

Power Quality Disturbances Classification Using Identity Feature Vector and Support Vector Machine

A.Baniasadi¹, B.BabaAli^{2*}

1- Faculty of Electrical and Computer Engineering, University of Semnan, Semnan, Iran.

2*- School of Mathematics, Statistics, and Computer Science, College of Science, University of Tehran, Tehran, Iran.

¹a.baniasadi@semnan.ac.ir, ^{2*}: babaali@ut.ac.ir

Corresponding author address: Bagher BabaAli, School of Mathematics, Statistics, Computer Science, College of Science, University of Tehran, Tehran, Iran, Post Code: 14155-6455

Abstract- Correct detection and classification of power quality disturbances is an essential issue in power systems. In this paper, an intelligent method is proposed to detect the power quality disturbances. This method is based on an identity vector framework that produces a fixed-length vector for each perturbation. In the first step of the proposed pipeline, the discrete wavelet transform is used to analyze power quality events and extract the features of each input signal, and then the identity vector is built using the approximation coefficients. After applying some normalization on the obtained identity, it is classified using a support vector machine classifier. In order to evaluate the proposed method, twelve types of disturbances have been synthesized and the efficiency of the proposed system is investigated using them. In addition, to verify the robustness of the proposed approach towards the noise, the synthesized signals are contaminated with white Gaussian noise with different SNR values, 30 dB, 40 dB and 50 dB. The results of the experiments demonstrate the efficiency of the proposed method for the classification of power quality signals with an accuracy of 99.2%.

Keywords- Power quality disturbances classification, Discrete wavelet transform, Identity vector, Feature normalization, Support vector machine.

به کارگیری ویژگی بردار هویت و ماشین بردار پشتیبان به منظور شناسایی و طبقه‌بندی اغتشاشات کیفیت توان

عاطفه بنی‌اسدی^۱، باقر باباعلی^{۲*}

۱- دانشکده مهندسی برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران.

۲* - دانشکده ریاضی، آمار و علوم کامپیوتر، دانشگاه تهران، تهران، ایران.

¹a.baniasadi@semnan.ac.ir, ^{2*} babaali@ut.ac.ir

* نشانی نویسنده مسئول: باقر باباعلی، تهران، خیابان آزادی، دانشگاه تهران، دانشکده ریاضی، آمار و علوم کامپیوتر، کد پستی: ۱۴۱۵۵-۶۴۵۵

چکیده - یکی از مسائل مهم در سیستم‌های قدرت، تشخیص صحیح اغتشاشات کیفیت توان است. در این مقاله یک روش هوشمند به منظور شناسایی اغتشاشات کیفیت توان ارائه شده است. در روش پیشنهادی که بر مبنای ویژگی بردار هویت است، برای هر سیگنال اغتشاش یک بردار با طول ثابت استخراج می‌شود. به این صورت که در مرحله اول، تبدیل موجک به منظور استخراج ویژگی از سیگنال اغتشاش ورودی به کار گرفته شده است و سپس با استفاده از دنباله ضرایب موجک استخراج شده، بردار هویت تولید می‌شود. در ادامه بعد از انجام نرمال‌سازی‌های لازم، بردار هویت نرمال شده استخراج شده توسط ماشین بردار پشتیبان طبقه‌بندی می‌شود. به منظور ارزیابی عملکرد روش پیشنهادی دوازده نوع اغتشاش اعم از تکی و ترکیبی ایجاد و کارایی سیستم در شرایط تمیز و نویزی بررسی شده است. نویز اعمال شده به هر سیگنال نویز سفید گاوسی با مقادیر سیگنال به نویز ۳۰، ۴۰ و ۵۰ دسی بل است. نتایج آزمایش‌ها میانگین دقت روش پیشنهادی را ۹۹/۲ درصد نشان می‌دهد.

واژه‌های کلیدی: طبقه‌بندی اغتشاشات کیفیت توان، ضرایب موجک، بردار هویت، نرمال‌سازی ویژگی، ماشین بردار پشتیبان

۱- مقدمه

توان، حفاظت، کنترل و مانیتورینگ این سیستم‌ها محسوب می‌شود [۳، ۴].

روش‌های زیادی در طی سال‌های اخیر برای این مسئله توسط پژوهشگران عرصه مهندسی برق قدرت پیشنهاد شده است. هر یک از این روش‌ها با ساختار متفاوتی از دیگر روش‌ها، می‌تواند در بعضی از جنبه‌ها مؤثر واقع شود و دقت قابل قبولی را ارائه دهد؛ اما هنوز مواردی از قبیل نویز مسئله مهمی در این عرصه محسوب می‌شود. دو راه‌حل برای مقابله با نویز وجود دارد: (۱) استفاده از روش‌های حذف نویز؛ در این روش‌ها مرحله جدیدی به نام حذف نویز به سیستم اضافه می‌شود. هدف این مرحله، کاهش اثرات نویز بر

هدف سیستم‌های برق قدرت، تأمین انرژی الکتریکی برای مصرف کنندگان است [۱]. به دلیل افزایش بکارگیری ادوات و دستگاه‌های حاوی قطعات الکتریکی و الکترونیکی در زندگی و حرکت پرشتاب دنیا به سمت ماشینی شدن، کیفیت این انرژی از اهمیت بالایی برخوردار است [۲]. عوامل زیادی از جمله بانک‌های خازنی، بارهای غیرخطی و غیره در ایجاد اغتشاش هنگام تحویل این انرژی به مصرف‌کننده دخیل است. چنین عواملی باعث اختلال در عملکرد این قطعات و کاهش عمر مفید آن‌ها شده است. از این رو شناسایی و اندازه‌گیری دقیق اغتشاشات کیفیت توان امر مهمی در اندازه‌گیری

این تبدیل علاوه برداشتن مزایای تبدیل موجک، وضوح فرکانسی را افزایش می‌دهد، به همین دلیل در مقالات [۱۲، ۱۳] از آن برای استخراج ویژگی بهره گرفته شده است. تبدیل S نوعی تبدیل فرکانسی مبتنی بر تبدیل فوریه زمان کوتاه و تبدیل موجک است و اندازه پنجره در آن وابسته به فرکانس است. در [۱۴، ۱۵] مشاهده می‌شود که از تبدیل S نیز می‌توان برای استخراج ویژگی بهره‌گرفت. در [۱۶] از تحلیل مؤلفه‌های مستقل^۹ برای حل مسئله طبقه‌بندی اغتشاشات کیفیت توان ترکیبی استفاده شده است. در این روش به کمک ویژگی استقلال آماری و توزیع غیر گاوسی منابع، سیگنال‌های اغتشاش ترکیبی به مؤلفه‌های مستقل که بیانگر منابع اصلی اغتشاش هستند، تجزیه می‌شوند. در [۱۷] روشی مبتنی بر توسعه فاکتور f در تبدیل موجک گسسته^{۱۰} برای طبقه‌بندی چهارده سیگنال اغتشاش معرفی شده است. در این روش که TQWT^{۱۱} نام دارد مؤلفه فرکانس اصلی از سیگنال استخراج شده و از ماشین بردار پشتیبان چند کلاسه برای طبقه‌بندی این اغتشاشات استفاده شده است.

در [۱۸، ۱۹] از شبکه عصبی پیچشی^{۱۲} برای حل مسئله شناسایی اغتشاشات استفاده شده است. مزیت استفاده از این شبکه عصبی این است که مرحله استخراج ویژگی در این شبکه تعبیه شده است و نیازی نیست صریحاً تلاشی در جهت استخراج و انتخاب ویژگی-های مناسب صورت گیرد. در [۲۰] روشی برای تشخیص هفت نوع اغتشاش تکی در کیفیت توان ارائه شده است. این سیستم مبتنی بر آنالیز مؤلفه مستقل و خود رمزگذار تنک^{۱۳} (SAE) است که می‌تواند به طور خودکار ویژگی‌های مورد نیاز برای آموزش را استخراج نماید. در [۲۱] روش خودکاری جهت طبقه‌بندی شانزده نوع از اختلالات کیفیت توان بر اساس بکارگیری فیلتر وفقی ارائه شده است. فیلتر وفقی مبتنی بر تبدیل موجک تجربی^{۱۴} برای سیگنال‌های ناپایمان مناسب است، از این‌رو در بخش استخراج ویژگی از آن بهره‌گرفته شده است. این روش در مرحله اول به کمک تبدیل فوریه سریع، فرکانس‌های واقعی موجود در سیگنال تخمین زده و سپس یک مجموعه از فیلترهای تطبیقی را در حوزه فرکانس به کار می‌گیرد تا اجزای تک فرکانسی را از اغتشاشات استخراج کند. در انتها ویژگی‌های استخراج شده به کمک ماشین بردار پشتیبان چند کلاسه طبقه‌بندی شده است.

