

A new Approach to Epilepsy Diagnosis based on the Social Spider Algorithm and the Support Vector Machine

Bahram Dehghan^{1*}

¹ Department of Electrical Engineering, Sarvestan Branch, Islamic Azad University, Sarvestan, Iran
Bahramdehghan1@gmail.com

Abstract: Epilepsy can be defined as recurrent seizures caused by sudden electrical discharges in a group of human brain cells. Electroencephalogram (EEG) signals play a very important role in the diagnosis of this disease. EEG signal recordings, which are recorded by portable recording devices, produce very long data, and the detection of the epileptic zone requires a long time for the analysis of all the data by a specialist. Traditional analysis methods are tedious, so in recent years, a large number of automatic systems for epilepsy diagnosis have emerged. In this paper, a new approach based on the social spider optimization algorithm (SSO) is presented. First, the EEG signal is decomposed based on the discrete wavelet transform. Then, 132 statistical features, entropy and chaos features are extracted, and then the best features are selected by the SSO with the proposed objective function. Finally, the selected features are used to classify seizure and non-seizure EEG signals by support vector machine algorithm. Simulation results show that the proposed method has good accuracy and sensitivity on Bonn university dataset, and this method can effectively help doctors in diagnosing epilepsy, thus reducing their workload.

Keywords: Epileptic Seizure Detection, Features Selection, Electroencephalogram Signals, Social Spider Optimization algorithm.

JCDSA, Vol. 3, No. 1, Spring 2025
 Received: 2025-01-16

Online ISSN: 2981-1295
 Accepted: 2025-05-23

Journal Homepage: <https://sanad.iau.ir/en/Journal/jcdsa>
 Published: 2025-06-21

CITATION

Dehghan, B., "A new Approach to Epilepsy Diagnosis based on the Social Spider Algorithm and the Support Vector Machine", Journal of Circuits, Data and Systems Analysis (JCDSA), Vol. 3, No. 1, pp. 13-22, 2025.
 DOI: 10.82526/jcdsa.2025.1196716

COPYRIGHTS



©2025 by the authors. Published by the Islamic Azad University Shiraz Branch. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0)
<https://creativecommons.org/licenses/by/4.0>

* Corresponding author

Extended Abstract

1- Introduction

Epilepsy is a chronic neurological disorder characterized by sudden, uncontrolled seizures and unpredictable patient behaviors. Accurate and timely diagnosis of epilepsy is essential for initiating antiepileptic drug therapy and reducing disease risk. Currently, epilepsy diagnosis relies on neurological examinations and auxiliary tests such as brain imaging and EEG, with EEG maintaining its position as the most widely used diagnostic approach. However, visual analysis of electroencephalogram (EEG) for epilepsy detection remains highly costly, time-consuming, and prone to errors. Therefore, it is crucial to develop an automated computer-aided diagnostic system to detect epileptic states from EEG signals automatically. Such a system would significantly assist specialists in achieving accurate and efficient diagnosis. Although extensive research has been conducted on epilepsy detection, challenges remain regarding the number of extracted features, which significantly impacts diagnostic accuracy. In this paper, EEG signals are first decomposed using the discrete wavelet transform (DWT) algorithm. Subsequently, 132 features including statistical, entropy, and chaos based features are extracted from the EEG signals to ensure comprehensive signal representation. To prevent overfitting and extract meaningful information, the social spider optimization (SSO) metaheuristic algorithm and a proposed objective function are employed for optimal feature selection. Finally, a support vector machine (SVM) classifier is implemented for EEG signal classification and epilepsy detection.

2- Methodology

This section outlines the theoretical framework of our proposed method for epilepsy detection. The diagnostic process, as illustrated in the accompanying flowchart, follows a structured sequence beginning with data preprocessing and segmentation, followed by discrete wavelet transform analysis. The methodology proceeds with comprehensive feature extraction encompassing statistical parameters, entropy measures, and chaos-based characteristics. Subsequent stages involve optimal feature selection through the social spider optimization metaheuristic algorithm, culminating in classification using a support vector machine architecture. The following discussion provides detailed technical specifications for each component of this systematic detection framework.

This paper uses the EEG database from the University of Bonn, Germany. The database consists of five groups (Z, O, N, F, S), each containing 100 EEG signal samples with a duration of 23.6 seconds and a sampling rate of 173.61 Hz. These signals belong to subjects aged between 6 and 43 years, and artifacts such as muscle movements and eye movements have been removed from these signals. Groups Z and O contain samples from healthy (non-

epileptic) individuals with eyes open and eyes closed, respectively. Groups N and F include samples from patients during interictal periods (between epileptic seizures). Group S consists of samples from patients during actual epileptic seizures. The database provides a standardized dataset with clean EEG signals that clearly differentiate between healthy states and various epileptic conditions, making it suitable for epilepsy detection research. The consistent sampling rate and recording duration across all samples allow for reliable comparative analysis of different epileptic states and normal brain activity.

3- Results and discussion

This section begins by examining the evaluation criteria for epilepsy detection methods before introducing the dataset employed in this study. The discussion then proceeds to present the experimental outcomes of our proposed detection approach, including comparative analyses with existing conventional methods. All computational experiments were implemented and executed using MATLAB software on a standard personal computer configuration.

The first experiment investigates the impact of varying EEG signal window sizes (4096, 2048, 1024, and 512 samples) on seizure detection performance. Results demonstrate that classification accuracy, sensitivity, and specificity all improve with increasing window length. Notably, the proposed model maintains acceptable performance even with shorter window sizes (512 samples), indicating its robustness across different signal durations.

The second experiment compares the proposed method with recent state-of-the-art approaches. Tabulated results show superior performance of our method in key classification metrics, confirming its effectiveness for epileptic seizure detection.

4- Conclusion

This paper presents a novel automated epilepsy detection system. The proposed methodology involves several key stages: First, noise removal and segmentation are performed on the raw EEG signals. The signals then undergo decomposition using discrete wavelet transform (DWT). Subsequently, 165 distinct features are extracted from both the raw and decomposed EEG signals. Since feature selection critically impacts epilepsy detection accuracy, the system employs an innovative approach combining the social spider optimization (SSO) metaheuristic algorithm with a custom objective function to identify the most discriminative features. Finally, a support vector machine (SVM) classifier distinguishes between ictal (seizure) and interictal (non-seizure) EEG patterns.

The developed system offers clinicians an efficient tool for rapid epilepsy diagnosis. Notably, the proposed framework shows potential for adaptation to other neurological disorders, including Alzheimer's disease detection, demonstrating its broader clinical applicability.





