

押下音聴取時の脳波に関する 機械学習によるスイッチの分類

宮田 悠斗¹ 朱 宇軒¹ 小澤 賢司¹ 下村 尚登² 白坂 剛²

概要: スイッチ押下音を聞いている際の脳波について、スイッチの種類などをラベルとして、分類の可能性を探ることが本研究の目的である。32チャンネル脳波計を用いて、スイッチ押下音を被験者に聴かせた際の脳波データを採取した。採取した脳波データを、ニューラルネットワークの1つであるEEGNetを用いて学習・分類を行った。特定の被験者、特定のスイッチ押下音について、複数回音を聴かせたデータを入れ替え交差検証した場合に高い正解率が得られた。しかし、特定の被験者について、スイッチを入れ替え交差検証した場合、正解率は低い結果となった。そこから、スイッチ押下音を聴いた際の脳波は再現性を持つこと、一方、未知のスイッチ音を聴いた際の脳波から、スイッチの特性を予測することは現時点では困難であると考察した。

キーワード: スイッチ, 脳波, 機械学習, ニューラルネットワーク, 分類, EEGNet

Classification of switches by machine learning regarding brain waves when listening to pressing sounds

Abstract: The purpose of this study is to explore the possibility of classification of brain waves when listening to switch sounds, i.e., sounds when a switch is pressed, using the type of the switch as a label. We collected electroencephalogram (EEG) data using a 32-channel recorder when subjects heard the switch sounds. The collected EEG data were learned and classified using EEGNet, which is one of the neural networks. A high accuracy was obtained when cross-validation was performed by exchanging data in which sounds were heard multiple times for a specific subject and a specific switch sounds. However, when cross-validation was performed by exchanging the switch for a specific subject, the accuracy was low. Based on these results, we considered that the brain waves when listening to the switch sounds have reproducibility, while it is difficult to predict the switch characteristics from the brain waves when listening to an unknown switch sounds.

Keywords: Switch, EEG, Machine Learning, Neural Network, Classification, EEGNet

1. はじめに

我々の身の回りにはスイッチをもつ多くの製品が存在している。近年、スイッチ本来の機能だけではなく、操作音の心地良さなど感性的な価値に焦点を当てる人が増えている [1], [2], [3], [4], [5], [6]。その状況を踏まえると、部品メーカーなどのスイッチを造る側の立場としても、スイッチ押下音の評価は大切になってくる。そのスイッチ押下音の評価する方法の例として、心理物理学的測定法が挙げられ

る。これは、スイッチ押下音という物理量と被験者の心理量の関係を測定することで音の評価するものである。

スイッチ以外のものに目を向けると、感性評価に脳波などの生理量が用いられる場合がある。例えば、脳波を用いた動画の評価が実用化されている [7]。しかし、スイッチ押下音について、脳波という生理量とスイッチ押下音の物理量、更には心理量との関係は明らかになっておらず、評価に脳波を測定する方法は用いられていない。脳波から心理量を推測するには、脳波に含まれるそのときの心理量についての特徴を捉える必要がある。そのために、スイッチ押下音を聴いている際の脳波を機械学習で分類することで、生理量と心理量の関係を明らかにし、スイッチ押下音の評

¹ 山梨大学大学院医工農学総合教育部・研究部
Graduated school, University of Yamanashi

² アルプスアルパイン株式会社
Alps Alpine Co., Ltd.

価に脳波測定を用いることを検討する。

本研究ではスイッチ押下音を聴いている際の脳波を測定し、機械学習によってスイッチをその構造や、先行研究 [4] で明らかになっている因子得点により分類ができるか検証する。これによってスイッチ押下音を聴いている際の脳波が持つ特徴を明らかにし、脳波測定と機械学習による、スイッチ押下音評価の可能性を探ることが本研究の目的である。

