



# تشخیص صرع در سیگنال EEG با استفاده از الگوریتم ابتکاری صفحات شیب‌دار (IPO)

محمد رضا اسماعیلی سعادت‌قلی\* و سید حمید ظهیری ممقانی

گروه الکترونیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه بیرجند، بیرجند، ایران



## چکیده

طبق مطالعات انجام‌شده، در حدود یک درصد از مردم دنیا از صرع رنج می‌برند. نخستین مرحله از درمان صرع، تشخیص صحیح آن است. یکی از راه‌های تشخیص صرع، تحلیل دقیق الکتروانسفالوگرافی (EEG) است. بدین‌منظور، روش‌های مختلفی جهت تشخیص خودکار صرع به‌وسیله تحلیل سیگنال EEG ارائه شده است. در این مقاله با استفاده از یک الگوریتم هوشمند و ابتکاری جدید به نام الگوریتم بهینه‌سازی صفحات شیب‌دار (IPO)، به تشخیص و جداسازی سیگنال EEG آغشته به صرع از سیگنال‌های افراد سالم پرداخته‌ایم. به‌دلیل خاصیت غیرخطی و ناایستای سیگنال EEG، از تبدیل موجک جهت استخراج ویژگی‌های سیگنال بهره گرفته شده است؛ سپس با استفاده از ویژگی‌های استخراج‌شده توسط تبدیل موجک و اعمال آن به سامانه مبتنی بر الگوریتم IPO به تشخیص صرع پرداخته شده است. با استناد به پژوهش انجام‌شده، مشخص شد که الگوریتم ابتکاری IPO توانایی بالایی در تشخیص صحیح صرع در سیگنال EEG دارد.

واژگان کلیدی: الکتروانسفالوگرافی، تشخیص صرع، تبدیل موجک گسسته، الگوریتم‌های ابتکاری، الگوریتم بهینه‌سازی صفحات شیب

## Epileptic seizure detection using Inclined Planes system Optimization algorithm (IPO)

Mohammad Reza Esmaili Saadatgholi\* & Seyed Hamid Zahiri Mamaghani

Department of Electronic, Faculty of Electrical and Computer, University of Birjand, Birjand, Iran

### Abstract

Epilepsy is a neurological disorder after stroke. About 1 percent of people in the world are involved with this second most common neurological disorder. Epilepsy can affect people of different ages with an altered behavior or lack of patient awareness and affect one's social life. In 75% of cases, if epilepsy is diagnosed early and properly, it can be treated.

Among all existing methods of analysis for the detection of epileptic brain activity, EEG is more applicable, due to its special features (including its low-cost and innocuous). Despite all the advantages of this method, the visual scoring of the EEG records by a human scorer is clearly a very time consuming and costly task considering the large number of epileptic patients admitted to the hospitals and the amount of data needs to be scored. Thus, a tremendous effort has been devoted by researchers towards automatic epileptic seizures detection in EEG.

This paper offers a novel method based on heuristic and intelligent algorithms, inclined planes system



optimization (IPO), to detect epileptic samples from healthy subjects. Like other heuristic algorithms, IPO is inspired by nature and its laws. How to move sphere objects on the slope without friction and their desire to reach the lowest point, shapes the main idea of the IPO. In the IPO, small balls like particles in the PSO are placed randomly on the search space. The balls search the search space to find the optimal point which is the lowest point (relative to a reference point) on the surface.

In the current work, the data described by Andrzejak et al. was used; which contains 5 sets (Z, O, N, F and S). In this work, three different classification problems are created from the above dataset in order to compare the performance of our method with other approaches:

1. In the first, two sets were examined, normal (set Z) and seizure (set S).
2. In the second, four sets of the dataset were used and they were classified into two different classes: non-seizure (sets Z, N, F) and seizure (set S).
3. In the third, all the EEGs from the dataset were used and they were classified into two different classes: sets Z, O, N and F are included in the non-seizure class and set S in the seizure class.

The EEG signal under study is firstly decomposed into five sub-bands through DWT (D1–D4 and A4), and each sub-band represents different frequency bands information. Afterwards, four statistical parameters of *maximum*, *minimum*, *average* and *standard deviation* were calculated for each sub-band. And then, using the optimization algorithm IPO, the best weights are calculated to apply to the OVA classifier in order to find the best hyper plane separating the two classes. The fitness function defined in the IPO algorithm, is the number of signals that have been classified incorrectly.

To classify EEG signals in three problems, the 10-fold Cross-Validation method is used. In this method, the data is divided into 10 subsections. And then, one subset is used for test and nine others for training. This procedure is repeated 10 times, until all the data is used for testing. The proposed algorithm have been implemented 10 times for the two wavelet functions Db1 and db2. Using the proposed method, the accuracy obtained for the three problems is 100%, 98/1%, 97/34%, respectively. Also by the proposed method diagnosis of epilepsy can be achieved very quickly. The results show that the algorithm is capable of detecting signals of epileptic and non-epileptic in less than 5 milliseconds. This makes it possible to use this method in real-time systems.

**Keywords:** Electroencephalogram (EEG), Epileptic seizure detection, Discrete wavelet transform (DWT), Heuristic algorithm, Inclined planes system optimization algorithm (IPO)

از بین روش‌های موجود تحلیل فعالیت‌های مغزی جهت تشخیص صرع، استفاده از نوار مغزی EEG، به دلیل ویژگی‌های خاص خود (از جمله کم‌هزینه و بی‌ضرر بودن) کاربرد بیشتری دارد. گرفتن نوار مغزی، یک آزمایش بی‌خطر و بدون درد برای بیمار است که اطلاعات زیادی را برای پزشک معالج مهیا می‌سازد، به علاوه ساختار ساده سامانه ثبت EEG، استفاده از آن را نسبت به سایر روش‌ها کم هزینه و راحت‌تر کرده است.

با وجود تمام مزیت‌های گفته شده، مطالعه و مشاهده بصری EEG جهت تشخیص صرع، به دلیل حجم بالای EEG‌های ضبط شده، بسیار وقت‌گیر و زمان‌بر است. به طوری که تجزیه و تحلیل این سیگنال‌ها و شناسایی حمله ناگهانی و تشخیص صرع حتی برای یک نورولوژیست مجرب از روی بررسی چشمی و بصری، از بزرگ‌ترین چالش‌هایی است که متخصصان با آن دست‌به‌گریبانند، با این وجود خطای انسانی نیز بر عدم تشخیص صحیح صرع در سیگنال EEG می‌افزاید. همچنین با توجه به این که سیگنال‌های زیستی از جمله سیگنال EEG بسیار ذهنی هستند، بنابراین ممکن

## ۱- مقدمه

صرع یک اختلال عصبی است که پس از سکته مغزی دومین اختلال عصبی رایج در انسان به‌شمار می‌رود و در حدود یک درصد از مردم دنیا را درگیر کرده است [1]. صرع می‌تواند در سنین مختلف اتفاق افتاده و مبتلایان را تحت تأثیر قرار دهد و موجب تغییر حالت و رفتار و یا عدم هوشیاری بیمار شود [2] و بر زندگی اجتماعی فرد تأثیر منفی بگذارد. یک‌بار تشنج به معنی آن نیست که فرد صرع دارد، بلکه فرد باید با دو تا سه تشنج بی‌دلیل روبه‌رو شود تا پزشک تشخیص صرع را بدهد [3]. در ۷۵٪ از موارد، اگر صرع به‌موقع و صحیح تشخیص داده شود، می‌توان آن را درمان کرد. بسته به میزان درگیری مناطق مختلف مغز در طول تشنج، صرع را می‌توان به دو نوع اصلی تقسیم کرد [4]:

الف) صرع عمومی: یکی از رایج‌ترین انواع صرع محسوب می‌شود که در آن تمام مغز درگیر اختلال الکتریکی می‌شود.

