

---

## A novel method based on a combination of deep learning algorithm and fuzzy intelligent functions for classifying power quality disturbances in power systems

Neda Jalali<sup>1</sup>, Mohammad Tolou Askari<sup>2</sup>, Hadi Razmi<sup>3</sup>

1- Department of Electrical Engineering, Semnan Branch, Islamic Azad University, Semnan, Iran  
nedajalali306@gmail.com

2-Energy and Sustainable Development Research Center, Semnan Branch, Islamic Azad University, Semnan, Iran  
m.asgary28@gmail.com

3- Department of Electrical Engineering, East Tehran Branch, Islamic Azad University, Tehran, Iran  
razmi.hadi@gmail.com

### Abstract

Automatic classification of power quality disturbances is the foundation to deal with the power quality problem. From a traditional viewpoint, the identification process of power quality disturbances should be divided into three independent stages: signal analysis, feature selection, and classification. However, there are some inherent defects in signal analysis and the procedure of manual feature selection is tedious and imprecise, leading to a low classification accuracy of multiple disturbances. To deal with these problems, this paper presents an automated system for the classification and identification of power quality disturbances. After receiving input signals, the proposed system requires some preprocessing such as changing the range of values by dividing the signals into their basic domains. In the next stage, the RMS value of the signal can be appraised to know the occurrence of the disturbance. If the RMS value of the input signal is not equal to the normal signal, the disturbance is occurring. To identify and classify disturbances, a novel deep learning-based method is developed. In this method, the activation function is expressed by a fuzzy approach. This makes the system more flexible. The benefits of the proposed strategy are separating the disturbances of basic frequency and using the nature of power quality signals as a tool for feature extraction. However, in the traditional method, for example, in empirical mode decomposition, the separation of signals from their components is not conveniently possible. To evaluate the proposed algorithm, a 33-bus distribution power network has been applied. The results reveal good agreement in comparison with other assessment tests.

**Keywords:** classification of power quality disturbances, power system, deep learning algorithm, fuzzy intelligent algorithm.

**Received:**2021/01/11

**Accepted:**2021/09/05

# ارائه‌ی یک روش جدید مبتنی بر ترکیب الگوریتم یادگیری عمیق و توابع هوشمند فازی به منظور طبقه‌بندی اختلالات کیفیت توان در سیستم‌های قدرت

نوع مطالعه: پژوهشی

ندا جلالی<sup>۱</sup>، دانشجوی دکتری، محمد طلوع عسکری<sup>۲\*</sup>، استادیار، هادی رزمی<sup>۳</sup>، استادیار

۱- گروه مهندسی برق، واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران  
*nedajalali306@gmail.com*

۲- مرکز تحقیقات انرژی و توسعه پایدار، واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران  
*m.asgary28@gmail.com*

۳- گروه مهندسی برق، واحد تهران شرق، دانشگاه آزاد اسلامی، تهران، ایران  
*razmi.hadi@gmail.com*

چکیده: طبقه‌بندی خودکار اختلالات کیفیت توان پایه و اساس حل مشکل کیفیت توان است. از نقطه‌نظر سنتی، فرآیند شناسایی اختلالات کیفیت توان باید به سه مرحله مستقل تقسیم شود: تحلیل سیگنال، انتخاب ویژگی و طبقه‌بندی. با این حال، برخی نواقص ذاتی در آنالیز سیگنال وجود دارد و روند انتخاب ویژگی دستی خسته‌کننده و غیردقیق است که منجر به دقت طبقه‌بندی پایین اختلالات چندگانه می‌شود. با توجه به این مشکلات، در این مقاله یک سیستم خودکار به منظور شناسایی و طبقه‌بندی اختلالات کیفیت توان ارائه شده است. در سیستم پیشنهادی پس از دریافت سیگنال ورودی پیش‌پردازش‌هایی نظیر تغییر بازه مقادیر با تقسیم سیگنال‌ها به دامنه پایه خود انجام می‌شود. در مرحله بعد مقدار RMS سیگنال برای بررسی رخداد اختلال مورد ارزیابی قرار می‌گیرد. در صورتی که RMS سیگنال ورودی با مقدار RMS سیگنال نرمال یکسان نباشد، به معنی رخداد اختلال در سیگنال است. به منظور شناسایی و دسته‌بندی اختلال‌ها از یک روش جدید مبتنی بر الگوریتم یادگیری عمیق استفاده شده است. در این روش، توابع فعال‌ساز به کمک توابع فازی تعریف می‌گردد. با این کار، انعطاف‌پذیری سیستم افزایش می‌یابد. مزیت روش ارائه شده در این است که به خوبی اختلالات ایجاد شده را از فرکانس پایه جدا می‌سازد و از ماهیت سیگنال‌های کیفیت توان به منظور استخراج ویژگی استفاده می‌کند. این در حالی است که جداسازی اجزای سیگنال در روش‌های کلاسیک مانند تجزیه مُد تجربی به خوبی امکان‌پذیر نبوده است. برای ارزیابی الگوریتم از شبیه‌سازی شبکه توزیع قدرت ۳۳ باسه استفاده شده است. دقت ارزیابی به دست آمده با استفاده از الگوریتم پیشنهادی در مقایسه با کارهای مشابه، بهبود نسبی پیدا کرده است.

واژه‌های کلیدی: طبقه‌بندی اختلالات کیفیت توان، سیستم قدرت، الگوریتم یادگیری عمیق، الگوریتم هوشمند فازی

تاریخ ارسال مقاله: ۱۳۹۹/۱۰/۲۲

تاریخ پذیرش مقاله: ۱۴۰۰/۰۶/۱۴

نام نویسنده‌ی مسئول: محمد طلوع عسکری

نشانی نویسنده‌ی مسئول: مرکز تحقیقات انرژی و توسعه پایدار، واحد سمنان، دانشگاه آزاد اسلامی، سمنان، ایران

## ۱- مقدمه:

صنعت برق شامل تولید انرژی الکتریکی، انتقال و در نهایت توزیع آن تا مصرف‌کننده نهایی است. انتقال توان الکتریکی از تولید تا مصرف به پارامترهای مختلفی بستگی دارد که فرصت‌های زیادی برای افت کیفیت توان فراهم می‌آورد (Mahela, Shaik, & Gupta, 2015). بروز این اختلالات موجب نقص فنی در تجهیزات سیستم‌های الکترونیکی، از بین رفتن داده‌ها و خرابی حافظه‌ی بارهای حساسی مانند کامپیوترها و کنترل‌کننده‌های منطقی برنامه‌پذیر در خطوط تولید کارخانه‌ها می‌شود. بدین ترتیب عدم کنترل این تغییرات، خسارت‌های سنگین به بارهای حساس متصل به شبکه برق وارد کرده و موجب نارضایتی مشترکین می‌شود. علاوه بر این، با توجه به اینکه این اختلالات در کسری از ثانیه رخ می‌دهند، رویداد ثبت شده در سیستم‌های نظارتی حجم عظیمی از اطلاعات را تولید می‌کند. لذا امکان نگهداری تمام سیگنال‌های تولیدشده در کامپیوترهای شخصی امکان‌پذیر نیست و نیاز به فشرده‌سازی داده‌ها بسیار ضروری است. برای فشرده‌سازی، نیاز به شناسایی این اختلالات با استفاده از سیستم‌های تشخیص و طبقه‌بندی آن‌ها ضروری بوده و نظارت مداوم روی آنها از اهمیت ویژه‌ای برخوردار است (Duchesne, Karangelos, & Wehenkel, 2020).

هر گونه انحراف از حالت ایده‌آل به عنوان پدیده اختلال کیفیت توان شناخته می‌شود. این اختلالات شامل افت ولتاژ بلندمدت<sup>۱</sup>، قطعی ولتاژ بلندمدت<sup>۲</sup>، افزایش ولتاژ بلندمدت<sup>۳</sup>، کمبود ولتاژ کوتاه‌مدت<sup>۴</sup>، قطعی ولتاژ کوتاه‌مدت<sup>۵</sup>، گذراهای ولتاژ<sup>۶</sup>، عدم تعادل ولتاژ<sup>۷</sup>، نوسانات ولتاژ<sup>۸</sup>، اختلال فرکانس، هارمونیک‌ها و میان‌هارمونیک‌ها<sup>۹</sup>، شکاف<sup>۱۰</sup> و نویز می‌باشد

- <sup>1</sup> Undervoltage
- <sup>2</sup> Outage
- <sup>3</sup> Overvoltage
- <sup>4</sup> Sag
- <sup>5</sup> Interruption
- <sup>6</sup> Voltage Transients
- <sup>7</sup> Voltage Unbalance
- <sup>8</sup> Voltage Flucuations
- <sup>9</sup> Harmonics and Interharmonics

(Mishra, 2019). در یک سیستم شناسایی و تشخیص اختلالات کیفیت توان، پس از دریافت سیگنال، ابتدا پیش‌پردازش‌هایی نظیر حذف نویز از سیگنال و نرمالیزه کردن آن انجام می‌شود. سپس، از روش‌های پردازش سیگنال استفاده شده و ویژگی‌هایی نظیر مشخصات آماری و شاخص‌های کیفیت توان از درون آن استخراج می‌شود. در نهایت، با استفاده از ویژگی‌های به دست آمده امکان طبقه‌بندی اختلال‌ها فراهم می‌گردد (Mishra, Nayak, Naik, & Abraham, 2020).

در مرجع (J. Liu, Song, & Zhou, 2019) با استفاده از موجک مادر Daubechies سیگنال اصلی تا شش سطح اول تجزیه می‌شود. سپس برای شناسایی و طبقه‌بندی اختلالات، ابتدا با استفاده از ضرایب جزئیات سطح اول تجزیه، محل رخداد اختلال تعیین می‌گردد. در گام بعد از انرژی نرمالیزه شده ضرایب جزئیات سطح دوم تا ششم تجزیه و مقدار rms نرمالیزه شده دامنه سیگنال اصلی در سه فاز، به عنوان پارامترهای بردار ویژگی استفاده می‌شود.

در مرجع (Mishra & Panigrahi, 2020) برای تخمین قیمت‌های کیفیت توان از تبدیل موجک مختلط استفاده شده است. در این رویکرد ابتدا با اعمال تبدیل موجک بدون کاستن از تعداد نمونه‌های<sup>۱۱</sup> سیگنال اصلی و تبدیل هیلبرت یافته آن، ضرایب جزئیات و کلیات دو بخش حقیقی و موهومی موجک مختلط بدست می‌آید. سپس با محاسبه‌ی دامنه و فاز آنی سیگنال‌های ولتاژ و جریان، کمیت‌هایی نظیر توان اکتیو و راکتیو آنی برای بارهای خطی، غیرخطی و اختلال هارمونیک محاسبه می‌گردد.

در مرجع (Gupta, Seethalekshmi, & Datta, 2021) به منظور شناسایی اختلالات، استخراج ویژگی‌ها با استفاده از روش نرم آنتروپی مبتنی بر تبدیل موجک انجام گرفته است. در این مرجع، روش استخراج ویژگی نرم آنتروپی مبتنی بر تبدیل موجک ارائه شده است. با توجه به مثبت بودن مقدار نرم آنتروپی برای تمام اختلالات، بردارهای ویژگی اختلالاتی نظیر افت ولتاژ کوتاه مدت و افزایش ولتاژ کوتاه مدت نزدیکی زیادی به یکدیگر دارند. لذا برای افزایش دقت طبقه‌بندی از بردار

<sup>10</sup> Notch

<sup>11</sup> Non-Decimated Wavelet Transform

عنوان تابع ارزیابی و افزایش دقت طبقه‌بند در ده فولد<sup>۱</sup> به عنوان تابع هدف در نظر گرفته شده است.

در مرجع (Mahela, Shaik, Khan, Mahla, & Alhelou, 2020) با استخراج ۱۴ ویژگی آماری از کانتورهای زمان-فرکانس، فرکانس، فرکانس-ماکزیمم دامنه، زمان-ماکزیمم دامنه و فرکانس-انحراف معیار در تبدیل S، بردار ویژگی اولیه برای این تبدیل ساخته شده است. سپس با بررسی جداپذیری انواع مختلف اختلالات با تمام جایگشت‌های ممکن برای دو ویژگی، مجموعه‌ی جفت ویژگی‌های برتر قابل دستیابی است. در این مرجع با انتخاب سه دسته از جفت ویژگی‌های برتر و در اختیار قرار دادن این شش ویژگی به یک شبکه عصبی پرسپترون ۳ لایه، نرخ یادگیری ۰.۵ و تابع فعال‌ساز تانژانت سیگموئید برای لایه ورودی و نهم و تابع فعال‌ساز لگاریتم سیگموئید برای لایه خروجی، طبقه‌بندی اختلالات انجام گرفته است. در مرجع (Rodrigues Junior et al., 2021) نیز مانند (Mahela et al., 2020) با استفاده از اطلاعات آماری نظیر انحراف معیار، مقادیر ماکزیمم و مینیمم، میانگین، چولگی و برجستگی منحنی‌های زمان-ماکزیمم دامنه، فرکانس-ماکزیمم دامنه، ۱۸ ویژگی استخراج شده است. سپس جداپذیری انواع مختلف اختلالات براساس جایگشت‌های مختلف از دو ویژگی استخراج شده بررسی می‌گردد تا دو ویژگی برتر انتخاب شوند. در صورت عدم جداپذیری اختلالات با دو ویژگی، یک ویژگی دیگر به مجموعه ویژگی موجود افزوده و جداپذیری اختلالات با سه ویژگی و یا تعداد بیشتر ویژگی بررسی می‌شود. در انتها نیز با استفاده از طبقه‌بند شبکه عصبی احتمالاتی اختلالات از یکدیگر تفکیک می‌شوند.

