

پیش‌بینی وقوع حمله صرع با استفاده از روش LASSOGLM

آزاده برنده^۱، سینا شامخی^{۲*} و عباس درویش فشتمی^۳

^۱ گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند تبریز، azadehb72@yahoo.com

^۲ گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند تبریز، shamekhi@sut.ac.ir

^۳ گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی سهند تبریز، farzad_darvish2011@hotmail.com

چکیده - بیماری صرع دومین بیماری رایج مغزی است که زندگی فرد را به شدت تحت تاثیر قرار می‌دهد و نرخ شیوع بالایی در دنیا دارد. از این‌رو پیش‌بینی به موقع حمله می‌تواند از بروز بسیاری از مشکلاتی که ممکن است در زندگی روزمره فرد ایجاد شود، جلوگیری کند و فرد بتواند به موقع خود را آماده وقوع حمله کند. تحقیق پیش‌رو روشی نوین برای پیش‌بینی حملات صرع با استفاده از سیگنال iEEG ارائه می‌دهد. در این مطالعه، از ویژگی‌های هم‌چون انتروپی شانون، انتروپی طیفی، همبستگی بین کانال‌ها و همبستگی بین باندهای فرکانسی، اسکینوس و کورتوزیس، پارامترهای هورت، ابعاد فرکتال و فاصله انتشار استفاده شده است. برای ایجاد تمایز بهتر بین دو دسته، به دلیل بعد بالای ماتریس ویژگی، از الگوریتم LDA برای کاهش بعد استفاده شده است. سپس برای طبقه‌بندی دو کلاس قبل از حمله و بین‌حمله‌ای از روش رگرسیون LASSOGLM استفاده شده است. در نهایت نتایج توسط معیارهای و ابزارهای کمی، مورد تحلیل و بررسی قرار گرفته است. الگوریتم پیشنهادی در حالت کلی دارای حساسیتی برابر با ۰/۹۸ و با نرخ پیش‌بینی اشتباه ۰/۱۷۵، با سطح زیر منحنی ۰/۹۹ نمودار ROC می‌باشد. با بررسی دقیق‌تر برای هر سگ، با حساسیت ۰/۹۹، به‌طور میانگین ۴۸ دقیقه قبل از حمله قادر به پیش‌بینی آن بوده است.
کلیدواژه- پیش‌بینی حمله، LASSOGLM، LDA.

وقوع پیش‌بینی شود تا خطرات و مشکلات به حداقل برسد. این کارها به‌گونه‌ای است تا ویژگی‌هایی مناسب انتخاب شود تا بین دو حالت بین‌حمله‌ای و قبل از حمله تمایز ایجاد کند. این تلاش‌ها از سال ۱۹۷۰ با کارهای ویگلیون و همکارانش در این حوزه آغاز شد. آن‌ها آزمایشی طراحی کردند که قادر به جداسازی ایپاک‌های قبل-ازحمله و بین‌حمله‌ای و حمله با دقت خوبی بود. البته این سیستم نتایج نادرست مثبت زیادی نیز داشت [۳]. استفاده از تغییرات کمی EEG [۴]، استفاده از ویژگی‌های بصری در EEG مانند اسپایک‌های صرع [۵، ۶] مورد توجه محققان بوده است. در دهه ۱۹۹۰ این تلاش‌ها جنبه دیگری به خود گرفت [۷]. استفاده از دینامیک غیرخطی، تغییرات در پارامترهای دینامیکی غیرخطی مانند بزرگترین نمای لیاپانوف (LLE) [۸]، تکنیک‌های توسعه یافته که سنکرون‌سازی فاز را ساعت‌ها قبل از حمله نشان می‌دهد [۹، ۱۰] و استفاده از چگالی همبستگی برای پیش‌بینی حمله در این دهه مورد توجه قرار گرفت [۱۱]. از سال ۲۰۰۰ روش‌های غیرخطی جدیدتری برای پیش‌بینی حمله مورد استفاده قرار گرفت. در سال ۲۰۰۳ از ویژگی‌هایی هم‌چون ویژگی‌های آماری، طول منحنی، انرژی انباشته شده، انرژی غیرخطی، انتروپی طیفی، توان ششم، انرژی بسته

۱- مقدمه

بیماری صرع پس از سکته مغزی، رایج‌ترین اختلال مغزی می‌باشد که بیش از ۱٪ از جمعیت جهان را تحت‌تاثیر قرار می‌دهد. این بیماری ناشی از فعالیت‌های غیرطبیعی سلول‌های مغزی است که در آن‌ها الگوی طبیعی فعالیت نورون‌ها مختل می‌شود [۱، ۲]. بیماری صرع علائم و نشانه‌های مختلفی دارد که به گسترش حملات و محل شروع اغتشاشات بستگی دارند. اما می‌توان بیان کرد که مهم‌ترین مشخصه این بیماری تشنج‌ها و حملات پی‌درپی و مکرر است. این حملات ناگهانی بوده [۱] و امکان وقوع آن در هر زمان و مکانی وجود دارد که این می‌تواند باعث ایجاد عواقب و عوارض جبران‌ناپذیری برای فرد بیمار شود و کیفیت زندگی فردی و اجتماعی فرد را تحت‌تاثیر قرار دهد. از این‌رو پیش‌بینی به‌موقع این حملات می‌تواند سبب جلوگیری از بروز بسیاری از مشکلات برای فرد بیمار شود و اقدام درمانی مناسب برای وی انجام گیرد. تلاش‌های بسیاری در حوزه پیش‌بینی حملات صرع همواره انجام گرفته و در حال انجام نیز می‌باشد تا با فاصله زمانی بیشتری از شروع حمله، زمان

