

# شناسایی صرع بر اساس بهینه‌سازی ویژگی‌های ادغامی تبدیل هارتلی با مدل ترکیبی MLP و GA همراه با استراتژی یادگیری ممتیک

مرتضی به نام<sup>۱</sup>، دانش‌آموخته کارشناسی ارشد، حسین پورقاسم<sup>۲</sup>، دانشیار

۱- دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران - [morteza.behnam@sel.iaun.ac.ir](mailto:morteza.behnam@sel.iaun.ac.ir)

۲- دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران - [h\\_pourghasem@iaun.ac.ir](mailto:h_pourghasem@iaun.ac.ir)

**چکیده:** یکی از مسائل مهم در پردازش سیگنال‌های EEG، تشخیص حمله صرع است. در این مقاله، یک الگوریتم تشخیص و طبقه‌بندی سیگنال‌های مغزی حاوی حمله صرع از سیگنال‌های بدون حمله بر اساس ادغام ویژگی‌های تبدیل هارتلی پیشنهاد شده است. در این الگوریتم، علاوه بر استخراج ویژگی‌های معمول زمانی و فرکانسی مانند آنتروپی طیفی و چگالی طیف توان، یک ویژگی جدید مبتنی بر ادغام ویژگی‌های مستخرج از تبدیل هارتلی تعریف می‌شود. برای تعریف این ویژگی جدید، ویژگی‌های مستخرج از تبدیل هارتلی بر اساس یک سناریوی ماتریس کرنلی ادغام می‌شوند. جهت بهینه کردن و کاهش ابعاد بردار ویژگی مستخرج از سیگنال‌های مغزی، از یک مدل ترکیبی الگوریتم ژنتیک تحت استراتژی آموزش ممتیک و شبکه عصبی چندلایه پس‌انتشار خطا استفاده می‌شود. طبقه‌بندی نهایی بر روی این ویژگی‌های بهینه‌شده توسط یک شبکه عصبی پرسپترون با یک لایه پنهان انجام می‌شود و به‌طور میانگین صحت ۹۵/۳۲۵٪ را در طبقه‌بندی سیگنال‌های صرعی فراهم می‌کند.

**واژه‌های کلیدی:** سیگنال EEG، صرع، ویژگی‌های ادغامی تبدیل هارتلی، الگوریتم ژنتیک با استراتژی یادگیری ممتیک.

## Epilepsy Detection Based on Optimization of Fused Hartley Transform Feature with Hybrid Model of MLP and GA using Memetic Learning Strategy

M. Behnam<sup>1</sup>, M.Sc. Student, H. Pourghasem<sup>2</sup>, Associate Professor

1- Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Isfahan, Iran, [morteza.behnam@sel.iaun.ac.ir](mailto:morteza.behnam@sel.iaun.ac.ir)

2- Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad Isfahan, Iran, [h\\_pourghasem@iaun.ac.ir](mailto:h_pourghasem@iaun.ac.ir)

**Abstract:** One of the important problems in EEG signal analysis is epilepsy detection. In this paper, an epilepsy detection and classification algorithm is proposed based on fusion of the extracted Hartley transform features. In this algorithm, in addition to usual frequency and time features such as spectrum entropy and power spectral density, a novel feature is defined based on fusion of the extracted Hartley transform features. To define this feature, the extracted features from Hartley transform are fused based on a kernel matrixes scenario. To optimize and reduce the dimensions of extracted feature vector from EEG signals, a hybrid model is applied based on Genetic algorithm using Memetic learning strategy and multilayer back-propagation neural network. The final classification is carried out on the optimal feature vectors by a Perceptron neural network with a hidden layer and average accuracy rate of 95.325% is obtained.

**Keywords:** EEG signal, epilepsy, fused Hartley transform features, Genetic algorithm with Memetic learning strategy.


تاریخ ارسال مقاله: ۱۳۹۳/۰۷/۰۸

تاریخ اصلاح مقاله: ۱۳۹۳/۰۹/۰۳ و ۱۳۹۳/۱۰/۱۳

تاریخ پذیرش مقاله: ۱۳۹۳/۱۰/۱۳

نام و نام خانوادگی نویسنده مسئول: حسین پورقاسم

نشانی نویسنده مسئول: دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، اصفهان، ایران



شکل ۱: دیاگرام کلی سیستم پردازش سیگنال

در تمامی پژوهش‌هایی که تاکنون انجام شده است، ابتدا ریتم‌های مغزی که معمولاً به ۵ یا ۶ عدد تفکیک می‌شوند، از هر سیگنال مغزی استخراج می‌گردند. پس از آماده‌سازی سیگنال‌ها برای پردازش، با اعمال روش‌های مختلف خطی و غیرخطی پردازشی، ویژگی‌هایی از این ریتم‌ها به دست می‌آیند. با استفاده از روش‌های داده‌کاوی داده‌ها و ویژگی‌های استخراجی برای تشخیص حمله صرع آماده می‌شوند. بنابراین با استفاده از یک الگوریتم انتخاب ویژگی، صفات کارآمد سیگنال‌ها انتخاب شده و در نهایت با استفاده از یک طبقه‌بند، سیگنال‌های دارای حمله از سیگنال‌های بدون حمله تفکیک می‌گردند [۱۰]. در تمامی این موارد و کاربردها می‌توان سیستمی مشابه شکل ۱ را برای بررسی سیگنال‌ها پیشنهاد داد.

ویلسون در [۱۱] یک آشکارساز وقوع تشنج با عنوان Reveal را ارائه داد که با تفکیک سیگنال‌های مغزی به ایپاک‌های<sup>۲</sup> ۲ ثانیه‌ای و قوانین شبکه عصبی، فعالیت‌های ریتمیک ناشی از وقوع تشنج را با استفاده از ویژگی‌های زمان-فرکانس با دقت خوبی طبقه‌بندی می‌کرد. همچنین در [۱۲] گزارش می‌شود که این الگوریتم که برای آشکارسازی وقوع تشنج بر مبنای فعالیت‌های ریتمیک مغزی است، از دقت نسبتاً پایینی برخوردار است. در [۱۳ و ۱۴]، این الگوریتم‌ها به صورت خاص برای هر بیمار تغییر می‌کند و مشاهدات حاکی از آن است که دقت تشخیص حمله صرع و حساسیت نسبی طبقه‌بندی افزایش می‌یابد.

## ۲- روش پیشنهادی

در این مقاله، شناسایی و آشکارسازی وقوع حمله صرع و تشنج به صورت برون‌خطی<sup>۳</sup> صورت می‌گیرد. با توجه به شکل ۲، در ابتدا سیگنال‌های موجود در پایگاه داده<sup>۴</sup> که از کودکان مبتلا به صرع مقاوم در بیمارستان بوستون جمع‌آوری شده است، به ایپاک مساوی تقسیم شده و هر یک بر اساس وجود یا عدم وجود حمله صرع برچسب‌گذاری می‌شوند. سپس در مرحله آماده‌سازی، فیلترینگ مناسب توسط روش پنجره‌گذاری در فیلترهای FIR و استفاده از فیلتر کیزر-بسل سیگنال‌های EEG در محدوده موردنیاز در حوزه فرکانسی فیلتر شده و مقادیر نویز، DC و مؤلفه‌های ناخواسته شامل آرتیفکت‌های حرکتی و سیگنال‌های حیاتی دیگر حذف می‌شوند.

## ۱- مقدمه

مغز و سیستم اعصاب مرکزی انسان با توجه به ارتباطات الکتریکی و یونی بین سلول‌های عصبی با عنوان نورون و همچنین ارسال و دریافت ایمپالس‌های الکتریکی، به‌عنوان یک مجموعه وسیع از دوقطبی‌های الکتریکی به حساب می‌آید و تمامی پردازش‌های ذهنی انسان در آن انجام می‌شود. ثبت این فعالیت‌های الکتریکی را EEG<sup>۱</sup> می‌نامند که از طریق نصب الکترودهای مناسب بر روی پوست سر، با استفاده از سیستم‌های متفاوت نصب الکترود مانند سیستم ۱۰-۲۰ قابل انجام است [۱]. به دلیل تضعیف سیگنال‌های رسیده به الکترودها، به خصوص در عبور از بافت استخوانی جمجمه و همچنین هدایت حجمی جریان الکتریکی در بافت مغز، سیگنالی که در هر الکترود ثبت می‌شود در حقیقت برآیند فعالیت‌های الکتریکی موجود در نواحی الکترود مزبور است. لذا تشخیص و پیش‌بینی رخداد‌های مختلف مغزی با بررسی این سیگنال‌ها همواره دارای اهمیت بوده است. از جمله این کاربردها می‌توان به سیستم‌های رابط انسان و رایانه (BCI)<sup>۱</sup> اشاره نمود. همچنین از نمونه‌های بسیار مهم، آشکارسازی شروع تشنج در بیماران مبتلا به صرع است [۲ و ۳]. در این‌گونه بیماران از ثبت دائمی سیگنال‌ها و پردازش بلادرنگ آن‌ها برای پیش‌بینی و تشخیص حمله صرع استفاده می‌گردد. در سال‌های اخیر تلاش‌های فراوانی برای معرفی معیارها و استراتژی‌های مناسب به‌منظور تشخیص حملات صرعی به صورت خودکار صورت گرفته است. این روش‌ها علاوه بر این‌که پزشک را در تشخیص بیماری کمک می‌کنند، درک مکانیزم‌های نهفته در بیماری را نیز آشکار می‌سازند.

در روش‌های کلاسیک، آنالیز و بررسی انواع سیگنال‌های الکتروانسفالوگرام تنها به بررسی ویژگی‌های مکانی و زمانی سیگنال‌ها خلاصه می‌شود. بیماری صرع را می‌توان به‌عنوان ناهنجاری دینامیکی سیستم مغز به شمار آورد [۴]. همواره مشاهده می‌شود که سیگنال‌های مغزی در حالت نرمال دارای خواص آشوبی هستند، در زمان وقوع حملات صرع این سیگنال‌ها نظم و خواص نیمه‌پریودیکی را از خود نشان می‌دهند و دوباره در پایان حمله صرع به مد آشوب‌گونه خود بازمی‌گردند. با آغاز حملات صرعی، پیچیدگی سیگنال‌ها کم‌تر شده و با پایان حمله به حالت اولیه خود بازمی‌گردند [۴].

لذا روش‌های متفاوتی برای تحلیل و بررسی سیگنال‌های مغزی ارائه شده است. این روش‌ها عمدتاً شامل استفاده از بعد همبستگی [۵]، نمای لیاپانوف [۶]، آنتروپی تقریبی [۷]، منحنی‌های بازگشتی و آنالیزهای مربوطه [۸] بوده است. این معیارها، تنها ویژگی‌های کلی دینامیک‌های غیرخطی را نشان می‌دهند، اما تفاوت‌های کوچک بین حالات دینامیکی مختلف، به‌خصوص وقتی داده‌ها کوتاه و نویزی می‌باشند را نشان نمی‌دهند [۹]. لذا در این مقاله سعی شده است تا با معرفی معیارهای مناسب نظیر آنتروپی طیفی، تبدیل هارتلی و چندین ویژگی زمان-فرکانس دیگر این‌گونه مشکلات کنار گذاشته شود.

که K از نظر تئوری بینهایت است. با توجه به طیف فرکانسی سیگنال‌های مغزی و همچنین مؤلفه‌های فرکانسی سیگنال در حالت تشنج سیگنال‌های EEG در تمامی ایپاک‌ها در فرکانس‌های زیر فیلتر می‌گردند [۱۸ و ۱۹]:

$$\omega_{c1} = 0.5 \text{ Hz}, \omega_{c2} = 35 \text{ Hz} \quad (3)$$

ناحیه عبور در فرکانس‌های زیر است:

$$\omega_{p1} = 0.55 \text{ Hz}, \omega_{p2} = 35.1 \text{ Hz} \quad (4)$$

میزان ریپل و نوسانات پاسخ فرکانسی فیلتر میان‌گذر در باندهای عبور و توقف به‌صورت زیر تعیین شده است:

$$\delta_1 = \delta_2 = 0.01, \delta_3 = 0.05 \quad (5)$$

نمای پاسخ فرکانسی فیلتر در شکل ۳، و نمونه‌ای از سیگنال مغزی فیلترشده در شکل ۴ مشاهده می‌شود.

#### ۴- استخراج ویژگی

در این گام ۱۰ ویژگی یکسان از تمامی سیگنال‌های موجود در پایگاه داده استخراج می‌شود، لذا برای هر سیگنال یک بردار ویژگی با طول ۱۰ درایه به دست خواهد آمد. برای این منظور ابتدا سیگنال‌ها به دسته‌های کوچک‌تری تقسیم شده است و ویژگی‌های موردنظر از هر یک از این دسته‌ها استخراج می‌شود. پارامترهایی همچون تعداد دسته‌ها (N) و طول نمونه‌های دسته‌ها (L) اثر مهمی در طبقه‌بندی داده‌ها دارند و با تغییر هر یک نتیجه نهایی تغییر خواهد کرد. ویژگی‌ها در نهایت در یک بردار ویژگی بنام  $x_i$  به ازای  $i=1, 2, \dots, N$  قرار می‌گیرند.

#### ۴-۱- ویژگی‌های زمانی سیگنال

پس از تعریف پارامتری به‌عنوان طول هر دسته از سیگنال‌ها به میزان ۶۰ نمونه، هر سیگنال با گام‌های ۶۰ تایی جدا می‌شود. سپس با محاسبه مقدار میانگین سیگنال در هر پنجره [۱۷]، دنباله‌ای برای هر سیگنال به دست خواهد آمد که معرف تغییرات دامنه متوسط سیگنال مغزی در هر ایپاک است. تغییرات دامنه متوسط سیگنال‌ها به‌صورت زیر به دست می‌آید:

$$\bar{x}(t) = \frac{1}{N} \sum_i x(i) \quad (6)$$

که  $x$  یک سری زمانی و معرف هر یک از سیگنال‌های EEG است.

