

不特定多数対象に対応可能な sEMG によるハンドジェスチャの識別手法

A Hand Gesture recognition Method by sEMG Applicable to Many and Unspecified Users

伊東 和輝[†] 田村 仁[†]
Kazuki Itoh Hitoshi Tamura

1. はじめに

ハンドジェスチャは、人間のコミュニケーション手段として発話や顔の表情とともにボディランゲージの一部として自然に用いられ、また手話として体系化されて利用されることもある。このため、電子機器やロボットなどへの自然なインタフェースとして着目されることも多い。

ハンドジェスチャを機械が認識するためには、カメラのような撮像デバイスや深度センサを用いたコンピュータビジョン的な技法を用いて手指形状や動作を認識する方式とセンサや器具を手指に装着して手指の形状や 3 次元加速度などを取得し、それを用いてハンドジェスチャを識別する方式に大別される。前者ではカメラや深度センサなどの外部センサを必要とし、撮影範囲や有効距離など認識させるために対象の位置や角度に制限が課されることが多い。また後者の場合には手指や上腕などに加速度や変位を取得するためのセンサなどを装着するため、人間の動作に制限を課すことや装着時の違和感が問題となる。また、いずれの方式にせよ、実際に使用するにあたり、撮影環境や個人に合わせた調整が必要となる。両方式ともこれまで極めて多数の様々な提案がある。これら古典的な手法に関しては文献[1]にまとめられている。これらセンサやカメラから得られた情報を用いて、隠れマルコフモデル(Hidden Markov Model; HMM)や有限状態機械(Finite State Machine; FSM)や主成分分析(Principal Component Analysis; PCA)などの手段によりジェスチャの種類を分類する方法がこれまで一般的であった。

また、近年発展した機械学習手法により、分類器の性能が劇的に向上し、クラス識別問題で多数の成果を挙げている。ハンドジェスチャの識別に対しては、上腕で測定した表面筋電信号(surface Electromyogram; sEMG)に機械学習を応用した例が最近多く見受けられる。

本論文で着目するのは、着脱が容易な市販の sEMG センサを用いて取得した sEMG を深層学習手法により分類し、ハンドジェスチャを識別する手法である。使用するセンサは Talmic Labs(現 North)製の Myo Gesture Control ArmBand(以下 Myo)であり、これは 8 個の sEMG センサが腕輪状に連結されている(図 1)。簡便に前腕に着脱可能であり、取得した 8 つの sEMG は Bluetooth 接続により PC などの制御機器に送信できる。また、3 軸加速度センサや 3 軸ジャイロスコップを搭載しており、重さは 93g 程度、センサの厚みは 11mm であることから VR や AR の様な直接的な操作を行い、デバイスの装着感が重要視される分野においても適しているデバイスであると考えられる。



図 1 Myo Gesture Control ArmBand

このような簡易センサを使用するならば、従来手法で必要となるカメラの設置、あるいは手指に装着する装置の調整や有線接続などが不要かつ装着時の違和感が少ない、より自然なインタフェースとして普及が見込める。

ハンドジェスチャ解析などに sEMG を従来の機械学習手法、例えば手話認識に対して決定木と HMM を使用する手法[2]や、ハンドジェスチャ解析に対して決定木と k 最近傍法(k-Nearest Neighbor; k-NN)を使用する手法[3]、義手制御に PCA を用いた手法[4]、HMM とサポートベクトルマシン(Support Vector Machine; SVM)を用いた手法[5]などがある。神経回路網(Neural Network; NN)をハンドジェスチャ解析に適用する試みとしては[6]がある。

こうした sEMG のパターンをいずれかの機械学習手法で分類する手法は、静止ジェスチャだけを対象にする場合には sEMG のある瞬間のスナップショットをする単純な方式も考えられるが、一般に動的なジェスチャに対応するために一連の時系列データを取得して分類する方式に分けられる。

動的なハンドジェスチャを sEMG の時系列データに対して機械学習による分類を行う場合、一般に時系列データに適しているといわれる再帰型ニューラルネットワーク(recurrent neural network; RNN)、特に時系列データ用に拡張された LSTM(long short term memory)モデルを用いることが考えられる。

sEMG を RNN によって解析しようというアイデア自体は生体医療工学やロボット工学分野で古くから見られ、sEMG から人体各部の間接角度を推定し、あるいはモータ制御パラメータを算出することでロボット、電動義手義足やパワーアシストスーツなどの制御に応用する研究が 1990 年代から見受けられる[7][8][9][10][11]。