فرد صورت گیرد و هم فرد دچار استرس ناشی از تشخیص اشتباه زمان بین حمله‌ای به‌عنوان قبل از حمله، نگردد. الگوریتم ارائه شده در این تحقیق مبتنی بر استفاده از ویژگی‌هایی هم‌چون انتروپی، ویژگی‌های آماری، همبستگی، فاصله انتشار، ابعاد فرکتال و پارامترهای هورت می‌باشد. ویژگی‌های مختلف پس از استخراج تشکیل ماتریس ویژگی را می‌دهند و سپس به دلیل بعد بالا با الگوریتم آنالیز جدا کننده خطی (LDA) کاهش بعد داده می‌شوند و سپس به‌منظور یادگیری و تست به دو دسته تقسیم شده و در نهایت به رگرسیون عملگر حداقل انتخاب و کاهش مطلق مدل تعمیم‌یافته خطی یا Least Absolut Shrinkage and Selection Operator of Generalized Linear Model (LASSOGLM) داده می‌شوند تا دو حالت قبل از حمله و بین حمله‌ای متمایز شوند و در نهایت برای بررسی عملکرد روش ارائه شده معیارهای کمی و کیفی محاسبه می‌شوند تا عملکرد روش مشخص شود.

ساختار مقاله به این‌صورت است که در بخش ۲ پایگاه مورد استفاده معرفی گردیده و سپس داده مورد استفاده به تفصیل توضیح داده شده است. در بخش ۳ نتایج به‌دست آمده از پیاده‌سازی الگوریتم پیشنهادی ارائه گردیده است و در نهایت در بخش ۴ به جمع‌بندی و نتیجه‌گیری پرداخته شده است.

۲- داده و الگوریتم پیشنهادی

در این بخش در ابتدا پایگاه داده مورد استفاده در این تحقیق معرفی گردیده است. سپس الگوریتم پیشنهادی به تفصیل توضیح داده شده است. در ابتدا پیش‌پردازش استفاده شده در این الگوریتم ارائه شده و سپس ویژگی‌های استخراج شده بیان گردیده است. سپس داده‌ها برای یادگیری و تست به دودسته تقسیم شده و به دلیل بعد بالا از LDA برای کاهش بعد آن استفاده شده و سپس داده‌ها برای یادگیری و تست به طبقه‌بند داده شده‌اند.

۲-۱- پایگاه داده کگل (Kaggle)

داده مورد استفاده در این تحقیق، مربوط به انجمن صرع آمریکا (AES) می‌باشد. این پایگاه داده شامل ۴ سگ و ۲ بیمار است که در این تحقیق از ۴ سگ استفاده شده است. ثبت‌های مربوط به هر کدام از این ۴ سگ، ۱۶ کاناله بوده و فرکانس ثبت حدود ۴۰۰ هرتز می‌باشد. در این پایگاه داده میانگین الکترودها به‌عنوان الکتروود مرجع در نظر گرفته شده است. ثبت‌ها طولانی مدت بوده و ثبت آن‌ها از چندین ماه تا یک‌سال به‌طول انجامیده است و در برخی از سگ‌ها تا ۱۰۰ حمله را شامل می‌شود. این داده‌ها درون

