

186. センサ融合による運動神経生理ビヘイビアキャプチャ

舒 利明

東京大学 大学院工学系研究科 人工物工学研究センター

Key words : EMG 分解, モーターユニット, パターン認識, 独立成分分析

緒 言

最新の調査によると、日本国内の上肢身体欠損患者は約 8 万 2 千人に上ることがわかっている [1]。上肢機能を補うための装置として、代表的なものとして義手があげられる。その中で筋電義手は、筋収縮によって発生する電気信号である筋電図 (Electromyogram : EMG) 信号を利用する義手である。EMG 信号は筋肉を動作させる際に運動神経が発生させる電氣的信号によるものであるため、ヒトの筋運動の状態や動作の意図を反映することを可能とし、直感的操作運動の実現や使用者の QOL (Quality of Life) を向上させるツールとして注目されている [2] が、手指の複雑な運動の制御が実現されていないという課題をもっている。

運動単位 (Motor Unit) は、神経筋系における最小の機能単位であり、一つの運動神経とそれが支配する多数の筋繊維を指す。得られた EMG を運動単位に分解することは、義手制御の神経インターフェイスとして有用なアプローチとなりうる。先行研究で、高密度 EMG (High-Density EMG : HD-EMG) 信号を複数の運動単位のスパイク列 (Motor Unit Spike Trains : MUST) に分解するアルゴリズムが提案されている [3]。MUST は、脊髄に存在する運動神経の発火のタイミングを示すパルスを意味し、運動単位の運動神経の活動を表している。しかし、MUST をどのように義手の制御に適用するかは確立されていない。同時に、リアルタイムにこれらのデータを処理して筋電義手に応用するアルゴリズムも実現されていない。また抽出された運動単位ごとの物理的意味は一般に無視されて数値的な解析のみが行われているため、手指の協調運動などの複雑な運動に対しても原理的に有用な手法であるということは示されていない。そのため、分解された運動単位の物理的な意味を理解し、それをを用いた義手制御手法を確立して、オンライン処理で義手を制御するアルゴリズムを実現することが求められている。

方 法

本研究では、手指の独立した屈曲動作及びその組み合わせによる協調運動の EMG データから、元信号である神経活動情報を抽出し、その物理的意味を示す方法を提案する。これにより協調運動に対しても、原理的に従来手法が適用可能であることを示す。

1. センサ融合による運動神経生理ビヘイビアキャプチャの構築

モーションキャプチャシステムを構築するため、まず深度カメラと慣性センサを採用した。さらに、センサフュージョンより深度カメラの高精度なリアルタイムで全身の運動を測定するアルゴリズムを開発した (図 1)。本研究では二つの手法の特徴を融合する上で、高精度な位置と姿勢の測定を可能にする、Azure Kinect DK 深度カメラ (Microsoft 社) を用い、コンピュータビジョンの手法より高速でヒトの深度画像と骨格情報を検知する。慣性センサ (Xsens 社) を用いることにより、リアルタイムで加速度と角速度を計測する。Dempster-Shafer 理論を用いて、計測した情報を融合するより、ヒトの姿勢・方位、関節速度、位置を得ることができた。また、高密度筋電電極を用いてジュラーアーキテクチャを備えた筋電測定するセンサユニットを開発した。各センサ

ユニットは、ボディセンサーネットワークのノードとして、さまざまな筋肉からの同期信号取得することが可能となった。

2. 神経活動情報抽出のアルゴリズム

肢身体欠損患者のため、センサ融合による運動神経生理ビヘイビアキャプチャを利用し、前腕筋群の運動神経情報抽出に基づく指の独立動作可能な筋電義手制御手法を開発する。実験装置は図 1 に示す。EMG データから神経活動情報を抽出する手法は一般に EMG decomposition と呼ばれる。本研究では従来研究と同様に、独立成分分析 (Independent Component Analysis : ICA) に基づいたアルゴリズムによって EMG decomposition を行う。ICA は以下のような生成モデルに基づいて元の成分を計算する手法である。

