

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

روش‌های تشخیص اختلال افسردگی عمده با استفاده از سیگنال

الکتروانسفالوگرام و یادگیری ماشین

وحید شرقیان دیزجی (نویسنده مسئول)^۱، یاشار سرباز^۲، لاجین صوفی‌زاده^۳، محمدرضا آریانی^۴

^۱ دانشگاه تبریز، تبریز sharghian@tabrizu.ac.ir

^۲ دانشگاه تبریز، تبریز yashar.sarbaz@tabrizu.ac.ir

^۳ دانشگاه تبریز، تبریز lachinsoufizadeh@gmail.com

^۴ دانشگاه تبریز، تبریز mohammadrezaariany@gmail.com

چکیده

اختلال افسردگی عمده (MDD) یکی از اختلالات روانی نسبتاً شایع در اکثر جوامع است که با علائمی مانند حالت و خلق افسردگی، بی‌علاقگی، و در موارد شدیدتر با میل به خودکشی ظهور و بروز می‌یابد. همچنین این بیماری می‌تواند با علائم فیزیکی مانند سردرد، خستگی، مشکلات گوارشی و کاهش اشتها نیز همراه باشد. تشخیص این بیماری عموماً با ارزیابی بالینی توسط پزشک یا روانشناس و همچنین به کمک گرفتن از پرسشنامه‌هایی مانند پرسشنامه افسردگی بک انجام می‌پذیرد. با توجه به اینکه در این روش‌ها احتمال خطای قابل توجهی وجود دارد و همچنین به دلیل اشتراک نشانه‌های این بیماری با علائم سایر بیماری‌ها مانند اختلال دو قطبی، روش‌های تشخیصی مبتنی بر علائم فیزیولوژیک که دارای قابلیت اتکای بالاتری هستند، مورد توجه قرار گرفته‌اند. یکی از این روش‌ها بهره‌گیری از سیگنال الکتروانسفالوگرام (EEG) است که منعکس‌کننده فعالیت نواحی مختلف قشر مغز است. با توجه به همبستگی موجود بین برخی از ویژگی‌های سیگنال EEG با اختلال افسردگی، می‌توان از این سیگنال برای تشخیص اختلال افسردگی و افتراق آن از سایر اختلالات بهره جست. در این مقاله آخرین پژوهش‌های انجام شده در حوزه تشخیص اختلال افسردگی عمده با استفاده از سیگنال الکتروانسفالوگرام مورد مرور و بررسی قرار گرفته‌اند.

واژه‌های کلیدی

اختلال افسردگی عمده، الکتروانسفالوگرام، افسردگی، EEG، MDD

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران


12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

۱. مقدمه

افسردگی یک بیماری روانی است که اغلب با از دست دادن علاقه، احساس گناه، افت اعتماد به نفس، کمبود تمرکز و در بدترین حالت، داشتن افکار خودکشی همبسته می‌شود [۱]. این بیماری بسته به شدت علائم آن با عناوین خفیف، متوسط یا شدید دسته‌بندی می‌شود. تخمین زده می‌شود که بیش از ۳۰۰ میلیون نفر از تمام گروه‌های سنی در سراسر جهان از افسردگی رنج می‌برند [۲]. حدود نیمی از افراد مبتلا به افسردگی از وجود بیماری خود آگاه نیستند یا اختلال آن‌ها اشتباه تشخیص داده شده است [۳]. به دلیل تبعات اجتماعی مرتبط با وضعیت و طبیعت افسردگی، افراد مبتلا به افسردگی کمتر تمایل به درخواست مراقبت دارند. به عبارت دیگر، بسیاری از افراد مبتلا به افسردگی تشخیص‌های نادرست و مراقبت ناکافی دریافت می‌کنند که باعث تأخیر در بهبود آن‌ها می‌شود. بنابراین، یک حوزه پژوهش در حال رشد، کشف راه‌های عملی و قابل اعتماد برای شناسایی افسردگی است. با آخرین نوآوری‌ها در فناوری‌های حسگری و تلفن همراه، تجزیه و تحلیل داده‌های فیزیولوژیکی برای تشخیص بیماری‌های روانی، یک فرصت کاملاً جدید برای ایجاد یک ابزار برای شناسایی افسردگی به وجود می‌آید.

