

表面筋電位を用いた手描画内容の再現の検討 A Study on Reconstructing Hand-Drawn Content Using Surface Electromyography

周子越[†] 田村仁[†] 望月典樹[†]
Ziyue Zhou Hitoshi Tamura Noriki Mochizuki

1. はじめに

創作活動は、自己表現の根源的な欲求を満たす上で不可欠である。しかし、身体的な制約により手の自由が利かない人々にとって、絵筆を握る行為さえも極めて困難である。口や足で描く代替手段は存在するものの、身体的負担が大きく、表現の自由度にも制約が伴う。

このアクセシビリティの課題に対し、本研究は、筋肉の収縮に伴う皮膚表面から計測する電気信号である表面筋電位 (sEMG) に着目する。人が手を動かそうと意図する際、大脳で生成された神経指令は、電気信号 (神経インパルス) として運動皮質から脊髄、末梢神経へと伝達され、対象となる手の筋線維に到達する。その信号を受けて神経筋接合部では神経伝達物質が放出され、筋線維に作用して活動電位が発生する。この活動電位が皮膚表面に伝達され、sEMG として観測される。この電位に応じて筋線維が収縮し、意図した手の運動が実現される[1]。つまり、sEMG を解析することで、運動の意図を捉えることが可能になる。

既存の sEMG 研究は、ジェスチャーのような静的な動作の識別に焦点を当てたものが大半を占め、本研究が目指すような、手の動作により描画内容の直接的な再現には至っていない。

以上の背景から、本研究の目的は、sEMG を用いて手の動作を推定し、新たな描画手法を提案することである。これにより、手の自由が利かない人々や新たな描画手法に興味を持つ人々に対して、より自由な創作活動を支援することが期待される。

2. 関連研究

sEMG を用いた手に関する研究で、静的なジェスチャー認識では高精度が達成されており、例えば Côté-Allard らは、一度訓練した分類器を再調整することなく 6 日間連続で使用し、7 種類のジェスチャーを平均 97.9% という精度でリアルタイムに認識し続けたことを報告している[2]。Meng らの研究では、静的ジェスチャーと動的ジェスチャーを比較し、同日内の精度は 95% を超えたものの、日ごとおよび被験者間での精度は 63% から 88% に低下した[3]。また、筋電位が実際の動作に先行する特性を活かした堀江氏の研究では、最大で 24 ミリ秒先の関節角速度を精度ほとんど落とすことなく予測できることを実証し、手と手首の動作速度を最大約 15% 前後の誤差でほぼ遅延なく推定する手法を示した[4,5,6]。

sEMG を用いた応用例の一つである筋電義手は、絵筆を握って絵を描くことも可能であるが、高性能なものも最低でも約 150 万円と高額であり[7]、その機能を十分に発揮させるには制御訓練が必要となる[8]。これに対し、本研究で提案する手法は、約 35 万円の筋電センサのみで構成され

るため比較的安価であり、制御訓練は不要である。ただし、現時点では筋電センサの再装着による誤差への対応が必要であり、使用のたびに方向筋電データの再収集が必要である。

3. 提案手法

本研究では、上下左右の 4 方向と、斜め 4 方向を加えた 8 方向へ手を動かす動作から sEMG データを収集し、深層学習により方向を推定するモデルを構築する。

自由な手描き動作時の sEMG データを設定した時間間隔で分割し、各分割区間内における手の運動方向を推定する。そして、描画時間内のすべての推定方向ベクトルを連結することで、手描きした内容の軌跡を再現する。

続いて、時間間隔、データ拡張に用いるノイズ係数、およびデータ量が再現性に与える影響についても検証する。

4. 実験方法

データ収集は著者 1 名が担当し、椅子に着席した姿勢で、机上の A4 コピー用紙にボールペンを用いて水平面上で行った。筋電センサは、スポーツセンシング社の DSP ワイヤレスを 7 台使用した。先行研究[9,10]で高精度が得られた配置方法に基づき、図 1 に示すように右手前腕の皮膚表面に一輪状に均等に装着した。サンプリング周波数は 1000Hz、PGA ゲインはデフォルト値である 6 倍に設定した。電極を設置するにあたって、良好な接触状態を確保した[11]。

