

Reconstruction of functional magnetic resonance imaging images using electroencephalogram signals with the method of autoencoder densely connected convolutional networks

Mahdi Arjmand¹ , Saeed Setayeshi^{2*} , Manouchehr Kelarestaghi³, Javad Hatami⁴

1. PhD Candidate of Cognitive Modeling, Department of Cognitive Modeling, Institute for Cognitive Science Studies, Tehran, Iran
2. Associate Professor, Department of Nuclear Engineering, Faculty of Physics and Energy Engineering, Amirkabir University of Technology, Tehran, Iran
3. Assistant Professor, Department of Electrical and Computer Engineering, Technical and Engineering Faculty, Khwarazmi University, Tehran, Iran
4. Associate Professor of Psychology, University of Tehran and Higher Education Institute of Cognitive Sciences, Tehran, Iran

Abstract

Received: 21 Jul. 2022
Revised: 29 Aug. 2022
Accepted: 1 Sep. 2022

Keywords

Deep learning
 Markov transfer field
 DenseNet
 fastICA
 Autoencoder networks

Corresponding author

Saeed Setayeshi, Associate Professor, Department of Nuclear Engineering, Faculty of Physics and Energy Engineering, Amirkabir University of Technology, Tehran, Iran

Email: Setayesh@aut.ac.ir



doi doi.org/10.30514/icss.24.3.105

Introduction: The data used in this study consists of the simultaneous recording of functional magnetic resonance imaging (fMRI) images and Electroencephalography (EEG) signals during the cognitive task of moving random dots to measure the confidence level in perceptual decision-making. This research reconstructs fMRI images using electroencephalogram signals.

Methods: EEG data assumed the model input and fMRI image data as model output, and the model learns how to generate output format data from input format data. Before entering the data into the model, the input data are pre-processed to increase the model accuracy by removing the artifacts with the fast algorithm for Independent Component Analysis (fastICA) method and transforming them into the Gramian matrix.

Results: Compared to other methods, the model has shown appropriate superiority, including in the execution time and the model accuracy.

Conclusion: The proposed deep convolutional learning model succeeded in simulating fMRI images from EEG signals with reasonable accuracy.

Extended Abstract

Introduction

Deep Neural Network (DNN) models are one of the most dominant unsupervised feature extraction methods that have been widely studied recently. Convolutional Neural Networks (CNN) combine learned features with input

data and use 2D convolutional layers, and this architecture is usually well suited for processing 2D data such as images. Convolutional neural networks work by extracting features directly from images and do not require fea-

ture extraction by an observer. The corresponding properties are not predefined. Convolutional neural networks learn to recognize different features of an image using tens or hundreds of hidden layers. Each hidden layer increases the complexity of the learned image features. The initially hidden layers can learn how to detect edges, and the later layers discover how to identify more complex shapes, particularly the shape of the object we are trying to detect.

Generally, CNNs in each layer recognize more detailed features from an image that conclude, analyze, and then decide.

Methods

The basis of this research is based on DenseNet deep learning architecture. DenseNet architecture consists of several dense transmission blocks placed between two adjacent dense blocks. Each layer uses all the previous feature maps as input. This new model provides elevated accuracy with a reasonable number of network parameters for object detection tasks.

With changes in settings, these algorithms achieved high accurate results in several datasets used for this purpose. Sets of features are collected in a flat layer and reconstructed layer by layer as a latent space of an Autoencoder network with UpSampling layers.

In a joint project with the support of the American Science Foundation, Stanford University, and several other scientific research centers, a website for the free sharing of brain and cognitive science data under the openfMRI was launched in 2011 and then renamed openNeuro. Accordingly, these data were related to confidence in per-

ceptual decisions, which were simultaneously recorded in EEG and fMRI.

The task used during data recording was the Random Moving Dots (RDM) test, in which healthy volunteers were asked to judge the direction in which dots were moving across the screen.

This study used the independent component analysis (ICA) method to clean the existing EEG signals in the Python programming language using the fastICA algorithm. The self-sufficient analysis components are called the separation of independent sources mixed by an unknown combination system. Besides, the separation should be done only based on the observation of the combined signals, i.e., both the combination system and the primary signals are unknown.

The Gramian Angular Sum/Difference Fields method and Markov Transfer Fields were used to reduce the size of the input without losing the basic data and to convert the EEG signal into images.

Results

The test data in this deep neural network are tensorial, consisting of MTF images with a size of $64 \times 64 \times 3$ and an fMRI image matrix with a size of $70 \times 70 \times 32$. The total available data are 16962, and the number of test data is 11873, which for this network, the ratio of test data to test data is 70-30. GPUs from Google's Collaboratory service were used to process these number calculations.

The total number of parameters is 1593175, of which 1541275 parameters, are trained in the network. The average accuracy of the model was 85.86% during 1000 iterations (Figure 1).

