

Using Support Vector Machines as an Intelligent Algorithm for Detecting Seizures from EEG Signals

Mojtaba Mohammadpoor*, Atefe Alizadeh

Department of Electrical and Computer Engineering, Gonabad Higher Education Complex, Gonabad, Iran

Article Info:

Received: 22 Aug 2020

Revised: 24 Dec 2020

Accepted: 10 Jan 2020

ABSTRACT

Introduction: Electroencephalography (EEG) is the most commonly used method to study the function of the brain. This study represents a computerized model for distinguishing between epileptic and healthy subjects using EEG signals with relatively high accuracy. **Materials and Methods:** The EEG database used in this study was obtained from the data available in Andrzejak. This dataset consists of 5 EEG sets (designated as A to E), each containing 100 EEG sections. Collections A and B comprised EEG signals that have been taken from 5 healthy volunteers. The C and D sets referred to EEGs from patients with focal epilepsy (without ictal recordings) and the E set was derived from a patient with ictal recording. Support vector machines were used after applying principal components analysis or linear discriminant analysis over the features of the signals. MATLAB has been used to implement and test the proposed classification algorithm. To evaluate the proposed method, the confusion matrix, overall success rate, ROC, and the AUC of each class were extracted. K-fold cross-validation technique was used to validate the results. **Results:** The overall success rate achieved in this study was above 82%. Dimension reduction algorithms can improve its accuracy and speed. **Conclusion:** It is helpful to be able to predict the occurrence of a seizure early and accurately. Using the computerized model represented in this study could accomplish this goal.

Keywords:

1. Seizures
2. Electroencephalography
3. Passive Cutaneous Anaphylaxis

*Corresponding Author: Mojtaba Mohammadpoor

Email: mohammadpur@gonabad.ac.ir



استفاده از ماشین‌های بردار پشتیبانی به عنوان یک الگوریتم هوشمند برای تشخیص تشنج از سیگنال‌های EEG

مجتبی محمدپور*، عاطفه علیزاده

گروه مهندسی برق و کامپیوتر، مجتمع آموزش عالی گناباد، گناباد، ایران

اطلاعات مقاله:

پذیرش: ۲۱ دی ۱۳۹۹

اصلاحیه: ۴ دی ۱۳۹۹

دریافت: ۱ شهریور ۱۳۹۹

چکیده

مقدمه: الکتروانسفالوگرافی (EEG) متداول‌ترین روش برای مطالعه عملکرد مغز است. این مقاله یک مدل رایانه‌ای برای تمایز بین افراد صرعی و سالم با استفاده از سیگنال‌های EEG با دقت نسبتاً بالا ارائه می‌دهد. **مواد و روش‌ها:** پایگاه داده EEG مورد استفاده در این مطالعه از داده‌های موجود در Andrzejak گرفته شده است. این مجموعه داده متشکل از ۵ مجموعه سیگنال‌های EEG (مشخص شده از A تا E) است که هر یک شامل ۱۰۰ بخش EEG می‌باشد. مجموعه‌های A و B شامل سیگنال‌های EEG هستند که از ۵ داوطلب سالم گرفته شده‌اند. مجموعه‌های C و D به EEG های بیماران مبتلا به صرع کانونی (بدون ضبط ictal) می‌باشند و مجموعه E از یک بیمار با ضبط ictal گرفته شده است. ماشین‌های بردار پشتیبان پس از استفاده از تجزیه و تحلیل مولفه‌های اصلی یا تجزیه و تحلیل تفکیکی خطی از ویژگی‌های سیگنال‌ها استفاده شدند. نرم‌افزار متلب برای پیاده‌سازی و آزمایش الگوریتم طبقه‌بندی پیشنهادی استفاده شده است. برای ارزیابی روش پیشنهادی، ماتریس سردرگمی، میزان موفقیت کلی، منحنی ROC و AUC هر کلاس استخراج شد. برای تأیید نتایج از روش اعتبارسنجی متقابل K برابر استفاده شد. **یافته‌ها:** میزان موفقیت کلی به دست آمده در این مطالعه بالاتر از ۸۲ درصد بود. الگوریتم‌های کاهش ابعاد می‌توانند دقت و سرعت آن را بهبود بخشند. **نتیجه‌گیری:** پیش بینی دقیق و زود هنگام وقوع تشنج بسیار مفید است. استفاده از مدل رایانه‌ای ارائه شده در این مطالعه می‌تواند این هدف را محقق سازد.

