

ESNを用いた筋電位による関節トルク推定とトルク制御筋電義手の開発

公立はこだて未来大学 櫻沢 繁

1. 背景と目的

事故や病気などによる手指欠損者が利用する義手の中に、残存筋の活動情報を利用しアクチュエータを駆動する筋電義手がある。筋電義手は、多自由度かつ直感的な操作を可能とする。筋電義手に関する研究には、複数の識別器を用いるもの^[1]や特徴量として筋電位のFFTを用いるもの^[2]などが知られている。手指切断に際し、筋の委縮を防ぐため残存筋の断端を骨に固定する術式が一般的となっている^[3]。筋電義手システムで指関節トルクの推定をおこなう場合、等尺性収縮時の筋による情報から、等張性・等尺性・等速性収縮運動をデコードする必要があるため、義手システムには一般的に機械学習による制御が行われ、その制御・予測性能向上には計算資源が増大する。しかし、潤沢な計算資源を義手に搭載すると価格および重量の増加につながるため、義手に搭載するシステムは簡素かつ、生活を送るために十分な自由度を確保できるものが望ましい。

学習コストを低下する機械学習手法として、RC (reservoir computing) が知られている。RCはRNN (Recurrent Neural Network) の一種であり、中間層の結合荷重を固定し少ない計算コストで学習が可能である。そこで本研究では、RCの一種であるESN (Echo State Network) を用いることにより、低い計算コストで、等尺性収縮条件下における筋電位情報から指関節角度情報の推定をおこなうシステムの開発を目指した。

2. 材料と方法

学習に必要な筋電位情報は差動増幅回路と4次ハイパスフィルタ ($f_c = 20 \text{ Hz}$) と非反転増幅回路によって計測された。また指角度情報は曲げセンサ (MB060-N-221-A02) と非反転増幅回路で計測された。計測器からの出力はpowerlab (ADInstruments) でサンプリング (1kHz) した。計測システムを図1に示す。筋電位を計測する側の手指は運動が等尺性収縮となるよう、直径30mmの円柱を握り包帯で固定した。両手を対向させ、両手を同じ動きをするようイメージし90秒間運動している間のデータをサンプリングした。筋電位情報からESNを利用し指角度を推定した。各ノードのリーク率は0から1の範囲でランダムに決定した。ESNへの入力および教師データは、10chの筋電位情報および指角度情報とした。また各筋電位情報は、前処理として2乗し、全体が0から1になるよう正規化した。計測されたデータ (90000ステップ×10ch) を半分に分割し、前半をトレーニングデータ、後半をテストデータとした。出力重みの調整にはリッジ回帰を用いた。

開発したESNによる性能評価のため、同様のネットワーク構造を持つRNN (Recurrent Neural Network) を構築し比較をおこなった。RNNの構築には、pytorch 2.1.0を利用した。RNNにおける学習にかかる時間を短縮しESNとの比較をしやすくするため、学習のepoch数は20とした。また、RNNの学習にはGPU (NVIDIA GeForce GTX 1070 Ti) による並列演算を用いた。

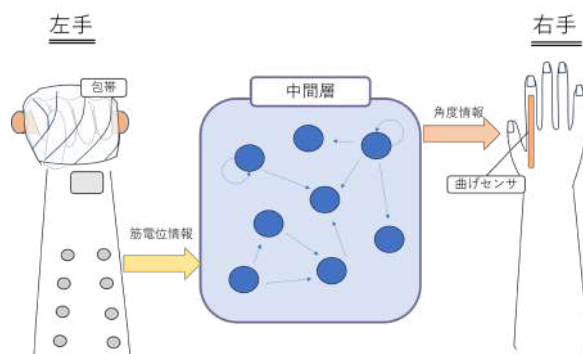


図1 実験システムの概念図

3. 結果

ESN, RNN による学習の結果をそれぞれ図 2, 図 3 に示す. グラフのグレーの部分はトレーニング用として利用されたデータであり, それ以降がテスト用データである. 出力値は, ノイズの影響を除くため 20 データずつ移動平均をとっている. また ESN, RNN でデータ (90000 ステップ×10ch) の学習にかかった時間はそれぞれ約 16 秒, 約 900 秒であった. また, RNN, ESN の予測値の結果を比較すると, RNN のほうが出力値にノイズが多く乗っている様子が見られた. RNN, ESN による予測誤差を MAE (Mean Absolute Error) で評価した結果, ESN は 0.320, RNN は 0.491 であった.




Fig.2 ESN による指関節角度時系列の学習結果. 上から母指, 示指, 中指, 環指, 小指. 青線は計測値で橙色は推定値.




Fig.3 RNN による指関節角度時系列の学習結果. 上から母指, 示指, 中指, 環指, 小指. 青線は計測値で橙色は推定値.

4. 考察

ESN による学習結果より, 各指角度推定値は実際に計測された値と一部誤差が含まれるものの, よく一致している様子が見られた. しかし環指と小指はどちらかの活動に両指とも活動していると推定される場所があった. 環指と小指の運動を担う筋が近く, また解剖的にも両指が腱によってつながっていることが原因と考えられる.

RNN と ESN の比較において, RNN はノイズが多く MAE の値は高い. ノイズの原因は設定した `epoc` 数が入出力のタイムスケールの差を学習するために十分ではなかったことと考えられる. 学習に必要な時間は `epoc` 数に比例し増大するため, `epoc` 数を増大することによる学習精度の向上は現実的ではない. また, ESN の学習時間は RNN に比べ非常に短かった. RNN の中間層の重み更新が非常に煩雑であったと考えられる.

以上の内容から, ESN のような RC による低い計算コストにより学習可能な機械学習システムは, 実際の義手に搭載するシステムとして有用であると考えられる.

5. 参考文献

- [1] Ayuko Ibe, Manabu Gouko, and Koji Ito: "Discrimination of Combined Motions for Prosthetic Hands Using Surface EMG Signals". Transactions of the Society of Instrument and Control Engineers 45.12, pp. 717–723, (Jan. 2011).
- [2] Akira HIRAIWA et al.: "EMG Recognition with a Neural Network Model for Cyber Finger Control". Transactions of the Society of Instrument and Control Engineers 30.2, pp. 216–224, (1994). doi: 10.9746/sicetr1965.30.216.
- [3] 田澤英二 and 日本義肢装具士協会: 義肢製作マニュアル. 第 2 版. 医歯薬出版, (2017)