ب) صرع موضعی: که از یک منطقه محدود از مغز سرچشمه می‌گیرد و محدود به همین منطقه می‌شود.

تبدیل مولتی ویولت و محاسبه آنتروپی تقریبی جهت استخراج و انتخاب ویژگی استفاده شده است؛ سپس این ویژگی‌ها به یک شبکه عصبی مصنوعی جهت طبقه‌بندی داده شده‌اند. در [10] استفاده از روش‌های تخمین طیفی  $^{1}EV$  و MUSIC جهت استخراج ویژگی برگزیده شده است؛ سپس ویژگی‌های انتخاب‌شده به ورودی یک شبکه عصبی جهت طبقه‌بندی سیگنال‌های سالم و صرعی اعمال شده‌اند. در [11] از تبدیل موجک و الگوریتم خوشه‌بندی K-means بهره گرفته شده است و با اعمال آن به ورودی یک شبکه عصبی مصنوعی به تشخیص صرع پرداخته شده است. در [12] از ترکیب الگوریتم ابتکاری جستجوی هارمونی<sup>۹</sup> و شبکه ANFIS<sup>۱۰</sup> جهت طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی بهره گرفته شده است. در [13] نیز تبدیل موجک و تحلیل غیرخطی RQA<sup>۱۱</sup> جهت استخراج ویژگی به کار برده شده‌اند؛ سپس این ویژگی‌ها به یک طبقه‌بند ECOC<sup>۱۲</sup> جهت تشخیص سیگنال‌های صرعی اعمال گردیده‌اند.

در این مقاله روشی جدید مبتنی بر الگوریتم ابتکاری و هوشمند صفحات شیب‌دار (IPO)<sup>۱۳</sup> که بر پایه دینامیک حرکت توپ‌ها بر روی صفحات شیب‌دار است، جهت تشخیص نمونه‌های صرعی از نمونه‌های سالم و غیر صرعی ارائه شده است.

پیکربندی این مقاله بدین صورت است که در بخش ۲ داده‌های مورد استفاده در این مقاله و طرح مسئله معرفی شده است. در بخش ۳ روش پیشنهادی بر مبنای الگوریتم IPO توضیح داده شده و در بخش ۴ نتایج ارائه شده است. و در نهایت بخش ۵ مقایسه صحت روش پیشنهادی با کارهای انجام‌شده در گذشته را در بر می‌گیرد. پیشنهادهایی جهت بهبود کارایی الگوریتم نیز در این بخش گنجانده شده است.

## ۲- داده‌های مورد استفاده

در این مقاله از داده‌هایی که به‌صورت رایگان توسط آندژیاک و همکاران [14] بر روی اینترنت قرار گرفته، استفاده شده است، که شامل ۵ گروه (S, F, N, O, Z) است. هر گروه داده شامل یکصد نمونه تک‌کاناله از سیگنال EEG با طول

است در یک سیگنال یکسان نیز اختلاف نظر وجود داشته باشد. بدین معنی که متخصصی تشخیص صرع بدهد در حالی که متخصص دیگری خلاف این نظر را داشته باشد، مگر اینکه علایم بالینی بیمار نیز مورد توجه قرار گیرد.

دلایل گفته شده و همچنین اهمیت تشخیص سریع و صحیح صرع جهت درمان آن، پژوهش‌گران را بر آن داشته است تا از روش‌های خودکار جهت تشخیص صرع در سیگنال‌های الکتروانسفالوگرافی بهره ببرند.

پژوهش‌ها بر روی سیگنال‌های الکتروانسفالوگرافی و تشخیص خودکار صرع، از سال ۱۹۷۰ آغاز شده و تا کنون روش‌های متفاوتی جهت تشخیص صرع از روی این سیگنال‌ها ارائه شده است. در [5] از تبدیل موجک و محاسبه انرژی ضرایب موجک به‌عنوان ویژگی و اعمال این ویژگی‌ها به چند طبقه‌بند مختلف از جمله، ماشین بردار پشتیبان<sup>۱</sup>، دو نوع شبکه عصبی مصنوعی، و شبکه عصبی فازی استفاده شده است. که بالاترین صحت به‌دست آمده در این پژوهش، با استفاده از شبکه عصبی فازی محقق شده است. در [6] از تبدیل موجک و اعمال ویژگی‌های آماری استخراج‌شده از آن مانند بیشینه و کمینه ضرایب موجک و میانگین و انحراف از معیار این ضرایب، به شبکه عصبی مصنوعی بهره گرفته شده است. در [7] از توزیع زمان فرکانس شبه واینر ویل نرم شده<sup>۲</sup> و تقسیم صفحات زمان-فرکانس به‌دست آمده، به بخش‌های مختلف استفاده شده است؛ سپس با محاسبه انرژی در هر بخش ویژگی‌ها استخراج شده‌اند. در ادامه با استفاده از الگوریتم PCA<sup>۳</sup> تعداد ویژگی‌ها کاهش یافته و در نهایت نیز با استفاده از یک شبکه عصبی مصنوعی اقدام به دسته‌بندی داده‌ها شده است.

در [8] با روش تعمیم‌یافته تبدیل موجک<sup>۴</sup> و استفاده از آنتروپی تقریبی جهت استخراج ویژگی و انتخاب ویژگی‌های استخراج‌شده، به‌وسیله الگوریتم ژنتیک<sup>۵</sup> و اعمال آن به یک شبکه کوانتیزه‌کننده برداری<sup>۶</sup>، به تشخیص صرع اقدام شده است. [4] تبدیل موجک و استخراج پارامتری به نام طول خط<sup>۷</sup> از ضرایب موجک و ترکیب آن با شبکه عصبی مصنوعی را مبنای کار خود جهت تشخیص صرع قرار داده است. در پژوهش دیگری که در [9] انجام شده است، از

<sup>1</sup> Support Vector Machine

<sup>2</sup> Smoothed Pseudo-Wigner-Ville Distribution

<sup>3</sup> Principal Component Analysis

<sup>4</sup> Wavelet Pocket Decomposition

<sup>5</sup> Genetic Algorithm

<sup>6</sup> Learning Vector Quantization

<sup>7</sup> Line Length

<sup>8</sup> Eigenvector

<sup>9</sup> Harmony Search

<sup>10</sup> Adaptive Neuro-Fuzzy Inference System

<sup>11</sup> Recurrence Quantification Analysis

<sup>12</sup> Error-Correction Output Codes

<sup>13</sup> Inclined Planes system Optimization algorithm

۲۳/۶ ثانیه با نرخ نمونه‌برداری ۱۷۳/۶۱ هرتز است که از سیگنال‌های الکتروانسفالوگرافی پیوسته جدا شده‌اند. گروه Z و O شامل نمونه‌های افراد سالم در حالت آرامش با چشم‌های باز (Z) و چشم‌های بسته (O) است. گروه‌های N و F نمونه‌های ضبط‌شده از بیماران در فواصل حملات صرع هستند. گروه S نیز شامل سیگنال‌های الکتروانسفالوگرافی افراد در حین حملات صرع بوده که توسط دستگاه EEG ضبط شده است. تمام سیگنال‌های مورد استفاده توسط سامانه‌های یکسان ضبط شده و با نرخ ۱۷۳/۶۱ نمونه بر ثانیه و دقت دوازده بیت گسسته‌سازی شده‌اند. نمونه‌ای از هر گروه در شکل (۱) نشان داده شده است.

