



Semnan University



Research Article

Introducing a Non-Linear Feature Extraction Based on DT-CWT Coefficients of EEG Signals for Detecting Epileptic Seizures

Afshin Koleiji ^a, Nematollah Ezati ^a, Mohsen Bahonar ^b, Abdollah Jafari hashemi ^b, Ehsan Mostafapour ^{a,*}

^a Faculty of Electrical And Computer Engineering, Urmia University of Technology, Urmia, Iran

^b Islamic Azad University, Mehdi Shahr Branch, Mehdi Shahr, Iran

PAPER INFO

Paper history:

Received: 2023-05-23

Revised: 2024-02-12

Accepted: 2025-03-12

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.

DOI: <https://doi.org/10.22075/jme.2025.30724.2461>

© 2026 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

* Corresponding author.

E-mail address: e.mostafapour@urmia.ac.ir

How to cite this article:

E. Mostafapour , A. Koleiji , M. Bahonar , N. Ezzati and A. Jafari Chashmi, "Introducing a non-linear feature extraction based on DT-CWT coefficients of EEG signals for detecting epileptic seizures," Journal of Modeling in Engineering, 24 84 (2026): 87-99, doi: 10.22075/jme.2025.30724.2461

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

افشین کلیجی^۱، نعمت الله عزتی^۱، محسن باهنر^۲، عبدالله جعفری چاشمی^۲، احسان مصطفی پور^{۱*}

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۲/۰۳/۰۲	صرع نوعی بیماری مغزی است که بررسی و تحلیل سیگنال های EEG قابل تشخیص است. بیماری صرع غالباً 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. نویسندگان 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 غیر خطی استفاده می شود. این ویژگی ها به عنوان ورودی کلاس بند تابع پایه هیبریدی شعاعی استفاده می گردند. با استفاده از روش پیشنهادی، حدود ۹۹ درصد دقت 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 دانش نویسندگان، این اولین بار است که جهت تشخیص صرع از استخراج ویژگی غیر خطی بر روی ضرایب یک سیگنال EEG استفاده می شود.
بازنگری مقاله: ۱۴۰۲/۱۱/۲۳	
پذیرش مقاله: ۱۴۰۳/۱۲/۲۲	
واژگان کلیدی: صرع، الگوریتم k-means، مشخصه های غیر خطی، شبکه های تابع پایه شعاعی، کلاس بندی EEG مغز، کاهش ویژگی.	
DOI: https://doi.org/10.22075/jme.2025.30724.2461	
© 2026 Published by Semnan University Press. This is an open access article under the CC-BY 4.0 license. (https://creativecommons.org/licenses/by/4.0/)	

۱- مقدمه

از خود محافظت کنند و ممکن است در اثر غش، با جراحی در تصادفات رانندگی جان خود را از دست بدهند [۸ و ۹]. اولین گام در ارزیابی بیمار، تعیین این موضوع است که آیا تشنج صرع تصویر 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 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

صرع یک بیماری مزمن عصبی است که قابل تشخیص است [۱-۴]. بیش 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 متمرکز است [۵-۷]. بیماران مبتلا به صرع در معرض تشنج های ناگهانی و غیرقابل پیش بینی قرار می گیرند، به طوری که نمی توانند

* پست الکترونیک نویسنده مسئول: e.mostafapour@urmia.ac.ir

۱. دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی ارومیه، ارومیه، ایران

۲. دانشگاه آزاد اسلامی واحد مهدی شهر، مهدیشهر، ایران

استناد به این مقاله:

توان پشتیبانی شده توسط روش انتخاب ویژگی، و بر اساس ترکیب نسبی توان‌های طیفی زیر نوارهای الکتروانسفالوگرام پیشنهاد کرده‌اند. سمیعی و همکاران [۳۲]، کلاس‌بندی تشنج‌های صرع را با استفاده از تبدیل فوریه منطق زمان - گسسته و کلاس‌بند پرسپترون چند لایه^۲ (MLP) پیشنهاد نموده‌اند [۳۳]. فو و همکاران [۳۴]، طیف حاشیه‌ای هیلبرت، آنتروپی و ویژگی‌های انرژی سیگنال‌های EEG در فرکانس باند، 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 قابل تنظیم و بسته‌بندی ارائه کرده‌اند [۳۵ و ۳۶]. گیسوال و بانکا [۳۷] از ویژگی‌های مشتق شده محلی استفاده نمودند یعنی: الگوی همسایگی توصیفی و الگوی گرادیان محلی یک بعدی برای کلاس‌بندی سیگنال‌های EEG صرعی با استفاده از چهار مدل مختلف که عبارتند از بیشترین شباهت (ML)، نزدیکترین همسایه، SVM، DT، و شبکه عصبی مصنوعی^۳ (ANN).