یک مقایسه شماتیک از اتصالات عصبی در یک فرد سالم و یک فرد افسرده در شکل (۱) ارائه شده است. نورون‌ها در افراد افسرده به درستی عمل نمی‌کنند این فرآیند منجر به کاهش آزادسازی نوروترانسمیتر و کاهش غلظت گیرنده‌ها در اتصالات عصبی نسبت به افراد سالم می‌شود [۴]. الکتروانسفالوگرافی (EEG) یک ابزار مؤثر و شناخته‌شده برای ثبت فعالیت مغز است [۵]. در سال‌های اخیر به طور گسترده‌ای برای مطالعه و تشخیص اختلالات عصبی مختلف از جمله صرع [۶، ۷، ۸]، پیش‌بینی تشنج [۹، ۱۰]، بیماری آلزایمر [۱۱]، کاهش توانایی شناختی ضعیف (MCI) [۱۲]، بیماری پارکینسون [۱۳، ۱۴]، بیماری کروتسفلد-جیکوب [۱۵] و مطالعات خواب [۱۶] استفاده شده است. [۱۷]



شکل (۱): مقایسه شماتیک از اتصالات سیناپسی در یک فرد سالم و یک بیمار افسرده

در حال حاضر، تشخیص افسردگی بر اساس ارزیابی‌های روانپزشکی انجام می‌شود که شامل گزارش‌های خود بیمار و برخی پرسشنامه‌ها مانند مقیاس افسردگی بک [۱۸] و مقیاس افسردگی همیلتون می‌شوند [۱۹]. این روش‌های سنتی توسط روانپزشکان انجام می‌شود و به تجربه حرفه‌ای آنها وابسته است، که ممکن است تحت تأثیر ارزیابی‌های ذهنی قرار بگیرد، زیرا بررسی‌های دقیق به دلیل محدودیت‌های

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

هزینه‌ای و زمانی به ندرت انجام می‌شوند. در سال‌های اخیر، برخی از روش‌های مبتنی بر داده‌های عصبی به صورت موضوعی معرفی شده‌اند. از جمله اندازه‌گیری‌های عصبی، الکتروانسفالوگرام^۱ (EEG) به عنوان یک روش مقرون به صرفه و بدون تداخل مزیت دارد. برای طبقه‌بندی افسردگی با استفاده از داده‌های EEG، بسیاری از روش‌های یادگیری ماشین استفاده شده است [۲۰ - ۲۲].

سیگنال الکتروانسفالوگرام گرفته شده از مناطق قدامی و گیجگاهی مغز یک فرد افسرده، نشانگر ویژگی‌های غیرطبیعی نسبت به یک فرد نرمال می‌باشد [۲۳]. بیماران افسرده فعالیت سمت چپ قدامی کمتری دارند و فعالیت بیشتری در باند آلفا را نسبت به یک فرد نرمال نشان می‌دهند. لازم به ذکر است که افزایش انرژی در باند آلفا به معنای کاهش فعال‌سازی است. به طور مشابه، بیماران افسرده نسبت به بیماران غیرافسرده، در سیگنال‌های EEG جبهه سمت راست فعالیت بیشتری دارند (کمترین انرژی باند آلفا) [۲۳ و ۲۴].

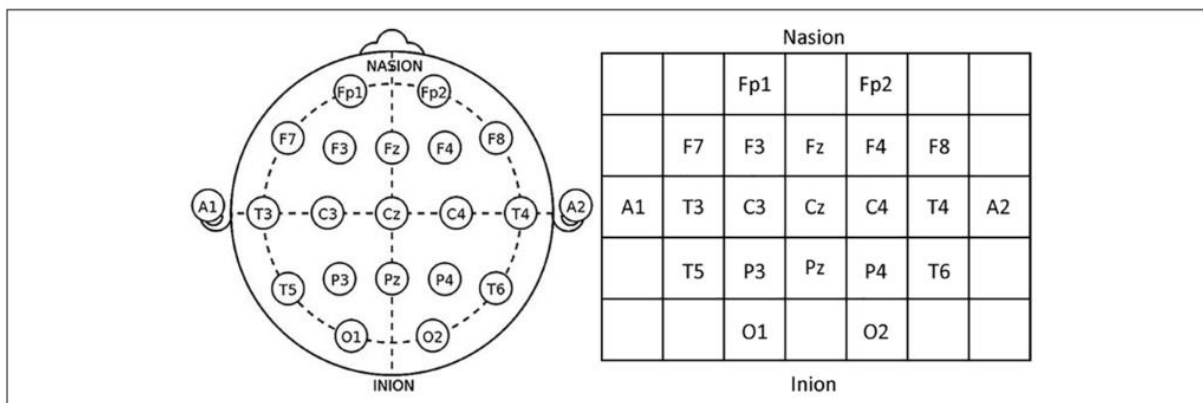
همچنین مشاهده شده است که پیچیدگی در عملکرد مغز در بیماران افسرده نسبت به افراد نرمال کاهش یافته که به کاهش تعامل با محیط اشاره می‌کند [۲۵]. Pezard و همکاران [۲۶] همچنین نشان داده‌اند که در پاسخ به مداخلات درمانی در دوره‌های ابتدایی و بعدی افسردگی تفاوت معنی‌داری وجود دارد. تجزیه و تحلیل سیگنال‌های عصبی - روانی به دست آمده به صورت دستی دشوار است [۲۷]. بنابراین، تکنیک‌های یادگیری ماشین که برای استخراج ویژگی‌های مهم استفاده می‌شوند برای کمک به طبقه‌بندیها وارد می‌شوند [۲۸].