با اینکه تبدیل موجک یکی از ابزارهای پر کاربرد در شناسایی اغتشاشات کیفیت توان است اما معایبی هم دارد. اول اینکه با افزایش سطوح تجزیه، بار محاسباتی افزایش می‌یابد که در بعضی مقالات برای حل این مسئله از الگوریتم‌های کاهش یا انتخاب ویژگی بهره‌گرفته شده است و دوم اینکه ذاتاً نسبت به نویز مقاوم

سیگنال است. در [۵، ۶] فیلترها و الگوریتم‌هایی برای حذف نویز پیشنهاد شده است. بکارگیری این روش‌ها علاوه بر افزایش بار محاسباتی سیستم، در بعضی مواقع نیز با اثرات مخرب خود باعث تغییر در ماهیت سیگنال می‌شود. (۲) استفاده از ویژگی‌های مقاوم به نویز؛ در این روش‌ها مرحله جدیدی به سیستم اضافه نمی‌شود بلکه از الگوریتم‌هایی برای استخراج ویژگی‌های مقاوم به نویز استفاده شده است.

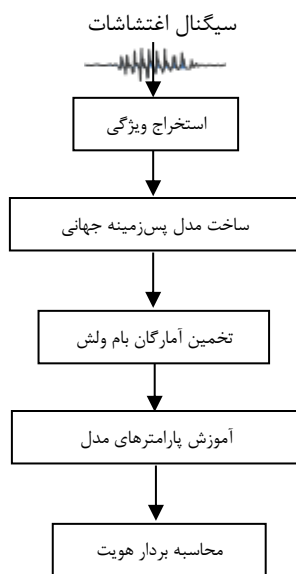
در راستای استخراج ویژگی برای به دست آوردن اطلاعات فرکانسی سیگنال، تبدیل فوریه گزینه مناسبی است. در [۷] از تبدیل فوریه جهت استخراج ویژگی استفاده شده است؛ اما از آنجائیکه تبدیل فوریه اطلاعات فرکانسی سیگنال را در بر دارد و زمان وقوع فرکانس را نشان نمی‌دهد، بنابراین برای سیگنال‌هایی که مشخصات اجزای طیفی آن‌ها در طول زمان تغییر نمی‌کند (سیگنال ایستا) مناسب است. یک ابزار مناسب برای استخراج اطلاعات فرکانسی و در عین حال حفظ زمان وقوع فرکانس تبدیل موجک است. در [۸] از تبدیل موجک برای استخراج ویژگی به منظور طبقه‌بندی اغتشاشات کیفیت توان استفاده شده است. به این صورت که ابتدا ضرایب جزئیات^۲ در نه سطح و ضریب تقریب^۲ در آخرین سطح استخراج شده است، سپس اطلاعات آماری مانند میانگین، انحراف معیار، آنتروپی انرژی، لگاریتم انرژی از روی آنها تولید شده است و سپس به کمک الگوریتم SFS^۴ مناسب‌ترین ویژگی‌ها انتخاب شده است؛ در آخر درخت لجستیک برای طبقه‌بندی این ویژگی‌ها بکار گرفته شده است. در [۹] نیز از تبدیل موجک برای استخراج ویژگی و از شبکه موجک به منظور طبقه‌بندی استفاده شده است. شبکه موجک متعلق به دسته شبکه‌های عصبی پیش‌خور^۵ است و موجک به‌عنوان تابع فعال‌ساز^۶ نوروها در این شبکه‌ها استفاده می‌شود.

در [۱۰] به کمک تبدیل فوریه و تبدیل موجک هشت ویژگی که عبارتند از: (۱) مؤلفه اصلی (۲) جابجایی زاویه‌ای (۳) اعوجاج هارمونیک کل (۴) تعداد نقاط بیشینه نسبی قدر مطلق ضرایب تبدیل موجک (۵) انرژی ضرایب تبدیل موجک (۶) تعداد دفعات عبور از صفر ولتاژ از دست‌رفته (۷) اعوجاج هارمونیک مراتب پایین (۸) تعداد دفعات عبور از صفر تغییرات مقدار مؤثر، برای هر اغتشاش به دست آمده است. در این مقاله دو سیستم فازی یکی برای تشخیص نوع اغتشاش و دیگری برای طبقه‌بندی استفاده شده است. تفاوت این روش نسبت به روش‌های [۳، ۱۱] در این است که معمولاً تنظیم پارامترهای توابع عضویت بر اساس اطلاعات فرد خبره و یا بر اساس آزمون و خطا است، اما در این مقاله از الگوریتم بهینه‌سازی ازدحام ذرات^۷ (PSO) برای تنظیم این مقادیر استفاده شده است.

تبدیل بسته موجک^۸ ابزار مناسبی برای تحلیل چند رزولوشنی است.

۲-۱- استخراج ویژگی

در هر سیگنال اطلاعات زیادی وجود دارد که بعضی از آن‌ها به دلیل افزونگی و یا غیرمفید بودن، به غیر از افزایش بار محاسباتی تأثیری در کارایی سیستم ندارند. بنابراین استخراج ویژگی به دو منظور انجام می‌گیرد. اول تمرکز بر روی اطلاعات مفید و مرتبط موجود در سیگنال که باعث افزایش شباهت درون کلاسی و کاهش شباهت بین کلاسی می‌شود؛ دوم آنکه حجم داده‌ها را به میزان زیادی کاهش داده و محاسبات به میزان زیادی کم می‌شود [۲۵]. روش استخراج ویژگی بکار گرفته شده در این مقاله تبدیل موجک است که در بخش روش پیشنهادی توضیح داده خواهد شد.



شکل ۱: نمای کلی مراحل استخراج بردار هویت

۲-۲- مدل پس‌زمینه جهانی

مدل پس‌زمینه جهانی [۲۶] همان مدل مخلوط گاوسی^{۲۱} است که هدفش مدل کردن توزیع اطلاعات، مستقل از هر کلاس است. برای این کار با استفاده از بردارهای ویژگی استخراج شده از تمام اغتشاشات، مدل مخلوط گاوسی آموزش می‌شود. مدل مخلوط گاوسی، مجموعه‌ای از توابع گاوسی با وزن‌های مختلف را برای مدل کردن تابع چگالی احتمال به کار می‌گیرد. تابع چگالی احتمال بردار D -بعدی x مطابق رابطه ۱ است.

$$P(x_n|\lambda) = \sum_{g=1}^M \pi_g N(x_n|\mu_g, \Sigma_g) \quad (1)$$

در این رابطه π_g نشان‌دهنده وزن g امین مخلوط گاوسی و N بیانگر توزیع گاوسی با میانگین μ_g و کوواریانس Σ_g است. مجموع اوزان مخلوط‌ها برابر یک است. هر جزء تابع چگالی خود یک توزیع گاوسی

نیست [۲۲]. در این مقاله، برای اولین بار از ویژگی جدیدی به نام بردار هویت^{۱۵} (i-vector) به منظور بازنمایی ویژگی بهره گرفته شده است. به این صورت که ابتدا ضرایب تقریب در اولین سطح از تبدیل موجک استخراج شده است و سپس به کمک این ضرایب برای هر اغتشاش بردار هویت تولید شده است؛ در ادامه پس از انجام نرمال‌سازی، بردار هویت نرمال‌سازی شده اغتشاشات، به کمک ماشین بردار پشتیبان طبقه‌بندی می‌شود.

نوآوری اصلی این مقاله در بکارگیری بردار هویت جهت تعبیه کردن^{۱۶} ویژگی‌های سیگنال اغتشاش در قالب یک بردار با طول ثابت است، مستقل از این که طول سیگنال اغتشاش چقدر است. در واقع روش پیشنهادی، با فشرده کردن خصوصیات سیگنال اغتشاش در قالب یک بردار با طول ثابت این امکان را فراهم می‌کند که بتوان از روش‌های معمول طبقه‌بندی نظیر ماشین بردار پشتیبان استفاده کرد. سامانه پیشنهادی برای اولین بار برای حل مسئله طبقه‌بندی اغتشاشات کیفیت توان توسط نویسندگان مقاله پیشنهاد شده است که بر مبنای آزمایش‌های انجام شده از کارایی کاملاً قابل قبولی برخوردار است.

بخش‌های مختلف مقاله به این صورت سازمان‌دهی شده است. در بخش دوم نحوه استخراج بردار هویت آمده است؛ بخش سوم جزئیات روش پیشنهادی را بیان می‌کند. به منظور ارزیابی روش پیشنهادی، دوازده نوع اغتشاش اعم از ساده و ترکیبی در شرایط تمیز و نویزی مورد بررسی قرار گرفته شده است و نتیجه آزمایش‌ها و مقایسه با سایر روش‌ها در بخش چهارم آمده است. بخش پنجم به بیان جمع‌بندی و نتیجه‌گیری پرداخته است.