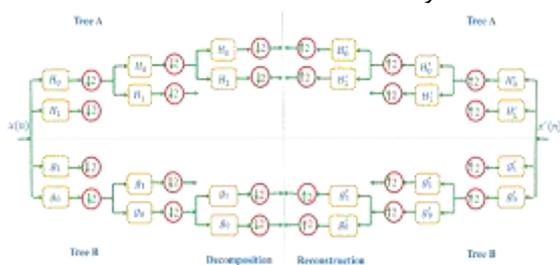
وانگ و همکاران [۳۸]، از استخراج ویژگی‌های چند متغیره و تجزیه و تحلیل غیرخطی و پنج مدل کلاس‌بندی مختلف ML، KNN، تجزیه و تحلیل وضوح خطی، NBC، رگرسیون لجستیک^۴ و SVM برای تشخیص خودکار تشنج‌های صرع در سیگنال‌های EEG استفاده نمودند. تریمورتا و همکاران [۳۹]، تشخیص خودکار تشنج‌ها را بر اساس تبدیل موجک گسسته بررسی کرده‌اند [۳۹ و ۴۰]. در این روش برای هر قسمت از EEG، آنالیز پنج سطحی اعمال می‌شود و پنج ویژگی از ضرایب موجک استخراج می‌شود. بردار ویژگی استخراج‌شده برای آموزش یک جنگل تصادفی استفاده می‌شود که کلاس‌بندی 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 کلاس‌بندی مؤثر هستند [۴۱ و 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 کلاس‌بندی

مهمی در مورد سندرم‌های الکترو-کلینیکال ارائه می‌دهد. باید به خاطر داشت که هر EEG طبیعی، بیانگر غیرمحمتمل بودن صرع نیست و هر ناهنجاری EEG نشان دهنده صرع نمی‌باشد. سیگنال EEG برای تشخیص صرع بسیار مهم است، زیرا با اندازه‌گیری جریان‌های یونی وابسته به احساس در نورون‌های مغز و اختلاف پتانسیل بین الکترودها در امتداد پوست سر بیمار، اطلاعات مکانی و زمانی ارزشمندی را در مورد مغز ارائه می‌دهد [۱۲ و ۱۳]. تشخیص ناهنجاری در EEG نیاز به معاینه توسط متخصصان مغز و اعصاب و صرع‌شناسان آموزش دیده دارد و می‌تواند زمان بر باشد. علاوه بر این، کارشناسان با تجربیات تشخیصی متفاوت ممکن است نظرات متفاوتی در مورد نتایج تشخیصی داشته باشند [۱۴ و ۱۵]. به همین دلیل، توسعه یک سیستم کامپیوتری خودکار برای تشخیص صرع از اهمیت بالایی برخوردار است [۱۶-۱۸]. نزدیک به دو دهه پیش، عادل و همکاران [۱۹]، با کار بر روی EEG، مدلی را جهت تشخیص خودکار تشنج پنهان ارائه دادند. متعاقباً عادل و همکاران [۲۰] و نیز قوش دستیدار و همکاران [۲۱]، تشخیص صرع خودکار گنجگاهی فکی مبتنی بر EEG را ارائه نمودند. صرع موقت یک تشخیص چالش برانگیز حتی برای صرع‌شناسان 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، و صرع مبتنی بر رایانه 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 آنتروپی از سیگنال‌های EEG استفاده نموده‌اند [۲۷ و ۲۸] که عبارتند از: کلاس‌بند فازی Sugeno، ماشین بردار پشتیبانی (SVM) [۲۹]، K، نزدیک‌ترین همسایه (KNN)، شبکه عصبی احتمالی، درخت تصمیم (DT)، مدل مختلط گاوسی [۳۰ و ۳۱] پیش‌بینی تشنج‌های صرع را با استفاده از ویژگی‌های طیفی

^۴Logistic regression^۲ Multilayer perceptron class^۳Artificial Neural Networks

موهومی ضرایب مختلط استفاده می‌کند. فیلترها به گونه ای طراحی شده‌اند که فیلترهای پایین گذر در دو درخت به اندازه نیم دوره نمونه متفاوت هستند و موجک‌های تولید شده توسط یک درخت تقریباً تبدیل هیلبرت موجک‌های تولید شده توسط درخت دیگر هستند. این تضمین می‌کند که موجک‌های پیچیده تقریباً تحلیلی هستند، به این معنی که آن‌ها دارای مولفه های فرکانس منفی ناچیز هستند [۷۰]. DT-CWT چندین مزیت نسبت به DWT دارد، مانند تغییر ناپذیری بهتر، انتخاب جهت و اطلاعات فاز. DT-CWT را می‌توان برای کارهای مختلف پردازش سیگنال و تصویر، مانند حذف نویز، فشرده سازی، استخراج ویژگی EEG [۳۸] و تشخیص لبه اعمال کرد. در کار حاضر نیز، همین روش اتخاذ می‌شود، اما همانطور که توضیح خواهیم داد، از ضرایب این تبدیل برای استخراج ویژگی های غیر خطی بهره می‌گیریم. DT-CWT از دو درخت فیلتر واقعی (درخت A و درخت B) همانطور که در شکل (۲) نشان داده شده است، استفاده می‌کند. بخش واقعی DT-CWT توسط اولین DWT بدست می‌آید که از یک جفت فیلتر پایین گذر و بالا گذر متقارن و متعامد استفاده می‌کند. بخش واقعی DT-CWT مؤلفه متقارن یکسان سیگنال را نشان می‌دهد و دارای همان ویژگی‌های DWT استاندارد است، مانند بازسازی کامل، وضوح چندگانه و پراکندگی. در مرجع [۳۰]، فرمول بندی (h, g) فیلترهای آینه درجه دوم (تربیع آینه فیلتر) آورده شده است. دو درخت، مربوط به بخش حقیقی و موهومی انتقال موجک موهومی می‌باشند. انتقال موهومی موجک در DT-CWT فرآیند عبور سیگنال از DWT دوم و بدست آوردن ضرایب فرضی در مقیاس‌ها و جهت‌گیری‌های مختلف است. ضرایب تبدیل شده انتخابی عبارتند از: $LL_{1a}, LH_{2a}, LL_{2a}, LL_{3a}, LH_{1b}, HL_{2b}$ و HL_{3b} .



