

علمی - پژوهشی

طبقه‌بندی سیگنال‌های ترکیبی EEG-fNIRS با استفاده از ویژگی‌های عمیق کاهش یافته برای کاربردهای BCI

اکبر اصغرزاده بناب^{۱*}، امیر حاتمیان^۲، مهدی اوریا^۳

۱- استادیار، دانشگاه فرماندهی و ستاد آجا، ۲- دانشجوی دکتری، دانشگاه ارومیه

(دریافت: ۱۴۰۲/۰۵/۰۴، پذیرش: ۱۴۰۲/۰۸/۰۵)

چکیده

رابط مغز و کامپیوتر (BCI) مبتنی بر تخیل حرکتی (MI) به‌عنوان یک روش مؤثر برای برقراری ارتباط مستقیم بین مغز و دستگاه‌های الکترونیکی خارجی ارائه شده است. مسئله اصلی در سیستم‌های BCI تبدیل سیگنال‌های تولید شده در مغز به دستورات قابل اعتماد برای کنترل دستگاه‌های الکترونیکی است. سیگنال الکتروانسفالوگرافی (EEG) پرکاربردترین سیگنال در پژوهش‌های مرتبط با BCI است. اخیراً ترکیب با برخی سیگنال‌های حیاتی دیگر نظیر طیف‌سنجی نزدیک مادون قرمز (NIRS) برای افزایش کارایی سیستم‌های BCI مورد توجه قرار گرفته است. مهم‌ترین چالش در سیستم‌های BCI با چندین سیگنال حیاتی، استخراج ویژگی و ترکیب ویژگی‌های سیگنال‌های مختلف است. برای این منظور، در این مقاله ابتدا سیگنال‌های EEG و اجزای NIRS، شامل HbO و HbR، به باندهای فرکانسی مختلف تجزیه شدند. در ادامه با استفاده از شبکه‌های عصبی کانولوشنی یک‌بعدی، ویژگی‌های عمیق از هر زیرباند استخراج شده و با هم ادغام می‌شوند. با توجه به ابعاد بالای بردار ویژگی نهایی، با استفاده از تجزیه و تحلیل اجزای اصلی با هسته (KPCA)، ویژگی‌های غیرمفید را حذف کرده و ویژگی‌های باقیمانده با استفاده از بردار پشتیبان ماشین طبقه‌بندی می‌شوند. نتایج نشان می‌دهند روش پیشنهادی دقت بالایی دارد و روش‌های ارائه شده اخیر را بهبود می‌دهد.

کلیدواژه‌ها: الکتروانسفالوگرافی، شبکه عصبی کانولوشنی، طیف‌سنجی نزدیک مادون قرمز، کاهش ویژگی، واسط مغز و کامپیوتر.

Classification of Hybrid EEG-fNIRS Signals using Reduced Deep Features for BCI Applications

Akbar Asgharzadeh-Bonab^{*}, Amir Hatamian and Mahdi Ouria

AJA Command and Staff University, Tehran, Iran

(Received: 2023/07/26, Accepted: 2023/10/27)

Abstract

The Motor Imagery (MI)-based Brain-Computer Interface (BCI) has been proposed as an effective method for direct communication between the brain and external electronic devices. In BCI systems, the main challenge is converting brain signals into reliable commands to control electronic devices. Electroencephalogram (EEG) is the most widely used signal in BCI-related research. Recently, it has been considered with some other biological signals, such as Near-Infrared Spectroscopy (NIRS), to increase the efficiency of BCI systems. The most important challenge in multi-modal BCI systems is combining the extracted features from different signals. For this purpose, in this paper, EEG and NIRS components, including HbO and HbR, were first decomposed into different frequency bands. Next, deep features are extracted from each band using a One-Dimensional (1D) Convolutional Neural Network (CNN). Since the final feature vector has a high dimension, Kernel Principal Component Analysis (KPCA) is employed to remove the irrelevant features, and the remaining ones are classified using the Support Vector Machine (SVM). The results show that the proposed method has high accuracy and improves the recently presented methods.

Keywords: EEG, Convolutional Neural Network, NIRS, Feature Reduction, BCI.

^{1*}Corresponding Author E-mail: Akbar.asgharzadeh@casu.ac.ir

۱. مقدمه

سیستم‌های مبتنی بر fMRI هزینه راه‌اندازی گران‌تری دارند. همچنین، سیستم‌های مبتنی بر fMRI، دارای معایبی مانند نویز بالا و راحتی کم را برای فرد در حین اندازه‌گیری هستند. برای جلوگیری از این اشکالات، اخیراً مطالعات بر روی ترکیب روش‌های مختلف ضبط سیگنال متمرکز شده است. استفاده از NIRS که کمتر تحت تأثیر حرکات بدن و نویز الکتریکی قرار می‌گیرد، در حال گسترش است. با این حال، NIRS زمانی که به‌تنهایی مورد استفاده قرار می‌گیرد، دارای معایبی است که مهم‌ترین مورد، عمق نفوذ کم است [۹]. سیگنال NIRS تغییر در سطح هموگلوبین اکسیژن (HbO^2) و هموگلوبین بدون اکسیژن (HbR^2) را اندازه‌گیری می‌کند. برای این منظور، تحلیل جریان خون را در طول فعال‌سازی عصبی انجام می‌دهد. با توجه به مزایا و معایب مدل‌های EEG و NIRS، برای استفاده در کنار هم کاملاً مناسب هستند.

در حالی که ترکیب EEG و NIRS بر اشکالات استفاده مستقل آن‌ها غلبه می‌کند، چالش‌های مختلف همچنان ادامه دارند که یکی از مهم‌ترین آن‌ها، تداخل نویز است. اگرچه این وضعیت تا حدودی با روش‌های مختلف پیش‌پردازش سیگنال قابل حل است، اما به دلیل پیش‌پردازش اطلاعات از دست می‌رود. مشکل دوم پیچیدگی سیگنال‌ها و درک این‌که آیا منبع سیگنال‌های به‌دست‌آمده توسط دستگاه‌ها، ناحیه مورد نظر در مغز است یا خیر. درک این‌که آیا این سیگنال‌ها در اثر موارد مختلفی مانند حرکات سر و پلک‌زدن ایجاد می‌شوند، چالش‌برانگیز است. این مشکل اساس بسیاری از مطالعات طبقه‌بندی را تشکیل می‌دهد. تفسیر این سیگنال‌ها انتقال حرکت را به دستگاه‌های خارجی فراهم می‌کند. چالش دیگر استخراج ویژگی‌های قوی و مؤثر است. انتخاب ویژگی‌های قوی با روش‌های دستی با توجه به پیچیدگی سیگنال‌های EEG بسیار دشوار است [۱۰]. مطالعات فعال برای رفع مشکلات ذکر شده با استفاده از روش‌های هوش مصنوعی ادامه دارد. اهداف این مقاله به‌صورت خلاصه به شرح ذیل قابل بیان است:

- ترکیب سیگنال‌های EEG و fNIRS برای افزایش دقت در کاربردهای BCI
- استفاده از شبکه‌های عصبی کانولوشنی (CNN^4) برای استخراج ویژگی‌های عمیق از زیرباند‌های مختلف سیگنال‌های EEG و fNIRS
- کاهش ویژگی‌های عمیق استخراج‌شده برای کاهش پیچیدگی محاسباتی طبقه‌بندی

واسط‌های بین مغز و رایانه (BCI^1) شامل ثبت فعالیت الکتریکی مغز و تبدیل این سیگنال‌ها به دستورات کامپیوتری برای کنترل دستگاه‌های الکترونیکی خارجی است. سیگنال‌های تولید شده توسط مغز با کمک نخاع به اندام‌ها منتقل می‌شود که این هدایت عصبی بدن انسان را قادر به حرکت می‌کند [۱]. اگر این فرآیند، یک سیستم الکتریکی در نظر گرفته شود، سیستم عصبی محیطی انتقال سیگنال را انجام می‌دهد. به عبارت دیگر، سیستم عصبی محیطی به‌عنوان یک کابل عمل می‌کند. زمانی که این سیستم به هر دلیلی آسیب ببیند یا شکسته شود، فرد دچار اختلالات حرکتی می‌شود. بسیاری از بیماران با ناتوانی‌های حرکتی شدید نمی‌توانند نیازهای روزانه خود را تأمین کنند. فناوری BCI قادر است فعالیت الکتریکی تولید شده در مغز را، با کمک کابل‌هایی که در خارج از مجسمه قرار می‌گیرند، بگیرد و با استفاده از این سیگنال‌ها، یک دستگاه خارجی حرکت دهد و از این طریق می‌تواند به افراد معلول کمک کند [۲]. بسیاری از مطالعات BCI می‌توانند صندلی‌های چرخ‌دار [۳]، بازوهای روباتیک [۴، ۵] و سایر دستگاه‌های خارجی را کنترل کنند [۶].

