

画像想起時脳波の分類に関する研究

Study on Classification of EEG during image recall

根本渉¹⁾, 小林伸彰²⁾

Wataru Nemoto, and Nobuaki Kobayashi

1) 日本大学理工学研究科精密機械工学専攻 大学院生 (〒274-8501 千葉県船橋市習志野台7-24-1, E-mail: cswa23028@g.nihon-u.ac.jp)

2) 博(工) 日本大学理工学部 准教授 (〒274-8501 千葉県船橋市習志野台7-24-1, E-mail: kobayashi.nobuaki@nihon-u.ac.jp)

In Japan, the birthrate is rapidly declining and the population is rapidly aging. Against this backdrop, a shortage of caregivers for the elderly is becoming an issue. In addition, some people in need of care who are physically unable to move themselves also want to live their lives without inconveniencing. BMI(Brain Machine Interface), which measures neural activity in the brain and operates machines based on the signals obtained, is attracting attention as a solution to these problems. There are BMIs that use various stimuli such as P300 and motor imagery. In this study, I focused on BMIs that use image recalling and achieved high average accuracy of 78.7% in three-class classification.

Key Words : EEG, CNN, brain computer interface.

1. はじめに

現在、日本では少子高齢化が進んでおり、2021年時点での高齢者(65歳以上)の人口は3640万人で総人口の29.1%で過去最多で世界で最も高くなっている。この割合は2065年には38.4%になると見込まれている。こうした背景から高齢者の介護者の人手不足が問題視されている。また、体が動かせない要介護者自身も、他人に迷惑をかけずに生活をしたいという人もいる。こうした問題の解決策として、脳内の神経活動を測定し得られた信号により機械を操作するBMI(Brain Machine Interface)が注目を集めている。BMIは体を動かさず機械を操作できるため、要介護者自身での機器の使用や、周りとのコミュニケーションが可能になるのではないかと考えられており、実際に色刺激を利用して車椅子を操作する研究などがある。[1]

P300、運動想起など様々な刺激を利用したBMIがあり、その中でも本研究では画像想起を利用したBMIに着目した。形や色を認識する際の脳波を分類することが可能なことが知られており[3][4]、画像想起時の脳波も分類可能であると考えられる。今回は事前に準備した画像を指定し、それを想起してもらうことで、基準となる刺激を設けてそれと同じものを想起させることによって被験者が想起しやすくなり、脳波の変化をつかみやすくした。また、画像を見るだけで済むのでSSVEPなどと違い視覚呈示装置が不要なため、事前の準備が簡単なほか、想起することによって脳に刺激を与え記憶を思い出すトレーニングにもなるため、認知症予防にもつながるという利点もある。

本研究では画像想起時の脳波を測定し、EEGNet[2]という深層学習モデルによって学習を行い、画像想起時の脳波の分類を行った。

2. 実験方法

脳波の測定には8チャンネルまで測定可能なGuger Technology社製のg.Nautilus、電極には同じくGuger Tehnology社製のg.SAHARA Active electrodeを使用した。画像の認識や記憶の呼び出しは側頭葉で行われることや、色彩情報の把握が後頭葉で行われることから、電極は国際10-10法に準拠し、図1のようにT7,TP7,O1,O2,P8,TP8,T8に配置した。グランド電極は左乳様突起、リファレンス電極は右乳様突起とした。脳波は250Hzでサンプリングした。5-60Hzのバンドパスフィルタと商用電源を取り除くために48-52Hzのノッチフィルタを適用した。被験者は事前に同意を得た4人の男女(21-22歳)で、いずれの被験者も既知の神経学的障害や重大な健康上の問題を有していない。

