

تشخیص ناهنجاری‌های اتصالات مغزی افراد بیش‌فعال با استفاده از شبکه عصبی سلولار

الهام عسکری^{۱*}، سارا معتمد^۲

^۱ گروه کامپیوتر، واحد فومن و شفت، دانشگاه آزاد اسلامی، فومن، ایران

*الهام عسکری، دریافت: ۰۲/۰۸/۱۰، بازنگری: ۰۲/۱۲/۰۸، پذیرش: ۰۲/۱۲/۲۶

چکیده

یکی از بیماری‌های شاخص نورولوژیک، اختلال کم‌توجهی بیش‌فعالی است که ناهنجاری‌هایی در قسمت‌های مختلف مغز و نوار مغزی آن‌ها دیده می‌شود. با پردازش سیگنال الکتروانسفالوگرافی این افراد می‌توان به صورت دقیق به تشخیص این بیماری پرداخت. در این مقاله به مدل‌سازی مغز افراد مبتلا به بیش‌فعالی با استفاده از شبکه عصبی سلولار در جهت تشخیص این بیماری پرداخته خواهد شد. ابتدا اتصالات درون ناحیه‌ای مغز افراد بیش‌فعال با استفاده از تابع همدوسی طیفی بین کانال‌ها محاسبه خواهد شد سپس اتصالات برون ناحیه‌ای با استفاده از شبکه عصبی سلولار به دست آورده می‌شود. نتایج به دست آمده نشان می‌دهد که اتصالات درون و برون ناحیه‌ای قسمت مرکزی مغز افراد بیش‌فعال با افراد نرمال متفاوت است همچنین تفاوت‌هایی در قسمت‌های پیشانی و آهیانه‌ای نیز مشاهده شده است. می‌توان نتیجه گرفت که وجود تفاوت‌های موجود در اتصالات درون و برون ناحیه‌ای مغز افراد بیش‌فعال نسبت به افراد نرمال باعث شده است که عملکرد مغز این دو گروه با یکدیگر متفاوت باشد.

کلمات کلیدی: بیش‌فعالی، شبکه عصبی سلولار، الکتروانسفالوگرافی، همدوسی طیفی.

۱- مقدمه

سن بهتر می‌شود ولی ممکن است در بزرگسالی هم ادامه پیدا کند در این صورت معمولاً بیش‌فعالی کم می‌شود ولی رفتارهای تکانشی، ضعف تمرکز و ریسک‌پذیری ممکن است بدتر شود. این مسائل ممکن است با یادگیری، کار و نحوه ارتباط فرد با دیگران تداخل پیدا کنند [۳ و ۴]. نظر به اهمیت موضوع، پژوهشگران بسیاری در علوم مهندسی در جهت شناسایی و تشخیص انواع بیماری‌های ذهنی و مغزی به کمک یادگیری ماشین و پردازش سیگنال‌های مغزی فعالیت داشته‌اند.

شواهدی وجود دارد که نشان می‌دهند تفاوت‌هایی در ساختار مغز و سیگنال‌های الکتروانسفالوگرافی این افراد با سایرین وجود دارد ولی عوامل محیطی در زندگی فرد

اختلال کم‌توجهی یا بیش‌فعالی^۱، یک اختلال رفتاری است که معمولاً فرد توانایی دقت و تمرکز بر روی یک موضوع را نداشته، یادگیری در او کند است و فرد از فعالیت بدنی غیرمعمول و بسیار بالا برخوردار است. این اختلال با فقدان توجه، فعالیت بیش‌ازحد، رفتارهای تکانشی یا ترکیبی از این موارد همراه است. اختلال بیش‌فعالی همیشه از دوران کودکی آغاز می‌شود اما در برخی از موارد ممکن است تا دوران بزرگسالی تشخیص داده نشود. روانشناسان بر اساس معیار استاندارد تشخیصی آمریکا^۲، این اختلال را شناسایی می‌کنند [۱ و ۲]. این اختلال با افزایش

* نویسنده مکاتبه کننده: الهام عسکری askary.elham@gmail.com

² Attention Deficit Hyperactivity Disorder (ADHD)

³ Diagnostic and Statistical Manual of Mental Disorders, Fourth Edition, Text Revision (DSM-IV-TR)

ماشین بردار پشتیبانی³ یکی از بهترین انتخاب‌ها برای بالا بردن دقت در شناسایی بیش‌فعالی است [۱۸]. ایچی کاوا و همکاران و زو و همکاران از دسته‌بندی SVM برای طبقه‌بندی بیش‌فعالی استفاده کرده‌اند [۱۹ و ۲۰]. یاسومورا و همکاران با استفاده از SVM بر روی فعالیت و تشخیص بیش‌فعالی در قسمت پیش پیشانی مغز پرداختند. آن‌ها میزان تفکیک‌پذیری کلی ۸۶/۲۶٪ را گزارش نمودند [۲۱].

متسیس و همکاران در سال ۲۰۱۴، از یک روش انتخاب ویژگی جدید مبتنی بر ساختار پراکندگی^۴ برای شناسایی هیبریداسیون ژنومی مقایسه‌ای آرایه‌ای^۵ استفاده کرد که می‌توانست در طبقه‌بندی زیرگروه‌های مختلف بیماری کمک کند. روش انتخاب ویژگی مبتنی بر اسپارس از سایر رویکردها بهتر پاسخ داد [۲۲]. در روش‌های بسیاری از کارایی بالای نظم دهی اسپارس در جهت کاهش ابعاد و انتخاب ویژگی استفاده شده است. در واقع در مدل رگرسیون یا SVM برای انجام انتخاب ویژگی با کوچک کردن ضرایب بی‌ربط، آن ویژگی‌ها به صفر می‌رسد [۲۳ و ۲۴].

در مطالعه‌ای از ۶۱ پسر مبتلا به اختلال بیش‌فعالی-نقص توجه و ۴۳ کودک عادی که به لحاظ سن و هوش با یکدیگر هم‌تصادف بودند استفاده شد و الکتروانسفالوگرافی آن‌ها در حالت چشم‌بسته مورد ارزیابی قرار گرفت. آن‌ها به این نتیجه رسیدند که نسبت تنا به بتا در همه زیرگروه‌های اختلال بیش‌فعالی-نقص توجه به‌ویژه زیرگروه نقص توجه در مقایسه با کودکان عادی بالاتر بود. به علاوه در زیرگروه نقص توجه، فعالیت تنا بالاتر و فعالیت بتا پایین‌تر بود. هیچ تفاوت معناداری بین گروه‌ها در فعالیت دلتا و آلفا مشاهده نشد [۲۵].

در آزمایشی نتایج الکتروانسفالوگرافی-کمی^۶ با نتایج آزمون ایوا^۷ در کودکان دارای اختلال نقص توجه و بیش‌فعالی مورد بررسی قرار گرفت. بر اساس آزمون IVA این کودکان به سه گروه بیش‌فعال، بی‌توجه و ترکیبی دسته‌بندی شدند. داده‌ها از طریق تحلیل واریانس چندگانه و آزمون تحلیل تشخیصی مورد تجزیه و تحلیل قرار گرفت. نتایج نشان داد که بین نتایج الگوی مغزی در QEEG و انواع ADHD مشخص شده در آزمون IVA رابطه مثبت وجود دارد. نتایج حاصله بیانگر تفاوت معنادار در توان نسبی امواج مغزی تنا در کودکان دارای اختلال نقص توجه - بیش‌فعالی از نوع تکانشی است. به این صورت که موج مغزی تنا در نقطه O2 در سه گروه باهم متفاوت است [۲۶].

محمدی و همکاران، رویکردی را معرفی کردند تا کودکان ADHD را از بچه‌های سالم با استفاده از سیگنال‌های EEG، هنگام صورت گرفتن یک وظیفه معین تشخیص دهند. آن‌ها کودکان را تحت اختلال‌های عصب‌شناسی هنگام انجام دادن فعالیت باهم مقایسه کردند تا رفتارها و توجه‌های آن‌ها شبیه‌سازی شوند. ابعاد فراکتال، آنتروپی تقریبی و نمای لیاپونوف از سیگنال‌های EEG به‌عنوان ویژگی‌های غیرخطی استخراج شدند. به‌منظور بهبود در نتایج طبقه‌بندی، روش‌های مربوط متقارن جفت ورودی^۸ و حداقل مربوط حداکثر فراوانی^۹ برای انتخاب بهترین ویژگی‌ها به‌عنوان ورودی شبکه عصبی پرسپترون چندلایه‌ای مورد استفاده قرار گرفتند. نتایج آنان نشان داد که کودکان با ADHD در انجام وظایف مشخص و شناخته‌شده تاخیرات بیشتر و دقت کمتری داشتند؛ بنابراین، ویژگی‌های استخراج شده غیرخطی نشان داد که شاخص‌های غیرخطی در قسمت‌های مختلف مغز کودکان ADHD در مقایسه با کودکان سالم بزرگ‌تر است. در نهایت اینکه آن‌ها با این روش، به‌دقت ۹۲/۲۸ درصد و ۹۳/۶۵ درصد به ترتیب با استفاده از روش gmRMR و روش DISR با استفاده از پرسپترون چندلایه^{۱۰} دست‌یافت‌اند [۲۷].

