



Classification of right and left-hand motor imagery using deep learning in electroencephalography and near-infrared spectroscopy

Hamid Ebrahimi¹, Ahmad Shalbaf^{2*} , Nader Jafarnia Dabanloo³

1. Department of Biomedical Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

2. Department of Biomedical Engineering and Medical Physics, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

3. Department of Biomedical Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

Received: 10 May 2020

Revised: 13 Jun. 2020

Accepted: 14 Jul. 2020

Keywords

Brain-computer interface
Electroencephalography
Near-infrared light spectroscopy
Convolutional neural network

Corresponding author

Ahmad Shalbaf, Department of Biomedical Engineering and Medical Physics, School of Medicine, Shahid Beheshti University of Medical Sciences, Tehran, Iran

Email: Shalbaf@sbmu.ac.ir



doi.org/10.30699/icss.22.3.95

Abstract

Introduction: In this study, a hybrid brain-computer interface for the classification of right and left-hand motor imagery using the deep learning method is presented to increase accuracy and performance. A hybrid brain-computer interface is designed to achieve a way of communicating between the brain and an external device for patients such as amyotrophic lateral sclerosis. Therefore, the user can control the external device such as a wheelchair without using any organs of the body and only using the brain.

Methods: Two electroencephalographic and near-infrared spectroscopy signals were recorded from 29 healthy men and women, and pre-processing of the signals was done to eliminate noise. The wavelet transform was used to obtain the scalogram as two-dimensional images for both of the signals, and images were inserted separately from each region of the brain and the merge region into the pre-trained convolutional neural network to extract features, classification, and prediction of left and right-hand motor imagery.

Results: The results for a combination of scalogram images of Frontal-Central and Central-Parietal regions in electroencephalographic signal reached 88%, for near-infrared light spectroscopy reached 85% and for the merge of two scalogram images reached 90%.

Conclusion: The combination of scalogram images and the deep learning method used in this study reached significant improvement in the prediction accuracy of right and left-hand motor imagery for wheelchair motion control.

Citation: Ebrahimi H, Shalbaf A, Jafarnia Dabanloo N. Classification of right and left-hand motor imagery using deep learning in electroencephalography and near-infrared spectroscopy. *Advances in Cognitive Sciences*. 2020;22(3):95-104.



طبقه‌بندی تصور حرکت دست راست و چپ با استفاده از روش‌های یادگیری عمیق از روی سیگنال‌های الکتروانسفالوگرافی و طیف‌سنجی مادون قرمز

حمید ابراهیمی^۱، احمد شالباف^{۲*} ID، نادر جعفرنیا دابانلو^۳

۱. گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران
۲. گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران
۳. گروه مهندسی پزشکی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

چکیده

مقدمه: در این مقاله یک واسط مغز و رایانه برای طبقه‌بندی تصور حرکت دست راست و چپ با استفاده از روش یادگیری عمیق از روی سیگنال‌های مغزی ارائه شده است. واسط مغز و رایانه به منظور دستیابی به یک راه ارتباطی بین مغز و یک دستگاه خارجی برای بیمارانی مانند اسکروز جانبی آمیوتروفیک طراحی می‌شود به گونه‌ای که کاربر بدون هیچ‌گونه استفاده از اندام‌های بدن و با استفاده از مغز خود دستگاه بیرونی از جمله یک ویلچر را کنترل کند.

روش کار: سیگنال الکتروانسفالوگرافی و طیف‌سنجی نور مادون قرمز از ۲۹ فرد سالم ثبت شد و پیش پردازش سیگنال‌ها به منظور حذف نویز انجام گرفت. سپس سیگنال‌ها به صورت جداگانه و به صورت ترکیبی به تصاویر دو بعدی زمان فرکانس اسکیلوگرام با استفاده از تبدیل موجک پیوسته تبدیل شدند و تصاویر هر ناحیه از مغز به صورت جداگانه و ترکیبی به شبکه عصبی کانولوشنی از پیش آموزش دیده ResNet 18 برای استخراج ویژگی و طبقه‌بندی وارد شدند.

یافته‌ها: نتایج به دست آمده از شبکه عصبی کانولوشنی از پیش آموزش دیده ResNet18 برای تصاویر اسکیلوگرام نواحی Frontal-Central, Central-Parietal مغز برای سیگنال الکتروانسفالوگرافی ۸۸ درصد، برای تصاویر اسکیلوگرام سیگنال طیف‌سنجی نور مادون قرمز ۸۵ درصد و برای مجموع تصاویر اسکیلوگرام، دقت ۹۰ درصد به دست آمد.

نتیجه‌گیری: ترکیب تصاویر اسکیلوگرام سیگنال‌های مغزی و روش یادگیری عمیق استفاده شده منجر به بهبود دقت طبقه‌بندی تصور حرکت دست راست و چپ نسبت به مطالعات گذشته شد.

دریافت: ۱۳۹۹/۰۲/۲۱

اصلاح نهایی: ۱۳۹۹/۰۳/۲۴

پذیرش: ۱۳۹۹/۰۴/۲۴

واژه‌های کلیدی

رابط مغز و رایانه
الکتروانسفالوگرافی
طیف‌نگاری نور نزدیک مادون قرمز
شبکه عصبی کانولوشنی

نویسنده مسئول

احمد شالباف، گروه مهندسی و فیزیک پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

ایمیل: Shalbf@sbmu.ac.ir



doi.org/10.30699/icss.22.3.95

مقدمه

می‌تواند راهی برای بهبود حرکات بیماران مبتلا به اختلالات شدید حرکتی، برای مثال اسکروز جانبی آمیوتروفیک (lateral sclerosis Amyotrophic) (۲)، سکتة مغزی، فلج مغزی یا آسیب نخاعی باشد. یک صندلی چرخ‌دار را می‌توان با تصور حرکت کنترل کرد (۳). در آینده حتی ممکن است گزینه‌هایی برای بای‌پس بخش‌های آسیب دیده نخاعی

