

معرفی مشخصه استخراج غیرخطی مبتنی بر ضرایب DT-CWT سیگنال های EEG مغز برای تشخیص تشنج های صرعی

افشین کلیجی^۱، نعمت الله عزتی^۲، محسن باهنر^۳، عبدالله جعفری چاشمی^۴، احسان مصطفی پور^{*۵ و ۶}
۱- دانشگاه صنعتی ارومیه ، ۲- دانشگاه آزاد اسلامی واحد مهدی شهر، ۳- دانشگاه ارومیه

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۳/۲۰ پذیرش مقاله: ۱۴۰۲/۰۷/۱۵	صرع نوعی بیماری مغزی است که بررسی و تحلیل سیگنال های EEG قابل تشخیص است. بیماری صرع غالبا در کودکان رخ می دهد. با این وجود، برخی از موارد در بزرگسالان نیز مشاهده می شود. تشخیص این بیماری در مراحل اولیه برای پزشکان یک کار چالش برانگیز است. نویسندهای در این کار، سیگنال EEG صرعی و طبیعی را با اتخاذ رویکرد یادگیری ماشین کلاس بندی کرده اند. برای دست یابی به ویژگی های کارآمد، موجک مختلط درختی دوگانه در نظر گرفته شده است. سپس، از ضرایب موجک برای استخراج ویژگی غیرخطی استفاده می شود. این ویژگی ها به عنوان ورودی کلاس بند تابع پایه همبریدی شعاعی استفاده می گردد. با استفاده از روش پیشنهادی، حدود ۹۹ درصد دقیق کلاس بندی مشاهده می شود. این امر، سبب بهبود قابل توجه الگوریتم پیشنهادی در مقایسه با سایر الگوریتم های ارائه شده قبلی است. با توجه به داشتن نویسندهای، این اولین بار است که جهت تشخیص صرع از استخراج ویژگی غیرخطی بر روی ضرایب یک سیگنال EEG استفاده می شود.
واژگان کلیدی: صرع، الگوریتم k-means، مشخصه های غیر خطی، شبکه های تابع پایه ساعی، کلاس بندی EEG مغز، کاهش ویژگی	

1. مقدمه

تخصص صرع از طریق معاینه بالینی و مشاهده بصری سیگنال الکتروانسفالوگرام (EEG) تشخیص داده می شود.

سیگنال EEG معمول، مهمترین نمایش بصری در تشخیص صرع و تشنج های صرعی است. بررسی عدم تقارن در سیگنال یا کاهش قابل توجه در فعالیت سطح، اطلاعات مهمی در مورد سندروم های الکترو-کلینیکال ارائه می دهد. باید به خاطر داشت که هر EEG طبیعی، بیانگر غیرمحتمل بودن صرع نیست و هر ناهنجاری EEG نشان دهنده صرع نمی باشد. سیگنال EEG برای تشخیص صرع بسیار مهم است، زیرا با اندازه گیری جریان های یونی وابسته به احساس در نورون های مغز و اختلاف پتانسیل بین الکترودها در امتداد پوست سر بیمار، اطلاعات مکانی و زمانی ارزشمندی را در مورد مغز ارائه می دهد [۱۲، ۱۳]. تشخیص ناهنجاری در EEG نیاز به معاینه توسط متخصصان مغز و اعصاب و صرع شناسان آموزش دیده دارد و می تواند زمان بر باشد. علاوه بر این، کارشناسان با تجربیات تشخیصی متفاوت ممکن است نظرات متفاوتی در مورد نتایج تشخیصی داشته باشند [۱۴، ۱۵]. به همین دلیل، توسعه یک

صرع یک بیماری مزمن عصبی است که قابل تشخیص است [۴-۱]. پیش از ۶۰ میلیون بیمار صرع در جهان وجود دارد و بیش از ۸۰ درصد از این بیماران در کشورهای در حال توسعه زندگی می کنند. بر اساس گزارش سازمان بهداشت جهانی (WHO)، صرع یکی از شایع ترین اختلالات عصبی در جهان است [۶]. تحقیقات علمی در مورد صرع، علل و درمان آن اغلب بر روی مناطق خاصی از مغز مرکز است [۵-۷].

بیماران مبتلا به صرع در معرض تشنج های ناگهانی و غیرقابل پیش بینی قرار می گیرند، به طوری که نمی توانند از خود محافظت کنند و ممکن است در اثر غش، با جراحت در تصادفات رانندگی جان خود را از دست بدهند [۸، ۹]. اولین گام در ارزیابی بیمار، تعیین این موضوع است که آیا تشنج صرع تصور بالینی دارد یا خیر [۱۰]. امروزه درمان ضد تشنج برای همه انواع صرع کاملاً مؤثر نیست [۱۱]. در حال حاضر، صرع توسط یک متخصص مغز و اعصاب یا یک فوق

را بر اساس تبدیل موجک گستته بررسی کردند [۴۰، ۳۹]. در این روش برای هر قسمت از EEG، آنالیز پنج سطحی اعمال می‌شود و پنج ویژگی از ضرایب موجک استخراج می‌شود. بردار ویژگی استخراج شده برای آموزش یک جنگل تصادفی استفاده می‌شود که کلاس بندی را برای تشخیص داده‌های EEG اکتال (در زمان حمله) از اینترکتال (بین حملات) انجام می‌دهد. روش‌های فوق همگی نیازمند اصلاح دستی روش‌های استخراج ویژگی برای انجام بهتر مراحل بعدی، یعنی کلاس بندی مؤثر هستند [۴۱، ۴۲]. پیشرفت‌های اخیر در یادگیری عمیق (DL) [۴۳-۴۶]، راهی برای حذف نیاز به تغییرات دستی در روش‌های استخراج ویژگی [۴۷] فراهم می‌کنند. به عنوان مثال، در مقاله حسن پور و همکاران [۴۸]، یک روش صفر تا صد DL برای کلاس بندی چند کلاسه سیگنال‌های EEG بصری حرکتی ارائه شده است. یکی از مؤثرترین روش‌های DL، شبکه عصبی کانولوشنی^۳ (CNN) [۴۳-۴۶] می‌باشد که برای پیش‌بینی صرع و اختلال روانی استفاده شده است [۵۲، ۵۳]. در نهایت در مرجع [۵۴] از CNN برای بهبود تشخیص تشنج صرع استفاده و درصدهای بالایی در این زمینه ارائه شده‌اند.

