

電極貼り直しに対してロバストな表面筋電位による動作識別システムの研究*

Robust Identification of Forearm Motion against Electrodes Replacement based on Surface Electromyography Signal

西川 佳男 Yoshio NISHIKAWA**

舒 羽 U JYO***

香川 美仁 Yoshihito KAGAWA**

Abstract

This paper describes an identification method of forearm motions from Surface Electromyography (sEMG). When sEMG is used to control an artificial arm or other device, great care must be taken to avoid improper operations. For this reason, the motions should be estimated from the sEMG without making any mistakes. It is also necessary to estimate the motion in the shortest time after the sEMG begins occurring. In this paper, we developed a motion discrimination system that combined a wavelet transform and a convolutional neural network (CNN) and determined forearm motions by CNN output. The required parameters for the system were experimentally determined. We carried out identification experiments of three motions such as "grasping", "flexing" and "turning" by sEMG, and demonstrated the accurate identification of these motions without mistakes. After that, the effects of electrode replacement and time lapse after attachment on the identification accuracy were investigated. It was exemplified that the proposed motion identification system had robustness to sEMG changes due to the above factors.

1. 緒言

筋肉が収縮する際に計測可能な表面筋電位 (Surface Electromyography, 以降sEMGと記す) は、電動義手やパワーアシスト装置などの制御用信号として期待されている。ところが、計測できる電圧信号には複数の筋肉のsEMGが重畳する上にアンプの高いゲインにより無視できない雑音が入るため、sEMGの利用には取得データの処理と解析が重要なテーマとなる。sEMGを筋の収縮開始および収縮中を示す情報として利用する研究¹⁾はあるが、人体動作の誘因であるsEMGを十分に活用しているとは言えない。sEMGと人体動作との関係を1対1に対応付け、運動の種類や速度、力まで関連付けることができれば極めて有用である。このような視点に立ち、粕谷²⁾らは、sEMGの時系列データからその時に生じている実際の動作を高精度に推定する手法を提案した。立ち上がり時のsEMGを利用することによって高速な識別も可能としている。しかし、動作の誤識別については言及していない。sEMGを義手などの福祉機器の制御に供するには、識別精度、反応速度の向上に加えて、機器が誤作動しない安全性が必要である。このような視点から筆者らは、立ち上がり時のsEMGによる高速動作識別に加え、誤識別しないシステムの構築を目的として、「不明な動作」という出力を加えたシステムを提案している³⁾。

本研究では、筆者らが提案するシステムを、電極貼付後の時間経過や電極の貼り直しによるsEMGの変化に対しても動作の誤識別がないように再構築することを目的とする。なお、一般にsEMGには、誘導コードが電極を引っ張ることによって、電極内のゲルの変形に伴う基線の揺れや皮膚と電極表面の擦れに伴う雑音が入ることがあるが、これらのアーティファクトのみを完全に除去することは困難な上に、システム

を実用に供する際これらの混入は避けられない。そこで本研究では、アーティファクトも含めてsEMGとして扱うこととする。

2. 識別対象動作と動作時sEMGの抽出方法

2.1 動作とsEMG取得位置

図1(a)~(c)に、本研究で対象とする人体動作、図1(d)に、sEMG取得用の電極貼付位置を示す。対象動作は、「手を握る」、「手首を屈曲する」、「腕を回内する」の3動作