#### ۴-۱-۱- ویژگی ماکزیمم دامنه میانگین

این ویژگی معادل، بیشترین دامنه موجود در سیگنال متوسط تغییرات دامنه است [۲۰]، که از رابطه زیر محاسبه می‌شود:

$$s_{max} = \max\{\bar{x}(t)\} \quad (7)$$

در مرحله بعد، ویژگی‌های متفاوتی از هر ایپاک استخراج می‌گردد؛ به‌گونه‌ای که می‌توان گفت این ویژگی‌ها شامل پارامترهای آماري سیگنال‌ها در فضای زمان و فرکانس می‌باشند. پارامترهایی مانند: آنتروپی‌های طیفی، چگالی طیف توان مقابل و تغییر یافته و همچنین واریانس طیفی. از طرف دیگر ویژگی جدیدی با استفاده از طیف تبدیل هارتلی و ادغام ویژگی‌های مستخرج از آن توسط روش ماتریس‌های کرنلی محاسبه شده است، که در بخش‌های بعدی مقاله درباره آن صحبت خواهد شد. در نهایت با تشکیل بردار ویژگی برای هر ایپاک از سیگنال‌ها، عمل بهینه‌سازی و کاهش ابعاد بردار ویژگی توسط مدل ترکیبی از شبکه عصبی چندلایه پرسپترون (MLP) و الگوریتم ژنتیک تحت استراتژی یادگیری ممتیک با نام روش لامارکین، صورت گرفته است. ویژگی‌های بهینه و مجموعه داده‌های هدف برای تعیین تعداد نورون‌های لایه پنهان و بهینه‌سازی طبقه‌بندی سیگنال‌ها در طبقه‌بند BPNN، مورد پردازش قرار می‌گیرد. در انتها، با استفاده از شبکه عصبی پس‌انتشار خطا با الگوریتم یادگیری لونیگ، سیگنال‌های موجود در پایگاه داده به دو کلاس صرعی و سالم طبقه‌بندی می‌شوند. همان‌طور که مشاهده می‌شود، در شکل ۲ تمامی مراحل و الگوریتم پیشنهادی برای تشخیص حمله صرع به‌طور خلاصه نمایش داده شده است.

#### ۳- آماده‌سازی سیگنال‌ها

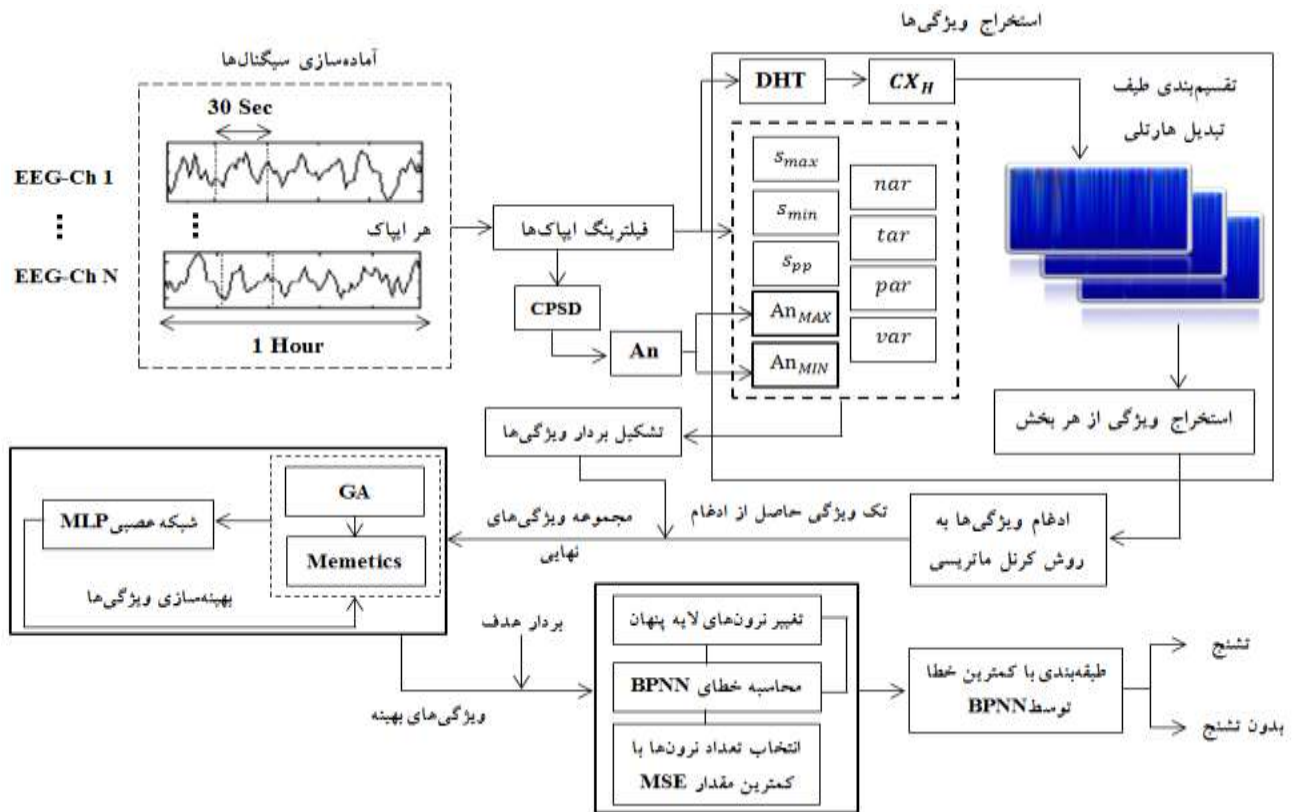
در ابتدای کار نیاز است تا تمامی سیگنال‌های ثبت‌شده آماده پردازش گردند. برای این منظور می‌بایست در ابتدا سیگنال‌ها را در محدوده موردنظر فیلتر نمود. لذا با استفاده از روش پنجره‌گذاری در طراحی فیلترهای FIR یک پنجره Kaiser-Bessel انتخاب می‌نماییم [۱۵]. از جمله مزایای این پنجره این است که ضرایب فیلتر ساده‌تر ایجاد می‌شوند و مصالحه بین سطح گلبرگ‌های جانبی و سطح آویز اصلی با انتخاب پارامتر  $\alpha$  تنظیم می‌گردد [۱۶]. این پنجره به‌صورت زیر تعریف می‌شود:

$$w[n_{KB}] = \frac{I_0\left[\beta\left(1-\left[\frac{n_{KB}-\alpha}{\alpha}\right]^2\right)^{\frac{1}{2}}\right]}{I_0(\beta)} \quad (1)$$


$$0 \leq |n_{KB}| \leq \frac{N}{2}$$

که در این رابطه  $\beta = \alpha\pi$  بوده و  $n_{KB}$  شماره نمونه تابع پنجره است،  $\alpha$  نیز یک پارامتر عددی قابل تنظیم است. همچنین N تعداد نقاط نمونه قابل تنظیم است. مقدار  $\alpha = \frac{N}{2}$  و  $I_0(\cdot)$  تابع بسل مرتبه صفر نوع اول را نشان می‌دهد [۱۷]. تابع بسل تغییر یافته از درجه صفر و از نوع اول به‌صورت زیر است:


$$I_0(x) = \sum_{k=0}^K \left[ \frac{\left(\frac{x}{2}\right)^{2k}}{k!} \right]^2 \quad (2)$$



شکل ۲: الگوریتم پردازشی برای آشکارسازی وقوع تشنج



شکل ۳: پاسخ فرکانسی فیلتر کیزر



شکل ۴: یک اپیک از سیگنال مغزی فیلترشده

۴-۱-۶- مجموع نواحی مثبت و منفی

$$tar = nar + par \quad (12)$$

که  $\bar{x}(t)$  تغییرات دامنه متوسط سیگنال‌های مغزی است.

#### ۴-۱-۲- ویژگی مینیمم دامنه میانگین

کم‌ترین دامنه موجود در سیگنال متوسط تغییرات دامنه [۲۰]، که با استفاده از رابطه زیر محاسبه می‌شود:

$$s_{min} = \min\{\bar{x}(t)\} \quad (8)$$

#### ۴-۱-۳- تفاضل بیش‌ترین و کم‌ترین دامنه

$$s_{pp} = s_{max} - s_{min} \quad (9)$$

#### ۴-۱-۴- ناحیه مثبت دنباله متوسط تغییرات دامنه

این ویژگی عبارت است از مجموع مقادیر مثبت هر دسته از سیگنال‌های مغزی [۲۰]، که به صورت زیر محاسبه می‌شود:

$$par = \sum_{i=1}^{number\ of\ signal} 0.5(s(t) + |s(t)|) \quad (10)$$


که  $s(t)$  هر دسته از سیگنال‌ها است.

#### ۴-۱-۵- ناحیه منفی دنباله متوسط تغییرات دامنه


مجموع مقادیر منفی هر دسته از سیگنال‌ها به صورت رابطه زیر محاسبه می‌شود:

$$nar = \sum_{i=1}^{number\ of\ signal} 0.5(s(t) - |s(t)|) \quad (11)$$


دو ویژگی تحت نام‌های ماکزیمم و مینیمم مقدار آنتروپی طیفی متوسط به ترتیب با گرافی مشابه شکل ۶ و شکل ۷ محاسبه می‌گردند.



شکل ۵: هم‌پوشانی ۵۰٪ پنجره‌های دنباله‌ها



شکل ۶: ماکزیمم مقدار آنتروپی طیفی متوسط



شکل ۷: مینیمم مقدار آنتروپی طیفی متوسط

### ۳-۲-۴- ویژگی واریانس طیف توان

مقادیر امید ریاضی و واریانس سری زمانی  $x(n)$  با در نظر گرفتن خود هم ناسازگاری آن به صورت زیر است:

$$E[x(n)] = \frac{1}{N} \sum_{n=0}^{N-1} x(n) \quad (16)$$

$$var[x(n)] = E[(x(n) - \bar{x}(n))^2] \quad (17)$$

### ۲-۲-۴- ویژگی‌های فرکانسی

Harris (۱۹۷۸)، به آثار و مشخصات متفاوت پنجره بر روی کارایی پنجره‌ها به تفصیل رسیدگی کرده و نتیجه گرفته است که تأثیرات اصلی بر روی کیفیت پنجره عبارت‌اند از بالاترین سطح و بیش‌ترین مقدار دامنه گلبرگ جانبی و تلفات ناشی از پردازش در بدترین حالت [۲۱]. لذا پنجره Blackman - Harris دارای کارایی بیش‌تری نسبت به سایر پنجره‌ها است. برای استخراج ویژگی‌های فرکانسی از این پنجره از طول نمونه استفاده شده است. هنگامی که داده‌ها پنجره می‌شوند انتهای توالی داده‌ها به‌سوی صفر میل می‌کند و این در واقع اتلاف اطلاعات است. به‌خصوص که ممکن است اتفاقات با طول کوتاه در ناحیه باریک‌شده از دست برود. لذا می‌بایست برای حل این مشکل، پنجره‌ها با یکدیگر هم‌پوشانی داشته باشند. بنابراین در اینجا این هم‌پوشانی برابر ۵۰٪ در نظر گرفته شده است، شکل ۵، در این حالت طیف‌های حاصله میانگین‌گیری می‌شوند تا تخمینی از طیف واقعی به دست آید [۱۷]. واریانس طیف با متوسط‌گیری از طیف‌های حاصل کاهش می‌یابد. واریانس متوسط برای  $k$  اندازه‌گیری معادل و مستقل از نظر آماری  $1/k$  برابر واریانس طیف مستقل است.

### ۴-۲-۱- محاسبه چگالی طیف توان متقابل (CPSD)

در اینجا برای محاسبه CPSD یک سیگنال گسسته در زمان از روش پریودوگرام تغییر یافته و استراتژی Welch استفاده می‌گردد [۲۲]. در این روش واریانس چگالی طیف توان بیش‌تر کاهش می‌یابد که البته به قیمت کاهش بیش‌تر در تفکیک نمایی طیفی است. در این روش  $L$  بخش از داده‌ها به طول  $M$  روی هم می‌افتند و پریودوگرام‌ها از  $L$  بخش داده پنجره‌شده محاسبه می‌گردند. این پریودوگرام توسط عامل  $U$  در رابطه زیر نرمالیزه می‌شود تا از اتلاف روی هم افتادگی جلوگیری شود [۲۳]:

$$U = \frac{1}{M} \sum_{n=0}^{M-1} \omega^2(n) \quad (13)$$

تخمین چگالی طیف توان Welch برابر است با  $P_{WE}$  که به صورت زیر تعریف می‌شود [۱۷]:

$$P_{WE}(f) = \frac{1}{L} \sum_{j=0}^{L-1} P_j(f) \quad (14)$$


لذا می‌توان با توجه به امید ریاضی طیف Welch بیان نمود که وقتی مقادیر  $M$  و  $N$  بزرگ باشد، واریانس تخمین Welch به‌سوی صفر میل می‌کند و بایاس نشده باقی می‌ماند.

