

تشخیص اختلال افسردگی عمده با استفاده از روش‌های هوش مصنوعی مبتنی بر سیگنال الکتروانسفالوگرام

چکیده

دریافت: ۱۴۰۲/۱۱/۰۴ ویرایش: ۱۴۰۲/۱۱/۱۰ پذیرش: ۱۴۰۳/۰۱/۲۳ آنلاین: ۱۴۰۳/۰۲/۰۱

محسن سادات شهابی، احمد شالباف*

گروه فیزیک و مهندسی پزشکی، دانشکده پزشکی، دانشگاه علوم پزشکی شهیدبهشتی، تهران، ایران.

زمینه و هدف: اختلال افسردگی عمده یکی از شایع‌ترین و ناتوان‌کننده‌ترین اختلالات روانی می‌باشد. با توجه به کاهش کیفیت زندگی این بیماران و ماهیت پیش‌رونده این بیماری‌ها، تشخیص به هنگام و درمان موثر این بیماری روانی ضروری می‌باشد. در این پژوهش از سیگنال‌های مغزی افراد برای تشخیص دقیق ابتلا به اختلال افسردگی عمده با استفاده از روش‌های هوش مصنوعی استفاده می‌شود.

روش بررسی: در این مطالعه تحلیلی که از شهریور ۱۴۰۲ تا اسفند ۱۴۰۲ در دانشکده پزشکی دانشگاه علوم پزشکی شهیدبهشتی انجام شده است، وجود اختلال افسردگی عمده در ۵۸ مراجعه‌کننده به کلینیک روانپزشکی با استفاده از مصاحبه حضوری با روانپزشک متخصص بررسی شد و ۳۰ نفر با اختلال افسردگی عمده تشخیص داده شدند. سیگنال مغزی الکتروانسفالوگرام از این افراد ثبت شده و پس از پیش‌پردازش و تمیز شدن سیگنال به‌عنوان ورودی به مدل‌های هوش مصنوعی داده شد. مدل‌های هوش مصنوعی EEGNet، ShallowConvNet و DeepConvNet که مبتنی بر مدل‌های یادگیری عمیق کانولوشنی توسعه یافتند، برای دسته‌بندی سیگنال‌های مغزی افراد سالم و افسرده استفاده شدند. دقت دسته‌بندی این مدل‌ها روی داده تست جداگانه گزارش شده است.

یافته‌ها: دقت تفکیک سیگنال مغزی افراد سالم و افسرده توسط مدل‌های EEGNet، ShallowConvNet و DeepConvNet به ترتیب برابر ۹۲/۳٪، ۸۳/۲٪ و ۹۲/۲٪ می‌باشد. همچنین مدل EEGNet با حساسیت ۹۸/۹٪ و ویژگی ۷۹/۱٪ بهترین عملکرد را در میان مدل‌های بررسی شده داشته است.

نتیجه‌گیری: دسته‌بندی افراد افسرده و سالم از روی سیگنال EEG با دقت بالا و به‌صورت تعمیم‌پذیر امکان‌پذیر است و مدل‌های هوش مصنوعی پیشنهاد شده می‌توانند در کلینیک‌های روانپزشکی به‌عنوان ابزارهای کمک تشخیصی مورد استفاده قرار گیرند.

کلمات کلیدی: هوش مصنوعی، یادگیری عمیق، الکتروانسفالوگرافی، اختلال افسردگی عمده.

* نویسنده مسئول: تهران، ولنجک، بلوار دانشجو، کوچه کودکان، دانشگاه علوم پزشکی شهیدبهشتی، دانشکده پزشکی، گروه فیزیک و مهندسی پزشکی.

تلفن: ۰۲۱-۲۲۴۳۹۹۴۱

E-mail: Shalbaf@sbm.ac.ir

مقدمه

(MDD) می‌باشد^۱. با توجه به کاهش کیفیت زندگی این بیماران و ماهیت پیش‌رونده این بیماری، درمان موثر و به موقع آن ضروری می‌باشد^۲. در حال حاضر تشخیص وجود بیماری در اشخاص و یا سطح آن براساس پرسشنامه و مصاحبه با افراد انجام می‌گیرد که زمانبر می‌باشند و خروجی آنها به همکاری بیمار و تجربه پزشک

براساس اعلام سازمان جهانی بهداشت (WHO) از هر هشت نفر در جهان یک نفر به یکی از انواع اختلالات روانی مبتلا می‌باشد که یکی از شایع‌ترین بیماری‌های حوزه روان، اختلال افسردگی عمده

