわりに .....	123

---

### 5.1 はじめに

本章では Offline 解析によってそれぞれの手法の推定精度の評価を行う。2.9 節で設定した問題設定の達成目標についてそれぞれ検証を行う。日を跨いで義手を付け外した学習データを用いて学習・推定を行い、十分な精度で推定が行えていることを確認する。また、把持力が十分な精度で推定できていることを確認する。それに追加してそれぞれの手法の比較として義手の付け外しに限らず一般的なノイズに対する耐性の評価と学習時間の検証を行う。

5.2 節では義手を付け外した際の識別率の変化から手法の汎化性の評価を行う。

5.3 節ではより一般的な汎化性の評価として学習・テストデータに人工的にノイズを付与し、ノイズの大きさに対して識別率がどのように変化するのか検証する。

5.4 節では学習時間に関して述べる。

5.5 節では本章のまとめについて述べる。

## 5.2 義手の付け外しによる時変性に対するノイズ耐性の評価

### 5.2.1 短期評価

3 人の健常者と 1 人の上肢切断者を被験者としてそれぞれ 6 日分の筋電位を計測した。学習データに関しては 3.7 節で定義した収集方法をもとに構築した。提案手法として DCNN と SLRM, 比較手法として 3 層フィードフォワード型の ANN の 3 つの手法を比較した。各日内で学習・推定を行う場合と日を跨いで学習・推定を行う場合をそれぞれ義手の再装着前, 再装着後として把持姿勢 9 姿勢及び DCNN と ANN に関しては把持力 3 段階, SLRM に関しては把持力を連続量として識別した際の識別率を求めて評価を行った。

義手の再装着前の評価として, 計測した各日のデータを 3 つに分け, 2 つ(216 万 data)を学習データ, 1 つ(108 万 data)をテストデータとして交差検定を行った。DCNN, SLRM, ANN の 3 つの手法の識別率を比較した。通常の筋電義手の制御と同様に学習・推定を義手を付け外さずに行うため, 理想的な識別率の限界値が得られることが期待される。また, この識別率を学習データ自体の識別のしやすさの指標として用いる。

義手再装着後の評価として, 計測した 6 日分のデータの内, 5 日分(1620 万 data)のデータを学習データとし, 1 日分(324 万 data)のデータをテストデータとして交差検定を行い識別率を求めた。ANN, DCNN, SLRM の識別率を比較した。また, 通常の筋電義手の制御手法と同様の識別器を想定して, ANN で 1 日分だけ学習した場合の識別率も求めた。義手を付け外しすることによって筋電位の信号特性の時変性が発生し, 識別率が低下するものと思われる。また, 提案手法ではネットワークの汎化性によって筋電位の信号特性の時変性を吸収し, 識別率の低下が抑制されることが期待される。

各手法の識別率の平均値を Table 5.1 に示す。被験者 A は上肢切断者であり, 残りの 3 名は健常者である。義手の再装着前と再装着後を比較すると全体的に識別率が低下していることが分かる。これによって義手の再装着が識別率の低下を引き落とすことが確認された。

Table 5.1 各手法の短期評価における識別率(25 動作) [%]

reseatng	method.	Sbj.A	Sbj.B	Sbj.C	Sbj.D
Before	ANN	36	79	80	89
	DCNN	37	85	85	95
	SLRM	52	87	97	95
After	ANN(1day)	24	57	68	77
	ANN	33	78	64	86
	DCNN	30	80	84	89
	SLRM	44	73	92	88

義手の再装着後の識別率を比較してみたときに ANN(1day)が他よりも大きく識別率が低下していることが分かる. このことから, 大規模な筋電位データを用いることは義手の信号特性の時変性を吸収することに対して有用であると言える. また, 健常者に関して被験者平均をとってみると ANN が 76%, DCNN が 84%, SLRM が 84%と比較手法が達成目標に対して 10%程度低いのに対して, 2つの提案手法では被験者 B がやや低い識別率 85%以上という達成目標をほぼ達成できている.

Table 5.2 姿勢と力の識別率と誤識別率 [%]

姿 勢	力	Sbj.B		Sbj.C		Sbj.D	
		DCNN	ANN	DCNN	ANN	DCNN	ANN
×	-	17	16	7	6	9	10
○	×	3	7	9	30	1	4
○	○	80	78	84	64	89	86
計		100	100	100	100	100	100

より詳細に検討するため把持姿勢と把持力の正誤にのみ着目して識別率を求めたものを Table 5.2 に示す. 1 行目は把持力の正誤を問わず把持姿勢が誤識別している割合, 2 行目は把持姿勢は正しく識別されているが把持力が誤識別されている割合, 3 行目は把持姿勢と把持力両方が正しく識別されている割合を表す. 3 行目は Table 5.1 の値と同じ値となる. 表を見てみると 1 行目の値は DCNN と ANN でほとんど変わらない. それに対して 2 行目は全ての被験者で DCNN の値と比較して ANN の値が 2 倍以上になっている. これは把持姿勢は正しく識別されているが把持力が誤識別されている状況に差があり, DCNN の方が ANN と比較して把持力の変化というより細かな情報まで抽出することができているということを表している.

Table 5.3 目標把持力と推定把持力の差の絶対値平均 [V]

	Sbj.B	Sbj.C	Sbj.D
day 1	0.132	0.147	0.087
day 2	0.099	0.144	0.110
day 3	0.117	0.125	0.077
day 4	0.076	0.165	0.096
day 5	0.088	0.136	0.112
day 6	0.094	0.136	0.082
Ave.	0.101	0.142	0.094

また，この時の健常者の SLRM の把持力の推定精度を目標把持力と推定把持力の差の絶対値平均を用いて検証した．推定精度の値を Table 5.3 に示す．

パターン認識型では把持力を 0.5V おきに 3 段階設定していたのに対してかなり細かく把持力の推定が行えていることが分かる．この表の値は目標把持力と推定把持力の差でありこの差には被験者が目標把持力に正しく追従できているかというヒューマンエラーも含んでいる．実際にはより高い精度で回帰が行えている．実際にタスクを行っている際の実際の把持力と推定把持力の例を Figure 5.1 に示す．タスクは 3.6 節で述べたように 5 秒間指定された把持姿勢と把持力を維持しており，把持姿勢は安静，開掌，握力把持，精密把持，側面把持，手首掌屈，手首背屈，手首回内，手首回外の順に変化させており，把持力は 0.0, 2.0, 2.5, 1.5, 1.5, 2.5, 2.0, 2.5, 2.0 の順に変化させている．把持力を連続的に推定することができており，把持力の推定誤差はヒューマンエラーよりもかなり小さいことが分かる．




Figure 5.1 タスク中の実際の把持力と推定把持力の例

切断者に関しては大規模な筋電位データを用いることによる識別率の低下の抑制に関しては確認することができたが、識別率は全体的に低く、また、健常者とは異なる傾向であった。これは今回対象とした切断者が同日・同姿勢・同把持力でも筋電位の再現性が乏しかったことが原因と思われる。

筋電位は様々な要因によって変化するが、本研究では同日・同姿勢・同把持力の状況下では筋電位の分散が十分に小さいことを想定している。これは同じ動作意図の場合には同じ筋電位が発現することを期待しており、これが成り立たない場合にはどのような識別器を用いても筋電位から動作意図を推定することが不可能となる。その上で、日を跨いで義手を再装着した際に変化してしまう筋電特徴の時変性の影響をどのようにすれば低減できるかということが本研究の注目領域である。

今回対象とした切断者は健常者と比較して計測された筋電位の振幅強度が小さかった。これは上肢を切断してから年数がたっており、筋が委縮してしまっているためと思われる。また、今回設定した把持姿勢は本切断者が普段使用している筋電義手よりもかなり多種にわたっており、それらの動作イメージが失われてしまっているため、それらの動作を一定時間維持し続けることが難しいとの申告を受けた。

しかしながら、筋肉量や動作イメージに関してはリハビリによって回復することが可能であり、訓練によって筋電位が安定し、識別率が向上することによって健常者と同様の傾向になると思われる。



また、同条件でパターン認識型の制御手法に関して把持力に依らず同一クラスとして学習した際の識別率も求めた。結果を Table 5.4 に示す。

Table 5.4 各手法の短期評価における識別率(9 動作) [%]

reseating	method.	Sbj.A	Sbj.B	Sbj.C	Sbj.D
Before	ANN	59	93	98	98
	DCNN	60	93	98	99
After	ANN(1day)	42	72	91	86
	ANN	52	87	96	91
	DCNN	53	84	96	92