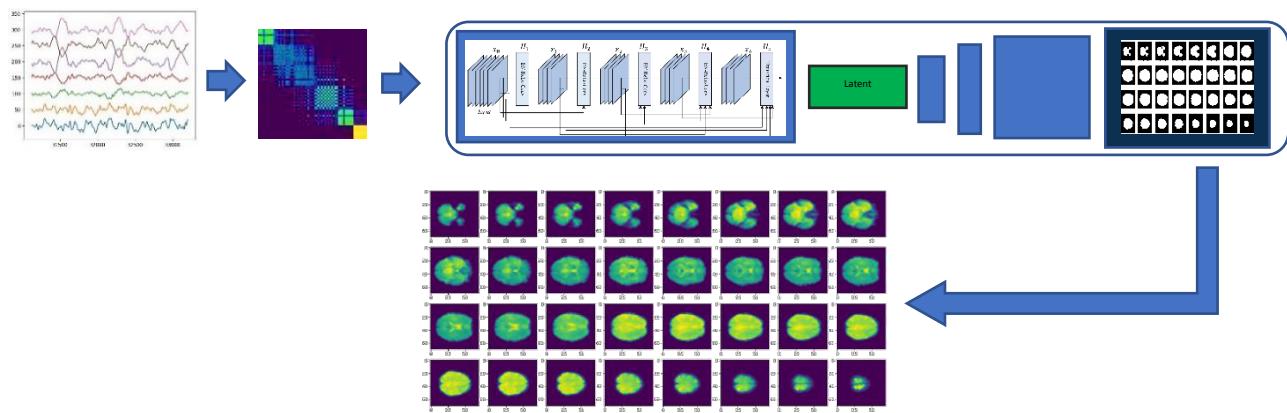


Figure 1. Model implementation steps

Conclusion

The above method using fastICA, MTF, and DenseNet deep learning algorithm and combining it with an auto-encoder network is new for reconstructing brain images. According to the obtained results, it can be concluded that the deep learning algorithm performs better than other superficial methods in many applications. As mentioned earlier, the deep learning algorithm is a new method yet has much potential for improvement and development. The method used in this research is a novel method in image reconstruction and there is a need to improve it. Developing methods can help improve the algorithm performance in future work to increase the accuracy model and a more appropriate weighting of the used neural network. Additionally, with newer deep structures that increase in number daily, their efficiency in image reconstruction using EEG signals can be evaluated and checked.

Ethical Considerations

Compliance with ethical guidelines

There were no ethical considerations involved in the re-

search related to this article.

Authors' contributions

The design of the research implementation stages and the writing of the article were done by Mahdi Arjmand. All authors performed the research literature and background. Saeed Stayeshi, Manuchehr Kelarestaghi, and Javad Hatami completed the design and actively participated in advising and supervising the implementation of the research and writing stages.

Funding

This research is not under the financial support of any institution or organization.

Acknowledgments

The authors are grateful to all the dignitaries who helped us in conducting and consensus on the current research.

Conflict of interest

The authors declare no conflicts of interest.

بازسازی تصاویر تصویربرداری تشید مغناطیسی کارکردی با استفاده از سیگنال‌های الکتروآنسفالوگرام با روش شبکه‌های کانولوشنی همبند متراکم خود رمزنگار

مهدی ارجمند^۱ ID، سعید ستایشی^{۲*} ID، منوچهر کلارستاقی^۳، جواد حاتمی^۴

۱. دانشجوی دکتری مدل‌سازی شناختی، گروه مدل‌سازی شناختی، موسسه آموزش عالی علوم شناختی، تهران، ایران
۲. دانشیار گروه مهندسی هسته‌ای، دانشکده فیزیک و مهندسی انرژی، دانشگاه صنعتی امیرکبیر، تهران، ایران
۳. استادیار گروه مهندسی برق و کامپیوتر، دانشکده فنی و مهندسی، دانشگاه خوارزمی، تهران، ایران
۴. دانشیار روان‌شناسی، دانشگاه تهران و موسسه آموزش عالی علوم شناختی، تهران، ایران

چکیده

مقدمه: داده‌های استفاده شده در این مدل یادگیر از ثبت هم‌زمان تصاویر تصویربرداری تشید مغناطیسی و سیگنال‌های الکتروآنسفالوگرام در حین انجام تکلیف شناختی نقاط تصادفی متحرک برای سنجش میزان اطمینان در تصمیم‌گیری ادراکی تشکیل شده است با یادگیری مدل می‌توان از داده‌های سیگنال‌های الکتروآنسفالوگرام در آینده به طور مستقل استفاده کرد. هدف این پژوهش بازسازی تصاویر تصویربرداری تشید مغناطیسی کارکردی با استفاده از سیگنال‌های الکتروآنسفالوگرام است این پژوهش کاربردی است که بر روی داده‌های ثبت شده هم‌زمان صورت پذیرفته است.

روش کار: داده‌های الکتروآنسفالوگرام به عنوان ورودی مدل و داده‌های تصاویر تصویربرداری تشید مغناطیسی به عنوان خروجی مدل در نظر گرفته شده و مدل یاد می‌گیرد که چطور از داده‌هایی با قالب ورودی، داده‌هایی از جنس قالب خروجی تولید نماید. قبل از ورود داده‌ها به مدل داده‌های ورودی برای بالا رفتن دقت مدل با حذف آرتفیکت‌ها با روش fastICA و تبدیل شدن به ماتریس گرامیان پیش‌پردازش می‌شود.

یافته‌ها: مدل نسبت به سایر روش‌ها برتری‌های مناسبی را در زمان آموزش و دقت مدل نشان داده است و مدل عمیق یادگیر کانولوشنی پیشنهادی با دقت مطلوبی موفق به شبیه‌سازی تصاویر تصویربرداری تشید مغناطیسی از روی سیگنال‌های الکتروآنسفالوگرام گردید.

نتیجه‌گیری: با استفاده از مدل عمیق یادگیر کانولوشنی پیشنهادی می‌توان به ارتباط بین فضای ساختاری و فضای رفتاری مغز پی برد و آن را جهت مطالعه هر بخش، پیاده‌سازی نمود.