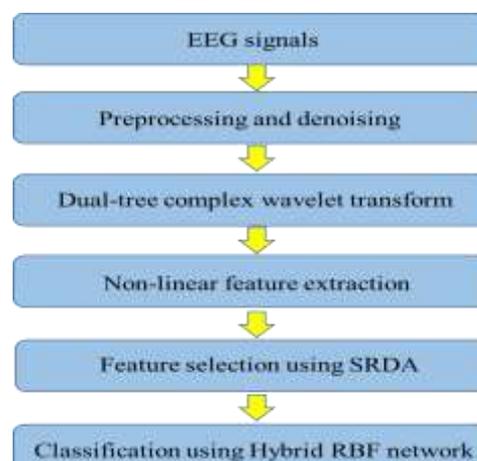
شکل ۲- سه سطح از DT-CWT دو بعدی اعمال شده به EEG مغز پیش پردازش شده

چند کلاسه سیگنال‌های EEG بصری حرکتی ارائه شده است. یکی از مؤثرترین روش‌های DL، شبکه عصبی کانولوشنی^۵ (CNN) [۴۳-۴۶] می‌باشد که برای پیش‌بینی صرع و اختلال روانی استفاده شده است [۵۲ و 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

۱-۲- استخراج و انتخاب ویژگی

روش کلی پیشنهادی تشخیص صرع بر اساس سیگنال های EEG در شکل (۱) نشان داده شده است. پس از استخراج ویژگی، از الگوریتم تجزیه و تحلیل تفکیک رگرسیون طیفی (SRDA) برای کاهش تعداد ویژگی ها و بار محاسباتی استفاده می‌کنیم و برای کلاس بندی از شبکه هیبریدی بهره می‌گیریم که در تشخیص بیماری صرع استفاده نشده 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 روش های کلاس بندی و شبکه های کلاس بندی است به صورت دقیق مقایسه ای بین دو کلاس بند RBF و SVM انجام داده است. همچنین، ما برای اولین بار از شبکه RBF هیبریدی برای کلاس بندی EEG بهره می‌گیریم.



شکل ۱- بلوک دیاگرام طرح تشخیص صرع پیشنهادی.

۲-۲- تبدیل موجک مختلط دو درختی^۶

تبدیل موجک پیچیده دو درختی تکنیکی است که تبدیل موجک گسسته (DWT) را برای تولید ضرایب با ارزش پیچیده گسترش می‌دهد. DT-CWT از دو DWT موازی با فیلترهای مختلف برای بدست آوردن بخش‌های واقعی و

^۶ Dual-tree complex wavelet transform

^۵ Convolutional Neural Network

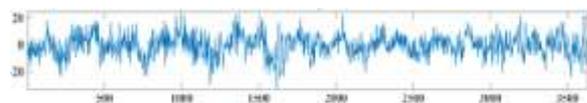
برای کلاس بندی EEG در این مقاله استفاده کرده ایم. این ویژگی ها در جدول ۱ تکمیل شده است. ApEn مخفف آنتروپی تقریبی است که معیاری برای پیش بینی ناپذیری یا بی نظمی یک سیگنال است. ApEn احتمال اینکه الگوهای مشابه نقاط داده در یک سیگنال در نقاط داده بعدی مشابه باقی بمانند را کمیت می کند. مقدار ApEn بالاتر نشان 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 تغییرپذیری 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 پایدارتر 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 غیر خطی از ضرایب DT-CWT، ابتدا داده های ورودی را به بردار 1×1024 تبدیل کرده و سپس فرمول استخراج ویژگی غیر خطی 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
IQR	Interquartile Range

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: LL, LH, HL, و HH، که در آن L مخفف low-pass و H مخفف 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، ۱۰۲۴ ویژگی DT-CWT بدست می آید. در این حالت، بردار ویژگی اولیه به دست آمده دارای ۱۰۲۴ ورودی است. کلاس بندی در مقیاس بزرگ چنین برداری، دارای پیچیدگی محاسباتی غیر قابل 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 ۴- سیگنال EEG صرعی

۲-۳- استخراج ویژگی های غیر خطی از ضرایب DT-CWT

پس از استخراج ضرایب DT-CWT از EEG انتخابی، ویژگی های غیر خطی را محاسبه می کنیم. ما برای اولین بار از ویژگی های غیر خطی ApEn، FE و IQR، [۲۵ و ۵۹]،