図 2 に実験手順を示す。動作方向は、4 方向 (上・下・左・右) および 8 方向 (4 方向に左上・右上・右下・左下を追加) の 2 種類を設定した。身体と平行な方向を左・右方向とし、それに直交する方向を上・下方向と定義した。斜め方向は、隣接する 2 方向の中間 (例: 左上は左と上の中間) と定めた。

描画動作は、①手首の位置を保持し、手指の動きで線を描く状態 (以下、「手首位置保持」) と、②手指を動かさず、上腕と前腕を併用して線を描く状態 (以下、「上腕前腕併用」) の 2 種類に分けた。

方向推定と描画再現は、方向筋電データ、図形筋電データ、図形写真の 3 種のデータに基づいて行う。方向筋電デ




図 1 筋電センサの一輪配置と単体外観

[†] 日本工業大学, 大学院, 機械システム工学専攻 Nippon Institute of Technology, Graduate School, Mechanical System Engineering Major

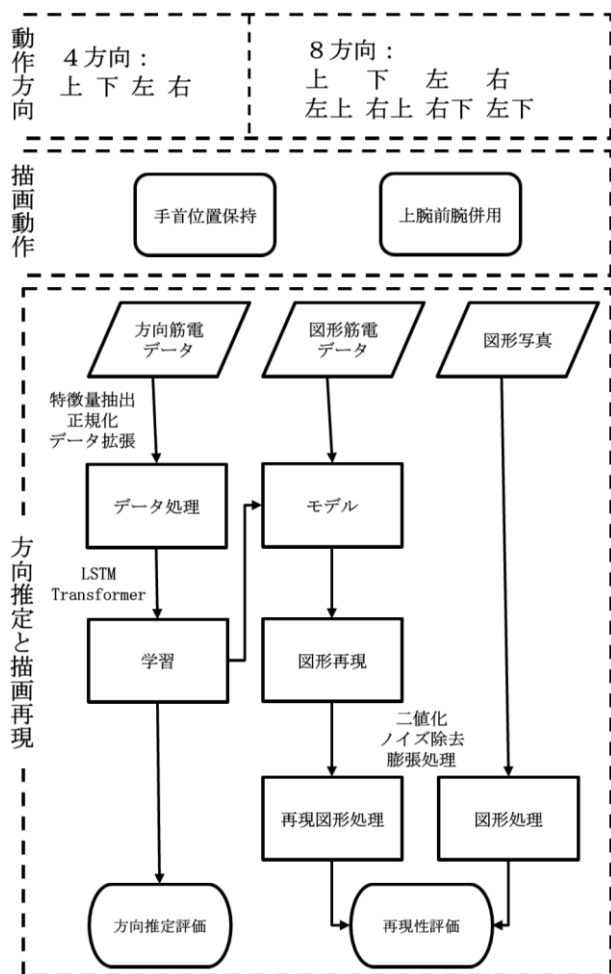


図 2 実験手順

	x_0	x_1	x_2	x_3	x_4	x_5	x_6	y
1	0.03434	0.000417	0.055999	0.019264	0.008479	0.010064	0.048275	1
2	0.022434	-0.04795	-0.08278	-0.09161	-0.03654	0.00746	0.028928	1
3	0.042897	-0.08255	-0.008	-0.12212	-0.06259	0.016762	0.030416	1
4	0.054059	-0.00107	0.062696	-0.23151	-0.10426	0.016762	0.022602	1
5	0.054431	0.00823	0.055999	-0.33383	-0.08379	-0.00259	0.030416	1
6	0.065593	-0.04832	0.002422	-0.32973	-0.0317	0.018994	0.0293	1
7	0.061129	-0.04312	0.017305	-0.35243	0.081032	0.02011	0.023347	1
8	0.030991	-0.01223	-0.00093	-0.38852	0.158793	0.004111	0.008092	1

