

## Research Paper

# A Method for Epileptic Seizure Detection in EEG Signals Based on Tunable Q-Factor Wavelet Transform Method Using Grasshopper Optimization Algorithm With Support Vector Machine Classifier



Anis Malekzadeh<sup>1</sup> , \*Assef Zare<sup>1</sup> , Mahdi Yaghoubi<sup>2</sup> , Roohallah Alizadehsani<sup>3</sup>

1. Department of Electrical Engineering, Faculty of Electrical Engineering, Gonabad Branch, Islamic Azad University, Gonabad, Iran.
2. Department of Electrical Engineering, Faculty of Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran.
3. Institute for Intelligent Systems Research and Innovation (IISRI), Deakin University, Geelong, Australia.



**Citation** Malekzadeh A, Zare A, Yaghoubi M, Alizadehsani R. [A Method for Epileptic Seizure Detection in EEG Signals based on Tunable Q-Factor Wavelet Transform Method Using Grasshopper Optimization Algorithm With Support Vector Machine Classifier (Persian)]. *Internal Medicine Today*. 2022; 28(1):98-127. <https://doi.org/10.32598/hms.28.1.3707.1>

<https://doi.org/10.32598/hms.28.1.3707.1>



Received: 18 Sep 2021  
Accepted: 04 Dec 2021  
Available Online: 01 Jan 2022

### Key words:

Epileptic seizures, Electroencephalography, Feature extraction, Grasshopper optimization algorithm, Support vector machine

## ABSTRACT

**Aims** Epilepsy is a brain disorder disease that affects people's quality of life. If it is detected at an early stage, seizures will not spread from the initial area. Electroencephalography (EEG) signals are used to diagnose epileptic seizures. However, this method cannot diagnose the state of epileptic seizure precisely. With the help of the Computer-Aided Diagnosis (CAD) system, neurologists can diagnose epileptic seizure stages correctly.

This study aims to present a novel method for epileptic seizures detection in EEG signals.

**Methods & Materials** The Bonn dataset was used in this study with available EEG signals divided into 5-second windows. Then, the Tunable Q-Factor Wavelet Transform (TQWT) was utilized to decompose the segmented EEG signals into various sub-bands. Several statistical and nonlinear features based on fractal dimension and entropy algorithms were extracted from the TQWT sub-bands. Then, the Autoencoder (AE) method with 7 layers was applied to reduce the number of features. Finally, the Support Vector Machine (SVM) and Grasshopper Optimization Algorithm with SVM classifier (GOA/SVM) were used for their classification compared to the K-Nearest Neighbors and Random Forest algorithms. The employment of AE for feature reduction and GOA/SVM for classification are the novelties of this study.

**Findings** The proposed method demonstrated better performance compared to other methods used in different studies. The GOA/SVM classification method had a high accuracy rate of 99.42% and 99.23% for two-class and multi-class classification problems, respectively.

**Conclusion** The combination of EEG feature classification methods increases the accuracy of the CAD system in diagnosing epileptic seizures. The method proposed in this study using different methods for extracting features and their classification has high accuracy for epileptic seizures detection.

## Extended Abstract

### Introduction

# E

pilepsy is a chronic noncommunicable neurological disorder which can affect people at any age [1]. It is a common brain

disease and approximately 50 million people worldwide are suffering from it. Eighty percent of patients with this disease live in low- or middle-income countries. Seventy percent of these patients can have a seizure-free life if treated and diagnosed properly. The risk of premature death is three times higher in these patients than in general population. Three quarters of epilepsy patients dwelling in developing coun-

### \* Corresponding Author:

Assef Zare, PhD.

Address: Department of Electrical Engineering, Faculty of Electrical Engineering, Gonabad Branch, Islamic Azad University, Gonabad, Iran.

Tel: +98 (915) 5331091

E-mail: assefzare@gmail.com

tries cannot afford to receive treatment [2]. These patients and their families suffer from discrimination and stigma. Generalized-onset and focal-onset seizures are two types of epilepsy [3]. Focal epilepsy affects one area of the brain. It is important to locate that area of the brain for proper medical attention. It is estimated that 60% of patients with focal epilepsy and 20% of those with generalized epilepsy become resistant to drugs and need surgery [4].

Various methods for epileptic seizure detection have been provided so far, including clinical methods and neuroimaging modalities; the latter are widely used by physicians [1-2]. Generally, neuroimaging modalities are categorized into functional and structural modalities [1-3]. Electroencephalography (EEG) is a functional neuroimaging modality for epileptic seizure detection [1-2]. EEG signals provide essential information from the affected area which helps physicians to detect epileptic seizures with a higher accuracy [1-3]. The diagnosis of epileptic seizures by EEG signals is a challenging task for physicians [1-2]. The EEG signals are accompanied by relatively high complexity, which makes it difficult or challenging to correctly diagnose epileptic seizures [1-2]. Accordingly, researchers have attempted to use Artificial Intelligence (AI) including Machine Learning (ML) [4-6] and Deep Learning (DL) [7, 8] to diagnose epileptic seizures early via EEG signals. In ML-based Computer-Aided Diagnosis (CAD) system, the feature extraction techniques include time [9], frequency [10], time-frequency [11], and non-linear methods [12]. In DL-based CAD system, the methods for epileptic seizures detection include Autoencoders (AEs) [13, 14], Recurrent Neural Networks (RNNs) [15, 16], Convolutional Neural Networks (CNNs) [17, 18], and Deep Belief Networks (DBNs) [19].

Abedin et al. [45] provided an epileptic seizure detection method based on statistical features and achieved promising results. They first used a Bonn dataset and Discrete Wavelet Transform (DWT) method to preprocess and analyze EEG signals based on different sub-bands. Then, each DWT sub-band was examined to extract some statistical properties, and Artificial Neural Network (ANN) was employed for data classification. Singh et al. [48] proposed a new method for epileptic seizure detection from Bonn EEG dataset. They used Complete Ensemble Empirical Mode Decomposition (CEEMD) and Refined Composite Multiscale Dispersion Entropy (RCMDE) methods to conduct preprocessing and extract properties, and tested various methods for feature selection to reduce the size of the feature matrix. Finally, the ANN classifier technique was applied which led to promising outcomes. Aliyu et al. [49] presented an epileptic seizure detection method by selecting optimal wavelet transforms. To analyze EEG data, DWT

was used to break them down into multiple sub-bands and extract various statistical information from each one. As a result, Correlation Coefficient and P-value (CCP) feature and Principal Component Analysis (PCA) were used to minimize the specificity. A Long Short-Term Memory (LSTM) model with the proposed layers was applied to categorize the inputs, resulted in 99% accuracy. Sameer and Gupta [50] considered Haralick texture features to present a method for detecting epileptic seizures from EEG signals, converted to two-dimensional images using Short-Time Fourier Transform (STFT) to extract Haralick texture features. Finally, the Decision Tree (DT) method was applied for categorization. The results reported 92.50% accuracy. Qureshi et al. [51] utilized Fractal Dimension (FD) and graph theories for feature extraction and used Electroconvulsive Therapy (ECT) for EEG signals pre-processing as the first stage of the study. Then, they extracted graph theory and FD-based features from EEG signals. Finally, they applied the Radio-Frequency (RF) method for classification and reached 98.50% accuracy.

The current study provides a novel method based on the extraction of statistical and non-linear features, feature reduction, and classification by the Grasshopper Optimization Algorithm and Support Vector Machines (GOA/SVM) model. The Bonn EEG dataset was used for epileptic seizures detection. **Figure 1** illustrates the proposed method for epileptic seizure detection from EEG signals. Various wavelet transformations has been employed in different studies. The Tunable Q-Factor Wavelet Transform (TQWT) approach is one of the best methods for EEG signals pre-processing [20], which is more efficient than DWT for preprocessing and analyzing EEG signals based on different frequency subbands. We used the TQWT for preprocessing of EEG signals. Analyzing EEG signals by the TQWT method can improve the accuracy of epileptic seizure detection. Various statistical and nonlinear features of EEG signals were extracted in the next stage. The AE model with the proposed layers was used to reduce the number of features which is a novel technique used in this study. The second novelty of this study is the use of the GOA combined with the SVM classifier. The GOA has not been used so far for epileptic seizure detection along with SVM. The GOA improves gradient optimization in terms of speed and performance. Gradient optimization algorithms are usually slow, and the selection of wrong parameters can lead to inefficiency. Moreover, these methods are not efficient for all problems. Thus, metaheuristic algorithms, such as genetic algorithm [53], particle swarm optimization [54], and breeding swarm [55] are applied for optimizing the classification algorithms. This paper is structured as following: Section 2 presents the methodology; the statistical

metrics are presented In section 3; the results are shown in Section 4, and conclusions are presented in Section 5.

## 2. Material and Methods

In this section, the proposed method for epileptic seizures detection in EEG signals is presented at following steps: Data selection, preprocessing, feature extraction, feature reduction, and classification.

### Data selection

The Bonn dataset was used in this study which has been recorded at the University of Bonn by a group of researchers and it had been widely used for epileptic seizure analysis and detection [22]. Bonn dataset is a publicly available dataset containing 500 single-channel EEG data. It was sampled at 173.6 Hz for 23.6 seconds. They consisted of five classes' viz. S, F, N, O, and Z with 100 segments recordings in each class [22]. The O and Z data were collected from 5 healthy controls in a relaxed position and awake state and using the 10-20 electrode placement standard. Intracranial electrodes were used on 5 patients with epilepsy to collect data of S, F and N classes. The epileptogenic zone and the opposite hemisphere were used for recording the signals of F and S classes, respectively during interictal period. Ictal period was taken into account for recording the signals of class S. Cutoff frequencies in the range of 0.53-40 Hz were applied with finite impulse response and 20 order band-pass filter for filtering of EEG data [22]. Figure 2 shows the EEG signals of the Bonn dataset. Other information about this database are presented in Tables 1 and 2.

### Preprocessing

For pre-processing of the EEG signals, the TQWT was used. It is a special type of DWT and is used in biomedical signal studies [20]. In TQWT, parameters include the redundancy, number of decomposition levels and Q-factor. Oscillatory signals are analyzed using higher Q-factors and transients are analyzed with lower Q-factors. The two-channel filter bank is applied for implementing TQWT. Low- and high-pass scale factors for this filter banks are represented by  $\gamma$  and  $\delta$ . The mathematical expression for the frequency response to low-pass filter and high-pass filter are presented in Equations 1 and 2, respectively [20]:

$$1) T0(\omega) = \begin{cases} 1, & \text{if } |\omega| \leq (1-\delta)\pi \\ \theta \left( \frac{\omega + (\delta-1)\pi}{\gamma + \delta - 1} \right), & \text{if } (1-\delta)\pi < |\omega| < \gamma\pi \\ 0, & \text{if } \gamma\pi \leq |\omega| \leq \pi \end{cases}$$

$$2) T1(\omega) = \begin{cases} 0, & \text{if } |\omega| \leq (1-\delta)\pi \\ \theta \left( \frac{\gamma\pi - \omega}{\gamma + \delta - 1} \right), & \text{if } (1-\delta)\pi < |\omega| < \gamma\pi \\ 1, & \text{if } \gamma\pi \leq |\omega| \leq \pi \end{cases}$$

For further information regarding the TQWT, see reference [20]. The TQWT parameters were selected similar to those reported in Ghassemi et al.'s study [34] (Q= 1, r= 3, and J= 8). In Figure 3, the TQWT sub-bands are illustrated based on the defined parameters. The TQWT frequency response is shown in Figure 4.

### Feature extraction

In this section, we presented different feature extraction methods for epileptic seizures detection. First, the TQWT was used for EEG signals decomposition. Different features such as statistical features, non-linear features based on FD method and non-linear features based on entropy algorithms were extracted from the TQWT sub-bands.

#### Statistical features

Five statistical features were extracted from the TQWT subbands [23] presented in Table 3.

#### FD-based features

The FD-based non-linear features provide significantly important information regarding EEG signals. The EEG signals have chaotic behavior; the non-linear methods such as FD technique can extract important information from EEG data. The non-linear features extracted from the TQWT sub-bands based on FD method were Katz, Higuchi, and Petrosian, and Hurst exponent.

#### Higuchi's method

Consider  $x(1), x(2), \dots, x(N)$  as the time sequence that should be examined. Create  $k$  new time series  $x_m^k$  defined by [12]:

$$3) x_m^k = \{x(m), x(m+k), x(m+2k), \dots, x(m + \lfloor \frac{N-m}{k} \rfloor k)\}, \text{ for } m=1, 2, \dots, k$$

, where  $[a]$  indicates integer part of  $a$ ,  $k$  shows the discrete time interval between points, and  $m$  indicates the initial time value. For each created time series, the mean length  $L_m(k)$  is defined as [25]:

$$4) L_m(k) = \frac{\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)|}{\lfloor \frac{N-m}{k} \rfloor}$$

An average length  $k$  is computed for all time series with the same delay  $k$  as the mean of  $k$  length  $L_m(k)$  for  $m=1, \dots, k$ . For each  $k$  ranging from 1 to  $k_{max}$ , the procedure is re-

peated producing a sum of average length  $L(k)$  for each  $k$  as indicated below [12]:

$$5) L(k) = \sum_k^{m=1} L_m(k)$$

The total average length for scale  $k$ ,  $L(k)$  is proportional to  $k$ -D, where  $D$  is the FD by Higuchi method [12].

#### Katz's method

The FD of a curve based on Katz's method is defined as [12]:

$$6) D = \frac{\log_{10}(d)}{\log_{10}(L)}$$

where  $d$  is the estimated diameter as the distance between the first point of the sequence and the points of sequence that provides the farthest distance, and  $L$  is the total length of the curve.  $d$  can be expressed mathematically as [12]:

$$7) d = \max(\text{distance}(1, i))$$

where  $i$  is the one that maximizes the distance with respect to the first point. The use of measurement units depends on the computed FDs which are different if the units are different. Katz's approach tries to solve the problem by creating a general unit: the average distance between successive points  $a$ . Normalizing distances by this method can lead to [25]:

$$8) D = \frac{\log_{10}(L/a)}{\log_{10}(d/a)}$$

If  $n = L/a$ , where  $n$  is the number of steps in the curve, the above equation can be written as Equation 9 which summarizes the Katz's approach for measuring DF of a EEG signal [12].

$$9) D = \frac{\log_{10}(n)}{\log_{10}(d/L) + \log_{10}(n)}$$

#### Petrosian method

The FD based on Petrosian method is defined as follows [12]:

$$10) D = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left( \frac{n}{n + 0.4 N_{\Delta}} \right)}$$

where  $N_{\Delta}$  is the number of dissimilar pairs and  $n$  is the length of the sequence in the generated binary sequence [12].

#### Hurst Exponent

The equation of Hurst Exponent (HE) is as follows [26]:

$$11) HE = \frac{\log_{10}(RS)}{\log(T)}$$

where  $S$  is the standard deviation,  $T$  is the duration of sample data and  $R$  represents the difference between the minimum and maximum deviation from the mean.

#### Entropy features

Different entropy algorithms were used to extract the features of EEG signals

#### Shannon entropy

Shannon entropy is a fundamental entropy technique for feature extraction in EEG signals [26]. It is defined as follows:

$$12) H(X) = -\sum_{i=0}^{N-1} P_i \log^2 P_i$$

where  $P_i$  is the probability of occurrence of  $i$ -th symbol.

