

## ارائه یک روش هوشمند برای شناسایی و طبقه‌بندی وقایع کیفیت توان

زهرا مروّج<sup>۱\*</sup>، علی‌اکبر عبدوس<sup>۲</sup> و محمد پازکی<sup>۳</sup>

اطلاعات مقاله	چکیده
<p><b>واژگان کلیدی:</b>            کیفیت توان،            شناسایی الگو،            تبدیل S،            شبکه عصبی احتمالی،            بهینه سازی اجتماع ذرات.</p>	<p>در این مقاله، یک روش جدید براساس تبدیل S و شبکه عصبی احتمالی به منظور تشخیص اغتشاشات کیفیت توان ارائه شده است. از آنجایی که اغتشاشات کیفیت توان سیگنال‌های نایب هستند، تبدیل S می‌تواند به طور مؤثری وقایع کیفیت توان را در هر دو حوزه زمان و فرکانس آنالیز نماید. شبکه عصبی احتمالی با استفاده از ویژگی‌های استخراج شده توسط تبدیل S، به منظور طبقه‌بندی رخدادها و کیفیت توان، آموزش داده می‌شود. از آنجایی که روش جدید می‌تواند ویژگی‌های بارز سیگنال‌های اغتشاشی را تا حد زیادی بدون از دست رفتن مشخصه اصلی کاهش دهد، حافظه و زمان مورد نیاز برای آموزش اطلاعات کاهش می‌یابد. از طرف دیگر، در شبکه عصبی احتمالی نیاز به انجام فرایند وقت‌گیر آموزش نیست و تنها نیاز به تعیین یک پارامتر (به نام عامل هموارساز) می‌باشد. از آنجایی که این عامل در دقت طبقه‌بندی کننده تأثیر زیادی دارد از الگوریتم تکاملی بهینه‌سازی اجتماع ذرات برای تعیین دقیق این پارامتر استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد که ترکیب تبدیل S و شبکه عصبی احتمالی به طور مؤثر وقایع کیفیت توان را طبقه‌بندی می‌کند. عملکرد روش پیشنهادی در شرایط نویزی مختلف نیز بررسی شده است. نتایج به دست آمده نشان می‌دهد که این روش حساسیت خیلی کمی به نویز دارد.</p>

### ۱- مقدمه

هارمونیک، قطعی<sup>۴</sup>، هارمونیک، فلیکر و نوسانات گذرا شکل می‌گیرد که خود باعث ایجاد مشکلاتی مانند عملکرد نادرست، ناپایداری، کاهش عمر تجهیزات و خرابی تجهیزات الکتریکی می‌گردد. از طرف دیگر، استفاده از ادوات سوئیچینگ و بارهای سوئیچ شونده الکترونیک و غیرخطی مانند یکسوسازها و اینورترها می‌تواند باعث ایجاد اغتشاشات هارمونیک در ولتاژ و جریان گردند. استفاده از کوره‌های قوس الکتریکی نیز یکی از عوامل ایجاد فلیکر در سیستم‌های قدرت می‌باشد. انرژی‌دار کردن ترانسفورماتور، یا سوئیچینگ خازن نیز می‌تواند

کیفیت توان الکتریکی<sup>۱</sup> به یک مسئله مهم برای شرکت‌های برق و مصرف کنندگان تبدیل شده است. به همین دلیل بررسی مسائل کیفیت توان همواره مورد توجه بوده است. تنزل کیفیت توان الکتریکی معمولاً توسط اغتشاشاتی مانند کمبود ولتاژ<sup>۲</sup>، بیش‌بود ولتاژ<sup>۳</sup> بدون/ با

\* پست الکترونیک نویسنده مسئول: moravej.zahra@gmail.com

۱. عضو هیئت علمی دانشکده برق و کامپیوتر، دانشگاه سمنان

۲. دانشجوی دکتری برق قدرت، دانشکده برق و کامپیوتر، دانشگاه سمنان

<sup>1</sup> Power Quality

<sup>2</sup> Sag

<sup>3</sup> Swell

<sup>4</sup> Interruption

آموزش شبکه‌های عصبی پیشخور<sup>۸</sup> بسیار وقت‌گیر و خسته کننده می‌باشد. طبقه‌بندی کننده‌های جدیدی مانند ماشین بردار پشتیبان<sup>۹</sup> [۴ و ۵] و شبکه عصبی احتمالی<sup>۱۰</sup> [۱۵] برای طبقه‌بندی و تشخیص وقایع کیفیت توان به کار گرفته شده است.

تبدیل موجک آنالیز سیگنال‌های اغتشاشی را با تجزیه به سطوح مختلف تقریب و جزییات [۹-۱۱] انجام می‌دهد. سطح تقریب شامل فرکانس‌های کم و جزییات شامل فرکانس‌های زیاد می‌باشد. لذا دامنه و فاز مؤلفه‌های فرکانسی در زمان مشخص نیست. از طرف دیگر، ویژگی‌های استخراج شده از سطح جزییات به شدت به نویز حساس هستند. لذا نیاز به یک ابزار دقیق‌تر برای آنالیز سیگنال‌های اغتشاش کیفیت توان می‌باشد. همچنین نوع موجک مادر و تعداد سطوح مناسب باید با روش سعی و خطا برای یافتن بهترین آنالیز تعیین گردد. در حالی که تبدیل S [۱۵ و ۱۶] می‌تواند با تعیین دامنه و فاز محتویات فرکانسی، اطلاعات کاملی در حوزه زمان و فرکانس به دست دهد. در این مقاله، ۹ گونه از اغتشاشات کیفیت توان با ارائه یک روش ترکیبی بر مبنای تبدیل S و شبکه عصبی احتمالی از یکدیگر تشخیص داده می‌شوند. شبکه عصبی احتمالی یکی از ابزارهای قدرتمند طبقه‌بندی کننده می‌باشد که از جهت زیر دارای برتری نسبت به دیگر انواع طبقه‌بندی کننده‌ها می‌باشد [۱۷] و [۱۸]:

- عدم نیاز به فرایند تکراری آموزش
- عدم وجود مشکلات مربوط به حداقل محلی
- تسهیل در اضافه و کم نمودن نمونه‌های آموزش
- ساختار شبکه واحد

اما از آنجایی که شبکه عصبی احتمالی دارای یک عامل هموارساز<sup>۱۱</sup> می‌باشد که دقت طبقه‌بندی تا حد زیادی به انتخاب دقیق آن وابسته است، از الگوریتم بهینه‌سازی

موجب نوسانات گذرا شود. در یک سیستم توزیع واقعی، به منظور بهبود کیفیت توان، نیاز است قبل از اینکه اقدامی مناسب جهت رفع آنها اتخاذ گردد، این اغتشاشات شناخته شوند. یکی از مهمترین مسائل در آنالیز کیفیت توان، تشخیص و طبقه‌بندی شکل موج‌ها به طور خودکار و از طریق یک الگوریتم مؤثر می‌باشد. به منظور تشخیص و رفع مسئله کیفیت توان، شرکت‌های زیادی پایش کیفیت توان را برای صنایع و مشتریان کلیدی خود انجام داده‌اند. در بازار تجدید ساختار یافته، پایش کیفیت توان، یک ابزار مؤثر برای فراهم نمودن سرویس بهتر برای مشتریان به همراه تشویق رقابت در میان شرکت‌ها خواهد بود.