رویکرد جدید در تشخیص بیماری صرع مبتنی بر الگوریتم عنکبوت

اجتماعی و الگوریتم ماشین بردار پشتیبان

بهرام دهقان^{۱*}

۱- گروه مهندسی برق، واحد سروستان، دانشگاه آزاد اسلامی، سروستان، ایران (Bahramdehghan1@gmail.com)

چکیده: بیماری صرع را می توان به عنوان تشنج های عودکننده ناشی از تخلیه الکتریسته ناگهانی بر روی یک گروه از سلول های مغزی انسان تعریف کرد. سیگنال های الکتروانسفالوگرام (EEG) نقش بسیار مهمی در تشخیص این بیماری ایفا می کند. ثبت سیگنال های EEG که توسط دستگاه های ثبت سیار ضبط می شوند، اطلاعاتی با طول بسیار بالا تولید می کنند که تشخیص ناحیه صرعی، نیازمند مدت زمان طولانی برای تحلیل کل اطلاعات توسط شخص متخصص می باشد. به دلیل خسته کننده بودن روش های سنتی تحلیل، در سال های اخیر تعداد بسیار زیادی سیستم اتوماتیک برای تشخیص صرع به وجود آمده است. در این مقاله، رویکرد جدیدی مبتنی بر الگوریتم عنکبوت اجتماعی ارائه شده است. در ابتدا سیگنال EEG براساس تبدیل موجک گسسته تجزیه می شود. سپس، ۱۳۲ ویژگی آماری، آنتروپی و ویژگی های آشوب استخراج می شوند و بهترین ویژگی ها توسط الگوریتم عنکبوت اجتماعی با تابع هدف پیشنهادی انتخاب می شوند. در نهایت، ویژگی های انتخابی با استفاده از الگوریتم ماشین بردار پشتیبان جهت طبقه بندی سیگنال های EEG تشنج و غیرتشنج استفاده می شود. نتایج شبیه سازی نشان می دهد که روش پیشنهادی بر روی مجموعه داده های سیگنال EEG دانشگاه بُن به صحت و حساسیت خوبی برخوردار است و این روش می تواند به طور مؤثر به پزشکان در تشخیص صرع کمک کند، بنابراین بارکاری آنها کاهش می یابد.

واژه های کلیدی: تشخیص بیماری صرع، انتخاب ویژگی ها، سیگنال های الکتروانسفالوگرام، الگوریتم بهینه سازی عنکبوت اجتماعی

DOI: 10.82526/jcdsa.2025.1196716

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۴/۰۳/۳۱

تاریخ پذیرش مقاله: ۱۴۰۴/۰۳/۰۲

تاریخ ارسال مقاله: ۱۴۰۳/۱۰/۲۷

صرعی را از سیگنال EEG تشخیص دهد [۷]. این سیستم، به متخصصان جهت تشخیص دقیق و مؤثر بسیار کمک کننده می باشد. تشخیص بیماری صرع به طور کلی با استفاده از الگوریتم یادگیری ماشین از سه مرحله، پیش پردازش، شناسایی ویژگی و طبقه بندی تشکیل شده است که مرحله شناسایی ویژگی ها یکی از مهم ترین مراحل می باشد [۸، ۹]. مرحله شناسایی ویژگی ها را می توان به سه مرحله استخراج ویژگی ها، انتخاب ویژگی ها و تبدیل ویژگی ها تقسیم کرد که مراحل استخراج و انتخاب ویژگی ها در دقت تشخیص بیماری صرع بسیار حائز اهمیت می باشد [۱۰]. این امر سبب شده هر روزه توجه محققانی بیشتری را به خود جلب کند که در ادامه که به مرور مواردی از آنها پرداخته می شود.

در [۱۱] از آنتروپی طیفی، آنتروپی نمونه و آنتروپی فاز به عنوان ویژگی ها از سیگنال EEG برای تشخیص بیماری صرع استفاده شده است. در [۱۲] جهت استخراج ویژگی ها، از ویژگی های آماری استفاده شده است. در [۱۳] از ویژگی های توان شامل طیف توان نسبی، نسبت طیف توان و ضرایب همبستگی متقابل جهت تشخیص بیماری صرع

۱- مقدمه

صرع به عنوان یکی از مهمترین اختلالات عصبی در جهان محسوب می شود که می تواند در همه گروه های سنی تأثیر بگذارد [۱، ۲]. در حال حاضر حدود ۶۵ میلیون نفر در سراسر جهان از بیماری صرع رنج می برند [۳]. صرع یک اختلال عصبی پایدار است که در آن تشنج با اختلالات ناخواسته ناگهانی و رفتارهای غیرقابل پیش بینی بیماران مشخص می شود. تشخیص صحیح و به موقع صرع برای شروع استفاده از داروهای کنترل کننده صرع و کاهش ریسک ابتلا به این بیماری، امری ضروری است. در حال حاضر، تشخیص صرع با آزمایش های نورولوژی و آزمایش های کمکی مثل تصاویر مغزی و اسکن بصری الکتروانسفالوگرام (EEG)^۲ حاصل می شود که EEG جایگاه خود را به عنوان پرکاربردترین رویکرد تشخیصی حفظ کرده است [۴، ۵]. با این وجود، اسکن EEG برای تشخیص صرع هنوز هم بسیار پرهزینه، زمان بر و کاری نادرست است [۶]. بنابراین ضروری است سیستم خودکار تشخیص کامپیوتری طراحی شود تا به طور خودکار، حالت های

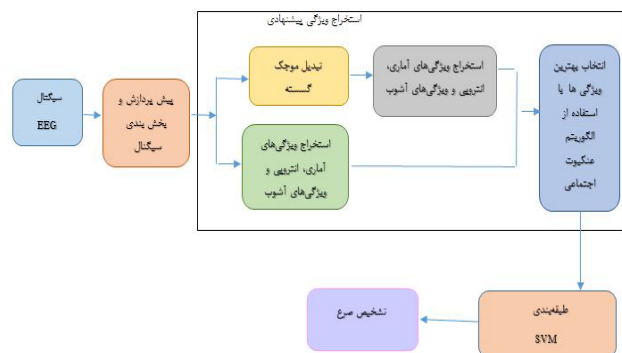
^{*} نویسنده مسئول² Electroencephalogram

زمینه‌های مختلف پردازش تصویر و پردازش سیگنال کاربرد دارد [۲۶-۲۸]. این الگوریتم برخلاف سایر الگوریتم‌های فرا ابتکاری دیگر همچون الگوریتم ژنتیک، الگوریتم ازدحام ذرات، الگوریتم بهینه‌سازی فاخته، الگوریتم جستجوی هارمونی، الگوریتم بهینه‌سازی شبکه اجتماعی و الگوریتم کلونی زنبور عسل مصنوعی، از همگرایی زودرس به راه حل‌های بهینه محلی یا تعادل محدود بین اکتشاف و بهره‌برداری جلوگیری می‌کند [۲۷]. این مزایا انگیزه استفاده از الگوریتم عنکبوت اجتماعی برای انتخاب بهترین ویژگی‌ها را فراهم می‌کند.

در این مقاله، ابتدا سیگنال EEG توسط الگوریتم تبدیل موجک گسسته تجزیه و تحلیل می‌شود. سپس، ۱۳۲ ویژگی از جمله ویژگی‌های آماری، آنتروپی و ویژگی‌های آشوب، از سیگنال EEG استخراج می‌شود که بتواند اطلاعات کافی از این سیگنال حاصل شود. پس از آن، برای جلوگیری از سرریز و استخراج اطلاعات مفید توسط الگوریتم فرا ابتکاری عنکبوت اجتماعی و تابع هدف پیشنهادی جهت انتخاب بهترین ویژگی‌ها استفاده می‌شود. در نهایت، از الگوریتم ماشین بردار پشتیبان جهت طبقه‌بندی سیگنال EEG و تشخیص صرع به کار گرفته می‌شود. سازمان‌دهی بقیه مقاله به این صورت است که در بخش دوم به شرح روش پیشنهادی جهت تشخیص بیماری صرع، در بخش‌های سوم و چهارم به ترتیب به نتایج و آزمایش‌ها و نتیجه‌گیری و پیشنهادها پرداخته می‌شود.

