

Parkinson's diagnosis from EEG signal spectrogram based on optimized deep features

Zahra Hekmati¹, *MSc student*, Mohammad Sajedipour¹, *MSc student*, Zahra Moradineghad¹,
MSc Student

¹ Department of Electrical and Computer Engineering, Kazerun Branch, Islamic Azad University,
Kazerun, Iran

zahrahekmati.bme@gmail.com

mehmetsajedipour@gmail.com

radmanesharmis@gmail.com

Received: 16 March 2024	Revised: 27 July 2024	Accepted: 28 July 2024
-------------------------	-----------------------	------------------------

Abstract:

Parkinson's disease (PD) is a progressive disorder of the nervous system that affects movement. Symptoms begin gradually, sometimes with just a small tremor in one hand that is barely noticeable. In addition to tremors, which are very common, the disorder also usually causes stiffness or slowness of movement. One way to diagnose Parkinson's disease is electroencephalography, which records brain information and diagnoses the disease. Deep learning methods are the most important and common methods for automatic diagnosis without manual intervention. In this paper, using a deep learning method based on a convolutional neural network, features are extracted from the EEG signal spectrogram and then optimized by selecting the best features. Two modes are used to do this: a) 1000 features extracted and top 10 features b) 1000 features extracted and top 20 features, then the modes were examined for diagnosing Parkinson's disease and the necessary simulations were performed. After evaluation, it was concluded that in the second mode (extraction of top 20 features), the support vector machine classification achieved better results with an accuracy of 97.33% for diagnosing Parkinson's than the first mode and the other classifiers. The results indicate that the proposed method is a suitable and efficient method for diagnosing Parkinson's disease using EEG signals.

Keywords: Parkinson's disease, convolutional neural network, deep learning, EEG signal.

Corresponding Author: Zahra Hekmati

Corresponding Author Address: Department of Electrical and Computer Engineering- Mellat Blvd.
-Islamic Azad University- Kazerun Branch, Iran.

تشخیص پارکینسون از اسپکتوگرام سیگنال EEG مبتنی بر ویژگی‌های عمیق بهینه شده

زهرا حکمتی^۱، دانشجوی کارشناسی ارشد، محمد ساجدی پور^۱، دانشجوی کارشناسی ارشد، زهرا مرادی نژاد^۱، دانشجوی کارشناسی ارشد

۱- دانشکده مهندسی برق و کامپیوتر، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران

zahrahekmati.bme@gmail.com

mehmetsajedipour@gmail.com

radmanesharmis@gmail.com

تاریخ پذیرش مقاله: ۱۴۰۳/۰۵/۰۷

تاریخ بازنگری مقاله: ۱۴۰۳/۰۵/۰۶

تاریخ ارسال مقاله: ۱۴۰۲/۱۲/۲۶

چکیده: بیماری پارکینسون (PD) نوعی اختلال پیشرونده سیستم عصبی است که بر روی حرکت تأثیر می‌گذارد. در این بیماری، علائم به تدریج شروع شده و گاهی اوقات تنها با یک لرزش کوچک در یک دست، که فرد به سختی متوجه آن می‌شود، آغاز می‌گردد. علاوه بر لرزش‌ها که بسیار رایج هستند، این اختلال معمولاً باعث خشکی یا کند شدن حرکت نیز می‌شود. یکی از راه‌های تشخیص بیماری پارکینسون الکتروانسفالوگرافی می‌باشد که اطلاعات مغزی را ثبت کرده و به تشخیص بیماری می‌پردازد. روش‌های یادگیری عمیق مهمترین و متداولترین روش‌ها برای تشخیص خودکار بدون دخالت دست می‌باشند. در این مقاله با استفاده از روش یادگیری عمیق بر مبنای شبکه عصبی کانولوشن ویژگی‌ها را از اسپکتوگرام سیگنال EEG استخراج کرده سپس با انتخاب ویژگی‌های برتر به بهینه کردن ویژگی‌ها پرداخته است، که برای انجام این امر از دو حالت استفاده می‌شود: الف) ۱۰۰۰ ویژگی استخراج شده و ۱۰ ویژگی برتر ب) ۱۰۰۰ ویژگی استخراج شده و ۲۰ ویژگی برتر، سپس به بررسی حالت‌ها برای تشخیص بیماری پارکینسون پرداخته شده و شبیه‌سازی‌های لازم انجام گردید و پس از ارزیابی، به این نتیجه دست یافتیم که در حالت دوم (استخراج ۲۰ ویژگی برتر)، طبقه‌بندی ماشین بردار پشتیبان با صحت ۹۷/۳۳٪ برای تشخیص پارکینسون نسبت به حالت اول و بقیه طبقه‌بندی‌کننده‌ها به نتایج بهتری دست یافت. نتایج بدست آمده حاکی از آن است که روش پیشنهادی، روشی مناسب و کارآمد برای تشخیص بیماری پارکینسون با استفاده از سیگنال EEG می‌باشد.

