


[研究助成 (C)]

筋電波形を用いた腕の動きに同調するパワーアシスト

2227008

研究代表者
(助成金受領者)長岡技術科学大学
大学院工学研究科5年一貫制
博士課程

田 中 太 一

[研究の目的]

■最終目標

建築・介護現場の怪我や慢性痛を防ぐアシストスーツは最大 25 kg を補助できるが、さらなる荷重に対応するには高出力化が必須である。しかし、出力向上に伴う抵抗増大が動作を阻害し、作業効率低下、身体各部への負担増加を通じて肩関節周辺での痛み増大と手先到達精度低下を招く。本研究は、これら課題を克服しつつ高出力化するため、腕動作に同調する上肢用アシストスーツを開発することを最終目標とする(図1)。

■技術的課題

運動の 50 ～ 100 ms 前にヒトの運動特徴を含んでいるためヒトの動作を予測可能な筋電を用いれば、腕に対して同調動作するアシストスーツを製作できる。ただ、実用化を妨げる2つの課題がある。

- ①筋電振幅の個人差が大きく、他人のデータで学習した機械学習モデルを使用すると 10 ～ 20% 予測精度が低下する。個人専用のモデルを得るために事前のデータ計測が必要である。

- ②筋電振幅が変動するため、学習時と異なる電極位置の予測精度が 10 ～ 20% 低下する。30 ～ 180 秒のキャリブレーションが必要である。

■研究目的

皮膚の厚さや発汗に伴う皮膚インピーダンス、筋肉量、電極位置の違いにより、筋電振幅は大きく変動する。そこで、本研究では分散正規化によって筋電振幅を揃え、筋電波形から運動を予測することで、二つの課題の解決を目指す。第一に、他者データで学習したモデルの予測精度を本人モデルに近づけること。第二に、異なる電極位置で学習・評価したモデルの予測精度を、同一電極位置で学習・評価したモデルに近づけることである。ここで、目標精度を超えれば精度が近づいたと判断し、研究目標を達成したとみなす。

[研究の内容、成果]

1. 提案手法 (分散正規化)

キャリブレーションが不要で、リアルタイムに実行できる正規化法を式(1)に示す。Sliding-window normalization (SWN) は z-score と移動窓を組み合わせた手法で移動窓内の信号の平均を 0、標準偏差を 1 にする(図2)。

$$y_{t, n+L} = \frac{x_n - m_t}{s_t} \quad (1)$$




図1 腕の動きに同調するアシストスーツの概要。

ここで、 t は離散時間番号、 n は移動窓内の番号、




図2 sliding-window normalization の概要。

L は移動窓の窓長, y は正規化した信号, x は入力信号, m_t と s_t は t^{th} での平均と標準偏差である。

2. 目標精度の計算

3章では本人のモデルの予測精度, 4章では同じ電極位置で学習と評価したモデルの予測精度を用いて式 (2) から目標精度を得た。

$$\begin{aligned} th_{\text{pfm}} &= x_l \quad (l = \lfloor v/2 - 1 \rfloor) \\ v &= F_{\text{Bin}(n, \beta)}^{-1}(1 - \gamma) \end{aligned} \quad (2)$$

ここで, th_{pfm} は目標精度, x は降順ソートされたデータ, l は許容誤差の下限番号, $F_{\text{Bin}(n, \beta)}^{-1}(1 - \gamma)$ は二項分布の累積密度逆関数, β はカバー率, γ は信頼水準である。(β, γ) = (90%, 95%) とした。

3. 他人のモデル使用による予測精度の低下

3.1. 実験

10人の被験者が右肘の短関節運動を行った。具体的には4つの終始点の内1つから他の3つの点の1つに腕を移動させるタスクである。全被験者が計360 trialsのタスクを行った。右肘の屈曲と伸展運動に関連する12 channelの筋電(2000 Hz)と、手先、肘、肩の位置データ(500 Hz)を計測した。

3.2. データ処理

筋電には前処理として3次ローパスバターワースフィルタ(200 Hz), デシメーション(2000 → 500 Hz), 3次ハイパスバターワースフィルタ(30 Hz), 正規化(SWN または正規

化無し)を順に適用した。その後、特徴抽出として mean absolute value, mean waveform length, difference root mean square, short-time Fourier transform, stationary wavelet transform の5つの特徴を抽出して、20 Hzヘデータ量を削減した。

位置データは2次零位相ローパスバターワースフィルタ(20 Hz)を適用後、位置→関節角度へ変換、関節角速度を基準に静止、屈曲、伸展のラベルを生成して、20 Hzヘデータ量を削減した。