把持力を別クラスとした場合と同様に大規模な筋電位データを用いることによって識別率の低減を抑制できていることは確認できたが、ANN と DCNN の間に大きな差はみられなかった。ANN と DCNN の最も大きな差は畳み込み層の有無である。前述の 25 動作識別では差があったのに対して 9 動作識別では差がなかったことから、このネットワーク構造の違いによって把持力の違いのようなより細かな動作意図まで筋電位から抽出することが可能となることを意味している。

### 5.2.2 長期評価

健康者 1 名を被験者として 20 日分(6480 万 data)の筋電位を計測した。学習データに関しては 3.7 節で定義した収集方法をもとに構築した。本評価は時間経過に対する効果に焦点を当てた検証である。短期評価と同様に各日内で学習・推定を行う場合と日を跨いで学習・推定を行う場合をそれぞれ義手の再装着前、再装着後として識別率を求めて評価を行った。

義手再装着前の評価として各日のデータを 3 つに分け、2 つ(216 万 data)を学習データ、1 つ(108 万 data)をテストデータとして交差検定を行った。短期評価と同様に ANN, DCNN, SLRM の 3 つの手法で識別率を計算し比較した。

義手再装着後の評価として 1 日分(324 万 data)のデータをテストデータとして、その直前の 3 日分(972 万 data)のデータを学習データとし識別率を求め、ANN, DCNN, SLRM を比較した。また、短期評価と同様に通常の筋電義手の制御手法と同様の識別器を想定して、ANN で直前の 1 日分(324 万 data)だけ学習した場合の識別率も求めた。DCNN に関しては重みの初期値は前日の学習結果を用いて学習を引き継いだ。

ANN の重みの初期値はランダムに決定された。

各手法の識別率を Figure 5.2 に示す。また、具体的な数値を Table 5.5 に示す。義手再装着前の識別率を見てみると ANN と DCNN が同様な結果を示しており、これはデータの識別率の理想的な限界を意味しており、各日のデータの識別のしやすさを意味しているものと思われる。また、SLRM は他と比較して若干識別率が低かった。




Figure 5.2 各手法の日数経過に対する識別率

Table 5.5 各手法の長期評価における識別率

reseating method	Before			After			
	ANN	DCNN	SLRM	ANN (1day)	ANN (3days)	DCNN (3days)	SLRM (3days)
day 1	98	99	98				
day 2	99	99	96	93			
day 3	99	99	97	86			
day 4	97	97	86	66	78	74	81
day 5	100	100	96	88	86	84	84
day 6	98	98	96	91	91	87	81
day 7	99	99	98	97	96	98	97
day 8	97	97	92	91	89	91	90
day 9	94	95	92	90	91	93	81
day 10	97	98	95	94	91	94	87
day 11	96	98	93	88	90	90	78
day 12	97	97	93	84	88	93	87
day 13	86	88	83	72	64	63	65
day 14	90	90	85	59	85	86	70
day 15	96	98	95	62	91	94	84
day 16	95	95	90	75	73	81	69
day 17	96	97	90	81	85	85	76
day 18	99	99	98	55	85	88	86
day 19	98	99	96	92	90	90	82
day 20	94	95	90	78	91	92	83
Ave. (day 4-20)	96	96	93	80	86	87	81

また、各手法の義手再装着前と再装着後の識別率の平均値を見てみると ANN(1day) が最も低くなっており、義手の再装着によって識別率が低下しているが他の手法ではそれが抑制されていることが分かる。これは短期評価と同様の傾向である。また、ANN(1day)は他と比較して識別率の変動が大きく不安定であることが分かる。

また、各日の DCNN(3days)の識別率を ANN(3days)の識別率で除した比を Figure 5.3 に示す。比が 1 より大きい場合は DCNN の方が識別率が高いことを意味し、1 より低い場合は ANN の方が識別率が高いことを意味する。グラフを見てみると比が 1 より小さくなっているのは 4 から 6 日目であり、それ以外の比では DCNN の方が識別率が高いか同等であり、日を経るごとに上昇傾向にある。これは畳み込み層を持っている DCNN の方が複雑な構造をしているため、十分な汎化性を得るためには多くの日数のデータを要することの意味していると思われる。DCNN の重みの初期値は前日の値を引き継いでおり、6 日目までは学習データが不十分であり、単純な構造をし

ている ANN の方が識別性能が高くなったものと思われる。複雑なネットワークは複雑なモデルを表現可能だが、十分な効果を得るためには多くのデータを要する。日常の使用によってより多くのデータを収集することが出来れば, DCNN の識別率が高くなることが期待される。




Figure 5.3 ANN(3days)に対する DCNN(3days)の比

### 5.3 一般的なノイズ耐性の評価

前節では筋電位の信号特性の時変性に対する汎化性の評価として義手を付け外しを想定して日を跨いだデータを計測し評価を行った。本節ではより一般的な汎化性の評価として前節と同じのデータに対して人工的にノイズを付与した際の識別率の変化に関して検証を行った。これによって電磁波などの外乱やアプローチなどの手指以外の上肢の動作など、筋電位の信号特性の時変性以外のノイズ要因に対する耐性を見ることができる。

ノイズを付与する方法としては収集した筋電位に対してホワイトノイズを畳み込むことによって付与した。5 日分(1620 万 data)の筋電位データを学習し 1 日分(324 万 data)の筋電位データをテストデータとして用いて 9 動作の識別を行った。被験者は健常者 3 名で ANN と DCNN と SLRM の 3 つの手法を比較した。

ノイズに対する識別率を以下に示す。S/N 比  $\eta_{S/N}$  は以下の式を用いて計算した。

$$\eta_{S/N} = 20 \log_{10} \frac{A_s}{A_N} [dB] \quad (5.1)$$

ここで  $A_s$  と  $A_N$  はそれぞれ信号とノイズの振幅平均(MAV)を意味しており、 $A_s$  は 2.0V とした。9 動作識別のためチャンスレベルは 11%である。結果を Table 5.6 及び Figure 5.4, Figure 5.5 に示す。結果を見てみると DCNN がほとんどの全てのノイズに対して識別率が最も高いことが分かる。また、ノイズを増加させていくと識別率が低下していくが、DCNN が最も変化が緩やかであり、大きなノイズが混入しても安定して識別が行えていることが分かる。

また、SLRM が他の手法と比較して全体的に識別率が低かった。これは前節と同様に SLRM が把持力の回帰性能や学習時間に対して重きを置いているからである。

Table 5.6 ノイズに対する識別率 [%]

S/N Ratio $\eta_{S/N}$ [dB]	S/N Ratio		Sbj.A			Sbj.B			Sbj.C		
	$A_N$	倍	ANN	DCNN	SLRM	ANN	DCNN	SLRM	ANN	DCNN	SLRM
$\infty$	0	0	91	95	88	93	92	85	99	100	97
20	0.2	10	91	94	88	94	92	84	99	99	97
12.04	0.5	4	90	94	88	94	94	83	99	99	97
6.02	1	2	87	88	87	92	89	81	98	99	96
0	2	1	84	90	84	87	91	81	95	99	94
-6.02	4	1/2	32	82	68	69	83	75	11	93	82
-12.04	8	1/4	13	39	25	11	47	25	11	46	28
-20	20	1/10	11	14	12	11	15	12	11	13	12




Figure 5.4 DCNN と ANN のノイズ耐性の比較




Figure 5.5 DCNN と SLRM のノイズ耐性の比較

## 5.4 学習時間の評価

Table 5.7 学習時間の計測に用いた PC のスペック

OS	Windows 10 Pro 64bit
CPU	Intel Core i7-8700K (3.7G-4.7GHz, 6 コア 12 スレッド)
GPU	NVIDIA GeForce GTX1080 Ti
RAM	16GB DDR4

Table 5.8 5 日分のデータの学習にかかる平均時間

手法	時間 [時:分:秒]
DCNN	12:03:06
ANN	1:54:44
SLRM	0:05:21

DCNN と ANN と SLRM それぞれについて 5 日分(1620 万 data)の筋電位データを学習した際にかかる時間について計測を行った。大規模な並列計算が必要な処理に関しては GPGPU によって高速化されている。計測に用いた PC のスペックについて Table 5.7 に示す。