کلمات کلیدی: بیماری پارکینسون، شبکه عصبی کانولوشن، یادگیری عمیق، سیگنال EEG

نام نویسنده‌ی مسئول: زهرا حکمتی

نشانی نویسنده‌ی مسئول: کازرون- بلوار ملت- دانشگاه آزاد اسلامی واحد کازرون- دانشکده مهندسی برق و کامپیوتر

۱- مقدمه

بیماری پارکینسون (PD) یک اختلال عصبی است که به طور عمده بر نورون‌های تولیدکننده دوپامین (دوپامینرژیک) در ناحیه‌ای خاص از مغز به نام ماده سیاه (سابستانتیا نیگرا) اثر می‌گذارد. دوپامین نقش مهمی در تنظیم حرکت بدن دارد و کاهش آن می‌تواند علت بسیاری از علائم این بیماری باشد. علت دقیق بروز این عارضه هنوز به طور کامل مشخص نیست، اما اکثر پژوهشگران بر این باورند که ترکیبی از عوامل ژنتیکی و محیطی در ایجاد آن نقش دارند [۱].

سیگنال افراد مبتلا به پارکینسون و افراد سالم به صورت آزاد در برخی پایگاه‌ها در دسترس هستند و در این پژوهش با توجه به نیاز، داندلود خواهند شد. از آنجا که سیگنال EEG ماهیتی ناپایستا دارد، تحلیل آن در حوزه زمان-فرکانس می‌تواند ویژگی‌های سیگنال را با دقت بیشتری آشکار کند. بنابراین، از اسپکتروگرام برای استخراج ویژگی‌های مربوط به تشخیص بیماران مبتلا به پارکینسون استفاده می‌شود [۲]. سیگنال EEG داندلودشده به حوزه زمان-فرکانس منتقل شده و با استفاده از تبدیل فوریه کوتاه‌مدت (STFT) به یک سیگنال دوبعدی تبدیل می‌گردد. سپس اسپکتروگرام حاصل، خصوصیات سیگنال را در طول زمان و در فرکانس‌های مختلف نمایش می‌دهد. اسپکتروگرام‌ها می‌توانند به صورت نمودارهای دوبعدی با متغیر رنگی یا نمودارهای سه‌بعدی همراه با یک متغیر رنگی چهارم ترسیم شوند. برای تولید اسپکتروگرام، ابتدا سیگنال حوزه زمان به بخش‌های کوتاه با طول مساوی تقسیم شده و سپس برای هر بخش، تبدیل فوریه سریع (FFT) محاسبه می‌شود. پارامتر Frame Count تعداد FFT‌های مورد استفاده را مشخص کرده و در نتیجه میزان سیگنال زمانی که به بخش‌های مستقل تقسیم می‌شود را تعیین می‌کند.

پس از این مرحله، اسپکتروگرام سه‌بعدی به یک شبکه عصبی کانولوشنال (CNN) وارد می‌شود تا ویژگی‌های عمیق استخراج گردند. در این پژوهش، از معماری AlexNet به عنوان CNN استفاده خواهد شد. شبکه‌های عصبی کانولوشنال نوعی از شبکه‌های عصبی مصنوعی (ANN) هستند که عمدتاً برای تحلیل داده‌های تصویری به کار می‌روند. این شبکه‌ها بر اساس معماری وزن مشترک در هسته‌های پیچشی (فیلترها) طراحی شده‌اند و پاسخ‌های حاصل از آن‌ها به صورت نقشه ویژگی ارائه می‌شود. اگرچه انواع مختلفی از معماری CNN وجود دارد، اما AlexNet یکی از متداول‌ترین و پرکاربردترین‌ها است [۳]. AlexNet که از یک CNN هشت‌لایه تشکیل شده است، در سال ۲۰۱۲ با اختلاف زیاد در رقابت تشخیص تصویر ImageNet برنده شد. این شبکه برای نخستین بار نشان داد که ویژگی‌های یادگرفته‌شده توسط شبکه می‌توانند عملکردی فراتر از ویژگی‌های طراحی‌شده به صورت دستی داشته باشند و موجب تغییر پارادایم در بینایی ماشین شوند.

پس از استخراج ویژگی‌ها توسط AlexNet، طبقه‌بندی نهایی با استفاده از الگوریتم ماشین بردار پشتیبان (SVM) انجام خواهد شد. SVM یکی از معتبرترین و پرکاربردترین الگوریتم‌های طبقه‌بندی است که با حجم محدودی از داده نیز عملکرد بسیار خوبی ارائه می‌دهد. هدف این الگوریتم یافتن یک ابرصفحه در فضای N بعدی (N تعداد ویژگی‌ها) است که به طور بهینه داده‌ها را به دو گروه (افراد سالم و بیماران مبتلا به پارکینسون) تفکیک کند [۴].

در نهایت، نتایج طبقه‌بندی SVM با نتایج به‌دست‌آمده از شبکه عصبی مقایسه شده و عملکرد روش‌های مختلف گزارش خواهد شد.

۲- بیان مسأله

بیماری پارکینسون سریع‌ترین اختلال عصبی در حال رشد در سراسر جهان است که هم علائم حرکتی و هم غیرحرکتی مشخص دارد. بیمارانی که دچار عوارض حرکتی می‌شوند ممکن است واجد شرایط تحریک عمیق مغز (DBS) باشند، یک مداخله جراحی تهاجمی که در تسکین عوارض حرکتی و بهبود کیفیت زندگی بسیار موثر است [۶]. علیرغم اثرات خوب بر عملکرد حرکتی و تسکین قابل توجه عوارض حرکتی مقاوم به داروهای خوراکی DBS، علائم شناختی را بهبود نمی‌بخشد و برخی از وخامت‌ها را می‌توان در حوزه‌های شناختی مشاهده کرد [۷]. بنابراین فرآیند غربالگری برای تشخیص مستلزم ارزیابی گسترده‌ای از عملکرد شناختی و عصب روانپزشکی برای رد اختلال شدید قبل از عمل جراحی، به منظور تعیین واجد شرایط بودن بیماری است.