واژه‌های کلیدی:

- ۱- تشنج
- ۲- الکتروانسفالوگرافی
- ۳- آنافیلاکسی پوستی منفعل

*نویسنده مسئول: مجتبی محمدپور

پست الکترونیک: mohammadpur@gonabad.ac.ir

مقدمه

پیشنهادی مورد استفاده قرار می‌گیرد، سپس مدل با پیش‌بینی کلاس سایر سیگنال‌ها و مقایسه کلاس‌های پیش‌بینی شده با کلاس‌های واقعی، ارزیابی می‌شود.

مواد و روش‌ها

بانک اطلاعاتی EEG که در این مطالعه استفاده می‌شود، توسط Andrzejak و همکاران تهیه شده است (۱۶، ۱۵). این داده‌ها از ۵ مجموعه سیگنال‌های EEG (که با عناوین A تا E نامگذاری گردیده‌اند) تشکیل شده است که هر مجموعه شامل ۱۰۰ سیگنال EEG ضبط شده است. فرکانس نمونه‌گیری از سیگنال‌ها ۱۷۳/۶ هرتز و وضوح آن ۱۲ بیت است. سیگنال‌ها از افراد ۶ تا ۴۳ ساله و با استفاده از روش قرار دادن الکتروود استاندارد ۲۰-۱۰ ضبط شده‌اند. مجموعه‌های A و B از سیگنال‌های EEG از ۵ داوطلب سالم تشکیل شده است. مجموعه‌های C و D متعلق به ضبط‌های متناوب از بیماران مبتلا به صرع کانونی و مجموعه E از ضبط‌های ictal است.

استخراج ویژگی

یک گام مهم در فرایند طبقه‌بندی، استخراج خصوصیات مناسب از سیگنال‌های خام است که باید نماینده خوبی از سیگنال اولیه باشد و بتواند بهترین تمایز را بین کلاس‌های مختلف داده فراهم کند. برای این کار از روش‌های زیر استفاده کردیم.

تبدیل موجک گسسته

با توجه به خصوصیات غیر ثابت سیگنال‌های EEG روش‌های فرکانس زمانی مانند تبدیل موجک می‌تواند روی آن‌ها اعمال شود تا اجزای فرکانس آنها نسبت به زمان استخراج شود. برای این کار، تبدیل موجک گسسته^۳ (DWT) به دلیل وضوح زمانی بالا استفاده می‌شود. این روش در اکثر روش‌های موجود به‌عنوان مثال در مراجع استفاده شده است (۱۷، ۶). انرژی هر کدام از سطوح تبدیل موجک سیگنال می‌تواند به‌عنوان پارامتری از سیگنال انتخاب شود. بدین منظور، ابتدا موجک مادر و تعداد سطح تجزیه مشخص می‌شود و سپس میانگین انرژی سطوح مختلف تجزیه که همان انرژی ضرایب موجک است محاسبه می‌شود (۱۷). در این تحقیق، سیگنال به پنج زیر باندها فرکانس تجزیه می‌شود و متوسط انرژی برای هر کدام محاسبه و در نظر گرفته می‌شود. آنتروپی معیاری برای اندازه‌گیری بی‌نظمی یا پیچیدگی یک سری زمانی است. هر چه مقدار آنتروپی بالاتر باشد، به معنای پیچیدگی یا بی‌نظمی بیشتر سیگنال است. آنتروپی نه تنها به