2. 押下音聴取時の脳波の測定

2.1 脳波測定実験の方法

本研究では、スイッチ押下音を被験者に聴かせ、その間の脳波を測定する実験を実施した。使用したスイッチ押下音は、先行研究 [4] で評価を行った 25 個のスイッチの押下音である。先行研究 [4] では、スイッチごとにその押下音の特性を表す因子得点が明らかになっており、本研究でも学習・分類でそれを用いる。これらのスイッチは構造によって 5 グループに分けられ、以下にそのグループ分けを示す。ただし、グループ 5 に属するスイッチ押下音は 1 個だけのため、脳波測定実験では用いたが、学習・分類には用いないこととした。

- グループ 1: 触感が深く、低い音のスイッチ (8 個: #1, 2, 3, 4, 5, 6, 22, 23)
- グループ 2: 触感が硬いスイッチ (5 個: #7, 8, 9, 12, 24)
- グループ 3: 特徴的な音のスイッチ (2 個: #10, 11)
- グループ 4: 触感が浅く、高い音のスイッチ (9 個: #13, 14, 15, 16, 17, 18, 19, 20, 21)
- グループ 5: 試作品 (1 個: #25)

まず、被験者への教示について説明する。25 種類のスイッチ音の中から所定の順に提示された音について、スイッチ押下音聴取時と休憩時の脳波を測定した。脳波測定中は顔や手足など身体全体を極力動かさないことを教示した。

次に、脳波測定実験の方法について説明する。脳波計は 32 チャンネルの測定が可能である湿式脳波計 (Emotiv, EPOC Flex) を使用した。電極は 10-20 法 [9] に基づいて設置されている。ジェル (Parker Laboratories, Spectra 360) を電極に注入して、脳波測定用アプリケーション (Emotiv, EMOTIVPRO) を用いて脳波計と被験者の頭皮との接触が十分であることを確認した後に測定を実施した。被験者にはイヤホン (Apple, EarPods) を装着させ、スイッチ音を聴かせた。脳波測定の前に、被験者自身が音がはっきりと聞こえるように音量を調節をした。

続いて、実験の流れについて説明する。スイッチ音 25 種類から、同じグループが連続しないようあらかじめ決定




図 1 グループ 3 のスイッチ音を聴かせた場合のある被験者の脳波の波形 (電極番号: F7)。横軸の単位は 1/128 s である。

した順番で 1 つ選び、それぞれのスイッチについて以下に示す手順でスイッチ音を呈示し、その間の脳波を標準化周波数 128 Hz で測定した。この流れのうち 5 秒間音を聴かせる時間を 1 セクションと呼称する。また、実験に先だって被験者に説明した後に練習セッションを行い、この流れを十分に理解させた上で実験を実施した。

1. 目を開けた状態で 10 秒間休憩させる。
2. 目を閉じた状態で 10 秒間休憩させる。
3. 5 秒間スイッチ音を聴かせる (1 セクション)。
4. 5 秒間休憩させる。
5. 3 と 4 を 2 回繰り返す。

20 名の被験者について実験を行った。被験者は、25 歳以下の男性 18 名 (日本語を母国語とする者 17 名、そうでない者 1 名)、女性 2 名 (日本語を母国語とする者 1 名、そうでない者 1 名) である。教示は日本人の被験者には日本語で実施し、日本語が母国語でない被験者には英語で実施した。

2.2 収集した脳波データ

本節では、収集した脳波データを例示する。図 1 はある被験者に、グループ 3 に属するスイッチ音を聴かせた際の脳波の波形である。波形は実験の流れのうち、最初にスイッチ音を聴かせる 5 秒間 (第 1 セクション) の、左側頭前部の電極の脳波の波形を示している。また、図 2 は、図 1 の波形について高速フーリエ変換 (FFT: Fast Fourier Transform) を行って求めた振幅スペクトルである。

他の被験者、スイッチについても同様に波形、スペクトルを確認したが、スイッチのグループ毎などで明確な傾向は見られなかった。そのためスイッチ分類のために、機械学習を用いた脳波の学習・分類が必要と考えた。また、得られた脳波データは、特に低周波数帯でノイズが含まれているため、学習・分類の前にノイズを除去するデータ処理も必要であると考えた。