طبقه‌بندی سیگنال‌های مغزی نشان‌دهنده فعالیت عصبی مربوط به تخیل برخی از حرکات حرکتی یا طبقه‌بندی سیگنال‌های مغزی تولید شده در حین انجام وظایف ذهنی مختلف از جمله وظایف اساسی BCI است. روش‌های تهاجمی و غیرتهاجمی برای ضبط سیگنال‌های مغزی وجود دارد که هر کدام مزایا و معایبی دارند. روش‌های تهاجمی، مانند ضبط داخل قشری، دارای اشکالات قابل توجهی مانند طول عمر محدود و تمایل به بدتر شدن تدریجی کیفیت سیگنال ثبت شده است. علاوه بر این، روش‌های غیرتهاجمی مانند الکتروانسفالوگرافی (EEG^2)، مگنتوانسفالوگرافی (MEG^3)، تصویربرداری تشدید مغناطیسی عملکردی ($fMRI^4$) و طیف‌سنجی مادون‌قرمز نزدیک ($NIRS^5$) دارای معایبی مانند رادیواکتیویته و فاصله تا فعالیت الکتریکی هستند.

مطالعات BCI سنتی بیشتر سیگنال‌های EEG را در بین روش‌های غیرتهاجمی ترجیح می‌دهند [۷]. علاوه بر این، تعداد سیستم‌های BCI با استفاده از fMRI نسبتاً زیاد است [۸]. اگرچه روش‌های مبتنی بر EEG دارای مزایای زیادی مانند وضوح زمانی خوب، هزینه متوسط و ارتباط با سایر دستگاه‌ها هستند، اما تحت تأثیر نویز الکتریکی و مصنوعات حرکتی قرار می‌گیرند.

¹ Brain-Computer Interface (BCI)

² Electroencephalography (EEG)

³ Magnetoencephalography (MEG)

⁴ Functional Magnetic Resonance Imaging (fMRI)

⁵ Near-Infrared Spectroscopy (NIRS)

⁶ Oxygenated Hemoglobin (HbO)

⁷ Deoxygenated Hemoglobin (HbR)

⁸ Convolutional Neural Network (CNN)

- انجام شبیه‌سازی‌های مختلف برای ارزیابی کار آبی روش پیشنهادی و مقایسه آن با روش‌های ارائه شده در سال‌های اخیر.

۲. پیشینه تحقیق

در این بخش مروری بر روش‌های طبقه‌بندی و روش‌های پیش-پردازش سیگنال‌های EEG و NIRS ارائه شده است. برای این منظور مطالعات انجام شده تنها با استفاده از سیگنال‌های EEG، سپس تنها با استفاده از سیگنال‌های NIRS و در نهایت با ترکیب این دو سیگنال مورد بررسی قرار می‌گیرد. مطالعات زیادی در گذشته برای استفاده در تجزیه و تحلیل سیستم‌های BCI با استفاده از EEG انجام شده است. Yongwook و همکاران [۱۱]، آنالیز طیفی توان را برای استخراج ویژگی‌های دامنه از EEG پیشنهاد کردند. سپس از نسبت Fisher برای انتخاب ویژگی‌های مهم استفاده کردند. Lee و همکاران [۱۲]، سه سطح توجه سیگنال‌های EEG را با استفاده از یک طبقه‌بند k NN بر اساس مدل مانیکین خود ارزیاب طبقه‌بندی کردند. Alazrai و همکاران [۱۳]، از یک مدل توزیع زمان - فرکانس درجه دوم برای تجزیه و تحلیل سیگنال‌های EEG استفاده کردند. آن‌ها مولفه‌های طیفی متغیر با زمان را بررسی کردند و ویژگی‌هایی را از سیگنال‌های EEG استخراج کردند. Mondini و همکاران [۱۴]، چارچوبی را بر اساس روش الگوی فضایی مشترک پیشنهاد کردند. سپس، آن‌ها ویژگی‌ها را با استفاده از ماشین بردار پشتیبان (SVM^2) طبقه‌بندی کردند. Arvaneh و همکاران [۱۵]، یک الگوریتم فضایی مشترک پراکنده برای انتخاب کانال‌های مؤثر از سیگنال‌های EEG پیشنهاد کردند. روش آن‌ها دقت طبقه‌بندی را تقریباً ۱۰٪ افزایش داد. Gaur و همکاران [۱۶]، یک روش فیلتر ویژه موضوعی را برای سیگنال EEG بر اساس فیلتر تجزیه حالت تجربی چندمتغیره پیشنهاد کردند. سپس، آن‌ها ویژگی‌های متقابل کانال را استخراج کرده و اطلاعات فرکانس خاص را برای افزایش عملکرد طبقه‌بندی بومی‌سازی کردند. تغییرات سیگنال EEG مبتنی بر حالات صورت را با استفاده از شبکه عصبی مصنوعی بررسی شده است [۱۷]. Pan و همکاران [۱۸]، روی تعیین باندهای فرکانسی برای بررسی اثر عملکرد باندهای فرکانسی کار کردند. در تحقیق آن‌ها، فرآیند طبقه‌بندی با SVM انجام شد. از سوی دیگر، پس از ظهور معماری CNN و دستیابی به دستاوردهای برجسته تقریباً در هر زمینه، مطالعات CNN در طبقه‌بندی EEG اعمال شد. Tan و همکاران [۱۹]، عملکرد مدل‌های CNN از پیش آموزش‌دیده را در طبقه‌بندی EEG با استفاده از رویکرد یادگیری انتقال آزمایش کرده‌اند. Fahimi و همکاران [۲۰]، از قدرت استخراج ویژگی معماری CNN با استفاده از سه

نمایش EEG مختلف استفاده کردند. موسوی و همکاران [۲۱]، ویژگی‌های آماری و ضرایب اتورگرسیون را با اعمال تابع موجک به‌عنوان ویژگی استخراج کردند و در ادامه با انتخاب ویژگی‌های مؤثر با روش 3SFFS ، آن‌ها را با استفاده از طبقه‌بند‌های مختلف کلاس‌بندی کردند.

Borghaei و همکاران [۲۲]، بهترین باندها و ویژگی‌های NIRS عملکردی (fNIRS⁴) را با استفاده از نقشه‌برداری پارامتری آماری و تحلیل همبستگی انتخاب کردند. آن‌ها این ویژگی‌ها را با استفاده از تحلیل تشخیصی خطی طبقه‌بندی کردند. Bauernfeind و همکاران [۲۳]، تجزیه و تحلیل تفکیک خطی، تجزیه و تحلیل متمایز درجه دوم و SVM را برای طبقه‌بندی سیگنال‌های fNIRS بررسی کردند. Zhang و همکاران [۲۴]، امکان به‌کارگیری الگوریتم مبتنی بر الگوی فضایی مشترک را برای طبقه‌بندی سیگنال fNIRS در کاربردهای BCI بررسی کردند. Erdogan و همکاران [۲۵]، ویژگی‌های موضوعی خاص را استخراج کردند تا به طور خودکار وظایف تخیل حرکت (MI⁵) و اجرای حرکتی (ME⁶) را با کمک سیگنال‌های NIRS طبقه‌بندی کنند. آن‌ها این ویژگی‌ها را با استفاده از جنگل تصادفی و شبکه‌های عصبی مصنوعی طبقه‌بندی کردند. Noori و همکاران [۲۶]، شش ویژگی از سیگنال‌های NIRS استخراج کردند (شامل شیب، میانگین، واریانس، اوج، کشیدگی، و چولگی). سپس این ویژگی‌ها با الگوریتم ژنتیک ترکیبی با SVM طبقه‌بندی می‌شوند. Choi و همکاران [۲۷]، سیگنال‌های NIRS را با یک روش مبتنی بر CNN طبقه‌بندی کردند تا معایب روش‌های مبتنی بر انتخاب ویژگی دستی را از بین ببرند. Janani و همکاران [۲۸]، مطالعه‌ای از جمله مزایای استفاده از راه‌حل‌های حاوی CNN برای BCI مبتنی بر NIRS نسبت به روش‌های دیگر ارائه کردند.

اخیراً، سیستم‌های هیبریدی EEG-NIRS توجه زیادی را برای افزایش عملکرد سیستم‌های BCI نسبت به حالتی که سیگنال‌های EEG یا NIRS به‌تنهایی مورد استفاده قرار می‌گیرند، به خود جلب کرده‌اند. Fazli و همکاران [۲۹]، رویکردی مبتنی بر NIRS و EEG پیشنهاد کردند. آن‌ها از الگوی BCI مبتنی بر ریتم حرکتی حسی در زمان واقعی استفاده کردند که به موفقیت طبقه‌بندی تقریباً ۹۰٪ رسیدند. Liu و همکاران [۳۰]، عملکرد طبقه‌بندی روش‌های EEG به‌تنهایی، NIRS به‌تنهایی و مبتنی بر-EEG NIRS را مقایسه کردند. Firooz و همکاران [۳۱]، ویژگی‌های سنتی، مانند کشیدگی و چولگی، را از سیگنال‌های NIRS و EEG استخراج کردند. در ادامه، تعداد ویژگی‌ها را با روش‌های

³ Sequential Forward Feature Selection (SFFS)

⁴ Functional NIRS (fNIRS)

⁵ Motor Imagery (MI)

⁶ Motor Execution (ME)

¹ k-Nearest Neighbor (kNN)

² Support Vector Machine (SVM)