رابط مغز و رایانه فعالیت سیستم عصبی مرکزی را اندازه‌گیری می‌کند و آن را به خروجی یک دستگاه تبدیل می‌کند (۱). برای کنترل اختیار یک دستگاه، رابط‌های مغز و رایانه معمولاً به شناخت یک یا چندین الگوهای فعالیت مغز قابل تشخیص که می‌توانند به صورت داوطلبانه توسط کاربر تولید شوند، تکیه می‌کنند. به طور خاص، رابط مغز و رایانه

در این تحقیق قصد داریم با استفاده از پردازش همزمان سیگنال‌های مغزی الکتروانسفالوگرافی، طیف‌سنجی نور مادون قرمز و استفاده از روش‌های یادگیری عمیق مخصوصاً شبکه عصبی کانولوشنی، دقت سیستم رابط مغز و رایانه را در هنگام تصور حرکت دست راست و چپ در ۲۹ فرد مورد آزمایش بهبود دهیم.

روش کار

دادگان

جامعه آماری شامل سیگنال‌های EEG و NIRS ثبت شده از ۲۹ نفر سالم (۱۴ مرد و ۱۵ زن با میانگین سنی ۲۸+۵ سال) بود. این دادگان دارای کد اخلاق به شماره SH_01_20150330 از دانشگاه برلین آلمان می‌باشند (۱۳). داده‌های EEG و NIRS در یک اتاق روشن و معمولی جمع‌آوری شد. داده‌های EEG توسط تقویت‌کننده EEG مغز (BrainAmp EEG amplifier) با ۳۰ الکتروود فعال (Germany Brain Products GmbH, Gilching) در نرخ نمونه‌برداری ۱۰۰۰ هرتز ثبت شد. ۳۰ الکتروود EEG بر اساس سیستم بین‌المللی ۱۰-۵ قرار گرفته‌اند. داده‌های NIRS به وسیله دستگاه NIRScout (NIRx GmbH, Berlin, Germany) با نرخ نمونه‌برداری ۱۲/۵ هرتز جمع‌آوری شد. چهارده منبع و شانزده آشکارساز به دست آمده در ۳۶ کانال فیزیولوژیکی در لوب فرونتال، موتوری و مناطق بصری قرار گرفتند. فاصله بین الکتروودها ۳۰ میلی‌متر بود. الکتروودهای NIRS در همان کلاه EEG ثابت شدند. نورهای محیطی توسط تماس قوی میان الکتروودهای NIRS و پوست سر و استفاده از کلاه مات مسدود شده بود. محل قرارگیری الکتروودها در شکل ۱ نشان داده شده است.

افراد مورد آزمایش در جلوی یک صفحه سفید ۵۰ اینچی روی صندلی راحت نشسته بودند. فاصله بین سر و صفحه نمایش آن ۱/۶ متر بود. از آنها خواسته شد که هیچ بخشی از بدن را در طول ثبت اطلاعات جابجا نکنند. این آزمایش در سه جلسه به طور مجزا انجام شده است. هر جلسه، شامل یک دوره استراحت ۶۰ ثانیه‌ای قبل از آزمایش، ۲۰ بار انجام آزمایش تصور حرکت دست راست و چپ و یک دوره استراحت پس از آزمایش ۶۰ ثانیه‌ای بود. انجام آزمایش با ۲ ثانیه که نوع تصور حرکت (راست یا چپ) را مشخص کرده آغاز شد و سپس ۱۰ ثانیه تصور حرکت دست چپ و یا راست انجام شد و در پایان دوره استراحت که به طور تصادفی از ۱۵ تا ۱۷ ثانیه داده شد، انجام گرفت. این فرایند در هر جلسه ۲۰ بار (۱۰ بار تصور حرکت دست راست و ۱۰ بار دست چپ) تکرار شد. لذا برای هر فرد ۶۰ بار (۳ جلسه و هر جلسه ۲۰ بار) این فرایند انجام گرفت، از این ۶۰ بار ۳۰ آزمایش مربوط به

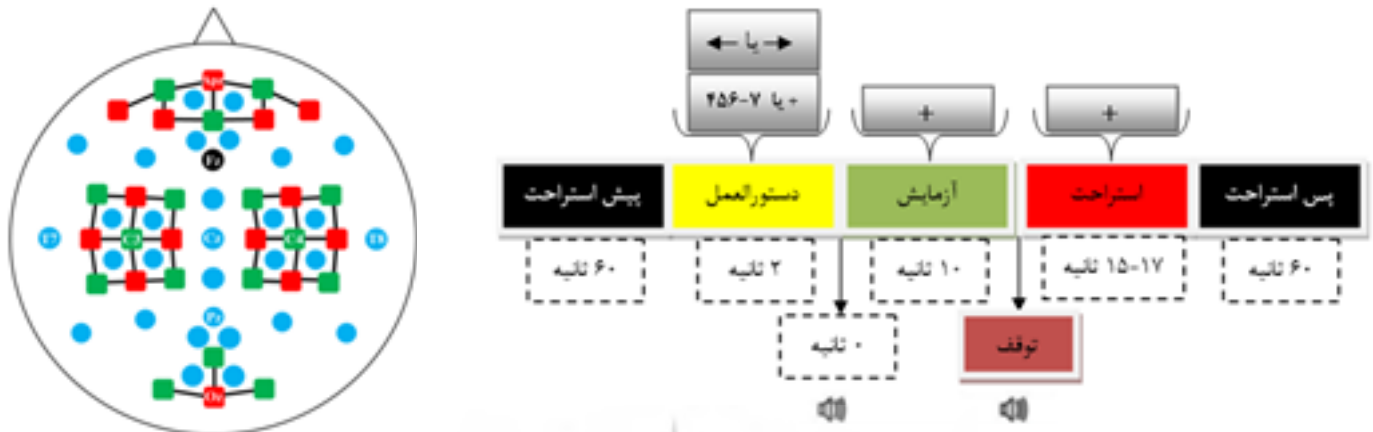
وجود داشته باشد، که اجازه حرکت واقعی اندام‌های فلج شده را تنها از طریق تصور حرکت می‌دهد (۴). اگر چه اکثر رابط‌های مغز و رایانه امروزه از الکتروانسفالوگرافی (Electroencephalography (EEG)) به تنهایی استفاده می‌کنند، اما روش‌های دیگر مانند طیف‌سنجی مادون قرمز (Near-infrared spectroscopy (NIRS))، اطلاعات مختلفی در مورد فعالیت مغز ارائه می‌دهند و می‌توانند اطلاعاتی را که تنها با الکتروانسفالوگرافی به دست می‌آید را تکمیل کنند (۵). در سیگنال‌های طیف‌سنجی مادون قرمز تغییرات هموگلوبین با اکسیژن و هموگلوبین بدون اکسیژن محاسبه می‌شوند.