موجک استفاده گردید [۱۲]. در سال ۲۰۰۹، ویژگی‌های مانند همبستگی متقابل، وابستگی متقابل غیرخطی و تحول دینامیکی به دلیل برجسته کردن همزمانی امواج مغزی مورد استفاده قرار گرفته است [۱۳]. در سال ۲۰۱۰، الگوریتمی مبتنی بر مدل‌سازی خودکاهنده در سری‌های زمانی و ترکیب تخمین‌گرهای پارامترهای حداقل مربعات برای استخراج ویژگی، برای پیش‌بینی برخط صرع، از دیگر کارهای انجام شده در این حوزه است که در آن به دلیل اجرای زمان-واقعی و پیش‌بینی درست و به‌موقع از AR استفاده شده بود [۱۴]. ساختار همبستگی زمانی- مکانی و ویژگی‌های همبستگی تاخیر فضا و ماتریس‌های کوواریانس، الگوهای همبستگی، ویژگی-های آماری در حوزه زمان هم‌چون انحراف از میانگین مطلق (MAD) و بازه چارک داخلی (IQR)، فیلتر ریخت‌شناسی برای شناسایی اسپایک‌ها و محاسبه نرخ اسپایک در سال ۲۰۱۱ برای پیش‌بینی حمله مورد استفاده قرار گرفته‌اند [۱۵]. در این حوزه می‌توان به استفاده از ویژگی‌های خطی تک‌متغیره هم‌چون ویژگی-های ممان‌های آماری مرتبه اول، دوم، سوم و چهارم، میانه دامنه‌ها و چگالی طیف توان در سال ۲۰۱۴ اشاره نمود [۱۶]. هم‌چنین می‌توان توان طیفی باندهای فرکانسی و توان طیفی نسبی [۱۷]، همبستگی دوفازه [۱۸]، استفاده هم‌زمان از ویژگی‌های طیفی و آماری [۱۹]، انتروپی از جمله انتروپی شانون [۲۰] برای پیش‌بینی حملات صرع استفاده نمود. در سال ۲۰۱۸ در تحقیقی جدید از ویژگی فاصله انتشار برای پیش‌بینی حملات صرع استفاده گردید [۲۱]. هم‌چنین در کارهای انجام شده در این حوزه به‌خصوص از سال ۲۰۰۰ تا کنون از طبقه‌بندهای مختلفی از جمله شبکه عصبی احتمالاتی (PNN)، شبکه عصبی کانولوشنی (CNN)، ماشین بردار پشتیبان (SVM)، رگرسیون منطقی (LR)، ماشین‌های بردار پشتیبان حساس به هزینه (CSVM)، نزدیکترین همسایگی (KNN) و آنالیز جداکننده خطی بی‌زین (BLDA) برای طبقه‌بندی ویژگی-های مذکور استفاده گردیده است [۱۵-۱۷، ۲۱-۲۴]. چالش مهم در تمام کارهای انجام شده در این حوزه، بهبود حساسیت، نرخ پیش‌بینی اشتباه و هم‌چنین زمان پیش‌بینی حمله بوده است. اما مشکل آن‌ها این است که قادر به تشخیص حمله با حساسیت بالا و نرخ پیش‌بینی پایین با تعیین زمان پیش‌بینی طولانی به‌طور هم‌زمان نبوده‌اند. از این‌رو هدف از انجام مقاله پیش‌رو، ارائه روشی جدید برای پیش‌بینی حملات صرع می‌باشد تا حساسیت، ویژگی، نرخ پیش‌بینی اشتباه، زمان پیش‌بینی حمله، به‌طور هم‌زمان بهبود یابند تا زمان‌های قبل از حمله و بین حمله‌ای به‌درستی تشخیص و از یکدیگر به‌طور کامل تمییز داده شوند و حمله‌ها با فاصله زمانی بیشتری از شروع حمله پیش‌بینی شوند تا هم اقدامات لازم برای

ویژگی‌هایی که در قسمت بعد توضیح داده شده است، استخراج می‌شود.

۳-۲- استخراج ویژگی


پس از پنجره‌گذاری داده‌ها، ۱۳ ویژگی از هر کدام از نمونه‌ها استخراج شده است. این ویژگی‌ها شامل انترپوی شانون، انترپوی طیفی، فرکانس لبه طیفی، ابعاد فرکتال، پارامترهای هورت (فعالیت، تحرک، پیچیدگی)، ویژگی‌های آماری (چولگی، کشیدگی)، همبستگی بین کانال‌ها، همبستگی بین فرکانس‌ها، انترپوی طیفی دوتایی، همبستگی دوتایی بین کانال‌ها و فاصله انتشار می‌باشد. به غیر از سه ویژگی همبستگی بین فرکانس‌ها، ابعاد فرکتال و فاصله انتشار، مابقی ویژگی‌ها برای هر کانال یک مقدار بدست آورده‌اند، پس برای هر نمونه ۱۶ مقدار وجود دارد. همبستگی بین فرکانس‌ها، بدین صورت است که برای هر باند فرکانسی یک مقدار محاسبه شده است. با توجه به تعداد باندهای فیلتر شده، برای هر نمونه ۶ مقدار به دست آورده شده است. ابعاد فرکتال با توجه به ماهیت این ویژگی برای هر کانال ۳ مقدار بدست آورده است، پس برای هر نمونه ۴۸ مقدار برای ابعاد فرکتال وجود دارد و در نهایت فاصله انتشار برای هر کانال در هر نمونه ۳ مقدار و به طور کلی برای هر نمونه ۴۸ مقدار محاسبه شده است. از اجتماع این ویژگی‌ها برای هر نمونه ۲۱۴ ویژگی وجود دارد که برای تشکیل ماتریس ویژگی استفاده شده است. سپس نمونه‌ها زیر یکدیگر قرار داده شده و تشکیل ماتریس ویژگی را می‌دهند.

۴-۲- کاهش بعد و طبقه‌بندی

پس از استخراج ویژگی و تشکیل ماتریس ویژگی، داده‌ها باید نرمالیزه شوند تا همگی در یک بازه قرار گیرند. سپس برای طبقه‌بندی نیاز است تا داده‌ها برچسب‌گذاری شوند، به همین دلیل عدد ۱ به داده‌های قبل از حمله و صفر به داده‌های بین‌حمله‌ای اختصاص می‌یابد.

