نشریه مهندسی مکانیک دانشگاه تبریز، شماره پیاپی ۹۹، جلد ۵۲، شماره ۲، تابستان ۱۴۰۱، صفحه ۳۶۱-۳۷۰ – پژوهشی کامل DOI: 10.22034/jmeut.2020.11607

طبقه‌بندی چند عصبی برای چرخ‌دنده‌ها بر پایه‌ی تبدیل موجک گسسته، انتخاب مناسب‌ترین ویژگی و ماشین بردار پشتیبان بهبود یافته

سعید نظامیوند چگینی دکتری تخصصی، گروه مهندسی مکانیک، دانشکده مهندسی مکانیک، دانشگاه گیلان، رشت، ایران، saeed.nezamivand@gmail.com

احمد باقری* استاد، گروه مهندسی مکانیک، دانشکده مهندسی مکانیک، دانشگاه گیلان، رشت، ایران، bagheri@guilan.ac.ir

میلاد رمضانی دشتمیان کارشناسی ارشد، گروه مهندسی مکانیک، موسسه آموزش عالی احرار، رشت، ایران، ramezani.d992@yahoo.com

بهمن احمدی استادیار، گروه مهندسی مکانیک، دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران، b.ahmadi.mech@gmail.com

چکیده

عیب‌یابی چرخ‌دنده‌ها به کمک روش‌های هوشمند یکی از موضوعات رایج در تحقیقات اخیر می‌باشد. در این مقاله، روش ترکیبی جدیدی بر پایه‌ی تبدیل موجک گسسته، استخراج ویژگی در حوزه زمان و ماشین بردار پشتیبان چند کلاسه (Multi-SVM) ارایه شده است. سیگنال‌های ارتعاشی در سه حالت سالم، لب-پریدگی و ساییدگی دندانه جمع‌آوری شده‌اند. این سیگنال‌ها به کمک روش تبدیل موجک گسسته با توابع موجک مختلف تجزیه شده و مناسب‌ترین سطح تجزیه به کمک مفهوم همبستگی متقابل انتخاب شده‌اند. با به کارگیری توابع آماری مختلف در حوزه‌ی زمان، بردار ویژگی متناظر با هر نمونه سیگنال استخراج شده است. برای تعیین وضعیت جعبه‌دنده از روش SVM از نوع «یک در برابر یک» استفاده شده است. شناسایی وضعیت یک جعبه‌دنده وابسته به نوع ویژگی-های استخراج شده و چگونگی تنظیم پارامترهای SVM می‌باشد. از این رو، در این مطالعه برای شناسایی حساس‌ترین ویژگی‌ها به حضور عیب و نوع آن و تعیین پارامترهای بهینه روش SVM از الگوریتم بهینه‌سازی ازدحام ذرات استفاده شده است. نتایج نشان می‌دهند که با بهبود ماتریس ویژگی و روش طبقه-بندی SVM، دقت شناسایی شرایط جعبه‌دنده به طور قابل ملاحظه‌ای افزایش می‌یابد.

واژه‌های کلیدی: عیب‌یابی، تبدیل موجک، استخراج ویژگی، ماشین بردار پشتیبان چند کلاسه، الگوریتم بهینه‌سازی ازدحام ذرات.

Multi-Fault Classification for Gears Based on Discrete Wavelet Transform, Best Features Selection and Improved Support Vector Machine

S. Nezamivand Chegini Faculty of Mechanical Engineering, University of Guilan, Rasht, Iran.
A. Bagheri Faculty of Mechanical Engineering, University of Guilan, Rasht, Iran.
M. Ramezani Dashtemian Mechanical Engineering, Ahrar Institute and Higher Education, Rasht, Iran
B. Ahmadi Faculty of Engineering, University of Kurdistan, Sanandaj, Iran

Abstract

Intelligent fault detection diagnosis methods are one of the common topics in recently investigations. In this paper, a new hybrid technique is presented based on discrete wavelet transform (DWT) and multi – class support vector machine (Multi-SVM). The considered vibrational signals are collected in three conditions: normal, chipped tooth and worn teeth. These signals are decomposed using DWT methods with different wavelet base functions and the most appropriate level of decomposition are selected by the cross - correlation concept. The feature vector for each sample is extracted using different time domain statistical functions. «One – against - one» support vector machine (SVM-OAO) is utilized for detecting the gearbox conditions. The condition recognition of a gearbox is depended on the extracted features type and setting the SVM parameters. Therefore, in this study, particle swarm optimization (PSO) is used for identifying the most sensitive features to the defect and its type and determining the optimal parameters of SVM method. The obtained results show that the identification accuracy of the gearbox conditions is significantly increased with improving the feature matrix and the SVM classifier method.

Keywords: Fault Detection, Wavelet Transform, Feature Extraction, Multi Class Support Vector Machine, Particle Swarm Optimization Algorithm

۱- مقدمه

چرخدنده‌ها، به طور گسترده‌ای در ماشین‌های دوار استفاده شده و خرابی آن‌ها یکی از دلایل اصلی شکست[1] ماشین‌ها می‌باشد. پایش وضعیت به کمک تحلیل سیگنال‌های ارتعاشی، یکی از رایج‌ترین روش-ها برای استخراج اطلاعات مهم به منظور شناسایی وضعیت چرخدنده‌ها و عیوب احتمالی آن‌ها می‌باشد. در تحلیل ارتعاشات، نشانه‌ها و مولفه-هایی بررسی می‌شود که به عیب خاصی حساس بوده و تغییر می‌کنند. روش‌های مختلفی در حوزه زمان، فرکانس و زمان – فرکانس جهت پردازش سیگنال‌های ارتعاشی مورد استفاده قرار می‌گیرند. تکنیک‌های حوزه‌ی زمان و فرکانس به عنوان نخستین روش‌های تشخیصی در

[1] Failure

* نویسنده مکاتبه کننده، آدرس پست الکترونیکی: bagheri@guilan.ac.ir

تاریخ دریافت: ۹۷/۱۰/۰۱
تاریخ پذیرش: ۹۹/۰۹/۲۴

زمینه‌ی عیب‌یابی در نظر گرفته می‌شوند. روش‌های زمان - فرکانس از جمله تکنیک‌های مفید برای استخراج ویژگی‌ها و مولفه‌های فرکانسی متغیر با زمان از سیگنال‌های غیرایستا به شمار می‌آیند. روش‌های تبدیل موجک (WT)[1] و تجزیه مود تجربی (EMD)[2] از جمله روش‌های رایج در حوزه زمان - فرکانس هستند که یک سیگنال پیچیده و غیرایستا را به تعدادی مولفه‌ی اصلی تجزیه می‌کنند. در واقع، روش EMD، یک ابزار تطبیقی برای تحلیل سیگنال‌های ارتعاشی غیرایستا است [۱ و ۲].

پس از مرحله استخراج ویژگی، از روش‌های شناسایی الگو[3] برای پیش‌بینی حالت ماشین‌های دوار استفاده می‌شود. در اکثر پژوهش‌هایی که در ادامه به آن‌ها اشاره خواهد شد، از روش‌های مختلفی نظیر شبکه عصبی مصنوعی[4] (ANN) و ماشین بردار پشتیبان[5] به منظور شناسایی وضعیت سیستم و طبقه‌بندی عیوب استفاده می‌شود.