۲. روش تحقیق

۲-۱. استخراج و انتخاب ویژگی

روش کلی پیشنهادی تشخیص صرع بر اساس سیگنال‌های در شکل (۱) نشان داده شده است. پس از استخراج ویژگی، از الگوریتم تجزیه و تحلیل تفکیک رگرسیون طیفی (SRDA) برای کاهش تعداد ویژگی‌ها و بار محاسباتی استفاده می‌کنیم و برای کلاس بندی از شبکه هیبریدی بهره می‌گیریم که در تشخیص بیماری صرع استفاده شده است [۵۵-۵۶]. در مرجع [۵۶] شبکه کلاس بندی RBF هیبریدی در مقایسه با کلاس بند SVM ارائه شده است. این مرجع که یک کتاب در مورد روش‌های کلاس بندی و شبکه‌های کلاس بندی است به صورت دقیق مقایسه ای بین دو کلاس بند RBF و RBF انجام داده است. همچنین، ما برای اولین بار از شبکه SVM هیبریدی برای کلاس بندی EEG بهره می‌گیریم.

سیستم کامپیوتی خودکار برای تشخیص صرع از اهمیت بالای برخوردار است [۱۶-۱۸]. نزدیک به دو دهه پیش، عادلی و همکاران [۱۹]، با کار بر روی EEG، مدلی را جهت تشخیص خودکار تشنج پنهان ارائه دادند. متعاقباً عادلی و همکاران [۲۰] و نیز قوش دستیدار و همکاران [۲۱]، تشخیص صرع خودکار گیجگاهی فکی مبتنی بر EEG را ارائه نمودند. صرع موقت یک تشخیص چالش برانگیز حتی برای صرع شناسان آموزش دیده است. از آن زمان تاکنون، مطالعات زیادی در این زمینه انجام شده و روش‌های مختلفی برای تشخیص تشنج و صرع ارائه شده‌اند [۲۲-۲۴].

مطالعه پردازش EEG مبتنی بر موجک توسط فاوست و همکاران [۲۵] برای کمک به تشخیص تشنج، صرع مبتنی بر رایله و پیش‌بینی خودکار تشنج توسط آچاریا و همکاران استفاده شده است [۲۶]. استخراج ویژگی یکی از مهم‌ترین مراحل در بسیاری از روش‌های موجود برای تشخیص صرع است. در میان کارهای اخیر، آچاریا و همکاران [۲۸]، از هفت روش مختلف یادگیری ماشین برای تشخیص صرع با کم کردن ویژگی‌های آنرودوبی از سیگنال‌های EEG استفاده نموده‌اند [۲۷، ۲۸] که عبارتند از: کلاس بند فازی Sugeno، ماشین بردار پشتیبانی (SVM) [۲۹]، K نزدیک‌ترین همسایه (KNN)، شبکه عصبی احتمالی، درخت تصمیم (DT)، مدل مختلف گاوی [۳۰] و کلاس بندی ساده بیزی (NBC). بذرآبادی و همکاران [۳۱]، پیش‌بینی تشنج‌های صرع را با استفاده از ویژگی‌های طیفی توان پشتیبانی شده توسط روش انتخاب ویژگی، و بر اساس ترکیب نسبی توان‌های طیفی زیر نوارهای الکتروانسفالوگرام پیشنهاد کرده‌اند. سمعی و همکاران [۳۲]، کلاس‌بندی تشنج‌های صرع را با استفاده از تبدیل فوریه منطق زمان-گستته و کلاس بند پرسپترون چند لایه^۱ (MLP) پیشنهاد نموده‌اند [۳۳]. فو و همکاران [۳۴]، طیف حاشیه‌ای هیلبرت، آنرودوبی و ویژگی‌های انرژی سیگنال‌های EEG در فرکانس بلند، و SVM برای تشخیص خودکار تشنج در سیگنال‌های EEG را به کار گرفتند. حسن و همکاران [۳۶]، تشخیص تشنج‌های صرعی را در سیگنال‌های EEG با استفاده از تبدیل موجک فاکتور Q قبل تنظیم و بسته‌بندی ارائه کرده اند [۳۵]. گیسوال و بانکا [۳۷] از ویژگی‌های مشتق شده محلی استفاده نمودند یعنی: الگوی همسایگی توصیفی و الگوی گرادیان محلی یک بعدی برای کلاس بندی سیگنال‌های EEG صرعی با استفاده از چهار مدل مختلف که عبارتند از بیشترین شباهت (ML)، نزدیک‌ترین همسایه، DT، SVM، و شبکه عصبی مصنوعی^۲ (ANN).

ولنگ و همکاران [۳۸]، از استخراج ویژگی‌های چند متغیره و تجزیه و تحلیل غیرخطی و پنج مدل کلاس بندی مختلف ML، KNN، NBC، تجزیه و تحلیل وضوح خطی، RGRSSION لجستیک^۳ و SVM برای تشخیص خودکار تشنج‌های صرع در سیگنال‌های EEG استفاده نمودند. تزیمورتا و همکاران [۳۹]، تشخیص خودکار تشنج‌ها

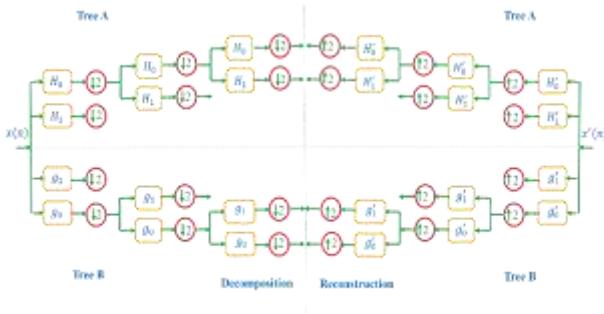
³Logistic regression

⁴ Convolutional Neural Network

¹ Multilayer perceptron class

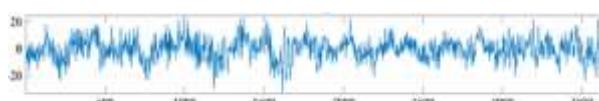
² Artificial Neural Networks

موهومی می باشند. انتقال موهومی موجک در DT-CWT فرآیند عبور سیگنال از DWT دوم و بدست آوردن ضرایب فرضی در مقیاس ها و جهت‌گیری‌های مختلف است. ضرایب تبدیل شده انتخابی عبارتند از: HL_{3b} و HL_{2b} , LH_{1b} , LL_{3a} , LL_{2a} , LH_{2a} , LL_{1a}