ハンドジェスチャ時の sEMG の時系列データに対して LSTM を適用して分類した例としては[12][13][14]がある。これらを見ると LSTM を用いた分類によって正解率が向上していることが示されている。

問題となるのは、ハンドジェスチャの識別に Myo などの簡便な sEMG センサを使用した場合に、装着時のわずかなずれに対して取得される sEMG が大きく影響を受けることである。体表面だけの筋電位を測定するセンサでは、本来

[†] 日本工業大学 Nippon Institute of Technology

複雑な3次元形状の前腕部分の筋肉の複雑な動きを検知するにはそもそも不安定である。これまで見てきた手法では、それを大量のデータを用いた機械学習手法により解決を図るものといえる。しかしその反面、大量のデータを必要とするために誰でもすぐ使える状態とすることは困難である。

sEMGを機械学習によって作成した分類器で分類する提案は多いが、使用者自身の学習データを使用して毎回分類器を学習する必要があるものが多く、学習済み分類器を不特定多数に適応可能とする観点の研究はこれまでに見受けられない。

本論文では、数名のsEMGデータを効果的なデータ拡張を施し、不特定多数に適用可能なハンドジェスチャ分類器を作成することを目的とする。

2. 想定するジェスチャと判別手法

2.1 想定するジェスチャの種類

想定するジェスチャは図2に示す6種類のジェスチャ(脱力、パー、軽く握る、強く握る、人差し指を立てる、チョキ)とする。ジェスチャで発生する筋電位から入力操作を行う事を考慮した場合、画像認識では識別が難しく、ジェスチャのsEMG特性が包含関係にあるという点からこの6種類のジェスチャで学習を行った。

また、各ジェスチャ1回分の計測時間は4秒間として計測を行い、sEMGが安定してからデータを使用するのではなく、実用性を考慮し、ジェスチャを行い始めた瞬間も含めて計測を行った。



図2 対象とするハンドジェスチャの一覧

2.2 LSTM ネットワークの構成

sEMGの学習を行う際、深層学習の統合開発環境としてSONYのNeural Network Consoleを使用した。Neural Network Consoleは学習後、定義されたモデルと学習済みパラメータを取り出すことが可能となっている為、将来的にUnityの様な開発環境上でsEMGによる入力操作の実験を行う事が可能だと考えられる。

学習に使用したLSTMは隠れ層にLSTM Blockと呼ばれる3つのゲート(Input Gate, Output Gate, Forget Gate)を持つことで時系列データに対し、高い判別性能を発揮する。LSTMの構造を図3に示し、実際に学習で使用したネットワークを図4に示す。




図3 LSTMの構造




図4 学習に使用したネットワーク

2.3 学習用データの取得方法

本研究では開発ソフトUnityを使用し、Myoから取得したsEMGデータを10ms毎にCSVファイルへ記録するシステムを作成した(図5)。取得するsEMGのデジタル値は-127～127の範囲で出力されるが、Neural Network Consoleで学習を行う為にCSVファイルへ出力する段階で-1～1の範囲となる数値へ変換を行っている。出力されたCSVファイルの例を図6に示す。



図5 Unityによる計測システム

	A	B	C	D	E	F	G	H
1	-0.03125	-0.03125	0.007813	-0.02344	-0.01563	0	-0.02344	0
2	-0.02344	0.03125	0.007813	-0.02344	-0.01563	0	-0.02344	0
3	0.007813	0.039063	-0.02344	-0.02344	-0.00781	-0.00781	0.015625	0
4	0	0.023438	-0.00781	-0.01563	0	-0.00781	0.015625	0
5	-0.04688	-0.0625	-0.04688	-0.03125	-0.01563	-0.00781	-0.02344	-0.03125
6	-0.01563	0.03125	0.015625	-0.01563	0.007813	0	-0.04688	-0.00781
7	-0.01563	0.015625	0.015625	0.03125	0.039063	-0.02344	0.046875	0.01563
8	0.039063	0.015625	0.015625	0.03125	0.039063	-0.02344	0.046875	0.01563