$$\mathbf{x}(n) = \mathbf{A}\mathbf{s}(n) \quad (1)$$

ここで n を離散時間として、 $\mathbf{x}(n)$ は観測されるデータ、 \mathbf{A} は混合行列、 $\mathbf{s}(n)$ は元の成分を表す。観測できるのは $\mathbf{x}(n)$ のみであり、両方を推定しなければならない。そのため、 $\mathbf{s}(n)$ の各成分が独立であり、非ガウスの変数であるという仮定の下で推定を行う。EMG decomposition としての解釈としては、 $\mathbf{x}(n)$ は EMG データ、 \mathbf{A} の各列は運動単位の活動電位 (MUAP) の波の広がり形状 (MUAP waveform)、 $\mathbf{s}(n)$ は MUAP の大きさを表す (ただし、EMG データ $\mathbf{x}(n)$ は MUAP の長さの分 R 個の遅延を追加して拡張したベクトルを用いる)。 $\mathbf{s}(n)$ の各成分が独立であるという仮定によって、独立した MUAP の推定が可能となる。以上の推定を実現するアルゴリズムとして FastICA [4] が一般的に使用される。推定によって得られた MUAP は、さらに、スパイク列を抽出するために K-means++ アルゴリズムによってバイナリ化され、最終的に MUST を得る。

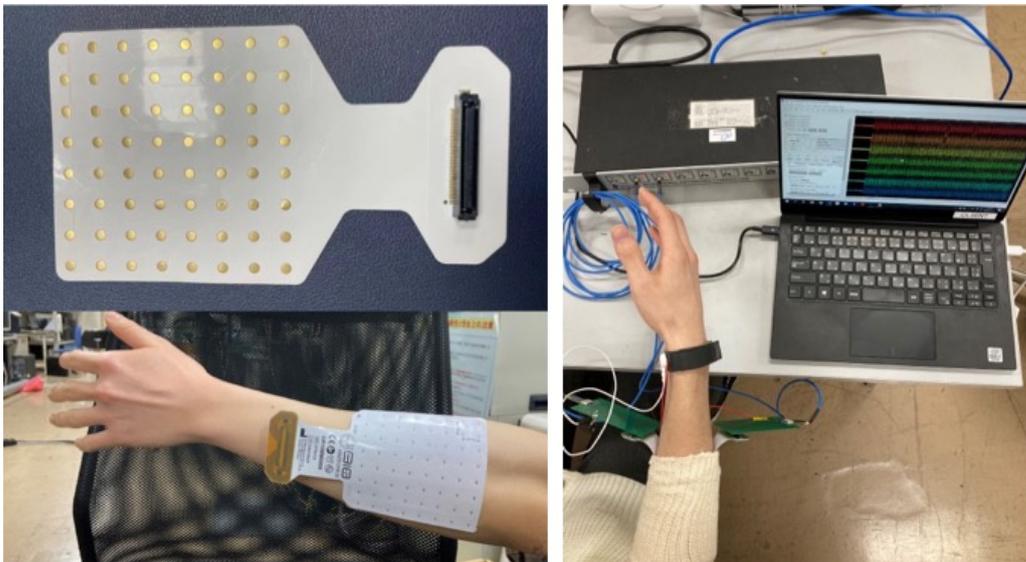


図 1. 筋電測定するセンサユニットとモーションキャプチャシステム

EMG センサは 8×8 のグリッドの 64 チャンネル高密度筋電センサを開発しており、各電極間の距離は 10 mm である。高密度筋電センサは指の屈筋群、伸筋群を覆うように 2 枚を前腕に貼付した。

3. 神経活動情報の物理的意味に関する解析

本研究では 4 人の被験者に対して手指の独立運動と協調運動の 8×8 の 64 チャンネル高密度 EMG のデータセットを作成し、それぞれについて EMG decomposition を行い、MUST を抽出した。データセット 1 では、(0)