### ۴-۲-۲- محاسبه آنتروپی طیفی

برای محاسبه مقدار آنتروپی طیفی [۲۴]، دنباله چگالی طیف توان متقابل با مقدار نامی  $An$ ، به صورت عبارت (۱۵) به دست می‌آید:

$$An = - \sum_i P_{WE} \log P_{WE} \quad (15)$$

که رابطه بالا برای هر ایپاک به صورت یک دنباله خواهد بود. لذا برای هر سیگنال، متوسط مقدار آنتروپی طیفی محاسبه می‌گردد و متناظراً



شکل ۸: منحنی واریانس طیف توان

لذا در دوره تناوب N خواهیم داشت:

$$R\{X(k)\} = \frac{X_H(k) + X_H(N-k)}{2} \quad (23)$$

$$I\{X(k)\} = -\frac{X_H(k) - X_H(N-k)}{2} \quad (24)$$

بنابراین در نهایت، رابطه بین ضرایب تبدیل فوری و تبدیل هارتلی به صورت زیر خواهد بود [۲۵]:

$$X_H(k) = R\{X(k)\} - I\{X(k)\} \quad (25)$$

با توجه به حقیقی بودن ورودی و خروجی تبدیل هارتلی، پیاده‌سازی آن به تعداد  $\frac{1}{2}$  تبدیل فوریه سریع، نیازمند عملیات ضرب است. لذا از لحاظ هزینه محاسباتی، سرعت و فضای محاسباتی بسیار کارآمدتر خواهد بود. از طرفی به جای استفاده از کرنل نمایی مختلط از مجموع توابع سینوس و کسینوس استفاده شده است که همان خواص را در حالت حقیقی بیان می‌نمایند.

در نهایت با معرفی تبدیل هارتلی و استخراج ضرایب آن به عنوان ویژگی، برای تشخیص حمله صرع می‌بایست ابتدا ضرایب آماده شوند. برای این منظور، با اعمال تبدیل هارتلی به تمامی سیگنال‌های موجود در پایگاه داده، مجموعه مؤلفه‌های تبدیل در یک ماتریس ضرایب تنظیم می‌گردند. ماتریس ضرایب با نام  $CX_H$  به صورت زیر است:

$$CX_H = \begin{bmatrix} X_{H,1}(1) & X_{H,2}(1) & \dots & X_{H,M}(1) \\ X_{H,1}(2) & X_{H,2}(2) & \dots & X_{H,M}(2) \\ X_{H,1}(3) & X_{H,2}(3) & \dots & X_{H,M}(3) \\ \vdots & \vdots & \ddots & \vdots \\ X_{H,1}(L) & X_{H,2}(L) & \dots & X_{H,M}(L) \end{bmatrix} \quad (26)$$

که در این ماتریس، L برابر با تعداد نمونه‌های هر سیگنال است که با طول تبدل یکسان خواهد بود، هم‌چنین M تعداد سیگنال‌های مورد آزمایش است.

با محاسبه ماتریس  $CX_H$  برای نمونه‌ها، تصویری از تغییرات طیفی سیگنال‌های دارای حمله صرع و سیگنال‌های سالم به دست می‌آید. در شکل ۹ نمونه‌ای از نمایش طیفی ماتریس  $CX_H$  برای تعدادی از سیگنال‌های EEG مشاهده می‌شود.

برای استخراج ویژگی مناسب از این طیف، طیف به ۳ اپک مساوی در طول محور فرکانسی تقسیم می‌شود. سپس می‌توان مقادیر

$$c_{xx}(m) = E[(x(n) - \bar{x}(n))(x(n+m) - \bar{x}(n))] \quad (18)$$

که در رابطه بالا مقدار m بر تأخیر دلالت دارد. از طرفی با توجه به رابطه زیر:

$$bias = \alpha - E[\alpha] \quad (19)$$

اگر بایاس صفر باشد در این صورت تخمین مقدار واقعی را می‌دهد [۱۷]، و اگر صفر نباشد مقدار خطا در  $\alpha$  را نشان می‌دهد. واریانس  $\alpha$  اندازه‌ای از پهنای قله تابع توزیع و چگالی احتمال  $\alpha$  است. واریانس کوچک‌تر، نشان‌دهنده قله باریک است و وقتی واریانس چگالی طیف به سمت صفر میل می‌کند مقدار تخمین‌زده شده طیف به سمت مقدار واقعی خود نزدیک می‌شود. لذا واریانس طیف توان مطابق شکل ۸، می‌تواند به عنوان ویژگی دیگری از سیگنال‌های صرعی باشد.

#### ۴-۲-۴- پیشینه ضرایب تبدیل Hartley سریع

با توجه به مطالب گفته‌شده توسط Wang و Bracewell در ۱۹۸۰ تبدیل هارتلی گسسته (DHT)، از لحاظ ساختاری مشابه تبدیلاتی نظیر، تبدیل فوریه گسسته (DFT) و تبدیل کسینوسی گسسته (DCT) می‌باشد [۲۵]. الگوریتم پیاده‌سازی تبدیل هارتلی سریع یا FHT بسیار شبیه به FFT است. ضرایب تبدیل مستقیم هارتلی گسسته به صورت رابطه زیر است [۲۵]:

$$X_H(k) = \sum_{n=0}^{N-1} x(n) \cdot \text{cas}\left(\frac{2\pi nk}{N}\right) \quad (20)$$

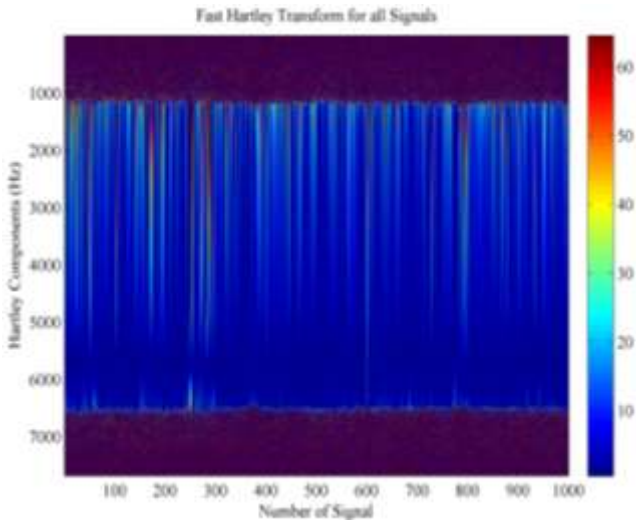
که در این رابطه، مقدار کرنل  $\text{cas}\varphi$  به صورت عبارت بیان شده در رابطه (۲۱) قابل تبیین است.

$$\text{cas}\varphi = \cos\varphi + \sin\varphi \quad (21)$$

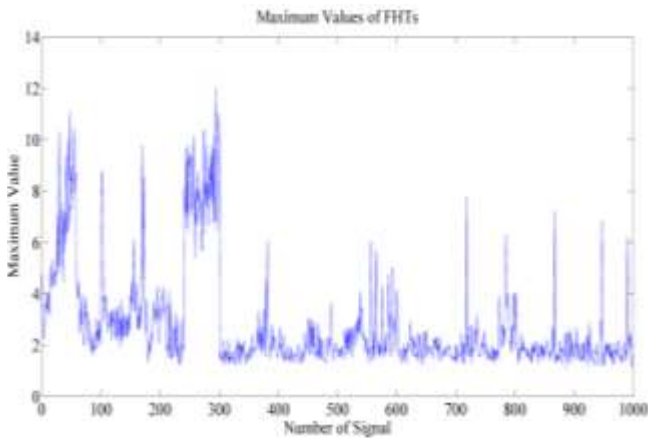
همچنین سیگنال  $x(t)$  یک سیگنال با مقادیر حقیقی در نظر گرفته می‌شود. لذا تبدیل هارتلی گسسته نیز دارای مقادیر حقیقی است. همانند یک DFT، تعداد نمونه‌های تبدیل DHT نیز برابر با طول سیگنال‌های مغزی است. تبدیل هارتلی پررودیک است و مقدار این دوره تناوب برابر با N است [۲۶].

با توجه به کرنل تبدیل هارتلی،  $\text{cas}\varphi_k t$  که در آن  $\varphi_k = \frac{2\pi k}{N}$  است، می‌توان بالاترین مؤلفه فرکانسی را به ازای  $k = \frac{N}{2}$  در نظر گرفت و بیان نمود که k امین و (N - k) امین مؤلفه فرکانسی با یکدیگر یکسان هستند. لذا می‌توان با برقراری رابطه بین DFT و DHT، تبدیل هارتلی سریع را پیاده‌سازی نمود. رابطه بین این دو تبدیل به صورت زیر است:

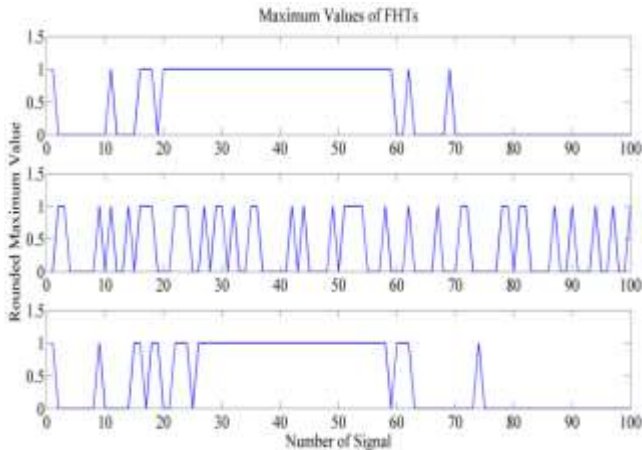
$$e^{j\varphi} = \frac{1+j}{2} \text{cas}(\varphi) + \frac{1-j}{2} \text{cas}(-\varphi) \quad (22)$$



شکل ۹: نمایش الگوی طیفی ماتریس  $CX_H$



شکل ۱۰: منحنی مقادیر ماکزیمم حاصل از طیف تبدیل هارتلی



شکل ۱۱: مدل آستانه‌گذاری شده برای ۳ دنباله ماکزیمم طیفی به صورت محلی

بر مبنای مطالب ارائه شده توسط Kuncheva در [۲۷]، در اینجا دو قانون برای ادغام ویژگی‌ها بیان می‌شود و بر اساس آن‌ها یک روش ترکیبی ارائه خواهد شد.

قانون اول: میانگین

$$(K_{f-ave})_{ij} = \frac{(K_x)_{ij} + (K_y)_{ij} + (K_z)_{ij}}{3} \quad (32)$$

ماکزیمم محلی را در هر سری فرکانسی و در هر قسمت از ضرایب تبدیل هارتلی در نظر گرفت. لذا با محاسبه مقدار ماکزیمم محلی مؤلفه‌ها، در قالب یک دنباله از ماکزیمم‌ها به صورت مجموعه زیر خواهیم داشت:

$$MCX_H = \max\{CX_H\} = \max\{\max\{X_{H,1}(j), X_{H,2}(j), \dots, X_{H,i}(j)\}_i\}_j \quad (27)$$

که  $i = 1, 2, \dots, M$  و مقدار  $j = 1, 2, \dots, L/3$  است. در واقع هر سیگنال شامل ۳ مقدار ماکزیمم خواهد بود که ماتریس دنباله ماکزیمم‌های محلی با نام  $MCX_H$  به صورت زیر است:

$$MCX_H = \begin{bmatrix} MCX_{H11} & MCX_{H12} & MCX_{H13} \\ MCX_{H21} & MCX_{H22} & MCX_{H23} \\ \vdots & \vdots & \vdots \\ MCX_{HM1} & MCX_{HM2} & MCX_{HM3} \end{bmatrix} \quad (28)$$

دنباله حاصل که تنها شامل ماکزیمم مقدارهای موجود به صورت محلی در ۳ پنجره از دنباله تبدیل هارتلی تمامی سیگنال‌ها است، به صورت نمونه در شکل ۱۰ قابل نمایش است.

برای ایجاد ویژگی مناسب با توجه به منحنی شکل ۱۰ با در نظر گرفتن یک مقدار آستانه به صورت میانگین مقادیر موجود در دنباله ماکزیمم‌ها و اعمال این آستانه بر روی دنباله مزبور، مقادیر ماکزیمم از مؤلفه‌های طیفی تبدیل هارتلی به دو دسته تقسیم می‌شوند. با در نظر گرفتن تقریب مناسب و باینری برای این دو دسته از اطلاعات، دو مقدار خیلی کوچک و خیلی بزرگ که برای آموزش شبکه عصبی به دلیل اختلاف زیاد و تغییر قابل ملاحظه در وزن‌های شبکه عصبی بسیار مناسب هستند، برای هر سیگنال ۳ ویژگی محاسبه می‌شود. این سه ویژگی برای سیگنال‌های حاوی تنشج دارای مقدار بیشینه و برای سیگنال‌های بدون تنشج دارای مقدار کمینه است. شکل ۱۱ نمودار این ویژگی‌ها را برای طیفی از سیگنال‌ها نمایش می‌دهد.