۲. الکتروانسفالوگرافی

سیگنال الکتروانسفالوگرام، یکی از سیگنال‌های عملکردی مغز است که با اندازه‌گیری جریان سطحی ناشی از فعالیت الکتریکی سیستم عصبی مغز در محل پوست جمجمه^۲ به دست می‌آید. یک سیگنال الکتروانسفالوگرام، حاصل اندازه‌گیری جریان‌هایی است که در طول تحریکات سیناپسی دندریت‌ها، از بسیاری از نورون‌های هرمی در قشر مغز جاری می‌شوند. زمانی که سلول‌های مغز (نورون‌ها) فعال هستند، جریان‌های سیناپسی درون دندریت‌ها تولید می‌شوند. این جریان‌ها، میدان مغناطیسی و میدان الکتریکی روی پوست سر تولید می‌کنند که به ترتیب توسط دستگاه‌های MEG^۳ و سیستم‌های EEG قابل سنجش است.

دیتای الکتروانسفالوگرام اغلب با استفاده از کلاه‌های مخصوص ضبط EEG نمونه برداری میشوند که روی سر فرد قرار می‌گیرند. همچنین در اکثر مواقع از سیستم موقعیت الکتروود بین المللی ۱۰-۲۰ برای ثبت استفاده می‌شود.

در [۲۹] برای ضبط داده‌های EEG، کلاه EEG شامل ۱۹ کانال بر روی پوست سر به ترتیب سیستم موقعیت الکتروود بین المللی ۱۰-۲۰ قرار گرفت و با بستن چشمان به مدت ۵ دقیقه به دست آمد.



شکل (۲): محل قرارگیری الکتروودها بر روی پوست جمجمه مطابق سیستم ۱۰ - ۲۰ [۲۹]

¹ Electroencephalogram

² Scalp

³ Magnetoencephalography

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

ممکن است دیتا های ضبط شده و تمیز شده در دسته بندی های مختلفی قرار گیرنده که شامل دسته بندی های - از لحاظ باند فرکانسی - کانال های نیمکره سمت راست و چپ باشد. یک کلاه الاستیک حاوی ۱۲۸ الکتروود، یک تجهیز معمول برای ضبط EEG در تحقیقات و محیط های بالینی است. این کلاه شامل یک کاپ است که بر سر شرکت کننده قرار می گیرد و ۱۲۸ الکتروود در مکان های مشخص بر اساس سیستم بین المللی ۲۰-۱۰ قرار داده شده است. یک مجموعه ۳ الکتروود قابل استفاده که قابلیت پوشیدن را دارد، نوعی جدیدتر از تجهیزات ضبط EEG است که برای کاربردهای گسترده طراحی شده است. به طور معمول، این مجموعه، شامل یک دستگاه کوچک است که بر روی پیشانی یا پشت گوش قرار داده می شود و سه الکتروود دارد که در تماس با پوست قرار می گیرند. این الکتروودها سیگنال های الکتریکی تولید شده توسط مغز را تشخیص می دهند و آنها را به یک گیرنده بی سیم یا برنامه تلفن همراه منتقل می کنند که سیگنال را ضبط و تحلیل می کند [۳۰].

بسیاری از اختلالات مغزی با بررسی بصری سیگنال های الکتروانسفالوگرام تشخیص داده می شوند. کارشناسان بالینی در این زمینه، با نحوه آسکار سازی ریتم های مغزی آشنا هستند؛ در بزرگسالان سالم، دامنه ها و فرکانس های چنین سیگنال هایی، برای حالت های مختلف یک انسان از جمله بیداری و خواب، تغییر می کنند. ویژگی های امواج نیز با تغییر سن، تغییر می کنند. پنج موج مغزی اصلی وجود دارند که با محدوده های فرکانسی مختلف شان متمایز می شوند. این باندهای فرکانسی عبارتند از دلتا، تتا، آلفا، بتا، گاما.

۳. اختلال افسردگی و الکتروانسفالوگرام

مطابق آنچه که در بخش های گذشته ذکر شد، اختلال افسردگی، فعالیت بخش های مختلف مغز را تحت تاثیر قرار می دهد. از طرفی فعالیت قسمت های مختلف قشر مغز می تواند از طریق ثبت غیرتهاجمی سیگنال EEG مورد مطالعه و رهگیری قرار گیرد. بنابر این؛ پژوهشگران متعددی در صدد برآمده اند تا با بهره جستن از اطلاعات استخراج شده از سیگنال الکتروانسفالوگرام به تشخیص اختلال افسردگی عمده (MDD) از روی این سیگنال بپردازند. در این بخش تعدادی از جدیدترین و مهم ترین پژوهش های انجام شده در این حوزه مورد مرور و بررسی قرار گرفته اند.