۲- بردار هویت

بردار هویت برای اولین بار در حوزه پردازش گفتار به منظور بازشناسی گوینده [۲۳] مطرح شد که در ادامه برای کاربردهای متعدد دیگری به کار گرفته شد. به طور کلی بردار هویت یک نمایش فشرده از اطلاعات مفید موجود در سیگنال است [۲۴]. این روش که بر پایه تجزیه عوامل توأم^{۱۷} است از سیگنال‌هایی با طول متفاوت، برداری با طول ثابت استخراج می‌کند. شکل ۱ مراحل استخراج بردار هویت را نشان می‌دهد. پس از استخراج ویژگی از سیگنال که معمولاً به صورت دنباله‌ای از بردارهای ویژگی است، مدل پس‌زمینه جهانی^{۱۸} آموزش داده می‌شود. در مرحله بعد، از دنباله ویژگی‌های استخراج شده، آمارگان بام ولش^{۱۹} به دست آمده و به کمک این مقادیر، فضای تغییرپذیری کل^{۲۰} مدل می‌شود و در نهایت بردار هویت تولید می‌شود. جزئیات هر یک از این مراحل در ادامه شرح داده خواهد شد.

D متغیره مطابق رابطه ۲ است.

کوواریانس طبق رابطه ۷ تشکیل شود.

$$\Sigma = \begin{bmatrix} \Sigma_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \Sigma_c \end{bmatrix} \quad (7)$$

که Σ_i ماتریس کوواریانس مؤلفه c از مدل پس‌زمینه جهانی است. فرض کنید x_i بردار ویژگی برای داده آموزشی i باشد و درستی‌مندی این بردار با $P(x_i|M, \Sigma)$ نشان‌داده‌شده شود آنگاه بیشینه‌سازی امید ریاضی در دو مرحله انجام می‌شود. اول با استفاده از مقدار T برای هر داده آموزشی برداری که درستی‌مندی را بیشینه می‌کند طبق رابطه ۸ به دست می‌آوریم سپس مقدار T را با رابطه ۹ به‌روز می‌کنیم.

$$w_i = \underset{w}{\operatorname{argmax}} P(X_i|m + Tw_i, \Sigma) \quad (8)$$

$$\prod_i P(X_i|m + Tw_i, \Sigma) \quad (9)$$

درستی‌مندی برای هر سیگنال با رابطه ۱۰ به دست می‌آید،

$$\sum_c \left(N_c \ln \frac{1}{(2\pi)^{M/2} |\Sigma_c|^{1/2}} - \frac{1}{2} \sum_t (X_{i,t} - T_c w_i - m_c)' \times \sum_c^1 (X_{i,t} - T_c w_i - m_c) \right) \quad (10)$$

که c و t به ترتیب مربوط به مؤلفه‌های مدل و بردارهای ویژگی است و T_c مربوط به مؤلفه c است. با داشتن آمارگان صفرم و یکم از یک سیگنال ماتریس کوواریانس پیشین، میانگین و گشتاور دوم برای متغیر w_i به ترتیب با روابط ۱۱، ۱۲، ۱۳ به دست می‌آید.

$$\operatorname{cov}(w_i, w_i) = \left(I, \sum_c N_c(X_i) T_c' \sum_c^{-1} F_c(X_i) \right)^{-1} \quad (11)$$

$$E[w_i] = \operatorname{cov}(w_i, w_i) \sum_c T_c' \sum_c^{-1} F_c(X_i) \quad (12)$$

$$E[w_i, w_i'] = \operatorname{cov}(w_i, w_i) + E[w_i]E[w_i'] \quad (13)$$

زمانی که رابطه ۹ را بیشینه کنیم رابطه ۱۴ برای به‌روزرسانی ماتریس تغییرپذیری کل استفاده می‌شود.

$$T_c = \left(\sum_i F_c(X_i) E[w_i'] \right) \left(\sum_i N_c(X_i) E[w_i, w_i'] \right)^{-1} \quad (14)$$

$$N(x_n | \mu_g, \Sigma_g) = \frac{1}{2\pi^{D/2} |\Sigma_g|^{1/2}} \exp \left(-\frac{1}{2} (x_g - \mu_g) \times \sum_g^{-1} (x_k - \mu_k) \right) \quad (2)$$

برای به دست آوردن پارامترهای میانگین، وزن مخلوط‌ها و ماتریس کوواریانس، الگوریتم بیشینه‌سازی امید ریاضی^{۲۲} بکار گرفته می‌شود.

۲-۳- تخمین آمارگان بام ولش

در این مرحله با استفاده از پارامترهای مدل پس‌زمینه جهانی، آمارگان بام ولش مرتبه صفر و یک برای هر بردار ویژگی تخمین زده می‌شود [۲۷]. آمارگان مرتبه صفر و یک برای نامین داده آموزشی با استفاده از روابط ۳ و ۴ به دست می‌آید.

$$N_c(X_i) = \sum_i \gamma_{i,t}(c) \quad (3)$$

$$F_c(X_i) = \sum_i \gamma_{i,t}(c) (X_{i,t} - m_c) \quad (4)$$

در رابطه ۴، m_c میانگین مؤلفه c است و $\gamma_{i,t}(c)$ که احتمال پیشین بردار $X_{i,t}$ توسط مؤلفه c مخلوط گوسی است و طبق رابطه ۵ به دست می‌آید.

$$\gamma_{i,t}(c) = P(c|X_{i,t}) = \frac{w_c P(X_{i,t}|c)}{\sum_{j=1}^M w_j P(X_{i,t}|j)} \quad (5)$$

۲-۴ آموزش پارامترهای مدل

اگر ویژگی‌های مربوط به یک سیگنال را توسط یک ابر بردار^{۲۳} نشان دهیم. این ابر بردار با رابطه ۶ مدل می‌شود [۲۴].

$$M = m + Tw \quad (6)$$

در این رابطه m یک ابر بردار مستقل از کلاس است. هر ابر بردار از کنار هم قرار دادن بردارهای میانگین مؤلفه‌های مدل پس‌زمینه جهانی به دست می‌آید که معمولاً یک بردار با طول زیاد است. T ماتریس تغییرپذیری کل نام دارد و یک ماتریس مرتبه پایین است. متغیر پنهان w بردار عامل‌های کل نامیده می‌شود و یک بردار تصادفی با توزیع $N(\mathbf{0}, \mathbf{I})$ است. بردار میانگین پسین w بردار هویت نام دارد. برای محاسبه ماتریس T از الگوریتم بیشینه‌سازی امید ریاضی استفاده شده است. فرض کنید مدل پس‌زمینه جهانی دارای c مؤلفه و ابعاد بردارهای ویژگی D باشد. ابتدا نیاز است ماتریس

۲-۵- محاسبه بردار هویت

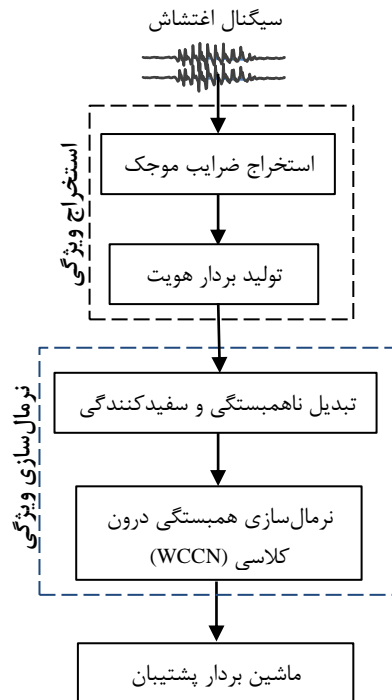
در این مرحله با کمک تخمین نقطه‌ای MAP از متغیر w بردار هویت به دست آمده است؛ که همان رابطه ۱۲ است. در شکل ۲ نمایش گرافیکی از روند استخراج بردار هویت نشان داده شده است.

۳- عملکرد روش پیشنهادی

در شکل ۳ مراحل سیستم پیشنهادی نشان داده شده است. برای تولید بردار هویت، می‌بایست دنباله بردارهای ویژگی استخراج شده از هر سیگنال در اختیار باشد. در این مقاله، بردارهای ویژگی به کمک تبدیل موجک گسسته استخراج می‌شود. پس از بازنمایی هر سیگنال در قالب بردار هویت با طول ثابت و نرمال‌سازی آن، از ماشین بردار پشتیبان برای طبقه‌بندی اغتشاشات بهره گرفته می‌شود. توضیح هر یک از این مراحل در بخش‌های بعدی آمده است.