مقدم و همکاران در سال ۲۰۲۲ از استخراج فراکتالیته EEG در جهت تشخیص ADHD گام برداشتند. آن‌ها با استفاده از الگوریتم رنگ‌آمیزی گراف، شبکه‌های اتصال (به‌عنوان مناطق متصل عملکردی) مغز و فرکتالیته EEG نشان دادند که بین

نیز ممکن است باعث بروز اختلال بیشتر شود؛ بنابراین یقیناً به کمک علوم مهندسی کامپیوتر و هوش مصنوعی می‌توان درصدد ارائه روش‌های هوشمند و کارا در جهت شناسایی و درمان این بیماری‌ها برآمد. با استفاده از روش‌های کارا مانند نظم دهی اسپارس، می‌توان ابتدا ویژگی‌های مؤثر را که باعث دقت بیشتر در عمل غربالگری می‌شوند را انتخاب کرد و کاهش بعد داد. انتخاب ویژگی‌ها یک قسمت مهم از فرآیند طبقه‌بندی است چون بسیاری از ویژگی‌های بیولوژیکی، مربوط به بیماری‌ها نیستند و باعث طبقه‌بندی اشتباه می‌شوند. در نهایت، با استفاده از روش‌های یادگیری ماشین، می‌توان ویژگی‌های مهم مستخرج از داده‌ها را مورد آنالیز و بررسی قرارداد [۵].

الکتروانسفالوگرافی^۱، یکی از ابزارهای مهم در شناسایی اختلالات نروفیزیولوژیک است. مغز فعالیت‌های خود را با سیگنال‌های مغزی اطلاع می‌دهد. می‌توان با پردازش‌های دقیق کامپیوتری آن‌ها، برخی اطلاعات را استخراج و با مقایسه این پردازش‌ها، اختلالات روانی را با درجه صحت بالا تشخیص داد. پس از تجویز روند درمانی هم می‌توان با مطالعه منظم فعالیت مغزی بیمار، از درصد پیشرفت درمان و روند بهبود بیمار مطلع شد [۶].

مولر و همکاران، یک سیستم یادگیری ماشینی را ارائه دادند که از دسته‌بندی ماشین بردار پشتیبان برای تفکیک بزرگ‌سالان بیش‌فعال از گروه‌های سالم استفاده می‌نمود. بر اساس اندازه‌گیری ویژگی پتانسیل‌های مربوط به رویداد که از EEG تولید می‌شود، طبقه‌بندی انجام می‌شد [۷ و ۸].

فن‌های تصویربرداری رزونانس مغناطیسی عملکردی^۲ به‌طور گسترده‌ای در تجزیه و تحلیل کمی مغز در افراد سالم و بیماران مبتلا به اختلالات روان‌پزشکی به‌منظور افزایش درک ما از شبکه‌های عملکردی مغز انسان مورد استفاده قرار می‌گیرند. روش‌های طبقه‌بندی بسیاری برای تشخیص بیش‌فعالی با داده‌های fMRI ارائه شده است [۹ و ۱۰]. در مطالعات عصبی-عملکردی با استفاده از fMRI که در حال استراحت ثبت شده بود تغییرات اتصالات عملکردی بین مناطق مغزی در افراد بیش‌فعال را نشان داده است [۱۱ و ۱۲]. یا او و همکاران با استفاده از fMRI روشی برای جداسازی افراد مبتلا به بیش‌فعالی و افراد سالم ارائه دادند [۱۲]. ویژگی‌های داده‌های fMRI، دارای بعد بالا است بنابراین یک روش کارآمد که قادر به کاهش ابعاد ویژگی اصلی در یک فضای فرعی بسیار تصفیه شده باشد بسیار مطلوب است. آن‌ها یک روش جدید انتخاب ویژگی را بر اساس اهمیت نسبی و یادگیری ارائه دادند. در مقایسه با روش‌های انتخاب ویژگی سنتی، الگوریتم آن‌ها طبقه‌بندی بیش‌فعالی را در طبقه‌بندی کودکان و بزرگ‌سالان در حدود ۱۵٪ بهبود بخشید و به‌دقت ۸۶/۱۸ دست‌یافت. به‌علاوه، این روش نشان داد که عمدتاً در نواحی گیجگاهی، پیشانی و مخچه در هر دو گروه افراد بیش‌فعال کودک و بزرگ‌سال تفاوت‌هایی وجود دارد [۱۳ و ۱۴].

چاندانا و همکاران در طرحی پیشنهادی به بررسی قسمت‌های مختلف مغز در افراد مبتلا به بیش‌فعالی پرداختند. آن‌ها در این طرح تفاوت‌های احتمالی که نواحی مغز افراد بیش‌فعال و افراد سالم دارند را در حالت‌های چشم‌بسته و باز بررسی نمودند. ابزار مورد استفاده آن‌ها شبکه‌های عصبی بود. آن‌ها از ویژگی آنرژي در باندهای آلفا، بتا، گاما و تتا بهره بردند [۱۵].

موریگوچی و هیراکی از طیف‌سنجی مادون قرمز نزدیک برای اندازه‌گیری پروکسی برخی از ویژگی‌های عملکرد مغز در افراد مبتلا به بیش‌فعالی استفاده کردند [۱۶] و برخی مطالعات نقش مهار کنترل در بیش‌فعالی را مورد بررسی قرار دادند. آنان بیان کردند که طیف‌سنجی مادون قرمز نزدیک، می‌تواند برای اندازه‌گیری جریان خون مغز استفاده شود [۱۷].

⁶ Quantitative Electroencephalography

⁷ Integrated Visual and Auditory (IVA)

⁸ Double Input Symmetrical Relevance (DISR)

⁹ Minimal Redundancy Maximal Relevance (mRMR)

¹⁰ Multi Layer Perceptron (MLP)

¹ Electroencephalography (EEG)

² Functional Magnetic Resonance Imaging (fMRI)

³ Support Vector Machine (SVM)

⁴ sparsity

⁵ Array Comparative Genomic Hybridization (aCGH)

مدل‌سازی مغز که پیچیده‌ترین عضو بدن است همواره یکی از چالش‌های علم به حساب می‌آید. در صورتی که بتوان آن را به اجزای ساده‌تر تبدیل نمود می‌توان در جهت مدل‌سازی آن برآمد. مغز و نواحی مختلف آن از اتصالات و الگوهای خاصی در حالت نرمال برخوردار است و در صورت وجود بیماری‌های نورولوژیک در این اتصالات، ناهنجاری‌هایی به وجود می‌آید. از دیگر چالش‌هایی که در تشخیص و درمان ADHD به چشم می‌خورد کم‌توجهی و عدم پرداختن کافی محققین علم مهندسی کامپیوتر و مهندسی پزشکی به این موضوع است.