در [۲۹] از اتصالات موثر^۴ مغزی برای شناسایی و تشخیص ابتلای فرد به اختلال افسردگی عمده استفاده شده است. اتصالات موثر مغزی به عنوان یک روش تحلیل محبوب در عصر نوین علوم اعصاب به دلیل قدرت خود در نمایش جریان اطلاعات بین کانال های مختلف، مورد توجه قرار گرفته است [۳۱]. مشهورترین روش برای تخمین اتصال موثر، رابطه علیت گرنجر (GC) است که یک رویکرد مبتنی بر مدل است [۳۲]. اگر یک سیگنال بتواند بهتر از اطلاعات خودش توسط اطلاعات قبلی سیگنال دیگری پیش بینی شود، در این صورت سیگنال دوم به عنوان علت سیگنال اول در نظر گرفته می شود. میزان GC می تواند در دامنه فرکانس محاسبه شود که این امر امکان تحلیل باندهای فرکانسی EEG را فراهم می کند. برای دستیابی به این موضوع، تخمین پارامترهای مدل خودبازگشتی^۵ چند متغیره (MVAR) برای داده های یک سیگنال فردی مورد نیاز است.

در پژوهشی دیگر [۳۳] از اطلاعات زمانی و فرکانسی سیگنال EEG برای دسته بندی افراد مبتلا به اختلال افسردگی و افراد سالم بهره گرفته شده است. برای این منظور، سیگنال EEG دوقطبی هر فرد از نیمکره چپ از طریق الکتروودهای P3, T5, C3, T3, F3, F7, Fp1 و O1 و از نیمکره راست از طریق الکتروودهای P4, T6, C4, T4, F4, F8, Fp2 و O2 در حالی که افراد بیدار و آرام بودند و چشمانشان بسته بود، به مدت ۲۰۰ ثانیه پس از شروع استراحت، ثبت شده است. مؤلفه های فرکانسی دلتا، تتا، آلفا و بتا با استفاده از فیلتر میان گذر Butterworth مرتبه ۱۲ به دست آمده است. فرکانس های قطع پایین و بالای ۳ دسی بل برای باند آلفا ۸ تا ۱۲.۵ هرتز، باند بتا ۱۳ تا ۳۰ هرتز، باند تتا ۴.۵ تا ۷.۵ هرتز و باند دلتا ۲ تا ۴ هرتز می باشد. ضعف باندهای حذف اول و دوم ۰.۰۰۰۱ بوده و تنوع پهنای نویز باند گذر عبوری ۰.۰۵۷۵ و ضریب چگالی به عنوان ۲۰ انتخاب شده است. الگوریتم فیلتر FIR (پاسخ ضربه متناهی) بهینه Parks-McClellan

⁴ Effective Connectivity

⁵ Autoregressive

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

که هدف آن کمینه کردن خطای باندهای گذر و توقف با استفاده از تقریب چپی شف است، در پیاده سازی فیلترها و ارزیابی ضرایب فیلتر استفاده شده است. در نهایت با استفاده از شبکه عصبی کانولوشنی عمیق، دسته بندی انجام شده است.

برای تشخیص افراد افسرده و افراد سالم، از الگوریتم ماشین بردار پشتیبان⁶ (SVM) نیز برای انجام دسته بندی دودویی استفاده شده است [۳۵]. از دسته بندی کننده SVM با موفقیت برای دسته بندی ویژگی های گراف مرتبط با افراد معتاد [۳۴]، EEG های افسرده گی [۳۵] و سیگنال های EEG خواب [۳۵ و ۳۶] استفاده شده است. این الگوریتم دسته بندی، تمایز فضای خطی و دسته بندی غیرخطی را با انتخاب توابع کرنل^۷ مختلف انجام می دهند که می توانند خطی، کرنل چندجمله ای، توابع پایه مبنا شعاعی (RBF) یا توابع سیگموئید باشند. یک SVM دو پارامتر فرایارامتر برای تنظیم دارد: هزینه C و گاما δ . جستجوی شبکه ای برای تخمین C و δ استفاده شد تا عملکرد بهینه را بدست آورد [۳۷]. فرایارامتر اول (C) مراقبت از تنظیم مدل است. پارامتر از کرنل RBF به دست می آید و به طور قابل فهم، تأثیر هر نقطه داده را بر پیش بینی مدل نشان می دهد [۳۸].

در [۳۹]، برای شناسایی افسردگی خفیف از سیگنال های EEG و الگوریتم بهینه سازی تکاملی تفاضلی (DE) استفاده شده است. DE یک الگوریتم بهینه سازی جهانی تطبیقی بر اساس تکامل جمعیت است [۴۰]. داده های EEG از ۱۰ نفر با افسردگی خفیف و ۱۰ نفر عادی جمع آوری شده است. الکترودها بر اساس سیستم ۱۰-۲۰ قرار داده شده اند و سیگنال ها در حین تماشای چهره های احساسی و بی احساس ضبط شده اند.

