

طرحی جدید برای طبقه‌بندی خودکار اغتشاشات کیفیت توان بر اساس ابزار پردازش سیگنال و یادگیری ماشین

مهدی حاجیان و اصغر اکبری فرود

برای بهبود کیفیت توان سیستم قدرت، کارایی مطلوب نخواهند داشت. برای دسترسی به این توانایی، ابزاری که بتواند این وظایف را انجام دهد مورد نیاز است. این ابزار باید قادر به تحلیل انواع اغتشاشات کیفیت توان به طور هم‌زمان در حوزه زمان و حوزه فرکانس باشد. هنوز مسأله طبقه‌بندی خودکار اغتشاشات کیفیت توان به دلیل آن که شامل طیف گسترده‌ای از دسته‌های اغتشاش و درجه‌های مختلفی از بی‌نظمی می‌باشد، با مشکل همراه است [۱] و [۲]. مسایل طبقه‌بندی از جمله مهم‌ترین مسایل حیطة تشخیص الگو می‌باشد که کاربردهای فراوانی در زمینه‌های مختلف دارد. برای چنین کاربردهای گسترده و مهمی، ابزاری نیاز است که بتواند با دقت، کارایی و قابلیت اطمینان بالا وظایف مورد نظر را انجام دهد. از جمله مؤثرترین ابزارهای طبقه‌بندی و پیش‌بینی، سیستم‌های مبتنی بر یادگیری ماشین هستند.

در مقالات گذشته تلاش‌هایی برای طرح یک سیستم خودکار تشخیص کیفیت توان به عمل آمده است [۳] تا [۵]. استخراج ویژگی معمولاً به روش‌های گوناگونی مانند تحلیل حوزه زمان، تحلیل حوزه فرکانس و یا تحلیل دینامیک‌های غیر خطی انجام می‌گیرد که در این میان ضرایب تبدیل فوریه و بالاخص ضرایب تبدیل موجک، ابزارهای مناسبی برای استخراج ویژگی محسوب می‌شوند. اخیراً روش جدید و مؤثر تبدیل S نیز به این مجموعه افزوده شده است. در [۵] تا [۸] استخراج ویژگی با استفاده از تبدیل S و در [۹] و [۱۰] با استفاده از تبدیل موجک گسسته^۱ (DWT) صورت گرفته و این ویژگی‌ها برای آموزش طبقه‌بندی کننده ماشین بردار پشتیبان چندکلاسه^۲ (MSVM) مورد استفاده قرار گرفته است. در [۱۱] چندین روش برای انتخاب ویژگی‌های مناسب و حذف ویژگی‌های غیر مفید، برای مسئله تشخیص سیگنال‌های کیفیت توان ارائه شده است.

اغتشاش‌های کیفیت توان طیف فرکانسی وسیعی دارند. برای پردازش شکل موج اغتشاش‌های کیفیت توان فرکانس پایین مانند نوسان ولتاژ، معمولاً از تبدیل فوریه گسسته استفاده می‌شود اما برای پردازش اغتشاش‌های کیفیت توان فرکانس بالا نظیر حالت‌های گذرا بهتر است ضرایب موجک به کار رود. از این رو برخی مقالات، این دو روش را در کنار یکدیگر به کار گرفته‌اند تا با استخراج ویژگی‌های مناسبی از شکل موج اغتشاش، شناسایی و طبقه‌بندی اغتشاش را ساده‌تر سازند [۱۲] تا [۱۷].

مشکلات روش‌های پیشین به این شرح است که تبدیل فوریه گسسته اطلاعات مناسبی را از حوزه زمان استخراج نمی‌کند. از نتایج مقالات پیشین می‌توان استنتاج کرد که با استفاده از تبدیل موجک به تنهایی نمی‌توان ویژگی‌هایی با کیفیت بالا ایجاد نمود. به بیان دیگر استفاده از

چکیده: تشخیص و دسته‌بندی اغتشاشات کیفیت توان یکی از وظایف مهم در حفاظت و نظارت سیستم‌های قدرت امروزی است. در حال حاضر اهمیت اصلی، بهبود روش‌های تشخیص و طبقه‌بندی خودکار شکل موج‌ها به کمک یک الگوریتم مؤثر می‌باشد. در این مقاله روشی مؤثر برای استخراج ویژگی بر اساس ترکیب تبدیل S هذلولی و موجک ارائه شده است. انتخاب و کاهش ویژگی، موجب کاهش زمان آموزش می‌گردد و در بیشتر موارد افزایش میزان دقت در طبقه‌بندی داده‌ها را به همراه دارد. در این مقاله، روشی جدید به نام گرام-اشمیت برای انتخاب ویژگی به کار گرفته شده و همچنین از ساختار طبقه‌بندی کننده مشهور ماشین بردار پشتیبان چندکلاسه استفاده شده است. همچنین پارامترهای متغیر این طبقه‌بندی کننده با استفاده از الگوریتم ابتکاری بهینه‌سازی گروهی ذرات، بهینه شده است. ۶ اغتشاش منفرد و ۲ اغتشاش ترکیبی و همچنین حالت نرمال برای طبقه‌بندی در نظر گرفته شده‌اند. حساسیت روش پیشنهادی تحت شرایط مختلف نویزی با سطوح مختلف سیگنال همراه با نویز بررسی شده است. همچنین با مقایسه نتایج این مقاله با نتایج مقالات دیگر، کارآمدی روش پیشنهادی مورد بررسی قرار گرفته است.

کلید واژه: مونیتورینگ کیفیت توان، تشخیص الگو، انتخاب ویژگی، تحلیل زمان-فرکانسی، تبدیل موجک گسسته، تبدیل S هذلولی.

۱- مقدمه

در حال حاضر، مسأله حفظ کیفیت توان در سطح استاندارد به عنوان یکی از ویژگی‌های ضروری برای یک سیستم الکتریکی موفق به رسمیت شناخته شده است. موضوع کیفیت توان به یکی از موارد جدی و اساسی در سیستم‌های قدرت تبدیل شده که علت آن را می‌توان در سه عامل جستجو کرد: (۱) تجهیزات الکتریکی حساس به کیفیت توان افزایش یافته‌اند، (۲) تجهیزات ایجاد اغتشاش کیفیت توان، کاربرد بیشتری پیدا کرده‌اند و (۳) افزایش بهره و بازده در شبکه‌های قدرت اهمیت بسیاری یافته است [۱]. در یک سیستم قدرت ابتدا باید وضعیت شبکه از نظر کیفیت توان مورد بررسی قرار گیرد و سپس در صورت نیاز اقدام مناسب جهت بهبود وضعیت کیفیت توان انجام پذیرد.

برای بهبود کیفیت توان الکتریکی، منابع تولید اغتشاش در سیستم قدرت باید شناسایی و کنترل شوند. این امر می‌تواند با تشخیص و طبقه‌بندی انواع اغتشاشات صورت پذیرد. عملکرد یک سیستم تشخیص، به آشکارسازی و طبقه‌بندی سیگنال دریافتی آن وابسته است به گونه‌ای که در صورت عدم تشخیص مناسب سیگنال، سایر عملیات کنترلی بعدی

این مقاله در تاریخ ۱۱ شهریور ماه ۱۳۹۱ دریافت و در تاریخ ۳۰ خرداد ماه ۱۳۹۲ بازنگری شد.

مهدی حاجیان، دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، (email: mehdi.hajian.sem@gmail.com).

اصغر اکبری فرود، دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، (email: aakbari@semnan.ac.ir).

1. Discrete Wavelet Transform
2. Multi Support Vector Machines

اختصاص دارد.

۲- روش پیشنهادی

در الگوریتم پیشنهادی، ابتدا ویژگی‌های مناسبی از شکل موج اغتشاش‌های کیفیت توان استخراج می‌شود. استخراج این ویژگی‌ها با استفاده از دو تبدیل S هذلولی و موج گسسته صورت می‌گیرد. ایده مقاله بر آن استوار است که ترکیب ویژگی‌های مهم و مؤثر این دو روش می‌تواند بردار ویژگی را با قدرت تفکیک بالا ایجاد نماید. به هر حال در نظر گرفتن ویژگی‌های زیاد نیاز به حجم حافظه و زمان محاسباتی بیشتری دارد. همچنین به طور یقین تمام ویژگی‌های استخراج شده از سیگنال‌های اغتشاش، توانایی یکسانی در ایجاد تمایز بین انواع اغتشاشات کیفیت توان را ندارند. بعضی از این ویژگی‌ها نسبت به برخی دیگر از قدرت تمایز بهتری برخوردارند و نقش مؤثرتری دارند. باید به دنبال ویژگی‌هایی بود که تقریباً در آشکارسازی هر ۹ نوع اغتشاش مؤثر باشند. لذا پس از استخراج ویژگی‌های مناسبی از شکل موج ولتاژ سیستم به انتخاب و کاهش این ویژگی‌ها پرداخته می‌شود. سپس با استفاده از این ویژگی‌ها، سیستم طبقه‌بندی پیشنهادی در مورد نوع هر یک از اغتشاش‌ها تصمیم‌گیری می‌کند و طبقه‌بندی بر اساس روش مشهور MSVM انجام گرفته است. برای تعیین دقیق پارامترهای طبقه‌بندی‌کننده این سیستم از الگوریتم بهینه‌سازی گروهی ذرات (PSO) استفاده شده است. به منظور ارزیابی الگوریتم پیشنهادی، شکل موج اغتشاش‌های کیفیت توان در ۲ دسته منفرد و ترکیبی به صورت نمونه‌برداری شده، فرض شده است.

شکل ۱ بلوک دیاگرام سیستم طبقه‌بندی اغتشاشات کیفیت توان را در این پژوهش نشان می‌دهد. همان طوری که در این شکل مشاهده می‌شود در این روش ابتدا داده‌های اطلاعاتی که شامل شکل موج‌های اغتشاشی می‌باشند جمع‌آوری و سپس بردار ویژگی هر اغتشاش توسط تبدیل S هذلولی و تبدیل موجک با تفکیک‌پذیری چندگانه سیگنال، استخراج می‌شود و بعد از آن از طریق روش انتخاب ویژگی پیشنهادی، این بردار بهینه می‌شود و سپس عملیات شناسایی و طبقه‌بندی انجام می‌گیرد و در مورد تعلق سیگنال اغتشاشی به طبقه‌ای خاص تصمیم‌گیری می‌شود. این عملیات به طور مشابه برای تمامی اغتشاشات به کار گرفته شده صورت می‌پذیرد.