نیمی از سیگنال‌های ضبط‌شده برچسب دست چپ و نیمی دیگر با برچسب دست راست می‌باشد. سی الکتروود برای ثبت سیگنال‌های EEG استفاده می‌شود که طبق سیستم بین‌المللی ۵-۱۰ قرار داده شده است. این الکتروودها عبارت‌اند از AFp2, AFp1, FCC3h, F8, F7, F4, F3, AFF6h, AFF5h, AFF2h, AFF1h, FCC4h, FCC5h, FCC6h, CCP4h, CCP3h, Cz, T8, T7, FCC6h, FCC5h, FCC4h, POO2, POO1, PPO2h, PPO1h, P8, P7, Pz, CCP6h, CCP5h و Fz برای الکتروود زمین. چهارده منبع تابش کننده و شانزده آشکارساز برای ثبت داده‌های NIRS استفاده می‌شود که منجر به سی و شش کانال فیزیولوژیکی می‌شود که عبارت‌اند از AF7Fp1, AF4AFz, FpzFp2, FpzAFz, FpzFp1, AF3AFz, AF3Fp1, AF4Fp2, AF4Fp2, Oz5CPO, Oz5CPO, AF5CPO, AF4Fp2, AF4Fp2, FC3C3, FC3FC5, C5C3, Oz5CPO, Oz5CPO, Oz5CPO, C1FC1, C1C3, CP3CP1, CP3C3, CP3CP5, FC3FC1, FC4C4, FC4FC2, C2C4, C2CP2, C2FC2, C1CP1, FCC4, CP4CP6, CP4CP6, CP4CP6, CP4CP6, FC4FC6

۴. روش پیشنهادی برای طبقه‌بندی سیگنال‌های ترکیبی EEG-fNIRS

بلوک دیاگرام روش پیشنهادی برای طبقه‌بندی سیگنال‌های BCI در شکل (۲) نشان داده شده است. همان‌طور که مشاهده می‌شود روش پیشنهادی شامل چهار بخش اصلی به شرح (۱) تجزیه سیگنال‌های حیاتی به باندهای فرکانسی مختلف، (۲) استخراج ویژگی‌های عمیق، (۳) ترکیب و کاهش ویژگی‌ها و (۴) طبقه‌بندی می‌باشد. در ادامه هر بخش با جزئیات شرح داده می‌شود. نوآوری روش پیشنهادی، ترکیب اطلاعات سیگنال‌های EEG و fNIRS با ترکیب ویژگی‌های عمیق استخراج شده از زیرباندهای مختلف سیگنال‌ها و کاهش آن‌ها قبل از اعمال به طبقه‌بند برای بهبود دقت طبقه‌بندی می‌باشد.

۴-۱. تجزیه به باندهای فرکانسی مختلف

سیگنال‌های fNIRS، ابتدا به اجزای HbO و HbR تجزیه می‌شود. فرض کنید $\Delta c_{HbO}(t)$ و $\Delta c_{HbR}(t)$ به ترتیب نشان دهنده اجزای HbO و HbR هستند. دو سیگنال با طول موج های ۷۶۰ نانومتر و ۸۳۰ نانومتر با نرخ نمونه‌برداری ۱/۸ هرتز استفاده می‌شود.

پس از اعمال قانون اصلاح‌شده بیر - لامبرت، سیگنال‌های EEG، HbO و HbR را داریم. این سیگنال‌ها بر اساس چارچوب پیشنهادی به پنج باند مجزا تقسیم می‌شوند. برای این منظور، از فیلترهای فرکانس گزین مختلف استفاده می‌شود.

تجزیه و تحلیل تفکیک‌پذیر خطی و تجزیه و تحلیل مؤلفه اصلی کاهش دادند. در نهایت، آن‌ها این بردارهای ویژگی را با استفاده از رگرسیون بردار پشتیبان طبقه‌بندی کردند. Kim و همکاران [۳۲]، با مقایسه روش‌های مختلف مزایای سیستم‌های NIRS-EEG را آشکار کردند. Ergun و همکاران [۹]، از مقادیر تجزیه ارزش منفرد تبدیل سریع والش - هادامارد برای استخراج ویژگی‌ها از EEG-NIRS استفاده کردند. سپس طبقه‌بند kNN برای طبقه‌بندی این ویژگی‌ها استفاده شد. Chiarelli و همکاران [۳۳]، از معماری شبکه عصبی عمیق برای طبقه‌بندی وظایف خیالی حرکتی چپ و راست استفاده کردند. Rahman و همکاران [۳۴]، قدرت استخراج ویژگی CNN را برای طبقه‌بندی هشت محرک مختلف مرتبط با حرکت را تسهیل کردند. شبکه FGANet در [۳۵] پیشنهاد شده است که ابتدا با استفاده از تبدیل تنسور، سیگنال‌های EEG و fNIRS یک‌بعدی را به سیگنال‌های سه‌بعدی تبدیل می‌کند و ادامه به استخراج ویژگی‌های عمیق از هر کدام از سیگنال‌ها می‌پردازد. شبکه MCFHNet برای ترکیب چند کانالی سیگنال‌های ترکیبی EEG و fNIRS در [۳۶] پیشنهاد شده است. حسنی و همکاران [۳۷] ویژگی‌های مبتنی بر RQA^۱ را از سیگنال‌های EEG و fNIRS استخراج کردند. در ادامه برای کاهش تعداد ویژگی‌های استخراج شده از LASSO^۲ استفاده کرده و در نهایت طبقه‌بندی با استفاده از SVM انجام شد.

۳. پایگاه داده

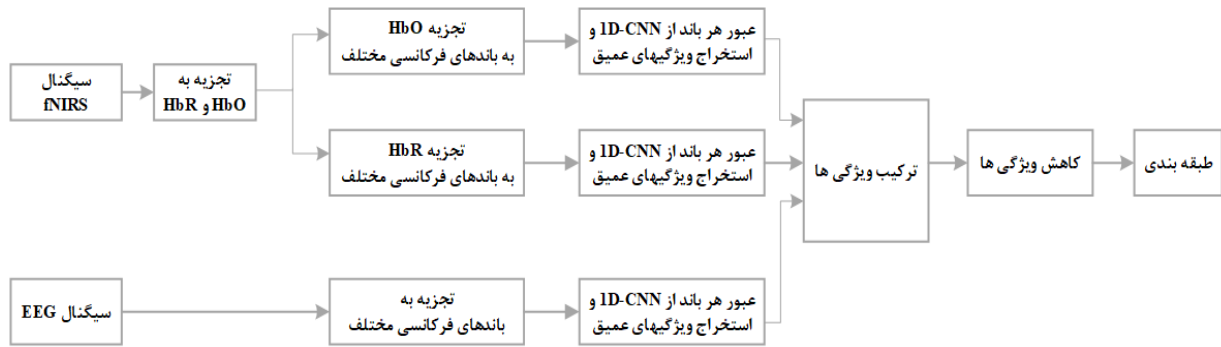
مجموعه داده شامل سیگنال‌های EEG و NIRS مبتنی بر تخیل در طول حرکت باز و بسته‌شدن دست راست و چپ است [۴۰، ۴۱]. سیگنال‌های ۲۹ فرد سالم در یک اتاق روشن معمولی ثبت شده‌اند که شامل ۱۴ مرد و ۱۵ زن در محدوده سنی ۲۴،۸ تا ۳۲،۲ سال هستند. هنگام ضبط سیگنال‌های EEG و NIRS، اشخاص راحت هستند و می‌نشینند. آن‌ها یک فلش سیاه را دنبال می‌کنند که در مرکز یک صفحه سفید اشاره می‌کند. فاصله بین اشخاص و صفحه‌نمایش ۱،۶ متر است. هر شخص هر کاری را ۲۰ بار تکرار می‌کند. از آنجایی که در مجموع سه جلسه برگزار می‌شود، برای هر شخص ۶۰ ضبط سیگنال وجود دارد. اطلاعات دقیق در مورد تحقق یک جلسه و مدت‌زمان آن در شکل (۱) ارائه شده است که پارادایم آزمایشی را با جزئیات نشان می‌دهد.



شکل ۱. نمودار شماتیک توالی اخذ سیگنال

¹ Recurrence Quantification Analysis (RQA)

² Least Absolute Shrinkage and Selection Operator (LASSO)



شکل ۲. بلوک دیاگرام روش پیشنهادی برای طبقه‌بندی سیگنال‌های BCI

CNN، یک معماری جدید یا یک‌لایه جدید CNN اغلب پیشنهاد می‌شود. به همین دلیل، انتخاب مناسب در بین معماری‌های فعلی CNN یا ایجاد یک معماری CNN با استفاده از لایه‌های فعلی چالش است. شبکه‌های عصبی کانولوشنی یک نوع از شبکه‌های عصبی عمیق است که ویژگی‌هایی را از سیگنال استخراج می‌کند که به‌عنوان ورودی در کاربردهای خاصی مانند طبقه‌بندی سیگنال، طبقه‌بندی تصویر و تشخیص چهره را انجام دهد. یک CNN دارای یک یا چندلایه کانولوشن برای استخراج ویژگی‌های ساده است که عملیات کانولوشن (ضرب مجموعه‌ای از وزن‌ها با ورودی) را درحالی‌که ویژگی‌های حیاتی (اطلاعات مکانی و زمانی) را بدون نظارت انسان حفظ می‌کند، اجرا می‌کند. امروزه در اکثر کاربردهای یادگیری ماشین، CNN نیاز است؛ زیرا راه‌حل مهم و دقیق‌تری برای مسائل طبقه‌بندی سیگنال‌ها و تصاویر است. همچنین، در شبکه‌های عصبی معمولی، با افزایش اندازه سیگنال، تعداد پارامترهای آموزشی به‌صورت تصاعدی افزایش می‌یابد و در نتیجه فضای ذخیره‌سازی از بین می‌رود. علاوه بر این، شبکه‌های عصبی معمولی نمی‌تواند اطلاعات متوالی مورد نیاز برای داده‌های توالی را بگیرد. بنابراین، CNN همیشه یک راه‌ارجح برای مسائل طبقه‌بندی سیگنال‌های یک و چندبعدی است، زیرا توانایی آن در برخورد با سیگنال به‌عنوان داده، دقت بالاتری را ارائه می‌دهد.