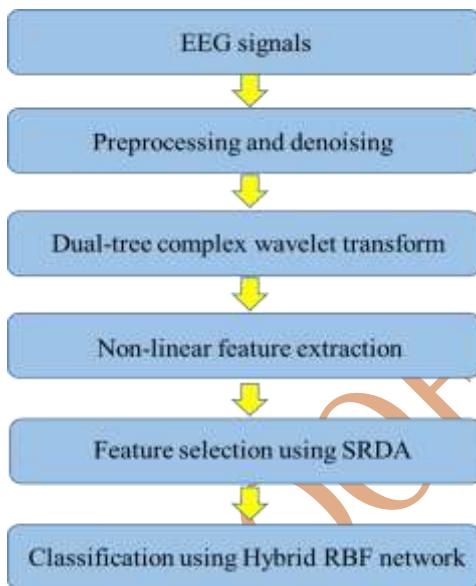


شکل ۲. سه سطح از DT-CWT دو بعدی اعمال شده به EEG مغز پیش پردازش شده

زیر گروه LL3 زیر باندی است که کمترین فرکانس سیگنال را در خود دارد و پس از سه مرحله DT-CWT بدست می آید. هر مرحله از DT-CWT سیگنال را به چهار زیر باند تجزیه می کند: L, LH, HL، و HH، که در آن L مخفف low-pass و H high-pass است. زیر باند LL در مرحله بعدی بیشتر تجزیه می شود، در حالی که سایر زیر باندها به عنوان ضرایب نهایی حفظ می شوند. بنابراین، پس از سه مرحله از DT-CWT، سیگنال به ۲۸ زیر باند تجزیه می شود و زیر گروه LL3 آخرین زیر باند LL است که به دست می آید. ضرایب زیر گروه LL3 به عنوان ویژگی برای برخی از وظایف پردازش سیگنال یا تصویر، مانند حذف نویز، فشرده سازی، یا طبقه بندی انتخاب می شوند. ویژگی ها مقادیر عددی هستند که برخی از ویژگی ها یا ویژگی های سیگنال یا تصویر را توصیف می کنند و می توان از آن ها برای انجام عملیات یا تجزیه و تحلیل های مختلف بر روی داده ها استفاده کرد. با انتخاب ضرایب زیر گروه LL3 به عنوان ویژگی، ۱۰۴۰ ویژگی DT-CWT بدست می آید. در این حالت، بردار ویژگی اولیه به دست آمده دارای ۱۰۴۰ ورودی است. کلاس بندی در مقیاس بزرگ چینین برداری، دارای پیچیدگی محاسباتی غیرقابل قبولی است، و ویژگی هایی وجود دارند که هیچ اطلاعات مفیدی برای کلاس بندی ارائه نمی دهند. بنابراین، انتخاب ویژگی و کاهش آن ضروری است. ما می خواهیم این ویژگی ها را به هفت یا کمتر کاهش دهیم. در اینجا روشی برای انتخاب ویژگی مناسب و مزایای آن شرح خواهیم داد.



شکل ۳. سیگنال EEG طبیعی



شکل ۱. بلوك دیاگرام طرح تشخیص صرع پیشنهادی.

۲-۲. تبدیل موجک مختلط دو درختی^۱

تبدیل موجک پیچیده دو درختی تکنیکی است که تبدیل موجک گسسته (DWT) را برای تولید ضرایب با ارزش پیچیده گسترش می دهد. DT-CWT از دو DWT موازی با فیلترهای مختلف برای بدست آوردن بخش های واقعی و موهومی ضرایب مختلط استفاده می کند. فیلترها به گونه ای طراحی شده اند که فیلترهای پایین گذر در دو درخت به اندازه نیم دوره نمونه متفاوت هستند و موجک های تولید شده توسط یک درخت تقریباً تبدیل هیلبرت موجک های تولید شده توسط درخت دیگر هستند. این تضمین می کند که موجک های پیچیده تقریباً تحلیلی هستند، به این معنی که آن ها دارای مولفه های فرکانس منفی ناچیز هستند [۲۰]. DT-CWT چندین مزیت نسبت به DWT دارد، مانند تغییر ناپذیری بهتر، انتخاب جهت و اطلاعات فاز. DT-CWT را می توان برای کارهای مختلف پردازش سیگنال و تصویر، مانند حذف نویز، فشرده سازی، استخراج EEG و تشوییض لبه اعمال کرد. در کار حاضر نیز، همین روش اتخاذ می شود، اما همانطور که توضیح خواهیم داد، از ضرایب این تبدیل برای استخراج ویژگی های غیر خطی بهره می گیریم. DT-CWT از دو درخت فیلتر واقعی (درخت A و درخت B) همانطور که در شکل (۲) نشان داده شده است، استفاده می کند. بخش واقعی DT-CWT توسط اولین DWT بدست می آید که از یک جفت فیلتر پایین گذر و بالا گذر متقارن و متعدد استفاده می کند. بخش واقعی DT-CWT مؤلفه متقان ریکسان سیگنال را نشان می دهد و دارای همان ویژگی های DWT استاندارد است، مانند بازسازی کامل، وضوح چندگانه و پراکندگی. در مرجع [۳۰]، فرمول بندی (g, h) فیلترهای آینه درجه دوم (تربيع اینه فیلتر) آورده شده است. دو درخت، مربوط به بخش حقیقی و موهومی انتقال موجک

^۱ Dual-tree complex wavelet transform

IQR	Interquartile Range
-----	---------------------

با استفاده از این سه روش استخراج ویژگی و با هشت ضریب انتخابی DT-CWT که در بخش سوم توضیح داده شده است، ۲۴، ویژگی برای هر EEG لاحظ شده در کلاس بندی، بدست می آید. با این حال، ما از کاهش ویژگی ها استفاده کرده ایم تا این ویژگی ها را تا حد امکان تقلیل نماییم.

۲-۳. الگوریتم تجزیه و تحلیل تفکیک رگرسیون طیفی (SRDA)

SDRA، یکی از قوی ترین الگوریتم ها برای کاهش ویژگی است. به همین دلیل، ما از این تکنیک در روش پیشنهادی خود استفاده نموده ایم. برای SDRA، مجموعه ای از داده های $x_m \in R^N$ در نظر گرفته می شوند. به طوریکه، متعلق به x_1, \dots, x_m در هستند و m_k به تعدادی از نمونه های آموزشی از کلاس k ام ($\sum_{k=1}^{N_c} m_k = m$) اختصاص یافته است. مراحل SDRA به صورت زیر خلاصه می شوند [۷۰] :

.۱

$$y_k = \begin{bmatrix} 0. \dots. 0. & 1. \dots. 1. & 0. \dots. 0 \\ \vdots & \vdots & \vdots \\ \sum_{i=1}^{k-1} m_i & m_k & \sum_{i=k+1}^{N_c} m_i \end{bmatrix}^T \quad k = 1, \dots, N_c \quad (1)$$

$y_0 = [1. \dots. 1]^T$ نشان دهنده بردار یک ها می باشد. از آنجایی که y_0 در زیرفاضا به صورت $\{y_k\}$ توصیف می شود، بردارهای $N_c - 1$ را روابط زیر به دست می آیند:

$$\{y_k\}_{k=1}^{N_c}. \quad (y_k^T y_j = 0 \text{ where } i \neq j) \quad (2)$$

۲. در این مرحله، ورودی جدید "I" به هر x_i اضافه می گردد که هنوز به x_i اختصاص داده می شود. بنابراین، بردارهای $N_c - 1$ که $a_k \in R^{N_c - 1}$ ایجاد می شوند، به طوری که a_k عنوان راه حلی برای مسئله حداقل مربعات منظم شده به صورت زیر تعریف می شود:

$$a_k = \left(\sum_{i=l}^m \left(a_i^T x_i - y_i^k \right)^2 + \alpha \|a\|^2 \right) \quad (3)$$

در اینجا، y_i^k المان k می باشد و $\alpha \geq 0$ پارامتری برای کنترل میزان کاهش است.

