

令和 6 年 5 月 24 日現在

機関番号：32665

研究種目：基盤研究(C)（一般）

研究期間：2021～2023

課題番号：21K12789

研究課題名（和文）深層学習エッジコンピューティングによる高効率なIoT向け脳 機械デバイスの開発

研究課題名（英文）Highly Efficient Brain-Machine Edge Devices Using Deep Learning for IoT

研究代表者

小林 伸彰（KOBAYASHI, Nobuaki）

日本大学・理工学部・准教授

研究者番号：50611422

交付決定額（研究期間全体）：（直接経費） 2,400,000円

研究成果の概要（和文）：要介護者の居住環境における快適性を向上し、介護職従事者の負担を軽減するために、要介護者が能動的に脳波（EEG）を用いて機械制御を可能とするブレイン・マシン・インタフェース（BMI）技術の確立が期待されている。本研究では、運動想起（MI）時のEEGに着目し、深層学習を用いてMIを分類する際の処理の高効率化に主眼を置いた。MIは学習に大量のデータを必要とするため、要介護者の負担が増大する。そこで過去に学習したモデルの重みを再学習して微調整することで高い分類精度を実現し、かつ学習に必要なデータ量を削減した。その結果、長時間使用可能・応答遅延を最小限に抑えられるBMIを実現した。

研究成果の学術的意義や社会的意義

要介護者のQoLの向上、また、介護職従事者の仕事量を減少することを目的に、実用化に向けたBMI型IoTデバイスの構築が目的である。このためには、「脳活動の高い識別精度」、「居住環境ノイズ下での使用に耐え得る」、「長時間使用によるユーザの使用負担を軽減する」、「遅延量を最小化する」、「消費電力を低減し使用時間を長くする」、といった要件を同時に満たす必要がある。これまでになく低遅延性・低消費電力性を兼ね備える高効率なBMI型IoTデバイスを開発・実証することで、BMIの介護分野における普及、IoT分野の進展に大きく貢献することが期待される。

研究成果の概要（英文）：Brain-machine interface (BMI) technology that enables carers to actively control machines using electroencephalography (EEG) is expected to improve the comfort of people requiring care in their living environment and reduce the burden on care workers. The main focus of this study is on EEG during motor imagery (MI) and on improving the processing efficiency of MI classification using deep learning, which requires a large amount of data for training, increasing the burden on carers. Therefore, the weights of previously trained models were re-trained and fine-tuned to achieve high classification accuracy and reduce the amount of data required for training. As a result, a BMI that can be used for long periods of time and with minimal response delay has been achieved.

研究分野：brain-machine interface, digital circuit

キーワード：EEG Brain-machine interface Brain-computer interface Edge computing IoT

様式 C-19、F-19-1 (共通)

1. 研究開始当初の背景

要介護者の行動制約を緩和することは、要介護者の QoL を向上させるだけでなく、介護職従事者の負担を軽減し、かつ、日本、ひいては世界中の少子化問題を抱える国々における介護職就労者の減少を救う一助となり得る。

2. 研究の目的

上下肢に機能障害を抱えるような要介護者にとって居住環境の快適性と QoL には密接な関係がある。家電製品や機械を脳活動のみの情報で制御するブレイン・マシン・インタフェース (BMI) を介護現場で活用することにより、要介護者の行動制約の緩和やストレスの軽減が期待でき、かつ、介護職従事者の仕事を減らすことになる。本研究では、長時間使用可能・応答遅延を最小限に抑えられる BMI を IoT エッジデバイス (IoT-Dev) 上で実現する。非侵襲式 EEG 計測で得られた脳波信号を深層学習により高精度に識別し、制御信号を無線で対象機器に送出する。一連の処理をデバイス上で完結させるエッジコンピューティング (EdgeCom) により高効率な BMI 型 IoT-Dev を開発する。

3. 研究の方法

(1) 被験者の協力を得て、同様の運動想起 (MI) 取得用の実験タスクを用いて、居住環境下でノイズが含まれる状態でこれらを取得し、深層学習ニューラルネットワークワーク (DNN) の学習データセットとして用いる。また、学習に必要な MI 取得実験の試行数を被験者毎に調べ、最適な値を得る。また、最適化された DNN の規模に応じ、効率的で最適な性能を備える IoT-Dev を選定する。高効率なマイクロコントローラ (MCU) を搭載する市販の IoT-Dev でその効果を検証する。

(2) より被験者の負担を小さくするために、MI 想起を簡単に行う訓練方法を複数試す。例えば、世界的にベンチマークとして最もよく用いられるデータセット BCI competition IV-2a on 4-class MI を用いた世界最高精度は TPCT と呼ばれるモデルを用いた場合で、90% 近くの識別率を達成するが、モデルが非常に大きい (パラメータ数が 10^7 オーダー)。よって、より特徴量が得られやすい MI 想起実験、モデル学習 (訓練) 方法を策定する。

