

## انتخاب یک فضای ویژگی بهینه در تشخیص حملات صرعی

### بر پایه آنالیز کمی سازی بازگشتی و الگوریتم ژنتیک

صالح لشکری<sup>(۱)</sup> - مهدی آذرنوش<sup>(۲)</sup>

(۱) دانشجوی دکترا - باشگاه پژوهشگران جوان و نخبگان، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) استادیار - باشگاه پژوهشگران جوان و نخبگان، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

تاریخ دریافت: ۱۳۹۴/۰۵/۰۱ تاریخ پذیرش: ۱۳۹۵/۰۲/۲۵

**خلاصه:** در طبقه‌بندی داده‌ها انتخاب فضای ویژگی متناسب با ماهیت پدیده و قدرت تفکیک بالا بسیار حائز اهمیت است. قابلیت نگاشت بازگشتی در تحلیل دادگان غیرایستا موجب می‌شود در تشخیص حملات صرعی نیز مورد توجه قرار گیرد. در این پژوهش به تشخیص حملات صرعی توسط آنالیز کمی‌سازی بازگشتی بر پایه ترکیب الگوریتم ژنتیک و طبقه‌بند بیزین پرداخته شده است. در ابتدا نگاشت بازگشتی سیگنال EEG دو گروه صرعی و نرمال هریک شامل ۱۰۰ نمونه، به ازای پنج نوع معیار فاصله (ماکزیمم فاصله، مینیمم فاصله، اقلیدوسی، ماهالانوبیس، منهن) و ۱۰ حد آستانه (E) مختلف تشکیل و بهترین مجموعه ویژگی بازای ۵۰ تکرار الگوریتم ژنتیک بر اساس نرخ طبقه‌بندی بیزین انتخاب گردید. نتایج، نشانگر کارایی بالای روش پیشنهادی بوده به گونه‌ای که با انتخاب معیار مینیمم فاصله و حد آستانه  $0.1 < \epsilon < 1$  تفکیک ۱۰۰٪ است. همچنین روش نسبت به حد آستانه (E) و معیار فاصله حساسیت پایینی دارد. ویژگی Trans با بیشترین مشارکت در انتخاب ویژگی و بالاترین صحت، به عنوان ویژگی بهینه معرفی می‌شود.

**کلمات کلیدی:** الکتروآنسفالوگرام، تشخیص حمله صرعی، آنالیز کمی‌سازی بازگشتی، انتخاب ویژگی، الگوریتم ژنتیک، طبقه‌کننده بیزین.

## Optimal Feature Space Selection in Detecting Epileptic Seizure based on Recurrent Quantification Analysis and Genetic Algorithm

Saleh Lashkari<sup>(1)</sup> - Mahdi Azarnoosh<sup>(2)</sup>

(1) MSc. - Department of Young Researchers and Elite Club, Mashhad Branch, Islamic Azad University, Mashhad, Iran

sl\_ieee@yahoo.com

(2) Assistant Professor - Department of Young Researchers and Elite Club, Mashhad Branch, Islamic Azad University, Mashhad, Iran

mahdi\_azarnoosh@yahoo.com

Selecting optimal features based on nature of the phenomenon and high discriminant ability is very important in the data classification problems. Since it doesn't require any assumption about stationary condition and size of the signal and the noise in Recurrent Quantification Analysis (RQA), it may be useful for epileptic seizure Detection. In this study, RQA was used to discriminate ictal EEG from the normal EEG where optimal features selected by combination of algorithm genetic and Bayesian Classifier. Recurrence plots of hundred samples in each two categories were obtained with five distance norms in this study: Euclidean, Maximum, Minimum, Normalized and Fixed Norm. In order to choose optimal threshold for each norm, ten threshold of  $\epsilon$  was generated and then the best feature space was selected by genetic algorithm in combination with a bayesian classifier. The results shown that proposed method is capable of discriminating the ictal EEG from the normal EEG where for Minimum norm and  $0.1 < \epsilon < 1$ , accuracy was 100%. In addition, the sensitivity of proposed framework to the  $\epsilon$  and the distance norm parameters was low. The optimal feature presented in this study is Trans which it was selected in most feature spaces with high accuracy.

**Index Terms:** Electroencephalogram, Seizure Epileptic Detection, Recurrent Quantification Analysis, Feature Selection, Genetic Algorithm, Bayesian Classifier.

نویسنده مسئول: صالح لشکری، دانشجوی دکترا - باشگاه پژوهشگران جوان و نخبگان، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران، saleh.lashkari@mshdiau.ac.ir

## ۱- مقدمه

امروزه طراحی سیستم‌های تشخیص و آشکارسازی برخط حملات صرعی، یکی از زمینه‌های مورد توجه محققان علوم پزشکی و مهندسی است. از طرفی گزینش روش‌هایی که بتواند خصایص بنیادین دینامیک سیستم مغزی را آشکار سازد ضروری است.

موضوع بازگشت حالات مدت زمان زیادی است که در طبیعت مورد بررسی قرار گرفته است [۱]. در سال ۱۹۸۷، اکمن<sup>۱</sup> روشی برای نمایش تکرار حالت سیستم در فضای فاز معرفی نمود. تکرار حالات سیستم، به معنای نزدیک شدن حالات سیستم به هم بعد از گذشت زمان بوده و یک خصیصه بنیادی در سیستم‌های معین است. با استفاده از نگاشت بازگشتی، یک بازنمایی مناسب از مسیرهای سیستم در دو بعد زمانی ایجاد می‌شود. با توجه به کاهش بی‌نظمی سیگنال EEG حین حمله صرعی، سیستم همسایگی تقریباً مشابهی را در فضای فاز ملاقات می‌کند. در نتیجه استفاده از این روش در تشخیص حملات می‌تواند معنادار باشد. به علاوه مزیت اصلی نگاشت بازگشتی قابلیت بکارگیری آن در داده‌های کوتاه و حتی غیر ایستا می‌باشد [۱ و ۲].

گاوژبانگ و همکاران در سال ۲۰۰۸ از آنالیز کمی سازی بازگشتی<sup>۲</sup> در تشخیص سه حالت نرمال، پیش‌حمله‌ای و صرعی موش‌های مبتلا به صرع ژنتیک غیب<sup>۳</sup> استفاده نمودند. نتایج این تحقیق نشان می‌دهد به ازای ویژگی‌های بازگشتی تفکیک‌پذیری معناداری بین دادگان صرعی و دو دسته دیگر وجود دارد [۵]. مقاله [۶] با اعمال ۱۰ ویژگی از نگاشت بازگشتی به ماشین بردار پشتیبان، صحت کلی ۹۵/۶٪ را در تفکیک دادگان صرعی از حالت نرمال و بین حمله‌ای سیگنال EEG انسان، گزارش کرده است. در مقاله [۷] پس از تجزیه سیگنال EEG سه دسته نرمال، بین حمله‌ای و صرعی انسان به زیرباندهای دلتا، تتا، آلفا و گاما، ویژگی‌های بازگشتی زیرباندها استخراج و به سیستم شناخت داده شده است. با توجه به دستاورد این تحقیق سه دسته با صحت کلی ۹۸/۶۷٪ قابل تفکیک می‌باشد.