با این حال، ارزیابی دقیق شناخت توسط عواملی مانند وضعیت فکری محدود می‌شود، در حالی که وظایف عملکرد ممکن است در معرض تفسیر نادرست قرار گیرند. اختلال حرکتی، خستگی، اختلال خلقی، استرس و انگیزه شخصی، که ممکن است نتایج را کمتر معتبر کند [۸]. علاوه بر این، غربالگری عصب روانشناختی برای بیماران وقت گیر و استرس زا است. در نتیجه، نیاز به نشانگرهای زیستی جدید برای تکمیل ارزیابی‌های عصبی روانشناختی فعلی وجود دارد. یک ابزار مهم برای چنین ارزیابی‌های تکمیلی، الکتروانسفالوگرافی است که می‌تواند فعالیت مغز را به طور مستقیم و غیر تهاجمی اندازه گیری کند. کاربرد الکتروانسفالوگرافی برای کمک به ارزیابی اختلالات شناختی و حتی پیش‌بینی زوال شناختی قبلاً در جمعیت عمومی استفاده شده است. تشخیص سریع و به موقع و صحیح بیماری بسیار مهم و حائز اهمیت است که روال درمان را سریع و روند بهبود را سریع و ساده و کارآمد تر می‌کند [۹]. از این رو در این مقاله سعی بر آن است که بیماری پارکینسون را توسط سیگنال الکتروانسفالوگرام، با استفاده از ویژگی‌های عمیق تشخیص دهیم.

۳- تحقیقات پیشین مرتبط

درمان پارکینسون شامل رویکردهای دارویی، معمولاً عوامل دوپامینرژیک، و درمان‌های جراحی است. یک مشخصه بارز پاتولوژیک متمایز پارکینسون عدم تقارن تخریب عصبی دوپامینرژیک در شروع آن است که با تظاهرات یک طرفه مشخصه اختلال عملکرد حرکتی همراه است [۱۰]. در [۱۱] مطالعات بر روی بررسی نوسانات حرکتی قشر مغز (به عنوان مثال، نوسانات بتا) در بیماری پارکینسون در طول بیداری متمرکز بودند. آگاهی روزافزونی از رابطه دو طرفه بین خواب و بیماری پارکینسون وجود دارد. شراینر و همکارانش ارتباطی بین SWE بالاتر و پیشرفت حرکتی کندتر پیدا کردند. بررسی‌های متعددی برای تشخیص پارکینسون انجام شده و در [۱۲] با استفاده تحلیل داده‌های MRI بیماری را تشخیص داده اند اما روش‌های مبتنی بر تصویر پردازش و تشخیص، هزینه بر و طاقت فرسا می‌باشند که اگر بتوان این کار را با سیگنال انجام داد بسیار مفید است. روش‌های مبتنی بر ویژگی‌های دستی تشخیص را مبتنی بر نوع و کیفیت ویژگی و وابسته به فرد می‌کند. اما اگر این آمار مبتنی بر مهندسی ویژگی و استخراج خودکار و برتر باشد، فرایند را بسیار ساده و مفید میکند. از این رو سعی بر آن است تا با استفاده از ویژگی‌های عمیق از سیگنال EEG بیماری پارکینسون را تشخیص داده شود.

۴- روش کار

در طول سال‌ها، نقص حرکتی در بیماران مبتلا به بیماری پارکینسون تا حد زیادی مورد مطالعه قرار گرفت، با این حال، هیچ الگوی ثابتی از روابط بین الکتروانسفالوگرافی و پارکینسون بیان نشده است. فقدان کلی اطلاعات در مورد رابطه بین تغییرات EEG و مقیاس‌های مربوط به نقص حرکتی خاص وجود دارد. مطالعه با هدف بررسی رابطه بین تغییرات فعالیت نوسانی مغز (و بیشترین استفاده از مقیاس‌های نقص حرکتی مرتبط با پارکینسون بسیار مورد نیاز است).



شکل (۱): فلورچارت کلی الگوریتم استفاده شده در پژوهش

به همین دلیل رسیدن به روش هایی با صحت بالا و قابلیت اطمینان برای تشخیص بیماری پارکینسون بسیار ضروری است و هر چه این کار سریعتر و دقیقتر انجام گیرد، روند درمان و بهبودی را تسریع می بخشد که گاهی تشخیص و درمان زودتر به مراتب درمان را ساده تر میکند. از این رو در این پژوهش با سیگنال EEG و روشهای ساده بیماری پارکینسون را تشخیص داده شده است. در شکل (۱) فلورچارت کلی برنامه قابل مشاهده است.