کلیه روش‌های ارائه‌شده مبتنی بر اتصالات مغزی افراد بیش‌فعال، ابتدا به صورت آماری و بدون ارائه یک مدل کاربردی، اتصالات مغزی را به دست آورده‌اند و سپس به جداسازی دو گروه پرداخته‌اند اما در این مقاله، با استفاده از مدلی هوشمند به بررسی و تشخیص میزان ناهنجاری‌ها و تفاوت‌های اتصالات مغزی افراد ADHD پرداخته‌شده است به طوری که مدل ارائه‌شده عملکردی مشابه مغز دارد. کلیه نواحی مغز، به صورت سراسری و ناحیه‌ای بر یکدیگر برهمکنش دارد. مدل ارائه‌شده نیز طوری طراحی شده است که ابتدا اتصالات برون‌ناحیه‌ای محاسبه می‌شود سپس در حین انجام محاسبه اتصالات درون‌ناحیه‌ای، میزان تأثیر دیگر نواحی بر آن ناحیه نیز در نظر گرفته شده و در محاسبات دخیل است. مقادیر اتصالات به دست آمده علاوه بر اینکه ناهنجاری‌های هر ناحیه را نشان می‌دهد می‌تواند در جهت تفکیک کارای دو گروه با استفاده از یک کلاس بند مناسب مانند شبکه عصبی کانولوشنی نیز استفاده شود؛ بنابراین در این مقاله پس از بررسی تعداد کافی سیگنال‌های الکتروانسفالوگرافی، مدلی با استفاده از یادگیری ماشین سلولار برای الگوی مغزی کودکان بیش‌فعال و نرمال پیدا خواهد شد. همچنین نحوه سازمان‌دهی و اتصالات نواحی دو گروه و تفاوت آن‌ها نشان داده می‌شود. همان‌گونه که در مغز، سلول‌ها در یک فرآیند نسبت به الگوهای ورودی منظم می‌شوند در این مقاله نیز به کمک ویژگی‌های مناسب مستخرج از سیگنال‌های EEG و شبکه‌های عصبی، این الگو برای افراد بیش‌فعال و سالم استخراج و به دست آورده خواهد شد. محل واحدهای تنظیم‌شده در شبکه‌های عصبی به گونه‌ای نظم می‌یابد که برای ویژگی‌های ورودی، یک دستگاه مختصات معنی‌دار روی شبکه ایجاد شود لذا یک نقشه توپوگرافی از الگوهای ورودی تشکیل می‌شود. این مدل قادر به ارائه کارکرد کلی و جزئی مغز است و توانایی ارائه تفاوت‌های اتصالات مغزی افراد مبتلا به بیش‌فعالی را داراست. این مقاله بدین صورت سازمان‌دهی شده است که پس از بیان مقدمه، در بخش دوم، روش پیشنهادی ارائه می‌شود. در بخش سوم به تحلیل نتایج و در بخش چهارم نتیجه‌گیری بیان خواهد شد.

۲- مواد و روش‌ها

مدل پیشنهادی بر اساس معماری و کارکرد مغز طراحی شده و شامل سه فاز اصلی است:

در فاز اول، بر روی سیگنال‌ها می‌بایست عمل پیش‌پردازش و آماده‌سازی انجام شود. قطعات مناسب و بدون نویز که در این طرح ۳ دقیقه برای هر فرد در نظر گرفته شده انتخاب می‌شود و سپس عمل نرمال‌سازی و فیلترینگ انجام می‌شود. در فاز دوم، طراحی مدل پیشنهادی انجام می‌شود و در فاز سوم نتایج به دست آمده تحلیل خواهد شد. فلوجارت مراحل روش پیشنهادی در فازهای مختلف به صورت تصویر (۱) است. در ادامه کلیه مراحل به تفصیل بیان خواهد شد.

لوب فرونتال و پس‌سری در کودکان ADHD قطعی وجود دارد که نقص لوب قدامی را در کودکان ADHD تأیید می‌کند [۲۸].

هی و همکاران در سال ۲۰۲۲ در مطالعه‌ای از مدل شبکه عصبی کانولوشنی حافظه کوتاه‌مدت^۱ برای پردازش داده‌های EEG منبع باز برای دستیابی به طبقه‌بندی با دقت بالا استفاده نمودند. این مدل همچنین برای تجسم ویژگی‌هایی که بیشترین کمک را داشتند و تولید داده‌های گرادیان ویژگی با دقت بالا استفاده شد. نتایج آن‌ها نشان داد که پردازش سنتی داده‌های اصلی با داده‌های گرادیان متفاوت است و دومی قابل‌اعتمادتر است. قوی‌ترین اتصالات در بیماران ADHD کوتاه برد بود در حالی که گروه سالم ارتباطات دوربرد بین لوب اکسیپیتال و نواحی گیجگاهی قدامی چپ داشتند [۲۹].

هلکر و همکاران در سال ۲۰۲۲، چارچوبی را پیشنهاد کردند که از ویژگی‌های الکتروانسفالوگرافی کمی برای تشخیص ADHD در کودکان استفاده می‌کند. از سیگنال EEG ۱۹ کانالی برای استخراج ویژگی‌های طیفی، دامنه و اتصال عملکردی در پنج باند فرکانسی برای تشخیص کودکان ADHD استفاده نمود. چهار روش انتخاب ویژگی آنوا^۲، مربع چی^۳، شاخص گینی^۴ و اطلاعات گین^۵ برای رتبه‌بندی ویژگی‌های QEEG بر اساس اهمیت نسبی آن‌ها برای کار طبقه‌بندی استفاده کرد و نشان داد که بالاترین دقت ۸۱/۸۲٪ با طبقه‌بندی کننده جنگل تصادفی به دست می‌آید، در حالی که طبقه‌بندی کننده‌های k نزدیک‌ترین همسایه^۶، SVM و شبکه عصبی مصنوعی^۷ به ترتیب دقت ۷۸/۵۱٪، ۷۶/۸۶٪ و ۷۶/۹۳٪ را نشان دادند [۳۰]. در مطالعه‌ای ونگ و همکاران در سال ۲۰۲۲، یک مدل CNN-LSTM را برای حل مشکلات طبقه‌بندی ADHD و کودکان سالم بر اساس مجموعه داده‌های الکتروانسفالوگرافی عمومی که شامل پتانسیل مرتبط با رویداد^۸ است پیشنهاد کردند. روش‌های تجسم پیچیدگی و نقشه برجسته برای مشاهده ویژگی‌هایی که به طور خودکار توسط مدل پیشنهادی استخراج می‌شوند استفاده شد. نتایج نشان داد که مدل CNN-LSTM می‌تواند به دقت ۹۸.۲۳ درصد در روش اعتبارسنجی متقابل پنج برابری دست یابد که به طور قابل توجهی بهتر از مدل‌های پیشرفته شبکه عصبی کانولوشنی فعلی بود [۳۱].

معمد و همکاران در سال ۲۰۲۲، در تحقیقی به جداسازی افراد سالم و مبتلا به بیش‌فعالی با استفاده از ویژگی‌های تبدیل فوریه سریع^۹ و کاهش ویژگی تحلیل مؤلفه‌های اصلی^{۱۰} پرداختند. آن‌ها برای تفکیک دو گروه از شبکه عصبی کانولوشنی استفاده کردند و توانستند به دقت ۹۱٪ دست یابند [۳۲].

بیماری بیش‌فعالی متأسفانه از جمله بیماری‌هایی است که درمان قطعی دارویی برای آن وجود ندارد و داروهای مورد استفاده هم فقط برای کاهش علائم آن کاربرد دارند بنابراین باید پس از تشخیص این بیماری در جهت کمک به رفع آن اقدام کرد. متأسفانه تعداد افراد مبتلا به بیش‌فعالی روزبه‌روز در حال افزایش است؛ بنابراین تمامی متخصصین در این امر معتقدند که تشخیص زودهنگام و شروع درمان در سنین کم بهترین نتایج را دربر خواهند داشت و کمک شایانی به آن‌ها خواهد کرد. اگر فرد هر چه زودتر در برنامه درمانی قرار گیرد زودتر هم به سطح رفتارهای عادی خواهد رسید. همچنین افراد متخصصی که بر روی افراد بیش‌فعالی سال‌ها کار کرده‌اند معتقدند هر چه برنامه درمانی منظم‌تر و دارای ساختار دقیق‌تری باشد می‌توان نتایج بهتری را به دست آورد. با توجه به مشکلات و اختلالات خاصی که در بیماران بیش‌فعالی مشاهده می‌شود یک برنامه درمانی مناسب باید این نیازها را برآورده کند که شامل رشد و بهبود رفتارهای اجتماعی فرد و رسیدن به تمرکز است [۴].

⁶ K-nearest neighbor(KNN)

⁷ Artificial Neural Network(ANN)

⁸ Event-Related Potential(ERP)

⁹ Fast Fourier Transform(FFT)

¹⁰ Principal component analysis(PCA)

¹ Convolutional Neural Network CNN Long Short-Term Memory Networks (CNN-LSTM)

² Anova

³ Chi-square

⁴ Gini Index

⁵ Information Gain

انرژی کل سیگنال گسسته $x(n)$ در فاصله زمانی $n_1 \leq n \leq n_2$ به صورت رابطه (۴) محاسبه می‌شود:

$$E(I) = \sum_{n=n_1}^{n_2} |X[n]|^2 \quad (4)$$

در این مقاله انرژی سیگنال به صورت زیر تعریف و محاسبه شده است [۶]:

$$E(I) = \sum_{i=1}^N d_i^2 \times T/N \quad (5)$$

به طوری که N تعداد نمونه‌های d_i سیگنال و T دوره تناوب است.