۳- استخراج ویژگی

مرحله استخراج ویژگی‌ها در سیستم‌های بازشناسی الگو، یکی از قسمت‌های کلیدی و مؤثر در کارایی سیستم می‌باشد، چرا که دقت سیستم بازشناسی به عملکرد استخراج ویژگی‌ها وابسته است. زیرسامانه استخراج ویژگی وظیفه کشف و استخراج ویژگی‌هایی را بر عهده دارد که بتوان بر اساس آنها اغتشاشات کیفیت توان را متمایز کرد [۹]. در این مرحله، شاخص‌های آماری مهم از ضرایب تبدیل موجک و خروجی تبدیل S هذلولی سیگنال اغتشاش، استخراج و سپس با استفاده از این شاخص‌ها و طبقه‌بندی‌کننده، اغتشاشات دسته‌بندی می‌شوند. ویژگی‌های استخراج شده باید بتوانند میان کلاس‌ها تمایز به وجود آورند [۲] و [۲۶]. هدف از بخش استخراج ویژگی، استخراج ویژگی‌های مفید و مؤثر است که بیان‌کننده خصوصیات اصلی سیگنال در شرایط مختلف نویزی باشند. تجربه نشان داده است که تبدیل موجک به تنهایی در برابر نویز مقاوم نیست [۷] بنابراین در این مقاله از ابزار پیشرفته تبدیل S هذلولی نیز استفاده شده که به طور ذاتی در برابر شرایط نویزی مقاوم‌تر است [۷]. در ادامه،

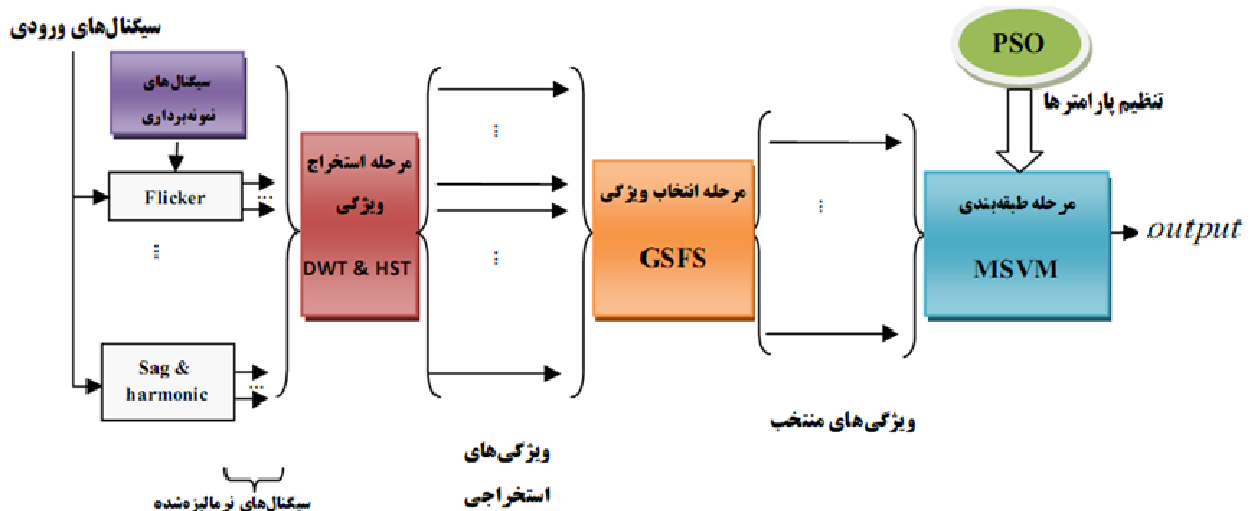
تبدیل فوری، ST و تبدیل موجک به تنهایی نمی‌تواند برای استخراج ویژگی مؤثر باشد زیرا هر کدام ضعف‌هایی دارند. به همین منظور اخیراً مقالاتی به استفاده از حالت ترکیبی تبدیل موجک و تبدیل فوری گسسته پرداخته‌اند [۱۳] تا [۱۸]. استخراج ویژگی با موجک به نوبه نیز حساس می‌باشد مخصوصاً اگر در سطوح جزئیات بالا، ویژگی‌ها استخراج شوند. طبقه‌بندی مسایل کیفیت توان با استفاده مستقیم از طبقه‌بندی‌کننده‌های کلاسیک، به دلیل حجم زیاد داده‌ها و وجود اثرات نامطلوب همپوشانی داده‌ها، دقت مطلوبی ندارد. در بسیاری از تحقیقات پیشین، بخش انتخاب ویژگی برای بهبود عمل سیستم تشخیص وجود ندارد [۱۹] و [۲۰]. اصولاً عملکرد ابزارهای تشخیص الگو به چند پارامتر داخلی وابسته است که این پارامترها در بسیاری از مقالات پیشین به وسیله سعی و خطا تنظیم شده است [۲۱].

در بسیاری از کاربردهای عملی در این حوزه، دقت و بازده روش‌های موجود در برابر شرایط مختلف نویزی مناسب نیست و باید بهبود یابد [۲۲] و [۲۳]. در برخی از مقالات با به کارگیری روش‌های نویززدایی و اضافه‌کردن مرحله‌ای جدید در ساختار سیستم تشخیص، برای بهبود عملکرد این سیستم تلاش شده است [۲۴] و [۲۵] اما این روش‌ها زیاد مورد استقبال قرار نگرفته (به علت پیچیدگی و بار محاسباتی) و پژوهش‌ها به سوی الگوریتم‌های جدید و پیشرفته پردازش سیگنال که به طور ذاتی در برابر نویز مقاوم هستند، سوق یافته است [۷].

الگوریتم ارائه‌شده در این مقاله شامل سه زیرسامانه استخراج ویژگی، انتخاب ویژگی و طبقه‌بندی است. در بخش استخراج ویژگی، تبدیل S هذلولی (تعمیم‌یافته) و تجزیه چندسطحی موجک به کار رفته و ویژگی‌های مختلفی مبتنی بر اطلاعات آماری یا مبتنی بر تئوری اطلاعات استخراج شده است. لازم به ذکر است که روش HST دارای دقت محاسباتی بالاتری از روش تبدیل S می‌باشد. در این مقاله، تعدادی از مهم‌ترین ویژگی‌های یک سیگنال الکتریکی مورد بررسی قرار می‌گیرد. در بخش انتخاب ویژگی مناسب، با استفاده از روش جدید GSFS^۱، ویژگی‌ها اولویت‌بندی شده است. در بخش طبقه‌بندی با استفاده از ابزار شناسایی الگو به دسته‌بندی اغتشاشات کیفیت توان پرداخته شده است.

در این مقاله ۹ گونه از اغتشاشات که به طور معمول در شبکه قدرت رخ می‌دهند، در نظر گرفته شده است. ۷ نوع از این اغتشاش‌ها از نوع منفرد و ۲ تا از آنها از نوع ترکیبی هستند. این اغتشاش‌ها عبارتند از: کمبود ولتاژ، بیشبود ولتاژ، قطعی، هارمونیک‌ها، نوسانات گذرا، کمبود ولتاژ با هارمونیک، بیشبود ولتاژ با هارمونیک و فلیکر. نتایج شبیه‌سازی، توانایی الگوریتم پیشنهادی را در شناسایی اغتشاش‌های منفرد و ترکیبی با دقت حدود ۹۹/۵٪ نشان می‌دهد و بیانگر آن است که روش پیشنهادی برای شناسایی و دسته‌بندی اغتشاشات کیفیت توان کاملاً مؤثر بوده و در مقابل نویز مقاوم است. در نهایت، مقایسه‌ای بین آخرین روش‌های ارائه‌شده در این زمینه و روش به کار گرفته شده در این مقاله، صورت گرفته است.

روش پیشنهادی این مقاله در بخش ۲ ارائه می‌شود. در بخش‌های ۳ تا ۵ به ترتیب الگوریتم‌های به کار رفته در خصوص استخراج و انتخاب ویژگی و همچنین طبقه‌بندی آمده است. در بخش ۶ چگونگی تولید داده‌های آموزش و تست برای سیستم تشخیص بیان شده و اجرای روش و نتایج آن در بخش ۷ آورده شده است. در بخش ۸ از نظر دقت درستی تشخیص اغتشاشات کیفیت توان با مقالات دیگر منتشرشده در این زمینه مقایسه صورت گرفته است. بخش‌های بعدی هم به نتیجه‌گیری و منابع



شکل ۱: بلوک دیاگرام سیستم طبقه‌بندی اغتشاشات کیفیت توان.

می‌گردد. تبدیل گسسته S برای سری زمانی گسسته $p[kT]$ به صورت زیر بیان می‌شود

$$S\left[\frac{n}{NT}, jT\right] = \sum_{m=0}^{N-1} P\left[\frac{m+n}{NT}\right] G(n, m) e^{\frac{j\pi m j}{N}} \quad (3)$$

که $G(m, n) = e^{-j\pi m^2/n^2}$ تابع گاوسی و $j, m, n = 0, 1, \dots, N-1$ است [۶].

با کمک گرفتن از تبدیل فوریه سریع و تئوری کانولوشن، تبدیل S گسسته به سرعت می‌تواند محاسبه شود و تبدیل S ، طیف فاز و همچنین طیف دامنه را مکان‌یابی می‌کند.

در این مقاله ماتریس S که فرمول آن طبق (۳) است، برای تحلیل اغتشاشات کیفیت توان استفاده می‌شود که سطرها، دامنه و ستون‌ها، مقادیر زمانی هستند. هر عنصر ماتریس S یک عدد مختلط است، هر سطر، دامنه تبدیل S را در همه فرکانس‌ها به طور هم‌زمان نشان می‌دهد و هر ستون، دامنه تبدیل S را با تغییر زمان از صفر تا $N-1$ در همان فرکانس نشان می‌دهد.

روش تبدیل S برای تجزیه سیگنال از یک پنجره گاوسی استفاده می‌کند. اگر پنجره گاوسی در حیطه زمان منقبض شود، افزایش قدرت تفکیک زمانی را مشاهده می‌کنیم. اما مشکل این شکل از تبدیل S این است که هر چند قدرت تفکیک زمانی بهبود می‌یابد، قدرت تفکیک فرکانسی کاهش می‌یابد. همچنین اگر پنجره گاوسی در حیطه زمان انبساط پیدا کند، افزایش قدرت تفکیک فرکانسی و کاهش قدرت تفکیک زمانی را شاهد هستیم، لذا روش فوق برای بهبود قدرت تفکیک زمانی و فرکانسی چندان مفید به نظر نمی‌رسد.

۳-۱-۱-۲ تبدیل S هذلولی (تعمیم یافته)

یک رهیافت برای بهبود قدرت تفکیک زمانی، استفاده از پنجره نامتقارن است. در این روش برای بهبود قدرت تفکیک زمان از پنجره‌ای نامتقارن استفاده می‌شود به نحوی که قسمت ابتدایی پنجره، در حیطه زمان منقبض و قسمت انتهایی آن در حیطه زمان منبسط است. در بسیاری از تحقیقات پردازش سیگنال، قسمت انتهایی رویداد اهمیت زیادی ندارد. در غیر این صورت می‌توان پنجره را یک بار از چپ به راست و یک بار از راست به چپ حرکت داد، تا هم قدرت تفکیک زمانی مربوط به قسمت ابتدایی رویداد و هم قدرت تفکیک زمانی مربوط به قسمت انتهایی رویداد، هم‌زمان در اختیار باشد. از طرفی با توجه به این که در

الگوریتم‌های به کار گرفته شده در استخراج ویژگی تشریح و سپس ویژگی‌های استخراج شده ارائه می‌گردند.

۳-۱ ابزار پردازش سیگنال

۳-۱-۱ تبدیل S

در سال ۱۹۹۶ استاکول و همکاران با مقیاس‌پذیر کردن پنجره در تبدیل فوریه زمان کوتاه، روش تبدیل فوریه زمان کوتاه را اصلاح و حاصل کار خود را تحت عنوان تبدیل S معرفی کردند که این تبدیل، یک بیان زمان-فرکانسی را از سری زمانی ایجاد می‌کند و به طور منحصر به فرد یک رزولوشن مبتنی بر فرکانس را تولید می‌کند که به طور هم‌زمان طیف‌های حقیقی و مجازی را محلی می‌سازد. توابع پایه برای تبدیل S ، توابع سینوسی مدوله‌شده گاوسی هستند و این باعث می‌شود که بتوان از فرکانس‌های سینوسی در اجرای طیف زمان فرکانسی نتیجه‌شده استفاده نمود. تبدیل S مانند تبدیل فوریه دارای این مزیت است که می‌توان سیگنالی را از حوزه زمان به حوزه زمان-فرکانس به سرعت و بدون تلفات انتقال داد و بالعکس. در تبدیل S ضمن تأمین توان تفکیک زمان-فرکانس، رابطه مستقیم با طیف فوریه نیز حفظ می‌شود که این مهم‌ترین ویژگی تبدیل S است [۶] و [۱۲].

