

تشخیص اسکیزوفرنی بر اساس سیگنال الکتروانسفالوگرام با استفاده از یادگیری عمیق

مریم الهیاری^۱، فاطمه جمشیدی^{۲*}

^۱ دانشکده مهندسی کامپیوتر، پردیس فنی و مهندسی، دانشگاه یزد، یزد، ایران

^۲ گروه مهندسی برق، دانشکده مهندسی، دانشگاه فسا، فسا، ایران

چکیده

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۱/۰۲/۱۱

تاریخ پذیرش:

۱۴۰۱/۰۸/۰۷

کلیدواژه‌ها:

اسکیزوفرنی، الکتروانسفالوگرام،

شبکه‌های عصبی عمیق،

یادگیری عمیق

نویسنده مسئول:

jamshidi@fasau.ac.ir

اسکیزوفرنی یک ناهنجاری در مغز است که در آن افراد واقعیت را غیرطبیعی تفسیر می‌کنند. این اختلال روانی با علائم رفتاری مانند توهم و بی‌نظمی گفتار مشخص می‌شود. سیگنال الکتروانسفالوگرام اختلالات مغزی را نشان می‌دهد و به‌طور گسترده برای مطالعه بیماری‌های مغزی استفاده می‌شود. هدف این مقاله تشخیص خودکار اسکیزوفرنی از روی سیگنال الکتروانسفالوگرام است. روش متداول در پژوهش‌ها، استخراج دستی ویژگی‌ها از سیگنال الکتروانسفالوگرام است. از آنجا که الگوریتم‌های یادگیری عمیق توانایی استخراج خودکار ویژگی‌های مهم و طبقه‌بندی آن‌ها را دارند، در این پژوهش به‌منظور استخراج ویژگی‌های مفیدتر، سیگنال الکتروانسفالوگرام به یک شبکه عصبی عمیق بازگشتی کانولوشنی یازده لایه اعمال شده است. سیگنال‌های الکتروانسفالوگرام جمع‌آوری شده در انستیتو ورشو از ۱۴ فرد سالم و ۱۴ بیمار اسکیزوفرنی، در اینجا مطالعه شده است. مقدار میانگین معیارهای ارزیابی درستی مدل شامل دقت، حساسیت، و مقدار پیش‌بینی شده مثبت برای مدل پیشنهادی به ترتیب برابر $0.98/79$ ، $0.98/73$ و $0.99/06$ به دست آمد که بهبود عملکرد مدل پیشنهادی برای طبقه‌بندی بیماران اسکیزوفرنی و افراد سالم را در مقایسه با مدل‌های قبلی تأیید می‌کند. مدل ارائه شده می‌تواند به‌عنوان یک ابزار تشخیصی به پزشکان برای تشخیص مراحل اولیه اسکیزوفرنی کمک کند.

۱- مقدمه

نورن‌های مغز از طریق الکترودها به دستگاه منتقل می‌شود و پس از تقویت و حذف نویز به صورت سیگنال زمانی ثبت و نمایش داده می‌شود. پزشک یا متخصص علوم اعصاب می‌تواند سیگنال ثبت شده را به طور مستقیم یا پس از پردازش کامپیوتری تجزیه و تحلیل کند. در روش‌های تهاجمی ضبط نوار مغزی که بانام نوار مغزی اینتراکرانیا (iEEG)^۲ شناخته می‌شوند، از سیستم مانیپولینگ اینتراکرانیا استفاده می‌شود تا متخصص در حین جراحی به داده‌های بیولوژیکی کامل تری که از طریق ضبط عادی از روی پوست سر قابل استخراج نیستند، دسترسی یابد. سیگنال EEG فعالیت‌های الکتریکی مغز را نشان می‌دهد و به دلیل داشتن اطلاعات با وضوح زمانی بالا، کاربرد گسترده‌ای در تشخیص اختلالات مغزی و پژوهش‌های مرتبط با آن دارد (Oh S. L., 2019)، (Shalbf, 2020). از آنجاکه امواج مغزی فرد مبتلا به بیماری اسکیزوفرنی با افراد سالم متفاوت است، با تحلیل امواج مغزی می‌توان بیماری را با دقت^۳ قابل قبولی تشخیص داد (Siuly, 2020).

یادگیری ماشین مطالعه الگوریتم‌هایی است که می‌توانند به طور خودکار از طریق تجربه و با استفاده از داده‌ها بهبود یابند. این الگوریتم‌ها به عنوان بخشی از هوش مصنوعی تلقی می‌شوند. الگوریتم‌های یادگیری ماشین یک مدل را بر اساس داده‌های نمونه، معروف به «داده‌های آموزشی»، به منظور پیش‌بینی یا تصمیم‌گیری بدون برنامه‌ریزی صریح، می‌سازند. الگوریتم‌های یادگیری ماشین در طیف گسترده‌ای از برنامه‌ها مانند پزشکی، فیلترینگ ایمیل، تشخیص گفتار و بینایی رایانه‌ای استفاده می‌شوند. یادگیری عمیق بخشی از خانواده گسترده‌تری از روش‌های یادگیری ماشین است که بر اساس شبکه‌های عصبی مصنوعی با یادگیری نمایشی ساخته شده است. یادگیری می‌تواند تحت نظارت، نیمه نظارت یا بدون نظارت باشد. معماری‌های یادگیری عمیق مانند شبکه‌های عصبی عمیق، یادگیری تقویتی عمیق، شبکه‌های عصبی بازگشتی و شبکه‌های عصبی کانولوشن در زمینه‌هایی از جمله بینایی کامپیوتر،

بیماری اسکیزوفرنی ناهنجاری مغزی است که ویژگی‌های رفتاری مانند تفکر، ادراک و گفتار را مختل می‌کند. این اختلال روانی با علائم رفتاری مانند توهم، بی‌نظمی در گفتار، ناتوانی در درک واقعیت و انجام رفتارهای نامعقول همراه است. عارضه روانی اسکیزوفرنی به دلیل فقدان نشانه‌های بالینی در مقایسه با سایر بیماری‌های مغزی مانند صرع و تشنج کمتر شناخته شده است. در حالی که ۳ تا ۷ درصد مردم در سراسر دنیا به این بیماری مبتلا و از عوارض آن رنج می‌برند.