۳-۱- مجموعه داده

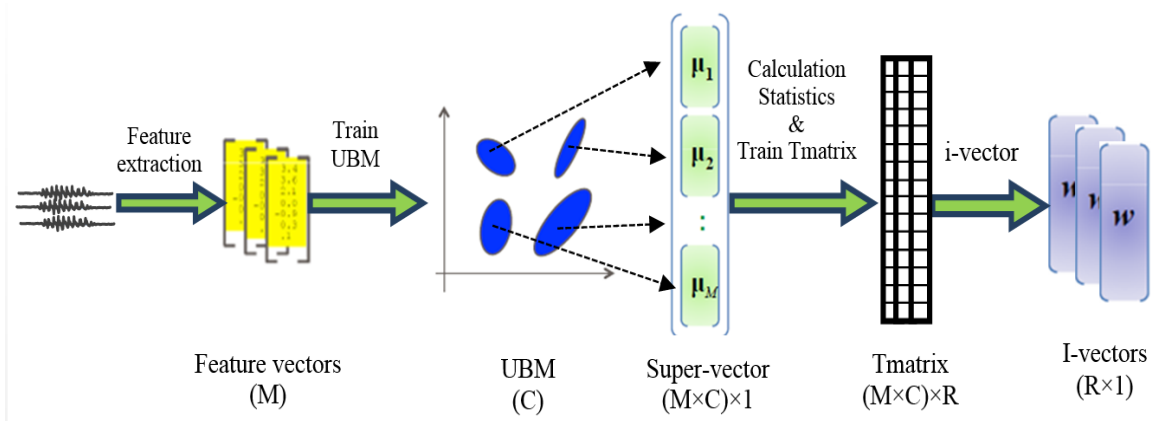
در این مقاله دوازده نوع اغتشاش اعم از ساده و ترکیبی بر اساس مدل‌های ارائه شده در جدول ۱ و با مقداردهی تصادفی در بازه پارامترهای کنترلی در محیط متلب تولید شده است. روابط جدول ۱ بر اساس مقالات [۲۸، ۱۰] شبیه‌سازی شده است. به دلیل احتمال بروز بعضی از اغتشاشات به‌طور همزمان، سعی شده است بعضی از اختلالات ترکیبی پر تکرار نیز تولید و بررسی شوند. این وقایع شامل ترکیب دوتایی و سه‌تایی از اغتشاشات ساده است. اغتشاشات ساده شامل هفت کلاس (Notch، Swell، Sag، Normal، Flicker، Spike، Harmonic) و اغتشاشات ترکیبی شامل پنج کلاس (Flicker + Sag، Harmonic + Swell، Harmonic + Sag، Flicker + Sag، Harmonic + Swell، Harmonic + Sag) است.



شکل ۳: بلوک دیاگرام سیستم پیشنهادی

۳-۲- تبدیل موجک گسسته

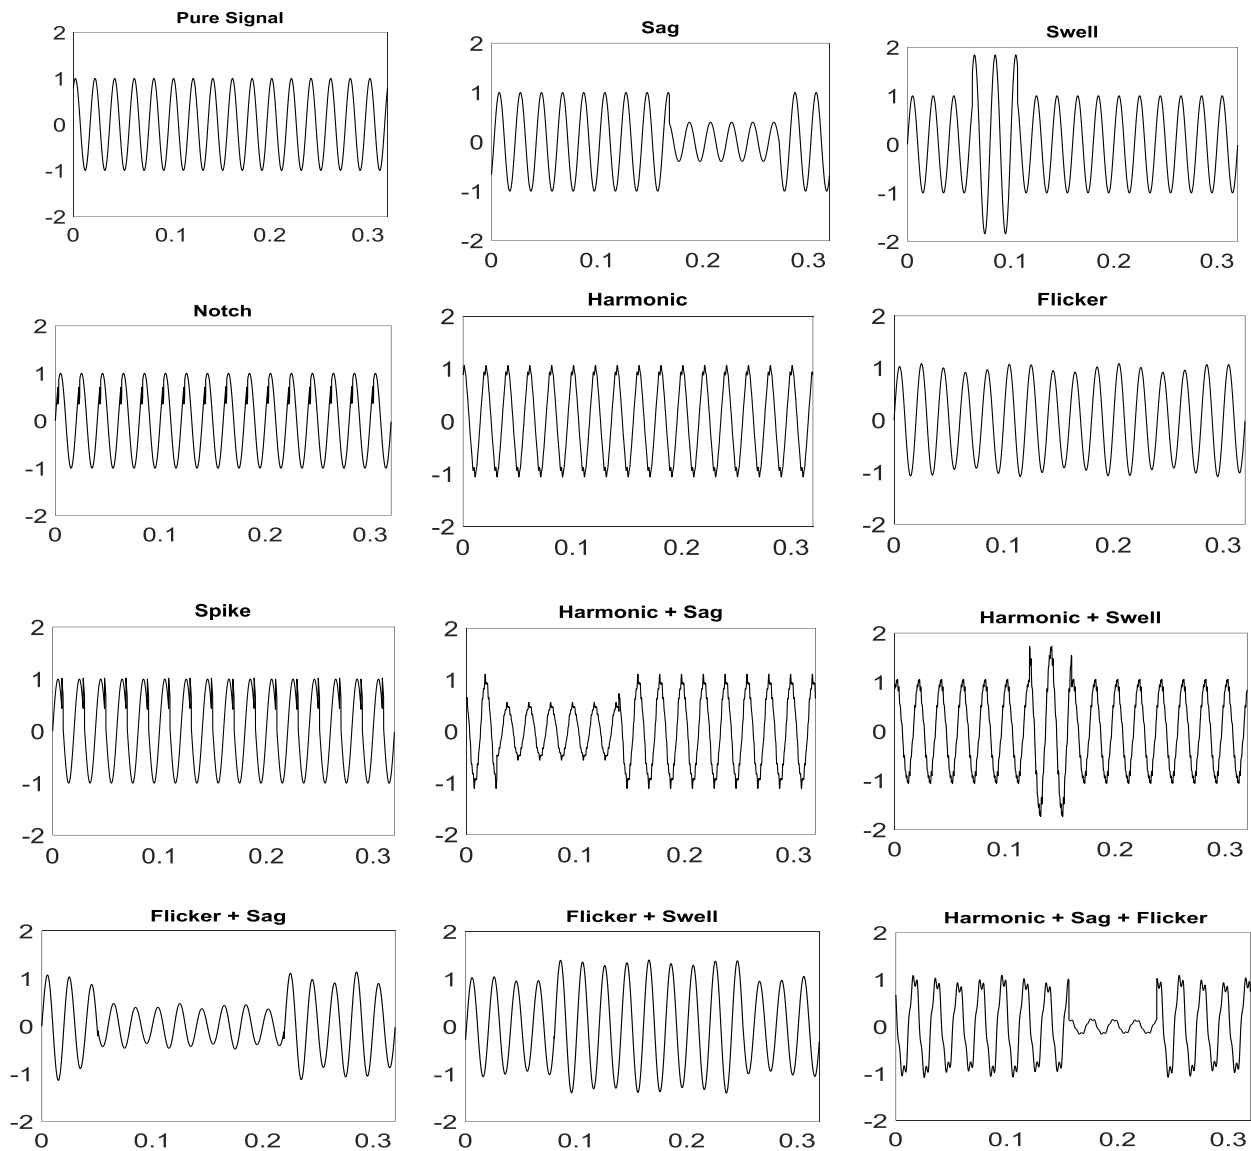
تبدیل موجک در ادامه روند بهبود تبدیل فوری و تبدیل فوری زمان کوتاه پیشنهاد شده است. در این تبدیل، برای آنالیز فرکانس‌های بالا



شکل ۲: نمایش گرافیکی از مراحل استخراج بردار هویت. M ابعاد بردار ویژگی برای هر سیگنال است. C تعداد مؤلفه‌های گوسی در آموزش مدل پس‌زمینه جهانی است. ابر بردار از الحاق میانگین مؤلفه‌های گوسی به دست می‌آید ابعاد این بردار $(M \times C) \times 1$ است. اگر مرتبه ماتریس تغییرپذیر کل R باشد ابعاد $Tmatrix$ برابر با $(M \times C) \times R$ است. در این شرایط ابعاد بردار هویت برای هر سیگنال $R \times 1$ است.