در سال‌های اخیر ترکیب سیگنال‌های EEG و NIRS به صورت همزمان در رابط مغز و رایانه مورد علاقه فراوان قرار گرفته است (۱۹-۶). بیشتر مطالعات رابط‌های مغز و رایانه دریافتند که ترکیب سیگنال‌های همودینامیکی و عصبی برای کنترل دستگاه یک رویکرد بهتر است. بنابراین نیاز به توسعه روش‌های جدیدی برای ترکیب فعالیت‌های عمیق نورونی و همودینامیکی مغز وجود دارد. در پژوهش‌های مختلف، ترکیبی از طیف‌سنجی نزدیک مادون قرمز و الکتروانسفالوگرافی برای تشخیص تصور حرکت یا وظایف حرکت مورد مطالعه قرار گرفته است (۱۹-۱۲). به عنوان مثال Fazli و همکاران بر اساس طبقه‌بندی فردی اطلاعات الکتروانسفالوگرافی، هموگلوبین با اکسیژن و هموگلوبین بدون اکسیژن از یک روش تلفیقی طبقه‌بندی برای تشخیص حرکت و تصور حرکت چپ از راست استفاده کردند که به طور متوسط دقت ۸۳/۲ درصد بود (۱۲). در مطالعه Khan و همکاران، برای افزایش تعداد دستورات ورودی در زمینه کنترل حرکت در چهار جهت از ترکیب این دو سیگنال استفاده شد. در حالی که حرکات چپ و راست با تصور حرکت با اندازه‌گیری EEG کنترل شد، حرکات رو به جلو و عقب با شمارش یا تفکیک ذهنی اندازه‌گیری شده در NIRS کنترل شد (۱۸). در پژوهش Koo و همکاران از NIRS برای تشخیص رخداد یک تصور حرکت و طبقه‌بندی آن به صورت تصور چپ یا راست با استفاده از الکتروانسفالوگرافی استفاده شد (۱۹).

همان‌طور که گفته شد یکی از بخش‌های اصلی یک سیستم رابط مغز و رایانه، طبقه‌بندی است. دو روش معمول استفاده شده در طبقه‌بندی تصور حرکت، تجزیه و تحلیل خطی و ماشین‌های بردار پشتیبان می‌باشند. به تازگی، طبقه‌بندی با استفاده از روش‌های یادگیری عمیق (Deep learning) و به خصوص شبکه عصبی کانولوشن (Convolutional Neural Networks) به دلیل ظرفیت برجسته در حال افزایش محبوبیت هستند و در تجزیه و تحلیل داده‌های پزشکی استفاده می‌شوند (۲۰، ۲۱).

ثابت) انجام دهند تا اطمینان حاصل شود که تصویر حرکت واقعی و نه تصور بصری، انجام شده است. تصورات حرکت در طول ۱۰ ثانیه انجام آزمایش به طور پیوسته انجام شد. مراحل آزمایش در شکل ۱ قابل مشاهده هستند.

تصور دست راست و ۳۰ آزمایش دیگر مربوط به تصور دست چپ بود. تمام دستورالعمل‌ها بر روی صفحه نمایش سفید نمایش داده شد. برای تصور حرکت، به افراد گفته شد یک تصور حرکت (به عنوان مثال تصور باز و بستن کردن دست خود به منظور گرفتن توپ با یک سرعت



شکل ۱. چپ: نواحی ثبت سیگنال‌های EEG و NIRS (مربع‌های قرمز الکترودهای فرستنده و مربع‌های سبز گیرنده NIRS و دایره‌ها الکترودهای EEG را نشان می‌دهد. راست: مراحل انجام آزمایش تصور حرکت دست راست و یا چپ (۱۳).

پیش پردازش داده‌ها

و به عبارتی تابع موجک مادر می‌باشد، $X(t)$ سیگنال زمانی است، S مقیاس است و τ پارامتر موقعیت است. در این مقاله، از تابع مورلت که از سایر خانواده‌های موجک مناسب‌تر است به عنوان مادر ویولت استفاده شده است. اندازه‌گیری چگالی انرژی فرکانس زمان محلی به عنوان یک اسکیلوگرام (Scalogram) نامیده می‌شود.