ماروان نشان داد گزینش مناسب معیار فاصله در نتایج اثرگذار است و می‌تواند امکان تحلیل برخی از ویژگی‌های بازگشتی را به صورت تحلیلی فراهم نموده و سرعت محاسبه الگوهای بازگشتی را افزایش دهد [۸]. بازای معیارهای فاصله مختلف درجات متفاوتی از همسایگی در نظر گرفته می‌شود و حفظ جزئیات مربوط به هر نگاشت متفاوت می‌گردد. علاوه بر این حد آستانه  $\epsilon$  کوچک باعث می‌شود، نقاط بازگشتی از دست رود. از طرف دیگر، اگر  $\epsilon$  خیلی بزرگ انتخاب شود هر دو نقطه موجود در فضا، همسایه یکدیگر بوده و خطا افزایش می‌یابد.

استفاده از همه ویژگی‌ها در مسئله طبقه‌بندی الزاماً منجر به بهترین نتیجه نمی‌شود. الگوریتم‌های انتخاب ویژگی بسته به روند ارزیابی آنها به دو دسته حلقه باز و حلقه بسته تقسیم می‌شوند. نشان داده شده است الگوریتم‌های دسته دوم معمولاً نتایج بهتری به دست می‌دهند [۳]. این روش، جستجو در فضای زیرمجموعه‌ها را بر اساس تخمین

دقت ناشی از انتخاب یک زیرمجموعه خاص تحت شرایط الگوریتم طبقه‌بندی مورد استفاده (به عنوان معیاری از بهینگی آن زیرمجموعه) انجام می‌دهد [۹]. در این روش‌ها مهمترین مسئله، الگوریتم جستجویی است که در آن به کار رفته است. طی دهه گذشته محققان روی الگوریتم‌های جستجوی تکاملی مانند الگوریتم ژنتیک<sup>۴</sup> [۱۰ و ۱۱]، الگوریتم مورچگان<sup>۵</sup> [۹، ۱۲ و ۱۳] و ترکیب الگوریتم ازدحام ذرات/مورچگان<sup>۶</sup> [۱۴] تمرکز کرده‌اند. توانایی الگوریتم ژنتیک در جستجوی سریع و کلی یک فضای بزرگ، استفاده از آن را در کاربرد انتخاب ویژگی مناسب می‌سازد [۳].

خط مشی اصلی در این مقاله ارزیابی کارایی یک زیر مجموعه از ویژگی‌های نگاشت‌های بازگشتی با استفاده از ترکیب الگوریتم ژنتیک و طبقه‌بندی کننده بیزین می‌باشد. بر این اساس در بخش ۲، چگونگی ایجاد نگاشت بازگشتی برای سری زمانی تشریح گردیده و ویژگی‌های نگاشت‌های بازگشتی معرفی می‌شود. در مرحله بعد، نگاشت بازگشتی به ازای پنج معیار فاصله اقلیدوسی، ماهالانوبیس، ماکزیمم فاصله، مینیمم فاصله و منهن و همچنین ۱۰ حد آستانه با فواصل ۰/۱ بازسازی و ویژگی‌های بازگشتی محاسبه می‌شود. سپس طبقه‌کننده بیزین بر اساس ویژگی‌های تعیین شده توسط الگوریتم ژنتیک و داده‌های آموزش در دسترس در هر مرحله، آموزش داده می‌شود. اصلاح وزن‌ها که متناظر با ویژگی‌ها هستند تا زمانی ادامه خواهد یافت که بهترین زیرمجموعه از ویژگی که منجر به بهترین نرخ طبقه‌بندی می‌شوند، انتخاب گردد. بعد از مرحله انتخاب ویژگی، از بیزین آموزش داده شده توسط بهترین زیر مجموعه از ویژگی‌ها برای تعیین صحت طبقه‌بندی در مجموعه داده آزمون استفاده خواهد شد. در بحث و نتیجه‌گیری به مقایسه دستاوردهای تحقیق با نتایج تحقیقات مربوط به تشخیص حملات صرعی مبتنی بر نگاشت بازگشتی و دیگر روش‌های تحلیل پرداخته می‌شود.

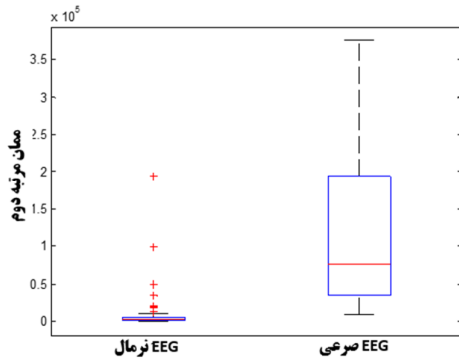
## ۲- روش انجام تحقیق

## ۲-۱ داده‌ها

داده‌های تحقیق مربوطه از پایگاه داده دپارتمان صرع دانشگاه بن آلمان می‌باشد [۱۵]. هر کدام از گروه‌ها، شامل ۱۰۰ قطعه EEG با طول ۲۳/۶ ثانیه است که بعد از بازبینی دستی برای آرتیفکت ناشی از فعالیت ماهیچه یا حرکت چشم، انتخاب و برش داده شده‌اند. گروه ۱ شامل EEG سطحی از پنج داوطلب سالم در وضعیت چشم باز، منطبق با استاندارد بین‌المللی ۲۰-۱۰ می‌باشد. گروه ۲ از پنج بیمار در وضعیت صرعی از هیپوکامپ راست، ثبت گردیده است. سیگنال‌ها به وسیله سیستم تقویت کننده ۱۲۸ کاناله، دارای مبدل آنالوگ به دیجیتال ۱۲ بیتی با نرخ نمونه برداری ۱۷۳/۶۱ هرتز ثبت شده است.

## ۲-۲ آنالیز کمی سازی بازگشتی

این روش که اولین بار در سال ۱۹۹۸ توسط اکمن و همکاران پیاده سازی شد قادر است جزئیات سیگنال غیرایستای EEG [۱۶-۱۹] را در زمان‌های مختلف به نمایش بگذارد. ایده اصلی این روش در



شکل (۲): نمودار جعبه‌ای مقادیر ممان مرتبه دوم برای سیگنال EEG  
Fig. (2): Box plot the values of second moments for EEG signal

### ۳-۲ الگوریتم ژنتیک

الگوریتم ژنتیک به واسطه توانایی بالا در حل مسائل بهینه‌سازی جای مناسبی در میان سایر روش‌ها دارد. این الگوریتم روشهای جستجوی کاملاً موازی را برای مسائل پیچیده بهینه‌سازی ارائه می‌نماید. الگوریتم ژنتیک تفاوت‌های اساسی با روش‌های جستجو و بهینه‌سازی متداول دارد [۴]:

- این الگوریتم نیازمندیهای ریاضی خاصی نداشته و بدون توجه به عملکرد درونی مسئله به حل مسائل بهینه‌سازی می‌پردازد.
- ساختار عملگرهای الگوریتم ژنتیک، این الگوریتم را قادر می‌سازد تا در یافتن جوابهای بهینه کلی موفق عمل کند.
- الگوریتم ژنتیک انعطاف‌پذیری بالایی را جهت تلفیق با تکنیکهای ابتکاری فراهم می‌سازد و از این طریق حل کارا و موثر یک مسئله را میسر می‌سازد.
- جمعیت اولیه تعداد کروموزومها در هر نسل و از نوع گسسته می‌باشد. برای تولید نسل جدید از ۳ عملگر نخبه‌گرایی<sup>۸</sup>، القاء<sup>۹</sup> تک نقطه‌ای و جهش<sup>۱۰</sup> استفاده گردیده است و در هر مرحله تعداد کروموزومهای نسل جدید برابر با تعداد کروموزومهای جمعیت اولیه بوده است (جدول (۲)).