3.3. 評価方法

●研究目標の達成条件

図3に示すように、本節では本人のデータで学習したモデル(model_OWN)と他人のデータで学習したモデル(model_OTHER)を使用した。SWN_OTHER(SWNを適用したmodel_OTHER)の予測精度がSWN_OWN(SWNを適用したmodel_OWN)とNone_OWN(正規化を適用しないmodel_OWN)の目標精度(2章で説明)を超えた時、研究目標を達成する。

●機械学習モデルの学習と評価

データは被験者ごとに50:50(180:180 trials)で学習データと評価データに分割した。

運動予測ではmodel_OWNは1人の被験者、model_OTHERは9人の被験者でモデルを学習して、1人の被験者で評価した。また、関節角度推定ではmodel_OWNは1人の被験者で学習して1人の被験者で評価し、model_OTHERは5人の被験者で学習して3人の被験者で評価した。

●パラメータ選定

SWNでは正規化と特徴抽出の窓長、正規化無し(None)では特徴抽出の窓長がパラメータと




図3 model_OWN と model_OTHER の学習と評価。

してある。正規化と特徴出の窓長を 200–500 ms 間で 100 ms 単位で変えて機械学習モデルを学習し、窓長間で最も予測性能が高いモデル同士を比較した。

●機械学習モデル

運動状態の予測では多クラスロジスティック回帰を使用して肘関節の静止、屈曲、伸展運動を予測した。また、関節角速度の推定では線形回帰を使用して、肘関節の角速度を推定した。

●多重比較

ウィルコクソン順位和検定とボンフェローニ補正を使用した。

3.4. 結果と考察

図 4a は肘関節の運動予測、図 4b は肘関節の角速度推定の model_OTHER と model_OWN の比較結果を示している。

図 4a と b より、運動予測と関節角度推定の両方で目標精度を超える予測性能を達成することができなかった。これは複数の要因が考えられる。(1) ノイズの影響：筋電は SN 比が低い信号である。本節では 30–200 Hz 外のノイズを除去できていないため、このノイズが分散推定に悪影響を与えている可能性がある。ノイズ成分を無視して筋電振幅を推定する必要がある；(2) 適切なスケーリングでない：本研究では線形スケーリングを適用した。しかし、筋電は筋活動に対する振幅の増加が非線形な信号である。そのため、非線形性を考慮した正規化が必要である；(3) 筋活動率情報の欠落：通常の筋電を用いる運動予測と関節角速度推定は、複数のセンサから得た筋電の振幅値で構成されるベクトルを用いる。しかし、SWN は短時間の窓

内の筋電の振幅を揃えており、全体的な筋電の活動情報を無視している。そのため、筋活動率を考慮した正規化法が必要である。

ただ、図 4a と b 両方で、SWN_OWN の予測性能が None_OWN より高い。この結果より、他人のモデルの予測性能を本人のモデルに近づけることには失敗したが、モデルの予測性能を向上させることに成功した。

4. 電極位置による予測精度の低下

4.1. 実験

電極位置が異なる筋電データを計測するためには電極位置を腕に対して水平方向に ± 2 cm ずらしてデータを計測した。全被験者は計 3 session の実験を行った。1 session 目は筋電振幅値が最大となる位置、2 session 目は 1 session の位置から右へ 2 cm 移動させた位置、3 session 目は 1 session の位置から左へ 2 cm 移動させた位置でデータ計測した。

各被験者は画面上に表示されたターゲットマーカを手首位置を操作して追従するタスクを行った。ターゲットマーカの軌道は躍度最小規範を基に 5 種類生成された。各被験者は 5 種類のタスクを 4 回ずつ 1 session で計 20 回行った (3 session で計 60 回)。

計測したデータは筋電と位置データである。筋電 (2000 Hz) は、腕の屈伸運動に関連する筋肉から 12 channel 分計測した。位置データ (20 Hz) は、手首、肘、肩の 3 か所計測した。

4.2. データ処理

筋電は、6 次バンドパスバターワースフィルタ (40–200 Hz)、デシメーション (2000 $\rightarrow$ 500 Hz)、正規化 (SWN または正規化無し)、絶対値化、セグメンテーション (100 ms の窓長で 50 ms ごとに信号を抽出)、最後に特徴量を 20 Hz へデシメーションした。

位置データは、位置 $\rightarrow$ 関節角度変換後、角速度と角加速度を基準に肩関節の静止、屈曲、伸展運動のラベルに変換した。




図4 被験者間の汎用性比較。破線は目標精度を示している。




図5 CNN-LSTMの概要。

4.3. 深層学習モデル

図5に示すCNN-LSTMを使用した。これはCNN、LSTM、Output、ADAの4つの層で構成されている。CNNとLSTM層は特徴抽出、Output層では運動の予測、ADA層では電極位置の予測を行う。