روش متداول برای تشخیص بیماری اسکیزوفرنی این است که روان‌پزشک با صحبت کردن با بیمار، عارضه را در وی تشخیص می‌دهد. روشن است که این روش تشخیص انسانی می‌تواند خطای زیادی داشته باشد. متخصصان با مطالعه ژنتیک، انجام تحقیقات رفتاری، ضبط و بررسی نوار مغزی یا الکتروانسفالوگرام (EEG)^۱ و استفاده از تصویربرداری پیشرفته برای بررسی ساختار و عملکرد مغز، علل بیماری را کشف می‌کنند. این رویکردها نوید درمان‌های جدید و موثرتری را می‌دهند. در حال حاضر درمان قطعی برای بیماری اسکیزوفرنی وجود ندارد. اگر بیماری اسکیزوفرنی به موقع تشخیص داده نشود و درمان آن در مراحل اولیه صورت نگیرد، توانایی‌های رفتاری فرد شدیدتر آسیب می‌بینند. از این رو تشخیص زودهنگام اسکیزوفرنی نقش مهمی در درمان و محدود کردن اثرات بیماری دارد.

سلول‌های مغز از طریق امواج الکتریکی با یکدیگر ارتباط برقرار می‌کنند و نوار مغز با سنجش این ارتباط می‌تواند به تشخیص برخی از بیماری‌ها از جمله تشنج و صرع کمک کند. سیگنال EEG الگوهای ارتباطی بین امواج الکتریکی مغز را ثبت می‌کند. برای این منظور الکترودهایی از جنس نقره به سر متصل می‌شوند. اتصال الکترودها به سر به دو صورت تهاجمی و غیرتهاجمی انجام می‌شود. در روش غیرتهاجمی، فعالیت الکتریکی مغز از طریق نصب الکترودهای سطحی بر روی سر ثبت می‌شود. اثر الکتریکی فعالیت

³ Accuracy

¹ Electroencephalogram (EEG)

² Intracranial Electroencephalogram (iEEG)

بستانی و همکاران در سال ۲۰۰۹ نمونه‌های سیگنال EEG ضبط‌شده در مرکز تحقیقات بالینی روان‌پزشکی پرت در استرالیای غربی شامل ۱۳ فرد مبتلا به اسکیزوفرنی و ۱۸ فرد سالم بررسی نمودند؛ آن‌ها با پیاده‌سازی روش‌های باند پاور^۲، رگرسیون خودکار^۳ و بعد فراکتال^۴ ویژگی استخراج نموده و با به‌کارگیری الگوریتم‌های مختلف یادگیری ماشین شامل LDA^۵، BDLDA و Adaboost^۶ به ترتیب به دقت‌های ۸۷/۵۱٪، ۸۵/۳۶٪ و ۸۵/۴۱٪ برای تشخیص فرد بیمار از فرد سالم دست یافتند (Boostani, 2009).

سیری واتسان و همکاران در سال ۲۰۱۹ برای تشخیص بیماری اسکیزوفرنی به‌جای سیگنال‌های EEG، از تصاویر رزونانس مغناطیسی مغز (MRI) استفاده کردند؛ آن‌ها ۱۴۴ نمونه که ۶۹ تای آن‌ها مبتلا به اختلال اسکیزوفرنی بودند را مطالعه کردند و سه مدل‌های مبتنی بر یادگیری ماشین شامل ماشین بردار پشتیبان^۷ (SVM)، رگرسیون منطقی^۸ و جنگل تصادفی^۹ و همچنین شبکه عصبی کانولوشنی (CNN) که مدلی مبتنی بر یادگیری عمیق است را پیاده‌سازی کردند؛ نتایج نشان داد که مدل CNN با دقت ۹۴ درصد بهترین مدل پیاده‌سازی شده در این مطالعه بوده است (Srinivasagopalan, 2019).

جاهمونا و همکاران در سال ۲۰۱۹ با استفاده از داده‌های ورشو لهستان (Oh S. L., 2019)، یک ابزار تشخیص خودکار^{۱۰} برای بررسی و طبقه‌بندی الگوهای سیگنال EEG در کلاس‌های عادی و اسکیزوفرنی ارائه دادند. این ابزار تشخیص خودکار دنباله‌ای از رویدادها از جمله: تقسیم سری EEG، استخراج ویژگی‌های غیرخطی، انتخاب ویژگی به کمک آزمون t، طبقه‌بندی و اعتبارسنجی را انجام داد. سپس استخراج ویژگی غیرخطی برای استخراج ۱۵۷ ویژگی از هر الگوی EEG اجرا شد، که از بین آن‌ها

تشخیص گفتار^۱، پردازش زبان طبیعی^۲، بیوانفورماتیک، طراحی دارو و پزشکی استفاده شده است و در برخی موارد عملکرد این الگوریتم‌ها از عملکرد متخصصان انسانی فراتر رفته است. از آنجاکه ابزارهای هوش مصنوعی برای تحلیل امواج مغزی به‌منظور تشخیص بیماری اسکیزوفرنی می‌تواند کارآمد باشد، در این مقاله، تشخیص سریع و صحیح بیماری اسکیزوفرنی با استفاده از تحلیل سیگنال EEG مبتنی بر یادگیری عمیق بررسی می‌شود. ارائه^۳ یک طرح خودکار برای تشخیص زود هنگام و با خطای کم بیماری اسکیزوفرنی از روی سیگنال EEG در تشخیص و درمان به‌موقع این بیماری اثربخش است. برتری مدل پیشنهادی نسبت به کارهای گذشته در استفاده از روشی مبتنی بر یادگیری عمیق است که به استخراج ویژگی‌های بهتر از داده‌ها و بهبود شرایط یادگیری و عملکرد مدل منجر می‌شود.