شبکه‌های عصبی عمیق

آخرین بخش مهم یک رابط مغز و رایانه پیش‌بینی صحیح تصور حرکت با استفاده از ویژگی‌های استخراج شده است. این پیش‌بینی به شدت به نوع طبقه‌بندی بستگی دارد، اما تعداد و نوع ویژگی‌های موجود نیز نقش مهمی ایفا می‌کنند. ما در این مطالعه از یادگیری عمیق، مخصوصاً شبکه عصبی کانولوشنی در استخراج ویژگی و طبقه‌بندی داده‌ها استفاده می‌کنیم که عملکرد سیستم را بهتر کرده و دقت بالاتری را به دست می‌آورد. شبکه‌های عصبی عمیق از قبل آموزش دیده بر روی مجموعه داده‌های بسیار بزرگ مانند ImageNet آموزش داده می‌شوند و می‌توانند برای طبقه‌بندی تصویر جدید استفاده شوند. این داده شامل ۱/۲ میلیون تصویر از ۱۰۰۰ کلاس مختلف مانند گربه‌ها، سگ‌ها، جداول و غیره است. در سال ۲۰۱۵ تعدادی از محققین مایکروسافت معماری ResNet را ارائه دادند. این معماری از ۱۵۲ لایه تشکیل شده است که یک رکورد در هر سه بخش تشخیص اشیاء و کلاس‌بندی با استفاده از یک مدل به جا گذاشت. این مدل در حقیقت از قدرت انسان

پیش پردازش سیگنال‌های EEG و NIRS به صورت جداگانه اعمال شد. به سیگنال EEG، فیلتر باتروث مرتبه سوم میان‌گذر اعمال شد و فرکانس‌های مورد نیاز تصور حرکت باند آلفا و بتا، در حدود ۸ هرتز تا ۳۰ هرتز استخراج شدند. فرکانس نمونه‌برداری سیگنال‌های EEG پیش پردازش شده تا ۲۰۰ هرتز کاهش پیدا کردند. به سیگنال NIRS، فیلتر باتروث مرتبه سوم میان‌گذر اعمال شد و فرکانس‌های مورد نیاز برای کار، در حدود ۰/۱ هرتز تا ۰/۵ هرتز استخراج شدند. فرکانس نمونه‌برداری سیگنال‌های NIRS پیش پردازش شده تا ۱۰ هرتز کاهش پیدا کردند.

تبدیل سیگنال به تصویر

در این مطالعه از تبدیل موجک پیوسته (Wavelet Transform Continuous) برای تبدیل سیگنال EEG و NIRS به تصویر استفاده شد. تبدیل موجک، تابع عملکرد پنجره‌ای به نام موجک اصلی است، که در طول فرآیند تبدیل هم مقیاس‌پذیر است و هم تغییر می‌کند. بازنمایی ریاضی تبدیل موجک پیوسته در معادله ۱ نمایش داده شده است (۲۲):

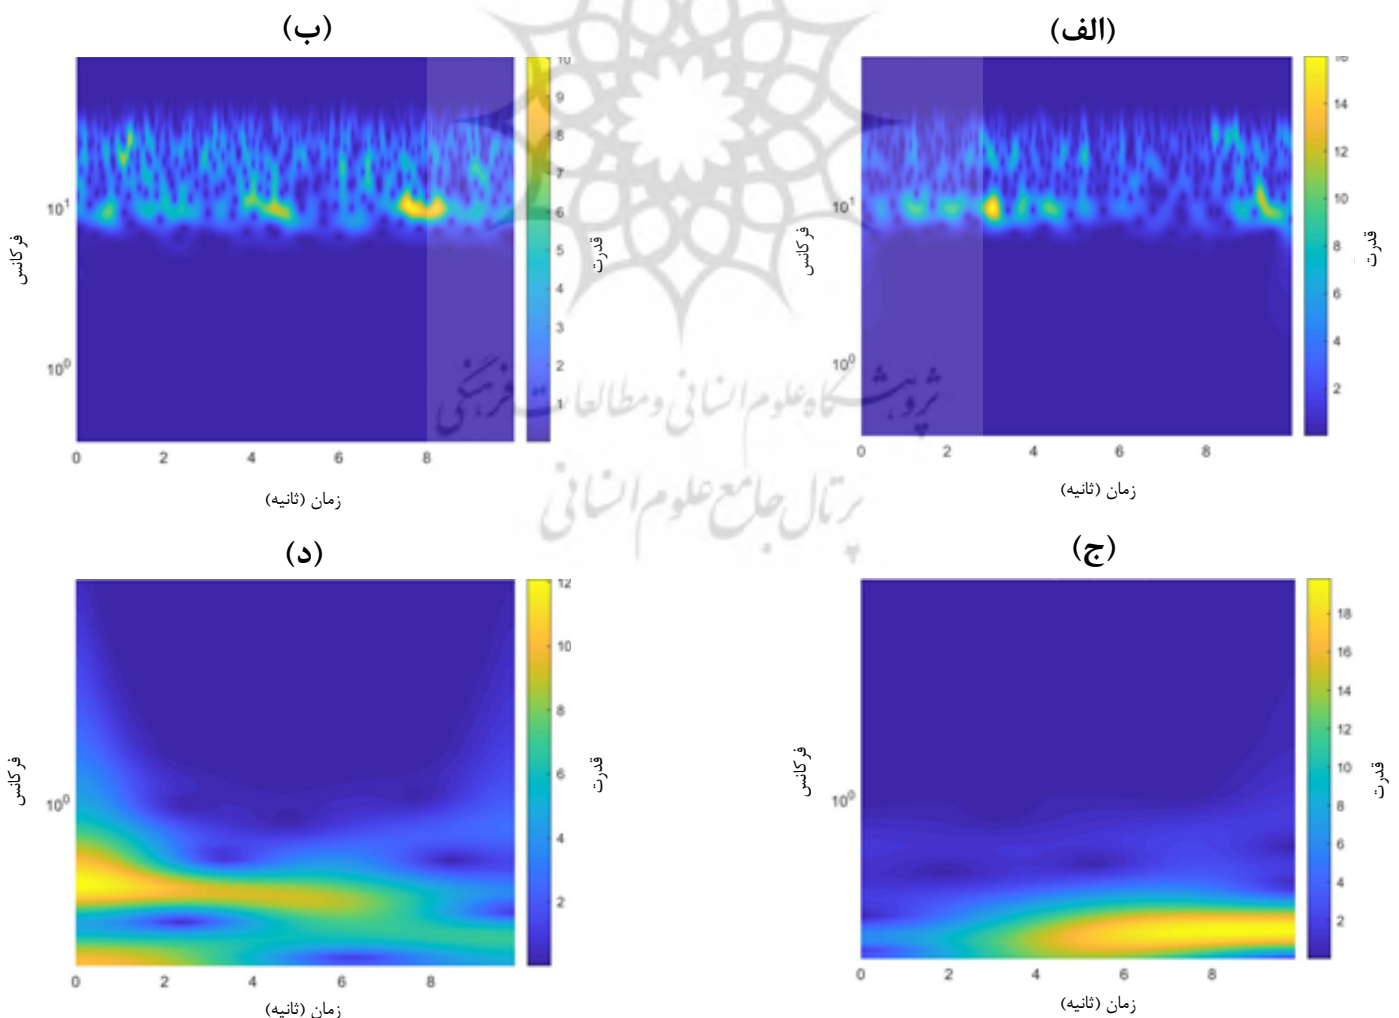
$$w_X(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t-\tau}{s} \right) dt \quad (1)$$

