

طبقه‌بندی سیگنال‌های مغزی EEG مبتنی بر تصور حرکتی با استفاده از روش‌های یادگیری عمیق

چکیده

دریافت: ۱۴۰۱/۰۸/۰۷ ویرایش: ۱۴۰۱/۰۸/۱۴ پذیرش: ۱۴۰۱/۰۹/۲۳ آنلاین: ۱۴۰۱/۱۰/۰۱

فائزه مقدس، زهرا امینی*، راحله کافیه

گروه مهندسی پزشکی، دانشکده فناوری‌های نوین پزشکی، دانشگاه علوم پزشکی اصفهان، اصفهان، ایران.

زمینه و هدف: سیستم‌های رابط مغز و رایانه از طریق سیگنال‌های مغزی امکان ارتباط با دنیای بیرون را بدون استفاده از واسطه‌های فیزیولوژیکی برای افراد دارای ناتوانی جسمی فراهم می‌کنند. یکی از انواع این سیستم‌ها، سیستم‌های مبتنی بر تصور حرکتی است. از مهمترین بخش‌ها در طراحی این سیستم‌ها، طبقه‌بندی سیگنال‌های مغزی مبتنی بر تصور حرکت به کلاس‌های تصور حرکت به‌منظور تبدیل به فرمان کنترلی است. در این مقاله یک روش نوین طبقه‌بندی سیگنال‌های مغزی مبتنی بر تصور حرکتی با استفاده از روش‌های یادگیری عمیق ارائه شده است.

روش بررسی: این مطالعه مقطعی در دانشکده فناوری‌های نوین پزشکی دانشگاه علوم پزشکی اصفهان از بهمن ۱۳۹۸ تا تیر ۱۴۰۱ انجام شد در بلوک پیش‌پردازش قطعه‌بندی سیگنال‌های مغزی، انتخاب کانال‌های مناسب و استفاده از فیلتر باتروث (Butterworth filter)، سپس تبدیل موجک جهت انتقال به حوزه زمان-فرکانس و در قسمت طبقه‌بندی از دو طبقه‌بند شبکه یادگیری عمیق کانولوشنی یک‌بعدی با دو معماری و شبکه یادگیری عمیق کانولوشن دو‌بعدی با دو معماری با ورودی سه موجک مادر Cmor، Mexicanhat و Cgaus به کار گرفته شده و در نهایت عملکرد شبکه‌ها بررسی شده‌اند.

یافته‌ها: سه کانال برای ۹ سوژه موردنظر، به‌عنوان بهترین کانال‌ها انتخاب شدند. همچنین پس از یافتن پارامترهای بهینه در ساختار داده، تبدیل موجک با موجک مادر Cgaus بالاترین درصد را در دو معماری پیشنهاد شده، دارد. صحت ۹۲/۵۳٪، بالاترین صحت مربوط به معماری دوم شبکه عصبی کانولوشن دو‌بعدی پیشنهاد داده شده است. **نتیجه‌گیری:** نتایج به‌دست آمده از شبکه‌های پیشنهاد شده، نشان‌دهنده آن است که شبکه‌های یادگیری عمیق مناسب می‌توانند به‌عنوان ابزاری مناسب و دقیق برای طبقه‌بندی دادگان مبتنی بر تصور حرکت مورد استفاده قرار گیرند.

کلمات کلیدی: سیستم‌های رابط مغز و رایانه، طبقه‌بندی، یادگیری عمیق، سیگنال الکتروانسفالوگرام.

* نویسنده مسئول: اصفهان، خیابان هزار جریب، دانشگاه علوم پزشکی اصفهان، دانشکده فناوری‌های نوین پزشکی، گروه مهندسی پزشکی.
تلفن: ۰۳۱-۳۷۹۲۳۸۶۶
E-mail: zahraamini64@yahoo.com.au

مقدمه

عملکرد کلی رابط‌های مغز و رایانه به این صورت است که ابتدا سیگنال‌های مغزی را به‌عنوان ورودی دریافت کرده، ویژگی‌های مفید را از سیگنال استخراج کرده، طبقه‌بندی کرده و در نهایت به یک فرمان کنترلی تبدیل می‌کنند.^{۱،۲} در میان انواع رابط‌های مغز و رایانه، سیستم‌های تصور حرکتی یا (Motor imagery, MI) به‌طور فزاینده‌ای در زمینه‌های مختلف مورد استفاده قرار گرفته‌اند. در این نوع از

رابط‌های مغز و رایانه یا (Brain computer interface, BCI)، با هدف کمک به افراد دارای ناتوانی‌های عضلانی که دارای پتانسیل‌های شناختی می‌باشند، سیگنال‌های مغز را تجزیه و تحلیل و بدون استفاده مستقیم از اعصاب و عضلات محیطی به دستور کنترلی تبدیل می‌کنند.