図6 測定したCSVファイルの例

CSV ファイルの記録では、EMG センサの番号毎(列)で保存、10ms 毎に改行して保存を行っている。列に関しては左から順番にセンサ番号 0~7(図 1 に示す番号)となっている。また、CSV ファイルへ記録した sEMG データは学習用データとして使用する為に整流波形へ変換を行い、平滑化処理も行う。

2.4 学習用データの拡張方法

本研究では計測した sEMG データに ± 0.15 のランダムノイズを加え、計測データと拡張したデータの正解率を比較し、データ拡張の有効性を検証した。また、拡張したデータには 20ms 毎に平均値を取り、平滑化処理を行う。拡張の倍率は計測データの 11 倍とし、学習を行った。図 7、図 8 に計測したデータと拡張処理を行ったデータを示す。




図 7 計測した sEMG データ




図 8 拡張処理を行った sEMG データ

3. 評価実験

3.1 装着時のズレを考慮した学習の結果

学習用データ 2,880 個を測定し、Myo を着脱せず、連続して評価用データも測定した時の正解率は 96.38% となった。そして、この学習用データを使用し、可能な限り前回と同じ位置となるように Myo を装着し直して測定したデータを評価用データとして判別を行った。結果、正解率は 35.00% となり、以上のことから装着時のズレによる影響で正解率が大幅に低下する事が確認できた。

次に装着時のズレを踏まえて 15° ずつ回転し、合計 7 つの角度で Myo を装着し直して測定した 22,680 個の学習用データで学習を行った。評価用データも Myo を装着し直して測定したものを使用した。結果、Myo の装着ズレがある状態でも正解率は 93.33% となり、このことから、数箇所では装着し、データの計測と学習を行うことで、装着時のズレに

よる正解率の低下を防ぐことが可能であると分かった。また、7 つの角度で Myo を装着し、学習用データを測定した時の評価結果を表 1 に示す。表 1 に示す正解率とは全ての推測中で正しく判別できた割合であり、適合率とは真であると推測した中で正しく判別出来た割合である。また、検出率とは真であるデータの中で真であると推測した割合であり、F 尺度とは適合率と検出率の調和平均である。

表 1 装着ズレを考慮した学習の評価結果

Accuracy(正解率)	93.33%
Precision(適合率)	94.23%
Recall(検出率)	93.33%
F-Measures(F 尺度)	93.34%

3.2 他人の sEMG でジェスチャ判別を行った結果

不特定多数の使用へ向けた sEMG の汎用化を目指す上で sEMG の個人差における正解率の変化を調べた。学習用データは上記の 22,680 個のデータを使用し、計測した被験者 3 人分のデータをそれぞれ評価用データ 60 個として判別を行った。結果、正解率の平均は 43.89% となった。判別結果を表 2 に示す。

表 2 各被験者の判別結果

	検出率(被験者A)	検出率(被験者B)	検出率(被験者C)
パー	40.00%	0.00%	70.00%
軽く握る	20.00%	20.00%	0.00%
強く握る	80.00%	50.00%	80.00%
人差し指	80.00%	60.00%	100.00%
チョキ	60.00%	0.00%	0.00%
脱力	70.00%	60.00%	0.00%
正解率(平均)	58.33%	31.67%	41.67%

強く握った時や人差し指を立てた時などジェスチャ自体に強い sEMG の特性が存在するジェスチャの場合、他人の sEMG でも判別が可能であると思われる。しかし、軽く握った時やチョキの様な特徴による判別が難しいジェスチャでは個人差による影響が大きく、正解率が著しく低下する事が分かった。図 9、10 に軽く握る、チョキのジェスチャにおける sEMG の個人差を示す。




図 9 軽く握る(左:学習用データ, 右:被験者 A)




図10 チョキ(左:学習用データ, 右:被験者 A)

3.3 ランダムノイズによるデータの拡張の結果

本研究ではデータ拡張で正解率が向上するかどうかを調べる為に15°ずつ角度を変更し、合計3箇所までMyoを装着する。そして、計測した3,240個のデータとランダムノイズを加え、このデータを11倍に拡張した35,640個のデータで学習を行った。評価用データは学習用データと同様に3箇所までMyoを装着し、計測を行った3,240個のデータを使用した。学習の結果、計測データのみでの学習では正解率が75.03%となった。そして、データ拡張を行った学習では78.48%となり、3.45%正解率が向上した。