که در آن $W(s, \tau)$ ضرایب موجک هستند، تابع سای (ψ) کرنل ویولت

یافته‌ها

تصاویر زمان فرکانس با اعمال تبدیل موجک پیوسته در ۱۰ ثانیه سیگنال‌های EEG (۳۰ کانال) و NIRS (۳۶ کانال) در هنگام تصور حرکت دست راست و دست چپ به طور مجزا در برای ۲۹ فرد به دست آمد. در داده‌های EEG برای تصور حرکت از نواحی مختلف تصاویر اسکیلوگرام به دست آمد. در داده‌های NIRS نیز برای تصور حرکت از نواحی مختلف تصاویر اسکیلوگرام به دست آمد. ابعاد این تصاویر رنگی ۸۷۵×۶۵۶ برای EEG و ۸۷۵×۱۳۱۲ NIRS است. این تصاویر با استفاده از روش درون‌یابی مکعبی به ابعاد ۲۲۴×۲۲۴ ، تغییر ابعاد داده شدند تا مناسب اعمال به ورودی شبکه عصبی کانولوشنی پیش آموزش دیده در مراحل بعدی شوند. در انتها تصاویر اسکیلوگرام سیگنال EEG و NIRS با ابعاد یکسان ۲۲۴×۲۲۴ با یکدیگر جمع شده و تصویر حاصل با نام ترکیب اسکیلوگرام تصاویر EEG و NIRS نامیده شد. نمونه‌هایی از تصاویر اسکیلوگرام برای سیگنال EEG و NIRS در شکل ۲ نشان داده شده است.

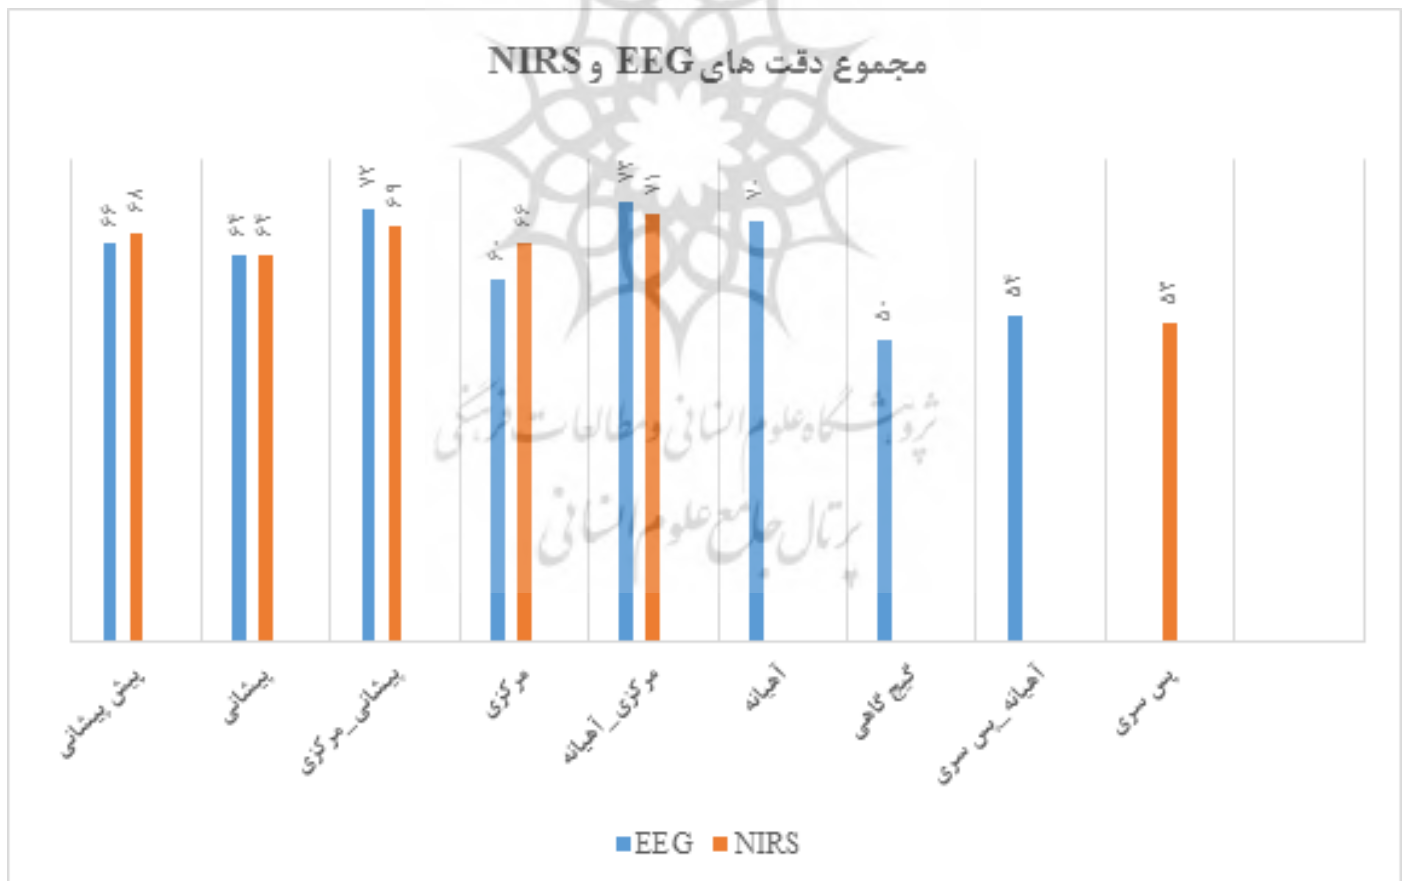
در تشخیص اشیاء بهتر بوده و با دقت به مراتب بالاتر از انسان‌ها اشیاء را تشخیص داد. ایده اصلی یک بلاک Residual این است که ورودی توسط یک لایه کانولوشن، لایه ReLU (۲۳) و یک لایه کانولوشن پردازش می‌شود. این معماری دارای نسخه‌های مختلف است. ما در این مقاله از ResNet18 استفاده کردیم و در لایه آخر از لایه فعال‌سازی Softmax استفاده نمودیم. لایه اول، لایه ورودی است که تصاویر با ابعاد $۲۲۴ \times ۲۲۴ \times ۳$ به آن داده می‌شوند. لایه‌های کانولوشنی ویژگی‌های تصاویر ورودی را استخراج می‌کنند و آخرین لایه برای طبقه‌بندی تصاویر استفاده می‌شوند. در شبکه ResNet18، لایه آخر شبکه که تماماً متصل است و ۱۰۰۰ نورون دارد با یک شبکه تماماً متصل جدید با دو کلاس جایگزین شده است. ضمناً شبکه ResNet18 علاوه بر آن که با استفاده از واحدهای Residual عملکرد را بهبود می‌بخشد، از ساختار قوی نیز برخوردار بوده و زمان بسیار کمتری رو برای تعلیم اختصاص می‌دهد و برای استفاده در لپ‌تاپ‌های معمولی نیاز به حافظه کمتری دارد.