۳-۱-۱-۳ تبدیل گسسته S

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

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

که $n = 0, 1, \dots, N-1$ و تبدیل فوریه گسسته معکوس نیز به صورت (۲) است


$$p[kT] = \sum_{n=0}^{N-1} P\left[\frac{n}{NT}\right] e^{\frac{j\pi nk}{N}} \quad (2)$$

بردار تعریف‌شده به وسیله سری زمانی $p[kT]$ به مجموعه‌ای از بردارها تبدیل می‌شود که این بردارها متعامد نیستند و عناصر تبدیل S هم مستقل نیستند. هر بردار پایه (از تبدیل فوریه) به N بردار به وسیله ضرب المان به المان با پنجره گاوسی که N بار شیفت یافته است، تقسیم

مقدار ماکسیمم محتویات فرکانسی در هر لحظه زمانی است. این نمودار با محاسبه ماکسیمم مقدار هر ستون از ماتریس S به دست خواهد آمد. کانتور ماتریس S یک نمایش کامل را از محتویات فرکانسی در لحظات مختلف با توجه به عناصر ماتریس S بیان می‌کند. نمودار فرکانسی نیز با محاسبه مقدار ماکسیمم دامنه برای یک فرکانس مشخص در طول بازه زمانی مورد نظر به دست می‌آید. کانتور فرکانسی، مقدار ماکسیمم عناصر هر ردیف از ماتریس S می‌باشد لذا از ماتریس S اطلاعات مهم مانند دامنه، فرکانس و فاز می‌تواند استخراج گردد. بنابراین با استفاده از خروجی تبدیل S برای هر سیگنال الکتریکی می‌توان کانتور زمان-فرکانس (TF - contour)، نمودار زمان-اندازه (TmA) و نمودار اندازه-فرکانس (FmA) را به دست آورد. به عبارت دیگر، خروجی تبدیل S یک ماتریس $N \times M$ می‌باشد که المان‌های آن یک عدد مختلط هستند و ماتریس S نامیده می‌شود که ردیف‌های آن بیانگر فرکانس و ستون‌های آن نشانگر زمان است. این نمودارها در شکل ۲ برای یک نوع از اغتشاشات، یعنی کمبود ولتاژ همراه با هارمونیک نشان داده شده است. هدف، بیرون کشیدن مشخصه‌هایی از این نمودارهاست به گونه‌ای که بتوان بر اساس آنها اغتشاشات را با بالاترین دقت و سرعت طبقه‌بندی نمود. ویژگی‌های (۱) تا (۱۷) استخراج شده از خروجی تبدیل S در جدول ۱ بیان شده است.

۳-۱-۲ تبدیل موجک گسسته

تئوری موجک یکی از روش‌های علم ریاضی است که ایده اصلی آن برگرفته از تبدیل فوریه است که در قرن نوزدهم مطرح شده ولی استفاده از آن قدمتی ۱۰ساله دارد. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس-زمان از سری‌های زمانی و روابط آنها جهت آنالیز سری‌های زمانی که شامل متغیرها و غیر ثابت‌ها می‌باشند را ارائه می‌دهند. ایده اصلی روش تبدیل موجک گسسته، مشابه تبدیل موجک پیوسته است که در آن نوعی توصیف زمان-مقیاس از سیگنال گسسته با استفاده از فیلترهای دیجیتال ارائه می‌گردد. تبدیل موجک، حاصل شباهت‌سنجی^۱ بین محتوای فرکانسی (مقیاسی) سیگنال و تابع موجک در مقیاس‌های مختلف است. برای محاسبه تبدیل موجک پیوسته نیز پنجره مورد نظر منقبض/منبسط شده و شیفت می‌یابد و در هر موقعیت، از حاصل ضرب آن در سیگنال، انتگرال زمانی گرفته می‌شود. در حالت گسسته، تئوری موجک بر مبنای یک مجموعه از فیلترهایی است که توسط انبساط و انقباض موجک مولد ایجاد می‌شوند. در این روش، فیلترهایی با فرکانس قطع‌های مختلف برای تحلیل سیگنال در مقیاس‌های متفاوت به کار برده می‌شود. مقیاس به طور ساده به معنای کشیده شدن یا فشرده شدن موجک می‌باشد. در حالت گسسته با تغییر فیلترها رزولوشن سیگنال کنترل می‌شود. در ابتدا سیگنال از یک فیلتر دیجیتال پایین‌گذر نیم‌باند با پاسخ ضربه $h[n]$ عبور می‌کند. حذف تمام مؤلفه‌های فرکانسی بیشتر از نصف بزرگ‌ترین فرکانس موجود در سیگنال به عنوان خروجی فیلتر است. با انجام این عمل، بدون این که اطلاعات مهم سیگنال از بین برود، طول سیگنال نصف خواهد شد (حذف یک در میان نمونه‌ها). روند مشابهی نیز با استفاده از یک فیلتر دیجیتال بالاگذر نیم‌باند با پاسخ ضربه $g[n]$ انجام می‌پذیرد. در نتیجه در خروجی اولین مرحله از اعمال تبدیل موجک، دو نسخه، یکی بالاگذر و دیگری پایین‌گذر با طول کاهش یافته (نصف شده) از سیگنال اولیه به صورت (۶) به دست می‌آیند



شکل ۲: سیگنال اغتشاش کمبود ولتاژ به همراه هارمونیک.

تبدیل S در فرکانس‌های زیاد قدرت تفکیک زمانی افزایش می‌یابد، بهتر است در چنین فرکانس‌هایی پنجره نامتقارن به پنجره گاوسی نزدیک شود که این رهیافت وابستگی تقارن پنجره با فرکانس را موجب می‌شود. با توجه به این که در تبدیل S قدرت تفکیک زمان-فرکانس تأمین می‌شود، لذا از این نظر نسبت به تبدیل فوریه زمان کوتاه دارای برتری است و نظر به این که اطلاعات زمانی مربوط به مؤلفه‌های فرکانسی در تبدیل S به صورت زمان-فرکانس ارائه می‌شود، لذا ویژگی آن نسبت به تبدیل موجک این است که خروجی قابل فهم‌تری دارد. تبدیل S با پنجره هذلولی بر اساس ایده وابستگی تقارنی پنجره با فرکانس عمل می‌کند. رابطه پنجره هذلولی بر اساس روابط زیر است [۱۲]

$$W(m, n) = \frac{2|f|}{\sqrt{2\pi(\gamma_{hy} + \mu_{hy})}} \cdot \exp\left(\frac{-f^2 Z^2}{2n^2}\right) \quad (4)$$

که در آن

$$Z = \frac{\gamma_{hy} + \mu_{hy}}{2\gamma_{hy}\mu_{hy}} t + \frac{\gamma_{hy} - \mu_{hy}}{2\gamma_{hy}\mu_{hy}} \sqrt{t^2 + \varphi_{hy}} \quad (5)$$

در (۴)، z در t یک هذلولی است که به پارامترهای نرم‌کننده عقب (backward taper, μ_{hy}) و نرم‌کننده جلو (forward taper, γ_{hy}) بستگی دارد. عامل انحنا است که دارای بعد زمان می‌باشد. واضح است که برای داشتن قدرت تفکیک زمانی خوب در ابتدای سیگنال اغتشاش باید شرط $0 < \gamma_{hy} < \mu_{hy}$ برقرار باشد.

در نزدیکی $f = 0$ ، $W(m, n)$ بسیار نامتقارن است اما با افزایش فرکانس، شکل این پنجره به حالت گاوسی متقارن نزدیک می‌شود. لذا در روش تبدیل S، مقدار دامنه و فاز محتویات فرکانسی در هر لحظه زمانی در ماتریس S، با عناصر مختلط مشخص می‌شود [۱۲]. نمودار دامنه،

جدول ۱: ویژگی‌های استخراج شده.

Reference	Feature extraction techniques	Feature number
[۵]	متوسط اندازه نمودار FmA	۱
[۵]	متوسط اندازه نمودار TmA	۲
[۵] و [۲۳]	انحراف معیار نمودار TmA	۳
[۵] و [۲۳]	انحراف معیار نمودار FmA	۴
[۵] و [۲۳]	انحراف معیار مجموعه داده‌های کانتور فاز	۵
[۵]	انرژی مجموعه داده‌های نمودار FmA	۶
[۵]	انرژی مجموعه داده‌های نمودار TmA	۷
	انرژی سطح اول اندازه کانتور زمان-فرکانس (TF-contour)	۸
	انرژی سطح دوم اندازه کانتور زمان-فرکانس (TF-contour)	۹
	انرژی سطح سوم اندازه کانتور زمان-فرکانس (TF-contour)	۱۰
	انرژی سطح چهارم اندازه کانتور زمان-فرکانس (TF-contour)	۱۱
	انرژی سطح پنجم اندازه کانتور زمان-فرکانس (TF-contour)	۱۲
	مساحت زیر نمودار FmA	۱۳
	مساحت زیر نمودار FmA محدود به فرکانس‌های ۰ تا ۵۰	۱۴
	مساحت زیر نمودار FmA محدود به فرکانس‌های ۵۰ تا ۱۶۰۰	۱۵
	مساحت زیر نمودار TmA	۱۶
[۵]	ضریب اندازه (فرمول آن در [۵] بیان شده است)	۱۷
	متوسط آنتروپی شانون برای تمام سطوح جزئیات	۱۸
	متوسط آنتروپی لگاریتمی برای تمام سطوح جزئیات	۱۹
	متوسط آنتروپی حد آستانه برای تمام سطوح جزئیات	۲۰
[۲۷]	انحراف معیار سطح دوم جزئیات	۲۱
[۲۷]	مینیم قدر مطلق سطح پنجم تقریب	۲۲
[۲۷]	متوسط میانگین قدر مطلق تمام سطوح جزئیات	۲۳
[۲۷]	میانگین انرژی تمام سطوح جزئیات به علاوه انرژی سطح چهارم تقریب سیگنال	۲۴
[۲۷]	انرژی سطح سوم جزئیات سیگنال تجزیه شده	۲۵
	شاخص آماری Skewness سیگنال زمانی اغتشاش	۲۶
	شاخص آماری Kurtosis سیگنال زمانی اغتشاش	۲۷
	گشتاور مرتبه دوم سیگنال زمانی اغتشاش	۲۸
	گشتاور مرتبه سوم سیگنال زمانی اغتشاش	۲۹
	گشتاور مرتبه چهارم سیگنال زمانی اغتشاش	۳۰
[۲۷]	مقدار RMS سیگنال زمانی اغتشاش (برابر جذر میانگین مربعات نمونه‌های سیگنال)	۳۱

قابل تشخیص باشد، ارائه دهد. علاوه بر این در صورتی که یک مؤلفه مهم فرکانسی توسط تبدیل موجک استخراج نشود، ممکن است بر روی دقت طبقه‌بندی تأثیر شایانی داشته باشد. از آنجایی که وقایع کیفیت توان سیگنال‌های غیر ایستا هستند، ترکیب HST و DWT می‌تواند به طور مؤثری به کار گرفته شود.