学習時間は事前に収集した筋電位を読み込んで重みのファイルを出力するまでの時間とする。時間は 5 回学習を行いその平均時間を求めた。識別等にかかる時間は学習時間には含まないものとする。各手法の計算時間を Table 5.8 に示す。

5 日分の筋電位データを用いて動作と筋電位との対応関係をモデル化しパラメータを決定するのに SLRM は約 5 分、ANN は約 2 時間、DCNN は約半日ほどかかる結果となった。SLRM と DCNN では約 135 倍の時間差となった。これは DCNN や ANN が学習に用いているバックプロパゲーションが勾配法的一种であり、得られた誤差を利用して誤差が小さくなるように重みを修正しながら探索的にパラメータを決定するのに対して、SLRM は最小二乗法を用いているため、一意に誤差が最小となる値を決定することができるためである。

また、今回 5ch の筋電位を用いた学習を行っているため、DCNN は各チャンネルの



畳み込み層と統合した後の全結合層の学習が必要であり、ANN は全結合層のみの学習が必要で、これは約 6 倍のネットワーク構造となっており、時間とネットワーク規模に比例的な関係がみられる。しかし、DCNN の畳み込み層の学習は各チャンネルで独立しており、複数の PC を用いることによって学習時間を半分以下まで減らせる可能性がある。

## 5.5 まとめ

Table 5.9 問題設定に対する達成度

		DCNN	ANN	SLRM
時変性の 吸収	識別率	○ (84.3%)	× (76.0%)	○ (84.3%)
	汎化性	○ (義手を付け外した データで学習・推定)		
高い 運動自由度	識別姿勢数	○ (9 動作)		
	把持力	○ (3 段階)		○ (連続値)
実用性	Online 化	第 6 章で検証		
	小型化	第 6 章で検証		

2.9 節で設定した問題設定の達成目標に関してそれぞれの達成度を Table 5.10 に示す. 5.2 節の検証から従来手法を想定した 1 日分学習した ANN と比較して大規模な筋電位データを用いた手法は識別率の低下を抑制できていることが確認された. また, 把持姿勢と把持力をともに識別した際に DCNN と SLRM は被験者平均で識別率がともに 84.3%であったのに対して ANN は 76.0%と提案手法の方がより細かな動作意図まで抽出可能であることを確認した.

加えて, 5.3 節で一般的なノイズ耐性の評価を行い DCNN が最もノイズ耐性が高く, ANN が最もノイズ耐性が低いという結果を得た. 提案手法の DCNN と SLRM は一般的な筋電義手制御手法である ANN をただ単に大規模データを用いるように改良したものよりも汎化性が高いことが示された.

また, 学習時間の検証を行い, SLRM は 5 分ほど, ANN は 2 時間ほど, DCNN は半日ほどの学習時間がかかるという結果を得た. 本研究の手法は一度学習を行って筋電位と動作との関係をモデル化したら義手を付け外しても再学習を不要とするための物であり, 学習時間の長さはあまり大きな問題とならないが短い方が望ましい. しかしながら, DCNN でも実現不可能な時間を要するものではなく実用的な範囲内に収まっていることを確認した.

## 5.6 おわりに

本章では Offline 解析によってそれぞれの手法の推定精度の評価を行った。2.9 節で設定した問題設定の達成目標についてそれぞれ検証を行った。日を跨いで義手を付け外しした学習データを用いて学習・推定を行い、十分な精度で推定が行えていることを確認した。また、把持力が十分な精度で推定できていることを確認した。それに追加してそれぞれの手法の比較として義手の付け外しに限らず一般的なノイズに対する耐性の評価と学習時間の検証を行った。

5.2 節では義手を付け外しした際の識別率の変化から手法の汎化性の評価を行った。その結果、義手を付け外すと識別率が低下してしまうことを確認した。また、従来手法と比べて提案手法は義手の付け外しによる識別率の低下を抑制できていることを確認した。DCNN と SLRM は把持姿勢と把持力両方を識別した際に共に被験者平均で識別率が約 84%と達成目標と同等な精度で識別が行えていたが、ANN は約 76%と把持力の誤識別が多かった。

5.3 節ではより一般的な汎化性の評価として学習・テストデータに人工的にノイズを付与し、ノイズの大きさに対して識別率がどのように変化するのか検証した。その結果、DCNN と SLRM が ANN と比較して高い汎化性を有していることを確認した。

5.4 節では学習時間に関して述べた。学習時間は SLRM が約 5 分、ANN が約 2 時間、DCNN が約半日と差があったがどれも現実的な時間内で学習を行うことができていた。

5.5 節では本章のまとめについて述べた。



## 第6章 筋電義手への適用と実使用環境下での評価

---

6.1 はじめに .....	126
6.2 筋電義手への実装 .....	127
6.3 平滑化フィルタの検討 .....	129
6.4 3種の把持での物体把持タスク .....	130
6.4.1 実験タスク・評価方法 .....	130
6.4.2 結果及び考察 .....	132
6.5 把持速度の制御 .....	135
6.6 まとめ .....	137
6.7 おわりに .....	138

---

## 6.1 はじめに

本章では提案手法を実際に義手に実装し，識別率等ではなく実際に義手を実使用環境下でタスクを行った際のタスク達成度によって評価を行う．

6.2 節では義手への実装を行い Offline 解析との違いについて述べる．

6.3 節では平滑化フィルタに関する基礎検証に関して述べる．

6.4 節では 3 種の把持姿勢での物体把持タスクに関する把持性能の検証について述べる．

6.5 節では把持速度の効果に関する検証について述べる．

6.5 節では Online での評価のまとめについて述べる．

## 6.2 筋電義手への実装

制御手法の Online 化を行うにあたって制御周期の問題が存在する。Offline の解析では計測したデータを端から順番に解析していけば問題ないが、Online 制御の場合には装着者と協調してタスクを実行するためリアルタイムに動作意図抽出を行い、義手を制御しなければならない。しかし、Offline と同様に識別を行うと実時間より時間がかかってしまい制御している間に識別がどんどん遅れてしまうという問題が発生する。そこで識別周期に合わせて最新の筋電位データを取得するようにデータの取得方法を改良し、識別の遅れが発生しないようにした。

また、実際に義手を使用すると義手が物体に接触した際などに一瞬だけ筋電センサに外乱が発生し誤識別してしまうということが頻発する。誤識別としては一瞬であるが、物体を把持しているときに一瞬でも誤識別するとロボットハンドが開いてしまい、物体を落下させてしまう。義手に入力される筋電位は装着者が自分の意図に基づいて発現しており、一瞬だけ全く異なる動作意図を発現させることはあり得ない。そこで識別結果に対してフィルタをかけ過去数十回の識別結果をもとに離散値である把持姿勢は最頻値、連続値である把持力は平均値を求めて、それを用いて制御の安定化を行った。フィルタのサイズを大きくし過ぎると応答性が悪くなり、小さくし過ぎると外乱による誤識別を除去できないことから、被験者に実際に使用してもらいその状況に応じてフィルタサイズを決定した。

100 秒間での平均識別回数から識別頻度の検証を行った。実験条件に関しては第 4 章で定めたものを使用した。結果として、ノート PC で識別した場合 11.05、デスクトップ PC で識別した場合 16.35fps であった。比較手法の ANN と SLRM が 16fps で識別を行っていることから、ノート PC でも十分な頻度で識別が行えているといえる。このことから携帯可能で実機への実装を行えており、実用性の問題をクリアできているといえる。

Table 6.1 識別回数 [回/100sec]

試行	ノート PC	デスクトップ PC
1	1104	1640
2	1105	1622
3	1106	1622
平均 FPS	11.05 (90ms)	16.35 (61ms)



## 6.3 平滑化フィルタの検討

平滑化フィルタを用いることによって識別率がどのように変化するのか Offline 解析のデータを用いて検証を行った。切断者と健常者のそれぞれ 1 名の被験者の義手を再装着した後のデータを用いて、識別結果に対して平滑化フィルタを適用し識別率を算出した。

Online 制御ではリアルタイムに識別を行わなくてはならないが、Offline 解析では時間的制約がないため、特徴抽出の shift 幅が 10data と細かくなっている。Online 制御では約 1 秒間になるように平滑化フィルタを定めている。そこで、本検証では平滑化フィルタのサイズを 1,10,20,40,80,160data と変更する。それぞれ、平滑化なし、0.0625, 0.125, 0.25, 0.5, 1sec に対応する。