در این مقاله سه مسئله طبقه‌بندی متفاوت جهت بررسی کارایی الگوریتم پیشنهادی، ارائه شده است:

- (۱) مسئله نخست دو طبقه Z (نمونه‌های سالم) و S (نمونه‌های صرعی) را مورد بررسی قرار می‌دهد.
- (۲) در مسئله دوم، چهار گروه از داده‌ها مورد استفاده قرار گرفته‌اند که به دو طبقه صرعی و غیر صرعی طبقه‌بندی می‌شوند. طبقه صرعی شامل گروه S (۱۰۰ نمونه) و طبقه غیر صرعی شامل گروه‌های Z، N و F (۳۰۰ نمونه) است.
- (۳) و در نهایت مسئله سوم که هر پنج گروه Z، O، N، F و S را شامل می‌شود که به دو طبقه صرعی و غیر صرعی طبقه‌بندی می‌شوند. طبقه صرعی، گروه S (۱۰۰ نمونه) و طبقه غیر صرعی، چهار گروه Z، O، N و F (۴۰۰ نمونه) را شامل می‌شوند.

### ۳- روش کار

#### ۳-۱- تبدیل موجک گسسته (DWT)<sup>۱</sup>

به دلیل ماهیت سیگنال‌های EEG و با در نظر داشتن این نکته که این سیگنال‌ها اطلاعات زیادی را در حوزه زمان و فرکانس دارند، استفاده از تبدیلاتی مانند تبدیل فوریه<sup>۲</sup> و تبدیل موجک که اطلاعات فرکانسی و زمانی و یا هر دو را به دست می‌دهند، می‌تواند سودمند باشد.

تبدیل فوریه تنها بیان‌کننده این است که فرکانس مشخصی در سیگنال حضور دارد یا خیر؛ اما هیچ اطلاعاتی در مورد بازه زمانی متناظر با پدیداری آن فرکانس در اختیار نمی‌گذارد. وضوح رزولوشن زمانی در حوزه فرکانس و وضوح

فرکانسی در حوزه زمان در این تبدیل برابر صفر است. تبدیل فوریه زمان کوتاه<sup>۳</sup> نیز در واقع نوعی از تبدیل فوریه است که در آن طول پنجره ثابت و دارای ابعاد محدودی است و فقط از بخشی از سیگنال که در داخل پنجره قرار دارد تبدیل فوریه گرفته می‌شود. از آن جا که در تبدیل فوریه زمان کوتاه، پنجره زمانی ثابت است، باید مصالحه‌ای بین وضوح زمانی و وضوح فرکانسی برقرار کرد. که این کار در مورد سیگنال‌های نایستایی<sup>۴</sup> همانند سیگنال الکتروانسفالوگرافی نتیجه خوبی را به دست نمی‌دهد. بر خلاف تبدیل فوریه و تبدیل فوریه زمان کوتاه، تبدیل موجک به دلیل پنجره با طول متغیر، توانایی استخراج اطلاعات فرکانسی و زمانی از یک سیگنال پیچیده و نایستا همچون سیگنال EEG را دارد. یکی از ویژگی‌های برجسته تبدیل موجک، ارائه اطلاعات فرکانسی دقیق در فرکانس‌های پایین و اطلاعات زمانی دقیق در فرکانس‌های بالا است [15]. رابطه تبدیل موجک پیوسته به صورت زیر نوشته می‌شود [16]:

$$CWT(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} X(t) \Psi^*\left(\frac{t - \tau}{s}\right) dt \quad (1)$$

که در آن s و  $\tau$  پارامترهای مقیاس و انتقال می‌باشند و  $\Psi$  تابع موجک مادر است که ویژگی‌های تبدیل موجک را مشخص می‌کنند. از آنجا که در سامانه‌های دیجیتال نیاز به گسسته‌سازی مقادیر داریم، بنابراین از تبدیل موجک گسسته استفاده می‌کنیم. اگر s و  $\tau$  را اعداد گسسته‌ای به صورت زیر در نظر بگیریم:

$$\begin{aligned} \tau_{j,k} &= 2^j k \quad j, k \in Z \\ s_j &= 2^j \end{aligned} \quad (2)$$

آنگاه می‌توان تبدیل موجک گسسته را به صورت زیر تعریف کرد [16]:

$$DWT(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{\infty} X(t) \Psi^*\left(\frac{t - 2^j k}{2^j}\right) dt \quad (3)$$


یک روش مؤثر جهت اعمال تبدیل موجک گسسته، استفاده از فیلترهای بالاگذر و پایین‌گذر است [17] که در اصطلاح روش بانک فیلتر گفته می‌شود (شکل ۲).

<sup>3</sup> Short-Time Fourier Transform


<sup>4</sup> Non-Stationary

<sup>1</sup> Discrete Wavelet Transform


<sup>2</sup> Fourier Transform



(شکل-۱): نمونه‌ای از سیگنال EEG گروه‌های Z تا S  
(Figure-1): A sample of EEG signals (set Z to S)



(شکل-۲): روش بانک فیلتر در تجزیه سیگنال  $x[n]$  به زیر باندهایش  
(Figure -2): Sub-band decomposition of DWT implementation



(شکل-۳): سیگنال نمونه‌ای از یک فرد سالم (گروه Z) و زیر باندهای مربوط به آن  
(Figure-3): A sample signal of a Normal person (set z) and related sub-bands

طریقه کار بدین صورت است که ابتدا سیگنال ورودی از دو فیلتر بالاگذر و پایین گذر  $H[n]$  و  $G[n]$  به طور موازی عبور داده می شود. خروجی فیلتر بالاگذر را جزئیات<sup>۱</sup> و خروجی فیلتر پایین گذر را تقریب<sup>۲</sup> می گویند. بعد از اعمال مرحله نخست تجزیه، ضرایب  $A1$  و  $D1$  که ضرایب موجک گرفته می شوند، به دست می آیند. در مرحله بعد خروجی فیلتر پایین گذر مرحله نخست دوباره به دو فیلتر بالاگذر و پایین گذر اعمال می شود و ضرایب  $A2$  و  $D2$  تولید می شوند. ضرایب  $A1, D1, A2, D2$  معرف محتویات فرکانسی سیگنال به ترتیب در فرکانس های  $0$  تا  $\frac{f_s}{4}$  (یک چهارم فرکانس نمونه برداری)،  $\frac{f_s}{4}$  تا  $\frac{f_s}{2}$ ،  $\frac{f_s}{2}$  تا  $\frac{3f_s}{4}$  و  $\frac{3f_s}{4}$  تا  $f_s$  می باشند. در تبدیل موجک گسسته به روش گفته شده، انتخاب تابع موجک و دفعات تجزیه از اهمیت ویژه ای برخوردار است. سطوح تجزیه به نوع سیگنال و کاربرد بستگی دارد و تابع موجک مناسب نیز با آزمون و خطا به دست می آید. در این مقاله از تابع موجک  $db1$  و  $db2$  و چهار مرحله تجزیه بهره گرفته شده است [4] و [18]. پس از اعمال چهار مرحله تجزیه، چهار زیرباند جزئیات  $D1$  تا  $D4$  و یک زیرباند تقریب  $A4$  تولید می شوند که هر کدام اطلاعات بازه فرکانسی خاصی را در خود جای داده اند. جدول (۱) باندهای فرکانسی هر مرحله را نشان می دهد.