شکل ۲. (الف) تصویر اسکیلوگرام سیگنال EEG در هنگام تصور حرکت دست راست. (ب) تصویر اسکیلوگرام سیگنال EEG در هنگام تصور حرکت دست چپ. (ج) تصویر اسکیلوگرام سیگنال NIRS در هنگام تصور حرکت دست راست. (د) تصویر اسکیلوگرام سیگنال NIRS در هنگام تصور حرکت دست چپ

(۶ فرد) برای تست استفاده شده است. تمام مراحل پردازش با نرم‌افزار MATLAB نسخه 2019a انجام شد. تمامی پردازش در لپ تاپ HP با سخت‌افزار Intel Core i7 3632QM 2.20GHz up to 3.20 GHz اجرا شده است. زمان پردازش با استفاده از شبکه از پیش آموزش دیده ResNet18 تقریباً ۱۰۰ ثانیه در مجموعه داده‌های تست بود. مجموع دقت‌های به دست آمده از شبکه پیش آموزش دیده شده برای تصاویر سیگنال‌های EEG و NIRS در شکل ۳ نشان داده شده است. ستون آبی رنگ نشان‌دهنده مجموع دقت برای تصاویر اسکیلوگرام سیگنال EEG و ستون قرمز رنگ نشان‌دهنده مجموع دقت به دست آمده برای تصاویر سیگنال NIRS از نواحی مختلف مغز به صورت جداگانه است. دقت‌های به دست آمده نشان‌دهنده آن است که ناحیه مرکزی-آهیانه‌ای (Central-Parietal) برای هر دو سیگنال دقت بالاتری را به دست می‌آورد و ناحیه گیج‌گاهی (Temporal) برای سیگنال EEG و ناحیه پس‌سری (Occipital) برای سیگنال NIRS پایین‌ترین دقت‌ها را به دست می‌آورند.

تصاویر اسکیلوگرام به دست آمده از نواحی سیگنال EEG، نواحی NIRS و همچنین ترکیب هر دو تصاویر برای ۲۹ فرد به طور مجزا برای استخراج ویژگی و طبقه‌بندی به یک شبکه عصبی عمیق از پیش آموزش دیده به نام شبکه ResNet18، وارد می‌شوند. در این قسمت باید تنظیمات آموزش شبکه انجام شود، تنظیماتی از جمله سایز mini-batch که چه تعداد تصویر در هر ایتراشن استفاده شود که برابر ۳۲ انتخاب شده، مشخص کردن تعداد اپوک که در این مطالعه برابر ۱۵ تعیین شده است. آموزش در سه مرحله مجزا برای تصاویر EEG، تصاویر NIRS و همچنین ترکیب مجموع هر دو تصاویر انجام شده است. برای هر فرد ۶۰ بار (۳ جلسه و هر جلسه ۲۰ بار) آزمایش انجام شد. از این ۶۰ بار ۳۰ آزمایش مربوط به تصور دست راست و ۳۰ آزمایش دیگر مربوط به تصور دست چپ بود. با توجه به داشتن ۲۹ فرد، برای هر کلاس $۳۰ \times ۲۹ = ۸۷۰$ داده وجود دارد. در این مطالعه از دادگان ۸۰ درصد افراد (۲۳ فرد) به طور تصادفی برای آموزش و بقیه ۲۰ درصد داده‌ها