図 3 収集した筋電データ (例)

データの収集では、事前に描かれた基準線に沿って、速度を保持して自然に直線を繰り返し描き、方向ごとに sEMG データを記録してラベル付けを行った。図形筋電データと図形写真の収集では、各図形を一定速度で十数秒かけて描き、その間の sEMG データを記録するとともに、描いた図形を撮影して保存した。この図形筋電データはモデルの学習には使用しない。収集した筋電データは、図 3 に示すようなミリボルト単位の電圧値を持つ、一行が 1/1000 秒に対応する時系列データである。

データ処理では、方向筋電データに対して特徴量抽出、正規化、ガウシアンノイズの付加によるデータ拡張を行い、設定した時間間隔で分割して深層学習モデルへの入力形式

に変換する。この分割されたデータ単位が、再現における方向ベクトルの最小単位となる。このデータセットを用いて、LSTM と Transformer モデルを学習させ、動作方向の推定性能を評価した。

図形筋電データは、学習済みモデルに入力して各時間間隔の動作方向を推定するために用いる。得られた方向を単位方向ベクトルとみなし、2次元平面上で連結して軌跡を描画し、再現図形として画像ファイルで出力する。

再現図形と元の図形写真のそれぞれに、視認性向上のため、二値化、ノイズ除去、膨張処理といった画像処理を施す。最終的に、両者を比較することで再現性を評価する。

5. データセット

表 1 に収集したデータセットの仕様を示す。すべてのデータセットにおいて、全方向および全図形の筋電データは一度の装着で連続して取得した。データセット 1 と 2 は、方向筋電データの収集時に、データセット 1 では 3 秒の描画動作と 2 秒の復帰動作、データセット 2 では 9 秒の描画動作と 1 秒の復帰動作を 1 往復として構成した。これにより、手が開始位置に戻る際の復帰動作データの除外が可能である。他のデータセットでは往復時間測定していないため、復帰動作の分離は行っていない。

表 1 各データセットの構成

番号	方向数 [個]	一方向データ収集時間 [sec]	データ量 [sec]	描画動作	復帰動作除外
1	4	60	240	①	○
2	4	60	240	②	○
3	4	120	480	①	×
4	8	120	960	①	×
5	4	120	480	②	×
6	8	120	960	②	×

備考：①手首位置保持, ②上腕前腕併用

6. 実験条件

図 4 に復帰動作の有無が方向推定の正確率に与える影響を示す。データセット 1 と 2 をそれぞれ 6 分割し、5 つを学習に、残る 1 つを評価に使用した。各条件におけるモデルの平均正確率 ± 標準偏差 (n=5) を棒グラフで示す。Wilcoxon 符号付き順位検定による統計解析の結果、いずれの条件でも有意差は認められなかった (p ≥ 0.05, ns)。手首位置保持と上腕前腕併用の両条件において、復帰動作の有無は方向推定の正確率に影響を及ぼさないと判断し、データセット 3, 4, 5, 6 の収集では、効率化のため復帰動作データを除外しなかった。

図 5 に筋電センサの再装着が方向推定の正確率に与える影響を示す。データセット 1 と 2 で学習したモデルを、データセット 3 と 5 で評価した。各条件におけるモデルの平

均正確率±標準偏差 (n=5) を棒グラフで示す. Wilcoxon 符号付き順位検定の結果, 手首位置保持 ($p < 0.01$) および上腕前腕併用 ($p < 0.001$) のいずれの条件においても, センサ再装着後に正解率の有意な低下が確認された. これは, 筋電センサの再装着が推定性能に明確な負の影響を与えることを示している. データ量を増やすことでこの影響は軽減できる可能性があるが, 本研究ではデータ量が限られるため, 影響を排除する目的で, 以降の実験ではデータセットを混用しなかった.