۲-۳-۲-۳ مدل پیشنهادی

در این مقاله مدلی با استفاده از شبکه عصبی سلولی مبتنی بر ساختار و کارکرد مغز ارائه خواهد شد. در این مدل برای مغز ۱۹ ناحیه که شامل نواحی نیمکره چپ و راست منظور می‌گردد. در هر ناحیه تعدادی الکتروود که هر الکتروود یک سلول غیرخطی است در نظر گرفته می‌شود؛ بنابراین کل مغز شامل ۱۹ سلول غیرخطی که در واقع ۱۹ الکتروود است. ورودی هر ناحیه، ورودی الکتروودهای مربوطه به اضافه فیدبک‌های نواحی غیرهمجوار و ورودی هر سلول، الکتروود مربوطه به اضافه فیدبک‌هایی که از سلول‌های مجاور می‌گیرد است. برای نمایش ناهنجاری‌ها و اتصالات سلولی نواحی مختلف مغز، ابتدا می‌بایست میزان ارتباط نواحی (الکتروودها) با یکدیگر را مشخص نمود که این کار با تابع همدوسی طیفی^۱ بین الکتروودها اندازه‌گیری می‌شود سپس اتصالات درون هر ناحیه با شبکه عصبی سلولی نشان داده خواهد شد. در زیر هر دو مرحله توضیح داده می‌شود.

۲-۳-۱-۲ همدوسی طیفی برای محاسبه اتصالات بین ناحیه‌ای

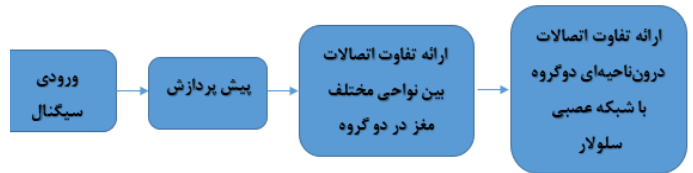
در مدل پیشنهادی برای محاسبه میزان تعامل بین کانال‌های مختلف از تابع همدوسی استفاده شده است. تجزیه و تحلیل‌های همدوسی یک روش غیرتهاجمی برای محاسبه درجه تزویج مابین کانال‌های مغزی است. در این محاسبه از میانگین پریودوگرام در هر دوره با همپوشانی و پنجره همینگ ۵۰ درصد برای کاهش اثر لبه‌ها استفاده شده است. اگر دو کانال $\xi(t)$ و $\eta(t)$ با طیف تقاطعی $P_{\eta\xi}(f)$ و طیف‌های خود متناظری $P_{\xi\xi}(f)$ و $P_{\eta\eta}(f)$ در نظر گرفته شود تابع همدوسی دو کانال در هر فرکانس با رابطه (۶) محاسبه می‌شود [۳۳]:

$$MSC(f) = \frac{|P_{\xi\eta}(f)|^2}{P_{\xi\xi}(f)P_{\eta\eta}(f)} \quad (6)$$

مقداری که از تابع فوق به دست می‌آید در محدوده صفر تا یک است که بر اساس فرکانس همدوسی دو سیگنال مربوط به دو کانال را نشان می‌دهد.

۲-۳-۲-۲ شبکه عصبی سلولار^۲ برای محاسبه اتصالات درون ناحیه‌ای

چون در شبکه عصبی سلولار یا به عبارتی CNN، برهم‌کنش‌های محلی و سراسری مابین سلول‌ها وجود دارد در مدل پیشنهادی از این ابزار استفاده می‌شود



شکل ۱- مدل سیستم پیشنهاددهنده

۲-۱-۲ پایگاه داده

پایگاه داده استفاده شده شامل سیگنال‌های EEG با پروتکل تشخیص کاراکترها در کارتون و شمردن تعداد کاراکترهاست. تعداد ۱۲۱ سیگنال ثبت شده که تعداد ۶۱ نفر از آن‌ها مبتلابه ADHD و ۶۰ نفر از آن‌ها نرمال تشخیص داده شده‌اند. برای ضبط از استاندارد ۱۰-۲۰ با ۲۱ الکتروود پوست سر و نرخ نمونه‌برداری ۱۲۸ هرتز استفاده شده است. الکتروودها شامل Cz, C3, T3, F8, Fz, F3, F7, Fp2, Fp1, C4, T5, T4, P3, P4, O1, O2, T6 و الکتروودهای مرجع A1 و A2 است. محدوده سنی افراد مبتلابه ADHD، ۷ تا ۱۲ سال است. پایگاه داده قابل دسترسی از سایت (<https://iee-dataport.org/open-access/eeg-data-adhd-control-children>) است.

۲-۲-۲-۲ پیش پردازش

از سیگنال‌های موجود، قطعات ۳ ثانیه‌ای (۱۵۰۰ نمونه) که هیچ‌گونه اغتشاشی از جمله اغتشاش‌های چشمی، حرکتی و الکترومایوگرام ندارد انتخاب می‌شود. از هر فرد ۵۰ قطعه ۳ ثانیه‌ای انتخاب گردیده است. مجموعاً ۱۸۰۰ قطعه از افراد بیش‌فعال و ۱۴۵۰ قطعه از افراد سالم به عنوان ورودی انتخاب شده است. به صورت نرم‌افزاری سیگنال‌ها در بازه ۰/۱ تا ۷۰ هرتز که ارزش مطالعه دارند و پزشکان در این فرکانس به بررسی عملکرد مغز می‌پردازند فیلتر شدند [۶].

۲-۲-۱-۲ تبدیل ویولت

سیگنال الکتروانسفالوگرافی به باندهای مختلف از تبدیل ویولت تجزیه می‌شود. با فیلتر کردن پی‌درپی سیگنال با فیلتر بالاگذر $H(n)$ و فیلتر پایین‌گذر $L(n)$ دامنه فرکانس برش داده می‌شود و به ضرایب A و D تجزیه خواهد شد. این عملیات تقریب مجموعه‌ای از ضرایب تقریبی را تولید می‌کند. رابطه (۱) تبدیل ویولت سیگنال پیوسته $x(t)$ در تابع Ψ ، با مقیاس a و پارامتر انتقال b را محاسبه می‌کند [۶].

$$CWT(a, b) = \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{|a|}} \Psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

تبدیل ویولت گسسته با استفاده از رابطه (۲)، محاسبه می‌شود.

$$DWT(a, b) = (1/\sqrt{|a|}) \sum_b x(t) \Psi_{a,b}(t) \quad (2)$$

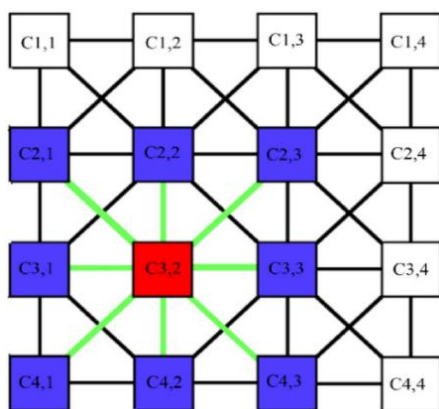
$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (3)$$

۲-۲-۲-۲ انرژی

² Cellular Neural Network(CNN)

¹ Spectral Coherence

سلولی 4×4 در نظر گرفته می‌شود. در هر ناحیه 4×4 اتصالات درون ناحیه‌ای هر ناحیه محاسبه خواهد شد.



تصویر ۲. سلول‌های در نظر گرفته شده در یک ناحیه

۳- بحث و نتایج آزمایش‌های

آزمایش‌های انجام شده برای شبیه‌سازی روش پیشنهادی با نرم‌افزار متلب نسخه R2022a انجام گردید. اعتبارسنجی روش پیشنهادی با استفاده از k -fold به صورتی که $k=10$ است انجام شد. در مرحله اول داده‌ها به $k-1$ دسته آموزش و یک دسته آزمایش تقسیم می‌شود. این نوع تقسیم ده بار انجام خواهد شد به طوری که برای همه دسته‌ها این عمل انجام می‌شود [۳۴]. برای نشان دادن تفکیک‌پذیر و معتبر بودن مقادیر به دست آمده از دو گروه از نرم‌افزار تحلیل آماری SPSS و آزمون آماری تی تست^۱ استفاده می‌شود [۲۳]. تی تست‌ها برای مشخص کردن تفاوت معنادار در میانگین به کار می‌روند. مقدار احتمال^۲، در آزمون t ، احتمال صحیح بودن و معنادار بودن پاسخ را نشان می‌دهد. هر چه مقدار احتمال کمتر و نزدیک‌تر به صفر باشد پاسخ صحیح‌تر است. معمولاً مقدار احتمال ۵ درصد برای کارهای تحقیقاتی به کار می‌رود که در این تحقیق مقدار $pvalue \leq 0.05$ در نظر گرفته شده است [۲۳ و ۵].

به طور کلی از ۱۹ ناحیه ثبت سیگنال انجام شده است. در مغز کلیه نواحی بر روی هم اثر می‌گذارند بنابراین در مدل پیشنهادی نیز هر ناحیه با نواحی دیگر ارتباط دارد بنابراین میزان همبستگی ۱۹ کانال با یکدیگر که 19×18 است می‌بایست محاسبه شود. به علت زیاد بودن ستون‌های این جدول تعدادی از این مقادیر به عنوان نمونه بیان می‌شود.