۳. بردارهای $\{a_k\}_{k=1}^{N_c - 1}$ ، بردارهای اساسی SRDA هستند. فرض کنید $A = [a_1, \dots, a_{N_c - 1}]$ یک ماتریس تبدیل $(N_c - 1) \times (N + 1)$ است. x را می توان در z و در زیرفضای $(N_c - 1)$ بعدی توسط رابطه زیر تعیین کرد:

$$z = A^T [x \ 1] \quad (4)$$

با استفاده از SRDA، ویژگی های هر EEG را به ۱ و ۷ با توجه به تعداد کلاس ها کاهش می دهیم.



شکل ۴. سیگنال EEG صریع

۲-۴. استخراج ویژگی های غیر خطی از ضرایب DT-CWT

پس از استخراج ضرایب DT-CWT از EEG انتخابی، ویژگی های غیرخطی را محاسبه می کنیم. ما برای اولین بار از ویژگی های غیرخطی FE، IQR و ApEn در EEG از کلاس بندی در این مقاله استفاده کرده ایم. این ویژگی ها در جدول (۱) تکمیل شده است. ApEn مخفف آنتروپوی تقریبی است که معیاری برای پیش بینی ناپذیری یا بی نظمی یک سیگنال است. ApEn احتمال اینکه الگوهای مشابه نقاط داده در یک سیگنال در نقاط داده بعدی مشابه باقی بمانند را کمیت می کند. مقدار ApEn بالاتر نشان دهنده سیگنال پیچیده تر و کمتر قابل پیش بینی است، در حالی که یک مقدار ApEn پایین نشان دهنده سیگنال منظم تر و قابل پیش بینی تر است. FE مخفف نما فراکتال است که معیاری برای خود شباهت یا خاصیت مقیاس پذیری یک سیگنال است. FE نحوه رفتار سیگنال در مقیاس ها یا وضوح های مختلف را کمی نشان می دهد. مقدار FE بالاتر نشان دهنده سیگنال صاف تر و پیچیده تر است، در حالی که مقدار FE کمتر نشان دهنده سیگنال خشن تر و پیچیده تر است. IQR مخفف محدوده بین چارکی است که معیاری برای پراکندگی یا تعییرپذیری یک سیگنال است. IQR تفاوت بین صدک ۷۵ و صدک ۲۵ مقادیر سیگنال را کمیت می کند. مقدار IQR بالاتر نشان دهنده سیگنال متغیر و متنوع تر است، در حالی که مقدار IQR پایین نشان دهنده سیگنال پایدار تر و همگن تر است. [۲۵]. مزیت استفاده از این ویژگی ها این است که می توانند اطلاعات و بینش بیشتری نسبت به ویژگی های خطی معمولی مانند میانگین، انحراف استاندارد یا طیف توان ارائه دهند. این ویژگی ها می توانند به تشخیص تغییرات در وضعیت فیزیولوژیکی یا وجود بیماری ها، مشخص کردن ساختار و مورفولوژی سیگنال ها و شناسایی مقادیر پرت یا غیر طبیعی در سیگنال ها کمک کنند.

ذکر این نکته ضروری است که برای استخراج ویژگی های غیرخطی از ضرایب DT-CWT، ابتدا داده های ورودی را به بردار 1×10^{24} تبدیل کرده و سپس فرمول استخراج ویژگی غیرخطی را که در مراجع [۲۵] و [۲۹] توضیح داده شده اند، به آن اعمال کرده ایم.

جدول ۱- ویژگی های غیر خطی استخراج شده از ضرایب DT-CWT

Features	Description
FE	Fuzzy Entropy
ApEn	Approximate Entropy

اما ما ازتابع گاوسی برای مقایسه بین SVM و RBF مانند مرجع [۱۶] استفاده می کنیم.

۳. لایه خروجی خطی است و برای ارائه پاسخ شبکه برای فعال سازی الگوی استفاده شده برای لایه ورودی طراحی شده است. این لایه در حالت نظارت شده، توسط دو مرحله از فرآیند هیبریدی آموزش داده می شود. هیچ محدودیتی برای اندازه لایه خروجی وجود ندارد به جز اینکه بگوییم به طور معمول لندازه لایه خروجی بسیار کوچکتر از لایه پنهان است. در اینجا ما الگوریتم یادگیری RBF را توضیح می دهیم:

۳-۱. خوش بندی K-means

K-means الگوریتمی است که از فاصله ها (به عنوان KNN) برای خوش بندی با دو مرحله استفاده می کند:

مرحله ۱: واریانس خوش با توجه به مجموعه اختصاص داده شده از میانگین خوش $\hat{E}_{j=1}^K$ به حداقل می رسد، حداقل سازی زیر باید انجام گردد:

$$\varphi_j(x) = \varphi(\|x - x_j\|) \quad j = 1, 2, \dots, N \quad (6)$$

مرحله ۲: $C(i) = \arg \min_{1 \leq j \leq k} \|x_i - \hat{\mu}_j\|^2$ یعنی خوش بهینه شده محاسبه کرده، و انکودر را به صورت زیر بهینه می کنیم:

$$C(i) = \arg \min_{1 \leq j \leq k} \|x_i - \hat{\mu}_j\|^2 \quad (7)$$

۳-۲. الگوریتم RLS در یادگیری هیبریدی

الگوریتم های وفقی برای همگرایی با وزن های خاص طراحی شده اند. این وزن ها در شبکه RBF در مرحله یادگیری تنظیم می شوند. الگوریتم RLS یکی از قدرتمندترین الگوریتم های وفقی است [۷۰]. در این قسمت، نقش RLS در لایه خروجی شبکه RBF را شرح می دهیم [۸]. بردار $1 \times K$ را در نظر بگیرید:

$$(x_i) = \begin{bmatrix} \varphi(x_i, \mu_1) \\ \varphi(x_i, \mu_2) \\ \vdots \\ \varphi(x_i, \mu_K) \end{bmatrix} \quad (8)$$