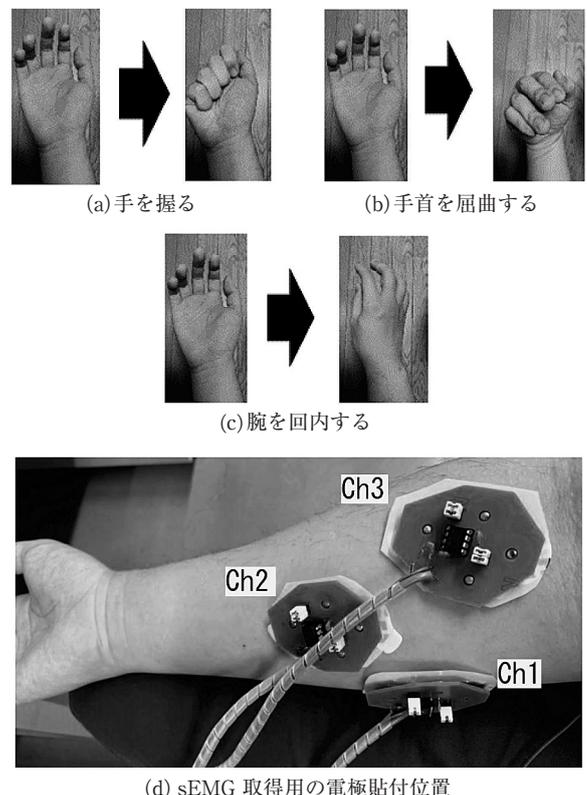


図1 識別対象動作と表面筋電位 (sEMG) 取得位置

* 原稿受付 2020年11月5日

** 拓殖大学工学部

*** モリカトロン (株)

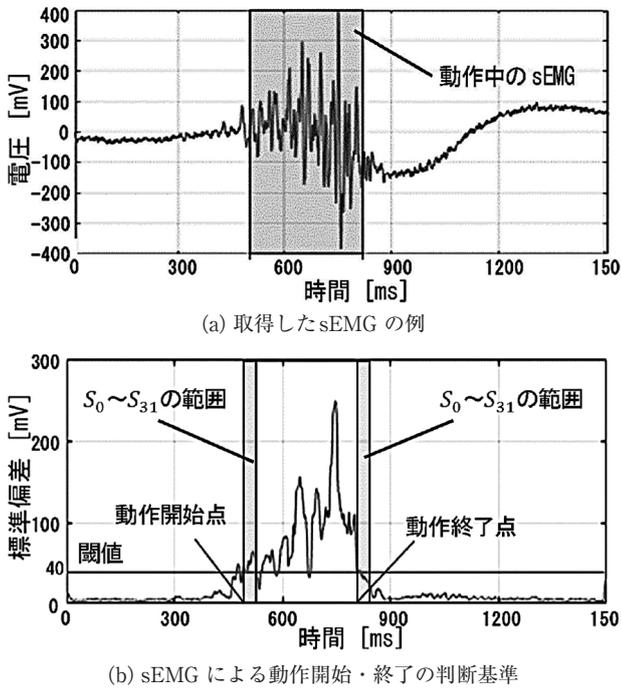


図2 前腕動作中のsEMG 取得方法

である。電極は各動作時に主に収縮する筋の上部3か所に貼付した(図1(d)中のCh1~Ch3)。各計測位置には19×36mmのディスク電極対を10mm離して貼付し、増幅率約1010倍、カットオフ周波数1kHzでローパスフィルタをかけ、サンプリング周波数10kHzでトリガをかけずに連続取得した。

2.2 前腕動作中sEMGの抽出

取得したsEMGには、図2(a)に示すように、前腕動作中の電圧と非動作時の電圧が含まれる。この図には、アーティファクトの影響の1つである基線の揺れが見られる。このデータから標準偏差を利用して動作中のsEMGを抽出する。20ms分(200個)のsEMGを1グループとして、+1msずつ時間をずらしながら各グループの標準偏差を計算し、その値が32回連続して40mV以上となるとき最初の時間を動作開始時刻、32回連続して40mV未満となる最初の時間を動作終了時刻とした。このようにしてsEMGから前腕動作の開始と終了時刻を調べた一例を図2(b)に示す。抽出した前腕動作中のsEMGの信号長は、同じ動作であっても計測毎に異なる。

3. 前腕動作識別システム

3.1 前腕動作識別システムの概要

sEMGは前腕動作が生じる約100ms前から筋肉収縮が終了するまで発生するが、その大きさや周波数と実際の動作との関係は、動作の速さや力の入れ具合など様々な要因によって大きく変化する。すなわちsEMGと実際の動作の間には強