زیرا مغز نیز عملکردی این‌گونه دارد نواحی مختلف مغز با یکدیگر ارتباط دارند. ارتباطات هر ناحیه با دیگر نواحی با استفاده از تابع همدوسی محاسبه می‌شود. برای محاسبه اتصالات درون ناحیه‌ای از مدل شبکه عصبی سلولار استفاده شده است. ساختار شبکه عصبی سلولار به صورتی است که سلول‌های موجود در هر ناحیه بر یکدیگر برهم‌کنش داشته و از یکدیگر فیدبک دریافت می‌کنند [۵ و ۶]. حال با توجه به اینکه سلول‌های هر ناحیه در مغز، فیدبک از نواحی هم‌جوار و غیرهم‌جوار دریافت می‌کند می‌بایست مقدار ارتباطات نواحی با یکدیگر محاسبه می‌شد و به هر ناحیه اعمال می‌شد که این کار توسط تابع همدوسی طیفی انجام شده است و میزان تأثیر نواحی مختلف مغز بر یکدیگر محاسبه و اعمال شد. چون در این تحقیق از ۱۹ کانال برای ثبت سیگنال مغز استفاده شده است بنابراین ۱۹ ناحیه نیز در نظر گرفته خواهد شد که هر ناحیه شامل یک شبکه عصبی سلولار با ابعاد 4×4 است.

۱-۲-۳-۲-۱ CNN

در این مقاله مدلی با استفاده از CNN، مبتنی بر ساختار و کارکرد مغز ارائه خواهد شد. شبکه‌های عصبی سلولار، ورودی‌ها را در لحظه پردازش می‌کنند. این سیستم مشابه یک اتوماتای سلولی، تشکیل شده از توده‌های حجیمی از مدارهای فاصله‌دار کولن است که با همسایگان مداری خود به‌طور مستقیم مرتبط است. CNN، کاربردهای مهمی در زمینه‌های شناسایی الگو دارد. سلول‌ها به‌طور محلی با همسایگان خود در ارتباط هستند. بدین معنی که هر سلول شبکه عصبی با سلول‌های همسایه خود در ارتباط است [۶ و ۳۴]. سلول‌ها دارای ورودی، خروجی و حالت (استیت) هستند. در سلول‌ها، حالات و خروجی‌ها با تأثیر از همسایگانشان به دست می‌آیند.

هر یک از مربع‌های تصویر ۲ معرف یک سلول $C(i,j)$ است. i معرف سطر سلول‌ها و j بیان‌کننده ستون شبکه سلول‌ها است. کلیه سلول‌ها و نواحی با یکدیگر مرتبط‌اند. ورودی به هر یک از CNN ها اعمال می‌شود سپس وزن‌ها و حالت‌های سلول‌ها طبق معادلاتی که در زیر بیان می‌شود محاسبه می‌شود. در اینجا همسایگی $i=1$ ، برای $C(i,j)$ در یک شبکه عصبی سلولی برابر است با معادله

$$N_r(i,j) = \{C(k,l) \mid \max\{|k-i|, |l-j|\} \leq r, 1 \leq k \leq M\} \quad (7)$$

به طوری که r عدد صحیح مثبت است. سیستم همسایگی تعریف شده در بالا همواره در حال نمایش یک دسته خواص متقارن برای تمام $C(i,j)$ ها و $C(k,l)$ در یک شبکه عصبی سلولی است. (۶). u ورودی، x حالت و y خروجی سلول است. معادله حالت سلول به صورت معادله (۸) است.

$$\frac{dx_{ij}(t)}{dt} = -x_{ij}(t) + \sum_{(k,l) \in N(i,j)} A(i,j;k,l) \cdot y_{kl}(t) + \sum_{(k,l) \in N(i,j)} B(i,j;k,l) \cdot u_{kl}(t) + z(i,j;k,l) \quad (8)$$

g و I ایندکس‌های سلول‌های همسایه است. اثر بازخورد خروجی همیشه وابسته به پارامترهای تعاملی $A(i,j;k,l)$ و اثر کنترل ورودی وابسته به $B(i,j;k,l)$ و z بایاس است. خروجی سلول بر اساس معادله (۹) محاسبه می‌شود.

همان‌طور که بیان شد در مرحله اول با استفاده از تابع همدوسی میزان ارتباط بین نواحی مشخص می‌شود سپس در مرحله بعد به یافتن اتصالات درون ناحیه‌ای مغز افراد بیش‌فعال در مقایسه با افراد عادی پرداخته خواهد شد. در این مدل‌سازی از ۱۹ ناحیه مغز سیگنال ثبت شده است بنابراین ۱۹ ناحیه از مغز در نظر گرفته می‌شود تا اتصالات درون ناحیه‌ای هر ناحیه محاسبه گردد. در واقع ۱۹ شبکه عصبی

² $pvalue$

¹ T-test

ناحیه‌ای در هر جدول گزارش شود. در اینجا به‌عنوان نمونه استیتهای کانال C3 و Fp1 در جداول (۲ و ۳) ارائه شده است. مواردی که اختلاف معناداری در آن مشاهده شده با * مشخص شده است.

جدول ۱. میانگین مقدار اتصالات بین ناحیه‌ای برای بیش‌فعالان و افراد نرمال

جدول ۲. میانگین مقادیر استیتهای به‌دست‌آمده از کانال C3 برای بیش‌فعالان و

افراد نرمال

حالات	بیش‌فعال		نرمال	
	انحراف معیار ±	میانگین	انحراف معیار ±	میانگین
S1,1*	۰/۰±۱۳۱/۰۰۷	۰/۰±۹۸۲/۱۶۴	۰/۰	
S2,1*	۰/۰±۰۵۴/۰۱۳	۰/۰±۹۹۱/۱۷۰	۰/۰	
S3,1*	۰/۰±۷۲۴/۱۰۵	۰/۰±۵۷۴/۰۴۹	۰/۰۵	
S4,1*	۰/۰±۷۲۳/۱۶۶	۰/۰±۶۰۰/۰۶۹	۰/۰	
S1,2*	۰/۰±۸۶۹/۰۲۱	۰/۰±۷۲۴/۱۰۶	۰/۰۱	
S2,2*	۰/۰±۳۸۷/۰۱۲	۰/۰±۸۱۹/۰۴۰	۰/۰	
S3,2*	۰/۰±۱۴۳/۰۱۵	۰/۰±۷۳۶۲/۱۵۶۵	۰/۰	
S4,2*	۰/۰±۰۴۲۴/۰۱۳	۰/۰±۳۵۲/۱۱۰	۰/۰	
S1,3*	۰/۰±۲۲۴/۱۲۰	۰/۰±۵۴۴/۰۴۹	۰/۰	
S2,3*	۰/۰±۷۲۳/۱۶۶	۰/۰±۴۴۶/۰۷۰	۰/۰	
S3,3*	۰/۰±۵۰۲/۱۰۵	۰/۰±۸۸۸/۱۷۸	۰/۰	
S4,3*	۰/۰±۵۱۹/۰۱۳	۰/۰±۸۵/۲۰۱	۰/۰	
S1,4*	۰/۰±۳۱۱/۰۱۲	۰/۰±۸۶۲/۱۲۵	۰/۰	
S2,4*	۰/۰±۲۱۴/۱۰۳	۰/۰±۹۷۴/۱۱۰	۰/۰	
S3,4*	۰/۰±۶۴۴/۱۰۳۵	۰/۰±۶۸۴/۱۰۹	۰/۰	
S4,4*	۰/۰±۸۲۳/۲۲۶	۰/۰±۴۲۳/۱۰۹	۰/۰	