خروجی واحدهای K را در لایه پنهان مشخص می کنیم. این بردار در پاسخ به محرک $N = 1, 2, \dots, i$ تولید می شود. بنابراین، نمونه آموزشی تا جایی که به آموزش نظارت شده لایه خروجی مربوط می شود، با $\{\Phi(i), d(i)\}_{i=1}^N$ تعریف می گردد. به طوری که x_i ، پاسخ مطلوب در خروجی کلی شبکه RBF برای ورودی x_i است. این آموزش با استفاده از الگوریتم RLS که در زیر توضیح داده شده است، انجام می پذیرد [۸]:

۳. کلاس بند RBF با یادگیری ترکیبی (K-means, RLS)

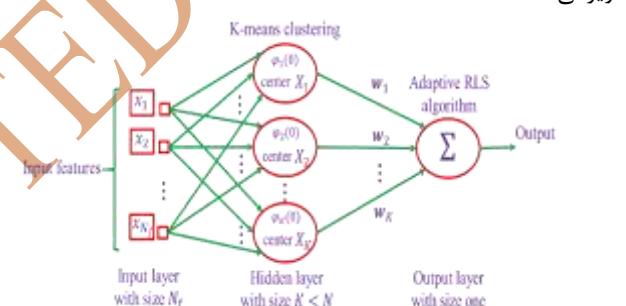
در این بخش، کلاس بند RBF شکل (۵) را با روش یادگیری ترکیبی، که ابزار کلاس بندی پیشنهادی ما است، توصیف می کنیم. کلاس بند پیشنهادی RBF هیبریدی نامیده شده است زیرا روش یادگیری هیبریدی دارای دو مرحله به ترتیب زیر است [۵۶ و ۵۷]:

مرحله ۱: الگوریتم از کلاس بندی K-means برای آموزش لایه پنهان در حالت بدون نظارت استفاده می شود. این روش طراحی دو دسته ها و در نتیجه تعداد بخش های محاسباتی در لایه پنهان به طور کلی کمتر از نمونه دنبالهای است.

مرحله ۲: از الگوریتم حداقل مرباعات منظم (RLS) برای محاسبه بردار وزن لایه بیرونی خطی استفاده می شود. این روش طراحی دو مرحله ای دارای یک جفت ویژگی مطلوب به نام های سادگی محاسبات و همگرایی تسريع شده است.

شبکه RBF از سه لایه تشکیل شده است که در شکل (۳) قابل مشاهده است و وظایف آن ها عبارتند از:

۱. لایه ورودی شامل گره های منبعی است که شبکه را به محیط آن متصل می کند. ورودی های شبکه برای کلاس بندی ویژگی ها هستند.



شکل ۵. کلاس بند RBF "k-means, RLS" هیبریدی [۲۹، ۸]

۲. لایه پنهان به منظور پیدا کردن موازک خوش ها توسط الگوریتم k-means طراحی شده است. برای بیشتر کاربردها، ابعاد، فقط لایه پنهان شبکه بالایی هستند. این لایه آموزشی تنها حالت بدون نظارت است که از مرحله (۱) روش یادگیری ترکیبی استفاده می کند. هر بخش در لایه پنهان به صورت ریاضی با یکتابع شعاعی اصلی توصیف می شود:

$$\varphi_j(x) = \varphi(\|x - x_j\|) \quad j = 1, 2, \dots, N \quad (5)$$

زمین نقطه داده ورودی x ، مرکز تابع پایه شعاعی را تعریف می کند و بردار x ، سیگنال (الگوی) اعمال شده به لایه ورودی است. بنابراین برخلاف پرسپترون چندلایه، پیوندهایی که گره های منبع را به قسمت های پنهان متصل می کنند، اتصالات مستقیم بدون وزن هستند. چندین تابع شعاعی برای استفاده در لایه پنهان وجود دارد،

بهبود اصلی انجام گرفته در این مقاله به کارگیری RBF هیبریدی است که در مقایسه با کلاس بند SVM در [۵۶] ادعا شده است که این کلاس بند از نظر بارمحاسباتی و زمان همگرایی تقریباً یک سوم SVM است. دلیل این بهبود در میزان بار محاسباتی مورد نیاز برای کلاس بند SVM است که این مقدار ضریبی از مقادیر تعداد ماشین بردارها یا N_s و ابعاد رودی n و تعداد آنها m بوده و برابر است با: $O(N_s^3 + N_s^2m + N_snm)$. این مقدار در بدترین شرایط برابر است با $O(nm^2)$. اما برای کلاس بند RBF هیبریدی این مقدار در بدترین شرایط برابر است با $O(m^{2.376})$ که به مراتب کمتر است.

۵. نتیجه گیری

کلاس بندی خودکار بیماری، یکی از مهم ترین تحقیقات در حوزه بیوانفورماتیک است. یک کلاس بند RBF هیبریدی با ویژگی های DTCWT برای کلاس بندی صرع برای تشخیص زودهنگام پیشنهاد شده است که برای کلاس بندی سیگنال های EEG کارآمد است. RBF هیبریدی با ویژگی های SVM در مقایسه با مدل ساده SVM عملکرد بهتری دارد. همچنین برای کاهش بار محاسباتی از کلاس بند Hybrid RBF استفاده شده است. علاوه بر این، نتیجه بدست آمده نیز با برخی از کارهای قبلی مقایسه شده و می توان تأیید کرد که روش پیشنهادی برای کلاس بندی EEG کارآمد است. علاوه بر این، دقت کلاس بندی را می توان با بهینه سازی ساختار شبکه بهبود بخشید و این موضوع به عنوان کار آینده در نظر گرفته شده است.

با توجه به نمونه آموزشی $\{\Phi(i), d(i)\}_{i=1}^N$ ، محاسبات زیر را برای تکرارهای $N = 1.2 \dots$ انجام می دهیم:

$$\mathbf{P}(n) = \mathbf{P}(n-1) - \frac{\mathbf{P}(n-1)\Phi(n)\Phi^T(n)\mathbf{P}(n-1)}{1+\Phi^T(n)\mathbf{P}(n-1)\Phi(n)} \quad (9)$$

$$\mathbf{g}(n) = \mathbf{P}(n)\Phi(n) \quad (10)$$

$$\alpha(n) = d(n) - \hat{\mathbf{w}}^T(n-1)\Phi(n) \quad (11)$$

$$\hat{\mathbf{w}}(n) = \hat{\mathbf{w}}(n-1) + \mathbf{g}(n)\alpha(n) \quad (12)$$

برای مقداردهی اولیه الگوریتم، $\mathbf{P}(0) = \lambda^{-1}\mathbf{I}$ و $\hat{\mathbf{w}}(0) = \mathbf{0}$ لحاظ می شوند که λ یک ثابت مثبت کوچک است.