لایه‌های معماری CNN، توابع و شرایط مورد نیاز برای مرحله آموزش، مهم‌ترین عواملی هستند که باعث عملکرد بالا می‌شوند. در پژوهش‌های پیشین، معماری‌های دوبعدی CNN به‌طور کلی برای کاربردهای پردازش تصویر، معماری‌های سه‌بعدی CNN برای کاربردهای تصویر حجمی و معماری‌های یک‌بعدی CNN برای کاربردهای پردازش سیگنال استفاده می‌شوند. لایه‌های این معماری‌ها تقریباً یکسان هستند. تنها تفاوت در اندازه آن‌ها است. درحالی‌که لایه‌های کانولوشن دوبعدی برای معماری‌های دوبعدی استفاده می‌شوند، لایه‌های کانولوشن یک‌بعدی در معماری‌های CNN یک‌بعدی استفاده می‌شوند. لایه‌های CNN مورد استفاده در این مطالعه به‌طور خلاصه در این بخش توضیح داده شده است.

سیگنال‌های EEG با ۱۰۰۰ هرتز و سیگنال‌های NIRS با ۱۰ هرتز نمونه‌برداری می‌شوند. بنابراین نوع و ترتیب فیلترهای اعمال شده بر روی این سیگنال‌ها متفاوت انتخاب می‌شوند. یک فیلتر درجه سوم Butterworth با فاز صفر برای تبدیل سیگنال‌های NIRS به چندین باند استفاده می‌شود. همچنین یک فیلتر مرتبه سوم Chebyshev نوع دو برای سیگنال‌های EEG استفاده می‌شود. براین اساس، پنج باند به دست آمده برای سیگنال‌های EEG در جدول (۱) نشان داده شده است. در پژوهش‌های پیشین، سیگنال‌های NIRS معمولاً در بازه‌های فرکانسی $[0, 0.1]$ Hz و $[0.1, 0.2]$ Hz بررسی می‌شوند. از آنجایی‌که این محدوده فرکانسی حاوی اطلاعات زیادی است، این بخش با گام‌های ۰/۰۵ مورد بررسی قرار می‌گیرد.

جدول ۱. باندهای فرکانسی استفاده‌شده در سیگنال‌های مختلف

EEG	fNIRS
Delta, ۴-۱ Hz	۰ - ۰/۰۵ Hz
Theta, ۴ - ۸ Hz	۰/۰۵ - ۰/۱۰ Hz
Alpha, ۸ - ۱۳ Hz	۰/۱۰ - ۰/۱۵ Hz
Beta, ۱۳ - ۳۰ Hz	۰/۱۵ - ۰/۲۰ Hz
Gamma, ۳۰ - ۱۰۰ Hz	

۴-۲. معماری CNN یک‌بعدی

معماری‌های CNN به‌طور خودکار استخراج ویژگی و طبقه‌بندی را انجام می‌دهند. برای این منظور ابتدا استخراج ویژگی را انجام می‌دهند، سپس ویژگی‌های استخراج‌شده را طبقه‌بندی می‌کنند. با توجه به نتیجه طبقه‌بندی، به‌طور خودکار ویژگی‌ها را بروز می‌کند و وزن ایده‌آل را برای یک مسئله مرتبط تعیین می‌کند و در مقایسه با روش‌های استخراج ویژگی دستی بسیار خوب عمل می‌کند [۳۶]. روش‌های مبتنی بر CNN برای مشکلات طبقه‌بندی و تقریباً همه وظایف مانند تقسیم‌بندی، تشخیص، ردیابی و رگرسیون استفاده می‌شوند. به لطف عملکرد و پایداری بالای معماری‌های CNN، امروزه تقریباً در تمام کاربردهای هوش مصنوعی استفاده می‌شود. با توجه به محبوبیت معماری‌های

به‌دست‌آمده برای هر باند فرکانسی، ۱۳ بردار ویژگی عمیق با ابعاد $1 \times N$ وجود دارد. ویژگی‌های موجود در هر بردار در کنار یکدیگر قرار می‌گیرند تا ترکیب شده و بردار ویژگی نهایی با ابعاد $1 \times 13N$ تشکیل شود. پس از استخراج ویژگی‌های عمیق و ترکیب آن‌ها، یک بردار با ابعاد بالا به دست می‌آید. برخی ویژگی‌ها در این بردار همبستگی بالایی با یکدیگر دارند و حاوی اطلاعات مفیدی برای تمایز بین کلاس‌های مختلف نیستند. از این رو باید ویژگی‌های غیرمؤثر را از بردار ویژگی حذف کرد تا با کاهش محاسباتی، سرعت و دقت طبقه‌بندی افزایش یابد. اگر کاهش تعداد ویژگی قبل از ترکیب ویژگی‌ها باشد، همبستگی احتمالی بین ویژگی‌های استخراج‌شده از زیرباندهای مختلف در نظر گرفته نمی‌شود و احتمال حضور ویژگی‌ها با همبستگی بالا در بردار ویژگی نهایی وجود دارد. بنابراین بهتر است ابتدا همه ویژگی‌های خام استخراج‌شده با یکدیگر ترکیب شوند و سپس عملیات کاهش ویژگی انجام شود تا همبستگی بین تمام ویژگی‌ها در کاهش ویژگی لحاظ شود. روش‌های انتخاب ویژگی، ساختار ویژگی‌ها را تغییر نداده و صرفاً ویژگی‌های زائد و فاقد اطلاعات را حذف می‌کنند و قادر به اصلاح ساختار ویژگی‌ها و خطی‌سازی آن‌ها نیست که نمی‌تواند پیچیدگی طبقه‌بند طراحی شده را کاهش دهد. در مقابل، روش‌های کاهش ویژگی که به روش‌های کاهش بعد هم معروف هستند، با طراحی ماتریس تبدیل، فضای ویژگی‌ها را تغییر می‌دهند و می‌توانند ویژگی‌هایی با تعداد کمتر و جداپذیری خطی تولید کنند که در نتیجه طبقه‌بند طراحی شده، ساده‌تر و دارای دقت بالاتری است. تجزیه و تحلیل مولفه‌های اصلی (PCA) ابزاری است که برای کاهش ابعاد داده‌ها بدون از دست دادن اطلاعات زیاد کاهش می‌دهد. PCA با یافتن چند ترکیب خطی متعامد (مولفه‌های اصلی) از متغیرهای اصلی با بیشترین واریانس، بعد را کاهش می‌دهد. اولین مؤلفه اصلی بیشتر واریانس داده را ثبت می‌کند. مؤلفه اصلی دوم متعامد به مؤلفه اصلی اول است و واریانس باقیمانده را که از مؤلفه اصلی اول باقی‌مانده است و غیره می‌گیرد. به اندازه تعداد متغیرهای اصلی، اجزای اصلی وجود دارد. این مولفه‌های اصلی ناهمبسته و مرتب هستند به طوری که چندین مؤلفه اصلی اول بیشتر واریانس داده اصلی را توضیح می‌دهند. PCA یک روش خطی است و فقط می‌توان آن را برای مجموعه داده‌هایی اعمال کرد که به صورت خطی قابل تفکیک هستند. در این صورت، یک کار عالی برای مجموعه داده که به صورت خطی قابل تفکیک هستند، انجام می‌دهد. اما، اگر از آن برای مجموعه داده غیرخطی استفاده کنیم، ممکن است نتیجه‌ای به دست آوریم که ممکن

لایه کانولوشن اساسی‌ترین لایه معماری CNN است. تمام ویژگی‌های مربوط به مسئله در هسته‌های لایه کانولوشن ذخیره می‌شوند. فرآیند یادگیری به صورت جداگانه در این هسته‌ها انجام می‌شود. در طول عملیات معماری CNN، این هسته‌ها روی تصویر می‌لغزند. یک واحد خطی اصلاح شده ($ReLU^1$) ساختار خطی شبکه را از بین می‌برد و آن را تنک^۲ می‌کند. معمولاً ReLU بعد از هر لایه کانولوشن استفاده می‌شود. لایه ادغام^۳ یک لایه قابل توجه است که به طور مؤثر تعداد پارامترهای شبکه را کاهش می‌دهد. این لایه با حفظ پارامترهای مهم، نمونه‌برداری کاهش را انجام می‌دهد. در این مشابه لایه کانولوشن، یک هسته روی تصویر می‌لغزد. لایه تمام متصل^۴ لایه‌ای است که مسئول طبقه‌بندی در معماری CNN است. این لایه مانند یک پرسپترون چندلایه (MLP^۵) عمل می‌کند و ماتریس‌های ویژگی تولید شده توسط CNN را طبقه‌بندی می‌کند. بیش‌برازش^۶ از حد یکی از رایج‌ترین مشکلاتی است که معماری‌های عمیق CNN با آن مواجه هستند. لایه dropout به عنوان ساده‌ترین و مؤثرترین راه‌حل برای این مشکل استفاده می‌شود. این لایه برخی از نورون‌های شبکه را در طول آموزش نادیده می‌گیرد. بنابراین، توانایی یادگیری هر نورون را به تنهایی افزایش می‌دهد. یک معماری CNN متشکل از لایه‌های ذکر شده را می‌توان با یک فرمول کلی به صورت زیر بیان کرد.