می توان در Z و در زیرفضای $(Nc - 1)$ بعدی توسط رابطه زیر تعیین کرد:

$$z = A^T [x \ 1] \quad (۴)$$

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

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

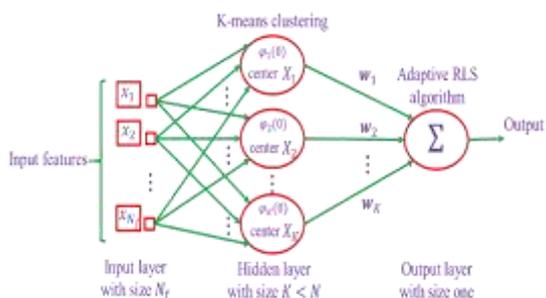
در این بخش، کلاس بند RBF شکل (۵) را با روش یادگیری ترکیبی، که ابزار کلاس بندی پیشنهادی ما است، توصیف می کنیم. کلاس بند پیشنهادی RBF هیبریدی نامیده شده است زیرا روش یادگیری هیبریدی دارای دو مرحله به ترتیب زیر است [۷۰ و ۵۶]:

مرحله ۱: الگوریتم از کلاس بندی K-means برای آموزش لایه پنهان در حالت بدون نظارت استفاده می کند. به طور معمول، تعداد دسته ها و در نتیجه تعداد بخش های محاسباتی در لایه پنهان به طور کلی کمتر از نمونه دنباله ای است.

مرحله ۲: از الگوریتم حداقل مربعات 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 تسریع 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]

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 لحاظ 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.

۲-۴ 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 $x_1, \dots, x_m \in R^N$ در نظر گرفته می شوند. به طوریکه، متعلق به Nc کلاس مختلف هستند و m_k به تعدادی از نمونه های آموزشی از کلاس k ام $(\sum_{k=1}^{Nc} m_k = m)$ اختصاص یافته است. مراحل SDRA به صورت زیر خلاصه می شوند [۷۰]:

$$y_k = \begin{bmatrix} 0, \dots, 0, 1, \dots, 1, 0, \dots, 0 \\ \sum_{i=1}^{k-1} m_i, m_k, \sum_{i=k+1}^{Nc} m_i \end{bmatrix}^T \quad k = 1, \dots, Nc \quad (۱)$$

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

$$\{y_k\}_{k=1}^{Nc} \cdot (y_i^T y_0 = 0 \text{ where } y_i^T y_j = 0, i \neq j) \quad (۲)$$

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

$$a_k = \left(\sum_{i=1}^m (a^T x_i - y_i^k)^2 + \alpha \|a\|^2 \right) \quad (۳)$$

در اینجا، $\alpha \geq 0$ پارامتری برای کنترل میزان کاهش است.

۳. بردارهای $\{a_k\}_{k=1}^{Nc-1}$ ، بردارهای اساسی SRDA هستند. فرض کنید $A = [a_1, \dots, a_{Nc-1}]$ یک ماتریس تبدیل $(N + 1) \times (Nc - 1)$ است. x را

۳-۲- الگوریتم RLS در یادگیری هیبریدی

الگوریتم‌های وفقی برای همگرایی با وزن‌های خاص طراحی شده‌اند. این وزن‌ها در شبکه RBF در مرحله یادگیری تنظیم می‌شوند. الگوریتم RLS یکی از قدرتمندترین الگوریتم‌های وفقی است [70]. در این قسمت، نقش RLS در لایه خروجی شبکه RBF را شرح می‌دهیم [۸]. بردار $K \times 1$ را در نظر بگیرید:

$$(x_i) = \begin{bmatrix} \varphi(x_i, \mu_1) \\ \varphi(x_i, \mu_2) \\ \vdots \\ \varphi(x_i, \mu_K) \end{bmatrix} \quad (۸)$$

خروجی واحدهای K را در لایه پنهان مشخص می‌کنیم. این بردار در پاسخ به محرک $x_i, i = 1, 2, \dots, N$ تولید می‌شود. بنابراین، نمونه آموزشی تا جایی که به آموزش نظارت شده لایه خروجی مربوط می‌شود، با $\{\Phi(i), d(i)\}_{i=1}^N$ تعریف می‌گردد. به طوری که d_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 می‌پذیرد [۸]:

با توجه به نمونه آموزشی $\{\Phi(i), d(i)\}_{i=1}^N$ ، محاسبات زیر را برای تکرارهای $n = 1, 2, \dots, N$ انجام می‌دهیم:

$$P(n) = \quad (۹)$$

$$P(n-1) - \frac{P(n-1)\Phi(n)\Phi^T(n)P(n-1)}{1+\Phi^T(n)P(n-1)\Phi(n)}$$

$$g(n) = P(n)\Phi(n) \quad (۱۰)$$

$$\alpha(n) = d(n) - \hat{w}^T(n-1)\Phi(n) \quad (۱۱)$$

$$\hat{w}(n) = \hat{w}(n-1) + g(n)\alpha(n) \quad (۱۲)$$

برای مقداردهی اولیه الگوریتم، $\hat{w}(0) = 0$ و $P(0) = I^{-1}\lambda$ لحاظ می‌شوند که λ یک ثابت مثبت کوچک است. در مرجع [۹]، یک تجزیه و تحلیل کامل برای نشان دادن برتری RBF هیبریدی نسبت به کلاس‌بند SVM هم از نظر محاسباتی و هم از نظر دقت انجام گرفته است. در قسمت شبیه‌سازی، عملکرد شبکه هیبریدی RBF را با عملکرد کلاس‌بندهای SVM و KNN در کلاس بندی بیماری‌های مغزی مقایسه خواهیم نمود.

