

脳波を用いた両腕の運動方向分類器の開発

Development of the motion direction classifiers for bimanual movement using electroencephalogram

加藤正起^{*1}

Masaki Kato

嶋田総太郎^{*1}

Sotaro Shimada

^{*1} 明治大学

Meiji University

Brain-machine interface (BMI) is a system that manipulates machines directly from the brain activity data. In daily life, there are many tasks that require cooperative movements of both arms, but most previous BMI employed unimanual movement, and few researches have assumed bimanual movement. The previous study in rhesus monkeys have shown that the BMI system developed for bimanual movement showed better performance than that combined two systems which were developed for left and right unimanual movements separately [Ifft 2013]. In this study, we developed classifiers based on electroencephalogram (EEG) data when bimanual or unimanual reaching movement was performed. The results showed that classifiers learned from EEG data with bimanual movement was more accurate than the classifier learned from EEG data with unimanual movement. Our results suggest that it is crucial to employ EEG data with bimanual movements to develop a BMI system for bimanual movements.

1. はじめに

ブレインマシンインターフェース (brain-machine interface : BMI) は脳活動を解析することで、脳から直接、コンピュータや機械を操作する技術である。非侵襲的な脳波 (electroencephalogram : EEG) や機能的核磁気共鳴計測 (functional magnetic resonance imaging : fMRI) による研究では、脳活動からコンピュータ画面上のカーソルの操作 [Wolpaw 1991] や車椅子の操作 [Choi 2012] を可能にする研究が行われている。

Korik (2016) は、被験者に 3 次元空間上に配置したターゲットに対して左腕を動かさずに、右腕のみでリーチング運動を行わせた。測定した EEG から回帰分析によって運動軌跡予測器を作成したところ、EEG から再構成した運動軌跡と実際の運動軌跡の間に相関 ($r = 0.7$) があり、運動軌跡を予測できたという結果を報告した。このように、機械学習を基にした回帰分析によって EEG から腕の連続的な運動軌跡を再構成した研究があるが、片腕の運動を想定した実験パラダイムになっている。一方、実生活においては、料理を作ったり、洗濯物を畳んだりと両腕の協調作業を必要とする場面は多いが、現在の多くの BMI の研究は片腕運動を想定した研究となっており、両腕の運動を想定したものは少ない。

サルを対象とした研究では、両腕運動時の脳活動というのは単純に片腕運動時の脳活動を組み合わせたものではないということが示唆されている [Rokni 2003, Steinberg 2002]。また両腕運動中は補足運動野および一次運動野などの皮質領域が特定の活動パターンを示すことが報告されている [Steinberg 2002]。アカゲザルを対象とした侵襲性の研究では両腕運動の軌跡予測において、片腕運動時の脳活動で学習した予測器を組み合わせたシステムよりも、両腕運動時の脳活動で学習し、両腕を同時に予測することの出来るシステムの方が、予測精度が良いということが示されている [Ifft 2013]。

本研究では、ヒトを対象としたシステムにおいても両腕運動を想定する必要があると考えた。ここでは、脳活動から腕の運動方向を分類する分類器を作成し、両腕運動時の脳活動で学習した分類器と片腕運動時の脳活動で学習した分類器ではどちらの方が両腕運動を想定した状況下における精度が良いか検討する。脳活動の計測には時間分解能が高い EEG を使用し、分類器には先行研究 [Liao 2014] でも利用されているカーネルサポートベクトルマシン (kernel support vector machine : kSVM) を用いた。

2. 実験方法

2.1 被験者

3 名の健康な右利きの男性 (22 ± 0.8 歳, 平均 $\pm$ 標準偏差) が実験に参加した。ただし、1 名分のデータに関しては機器の不具合により、データが破損していたため、解析から除外し、2 名分のデータで解析を行った。被験者には、事前に実験方法などの説明を行い、書面にて実験参加の同意を得た。

2.2 実験環境

図 1 のように液晶モニタ (LCD-MF276XDB-B, I-O DATA) にはゲーム開発ソフト (Unity, Unity Technologies) で作成したアバターアームが映し出されていた。このアバターアームは被験者に装着したモーションキャプチャー (Perception Neuron, Noitom Ltd.) によって被験者の動きと同期しており、被験者はアバターアームを操作することで、リーチング課題を行った。被験者は実験中、顎台に顎を置き、自分の手を見ないようにした。

実験装置を接続することによって生じる被験者の実際の手の運動と画面上のアバターアームの運動の遅延時間は、ハイスピードカメラ (EX-F1, CASIO) で測定したところ約 107ms であった。