#### Log Energy entropy

The log energy entropy can be defined as [26]:

$$13) E_{Log} = \sum_{i=0}^K \log(E_i^2)$$

where  $K$  and denote the length of the EEG signal and  $i$ th sample of the EEG signal, respectively.

#### Sample entropy

The sample entropy is defined as [26]:

$$14) SampEn = -\log(A/B)$$

Where  $A$  refers to the total number of vector pairs of length  $m + 1$ , and  $B$  shows the total number of vector pairs of length  $m$ .

#### Tsallis entropy

The tsallis entropy is defined as [26]:

$$15) E_{ts} = -(1 - \sum_{n=1}^x E_n^{\alpha}) / \alpha$$

where the probability of occurrence is shown by  $E_n$ , and  $P_n$  is the feature value of the feature  $P$  that has the range of values from  $P_1$  to  $P_x$  [26].

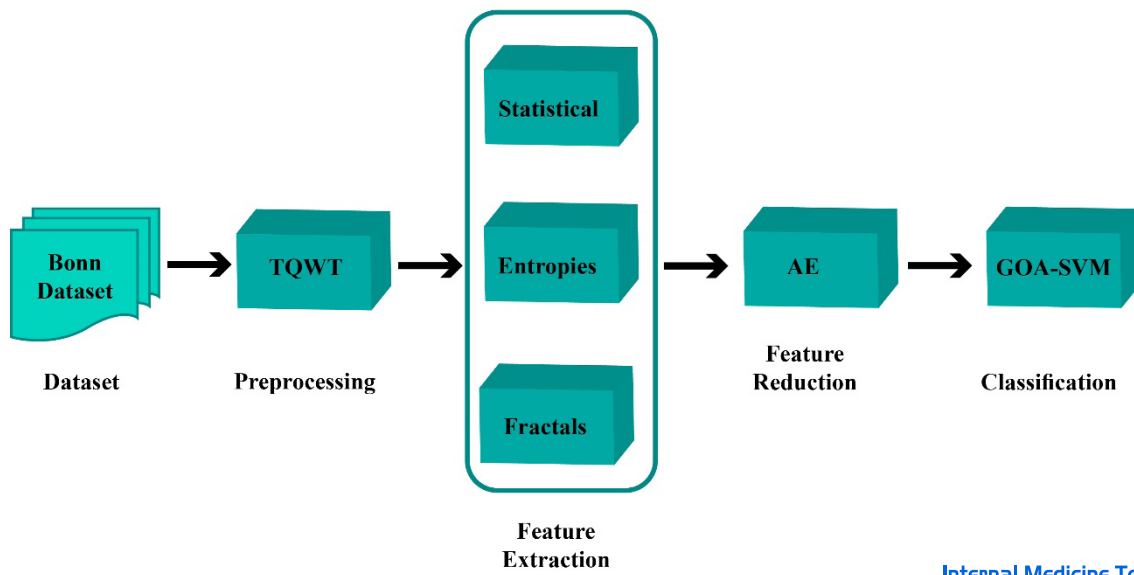


Figure 1. Proposed method for epileptic seizure detection

Internal Medicine Today

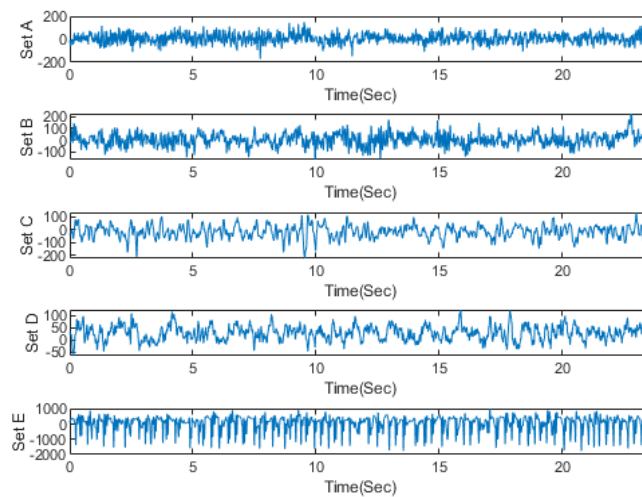


Figure 2. Exemplary EEG signals from the Bonn dataset of five samples

Internal Medicine Today

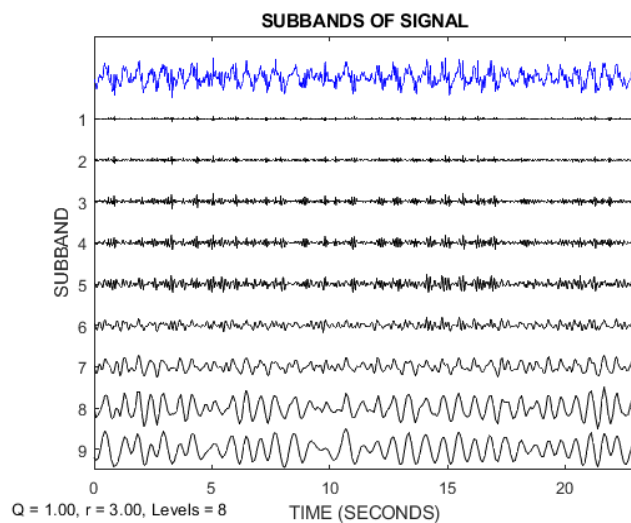


Figure 3. EEG sub-bands using TQWT

Internal Medicine Today

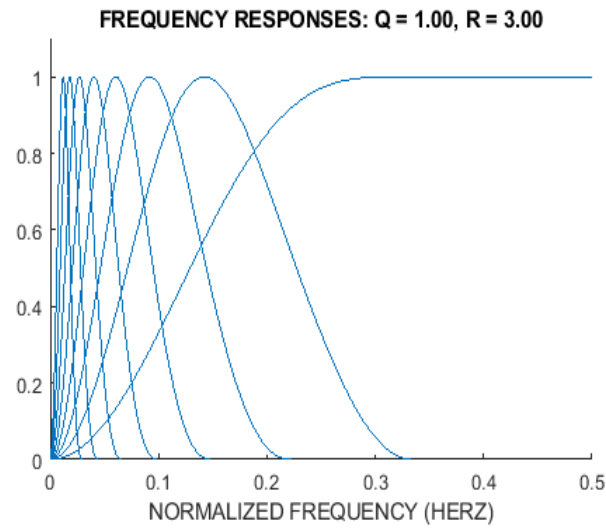


Figure 4. Frequency response for TQWT

Internal Medicine Today




Figure 5. Proposed AE for feature reduction

Internal Medicine Today

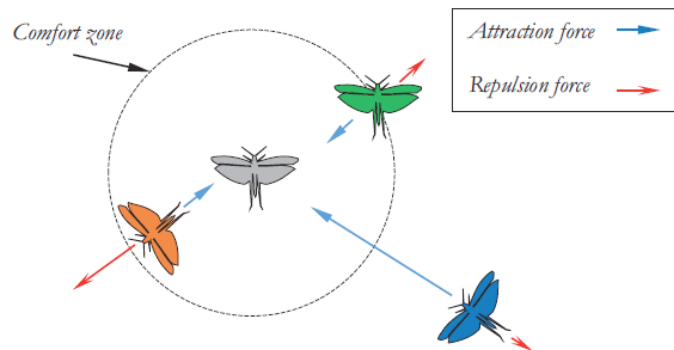


Figure 6. Primitive corrective patterns between individuals in a swarm of grasshoppers [21]

Internal Medicine Today

### Fuzzy entropy

For a time series  $x(i), i=\{1, \dots, N\}$ , standard fuzzy entropy or FuzzyEn [27] establishes vector sequences  $\{X_{im}, i=1, \dots, N-m+1\}$  as defined below [26]:

$$16) X_i^m = \{x(i), x(i+1), \dots, x(i+m-1)\} - x_0(i)$$

Where the length of sequences is denoted by  $m$ , and  $x_0(i)$  is a baseline.  $\mu$  is the similarity degree using fuzzy membership function for the vector and replacing the Heaviside function [26].

$$17) \mu(d_{ij}^m, n, r) = e^{-\frac{(d_{ij}^m)^n}{r}}$$

where  $r$  and  $n$  are predefined gradient and width of the exponential function, and  $D_{ij}^m$  is the maximum absolute difference between  $X_i^m$  and  $X_j^m$ .  $\varnothing^m$  function is defined as follow [26]:

$$18) \varnothing^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left( \frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right)$$

The sequences  $\{X_i^{(m+1)}\}$  is generated by  $m \leftarrow m+1$  setting  $m \leftarrow m+1$  and  $\varnothing^{(m+1)}(n, r)$  is constructed afterwards. Time series  $x(i)$  for input for FuzzyEn is generated  $\varnothing^{(m+1)}(n, r)$  deviated from  $\varnothing^{(m+1)}(n, r)$  as given below [26]:

$$19) \text{FuzzyEn}(m, n, t, N) = \ln \varnothing^m(n, r) - \ln \varnothing^{(m+1)}(n, r)$$

### Recurrence entropy

The recurrence entropy is defined as follow [26]:

$$20) E^{re} = - \sum_{n=n_{min}}^N R(n) \ln[R(n)]$$

Where  $R(n)$  is the frequency distribution of the diagonal lines with length  $n$  [26].

### Spectral entropy

The Spectral Entropy (SEN) is defined as [26]:

$$21) SEN = \sum_f p_f \log\left(\frac{1}{p_f}\right)$$

### Graph entropy

The graph theory-based entropy is defined as follows [27]:

$$22) H_n(m) = - \frac{\ln(m!)}{\left(\sum_{i=1}^{m!} p(\pi_i) \log(p(\pi_i))\right)}$$

$$23) H_n(m) = - \frac{\ln(m!)}{\left(\sum_{i=1}^{m!} p(\pi_i) \log(p(\pi_i))\right)}$$

### Feature reduction

Feature reduction is one of the important steps for disease diagnosis in the CAD system. The main goal of feature reduction is to apply important features to the inputs of classification algorithms [28]. This increases the classification speed and the accuracy of inputs [28]. Feature reduction is performed regularly with conventional ML and DL techniques. In this study, an AE model with 7 layers was used for feature reduction. Contrary to conventional techniques such as PCA, the feature reduction by AE method has higher performance [28]. Figure 5 shows the AE model with proposed layers. By this method, the number of features was reduced from 153 to 32.

### Classification

#### Support Vector Machine

SVM is one of the prominent classifiers used in ML. It creates an optimal margin hyperplane in the feature space that maximizes the margin between the nearest data points of each class and hyperplane. For linearly inseparable data, kernel functions are used to map the samples into a higher dimensional feature space where the data become linearly separable [29]. In this study, we used the GOA combined with the SVM classifier.

#### GOA algorithm

SVM is one of the most popular classification methods. By optimizing the important parameters of this method, including its kernels, the accuracy of the CAD system for diagnosing epilepsy can be improved. In this study we used the GOA algorithm for the optimization of SVM classification method. The model applied to simulate the behavior and movement of grasshoppers is defined as follows [21]:

$$24) mXi(t+1) = SI(t) + Gi(t) + Ai(t),$$

$$i=1, 2, \dots, nPop \quad t=1, 2, \dots, tMax$$

where,  $i$  is the position of the  $i$ -th grasshopper at the  $t$ -th iteration,  $SI$  is the social interaction of the  $i$ -th grasshopper at the  $t$ -th iteration shows the gravity force on the  $i$ -th grasshopper at the  $t$ -th iteration and  $Ai$  indicates the wind advection on the  $i$ -th grasshopper at the  $t$ -th iteration

The social interaction of grasshopper is defined as [21]:

$$25) S_i = \sum_{j=1, j \neq i}^{nPop} s(d_{ij}) d_{ij}$$

$d_{ij}$ : The distance between the  $i$ -th and the  $j$ -th grasshopper, computed as  $d_{ij} = |x(i) - x(j)|$

**Table 1.** Five subsets of Bonn dataset

Sets	Subjects			
	Patient Stage	Num. of Cases	Num. of Data	Length of Segments
Set A	Eye Open	5	100	4097
Set B	Eye Close	5	100	4097
Set C	Seizure Free	5	100	4097
Set D	Seizure Free	5	100	4097
Set E	Seizure Activity	5	100	4097

Internal Medicine Today

**Table 2.** Six classification problems

Row	Classification	Descriptions
1	A-E	Healthy Control-Ictal
2	B-E	Healthy Control-Ictal
3	C-E	Interictal-Ictal
4	D-E	Interictal-Ictal
5	ABCD-E	Normal-Seizure
6	AB-CD-E	Healthy Control-Interictal-Seizure

Internal Medicine Today

**Table 3.** Statistical features extracted from TQWT sub-bands

Feature Name	Equations
Mean	$X_{mean} = \frac{1}{n} \sum_{i=1}^n x_i$
Variance (Var)	$X_{var} = \frac{\sum_{i=1}^N x_i (x_i - AM)}{N-1}$
Kurtosis (Kur)	$X_{ku} = \frac{\sum_{i=1}^N x_i (x_i - AM)^4}{(N-1)SD^4}$
Skewness (Skw)	$X_{ske} = \frac{\sum_{i=1}^N x_i (x_i - AM)^3}{(N-1)SD^3}$
Standard Deviation (STD)	$X_{ske} = \sqrt{\frac{\sum_{i=1}^N x_i (x_i - AM)^2}{N-1}}$

Internal Medicine Today



**Table 4.** Results For different classifiers

Methods	Sets	Window	Accuracy	Precision	Specificity	Sensitivity	F1-Score
Standard SVM	A-E	5	98.50	98.50	98.50	98.50	98.00
	B-E		99.42	99.16	99.25	99.46	99.23
	C-E		99.25	98.76	98.75	99.65	99.25
	D-E		99.37	99.13	98.96	99.03	99.18
	ABCD-E		99.21	99.23	99.25	99.15	99.16
	AB-CD-E		99.11	99.08	98.96	99.08	99.19
GOA/SVM	A-E	5	99.57	99.78	99.98	99.94	99.27
	B-E		99.41	99.86	98.75	99.83	99.32
	C-E		99.38	99.71	99.68	99.43	99.51
	D-E		99.42	99.86	99.52	99.62	99.37
	ABCD-E		99.34	99.28	99.55	99.28	99.42
	AB-CD-E		99.23	99.29	99.07	99.42	99.30
KNN (K=3)	A-E	5	98.62	97.32	97.54	97.79	97.43
	B-E		98.37	98.25	98.31	98.49	98.37
	C-E		97.62	97.37	97.24	98.03	97.62
	D-E		98.87	98.13	98.37	98.23	98.77
	ABCD-E		97.91	97.62	97.87	97.66	97.52
	AB-CD-E		97.04	96.93	97.17	97.23	97.14
RF	A-E	5	99.71	99.62	99.59	99.63	99.52
	B-E		99.31	98.69	98.59	99.71	99.14
	C-E		99.28	99.27	99.16	99.17	99.22
	D-E		99.18	99.15	99.09	99.29	99.21
	ABCD-E		99.32	99.28	99.11	99.22	99.46
	AB-CD-E		99.08	99.13	99.06	99.29	99.31

$\hat{d}_{ij}$ : A unit vector from the  $i$ -th grasshopper to the  $j$ -th grasshopper, calculated as  $\hat{d}_{ij} = \frac{x(i)-x(j)}{d_{ij}}$

S: A function to define the strength of social forces which is explained as follows:

$$26) s(d) = fe^{\frac{d}{l}} - e^{-d}$$

where  $f$  is an indicator of the attraction intensity, and  $l$  is the attractive length scale. The  $s$  function demonstrates the impact of social interactions (repulsion and attraction) of grasshoppers. **Figure 6** shows the primitive corrective patterns between individuals in a swarm of grasshoppers [21].