脱力・(1) 第1指・(2) 第2指・(3) 第3指・(4) 第4指・(5) 第5指の独立した屈曲をそれぞれ3回ずつ行った。データセット2では、(0) 脱力・(1) 第2指・(2) 第2指、第3指・(3) 第2指、第3指、第4指・(4) 第2指、第3指、第4指、第5指のそれぞれの組み合わせの屈曲動作を各3回ずつ行った。データセット1の MUST 抽出結果の一例を図2に示す。縦軸が運動単位のインデックス、横軸が時間を示し、スパイクを縦棒で表した(図2)。抽出された運動単位のうち最も各手指の駆動にかかわっているものを選ぶために、(i) それぞれのデータセットで各手指を駆動する有意な運動単位を絞る(ii) データセット1、2間で共通の活性化を示す運動単位を選び出す、という二段階の抽出を行う。

(i) では MUST から単位時間当たりのスパイクの数(Firing Rate : FR)を算出し、それぞれの動作で平均値を計算する。これによって、それぞれの運動単位ごとに動作数分の平均値データを得る。この数値を各手指への貢献度の指標として、各手指に対して優位な運動単位の候補を選別する。

(ii) では、式(1)の混合行列 \mathbf{A} に基づいた活性化のマッピング(MUAPマッピング)を行う。 \mathbf{A} の各列はそれぞれの運動単位に対応し、各列の要素はセンサの電極に対応する。したがって、各列は運動単位が活性化するときの電極が受け取る電位の大きさを反映している。(i)の候補の中から、このマッピングがデータセット1、2間で最も類似している運動単位を、各手指の駆動に最も貢献する運動単位であるとして抽出した。その一例を図3に示す。

この活性化の様子は、データセット1、2間で非常に類似しており、さらに、手指にかかわる筋の解剖学的な特徴に合致した。このことから協調運動が、独立運動で駆動する運動単位の活性化の組み合わせによって行われることが示唆された。

