

## 深層学習を用いた脳波分類における 入力データセット構成の研究

### An Investigation of Input data Configuration for EEG Classification using Deep Learning

小笹 龍之介\*<sup>1</sup> 山本 尚哉\*<sup>1</sup> 夏 苗\*<sup>1</sup> 安藝 史崇\*<sup>2</sup>  
木村 達洋\*<sup>3</sup> 大島 浩\*<sup>4</sup> 山崎 清之\*<sup>4</sup>  
by Ryunosuke OZASA, Naoya YAMAMOTO,  
Miao XIA, Fumitaka AKI, Tatsuhiko KIMURA,  
Hiroshi OHSHIMA and Kiyoyuki YAMAZAKI

#### 1. 研究の背景

筋萎縮性側索硬化症 (Amyotrophic Lateral Sclerosis : ALS) や脳卒中、ギラン・バレー症候群などによる閉じ込め症候群は、認知機能や睡眠・覚醒サイクルは正常で垂直方向の眼球運動および瞬きすることは可能だが、顔面下部、咀嚼、嚥下、発話、呼吸、四肢の運動をすることができない障害である。これにより、コミュニケーションが困難となっている患者は少なくない。この問題は、患者自身はもちろん、介護者にとっても患者の意図を読み取ることは難しく深刻な問題となっている。

近年、脳活動でコンピュータを制御するブレインコンピュータインターフェース (Brain Computer Interface : BCI) の技術を利用した意思疎通のための代替コミュニケーションシステムの研究が行われている。本研究室でも以前からフラッシュを用いた定常状態視覚誘発電位 (Steady State Visual Evoked Potentials : SSVEP) を用いた BCI の研究を行っている。データ処理は脳波のデータ区間を高速フーリエ変換 (Fast Fourier Transform : FFT) したものを使用し、畳み込みニューラルネットワーク (Convolutional Neural Network : CNN) を用いた深層学習を用いて判別する解析手法を検討している。

#### 2. 目的

誘発電位や事象関連電位などの信号は、通常、様々なノイズ成分を含んでおり、一般的にデジタルフィルタや移動平均法などを用いて除去される。脳波は周波数帯域ごとに特徴付けられているため、周波数情報に着目すると特徴が抽出しやすいと考えられている。

本研究では 20Hz と 60Hz の光刺激を見せたときの脳波を測定し、周波数解析を行った。周波数解析は短いデータ区間で行ったため、肉眼で 20Hz の光刺激を見た脳波なのか、60Hz の光刺激を見た脳波なのかを判断するのは極めて困難であり、実用上では不可能である。そこで自動的に特徴量を抽出し、分類することができる深層学習を用いることとした。

2 通りの光刺激を深層学習にて分類する際の入力データセットを三次元データにする必要がある。また、CNN を用いて解析を進めるため、Z 軸方向は畳み込まれることになる。この時、X 軸方向を周波数としたとき、Y 軸方向にパワースペクトル、Z 軸方向に脳波のチャンネルに

するか、Y 軸方向に脳波のチャンネル、Z 軸方向に脳波のパワースペクトルにするか、どちらが判別において最適であるかを検討することとする。

#### 3. 解析方法

##### 3.1 準備および測定方法

健康成人男性 9 名を対象に brain vision V-AMP(BRAIN PRODUCTS 製)を使用してシールドルーム内で脳波の測定を行った。電極は 10-20 法に基づき、C3,C4,P3,P4,O1,O2 に配置し、両耳朶を基準とした単極導出を行い、サンプリング周波数を 250[Hz]で記録した。

測定手順は、安静閉眼時、安静開眼時の脳波を 1 分間ずつ測定し、20[Hz]の刺激光、60[Hz]の刺激光を 2 分間ずつ提示して脳波を測定した。各条件の測定終了するごとに、1 分間の休憩を設けた。

Fig.1 に実験に使用した光刺激装置を示す。装置内には、光刺激の光源に使用した Arduino により制御された緑色に発光する 1 つの LED のみが設置されている。LED の光の強さは装置を覗いた時に被検者の目が置かれるおおよその位置で、1[lux]であった。また、測定中に装置外の光が干渉しないようにシールドルーム内を暗闇にした。




Fig.1 光刺激装置の外観

##### 3.2 解析手順

測定した脳波を電極データごとに耳朶電極を基準としたリモンタージュを行った後、1250 個のデータ (5 秒間に相当する) ずつに分割した。この時、オーバーラップという手法が用いられている。オーバーラップは、1250 個ごとに区切られたデータのうち一部を次のデータセットに用いることで、データ数を増やし、データの連続性を保つことができる。今回は、80[%]をオーバーラップして、データが抽出されている。抽出したデータごとに平均値を算出して減算後、ハミング窓をかけ、個人差をなくすために標準化を行った。そして、Fig.2 のように、(電極、パワースペクトル、周波数) からなる三次元データを 1 個のデータセットとして 2 通り作成し、9 人の被験者のデータから、20[Hz]の点滅光を提示中の脳波の入力データセットを 1044 個、60[Hz]の点滅光を提示中の脳波の入力データセットを 1044 個、合計 2088 個の入力データセットを CNN の学習に使用した。学習は、結果に再現性を持たせるためにそれぞれ 100 回試行した。

