

振幅確率密度分布を利用した CNN による脳波状態分類

山本 尚哉^{*1} 小笹 龍之介^{*1} 圓城寺 純矢^{*1} 安藝 史崇^{*2}
木村 達洋^{*3} 山崎 清之^{*4}

Investigation on CNN-based EEG Classification Using Amplitude Probability Density Distribution by

Naoya Yamamoto, Ryunosuke Ozasa, Junya Enjoji, Fumitaka Aki,
Tatsuhiko Kimura and Kiyoyuki Yamazaki

(Received: November 12, 2020, Accepted: December 16, 2020)

Abstract

We have been studying SSVEP-based BCI for patients with disabilities. The purpose of this study is to classify the EEG state using the amplitude probability density distribution (APD) in order to analyze from the morphological features, and to verify whether it is feasible as an analysis that contributes to the classification of EEG. In this study, APD was used as a morphological index of EEG and adapted to EEG state classification using deep learning. A model of deep learning was constructed using CNN, and the data obtained by the APD method and FFT were compare the feasibility. The participants were presented with flashing lights of low stimulation altitude of 20 Hz and 60 Hz, and EEGs were recorded. As a result, the classification system using FFT as control data was 92.66%, and the classification system using APD was 90.56%. It was shown that the classification accuracy of both is almost the same. From this, it was shown that the two different frequency information can classify the EEG characteristics not only from the frequency characteristics used in the EEG classification but also from the morphological characteristics. The problems in BCI and the effectiveness of APD in the field of BCI were discussed.

Key Words: Deep Learning, SSVEP, Assistive Technology, EEG Classification

1. はじめに

1.1 BCI の研究

Brain-Computer Interface (BCI) は、ユーザーの意図を脳波などの生体情報から抽出してシステムを制御する信号に変換することを目的としたインターフェースである。このシステムは人間の脳とコンピュータをつなぐ新しい情報チャンネルとして注目され、医療においては患者の運動機能の補助や代替するコミュニケーションシステムとして使用されている[1][2]。これらの信号を取得する1つの手法として、脳波 (Electroencephalogram:EEG) を用いた方法がある。例えば、脳波を利用して車椅子を操作するシステムが研究されている[3]。BCI システムに使用される脳波にはさまざまな種類があるが、中でも代表的なものとして定常状

態視覚誘発電位 (Steady State Visual

Evoked Potentials:SSVEP) が挙げられる。著者らの研究室でも、フリッカー刺激の周波数と同期して誘発される SSVEP を用いた研究を行ってきた[4]。

1.2 本研究の目的

誘発電位や事象関連電位などの信号は、通常、さまざまなノイズ成分を含んでいる。一般にノイズはデジタルフィルタや移動平均法などにより除去する。脳波は周波数帯域ごとに特徴付けられており、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。したがって、多くの研究では周波数情報を使用して分析し、波の特性を抽出している[5]。一方、脳波の時系列波形における形態学的特徴に着目した研究はほとんどない。そこで本研究では、脳波解析の新しい方法として脳波の時系列波形における形態学的特徴を含む振幅確率密度分布 (Amplitude Probability Distribution:APD) を導入した。この方法では、振幅の各階級における確率の密度分布の確率を調べることができる。

^{*1} 東海大学大学院 工学研究科 医用生体工学専攻 修士課程

^{*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 医務衛生工学科 准教授

^{*4} 東海大学 工学部 医用生体工学科 教授

本研究では 20Hz と 60Hz の光刺激を見せた時の脳波を測定し、APD に変換した。しかし、APD に変換したデータから 20Hz の脳波なのか 60Hz の脳波なのかを肉眼で判断するのは極めて困難であり、実用上は不可能である。

そこで、それぞれの脳波判定に寄与する特徴が内在するかどうかを見つけるために深層学習を採用した。機械学習は人間が特徴を定義し、分類するが、深層学習は自動で特徴量を抽出し、分類する。脳波のような分類のための手がかりが未知の場合は特徴量を探索的に求めることができる深層学習が有利であると考えた。APD に変換して脳波が深層学習によって分類できるかどうかを調べ、APD が BCI の脳波状態分類の判定において将来使用できる方法かどうか検討することを目的とする。