۲- روش پیشنهادی

در این بخش، به تئوری روش پیشنهادی تشخیص بیماری صرع پرداخته می‌شود. فرآیند تشخیص بیماری صرع پیشنهادی مطابق شکل (۱) شامل پنج مرحله اصلی، پیش‌پردازش و بخش‌بندی دیتا، تبدیل موجک گسسته، استخراج ویژگی‌های آماری، آنتروپی و ویژگی‌های آشوب، انتخاب بهترین ویژگی با استفاده از الگوریتم فرا ابتکاری عنکبوت اجتماعی و در نهایت، طبقه‌بندی با استفاده از الگوریتم ماشین بردار پشتیبان می‌باشد. در ادامه، به شرح جزئیات هر یک از مراحل پیشنهادی جهت تشخیص بیماری صرع پرداخته می‌شود.



شکل (۱). فلوچارت روش پیشنهادی

استفاده شده است. در [۱۴] از شبکه‌های یادگیری عمیق روی داده‌های EEG جهت استخراج ویژگی‌ها استفاده شده است. در [۱۵] از تبدیل موجک و تحلیل غیرخطی RQA جهت استخراج ویژگی‌ها در تشخیص بیماری صرع استفاده شده است. در [۱۶] از تبدیل موجک و محاسبه انرژی ضرایب موجک به عنوان ویژگی‌ها جهت تشخیص بیماری صرع استفاده شده است. در [۱۷] از تبدیل موجک و الگوریتم K-means جهت استخراج ویژگی‌ها استفاده شده است. در [۱۸] از روش‌های تخمین طیفی EV و MUSIC جهت استخراج ویژگی‌ها استفاده شده است. در [۱۹] از روش تعمیم یافته تبدیل موجک و آنتروپی تقریبی جهت استخراج ویژگی‌ها و از الگوریتم ژنتیک جهت انتخاب ویژگی‌ها استفاده شده است. در [۲۰] از الگوریتم جستجوی گرانشی باینری جهت انتخاب ویژگی‌ها استفاده شده است. در [۲۱] از آنالیز خودرگرسیون^۱ جهت استخراج ویژگی‌ها از سیگنال EEG استفاده شده است. در [۲۲] از ترکیب روش‌های زمانی و فرکانسی جهت استخراج ویژگی‌ها استفاده شده است. در [۲۳]، از الگوریتم گرگ خاکستری جهت انتخاب بهترین ویژگی‌ها و انتخاب مقدار بهینه پارامترهای الگوریتم ماشین بردار پشتیبان استفاده شده است. در [۲۴]، از ترکیب ویژگی‌های مبتنی بر زمان، مبتنی بر فرکانس و مبتنی بر فرکانس-زمان جهت استخراج اطلاعات کافی از سیگنال EEG استفاده شده است و سپس از شبکه سیامی جهت کاهش ابعاد ویژگی‌ها ارائه شده است. در [۲۵]، از الگوریتم فرا ابتکاری همچون الگوریتم جستجوی همزیستی ارگانیسم^۲، الگوریتم بهینه‌سازی ملخ^۳، الگوریتم باوری زمین‌های کشاورزی^۴ جهت انتخاب بهترین ویژگی‌ها استفاده شده که انتخاب بهترین ویژگی‌ها با الگوریتم باروری زمین‌های کشاورزی از دقت بهتری برخوردار است.

اگرچه تحقیقات فراوانی جهت تشخیص بیماری صرع انجام شده است اما هنوز چالش‌های در تعداد ویژگی‌های استخراج شده می‌باشد که در دقت تشخیص بیماری صرع بسیار موثر می‌باشد. تعیین تعداد ویژگی‌های استخراج شده از سیگنال EEG بسیار حائز اهمیت است، زیرا اگر از تعداد ویژگی‌های کمتری استفاده شود ممکن است اطلاعات کافی از سیگنال EEG جهت تشخیص بیماری صرع حاصل نشود و از طرف دیگر، اگر از تعداد ویژگی‌های زیادی استفاده شود منجر به سرریز^۵ می‌شود که سبب پیچیدگی محاسباتی در مراحل بعدی می‌شود. بنابراین، تعداد ویژگی‌ها باید به حد کافی باشد که از یک طرف، بتواند اطلاعات موثر از سیگنال EEG استخراج شود و از طرف دیگر منجر به سرریز نشود. این مستلزم پیشنهاد یک روش مناسب جهت استخراج و انتخاب ویژگی‌های مناسب از سیگنال EEG می‌باشد. الگوریتم‌های فرا ابتکاری مختلفی جهت انتخاب بهترین ویژگی‌ها می‌توان استفاده کرد اما انتخاب الگوریتم فرا ابتکاری مناسب در اسین زمینه بسیار حائز اهمیت است. الگوریتم عنکبوت اجتماعی یکی از الگوریتم‌های فرا ابتکاری می‌باشد که به طور گسترده در

⁴ Farmland fertility algorithm (FFA)

⁵ Ccruse of Dimensional

¹ Autoregressive

² Symbiotic-Organism Search Algorithm (SOSA)

³ Grasshopper Optimisation Algorithm (GOA)



۱-۲- پیش پردازش و بخش بندی سیگنال

سیگنال الکتروآنسفالوگرافی شامل نویزهای از جمله، نویز برق شهر و نویز حاصل از چشمک زدن، حرکات چشمی و همچنین آرتیفکت های ماهیچه ای است که جهت استفاده از این سیگنال ها لازم است از روش فیلترینگ FIR استفاده کرد. فیلترینگ موردنظر در اینجا از دو فیلتر FIR تشکیل شده است. یک فیلتر میان نگذر با باند فرکانسی ۴۰-۵۰ هرتز که مربوط به فرکانس برق شهر، را رد می کند. دیگری یک فیلتر میان گذر که بازه فرکانسی ۵/۳۰-۰ هرتز را عبور می دهد. بعد از حذف نویز، سیگنال EEG به بخش هایی با طول ثابت، تقسیم می شود. در این راستا، طول سیگنالی که در این مقاله مورد بررسی قرار می گیرد: ۵۱۲ نمونه، ۱۰۲۴ نمونه، ۲۰۴۸ نمونه و کل طول (۴۰۹۷ نمونه) سیگنال EEG است.

۲-۲- تبدیل موجک گسسته

در این بخش، از روش تبدیل موجک گسسته برای تجزیه و تحلیل سیگنال EEG به باندهای فرکانسی مختلف استفاده شده است. توابع موجک گسسته توسط جفت فیلترهای بالاگذر و پایین گذر تعریف می شوند. این فیلترها اجزای فرکانس بالا و پایین سیگنال ورودی را جدا می کنند. در مرحله اول، خروجی فیلتر بالاگذر ضرایب جزئیات (D1) و خروجی فیلتر پایین گذر ضرایب تقریبی (A1) می باشد. ضرایب (A1) دوباره تجزیه شده و تا چهار مرحله ادامه می یابد.