جدول (۲): پارامترهای انتخابی برای الگوریتم ژنتیک  
Table (2): parameters for the genetic algorithm

پارامتر	مقدار تنظیم	
جمعیت اولیه	50	
اندازه کروموزوم	12	
مقادیر ژن	مینیمم	1
	ماکزیمم	12
اپراتورهای ژنتیکی	نرخ ترکیب	0.8
	نرخ جهش	0.05
	نرخ نخبه‌گرایی	0.15

### ۴-۲ طبقه‌بندی کننده بیزین

در علم آمار دسته‌بندی کننده بیزین یک دسته‌بندی کننده بهینه می‌باشد که متوسط خطا را حداقل می‌کند، به عبارت دیگر این

بازگشت‌های حالت سیستم به مناطق یکسانی از فضای فاز<sup>۷</sup>، که قبلاً مسیر در آنها بوده است، می‌باشد. تکرار یک حالت رخ داده در زمان  $t_i$  در زمان‌های مختلف  $z$  به وسیله یک ماتریس مربعی شامل صفر و یک (نقاط سیاه و سفید در نمودار) مشخص می‌شود که هر دو محور نمودار زمان می‌باشد. به بیان ریاضی نگاهت بازگشتی می‌تواند به صورت زیر ایجاد شود:

$$R(i, j) = \theta(\epsilon(i) - \|x(i) - x(j)\|), x \in \mathcal{R}^m, i, j = 1, \dots, N \quad (1)$$

که  $N$  طول سری زمانی و  $\theta$  تابع پله،  $\| \cdot \|$  معیار فاصله و  $\epsilon(i)$  شعاعی است که برای همسایگی هر نقطه  $x_i$  باید انتخاب شود [۱].


با انتخاب ویژگی‌های مناسب از ماتریس بازگشتی، امکان آشکارسازی الگوهای مخفی و تغییرات ساختاری در دینامیک فراهم می‌شود. این قابلیت که تحت عنوان آنالیز کمی بازگشتی شناخته شده است. در جدول (۱) ویژگی‌های مستخرج از نگاهت بازگشتی ذکر گردیده است [۲].

Table (1): Exacted features from Recurent plot

جدول (۱): ویژگی‌های مستخرج از نگاهت بازگشتی

ویژگی	شرح
RR	نرخ بازگشت
Det	قطعیت
$\langle l \rangle$	میانگین طول خطوط قطری
Lmax	طولانی‌ترین خط قطری
ENTR	آنتروپی
LAM	لایه‌ای بودن
TT	زمان به دام افتادن
Vmax	طولانی‌ترین خط عمودی
$T_1$	زمان بازگشت نوع ۱
$T_2$	زمان بازگشت نوع ۲
RTE	آنتروپی زمان بازگشت
Trans	انتقال پذیری

همانگونه که در مقدمه اشاره گردید این روش برای پردازش سیگنال‌های غیرایستا مناسب می‌باشد. در شکل‌های (۱) و (۲) به ترتیب ممان‌های مرتبه اول و دوم دو دسته سیگنال EEG سالم و صرعی در طول زمان محاسبه گشته است که با توجه به متغیر با زمان بودن ممان‌ها غیرایستایی سیگنال مغزی اثبات می‌شود.



شکل (۱): نمودار جعبه‌ای مقادیر ممان مرتبه اول برای سیگنال EEG  
Fig. (1): Box plot values of first moments for EEG signal.

که در آن  $f$  فرکانس نسبی تجمعی واقعی و  $\hat{f}$  فرکانس نسبی تجمعی مورد انتظار است. با انتخاب مقدار  $\alpha$  به عنوان مقدار خطا و برای تعداد نمونه  $n$ ،  $D_\alpha$  از جداول مربوطه فراخوانی می‌شود. در صورتی که مقدار  $D$  از  $D_\alpha$  به دست آمده کمتر باشد، آنگاه فرض تبعیت نمونه از توزیع در نظر گرفته شده پذیرفته شده و در غیر این صورت رد می‌شود. در جدول (۳) این آزمون برای به ازای ویژگی‌های کمی سازی بازگشتی و برای دو دسته EEG نرمال و صرعی محاسبه گردیده است. با توجه به اینکه مقدار  $D$  (یا  $P$ ) از  $(0.05)D_\alpha$  کوچکتر می‌باشد در نتیجه فرض تبعیت ویژگی‌ها از توزیع نرمال پذیرفته می‌گردد.

### نتایج پیاده‌سازی

در قدم اول، بازسازی نگاشت بازگشتی به ازای پنج معیار فاصله و ۱۰ حد آستانه ( $\epsilon_{min} = 0.1, \epsilon_{max} = 1, \Delta\epsilon = 0.1$ ) صورت پذیرفت. تأخیر زمانی  $\tau$  و بعد فضا سازی  $m$  برای تمامی نمونه‌ها با استفاده از روش میانگین اطلاعات متقابل<sup>۱۱</sup> و نزدیکترین همسایگی اشتباه<sup>۱۲</sup> محاسبه شد. به منظور تعیین تأخیر بهینه، تابع میانگین اطلاعات متقابل برحسب تأخیر زمانی برای هر قطعه EEG محاسبه گردید. مقادیر  $\tau$  بهینه متناظر با وقوع اولین مینیمم تابع میانگین اطلاعات متقابل در محدوده ۴ تا ۱۱ حاصل شد. همچنین بعد فضا سازی به روش نزدیکترین همسایگی اشتباه بازای بعدها فضا سازی مختلف برای هر قطعه EEG محاسبه شد. بعد فضا سازی برای کل داده‌ها بین ۵ تا ۱۰ به دست آمد.

Table (3): Kolmogorov-Smirnov test for normal and epileptic EEG.

جدول (۳): آزمون کولموگروف-اسمیرنوف دو دسته EEG نرمال و صرعی

ویژگی	مقدار p	
	دسته EEG صرعی	دسته EEG نرمال
RR	$2/45 \times 10^{-89}$	$2/45 \times 10^{-89}$
DET	$2/31 \times 10^{-63}$	$2/31 \times 10^{-63}$
L	$2/49 \times 10^{-87}$	$1/31 \times 10^{-71}$
$L_{max}$	$4/77 \times 10^{-74}$	$5/17 \times 10^{-60}$
$\langle L \rangle$	$3/02 \times 10^{-45}$	$3/75 \times 10^{-39}$
ENTR	$1/83 \times 10^{-22}$	$1/81 \times 10^{-24}$
LAM	$1/83 \times 10^{-22}$	$1/83 \times 10^{-22}$
TT	$5/64 \times 10^{-71}$	$1/83 \times 10^{-22}$
Vmax	$4/26 \times 10^{-89}$	$7/69 \times 10^{-25}$
T1	$1/67 \times 10^{-64}$	$1/93 \times 10^{-54}$
T2	$2/06 \times 10^{-28}$	$8/17 \times 10^{-30}$
Trans	$1/72 \times 10^{-32}$	$1/81 \times 10^{-33}$

