

運動想起を用いたBCIにおける脳波分類モデルの最適化とエッジデバイス実装に向けた検討

Optimization of Motor Imagery classification models for BCI-Edge Device Implementation

久保俊輔¹⁾, 小林伸彰²⁾

Shunsuke Kubo and Nobuaki Kobayashi

1) 日本大学 精密機械工学専攻 修士 (〒274-0063 千葉県船橋市習志野台7-24-1, E-mail: cssh25007@g.nihon-u.ac.jp)

2) 博(工) 日本大学 准教授 (〒274-0063 千葉県船橋市習志野台7-24-1, E-mail: kobayashi.nobuaki@nihon-u.ac.jp)

This study utilized a brain-computer interface (BCI) that uses motor imagery to construct and evaluate famous EEG classification models to support rehabilitation for patients with stroke or lower limb paralysis. We used motor imagery data from PhysioNet, an international benchmark, to compare four deep learning models, including EEGNet. We investigated the optimization of classification accuracy and the number of electrodes. As a result, we confirmed that classification accuracy of over 80% can be maintained with a minimum of 11 channels. In addition, when comparing classification accuracy when the number of subjects was increased, it was determined that EISATC-FUSION was optimal for improving accuracy and that EEGNet was optimal for edge device implementation. From the above, it was found that EEGNet is a model that excels in accuracy, is lightweight and is suitable for real-time processing. In the future, we will consider verification in real environments and expansion to multi-class classification.

Key Words : BCI, motor imagery

1. はじめに

世界各国で問題となっている少子高齢化によって、脳卒中や下半身まひなどの患者が増加しているのに対して、担当する医師の不足によって効果的なリハビリを行えないという問題がある。この課題を解決するために運動想起(Motor Imagery)を用いたBCI(Brain Computer Interface)という人の脳と外部のデバイスを接続する技術についての研究が注目されている。本研究では、身体を自分の意志で自由に動かせない肢体不自由者の機能回復を目的とし、運動想起を用いてBCIを活用した新たなリハビリテーションシステムの構築に向けて、PhysioNet内のデータセットを活用し、実運動時と想起時の脳波を使って深層学習モデルを作成し、それぞれの精度を検証した。また、エッジデバイスなどのメモリ容量に制約があるデバイスへの実装を考え、データ数をなるべく小さくする必要があることから、精度を保てる最小のチャンネル数を模索し、モデルサイズや総パラメータ数といった性能の比較を深層学習モデルごとに検証・評価した。

2. 実験条件

本実験ではPhysioNet にあるニューヨーク州保健局ワズワースセンターのBCI R&D プログラムでGerwin Schalk(schalk at wadsworth dot org)氏とその同僚によって作成されたデータセットを活用した。本データセットは被験者に対して図1のように電極を付けてもらい、2分間で右手左手の開閉を実運動 or 想起したものを1タスクとして、これを3回繰り返したもので構成される。

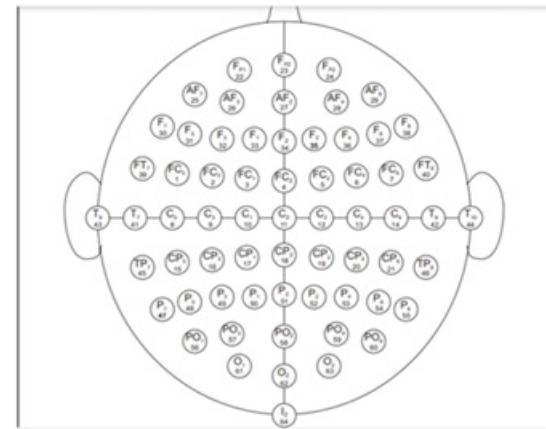


図1 64チャンネルの電極位置

3. 実験方法

(1) 実験I

まず「モデルの精度とチャンネル数の削減」を目的として以下の①～③の方法で行った。

- ① データセットから、タスク1の(右手左手を実際に開閉する)ファイルをEEGNet モデルで学習させ、出力結果を記録する。
- ② 同じように「動かす想像をした」時のデータセットでの出力結果を記録する。
- ③ チャンネル数を2、5、8と最小の電極数から増やしていく、64チャンネルの精度と同程度持てる必要最小限のチャンネルを選定する。

(2) 実験II

次に「EEGNet以外のモデルとの精度比較とエッジデバイス実装」を目的とした実験IIは以下の①～④の方法を行った。

表1 チャンネル数ごとの分類精度

被験者10人分の平均値										
\	64チャンネル	2チャンネル	5チャンネル	8チャンネル	9チャンネル	9チャンネル2	10チャンネル	10チャンネル2	11チャンネル	平均値
	平均値	平均値	平均値	平均値	平均値	平均値	平均値	平均値	平均値	
想起時	86.14%	75.60%	75.07%	78.66%	77.06%	79.19%	79.33%	79.60%	81.46%	
実運動時	85.71%	76.54%	80.27%	82.27%	81.47%	81.47%	82.53%	82.53%	81.73%	