(جدول-۱): باندهای فرکانسی به دست آمده پس از چهار مرحله

تجزیه سیگنال EEG

(Table-1): Frequency bands of EEG signals with four-level DWT decomposition

باند فرکانسی (هرتز)	زیر سیگنال
86.8 – 43.4	D1
43.4 – 21.7	D2
21.7 – 10.8	D3
10.8 – 5.4	D4
5.4 – 0	A4

شکل (۳) نیز سیگنال اصلی و زیر سیگنال های تولید شده را برای نمونه ای از سیگنال EEG فرد سالم نشان می دهد.

به جهت کاهش ابعاد ویژگی، چهار پارامتر آماری زیر از هر زیرباند تولید شده ( $D1-D2-D3-D4-A4$ ) استخراج می شود [19]:

- (الف) بیشینه ضرایب موجک در هر زیرباند
- (ب) کمینه ضرایب موجک در هر زیرباند
- (ج) میانگین ضرایب موجک در هر زیرباند
- (د) انحراف از معیار ضرایب موجک در هر زیرباند

جدول (۲)، مقادیر بیشینه، کمینه، میانگین و انحراف از معیار به دست آمده پس از اعمال تبدیل موجک  $db1$  به ترتیب برای یک سیگنال نمونه گروه  $Z, O, N, F, S$  را نشان می دهد. همان طور که از این جدول برمی آید، مشاهده می شود که مقادیر به دست آمده به قدر کافی متمایز هستند که بتوان از آن ها به عنوان ویژگی برای ورودی یک طبقه بند استفاده کرد.

(جدول-۲): مقادیر به دست آمده حاصل از ضرایب موجک برای

یک نمونه از گروه های  $Z, O, N, F, S$

(Table-2): The Statistical values of the samples from five sets

انحراف معیار	میانگین	کمینه	بیشینه	گروه	زیر باند
13.75	-0.01	-43.95	51.26	Z	D1
16.88	-0.005	-53.31	57.63	O	
6.12	0	-23.51	21.8	N	
6.05	-0.009	-22.61	25.26	F	
55.73	-0.01	-131.9	252.59	S	
33.34	-0.15	-103.5	101.25	Z	D2
41.83	-0.04	-155.15	141.47	O	
16.27	0.01	-61.91	53.31	N	
16.44	-0.05	-55.59	75.24	F	
150.02	0.008	-345.15	560.25	S	
59.58	-0.99	-172.64	214.18	Z	D3
75.5	-5.29	-224.28	225.69	O	
39.17	-0.77	-157.15	124.91	N	
39.35	-0.85	-135.42	121.49	F	
381.23	2.53	-849.36	1388.9	S	
72.13	1.28	-307.89	245.84	Z	D4
90.2	5.74	-241.98	247.44	O	
88.61	-1.35	-255.17	294.72	N	
87.29	-3.94	-295.8	244.49	F	
771.45	-35.75	-1715.9	1576.7	S	
105.92	230.15	-122.94	512.7	Z	A4
100.1	29.69	-232.43	426.95	O	
244.18	-53.69	-703.75	759.04	N	
124.84	-41.84	-357.5	453.13	F	
987.62	-68.06	-2344.2	1880.9	S	

### ۳-۲- الگوریتم بهینه سازی صفحات

#### شیبدار (IPO)

الگوریتم بهینه سازی صفحات شیبدار نمونه ای از الگوریتم های ابتکاری و هوشمند است که جهت پیدا کردن

<sup>1</sup> Detail

<sup>2</sup> Approximation

که در آن  $f_i(t)$  مقدار تابع هدف برای توپ  $i$  در زمان  $t$  است. بنابر تجربه و آزمایش و برای کاهش حجم محاسباتی، جهت رسیدن به جواب‌های بهتر، شتاب هر توپ در هر بعد به صورت جدا از دیگر ابعاد محاسبه می‌شود. برای اینکه توپ‌ها به سمت پایین سرازیر شوند، در محاسبه شتاب آن‌ها، توپ‌هایی که در ارتفاع پایین‌تر قرار دارند در نظر گرفته می‌شوند. طبق قانون دوم نیوتن داریم:

$$\sum \vec{F} = m \cdot \vec{a} \quad (6)$$

همچنین طبق قوانین حرکت، شتاب به صورت زیر محاسبه می‌شود:

$$\alpha = g \cdot \sin(\phi) \quad (7)$$

که در آن  $g$  ثابت گرانش زمین است. در الگوریتم IPO با اعمال یک سری تغییرات، شتاب توپ  $i$  در زمان  $t$  در بعد  $d$  به صورت زیر محاسبه می‌شود:

$$\alpha_i^d(t) = \sum_{j=1}^N U(f_j(t) - f_i(t)) \cdot \sin(\phi_{ij}^d(t)) \quad (8)$$

که در آن  $U$  تابع پله واحد است. سرعت توپ  $i$  در بعد  $d$  ام نیز همانند قوانین حرکت به صورت زیر محاسبه می‌شود:

$$v = \frac{\Delta x}{\Delta t} \quad (9)$$

$$v_i^d(t) = \frac{x_{best}^d(t) - x_i^d(t)}{\Delta t} \quad (10)$$

که در آن  $x_{best}$  تویی است که بهترین برازندگی را در کل تکرارها دارد و برای اینکه توپ‌ها میل رسیدن به بهترین مقدار را داشته باشند، در صورت کسر قرار گرفته است. برای به روزرسانی موقعیت توپ‌ها نیز با الهام از قوانین حرکت داریم:

$$x_i^d(t+1) = k_1 r_1 \alpha_i^d(t) \Delta t^2 + k_2 r_2 v_i^d(t) \Delta t + x_i^d(t) \quad (11)$$

که در آن  $r_1$  و  $r_2$  دو عدد تصادفی در بازه  $[0, 1]$  هستند.  $k_1$  و  $k_2$  نیز دو ضریب جهت کنترل فرآیند الگوریتم هستند که در این مقاله پس از آزمون و خطا دو عدد ثابت در نظر گرفته شده‌اند.

نقاط بهینه یک مسئله به تازگی ارائه شده است [20]. الگوریتم‌های ابتکاری به طور معمول از پدیده‌های زیستی و یا اصول علم فیزیک سر منشأ می‌گیرند. مانند الگوریتم مورچگان که از رفتار مورچگان در جستجوی غذا الهام گرفته است [21]. و یا الگوریتم گروه ذرات که برگرفته از رفتار اجتماعی گروه پرندگان است [22]. همچنین الگوریتم جستجوی گرانشی که با الهام از نیروی گرانش بین کرات و اجسام، مسئله را به سمت بهترین جواب سوق می‌دهد [23].

همانند سایر الگوریتم‌های هوشمند، الگوریتم سامانه صفحات شیب‌دار که IPO نامیده می‌شود نیز از طبیعت و قوانین آن الهام گرفته است. نحوه حرکت دینامیکی اجسام کروی بر روی سطح شیب‌دار بدون اصطکاک و تمایل آن‌ها برای رسیدن به پایین‌ترین نقطه، ایده به کار برده شده در این الگوریتم است. در IPO، توپ‌های کوچک مانند ذرات در PSO به صورت تصادفی بر روی فضای جستجو قرار می‌گیرند. این توپ‌ها فضای جستجو را برای یافتن نقطه بهینه که همان پایین‌ترین نقطه (نسبت به یک نقطه مرجع) بر روی سطح است، جستجو می‌کنند. در این الگوریتم، به هر توپ یک ارتفاع نسبت داده می‌شود که این ارتفاع بر اساس تابع برازندگی هر توپ که جوابی شدنی از مسئله است به دست می‌آید. طبق قوانین فیزیکی، توپ‌ها تمایل دارند شتاب گرفته و انرژی پتانسیل خود را برای رسیدن به پایین‌ترین نقطه (کم‌تر شدن تابع برازندگی) از دست بدهند. بنابراین توپ‌ها به نسبت شتابی که می‌گیرند در فضای جستجو حرکت کرده و به سمت پاسخ بهتر سوق می‌یابند.

