

畳み込みニューラルネットワークを用いた

脳波ブレイン・マシン・インターフェイスの開発

Development of Electroencephalogram brain-machine interface using convolutional neural network

加藤正起^{*1}

Masaki Kato

嶋田総太郎^{*2}

Sotaro Shimada

^{*1} 明治大学大学院

Meiji University Graduate School

^{*2} 明治大学

Meiji University

Brain-machine interface (BMI) is a system that manipulates machines directly from the brain activity data. Convolutional Neural Network (CNN) which enables end-to-end learning allows extracting information from brain activity [Antoniades 2016][Bashivan 2016]. In the previous study [Schirrmeister 2017], CNN was used to predict four kinds of motor imagery of right arm, left arm, foot and rest from electroencephalogram (EEG) data. In this study, we measured EEG when an individual performed reaching movements with his right arm. We propose a BMI system by using CNN that can classify four directions of reaching motion of the right arm from EEG data with about 78% accuracy.

1. はじめに

ブレイン・マシン・インターフェイス(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(EEG)や機能的核磁気共鳴計測(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。近年では脳波を含む脳活動の分析のためにend-to-end学習が可能である畳み込みニューラルネットワーク(Convolutional Neural Network : CNN)を用いた研究が行われている[Antoniades 2016][Bashivan 2016]。

先行研究[Schirrmeister 2017]ではCNNを用いて脳波から右腕、左腕、足の運動想起とレストの4種類を約90%の精度で予測した。しかし、それぞれの運動想起では握るなど具体的な運動を行っているわけではないため、四肢の詳細な運動を分類できるわけではない。

本研究では、右腕でリーチング運動を行った時の脳波を計測し、CNNを用いて、右腕の4種類の運動を分類することを可能にするBMIを開発した。

2. 実験方法

2.1 被験者

2名の健康な右利きの男性(23歳)が実験に参加した。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のようにプロジェクタ(EB-W420, EPSON)によって壁にゲーム開発ソフト(Unity, Unity Technologies)で作成したアバター アームを表示した。このアバター アームの動作はジョイステイック(T.Flight Stick X, THRUSTMASTER)により制御され、被験者はアバター アームを右腕で操作することで、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。

連絡先: 加藤正起, 明治大学大学院理工学研究科, 神奈川県
川崎市多摩区東三田 1-1-1, E-mail: ce181021@meiji.ac.jp

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とアバター アームの運動の遅延は、ハイスピードカメラ(EX-F1, CASIO)で測定したところ約200ms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: 60ch
(Fp1,Fpz,Fp2,AF7,AF3,AF4,AF8,F7,F5,F3,F1,Fz,F2,F4,F6,F8,FT7,FC5,FC3,FC1,FCz,FC2,FC4,FC6,FT8,T7,C5,C3,C1,Cz,C2,C4,C6,T8,TP7,CP5,CP3,CP1,CPz,CP2,CP4,CP6,TP8,P7,P5,P3,P1,Pz,P2,P4,P6,P8,PO7,PO3,POz,PO4,PO8,O1,Oz,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: 0.5-100 Hz



図1 実験風景

2.3 実験手順

1トライアルの流れを図2に示す。被験者がアバター アームを一辺12cmのベースポジション上に置くことでトライアルの開始とした。ベースポジションの位置は毎回同じで、直径12cmの円のターゲットはベースポジションの位置から前後左右の20cm離れた場所に出現させた。ターゲットの4通りの位置(front, back, left, right)はランダムに出現させた。実験中は右腕のアバター アームだけが表示された。また、左腕は動かさないように被験者に指示をした。実験では2セッションを行い、セッション内には8つのブロックがあった。それぞれのブ

ロックでは 150 トライアル繰り返した。被験者には、できるだけ早く、正確にリーチング運動を行うよう教示した。なお事前に 1 ブロック分(150 トライアル)の練習を行った。