به منظور تعیین اغتشاشات، روش‌های الگوشناسی<sup>۱</sup> به طور گسترده مورد استفاده قرار گرفته‌اند. ابزارهای آنالیز سیگنال و طبقه‌بندی کننده‌های<sup>۲</sup> مختلف در تشخیص اغتشاشات کیفیت توان بسیار متداول هستند. در برخی، داده‌های سری زمانی سیگنال توسط ابزارهای طبقه‌بندی از یکدیگر تفکیک می‌شوند و در برخی، ویژگی‌های استخراج شده با استفاده از یک طبقه‌بندی کننده مناسب تشخیص داده می‌شوند. برخی از ابزارهای آنالیز سیگنال مانند تبدیل فوریه<sup>۳</sup> [۱ و ۲]، تبدیل هیلبرت<sup>۴</sup> [۳]، تبدیل موجک<sup>۵</sup> [۴-۱۲] و تبدیل S [۱۲-۱۴] به منظور پردازش سیگنال‌های اغتشاشی و استخراج ویژگی<sup>۶</sup> به کار گرفته شده‌اند. شبکه‌های عصبی مصنوعی<sup>۷</sup> به واسطه قابلیت یادگیری و تعمیم‌پذیری به عنوان هسته طبقه‌بندی کننده در مسائل الگوشناسی به کار گرفته شده‌اند. اما شبکه‌های عصبی مصنوعی دارای دو مشکل اصلی می‌باشند: اولاً روش مشخصی برای تعیین تعداد لایه‌ها، تعداد نرون‌های هر لایه و نوع توابع تحریک وجود ندارد و ثانیاً فرایند

<sup>1</sup> Pattern Recognition

<sup>2</sup> Classifier

<sup>3</sup> Fourier Transform

<sup>4</sup> Hilbert Transform

<sup>5</sup> Wavelet Transform

<sup>6</sup> Feature Extraction

<sup>7</sup> Artificial Neural Networks (ANN)

<sup>8</sup> Feed Forward Neural Networks

<sup>9</sup> Support Vector Machines (SVMs)

<sup>10</sup> Probabilistic Neural Network (PNN)

<sup>11</sup> Smoothing Factor

برای به دست آوردن  $P[m/NT]$  با به کارگیری الگوریتم FFT<sup>۲</sup>. این مرحله تنها برای یکبار انجام می شود.

(۲) محاسبه تابع گوسین  $G(n, m)$  برای فرکانس مورد نیاز  $n/NT$ .

(۳) شیفت طیف  $P[m/NT]$  به  $P[(m+n)/NT]$  برای فرکانس  $n/NT$ .

(۴) ضرب  $P[(m+n)/NT]$  و  $G[n, m]$  به منظور به دست آوردن  $B[n/NT, m/NT]$ .

(۵) تبدیل فوریه معکوس  $B[n/NT, m/NT]$  برای محاسبه ردیف های ماتریس  $S[n/NT, jT]$  متناظر با فرکانس  $n/NT$ .

(۶) تکرار مراحل ۳، ۴ و ۵ تا زمانی که تمامی ردیف های ماتریس  $S[n/NT, jT]$  متناظر با تمامی فرکانس ها  $n/NT$  به دست آیند.

از معادله (۳) مشخص می شود که خروجی تبدیل  $S$  یک ماتریس  $N \times M$  است که به ماتریس  $S$  معروف است. سطرهای این ماتریس شامل فرکانس و ستون های آن متناظر با زمان می باشد. هر عنصر ماتریس  $S$  یک عدد مختلط است. انتخاب تابع پنجره ای محدود به تابع گوسین نیست. دیگر توابع پنجره ای نیز با موفقیت به کار گرفته شده اند [۱۵ و ۱۶].

### ۳- شبکه عصبی احتمالی

شبکه عصبی احتمالی یکی از انواع شبکه های عصبی پیشخور می باشد. ساختار اصلی آن یک شبکه عصبی بر پایه تخمین تابع توزیع چگالی احتمالی و قانون طبقه بندی بیز می باشد [۱۷ و ۱۸]. شبکه عصبی احتمالی می تواند بعد از تعیین مجموعه الگوهای مثال طی یک مرحله ایجاد گردد، که زمان خیلی کمی نیاز دارد. شبکه با تعیین بردار وزن در هر یک از واحدهای الگوی مجزا در مجموعه الگوهای مثال از یک کلاس مشخص ساخته

اجتماع ذرات<sup>۱</sup> برای محاسبه مقدار این عامل استفاده می شود. این الگوریتم جزو روش های بهینه سازی تکاملی است که با تولید یک جمعیت تصادفی به سمت نقطه بهینه حرکت می کند.

### ۲- تبدیل گسسته S

فرض کنید  $p[kT]$ ،  $k = 0, 1, \dots, N-1$  بیانگر یک سری زمانی براساس سیگنال  $p(t)$ ، با بازه زمانی نمونه برداری  $T$  باشد. تبدیل فوریه گسسته این سیگنال به صورت زیر است:

$$P\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} p[kT] e^{-i2\pi nk/N} \quad (۱)$$

که  $n = 0, 1, \dots, N-1$  و تبدیل فوریه گسسته معکوس

$$p[kT] = \sum_{n=0}^{N-1} P\left[\frac{n}{NT}\right] e^{i2\pi nk/N} \quad (۲)$$

در فرم گسسته تبدیل  $S$ ، بردار تعریف شده به وسیله سری زمانی  $p[kT]$ ، به مجموعه ای از بردارها تبدیل می شود [۱۵]. این بردارها متعامد نیستند و عناصر تبدیل  $S$  مستقل نیستند. هر بردار پایه (از تبدیل فوریه) به  $N$  بردار به وسیله ضرب عنصر به عنصر با پنجره گوسی که  $N$  بار شیفت پیدا کرده است، تقسیم می گردد، به گونه ای که مجموع این  $N$  بردار، بردار پایه اصلی است. تبدیل گسسته  $S$  برای سری زمانی گسسته  $p[kT]$  در مرجع [۱۰] به صورت زیر داده شده است:

$$S\left[\frac{n}{NT}, jT\right] = \sum_{m=0}^{N-1} P\left[\frac{m+n}{NT}\right] G(n, m) e^{i2\pi mj/N} \quad (۳)$$

که  $G(m, n) = e^{-(2\pi^2 m^2 / n^2)}$  تابع گوسین و  $j, m, n = 0, 1, \dots, N-1$  می باشد.

مراحل زیر برای محاسبه تبدیل  $S$  گسسته به کار می رود [۱۵]:

(۱) انجام تبدیل فوریه گسسته سیگنال زمانی اصلی  $P[kT]$  (با  $N$  نقطه و بازه نمونه برداری  $T$ )

<sup>۲</sup> Fast Fourier Transform

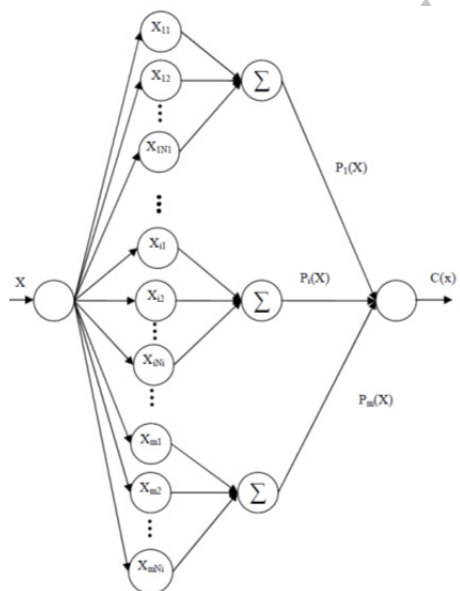
<sup>۱</sup> Particle Swarm Optimization (PSO)

فرض می‌شود که احتمالات  $p_r(S_i)$  برای کلاس‌های مختلف مشخص بوده و تابع توزیع چگالی احتمال به صورت گوسی باشد. تخمین تابع چگالی احتمال به صورت زیر خواهد بود:

$$\hat{p}(x | S_i) = \frac{1}{(2\pi)^{d/2} \sigma_i^d |S_i|} * \sum_{j=1}^{n_i} \exp \left[ \frac{-(x - x_j)^T (x - x_j)}{2\sigma_i^2} \right] \quad (۶)$$

که  $x_j^i$  الگوی مثال  $j$ ام از کلاس  $S_i$ ،  $|S_i| = n_i$  و  $\sigma_i$  فاکتور هموارساز است.