به منظور یادگیری مدل و تست روش پیشنهادی داده‌ها باید به دو دسته داده‌های آموزش و یادگیری تقسیم می‌شوند. بدین منظور، داده‌ها به نسبت ۶۰-۴۰ تقسیم بندی شده‌اند. به این معنا که ۶۰٪ از هر نوع از داده‌ها (قبل از حمله، بین حمله‌ای) برای آموزش الگوریتم پیشنهادی و ۴۰٪ باقی‌مانده از هر کدام به تست آن اختصاص یافته است. سپس، با توجه به ابعاد بالای ماتریس ویژگی، از روش LDA برای کاهش بعد استفاده شده است. بعد زیاد داده سبب بیش‌برازش (Over fitting) می‌شود زیرا تعداد ویژگی‌ها زیاد بوده و این سبب یادگیری بیش‌ازحد مدل می‌شود و در نتیجه بیش‌برازش رخ می‌-

جمجمه‌ای (iEEG) بوده و به دو صورت بین حمله‌ای و قبل از حمله هستند. ثبت‌های مذکور دارای بخش‌های ۱۰ دقیقه‌ای می‌باشند که با برچسب قبل از حمله و یا بین حمله‌ای مشخص شده‌اند. این بخش‌ها به صورت دنباله‌ای و پشت‌سرهم شماره‌گذاری شده‌اند. به این صورت که در توالی ثبت‌های قبل از حمله‌ای، هر ۶ ثبت نشان‌دهنده یک دوره قبل از حمله‌ای است. به عبارتی داده‌های قبل از حمله به گونه‌ای ثبت شده‌اند که ۱ ساعت قبل از پوشش می‌دهند و زمان افق پیش‌بینی ۵ دقیقه در نظر گرفته شده است که در شکل (۱) آمده است. تعداد ساعات قبل از حمله و بین حمله‌ای به تفکیک در جدول (۱) آمده است [۲۵].



شکل ۱: نمونه‌ای سیگنال iEEG پایگاه داده مورد استفاده [۲۵]

جدول ۱- تعداد ساعات بین حمله‌ای، قبل از حمله، تعداد حملات

ردیف	بین حمله‌ای	قبل از حمله	تعداد حملات
سگ شماره ۱	۸۰	۴	۴
سگ شماره ۲	۸۳	۷	۷
سگ شماره ۳	۲۴۰	۱۲	۱۲
سگ شماره ۴	۱۳۴	۱۶	۱۶

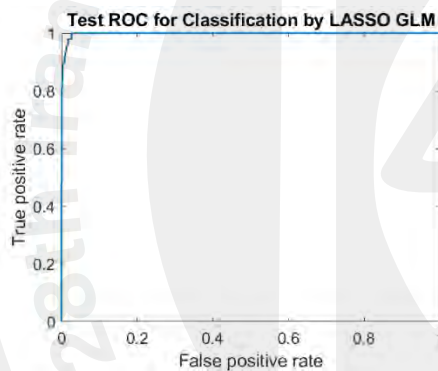
۲-۲- پیش‌پردازش

در این تحقیق، جهت آماده‌سازی پایگاه داده پیش‌پردازش‌هایی بر روی داده‌ها صورت گرفته است که در ادامه توضیح داده می‌شود. در ابتدا در قالب یک مرحله پنجره‌گذاری، هر بخش ۱۰ دقیقه‌ای به پنجره‌های ۱ دقیقه‌ای تقسیم می‌شوند که به هر کدام از این پنجره‌ها، ۱ نمونه گفته می‌شود. تعداد نقاط داده مربوط به هر سگ در هر بخش ۱۰ دقیقه‌ای عدد ۲۳۹۷۶۶ و فرکانس ثبت داده ۳۹۹/۶۰ هرتز است. با توجه به فرکانس و طول داده ذکر شده امکان قطع‌بندی به ۹ پنجره در ۱۰ دقیقه فراهم بوده است. بنابراین هر بخش ۱۰ دقیقه‌ای دارای ۹ نمونه می‌باشد. سپس از هر کدام از این نمونه‌ها

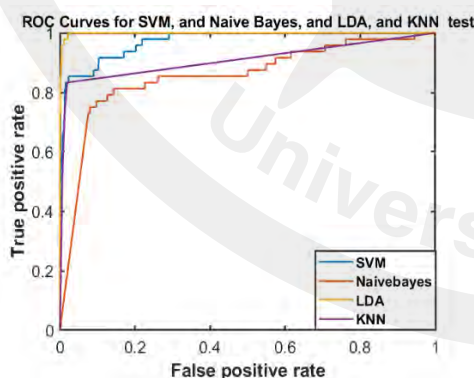
توزیع احتمال y ، جز سیستماتیک بیانگر ترکیب خطی متغیرهای مستقل شامل بردار پیش‌بینی‌ها و تابع اتصال، ارتباط‌دهنده دو جز قبلی است. در این تحقیق، به‌علت وجود دو کلاس قبل از حمله و بین‌حمله‌ای برای طبقه‌بندی، LASSOGLM، با توزیع دوجمله‌ای (Binomial) برای متغیر پاسخ در نظر گرفته شده است. هم‌چنین تابع اتصال مورد استفاده برای توزیع دو جمله‌ای، تابع logit است.