#### ۴-۲-۴-۱- روش ادغام ویژگی‌های FHT با ماتریس‌های کرنلی

برای ایجاد یک ویژگی معتبر به جای استفاده از ۳ ویژگی استخراج شده از تبدیل هارتلی از یک روش ادغام مبتنی بر ماتریس‌های کرنلی استفاده می‌شود. ابتدا ۳ ویژگی مزبور به صورت مجموعه‌های  $\{x_i\}$  و  $\{y_i\}$  و  $\{z_i\}$  تعریف می‌شوند. نگاشت این ویژگی‌ها به یک فضای ویژگی با ابعاد وسیع، با نام  $F$  توسط سه نگاشت غیرخطی  $\varphi_x$  و  $\varphi_y$  و  $\varphi_z$  صورت می‌گیرد. کرنل ماتریسی برای این سه صفت استخراجی را می‌توان به صورت زیر در نظر گرفت:

$$(K_x)_{ij} = k_x(x_i, x_j) \quad (29)$$

$$(K_y)_{ij} = k_y(y_i, y_j) \quad (30)$$

$$(K_z)_{ij} = k_z(z_i, z_j) \quad (31)$$

**قانون دوم : جمع وزن‌دار**

$$(K_{f-wsum})_{ij} = \alpha(K_x)_{ij} + \beta(K_y)_{ij} + \gamma(K_z)_{ij} \quad (33)$$

که در این رابطه  $\alpha + \beta + \gamma = 1$  است. پس از ادغام ماتریس‌ها، ماتریس کرنل تحت عنوان ماتریس  $K_f$  ایجاد می‌شود.  $K_f$  ماتریس همبستگی نمونه‌ها در فضای F است. در اینجا ثابت می‌شود که پس از ادغام هم، همچنان کرنل نهایی، معتبر است. لذا برای قاعده میانگین می‌توان نشان داد که با فرض:

$$\sum_{i,j=1}^n c_i c_j k_x(x_i, x_j) \geq 0, \forall c_i \in R \quad (34)$$

$$\sum_{i,j=1}^n c_i c_j k_y(y_i, y_j) \geq 0, \forall c_i \in R \quad (35)$$

$$\sum_{i,j=1}^n c_i c_j k_z(z_i, z_j) \geq 0, \forall c_i \in R \quad (36)$$

ماتریس کرنل  $K_f$  بعد از ادغام،  $K_\varphi(\varphi_i, \varphi_j)$  نامیده می‌شود. لذا:

$$\sum_{i,j=1}^n c_i c_j K_\varphi(\varphi_i, \varphi_j) \geq 0 \quad (37)$$

$$\begin{aligned} &= \sum_{i,j=1}^n c_i c_j \frac{\{k_x(x_i, x_j) + k_y(y_i, y_j) + k_z(z_i, z_j)\}}{3} \\ &= \frac{\sum_{i,j=1}^n c_i c_j k_x(x_i, x_j)}{3} + \frac{\sum_{i,j=1}^n c_i c_j k_y(y_i, y_j)}{3} \\ &\quad + \frac{\sum_{i,j=1}^n c_i c_j k_z(z_i, z_j)}{3} \geq 0 \end{aligned}$$

بنابراین مقدار کرنل  $K_{f-ave}$  همواره مقدار مثبتی دارد. همچنین برای قانون میانگین مقدار  $K = k_x \otimes k_y \otimes k_z$  را تنسور ضرب می‌نامیم. هم‌چنین برای قانون دوم و برای جمع وزن‌دار شده خواهیم داشت:

$$\sum_{i,j=1}^n c_i c_j K_\varphi(\varphi_i, \varphi_j) \geq 0 \quad (38)$$

$$\begin{aligned} &= \sum_{i,j=1}^n c_i c_j \{ \alpha k_x(x_i, x_j) + \beta k_y(y_i, y_j) + \gamma k_z(z_i, z_j) \} \\ &= \alpha \sum_{i,j=1}^n c_i c_j k_x(x_i, x_j) \\ &\quad + \beta \sum_{i,j=1}^n c_i c_j k_y(y_i, y_j) \\ &\quad + \gamma \sum_{i,j=1}^n c_i c_j k_z(z_i, z_j) \geq 0 \end{aligned}$$

لذا  $K_{f-wsum}$  نیز هنوز مثبت است. رابطه حاصل از ترکیب دو قانون به صورت زیر خواهد بود:

$$(K_{f-wsa})_{ij} = \frac{\{\alpha(K_x)_{ij} + \beta(K_y)_{ij} + \gamma(K_z)_{ij}\}}{3n} \quad (39)$$

که  $\alpha + \beta + \gamma = 1$  است و  $n$  ضریب نرمالیزاسیون است. با توجه به مطالب اثبات‌شده، مقدار  $K_{f-wsa}$  نیز همواره یک کرنل معتبر است [۲۷].

لذا ۳ ویژگی به دست آمده از ایپاک‌بندی طیف تبدیل هارتلی در مرحله قبل، با استفاده از رابطه (۳۹) با یکدیگر ادغام می‌شوند. در

نهایت، یک ویژگی برای هر سیگنال ایجاد می‌گردد که ترکیبی از ۳ ویژگی محلی است که این ویژگی در اینجا ویژگی ادغام‌شده از طیف شکسته یا FFBS<sup>۲</sup> نامیده می‌شود.

**۵- بهینه‌سازی ویژگی‌ها**

با توجه به این‌که ممکن است تمامی ویژگی‌های استخراج‌شده در تشخیص وقوع حمله صرع مفید نباشند، لذا می‌بایست ویژگی‌های بهینه انتخاب شوند و عمل طبقه‌بندی سیگنال‌ها به واسطه آن‌ها صورت پذیرد. در این مقاله برای یافتن ویژگی‌های مناسب از ترکیب شبکه‌ی عصبی MLP و الگوریتم ژنتیک و استفاده از الگوریتم‌های ممتیک با استراتژی یادگیری لامارکین در الگوریتم ژنتیک مورد استفاده قرار گرفته است [۲۸].

**۵-۱- ساختار ترکیبی شبکه MLP و GA، استراتژی**

**ممتیک و یادگیری لامارکین**

برای جستجوی ویژگی‌های بهینه توسط الگوریتم ژنتیک، ابتدا یک جمعیت اولیه شامل ۲۰ کروموزوم به طول ۱۰ ژن تولید می‌گردد. ژن‌های این کروموزوم‌ها به صورت باینری بوده و تنها مقادیر صفر و یک را دارا می‌باشند. بنابر این مقدار یک نشان‌دهنده وجود ویژگی با اندیس مربوطه و مقدار صفر نشان‌دهنده عدم وجود ویژگی موردنظر در ساختار الگوی ژنی است.

شبکه عصبی، یک شبکه چندلایه پرسپترون تحت قاعده پس‌انتشار خطا و همچنین با استفاده از تابع آموزش تحت عنوان Levenberg-Marquardt است. معماری شبکه عصبی به صورت feed-forward بوده [۲۹] و دارای یک لایه پنهان است. با توجه به تعداد ویژگی‌های استخراج‌شده، تعداد نرون‌های لایه‌ی ورودی همواره بین [۰, ۱۰] متغیر بوده که به ساختار ژنی حاصل از GA وابسته است. برای جلوگیری از Over-fitting شبکه، تعداد نرون‌های لایه پنهان، ۲ برابر نرون‌های لایه ورودی در نظر گرفته شده است. در هر بار آموزش شبکه عصبی مقدار ۷۰٪ داده‌های پایگاه داده به عنوان مجموعه آموزشی و ۳۰٪ داده‌ها به عنوان مجموعه آزمایش شبکه در نظر گرفته می‌شود. در نهایت مقدار MSE شبکه برای هر بردار ویژگی ورودی محاسبه می‌گردد.

بنابر این برای محاسبه خطای شبکه عصبی از روابط زیر استفاده

می‌شود:

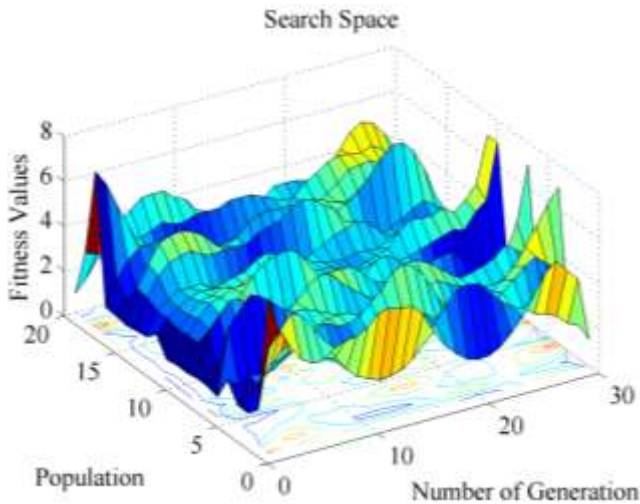
$$net_j = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (40)$$

$$y_j = f_j(net_j) \quad (41)$$

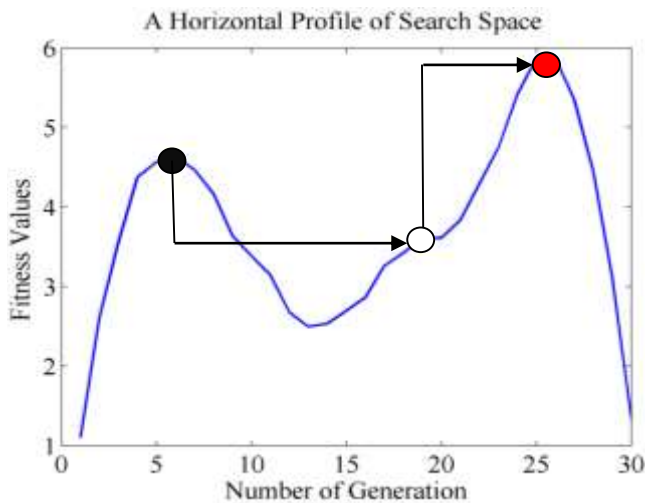
$$e_j(n) = d_j(n) - y_j(n) : Error \quad (42)$$

که  $d$  خروجی هدف و  $y$  خروجی حاصل از شبکه است. همچنین مقدار  $e$  خطای عملکردی شبکه است. لذا خطای کل خروجی شبکه عصبی  $\xi$ ، به ازای  $c$  نرون در لایه خروجی برابر است با:





شکل ۱۲: بخشی از فضای تحت جستجوی الگوریتم ژنتیک در مساله بهینه‌سازی ویژگی‌ها



شکل ۱۳: یک برش افقی از فضای جستجو

لذا این‌گونه برداشت می‌گردد که جستجوی تمامی فضا امری بیهوده و زمان‌بر بوده و از طرفی نیاز به جستجوی مناسب برای یافتن جوابی که تا جای ممکن بهینه باشد، حس می‌شود.

شکل ۱۲ قسمتی از فضای جستجو در این پژوهش است. همان‌طور که مشاهده می‌گردد فضای جستجو از ضابطه خاصی پیروی نکرده و یافتن مقدار بهینه آن نیازمند الگوریتمی مناسب است. هم‌چنین شکل ۱۳ یک برش افقی از فضای جستجو است. با در نظر گرفتن شکل ۱۳، می‌توان مقایسه‌ای بین الگوریتم ژنتیک ساده و الگوریتمی تحت قاعده یادگیری لامارکین داشت. اگر دایره سیاه محل اولیه و آغازین الگوریتم ژنتیک در نظر گرفته شود، دایره سفید نشان‌دهنده گام بعدی جستجو در مدل ساده الگوریتم است و دایره قرمز نشان‌دهنده گام بعدی جستجو با استفاده از استراتژی لامارکین است. لذا همان‌طور که مشاهده می‌شود، نتیجه حاصل از اعمال روش یادگیری برای الگوریتم ژنتیک بسیار بهینه‌تر از مدل ساده آن است. دلیل این مسئله را می‌توان ماهیت مدل یادگیرنده لامارکین دانست.

$$\xi(n) = \sum_{j=c} e^2(n) : \text{total Error} \quad (43)$$

همچنین مقدار MSE شبکه برای N داده‌ی آموزشی برابر خواهد بود با:

$$MSE = \xi_{ave} = \frac{1}{N} \sum_{n=1}^N \xi(n) \quad (44)$$

پس از آموزش شبکه عصبی برای هر ۲۰ کروموزوم ورودی اولیه به شبکه، مقدار  $\frac{1}{MSE}$  به‌عنوان تابع برازندگی الگوریتم ژنتیک به‌صورت زیر محاسبه می‌شود [۳۰]:

$$\text{fitness function} = \frac{1}{MSE(\text{net})} \quad (45)$$

استراتژی‌های ممتیکی بر اثر یک مقایسه ژنی در زمینه تکامل فرهنگی توسط فردی به‌نام Dawkins معرفی شده است. Meme یک عنصر فرهنگی یا رفتاری است که به وسیله عوامل غیرژنتیکی از نسلی به نسل بعد منتقل می‌گردد [۳۱]. ساختار یک الگوی ممتیکی و هم‌چنین یادگیری لامارکین به‌عنوان یک نوع خاص از الگوریتم‌های ممتیکی، دارای دو ویژگی عمده است، پاسخ بهبودیافته پس از فرآیند جستجوی محلی، جایگزین کروموزوم‌های اولیه می‌شود و هم‌چنین مفاهیم یادگرفته شده مستقیماً وارد دنباله ژنی کروموزوم می‌گردند. این‌گونه عملکرد نسبت به یادگیری‌هایی نظیر الگوریتم بالدوینی، بسیار مناسب‌تر خواهد بود [۳۲].

در مفاهیم بهینه‌سازی آماری پیشرفته، الگوریتم یادگیری لامارکین، به‌عنوان یکی از استراتژی‌های جستجو بر مبنای جمعیت می‌باشد. در حالت کلی الگوریتم ژنتیک بر مبنای یک عملکرد تصادفی، رشته‌ای از کروموزوم‌ها را به‌عنوان جمعیت اولیه تولید می‌نماید. این جمعیت با استفاده از قوانینی نظیر تقابل نسل‌ها و جهش که قوانینی قانون‌مند و درعین‌حال بر مبنای تصادف و احتمال می‌باشند، عمل کرده و نسل جدیدی از کروموزوم‌ها را ایجاد می‌نمایند [۳۳]. در حقیقت می‌توان این مسئله را به‌این‌صورت بیان نمود که الگوریتم ژنتیک به‌عنوان یک الگوریتم تکاملی و یک الگوریتم جستجوی سراسری عمل می‌کند. برخلاف سایر الگوریتم‌های جستجو که به‌عنوان نمونه بر مبنای گرادیان رفتار می‌کنند، الگوریتم ژنتیک هیچ‌گاه در اکسترم‌های محلی گرفتار نمی‌شود و به واسطه ماهیت تصادفی آن از هر نقطه فضای جستجو به نقطه دیگر جهش می‌نماید [۳۲].