Table 6.2 平滑化フィルタのサイズによる識別率

フィルタサイズ	切断者	健常者
1(平滑化なし)	30.220%	89.483%
10(0.0625sec)	30.245%	89.496%
20(0.125sec)	30.254%	89.515%
40(0.25sec)	30.245%	89.632%
80(0.5sec)	30.437%	89.826%
160(1sec)	30.618%	90.448%

フィルタサイズを大きくすると識別率が向上する傾向にあったが、変化量は小さく 0.5～1.0%程度であった。Offline 解析のデータは筋電位情報を被験者にフィードバックしており、筋電位の維持が行いやすかったため、瞬間的な誤識別が少なくほとんど平滑化フィルタによる効果がみられなかったものと思われる。

しかしながら、Online 制御の場合には実装上、一度でも別の姿勢が識別されると中間姿勢を経由してから終端姿勢を実現するようになっているため、瞬間的な誤識別に対する対策の重要性が高まっており、平滑化フィルタはそれに対する重要な手段であると考えられる。

## 6.4 3 種の把持での物体把持タスク

### 6.4.1 実験タスク・評価方法

実使用環境下で物体把持タスクを行った際の各手法のパフォーマンスの評価を行った。実験の様子を Figure 6.1 に示す。

健常者 1 名を被験者として実験を行った。第 5 章で用いた Offline 解析を行った際に収集した筋電位データを用いて手指 5 姿勢、手首 4 姿勢の計 9 姿勢の学習を行っており、筋電センサを貼付すれば学習せずにすぐに 9 姿勢が実現可能になっている。5 日分(1620 万 data)の学習データを用いて学習した。筋電位を収集してから本実験を行うまでに 3 か月以上の期間が開いている。

被験者は Figure 6.1 の画像に示されているように目の前に並べられた把持物体を左から順に把持していき手前のトレイに入れるというタスクを 3 巡繰り返すことを 1 試行として各手法 10 試行ずつ行った。それぞれの把持物体及び物体とトレイとの位置関係をそれぞれ Figure 6.2 と Figure 6.3 に示す。把持物体は積まれた積み木の立方体、パイプの上にのせられたスポンジボール、立てられたカードの 3 種類であり、それぞれボールは握力把持、積み木は精密把持、カードは側面把持によって把持するように指示をした。被験者には物体を崩さないように注意することを最優先としながら、可能な限り早くタスクを行うように指示をした。積み木の大きさやボールの支柱の高さを変えることによって不安定さに変化を生じさせており、安定な物体は早く、不安定な物体はゆっくり持つように指示をした。積み木はそれぞれ 30, 15, 10mm、ボールの支柱は 180, 85mm である。




Figure 6.1 実験の様子




Figure 6.2 把持物体と指定された把持姿勢




Figure 6.3 各物体とトレイの配置と距離

それぞれの手法を評価する評価指標としてアプローチ時間と失敗回数によって評価を行う。アプローチ時間はトレイの上から腕が動き始めてから物体を把持するまでにかかった時間とする。物体を把持してからトレイに入れるまでのリリース時間は手法によって差がみられないことから今回は評価しない。また、タスクは把持物体(積み木の場合は一番上のもの)を把持してトレイに入れられれば成功とした。アプローチ時に把持物体を倒してしまい把持できなかった場合や、把持した後トレイに入れる前に落下させてしまった場合は失敗とした。また、これらに当てはまらなくても、誤識別によって目的の把持が実現しないなどの理由により2分以上かかっても物体が把持できなかった場合は、被験者の自己申告によってその把持物体を失敗扱いとして次の把持

物体に移ることを許可した。

提案手法としては DCNN, ANN, SLRM とし, 比較を行った。DCNN は把持力と把持姿勢両方をパターン化するパターン認識型制御として用いた。また, SLRM は把持姿勢はパターン認識, 把持力は線形回帰の併用型制御手法として用いた。それぞれ把持力の強さに応じて把持速度が変化する。ANN は把持姿勢のみパターン認識を行い, 把持速度は一定とし, 把持速度が速いものと遅いものの2つで評価した。全ての制御手法は事前に計測を行った同じ5日分の筋電位データを用いて学習を行った。学習効果が載らないように試行ごとに制御手法の順番を変更しながらタスクを行った。

把持物体の不安定さが高いものは速い速度でつかもうとすると把持に失敗してしまう可能性が高くなることから, 把持速度が制御可能で物体に合わせて把持速度を変更できると不安定な物体の把持の成功率が向上することが期待される。また, 把持姿勢の誤識別が多いとそもそも物体の把持を失敗してしまう可能性が高くなるため, 事前に収集した筋電位を用いて学習したモデルを用いて安定的に制御できるかどうかということがタスクの達成度に反映されるものと思われる。DCNN は把持姿勢の識別率が高いため, 失敗回数が減少し, SLRM は把持力の回帰性能が高いため, アプローチ時間が減少することが期待される。

## 6.4.2 結果及び考察

Table 6.3 平均失敗回数 [回/3 回]

	積み木			ボール		カード	計 [回/18 回]
	大	中	小	高	低		
DCNN	0.1	0	0.1	0.4	0.7	0.5	1.8
ANN(速)	0.6	0.5	1.3	0.3	0.4	0.6	3.7
ANN(遅)	0.2	0.3	0	0.2	0.2	0.6	1.5
SLRM	0.6	0.3	0.4	0	0.1	2.1	3.5

Table 6.4 平均アプローチ時間 [sec]

	積み木			ボール		カード	計 [sec/巡]
	大	中	小	高	低		
DCNN	10.3	12.0	10.3	10.1	7.9	13.0	63.5
ANN(速)	5.5	4.4	5.2	4.8	3.8	6.7	30.4
ANN(遅)	8.8	8.2	10.2	6.4	6.5	11.4	51.5
SLRM	12.3	11.0	9.5	8.2	7.7	13.7	62.4

1 試行における失敗回数とアプローチ時間の平均をそれぞれ Table 6.2 と Table 6.3 に示す。アプローチ時間はタスクに失敗した場合と誤識別等によって極端に時間がかかった場合(30sec 以上)は外れ値としてアプローチ時間の算出に用いていない。平均失敗回数は 1 試行 3 巡タスクを行うため 1 つの物体に対して 3 回把持を試みた場合の失敗回数であり、表の右の計は 1 試行(6 物体 3 巡)行ったときの平均失敗回数である。平均アプローチ時間は 1 回物体の把持を試みた際の時間であり、表の右の計は 1 巡中におけるアプローチ時間の平均値である。

ANN の把持速度が速い場合と遅い場合を比較してみると、把持速度が速いとアプローチ時間が短いが失敗回数が多くなっており、把持速度が遅いとアプローチ時間が長くなるが失敗回数が少なくなっている。これは事前に期待した通りの結果が得られている。DCNN と SLRM に関しては把持力によって把持速度が制御可能であるため物体に合わせて把持速度を制御し、安定な物体は速く、不安定な物体は遅く把持することにより、アプローチ時間と失敗回数がともに良い成績となることが期待されたが、あまりそのような傾向がみられなかった。

失敗回数に関しては、DCNN はタスクの達成度が 90%であり、概ね期待通りの成績であったが、SLRM は失敗回数が多い結果になった。これは前章のオフライン解析で明らかになったようにもともと SLRM の識別率が若干低く把持力の回帰に重みを置いた設計になっているためであると思われる。

アプローチ時間に関しては DCNN と SLRM とともに期待していた時間よりも長い時間がかかってしまっている結果となった。被験者には物体を崩さずに把持することを最優先課題としてそのもとで可能な限り安定した物体は早く把持を行うように指示をしていた。しかし、被験者にとってタスクの難易度が高く全ての把持物体に対して遅

く慎重に把持を行っており、把持物体の不安定さに対するアプローチ時間の変化が見られなかった。

DCNN に関して実験のログファイルをもとにオフライン解析によって各試行中にもどの把持姿勢と把持力が推定されていたか求めた。全試行の識別結果を Table 6.5 に示す。また、DCNN は 10 試行中に失敗回数が 0 回の試行が 3 試行あった。装着者の意図通りに義手を制御できていた理想的な試行として参考に同様に Table 6.6 に示す。