شکل (۴) الگوی نگاشت بازگشتی را برای پنج معیار فاصله بازای  $\epsilon = 0.5$  نشان می‌دهد. بازای معیارهای مختلف، درجات متفاوتی از همسایگی در نظر گرفته شده است که در نتیجه حفظ جزئیات مربوط به هر نگاشت متفاوت می‌گردد. مشاهده می‌گردد که با جابجایی از

دسته بندی کننده سعی در یافتن مینیمم اصلی در تابع خطا دارد. در این طبقه بند بردار ویژگی‌های  $X$  مربوط به کلاسی است که احتمال آن  $P(\omega_i|X)$  باشد که طور کلی به صورت زیر بیان می‌شود [۲۰ و ۲۱].

$$P(\omega_i|X) = \frac{P(\omega_i)P(X|\omega_i)}{P(X)} \quad (2)$$

for all  $i \neq j$

کلاس  $w_i$  ام و  $X$  بردار ویژگی ورودی و  $P(w_i|X)$  تابع تصمیم گیری است. از طرفی بیز بیان می‌کند که

$$P(X|\omega_i) = \frac{1}{(2\pi)^{\frac{n}{2}}|\Sigma_i|^{\frac{1}{2}}} e^{-\frac{1}{2}(X-\mu_i)^T \Sigma_i^{-1} (X-\mu_i)} \quad (3)$$

که  $P(X|\omega_i)$  چگالی احتمال کلاس  $\omega_i$  و  $P(\omega_i)$  احتمال وقوع کلاس  $\omega_i$  و  $P(X)$  احتمال وقوع کلاس  $X$  که به علت وجودش در تمامی توابع تصمیم گیر کلاس‌ها از آن صرف نظر می‌شود. بنابراین:

$$g_i(X) = P(\omega_i)P(X|\omega_i) \quad (4)$$

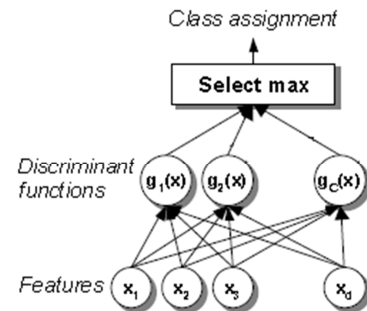
با فرض اینکه تابع چگالی بردار ویژگی‌ها از توزیع نرمال تبعیت می‌کند (جدول (۳)) خواهیم داشت:

$$P(X|\omega_i) = \frac{1}{(2\pi)^{\frac{n}{2}}|\Sigma_i|^{\frac{1}{2}}} e^{-\frac{1}{2}(X-\mu_i)^T \Sigma_i^{-1} (X-\mu_i)} \quad (5)$$

که  $\mu_i$  و  $\Sigma_i$  به ترتیب متوسط و کواریانس بردارهای ویژگی داده تست هر کلاس می‌باشد. پس با توجه به این رابطه تابع تصمیم گیر برای کلاس  $i$  ام برابر است با:

$$g_i(X) = -\frac{1}{2}(X - \mu_i)\Sigma_i^{-1}(X - \mu_i)^T - \frac{1}{2}\log(|\Sigma_i|) + \log(p(\omega_i)) \quad (6)$$

بردار  $X$  متعلق به کلاسی خواهد بود که تابع تصمیم گیری آن ماکزیمم گردد. شکل (۳) ساختار یک طبقه بندی کننده بیز را نشان می‌دهد.



شکل (۳): ساختار طبقه کننده بیزین  
Fig. (3): Bayesian classifier structure

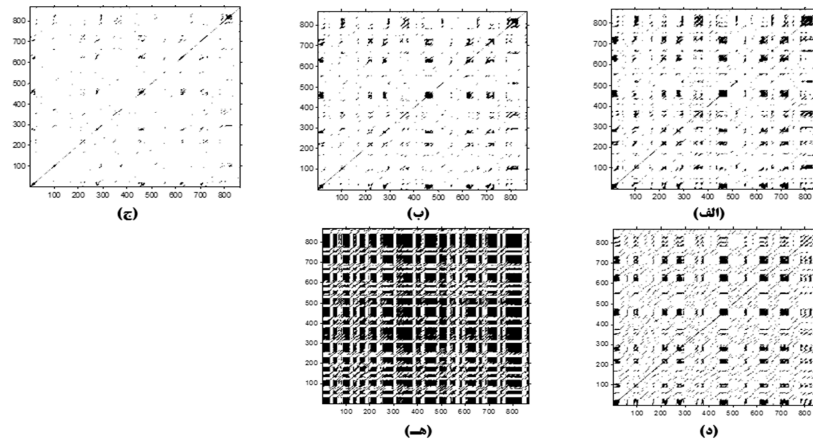
### ۵-۲ آزمون کولموگروف-اسمیرنوف

از این آزمون جهت سنجش تبعیت توزیع یک نمونه از توزیع خاص استفاده می‌شود. آزمون کای اسکواتر هنگامیکه تعداد نمونه‌ها به اندازه کافی بزرگ باشد خوب عمل می‌کند. در غیر این صورت استفاده از آزمون کولموگروف-اسمیرنوف توصیه می‌شود. آماره این آزمون بیشترین اختلاف بین فرکانس‌های مورد انتظار و واقعی (به صورت قدرمطلق) اندازه گیری شده در دسته‌های مختلف می‌باشد. این آماره به صورت رابطه (۷) نوشته می‌شود:

$$D = \max|f(x) - \hat{f}(x)| \quad (7)$$

به منظور تعیین ویژگی بهینه در آنالیز کمی سازی بازگشتی سه معیار مورد بررسی قرار گرفت: میزان مشارکت ویژگی در کل تکرارها، قابلیت تفکیک ویژگی، رخدادهای صحت ۱۰۰٪ به ازای تک ویژگی. میزان مشارکت هر ویژگی در کل حالات بررسی شده نشان می‌دهد به طور میانگین هر کدام از ویژگی‌ها در ۵۲٪ تکرارها ظاهر شده‌اند که در این میان ویژگی‌های Trans و DET به ترتیب با ۶۲٪ و ۳۲٪ بیشترین و کمترین میزان مشارکت را در مرحله انتخاب ویژگی داشته‌اند (جدول (۶)).


شکل الف به هر درصد نقاط مشکلی افزایش یافته است. در مرحله بعد ویژگی‌های بازگشتی با استفاده از جعبه ابزار CRP Toolbox بازای حالت‌های در نظر گرفته شده محاسبه و به سیستم شناخت اعمال گردید. در مرحله انتخاب ویژگی الگوریتم ژنتیک با ۵۰ بار تکرار اجرا شد که نتایج آن در جدول (۴) ذکر شده است. جدول (۵) نشان می‌دهد به طور میانگین تعداد ۶/۲۷ همزمان در مرحله انتخاب ویژگی مشارکت داشته‌اند که در این میان برای دستیابی به صحت تفکیک مناسب معیار اقلیدوسی کمترین و معیار ماهالانوبیس بیشترین تعداد ویژگی را لازم داشته‌اند.