در این الگوریتم هر توپ سه مختصات دارد: موقعیت، ارتفاع و زاویه نسبت به توپ‌های دیگر. سامانه‌ای با  $N$  توپ را در نظر می‌گیریم. موقعیت و مکان توپ  $i$  ام به صورت زیر تعریف می‌شود:

$$\vec{x}_i = (x_i^1, \dots, x_i^d, \dots, x_i^n), i = 1, 2, \dots, N \quad (4)$$

$$x_j^{min} \leq x_j \leq x_j^{max}, 1 \leq j \leq n$$

که در آن  $x_i^d$  موقعیت توپ  $i$  ام در بعد  $d$  ام است. در یک زمان مشخص مانند  $t$ ، زاویه بین توپ  $i$  ام و توپ  $j$  ام در بعد  $d$ ، به صورت زیر محاسبه می‌شود:

$$\phi_{ij}^d(t) = \left( \tan^{-1} \left( \frac{f_j(t) - f_i(t)}{x_i^d(t) - x_j^d(t)} \right) \right) \quad (5)$$

for  $d = 1, \dots, n$   $i, j = 1, 2, \dots, N, i \neq j$

### ۳-۳- استفاده از الگوریتم IPO در طبقه‌بندی سیگنال EEG

ابتدا با اعمال تبدیل ویولت گسسته به سیگنال‌های خام الکتروانسفالوگرافی و تجزیه چهارسطحی این سیگنال‌ها، پنج زیر باندها D1، D2، D3، D4 و A4 که هر کدام شامل بخشی از اطلاعات سیگنال در بازه فرکانسی خاصی هستند، به دست می‌آیند. جهت کاهش ابعاد ویژگی‌های استخراج شده از تبدیل موجک، چهار پارامتر آماری بیشینه، کمینه، میانگین و انحراف از معیار برای هر زیر باندها محاسبه شده و در کل بیست ویژگی از هر سیگنال EEG استخراج می‌شود. حال با استفاده از الگوریتم بهینه‌سازی IPO بهترین وزن‌ها جهت طبقه‌بندی سیگنال‌ها توسط سامانه OVA محاسبه می‌شوند، تا بهترین ابرصفحه جداکننده دو طبقه مشخص شود. در این روش موقعیت هر توپ در الگوریتم نمایان‌گر وزن‌های مورد نظر هستند.

$$dx = [w_1, w_2, \dots, w_{21}] \times \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_{20} \\ 1 \end{bmatrix} \quad (12)$$

مقادیر  $f_1$  تا  $f_{20}$  ویژگی‌های استخراج شده و  $w_1$  تا  $w_{21}$  وزن‌های محاسبه شده به وسیله الگوریتم IPO هستند، به طوری که  $w_{21}$  وزن بایاس است. وزن‌ها باید به گونه‌ای انتخاب شوند که به ازای سیگنال‌های صرعی ورودی،  $dx$  بزرگتر از صفر شده و به ازای سیگنال‌های غیر صرعی، منفی باشد. تابع برازندگی تعریف شده در الگوریتم IPO نیز، تعداد سیگنال‌هایی است که به اشتباه طبقه‌بندی شده‌اند. بدین ترتیب الگوریتم به سمتی پیش می‌رود که این خطاها را به حداقل برساند و دقت طبقه‌بندی را افزایش دهد. شکل (۴) مراحل اجرای روش پیشنهادی را نشان می‌دهد.

### ۴- نتایج

جهت به دست آوردن صحت روش پیشنهادی در طبقه‌بندی سیگنال‌های الکتروانسفالوگرافی به دو طبقه صرعی و غیر صرعی در سه مسئله مطرح شده در بالا، از روش اعتبارسنجی 10-fold Cross-Validation استفاده شده است.

در این روش، داده‌ها به ده زیرمجموعه تقسیم می‌شوند (نسبت یک به ده از داده‌های هر گروه). از این ده زیرمجموعه، هر بار یکی برای آزمون و ۹ تای دیگر جهت آموزش به کار می‌روند. این روال ده بار تکرار می‌شود و همه داده‌ها به طور دقیق یک بار برای آزمون استفاده می‌شوند. میانگین نتیجه این ده بار اجرای برنامه به عنوان پاسخ یک بار اجرای الگوریتم در نظر گرفته می‌شود. روش پیشنهادی در نرم‌افزار MATLAB (R2013a) و سامانه‌ای با مشخصات، پردازشگر Cori7 Q720 با فرکانس کاری ۱/۶ گیگاهرتز و 4Gb حافظه رم، پیاده‌سازی و اجرا شده است. جمعیت اولیه در الگوریتم IPO نیز پنجاه توپ در نظر گرفته شده است.



(شکل-۴): نمودار مربوط به اجرای روش پیشنهادی بر مبنای

الگوریتم سیستم صفحات شیبدار (IPO)

(Figure – 4): Block diagram of the proposed method using IPO

جهت ارزیابی روش پیشنهادی در دسته‌بندی سیگنال‌های EEG به دو گروه صرعی و غیر صرعی، سه پارامتر ارزیابی به شرح زیر در نظر گرفته و محاسبه شده است:

صحت کلی (ACC)<sup>۲</sup>: نسبت مجموع نمونه‌های

<sup>2</sup> Accuracy

<sup>1</sup> One-Vs-All

در جدول (۴) نیز نرخ تشخیص صحیح داده‌های آزمون با روش پیشنهادی و با استفاده از تابع موجک db2 مشاهده می‌شود. صحت به‌دست‌آمده برای سه مسئله مطرح‌شده درحالی‌که از تابع موجک db2 استفاده کرده‌ایم، به‌ترتیب برابر ۱۰۰، ۹۸/۱ و ۹۷/۳۴ درصد است. همان‌طور که مشاهده می‌شود، صحت طبقه‌بندی دو گروه سالم و صرعی (Z-S) با استفاده از روش پیشنهادی و با تابع موجک db1 برابر حالتی است که از تابع موجک db2 استفاده کرده‌ایم. این در حالی است که طبقه‌بندی دو گروه ZNF و S با تابع موجک db2 نتایج بهتری دارد. این موضوع در مورد طبقه‌بندی دو گروه ZONF و S نیز صدق می‌کند.

(جدول-۳): نرخ تشخیص داده‌های آزمون به‌ازای تابع موجک db1 (%)

(Table-3): The performance evaluation parameters using db1 (%)

دسته	ACC	SEN	SPC	PPV
Z-S	100	100	100	100
ZNF-S	97.77	95.4	98.56	95.9
ZONF-S	96.96	94.6	97.55	91.06

(جدول-۴): نرخ تشخیص داده‌های آزمون به‌ازای تابع موجک db2 (%)

(Table-4): The performance evaluation parameters using db2 (%)

دسته	ACC	SEN	SPC	PPV
Z-S	100	100	100	100
ZNF-S	98.1	96.1	98.63	96.1
ZONF-S	97.34	95.3	97.85	92.19

شکل (۵) نمونه‌ای از اجرای الگوریتم جهت آموزش طبقه‌بندی دو گروه Z و S را نشان می‌دهد. همان‌طور که از این شکل دیده می‌شود، دست‌یابی به پاسخ بهینه در تکرارهای نخست، متضمن سرعت بالای الگوریتم در تشخیص صحیح سیگنال‌های سالم و صرعی است.