۳- نتایج و بحث

در این قسمت به بررسی نتایج حاصل از پیاده‌سازی روش پیشنهادی پرداخته می‌شود. برای مقایسه روش این مقاله با دیگر روش‌های طبقه‌بندی از جمله SVM، KNN، NaiveBayes و LDA، ۴ طبقه‌بند مذکور نیز بر روی داده‌ها اعمال شده و نتایج آن‌ها با نتایج روش پیشنهادی مقایسه گردیده است. این نتایج در قالب نمودار ROC، معیارهای ارزیابی از جمله حساسیت، ویژگی، نرخ پیش‌بینی اشتباه آورده شده است.



شکل ۲: نمودار ROC روش پیشنهادی



شکل ۳: نمودار ROC طبقه‌بندهای مقایسه‌ای

دهد. از دیگر مزایای استفاده از LDA برای کاهش بعد آن است که این روش، واریانس درون کلاسی و بین کلاسی را محاسبه می‌کند و سعی دارد تا واریانس بین کلاسی را افزایش و درون کلاسی را کاهش دهد که این امر سبب تمایز کامل داده‌ها شده و دو کلاس قبل از حمله و بین‌حمله‌ای به‌طور کامل از یکدیگر جدا شده و تمییز داده می‌شوند. سپس داده‌ها باید طبقه‌بندی شوند تا دو کلاس بین-حمله‌ای و قبل از حمله از یکدیگر مشخص شوند. از دیگر ویژگی‌های این روش این است که با توجه به ضریبی که برای هر ویژگی تعیین می‌کند، می‌توان ویژگی که بیشترین تمایز را ایجاد کرده است، تشخیص داد. پس از اعمال الگوریتم LDA بر روی ویژگی‌ها، خروجی حاصل طبقه‌بندی می‌گردد.

در این تحقیق از روش رگرسیون LASSOGLM برای طبقه‌بندی استفاده شده است [۲۶]. LASSO، یک روش آنالیز رگرسیون است که هم برای انتخاب متغیر و هم رگرسیون، به‌علت صحت بالای پیش‌بینی و تفسیرپذیری مدل آماری که تولید می‌کند، به‌کار می‌رود. این روش در واقع بر پایه دیدگاه تنک بودن (sparsity) است که ضرایب برخی از ویژگی‌ها صفر شده و مابقی در شکل‌گیری مدل نقش دارند. این روش یک مدل خطی برای داده‌ها در نظر می‌گیرد که به‌صورت معادله (۱) است.

$$y_i = \beta_0 + x_{i1}\beta_1 + \dots + x_{ik}\beta_k + \varepsilon_i \quad (1)$$

در این معادله، β_i ها، ضرایب رگرسیون، x_i ها ویژگی‌ها یا داده‌های ورودی یا متغیر مستقل و y_i متغیر پاسخ یا همان برجسب‌ها هستند. ε نیز بردار خطا در نظر گرفته شده است. در این روش باید ضرائب رگرسیون بهینه محاسبه شوند، به‌همین منظور از روش نرم $(L1)$ استفاده می‌شود و معادله (۲) ضرائب بهینه را به‌دست می‌آورد.

$$\hat{\beta}(\lambda) = \operatorname{argmin}_{\beta} \left(\frac{\|Y - X\beta\|_2^2}{n} + \lambda \|\beta\|_1 \right) \quad (2)$$

$$\|Y - X\beta\|_2^2 = \sum_{i=0}^n (y_i - (X\beta)_i)^2 \quad (3)$$

$$\|\beta\|_1 = \sum_{j=1}^k |\beta_j| \quad (4)$$

در این معادله λ بیانگر ضریبی است که میزان تاثیر ضریب رگرسیون را بیان می‌کند. زمانی که مقدار این ضریب صفر باشد، β مربوط به آن صفر در نظر گرفته می‌شود و حذف می‌شود. در حالت کلی LASSO برای متغیرهای پاسخ، توزیع گوسی یا نرمال در نظر می‌گیرد. اما می‌توان از توزیع‌های غیرنرمال هم‌چون توزیع پواسون، دوجمله‌ای، چندجمله‌ای یا توزیع احتمالات از خانواده توابع نمایی استفاده کرد که در این‌صورت تبدیل به مدل خطی تعمیم‌یافته یا LASSOGLM می‌شود. مدل تعمیم‌یافته خطی خود شامل سه جزء سیستماتیک، تصادفی و تابع اتصال است. جزء تصادفی بیان‌کننده