ساختار شبکه عصبی احتمالی در شکل ۱ نشان داده شده است. بردار ورودی  $x \in R^d$  دارای  $d$  بعد می‌باشد. لایه پنهان اول دارای یک واحد الگو برای هر مثال آموزشی است. لایه دوم لایه جمع کننده است که احتمال تعلق بردار ورودی به هر کلاس را مطابق رابطه (۶) محاسبه می‌نماید. در لایه سوم، که لایه تصمیم‌گیری می‌باشد، کلاسی که دارای بزرگترین احتمال باشد به عنوان کلاس برنده انتخاب می‌گردد.



شکل ۱- ساختار شبکه عصبی احتمالی

همچنین الگوریتم‌های زیادی به منظور به‌دست آوردن الگوهای مثال بهینه ارائه شده که اطلاعات اضافه را حذف

می‌شود. سپس خروجی‌های واحد الگو به واحد جمع مناسب آن کلاس متصل می‌گردد. شبکه‌های عصبی احتمالی به خاطر سرعت زیاد و تعمیم‌پذیری خوبشان نسبت به شبکه‌های عصبی مصنوعی پس‌انتشار برتر هستند. آموزش مورد نیاز برای شبکه‌های عصبی احتمالی متفاوت و خیلی سریعتر از الگوریتم آموزش مورد نیاز برای شبکه عصبی مصنوعی با الگوریتم پس‌انتشار خطا می‌باشد. در شبکه‌های عصبی احتمالی فرایند آموزش شامل یک مرحله است و هیچ گونه تکراری برای تعدیل وزن نیاز نیست که این برخلاف روش پس‌انتشار خطاست که نیاز به تکرارهای زیادی برای تعدیل وزن‌هاست. تنها عیب کوچک شبکه عصبی احتمالی نیاز به ذخیره الگوهای مثال است. از آنجایی که حافظه کامپیوترها خیلی ارزان و پربازده هستند، امروزه میزان ذخیره اطلاعات خیلی جای نگرانی ندارد. شبکه‌های عصبی احتمالی به طور وسیع در زمینه‌هایی از جمله الگو شناسی، تخمین و پیش‌بینی، نگاشت غیرخطی و تخمین احتمال عضویت به کار گرفته می‌شوند.

فرض کنید  $x \in R^d$  که بردارهای الگوی  $d$  بعدی و کلاس متناظر آن  $i \in (S_1, S_2, S_3, \dots, S_k)$  باشد، که  $k$  تعداد کلاس‌های ممکن است. اگر احتمال استقرایی  $p_r(S_i | x)$  که از کلاس  $S_i$  است، توسط قانون بیز بیان شود:

$$p_r(S_i | x) = \frac{p_r(x | S_i) p_r(S_i)}{p(x)} \quad (۴)$$

که  $i = 1, 2, 3, \dots, k$ ، تابع چگالی احتمال این الگو در کلاس‌هایی است که باید از هم جدا گردند.  $p_r(S_i)$ ،  $i = 1, 2, 3, \dots, k$  احتمالات کلاس‌هاست، و فرض می‌شود که  $p(x)$  یک مقدار ثابت باشد. قانون تصمیم‌گیری برای کلاس  $S_i$  این است که برای آن کلاس مقدار  $p_r(S_i | x)$  حداکثر گردد. این زمانی رخ خواهد داد که برای تمامی  $j \neq i$  داشته باشیم:

$$p(x | S_i) p_r(S_i) > p(x | S_j) p_r(S_j) \quad (۵)$$

طبق قانون دوم نیوتن،  $\vec{F}$  نیروی وارد بر هر ذره را مشخص می‌کند. با فرض واحد بودن جرم هر ذره و  $\Delta t$ ، برای به کارگیری روابط سرعت و شتاب در فرایند تکراری می‌توان روابط را به شکل گسسته زیر درآورد:

$$\vec{v}(t) = \frac{\vec{x}(t) - \vec{x}(t-1)}{\Delta t} \mapsto \vec{x}(t) = \vec{x}(t-1) + \vec{v}(t) \quad (8)$$

$$\frac{\vec{F}(t-1)}{m} = \frac{\vec{v}(t) - \vec{v}(t-1)}{\Delta t} \mapsto \vec{v}(t) = \vec{v}(t-1) + \vec{F}(t-1) \quad (9)$$

با الگو گرفتن از جستجوی غذا توسط پرندگان، حال باید نیروی وارد بر هر ذره را در لحظه (تکرار)  $(t-1)$  به دست آورد. پرندگان، اطلاعات کل مجموعه را برای مشخص کردن جهت حرکتشان در نظر می‌گیرند. از اینرو بهترین موقعیت سراسری گروه و بهترین موقعیت شخصی ذرات در هر لحظه از زمان محاسبه می‌شود. جهت جدید جستجو، ترکیبی از این دو جهت و جهت قبلی ذره می‌باشد. در فضای جستجوی  $D$  بُعدی بهترین موقعیت شخصی ذره  $i$  با  $\vec{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$  و بهترین موقعیت گروه با  $\vec{g} = (g_1, g_2, \dots, g_D)$  نمایش داده می‌شود. نیروی وارد بر ذره  $i$  توسط بهترین موقعیت شخصی ذره و بهترین موقعیت، به صورت دو فنر متصل به ذره که اولی در جهت بهترین تجربه شخصی و دومی در جهت بهترین تجربه سراسری نیرو وارد می‌کند، مدل‌سازی می‌شود. رابطه نهایی سرعت ذره در لحظه (تکرار) بعد به شکل زیر به دست می‌آید:

$$\begin{aligned} v_{id}(t+1) = & \omega v_{id}(t) + \\ & c_1 \text{rand}_1(p_{id}(t) - x_{id}(t)) + \\ & c_2 \text{rand}_2(g_d(t) - x_{id}(t)) \end{aligned} \quad (10)$$

در رابطه (10)،  $\omega$  ضریب اینرسی ذره و  $c_1$  و  $c_2$  ضرایب فنری هوک یا ضرایب شتاب هستند. برای تصادفی کردن ماهیت سرعت، ضرایب  $c_1$  و  $c_2$  در اعداد تصادفی  $\text{rand}_2, \text{rand}_1$  ضرب شده‌اند. معمولاً در هنگام اجرای الگوریتم مقادیر کم  $\omega$  منجر به همگرایی سریع در یک مکان بهینه محلی می‌شود. در حالی که مقادیر خیلی زیاد

می‌کند. این عمل باعث افزایش سرعت طبقه‌بندی با کاهش اندازه مجموعه مثال الگو می‌گردد [۱۷]. یافتن مقدار بهینه فاکتور هموارساز در شبکه عصبی احتمالی بسیار مهم است [۱۸]. محدودیت بازه تصمیم‌گیری شبکه عصبی احتمالی هنگامی که پارامتر هموارساز افزایش می‌یابد، تغییر می‌کند. در این مقاله، از روش جستجوی تصادفی مبتنی بر الگوریتم بهینه‌سازی اجتماع ذرات استفاده شده که مراحل آن در بخش بعدی توضیح داده شده است.

#### ۴- الگوریتم بهینه‌سازی اجتماع ذرات

روش بهینه‌سازی اجتماع ذرات یکی از روش‌های تکاملی<sup>۱</sup> است که اولین بار در سال ۱۹۹۵ ارائه شد [۱۹]. این الگوریتم سرعت همگرایی بالایی دارد و تحقیقات برای افزایش کارایی آن ادامه دارد [۲۰ و ۲۱]. این روش در مقایسه با الگوریتم ژنتیک اجرای ساده‌تر و پارامترهای قابل تنظیم کمتری دارد. ایده اصلی این الگوریتم از حرکت جمعی پرندگان یا انواع ماهیان برای یافتن غذا اقتباس شده است. به این ترتیب که تغییر مسیر یا جهت‌گیری هر عضو از این دسته از حیوانات بر اساس کسب آگاهی از دو منبع صورت می‌پذیرد. یکی بهترین مسیر یا جهتی که هر عضو به تنهایی تجربه کرده است و در حافظه خود دارد و دیگری بهترین مسیر یا جهتی که اعضای واقع در همسایگی او در طی مسیر تجربه کرده‌اند. لذا در هر لحظه از زمان، مسیر حرکت بعدی هر عضو از ترکیب دو اطلاع فوق تعیین می‌شود. با استفاده از قوانین مکانیک نیوتن می‌توان الگوریتم بهینه‌سازی اجتماع ذرات را تشریح کرد.