باندهای فرکانسی کلیدی (تتا، آلفا، بتا) با استفاده از فیلترهای باند گذر استخراج شده و ویژگی هایی از جمله چگالی طیفی توان، پارامترهای Hjorth [۴۱] و ویژگی های غیرخطی مانند آنتروپی محاسبه شده اند که منجر به تولید ۸۶۴ ویژگی می شود. سپس DE به عنوان جمعیت فضای ویژگی مورد استفاده قرار گرفته است. عملیات موتاسیون، تقاطع و انتخاب برای به دست آوردن ویژگی های بهینه انجام شده و در ادامه به منظور دسته بندی از دسته بندی کننده نزدیک ترین همسایه (kNN) استفاده شده است.

نتایج نشان می دهد که بهینه سازی ویژگی با استفاده از DE، دقت دسته بندی را حدود ۱۶-۱۷٪ نسبت به kNN به تنهایی در مجموعه های داده مختلف افزایش داده است. ویژگی های باند بتا دقت بالاتر ۹۷،۴۴٪ را ارائه داده اند که نشان می دهد که موج های بتا برای تمییز افسردگی بسیار مهم هستند. مقایسه با روش های انتخاب ویژگی دیگر مانند انتخاب مبتنی بر همبستگی نیز عملکرد برتر بهینه سازی DE پیشنهادی را نشان می دهد.

به طور خلاصه، DE یک روش موثر برای بهینه سازی ویژگی های EEG استخراج شده برای شناسایی افسردگی خفیف است که باعث افزایش قابل توجه دقت دسته بندی نسبت به روش های استاندارد می شود. این مطالعه چارچوبی برای استفاده از الگوریتم های جستجوی سراسری مانند DE در افزایش عملکرد سیستم های تشخیصی مبتنی بر EEG ارائه می دهد.

تحقیق [۴۲] یک روش تشخیص افسردگی مبتنی بر EEG با استفاده از اطلاعات فضایی را پیشنهاد کرده است. داده های EEG از ۱۶ بیمار افسردگی و ۱۴ کنترل سالم در حین انجام وظیفه ی نگاه به جمعیت با چهره های مثبت و منفی جمع آوری شده اند [۴۳]. برای افزایش تفاوت های فضایی، روش الگوی فضایی مشترک مرتبط با وظیفه^۸ (TCSP) پیشنهاد شده است. ویژگی هایی از جمله آنتروپی تفاضلی از باندهای فرکانسی دلتا، تتا، آلفا، بتا و گاما استخراج شده، توسط یک الگوریتم ژنتیک^۹ (GA) و ویژگی های بهینه انتخاب شده اند. در نهایت این ویژگی ها توسط یک ماشین بردار پشتیبان (SVM) دسته بندی می شوند.

نتایج نشان می دهد که با استفاده از TCSP، دقت دسته بندی به طرز قابل ملاحظه ای افزایش یافته و به دقت ۸۴-۸۵،۷٪ نسبت به ۸۱،۷-۸۳،۲٪ بدون TCSP دست یافته است. در این مطالعه، ترکیب تمام باندهای فرکانسی بهترین عملکرد را ارائه داده است. مقایسه با روش های انتخاب ویژگی مبتنی بر همبستگی نیز عملکرد بهتر بهینه سازی TCSP پیشنهادی را نشان می دهد. تجزیه و تحلیل مناطق

⁶ Support Vector Machine

⁷ kernel

⁸ Task dependent Common Spatial Pattern

⁹ Genetic Algorithm

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

مختلف مغز نشان دهنده آن است که افزایش اطلاعات فضایی، عملکرد TCSP را افزایش می دهد و باند گاما بیشترین تمایز را فراهم کرده که با ارتباط آن با افسردگی سازگار است.

به طور خلاصه، مطالعه مذکور به ارائه یک روش دسته بندی افسردگی مبتنی بر EEG با استفاده از TCSP برای بهینه سازی اطلاعات فضایی می پردازد. TCSP با انتخاب ویژگی GA و دسته بندی SVM به طرز قابل ملاحظه ای دقت را در مقایسه با روش های استاندارد افزایش می دهد. نتایج نشان می دهند که بهره گیری از ویژگی های فضایی EEG برای تمایز بیماران افسردگی از افراد سالم اهمیت دارد.

محققان [۴۴] یک مدل عمیق یادگیری ترکیبی که شبکه های عصبی کانولوشنی (CNN) و شبکه های عصبی کانولوشنی زمانی (TCN) را ترکیب کرده را معرفی کرده اند تا به طور مداوم امتیازات شدت افسردگی را از سیگنال های EEG پیش بینی کند. آن ها عملکرد مدل را با استفاده از مجموعه داده ای از ۱۱۹ شرکت کننده [۴۵] که پرسشنامه افسردگی بک (BDI) را تکمیل کرده [۴۶] و EEG آن ها در حالت های چشم باز و چشم بسته ثبت شده بود، ارزیابی کرده اند.