مقاله حاضر شامل بخش‌های زیر است: مرور اجمالی بر کارهای گذشته و روش‌های استفاده‌شده در این زمینه، معرفی داده مورد مطالعه در این پژوهش و نرمال‌سازی داده و آماده‌سازی آن برای ورود به مدل پیشنهادی، معرفی مدل پیشنهادی مبتنی بر یادگیری عمیق که مدل ترکیبی از شبکه‌های بازگشتی و کانولوشنی است، ارائه نتایج مدل پیشنهادی و در نهایت بخش آخر به نتیجه‌گیری می‌پردازد.

۲- مروری بر کارهای پیشین

در سال‌های اخیر متخصصین هوش مصنوعی و پزشکان با همکاری یکدیگر گام‌های بزرگی در تشخیص و پیش‌بینی بیماری‌های مختلف مغزی با استفاده از تجزیه و تحلیل سیگنال‌های EEG برداشته‌اند. الگوریتم‌های یادگیری ماشین و روش‌های یادگیری عمیق از جمله ابزارهایی هستند که استفاده شده‌اند.

⁷ Support Vector Machine (SVM)

⁸ Logistic Regression

⁹ Random Forest

¹⁰ Automatic Diagnostic Tool

¹ Speech Recognition

² Natural Language Processing (NLP)

³ Band Power

⁴ Autoregressive Model (AR)

⁵ Fractal Dimension

⁶ Latent Dirichlet Allocation (LDA)

چاله^۶ (BH)، جست‌وجوی کرم^۷ (GS)، فلورا مصنوعی^۸ (AF) و جست‌وجوی میمون^۹ (MS) و استفاده از مدل SVM-RBF به دقت ۹۲/۱۷٪ در تشخیص بیماری اسکیزوفرنی دست یافتند (Prabhakar, 2020).

کریشان و همکاران در سال ۲۰۲۰ روش تحلیل چند متغیره سیگنال‌های EEG را برای تشخیص اسکیزوفرنی به کاربرند؛ آن‌ها با استفاده از روش تجزیه حالت تجربی چند متغیره^{۱۱} (MEMD) سیگنال‌های EEG را به سیگنال‌های توابع مد داخلی (IMF) تجزیه نمودند؛ سپس از ۵ معیار آنتروپی برای تفکیک سیگنال افراد بیمار و سالم به روش یادگیری ماشین SVM استفاده کردند؛ بهترین دقت به دست آمده ۹۳ درصد بود (Krishnan, 2020).

اسلان و همکاران در سال ۲۰۲۰، یک شبکه CNN از نوع vgg-16 را برای تشخیص خودکار اسکیزوفرنی ارائه دادند؛ آن‌ها، به جای استفاده از سیگنال‌های EEG به عنوان ورودی، نخست داده EEG را با استفاده از تبدیل فوریه به فضای دوبعدی فرکانس- زمان بردند؛ سپس با استفاده از یک شبکه عصبی کانولوشنال با معماری vgg-16 به دقت‌های ۹۵ و ۹۷ درصد رسیدند؛ در این مقاله دودسته داده استفاده شد، دسته اول را مولفان ثبت کردند و دسته دوم داده^{۱۰} موسسه ورشو در لهستان (Oh S. L., 2019) بود (Aslan, 2020).

شالاب و همکاران در سال ۲۰۲۰ با کار روی داده^{۱۱} موسسه ورشو در لهستان (Oh S. L., 2019) و استفاده از ایده^{۱۲} یادگیری انتقالی^{۱۱}، ابتدا سیگنال‌های EEG با استفاده از یک روش زمان-فرکانس به نام روش تبدیل موجک پیوسته^{۱۲} به تصاویر تبدیل کردند. سپس، تصاویر سیگنال‌های EEG روی چهار شبکه CNN

۱۴ ویژگی اصلی بر اساس اهمیت مشخص گردید. در نهایت، یک روش طبقه‌بندی سیگنال با درخت تصمیم^۱، تحلیل خطی-مشخص^۲، k- نزدیک‌ترین همسایه^۳ (KNN)، شبکه عصبی احتمالی^۴ و SVM با هسته‌های مختلف اجرا شد. نتایج نشان داد که SVM در مقایسه با سایر طبقه‌بندی کننده‌های پیاده‌سازی شده در این کار، مقدار متوسط دقت بهتری دارد. میانگین دقت این طبقه‌بند ۹۱/۹۲٪ گزارش شد (Jahmunah, 2019).

یان و همکاران در سال ۲۰۱۹، از تصویرهای MRI عملکردی^۵ (fMRI) مغزی به عنوان داده برای تشخیص اسکیزوفرنی استفاده کردند؛ آن‌ها از شبکه‌های عصبی بازگشتی (RNN) برای تفکیک ۵۵۸ بیمار اسکیزوفرنی از ۵۴۲ فرد سالم استفاده نمودند؛ آن‌ها برای بهبود نتایج، استراتژی leave-on-IC-out looping را به کاربردند تا مولفه‌های مستقلی که نقش بیشتری در تفکیک دارند را شناسایی و استفاده کنند؛ دقت‌های به دست آمده در این مطالعه ۸۳/۲٪ و ۸۰/۲٪ درصد به ترتیب برای روش‌های ارزیابی Multi-site pooling و Leave-one-site-out بود (Yan, 2019).

لی و همکاران در سال ۲۰۱۹ دو مدل شبکه کانولوشن عمیق^{۱۱} لایه‌ای را برای تشخیص خودکار بیماری اسکیزوفرنی معرفی و پیاده‌سازی کردند؛ آن‌ها سیگنال‌های EEG ضبط شده از ۱۴ فرد سالم و ۱۴ فرد مبتلا به اسکیزوفرنی در انستیتو ورشو در لهستان را استفاده کردند و در نهایت به دقت‌های قابل توجه ۹۸/۰۷٪ و ۸۱/۲۶٪ دست یافتند (Oh S. L., 2019).