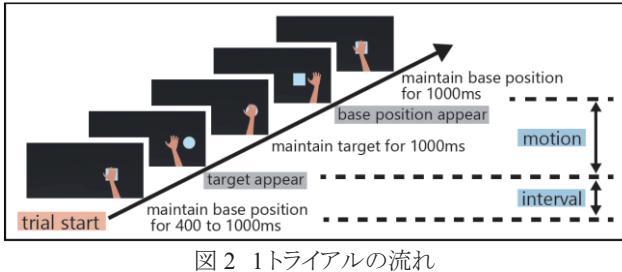


図 2 1 トライアルの流れ

3. 解析

3.1 前処理

測定した脳波データに対して、1Hz の高域通過フィルタをかけ、250Hz までダウンサンプリングを行った。1 セッション分のトライアルの中で-100μV～+100μV の範囲を超える脳波データが 50% 以上含まれる電極 (Subject1: F6, T8, PO8, O1, Oz, O2, Subject2: T8, PO3) を解析から除外した。ターゲットが表示される 0.5 秒前から表示後 3.25 秒 (Subject2 は 3.2 秒) までを 1 トライアルとし脳波データを分割した。-100μV～+100μV または-60dB～40dB の範囲を超える脳波データを含むトライアルを除いた後、脳波データに含まれる眼電成分と筋電成分を取り除くために独立成分分析を行った。

Subject2 の脳波データは測定機器の不良により、セッション 1 と 2 の 5, 6, 7, 8 ブロックのデータにノイズが多く含まれていたため、解析から除外した。これらの前処理は脳波解析ソフトである EEGLAB(v14.1.2)で行った。

3.2 入力データの作成

トライアルごとに分割された脳波データに対し、それぞれに対応した種類のラベル (front, back, left, right) を付けた。1 トライアル分の脳波データを時間窓 2 秒、スライド幅 0.04 秒で分割することで 1 トライアルあたり 44 個 (Subject2 は 43 個) の脳波データを作成し、入力データとした。1 トライアルあたり 44 個または 43 個の入力データが作成されるが、それぞれのラベルについては分割する前のトライアルに付属されたラベルと同じものを使用した。入力データのサイズは時間ステップ数 × 電極数で、Subject1 は 500×53 , Subject2 は 500×58 であった。

また、脳波データを学習データ、検証データ、テストデータの 3 つに 8 : 1 : 1 で分割した。

3.3 CNN による運動方向分類モデル

先行研究 [Schirrmeister 2017] のモデルをもとに脳波から右腕の運動方向を分類するために図 3 のような CNN を深層学習のフレームワークである TensorFlow を用いて作成した。

CNN は主に、画像データに対して用いられているが、本研究では入力データとして時系列信号を用いた。これは、脳波をウェーブレット変換などの時間周波数解析によって、画像として学習することも可能であるが、学習させる特徴量が 1 つの電極につき周波数分、増えてしまう。そのため本研究では、脳波を時系列信号の状態で学習することで特徴次元数を減少させた。

脳波は時系列情報を持つ信号であり、脳内の複数の双極性電流源によって引き起こされる空間的に広がる電圧の線形重ね合わせに近似すると仮定されている [Nunez 2006]。時間的空間的な情報をもつ脳波の特徴を捉えるため、第 1 層目で電極ごと

に脳波データを時間方向に畳み込んだ後、全電極分の特徴量を一度に畳み込むようなモデルを設計した。また、すべての畳み込み層のレイヤーにおいてドロップアウトを使用することで過学習を抑制した。最後の全結合層のソフトマックス関数によって入力データは 4 種類の運動のいずれかに分類された。

