

運動イメージの複合想起を活用した 7クラス分類の精度検証

7-class Classification Accuracy Using Complex Motor Imagery

鹿島諒¹⁾, 小林伸彰²⁾

Ryo Kashima and Nobuaki Kobayashi

1) 日本大学 精密機械工学専攻 修士 (〒274-8501 千葉県船橋市習志野台 7-24-1, E-mail:csru21019@g.nihon-u.ac.jp)

2) 博(工) 日本大学 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 this study, we aimed to realize a Brain-Computer Interface (BCI) using motor imagery for individuals with severe physical disabilities, such as bedridden patients and those with Amyotrophic Lateral Sclerosis (ALS), who cannot voluntarily control their bodies. We focused on motor imagery and examined the impact of machine learning on classification accuracy. Specifically, we considered seven classes of imagined movements: left hand, right hand, both feet, tongue, both hands, left hand + both feet and right hand + both feet. The three classes of Composite Motor Imagery—both hands, left hand + both feet and right hand + both feet—were composed of two different types of movements. We compared the classification accuracy between models trained solely using EISATC-Fusion on EEG data measured with video stimuli and models utilizing ensemble learning with EEG-TCNet, TCNet-Fusion, and EISATC-Fusion. The results showed an average improvement of 23.67% in classification accuracy.

Key Words : BMI, Motor Imagery, EEG TCNet, TCNet fusion, EISATC Fusion

1. はじめに

2025年現在、世界各地の先進国では少子高齢化が進んでいる。この増加傾向は今後も続くとみられ、2060 年には65歳以上の人口が18億人にまで到達すると見込まれている。ここで問題になるのは身体が不自由な高齢者をはじめとした、手足が不自由な要介護者の生活の質の低下である。この問題を解決するために運動想起(Motor Imagery)を用いたBCI (Brain Computer Interface), BMI (Brain Machine Interface) など、脳波を用いて機器やコンピュータを操作する研究が注目されている。脳活動で機械を制御する技術やそれを動作させるプログラムの総称を BMIと呼び、コンピュータ制御やそれを動作させるプログラムの総称を BCIと呼ぶため、どちらも根幹の技術は同じである。BMIの長所は、脳活動を用いて機械を制御するため、身体的障害がハンディキャップにならない点である。2024 年現在では、BMIに用いられる脳活動として非侵襲脳波 (EEG) の研究例が多い。また、EEGとして、外部からの刺激が与えられたとき、あるいは特定の動作を行ったときに生じたものを活用することが多い。例えば、高速で点滅する光を見る、身体を動かすイメージをする、などが挙げられる。本論文では、運動を想像することで生じる運動野周辺の脳活動を誘発する手法である運動想起 (Motor Imagery) について検討する。本研究では、寝たきりや ALS(筋萎縮性側索硬化症)患者などの自発的に身体をコントロールすることのできない肢体不自由者のため、身体的な動作を必要としない運動想起を用いたBCI の実現を目指す。

運動想起の1クラスの動作を動かしたい機器の 1 動作

とした場合、既存の左手、右手、両足、舌の4クラスでは4種類の動作しかすることができます、利便性に欠けると考えられる。そこで、動かしたい機器の種類や動作が増加した場合に備え、運動想起のクラス数を増やすことを目的とした。増加したクラスは両手、左手+両足、右手+両足の3クラスであり、複合想起として異なる2クラスの動作を組み合わせた動作である。BCIの実用化を目的に見据えた際、運動想起した際に読み取れる脳波の分類精度を高める必要がある。そのために機械学習の学習方法を変更することによって分類精度がどのように変化するのかを検証した。