دربافت: ۱۴۰۱/۰۴/۳۰

اصلاح نهایی: ۱۴۰۱/۰۶/۰۷

پذیرش: ۱۴۰۱/۰۶/۱۰

واژه‌های کلیدی

یادگیری عمیق

میدان انتقال مارکوف

DenseNet

fastICA

شبکه‌های خود رمزنگار

نویسنده مسئول

سعید ستایشی، دانشیار گروه مهندسی هسته‌ای، دانشکده فیزیک و مهندسی انرژی،

دانشگاه صنعتی امیرکبیر، تهران، ایران

ایمیل: Setayesh@aut.ac.ir



doi.org/10.30514/icss.24.3.105

مقدمه

تصویر، تشخیص گفتار و درک متن موفقیت بزرگی کسب نموده است. این تکنیک از استراتژی‌های نظارت شده و بدون نظارت برای یادگیری نمایش‌ها و ویژگی‌های چند سطحی در معماری‌های سلسله‌مراتبی (Hierarchical architectures) برای طبقه‌بندی و شناخت الگو استفاده می‌کند (۲).

مدل‌های شبکه‌های عصبی عمیق از قوی‌ترین روش‌های استخراج

شبیه‌سازی (Simulation) رفتار مغز انسان یکی از مهم‌ترین چالش‌ها در محاسبات امروزی است. مشکل اصلی شامل یافتن راههای کارآمد، برای کنترل و محاسبه حجم عظیمی از داده‌هایی است که این نوع شبیه‌سازی‌ها با استفاده از فناوری فعلی نیاز دارند (۱).

یادگیری عمیق، در حال حاضر به عنوان یکی از مهم‌ترین، تکنیک‌های یادگیری ماشین در بسیاری از برنامه‌های کاربردی مانند تجزیه و تحلیل

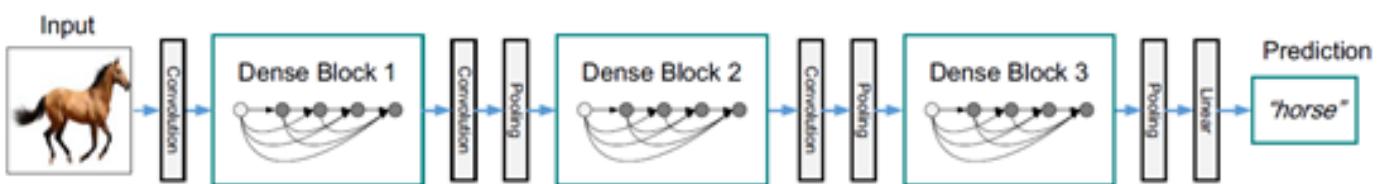
(Near) و غیره استفاده نمود (۴) که در بین این روش‌ها EEG، از مزایای مهمی مانند، وضوح زمانی بالای داده‌ها برخوردار است زیرا الگوی EEG خیلی سریع به تغییرات فعالیت در بدن واکنش می‌دهد (۵) همچنین این روش یک روش غیرتهاجمی، قابل حمل، ارزان قیمت و سهولت در استفاده را دارد است اما این روش دارای معایبی از جمله وجود نویز است که البته در پیش‌پردازش سیگنال‌ها تا حدی، با استفاده از فیلترهای رفع نویز، قابل برطرف شدن می‌باشد (۶).

همچنین روش fMRI دارای مزایایی متفاوت از EEG است که از جمله آنها می‌توان به وضوح مکانی بالا و قابلیت تفسیر ساده‌تر آن اشاره نمود (۷).

پژوهش به این پرسش که آیا ارتباطی بین سیگنال‌های مغزی (EEG) و تصاویر تصویربرداری تشید مغناطیسی کارکردی (fMRI) وجود دارد، با استفاده از یک شبکه عصبی کانولوشنی عمیق پاسخ می‌دهد و با استفاده از داده‌های EEG سعی در شبیه‌سازی تصاویر fMRI دارد. در ادامه ابتدا در مورد روش‌های به کار رفته در پژوهش مقدماتی بیان شده و سپس چند معماری شبکه‌های عصبی کانولوشنی معرفی می‌گردد و در پایان، پیاده‌سازی و نتایج کسب شده آن و مقایسه با سایر روش‌ها را بررسی می‌شود.

روش کار

مبنای این پژوهش بر اساس معماری یادگیری عمیق DenseNet می‌باشد که در ادامه به اختصار ساختار کلی آن، بیان شده است.



شکل ۱. یک الگوریتم DenseNet با سه بلوک متراکم (۸)

انتقال تشکیل می‌شود که بین دو بلوک متراکم مجاور قرار داده شده است. نمودار مفهومی یک بلوک متراکم در **شکل ۱** نشان داده شده است (۸). هر لایه تمام نقشه‌های ویژگی قبلی را به عنوان ورودی در نظر می‌گیرد. هنگام ساختن **شکل ۱**، *l*-امین لایه تمام نقشه‌های ویژگی لایه‌های قبلی x_{l-1}, \dots, x_0 را به عنوان ورودی دریافت کرده است.

ویژگی بدون نظارت هستند که در سال‌های اخیر مطالعات گسترده‌ای روی آنها صورت پذیرفته شده است. شبکه‌های عصبی کانولوشنی (Convolutional Neural Network (CNN)) ویژگی‌های آموخته شده را با داده‌های ورودی جمع می‌کند و از لایه‌های کانولوشن دو بعدی استفاده می‌کند و این معماری معمولاً برای پردازش داده‌های دو بعدی مانند تصاویر بسیار مناسب است. شبکه‌های عصبی کانولوشنی با استخراج ویژگی‌ها به صورت مستقیم از تصاویر کار می‌کند و نیازی به استخراج ویژگی به وسیله یک ناظر ندارند. ویژگی‌های مربوطه از پیش تعیین شده نیستند. شبکه‌های عصبی کانولوشن یاد می‌گیرند که با استفاده از داده‌ها یا صدها لایه مخفی ویژگی‌های مختلف یک تصویر را تشخیص دهنند. هر لایه پنهان پیچیدگی ویژگی‌های تصویر آموخته شده را افزایش می‌دهد. لایه‌های پنهان ابتدایی می‌توانند نحوه تشخیص لبه‌ها را بیاموزد و لایه‌های بعدی نحوه تشخیص اشکال پیچیده‌تر به طور خاص شکل شی ای که سعی در تشخیص آن داریم را یاد می‌گیرد. به طور کلی CNN‌ها در هر لایه ویژگی‌های جزئی تری را از یک تصویر تشخیص می‌دهند و در نهایت نتیجه‌گیری، تجزیه و تحلیل می‌کنند و سپس تصمیم می‌گیرد (۳).