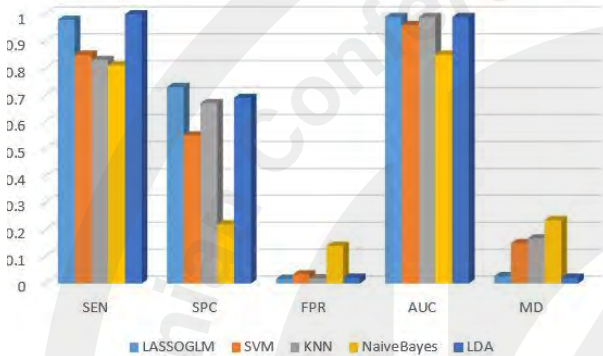
تشخیص داده شده‌اند، بسیار کم بوده و دلیل دیگری بر پیش‌بینی درست بالای روش پیشنهادی دارد.

جدول ۳ - بررسی زمان پیش‌بینی حمله روش پیشنهادی

سگ	سگ	سگ	سگ	
شماره ۱	شماره ۲	شماره ۳	شماره ۴	
۰/۹۹	۰/۹۹	۰/۹۹	۰/۹۹	حساسیت
۵۴	۵۴	۵۴	۲۸-۳۶	زمان پیش- بینی (دقیقه)

جدول ۲- نتایج مربوط به تست روش پیشنهادی و روش‌های مقایسه‌ای

method	حساسیت	ویژگی	fpr	AUC	MI
SVM	۰/۸۵	۰/۵۵	۰/۰۳۴	۰/۹۶	۰/۱۴۹۸
KNN	۰/۸۳	۰/۶۷	۰/۰۱۹۶	۰/۹۹	۰/۱۶۷۸
NB	۰/۸۱	۰/۲۲	۰/۱۴	۰/۸۵	۰/۲۳۵۵
LDA	۱	۰/۶۹	۰/۰۲۱۷	۰/۹۹	۰/۰۲۱۷
روش پیشنهادی	۰/۹۸	۰/۷۳	۰/۰۱۷۵	۰/۹۹	۰/۰۲۷۲



شکل ۴: مقایسه روش پیشنهادی و طبقه‌بندهای مقایسه‌ای

هم‌چنین به‌منظور بررسی دقیق‌تر، روش پیشنهادی به‌طور جداگانه بر روی نمونه‌های مربوط به هر سگ اعمال شده است تا زمان پیش‌بینی برای هر سگ به‌طور جداگانه محاسبه گردد که این زمان در جدول (۳) به همراه میزان حساسیت آورده شده است. همان‌طور که در این جدول قابل مشاهده است برای سگ ۱ تا ۳، ۵۴ دقیقه قبل از شروع حمله با حساسیت ۰/۹۹ و برای سگ ۴، ۲۸-۳۶ دقیقه قبل از شروع حمله با حساسیت ۰/۹۹، حمله‌ها قابل پیش‌بینی هستند که می‌توان گفت به‌طور میانگین روش پیشنهادی ۴۸ دقیقه قبل از شروع حمله، می‌توان آن را پیش‌بینی نماید.

با توجه به نتایج به‌دست آمده و ارائه شده، روش پیشنهادی، این مقاله در مقایسه با دیگر روش‌ها بهبود یافته‌تر است. هم‌چنین می‌توان استفاده از LDA را به‌عنوان یک مزیت این روش بیان کرد زیرا این الگوریتم باعث ایجاد تمایز کامل بین ویژگی‌های دو گروه قبل از حمله و بین حمله‌ای شده و ویژگی که دارای بیشترین تاثیر در ایجاد تمایز بین گروه می‌شود، بیشترین تاثیر در جداسازی توسط طبقه‌بند را داراست. در واقع این الگوریتم با تعیین میزان اهمیت ویژگی‌ها در متمایز کردن ویژگی‌های دو گروه مذکور، ویژگی که دارای بیشترین تاثیر است را مشخص می‌سازد. در این مقاله ویژگی انترویی شانون بیشترین تاثیر را در جداسازی بخش‌های قبل از حمله و بین حمله‌ای و پیش‌بینی حمله داشته است.

نمودار منحنی مشخصه عملکرد سیستم (ROC)، یک روش کمی برای ارزیابی الگوریتم پیشنهادی است که در آن پیش‌بینی مثبت درست نسبت به پیش‌بینی مثبت نادرست یا نرخ پیش‌بینی اشتباه نشان داده شده است. سطح زیر این نمودار (AUC) بیانگر عملکرد الگوریتم می‌باشد. همان‌گونه که در شکل (۲) قابل مشاهده است، سطح زیر این منحنی برای روش پیشنهادی بسیار نزدیک به ۱ بوده و فاصله نقطه بهینه نمودار تا نقطه ایده‌آل دارای مقدار بسیار کمی می‌باشد.