دسته‌بندی ویژگی‌های استخراج شده از سیگنال EEG افراد برای تشخیص وجود افسردگی استفاده کردند و به دقت حدود ۹۶٪ دست یافتند.^{۱۱} Zhang و همکاران از یک مدل یادگیری عمیق مبتنی بر مکانیسم توجه برای تشخیص افسردگی از روی سیگنال خام استفاده کردند و به دقت ۹۲٪ رسیدند.^{۱۲} مکانیسم توجه در این روش روی وابستگی‌های طولانی‌مدت موجود در سیگنال مغزی تمرکز می‌کند و به این ترتیب ممکن است به خاطر توجه کمتر به وابستگی‌های کوتاه مدت موجود در سیگنال مغزی، تعمیم پذیری روش کاهش یابد. Das و Naskar یک مدل مبتنی بر هوش مصنوعی مولد توسعه دادند که می‌تواند سیگنال‌های مغزی مشابه سیگنال مغزی فرد افسرده تولید کند و در صورتی که سیگنال مغزی اصلی مشابهت بالایی با سیگنال تولید شده داشته باشد، آن فرد به‌عنوان بیمار افسرده دسته‌بندی می‌شود.^{۱۳} با استفاده از این روش دقت دسته‌بندی حدود ۹۲٪ به دست آمد. با این وجود با توجه به پیچیدگی‌های موجود در یک سیگنال EEG و تفاوت‌های بین فردی، استفاده از این روش نیازمند دسترسی به حجم بسیار بالایی از داده‌ها می‌باشد.

با توجه به اینکه استخراج ویژگی‌های خاص از سیگنال EEG می‌تواند سبب تخریب اطلاعات ذاتی موجود در سیگنال شود و با توجه به محدودیت‌ها و دشواری‌های مربوط به جمع‌آوری مجموعه بزرگی از داده‌ها، توسعه مدل هوش مصنوعی که از سیگنال مغزی خام استفاده نماید، ضروری به نظر می‌رسد.^{۱۴} از طرفی یک مدل هوش مصنوعی با ساختار ساده، علاوه بر نیاز کمتر به داده ورودی، قابلیت استفاده و تفسیرپذیری بالاتری را برای پزشکان فراهم می‌آورد. در نتیجه سوال اصلی این تحقیق این بوده است که آیا می‌توان یک مدل ساده هوش مصنوعی برای دسته‌بندی سیگنال EEG افراد سالم و افسرده توسعه داد که بتواند مستقیماً با استفاده از داده خام EEG افسردگی را تشخیص دهد؟ هدف از این تحقیق استفاده از یک الگوریتم یادگیری عمیق مبتنی بر مدل‌های کانولوشنی برای ساخت سامانه تشخیص خودکار افسردگی از روی سیگنال EEG افراد می‌باشد.

روش بررسی

داده‌ها و پیش‌پردازش: در این پژوهش از داده EEG مربوط به

وابسته است و در نتیجه ممکن است این روش‌ها سبب اتلاف زمان و هزینه بیمار و پزشکان گردند.^{۱۵} در نتیجه در بسیاری از مطالعات اخیر، یک رویکرد پزشکی دقیق برای دستیابی به روش‌های شخصی‌سازی شده برای هر بیمار اتخاذ شده است. به این ترتیب نیاز به یک روش شخصی‌سازی شده مبتنی بر روش‌های پیشرفته هوش مصنوعی برای تشخیص دقیق این بیماری برای هر مراجعه‌کننده ضروری می‌باشد.^{۱۶} از روش‌های مختلفی برای بررسی خودکار ابتلا به افسردگی با استفاده از الگوریتم‌های هوش مصنوعی استفاده می‌شود. می‌توان تشخیص افسردگی را با استفاده از اطلاعات شخصی، کلینیکی، ژنتیکی، تصویربرداری مغزی یا فعالیت‌های مجازی اشخاص انجام داد.^{۱۷} سیگنال‌های الکتروانسفالوگرام (EEG) که یکی از روش‌های نقشه‌برداری مغز به‌شمار می‌آید و فعالیت مغزی ثبت شده از روی پوست سر را نشان می‌دهند به دلیل ارتباط مستقیم با منشا افسردگی، دقت زمانی بالا، کاربری راحت و در دسترس بودن گزینه مناسبی برای بررسی‌های کلینیکی می‌باشد.

