

不特定多数の利用者を対象とした sEMG によるハンドジェスチャの識別手法

伊東 和輝† 田村 仁†

日本工業大学 工学研究科 機械システム工学専攻†

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。

本論文で着目するのは、着脱が容易な市販の表面筋電信号(surface Electromyogram; 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軸ジャイロスコープを搭載しており、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

A Hand Gesture Recognition Method by sEMG a Subject of Many and Unspecified Users

† Kazuki Itoh, Hitoshi Tamura, Nippon Institute of Technology
Department of Mechanical Systems Engineering Major.

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[1]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[2]、義手制御に PCA を用いた手法[3]、HMM とサポートベクトルマシン(Support Vector Machine; SVM)を用いた手法[4]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[5]がある。

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。

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[6]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、装着時のわずかなズレ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、利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用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、sEMG データに対して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。これらのジェスチャを選んだ理由として、画像認識では識別が難しいという点。もしくは、2種類のジェスチャにおける sEMG 特性が包含関係にあるという点が挙げられる。

各ジェスチャ1回分の計測時間は2.56秒間として行い、-127~127の範囲で出力されたデジタル値を100Hzで測定を行う。また、sEMG が安定してからのデータを使用

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 学習用データの拡張

不特定多数の使用者へ対応可能にするには、各ジェスチャにおける sEMG の特性を学習させる必要があり、計測時間を最小限に抑えつつ、多くの sEMG データを生成する必要がある。今回はランダムノイズの加算のみを行う方法、そして、一般的に音声信号の特徴量抽出で使用されるケプストラムを活用することでスペクトル包絡を維持しつつ、微細構造にのみランダムノイズを加算する方法でデータ拡張を行い、検証した。

ケプストラムを活用したデータ拡張の処理手順を下記に示す。また、元データと拡張したデータを図3に示す。

- (1) 計測した sEMG データを高速フーリエ変換し、パワースペクトルを算出
- (2) 対数計算を行い、対数パワースペクトルを算出
- (3) 高速フーリエ逆変換を行い、ケプストラムを算出
- (4) 微細構造部分である高次のケプストラムにランダムノイズを加算
- (5) 高速フーリエ変換を行い、データ拡張後の対数パワースペクトルを算出
- (6) 対数の逆計算を行いデータ拡張したパワースペクトルを算出




図3 データ拡張(左:元のデータ, 右:拡張したデータ)

3. 評価実験

3.1 ランダムノイズの加算のみ

被験者1人から3,240回分のデータを計測し、そのデータに±12.7[mV]の範囲からランダムで数値を加算し、11倍のデータ拡張を行った。また、装着ズレによる大幅な正解率低下を防ぐため、15度ずつMyoの装着角度を変更し、合計3箇所所でデータを計測した。結果、計測データのみで学習させた場合の正解率が75.03%となり、データ拡張後の正解率が78.48%となった。データ拡張する事で総合的な正解率は向上したが、各ジェスチャの正解率では低下したのものがああり、単純にランダムノイズのみを加算する方法は有効でないと考えられる。

3.2 ケプストラムによるデータ拡張

被験者1人から3回計測(1回あたり1,260個のsEMGデータ)を行い、そのうちの1回分からケプストラムを

活用して11倍のデータ拡張を行った。また、装着時のズレが30度以内に収まる事を前提として15度ずつMyoの装着角度を変更し、合計3箇所所でデータを計測した。結果、計測3回分のデータの場合、98.21%の正解率となり、計測1回分のみのデータでは91.19%の正解率となった。そして、ケプストラムによる拡張を行ったデータでは99.28%の正解率となった(表1)。

表1 実験の判別結果

ジェスチャ	検出率(計測3回分)	検出率(計測1回分)	検出率(データ拡張)
パー	100.00%	97.14%	100.00%
軽く握る	100.00%	76.42%	100.00%
強く握る	100.00%	100.00%	99.28%
人差し指	90.71%	87.14%	97.14%
チョキ	98.57%	86.42%	99.28%
脱力	100.00%	100.00%	100.00%
正解率	98.21%	91.19%	99.28%

4. 考察

実験結果からケプストラムを活用する事で1,260回分の計測データのみで3,780回分の学習結果より高い正解率が得られると判明した。このことから、特徴量を維持しつつ、データ計測の時間短縮が可能であり、不特定多数の使用者へ対応できる有効なデータ拡張手法であると考えられる。

5. おわりに

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の計測を行った。そして、再帰型ニューラルネットワークであるLSTMを使用して学習を行い、不特定多数の被験者を前提としたハンドジェスチャ識別の実験を行った。実験結果からケプストラムの活用により、学習に有効である人工的なsEMGデータを作成する事が可能だと判明した。そして、この手法は不特定多数の使用者へ対応できる有効なデータ拡張手法であると考えられる。

参考文献

- [1] 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.
- [2] 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.
- [3] 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.
- [4] M. Rossi, S. Benatti, E. Farella, and L. Benini, Hybrid EMG classifierbased on HMM and SVM for hand gesture recognition in prosthetics, *Proc. Int. Conf. Ind. Technol.*, 2015, pp. 1700-1705.
- [5] 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.
- [6] Yuheng Wu, Bin Zheng and Yongting Zhao, Dynamic Gesture Recognition Based on LSTM-CNN, *Chinese Automation Congress*, 2018, pp.2446-2450.
- [7] M. D. Rudresh, A. S. Latha, J. Suganya, C. G. Nayana, Performance Analysis of Speech Digit Recognition using Cepstrum and Vector Quantization, *2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICEECCOT)*.