شکل (۴): نگاشت بازگشتی سیگنال EEG صرعی بازای  $\epsilon = 0.5$  الف) اقلیدوسی ب) ماکزیمم فاصله ج) مینیمم فاصله د) ماهالانوبیس ه) منهتن.  
Fig. (4): Recurrent plot of epileptic EEG for  $\epsilon = 0.5$ , A) Euclidean B) Maximum distance C) Minimum distance D) Mahalanobis E) Manhattan

Table (4): Average accuracy of 50 iterations for genetic algorithms  
جدول (۴): میانگین صحت تشخیص حملات صرعی بازای ۵۰ تکرار برای الگوریتم ژنتیک

معیار فاصله	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
ماکزیمم فاصله	100 %	100 %	100 %	100 %	100 %	97/99 %	100 %	99/93 %	99/83 %	99/97 %
مینیمم فاصله	98/98 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	100 %	99/89 %
اقلیدوسی	100 %	100 %	100 %	100 %	100 %	100 %	99/72 %	99/96 %	99/96 %	99/79 %
ماهالانوبیس	98/74 %	98/60 %	98/77 %	100 %	98/30 %	98/57 %	98/36 %	98/30 %	98/43 %	100 %
منهتن	99/59 %	99/69 %	99/45 %	99/69 %	98/40 %	99/42 %	98/70 %	98/57 %	97/95 %	100 %



شکل (۵): نمودار جعبه‌ای مقادیر p برای ویژگی‌های بازگشتی  
Fig. (5): Box plot values of p for Recurrence features

Table (5): The average number of features used in 500 iteration of GA(50\*10)

جدول (۵): متوسط تعداد ویژگی‌های استفاده شده در ۵۰۰ تکرار الگوریتم ژنتیک (۵۰×۱۰)

معیار فاصله	متوسط ویژگی ظاهر شده
اقلیدوسی	5/41
مینیمم فاصله	5/81
ماکزیمم فاصله	6/02
منهتن	6.62
ماهالانوبیس	7/51
کل معیارها	6/27

شکل (۵) و جدول (۷) قابلیت تفکیک هر کدام از ویژگی‌ها را در کل حالات در نظر گرفته شده نشان می‌دهد. محاسبه مقدار  $p$  با استفاده از آزمون آماری  $T$  نشان می‌دهد ویژگی‌های  $V_{max}$  و  $Trans$  به ترتیب بیشترین و کمترین تفکیک را ایجاد کرده‌اند. در جدول (۸) ویژگی‌های  $L_{max}$ ،  $Trans$  و  $RR$  به ترتیب با ۳، ۳ و ۳ رخداد تفکیک ۱۰۰ را ایجاد نموده‌اند. همچنین ویژگی‌های  $TT$ ،  $V_{max}$  و  $T_2$  با عدم ایجاد تفکیک ۱۰۰٪ ضعیف‌ترین حالت را داشته‌اند.

### نتیجه‌گیری

در این مقاله روشی جدید در تشخیص حملات صرعی بر مبنای آنالیز کمی سازی بازگشتی و ترکیب الگوریتم ژنتیک و طبقه‌بند بی‌زین ارائه گشت و برای اولین بار زیرمجموعه بهینه از نگاهت بازگشتی در تشخیص حملات صرعی به دست آمد.

Table (6): The participation features in 2500 iteration for the Genetic Algorithm(50\*10\*5)

جدول (۶): میزان مشارکت ویژگی‌ها با بازی ۲۵۰۰ تکرار الگوریتم ژنتیک (۵×۱۰×۵۰).

ویژگی	میزان مشارکت(%)
Trans	62
RR	61
LAM	61
T1	58
TT	56
L	55
$L_{max}$	53
$V_{max}$	53
ENTR	47
DET	46
$\langle L \rangle$	46
T2	44

Table (7): The average value of  $p$  in 50 status

جدول (۷): متوسط مقادیر  $p$  در ۵۰ حالت

ویژگی	میانگین مقدار $p$
RR	$7/6 \times 10^{-5}$
DET	$3/86 \times 10^{-2}$
L	$8/81 \times 10^{-3}$
$L_{max}$	$5/41 \times 10^{-7}$
$\langle L \rangle$	$4/46 \times 10^{-2}$
ENTR	$2/58 \times 10^{-6}$
LAM	$5/21 \times 10^{-3}$
TT	$5/64 \times 10^{-7}$
$V_{max}$	$7/69 \times 10^{-2}$
T1	$1/09 \times 10^{-5}$
T2	$1/17 \times 10^{-2}$
Trans	$9/62 \times 10^{-12}$

Table (8): conditions for 100 % Accuracy

جدول (۸): حالت‌های مربوط به صحت ۱۰۰٪

ویژگی	معیار فاصله	حد آستانه	تفکیک ۱۰۰٪	جمع رخداد ۱۰۰٪
RR	ماهان‌لایوبیس	1	3	3
DET	ماهان‌لایوبیس	1	1	1
L	اقلیدوسی	0.2	2	2
$L_{max}$	ماکزیمم فاصله	0.2	1	6
		0.2	1	
	مینیمم فاصله	0.2	1	
		0.2	3	
$\langle L \rangle$	اقلیدوسی	0.1	1	2
		0.2	1	
ENTR	ماهان‌لایوبیس	1	1	1
LAM	ماهان‌لایوبیس	1	2	2
TT	-	-	-	-
$V_{max}$	-	-	-	-
T1	ماهان‌لایوبیس	2	2	2
T2	-	-	-	-
Trans	ماهان‌لایوبیس	1	3	3

در جدول (۹) ویژگی‌های بهینه بازی سه معیار معرفی شده به طور خلاصه آورده شده است.

Table (9): The optimal features selection of recurrence quantification analysis

جدول (۹): گزینش ویژگی‌های بهینه آنالیز کمی‌ساز بازگشتی

ویژگی بهینه	معیار ارزیابی
Trans	میزان مشارکت
Trans	بیشترین قابلیت تفکیک
L <sub>max</sub>	رخداد تفکیک ۱۰۰٪

ماروان نشان داد انتخاب این دو پارامتر در نتایج پردازش اثرگذار است [۸]. در این تحقیق برای اولین بار تأثیر پارامترهای تشکیل‌دهنده نگاشت‌های بازگشتی بر نتایج مورد بررسی قرار گرفت. نتایج نشانگر حساسیت پایین روش به پارامتر حد آستانه،  $\epsilon$  می‌باشد به گونه‌ای که بازای معیارهای ماکزیمم فاصله، مینیمم فاصله و اقلیدوسی الگوریتم پیشنهادی با تغییر مجموعه ویژگی‌ها قادر است میانگین تفکیک بالاتر از ۹۹/۷۲٪ را ایجاد نماید. در این میان حساسیت روش به تغییرات حد آستانه پایین‌تر می‌باشد. در [۵] تنها به آنالیز آماری ویژگی‌های بازگشتی کفایت شده است و الگوریتمی مبتنی بر سیستم‌های شناخت ارائه نشده است. در [۶] و [۷] برای دستیابی به تفکیک ۹۵/۶٪ و ۹۸/۶۸٪ ویژگی‌های نگاشت بازگشتی برای چهار زیرباند دلنا، تن، آلفا و گاما استخراج گردیده است که این عمل حجم محاسبات را بسیار بالا می‌برد.