3. 脳波の前処理と分類手法

前章では、脳波データを収集する実験を行い、スイッチ




図 2 図 1 に示す脳波の振幅スペクトル

表 1 脳波の名称と周波数

名称	周波数 (Hz)
δ 波	0.5~4
θ 波	4~8
α 波	8~13
β 波	13~40

分類のためにデータ処理と機械学習による分類が必要であることを述べた。本章では、そのデータ処理と機械学習による分類について述べる。

3.1 EEGLAB を用いた脳波データの前処理

前章で実施した実験により脳波データを収集したが、雑音が含まれていると見られるためその雑音の除去を実施した。その際には MATLAB 上で動作するアプリケーションである EEGLAB [8] を用いることとした。雑音除去に関して説明するのに先立ち、周波数による脳波の分類に関して簡単に記述する。

脳波は様々な周波数の波が重なって観測され、人間の状態によって異なる周波数帯の波が現れる [9]。表 1 に波の名称と周波数帯を示す。例えば、 α 波は眼を閉じてくつろいでいる際に現れやすい。前章で収集した脳波データを確認すると特に 1 Hz 以下の低周波数帯で雑音が含まれていること分かる。また、脳波測定において被験者の身体や電極が動くことなどによって、雑音の混入は避けられないため、脳波の学習前にそれを除去する前処理が必要である。

EEGLAB 上で、以下の手順で脳波データに前処理を施した。

1. 振幅の平均値を引き去る。
2. 1 Hz 以下の波を除去する。
3. 45 Hz 以上の波を除去する。
4. 独立成分分析を用いて雑音の除去を行う。

1 は、収集したデータの間で振幅の差を小さくするために実施した。2 と 3 は、上記脳波の周波数帯に基づいて雑音と見られる波を除去した。4 の処理により、複数のチャンネルを観測することで、そこから雑音とそうでない成分に分けることができ、雑音成分の除去を行う。

図 3 は、図 1 に示した脳波にデータ処理を施した結果の波形である。また、図 4 は、図 3 の波形について高速フーリエ変換を行った場合の振幅スペクトルである。この図から特に低周波成分の雑音が除去されたことを確認すること




図 3 図 1 の脳波についての前処理後の波形




図 4 図 3 の脳波の振幅スペクトル

ができる。

3.2 ニューラルネットワークの構造

脳波を機械学習で分類するにあたり、予備的に SVM (Support Vector Machine) による学習・分類を試みたが、高い精度は得られなかった。そこで、本研究では、ニューラルネットワークによる学習・分類を実施することとした。

モデルには EEGNet [10] と EEGNetT [11] を用いた。これらは 2 次元畳み込み層を複数組み合わせ合わせたニューラルネットワークであり、脳波分類において高い精度が得られることや、少ないパラメータ、特徴量で学習が可能であることから採用した。

図 5 は EEGNet と EEGNetT の概略図である。両者の違いは、図 5 における (C) と (E) について、前者は Average Pooling 層、後者は DepthwiseConv2D 層を採用しているところにあり、その他の層は共通している。これらの層は次元数を減らし過学習の抑制に寄与している。(A) は Conv2D 層であり時間的特徴を抽出する。(B) は DepthwiseConv2D 層であり、空間的特徴 (脳波のチャンネルの特徴) を抽出する。(D) は SeparableConv2D 層でありパラメータの削減に寄与している。 E はチャンネル数、 W はポイント数と対応している。本研究では、どの学習でも共通して $E = 32$ 、 $W = 32$ である。 $F1$ 、 D 、 $F2$ はそれぞれの畳み込み層におけるカーネルの大きさである。 $F2$ の値は $F1$ と D の積が最適とされており [10]、本研究では 1 から 8 までの 2 の累乗の値の中から、最適な組み合わせを採用した。学習・分類を両者で試行したところ、EEGNet の方が高い精度が得られたので、最終的には EEGNet を用いて学習・分類を




図 5 EEGNet と EEGNetT の概略図 [11]