上記の比較実験は LSTM モデルを使用し, 時間間隔を 50 ミリ秒, ノイズ係数を 0.05 (追加ノイズの標準偏差が, 正規化された特徴量データの標準偏差の 5%に相当) に設定して実施した.




図 4 復帰動作有無の方向推定正確率グラフ




図 5 筋電センサ再装着の方向推定正確率グラフ

7. 手首位置保持下の方向推定と描画再現の結果

7.1 4 方向の方向推定と描画再現の結果

データセット 3 を使用し, 時間間隔 50 ミリ秒, ノイズ係数 0.05 で学習を行った. 図 6 に方向推定の分類レポートをヒートマップで示す. 方向推定の全体的な正確率は LSTM が 0.93, Transformer が 0.94 であり, モデル間に有意差は確認されなかった. 両モデルとも, すべての方向において適合率 (Precision), 再現率 (Recall), F1 スコアが 0.91 以上と高い値を示した.




図 6 手首位置保持下の 4 方向の方向推定分類レポートのヒートマップ



図 7 手首位置保持下の 4 方向の再現図形

図 7 に手首位置保持下の 4 方向の描画再現図形を示す. 1 行目と 2 行目は図形写真と処理後の図形写真, 3 行目と 4 行目は LSTM と Transformer による再現図形である. 描画の開始位置は 2 行目の矢印で示される. 図形は明確に再現されたが, 両モデルともに左方向の推定に弱い傾向が見られた.

7.2 8 方向の方向推定と描画再現の結果

データセット 4 を使用し, 時間間隔 50 ミリ秒, ノイズ係数 0.05 で学習を行った. 図 8 に方向推定の分類レポートをヒートマップで示す. 方向推定の全体的な正確率は LSTM が 0.90, Transformer が 0.94 であり, モデル間に有意差は確認されなかった. LSTM では, 各指標がおおむね 0.8 以上であったが, 左方向および左上方向の再現率が 0.7 とやや低かった. 一方, Transformer では, すべての指標がおおむね 0.9 以上に達した.

図 9 に手首位置保持下の 8 方向の描画再現図形を示す. 1 行目と 2 行目は図形写真と処理後の図形写真, 3 行目と 4



図 8 手首位置保持下の 8 方向の方向推定分類レポートのヒートマップ

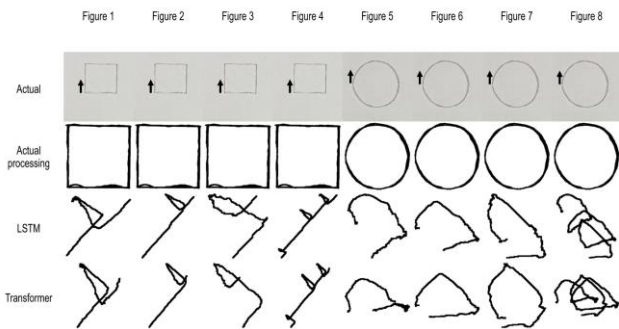


図 9 手首位置保持下の 8 方向再現図形




図 10 データセット 4 から 4 方向データのみの再現図形

行目は LSTM と Transformer による再現図形である。描画の開始位置は 2 行目の矢印で示される。Figure4 と Figure8 は、3 周描画したものであり、Figure1~3 と Figure5~7 は、その 1 周ごとの分解図である。両モデルともに、描画方向の数が少ない正方形の再現性が低く、一方で多様な方向を含む円形の再現性が比較的に高いことが確認された。

7.3 8 方向と同じデータセットを用いた 4 方向の再現

図 10 に、データセット 4 から 4 方向のデータのみを使用して手首位置保持下の描画再現図形を示す。時間間隔 50 ミリ秒、ノイズ係数 0.05 で学習を行った。両モデルともに、8 方向での再現 (図 9) と比較して、正方形の再現性が向上し、描かれた図形に近い形状となった。一方で円形の軌跡は硬くなり、再現性は 8 方向での結果より低下する傾向が示された。