برای آماده سازی داده های EEG برای تجزیه و تحلیل، چند مرحله پیش پردازش شامل حذف پایه ها، فیلترینگ ناچ [۴۷]، فیلترینگ باند گذر، فیلتر باتروورث [۴۸] و استفاده از تحلیل مولفه های مستقل برای حذف اغتشاشات به کار رفته است. داده های EEG پیش پردازش شده به دنباله های با حالت های چشم باز و چشم بسته تقسیم شده، همچنین از رویکرد مبتنی بر ویژگی استفاده شده است و ۳۱ ویژگی از حوزه های مختلف (زمان، موجک، پیچیدگی و فرکانس) از هر کانال و بخش EEG استخراج گردیده است [۴۹ - ۵۲].

از نظر عملکرد، مدل با استفاده از EEG خام برای داده چشم باز، خطای میانگین مربعات^{۱۰} (MSE) ۵/۶۴ و خطای میانگین مطلق^{۱۱} (MAE) ۱/۷۳ را داشته است. برای داده چشم بسته، MSE و MAE به ترتیب برابر با ۹/۵۳ و ۲/۳۲ بودند. همچنین با استفاده از ویژگی های EEG، مدل، MSE برابر با ۱۰/۸۱ و MAE برابر با ۲/۴۱ را بدست آورده و عملکرد بهتری نسبت به روش های کلاسیک تحلیل رگرسیون مانند SVR، KNN و جنگل های تصادفی^{۱۲} داشته است.

۴. نتیجه گیری و پیشنهاد

با توجه به آنچه که از پژوهش های اخیر در زمینه تشخیص اختلال افسردگی عمده مورد بحث و بررسی قرار گرفت، می توان نتیجه گرفت که استفاده از سیگنال های حیاتی از جمله سیگنال EEG می تواند صحت و دقت تشخیص این بیماری را به میزان چشمگیری افزایش دهد. بنابراین، بهره گیری از مزایای سیگنال الکتروانسفالوگرام در کنار روش های متداول تشخیصی مانند بررسی بالینی و استفاده از پرسشنامه ها می تواند تشخیص نهایی را قابل اتکاتر کند. همچنین می توان از سیگنال های حیاتی دیگری (مانند ردیابی چشمی) نیز در کنار EEG برای افزایش صحت تشخیص استفاده کرد.

منابع

- [1] Dereymaeker, A., Pillay, K., Vervisch, J., Van Huffel, S., Naulaers, G., Jansen, K., & De Vos, M. (2017). An automated quiet sleep detection approach in preterm infants as a gateway to assess brain maturation. *International journal of neural systems*, 27(06), 1750023.
- [2] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adeli, H., & Subha, D. P. (2018). Automated EEG-based screening of depression using deep convolutional neural network. *Computer methods and programs in biomedicine*, 161, 103-113.
- [3] Ay, B., Yildirim, O., Talo, M., Baloglu, U. B., Aydin, G., Puthankattil, S. D., & Acharya, U. R. (2019). Automated depression detection using deep representation and sequence learning with EEG signals. *Journal of medical systems*, 43, 1-12.