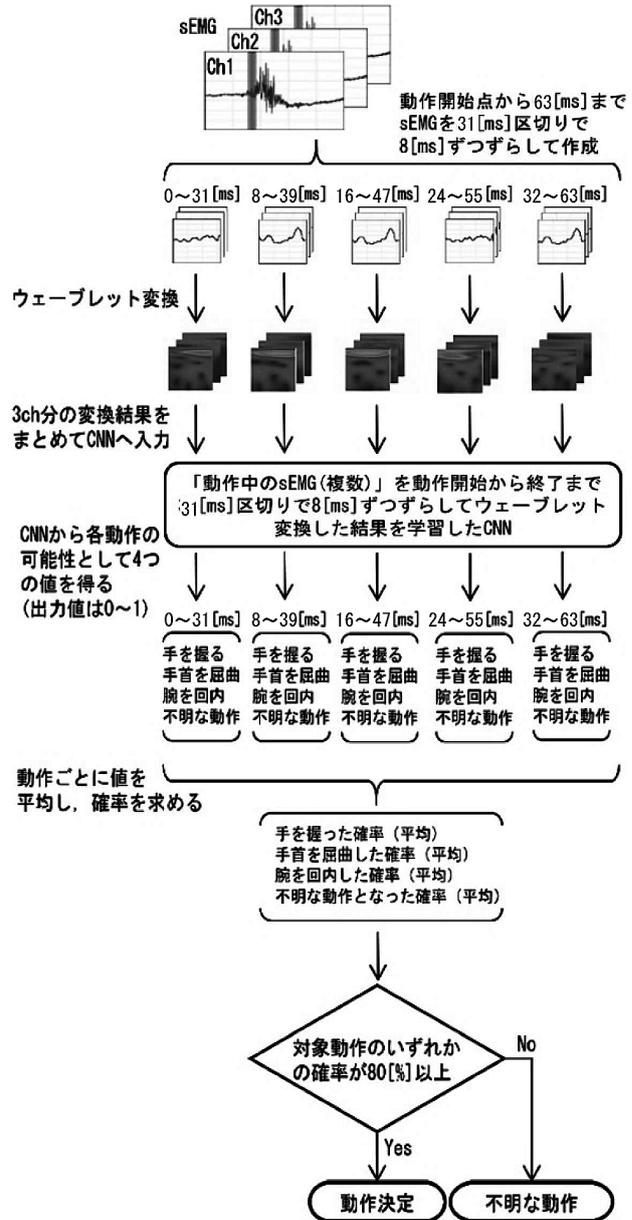


図3 提案するシステム

い非線形性を有し、同じ動作を行ったつもりでも同じsEMGが得られることはほぼないため、電圧の大きさと変化のみを特徴量として動作推定するのは困難である。そこで本研究では周波数特性の変化をsEMGの特徴量として利用する。図3に本システムの概要を示す。システムは、sEMG取得部、ウェーブレット変換による特徴量抽出部、ニューラルネットワークによる動作識別部、識別結果確定部から構成される。動作開始時刻から63ms分のsEMGを3か所に貼付した電極対で取得し、0-31msのsEMGをウェーブレット変換して特徴量を求める。次に、畳み込みニューラルネットワーク(Convolutional Neural Network, 以降CNNと記す)に入力し