در مرجع (Hajian & Foroud, 2014) با ترکیب تبدیل S هذلولی و تبدیل موجک ویژگی‌های طیفی و آماری نظیر میانگین، انحراف معیار، مساحت زیر نمودار و انرژی مجموعه داده‌ها از نمودارهای فرکانس-ماکزیمم دامنه، زمان-ماکزیمم دامنه و کانتور فرکانس-زمان، متوسط آنتروپی شانون، لگاریتمی و حد آستانه برای چهار سطح اول تجزیه موجک و ... استخراج شده است. در تبدیل S هذلولی به جای پنجره گوسی متقارن از پنجره گوسی نامتقارن استفاده شده است. در پنجره

ویژگی سیگنال سینوسی خالص به عنوان مرجع استفاده می‌گردد. در نهایت، به منظور طبقه‌بندی اختلالات، بردارهای ویژگی به دست آمده در اختیار شبکه عصبی پرسپترون سه لایه قرار می‌گیرد.

در مرجع (Deokar & Waghmare, 2014) از روش تجزیه دو سطحی تبدیل موجک گسسته برای شناسایی اختلالات کیفیت توان استفاده شده است. در این مرجع، ابتدا برای سیگنال خالص و سیگنال دارای اختلال بردار ویژگی اولیه ساخته می‌شود. سپس بر اساس آن مقدار متوسط آنتروپی انرژی و اختلاف مقدار متوسط مجموع ضرایب جزئیات دو سیگنال خالص و سیگنال دارای اختلال به عنوان ویژگی نهایی استخراج می‌گردد. علاوه بر این، به منظور تشخیص اختلال در هنگام حضور نویز نیز از یک الگوریتم مبتنی بر تبدیل موجک و تبدیل فوریه سریع استفاده شده است. در این الگوریتم با تعیین میزان ماکزیمم و مینیمم متوسط ضرایب جزئیات ده سطح اول تجزیه برای مجموعه سیگنال‌های آموزش هر یک از اختلالات، یک بازه مقادیر حاصل می‌شود که بازه مقادیر کرانه‌ای به دست آمده برای اختلالات مختلف مقادیر نسبتاً منحصر به فردی هستند. بدین ترتیب با محاسبه متوسط انرژی ضرایب ده سطح اول تجزیه سیگنال تست می‌توان گروهی را که اختلال در آن قرار می‌گیرد تشخیص داد. سپس برای تعیین دقیق نوع اختلال تبدیل فوریه سریع سیگنال اصلی محاسبه می‌شود تا تعداد اجزای فرکانسی موجود در سیگنال تعیین گردد. با این وجود باید توجه کرد که در این مرجع دامنه نویز اضافه شده به سیگنال مقدار نسبتاً کمی در نظر گرفته شده است.

در مرجع (Zhao, Shang, & Sun, 2019) با استفاده از تبدیل موجک بدون تلفات سیگنال اصلی تا چهار سطح تجزیه شده است. سپس با اعمال ویژگی‌های آماری نظیر انحراف معیار، چولگی، انرژی، میانگین، آنتروپی و کشیدگی روی ضرایب سطح چهارم تجزیه، بردار ویژگی ساخته می‌شود. در این مرجع برای کاهش تعداد ویژگی‌ها از الگوریتم ژنتیک استفاده شده است که طبقه‌بند k نزدیک‌ترین همسایه فازی به

<sup>1</sup> 10-Fold

فرکانس‌های مختلف، روشی برای افزایش سرعت محاسبات تبدیل S ارائه شده است.

در مرجع (Cai, Hu, Cao, & Li, 2019) با استفاده از روش EMD، سیگنال دریافتی به توابع مد ذاتی تجزیه می‌شود. سپس با استفاده از تبدیل هیلبرت، منحنی‌های دامنه و فاز آنی سه تابع مد ذاتی اول بدست می‌آید. در نهایت، بردار ویژگی با استفاده از انرژی IMF و انحراف معیار منحنی‌های دامنه و فاز آنی سه IMF اول ساخته می‌شود تا عملیات طبقه‌بندی انجام گیرد.

در مرجع (Shukla, Mishra, & Singh, 2013) برای شناسایی و طبقه‌بندی اختلالات کیفیت توان دو روش حذف نویز مبتنی بر روش EMD ارائه شده است. ابتدا سیگنال نویزی با استفاده تبدیل EMD به IMF‌های مختلف تجزیه می‌شود. سپس هر یک از IMF‌ها آستانه‌گذاری شده و سیگنال بدون نویز با ترکیب IMF‌های اصلاح شده به دست می‌آید. در روش دوم، IMF اول از سایر IMF‌ها جدا می‌شود و با استفاده از IMF‌های دوم به بعد یک نسخه جزئی از سیگنال مورد بررسی ساخته می‌شود. با توجه به اینکه IMF اول دارای اجزاء فرکانس بالای سیگنال یعنی نویز است، نسخه‌های مختلفی از IMF اول با جابه‌جایی تصادفی مکان نمونه‌ها ایجاد می‌گردد. پس از آن، با ترکیب نسخه جزئی سیگنال و نسخه‌های مختلف IMF اول، نمونه‌های مختلفی از سیگنال نویزی اولیه ساخته می‌شود. با اعمال روش EMD روی این سیگنال‌ها، آستانه‌گذاری IMF‌ها و میانگین‌گیری از نتایج سیگنال بدون نویز بدست می‌آید. در نهایت، با اعمال تبدیل هیلبرت روی سیگنال بدون نویز و استخراج اطلاعات آماری نظیر انرژی، انحراف معیار و ... بردار ویژگی ساخته می‌شود.

در مرجع (Santos-Hernandez, Valtierra-Rodriguez, Amezcua-Sanchez, Romero-Troncoso, & Camarena-Martinez, 2019) تنها از تبدیل هیلبرت برای استخراج ویژگی در شناسایی اختلالات کیفیت توان استفاده شده است. با توجه به اینکه پاسخ ضربه تبدیل هیلبرت غیرعالی می‌باشد، برای دستیابی به دقت بالاتر، پیاده‌سازی تبدیل هیلبرت در این مرجع به صورت فیلتر پاسخ

نامتقارن به منظور افزایش قدرت تفکیک زمان-فرکانس، قسمت ابتدایی پنجره در حوزه زمان منقبض و قسمت انتهایی پنجره منبسط می‌گردد. بدین ترتیب قسمت ابتدایی پنجره نامتقارن قدرت تفکیک زمانی و قسمت انتهایی آن قدرت تفکیک فرکانسی را تضمین می‌کند. در این مرجع، روش گرام-اشمیت برای انتخاب ویژگی به کار گرفته شده و در انتها از ساختار طبقه‌بندی‌کننده ماشین بردار پشتیبان چند کلاسه برای تشخیص اختلالات استفاده شده است.

در مرجع (Khoramabadi, Keshavarz, & Dashti, 2020) با ترکیب تبدیل S و روش دینامیک، روشی برای تشخیص اختلالات کیفیت توان ارائه شده است. ایده اصلی این مرجع افزایش سرعت عملکرد تبدیل S بوده و مبتنی بر این اصل است که بخش زیادی از فرکانس‌های در نظر گرفته شده برای محاسبه تبدیل S در سیگنال اصلی دارای مقدار صفر بوده و یا به عنوان نویز سیگنال محسوب می‌شوند که دارای اطلاعات مفیدی برای بیان سیگنال نیستند. بنابراین، با استفاده از روش دینامیک که یک روش شناسایی نقاط اکسترمم در شرایط نویزی است، فرکانس‌های مورد نظر غیرصفر و غیرنویز از طیف سیگنال انتخاب می‌شوند. سپس سیگنال اصلی در حوزه طیف به دو بخش سیگنال با مولفه اصلی ۵۰ هرتز و سیگنال با مؤلفه‌های فرکانس بالا تبدیل می‌شود.

در مرجع (Khoramabadi et al., 2020) با استفاده از تبدیل S متعامد روشی برای تحلیل سیگنال‌های اختلالات کیفیت توان ارائه شده است. در تبدیل S متعامد نرخ نمونه‌برداری فرکانس‌های پایین با نرخ نمونه‌برداری فرکانس‌های بالا متفاوت می‌باشد. همچنین، از نحوه نمونه‌برداری اکتا<sup>۱</sup> برای نمونه‌برداری از بازه‌های فرکانسی استفاده شده است. در این مدل از نمونه‌برداری، نرخ نمونه‌برداری در بازه فرکانسی بعد دو برابر نرخ نمونه‌برداری بازه فرکانسی اخیر می‌گردد. این روش باعث افزایش سرعت محاسبات، رزولوشن زمان-فرکانس و کاهش افزودگی میشود. در مرجع (Taheri, Eslami, & Damchi, 2020) نیز مشابه (Khoramabadi et al., 2020) با تغییر نرخ نمونه‌برداری در

<sup>1</sup> Octave Sampling

ولتاژ به همراه هارمونیک و افزایش ولتاژ به همراه هارمونیک به مجموعه اختلالات شناسایی شده در (Cheng et al., 2020) افزوده شده است. بنابراین، با توجه به افزودن اختلال‌های مربوط به هارمونیک مجموعه، متغیرهای حالت نیز تغییر خواهد کرد و به ازای هر یک از هارمونیک‌هایی که در نظر گرفته می‌شود، دو متغیر بخش حقیقی و بخش موهومی هارمونیک به مجموعه متغیرها افزوده می‌شود. بدین ترتیب پارامتر تخمینی دامنه علاوه بر اینکه شامل دامنه فرکانس پایه خواهد شد، مجموعه دامنه هارمونیک‌های افزوده شده را نیز دربر می‌گیرد. در نهایت، میانگین دامنه فرکانس اصلی و هارمونیک‌ها به عنوان پارامتر میانگین انحراف معیار در اختیار یک سیستم خبره فازی قرار می‌گیرد تا مجموعه‌ای از قوانین به منظور تشخیص نوع اختلال به دست آید.

در مرجع (Valtierra-Rodriguez, de Jesus Romero) (Troncoso, Osornio-Rios, & Garcia-Perez, 2013) استفاده از یک شبکه عصبی رو به جلو با سه لایه و تعداد ۳۰ نرون در لایه مخفی، تابع فعال‌ساز لگاریتم-سیگموئید و الگوریتم یادگیری Levenberg-Marquardt طبقه‌بندی اختلالات کیفیت توان انجام شده است. در مرجع (Shamachurn, 2019) از شبکه عصبی احتمالاتی برای طبقه‌بندی اختلالات استفاده شده است. فرآیند یادگیری در این شبکه بسیار سریع است و نمونه‌های آموزش بر طبق نحوه توزیع تابع چگالی احتمالشان<sup>۲</sup> طبقه‌بندی می‌شوند. تابع چگالی احتمالی که در این شبکه استفاده می‌گردد، تابع توزیع احتمالاتی پارزن<sup>۳</sup> یا شبه پارزن است. در مرجع (Subbarao, Kumar, Raju, & Samundiswary, 2020) از شبکه عصبی سه لایه با تابع فعال‌ساز RBF استفاده شده است. به منظور تعیین تعداد مناسب نرون‌های لایه نهان از روش بهینه‌سازی کمینه مربعات خطا استفاده شده است. تعیین محل مراکز کرنل‌های RBF نیز با استفاده از ترکیب الگوریتم ژنتیک و روش خوشه‌بندی K-means انجام شده است.

در مراجع (Xi et al., 2018) و (Saini, Kapoor, Beniwal, & Aggarwal, 2019) از یک سیستم استنتاج

ضربه محدود<sup>۱</sup> انجام گشته است. با استفاده از نمودار پوش به دست آمده از اعمال این تبدیل روی سیگنال و استخراج ویژگی‌های آماری نظیر انرژی، انحراف معیار، میانگین و واریانس امکان شناسایی انواع اختلالات در هنگام حضور/عدم حضور نویز با دقت بالا فراهم شده است.

در مرجع (Cheng et al., 2020) برای افزایش دقت محاسبات در ردیابی نوسانات هارمونیک از یک روش خود تنظیم‌کننده برای کوواریانس خطای مدل استفاده شده است. در این مرجع برای هر یک از هارمونیک‌ها دو متغیر حالت (بخش حقیقی و موهومی) لحاظ شده است. به طور معمول در ردیابی نوسانات هارمونیک، مقدار کوواریانس خطای مدل صفر در نظر گرفته می‌شود. همچنین، تلاش شده است که نویز مدل به صورت تفاضل مشاهده به دست آمده و تخمین پیشین در نظر گرفته شود. با توجه به اینکه عناصر نویز مدل منجر به واریانس‌های مختلف می‌شوند، ماتریس کوواریانس نویز مدل سیستم به صورت میانگین واریانس‌های عناصر نویز مدل تعریف شده است.