بِن‌علی و همکاران با استفاده از روش EMD، ویژگی‌هایی را از سیگنال‌های غیرخطی و غیرایستا استخراج نموده‌اند. سپس، از این ویژگی‌ها برای آموزش شبکه‌ی عصبی مصنوعی و دسته‌بندی عیوب یاتاقان استفاده کرده‌اند [۳]. جدلینسکی و جوناک [۴] روشی برای تشخیص زودهنگام عیب در جعبه‌دنده بر پایه‌ی SVM ارایه داده‌اند و از شبکه‌های عصبی مصنوعی به منظور ارزیابی روش خود استفاده کرده‌اند. آن‌ها به کمک تبدیل موجک پیوسته[6]، سیگنال‌های ارتعاشی را به ضرایب موجک تجزیه نموده‌اند. سپس، مقیاس‌ها و ضرایبی به عنوان ورودی‌های شبکه‌های ANN و SVM انتخاب شده‌اند که دارای مقادیر بزرگی هستند. با توجه به این که روش‌های شناسایی الگو دارای متغیرهایی هستند که باید تنظیم شوند و از طرفی تمامی ویژگی‌های آماری، برای عیب‌یابی مناسب نیستند، بنابراین به کارگیری یک الگوریتم بهینه‌سازی[7] به منظور بهبود روش‌های شناسایی الگو و انتخاب مناسب‌ترین ویژگی آماری و حساس به عیب ضروری به نظر می‌رسد. برای مثال، راجِسواری و همکاران [۵] با استفاده از تبدیل موجک، سیگنال‌های ارتعاشی جعبه‌دنده را پیش‌پردازش و سپس ویژگی‌های آماری مختلفی را محاسبه کرده‌اند. آن‌ها با استفاده از الگوریتم ژنتیک، ویژگی‌های پر اهمیت را انتخاب نموده‌اند. در نهایت، از ویژگی‌های انتخاب شده به عنوان ورودی شبکه عصبی استفاده کرده‌اند. بُردُلوی و تیواری در [۶ و ۷] یک روش طبقه‌بندی چند کلاسه را برای تعیین عیوب چرخدنده‌ها به کمک ماشین بردار پشتیبان ارائه داده‌اند. آن‌ها قبل از یادگیری و تست نهایی SVM، پارامترهای این شبکه را توسط الگوریتم‌های جستجوی شبکه، ژنتیک و زنبور عسل بهینه نموده‌اند. سپس توابع آماری مانند کشیدگی[8]، انحراف معیار و چولگی[9] استخراج شده از حوزه‌ی فرکانس و ضرایب تبدیل موجک پیوسته و تبدیل موجک گسسته، ویژگی‌هایی بوده‌اند که به عنوان ورودی SVM استفاده شده‌اند. آن‌ها در کار دیگری با بهبود تکنیک SVM، روشی برای طبقه‌بندی عیوب مختلف در یاتاقان‌ها ارائه داده‌اند [۸]. در این تحقیق، قبل از انجام مراحل آموزش و تست نهایی طبقه‌بندی کننده، پارامترهای SVM توسط الگوریتم‌های ژنتیک، زنبور عسل و روش جستجوی شبکه‌ای بهینه شده‌اند. عیب رینگ داخلی، عیب رینگ خارجی، عیب المان ساچمه و شرایط نرمال یاتاقان، حالات مختلفی بوده‌اند که در این مطالعه در نظر گرفته شده‌اند. همچنین، برای دسته‌بندی عیوب از ویژگی‌های سیگنال ارتعاشی در حوزه‌ی زمان مانند کشیدگی، انحراف معیار و چولگی استفاده شده است. لیو و همکاران یک روش ترکیبی و هوشمند برای طبقه‌بندی چندین عیب در یاتاقان‌های غلتشی ارائه کرده‌اند که بر پایه‌ی تجزیه‌ی مود تجربی (EMD)، تکنیک ارزیابی فاصله، ماشین بردار پشتیبان با تابع هسته‌ی موجک[10] و الگوریتم بهینه‌سازی PSO می‌باشد [۹]. دالین و لیونگ به منظور شناسایی عیب در یک جعبه‌دنده، روش شناسایی الگوی SVM با تابع هسته گوسی را به کمک الگوریتم بهینه‌سازی کولنی مصنوعی زنبور عسل[11]، بهینه نموده‌اند. آن‌ها با استفاده از روش تجزیه مود تجربی کلی، ویژگی‌هایی را به عنوان ورودی SVM بهینه شده، استخراج کرده‌اند [۱۰]. هوانگ و همکاران از تبدیل بسته‌ای موجک بهبود یافته[12] برای استخراج ویژگی از سیگنال‌های ارتعاشی مربوط به یک مجموعه چرخ‌دنده استفاده نموده‌اند. آن‌ها از این ویژگی‌ها با ابعاد بالا به عنوان ورودی روش انتخاب ویژگی مجموعه‌های ناهموار[13] و حذف ویژگی‌های نامرتبط با عیب استفاده نموده‌اند. سپس، با به کارگیری الگوریتم ژنتیک، مجموعه ویژگی بهینه را برای عیب‌یابی جعبه‌دنده تعیین کرده‌اند [۱۱]. یو و همکاران به منظور بهبود دقت عیب‌یابی در یاتاقان‌ها در سرعت‌های مختلف، تکنیکی ارایه نموده‌اند که حاصل ترکیب یک روش استخراج ویژگی جدید و یک روش کاهش ابعاد ماتریس ویژگی بهبود یافته می‌باشد. آن‌ها سیگنال‌های ارتعاشی را به کمک روش EMD به مولفه‌های ساده‌تری تجزیه نموده و به منظور تشکیل ماتریس ویژگی، مشخصه‌های آماری این مولفه‌ها را استخراج نموده‌اند. سپس، با ترکیب روش K- میانگین[14] و انحراف معیار مجموعه ویژگی، موثرترین ویژگی‌ها انتخاب شده‌اند. آن‌ها ابعاد فضای ویژگی را به کمک روش تحلیل تفکیک کننده‌ی فیشر محلی[15] (LFDA) کاهش داده و در نهایت از الگوریتم SVM برای شناسایی شرایط حاکم بر یاتاقان استفاده نموده‌اند [۱۲].

دراین مقاله از تبدیل موجک گسسته با توابع پایه‌ای موجک مختلف برای تجزیه سیگنال‌های ارتعاشی استفاده شده است. از آنجایی که تنها برخی از سطوح حاصل از تجزیه شامل اطلاعات مفیدی از سیگنال هستند و بقیه ممکن است شامل اطلاعات غیرمرتبط و یا نویز باشند، در این مطالعه مشابه مرجع [۱۳] از مفهوم همبستگی متقابل برای انتخاب پرمعنی‌ترین مولفه‌های حاصل از تجزیه استفاده شده است. از طرفی در اکثر روش‌های ارایه شده در گذشته مانند [۱۴ و

[1] Wavelet Transform (WT)
[2] Empirical Mode Decomposition (EMD)
[3] Pattern Recognition Methods
[4] Artificial Neural Network (ANN)
[5] Support Vector Machine (SVM)
[6] Continuous Wavelet Transform (CWT)
[7] Optimization Algorithm
[8] Kurtosis
[9] Skewness
[10] Wavelet Support Vector Machine (WSVM)
[11] Artificial Bee Colony (ABC)
[12] Improved Wavelet Packet Transform (IWPT)
[13] Rough Sets Method (RS)
[14] K-means
[15] Local Fisher Discriminant Analysis (LFDA)

۱۵]، بدون توجه به این که کدام ویژگی قابلیت آشکارسازی عیب را به خوبی دارد، از یک یا چند ویژگی در کارهای خود استفاده کرده‌اند. اما، استخراج ویژگی‌های مناسب که قابلیت آشکارسازی عیب را به خوبی داشته باشند، می‌تواند تا حد بسیار زیادی موجب افزایش دقت طبقه-بندی شود. یکی از اهداف این مقاله ارایه رویکردی برای انتخاب مناسب‌ترین ویژگی با توجه به نوع سطح تجزیه به منظور تفکیک بهتر شرایط حاکم بر مجموعه جعبه‌دنده می‌باشد.

روش جدید ارائه شده در این مقاله، یک رویکرد عیب‌یابی هوشمند ترکیبی است که بر پایه‌ی تبدیل موجک گسسته، انتخاب مجموعه ویژگی بهینه و بهبود طبقه‌بند SVM توسط الگوریتم PSO می‌باشد. از آنجایی که کیفیت اطلاعات استخراج شده توسط تبدیل موجک به شدت وابسته به توابع پایه‌ی موجک و تعداد سطوح تجزیه سیگنال می-باشد، بنابراین، یکی از اهداف این مقاله انتخاب توابع موجک مناسب و تعداد سطوح تجزیه بهینه به منظور استخراج ویژگی‌های پرمعنی از داده‌های ارتعاشی است. علاوه براین، طیف وسیعی از ویژگی‌های آماری در حوزه زمان از سطوح تجزیه بهینه استخراج شده‌اند. سپس، با بهره-گیری از الگوریتم بهینه‌سازی PSO، مناسب‌ترین ویژگی‌ها (یا ماتریس ویژگی بهنیه) انتخاب شده و دقت روش طبقه‌بند SVM در تشخیص شرایط حاکم بر چرخ‌دنده بهبود یافته است. به طور خلاصه، نوآوری‌های این مطالعه را می توان به شرح زیر بیان کرد:

- ارائه رویکردی به منظور تعیین مناسب‌ترین توابع موجک و سطوح تجزیه حاصل از آن‌ها
- بهره‌گیری از الگوریتم فرا ابتکاری PSO به منظور انتخاب ویژگی‌های پر معنی و تشکیل ماتریس ویژگی بهینه
- ارائه رویکردی که به طور هم‌زمان توسط الگوریتم PSO، ماتریس ویژگی بهینه را به عنوان ورودی SVM تشکیل داده و این طبقه‌بند را بهبود دهد.