مراجع [۵]، [۶] و [۷] از آنالیز کمی‌ساز بازگشتی در کاربرد تشخیص حملات صرعی استفاده نمودند. در هر سه مقاله تفکیک دادگان صرعی از دو دسته نرمال و بین حمله‌ای انجام شده است. در تحقیقات مذکور تمام ویژگی‌های بازگشتی در سیستم شناخت مورد استفاده قرار گرفته و روشی برای انتخاب ترکیب بهینه از ویژگی‌ها ارائه نگردیده است. در حالیکه نتایج نشان می‌دهد در صورت انتخاب روش مناسب می‌توان با تعداد ویژگی پایین نیز به صحت قابل قبولی در تشخیص حملات صرعی دست یافت. با مشاهده متوسط ویژگی‌های شرکت کرده به ازای هر معیار فاصله این نتیجه حاصل می‌گردد که برای تشخیص حملات صرعی با صحت تفکیک بالا، نیاز به استفاده از تمامی ویژگی‌های کمی‌ساز بازگشتی نبوده و به صورت تقریبی با اعمال هفت ویژگی به سیستم شناخت پیشنهاد شده می‌توان به هدف مورد نظر دست یافت. در هیچ کدام از این تحقیقات حساسیت روش و الگوریتم پیشنهادی به پارامترهای حد آستانه و معیار فاصله بررسی نشده است در حالیکه

Table (10): Summary of previous investigations in the diagnosis of epileptic seizures on normal status

جدول (۱۰): خلاصه تحقیقات قبلی در تشخیص حملات صرعی از حالت نرمال

مرجع	ویژگی‌ها	طبقه‌بندی کننده	صحت (%)
[22]	فیلتر غیرخطی	شبکه عصبی مصنوعی	97/20
[23]	آنتروپی	سیستم فازی ANFIS	92/22
[24]	زمانی-فرکانسی	شبکه المن	99/60
[25]	ضرایب و بولت گسسته	شبکه فازی تطبیقی	85/90
[26]	ضرایب و بولت گسسته، آماری	ترکیب خیره‌ها	94/50
[27]	فرکانسی	درخت تصمیم	98/22
[28]	زمانی-فرکانسی	شبکه عصبی مصنوعی	97/2-100
[29]	آنتروپی تقریبی	شبکه عصبی احتمالی، شبکه المن	100
[30]	فرکانسی	سیستم بازشناسی مصنوعی	100
[31]	ضرایب مدل AR	درخت تصمیم	99/32
[32]	آنتروپی، ضرایب و بولت گسسته	آستانه گذاری	96/65
[33]	ضرایب و بولت آنتروپی	شبکه عصبی مصنوعی	95/20
[34]	آنتروپی تقریبی، و بولت	شبکه عصبی مصنوعی	85-99
[35]	ویژگی‌های طول خط، تبدیل و بولت	شبکه عصبی مصنوعی	99/60
[36]	بولت گسسته، آنالیز مؤلفه‌های مستقل، آنالیز مؤلفه‌های اساسی، آنالیز تفکیک کنندگی خطی	ماشین بردار پشتیبان	98/75 (آنالیز مؤلفه‌های اساسی)، 99/50 (آنالیز مؤلفه‌های مستقل)، 100 (آنالیز تفکیک کنندگی خطی)
[37]	ضرایب مدل AR	ماشین بردار پشتیبان	99/56
[38]	ضرایب و بولت	ماشین بردار پشتیبان	100
[39]	برنامه ژنتیکی	نزدیک ترین همسایگی	99
[40]	ضرایب و بولت آنتروپی	نزدیک ترین همسایگی	100
[41]	همبستگی متقابل، چگالی طیف توان	ماشین بردار پشتیبان	100
[42]	ضرایب و بولت گسسته	شبکه عصبی مصنوعی	100

نتایج به دست آمده در جدول (۴) نشان می‌دهد روش پیشنهادی مرکب از الگوریتم ژنتیک و شبکه بی‌زین قابلیت بالایی در تشخیص حملات صرعی نشان داده است. بازای معیارهای ماکزیمم فاصله، مینیمم فاصله، اقلیدوسی، ماهالانویس و منهن به ترتیب میانگین صحت ۹۹/۹۴٪، ۹۹/۹۶٪، ۹۹/۸۸٪، ۹۹/۸۹٪ و ۹۹/۱۴٪ در تشخیص حملات صرعی ایجاد می‌شود. با انتخاب معیار مینیمم فاصله و حد آستانه در محدوده  $0.1 < \epsilon < 1$  تفکیک ۱۰۰٪ میان دادگان صرعی و نرمال به دست خواهد آمد. در جدول (۱۰) خلاصه تحقیقات پیشین انجام گرفته بر روی داده‌های مقاله ذکر شده است.

نیگام [۲۲] با استفاده از فیلتر پیش‌پردازش غیرخطی چند طبقه‌ای<sup>۱۳</sup> و شبکه عصبی مصنوعی در تشخیص خودکار سیگنال‌های صرعی به صحتی در حدود ۹۰/۲۰٪ دست یافتند. سیگنال‌های EEG در دو وضعیت صرعی و نرمال با استفاده از آنروپی‌های مختلف و سیستم فازی ANFIS طبقه‌بندی شده و صحت ماکزیمم برابر ۹۲/۲٪ به دست آمد [۲۳]. ویژگی‌های زمانی و فرکانسی در ترکیب به شبکه المن در طبقه‌بندی دو دسته استفاده شد و صحتی معادل ۹۹/۶٪ حاصل شد [۲۴]. سیگنال‌های صرعی و نرمال EEG به صورت خودکار طبقه‌بندی و صحت برابر ۸۵/۹٪ در اعمال ویژگی‌های استخراجی از انرژی زیرباند‌های تبدیل ویولت گسسته به شبکه فازی عصبی تطبیقی به دست آمد [۲۵].

سرنیواسان و همکاران [۲۹] سیستم‌های تشخیص حملات صرعی را با ترکیب شبکه‌های عصبی احتمالی و آنروپی تقریبی توسعه دادند. طراحی این سیستم به صحت کلی برابر ۱۰۰٪ منجر گشت. ترالاس و همکاران با به کارگیری روش‌های زمان-فرکانسی و شبکه عصبی برای آنالیز قطعه‌های سیگنال EEG در تشخیص خودکار حملات صرعی صحتی در محدوده ۹۷/۲٪ تا ۱۰۰٪ به دست آوردند. سوپاسی [۲۶] با اعمال تبدیل ویولت گسسته بر روی سیگنال EEG و تجزیه آن‌ها به زیرباند‌های فرکانسی، پس از استخراج ضرایب تبدیل ویولت گسسته و تعریف ویژگی‌های آماری بر روی آنها، به یک شبکه عصبی قیاسی<sup>۱۴</sup> تحت عنوان ترکیب خبره‌ها<sup>۱۵</sup> اعمال نمودند. آنها داده صرعی از سالم را با صحت ۹۴/۵٪ تفکیک نمودند. پلات و گینس [۲۷] با استفاده از روش تبدیل فوریه سریع مبتنی بر الگوریتم تخمین Welch و طبقه‌بندی کننده تصمیم درخت به ماکزیمم صحت ۹۸/۷۲٪ دست یافتند. همین گروه [۳۰] با استفاده از تبدیل فوریه سریع به روش Welch برای استخراج ویژگی، اعمال آنالیز مؤلفه‌های اساسی برای کاهش بعد و یک سیستم تشخیص خودکار هیبرید جدید مبتنی بر ANFIS و مکانسیم تخصیص منابع فازی<sup>۱۶</sup> برای طبقه‌بندی قطعه‌های EEG نرمال از صرعی صحت ۱۰۰٪ را گزارش کردند. گروه مذکور با استفاده از مدل AR برای استخراج ویژگی و طبقه‌بندی کننده درخت تصمیم برای دسته‌بندی صحتی برابر ۹۹/۳۲٪ را گزارش نمودند [۳۱]. آکاک و همکاران [۳۲] روش تشخیص خودکار حملات را مبتنی بر آنروپی تقریبی و تبدیل ویولت گسسته توسعه دادند. آنها موفق به