با توجه به پیچیدگی‌های مربوط به بیماری افسردگی و تفاوت علائم آن در افراد مختلف، یافتن یک رویکرد جامع و کارآمد برای همه افراد نیازمند مدل‌های شخصی‌سازی شده می‌باشد. امروزه اغلب روش‌های تشخیص خودکار بیماری افسردگی از روش‌های پیشرفته هوش مصنوعی استفاده می‌کنند.^{۱۸} برخی روش‌های هوش مصنوعی که اغلب با عنوان روش‌های یادگیری ماشین شناخته می‌شوند، مبتنی بر استخراج ویژگی‌های خاص از سیگنال EEG می‌باشند. این روش‌ها علاوه بر وابستگی به یک فرد متخصص برای استخراج دستی ویژگی‌های مهندسی شده، می‌توانند سبب تخریب اطلاعات ذاتی موجود در سیگنال شوند.^{۱۹} به این ترتیب تعمیم‌پذیری خروجی این مدل‌ها کاهش می‌یابد. برای حل این مشکل از نوع خاصی از روش‌های یادگیری ماشین با عنوان روش‌های یادگیری عمیق (Deep Learning) استفاده می‌شود که می‌توانند به‌صورت خودکار بهترین ویژگی‌های تفکیک‌کننده را از داده خام استخراج نمایند. به این ترتیب علاوه بر افزایش دقت و کارایی این مدل‌ها، می‌توان نتایج کاربردی تر و تعمیم‌پذیرتری از این مدل‌ها به دست آورد.^{۲۰}

Khan و همکاران از روش‌های یادگیری ماشین مبتنی بر ماشین بردار پشتیبان (Support vector machine)، نزدیکترین همسایگی (K-nearest neighbor) و درخت تصمیم (Decision tree) برای


شده است. فرآیند آموزش و ارزیابی مدل برای تعیین ابرپارامترهای مدل شامل اندازه بسته آموزشی، نرخ یادگیری و تعداد گام آموزش با هدف دستیابی به بالاترین دقت دسته‌بندی انجام شده است.

یافته‌ها

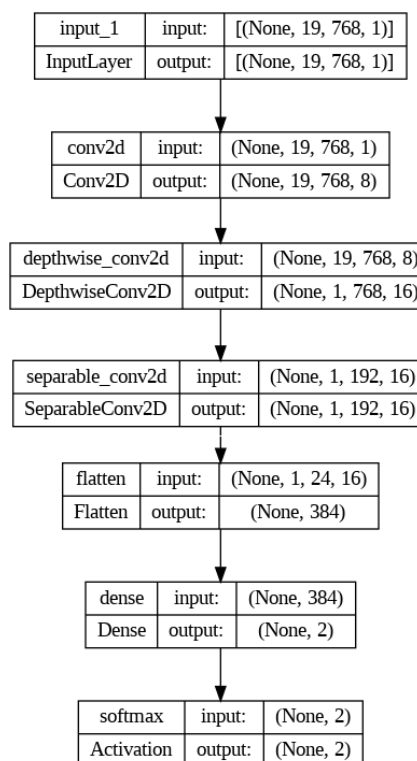
سه مدل یادگیری عمیق کانولوشنی برای دسته‌بندی سیگنال EEG افراد سالم و افسرده مورد استفاده قرار گرفتند و توسط مولفه‌های ارزیابی عملکرد مختلف با یکدیگر مقایسه شدند. برای آموزش این مدل‌ها، ابرپارامترهای آموزش مدل شامل نرخ یادگیری، اندازه بسته آموزشی و تعداد گام آموزش به ترتیب 1e-4، ۴۰ و ۵۰ در نظر گرفته شدند. نمودار آموزش مدل EEGNet در شکل ۲ نمایش داده شده است. نمودار آموزش مدل یادگیری عمیق شامل نمودار دقت و

فرآیند آموزش و تنظیم پارامترها برای رسیدن به بالاترین دقت دسته‌بندی، داده‌های بخش آموزش به دو بخش آموزش و ارزیابی تقسیم شدند تا در هر مرحله از آموزش مدل، ارزیابی اولیه عملکرد مدل توسط داده‌های ارزیابی انجام گیرد. به این ترتیب ۸۰٪ از کل افراد به‌عنوان داده آموزش، ۱۰٪ به‌عنوان داده ارزیابی و ۱۰٪ به‌عنوان داده تست نهایی در نظر گرفته شدند. در آخر دقت مدل روی داده تست نهایی به‌عنوان عملکرد مدل روی داده سنجش که دیده نشده است، گزارش می‌گردد. علاوه بر دقت مدل، حساسیت (Sensitivity)، خاصیت (Specificity) و ضریب F1 نیز گزارش می‌شوند.