۲۰۰۸ برگزار شده، استفاده شده است. این دادگان شامل سیگنال‌های EEG با ۲۲ الکتروود ثبت سیگنال، که با استاندارد ۲۰-۱۰ بر روی سر افراد قرار گرفته‌اند، از ۹ سوژه نرمال ثبت شده است. سیگنال‌ها با فرکانس ۲۵۰ هرتز نمونه‌برداری و با فیلتر ۰/۵ تا ۱۰۰ هرتز فیلتر شده‌اند. آزمایش ثبت سیگنال، مبتنی بر نشانه است و شامل چهار وظیفه تصور حرکت (تصور حرکت دست راست، دست چپ، پاها و زبان) می‌باشد. در این دادگان ثبت سیگنال برای هر سوژه در دو جلسه صورت گرفته است که هر جلسه ثبت شامل شش اجرا بوده و در هر اجرا ۴۸ آزمایش (هر کلاس تصور حرکت ۱۲ بار آزمایش) و در مجموع ۲۸۸ آزمایش برای هر فرد ثبت شده است. در شروع هر آزمایش ($t=0$) یک علامت + بر روی صفحه رایانه ظاهر می‌شود، پس از ۲ ثانیه ($t=2s$) با هشدار صوتی کوتاهی علامت + به فلش تبدیل شده و به یکی از جهت‌های بالا، پایین، چپ و راست (هر حرکت مرتبط به یک تصور حرکت) حرکت می‌کند سپس با استراحت کوتاهی سوژه آزمایش بعدی را انجام می‌دهد.^{۱۰}

روش پیشنهادی: هدف این مقاله طبقه‌بندی سیگنال‌های مغزی مبتنی بر تصورات حرکتی با استفاده از شبکه عصبی کانولوشن دوبعدی است. روش پیشنهادی، شامل پیاده‌سازی شبکه عصبی کانولوشن دو بعدی با ورودی دادگان زمان-فرکانس به‌دست‌آمده با روش تبدیل موجک با موجک‌های مادر مختلف و مقایسه عملکرد این شبکه به‌منظور طبقه‌بندی دادگان می‌باشد. به‌طورکلی روش پیشنهادی در بلوک دیاگرام شکل (۱) آمده است.

پیش‌پردازش: در ابتدا جهت انتخاب کانال‌های مناسب و موثر، برای هر سوژه، تمام ۲۲ کانال ثبت سیگنال بررسی شده و کانال‌هایی منتخب شدند که با توجه به ساختار آناتومیکی مغز اطلاعات بیشتری مربوط به سیگنال‌های تصور حرکت را داشته باشند. کانال‌های منتخب برای هر سوژه کانال‌های C3، C4 و Cz می‌باشند که در ناحیه حسی و حرکتی مغز قرار گرفته‌اند. در شکل (۲) محل قرارگیری الکترودهای منتخب و همچنین نمونه‌ای از سیگنال‌های مغزی کانال‌های C3، C4 و Cz در سوژه اول که به‌طور میانگین برای ۱۲ بار تصور حرکت برای هر کلاس به‌دست آمده، نشان داده شده است. همچنین با توجه به این‌که تصور حرکت در بازه فرکانسی μ و β است، سیگنال‌های مغزی را با فیلتر باترورث درجه ۵ فیلتر می‌کنیم.

تبدیل حوزه زمان-فرکانس با استفاده از تبدیل موجک ما برای

سیستم‌های رابط مغز و رایانه، زمانی که سوژه قسمتی از اندام خود (مانند دست راست یا چپ) را حرکت می‌دهد یا تصور حرکت می‌کند، مشخصات فرکانسی مغز در بازه فرکانسی μ و β تغییر پیدا خواهد کرد که این پدیده‌ها همگام‌سازی مرتبط با رویداد (ERS) و عدم همزمانی مربوط به رویداد (ERD) را نشان می‌دهند که بر این مبنا می‌توان سیگنال‌های مغزی مبتنی بر تصور حرکت را طبقه‌بندی نمود.^۳ به‌طورکلی مطالعات انجام شده برای طبقه‌بندی این سیستم‌ها به دو روش کلاسیک یادگیری ماشین و روش‌های نوین مبتنی بر یادگیری عمیق (Deep learning) انجام می‌شود. روش‌های کلاسیک یادگیری ماشین دارای دو بخش نسبتاً مستقل استخراج ویژگی و طبقه‌بندی می‌باشند.^۴ از چالش‌های بزرگ در روش‌های کلاسیک یادگیری ماشین می‌توان به استخراج ویژگی‌های مناسب و عدم کارایی در تقابل با دادگان غیر خطی اشاره کرد.^۶ به‌منظور حل این مشکلات و همچنین نیاز به پردازش دادگان با خاصیت غیرخطی استفاده از روش‌های یادگیری عمیق جهت طبقه‌بندی دادگان به تدریج افزایش یافت و در سال‌های اخیر با پیشرفت روزافزون سخت‌افزارها، استفاده از این روش‌ها برای کاربردهای مختلف منجمله طبقه‌بندی دادگان تصور حرکت رشد چشمگیری داشته است.^۶ در مطالعه‌ای به بررسی روش‌های یادگیری عمیق جهت طبقه‌بندی دادگان مغزی پرداخته شده است، براساس این مطالعه پرکاربردترین روش یادگیری عمیق در طبقه‌بندی دادگان مغزی شبکه عصبی کانولوشن (Convolutional neural network) می‌باشد.^۱ همچنین براساس مطالعات دیگری در طبقه‌بندی تصور حرکت نیز از این شبکه بیش از سایر شبکه‌های یادگیری عمیق استفاده شده است.^{۷-۹} از مزایای استفاده از این روش‌ها می‌توان به استخراج ویژگی به‌صورت خودکار و عملکرد بهتر در مواجهه با دادگان غیرخطی اشاره کرد.^۶ ما در این مقاله قصد داریم با طراحی مناسب یک شبکه عصبی کانولوشن به شبکه بهینه و پایدار برای طبقه‌بندی تصور حرکتی پردازیم. در ادامه به معرفی دادگان، روش‌های پیشنهادی، یافته‌ها و در انتها به بحث و نتیجه‌گیری یافته‌ها می‌پردازیم.