**Table 5.** Comparison of the proposed method with other methods used in different studies

Reference	Methods	Accuracy (%)	
		Two Classes	Multi Classes
[34]	TQWT Preprocessing + Npn-Linear and Statistical Features + Ensemble Learning classifier	100	98
[35]	TQWT Preprocessing + CLP features + RF classifier	99	--
[36]	TQWT Preprocessing + Different Non-linear Features + Firefly Optimization feature selection + RF Classifier	97	--
[37]	EMD – TQWT Preprocessing + IP Feature Extraction + LS-SVM Classifier	99	--
[38]	TQWT Preprocessing + CCE Feature Extraction + Different Classifiers	98.30	98.20
[39]	STFT Preprocessing + Spectrum Energy Feature Extraction + Different Classifiers	95.56	--
[40]	DWT Preprocessing + Dynamic Feature Extraction Methods + FSFS Feature Selection + LS-SVM Classifier	99.50	--
[41]	LSP Preprocessing + NCA Feature Extraction + SVM Classifier	99.10	96.50
[42]	FBSE Preprocessing + WMRPE Feature Extraction + RF Classifier	98.93	--
[43]	Matrix Determinant Based Feature Extraction + MLP Classifier	96.94	95.97
[44]	IMFs Preprocessing + AmE Feature Extraction + DESA Feature Selection + RF Classifier	97.97	98.00
[45]	DWT Preprocessing + Statistical Features + ANN Classifier	--	97.33
[46]	DWT Preprocessing + Different Linear and Non-Linear Features + RF Classifier	95.60	--
[47]	CEEMD Preprocessing + RCMDE Feature + Different Feature Selection Methods + ANN Classifier	99.00	98.97
[48]	WPD Preprocessing + Energy and ApEn Features + E-LPP Feature Selection + LS-SVM Classifier	99.50	--
[49]	DWT Preprocessing + Statistical Features + CCP and PCA Feature Reduction + LSTM Classifier	99.00	--
[50]	STFT Preprocessing + Haralick's Texture Feature from Beta Sub-Band + DT Classifier	92.50	--
[51]	ECT Preprocessing + Graph Theory and FD Features + RF Classifier	98.50	--
[52]	Clustering and Covariance Matrix Preprocessing + Statistical Features + Non-Parametric Tests Feature Selection + AB-LS-SVM Classifier	99.00	--
Proposed Method	TQWT Preprocessing + Different Features + AE Feature Reduction + GOA/SVM Classifier	99.42	99.23

The gravity force on the  $i$ -th grasshopper is defined as follows, where  $g$  is the gravity force and represents a unity vector towards the center of earth.

$$27) G_i = -ge_g$$

The wind advection on the  $i$ -th grasshopper is calculated as follows, where  $u$  is the constant drift and is the unit vector of the wind [21]:

$$28) A_i = -ue_w$$

Now, according to the employed definitions, we can expand the Equation 24 as follows [21]:

$$29) X_i = \sum_{j=1}^{nPop} s(|x(i)-x(j)|) \frac{x(i)-x(j)}{d_{ij}} - ge_g - ue_w$$

The Equation 29 cannot be used in the optimization since it prevents the algorithm from exploring and exploiting decently in the search space around a solution. The second reason is that this equation is for outdoor modeling. To modify the Equation 29 and provide a functional model of the GOA algorithm to update the location of each grasshopper, we rewrite it as follows [21]:

$$30) X_i = \sum_{j=1}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_i(t) - x_j(t)}{d_{ij}(t)} + T_d(t)$$

Where,  $ub_d$  is the upper bound in the D-th dimension,  $lb_d$  is the lower bound in the D-th dimension, and  $x_j(t)$  is the value of the D-th the dimension in the target, and  $c$  is a decreasing coefficient [21]. Equation 31 defines the next position of the grasshopper [21]:

$$31) X_i = \sum_{j=1}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_j(t) - x_i(t)}{d_{ij}(t)} + T_d(t)$$

where,  $X_i$  is the next position of the grasshopper  $i$ ,  $x_i(t)$  is the current position of the grasshopper  $i$ ,  $x_j(t)$  is the position of all other grasshoppers, and  $T_d(t)$  is the target position [21]. The parameter  $c$  is calculated as [21]:

$$32) C = C_{max} - t \frac{C_{max} - C_{min}}{tMax}$$

where  $C_{max}$  is the maximum value  $C$  (usually close to 1),  $C_{min}$  is the minimum value  $C$  (usually close to +0),  $t$  is the current iteration, and  $tMax$  is the maximum iteration. The adaptive parameter  $c$  is used twice in Equation 32; the first  $c$  establishes a balance between exploration and exploitation. This  $c$  is highly resembling the  $w$  parameter in the PSO optimization algorithm. The second  $c$  reduces the attraction zone, comfort zone, and repulsion zone between grasshoppers (Equation 33) [21].

$$33) X_i = \sum_{j=1}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_j(t) - x_i(t)}{d_{ij}(t)} + T_d(t)$$

### K-nearest neighbor

We also used the K-Nearest Neighbor (KNN) for feature classification. The KNN is a simple algorithm that store all available cases and classifies the new cases based on distance functions [31]. KNN is utilized in pattern recognition and statistical estimation as a non-parametric method. Majority vote of the neighbors is considered to classify a case. By measuring the distance function, a class is being assigned to a case. The advantages of KNN includes: (a) it is easy to implement and simple, (b) it can be used for regression and classification problems, and (c) there is no need to tune parameters, make extra assumptions or build a model. However, its disadvantage is that as the number of independent variables or predictors increase, the performance of the algorithm decreases significantly.

### Random forest

The interpretability of DT method and their logical course of training have always attracted the attention of researchers, but one of the problems of this method is its quick overfitting. Random Forest (RF) is one of the methods to solve this problem. In this study, it was also used for classification of features. It has high accuracy, ap-

propriate learning speed, and ability to separate data in high-dimensional spaces. By training different DTs and voting among them, these models become more robust to outliers and noises [31].

### Validation

The classification results were evaluated using 10-fold cross validation method. The performance of the algorithm was estimated using metrics such as Specificity (Spec), Sensitivity (Sens), Accuracy (ACC), Precision (Prec), and F1-Score (FS) whose equations are presented below. These terminologies are extracted from confusion matrix which consists of True Positive (TP), False Negative (FN), True Negative (TN) and False Positive (FP) [22].

### Results

In this study, in order to implement the proposed method for detection of epileptic seizures, a system with 16 GB RAM, Nvidia GeForce GTX 1070, and Intel Core i7 was used. The preprocessing and feature extraction were conducted in MATLAB 2019a. The the AE method and classification techniques were implemented using Python, Keras, and Scikit-learn softwares [3, 34]. In the proposed method, the Bonn dataset was used for the diagnosis of epileptic seizures. As indicated in Table 2, we used six different classification problems. First, the EEG signals from the Bonn dataset were decomposed into 5-second time windows. Then, the TQWT was used for signal decomposition into different frequency sub-bands. Next, different statistical and non-linear features were extracted from the TQWT sub-bands. In this regard, 153 features were extracted. The AE method with 7 layers was used for feature reduction. By this method, the number of features was reduced to 32. At the end, different algorithms were used for classification.

When optimization algorithms such as medical data classification are used in ML, researchers often perform the method several times in a same conditions to obtain valid results. In this regard, we performed all classification algorithms 10 times in a exactly same conditions to obtain valid results. The results of each classification algorithm for different modes are presented in Table 4. According to the results, by using the GOA/SVM method, higher accuracy was obtained compared to other classification algorithms.

### Discussion and Conclusion

Epilepsy is a brain disorder, which is known as a neurological disorder and causes seizures or abnormal behavior, emotions, and sometimes anesthesia [1-4]. One of the most commonly used functional neuroimaging methods fro the

diagnosis of epileptic seizures is EEG. It can find the exact location of epilepsy, and its recording is less expensive than other neuroimaging methods [1-4]. EEG signals cause some challenges for physicians despite their advantages. EEG recording is conducted in a long-term period to detect epileptic seizures, which challenges physicians for accurately locating the disease. Epileptic seizures are difficult to diagnose because EEG images often contain a variety of internal and external abnormalities. A novel method for epileptic seizure detection was presented in this study based on ML and DL techniques to overcome these challenges. Preprocessing of TQWT subbands, extraction of statistical and nonlinear features, feature reduction by a DL-based AE method, and classification by the GOA/SVM model were used in this study to detect epileptic seizures from EEG signals. Adopting the features extracted in this study improved the accuracy of epileptic seizures detection. Table 5 compares the results of the proposed method with other methods used EEG signals for epileptic seizures detection.

The results of the proposed method were more accurate than other methods due to proper preprocessing, feature extraction, feature selection, and classification. The proposed method can be implemented in a hardware or software to help physicians detect epileptic seizures. Future research can focus on new techniques of DL such as attention learning, graph, and q-learning for epileptic seizures detection using EEG signals [56-60]. Deep feature fusion techniques can also be used in future studies, as well as the combination of handcrafted features with DL techniques for epileptic seizures detection [61-63].

$$34) Acc = \frac{TP+TN}{FP+FN+TP+TN}$$

$$35) Sens = \frac{TP}{TP+FN}$$

$$36) Spec = \frac{TN}{FP+TN}$$

$$37) Prec = \frac{TP}{TP+FN}$$

$$38) FS = \frac{2 TP}{2 TP+FP+FN}$$

## Ethical Considerations

### Compliance with ethical guidelines

No ethical approval was needed, since no any experiment on human or animal samples were conducted.

### Funding

The paper was extracted from the PhD. dissertation by Anis Malekzadeh/Assef Zare/Mehdi Yaghoubi, at Depart-

ment of Electrical, Technical Engineering, Islamic Azad University.

### Authors' contributions

All authors equally contributed to preparing this article.

### Conflicts of interest

The authors declared no conflict of interest.

### Acknowledgments

The authors would like to thank the Deputy for Research of Islamic Azad University of Gonabad branch for their cooperation.

This Page Intentionally Left Blank

## مقاله پژوهشی

# تشخیص تشنج صرع در سیگنال‌های EEG با استفاده از طبقه‌بندی SVM-GOA و TQWT

انیس ملک‌زاده<sup>۱</sup>، آصف زارع<sup>۱</sup>، مهدی یعقوبی<sup>۲</sup>، روح‌الله علیزاده<sup>۳</sup>

۱. گروه مهندسی برق، دانشکده مهندسی برق، واحد گناباد، دانشگاه آزاد اسلامی، گناباد، ایران.
۲. گروه مهندسی برق، دانشکده مهندسی، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.
۳. مؤسسه تحقیقات و نوآوری سیستم‌های هوشمند (ISRI)، دانشگاه دیکین، جیلونگ، استرالیا.

### چکیده

تاریخ دریافت: ۲۷ شهریور ۱۴۰۰  
تاریخ پذیرش: ۱۳ آذر ۱۴۰۰  
تاریخ انتشار: ۱۱ دی ۱۴۰۰

**هدف:** صرع یک بیماری اختلال مغزی است که کیفیت زندگی افراد را تحت تأثیر قرار می‌دهد. اگر در مراحل اولیه تشخیص داده شود، گسترش نخواهد یافت. سیگنال‌های الکتروانسفالوگرافی برای تشخیص تشنج‌های صرع استفاده می‌شود. با این حال، این سیستم غربالگری نمی‌تواند حالت‌های تشنج صرع را دقیقاً تشخیص دهد. با وجود این، با کمک سیستم‌های تشخیصی به کمک رایانه (CADs)، متخصصان مغز و اعصاب می‌توانند مراحل تشنج صرع را به‌درستی تشخیص دهند. هدف از این مطالعه تشخیص تشنج صرع با استفاده از سیگنال‌های EEG و تشخیص مراحل مختلف آن است. CADs پیشنهادی در این مطالعه از ویژگی‌های آماری و غیرخطی مختلف، قادر به تشخیص دقیق و سریع تشنج‌های صرع است. بنابراین، این سیستم می‌تواند به متخصصان مغز و اعصاب در تشخیص دقیق‌تر کمک کند.

**مواد و روش‌ها:** این مقاله بر روی یک روش جدید برای تشخیص تشنج صرع بر اساس سیگنال‌های الکتروانسفالوگرام با استفاده از تکنیک‌های هوش مصنوعی (AI) تأکید می‌کند. ابتدا از مجموعه داده بن برای آزمایشات استفاده می‌شود و سیگنال‌های الکتروانسفالوگرام به فواصل پنج‌ثانیه‌ای تقسیم می‌شوند. سپس تبدیل موجک عامل Q قابل تنظیم برای تجزیه و تحلیل سیگنال‌های الکتروانسفالوگرام به زیر باندهای مختلف استفاده شد. چند ویژگی آماری و غیرخطی (ابعاد فراکتال (FDs) و آنتروپی) زیرباندهای تبدیل موجک عامل Q قابل تنظیم برای روش‌های استفاده‌شده در آنتروپی و فرکتال استخراج می‌شوند. در روش بعدی از روش هوش مصنوعی با لایه‌های پیشنهادی برای کاهش ویژگی‌ها استفاده می‌شود و در نهایت الگوریتم‌های طبقه‌بندی مختلف مانند دستگاه بردار پشتیبانی با الگوریتم بهینه‌سازی ملخ (SVM-GOA)، نزدیک‌ترین همسایه K-Nearest (KNN)، و جنگل تصادفی استفاده می‌شوند. استفاده از AE برای کاهش ویژگی و SVM-GOA برای طبقه‌بندی، نشان‌دهنده تازگی این مطالعه است.

**یافته‌ها:** با توجه به نتایج، روش پیشنهادی، تشخیص تشنج صرع عملکرد بهتری را در مقایسه با کارهای مرتبط نشان داد. روش طبقه‌بندی پیشنهادی SVM-GOA دارای میزان دقت بالاتری به میزان ۹۹/۴۲ و ۹۹/۲۳ درصد برای مشکلات طبقه‌بندی دو کلاسه و چند کلاسه است.

**نتیجه‌گیری:** ترکیب ویژگی‌های مؤثر در تشخیص دوره‌های تشنج صرع همراه با روش‌های طبقه‌بندی مناسب، دقت CADs را افزایش می‌دهد. با توجه به اهمیت تشخیص انواع حملات صرع، یک CADs با دقت بالا در این کار معرفی شده است. دقت بالا، استفاده از روش‌های مختلف برای استخراج ویژگی‌ها و طبقه‌بندی از جمله مزایای روش پیشنهادی ماست.

### کلیدواژه‌ها:

تشنج صرع،  
سیگنال‌های EEG،  
تشخیص، استخراج  
SVM-GOA،  
ویژگی،

### مقدمه

زندگی می‌کنند. در صورت درمان و تشخیص مناسب، ۷۰ درصد از افراد مبتلا به این بیماری می‌توانند به زندگی بدون تشنج برسند. خطر مرگ زودرس در افراد مبتلا به صرع ۳ برابر بیشتر از افراد عادی است. سه‌چهارم بیماران صرعی که در کشورهای در حال توسعه زندگی می‌کنند، نمی‌توانند به درمان لازم بپردازند [۱]. چنین بیمارانی و خانواده‌هایشان از تبعیض و انگ رنج می‌برند. صرع دو نوع عمومی و کانونی دارد [۲]. اثرات صرع کانونی بر روی

صرع یک خطر عصبی مزمن غیر قابل انتقال است که ممکن است بر روی افراد در هر سنی تأثیر بگذارد [۱]. ممکن است از آن به عنوان یک بیماری شایع مغزی یاد شود. تقریباً ۵۰ میلیون نفر در سراسر جهان به شکل اغراق‌آمیزی به آن مبتلا هستند. ۸۰ درصد مبتلایان به این بیماری در کشورهای متوسط و کم‌درآمد

\* نویسنده مسئول:

دکتر آصف زارع

نشانی: گناباد، دانشگاه آزاد اسلامی، واحد گناباد، دانشکده مهندسی برق، گروه مهندسی برق.