正解率が数パーセントしか向上していない上に計測データのみで学習した方が高い検出率を示すジェスチャも存在する。その為、この結果だけではランダムノイズによるデータ拡張が有効であるとは言えない。しかし、拡張する元のデータが3,240個のみであったことを考慮するとノイズ付加によるデータ拡張はデータの処理次第で有効になる可能性があることが分かった。表3に計測データのみで学習した時と拡張したデータを用いて学習した時でのジェスチャ毎の判別精度を示す。また、表4、表5には2つの学習器による評価結果を示す。

表3 データ拡張による検出率の変化

	検出率(計測データ)	検出率(拡張データ)
パー	61.66%	50.00%
軽く握る	82.59%	77.03%
強く握る	94.07%	96.66%
人差し指	85.92%	64.81%
チョキ	31.48%	82.40%
脱力	94.44%	100.00%

表4 計測データのみでの評価結果

Accuracy(正解率)	75.03%
Precision(適合率)	77.33%
Recall(検出率)	75.03%
F-Measures(F 尺度)	74.04%

表5 拡張処理を行った時の評価結果

Accuracy(正解率)	78.48%
Precision(適合率)	80.37%
Recall(検出率)	78.48%
F-Measures(F 尺度)	78.02%

4. 考察

学習用データを測定する際、何度か角度を変更し、Myoを装着するという手法では、大幅な正解率の向上を図ることが可能だと示すことができた。これは学習時、それぞれのsEMGセンサの値だけを見て判別するのではなく、8個のsEMGセンサ全体の数値バランスから判別しようとしている為であると考えられる。同じジェスチャでもsEMGの出力値に個人差が生じるが、同じジェスチャであれば必ず共通するsEMGの出力値の動き、または、バランスが存在するはずである。今回の実験ではズレを考慮した学習器を他人に併用した際、正解率が43.89%となってしまったが、ジェスチャのsEMG特性を学習させることを踏まえると角度を変更し、測定する手法は汎用化に有効的であると思われる。

しかし、この手法だけで学習用データを集める場合、膨大な計測時間が必要となる。特に今回の実験以上に計測する角度を増やす事を考慮するとより効率的に学習を行う為、データの拡張化は必要になると考えられる。

他人のsEMGを評価用データとして使用し、装着ズレに対応した学習済みパラメータで判別を行った結果、正解率が非常に低くなった。この原因の1つとしてはジェスチャの中には出力値のバランス自体が個人差に大きく影響される場合がある為だと考えられる。例えば「チョキ」のジェスチャを行う場合、親指に全く力を入れない人もいれば、親指と薬指を重ねてそこに力を入れる人もいる。このように、取り方自体に個人差が生じるジェスチャは学習用データとしては適していないと思われる。

また、2つ目の原因として筋力による個人差の影響である。同じジェスチャでも力の入れ具合は全く異なる為である。その為、各被験者の力レベルを事前に把握し、効果的に比較が行える様に基準を合わせる処理が必要になると考えられる。具体的には力レベルを弱、中、強の三段階で分け、中のレベルを基準として計測を行う。この処理を行うことで波形の強弱が明確化され、汎用化にも繋がると考えられる。しかし、Myoの装着角度を変更して測定を行う手法と同様に学習用データの準備に負担がかかる手法でもある為、データの拡張手法は必要になってくる。

今回の実験ではsEMGセンサ毎にランダムにノイズを加えて学習を行ったが、学習済みパラメータを不特定多数対象として判別可能にする事を考慮すると今後は各センサの数値バランスから判別を行える様に8つのセンサの関係を踏まえた上でノイズを加える手法を試みるべきである。また、ランダム出力範囲を広げた場合の正解率の変化や評価用データを学習用データの計測者本人と被験者として比較し、ノイズによるデータ拡張による汎用性の変化なども実験するべきだと考えられる。

そして、ランダムノイズによるデータ拡張だけでなく、平均値を維持してノイズを加える手法やラグランジュ補間により補間した値で拡張化し、その後ノイズを加える手法なども今後、検証を行う。