تشخیص حملات صرعی با صحتی برابر ۹۶٪ گشتند. گروه جیو پس از مطالعات بسیار در استفاده از شبکه عصبی مصنوعی برای طبقه‌بندی صحت ۹۵/۲٪ را با استفاده از ویژگی‌های مبتنی بر انرژی ویولت نسبی<sup>۱۷</sup> [۳۳]، صحت ۹۹/۸۵٪ در استفاده از تبدیل ویولت و ویژگی‌های آنروپی تقریبی [۳۴]، صحت ۹۹/۶۰٪ با استفاده از تبدیل ویولت و ویژگی طول خط [۳۵] و صحت ۹۹٪ با استفاده از ویژگی‌های مبتنی بر برنامه ژنتیکی در اعمال به طبقه‌بندی کننده نزدیکترین همسایگی دست یافتند [۳۹]. ویژگی‌های تبدیل ویولت گسسته پس از کاهش با استفاده از آنالیز مؤلفه‌های اساسی، آنالیز مؤلفه‌های مستقل و آنالیز تفکیک‌کنندگی خطی با استفاده از ماشین بردار پشتیبان دسته‌بندی شدند [۳۶]. آنها صحتی معادل ۹۸/۸۵٪ با استفاده از روش آنالیز مؤلفه‌های مستقل، ۹۹/۵٪ با روش آنالیز مؤلفه‌های مستقل و ۱۰۰٪ در استفاده از تفکیک‌کننده خطی به دست آوردند. اولی [۳۷] از ضرایب AR برای استخراج ویژگی و ماشین بردار پشتیبان استفاده کرده و در نهایت صحت تفکیک ۹۹/۵۶٪ گزارش شده است.

در [۳۸ و ۴۰] صحت دسته‌بندی برابر ۱۰۰٪ حاصل شده است. در [۴۰] از زیرباند‌های متعدد و ساختار طبقه‌بندی پیچیده استفاده شده است. در [۴۲] نیز از زیر باند‌های تبدیل ویولت گسسته و ساختار شبکه عصبی چندلایه به منظور تفکیک دو دسته بهره گرفته شده است. در [۲۸] صحت به دست آمده بین ۹۷/۷۲ تا ۱۰۰٪ می‌باشد در حالیکه در تحقیق انجام شده بازای پنج معیار فاصله، میانگین صحت بازای ۵۰۰ تکرار برای هر معیار بالاتر از ۹۹/۹۱٪ حاصل شده است. این مقاله از ویژگی‌های مختلف زمان-فرکانس استفاده شده و در حوزه فرکانس بازای قطعه‌های مختلف EEG تعداد ۴، ۵، ۷ و ۱۳ زیرباند استفاده شده است که پیچیدگی محاسبات را افزایش می‌دهد. مقاله [۴۱] در این مقاله از ترکیب ویژگی‌های زمانی و فرکانسی استفاده شده است. ۵ ویژگی به عنوان ویژگی‌های زمانی و ۵ ویژگی به عنوان ویژگی‌های فرکانسی استفاده شده است.

اگرچه در برخی از تحقیقات اخیر انجام شده در تشخیص حملات، ماکزیمم صحت به دست آمده است، اما تناسب آنالیز کمی سازی بازگشتی با ماهیت سیستم‌های آشوبگونه این امکان را فراهم می‌آورد تا علاوه بر به کارگیری آن در سیستم‌های خودکار، قابلیت تفسیرها و تحلیل‌های لازم از دیدگاه آشوب ایجاد شود.

با توجه به میزان مشارکت بالای Trans در مرحله انتخاب ویژگی و تفکیک بالای دادگان صرعی از نرمال به عنوان ویژگی بهینه در تشخیص حمله صرعی معرفی می‌شود. این ویژگی معرف وابستگی تعداد نقاط بازگشتی خطوط موازی خط قطری مرکزی نسبت به فاصله آنها از این خط می‌باشد [۴۳]:


$$\text{Trans} = \frac{\sum_{i=1}^N (i - \bar{N}/2)(RR_i - (RR_i))}{\sum_{i=1}^N (i - \bar{N}/2)^2} \quad (8)$$

که در آن  $\bar{N}$  ماکزیمم تعداد خطوط موازی خط قطری مرکزی،  $i$  شماره  $i$ امین خط موازی و  $RR_i$  نشان دهنده نرخ بازگشت  $i$ امین خط موازی است. این ویژگی بیانگر درجه غیرایستایی سیستم می‌باشد. در صورتی



پی نوشت که نقاط بازگشتی به صورت همگن در نمودار بازگشتی توزیع شده باشند، مقادیر Trans نزدیک عدد صفر خواهد بود و در صورتیکه توزیع نقاط بازگشتی در نمودار بازگشتی به صورت غیرهمگن باشد، مقادیر Trans از عدد صفر انحراف پیدا می کند [۴۴]. شکل (۶) محدوده مقادیر ویژگی Trans را برای دو دسته EEG نرمال و EEG صرعی نشان می دهد. همانگونه که مشاهده می شود در هر دو وضعیت نرمال و صرعی مقادیر ویژگی Trans از عدد صفر بیشتر شده است که نشان از غیر ایستایی سیگنال مغزی است. اگرچه میزان ویژگی Trans حین حملات صرعی افزایش قابل توجهی داشته است.

1. Eckmann
2. Recurrent Quantification Analysis
3. Genetic Absence Seizure
4. Genetic Algorithm
5. Ant Colony Optimization
6. Particle Swarm Optimization
7. Phase Space
8. Selection
9. Cross over
10. Mutation
11. Mutual Information
12. False Near Neighbor
13. Multistage nonlinear preprocessing filter
14. Modular
15. Mixture of Experts
16. Fuzzy resource allocation
17. Relative Wavelet Energy