روش بررسی


دادگان: در این مقاله از دادگان 2a مسابقات BCI که در سال

عصبی کانولوشن، روشی موثر و برتر نسبت به روش‌های دیگر در طبقه‌بندی دادگان تصور حرکت بوده و بسیار مورد توجه قرار گرفته است.^۶ در این مقاله عملکرد طبقه‌بندی شبکه عصبی کانولوشن دوبعدی (CNN2D) برای تصاویر به‌دست آمده از تبدیل موجک با سه موجک مادر Cmor، Mexican hat و Cgaus بررسی شده است. بدین منظور دو معماری مختلف شبکه عصبی کانولوشن دوبعدی (CNN2D) با هدف طبقه‌بندی دادگان مبتنی بر تصور حرکت پیشنهاد شده است. در معماری اول، شبکه شامل یک لایه کانولوشن متشکل از ۲۵۶ کرنل با ابعاد ۳ در ۳ و گام ۱ است.

لایه‌های بعدی شامل لایه Max pooling و برای جلوگیری از بیش‌برازش، یک لایه Dropout می‌باشد. جهت آماده‌سازی دادگان برای طبقه‌بندی نیز از لایه Flatten و سپس از دولایه تماماً اتصال استفاده شده است. در معماری دوم، شبکه از دو لایه کانولوشن تشکیل شده که در لایه اول ۳۲ کرنل با ابعاد ۳ در ۳ و گام ۱ و در لایه دوم ۱۶ کرنل با ابعاد ۳ در ۳ و گام ۱ به کار برده شده است. در میان لایه‌های کانولوشن نیز از یک لایه Max pooling و یک لایه Dropout استفاده شده و برای آماده‌سازی دادگان یک لایه Flatten و جهت طبقه‌بندی نیز، دو لایه تماماً اتصال به ترتیب با ۲۰۰ و ۵۰ نورون، به‌کار برده شده است. معماری این دو شبکه در شکل (۴) به نمایش گذاشته شده است.

معیارهای ارزیابی: یکی از مراحل مهم پس از طراحی و ساخت یک مدل، ارزیابی آن مدل است. این معیارها براساس چهار عنصر اصلی ماتریس کانفیوژن (Confusion matrix) یعنی درست مثبت یا به عبارتی پیش‌بینی‌هایی که مثبت در نظر گرفته شده‌اند و درست پیش‌بینی شده‌اند (TP) True positive، درست منفی یا به عبارتی پاسخ‌هایی که منفی در نظر گرفته شده‌اند و درست پیش‌بینی شده‌اند (TN) True negative، غلط مثبت یا به عبارتی پیش‌بینی‌هایی که مثبت در نظر گرفته شده‌اند و به اشتباه پیش‌بینی شده‌اند False positive (FP) و غلط منفی یا به عبارتی پیش‌بینی‌هایی که به‌عنوان کلاس منفی در نظر گرفته شده‌اند و به اشتباه پیش‌بینی شده‌اند False negative- (FN). در زیر هر یک از معیارهای ارزیابی شرح داده می‌شود:


الف- معیار ارزیابی صحت (Accuracy): رابطه (۱) نحوه به‌دست آوردن معیار ارزیابی صحت را نشان می‌دهد. صحت نشان‌دهنده تعداد پیش‌بینی‌های درست تقسیم بر کل پیش‌بینی‌ها است. پیش‌بینی‌های