زیرسامانه استخراج ویژگی، وظیفه کشف و استخراج ویژگی‌هایی را بر عهده دارد که بتوان بر اساس آنها اغتشاشات کیفیت توان را متمایز کرد. برای دسته‌بندی و طبقه‌بندی سیگنال‌های اغتشاش کیفیت توان، ابتدا شاخص‌های مهم از ضرایب تبدیل موجک و خروجی تبدیل S هذلولی سیگنال اغتشاش استخراج و سپس با استفاده از این شاخص‌ها و الگوریتم‌های یادگیری ماشین، اغتشاشات طبقه‌بندی می‌شوند. دقت حاصل از طبقه‌بندی نهایی، وابستگی زیادی به الگوریتم استخراج ویژگی دارد. یک الگوریتم استخراج ویژگی بهینه باید به گونه‌ای باشد که در ویژگی‌های حاصل تمام کلاس‌های مورد نظر وجود داشته و کلاس‌ها قابل جداسازی باشند.

در این مقاله یک روش ترکیبی استخراج ویژگی با استفاده از ضرایب تبدیل موجک و تبدیل S هذلولی ارائه شده است که با استفاده از

$$F_{High}[k] = \sum_n x[n].g[\gamma k - n]$$

$$F_{Low}[k] = \sum_n x[n].h[\gamma k - n]$$
(۶)

با این عمل، رزولوشن زمانی، نصف شده و در مقابل رزولوشن فرکانسی، دو برابر می‌شود. این روند را می‌توان مجدداً بر روی نسخه پایین‌گذر شده اعمال نمود و در هر مرحله با کاهش رزولوشن زمانی به میزان نصف مرحله قبل، رزولوشن فرکانسی را ۲ برابر کرد. این ایده برای محاسبه تبدیل موجک گسسته به روش بانک فیلتر مشهور است. می‌توان دید که ضرایب خروجی فیلتر پایین‌گذر، شکل اولیه سیگنال را دنبال می‌کنند به همین دلیل به این ضرایب، تقریب گفته می‌شود. همچنین ضرایب خروجی فیلتر بالاگذر، جزئیات فرکانس بالای سیگنال را دربردارند و به همین دلیل به این ضرایب، جزئیات گفته می‌شود [۱۸] و [۲۷].

۳-۲ چگونگی استخراج ویژگی

ماهیت این اغتشاشات غیر ایستا مانند فرورفتگی‌های ولتاژ و برآمدگی‌های ولتاژ، به گونه‌ای است که تبدیل موجک نمی‌تواند خصوصیات و محتوای طیفی را که به آسانی برای طبقه‌بندی اغتشاشات

شود و یا آن که با شیوه‌هایی نظیر گرام اشمیت آنها را به سوی تعامد سوق داد [۳۱].

بردار U را در زیرفضای V_1 متعامد گویند اگر بردار U بر هر بردار در زیرفضای V_1 متعامد باشد و به مجموعه‌ای که شامل تمامی بردارهای متعامد بر زیرفضای V_1 باشد، مکمل متعامد زیرفضای V_1 گویند. دو زیرفضای V_1 و V_2 را متعامد گویند اگر هر بردار در زیرفضای V_1 با هر بردار در زیرفضای V_2 متعامد باشد. همچنین بر اساس قضیه‌ای در جبر خطی، تمامی بردارهای یک مجموعه متعامد، مستقل خطی هستند.

۴-۱-۱ خلاصه فرایند متعامدسازی گرام-اشمیت

می‌توان به صورت خلاصه بیان کرد که اگر بردارهای U_1, U_2, \dots, U_n بردارهای مستقل خطی باشند، آن گاه

$$\begin{aligned} V_1 &= U_1 \\ V_2 &= U_2 - \frac{\langle V_1, U_2 \rangle}{\|V_1\|^2} V_1 \\ V_3 &= U_3 - \frac{\langle V_1, U_3 \rangle}{\|V_1\|^2} V_1 - \frac{\langle V_2, U_3 \rangle}{\|V_2\|^2} V_2 \\ &\vdots \\ V_n &= U_n - \frac{\langle V_1, U_n \rangle}{\|V_1\|^2} V_1 - \frac{\langle V_2, U_n \rangle}{\|V_2\|^2} V_2 - \dots - \frac{\langle V_{n-1}, U_n \rangle}{\|V_{n-1}\|^2} V_{n-1} \end{aligned} \quad (7)$$

در نتیجه بردارهای V_1, V_2, \dots, V_n متعامد خواهند بود.

۴-۱-۲ تعریف ریاضی مسأله کاهش ابعاد ویژگی

مسأله کاهش ابعاد داده را به طور ریاضی می‌توان به این صورت بیان کرد که یک متغیر تصادفی n بعدی $x = (x_1, \dots, x_n)^T$ داریم. می‌خواهیم متغیر m بعدی $b = (b_1, \dots, b_m)^T$ را به گونه‌ای پیدا کنیم که اولاً $m \leq n$ باشد و ثانیاً b محتویاتی که در x وجود دارد را بر اساس معیاری خاص دارا باشد. روش‌های خطی سعی می‌کنند هر یک از این m مؤلفه را از ترکیب خطی n مؤلفه اولیه به دست آورند

$$X_{m \times n} x = b \quad (8)$$

که $X_{m \times n}$ ماتریس وزن‌های نگاشت خطی می‌باشد.

۴-۱-۳ تجزیه QR ماتریس‌ها (QR Factorization)

یکی از روش‌های حل مسأله دستگاه معادلات، استفاده از تجزیه QR ماتریس‌ها است. در این روش ماتریس $X_{m \times n}$ رتبه کامل، به حاصل ضرب دو ماتریس $X = QR$ تجزیه می‌گردد که در آن $Q_{m \times n}$ یک ماتریس متعامد و $R_{n \times n}$ یک ماتریس معکوس‌پذیر بالامثلثی با عناصر قطری مثبت است. با استفاده از این تجزیه معادلات نرمال را به صورت زیر می‌توان حل نمود. لذا برای به دست آوردن بردار x ، محاسباتی در حل دستگاه معادلات $X_{m \times n} x = b$ با استفاده از تجزیه QR به صورت زیر انجام می‌شود

$$\begin{aligned} Xx &= b \\ n - \text{Dimensional random variables} &\rightarrow x = (x_1, \dots, x_n)^T \\ X^T Xx &= X^T b \quad b \rightarrow \text{bias matrix} \\ R^T Q^T QRx &= R^T Q^T b \\ (Q^T Q = I \text{ (the columns of } Q \text{ are orthonormal vectors)}) & \\ R^T Rx &= R^T Q^T b \\ (R \rightarrow \text{nonsingular (upper triangular and invertible)}) & \\ Rx &= Q^T b \end{aligned}$$

اطلاعات طیفی و با اعمال شاخص‌های آماری ضرایب DWT و خروجی‌های HST، ویژگی‌های مناسب استخراج می‌شود. یکی از خصوصیات مهم ویژگی‌های انتخاب‌شده، تغییرات زیاد ویژگی در اغتشاشات مختلف می‌باشد. در این مقاله ویژگی‌هایی بر اساس متوسط، انحراف معیار استاندارد، مساحت، انرژی، آنتروپی و گشتاور سیگنال اغتشاش استخراج شده است.

به منظور بهره‌گیری از تبدیل S تعمیم‌یافته در آشکارسازی شکل موج ولتاژ سیستم، از ماتریس S و کانتور زمان-فرکانس (TF-contour)، نمودار زمان-اندازه (TmA) و نمودار اندازه-فرکانس (FmA) بر اساس اطلاعات آماری یا مبتنی بر تئوری اطلاعات، ویژگی‌هایی استخراج می‌گردد. ویژگی‌های ۱ تا ۱۷ که در جدول ۱ آمده است از این نوعند.

در این مقاله، موجک مادر $db4$ مورد استفاده قرار گرفته است. این موجک نیز به خوبی شناخته شده و به طور گسترده‌ای در برنامه‌های کاربردی دیگر استفاده می‌شود. به منظور بهره‌گیری از تبدیل موجک در آشکارسازی، موجک گسسته $db4$ تا سطح چهارم تجزیه می‌شود و ضرایب جزئیات موجک در سطح چهارم تجزیه به دست می‌آید و با این ضرایب ویژگی‌های مختلفی مبتنی بر اطلاعات آماری یا مبتنی بر تئوری اطلاعات استخراج می‌گردد. ویژگی‌های ۱۸ تا ۲۵ که در جدول ۱ نشان داده شده از این نوعند. تعدادی از ویژگی‌ها هم مبتنی بر شکل موج زمانی اغتشاش و شاخص‌های آماری اعمال شده بر آنها می‌باشد. ویژگی‌های ۲۶ تا ۳۱ که در جدول ۱ نشان داده شده از این نوعند. علت انتخاب برخی از ویژگی‌های جدول ۱ آن است که در بسیاری از تحقیقات انجام‌شده در این زمینه مانند [۵] و [۲۳] تا [۲۸]، کارایی آنها به اثبات رسیده است.

۴- انتخاب ویژگی

از آنجایی که افزایش تعداد ویژگی‌ها هزینه محاسباتی یک سیستم را افزایش می‌دهد، طراحی و پیاده‌سازی سامانه‌ای با کمترین تعداد ویژگی، ضروری به نظر می‌رسد. از طرف دیگر، توجه به این موضوع بسیار مهم است که باید زیرمجموعه مؤثری از ویژگی‌ها انتخاب شود که کارایی قابل قبولی برای سیستم ایجاد کند [۲۹]. به عبارت دیگر، هدف از الگوریتم‌های انتخاب ویژگی، کاهش ابعاد داده‌های ورودی سیستم است به صورتی که ویژگی‌های مهم‌تر آن باقی بمانند. این کار در افزایش سرعت سیستم‌ها و کاهش هزینه‌های محاسباتی تأثیر بسیاری دارد و در برخی موارد حتی باعث افزایش دقت سیستم‌ها نیز می‌گردد [۱۱]. با انتخاب ویژگی‌های مناسب، ماشین یادگیری می‌تواند به راحتی الگوهای مختلف را از یکدیگر تشخیص دهد. انتخاب ویژگی برای روش‌های شناسایی الگو بسیار مهم است، از این رو یکی از مؤلفه‌های مهم برای طراحی سیستم‌های هوشمند بر اساس روش شناسایی الگو محسوب می‌شود. این اهمیت تا آنجایی است که اگر مشخصه‌های خوبی انتخاب نشود، بهترین طبقه‌بندی‌کننده‌ها هم ضعیف عمل می‌کنند [۳۰]. در این مرحله با استفاده از الگوریتم جدید انتخاب ویژگی گرام اشمیت، بردار ویژگی اولیه (جدول ۱) اولویت‌بندی می‌شود. با توجه به درجه اهمیت هر ویژگی، ترکیبی از بهترین ویژگی‌ها برای طبقه‌بندی در نظر گرفته می‌شود.