سانیل کومار و همکاران در سال ۲۰۲۰ با استخراج ویژگی از داده‌های EEG ضبط شده در ورشو لهستان (Oh S. L., 2019) و انتخاب بهترین ویژگی‌ها با بهره‌گیری از روش‌های بهینه‌یابی سیاه

⁸ Artificial Flora (AF)

⁹ Monkey Search (MS)

¹⁰ Multivariate Empirical Mode Decomposition

¹¹ Transfer Learning

¹² Continuous Wavelet Transform

¹ Decision Tree

² Linear Discriminant Analysis

³ K-nearest Neighbors (KNN)

⁴ Probabilistic Neural Network

⁵ Functional MRI (fMRI)

⁶ Black Hole (BH)

⁷ Glowworm Search (GS)

بر اساس سیگنال‌های EEG کار می‌کند. به‌تازگی، محققان از ترکیب سیگنال‌های EEG با سیگنال‌های دیگر برای بهبود عملکرد سیستم‌های BCI استفاده کرده‌اند. در میان این سیگنال‌ها، ترکیب EEG با fNIRS به نتایج مطلوبی دست‌یافته است. در اکثر مطالعات، فقط EEG یا fNIR ها به‌عنوان توالی‌های زنجیره‌ای در نظر گرفته شده‌اند و همبستگی پیچیده‌ای بین سیگنال‌های مجاور را در زمان و مکان کانال در نظر نمی‌گیرند. قنچی و همکاران در سال ۲۰۲۰، یک مدل شبکه عصبی عمیق برای شناسایی اهداف دقیق مغز انسان با معرفی ویژگی‌های زمانی و مکانی معرفی کردند. مدل پیشنهادی شامل ارتباط فضایی بین سیگنال‌های EEG و fNIRS است. این را می‌توان با تبدیل توالی این سیگنال‌های زنجیره‌ای به تنسورهای سه‌درجه‌ای سلسله‌مراتبی پیاده‌سازی کرد. آزمایش‌ها نشان می‌دهد که مدل پیشنهادی آن‌ها دارای دقت ۹۹/۶٪ است (Ghonchi, 2020).

همان‌طور که دیده می‌شود چالش‌هایی هم‌چون رسیدن به دقت بالا، حجم محاسباتی بالا و زمان آموزش بالا در مساله مذکور وجود دارد. در اینجا یک شبکه عصبی عمیق بازگشتی کانولوشنی ارائه می‌شود که سعی در فائق آمدن بر چالش‌های مذکور دارد.

۳- - معرفی داده و پیش‌پردازش

سیگنال‌های EEG استفاده شده در این مقاله، سیگنال‌های جمع‌آوری شده در انستیتو روان‌پزشکی و مغز و اعصاب واقع در شهر ورشو در کشور لهستان است. این سیگنال‌ها شامل سیگنال‌های EEG چهارده بیمار مبتلا به اختلال اسکیزوفرنی، شامل هفت مرد و هفت زن، به ترتیب با میانگین سنی $27/9 \pm 3/3$ و $28/3 \pm 4/1$ سال و سیگنال‌های EEG چهارده فرد سالم در همان گروه سنی و نسبت جمعیتی بودند (Oh S. L., 2019). پانزده دقیقه اطلاعات EEG با سرعت نمونه‌گیری ۲۵۰ هرتز جمع‌آوری شده بود. داده‌ها طبق استاندارد بین‌المللی ۱۰-۲۰

از پیش آموزش دیده محبوب AlexNet, ResNet-18, VGG-19 و Inception-v3 اعمال شدند. خروجی لایه‌های کانولوشن این مدل‌ها به‌عنوان ویژگی‌های عمیق اصلی استفاده و به طبقه‌بندکننده SVM برای طبقه‌بندی افراد سالم و بیمار داده شد. مدل ResNet-SVM به دقت ۹۸/۶٪ در تشخیص بیماری اسکیزوفرنی رسید (Shalhaf, 2020).

شارما و همکاران در سال ۲۰۲۱ از داده‌ی موسسه ورشو در لهستان (Oh S. L., 2019) استفاده کردند؛ آن‌ها با به‌کارگیری روش مبتنی بر موجک، ابتدا سیگنال‌های EEG را طی شش تکرار که منجر به تولید هفت باند فرعی می‌شود، در معرض تجزیه موجک قرار دادند؛ هنجار II برای هر زیر باند محاسبه شد و ویژگی‌های نرمال استخراج شده در روش یادگیری ماشین K نزدیک‌ترین همسایه (KNN) و با روش ارزیابی 10Fold استفاده شد و به دقت قابل‌توجه ۹۹/۲۱٪ رسید (Sharma, 2021).

اکبری و همکاران در سال ۲۰۲۱ با استفاده از سیگنال EEG ضبط شده در انستیتو ورشو لهستان (Oh S. L., 2019) و به کمک روش پویایی فضای باز^۱، ابتدا سیگنال‌های EEG را در فضای دکارتی ترسیم کردند و سپس ۱۵ ویژگی گرافیکی برای ارزیابی رفتار آشفته^۲ بر اساس سالم و اسکیزوفرنی بودن موارد مورد مطالعه، استخراج گردید. همچنین، تعداد قابل‌توجهی از ویژگی‌های برجسته و کانال‌های بهینه توسط الگوریتم انتخاب روبه‌جلو^۳ به دست آمد. در نهایت، هشت طبقه‌بندی‌کننده مختلف برای تشخیص اسکیزوفرنی آزمایش شدند که در این مورد، KNN و شبکه عصبی رگرسیون تعمیم یافته^۴ عملکرد بهتری نسبت به سایرین نشان دادند و متوسط دقت طبقه‌بند KNN بر اساس استراتژی اعتبارسنجی 10Fold، ۹۴/۸٪ گزارش شد (Akbari, 2021).