5. おわりに

ハンドジェスチャは人同士のコミュニケーション手段だけでなく、電子機器やロボットを操作する手法としても注目されている。従来の認識手法ではカメラを用いたコンピュータビジョンによるものやセンサを装着するグローブ型のデバイスなどが挙げられる。また、近年では深層学習の様に機械学習手法による分類器の性能が向上していることからハンドジェスチャの sEMG を学習し、判別精度の向上を試みる研究が多く見受けられる。本研究では着脱が容易であるアームバンド型デバイスの Myo を使用し、sEMG の計測を行う。そして、再帰型ニューラルネットワークである LSTM のネットワークで学習を行い、不特定多数の被験者を対象としたハンドジェスチャの識別手法について着目し、実験を行った。

実験内容を下記に示す。

- (1) Myo の装着ズレによる判別精度の低下対策
- (2) 複数の角度から計測したデータを使用し、学習を行った分類器での汎用化
- (3) ランダムノイズによる学習用データの拡張化
これらの実験結果の要約を下記に示す。
- (A) 複数の角度から Myo を装着し、測定したデータで学習を行うことで装着ズレによる正解率低下の軽減化が可能であり、頑健性の向上が期待できると分かった。
- (B) データ拡張ではノイズを加える事でより少ない計測データから判別精度の向上が期待できると分かった。

最後に今後の課題としては弱、中、強の力レベルで分類し、計測を行うことで個人の力量差による影響の軽減化を試みる。そして、データ拡張に関してはランダムノイズだけでなく、平均値を維持した状態でノイズを加える手法やラグランジュ補間により補間した値で拡張化を行い、その後、ノイズを加える手法などで実験を行う。