۴-۱- انتخاب ویژگی گرام اشمیت

با دیدی کلی می‌توان اظهار داشت که پایه‌های متعامد، حالتی بهینه برای تنیدن فضاهای برداری (چه فضاهای با ابعاد متناهی و چه فضاهای بی‌نهایت بعدی) و انجام محاسبات ارائه می‌نمایند. لذا همواره تمایل و تلاش در این راستا قرار داشته که یا مجموعه پایه‌ها از آغاز متعامد انتخاب

را شناسایی کند. تشخیص الگو می‌تواند به عنوان طبقه‌بندی داده‌های ورودی در کلاس‌های شناخته‌شده به وسیله استخراج ویژگی‌های مهم داده، تعریف شود [۱۲]. شناسایی الگو در حوزه سیستم‌های قدرت نیز دارای کاربرد بسیاری است که از آن جمله می‌توان به شناسایی و طبقه‌بندی شکل موج و یا انواع اغتشاش در بحث کیفیت توان اشاره نمود [۲]. روش MSVM یکی از محبوب‌ترین روش‌های یادگیری است که دقت خوبی در کاربردهای مختلف دسته‌بندی ارائه می‌دهد. از مهم‌ترین ویژگی‌های روش ماشین بردار تکیه‌گاه، سادگی و قابلیت تعمیم‌دهی تصمیم‌گیری آن به نمونه‌های جدید است. دارا بودن چنین ویژگی‌هایی سبب شده اخیراً این روش به طور جدی برای حل مسایل مختلف در سیستم‌های قدرت مد نظر قرار گیرد. بنابراین در این مقاله از این روش برای طبقه‌بندی استفاده شده است.

۴-۱-۱ ماشین بردار پشتیبان

ماشین بردار پشتیبان یک مجموعه از روش‌های یادگیری با ناظر است که برای طبقه‌بندی و رگرسیون استفاده می‌شود. ماشین بردار پشتیبان در سال ۱۹۹۲ توسط وپنیک و چروننکیس بر پایه تئوری یادگیری آماری معرفی شد. SVM از یک ابرصفحه خطی تفکیک‌گر بهینه برای دسته‌بندی داده‌ها استفاده می‌کند که این ابرصفحه بهینه از حداکثر کردن حاشیه به دست می‌آید. به این منظور باید یک مسأله بهینه‌سازی غیر خطی مقید حل شود. SVM جزو گروه دسته‌بندی کننده‌هایی است که بدون دانستن مدل توزیع داده‌ها دسته‌بندی را انجام می‌دهد. حتی فراتر، این مدل نیازی به دانستن یک ساختار کلی از مسأله ندارد. به طور کلی SVM بردارهای ورودی را با استفاده از یک تابع کرنل به یک فضای بزرگ‌تری می‌برد که تفکیک‌پذیری خطی در آن بهتر و قاطعانه‌تر انجام شود [۳۳].

تعدادی داده آموزشی وجود دارد. یک مجموعه از نقاط به فرم

$$D = \{(x_i, y_i) \mid x_i \in \mathbb{R}^p, y_i \in \{1, -1\}\} \quad (13)$$

$$i = 1, \dots, n$$

که y_i می‌تواند ۱ یا -۱ باشد و مشخص‌کننده تعلق x_i به کلاس مورد نظر است و هر x_i یک بردار p بعدی است. هدف پیدا کردن جداکننده ماکسیمم حاشیه‌ای می‌باشد به طوری که نقاط y_i برابر ۱ را از نقاط -۱ جدا می‌کند. هر ابرصفحه می‌تواند به صورت یک مجموعه از نقاط x نوشته شود که رابطه زیر معرف آن است

$$W \cdot X - b = 0 \quad (14)$$

بردار w ، بردار نرمال ابرصفحه است که بر آن عمود می‌باشد و پارامتر b/w میزان آفست ابرصفحه از مبدأ در امتداد بردار نرمال w است. هدف انتخاب w و b می‌باشد به طوری که حاشیه یا فاصله بین ابرصفحه‌های موازی ماکسیمم شود تا جداسازی داده‌ها تسهیل گردد. فاصله بین دو ابرصفحه (پهنای حاشیه) برابر $2/\|w\|$ است، بنابراین لازم است $\|w\|$ مینیمم گردد. ضمن این که از قرارگرفتن نقاط در حاشیه جلوگیری می‌شود و با اضافه کردن محدودیت

$$y_i(w \cdot x_i + b) \geq 1 \quad (15)$$

به همراه ضرایب لاگرانژ غیر منفی، مسأله بهینه‌سازی به صورت زیر بیان می‌شود

$$(\bar{w}, b, \alpha) = \frac{1}{\nu} \|w\|^2 - \sum_{i=1}^N \alpha_i [y_i (\bar{w}^T \bar{x}_i + b) - 1] \quad (16)$$

الف) تجزیه QR ماتریس $X = QR$

ب) محاسبه بردار $Y = bQ^T$

ج) حل دستگاه معادلات $Rx = y$

برای به دست آوردن ماتریس Q و R از فرایند گرام-اشمیت استفاده می‌شود. ماتریس رتبه کامل $X_{m \times n}$ را در نظر بگیرید. از آنجایی که رتبه ماتریس کامل است، ستون‌های ماتریس $X_{m \times n}$ مستقیم خطی می‌باشند، لذا می‌توان آنها را به عنوان بردارهای پایه برای فضای گسترده ماتریس $X_{m \times n}$ در نظر گرفت. از طرفی می‌توان با اعمال فرایند گرام-اشمیت این بردارهای پایه را به بردارهای پایه متعامد تبدیل کرد. کیفیت طیفی از ویژگی‌ها می‌تواند بر اساس توانایی آنها در ارضای معیار جداپذیری طبقه‌ها ارزیابی شود [۳۲].

۴-۱-۲ معیار جداپذیری طبقه‌ها

به وسیله این معیار می‌توانیم به قدرت جداشوندگی بردار ویژگی استخراجی بدون استفاده از دسته‌بندی کننده پی ببریم. لذا علاوه بر کسب اطلاعات عملی نسبت به قدرت یکایک ویژگی‌ها حین دسته‌بندی می‌توان سریع‌تر به جواب مطلوب رسید. معیارهای متفاوتی برای جداپذیری طبقه‌ها معرفی شده است که در این پژوهش از معیار ساده‌تر و پرکاربردتری با نام ماتریس پراکندگی استفاده شده است. در فضای متعامد، ماتریس پراکندگی (کواریانس) یک ماتریس قطری می‌باشد. رابطه (۹) به فاصله ماهالانوبیس^۱ شهرت دارد که در آن از ماتریس پراکندگی استفاده می‌شود. برای مسایل طبقه‌بندی دوکلاسه، اندازه‌گیری فاصله ماهالانوبیس طبق (۹) می‌باشد

$$J(i, j) = [m_i - m_j]^T C_{ij}^{-1} [m_i - m_j] \quad (9)$$

$$C_{ij} = C_i + C_j$$

C_i و C_j به ترتیب ماتریس‌های کواریانس کلاس‌های i و j ، m_i بردار متوسط نمونه‌ها در کلاس i و C_{ij} ماتریس کواریانس است. $J(i, j)$ وزن‌های مختلفی را به ویژگی‌های مختلف بر اساس واریانس آنها و وابستگی خطی بین هر دو نمونه نسبت می‌دهد. بنابراین اندازه‌گیری جداپذیری هر کلاس در فضای متعامد می‌تواند به صورت زیر بیان شود

$$J(i, j) = \sum_{k=1}^n \frac{(m_{ki} - m_{kj})^2}{\sigma_{kij}^2} \quad (10)$$

که σ_{kij}^2 عضو قطر اصلی ماتریس کواریانس است. برای مسایل چندکلاسه، متوسط اندازه‌گیری معیار جداپذیری هر کلاس می‌تواند به عنوان معیاری برای ارزیابی طیفی از ویژگی‌ها استفاده شود

$$J_k = \frac{2}{L(L-1)} \sum_{i=1}^{L-1} \sum_{j=i+1}^L \frac{(m_{ki} - m_{kj})^2}{\sigma_{kij}^2} \quad (11)$$

که L تعداد کلاس‌ها است

$$J = \sum_{k=1}^n J_k \quad (12)$$

بنابراین J معیار رتبه‌بندی ویژگی‌ها خواهد بود [۳۰].

۵- طبقه‌بندی

شناسایی الگو یکی از روش‌های شناسایی است و قادر است ویژگی‌های یک الگو را تشخیص داده و سپس بر اساس این ویژگی‌ها، الگوهای جدید

جدول ۲: مدل ریاضی اغتشاشات کیفیت توان.

PQ disturbance	Class Symbol	Model	Parameters
Pure signal	C۱	$f(t) = A \sin(\omega t)$	Frequency: $\Delta 0$ Hz, $A = 1$
Sag	C۲	$f(t) = A(1 - \alpha(u(t-t_r) - u(t-t_r))) \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9$, $T \leq t_r - t_l \leq 9T$
Swell	C۳	$f(t) = A(1 + \alpha(u(t-t_r) - u(t-t_r))) \sin(\omega t)$	$0.1 \leq \alpha \leq 0.9$, $T \leq t_r - t_l \leq 9T$
Interruption	C۴	$f(t) = A(1 - \alpha(u(t-t_r) - u(t-t_r))) \sin(\omega t)$	$0.9 \leq \alpha \leq 1$, $T \leq t_r - t_l \leq 9T$
Harmonic	C۵	$f(t) = A(\alpha_1 \sin(\omega t) + \alpha_2 \sin(3\omega t) + \alpha_3 \sin(5\omega t) + \alpha_4 \sin(7\omega t))$	$0.75 \leq \alpha_r \leq 0.95$, $0.75 \leq \alpha_s \leq 0.95$ $0.75 \leq \alpha_v \leq 0.95$, $\sum \alpha_i^2 = 1$
Transient	C۶	$f(t) = (\sin(\omega t) + \alpha_{osc} \exp(-(t-t_r)/\tau_{osc})) \sin(\omega_{nosc}(t-t_r))$	$\tau_{osc} = 0.008 - 0.048$ s $\omega_{nosc} = 100 - 400$ Hz $0.1 \leq \alpha \leq 0.9$, $T \leq t_r - t_l \leq 9T$
Sag + Harmonics	C۷	$f(t) = A(1 - \alpha(u(t-t_r) - u(t-t_r)))(\alpha_1 \sin(\omega t) + \alpha_2 \sin(\omega t) + \alpha_3 \sin(5\omega t))$	$0.75 \leq \alpha_r \leq 0.95$, $0.75 \leq \alpha_s \leq 0.95$ $0.75 \leq \alpha_v \leq 0.95$, $\sum \alpha_i^2 = 1$ $0.1 \leq \alpha \leq 0.9$, $T \leq t_r - t_l \leq 9T$
Swell + Harmonics	C۸	$f(t) = A(1 + \alpha(u(t-t_r) - u(t-t_r)))(\alpha_1 \sin(\omega t) + \alpha_2 \sin(\omega t) + \alpha_3 \sin(5\omega t))$	$0.75 \leq \alpha_r \leq 0.95$, $0.75 \leq \alpha_s \leq 0.95$ $0.75 \leq \alpha_v \leq 0.95$, $\sum \alpha_i^2 = 1$
Flicker	C۹	$f(t) = (1 + \alpha_f \sin(\beta_f \omega t)) \sin(\omega t)$	$\alpha_f = 0.1 - 0.2$, $\beta_f = 5 - 10$ Hz

آموزش هستند. به منظور دستیابی به اطلاعات مورد نیاز در این مقاله، انواع وقایع کیفیت توان با استفاده از معادلات پارامتری شبیه‌سازی شده‌اند. تولید داده با استفاده از معادلات پارامتری دارای مزایایی است. امکان تغییر پارامترهای سیگنال آموزش و تست را در رنج وسیع و قابل کنترلی فراهم می‌کند. سیگنال شبیه‌سازی شده با این طریق به شرایط واقعی خیلی نزدیک است و از طرف دیگر، سیگنال‌های مختلف متعلق به یک دسته، امکان توانایی عمومیت‌بخشیدن به طبقه‌بندی کننده MSVM را می‌دهد.