۴-۱- پایگاه داده

در این تحقیق از پایگاه داده Mendeley EEG استفاده شده است. این پایگاه داده، مجموعه‌ای معتبر و در دسترس آزاد است که شامل سیگنال‌های مغزی ۱۴۰ بیمار مبتلا به پارکینسون می‌باشد. داده‌ها در واحد نظارت بر پارکینسون در مرکز پزشکی دانشگاه آمریکایی ثبت شده‌اند. ثبت سیگنال‌ها با استفاده از یک سیستم ۲۰ الکترودی و با فرکانس نمونه‌برداری ۵۰۰ هرتز انجام شده است. تمام کانال‌ها در بازه فرکانسی ۱.۶ تا ۷۰ هرتز فیلتر شده‌اند و نویز ناشی از فرکانس ۵۰ هرتز (ابزارهای الکتریکی) نیز حذف شده است. برخی کانال‌ها به دلیل محدودیت‌های ابزار ضبط کنار گذاشته شده‌اند. سیگنال‌ها توسط پزشک متخصص برچسب‌گذاری شده و در پایگاه داده موجود هستند.


این مجموعه داده به صورت چندوجهی شامل الکتروانسفالوگرام (EEG)، الکترومیوگرام (EMG)، الکتروکاردیوگرام (ECG)، هدایت پوست (SC) و شتاب‌سنج (ACC) در حین انجام فعالیت‌های پیاده‌روی ثبت شده‌اند. برای این منظور از یک سیستم سخت‌افزاری تجاری با کیفیت بالا و طراحی اختصاصی استفاده گردید. حسگرها بر اساس یک روش آزمایشی استاندارد طراحی شدند تا امکان ثبت دقیق داده‌ها در محیط بیمارستان فراهم شود. در مجموع، ۱۲ بیمار مبتلا به پارکینسون آزمایش‌ها را تکمیل کردند و ۳ ساعت و ۴۲ دقیقه داده معتبر به دست آمد. بخش‌های مختلف داده‌های چندوجهی توسط دو پزشک واجد شرایط برچسب‌گذاری شدند.

این داده‌ها قابلیت استفاده در تشخیص مؤثر پارکینسون در مقایسه با حرکت طبیعی را دارند و نشان می‌دهند که تغییرات سیگنال‌های حرکتی و الکتروفیزیولوژیکی چندوجهی در دوره‌های مختلف می‌تواند برای هدایت روند درمان و بهبود بیماران پارکینسون به کار گرفته شود. داده‌های خام در قالب فرمت داده‌های اروپایی (EDF) ذخیره شده‌اند که رکوردهای EEG را به دو بخش اطلاعات عنوان و اطلاعات داده تقسیم می‌کند.


برچسب‌گذاری رکوردهای EEG به عنوان داده‌های عادی (۰) و داده‌های مربوط به بیماران پارکینسون (۱) نقش مهمی در کاربردهای یادگیری ماشین دارد. به همین دلیل، داده‌های EEG موجود پردازش و جداسازی شده و به صورت داده‌های سالم یا بیمار برچسب‌گذاری گردیده‌اند. در این تحقیق، از نسخه پردازش‌شده داده‌ها در فرمت متلب (MATLAB) استفاده شده است. شکل ۲ تا ۴ نمونه‌ای از سیگنال EEG نمایش داده شده است.



شکل (۲): نمونه‌ای از سیگنال EEG استفاده شده در الگوریتم پژوهش



شکل (۳): نمونه سیگنال یک ثانیه ای از فرد سالم استفاده شده در الگوریتم پژوهش



شکل (۴): نمونه سیگنال یک ثانیه ای از فرد دارای پارکینسون استفاده شده در الگوریتم پژوهش

۲-۴- پیش پردازش

بعد از دانلود داده ها و برچسب داده ها از سایت معتبر داده ها پنجره گذاری شدند. پنجره ها به صورت نمونه های یک ثانیه ای تفکیک شدند و مورد بررسی قرار گرفته اند. در این قسمت کانال اول برای قسمت آموزش و کانال دوم سیگنال برای آزمایش مورد استفاده قرار گرفت. در جدول (۱) برچسب داده ها قابل مشاهده می باشد.

جدول (۱): برچسب داده ها برحسب نوع سیگنال

نوع سیگنال	برچسب
سیگنال EEG فرد سالم	۰
سیگنال EEG فرد دارای پارکینسون	۱

۳-۴- استخراج ویژگی

در این مقاله ویژگی از باند های فرکانسی سیگنال EEG استخراج گردیده است. EEG روشی برای اندازه گیری فعالیت الکتریکی مغز است. فعالیت الکتریکی مغزی توسط میلیاردها سلول عصبی یا نرون به وجود می آید. سیگنال ثبت شده از روی سطح سر بوده و برآیند ناشی از فعالیت این سلولهای عصبی می باشد. سیستم عصبی مرکزی از دو گروه سلول بنام سلولهای عصبی و سلولهای گلایا تشکیل شده است. دو دسته سیستم ارتباطی برای انتقال پیام و نتیجه پردازش بین سلولهای عصبی