表2 11チャンネルにおける50人分の出力結果: EEGNet

EEGNet	モデル: 2205	テスト: 45	モデル(s1～s50): 10パターン(11チャンネル:Fz,FC3,FC4,C3,Cz,C4,CP3,CP4,Pz,時間サンプル数481)										
			test5	test10	test15	test20	test25	test30	test35	test40	test45	test50	平均値
想起時	68.00%	67.58%	100.00%	85.78%	69.33%	80.88%	92.44%	81.76%	79.58%	78.24%	80.36%		
実運動時	84.44%	68.90%	85.32%	81.78%	78.24%	89.78%	91.12%	87.12%	77.36%	89.34%	83.34%		
訓練時間(秒)	500	600	500	500	520	550	450	550	500	400	507		
	8分20秒	10分00秒	8分20秒	8分20秒	8分40秒	9分10秒	7分30秒	9分10秒	8分20秒	6分40秒	4分50秒		

表3 11チャンネルにおける50人分の出力結果: EEG_TCNet

EEG_TCNet	モデル: 2205	テスト: 45	モデル(s1～s50): 10パターン(11チャンネル:Fz,FC3,FC4,C3,Cz,C4,CP3,CP4,Pz,時間サンプル数481)										
			test5	test10	test15	test20	test25	test30	test35	test40	test45	test50	平均値
想起時	68.88%	66.66%	99.12%	89.34%	72.00%	80.88%	93.78%	83.98%	84.42%	83.10%	82.22%		
実運動時	82.20%	73.34%	89.34%	84.44%	76.00%	88.90%	91.10%	90.22%	80.00%	92.42%	84.80%		
訓練時間(秒)	610	600	450	520	600	600	700	600	520	650	585		
	10分10秒	10分00秒	7分30秒	8分40秒	10分00秒	10分00秒	11分40秒	10分00秒	8分40秒	6分50秒	9分45秒		

表4 11チャンネルにおける50人分の出力結果: EEG_Conformer

EEG_Conformer	モデル: 2205	テスト: 45	モデル(s1～s50): 10パターン(11チャンネル:Fz,FC3,FC4,C3,Cz,C4,CP3,CP4,Pz,時間サンプル数481)										
			test5	test10	test15	test20	test25	test30	test35	test40	test45	test50	平均値
想起時	67.55%	66.97%	99.27%	88.14%	68.30%	80.29%	91.99%	83.11%	85.04%	82.51%	81.32%		
実運動時	84.44%	73.30%	87.56%	85.78%	76.42%	88.02%	92.00%	89.34%	80.00%	91.54%	84.84%		
訓練時間(秒)	800	950	900	800	800	850	770	840	900	950	856		
	13分20秒	15分50秒	15分00秒	13分20秒	13分20秒	13分50秒	12分50秒	14分00秒	15分00秒	15分50秒	14分16秒		

表5 11チャンネルにおける50人分の出力結果: EISATC_FUSION

EISATC_FUSION	モデル: 2205	テスト: 45	モデル(s1～s50): 10パターン(11チャンネル:Fz,FC3,FC4,C3,Cz,C4,CP3,CP4,Pz,時間サンプル数481)										
			test5	test10	test15	test20	test25	test30	test35	test40	test45	test50	平均値
想起時	67.10%	67.14%	100.00%	85.78%	70.24%	83.98%	94.68%	85.76%	84.42%	83.10%	82.22%		
実運動時	83.54%	71.98%	89.34%	85.32%	75.12%	87.12%	96.04%	89.78%	82.20%	91.54%	85.20%		
訓練時間(秒)	800	900	600	800	960	800	750	800	700	900	801		
	13分20秒	15分00秒	10分00秒	13分20秒	16分00秒	13分20秒	12分30秒	13分20秒	11分40秒	15分00秒	13分01秒		

- ① 実験Iで選定したチャンネルだけを使い、10人分の脳波データの内9人分をEEGNetモデルの学習、1人分をテスト用データに分類して精度を記録する。
- ② 学習するモデルを変更(EEG-TCNet、EEG-Conformer、EISATC FUSION)し、同じように精度を記録し比較する。
- ③ 被験者のデータを30人、50人と増やした時の(テストデータは1人分)、精度を記録し比較する。
- ④ 各モデルの最大メモリ使用量、1回の推論時間、モデルサイズ、モデルの総パラメータ数を記録・比較し、エッジデバイスに最適なモデルを選定する。

4. 結果

実験Iの結果としてチャンネル数での分類精度を表1に示す。表1の結果から、チャンネル数が増加すると分類精度は上昇することが分かり、最適な配置を模索した結果、図2に示した11チャンネルが最適であることが分かった。