$$f(O) = \text{pool}_{n \times n}(\sigma(w \otimes I + b)) \quad (1)$$

در رابطه (۱)، متغیر I بیانگر ماتریس یا بردار ورودی، عبارت pool بیانگر لایه ادغام، n بیان‌کننده تعداد هسته‌ها، σ نشان‌دهنده لایه $ReLU$ ، w برابر وزن‌های لایه کانولوشن، b بیانگر بایاس و \otimes بیانگر عملیات کانولوشن است. برای پیاده‌سازی شبکه یک‌بعدی برای پردازش سیگنال، عملیات ذکر شده در رابطه (۱) در حالت یک-بعدی پیاده‌سازی می‌شود که در این حالت، اندازه کرنل‌ها به صورت $1 \times N$ است. ویژگی‌های به‌دست‌آمده از آخرین لایه ادغام به عنوان ویژگی‌های عمیق شناخته می‌شوند که برای محاسبات بعدی مورد استفاده قرار می‌گیرند.

۴-۳. ترکیب و کاهش ویژگی‌ها

با توجه به جدول (۱)، سیگنال‌های EEG و fNIRS به ترتیب به پنج و چهار باند فرکانسی تقسیم می‌شوند و در کل ۱۳ باند فرکانسی وجود دارد. با در نظر گرفتن یک بردار ویژگی‌های عمیق

¹ Rectified Linear Unit (ReLU)

² Sparse

³ Pooling

⁴ Fully-connected layer

⁵ Multi-Layer Perceptron (MLP)

⁶ Overfitting

⁷ Principal Component Analysis (PCA)

۵. نتایج و بحث

۵-۱. روش و معیارهای ارزیابی

این بخش شامل ارزیابی عملکرد چارچوب پیشنهادی و مقایسه آن با عملکرد روش‌های پیشرفته فعلی است. برای این منظور، ابتدا عملکرد هر کدام از سیگنال‌های EEG، HbR و HbO به‌تنهایی ارزیابی می‌شوند. سپس ترکیب‌های EEG + HbO و EEG + HbR ارزیابی می‌شوند. در نهایت ارزیابی ترکیب EEG + NIRS انجام می‌شود. برای محاسبه دقت هر کدام از ترکیبات، از روش ارزیابی متقابل پنج‌گانه^۲ استفاده می‌شود. برای این منظور در هر تکرار، ۸۰ درصد از نمونه‌های موجود در داده‌ها به‌صورت تصادفی برای آموزش، ۱۰ درصد به‌صورت تصادفی برای اعتبارسنجی و ۱۰ درصد باقیمانده نیز برای تست در نظر گرفته می‌شوند. شایان ذکر است مجموعه داده برای هر تکرار به‌هم‌ریخته شده است. پارامترهای استفاده شده در فرآیند یادگیری در جدول (۲) ارائه شده است. همچنین ساختار شبکه عصبی CNN یک‌بعدی در جدول (۳) ارائه شده است.

جدول ۲. پارامترهای استفاده شده در شبیه‌سازی

پارامتر	مقدار
بهنه‌ساز	گردایان نزولی تصادفی با تکانه ^۳
تابع تلفات	انتروپی متقابل ^۴
تعداد Epoch	۶۰
اندازه دسته ^۵	۳۲
نرخ یادگیری	۰.۱۰ ^۵
تکانه	۰.۸۵

جدول ۳. ساختار شبکه CNN استفاده شده

نوع لایه	ابعاد فیلتر / گام ^۶
کانولوشن ۱	۱ × ۱۰۰ / ۱ × ۸۰
واحد خطی اصلاح شده ۱	---
ادغام	۱ × ۲ / ۲
کانولوشن ۲	۱ × ۱۲۸ / ۱ × ۳۸
واحد خطی اصلاح شده ۲	---
ادغام	۱ × ۲ / ۲
کانولوشن ۳	۱ × ۲۵۶ / ۱ × ۱۸ × ۱۲۸
واحد خطی اصلاح شده ۳	---
کانولوشن ۴	۱ × ۱۲۸ / ۱ × ۹ × ۶۴
واحد خطی اصلاح شده ۴	---
کانولوشن ۵	۱ × ۶۴ / ۱ × ۴ × ۳۲
واحد خطی اصلاح شده ۵	---
مسطح کننده ^۱	---

است کاهش ابعاد بهینه نباشد. PCA با هسته (KPCA)^۱ از یک تابع هسته استفاده می‌کند تا مجموعه داده را در یک فضای ویژگی با ابعاد بالاتر که به‌صورت خطی قابل تفکیک است، نمایش دهد که شبیه به ایده ماشین‌های بردار پشتیبان است. هسته‌های مختلفی مانند خطی، چندجمله‌ای و گاوسی وجود دارد. با توجه به ابعاد بالای بردار ویژگی نهایی که از ترکیب بردارهای ویژگی باندهای فرکانسی مختلف به دست می‌آید، با استفاده از روش KPCA ابعاد بردار ویژگی اعمالی به طبقه‌بند را کاهش خواهیم داد.

۴-۴. طبقه‌بندی

در این پژوهش از چندین طبقه‌بند به‌صورت جداگانه برای طبقه‌بندی ویژگی‌های کاهش‌یافته توسط KPCA استفاده شد که در ادامه شرح داده می‌شوند.

ماشین بردار پشتیبانی (SVM): این طبقه‌بند توسط Vapnik را به‌عنوان یک روش طبقه‌بندی قوی معرفی شد. به دلیل پیچیدگی محاسباتی کمتر و پردازش آسان مجموعه داده‌های کوچک، معمولاً در مطالعات مختلف BCI استفاده شده است. ابر صفحه بهینه در SVM فاصله حاشیه‌ای بین کلاس‌ها را به حداکثر می‌رساند. در این مقاله از SVM خطی استفاده شده است.

k-نزدیک‌ترین همسایه (kNN): یک روش آماری معروف در الگوریتم‌های طبقه‌بندی مبتنی بر یادگیری ماشین است. kNN یک طبقه‌بندی‌کننده ساده در کاربردهای BCI است که هر داده تست را با در نظر گرفتن معیارهای فاصله k بین داده تست و نزدیک‌ترین کلاس‌ها در فضای ویژگی طبقه‌بندی می‌کند. در نتیجه، پارامتر k یک کلید اساسی در عملکرد kNN است. به‌صورت خلاصه، شبه کد روش پیشنهادی در الگوریتم ۱ بیان شده است.

الگوریتم ۱. شبه کد روش پیشنهادی برای طبقه‌بندی سیگنال‌های ترکیبی EEG و fNIRS

- ۱- ورودی: سیگنال‌های EEG و fNIRS
- ۲- استخراج سیگنال‌های HbO و HbR از سیگنال fNIRS
- ۳- تجزیه سیگنال‌های EEG به پنج زیرباند بر اساس جدول ۱
- ۴- تجزیه سیگنال‌های HbO و HbR به چهار زیرباند بر اساس جدول ۱
- ۵- استخراج ویژگی‌های عمیق از زیرباندهای استخراج‌شده در بندهای ۳ و ۴ با CNN توصیف شده در جدول ۳
- ۶- ترکیب ویژگی‌های عمیق استخراج‌شده در بند ۵
- ۷- کاهش ویژگی‌های ترکیب‌شده با KPCA
- ۸- طبقه‌بندی ویژگی‌های کاهش‌یافته
- ۹- خروجی: کلاس سیگنال

^۲ Five-fold cross-validation

^۳ Stochastic Gradient Descent with Momentum (SGDM)

^۴ Cross-entropy

^۵ Batch

^۶ Stride

^۱ Kernel PCA (KPCA)

فرکانسی مختلف و همچنین کاهش ویژگی‌های غیرمؤثر عملکرد بالاتری در مقایسه با مطالعات مربوط به سایر راهکارهای مبتنی بر CNN دارد. همچنین طبقه‌بند SVM دقت بالاتری نسبت به طبقه‌بند kNN دارد.