また、EEG の計測は g.tec 社製の g.USBamp を用いて、以下の条件で行った。

- 電極数: 28ch
(Fp1, Fp2, F7, F3, Fz, F4, F8, FC3, FCz, FC4, T7, C3, C1, Cz, C2, C4, T8, CP5, CP1, CP2, CP6, P7, P3, Pz, P4, P8, O1, O2)

- 眼電 : 4ch(左右の垂直水平成分)
- サンプリング周波数 : 1200 Hz
- 帯域通過フィルタ : 1-100 Hz




図 1 実験風景

2.3 実験手順

1 トライアルの流れは図 2 に示したように、被験者がアバターアームを一辺 8 cm のセンターターゲット上に置くことでトライアルの開始とした。センターターゲットの位置は毎回同じで、直径 8 cm の円のターゲットはセンターターゲットの位置から前後左右の 15 cm 離れた場所に出現させた。ターゲットは 1 つのアバターアームに対して、4 つの配置があり、16 通りの配置はランダムに出現させた。このトライアルを行う際には両腕でトライアルを行う bimanual 条件と左腕のみでトライアルを行う unimanual left 条件、右腕のみでトライアルを行う unimanual right 条件の 3 種類の条件があった。unimanual left 条件と unimanual right 条件時のトライアルは片方のアバターアームとセンターターゲット、ターゲットのみが画面上に映り、その間は使わない腕は動かさないように被験者に指示した。この実験は 2 セッションを行い、セッション内には 4 つのブロックがあった(図 3)。1 つ目と 4 つ目のブロックは bimanual 条件で行い、2 つ目のブロックは unimanual left 条件、3 つ目のブロックは unimanual right 条件で行った。それぞれのブロックは 150 トライアルが行われた。被験者は実験が行われる前に練習として 1 回分のセッションを、脳波測定器を装着しない状態で行った。「できるだけ早く、正確にリーチング課題を行う」という教示を与えた。




図 2 1 トライアルの流れ




図 3 実験手順

3. 解析

3.1 前処理

測定した脳波データに対して、45 Hz までの低域通過フィルタをかけた。また脳波データに含まれる眼電成分を取り除くために独立成分分析を行った。眼電成分を取り除いた後、脳波データを 240 Hz までダウンサンプリングを行った。各電極のデータは Common Average Reference フィルタにかけた。その後、ウェーブレット変換によって時間-周波数解析を行い 1-3 Hz、4-7 Hz、8-11 Hz、12-17 Hz、18-27 Hz、28-40 Hz の 6 つの周波数帯内でパワー値を平均化し、トライアルごとにデータを分割した。トライアル内でデータを運動前と運動後に分割した後、時間方向に平均化することで特徴量とした。subject 1 の Fp1,Fp2,F7,F8,T8,P7,P8 と subject 2 の F7,T7,T8,P8 に関してはノイズが多く含まれていたため、解析から除外した。

3.2 機械学習

脳活動から腕の運動方向を分類するためにデータを運動前と運動後に分類する 2 クラス分類 kSVM と運動後に分類されたデータのうち前後左右の 4 方向のどのクラスに属するかを分類する 4 クラス分類 kSVM の 2 種類の kSVM を組み合わせた。作成した運動方向分類器のモデルを図 4 に示した。それぞれの kSVM には 2 種類のハイパーパラメータがあり、最適な組み合わせを求めるためにグリッドサーチ[Dong 2017]を用いた。ハイパーパラメータの組み合わせの分類精度を確かめるために 10 分割交差確認法[Dong 2017]を使用して 10 回分の平均分類精度を求めた。最も良い平均分類精度を出力したハイパーパラメータの組み合わせを用いて、全ての訓練標本で kSVM を学習し、運動分類 kSVM と方向分類 kSVM を作成した。

kSVM に学習させる脳波データとクラスラベルを変えることで 4 種類の分類器を作成した。作成した分類器を表 1 に示した。最終的な分類精度は、bimanual 条件時の脳活動のテスト標本で検証することで、どの分類器が両腕運動に対応した分類器か検証した。




図 4 運動方向分類モデル図

表 1 分類器		
分類器	学習データ	分類
bimanual left	bimanual 条件	左腕方向
bimanual right	bimanual 条件	右腕方向
unimanual left	unimanual left 条件	左腕方向
unimanual right	unimanual right 条件	右腕方向

4. 結果と考察

4.1 結果

subject 1 と subject 2 の運動分類 kSVM と方向分類 kSVM の学習時の分類精度の結果を図 5 と図 6 にそれぞれ示した。図の赤の点線はチャンスレベルを示す。ここで、運動分類 kSVM と方向分類 kSVM における学習時の分類精度とは、それぞれの

kSVM での最も高い平均分類精度のことを示す。運動分類 kSVM のチャンスレベルは 50%で、全ての運動分類 kSVM でチャンスレベルを超えていた。また、方向分類 kSVM のチャンスレベルは 25%で、全ての方向分類 kSVM でチャンスレベルを超えていた。以上のことから全ての kSVM で学習ができていると考えられる。