表は試行全体において各把持姿勢と把持力がどの程度の頻度で推定されたかを表したものであり、すべて合計すると 100 になる。Table 6.5 を見てみると把持力の弱いパターンが推定されている場合がほとんどであり、把持力が強いパターンがほとんど使われていないことが分かる。誤識別が少ないと思われる失敗回数が 0 回だった試行を見てみるとその傾向はより顕著になり、安静と把持力の弱い手指動作が 98%を占めており、把持力の強い動作や手首動作はほとんど使われていない。このことから被験者はタスクを成功させるために、ほとんど遅い速度で把持しており、物体に合わせて把持速度を制御する余裕がなかったことが分かる。

Table 6.5 全試行における識別結果 [%]

	安静	開掌	握力 把持	精密 把持	側面 把持	手首 掌屈	手首 背屈	手首 回内	手首 回外
把 弱		6.5	2.1	38.0	17.1	1.5	1.7	0.0	7.4
持 中	16.9	0.2	0.6	2.1	0.5	0.1	0.5	0.1	0.5
力 強		0.0	0.7	1.3	0.9	0.2	0.0	0.1	0.3

Table 6.6 失敗回数が 0 回の試行における識別結果 [%]

	安静	開掌	握力 把持	精密 把持	側面 把持	手首 掌屈	手首 背屈	手首 回内	手首 回外
把 弱		10.7	0.1	40.4	27.6	1.2	0.0	0.4	0.1
持 中	19.0	0.2	0.0	0.0	0.0	0.0	0.1	0.0	0.1
力 強		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1

## 6.5 把持速度の制御

前節において把持速度の影響に関してアプローチ時間から評価を行おうとしたが、アプローチ時間は誤識別など他の要因によって変化してしまう場合が多く十分にその効果を見ることができなかった。また、把持速度の制御よりもタスクの成功を優先させるように被験者に指示したことから全ての把持物体に関して遅く物体把持を行い、そもそも把持速度の制御をほとんど被験者が行っていなかった。そこで把持速度の制御に関してのみ着目し再度評価を行った。

実験の様子を Figure 6.4 に示す。前節で用いた 30mm の積み木(大)と前節で用いたものよりさらに小さい 7mm の積み木(極小)を用いてタスクを行った。被験者は 1 名であり、前節と同様に学習を行っている。手法は DCNN, SLRM, ANN(速)の 3 種類で ANN は把持速度一定, DCNN は 3 段階, SLRM は連続量として制御可能である。被験者には必ず積み木(大)は速い速度で、積み木(極小)は遅い速度で把持をするように指示をし、異なる把持速度で把持を行った場合は試行をやり直した。ただし、ANN は把持速度が速い速度で一定であるため、積み木(極小)を把持するのは困難な設定となっている。識別器は 9 姿勢と把持力を識別するが、誤識別の影響を無くするため、精密把持以外に識別した際にはハンドが開いて把持が行えないようにだけ設定されている。各物体を順番に把持していき、3 巡することを 1 試行として 5 試行行った。学習効果が載らないように試行ごとに制御手法の順番を変更しながらタスクを行った。




Figure 6.4 実験の様子

Table 6.7 平均失敗回数 [回/3 回]

	ANN	DCNN	SLRM
積み木(大)	0.4	0.4	0.0
積み木(極小)	2	0.6	0.4

実験の結果を Table 6.7 に示す．把持速度が一定である ANN では積み木(極小)が平均して 3 回中 2 回失敗していたのに対して，DCNN が 0.6 回，SLRM が 0.4 回と失敗回数が 3 分の 1 以下であった．これによって把持速度が制御できることによって義手の把持機能が向上すること，また，DCNN 及び SLRM で把持力が適切に制御できていることが確認された．



## 6.6 まとめ

Table 6.8 問題設定に対する達成度

		DCNN	SLRM	ANN
時変性の 吸収	識別率	第 5 章で検証		
	汎化性	○ (3 か月以上前のデータで学習)		
高い 運動自由度	識別姿勢数	○ (物体に合わせて把持が可能)		
	把持力	○ (物体に合わせて 制御可能)	× (一定)	
実用性	Online 化	○ (直前の学習不要 ・ 10fps 以上で制御可能)		
	小型化	○ (ノート PC に実装・携帯可能)		

2.9 節で設定した問題設定の達成目標に関してそれぞれの達成度を Table 6.8 に示す。各手法の実機への実装を行い、ノートパソコンを用いて 10fps 以上の速度で義手が制御可能であることを確認した。このことから携帯可能で実機で制御可能であり、実用性の高い動作意図抽出を実現できているといえる。

物体に合わせてそれぞれ異なる把持姿勢で物体を把持出来ることが確認された。また、物体の安定性に応じて把持速度を制御できることが確認された。

3 か月以上前に収集した筋電位のデータを用いて学習したモデルを用いて、再学習なしでも DCNN は 90%，SLRM は 81%の達成度でタスクを行うことが可能であった。把持姿勢 9 姿勢，把持力 3 段階という制御可能な運動自由度は先行研究と比較してかなり多くの装着者の動作意図を抽出できている。多くの運動自由度を制御できている研究のほとんどは Offline 解析によるものであり Online 制御でこれほど多くの自由度を制御できているほとんどない。これは大規模な筋電位を用いて学習をすることによって筋電位の信号特性の時変性を吸収できており、再学習が不要となったため、学習データの収集と学習に数時間から数日掛かるような複雑な識別器を Online 制御によって利用できているようになったからである。

### 6.7 おわりに

本章では提案手法を実際に義手に実装し、識別率等ではなく実際に義手を実使用環境下でタスクを行った際のタスク達成度によって評価を行った。

6.2 節では義手への実装を行い Offline 解析との違いについて述べた。データの取得を改良しリアルタイムで推定が行えるようにした。また、フィルタを用いて動作の安定化を行った。ノートパソコンで 10fps 以上で制御可能であることを確認し、Online 化と携帯化が実機で実装できていることを確認した。

6.3 節では平滑化フィルタの基礎検証に関して述べた。Offline 解析のデータに対しては識別率に大きな影響を与えなかった。

6.4 節では 3 種の把持での物体把持に関するタスクを行った。3 か月以上前のデータを用いて構築したモデルによって、再学習なしで義手が制御できることを確認した。DCNN は 90%，SLRM は 81%の達成度でタスクを行うことが可能だった。

6.5 節では把持速度の制御に関する検証を行った。その結果、物体の安定度に応じて把持速度を変えることにより把持性能が向上すること、また、提案手法で適切に把持力の制御が行えていることが確認された。

6.6 節では Online での評価のまとめについて述べた。大規模な筋電位を用いて学習することにより筋電位の信号特性の時変性を吸収できており、再学習が不要となったため、学習データの収集と学習に時間がかかる複雑な識別器を Online 制御で利用できたことが示された。

# 第7章 結論

---

7.1 結論.....	140
7.2 今後の展望.....	142

---

### 7.1 結論

上肢切断者の上肢機能を代替するものとして筋電義手というものが存在する．筋電義手は人が筋肉を収縮させる際に筋表面に生じる筋電位という微弱な電位を用いて装着者の動作意図を推定し動作する義手である．装飾義手と異なり装着者の意図に基づいて物体を把持する等のことが行えるが，筋電位は微弱な生体信号であり不安定で，日を跨いだり義手を付け外ししたりすると筋電位の信号特性が変化してしまう時変性の問題が存在する．

これに対して既存の筋電義手は時変性の影響を受けにくい単純な筋電特徴を用いるか機械学習手法を用いて義手を装着するたびに筋電位と動作の関係をモデル化するか大きく2つ方法をとってきた．しかし，前者は筋電位から得られる情報が不足してしまうため制御可能な運動自由度が限られてしまい健常の手とのギャップが大きいという問題，後者は制御可能な運動自由度を増やすほど学習コストが増大して実現性が乏しくなり，学習時間等を実現可能な範囲内に抑えようとする制御可能な運動自由度が減少してしまうという問題があった．

しかし，近年，計算資源の向上と新しい機械学習手法が登場しており大規模なデータを用いて汎化性の高い識別が行えるようになってきた．大規模な筋電位を収集し，筋電位の信号特性の時変性を吸収するような学習を行うことによって，義手の付け外しによる再学習を不要にできるのではないかと考えた．

そこで本研究では義手の装着し直しによる再学習が不要であり，制御可能な運動自由度の多い実用的な筋電義手制御手法の実現を目的とした．

第2章では関連研究と予備実験から本研究が扱う問題領域を定義し，第1章で定めた目標を達成するための評価基準の設定を行い，それに対する本研究のアプローチについて述べた．