شکل ۳. دقت‌های به دست آمده از شبکه پیش آموزش دیده ResNet18 برای نواحی مختلف مغز با استفاده از EEG و NIRS به طور مجزا (درصد)

کرده و دقت هر نواحی ترکیب شده را به دست می‌آوریم. دقت‌های به دست آمده از ترکیب نواحی برای سیگنال EEG و NIRS به ترتیب در شکل‌های ۴ و ۵ قابل مشاهده هستند. از دقت‌های حاصل

پس از به دست آوردن دقت هر ناحیه از مغز به صورت جداگانه، نواحی مغز را به صورت دوتایی برای رسیدن به دقت بالاتر با یکدیگر ترکیب می‌کنیم. ابتدا نواحی EEG و سپس نواحی NIRS را ترکیب

بالاترین دقت‌ها را برای EEG و NIRS به دست آورده‌اند را ترکیب می‌کنیم و سپس به شبکه از پیش آموزش دیده ResNet18 وارد می‌کنیم و دقت را به دست می‌آوریم. نتایج به دست آمده که در شکل ۶ نشان داده شده است، که بیان‌گر افزایش دقت به ۹۰ درصد می‌باشد.

در ادامه به ترکیب ۳ تایی از نواحی در سیگنال EEG و NIRS پرداختیم که دقت افزایش خاصی پیدا نکرد. بنابراین همان ترکیب ۲ تایی نواحی ذکر شده به عنوان بالاترین دقت در نظر گرفته شدند. در نهایت ما تصاویر ترکیب دو ناحیه از مغز پیشانی-مرکزی و مرکزی-آهیانه که



شکل ۶. دقت‌های به دست آمده از شبکه پیش آموزش دیده ResNet18 برای ترکیب تصاویر EEG و NIRS در بهترین ترکیب دو ناحیه از مغز (پیشانی-مرکزی و مرکزی-آهیانه) (درصد)

به انتخاب یک کار از چندین گزینه دارد. یک نتیجه خوب و منطقی زمانی حاصل می‌شود که نمونه‌های بزرگی از بیماران برای ارزیابی انواع مختلف فعالیت‌های مغز مورد استفاده قرار گیرد. یک مسئله دیگر در دستیابی به کنترل دستگاه، قابل اطمینان بودن سیگنال‌های مغز دریافتی از بیماران است. ممکن است برای یک بیمار دشوار باشد تا به صورت طولانی مدت بر روی عملکرد مغز تمرکز کند. بنابراین، دقت کنترل دستگاه به طور قابل توجهی کاهش می‌یابد. اگر یک کنترل مشترک برای دستیابی به نتایج بهتر برای یک بیمار اجرا شود بهتر خواهد بود. کنترل مشترک با استفاده از روش هوش مصنوعی همراه با یک رابط مغز و رایانه برای بهبود عملکرد کنترل استفاده می‌شود. برای مثال، در مورد کنترل صندلی چرخ‌دار، یک کنترل نیمه مستقل می‌تواند اجرا شود. سیگنال‌های مغز برای فعال یا غیرفعال کردن صندلی چرخ‌دار مورد استفاده قرار می‌گیرند در حالی که یک الگوریتم برنامه‌ریزی حرکت می‌تواند برای صندلی چرخ‌دار برای رسیدن به مقصد اجرا شود. در این مورد، بیمار می‌تواند کمتر در تولید فعالیت مغزی برای کنترل تمرکز کند و این باعث کاهش سطح استرس و اضطراب بیمار می‌شود. در پایان یکی از فوری‌ترین نیازهای فعلی برای کاربردی کردن EEG و NIRS ترکیبی، پیشرفت قابل توجه در توسعه سخت‌افزار است. یک سیستم ترکیبی کم حجم و راحت برای

بحث

در این مقاله از ترکیب سیگنال‌های EEG و NIRS و یک روش یادگیری عمیق استفاده شده و یک بهبود قابل توجه در دقت طبقه‌بندی تصور حرکت دست راست و چپ حاصل شد. از این نتایج، می‌توان چنین استنتاج کرد که شبکه عصبی کانولوشنی از پیش آموزش دیده ResNet18 در استخراج ویژگی‌های تصاویر اسکیلوگرام و طبقه‌بندی ویژگی‌ها بازدهی بالا را دارد. این کار در بهبود دقت طبقه‌بندی تصور حرکت دست راست و چپ موثر بوده است. نتایج حاصل نشان می‌دهد که ترکیب تصاویر اسکیلوگرام سیگنال‌های EEG و NIRS در ترکیب دو ناحیه از مغز سبب بهبود نتایج شده است و در مقایسه با مطالعات پیشین دقت قابل توجهی ایجاد کرده است (۱۲، ۱۹).

با توجه به نتایجی که از این مقاله به دست آمده چند پیشنهاد را می‌توان برای پژوهش‌های آتی بیان کرد: اولین مسئله الزام استفاده از بیماران به جای افراد سالم است. اگر برنامه‌های رابط مغز و رایانه با موفقیت در افراد سالم اجرا شوند، ممکن است همین روش برای بیماران با دقت کمتر انجام شود. ضرورت دوم انتخاب فعالیت مغزی (تصور حرکت دست راست یا چپ) مناسب برای بیماران است. در حال حاضر نمی‌توانیم بگوییم که فعالیت مغز برای بیمار مناسب است. یک فرد سالم می‌تواند هر کار معقولی را انجام دهد، اما یک بیمار نیاز

ناحیه از مغز (پیشانی_مرکزی و مرکزی_آهیانه) سیگنال‌های EEG و NIRS با استفاده از روش شبکه عصبی کانولوشنی از پیش آموزش دیده ResNet18 با دقت ۹۰ درصد برای طبقه‌بندی تصور حرکت دست راست و چپ استفاده شد.