4. 研究成果

(1) 運動想起 (MI) の識別に必要なチャンネル数の削減を目的とした最適化を行った。BCI competition IV-2a on 4-class MI をベースとし、EEGNet と呼ばれる脳波に特化した深層学習ネットワークを対象にチャンネル数と分類精度の関係を以下の手順にて調べた。

- ・ n 個のチャンネルから r 個 ($r=n-2$) を取り出して学習させる (${}_{22}C_{20}=231$)。
 - ・ 全学習結果の組み合わせから精度の高い 10 個の組み合わせと精度の低い 10 個を抽出する。
 - ・ 抽出した組み合わせのチャンネルの頻出回数に着目し、有用性の低いチャンネルを特定する。
 - ・ 抽出された回数 (登場回数) が等しい場合、15 個に範囲を広げてチャンネルの選定を行う。
 - ・ 15 個でも等しい場合、精度が高いチャンネルの組み合わせで学習を行い、削除するチャンネルを選定する。
 - ・ これを 22 チャンネルから 16 チャンネルまで行う。
- 続いて、以下の手順にて精度を保つことが可能なチャンネル数の最下限を特定する。
- ・ 16 チャンネル以降は、1 チャンネルずつチャンネルの選定を行う。
 - ・ 16 個のチャンネルから 15 個を取り出して 2 回学習させる (${}_{16}C_{15} \times 2=32$)。
 - ・ 2 回平均で高精度の組み合わせを特定する。
 - ・ 特定したチャンネルの組み合わせを使用して、同条件で 10 回学習させる。
 - ・ これを繰り返し行い、精度が維持できる最下限のチャンネル数を特定する。

以上の手順にて得られた結果を図 1 に示す。チャンネル数を減らしても被験者 9 名の平均精度は 11 チャンネル程度までは 70% 程度を維持し、ほぼ減少は見られないが、10 チャンネルから徐々に下降する。ただ、6 チャンネルまでは 68% 程度の識別精度を維持できるが、5 チャンネル以降に大きな下降が見られ、4 チャンネルでは約 64% まで減少した。以上より、MI の分類精度の劣化をある程度抑えたい場合にはチャンネル数は 6 チャンネル以上使用したほうが良

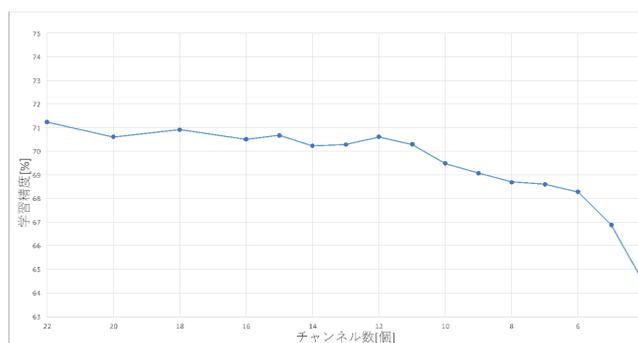


図 1 学習精度とチャンネル数の関係

いと言える。

(2) (1)により少ないチャンネル数でもある程度の分類精度を維持できることが分かった。続いて、使用者が毎日使うことを考慮し、MI 測定時の電極へのゲル使用をなくし、少ない電極（今回は8チャンネル）、ドライ電極でMI測定（実験1）を行った。

この実験により得られたMIを(1)と同じ条件で学習させた時のMIの分類精度を表1に示す。その結果、被験者4名における分類精度は約34~40%程度で低い値であった。ドライ電極は湿式電極よりも皮膚との接触インピーダンスが高く、ノイズが脳波信号に重畳しやすいことが原因と考えられる。よって、特徴量がより向上することを目的に、動画をMI誘発の補助資料に用いることで、被験者がより容易にMIを想起しやすくした。具体的には以下の手順とした。

・被験者をリラックスした状態で椅子に座らせる。

・2秒間十字の画像を表示する。

・1.25秒間、右手、左手、脚、舌のいずれかの想起を指示する動画が再生される。

・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。

・2秒間真っ黒の画面を表示する。

上記の手順を各部位ごとに12回ずつ、計48回繰り返し、これを1セットとし、以上を12セット行う。

なお、被験者に実際に提示した画像を図2に示す。本実験（実験2）により得られたMIを用いて同条件にて分類した結果、分類精度は約45%~66%程度に向上が見られた。以上より、動画によるMIの誘発はある程度効果が見込めることが分かった。