در مرجع (H. Liu, Hussain, Yue, Yildirim, & Yawar, 2019; S. Wang & Chen, 2019) فیلتر کالمن در کنار تبدیل موجک گسسته برای استخراج پارامترهای سیگنال نظیر دامنه و شیب به کار گرفته شده است. ابتدا با استفاده از ضرایب جزئیات سطح اول تبدیل موجک گسسته، مقدار و کوواریانس نویز محاسبه می‌شود و به همراه سیگنال ورودی در اختیار فیلتر کالمن خطی قرار می‌گیرد. پس از آن، فیلتر کالمن به تخمین دامنه و شیب سیگنال می‌پردازد. با در اختیار قرار دادن پارامترهای تخمینی به یک سیستم خبره فازی، مجموعه‌ای از قوانین به منظور تشخیص نوع اختلال تعیین می‌گردد.

در مرجع (H. Liu et al., 2019) مشابه با (S. Wang & Chen, 2019) از فیلتر کالمن در کنار تبدیل موجک گسسته استفاده شده است. در این مرجع علاوه بر پارامترهای دامنه و شیب از پارامتر میانگین انحراف معیار هم استفاده شده است. دو اختلال مربوط به هارمونیک‌های سیگنال اصلی شامل افت

<sup>2</sup> Probabilistic density function

<sup>3</sup> Parzen

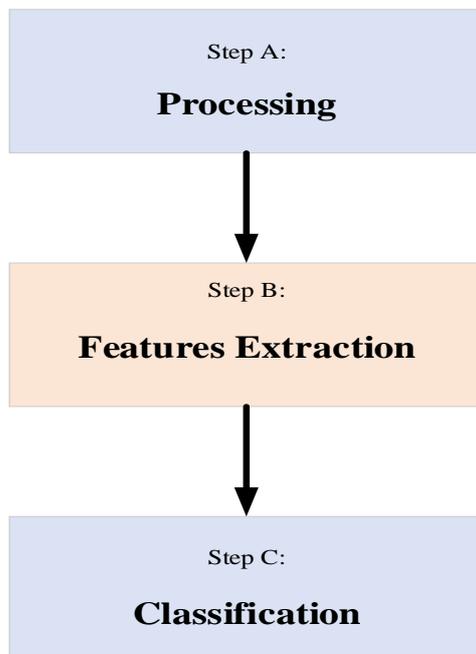
<sup>1</sup> Finite Impulse Response Filter

بالای توابع فازی، دامنه‌ی عملکردی الگوریتم بالاتر می‌رود. بدین ترتیب می‌توان امید داشت که دقت و سرعت روش یادگیری عمیق بهبود نسبی پیدا کند.

مقاله‌ی حاضر در پنج بخش تنظیم شده است. در بخش دوم، متدلوژی کار ارائه شده است و روابط و نمودارهای مربوط به الگوریتم یادگیری عمیق مبتنی بر روش فازی بیان شده است. در بخش سوم مطالعه موردی مقاله ارائه شده است. در بخش چهارم، نتایج شبیه‌سازی ارائه شده و در انتها بخش پنجم به نتیجه‌گیری اختصاص داده شده است.

## ۲- متدلوژی

در این مقاله، طبقه‌بندی اختلالات توان در سه گام شامل پردازش، استخراج ویژگی و طبقه‌بندی انجام می‌گیرد. در این راستا، یک الگوریتم جدید یادگیری عمیق ارائه شده است. در این الگوریتم، شبکه عصبی موجود در ساختار الگوریتم یادگیری عمیق به صورت پویا عمل می‌کند. بدین صورت که توابع فعال‌ساز آن در قالب توابع فازی تعریف می‌گردد. با این کار، دامنه‌ی عملکرد الگوریتم یادگیری عمیق گسترده شده و انعطاف‌پذیری آن نسبت به قبل افزایش می‌یابد. ترتیب مراحل یاد شده در طبقه‌بندی اختلالات توان توسط این الگوریتم در قالب این سه گام مطابق شکل ۱ ارائه شده است. در ادامه، هر کدام از این سه مرحله توضیح داده شده است.



شکل ۱: طراحی چارچوب تولید ناحیه‌ی اختلال توان

فازی به روش ممدانی استفاده شده است. غیر فازی‌سازی سیستم با استفاده از معیارهای مرکز ناحیه و مینیمم و ماکزیمم‌ها به دست آمده است. در مرجع ( Karasu & Saraç, 2020) برای تشخیص اختلالات کیفیت توان از دو سیستم فازی با پیاده‌سازی به روش سوگنو استفاده شده است. در سیستم فازی اول با استفاده از پارامترهای مقدار RMS، اعوجاج هارمونیک کل و اختلاف فاز وجود اختلال در هر سیکل سیگنال بررسی می‌شود. سپس، در سیستم فازی دوم نوع اختلال مشخص می‌گردد. نوع تابع عضویت در هر دو سیستم دوزنقه‌ای می‌باشد که در سیستم دوم پارامترهای تابع عضویت مربوط به هر کلاس با استفاده از روش بهینه‌سازی ازدحام ذرات به صورت بهینه انتخاب شده‌اند. در مرجع ( Qu, Li, Liu, & Alsaadi, 2020) از سیستم فازی با دو تابع عضویت گوسی و دوزنقه‌ای برای طبقه‌بندی اختلالات استفاده شده است.

با توجه به آنچه گفته شد، رویکردهای مختلفی به منظور طبقه‌بندی اختلالات کیفیت توان توسعه‌یافته‌اند، اما روش‌های سنتی دارای برخی معایب ذاتی هستند به طوری که عملکرد طبقه‌بندی آن به انتخاب ویژگی‌ها و طبقه‌بندی‌کننده متصل به شدت وابسته است. علاوه بر این، تمام این روش‌ها تحت‌تأثیر سیگنال نویز قرار می‌گیرند و بار محاسباتی سنگینی دارند (Sindi, Nour, Rawa, Öztürk, & Polat, 2021). بنابراین، یک الگوریتم پردازش سیگنال جدید با قابلیت کاربرد گسترده و ضد نویز باید اتخاذ شود. الگوریتم یادگیری عمیق دارای عملکرد چشم‌گیری در طبقه‌بندی اختلالات کیفیت توان می‌باشد (Yoshikane & Yoshimura, 2021). شبکه‌های عصبی عمیق از طریق لایه‌های خاص و آموزش نظارت شده، می‌توانند استخراج خودکار ویژگی‌های فضایی و زمانی را از داده‌های ورودی بدون هیچ مرحله سنتی پردازش سیگنال و سپس تکمیل کارهایی مانند طبقه‌بندی و رگرسیون تحقق بخشند. کاربرد یادگیری عمیق در مسائل طبقه‌بندی اختلالات کیفیت توان نه تنها می‌تواند دقت طبقه‌بندی را بهبود بخشد، بلکه می‌تواند فرآیندها را نیز ساده‌تر کند (Aslam et al., 2021). البته در بیشتر مراجع بررسی شده، روش یادگیری عمیق مبتنی بر الگوریتم شبکه عصبی معمولی برای طبقه‌بندی اختلالات کیفیت توان استفاده شده است. در این روش، بر اساس داده‌های ورودی-خروجی سیستم، شبکه عصبی آموزش داده می‌شود. سپس، توابع فعال‌ساز نیز بر اساس الگوریتم‌های از پیش تعیین شده تعریف می‌گردد. این توابع از پیش تعیین شده، محدودیت‌هایی را برای کارکرد الگوریتم یادگیری عمیق ایجاد می‌کند. چرا که توابع فعال‌ساز یک دامنه‌ی خاصی را پوشش می‌دهند. هدف این مقاله، تعریف توابع فعال‌ساز در قالب الگوریتم فازی است. در این روش، به دلیل انعطاف‌پذیری

## ۲-۱-۱ گام A: پردازش

بودجه‌ی عدم قطعیت باس  $b$  در لحظه  $k$  هستند. هر ورودی توسط سه تابع عضویت<sup>۱</sup> مثلثی و هر خروجی توسط پنج تابع عضویت گوسی تعریف شده‌اند. ۱۸ قانون فازی در جدول ۱ داده شده است، سه ردیف اول برای وزن حد بالای بودجه عدم قطعیت و سه ردیف آخر برای وزن حد پایین بودجه عدم قطعیت باس است.

خطر حد بالا عدم قطعیت توان باس در هر لحظه اختلاف بین حد بالای عدم قطعیت توان و حداکثر حد بحرانی عدم قطعیت توان است (رابطه‌ی (۲)). از طرفی حدهای بحرانی عدم قطعیت توان یک تابع هم در ولتاژ باس در حالت قطعی  $v_{bk}(0)$  و هم در حساسیت ولتاژ باس است (رابطه‌ی (۳)).

$$\begin{aligned} R_{UULbk} &= \frac{p_{bk}}{\partial p_{bk}} R_{ULLbk} \\ &= p_{bk} - \frac{\partial p_{bk}}{\partial p_{bk}} \end{aligned} \quad (2)$$

$$\begin{aligned} \frac{\partial p_{bk}}{\partial p_{bk}} &= \frac{\bar{v} - v_{bk}(0)}{\Lambda_{bp} + \Lambda_{bq}\lambda_l} \frac{\partial p_{bk}}{\partial p_{bk}} \\ &= \frac{v - v_{bk}(0)}{\Lambda_{bp} + \Lambda_{bq}\lambda_l} \end{aligned} \quad (3)$$

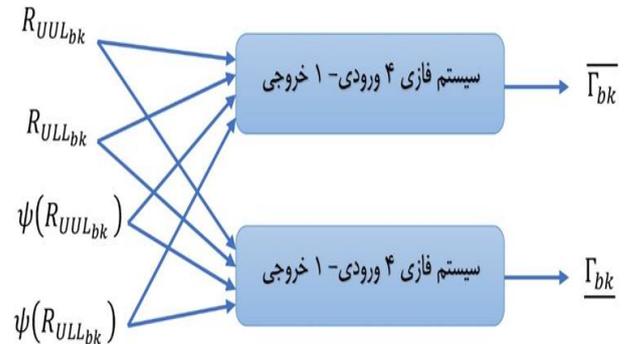
جدول ۱: قوانین کنترل کننده‌ی فازی

$R_{UULbk}$ / $\psi(R_{UULbk})$	Positive	Zero	Negative
Low probability	V-Low	Low	Medium
Medium probability	Low	Medium	High
High probability	Medium	High	V-High

در این مرحله، دامنه‌ی عدم قطعیت توان باس‌ها یعنی  $D$  استفاده از یک متخصص فازی به دامنه‌ی  $D_f$  که نتایج محافظه کارانه‌ی کمتری دارد، اصلاح می‌شود:

$$\begin{aligned} D &= \left\{ (\tilde{p}_{1k}, \tilde{p}_{n_{bk}}) \mid \tilde{p}_{bk} \in [p_{bk}, \bar{p}_{bk}] \right. \\ &\quad \left. \forall b \in [1, n_b] \right\} \quad (1) \\ D_f &= \left\{ (\tilde{p}_{1k}, \tilde{p}_{n_{bk}}) \mid \tilde{p}_{bk} \in [\underline{\Gamma}_{bk} p_{bk}, \overline{\Gamma}_{bk} \bar{p}_{bk}] \right. \\ &\quad \left. \forall b \in [1, n_b] \right\} \end{aligned}$$

الگوریتم انفیس مورد استفاده در این مرحله، ۴ ورودی و ۲ خروجی دارد و پایگاه قواعد فازی شامل ۱۸ قانون است. سیستم‌های فازی نگاشت‌هایی به صورت چند ورودی و یک خروجی از یک بردار با مقادیر حقیقی به یک اسکالر با مقدار حقیقی هستند. بنابراین، هر سیستم چند ورودی-چند خروجی را می‌توان به مجموعه‌ای از سیستم‌های یک خروجی تفکیک نمود. برای طراحی سیستم ۴ ورودی-۲ خروجی فازی در این مقاله، در ابتدا دو سیستم ۴ ورودی-۱ خروجی به طور مجزا طراحی شده و سپس مطابق شکل ۲ با هم ترکیب می‌شوند.