در حال حاضر برای اندازه‌گیری عملکرد مغز افراد در هنگام فعالیت و یا استراحت می‌توان از روش‌هایی مانند الکتروآنسفالوگرام (EEG)، تصویرسازی تشید مغناطیسی کارکردی (Electroencephalogram (EEG)، Resonance Imaging Functional Magnetic (fMRI) و Infrared Spectroscopy (NIRS)) فریشنسی فروسرخ نزدیک (NIRS) (۹)

معماری DenseNet در سال ۲۰۱۷ توسط Huang و همکاران که از لایه‌های متراکم شبکه‌های عصبی کانولوشنی متصل استفاده می‌کند توسعه یافت، خروجی‌های هر لایه با تمام لایه‌های جانشین در یک بلوک متراکم به هم متصل‌اند (۸) این مفهوم برای استفاده مجدد از ویژگی‌ها که باعث کاهش چشمگیر پارامترهای شبکه می‌شود، کارآمد است. معماری DenseNet از چندین بلوک متراکم و بلوک

$$x_l = H_l([x_0, \dots, x_{l-1}]) \quad (1)$$

دسته‌ای (Batch normalization) (۹) و (۱۰)، یک ReLU (۹) و (۱۱) اعمال یک عملگر کانولوشن 3×3 (۸) تابع ReLU از نظر ریاضی با رابطه ۲ تعریف می‌شود:

$$y = \max(x, 0) \quad (2)$$

به طور همزمان ثبت داده‌ها در EEG و fMRI صورت گرفته و آخرين بروزرسانی آن در حال حاضر در تاریخ ۵/۰۵/۲۰۲۰ انجام شده است و Philiastides و Gherman چگونگی ارتباط مغز با اطمینان را در مراحل اولیه تصمیم‌گیری، یعنی قبل از این که افراد صریحاً به یک انتخاب خاص متوجه باشند، بررسی کردند (۱۲). تکلیف استفاده شده در حین ثبت داده‌ها، آزمون نقاط متحرک تصادفی (Random Dot Motion) بود شکل ۲ که از داوطلبان سالم خواسته شد که مسیری را که نقاط در سراسر صفحه نمایش در حال حرکت هستند، قضاوت کنند. آنها سپس مجبور به ارزیابی میزان اطمینان در تصمیم خود شدند که در این پژوهش ارزیابی شرکت‌کنندگان بدون کاربرد می‌باشد.

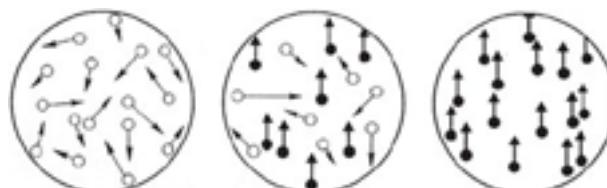
با استفاده از دو روش EEG و fMRI fMRI فعالیت مغز خود را در حین آزمون ثبت گردید. روش EEG از الکترودهای پوست سر استفاده می‌کند تا نشان دهد چه موقع و چگونه فعالیت الکتریکی در مغز تغییر می‌کند، در حالی که fMRI، نوعی اسکن مغز، نشان می‌دهد که این تغییرات فعالیت مغز در کجا رخ می‌دهد. این دو روش در کنار هم استفاده می‌شوند، درک بیشتری از فعالیت مغز نسبت به هر کدام را به تنها بی ارائه می‌دهند. فعالیت در نواحی مختلف مغز با اطمینان در مراحل مختلف کار ارتباط دارد. در این آزمایش سی نفر شرکت کردند که چهار نفر پس از آن از آنالیز خارج شدند که سه نفر به دلیل عملکرد تصادفی و یک نفر به علت عملکرد نزدیک سقف و بسیار زیاد قوی حذف شدند. علاوه بر اینها دو آزمودنی دیگر نیز از آزمایش به دلیل شرایط آزمایش و ایجاد در دستگاه EEG از مطالعه کنار گذاشته شدند (۱۳).

که x_0, \dots, x_L ویژگی‌های الحق شده برای لایه‌های ۰...۱... L می‌باشند (H_L) و به عنوان یک تنسور واحد در نظر گرفته می‌شود که سه عملیات متوالی مختلف را انجام می‌دهد یک عملیات نرمال‌ساز

در بلوک انتقال (Transition)، عملگر کانولوشن 1×1 با نرمال‌ساز دسته‌ای و به دنبال آن یک لایه پولینگ متوسط 2×2 انجام می‌شود (۸). الگوریتم نرمال‌ساز دسته‌ای مراحل عملیات نرمال‌ساز دسته‌ای را بیان می‌کند (۱۲) این مدل جدید دقت بسیار بالایی را با تعداد معقولی از پارامترهای شبکه برای کارهای تشخیص اشیا، ارائه می‌دهد (۸). شبکه‌های عصبی کانولوشنی بالاخص الگوریتم‌های DenseNet با افزایش تعداد پارامترها، بدون هیچ‌گونه نشانه‌ای از تخریب عملکرد یا اضافه کاری، باعث بهبود مداوم در دقت عملیات می‌شوند. با تغییرات تنظیمات، این الگوریتم‌ها موفق به کسب نتایج بسیار دقیق در چندین مجموعه داده‌ای که برای رقابت به این منظور بوده‌اند شد (۸). در این پژوهش پس از این که ویژگی‌ها توسط بلوک‌های زیاد و الحق شده استخراج شدند، این مجموعه ویژگی در یک لایه مسطح (Flatten) گردآوری می‌شود و به عنوان فضای پنهان (Latent Space) یک شبکه خود رمزنگار با لایه‌های بالا نمونه‌برداری (UpSampling) لایه به لایه بازسازی می‌گردد.