صرع یکی از شایع‌ترین اختلالات سیستم عصبی مرکزی است که حدود ۱ درصد از جمعیت جهان را تحت تأثیر قرار می‌دهد. تشنج صرع ناشی از تخلیه عصبی غیرعادی بیش از حد است (۱). از آنجا که تشنج‌های صرع به طور ناگهانی در فعالیت طبیعی مغز ایجاد اختلال می‌کنند، ممکن است منجر به از دست رفتن غیرقابل پیش‌بینی و ناگهانی هوشیاری و لذا اختلال در رفتارها، حرکات و احساسات بیماران شود. در نتیجه، بیماران مبتلا به صرع ممکن است تصادفات و جراحات بدنی یا حتی مرگ را با تشنج خود تجربه کنند (۳). یکی از راه‌های جلوگیری از این پیامدها در بیماران مبتلا به صرع، توسعه و استفاده از وسایل و روش‌هایی است که می‌توانند وقوع حمله صرعی را سریع و دقیق تشخیص دهند. چنین وسایلی، به‌عنوان مثال، می‌توانند با پیش‌بینی وقوع تشنج و با مصرف خودکار داروها یا محرک‌های الکتریکی از بروز تشنج صرع جلوگیری کنند، یا حمله اولیه را بعد از شروع بلا اثر کنند، یا حداقل در اسرع وقت به افراد نزدیک بیمار در معرض خطر اطلاع رسانی کنند (۴). بررسی فعالیت‌های مغزی که توسط الکتروانسفالوگرافی^۱ (EEG) ضبط شده است یک تکنیک مهم و متداول برای بررسی عملکردها و اختلالات مغزی است (۵). روش‌های زیادی برای تجزیه و تحلیل سیگنال‌های EEG وجود دارد. بازرسی بصری، آنالیز طیفی، تبدیل موجک گسسته برای تجزیه و تحلیل سیگنال‌های غیر ثابت، آنتروپی، شبکه‌های عصبی مصنوعی و بسیاری از تکنیک‌ها و فن‌آوری‌های دیگر بدین منظور ارائه شده‌اند. برخی به طور خاص به‌عنوان ابزار پیش‌بینی در حال توسعه هستند (۱۴-۶). تشنج صرع از چندین نوع تشکیل شده است. شرایط دیگری نیز وجود دارد که ممکن است شباهت‌هایی به تشنج صرع داشته باشند، اما دارای طبیعت متفاوتی باشند (به عنوان مثال، تشنج غیر صرع روانشناختی (PNES)). آنها فاقد منشأ عصب‌شناسی مشابه تشنج صرع هستند و با تغییرات صرع الکتروفیزیولوژیکی همراه نیستند (۲۷). برخی روش‌های طبقه‌بندی برای این منظور معرفی شده‌اند. به‌عنوان مثال آویس و عبدالحی در فقط از ویژگی‌های HHT برای طبقه‌بندی افراد سالم و تشنج استفاده کرده‌اند (۱۱). سوپاسی و گرسوی در از ویژگی‌های DWT برای همین منظور استفاده می‌کردند (۲۰). آن‌ها با استفاده از روش‌های PCA، LDA و... از ویژگی‌های مفید DWT بیشتری استفاده کردند. هدف از این مطالعه ارائه یک روش طبقه‌بندی دقیق است که بتواند سیگنال‌های EEG را طبقه‌بندی کند. برای این منظور، بخشی از سیگنال‌های موجود برای آموزش مدل

^۱Electroencephalography^۲Psychogenic Nonepileptic Seizures^۳Discrete Wavelet Transform

ماشین های بردار پشتیبان

یکی از محبوب ترین الگوریتم های طبقه بندی است که در بسیاری از زمینه ها مانند پردازش گفتار، یادگیری ماشین، تشخیص فعالیت و غیره مورد استفاده قرار گرفته است. مبنای SVM غیرخطی شامل تطابق یک عملکرد هسته غیرخطی برای تبدیل داده های ورودی به یک فضای با وضوح بالا است که باعث می شود تمایز داده ها از فضای ورودی اصلی آسان تر شود (۲۳). بسته به نوع داده، می توان از انتخاب مناسب هسته استفاده کرد. ماشین بردار پشتیبان^۶ (SVM) یک طبقه بندی باینری است، بنابراین در صورت وجود بیش از یک کلاس، باید آن را به چند طبقه تعمیم دهیم؛ دو روش برای این کار وجود دارد: روش یکی در مقابل یکی، و روش یکی در مقابل بقیه (۲۴).

دقت مطالعه غربالگری

هنگام انجام هر مطالعه تشخیصی، هر شخصی مورد آزمایش ممکن است بیماری داشته باشد یا نداشته باشد. نتیجه آزمایش می تواند مثبت (طبقه بندی فرد به عنوان بیماری) یا منفی (طبقه بندی فرد به عنوان عدم بیماری) باشد. نتایج آزمون برای هر موضوع ممکن است با وضعیت واقعی آن مطابقت داشته باشد. پارامترهای زیر در این خصوص قابل تعریف است:

• مثبت واقعی^۸ (TP): افراد بیمار که به درستی بیمار شناخته می شوند.

• مثبت کاذب^۹ (FP): افراد سالم که به اشتباه به عنوان بیمار شناخته می شوند.

• منفی واقعی^{۱۰} (TN): افراد سالم که به درستی به عنوان سالم شناخته می شوند.

• منفی کاذب^{۱۱} (FN): افراد بیمار که به اشتباه به عنوان سالم شناخته می شوند (۲۵).