هر ذره  $i$  با جرم  $m$  در فضای جستجوی  $D$  بُعدی دارای جابه‌جایی  $\vec{x}_i(t)$  می‌باشد. سرعت و شتاب هر ذره به صورت زیر به دست می‌آید:

$$\vec{a} = \frac{d\vec{v}}{dt} = \frac{\vec{F}}{m}, \quad \vec{v} = \frac{d\vec{x}}{dt} \quad (7)$$

<sup>1</sup> Evolutionary

شبیه‌سازی شده بدین طریق به شرایط واقعی خیلی نزدیک است. از طرف دیگر، سیگنال‌های مختلف متعلق به یک دسته، باعث تعمیم بهتر طبقه‌بندی کننده می‌گردند [۴، ۵ و ۷].

تعداد ۹ دسته (C1-C9) از وقایع کیفیت توان که مورد بررسی قرار گرفته‌اند عبارتند از: سیگنال نرمال، کمبود ولتاژ، بیش‌بود ولتاژ، قطعی، هارمونیک‌ها، نوسانات گذرا، کمبود ولتاژ با هارمونیک، بیش‌بود ولتاژ با هارمونیک و فلیکر. جدول ۱ روابط ریاضی تولید سیگنال‌های اغتشاشات کیفیت توان و پارامترهای کنترلی متناظر با آن را نشان می‌دهد. صد مورد از هر دسته با تغییر پارامترهای مختلف برای آموزش و ۱۰۰ مورد برای تست تولید شده است. از هر دو سیگنال‌های آموزش و تست با نرخ ۶۴ نمونه در هر دوره نمونه‌برداری شده و فرکانس سیستم قدرت هم ۵۰ هرتز است. لذا فرکانس نمونه‌برداری ۳/۲ کیلو هرتز می‌باشد. پنج سیکل از هر شکل موج اغتشاشی جهت آنالیز سیگنال استفاده می‌گردد.

احتمالاً از همگرایی جلوگیری کنند. در رابطه سرعت نهایی (۱۰) جمله  $c_1 rand_1(p_{id}(t) - x_{id}(t))$  مرتبط با تجربه شخصی می‌باشد و جمله  $c_2 rand_2(g_d(t) - x_{id}(t))$  اثر متقابل اجتماعی بین ذرات را نشان می‌دهد. بردار سرعت ذره  $i$  ام،  $\vec{v}_i$  در هر بُعد از فضای جستجوی  $D$  بُعدی در بازه‌ای محدود می‌شود تا احتمال ترک فضای جستجو توسط ذره را کم کند و فضای مسئله را با گام‌های کوچکتر و دقیق‌تر جستجو نماید [۲۱].

## ۵- روش پیشنهادی

### ۵-۱- شبیه‌سازی انواع وقایع کیفیت توان با استفاده از معادلات پارامتری

انواع وقایع کیفیت توان با استفاده از معادلات پارامتری شبیه‌سازی شده‌اند. تولید داده با استفاده از معادلات پارامتری امکان تغییر سیگنال‌های آموزش و تست را در محدوده وسیعی فراهم می‌کند. سیگنال‌های

جدول ۱- معادلات ریاضی انواع وقایع کیفیت توان

پارامترها	مدل ریاضی	کلاس	نوع اغتشاش
$Frequency: 50 Hz \quad A=1$	$f(t) = A \sin(\omega t)$	C1	نرمال
$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T$	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_2))) \sin(\omega t)$	C2	کمبود ولتاژ
$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T$	$f(t) = A(1 + \alpha(u(t-t_1) - u(t-t_2))) \sin(\omega t)$	C3	بیش‌بود ولتاژ
$0.9 \leq \alpha \leq 1; T \leq t_2 - t_1 \leq 9T$	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_2))) \sin(\omega t)$	C4	قطعی
$0.05 \leq \alpha_3 \leq 0.15, 0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15, \sum \alpha_i^2 = 1$	$f(t) = A(\alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t))$	C5	هارمونیک
$\tau_{osc} = 0.008 - 0.04 s$ , $\omega_{nosc} = 100 - 400 HZ$	$f(t) = (\sin(\omega t) + \alpha_{osc} \exp(-(t-t_1)/\tau_{osc})) \sin(\omega_{nosc}(t-t_1))$	C6	نوسانات گذرا
$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T$ ; $0.05 \leq \alpha_3 \leq 0.15, 0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15, \sum \alpha_i^2 = 1$	$f(t) = A(1 - \alpha(u(t-t_1) - u(t-t_2)))(\alpha_1 \sin(\omega t) + \alpha_3 \sin(\omega t) + \alpha_5 \sin(5\omega t))$	C7	کمبود ولتاژ با هارمونیک
$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T$ ; $0.05 \leq \alpha_3 \leq 0.15, 0.05 \leq \alpha_5 \leq 0.15$ $0.05 \leq \alpha_7 \leq 0.15, \sum \alpha_i^2 = 1$	$f(t) = A(1 + \alpha(u(t-t_1) - u(t-t_2)))(\alpha_1 \sin(\omega t) + \alpha_3 \sin(\omega t) + \alpha_5 \sin(5\omega t))$	C8	بیش‌بود ولتاژ با هارمونیک
$\alpha_f = 0.1 - 0.2, \beta_f = 5 - 10 HZ$	$f(t) = (1 + \alpha_f \sin(\beta_f \omega t)) \sin(\omega t)$	C9	فلیکر

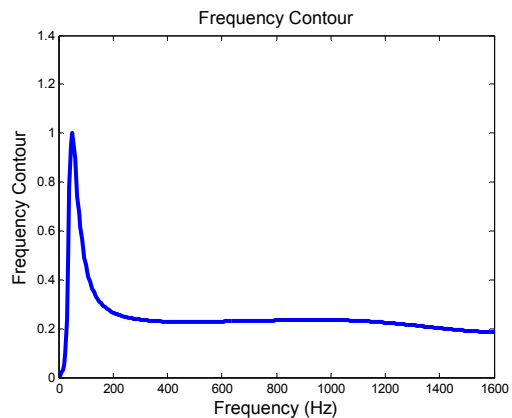
## ۵-۲- استخراج ویژگی با استفاده از تبدیل S