تلفن: ۵۳۳۱۰۹۱ (۵۱) +۹۸

پست الکترونیکی: assefzare@gmail.com

الکتروانسفالوگرافی به زیرباند های مختلف استفاده کرد. سپس، هر زیرباند DWT برای استخراج برخی از ویژگی های آماری مورد بررسی قرار گرفت و شبکه عصبی مصنوعی<sup>۱</sup> برای طبقه بندی داده ها استفاده شد. سینگ و همکاران [۴۷] روش جدیدی برای تشخیص تشنج صرع از سیگنال های الکتروانسفالوگرافی مجموعه داده بن پیشنهاد کردند. آن ها از روش های تجزیه ی مد تجربی یکپارچه کامل، یعنی تجزیه مجموعه های تکمیلی حالت تجربی<sup>۱۰</sup> و آنتروپی پراکندگی چند مقیاس تصفیه شده<sup>۱۱</sup> برای انجام پیش پردازش و استخراج خواص استفاده کردند و روش های مختلفی را برای انتخاب ویژگی آزمایش کردند تا اندازه ماتریس ویژگی را کاهش دهند. در نهایت، تکنیک طبقه بندی شبکه عصبی مصنوعی استفاده شد و به نتایج امیدوار کننده ای منجر شد. علیو و همکاران [۴۹] یک تشخیص تشنج صرع را بر اساس انتخاب تبدیل موجک بهینه ارائه کردند. برای تجزیه و تحلیل داده های سیگنال های الکتروانسفالوگرافی، از روش تبدیل موجک گسسته به منظور تجزیه آن ها به زیرباند های متعدد و استخراج اطلاعات آماری مختلف از هریک استفاده شده است. در نتیجه، رویکردهای ضریب همبستگی و ویژگی (CCP) P و تحلیل مؤلفه اصلی<sup>۱۲</sup> برای به حداقل رساندن اختصاصیت مورد استفاده قرار گرفتند. مدل حافظه کوتاه مدت ماندگار<sup>۱۳</sup> با لایه های پیشنهادی برای طبقه بندی ویژگی های ورودی استفاده شد که منجر به دقت ۹۹ درصد شد. محققان [۵۰] ویژگی های هارالیک<sup>۱۴</sup> را به عنوان روشی برای تشخیص تشنج های صرع از سیگنال های الکتروانسفالوگرافی در نظر گرفتند که با استفاده از تبدیل فوری کوتاه مدت<sup>۱۵</sup> برای استخراج ویژگی های هارالیک به تصاویر دوبعدی تبدیل شدند. در نهایت از روش درخت تصمیم<sup>۱۶</sup> برای طبقه بندی استفاده شد و نتایج تحقیق با دقت ۹۲/۵۰ درصد به دست آمد. همچنین محققان [۵۱] از نظریه های FD و گراف برای استخراج ویژگی استفاده کردند و از روش ECT برای پیش پردازش سیگنال های الکتروانسفالوگرافی به عنوان اولین مرحله مطالعه استفاده کردند. سپس، آن ها نظریه گراف و ویژگی های مبتنی بر ابعاد فراکتال<sup>۱۷</sup> را از سیگنال های الکتروانسفالوگرافی استخراج کردند. در نهایت از روش RF برای طبقه بندی استفاده کردند و به دقت ۹۸/۵۰ درصد رسیدند.

این مقاله یک روش جدید مبتنی بر استخراج ویژگی های

9. Artificial Neural Network (ANN)
10. Complementary Ensemble Empirical Mode Decomposition (CEEMD)
11. Refined Composite Multi-scale Dispersion Entropy (RCMDE)
12. Principal component analysis (PCA)
13. Long short-term memory (LSTM)
14. Haralick
15. Short-Time Fourier Transform (STFT)
16. Decision Tree (DT)
17. FRACTAL Dimension (FD)

ناحیه ای از مغز است و پیدا کردن بخشی از مغز که تحت تأثیر صرع کانونی قرار گرفته است برای مراقبت های پزشکی مهم است. شصت درصد بیماران صرع کانونی و بیست درصد بیماران مبتلا به صرع عمومی به دارو مقاوم می شوند و برای چنین بیمارانی نیاز به عمل جراحی است [۴].

روش های مختلفی برای تشخیص تشنج صرع ارائه شده است، از جمله روش های بالینی و روش های تصویربرداری عصبی [۱، ۲] که در میان آن ها روش های تصویربرداری عصبی به طور گسترده توسط پزشکان استفاده می شود [۱، ۲]. به طور کلی، روش های تصویربرداری عصبی به روش های عملکردی و ساختاری طبقه بندی می شوند [۱-۳] و ثبت سیگنال های الکتروانسفالوگرافی یک روش تشخیص تشنج صرع بر اساس روش های تصویربرداری عصبی عملکردی است [۱، ۲]. سیگنال های الکتروانسفالوگرافی اطلاعات ضروری را از محل تشنج صرع ارائه می دهند که به پزشکان کمک می کند تا تشنج های صرعی را با دقت بالاتر تشخیص دهند [۱-۳].

تشخیص تشنج های صرع از طریق سیگنال های الکتروانسفالوگرافی کاری چالش برانگیز برای پزشکان متخصص است [۱، ۲]. سیگنال های الکتروانسفالوگرافی با پیچیدگی نسبتاً زیادی همراه هستند و برای تشخیص صحیح، چالش و دشواری ایجاد می کنند [۱، ۲]. بر این اساس، با استفاده از روش هوش مصنوعی<sup>۱</sup>، هدف محققان تشخیص زودهنگام تشنج های صرع از طریق سیگنال های الکتروانسفالوگرافی است. تشنج های صرع با استفاده از یادگیری ماشینی<sup>۲</sup> [۴-۶] و یادگیری عمیق<sup>۳</sup> [۷، ۸] انجام می شوند که از جمله تکنیک های هوش مصنوعی هستند.

در CADs مبتنی بر ML، تکنیک های استخراج ویژگی شامل زمان، فرکانس، زمان - فرکانس و روش های غیرخطی [۹-۱۲] است. همچنین در CADs مبتنی بر روش های DL تکنیک های تشخیص تشنج های صرع، رمزنگارهای خودکار<sup>۴</sup>، شبکه های عصبی بازگشتی<sup>۵</sup>، شبکه های عصبی کانولوشن<sup>۶</sup> و شبکه های باور عمیق هستند [۱۳-۱۹].

عابدین و همکاران [۴۵] یک روش تشخیص تشنج صرع را بر اساس ویژگی های آماری ارائه کردند و به نتایج امیدوار کننده ای دست یافتند. این مطالعه ابتدا از یک مجموعه داده بن و روش تبدیل موجک گسسته<sup>۸</sup> برای پیش پردازش و تجزیه و تحلیل سیگنال های

1. Artificial Intelligence (AI)
2. Machine Learning (ML)
3. Deep Learning (DL)
4. Autoencoder (AEs)
5. Returned Neural Network (RNNs)
6. Convolutional Neural network (CNNs)
7. Deep Belief Network (DBNs)
8. Discrete Wavelet Transform (DWT)

گرادیان از نظر سرعت و عملکرد بهتر عمل می‌کند. الگوریتم‌های بهینه‌سازی گرادیان معمولاً کند هستند و انتخاب پارامترهای نادرست می‌تواند منجر به کارایی نامناسب شود. علاوه بر این، روش‌های گرادیان در همه مسائل کارآمد نیستند. بنابراین، الگوریتم‌های فراابتکاری، از جمله الگوریتم ژنتیک<sup>۱۹</sup> [۵۳]، بهینه‌سازی ازدحام ذرات<sup>۲۰</sup> [۵۴]، ازدحام پرورش (BS) [۵۵] و غیره، برای بهینه‌سازی الگوریتم‌های طبقه‌بندی استفاده می‌شوند.

### مواد و روش‌ها

در این بخش روش پیشنهادی برای تشخیص تشنج صرع در سیگنال‌های الکتروانسفالوگرافی ارائه شده است. روش پیشنهادی شامل مراحل انتخاب داده، پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و در نهایت طبقه‌بندی است.

### مجموعه داده

#### مجموعه داده بُن

مجموعه داده بن توسط گروهی از محققین در دانشگاه بن ثبت شد و به طور گسترده در زمینه تجزیه و تحلیل و تشخیص تشنج صرع استفاده شده بود [۲۲]. مجموعه داده بن داده‌های تک کانالی ۵۰۰ سیگنال الکتروانسفالوگرافی در دسترس عموم است. از آن در ۱۷۳/۶ هرتز با مدت زمان ۲۳/۶ ثانیه نمونه‌برداری شد. آن‌ها از پنج کلاس تشکیل شده بودند. S، F، N، O و Z با ۱۰۰ کانال ثبت شده در هر کلاس [۲۲]. پنج کنترل سالم در حالت آرام و بیدار با طرح قرار دادن الکترواستاندارد ۱۰-۲۰ به داده‌های سطح سیگنال‌های الکتروانسفالوگرافی کلاس O و Z کمک کردند. برای جمع‌آوری داده‌های کلاس‌های S، F، N از الکترودهای داخل جمجمه‌ای برای پنج بیمار مبتلا به صرع استفاده شد. نیمکره ناحیه صرع‌زا و نیمکره مخالف به ترتیب برای ثبت سیگنال‌های کلاس‌های S و F در طول دوره اینترکتال استفاده شد. در مورد ثبت طبقه S دوره ایکتال در نظر گرفته شد. فرکانس‌های برش در محدوده ۰/۵۳ تا ۴۰ هرتز با واکنش متناهی ضربه با فیلتر باند میان‌گذر ۲۰ مرتبه برای فیلتر کردن داده‌های سیگنال‌های الکتروانسفالوگرافی اعمال شد [۲۲].

**تصویر شماره ۲** سیگنال‌های الکتروانسفالوگرافی مجموعه داده بن را نشان می‌دهد. همچنین سایر اطلاعات این پایگاه در جدول‌های شماره ۱ و ۲ آمده است.

### پیش‌پردازش

#### تبدیل موجک عامل Q قابل تنظیم

نوع خاصی از تبدیل موجک گسسته است و در تحقیقات سیگنال زیست پزشکی استفاده شده است [۲۰]. در تبدیل

غیرخطی، کاهش ویژگی DL و روش طبقه‌بندی SVM-GOA ارائه می‌دهد. در این مقاله، از سیگنال‌های الکتروانسفالوگرافی مجموعه داده بن، برای تشخیص تشنج صرع استفاده شده است. **تصویر شماره ۱** قطعه نموداری از روش پیشنهادی برای تشخیص تشنج صرع از سیگنال‌های الکتروانسفالوگرافی را نشان می‌دهد.

پزشکان باید سیگنال‌های الکتروانسفالوگرافی را در فرکانس‌های خاص آنالیز کنند تا تشنج‌های صرع را به درستی تشخیص دهند. تبدیل موجک پرکاربردترین روش برای پیش‌پردازش و استخراج فرکانس‌های قابل توجه از سیگنال‌های الکتروانسفالوگرافی است. انواع مختلفی از تبدیل‌های بنفش در تحقیقات مختلف مورد استفاده قرار گرفته‌اند که در میان آن‌ها رویکرد تبدیل موجک عامل Q قابل تنظیم<sup>۱۸</sup> یکی از بهترین روش‌ها برای پیش‌پردازش سیگنال‌های الکتروانسفالوگرافی است [۲۰]. نشان داده شده است که این روش نسبت به روش تبدیل موجک گسسته در زمینه پیش‌پردازش و تجزیه و تحلیل سیگنال‌های الکتروانسفالوگرافی به زیرباندهای فرکانس مختلف کارآمدتر است. بنابراین، این مقاله از تبدیل موجک عامل Q قابل تنظیم برای پیش‌پردازش و تجزیه و تحلیل سیگنال‌های الکتروانسفالوگرافی مجموعه داده بن استفاده کرد. پارامترهای تبدیل موجک عامل Q قابل تنظیم مشابه  $l = 8$  و  $r = 3$  و  $Q = 1$  [۳۴] انتخاب شدند و تجزیه و تحلیل سیگنال‌های الکتروانسفالوگرافی با روش تبدیل موجک عامل Q قابل تنظیم منجر به استخراج خواص مهم از زیرباندهای فرکانس شد که می‌تواند میزان دقت تشخیص تشنج صرع را افزایش دهد.

در مرحله بعد، ویژگی‌های آماری و غیرخطی مختلفی از سیگنال‌های الکتروانسفالوگرافی استخراج می‌شود و پنج لحظه آماری، ویژگی‌های غیرخطی مانند رویکردهای FD و آنتروپی از زیرباندهای تبدیل موجک عامل Q قابل تنظیم بازیابی می‌شوند. هیگوجی، کاتز، پتروسیان، و نمای هرست برخی از ویژگی‌های غیرخطی مبتنی بر فراکتال‌ها هستند و شانون، نمودار انرژی، نمونه، تسالیس، فازی، بازگشتی، طیفی و نمودار از جمله ویژگی‌های غیرخطی مبتنی بر آنتروپی هستند. در نتیجه، در مجموع ۱۵۳ ویژگی از هر فریم سیگنال الکتروانسفالوگرافی استخراج شد. مدل AE با لایه‌های پیشنهادی برای کاهش ویژگی به عنوان اولین تازگی این مقاله استفاده شد و ویژگی‌ها را از ۱۵۳ به ۳۲ کاهش داد.

علاوه بر این، چندین رویکرد یادگیری ماشینی شامل SVM، KNN، SVM-GOA، و RF برای طبقه‌بندی استفاده می‌شوند. دومین نکته جدید این مقاله استفاده از الگوریتم GOA در ارتباط با طبقه‌بندی SVM است. الگوریتم GOA یک روش بهینه‌سازی جدید است که تاکنون در تشخیص تشنج صرع همراه با SVM استفاده نشده است. رویکرد GOA از روش‌های بهینه‌سازی

19. Genetic Algorithm (GA)

20. Particle Swarm Optimization (PSO)

18. Tunable Q-factor Wavelet Transform (TQWT)



موجک عامل Q قابل تنظیم، افزودگی، تعداد سطوح تجزیه و فاکتور Q را می‌توان تنظیم کرد. سیگنال‌های نوسانی با مقدار Q بالا و سیگنال‌های گذرا با مقدار Q پایین تجزیه و تحلیل می‌شوند. مفهوم بانک فیلتر دو کاناله در تبدیل موجک عامل Q قابل تنظیم اعمال می‌شود. فاکتورهای مقیاس پایین و بالا گذر برای بانک‌های فیلتر با دو کانال با  $\gamma$  و  $\delta$  نشان داده می‌شوند. عبارت ریاضی پاسخ فرکانس فیلتر پایین گذر در فرمول شماره ۱ آمده است [۲۰]:

۱.

$$T0(\omega) = \begin{cases} 1, & \text{if } |\omega| \leq (1-\delta)\pi \\ \theta \left( \frac{\omega + (\delta-1)\pi}{\gamma + \delta - 1} \right), & \text{if } (1-\delta)\pi < |\omega| < \gamma\pi \\ 0, & \text{if } \gamma\pi \leq |\omega| \leq \pi \end{cases}$$

عبارت ریاضی پاسخ فرکانس فیلتر بالا گذر در فرمول شماره ۲ آمده است:

۲.

$$T1(\omega) = \begin{cases} 0, & \text{if } |\omega| \leq (1-\delta)\pi \\ \theta \left( \frac{\gamma\pi - \omega}{\gamma + \delta - 1} \right), & \text{if } (1-\delta)\pi < |\omega| < \gamma\pi \\ 1, & \text{if } \gamma\pi \leq |\omega| \leq \pi \end{cases}$$

اطلاعات بیشتر در مورد تبدیل موجک عامل Q قابل تنظیم در برخی منابع ارائه شده است [۲۰]. این مقاله ل، Q، و ۲ را به ترتیب ۸، ۳ و ۱ تعریف می‌کند. در تصویر شماره ۳، زیرباندهای تبدیل موجک عامل Q قابل تنظیم بر اساس پارامترهای تعریف شده نشان داده شده‌اند. همچنین پاسخ فرکانس موجک در تصویر شماره ۴ ترسیم شده است.