شکل ۲: ساختار الگوریتم انفیس

با توجه به شکل ۲،  $R_{UULbk}$  و  $R_{ULLbk}$  به ترتیب خطر حد بالای عدم قطعیت و خطر حد پایین عدم قطعیت توان باس  $b$  در لحظه  $k$  است. ورودی‌های  $\psi(R_{UULbk})$  و  $\psi(R_{ULLbk})$  نیز احتمال‌های خطر هستند. خروجی‌های  $\Gamma_{bk}$  و  $\bar{\Gamma}_{bk}$  حدهای

<sup>1</sup> Membership function

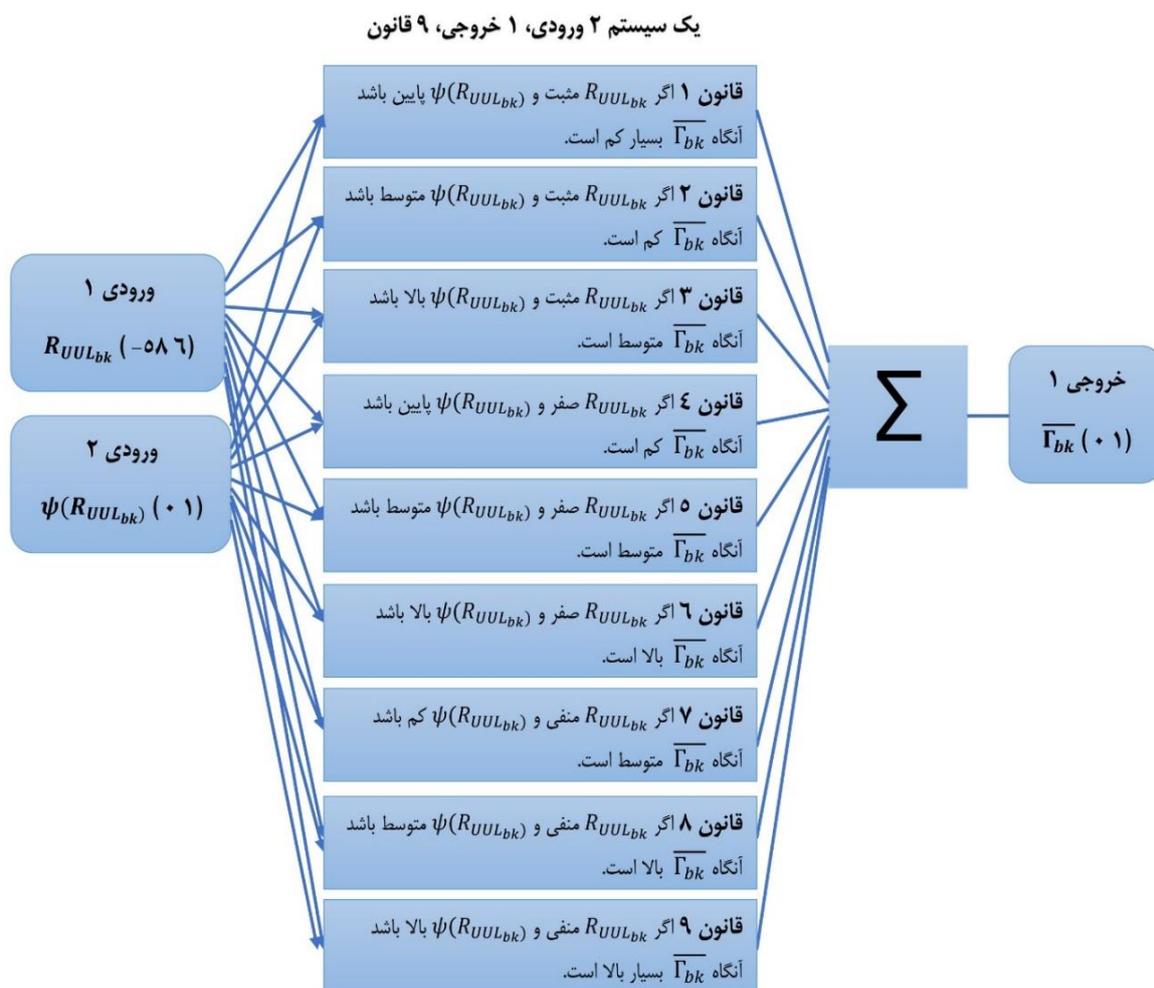
برای محاسبه‌ی احتمال خطر نیز نیاز به یک تابع توزیع تجمعی است. با توجه به اینکه عملگر شبکه توزیع مجبور به دانستن تابع توزیع تجمعی دقیق نیست، در این مقاله از تابع توزیع تجمعی با میانگین ۰.۵ و انحراف معیار ۱ استفاده می‌شود. برای محاسبه‌ی خطر حد پایین عدم قطعیت توان و احتمال آن نیز به همین روش عمل می‌شود. نتایج به دست آمده نشان می‌دهد که دامنه‌ی خطر حد بالا عدم قطعیت [۶-۵۸]، خطر حد پایین عدم قطعیت [۳-۲۲] و احتمال‌های هر دو خطر [۱۰] هستند.

در ادامه به منظور تولید وزن حد بالای بودجه‌ی عدم قطعیت، بخش اول کنترل فازی شکل ۲ پیاده‌سازی می‌گردد. ورودی‌ها خطر حد بالای عدم قطعیت توان باس در هر لحظه و احتمال خطر آن می‌باشند. خروجی نیز کمیت مورد جستجو است یعنی وزن حد بالای بودجه عدم قطعیت باس در هر لحظه. سه ردیف اول جدول ۱ قواعد موجود در پایگاه قواعد فازی را تشکیل می‌دهند. مطابق شکل ۳ هر ورودی به وسیله‌ی سه تابع تعلق مثلثی بر روی دامنه به ترتیب [۶-۵۸] و [۱۰] تعریف شده‌اند. خروجی نیز به وسیله‌ی پنج تابع تعلق گوسی در بازه‌ی [۱۰] توصیف شده است. در این پردازش از موتور استنتاج مینیمم همراه با استنتاج مبتنی بر قواعد جداگانه با ترکیب اجتماع، استلزام مینیمم مدانی، عملگر min برای t-نرم‌ها و max برای s-نرم‌ها استفاده شده است. غیر فازی‌ساز نیز از نوع میانگین مراکز است. اهمیت تمامی قواعد به یک صورت است و برای همگی بصورت پیش‌فرض ۱ در نظر گرفته شده است. توابع عضویت ورودی‌ها و خروجی در شکل ۴ نشان داده شده است.

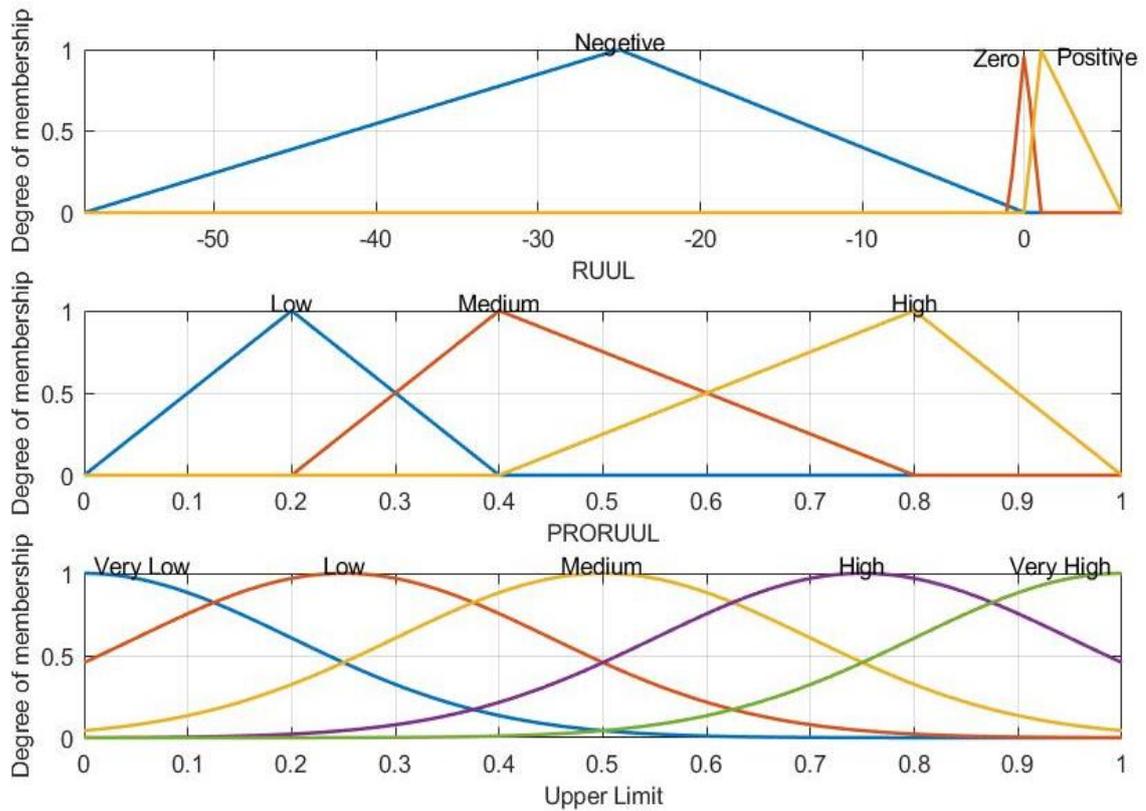
$R_{ULLbk}$	Negative	Zero	Positive
$\psi(R_{ULLbk})$			
Low probability	V-Low	Low	Medium
Medium probability	Low	Medium	High
High probability	Medium	High	V-High

با توجه به اینکه باتری‌ها در زمان‌های مشخصی وارد شبکه می‌شوند، حداکثر و حداقل تغییرات توان باس آن‌ها در حالت شارژ و تخلیه رخ می‌دهد که متناظر با ظرفیت باتری‌ها می‌باشد. این مقدار برای باتری ۱ و ۲ به ترتیب ۱ و ۲ مگاوات است. در محاسبه‌ی حدهای بحرانی عدم قطعیت توان حداقل و حداکثر ولتاژ مجاز شبکه در واحد پریونیت به ترتیب ۰.۹ و ۱.۱ است. ولتاژ باس در حالت قطعی،  $v_{bk}(0)$  بدون در نظر گرفتن عدم قطعیت منابع انرژی تجدیدپذیر و بار به دست می‌آید. این مقدار برای باس ۱۶ و ۲۸ به ترتیب ۰.۷۶۹۲ و ۰.۸۴۹۰ است. حساسیت ولتاژ باس به توان اکتیو، از اختلاف ولتاژ باس بر اختلاف توان اکتیو در دو لحظه  $k$  و  $k-1$  قابل محاسبه می‌باشد در حالی که حساسیت ولتاژ باس به توان راکتیو، اختلاف ولتاژ باس بر اختلاف توان راکتیو است. از رابطه ۷،  $\lambda_l$  برای مصرف‌کنندگان با ضریب قدرت ۰.۹، مقدار ۰.۴۸ محاسبه می‌شود.

$$\lambda_l = \tan(\cos^{-1} \text{ power factor})$$



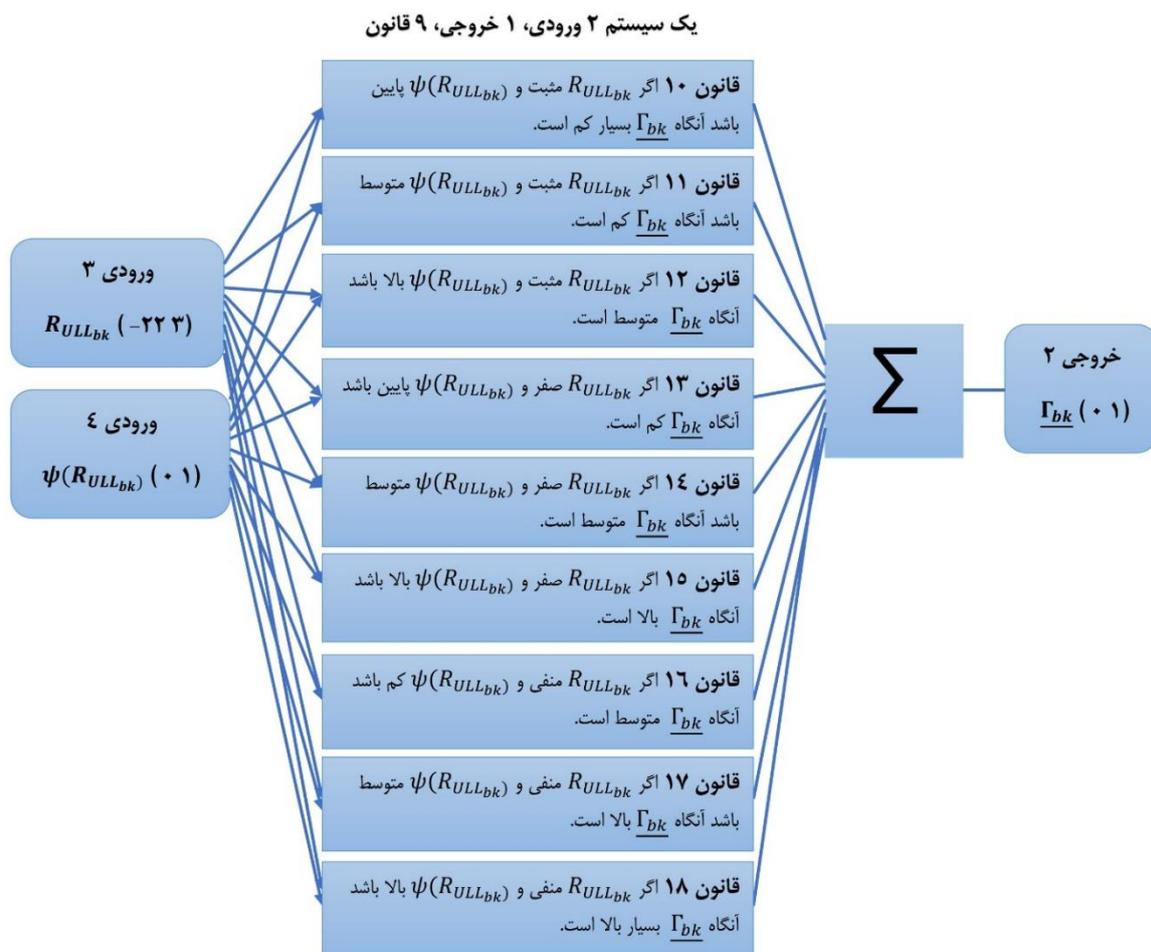
شکل ۳: ساختار اصلی سیستم فازی اول برای تولید  $\overline{\Gamma_{bk}}$