مرکزی وجود دارند. دندریتها و آکسونها وظیفه دریافت و انتقال پیام را به سلولهای مجاور و ارگانهای دیگر بر عهده دارند و محل اتصال دو سلول یعنی تماس آکسون به دندريت سیناپس نامیده می شود. فعالیت الکتریکی یک سلول عصبی از دو دیدگاه پتانسیلهای داخل سلولی و خارج سلولی تحلیل و اندازه گیری می شوند. با در نظر گرفتن سازوکار تولید پتانسیل های میدانی خارج سلولی می توان سیگنال ثبت شده در سطح جمجمه را ناشی از برآیند این پتانسیلهای میدانی موجود در هادی حجمی مغز دانست. با این تفصیل ماهیت آشوبگونه و یا تصادفی سیگنال مغزی بیشتر قابل درک خواهد بود چرا که هر بخش مسئول انجام اعمال خاصی است که در وضعیت های مختلف فعالیت این نواحی متغیر خواهد بود. بنابراین برهم کنش سیگنالهای حاصل از این تحریکات پس سیناپسی در مناطق مختلف مغز از نواحی مختلف جمجمه قابل جمع اوری است و همین امر مفهوم الکتروانسفالوگرافی را بنا نهاده است. دقت زمانی این سیگنال در حد میلی ثانیه بوده و بسیارمطلوب است ولی دقت فضایی خوبی ندارد و به تعداد الکترودها بستگی دارد و به هر حال در حد سانتیمتر است. محدوده دامنه این سیگنال بین ۱۰ تا ۳۰۰ میکرو ولت است. در این مقاله ۳۰۰ نمونه سیگنال EEG از پایگاه داده داندلود شده است. که ۱۴۰ سیگنال مربوط به فرد دارای بیماری پارکینسون و ۱۶۰ سیگنال مربوط به فرد سالم می باشد که به صورت رندوم وارد شبکه عصبی کانولوشن می شود و فرآیند آموزش و آزمایش با نسبت ۷۰٪ به ۳۰٪ بر روی داده ها انجام می شود.

۴-۴- ویژگی های عمیق

در این پروژه، به منظور دستیابی به یک سیستم کاملاً خودکار برای تشخیص بیماری، از ویژگی های عمیق استفاده شده است تا نیازی به دخالت انسان در فرآیند استخراج ویژگی نباشد. بدین ترتیب، کل فرآیند تشخیص می تواند به صورت هوشمند و مستقل انجام شود. برای این منظور، از شبکه عصبی کانولوشنال (CNN) جهت استخراج ویژگی های عمیق از سیگنال های EEG استفاده گردیده است. از آنجا که سیگنال ها به صورت مستقیم قابلیت ورود به شبکه CNN را ندارند، ابتدا باید به تصویر تبدیل شوند. ابزار متداول برای این تبدیل، اسپکتروگرام است که نمایش زمان - فرکانس سیگنال را فراهم می آورد. در اسپکتروگرام، سیگنال حوزه زمان به بخش های کوتاه تقسیم شده و سپس با استفاده از تبدیل فوریه کوتاه مدت (STFT)، به نمایش دوبعدی زمان - فرکانس تبدیل می شود. این نمایش تصویری امکان می دهد تا تغییرات لحظه ای در فرکانس و دامنه سیگنال در طول زمان آشکار گردد. از آنجا که سیگنال های فیزیولوژیکی ماهیتی ناایستا دارند و فرکانس آن ها با گذر زمان تغییر می کند، استفاده از روش های سنتی مبتنی بر فرکانس ثابت، نمی تواند به طور کامل ویژگی های آن ها را توصیف کند. به همین دلیل، STFT به عنوان روشی پیشرفته و مبتنی بر تبدیل فوریه گسسته (DFT) انتخاب شده است تا بتواند همزمان اطلاعات مربوط به فرکانس لحظه ای و دامنه لحظه ای سیگنال را استخراج نماید.

۴-۵- اسپکتروگرام سیگنال

اسپکتروگرام نمایشی از طیف فرکانسی صوت یا دیگر سیگنال هایی است که نسبت به زمان تغییرات زیادی دارند. از اسپکتروگرام می توان برای شناسایی کلمات گفته شده به صورت آوایی و تحلیل آوای مختلف حیوانات استفاده کرد. یکی از کاربردهای بسیار مهم اسپکتروگرام، تحلیل صوت با استفاده از روش های پردازش تصویر می باشد چون در این روش، صوت به صورت تصویر مدل سازی می شود. ما در اینجا از تحلیل اسپکتروگرام سیگنال استفاده کرده و مشخصات زمان فرکانس سیگنال را در قالب تصویر استخراج کردیم. از یک طرف STFT، بر نواقص تبدیل فوریه متداول که فقط دارای رزولوشن فرکانس بدون رزولوشن زمان است، غلبه می کند. از طرف دیگر، از پدیده تداخل باند فرکانسی که در تحلیل موزیک وجود دارد، جلوگیری می کند. به کرات برای تبدیل فوریه از STFT استفاده شده است. ایده پشت STFT، معرفی عملکرد پنجره $w(t)$ است که سیگنال آنالیز $x(t)$ را کوتاه کرده و سپس

تبدیل فوری سیگنال کوتاه شده را محاسبه می‌کند. $STFT$ با کشیدن پنجره در امتداد سیگنال بدست می‌آید. رابطه ریاضی تبدیل $STFT$ در فرم آنالوگ در رابطه (۱) قابل مشاهده می‌باشد:

(۱)

$$STFT(t, \omega) = \int_{-\infty}^{\infty} x(t + \tau) \omega(\tau) e^{-j\omega\tau} d\tau$$