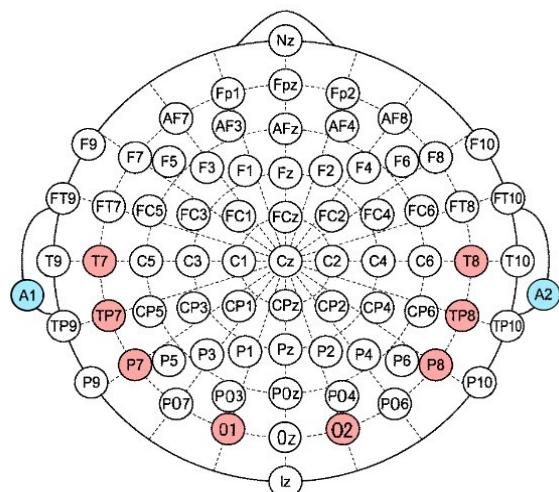


図1 国際10-10法に基づいた電極配置

次の実際の実験パラダイムについて示す。

- (1) 被験者を楽な姿勢で椅子に座らせる。
- (2) 2秒間マスク画像を表示する。
- (3) 2秒間ネコ、ウサギ、ゾウの中からランダムな画像を1枚表示する。
- (4) 3秒間再びマスク画像を表示する。
- (5) 3秒間黒い画面を表示し、(3)で表示された画像を想起する。
- (6) (2)-(5)の手順を10回繰り返す。
- (7) 約1分の休憩を与える。
- (8) (2)-(7)を1セットとし、これを10セット行い、計100試行測定する。

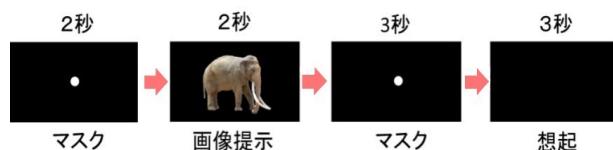


図 2 画像の表示順序

実際の実験の様子を図3に示す。

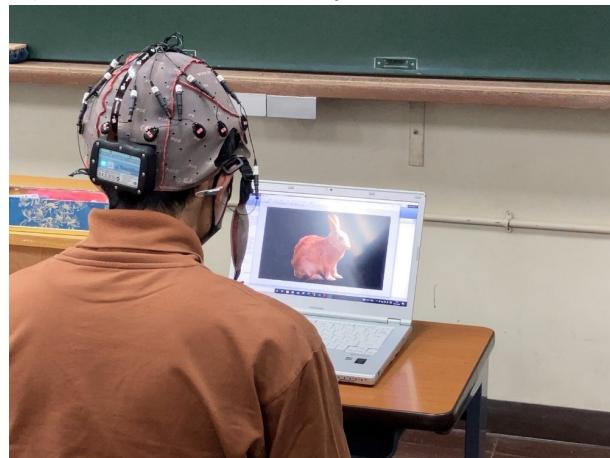


図 3 実験時の様子

上記の手順で得られたデータをEEGNetによって学習、分類する。EEGNetとはEEGの分類に特化している比較的軽量なCNN(Convolution Neural Network)のことである。Separable Convolution、Depthwise Convolution層を有している。入力データは1秒間(8x250)とする。単純に3秒間のデータを三分割すると学習データが不足するので画像想起部分の脳波データを1秒のデータを0.1秒ずつずらしてデータ拡張を行った。そのうち7割のデータを学習用データ、3割のデータをテストデータとし学習、分類を行った。また、エポック数は200とした。