۲. لایه پنهان به منظور پیدا کردن مراکز خوشه‌ها 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 می‌کند. هر بخش در لایه پنهان به صورت ریاضی با یک تابع شعاعی اصلی توصیف می‌شود:

$$\varphi_j(x) = \varphi(\|x - x_j\|) \quad j = 1, 2, \dots, N \quad (۵)$$

j امین نقطه داده ورودی x_j ، مرکز تابع پایه شعاعی را تعریف می‌کند و بردار x سیگنال (الگوی) اعمال شده به لایه ورودی است. بنابراین برخلاف پرسپترون چندلایه، پیوندهایی که گره‌های منبع را به قسمت‌های پنهان متصل می‌کنند، اتصالات مستقیم بدون وزن هستند. چندین تابع شعاعی برای استفاده در لایه پنهان وجود دارد، اما ما از تابع گاوسی برای مقایسه بین SVM و RBF مانند مرجع [۱۶] استفاده می‌کنیم.

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 می‌شود. هیچ محدودیتی برای اندازه لایه خروجی وجود ندارد به جز اینکه بگوییم به طور معمول اندازه لایه خروجی بسیار کوچکتر از لایه پنهان است. در اینجا ما الگوریتم یادگیری RBF را توضیح می‌دهیم:

۳-۱- خوشه‌بندی K-means

K-means الگوریتمی است که از فاصله‌ها (به عنوان KNN) برای خوشه بندی با دو مرحله استفاده می‌کند: مرحله ۱: واریانس خوشه با توجه به مجموعه اختصاص داده شده از میانگین خوشه $\{\hat{E}\}_{j=1}^K$ به حداقل می‌رسد، حداقل سازی زیر باید انجام گردد:

$$\varphi_j(x) = \varphi(\|x - x_j\|) \quad j = 1, 2, \dots, N \quad (۶)$$

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

$$C(i) = \arg \min_{1 \leq j \leq K} \|x_i - \hat{\mu}_j\|^2 \quad (۷)$$

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

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 زود هنگام پیشنهاد شده است که برای کلاس بندی سیگنال های EEG کارآمد است. RBF هیبریدی با ویژگی های DTCWT 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 به دست 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.

تقدیر و تشکر

از مسئولان دانشگاه صنعتی ارومیه به این وسیله تشکر و قدردانی میگردد.

تعارض منافع

نویسندگان اعلام می کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارد.

تاییدیه اخلاقی

نویسندگان متعهد میشوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانند.

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 تشخیص های صرع است، برای آموزش و ارزیابی مدل انتخاب شده است [72]. 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 تشخیص 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 وضوح 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.

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 بار محاسباتی 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 ورودی n و تعداد آنها m بوده و برابر است با: $O(N_s^3 + N_s^2 m + N_s n m)$. این مقدار در بدترین

مشارکت های نویسندگان

افشین کلیجی: جمع آوری داده ها، تحلیل یافته ها، نگارش و تهیه پیش نویس مقاله

نعمت الله عزتی: راهنمایی علمی، ویرایش تخصصی و نگارش مقاله، ارزیابی و تفسیر نتایج

محسن باهنر: مشاوره علمی، ویرایش تخصصی و نگارش مقاله، ارزیابی و تفسیر نتایج

عبدالله جعفری چاشمی: مشاوره علمی، ویرایش

تخصصی و نگارشی مقاله، ارزیابی و تفسیر نتایج

احسان مصطفی پور: جمع آوری داده ها، تحلیل یافته ها،

نگارش و تهیه پیش نویس مقاله

منابع مالی

این مقاله با هزینه شخصی نگارش یافته است.