2. 実験条件と方法

(1) 実験条件

脳波の測定には16チャンネルまで測定可能なGuger Technology社製のg.USBAmp, 電極には同じく Guger Technology社製のg.SAHARA Hybrid Active Electrodeを使用した。被験者は4人 (21~22歳) とし、いずれの被験者も既知の神経学的障がいや重大な健康上の問題を有していない。電極は図1のように配置した。図1に示すように、国際10-20法に従って、FZ, FC3, FC1, FCZ, C5, C3, CZ, C2, C4, CP3, CP1, CPZ, CP2, CP4, P2, POZの計16チャンネルに電極を配置した。基準電極は左側の乳様突起に配置され、接地電極は右側の乳様突起に配置した。

(2) 実験1

被験者に想起を促すための補助資料として動画を用いた運動想起時の脳波の測定を以下の(1)~(7)の手順で行った。図4に動画の表示のされ方を、図5に表示される7種

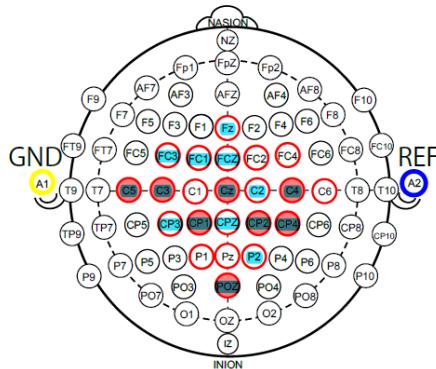


図1 電極配置

類の動画を示す。

- (1) 被験者をリラックスした状態で椅子に座らせる。
- (2) 2秒間十字の画像を表示する。
- (3) 1.25秒間、右手、左手、両足、舌、両手、左手+両足、右手+両足のいずれかの想起を指示する動画が再生される。
- (4) そのまま4秒間動画の再生を続け、この間に動画と同様の動作の想起を行う。
- (5) 2秒間真っ黒の画面を表示する。
- (6) (2)～(5)の手順を各部位ごとに12回ずつ、計84回繰り返し、これを1セットとする。
- (7) 以上を12セット行う。

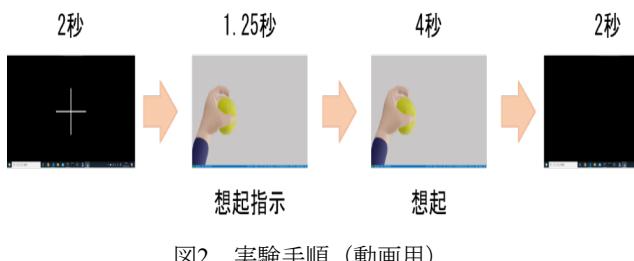


図2 実験手順（動画用）

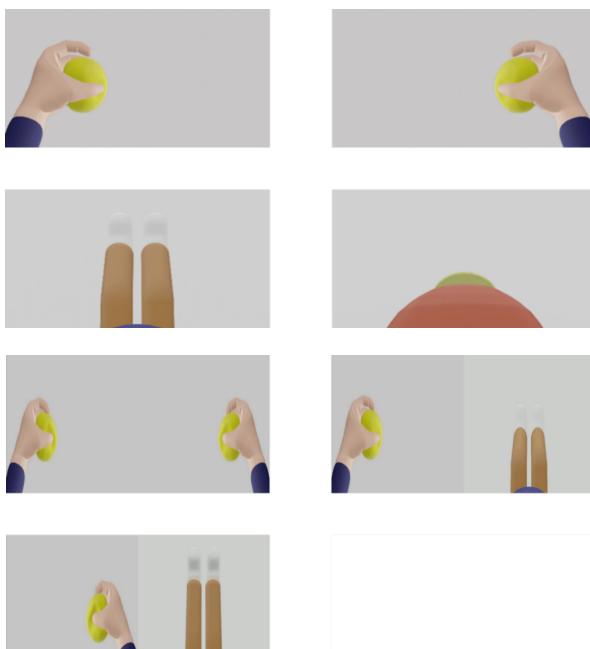


図3 想起指示用の7種類の動画

それぞれの動画で指示している運動について以下に示す。

- 左手：ボールをゆっくりと握りつぶす運動
- 右手：左手と同様の運動
- 両足：椅子に座った状態で膝を曲げ伸ばす運動
- 舌：キャンディーを舐める運動
- 両手、左手+両足、右手+両足の動きは上記の3種類の動きを横並びにして指示したものとなっている。