در یک الگوریتم ژنتیک ساده پس از تعدادی تولید نسل تصادفی و بررسی میزان برازندگی آن‌ها مقدار بهینه انتخاب می‌گردد. سؤالی که در اینجا مطرح می‌گردد، این است که آیا این الگوریتم کل فضا را جستجو نموده است؟ اگر پاسخ مثبت است، پس چه لزومی به استفاده از الگوریتم ژنتیک وجود دارد و اگر پاسخ منفی است چه لزومی دارد که نتیجه نهایی حاصل از جستجو بهینه باشد.

نمونه‌برداری ۲۵۶ هرتز و هم‌چنین رزولوشن ۱۶ بیت هستند. از این سیگنال‌ها ۲۰۴۰ عدد دارای نشانه‌های حمله صرع هستند [۳۷].

## ۶-۲- تنظیم پارامترهای FFBS

ویژگی ادغام‌شده از طیف شکسته، در واقع با شکستن طیف تبدیل هارتلی سیگنال‌های EEG و استخراج ویژگی‌های بیان‌شده در مراحل پیشین و هم‌چنین ادغام این ویژگی‌ها به‌صورت زیر بیان می‌شود:

$$(K_{FFBS})_{ij} = \frac{\{\alpha k_x(x_i, x_j) + \beta k_y(y_i, y_j) + \gamma k_z(z_i, z_j)\}}{3 \times Normalization} \quad (49)$$

که در این رابطه مقادیر پارامترهای  $\alpha$  و  $\beta$  و  $\gamma$  همواره ثابت بوده و دارای مجموع واحد است. برای اثبات رابطه (۴۹) به‌عنوان یک قاعده ادغام برای سه ویژگی مستخرج از طیف تبدیل هارتلی، می‌توان به طریقی مشابه با اثبات قانون اول و دوم عمل نمود. بنابراین، با در نظر گرفتن رابطه (۳۸) به‌صورت زیر خواهیم داشت:

$$\sum_{i,j=1}^n c_i c_j K_\varphi(\varphi_i, \varphi_j) \geq 0 \quad (50)$$

$$\begin{aligned} (K_{FFBS})_{ij} &= \\ &= \sum_{i,j=1}^n c_i c_j \frac{\{\alpha k_x(x_i, x_j) + \beta k_y(y_i, y_j) + \gamma k_z(z_i, z_j)\}}{3 \times Normalization} \\ &= \frac{1}{3 \times Normalization} \left\{ \sum_{i,j=1}^n c_i c_j \{\alpha k_x(x_i, x_j) + \beta k_y(y_i, y_j) + \gamma k_z(z_i, z_j)\} \right\} \\ &= \frac{\alpha}{3 \times Normalization} \sum_{i,j=1}^n c_i c_j k_x(x_i, x_j) \\ &\quad + \frac{\beta}{3 \times Normalization} \sum_{i,j=1}^n c_i c_j k_y(y_i, y_j) \\ &\quad + \frac{\gamma}{3 \times Normalization} \sum_{i,j=1}^n c_i c_j k_z(z_i, z_j) \\ &\geq 0 \end{aligned}$$

همان‌طور که مشاهده می‌گردد، ویژگی FFBS با توجه به مقادیر مثبت پارامترهای تنظیم آن و هم‌چنین روابط اثبات‌شده در زیر بخش روش ادغام ویژگی‌های FHT با ماتریس‌های کرنل (روابط ۲۹ تا ۳۹)، همواره معتبر بوده و می‌توان از آن به‌عنوان یک رابطه برای ادغام ویژگی‌های موردنظر بهره برد.

در رابطه (۴۹)، ۳ پارامتر  $\alpha$  و  $\beta$  و  $\gamma$  به‌عنوان وزن‌های هر ویژگی و هم‌چنین یک پارامتر اختیاری تحت عنوان ضریب نرمالیزاسیون وجود دارد. انتخاب این پارامترها بسته به کاربردهای آن نوع ویژگی‌های موجود متفاوت است. برای محاسبه این ضرایب و هم‌چنین ایجاد بهترین ادغام از راهکاری آماری مبتنی بر منحنی تغییرات FFBS به ازای مقادیر مختلف پارامترهای مختلف تأثیرگذار استفاده شده است [۲۷].

این روش به‌عنوان یکی از استراتژی‌های رایج الگوریتم‌های ممتیک، به‌دلیل وجود یک مرحله اضافی تحت عنوان جستجوی محلی در هر نسل، مقدار بهینه را برای عمل انتخاب نسل در مرحله تولید نسل بعدی آماده می‌سازد. در حقیقت این رفتار شاید مشابه اتفاقی باشد که در الگوریتم بهینه‌سازی ازدحام ذرات (PSO) پیش می‌آید [۳۴].

با این حال احتمال انتخاب یک همسایگی در الگوریتم ممتیک بر اساس رابطه بولتزمن برای پذیرش و انتخاب همسایه بهینه به‌صورت رابطه زیر است [۳۴]:

$$P(\text{accepting neighbour}) = \begin{cases} 1, & \Delta f > 0 \\ e^{\frac{k\Delta f}{f_{max} - f_{avg}}}, & \Delta f < 0 \end{cases} \quad (46)$$

که در این رابطه مقدار  $\Delta f$  به‌صورت زیر تعریف می‌شود:

$$\Delta f = \text{fitness of neighbour} - \text{Current fitness} \quad (47)$$

مقدار  $f$  نشان‌دهنده میزان برزندگی در هر نقطه است. لذا با اعمال قاعده یادگیری لامارکین در زمان جستجو، می‌توان به‌صورت بهینه‌تری فضا را بررسی نمود و جواب نهایی الگوریتم دارای قابلیت اطمینان بیشتری است [۳۴].

در ساختار GA از ۲۰ کروموزوم موجود در جمعیت اولیه، ۱۰ عدد کروموزوم جدید ایجاد می‌گردد. در تولید و انتخاب نسل بعدی، کروموزوم‌های بهینه‌تر جایگزین این کروموزوم‌های ضعیف خواهند شد [۳۵]. مشخصات ساختاری الگوریتم و پارامترهای اساسی آن شامل ۳ مورد می‌باشند، که به‌صورت زیر بیان شده‌اند:

۱. تعداد نسل‌ها<sup>۱۴</sup> به‌میزان ۳۰ نسل در انتخاب نسل اول.
۲. درصد جهش<sup>۱۵</sup> به‌میزان ۱٪ احتمال جهش برای هر ژن.
۳. درصد تقابل<sup>۱۶</sup> به‌میزان ۵۰٪ یا به‌عبارتی ۵ ژن از ۱۰ ژن.

مراحل الگوریتم ژنتیک با تقابل تک‌نقطه‌ای و جهش‌های وارون‌ساز صورت گرفته است. در این مسئله بهینه‌سازی، فضای جستجو با توجه به قاعده شمارش  $n^r$  برابر است با:

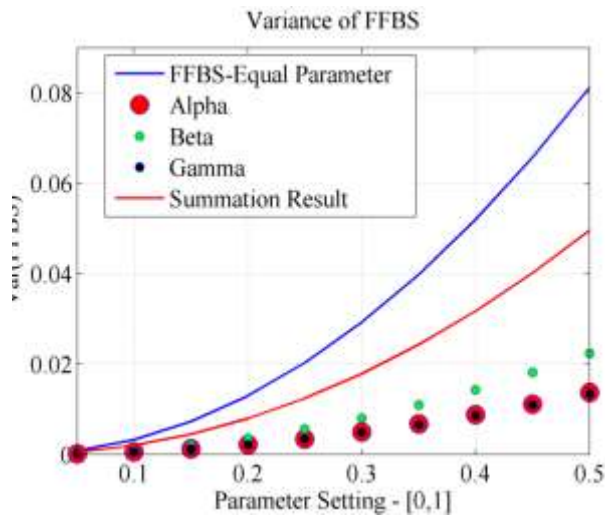
$$\text{Energyfunction} : 2^{\text{number of features}} = 2^{10} = 1024 \quad (48)$$

مشاهده می‌شود، ابعاد فضای جستجو برابر با ۱۰۲۴ حالت مختلف می‌باشد [۳۶].

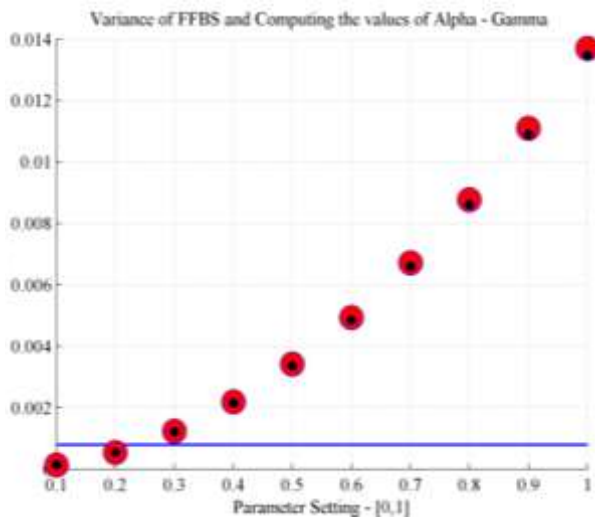
## ۶- نتایج آزمایش‌ها

### ۶-۱- مجموعه داده‌های EEG

این مجموعه از داده‌ها، شامل سیگنال‌های EEG از کودکان مبتلا به تشنج مقاوم نسبت به درمان است که از بیمارستان کودکان بوستون (CHB-MIT)، جمع‌آوری شده است. افراد مورد آزمایش تا چند روز پس از خروج داروهای ضد تشنج برای مداخله و عمل جراحی تحت نظر قرار گرفته‌اند. در این مقاله تنها از ۱۰۰ ساعت از سیگنال‌های مغزی استفاده شده است. هر سیگنال به  $N=120$  قسمت تقسیم شده است و هر ایپاک دارای طول زمانی ۳۰ ثانیه است. لذا در کل ۱۲۴۸۰ سیگنال وجود دارد که تماماً دارای فرکانس



شکل ۱۴: مقادیر واریانس ویژگی‌ها قبل از ادغام برحسب نرخ تغییرات  $\alpha$  و  $\beta$  و  $\gamma$  و نمایش مجموع واریانس ۳ حالت موجود



شکل ۱۵: تعیین ضرایب  $\alpha$  و  $\gamma$  از برخورد منحنی واریانس تغییرات

برای تعیین مقادیر  $\alpha$  و  $\gamma$  ابتدا ۱۰ مقدار حاصل از ویژگی FFBS که به ازای مقادیر  $\alpha = \beta = \gamma$  برای تمامی سیگنال‌ها محاسبه شده است، میانگین‌گیری شده و واریانس بردار حاصل برای تعیین پراکندگی داده‌ها به‌طور متوسط با مقادیر حاصل از رابطه‌های (۵۱) تا (۵۳) برخورد داده می‌شود. شکل ۱۵ نتیجه این برخورد را برای تعیین ضرایب  $\alpha$  و  $\gamma$  نشان می‌دهد. همان‌طور که مشاهده می‌شود حداقل فاصله بین ۳ منحنی به‌طور متوسط به ازای  $\alpha = \gamma = 0.2$  رخ داده است. همچنین برای تعیین پارامتر  $\beta$  مقدار میانگین  $(K_{FFBS})_{ij}$  به ازای تغییرات  $\beta$  در بازه  $[0,1]$  در حالتی که دو پارامتر  $\alpha = \gamma$  برابر ۰/۲ در نظر گرفته شده است، محاسبه می‌شود. در ادامه نیز این مقدار با واریانس ویژگی  $(K_{FFBS})_{ij}$  به ازای تغییرات  $\alpha = \beta = \gamma$  در همان بازه مقایسه خواهد شد. شکل ۱۶ نشان‌دهنده دو منحنی حاصل از میانگین‌گیری  $(K_{FFBS})_{ij}$  با تنظیم  $\alpha = \gamma = 0.2$  و منحنی  $(K_{FFBS})_{ij}$  با تنظیم  $\alpha = \beta = \gamma$  است.

با توجه به این موضوع که پارامترهای  $\alpha$  و  $\beta$  و  $\gamma$  دارای مجموع واحد و همچنین دارای مقادیری در بازه  $[0,1]$  هستند؛ با محاسبه نرخ پراکندگی داده‌های حاصل از ادغام یا ویژگی FFBS برای تمام سیگنال‌های EEG، مقدار بهینه برای پارامترهای تنظیم محاسبه خواهد شد. بر این اساس خواهیم داشت:

$$(K_{FFBS-\alpha})_{ij} = \frac{\{\alpha k_x(x_i, x_j)\}}{3 \times \text{Normalization}} \quad (51)$$

$$(K_{FFBS-\beta})_{ij} = \frac{\{\beta k_x(x_i, x_j)\}}{3 \times \text{Normalization}} \quad (52)$$


$$(K_{FFBS-\gamma})_{ij} = \frac{\{\gamma k_x(x_i, x_j)\}}{3 \times \text{Normalization}} \quad (53)$$

که  $(K_{FFBS-\alpha})_{ij}$  و  $(K_{FFBS-\beta})_{ij}$  و  $(K_{FFBS-\gamma})_{ij}$  ویژگی‌هایی تنها با تأثیر یک پارامتر هستند. در واقع فرض شده است در هر بار یک ویژگی موجود است و سایر ضرایب صفر در نظر گرفته شده است.