مراجع

- [1] Adeli, Hojjat, and Samanwoy Ghosh-Dastidar. Automated EEG-based diagnosis of neurological disorders: Inventing the future of neurology. CRC press, 2010.
- [2] Li, Yang, Weigang Cui, Meilin Luo, Ke Li, and Lina Wang. "Epileptic seizure detection based on time-frequency images of EEG signals using Gaussian mixture model and gray level co-occurrence matrix features." International journal of neural systems 28, no. 07 (2018): 1850003.
- [3] Koutlis, Christos, Vasilios K. Kimiskidis, and Dimitris Kugiumtzis. "Identification of hidden sources by estimating instantaneous causality in high-dimensional biomedical time series." International journal of neural systems 29, no. 04 (2019): 1850051.
- [4] Schaper, Frédéric LWVJ, Yan Zhao, Marcus LF Janssen, G. Louis Wagner, Albert J. Colon, Danny MW Hilkmann, Erik Gommer et al. "Single-cell recordings to target the anterior nucleus of the thalamus in deep brain stimulation for patients with refractory epilepsy." International journal of neural systems 29, no. 04 (2019): 1850012.
- [5] Jiang, Sisi, Cheng Luo, Jinnan Gong, Rui Peng, Shuai Ma, Song Tan, Guofeng Ye, Li Dong, and Dezhong Yao. "Aberrant thalamocortical connectivity in juvenile myoclonic epilepsy." International journal of neural systems 28, no. 01 (2018): 1750034.
- [6] Yuan, Shasha, Weidong Zhou, and Liyan Chen. "Epileptic seizure prediction using diffusion distance and bayesian linear discriminate analysis on intracranial EEG." International journal of neural systems 28, no. 01 (2018): 1750043.
- [7] Ansari, Amir H., Perumpillichira J. Cherian, Alexander Caicedo, Gunnar Naulaers, Maarten De Vos, and Sabine Van Huffel. "Neonatal seizure detection using deep convolutional neural networks." International journal of neural systems 29, no. 04 (2019): 1850011.
- [8] Yan, Tianyi, Xiaoshan Bi, Mengmeng Zhang, Wenhui Wang, Zhiqi Yao, Weiping Yang, and Jinglong Wu. "Age-related oscillatory theta modulation of multisensory integration in frontocentral regions." Neuroreport 27, no. 11 (2016): 796-801.
- [9] Mutlu, Ali Yener. "Detection of epileptic dysfunctions in EEG signals using Hilbert vibration decomposition." Biomedical Signal Processing and Control 40 (2018): 33-40.
- [10] Akdağ, Gönül, Demet Algin, and Oğuz Erdinç. "Epilepsi/epilepsy." Osmangazi Tıp Dergisi 38, no. 1 (2016).
- [11] Yan, Tianyi, Yansong Geng, Jinglong Wu, and Chunlin Li. "Interactions between multisensory inputs with voluntary spatial attention: an fMRI study." Neuroreport 26, no. 11 (2015): 605-612.
- [12] Stern, John M. Atlas of EEG patterns. Lippincott Williams & Wilkins, 2005.
- [13] Pachori, Ram Bilas, and Shivnarayan Patidar. "Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions." Computer Methods and Programs in Biomedicine 113, no. 2 (2014): 494-502.
- [14] Wang, Bin, Jiayue Guo, Tianyi Yan, Seiichiro Ohno, Susumu Kanazawa, Qiang Huang, and Jinglong Wu. "Neural responses to central and peripheral objects in the lateral occipital cortex." Frontiers in Human Neuroscience 10 (2016): 54.

- [15] Yan, Tianyi, Xiaonan Dong, Nan Mu, Tiantian Liu, Duanduan Chen, Li Deng, Changming Wang, and Lun Zhao. "Positive classification advantage: tracing the time course based on brain oscillation." *Frontiers in Human Neuroscience* 11 (2018): 659.
- [16] Ren, Guo-Ping, Jia-Qing Yan, Zhi-Xin Yu, Dan Wang, Xiao-Nan Li, Shan-Shan Mei, Jin-Dong Dai et al. "Automated detector of high frequency oscillations in epilepsy based on maximum distributed peak points." *International Journal of Neural Systems* 28, no. 01 (2018): 1750029.
- [17] Sun, Chengfa, Hui Cui, Weidong Zhou, Weiwei Nie, Xiuying Wang, and Qi Yuan. "Epileptic seizure detection with EEG textural features and imbalanced classification based on EasyEnsemble learning." *International Journal of Neural Systems* 29, no. 10 (2019): 1950021.
- [18] Ibáñez-Molina, Antonio José, Sergio Iglesias-Parro, and Javier Escudero. "Differential effects of simulated cortical network lesions on synchrony and EEG complexity." *International Journal of Neural Systems* 29, no. 04 (2019): 1850024.
- [19] Ghosh-Dastidar, Samanwoy, Hojjat Adeli, and Nahid Dadmehr. "Analysis of EEG records in an epileptic patient using wavelet transform." *J Neurosci Methods* 123, no.1 (2003): 69-87.
- [20] Ghosh-Dastidar, Samanwoy, Hojjat Adeli, and Nahid Dadmehr. "A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy." *IEEE Trans Biomed Eng* 54, no.2 (2007): 205-11.
- [21] Ghosh-Dastidar, Samanwoy, Hojjat Adeli, and Nahid Dadmehr. "Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection." *IEEE Transactions on Biomedical Engineering* 54, no. 9 (2007): 1545-1551.
- [22] De Lucia, Marzia, Juan Fritschy, Peter Dayan, and David S. Holder. "A novel method for automated classification of epileptiform activity in the human electroencephalogram-based on independent component analysis." *Medical & Biological Engineering & Computing* 46, no. 3 (2008): 263-272.
- [23] Tapani, Karoliina T., Sampsa Vanhatalo, and Nathan J. Stevenson. "Time-varying EEG correlations improve automated neonatal seizure detection." *International Journal of Neural Systems* 29, no. 04 (2019): 1850030.
- [24] Ma, Xin, Nana Yu, and Weidong Zhou. "Using dictionary pair learning for seizure detection." *International Journal of Neural Systems* 29, no. 04 (2019): 1850005.
- [25] Faust, Oliver, Rajendra Acharya, Hojjat Adeli, and Amir Adeli. "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis." *Seizure* 26 (2015): 56-64.
- [26] Acharya, U. Rajendra, Yuki Hagiwara, and Hojjat Adeli. "Automated seizure prediction." *Epilepsy & Behavior* 88 (2018): 251-261.
- [27] Martínez-Rodrigo, Arturo, Beatriz García-Martínez, Raúl Alcaraz, Pascual González, and Antonio Fernández-Caballero. "Multiscale entropy analysis for recognition of visually elicited negative stress from EEG recordings." *International Journal of Neural Systems* 29, no. 02 (2019): 1850038.
- [28] Acharya, U. Rajendra, S. Vinitha Sree, Peng Chuan Alvin Ang, Ratna Yanti, and Jasjit S. Suri. "Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals." *International Journal of Neural Systems* 22, no. 02 (2012): 1250002.
- [29] Zhang, Jinhao, Mi Xiao, Liang Gao, and Sheng Chu. "Probability and interval hybrid reliability analysis based on adaptive local approximation of projection outlines using support vector machine." *Computer-Aided Civil and Infrastructure Engineering* 34, no. 11 (2019): 991-1009.
- [30] Martínez-Vargas, Juan David, Leonardo Duque-Muñoz, F. Vargas-Bonilla, José David López, and Germán Castellanos-Dominguez. "Enhanced data covariance estimation using weighted combination of multiple Gaussian kernels for improved M/EEG source localization." *International Journal of Neural Systems* 29, no. 06 (2019): 1950001.
- [31] Bandarabadi, Mojtaba, César A. Teixeira, Jalil Rasekhi, and António Dourado. "Epileptic seizure prediction using relative spectral power features." *Clinical Neurophysiology* 126, no. 2 (2015): 237-248.
- [32] Samiee, Kaveh, Peter Kovacs, and Moncef Gabbouj. "Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform." *IEEE transactions on Biomedical Engineering* 62, no. 2 (2014): 541-552.
- [33] Adeli, Hojjat. "Machine learning-neural networks, genetic algorithms and fuzzy systems." (1999): 317-318.