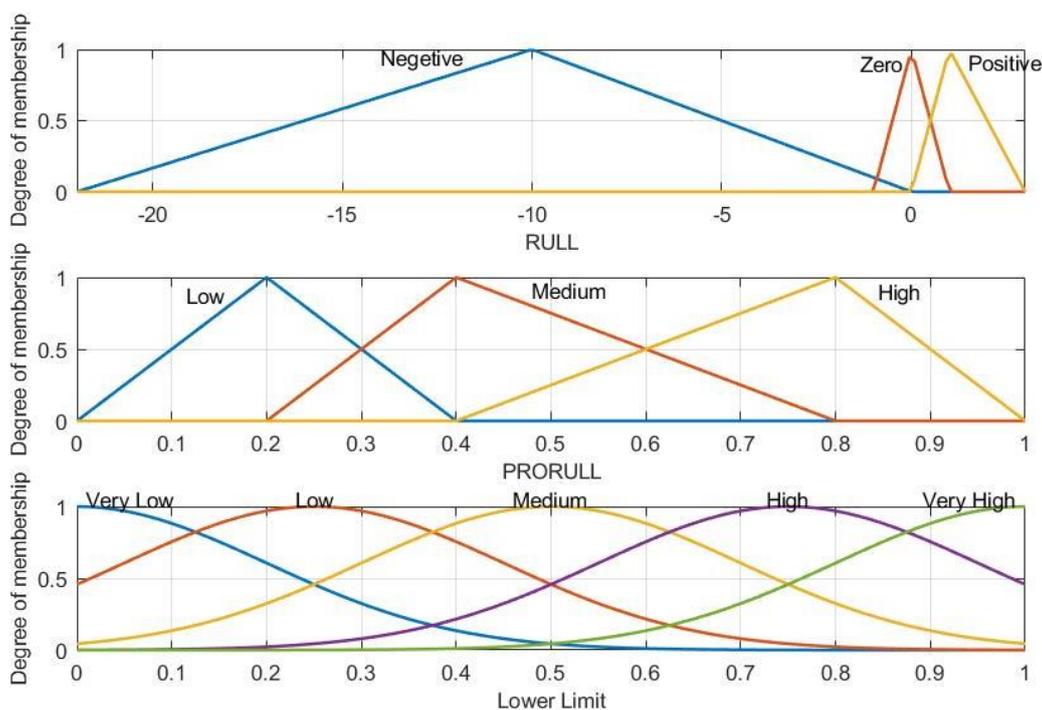
شکل ۴: توابع عضویت ورودی‌ها و خروجی در سیستم اول

تعریف شده‌اند. خروجی نیز به وسیله‌ی پنج تابع عضویت گوسی در بازه [۰ ۱] توصیف شده است. در این پردازش از موتور استنتاج مینیمم همراه با استنتاج مبتنی بر قواعد جداگانه با ترکیب اجتماع، استلزام مینیمم ممدانی، عملگر  $\min$  برای  $t$ -نرم‌ها و  $\max$  برای  $s$ -نرم‌ها استفاده شده است. غیر فازی‌ساز نیز از نوع میانگین مراکز است. اهمیت تمامی قواعد به یک صورت است و برای همگی به صورت پیش‌فرض ۱ در نظر گرفته شده است. توابع تعلق ورودی‌ها و خروجی در شکل ۶ نشان داده شده است.

مشابه تولید حد بالای بودجه، وزن حد پایین بودجه عدم قطعیت نیز محاسبه می‌شود. برای این منظور بخش دوم کنترل‌کننده‌ی فازی شکل ۲ پیاده‌سازی می‌شود. ورودی‌ها خطر حد پایین عدم قطعیت توان باس در هر لحظه و احتمال خطر آن می‌باشند. خروجی نیز کمیت مورد جستجو است یعنی وزن حد پایین بودجه عدم قطعیت باس در هر لحظه. سه ردیف آخر جدول ۱ قواعد موجود در پایگاه قواعد فازی را تشکیل می‌دهند. مطابق شکل ۵، هر ورودی به وسیله‌ی سه تابع عضویت مثلثی بر روی دامنه به ترتیب [۳ -۲۲] و [۱ ۰]



شکل ۵: ساختار اصلی سیستم فازی دوم برای تولید  $\Gamma_{bk}$



شکل ۶: توابع تعلق ورودی‌ها و خروجی در سیستم دوم

## ۲-۲-۲ گام B: استخراج ویژگی

در این مرحله با استفاده از الگوریتم انفیس طراحی شده، استخراج ویژگی توان در دامنه‌ی  $D_f$  که در مرحله‌ی قبل به وسیله‌ی کنترل‌کننده‌ی فازی تعیین شد، به دست می‌آید. برای این منظور، بهینه‌ساز تابع جریمه‌ی زیر را که مجموع انحراف ولتاژ در تمامی باس‌هاست، حداکثر می‌کند.

$$\begin{aligned} \max(fV_k) \forall k \\ fV_k \\ = \sum_{b=1}^{n_b} \frac{1}{1 + e^{-\alpha(\underline{v} - v_{bk})}} \\ + \frac{1}{1 + e^{\alpha(\bar{v} - v_{bk})}} \\ + \beta(v_{bk} - v_r)^2 \end{aligned} \quad (5)$$

با توجه به اینکه انتخاب تابع در چنین شکلی یک جریمه‌ی کم برای انحراف ولتاژ در ناحیه‌ی ولتاژ مجاز اما جریمه‌ی بسیار بالاتر برای کار در خارج از این ناحیه اختصاص می‌دهد، بنابراین  $\alpha$  یک عدد کوچک و  $\beta$  یک عدد بسیار بزرگ در نظر گرفته می‌شوند. این مقادیر به ترتیب ۱۰ و  $10^6$  هستند. ولتاژ نامی شبکه یعنی  $v_r$ ، ۱ و  $v_{bk}$  نیز تنها متغیر تصمیم‌گیری مسأله می‌باشد. لازم به ذکر است طبق رابطه‌ی (۶)، بدترین حالت عدم قطعیت برابر با بهترین موقعیت سراسری است.

$$WCU_k = Gbest_k \quad (6)$$

در این مقاله، از یک جمعیت ۱۰ ازدحامی استفاده شده است و شرط توقف حداکثر تعداد تکرار ۲۰۰ می‌باشد. دامنه‌ی جستجو حاصل ضرب حدهای بودجه‌ی عدم قطعیت در تغییرات توان باس باتری‌هاست که متناسب با ظرفیت آن‌ها در حالت شارژ و تخلیه می‌باشد. از آنجاکه در طول فرآیند بهینه‌سازی، تابع جریمه حداقل می‌شود، بنابراین با حداقل کردن قرینه‌ی تابع جریمه می‌توان به هدف، که حداکثر نمودن آن است، دست یافت.

## ۲-۳ مرحله C: طبقه‌بندی

پس از استخراج ویژگی، یک آزمایش جریان برق با مشارکت کامل توان تخلیه‌ی ذخیره‌سازهای انرژی در بدترین حالت عدم قطعیت به منظور طبقه‌بندی اختلالات توان انجام شده است. اگر هر یک از محدودیت‌های ولتاژ و یا جریان

سیستم قدرت مطابق رابطه‌ی (۷) نقض شده باشد، آنگاه بدترین حالت عدم قطعیت به صورت  $\bar{p}_{bk} = WCU_k$  تنظیم می‌شود.

$$\forall b \in \mathcal{N}_b, t \in \mathcal{N}_t, k \in \mathcal{N}_k \begin{cases} \ell_{tk} \leq \bar{\ell}_t \\ \underline{v} \leq v_{bk} \leq \bar{v} \end{cases} \quad (7)$$

در این حالت ناحیه اختلال توان هر یک از ذخیره‌سازها از رابطه‌ی زیر محاسبه خواهد شد:

$$ROZS_s = \frac{\int_{k=0}^{n_k} (\bar{p}_{sk} - \underline{p}_{sk}) dk}{\int_{k=0}^{n_k} 2S_s dk} \quad \forall s \in \mathcal{N}_s \quad (8)$$

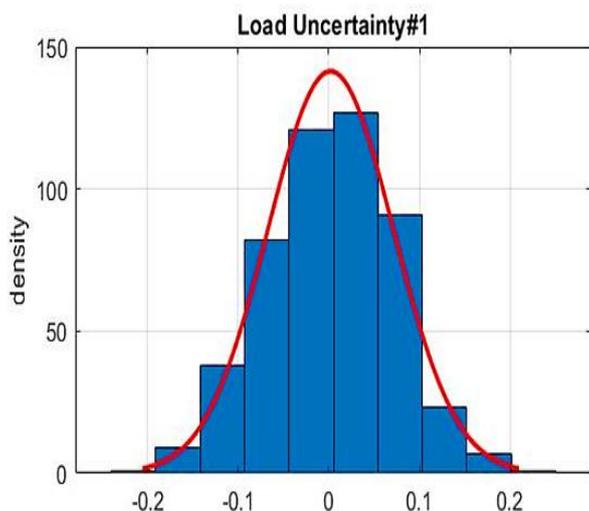
به همین ترتیب، یک آزمایش جریان برق با مشارکت کامل توان شارژ ذخیره‌سازهای انرژی در بدترین حالت عدم قطعیت انجام می‌شود و در صورت نقض محدودیت‌ها، حداکثر توان شارژ نیز، از حل رابطه‌ی (۸) به دست می‌آید. اما اگر محدودیت‌های شبکه‌ی قدرت نقض نشوند، ذخیره‌سازهای انرژی (باتری‌ها) می‌توانند به طور کامل تخلیه و یا شارژ شوند یعنی:

$$\overline{ROZ}_s = S_s \quad \text{و} \quad \underline{ROZ}_s = -S_s \quad (9)$$

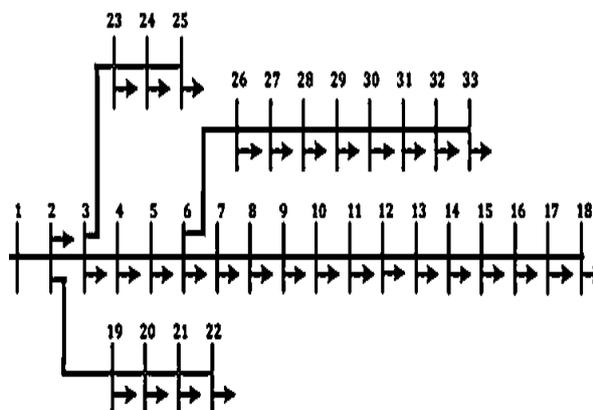
## ۳- معرفی مطالعه موردی و پارامترهای

### ورودی به مدل

سیستم مورد بررسی در شکل ۷، یک شبکه‌ی توزیع قدرت ۳۳ باسه دارای استاندارد IEEE می‌باشد. این شبکه قسمتی از سیستم فوق توزیع شهر نیویورک آمریکاست و ظرفیت آن ۱۰۰MVA و ۱۲.۶۶kV می‌باشد. بار روی شبکه از نوع مسکونی بوده و دارای متوسط ۵kw برای هر واحد می‌باشد. شبکه‌ی قدرت ۵ عدد منبع انرژی تجدیدپذیر (۳ توربین بادی و ۲ صفحه فتوولتاییک) با نفوذ ۳۰٪ دارد. ۲ ذخیره‌ساز الکتریکی (باتری ۱ و ۲) موجود با هدف فراهم کردن پشتیبانی کافی توان راکتیو دارای نفوذ ۱۵٪ هستند. یک توربین بادی با ظرفیت ۱.۵ و دو توربین دیگر با ظرفیت ۱ مگاوات به ترتیب بر روی باس‌های ۱۷، ۲۹ و ۳۱ واقع شده‌اند. هر دو صفحه فتوولتاییک به ظرفیت ۱ مگاوات بر روی باس‌های ۱۸ و ۳۰ قرار دارند. به علاوه، باتری ۱ با ظرفیت ۱ مگاوات و باتری ۲ با ظرفیت ۲ مگاوات به ترتیب بر روی باس‌های ۱۶ و ۲۸ واقع‌اند. به منظور حداقل کردن تلفات توان، موقعیت منابع انرژی



شکل ۸: توزیع نرمال عدم قطعیت بار در شبکه‌ی قدرت



شکل ۷: دیاگرام خطی شبکه توزیع قدرت ۳۳ باسه

(Abdeltawab &amp; Mohamed, 2017)

### ۲-۲- مدل احتمالی توان تولیدی توربین‌های بادی

در یک توربین بادی توان خروجی متأثر از سرعت باد بوده و یک رابطه‌ی غیرخطی بین این دو پارامتر وجود دارد. سرعت باد به طور پیوسته در حال تغییر است. میزان توان متوسط مشخص شده برای یک منطقه‌ی خاص صرفاً نمی‌تواند میزان تولید توربین بادی نصب شده در آن منطقه را مشخص کند. برای مشخص کردن فراوانی سرعت باد در یک منطقه در چنین حالتی می‌توان از توابع توزیع احتمالی بهره گرفت. در این مقاله، از تابع توزیع نرمال در مدل‌سازی سرعت باد استفاده شده است. منحنی مشخصه‌ی توان-سرعت توربین‌های بادی توسط رابطه‌ی زیر قابل بیان است:

$$P_{WT}(v) = \begin{cases} 0 & 0 \leq v \leq v_{ci} \text{ or } v \geq v_{co} \\ P_{WT,r} \times \frac{v^2 - v_{ci}^2}{v_r^2 - v_{ci}^2} & v_{ci} \leq v \leq v_r \\ P_{WT,r} & v_r \leq v \leq v_{co} \end{cases} \quad (10)$$

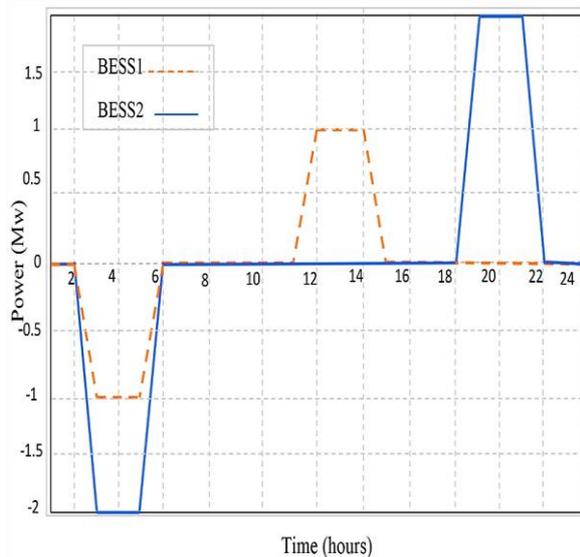
$v_{ci}$ ،  $v_r$  و  $v_{co}$  به ترتیب سرعت وصل، سرعت نامی و سرعت قطع توربین بادی می‌باشد.  $P_{WT,r}$  توان نامی توربین بادی است.