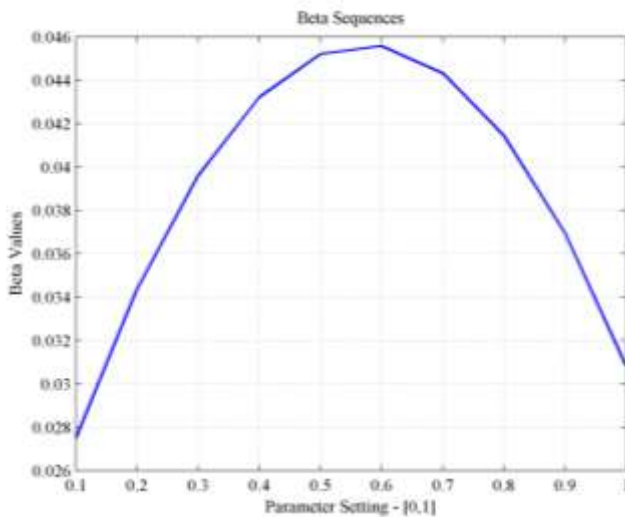
سیس برای هر ویژگی قبل از ادغام مقادیر واریانس آن‌ها محاسبه می‌گردد [۳۸]. این امر در حالی است که برای نمونه در رابطه (۵۱) با تغییرات مقادیر  $\alpha$  در بازه  $[0,1]$  با گام‌هایی به طول 0.1 مقادیر  $\beta$  و  $\gamma$  صفر در نظر گرفته شده است. شکل ۱۴ نمودار تغییرات واریانس ویژگی‌ها را با احتساب تنها یک پارامتر تنظیم نشان می‌دهد.

در شکل ۱۴، منحنی آبی رنگ نمایش‌دهنده حالتی است که  $\alpha = \beta = \gamma$  است. همان‌طور که دیده می‌شود، نرخ تغییرات دارای رشد نمایی و بیش‌تر از حالتی است که ضرایب دارای مقادیر متفاوتی می‌باشند. در شکل ۱۴ مشاهده می‌گردد که نرخ تغییرات واریانس ویژگی ادغام‌شده، حاصل از تغییرات پارامتر  $\alpha$  و  $\gamma$  که هر یک در غیاب دو پارامتر دیگر محاسبه شده است، کاملاً یکسان است. لذا می‌توان این‌گونه نتیجه‌گیری نمود که اثر این دو ویژگی با یکدیگر مساوی است. این مسئله در حالی مطرح می‌شود که پارامتر  $\beta$  دارای مقادیری کاملاً متفاوت از نرخ واریانس آن‌ها است.


نکته قابل‌ملاحظه این است که مقادیر  $\alpha$  و  $\gamma$  نماینده وزن ویژگی‌هایی است که از طیف تبدیل هارتلی در محدوده‌های فرکانس‌های پایین و بالا استخراج شده است، ولی پارامتر  $\beta$  به وزن ویژگی مستخرج از طیف در فرکانس‌های میانی اشاره دارد. لذا مقدار بزرگ یا کوچک آن‌ها مبین تأثیر باند فرکانسی هر یک در بروز و تشخیص حمله صرع است.



شکل ۱۶: محاسبه میزان انحراف FFBS در دو حالت  $\alpha = \gamma = 0.2$  با  $\beta$  متغیر و حالت  $\alpha = \beta = \gamma$  با تغییر ۳ پارامتر



شکل ۱۷: دنباله  $\beta$  برای تعیین مقدار بیشینه و بهینه آن



شکل ۱۸: همگرایی در GA در ترکیب با MLP پس از ۶۰۰ بار تولید نسل در مقیاس ۰/۱

برای تعیین تعداد نرون‌های لایه پنهان از یک حلقه تکرار شامل ۳۰ بار آموزش شبکه عصبی با تعداد نرون‌های مخفی مختلف استفاده شده

لذا می‌توان بیشینه فاصله موجود بین دو نمودار و در نتیجه نقطه مطلوب برای پارامتر  $\beta$  را به صورت زیر محاسبه نمود [۳۸]:

$$\beta = \left| \text{Max} \left\{ \frac{1}{10} \sum (K_{FFBS})_{ij} - \frac{1}{9} \sum ((K_{FFBS})_{ij} - \frac{1}{10} \sum (K_{FFBS})_{ij})^2 \right\} \right| \quad (54)$$

که در این رابطه مقدار  $\beta$  حاصل، مقداری است که باید در رابطه نهایی برای ادغام ویژگی‌ها در نظر گرفته شود. نمودار شکل ۱۷ مقادیر مختلف  $\beta$  را نشان می‌دهد که مقدار ماکزیمم آن جواب مسئله خواهد بود. بنابر این  $\beta = 0.6$  و از محاسبات و شبیه‌سازی‌های قبلی نیز  $\alpha = 0.2$  به دست آمده است. همچنین مقدار ضریب نرمالیزاسیون برابر با مقدار ۱ در نظر گرفته شده است.

بنابر این می‌توان این گونه استنباط نمود که ویژگی‌های موجود در طیف فرکانسی تبدیل هارتلی از لحاظ اهمیت به دو دسته قابل تقسیم هستند: دسته اول شامل ویژگی‌های استخراج شده از فرکانس‌های پایین و بالا و دسته دوم شامل مؤلفه‌هایی با فرکانس متوسط هستند. به عبارت دیگر، این موضوع اهمیت فرکانس‌های میانی در طیف را نشان می‌دهد؛ زیرا پس از محاسبه پارامترهای تنظیمی برای FFBS مقدار ضریب  $\beta$  حدود ۳ برابر  $\alpha$  و  $\gamma$  محاسبه شده است.

### ۳-۶- نتایج حاصل از بهینه‌سازی

پس از ۳۰ بار تولید نسل، آموزش‌های مداوم شبکه عصبی MLP و تولید بردارهای ویژگی تصادفی، سرانجام الگوریتم ژنتیک به سمت نسل بهینه همگرا می‌شود، شکل ۱۸ این همگرایی را نشان می‌دهد. لذا تمام نسل‌ها در خروجی آن، بردارهایی کاملاً یکسان و بهینه خواهند بود.

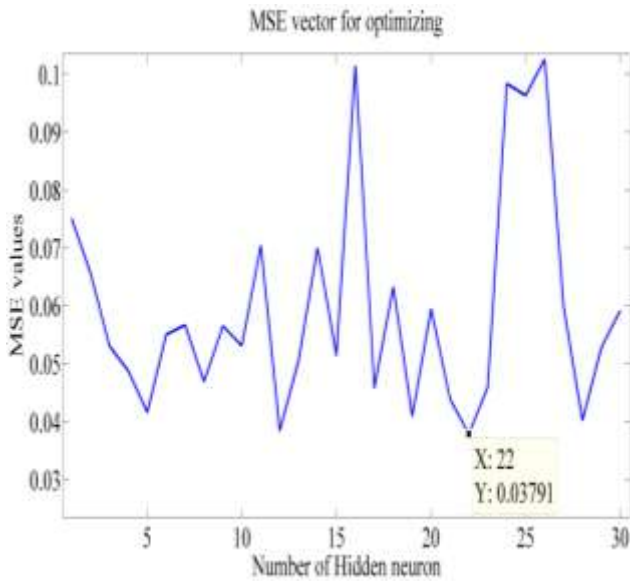
در نهایت برداری که پیروز رقابت می‌شود و در جستجوی سراسری توسط GA به عنوان برداری با مینیمم خطای ممکن شناخته می‌گردد، به صورت بردار زیر است:

$$\text{OptimumFeatures} = [1011010001] \quad (55)$$

لذا ویژگی‌های بهینه متناظر، برابر با ۵ مورد از ۱۰ ویژگی هستند. این ویژگی‌ها عبارت‌اند از: ماکزیمم دامنه میانگین، تفاضل بیش‌ترین و کم‌ترین دامنه، واریانس طیف توان، ماکزیمم مقدار آنترپی طیفی متوسط و مقادیر حاصل از ادغام ویژگی‌های طیفی در تبدیل هارتلی. لذا برای طبقه‌بندی نهایی از این ویژگی‌ها استفاده خواهد شد.

### ۴-۶- طبقه‌بندی با استفاده از BPNN

در نهایت برای طبقه‌بندی سیگنال‌های دارای صرع از سیگنال‌های مغزی بدون حالت تشنج از شبکه عصبی پرسپترون چندلایه با الگوی پس‌انتشار خطا با استفاده از تابع آموزشی لوبنرگ، استفاده می‌شود. شبکه BPNN یک شبکه با یک لایه پنهان بوده و با توجه به ویژگی‌های بهینه‌شده، تعداد نرون‌های لایه ورودی ۵ عدد است.



شکل ۱۹: بهینه‌سازی تعداد نرون‌های لایه پنهان

در ابتدا مجموعه کل پایگاه داده با استفاده از الگوریتم اعتبار سنجی K-fold به چهار مجموعه داده با هم‌پوشانی مناسب تفکیک می‌گردد. سپس با تعیین مجموعه داده‌های آموزشی، یک طبقه‌بند عمل تشخیص سیگنال‌های دارای تشنج از سیگنال‌های سالم را انجام می‌دهد. در هر مجموعه داده، مجموعه آموزشی ۷۵٪، مجموعه آزمایشی ۱۵٪ و ۱۰٪ نیز به‌عنوان داده‌هایی برای سنجش اعتبار و ارزیابی شبکه عصبی برای هر مجموعه داده در نظر گرفته شده است. لذا به ازای هر ۴ مجموعه داده، ۴ شبکه عصبی ایجاد می‌گردد. هر شبکه به ازای هر مجموعه دارای یک مجموعه از ۳ مقدار صحت شامل صحت آموزش، صحت آزمایش و صحت ارزیابی است. در آخر با محاسبه عملکرد نهایی هر طبقه‌بند، بدترین طبقه‌بندی و بدترین شبکه عصبی به‌عنوان شبکه آموزش‌دیده نهایی انتخاب می‌گردد تا در حد امکان از بایاس‌های ناخواسته جلوگیری شود.

پس از انتخاب طبقه‌بند نهایی، داده‌های در نظر گرفته شده به‌عنوان مجموعه ارزیابی برای بار دیگر و به دلیل سنجش اعتبار نهایی توسط طبقه‌بند، انتخاب شده و دوباره تحت آزمایش قرار می‌گیرند. این نتایج را اعتبارسنجی نهایی یا به اختصار FVCH<sup>۱۹</sup> می‌نامیم. برای ارزیابی ویژگی‌های استخراج شده و همچنین صحت این تحقیق، میانگین و واریانس تمام نتایج حاصل از مراحل قبل و خطای شبکه عصبی به ازای تمام مجموعه‌ها محاسبه شده و در جدول ۱ مشاهده می‌گردد.

پس از آموزش شبکه عصبی در ۲۰۰ تکرار در نهایت منحنی عملکرد شبکه عصبی به‌صورت میانگین به سمت بهترین مقدار MSE در ۰/۰۳۸۸۰۰ همگرا شده است. شبکه با دقت ۹۵/۳۲۵٪ به‌طور میانگین طبقه‌بندی سیگنال‌های دارای تشنج را از سیگنال‌های EEG بدون تشنج انجام می‌دهد. همچنین میزان اعتبارسنجی یا ارزیابی طبقه‌بندی برای تمامی مجموعه داده‌ها برابر با ۹۳/۷۵٪ است. مقدار بسیار کوچک واریانس خطای MSE نشان از انحراف بسیار کوچک

است. در هر بار آموزش شبکه، خطای طبقه‌بندی محاسبه می‌گردد و در آخر بهترین گزینه برای نرون‌های لایه میانی شبکه عصبی انتخاب می‌گردد. شکل ۱۹ منحنی خطای BPNN را بر اساس تعداد مختلف نرون‌های لایه پنهان نشان می‌دهد. برای این منظور از کل داده‌های موجود برای شبیه‌سازی استفاده شده است، به‌گونه‌ای که ۷۰٪ داده برای آموزش، ۲۰٪ به‌عنوان مجموعه آزمایشی و ۱۰٪ برای ارزیابی عملکرد نهایی شبکه در هر بار آموزش استفاده شده است. لذا برای جلوگیری از سرریز شبکه عصبی با در نظر گرفتن ۲۲ نرون برای لایه میانی در حالت کلی و بدون تقسیم‌بندی داده‌ها، میانگین مربعات خطا در مقدار ۰/۰۳۷۹۱ همگرا می‌گردد. لازم به ذکر است که تابع انتقال لایه خروجی به‌صورت سیگموئید است. همچنین ۳ شرط هم‌زمان برای توقف آموزش شبکه عصبی [۳۹]، به‌صورت زیر در نظر گرفته می‌شود:

۱. تعداد ۲۰۰ تکرار در هر اپیاک.
۲. همگرایی در میانگین مربعات خطا در مقدار  $10^{-6}$ .
۳. همگرایی در نزول مقدار گرادیان خطا در  $10^{-9}$ .