最終的な精度として各分類器に bimanual 条件時のテスト標本を入力したとき、入力したデータが運動前又は前後左右の 4 方向に正しく分類された精度をテスト時の分類精度として表 2 にまとめた。分類器のチャンスレベルは 31.25%で、全ての分類器でチャンスレベルを超えていた。両腕運動時の脳活動で学習した分類器の分類精度は subject 1 で $56.78 \pm 0.71\%$ (平均 $\pm$ 標準偏差), subject 2 で $57.21 \pm 0.45\%$ だった。片腕運動時の脳活動で学習した分類器の分類精度は subject 1 で $46.97 \pm 1.64\%$, subject 2 で $49.78 \pm 0.23\%$ だった。以上のことからテスト時の分類精度は、両腕運動時の脳活動で学習したときの分類器の方が、片腕運動時の脳活動で学習した分類器よりも高かった。




図 5 運動分類 kSVM における学習時の分類精度




図 6 方向分類 kSVM における学習時の分類精度

表 2 テスト時の分類精度の結果

分類器	精度[%]		チャンスレベル[%]
	subject 1	subject 2	
bimanual left	57.48	56.76	31.25
bimanual right	56.07	57.66	31.25
unimanual left	45.33	49.55	31.25
unimanual right	48.60	50.00	31.25

4.2 考察

表 2 より、テスト時の分類精度において両腕運動時の脳活動で学習した分類器の分類精度の方が高いという結果になった。これは片腕運動時の脳活動で学習した分類器は両腕運動に対応したシステムとしては十分とはいえず、ヒトの EEG においても両腕運動に対応したシステムを作るには、両腕運動時の脳活動で学習する必要があることが示唆される。

5. 展望

本研究では、kSVM を学習させる際、グリッドサーチによってハイパーパラメータのチューニングを行ったが、特徴量の抽出・選択は行わなかった。今回使用したデータの特徴量は 28ch×6 つの周波数帯となっているため、最大で 168 個の特徴量を持つことになる。実際のデータはノイズが含まれる電極を取り除いているため、168 個よりも少ないが、機械学習においては不要な特徴量を出るだけ減らすことが精度を上げる 1 つの手段である。今後は主成分分析や逐次後退選択などを行うことで特徴量の削減していく必要がある。また、時間方向に平均化することで特徴量としていたが、時系列情報を残した状態での分類や回帰分析によって腕の軌跡を再構成することで、より現実的な BMI の開発につながると考えられる。

参考文献

[Wolpaw 1991] Wolpaw, J R.,McFarland, D J.,Neat, G W.,Forneris, C A: An EEG-based brain-computer interface for cursor control , Electroencephalography and Clinical Neurophysiology, Vol.78(3), pp.252-259, 1991.

[Choi 2012] Choi.K.: Control of a vehicle with EEG signals in real-time and system evaluation, European Journal of Applied Physiology, Vol.112(2), pp.755-766, 2012.

[Korik 2016] Korik, A., Sosnik, R., Siddique, N., & Coyle, D.: 3D hand motion trajectory prediction from EEG mu and beta bandpower, Progress in Brain Research, Vol.228, pp.71-105, 2016.

[Rokni 2003] Rokni, U., Steinberg, O., Vaadia, E., & Sompolsinsky, H.: Cortical representation of bimanual movements, Vol.23(37), pp11577-11586, 2003.

[Steinberg 2002] Steinberg, O., Donchin, O., Gribova, A., Cardoso de Oliveira, S., Bergman, H., & Vaadia, E.: Neuronal populations in primary motor cortex encode bimanual arm movements, European Journal of Neuroscience, Vol.15(8), pp1371-1380, 2002.

[Ifft 2013] Ifft, P. J., Shokur, S., Li, Z., Lebedev, M. A., & Nicolelis, M. A. L.: A Brain-Machine Interface Enables Bimanual Arm Movements in Monkeys , Science Translational Medicine, Vol.5(210), 2013.

[Liao 2014] Liao, K., Xiao, R., Gonzalez, J., & Ding, L.: Decoding individual finger movements from one hand using human EEG signals, PLoS ONE, Vol.9(1), pp.1-12, 2014

[Dong 2017] Dong, E., Li, C., Li, L., du, S., Belkacem, A. N., & Chen, C.: Classification of multi-class motor imagery with a novel hierarchical SVM algorithm for brain-computer interfaces , Medical and Biological Engineering and Computing, pp.1-10, 2017