جدول ۱: روابط ریاضی اغتشاشات کیفیت توان

نوع اغتشاش	مدل ریاضی	بازه پارامترهای کنترلی
Normal	$v(t) = \sin(\omega t + \varphi)$	$\omega = 2\pi \times 50$ $-\pi \leq \varphi \leq \pi$
Sag	$v(t) = [1 - \alpha(u(t - t_s) - u(t - t_e))] \sin(\omega t + \varphi)$	$0.1 \leq \alpha \leq 0.9$ $T \leq t_e - t_s \leq 9T$
Swell	$v(t) = [1 + \alpha(u(t - t_s) - u(t - t_e))] \sin(\omega t + \varphi)$	$T \leq t_e - t_s \leq 9T$ $1.1 \leq \alpha \leq 1.8$
Notch	$v(t) = \sin(\omega t + \varphi) - \text{sign}(\sin(\omega t + \varphi)) \times \left\{ \sum_{n=0}^{15} k [u(t - (t_s + 0.02n)) - u(t - (t_e + 0.02n))] \right\}$	$0.1 \leq k \leq 0.4$ $0 \leq t_e, t_s \leq 0.5T$ $0.01T \leq t_e - t_s \leq 0.05T$
Harmonic	$v(t) = \sin(\omega t + \varphi) - \alpha_{2k} \sin(2k\omega t + \varphi_{2k}) + \alpha_{2k+1} \sin((2k+1)\omega t + \varphi_{2k+1}) + \dots$	$-\pi \leq \varphi, \varphi_{2k}, \varphi_{2k+1} \leq \pi$ $0.015 \leq \alpha_{2k} \leq 0.03$ $0.03 \leq \alpha_{2k+1} \leq 0.06$ $k = 1, 2, 3, \dots, 16$
Flicker	$v(t) = [1 + \alpha \sin(2\pi\beta t)] \sin(\omega t + \varphi)$	$0.05 \leq \alpha \leq 0.1$ $8 \leq \beta \leq 25$
Spike	$v(t) = \sin(\omega t + \varphi) - \text{sign}(\sin(\omega t + \varphi)) \times \left\{ \sum_{n=0}^{15} k [u(t - (t_s + 0.02n)) - u(t - (t_e + 0.02n))] \right\}$	$0.1 \leq k \leq 0.4$ $0 \leq t_e, t_s \leq 0.5T$ $0.01T \leq t_e - t_s \leq 0.05T$
Harmonic + Sag	$v(t) = \sin(\omega t + \varphi) + \alpha_{2k} \sin(2k\omega t + \varphi_{2k}) + \alpha_{2k+1} \sin((2k+1)\omega t + \varphi_{2k+1}) + \dots [1 - \alpha(u(t - t_s) - u(t - t_e))]$	$-\pi \leq \varphi, \varphi_{2k}, \varphi_{2k+1} \leq \pi$ $0.1 \leq \alpha \leq 0.9$ $0.015 \leq \alpha_{2k} \leq 0.03$ $0.03 \leq \alpha_{2k+1} \leq 0.06$ $T \leq t_e - t_s \leq 9T$ $k = 1, 2, 3, \dots, 16$
Harmonic + Swell	$v(t) = \sin(\omega t + \varphi) + \alpha_{2k} \sin(2k\omega t + \varphi_{2k}) + \alpha_{2k+1} \sin((2k+1)\omega t + \varphi_{2k+1}) + \dots [1 + \alpha(u(t - t_s) - u(t - t_e))]$	$-\pi \leq \varphi, \varphi_{2k}, \varphi_{2k+1} \leq \pi$ $1.1 \leq \alpha \leq 1.8$ $0.015 \leq \alpha_{2k} \leq 0.03$ $0.03 \leq \alpha_{2k+1} \leq 0.06$ $T \leq t_e - t_s \leq 9T$ $k = 1, 2, 3, \dots, 16$
Flicker + Sag	$v(t) = [1 + \alpha \sin(2\pi\beta t)] \sin(\omega t + \varphi) [1 - \alpha(u(t - t_s) - u(t - t_e))]$	$0.1 \leq \alpha \leq 0.9$ $-\pi/4 \leq \varphi \leq \pi/4$ $T \leq t_s \leq 15T$ $T \leq t_e \leq 16T$
Flicker + swell	$v(t) = [1 + \alpha \sin(2\pi\beta t)] \sin(\omega t + \varphi) [1 + \alpha(u(t - t_s) - u(t - t_e))]$	$1.1 \leq \alpha \leq 1.8$ $-\pi/4 \leq \varphi \leq \pi/4$ $T \leq t_s \leq 15T$ $T \leq t_e \leq 16T$
Harmonic + sag + Flicker	$v(t) = \sin(\omega t + \varphi) + \alpha_{2k} \sin(2k\omega t + \varphi_{2k}) + \alpha_{2k+1} \sin((2k+1)\omega t + \varphi_{2k+1}) + \dots [1 - \alpha(u(t - t_s) - u(t - t_e))] \times [1 + \alpha \sin(2\pi\beta t)]$	$-\pi \leq \varphi, \varphi_{2k}, \varphi_{2k+1} \leq \pi$ $0.1 \leq \alpha \leq 0.9$ $0.015 \leq \alpha_{2k} \leq 0.03$ $0.03 \leq \alpha_{2k+1} \leq 0.06$ $T \leq t_e - t_s \leq 9T$ $k = 1, 2, 3, \dots, 16$ $0.05 \leq \alpha_n \leq 0.1$ $8 \leq \beta \leq 25$



شکل ۴: سیگنال‌های اغتشاشات کیفیت توان

هر قاب به دست آمده است. میزان هم‌پوشانی قاب‌ها ۱۵ نمونه است. پس از اتمام این مرحله، ضرایب تقریب به صورت دنباله‌ای از بردارهای ویژگی درآمده است. دلیل استفاده از این ضرایب، نتایج به دست آمده در آزمایش‌ها است.

۳-۳- تشکیل بردار هویت

در این مرحله، با توجه به توضیحات بیان شده در بخش ۲ برای هر سیگنال اغتشاش ورودی، بردار هویت تولید می‌شود. تعیین تعداد مخلوط‌های گاوسی در هنگام آموزش مدل پس‌زمینه جهانی بر اساس آزمون و خطا صورت می‌گیرد. با انجام آزمایش‌های متعدد، تعداد مخلوط‌های گاوسی ۳۲ در نظر گرفته شده است. پس از به دست آوردن آمارگان بام ولش و مدل کردن فضای تغییرپذیری کل،

پنجره‌ای با عرض کم (وضوح زمانی بالا) و برای آنالیز فرکانس‌های پایین، پنجره‌ای با عرض زیاد (وضوح فرکانسی بالا) بکار گرفته می‌شود. در تبدیل موجک گسسته، سیگنال در هر سطح به دو بخش تقسیم می‌شود. (۱) بخش حاصل از اعمال فیلتر بالاگذر برای به دست آوردن اطلاعات فرکانس‌های بالای سیگنال (از جمله نویز) که خروجی آن شامل ضرایب تقریب است. (۲) بخش حاصل از اعمال فیلتر پایین‌گذر برای به دست آوردن اطلاعات فرکانس پایین سیگنال که خروجی این بخش شامل ضرایب جزئیات است [۵، ۷]. در این مقاله برای استخراج ویژگی از تبدیل گسسته موجک و موجک مادر Daubechies' D2 استفاده شده است. این موجک فقط در یک سطح به سیگنال اعمال شده است. برای این کار سیگنال به قاب‌هایی شامل ۴۰ نمونه تقسیم شده و سپس ضرایب موجک برای

$$\Phi_{WCCN} = A_{WCCN}^T W \quad (17)$$

۳-۵- ماشین بردار پشتیبان

ماشین بردار پشتیبان یک روش یادگیری با نظارت برای طبقه‌بندی داده‌های دو کلاس است. در این روش طبقه‌بندی، هدف پیدا کردن ابر صفحه‌ای است که بیشترین فاصله را از داده‌های دو کلاس داشته باشد. توضیحات بیشتر این روش دسته‌بندی دو کلاس در مرجع [۳۳] آمده است. در این مقاله پس از تولید بردار هویت و انجام عملیات نرمال‌سازی، از ماشین بردار پشتیبان برای طبقه‌بندی داده‌ها استفاده شده است. از آنجائیکه ماشین بردار پشتیبان اساساً یک جداکننده دودویی است؛ برای بکارگیری آن در حل مسایل چندکلاسه، رهیافت کلی کاهش مسأله چندکلاسه به چندین مسأله دو کلاس است. به این صورت که ابتدا هر یک از مسایل دو کلاس با یک جداکننده دودویی حل می‌شود، سپس خروجی جداکننده‌های دودویی با هم ترکیب شده و به این ترتیب مسأله چندکلاسه (که در مقاله ۱۲ کلاس است) حل می‌شود. در این مقاله نیز این رویکرد بکار گرفته شده است.

۴- آزمایش‌ها و نتایج

در این بخش کارایی روش پیشنهادی مورد بررسی قرار گرفته است. نتایج به دست آمده در جدول ۲ ارائه شده است. علاوه بر این، با اضافه کردن نویز به سیگنال‌های اغتشاش سعی شده است تا عملکرد الگوریتم در شرایط واقعی نیز مورد بررسی قرار گیرد. نویز یک پدیده تصادفی و غیرقابل پیش‌بینی است. در مقالات مربوط به این حوزه معمولاً نویز سفید گاوسی در نظر گرفته می‌شود. در این مقاله نیز نویز سفید گاوسی با نسبت‌های سیگنال به نویز ۳۰، ۴۰ و ۵۰ دسی-بل توسط توابع محیط برنامه‌نویسی متلب به سیگنال اصلی اضافه شده است.