الکترودها	بیش‌فعالان		نرمال	
	انحراف معیار ±	میانگین	انحراف معیار ±	میانگین
F7-F8	۰/۰±۳۰۱/۰۱۲	۰/۰±۶۵۸/۰۰۲	۰/۰۵	
F7-T5	۰/۰±۴۰۸/۰۱۰	۰/۰±۶۶۸/۰۶۲	۰/۰۵	
F7-P8	۰/۰±۲۹۱/۲۱۷	۰/۰±۵۹۴/۲۴۷	۰/۰۵	
F7-O1	۰/۰±۳۴۵/۰۵۲	۰/۰±۶۸۲/۰۱۲	۰/۰۵	
F7-O2	۰/۰±۳۶۵/۰۸۵	۰/۰±۶۳۲/۰۲۰	۰/۰۷	
F8-P5	۰/۰±۲۱۷/۰۲۱	۰/۰±۵۳۱/۰۴۰	۰/۰۵	
F8-T4	۰/۰±۳۱۵/۰۰۹	۰/۰±۵۲۱/۰۰۹	۰/۰۶	
Cz-P7	۰/۰±۷۸۱/۰۲۰	۰/۰±۴۷۸/۰۰۸	۰/۰۵	
Cz-O2	۰/۰±۷۵۲/۰۳۶	۰/۰±۳۳۲/۰۱۵	۰/۰۵	
C3-O1	۰/۰±۸۱۱/۰۱۲	۰/۰±۳۸۱/۰۱۰	۰/۰۵	
C3-T7	۰/۰±۶۹۲/۰۳۵	۰/۰±۴۷۵/۰۰۱	۰/۰۵	
P4-P3	۰/۰±۵۲۲/۰۳۳	۰/۰±۵۰۰/۰۲۱	۰/۰۳۹	
O1-O2	۰/۰±۳۱۹/۰۰۸	۰/۰±۳۴۴/۱۱	۰/۰۴۲	

همان‌طور که در جدول (۱) مشاهده می‌شود بعضی مقادیر به‌دست‌آمده در ارتباطات نواحی مغزی در افراد نرمال و افراد بیش‌فعال با یکدیگر متفاوت است. نتایج به‌دست‌آمده نشان می‌دهد که در افراد عادی ارتباط نواحی پیشانی با دیگر نواحی بیشتر است حال آن‌که در افراد بیش‌فعال مقدار این ارتباط کمتر گزارش شده است. همچنین دیده می‌شود که ناحیه مرکزی مغز در افراد بیش‌فعال با دیگر نواحی اتصالات بیشتری دارد در صورتی‌که در افراد نرمال این اتصالات کمتر است. ارتباط بین نواحی آهیانه‌ای در افراد بیش‌فعال کمتر از افراد نرمال دیده شده است. بقیه ارتباطات در دیگر نواحی نرمال گزارش شده است و تفکیک‌پذیری معناداری ($pvalue \leq 0.05$) دیده نشده است.

در جدول بالا دیده می‌شود که در ناحیه C3 در کلیه استیتهای با $p < 0.05$ value، بین دو گروه تفاوت‌های معنادار مشاهده شده است. با توجه به نتایج

هر ناحیه از مدل بیان شده شامل ۱۶، CNN است بنابراین ۱۶ استیتهای در هر جدول برای هر کانال نوشته خواهد شد و باید با توجه به تعداد الکترودها که همان کانال‌های ثبت سیگنال است تعداد ۱۶ جدول کشیده شود تا میزان اتصالات درون

همان طور که در جدول بالا دیده می شود در این ناحیه نیز در اغلب استیت های آن تفاوت های معنادار بین دو گروه مشاهده می شود.

با توجه به نتایج به دست آمده از این جدول می توان به این نتیجه رسید که عملکرد ناحیه پیشانی سمت چپ مغز (Fp1) در افراد نرمال با افراد بیش فعال کاملاً متفاوت است. در اینجا نیز می توان به این نتیجه رسید که ناحیه پیشانی سمت چپ مغز در افراد بیش فعال چه از نظر اتصالات درون ناحیه ای و چه از نظر اتصالات برون ناحیه ای دارای ناهنجاری هایی است. در جدول (۴)، استیت های به دست آمده از نواحی مختلف مغز دو گروه که دارای تفاوت معنادار در نواحی مختلف مغز با $(p \leq 0.05)$ هستند ارائه شده است.

جدول ۴. انواع استیت های دارای تفاوت معنادار $(p \leq 0.05)$ ، در ۱۹ کانال

States	ناحیه	ثبت شده
	Fp1	کلیه حالات به جز ۳ مورد
	Fp2	کلیه حالات به جز ۶ مورد
	F7	کلیه حالات به جز ۴ مورد
	F8	کلیه حالات به جز ۶ مورد
	F4	کلیه حالات به جز ۶ مورد
	F3	۸ حالت
	Fz	همه حالات به جز ۵ مورد
	C3	همه حالات
	Cz	همه حالات
	C4	همه حالات
	T4	هیچ حالتی
	T5	هیچ حالتی
	T3	هیچ حالتی
	T6	هیچ حالتی
	P3	هیچ حالتی به جز ۳ مورد
	P4	هیچ حالتی به جز ۳ مورد
	O1	هیچ حالتی

به دست آمده از این جدول می توان به این نتیجه رسید که ناحیه مرکزی مغز در افراد نرمال از لحاظ عملکردی با افراد بیش فعال کاملاً متفاوت است. در اینجا می توان دریافت که ناحیه مرکزی مغز در افراد بیش فعال چه از نظر اتصالات درون ناحیه ای و چه از نظر اتصالات برون ناحیه ای دارای ناهنجاری های فاحشی است. در جدول (۵)، میانگین مقادیر استیت های به دست آمده از کانال Fp1، برای افراد نرمال و بیش فعال گزارش شده است.

جدول ۳. میانگین مقادیر استیت های به دست آمده از کانال Fp1، برای افراد نرمال

و بیش فعال

حالات	بیش فعال		نرمال	
	انحراف معیار \pm	میانگین	انحراف معیار \pm	(P value)
S1,1	۰/۰+۲۳۱/۲۰۴	۰/۰+۹۳۵۸/۱۹۷	۰/۰+۹۳۵۸/۱۹۷	۰/۰۵
S2,1	۰/۰+۲۰۴۲/۰۰۴	۰/۰+۹۰۶۵/۳۰۲	۰/۰+۹۰۶۵/۳۰۲	۰/۰۵
S3,1	۰/۰+۳۲۷/۰۲۲	۰/۰+۸۱۲/۰۰۶	۰/۰+۸۱۲/۰۰۶	۰/۰۵
S4,1	۰/۰+۲۱۷۵/۰۳۳۲	۰/۰+۷۳۴/۳۵۶	۰/۰+۷۳۴/۳۵۶	۰/۰۵
S1,2	۰/۰+۱۹۲۷/۰۱۰	۰/۰+۸۱۲/۰۸۶	۰/۰+۸۱۲/۰۸۶	۰/۰۵
S2,2	۰/۰+۳۱۷۵/۳۰۲	۰/۰+۷۳۴/۳۵۶	۰/۰+۷۳۴/۳۵۶	۰/۰۵
S3,2	۰/۰+۳۷۸/۲۰۴	۰/۰+۵۰۶۵/۳۰۲	۰/۰+۵۰۶۵/۳۰۲	۰/۰۶
S4,2	۰/۰+۳۲۷/۰۰۲	۰/۰+۸۱۲/۰۸۶	۰/۰+۸۱۲/۰۸۶	۰/۰۵
S1,3	۰/۰+۴۲۱/۰۳۲	۰/۰+۷۳۴/۳۵۶	۰/۰+۷۳۴/۳۵۶	۰/۰۵
S2,3	۰/۰+۳۸۳۲/۰۲۹	۰/۰+۵۸۵۲/۱۷۱	۰/۰+۵۸۵۲/۱۷۱	۰/۰۹
S3,3	۰/۰+۵۵۲/۰۶۰	۰/۰+۹۱۲۷/۰۰۵	۰/۰+۹۱۲۷/۰۰۵	۰/۰۵
S4,3	۰/۰+۲۶۱۵/۰۲۳	۰/۰+۴۱۶۷/۰۱۱	۰/۰+۴۱۶۷/۰۱۱	۰/۰۵
S1,4	۰/۰+۷۳۵۲/۲۱۲	۰/۰+۹۶۷۵/۲۰۲	۰/۰+۹۶۷۵/۲۰۲	۰/۰۸
S2,4	۰/۰+۲۰۴۲/۰۰۲	۰/۰+۷۰۶۵/۳۰۲	۰/۰+۷۰۶۵/۳۰۲	۰/۰۵
S3,4	۰/۰+۵۱۴۲/۰۰۴	۰/۰+۹۴۶۵/۰۰۲	۰/۰+۹۴۶۵/۰۰۲	۰/۰۵
S4,4	۰/۰+۳۲۷/۰۲۲	۰/۰+۸۱۲/۰۸۶	۰/۰+۸۱۲/۰۸۶	۰/۰۵

۰/۴۱	۰/۰+۵۳۶/۰۷۴	۰/۰+۵۳۳/۰۵۶	T5
۰/۱۷۶	۰/۰+۹۷۷/۰۳۱	۰/۰+۹۵۶/۰۳۲	T3
۰/۲۰۵	۰/۰+۸۸۹/۰۵۰	۰/۰+۸۵۵/۰۲۳	T6
۰/۰۷	۰/۰+۸۸۹/۰۵۹	۰/۰+۶۵۵/۱۲۳	P3
۰/۰۶	۰/۰+۷۹۹/۰۵۰	۰/۰+۶۵۵/۰۲۳	P4
۰/۶۱	۰/۰+۷۳۴/۰۶۴	۰/۰+۷۳۳/۰۴۶	Pz
۰/۵۴	۰/۰+۴۵۲/۰۹۲	۰/۰+۴۲۸/۰۴۲	O1
۰/۵۰	۰/۰+۳۵۱/۰۹۲	۰/۰+۳۲۵/۰۴۲	O2

هیچ حالتی **O2**

با توجه به مقادیر استیتهای به‌دست‌آمده که در جدول بالا گزارش شده است می‌توان به این نتیجه دست‌یافت که در قسمت‌های مختلفی از مغز دو گروه ناهنجاری‌های اتصالات مغزی دیده می‌شود. ناهنجاری‌های معناداری در نواحی مرکزی و پیشانی مغز افراد بیش‌فعال مشاهده شده است. در ناحیه آهیانه‌ای تفاوت کمی بین دو گروه مشاهده شده است. در دیگر نواحی هیچ‌گونه تفاوتی که ناشی از ناهنجاری‌های اتصالات مغزی باشد مشاهده نشده است.