جدول (۲) و شکل (۴) برای ارزیابی عملکرد روش پیشنهادی و مقایسه آن با طبقه‌بندهای مقایسه‌ای ارائه شده است. این نتایج در قالب حساسیت، ویژگی، نرخ پیش‌بینی اشتباه، سطح زیر نمودار ROC و MI محاسبه شده است. هم‌چنین برای بررسی دقیق‌تر الگوریتم پیشنهادی، زمان پیش‌بینی حمله نیز برای هر سگ به‌طور جداگانه محاسبه شده و در جدول (۳) ارائه گردیده است.

روش پیشنهادی این مقاله، با حساسیت ۰/۹۸ و ویژگی ۰/۷۳ در مقایسه با طبقه‌بندهای مقایسه‌ای دارای عملکرد بهتر و بهبود یافته‌تری می‌باشد. حساسیت بالای این روش، نشان از این دارد که این روش، زمان‌های قبل از حمله را به‌درستی تشخیص داده است و در نتیجه تقریباً تمام حملات به‌درستی پیش‌بینی شده‌اند. هم‌چنین میزان ویژگی محاسبه شده برای روش پیشنهادی در مقایسه با دیگر روش‌های مقایسه‌ای بالاتر بوده است که این بیانگر این است که تعداد زیادی از زمان‌های بین حمله‌ای به‌درستی تشخیص داده شده‌اند. زیرا زمانی که میزان تشخیص اشتباه زمان‌های بین حمله‌ای به‌عنوان قبل از حمله، بالا باشد، می‌تواند استرس بیمار را زیاد کند در صورتی که در آن زمان، حمله‌ای در حال وقوع نیست. هم‌چنین نرخ پیش‌بینی اشتباه روش پیشنهادی ۰/۰۱۷۵ بوده که بسیار پایین‌تر از روش‌های مقایسه‌ای می‌باشد که در مقایسه با روش‌های دیگر بهبود یافته است که این بیانگر این است که تعداد تشخیص‌های اشتباه یعنی بخش‌های قبل از حمله که به اشتباه بین حمله‌ای

۴- نتیجه‌گیری و جمع‌بندی

پیش‌بینی صرع همواره اهمیت ویژه‌ای در بیماری صرع داشته است زیرا پیش‌بینی به‌موقع آن می‌تواند سبب انجام اقدامات لازم برای فرد بیمار شود تا خطرات احتمالی ناشی از حمله کاهش یابد. زمان پیش‌بینی و تشخیص درست زمان قبل از حمله به‌عنوان مهم‌ترین چالش در این حوزه بوده است. در این مقاله روش جدیدی برای پیش‌بینی صرع ارائه شد. روش پیشنهادی بر روی پایگاه داده EEG درون مجموعه‌های Kaggle اعمال گردید. این روش ترکیبی از ۱۳ ویژگی و روش رگرسیون LASSOGLM برای طبقه‌بندی می‌باشد. استفاده از این روش پیش‌بینی سبب تنک شدن ویژگی‌ها می‌شود. در این روش به‌علت بعد بالای ماتریس ویژگی از روش کاهش بعد LDA استفاده شد که سبب کم شدن فاصله درون کلاسی و زیاد شدن فاصله بین کلاسی می‌شود که علاوه بر کاهش بعد، توانایی جداسازی کامل ویژگی‌های دو کلاس مدنظر را دارا می‌باشد که در نتایج نهایی بسیار تاثیرگذار است. هم‌چنین در این تحقیق برای مقایسه روش پیشنهادی با دیگر روش‌ها، طبقه‌بندهای SVM، KNN، NaiveBayes و LDA نیز بر روی داده‌ها اعمال گردید و نتایج به‌دست آمده با روش پیشنهادی مورد مقایسه قرار گرفت و بررسی‌ها نشان داد عملکرد روش پیشنهادی بهتر می‌باشد. پیشنهاد می‌گردد برای کارهای آتی، الگوریتم پیشنهادی بر روی سیگنال‌های EEG سطحی اعمال گردد زیرا ثبت آن‌ها راحت‌تر بوده و هم‌چنین غیرتهاجمی می‌باشد و برای ثبت‌های انسانی مناسب‌تر است.