¹⁰ Mean Squared Error

¹¹ Mean Absolute Error

¹² Random Forest

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [4] Direito, B., Teixeira, C. A., Sales, F., Castelo-Branco, M., & Dourado, A. (2017). A realistic seizure prediction study based on multiclass SVM. *International journal of neural systems*, 27(03), 1750006.
- [5] Goudiaby, B., Othmani, A., & Nait-ali, A. (2020). Eeg biometrics for person verification. *Hidden Biometrics: When Biometric Security Meets Biomedical Engineering*, 45-69.
- [6] Mohammadzadeh, B., Khodabandelu, M., & Lotfizadeh, M. (2016). Comparing diagnosis of depression in depressed patients by eeg, based on two algorithms: Artificial nerve networks and neuro-fuzzy networks. *Epidemiology and Health System Journal*, 3(3), 246-258.
- [7] Sun, B., Zhang, Y., He, J., Yu, L., Xu, Q., Li, D., & Wang, Z. (2017, October). A random forest regression method with selected-text feature for depression assessment. In *Proceedings of the 7th annual workshop on Audio/Visual emotion challenge* (pp. 61-68).
- [8] Beck, A. T., Steer, R. A., & Carbin, M. G. (1988). Psychometric properties of the Beck Depression Inventory: Twenty-five years of evaluation. *Clinical psychology review*, 8(1), 77-100.
- [9] Geier, C., & Lehnertz, K. (2017). Which brain regions are important for seizure dynamics in epileptic networks? Influence of link identification and EEG recording montage on node centralities. *International Journal of Neural Systems*, 27(01), 1650033.
- [10] Cai, H., Qu, Z., Li, Z., Zhang, Y., Hu, X., & Hu, B. (2020). Feature-level fusion approaches based on multimodal EEG data for depression recognition. *Information Fusion*, 59, 127-138.
- [11] Cai, H., Sha, X., Han, X., Wei, S., & Hu, B. (2016, December). Pervasive EEG diagnosis of depression using Deep Belief Network with three-electrodes EEG collector. In *2016 IEEE international conference on bioinformatics and biomedicine (BIBM)* (pp. 1239-1246). IEEE.
- [12] Cai, H., Yuan, Z., Gao, Y., Sun, S., Li, N., Tian, F., ... & Hu, B. (2022). A multi-modal open dataset for mental-disorder analysis. *Scientific Data*, 9(1), 178.
- [13] Cogan, D., Birjandtalab, J., Nourani, M., Harvey, J., & Nagaraddi, V. (2017). Multi-biosignal analysis for epileptic seizure monitoring. *International journal of neural systems*, 27(01), 1650031.
- [14] Hecht, D. (2010). Depression and the hyperactive right-hemisphere. *Neuroscience research*, 68(2), 77-87.
- [15] Kingma, D. P., & Ba, J. (2015). Adam: A Method for Stochastic Optimization. international conference on learning representations (2015). *San Diego, California*.
- [16] Subha, D. P., Joseph, P. K., Acharya U. R., & Lim, C. M. (2010). EEG signal analysis: a survey. *Journal of medical systems*, 34, 195-212.
- [17] Khan, S. (2008). Ethem Alpaydin. Introduction to Machine Learning (Adaptive Computation and Machine Learning Series). The MIT Press, 2004. ISBN: 0 262 01211 1 Price£ 32.95/\$50.00 (hardcover). xxx+ 415 pages. *Natural Language Engineering*, 14(1), 133-137.
- [18] Morabito, F. C., Campolo, M., Labate, D., Morabito, G., Bonanno, L., Bramanti, A., ... & Bramanti, P. (2015). A longitudinal EEG study of Alzheimer's disease progression based on a complex network approach. *International journal of neural systems*, 25(02), 1550005.
- [19] Morabito, F. C., Campolo, M., Mammone, N., Versaci, M., Franceschetti, S., Tagliavini, F., ... & Aguglia, U. (2017). Deep learning representation from electroencephalography of early-stage Creutzfeldt-Jakob disease and features for differentiation from rapidly progressive dementia. *International journal of neural systems*, 27(02), 1650039.
- [20] Hamilton, M. (1960). The Hamilton Depression Scale—accelerator or break on antidepressant drug discovery. *Psychiatry*, 23(1), 56-62.
- [21] Hosseini, B., Moradi, M. H., & Rostami, R. (2013). Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal. *Computer methods and programs in biomedicine*, 109(3), 339-345.
- [22] Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification.
- [23] Henriques, J. B., & Davidson, R. J. (1991). Left frontal hypoactivation in depression. *Journal of abnormal psychology*, 100(4), 535.
- [24] Bruder, J. C., Dümpelmann, M., Piza, D. L., Mader, M., Schulze-Bonhage, A., & Jacobs-Le Van, J. (2017). Physiological ripples associated with sleep spindles differ in waveform morphology from epileptic ripples. *International journal of neural systems*, 27(07), 1750011.
- [25] Nandrino, J. L., Pezard, L., Martinerie, J., El Massioui, F., Renault, B., Jouvent, R., ... & Widlöcher, D. (1994). Decrease of complexity in EEG as a symptom of depression. *Neuroreport*, 5(4), 528-530.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [26] Mumtaz, W., Ali, S. S. A., Yasin, M. A. M., & Malik, A. S. (2018). A machine learning framework involving EEG-based functional connectivity to diagnose major depressive disorder (MDD). *Medical & biological engineering & computing*, 56, 233-246.
- [27] Guo, L., Wang, Z., Cabrerizo, M., & Adjouadi, M. (2017). A cross-correlated delay shift supervised learning method for spiking neurons with application to interictal spike detection in epilepsy. *International Journal of Neural Systems*, 27(03), 1750002.
- [28] Pezard, L., Nandrino, J. L., Renault, B., El Massioui, F., Allilaire, J. F., Müller, J., ... & Martinerie, J. (1996). Depression as a dynamical disease. *Biological Psychiatry*, 39(12), 991-999.
- [29] Saeedi, A., Saeedi, M., Maghsoudi, A. et al. Major depressive disorder diagnosis based on effective connectivity in EEG signals: a convolutional neural network and long short-term memory approach. *Cogn Neurodyn* 15, 239–252 (2021). <https://doi.org/10.1007/s11571-020-09619-0>
- [30] Ksibi, A., Zakariah, M., Menzli, L. J., Saidani, O., Almuqren, L., & Hanafieh, R. A. M. (2023). Electroencephalography-Based Depression Detection Using Multiple Machine Learning Techniques. *Diagnostics*, 13(10), 1779.
- [31] Astolfi, L., Cincotti, F., Mattia, D., Marciani, M. G., Baccala, L. A., de Vico Fallani, F., ... & Babiloni, F. (2007). Comparison of different cortical connectivity estimators for high-resolution EEG recordings. *Human brain mapping*, 28(2), 143-157.
- [32] Marinazzo, D., Liao, W., Chen, H., & Stramaglia, S. (2011). Nonlinear connectivity by Granger causality. *Neuroimage*, 58(2), 330-338.
- [33] Uyulan, C., Ergüzel, T. T., Unubol, H., Cebi, M., Sayar, G. H., Nezhad Asad, M., & Tarhan, N. (2021). Major depressive disorder classification based on different convolutional neural network models: Deep learning approach. *Clinical EEG and neuroscience*, 52(1), 38-51.
- [34] Zhu, G., Li, Y., Wen, P. P., & Wang, S. (2014). Analysis of alcoholic EEG signals based on horizontal visibility graph entropy. *Brain informatics*, 1(1), 19-25.
- [35] Zhang, Y., Wang, K., Wei, Y., Guo, X., Wen, J., & Luo, Y. (2022). Minimal EEG channel selection for depression detection with connectivity features during sleep. *Computers in Biology and Medicine*, 147, 105690.
- [36] Zhu, G., Li, Y., & Wen, P. (2014). Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal. *IEEE journal of biomedical and health informatics*, 18(6), 1813-1821.
- [37] Yuanyuan, S., Yongming, W., Lili, G., Zhongsong, M., & Shan, J. (2017, October). The comparison of optimizing SVM by GA and grid search. In 2017 13th IEEE International Conference on Electronic Measurement & Instruments (ICEMI) (pp. 354-360). IEEE.
- [38] Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification.
- [39] Li, Y., Hu, B., Zheng, X., & Li, X. (2018). EEG-based mild depressive detection using differential evolution. *IEEE Access*, 7, 7814-7822.
- [40] Price, K., Storn, R. M., & Lampinen, J. A. (2006). *Differential evolution: a practical approach to global optimization*. Springer Science & Business Media.
- [41] Hjorth, B. (1975). Time domain descriptors and their relation to a particular model for generation of EEG activity. *CEAN-Computerized EEG analysis*, 3-8.
- [42] Jiang, C., Li, Y., Tang, Y., & Guan, C. (2021). Enhancing EEG-based classification of depression patients using spatial information. *IEEE transactions on neural systems and rehabilitation engineering*, 29, 566-575.
- [43] Qian, K., Kuromiya, H., Zhang, Z., Kim, J., Nakamura, T., Yoshiuchi, K., ... & Yamamoto, Y. (2019, July). Teaching machines to know your depressive state: On physical activity in health and major depressive disorder. In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 3592-3595). IEEE.
- [44] Hashempour, S., Boostani, R., Mohammadi, M., & Sanei, S. (2022). Continuous scoring of depression from EEG signals via a hybrid of convolutional neural networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 176-183.
- [45] Cavanagh, J. F., Napolitano, A., Wu, C., & Mueen, A. (2017). The patient repository for EEG data+ computational tools (PRED+ CT). *Frontiers in neuroinformatics*, 11, 67.
- [46] Wang, Y. P., & Gorenstein, C. (2013). Psychometric properties of the Beck Depression Inventory-II: a comprehensive review. *Brazilian Journal of Psychiatry*, 35, 416-431.
- [47] Zając, B., & Paszkiel, S. (2020). Using brain-computer interface technology as a controller in video games. *Infarmatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska*, 10(3), 26-31.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