2. 深層学習

ここでは著者らが使用した深層学習の概要について簡単に説明する。

2.1 深層学習とは

機械学習のアルゴリズムの 1 つにパーセプトロンがある。パーセプトロンは重みとバイアスという 2 つのパラメータを有し、複数のクラスから構成される入力データに応じた適切な重みとバイアスを設定することでクラス分類を行うことができる。また、パーセプトロンではモデルの分類性能を高めるために層を増やすことができ、多層化したものは多層パーセプトロンと呼ばれている。しかし、パーセプトロンの重みとバイアスの設定は解析者が手動で行う必要があり、層が多層になるにつれてパラメータ数が増大するため、適切なパラメータ設定を行うことが困難となる。そこで、パラメータの最適な数値を自動で学習できるようにしたものがニューラルネットワークである [6]。ニューラルネットワークは複数の層から構成され、大きく分けて入力層、中間層、出力層の 3 つがある。中間層は 2 層以上にすることができ、層を増やすほどモデルの性能が向上するとされている。このように中間層を 2 層以上にしてモデルの表現力を高くし、入力データに含まれる抽象度の高い特徴量も自動で学習できるようにしたものが深層学習である。

2.2 畳み込みニューラルネットワーク

深層学習のモデルの 1 つに畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) がある。CNN は畳み込み層とプーリング層と呼ばれる 2 つの特徴的な隠れ層を持つモデルで、畳み込み層により入力データから局所的な特徴量を抽出し、プーリング層により特徴量の位置ずれに対してロバストになる [6]。

画像認識において高い性能を持つため画像認識の分野で用いられることが多かったが、最近では時系列データである脳波に対して応用される報告例もみられるようになった [7]。

2.3 畳み込み層

畳み込み層は、元の入力データに対してフィルタを適応する「畳み込み演算」という処理を行う。この処理方法は画像処理における「フィルタ演算」に相当する処理方法である。例えば、縦方向と横方向の 2 次元の形状の入力データ ($a \times b$) があり、この入力データにフィルタ ($c \times d$) を適応するとフィルタサイズそれぞれの場所でフィルタの要素と入力データの要素を乗算し、その和を求める積和演算を行う。この作業を入力データ全体で行うことで、入力データから特徴量だけを抽出した特徴マップと呼ばれる二次元構造のデータが出力される [6]。この処理は入力データのデータ構造がカラー画像のような 3 次元構造であっても同様に行うことができ、3 次元構造の場合にはチャンネルごとに対応するフィルタを畳み込み生成されたチャンネルごとの特徴マップを合算することで、1 つの 2 次元構造の特徴マップを得ることができる。

2.4 Pooling 層

Pooling 層の方法には Max Pooling と Average Pooling の 2 種類がある。Pooling 層では畳み込み層で出力されたデータの局所的な情報をまとめる空間サイズを小さくする処理を行う。Max Pooling は対象領域から最大値をとる演算であり、最大値を 1 つの要素に集約する操作をしている。また Average Pooling は対象領域の平均値を計算し、1 つの要素に集約する方法である。今回の深層学習の Pooling 層には Max Pooling を採用した。Max Pooling 層は入力データの微小な位置ずれに対して、同じような結果を出力することができる。そのため、Max Pooling 層は入力データの小さな位置ずれによる影響を緩和できる特徴がある [6]。

3. 実験方法

実験は、平均年齢が 22 歳の健康な成人男性 9 名で行った。EEG 測定では、6 チャンネルの EEG 電極を、10-20 法に従い、C3、C4、P3、P4、O1、O2 に配置した (Fig. 1)。測定機器は、BRAIN PRODUCTS Inc. Brain Vision Recorder1.20 を使用し、静電シールドルームで 250Hz のサンプリング周波数で記録した。

Fig. 2 に本実験で使用した光刺激装置を示す。光刺激の光源には緑色に発光する LED を使用し、装置の内部に

設置した。装置を覗いた時に被験者の目が置かれると想定される距離でLEDの光の強さを測定すると1[lux]であった。LEDの点滅はPCからの入力を受けたArduinoによって制御され、任意の周波数で点滅するように設計されている。この実験では脳波の一般的な周波数成分とほとんど重複しないと考えられる20Hzと、それよりも高く、融合して認知される周波数としてかつ50Hzの商用電源周波数を避けた60Hzに刺激周波数を設定した。また測定中には、実験室の照明など刺激装置の光源以外からの余分な光が干渉することがないように暗闇にて実験を行った。次に、Table 1に実験プロトコルを示す。安静閉眼、安静開眼で1分間ずつ脳波を測定した後、20Hzと60Hzの2種類の周波数で点滅させ、被験者に刺激を与えている状態で脳波を2分間ずつ測定した。被験者は、各条件の間に1分間休憩を挟んで実験を行った。