این مقاله در ۱۰ بخش تدوین شده است: در بخش ۲، مجموعه آزمایشگاهی معرفی شده است. در بخش ۳، به نظریه حاکم بر روش تبدیل موجک گسسته پرداخته شده است. در بخش‌های ۴ و ۵ به ترتیب ویژگی‌های استخراج شده در حوزه زمان و ماشین بردار پشتیبان آمده‌اند. در بخش ۶ مفهوم همبستگی متقابل به منظور انتخاب مناسب‌ترین مولفه‌های یک سیگنال ارایه شده است. در بخش ۷ به ارایه الگوریتم بهینه‌سازی ازدحام ذرات پرداخته شده است. در بخش ۸ جزئیات روش پیشنهادی در این مقاله ارایه گردیده و در بخش ۹ نیز به تحلیل نتایج حاصل از این مقاله پرداخته شده است. در نهایت، مقاله در بخش ۱۰ نتیجه‌گیری شده است.

۲- مجموعه آزمایشگاهی

در این پژوهش، از داده‌های آزمایشگاهی دانشگاه صنعتی امیر کبیر (پلی تکنیک تهران) استفاده شده است. در شکل ۱ این مجموعه آزمایشگاهی نشان داده شده است. جعبه‌دنده توسط یک الکتروموتور سه فاز با سرعت نامی ۱۴۲۰ rpm دوران می‌کند. پینیون (N_1= ۱۵) و چرخ‌دنده (N_2 = ۱۱۰)، نسبت سرعت ۱: ۷٫۳۳ را برای جعبه‌دنده تولید می‌کند. سیگنال‌های ارتعاشی برای سه حالت سالم، لب‌پریدگی دندانه و ساییدگی دندانه پینیون در مدت ۱۰ ثانیه با نرخ فرکانس نمونه برداری ۱۰ KHz جمع‌آوری شده‌اند [۱۶]. در حالت لب‌پریدگی دندانه، ۵۰ درصد از قسمت بالایی دندانه پینیون تا سطح گام دنده حذف گردیده است. در حالت ساییدگی دندانه مواد سطح و پهلوی سه دندانه‌ی پینیون با ضخامت ۰٫۵ میلی‌متر حذف شده است. شکل‌های ۲ و ۳ به ترتیب شرایط مختلف چرخ‌دنده و سیگنال‌های ارتعاشی متناظر با آن‌ها را نشان می‌دهند.

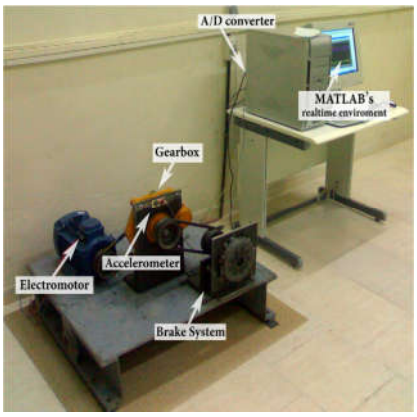

شکل ۱- مجموعه آزمایشگاهی دانشگاه صنعتی امیرکبیر[۱۶]

شکل ۲- شرایط چرخ‌دنده‌ها: چرخ‌دنده‌ی سمت راست: لب‌پریدگی، چرخ‌دنده‌ی میانی: ساییدگی و چرخ‌دنده‌ی سمت چپ: سالم [۱۶]

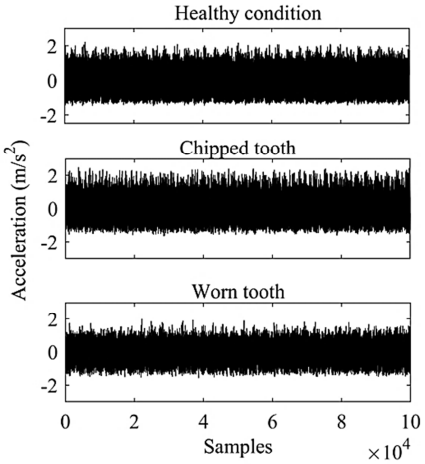

شکل ۳- سیگنال‌های ارتعاشی برای شرایط مختلف: سالم، لب‌پریدگی دندانه و ساییدگی دندانه [۱۶]

۳- تبدیل موجک

در این بخش، به طور خلاصه نظریه موجک معرفی شده است. جزئیات بیشتر را می‌توان در [۱۷] یافت.

۳-۱- موجک‌ها

موجک‌ها توابعی نوسانی با طول محدود هستند که دارای مقادیر حقیقی و یا مختلط و با میانگین صفر می‌باشند.

۳-۲- موجک پیوسته و تبدیل موجک پیوسته

اگر فرض شود که $\psi(x)$ موجک مادر باشد، خانواده‌ای از موجک‌های پیوسته $\psi_{u,s}(x)$ را می‌توان با مقیاس کردن با s و انتقال دادن به u تولید نمود. به عبارت دیگر:

$$\psi_{u,s} = \frac{1}{\sqrt{s}}\psi\left(\frac{x-u}{s}\right) \qquad (۱)$$

تبدیل موجک پیوسته تابع $f(x)$ در مقیاس s و در محل x به صورت زیر تعریف می‌شود:

$$CWT(u,s) = < f, \psi_{u,s} > = \int_{-\infty}^{+\infty} f(x)\, \frac{1}{\sqrt{s}}\, \psi^*\left(\frac{x-u}{s}\right) dx \qquad (۲)$$

عبارت $CWT(u,s)$ به عنوان ضریب موجک تابع $f(x)$ برای موجک $\psi_{u,s}(x)$ شناخته می‌شود. ψ^* مزدوج مختلط ψ می‌باشد.

۳-۳- موجک‌های گسسته و تبدیل موجک گسسته

مشابه موجک‌های پیوسته، موجک‌های گسسته را می‌توان توسط انتقال دادن و مقیاس کردن موجک مادر به دست آورد. در این موارد، اگر ψ موجک مادر، j پارامتر مقیاس و k پارامتر انتقال باشد، آنگاه:

$$\psi_{j,k} = |a_0|^{-\frac{j}{2}}\psi\left(a_0^{-j}x - kb_0\right) \quad j,k \in Z \qquad (۳)$$

تبدیل موجک گسسته به صورت زیر تعریف می‌شود:

$$d_{j,k} = < f, \psi_{j,k} > = |a_0|^{-\frac{j}{2}} \int_{-\infty}^{+\infty} \psi^*\left(a_0^{-j}x - kb_0\right)\, dx \qquad (۴)$$

به طور مشابه، تابع مقیاس گسسته به صورت زیر تعریف می‌شود:

$$\phi_{j,k} = |a_0|^{-\frac{j}{2}}\phi\left(a_0^{-j}x - kb_0\right) \quad j,k \in Z \qquad (۵)$$

به همین ترتیب، تجزیه موجک بر پایه‌ی تابع مقیاس گسسته به صورت زیر به دست می‌آید:

$$a_{j,k} = < f, \phi_{j,k} > = |a_0|^{-\frac{j}{2}} \int_{-\infty}^{+\infty} \phi^*\left(a_0^{-j}x - kb_0\right)\, dx \qquad (۶)$$

معادلات (۴) و (۶) به ترتیب ضرایب جزئیات و ضرایب تقریب گسسته هستند.

۴- استخراج ویژگی در حوزه‌ی زمان

برای مقایسه کردن و شناسایی حالت ماشین در حوزه‌ی زمان، از ویژگی‌های معنادار آماری استفاده می‌شود [۱۸]. در این پژوهش جهت تشکیل ماتریس ویژگی از ۱۶ نوع ویژگی آماری مطابق جدول ۱ استفاده شده است.

۵- ماشین بردار پشتیبان

این الگوریتم از مجموعه‌ای به نام مجموعه داده‌های آموزش، یاد می‌گیرد و سعی می‌کند تا آن را جامع کرده و پیش‌بینی‌های صحیحی را با توجه به داده‌های جدید، به دست آورد. در ادامه مفاهیم پایه‌ای روش ماشین بردار پشتیبان تشریح شده‌اند.