رابط کامپیوتری مغز^۵ (BCI) یک سیستم قدرتمند برای برقراری ارتباط بین مغز و جهان خارج است. سیستم‌های سنتی BCI فقط

⁴ Generalized Regression Neural Network

⁵ Brain Computer Interface (BCI)

¹ Phase Space Dynamic

² Chaotic Behavior

³ Forward Selection Algorithm

۴- روش پیشنهادی

از آنجاکه ماهیت سیگنال‌های EEG غیرخطی است، اغلب برای تشخیص سیگنال‌های EEG افراد سالم از بیماران اسکیزوفرنی تکنیک‌های استخراج ویژگی‌های غیرخطی استفاده می‌شود (Hornero, 2006). یادگیری ماشین عمدتاً برای تشخیص الگو استفاده می‌شود. با این حال، این تکنیک پیشرفته ضعف‌هایی نیز دارد. به عنوان مثال برای کارهای ساده تشخیص، الگوریتم‌های یادگیری ماشین خوب عمل می‌کند، اما زمانی که تنوع ویژگی‌های مورد مطالعه زیاد باشد، مجموعه‌های آموزشی بزرگتری برای تشخیص صحیح نیاز دارند. در مقایسه با تکنیک‌های سنتی یادگیری ماشین، یادگیری عمیق یک مدل با ظرفیت یادگیری به طور قابل ملاحظه‌ای بالاتر ارائه می‌دهد که امکان مطالعه ویژگی‌های سطح بالاتری را از طریق یادگیری داده‌ها از مجموعه داده‌های بزرگ فراهم می‌آورد. در یادگیری عمیق برخلاف تکنیک‌های سنتی یادگیری ماشین، هر دو عمل استخراج ویژگی‌ها و طبقه‌بندی به طور خودکار انجام می‌شود (Acharya, 2017).


حافظه کوتاه بلندمدت^۲ (LSTM) پیکربندی خاصی از شبکه‌های بازگشتی است که مسیریابی ایجاد می‌کند که شیب گرادیان از طریق آن‌ها قادر است در دوره‌های طولانی جریان یابد.

در فرآیند یادگیری، این نوع شبکه‌ها تمایل به تکرار الگوهای مکرر را دارند که از طریق اشتراک‌گذاری متغیرها در تمام مراحل زمانی میسر می‌شود (Xu, 2020).

در این مطالعه، از مدل شبکه عصبی عمیق بازگشتی کانولوشنی ۱۱ لایه استفاده شده است. داده‌های موجود بعد از پیش‌پردازش وارد لایه‌های کانولوشن یک‌بعدی می‌شوند؛ سپس با گذر از لایه‌های بازگشتی، بهترین ویژگی‌ها را استخراج می‌نمایند و بر اساس ویژگی‌های استخراج شده طبقه‌بندی انجام می‌شود.

توجه شود که تفاوت این ساختار با ساختار مقاله مرجع (Oh S., 2019) از جهت آن است که در اینجا شبکه استفاده شده یک شبکه ترکیبی با لایه‌های کانولوشن و لایه‌های بازگشتی است. برای بهبود عملکرد شبکه بازگشتی کانولوشن عمیق ۱۱ لایه، dropout

جمع‌آوری شده بودند. هر الکتروود یک حرف اختصاصی دارد: F برای لوب پیشانی، P برای لوب آهینانه‌ای، O برای لوب پس سری، T برای لوب گیجگاهی و Z برای خط میانی. لوب‌های مختلف مغز مسئول اعمال خاصی مانند زبان، حافظه و کلام هستند. الکتروودهای Cz, C3, T3, F8, F4, Fz, F3, F7, Fp2, Fp1, C4, T4, T5, P3, Pz, P4, T6, O1 و O2 استفاده شده بودند و محل قرارگیری این الکتروودها روی سر طبق استاندارد ۲۰-۱۰ مطابق شکل (۱) بود. سیگنال‌های به دست آمده به بخش‌هایی تقسیم شدند که در آن بخش‌ها می‌توان سیگنال‌ها را ثابت در نظر گرفت. طول پنجره^۱ هر بخش ۲۵ ثانیه و شامل ۶۲۵۰ نمونه بود.



شکل (۱): محل قرارگیری الکتروودها (استاندارد ۲۰-)

(Prabhakar, ۲۰۲۰) (۱۰)

قبل از تغذیه شبکه پیشنهادی برای آموزش، داده‌ها با استفاده از روش استانداردسازی Z-score نرمال شدند. از ۱۱۴۲ بخش EEG شامل ۵۱۶ بخش از افراد سالم و ۶۲۶ بخش از افراد مبتلا به اسکیزوفرنی استفاده شد که هر بخش ۱۹×۶۲۵۰ نقطه نمونه برداری داشت.

از نرمال‌سازی برای مقیاس‌گذاری سیگنال‌ها در محدوده استاندارد از مقادیر استفاده شد. در استانداردسازی Z-score برای پیشگیری از رخداد مشکل بیش‌برازش^۱، داده‌ها به مقادیر دارای میانگین صفر و واریانس یک آورده می‌شوند. شکل (۲)، نمونه سیگنال فرد سالم و بیمار را مقایسه می‌کند.

² Long-Short Term Memory (LSTM)

¹ Overfitting

(۱) یک مدل شبکه عصبی بازگشتی کانولوشن عمیق ۱۱ لایه برای ارزیابی دقیق بیماران اسکیزوفرنی در مقابل گروه افراد سالم ارائه شده است.

(۲) مدل پیشنهادی فرآیندهای استخراج و انتخاب بهترین ویژگی‌ها و طبقه‌بندی را به‌طور خودکار در لایه‌های کانولوشن و LSTM انجام می‌دهد.


(۳) ارزیابی مدل با تکنیک 10Fold بسیار معتبر است.

(۴) دقت بالا با حجم داده‌های کوچک صحت عملکرد سیستم را تأیید می‌کند.