参考文献

- [1] S. Mitra and T. Acharya, Gesture recognition: A survey, *IEEE Trans. Syst., Man, Cybern. C, Appl. Rev.*, 2007, Vol. 37, No. 3, pp. 311–324.
- [2] X. Zhang, X. Chen, Y. Li, V. Lantz, K. Wang, and J. Yang, A framework for hand gesture recognition based on accelerometer and EMG sensors. *IEEE Trans. Syst., Man, Cybern. A, Syst. and Humans*, 2011, Vol. 41, No. 6, p. 1064–1076.
- [3] Kuang-Yow Lian, Chun-CHieh Chiu, Yong-Jie Hong and Wen-Tsai Sung, Wearable Armband for Real Time Hand Gesture Recognition. *IEEE International Conf. Syst., Man, Cybern.*, 2017, p. 2992–2995.
- [4] G. Matrone, C. Ciprian, M. C. Carrozza and G. Magene, Two-Channel Real-Time EMG control of a Dexterous Hand Prosthesis. *Proceedings of the 5th International IEEE EMBS Conf. On Neural Eng.*, 2011, pp. 554–557.
- [5] M. Rossi, S. Benatti, E. Farella, and L. Benini, Hybrid EMG classifier based on HMM and SVM for hand gesture recognition in prosthetics, *Proc. Int. Conf. Ind. Technol.*, 2015, pp. 1700–1705.
- [6] Xilin Liu, Jacob Sacks, Milin Zhang, Andrew G. Richardson, Timothy H. Lucas, and Jan Van der Spiegel, The Virtual Trackpad: An Electromyography-Based, Wireless, Real-Time, Low-Power, Embedded Hand-Gesture-Recognition System Using an Event-Driven Artificial Neural Network, *IEEE Trans. Circuits and Sys.*, 2017, Vol. 64, No. 11, pp. 1257–1261.
- [7] 小池康晴、本多清志、平山亮、五味裕章、エリック ベイツン、川人光男, 神経回路モデルを用いた表面筋電信号からの等尺性トルクの推定. 電子情報通信学会論文誌 DII, 1993, Vol. 76, No. 6, pp. 1270–1279.
- [8] 小池康晴、川人光男: 神経回路モデルを用いた表面筋電信号からの人腕の軌道生成. 電子情報通信学会論文誌 DII, 1994, Vol. 77, No. 1, pp. 193–203.
- [9] Koike Y, Kawato M. Estimation of dynamic joint torques and trajectory formation from surface electromyography signals using a neural network model. 1995, *Biol. Cybern.* Vol. 73, No. 4, pp. 291–300.
- [10] Cheron G, Draye JP, Bourgeois M, Libert G. A dynamic neural network identification of electromyography and arm trajectory relationship during complex movements, *IEEE Trans. Biomed. Eng.* 1996, Vol. 43, No. 5, pp. 552–558.
- [11] Cheron G, Leurs F, Bengoetxea A, Draye JP, Destrée M, Dan B. A dynamic recurrent neural network for multiple muscles electromyographic mapping to elevation angles of the lower limb in human locomotion, *Journal of Neuroscience Methods*, 2003, Vol. 129, No. 2, pp. 95–104.
- [12] Yuheng Wu, Bin Zheng and Yongting Zhao, Dynamic Gesture Recognition Based on LSTM-CNN, *Chinese Automation Congress*, 2018, pp. 2446–2450.
- [13] Ali Samadani, Gated Recurrent Neural Networks for EMG-Based Hand Gesture Classification: A Comparative Study, *40th Annual International Conf. of the IEEE Engineering in Medicine and Biology Society*, 2018, pp. 1094–1097.
- [14] Fernando Quivira, Toshiaki Koike-Akino, Ye Wang and Deniz Erdogmus, Translating sEMG Signals to Continuous Hand Poses using Recurrent Neural Networks, *IEEE EMBS International Conf. on Biomedical & Health Informatics*, 2018, pp. 166–169.
- [15] G.-C. Luh, Y.-H. Ma, C.-J. Yen, and H.-A. Lin, Muscle-gesture robot hand control based on semg signals with wavelet transform features and neural network classifier, in *Machine Learning and Cybernetics (ICMLC)*, 2016 International Conference on, vol. 2. IEEE, 2016, pp. 627–632.
- [16] M. Haris, P. Chakraborty, and B. V. Rao, Emg signal based finger movement recognition for prosthetic hand control, in *Communication, Control and Intelligent Systems (CCIS)*, 2015. IEEE, 2015, pp. 194–198.
- [17] M. E. Benalcázar, A. G. Jaramillo, J. A. Zea, A. P´aez, and V. H. ´Andaluz, Hand gesture recognition using machine learning and the myo armband.
- [18] Guan-Chun, L., Heng-An, L., Yi-Hsiang, M., ChienJung, Y.: Intuitive Muscle-Gesture Based Robot Navigation Control Using Wearable Gesture Armband. In: 2015 International Conference on Machine Learning and Cybernetics (ICMLC), vol. 1, pp. 389–395. IEEE Conference Publications, (2015)
- [19] M. Hioki and H. Kawasaki, Estimation of finger joint angles from sEMG using a neural network including time delay factor and recurrent structure, *Int Scholarly Res Netw (ISRNet) Rehabil*, vol. 2012, 2012.
- [20] F. E. R. Mattioli, E. A. Lamounier, A. Cardoso, A. B. Soares, and A. O. Andrade, Classification of EMG signals using artificial neural networks for virtual hand prosthesis control, in 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Aug 2011, pp. 7254–7257.
- [21] C. Choi and J. Kim, A Real-time EMG-based Assistive Computer Interface for the Upper Limb Disabled, *Proceedings of the 2007 IEEE 10th International Conference on Rehabilitation Robotics*, 2007, pp. 459–462.
- [22] M. Arvetti, G. Gini, and M. Folgheraiter, Classification of EMG signals through wavelet analysis and neural networks for controlling an active hand prosthesis, *Proceedings of the 2007 IEEE 10th International Conference on Rehabilitation Robotics*, 2007, pp. 531–536.
- [23] V. P. Singh and D. K. Kumar, Classification of low-level finger contraction from single channel Surface EMG, 30th Annual International IEEE EMBS Conference Vancouver, 2008, pp. 2900–2903.
- [24] H. Kawashima, N. Tsujiuchi, and T. Koizumi, Hand Motion Discrimination by EMG Signals without Incorrect Discriminations that Elbow motions Cause, 30th Annual International IEEE EMBS Conference Vancouver, 2008, pp. 2103–2107.