### استخراج ویژگی

در این بخش، روش‌های مختلف استخراج ویژگی برای تشخیص تشنج صرع را ارائه می‌کنیم. در ابتدا، تبدیل موجک عامل Q قابل تنظیم برای تجزیه سیگنال‌های الکتروانسفالوگرافی استفاده شد و در ادامه، ویژگی‌های متفاوتی مانند آماری، غیرخطی بر اساس فراکتال و غیرخطی بر اساس آنتروپی در زیرباندهای تبدیل موجک عامل Q قابل تنظیم استخراج شد.

### ویژگی‌های آماری

ویژگی‌های آماری در این بخش معرفی شده است. در این مقاله، پنج لحظه آماری از زیرباندهای تبدیل موجک عامل Q قابل تنظیم استخراج شده است [۲۳]. جدول شماره ۳ ویژگی‌های آماری برای تشخیص تشنج‌های صرع در سیگنال‌های الکتروانسفالوگرافی را نشان می‌دهد.

### ویژگی‌های فراکتال

در این بخش، ویژگی‌های فراکتال از زیرباندهای تبدیل

### هیگوچی فراکتال

$x(1), x(2), \dots, x(N)$  دنباله زمانی مورد بررسی را در نظر بگیرید. k سری زمانی جدید  $X_m^k$  را به عنوان [۱۲] ایجاد کنید (فرمول شماره ۳).

۳.

$$x_m^k = \{x(m), x(m+k), x(m+2k), \dots, x(m + \lfloor \frac{N-m}{k} \rfloor k)\}, \text{ for } m=1, 2, \dots, k$$

در جایی که [a] قسمت صحیح a را نشان می‌دهد، k به معنای فاصله زمانی گسسته بین نقاط، m به معنای مقدار زمانی اولیه است. برای هر سری زمانی  $X_m^k$  ایجاد شده، میانگین طول  $L_m(k)$  به صورت فرمول شماره ۴ محاسبه می‌شود [۱۲].

۴.

$$L_m(k) = \frac{\sum_{i=1}^{\lfloor \frac{N-m}{k} \rfloor} |x(m+ik) - x(m+(i-1)k)|^{n-1}}{\lfloor \frac{N-m}{k} \rfloor}$$

تأخیر k در تمام سری‌های زمانی با طول متوسط k، به صورت میانگین طول‌های  $L_m(k)$  برای  $k=1, \dots, k$  محاسبه می‌شود. برای هر k از ۱ تا  $k_{max}$ ، این روش تکرار می‌شود و مجموع طول‌های متوسط  $L(k)$  برای هر k همان‌طور که در فرمول شماره ۵ نشان داده شده است [۱۲] تولید می‌شود.

۵.

$$L(k) = \sum_{m=1}^k L_m(k)$$

$L(k)$  متناسب با  $k^D$ ، که در آن FD، D توسط الگوریتم برای طول متوسط کل برای مقیاس k است [۱۲].

### کاتز فراکتال

بعد فراکتال یک منحنی را می‌توان به صورت فرمول شماره ۶ ارائه کرد [۱۲].

۶.

$$HE = \frac{\log_{10}(RS)}{\log(T)}$$

به طوری که S انحراف استاندارد است، T مدت زمان داده‌های نمونه و R نشان‌دهنده تفاوت بین حداقل و حداکثر انحراف از میانگین است.

#### ویژگی‌های آنتروپی

در این مقاله، آنتروپی‌های مختلف برای استخراج مشخصه سیگنال‌های الکتروانسفالوگرافی مورد بهره‌برداری قرار می‌گیرند. در ادامه معادلات تمامی آنتروپی‌ها شرح داده شده است.

#### آنتروپی شانون

آنتروپی شانون، تکنیک آنتروپی اساسی برای استخراج ویژگی در سیگنال‌های الکتروانسفالوگرافی است [۲۶]. معادله آنتروپی شانون به صورت فرمول شماره ۱۲ است.

۱۲.

$$H(X) = -\sum_{i=0}^{N-1} P_i \log_2 P_i$$

به طوری که در این فرمول، Pi احتمال وقوع یک نماد معین است.

#### نمودار LOG آنتروپی انرژی

لگ آنتروپی انرژی را می‌توان به صورت فرمول شماره ۱۳ نشان داد [۲۶].

۱۳.

$$E_{Log} = \sum_{i=0}^K \log(E_i^2)$$

به طوری که در آن K و  $E_i$  به ترتیب طول سیگنال الکتروانسفالوگرافی و n امین نمونه سیگنال الکتروانسفالوگرافی را نشان می‌دهند.

#### آنتروپی نمونه

در فرمول شماره ۱۴، فرمول آنتروپی نمونه نشان داده شده است [۲۶].

۱۴.

$$SampEn = -\log(A/B)$$

به طوری که A به تعداد کل جفت بردارهای طول  $m+1$  اشاره دارد. همچنین، B شامل تعداد کل جفت‌های بردار طول m است.

#### آنتروپی تسالیس<sup>۲۲</sup>

22. Tsallis entropy (Ets)

$$D = \frac{\log_{10}(d)}{\log_{10}(L)}$$

به طوری که در آن d قطر تخمین زده شده به منظور فاصله بین نقاط دنباله‌ای است که دورترین فاصله و اولین نقطه دنباله را فراهم می‌کند و L طول کل منحنی است. d را می‌توان از نظر ریاضی به صورت فرمول شماره ۷ بیان کرد [۱۲]:

۷.

$$d = \max(\text{distance}(l, i))$$

نقطه i همان نقطه‌ای است که با اولین نقطه حداکثر می‌شود. اندازه‌گیری واحدهای مورد استفاده به FDهای محاسبه شده بستگی دارد. اگر واحدها متفاوت باشند، FDها متفاوت هستند. رویکرد کاتز سعی می‌کند با ایجاد یک واحد عمومی مشکل را حل کند [۱۲] (فرمول شماره ۸).

۸.

$$D = \frac{\log_{10}(L/a)}{\log_{10}(d/a)}$$

اگر  $n=L/a$ ، که در آن n تعداد مراحل منحنی است باشد، معادله مذکور را می‌توان به صورت زیر نوشت که استراتژی کاتز برای اندازه‌گیری بعد فراکتال سیگنال الکتروانسفالوگرافی را خلاصه می‌کند [۱۲] (فرمول شماره ۹).

۹.

$$D = \frac{\log_{10}(n)}{\log_{10}(d/L) + \log_{10}(n)}$$

#### فراکتال پتروسیان

در این بخش روش پتروسیان ارائه شده است. معادله این تکنیک فراکتال به صورت فرمول شماره ۱۰ است [۱۲].

۱۰.

$$D = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left( \frac{n}{n+0.4 N \Delta} \right)}$$

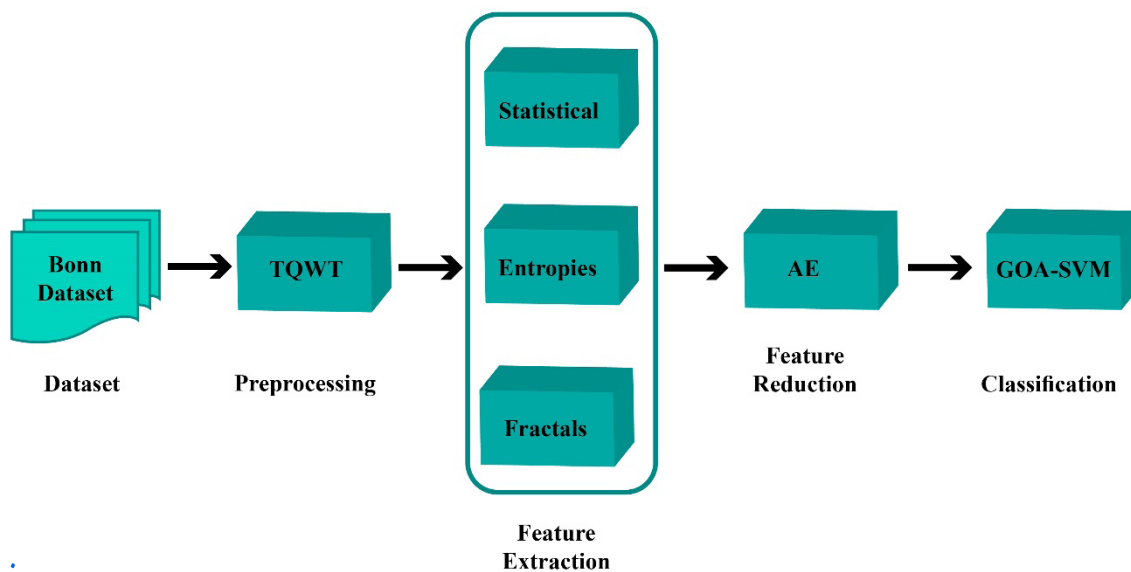
به طوری که در آن  $N_{\Delta}$  تعداد جفت‌های غیرمشابه و n طول دنباله در دنباله باینری به دست آمده است [۱۲].

#### نمودار هرست

معادله توان هرست<sup>۲۱</sup> به صورت فرمول شماره ۱۱ است [۲۵].


۱۱.

21. Hurst exponen (HE)




طب داخلی روز

تصویر ۱. روش پیشنهادی برای تشخیص تشنج صرع




طب داخلی روز

تصویر ۲. نمونه مجموعه داده‌های بن سیگنال‌های الکتروانسفالوگرافی از پنج نمونه.



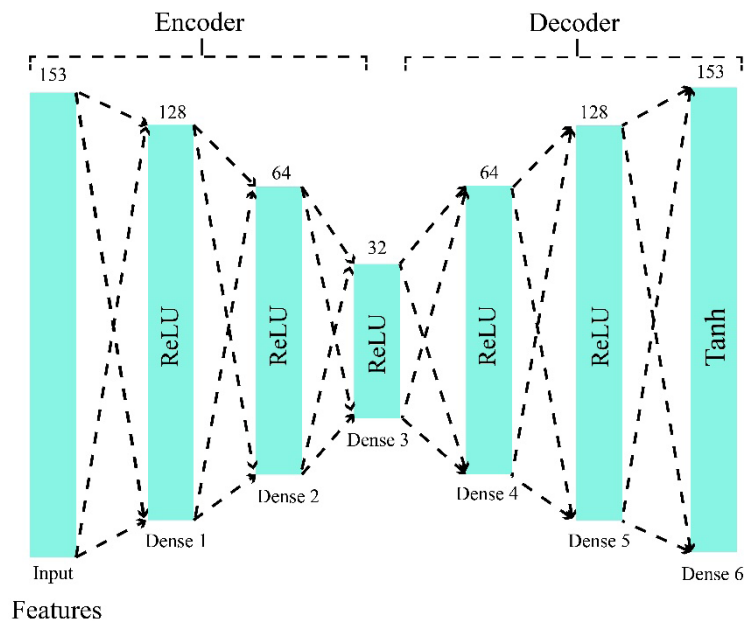
طب داخلی روز

تصویر ۳. زیرباند‌های سیگنال‌های الکتروانسفالوگرافی با استفاده از تبدیل موجک عامل Q قابل تنظیم




تصویر ۴. پاسخ فرکانس برای TQWT با پارامترهای  $Q$  و  $R$  پیشنهادی.

طب داخلی روز



تصویر ۵. EA پیشنهادی برای کاهش ویژگی

طب داخلی روز



تصویر ۶. الگوهای اصلاحی اولیه بین افراد در دسته ای از ملخها [۲۱]

طب داخلی روز

جدول ۱. توضیح کامل پنج زیر مجموعه، مجموعه داده

مجموعه‌ها	آزمودنی‌ها		
	مرحله بیمار	تعداد مورد	تعداد داده‌ها
Set A	Eye Open	۵	۱۰۰
Set B	Eye Close	۵	۱۰۰
Set C	Seizure Free	۵	۱۰۰
Set D	Seizure Free	۵	۱۰۰
Set E	Seizure Activity	۵	۱۰۰

طب داخلی روز

جدول ۲. جزئیات بیشتر در مورد طبقه‌بندی شش مسئله

ردیف	طبقه‌بندی‌ها	توضیحات
۱	A-E	Healthy Control – Ictal
۲	B-E	Healthy Control – Ictal
۳	C-E	Interictal – Ictal
۴	D-E	Interictal – Ictal
۵	ABCD-E	Normal – Seizure
۶	AB-CD-E	Healthy Control – Interictal – Seizure

طب داخلی روز

جدول ۳. استخراج ویژگی‌های آماری در زیر باندهای TQWT

فرمول	نام ویژگی	فرمول
۳	میانگین	$X_{mean} = \frac{1}{n} \sum_{i=1}^n x_i$
۴	واریانس (Var)	$X_{var} = \sum_{n=1}^N x_i (x_n - AM) \frac{2}{N-1}$
۵	کشیدگی (Kur)	$X_{ku} = \sum_{n=1}^N x_i (x_n - AM) \frac{4}{(N-1)SD^4}$
۶	چولگی (Skw)	$X_{ske} = \frac{1}{n} \sum_{n=1}^N x_i (x_n - AM) \frac{3}{(N-1)SD^3}$
۷	انحراف معیار (STD)	$X_{ske} = \sqrt{\sum_{n=1}^N x_i (x_n - AM) \frac{2}{N-1}}$