### ۳-۳- مدل احتمالی توان تولیدی سلول‌های خورشیدی

دو عامل مهمی که باعث ایجاد تغییرات و رفتار احتمالی در تولید توان سلول‌های خورشیدی هستند، میزان تابش اشعه‌ی خورشید و دمای محیط می‌باشند. برای تولید تابع توزیع

### ۳-۱- مدل احتمالی بار مصرفی

بار تا حد زیادی به فعالیت‌های بشری و فاکتور زمانی بستگی دارد. تغییرات بار به صورت پیوسته می‌باشد و این تغییرات با عدم قطعیت همراه است. در تئوری احتمالات، بار غیرقطعی می‌تواند توسط تابع چگالی احتمال که مناسب رفتار بار در هر لحظه می‌باشد، تنظیم شود. به عبارتی در پخش بار قطعی، بارهای مصرفی به صورت ثابت و بدون هیچ تغییری در نظر گرفته می‌شوند. در حالی که در عمل و واقعیت، بارها در هر لحظه از زمان در حال تغییرند و برای مدل کردن این تغییرات از تابع توزیع احتمال به جای عدد ثابت بهره گرفته می‌شود. در این مقاله، برای مدل‌سازی بار مصرفی از تابع توزیع نرمال و با در نظر گرفتن ۵۰۰ نمونه در هر باس استفاده می‌شود (شکل ۸).



شکل ۹: مشخصات توان مطلوب باتری‌ها بدون ناحیه‌ی اختلال توان

با توجه به شکل ۹، دستیابی به حداکثر میزان شارژ و تخلیه‌ی باتری‌ها در یک فرآیند سه مرحله‌ای انجام می‌شود. در مرحله‌ی اول، دامنه‌ی عدم قطعیت توان باس‌ها تعدیل می‌شود. بنابراین، نتایج محافظه‌کاری کمتری دارند. این کار از طریق الگوریتم یادگیری عمیق میسر است. سپس در مرحله‌ی دوم، با تعریف توابع فعال‌ساز فازی در ساختار الگوریتم یادگیری عمیق، بدترین حالت عدم قطعیت توان بر روی دامنه‌های اصلاح‌شده تعیین می‌شود. در نهایت در مرحله‌ی سوم، بدترین حالت عدم قطعیت توان با مشارکت کامل توان شارژ و تخلیه‌ی باتری‌ها آزمایش می‌شود. اگر نقض ولتاژ رخ ندهد، باتری‌ها می‌توانند حداکثر به میزان توان ظاهری خود (یعنی  $S_c$ ) شارژ و یا تخلیه شوند، در غیر این صورت، این مقدار برابر ناحیه‌ی اختلال توان هر باتری (یعنی  $ROZ_s$ ) خواهد بود.

مقادیر نواحی اختلال توان برای هر دو ذخیره‌ساز الکتریکی در ضرایب نفوذ مختلف منابع انرژی تجدیدپذیر و همچنین حداکثر افت ولتاژ شبکه توزیع قدرت در جدول ۲ آمده است. بررسی داده‌ها نشان می‌دهد با افزایش ضریب نفوذ منابع تجدیدپذیر، نواحی اختلال توان کاهش می‌یابد. در واقع برای یک نفوذ بالاتر منابع انرژی تجدیدپذیر، پشتیبانی توان راکتیو بالاتر از ذخیره‌سازهای انرژی مورد نیاز است. در نتیجه، حدهای توان اکتیو کاهش می‌یابد. در حالت کارکرد دائم شبکه یعنی ضریب نفوذ ۳۰٪، حداکثر افت ولتاژ بر روی برخی باس‌های شبکه از ۱۳٪ تجاوز نمی‌کند. با توجه به اینکه حداکثر افت ولتاژ مجاز شبکه ۱۰٪ است نتایج به دست آمده می‌تواند تقریب مناسبی از شبکه واقعی باشد

احتمالی این پارامترها از تابع توزیع نرمال استفاده می‌شود. از رابطه‌ی زیر برای به دست آوردن میزان تولید توان خورشیدی در فرم تابع توزیع احتمال استفاده می‌شود:

$$P_{PV} = P_{STC} \times \frac{G_{ING}}{G_{STC}} \times (1 + k_{\alpha}(T_c - T_r)) \quad (11)$$

میزان تابش خورشید و دمای محیط در شرایط استاندارد به ترتیب  $G_{STC} = 1000 \text{ W/m}^2$  و  $T_r = 25^\circ\text{C}$  در نظر گرفته می‌شود.  $G_{ING}$  میزان تابش نور خورشید،  $T_c$  دمای پیرامون سلول و  $k_{\alpha}$  ضریب دما به ازای توان حداکثر می‌باشد.

### ۳-۴- پیاده‌سازی شبکه‌ی توزیع قدرت ۳۳ باسه

در این بخش، شبکه‌ی توزیع ۳۳ باسه‌ی استاندارد پیاده‌سازی می‌شود. منابع انرژی تجدیدپذیر و بارها با مدل‌های ارائه شده، به شبکه اعمال می‌شوند. برای مدل‌سازی عدم قطعیت توان تولیدی منابع تجدیدپذیر و بار، از مجموع متوسط توان و تغییرات آن استفاده شده است. این تغییرات به صورت تصادفی در بازه‌ی  $[-1, 1]$  ساخته می‌شود. شبکه در ضریب نفوذ ۳۰٪ منابع انرژی تجدیدپذیر و ۱۵٪ ذخیره‌سازهای الکتریکی کار می‌کند، اگرچه بررسی نتایج در ضریب نفوذ ۲۰٪ و ۴۰٪ نیز تکرار می‌گردد. افت ولتاژ مجاز شبکه ۱۰٪ است. هر بار مصرفی به صورت یک ساختمان ۸ واحدی با مقدار متوسط مصرف ۵kw (برای هر واحد) در نظر گرفته شده است.

### ۴- شبیه‌سازی و تحلیل نتایج

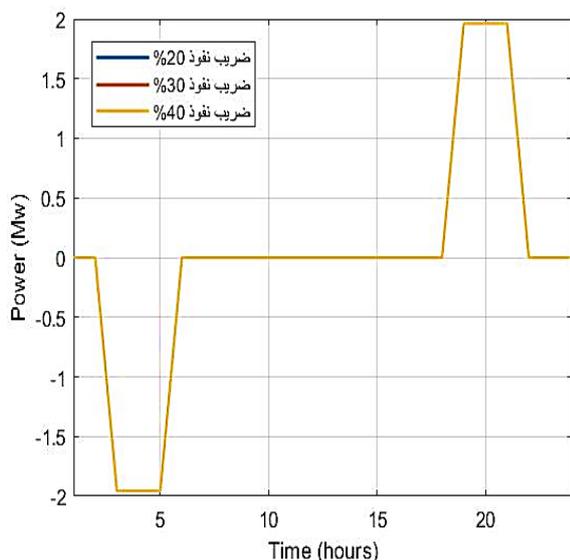
بررسی اطلاعات مصرف برق نشان می‌دهد که در شش ماه اول سال، اوج بار در ساعات ۱۶-۱۲ و ۱۹-۲۳، میان باری در ساعات ۱۹-۷ و کم باری در ساعات ۷-۲۳ است. این در حالی است که در شش ماه دوم سال اوج بار در ساعات ۱۱-۱۵ و ۱۸-۲۲، میان باری در ساعات ۱۸-۶ و کم باری در ساعات ۶-۲۲ می‌باشد. در این مقاله با توجه به ساعات اوج مصرف، ذخیره‌سازهایی با مشخصات نشان داده شده در شکل ۹ در نظر گرفته شده است.

باتری به معنای سود بیشتر و ذخیره‌ی توان بیشتر برای ساعات اوج مصرف خواهد بود. به طور مشابه نواحی اختلال توان باتری ۲ برای سه ضریب نفوذ منابع انرژی تجدیدپذیر در شکل ۱۱ نمایش داده شده است.

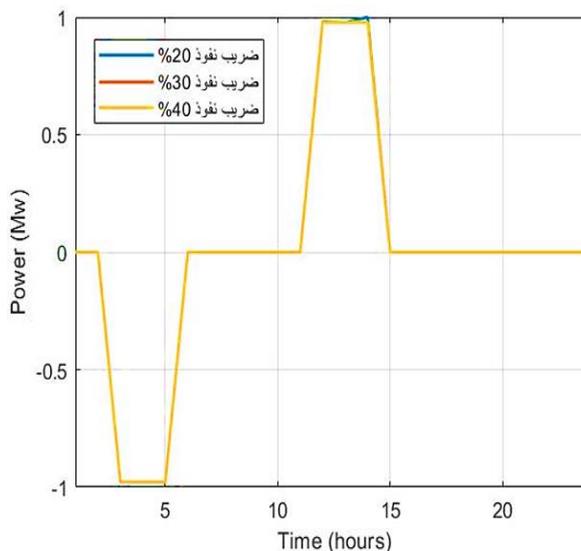
نواحی اختلال توان باتری ۱ برای سه ضریب نفوذ منابع انرژی تجدیدپذیر در شکل ۱۰ نمایش داده شده است. بررسی مشخصه‌ی به دست آمده نشان می‌دهد باتری با تقریب خوبی مقدار مطلوب را دنبال می‌کند و این همان چیزی است که صاحبان ذخیره‌سازها به دنبال آن هستند. چرا که ظرفیت بالاتر

جدول ۲: اندازه‌ی نواحی اختلال توان برای باتری‌های ۱ و ۲ و افت ولتاژ شبکه

ضریب نفوذ منابع تجدیدپذیر	%20			%30			%40		
	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان
	%98.2	%98.1	%11	%97.8	%98.1	%13	%97.8	%98.1	%14



شکل ۱۱: تغییرات مشخصه‌ی توان باتری ۲ در سه ضریب نفوذ ۲۰، ۳۰ و ۴۰ درصد منابع انرژی تجدیدپذیر



شکل ۱۰: تغییرات مشخصه‌ی توان باتری ۱ در سه ضریب نفوذ ۲۰، ۳۰ و ۴۰ درصد منابع انرژی تجدیدپذیر

به منظور اعتبارسنجی نتایج به دست آمده، آزمایش انجام گرفته بر روی دو گروه از منابع انرژی تجدیدپذیر تکرار شده است. گروه اول شامل دو توربین بادی ۱.۵ مگاوات و یک توربین بادی ۱ مگاوات، دو صفحه‌ی فتوولتایک به ظرفیت ۰.۵ مگاوات و دو ذخیره‌ساز الکتریکی ۱ و ۲ مگاوات می‌باشد. گروه دوم نیز شامل یک توربین بادی ۱.۵ مگاوات و دو توربین بادی ۱ مگاوات، دو صفحه‌ی فتوولتایک هر کدام به ظرفیت ۰.۵ مگاوات و دو ذخیره‌ساز الکتریکی ۱ و ۲ مگاوات می‌باشد. دسته‌بندی منابع انرژی تجدیدپذیر و باتری‌ها برای هر گروه در جدول ۳ داده شده است. پس از پیاده‌سازی هر گروه در شبکه‌ی توزیع قدرت، نواحی اختلال توان و هم‌چنین حداکثر افت ولتاژ شبکه محاسبه شد و نتایج برای سه ضریب نفوذ

مختلف منابع انرژی تجدیدپذیر تکرار گردید که مطابق جدول ۴ گزارش می‌شود. از تجزیه و تحلیل نتایج به دست آمده واضح است که تزریق توان اکتیو اضافه‌شده به شبکه سبب افت ولتاژ بر روی باس‌ها می‌شود. برای گروه اول و دوم در ضریب نفوذ ۲۰٪، برای ساعاتی ناحیه‌ی اختلال توان باتری ۱، ۱۰۰٪ است؛ بدین معنا که باتری می‌تواند به اندازه‌ی ظرفیت نامی خود یعنی  $S_k$  شارژ و یا تخلیه شود.