#### ۴-۴-۶-۱- ارزیابی K-fold و جزءبندی پایگاه داده<sup>۱۹</sup>

برای شبیه‌سازی نهایی و آموزش شبکه عصبی BPNN بهینه با استفاده از ویژگی‌های بهینه‌سازی شده، از الگوریتم K-fold برای جزءبندی پایگاه داده استفاده شده است [۴۰]. تقسیم‌بندی مناسب و مجموعه‌های آزمایش و آموزش و اجرای شبکه عصبی با هر قسمت، موجب می‌گردد تا در آخر امید ریاضی نتیجه نهایی طبقه‌بندی که حاصل از میانگین‌گیری نتایج مجزای هر قسمت است، به‌سمت مقدار واقعی خود میل نماید. خطای الگوریتم K-fold با استفاده از میانگین خطای هر مرحله تخمین زده می‌شود. این خطا به‌صورت زیر تعریف می‌شود:

$$E_{K-fold} = \frac{1}{K} \sum_{i=1}^K E_i \quad (56)$$

که در این رابطه  $E_i$  خطای ناشی از هر بخش‌بندی است و همچنین مقدار K تعداد تقسیمات پایگاه داده را نشان می‌دهد. مزیت این روش این است که تمام داده‌های موجود هم در روند آموزش و هم در روند آزمایش شرکت می‌کنند و تعمیم‌پذیری طبقه‌بند، مورد آزمایش و بررسی دقیق قرار می‌گیرد.

#### ۴-۴-۶-۲- نتایج آزمایش و طبقه‌بندی نهایی

هدف از آزمایش نهایی بررسی بردار ویژگی‌های استخراج شده از سیگنال‌های EEG جهت تشخیص برون‌خطی بیماری صرع و آشکارسازی سیگنال‌های دارای تشنج و بدون تشنج از یکدیگر است. در واقع و به بیان ساده‌تر، هدف پیاده‌سازی طبقه‌بند بهینه‌سازی شده و استفاده از داده‌های جزءبندی شده در مجموعه‌های مجزا است.

## ۶-۶- مقایسه با پژوهش‌های دیگر

ارائه یک مقایسه جامع و کامل بین پژوهش‌های قبلی و الگوریتم پیشنهادی به دلیل تفاوت پایگاه داده و همچنین معیارهای متفاوت ارزیابی، کار مشکلی است. به‌هرحال جهت مشخص شدن جایگاه الگوریتم پیشنهادی در بین پژوهش‌های فراوانی که در زمینه تشخیص بیماری صرع انجام شده است، یک مقایسه اجمالی بر اساس ابزارهای مورد استفاده در استخراج ویژگی، بهینه‌سازی ویژگی و طبقه‌بندی و همچنین عملکرد الگوریتم‌ها ارائه می‌شود. به‌عنوان نمونه در [۴۰]، انتخاب ویژگی‌های بهینه و همچنین کاهش ابعاد ویژگی‌ها در ۴ کلاس کاری بیان شده است. طبقه‌بندی سیگنال‌ها به‌طور متوسط هنگامی که از تانسور GTDA استفاده شده است، برابر با  $0.72/0.62$ ؛ همچنین به ازای استفاده از LDA، JCA و PCA میزان صحت طبقه‌بندی به ترتیب برابر با  $0.70/0.29$ ؛  $0.67/0.88$ ؛  $0.63/0.85$  بوده است. به‌طور مشابه در مرجع [۳]، از تانسور GTDA به‌عنوان یک روش پایه‌ای برای تخمین وقوع حمله صرع استفاده شده است، در این تحقیق با توجه به اهمیت پیش‌بینی وقوع حمله صرع، زمان نهفتگی و مدت‌زمان پردازش نیز دارای اهمیت است. لذا با بررسی پایگاه داده استاندارد و در نظر گرفتن ۴۴ بیمار، به‌طور متوسط دارای صحت عملکرد  $0.98$  و زمان تأخیری برابر با  $4/5$  ثانیه است. همچنین در مقاله [۴۱]، پردازش همزمان سیگنال‌های ECG و EEG جهت تشخیص و همچنین تخمین یا پیش‌بینی وقوع حمله صرع استفاده شده است، حال آنکه صحت این تشخیص با در نظر گرفتن تنها سیگنال‌های EEG برابر با  $0.84/0.55$  است، از طرفی در یک کار مشابه در [۴۲]، با اضافه نمودن یک ادغام ویژگی که به‌واسطه تابع Gabor صورت گرفته است. این نتیجه به  $0.84/0.95$  می‌رسد. به‌عنوان یک نمونه دیگر در مقاله [۳۱]، با استفاده از ویژگی‌های مبتنی بر طیف تبدیل موجک و همچنین ادغام ویژگی‌ها و کاهش ابعاد آن‌ها با استفاده از PCA و به‌عنوان یک روش بهینه‌سازی، برای طبقه‌بندی سیگنال‌های مغزی در کاربرد ICB توسط شبکه‌های عصبی در نهایت، صحت تشخیصی برابر با  $0.72/0.24$  به دست آمده است. به‌عنوان پژوهشی دیگر در زمینه تشخیص دو کلاس بیماری صرع، مرجع [۴۳] با استفاده از ویژگی‌های مبتنی بر تبدیلات موجک از ریت‌های سیگنال‌های EEG و همچنین استفاده از الگوریتم ژنتیک ساده برای بهینه‌سازی ویژگی‌ها توانسته است، با استفاده از طبقه‌بند ماشین بردار پشتیبان (SVM)، عمل طبقه‌بندی را برای سیگنال‌های دچار حمله صرع به میزان  $0.91/0.8$  تشخیص دهد، همچنین این الگوریتم سیگنال‌های طبیعی و بدون حمله را به میزان  $0.93/0.3$  تفکیک می‌نماید. این مسئله در حالی است که بدون بهینه‌سازی ویژگی‌ها و تنها با استفاده از این طبقه‌بند، این مقادیر به ترتیب برابر با  $0.81/0.2$  و  $0.90$  شده است. در ادامه می‌توان به مرجع [۴۴] اشاره نمود. در این پژوهش با استفاده از ویژگی‌های مبتنی بر تجزیه مقادیر منفرد (SVD) و استفاده از شبکه عصبی المن بهینه‌شده، سیگنال‌های دارای تشنج از سیگنال‌های بدون تشنج با صحت  $0.98/0.92$  تفکیک شده است، این در

مقادیر خطا از مقدار میانگین آن‌ها دارد و همچنین نشان‌دهنده دقت بالا و خطای بسیار پایین در محاسبه میزان صحت عملکرد طبقه‌بندی‌های انجام شده است. ابعاد پایگاه داده به ازای هر مجموعه آزمایشی و نتایج نهایی حاصل از طبقه‌بندی، شامل صحت آزمایش‌ها و ارزیابی‌ها و همچنین میزان خطاها در جدول ۱ موسوم به جدول پراکندگی، بیان شده است.

## ۶-۵- نتایج حاصل از مدل ساده GA و MLP

با توجه به پارامترهای تعیین شده برای الگوریتم ژنتیک که با استفاده از قاعده یادگیری ممیتیک و استراتژی لامارکین عمل می‌نماید، جهت ارائه نمای کلی و قیاس بین الگوریتم مزبور و مدل ساده الگوریتم ژنتیک، این بهینه‌سازی توسط یک مدل ساده و با همان پارامترهای پیشین انجام می‌پذیرد.

نتایج حاصل از اعمال مدل ساده GA و MLP، انتخاب ۷ عدد ویژگی ماکزیمم دامنه میانگین، مینیمم دامنه میانگین، تفاضل بیش‌ترین و کم‌ترین دامنه، مجموع نواحی مثبت و منفی، واریانس طیف توان، ناحیه منفی دنباله متوسط تغییرات دامنه و مقادیر حاصل از ادغام ویژگی‌های طیفی در تبدیل هارتلی است. با استفاده از یک شبکه عصبی MLP و بهینه‌شده در لایه میانی که شامل ۲۲ نورون پنهان و ۷ نورون در لایه ورودی است، تحت تابع آموزشی لونیبرگ عمل طبقه‌بندی سیگنال‌های دارای تشنج و بدون تشنج صورت می‌گیرد. در نهایت مشاهده می‌شود که مقدار صحت آموزشی برابر با  $0.90/0.8$ ؛ میزان صحت آزمایش برابر با  $0.87/0.8$ ؛ صحت ارزیابی  $0.88/0.5$  و به‌طور کلی دارای دقتی برابر با  $0.90$  است. این در حالی است که  $0.70$  داده‌ها برای آموزش،  $0.20$  برای آزمایش و  $0.10$  برای ارزیابی انتخاب شده‌اند. در نهایت میزان MSE طبقه‌بندی برابر با  $0.0913$  است. در مقایسه با الگوریتم بهینه‌سازی پیشنهادی در این مقاله، میزان خطای الگوریتم ژنتیک ساده ۳ برابر مدل بهینه‌شده آن با استفاده از قاعده یادگیری لامارکین است.

آنچه مشخص است، انتخاب مقادیر دیگری برای ضرایب الگوریتم بهینه‌سازی پیشنهادی منجر به افزایش بایاس در ویژگی FFBS شده و نتایج حاصل از طبقه‌بندی را دچار خطا می‌نماید. این مطلب با توجه به شکل ۱۷ برای مقدار  $\beta$  نشان‌دهنده این موضوع است که با افزایش یا کاهش این پارامتر، مقدار خطا افزایش می‌یابد. دلیل این رخداد دور شدن ضریب  $\beta$  از مقدار بیشینه خود است. همچنین برای دو ضریب  $\alpha$  و  $\gamma$  با عنایت به مقدار پراکندگی مساوی و تأثیر یکسان آن‌ها می‌توان انتخاب مقدار  $0.2$  را علاوه بر مستندات استخراج شده از شکل (۱۵)، شرط  $\alpha + \beta + \gamma = 1$  را نیز در نظر گرفت.

ناشی از استخراج ویژگی‌های مناسب و همچنین بهینه‌سازی آن‌ها است، به نسبت پژوهش‌های دیگر مناسب‌تر بوده و دارای صحت تشخیص بالاتری است، این امر در صورتی مطرح شده است، که در اکثر تحقیقات بیان شده از یک پایگاه داده با منبعی یکسان استفاده نشده است. خلاصه‌ای از مقایسه روش پیشنهادی با کارهای قبلی در جدول ۲ آورده شده است.

صورتی مقدور شده است که نرخ خطای تشخیص اشتباه برابر با ۰/۰۱۰۸ است. در مرجع [۱۱]، گزارش داده می‌شود که الگوریتم Reveal مقدار ۷۶٪ از تشنج ثبت شده از بیماران صرعی را آشکار می‌کند. این در حالی است که این الگوریتم ۱۱٪ خطا را بر روی افراد بدون صرع از خود نشان می‌دهد. لذا در پژوهش حاضر، به‌طور قیاسی می‌توان بیان نمود که به‌صورت میانگین، عملکرد طبقه‌بندی که خود

جدول ۱: نتایج نهایی طبقه‌بندی سیگنال‌های مغزی

کلاس‌های ورودی	مجموعه آموزشی	مجموعه آزمایشی	مجموعه ارزیابی	صحت آموزش	صحت آزمایش	صحت ارزیابی	صحت کل	FVCH
مجموعه داده‌های ۱	۹۳۶۰	۱۸۷۲	۱۲۴۸	۹۵/۲٪	۹۷/۴٪	۹۶/۶٪	۹۵/۸٪	۹۵٪
مجموعه داده‌های ۲	۹۳۶۰	۱۸۷۲	۱۲۴۸	۹۴/۷٪	۹۴٪	۹۵/۷٪	۹۴/۷٪	۹۵٪
مجموعه داده‌های ۳	۹۳۶۰	۱۸۷۲	۱۲۴۸	۹۴/۹٪	۹۵/۷٪	۹۷/۴٪	۹۵/۴٪	۹۵٪
مجموعه داده‌های ۴	۹۳۶۰	۱۸۷۲	۱۲۴۸	۹۵/۲٪	۹۶/۶٪	۹۴/۹٪	۹۵/۴٪	۹۰٪
کل داده‌های ورودی	سیگنال سالم	سیگنال صرعی	خطای طبقه‌بندی		میانگین عملکرد طبقه‌بندی			
سیگنال‌ها (درصد)	۱۶٪	۸۴٪	نوع سنجش خطا	مقدار خطا	تشخیص درست	تشخیص نادرست		
سیگنال‌ها (تعداد)	۲۰۴۰	۱۰۴۴۰	واریانس خطا	۰/۲۰۹۲۰۰	۹۵/۳۲۵٪	۴/۶۷۵٪		
مدت‌زمان (ثانیه)	۶۱۲۰۰	۳۱۳۲۰۰	واریانس MSE	۰/۰۰۰۰۱۱	صحت ارزیابی	خطای ارزیابی		
			میانگین MSE	۰/۰۳۸۸۰۰	۹۳/۷۵٪	۶/۲۵٪		

جدول ۲: خلاصه‌ای از مقایسه روش پیشنهادی با کارهای دیگران

روش‌ها	ویژگی‌ها	طبقه‌بند	پایگاه داده	نتایج طبقه‌بندی
Nasehi et al. [40]	ویژگی‌های تابع Gabor	GTDA	BCI Competition III (IDIAP)	۷۲/۶۲٪
Nasehi et al. [3]	ویژگی طیفی و مکانی از DWT	GTDA	CHB-MIT Dataset	۹۸٪
Barry R. Greene et al. [41]	طیف توان و آنتروپی طیفی	تفکیک کننده خطی و روش ادغام EI و LI	United Maternity Hospital, Ireland	۸۴/۵۵٪
Nasehi et al. [42]	ویژگی طیفی و مکانی بر مبنای تابع Gabor	طبقه‌بند K-NN	United Maternity Hospital, Ireland King College Hospital, London	۸۴/۹۵٪
Nasehi et al. [۳۱]	ویژگی‌های مبتنی بر طیف تبدیل موجک	شبکه عصبی و IPSO	BCI Competition III (IDIAP)	۷۲/۲۴٪
K. Ansari-Asl et al. [11]	مؤلفه‌های طیف فرکانسی	شبکه عصبی	Epilepsy Lab, University of Pittsburgh	۷۶٪
K. -C. Hsu et al. [43]	ضرایب تبدیل موجک در ریتم‌های متفاوت	GA و SVM	University of Bonn, Germany	۹۱/۸٪
R. Harikumar et al. [44]	ویژگی‌های مبتنی بر SVD	شبکه عصبی المن	Neurology department of Sri Ramakrishna Hospital, India	۹۸/۹۲٪
روش پیشنهادی	ادغام طیف تبدیل هارتلی، ویژگی‌های مکانی و فرکانسی	MLP و GA همراه با استراتژی یادگیری ممتیک	CHB-MIT Dataset	۹۵/۳۲۵٪