3. 結果

被験者1~4の分類結果を図4~7に、すべての被験者の結果と平均をまとめたものを表1に示す。

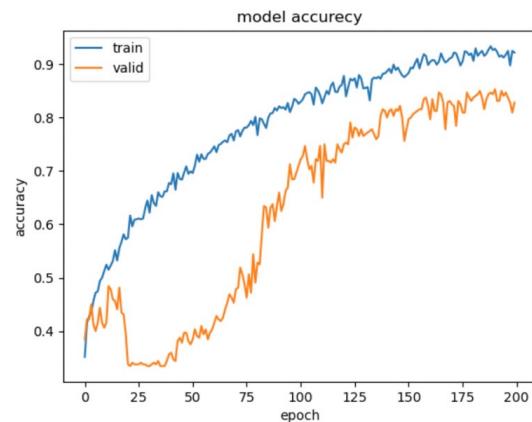


図 4 被験者 1 の分類結果

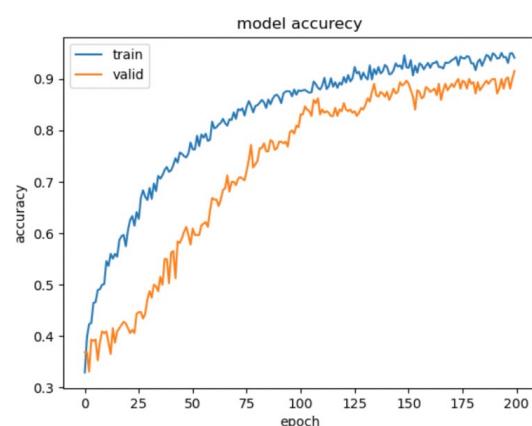


図 5 被験者 2 の分類結果

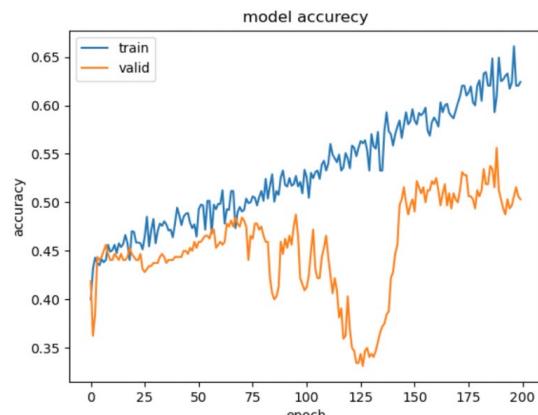


図 6 被験者 3 の分類精度

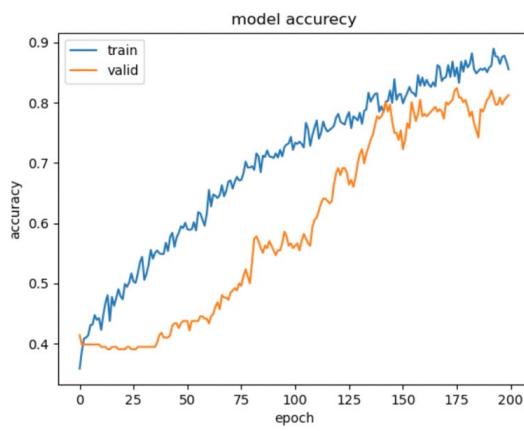


図 7 被験者 4 の分類精度

表 1 各被験者の分類精度と平均

被験者	1	2	3	4	平均
精度[%]	90.2	92.5	54.2	77.8	78.7

4. 考察

EEGNetによって画像想起時の脳波の分類を行ったところ、平均で78.7%という高い精度で分類することができた。中でも被験者4人のうち2人が90%以上という非常に高い精度を出しており、画像想起時の脳波の分類にEEGNetが非常に有効であるとわかる。

参考文献

- [1] Nafiu Hasan,Md, Mahmudul Hasan, Md. Akramul Alim: Design of EEG Based Wheel Chair by Using Color Stimuli and Rhythm Analysis, International Conference on Advances in Science, Engineering and Robotics Technology, pp. 1-4, 2019.
- [2] Vernon J. Lawhern, Amelia J. Solon, Nicholas R. Waytowich, Stephen M. Gordon, Chou P. Hung, and Brent J. Lance: EEGNet: A Compact Convolutional Neural Network for EEG-based Brain-Computer Interfaces, Journal of Neural Engineering, Vol. 15, No. 5, 2018.
- [3] Daniel Zakzewski, Ismail Jouny, and Yih Choung Yu: Statistical Features of EEG Responses to Color Stimuli, Statistical features of EEG responses to color stimuli, Annual Northeast Bioengineering Conference, pp. 1-4, 2014.
- [4] Monalisa Pal, Anwesha Khasnobish, Amit Konar,D. N. Tibarewala, R. Janarthanan: Performance Enhancement of Object Shape Classification by Coupling Tactile Sensing with EEG, International Conference on Electronics, Communication and Instrumentation, pp. 1-4, 2014.

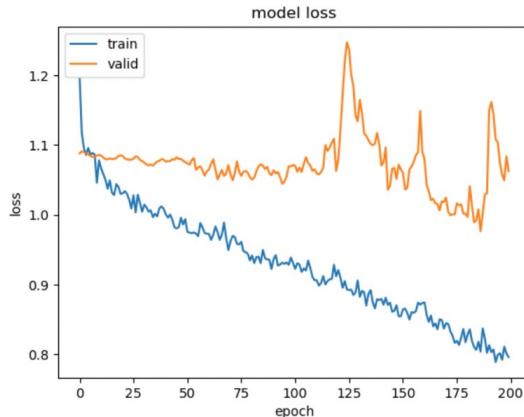


図 8 被験者 3 の損失

しかし、図8からわかるように被験者3は全体的に精度が低いことに加えて、グラフが途中で大きく下降している。図9に被験者3の学習、推論時の損失のグラフを示す。図からは後半部分での学習時の損失の減少と同時に損失の増大の傾向があり、過学習が起きている可能性が示唆されている。そのほかの要因としては、データ数の不足、騒音などにより被験者の注意が他に向いてしまったことなどが考えられる。

今回は3種類の画像で分類を試みたが、分類数を増やした際にも高い精度を維持できるかが今後の課題としていきたい。