جدول ۴. عملکرد سیگنال EEG

روش	Spec. (%)	Sens. (%)	Acc. (%)
Shin و همکاران [۳۸]	---	---	۶۵/۶
انرژی زیرباندها	---	---	۶۸/۴
Ergun و همکاران [۹]	---	---	۷۱/۵
Khan و همکاران [۳۹]	---	---	۸۶/۰
Yang و همکاران [۴۰]	---	---	۸۶/۷
Zeng و همکاران [۴۱]	---	---	۹۲/۷
Zhang و همکاران [۴۲]	---	---	۹۸/۳
SVM	۹۸/۷	۹۹/۱	۹۸/۸
kNN	۹۸/۲	۹۸/۸	۹۸/۵

۵-۳. عملکرد سیگنال NIRS و اجزای آن

در این بخش ارزیابی عملکرد روش پیشنهادی با در نظر گرفتن سیگنال‌های HbO، HbR و NIRS به‌تنهایی انجام می‌شود. برای این منظور تغییراتی در معماری CNN یک‌بعدی ایجاد می‌شود. برای آزمایش‌های فقط HbR و فقط HbO، چهار سیگنال به ورودی CNN اعمال می‌شود. برای آزمایش NIRS، هشت سیگنال به ورودی CNN اعمال می‌شود. جدول (۵) عملکرد روش پیشنهادی را با استفاده از NIRS و اجزای آن نشان می‌دهد.

سیگنال‌های HbO و HbR که اجزای NIRS هستند، عملکرد طبقه‌بندی رضایت‌بخشی را زمانی که به‌تنهایی استفاده می‌شوند، ایجاد می‌کنند. با این حال، انحراف معیار بسیار بالا در نتایج، بی‌ثباتی در عملکرد ایجاد می‌کند. به همین دلیل، این دو سیگنال برای آموزش چارچوب پیشنهادی ترکیب می‌شوند. استفاده از دو مؤلفه باهم، دقت طبقه‌بندی را در حدود ۲٪ بهبود داده و انحراف معیار را به میزان قابل توجهی کاهش می‌دهد. همان‌طور که مشاهده می‌شود عملکرد روش پیشنهادی بالاتر از روش‌های اخیر است. تفاوت زیاد بین آن‌ها موفقیت رویکردهای استفاده از باندهای فرکانسی متفاوت و ترکیب و کاهش ویژگی را اثبات می‌کند.

۵-۴. عملکرد سیگنال‌های ترکیبی EEG و اجزای NIRS

ترکیب سیگنال‌های EEG و NIRS برای رفع محدودیت‌های یکدیگر استفاده می‌شود. به همین دلیل، بسیاری از مطالعات، تجزیه و تحلیل را با ترکیب این دو تکنیک انجام می‌دهند. در این بخش، سیگنال EEG و اجزای سیگنال NIRS (HbR و HbO) به طور جداگانه ترکیب و تجزیه و تحلیل می‌شوند. جدول (۶) عملکرد EEG + HbR و EEG + HbR پیشنهادی را در مقایسه با سایر روش‌های پیشرفته نشان می‌دهد. با توجه به نتایج به دست آمده از

معیارهای ارزیابی در مطالعات EEG و NIRS در پژوهش‌های پیشین در این مطالعه نیز برای ارزیابی منصفانه عملکرد روش پیشنهادی استفاده شده است. برای این منظور از حساسیت^۲ (Sens.)، اختصاص^۳ (Spec.) و دقت^۴ (Acc.) برای ارزیابی عملکرد چارچوب پیشنهادی استفاده می‌شود. مطالعات در ادبیات معمولاً شامل یک یا چند مورد از این پارامترها است. به همین دلیل، برخی از پارامترها در جداول مقایسه خالی مانده‌اند.

$$Sens. = \frac{TN}{TN + FP} \quad (2)$$

$$Spec. = \frac{TP}{TP + FN} \quad (3)$$

$$Acc. = \frac{TN + TP}{TN + TP + FN + FP} \quad (4)$$

که در آن TN نشان‌دهنده منفی واقعی، FP نشان‌دهنده مثبت کاذب، TP نشان‌دهنده مثبت واقعی و FN نشان‌دهنده منفی کاذب است. بنابراین، TP اشاره به حرکت صحیح دست راست، FP اشاره به حرکت نادرست دست راست، TN به حرکت صحیح دست چپ و FN اشاره به حرکت نادرست دست چپ دارد.

شبیه‌سازی روش پیشنهادی با نرم‌افزار MATLAB R2022a و سیستم با مشخصات سخت‌افزاری مقابل انجام شده است: CPU: HDD: 512 GB, RAM: 32 GB, Core i7, 2.5 GHz, 12 Core برای مقایسه با روش‌های سنتی، طبقه‌بندی با استفاده از انرژی زیرباندها نیز صورت گرفته است. برای این منظور ابتدا، سیگنال‌های مختلف بر اساس جدول (۱) به زیرباندهای مختلف تجزیه شده و انرژی هر زیرباند به‌عنوان ویژگی محاسبه شد. در ادامه، ویژگی‌های استخراج‌شده با استفاده از طبقه‌بند SVM کلاس‌بندی شدند.

۵-۲. عملکرد سیگنال EEG

در این بخش، عملکرد روش پیشنهادی تنها با استفاده از سیگنال‌های EEG مورد بررسی قرار می‌گیرد. برای این منظور، پنج معماری‌های CNN یک‌بعدی داریم، چون مطابق جدول (۱) سیگنال EEG به پنج زیرباند تقسیم می‌شود.

نتایج آزمایش روش پیشنهادی تنها با استفاده از EEG در جدول (۴) نشان داده شده است. آزمایش‌ها بر اساس طبقه‌بندی وظایف باز و بسته کردن دست راست و چپ انجام می‌شود. نتایج سایر روش‌ها در جدول (۴) فقط به طبقه‌بندی سیگنال‌های EEG تعلق دارد. بر این اساس، مشاهده می‌شود که روش‌ها، از جمله رویکردهای مبتنی بر یادگیری عمیق، کارایی بالاتری را ایجاد می‌کنند. علاوه بر این، به دلیل استفاده از ویژگی‌های باندهای

¹ Flatten

² Sensitivity

³ Specificity


⁴ Accuracy

مبتنی بر CNN هستند. به نظر می‌رسد روش‌های مبتنی بر CNN نسبت به سایر روش‌ها موفق‌تر هستند. روش‌های مبتنی بر CNN به طور متوسط تقریباً ۲۰٪ عملکرد بالاتری نسبت به روش‌های دیگر دارند. در میان سایر روش‌های مبتنی بر CNN، چارچوب پیشنهادی بهتر از روش‌های دیگر عمل می‌کند.

شکل (۳) عملکرد روش پیشنهادی برای ترکیب‌های مختلف سیگنال‌های EEG و NIRS را با هم مقایسه می‌کند. همان‌طور که مشاهده می‌شود حضور سیگنال در ترکیب، دقت طبقه‌بندی را به میزان چشمگیری بهبود می‌دهد. باین‌حال، حضور هم‌زمان دو سیگنال، عملکرد بالاتری نسبت به استفاده منفرد از هر کدام از سیگنال‌ها دارد.

جدول ۷. عملکرد سیگنال‌های ترکیبی EEG و NIRS

روش	Acc. (%)	Spec. (%)	Sens. (%)
Shin و همکاران [۳۸]	۷۴/۲	---	---
Ergun و همکاران [۹]	۷۸/۲	---	---
Chiarelli و همکاران [۳۳]	۸۳/۳	---	---
Ho و همکاران [۴۳]	۸۴/۳	---	---
Ghonchi و همکاران [۱۰]	۹۹/۶	---	---
SVM	۹۹/۹	۱۰۰	۹۹/۹
روش پیشنهادی	۹۹/۸	۹۹/۹	۹۹/۹



شکل ۳. عملکرد روش پیشنهادی برای ترکیب‌های مختلف سیگنال‌های EEG و NIRS

۶. نتیجه‌گیری

در این مقاله روش جدیدی برای طبقه‌بندی سیگنال‌های BCI ترکیبی از EEG و fNIRS ارائه شد. در این روش، ابتدا سیگنال‌های EEG، HbO و HbR با استفاده از فیلترهای میان‌گذر به باندهای فرکانسی متعددی تجزیه شدند که پنج زیرباند برای سیگنال EEG و چهار زیرباند برای هر کدام از اجزای سیگنال NIRS در نظر گرفته‌شده. در ادامه برای استخراج ویژگی‌های

جدول (۶)، چارچوب پیشنهادی از موفقیت بالاتری نسبت به سایر روش‌ها برخوردار است. با توجه به رویکرد چارچوب پیشنهادی، ترکیب EEG + HbO و EEG + HbR با در نظر گرفتن باندهای فرکانسی مختلف، ترکیب و کاهش ویژگی‌ها، به‌دقت بالاتری نسبت به روش‌های موجود دست یافتند. همچنین ترکیب EEG با HbO به نتایج بهتری نسبت به ترکیب EEG با HbR می‌رسد.