3. 実験結果と評価

実験1で取得した3人の被験者毎の脳波をEISATC-Fusion [1]と呼ばれる深層学習モデルを用いて学習した。また、EEG-TCNet[2], TCNet-Fusion[3], EISATC-Fusionの3モデルを使用してアンサンブル学習を行い、単一モデルとの精度比較を行った。各被験者の単一モデルでの分類精度の平均値を表1に、アンサンブル学習での分類精度を表2に示し、分類精度の比較を表したものと図7、表3に示す。

表1 各被験者の分類精度(単一モデル)

	被験者1	被験者2	被験者3	
1回目	26.69%	29.36%	31.75%	
2回目	25.20%	27.48%	31.75%	
3回目	24.61%	26.79%	33.24%	
4回目	24.11%	27.68%	31.15%	
5回目	27.39%	28.27%	31.65%	平均
平均	25.60%	27.92%	31.90%	28.47%

表2 各被験者の分類精度(アンサンブルモデル)

	被験者1	被験者2	被験者3	
1回目	54.56%	45.04%	56.35%	
2回目	48.61%	47.02%	59.52%	
3回目	46.23%	50.40%	63.49%	
4回目	52.98%	51.59%	55.16%	
5回目	50.20%	50.79%	50.20%	平均
平均	50.52%	48.97%	56.94%	52.14%

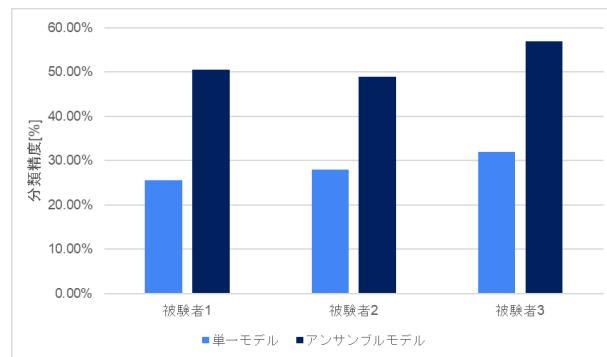


表3 単一モデルとアンサンブルモデルの精度比較

	被験者1	被験者2	被験者3	平均
精度の差	24.92%	21.05%	25.04%	23.67%

図4、表3から被験者全員の分類精度の向上を確認することができた。これは、3種類のモデルを使用したことにより、1つのモデルでは上手く分類できなかった脳波が特徴の異なるモデルを使用することで分類精度が向上し、不正解が減った分、精度が向上したと考えられる。今後は複合想起を含んだ7クラスを上手く分類するために、どのモデルのどの機構が有効な働きをしているかを調査し、複合想起を分類するのに適した深層学習モデルを構築する。

4. 結言

本研究では運動想起に着目し、複合想起を含む7クラス分類において機械学習の方法を変更することによって分類精度がどのように変化していくのかを検証した。単一モデルで学習するよりも、複数モデルでのアンサンブル学習をすることによって分類精度が向上する結果が得られた。

参考文献

- [1] Guangjin Liang. et al. "EISATC-Fusion: Inception Self-Attention Temporal Convolutional Network Fusion for Motor Imagery EEG Decoding," IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 32, pp. 1535-1545, 2024.
- [2] Thorir Mar Ingolfsson. et al. "EEG-TCNet: An Accurate Temporal Convolutional Network for Embedded Motor-Imagery Brain-Machine Interfaces," 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC), pp. 2958-2965, 2020.
- [3] Y. K. Musallam et al., "Electroencephalography-based motor imagery classification using temporal convolutional network fusion," Biomed. Signal Process. Control, vol. 69, 2021.