- [48] Kamenov, K., Caballero, F. F., Miret, M., Leonardi, M., Sainio, P., Tobiasz-Adamczyk, B., ... & Cabello, M. (2016). Which are the most burdensome functioning areas in depression? A cross-national study. *Frontiers in psychology*, 7, 1342.
- [49] Ding, X., Yue, X., Zheng, R., Bi, C., Li, D., & Yao, G. (2019). Classifying major depression patients and healthy controls using EEG, eye tracking and galvanic skin response data. *Journal of affective Disorders*, 251, 156-161.
- [50] Jiang, D., Lu, Y. N., Yu, M. A., & Yuanyuan, W. A. N. G. (2019). Robust sleep stage classification with single-channel EEG signals using multimodal decomposition and HMM-based refinement. *Expert Systems with Applications*, 121, 188-203.
- [51] D. Jiang, Y. Ma, and Y. Wang, "A robust two-stage sleep spindle detection approach using single-channel EEG," *J. Neural Eng.*, vol. 18, no. 2, Apr. 2021, Art. no. 026026.
- [52] Pandey, P., & Seeja, K. R. (2019). Subject-independent emotion detection from EEG signals using deep neural network. In *International Conference on Innovative Computing and Communications: Proceedings of ICICC 2018, Volume 2* (pp. 41-46). Springer Singapore.