



عیب‌یابی چرخ‌دنده بر پایه انتخاب مناسب‌ترین ویژگی به کمک الگوریتم بهینه‌سازی ازدحام ذرات

احمد باقری^۱، سعید نظامیوند چگینی^{۲*}، میلاد رضانی دشتیمیان^۳ و فرید نجفی^۱

^۱ استاد، دانشکده مهندسی مکانیک، دانشگاه گیلان، رشت

^۲ دانشجوی دکتری، دانشکده مهندسی مکانیک، دانشگاه گیلان، رشت

^۳ کارشناسی ارشد، موسسه آموزش عالی غیر انتفاعی - غیر دولتی احرار، رشت

مقاله مستقل، تاریخ دریافت: ۱۳۹۶/۰۵/۲۲؛ تاریخ بازنگری: ۱۳۹۶/۰۹/۲۶؛ تاریخ پذیرش: ۱۳۹۷/۰۶/۱۰

چکیده

در این مقاله، روش جدیدی برای عیب‌یابی در چرخ‌دنده‌ها ارائه شده است. سیگنال‌های ارتعاشی مجموعه جعبه‌دنده در سه حالت سالم، لب‌پریدگی دندانه و ساییدگی دندانه جمع‌آوری شده‌اند. این سیگنال‌ها با استفاده از روش تجزیه مود تجربی، به تعدادی توابع مود ذاتی تجزیه شده‌اند. با توجه به این که همه توابع مود ذاتی به دست آمده از روش تجزیه مود تجربی، مناسب برای عیب‌یابی نیستند، از مفهوم همبستگی متقابل برای انتخاب مناسب‌ترین تابع مود ذاتی استفاده شده است. سپس، با به کارگیری توابع آماری مختلف، ماتریس ویژگی متناظر با هر حالت چرخ‌دنده، استخراج شده است. ماشین بردار پشتیبان چند کلاسه از نوع «یک در برابر یک» برای طبقه‌بندی عیوب به کار گرفته شده است. از آنجایی که تمامی ویژگی‌های استخراج شده برای عیب‌یابی مناسب نیستند و ماشین بردار پشتیبان دارای پارامترهایی است که باید تنظیم شوند، از این رو، از الگوریتم بهینه‌سازی ازدحام ذرات برای انتخاب مناسب‌ترین ویژگی و تعیین پارامترهای بهینه ماشین بردار پشتیبان استفاده شده است. تابع هدف در این مقاله، دقت طبقه‌بندی کننده ماشین بردار پشتیبان در پیش-بینی حالت جعبه‌دنده است. نتایج به دست آمده نشان می‌دهند که ویژگی‌های انتخاب شده در این روش و ماشین بردار پشتیبان بهینه شده، دارای توانایی عالی در طبقه‌بندی عیوب می‌باشند.

کلمات کلیدی: عیب‌یابی چرخ‌دنده؛ انتخاب ویژگی؛ تجزیه مود تجربی؛ ماشین بردار پشتیبان؛ الگوریتم بهینه‌سازی ازدحام ذرات.

Gear Fault Detection Based on Best Feature Selection by Particle Swarm Optimization

A. Bagheri¹, S. Nezamivand Chegini^{2,*}, M. Ramezani Dashtemian³, F. Najafi¹

¹ Prof., Dep. Of Mech. Eng., Guilan Univ., Rasht, Iran.

² Ph.D. Student, Mech. Eng., Guilan Univ., Rasht, Iran.

³ MSc of Mechanical Engineering, Ahrar Institute of Technology and Higher Education, Rasht, Iran.

Abstract

In this paper, a new method is presented for gear fault detection. The vibrational signals of gearbox set are collected in three conditions: normal, chipped and worn teeth. These signals are adaptively decomposed into a number of intrinsic mode functions (IMFs) by the empirical mode decomposition (EMD). Since, all of the IMFs driven from the EMD are not appropriate for fault detection, the cross-correlation concept is used to select all most appropriate IMFs. Then, feature matrix corresponding to each condition, is extracted using statistical functions. "One-against-one" support vector machine (SVM-OAO) is utilized to classify the faults. Since, all of the extracted features are not suitable for fault detection and SVM has parameters to be set, the particle swarm optimization (PSO) is used to select the best feature and detect optimal parameters of SVM. Objective function in this paper is accuracy of the SVM classifier in predicting of gearbox condition. Obtained results show that the selected features in this method and optimized SVM have the excellent ability to classify the faults.

Keywords: Gearbox Fault Detection; Feature Selection; Empirical Mode Decomposition; Support Vector Machine; Particle Swarm Optimization.