実施することとした。

4. セクションを入れ替える交差検証

4.1 検証の目的と方法

前処理後の脳波データについて EEGNet を用いて学習・分類を実施した。分類を行う際は交差検証で性能を検証した。交差検証は、全データの中から分類対象をテストデータとして抜き出し、残りのデータで学習して正解率を測る手法である。これによって純粋な未知データに対する結果を得ることができる。

本章ではセクションを入れ替える交差検証について述べる。この検証の目的は、特定の被験者が特定のスイッチ音を繰り返して聞いた際の脳波から、共通した特徴を捉えることができるか検証することである。それゆえ、以下の検証は被験者ごと独立に行う。

まず、交差検証の方法を述べる。脳波測定実験でスイッチ音を聴いている際の脳波データを 3 セクションにわたって収集したが、そのうち 1 セクション分の脳波データをテストデータとして割り当てた。訓練データには、その際にテストデータにしなかった残り 2 セクションを割り当てた。テストデータとして割り当てるセクションを入れ替え、それぞれの結果を確認した。

4.2 ラベルにスイッチのグループを割り当てた際の結果

ラベルにスイッチのグループを割り当てた場合について説明する。ラベルとしては、試作品であるスイッチ 25 を除くスイッチのグループ 4 種類を割り当てた。学習条件は表 2 のとおりである。また、入力データとして脳波データを 32 ポイント (1/4 s) ごとに切り分け、全てのスイッチ、セクションのデータをランダムに並べて与えた。このとき、1 セクション (5 s) のデータ数は 20 となる。ここから学習条件の学習データ数 960 は、20 (1 セクションのデータ数) と 2 (セクションの数) と 24 (スイッチの数) の積から算出される。なお、20 人分のデータのうち 2 人分はデータに欠損があるため除外した。除外したデータ 2 人分は、どちらも日本人の男性のものである。

図 6 はそれぞれの被験者ごとに交差検証を行った結果である。正解率は 3 セクション分テストデータを入れ替えた

表 2 4 章における学習条件

パラメータ	値
Kerrel Length	3
F1	16
D	4
F2	64
活性化関数	Relu
学習データ数	960
エポック数	1000
バッチサイズ	64

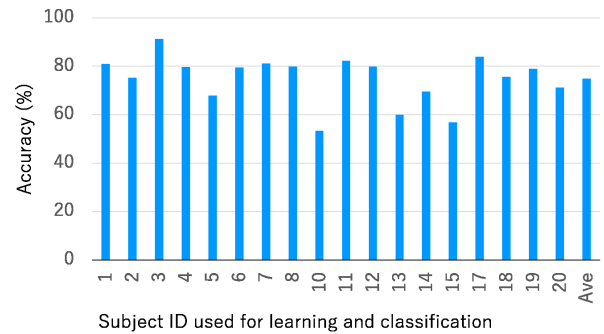


図 6 ラベルにスイッチのグループを割り当て、セクションを入れ替える交差検証の結果

結果の平均値を評価値としている。4 分類であれば学習が全くなされておらず、ランダムに値を出力するようなモデルは 25% の正解率となる。それと比較すると、被験者ごとに差が見られるが、比較的高い結果が得られたと考えられる。それぞれの被験者ごとに片側二項検定を実施したところ、正解率 25% に対して有意水準 5% で有意な差が見られた。

4.3 ラベルにスイッチの因子得点の正負を割り当てた際の結果

ラベルに因子得点の正負を割り当てた際の結果を説明する。学習条件や特徴量は、ラベルにスイッチのグループを割り当てた際と同様である。ラベルには、先行研究 [4] で明らかになっている、「積極的に音を聞いている聴取者」から得られた力動性の因子得点の正負を割り当てた。そのためラベルは 2 種類与えたこととなる。

図 7 はそれぞれの被験者ごとに交差検証を行った際の結果であり、評価値の設定方法もラベルにスイッチのグループを割り当てた際と同様である。この学習でも、2 分類であることを踏まえても高い正解率が得られた。それぞれの被験者ごとに片側二項検定を実施したところ、正解率 50% に対して有意水準 5% で有意な差が見られた。