داده‌های پژوهش

در پژوهش‌های مشترک با حمایت بنیاد علوم آمریکا و دانشگاه استنفورد و چند مرکز علمی پژوهشی دیگر وب‌سایتی جهت اشتراک‌گذاری رایگان داده‌های مربوط به مغز و علوم‌شناختی تحت عنوان openfMRI در سال ۲۰۱۱ راهاندازی گردید و بعداً به openNeuro تغییر نام داد که این مجموعه داده در آدرس (۱۴) موجود و پژوهش مرتبط آن در (۱۳) آمده است. این داده‌ها مربوط به اطمینان در تصمیمات ادراکی است که



شکل ۲. تکلیف نقاط متحرک تصادفی (۱۵)

عصوبی نداشتند (۱۳). دستگاه EEG استفاده شده در این آزمایش محصول شرکت آلمانی Brain Products که توسط نرمافزار Brain Vision Recorder داده‌ها را از اسکالپ 64 کاناله (Ag/AgCl) با نرخ

تمام نتایج ارائه شده در مجموعه داده ارائه شده بر اساس ۲۴ نفر باقیمانده (محدوده سنی ۳۲-۲۰ سال) است. همه افراد راست دست، بینایی نرمال یا تصحیح شده بودند و هیچ‌گونه سابقه‌ای از مشکلات

شده است. آنالیز مؤلفه‌های مستقل به جداسازی منابع مستقل از هم گفته می‌شود که به وسیله یک سیستم ترکیب ناشناخته با یکدیگر آمیخته شده‌اند و جداسازی باید تنها بر پایه مشاهده سیگنال‌های ترکیبی صورت گیرد، یعنی هم سیستم ترکیب و هم سیگنال‌های اولیه نامعلوم‌اند (۱۶). شرح تفضیلی الگوریتم fastICA را می‌توان در مشاهده نمود (۱۶).

در صورتی که داده‌های خام EEG را به عنوان ورودی به الگوریتم بدھیم حجم محاسبات بسیار عظیم خواهد شد و کارایی معماری یادگیری عمیق کاهش می‌یابد بنابراین برای کاهش دادن سایز ورودی بدون از دست دادن داده‌های اساسی و همچنین تبدیل سیگنال EEG به تصاویر از روش میدان‌های جمع/تفاضل زاویه‌ای گرامیان (GASF/GADF) و میدان‌های انتقال مارکوف (MTF) استفاده شده است (۱۷).

یافته‌ها

تمامی داده‌های موجود به عنوان تصاویر fMRI همان‌گونه که در آمده است (۱۳)، ۷۷۱ تصویر کامل از مغز آزمودنی‌ها که هر یک نیز شامل ۳۲ برش می‌باشد در طول برگزاری تکلیف تهیه شده است. برای هم‌زمان‌سازی داده‌های EEG و تصاویر فوق زمانی که هر تصویر در حال ثبت است، سیگنال‌های EEG از ۶۴ کانال ثبت شده‌اند که می‌توان هر کدام از تصاویر ثبت شده را با قطعه از سیگنال‌های فوق نظری نمود، با توجه به ثابت بودن زمان ثبت داده‌های EEG پس از حذف آرتیفکت‌ها با الگوریتم fastICA در بازه زمانی‌های فوق و استفاده از روشی که شرح داده شد این سیگنال‌ها به ماتریس MTF تبدیل شدند و همچنین هر مرحله از تصاویر اسکن کامل مغز را در آن دوره زمانی در یک ماتریس دیگر ذخیره کردند که برای سهولت در بحث در ادامه به آنها مجددًا داده‌های EEG و داده‌های fMRI گفته می‌شود. ورودی مدل شبکه عصبی قطعات سیگنال‌های EEG که تبدیل به تصاویر MTF شده، می‌باشد و خروجی آن ماتریس مجموعه‌ای از ۳۲ برش تصاویر مغز در آن بازه زمانی است. **شکل ۳** مراحل انجام این عملیات را نمایش می‌دهد.

تابع فعال‌ساز غیرخطی mish با توجه به کارایی بهتر (۱۸) در این شبکه به کار برده شده است که ضابطه آن مطابق **رابطه ۳** می‌باشد:

$$f(x) = x \cdot \tanh(\ln(1 + e^x)) \quad (3)$$

در شرکت گوگل برای پیش‌بینی نرخ کلیک در اوایل دهه ۲۰۱۰ توسعه‌یافته و در سال ۲۰۱۳ منتشر شده است (۱۹).