مراجع

- [9] F. Mormann, K. Lehnertz, R. Andrzejak, and C. Elger, "Characterizing preictal states by changes in phase synchronization in intracranial EEG recordings from epilepsy patients," *Epilepsia*, vol. 41, no. suppl 7, p. 167.2000 ,
- [10] F. Mormann, K. Lehnertz, P. David, and C. E. Elger, "Mean phase coherence as a measure for phase synchronization and its application to the EEG of epilepsy patients," *Physica D: Nonlinear Phenomena*, vol. 144, no. 3-4, pp. 358-369, 2000.
- [11] M. Le Van Quyen, C. Adam, J. Martinerie, M. Baulac, S. Clemenceau, and F. Varela, "Spatio-temporal characterizations of non-linear changes in intracranial activities prior to human temporal lobe seizures," *European Journal of Neuroscience*, vol. 12, no. 6, pp. 2124-2134, 2000.
- [12] M. D'Alessandro, R. Esteller, G. Vachtsevanos, A. Hinson, J. Echauz, and B. Litt, "Epileptic seizure prediction using hybrid feature selection over multiple intracranial EEG electrode contacts: a report of four patients," *IEEE transactions on biomedical engineering*, vol. 50, no. 5, pp. 603-615, 2003.
- [13] P. Mirowski, D. Madhavan, Y. LeCun, and R. Kuzniecky, "Classification of patterns of EEG synchronization for seizure prediction," *Clinical neurophysiology*, vol. 120, no. 11, pp. 1927-1940, 2009.
- [14] L. Chisci *et al.*, "Real-time epileptic seizure prediction using AR models and support vector machines," *IEEE Transactions on Biomedical Engineering*, vol. 57, no. 5, pp. 1124-1132, 2010.
- [15] J. R. Williamson, D. W. Bliss, and D. W. Browne, "Epileptic seizure prediction using the spatiotemporal correlation structure of intracranial EEG," in *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2011: IEEE, pp. 665-668.
- [16] P. Ghaderyan, A. Abbasi, and M. H. Sedaaghi, "An efficient seizure prediction method using KNN-based undersampling and linear frequency measures," *Journal of neuroscience methods*, vol. 232, pp. 134-142, 2014.
- [17] M. Bandarabadi, C. A. Teixeira, J. Rasekhi, and A. Dourado, "Epileptic seizure prediction using relative spectral power features," *Clinical Neurophysiology*, vol. 126, no. 2, pp. 237-248, 2015.
- [18] Z. Vahabi, R. Amirfattahi, F. Shayegh, and F. Ghassemi, "Online epileptic seizure prediction using wavelet-based bi-phase correlation of electrical signals tomography," *International journal of neural systems*, vol. 25, no. 06, p. 1550028, 2015.
- [19] S. M. Usman, M. Usman, and S. Fong, "Epileptic seizures prediction using machine learning methods," *Computational and mathematical methods in medicine*, vol. 2017, 2017.
- [20] S. W. Ibrahim, R. Djemal, A. Alsuwailam, and S. Gannouni, "Electroencephalography (EEG)-based epileptic seizure prediction using entropy and K-nearest neighbor (KNN)," *Communications in Science and Technology*, vol. 2, no. 1, 2017.
- [21] S. Yuan, W. Zhou, and L. Chen, "Epileptic seizure prediction using diffusion distance and bayesian linear discriminate analysis on intracranial EEG," *International journal of neural systems*, vol. 28, no. 01, p. 1750043, 2018.
- [22] Y. Park, L. Luo, K. K. Parhi, and T. Netoff, "Seizure prediction with spectral power of EEG using cost-sensitive support vector machines," *Epilepsia*, vol. 52, no. 10, pp. 1761-1770, 2011.
- [23] J. R. Williamson, D. W. Bliss, D. W. Browne, and J. T. Narayanan, "Seizure prediction using EEG spatiotemporal correlation structure," *Epilepsy & Behavior*, vol. 25, no. 2, pp. 230-238, 2012.
- [24] S. W. Ibrahim, R. Djemal, A. Alsuwailam, and S. Gannouni, "Electroencephalography (EEG)-based epileptic seizure prediction using entropy and K-nearest neighbor (KNN)." (accessed 1, 2).
- [25] <https://www.kaggle.com/c/seizure-prediction>. (accessed.
- [26] R. Tibshirani, "Regression shrinkage and selection via the lasso," *Journal of the Royal Statistical Society: Series B (Methodological)*, vol. 58, no. 1, pp. 267-288, 1996.
- [1] www.who.int/news-room/fact-sheets/detail/epilepsy (accessed.
- [2] P. Dekker and W. H. Organization, "Epilepsy: A manual for medical and clinical officers in Africa," Geneva: World Health Organization, 2002.
- [3] S. Viglione and G. Walsh, "Proceedings: Epileptic seizure prediction," *Electroencephalography and clinical neurophysiology*, vol. 39, no. 4, pp. 435-436, 1975.
- [4] B. Litt and K. Lehnertz, "Seizure prediction and the pre-seizure period," *Current opinion in neurology*, vol. 15, no. 2, pp. 173-177, 2002.
- [5] H. H. Lange, J. P. Lieb, J. Engel Jr, and P. H. Crandall, "Temporo-spatial patterns of pre-ictal spike activity in human temporal lobe epilepsy," *Electroencephalography and clinical neurophysiology*, vol. 56, no. 6, pp. 543-555, 1983.
- [6] I. Sherwin, "Interictal-ictal transition in the feline penicillin epileptogenic focus," *Electroencephalography and clinical neurophysiology*, vol. 45, no. 4, pp. 525-534, 1978.
- [7] B. Litt *et al.*, "Epileptic seizures may begin hours in advance of clinical onset: a report of five patients," *Neuron*, vol. 30, no. 1, pp. 51-64, 2001.
- [8] L. D. Iasemidis, J. C. Sackellares, H. P. Zaveri, and W. J. Williams, "Phase space topography and the Lyapunov exponent of electrocorticograms in partial seizures," *Brain topography*, vol. 2, no. 3, pp. 187-201, 1990.