شکل ۱: بلوک دیاگرام روش پیشنهادی طبقه‌بندی دادگان

استخراج ویژگی‌های تصور حرکت در باندهای فرکانسی μ و β یک تصویر دوبعدی از تبدیل حوزه زمان به حوزه زمان-فرکانس ایجاد کردیم. به‌طورکلی تبدیل فوریه زمان کوتاه یا Short time fourier transform (STFT) برای تبدیل حوزه زمان به حوزه زمان-فرکانس استفاده می‌شود اما با توجه به مطالعاتی که به مقایسه روش‌های تبدیل فوریه زمان کوتاه و تبدیل موجک یا (Wavelet transform (WT) برای تبدیل حوزه زمان به حوزه زمان-فرکانس در دادگان مغزی تصور حرکت پرداخته است، دیده شده که در تفسیر سیگنال‌های مغزی تصور حرکت به علت ناپایداری شدید و تغییر در وضوح زمان و فرکانس به‌علت ثابت بودن پنجره زمانی در روش تبدیل فوریه زمان کوتاه، روش تبدیل موجک نتایج برتری داشته است.^{۱۱} بنابراین در این مقاله نیز از روش تبدیل موجک با سه موجک مادر Cmor، Mexican hat و Cgaus برای تبدیل حوزه زمان به حوزه زمان-فرکانس استفاده شده است تا از میان این سه موجک مادر توانمندترین آنها جهت پردازش دادگان و استخراج ویژگی‌های مناسب زمانی-فرکانسی انتخاب گردد. شکل (۳) تصویر زمان-فرکانس ایجاد شده از تبدیل یک نمونه از دادگان زمانی توسط سه موجک مادر فوق را نشان می‌دهد. این تصاویر در باند فرکانسی μ و β و برای سه کانال C3، C4 و Cz با ابعاد 64×64 می‌باشد.

طبقه‌بندی: با توجه به مطالعات قبلی، مشاهده می‌شود که شبکه




الف



ب

شکل ۲: الف- محل قرارگیری کانال‌های C3، C4 و Cz. ب- رسم سیگنال‌های کانال‌های منتخب برای دو کلاس ۱ و ۴



شکل ۳: نمونه تبدیل موجک یک داده زمانی در سه کانال منتخب C3، C4 و Cz با موجک‌های مادر مختلف، از سمت چپ به ترتیب Cmor، Mexicanhat و Cgaus

به‌دست‌آمده را درست تشخیص می‌دهد و نشان می‌دهد زمانیکه مدل نتیجه را مثبت پیش‌بینی می‌کند، این نتیجه تا چه اندازه درست است. با این ارزیابی به‌طورکلی می‌توان فهمید که مدل طراحی شده درست آموزش دیده یا خیر و کارایی آن به چه صورت است.

$$Precision = \frac{TP}{TP + FP}$$

رابطه ۲

پ- معیار ارزیابی حساسیت (Sensitivity): این معیار ارزیابی،

درست شامل پیش‌بینی‌های درست مثبت و پیش‌بینی‌های درست منفی است. این معیار ارزیابی به‌طورکلی میزان پیش‌بینی‌های درست مدل را به ما نشان می‌دهد.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

رابطه ۱

ب- معیار ارزیابی دقت (Precision): معیار ارزیابی دقت در رابطه (۲) به این معناست که مدل طراحی شده تا چه اندازه خروجی

می‌گیرد. مقدار F1 در واقع میانگین صحت و حساسیت است. این معیار دارای مقداری در رنج صفر تا یک می‌باشد که در بهترین حالت یک و در بدترین حالت صفر است. معیار ارزیابی F1score مطابق رابطه (۴) محاسبه می‌شود.

$$F1_Score = \frac{TP}{TP + 1/2(FP + FN)}$$

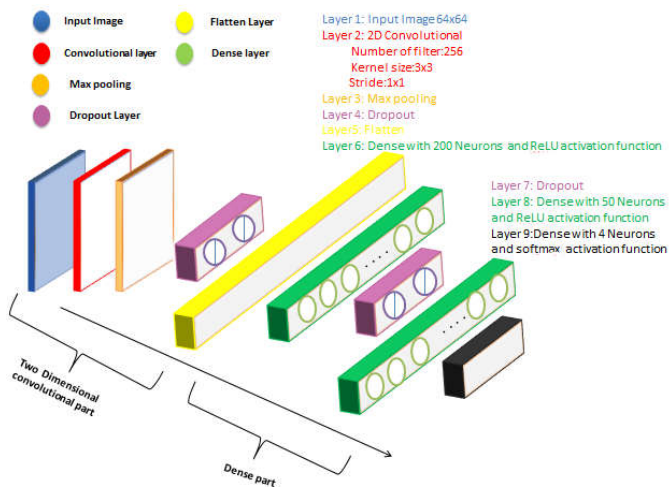
رابطه ۴

عملکرد شبکه موردنظر را در نمونه‌های مثبتی که درست پیش‌بینی شده است، بیان می‌کند. معیار ارزیابی حساسیت مطابق رابطه (۳) محاسبه می‌شود.


$$Sensitivity = \frac{TP}{TP + FN}$$

رابطه ۳

ت- معیار ارزیابی F1score: معیار F1، برای ارزیابی دقت یک آزمایش به‌کار می‌رود. این معیار صحت و حساسیت را با هم در نظر