- [25] J. U. Chu, I. Moon, and M. S. Mun, A real-time EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand, *IEEE Transactions on Biomedical Engineering*, Vol. 53, pp. 2232-2239, July. 2006.
- [26] H. Huang and C. Chen, Development of a Myoelectric Discrimination System for a Multi Degree Prosthetic Hand, *Proceeding of the 1999 IEEE, International Conference on Robotics & Automation*, Detroit, Michigan, May 1999.
- [27] K. Englehart, B. Hudgins, and P. A. Parker, "A wavelet-based continuous classification scheme for multifunction myoelectric control," *IEEE Trans. Biomed. Eng.*, vol. 48, no. 3, pp. 302-311, Mar. 2001.
- [28] D. Peleg, E. Braiman, E. Yom-Tov, and G. F. Inbar, Classification of finger activation for use in a robotic prosthesis arm, *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 10, no. 4, pp. 290-293, Dec. 2002.
- [29] Y. Yazama, M. Fukumi, Y. Mitsukura, and N. Akamatsu, Feature analysis for the EMG signals based on the class distance, in *Proc. 2003 IEEE Int. Symp. Computational Intell. Robotics Autom.*, Kobe, Japan, Jul. 2003, vol. 2, pp. 860-863.
- [30] Ryan J. Smith, F. Tenore, D. Huberdeau, R. Etienne-Cummings, and Nitish V. Thakor, Continuous Decoding of Finger Position from Surface EMG Signals for the Control of Powered Prostheses, *30th Annual International IEEE EMBS Conference Vancouver*, 2008, pp. 197-200.
- [31] Nymoen, K., Haugen, M.R., Jensenius, A.R.: MuMYOEvaluating and Exploring the MYO Armband for Musical Interaction. *NIME'15*, May 31-June 3, 2015, Louisiana State Univ., Baton Rouge, LA.
- [32] F. Tenore, A. Ramos, A. Fahmy, S. Acharya, R. Etienne-Cummings, and N. V. Thakor, Towards the control of individual fingers of a prosthetic hand using surface EMG signals, *Conf Proc IEEE Eng Med Biol Soc*, vol. 2007, pp. 6146-9, 2007.
- [33] R. Kato, T. Fujita, H. Yokoi, and T. Arai, *Adaptable EMG Prosthetic Hand using On-line Learning Method-Investigation of Mutual Adaptation between Human and Adaptable Machine*, 2006, pp. 599-604.
- [34] Ganiev, A., Shin, H.S., Lee, K.H.: Study on Virtual Control of a Robotic Arm via a Myo Armband for the Self-Manipulation of a Hand Amputee. *International Journal of Applied Engineering Research*, vol. 11, no. 2, pp. 755-782, 2016.
- [35] Nymoen, K., Haugen, M.R., Jensenius, A.R.: MuMYOEvaluating and Exploring the MYO Armband for Musical Interaction. *NIME'15*, May 31-June 3, 2015, Louisiana State Univ., Baton Rouge, LA.
- [36] Chen X, Zhang X., Multiple hand gesture recognition based on surface EMG signal[C]. *The International Conference on Bioinformatics and Biomedical Engineering*. 2007, pp. 506-509.
- [37] M Leon, JM Gutierrez, L Leija, and R Munoz. Emg pattern recognition using support vector machines classifier for myoelectric control purposes. In *Health Care Exchanges (PAHCE)*, 2011 Pan American, pages 175-178. IEEE, 2011.
- [38] G Tsenov, AH Zeghib, F Palis, N Shoylev, and V Mladenov. Neural networks for online classification of hand and finger movements using surface emg signals. In *Neural Network Applications in Electrical Engineering*, 2006. NEUREL 2006. 8th Seminar on, pages 167-171. IEEE, 2006.
- [39] Aaron J Young, Levi J Hargrove, and Todd A Kuiken. Improving myoelectric pattern recognition robustness to electrode shift by changing interelectrode distance and electrode configuration. *Biomedical Engineering*, *IEEE Transactions on*, 59(3):645-652, 2012.
- [40] U. Côté-Allard et al., Transfer Learning for sEMG Hand Gesture Recognition Using Convolutional Neural Networks, in *IEEE International Conference On Systems, Man and Cybernetics*, 2017.
- [41] U. Côté-Allard et al., Deep Learning for Electromyographic Hand Gesture Signal Classification by Leveraging Transfer Learning, 2018.
- [42] R. N. Khushaba and S. Kodagoda, Electromyogram (EMG) feature reduction using Mutual Components Analysis for multifunction prosthetic fingers control, in *International Conference on Control Automation Robotics & Vision*, 2012, pp. 1534-1539.