4.4. 比較手法

● Vanilla

通常のCNN-LSTMモデル。

● Transfer learning (TL)

学習時とは異なる電極位置データでモデルを再学習する。再学習データと評価のデータの電極位置は同じである。

● Adversarial domain adaptation (ADA)

3種類の電極位置データを使用して、かつADA層を利用してモデルを学習する。

● Mixture of multiple electrode positions (MIX)

3種類の電極位置データのみを使用してモデルを学習する。

4.5. 評価方法

● データ分割

3-fold cross validationで評価を行った。VanillaとTLは通常通り学習データを用いて学習し

た。TLの再学習には、30%のデータを評価時の電極位置の学習データを使用した。ADAとMIXの学習には、30%のデータを3種類の電極位置の学習データを使用した。

● 電極位置の組み合わせ

VanillaとTLは6通り、ADAとMIXは3通りの学習と評価の電極位置の組み合わせがある。

● 評価指標

評価指標として式(3)に示す差分分類精度を使用した。これは異なる電極位置で学習と評価したモデルの分類精度から同じ電極位置で学習と評価したモデルの分類精度を引くことで得た。

$$y_{n,i,j} = x_{n,i,j} - x_{n,i,j}^{\text{BASELINE}} \quad (3)$$

ここで、 n は正規化法、 i は学習の電極位置、 j は評価の電極位置、 y は差分分類精度、 x は n 正規化を適用して i 電極で学習して j 電極で評価したモデルの分類精度である。

● 研究目標の達成条件

SWNを適用したVanilla CNN-LSTM (SWN of Vanilla)において、異なる電極位置で学習と評価したモデルの差分分類精度が同じ電極位置で学習と評価したモデルの差分分類精度から得た目標精度(2章で説明)を超えた時、研究目標を達成する。

● パラメータ選定

SWNでは正規化と特徴抽出の窓長、正規化無し(None)では特徴抽出の窓長がパラメータとしてある。正規化と特徴抽出の窓長を200-1000 ms間で200 ms単位で変えて機械学習モデルを学習し、窓長間で最も予測性能が高いモデル同士を比較した。

● 多重比較

ウィルコクソン順位和検定とボンフェローニ補正を使用した。

4.6. 結果と考察

図6は差分分類精度の比較結果を示している。SWN of VanillaはSWNを適用したVanillaモデルの結果であり、TL_None, ADA_None, MIX_None, Vanilla_Noneは正規化無しのTL,




図6 差分分類精度の結果。緑の破線は目標性能、黒の破線はSWN of Vanillaの差分分類精度の平均値を示している。

ADA, MIX, Vanilla モデルの結果である。

SWN of Vanilla の予測精度と目標精度を比較すると、予測精度の方が目標精度より高い。この結果より、研究目標を達成した。これは、筋電振幅を正規化によって揃えることによって、電極位置による筋電振幅の変動の影響を低減できたためだと考えられる。

しかし、SWN of Vanilla と MIX_None と比較すると MIX_None の方が予測精度が高く、SWN は最も優れた方法ではなかった。また、MIX_None と ADA_None の予測精度も目標精度を上回っている。ただ、ADA, MIX, TL と比較した SWN の利点は、複数の電極位置データでの学習と EMG デバイスを使用する前のモデルのキャリブレーション（再学習）が不要なことである。

5. まとめ

課題1：他人のモデルの予測性能を本人のモデルに近づけることには失敗したが、機械学習モデルの予測精度を向上させることに成功した。

課題2：目標精度を達成したため、異なる電極位置で学習と評価したモデルの予測精度を同じ電極位置で学習と評価したモデルに近づけることに成功した。

ただ、課題2にでも分類しか行っていないため、回帰でもモデルの予測精度を近づけられるか調べる必要がある。また、他人のモデルの予測精度を向上するために、ノイズ除去や非線形性の低減方法を考える必要がある。

[成果の発表、論文など]

■ジャーナル

1. Taichi Tanaka, Isao Nambu, Yoshiko Maruyama, and Yasuhiro Wada. Sliding-window normalization to improve the performance of machine-learning models for real-time motion prediction using electromyography. *Sensors*, 22(13): 5005, 2022
2. Taichi Tanaka, Isao Nambu, and Yasuhiro Wada. Mitigating the impact of electrode shift on classification performance in electromyography applications using sliding-window normalization. *Sensors*, 25(13): 4119, 2025

■国内学会

1. 田中太一, 南部功夫, 圓山由子, and 和田安弘. Sliding-window normalization による筋電を用いる他人のデータで学習した分類器の予測精度向上. In *Proceedings of the 2022 Annual Conference of the Robotics Society of Japan*, Tokyo, Japan, September 2022. Non-peer-reviewed, oral presentation (Japanese)