این اندازه گیری را می توان در یک ماتریس در هم ریختگی نشان داد، همان طور که در جدول ۱ نشان داده شده است. دقت کلی طبقه بندی را می توان با جمع

درک پویایی و اختلال در سیگنال های EEG مغز کمک می کند بلکه می توان از آن برای تشخیص تشنج نیز استفاده کرد، زیرا به دلیل کارکرد همزمان گروه های عصبی در طی یک فعالیت سریع، آنتروپی از سیگنال های EEG در طی تشنج ناگهان کاهش می یابد (۱۹، ۱۸).

تبدیل هیلبرت- هوانگ

هیلبرت- هوانگ^۴ (HHT) یک ابزار تجزیه و تحلیل قدرتمند داده می باشد که توسط هوانگ ارائه شده است که می تواند اجزای دوره ای تعبیه شده در سیگنال های احتمالا غیرخطی و غیر ثابت را استخراج کند (۲۱). HHT از دو مؤلفه تشکیل شده است: یک الگوریتم تجزیه به نام تجزیه حالت تجربی (EMD) و یک ابزار تجزیه و تحلیل طیفی به نام آنالیز طیفی هیلبرت. با توجه به ویژگی های سیگنال های EEG، می توان از روش HHT برای تجزیه و تحلیل آن ها استفاده کرد (۱۱).

آنالیز تشخیصی خطی

هدف آنالیز تشخیصی خطی^۵ (LDA) ایجاد متغیرهای جدیدی از ترکیب مقادیر اصلی است که حداکثر تفاوت بین گروه ایجاد کند. هدف این است که امتیازات متغیرهای پیش بینی شده و ترکیب آن ها برای تشکیل یک متغیر ترکیبی جدید بهتر ارائه شود. به طور کلی، پیش بینی کننده هایی که تفاوت زیادی بین گروه ها ایجاد می کنند وزن بیشتری دارند (۲۰).

تجزیه و تحلیل مؤلفه اصلی

تجزیه و تحلیل مؤلفه اصلی^۶ (PCA) روش خوبی برای استخراج ویژگی ها و کاهش ابعاد است. در PCA سعی می شود داده ها در یک فضای با ابعاد کمتر نشان داده شود تا باعث کاهش پیچیدگی فضا و زمان شود. در این روش، ابتدا بردار میانگین و ماتریس کواریانس آن برای داده ها محاسبه می شود، سپس بردارهای ویژه و مقادیر ویژه آنها محاسبه و به ترتیب صعودی مرتب می شوند. در ادامه، بر حسب نیاز بزرگترین ویژگی ها انتخاب می شوند و ابعاد دیگر نادیده گرفته می شوند (۲۰).

جدول ۱- پارامترهای ماتریس درهم ریختگی

وضعیت تخمین زده شده \ وضعیت واقعی	مثبت	منفی
مثبت	مثبت واقعی	منفی کاذب
منفی	مثبت کاذب	منفی واقعی

^۴ Hilbert-Huang Transform

^۵ Linear discriminate Analysis

^۶ Principal component Analysis

^۷ Support Vector Machines


^۸ True Positive

^۹ False positive

^{۱۰} True Negative

^{۱۱} False Negative

هوانگ به عنوان ویژگی‌های سیگنال و سپس اعمال الگوریتم‌های LDA و PCA برای تنظیم ویژگی‌ها؛ و در آخر، یک طبقه‌بندی SVM پنج طبقه برای طبقه‌بندی سیگنال‌ها می‌باشد. تصویر ۱ چارچوب کلی روش پیشنهادی را نشان می‌دهد.



تصویر ۱- فلوچارت روش پیشنهادی

انتخاب موجک مناسب و تعداد سطوح تحلیلی در آنالیز سیگنال با استفاده از تبدیل موجک گسسته از اهمیت بالایی برخوردار است. تعداد سطوح آنالیز بر اساس اجزای فرکانس سیگنال انتخاب می‌شود. از آنجا که سیگنال‌های EEG هیچ مؤلفه فرکانس مفیدی بیش از ۳۰ هرتز ندارند، تعداد سطوح تجزیه سیگنال برابر ۵ انتخاب می‌شود. الگوریتم SVM برای طبقه‌بندی پس از اعمال PCA، LDA و ترکیب آن‌ها بر ویژگی‌های سیگنال استفاده می‌شود. برای ارزیابی روش پیشنهادی، ماتریس درهم ریختگی، میزان موفقیت کلی، منحنی ROC و سطح زیر منحنی آن استخراج می‌شود. از روش اعتبارسنجی متقاطع k-fold با مقدار k=5 استفاده شده است.