جدول (۱): جزئیات مدل پیشنهادی

Layers	Filter	Kernel Size	Stride	Activation
Conv 1D	5	10	1	LeakyRelu
Max pooling	-	2	2	-
Conv 1D	10	10	1	LeakyRelu
Max pooling	-	2	2	-
Conv 1D	10	10	1	LeakyRelu
Max pooling	-	2	2	-
Conv 1D	15	5	1	LeakyRelu
Max pooling	-	2	2	-
LSTM	30	1	-	-
Dropout	-	-	Rate=0.5	-
LSTM	20	1	-	-
Dropout	-	-	Rate=0.5	-
Dense	1	-	-	Softmax

به لایه‌های ۹ و ۱۰، با میزان ۵۰ درصد (به این معنی که با احتمال ۵۰ درصد، یک نرون در حین آموزش خارج می‌شود) اعمال شده است. پارامترهای بهینه‌سازی آدام، با میزان یادگیری ۰/۰۰۰۱ به‌کاررفته است و تابع فعال‌ساز برای لایه‌های ۱، ۳، ۵ و ۷، واحد خطی یک‌سوساز^۱ و برای لایه آخر (به‌منظور طبقه‌بندی)، تابع softmax استفاده شده است. جزئیات مدل پیشنهادی در جدول (۱) آمده است. سایر پارامترهای مدل پیشنهادی با آزمون و خطا به‌دست‌آمده آمده‌اند. شبکه پیشنهادی در این مقاله، با زبان برنامه‌نویسی پایتون و در محیط گوگل کولب پیاده‌سازی و اجرا شده است.



الف) فرد سالم



ب) فرد بیمار

شکل (۲): سیگنال مغزی (الف) فرد سالم (ب) بیمار اسکیزوفرنی

ویژگی‌های اصلی سیستم پیشنهادی عبارتند از:

¹ LeakyRelu

جدول (۴)، روش پیشنهادی را با روش‌های پیشین انجام‌شده روی مجموعه داده ورشو (Oh S. L., 2019) که تنها مجموعه داده موردبررسی در این مقاله بوده است، مقایسه می‌کند.

جدول (۲): نتایج طبقه‌بندی مدل پیشنهادی بر اساس تعداد fold

Fold	Accuracy %	PPV %	Sensitivity %	Specificity %
1	98.77	98.57	99.19	98.25
2	99.03	99.52	98.71	99.41
3	99.12	99.36	99.04	99.22
4	98.15	98.43	98.24	98.05
5	99.03	99.21	99.03	99.03
6	98.42	98.42	98.72	98.05
7	99.12	99.68	98.72	99.61
8	98.77	99.22	98.55	99.02
9	99.03	99.36	98.87	99.22
10	98.50	99.05	98.24	98.82

دیده می‌شود روش‌های مبتنی بر یادگیری عمیق به دلیل انتخاب خودکار ویژگی‌ها، ویژگی‌های موثرتری را استخراج کردند که منجر به عملکرد بهتر مدل در تفکیک نمونه سالم از بیمار شده است و به‌طور خاص روش پیشنهادی این مقاله به دلیل بهره‌گیری از خاصیت شبکه‌های بازگشتی، دقت طبقه‌بندی بالاتری در مقایسه با روش‌های مبتنی بر یادگیری ماشین و شبکه‌های کانولوشنی دارد.

۵- آزمایش‌ها

در این مقاله از روش ارزیابی KFold برای ارزیابی روش پیشنهادی استفاده شده است. در ارزیابی مدل پیشنهادی، ۲۰ درصد از داده‌های آموزش برای اعتبارسنجی استفاده شده است. هر دوره از آموزش مدل پیشنهادی در طی ۷۰ تکرار صورت گرفته است که هر تکرار بین ۲ تا ۵ ثانیه زمان برده است که در مقایسه با مقاله مرجع (Oh S. L., 2019) که برای هر تکرار زمان ۲ تا ۳ ثانیه را گزارش داده‌اند، زمان بیشتری دارد.

در مدل پیشنهادی از روش ارزیابی 10-Times 10-Fold استفاده شده است که به نتایج اعتبار بهتری می‌دهد و در مقایسه با روش‌های پیشین مدل پیشنهادی دوره آموزش طولانی‌تری را طی کرده است.


معیارهای ارزیابی دقت (Accuracy)، حساسیت (Sensitivity)، خاصیت (Specificity) و مقدار پیش‌بینی شده مثبت (PPV) که به ترتیب از روابط زیر قابل محاسبه هستند، به‌کار رفته‌اند:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۱)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (۲)$$

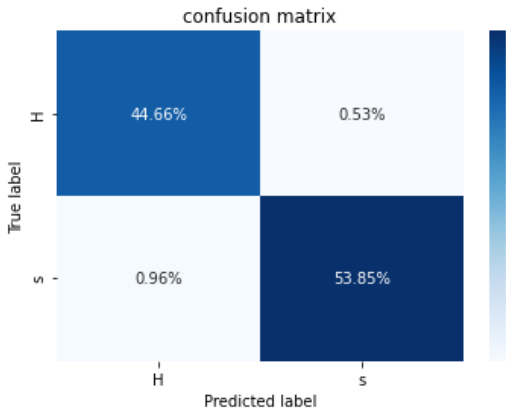
$$Specificity = \frac{TN}{TN + FP} \quad (۳)$$

$$PPV = \frac{TP}{TP + FP} \quad (۴)$$

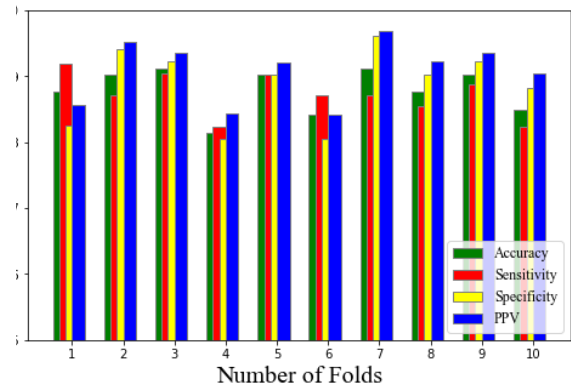


شکل (۳): دقت آموزش مدل ارائه‌شده در تکرارهای متوالی

¹ Positive Predictive Value (PPV)