داده‌های x_i $(i = 1, \dots, n)$ را در نظر بگیرید که به صورت کلاس‌های مثبت $(y_i = +1)$ یا منفی $(y_i = -1)$ برچسب شده‌اند. ابر صفحه جداکننده بهینه $f(x) = \boldsymbol{w}.\boldsymbol{x} + b$ را می‌توان با حل مسئله بهینه‌سازی زیر به دست آورد [۱۹]:

$$\min\left(\frac{1}{2}\|\boldsymbol{w}\|^2 + C\sum_{i=1}^{N}\xi_i\right)$$
$$subject\ to: \begin{cases} y_i(\boldsymbol{w}.\boldsymbol{x} + b) \geq 1 - \xi_i & i = 1, \dots, N \\ \xi_i \geq 0 \end{cases} \qquad (۷)$$

که ξ_i فاصله‌ی بین ابرصفحه و نمونه‌های قرار گرفته در طرف اشتباه ابرصفحه را اندازه می‌گیرد و C پارامتر جریمه است. با معرفی ضرایب لاگرانژ α_i و β_i برای قیود مساله (۷) و تعیین معادلات زینی، یک مساله بهینه‌سازی درجه دوم به دست می‌آید. اگر α_i^* مقدار بهینه‌ای برای پارامتر α_i باشد که با حل این معادله به دست می‌آید، آنگاه می‌توان پارامترهای بهینه‌ی ابرصفحه را محاسبه نمود. در نهایت، تابع طبقه‌بندی را می‌توان به صورت زیر نوشت:

$$f(\boldsymbol{x}) = sign\left(\sum_{i=1}^{N}\alpha_i y_i\left(\boldsymbol{x}_i.\boldsymbol{x}_j\right) + b\right) \qquad (۸)$$

در حالتی که در فضای ورودی، دسته‌بندی غیرخطی است، می‌توان روش SVM را با نگاشت داده‌ها به فضای ویژگی با ابعاد بالاتر اعمال نمود. در این حالت می‌توان از یک تابع غیرخطی همچون $\boldsymbol{\phi}(\boldsymbol{x}) = (\varphi_1(\boldsymbol{x}), \dots, \varphi_l(\boldsymbol{x}))$ برای نگاشت بردار ورودی n بعدی x به فضای ویژگی l بعدی استفاده نمود به طوری که تابع تصمیم به فرم زیر تغییر می‌یابد:

$$f(\boldsymbol{x}) = sign\left(\sum_{i,j=1}^{N}\alpha_i y_i\, K(\boldsymbol{x}_i, \boldsymbol{x}_j) + b\right) \qquad (۹)$$

که $K(\boldsymbol{x}_i, \boldsymbol{x}_j)$ تابع هسته بوده و به صورت زیر تعریف می‌شود:

$$K(\boldsymbol{x}_i, \boldsymbol{x}_j) = \left(\boldsymbol{\phi}(\boldsymbol{x}_i).\boldsymbol{\phi}(\boldsymbol{x}_j)\right) \qquad (۱۰)$$

تابع هسته‌ای که در کاربردهای عملی SVM به طور گسترده‌ای استفاده می‌شود، تابع پایه شعاعی[1] است که صورت زیر تعریف می‌شود:

$$K(\boldsymbol{x}.\boldsymbol{x}_j) = \exp\left(-\frac{\|x - \boldsymbol{x}_j\|^2}{\sigma^2}\right) \qquad (۱۱)$$

انتخاب پارامترهای جریمه C و σ، به شدت کارایی SVM را تحت تاثیر قرار می‌دهد. همان‌طور که خواهید دید در این مطالعه، از الگوریتم بهینه‌سازی PSO برای یافتن مقادیر بهینه‌ی این دو پارامتر استفاده خواهد شد.

گاهی اوقات، با مسایلی سروکار داریم که بیش از دو کلاس در آن‌ها وجود دارد. برای مثال، می‌توان به شناسایی عیب در ماشین‌های دواری اشاره نمود که دارای چندین منبع عیب هستند. در چنین شرایطی معمولا از دو نوع استراتژی برای ساخت SVM چند کلاسه[2]

[1] Radial Basis Function
[2] Multi – Class SVM

«یک در برابر همه[1]» و «یک در برابر یک[2]» استفاده می‌شود. در این مقاله تنها از نوع «یک در برابر یک» استفاده شده است.

۶- همبستگی متقابل

ضریب همبستگی ابزار آماری برای تعیین نوع و درجه رابطه یک متغیر کمی با متغیر کمی دیگر است. در واقع، ضریب همبستگی یکی از معیارهای مورد استفاده در تعیین همبستگی دو متغیر است که شدت رابطه و همچنین نوع رابطه (مستقیم یا معکوس) را نشان می‌دهد. اگر X سیگنال اول در زمان t_1 و C سیگنال دوم در زمان t_2 باشند و زمان تاخیر τ برابر باشد با: $\tau = t_2 - t_1$، ضریب همبستگی به صورت زیر محاسبه می‌شود [۱۳]:

$$\rho_{xc} = \frac{C_{xc}(\tau)}{\sigma_x \sigma_c} \tag{۱۲}$$

که C_{xc} (τ) کواریانس متقابل X(t)، σ_x واریانس استاندارد X(t) و σ_c واریانس استاندارد C(t) می‌باشند. X (t) و C (t) زمانی با هم رابطه کامل دارند که $\rho_{xc} = 1$ باشد. اگر X (t) و C (t) با هم هیچ رابطه‌ای نداشته باشند آنگاه: $\rho_{xc} = 0$

۷- الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی تجمعی ذرات یک تکنیک بهینه‌سازی بر پایه جمعیت است که از رفتار اجتماعی گروه‌های ماهی‌ها و پرندگان الهام گرفته شده است [۲۰]. در این الگوریتم از افرادی که ذره نامیده می‌شوند، برای یافتن بهترین پاسخ در فضای جستجو استفاده می‌شود. هر ذره در این الگوریتم، یک پاسخ از مساله مورد نظر است. برای یک مساله d – بعدی، هر ذره دارای دو بردار سرعت و موقعیت می‌باشد. الگوریتم PSO شامل دو مرحله مقداردهی اولیه و محاسبات است. در فاز مقدار دهی اولیه، به هر ذره یک موقعیت اولیه و یک سرعت اولیه به صورت تصادفی اختصاص داده می‌شود. در فاز محاسبات، هر ذره برای یافتن موقعیت بعدی خود و حرکت در فضای جستجو، از بهترین تجربه شخصی خود ($\vec{X}_{pBest}$) و بهترین تجربه کل ذرات ($\vec{X}_{gBest}$) به صورت زیر استفاده می‌کند:

$$\vec{V}_i(t+1) = w\vec{V}_i(t) + c_1 r_1 \left(\vec{X}_{pBest_i} - \vec{X}_i(t)\right) + c_2 r_2 \left(\vec{X}_{gBest} - \vec{X}_i(t)\right) \tag{۱۳}$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \tag{۱۴}$$

که $\vec{V}_i(t+1)$ بردار سرعت ذره در تکرار t+1، $\vec{X}_i(t+1)$ بردار موقعیت ذره i ام است. c_1 ضریب یادگیری شخصی، c_2 ضریب یادگیری اجتماعی هستند. r_1 و r_2 دارای مقادیر تصادفی در بازه‌ی [۰،۱] هستند. در این مقاله، مقادیر c_1، c_2 و w مطابق مرجع [۲۰] در نظر گرفته شده‌اند. در فاز محاسبات با محاسبه مقدار تابع هدف در هر تکرار، $\vec{X}_{pBest}$ برای هر ذره و $\vec{X}_{gBest}$ یعنی بهترین پاسخ تعیین می‌شوند. این فرآیند تا برآورده شدن شرط خاتمه ادامه می‌یابد.

تعداد عملگرهای موجود در الگوریتم بهینه‌سازی ازدحام ذرات به مراتب کم‌تر از سایر الگوریتم‌های فرا ابتکاری می‌باشد. بنابراین، پیاده‌سازی این الگوریتم نسبت به الگوریتم‌هایی نظیر الگوریتم بهینه‌سازی ژنتیک ساده‌تر بوده و دارای حجم محاسبات کم‌تری می‌باشد. به همین دلیل در این مقاله از این الگوریتم در فرآیند عیب‌یابی مجموعه جعبه‌دنده استفاده شده است.

۸- روش پیشنهادی

روش هوشمند ارایه شده در این مقاله ترکیبی از روش‌های تبدیل موجک گسسته (DWT)، استخراج ویژگی در حوزه‌ی زمان، ماشین بردار پشتیبان چند کلاسه (SVM-OAO) و الگوریتم بهینه‌سازی ذرات (PSO) می‌باشد. در اینجا، هر سیگنال توسط روش DWT به سطوح مختلفی تجزیه می‌شود. برای این منظور از موجک‌های دبیشی[3] از مرتبه دهم (db10)، سیملت[4] مرتبه ۸ (Sym8)، کویفلتز مرتبه[5] ۸ (Coif8)، متعامد دوگانه[6] از مرتبه 6.8 (bior6.8)، معکوس متعامد دوگانه[7](rbio6.8)، مِیر گسسته[8] (dmey) و هاآر[9] برای تحلیل سیگنال‌های ارتعاشی استفاده شده است. در شکل ۴، یک نمونه سیگنال ارتعاشی به همراه ۵ سطح اول حاصل از اعمال روش DWT نشان داده شده است.