یافته‌ها

در این مطالعه، از سیگنال‌های EEG از مجموعه داده‌های اندروژاک استفاده گردید. مدلی برای پیش‌بینی دقیق هر ترکیبی از ورودی‌هایی که در یکی از پنج کلاس (A-E) قرار می‌گیرند پیشنهاد داده شد. به‌منظور مشاهده عملکرد الگوریتم پیشنهادی، ابتدا به‌عنوان مرحله استخراج ویژگی، با اعمال تکنیک‌های تبدیل موجک و هیلبرت هوانگ و محاسبه پارامترهایی مثل

کردن پارامترهای منفی مثبت و منفی واقعی و تقسیم آن بر کل جمعیت محاسبه کرد. در صورت طبقه‌بندی چندکلاسی، اندازه ماتریس درهم ریختگی به اندازه تعداد کلاس‌ها افزایش می‌یابد، از این رو مقادیر پیش بینی غلط ممکن است در سلول‌های مختلف قرار گیرند، اما مقادیر مورب هنوز حاکی از میزان پیش بینی واقعی است. محبوب‌ترین معیار برای دقت طبقه‌بندی، میزان موفقیت کلی (OSR) به‌عنوان پارامتری از ماتریس درهم ریختگی عادی تعریف می‌شود (۲۵).

منحنی مشخصه عملکرد سیستم

این منحنی که با رسم میزان مثبت واقعی (حساسیت) بر حسب میزان مثبت کاذب در آستانه‌های مختلف ایجاد می‌شود روشی گرافیکی برای بیان خصوصیات غربالگری یک آزمایش می‌باشد. سطح زیر این منحنی (AUC) کیفیت کلی آزمون‌های تشخیصی را نشان می‌دهد که هر چه به یک نزدیک‌تر باشد مبین دقت بالاتری می‌باشد.

اعتبارسنجی متقاطع

اعتبارسنجی متقاطع^{۱۲} یک روش اعتبارسنجی متداول برای اندازه‌گیری چگونگی نتایج حاصل از تجزیه و تحلیل آماری در یک مجموعه داده مستقل است. در اعتبارسنجی متقاطع k-fold^{۱۳}، مجموعه داده به طور تصادفی به k قسمت تقریباً مساوی تقسیم می‌شوند. قسمت k ام به‌عنوان داده‌های صحت‌سنجی برای آزمایش مدل نگهداری می‌شود و نمونه‌های k-1 باقیمانده به‌عنوان داده‌های آموزش استفاده می‌شوند. این فرایند k بار به صورت چرخشی تکرار می‌شود تا همه قسمت‌ها پوشش داده شوند (۲۶).

روش پیشنهادی

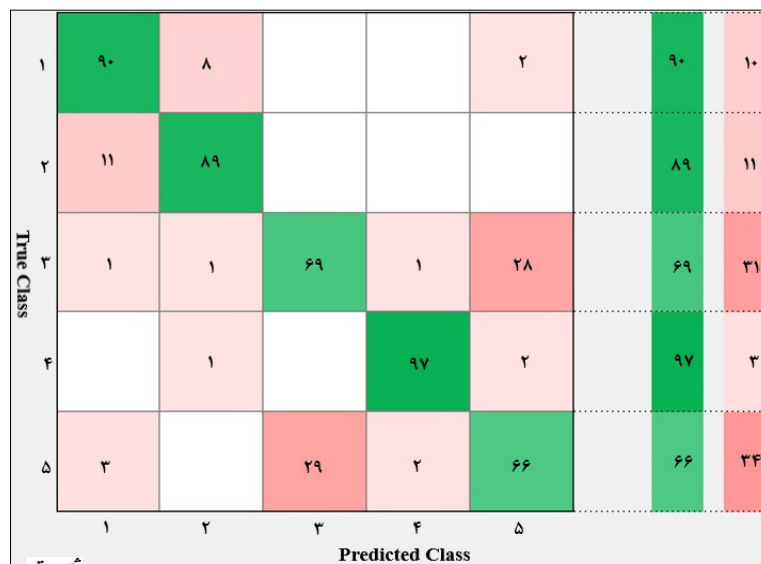
تشخیص تشنج صرع با استفاده از سیگنال‌های مغزی شامل مراحل دریافت سیگنال از مغز، استخراج ویژگی‌های مناسب سیگنال، کاهش ابعاد ویژگی‌ها، استفاده از الگوریتم طبقه‌بندی مناسب، آموزش آن و سپس استفاده برای تشخیص تشنج است. هدف در این مطالعه، ارائه طبقه‌بندی است که بتواند هر کدام از ورودی‌های متعلق به هر پنج کلاس داده را شناسایی کند. برای این منظور، روش پیشنهادی مبتنی بر استخراج انرژی و آنتروپی موجک‌ها و تبدیل هیلبرت-