الف



ب

شکل ۴: معماری‌های شبکه عصبی کانولوشن دوبعدی (CNN2D) پیشنهادی جهت طبقه‌بندی دادگان مغزی تصور حرکت. الف- معماری اول پیشنهادی، ب-معماری دوم پیشنهادی

یافته‌ها

ارزیابی صحت، دقت، حساسیت و FIscore عملکرد بهتری نسبت به معماری اول دارد. بهترین درصد کسب شده مربوط به معماری دوم با موجک مادر Cgaus بوده است که به‌طور میانگین روی ۹ سوژه بهترین درصد کسب شده در معیارهای ارزیابی صحت ۹۲/۵۳٪، دقت ۹۴/۱٪، حساسیت ۹۵/۰۹٪ و FIscore ۹۳/۳۶٪ گزارش شده است. همچنین در جدول‌های ۳ و ۴ نتایج به‌دست آمده از روش پیشنهادی با روش‌های برتر حوزه کلاسیک و حوزه یادگیری عمیق مقایسه شده است.

نتایج حاصل از پیاده‌سازی معماری اول و دوم شبکه عصبی کانولوشن دوبعدی با سه موجک مادر Cmor، Mexicanhat و Cgaus در ۹ سوژه و با معیارهای ارزیابی صحت، دقت، حساسیت و FIscore در جدول‌های ۱ و ۲ قابل مشاهده است. نتایج نشان‌دهنده آن است که معماری دوم پیشنهادی با دو لایه کانولوشن، در معیارهای

جدول ۱: نتایج ارزیابی معماری اول شبکه پیشنهادی با استفاده از موجک‌های مادر مختلف

افراد مورد آزمایش	صحت			دقت			حساسیت			FIscore		
	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus
فرد اول	۹۳/۲۲	۸۵/۹۷	۹۳/۹۴	۹۴/۳۲	۸۷/۱۶	۹۴/۵۷	۹۵/۵۶	۸۷/۹۸	۹۵/۴۶	۹۴/۴۳	۸۶/۰۹	۹۴/۲۰
فرد دوم	۸۷/۳۲	۷۴/۴۰	۸۹/۰۲	۸۹/۲۳	۷۵/۲۹	۹۰/۴۳	۹۰/۴۳	۷۷/۴۳	۹۲/۲۷	۷۹/۳۸	۸۹/۸۷	۸۹/۸۷
فرد سوم	۶۷/۲۷	۵۹/۱۸	۶۶/۹۱	۷۰/۰۷	۶۰/۶۸	۶۷/۹۴	۷۰/۹۷	۶۱/۳۲	۶۸/۹۵	۶۰/۰۱	۶۷/۳۱	۶۷/۳۱
فرد چهارم	۹۱/۵۲	۷۷/۴۲	۹۱/۹۷	۹۲/۸۷	۷۹/۹۶	۹۳/۲۰	۹۳/۴۲	۸۱/۰۹	۹۳/۸۹	۷۹/۱۲	۹۲/۶۹	۹۲/۶۹
فرد پنجم	۹۵/۸۰	۸۸/۹۸	۹۶/۱۳	۹۶/۶۵	۹۰/۰۱	۹۷/۶۵	۹۸/۰۲	۹۰/۹۷	۹۸/۳۸	۸۹/۴۵	۹۷/۰۴	۹۷/۰۴
فرد ششم	۸۹/۴۳	۸۸/۰۷	۸۹/۹۴	۹۰/۳۱	۸۹/۹۱	۹۱/۶۵	۹۲/۲۶	۹۰/۲۱	۹۳/۱۸	۸۸/۹۴	۹۰/۳۴	۹۰/۳۴
فرد هفتم	۹۵/۴۶	۸۰/۰۷	۹۵/۷۸	۹۶/۶۸	۸۱/۸۳	۹۷/۴۴	۹۷/۳۴	۸۲/۲۰	۹۷/۹۸	۸۰/۹۸	۹۶/۴۲	۹۶/۴۲
فرد هشتم	۸۳/۴۷	۸۰/۰۴	۸۴/۰۱	۸۴/۶۴	۸۱/۶۹	۸۵/۴۸	۸۴/۹۸	۸۲/۰۳	۸۷/۴۳	۸۰/۸۷	۸۴/۹۸	۸۴/۹۸
فرد نهم	۹۶/۸۷	۹۴/۶۷	۹۶/۸۹	۹۷/۳۱	۹۵/۳۲	۹۸/۳۶	۹۷/۹۳	۹۵/۹۸	۹۸/۹۰	۹۵/۴۳	۹۷/۲۳	۹۷/۲۳
میانگین	۸۹/۰۴	۸۱/۴۳	۸۹/۳۹	۹۰/۲۳	۸۲/۴۷	۹۰/۷۴	۹۱/۲۱	۸۳/۲۴	۹۱/۸۲	۸۱/۸۰	۹۰/۰۰	۹۰/۰۰