شکل (۵): ماتریس ابهام مدل پیشنهادی



شکل (۴): میانگین نتایج معیارهای ارزیابی مدل پیشنهادی

جدول (۳): خلاصه مطالعات برای طبقه‌بندی اسکیزوفرنی با استفاده از سیگنال EEG

نویسندگان	تعداد ویژگی‌ها	تکنیک	داده	دقت طبقه بند
کیم و همکاران (Kim, 2015)	-	<ul style="list-style-type: none"> قدرت طیفی EEG با تبدیل سریع فوری با استفاده از MATLAB (متغیرهای متغیر) محاسبه می‌شود. باند فرکانس دلتا، تتا، آلفا و بتا مورد تجزیه و تحلیل قرار گرفت. تجزیه و تحلیل واریانس 	<p>نرمال: نمونه ۹۰ فرد سالم</p> <p>اسکیزوفرنی: نمونه ۹۰ فرد مبتلا به اختلال اسکیزوفرنی</p>	<p>در باند فرکانسی دلتا</p> <p>٪۶۲/۲۰</p>
سانتوس و همکاران (Santos-Mayo, 2016)	۲۰ ویژگی از هر نمونه	<ul style="list-style-type: none"> سیگنال‌های مغزی P3b زمان، ویژگی‌های دامنه فرکانس گروه‌بندی کانال‌ها طبقه‌بندی کننده‌های SVM و پرسپترون چندلایه (MLP) 	<p>نرمال: نمونه ۳۱ فرد سالم</p> <p>اسکیزوفرنی: نمونه ۱۶ فرد مبتلا به اختلال اسکیزوفرنی</p>	<p>در روش MLP</p> <p>٪۹۸/۴۲</p> <p>در روش SVM</p> <p>٪۹۳/۲۳</p>
روش ارائه شده	-	<ul style="list-style-type: none"> شبکه عصبی بازگشتی کانولوشنی عمیق ۱۱ لایه ارزیابی با روش 10Fold 	<p>نرمال: نمونه ۱۴ فرد سالم</p> <p>اسکیزوفرنی: نمونه ۱۴ فرد مبتلا به اختلال اسکیزوفرنی</p>	٪۹۸/۷۹

و انتخاب ویژگی و طبقه‌بندی را به‌طور خودکار در لایه‌های کانولوشن و LSTM انجام می‌دهد. حافظه‌دار بودن شبکه‌های LSTM و ساختار مناسب آن‌ها ویژگی‌های لازم برای تشخیص بیماری اسکیزوفرنی را فراهم آورد. استخراج ویژگی به‌صورت

۶- نتیجه‌گیری

در این مقاله به تشخیص بیماری اسکیزوفرنی از روی سیگنال‌های EEG پرداخته شد. مدل پیشنهادی این مقاله فرآیندهای استخراج



جدول (۴): خلاصه مطالعات برای طبقه‌بندی اسکیزوفرنی با استفاده از مجموعه داده ورشو لهستان (Oh S. L., ۲۰۱۹)

نویسندگان	تعداد ویژگی‌ها	تکنیک	داده	دقت طبقه بند
جاهمونا و همکاران (Jahmunah, 2019)	۱۴ ویژگی	▪ تقسیم سری EEG ▪ استخراج و انتخاب ویژگی با آزمون t ▪ مدل SVM-RBF	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	٪۹۱/۹۲
لی و همکاران (Oh S. L., 2019)	-	▪ شبکه عصبی کانولوشنی عمیق ۱۱ لایه ▪ ارزیابی با روش 10Fold ▪ شبکه عصبی کانولوشنی عمیق ۱۱ لایه ▪ ارزیابی با روش 14Fold	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	▪ در شبکه اول ٪۹۸/۰۷ ▪ در شبکه دوم ٪۸۱/۳۶
اسلان و همکاران (Aslan, 2020)	-	▪ تبدیل فوری برای تبدیل سیگنال به تصویر ▪ مدل vgg16	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	٪۹۷
شالباف و همکاران (Shalbfaf, 2020)	-	▪ تبدیل موجک برای تبدیل سیگنال به تصویر ▪ مدل ResNet-SVM	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	٪۹۸/۶
اکبری و همکاران (Akbari, 2021)	۱۵ ویژگی	▪ ترسیم سیگنال در فضای دکارتی ▪ استخراج ویژگی گرافیکی برای ارزیابی رفتار آشفته ▪ مدل KNN	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	٪۹۴/۸
روش ارائه شده	=	▪ شبکه عصبی بازگشتی کانولوشنی عمیق ۱۱ لایه ▪ ارزیابی با روش 10Fold	نرمال: نمونه ۱۴ فرد سالم اسکیزوفرنی: نمونه ۱۴ فرد مبتلابه اختلال اسکیزوفرنی	٪۹۸/۷۹

این مقاله با مجموعه داده بزرگتری از اسکیزوفرنی مانند مجموعه داده اسکیزوفرنی موجود در سایت کگل که با ۶۴ الکتروود ضبط شده است و در مجموع نمونه‌های ۸۱ فرد سالم و بیمار را دربردارد. بررسی صحت عملکرد مدل پیشنهادی این مقاله بر روی مجموعه داده‌های سایر ناهنجاری‌های مغزی مانند پارکینسون، اتیسم، آلزایمر، افسردگی و اختلالات خواب. بدین ترتیب می‌توان عملکرد روش پیشنهادی در تشخیص سایر عارضه‌های روانی را ارزیابی نمود.

خودکار یکی از مزایای این روش است که به بهبود عملکرد مدل نیز کمک می‌کند. علیرغم وجود مجموعه داده کوچک مورد ارزیابی در این پژوهش، صحت طبقه‌بندی بالا (٪۹۸/۷۹) نشان داد که تکنیک پیشنهادی می‌تواند به‌عنوان ابزاری قابل‌اعتماد در تشخیص خودکار اختلال روانی اسکیزوفرنی توسط پزشکان مورد استفاده و استناد قرار بگیرد.

با توجه به تحقیقات اخیر و نتایج به‌دست‌آمده، موارد زیر برای ادامه این پژوهش پیشنهاد می‌گردد: بررسی عملکرد مدل پیشنهادی



Decomposition and entropy measures from multichannel EEG signal. *Biocybernetics and Biomedical Engineering*, 40(3), 1124-1139.