^{۱۲} Cross validation

^{۱۳} K-fold cross validation

عمل به صورت چرخشی روی تمام پنج قسمت تکرار می‌شود. به علت ماهیت تصادفی قسمت‌بندی هر بار ممکن است نتایج اندکی تغییر کند. در این تحقیق، در میان انواع کلاسیفایرها الگوریتم‌های SVM و En-semble عموماً بالاترین دقت تشخیص را دارا می‌باشند. به‌عنوان نمونه، در یک اجرا دقت هر دو الگوریتم ۸۲ درصد گزارش گردید. تصویر ۲ ماتریس درهم ریختگی الگوریتم SVM را نشان می‌دهد.


انرژی و توان آن‌ها بر هر سیگنال EEG برداری به طول ۴۵ داده تشکیل می‌شود که با اجرای آن بر روی تمام سیگنال‌ها ماتریس میانی با ابعاد 50×45 جهت مراحل بعدی تهیه می‌گردد. با اعمال روش اعتبار سنجی K-fold به ازای $K=5$ داده‌های هر کلاس به صورت تصادفی به پنج قسمت مساوی تقسیم می‌شود. تمام الگوریتم‌های طبقه‌بندی موجود روی یکی از قسمت‌ها اعمال و دقت آن‌ها با چهار قسمت باقی مانده سنجیده می‌شود. این



تصویر ۲- ماتریس درهم ریختگی حاصل اجرای الگوریتم SVM بدون کاهش ابعاد

به‌منظور بررسی اثر الگوریتم تجزیه و تحلیل مؤلفه اصلی (PCA)، این الگوریتم با تعداد مولفه‌های اصلی (PCs) مختلف اعمال می‌شود. تصویر ۴ اثر اعمال الگوریتم PCA را روی پارامتر دقت الگوریتم SVM نشان می‌دهد. منحنی افقی تعداد اجزاء اصلی (PCs) را نشان می‌دهد.

منحنی ROC می‌تواند کمک شایانی به بررسی بیشتر الگوریتم بنماید. از آنجا که این منحنی برای طبقه‌بندی‌های دوکلاسه تعریف شده است، بدون از دست دادن عمومیت، کلاس اول نسبت به مجموع چهار کلاس دیگر سنجیده می‌شود. تصویر ۳ منحنی ROC و سطح زیر آن را نشان می‌دهد.



تصویر ۳- منحنی ROC حاصل از اجرای الگوریتم SVM بدون کاهش ابعاد


ماتریس درهم ریختگی و منحنی ROC این مرحله را نشان می‌دهند.

بحث و نتیجه‌گیری

از نظر بالینی بسیار مهم است که بتوانیم بیماران مبتلا

همانطور که مشاهده می‌شود الگوریتم PCA بهبود محسوسی بر دقت الگوریتم ایجاد نمی‌کند. با اعمال الگوریتم آنالیز تشخیصی خطی (LDA) ابعاد داده‌های ویژگی به ۴ کاهش می‌یابد. با این روش دقت الگوریتم به ۸۳ و ۶ درصد می‌رسد. تصویرهای ۵ و ۶ به ترتیب،


SVM Accuracy



تصویر ۴- اثر اعمال الگوریتم PCA روی پارامتر دقت الگوریتم SVM

True Class	۱	۲	۳	۴	۵		۱	۲
	۹۹	۱					۹۹	۱
	۱۳	۸۶			۱		۸۶	۱۴
	۲		۷۱		۲۷		۷۷	۲۹
			۱	۹۶	۳		۹۶	۴
درصد	۲	۱	۲۹	۲	۶۶		۶۶	۲۴
Predicted Class								
						درصد		
						۱ ۲ ۳ ۴ ۵		