8. 上腕前腕併用下の方向推定と描画再現の結果

データセット 5 と 6 を使用し、時間間隔 50 ミリ秒、ノイズ係数 0.05 で学習を行った。図 11 に LSTM モデルで学習させた場合の方向推定の分類レポートをヒートマップで示す。方向推定の全体的な正確率は 4 方向で 0.99、8 方向で 0.97 と非常に高かった。いずれの方向においても、適合率、再現率、F1 スコアは 0.94 以上であった。

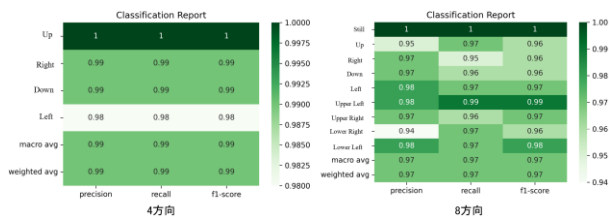


図 11 上腕前腕併用下の 4 方向と 8 方向の方向推定分類レポートのヒートマップ

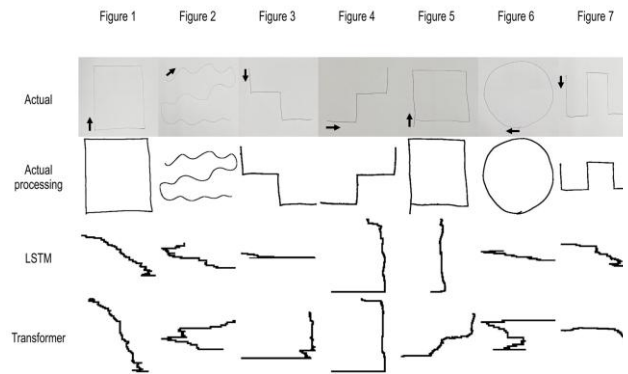


図 12 上腕前腕併用下の 4 方向の再現図形




図 13 上腕前腕併用下の 8 方向の再現図形

図 12 と図 13 に手首位置保持下の 4 方向と 8 方向の描画再現結果を示す。1 行目と 2 行目は図形写真と処理後の図形写真、3 行目と 4 行目は LSTM と Transformer による再現図形である。描画の開始位置は 2 行目の矢印で示される。図 12 では、両モデルとも Figure1 と Figure4 において部分的な形状の再現が見られるものの、その他の図形は再現されたい。図 13 では、両モデルとも Figure1, Figure4, Figure6 において部分的な再現が見られ、Figure2 はおおむね再現されたが、その他の図形については再現されたいと言えない。

9. 時間間隔とノイズ係数が再現性に与える影響

図 14 に、左側の部分は各時間間隔の再現図形で、右側の部分はガウシアンノイズでデータ拡張に用いる各ノイズ係数の再現図形を示す。データセット 3 を使用し、LSTM モデルで学習させ、時間間隔を調整する際はノイズ係数を 0.05 に、ノイズ係数を調整する際は時間間隔を 50 ミリ秒に固定した。

時間間隔が短いほど軌跡の分解能は高くなるが、短すぎると、1 区間あたりのデータ量が不足し、推定精度が低下した。逆に、時間間隔が長いほど軌跡は直線的になり、細かな動作を捉えきれず再現性が損なわれた。時間間隔が 400 ミリ秒以上になると、一部の再現図形が縦の一直線になり、学習が崩壊したと考えられた。学習が可能とみられ