- [11] Aslan, Z., & Akın, M. (2020). Automatic detection of schizophrenia by applying deep learning over spectrogram images of EEG signals.
- [12] Sharma, M., & Acharya, U. R. (2021). Automated detection of schizophrenia using optimal wavelet-based l_1 norm features extracted from single-channel EEG. *Cognitive Neurodynamics*, 15(4), 661-674.
- [13] Akbari, H., Ghofrani, S., Zakalvand, P., & Sadiq, M. T. (2021). Schizophrenia recognition based on the phase space dynamic of EEG signals and graphical features. *Biomedical Signal Processing and Control*, 69, 102917.
- [14] Ghonchi, H., Fateh, M., Abolghasemi, V., Ferdowsi, S., & Rezvani, M. (2020). Deep recurrent-convolutional neural network for classification of simultaneous EEG-fNIRS signals. *IET Signal Processing*, 14(3), 142-153.
- [15] Hornero, R., Abásolo, D., Jimeno, N., Sánchez, C. I., Poza, J., & Aboy, M. (2006). Variability, regularity, and complexity of time series generated by schizophrenic patients and control subjects. *IEEE Transactions on Biomedical Engineering*, 53(2), 210-218.
- [16] Acharya, U. R., Fujita, H., Lih, O. S., Adam, M., Tan, J. H., & Chua, C. K. (2017). Automated detection of coronary artery disease using different durations of ECG segments with convolutional neural network. *Knowledge-Based Systems*, 132, 62-71.
- [17] Xu, S., Wang, Z., Sun, J., Zhang, Z., Wu, Z., Yang, T., ... & Cheng, C. (2020). Using a deep recurrent neural network with EEG signal to detect Parkinson's disease. *Annals of translational medicine*, 8(14).
- [18] Kim, J. W., Lee, Y. S., Han, D. H., Min, K. J., Lee, J., & Lee, K. (2015). Diagnostic utility of quantitative EEG in un-medicated schizophrenia. *Neuroscience letters*, 589, 126-131.
- [19] Santos-Mayo, L., San-José-Revuelta, L. M., & Arribas, J. I. (2016). A computer-aided diagnosis system with EEG based on the P3b wave during an auditory odd-ball task in schizophrenia. *IEEE transactions on biomedical engineering*, 64(2), 395-407.

References

- [1] Oh, J., Oh, B. L., Lee, K. U., Chae, J. H., & Yun, K. (2020). Identifying schizophrenia using structural MRI with a deep learning algorithm. *Frontiers in psychiatry*, 11, 16.
- [2] Oh, S. L., Vicnesh, J., Ciaccio, E. J., Yuvaraj, R., & Acharya, U. R. (2019). Deep convolutional neural network model for automated diagnosis of schizophrenia using EEG signals. *Applied Sciences*, 9(14), 2870.
- [3] Shalbaf, A., Bagherzadeh, S., & Maghsoudi, A. (2020). Transfer learning with deep convolutional neural network for automated detection of schizophrenia from EEG signals. *Physical and Engineering Sciences in Medicine*, 43(4), 1229-1239.
- [4] Siuly, S., Khare, S. K., Bajaj, V., Wang, H., & Zhang, Y. (2020). A computerized method for automatic detection of schizophrenia using EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(11), 2390-2400.
- [5] Boostani, R., Sadatnezhad, K., & Sabeti, M. (2009). An efficient classifier to diagnose of schizophrenia based on the EEG signals. *Expert Systems with Applications*, 36(3), 6492-6499.
- [6] Srinivasagopalan, S., Barry, J., Gurupur, V., & Thankachan, S. (2019). A deep learning approach for diagnosing schizophrenic patients. *Journal of Experimental & Theoretical Artificial Intelligence*, 31(6), 803-816.
- [7] Jahmunah, V., Oh, S. L., Rajinikanth, V., Ciaccio, E. J., Cheong, K. H., Arunkumar, N., & Acharya, U. R. (2019). Automated detection of schizophrenia using nonlinear signal processing methods. *Artificial intelligence in medicine*, 100, 101698.
- [8] Yan, W., Calhoun, V., Song, M., Cui, Y., Yan, H., Liu, S., ... & Sui, J. (2019). Discriminating schizophrenia using recurrent neural network applied on time courses of multi-site fMRI data. *EBioMedicine*, 47, 543-552.
- [9] Prabhakar, S. K., Rajaguru, H., & Kim, S. H. (2020). Schizophrenia EEG signal classification based on swarm intelligence computing. *Computational Intelligence and Neuroscience*, 2020.
- [10] Krishnan, P. T., Raj, A. N. J., Balasubramanian, P., & Chen, Y. (2020). Schizophrenia detection using Multivariate Empirical Mode

Diagnosis of schizophrenia based on electroencephalogram signal using deep learning

Maryam Allahyari ¹, Fatemeh Jamshidi ^{2*}

¹ Department of Computer Engineering, Faculty of Technical and Engineering, Yazd University, Yazd, Iran

² Assistant Professor, Department of Electrical Engineering, Faculty of Engineering, Fasa University, Fasa, Iran

Article Information

Original Research Paper

Received:

2022 May 19

Accepted:

2022 October 29

Keywords:

Schizophrenia, Electroencephalogram, Deep neural networks, Deep learning

Corresponding Author*:

jamshidif59@yahoo.com

Abstract

Schizophrenia is a disorder of the brain in which people misinterpret reality. This mental disorder is characterized by behavioral symptoms such as hallucinations and speech disorders. Electroencephalogram (EEG) signal indicates brain disorders and is widely used to study brain diseases. The aim of this article is to automatically detect schizophrenia based on the EEG signal. A common method in research is the manual extraction of features from the EEG signal. Because deep learning algorithms have the ability to automatically extract important features and classify them, in this study, in order to extract more useful features, the EEG signal was applied to an eleven-layer convolutional deep recursive neural network. The EEG signals collected at the Warsaw Institute from 14 healthy individuals and 14 patients with schizophrenia are studied here. The mean values of the accuracy evaluation criteria of the model including Accuracy, Sensitivity, Specificity and PPV for the proposed model were 98.79%, 98.73%, 98.86% and 99.06%, respectively, which improved the performance of the proposed model for classifying schizophrenic patients and approves healthy people compared to previous models. The proposed model can be used as a diagnostic tool to help physicians diagnose the early stages of schizophrenia.