تبدیل S آنالیز تفکیک‌پذیری چندگانه را با استفاده از یک پنجره گوسی که پهنای آن به طور معکوس با فرکانس تغییر می‌نماید، انجام می‌دهد. از آنجایی که وقایع کیفیت توان سیگنال‌های غیرایستا هستند، تبدیل S می‌تواند به طور مؤثری در آنالیز این سیگنال‌ها به کار گرفته شود. در این مقاله، سیگنال‌های اغتشاشی با کمک نرم‌افزار MATLAB [۲۲] شبیه‌سازی شده‌اند. فرکانس نمونه-برداری برابر با  $50 \times 64$  یعنی  $3/2$  کیلوهرتز است. تعداد ۹ گونه از اغتشاشات کیفیت توان شبیه‌سازی شده است. از ماتریس S، اطلاعات مهم مانند دامنه، فرکانس و فاز می‌تواند استخراج گردد. این اطلاعات در شکل‌های ۲ و ۳ برای دو نوع از اغتشاشات یعنی کمبود و بیش‌بود ولتاژ نشان داده شده است. در شکل ۲-الف، خط قرمز مکان هندسی ماکزیمم مقادیر المان‌های موجود در ستون ماتریس S، متناظر با هر لحظه زمانی است. شکل ۲-ب کانتور فرکانسی ماتریس S را نمایش می‌دهد که تصویر کاملی از کمبود ولتاژ است. شکل ۲-ج ماکزیمم دامنه اجزای فرکانسی موجود در سیگنال را نمایش می‌دهد. به منظور تعیین فاز ماتریس S، المان‌هایی که ماکزیمم دامنه را در هر ستون دارند تعیین شده و فاز متناظر با آن محاسبه می‌گردد. فاز به دست آمده فاز ایستای سیگنال نامیده می‌شود که در شکل ۲-د نمایش داده شده است. به طور مشابه، شکل ۳-الف، ب، ج، د مشخصات ذکر شده بالا را برای اغتشاش بیش‌بود ولتاژ نمایش می‌دهد. استخراج ویژگی با به‌کارگیری تکنیک‌های آماری استاندارد روی ماتریس S انجام می‌شود. ویژگی‌های زیادی مانند دامنه، شیب (گرادیان)، دامنه، میانگین، انحراف معیار و انرژی سیگنال تبدیل یافته به منظور

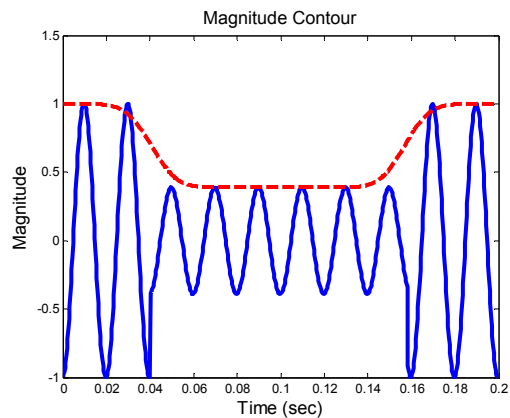
طبقه‌بندی صحیح، به طور گسترده استفاده شده است. از آنجایی که هدف به دست آوردن دقت طبقه‌بندی قابل قبول است، برخی از ویژگی‌های نامبرده شده در بالا می‌تواند مورد استفاده قرار گیرد.

در این مقاله، ویژگی‌هایی براساس انحراف استاندارد و انرژی سیگنال‌های به دست آمده به صورت زیر استخراج می‌شود:

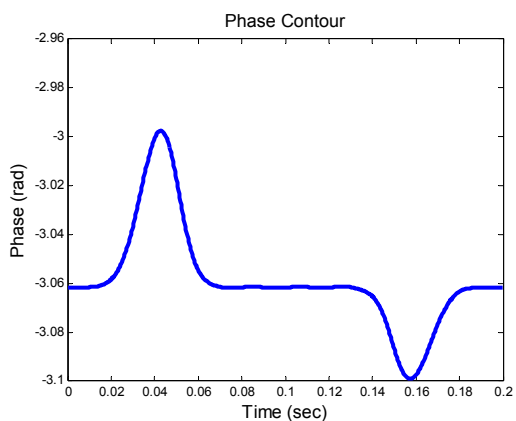
- ویژگی ۱: انحراف معیار مجموعه داده‌هایی که شامل المان‌هایی متناظر با دامنه ماکزیمم هر ستون ماتریس S است.
  - ویژگی ۲: انرژی مجموعه داده‌هایی که شامل المان‌هایی متناظر با دامنه ماکزیمم هر ستون ماتریس S است.
  - ویژگی ۳: انحراف معیار مجموعه داده‌هایی که شامل المان‌هایی متناظر با دامنه ماکزیمم هر ردیف ماتریس S است.
  - ویژگی ۴: انرژی مجموعه داده‌هایی که شامل المان‌هایی متناظر با دامنه ماکزیمم هر ردیف ماتریس S است.
- برای نشان دادن کارآمدی ویژگی‌های استخراج شده به منظور طبقه‌بندی اغتشاشات کیفیت توان، شمای سه بعدی چهار ویژگی بالا در شکل‌های ۴-الف، ب، ج آمده است. به وضوح مشخص است که ویژگی‌های استخراج شده می‌توانند فضا را به بخش‌های مجزایی تقسیم نمایند. لذا این ویژگی‌ها می‌توانند در تشخیص وقایع کیفیت توان به کار گرفته شوند. از طرف دیگر، با انتخاب ویژگی‌های مناسب ماشین یادگیری می‌تواند به راحتی الگوهای مختلف را از یکدیگر تشخیص دهد.



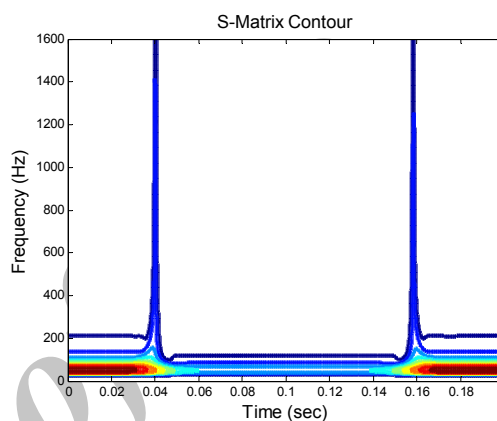
(ب-۲)



(الف-۲)

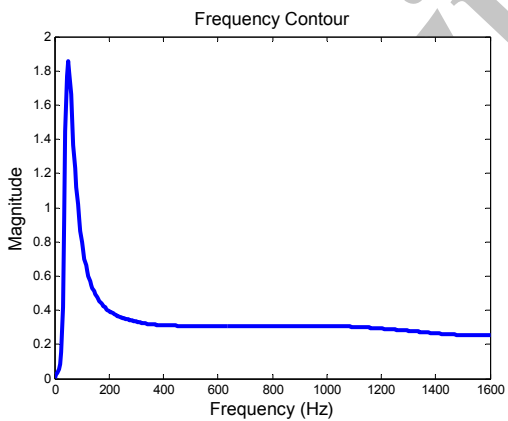


(د-۲)

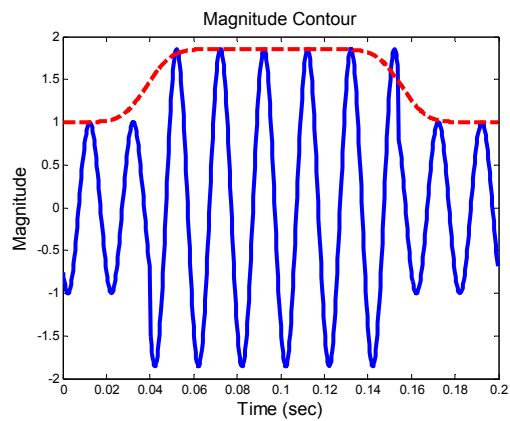


(ج-۲)

شکل ۲- کمبود ولتاژ و شکل موج ویژگی‌ها

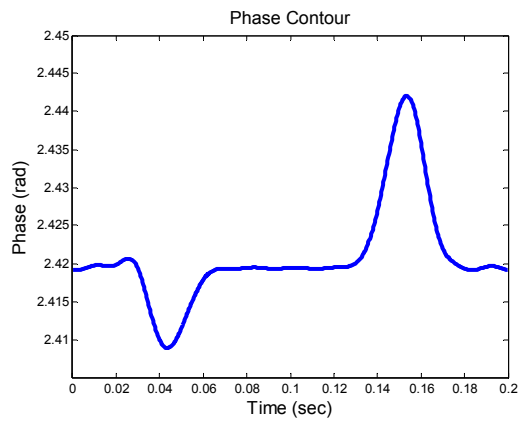


(ب-۳)