この時、X 軸方向を周波数、Y 軸方向をパワースペク

\*1 東海大学大学院工学研究科医用生体工学専攻

\*2 東海大学工学部医用生体工学科助教

\*3 東海大学基盤工学部医療福祉工学科准教授

\*4 東海大学工学部医用生体工学科教授

トル、Z軸方向を脳波のチャンネルにしたものを入力A、X軸方向を周波数、Y軸方向を脳波のチャンネル、Z軸方向をパワースペクトルにしたものを入力Bとした。




Fig.2 入力データセットの構成略図

作成したデータセットを Python の Chainer で構築した CNN のモデルに入力し、層化 10-分割交差検証でモデルの性能評価を行なった。層化 k-分割交差検証は、入力データセットを k 個に分割し、1つを検証用データ、残りの k-1 個を学習用データに分割し、k-1 個のデータの学習後に検証用データで評価を行うことを k 回繰り返す、その平均を算出することでモデル性能を可能な限り正確に評価することを目的とした手法である。学習用データはモデルの学習を行うためのデータ、検証用データは学習したモデルの性能を評価するためのデータである。

#### 4. 結果

作成した2通りの入力データセット(Fig.2)を、それぞれ CNN を用いた深層学習を行い、その結果を Table 1 に示す。入力 A では、学習用データに対する精度が 97.1[%]、検証用データに対する精度が 90.9[%]であった。また、入力 B では、学習用データに対する精度が 98.2[%]、検証用データに対する精度が 94.5[%]であった。X 軸方向を周波数、Y 軸方向を脳波のチャンネル、Z 軸方向をパワースペクトルとした入力 B の方が、Y 軸方向をパワースペクトル、Z 軸方向を脳波のチャンネルとした入力 A に比べて高い精度で学習させることができた。

Table 1 入力データセットに対する平均分類精度

	学習用データ	検証用データ
入力 A	97.1[%]	90.9[%]
入力 B	98.2[%]	94.5[%]

#### 5. 考察

CNN を用いた深層学習において、入力データセットの形状については、入力 A、入力 B のどちらの場合でも、比較的高い精度を得ることができた。しかし、わずかではあるが、入力 B の方が学習用データおよび検証用データに対して、入力 A よりも高い精度が得られている。入力 B が高い精度で得られた理由として、脳波のチャンネルを畳み込まずに学習したためであると考えられる。脳波は、測定部位によってそれぞれ異なった感覚野からの活動電位を測定している。しかし、畳み込み演算を行う際に、脳波のチャンネル方向を畳み込むことで、それぞれのチャンネルごとに含まれていた特徴量が混ざり、これにより、各チャンネルが持っていた特徴量が見えにくくなったと考えられる。

また、今回の結果を得るにあたり作成した各入力データセットは、5 秒間分 (1250 個のデータ) で検証を行い、高い精度を得ることができた。周波数解析を行ったデータを CNN により、解析を行う際に用いたデータ数は、CNN モデルを用いた深層学習を行うにあたり、脳波状態分類するために十分なデータ量であったと考えられる。

#### 6. まとめ

5 秒間分の脳波を測定したデータを周波数解析し、深層学習のモデルの 1 つである CNN を用いて 2 通りの入力データセットを用いて脳波状態分類を行った。その結果、脳波のチャンネルにはそれぞれ異なる特徴量が含まれていることが考えられ、Z 軸方向を脳波のチャンネルとして畳み込むと特徴量が失われる可能性があると考えられた。そのため、脳波分類を、CNN モデルを用いた深層学習で行う場合は、チャンネル方向を畳み込む際には注意が必要であることが考えられた。

本研究では、Z 軸方向に脳波のチャンネルを畳み込むか否かで比較を行ったが、中間層で畳み込む際に、フィルタの設定により脳波のチャンネルが畳み込まれた場合、どのような精度が得られるか今後、検討していく必要がある。また、実際に BCI に用いることができるかどうかを検討するために、9 名の被験者以外で同様の測定を行い、一般化に向けた精度評価を行う必要があると考えられる。

#### 参考文献

- 1) Vernon J. Lawhem et al. "EEGNet: A Compact Convolutional Neural Network for EEG-based Brain-Computer Interfaces" Journal of Neural Engineering, 2018, Vol15(5)
- 2) 斎藤康毅. ゼロから作る Deep Learning -Python で学ぶディープラーニングの理論と実装. オライリー・ジャパン. 初版第 12 刷. 2018.8
- 3) 圓城寺純矢ら. 深層学習による BCI コミュニケーションのための脳波状態分類. 東海大学基盤工学部紀要 7 (2019), p1-7
- 4) Naoya Yamamoto et al. "Investigation on CNN-Based State Classification Towards BCI Application Using Amplitude Probability Density Distribution" HCCI 2020, 2020, p683-689