以上のとおり、ラベルにスイッチのグループ、因子得点を与えた場合どちらについても高い正解率が得られた。ここから、特定の被験者が特定のスイッチ音を繰り返して聞いた際の脳波から、似た特徴を捉えることができると考えられる。

表 3 5章における学習条件

パラメータ	値
Kerlel Length	3
F1	16
D	8
F2	128
活性化関数	Relu
学習データ数	720 (グループ 2 をテストデータにした場合) 900 (グループ 1,4 をテストデータにした場合)
エポック数	500
バッチサイズ	64




図 7 ラベルにスイッチの因子得点の正負を割り当て、セクションを入れ替える交差検証の結果

5. スイッチを入れ替える交差検証

5.1 検証の目的と方法

本章では、スイッチを入れ替える交差検証に関して述べる。この検証の目的は、ある特定の被験者についてスイッチを聴いている際の脳波データを学習すれば、その被験者が未知のスイッチ音を聴いた際の脳波から、そのスイッチの特性を予測することができるか検証することである。

まず、交差検証の方法を述べる。この検証では訓練データに割り当てるラベルの数を等しくするため、スイッチ数の少ないグループ3とグループ5のスイッチは省いた。また、他のグループにおいてもラベルの数を等しくできるように、テストデータに割り当てるスイッチは各グループ5個、合計15個になるようにスイッチを選定した。具体的に、グループ1からは#1, 2, 3, 4, 5, グループ2からは#7, 8, 9, 12, 24, グループ4からは#13, 14, 15, 16, 17を選定した。そこからテストデータにスイッチを1つ割り当て、残りはラベルの数が等しくなるように訓練データに割り当てた。テストデータにするグループが1の場合は#6を、グループが4の場合は#18を訓練データに加え、グループが2の場合は#1, 13を訓練データから除いた。テストデータとして割り当てるスイッチを入れ替え、それぞれの結果を確認した。

5.2 ラベルにスイッチのグループを割り当てた際の結果

ラベルにスイッチのグループを割り当てた際の結果を述べる。ラベルとして上記のように、スイッチのグループ3種類を割り当てた。学習条件は表3のとおりである。分類対象としたデータと、データの欠損のために実際に学習から除いたデータは、前章のセクションを入れ替える交差検証と同様である。

図8は、それぞれの被験者ごとに交差検証を行った際の結果である。正解率はスイッチ15個分テストデータを入れ替えた結果の平均値を評価値としている。3分類であれば学習が全く上手くいっておらずランダムに値を出力する




図 8 ラベルにスイッチのグループを割り当て、スイッチを入れ替える交差検証の結果

ようなモデルは33.3%の正解率となる。それを基準として考えても、正解率は低い結果となった。

5.3 ラベルにスイッチの因子得点の正負を割り当てた際の結果

ラベルに因子得点の正負を割り当てた際の結果を説明する。学習条件や入力データはラベルにスイッチのグループを割り当てた際と同様である。またラベルの与え方は、4.3項と同じである。そのためラベルは2種類与えたこととなる。図9はそれぞれの被験者ごとに交差検証を行った際の結果であり、評価値の設定方法もラベルにスイッチのグループを割り当てた際と同様である。この学習でも、2分類であることを踏まえても正解率は低い結果となった。

ラベルにスイッチのグループ、因子得点を与えた場合どちらについても正解率は低い結果となった。ここから、ある特定の被験者のスイッチを聴いている際の脳波データを学習しても、その被験者が未知のスイッチ音を聴いた際の脳波からそのスイッチの特性を予測することは困難であると考えられる。

この原因として、分類のためのニューラルネットワークの検討が十分にできておらず、脳波データの特徴を捉えられていないことや、元々、同じグループや因子得点を持つスイッチ音を聴かせた脳波データに、共通する特徴が含まれていないことが考えられる。また、学習のデータ数が少ないことや脳波データの精度が低いこと、雑音除去