جدول ۳: دسته‌بندی منابع انرژی تجدیدپذیر و باتری‌ها برای

گروه اول و دوم

گروه اول	$p_{pv1} = 0.5MW$ $p_{pv2} = 0.5MW$ $p_{WT1} = 1.5MW$ $p_{WT2} = 1.5MW$ $p_{WT3} = 1MW$ $p_{BESS1} = 1MW$ $p_{BESS2} = 2MW$
گروه دوم	$p_{pv1} = 0.5MW$ $p_{pv2} = 0.5MW$ $p_{WT1} = 1.5MW$ $p_{WT2} = 1MW$ $p_{WT3} = 1MW$ $p_{BESS1} = 1MW$ $p_{BESS2} = 2MW$

جدول ۴: اندازه‌ی نواحی اختلال توان و افت ولتاژ شبکه برای گروه اول و دوم

ضریب نفوذ منابع تجدیدپذیر	%20			%30			%40		
	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان	$ROZ_{s1}$	$ROZ_{s2}$	اختلال توان
گروه اول	%100	%98.2	%10	%97.8	%97.9	%12	%97.8	%97.8	%13
گروه دوم	%100	%98.2	%10	%98.1	%98.1	%12	%97.9	%98.1	%13

خطاهای سیگنال خط به زمین (SLG) روی باس یا در پایان خط انتقال رخ می‌دهند و رویدادهای افت لحظه‌ای ولتاژ را ایجاد می‌کنند. در سیستم شبیه‌سازی، کمبود ولتاژ از طریق شارژ باتری ذخیره‌سازی و روشن کردن بار خطی در همان زمان ایجاد شده است.

#### (۳) برآمدگی ولتاژ<sup>۳</sup>

برآمدگی ولتاژ افزایش ۱۰ تا ۹۰ درصدی ولتاژ شبکه قدرت را در طول یک دوره زمانی توصیف می‌کند. خطاهای خط به خط (LL) یا قطع بار سنگین در یک زمان کوتاه باعث برآمدگی ولتاژ می‌شود. در سیستم شبیه‌سازی، نمونه‌های برآمدگی ولتاژ با اضافه کردن خطاهای کوچک در نقطه اتصال مشترک و خاموش کردن بیشتر بارهای ریز شبکه تولید می‌شوند.

#### (۴) پالس ولتاژ، گذرای تکانشی و نوسانی<sup>۴</sup>

دلیل اصلی که باعث پالس‌ها و تکانش‌گری در سیستم قدرت می‌شود، تغییر یک بانک خازن بزرگ در سیستم توزیع

خطاهای خط و برخی رویدادهای عملیاتی ویژه باعث بروز اختلال کیفیت توان در سیستم‌های قدرت می‌شوند که مشابه سیستم قدرت سنتی نیست. در ادامه، اختلالات بررسی شده در این مقاله و نحوه شبیه‌سازی آن‌ها معرفی شده است.

#### (۱) قطع ولتاژ<sup>۱</sup>

قطع ولتاژ یک افت ۹۰ تا ۱۰۰ درصدی ولتاژ شبکه قدرت را در طول یک دوره زمانی توصیف می‌کند. خطاهای خط به زمین (LLG) و خطاهای سه‌فاز (LLL) یک وقفه ولتاژ آشکار ایجاد می‌کنند. علاوه بر این، برای یک شبکه قدرت فعال، قطع برق یک DG با بار سنگین نیز باعث قطع ولتاژ خواهد شد. بنابراین، در این مقاله چندین ترکیب از خروجی‌های شبکه تنظیم شده است، سپس خطاهای LLG و LLL در نقطه اتصال مشترک در سیستم شبیه‌سازی اضافه شده است.

#### (۲) افت لحظه‌ای ولتاژ<sup>۲</sup>

افت لحظه‌ای ولتاژ یک افت ۱۰ تا ۹۰ درصدی از ولتاژ شبکه قدرت را در طول یک دوره زمانی توصیف می‌کند.

<sup>3</sup> Voltage swell

<sup>4</sup> Voltage spike, impulsive and oscillatory transient

<sup>1</sup> Voltage interruption

<sup>2</sup> Voltage sag

تفکر سیستمی و جنگل تصادفی (RF) (Huang et al., 2016)، تبدیل فوریه سریع (FFT) و شبکه‌های عصبی مصنوعی (Borges, Fernandes, Silva, & Silva, 2015). همان‌طور که در جدول ۶ نشان داده شده است، برای اختلالات کیفیت توان برای ضرایب نفوذ مختلف منابع تجدیدپذیر شامل ۰٪، ۲۰٪، ۳۰٪ و ۴۰٪ دقت طبقه‌بندی مربوط به الگوریتم پیشنهادی بالاتر از همه الگوریتم‌های دیگر است. به خصوص تحت شرایط ضریب نفوذ ۴۰٪ استفاده از شبکه عصبی مصنوعی با توابع هوشمند فازی اضافه شده، افزایش قابل‌توجهی در مصونیت از اختلال در مقایسه با روش‌های مرسوم وجود دارد. علاوه بر این، ساختار حلقه بسته و انتخاب ویژگی خودکار توسط شبکه عصبی مصنوعی می‌تواند به طور مؤثری دقت شناسایی اختلالات کیفیت توان را بهبود بخشد چون می‌تواند مهم‌ترین ویژگی‌های اختلالات مختلف را با دقت استخراج کند. در مقایسه با روش‌های کلاسیک، روش ارائه‌شده در این مقاله، فرآیند تجزیه و تحلیل اختلالات کیفیت توان را یکپارچه‌تر و ساده‌تر می‌کند. بنابراین، روش پیشنهادی در این مقاله پتانسیل زیادی برای بهبود عملکرد تجهیزات پایش کیفیت توان خودکار با قابلیت طبقه‌بندی دارد.

در

است. در سیستم شبیه‌سازی، یک بانک خازن بزرگ در سیستم توزیع نزدیک به نقطه اتصال مشترک متصل می‌شود.

(۵) هارمونیک‌ها، نوسانات شدید و اختلالات شکاف<sup>۱</sup>

در سیستم شبیه‌سازی این اختلالات با اتصال مبدل‌های الکترونیک قدرت غیرخطی و شبیه‌سازی وقوع برخی از خطاهای خط ویژه ایجاد شده است.

اختلالات کیفیت توان ترکیبی را می‌توان از طریق کاربردهای همزمان خطاهای خط، بارهای کلیدزنی و تغییر حالت عملیات در شبکه قدرت شبیه‌سازی شده تولید کرد. در جدول ۵ جزئیات عملکرد سیستم شبکه عصبی مصنوعی مبتنی بر الگوریتم هوشمند فازی برای شبکه قدرت ۳۳ باسه نشان داده شده است. نتایج به دست آمده ثابت می‌کند که روش پیشنهادی برای تشخیص اختلالات کیفیت توان ناشی از خطاهای خطی، ژنراتورهای توزیع‌شده، بارهای غیرخطی و حالت عملیات مناسب است. با توجه به روش معرفی شده، دلیل اختلال را می‌توان به راحتی با توجه به نوع اختلال حدس زد و سپس اقدامات هدفمند را می‌توان برای حل آن انجام داد، به طوری که کیفیت توان شبکه قدرت حاوی انرژی پراکنده بهبود یابد.

در جدول ۶ دقت الگوریتم پیشنهادی با روش‌های کلاسیک برای ضرایب نفوذ مختلف منابع تجدیدپذیر مقایسه شده است. روش‌های کلاسیک انتخاب شده عبارتند از فیلتر کالمن (KF) و سیستم خبره فازی (FES) (Abdelsalam, Eldesouky, & Sallam, 2012)، تبدیل موجک (WT) و بهینه‌سازی ازدحام ذرات با ماشین یادگیری (PSOELM) (Manimala, Ahila, Sadasivam, & Manimala, 2015)، تبدیل بسته طول موج (WPT) و الگوریتم ژنتیک (GA) (Manimala, Selvi, & Ahila, 2012)، WT و شبکه عصبی فازی (FANN) (Decanini, Tonelli-Neto, Malange, & Minussi, 2011)، تبدیل موجک گسسته (DWT) و شبکه عصبی مصنوعی مبتنی بر شبکه عصبی مصنوعی (PNABC) (Singh & Singh, 2019)، تفکر سیستمی و PNN (H. Wang, Wang, & Liu, 2017).

<sup>1</sup> Harmonics, flicker and notches disturbances

شده است. در این مقاله با استفاده از ۱۰۰ داده آموزش و تست برای هر طبقه‌بند دقت ۹۹.۷ درصد با استفاده از ماشین بردار چند کلاسه به دست آمده است. همچنین، با اعمال طبقه‌بندهای k نزدیکترین همسایه و شبکه عصبی احتمالاتی روی کل داده‌ها به ترتیب دقت ۹۷.۵۵ و ۹۷.۴۴ به دست آمده است. همان‌طور که مشاهده می‌شود الگوریتم پیشنهادی در این مقاله نسبت به الگوریتم‌های پایه خود یعنی EMD و EEMD که به منظور استخراج ویژگی استفاده شده است، بهبود مناسبی داشته است. در مقایسه با سایر الگوریتم‌ها نظیر (Nie, 2019) و (Minh Khoa & Van Dai, 2020) از دقت بهتری برخوردار است با این تفاوت که امکان استفاده از فیلتر کالمن در کاربردهای برخط وجود دارد. با توجه به اینکه الگوریتم پیشنهادی به صورت وفقی روی داده‌ها قابل پیاده‌سازی است و تنها از پوش سیگنال و عملگر تفاضل به منظور تفکیک اجزاء متمایز فرکانسی سیگنال استفاده می‌کند، امید است تا بتوان پیاده‌سازی از آن ارائه کرد که به کاربرد آنلاین نزدیک شود.

**جدول ۷** الگوریتم پیشنهادی با چند روش دیگر که از دقت بالایی برخوردار هستند، مقایسه شده است. تعداد نمونه‌های تست استفاده شده در هر رویکرد قابل مشاهده است. در مرجع (Khokhar, Zin, Memon, & Mokhtar, 2017) از روش EEMD برای استخراج ویژگی استفاده شده است. طبقه‌بندهای مورد استفاده در این مقاله ماشین بردار پشتیبان، مدل‌های ترکیب گوسی، آدابوست و الگوریتم بگینگ است که در میان این الگوریتم‌ها آدابوست و بگینگ از دقت بالاتری برخوردار هستند. به همین دلیل در جدول ۷ تنها به این دو طبقه‌بندی اشاره شده است. در مرجع (Shukla et al., 2013) از روش مبتنی بر الگوریتم EMD به منظور شناسایی اختلالات استفاده شده است. دقت به دست آمده در این مقاله با ۴۵ داده تست در حدود ۹۸ درصد می‌باشد. در مرجع (Nie, 2019) با استفاده از فیلتر کالمن ۶ نوع اختلال مورد بررسی قرار گرفته است. دقت به دست آمده در این مقاله در حدود ۹۲.۸۳ درصد می‌باشد. در مرجع (Hajian & Foroud, 2014) ارزیابی الگوریتم به صورت کلی و با استفاده از دقت آموزش و تست با یکدیگر سنجیده

جدول ۵: عملکرد شبکه عصبی مبتنی بر الگوریتم فازی در طبقه‌بندی اختلالات کیفیت توان شبکه قدرت

نوع اختلال کیفیت توان	عملکرد شبکه عصبی مبتنی بر توابع هوشمند فازی								
	ضریب نفوذ منابع تجدیدپذیر	گروه اول				گروه دوم			
		0	%20	%30	%40	0	%20	%30	%40
Normal	100	100	98.60	97.70	100	99.90	96.70	92.10	
Swell	100	100	100	100	100	100	100	99.90	
Sag	99.70	99.70	99.70	99.20	99.70	99.50	99.50	99.00	
Impulsive Transient	100	99.80	97.20	76.20	98.20	98.00	89.60	64.40	
Interruption	100	100	99.80	99.70	100	100	99.90	99.70	
Flicker	100	100	100	100	100	100	100	99.90	
Flicker with swell	100	100	100	99.70	100	100	100	99.80	
Flicker with sag	100	100	99.90	99.50	100	100	100	99.80	
Flicker with harmonics	100	100	100	100	100	100	100	100	
Oscillatory transient	99.90	100	99.90	99.50	100	100	100	98.70	
Harmonics	100	100	100	100	100	100	100	100	
Swell with harmonics	100	100	100	100	100	100	100	100	
Sag with harmonics	100	100	100	99.80	99.60	99.90	99.50	98.90	
Interruption with harmonics	99.80	99.70	99.80	98.90	99.60	100	99.70	99.00	

Periodic notch	100	100	100	100	100	100	100	100
Spike	100	100	100	99.90	100	100	100	99.90
<b>AVE</b>	<b>99.96</b>	<b>99.95</b>	<b>99.66</b>	<b>98.13</b>	<b>99.84</b>	<b>99.83</b>	<b>99.06</b>	<b>96.94</b>

جدول ۶: مقایسه دقت الگوریتم پیشنهادی با روش‌های کلاسیک برای ضرایب نفوذ مختلف منابع تجدیدپذیر

	تعداد ویژگی‌های انتخاب شده	تعداد اختلالات کیفیت توان	ضریب نفوذ منابع تجدیدپذیر			
			0	%20	%30	%40
KF and FES [33]	-	7	-	98.71	97	92.3
WT and PSO-ELM [34]	6	10	97.6	-	-	-
WPT and GA [35]	15	8	98.33	-	-	-
WT and FANN [36]	-	8	99.66	-	-	-
DWT and PNN-ABC [37]	9	16	99.875	98.6	95.2	93.6
ST and PNN [38]	4	9	99.26	99.13	98.63	-
ST and RF [39]	4	15	99.7	99.9	99.7	95.9
FFT and ANNS [40]	-	8	-	93.95	95.65	-
<b>Proposed Method</b>	<b>AUTO</b>	<b>16</b>	<b>99.96</b>	<b>99.95</b>	<b>99.66</b>	<b>98.13</b>