て、3動作（握る、屈曲、回内）および不明な動作のいずれに該当するか推定する。この操作は、このニューラルネットワークを利用してウェーブレット変換結果である画像を識別することに相当する。ここまでの操作にて、3か所で取得した0-31msのsEMGから、ウェーブレット変換とCNNによって動作推定結果を得る。次に、同様の操作を、8msずつ時間をずらしたsEMG（8-39ms, 16-47ms, 24-55ms, 32-63ms）に対して繰り返し、それぞれ動作推定結果を得る。最後に、上述5回の推定結果の平均値が0.8以上（最大値1.0）である動作について、その最大値を与える動作を識別結果とする。0.8を超える動作がない場合には「不明な動作」となる。ここで、63msのsEMGを対象として31msずつ分割してウェーブレット変換するのは、学習の収束と推定速度向上のためである⁴⁾が、データ長31msのデータをウェーブレット変換しているため、基線の揺れのような低周波信号については、一周期に満たない信号を解析することとなる。そのために生じる実動作とは無関係なアーティファクトによるウェーブレット変換結果への影響も含めて動作の特徴量と見なし、動作推定を試みる。このようにアーティファクトの影響も特徴量の一部と見なすのは、電極を貼り直さない限り類似の影響が混入するとの仮定に基づいているが、この影響への精査は今後の課題である。

3.2 ウェーブレット変換

本研究では式(1)のモルレーウェーブレット ψ を用いる⁵⁾。

$$\psi\left(\frac{t-b}{a}\right) = \pi^{-\frac{1}{4}} \left(e^{i\omega_0\left(\frac{t-b}{a}\right)} - e^{-\frac{\omega_0^2}{2}\left(\frac{t-b}{a}\right)^2} \right) e^{-\frac{1}{2}\left(\frac{t-b}{a}\right)^2} \quad \dots (1)$$

ここで、 t は時間、 a はウェーブレットの窓幅を決定する定数、 b はウェーブレットの中心位置を決定する定数、 ω_0 はウェーブレットの中心周波数 $f_0=0.849\text{Hz}$ とする中心角周波数である。

動作中のsEMGを $x(t)$ とするとウェーブレット変換は式(2)により行う。解析周波数 f_a は式(3)である。

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad \dots (2)$$

$$f_a = \frac{f_0}{a} \quad \dots (3)$$

なお、解析周波数を20Hz から2Hz刻みで128ライン、274Hzまでとなるように式(3)の a を変更し、モルレーウェーブレット ψ の中心位置を0sから1ms刻みで32ライン、31msまで移動するように b を変更する。ウェーブレット変換は、31ms分の $x(t)$ に対して式(2)で行い、このとき、 ψ は0~31ms間でのみで値を持つものとする。そして、次式で得る大きさを求める。

表1 ResNet-18 を用いて作成したCNN構成

Layer Name	Output Size	ResNet-18
input	128 X 32 X 3	
conv1	64 X 32 X 64	7 × 7, 64, stride (2X1)
conv2_x	32 X 16 X 64	3 × 3 max pool, stride (2X2) $\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$
conv3_x	16 X 8 X 128	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$
conv4_x	8 X 4 X 256	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$
conv5_x	4 X 2 X 512	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$
average pool	1 X 1 X 512	4 X 2 average pool
fully connected	4	512 × 4 fully connections
softmax	4	

$$|W(a, b)| = \sqrt{(W_R)^2 + (W_I)^2} \quad \dots (4)$$

ここに、 W_R は $W(a, b)$ の実部、 W_I は $W(a, b)$ の虚部である。

3.3 畳み込みニューラルネットワーク (CNN)

CNNの層増加による性能悪化を対策したResidual Network (ResNet)⁶⁾を利用し、表1に示す形で“conv1”から“fully connected”までが18層となるResNet-18を用いる。

“input layer”はCNNの入力層である。ここではデータを正規化するのが一般的であるが、同じ動作を行っても速さや力によってsEMGの大きさもピーク間の関係も変化する。そこで、式(4)の最大値で正規化したのでは、実動作の情報の一部を失うことになるため、正規化の代わりに式(4)の自然対数を取ってCNNの入力とする。この処理により、4096個 (=128 × 32) の要素を持つ入力を得る。以後、これを入力セットと呼ぶ。

出力層である“softmax layer”では、「手を握る」「手首を屈曲する」「腕を回内する」「不明な動作」それぞれについて0~1の実数を出力する。この数値が1に近いほど、その動作である可能性が高いことを示している。