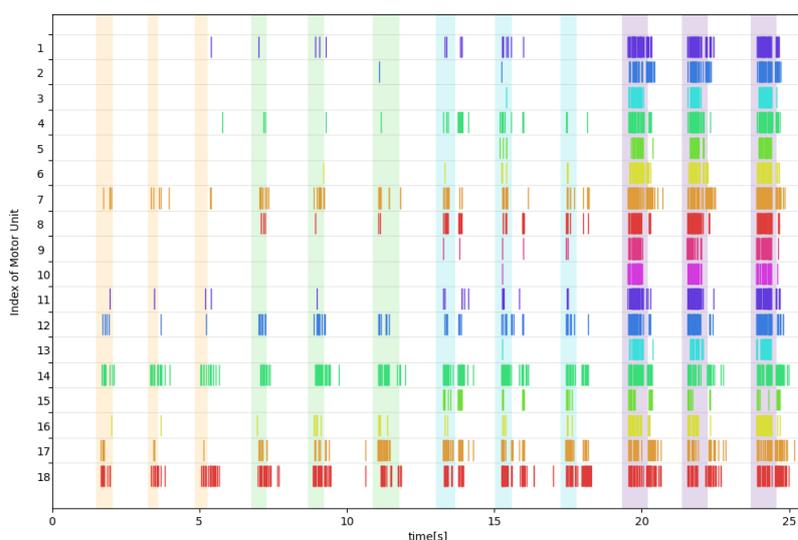


図2. 運動単位のスパイク列の例

各被験者に対するデータセットの MUST 抽出の結果を以下に示す。縦軸に運動単位のインデックスを置き、横軸を時間としてスパイク列の発生タイミングを縦棒で表した。

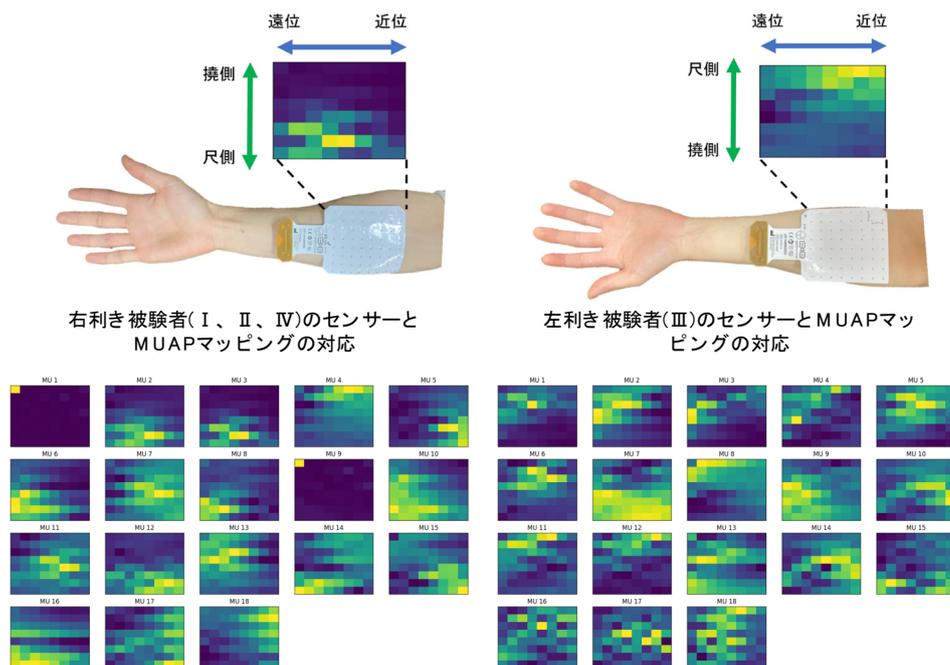


図 3. MUAP マッピング

被験者 I、II、IV は右利きで、それぞれのマッピングにおいて上が撓側、下が尺側、右が近位、左が遠位となっている。また、被験者 III は、上下が逆で、上が尺側、下が撓側となっている。

4. パターン認識での手指屈曲動作分類

独立運動及び協調運動から得られた MUST は、解剖学的・神経科学的に妥当なものであることが示された (図 4)。そのため、この情報が筋電義手制御のための特徴量として、従来的特徴量と比較して優位なものであることを示すために、パターン認識モデルによる動作分類を行った。パターン認識モデルは筋電義手制御のための手法として提案されてきたものだが、EMG から二乗平均平方根 (Root Mean Square : RMS) などの特徴量を算出して用いるのが一般的である。そのため、本研究では MUST から FR を算出し、それを特徴量としてデータセット 1 及び 2 のそれぞれについてパターン認識モデルを学習し、評価を行った。同時に RMS を入力とするパターン認識モデルによる分類を行い比較した。

データセット 1、2 で MUST に基づくものはそれぞれ平均 Accuracy 0.936、0.816 を得た。この結果について、MUST に基づくパターン認識モデルと RMS に基づくパターン認識モデル間で t 検定を行った結果、それぞれ $p=0.0434$ 、 $p=0.0068$ で $p<0.05$ より、平均値に有意差が示唆された。そのため、独立運動、協調運動ともに従来手法に対する優位性が示された。