به دلیل بالابودن احتمال وقوع بعضی از پدیده‌ها به صورت همزمان، در این مقاله سعی بر این بوده است که بعضی از پدیده‌هایی که احتمال وقوعشان به طور هم‌زمان بیشتر است، شبیه‌سازی شود که در مقاله‌های پیشین این مورد کمتر مورد توجه قرار گرفته است.

فرکانس نمونه‌برداری ۳/۲ کیلوهرتز و فرکانس نرمال ۵۰ هرتز است و جدول ۲ مدل‌های تولید سیگنال و پارامترهای کنترلی آن را نشان می‌دهد [۴] و [۵]. ۱۰۰ مورد از هر دسته با پارامترهای مختلف برای آموزش و ۱۰۰ مورد برای تست تولید شده است. ۱۰ سیکل از شکل موج الکتریکی که شامل اغتشاش می‌باشد، برای استخراج بردار مشخصه استفاده شده است. ۹ دسته 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.

۷- نتایج شبیه‌سازی

برای ارزیابی دقت طبقه‌بندی سیستم پیشنهادی در کار تشخیص اغتشاشات کیفیت توان سیستم قدرت، سیگنال‌های اغتشاش و موج سینوسی خالص با استفاده از معادلات پارامتریک در MATLAB ایجاد شده است.

سیگنال نمونه‌برداری شده در محیط‌های الکتریکی، معمولاً آلوده به نویز است و این بدین معنی است که سیگنال‌ها در سیستم‌های قدرت واقعی معمولاً دارای نویز هستند. در تحقیقات مربوط به کیفیت توان، افزودن نویز سفید گاوسی رایج است. پس به منظور تجزیه و تحلیل روش پیشنهادی در محیط‌های مختلف نویزی، نویز سفید گاوسی به نسبت سیگنال به نویز ۳۰، ۴۰ و ۲۰ دسی‌بل به سیگنال اصلی اضافه شد. یک سیگنال در سیستم قدرت واقعی معمولاً دارای نویز می‌باشد و نویز تصادفی

سپس $L(w, b, \alpha)$ نسبت به w و b مینیمم می‌شود. تنها تعداد کمی از α_i ها می‌توانند بزرگ‌تر از صفر باشند که این تعداد دقیقاً بردارهای پشتیبان x_i هستند که روی حاشیه قرار دارند و در $y_i(w \cdot x_i + b) \geq 1$ صدق می‌کنند. اگر داده آموزشی به صورت خطی قابل جداسازی نباشد، با اضافه کردن متغیر کمکی می‌توان جداسازی اشتباه را در نمونه‌های نویزی تصحیح کرد. رابطه جدید شامل متغیرهای کمکی به صورت زیر است

$$\phi(\bar{w}, \xi) = \frac{1}{4} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (17)$$

با در نظر گرفتن محدودیت زیر

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \quad (18)$$

عبارت $C \sum_{i=1}^N \xi_i$ حداکثر تعداد خطا را تعیین می‌کند و پارامتر c به عنوان راهی برای کنترل سرریز است که هرچه c بزرگ‌تر باشد، حساسیت بیشتری نسبت به خطاهای رخ داده پیدا می‌کند. در حقیقت c یک مصالحه بین پهنای حاشیه و جداسازی اشتباه است. به c پارامتر تنظیم‌کننده گفته می‌شود و باید توسط کاربر انتخاب شود.

ماشین بردار پشتیبان (svm) یک طبقه‌بندی کننده بسیار کارا است که در حالتی که نمونه‌های کلاس‌ها را نتوان توسط یک ابرصفحه از هم جدا کرد آنها را به بعد بالاتری نگاشت می‌کند و طبقه‌بندی در فضای با بعد بالاتر انجام می‌شود. به منظور نگاشت نمونه‌ها به بعد بالاتر عموماً از کرنل‌های غیر خطی استفاده می‌شود. تابع کرنل، جایگزین ضرب داخلی شده است. برای حل مسأله باید مقادیر σ ، c و پارامترهای مربوط به تابع کرنل انتخابی مشخص باشند. ماشین بردار پشتیبان اساساً یک جداکننده دودویی است. برای مسایل چندکلاسی، رهیافت کلی کاهش مسأله چندکلاسی به چندین مسأله دودویی است. هر یک از مسایل با یک جداکننده دودویی حل می‌شود. سپس خروجی جداکننده‌های دودویی SVM با هم ترکیب شده و به این ترتیب مسأله چندکلاس حل می‌شود [۳۳].

۶- تولید انواع وقایع کیفیت توان

استفاده از روش‌های تشخیص الگو نیازمند داده‌های اطلاعاتی برای

جدول ۳: نتایج حاصل از سیستم تشخیص با MSVM و در شرایط بدون نویز.

Dimension	Accuracy (%)	Selected feature
۱	۱۰,۷۷	۲۶
۲	۳۷,۵۵	۲۱,۲۶
۳	۴۹,۷۷	۱۵,۲۱,۲۶
۴	۷۱,۵۵	۶,۱۵,۲۱,۲۶
۵	۷۶,۵۵	۲۳,۶,۱۵,۲۱,۲۶
۶	۸۱,۸۸	۸,۲۳,۶,۱۵,۲۱,۲۶
۷	۹۴,۵۵	۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۸	۹۴,۵۵	۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۹	۹۴,۷۷	۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۰	۹۴,۳۳	۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۱	۹۴,۳۳	۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۲	۹۶,۷۷	۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۳	۹۷,۳۳	۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۴	۹۸,۷۷	۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۵	۹۹	۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۶	۹۹,۱۱	۱۴,۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۷	۹۹,۱۱	۲۸,۱۴,۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۸	۹۹,۳۳	۱۹,۲۸,۱۴,۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۹	۹۹,۳۳	۱۰,۱۹,۲۸,۱۴,۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۲۰	۹۹,۴۴	۳۱,۱۰,۱۹,۲۸,۱۴,۱۳,۳,۱,۲۴,۲۷,۲۵,۵,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶

صحت طبقه‌بند MSVM دارد. پارامترهای دلخواه C و σ به طور عمده بر روی دقت و عملکرد درست طبقه‌بندی MSVM تأثیر می‌گذارند. تاکنون مقادیر مناسبی از این پارامترها برای عملکرد مطلوب MSVM یافت نشده است. در این مقاله از الگوریتم بهینه‌سازی گروهی ذرات جهت برطرف ساختن مشکل انتخاب بهینه پارامترها در MSVM استفاده شده است.

به علت فضای جستجوی گسترده پارامترهای دلخواه بیان شده، استفاده از روش‌های کلاسیک برای تعیین آنها مناسب نمی‌باشد و بنابراین در این مقاله از یک روش تکاملی برای تعیین بهینه این پارامترها استفاده شده است. در حال حاضر یکی از مرسوم‌ترین تکنیک‌های جستجوی تکاملی، روش بهینه‌سازی گروهی ذرات می‌باشد [۱۸]، لذا از الگوریتم PSO برای یافتن پارامترهای MSVM استفاده شده است. نتایج به دست آمده از این استراتژی، تحت ویژگی‌های تابع کرنل (RBF) و مقادیر بهینه پارامترهای C و σ به ترتیب ۵ و ۰/۱ می‌باشد.

با توجه به خروجی فرایند انتخاب ویژگی، بر طبق جداول ۳ تا ۶ ترکیب‌های مختلف ویژگی‌های انتخاب شده با رویکرد ترتیبی رو به جلوی برترین ویژگی‌ها، به عنوان ورودی سیستم طبقه‌بندی در نظر گرفته شده است. تعداد ۱۰۰ سیگنال از هر اغتشاش برای داده‌های آموزش طبقه‌بندی کننده به سیستم تشخیص داده می‌شود. سپس ۱۰۰ سیگنال از هر اغتشاش برای تست سیستم پیشنهادی به کار می‌رود. نتایج دقت سیستم پیشنهادی در تشخیص و طبقه‌بندی درست اغتشاشات کیفیت توان برای هر ترکیب بهینه از ویژگی‌های ورودی در جداول ۳ تا ۶ نشان داده شده است.

همان طور که مشاهده می‌شود در این جداول تا ۲۰ ترکیب بهینه از ویژگی‌ها نمایش داده شده است. بالاترین دقت در این ابعاد ویژگی، در

غیر قابل کنترل است و مقدار دقیق آن در آزمایش‌های مختلف با هم متفاوت است و بهتر است که به صورت آماری نشان داده شود [۳۴]. نویز، تصادفی است و معمولاً توزیع آن را توزیع گوسی در نظر می‌گیرند. در تحقیقات انجام شده در سیستم‌های الکتریکی، پرکاربردترین مدل نویزی، نویز سفید گوسی می‌باشد. در محدوده فرکانسی که اکثر گیرنده‌ها کار می‌کنند، چگالی طیف توان نویز حرارتی مقدار ثابتی است (به فرکانس بستگی ندارد) و از این جهت نویز سفید نامیده می‌شود [۳۴] و [۲۵] چرا که شامل تمام فرکانس‌ها می‌باشد و همه سیستم‌ها دارای نویز سفید می‌باشند. زمانی که یک سیستم را در محیط نویزی بررسی و تحلیل می‌کنیم بدترین شرایط وقتی است که بخواهیم حداکثر توان را منتقل نماییم. در مدارهای الکتریکی، حداکثر توان وقتی منتقل می‌شود که در مدار، تطبیق امپدانس وجود داشته باشد. مستقل از اندازه مقاومت، چگالی طیف توان نویز داده شده به بار در شرایط تطبیق، مقداری ثابت است [۲۵]. پس مدل نویز سفید گوسی دارای پتانسیل خوبی برای مدل نمودن شرایط واقعی می‌باشد [۳۶]. لازم به ذکر است که در بیشتر مقالات منتشر شده در حوزه تشخیص سیگنال‌های کیفیت توان، شرایط نویزی با این مدل نویز بررسی شده است [۲۴]، [۳۷] و [۳۸]. در این مقاله، حساسیت روش‌های پیشنهادی تحت شرایط مختلف نویزی با سطوح مختلف سیگنال همراه با نویز بررسی شده است.

نتایج فرایند انتخاب ویژگی، رتبه‌بندی ترکیب‌های مختلف ویژگی‌های استخراج شده می‌باشد که در جداول ۳ تا ۶ ارائه گردیده است. در این جدول‌ها فقط بهترین ۲۰ ترکیب اول از ویژگی‌های انتخاب شده (توسط فرایند انتخاب ویژگی پیشنهادی) برای هر دو سیگنال بدون نویز (خالص) و نویزی ارائه شده است.

بعد از استخراج و انتخاب ویژگی‌ها در طی مرحله پیش‌پردازش، مرحله طبقه‌بندی توسط ماشین بردار پشتیبان چندکلاسه انجام می‌شود. انتخاب دقیق و مناسب پارامترهای MSVM تأثیر مهم و حیاتی بر روی دقت و

جدول ۴: نتایج حاصل از سیستم تشخیص با MSVM و در شرایط ۴۰ دسی بل نویز.