جایی که $x(t + \tau)$ سیگنال تغییر یافته در زمان است و $\omega(\tau)$ یک عملکرد پنجره است. فرم گسسته تبدیل $STFT$ در رابطه (۲) آورده شده است:

(۲)


$$STFT(n, k) = \sum_{m=-\infty}^{\infty} \omega(m) X(n + m) e^{-j\frac{2\pi}{N}mk}$$

فرم انرژی $STFT$ ، اسپکتروگرام نامیده می‌شود. به صورت رابطه (۳) تعریف می‌شود:


(۳)

$$SPEC(t, \omega) = |STFT(t, \omega)|^2$$

نتایج بدست آمده با استفاده از $STFT$ می‌تواند اطلاعاتی در مورد تکامل زمانی تغییر فرکانس سیگنال بدست آورد، زیرا بازه زمانی کامل به تعدادی از بازه‌های زمانی کوچک تقسیم می‌شود و سپس آن‌ها به تنهایی با استفاده از تبدیل فوری تحلیل می‌شوند. $STFT$ به طور همزمان در بعد زمانی و فرکانسی از وضوح کافی برخوردار نیست. بهبود وضوح فرکانس با استفاده از پنجره‌های باریک منجر به از دست دادن وضوح در بعد زمان می‌شود. پنجره‌های کوتاه مدت محلی سازی کافی را در زمان انجام می‌دهند، اما منجر به وضوح فرکانس ضعیف می‌شوند. برای بهبود وضوح فرکانس، بخشهای طولانی از داده‌های زمان باید تبدیل به فوری شوند، که باعث کم شدن محلی سازی زمان می‌شود. اگر تغییرات زمانی محتوای فرکانس سریع باشد، مانند سیگنال‌های ناپایدار کوتاه مدت، طیف نگار ناکافی است. در شکل‌های (۵ و ۶) اسپکتروگرام سیگنال‌های دانلود شده نمایش داده شده است.



شکل (۵): نمایش اسپکتروگرام سیگنال EEG فرد سالم استفاده شده در الگوریتم پژوهش



شکل (۶): نمایش اسپکتروگرام سیگنال EEG فرد دارای پارکینسون استفاده شده در الگوریتم پژوهش

۴-۶- شبکه عصبی کانولوشن

شبکه عصبی کانولوشن نوعی شبکه عصبی مصنوعی می باشد که در تشخیص و پردازش تصویر استفاده می شود. شبکه عصبی سیستمی از سخت افزار و یا نرم افزار می باشد. که از عملکرد نورون ها در مغز انسان الگوبرداری شده است. CNN نورون های خود را بیشتر شبیه نورون های لوب فرونتال، ناحیه ای که مسئول پردازش محرک های بصری در انسان و سایر حیوانات است، مرتب می کند. لایه های CNN شامل یک لایه ورودی، یک لایه خروجی و یک لایه پنهان است.

شبکه عصبی کانولوشن یک معماری شبکه برای یادگیری عمیق است که مستقیماً از داده ها یاد می گیرد. این شبکه های کانولوشنی زیر مجموعه ای از یادگیری ماشین هستند و در قلب الگوریتم های یادگیری عمیق قرار دارند. آن ها از لایه های گره تشکیل شده اند که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. در این پژوهش به دو طریق از شبکه عصبی کانولوشن و از لایه تمام متصل fc7 و fc8 استخراج ویژگی شده است.

۱- در روش اول توسط لایه تمام متصل fc8 از شبکه عصبی کانولوشن ۱۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی به روش TF، ۱۰ ویژگی برتر انتخاب می شود.

۲- در روش دوم به واسطه لایه تمام متصل fc7 از شبکه عصبی کانولوشن ۲۰۰۰ ویژگی استخراج شده و سپس از طریق انتخاب ویژگی به روش TF، ۲۰ ویژگی برتر انتخاب می شود

سپس پس از انتخاب ویژگی های برتر، این ویژگی ها به عنوان ورودی وارد طبقه کننده ها می شود. در این مقاله از سه طبقه بندی کننده شبکه عصبی، ماشین بردار پشتیبان و K-نزدیکترین همسایه استفاده شده است. سپس نتایج با هم مقایسه می گردد. همچنین در این مقاله برای انتخاب ویژگی های برتر از روش وزن دهی TF استفاده شده است.

۴-۷- روش TF


این روش ساده و بسیار کاربردی که برای اولین بار در ارائه شد که در صورت وجود ویژگی t_k در مستند d_i وزن آن برابر تعداد تکرار آن ویژگی در رابطه (۴) تنظیم می کند.

(۴)

$$w_{ki} = tf(t_k, d_i) = \begin{cases} \#(t_k, d_i) & t_k \in \text{vector of } d_i \\ 0 & t_k \in \text{vector of } \bar{d}_i \end{cases}$$


که در آن $\#(t_k, d_i)$ برابر تعداد تکرار هر ویژگی t_k در مستند d_i است.

- در روش اول همانطور که در شکل (۷) قابل مشاهده است، ۱۰۰۰ ویژگی توسط لایه تمام متصل fc8 انتخاب شده و ۱۰ ویژگی برتر آن متناسب با روش TF برگزیده شده است.