همانطور که در جدول ۲ قابل مشاهده است اغتشاشات Normal، Sag، Swell، Harmonic، Flicker در شرایط تمیز و نویزی ۴۰ و ۵۰ دسی‌بل با دقت صد درصد شناسایی شده است؛ اما شناسایی سیگنال‌های Notch و Spike با خطا همراه است. هر چند که سیگنال‌های تکی Sag، Swell، Harmonic بدون خطا شناسایی شده‌اند؛ ولی سیستم در تشخیص دو اغتشاش ترکیبی Harmonic + sag و Harmonic + swell مقداری خطا دارد. نتایج جدول ۲ نشان می‌دهد که حضور نویز در سایر اغتشاشات تأثیر قابل توجهی بر دقت شناسایی نداشته و می‌توان گفت روش پیشنهادی در مقابل نویز مقاوم است.

بردار هویت استخراج می‌شود. طی آزمایش‌های مختلف، ابعاد بردار هویت ۱۱۰ در نظر گرفته شد.

۳-۴- نرمال‌سازی بردارهای هویت

اعمال تکنیک‌های نرمال‌سازی بر روی بردار هویت، یکی از مراحل موثر در افزایش کارایی سیستم است. در این مرحله از تبدیلات ناهمبستگی و سفیدکنندگی^{۲۵} و الگوریتم نرمال‌سازی کوواریانس درون کلاسی^{۲۶} به منظور آماده‌سازی داده و کاهش تغییرات درون کلاسی استفاده شده است.

۳-۴-۱- تبدیل ناهمبستگی و سفیدکنندگی

تبدیل ناهمبستگی و سفیدکنندگی باعث ناهمبسته شدن و یکسان کردن تأثیر ویژگی‌ها می‌شود. برای اعمال این تبدیل‌ها ابتدا میانگین و کوواریانس بردارهای هویت بر روی کل مجموعه آموزش به دست می‌آید و سپس با استفاده از این مقادیر، تمام بردارهای هویت ناهمبسته و سفید می‌شوند. در گام بعد، داده‌ها به فضای واحد نگاشت می‌شوند. این مراحل در سال ۲۰۱۴ بر روی بردارهای هویت مجموعه دادگان NIST i-Vector Challenge تأثیر مثبتی زیادی به همراه داشته است [۳۰].

۳-۴-۲- نرمال‌سازی همبستگی درون کلاسی (WCCN)

هدف روش نرمال‌سازی همبستگی درون کلاسی [۲۳، ۳۱] مانند الگوریتم‌های تحلیل تمایز خطی^{۲۷} [۳۲] و از بین برنده جهت‌های مزاحم^{۲۸} [۳۲]، کاهش تغییرات درون کلاسی است. این روش اساساً برای بهبود کارایی در سیستم‌های تصدیق هویت گوینده مبتنی بر ماشین بردار پشتیبان پیشنهاد شده است. برای اجرای این تبدیل ابتدا ماتریس کوواریانس درون کلاسی با رابطه ۱۵ به دست می‌آید.

$$s_w = \frac{1}{S} \sum_{s=1}^S \frac{1}{n_s} \sum_{i=1}^{n_s} (w_{s,i} - \bar{w}_s) (w_{s,i} - \bar{w}_s)^T \quad (15)$$

در این رابطه S تعداد کل کلاس‌ها، n_s تعداد نمونه‌های کلاس S، $w_{s,i}$ نمونه نام از کلاس S و \bar{w}_s میانگین نمونه‌های کلاس S است. ماتریس تبدیل WCCN از طریق فاکتورگیری چولسکی از ماتریس کوواریانس درون کلاسی، مطابق رابطه ۱۶ به دست می‌آید.

$$s_w^{-1} = A_{WCCN} A_{WCCN}^T \quad (16)$$

در نهایت نمونه‌ها در فضای جدید به کمک رابطه ۱۷ به دست می‌آید که w بردار هویت و A_{WCCN}^T ماتریس انتقال است.

جدول ۲: ارزیابی روش پیشنهادی در شرایط تمیز و نویزی

برچسب کلاس	نوع اغتشاش	درصد دقت تشخیص		
		بدون نویز	نویز ۵۰ دسی بل	نویز ۴۰ دسی بل
C1	Normal	۱۰۰	۱۰۰	۹۹
C2	Sag	۱۰۰	۱۰۰	۱۰۰
C3	Swell	۱۰۰	۱۰۰	۱۰۰
C4	Notch	۹۸	۹۹	۱۰۰
C5	Harmonic	۱۰۰	۱۰۰	۹۹
C6	Flicker	۱۰۰	۱۰۰	۱۰۰
C7	Spike	۹۹	۹۸	۹۸
C8	Harmonic + sag	۹۸	۹۶	۹۵
C9	Harmonic + swell	۹۶	۹۷	۹۳
C10	Flicker + sag	۱۰۰	۱۰۰	۱۰۰
C11	Flicker + swell	۱۰۰	۱۰۰	۱۰۰
C12	Harmonic + sag + Flicker	۹۹	۹۸	۱۰۰
میانگین دقت کل کلاسها (بر حسب درصد)		۹۹/۲	۹۹	۹۸/۸

۴-۱- تأثیر مراحل نرمال سازی

مرکز کلاس متمرکز شوند و مرز دسته‌ها راحت‌تر شناسایی شود. از این شکل می‌توان به راحتی نتیجه گرفت که مرحله نرمال سازی باعث می‌شود ماشین بردار پشتیبان بهتر آموزش ببیند و به دقت بالاتری در شناسایی کلاس‌های اغتشاشات دست یافت که نتایج جدول ۳ مؤید این ادعا است.

به منظور بررسی کارایی الگوریتم‌های نرمال سازی، در یک آزمایش جدا تأثیر استفاده از این مراحل مورد بررسی قرار گرفته است. جدول ۳ دقت سیستم پیشنهادی، هنگام استفاده و عدم استفاده از مراحل نرمال سازی را در شرایط بدون نویز نشان می‌دهد. همان طور که در این جدول قابل مشاهده است، دقت سیستم پیشنهادی در صورت عدم استفاده از مراحل نرمال سازی از ۹۹/۲ درصد به ۹۳/۴ درصد کاهش پیدا کرده است. بنابراین می‌توان پی برد که اعمال مراحل نرمال سازی تأثیر مثبتی در نتیجه نهایی دارد.


جدول ۳: بررسی تأثیر اعمال مراحل نرمال سازی بر روی سیستم

پیشنهادی در محیط تمیز

نوع اغتشاش	بدون نرمال سازی	درصد دقت تشخیص	
		فقط تبدیل WCCN	فقط تبدیل ناهمبستگی و سفیدکنندگی
Normal	۱۰۰	۱۰۰	۱۰۰
Sag	۹۱	۹۷	۹۸
Swell	۱۰۰	۱۰۰	۱۰۰
Notch	۹۵	۹۵	۹۷
Harmonic	۹۵	۱۰۰	۹۹
Flicker	۱۰۰	۱۰۰	۱۰۰
Spike	۹۵	۹۶	۹۹
Harmonic + sag	۸۰	۹۵	۹۲
Harmonic + swell	۷۶	۹۷	۹۰
Flicker + sag	۹۹	۱۰۰	۹۹
Flicker + swell	۹۵	۹۸	۹۹
Harmonic + sag + Flicker	۹۵	۹۸	۹۹
میانگین دقت	۹۳/۴	۹۸	۹۷/۷

یک راه دیگر برای مشاهده تأثیر مراحل نرمال سازی، استفاده از الگوریتم t -SNE^{۲۹} برای نمایش بردارهای هویت نرمال شده در فضای دو بعدی است. الگوریتم t -SNE یک روش غیرخطی و ابزاری مناسب برای مصورسازی داده‌ها با ابعاد بالا است که با تغییراتی در روش جایگذاری همسایه تصادفی^{۳۰} ایجاد شده است. این الگوریتم قادر است به خوبی ساختار محلی و سراسری دادگان را یاد بگیرد [۳۵].

در شکل ۴ نتیجه مصورسازی بردارهای هویت دادگان آموزشی در دو حالت استفاده و عدم استفاده از مرحله نرمال سازی نشان داده شده است. در این شکل محور افقی مربوط به بعد اول و محور عمودی مربوط به بعد دوم ویژگی است. همان طور که در قسمت الف شکل نشان داده شده است داده‌های دوازده کلاس به گونه‌ای در فضا قرار گرفته‌اند که به سختی می‌توان مرز بین کلاس‌ها را شناسایی کرد؛ اما اجرای مرحله نرمال سازی باعث می‌شود داده‌های هر دسته در



شکل ۴: مصورسازی بردارهای هویت مجموعه داده آموزش با الگوریتم t-SNE (الف) عدم استفاده از مرحله نرمال‌سازی (ب) استفاده از مرحله نرمال‌سازی. محور افقی و عمودی به ترتیب بعد اول و بعد دوم ویژگی را نشان می‌دهد.