توسعه مدل‌های معرفی شده توسط پکیج Keras با زیربنای Tensorflow و زبان برنامه‌نویسی پایتون در محیط Google Colaboratory روی کارت گرافیک Tesla4 با ۱۲ گیگابایت رم انجام




شکل ۲: نمودارهای آموزش مدل EEGNet. نمودار سمت چپ افزایش دقت مدل در طی مراحل مختلف آموزش را نشان می‌دهد. همچنین نمودار سمت راست کاهش تابع هزینه در مرحله آموزش و ارزیابی را به‌طور همزمان نشان می‌دهد که بیانگر عدم وجود بیش‌برازش در مرحله آموزش می‌باشد.



شکل ۱: ساختار درونی مدل EEGNet. ابعاد ورودی و تغییر آنها در لایه‌های مختلف نشان داده شده‌اند. برخی لایه‌های میانی شامل نرمال‌سازی و فعال‌سازی برای نمایش بهتر حذف شده‌اند.

جدول ۱: نتایج حاصل از ارزیابی مدل‌های آموزش دیده بر روی دادگان سنجش.

F1	خاصیت	حساسیت	دقت	
٪۹۴/۵	٪۷۹/۱	٪۹۸/۹	٪۹۲/۳	EEGNet
٪۹۴/۴	٪۸۱/۸	٪۹۷/۵	٪۹۲/۲	DeepConvNet
٪۸۸/۳	٪۵۹/۳	٪۹۵/۱	٪۸۳/۲	ShallowConvNet



شکل ۳: ماتریس درهم‌ریختگی مدل‌های مختلف. برچسب صفر و یک به ترتیب بیانگر افراد سالم و افسرده می‌باشد. برچسب پیش‌بینی شده نیز خروجی مدل هوش مصنوعی می‌باشد.

نمودار تابع هزینه برای دو مرحله‌ی آموزش و ارزیابی می‌باشد. از این نمودار می‌توان برای ارزیابی وجود بیش‌برازش در مرحله آموزش مدل استفاده کرد. جدول ۱ نشان‌دهنده نتایج ارزیابی مدل‌های هوش مصنوعی مورد مطالعه برای دسته‌بندی سیگنال EEG افراد جامعه سنجش است که قبلاً توسط مدل دیده نشده‌اند. به‌طورکلی مدل EEGNet بالاترین عملکرد را ارائه نموده است. هرچند از دیدگاه مولفه خاصیت (SPE) عملکرد مناسبی نداشته است. برای درک بهتر عملکرد مدل‌های ارائه شده، ماتریس درهم‌ریختگی هر کدام از مدل‌ها در شکل زیر نمایش داده شده‌اند. برچسب صفر و یک به ترتیب معادل افراد سالم و بیمار می‌باشد و برچسب‌های پیش‌بینی شده و واقعی به ترتیب خروجی مدل هوش مصنوعی و برچسب داده اصلی می‌باشند.

نمودار تابع هزینه برای دو مرحله‌ی آموزش و ارزیابی می‌باشد. از این نمودار می‌توان برای ارزیابی وجود بیش‌برازش در مرحله آموزش مدل استفاده کرد. جدول ۱ نشان‌دهنده نتایج ارزیابی مدل‌های هوش مصنوعی مورد مطالعه برای دسته‌بندی سیگنال EEG افراد جامعه سنجش است که قبلاً توسط مدل دیده نشده‌اند. به‌طورکلی مدل EEGNet بالاترین عملکرد را ارائه نموده است. هرچند از دیدگاه مولفه خاصیت (SPE) عملکرد مناسبی نداشته است. برای درک بهتر عملکرد مدل‌های ارائه شده، ماتریس درهم‌ریختگی هر کدام از مدل‌ها در شکل زیر نمایش داده شده‌اند. برچسب صفر و یک به ترتیب معادل افراد سالم و بیمار می‌باشد و برچسب‌های پیش‌بینی شده و واقعی به ترتیب خروجی مدل هوش مصنوعی و برچسب داده اصلی می‌باشند.

برای دسته‌بندی سیگنال EEG خام استفاده شده است. سه مدل EEGNet، DeepConvNet و ShallowConvNet توسط سیگنال‌های مغزی ۵۸ شرکت‌کننده در مطالعه آموزش داده شدند و نتایج ارزیابی نهایی مدل‌ها نشان می‌دهد که مدل EEGNet با دقت حدود ٪۹۲ می‌تواند به شکل قابل‌قبولی برای تشخیص افسردگی مورد استفاده قرار گیرد.