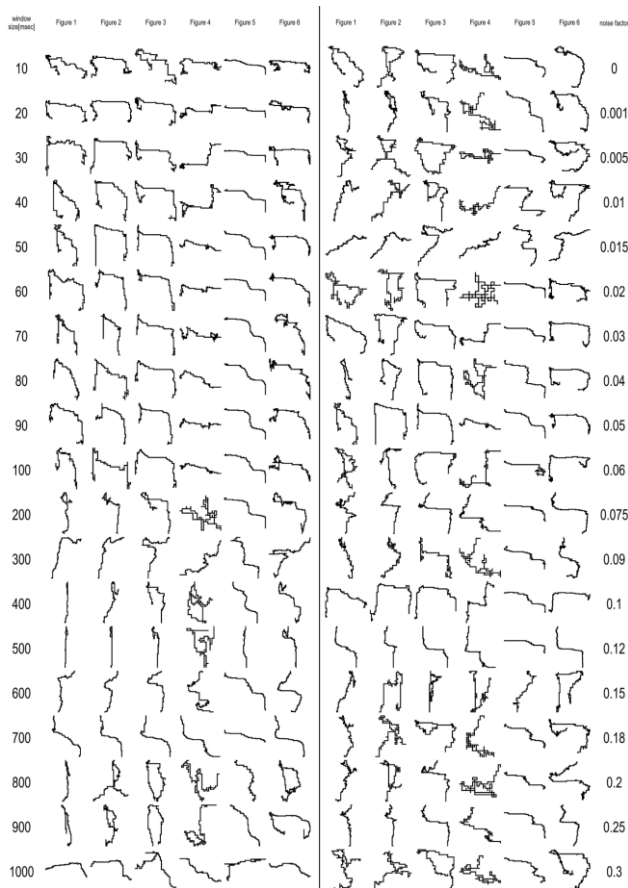


図 14 各時間間隔と各ノイズ係数再現図形

る時間間隔は 100 ミリ秒以下であり、再現性が良好な時間間隔はおおむね 30～50 ミリ秒の範囲であった。

ノイズ係数が過大な場合も再現性が低下し、同様に学習の崩壊が見られた。学習が可能とみられるノイズ係数は 0.1 以下であり、安定して良好な再現性が得られるノイズ係数は 0.03～0.05 および 0.1 の場合であった。

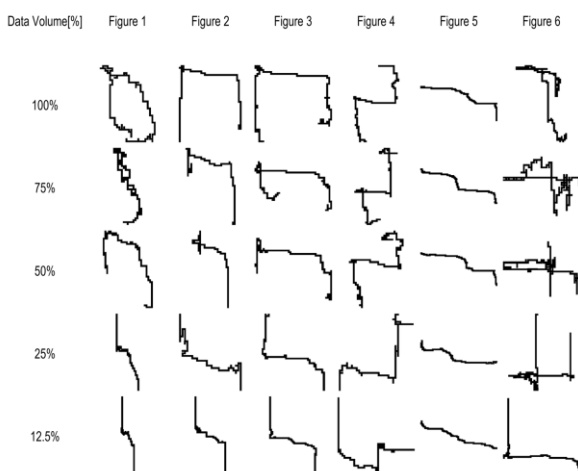


図 15 各データ量における再現図形

10. データ量が再現性に与える影響

図 15 に、データ量を減らした場合の再現性への影響を示す。データセット 3 を使用し、時間間隔 50 ミリ秒、ノイズ係数 0.05、Transformer モデルで学習を行った。データ量を減らすにつれて再現性も低下した。元のデータ量の 25% と 12.5% では、一部の再現図形が縦の一直線になり、学習が崩壊したと考えられた。このことから、本手法では一方向あたり少なくとも 60 秒のデータが必要であることが示唆された。

11. 考察

11.1 方向推定の正確率と再現図形の再現性の乖離

本研究の方向推定モデルは、いずれの条件下でも 0.90 以上という高い分類正確率を示した (図 6, 8, 11)。しかし、このモデルを用いて描画を再現した結果 (図 7, 9, 12, 13)、特に連続的な図形において、分類正確率の数値から期待されるほどの高い再現性は得られなかった。この乖離の要因は、主に二つ考えられる。

第一に、学習データと描画データの sEMG 特性の差異である。学習に用いた方向筋電データは、単一方向への反復的かつ断続的な動作から収集された、いわば「静的な方向」のデータに近い。一方、図形を描く際の動作は、複数の方向が滑らかに連続し、方向転換時には複数の筋肉群が複雑な協調・拮抗運動を行う「動的な軌跡」である。現在のモデルは、この方向転換時の過渡的な信号パターンを十分に学習できておらず、推定エラーがこの瞬間に集中し、再現性の低下を招いた可能性がある。