جدول ۷: مقایسه دقت الگوریتم پیشنهادی با سایر الگوریتم‌های پیشرفته

Data/Classifier	Method					
	Proposed Method	[41]	[17]	[42]	[43]	[44]
N Of Samples	72 Train/48 Test	90 Train/25 Test	90 Train/45 Test	No Train/100 Test/6 Disturbances	Train & Test=100	60 Test
RUSBoost	98.44					
LPBoost	98.70					
TotalBoost	98.44					
AdaBoost	98.96					
Bagging	98.96					
Fuzzy Expert System			98			
Fuzzy Expert System				92.83		
Multiclass SVM					99.7	
PNN					97.44	
KNN					97.55	
HMM						95.83

فازی، دامنه‌ی عملکردی الگوریتم یادگیری عمیق بالاتر می‌رود. بدین ترتیب می‌توان امید داشت که دقت و سرعت این الگوریتم بهبود نسبی پیدا کند. برای ارزیابی الگوریتم از شبیه‌سازی شبکه توزیع قدرت ۳۳ باسه استفاده شده است. دقت ارزیابی به دست آمده با استفاده از الگوریتم پیشنهادی در مقایسه با کارهای مشابه، بهبود نسبی پیدا کرده است. الگوریتمی که به منظور تفکیک اجزای سیگنال در این مقاله ارائه شده است، در بررسی سیگنال‌های نویزی از مقاومت متوسطی برخوردار است. به دلیل اینکه نویز به عنوان اطلاعات فرکانس بالا تلقی می‌شود، در اولین مُد تجربی مربوط به تجزیه سیگنال قرار خواهد گرفت. بدین ترتیب با توجه به اینکه این مُد حاوی اطلاعات مفیدی در زمینه شناسایی اختلال گذر نوسانی ولتاژ و همچنین شناسایی محل رخداد اختلالات است، حضور نویز در کنار این اطلاعات می‌تواند موجب بروز خطا در شناسایی اختلال یا محل دخداد آن شود. بنابراین، بهتر آن است که در کارهای آتی و در مرحله پیش‌پردازش روش مناسبی برای حذف نویز از سیگنال لحاظ شود تا از بروز خطا در هنگام مواجه با سیگنال نویزی جلوگیری شود

## مراجع

## ۵- نتیجه‌گیری

در این مقاله یک سیستم خودکار به منظور شناسایی و طبقه‌بندی اختلالات کیفیت توان در یک سیستم قدرت ۳۳ باسه ارائه شده است. پیشرفت تکنولوژی موجب استفاده از انواع بارهای غیرخطی در شبکه‌های توزیع قدرت شده است. وجود این بارها موجب انحراف شکل موج از حالت ایده‌آل سینوسی می‌شود و در نتیجه برخی از اغتشاشات کیفیت توان پدید می‌آیند. از طرف دیگر، بسیاری از بارها توسط سیستم‌های حساس الکترونیکی و میکروپروسسوری کنترل می‌شوند که به اغتشاشات مختلف در شبکه حساس بوده و احتمال بروز اختلال در عملکرد آنها وجود دارد. عدم کنترل این تغییرات خسارت‌های سنگینی به بارهای حساس متصل به شبکه توزیع قدرت وارد کرده و موجب نارضایتی مشترکین می‌شود. در این مقاله به منظور طبقه‌بندی اختلالات کیفیت توان، یک روش جدید در قالب الگوریتم یادگیری عمیق ارائه شده است. در این روش، توابع فعال‌ساز به صورت فازی تعریف شده است. تفاوت این روش با پژوهش‌های مشابه، نحوه‌ی ترکیب الگوریتم فازی در ساختار یادگیری عمیق می‌باشد. در این روش، به دلیل انعطاف‌پذیری بالای توابع

- Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. *Electric Power Systems Research*, 81(12), 2057-2065 .
- Deokar, S., & Waghmare, L. (2014). Integrated DWT-FFT approach for detection and classification of power quality disturbances. *International Journal of Electrical Power & Energy Systems*, 61, 594-605 .
- Duchesne, L., Karangelos, E., & Wehenkel, L. (2020). Recent developments in machine learning for energy systems reliability management. *Proceedings of the IEEE*, 108(9), 1656-1676 .
- Gupta, N., Seethalekshmi, K., & Datta, S. S. (2021). Wavelet based real-time monitoring of electrical signals in Distributed Generation (DG) integrated system. *Engineering Science and Technology, an International Journal*, 24(1), 218-228 .
- Hajian, M., & Foroud, A. A. (2014). A new hybrid pattern recognition scheme for automatic discrimination of power quality disturbances. *Measurement*, 51, 265-280 .
- Huang, N., Lu, G., Cai, G., Xu, D., Xu, J., Li, F., & Zhang, L. (2016). Feature selection of power quality disturbance signals with an entropy-importance-based random forest. *Entropy* .44 ,(2)18 ,
- Karasu, S., & Saraç, Z. (2020). Classification of power quality disturbances by 2D-Riesz Transform, multi-objective grey wolf optimizer and machine learning methods. *Digital Signal Processing*, 101, 102711 .
- Khokhar, S., Zin, A. A. M., Memon ,A. P., & Mokhtar, A. S. (2017). A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network. *Measurement*, 95, 246-259 .
- Abdelsalam, A. A., Eldesouky, A. A., & Sallam, A. A. (2012). Characterization of power quality disturbances using hybrid technique of linear Kalman filter and fuzzy-expert system. *Electric Power Systems Research*, 83(1), 41-50 .
- Abdeltawab, H. H., & Mohamed, Y. A.-r. I. (2017). Robust operating zones identification for energy storage day-ahead operation. *Sustainable Energy, Grids and Networks*, 10, 1-11 .
- Ahila, R., Sadasivam, V., & Manimala, K. (2015). An integrated PSO for parameter determination and feature selection of ELM and its application in classification of power system disturbances. *Applied Soft Computing*, 32, 23-37 .
- Aslam, S., Herodotou, H., Mohsin, S. M., Javid, N., Ashraf, N., & Aslam, S. (2021). A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids. *Renewable and Sustainable Energy Reviews*, 144, 110992 .
- Borges, F. A., Fernandes, R. A., Silva, I. N., & Silva, C. B. (2015). Feature extraction and power quality disturbances classification using smart meters signals. *IEEE Transactions on industrial informatics*, 12(2), 824-833 .
- Cai, K., Hu, T., Cao, W., & Li, G. (2019). Classifying power quality disturbances based on phase space reconstruction and a convolutional neural network. *Applied Sciences* .3681 ,(18)9 ,
- Cheng, Y., Wu, W., Chung, H., Blaabjerg, F., Eftychios, K., & Zhu, L. (2020). *Using Kalman Filter to Achieve Online Estimation of Equivalent Grid Impedance and High Bandwidth Control for LCL-Filtered Grid-tied Inverters*. Paper presented at the IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society.
- Decanini, J. G., Tonelli-Neto, M. S., Malange, F. C., & Minussi, C. R. (2011).

- review. *International Transactions on Electrical Energy Systems*, 29(8), e12008 .
- Mishra, M., Nayak, J., Naik, B., & Abraham, A. (2020). Deep learning in electrical utility industry: a comprehensive review of a decade of research. *Engineering Applications of Artificial Intelligence*, 96, 104000 .
- Mishra, M., & Panigrahi, R. R. (2020). Advanced signal processing and machine learning techniques for voltage sag causes detection in an electric power system. *International Transactions on Electrical Energy Systems*, 30(1), e12167 .
- Nie, X. (2019). Detection of grid voltage fundamental and harmonic components using Kalman filter based on dynamic tracking model. *IEEE transactions on industrial electronics*, 67 .1200-1191 ,(2)
- Qu, B., Li, N., Liu, Y., & Alsaadi, F. E. (2020). Estimation for power quality disturbances with multiplicative noises and correlated noises: A recursive estimation approach. *International Journal of Systems Science*, 51(7), 1200-1217 .
- Rodrigues Junior, W. L., Borges, F. A., Rabelo, R. d. A., Rodrigues, J. J., Fernandes, R. A., & da Silva, I. N. (2021). A methodology for detection and classification of power quality disturbances using a real-time operating system in the context of home energy management systems. *International Journal of Energy Research*, 45(1), 203-219 .
- Saini, M. K., Kapoor, R., Beniwal, R. K., & Aggarwal, A. (2019). Recognition of voltage sag causes using fractionally delayed biorthogonal wavelet. *Transactions of the Institute of Measurement and Control*, 41(10), 2851-2863 .
- Khoramabadi, H. R., Keshavarz, A & ., Dashti, R. (2020). A novel fault location method for compensated transmission line including UPFC using one-ended voltage and FDOST transform. *International Transactions on Electrical Energy Systems*, 30(6), e12357 .
- Liu, H., Hussain, F., Yue, S., Yildirim , O., & Yawar, S. J. (2019). Classification of multiple power quality events via compressed deep learning. *International Transactions on Electrical Energy Systems*, 29(6), e12010 .
- Liu, J., Song, H., & Zhou, L. (2019). *Identification and location of voltage sag sources based on multi-label random forest*. Paper presented at the 2019 IEEE Sustainable Power and Energy Conference (iSPEC).
- Mahela, O. P., Shaik, A. G., & Gupta, N. (2015). A critical review of detection and classification of power quality events . *Renewable and Sustainable Energy Reviews*, 41, 495-505 .
- Mahela, O. P., Shaik, A. G., Khan, B., Mahla, R., & Alhelou, H. H. (2020). Recognition of Complex Power Quality Disturbances Using S-Transform Based Ruled Decision Tree. *IEEE Access*, 8, 173530-17354 .7
- Manimala, K., Selvi, K., & Ahila, R. (2012). Optimization techniques for improving power quality data mining using wavelet packet based support vector machine. *Neurocomputing*, 77(1), 36-47 .
- Minh Khoa, N., & Van Dai, L. (2020). Detection and Classification of Power Quality Disturbances in Power System Using Modified-Combination between the Stockwell Transform and Decision Tree Methods. *Energies*, 13(14), 3623 .
- Mishra, M. (2019). Power quality disturbance detection and classification using signal processing and soft computing techniques: A comprehensive

- Taheri, R., Eslami, M., & Damchi, Y. (2020). Single-end current-based algorithm for fault location in series capacitor compensated transmission lines. *International Journal of Electrical Power & Energy Systems*, 123, 106254 .
- Valtierra-Rodriguez, M., de Jesus Romero-Troncoso, R., Osornio-Rios, R. A., & Garcia-Perez, A. (2013). Detection and classification of single and combined power quality disturbances using neural networks. *IEEE transactions on industrial electronics*, 61(5), 2473-2482 .
- Wang, H., Wang, P., & Liu, T. (2017). Power quality disturbance classification using the S-transform and probabilistic neural network. *Energies*, 10(1), 107 .
- Wang, S., & Chen, H. (2019). A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network. *Applied energy*, 235, 1126-114 .0
- Xi, Y., Li, Z., Zeng, X., Tang, X., Liu, Q., & Xiao, H. (2018). Detection of power quality disturbances using an adaptive process noise covariance Kalman filter. *Digital Signal Processing*, 76, 34-49 .
- Yoshikane, T., & Yoshimura, K. (2021). A machine learning bias correction method for precipitation corresponding to weather conditions using simple input data. *Earth and Space Science Open Archive ESSOAr* .
- Zhao, W., Shang, L., & Sun, J. (2019). Power quality disturbance classification based on time-frequency domain multi-feature and decision tree. *Protection and Control of Modern Power Systems*, 4(1), 1-6 .
- Santos-Hernandez, J. A., Valtierra-Rodriguez, M., Amezcua-Sanchez, J. P., Romero-Troncoso, R. D. J., & Camarena-Martinez, D. (2019). Hilbert filter based FPGA architecture for power quality monitoring. *Measurement*, 147, 106819 .
- Shamachurn, H. (2019). Assessing the performance of a modified S-transform with probabilistic neural network, support vector machine and nearest neighbour classifiers for single and multiple power quality disturbances identification. *Neural Computing and Applications*, 31(4), 1041-1060 .
- Shukla, S., Mishra, S., & Singh, B. (2013). Power quality event classification under noisy conditions using EMD-based de-noising techniques. *IEEE Transactions on industrial informatics*, 10(2), 104 .1054-4
- Sindi, H., Nour, M., Rawa, M., Öztürk, Ş., & Polat, K. (2021). A novel hybrid deep learning approach including combination of 1D power signals and 2D signal images for power quality disturbance classification. *Expert Systems with Applications*, 17 .114785 ,4
- Singh, U., & Singh, S. N. (2019). A new optimal feature selection scheme for classification of power quality disturbances based on ant colony framework. *Applied Soft Computing*, 74, 216-225 .
- Subbarao, M. V., Kumar, T. S., Raju, G., & Samundiswary, P. (2020). Power Quality Event Recognition Using Cumulants and Decision Tree Classifiers *Innovations in Electronics and Communication Engineering* (pp. 571-583): Springer, Singapore.