مدل‌های توسعه داده شده همگی ترکیبی از لایه‌های کانولوشنی بوده‌اند و تفاوت اصلی آنها در تعداد لایه‌ها و کرنل‌ها یا فیلترهای مورد استفاده بوده است. با این حال نتایج حاصل از آموزش این مدل‌ها نشان می‌دهد که مدل ShallowConvNet که فقط از دو لایه کانولوشنی ساده استفاده کرده است، توانایی زیادی در دسته‌بندی سیگنال‌های مغزی ندارد. این مساله به خاطر ظرفیت پایین این مدل در یادگیری پیچیدگی‌های داده ورودی می‌باشد. با این حال وقتی تعداد لایه‌های کانولوشنی در مدل DeepConvNet به پنج لایه کانولوشنی افزایش پیدا کرده است، قدرت یادگیری مدل به میزان

در این پژوهش برای تشخیص افسردگی از سه مدل کانولوشنی

بحث

در این پژوهش برای تشخیص افسردگی از سه مدل کانولوشنی

بالاتری از دادگان نیز می‌باشد. در مطالعه Das و Naskar از مدل‌های مولد برای تولید سیگنال ساختگی در کنار سیگنال اصلی و استفاده از آن برای آموزش دقت‌تر مدل استفاده شده است.^{۱۳} با وجود استفاده از یک مدل پیچیده که نیازمند داده ورودی بسیار بیشتری می‌باشد و تفسیرپذیری مدل را سخت‌تر می‌کند، دقت به‌دست آمده از این روش تقریباً برابر دقت مطالعه حاضر می‌باشد. از طرفی استفاده از سیگنال ساختگی و تولید شده توسط مدل برای تصمیم‌گیری می‌تواند تعمیم‌پذیری مدل را کاهش دهد و استفاده از این ابزار در محیط واقعی را محدود سازد.^{۱۴}

در مطالعه حاضر با استفاده دقیق از لایه‌های کانولوشنی ساده دقت مشابه با مطالعات روز دنیا به‌دست آمده است. علاوه بر این به دلیل محدودیت تعداد لایه و ساختار ساده‌تر، استفاده از روش‌های تفسیرپذیری برای این مدل نتایج بهتری ایجاد خواهد کرد.^{۱۵}

ماتریس‌های درهم‌ریختگی مدل‌های مختلف در شکل ۳ نشان داده شده است که جزئیات مربوط به تصمیم‌گیری مدل و نقاط ضعف و قدرت مدل را نشان می‌دهد. ماتریس درهم‌ریختگی در دسته‌بندی دودویی به‌صورت ماتریس دو در دو می‌باشد که در اینجا قسمت راست پایین نشان‌دهنده صحیح مثبت می‌باشد که به معنی تعداد نمونه‌هایی است که به‌عنوان بیمار تشخیص داده شدند و واقعا بیمار بوده‌اند. به این ترتیب سمت چپ بالا به عنوان صحیح منفی، چپ پایین به عنوان غلط مثبت و بالا راست به عنوان غلط منفی می‌باشند.^{۱۶} در نتیجه با مشاهده بخش غلط مثبت و مقایسه آن با غلط منفی می‌توان دریافت که بیشترین اشتباهات مدل در تشخیص سیگنال مغزی افراد سالم به‌عنوان افسرده بوده است و بهترین عملکرد مدل در تشخیص صحیح افراد افسرده می‌باشد. این مساله با حساسیت بسیار بالایی که برای هر کدام از مدل‌ها به‌دست آمده است همخوانی دارد. در نتیجه می‌توان گفت که مدل‌های معرفی شده با احتمال بالایی افراد افسرده را به درستی تشخیص می‌دهند و از آنجایی که هدف نهایی این سیستم نیز تشخیص افراد افسرده می‌باشد، می‌توان با اطمینان بالایی از این مدل‌ها در کلینیک‌ها استفاده نمود.^{۱۷} از طرفی معیار خاصیت در این مدل‌ها نسبتاً پایین است که باید در ارزیابی افراد سالم و دادن برجسب افسرده به آنها با دقت بیشتری عمل شود.^{۱۸}

به‌طور خلاصه مدل‌های معرفی شده در این پژوهش، به خصوص مدل EEGNet قابلیت بالایی در دسته‌بندی افراد سالم و افسرده دارند.