داده‌های آزمایش در این شبکه عصبی عمیق به صورت تنسوری

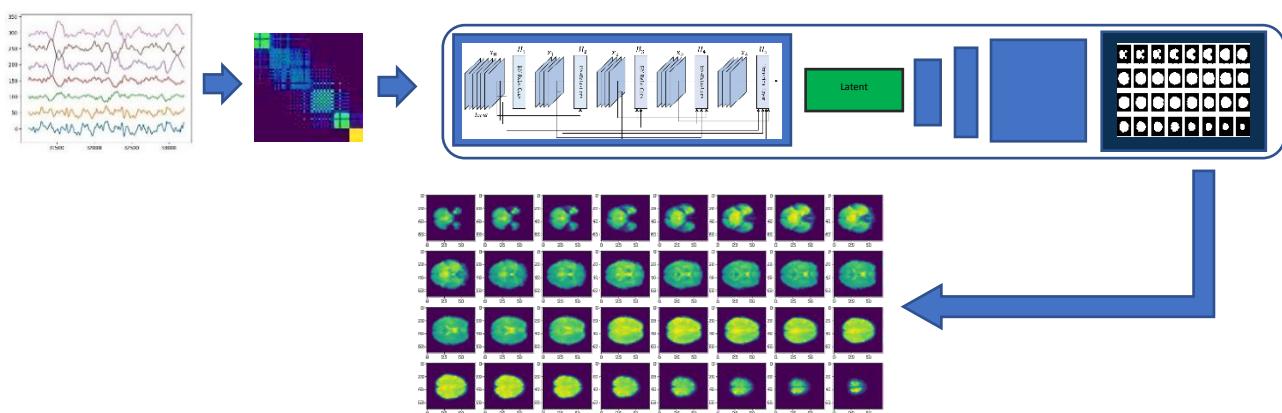
نمونه‌برداری ۵۰۰۰ هرتز ثبت شدن و الکترودها با سیستم ۱۰-۲۰ جای‌گذاری شده بودند و یک الکترود نیز بر روی دماغک قرار گرفته بود. پیش‌پردازش سیگنال‌های EEG با استفاده از نرم‌افزار Matlab انجام شده است. سیگنال‌های EEG ثبت شده در داخل یک اسکنر MR به دلیل القای مغناطیسی بر روی الکترودهای EEG به آرتیفکت‌های (Ballistocardiogram) گردایان و آرتیفکت‌های بالیستوکاردیوگرام (Ballistocardiogram) آلوده می‌شوند. برای تصحیح آرتیفکت مرتبط با گردایان، الگوهای آرتیفکت با میانگین گیری از مجموعه‌های ۸۰ حجم عملکردی متوالی با محوریت هر حجم دلخواه ساخته شده است و از سیگنال EEG کم شده است. این فرایند برای هر حجم عملکردی در مجموعه داده تکرار شده است. علاوه بر این، از یک فیلتر میانگین ۱۲ میلی‌ثانیه برای حذف هرگونه آرتیفکت اسپایک باقی‌مانده استفاده شده است. آرтیفکت‌های EEG استاندارد تصحیح شده و یک فیلتر باند_گذر ۴۰-۵۰ هرتز را برای حذف جریان‌های آهسته DC و نویز فرکانس بالا اعمال گردیده است. تمام داده‌ها با نرخ ۱۰۰۰ هرتز زیر_نمونه‌برداری (DownSampling) شده‌اند. برای حذف آرتیفکت حرکات چشم، آزمودنی‌ها قبل از آزمایش اصلی یک کار کالیبراسیون حرکت چشم را انجام داده‌اند (در حالی که اسکنر MRI خاموش بوده است)، که در آن به آنها دستور داده شد چندین بار پلک بزنند در حالی که یک ضربدر ثابت مرکزی در تصویر نمایش داده می‌شد. از تجزیه و تحلیل مؤلفه اصلی ((PCA Principal Component Analysis)) برای شناسایی مؤلفه‌های خطی مرتبط با چشمک‌ها و پلک‌زدن‌های سریع استفاده شده است که متعاقباً از داده‌های EEG حذف شدند. در مرحله بعد، آرتیفکت مربوط به قلب (به عنوان مثال، بالیستوکاردیوگرام، BCG) با استفاده از فیلتر پایین_گذر (در ۴ هرتز) و روش تحلیل مؤلفه اصلی و در نهایت، حذف سیگنال میانگین در بازه ۱۰۰ میلی‌ثانیه پیش از تحریک تصحیح شده‌اند (۱۳).

هرچند روش‌های بالا برای حذف آرتیفکت‌ها تا حد زیادی مؤثر است اما در این پژوهش به علت این که ممکن است تمامی آرتیفکت‌های موجود به درستی حذف نشده باشند از روش تحلیل مؤلفه مستقل (ICA) برای پاک‌سازی سیگنال‌های EEG موجود، در زبان برنامه‌نویسی پایتون با استفاده از الگوریتم fastICA بهره گرفته

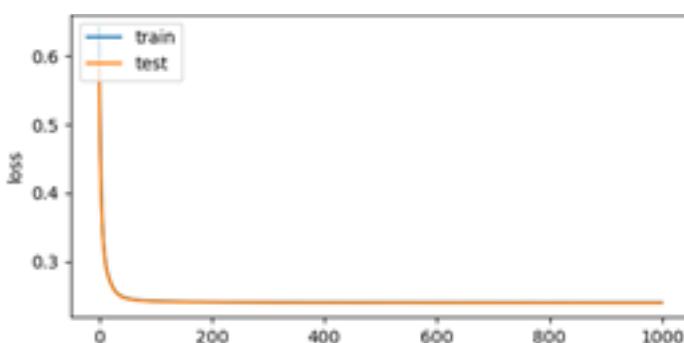
تابع Binary crossentropy به عنوان تابع زیان شبکه استفاده شده است که بایستی کمینه گردد و وزن‌های شبکه به کمک الگوریتم FTRL با نرخ یادگیری ۰.۱ بهینه شده است. این الگوریتم بهینه‌سازی

استفاده شده است. تعداد کل پارامترها 1593175 است که از این تعداد 1541275 پارامتر در شبکه آموزش می‌بینند، میانگین دقت مدل، برابر $85/86$ درصد در طی 1000 تکرار به دست آمده و تعداد لایه در این معماری، برابر 7278 لایه است. فایل‌های کدنویسی شده با زبان پایتون را می‌توان از منبع (۲۰) دریافت نمود (شکل ۴).