表1 各被験者の分類精度の平均値

被験者	1	2	3	4
実験1[%]	34.72	40.97	40.14	39.58
実験2[%]	45.14	58.33	65.97	60.42

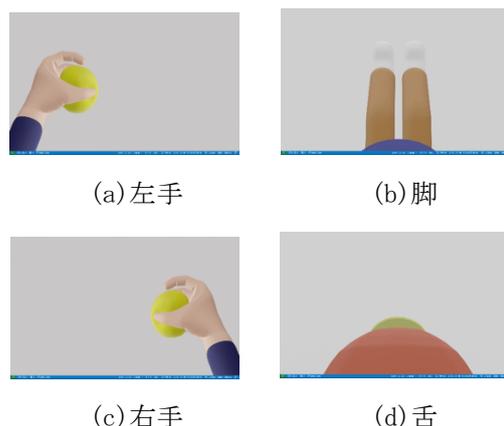


図2 想起指示用の4種類の動画

(3) 本実験ではEEGNet, EEG TCNet, TCNet Fusionの3つの深層学習ネットワークをARM Cortex-A72を搭載したRaspberry Pi 4 Model Bに実装し、その実行速度の比較を行った。処理速度の計測は、c言語のclock関数を用いてCPUのクロックを用いて計測を行った。また、計測結果はテストデータの4.5秒の入力データに対して出力されるまでの時間で行い、各被験者に入力データ数の平均を結果として使用した。ネットワーク毎の処理速度を表2に示す。各ネットワーク別で比較した場合、パラメータ数が増加するほど分類精度が高い結果が得られた。Tensorflow liteの重み係数を用いた結果では、pythonとc言語で異なる結果が得られた。Pythonとc言語で評価関数の構造に違いがあるためだと考えられる。以上より、実装方法により精度に違いが見られた。また、表3にはネットワークとCPU別の推論速度を示した。

表2 各深層学習ネットワークの重み係数別分類精度

model	EEGNet			EEG TCNet			TCNet Fusion					
	param	accuracy[%]			param	accuracy[%]			param	accuracy[%]		
被験者		python(.pth)	python(.tflite)	c(.tflite)		python(.pth)	python(.tflite)	c(.tflite)		python(.pth)	python(.tflite)	c(.tflite)
s1	2538	83.63	82.92	76.07	5680	81.14	79.00	73.93	20368	82.21	80.43	76.07
s2		61.84	49.12	49.29		63.25	51.59	51.06		59.72	55.83	54.61
s3		92.31	85.71	84.93		90.48	87.55	81.99		90.48	86.08	81.62
s4		64.91	60.09	56.83		71.05	67.11	61.67		74.56	69.30	63.88
s5		60.87	53.99	54.18		73.55	70.29	64.36		79.35	72.10	65.45
s6		64.65	60.47	57.48		65.58	58.60	56.07		63.72	61.40	58.88
s7		88.45	77.26	76.09		85.56	81.23	78.62		88.45	86.64	83.33
s8		80.07	72.69	68.89		80.81	73.80	71.48		83.39	81.92	74.07
s9		82.58	80.30	77.57		74.62	73.48	70.34		82.58	76.89	73.38
average		75.48	69.17	66.81		76.23	71.41	67.73		78.27	74.51	70.14

表3 各深層学習ネットワークとCPU別推論速度

model	EEGNet		EEG TCNet		TCNet Fusion	
c言語(.tflite)	1試行あたりの推論速度(s)					
device	AMD Ryzen 5 PRO 4650G	Raspberry Pi 4 Model B	AMD Ryzen 5 PRO 4650G	Raspberry Pi 4 Model B	AMD Ryzen 5 PRO 4650G	Raspberry Pi 4 Model B
s1	0.00674	0.02082	0.00719	0.01392	0.01078	0.01764
s2	0.00593	0.02041	0.00708	0.01436	0.01002	0.01768
s3	0.00627	0.02060	0.00684	0.01435	0.01086	0.01753
s4	0.00645	0.02046	0.00667	0.01455	0.00928	0.01757
s5	0.00624	0.02076	0.00688	0.01457	0.01052	0.01765
s6	0.00676	0.02036	0.00711	0.01464	0.01063	0.01897
s7	0.00677	0.02059	0.00722	0.01451	0.01072	0.01926
s8	0.00666	0.02077	0.00675	0.01451	0.00959	0.02280
s9	0.00672	0.02042	0.00688	0.01465	0.01047	0.02319
average	0.00650	0.02058	0.00696	0.01445	0.01032	0.01914