- [34] Fu, Kai, Jianfeng Qu, Yi Chai, and Tao Zou. "Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals." *Biomedical Signal Processing and Control* 18 (2015): 179-185.
- [35] Hassan, Ahnaf Rashik, Siuly Siuly, and Yanchun Zhang. "Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating." *Computer Methods And Programs in Biomedicine* 137 (2016): 247-259.
- [36] Wang, Shui-Hua, Yu-Dong Zhang, Ming Yang, Bin Liu, Javier Ramirez, and Juan Manuel Gorriz. "Unilateral sensorineural hearing loss identification based on double-density dual-tree complex wavelet transform and multinomial logistic regression." *Integrated Computer-Aided Engineering* 26, no. 4 (2019): 411-426.
- [37] Jaiswal, Abeg Kumar, and Haider Banka. "Local pattern transformation based feature extraction techniques for classification of epileptic EEG signals." *Biomedical Signal Processing and Control* 34 (2017): 81-92.
- [38] Wang, Lina, Weining Xue, Yang Li, Meilin Luo, Jie Huang, Weigang Cui, and Chao Huang. "Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis." *Entropy* 19, no. 6 (2017): 222.
- [39] Tzamourta, Katerina D., Alexandros T. Tzallas, Nikolaos Giannakeas, Loukas G. Astrakas, Dimitrios G. Tsalikakis, Pantelis Angelidis, and Markos G. Tsipouras. "A robust methodology for classification of epileptic seizures in EEG signals." *Health and Technology* 9, no. 2 (2019): 135-142.
- [40] Chang, Zhiwang, Flavia De Luca, and Katsuchihiro Goda. "Automated classification of near-fault acceleration pulses using wavelet packets." *Computer-Aided Civil and Infrastructure Engineering* 34, no. 7 (2019): 569-585.
- [41] Xiang, Jie, Conggai Li, Haifang Li, Rui Cao, Bin Wang, Xiaohong Han, and Junjie Chen. "The detection of epileptic seizure signals based on fuzzy entropy." *Journal of Neuroscience Methods* 243 (2015): 18-25.
- [42] Wang, Bin, Tianyi Yan, Seiichiro Ohno, Susumu Kanazawa, and Jinglong Wu. "Retinotopy and attention to the face and house images in the human visual cortex." *Experimental Brain Research* 234, no. 6 (2016): 1623-1635.
- [43] Vera-Olmos, Francisco Javier, Esteban Pardo, Helena Melero, and Norberto Malpica. "DeepEye: Deep convolutional network for pupil detection in real environments." *Integrated Computer-Aided Engineering* 26, no. 1 (2019): 85-95.
- [44] Yang, Tao, Cindy Cappelle, Yassine Ruichek, and Mohammed El Bagdouri. "Multi-object tracking with discriminant correlation filter based deep learning tracker." *Integrated Computer-Aided Engineering* 26, no. 3 (2019): 273-284.
- [45] Hua, Chengcheng, Hong Wang, Hong Wang, Shaowen Lu, Chong Liu, and Syed Madiha Khalid. "A novel method of building functional brain network using deep learning algorithm with application in proficiency detection." *International Journal of Neural Systems* 29, no. 01 (2019): 1850015.
- [46] Zhang, Yang, Tao Cheng, and Yibin Ren. "A graph deep learning method for short-term traffic forecasting on large road networks." *Computer-Aided Civil and Infrastructure Engineering* 34, no. 10 (2019): 877-896.
- [47] Ahmedt-Aristizabal, David, Clinton Fookes, Kien Nguyen, Simon Denman, Sridha Sridharan, and Sasha Dionisio. "Deep facial analysis: A new phase I epilepsy evaluation using computer vision." *Epilepsy & Behavior* 82 (2018): 17-24.
- [48] Hassanpour, Ahmad, Majid Moradikia, Hojjat Adeli, Seyed Raouf Khayami, and Pirooz Shamsinejadbabaki. "A novel end-to-end deep learning scheme for classifying multi-class motor imagery electroencephalography signals." *Expert Systems* 36, no. 6 (2019): e12494.
- [49] Molina-Cabello, Miguel A., Rafael Marcos Luque-Baena, Ezequiel Lopez-Rubio, and Karl Thurnhofer-Hemsi. "Vehicle type detection by ensembles of convolutional neural networks operating on super resolved images." *Integrated Computer-Aided Engineering* 25, no. 4 (2018): 321-333.
- [50] Li, Shengyuan, Xuefeng Zhao, and Guangyi Zhou. "Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network." *Computer-Aided Civil and Infrastructure Engineering* 34, no. 7 (2019): 616-634.
- [51] Maeda, Keisuke, Sho Takahashi, Takahiro Ogawa, and Miki Haseyama. "Convolutional sparse coding-based deep random vector functional link network for distress classification of road structures." *Computer-Aided Civil and Infrastructure Engineering* 34, no. 8 (2019): 654-676.