۳-۲- استخراج ویژگی

روش های استخراج ویژگی به طور کلی به سه دسته، استخراج ویژگی های آماری، آنتروپی و ویژگی های آشوب، تقسیم می شوند که اخیرا تحقیقات نشان دهنده اینست که ترکیب هر سه روش جهت بهبود دقت تشخیص خودکار صرع بسیار موثرتر است [۲۹-۳۱]. در جدول (۱) لیستی از ترکیب هر سه روش ویژگی های استفاده شده در این مقاله معرفی شد. در نهایت، ((۲۲×(۱+۵)) ویژگی از هر دو سیگنال EEG خام و زیرباندهای تجزیه شده استخراج می شود. برخی از این ویژگی ها ممکن است زائد باشند که برای طبقه بندی مناسب نیستند. حذف ویژگی های زائد، امری بسیار ضروری است که در این مقاله، از الگوریتم فرا ابتکاری عنکبوت اجتماعی و تابع هدف پیشنهادی استفاده می شود.

جدول ۱: لیستی از ویژگی های استخراج شده

شماره	نوع ویژگی	روابط ویژگی ها
۱	میانگین	$\mu_a = \frac{1}{N} \sum_{i=1}^N a_i$
۲	انحراف استاندارد	$\sigma_a = \sqrt{\frac{1}{N-1} \sum_{i=1}^N a_i - \mu_a ^2}$
۳	واریانس	$V_a = \frac{1}{N-1} \sum_{i=1}^N a_i - \mu_a ^2$
۴	انحراف	$S_a = \frac{R_3}{R_2 \sqrt{R_2}}, R_k = \frac{1}{N} \sum_{i=1}^N a_i - \mu_a ^k$

۵	کورتوز	$K_a = \frac{R_4}{R_2 R_2}, R_k = \frac{1}{N} \sum_{i=1}^N a_i - \mu_a ^k$
۶	طول خط	$L_a = \sum_{i=1}^{N-1} a_i - a_{i-1} $
۷	انرژی غیرخطی	$NE_a = \sum_{i=2}^{N-1} a_i^2 - a_{i+1} a_{i-1} $
۸	SampEn	$SEn(a, m, r) = \log \phi^m(r) - \log \phi^{m+1}(r)$ $\phi^m(r) = \sum_{j=0}^{N-m} \sum_{i=0}^{N-m} \Theta(r - \ a_i - a_j\)$ where $\Theta(\cdot)$ is Heaviside step function
۹	آنتروپی جایگشت	$PEn(a) = -\sum_{k=1}^{m-1} p(\pi_k) \log p(\pi_k)$ $p(\pi_k) = \frac{1}{N-m+1} \sum_{i=0}^{N-m} \delta[a_i - \pi_k]$ where $\delta(\cdot)$ is Dirac function
۱۰	آنتروپی شانون	$ShEn(a) = -\sum_{i=1}^N p_i \log p_i$
۱۱	آنتروپی طیفی	$SpEn(a) = -\sum_{f=1}^N p_f \log p_f$
۱۲	آنتروپی طیفی نرمالیزه شده	$NSE = \frac{1}{\log(N_f)} \sum_{f=f_1}^{f_2} S(f) (\log \frac{1}{S(f)})$
۱۳	آنتروپی بولتزمن	$Boltzmann_entropy = k \ln(W)$
۱۴	آنتروپی کولموگروف	$K = \lim_{n \rightarrow \infty} \sum_{n=1}^{N-1} (S_{n+1} - S_n) = \lim_{n \rightarrow \infty} \frac{1}{N} [S_N - S_0]$
۱۵	تحرك	$M_a = \frac{\sigma_{a'}}{\sigma_a}, a'_i = a_{i+1} - a_i$
۱۶	پیچیدگی	$C_a = \frac{\sigma_{a''}}{\sigma_{a'}}, a''_i = a'_{i+1} - a'_i$
۱۷	Number of zero-crossings	NZ_a
۱۸	تعداد اکسترمم محلی	NX_a
۱۹	ابعاد فراکتال کاتز	$katz = \frac{\log(L/a)}{\log(d/a)}$
۲۰	بزرگترین توان لیاپانوف	$LLE = \lim_{t \rightarrow \infty} \frac{1}{t} \ln \frac{ \Delta x(x_0, t) }{ \Delta x_0 }$
۲۱	بعد فراکتال پطروسیان	$PFD = \frac{\log N}{\log N + \log N + 0.4M}$
۲۲	اندازه گیری همبستگی پیچیده	$A(i) = \frac{1}{2} \begin{bmatrix} x_1, y_1, 1, 1 \\ x_2, y_2, 1 \\ x_3, y_3, 1 \end{bmatrix}$ $C_n = \pi \times SD1 \times CCM(m) = \frac{1}{C_n(N-2)} \sum_{i=1}^{N-2} \ A(i)\ $



۲-۴- انتخاب بهترین ویژگی‌ها

انتخاب ویژگی‌ها، فرآیند شناسایی و حذف ویژگی‌های نامربوط، کم اهمیتیت و حذف ویژگی‌های زائد جهت انتخاب بهترین ورودی برای طبقه‌بندی و بهبود دقت تشخیص صرع می‌باشد. برای استخراج بهترین ویژگی‌ها، الگوریتم فراابتکاری عنکبوت اجتماعی پیشنهاد شده است. در ادامه به شرح جزئیات این الگوریتم پرداخته می‌شود.

۲-۴-۱- الگوریتم عنکبوت اجتماعی

الگوریتم بهینه‌سازی عنکبوت اجتماعی توسط کائوس و همکاران در سال ۲۰۱۳ ارائه شده است [۳۲]. رفتار جستجوگر عنکبوت اجتماعی را می‌توان به عنوان جنبش جمعی عنکبوت‌ها به سمت محل منبع غذایی توصیف کرد. عنکبوت ارتعاشات منتشر شده در شبکه را برای تعیین جهت بالقوه یک منبع غذایی دریافت و تحلیل می‌کند. هر عنکبوت در وب دارای یک موقعیت و یک برازش است که نشان دهنده بالقوه یافتن منبع غذایی در آن موقعیت می‌باشد. عنکبوت می‌تواند آزادانه در وب حرکت کند، اما وب را نمی‌تواند ترک کند. هنگامی که یک عنکبوت به موقعیت جدیدی حرکت نماید، یک ارتعاش تولید می‌کند که در سراسر وب منتشر می‌شود. اعضای اجتماعی به جنس ماده و جنس نر تقسیم شده است که در آن تعداد جنس ماده بیشتر از جنس نر است، جنس ماده حدود ۹۰ درصد از جمعیت را تشکیل می‌دهد. در طول بهینه‌سازی، عنکبوت با ارتعاش رشته‌ها در وب ارتباط برقرار می‌کند. ارتعاش که یک عنکبوت جنس ماده دریافت می‌کند، با توجه به اندازه عنکبوت و فاصله‌ی عنکبوت‌ها از یکدیگر صرفنظر از جنس تعریف شده است. پاسخ جنس ماده به این ارتعاشات به صورت جاذبه یا دافعه است که یا به سمت آن ارتعاش جذب می‌شود و یا از آن دور می‌شود. مدل ریاضی که توسط کائوس و همکاران ارائه شده است در (۱) آمده است:

$$Vibsi = w_j e_{ij}^d \quad (1)$$

در این رابطه، w وزن عنکبوت z ام و d فاصله اقلیدوسی بین عنکبوت i ام و j ام است. فرض بر اینست که عنکبوت جنس ماده قادر به احساس سه ارتعاش از عنکبوت‌ها به شرح ذیل است: نزدیکترین عضو با وزن بالاتر ($Vibsi$)، پیش‌ترین عنکبوت در اجتماع ($Vibbi$)، نزدیکترین عنکبوت نر به عنکبوت ماده که برای آن مناسب‌تر است ($Vibfi$) [۳۳]. عنکبوت جنس ماده به سمت منشأ ارتعاشات جذب می‌شود و یا از آن دور می‌شود. حرکت جاذبه و یا دافعه بستگی به چند پدیده تصادفی دارد. یک عدد تصادفی ثابت در محدوده $\{0,1\}$ تولید می‌شود در صورتی که عدد کوچکتر از PF (حد آستانه) باشد جنبش جاذبه و در غیر اینصورت جنبش دافعه است (مطابق (۲)).

$$X_i(t+1) = X_i(t) + \left(\alpha \cdot Vibci \cdot (S_c - X_i(t)) + \beta \cdot Vibbi \cdot (S_b - X_i(t)) + \delta(r - 0.5) \right) \quad (2)$$

که در آنها α, β, δ ارزش‌های تصادفی در بازه $\{0,1\}$ نزدیک‌ترین و بهترین همسایه و S_b عنکبوت پردازش شده می‌باشد. این فرمول زمانی قابل اجرا است که جنس ماده به سمت منشأ ارتعاشات جذب شود. در صورتی که از منشأ ارتعاشات دور شود از (۳) استفاده شده است.

$$X_i(t+1) = X_i(t) + \left(\alpha \cdot Vibci \cdot (S_c - X_i(t)) + \beta \cdot Vibbi \cdot (S_b - X_i(t)) + \delta(r - 0.5) \right) \quad (3)$$

جنس نر به روش‌های مختلف موقعیت خود را بروزرسانی می‌کند. عنکبوت‌ها در ابتدا به دو گروه عنکبوت غالب و مغلوب تقسیم می‌شوند. عنکبوت غالب با وزن بالاتر و تناسب اندام بهتر است و عنکبوت جنس ماده تمایل بیشتری دارد به سمت ارتعاشات آن جذب شود. درحالی‌که دیگر عنکبوت تمایل دارد به سمت مرکز جمعیت حرکت کند و به عنوان یک استراژی به استفاده از منابع غذایی که توسط عنکبوت غالب هدر رفته می‌پردازد. این رفتار برگرفته شده از الگوی رفتاری عنکبوت برای پیدا کردن غذا است. بدین ترتیب وزن تمام عنکبوت نر در هر تکرار مشخص می‌شود. موقعیت عنکبوت غلب و مغلوب به ترتیب مطابق (۴ و ۵) به دست می‌آید.

$$X_i(t+1) = X_i(t) + \left(\alpha \cdot Vibfi \cdot (S_f - X_i(t)) + \delta(r - 0.5) \right) \quad (4)$$

$$X_i(t+1) = X_i(t) + \left(\alpha \left(\frac{\sum_j^N m_{ij}^k \cdot N_{f+j}}{\sum_j^N N_f} \right) - X_i(t) \right) \quad (5)$$

که در آنها S_f نزدیکترین جنس نر و α, β, δ ارزش‌های تصادفی در بازه $\{0,1\}$ می‌باشند. از اینرو عنکبوت غالب در یک شعاع خاص که متشکل از یک یا چند جنس نر و ماده است، شروع به جفت‌گیری می‌کند. بنابراین، یک مکانیسم چرخ‌گردان به طور تصادفی به انتخاب پدر و مادری متناسب با ارزش‌های خود می‌پردازد. عنکبوت جدید ساخته شده (ترکیبی از ژنها) برازش آنها در مقایسه با بدترین عنکبوت (کمترین وزن و اندام نامناسب) در جامعه محاسبه و مقایسه می‌شود. در صورتی که عنکبوت جدید بهترین باشد توسط بدترین عنکبوت تولید شده جایگزین می‌شود.

۲-۴-۲- انتخاب ویژگی توسط الگوریتم عنکبوت اجتماعی

در این بخش، ۲۲ ویژگی از سیگنال خام EEG و ۲۲ ویژگی از هر یک از زیر باندهای تبدیل موجک گسسته استخراج می‌شوند (مطابق شکل (۲)) که در مجموع ۱۳۲ ویژگی استخراج شده است. این مجموع ۱۳۲ ویژگی به الگوریتم عنکبوت اجتماعی وارد می‌شود و این الگوریتم با استفاده از تابع شایستگی پیشنهادی مطابق (۶) بهترین بردار ویژگی‌ها جهت طبقه‌بندی تشخیص صرع انتخاب می‌کند.

$$objectiv - function = precision + \frac{\max(numberfeatureremoved)}{numberfeature} \quad (6)$$



$$w(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j k(x_i, x_j) \quad (10)$$

اثر SVM بستگی به انتخاب هسته، پارامترهای هسته، دارد که در این مقاله از تابع هسته RBF برای SVM استفاده شده است چون تابع هسته RBF می‌تواند داده با ابعاد بالا را آنالیز کند.

۳- نتایج

در این بخش، ابتدا معیارهای ارزیابی روش‌های تشخیص بیماری صرع مورد بررسی قرار خواهد گرفت و پس از آن، دیتابیس مورد استفاده معرفی خواهد شد. در نهایت نتایج عملی تشخیص بیماری صرع با روش پیشنهادی و مقایسه آن با روش‌های کلاسیک آخرین زیربخش این قسمت خواهد بود. تمام آزمایشات بر روی کامپیوتر شخصی با نرم‌افزار متلب ۲۰۲۳ انجام شده است.

۳-۱- معیارهای ارزیابی

برای ارزیابی کارایی روش‌های تشخیص بیماری صرع از معیارهای ارزیابی کلاسیک صحت مطابق (۱۱)، حساسیت و ویژگی‌ها مطابق (۱۲) و خصوصیت^۱ مطابق (۱۳) استفاده می‌شود. هر چه مقدار صحت، حساسیت و ویژگی‌ها، ویژگی بیشتر باشد مناسب‌تر است.

$$Acc(\%) = \frac{TP + TN}{TP + FP + TN + FN} \quad (11)$$


$$Se(\%) = \frac{TP}{TP + FN} \quad (12)$$

$$Sp(\%) = \frac{TN}{TN + FP} \quad (13)$$

در (۱۱-۱۳)، مثبت واقعی (TP) و منفی واقعی (TN) به ترتیب تعداد سیگنال‌های EEG به درستی شناسایی شده و تعداد سیگنال‌های EEG به درستی رد شده را برای هر کلاس نشان می‌دهند. همچنین، منفی کاذب (FN) و مثبت کاذب (FP) تعداد سیگنال‌های EEG اشتباه رد شده و سیگنال‌های EEG اشتباه تشخیص داده شده برای هر کلاس هستند.