در مرجع [۹]، یک تجزیه و تحلیل کامل برای نشان دادن برتری RBF هیبریدی نسبت به کلاس بند SVM هم از نظر محاسباتی و هم از نظر دقت انجام گرفته است. در قسمت شبیه سازی، عملکرد شبکه هیبریدی RBF را با عملکرد کلاس بندهای KNN و SVM در کلاس بندی بیماری های مغزی مقایسه خواهیم نمود.

۴. نتایج شبیه سازی و کلاس بندی

در این مطالعه مجموعه داده های بیمارستان کودکان بوستون موسسه فناوری ماساچوست CHB-MIT که رایج ترین مجموعه داده در زمینه تشنج های صرع است، برای آموزش و ارزیابی مدل انتخاب شده است [۷۲]. مجموعه داده شامل سیگنال های EEG از ۲۳ بیمار بستری شده در بیمارستان کودکان بوستون می باشد. بیماران همگی زیر ۲۲ سال و ۵ نفر مرد و ۱۷ نفر زن هستند. در این مجموعه داده، بین ۲۴ تا ۷۰ ساعت سیگنال EEG ثبت شده برای هر بیمار وجود دارد. سیگنال های ثبت شده هر بیمار در این مجموعه داده، پیوسته و بدون وقفه می باشند و هر بیمار دارای حداقل ۵ تشنج ثبت شده است. داده های این مجموعه داده، تنها دو علامت دارند: از نوع تشنجی و عادی. تعداد الکترودهای ضبط سیگنال بین ۱۸ تا ۲۳ کانال است (در برخی بیماران تعداد کانال ها کمتر می باشد). فرکانس نمونه برداری ۲۵۶ هرتز و واضح بیت، ۱۶ بیت است.

در قسمت نتایج، جهت مقایسه کار پیشنهادی با کارهای قبلی در این زمینه از جدولی مشابه جدول (۲) استفاده شده است.

جدول ۲- مقایسه روش های مختلف کلاس بندی در سناریوی دو کلاسه

Authors	Year	Method	Accuracy (%)
Guo et al. [57]	2011	GP-based feature extraction + KNN	93.5
Du et al. [58]	2012	HOS + simple logistic regression	94.5
Acharya et al. [63]	2012	Entropies, HOS, FD and H + Fuzzy classifier	99.7
Martis et al. [59]	2013	ITD derived features + DT	95.6
Acharya et al. [60]	2013	CWT based HOS and textures + SVM	96.0
Kaya et al. [61]	2014	1-D local binary patterns + BayesNet	95.67
Martis et al. [64]	2015	WPD based non-linear features + SVM	98.0
Riaz et al. [62]	2015	EMD based temporal and spectral features + SVM	84.0
Li et al. [65]	2017	DT-CWT-based non-linear features + SVM	98.87
This work		DT-CWT-based non-linear features + Hybrid RBF	99.54

مراجع

- [1] Adeli H.; Ghosh-Dastidar S. "Automated EEG based diagnosis of neurological disorders: inventing the future of neurology; in corroboration with Nahid Dadmehr"; 1st ed. Boca Raton, Florida, CRC Press, 2010 Feb.
- [2] Li Y.; Cui W.; Luo M.; Li K.; Wang L. "Epileptic seizure detection based on time-frequency images of EEG signals using Gaussian mixture model and gray level co-occurrence matrix features": Int J Neural Syst. 2018, 28(7), 1850003.
- [3] Koutlis C.; Kimiskidis VK.; Kugiumtzis D. "Identification of hidden sources by estimating instantaneous causality in high-dimensional biomedical time series"; Int J Neural Syst. 2019, 29(4), 1850051.
- [4] Schaper FLWVJ.; Zhao Y.; Janssen MLF.; Wagner GL.; Colon AJ.; Hilkman DMW.; et al. "Single-cell recordings to target the anterior nucleus of the thalamus in deep brain stimulation for patients with refractory epilepsy"; Int J Neural Syst. 2019, 29(4), 1850012.
- [5] Jiang S.; Luo C.; Gong J.; Peng R.; Ma S.; Tan S.; et al. "Aberrant thalamocortical connectivity in juvenile myoclonic epilepsy"; Int J Neural Syst. 2018, 28(1), 1750034.
- [6] Yuan S.; Zhou W.; Chen L. "Epileptic seizure prediction using diffusion distance and Bayesian linear discriminant analysis on intracranial EEG"; Int J Neur Syst. 2018, 28(01), 1750043–12.1
- [7] Ansari A.H.; Cherian P.J.; Caicedo A.; Naulaers G.; De Vos M.; Van Huffel S. "Neonatal seizure detection using deep convolutional neural networks"; Int J Neural Syst. 2019, 29(4), 1850011.
- [8] Yan T.; Bi X.; Zhang M.; Wang W.; Yao Z.; Yang W.; et al. "Age-related oscillatory theta modulation of multisensory integration in frontocentral regions."; Neuroreport. 2016, 27(11), 796–801.
- [9] Mutlu A.Y. "Detection of epileptic dysfunctions in EEG signals using Hilbert vibration decomposition"; Biomed Signal Process Control. 2018, 40, 33–40.
- [10] Akdag G.; Algin I.D.; Erdinç OO. "Epilepsy"; Osmangazi J Med. 2016, 38(Special Issue 1), 35– 41.
- [11] Yan T.; Geng Y.; Wu J.; Li C. "Interactions between multisensory inputs with voluntary spatial attention: an fMRI study"; Neuroreport. 2015, 26(11), 605–12.
- [12] Misulis K.E. "Atlas of EEG; seizure semiology; and management"; 1st ed. New York, NY: Oxford University Press,2013.
- [13] Pachori R.B.; Patidar S. "Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions"; Comput Methods Programs Biomed. 2014, 113(2), 494–502.
- [14] Wang B.; Guo J.; Yan T.; Ohno S.; Kanazawa S.; Huang Q.; et al. Neural responses to central and peripheral objects in the lateral occipital cortex. Front Hum Neurosci. 2016a; 10(54): 54–11.
- [15] Yan T.; Dong X.; Mu N.; Liu T.; Chen C.; Deng L.; et al. "Positive classification advantage: tracing the time course based on brain oscillation"; Front Hum Neurosc. 2017; 11(1): 659.
- [16] Ren G.P.; Yan J.Q.; Yu Z.X.; Wang D.; Li XN.; Mei SS.; et al. "Automated detector of high frequency oscillations in epilepsy based on maximum distributed peak points"; Int J Neural Syst. 2018; 28(1): 1750029.
- [17] Sun C.; Cui H.; Zhou W.; Nie W.; Wang X.; Yuan Q. "Epileptic seizure detection with EEG textural features and imbalanced classification based on EasyEnsemble learning"; Int J Neural Syst. 2019, 29(10), 1950021.
- [18] Ibáñez-Molina AJ.; Iglesias-Parro S.; Escudero J. "Differential effects of simulated cortical network lesions on synchrony and EEG complexity"; Int J Neur Syst. 2019, 29(04), 1850024.
- [19] Adeli H.; Zhou Z.; Dadmehr N. "Analysis of EEG records in an epileptic patient using wavelet transform"; J Neurosci Methods. 2003, 123(1), 69–87.
- [20] Adeli H.; Ghosh-Dastidar S.; Dadmehr N. "A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy"; IEEE Trans Biomed Eng. 2007, 54(2), 205–11.
- [21] Ghosh-Dastidar S.; Adeli H.; Dadmehr N. "Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection"; IEEE Trans Biomed Eng. 2007, 54(9), 1545–51.
- [22] De Lucia M.; Fritschy J.; Dayan P.; Holder DS. "A novel method for automated classification of epileptiform activity in the human electroencephalogram-based on independent component analysis"; Med Biol Eng Comput. 2008, 46(3), 263–72.
- [23] Tapani KT.; Vanhatalo S.; Stevenson NJ. "Timevarying EEG correlations improve neonatal seizure detection"; Int J Neural Syst. 2019,29(4), 1850030.
- [24] Ma X.; Yu N.; Zhou W. "Using dictionary pair learning for seizure detection"; Int J Neural Syst. 2019, 29(4): 1850005.
- [25] Faust O.; AcharyaAdeli URH.; Adeli H.; Adeli A. "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis"; Seizure. 2015, 26, 56–64.
- [26] Acharya UR; Hagiwara Y.; Adeli H. "Automated seizure prediction"; Epilepsy Behav. 2018a, 88, 251–61.
- [27] Martínez-Rodrigo A.; García-Martínez B.; Alcaraz R.; González P.; Fernández-Caballero A. "Multiscale entropy analysis for recognition of visually elicited negative stress from EEG recordings"; Int J Neur Syst. 2019, 29(02), 1850038.
- [28] Acharya UR.; Sree SV.; Alvin AP.; Yanti R.; Suri JS. "Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals"; Into J Neural Syst. 2012, 22(2), 1250002.