4. CNNの学習

4.1 学習データ

健康な成人男性1名の右前腕から、3動作のsEMGを約320回ずつ取得した。これらのデータを2.2節の方法で動作時と非動作時に分類し、各100動作分を実験用、残りを学習用データとした。学習用データは、各動作時データを「3動作」用に、非動作時データを「不明な動作」用にした。ここで、非

表2 動作識別結果

識別結果		正しく識別 [%]	誤識別 [%]	不明な動作 [%]
入力信号	握る	92	0	8
	屈曲	83	0	17
	回内	87	1	12

動作時データを「不明な動作」学習用とするのは、アーティファクトのようなデータの混入による誤識別への影響を軽減しようとしたためである。

全sEMGの0~31ms(31ms間)の入力セットを第1グループとして、8msずつ時間をずらしながら、動作中のsEMGが終了するまで順次31ms間の入力セットを作り、第2、第3…グループとする。同じ動作でもsEMG長によって作成できるグループ数は異なる。これらのグループから、「手を握る」「手首を屈曲する」動作の学習データには、各動作のグループから400入力セットずつランダムに合計2400入力セットずつ選び、「腕を回内する」動作用には、sEMG長が短いため、この動作の第1、第2グループおよびその他から800セットずつ計2400入力セット、「不明な動作」用にはこの動作の第1~3グループおよびその他から600セット計2400入力セットをランダムに選んだ。また、学習時の出力データは、3動作と「不明な動作」に該当する時を1、それ以外を0とした。

4.2 学習の検証

学習の検証には10分割交差検証を用いた。これは、学習用データを10グループにわけ(A, B, C, …, Jグループとする)、Aグループをテストデータ、残りを訓練データとして、訓練データで学習し、テストデータAを入力してその正答率を求める。これを1回の学習として、テストデータ、訓練データを変えながら同様の学習を繰り返していく方法である。Jグループをテストデータ、残りを訓練データとした学習で1学習サイクルを終える。本研究ではこのサイクルを、どのグループをテストデータとしても95%以上の正解率が得られるまで繰り返すこととして行った結果、どのグループをテストデータとしても100%の正答率を得た。

5. 前腕動作識別システムの実験検証

5.1 動作推定結果と考察

これまで述べてきたシステムを、学習に使っていない各動作100回、計300動作分のsEMGを用いて検証した。動作識別結果を表2に示す。83%以上の高確率で正しく識別でき、誤識別も「腕を回内する」動作のみ1%という結果となった。

ここで生じる1%の誤識別は、システムの反応速度を上げるために、3.1節で述べたように、動作開始時刻から63msのみのsEMGで識別しているために生じていると考えられる。

表3 動作候補連続回数と動作識別結果

		正しく識別 [%]				誤識別 [%]			
同じ動作が連続して候補となった回数		2	3	4	5	2	3	4	5
入力信号	握る	97	97	97	97	1	1	1	0
	屈曲	93	93	92	92	0	0	0	0
	回内	88	86	81	73	0	0	0	0

表4 「動作候補」連続5回を条件とした場合の推定時間

入力信号	sEMG全体(平均) [ms]	動作決定に要する時間(平均) [ms]	動作決定(最小) [ms]
握る	237	100	96
屈曲	226	104	96
回内	145	100	96

表5 sEMG(全体)に対する識別に用いたsEMGの割合

入力信号	平均 [%]	最短 [%]	最長 [%]
握る	45	22	95
屈曲	47	20	92
回内	62	29	100

この間のsEMGは実際の前腕動作が生じる前の信号(実際の動作が生じる100ms程前からsEMGが発生すると言われていた)であることから、これを入力したCNN出力が推定の度に変化するの、識別結果確定部でこれを補正できないと考えられる。