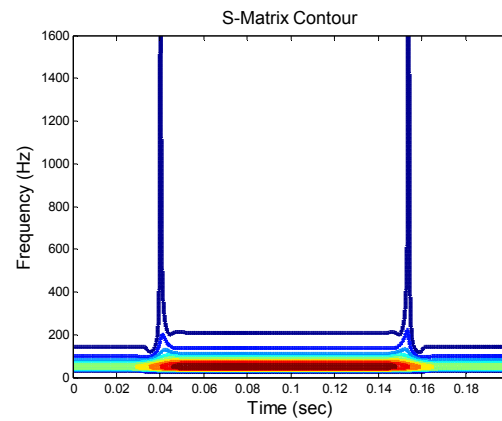


(الف-۳)



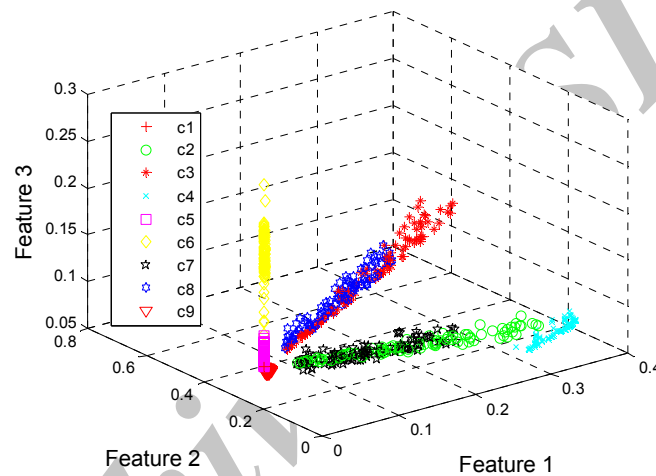


(د-۳)

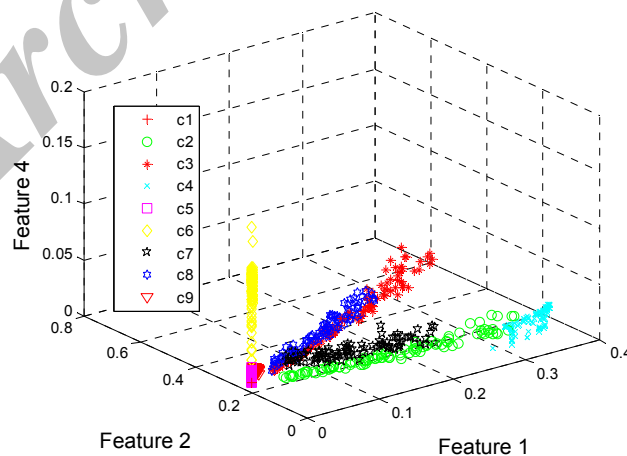


(ج-۳)

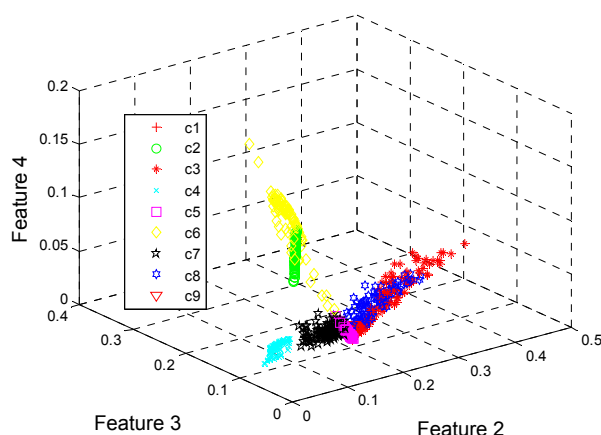
شکل ۳- بیش بود ولتاژ و شکل موج ویژگی‌ها



(الف-۴)



(ب-۴)



(۴-ج)

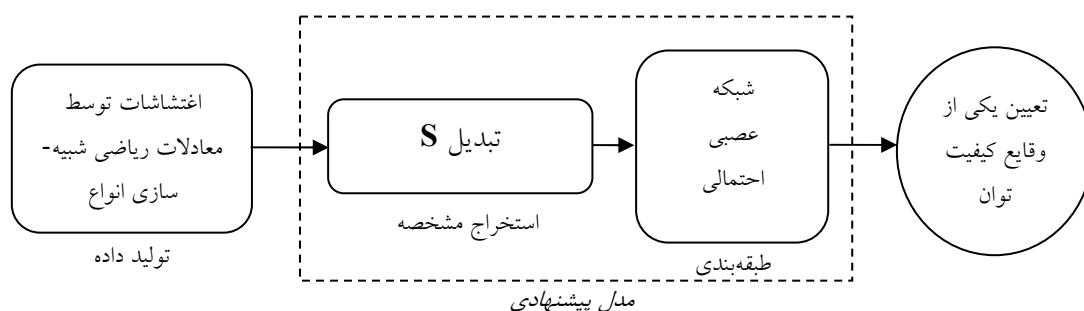
شکل ۴- شمای سه بعدی ویژگی‌های استخراج شده

است. استخراج مشخصه برای روش‌های شناسایی الگو بسیار مهم است. از اینرو یکی از مؤلفه‌های مهم برای طراحی سیستم‌های هوشمند شناسایی الگو محسوب می‌شود. این اهمیت تا آنجایی است که اگر مشخصه‌های خوبی انتخاب نشود، بهترین طبقه‌کننده‌ها هم ممکن است عملکرد خوبی نداشته باشند. یک استخراج کننده مشخصه باید ابعاد بردار نمونه‌ها (شکل موج‌های اصلی) را کاهش دهد. در حالی که شامل اطلاعات مفیدی از بردارهای اصلی باشد. در این الگوریتم، بعد از تحقق مرحله استخراج مشخصه (پیش‌پردازش) توسط تبدیل  $S$ ، مرحله طبقه‌بندی توسط شبکه عصبی احتمالی اجرا می‌شود. ورودی الگوریتم طبقه‌بندی کننده، سیگنال اغتشاشی است و خروجی آن نوع اغتشاش متناظر با سیگنال ورودی است.

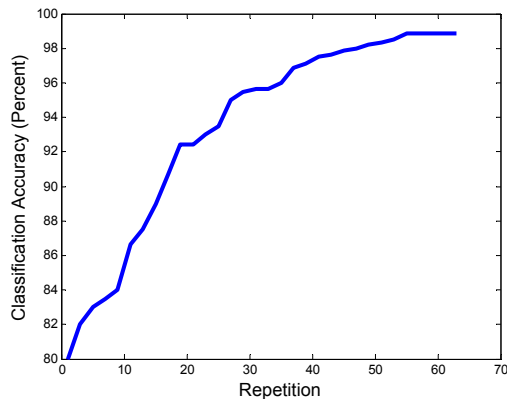
### ۵-۳- آموزش بردارهای مشخصه

مجموعه مشخصه چهار بُعدی، توضیح داده شده در قسمت ۲-۵، برای داده‌های آموزش و تست ساخته می‌شود. بُعد بیان شده در اینجا همان تعداد مشخصه‌های مختلف استخراج شده از تبدیل  $S$  است که در این صورت اندازه کلی داده‌های آموزش و تست  $4 \times 900$  خواهد بود، که ۴ بُعد مشخصه هر مورد و ۹۰۰، از ۱۰۰ مورد برای هر دسته که در تعداد دسته‌ها (۹) ضرب می‌شود، به دست می‌آید.