برای نمایش میزان اتصالات درون ناحیه‌ای مغز افراد بیش‌فعال و نرمال جدول (۵) ارائه شده است. اعداد این جدول مبتنی بر داده‌های ورودی که به هر ناحیه اعمال می‌شود و میزان ارتباطی که CNN‌های درونی هر ناحیه با یکدیگر دارند محاسبه شده است. با توجه به معماری مدل پیشنهادشده، ۱۹ اتصال درون ناحیه مغزی برای هر فرد در نظر گرفته شده است. مقادیری که دارای تفاوت معناداری هستند با * مشخص شده است.

جدول ۵. میانگین مقادیر وزن‌های به‌دست‌آمده برای افراد بیش‌فعال و نرمال در هر

ناحیه از CNN برای ۱۹ کانال

ناحیه	بیش‌فعال		نرمال	
	انحراف معیار \pm	میانگین	انحراف معیار \pm	(P value) میانگین
*Fp1	۰/۰+۵۰۲/۰۲۹	۰/۰+۹۸۸/۰۲۵	۰/۰+۹۸۸/۰۲۵	۰/۰۵
*Fp2	۰/۰+۴۳۳/۰۲۳	۰/۰+۸۲۳/۰۳۹	۰/۰+۸۲۳/۰۳۹	۰/۰۵
*F7	۰/۰+۲۴۰/۰۳۰	۰/۰+۷۵۲/۰۴۵	۰/۰+۷۵۲/۰۴۵	۰/۰۵
*F8	۰/۰+۳۵۲/۰۵۰	۰/۰+۶۹۳/۱۶۵	۰/۰+۶۹۳/۱۶۵	۰/۰۵
F4	۰/۰+۴۳۲/۰۱۳	۰/۰+۵۹۳/۰۱	۰/۰+۵۹۳/۰۱	۰/۰۸
*F3	۰/۰+۲۱۷/۰۰۴	۰/۰+۶۸۸/۱۲۱	۰/۰+۶۸۸/۱۲۱	۰/۰۵
*Fz	۰/۰+۳۸۳/۰۳۰	۰/۰+۵۰۴/۰۶۵	۰/۰+۵۰۴/۰۶۵	۰/۰۵
*C3	۰/۰+۸۹۹/۰۲۶	۰/۰+۳۰۴/۰۶۴	۰/۰+۳۰۴/۰۶۴	۰/۰۵
*Cz	۰/۰+۸۹۵/۱۳۳	۰/۰+۴۶۵/۰۵۱	۰/۰+۴۶۵/۰۵۱	۰/۰۵
*C4	۰/۷۷۵/۰۸۰	۰/۰+۵۲۰/۰۳۰	۰/۰+۵۲۰/۰۳۰	۰/۰۵
T4	۰/۰+۹۶۳/۰۳۶	۰/۰+۹۳۶/۰۴۴	۰/۰+۹۳۶/۰۴۴	۰/۳۲

همان‌طور که در جدول بالا و دیگر نتایجی که به‌دست‌آمده مشاهده می‌شود که افراد بیش‌فعال در مقایسه با افراد نرمال از نظر اتصالات بین ناحیه‌ای مغز ناهنجاری‌هایی را در نواحی مرکزی و پیشانی دارند. اتصالات بین ناحیه‌ای مغزی ناحیه مرکزی در افراد بیش‌فعال به نسبت افراد عادی بیشتر است. اتصالات بین ناحیه‌ای مغزی ناحیه مرکزی قسمت پیشانی مغز افراد نرمال بیشتر از افراد بیش‌فعال است. در مورد اتصالات درون ناحیه‌ای این دو گروه می‌توان بیان نمود که اتصالات درون ناحیه‌ای قسمت‌های پیشانی و مرکزی افراد بیش‌فعال نیز دارای تفاوت‌های معناداری با افراد نرمال است. در نواحی آهیانه‌ای تفاوت‌های کمی دیده شده است. در نواحی پس‌سری تفاوتی مشاهده نشده است. نتایج به‌دست‌آمده با نتایج به‌دست‌آمده از پژوهش‌های دیگر محققین در این زمینه همسو است [۳۳].

اتصالات به‌دست‌آمده از مدل پیشنهادی، میزان ناهنجاری‌های مغزی افراد ADHD و نرمال را دقیق‌تر ارائه می‌کند. در جدول (۶)، استفاده و عدم استفاده از میزان اتصالات مغزی جهت تفکیک دو گروه ارائه می‌شود.

جدول ۶. مقایسه میزان دقت استفاده و عدم استفاده از میزان اتصالات نواحی مغز

روش	مبتنی بر اتصالات	مبتنی بر سیگنال [۳۲]
شبکه عصبی کانولوشنی	۹۴/۷	۹۰/۱
SVM	۸۵/۳	۸۱
KNN	۸۱/۱	۷۹/۳
شبکه عصبی چندلایه	۸۲/۷	۸۰/۳

نتایج به‌دست‌آمده نشان می‌دهد که در صورتی که از یک کلاس بند مناسب مانند شبکه عصبی کانولوشنی استفاده شود به‌طوری‌که از میزان اتصالات به‌دست‌آمده از مدل هوشمند پیشنهادی باشد، به نتایج بهتری در تفکیک دو گروه دست‌یافته خواهد شد.

۴- نتیجه‌گیری و کارهای آینده

بیش‌فعالی اختلال رفتاری است که سبب می‌شود فرد قدرت دقت و تمرکز بر روی یک موضوع را نداشته باشد. شواهدی موجود است که نشان می‌دهد تفاوت‌هایی در