شکل (۶) و (۷) اجرای الگوریتم پیشنهادی را به‌ترتیب جهت آموزش طبقه‌بندی دو طبقه گروه‌های ZNF-S و طبقه‌بندی دو طبقه گروه‌های ZONF-S نشان می‌دهند. نزدیک شدن به نقطه بهینه در زمان کوتاه (تکرارهای اولیه)، در این دو شکل نیز مشخص است. در شکل‌های (۵)، (۶) و (۷) نقاط دایره، بیان‌گر میانگین برانندگی توپ‌های الگوریتم

صرعی که درست تشخیص داده شده‌اند (TP)<sup>۱</sup> و نمونه‌های غیرصرعی که به درستی تشخیص داده شده‌اند (TN)<sup>۲</sup> به مجموع کل نمونه‌های صرعی و غیرصرعی:

$$ACC = \frac{TN+TN}{TN+FP+FN+TP} \times 100 \quad (13)$$

حساسیت (SEN)<sup>۳</sup>: نسبت نمونه‌های صرعی که درست تشخیص داده شده‌اند (TP) به کل نمونه‌های صرعی واقعی:

$$SEN = \frac{TP}{FN+TP} \times 100 \quad (14)$$

ویژگی (SPC)<sup>۴</sup>: نسبت نمونه‌های غیرصرعی که به‌درستی تشخیص داده شده‌اند (TN) به کل نمونه‌های غیرصرعی واقعی:

$$SPC = \frac{TN}{TN+FP} \times 100 \quad (15)$$

مقدار پیش‌بینی مثبت (PPV)<sup>۵</sup>: نسبت نمونه‌های صرعی که به درستی تشخیص داده شده‌اند (TP)، به مجموع نمونه‌های صرعی که درست تشخیص داده شده‌اند و نمونه‌های غیرصرعی که اشتباه تشخیص داده شده‌اند (FP)<sup>۶</sup>:

$$PPV = \frac{TP}{TP+FP} \times 100 \quad (16)$$

الگوریتم پیشنهادی ده مرتبه برای دو تابع موجک db1 و db2 اجرا شده و میانگین جواب‌های به‌دست‌آمده به‌عنوان صحت طبقه‌بندی لحاظ شده‌اند. جداول (۳) و (۴) صحت روش پیشنهادی بر مبنای الگوریتم IPO را در تشخیص و جداسازی داده‌های آزمون به‌ترتیب برای دو تابع موجک db1 و db2 نشان می‌دهند.

جدول (۳) نرخ تشخیص صحیح داده‌های در نظر گرفته‌شده جهت آزمون، توسط روش پیشنهادی و استفاده از تابع موجک db1 را نشان می‌دهد. بر طبق این جدول، نرخ تشخیص سه مسئله مطرح‌شده در بالا، به‌ترتیب برابر ۱۰۰، ۹۷/۷۷ و ۹۶/۹۶ درصد است.

<sup>1</sup> True Positive

<sup>2</sup> True Negative


<sup>3</sup> Sensitivity

<sup>4</sup> Specificity

<sup>5</sup> Positive Predictive Value

<sup>6</sup> False Positive

مشاهده می‌شود که اعداد به دست آمده در هر سه مسئله به یکدیگر نزدیک بوده و به طور تقریبی برابر با چهار میلی‌ثانیه هستند. این امر به این دلیل است که پس از طی شدن مرحله آموزش، الگوریتم IPO به صورت موفقیت آمیز ابر صفحه جداکننده سیگنال‌های صرعی و غیرصرعی را محاسبه می‌کند و در مرحله اجرا دیگر هیچکدام از این هزینه‌های محاسباتی تکرار نمی‌شود و فقط کافی است که ویژگی‌های سیگنال ورودی استخراج شود و توسط ابر صفحه تخمین زده شده در مرحله قبل، تعیین علامت شود. بنابراین استخراج ویژگی و تعیین علامت یک سیگنال نمونه ورودی، برای هر سه مسئله ذکر شده، از لحاظ زمانی تفاوت چندانی با هم ندارند و همه در حدود چهار تا پنج میلی‌ثانیه به دست آمده‌اند.



(شکل-۷): نمونه‌ای از اجرای الگوریتم پیشنهادی جهت

طبقه‌بندی دو کلاس S و ZONF

(Figure-7): Example of the implementation of the proposed algorithm to classify two classes S and ZNF


(جدول-۵): میانگین زمان مورد نیاز الگوریتم پیشنهادی جهت تشخیص یک داده آزمون ورودی برای دو تابع موجک db2 و db1 بر حسب میلی‌ثانیه (ms)

(Table-5): Average time required by the proposed algorithm for classifying a test EEG input (ms)

دسته‌ها	Db1	Db2
Z-S	4.51	4.41
ZNF-S	4.54	4.64
ZONF-S	4.48	4.40

IPO در هر تکرار بوده و نقاط مشخص شده به صورت ستاره، بهترین برازندگی آن‌ها را در هر تکرار نشان می‌دهند. این سه شکل، برآمده از اجرای الگوریتم در یکصد تکرار نخست می‌باشند.


جدول (۵) نشان‌دهنده میانگین زمان سپری شده جهت تشخیص یک داده ورودی آزمون، برای طبقه‌بندی سیگنال EEG است. طبق این جدول مشاهده می‌شود که در هر سه مسئله مطرح شده، تشخیص صرع با الگوریتم پیشنهادی با سرعت بسیار بالایی صورت می‌گیرد. مشاهده می‌شود که این الگوریتم به طور میانگین قابلیت تشخیص سیگنال‌های صرعی و غیرصرعی را در زمانی کمتر از پنج میلی‌ثانیه دارد. این امر موجب می‌شود بتوان از این روش در تشخیص صرع در سامانه‌های بلادرنگ استفاده کرد.



(شکل-۵): نمونه‌ای از اجرای الگوریتم پیشنهادی جهت

طبقه‌بندی دو گروه S و Z

(Figure-5): Example of the implementation of the proposed algorithm to classify two sets Z and S



(شکل-۶): نمونه‌ای از اجرای الگوریتم پیشنهادی جهت

طبقه‌بندی دو کلاس S و ZNF

(Figure-6): Example of the implementation of the proposed algorithm to classify two classes S and ZNF

## ۵- مقایسه با کارهای انجام شده در گذشته

جدول (۶) مقایسه‌ای است از روش پیشنهادی در این مقاله با کارهای انجام شده توسط سایر پژوهش‌گران در گذشته. طبق این جدول، در نخستین مسئله مطرح شده که به طبقه‌بندی دو گروه سالم و صرعی (Z-S) می‌پردازد، روش پیشنهادی در این مقاله به همراه روش‌های [26]، [25]، [24]، [7]، بالاترین نرخ تشخیص را که همان یکصد درصد است دارد.

در مسئله دوم که شامل طبقه‌بندی دوطبقه چهار گروه (ZNF-S) است، روش پیشنهادی که بر مبنای الگوریتم ابتکاری IPO برنامه‌ریزی شده است، از صحت بالاتری نسبت به سایر کارهای انجام شده برخوردار است. به اضافه اینکه سرعت الگوریتم پیشنهادی در این مقاله نیز یکی از ویژگی‌های بارز آن است.