مشکل از تصاویر MTF با اندازه $(3 \times 64 \times 64)$ و ماتریس تصاویر fMRI با اندازه $(32 \times 70 \times 70)$ است. کل داده‌های موجود 16962 عدد بوده است، تعداد داده‌های آموزشی 11873 و تعداد داده‌های تست 5089 عدد است که برای این شبکه، نسبت داده‌های آموزشی به داده‌های تست 30 به 70 درصد می‌باشد. برای پردازش این حجم از محاسبات، از GPUهای سرویس Colaboratory شرکت گوگل



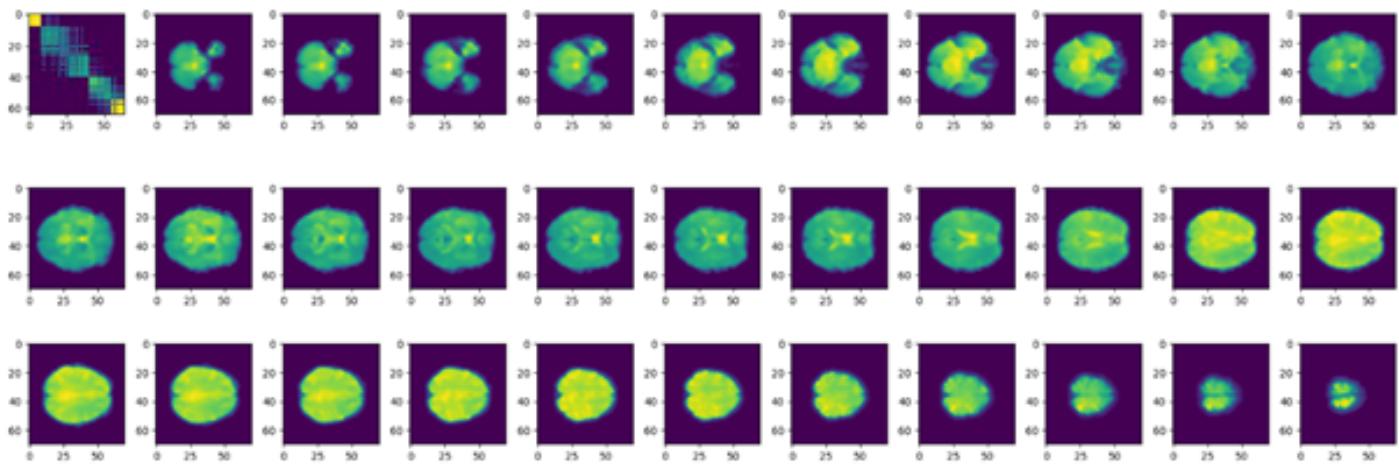
شکل ۳. آموزش شبکه عصبی با استفاده از ورودی EEG و خروجی fMRI



شکل ۴. نمودار دقت و تابع زیان مدل

زمانی ثبت EEG مذکور هستند که روش پیشنهادی، در این مطالعه بازسازی نموده است. **جدول ۱**، مقایسه این معماری تغییریافته با سایر معماری‌های دیگر را نشان می‌دهد که با توجه به این که بالا رفتن دقت حتی به میزان کوچک نیز یک مزیت برای مسائل جدید است.

خروجی مدل بر روی داده‌های تست، پس از بازسازی تصاویر با سایز $(32 \times 70 \times 70)$ است که یک نمونه از آن در **شکل ۵** آورده شده است. تصویر اول، یک نمونه از ورودی مدل که یک سیگنال EEG است که پس از حذف آرتیفکت با الگوریتم fastICA و تبدیل به MTF شده است و 32 تصویر دیگر خروجی، تصاویر برش‌های fMRI در بازه



شکل ۵. تصاویر برش‌های بازسازی شده از یک تصویر MTF در یک بازه زمانی

جدول ۱. مقایسه DenseNet خود رمزگار با معماری‌های VGG16 - AutoEncoder و DenseNet121 - AutoEncoder

مدل	تعداد پارامترها به میلیون	میانگین دقت مدل در چرخه ۱۰۰۰ تکراری	زمان آموزش (ثانیه)
VGG16 - AutoEncoder	۱۱/۴	۷۹/۶۲	۵۲۷۰۰
ResNet50 - AutoEncoder	۴	۸۱/۲۴	۳۰۵۰۰
DenseNet121 - AutoEncoder	۱/۶	۸۵/۸۶	۴۶۹۰۰

زیادی برای بهبود و توسعه دارد. روشی که در این پژوهش استفاده شد روشی نو در بازسازی تصاویر می‌باشد و نیاز به بهبود در آن وجود دارد. یکی از مواردی که می‌تواند در کارهای آینده به بهبود عملکرد الگوریتم کمک کند توسعه روش‌هایی برای بالا بردن دقت مدل و وزن‌دهی مناسب‌تر شبکه عصبی مورد استفاده است. علاوه بر این، با ساختارهای عمیق جدیدتر که هر روز بر تعداد آنها افزوده می‌گردد می‌توان کارایی آنها را در بازسازی تصاویر با استفاده از سیگنال EEG مورد ارزیابی و بررسی قرارداد.