- [52] Acharya, Rajendra, Shu Lih Oh, Yuki Hagiwara, Jen Hong Tan, Hojjat Adeli, and D. Puthankattil Subha. "Automated EEG-based screening of depression using deep convolutional neural network." *Computer Methods and Programs in Biomedicine* 161 (2018): 103-113.
- [53] Acharya, Rajendra, Shu Lih Oh, Yuki Hagiwara, Jen Hong Tan, and Hojjat Adeli. "Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals." *Computers in Biology And Medicine* 100 (2018): 270-278.
- [54] Nogay, Hidir Selcuk, and Hojjat Adeli. "Detection of epileptic seizure using pretrained deep convolutional neural network and transfer learning." *European Neurology* 83, no. 6 (2021): 602-614.
- [55] Ostadieh Jawad.; Chehel Amirani Mehdi.; and Valizadeh Morteza. "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* 10, no. 4 (2020): 219.
- [56] Haykin Simon. "Neural networks and learning machines"; Prentice Hall 2008, pp. 230-263.
- [57] Guo, Ling, Daniel Rivero, Julián Dorado, Cristian R. Munteanu, and Alejandro Pazos. "Automatic feature extraction using genetic programming: An application to epileptic EEG classification." *Expert Systems with Applications* 38, no. 8 (2011): 10425-10436.
- [58] Du, Xian, Sumeet Dua, Rajendra U. Acharya, and Chua Kuang Chua. "Classification of epilepsy using high-order spectra features and principle component analysis." *Journal of Medical Systems* 36, no. 3 (2012): 1731-1743.
- [59] Martis, Roshan Joy, U. Rajendra Acharya, Jen Hong Tan, Andrea Petznick, Louis Tong, Chua Kuang Chua, and Eddie Yin Kwee Ng. "Application of intrinsic time-scale decomposition (ITD) to EEG signals for automated seizure prediction." *International Journal of Neural Systems* 23, no. 05 (2013): 1350023.
- [60] Acharya, U. Rajendra, Ratna Yanti, Jia Wei Zheng, M. Muthu Rama Krishnan, Jen Hong Tan, Roshan Joy Martis, and Choo Min Lim. "Automated diagnosis of epilepsy using CWT, HOS and texture parameters." *International Journal of Neural Systems* 23, no. 03 (2013): 1350009.
- [61] Kaya, Yılmaz, Murat Uyar, Ramazan Tekin, and Selçuk Yıldırım. "1D-local binary pattern based feature extraction for classification of epileptic EEG signals." *Applied Mathematics and Computation* 243 (2014): 209-219.
- [62] Riaz, Farhan, Ali Hassan, Saad Rehman, Imran Khan Niazi, and Kim Dremstrup. "EMD-based temporal and spectral features for the classification of EEG signals using supervised learning." *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 24, no. 1 (2015): 28-35.
- [63] Acharya, U. Rajendra, S. Vinitha Sree, Peng Chuan Alvin Ang, Ratna Yanti, and Jasjit S. Suri. "Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals." *International Journal of Neural Systems* 22, no. 02 (2012): 1250002.
- [64] Martis, Roshan Joy, Jen Hong Tan, Chua Kuang Chua, Too Cheah Loon, SHARON WAN JIE YEO, and Louis Tong. "Epileptic EEG classification using nonlinear parameters on different frequency bands." *Journal of Mechanics in Medicine and Biology* 15, no. 03 (2015): 1550040.
- [65] Li, Mingyang, Wanzhong Chen, and Tao Zhang. "Automatic epileptic EEG detection using DT-CWT-based non-linear features." *Biomedical Signal Processing and Control* 34 (2017): 114-125.
- [66] Milligan, Tracey "Epilepsy: a clinical overview." *The American Journal of Medicine* 134, no. 7 (2021): 840-847.
- [67] Selesnick, Ivan W., Richard G. Baraniuk, and Nick C. Kingsbury. "The dual-tree complex wavelet transform." *IEEE Signal Processing Magazine* 22, no. 6 (2005): 123-151.
- [68] Benesty, Jacob, and Tomas Gänslér. "New insights into the RLS algorithm." *EURASIP Journal on Advances in Signal Processing* 2004, no. 3 (2004): 243857.
- [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, John. "CHB-MIT scalp EEG database (version 1.0. 0)." *PhysioNet* 10 (2010): C2K01R.