جدول ۲: نتایج ارزیابی معماری دوم شبکه پیشنهادی با استفاده از موجک‌های مادر مختلف

افراد مورد آزمایش	صحت			دقت			حساسیت			FIscore		
	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus	Cmor	Mexicanhat	Cgaus
فرد اول	۹۴/۲۲	۹۳/۴۲	۹۷/۵۶	۹۵/۹۷	۹۴/۹۷	۹۰/۶۷	۹۶/۸۴	۹۶/۱۳	۹۹/۰۵	۹۴/۱۸	۹۸/۰۲	۹۸/۰۲
فرد دوم	۸۹/۷۳	۸۶/۳۶	۸۸/۹۱	۹۱/۲۵	۸۸/۶۸	۹۰/۱۲	۹۲/۴۸	۸۹/۴۱	۹۱/۳۸	۸۷/۶۵	۸۹/۳۴	۸۹/۳۴
فرد سوم	۷۰/۵۶	۶۸/۵۶	۷۴/۵۲	۷۱/۳۴	۷۰/۰۵	۷۶/۸۹	۷۲/۴۰	۷۲/۵۸	۷۸/۳۶	۶۹/۴۳	۷۵/۴۸	۷۵/۴۸
فرد چهارم	۹۰/۰۷	۸۹/۸۶	۹۵/۴۳	۹۱/۹۷	۹۱/۴۷	۹۶/۸۹	۹۲/۶۹	۹۳/۳۰	۹۷/۶۹	۹۰/۶۸	۹۶/۰۵	۹۶/۰۵
فرد پنجم	۹۵/۶۹	۹۳/۸۵	۹۶/۱۴	۹۷/۷۶	۹۵/۴۳	۹۸/۰۲	۹۸/۵۰	۹۶/۸۹	۹۸/۹۹	۹۴/۷۸	۹۷/۳۴	۹۷/۳۴
فرد ششم	۹۶/۵۳	۹۶/۰۶	۹۶/۱۸	۹۷/۹۵	۹۷/۸۶	۹۸/۳۱	۹۸/۰۲	۹۸/۳۱	۹۹/۰۲	۹۷/۱۱	۹۷/۷۸	۹۷/۷۸
فرد هفتم	۹۷/۳۵	۹۶/۷۸	۹۵/۶۵	۹۸/۸۰	۹۷/۹۰	۹۷/۰۶	۹۸/۹۷	۹۸/۵۶	۹۷/۹۸	۹۷/۵۶	۹۷/۵۶	۹۷/۵۶
فرد هشتم	۹۱/۲۲	۹۰/۵۸	۸۹/۷۸	۹۱/۹۴	۹۱/۸۹	۹۱/۴۹	۹۳/۶۷	۹۳/۴۶	۹۳/۳۸	۹۱/۴۳	۹۰/۳۹	۹۰/۳۹
فرد نهم	۹۸/۷۱	۹۷/۴۷	۹۸/۸۶	۹۹/۰۱	۹۸/۹۴	۹۹/۴۸	۹۹/۵۶	۹۹/۰۱	۹۹/۹۸	۹۸/۳۲	۹۹/۳۲	۹۹/۳۲
میانگین	۹۱/۵۶	۹۰/۳۲	۹۲/۵۳	۹۲/۸۸	۹۱/۹۰	۹۴/۱	۹۳/۹۲۶	۹۳/۰۷	۹۵/۰۹	۹۱/۲۴	۹۳/۳۶	۹۳/۳۶

جدول ۳: مقایسه نتایج روش یادگیری عمیق پیشنهادی با کارهای برتر روش کلاسیک برای طبقه‌بندی دادگان 2a مسابقات BCI

منبع	استخراج ویژگی	طبقه‌بند	صحت میانگین روی ۹ سوژه
۱۳	SFBCSP	SVM	٪۹۲
۱۴	Circular translation data augmentation	SVM	٪۸۱/۸۵
۱۵	Variance	SVM	٪۷۰
	KLD		٪۷۶
	FN		٪۷۸
۱۶	Variance	TSLDA	٪۷۰/۲
		MDRM	٪۶۳/۲
۱۷	CSP	LDA	٪۸۹/۲۳
روش پیشنهادی	(Cgaus) WT	CNN2-D	٪۹۲/۵۳

جدول ۴: مقایسه نتایج به‌دست‌آمده از شبکه پیشنهادی با کارهای برتر پیشین جهت طبقه‌بندی دادگان 2a مسابقات BCI به‌روش یادگیری عمیق

منبع	پیش‌پردازش	معماری	صحت میانگین روی ۹ سوژه
۱۸	WT	CNN-2D	٪۸۷/۶
۱۹	CWT	CNN-2D Typical VGG-16	٪۶۸/۳۳
۹	WT	CNN-2D	٪۸۵/۵۹
۲۰	CSP+WT	CNN-2D	٪۷۲/۲۵
۱۲	WT	CNN-2D	٪۸۹/۳۶
روش پیشنهادی	(Cgaus) WT	CNN2-D	٪۹۲/۵۳

بحث

طبقه‌بندی در هر دو معماری را داشته و در میان معماری‌های پیشنهادی، معماری دوم با دولایه کانولوشن برترین عملکرد را نشان داده است که این امر برحسب معیارهای ارزیابی گوناگون شامل صحت، دقت، حساسیت و F1score تأیید شده است. به‌این‌ترتیب شبکه پیشنهادی با میانگین صحت ٪۹۲/۵۳، دقت ٪۹۴/۱، حساسیت ٪۹۵/۰۹ و F1score ٪۹۳/۲۶ بهترین عملکرد را داراست.