以上をまとめると、3つの深層学習モデルで最適化された tensorflow lite を扱い、各ネットワークの分類精度とエッジデバイスとc言語を用いて推論速度に関して比較、評価を行った。その結果、深層学習ネットワークのパラメータ数を増加させると分類精度が高くなる結果が得られた。推論速度は、AMD Ryzen ではパラメータ数を増加させると推論時間が増加する結果が得られた。Raspberry Pi では、パラメータ数を増加させても EEG TCNet に関しては推論時間が減少する結果が得られた。TCNet Fusion は EEGNet よりも推論時間が短縮されたが、EEG TCNet よりも推論時間がかかった。このことから、エッジデバイスへの実装としては EEG TCNet が最適であると考えられる。

要介護者が居住環境で簡便に利用可能な BMI を構築するには、①ウェアラブル性、②超低遅延性、③低消費電力性を満たす必要がある。①は、少ない電極数で、頭皮への接触を最小限に抑え、かつ、皮膚との接触インピーダンスを低く抑えるためのゲルやペーストといった材料を用いない乾式電極とすることで長時間使用によるユーザの負担を緩和することができる。②はエッジコンピューティングと呼ばれる、IoT デバイス自身に処理能力を持たせる技術で解決できる。③は②とも関連し、クラウド方式ではデータ転送に係る消費電力が大半を占めるのに対し、エッジコンピューティングはセンサ機構（脳波取得）と処理機構を同デバイス上に配置することで高効率性を備えることができ、また、ユーザ使用時の快適性の確保、また、ローカルシステム上で処理が完結することによるデータの機密保持、プライバシーの確保といったメリットもある。ただし、EEG の識別精度を上げるための深層ニューラルネットワークは従来の機械学習技術と比べ処理量が大きく、また、ネットワークの規模による使用メモリ容量も大きいため、③との両立が難しい。以上の課題に対して、本研究課題ではリアルタイム処理を軸として、実使用に耐えうるためのシステム、という水準においてはある程度克服できたものと考えている。具体的には、①MI を少ないチャンネル数（8）で Raspberry Pi 程度の市販の安価な IoT デバイスで実行時間を 10~20msec 程度と実際の使用に耐えうるオーダーの処理時間でリアルタイム処理が可能なことを示した。今後はさらなる分類精度の向上、深層学習モデルの学習時間の短縮、パラメータ数の縮小によるメモリ使用量の削減など、より高速な処理、低消費電力が可能なシステムを構築することができるよう、詳細な部分のシステムの利便性の向上が求められる。また、普及性を見込むためには、コストを抑える必要があるため、現状でコストが高い脳波計測部分のセンサ機構の簡易化、これに伴う精度の劣化を如何に抑えるか、といった課題の解決が必要である。

5. 主な発表論文等

〔雑誌論文〕 計4件（うち査読付論文 4件/うち国際共著 0件/うちオープンアクセス 0件）

1. 著者名 Nobuaki Kobayashi, Tomoya Nemoto and Takahiro Morooka	4. 巻 1
2. 論文標題 High Accuracy Silent Speech BCI Using Compact Deep Learning Model for Edge Computing	5. 発行年 2023年
3. 雑誌名 2023 11th International Winter Conference on Brain-Computer Interface (BCI)	6. 最初と最後の頁 1-6
掲載論文のDOI（デジタルオブジェクト識別子） 10.1109/BCI57258.2023.10078589	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Musashi Ino, Kono Yoshihiro and Nobuaki Kobayashi	4. 巻 1
2. 論文標題 Effect of Electrooculography on Electroencephalography Classifying Accuracy in Deep Learning and Reducing Number of Channels in Motor-Imagery Brain-Computer Interface	5. 発行年 2022年
3. 雑誌名 2022 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)	6. 最初と最後の頁 1173-1180
掲載論文のDOI（デジタルオブジェクト識別子） 10.23919/APSIPAASC55919.2022.9980232	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Wataru Nemoto, Nobuaki Kobayashi	4. 巻 1
2. 論文標題 Classification Accuracy of Deep Learning in SSVEP Using Smart Glasses and LCD	5. 発行年 2023年
3. 雑誌名 2023 International Symposium on Image and Signal Processing and Analysis (ISPA)	6. 最初と最後の頁 1-5
掲載論文のDOI（デジタルオブジェクト識別子） 10.1109/ISPA58351.2023.10279473	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Haruto Yagyu, Nobuaki Kobayashi	4. 巻 1
2. 論文標題 Optimizing Amount of Training Data and Classification Accuracy for Newly Measured Motor Imagery Using Fine-Tuning	5. 発行年 2023年
3. 雑誌名 2023 International Symposium on Image and Signal Processing and Analysis (ISPA)	6. 最初と最後の頁 1-6
掲載論文のDOI（デジタルオブジェクト識別子） 10.1109/ISPA58351.2023.10279756	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

〔学会発表〕 計0件

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
--	---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------