جدول ۵. عملکرد سیگنال‌های NIRS

روش	Acc. (%)	Spec. (%)	Sens. (%)
انرژی زیرباندها (HbO)	۵۳/۸	---	---
انرژی زیرباندها (HbR)	۵۳/۹	---	---
انرژی زیرباندها (NIRS)	۵۴/۲	---	---
Ergun و همکاران [۹] (HbO)	۵۵/۰	---	---
Ergun و همکاران [۹] (HbR)	۵۵/۷	---	---
Ergun و همکاران [۹] (NIRS)	۵۵/۰	---	---
Shin و همکاران [۳۸] (NIRS)	۶۶/۵	---	---
Khan و همکاران [۳۹] (NIRS)	۷۵/۶	---	---
روش پیشنهادی	۸۸/۵	۸۹/۷	۸۷/۴
	۸۸/۲	۸۹/۴	۸۷/۰
SVM	۹۱/۴	۹۲/۲	۹۰/۶
	۹۱/۱	۹۱/۸	۹۰/۳
M-kNN	۹۳/۲	۹۳/۶	۹۲/۹
	۹۲/۸	۹۳/۱	۹۲/۵

جدول ۶. عملکرد سیگنال‌های ترکیبی EEG و اجزای NIRS

روش	Acc. (%)	Spec. (%)	Sens. (%)
انرژی زیرباندها (EEG + HbO)	۷۵،۰	---	---
انرژی زیرباندها (EEG + HbR)	۷۵،۵	---	---
Ergun و همکاران [۹] (EEG + HbO)	۷۸،۲	---	---
Ergun و همکاران [۹] (EEG + HbR)	۷۶،۲	---	---
روش پیشنهادی	۹۸،۹	۹۹،۰	۹۸،۸
	۹۸،۶	۹۸،۷	۹۸،۵
SVM	۹۸،۷	۹۸،۷	۹۸،۶
	۹۸،۳	۹۸،۴	۹۸،۳

۵-۵. عملکرد سیگنال ترکیبی EEG و اجزای NIRS

در نهایت، عملکرد روش پیشنهادی با استفاده از سیگنال ترکیبی EEG + NIRS آزمایش می‌شود. جدول (۷) نتایج آزمایش‌های EEG + NIRS را با استفاده از داده‌های آزمایش نشان می‌دهد. مقایسه جدول (۷) از دو منظر متفاوت مفید است. درحالی‌که سه روش اول روش‌های مبتنی بر CNN نیستند، روش‌های دیگر

- [8] Sawangjai, P.; Hompoonsup, S.; Leelaarporn, P.; Kongwudhikunakorn, S.; Wilaiprasitporn, T. "Consumer Grade EEG Measuring Sensors as Research Tools: A Review"; *IEEE Sensor. J.* 2019, 20, 3996-4024. <http://doi.org/10.1109/JSEN.2019.2962874>.
- [9] Ergün, E.; Aydemir, Ö. "A Hybrid BCI Using Singular Value Decomposition Values of the Fast Walsh Hadamard Transform Coefficients"; *IEEE Trans. Cogn. Dev. Syst.* 2020. <http://doi.org/10.1109/TCDS.2020.3028785>.
- [10] Ghonchi, H.; Fateh, M.; Abolghasemi, V.; Ferdowsi, S.; Rezvani, M. "Deep Recurrent-Convolutional Neural Network for Classification of Simultaneous EEG-fNIRS Signals"; *IET Signal Proc.* 2020, 14, 142-153. <http://doi.org/10.1049/iet-spr.2019.0297>.
- [11] Chae, Y.; Jeong, J.; Jo, S. "Toward Brain-Actuated Humanoid Robots: Asynchronous Direct Control Using an EEG-Based BCI"; *IEEE Trans. on Robot.* 2012, 28, 1131-1144. <http://doi.org/10.1109/TRO.2012.2201310>.
- [12] Li, Y.; Li, X.; Ratcliffe, M.; Liu, L.; Qi, Y.; Liu, Q. "A Real-Time EEG-Based BCI System for Attention Recognition in Ubiquitous Environment"; *Int. Workshop Ubiquitous Affective Awareness and Intelligent Interaction 2011*, 33-40. <http://doi.org/10.1145/2030092.2030099>
- [13] Alazrai, A.; Alwanni, H.; Daoud, M. I. "EEG-Based BCI System for Decoding Finger Movements Within the Same Hand"; *Neurosci. Lett.* 2019, 698, 113-120. <http://doi.org/10.1016/j.neulet.2018.12.045>.
- [14] Mondini, V.; Mangia, A. L.; Cappello, A. "EEG-Based BCI System Using Adaptive Features Extraction and Classification Procedures"; *Computat. Intell. Neurosci.* 2016, 4562601. <http://doi.org/10.1155/2016/4562601>.
- [15] Arvaneh, M.; Guan, C.; Ang, K.; Quek, C. "Optimizing the Channel Selection and Classification Accuracy in EEG-Based BCI"; *IEEE Trans. Bio-Med. Eng.* 2011, 58, 1865-1873. <http://doi.org/10.1109/TBME.2011.2131142>.
- [16] Gaur, P.; Pachori, R. B.; Wang, H.; Prasad, G. "A Multi-Class EEG-Based BCI Classification Using Multivariate Empirical Mode Decomposition Based Filtering and Riemannian Geometry"; *Expert Syst. Appl.* 2018, 95, 201-211. <http://doi.org/10.1016/j.eswa.2017.11.007>.
- [17] Paszkiel, S. "Using Neural Networks for Classification of the Changes in the EEG Signal Based on Facial Expressions"; *Analysis and Classification of EEG Signals for Brain-Computer Interfaces: Springer* 2020, 41-69. <http://doi.org/10.1016/j.bspc.2016.11.018>.
- [18] Pan, J.; Li, Y.; Wang, J. "An EEG-Based Brain-Computer Interface for Emotion Recognition"; *Int. Conf. Neural Networks 2016*, 2063-2067. <http://doi.org/10.1109/TAFFC.2019.2901456>.
- [19] Tan, C.; Sun, F.; Zhang, W. "Deep Transfer Learning for EEG-Based Brain-Computer Interface"; *IEEE Int. Conf. Acoustics, Speech and Signal Processing 2018*, 916-920. <http://doi.org/10.48550/arXiv.1808.01752>.
- [20] Fahimi, F.; Zhang, Z.; Goh, W. B.; Lee, T. -S.; Ang, K.; Guan, C. "Inter-Subject Transfer Learning with an End-to-End Deep Convolutional Neural Network for EEG-Based BCI"; *J. Neural Eng.* 2019, 16, 026007. <http://doi.org/10.1088/1741-2552/aaf3f6>.
- [21] Mousavi, H.; Shahrokh-Abadi, M. H.; Tavakkoli, H. "Classification of Brain Signals in BCI System Using Wavelet Transform" *J. New Appr. Basic Sci., Tech. Eng. Res.* 2020, 2, 6, 20-29. (In Persian)
- [22] Borgheai, S. B.; McLinden, J.; Zisk, A. H.; Hosni, S. I.; Deligani, R.J.; Abtahi, M.; Mankodiya, K.; Shahriari, Y. "Enhancing Communication for People in Late-Stage ALS Using an fNIRS-Based BCI System"; *IEEE Trans. Neural Syst. Rehabil. Eng.* 2020, 28, 1198-1207. <http://doi.org/10.1109/TNSRE.2020.2980772>.
- عمیق از زیرباندهای به‌دست‌آمده از شبکه‌های عصبی کانولوشنی یک‌بعدی استفاده شد. ویژگی‌های عمیق به دست آمده از هر زیرباند با هم ترکیب شده و با توجه به ماهیت غیرخطی آن‌ها، از KPCA برای کاهش ابعاد بردار ویژگی نهایی استفاده شد. در نهایت، عملکرد طبقه‌بندهای SVM و kNN برای تعیین عمل انجام‌شده در BCI مورد ارزیابی قرار گرفت. نتایج به‌دست‌آمده نشان دادند که ترکیب سیگنال‌های EEG، HbO و HbR نتایج بهتری نسبت به استفاده منفرد از هر کدام از سیگنال‌های ذکر شده و سایر ترکیبات آن‌ها دارد که بادقت ۹۹٫۸۸٪ بیشترین دقت طبقه‌بندی را دارد. همچنین سیگنال EEG بالاترین دقت در استفاده منفرد از سیگنال‌ها را دارد و اضافه‌شدن اجزای مختلف سیگنال NIRS به آن، دقت طبقه‌بندی را بهبود می‌دهد. روش پیشنهادی در این پژوهش به‌دقت بالاتری نسبت به سایر روش‌های ارائه در پژوهش‌های قبلی رسید، ولی پیچیدگی محاسباتی آن نسبت به روش‌های مقایسه شده بیشتر است. به همین منظور در پژوهش‌های آتی ابتدا پیچیدگی محاسباتی روش ارائه شده بادقت ارزیابی شده و سپس کاهش پیچیدگی محاسباتی با ساده‌سازی ساختار شبکه عصبی عمیق را در نظر گرفت. همچنین یافتن باندهای فرکانسی جدید برای سیگنال‌های EEG و NIRS را می‌توان بررسی کرد.