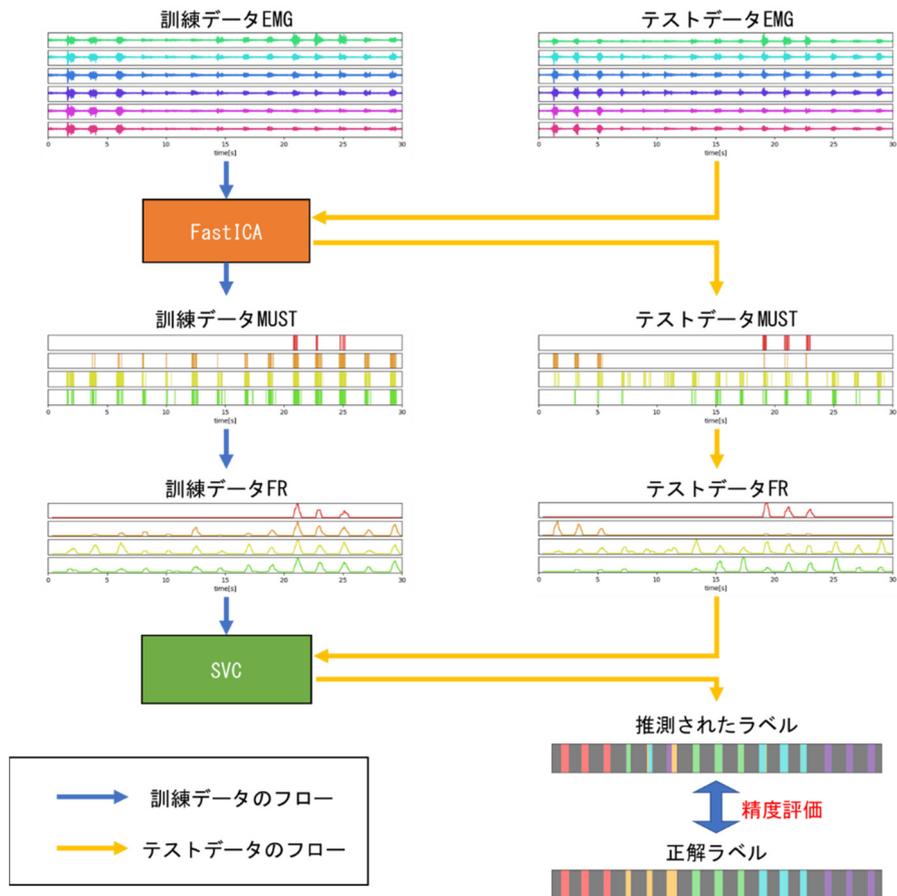


図 4. パターン認識での手指屈曲動作分類手法

訓練データ EMG に対して FastICA による EMG decomposition を行い、MUST を推定する。このときに得られる白色化行列及び直交変換行列、どの運動単位が SIL に基づき採用されたかを保存しておく。さらに、得られた MUST から、それぞれの運動単位について単位時間当たりの発火率 (Firing Rate : FR) を算出する。このようにして得られた FR のサンプルに対して、それぞれのサンプルがどの動作に対応するかのラベル付けを行う。FR を入力として、線形のサポートベクター分類器 (Support Vector Classifier : SVC) を用いてラベル付けした動作を推定できるよう学習を行う。

5. オンライン筋電義手制御システム

EMG decomposition に基づく手指屈曲動作の分類を利用して、オンラインの筋電義手制御システム (図 5) を構成し、筋電義手制御のシミュレーションを行って妥当性を検証する。以下にその概念図を示す。このシステムによって、EMG センサからのデータをオンライン処理し、パターン認識モデルで分類した動作を、ロボットハンドにリアルタイムかつ 90% の精度で反映することを可能にした。