- [29] Zhang J.; Xiao M.; Gao L.; Chu S. “Probability and interval hybrid reliability analysis based on adaptive local approximation of projection outlines using support vector machine”; *Comput-Aided Civ Inf.* 2019c, 34(11), 991–1009.
- [30] Martinez-Vargas JD.; Duque-Muñoz L.; Vargas-Bonilla F.; Lopez JD.; Castellanos-Dominguez G. “Enhanced data covariance estimation using weighted combination of multiple Gaussian kernels for improved M/EEG source localization”; *Int J Neural Syst.* 2019, 29(6), 1950001.
- [31] Bandarabadi M.; Teixeira CA.; Rasekh J.; Dourado A. “Epileptic seizure prediction using relative spectral power features”; *Clin Neurophysiol.* 2015, 126(2), 237–48.
- [32] Samiee K.; Kovács P.; Gabbouj M. “Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform”; *IEEE Trans Biomed Eng.* 2015, 62(2), 541–52.
- [33] Adeli H.; Hung SL. “Machine learning: neural networks; genetic algorithms; and fuzzy systems”; New York: John Wiley and Sons, 1995.
- [34] Fu K.; Qu J.; Chai Y.; Zou T. “Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals”; *Biomed Signal Process Control.* 2015, 18, 179–85.
- [35] Hassan AR.; Siuly S.; Zhang Y. “Epileptic seizure detection in EEG signals using Tunable-Q factor wavelet transform and bootstrap aggregating”; *Comput Methods Programs Biomed.* 2016, 137, 247–59.
- [36] Wang S-H.; Zhang Y-D.; Yang M.; Liu B.; Ramirez J.; Gorri JM. “Unilateral sensorineural hearing loss identification based on double-density dual-tree complex wavelet transform and multinomial logistic regression”; *ICA.* 2019, 26(4), 411–26.
- [37] Jaiswal AK.; Banka H. “Local pattern transformation-based feature extraction techniques for classification of epileptic EEG signals”; *Biomed Signal Process Control.* 2017, 34, 81–92.
- [38] Wang L.; Xue W.; Li Y.; Luo M.; Huang J.; Cui W.; et al. “Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis”; *Entropy.* 2017; 19(6): 222.
- [39] Tzimourta KD.; Tzallas AT.; Giannakeas N.; Astrakas LG.; Tsilikas’s DG.; Angelidis P.; et al. “A robust methodology for classification of epileptic seizures in EEG signals”; *Health Technol.* 2019, 9(2), 135–42.
- [40] Chang Z.; Luca F.; Goda K. “Automated classification of near-fault acceleration pulses using wavelet packets”; *Comput-Aided Civ Inf Eng.* 2019; 34(7), 569–85.
- [41] Xiang J.; Li C.; Li H.; Cao R.; Wang B.; Han X.; et al. “The detection of epileptic seizure signals based on fuzzy entropy”; *J Neurosci Methods.* 2015, 243, 18–25.
- [42] Wang B.; Yan T.; Ohno S.; Kanazawa S.; Wu J. “Retinotopy and attention to the face and house images in the human visual cortex”; *Exp Brain Res.* 2016b, 234(6), 1623–35.
- [43] Vera-Olmos FJ.; Pardo E.; Melero H.; DeepEye MN. “Deep convolutional network for pupil detection in real environments”; *Integr Comput Aided Eng.* 2019, 26(1), 85–95.
- [44] Yang T.; Cappelle C.; Ruichek Y.; El Bagdouri M. “Multi-object tracking with discriminant correlation filter based deep learning tracker”; *Integr Comput Aided Eng.* 2019, 26(3), 273–84.
- [45] Hua C.; Wang H.; Wang H.; Lu S.; Liu C.; Khalid SM. “A novel method of building functional brain network using deep learning algorithm with application in proficiency detection”; *Int J Neural Syst.* 2019, 29(1), 1850015.
- [46] Zhang Y.; Cheng T.; Ren Y. “A graph deep learning method for short-term traffic forecasting on large road networks”; *Comput-Aided Civ Inf Eng.* 2019b, 34(10), 877–96.
- [47] Ahmedt-Aristizabal D.; Fookes C.; Nguyen K.; Denman S.; Sridharan S.; Dionisio S. “Deep facial analysis: a new phase I epilepsy evaluation using computer vision”; *Epilepsy Behav.* 2018; 82: 17–24.
- [48] Hassanpour A.; Moradikia M.; Adeli H.; Khayami SR.; Shamsinejadbabaki P. “A novel end to-end deep learning scheme for classifying multi-class motor imagery electroencephalography signals”; *Expert Syst.* 2019 Dec, 36(6).
- [49] Molina-Cabello MA.; Luque-Baena RM.; López-Rubio E.; Thurnhofer-Hemsi K. “Vehicle type detection by ensembles of convolutional neural networks operating on super resolved images”; *Integr Comput Aided Eng.* 2018, 25(4), 321–33.
- [50] Li S.; Zhao X.; Zhou G. “Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network”; *Comput-Aided Civ Inf Eng.* 2019, 34(7), 616–34.
- [51] Maeda K.; Takahashi S.; Ogawa T.; Haseyama M. “Convolutional sparse coding-based deep random vector functional link network for distress classification of road structures. *Comput-Aided Civ Inf Eng.* 2019, 34(8), 654–76.
- [52] Acharya UR.; Oh SL.; Hagiwara Y.; Tan JH.; Adeli H.; Subha DP. “Automated EEG-based screening of depression using deep convolutional neural network. *Comput Methods Programs Biomed.*”; 2018b, 161, 103–13.
- [53] Acharya UR.; Oh SL.; Hagiwara Y.; Tan JH.; Adeli H. “Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals”; *Comput Biol Med.* 2018c, 100, 270–8.
- [54] Nogay H. S.; Adeli; H. “Detection of epileptic seizure using pretrained deep convolutional neural network and transfer learning”; *European Neurology* 2021, 83(6), 602-614.
- [55] Ostadieh J.; Amirani M. C.; and Valizadeh M.; “Enhancing obstructive apnea disease detection using dual-tree complex wavelet transform-based features and the hybrid “K-means; recursive least-squares” learning for the radial basis function network.”; *Journal of Medical Signals and Sensors* 2020, 10(4), 219.
- [56] Haykin S. “Neural networks and learning machines”; Prentice Hall 2008, pp. 230-263.