۴-۲- مقایسه با سایر روش‌ها

در این بخش با مقایسه نتایج این مقاله و نتایج گزارش شده در مراجع [۳، ۹، ۱۰، ۱۲، ۱۵، ۱۷، ۲۱، ۳۶، ۳۷] کارایی روش پیشنهادی مورد ارزیابی قرار می‌گیرد. از آنجائیکه مجموعه داده استاندارد در این حوزه وجود ندارد و سایر مراجع نیز برای تولید داده از مدل‌های ریاضی مانند آنچه در جدول ۱ وجود دارد استفاده می‌کنند؛ بنابراین نوع و تعداد اغتشاشات در مقالات مختلف یکسان نیست و نمی‌توان مقایسه دقیقی و عادلانه‌ای بین کارایی سیستم پیشنهادی و روش‌های سایر مقالات داشت. از این‌رو در جدول ۴ صرف نظر از نوع و تعداد اغتشاش، دقت کلی سایر مقالات ذکر شده است و در جدول ۵ فقط نتایج اغتشاشات مشترک بین مراجع جدول چهار و روش پیشنهادی آمده است. جهت عادلانه‌تر بودن مقایسه، نتایج براساس دقت کلی و اغتشاشات مشترک بیان شده است.

دقت روش پیشنهادی در هر دو شرایط عادی و نویزی از دقت گزارش شده در مراجع [۳، ۹، ۱۲، ۳۶، ۳۸] بالاتر است. این مقایسه

جدول ۴: مقایسه درصد دقت روش پیشنهادی با سایر مقالات بر

اساس دقت کلی				
تعداد اغتشاشات دسته‌بندی شده	دقت در شرایط بدون نویز	دقت با نویز	دقت با نویز	دقت با نویز
مرجع [۳]	۱۳	۹۸/۷	۹۷/۹	۹۸/۶
مرجع [۹]	۱۶	۹۸/۲	۹۷/۸	۹۸
مرجع [۱۲]	۱۰	۹۶/۱	۹۳/۵	۹۵/۹
مرجع [۱۵]	۸	۱۰۰	۹۳/۳	۹۸/۹
مرجع [۱۹]	۱۱	۹۸/۴	-	-
مرجع [۲۱]	۱۶	۹۷/۲	-	-
مرجع [۳۶]	۹	۹۸/۹	۹۷	۹۸/۲
مرجع [۳۷]	۹	۹۹/۶	۹۶/۶	۹۸/۹
مرجع [۳۸]	۱۴	۹۸/۸	۹۷	-
مرجع [۳۹]	۶	۹۹/۲	۹۷/۶	۹۹
روش پیشنهادی	۱۲	۹۹/۲	۹۸/۸	۹۸/۷

جدول ۵: مقایسه درصد دقت روش پیشنهادی با سایر مقالات براساس اغتشاشات مشترک

نام کلاس	روش پیشنهادی	مرجع [۳]	مرجع [۹]	مرجع [۱۲]	مرجع [۱۵]	مرجع [۱۷]	مرجع [۲۱]	مرجع [۳۶]	مرجع [۳۷]	مرجع [۳۶]	مرجع [۳۷]
Normal	۱۰۰	-	-	-	۱۰۰	-	۹۶	۱۰۰	۱۰۰	۱۰۰	۱۰۰
Sag	۱۰۰	۹۷/۳۳	۹۸/۶۷	۹۷/۶۵	۹۵	۹۸	۹۴	۹۸	۱۰۰	۹۸	۹۸
Swell	۱۰۰	۹۸/۶۷	۹۹/۳۳	۹۴/۱۲	۱۰۰	۱۰۰	۹۷	۱۰۰	۱۰۰	۱۰۰	۱۰۰
Notch	۹۸	۹۹/۳۳	۹۷/۳۳	۱۰۰	-	۱۰۰	۹۶	-	-	-	-
Harmonic	۱۰۰	۱۰۰	۹۹/۳۳	۱۰۰	۱۰۰	۱۰۰	۹۶	۹۸	۱۰۰	۹۸	۱۰۰
Flicker	۱۰۰	-	۹۸/۶۷	۸۳/۲۵	-	-	۹۷	۹۷	۱۰۰	۹۷	۹۷
Spike	۹۹	۱۰۰	-	۱۰۰	-	۹۴	۹۴	-	-	-	-
Harmonic + Sag	۹۸	-	-	۹۶/۱۰	۱۰۰	-	۹۲	-	-	-	-
Harmonic + Swell	۹۶	-	-	۹۷/۰۶	۹۷	-	۱۰۰	-	-	-	-
Flicker + Sag	۱۰۰	-	-	-	-	-	-	-	-	-	-
Flicker + Swell	۱۰۰	-	-	-	-	-	-	-	-	-	-
Harmonic + Sag + Flicker	۹۹	-	-	-	-	-	-	-	-	-	-
میانگین دقت	۹۹/۲	۹۹/۰۶	۹۸/۶۷	۹۶/۰۲	۹۸/۶۷	۹۸/۴	۹۹/۵	۹۹	۹۹/۶	۹۹	۹۹/۶

۵- جمع بندی و نتیجه گیری

در این مقاله کارایی بردار هویت در حوزه طبقه بندی اغتشاشات کیفیت توان مورد بررسی قرار گرفت. مهم ترین خصیصه استفاده از بردار هویت، رسیدن از یک دنباله بردارهای ویژگی به یک بردار بازنمایی با طول ثابت است که برخلاف اندازه کم آن در مقایسه با دنباله بردارهای ویژگی، از کارایی مطلوبی به خصوص در شرایط نویزی برخوردار است و امکان اعمال تبدیلات نرمال سازی را فراهم کرده است. برای کاهش تغییرات درون کلاسی، تبدیل ناهمبستگی و سفیدکنندگی و الگوریتم نرمال سازی همبستگی درون کلاسی (WCCN) بر روی بردار هویت اعمال گردید که بهبود در خور توجهی در دقت طبقه بندی به همراه داشت. نتایج شبیه سازی نشان می دهد که روش پیشنهادی در شناسایی اغتشاشات کیفیت توان کارایی مناسبی دارد. علاوه بر این با اضافه کردن نویز به سیگنال اغتشاش در دقت سیستم افت چشمگیری دیده نمی شود. در واقع روش پیشنهادی توانسته است بدون استفاده از الگوریتم های حذف نویز و با تکیه بر تولید بردار هویت تا حد زیادی با اثرات نویز که در شرایط واقعی وجود دارد مقابله کند.

مراجع

- [1] Mishra, S. and T. Nagwani, "A Review on Detection and Classification Methods for Power Quality Disturbances." International Journal of Engineering Science and Computing, 6,(۳) 2016.
- [2] Granados-Lieberman, D, et al, "Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review." IET Generation, Transmission & Distribution, 5(4): p. 519-529,2011.
- [3] Biswal, M. and P.K. Dash, "Measurement and classification of simultaneous power signal patterns with an S-transform variant and fuzzy decision tree." IEEE Transactions on Industrial Informatics, 9(4): p. 1819-1827. 2013.

در دو حالت دقت کلی (جدول چهار) و اغتشاشات مشترک (جدول پنج) صورت گرفته است. مرجع [۱۲] در شرایط نویز ۳۰ دسی بل کاهش دقت زیادی دارد. اگرچه در [۳۶] فقط ۹ اغتشاش مورد آزمایش قرار گرفته است، دقت روش پیشنهادی در هر دو حالت کلی و اغتشاشات مشترک، و در هر دو شرایط تمیز و نویزی از مرجع [۳۶] بهتر است. همان طور که در جدول ۵ قابل مشاهده است دقت روش پیشنهادی از دقت کلی در مرجع [۳۷] کمتر است اما باید توجه داشت که این روش فقط نه کلاس را مورد دسته بندی قرار داده است. اگر فقط اغتشاشات مشترک در نظر گرفته شود؛ یعنی مقایسه بر روی کلاس های (Normal، Sag، Swell، Flicker، Harmonic) صورت گیرد دقت روش پیشنهادی بهتر است. همچنین با حضور نویز ۳۰ و ۴۰ دسی بل، روش ارائه شده در [۳۷] کاهش دقت زیادی دارد.

همچنین دقت مرجع [۱۵] از دقت روش پیشنهادی بالاتر است اما این روش فقط هشت نوع اغتشاش را طبقه بندی کرده است و با اضافه شدن نویز ۳۰ دسی بل افت چشمگیری دارد و همچنین بر روی اغتشاشات مشترک (Normal، Sag، Swell، Harmonic، Harmonic+Sag، Harmonic + Swell) روش پیشنهادی ما دقت بالاتری دارد. مرجع [۳۹] با اینکه دقتی تقریباً برابر با روش پیشنهادی دارد اما تنها شش اغتشاشات ساده را طبقه بندی کرده است و به بررسی اغتشاشات ترکیبی نپرداخته است. مراجع [۱۹] و [۲۱] نیز توانسته اند به ترتیب ۱۱ و ۱۶ نوع اغتشاش را با دقت خوبی طبقه بندی کنند اما در این مراجع به بررسی تأثیر نویز در عملکرد سیستم اشاره ای نشده است.