Dimension	Accuracy (%)	Selected feature
۱	۳۹,۲۲	۱۹
۲	۵۵	۲۱,۱۹
۳	۷۲,۵۵	۱,۲۱,۱۹
۴	۷۸,۴۴	۸,۱,۲۱,۱۹
۵	۸۷,۸۸	۱۱,۸,۱,۲۱,۱۹
۶	۹۰	۲۳,۱۱,۸,۱,۲۱,۱۹
۷	۹۰,۲۲	۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۸	۹۱,۵۵	۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۹	۹۲,۷۷	۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۰	۹۲,۸۸	۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۱	۹۲,۵۵	۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۲	۹۲,۸۸	۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۳	۹۷,۴۴	۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۴	۹۷,۵۵	۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۵	۹۹,۳۳	۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۶	۹۹,۳۳	۱۳,۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۷	۹۹,۴۴	۲۸,۱۳,۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۸	۹۹,۴۴	۲۴,۲۸,۱۳,۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۱۹	۹۹,۴۴	۳۱,۲۴,۲۸,۱۳,۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹
۲۰	۹۹,۴۴	۱۶,۳۱,۲۴,۲۸,۱۳,۷,۶,۱۵,۴,۵,۱۸,۲۵,۲۷,۲۰,۲۳,۱۱,۸,۱,۲۱,۱۹

جدول ۵: نتایج حاصل از سیستم تشخیص با MSVM و در شرایط ۳۰ دسی بل نویز.

Dimension	Accuracy (%)	Selected feature
۱	۱۶,۳۳	۲۶
۲	۳۶	۲۱,۲۶
۳	۶۳,۳۳	۱۵,۲۱,۲۶
۴	۷۶,۶۶	۶,۱۵,۲۱,۲۶
۵	۷۷	۲۳,۶,۱۵,۲۱,۲۶
۶	۸۱,۱۱	۸,۲۳,۶,۱۵,۲۱,۲۶
۷	۹۶,۸۸	۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۸	۹۶,۶۶	۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۹	۹۶,۵۵	۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۰	۹۶,۷۷	۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۱	۹۶,۵۵	۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۲	۹۸,۸۸	۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۳	۹۹	۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۴	۹۹,۱۱	۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۵	۹۹,۲۲	۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۶	۹۹,۲۲	۱,۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۷	۹۹,۲۲	۱۳,۱,۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۸	۹۹,۱۱	۱۹,۱۳,۱,۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۱۹	۹۹,۲۲	۳۱,۱۹,۱۳,۱,۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶
۲۰	۹۹,۲۲	۲۸,۳۱,۱۹,۱۳,۱,۱۲,۴,۱۴,۳,۵,۲۵,۲۷,۱۸,۳۰,۸,۲۳,۶,۱۵,۲۱,۲۶

استفاده شده که قبلاً به سامانه وارد نشده‌اند. آزمایش سامانه با اغتشاشاتی که برای آن ناشناخته‌اند، قدرت تعمیم‌پذیری سامانه را نشان می‌دهد. نتایج خروجی سیستم تشخیص برای ترکیب‌های مختلف از ویژگی‌های برتر در شرایط مختلف نویزی در جداول ۳ تا ۶ نشان داده شده است.

بهترین نتایج به دست آمده از بالاترین تا پایین‌ترین ابعاد ویژگی در جدول ۷ نمایش داده شده است. بالاترین دقت توسط ۲۶ ویژگی، برای

این جداول نمایش داده شد. مناسب‌ترین دقت توسط ۲۰ ویژگی، برای سیگنال‌های خالص، ۱۷ ویژگی برای سیگنال با ۴۰ دسی بل نویز، ۱۵ ویژگی برای سیگنال با ۳۰ دسی بل نویز و ۱۸ ویژگی برای سیگنال با ۲۰ دسی بل نویز به دست آمده است.

پس از آموزش سامانه می‌توان از آن به عنوان ابزاری قدرتمند جهت مشخص‌نمودن اغتشاشات استفاده کرد. در فرایند آزمایش از اغتشاشاتی

جدول ۶: نتایج حاصل از سیستم تشخیص با MSVM و در شرایط ۴۰ دسی‌بل نویز.

Dimension	Accuracy (%)	Selected feature
۱	۵۰	۲۳
۲	۳۹٫۷۷	۲۶٫۲۳
۳	۷۱	۱٫۲۶٫۲۳
۴	۶۸٫۳۳	۸٫۱٫۲۶٫۲۳
۵	۷۵٫۲۲	۱۸٫۸٫۱٫۲۶٫۲۳
۶	۸۰٫۱۱	۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۷	۸۵٫۵۵	۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۸	۸۶٫۷۷	۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۹	۸۶٫۸۸	۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۰	۸۸٫۱۱	۲۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۱	۹۰٫۸۸	۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۲	۹۷٫۴۴	۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۳	۹۷٫۶۶	۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۴	۹۷٫۶۶	۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۵	۹۷٫۸۸	۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۶	۹۸٫۱۱	۲۰٫۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۷	۹۸٫۸۸	۱۴٫۲۰٫۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۸	۹۹	۱۱٫۱۴٫۲۰٫۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۱۹	۹۹	۱۷٫۱۱٫۱۴٫۲۰٫۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳
۲۰	۹۹	۲٫۱۷٫۱۱٫۱۴٫۲۰٫۱۹٫۶٫۲۹٫۳٫۴٫۳۱٫۲۵٫۱۳٫۱۵٫۲۷٫۱۸٫۸٫۱٫۲۶٫۲۳

جدول ۷: بهترین نتایج ممکن از بین ۳۱ ویژگی.

Signal	Classifier	
	GS-MSVM	
Normal	Accuracy	۹۹٫۷۷
	Feature rank	۲۶
۴۰ db	Accuracy	۹۹٫۴۴
	Feature rank	۱۷
۳۰ db	Accuracy	۹۹٫۷۷
	Feature rank	۲۶
۲۰ db	Accuracy	۹۹٫۲۲
	Feature rank	۳۰

شرایط مختلف نویزی بیان نشده است. با وجود این که در مقاله [۲۴] تعداد داده‌های آموزشی سامانه تشخیص دو برابر این مقاله لحاظ شده است، عملکرد سامانه تشخیص پیشنهاد شده مقاله حاضر در حالت نویزی بهتر از مقاله مذکور می‌باشد. نکته قابل توجه این است که دقت به دست آمده در این مقاله، با وجود بدترین شرایط نویزی از دقت مقاله‌های [۳۳] و [۲۲] در شرایط بدون نویز بیشتر است. نتایج مقایسه نشان می‌دهد الگوریتم طبقه‌بندی ارائه شده در این مقاله با وجود نویز دقت بالایی دارد.

۹- نتیجه‌گیری

ایده اصلی مقاله، غلبه بر کمبودهای آنالیزورهای کیفیت توان مانند حساسیت در برابر نوسانات سریع پارامترهای سیگنال ورودی و تشخیص با دقت بالا می‌باشد. این مقاله یک روش جدید بر اساس تبدیل s هذلولی و تبدیل موجک گسسته و ابزار یادگیری ماشین را به منظور تشخیص اغتشاشات کیفیت توان ارائه می‌کند. در این مقاله روش و سامانه‌ای کارآمد برای تشخیص اغتشاشات کیفیت توان بر اساس ابزار پردازش سیگنال و یادگیری ماشین ارائه شده است. ارزیابی سامانه تشخیص از یک طرف مبتنی بر دقت آن و از طرف دیگر بر تنوع اغتشاشات تشخیص داده شده می‌باشد. در این مقاله یک سیستم هوشمند جهت تشخیص و طبقه‌بندی خودکار تعداد قابل توجهی از اغتشاشات با دقت بالا ارائه شده است. در این سامانه از تبدیل S تعمیم یافته و موجک برای استخراج ویژگی استفاده می‌شود. در ادامه، ویژگی‌های مختلفی مبتنی بر اطلاعات آماری یا مبتنی بر تئوری اطلاعات استخراج می‌گردد. پس از استخراج رتبه‌بندی ویژگی‌های مناسب از شکل موج اغتشاشات و لتنازی سیستم قدرت به طبقه‌بندی اغتشاشات پرداخته شده است. برای این منظور کارایی روش قدرتمند ماشین بردار پشتیبان مورد بررسی قرار گرفت. نرخ متوسط طبقه‌بندی صحیح با استفاده از روش پیشنهادی برای مسأله کیفیت توان در شرایط مختلف نویزی ۹۹٫۵۵٪ به دست آمده است.

سیگنال‌های خالص، ۱۷ ویژگی برای سیگنال با ۴۰ دسی‌بل نویز، ۲۶ ویژگی برای سیگنال با ۳۰ دسی‌بل نویز و ۳۰ ویژگی برای سیگنال با ۲۰ دسی‌بل نویز به دست آمده است. با توجه به عملکرد کارایی MSVM در یادگیری رابطه غیر خطی بین ورودی و خروجی و مقاومت آن در مقابل نویز، نتایج به دست آمده دارای دقت بالایی می‌باشند. همان طور که در جدول ۷ مشاهده می‌شود ماشین بردار پشتیبان، اغتشاشات کیفیت توان را به درستی با دقت بالایی طبقه‌بندی می‌نماید. در ادامه روش ارائه شده در این مقاله با روش دیگر مقالات مقایسه گردیده است.

۸- مقایسه با دیگر مقالات

به منظور بررسی اثربخشی و امکان سنجی روش پیشنهادی، مقایسه از لحاظ درصد دقت طبقه‌بندی بین نتایج این مطالعه و نتایج مقالات در جدول ۸ ارائه شده است. همان طور که در جدول ۸ دیده می‌شود، عملکرد سیستم خبره پیشنهاد شده در حالت بدون نویز بهتر از مقاله‌های [۵]، [۸]، [۲۲] و [۲۳] می‌باشد. در مقاله‌های [۲۲] و [۳۳] دقت طبقه‌بندی تحت

جدول ۸: نتایج دقت روش پیشنهادی در طبقه‌بندی اغتشاشات کیفیت توان در مقایسه با مقالات پیشین.

Some of PQ studies	Classification accuracy (%)					
	Reference	Noiseless	۴۰ db	۳۰ db	۲۰ db	Overall
K. Manimala, K. Selvi, and R. Ahila (۲۰۱۱) [۳۳]		۹۷٫۵	-	-	-	۹۷٫۵
H. Eristi, A. Ucar, and Y. Demir (۲۰۱۰) [۲۴]		۹۹٫۸۱	-	۹۹٫۳۱	۹۷٫۶۹	۹۸٫۹۳
H. Eristi and Y. Demir (۲۰۱۰) [۳]		۹۹٫۷۱	۹۹٫۵۷	۹۶٫۹۸	۸۴٫۸۶	۹۵٫۲۸
M. Uyar, S. Yildirim, and M. Gencoglu (۲۰۰۹) [۵]		۹۹٫۶۷	۹۹٫۵۶	۹۹٫۱۱	۹۴	۹۸٫۰۸
M. Uyar, S. Yildirim, and M. Gencoglu (۲۰۰۸) [۹]		-	۹۳٫۶۴	۹۱٫۸۵	۸۲٫۹۲	۹۱٫۸
G. S. Hu, F. F. Zhu, and Z. Ren (۲۰۰۸) [۲۲]		۹۸٫۴	-	-	-	۹۸٫۴
F. Zhao and R. Yang (۲۰۰۷) [۳۹]		-	۹۹٫۷	۹۸٫۵	۹۳٫۸	۹۷٫۳۳
M. V. Chilukuri and P. K. Dash (۲۰۰۴) [۸]		-	۹۹٫۲۸	۹۶٫۵	۷۵	۹۰٫۲۶
Z. Moravej, M. Pazoki, and A. Abdoos (۲۰۱۰) [۲۵]		-	-	-	۹۸٫۴۷	۹۹٫۰۳
This paper		۹۹٫۷۷	۹۹٫۴۴	۹۹٫۷۷	۹۹٫۲۲	۹۹٫۵۵