قابل‌توجهی افزایش پیدا کرده است. در نتیجه دقت مدل هوش مصنوعی از ۸۳٪ به ۹۲٪ ارتقا یافته است. با این حال مدل DeepConvNet به‌دلیل استفاده از تعداد بسیار بیشتری لایه کانولوشنی و در نتیجه تعداد خیلی بیشتری پارامترهای یادگیری، یک مدل تعمیم‌پذیر و قابل اتکا نیست و برای آموزش صحیح چنین مدلی به حجم بسیار بیشتری از داده ورودی نیاز داریم.^{۱۸} برای حل این مشکل از طراحی مدل EEGNet استفاده شده که می‌تواند با استفاده از تعداد لایه کانولوشنی محدود و طراحی خاص لایه‌های کانولوشنی، علاوه بر دستیابی به نتایج قابل‌قبول، پایداری و تعمیم‌پذیری نتایج مدل را فراهم سازد. به این ترتیب مدل EEGNet توانسته با تعداد لایه کمتر نسبت به DeepConvNet به‌دقت ۹۲٪ برسد و همزمان نتایج پایدارتر و تعمیم‌پذیرتری را ارائه نماید. علاوه بر این به‌دلیل استفاده از معماری ساده‌تر در مدل EEGNet می‌توان از این مدل برای تفسیر نتایج خروجی و پی بردن به علت تصمیم‌گیری مدل هوش مصنوعی استفاده نمود.

نمودار آموزش مدل EEGNet که در شکل ۲ نشان داده شده است، بیانگر همگرایی مدل پس از ۵۰ گام آموزش می‌باشد و فاصله کم بین نمودار آموزش و ارزیابی در هر دو شکل مربوط به دقت و تابع هزینه مدل نشان‌دهنده عدم وجود بیش‌برازش در مرحله یادگیری مدل هوش مصنوعی می‌باشد. علاوه بر این، نوسانات حداقلی در نمودار ارزیابی مدل در زمان همگرایی نشان‌دهنده پایداری مدل در دسته‌بندی سیگنال مغزی می‌باشد.^{۱۹}

نتایج حاصل از این پژوهش در حد نتایج منتشر شده در مطالعات روز دنیا برای تشخیص افسردگی از روی سیگنال EEG می‌باشد.^{۱۱-۱۳} در تحقیق Khan و همکاران از روش‌های یادگیری ماشین سنتی برای تشخیص افسردگی استفاده شده است که با وجود تفسیرپذیری بیشتر امکان استخراج بیشترین اطلاعات از سیگنال مغزی را ندارند و ممکن است ویژگی‌های ذاتی موجود در سیگنال مغزی را تخریب نمایند.^{۲۰} در تحقیق Zhang و همکاران که از مدل توجه برای تشخیص افسردگی استفاده کردند، دقت برابر با روش پیشنهادی در این مطالعه به‌دست آمده است. این درحالی است که مدل‌های مبتنی بر توجه بیشترین تمرکز را روی روابط بلندمدت موجود در توالی‌های ورودی دارند و ویژگی‌های محلی و کوتاه‌مدت ورودی را از دست می‌دهند.^{۱۲} علاوه بر این آموزش مدل‌های مبتنی بر توجه نیازمند حجم

پژوهش بعدی در این زمینه می‌تواند توسعه یک مدل هوش مصنوعی تفسیرپذیر برای تشخیص افسردگی از روی سیگنال EEG باشد. علاوه بر این توسعه مدل‌های ساده مبتنی بر تبدیل شونده‌ها (Transformers) و شبکه‌های عصبی گرافی (Graph neural networks) که کارایی بالایی در حوزه‌های دیگر نشان داده‌اند، برای دسته‌بندی سیگنال‌های مغزی، نیز می‌تواند مفید باشد.

سپاسگزار می‌باشم: این مقاله منتج از پایان‌نامه تحت عنوان "پیش‌بینی پاسخ به درمان تحریک مغناطیسی فراجمجمه‌ای تکراری برای اختلال افسردگی عمده با استفاده از EEG و الگوریتم‌های یادگیری عمیق" مقطع دکترای تخصصی رشته مهندسی پزشکی در سال ۱۴۰۲ با کد ۲۱۸۲۴ می‌باشد که در دانشگاه علوم پزشکی شهیدبهشتی به انجام رسیده است.