۳-۲- پایگاه داده

در این مقاله از پایگاه داده دانشگاه بن آلمان استفاده شده است [۳۵]. این پایگاه داده شامل پنج گروه (Z, O, N, F, S) است. هر گروه داده، صد نمونه از سیگنال EEG با طول ۲۳/۶ ثانیه و با نرخ نمونه‌برداری ۱۷۳/۶۱ می‌باشد. این سیگنال‌ها متعلق به دامنه سنی ۶ تا ۴۳ ساله است و از این سیگنال‌ها، آرتیفکت‌هایی چون حرکت عضلات و چشم حذف شده است. گروه Z و O شامل نمونه‌های افراد سالم (غیر صرعی) به ترتیب با چشم‌های باز و چشم‌های بسته می‌باشد. گروه N و F نمونه‌های بیماران در فواصل حملات صرعی می‌باشد. گروه



شکل (۲). تجزیه EEG توسط تبدیل موجک گسسته. (الف) EEG، (ب) تا (و) تجزیه ۵ زیر باند EEG توسط تبدیل موجک گسسته

۲-۵- طبقه بندی

الگوریتم ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است که در این مقاله از آن برای طبقه‌بندی ویژگی‌های انتخابی استفاده می‌شود [۳۴]. مبنای کار طبقه‌بند SVM دسته‌بندی خطی داده‌ها است و در تقسیم داده‌ها سعی می‌شود، خطی انتخاب شود که حاشیه اطمینان بیشتری داشته باشد. تابع جداساز برای SVM دو کلاس، عبارت است از:

$$f(x) = \sum_{i=1}^n y_i a_i k(x, x_i) + b \quad (7)$$

در (۷)، n تعداد نمونه‌های آموزشی، x_i نمونه آموزشی i ام و y_i طبقه صحیح برای نمونه آموزشی i ام است. مقدار y_i برای یکی از کلاس‌ها ۱ و برای کلاس دیگری -۱ در نظر گرفته می‌شود و b مقدار بایاس تابع است. مقادیر a_i ضرایب طبقه‌بند هستند که به همراه b در حین آموزش تعیین می‌شوند. تابع $k(x_1, x_2)$ هسته است که دو نمونه از متوالترین هسته‌هایی که برای SVM استفاده می‌شوند، عبارت‌اند از:

$$k(x_1, x_2, p) = (1 + x_2 \cdot x_1)^p \quad (8)$$

$$k(x_1, x_2, \sigma) = e^{-\frac{\|x_1 - x_2\|^2}{2\sigma^2}} \quad (9)$$

در (۸-۹)، p و σ به ترتیب پارامترهای قابل تنظیم برای هسته‌های چندجمله‌ای و RBF هستند. ضرایب a_i در (۷)، با حل مسائل بهینه‌سازی زیر بدست می‌آیند:

¹ Specificity

S نمونه‌های بیماران در حین حملات صرع می‌باشد که در جدول (۲) مورد‌های متفاوت در نظر گرفته شده است.

۳-۳-۳ نتایج و آزمایش‌ها


برای ارزیابی عملکرد روش پیشنهادی با روش [۳۷]، روش [۳۸]، روش [۳۹]، روش [۴۰] و روش [۴۱]، دو مجموعه آزمایش انجام می‌شود. در مجموعه آزمایش اول، به بررسی تاثیر طول‌های مختلف سیگنال EEG بر روی عملکرد روش پیشنهادی پرداخته می‌شود. در مجموعه دوم، به بررسی عملکرد روش پیشنهادی با روش‌های اخیر پرداخته می‌شود.

۳-۳-۳-۱ تاثیر طول موج‌های مختلف سیگنال EEG

در این آزمایش، تاثیر طول‌های مختلف سیگنال EEG بر روی تشخیص تشنج بررسی می‌شود. طول پنجره به ترتیب ۴۰۹۶، ۲۰۴۸، ۱۰۲۴ و ۵۱۲ تعیین شد و برای هر پنجره، عملکرد روش پیشنهادی مورد ارزیابی قرار گرفت (جدول (۳)). همان‌طور که در جدول (۳) مشاهده می‌شود، با افزایش طول پنجره، صحت، حساسیت و خصوصیت افزایش می‌یابد. همچنین لازم به ذکر است که برای پنجره با طول کوتاه، عملکرد مدل پیشنهادی خوب و قابل قبول می‌باشد.

۳-۳-۳-۲ مقایسه با کارهای اخیر انجام شده

در این بخش، عملکرد روش پیشنهادی با سایر روش‌های کلاسیک مقایسه شد که در جدول (۴) نشان داده شده است که در آن، روش [۳۷] نسبت به روش‌های دیگر عملکرد بهتری دارد. روش [۴۰] نسبت به روش‌های [۳۷]، [۳۸]، [۳۹] و [۴۱] از صحت، حساسیت و خاصیت بهتری برخوردار است که نشان‌دهنده عملکرد مناسب آن در تشخیص صرع می‌باشد اما روش پیشنهادی نسبت به روش [۴۰] و روش‌های دیگر عملکرد بهتری دارد. با توجه به عملکرد روش پیشنهادی پزشکان می‌توانند جهت تشخیص خودکار بیماری صرع از آن استفاده کنند.



شکل (۳): نمونه‌ای از سیگنال EEG به ترتیب مربوط گروه Z تا S

جدول (۲): مورد‌های متفاوت در نظر گرفته شده

مورد	کلاسها	توصیف	نوع
۱	S یا Z		
۲	S یا O	نمونه غیرصرعی و حین تشنج	دو کلاس
۳	S یا ZO		
۴	S یا N	نمونه فاصله بین و حین تشنج ها	دو کلاس
۵	S یا F		
۶	S یا NF		
۷	S یا NZO		دو کلاس
۸	S یا FZO		
۹	S یا ZONF	نمونه حین تشنج	
۱۰	S یا N یا Z		سه کلاس
۱۱	S یا NF یا ZO	نمونه غیرصرع، فاصله بین تشنج‌ها و حین تشنج	
۱۲	F یا N یا O یا Z یا S	کل نمونه ها	پنج کلاس

جدول (۳): ارزیابی روش پیشنهادی با طول متفاوت سیگنال EEG

پنجره	مورد	صحت	حساسیت	خصوصیت
۵۱۲	۱	۱۰۰	۱۰۰	۱۰۰
	۹	۹۹/۳۷	۹۸/۸۹	۹۹/۵۹
	۱۱	۹۹/۳۹	۹۸/۹۷	۹۹/۶۸
	۱۲	۹۸/۹۶	۹۷/۹۸	۹۹/۱۷
۱۰۲۴	۱	۱۰۰	۱۰۰	۱۰۰
	۹	۹۹/۴۵	۹۸/۸۰	۹۹/۶۱
	۱۱	۹۹/۹۱	۹۹/۹۷	۹۹/۸۱
	۱۲	۹۹/۱۲	۹۸/۸۶	۹۹/۳۰
۲۰۴۸	۱	۱۰۰	۱۰۰	۱۰۰
	۹	۹۹/۸۱	۹۹/۴۳	۹۹/۹۴
	۱۱	۹۹/۹۲	۹۹/۹۷	۹۹/۸۰
	۱۲	۹۹/۲۸	۹۹/۰۱	۹۹/۴۱
۴۰۹۶	۱	۱۰۰	۱۰۰	۱۰۰
	۹	۹۹/۷۲	۹۹/۴۲	۹۹/۹۱
	۱۱	۹۹/۹۷	۱۰۰	۹۹/۹۲
	۱۲	۹۹/۴۳	۹۹/۷۵	۹۹/۳۱