طب داخلی روز

جدول ۴. نتایج برای طبقه‌بندی کننده‌های مختلف

روش‌ها	مجموعه‌ها	پنجره	دقت	درستی	اختصاصیت	حساسیت	F1-Score
Standard SVM	A-E	۵	۹۸/۵۰	۹۸/۵۰	۹۸/۵۰	۹۸/۵۰	۹۸/۰۰
	B-E		۹۹/۴۲	۹۹/۱۶	۹۹/۲۵	۹۹/۴۶	۹۹/۲۳
	C-E		۹۹/۲۵	۹۸/۷۶	۹۸/۷۵	۹۹/۶۵	۹۹/۲۵
	D-E		۹۹/۳۷	۹۹/۱۳	۹۸/۹۶	۹۹/۰۳	۹۹/۱۸
	ABCD-E		۹۹/۲۱	۹۹/۲۳	۹۹/۲۵	۹۹/۱۵	۹۹/۱۶
	AB-CD-E		۹۹/۱۱	۹۹/۰۸	۹۸/۹۶	۹۹/۰۸	۹۹/۱۹
	A-E		۹۹/۵۷	۹۹/۷۸	۹۹/۹۸	۹۹/۹۴	۹۹/۲۷
SVM-GOA	B-E	۵	۹۹/۴۱	۹۹/۸۶	۹۸/۷۵	۹۹/۸۳	۹۹/۳۲
	C-E		۹۹/۳۸	۹۹/۷۱	۹۹/۶۸	۹۹/۴۳	۹۹/۵۱
	D-E		۹۹/۴۲	۹۹/۸۶	۹۹/۵۲	۹۹/۶۲	۹۹/۲۷
	ABCD-E		۹۹/۳۴	۹۹/۲۸	۹۹/۵۵	۹۹/۲۸	۹۹/۴۲
	AB-CD-E		۹۹/۲۳	۹۹/۲۹	۹۹/۰۷	۹۹/۴۲	۹۹/۳۰
	A-E		۹۸/۶۲	۹۷/۳۲	۹۷/۵۴	۹۷/۷۹	۹۷/۴۳
KNN (K=۳)	B-E	۵	۹۸/۳۷	۹۸/۲۵	۹۸/۳۱	۹۸/۴۹	۹۸/۲۷
	C-E		۹۷/۶۲	۹۷/۳۷	۹۷/۲۴	۹۸/۰۳	۹۷/۶۲
	D-E		۹۸/۸۷	۹۸/۱۳	۹۸/۳۷	۹۸/۲۳	۹۸/۷۷
	ABCD-E		۹۷/۹۱	۹۷/۶۲	۹۷/۸۷	۹۷/۶۶	۹۷/۵۲
	AB-CD-E		۹۷/۰۴	۹۶/۹۳	۹۷/۱۷	۹۷/۲۳	۹۷/۱۴
	A-E		۹۹/۷۱	۹۹/۶۲	۹۹/۵۹	۹۹/۶۳	۹۹/۵۲
RF	B-E	۵	۹۹/۳۱	۹۸/۶۹	۹۸/۵۹	۹۹/۷۱	۹۹/۱۴
	C-E		۹۹/۲۸	۹۹/۲۷	۹۹/۱۶	۹۹/۱۷	۹۹/۲۲
	D-E		۹۹/۱۸	۹۹/۱۵	۹۹/۰۹	۹۹/۲۹	۹۹/۲۱
	ABCD-E		۹۹/۳۲	۹۹/۲۸	۹۹/۱۱	۹۹/۲۲	۹۹/۴۶
	AB-CD-E		۹۹/۰۸	۹۹/۱۳	۹۹/۰۶	۹۹/۲۹	۹۹/۳۱

طب داخلی روز

آنتروپی فازی

در فرمول شماره ۱۵، آنتروپی تسالی معرفی شده است [۲۶].

۱۵

برای سری زمانی  $x(i), i=\{1, \dots, N\}$ ، آنتروپی فازی استاندارد یا Fuzzy En [۲۷] دنباله‌های برداری  $\{X_i^m, i=1, \dots, N-m+1\}$  به صورت فرمول شماره ۱۶ [۲۶] ارائه شده است.

۱۶

$$E_{is} = -(1 - \sum_{n=1}^x E_n^{\alpha}) \text{ for } \alpha \neq 1$$

به طوری که در آن احتمال وقوع به منظور  $E_n$  نامیده می‌شود و  $P_n$  مقدار ویژگی  $P$  است که محدوده مقادیر از  $P_1$  تا  $P_x$  را دارد [۲۷].

$$X_i^m = \{x(i), x(i+1), \dots, x(i+m-1)\} - x_0(i)$$

جدول ۵. کار پیشنهادی فشرده با سایر تحقیقات

کارها	روش‌ها	دقت (درصد)	
		دو کلاسه	چند کلاسه
[34]	TQWT Preprocessing + Npn-Linear and Statistical Features + Ensemble Learning classifier	۱۰۰	۹۸
[35]	TQWT Preprocessing + CLP features + RF classifier	۹۹	—
[36]	TQWT Preprocessing + Different Non-linear Features + Firefly Optimization feature selection + RF Classifier	۹۷	—
[37]	EMD – TQWT Preprocessing + IP Feature Extraction + LS-SVM Classifier	۹۹	—
[38]	TQWT Preprocessing + CCE Feature Extraction + Different Classifiers	۹۸/۳۰	۹۸/۲۰
[39]	STFT Preprocessing + Spectrum Energy Feature Extraction + Different Classifiers	۹۵/۵۶	—
[40]	DWT Preprocessing + Dynamic Feature Extraction Methods + FSFS Feature Selection + LS-SVM Classifier	۹۹/۵۰	—
[41]	LSP Preprocessing + NCA Feature Extraction + SVM Classifier	۹۹/۱۰	۹۶/۵۰
[42]	FBSE Preprocessing + WMRPE Feature Extraction + RF Classifier	۹۸/۹۳	—
[43]	Matrix Determinant Based Feature Extraction + MLP Classifier	۹۶/۹۴	۹۵/۹۷
[44]	IMFs Preprocessing + AmE Feature Extraction + DESA Feature Selection + RF Classifier	۹۷/۹۷	۹۸/۰۰
[45]	DWT Preprocessing + Statistical Features + ANN Classifier	—	۹۷/۳۳
[46]	DWT Preprocessing + Different Linear and Non-Linear Features + RF Classifier	۹۵/۶۰	—
[47]	CEEMD Preprocessing + RCMDE Feature + Different Feature Selection Methods + ANN Classifier	۹۹/۰۰	۹۸/۹۷
[48]	WPD Preprocessing + Energy and ApEn Features + E-LPP Feature Selection + LS-SVM Classifier	۹۹/۵۰	—
[49]	DWT Preprocessing + Statistical Features + CCP and PCA Feature Reduction + LSTM Classifier	۹۹/۰۰	—
[50]	STFT Preprocessing + Haralick's Texture Feature from Beta Sub-Band + DT Classifier	۹۲/۵۰	—
[51]	ECT Preprocessing + Graph Theory and FD Features + RF Classifier	۹۸/۵۰	—
[52]	Clustering and Covariance Matrix Preprocessing + Statistical Features + Non-Parametric Tests Feature Selection + AB-LS-SVM Classifier	۹۹/۰۰	—
روش پیشنهادی	TQWT Preprocessing + Different Features + AE Feature Reduction + SVM-GOA Classifier	۹۹/۴۲	۹۹/۲۳

طب داخلی روز

$$\mu(d_{ij}^m, n, r) = e^{-\frac{(d_{ij}^m)^n}{r}}$$

به طوری که  $r$  و  $n$  گرادیان و عرض تابع نموداری از پیش تعریف شده هستند،  $D_{ij}^m$  حداکثر اختلاف مطلق بین  $X_{jm}^m$  و  $X_{im}^m$  هستند. تابع به صورت فرمول شماره ۱۸ تعریف می‌شود [۲۶].

۱۸.

$$\varnothing^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left( \frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right)$$

به طوری که طول دنباله‌ها با  $m$  نشان داده می‌شود،  $x_0(i)$  یک خط میناست [۲۶].

$D_{ij}^m(n, r)$  درجه تشابه با استفاده از تابع عضویت فازی  $\mu(D_{ij}^m, n, r)$  برای بردار  $X_{jm}^m$  و  $X_{im}^m$  جایگزین تابع هوی ساید است (فرمول شماره ۱۷) [۲۶].

۱۷.

لایه‌های پیشنهادی برای کاهش ویژگی استفاده شده است. بر خلاف تکنیک‌های مرسوم، به عنوان مثال، PCA، کاهش ویژگی روش AE عملکرد بالاتری دارد [۲۸]. AE پیشنهادی دارای هفت لایه است. تصویر شماره ۵ AE را با لایه‌های پیشنهادی نشان می‌دهد. این روش یکی دیگر از نوآوری‌های مقاله است. در این بخش، ۱۵۳ ویژگی به ۳۲ ویژگی کاهش یافت.

### طبقه‌بندی

#### ماشین بردار پشتیبان

SVM یکی از طبقه‌بندی‌کننده‌های برجسته مورد استفاده در حوزه یادگیری ماشین است. ایده اصلی SVM ایجاد ابرصفحه جداکننده بهینه در فضای ویژگی است که حاشیه بین نزدیک‌ترین نقاط داده هر کلاس و ابرصفحه را به حداکثر می‌رساند. در حالت تفکیک‌ناپذیری خطی، از توابع هسته برای نگاشت نمونه‌ها در یک فضای ویژگی با ابعاد بالاتر استفاده می‌شود که در آن داده‌ها به صورت خطی قابل تفکیک می‌شوند [۲۹].

#### بهینه‌سازی GOA

SVM یکی از محبوب‌ترین روش‌های طبقه‌بندی است. با بهینه‌سازی پارامترهای مهم این روش از جمله هسته آن، می‌توان دقت سیستم CAD برای تشخیص صرع را بهبود بخشید. در ادامه این بخش، الگوریتم GOA با رویکرد بهینه‌سازی روش طبقه‌بندی SVM تشریح می‌شود.

مدل اعمال شده برای شبیه‌سازی رفتار و حرکت ملخ‌ها به صورت فرمول شماره ۲۴ ارائه شده است [۲۱].

۲۴

$$mX_i(t+1) = SI(t) + Gi(t) + Ai(t),$$

$$i=1,2,\dots,nPop \quad t=1,2,\dots,tMax$$

از روابط مذکور، هر یک از پارامترها به صورت زیر تعریف می‌شوند:

$$X_i(t): \text{موقعیت ملخ } \alpha_m \text{ در تکرار } t\alpha_m;$$

$$S_i(t): \text{تعامل اجتماعی ملخ } \alpha_m \text{ در تکرار } t\alpha_m;$$

$$G_i(t): \text{نیروی گرانش روی ملخ } \alpha_m \text{ در تکرار } t\alpha_m;$$

$$A_i(t): \text{فرارفت باد روی ملخ } \alpha_m \text{ در تکرار } t\alpha_m.$$

در ادامه هر یک از تعاریف مذکور به تفصیل مورد بررسی قرار می‌گیرد. تعامل اجتماعی ملخ با فرمول شماره ۲۵ محاسبه می‌شود [۲۱].

۲۵

دنباله‌های  $\{X_i^{(m+1)}\}$  با تنظیم  $m \leftarrow m+1$  تولید می‌شوند و  $\mathcal{O}^m(n,r)$  پس از آن ساخته می‌شوند. سری زمانی برای ورودی  $x(i)$  برای  $FuzzyEn, \mathcal{O}^m(n,r)$  با انحراف از  $\mathcal{O}^{(m+1)}(n,r)$  تولید می‌شود که در فرمول شماره ۱۹ نشان داده شده است [۲۶].

۱۹

$$FuzzyEn(m,n,t,N) = \ln \mathcal{O}^m(n,r) - \ln \mathcal{O}^{(m+1)}(n,r)$$

#### آنتروپی بازگشتی

معادله آنتروپی بازگشتی به صورت فرمول شماره ۲۰ است

[۲۶].

۲۰

$$E^{re} = - \sum_{n=n_{min}}^N R(n) \ln[R(n)]$$

به طوری که  $R(n)$  توزیع فرکانس طول  $n$  خطوط مورب است

[۲۶].

#### آنتروپی طیفی

SEN به صورت فرمول شماره ۲۱ نشان داده می‌شود [۲۶].

۲۱

$$SEN = \sum_f p_f \log\left(\frac{1}{p_f}\right)$$

#### آنتروپی نمودار

یک روش جدید استخراج ویژگی مبتنی بر نظریه گراف در این بخش ارائه شده است. آنتروپی مبتنی بر نظریه گراف در فرمول شماره ۲۲ و ۲۳ ارائه شده است [۲۷].

۲۲

$$H_n(m) = - \frac{\ln(m!)}{(\sum_{i=p}^m p(\pi_i) \log(p(\pi_i)))}$$

۲۳

$$H_n(m) = - \frac{\ln(m!)}{(\sum_{i=p}^m p(\pi_i) \log(p(\pi_i)))}$$

#### کاهش ویژگی با استفاده از AutoOencOder

کاهش ویژگی یکی از مراحل مهم در سیستم CADs تشخیص بیماری است. هدف اصلی کاهش ویژگی، اعمال ویژگی‌های مهم در ورودی الگوریتم‌های طبقه‌بندی است [۲۸]. این امر سرعت طبقه‌بندی و دقت داده‌های ورودی را افزایش می‌دهد [۲۸]. کاهش ویژگی به طور منظم با یادگیری ماشین معمولی و تکنیک‌های DL انجام می‌شود. در این مقاله از مدل AE و تعداد



می‌کنیم (فرمول شماره ۳۰) [۲۱].

۳۰

$$Xi = \sum_{j=1 (j \neq i)}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_i(t) - x_j(t)}{d_{ij}(t)} + T_d(t)$$

در معادله مذکور، پارامترهای جدید به صورت زیر بیان می‌شوند [۲۱]:

$ub_d$ : کران بالایی در بعد  $d$ ،  $lb_d$ : کران پایینی در بعد  $d$  است [۲۱].

$T_d(d)$ : مقدار بهترین راه‌حل به دست آمده (تا تکرار  $d$ ) در بعد  $d$  و همچنین  $C$  به عنوان ضریب کاهشی در نظر گرفته می‌شود [۲۱].

فرمول شماره ۳۱ موقعیت بعدی ملخ بیان می‌کند [۲۱].

۳۱

$$Xi = \sum_{j=1 (j \neq i)}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_i(t) - x_j(t)}{d_{ij}(t)} + T_d(t)$$

در معادله مذکور،  $x_i^d(t+1)$  موقعیت بعدی ملخ  $x_i(t)$ ،  $x_j(t)$  موقعیت فعلی ملخ  $x_j(t)$ ،  $i$  موقعیت همه ملخ‌های دیگر و در نهایت  $T_d(t)$  موقعیت هدف است [۲۱].

بحث بعدی در مورد پارامتر  $C$  است. به‌روزرسانی پارامتر  $C$  با فرمول شماره ۳۲ انجام می‌شود [۲۱].

۳۲

$$C = C_{max} - t \frac{C_{max} - C_{min}}{t_{Max}}$$

در این معادله،  $C_{max}$  به عنوان حداکثر مقدار  $C$  (معمولاً نزدیک به ۱)،  $C_{min}$  حداقل مقدار  $C$  (معمولاً نزدیک به صفر مثبت)،  $t$  تکرار فعلی و در نهایت،  $t_{Max}$  حداکثر تکرار است. پارامتر مقایسه‌ای  $C$  دو بار در این فرمول به دست می‌آید که دلایل آن به صورت زیر توضیح داده شده است [۲۱].

$C$  اول: بین اکتشاف و بهره‌برداری تعادل برقرار می‌کند. این  $C$  شباهت زیادی به پارامتر  $w$  در الگوریتم بهینه‌سازی PSO دارد [۲۱].

$C$  دوم: منطقه جذب، منطقه آسایش و منطقه دافعه بین ملخ‌ها را کاهش می‌دهد [۵۷] (فرمول شماره ۳۳).