بحث

هر چند معماری DenseNet در مقایسه با اکثر معماری‌ها به علت الحاق‌های بسیار زیاد لایه‌های قبلی به لایه‌های بعدی نیازمند محاسبات بیشتری است اما همین ویژگی سبب استخراج ویژگی‌های بهتر و همچنین دقت بالای مدل در این پژوهش شده است. تعداد پارامترها و تعداد لایه‌ها در این الگوریتم با تغییر اندازه بلوک‌ها و سرعت رشد آنها همان‌گونه که پیش‌تر اشاره شد به راحتی قابل تغییر است. معماری پیشنهادی با وجود تعداد پارامترهای کمتر، دارای میانگین دقت بالاتری بر روی داده‌های پژوهش است.

ملاحظات اخلاقی

پیروی از اصول اخلاق در پژوهش

در انجام پژوهش مربوط به این مقاله هیچ‌گونه ملاحظه اخلاقی دخیل نبوده است.

مشارکت نویسنده‌گان

طراحی مراحل اجرای پژوهش و نگارش مقاله توسط مهدی ارجمند انجام شد. همه نویسنده‌گان در بررسی ادبیات و پیشینه پژوهش

نتیجه‌گیری

روش فوق با استفاده از MTF و fastICA و الگوریتم یادگیری عمیق DenseNet و ترکیب آن با یک شبکه خود رمزگار برای بازسازی تصاویر مغزی یک شیوه نوین است. با توجه به نتایج به دست آمده می‌توان استنباط کرد که الگوریتم یادگیری عمیق نسبت به روش‌های سطحی دیگر در بسیاری از کاربردها بهتر عمل می‌کند. همان‌طور که گفته شده الگوریتم یادگیری عمیق روش جدیدی است و پتانسیل

تشکر و قدردانی

از تمامی بزرگوارانی که در اجرا و همفکری پژوهش حاضر ما را یاری نمودند، سپاسگزاریم.

همکاری داشتند. سعید ستایشی، منوچهر کلارستاقی و جواد حاتمی در تکمیل طراحی، مشاوره و نظارت بر اجرای مراحل پژوهش و نگارش، مشارکت فعال داشتند.

تعارض منافع

نویسنده‌گان مقاله حاضر هیچ‌گونه تعارض منافعی را گزارش نکرده‌اند.

منابع مالی

این پژوهش تحت حمایت مالی هیچ مؤسسه و سازمانی قرار ندارد.

References

- Makin S. The four biggest challenges in brain simulation. *Nature*. 2019;571(7766):S9.
- Sarker IH. Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*. 2021;2:420.
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-444.
- Haartsen R, Jones E, Johnson M. Human brain development over the early years. *Current Opinion in Behavioral Sciences*. 2016;10:149-154.
- Multrus F. Calculation of the electric potential for a neuronal activity model in the brain [PhD Dissertation]. Dresden, Germany:Dresden University of Technology;2014.
- Elsayed N, Zaghloul ZS, Bayoumi M. Brain computer interface: EEG signal preprocessing issues and solutions. *International Journal of Computer Applications*. 2017;169(3):12-16.
- Poldrack R, Mumford J, Nichols T. Handbook of functional MRI data analysis. New York:Cambridge University Press;2011.
- Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Denseley connected convolutional networks. Proceedings of the IEEE conference on computer vision and pattern recognition; 2017 July 21-26; Honolulu, HI, USA:IEEE;2017. pp. 2261-2269.
- Zahangir Alom M, Taha TM, Yakopcic C, Westberg S, Sidike P, Shamima Nasrin M, et al. The history began from AlexNet: a comprehensive survey on deep learning approaches. arXiv e-prints. 2018 Mar:arXiv-1803.
- Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. International Conference on Machine Learning; 2015 July 6-11; Lille, France;2015. pp. 448-456.
- Nair V, Hinton GE. Rectified linear units improve restricted boltzmann machines. The 27th International Conference on Machine Learning (ICML 2010); 2010 June 21-24; Haifa, Israel;2010.
- Zhang J, Lu C, Li X, Kim HJ, Wang J. A full convolutional network based on DenseNet for remote sensing scene classification. *Mathematical Biosciences and Engineering*. 2019;16(5):3345-3367.
- Gherman S, Philiastides MG. Human VMPFC encodes early signatures of confidence in perceptual decisions. *Elife*. 2018;7:e38293.
- Gherman S, Philiastides MG. [Internet]. Openneuro.org. 2022 [cited 21 July 2022]. Available from: <https://openneuro.org/datasets/ds002739/versions/1.0.0>. 2020.
- Mojzisch A, Krug K. Cells, circuits, and choices: Social influences on perceptual decision making. *Cognitive, Affective, & Behavioral Neuroscience*. 2008;8(4):498-508.
- Geetha G, Geethalakshmi SN. Artifact removal from eeg using spatially constrained fastica and fuzzy shrink thresholding technique. *International Journal of Applied Information Systems*. 2012;4(11):25-29.
- Wang Z, Oates T. Imaging time-series to improve classi-

fication and imputation. Twenty-Fourth International Joint Conference on Artificial Intelligence. 2015 July 25-31; Buenos Aires, Argentina;2015.

18. Mish MD. A self regularized non-monotonic activation function. arXiv preprint. 2019. arXiv:1908.08681.

19. tf.keras.optimizers.Ftrl | TensorFlow Core v2.9.1 [Internet]. TensorFlow. Available from: https://www.tensorflow.org/api_docs/python/tf/keras/optimizers/Ftrl. 2022 [cited 21 July 2022]

net]. TensorFlow. Available from: https://www.tensorflow.org/api_docs/python/tf/keras/optimizers/Ftrl. 2022 [cited 21 July 2022]

20. Arjmand M. Overview [Internet]. GitHub. Available from: <https://github.com/mahdiarjmand/python->. 2022 [cited 21 July 2022]