تمامی سطوح تجزیه به دست آمده از روش DWT، لزوماً دارای اطلاعات مناسبی از عیب نمی‌باشند. بنابراین، در اینجا برای انتخاب مناسب‌ترین سطح تجزیه، از مفهوم همبستگی متقابل بین سیگنال اصلی و هر سطح تجزیه استفاده شده است. هر چه قدر مقدار همبستگی متقابل بین یک سطح تجزیه خاص و سیگنال اصلی بزرگ‌تر باشد، دلالت بر اهمیت این سطح تجزیه در استخراج ویژگی‌های حساس به عیب دارد. برای مثال، همبستگی متقابل بین ضرایب موجک bior6.8 و سیگنال اصلی حالت لب‌پریدگی دندانه در جدول ۲ ارایه شده‌اند. مطابق این جدول، سطوح تجزیه d2، d3 و d4 دارای بیشترین مقدار ضریب همبستگی در بین تمامی سطوح هستند. به عبارت دیگر، چنانچه تنها از این سطوح در فرآیند پردازش سیگنال و استخراج ویژگی استفاده شود، به بخشی اعظمی از اطلاعات مفید سیگنال دست خواهیم یافت. از آنجایی که انتخاب نوع موجک، روند استخراج ویژگی به کمک تبدیل موجک را تحت تاثیر خود قرار می‌دهد، بنابراین در این مقاله ضریب همبستگی متقابل برای سه حالت سالم، لب‌پریدگی و سائیدگی دندانه به ازای توابع موجک مختلف محاسبه شده و سپس مناسب‌ترین سطوح تجزیه مطابق جدول ۳ انتخاب شده‌اند. در این مطالعه، تنها از سه سطحی که بیشترین ضریب همبستگی با سیگنال اصلی را دارند، به منظور استخراج ویژگی‌های آماری استفاده شده است.

در اینجا، از مشخصه‌های آماری جدول ۱ برای تشکیل ویژگی‌هایی که به حضور عیب و نوع آن‌ها حساس هستند، استفاده شده است. این ویژگی‌ها از سطوح تجزیه منتخب جدول ۳ مربوط به هر نمونه سیگنال استخراج شده‌اند. اما از آنجایی که ممکن است تمامی توابع آماری مزبور برای نمایان ساختن عیوب مختلف مناسب نباشند، در این

[1] One- Against -All (OAA)
[2] One- Against- One (OAO)

[3] Daubechies Wavelet (db)
[4] Symlet wavelet (Sym)
[5] Coiflet Wavelet (Coif)
[6] Biorthogonal Wavelet (bior)
[7] Reverse biorthogonal (rbio)
[8] Discrete Meyer (dmey)
[9] Haar

مطالعه، برای هر کدام از سطوح انتخاب شده، از بهترین ویژگی آماری استفاده شده است. فرم کلی ماتریس ویژگی به صورت زیر معرفی می‌گردد:

$$FM = \begin{bmatrix} f_{11} & f_{12} & f_{13} \\ \vdots & \vdots & \vdots \\ f_{n1} & f_{n2} & f_{n3} \end{bmatrix} \quad (۱۵)$$

که f_{ij} ها (i=1,2,3 و j=1,2,…,n) ویژگی متناظر با سطح تجزیه i ام و نمونه سیگنال j ام است. برای تشکیل ماتریس ویژگی رابطه (۱۵)، از میان توابع آماری جدول ۱، فقط از سه ویژگی که قادر به نمایش نشانه‌های عیوب مختلف در جعبه‌دنده هستند، استفاده خواهد شد. بنابراین، در این مقاله از الگوریتم بهینه‌سازی PSO برای استخراج f_{ij}ها و تعیین پارامترهای طبقه‌بندی کننده‌ی SVM استفاده شده تا دقت شناسایی عیوب به حداکثر برسد.

جدول ۱- ویژگی‌های آماری در حوزه زمان

ویژگی	فرمول	ویژگی	فرمول	ویژگی	فرمول
۱- میانگین	$\frac{1}{N}\sum_{i=1}^{N} x(i)$	۷- فاکتور شکل	$\frac{x_{RMS}}{\left(\frac{1}{N}\right)\sum_{i=1}^{N}\lvert x_i\rvert}$	۱۳- آنتروپی	$-\sum_{i=1}^{N} x_i^2 \log(x_i^2)$
۲- کشیدگی	$\frac{\frac{1}{N}\sum_{i=1}^{N}(x_i-\bar{x})^4}{\left(\frac{1}{N}\sum_{i=1}^{N}(x_i-\bar{x})^2\right)^2}$	۸- ریشه میانگین مربعات	$\sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}$	۱۴- فاکتور لقی	$\frac{Peak}{\left(\left(\frac{1}{N}\right)\sum_{i=1}^{N}\sqrt{\lvert x_i\rvert}\right)^2}$
۳- انحراف معیار	$\sqrt{\frac{1}{N-1}\sum_{i=1}^{N}(x_i-\bar{x})^2}$	۹- دامنه	$max(x_i)-min(x_i)$	۱۵- ضریب اوج	$\frac{\max(abs(x))}{RMS}$
۴- واریانس	$\frac{1}{N}\sum_{i=1}^{N}(x_i-\bar{x})^2$	۱۰- میانه	$x_{\left(\frac{N+1}{2}\right)}$	۱۶- انرژی	$\int \lvert x(t)\rvert^2\, dt$
۵- چولگی	$\frac{\frac{1}{N}\sum_{i=1}^{N}(x_i-\bar{x})^3}{\left(\frac{1}{N}\sum_{i=1}^{N}(x_i-\bar{x})^2\right)^{\frac{3}{2}}}$	۱۱- میانگین پیک	$mean(total\ peak\ value)$	در روابط این جدول، x(t) سیگنال ارتعاشی و $\bar{x}$ میانگین هر نمونه سیگنال می‌باشد.	
۶- اوج	$\max(\lvert x_i\rvert)$	۱۲- فاکتور ایمپالس	$\frac{Peak}{\left(\frac{1}{N}\right)\sum_{i=1}^{N}\lvert x_i\rvert}$		

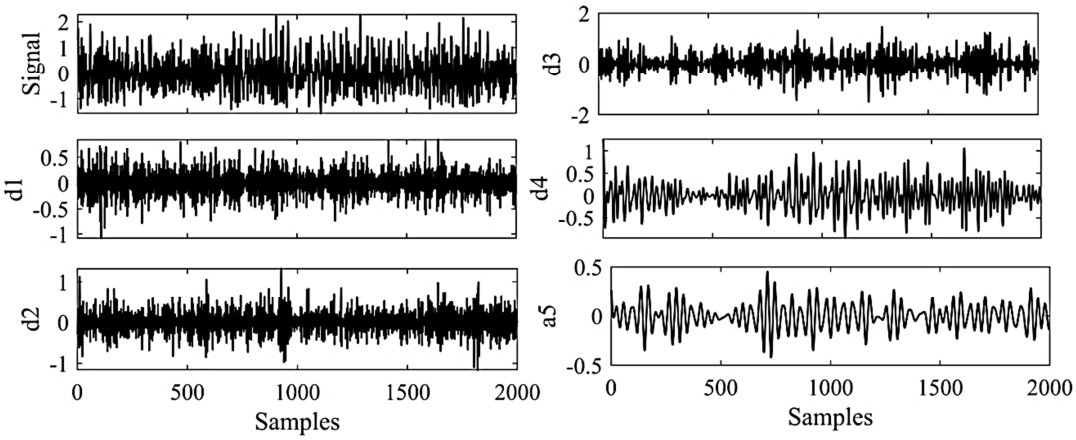

شکل ۴- نتایج تجزیه سیگنال ارتعاشی برای حالت لب‌پریدگی دندانه به کمک روش DWT و موجک bior6.8

جدول ۲ - ضرایب همبستگی بین سطح‌های تجزیه مختلف تابع موجک bior6.8 و سیگنال حالت لب‌پریدگی دندانه