شکل (۷): ۱۰ ویژگی انتخاب شده از میان ۱۰۰۰ ویژگی استخراج شده توسط یادگیری عمیق

- در روش دوم همانطور که در شکل (۸) قابل مشاهده است، ۲۰۰۰ ویژگی توسط لایه تمام متصل fc7 انتخاب شده و ۲۰ ویژگی برتر آن متناسب با روش TF برگزیده شده است.



شکل (۸): ویژگی انتخاب شده از میان ۲۰۰۰ ویژگی استخراج شده توسط یادگیری عمیق

سپس ویژگی‌های برتر انتخاب شده در دو روش، به عنوان ورودی وارد طبقه بندی کننده‌ها می‌شود و خروجی آن توسط ماتریس درهم ریختگی یا کانفیوژن بررسی و نتایج مورد بررسی قرار می‌گیرد.

۵- ماتریس درهم ریختگی

ماتریس درهم ریختگی یک ماتریس (جدول) است که می‌تواند برای اندازه گیری عملکرد یک الگوریتم یادگیری ماشین (معمولاً الگوریتم‌های یادگیری نظارت شده) استفاده شود.

هر ردیف ماتریس درهم ریختگی نشان دهنده نمونه‌ای از یک کلاس واقعی^۱ است و هر ستون نمونه‌هایی از یک کلاس پیش‌بینی شده^۲ را نشان می‌دهد.

جدول (۲): ماتریس کامفیوژن

برچسب پیش بینی شده			
برچسب شناخته شده	مثبت (۱)		منفی (۰)
	مثبت (۱)	TP	FN
	منفی (۰)	FN	TN

این جدول را اصطلاحاً ماتریس درهم ریختگی می‌گویند. جدول یا ماتریس درهم ریختگی، نتایج حاصل از طبقه‌بندی را بر اساس اطلاعات واقعی موجود، نمایش می‌دهد. حال بر اساس این مقادیر می‌توان معیارهای مختلف دقت، صحت و حساسیت را محاسبه نمود

صحت (Accuracy) به معنای توانایی یک ابزار اندازه‌گیری در تعیین مقدار واقعی و دقیق یک کمیت است. به بیان دیگر، هرچه مقدار اندازه‌گیری شده به مقدار واقعی و استاندارد نزدیک‌تر باشد، ابزار از صحت بیشتری برخوردار است. برای درک صحت یک اندازه‌گیری، باید یک کمیت چندین بار اندازه‌گیری شود. اگر میانگین این اندازه‌گیری‌ها به مقدار واقعی نزدیک باشد، می‌توان گفت ابزار اندازه‌گیری دارای دقت (صحت) بالایی است. رابطه (۵) نحوه محاسبه صحت را نشان می‌دهد. لازم به ذکر است که این پارامتر معمولاً به صورت درصد بیان می‌شود.

(۵)

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


دومین پارامتری که در این مقاله مورد استفاده قرار گرفته است حساسیت می باشد که به معنی نسبتی از موارد مثبت است که آزمایش آن‌ها را به درستی به عنوان نمونه مثبت تشخیص داده است. در واقع، حساسیت، معیار است که مشخص می‌کند طبقه بند، به چه اندازه در تشخیص تمام افراد مبتلا به بیماری موفق بوده است. این پارامتر به صورت رابطه (۶) محاسبه می‌شود:

(۶)

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

۵- نتایج

۱- روش اول با ۱۰۰۰ ویژگی و ۱۰ انتخاب برتر است. که نمودار صحت روش پیشنهادی در شکل (۹) و نتایج حاصل از آن در جدول (۳ و ۴) قابل مشاهده می‌باشد.



شکل (۹): صحت طبقه بندی کننده‌ها به صورت نمودار در روش اول (۱۰۰۰ ویژگی و ۱۰ انتخاب برتر)


جدول (۳): نتایج صحت متوسط طبقه بندی کننده‌ها با ۱۰۰۰ ویژگی استخراج شده و ۱۰ ویژگی منتخب

طبقه بندی کننده	صحت متوسط کل
شبکه عصبی	۹۰/۸۶
ماشین بردار پشتیبان	۹۸/۸۶
ک - نزدیکترین همسایه	۹۰/۸۹

جدول (۴): صحت و حساسیت کلاس‌ها در روش اول (۱۰۰۰ ویژگی استخراج شده و ۱۰ ویژگی منتخب)

نوع سیگنال	صحت	حساسیت
سیگنال فرد سالم	۹۸/۰۸	۹۸/۶۱
فرد دارای بیماری پارکینسون	۹۸/۵۰	۹۸/۳۴
مجموع	۹۸/۸۶	۹۸/۷۸

۲- روش دوم با ۲۰۰۰ ویژگی و ۲۰ انتخاب برتر است. که نمودار صحت روش پیشنهادی در شکل (۱۰) و نتایج حاصل از آن در جدول (۵ و ۶) قابل مشاهده می‌باشد.