همچنین شبکه برتر پیشنهادی در مقایسه با روش‌های برتر کلاسیک که در این حوزه جهت طبقه‌بندی دادگان تصور حرکت استفاده شده، عملکرد بهتری داشته است و در میان مقالات برتر پیشین که بر روی دادگان مشابه کار کرده‌اند، در حوزه روش‌های کلاسیک یادگیری ماشینی طبق نتایج جدول ۳، طبقه‌بند SVM بالاترین عملکرد را داراست. براین اساس در مطالعه‌ای که از روش SVM

در این مقاله با هدف طراحی یک سیستم طبقه‌بندی دادگان تصور حرکت مبتنی بر روش‌های یادگیری عمیق، بخش‌های مختلف کار مورد بررسی قرار گرفت. به این منظور پس از بررسی مطالعات انجام شده در این زمینه و جمع‌آوری اطلاعات، سیستم پیشنهادی معرفی و پیاده‌سازی شد و جزئیات مربوط به این سیستم‌ها مورد بررسی قرار گرفت. مدل پیشنهاد داده شده با هدف طبقه‌بندی دادگان تصور حرکت شامل بلوک‌های انتخاب کانال، فیلترینگ، انتقال داده به حوزه زمان-فرکانس جهت کسب اطلاعات بیشتر، طبقه‌بندی و ارزیابی مدل پیشنهادی می‌باشد. در بین تبدیل موجک‌های بررسی شده، تصاویر ایجاد شده با موجک مادر Cgaus بهترین عملکرد در

از کرنل‌های یک بعدی به جای کرنل دوبعدی و تعداد لایه‌های استفاده شده در شبکه، صورت بگیرد. همچنین با توجه به تنوع موجک‌های مادر موجود، مطالعات بیشتری بر روی تبدیل موجک‌هایی با موجک‌های مادر دیگر پیشنهاد می‌شود.

سپاسگزاری: این مقاله حاصل از پایان‌نامه و طرح تحقیقاتی تحت عنوان "طبقه‌بندی سیگنال‌های مغزی EEG مبتنی بر تصور حرکت با استفاده از روش‌های یادگیری عمیق" در مقطع کارشناسی ارشد مهندسی پزشکی - بیوالکترونیک در سال ۱۳۹۸ و کد ۳۹۸۸۲۲ می‌باشد که با حمایت دانشگاه علوم پزشکی اصفهان اجرا شده است.