Fig. 1 10-20法に基づいた電極配置図




Fig. 2 装置の外観

Table 1 実験プロトコル

安静 開眼	休憩	安静 閉眼	休憩	20Hz	休憩	60Hz
1分間		1分間		2分間		2分間

4. 解析方法

4.1 APDの抽出およびFFT解析

Fig. 3は深層学習に使用するAPD入力データセット作成の流れを簡単に説明した図である。図中のxは測定によって得られた脳波の振幅値を示している。それぞれ6つの電極に対して5秒間に相当するデータ数(データセ

ット)に分割する処理を行い、時間軸上で同期するデータセットを全電極で1つにまとめ、入力データセットを作成した。ここで、データ数を増やすためにオーバーラップという手法を用いた。これは前のデータセットの何割かを重ねて次のデータセットとすることでデータ数を増やすことのできる手法である。Fig. 3における黄枠が1つのデータセットである。二つ目のデータセットからは1つ前のデータセットのうち80%をオーバーラップさせた。この作業を測定データの最後まで行ったことでデータセットは1つの電極につき116個作成された。次に、データセットの振幅を20のクラスに分割してAPDのデータセットを作成した。Fig. 3のグラフの横軸Cは振幅のクラスを示し、縦軸Pはクラスごとの頻度を表している。クラス数を少なくすると、APDのグラフは粗くなり、クラス数が多くなるとAPDは平坦になる。その結果、どちらのグラフにも偏りがなく、最も適切であると思われる、20のクラスを選択した。安静時の健常者の脳波には個人差があるため、振幅の上限を50μV、下限を-50μVに設定した。筋電図(Electromyography:EMG)などのノイズ成分がEEG信号と混同しないように振幅が±50μVを超えたデータは取り除いた。

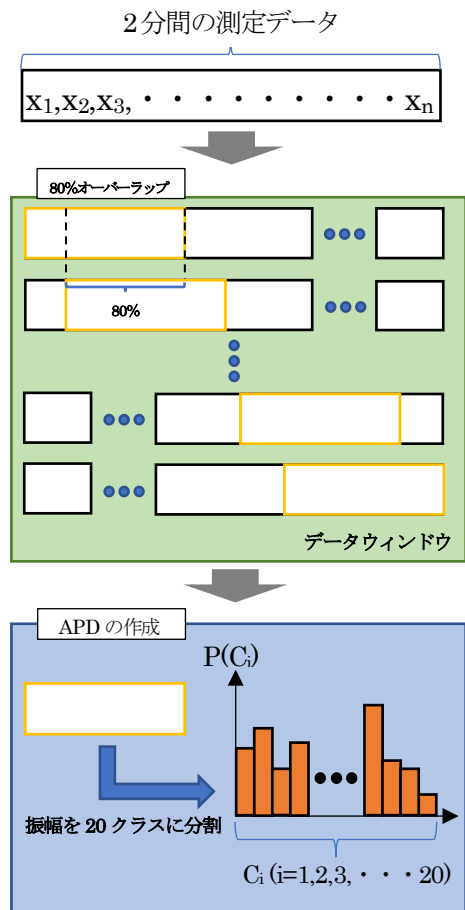


Fig. 3 APDの入力データセット作成の流れ

FFT 解析に用いる入力データセットも同様の手順により、2 分間の測定データから 116 個のデータセットを作成された。1 つのデータセットごと FFT 解析を Python のプログラムによって行い、FFT 入力データセットを作成した。

Fig. 4 に深層学習に用いた APD 入力データセットのデータ構造を簡単に示す。深層学習に用いるデータセットは 6 つの電極を 1 つにまとめた構造になっている。縦は確率密度、横はクラス数、奥行きはチャンネル数となっている。FFT 入力データセットの場合には横が周波数軸となる。

APD 及び FFT の入力データセットは 116 個作成され、これを被験者 9 名分のデータに対して行うことで合計 1044 個が得られた。また、20Hz と 60Hz の点滅刺激を提示した時の脳波を測定したため、合計 2088 個の入力データセットが得られた。その後、データの偏りを軽減するために 2088 個の入力データセットをシャッフルした。

シャッフルされた入力データセットを CNN モデルに入力し学習させ、20 [Hz] で点滅刺激を与えた場合の脳波であるか、それとも 60 [Hz] で点滅刺激を与えた場合の脳波であるかの二値分類を行わせた。