- [22] Panigrahi, B.K., P.K. Dash, and J. Reddy, "Hybrid signal processing and machine intelligence techniques for detection, quantification and classification of power quality disturbances." *Engineering Applications of Artificial Intelligence*, 22(3): p. 442-454. 2009
- [23] Dehak, N., et al., "Front-end factor analysis for speaker verification." *IEEE Transactions on Audio, Speech, and Language Processing*, 19(4): p. 788-798. 2011
- [24] Ghahabi, O. and J. Hernando, "I-vector modeling with deep belief networks for multi-session speaker recognition." *network*, 20: p. 13. 2014.
- [25] Kinnunen, T. and H. Li, "An overview of text-independent speaker recognition: From features to supervectors." *Speech communication*, 52(1): p. 12-40. 2010.
- [26] Reynolds, D.A., T.F. Quatieri, and R.B. Dunn, "Speaker verification using adapted Gaussian mixture models." *Digital signal processing*, 10(1-3): p. 19-41. 2000.
- [27] Kenny, P., et al., "A study of interspeaker variability in speaker verification." *IEEE Transactions on Audio, Speech, and Language Processing*, 16(5): p. 980. 2008.
- [28] Lee, C.-Y. and Y.-X. Shen, "Optimal feature selection for power-quality disturbances classification." *IEEE Transactions on power delivery*, 26(4): p. 2342-2351, 2011.
- [29] Zeinali, H., et al., "Telephony text-prompted speaker verification using i-vector representation." in *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference on*. 2015.
- [30] Greenberg, C.S., et al., "The NIST 2014 speaker recognition i-vector machine learning challenge." in *Odyssey: The Speaker and Language Recognition Workshop*. 2014.
- [31] Hatch, A.O., S. Kajarekar, and A. Stolcke, "Within-class covariance normalization for SVM-based speaker recognition." in *Ninth international conference on spoken language processing*. 2006.
- [32] Solomonoff, A., W.M. Campbell, and I. Boardman, "Advances in channel compensation for SVM speaker recognition." in *Acoustics, Speech, and Signal Processing, 2005. Proceedings. (ICASSP'05). IEEE International Conference on*. 2005. IEEE
- [33] Reynolds, D.A., "Automatic speaker recognition: Current approaches and future trends." *Speaker Verification: From Research to Reality*, 5: p. 14-15. 2001.
- [34] Krishnan, M.H. and R. Viswanathan, "A new concept of reduction of Gaussian noise in images based on fuzzy logic." *Applied Mathematical Sciences*, 7(12): p. 595-602. 2013.
- [35] Maaten, L.v.d. and G. Hinton, "Visualizing data using t-SNE." *Journal of machine learning research*, 9(Nov): p. 2579-2605. 2008.
- [36] Moravej, Z., A. Abdoos, and M. Pazoki, "Detection and classification of power quality disturbances using wavelet transform and support vector machines." *Electric Power Components and Systems*, 38(2): p. 182-196. 2009.
- [37] Uyar, M., 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*, 36(3): p. 5962-5975. 2009.
- [38] Qiu, W., et al., "Power Quality Disturbances Recognition Using Modified S Transform and Parallel Stack Sparse Auto-encoder." *Electric Power Systems Research*, 174: p. 105876. 2019.
- [39] Jeba Singh, O., et al., "Robust detection of real-time power quality disturbances under noisy condition using FTDD features." *Automatika*, 60(1): p. 11-18. 2019.
- [4] Smith, J.C., G. Hensley, and L. Ray, "IEEE recommended practice for monitoring electric power quality." *IEEE Std*, p. 1159-1995. 1995.
- [5] Abdelsalam, A.A., A.A. Eldesouky, and A.A. Sallam, "Classification of power system disturbances using linear Kalman filter and fuzzy-expert system." *International Journal of Electrical Power & Energy Systems*, 43(1): p. 688-695. 2012.
- [6] Yang, H.-T. and C.-C. Liao, "A de-noising scheme for enhancing wavelet-based power quality monitoring system." *IEEE Transactions on Power Delivery*, 16(3): p. 353-360. 2001.
- [7] Abdel-Galil, T., et al., "Disturbance classification using hidden Markov models and vector quantization." *IEEE transactions on power delivery*, 20(3): p. 2129-2135. 2005.
- [8] Eristi, H. and Y. Demir, "The feature selection based power quality event classification using wavelet transform and logistic model tree." *Przeegląd Elektrotechniczny*, 88(7a): p. 43-48. 2012.
- [9] Masoum, M., S. Jamali, and N. Ghaffarzadeh, "Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks." *IET Science, Measurement & Technology*, 4(4): p. 193-205, 2010.
- [10] Hooshmand, R. and A. Enshaee, "Detection and classification of single and combined power quality disturbances using fuzzy systems oriented by particle swarm optimization algorithm." *Electric Power Systems Research*, 80(12): p. 1552-1561, 2010.
- [11] Huang, J., M. Negnevitsky, and D.T. Nguyen, "A neural-fuzzy classifier for recognition of power quality disturbances." *IEEE Transactions on Power Delivery*, 17(2): p. 609-616, 2002.
- [12] Panigrahi, B. and V.R. Pandi, "Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy k-nearest neighbour algorithm." *IET generation, transmission & distribution*, 3(3): p. 296-306. 2009.
- [13] Zhang, M., K. Li, and Y. Hu, "Classification of power quality disturbances using wavelet packet energy entropy and LS-SVM." *Energy and Power Engineering*, 2(03): p. 154. 2010.
- [۱۴] علی انشایی، رحمت‌اله هوشمند، "یک روش جدید برای شناسایی اغتشاشات کیفیت توان با استفاده از تبدیل S"، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۴، زمستان ۱۳۹۴.
- [15] Huang, N., et al., "Power quality disturbances classification based on S-transform and probabilistic neural network." *Neurocomputing*, 98: p. 12-23. 2012.
- [۱۶] سینا نظری، سعید اسماعیلی، فرزاد کریم زاده، "شناسایی و دسته‌بندی اغتشاشات تکی و ترکیبی کیفیت توان با استفاده از روش مبتنی بر تحلیل مولفه‌های مستقل"، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۸، شماره ۱، بهار ۱۳۹۷.
- [17] Thirumala, K., et al., "Tunable-Q wavelet transform and dual multiclass SVM for online automatic detection of power quality disturbances." *IEEE Transactions on Smart Grid*, 9(4): p. 3018-3028, 2018.
- [18] Wang, S. and H. Chen, "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network." *Applied Energy*, 235: p. 1126-1140. 2019.
- [19] Mohan, N., K. Soman, and R. Vinayakumar, "Deep power: Deep learning architectures for power quality disturbances classification." in *2017 International Conference on Technological Advancements in Power and Energy (TAP Energy)*. IEEE. 2017.
- [20] Shi, X., et al., "An independent component analysis classification for complex power quality disturbances with sparse auto encoder features." *IEEE Access*, 7: p. 20961-20966. 2019.
- [21] Thirumala, K., et al., "A classification method for multiple power quality disturbances using EWT based adaptive filtering and multiclass SVM." *Neurocomputing*. 334: p. 265-274. , 2019.

زیرنویس ها:

- | | |
|---|---|
| ¹ Power Quality Disturbances | ¹⁷ Joint Factor Analysis |
| ² Details | ¹⁸ Universal Background Model |
| ³ Approximation | ¹⁹ Baum-Welch |
| ⁴ Sequential Forward Selection | ²⁰ Total variability space |
| ⁵ Feed-forward Neural Network | ²¹ Gaussian Mixture Model |
| ⁶ Activation Function | ²² Expectation Maximization |
| ⁷ Particle Swarm Optimization | ²³ Super-vector |
| ⁸ Wavelet Packet Transform | ²⁴ Maximum a posteriori probability |
| ⁹ Independent Component Analysis | ²⁵ Whitening |
| ¹⁰ Discrete Wavelet Transform | ²⁶ Within-Class Covariance Normalization |
| ¹¹ Tunable-Q Wavelet Transform | ²⁷ Linear Discriminant Analysis |
| ¹² Convolutional Neural Network | ²⁸ Nuisance Attribute Projection |
| ¹³ Sparse Auto Encoder | ²⁹ t-Distributed Stochastic Neighbor Embedding |
| ¹⁴ Empirical Wavelet Transform | ³⁰ Stochastic Neighbor Embedding |
| ¹⁵ Identity vector | |
| ¹⁶ Embedding | |