第3章では大規模な筋電位を用いた動作意図抽出法として，把持姿勢と把持力の両方をパターン化して扱うパターン認識型と，把持姿勢はパターン認識によって識別し，把持力は線形回帰によって推定する併用型の2つの制御方式に関してそれぞれ Deep Convolutional Neural Network (DCNN) と Selective Linear Regression Model (SLRM) の2つ手法の提案を行った．また，汎化性の高い識別器を構築するための学習データの収集とデータセットの構築方法に関して述べた．

第4章ではハイパーパラメータが識別率に対してどのような影響を与えるのか調査し最適化を行った。

第5章では Offline 解析として提案手法の DCNN, SLRM, そして従来手法であり3層の Artificial Neural Network (ANN)に対して大規模データを適用したものを義手の付け外しを含めた汎化性, 把持力の推定精度, 学習時間によって評価した。

第6章では各手法を実際に義手に実装し, Online で義手を用いて実使用環境下でタスクを行った際のタスクの達成度によって評価を行った。

本研究の成果を以下に示す。

- ・大規模な筋電位データを用いて筋電位の信号特性の時変性を吸収する動作意図識別手法として SLRM と DCNN を提案した。従来手法と比較して筋電位の信号特性の時変性による識別率の低下を抑制できていることが確認された。
- ・DCNN を用いて義手を付け外して識別した際, 把持力を考慮せずに 9 姿勢の識別を行った場合には健常者の被験者平均で約 91%, 把持力を考慮して 25 動作の識別を行った場合には約 84%の識別率で識別が行えた。SLRM を用いて義手を付け外して識別した際, 把持力を連続量として推定しながら各把持姿勢を約 84%の識別率で識別が行えた。このことから達成目標とほぼ同等の精度で筋電位の信号特性の時変性を吸収しつつ, 高い運動自由度を制御できることを示した。
- ・ノイズを混入した筋電位を用いて識別率の変化を検証することによって一般的なノイズ耐性の評価を行った。その結果, DCNN と SLRM は大規模な筋電位データを用いた ANN と比較してノイズ耐性が高く, 義手の付け外しのみならず, 電磁波などの外乱に対しても安定して識別が行えることを示した。
- ・学習時間の検証を行い, 現実的な時間で学習が行えることを確認した。
- ・実機への実装を行い, ノートパソコンによって制御した結果 10fps 以上で制御可能であることを確認した。このことから義手の Online 化と携帯化が行えており, 実用的な範囲内で手法の実装ができることを確認した。
- ・実使用環境下で物体把持タスクを行い, DCNN は 90%, SLRM は 81%の達成度でタスクが行え, 実使用環境下でも安定して制御可能であることを示した。また, 物体の安定度に応じて把持速度を制御できることを確認した。

以上より, 義手の装着し直しによる再学習が不要であり, 制御可能な運動自由度の多い実用的な筋電義手制御手法の実現という目標を達成できたことが示された。

## 7.2 今後の展望

上肢切断者に関して本研究では **Offline** の解析のみ行ったが、全体的に識別率が低い傾向であった。原因としては発揮される筋電位が健常者と比較して小さかったこと、筋電位の再現性が乏しかったことが挙げられる。動作意図と筋電位が一致しない場合、手法に依らず筋電位から動作意図を推定することが困難となってしまう。今回対象とした被験者は受傷後 15 年以上経過しており筋委縮が起こってしまっていること、また、運動イメージの喪失が起こっていることが要因として挙げられる。しかし、これらの要因に関しては筋トレのようなリハビリによって回復可能であることが知られており、長期的なリハビリを行った際に識別率が改善するか検証する必要がある。

本研究では最低限の運動自由度として把持姿勢 9 姿勢、把持力 3 段階もしくは連続値としたが、9 動作では ANN と DCNN の識別率に差がみられなかったが、25 動作では DCNN の方が識別率が高かったことから、より多くの運動自由度を対象とした方が DCNN の優位性が示される可能性があり、対象動作を増やして検証する必要がある。

本研究では他の筋電義手に関する研究と比較して大規模な筋電位データを用いているがそれでも数日分の筋電位しか用いていない。義手は日常的に装着して長時間使用するものである。実際に日常的に義手を使用している際の筋電位を収集し逐次学習データを追加していくことによって、より推定性能が向上することが期待され、数か月にわたるような長期的な検証を行う価値がある。

## 謝辭

本論文は横浜国立大学加藤研究室にて執筆されたものです。この場をお借りしてご指導ご協力いただいた皆様に厚くお礼申し上げます。

まず初めに指導教員である横浜国立大学工学府の加藤龍准教授に深く感謝いたします。加藤准教授には学部生のころから6年以上にわたってご指導いただきました。研究の進め方や発表の仕方、また、情報処理や筋電義手の基礎などに関してまだ何もわかっていなかった私にご教授いただきました。特に学部や修士課程時には多くの時間をかけてご指導いただいたことによって研究者としての基礎を培うことができたと思っています。また、加藤准教授のご尽力により恵まれた研究環境によって研究活動に専念できたことを深く感謝しています。

また、電気通信大学情報理工学研究科の横井浩史教授に深く感謝いたします。横井研究室は共同研究先であり、また、私の学部及び修士課程時の所属先でした。横井教授には私に筋電義手の研究に携わるきっかけを与えていただきました。横井教授に出会い、研究の楽しさに触れていなければ研究者を志していなかったと思います。厳しくも暖かいご指導によって導いていただいたことを心よりお礼申し上げます。

研究活動を進めるにあたって研究室のスタッフ、先輩、後輩、同期の学生に様々なお力添えをいただきました。特に加藤研究室は新設の研究室であったため私が最年長者となる機会が多く、後輩たちには様々な面で迷惑をかける機会も多かったと思います。彼らに研究に関する議論や実験に付き合ってもらうことがなければ研究活動を行うことはできませんでした。協力していただきありがとうございました。

私の研究は上肢切断者の被験者や共同研究先の医師、義肢装具士、理学療法士など様々な分野の多くの方々のご協力のもとに成り立っている研究です。これらの方々の協力無くして研究活動を進めることは不可能でした。これだけ多くの方々にご協力いただいて研究活動を行うことは稀なことであり、とても恵まれた環境で研究活動を行うことができたと思っています。このような環境を作るためにご尽力いただいた先生方、ご協力いただいた被験者の方々や共同研究先の方々に深く感謝申し上げます。

2019 年 03 月



# 参考文献

## 和文文献

[加藤 2008]

加藤 龍："信号の個人差と時変性に適応する筋電義手を用いた運動機能再建に関する研究", 東京大学博士論文, (2008).

[栗田 2018]

栗田 雄一, 石原 茂和, 稲見 昌彦："サイバスロンと人間拡張工学", 電子情報通信学会 通信ソサイエティマガジン, Vol.12, No.2, pp.105-111, (2018).

[厚生労働省 2013] 平成 23 年生活のしづらさなどに関する調査(全国在宅障害児・者実態調査)結果, (2013).

[辻 2010]

辻 敏夫, 芝軒 太郎, 島 圭介, 高木 健, 大塚 彰, 陳 隆明："電動義手 日本元年を迎えて 5 指駆動型筋電義手と筋シナジーモデルに基づく制御法", 日本義肢装具学会誌, Vol.26, No.2, pp.91-96, (2010).

[辻内 2010]

辻内 伸好, 小泉 孝之, 栗栖 直之："動作識別手法を用いた筋電義手制御法", 生活生命支援医療福祉工学系学会連合大会講演論文集 2010, (2010).

[永田 2010]

永田 健太郎, 曲谷 一成, 山田 雅史："表面筋電図を利用した手の動作認識と動作時の筋力推定", Proceedings of the 2010 JSME Conference on Robotics and Mechatronics, (2010).

[山田 2017]

山田 洋："筋電義手操作に同期した触刺激が運動主体感に与える影響の調査", 横浜国立大学修士論文, (2017).

[otto bock 2014]

Ottobock JP："筋電義手：マイオボック成人用", [https://www.ottobock.co.jp/prosthetic\\_ue/myoelectric/myo\\_system/](https://www.ottobock.co.jp/prosthetic_ue/myoelectric/myo_system/), (2014) .