جدول (۴): مقایسه روش پیشنهادی با روش‌های دیگر

روش ها	صحت	حساسیت	خصوصیت
روش [۳۷]	۷۹/۸	۸۱/۵	۷۷/۲
روش [۳۸]	۹۳	۹۷	۹۲
روش [۳۹]	۹۸/۴۰	۹۸/۲۲	۹۸/۳۱
روش [۴۰]	۹۹/۳۰	۹۹/۶۴	۹۹/۱۲
روش [۴۱]	۹۶/۲	۹۵/۶۸	۹۸/۷۹
روش پیشنهادی	۹۹/۵۶	۹۹/۸۲	۹۹/۳۱



۴- جمع‌بندی

در این مقاله، سیستم جدیدی برای تشخیص خودکار صرع ارائه شده است. در ابتدا، نویز از سیگنال EEG حذف و سیگنال بخش‌بندی می‌شود. سپس، تبدیل موجک گسسته به تجزیه سیگنال می‌پردازد. پس از آن، ۱۶۵ ویژگی متفاوت از سیگنال EEG خام و سیگنال EEG تجزیه شده استخراج می‌شود. انتخاب بهترین ویژگی‌ها در دقت تشخیص بیماری صرع بسیار موثر می‌باشد، که در این سیستم جدید از الگوریتم فرا ابتکاری عنکبوت اجتماعی و تابع هدف پیشنهادی جهت انتخاب بهترین اطلاعات استفاده می‌شود. در نهایت، برای طبقه‌بندی سیگنال‌های EEG تشنج و غیر تشنج، الگوریتم ماشین بردار پشتیبان به کار گرفته می‌شود. سیستم جدید تشخیص خودکار صرع پیشنهادی را می‌توان پزشکان جهت تشخیص سریع بیماری صرع استفاده کنند. در مطالعات آتی تلاش می‌شود، از این سیستم جدید پیشنهادی در تشخیص آلزایمر به کار گرفته شود.

مراجع

- neural network," Scientific Reports, vol. 13, no. 1, p. 17710, 2023. DOI: 10.1038/s41598-023-44318-w
- [۹] M. Omidvar, A. Zahedi, and H. Bakhshi, "EEG signal processing for epilepsy seizure detection using 5-level Db4 discrete wavelet transform, GA-based feature selection and ANN/SVM classifiers," Journal of ambient intelligence and humanized computing, vol. 12, no. 11, pp. 10395-10403, 2021. DOI: 10.1007/s12652-020-02837-8.
- [۱۰] M. P. Kantipudi, N. P. Kumar, R. Aluvalu, S. Selvarajan, and K. Kotecha, "An improved GBSO-TAENN-based EEG signal classification model for epileptic seizure detection," Scientific Reports, vol. 14, no. 1, p. 843, 2024. DOI: 10.1038/s41598-024-51337-8
- [۱۱] U. R. Acharya, F. Molinari, S. V. Sree, S. Chattopadhyay, K.-H. Ng, and J. S. Suri, "Automated diagnosis of epileptic EEG using entropies," Biomedical Signal Processing and Control, vol. 7, no. 4, pp. 401-408, 2012. DOI: 10.1016/j.bspc.2011.07.007
- [۱۲] D. S. T. Behara, A. Kumar, P. Swami, B. K. Panigrahi, and T. K. Gandhi, "Detection of epileptic seizure patterns in EEG through fragmented feature extraction," in 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), 2016: IEEE, pp. 2539-2542. DOI:10.1109/INDIACom.2016.7563001
- [۱۳] Z. Zhang and K. K. Parhi, "Seizure prediction using long-term fragmented intracranial canine and human EEG recordings," in 2016 50th Asilomar Conference on Signals, Systems and Computers, 2016: IEEE, pp. 361-365. DOI: 10.1109/ACSSC.2016.7869060
- [۱۴] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, and O. Kavehei, "A generalised seizure prediction with convolutional neural networks for intracranial and scalp electroencephalogram data analysis," arXiv preprint arXiv:1707.01976, 2017. DOI: 10.48550/arXiv.1707.01976
- [۱۵] M. Niknazar, S. Mousavi, B. V. Vahdat, and M. Sayyah, "A new framework based on recurrence quantification analysis for epileptic seizure detection," IEEE journal of biomedical and health informatics, vol. 17, no. 3, pp. 572-578, 2013. DOI:10.1109/JBHI.2013.2255132
- [۱۶] N. Sadati, H. R. Mohseni, and A. Maghsoudi, "Epileptic seizure detection using neural fuzzy networks," in 2006 IEEE international conference on fuzzy systems, 2006: IEEE, pp. 596-600, DOI: 10.1109/FUZZY.2006.1681772
- [۱۷] U. Orhan, M. Hekim, and M. Ozer, "EEG signals classification using the K-means clustering and a multilayer perceptron neural network model," Expert Systems with Applications, vol. 38, no. 10, pp. 13475-13481, 2011. DOI: 10.1016/j.eswa.2011.04.149
- [۱۸] A. R. Naghsh-Nilchi and M. Aghashahi, "Epilepsy seizure detection using eigen-system spectral estimation and Multiple Layer Perceptron neural network," Biomedical Signal Processing and Control, vol. 5, no. 2, pp. 147-157, 2010. DOI: 10.1016/j.bspc.2010.01.004
- [۱۹] H. Ocak, "Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm," Signal processing, vol. 88, no. 7, pp. 1858-1867, 2008. DOI: 10.1016/j.sigpro.2008.01.026
- [۱] S. Mekruksavanich, W. Phaphan, and A. Jitpattanakul, "Epileptic seizure detection in EEG signals via an enhanced hybrid CNN with an integrated attention mechanism," Mathematical Biosciences and Engineering, vol. 22, no. 1, pp. 73-105, 2025, DOI: 10.3934/mbe.2025004
- [۲] M. Pouryosef, R. Abedini-Nassab, and S. M. R. Akrami, "A novel framework for epileptic seizure detection using electroencephalogram signals based on the bat feature selection algorithm," Neuroscience, vol. 541, pp. 35-49, 2024, DOI: 10.1016/j.neuroscience.2024.01.014
- [۳] X. Qiu, F. Yan, and H. Liu, "A difference attention ResNet-LSTM network for epileptic seizure detection using EEG signal," Biomedical Signal Processing and Control, vol. 83, p. 104652, 2023, DOI: 10.1016/j.bspc.2023.104652
- [۴] M. Shen, P. Wen, B. Song, and Y. Li, "An EEG based real-time epilepsy seizure detection approach using discrete wavelet transform and machine learning methods," Biomedical Signal Processing and Control, vol. 77, p. 103820, 2022, DOI: 10.1016/j.bspc.2022.103820
- [۵] J. Zhang, S. Zheng, W. Chen, G. Du, Q. Fu, and H. Jiang, "A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction," Scientific Reports, vol. 14, no. 1, p. 16916, 2024, DOI: 10.1038/s41598-024-67855-4
- [۶] H. Ocak, "Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy," Expert Systems with Applications, vol. 36, no. 2, pp. 2027-2036, 2009, DOI: 10.1016/j.eswa.2007.12.065
- [۷] S. Jain, V. V. Gupta, A. S. Bist, M. Joshi, and A. Garg, "Automated Epileptic Seizure Detection of EEG Signals Using Machine Learning," in International Conference on Cognitive Computing and Cyber Physical Systems, 2025: Springer, pp. 349-357. DOI: 10.1007/978-981-97-7371-8_27
- [۸] G. Yogarajan et al., "EEG-based epileptic seizure detection using binary dragonfly algorithm and deep



techniques," in 2016 International Conference on Emerging Technologies (ICET), 2016: IEEE, pp. 1-6 .