تصویر ۵- ماتریس درهم ریختگی با اعمال الگوریتم LDA



تصویر ۶- منحنی ROC با اعمال الگوریتم LDA

جدید مانند موارد سالم و تشنج، همان طور که در انجام می شود، ممکن است به دلیل ساختار دودویی آن ها، توانایی طبقه بندی را قوی تر کند، اما کارایی مدل را از نظر پزشکی کاهش می دهد (۲۰، ۱۱). نتایج حاصله نشان می دهند که روش استخراج ویژگی ارائه شده و اسنفاده از الگوریتم SVM منجر به ارائه مدلی با دقت قابل قبول در تفکیک سیگنال های EEG افراد سالم یا مبتلای به حملات صرعی می گردد. همچنین نتایج نشان می دهند که کاهش ابعاد ویژگی ها با کمک ترکیب الگوریتم های PCA و LDA می تواند علاوه بر بهبود سرعت سیستم، دقت تشخیص را نیز بهبود بخشد. از آنجا که الکتروانسفالوگرافی (EEG) رایج ترین فن آوری برای بررسی عملکرد و اختلال عملکرد مغز می باشد، و نظر به اهمیت تشخیص سریع حملات صرعی، در این مقاله روشی جهت کلاسه بندی سیگنال های EEG با استفاده از ابزارهای مختلف و با کمک ماشین های بردار پشتیبان ارائه گردید. از پایگاه داده های موجود در اینترنت جهت بررسی عملکرد الگوریتم پیشنهادی ارائه گردید. با اعمال الگوریتم بر روی هر پنج کلاس سیگنال ها و استفاده از روش اعتبار سنجی متقاطع میزان کل موفقیت بالای ۸۲ درصد بدست آمد که دقت قابل قبولی می باشد. روش های کاهش ابعاد می تواند بر دقت و سرعت الگوریتم بیافزاید. الگوریتم پیشنهادی می تواند به تشخیص حملات صرعی کمک کند.

به صرعی را از کسانی که صرعی ندارند و ممکن است ناشی از شرایط دیگر (به عنوان مثال، PNES) باشند، را با دقت بالا تفکیک کرد. در این مطالعه، ما روشی را برای تفکیک بین هر پنج کلاس مختلف از داده های EEG با دقت مناسب ارائه کرده ایم. در روش پیشنهادی از ویژگی های بیشتری با افزودن HHT و DWT استفاده کردیم، آن ها را با استفاده از PCA و LDA تنظیم مجدد کرده و سپس آن ها را با استفاده از طبقه بندی SVM تفکیک کردیم.

توانایی عمومی سازی هر الگوریتم طبقه بندی هنوز یک مسئله باز است. در واقع، اگر نمونه های آموزش و تست به درستی و جامع انتخاب نشوند، دستیابی به دقت مناسب نمی تواند عملکرد آن را در صورت مشاهده موارد جدید تضمین کند. به عنوان مثال سوباسی و گرسوی در ۵۰ درصد از مجموعه داده ها را برای آموزش و ۵۰ درصد دیگر برای آزمون استفاده کرده اند (۲۰). در این تحقیق از آزمون اعتبارسنجی k-fold استفاده شده که k بار تکرار می شود، تا اطمینان حاصل شود که تمام سیگنال ها این شانس را دارند که حداقل یک بار به عنوان آموزش انتخاب شوند. یکی دیگر از مزایای روش پیشنهادی نسبت به روش های موجود، طبقه بندی سیگنال های EEG با چند کلاس است. در این مقاله، هر پنج کلاس به صورت جداگانه در نظر گرفته می شوند. اگر چه ادغام دو یا چند کلاس با هم و ایجاد گروه های

منابع

1. Litt B, Echauz J. Prediction of epileptic seizures. *The Lancet Neurology*. 2002 May 1; 1(1): 22-30.
2. Asadi-Pooya AA, Nikseresht AR, Yaghoobi E, Nei M. Physical injuries in patients with epilepsy and their associated risk factors. *Seizure* 2012; 21: 165-68.
3. Asadi-Pooya AA, Sperling MR. Clinical features of sudden unexpected death in epilepsy. *J Clin Neurophysiol* 2009; 26(5): 297-301.
4. Bronzino JD. Principles of electroencephalography. *The biomedical engineering handbook*. 1995;1.
5. Doppelbauer A, Zeitlhofer J, Zifko U, Baumgartner C, Mayr N, Deecke L. Occurrence of epileptiform activity in the routine EEG of epileptic patients. *Acta neurologica scandinavica*. 1993 May; 87(5): 345-52.
6. Subasi A. EEG signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*. 2007 May 1; 32(4): 1084-93.
7. Bashar MK, Reza F, Idris Z, Yoshida H. Epileptic seizure classification from intracranial EEG signals: A comparative study EEG-based seizure classification. In *Biomedical Engineering and Sciences (IECBES)*, 2016 IEEE EMBS Conference on 2016 Dec 4 (pp. 96-101). IEEE.
8. Gupta A, Singh P, Karlekar M. A Novel Signal Modeling Approach for Classification of Seizure and Seizure-Free EEG Signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. 2018 May; 26(5): 925-35.
9. Li Y, Wang XD, Luo ML, Li K, Yang XF, Guo Q. Epileptic seizure classification of EEGs using time-frequency analysis based multiscale radial basis functions. *IEEE journal of biomedical and health informatics*. 2018 Mar; 22(2): 386-97.
10. Correa AG, Laciari E, Orosco L, Gomez ME, Otoya R, Jane R. An energy-based detection algorithm of epileptic seizures in EEG records. In *Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE 2009 Sep 3* (pp. 1384-1387). IEEE.
11. Oweis RJ, Abdulhay EW. Seizure classification