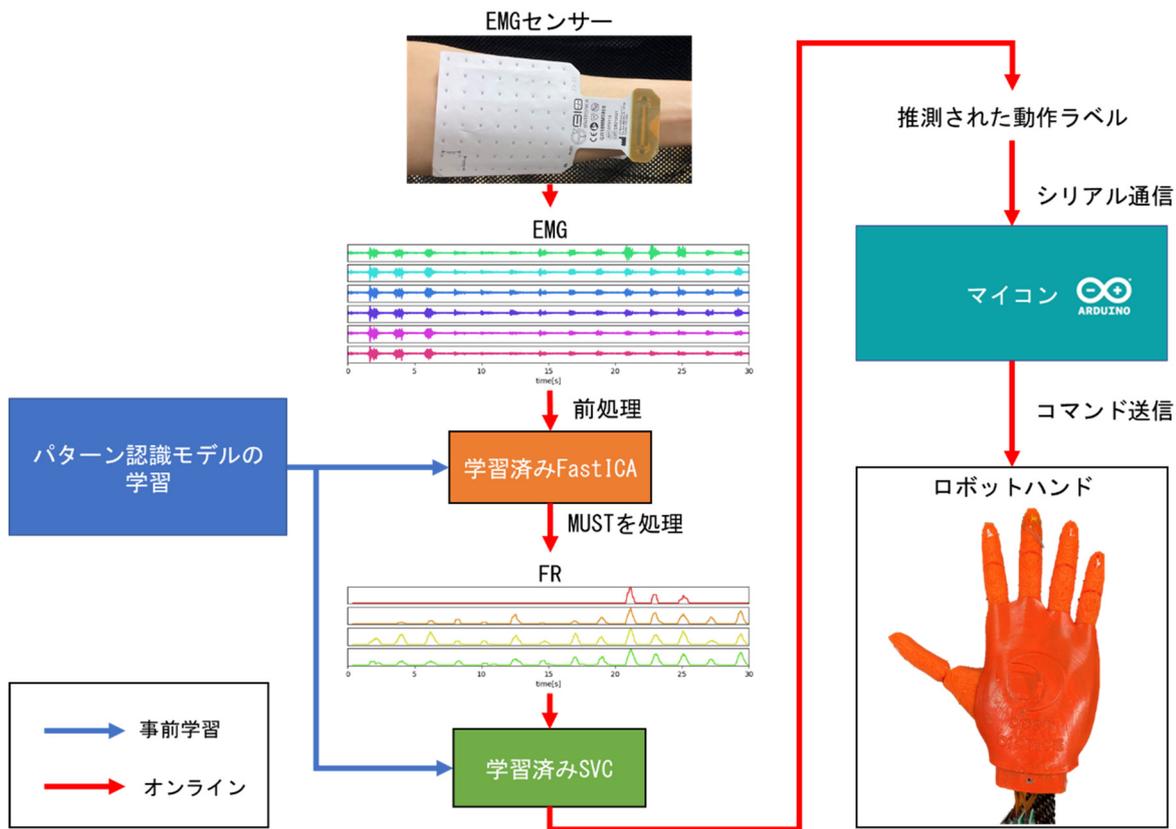


図 5. オンライン筋電義手制御システム

EMG Decomposition に基づくオンライン筋電義手制御システムであり、実際の動作を反映させるために、Open Bionics の提供するロボットハンド“Ada Robotic Hand”を用いて、動作分類の結果を義手の動作として実現した。

結果

本研究では、手指の独立及び協調の屈曲動作について神経活動情報の抽出を行い、その妥当性を検証した。解析によってそれぞれに共通の運動単位がみられたことから、独立運動の運動単位の活動を複数組み合わせることで、協調運動の筋活動を表現することが示された。また、混合行列から得られた活性化の様子は解剖学的事実を反映しており、複雑な手指の筋の構造の理解に貢献する可能性が示唆された。また、オンライン筋電義手制御システムによってリアルタイムでも高精度な動作分類が可能であることを示した。

実際にリアルタイムの制御を行った際の実分類精度はおおよそ 90%で、オフラインの学習結果と比較すると低いですが、十分なロバスト性を持っていることが確認された。しかし、動作を開始してからロボットハンドに反映されるまでの遅延時間は、0.384 s のデータ長の分を含め 1.0 s 程度であった。これは、マイコンへの入力がオーバーフローしないよう設定した 0.3 s の遅延、さらにロボットハンドを駆動するリニアアクチュエータに接続している紐の遊びによって、張力がかかるまでに時間がかかってしまうなどの問題によるものと考えられる。よって、マイコン側の高速度処理化やハードウェアの精密さを高めることにより、遅延時間は大幅に削減可能であると推測される。