۳۳

$$Xi = \sum_{j=1 (j \neq i)}^{nPop} \frac{ub_d - lb_d}{2} s(|x_i(t) - x_j(t)|) \frac{x_i(t) - x_j(t)}{d_{ij}(t)} + T_d(t)$$

Nearest Neighbor - K- نزدیک‌ترین همسایه

KNN یک الگوریتم ساده است که تمام موارد موجود را ردیابی می‌کند و موارد جدید بر اساس توابع فاصله طبقه‌بندی می‌شوند

$$S_i = \sum_{j=1 (j \neq i)}^{nPop} s(d_{ij}) (d_{ij}) d_{ij}$$

$d_{ij}$ : فاصله بین ملخ  $i$  و  $j$ ، محاسبه شده به صورت  $|x(i) - x(j)|$

$d_{ij}^*$ : بردار واحدی از ملخ  $i$  به ملخ  $j$  که به صورت  $(x(i) - x(j))/d_{ij}$  محاسبه می‌شود.

$S$ : تابعی برای تعریف قدرت نیروهای اجتماعی که به صورت فرمول شماره ۲۶ توضیح داده شده است.

۲۶

$$s(d) = fe^{\frac{d}{l}} - e^{-d}$$

که در آن  $f$  نشانگر شدت جاذبه و  $l$  مقیاس طول جذاب است. تابع  $s$  تأثیر تعاملات اجتماعی (دافعه و جاذبه) ملخ‌ها را نشان می‌دهد. تصویر شماره ۶ الگوهای اصلاحی اولیه بین افراد را در دسته‌ای از ملخ‌ها نشان می‌دهد [۲۱]. تصویر شماره ۶ الگوهای اصلاحی اولیه بین افراد در یک دسته ملخ را نشان می‌دهد [۲۱].

نیروی گرانش روی ملخ  $i$  به صورت فرمول شماره ۲۷ تعریف می‌شود.

۲۷

$$G_i = -ge_g$$

به طوری که  $g$  نیروی گرانش است و  $eg$  نشان‌دهنده یک بردار واحد به سمت مرکز زمین است.

فرارفت باد روی ملخ  $i$  به صورت فرمول شماره ۲۸ محاسبه می‌شود [۲۱].

۲۸

$$A_i = -ue_w$$

که  $u$  رانش ثابت و  $e_w$  بردار واحد باد است. حال با توجه به تعاریف به کاررفته، فرمول شماره ۲۹ ارائه می‌شود [۲۱].

۲۹

$$Xi = \sum_{j=1 (j \neq i)}^{nPop} s(|x(i) - x(j)|) \frac{x(i) - x(j)}{d_{ij}} - ge_g - ue_w$$

معادله مذکور را نمی‌توان به عنوان یک مسئله بهینه‌سازی استفاده کرد، زیرا الگوریتم را از کاوش و بهره‌برداری مناسب در فضای جست‌وجو در اطراف یک راه حل منع می‌کند. دلیل دوم این است که این معادله برای مدل‌سازی فضای باز است. برای اصلاح معادله مذکور و ارائه یک مدل عملکردی از الگوریتم GOA برای به‌روزرسانی مکان هر ملخ، آن را به صورت زیر بازنویسی

۳۵

$$Spec = \frac{TN}{FP+TN}$$

۳۶

$$Prec = \frac{TP}{TP+FN}$$

۳۷

$$FS = \frac{2TP}{2TP+FP+FN}$$

### یافته‌ها

نتایج روش پیشنهادی در این بخش ارائه شده است. به منظور پیاده‌سازی روش پیشنهادی، از سیستمی مجهز به رم ۱۶ گیگابایتی، پردازنده گرافیکی Nvidia 1070 و CPU Core i7 استفاده شده است. MATLAB 2019a برای اجرای بخش‌های پیش‌پردازش و استخراج ویژگی استفاده شده است. همچنین، روش AE و تکنیک‌های طبقه‌بندی با استفاده از جعبه ابزار پایتون، کراس و Sk-learn پیاده‌سازی شده است [۳۲-۳۳].

در روش پیشنهادی، از مجموعه داده بن برای تشخیص تشنج صرع استفاده شده است. همان‌طور که در جدول شماره ۲ نشان داده شده است، از شش مسئله طبقه‌بندی مختلف استفاده کرده‌ایم. ابتدا، سیگنال‌های الکتروانسفالوگرافی مجموعه داده بن به پنجره‌های زمانی پنج‌ثانیه‌ای تجزیه می‌شوند. در ادامه، تبدیل موجک عامل Q قابل تنظیم برای تجزیه سیگنال‌های الکتروانسفالوگرافی به زیرباندهای فرکانسی مختلف استفاده شده است. در ادامه، ویژگی‌های مختلف آماری و غیرخطی از زیرباندهای تبدیل موجک عامل Q قابل تنظیم استخراج شده است. در این بخش تعداد ۱۵۳ ویژگی از زیرباندهای موجک استخراج شده است. در مرحله بعد از روش AE و تعداد لایه‌های پیشنهادی برای کاهش ویژگی استفاده شده است. با استفاده از روش AE، تعداد ویژگی‌ها به X کاهش یافت. در نهایت الگوریتم‌های مختلفی برای طبقه‌بندی استفاده شده است.

هنگامی که از الگوریتم‌های بهینه‌سازی در یادگیری ماشینی (از جمله طبقه‌بندی داده‌های پزشکی) استفاده می‌شود، محققان اغلب روش پیشنهادی را چندین بار در شرایط یکسان برای به دست آوردن نتایج معتبر انجام می‌دهند. بدین منظور در بخش تجربی، تمامی الگوریتم‌های طبقه‌بندی را ده بار در شرایط مشابه انجام داده‌ایم تا نتایج معتبری به دست آوریم. نتایج هر الگوریتم طبقه‌بندی برای حالت‌های طبقه‌بندی مختلف در جدول شماره ۴ نشان داده شده است. با توجه به جدول شماره ۴، روش SVM-GOA توانسته است به دقت بالاتری نسبت به سایر الگوریتم‌های طبقه‌بندی کننده دست یابد.

[۳۰] KNN در تشخیص الگو و تخمین آماری به عنوان یک روش ناپارامتریک استفاده شده است. رأی اکثریت همسایه‌ها برای طبقه‌بندی یک مورد، در نظر گرفته می‌شود و با اندازه‌گیری تابع فاصله یک کلاس به یک مورد اختصاص می‌یابد. مزایای KNN شامل این موارد است: ۱. اجرای آن آسان و ساده است. ۲. الگوریتم را می‌توان برای جست‌وجو، رگرسیون و همچنین طبقه‌بندی استفاده کرد. ۳. نیازی به تنظیم پارامترها، ایجاد فرضیات اضافی یا ساخت مدل نیست. نقطه ضعف الگوریتم این است که با افزایش تعداد متغیرهای مستقل یا پیش‌بینی کننده‌ها، عملکرد الگوریتم به طور قابل توجهی کاهش می‌یابد.

### جنگل تصادفی<sup>۲۳</sup>

تفسیرپذیری درختان تصمیم<sup>۲۴</sup> و دوره منطقی آموزش آن‌ها همواره توجه محققان را به خود جلب کرده است، اما یکی از مشکلات این روش‌ها همیشه برآزش بیش از حد بوده است. جنگل تصادفی یکی از روش‌هایی است که برای حل مشکل برآزش بیش از حد در DTها معرفی شده است. به دلیل دقت بالا، سرعت یادگیری مناسب و توانایی تفکیک داده‌ها در فضاهای با ابعاد بالا، به سرعت جایگاه خود را در بین محققان پیدا کرد. با آموزش چندین درخت تصمیم‌گیری مختلف و رأی دادن در میان آن‌ها، این مدل‌ها در برابر نویزها و داده‌های پرت می‌توانند قوی‌تر باشند [۳۱].

### پارامترهای آماری

نتایج طبقه‌بندی با استفاده از روش اعتبارسنجی متقاطع دبرابری ارزیابی می‌شود. عملکرد الگوریتم با استفاده از معیارهای ارزیابی مانند اختصاصیت<sup>۲۵</sup>، حساسیت<sup>۲۶</sup>، دقت<sup>۲۷</sup> و F1-ScOre (F-S) برآورد شد. این اصطلاحات از ماتریس درهم‌ریختگی استخراج می‌شوند: مثبت درست<sup>۲۸</sup>، منفی غلط<sup>۲۹</sup>، منفی درست<sup>۳۰</sup> و مثبت غلط<sup>۳۱</sup> (فرمول‌های شماره ۳۳ تا ۳۷) [۲۲].

۳۳

$$Acc = \frac{TP+TN}{FP+FN+TP+TN}$$

۳۴

$$Sens = \frac{TP}{TP+FN}$$

23. Random Forest (RF)
24. Random forest (DTs)
25. Specialty (Spec)
26. Sensitive (Sens)
27. Accuracy (ACC)
28. True-Positive (TP)
29. False-Negative (FN)
30. True-Negative (TN)
31. False-Positive (FP)

## بحث

تشنج صرع مقایسه می‌کند.

با توجه به جدول شماره ۵، نتایج روش پیشنهادی به دلیل روش‌های پیش‌پردازش مناسب، استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی، دقیق‌تر از سایر مطالعات است. روش پیشنهادی را می‌توان بر روی یک پلت‌فرم سخت‌افزاری یا نرم‌افزاری برای کمک به پزشکان در تشخیص تشنج‌های صرع پیاده‌سازی کرد. تحقیقات آینده می‌تواند بر روی تکنیک‌های جدید DL، مانند یادگیری توجه، نمودار، و یادگیری q و غیره برای تشخیص تشنج‌های صرع با استفاده از سیگنال‌های الکتروانسفالوگرافی تمرکز کند [۵۶-۶۰]. تکنیک‌های همجوشی و ویژگی عمیق را نیز می‌توان در مطالعات آینده مورد بررسی قرار داد و ترکیبی از ویژگی‌های دست‌ساز را می‌توان همراه با تکنیک‌های DL برای تشخیص تشنج‌های صرعی به کار برد [۶۱-۶۳].

## ملاحظات اخلاقی

### پیروی از اصول اخلاق پژوهش

این پژوهش از یک پایان‌نامه استخراج شده است و نیازی به تأیید اخلاقی نبود.

### حامی مالی

این مطالعه از هیچ سازمانی حمایت مالی و عملکردی دریافت نکرده است.

### مشارکت نویسندگان

همه نویسندگان سهم یکسانی در تهیه این مقاله داشتند.

### تعارض منافع

بنابر اظهار نویسندگان این مقاله تعارض منافع ندارد.

### تشکر و قدردانی

نویسندگان از همکاری معاونت پژوهشی دانشگاه آزاد اسلامی واحد گناباد تشکر و قدردانی می‌کنند.

صرع به عنوان یک فعالیت غیرطبیعی در مغز که به عنوان یک اختلال عصبی شناخته می‌شود و باعث تشنج یا دوره‌های رفتار غیرطبیعی، احساسات و گاهی اوقات بیهوشی می‌شود در نظر گرفته می‌شود [۴-۱]. یکی از متداول‌ترین روش‌های تصویربرداری عصبی عملکردی در تشخیص اپیزودهای صرع، ثبت سیگنال‌های الکتروانسفالوگرافی است. سیگنال‌های الکتروانسفالوگرافی می‌تواند محل دقیق صرع را مشخص کند و ثبت آن نسبت به سایر روش‌های تصویربرداری عصبی هزینه کمتری دارد [۴-۱]. علاوه بر این، سیگنال‌های الکتروانسفالوگرافی با وجود مزایایی که دارند، چالش‌های مختلفی را برای پزشکان ایجاد می‌کنند. ثبت سیگنال‌های الکتروانسفالوگرافی بیماران به روشی طولانی‌مدت برای تشخیص تشنج‌های صرع انجام می‌شود که پزشکان را در مکان‌یابی دقیق بیماری به چالش می‌کشد. تشخیص تشنج‌های صرع دشوار است، زیرا قرائت‌های سیگنال‌های الکتروانسفالوگرافی اغلب حاوی انواع ناهنجاری‌های داخلی و خارجی هستند. بنابراین یک روش جدید برای تشخیص تشنج صرع در این مطالعه بر اساس تکنیک‌های ML و DL برای غلبه بر این چالش‌ها ارائه شده است.

## نتیجه‌گیری

پیش‌پردازش تبدیل موجک عامل Q قابل تنظیم، استخراج ویژگی‌های آماری و غیرخطی، کاهش ویژگی AE و طبقه‌بندی SVM-GOA در این مطالعه برای تشخیص تشنج‌های صرع از سیگنال‌های الکتروانسفالوگرافی استفاده می‌شوند. در مرحله اول از پایگاه داده بن برای پیاده‌سازی روش پیشنهادی استفاده می‌شود. سپس سیگنال‌های الکتروانسفالوگرافی در بخش پیش‌پردازش به فواصل پنج‌ثانیه‌ای تقسیم می‌شوند و از تبدیل موجک عامل Q قابل تنظیم برای تجزیه و تحلیل آن‌ها به زیرباندهای خود استفاده می‌شود که پارامترهای آن‌ها در  $t=3$ ،  $Q=1$  و  $J=8$  تنظیم شده است. مرتبط‌ترین ویژگی‌های آماری و غیرخطی از هر زیرباند تبدیل موجک عامل Q قابل تنظیم در مرحله استخراج ویژگی بازیابی می‌شوند. سیگنال‌های الکتروانسفالوگرافی رفتار آشفته‌ای دارند و اتخاذ ویژگی‌های توصیف‌شده در این مطالعه، دقت تشخیص تشنج‌های صرعی را بهبود بخشیده است. در مرحله کاهش ویژگی از روش AE مبتنی بر DL استفاده شده است که برای اولین بار توسط این مقاله با تعداد لایه‌های پیشنهادی به عنوان اولین نوآوری این مطالعه ارائه شده است. در نهایت از روش‌های مختلف ML در مرحله طبقه‌بندی برای انجام مقایسه‌ها استفاده شد. استفاده از روش طبقه‌بندی SVM-GOA نوآوری این بخش است که توسط محققین ارائه شده است. جدول شماره ۵ نتایج روش پیشنهادی را با روش‌های دیگر با استفاده از سیگنال‌های سیگنال‌های الکتروانسفالوگرافی برای تشخیص