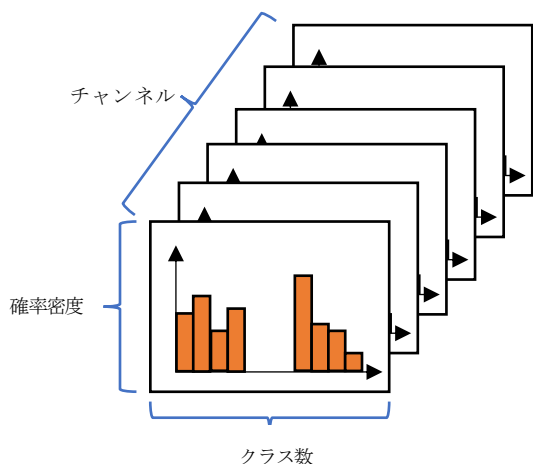


Fig. 4 入力データセットの構造(APD)

4.2 学習及び評価方法

深層学習の評価方法には 10 分割交差検証を採用した。10 分割交差検証は、入力データを 10 セットに分割し、そのうちの 1 つを検証データ、残りの 9 つを学習データとして学習及び評価することを、分割した 10 セット全てが検証データになるまで繰り返す方法である。この方法では、学習データ及び検証データに対する分類精度を 10 回の学習及び評価の全てで求め平均を算出し、算出された分類精度の平均をモデルの性能の指標として扱う。

このため、10 分割交差検証は入力データセットを学習データ及び検証データに分割することを 1 回だけ行い、得られた学習データ及び検証データに対する分類精度をモデルの性能の指標として扱うホールドアウト法よりも正確にモデルの性能を評価することができる。

Table 2 は脳波を APD 解析したデータを入力した場合、Table 3 は脳波を FFT 解析したデータを入力した場合の CNN の各層におけるパラメータと出力データの形状を示している。Table 2、Table 3 における「エポック数」は、学習する回数を示している。また、「ドロップアウト」は、学習データに対して過剰に適応したため、検証データに適応できていない状態である「過学習」を抑制するためのパラメータである。過学習を抑制することはモデルの汎化性能（学習データのような学習したデータだけでなく、検証データのような学習していない未知のデータに対しても学習データと同様な分類性能を発揮できる能力）を向上させるために重要である。

Table 2、Table 3 のフィルタは出力フィルタ数、サイズはフィルタサイズを示している。サイズやストライドの表記は行列で表記しており、フィルタサイズ及びストライドの項目に (1, 2) と表記されている場合、行方向に 1、列方向に 2 という大きさを持ったフィルタサイズ、もしくは行方向に 1 つ分、列方向に 2 つ分だけフィルタをずらす (ストライド) ことを表している。それぞれの出力は 3 次的に示し、チャンネル数×縦×横で表記した。

Table 2 APD のパラメータと出力

層の種類	フィルタ	サイズ ストライド	出力
畳み込み	4	(1,2)/(1,2)	4×1×10
中間層			64
中間層			32
中間層			2

*エポック数 : 1000、dropout : 0.3

Table 3 FFT のパラメータと出力

層の種類	フィルタ	サイズ ストライド	出力
畳み込み	2	(1,4)/(1,4)	2×1×156
プーリング		(1,3)/(1,2)	2×1×78
中間層			64
中間層			2

*エポック数 : 1000、dropout : なし

5. 結果

Fig. 5 と Fig. 6 は APD または FFT を入力データとした時の 10 分割交差検証によって得られた学習データと検証データの精度 (accuracy) の推移を表した図である。Fig. 5 は APD における 10 分割交差検証の 8 回目の結果を示し、Fig. 6 は FFT における 10 分割交差検証の 4 回目の結果を示している。縦軸は精度を表し、横軸はエポック数を表している。エポック数とは学習データの繰り返し行う学習の回数のことである。青い線は学習データを示し、オレンジの線は検証データを示す。どちらの図もエポック数が増えるにつれて精度が上がっていることがわかる。

Fig. 7 は 10 分割交差検証によって得られた 10 個のデータの精度を平均し、APD と FFT の状態分類精度を比較した図である。Fig. 7 における左側は学習データの精度の比較で、右側が検証データの精度の比較を示している。学習データの APD の精度は 94.74%、検証データの精度は 90.56% であり、FFT による学習データの精度は 90.54%、検証データの精度は 92.66% となった。

Table 4 は深層学習における APD と FFT それぞれに要する学習時間を示している。1 回ごとの学習時間の平均と合計でかかった時間を示した。APD の場合、1 回の平均学習時間は 3 分 20 秒、10 回分の合計学習時間は 33 分 33 秒となった。また、FFT の場合、1 回の平均学習時間は 5 分 30 秒、10 回分の合計学習時間は 55 分となった。