第二に、推定誤差の累積効果である。描画再現は、推定された方向ベクトルを時系列で逐次連結して軌跡を生成する。この方式では、ある時点での一つの小さな推定ミスが、それ以降に続くすべてのベクトルの開始位置をずらし、誤差が累積していく。しかし、今回の実験では、特に手首位置保持で、図形の全体的な形状は大半において再現可能であった。この結果は、誤差の累積が軌跡の絶対位置に与える影響と、認識可能な形状に与える影響とを区別して考察する必要があることを示唆する。軌跡全体の絶対位置に多少のずれが生じて、正方形や円といった図形固有の形状的特徴は維持されたと考えられる。加えて、十数秒という描画時間では、誤差の累積が形状そのものを完全に破綻させるまでには至らなかったことも、再現を可能にした一因であろう。

11.2 手首位置保持と上腕前腕併用の再現性の差異

手首位置保持と上腕前腕併用の再現性には、顕著な差異が観察された。上腕前腕併用での方向推定の正確率は、本研究で最も高い数値を記録した (図 11)。にもかかわらず、その描画の再現性 (図 12, 13) は手首位置保持条件 (図 7, 9) に比較して著しく低下した。

この高い正確率と低い再現性という一見矛盾した結果は、モデルの汎化性能の低さに起因すると考えられる。モデルが学習データのパターンに過学習し、未知のデータに対する汎化性能を失っていることを強く示唆する。上腕前腕を併用する動作は、手首のみの動作よりも広範な筋肉群が関与し、その協調パターンも複雑になる。学習データ (単一方向への直線運動) は、この複雑な筋活動のごく一部しか

捉えられていない。そのため、モデルは学習データにはほぼ完璧に適合するものの、より複雑な連続描画タスクに対して全く対応できず、軌跡が破綻したと推察される。

11.3.4 方向と 8 方向の再現性の比較

8 方向条件の描画再現 (図 9) では、方向数が少ない正方形の再現精度が低い一方、多様な方向を含む円形では誤推定の影響が分散され、比較的良好な再現が可能であった。

同じデータセットを用いた 4 方向条件での再現 (図 10) では、学習方向数が減ることで正方形のような単純図形の再現性は向上したが、円形の再現に必要な方向の多様性が失われ、軌跡が硬くなる傾向が見られた。

11.4 再現性に対する時間間隔・ノイズ係数の影響

時間間隔は、時間分解能と推定安定性の間のトレードオフを示した。30~50ms が、細かな動きを捉えつつ安定した推定を行うための最適な領域であることが示された。ノイズ係数によるデータ拡張は、0.03~0.05 の範囲でモデルのロバスト性を高め、再現性向上に効果的であった。

また、モデルの性能は学習データ量に強く依存し、一方向あたり少なくとも 60 秒程度のデータが必要であることが示唆された。本研究では、センサ再装着による精度低下を避けるため、一度の装着で全データを取得する必要があり、この制約が収集可能なデータ量を制限する一因となった。

11.5 再現性に対するデータ量の影響

モデルの性能は学習データ量に強く依存し、一方向あたり少なくとも 60 秒程度のデータが必要であることが示唆された。本研究では、センサ再装着による精度低下を避けるため、一度の装着で全データを取得する必要があり、この制約が収集可能なデータ量を制限する一因となった。