با این حال محدودیت اصلی تحقیق حاضر استفاده از تعداد محدودی شرکت‌کننده بوده که بیانگر تمام تنوع موجود بین بیماران مبتلا به افسردگی و افراد سالم نیست. به این ترتیب افزایش تعداد نمونه‌ها می‌تواند خروجی‌های قابل اطمینان‌تری ایجاد نماید. همچنین افزایش تعداد نمونه‌ها می‌تواند امکان توسعه مدل‌های پیچیده‌تر و عمیق‌تر را فراهم سازد که سبب افزایش دقت و کارایی دسته‌بندی سیگنال مغزی می‌گردد.^{۲۴} محدودیت دیگر مدل‌های ارائه شده عدم تفسیرپذیری نتایج می‌باشد، به این معنی که مشخص نیست مدل هوش مصنوعی بر چه اساسی تصمیم گرفته است که یک نمونه سیگنال مغزی متعلق به فرد سالم یا افسرده می‌باشد.^۶ برای درک بهتر این مساله باید از روش‌های تفسیرپذیری استفاده شود تا مشخص گردد کدام بخش‌های ورودی بیشترین تاثیر را در تصمیم‌گیری مدل داشته‌اند. به این ترتیب

References

1. Wu Y, Zhao X, Li Z, Yang R, Peng R, Zhou Y, et al. Prevalence and risk factors for psychotic symptoms in young, first-episode and drug-naïve patients with major depressive disorder. *BMC psychiatry* 2024;24(1):66.
2. Shahabi MS, Shalbf A, Maghsoudi A. Prediction of drug response in major depressive disorder using ensemble of transfer learning with convolutional neural network based on eeg. *Biocybernetics and Biomedical Engineering* 2021;41(3):946-59.
3. Chiang H-S, Chen M-Y, Liao L-S. Cognitive depression detection cyber-medical system based on EEG analysis and deep learning approaches. *IEEE Journal of Biomedical and Health Informatics* 2022;27(2):608-16.
4. Ams M, van Dijk H, Luyck JJ, van Wingen G, Olbrich S. Stratified psychiatry: Tomorrow's precision psychiatry? *European Neuropsychopharmacology* 2022;55:14-9.
5. Karvelis P, Charlton CE, Allohverdi SG, Bedford P, Hauke DJ, Diaconescu AO. Computational approaches to treatment response prediction in major depression using brain activity and behavioral data: A systematic review. *Network Neuroscience* 2022;6(4):1066-103.
6. Byeon H. Advances in Machine Learning and Explainable Artificial Intelligence for Depression Prediction. *International Journal of Advanced Computer Science and Applications* 2023.
7. Singhi SK, Liu H, editors. Feature subset selection bias for classification learning. *Proceedings of the 23rd international conference on Machine learning* 2006.
8. Shahabi MS, Shalbf A, Rostami R. Prediction of response to repetitive transcranial magnetic stimulation for major depressive disorder using hybrid Convolutional recurrent neural networks and raw Electroencephalogram Signal. *Cognitive Neurodynamics* 2023;17(4):909-20.
9. Ay B, Yildirim O, Talo M, Baloglu UB, Aydin G, Puthankattil SD, et al. Automated depression detection using deep representation and sequence learning with EEG signals. *Journal of Medical System*. 2019;43(7):205.
10. Shahabi MS, Shalbf A, Nobakhsh B, Rostami R, Kazemi R. Attention-Based Convolutional Recurrent Deep Neural Networks for the Prediction of Response to Repetitive Transcranial Magnetic Stimulation for Major Depressive Disorder. *International Journal of Neural Systems* 2023;33(02):2350007.
11. Khan S, Umar Saeed SM, Fmda J, Arsalan A, Amin R, Gantassi R, et al. A machine learning based depression screening framework using temporal domain features of the electroencephalography signals. *Plos one* 2024;19(3):e0299127.
12. Zhang Z, Meng Q, Jin L, Wang H, Hou H. A novel EEG-based graph convolution network for depression detection: incorporating secondary subject partitioning and attention mechanism. *Expert Systems with Applications* 2024;239:122356.
13. Das AK, Naskar R. A deep learning model for depression detection based on MFCC and CNN generated spectrogram features. *Biomedical Signal Processing and Control* 2024;90:105898.
14. Mumtaz W, Xia L, Mohd Yasin MA, Azhar Ali SS, Malik AS. A wavelet-based technique to predict treatment outcome for major depressive disorder. *PLoS one* 2017;12(2):e0171409.
15. Shahabi MS, Shalbf A, Rostami R, Kazemi R. A convolutional recurrent neural network with attention for response prediction to repetitive transcranial magnetic stimulation in major depressive disorder. *Scientific Reports* 2023;13(1):10147.
16. Wan Z, Huang J, Zhang H, Zhou H, Yang J, Zhong N. HybridEEGNet: A Convolutional Neural Network for EEG Feature Learning and Depression Discrimination. *IEEE Access* 2020;8:30332-42.
17. Lawhern VJ, Solon AJ, Waytowich NR, Gordon SM, Hung CP, Lance BJ. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of neural engineering* 2018;15(5):056013.
18. Bagherzadeh S, Shahabi MS, Shalbf A. Detection of schizophrenia using hybrid of deep learning and brain effective connectivity image from electroencephalogram signal. *Computers in Biology and Medicine* 2022;146:105570.
19. Shahabi MS, Nobakhsh B, Shalbf A, Rostami R, Kazemi R. Prediction of treatment outcome for repetitive transcranial magnetic stimulation in major depressive disorder using connectivity measures and ensemble of pre-trained deep learning models. *Biomedical Signal Processing and Control* 2023;85:104822.
20. Khan A, Sohail A, Zahoora U, Qureshi AS. A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review* 2020;53:5455-516.