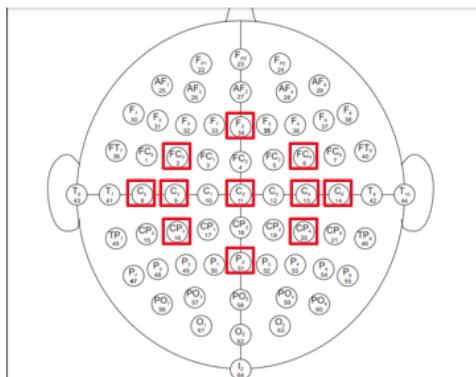


図2 11チャンネルの電極配置

実験IIで人数を増やした時の一例として50人の分類精度を表2~5に示す。また、モデル性能の比較を表6~9に示す。

表6 EEGNetのメモリ使用量、推論時間、サイズ、総パラメータ数(10~50人)

EEGNet		サイズ(MB)	総パラメータ数(-)
メモリ使用量(MB)	推論時間(ms)		
0.36	0.25	0.01	1,762
0.36	0.25	0.01	1,762

表7 EEG_TCNetのメモリ使用量、推論時間、サイズ、総パラメータ数(10~50人)

EEG_TCNet		サイズ(MB)	総パラメータ数(-)
メモリ使用量(MB)	推論時間(ms)		
0.38	0.315	0.03	3,846
0.38	0.315	0.03	3,846

表8 EEG_Conformerのメモリ使用量、推論時間、サイズ、総パラメータ数(10~50人)

EEG_Conformer		サイズ(MB)	総パラメータ数(-)
メモリ使用量(MB)	推論時間(ms)		
3.42	0.35	0.03	3,846
3.42	0.35	0.03	3,846

表9 EISATC_FUSIONのメモリ使用量、推論時間、サイズ、総パラメータ数(10~50人)

EISATC_FUSION			
メモリ使用量(MB)	推論時間(ms)	サイズ(MB)	総パラメータ数(-)
2.4	0.75	1.1	280,645
2.4	0.75	1.1	280,645

5. 考察

実験Iから、64チャンネルでの実運動時と想起時の分類精度は、約8割の確率で正しい判断ができることが分かり、10人分のデータの平均を取ると想起時が86.1%、実運動時が85.7%という精度から有効性は高いと考えられる。次に徐々に電極数を増やして分類を行ったところ、実運動時、想起時がともに11チャンネルで80%を超えたことから、脳波を必要最小限なチャンネル数と選定した。また9チャンネル、10チャンネルで行った実験において、同じチャンネル数で電極の配置だけを変更した結果を見ると、想起時の分類精度が上昇している事から、電極の配置によって分類精度に影響を与えると考えられる。実験IIから、被験者のデータを10人、30人と増やした時の分類精度を見ると、EEGNetの想起時は83.4%から88.70%になり、実運動時では82.9%から84.6%と上昇し、他のモデルでも分類精度は上昇しており、EISATC-FUSIONでは想起時に89.3%と90%近い値となった。このことから、モデルの学習に使用するデータを増やすことで、分類したいクラスについての特徴量が明確化された事やノイズの軽減、過学習の抑制などによって分類精度が向上すると考えられる。しかし50人での結果を見ると、どのモデルも30人に比べて分類精度が低下する結果となってしまった。そのため、モデルに使う人数をむやみに増やしても分類精度が上昇するわけではないと考えられる。次にモデルのメモリ使用量、推論時間、モサイズ、総パラメータ数についての比較結果から、実験で使用した4モデルの中では、EEGNetが被験者数の増加に対しても一定の分類精度を維持しつつ、モデルの軽量化も実現できることが確認された。この二つの実験結果から、エッジデバイスへの実装に最も適したモデルはEEGNetであると考えられる。

参考文献

- [1] 甘利俊一, 「脳・心・人工知能」, 講談社ブルーバックス, 2016.
- [2] 株式会社マクニカ「脳波とは何か?」- AI事業 - マクニカ, <https://www.macnica.co.jp/business/ai/manufacturers/innereye/135664> (閲覧日: 2025年1月11日)
- [3] ビジネスマディアReinforz Insight「未来の医療を支え

る技術：侵襲型と非侵襲型ブレインテックの計測方法とその革新」, <https://reinforz.co.jp/bizmedia/23923/>
(閲覧日：2025年1月13日)

- [4] Note「要注目の侵襲型Brain Machine Interface (BMI)企業の動向や今後の展望」, https://note.com/daichi_konno/n/na3202fb0585d (閲覧日：2025年1月13日)
- [5] 曹建庭, 脳・コンピュータインターフェイス (BCI)システムの基礎と応用, 埼玉工業大学学術研究成果コレクション, https://sit.repo.nii.ac.jp/records/2000024/file_details/, (閲覧日：2025年1月14日)