考 察

手指の独立運動と協調運動を解析するために、筋活動にかかわる神経情報を EMG データから抽出した。その過程で、独立成分分析による EMG decomposition を行い、運動単位のスパイク列 (MUST) 及びその発火率 (FR) を得たが、それらの値は浅層・深層からなる浅指屈筋の筋配置を反映したものであると結論付けられた。被験者間でも FR の傾向は類似しており、スパイク発火の絶対数のみが大きく異なっており、先に述べた通り被験者ごとに駆動する運動単位の性質 (動員・発火率) が異なることの裏付けといえる。

さらに、各動作の FR に基づく選別と混合行列に基づく選別によって、独立運動 (データセット 1) と協調運動 (データセット 2) に共通して存在する各手指のみを駆動する運動単位を特定し、その活性化を観察した。FR に基づく選別では、本研究で「FR ベクトル」と名付けた動作ごとの FR を各成分とした単位ベクトルによって、運動単位がどの手指の運動にかかわるものかを大別可能であることを確認した。これによって運動単位の定量的な解釈可能性を示すことができた。また、混合行列を MUAP マッピングに落とし込んで解析することにより、運動時の筋肉の活性部位の特定を行ったが、活性化の様子は解剖学的な解釈と結びつけることが可能であった。このことから、独立成分分析による MUST の抽出は、運動単位が独立な活動を行うという仮定のもとに行われており、数学的・統計学的意味をもつ概念だが、それぞれの活動の様子を詳細に考察することにより、解剖学的な観点からも重要な位置づけにあるといえる。

また、被験者間で運動単位の動員数や発火率調整などの性質が大きく異なっていたにもかかわらず、FR や MUAP マッピングには同様の傾向がみられた。このことから、EMG decomposition による神経活動情報抽出は対象者の運動神経系の性質にかかわらず、有意な運動単位の情報へと分解可能と結論付けられる。

EMG decomposition に基づく特徴量抽出手法を利用して、オンラインの筋電義手制御システムを構築した。これによって被験者の動作を、EMG センサを介してリアルタイムに反映することを可能とした。前述のパターン認識モデルを分類器として、EMG データから動作を分類し、シリアル通信でマイコンにその情報を送信、ロボットハンドを駆動することで運動を再現することに成功した。

遅延時間の点に課題を残したが、ハードウェア及び動作のコマンド送信を改善することで解決できると考えられた。また、リアルタイムの動作分類の精度は十分なものであり、提案したアルゴリズムを適用するうえで、実際の筋電義手のシミュレータとして有用であることを結論付けることができた。

共同研究者・謝辞

本研究の共同研究者は、東京大学大学院工学研究科杉田研究室の杉田直彦教授である。

文 献

- 1) Rimmer J H. Health promotion for people with disabilities: the emerging paradigm shift from disability prevention to prevention of secondary conditions. *Physical therapy*, 1999, 79(5): 495-502. DOI : 10.1093/ptj/79.5.495
- 2) 星川英, 迫田辰太郎, 山野井佑介, 等. 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*, 2015, 27(6): 885-897. DOI: 10.3156/jsoft.27.885
- 3) Zheng Y, Hu X. Concurrent estimation of finger flexion and extension forces using motoneuron discharge information[J]. *IEEE transactions on biomedical engineering*, 2021, 68(5): 1638-1645. PMID: 33534701 DOI: 10.1109/TBME.2021.3056930
- 4) Hyvärinen A, Oja E. A fast fixed-point algorithm for independent component analysis[J]. *Neural computation*, 1997, 9(7): 1483-1492. DOI: 10.1162/neco.1997.9.7.1483