- [8] M. V. Chilukuri and P. K. Dash, "Multiresolution S-transform-based fuzzy recognition system for power quality events," *IEEE Trans. on Power Delivery*, vol. 19, no. 1, pp. 323-330, Jan. 2004.
- [9] M. Uyar, S. Yildirim, and M. T. Gencoglu, "An effective wavelet-based feature extraction method for classification of power quality disturbance signals," *Electric Power Systems Research*, vol. 78, no. 10, pp. 1747-1755, Oct. 2008.
- [10] H. Eris, A. Ucar, and Y. Demir, "Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines," *Electric Power Systems Research*, vol. 80, no. 7, pp. 743-752, Jul. 2010.
- [11] S. Gunal, O. N. Gerek, D. Gokhan Ece, and R. Edizkan, "The search for optimal feature set in power quality event classification," *Expert Systems with Applications*, vol. 36, no. 7, pp. 10266-10273, Sep. 2009.
- [12] P. K. Dash and S. R. Samantaray, "A novel distance protection scheme using time-frequency analysis and pattern recognition approach," *Electrical Power and Energy Systems*, vol. 29, no. 2, pp. 129-137, Feb. 2007.
- [13] M. Kezunovic and Y. Liao, "A novel software implementation concept for power quality study," *IEEE Trans. on Power Delivery*, vol. 17, no. 2, pp. 544-549, Apr. 2002.
- [14] Y. Liao and J. B. Lee, "A fuzzy - expert system for classifying power quality disturbances," *International J. Electrical Power and Energy System*, vol. 26, no. 3, pp. 199-205, Mar 2004.
- [15] A. Thapar, T. K. Saha, and Z. Y. Dong, "Investigation of power quality categorization and simulating its impact on sensitive electronic equipment," *Power Engineering Society General Meeting*, vol. 6, no. 10, pp. 528-533, Jun. 2004.
- [16] B. Bizjak and P. Planinsic, "Classification of power disturbances using fuzzy logic," in *International Conf. on Power Electronics and Motion Control*, vol. 1, pp. 1356-1360, Aug./Sep. 2006.
- [17] G. S. Hu, J. Xie, and F. F. Zhu, "Classification of power quality disturbances using wavelet and fuzzy support vector machines," in *Proc. Int. Conf. on Machine Learning and Cybernetics*, vol. 7, pp. 3981-3984, 18-21 Aug. 2005.
- [18] R. Hooshmand and A. Enshae, "Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm," *Electric Power Systems Research*, vol. 80, no. 12, pp. 1552-1561, Dec. 2010.
- [19] T. Nguyen and Y. Liao, "Power quality disturbance classification utilizing S-transform and binary feature matrix method," *Electric Power Systems Research*, vol. 79, no. 4, pp. 569-575, Apr. 2009.
- [20] Z. He, S. Gao, X. Chen, J. Zhang, Z. Bo, and Q. Qian, "Study of a new method for power system transients classification based on wavelet entropy and neural network," *Electrical Power and Energy Systems*, vol. 33, no. 3, pp. 402-410, Mar. 2011.
- [21] S. Kaewarsa, K. Attakitmongcol, and T. Kulworawanichpong, "Recognition of power quality events by using multi wavelet-based neural networks," *Electrical Power and Energy Systems*, vol. 30, no. 4, pp. 254-260, May 2008.
- [22] G. S. Hu, F. F. Zhu, and Z. Ren, "Power quality disturbance identification using wavelet packet energy entropy and weighted support vector machines," *Expert Systems with Applications*, vol. 35, no. 2, pp. 143-149, Aug. 2008.
- [23] C. N. Bhende, S. Mishra, and B. K. Panigrahi, "Detection and classification of power quality disturbances using S-transform and

در این مقاله سعی شده است تا با استفاده از این روش، رنج وسیعی از اغتشاشات تک و ترکیبی کیفیت توان مورد شناسایی و دسته‌بندی قرار گیرد. از دلایل توانایی روش پیشنهادی می‌توان به استخراج بردار ویژگی‌های مناسب توسط تبدیل S تعمیم‌یافته و تبدیل موجک گسسته، روش جدید انتخاب این ویژگی‌ها و همچنین استفاده از قابلیت بالای روش MSVM در تشخیص و طبقه‌بندی الگوها اشاره کرد. از جمله برتری‌های دیگر این روش نسبت به کارهای پیشین این است که در این مقاله بعضی پدیده‌های توأم نیز در نظر گرفته شده است. همچنین به دلیل استفاده از روش ترکیبی GSFS - MSVM، سرعت و به خصوص دقت در حد قابل قبولی بالا رفته است.

با توجه به نتایج شبیه‌سازی‌های ارائه‌شده در این مقاله و مقایسه آن با دیگر مقالات چاپ‌شده در این حوزه، روش پیشنهادی بدون استفاده از الگوریتم‌های نوین‌زادایی، در شرایط نوین‌زادایی دارای بهترین عملکرد می‌باشند و می‌تواند بدون پیچیدگی و انجام مراحل و محاسبات نوین‌زادایی، اغتشاشات کیفیت توان را با دقت مناسب شناسایی نماید.

مراجع

- [1] D. Granados-Lieberman, R. J. Romero-Troncoso, R. A. Osornio-Rios, A. Garcia-Perez, and E. Cabal-Yepez, "Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review," *IET Generation, Transmission, and Distribution*, vol. 5, no. 4, pp. 519-529, Apr 2010.
- [2] M. Kumar Saini and R. Kapoor, "Classification of power quality events - a review," *Electrical Power and Energy Systems*, vol. 43, no. 1, pp. 11-19, Dec. 2012.
- [3] H. Eristi and Y. Demir, "A new algorithm for automatic classification of power quality events based on wavelet transform and SVM," *Expert Systems with Applications*, vol. 37, no. 6, pp. 4094-4102, Jun. 2010.
- [4] J. G. M. S. Decanini, M. S. Tonelli-Neto, F. C. V. Malange, and C. R. Minussi, "Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network," *Electric Power Systems Research*, vol. 81, no. 12, pp. 2057-2065, Dec. 2011.
- [5] M. Uyar, S. Yildirim, and M. T. Gencoglu, "An expert system based on S-transform and neural network for automatic classification of power quality disturbances," *Expert Systems with Applications*, vol. 36, no. 3, pp. 5962-5975, Apr. 2009.
- [6] H. S. Behera, P. K. Dash, and B. Biswal, "Power quality time series data mining using S-transform and fuzzy expert system," *Applied Soft Computing*, vol. 10, no. 3, pp. 945-955, Jun. 2010.
- [7] B. K. Panigrahi, P. K. Dash, and J. B. V. Reddy, "Hybrid signal processing and machine intelligence techniques for detection, quantification, and classification of power quality disturbances," *Engineering Applications of Artificial Intelligence*, vol. 22, no. 3, pp. 442-454, Apr. 2009.

- [34] M. Hari Krishnan and R. Viswanathan, "New concept of reduction of gaussian noise in images based on fuzzy logic," *Applied Mathematical Sciences*, vol. 7, no. 12, pp. 595-602, Sep. 2013.
- [35] www.sutec.ac.ir/portal/channels/fckuploadedfiles/fa/743/Document s.
- [36] S. Verdu, "Spectral efficiency in the wideband regime," *IEEE Trans. on Information Theory*, vol. 48, no. 6, pp. 132-140, Jun. 2002.
- [37] H. Zhang, P. Liu, and O. P. Malik, "Detection and classification of power quality disturbances in noisy conditions," in *IEE Proc. Gen Transm Distrib*, vol. 150, no. 5, pp. 567-572, Sep. 2003.
- [38] P. O'shea, "A high - resolution spectral analysis algorithm for power - system disturbance monitoring," *IEEE Trans. on Power Systems*, vol. 17, no. 3, pp. 676-680, Jun. 2002.
- [39] F. Zhao and R. Yang, "Power - quality disturbance recognition using S transform," *IEEE Trans. on Power Delivery*, vol. 22, no. 2, pp. 944-950, Apr. 2007.
- modular neural network," *Electric Power Systems Research*, vol. 78, no. 1, pp. 122-128, Jan. 2008.
- [24] H. T. Yang and C. C. Liao, "A de-noising scheme for enhancing wavelet-based power quality monitoring system," *IEEE Trans. on Power Delivery*, vol. 16, no. 3, pp. 353-360, Jul. 2001.
- [25] C. W. Lu and S. J. Huang, "An application of B-spline wavelet transform for notch detection enhancement," *IEEE Trans. on Power Delivery*, vol. 19, no. 3, pp. 1419-1425, Jul. 2004.
- [26] H. Eristi, A. Ucar, and Y. Demir, "Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines," *Electric Power Systems Research*, vol. 80, no. 7, pp. 743-752, Jul. 2010.
- [27] Z. Moravej, M. Pazoki, and A. A. Abdoos, "Wavelet transform and multi-class relevance vector machines based recognition and classification of power quality disturbances," *Euro Trans. on Electrical Power*, vol. 21, no. 1, pp. 221-222, Jan. 2010.
- [28] V. Fernaldo Pires, T. G. Amaral, and J. F. Martins, "Power quality disturbances classification using the 3-D space representation and PCA based neuro-fuzzy approach," *Expert Systems with Applications*, vol. 38, no. 9, pp. 11911-11917, Sep. 2011.
- [29] Y. Sun, S. Todorovic, and S. Goodison, "Local - learning - based feature selection for high - dimensional data analysis," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 32, no. 9, pp. 1610-1626, Sep. 2010.
- [30] S. Foithong, O. Pinngern, and B. Attachoo, "Feature subset selection wrapper based on mutual information and rough sets," *Expert Systems with Applications*, vol. 39, no. 1, pp. 574-584, Jan. 2012.
- [31] J. Li, M. T. Manry, P. L. Narasimha, and C. Yu, "Feature selection using a piecewise linear network," *IEEE Trans. on Neural Networks*, vol. 17, no. 5, pp. 1101-1105, Sep. 2006.
- [32] K. Z. Mao, "Orthogonal forward selection and backward elimination algorithms for feature subset selection," *IEEE Trans. on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 34, no. 1, pp. 629-634, Feb. 2004.
- [33] K. Manimala, K. Selvi, and R. Ahila, "Hybrid soft computing techniques for feature selection and parameter optimization in power quality data mining," *Applied Soft Computing*, vol. 1111, no.8, pp. 5485-5497, Dec. 2011.

مهدی حاجیان تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق گرایش قدرت به ترتیب در سال‌های ۱۳۸۹ و ۱۳۹۱ از دانشگاه سمنان به پایان رسانده است و هم‌اکنون به‌عنوان پژوهشگر فعالیت می‌نماید. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پایداری سیستم‌های قدرت، حفاظت سیستم‌های قدرت، هوش مصنوعی و کیفیت توان.

اصغر اکبری فرود در سال ۱۳۷۳ مدرک کارشناسی مهندسی برق خود را از دانشگاه تهران و در سال ۱۳۷۶ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه تربیت مدرس دریافت نمود. از سال ۱۳۷۶ به‌عنوان عضو هیأت‌علمی در دانشگاه سمنان مشغول به کار شد. ایشان در سال ۱۳۸۵ موفق به اخذ درجه دکتری از دانشگاه تربیت مدرس گردید. در حال حاضر ایشان به‌عنوان هیأت‌علمی در دانشکده مهندسی برق و کامپیوتر دانشگاه سمنان مشغول به کار است. زمینه‌های علمی مورد علاقه نام‌برده متنوع بوده و شامل موضوعاتی مانند دینامیک و بهره‌برداری از سیستم‌های قدرت، تجدید ساختار و کیفیت توان می‌باشد.