DOI:10.1109/ICET.2016.7813209

[۳۲] E. Cuevas, M. Cienfuegos, D. Zaldívar, and M. Pérez-Cisneros, "A swarm optimization algorithm inspired in the behavior of the social-spider," *Expert Systems with Applications*, vol. 40, no. 16, pp. 6374-6384, 2013. DOI: 10.1016/j.eswa.2013.05.041

[۳۳] E. Cuevas and M. Cienfuegos, "A new algorithm inspired in the behavior of the social-spider for constrained optimization," *Expert Systems with Applications*, vol. 41, no. 2, pp. 412-425, 2014. DOI: 10.1016/j.eswa.2013.07.067

[۳۴] C. J. Burges, "A tutorial on support vector machines for pattern recognition," *Data mining and knowledge discovery*, vol. 2, no. 2, pp. 121-167, 1998. doi: 10.1023/A:1009715923555

[۳۵] M. K. Siddiqui, R. Morales-Menendez, X. Huang, and N. Hussain, "A review of epileptic seizure detection using machine learning classifiers," *Brain informatics*, vol. 7, no. 1, p. 5.۲۰۲۰, DOI:10.1186/s40708-020-00105-1

[۳۶] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, "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*, vol. 64, no. 6, p. 061907, 2001. DOI: 10.1103/PhysRevE.64.061907

[۳۷] T. Zhang, W. Chen, and M. Li, "Generalized Stockwell transform and SVD-based epileptic seizure detection in EEG using random forest," *Biocybernetics and Biomedical Engineering*, vol. 38, no. 3, pp. 519-534, 2018. DOI:10.1016/j.bbe.2018.03.007

[۳۸] M. Mahmud, M. S. Kaiser, A. Hussain, and S. Vassanelli, "Applications of deep learning and reinforcement learning to biological data," *IEEE transactions on neural networks and learning systems*, vol. 29, no. 6, pp. 2063-2079, 2018. DOI: 10.1109/TNNLS.2018.2790388

[۳۹] E. Aydemir, T. Tuncer, and S. Dogan, "A Tunable-Q wavelet transform and quadruple symmetric pattern based EEG signal classification method," *Medical hypotheses*, vol. 134, p. 109519, 2020. DOI: 10.1016/j.mehy.2019.109519

[۴۰] T. Iloin, R. Barati, and H. Azad, "A New Approach in Epilepsy Diagnosis using Discrete Wavelet Transformation and Analysis of Variance," *Signal Processing and Renewable Energy*, vol. 7, no. 3, pp. 1-11, 2023. <https://oiccpres.com/spre/article/view/7894>

[41] ف. قره‌داغی س. مشگینی, "تشخیص حمله‌های صرعی از روی ضرایب موجک با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی انبوه ذرات (PSO)," *هوش محاسباتی در مهندسی برق*, vol. 10, no. 3, pp. 11-24, 2019, doi: 10.22108/isee.2019.116284.1207

[۲۰] A. Jain and D. Zongker, "Feature selection: Evaluation, application, and small sample performance," *IEEE transactions on pattern analysis and machine intelligence*, vol. 19, no. 2, pp. 153-158, 1997. DOI: 10.1109/34.574797

[۲۱] S. Mousavi, M. Niknazar, and B. V. Vahdat, "Epileptic seizure detection using AR model on EEG signals," in 2008 Cairo International Biomedical Engineering Conference, 2008: IEEE, pp. 1-4 . DOI:10.1109/CIBEC.2008.4786067

[۲۲] L. Wang et al., "Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis ", *Entropy*, vol. 19, no. 6, p. 222, 2017. DOI: 10.3390/e19060222

[۲۳] A. Hamad, E. H. Houssein, A. E. Hassanien, and A. A. Fahmy, "A hybrid EEG signals classification approach based on grey wolf optimizer enhanced SVMs for epileptic detection," in *Proceedings of the international conference on advanced intelligent systems and informatics 2017*, 2018: Springer, pp. 108-117 . DOI: 10.1007/978-3-319-64861-3_10

[۲۴] Z. Hossein-Nejad and M. Nasri, "Epileptic Seizure Detection based on Statistical and Wavelet Features and Siamese Network," in 2023 14th International Conference on Information and Knowledge Technology (IKT), 2023: IEEE, pp. 201-205 . DOI:10.1109/IKT62039.2023.10433025

[۲۵] P. Mallik, A. K. Nayak, S. K. Mohapatra, and K. Swain, "Effectiveness of SOSA, FFA and GOA Algorithms for Epileptic Seizure Detection Using DWT and SVM," in *Computing, Communication and Intelligence: CRC Press*, 2025, pp. 52-56. DOI:10.1201/9781003581215-11

[۲۶] Z. Hossein, "Social Spider Optimization Algorithm in Multimodal Medical Image Registration," *Journal of Optimization of Soft Computing (JOSC)*, vol. 1, no. 1, pp. 23-30, 2023. <https://www.researchgate.net/publication/375279624>

[۲۷] A. Luque-Chang, E. Cuevas, F. Fausto, D. Zaldívar, and M. Pérez, "Social spider optimization algorithm: modifications, applications, and perspectives," *Mathematical Problems in Engineering*, vol. 2018, no. 1, p. 6843923, 2018. DOI: 10.1155/2018/6843923

[۲۸] R. Vijay and V. Priya, "Anti-islanding protection of distributed generation based on social spider optimization technique," *International Journal of Advanced Engineering Research and Science*, vol. 4, no. 6, p. 237193, 2017. DOI: 10.22161/ijaers.4.6.5

[۲۹] U. R. Acharya et al., "Characterization of focal EEG signals :a review," *Future Generation Computer Systems*, vol. 91, pp. 290-299, 2019. DOI: 10.1016/j.future.2018.08.044

[۳۰] P. Boonyakitanont, A. Lek-Uthai, K. Chomtho, and J. Songsiri, "A review of feature extraction and performance evaluation in epileptic seizure detection using EEG," *Biomedical Signal Processing and Control*, vol. 57, p. 101702, 2020. DOI: 10.1016/j.bspc.2019.101702

[۳۱] M. Ahmad, M. Saeed, S. Saleem, and A. M. Kamboh, "Seizure detection using EEG: A survey of different