در مسئله سوم که طبقه‌بندی دوطبقه هر پنج گروه از داده‌ها (ZONF-S) را شامل می‌شود، روش پیشنهادی با نرخ مناسبی قادر به تشخیص دو گروه صرعی و غیرصرعی است. با وجود اینکه روش پیشنهادی به نسبت کارهای انجام شده، با اختلاف اندکی، ضعیف‌تر عمل می‌کند، اما بار محاسباتی کم و سرعت بالای روش پیشنهادی در تشخیص و دست‌یابی به پاسخ بهینه، می‌تواند یکی از ویژگی‌های روش پیشنهادی

باشد. به‌طور مثال در [26]، زمان مورد نیاز برای مسئله یک و سه، به ترتیب برابر ۶/۷ میلی‌ثانیه و ۱۴/۴ میلی‌ثانیه محاسبه شده است (مشخصات سیستم سامانه استفاده در مقاله مذکور مشابه سامانه استفاده شده در این مقاله است).

استفاده از روش‌های دیگر استخراج ویژگی همانند، استفاده از نماهای لیپانوف [27]، استفاده از روش آنتروپی تقریبی [28] و سایر روش‌های استخراج و انتخاب ویژگی ممکن است، در صحت و سرعت الگوریتم پیشنهادی تأثیر مثبت بگذارد. بنابراین به‌عنوان یکی از کارهایی که می‌توان در آینده جهت بهبود روش پیشنهادی انجام داد، استفاده از سایر روش‌های استخراج و انتخاب ویژگی است. در حین آزمایش و به‌صورت تجربی مشاهده شد که سرعت و صحت و به‌طور کلی، کارایی الگوریتم به نحو چشم‌گیری به مقادیر ضرایب  $k_1$  و  $k_2$  وابسته است و مقادیر این دو پارامتر، صحت الگوریتم را به شدت تحت تأثیر قرار می‌دهند؛ به‌طوری‌که انتخاب مقادیر نامناسب برای این دو پارامتر ممکن است الگوریتم را به کلی از جواب بهینه دور سازد. پژوهش بر روی تأثیر مقادیر  $k_1$  و  $k_2$  جهت بهبود نرخ تشخیص صحیح صرعی در سیگنال‌های الکتروانسفالوگرافی پیشنهاد دیگری است که می‌توان جهت بهبود کارایی روش ارائه شده در این مقاله ارائه داد. همچنین می‌توان روش پیشنهادی را بر روی پایگاه داده‌های دیگر و یا مسائل طبقه‌بندی دیگر از جمله تشخیص آلزایمر و... نیز مورد آزمون قرار داد.

(جدول-۶): مقایسه با برخی از کارهای انجام شده در گذشته

(Table-6): Comparison of the classification accuracy obtained by our method and some previous studies

صحت (%)	داده‌ها	روش	محققین
99.6	Z-S	ویژگی‌های زمان فرکانسی و شبکه عصبی Elman	سربینواسان و همکاران [29]
95	Z-S	تبدیل موجک و مدل ترکیب خبره	سوباسی [30]
98.72	Z-S	تبدیل فوریه سریع و درخت تصمیم	پولات و گونش [31]
100	Z-S	آنالیز زمان فرکانس و شبکه عصبی مصنوعی	تزالاس و همکاران [7]
95.2	Z-S	تبدیل فوریه و شبکه عصبی چند لایه	گو و همکاران [32]
99.6	Z-S	تبدیل موجک و ویژگی طول خط و شبکه عصبی	گو و همکاران [4]
100	Z-S	الگوریتم بهبود یافته MR بوسیله HS	گو و همکاران [24]
100	Z-S	وارپانس موجک و K نزدیک‌ترین همسایه	ژی و کریشنان [25]
100	Z-S	استفاده از تبدیل موجک DTCWT	چن [26]
100	Z-S	تبدیل موجک، الگوریتم ژنتیک و SVM	دیمان و ساینی [33]
100	Z-S	تبدیل موجک و الگوریتم IPO	روش پیشنهادی
96.65	ZNF-S	تبدیل موجک و آنتروپی تقریبی	اوجاک [28]

97.75	ZNF-S	تبدیل موجک و ویژگی طول خط و شبکه عصبی	گو و همکاران [4]
98.1	ZNF-S	تبدیل موجک و الگوریتم IPO	روش پیشنهادی
97.73	ZONF-S	آنالیز زمان فرکانس و شبکه عصبی مصنوعی	تزالیاس و همکاران [7]
98.27	ZONF-S	تبدیل مولتی و بولت، آنتروپی تقریب و شبکه عصبی	گو و همکاران [9]
98.66	ZONF-S	تبدیل موجک و شبکه عصبی WNN	زین‌الدین و همکاران [34]
100	ZONF-S	واریانس موجک و K نزدیک‌ترین همسایه	ژی و کریشنان [25]
100	ZONF-S	استفاده از تبدیل موجک DTCWT	چن [26]
97.34	ZONF-S	تبدیل موجک و الگوریتم IPO	روش پیشنهادی

یزدانیان از دانشگاه خواجه نصیرالدین طوسی، به‌خاطر راهنمایی‌های مفید و سودمندشان قدردانی کنیم.

## 7-References

## ۷-مراجع

- [1] E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, and A. J. Hudspeth, *Principles of neural science*. vol. 4, New York: McGraw-hill, 2000.
- [2] S. Sanei and J. A. Chambers, *EEG signal processing*. England: John Wiley & Sons, 2007.
- [3] E. Niedermeyer and F. L. da Silva, *Electroencephalography: basic principles, clinical applications, and related fields*. 5<sup>th</sup> ed. Lippincott Williams & Wilkins, 2005.
- [4] L. Guo, D. Rivero, J. Dorado, J. R. Rabunal, and A. Pazos, "Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks," *Journal of neuroscience methods*, vol. 191, pp. 101-109, 2010.
- [5] N. Sadati, H. R. Mohseni, and A. Maghsoudi, "Epileptic seizure detection using neural fuzzy networks," in *Fuzzy Systems, 2006 IEEE International Conference on*, 2006, pp. 596-600.
- [6] P. Jahankhani, V. Kodogiannis, and K. Revett, "EEG signal classification using wavelet feature extraction and neural networks," in *Modern Computing, 2006. JVA'06. IEEE John Vincent Atanasoff 2006 International Symposium on*, 2006, pp. 120-124.
- [7] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, "Automatic seizure detection based on time-frequency analysis and artificial neural networks," *Computational Intelligence and Neuroscience*, vol. 2007, 2007.
- [8] H. Ocak, "Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm," *Signal processing*, vol. 88,