- [16] Y. Moriguchi, K. Hiraki, "Neural origin of cognitive shifting in young children," Proc of the National Academy of Sciences of the United States of America. Vol.106, pp.6017-6021, 2009.
- [17] H. Negoro, M. Sawada, J. Iida, T. Ota, S. Tanaka, T. Kishimoto, "Prefrontal dysfunction in attention-deficit/hyperactivity disorder as measured by near-infrared spectroscopy," Child Psychiatry & Human Development. vol.41, pp.193-203, 2010.
- [18] C. Cortes, V. Vapnik, "Support-vector networks," Machine Learning. Vol. 20, pp. 273-297, 1995.
- [19] C. Z. Zhu, Y. F. Zang, M. Liang, L. X. Tian, Y. He, X. B. Li, T. Z. Jiang, "Discriminative analysis of brain function at resting-state for attention deficit/hyperactivity disorder," Medical Image Computing and Computer-Assisted Intervention. Vol.8, pp.468-475, 2016.
- [20] H. Ichikawa, J. Kitazono, K. Nagata, A. Manda, K. Shimamura, R. Sakuta, R. Kakigi, "Novel method to classify hemodynamic response obtained using multi-channel fNIRS measurements into two groups: Exploring the combinations of channels," Frontiers of Human Neuroscience. Vol. 480, 2014.
- [21] A. Akira Yasumura, M. Omori, Y. Fukuda, J. Takahashi, "Applied Machine Learning Method to Predict Children With ADHD Using Prefrontal Cortex Activity: A Multicenter Study in Japan". Journal of Attention Disorders", 2017.
- [22] V. Metsis, F. Makedon, D. Shen, H. Huang, V. Metsis, F. Makedon, D. Shen, H. Huang. "IEEE/ACM Transactions on Computational Biology and Bioinformatics", vol.11, no.1, pp.168-181.
- [23] A. Y. Ng, "Feature selection, l1 vs. l2 regularization, and rotational invariance", ACM, vol. 78, 2004.
- [24] P. S. Bradley, O. L. Mangasarian, "Feature selection via concave minimization and support vector machines," Proc. in Fifteenth International Conference Machine Learning (ICML'98), pp. 82-90, 1988.
- [25] L. Breiman, J. Friedman, C. J. Stone et al. "Classification and regression trees," CRC press. Vol. 6, pp. 2619-2631, 1984.
- [26] J. H. Park et al. "Comparison of QEEG finding between adolescents with attention deficit hyperactivity disorder (ADHD) without comorbidity and ADHD comorbid with Internet gaming disorder", J.Korean Med. Sci. vol. 32, no.3, pp.514-521, 2017.
- [27] M.R. Mohammadi, A. Khaleghi, A. Moti Nasrabadi, S. Rafieivand, M. Begol, "EEG Classification of ADHD and Normal Children Using Non-linear Features and neural network", Biomedical Engineering Letters springer. 2016.
- [28] R. Moqadam, N. Loghmani, A. Kh Moghaddam, a. Allahverdy, "Differentiating Brain Connectivity Networks in ADHD and Normal Children using EEG," Proc in 30th International Conference on Electrical Engineering (ICEE), 2022.
- [29] Y. He et al. "Brain Network Connectivity Analysis of Different ADHD Groups Based on CNN-LSTM Classification Model," Proc in International Conference on Intelligent Robotics and Applications (ICIRA), pp.626-635, 2022.
- [30] H. Holker, S. Susan, "Computer-Aided Diagnosis Framework for ADHD Detection Using Quantitative EEG," International Conference on Brain Informatics. pp.229-240, 2022.
- [31] Ch. Wang et al, "Towards high-accuracy classifying attention-deficit/hyperactivity disorders using CNN-LSTM model", Journal of Neural Engineering. vol.19. no. 4. 2022.
- [32] S. Motamed, E. Askari, "Recognition of Attention Deficit/Hyperactivity Disorder (ADHD) Based on Electroencephalographic Signals Using Convolutional Neural Networks (CNNs)," Journal of Information Systems and Telecommunication (JIST). Vol.10, 2022.
- [33] A. Ekhlasi, A. MNasrabadi, M.R. Mohammadi, "Analysis of Effective Connectivity Strength in Children with Attention Deficit Hyperactivity Disorder Using Phase Transfer Entropy", Iranian Journal of Psychiatry. vol. 16, no.4, 2022.

ساختار مغز و سیگنال‌های الکتروانسفالوگرافی بیش‌فعالان وجود دارد بنابراین در این مقاله به کمک مدلی هوشمند و کارا به شناسایی نواحی متفاوت پرداخته شد.

در مدل پیشنهادی ابتدا اتصالات درون ناحیه‌ای مغز افراد بیش‌فعال با استفاده از تابع هم‌دوسی طیفی بین کانال‌ها محاسبه شد سپس اتصالات درون ناحیه‌ای با استفاده از شبکه عصبی سلولار به دست آورده شد. نتایج به‌دست‌آمده نشان داد که در اتصالات درون و برون ناحیه‌ای نواحی مرکزی مغز افراد بیش‌فعال نابهنجاری‌هایی دیده می‌شود. میزان اتصالات برون ناحیه‌ای افراد بیش‌فعال بیشتر است. همچنین تفاوت‌هایی در نواحی پیشانی و آهیانه‌ای نیز مشاهده شده است به‌طوری‌که در ناحیه آهیانه‌ای اتصالات درون ناحیه‌ای کمتری وجود دارد. در نهایت با استفاده از شبکه عصبی کانولوشنی مبتنی بر اتصالات به‌دست‌آمده از مدل پیشنهادی با دقت ۹۴/۴٪، دو گروه ADHD و نرمال تفکیک شدند.

۵- مآخذ

- [1] A. Boonstra, J. Kooij, J. Oosterlaan, J. A. Sergeant, J. k. Buitelaar, "Dose methylphenidate improve inhibition and other cognitive abilities in adults with childhood onest ADHD?" Journal of Clinical and Exceptional Neurobiology. Vol. 27, pp.278-298, 2005.
- [2] S. Brock, S. R. Jemerson, R. L. Hansen, Developmental psychopathological at school: Identifying, assessing and treating ADHD at school, Springer. 2009.
- [3] A. Müller, S. Vetsch, I. IPershin, G. Candrian, G. D. Baschera, J. Kropotov, J. Kasper, "EEG/ERP-based biomarker/neuroalgorithms in adults with ADHD: Development, reliability, and application in clinical practice," The World Journal of Biological Psychiatry, pp.1-12, 2019.
- [4] S. Baijot, H. Slama, G. Söderlund, B. Dan, P. Deltenre, C. Colin, N. Deconinck, "Neuropsychological and neurophysiological benefits from white noise in children with and without ADHD", Behav. Brain Funct. vol. 12, 2017.
- [5] E. Askari, S. K. Setarehdan, A. Sheikhan, M. R. Mohamadi, M. Teshnelab, "Designing a model to detect the brain connections abnormalities in children with autism using 3D-cellular neural networks," Journal of Integrative Neuroscience. Vol.17, no.3, pp.391-411, 2018.
- [6] E. Askari, S. K. Setarehdan, A. Sheikhan, M. R. Mohamadi, M. Teshnelab, "Modeling the connections of brain regions in children with autism using cellular neural networks and electroencephalography analysis," Artificial Intelligence in Medicine. Vol. 89, pp.40-50.
- [7] A. Mueller, G. Candrian, J.D. Kropotov, V. A. Ponomarev, G. M. Baschera, "Classification of ADHD patients on the basis of independent ERP components using a machine learning system," Nonlinear Biomedical Physics. Vol. 4, 2010.
- [8] A. Mueller, G. Candrian, V. Arntsberg Grane, J.D. Kropotov, V.A. Ponomarev, G. M. Baschera, "Discriminating between ADHD adults and controls using independent ERP components and a support vector machine: a validation study," Nonlinear Biomedical Physics. Vol. 5, no.1, 2011.
- [9] J.R. J. Sato, M. Hoexter, A. Fujita, "Evaluation of Pattern Recognition and Feature Extraction Methods in ADHD Prediction," Frontiers in Systems Neuroscience. Vol. 6, no.4, 2012.
- [10] J. Du, L. Wang, B. Jie B, "Network-based classification of ADHD patients using discriminative sub network selection and graph kernel," Computerized Medical Imaging & Graphics the Official Journal of the Computerized Medical Imaging Society", vol.52, pp.82-88, 2016.
- [11] F. X. Castellanos, C. Kelly, M. P. Milham, "The restless brain: attention-deficit hyperactivity disorder, resting-state functional connectivity, and intrasubject variability," Canadian Journal of Psychiatry Revue Canadienne De Psychiatrie. Vol. 54, no.10, pp. 665-72, 2009.
- [12] G. Bush Cingulate, "Frontal and Parietal Cortical Dysfunction in Attention-Deficit/Hyperactivity Disorder. Biological Psychiatry," vol. 69, no.12, pp.1160-1167, 2011.
- [13] D. Yao, X. Guo, Q. Zhao, L. Liu L, "Discriminating ADHD from healthy controls using a novel feature selection method based on relative importance and ensemble learning," 40th annual international conference of IEEE Engineering in Medicine and Biology Society. 2018.
- [14] L. Breiman, J. Friedman, C. J. Stone, "Classification and regression trees" CRC press. Vol. 6, pp. 2619-31, 1984.
- [15] S. Chandana, K. Balaraj, P. Sushmitha, P. Usha, "Extraction and Analysis of EEG signals for the detection of ADHD syndrome," A novel approach. A project Report. 2016.

الهام عسکری، دکترای خود را در رشته مهندسی رایانه گرایش هوش مصنوعی در سال ۱۳۹۷ دریافت کرده است. ایشان هم‌اکنون استادیار بخش مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد فومن و شفت است. زمینه‌های پژوهشی وی پردازش سیگنال، منطق، سامانه‌های فازی و کاربردهای



آن‌ها، هوش مصنوعی و یادگیری ماشین است. نشانی رایانامه ایشان عبارت است از:

askary.elham@gmail.com

سارا معتمد، دکترای خود را در رشته مهندسی رایانه گرایش هوش مصنوعی در سال ۱۳۹۶ دریافت کرده است. ایشان هم‌اکنون استادیار بخش مهندسی کامپیوتر دانشگاه آزاد اسلامی واحد فومن و شفت است. زمینه‌های پژوهشی وی هوش مصنوعی، پردازش تصاویر، بینایی ماشین و علم داده است. نشانی رایانامه ایشان عبارت است از:



motamed.sarah@gmail.com