References

1. Yi W, Qiu S, Qi H, Zhang L, Wan B, Ming D. EEG feature comparison and classification of simple and compound limb motor imagery. *Journal of neuroengineering and rehabilitation* 2013;10(1):1-2.
2. Gao Q, Dou L, Belkacem AN, Chen C. Noninvasive electroencephalogram based control of a robotic arm for writing task using hybrid BCI system. *BioMed research international* 2017;2017.
3. Pfurtscheller G, Neuper C, Flotzinger D, Pregenzer M. EEG-based discrimination between imagination of right and left hand movement. *Electroencephalography and clinical Neurophysiology* 1997;103(6):642-51.
4. Aggarwal S, Chugh N. Signal processing techniques for motor imagery brain computer interface: A review. *Array* 2019;1:100003.
5. Malan NS, Sharma S. Feature selection using regularized neighbourhood component analysis to enhance the classification performance of motor imagery signals. *Computers in biology and medicine* 2019;107:118-26.
6. Roy Y, Banville H, Albuquerque I, Gramfort A, Falk TH, Faubert J. Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering* 2019;16(5):051001.
7. Gao G, Shang L, Xiong K, Fang J, Zhang C, Gu X. EEG classification based on sparse representation and deep learning. *NeuroQuantology* 2018;16(6).
8. Pérez-Zapata AF, Cardona-Escobar AF, Jaramillo-Garzón JA, Díaz GM. Deep convolutional neural networks and power spectral density features for motor imagery classification of EEG signals. In *Augmented Cognition: Intelligent Technologies: 12th International Conference, AC 2018, Held as Part of HCI International 2018, Las Vegas, NV, USA, 2018, Proceedings, Part I 2018* (pp. 158-169). Springer International Publishing
9. Xu B, Zhang L, Song A, Wu C, Li W, Zhang D, Xu G, Li H, Zeng H. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification. *Ieee Access* 2018;7:6084-93.
10. Brunner C, Leeb R, Müller-Putz G, Schlögl A, Pfurtscheller G, Competition BC. Graz Data Set A, provided by the Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces). Graz University of Technology 2008.
11. Gómez MJ, Castejón C, García-Prada JC. Review of recent advances in the application of the wavelet transform to diagnose cracked rotors. *Algorithms* 2016;9(1):19.
12. Kim C, Sun J, Liu D, Wang Q, Paek S. An effective feature extraction method by power spectral density of EEG signal for 2-class motor imagery-based BCI. *Medical & biological engineering & computing* 2018;56:1645-58.
13. Jiao Y, Zhou T, Yao L, Zhou G, Wang X, Zhang Y. Multi-view multi-scale optimization of feature representation for EEG classification improvement. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2020;28(12):2589-97.
14. Yang L, Song Y, Ma K, Xie L. Motor imagery EEG decoding method based on a discriminative feature learning strategy. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2021;29:368-79.
15. Song X, Yoon SC, Perera V. Adaptive common spatial pattern for single-trial EEG classification in multisubject BCI. In *2013 6th International IEEE/EMBS Conference on Neural Engineering (NER) 2013* (pp. 411-414). IEEE.
16. Barachant A, Bonnet S, Congedo M, Jutten C. Multiclass brain-computer interface classification by Riemannian geometry. *IEEE Transactions on Biomedical Engineering* 2011;59(4):920-8.
17. Gaur P, Pachori RB, Wang H, Prasad G. An automatic subject specific intrinsic mode function selection for enhancing two-class EEG-based motor imagery-brain computer interface. *IEEE Sensors Journal* 2019;19(16):6938-47.
18. Collazos-Huertas DF, Álvarez-Meza AM, Acosta-Medina CD, Castaño-Duque GA, Castellanos-Dominguez G. CNN-based framework using spatial dropping for enhanced interpretation of neural activity in motor imagery classification. *Brain Informatics* 2020;7(1):8.
19. Ling SH, Makgawinata H, Monsivais FH, Lourenco AD, Lyu J, Chai R. Classification of EEG Motor Imagery Tasks Using Convolution Neural Networks. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) 2019* (pp. 758-761). IEEE.
20. Mahamune R, Laskar SH. Classification of the four-class motor imagery signals using continuous wavelet transform filter bank-based two-dimensional images. *International Journal of Imaging Systems and Technology* 2021;31(4):2237-48.

Deep learning approach for motor imagery EEG signal classification

Faezeh Moghadas M.Sc.
Zahra Amini Ph.D.*
Rahele Kafieh Ph.D.

Department of Biomedical
Engineering, School of Advanced
Technologies in Medicine, Isfahan
University of Medical Sciences,
Isfahan, Iran.

* Corresponding author: Department of
Biomedical Engineering, School of
Advanced Technologies in Medicine,
Isfahan University of Medical Sciences,
Hezar Jerib St., Isfahan, Iran.
Tel: +98-31-37923866
E-mail: zahraamini64@yahoo.com.au

Abstract

Received: 29 Oct. 2022 Revised: 05 Nov. 2022 Accepted: 14 Dec. 2022 Available online: 22 Dec. 2022

Background: Brain-computer interface systems provide the possibility of communicating with the outside world without using physiological mediators for people with physical disabilities through brain signals. A popular type of BCIs is the motor imagery-based systems and one of the most important parts in the design of these systems is the classification of brain signals into different motor imagery classes in order to transform them into control commands. In this paper, a new method of brain signal classifying based on deep learning methods is presented.

Methods: This cross-sectional study was conducted at Isfahan University of Medical Sciences, School of Advanced Technologies in Medicine, from February 2020 to June 2022. In the pre-processing block, segmentation of brain signals, selection of suitable channels and filtering by Butterworth filter have been done; then data has transformed to the time-frequency domain by three different kinds of mother wavelets including Cmor, Mexicanhat, and Cgaus. In the classification step, two types of convolutional neural networks (one-dimensional and two-dimensional) were applied whereas each one of them was utilized in two different architectures. Finally, the performance of the networks has been investigated by each one of these three types of input data.

Results: Three channels were selected as the best ones for nine subjects. To separate 8-30 Hz, a 5th degree Butterworth filter was used. After finding the optimal parameters in the proposed networks, wavelet transform with Cgauss mother wavelet has the highest percentage in the both proposed architectures. Two-dimensional convolutional neural network has higher convergence speed, higher accuracy and more complexity of calculations. In terms of accuracy, precision, sensitivity and F1-score, two-dimensional convolutional neural network has performed better than one-dimensional convolutional neural network. The accuracy of 92.53%, which is obtained from the second architecture, as the best result, is reported.

Conclusion: The results obtained from the proposed network indicate that suitable, and well-designed deep learning networks can be utilized as an accurate tool for data classification in application of motion perception.

Keywords: brain-computer interface (BCI), classification, deep learning, electroencephalography (EEG).