## ۶-نتیجه‌گیری

بار محاسباتی کم و سرعت اجرای بالا در تشخیص نمونه‌های صرعی و غیرصرعی، یکی از مزیت‌های طبقه‌بند پیشنهادی در این مقاله است. به‌نحوی که می‌توان از آن در سامانه‌های برخط، جهت تشخیص صرع در سیگنال الکتروانسفالوگرافی استفاده کرد. همچنین جهت بهبود کارایی الگوریتم پیشنهادی، استفاده از روش‌های دیگر استخراج ویژگی همانند، استفاده از نماهای لیپانوف [27]، استفاده از روش آنتروپی تقریبی [28] و سایر روش‌های استخراج و انتخاب ویژگی و ترکیب آن با طبقه‌بند معرفی شده، ممکن است در صحت و سرعت الگوریتم پیشنهادی تأثیر مثبت بگذارد. بنابراین به‌عنوان یکی از کارهایی که می‌توان در آینده جهت بهبود روش پیشنهادی انجام داد، استفاده از سایر روش‌های استخراج و انتخاب ویژگی است. در حین آزمایش و به‌صورت تجربی مشاهده شد که سرعت و صحت و به‌طور کلی، کارایی الگوریتم به نحو چشم‌گیری به مقادیر ضرایب  $k_1$  و  $k_2$  وابسته است و مقادیر این دو پارامتر، صحت الگوریتم را به شدت تحت تأثیر قرار می‌دهند؛ به‌طوری که انتخاب مقادیر نامناسب برای این دو پارامتر ممکن است الگوریتم را به کلی از جواب بهینه دور سازد. پژوهش بر روی تأثیر مقادیر  $k_1$  و  $k_2$  جهت بهبود نرخ تشخیص صحیح صرع در سیگنال‌های الکتروانسفالوگرافی پیشنهاد دیگری است که می‌توان جهت بهبود کارایی روش ارائه‌شده در این مقاله ارائه داد. همچنین می‌توان روش پیشنهادی را بر روی پایگاه داده‌های دیگر و یا مسائل طبقه‌بندی دیگر از جمله تشخیص آلزایمر ... نیز مورد آزمون قرار داد.

## تقدیر و تشکر

در پایان لازم می‌دانیم از زحمات جناب آقای دکتر مصطفی الماسی از دانشگاه علوم پزشکی تهران و آقای مهندس حسن

فصلنامه



- fuzzy inference system for classification of EEG signals using wavelet coefficients," *Journal of neuroscience methods*, vol. 148, pp. 113-121, 2005.
- [20] M. H. Mozaffari and S. H. Zahiri, "Unsupervised Data and Histogram Clustering Using Inclined Planes System Optimization Algorithm," *Image Analysis & Stereology*, vol. 33, pp. 65-74, 2014.
- [21] M. Dorigo, "Optimization, learning and natural algorithms," Ph. D. Thesis, Politecnico di Milano, Milan, Italy, 1992.
- [22] J. Kennedy and R. Eberhart, "Particle swarm optimization," In *Proceedings of IEEE international conference on neural networks*, Perth, 1995, pp. 1942-1948.
- [23] E. Rashedi, H. Nezamabadi-Pour, and S. Saryazdi, "GSA: a gravitational search algorithm," *Information sciences*, vol. 179, pp. 2232-2248, 2009.
- [24] P. Guo, J. Wang, X. Z. Gao, and J. M. Tanskanen, "Epileptic EEG signal classification with marching pursuit based on harmony search method," in *Systems, Man, and Cybernetics (SMC), 2012 IEEE International Conference on*, 2012, pp. 283-288.
- [25] S. Xie and S. Krishnan, "Wavelet-based sparse functional linear model with applications to EEGs seizure detection and epilepsy diagnosis," *Medical & biological engineering & computing*, vol. 51, pp. 49-60, 2013.
- [26] G. Chen, "Automatic EEG seizure detection using dual-tree complex wavelet-Fourier features," *Expert Systems with Applications*, vol. 41, pp. 2391-2394, 2014.
- [27] N. F. Güler, E. D. Übeyli, and I. Güler, "Recurrent neural networks employing Lyapunov exponents for EEG signals classification," *Expert systems with applications*, vol. 29, pp. 506-514, 2005.
- [28] H. Ocak, "Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy," *Expert Systems with Applications*, vol. 36, pp. 2027-2036, 2009.
- [29] V. Srinivasan, C. Eswaran, and Sriraam, "Artificial neural network based epileptic detection using time-domain and frequency-domain features," *Journal of Medical Systems*, vol. 29, pp. 647-660, 2005.
- [30] A. Subasi, "EEG signal classification using pp. 1858-1867, 2008.
- [9] L. Guo, D. Rivero, and A. Pazos, "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks," *Journal of neuroscience methods*, vol. 193, pp. 156-163, 2010.
- [10] 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, pp. 147-157, 2010.
- [11] 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, pp. 13475-13481, 2011.
- [12] J. Wang, X. Gao, J. M. Tanskanen, and P. Guo, "Epileptic EEG Signal Classification with ANFIS based on Harmony Search Method," in *Computational Intelligence and Security (CIS), 2012 Eighth International Conference on*, Guangzhou, 2012, pp. 690-694.
- [13] 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, pp. 572-578, 2013.
- [14] 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, p. 061907, 2001.
- [15] H. Adeli, Z. Zhou, and N. Dadmehr, "Analysis of EEG records in an epileptic patient using wavelet transform," *Journal of neuroscience methods*, vol. 123, pp. 69-87, 2003.
- [16] C. K. Chui, *An introduction to wavelets*. Boston: Academic press, 1992.
- [17] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 11, pp. 674-693, 1989.
- [18] O. Faust, U. R. Acharya, H. Adeli, and A. Adeli, "Wavelet-based EEG processing for computer-aided seizure detection and epilepsy diagnosis," *Seizure*, vol. 26, pp. 56-64, 2015.
- [19] I. Güler and E. D. Übeyli, "Adaptive neuro-

در حال حاضر استاد تمام گروه برق الکترونیک دانشکده مهندسی برق و کامپیوتر دانشگاه بیرجند هستند. زمینه‌های مورد علاقه ایشان، روش‌های بهینه‌سازی تکاملی، روش‌های بهینه‌سازی هوش جمعی، محاسبات نرم، تشخیص الگو، پردازش تصویر و پردازش سیگنال است.

shzahiri@yahoo.com

wavelet feature extraction and a mixture of expert model," *Expert Systems with Applications*, vol. 32, pp. 1084-1093, 2007.

- [31] K. Polat and S. Güneş, "Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform," *Applied Mathematics and Computation*, vol. 187, pp. 1017-1026, 2007.
- [32] L. Guo, D. Rivero, J. A. Seoane, and A. Pazos, "Classification of EEG signals using relative wavelet energy and artificial neural networks," in *Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation*, 2009, pp. 177-184.
- [33] R. Dhiman and J. Saini, "Genetic algorithms tuned expert model for detection of epileptic seizures from EEG signatures," *Applied Soft Computing*, vol. 19, pp. 8-17, 2014.
- [34] Z. Zainuddin, L. K. Huong, and O. Pauline, "On the use of wavelet neural networks in the task of epileptic seizure detection from electroencephalography signals," *Procedia Computer Science*, vol. 11, pp. 149-159, 2012.



### محمد رضا اسماعیلی سعادتی

مدارک کارشناسی و کارشناسی ارشد خود را در رشته الکترونیک از دانشگاه بیرجند به ترتیب در سال‌های ۱۳۹۱ و ۱۳۹۳ اخذ کرد. ایشان هم‌اکنون

دانشجوی دکتری رشته مهندسی برق الکترونیک در دانشکده مهندسی برق و کامپیوتر دانشگاه بیرجند هستند. زمینه‌های مورد علاقه ایشان، پردازش سیگنال، پردازش سیگنال‌ها و علائم حیاتی، الگوریتم‌های بهینه‌سازی فراابتکاری و طراحی بهینه مدارات مجتمع است. نشانی رایانامه ایشان عبارت است از:

Mr.esmaeili@birjand.ac.ir



### سید حمید ظهیری ممقانی مدارک

کارشناسی و کارشناسی ارشد خود را به ترتیب در رشته مهندسی برق الکترونیک از دانشگاه صنعتی شریف و تربیت مدرس دریافت کردند. ایشان در

سال ۱۳۸۴ مدرک دکتری خود را در رشته مهندسی برق الکترونیک در دانشگاه فردوسی مشهد به اتمام رساندند. وی