تشکر و قدردانی

بر خود لازم می‌دانیم از تمام کسانی که ما را در انجام این پژوهش همراهی کردند، کمال تشکر و قدردانی را داشته باشیم.

تشخیص و ادغام سیگنال‌های همودینامیک و نورونی برای بیماران نیاز است. سخت‌افزار باید بتواند از آرتیفکت‌های حرکتی تولید شده توسط بیماران جلوگیری کند. بنابراین، تحقیق باید بر روی توسعه سخت‌افزار تمرکز کند که می‌تواند به طور موثری فعالیت مغزی عمیق را در زمان واقعی به دست آورد.

نتیجه‌گیری

در این مقاله از استخراج ویژگی‌های تصاویر اسکیلوگرام ترکیب دو

References

1. Pfurtscheller G, Allison B, Bauernfeind G, Brunner C, Solis Escalante T, Scherer R, et al. The hybrid BCI. *Frontiers in Neuroscience*. 2010;4:3.
2. Mitchell JD, Borasio GD. Amyotrophic lateral sclerosis. *Lancet*. 2007;369(9578):2031-2041.
3. Kaufmann T, Herweg A, Kubler A. Toward brain-computer interface based wheelchair control utilizing tactually-evoked event-related potentials. *Journal of NeuroEngineering and Rehabilitation*. 2014;11(1):7.
4. Birbaumer N, Cohen LG. Brain-computer interfaces: Communication and restoration of movement in paralysis. *The Journal of Physiology*. 2007;579(3):621-636.
5. Hwang HJ, Kim S, Choi S, Im CH. EEG-based brain-computer interfaces: A thorough literature survey. *International Journal of Human-Computer Interaction*. 2013;29(12):814-826.
6. Maye A, Zhang D, Wang Y, Gao S, Engel AK. Multimodal brain-computer interfaces. *Tsinghua Science and Technology*. 2011;16(2):133-139.
7. Ko LW, Ranga SS, Komarov O, Chen CC. Development of single-channel hybrid BCI system using motor imagery and SSVEP. *Journal of Healthcare Engineering*. 2017;2017. 3789386.
8. Wang Z, Yu Y, Xu M, Liu Y, Yin E, Zhou Z. Towards a hybrid BCI gaming paradigm based on motor imagery and SSVEP. *International Journal of Human-Computer Interaction*. 2019;35(3):197-205
9. Yu T, Xiao J, Wang F, Zhang R, Gu Z, Cichocki A, Li Y. Enhanced motor imagery training using a hybrid BCI with feedback. *IEEE Transactions on Biomedical Engineering*. 2015;62(7):1706-1717.
10. Ma T, Li H, Deng L, Yang H, Lv X, Li P, et al. The hybrid BCI system for movement control by combining motor imagery and moving onset visual evoked potential. *Journal of Neural Engineering*. 2017;14(2):026015.
11. Feng Z, He Q, Zhang J, Wang L, Zhu X, Qiu M. A hybrid BCI system based on motor imagery and transient visual evoked potential. *Multimedia Tools and Applications*. 2020;79(15):10327-10340.
12. Fazli S, Mehnert J, Steinbrink J, Curio G, Villringer A, Muller KR, et al. Enhanced performance by a hybrid NIRS-EEG brain computer interface. *Neuroimage*. 2012;59(1):519-529.
13. Shin J, Von Luhmann A, Blankertz B, Kim DW, Jeong J, Hwang HJ, et al. Open access dataset for EEG+NIRS single-trial classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2016;25(10):1735-1745.
14. Shin J, Kwon J, Im CH. A ternary hybrid EEG-NIRS brain-computer interface for the classification of brain activation patterns during mental arithmetic, motor imagery, and idle state. *Frontiers in Neuroinformatics*. 2018;12:5.
15. Kaiser V, Bauernfeind G, Kreilinger A, Kaufmann T, Kubler A, Neuper C, et al. Cortical effects of user training in a motor imagery based brain-computer interface measured by

fNIRS and EEG. *NeuroImage*. 2013;85(1):432-444.

16. Ahn S, Jun SC. Multi-modal integration of EEG-fNIRS for brain-computer interfaces - current limitations and future directions. *Frontiers in Human Neuroscience*. 2017;11:503.

17. Buccino AP, Keles HO, Omurtag A. Hybrid EEG-fNIRS asynchronous brain-computer interface for multiple motor tasks. *PLoS One*. 2016;11(1):e0146610.

18. Khan MJ, Hong MJ, Hong K-S. Decoding of four movement directions using hybrid NIRS-EEG brain-computer interface. *Frontiers in Human Neuroscience*. 2014;8:244.

19. Koo B, Lee HG, Nam Y, Kang H, Koh CS, Shin HC, et al. A hybrid NIRS-EEG system for self-paced brain computer interface with online motor imagery. *Journal of Neuroscience Methods*. 2015;244:26-32.

20. Acharya UR, Oh SL, Hagiwara Y, Tan JH, Adeli H. Deep convolutional neural network for the automated detection and

diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*. 2018;100:270-278.

21. Turk O, Ozerdem MS. Epilepsy detection by using scalogram based convolutional neural network from EEG signals. *Brain Sciences*. 2019;9(5):115.

22. Eltvik A. Deep learning for the classification of EEG time-frequency representations [MSc Thesis]. Trondheim, Norway:Norwegian University of Science and Technology Department of Engineering Cybernetics;2018.

23. Wang H, Raj B. On the origin of deep learning. Available online: <https://arxiv.org/abs/1702.07800> (accessed on 21 January 2019).

24. Allison BZ, Brunner C, Kaiser V, Muller-Putz GR, Neuper C, Pfurtscheller G. Toward a hybrid brain-computer interface based on imagined movement and visual attention. *Journal of Neural Engineering*. 2010;7(2):026007.