21. Roessner V, Rothe J, Kohls G, Schomerus G, Ehrlich S, Beste C. Taming the chaos?! Using eXplainable Artificial Intelligence (XAI) to tackle the complexity in mental health research. *Springer* 2021. p. 1143-6.
22. Shahabi MS, Shalhaf A. Prediction of Treatment Outcome in Major Depressive Disorder using Ensemble of Hybrid Transfer Learning and Long Short Term Memory based on EEG Signal. *IEEE Transactions on Cognitive and Developmental Systems* 2022.
23. Khosla A, Khandnor P, Chand T. Automated diagnosis of depression from EEG signals using traditional and deep learning approaches: A comparative analysis. *Biocybernetics and Biomedical Engineering* 2022;42(1):108-42.
24. Ellis CA, Sancho ML, Miller RL, Calhoun VD. Identifying EEG Biomarkers of Depression with Novel Explainable Deep Learning Architectures. *bioRxiv* 2024.

Detection of major depressive disorder using artificial intelligence methods based on electroencephalogram signals

Mohsen Sadat Shahabi Ph.D.
Ahmad Shalbaf Ph.D.*

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

* Corresponding author: Department of
Physics and Biomedical Engineering,
School of Medical Sciences, Shahid
Beheshti University of Medical Sciences,
Koodak Yar St., Daneshjou Blvd.,
Velenjak, Tehran, Iran.
Tel: +98-21-22439941
E-mail: Shalbaf@sbmu.ac.ir

Abstract

Received: 24 Jan. 2024 Revised: 30 Jan. 2024 Accepted: 11 Apr. 2024 Available online: 20 Apr. 2024

Background: Major Depressive Disorder (MDD) is one of the most prevalent and disabling mental disorders in the world. Due to the life quality decline caused by this disease and its growing nature, timely detection and treatment is of paramount importance. In the present study Electroencephalogram (EEG) signal utilized for the precise detection of MDD using Artificial Intelligence (AI) Methods.

Methods: In this analytic study, which is done in Shahid Beheshti University of medical Sciences in 2023, fifty eight subjects were investigated using an experienced psychiatrist that 30 subjects diagnosed as MDD and 28 determined to be healthy. Nineteen channels EEG signals in resting state with eyes closed situation acquired for five minutes from all of the participants including 36 men and 22 women with the average age of 39.3 years. The EEG signals were preprocessed to remove contaminating signals from brain-originated signals. The EEGLAB package in MATLAB utilized to re-reference channels to the average reference, apply a band-pass filter between 1 and 40 Hz and to remove non-brain components of the signal using Independent Component Analysis (ICA). The cleaned data segmented to the three seconds windows with 50 percent overlapping. These segments were used as the input to the AI models. Deep Learning (DL) models utilized in the present study were EEGNet, ShallowConvNet and DeepConvNet which were developed based on the deep convolutional models for the classification of healthy and MDD brain signals. The main difference between these models laid in the number of specific convolutional layers and the model complexity.

Results: MDD and Healthy signals classification has been done using EEGNet, ShallowConvNet and DeepConvNet models and accuracy of 92.3%, 83.2% and 92.2% were achieved, respectively. Also EEGNet acquired the highest sensitivity of 98.9% and specificity of 79.1%.

Conclusion: The detection of MDD patients using EEG signals with high accuracy and generalizability is possible and proposed AI models can be utilized in the clinical settings as assistant tools.

Keywords: artificial intelligence, deep learning, electroencephalography, major depressive disorder.