۱- مقدمه

چرخ‌دنده‌ها، به طور گسترده‌ای در ماشین‌های دوار استفاده شده و خرابی آن‌ها یکی از دلایل اصلی واماندگی^۱ ماشین‌ها است. پایش وضعیت بر پایه ارتعاشات، رایج‌ترین روش برای استخراج کردن بعضی اطلاعات مهم برای شناسایی وضعیت چرخ‌دنده‌ها و عیوب احتمالی آن‌ها است. در تحلیل ارتعاشات، نشانه‌ها و مؤلفه‌هایی 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 حوزه زمان و فرکانس، به عنوان نخستین روش‌های تشخیصی در زمینه عیب‌یابی در نظر گرفته می‌شوند. روش‌های زمان - فرکانس، از جمله تکنیک‌های مفید برای استخراج ویژگی‌ها و مؤلفه‌های فرکانسی متغیر با زمان از سیگنال‌های غیرایستا به شمار می‌آیند. روش تجزیه مود تجربی^۲، یکی از روش‌های رایج در حوزه زمان - فرکانس است که یک سیگنال چند مؤلفه‌ای را به تعدادی مؤلفه اصلی تجزیه می‌کند. در واقع، روش تجزیه مود تجربی، یک ابزار تطبیقی برای تحلیل سیگنال‌های ارتعاشی غیرایستا است [۱].

پس از مرحله استخراج ویژگی، از روش‌های شناسایی الگو^۳ برای پیش‌بینی حالت چرخ‌دنده استفاده می‌شود. شناسایی الگو شامل، روش‌هایی است که به توصیف حالت عیب بر پایه بردار ویژگی استخراج شده از طریق تکنیک‌های پردازش سیگنال، می‌پردازد.

بن‌علی^۴ و همکاران با استفاده از روش تجزیه مود تجربی، ویژگی‌هایی را از سیگنال‌های غیرخطی و غیرایستا^۵ استخراج نموده‌اند. سپس، از این ویژگی‌ها برای آموزش شبکه عصبی مصنوعی^۶ و دسته‌بندی عیوب یاتاقان استفاده کرده‌اند [۲]. چایی‌بخش و رهبر [۳] روش‌های تجزیه مود تجربی و تبدیل موجک را در تشخیص نابالانسی ماشین‌های دوار به کمک ماشین بردار پشتیبان با هم مقایسه کرده‌اند. آن‌ها به منظور

تفکیک حالت سالم از معیوب از ماشین بردار پشتیبان استفاده کرده‌اند. 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^۷ به منظور بهبود روش‌های شناسایی الگو و انتخاب مناسب‌ترین ویژگی آماری و حساس به عیب ضروری به نظر می‌رسد. برای مثال، راجسوار^۸ و همکاران با استفاده از تبدیل موجک^۹، 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 [۴]. بُردلوی و تیواری^{۱۰} در [۵ و ۶] یک روش طبقه‌بندی چند کلاسه را برای تعیین عیوب چرخ‌دنده‌ها به کمک ماشین بردار پشتیبان^{۱۱} ارائه داده‌اند. آن‌ها قبل از یادگیری و آزمایش نهایی ماشین بردار پشتیبان، پارامترهای این شبکه را توسط الگوریتم‌های جستجوی شبکه، ژنتیک و زنبور عسل بهینه نموده‌اند. سپس توابع آماری مانند، کشیدگی^{۱۲}، انحراف معیار و چولگی^{۱۳} استخراج شده از حوزه فرکانس و ضرایب تبدیل موجک پیوسته و تبدیل موجک گسسته، ویژگی‌هایی بوده‌اند که به عنوان ورودی ماشین بردار پشتیبان استفاده شده‌اند. آن‌ها در کار دیگری با بهبود تکنیک ماشین بردار پشتیبان، روشی برای طبقه‌بندی عیوب مختلف در یاتاقان‌ها ارائه داده‌اند. در این تحقیق، قبل از انجام مراحل آموزش و آزمایش نهایی طبقه‌بندی کننده، پارامترهای ماشین بردار پشتیبان 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 حوزه

⁷ Optimization Algorithms

⁸ C. Rajeswari

⁹ Wavelet Transform (WT)

¹⁰ D. J. Bordoloi and R. Tiwari

¹¹ Support Vectore Machine (SVM)

¹² Kurtosis

¹³ Skewness

¹ Failure

² Empirical Mode Decomposition (EMD)

³ Pattern Recognition Methods

⁴ J. Ben Ali

⁵ Nonstationary

⁶ Artificial Neural Networks (ANN)