ورودی شبکه عصبی احتمالی، ویژگی‌های ذکر شده استخراجی توسط تبدیل  $S$  می‌باشد. سیگنال‌های وقایع کیفیت توان برای طبقه‌بندی به صورت مستقیم به شبکه عصبی احتمالی اعمال نمی‌شوند، بلکه بعد از طی مرحله پیش‌پردازش توسط تبدیل  $S$ ، شناسایی و دسته‌بندی می‌شوند. نمایش بلوکی روش پیشنهادی در شکل ۵ آمده



شکل ۵- بلوک دیاگرام روش پیشنهادی



شکل ۶- میزان دقت طبقه‌بندی در هر تکرار

در هر مرحله، شبکه عصبی احتمالی با داده‌های آموزشی آموزش داده می‌شود و سپس با داده‌های دیده نشده تست می‌گردد. دقت طبقه‌بندی به دست آمده، مقدار برازش هر ذره می‌باشد. این فرایند آنقدر تکرار می‌گردد تا معیار توقف محقق شود. این معیار می‌تواند شامل تعداد تکرارها، ثابت ماندن جواب بهینه برای تعداد تکرار متوالی مشخص و یا زمان اجرای الگوریتم باشد. تعداد ذرات در هر تکرار ۱۰۰ انتخاب شده است و شکل ۶ نشان می‌دهد که فرایند بهینه‌سازی بعد از ۵۶ تکرار به بالاترین میزان دقت طبقه‌بندی می‌رسد و پس از آن ثابت باقی می‌ماند. بالاترین میزان دقت طبقه‌بندی کننده ۹۸/۸۸ می‌باشد که مقدار پارامتر هموارساز متناظر با آن ۰/۱۱ است.

جدول ۲ نشان می‌دهد که در شرایط بدون نویز دقت طبقه‌بندی برابر با ۹۸/۸۸ خواهد بود که در آن شرایط نرمال، کمبود ولتاژ و فلیکر به طور کامل شناسایی می‌شوند و بقیه اغتشاشات نیز با ۰/۲ خطا از یکدیگر تفکیک می‌شوند. از طرف دیگر، سیگنال‌ها در سیستم‌های قدرت واقعی معمولاً دارای نویز هستند. لذا برای مدل نمودن شرایط نویزی می‌توان نویز سفید گوسی را به شکل موج‌های وقایع کیفیت توان اضافه نمود [۹ و ۱۵]. به منظور تست روش ارائه شده تحت شرایط نویزی، بیشترین مقدار نویز، یا به عبارت دیگر کمترین نسبت سیگنال به نویز، به میزان ۲۰ دسیبل در نظر گرفته شده است. مقدار سیگنال به نویز به صورت زیر تعریف می‌شود:

## ۶- اجرای روش و نتایج

پس از آنالیز سیگنال‌های اغتشاشی توسط تبدیل S، ویژگی‌های استخراج شده نرمالیزه می‌گردند تا اثر تغییرات ویژگی‌های استخراج شده در بازه‌های مختلف از بین رود. در این صورت، داده‌های آموزشی برای ماشین یادگیری مناسب خواهد بود. برای تعیین مقدار بهینه پارامتر هموارساز نیز ابتدا شبکه عصبی احتمالی با داده‌های آموزشی، آموزش داده می‌شود و سپس برای هر یک از جواب‌های الگوریتم بهینه‌سازی اجتماع ذرات، شبکه آموزش داده شده با داده‌های دیده نشده مورد آزمایش قرار می‌گیرند و دقت به دست آمده به عنوان تابع برازش انتخاب می‌گردد. مراحل انجام الگوریتم بهینه‌سازی اجتماع ذرات به منظور یافتن پارامتر هموارساز به صورت زیر می‌باشد:

- ۱- مقداردهی اولیه ذرات (مقدار این پارامتر می‌تواند بین صفر تا ۱ متغیر باشد)
- ۲- محاسبه تابع برازش برای هر ذره که برابر با نرخ طبقه‌بندی شبکه عصبی احتمالی با پارامتر هموارساز متناظر با آن ذره می‌باشد.
- ۳- اگر مقدار برازش ذره کنونی از مقدار برازش همان ذره در مراحل قبلی بهتر است باید به عنوان بهترین جواب محلی ذره فوق تعیین گردد.
- ۴- انتخاب بهترین تابع برازش به عنوان بهترین جواب کلی
- ۵- محاسبه مقدار سرعت هر یک از ذرات مطابق رابطه (۱۰)

۶- تعیین محل جدید هر یک از ذرات

۷- تکرار مراحل ۲ تا ۶ تا تحقق معیار توقف.

پیشنهادی از دیگر روش‌ها بیشتر است. همچنین، مقایسه‌ای بین نتیجه این مقاله و مقالات [۸] و [۹] در شرایط نویزی انجام شده است. دقت طبقه‌بندی در مقالات [۸] و [۹] به ترتیب حدود ۹۰-۹۴ و ۹۵-۹۵ درصد برای مقادیر سیگنال به نویز از ۲۰ تا ۵۰ دسیبل به دست آمده است. در حالی که میزان دقت طبقه‌بندی روش ترکیبی ارائه شده در بیشترین مقدار نویز از دیگر روش‌ها بیشتر است. نکته قابل توجه این است که دقت به دست آمده در این مقاله، با وجود بدترین شرایط نویزی، از دقت مقالات [۸] و [۹] در شرایط عادی بدون نویز بیشتر است. نتایج مقایسه نشان می‌دهد که الگوریتم طبقه‌بندی ارائه شده در این مقاله، با وجود نویز، دقت زیادی دارد.

جدول ۳- مقایسه الگوریتم ارائه شده با دیگر مقاله‌ها

روش ارائه شده در			نوع اغتشاش
مرجع [۸]	مرجع [۹]	این مقاله تبدیل S و شبکه عصبی احتمالی	
۱۰۰	۱۰۰	۱۰۰	نرمال
۸۸	۸۷	۱۰۰	کمبود ولتاژ
۹۶/۵	۱۰۰	۹۸	بیش بود ولتاژ
۸۵/۵۵	۸۰/۵	۱۰۰	قطعی
۱۰۰	۱۰۰	۹۸	هارمونیک
-	-	۹۸	نوسانات گذرا
۱۰۰	۹۷	۹۷	کمبود ولتاژ با هارمونیک
۱۰۰	۱۰۰	۹۹	بیش بود ولتاژ با هارمونیک
-	-	۱۰۰	فلیکر
۹۵/۷۱	۹۴/۹۳	۹۸/۸۸	دقت نهایی

$$SNR (dB) = 10 * \log\left(\frac{P_s}{P_n}\right) \quad (15)$$

که  $P_s$  توان سیگنال، و  $P_n$  مقدار مشابه به ازای نویز است. مطابق جدول ۲، برای نسبت سیگنال به نویز ۲۰ دسیبل، الگوریتم پیشنهادی با دقت ۹۷/۲۲٪ اغتشاشات کیفیت توان را طبقه‌بندی کرده است. هر چه نسبت سیگنال به نویز افزایش پیدا کند، میزان نویز کمتر و طبقه‌بندی با دقت بیشتری انجام می‌شود. این الگوریتم روشی مقاوم در مقابل شرایط نویزی محسوب می‌شود، چرا که توانسته در شرایط وجود نویز زیاد، با دقت بیشتری طبقه‌بندی وقایع کیفیت توان را انجام دهد.