## 英文文献

[Atzori 2016]

Manfredo Atzori, Matteo Cognolato, and Henning Müller : "Deep Learning with Convolutional Neural Networks Applied to Electromyography Data: A Resource for the Classification of Movements for Prosthetic Hands", *frontiers in Neurorobotics*, vol.10, Article 9, (2016)

[Cannon 1924]

Walter Bradford Cannon : "Biographical Memoir, Henry Pickering Bowditch, 1840-1911", *National Academy of Sciences*, Vol.17, 8<sup>th</sup> memoir, pp.181-196, (1924).

[Celadon 2016]

Nicolò Celadon, Strahinja Došen, Iris Binder, Paolo Ariano, Dario Farina : "Proportional estimation of finger movements from high-density surface electromyography", *Journal of NeuroEngineering and Rehabilitation*, Vol.13, No.1, Article 73, (2016).

[Cipriani 2011]

Christian Cipriani, Christian Antfolk, Marco Controzzi, Goran Lundborg, Birgitta Rosen, Maria Chiara Carrozza, Fredrik Sebelius : "Online Myoelectric Control of a Dexterous Hand Prosthesis by Transradial Amputees", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol.19, No.3, pp.260-270, (2011).

[Controzzi 2016]

Marco Controzzi, Francesco Clemente, Diego Barone, Alessio Ghionzoli, Christian Cipriani : "The SSSA-MyHand : a dexterous lightweight myoelectric hand prosthesis", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, pp.1-11, (2016).

[Glorot 2011]

Xavier Glorot, Antoine Bordes, and Yoshua Bengio : "Deep Sparse Rectifier Neural Networks", *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, pp. 315-323, (2011)

[Hinton 2006]

Geoffery E.Hinton, Simon Osindero, Yee-Whye The : "A Fast Learning Algorithm for Deep Belief Nets", Neural Computation, Vol.8, No.7, pp.1527-1554, (2006)

[Hioki 2011]

Masaaki Hioki, Shoya Ebisawa, Hirofumi Sakaeda, Tetsuya Mouri, Shinobu Nakagawa, Yoshinori Uchida, Haruhisa Kawasaki : "Design and Control of Electromyogram Prosthetic Hand with High Grasping Force", Proceedings of the 2011 IEEE International Conference on Robotics and Biomimetics, pp.1128-1133, (2011) .

[Kauppi 2015]

Jukka-Pekka Kauppi, Janne Hahne, Klaus-Robert Müller, Aapo Hyvärinen : "Three-Way Analysis of Spectrospatial Electromyography Data: Classification and Interpretation", PloS one, Vol.10, No.6, Article e0127231, (2015).

[Krizhevsky 2012]

Alex Krizhevsky, Ilya Sutskever, Geffery E. Hinton : "ImageNet Classification with Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems, pp.1097-1105, (2012)

[LeCun 1989]

Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R.E. Howard, W. Hubberd, L. D. Jackel : "Backpropagation Applied to Handwritten Zip Code Recognition", Neural Computation, Vol.1, No.4, pp.541-551, (1989)

[Minohara 2016]

Rin Minohara, Wen Wen, Shunsuke Hamasaki, Takaki Maeda, Motoichiro Kato, Hiroshi Yamakawa, Atsushi Yamashita, Hajime Asama : "Strength of Intentional Effort Enhances the Sense of Agency", Frontiers in psychology, vol.7:1165, (2016).

[Rojas-Martínez 2012]

Monica Rojas-Martínez, Miguel A Mañanas, Joan F Alonso : "High-density surface EMG maps from upper-arm and forearm muscles", Journal of NeuroEngineering and Rehabilitation, Vol.9, No.1, Article 85, (2012).

[RSL Steeper 2017]

RSL Steeper : “The world’s most advanced Prosthetic Hand - bebionic”, <http://bebionic.com/>, (2017).

[Sasaki 2017]

Tomoya Sasaki, MHD Yamen Saraiji, Charith Lasantha Frnand, Kouta Minamizawa, Masahiko Inami : “MetaLimbs: Multiple Arms Interaction Metamorphism”, ACM SIGGRAPH 2017 Emerging Technologies, (2017).

[Shim 2015]

Shim Hyeon-min, Lee Sangmin : "Multi-channel electromyography pattern classification using deep belief networks for enhanced user experience", Journal of Central South University, Vol.22, No.5, pp.1801-1808, (2015)

[Sidek 2012]

Shahrul Naim Sidek, Nor Anija Jalaludin, Abu Ubaidah Shamsudin : "Surface Electromyography (sEMG)-based Thumb-tip Angle and Force Estimation Using Artificial Neural Network for Prosthetic Thumb", Procedia Engineering, Vol.41, pp.650-656, (2012).

[Touch Bionics 2018]

Touch Bionics : “i-limb quantum”, <http://touchbionics.com/products/active-prostheses/i-limb-quantum>, (2018).



## 研究業績

### 学術雑誌

- (1) Yusuke Yamanoi, Soichiro Morishita, Ryu Kato, Hiroshi Yokoi : “Development of myoelectric hand that determines hand posture and estimates grip force simultaneously”, Biomedical Signal Processing and Control vol.38, pp.312-321, (2017).
- (2) [共著] Takehiko Takagi, Yosuke Ogiri, Ryu Kato, Mitsuhiko Kodama, Yusuke Yamanoi, Wataru Nishino, Yoshihisa Masakado, Masahiko Watanabe : “Selective Motor Fascicle Transfer and Neural-Machine Interface : case report”, Journal of Neurosurgery, pp.1-7, (2019).
- (3) [共著] Yosuke Ogiri, Yusuke Yamanoi, Wataru Nishino, Ryu Kato, Takehiko Takagi, Hiroshi Yokoi : “Development of an upper-limb neuroprosthesis to voluntarily control elbow and hand”, Advanced Robotics, vol.32, No.16, pp.879-886, (2018).
- (4) [共著] 星川 英, 迫田 辰太郎, 山野井 佑介, 加藤 龍, 森下 壮一郎, 中村 達弘, 關 達也, 姜 銀来, 横井 浩史 : "基本把持機能を有する簡易型筋電義手の開発と評価," 知能と情報, vol.27, No.6, pp.885-897, (2015).

### 国際会議

- (1) Yusuke Yamanoi, Ryu Kato : “Control Method for Myoelectric Hand using Convolutional Neural Network to Simplify Learning of EMG Signals”, 2017 IEEE International Conference on Cyborg and Bionic Systems, pp.114-118, (2017).
- (2) Yusuke Yamanoi, Soichiro Morishita, Ryu Kato, Hiroshi Yokoi : "Selective Linear-Regression Model for Hand Posture Discrimination and Grip Force Estimation using Surface Electromyogram Signals", 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 4812-4815, (2015).
- (3) [共著・発表者] Daiki Suzuki, Yusuke Yamanoi, Hiroshi Yamada, Ko



Wakita, Ryu Kato, Hiroshi Yokoi : "Grasping-posture classification using myoelectric signal on hand pre-shaping for natural control of myoelectric hand", 2015 IEEE International Conference on Technologies for Practical Robot Applications, (2015).

- (4) [共著] Yosuke Ogiri, Yusuke Yamanoi, Wataru Nishino, Ryu Kato, Takehiko Takagi, Hiroshi Yokoi : “Development of an upper limb neuroprosthesis to voluntarily control elbow and hand”, 2017 26<sup>th</sup> IEEE International Symposium on Robot and Human Interactive Communication, pp.298-303, (2017).
- (5) [共著] Josuke Kawashimo, Yusuke Yamanoi, Ryu Kato : “Development of Easily Wearable Assistive Device with Elastic Exoskeleton for Paralyzed Hand”, 2017 26<sup>th</sup> IEEE International Symposium on Robot and Human Interactive Communication, pp.1046-1051, (2017).
- (6) [共著] Wataru Nishino, Yusuke Yamanoi, Yoshiaki Sakuma, Ryu Kato : “Development of a Myoelectric Prosthesis Simulator using Augmented Reality”, 2017 IEEE International Conference on Systems, Man, and Cybernetics, pp.1046-1051, (2017).
- (7) [共著] Hiroshi Yamada, Yusuke Yamanoi, Ko Wakita, Ryu Kato : “Investigation of a cognitive strain on hand grasping induced by sensory feedback for myoelectric hand”, 2016 IEEE International Conference on Robotics and Automation, pp.3449-3554, (2016).