- in EEG signals utilizing Hilbert-Huang transform. Biomedical engineering online. 2011 Dec; 10(1): 38.
12. Jiang Y, Wu D, Deng Z, Qian P, Wang J, Wang G, Chung FL, Choi KS, Wang S. Seizure Classification from EEG Signals using Transfer Learning, Semi-Supervised Learning and TSK Fuzzy System. IEEE Transactions on Neural Systems and Rehabilitation Engineering. 2017 Dec; 25(12): 2270-84.
 13. Fasil OK, Rajesh R. Time-domain exponential energy for epileptic EEG signal classification. Neuroscience Letters. 2019 Feb 16; 694: 1-8.
 14. Jothiraj SN, Selvaraj TG, Ramasamy B, Deivendran NP, Subathra MS. Classification of EEG signals for detection of epileptic seizure activities based on feature extraction from brain maps using image processing algorithms. IET Image Processing. 2018 Aug 14; 12(12): 2153-62.
 15. Andrzejak RG, Lehnertz K, Mormann F, Rieke C, David P, Elger CE. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. Physical Review E. 2001 Nov 20; 64(6): 061907.
 16. <https://archive.ics.uci.edu/ml/datasets/Epileptic+Seizure+Recognition>
 17. Guo L, Rivero D, Seoane JA, Pazos A. Classification of EEG signals using relative wavelet energy and artificial neural networks. In Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation 2009 Jun 12 (pp. 177-184). ACM.
 18. Acharya UR, Molinari F, Sree SV, Chattopadhyay S, Ng KH, Suri JS. Automated diagnosis of epileptic EEG using entropies. Biomedical Signal Processing and Control. 2012 Jul 1; 7(4): 401-8.
 19. Ocak H. Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm. Signal processing. 2008 Jul 1; 88(7): 1858-67.
 20. Subasi A, Gursoy MI. EEG signal classification using PCA, ICA, LDA and support vector machines. Expert systems with applications. 2010 Dec 1; 37(12): 8659-66. [17] Mallat, S. (1999). A wavelet tour of signal processing. Elsevier.
 21. Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, Yen NC, Tung CC, Liu HH. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. In Proceedings of the Royal Society of London A: mathematical, physical and engineering sciences 1998 Mar 8 (Vol. 454, No. 1971, pp. 903-995). The Royal Society.
 22. Lin YP, Wang CH, Wu TL, Jeng SK, Chen JH. Support vector machine for EEG signal classification during listening to emotional music. In Multimedia Signal Processing, 2008 IEEE 10th Workshop on 2008 Oct 8 (pp. 127-130). IEEE.
 23. Richhariya B, Tanveer M. EEG signal classification using universum support vector machine. Expert Systems with Applications. 2018 Sep 15; 106: 169-82.
 24. Murugavel AM, Ramakrishnan S. Hierarchical multi-class SVM with ELM kernel for epileptic EEG signal classification. Medical & biological engineering & computing. 2016 Jan 1; 54(1): 149-61.
 25. https://en.wikipedia.org/wiki/Sensitivity_and_specificity, accessed 28 Jan 2019.
 26. Labatut V, Cherifi H. Evaluation of performance measures for classifiers comparison. arXiv preprint arXiv:1112. 4133. 2011 Dec 18.
 27. Polat K, Güneş S. Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. Applied Mathematics and Computation. 2007 Apr 15; 187(2): 1017-26.
 28. Asadi-Pooya AA, Sperling MR. Epidemiology of psychogenic non-epileptic seizures. Epilepsy Behav 2015; 46: 60-65.