شکل (۱۰): صحت طبقه بندی کننده‌ها به صورت نمودار روش دوم (۲۰۰۰ ویژگی و ۲۰ انتخاب برتر)

جدول (۵): نتایج صحت متوسط طبقه بندی کننده‌ها با ۲۰۰۰ ویژگی استخراج شده و ۲۰ ویژگی منتخب

طبقه بندی کننده	صحت متوسط کل
شبکه عصبی	۲۲/۲۲
ماشین بردار پشتیبان	۹۷/۳۳
ک - نزدیکترین همسایه	۶۱/۱۱

جدول (۶): صحت و حساسیت کلاس‌ها در روش اول (۲۰۰۰ ویژگی استخراج شده و ۲۰ ویژگی منتخب)

نوع سیگنال	صحت	حساسیت
سیگنال فرد سالم	۹۶/۸۲	۹۶/۷۷
فرد دارای بیماری	۹۷/۲۹	۹۸/۶۱
پارکینسون	۹۷/۳۳	۹۸/۳۱
مجموع		

۶- نتیجه گیری

در این مقاله ابتدا سیگنال EEG مورد نیاز از فرد سالم و دارای بیماری پارکینسون از سایت مندلی دانلود شد سپس با توجه به استفاده از شبکه عصبی کانولوشن و یادگیری عمیق و تاکید بر این موضوع که ورودی این شبکه حتما باید تصویر باشد سیگنال‌های دانلود شده توسط اسپکتوگرام به تصویر تبدیل شدند و به عنوان ورودی به شبکه عصبی داده شدند. سپس از طریق معماری الکس نت و لایه‌های تمام متصل FC7 و FC8 و یادگیری عمیق از تصاویر، ویژگی استخراج شد، در نهایت با استفاده از انتخاب ویژگی برتر روش وزن دهی TF، ویژگی‌های برتر را انتخاب تموده و به عنوان ورودی به طبقه بندی کننده‌ها داده شد. نتایج نشان داد که با توجه به دو روش گفته شده روش ۱۰۰۰ ویژگی و ۱۰ انتخاب برتر دارای نتایج بهتری نسبت به روش دیگر بوده که از طریق مقایسه بین نتایج طبقه بندی کننده‌ها به این مفهوم پرداخته شد و طبقه بندی کننده SVM با صحت ۹۷/۳۳ به عنوان طبقه بندی کننده برتر شناخته شد. با توجه به بررسی نتایج حاصل از طبقه بندی کننده‌ها می‌توان

به این نتیجه رسید که که روش پیشنهادی برای تشخیص بیماری پارکینسون مناسب می‌باشد. با توجه به استفاده از ویژگی‌های عمیق بدون دخالت دست سیستم را یک سیستم کاملاً خودکار می‌توان در نظر گرفت. به دلیل زمان پردازش پایین می‌توان سیستم را یک سیستم تشخیصی زمان حقیقی دانست.

References

مراجع

- [1] N. Kannathal, C. M. Lim, U. R. Acharya, P. K. Sadasivan, "Entropies for detection of epilepsy in EEG", *Comput. Methods Programs Biomed.*, vol. 80, no. 3, pp. 187–194, 2005.
- [2] L. Pezard, R. Jech, E. Růžicka, "Investigation of nonlinear properties of multichannel EEG in the early stages of Parkinson's disease", *Clin. Neurophysiol.*, vol. 112, no. 1, pp. 38–45, 2001.
- [3] I. T. French, K. A. Muthusamy, "A review of the pedunculopontine nucleus in Parkinson's disease", *Front. Aging Neurosci.*, vol. 10, p. 99, 2018.
- [4] B. T. Klassen, J. G. Hentz, H. A. Shill, E. Driver-Dunckley, V. G. H. Evidente, M. N. Sabbagh, J. N. Caviness, "Quantitative EEG as a predictive biomarker for Parkinson disease dementia", *Neurology*, vol. 77, no. 2, pp. 118–124, 2011.
- [5] A. A. Handojoseno, J. M. Shine, T. N. Nguyen, Y. Tran, S. J. Lewis, H. T. Nguyen, "The detection of Freezing of Gait in Parkinson's disease patients using EEG signals based on Wavelet decomposition", in *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. (EMBC)*, 2012.
- [6] P. Miguel, J. Paulo, "Classification of Electroencephalogram Signals Using Artificial Neural Networks", in *Proc. 3rd Int. Conf. Biomed. Eng. Informatics (BMEI)*, 2010.
- [7] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N. Yen, C. C. Tung, H. H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proc. R. Soc. Lond. Ser. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903–995, 1998.
- [8] W. Chen, J. Zhuang, W. Yu, and Z. Wang, "Measuring complexity using fuzzyEn, ApEn, and SampEn", *Med. Eng. Phys.*, vol. 31, pp. 61–68, 2009.
- [9] M. A. Colominas, G. Schlotthauer, and M. E. Torres, "Improved complete ensemble EMD: a suitable tool for biomedical signal processing", *Biomed. Signal Process. Control*, vol. 14, pp. 19–29, 2020.
- [10] M. A. Colominas, G. Schlotthauer, M. E. Torres, and P. Flandrin, "Noise-assisted EMD methods in action", *Adv. Adapt. Data Anal.*, vol. 4, no. 1250025, 2020.
- [11] I. Daly, S. J. Nasuto, and K. Warwick, "Brain computer interface control via functional connectivity dynamics", *Pattern Recogn.*, vol. 45, pp. 2123–2136, 2012.
- [12] R. Silva, P. Almeida, C. Santos, "Exploring the complexity of EEG patterns in Parkinson's disease: Insights into disease progression", *Neurobiol. Aging*, vol. 138, p. 39, 2024.

¹ Actual class

² Predicted class