## 国内発表

- (1) 山野井 佑介, 加藤 龍 : “Convolution Neural Network を用いた再学習不要な筋電義手の制御手法”, 計測自動制御学会 第 23 回創発システム・シンポジウム「創発夏の学校」, (2017).
- (2) 山野井 佑介, 森下 壮一郎, 加藤 龍, 横井 浩史 : “把持し姿勢識別と把持力推定を同時に行う筋電義手の開発”, 計測自動制御学会 第 22 回創発システム・シンポジウム「創発夏の学校」, (2016).

- (3) 山野井 佑介, 森下 壮一郎, 加藤 龍, 横井 浩史 : “Bilateral Training を利用した表面筋電位からの把持姿勢識別及び把持力推定手法”, 日本ロボット学会学術講演会, (2015).
- (4) 山野井 佑介, 鈴木 大輝, 加藤 龍, 横井 浩史 : “選択的線形回帰モデルを用いた表面筋電位からの把持姿勢識別及び把持力推定”, 第 92 回パターン計測部会研究会, pp.20-27, (2014).
- (5) 山野井 佑介, 加藤 龍, 横井 浩史 : “筋電義手による自然な物体把持のための把持姿勢及び把持力推定手法”, 第 15 回日本電気生理運動学会, pp.3-4, (2014).
- (6) [共著] 高木 岳彦, 児玉 三彦, 加藤 龍, 山野井 佑介, 西野 亘, 大桐 洋亮, 横井 浩史, 高山 真一郎, 将門 由久, 渡辺 雅彦 : “上腕切断患者に対する Targeted Muscle Reinnervation –神経の選定と再支配、より効率的な多自由度筋電義手操作のために-”, 第 28 回日本末梢神経学会, (2017).
- (7) [共著] 佐久間 良顕, 山野井 佑介, 加藤 龍, 山村 修 : “床振動音を用いた独居高齢者の転倒因子予測に関する研究”, LIFE2016 (第 32 回ライフサポート学会大会, 第 16 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 2016), (2016).
- (8) [共著] 西野 亘, 山野井 佑介, 佐久間 良顕, 加藤 龍 : “拡張現実感を用いた筋電義手シミュレータの開発”, 第 21 回日本バーチャルリアリティ学会, (2016).
- (9) [共著] 横河 佑一, 山田 洋, 山野井 佑介, 加藤 龍 : “母指姿勢の制御を可能とする表面電気刺激手法の開発”, 第 34 回日本ロボット学会学術講演会, (2016).
- (10) [共著] 川下 丈佑, 山野井 佑介, 加藤 龍 : “麻痺種への簡易装着可能な手指運動支援装置の開発”, 第 34 回日本ロボット学会学術講演会, (2016).
- (11) [共著] 大桐 洋亮, 山野井 佑介, 山田 洋, 西野 亘, 加藤 龍, 矢吹 佳子, 横井 浩史 : “肘と手指を同時制御可能な生体信号制御型電動義手の開発 –身体負担が小さく日常生活動作が可能な上肢電動義手の製作-”, 第 34 回ロ

ボット学会学術講演会, (2016).

- (12) [共著] 脇田 航, 山田 洋, 鈴木 大輝, 山野井 佑介, 加藤 龍 : "多自由度筋電義手のための眼電信号による把持速度制御法", 第 33 回日本ロボット学会学術講演会, (2015).
- (13) [共著] 山田 洋, 鈴木 大輝, 山野井 佑介, 脇田 航, 加藤 龍 : "筋電義手の触覚フィードバック方法が把持に関する認知的負担に与える影響の調査", 第 33 回日本ロボット学会学術講演会, (2015).
- (14) [共著] 鈴木 大輝, 山田 洋, 脇田 航, 山野井 佑介, 横井 浩史, 加藤 龍 : "自然な操作感実現のための手指のプリシェイピング時の表面筋電位と物理センサを用いた筋電義手の制御法", 日本機械学会関東支部第 21 期総会講演会, (2015).
- (15) [共著] 脇田 航, 山田 洋, 鈴木 大輝, 山野井 佑介, 加藤 龍 : "多自由度筋電義手の把持速度制御のための眼電図を用いた物体注視度の推定", 関東学生会第 54 回学生員卒業研究発表講演会, (2015).
- (16) [共著] 山田 洋, 鈴木 大輝, 山野井 佑介, 脇田 航, 加藤 龍 : "筋電義手の触覚フィードバック方法が把持に関する認知的負担に与える影響の調査", 関東学生会第 54 回学生員卒業研究発表講演会, (2015).
- (17) [共著] 鈴木 大輝, 山野井 佑介, 加藤 龍, 横井 浩史 : "プリシェイピング中に計測される表面筋電位を用いた物体の把持姿勢識別", 第 15 回日本電気生理運動学会, pp.5-6, (2014).



## 付録

## A. 筋電位の計測

本節では次節以降で各手法について詳しく論じる前に計測された筋電位の特性に関して述べる．本論文における全ての筋電位は筆者が所属する研究室で設計された筋電センサを用いて計測された．筋電センサの回路図を **Figure A.1** に示す．筋電位は微弱な生体信号でありノイズの影響を受けやすい．設計した筋電センサは差動増幅器，ノッチフィルタ，バンドパスフィルタ，2 次アンプから成る．

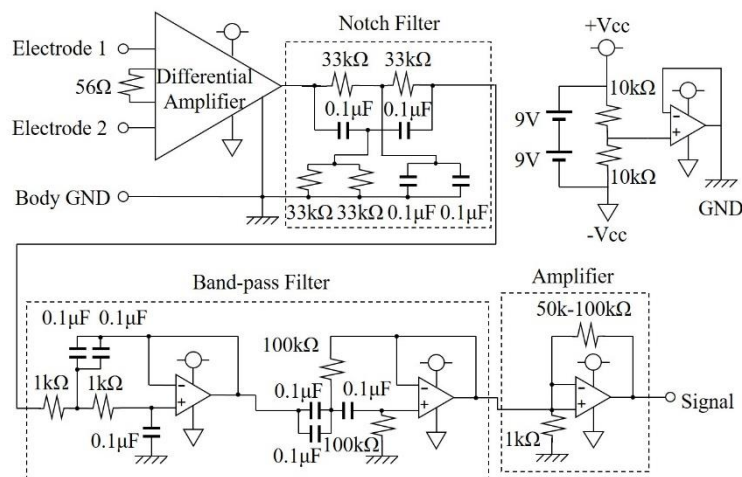


Figure A.1 筋電センサ回路図

差動増幅器とは隣接する 2 つの電極から計測された信号の差をとることによって，2 つの電極に共通して混入するノイズの同相成分を除去し，2 つのセンサ間に流れる電流のみを抽出する回路であり，微弱な生体信号を計測する際によく用いられる．筋電センサの場合，2 つの電極を筋繊維方向に貼付し，ボディ GND を肘などの直下に筋が存在しない位置に貼付する．差動増幅器はボディ GND とそれぞれの電極との電圧を計測し，その差を増幅して出力する．それにより，電磁波等の外部からセンサに対して混入するノイズを除去し，筋繊維に流れる筋電位のみを計測することができる．

差動増幅器によって同相成分のノイズを除去したがそれでも計測される筋電位にはまだ多くのノイズが含まれている．表面筋電位の主たるノイズは商用電源から発せられる電磁波である Power Line Interference (PLI) であると言われている [Chowdhury 2013]．PLI は 50Hz もしくは 60Hz のノイズであるため，ノッチフィルタを用いて 50Hz 周辺のノイズ要素を除去する．

また，筋電位は神経から筋繊維に対して伝わるインパルス信号であるが，その周波数は 10 から 400Hz 程度であると言われている．そのため，計測された信号の内，10

から 400Hz の周波数以外の信号成分は筋電位以外によるものと考えることができる．そこでハイパスフィルタとローパスフィルタを組み合わせたバンドパスフィルタによって 10 から 400Hz の信号成分のみを抽出する．

最後にセンサから計測された信号が AD コンバータによって取り込まれるまでの送電中に電磁波等の影響を受け辛くするために 2 次アンプによって増幅する．最終的に差動増幅器と 2 次アンプを合わせて 80000 倍程度に増幅する．

計測された筋電位信号とその周波数特性を Figure A.2 と Figure A.3 に示す．




Figure A.2 筋電センサによって計測された筋電位




Figure A.3 筋電位の周波数特性