## ۷- نتیجه‌گیری

همواره در تشخیص سیگنال‌هایی که دچار حمله صرع هستند استخراج ویژگی مناسب از اهمیت ویژه‌ای برخوردار است، به‌گونه‌ای که حتی وجود یک مورد نامعتبر و نامناسب در بردار ویژگی می‌تواند عملکرد طبقه‌بند را به‌طور کامل پایین آورد و در نتیجه، خطای طبقه‌بندی به‌شدت افزایش می‌یابد. لذا با توجه به وسعت زیاد فضای جستجو، استفاده از الگوریتم‌های تکاملی خصوصاً الگوریتم ژنتیک و همچنین بهره‌بردن از استراتژی‌های ممتیک به‌عنوان روشی برای یادگیری در الگوریتم ژنتیک و همچنین ترکیب آن با یک طبقه‌بند مانند شبکه‌های عصبی می‌تواند برای یافتن ویژگی‌های بهینه بسیار مؤثر باشد و فضای جستجو را که می‌تواند بسیار بزرگ باشد، به‌صورت مناسب‌تری بررسی نماید، به‌گونه‌ای که همواره بهینه‌ترین مقدار ممکن انتخاب شود.

## مراجع

- detection," *Clinical Neurophysiology*, vol. 116, no. 8, pp.1785-1795, August 2005.
- [14] S. B. Wilson, "Algorithm architectures for patient dependent seizure detection," *Clinical Neurophysiology*, vol. 117, no. 6, pp. 1204-1216, June 2006.
- [15] J. F. Kaiser, "Nonrecursive Digital Filter Design using I0-sinh Window Function," *Proceedings of IEEE Int. Symp. Circuits and Systems (ISCAS'74)*, San Francisco, Calif., USA, pp.20-23, 1974.
- [16] K. Avci and A. Nacaroglu, "Cosh window family and its application to FIR filter design," *Int. Journal of Electronics and Communications*, vol. 63, no. 11, pp. 907-916, 2009.
- [17] E. C. Ifeachor and Barrie W. Jervis, *Digital Signal Processing: A practical approach*, 2nd ed, 1993 Addison, Wesley Publishing Company Inc.
- [18] C. A. Chapman, Y. Xu, S. Haykin and R. J. Racine, "Beta-frequency (15–35 Hz) electroencephalogram activities elicited by toluene and electrical stimulation in the behaving rat," *Neuroscience*, vol. 86, pp. 1307–1319, 1998.
- [19] Y. Kumar, M. L. Dewal and R. S. Anand, "Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network," *Signal, Image and Video Processing*, pp. 1-12, August 2012.
- [20] I. Kalatzis, E. Piliouras Ventouras, C. C. Papageorgiou, A. D. Rabavilas and D. Cavouras, "Design and implementation of an SVM-based computer classification system for discriminating depressive patients from healthy controls using the P600 component of ERP signals," *Computer Methods and Programs in Biomedicine*, vol. 75, no. 1, pp. 11-22, July 2004.
- [21] G. Huang, J. Meng, D. Zhang and Xi. Zhu, "Window function for EEG power density estimation and its application in SSVEP based BCIs," *Intelligent Robotics and Applications*, vol. 7102, no. 2, pp. 135-144, 2011.
- [22] K. Ansari-Asl, J. Bellanger, F. Bartolomei, F. Wendling and L. Senhadji, "Time-frequency characterization of inter dependencies in non-stationary signals: application to epileptic EEG," *IEEE Transactions on Biomedical Engineering*, vol. 52, no. 7, July 2005.
- [23] S. Nasehi and H. Pourghassem, "Patient-specific epileptic seizure onset detection algorithm based on spectral features and IPSONN classifier," *International Conference on Communication Systems and Network Technologies (CSNT)*, pp. 186-190, April 2013.
- [24] S. Nasehi and H. Pourghassem, "A novel effective feature selection algorithm based on S-PCA and wavelet transform features in EEG signal," *IEEE 3rd International Conference on Communication Software and Networks (ICCSN)*, pp.114-117, May 2011.
- [25] Dr. K. Jones, "The discrete hartley transform," *The Regularized Fast Hartley Transform Signals and Communication Technology*, pp. 27-40, 2010.
- [26] D. Puthankattil Subha, P. K. Joseph, U. Rajendra Acharya and Ch. M. Lim, "EEG signal analysis: a survey," *Journal of Medical Systems*, vol. 34, no. 2, pp. 195-212, April 2010.
- [27] L. I. Kuncheva, J. C. Vezdek and R. P. W. Duin, "Decision templates for multiple classifier fusion: an experimental comparison," *Pattern Recognition*, vol. 34, no. 2, pp. 299-314, February 2001.
- [28] S. Mallikarjun Akareddy and P. K. Kulkarni, "EEG signal classification for epilepsy seizure detection using improved approximate entropy", *International Journal of Public Health Science (IJPHS)*, vol. 2, no. 1, pp. 23-32, March 2013.
- [29] H. Pourghassem and S. Daneshvar, "A framework for medical image retrieval using merging-based classification with dependency probability-based relevance feedback," *Turkish Journal of Electrical Engineering and Computer Science*, vol. 21, no. 3, pp. 882-896, 2013.
- [30] A. B. Sankar, J. A. V. Selvi, D. Kumar and K. S. Lakshmi, "Effective enhancement of classification of respiratory states using feed forward back propagation neural networks," *Indian Academy of Sciences*, vol. 38, no. 3, pp. 377–395, June 2013.
- [31] S. Nasehi and H. Pourghassem, "Online mental task classification based on DWT-PCA features and probabilistic neural network," *International Journal of Imaging and Robotics*, vol. 7, no. 1, pp. 110-118, January 2012.
- [1] S. Nasehi and H. Pourghassem, "Seizure detection algorithms based on analysis of EEG and ECG signals: a survey," *Neurophysiology*, vol. 44, no. 2, pp. 174-186, June 2012.
- [2] A. Shoeb, S. Schachter, D. Schomer, B. Bourgeois and J. Guttag, "Detecting seizure onset in the ambulatory setting: Demonstrating feasibility," in *Proc. of IEEE Eng. Med. Biol. Soc. Conf*, Sep 2005.
- [3] S. Nasehi and H. Pourghassem, "A novel fast epileptic seizure onset detection algorithm using general tensor discriminant analysis," *Journal of Clinical Neurophysiology*, vol. 30, no. 4, pp. 362-370, August 2013.
- [4] F. Da Silva, W. Blanes, S. Kalitzin, J. Parra, P. Suffczynski and D. Velis, "Dynamical diseases of brain systems: different routes to epileptic seizures," *IEEE Transaction on Biomedical Engineering*, vol. 50, no. 5, pp. 540-548, June 2003.
- [5] H. Jing and M. Takigawa, "Topographic analysis of dimension estimates of EEG and filtered rhythms in epileptic patients with complex partial seizures," *Biological Cybernetics*, vol. 83, no. 5, pp. 391-397, May 2000.
- [6] E. Ubeyli and I. Guler, "Detection of electrocardiographic changes in partial epileptic patients using Lyapunov exponents with multilayer perceptron neural networks," *Engineering Applications of Artificial Intelligence*, vol. 17, no. 6, pp. 567-576, September 2004.
- [7] N. Kannathal, M. Choo, U. Acharya and P. Sadasivan, "Entropies for detection of epilepsy in EEG," *Computer Methods and Programs in Biomedicine*, vol. 80, no. 3, pp. 187-194, December 2005.
- [8] X. Li, G. Ouyang and X. Yao, "Dynamical characteristics of preepileptic seizures in rats with recurrence quantification analysis," *Physics Letters A*, vol. 333, no. 1-2, pp. 164-171, November 2004.
- [9] V. Protopopescu and L. Hively, "Phase space dissimilarity measures of nonlinear dynamics: industrial and biomedical applications," *Recent Res. Devel. Physics*, vol. 6, no. 2, pp. 649-688, 2005.
- [10] V. Bajaj and R.B. Pachori, "Epileptic seizure detection based on the instantaneous area of analytic intrinsic mode functions of EEG signals," *Biomedical Engineering Letters*, vol. 3, no. 1, pp. 17-21, March 2013.
- [11] S.B. Wilson, M.L. Scheuer, C. Plummer, B. Young and S. Pacia, "Seizure detection: correlation of human experts," *Clinical Neurophysiology*, vol. 114, no. 11, pp. 2156-2164, November 2003.
- [12] S.B. Wilson, M.L. Scheuer, R.G. Emerson and A.J. Gabor, "Seizure detection: evaluation of the Reveal algorithm," *Clinical Neurophysiology*, vol. 115, no. 10, pp. 2280-2291, October 2004.
- [13] S.B. Wilson, "A neural network method for automatic and incremental learning applied to patient-dependent seizure



- ۱۲ Fused Feature of Broken Spectrum
- ۱۳ Particles Swarm Optimization
- ۱۴ Generation
- ۱۵ Mutation
- ۱۶ Cross Over
- ۱۷ K-fold Cross Validation
- ۱۸ Dataset Partitioning
- ۱۹ Final Validation Check

- [32] M. Hashemian and H. Pourghassem, "diagnosing autism spectrum disorders based on EEG analysis: a survey", *Neurophysiology*, vol. 46, no. 2, April 2014.
- [33] M. Nurmohamadi and H. Pourghassem, "Clavulanic acid production estimation based on color and structural features of streptomyces clavuligerus bacteria using self-organizing map and genetic algorithm," *Computer Methods and Programs in Biomedicine*, vol. 114, no. 3, pp. 337-348, May 2014.
- [34] A. Atyabi, Martin H. Luerssen, Sean P. Fitzgibbon and David M. W. Powersm, "The impact of PSO based dimension reduction on EEG classification," *Brain Informatics Lecture Notes in Computer Science*, vol. 7670, pp. 220-231, 2012.
- [35] R. Nogueras, C. Cotta, C. M. Fernandes, J. Luis, J. Laredo, J. J. Merelo and A. C. Rosa, "An analysis of a selecto-lamarckian model of multimemetic algorithms with dynamic self-organized topology," *Lecture Notes in Computer Science*, vol. 8273, pp. 205-216, 2013.
- [36] M. Behnam and H. Pourghassem, "Feature descriptor optimization in medical image retrieval based on genetic algorithm," *20th Iranian Conference on Biomedical Engineering (ICBME2013)*, Tehran, pp. 280- 285, December 2013.
- [37] EEG Database, <http://www.physionet.org/pn6/chbmit>.
- [38] S. M. Zoldi, A. Krystal and Henry S. Greenside, "Stationarity and redundancy of multichannel EEG data recorded during generalized tonic-clonic seizures," *Brain Topography*, vol. 12, no. 3, pp. 187-200, March 2000.
- [39] H. Pourghassem and H. Ghassemian, "Content-based medical image classification using a new hierarchical merging scheme," *Journal of Computerized Medical Imaging and Graphics*, vol. 32, no. 5, pp. 651-661, December 2008.
- [40] S. Nasehi and H. Pourghassem, "A new feature dimensionally reduction approach based on general tensor discriminant analysis in EEG signal classification," *International Conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI)*, China, pp. 188-191, December 2011.
- [41] Barry R. Greene, Geraldine B. Boylan, Richard B. Reilly, Philip de Chazal and Sean Connolly, "Combination of EEG and ECG for improved automatic neonatal seizure detection," *Clinical Neurophysiology*, vol. 118, no. 6, pp. 1348-1359, June 2007.
- [42] S. Nasehi and H. Pourghassem, "Real-time seizure detection based on EEG and ECG fused features using Gabor functions," *IEEE International conference on Intelligent Computation and Bio-Medical Instrumentation (ICBMI2011)*, Wuhan, China, pp. 204-207, December 2011.
- [43] K. C. Hsu and S. N. Yu, "Classification of seizures in EEG using wavelet-chaos methodology and genetic algorithm," *World Congress on Medical Physics and Biomedical Engineering (IFMBE Proceedings)*, vol. 25, no. 4, pp. 564-567, September 2009.
- [44] R. Harikumar, C. Ganeshbabu, M. Balasubramani and P. Sinthiya, "Analysis of SVD neural networks for classification of epilepsy risk level from EEG signals," *Proceedings of the Fourth International Conference on Signal and Image Processing 2012 (ICSIP 2012)*, vol. 222, pp. 27-34, January 2013.

## زیر نویس‌ها

- ۱ Brain-Computer Interface
- ۲ Epoch
- ۳ Offline
- ۴ Dataset
- ۵ Multi-Layer Perceptron
- ۶ Back Propagation Neural Network
- ۷ Cross Power Spectral Density
- ۸ Discrete Hartley Transform
- ۹ Fast Hartley Transform
- ۱۰ Fusion Method of Kernel Matrixes
- ۱۱ Fusion