جدول ۲- نتایج طبقه‌بندی اغتشاشات مختلف

اغتشاشات کیفیت توان	دقت هر کلاس بر حسب درصد بدون نویز	دقت هر کلاس بر حسب درصد با وجود ۲۰ دسیبل نویز
نرمال	۱۰۰	۹۸
کمبود ولتاژ	۱۰۰	۹۹
بیش بود ولتاژ	۹۸	۹۷
قطعی	۱۰۰	۱۰۰
هارمونیک	۹۸	۹۳
نوسانات گذرا	۹۸	۹۵
کمبود ولتاژ با هارمونیک	۹۷	۹۷
بیش بود ولتاژ با هارمونیک	۹۹	۹۷
فلیکر	۱۰۰	۹۹
دقت نهایی	۹۸/۸۸	۹۷/۲۲

## ۷- مقایسه با روش‌های دیگر

به منظور ارزیابی کارایی روش پیشنهادی، در جدول ۳، مقایسه‌ای بین دقت طبقه‌بندی به دست آمده در این مقاله و مراجع [۸] و [۹] شده است. این مقالات تنها شامل هفت نوع از اغتشاشات (بجز حالت گذرا و فلیکر) هستند و از معادلات ریاضی مشابه مقاله حاضر استفاده کرده‌اند. همانطور که از جدول ۳ برمی‌آید، میزان دقت روش

## ۸- نتیجه‌گیری

در این مقاله سعی شده که ویژگی‌های بارز اغتشاشات کیفیت توان با استفاده از تبدیل S استخراج گردد. مشاهده گردید که ویژگی‌های استخراج شده تا حد زیادی تفکیک‌پذیر هستند و می‌توانند اغتشاشات کیفیت توان را حتی در شرایط نویزی به خوبی طبقه‌بندی نمایند. مزیت

ویژگی‌های استخراج شده در تبدیل S، به نویز حساس نیستند. از طرف دیگر، شبکه عصبی احتمالی تنها با داشتن یک پارامتر تنظیمی، از سرعت و دقت زیادی برخوردار است.

این روش بر تبدیل موجک این است که در تبدیل موجک برخی از ویژگی‌ها نویزپذیر هستند (مانند انرژی جزییات سطوح ۱ و ۲) و یک الگوریتم نویززدایی باید ارائه گردد تا ویژگی‌ها به درستی استخراج گردند. در حالی که

## ۹- مراجع

- [1] Wijayakulasooriya, J.V., Putrus, G.A., Minns, P.D. (2002), "Electric power quality disturbance classification using self-adapting artificial neural networks". Generation, Transmission and Distribution, IEE Proceedings, Vol. 149, pp. 98-101.
- [2] Heydt, G.T., Fjeld, P.S., Liu, C.C., Pierce, D., Tu, L., Hensley, G. (1999), "Applications of the windowed FFT to electric power quality assessment". IEEE Trans. Power Del., Vol. 14, pp. 1411-1416.
- [3] Jayasree, T., Devaraj, D., Sukanesh, R. (2010), "Power quality disturbance classification using Hilbert transform and RBF networks". Neurocomp. Vol. 73, pp. 1451-1456.
- [4] Moravej, Z., Abdoos, A.A., Pazoki, M. (2010), "Detection and classification of power quality disturbances using wavelet transform and support vector machines". Electr. Power Components Sys., Vol. 38, pp. 182-196.
- [5] Moravej, Z., Pazoki, M., Abdoos, A.A. (2010), "Wavelet transform and multi-class relevance vector machines based recognition and classification of power quality disturbances". Intl. Trans. Electr. Energy Sys. Vol. 21, No. 1, pp. 212-222.
- [6] Morsi, W.G., El-Hawary, M.E. (2009), "Fuzzy-wavelet-based electric power quality assessment of distribution systems under stationary and nonstationary disturbances". IEEE Trans. Power Del., Vol. 24, pp. 2099-2106.
- [7] Kaewarsa, S., Attakitmongcol, K., Kulworawanichpong, T. (2008), "Recognition of power quality events by using multi wavelet-based neural networks". Intl. J. Elect. Power Energy Sys., Vol. 30, pp. 254-260.
- [8] Uyar, M., Yildirim, S., Gencoglu, M.T. (2008), "An effective wavelet-based feature extraction method for classification of power quality disturbance signals". Elect. Power Sys. Res. Vol. 78, pp. 1747-1755.
- [9] He, H., Starzyk, J.A. (2006), "A self-organizing learning array system for power quality classification based on wavelet transforms". IEEE Trans. Power Del., Vol. 21, pp. 286-295.
- [10] Santoso, S., Powers, E.J., Grady, W.M., Parsons, A.C. (2000), "Power quality disturbance waveform recognition using wavelet-based neural classifier- part 2: Application". IEEE Trans. Power Del., Vol. 15, pp. 229-235.
- [11] Tong, W., Song, X., Lin, J., Zhao, Z. (2006), "Detection and classification of power quality disturbances based on wavelet packet decomposition and support vector machines". Signal Processing, 8<sup>th</sup> International Conference.
- [12] Mishra, S., Bhende, C.N., Panigrahi, B.K. (2008), "Detection and classification of power quality disturbances using S-transform and probabilistic neural network". IEEE Trans. Power Del., Vol. 23, pp. 280-287.
- [13] Suja, S., Jerome, J. (2010), "Pattern recognition of power signal disturbances using S transform and TT transform". Intl. J. Elec. Power Energy Sys., Vol. 32, pp. 37-53.
- [14] Uyar, M., Yildirim, S., Gencoglu, M.T. (2009), "An expert system based on S-transform and neural network for automatic classification of power quality disturbances". Expert Sys. with Appl., Vol. 36, pp. 5962-5975.

- [15] Stockwell, R.G. (1991), "Why use the S-transform?". Northwest Research Associates, Colorado Research Associates Division, Boulder, Colorado, USA.
- [16] Stockwell, R.G., Mansinha, L., Lowe, R.P. (1996), "Localization of the complex spectrum: The S-transform". IEEE Trans. Signal Process., Vol. 4, pp. 998-1001.
- [17] Specht, D.F. (1990), "Probabilistic neural network". Neural Networks, Vol. 1, pp.109-118.
- [18] Mao, K.Z., Tan, K.C., Ser, W. (2000), "Probabilistic neural-network structure determination for pattern classification". IEEE Trans. Neural Networks, Vol. 11, pp. 1009-1016.
- [19] Kennedy, J., Eberhart, R.C. (1995), "Particle swarm optimization". IEEE International Conference on Neural Network, Piscataway, NJ.
- [20] Eberhart, R.C., Shi, Y. (1998), "Comparison between genetic algorithm and particle swarm optimization". Evolutionary Programming VII, edited by V.W. Porto, N. Saravanan, D. Waagen, A.E. Eiben, Vol. 1447, Lecture Notes in Computer Science, Springer-Verlag, Berlin, pp. 611-616.
- [21] Angeline, P.J. (1998), "Using selection to improve particle swarm optimization". IEEE International Conference on Evolutionary Computation, Anchorage, Alaska, USA, pp. 84-89.
- [22] MATLAB 7.4 Version Wavelet Toolbox, Math Works Company, Natick, MA.

Archive of SID

## AN INTELLIGENT METHOD FOR DETECTION AND CLASSIFICATION OF POWER QUALITY EVENTS

Z. Moravej<sup>1\*</sup>, A.A. Abdoos<sup>2</sup> and M. Pazoki<sup>2</sup>

1. Associate Professor, Faculty of Electrical & Computer Engineering, Semnan University, Semnan
2. Ph.D. Student, Faculty of Electrical & Computer Engineering, Semnan University, Semnan

\*Corresponding Author: moravej.zahra@gmail.com

---

### ARTICLE INFO

---

Keywords:

Power Quality,  
Pattern Recognition,  
Feature Extraction,  
S-Transform,  
Probabilistic Neural  
Network,  
Particle Swarm  
Optimization.

---

### ABSTRACT

---

This paper presents a new method based on S-transform and Probabilistic Neural Network (PNN) for detection of power quality disturbances. Since power quality disturbances are non-stationary signals, S-transform can analyze these events in both time and frequency domains, effectively. The PNN is trained by extracted features obtained from S-transform output. This new method can reduce distinguished features of disturbed signals without loss of main characteristics of signals, hence required time and memory for data training process decrease. On the other hand the PNN classifier does not need any time consuming training process and only one parameter (smoothing factor) is needed to be set. This parameter has a great impact on classifier accuracy, thus an evolutionary search algorithm i.e. Particle Swarm Optimization (PSO) is used for precise setting of this parameter. Simulation results show that the combination of S-transform and PNN can classify power quality events, effectively. The operation of proposed algorithm has been evaluated in noisy condition and the obtained results show the less sensitivity of the proposed method in the presence of noise.

---