図 9 ラベルにスイッチの因子得点の正負を割り当て、スイッチを入れ替える交差検証の結果

の過程で必要な特徴も除去してしまった可能性が考えられる。

6. おわりに

我々の身の回りには、スイッチをもつ多くの製品が存在している。しかし、そのスイッチ音を評価する方法として脳波という生理量は用いられていない。そこで本研究では、スイッチ音を聴いている際の脳波を測定する実験を実施した。そして、収集した脳波データについて、機械学習による学習・分類を実施した。

ニューラルネットワークの1つである EEGNet を用いて、セクションを入れ替える交差検証と、スイッチを入れ替える交差検証という、2つの交差検証を実施した。セクションを入れ替える交差検証の結果では高い正解率が得られ、特定の被験者が特定のスイッチ音を繰り返して聴いたときの脳波から、似た特徴を捉えることができ、再現性を持つことを明らかにした。一方、スイッチを入れ替える交差検証では正解率は低い結果となり、ある特定の被験者のスイッチ音を聴いている際の脳波データを学習しても、その被験者が未知のスイッチ音を聴いた際の脳波から、スイッチの特性を予測することが困難であると考察した。

今後の課題として、スイッチを入れ替える交差検証でも、さらに高い正解率が得られるように、ニューラルネットワークを検討することが挙げられる。また、被験者を入れ替える交差検証についても高い精度が得られるよう検討することが挙げられる。また、脳波データの数を増やすことや、精度を検討することも正解率を高めることにつながると考えられる。最終的には、スイッチ音を評価する方法としての、脳波測定と機械学習による学習・分類の手法を確立したい。

参考文献

[1] Ishimitsu, S., Sakamoto, K., Arai, T., Yoshimi, T., Fujimoto, Y., and Kawasaki, K.: A study of evaluating the button sounds, Proc. Acoustics 08, pp. 3153–3158 (2008).

[2] 阪本浩二, 石光俊介, 荒井貴行, 好美敏和, 藤本裕一, 川崎健一: カーオーディオ・メインユニットのボタン押し音評価に関する検討, 日本感性工学会論文誌, Vol. 10, No. 3, pp. 375–385 (2011).

[3] Ozawa, K., Yamaji, K., Shirasaka, T., Saito, K., and Shimomura, H.: Effects of listening attitudes on affective evaluation of switch sounds, Proc. of the 5th International Symposium on Affective Science and Engineering (ISASE 2019), #C000018, 4 pages (2019).

[4] 安藤舞, 小澤賢司, 白坂剛, 下村尚登: 聴取立場がスイッチ押下音の印象に及ぼす影響に関する考察, 日本音響学会聴覚研資, Vol. 49, No. 7, H-2019-97, pp. 529–534 (2019).

[5] Ozawa, K., Yamaji, K., Shirasaka, T., Saito, K., and Shimomura, H.: The effects of tactile feedback on the affective evaluation of switch sounds, Proc. of the 6th International Symposium on Affective Science and Engineering (ISASE 2020), #C000044, 4 pages (2020).

[6] Ozawa, K., Ando, M., Shimomura, H., Shirasaka, T., and Saito, K.: Bayesian explanation of the effects of tactile feedback on the affective evaluation of switch sounds, Proc. of the 7th International Symposium on Affective Science and Engineering (ISASE 2021), #C000018, 4 pages (2021).

[7] 株式会社 SandBox: SERVICE, SandBox Inc. (online), <<https://www.sandbox-inc.com/service>> (2021–03–01).

[8] Regents of the University of California: EEGLAB, Swartz Center for Computational Neuroscience (online), <<https://scn.ucsd.edu/eeglab/index.php>> (2021–02–28).

[9] 市川忠彦: 新版 脳波の旅への誘い 第2版, p. 241, 星和書店, 東京 (2006).

[10] Lawhern J. V., Solon J. A., Waytowich R. N., Gordon M. S., Hung P. C., and Lance J. B.: EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces, Journal of Neural Engineering Vol. 15, #056013 (2018).

[11] Zhu, Y., Ozawa, K. and Kong, W.: EEGNetT: EEG-based neural network for emotion recognition in real-world applications, Proc. of the 3rd IEEE Global Conference on Life Sciences and Technologies (LifeTech 2021), pp. 380–382 (2021).