Fig. 5 10 分割交差検証 8 回目 (APD)




Fig. 6 10 分割交差検証 4 回目 (FFT)

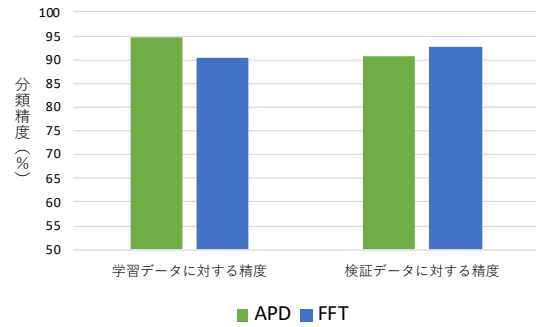


Fig. 7 APD 及び FFT の解析によって得られた精度の比較

Table 4 APD 及び FFT の学習時間の比較

処理方法	1 回の平均学習時間	10 回分の合計学習時間
APD	3 分 20 秒	33 分 33 秒
FFT	5 分 30 秒	55 分

6. 考察

脳波は、複雑に組み合わせられたいくつかの要因を含む時系列信号であるため、測定部位によって脳波の見え方が異なるが、FFT と APD を比較すると、どちらの場合も高い精度が得られた。したがって、20Hz と 60Hz で反転した光刺激によって得られた脳波の APD 及び FFT 入力データセットに含まれる特徴を深層学習が抽出できたため、状態分類ができたと考えられる。このことから、APD のような波形の形態的特性にも何らかの特徴が現れていると考えられる。

APD の精度は、学習データよりも検証データの方がわずかに高かった。これは、データ処理中に深層学習のパラメータが適切に最適化されない可能性があるためである。また、APD 及び FFT 入力データセットを同じ CNN モデルで分類した場合、両方で高い精度が得られた。したがって、光刺激による脳波の分類は周波数情報だけでなく、波形の形態的特徴からも分類できると考えられる。

APD と FFT の 1 回の学習において、学習時間に約 2 分の差が生じた。また、10 回分の学習においては約 20 分の差があり、FFT と比べて APD の方が学習時間を短縮できることがわかった。これは APD 処理されたデータの情報量が少なく、シンプルであるためと考えられる。

7. 結論

APD 及び FFT を入力データとして使用し、深層学習のモデルの 1 つである CNN により脳波状態分類を行った。その結果、APD による分析方法では、従来の FFT と同程度の精度が得られた。一般的に BCI の分析には周波数情報を用いた分類が使用されるが、将来的には APD など

の波形の形態特性がBCIにおける分析の特徴抽出として使用できる可能性がある。そして、深層学習により脳波を学習させてBCIに用いる場合、APDを用いる場合の方が学習時間を大幅に短縮できるため、BCIシステムに実装した場合でも効率化が期待できる。本研究では深層学習によって脳波データを用いたAPDには何らかの特徴があることが確認できた。今後は、深層学習が脳波の状態分類を行った際に使用したAPDの特徴がどのような特徴であるかを検討していく必要がある。

on Deep Learning Approach, Expert Systems with Applications 2018, Volume 107, p. 61-71

8. 謝辞

本研究の一部は、公益財団法人フジクラ財団の研究助成を受けて行われた。ここに記して深謝いたします。

9. 文献

[1]木村達洋, 山崎清之;最近のBrain-Computer-Interface (BCI) 研究の動向, 東海大学紀要 開発工学部 2010, 第20号, p. 7-12

[2]F Lotte, L Bougrain, A Cichocki, et. al; A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update, Journal of Neural Engineering 2018, 15 031005

[3]Sim Kok Swee, Lim Zheng You; Fast Fourier Analysis and EEG Classification Brainwave Controlled Wheelchair, International Conference on Control Science and Systems Engineering 2016, 2nd, p20-23

[4]I. Chanpornpakdi, et. al; FUNDAMENTAL STUDY ON NONINVASIVE BCI COMMUNICATION USING CHECKERBOARD PATTERN REVERSAL STIMULUS, IADIS IHCI 2019 Proc, p. 459-462, 2019

[5]Takeshi Sakurada, Toshihiro Kawase, et. al; Use of high-frequency visual stimuli above the critical flicker frequency in a SSVEP-based BMI, Clinical Neurophysiology 2015, 126, p. 1972-1978

[6]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, 株式会社オーム社, 2018, p. 21-285

[7]Ihsan Ullah, et. al; An Automated System for Epilepsy Detection using EEG Brain Signals based