-
- [57] Guo L.; Rivero D.; Dorado J.; Munteanu C.R.; Pazos A. "Automatic feature extraction using genetic programming: an application to epileptic EEG classification"; *Expert Syst. Appl.* 2011, 38 (8), 10425–10436.
- [58] Du X.; Dua S.; Acharya U.R.; Chua C.K. "Classification of epilepsy using high-order spectra features and principle component analysis"; *J. Med. Syst.* 2012, 36 (3), 1731–1743.
- [59] Martis R.J.; Acharya U.R.; TanJ.H.; Petznick A.; TongL.; "Application of intrinsic time-scale decomposition (ITD) to EEG signals for automated seizure prediction"; *Int. J. Neural Syst.* 2013, 23 (5), 1557–1565.
- [60] Acharya U.R.; Yanti R.; Zheng J.W. "Automated diagnosis of epilepsy using CWT; HOS and texture parameters"; *Int. J. Neural Syst.* 2013, 23 (3), 1001–1007.
- [61] Kaya Y.; Uyar M.; Tekin R.; Yıldırım S. "1D-local binary pattern based feature extraction for classification of epileptic EEG signals"; *Appl. Math. Comput.* 2014, 243, 209–219.
- [62] Riaz F.; Hassan A.; Rehman S.; Niazi I.K.; Dremstrup K.; "EMD based temporal and spectral features for the classification of EEG signals using supervised learning"; *IEEE Trans. Neural Syst. Rehabil. Eng.* 2015, 24 (1), 28–35.
- [63] Acharya U.R.; Sree S.V.; Suri J.S. "Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals"; *Int. J. Neural Syst.* 2012, 22 (2), 565–579.
- [64] Martis R.J.; Tan J.H.; Chua C.K.; Loon C.T.; Jie S.Y.W.; TongL. "Epileptic EEG classification using nonlinear parameters on different frequency bands"; *J. Mech. Med. Biol.* 2015, 15 (3), 1550040.
- [65] Li M.; Chen W.; Zhang T. "Automatic epileptic EEG detection using DT-CWT-based non-linear features"; *Biomedical Signal Processing and Control* 2017, 34, pp.114-125.
- [66] Milligan, T. A. (2021). Epilepsy: a clinical overview. *The American Journal of Medicine*, 134(7), 840-847.
- [67] Selesnick, I. W., Baraniuk, R. G., & Kingsbury, N. C. (2005). The dual-tree complex wavelet transform. *IEEE signal processing magazine*, 22(6), 123-151.
- [68] Benesty, J., & Gänslor, T. (2004). New insights into the RLS algorithm. *EURASIP journal on advances in signal processing*, 2004, 1-9.
- [69] Hatamian, Amir, Farzad Farshidi, Changiz Ghobadi, Javad Nourinia, and Ehsan Mostafapour. "Improving the Quality of ECG Signal Using Wavelet Transform and Adaptive Filters." *Journal of Applied Research in Electrical Engineering* 2, no. 1 (2023).
- [70] Bazdar, Amir, Amir Hatamian, Javad Ostadieh, Javad Nourinia, Changiz Ghobadi, and Ehsan Mostafapour. "Nonlinear feature extraction methods based on dual-tree complex wavelet transform subimages of brain magnetic resonance imaging for the classification of multiple diseases." *Journal of Medical Signals & Sensors* 13, no. 2 (2023): 165-172.
- [71] Koliji, Afshin, Sara Mihandoost, Nematollah Ezzati, and Ehsan Mostafapour. "Improving the diagnosis of sudden cardiac death by using non-linear features of the ECG signal and hybrid RBF." *Journal of Applied Research in Electrical Engineering* 2, no. 2 (2023): 18-24.
- [72] Guttag, J. (2010). CHB-MIT Scalp EEG Database (version 1.0.0). *PhysioNet*. <https://doi.org/10.13026/C2K01R>.

Introducing a non-linear feature extraction based on DT-CWT coefficients of EEG signals for detecting epileptic seizures

A. Koleiji¹, N. Ezati², M. Bahonar³, A. Jafari hashemi⁴, E. Mostafapour^{5*}

1, 2-Urmia University of Technology, 3, 4- Islamic Azad University, Mehdi Shahr Branch, 5- Urmia University

ARTICLE INFO

Keywords: Epilepsy, k-means algorithm, Non-linear features, Radial basis function networks, Brain EEG classification, Feature reduction

ABSTRACT

Epilepsy is a type of brain disease that can be diagnosed by observing EEG signals. This disease often occurs in children, but some cases are also observed in adults. Early diagnosis of this disease is a challenging task for doctors. In this study, the authors have classified epileptic and normal EEG signals by adopting a deep learning approach. To obtain efficient features, the Dual-Tree Complex Wavelet Transform (DTCWT) is considered. Then, the wavelet coefficients are decomposed to extract nonlinear features. These features are used as input to the Radial

Basis Function (RBF) hybrid base classifier. Using the proposed method, approximately 99% classification accuracy is achieved, which requires a significant improvement compared to previous proposed algorithms. This is the first time that nonlinear feature extraction from DT-CWT coefficients of an EEG signal is used for epilepsy diagnosis.

UNCORRECTED PROOF