## References

- [1] Shoeibi A, Khodatars M, Ghassemi N, Jafari M, Moridian P, Alizadehsani R, et al. Epileptic seizures detection using deep learning techniques: A review. *International Journal of Environmental Research and Public Health*. 2021; 18(11):5780. [DOI:10.3390/ijerph18115780] [PMID] [PMCID]
- [2] Shoeibi A, Ghassemi N, Khodatars M, Jafari M, Moridian P, Alizadehsani R, et al. Applications of epileptic seizures detection in neuroimaging modalities using deep learning techniques: Methods, challenges, and future works. *arXiv preprint arXiv:2105.14278*. 2021. <https://arxiv.org/pdf/2105.14278.pdf>
- [3] Subasi A. Epileptic seizure detection using dynamic wavelet network. *Expert Systems with Applications*. 2005; 29(2):343-55. [DOI:10.1016/j.eswa.2005.04.007]
- [4] Subasi A, Ercebebi E, Alkan A, Koklukaya E. Comparison of subspace-based methods with AR parametric methods in epileptic seizure detection. *Computers in Biology and Medicine*. 2006; 36(2):195-208. [DOI:10.1016/j.compbiomed.2004.11.001] [PMID]
- [5] Alizadehsani R, Roshanzamir M, Hussain S, Khosravi A, Koohestani A, Zangoeei MH, et al. Handling of uncertainty in medical data using machine learning and probability theory techniques: A review of 30 years (1991–2020). *Annals of Operations Research*. 2021:1-42. [DOI:10.1007/s10479-021-04006-2] [PMID] [PMCID]
- [6] Siddiqui MK, Morales-Menendez R, Huang X, Hussain N. A review of epileptic seizure detection using machine learning classifiers. *Brain Informatics*. 2020; 7(1):5. [DOI:10.1186/s40708-020-00105-1] [PMID] [PMCID]
- [7] Piccialli F, Di Somma V, Giampaolo F, Cuomo S, Fortino G. A survey on deep learning in medicine: Why, how and when? *Information Fusion*. 2021; 66:111-37. [DOI:10.1016/j.inffus.2020.09.006]
- [8] Akay A, Hess H. Deep learning: Current and emerging applications in medicine and technology. *IEEE Journal of Biomedical and Health Informatics*. 2019; 23(3):906-20. [DOI:10.1109/JBHI.2019.2894713] [PMID]
- [9] Srinivasan V, Eswaran C, Sriraam N. Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems*. 2005; 29(6):647-60. [DOI:10.1007/s10916-005-6133-1] [PMID]
- [10] Faust O, Acharya UR, Min LC, Spath BH. Automatic identification of epileptic and background EEG signals using frequency domain parameters. *International Journal of Neural Systems*. 2010; 20(2):159-76. [DOI:10.1142/S0129065710002334] [PMID]
- [11] Li M, Sun X, Chen W, Jiang Y, Zhang T. Classification epileptic seizures in EEG using time-frequency image and block texture features. *IEEE Access*. 2019; 8:9770-81. [DOI:10.1109/ACCESS.2019.2960848]
- [12] Yuan Q, Zhou W, Liu Y, Wang J. Epileptic seizure detection with linear and nonlinear features. *Epilepsy & Behavior*. 2012; 24(4):415-21. [DOI:10.1016/j.yebeh.2012.05.009] [PMID]
- [13] Goodfellow I, Bengio Y, Courville A. *Deep learning*. United States: MIT press; 2016. [https://books.google.com/books/about/Deep\\_Learning.html?id=Np9SDQAAQBAJ](https://books.google.com/books/about/Deep_Learning.html?id=Np9SDQAAQBAJ)
- [14] Emami A, Kunii N, Matsuo T, Shinozaki T, Kawai K, Takahashi H. Autoencoding of long-term scalp electroencephalogram to detect epileptic seizure for diagnosis support system. *Computers in Biology and Medicine*. 2019; 110:227-33. [DOI:10.1016/j.compbiomed.2019.05.025] [PMID]
- [15] Jaafar ST, Mohammadi M. Epileptic seizure detection using deep learning approach. *UHD Journal of Science and Technology*. 2019; 3(2):41-50. [DOI:10.21928/uhdjs.v3n2y2019.pp41-50]
- [16] Shahbazi M, Aghajani H. A generalizable model for seizure prediction based on deep learning using CNN-LSTM architecture. *IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2018 Nov 26, Anaheim, CA, USA. [DOI:10.1109/GlobalSIP.2018.8646505]
- [17] Truong ND, Kavehei O. Low precision electroencephalogram for seizure detection with convolutional neural network. *IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)*, 2019 Mar 18, Taiwan. [DOI:10.1109/AICAS.2019.8771569]
- [18] Zhou M, Tian C, Cao R, Wang B, Niu Y, Hu T, et al. Epileptic seizure detection based on EEG signals and CNN. *Frontiers in Neuroinformatics*. 2018; 12:95. [DOI:10.3389/fninf.2018.00095] [PMID] [PMCID]
- [19] Movahedi F, Coyle JL, Sejdić E. Deep belief networks for electroencephalography: A review of recent contributions and future outlooks. *IEEE Journal of Biomedical and Health Informatics*. 2017; 22(3):642-52. [DOI:10.1109/JBHI.2017.2727218] [PMID] [PMCID]
- [20] Selesnick IW. Wavelet transform with tunable Q-factor. *IEEE Transactions on Signal Processing*. 2011; 59(8):3560-75. [DOI:10.1109/TSP.2011.2143711]
- [21] Abualigah L, Diabat A. A comprehensive survey of the Grasshopper optimization algorithm: Results, variants, and applications. *Neural Computing and Applications*. 2020; 32(19):15533-56. [DOI:10.1007/s00521-020-04789-8].
- [22] Department of Epileptology University of Bonn. EEG time series data. Bonn: Department of Epileptology University of Bonn, Germany; 2015. [http://epileptologie-bonn.de/cms/front\\_content.php?idcat=193&lang=3&changelang=3](http://epileptologie-bonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3) [accessed September, 2015]
- [23] Sameer M, Gupta B. Detection of epileptic seizures based on alpha band statistical features. *Wireless Personal Communications*. 2020; 115(2):909-25. [DOI:10.1007/s11277-020-07852-8]
- [24] Esteller R, Vachtsevanos G, Echaz J, Litt B. A comparison of wave-form fractal dimension algorithms. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*. 2001; 48(2):177-83. [DOI:10.1109/81.904882]
- [25] Madan S, Srivastava K, Sharmila A, Mahalakshmi P. A case study on Discrete Wavelet Transform based Hurst exponent for epilepsy detection. *Journal of Medical Engineering & Technology*. 2018; 42(1):9-17. [DOI:10.1080/03091902.2017.1394390] [PMID]
- [26] Acharya UR, Hagiwara Y, Koh JE, Oh SL, Tan JH, Adam M, et al. Entropies for automated detection of coronary artery disease using ECG signals: A review. *Biocybernetics and Biomedical Engineering*. 2018; 38(2):373-84. [DOI:10.1016/j.bbe.2018.03.001]
- [27] Mohammadpoory Z, Nasrolahzadeh M, Haddadnia J. Epileptic seizure detection in EEGs signals based on the weighted visibility graph entropy. *Seizure*. 2017; 50:202-8. [DOI:10.1016/j.seizure.2017.07.001] [PMID]
- [28] Wang Y, Yao H, Zhao S. Auto-encoder based dimensionality reduction. *Neurocomputing*. 2016; 184:232-42. [DOI:10.1016/j.neucom.2015.08.104]
- [29] William SN, Teukolsky SA. What is a support vector machine. *Nat Biotechnol*. 2006; 24(12):1565-7. [DOI:10.1038/nbt1206-1565] [PMID]
- [30] Keller JM, Gray MR, Givens JA. A fuzzy k-nearest neighbor algorithm. *IEEE Transactions on Systems, Man, and Cybernetics*. 1985; 15(4):258-63. [DOI:10.1109/TSMC.1985.6313426]

- [31] Oshiro TM, Perez PS, Baranauskas JA. How many trees in a random forest? International workshop on machine learning and data mining in pattern recognition. Berlin, Heidelberg: Springer; 2012. [DOI:10.1007/978-3-642-31537-4\_13]
- [32] Ketkar N. Introduction to GPUs. Deep learning with Python. 1th ed. Berkeley, CA: Apress; 2017. [DOI:10.1007/978-1-4842-2766-4\_10]
- [33] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine learning in Python. The Journal of Machine Learning Research. 2011; 12:2825-30. <https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf?ref=https://githubhelp.com>
- [34] Ghassemi N, Shoeibi A, Rouhani M, Hosseini-Nejad H. Epileptic seizures detection in EEG signals using TQWT and ensemble learning. 9th International Conference on Computer and Knowledge Engineering (ICCKE), 2019 Oct 24, Mashhad, Iran. [DOI:10.1109/ICCKE48569.2019.8964826]
- [35] Nishad A, Pachori RB. Classification of epileptic electroencephalogram signals using tunable-Q wavelet transform based filter-bank. Journal of Ambient Intelligence and Humanized Computing. 2020. [DOI:10.1007/s12652-020-01722-8]
- [36] Sharaf AI, El-Soud MA, El-Henawy IM. An automated approach for epilepsy detection based on tunable Q-wavelet and firefly feature selection algorithm. International Journal of Biomedical Imaging. 2018; 2018:5812872. [DOI:10.1155/2018/5812872] [PMID] [PMCID]
- [37] Gupta V, Bhattacharyya A, Pachori RB. Classification of seizure and non-seizure EEG signals based on EMD-TQWT method. 22nd International Conference on Digital Signal Processing (DSP), 2017 Aug 23, London, United Kingdom. [DOI:10.1109/ICDSP.2017.8096036]
- [38] Reddy GR, Rao R. Automated identification system for seizure EEG signals using tunable-Q wavelet transform. Engineering Science and Technology, an International Journal. 2017; 20(5):1486-93. [DOI:10.1016/j.jestch.2017.11.003]
- [39] Ramos-Aguilar R, Olvera-López JA, Olmos-Pineda I, Sánchez-Urrieta S. Feature extraction from EEG spectrograms for epileptic seizure detection. Pattern Recognition Letters. 2020; 133:202-9. [DOI:10.1016/j.patrec.2020.03.006]
- [40] Chen S, Zhang X, Chen L, Yang Z. Automatic diagnosis of epileptic seizure in electroencephalography signals using nonlinear dynamics features. IEEE Access. 2019; 7:61046-56. [DOI:10.1109/ACCESS.2019.2915610]
- [41] Tuncer T, Dogan S, Akbal E. A novel local senary pattern based epilepsy diagnosis system using EEG signals. Australasian Physical & Engineering Sciences in Medicine. 2019; 42(4):939-48. [DOI:10.1007/s13246-019-00794-x] [PMID]
- [42] Gupta V, Pachori RB. Epileptic seizure identification using entropy of FBSE based EEG rhythms. Biomedical Signal Processing and Control. 2019; 53:101569. [DOI:10.1016/j.bspc.2019.101569]
- [43] Raghu S, Sriraam N, Hegde AS, Kubben PL. A novel approach for classification of epileptic seizures using matrix determinant. Expert Systems with Applications. 2019; 127:323-41. [DOI:10.1016/j.eswa.2019.03.021]
- [44] Sharma S, Bhatia V, Gupta A. Noncoherent IR-UWB receiver using massive antenna arrays for wireless sensor networks. IEEE Sensors Letters. 2017; 2(1):1-4. [DOI:10.1109/LENS.2017.2778430]
- [45] Abedin MZ, Akther S, Hossain MS. An artificial neural network model for epilepsy seizure detection. 5th International Conference on Advances in Electrical Engineering (ICAEE) 2019 Sep 26, Dhaka, Bangladesh. [DOI:10.1109/ICAEE48663.2019.8975569]
- [46] Tzimourta KD, Tzallas AT, Giannakeas N, Astrakas LG, Tsalikakis DG, Angelidis P, et al. A robust methodology for classification of epileptic seizures in EEG signals. Health and Technology. 2019; 9(2):135-42. [DOI:10.1007/s12553-018-0265-z]
- [47] Singh G, Kaur M, Singh B. Detection of epileptic seizure EEG signal using multiscale entropies and complete ensemble empirical mode decomposition. Wireless Personal Communications. 2021; 116(1):845-64. [DOI:10.1007/s11277-020-07742-z]
- [48] Liu Y, Jiang B, Feng J, Hu J, Zhang H. Classification of EEG signals for epileptic seizures using feature dimension reduction algorithm based on LPP. Multimedia Tools and Applications. 2021; 80(20):30261-82. [DOI:10.1007/s11042-020-09135-7]
- [49] Aliyu I, Lim CG. Selection of optimal wavelet features for epileptic EEG signal classification with LSTM. Neural Computing and Applications. 2021. [DOI:10.1007/s00521-020-05666-0]
- [50] Sameer M, Gupta B. Beta band as a biomarker for classification between interictal and ictal states of epileptical patients. 7th International Conference on Signal Processing and Integrated Networks (SPIN), 2020 Feb 27, Noida, India. [DOI:10.1109/SPIN48934.2020.9071343]
- [51] Qureshi MB, Afzaal M, Qureshi MS, Fayaz M. Machine learning-based EEG signals classification model for epileptic seizure detection. Multimedia Tools and Applications. 2021; 80(12):17849-77. [DOI:10.1007/s11042-021-10597-6]
- [52] Al-Hadeethi H, Abdulla S, Diykh M, Deo RC, Green JH. Adaptive boost LS-SVM classification approach for time-series signal classification in epileptic seizure diagnosis applications. Expert Systems with Applications. 2020; 161:113676. [DOI:10.1016/j.eswa.2020.113676]
- [53] Whitley D. A genetic algorithm tutorial. Statistics and Computing. 1994; 4(2):65-85. [DOI:10.1007/BF00175354]
- [54] Zhou C, Gao HB, Gao L, Zhang WG. Particle swarm optimization (PSO) algorithm. Application Research of Computers. 2003; 12:7-11.
- [55] Settles M, Soule T. Breeding swarms: A GA/PSO hybrid. 7th annual conference on genetic and evolutionary computation, 2005 Jun 25, New York, United States. [DOI:10.1145/1068009.1068035]
- [56] Khodatars M, Shoeibi A, Sadeghi D, Ghassemi N, Jafari M, Moridian P, et al. Deep learning for neuroimaging-based diagnosis and rehabilitation of autism spectrum disorder: A review. Computers in Biology and Medicine. 2021; 139:104949 [DOI:10.1016/j.combiomed.2021.104949] [PMID]
- [57] Shoeibi A, Sadeghi D, Moridian P, Ghassemi N, Heras J, Alizadehsani R, et al. Automatic diagnosis of schizophrenia using EEG signals and CNN-LSTM models. Frontiers in Neuroinformatics. 2021; 15:777977 [DOI:10.3389/fninf.2021.777977] [PMID] [PMCID]
- [58] Shoeibi A, Khodatars M, Jafari M, Moridian P, Rezaei M, Alizadehsani R, et al. Applications of deep learning techniques for automated multiple sclerosis detection using magnetic resonance imaging: A review. Computers in Biology and Medicine. 2021; 136:104697. [DOI:10.1016/j.combiomed.2021.104697] [PMID]
- [59] Sadeghi D, Shoeibi A, Ghassemi N, Moridian P, Khadem A, Alizadehsani R, et al. An overview on artificial intelligence techniques for diagnosis of schizophrenia based on magnetic resonance imaging modalities: Methods, challenges, and future works. arXiv preprint arXiv:2103.03081. 2021. <https://arxiv.org/abs/2103.03081>
- [60] Alizadehsani R, Sharifrazi D, Izadi NH, Joloudari JH, Shoeibi A, Gorriz JM, et al. Uncertainty-aware semi-supervised method using large unlabeled and limited labeled COVID-19 data. ACM Transactions on Multi-

- media Computing, Communications, and Applications. 2021; 17(3s):1-24. [DOI:10.1145/3462635]
- [61] Yang J, Yao S, Wang J. Deep fusion feature learning network for MI-EEG classification. IEEE Access. 2018; 6:79050-9. [DOI:10.1109/ACCESS.2018.2877452]
- [62] Amin SU, Alsulaiman M, Muhammad G, Mekhtiche MA, Hossain MS. Deep Learning for EEG motor imagery classification based on multi-layer CNNs feature fusion. Future Generation Computer Systems. 2019; 101:542-54. [DOI:10.1016/j.future.2019.06.027]
- [63] Hu D, Cao J, Lai X, Wang Y, Wang S, Ding Y. Epileptic state classification by fusing hand-crafted and deep learning EEG features. IEEE Transactions on Circuits and Systems II: Express Briefs. 2020; 68(4):1542-6. [DOI:10.1109/TCSII.2020.3031399]