شکل (۶): نمودار جعبه‌ای مقادیر Trans برای دو دسته سیگنال EEG نرمال و صرعی

Fig. (6): Trans box plot values for both normal and epileptic EEG signal

## References

- [1] M. Azarnoosh, "Variability of non-linear dynamic parameters of EEG signal in attentive long-term activity", Ph.D. Thesis, Islamic Azad University, Science and Research Branch, Tehran, Iran, 2012.
- [2] S. Lashkari, "Evaluation of EEG signals during Epileptic seizures based on nonlinear features", Msc. Thesis, Islamic Azad University, Mashhad Branch, Mashhad, Iran, 2013.
- [3] D. Kalyanmoy, et al. "A fast and elitist multi objective genetic algorithm: NSGA-II", IEEE Trans. on Evolutionary Computation, Vol. 6, No. 2, pp. 182-197, 2002.
- [4] N. Faghih, A. Honarvar. "Genetic algorithms in planning preventive inspections", 2005.
- [5] O. Gaoxiang. L. Xiaoli, D. Chuangyin, "Using recurrence plot for determinism analysis of EEG recordings in genetic absence epilepsy rats", Clinical neurophysiology, Vol. 119, pp. 1747-1755, 2008.
- [6] U. Rajendra, et al, "Application of recurrence quantification analysis for the automated identification of epileptic EEG signals", International Journal of Neural Systems, Vol. 21, pp. 199-211, 2011.
- [7] M. Niknazar, et al, "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.
- [8] N. Marwan, M.C. Romano, M. Thiel, "Recurrence plots for the analysis of complex systems", Physics Reports, Vol. 438, pp. 237-329, 2007.
- [9] H. Rashidy, K. Faez, M. Hosseinzadeh, "Face recognition system using ant colony optimization-based selected features", Proceeding of the IEEE/CISDA, pp. 57-62, Honolulu, HI, April 2007.
- [10] W. Siedlecki, J. Sklansky, "A note on genetic algorithms for large-scale feature selection", Pattern Recognition Letters, Vol. 10, pp. 335-347, 1989.
- [11] A. Bon, et al, "Feature selection in beltline moulding process using genetic algorithm", Journal of Applied Sciences Research, Vol. 4, pp. 783-792, 2008.
- [12] R. Jensen, "Combining rough and fuzzy sets for feature selection", Ph.D. Thesis, School of Informatics, University, Edinburgh, 2005.
- [13] B. Liu, B. McKay, "Classification rule discovery with ant colony optimization", Proceeding of the IEEE/WIC/ACM, pp. 83-88, Oct. 2003.
- [14] Y. Meng, "A swarm intelligence based algorithm for proteomic pattern detection of ovarian cancer", Proceeding of the IEEE/CIBCB, pp. 1-7, Toronto, Ont., Sep. 2006.
- [15] R.G. Andrzejak, et al, "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state", Physical Review, pp. 64, 2001.

- [16] K. Ansari-Asl, et al. "Comparison of two estimators of time-frequency interdependencies between nonstationary signals: application to epileptic EEG", Proceeding of the IEEE/IEMBS, Vol. 1, pp. 263-266, San Francisco, CA, Sep. 2004.
- [17] M.P. Tarvainen, et al., "Estimation of nonstationary EEG with Kalman smoother approach: an application to event-related synchronization (ERS)", IEEE Trans. on Biomedical Engineering, Vol. 51, No. 3, pp. 516-524, March 2004.
- [18] Kaplan, Y. Alexander, et al., "Nonstationary nature of the brain activity as revealed by EEG/MEG: Methodological, practical and conceptual challenges", Signal Processing, Vol. 85, No. 11, pp. 2190-2212, 2005.
- [19] T. Dikanev, et al. "EEG nonstationarity during intracranially recorded seizures: statistical and dynamical analysis." Clinical Neurophysiology, Vol. 116, No. 8, pp. 1796-1807, 2005.
- [20] K.B. Korb, E. Ann, Nicholson. "Bayesian artificial intelligence". CRC press, 2010.
- [21] C.R. Twardy, et al., "Epidemiological data mining of cardiovascular Bayesian networks", Electronic Journal of Health Informatics. 2006.
- [22] V.P Nigam, G. Daniel, "A neural-network-based detection of epilepsy", Neurological Research, Vol. 26, pp. 55-60, 2004.
- [23] N. Kannathal, et al, "Entropies for detection of epilepsy in EEG", Computer Methods and Programs in Biomedicine, Vol. 80, pp. 187-194, 2005.
- [24] V. Srinivasan, C. Eswaran, N. Sriraam, "Artificial neural network based epileptic detection using time-domain and frequency-domain features", Journal of Medical Systems, Vol. 12, pp. 647-660, 2005.
- [25] N. Sadati, H. Mohseni, A. Maghsoudi, "Epileptic seizure detection using neural fuzzy networks", Proceeding of the IEEE/FUZZY, pp. 596-600, Vancouver, BC, 2006.
- [26] A. Subasi, "EEG signal classification using wavelet feature extraction and a mixture of expert model", Expert Systems with Applications, Vol. 32, pp. 1084-1093, 2007.
- [27] K. Polat, G. Salih, "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.
- [28] A.T. Tzallas, M.G. Tsipouras, D.I. Fotiadis, "Automatic seizure detection based on time-frequency analysis and artificial neural networks", Comput Intell Neurosci, 2007.
- [29] V. Srinivasan, C. Eswaran, N. Sriraam, "Approximate entropy-based epileptic EEG detection using artificial neural networks", IEEE Trans. on Information Technology in Biomedicine, Vol. 11, pp. 288-295, 2007.
- [30] P. Kemal, G. Salih, "Artificial immune recognition system with fuzzy resource allocation mechanism classifier, principal component analysis and FFT method based new hybrid automated identification system for classification of EEG signals", Expert Systems with Applications, Vol. 34, pp. 2039-2048, 2008.
- [31] K. Polat, G. Salih, "A novel data reduction method: Distance based data reduction and its application to classification of epileptiform EEG signals", Applied Mathematics and Computation, Vol. 200, pp. 10-27, 2008.
- [32] 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.
- [33] L. Guo, et al, "Classification of EEG signals using relative wavelet energy and artificial neural networks", Proceedings of the first ACM/SIGEVO Summit on Genetic and Evolutionary Computation, 2009.
- [34] L. Guo, R. Daniel, P. Alejandro, "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks", Journal of Neuroscience Methods, Vol. 193, pp. 156-163, 2010.
- [35] L. Guo, et al, "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.
- [36] A. Subasi, G.M. Ismail, "EEG signal classification using PCA, ICA, LDA and support vector machines", Expert Systems with Applications, Vol. 37, pp. 8659-8666, 2010.
- [37] E. Übeyli, "Least squares support vector machine employing model-based methods coefficients for analysis of EEG signals", Expert Systems with Applications, Vol. 37, pp. 233-239, 2010.
- [38] C. Lima, C. André, E. Marcio, "Tackling EEG signal classification with least squares support vector machines: A sensitivity analysis study", Computers in Biology and Medicine, Vol. 40, pp. 705-714, 2010.
- [39] L. Guo, et al, "Automatic feature extraction using genetic programming: An application to epileptic EEG classification", Expert Systems with Applications, Vol. 38, pp. 10425-10436, 2011.
- [40] D. Wang, M. Duoqian, X. Chen, "Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection", Expert Systems with Applications, Vol. 38, pp. 14314-14320, 2011.
- [41] Z. Iscan, D. Zümray, D. Tamer, "Classification of electroencephalogram signals with combined time and frequency features", Expert Systems with Applications, Vol. 38, pp. 10499-10505, 2011.
- [42] U. Orhan, M. Hekim, 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.
- [43] L. Charles, J. Webber, N. Marwan, "Recurrence quantification analysis: Theory and best practices", Springer, 2014.
- [44] J. Webber, L. Charles, J.P. Zbilut, "Recurrence quantification analysis of nonlinear dynamical systems", Tutorials in Contemporary Nonlinear Methods for the Behavioral Sciences, pp. 26-94, 2005.