12. おわりに

本研究では、表面筋電位を用いた新たな描画手法を提案し、以下の点を明らかにした。

- (1) 手首位置保持条件では、円や正方形といった基本的な図形の形状を再現できることを実証した。
- (2) 方向推定モデルの分類正確率は 90%以上と高い一方、実際の描画再現性はそれほど高くないという乖離が見られた。これは、単一方向の学習データと連続的な描画動作との間の sEMG 特性の違いや、時系列での推定誤差の累積が原因と考えられた。
- (3) 上腕前腕併用条件は、方向推定の正確率自体は非常に高いものの、学習データへの過学習により描画の再現性は著しく低下した。
- (4) 描画の再現性は、sEMG データを分割する時間間隔 (最適範囲 30~50ms)、データ拡張に用いるノイズ係数 (最適範囲 0.03~0.05)、および学習データ量 (一方向あたり 60 秒以上が望ましい) に強く依存することを示した。

今後の課題として、まず、筋電センサの再装着による精度低下という実用上の問題への対応が挙げられる。現状では使用のたびに学習データを再収集する必要がある。また、上腕前腕併用条件での汎化性能の向上や、長時間の描画で深刻化する累積誤差の問題への対処も必要である。さらに、

現在は視覚的な比較に留まっている再現性評価の定量的な手法の確立や、データ収集の効率化と速度情報の付与を目的とした、IMU センサやカメラで計測した手の位置情報を教師データとする実験手法への見直しも急務である。

今後はこれらの課題に継続的に取り組むことで、誰もが身体的な制約なく、自らの意図を自由に表現できる世界の実現に貢献していく所存である。

謝辞

本研究は JSPS 科研費 JP24K15033 の助成を受けたものです。

参考文献

- [1] 村上 賢一, “筋線維伝導速度の基礎”, 理学療法歩み, Vol.20, No.1, pp.21-26, 2009.
- [2] Ulysse Côté Allard, François Nougrou, Cheikh Latyr Fall, Philippe Giguère, Clément Gosselin, François Laviolette and Benoit Gosselin, “A convolutional neural network for robotic arm guidance using sEMG based frequency-features”, IEEE, 2016.
- [3] Long Meng, Xinyu Jiang, Xiangyu Liu, Jiahao Fan, Haoran Ren, Yao Guo, Haikang Diao, Zihao Wang, Chen Chen, Chenyun Dai and Wei Chen, “User-Tailored Hand Gesture Recognition System for Wearable Prosthesis and Armband Based on Surface Electromyogram”, IEEE, 2022.
- [4] Kazumasa Horie, Atsuo Suemitsu, Masahiko Morita, “Direct Estimation of Hand Motion Speed from Surface Electromyograms Using a Selective Desensitization Neural Network”, Journal of Signal Processing, Research Institute of Signal Processing Japan, Vol.18, No.4, pp.225-228, 2014.
- [5] Tomohiro Tanno, Kazumasa Horie, Takaaki Kobayashi, Masahiko Morita, “Effect of pattern coding on pattern classification neural networks”, International Journal of Machine Learning and Computing, Vol.5, No.4, pp.339-343, 2015.
- [6] 堀江和正, 末光厚夫, 森田昌彦, “選択的不感化ニューラルネットによる表面筋電位からの手首関節角速度推定”, 電子情報通信学会論文誌, 2016.
- [7] 田中 洋平, “筋電義手・電動義手の現状と課題”, 日本義肢装具学会誌, Vol.J99-D, No.6, pp.617-629, 2018.
- [8] 溝部 二十四, 陳 隆明, 戸田 光紀, 柴田 八衣子, 岡本 真規子, 増田 章人, “最新の筋電義手の動向”, 日本義肢装具学会誌, 2020.
- [9] 伊東 和輝, 田村 仁, “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”, 第 18 回情報科学技術フォーラム講演論文集 (3), pp.271-276, 2019.
- [10] Hitoshi Tamura, Kazuteru Itoh, Yasushi Kambayashi, “A User Independent Method for Identifying Hand Gestures with sEMG”, Proceedings of the 12th International Conference on Agents and Artificial Intelligence (ICAART2020), pp.355-362, 2020.
- [11] 増田 正, “特集③人間工学のための計測手法 第 4 部: 生体電気現象その他の計測と解析 (1) - 表面筋電図の測定方法と人間工学への応用 -”, 一般社団法人日本人間工学会, 2015.