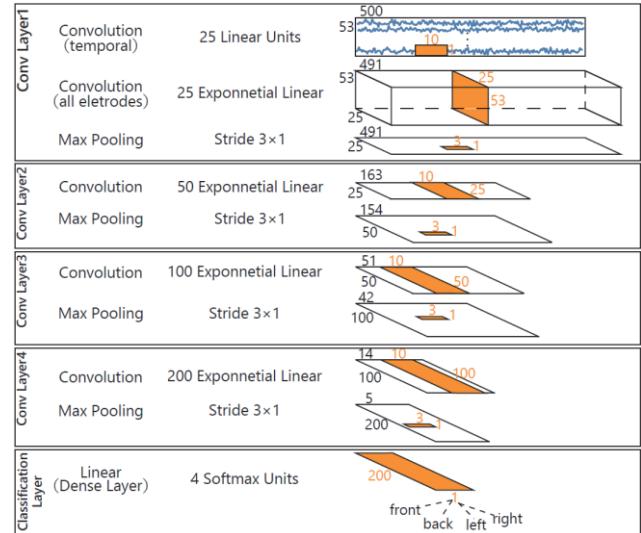


図 3 運動方向分類モデルの構造

4. 結果

テストデータを入力したときの混合行列を図 4 に示す。Subject1 と Subject2 の分類精度はそれぞれ 77.90% と 56.73% であった (チャンスレベルは 25%)。

本実験結果より、作成したモデルによって脳波から右腕の 4 種類の運動を最大で約 78% のという高い精度で分類できることが分かった。Subject2 の分類精度が Subject1 に比べ、20% 程低くなっている。これはノイズにより全データの半分しか学習データに使用できなかったため、汎化性能が低くなってしまったと考えられる。

		predicted label				true label							
		right	front	left	back	right	front	left	back	Sensitivity			
predicted label	Sensitivity	right	1749 90.3%	136 7.0%	82 4.2%	366 18.9%	74.97%	453 43.9%	8 0.8%	48 4.7%	59 5.7%	79.75%	
		front	75 3.9%	1497 77.3%	58 3.0%	384 19.8%	74.33%	right	159 15.4%	873 84.6%	208 20.2%	312 30.2%	56.25%
predicted label	Sensitivity	left	64 3.2%	245 12.4%	1778 89.8%	153 7.7%	79.38%	front	330 32.0%	100 9.7%	623 60.4%	268 26.0%	47.16%
		back	48 2.4%	58 2.9%	62 3.1%	1077 54.4%	86.51%	left	90 8.7%	51 4.9%	153 14.8%	393 38.1%	57.21%
		true label				predicted label				Accuracy			
		right	front	left	back	right	front	left	back	Precision			
		90.34%	77.32%	89.80%	54.39%	77.90%	84.59%	60.37%	38.08%	56.73%			

(a) Subject1

(b) Subject2

図 4 テストデータ入力時の混合行列

5. まとめ

分類精度が約 78% と先行研究 [Schirrmeister 2017] の 90% と比べ低くなっているが、先行研究で行われた右腕、左腕、足の運動想起はそれぞれ、左脳の一次運動野、右脳の一次運動野、頭頂葉付近の一次運動野など脳の活動領域が異なる。それに比べ本研究で行った右腕のリーチング運動は左脳の一次運動野の中での活動であり、その狭い脳領域で 4 種類の運動の特徴を捉える必要があったため、精度が下がってしまったと考えられる。また、1 トライアルのなかでターゲットにアバター アームを

伸ばして戻すという運動を行うが、この一連の動作に対して1つのラベルを割り当てるためだと考えられる。

しかし、本研究では右腕の4種類の運動の分類を可能にした。今度は学習データとして右腕運動時の脳波だけでなく、左腕や両腕を動かしたときの脳波を用いて、BMIとしての分類数をさらに増やしていきたい。これによって、より現実的なBMIの開発を目指す。

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.
- [Antoniades 2016] Antoniades, A., Spyrou, L., Took, C. C., & Sanei, S.: Deep learning for epileptic intracranial EEG data, IEEE International Workshop on Machine Learning for Signal Processing, MLSP, 2016.
- [Bashivan 2016] Bashivan, P., Rish, I., Yeasin, M., & Codella, N.: Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks, ICLR, pp.1-15, 2015.
- [Schirrmeister 2017] Schirrmeister, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggensperger, K., Tangermann, M., ... Ball, T.: Deep learning with convolutional neural networks for EEG decoding and visualization, Human Brain Mapping, 38(11), 5391–5420, 2017.
- [Nunez 2006] Nunez, P. L., & Srinivasan, R.: Electric Fields of the Brain, The Neurophysics of EEG Second Edition, Oxford University Press, 2006.