5.2 動作識別結果の変化を考慮した識別法と考察

前節の誤識別の一因でもあるCNN出力の変化は、電極を貼り直した際にも生じると予測できるため、識別結果確定部におけるCNN出力の観察時間を、CNN出力が安定するまで延長することとする。

はじめの0~63msで得られる5つのCNN出力を「第1動作候補群」とし、sEMG取得時間を8ms延長して8~71msの63ms分のsEMGで「第2動作候補群」を得る。このように8ms単位で時間を延長しながらsEMG取得と動作識別を繰り返し、「動作候補群」内の各動作候補が一定の条件を満たしたとき、その動作を識別結果とする。ここで、CNN出力の「不明な動作」は「動作候補群」に加え、sEMGの終了時刻まで動作を特定できない場合にのみ「不明な動作」と決定することとする。

「動作候補群」内の動作候補の連続回数と識別正答率の関係を調べる。使用するデータは5.1節の300動作分のsEMG(各100動作)である。表3に、連続して「動作候補」となることを動作識別条件としたときの結果を示す。識別結果を出す

表6 電極貼り直し・時間経過後の識別結果

識別結果		正しく識別 [%]	誤識別 [%]	不明な動作 [%]
同じ動作が連続して候補となった回数		5	5	5
入力信号	握る	29.8	8.9	61.3
	屈曲	83.3	0.0	16.7
	回内	49.8	0.0	50.2

までに連続して「動作候補」となる回数を増やすと、正しく識別できる確率が下がるものの、連続回数を5としたとき誤識別が0%となった。この結果より、動作識別条件を「5回連続で動作候補になること」とする。また、この識別結果を得るまでに要する時間を表4に示す。各動作の平均sEMG長は237ms（握る）、226ms（屈曲）、145ms（回内）であり、識別結果を得るまでに要した時間はどの動作も平均100ms程度、最小96ms（64ms+8ms×4）となった。実動作が生じる前に動作識別結果を得ている場合を実時間ということとして、このシステムの実時間性について検討するために、動作1回分のsEMG（全体）に対する識別に用いたsEMG長の割合を表5に示す。このように比を考えたのは、一般に、実動作の100ms程度前にsEMGが発生すると言われるが、表4から分かるように、「回内」動作ではsEMG全体が平均145msであるので、動作開始前のsEMGは100msより短いと考えるのが妥当であるからである。

表5より、「腕を回内する」では、動作決定に必要なsEMG長の平均が全体の60%を超えているので、この動作ではシステムの実時間性が問題になると予想できる。なお、各動作の最短は20~30%であり短時間で動作を識別できていると考えられるが、最長である92~100%となるような場合には、手や腕を動かし終わってから識別結果が出ることになる。

以上より、本実験において、誤識別の無い3動作識別が可能であることが分かった。一方で、実時間性と誤識別とはトレードオフの関係にあるといえる。

6. 電極の貼り直しに対するロバスト性の検討

6.1 電極貼り直し後の識別実験と結果

電極の貼り直しと電極貼付後の時間経過の識別率への影響を検討する。電極は同じものを使用して各動作500回ずつデータを取り直し、取得データの標準偏差の検討により動作時のsEMGを抽出し、「手を握る」460回、「手首を屈曲する」466回、「腕を回内する」436回分を取得した。このすべてのデータを、表3を得たシステムで識別した結果を表6に示す。表3の「連続して候補となった回数5」の結果と比較すると、正しく識別した割合が、30%~80%と極端に低くなっている。しかしながら、誤識別は「握る」で8.9%（40回/460回）、そ

表7 極貼り直し・時間経過後の識別結果（追加学習後の結果）

識別結果		正しく識別 [%]	誤識別 [%]	不明な動作 [%]
同じ動作が連続して候補となった回数		5	5	5
入力信号	握る	78.1	0.0	21.7
	屈曲	82.2	0.0	17.8
	回内	50.0	0.0	50.0