سطح	مقدار	سطح	مقدار
d1	۰٫۳۷۸۹	d 7	۰٫۰۱۳۴
d2	۰٫۴۴۵۲	d8	۰٫۰۰۷۵
d3	۰٫۶۲۷۵	d9	۰٫۰۰۲۸
d4	۰٫۴۸۱۶	d10	۰٫۰۰۲۰
d5	۰٫۱۹۱۱	d11	۰٫۰۰۱۹
d6	۰٫۰۱۶۹	d12	۰٫۰۰۰۳

جدول ۳- سطح‌های تجزیه مناسب برای توابع موجک مختلف و شرایط مختلف

موجک	سائیدگی	لب‌پریدگی	سالم
هار	d1,d2,d3	d1,d2,d3	d1,d2,d3
دبیشی ۱۰	d2,d3,d4	d2,d3,d4	d1,d2,d3
سیملت ۸	d2,d3,d4	d2,d3,d4	d1,d2,d3
کویفلتز ۸	d2,d3,d4	d2,d3,d4	d1,d2,d3
متعامد دوگانه	d2,d3,d4	d2,d3,d4	d1,d2,d3
مِیِر گسسته	d2,d3,d4	d2,d3,d4	d1,d2,d3

مراحل روش پیشنهادی برای این پژوهش، به صورت زیر می‌باشند:

۱- هر سیگنال ارتعاشی به بخش‌هایی شامل ۱۲۵۰ نمونه داده تقسیم می‌شود.

۲- هر بخش از سیگنال مرحله‌ی ۱ توسط روش DWT به سطوح مختلفی تجزیه می‌شود.

۳- مناسب‌ترین سطوح توسط ضریب همبستگی متقابل انتخاب می‌شوند. با توجه به این که سیگنال‌های ارتعاشی مجموعاً به ۲۴۰ بخش تقسیم شده‌اند و تنها سه سطح اول با بیشترین ضریب همبستگی انتخاب می‌شوند، بنابراین، جمعاً ۳×۲۴۰ ضریب موجک به دست آمده است.

۴- شصت درصد از داده‌ها به «داده‌های آموزش» اختصاص یافته و مابقی برای «داده‌های تست نهایی» استفاده می‌شود.

۵- از سطوح تجزیه مربوط به داده‌های آموزش، ویژگی‌های آماری گفته شده در قسمت ۴، استخراج می‌شود.

۶- ماتریس ویژگی حاصل از مرحله‌ی قبل به دو مجموعه داده «داده‌های آموزش SVM» و «داده‌های اعتبارسنجی» تفکیک می‌شود.

۷- از مجموعه داده‌ی آموزش مرحله‌ی ششم برای ساخت طبقه‌بندی کننده‌ی SVM-OAO و از مجموعه داده‌ی اعتبارسنجی برای آموزش SVM استفاده می‌شود.

۸- برای انتخاب مناسب‌ترین ویژگی برای هر سطح تجزیه منتخب و پارامترهای ماشین بردار پشتیبان، از الگوریتم بهینه‌سازی ازدحام ذرات استفاده می‌شود. برای این منظور، تابع هدفی که باید کمینه شود، به صورت زیر تعریف می‌گردد:

$$\text{Fitness} = \frac{\text{Incorrectly Classified}}{Classified\ Sample} \times 100 \qquad (۱۶)$$

صورت این کسر تعداد داده‌هایی است که به درستی پیش‌بینی نشده‌اند و مخرج آن تعداد کل نمونه سیگنال‌های تست نهایی می‌باشد. متغیرهای تصمیم‌گیری در فرآیند بهینه‌سازی عبارتند از: پارامتر جریمه C، پارامتر تابع هسته ماشین بردار پشتیبان σ و نوع ویژگی[1]. کران‌های بالا و پایین پارامترهای C، σ و نوع ویژگی در جدول ۴ آمده‌اند. محدوده تغییرات متغیرهای C و σ مطابق مرجع [۶] در نظر گرفته شده است.

همان‌طور که در این مرحله گفته شد، به منظور بهبود دقت شناسایی عیب، از الگوریتم بهینه‌سازی PSO استفاده می‌شود. حال این سوال مطرح می‌شود که چرا در این مطالعه از روش‌های مبتنی بر گرادیان[2] برای حل مسئله عیب‌یابی استفاده نشده است. در روش تندترین شیب و به طور کلی روش‌های مبتنی بر مشتق از مشتقات تابع هدف برای حل مسایل بهینه‌سازی استفاده می‌شود. در این روش‌ها حل مسئله بهینه‌سازی به شدت به نقطه شروع وابسته است به طوری که اگر نقطه شروع حل مناسب نباشد منجر به یافتن نقاط بهینه محلی به جای نقاط بهینه جهانی می‌شود. بدیهی است اگر تابع هدف به شکل صریح قابل بیان نباشد و یا مشتق‌پذیر نباشد، نمی‌توان از روش‌های مبتنی بر گردایان برای حل مسایل بهینه‌سازی استفاده کرد. در حالی که در الگوریتم‌های بهینه‌سازی فرا ابتکاری (از جمله PSO) تنها از مقادیر خود تابع هدف استفاده می‌شود و فاقد محدودیت‌هایی از قبیل نیاز به شکل صریح تابع هدف و مشتق‌پذیر بودن آن می‌باشد. این روش‌ها از مجموعه‌ای از نقاط به جای یک نقطه، شروع به جستجو می‌کنند و همچنین از قواعد احتمالاتی به جای قواعد قطعی استفاده می‌کنند. بنابراین، احتمال گیر افتادن پاسخ در نقاط بهینه محلی کاهش می‌یابد. همچنین، قابل ذکر است که روش‌های مبتنی بر مشتق در مواردی که متغیرهای تصمیم‌گیری کمیت‌های گسسته باشند، کارایی خود را از دست داده و این در حالی است که در الگوریتم‌های جستجوی مستقیم هوشمند این محدودیت وجود ندارد.

جدول۴- دامنه تغییرات متغیرهای طراحی

پارامتر	کران پایین	کران بالا
C	۰/۱	۱۰
σ	۰/۱	۱
نوع عیب	۱	۱۶

۹- جهت ارزیابی روش پیشنهادی، از داده‌های تست نهایی استفاده شده است. برای این منظور، به کمک مناسب‌ترین ویژگی‌های به‌دست آمده در مرحله ۸، ماتریس ویژگی از داده‌های تست نهایی استخراج می‌شود و در نهایت، با به‌کارگیری SVM بهینه شده، کلاس داده‌ها و در نتیجه شرایط حاکم بر مجموعه چرخ‌دنده تشخیص داده می‌شود.

فلوچارت روش پیشنهادی در شکل ۵ ارایه شده است.

۹- نتایج و تحلیل

۹-۱- انتخاب مناسب‌ترین ویژگی

نتایج حاصل از روش ترکیبی پیشنهاد شده در بخش ۸ برای موجک‌های haar، db10، sym4، coif5، bior6.8 و dmey در جدول ۵ ارایه شده است. همان‌طور که در این جدول دیده می‌شود، چنانچه از تابع موجک Haar برای تجزیه سیگنال‌های ارتعاشی استفاده شود، روش پیشنهاد شده قادر به پیش‌بینی دقیق حالت‌های سالم و لب‌پریدگی دندانه نمی‌باشد. ولی بقیه موجک‌های استفاده شده در این مطالعه، شرایط حاکم بر چرخ‌دنده را به درستی تعیین می‌نمایند.

میزان مفید بودن ویژگی‌های استخراج شده از سیگنال‌های ارتعاشی به کمک تبدیل موجک وابسته به تابع موجکی است که در فرآیند پردازش سیگنال از آن استفاده شده است. در واقع تبدیل موجک نشان‌دهنده‌ی همبستگی سیگنال با تابع موجک در مقیاس‌های مختلف می‌باشد. ضرایب موجک مربوط به تابع موجکی که به سیگنال شبیه‌تر است، در استخراج اطلاعات مفید از سیگنال توانمندتر خواهد بود. نتایج جدول ۵ نشان می‌دهند که موجک Haar نسبت به بقیه موجک‌ها، از شباهت کم‌تری نسبت به سیگنال برخوردار است. نکته دیگری که در جدول ۵ دیده می‌شود، انتخاب مجموعه ویژگی‌های آنتروپی، انحراف معیار و ریشه میانگین مربعات به عنوان بردار ویژگی بهینه توسط روش پیشنهادی است. جالب توجه است که انتخاب بردار ویژگی بهینه مستقل از نوع موجک مورد استفاده در این مقاله می‌باشد. در شکل ۶، بردار ویژگی بهینه به دست آمده توسط روش پیشنهادی در هنگام استفاده از تابع موجک bior6.8 ترسیم شده‌اند. همان‌طور که مشاهده می‌شود، شرایط مختلف حاکم بر چرخ‌دنده به خوبی از یکدیگر قابل تفکیک و تمییز می‌باشند.