۷. مراجع‌ها

- [1] Khare, S. K.; Bajaj, V. "A Facile and Flexible Motor Imagery Classification Using Electroencephalogram Signals"; *Comput. Meth. Prog. Bio.* 2020, 197, 105722. <http://doi.org/10.1016/j.cmpb.2020.105722>.
- [2] Ang, K.K.; Chin, Z.Y.; Zhang, H.; Guan, C. "Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface"; *IEEE Int. Conf. Neu. Net.* 2008, 2390-2397. <http://doi.org/10.1109/IJCNN.2008.4634130>.
- [3] Zhang, R.; Li, Y.; Yan, Y.; Zhang, H.; Wu, S.; Yu, T.; Gu, Z. "Control of a Wheelchair in an Indoor Environment Based on a Brain-Computer Interface and Automated Navigation"; *IEEE Trans. Neu. Syst. Rehabil. Eng.* 2015, 24, 128-139. <http://doi.org/10.1109/TNSRE.2015.2439298>.
- [4] Wang, H.; Dong, X.; Chen, Z.; Shi, B. E. "Hybrid Gaze/EEG Brain Computer Interface for Robot Arm Control on a Pick and Place Task"; *Int. Conf. IEEE Eng. Med. Bio. Soc.* 2015, 1476-1479. <http://doi.org/10.1109/EMBC.2015.7318649>.
- [5] Paszkiel, S. "Using BCI Technology for Controlling a Mobile Vehicle"; *Analysis and Classification of EEG Signals for Brain-Computer Interfaces: Springer* 2020, 71-77. http://doi.org/10.1007/978-3-030-13273-6_34.
- [6] LaFleur, K.; Cassady, K.; Doud, A.; Shades, K.; Rogin, E.; He, B. "Quadcopter Control in Three-Dimensional Space Using a Noninvasive Motor Imagery-Based Brain-Computer Interface"; *J. Neural Eng.*, 2013, 046003. <http://doi.org/10.1088/1741-2560/10/4/046003>.
- [7] Schirrneister, R.T.; Springenberg, J.T.; Fiederer, L.D.J., Glasstetter, M.; Eggensperger, K.; Tangermann, M.; Hutter, F.; Burgard, W.; Ball, T. "Deep Learning with Convolutional Neural Networks for EEG Decoding and Visualization"; *Hum. Brain Mapp.* 2017, 38, 5391-5420. <http://doi.org/10.48550/arXiv.1703.05051>.

- [33] Chiarelli, A. M.; Croce, P.; Merla, A.; Zappasodi, F. "Deep Learning for Hybrid EEG-fNIRS Brain-Computer Interface: Application to Motor Imagery Classification"; *J. Neural Eng.* 2018, 15, 3, 036028. <http://doi.org/10.1088/1741-2552/aaaf82>.
- [34] Rahman, M.; Uddin, M. S.; Ahmad, M. "Modeling and Classification of Voluntary and Imagery Movements for Brain-Computer Interface from fNIR and EEG Signals Through Convolutional Neural Network"; *Health Info. Sci. Syst.* 2019, 7, 1-22. <http://doi.org/10.1007/s13755-019-00815>.
- [35] Kwak, Y., Song, W.-J.; Kim, S. E. "FGANet: fNIRS-Guided Attention Network for Hybrid EEG-fNIRS Brain-Computer Interfaces." *IEEE Trans. Neu. Sys. Reh. Eng.* 2022, 30, 329-33. <http://doi.org/10.1109/TNSRE.2022.3149899>.
- [36] Chen, J.; Wang, D.; Hu, B.; Yi, W.; Xu, M.; Chen, D.; Zhao, Q. "MCFHNet: Multi-Channel Fusion Hybrid Network for Efficient EEG-fNIRS Multi-modal Motor Imagery Decoding" in 44th Annual Intl. Conf. IEEE Eng. Med. & Bio.Soc.(EMBC) 2022, 4821-4825. <http://doi.org/10.1109/EMBC48229.2022.9871385>.
- [37] Hosni, S. M. I.; Borgheai, S. B.; McLinden, J.; Zhu, S.; Huang, X.; Ostadabbas, S.; Shahriari, Y. "A Graph-Based Nonlinear Dynamic Characterization of Motor Imagery Toward an Enhanced Hybrid BCI" *Neuroinformatics* 2022, 20, 1169-1189. <http://doi.org/10.1007/s12021-022-09595-2>.
- [38] Shin, J.; von Lüthmann, A.; Blankertz, B.; Kim, D.W.; Jeong, J.; Hwang, H. J.; Müller, K.R. "Open Access Dataset for EEG+ NIRS Single-Trial Classification"; *IEEE Trans. Neural Syst. Rehabil. Eng.* 2016, 25, 1735-1745. <http://doi.org/10.1109/TNSRE.2016.2628057>.
- [39] Khan, M. J.; Hong, K. S. "Hybrid EEG-fNIRS-Based Eight-Command Decoding for BCI: Application to Quadcopter Control"; *Fronti. Neuroinformatics* 2017, 11, 6. <http://doi.org/10.3389/fnbot.2017.00006>.
- [40] Yang, J.; Yao, S.; Wang, J. "Deep Fusion Feature Learning Network for MI-EEG Classification"; *IEEE Access* 2018, 6, 79050-79059. <http://doi.org/10.1109/ACCESS.2018.2877452>.
- [41] Zeng, H.; Yang, C.; Dai, G.; Qin, F.; Zhang, J.; Kong, W.; "Classification of Driver Mental States by Deep Learning Cognitive"; *Neurodyn* 2018, 12, 597-606. <http://doi.org/10.1007/s11571-018-9496-y>
- [42] Zhang, D.; Yao, L.; Zhang, X.; Wang, S.; Chen, W.; Boots, R.; Benatallah, B. "Cascade and Parallel Convolutional Recurrent Neural Networks on EEG-Based Intention Recognition for Brain Computer Interface"; *AAAI Conf. Art. Intell.* 2018. <http://doi.org/10.48550/arXiv.1708.06578>
- [43] Ho, T. K. K.; Gwak, J.; Park, C. M.; Khare, A.; Song, J. I. "Deep Learning-Based Approach for Mental Workload Discrimination from Multi-Channel fNIRS"; *Recent Trends in Communication, Computing, and Electronics: Springer* 2019, 431-440. http://doi.org/10.1007/978-981-13-2685-1_41.
- [23] Bauernfeind, G.; Steyrl, D.; Brunner, C.; Müller-Putz, G.R. "Single Trial Classification of fNIRS-Based Brain-Computer Interface Mental Arithmetic Data: a Comparison Between Different Classifiers"; *Int. Conf. IEEE Engineering in Medicine and Biology Society* 2014, 2004-2007. <http://doi.org/10.1109/EMBC.2014.6944008>.
- [24] Zhang, S.; Zheng, Y.; Wang, D.; Wang, L.; Ma, J.; Zhang, J.; Xu, W.; Li, D.; Zhang, D. "Application of a Common Spatial Pattern-Based Algorithm for an fNIRS-Based Motor Imagery Brain-Computer Interface"; *Neurosci. Lett.* 2017, 655, 35-40. <http://doi.org/10.1016/j.neulet.2017.06.044>
- [25] Erdoğan, S. B.; Özsarfati, E.; Dilek, B.; Kadak, S.L.; Hanoğlu, K.; Akın, A. "Classification of Motor Imagery and Execution Signals with Population-Level Feature Sets: Implications for Probe Design in fNIRS Based BCI"; *J. Neural Eng.* 2019, 16, 026029. <http://doi.org/10.1088/1741-2552/aafdc>
- [26] Noori, F. M.; Naseer, N.; Qureshi, N. K.; Nazeer, H.; Khan, R.A. "Optimal Feature Selection from fNIRS Signals Using Genetic Algorithms for BCI"; *Neurosci. Lett.* 2017, 647, 61-66. <http://doi.org/10.1016/j.neulet.2017.03.013>.
- [27] Trakoolwilaiwan, T.; Behboodi, B.; Lee, J.; Kim, K.; Choi, J.-W. "Convolutional Neural Network for High-Accuracy Functional Near-Infrared Spectroscopy in a Brain-Computer Interface: Three-Class Classification of Rest, Right-, and Left-hand Motor Execution"; *Neurophotonics* 2017, 5, 011008. <http://doi.org/10.1117/1.NPh.5.1.011008>.
- [28] Chhabra, H.; Shajil, N.; Venkatasubramanian, G.; "Investigation of Deep Convolutional Neural Network for Classification of Motor Imagery fNIRS Signals for BCI Applications"; *Biomed. Signal Proc. Cont.* 2020, 62, 102133. <http://doi.org/10.1016/j.bspc.2020.102133>.
- [29] Fazli, S.; Mehnert, J.; Steinbrink, J.; Curio, G.; Villringer, A.; Müller, K.R.; Blankertz, B. "Enhanced Performance by a Hybrid NIRS-EEG Brain Computer Interface"; *Neuroimage* 2012, 59, 519-529. <http://doi.org/10.1016/j.neuroimage.2011.07.084>.
- [30] Liu, Y.; Ayaz, H.; Shewokis, P. A. "Multi-Subject Learning for Mental Workload Classification Using Concurrent EEG, fNIRS, and Physiological Measures"; *Fronti. Hum. Neurosci.* 2017, 11, 389. <http://doi.org/10.3389/fnhum.2017.00389>.
- [31] Firooz, S.; Setarehdan, S. K. "IQ Estimation by Means of EEG-fNIRS Recordings During a Logical-Mathematical Intelligence Test"; *Computers in biology and medicine*, 2019, 110, 218-226. <http://doi.org/10.1016/j.compbio.2019.05.017>.
- [32] Kim, H. J.; Wang, I. N.; Kim, Y. T.; Kim, H.; Kim, D. J. "Comparative analysis of NIRS-EEG Motor Imagery Data Using Features from Spatial, Spectral and Temporal Domain"; *IEEE Int. Conf. Brain-Computer Interface (BCI)* 2020, 1-4. <http://doi.org/10.1109/BCI48061.2020.9061636>.