他の動作は誤識別0%であることから、CNNの出力変化を考慮して、動作識別条件を「5回連続で動作候補になること」とした効果が見られていると考えられる。

6.2 再学習と考察

前節の識別実験で使用したsEMGの一部（動作時と非動作時sEMGの1回目から100回分）を用いて再学習してCNNの改善を図り、残りのデータで再度識別実験を行った。学習方法は4章の通りである。表7に識別結果を示す。「手を握る」動作で50%弱識別率が向上して78.1%、その他の動作ではほぼ変化なしという結果となった。いずれも誤識別は0%である。また、識別結果を得るまでに要する時間が、動作識別条件に比例するため、最短で96ms必要である点は変わらない。

以上より、CNNの出力を識別候補とした本動作識別システムは、電極の貼り直しとそれに伴う時間経過があっても誤識別しないシステムであることが例証された。この結果には、追加学習が必要であるが、本学習に比して非常に低コストである。一方で、異なる条件での効果を保証するために実験を重ねる必要がある。また、誤識別を排除するために動作識別条件を厳しくしたため、実時間性の課題は無視できない。これは義手等の機器を制御する際に、動かそうとする意志と実際の機器動作間でのタイムラグを引き起こすので、使用時の違和感や使いにくさ、それに伴う誤動作などに対する考慮が必要である。

7. 結 言

義手やロボットアーム等をsEMGで制御可能なシステムを開発するために、右手前腕の3ヶ所で同時に取得したsEMGから、「手を握る」「手首を屈曲する」「腕を回内する」の3動作を誤りなく識別可能な動作識別法を構築するために、電極貼り直しおよび貼付後の時間経過によるsEMG変化に対するロバスト性を検証した。得られた結果は次の通りである。

- (1) ウェーブレット変換によりsEMGの特徴を画像として捉え、これをCNNで解析してsEMGに対する動作候補を上げ、この変化を考慮して、動作推定するシステムを構築した。
- (2) 健常な成人男性の前腕3動作（「手を握る」「手首を屈曲する」「腕を回内する」）時のsEMGを取得し、構築したシス

テムで動作識別実験を行った。CNNで連続5回動作候補となった動作を識別結果とすることで、誤識別なく、73%～97%の精度で正しく動作を推定することが可能であった。

- (3) 電極貼り直しとそれに伴う電極貼付後の時間経過による動作識別率への影響について検討し、本実験の範囲において、追加学習により、これらの要因によるsEMGの変化があっても誤識別しないことから、誤識別へのロバスト性を示した。一方で、追加学習が必要なこと、異なる条件での効果の検討などの課題がある。

引用文献

- 1) 石井峰雄, 山本圭治郎, 兵頭和人: 完全独立型パワーアシストスーツの開発 (機構の改良と実用可能性). 日本機械学会論文集 (C編). 2006 ; vol.72 No.715 : 175-182.
- 2) 粕谷昌宏, 加藤龍, 横井浩史: 時系列情報を用いた筋電パターン識別精度向上フィルタの提案. 生体医工学. 2015; vol.53 No.4 : 217-224.
- 3) 西川佳男, 舒羽: 前腕の表面筋電位から動作を誤推定しないための識別システムの構築 (義手などの機器操作のためのシステム研究). 日本ヒューマンケア・ネットワーク学会誌. 2020 ; vol.18 No.1 : 82-89.
- 4) Yoshio Nishikawa, Yoshihito Kagawa, Jun Kurabayashi: High Accurate Discrimination Method of Forearm Motions from Surface Electromyogram and its Condition. Journal of Advanced Computational Intelligence and Intelligent Informatics. 2011 ; vol15, No.5, 545-553
- 5) 山田英司, 加藤浩, 宮本賢作・他: ウェーブレット変換を用いた等速性運動中の筋電図周波数解析. 理学療法学. 2003; vol.30 No.7 : 391-396.
- 6) K. Simonyan, A. Zisserma : Very deep convolutional networks for large-scale image recognition. ICLR. 2014 ; arXiv : 1409.1556.