[1] Feature Type
[2] Gradient based methods

۹-۲- مقایسه با دیگر روش‌های عیب‌یابی

برای مقایسه توانمندی روش انتخاب ویژگی و تشخیص عیب پیشنهاد شده در این مقاله با دیگر روش‌ها، از سه تکنیک به کار گرفته شده در مراجع [۶، ۱۶ و ۱۹] استفاده شده است. ویژگی‌های آماری و همچنین، دقت روش پیشنهادی و هر کدام از سه روش مزبور در پیش-بینی داده‌های مراحل آموزش و تست نهایی در جدول ۶ گزارش شده-اند. مطابق این جدول، روش ارایه شده در [۶] تنها در مورد تست نهایی سائیدگی دندانه دارای خطای تشخیص ۳٫۱۳ درصد است. الگوریتم ارایه شده در [۱۶] دارای خطای ناچیز ۰٫۶۷ درصد در تشخیص لب-پریدگی و سائیدگی دندانه در مرحله تست نهایی است. روش پیشنهاد شده در [۱۹] در شناسایی حالت سالم و لب‌پریدگی دندانه دارای خطای ۵٫۱۶۳۳ درصد در مرحله آموزش است. اما با استفاده از روش ترکیبی ارایه شده در این مقاله می‌توان هر سه حالت چرخ‌دنده را چه در مرحله آموزش و چه در مرحله تست نهایی به درستی پیش‌بینی کرد. این نتایج برتری روش ارایه شده در این مقاله را نسبت به دیگر تحقیقات ارایه شده در اینجا تایید نموده و قابلیت روش پیشنهاد شده را اثبات می‌کند.

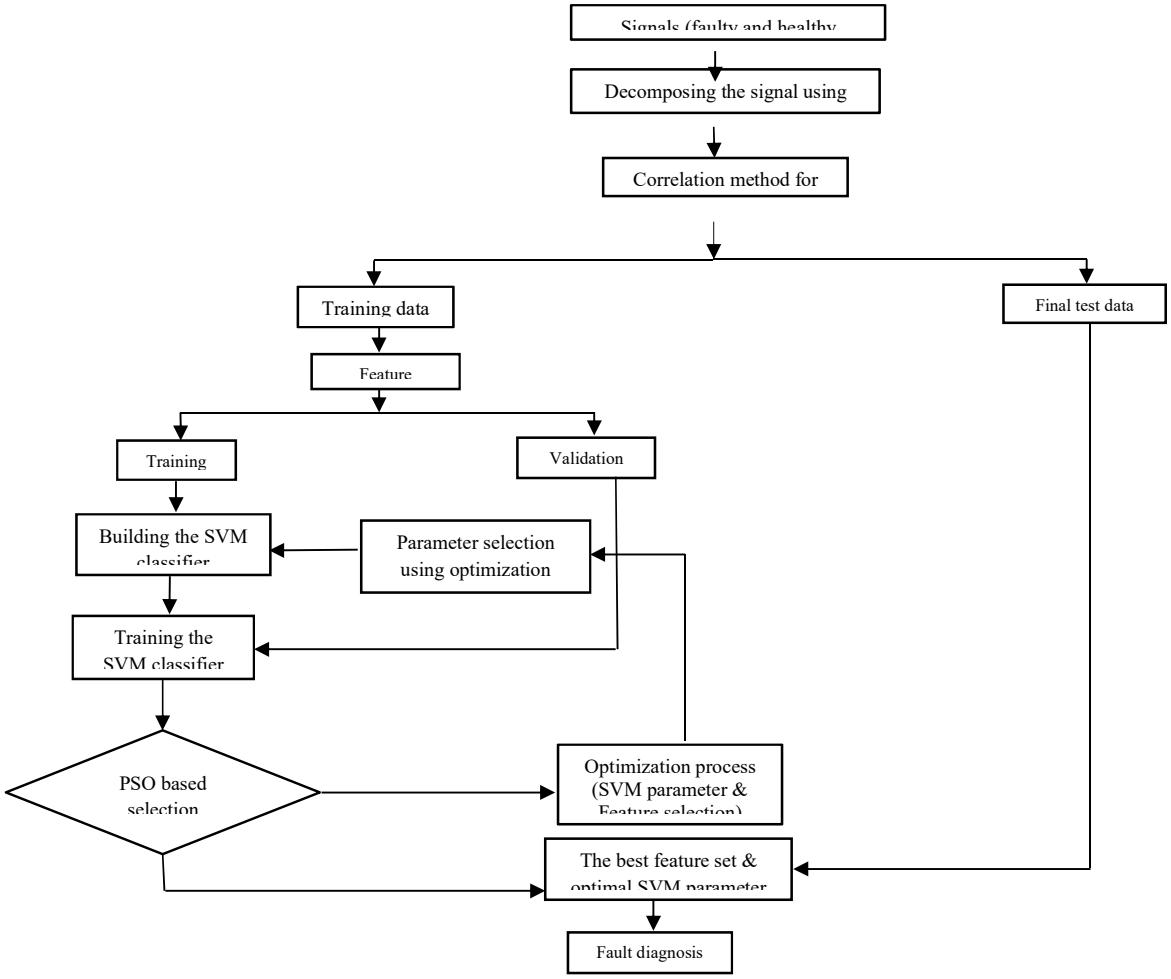

شکل ۵- فلوچارت روش پیشنهادی

جدول ۵- نتایج حاصل از روش ترکیبی پیشنهاد شده

تابع موجک	ویژگی‌های بهینه	حالت سالم		لب‌پریدگی دندانه		سائیدگی دندانه	
		آموزش (٪)	تست (٪)	آموزش (٪)	تست (٪)	آموزش (٪)	تست (٪)
دبیشی ۱۰، سیملت ۸، کویفلتز ۸، بای‌اورتوگونال ۶٫۸، متعامد دوگانه ۶٫۸، مِیر گسسته	آنتروپی انحراف معیار ریشه میانگین مربعات	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
هار	آنتروپی انحراف معیار ریشه میانگین مربعات	۱۰۰	۹۳٫۷۵	۸۹٫۴۷۴۳	۸۷٫۵	۱۰۰	۱۰۰

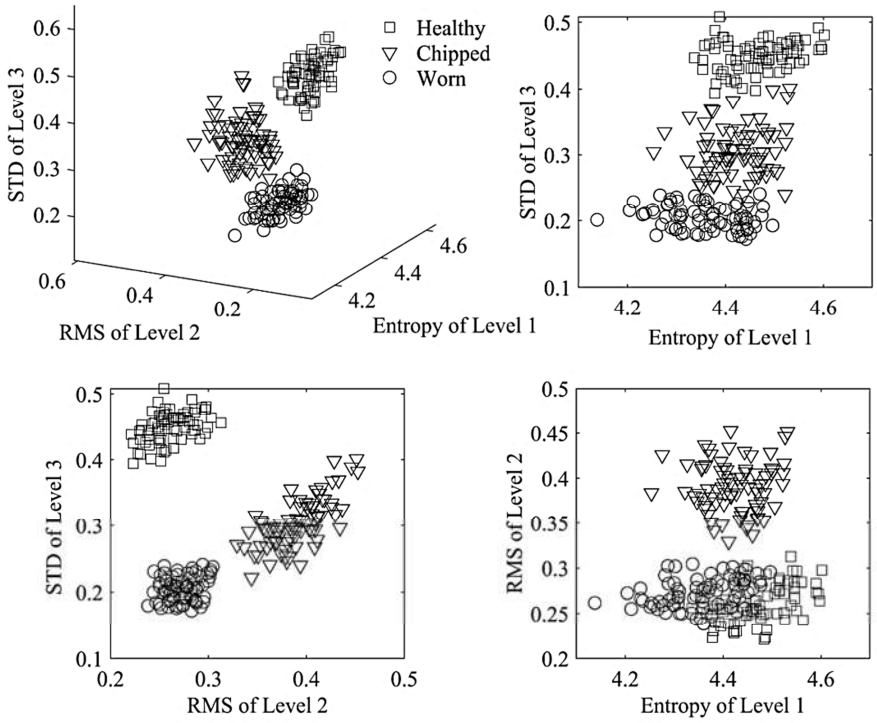

شکل ۶- بردار ویژگی بهینه به دست آمده توسط روش انتخاب ویژگی پیشنهادی

جدول ۶- مقایسه کارایی روش پیشنهادی با دیگر روش‌های عیب‌یابی

روش	ویژگی‌ها	پارامترهای بهینه	سالم		لب‌پریدگی دندانه		سائیدگی دندانه	
			آموزش (٪)	تست (٪)	آموزش (٪)	تست (٪)	آموزش (٪)	تست (٪)
روش ۱ [۶] (SVM (OAO)+FFT+GA)	انحراف معیار، چولگی، کشیدگی	C = ۳٫۶۷۷۴ σ = ۰٫۲۴۷۲	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۹۶٫۸۷۵
روش ۲ [۱۶] (Linear – SVM+ EMD)	همبستگی محلی گوسی	---	۱۰۰	۱۰۰	۱۰۰	۹۹٫۳۳	۱۰۰	۹۹٫۳۳
روش ۳ [۱۹] (SVM (OAO)+EMD)	انرژی	C = ۱۰ σ = ۰٫۸	۹۴٫۷۳۶۸	۱۰۰	۹۴٫۷۳۶۸	۱۰۰	۱۰۰	۱۰۰
روش پیشنهادی	آنتروپی، ریشه میانگین مربعات، انحراف معیار	C = ۱٫۷۵۹۰ σ = ۰٫۵۱۰۷	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰

۱۰- نتیجه‌گیری

در این مقاله، روش جدیدی به منظور عیب‌یابی چند کلاسه‌ی چرخ‌دنده‌ها بر اساس استراتژی انتخاب مناسب‌ترین مولفه‌های حاصل از تجزیه سیگنال‌های ارتعاشی و تشکیل ماتریس ویژگی، با ترکیب روش‌های تبدیل موجک، مفهوم همبستگی متقابل، ماشین بردار پشتیبان از نوع «یک در برابر یک» (SVM-OAO) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) ارایه شده است. به دلیل پیچیدگی و غیرایستا بودن سیگنال‌های ارتعاشی اکتساب شده از چرخ‌دنده‌ها، از روش تبدیل موجک گسسته برای تجزیه سیگنال‌ها به مولفه‌های ساده‌تر بهره گرفته شده است. در مرحله‌ی بعد، از مفهوم همبستگی متقابل بین سیگنال اصلی و سطوح مختلف برای انتخاب مناسب‌ترین سطوح استفاده شده است. از میان سطوح مختلف حاصل از تجزیه سیگنال‌ها، سه سطحی که دارای بیشترین مقدار همبستگی بودند، جهت استخراج ویژگی‌های آماری انتخاب شدند. برای تشکیل ماتریس ویژگی از انواع توابع آماری در حوزه‌ی زمان استفاده گردید. در قدم بعدی، از روش ماشین بردار پشتیبان، برای طبقه‌بندی حالت چرخ‌دنده بهره گرفته و در نهایت، از الگوریتم بهینه‌سازی PSO جهت انتخاب مناسب‌ترین ویژگی و تعیین پارامترهای بهینه SVM استفاده شده است. نتایج نشان می‌دهند اگر ویژگی‌های آنتروپی، انحراف معیار و ریشه میانگین مربعات از سه سطح منتخب استخراج شوند، حالت‌های چرخ‌دنده از یکدیگر به خوبی تفکیک شده و SVM بهینه شده قادر به پیش‌بینی درستی از شرایط چرخ‌دنده است. همچنین، مقایسه نتایج این مقاله با تحقیقات پیشین، توانمندی روش پیشنهادی را اثبات می‌کند.

۱۱- مراجع

[1] Yan R., Gao R. X., Chen X., Wavelets for Fault Diagnosis of Rotary Machines: A Review with Applications. *Signal Processing*, Vol. 96, pp. 1-15, 2014.

[2] Lei Y., Lin J., He Z., Zuo M., A Review on Empirical Mode Decomposition in Fault Diagnosis of Rotating Machinery. *Mechanical System and Signal Processing*, Vol. 35, pp. 108-126, 2013.

[3] Ben Ali J., Fnaiech N., Saidi L., Chebel-Morello B., Fnaiech F., Application of Empirical Mode Decomposition and Artificial Neural Network for Automatic Bearing Fault Diagnosis Based on Vibration Signals. *Applied Acoustics*, Vol. 89, pp.16-27, 2015.

[4] Jedlinski L., Jonak J., Early Fault Detection in Gearboxes Based on Support Vector Machines and Multilayer Perceptron with a Continuous Wavelet Transform. *Applied Soft Computing*, Vol. 30, pp. 636-641, 2015.

[5] Rajeswari C., Sathiyabhama B., Devendiran S., Manivannan K., A Gear Fault Identification Using Wavelet Transform, Rough Set Based GA, ANN and C4.5 Algorithm. *Procedia Engineering*, Vol. 97, pp. 1831-1841, 2014.

[6] Bordoloi D. J., Tiwari R., Support Vector Machine Based Optimization of Multi-Fault Classification of Gears with Evolutionary Algorithms from Time–Frequency Vibration Data. *Measurement*, Vol. 55, pp. 1-14, 2014.

[7] Bordoloi D. J., Tiwari R., Optimum Multi-Fault Classification of Gears with Integration of Evolutionary and SVM Algorithms. *Mechanism and Machine Theory*, Vol. 73, pp. 49–60, 2014.

[8] Bordoloi D. J., Tiwari R., Optimisation of SVM Methodology for Multiple Fault Taxonomy of Rolling Bearings from Acceleration Records. *9th IFToMM International Conference on Rotor Dynamics Mechanisms and Machine Science*, Vol. 21, pp. 533-542, 2015.

[9] Liu Z., Cao H., Chen X., He Z., Shen Z., Multi-Fault Classification Based on Wavelet SVM with PSO Algorithm to Analyze Vibration Signals from Rolling Element Bearings. *Neurocomputing*, Vol. 99, pp. 399–410, 2013.

[10] Dalian Y., Liyong M., Gear Fault Diagnosis Based on Support Vector Machine Optimized by Artificial Bee Colony Algorithm. *Mechanism and Machine Theory*, Vol. 90, pp. 219-229, 2015.

[11] Huang W., Kong F., Zhao X., Spur Bevel Gearbox Fault Diagnosis Using Wavelet Packet Transform and Rough Set Theory. *Journal of Intelligent Manufacturing*, Vol. *29, No.*6, pp.1257-1271, 2018.

[12] Yu X., Dong F., Ding E., Wu S., Fan C., Rolling Bearing Fault Diagnosis Using Modified LFDA and EMD with Sensitive Feature Selection. *IEEE Access*, Vol. *6*, pp.3715-3730, 2018.

[13] Jin S., Kim J. S., Lee S. K., Sensitive Method for Detecting Tooth Faults in Gearboxes Based on Wavelet Denoising and Empirical Mode Decomposition. *Journal of Mechanical Science and Technology*, Vol. 29, No. 8, pp. 3165-3173, 2015.

[14] Tabrizi A., Garibaldi L., Fasana A., Marchesiello S., Influence of Stopping Criterion for Sifting Process of Empirical Mode Decomposition (EMD) on Roller Bearing Fault Diagnosis. *Advances in Condition Monitoring of Machinery in Non-Stationary Operations Lecture Notes in Mechanical Engineering*, Berline, Germany, 389-398, 2014.

[15] Dhamandeh SL, Chaudhari BM, Detection of Combined Gear-Bearing Fault in Single Stage Spur Gear Box Using Artificial Neural Network. *Procedia Engineering*, pp. 144: 759-766, 2016.

[16] Zamanian A. H., Ohadi A., Gear Fault Diagnosis Based on Gaussian Correlation of Vibrations Signals and Wavelet Coefficients. *Applied Soft Computing*, Vol. 11, pp. 4807-4819, 2011.

[17] Mallat S., A Theory of Multiresolution Signal Decomposition: the Wavelet Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 11, No. 7, pp. 674-693, 1989.

[18] Zhong J., Ma W., Lin J., Ma L., Jia X., Fault Diagnosis Approach for Rotating Machinery Based on Dynamic Model and Computational Intelligence. *Measurement,* Vol. 59, pp. 73-87, 2014.

[19] Tabrizi A. A., *Development of New Fault Detection Methods for Rotating Machines (Roller Bearings),* PhD Thesis, University of Politecnico di Torino, 2015.

[20] Ratnaweera A., Halgamuge S. K., Watson H. C., Self-Organizing Hierarchical Particle Swarm Optimizer with Time-Varying Acceleration Coefficients. *IEEE Transactions on Evolutionary Computation,* Vol. 8, No. 3, pp. 240-255, 2004.