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 طبقه‌بندی شود. همچنین، در تحقیقات انجام شده در گذشته مانند [۱۵ و ۱۶]، هنگام استفاده از روش تجزیه مود تجربی، بدون توجه به این که کدام یک از سطح‌های تجزیه بیشترین سهم از اطلاعات عیب را داراست، از سطوح تجزیه مختلف استفاده کرده‌اند؛ اما انتخاب سطح تجزیه مناسب مانع از دست رفتن بخشی از اطلاعات مربوط به عیب شده و موجب افزایش دقت طبقه‌بندی می‌شود. علاوه بر انتخاب سطح تجزیه، انتخاب مناسب‌ترین ویژگی با توجه به نوع سطح تجزیه می‌تواند موجب تفکیک بهتر عیب، افزایش دقت روش‌های شناسایی الگو شود. روش جدیدی که در این مقاله ارائه شده است، بر دو مسئله انتخاب مناسب‌ترین مؤلفه‌های حاصل از تجزیه سیگنال‌های ارتعاشی و تشکیل بهترین ماتریس ویژگی (بهترین ترکیب ویژگی) تمرکز یافته است. در این روش، از مفهوم همبستگی متقابل^۹ برای انتخاب انتخاب مناسب‌ترین سطح تجزیه و از الگوریتم بهینه‌سازی ازدحام ذرات برای انتخاب مناسب‌ترین ویژگی با توجه به سطح تجزیه و همچنین بهبود طبقه‌بندی کننده ماشین بردار پشتیبان استفاده شده است تا دقت عیب‌یابی به حداکثر برسد.

این مقاله در ۱۰ بخش تدوین شده است: در بخش ۲، مجموعه آزمایشگاهی معرفی شده است. در بخش ۳، به تئوری حاکم بر روش‌های تجزیه مود تجربی 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 مؤلفه‌های یک سیگنال ارائه شده است. در بخش ۷، به ارائه الگوریتم بهینه‌سازی ازدحام ذرات پرداخته شده است. در بخش ۸ جزئیات روش پیشنهادی در این مقاله ارائه گردیده و در بخش ۹، به تحلیل نتایج حاصل از این مقاله پرداخته شده است. در نهایت، مقاله در بخش ۱۰ نتیجه‌گیری شده است.

زمان مانند کشیدگی، انحراف معیار و چولگی استفاده شده است [۱۷]. لیو^۱ و همکاران یک روش ترکیبی و هوشمند برای برای طبقه‌بندی چندین عیب در یاتاقان‌های غلتشی ارائه کرده‌اند که بر پایه تجزیه مود تجربی، تکنیک ارزیابی فاصله، ماشین بردار پشتیبان با تابع هسته موجک^۲ و الگوریتم بهینه-بهینه‌سازی ازدحام ذرات است [۸]. جک و ناد^۳ ویژگی‌های آماری برای سیگنال‌های ارتعاشی مربوط به یاتاقان‌های غلتشی را محاسبه و با استفاده از الگوریتم ژنتیک، ویژگی‌های آماری بهینه را انتخاب نموده‌اند. آن‌ها از ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای شناسایی عیب استفاده کرده‌اند [۹]. دالین و لیونگ^۴ به منظور شناسایی عیب در یک جعبه‌دنده، روش شناسایی الگوی ماشین بردار پشتیبان با تابع هسته گوسی را به کمک الگوریتم بهینه‌سازی کولنی مصنوعی زنبور عسل^۵، بهینه نموده‌اند. آن‌ها با استفاده از روش تجزیه مود تجربی کلی، ویژگی‌هایی را به عنوان ورودی ماشین بردار پشتیبان بهینه شده، استخراج کرده‌اند [۱۰]. زبانی^۶ و همکاران با معیار فیشر و الگوریتم بهینه‌سازی ازدحام ذرات باینری^۷، روشی برای انتخاب مناسب‌ترین مجموعه از ویژگی‌های استخراج شده از سیگنال‌های ارتعاشی یاتاقان‌ها ارائه نموده‌اند. سپس، از ویژگی‌های منتخب به عنوان ورودی‌های ماشین بردار پشتیبان چند کلاسه استفاده نموده‌اند [۱۱]. ژانگ^۸ و همکاران [۱۲] روشی شامل، دو مرحله برای عیب‌یابی یاتاقان‌ها ارائه نموده‌اند. در مرحله اول، به کمک روش ReliefF، مجموعه اولیه‌ای از همه ویژگی‌ها انتخاب شده است. در مرحله دوم، مجموعه ویژگی بهینه و پارامترهای الگوریتم ماشین بردار پشتیبان طوری تعیین شده‌اند که خطای پیش‌بینی وضعیت یاتاقان و تعداد ویژگی‌ها کمینه شوند.

در اکثر روش‌های ارائه شده در گذشته مانند [۱۳ و ۱۴]، بدون توجه به این که کدام ویژگی قابلیت آشکارسازی عیب

¹ Z. Liu

² Wavelet Support Vector Machine (WSVM)

³ L. B. Jack and A. K. Nandi

⁴ Y. Dalian and M. Liyong

⁵ Artificial Bee Colony (ABC)

⁶ R. Ziani


⁷ Binary Particle Swarm Optimization (BPSO)

⁸ X. Zhang

⁹ Cross - Correlation



شکل ۲- شرایط چرخ‌دنده‌ها: چرخ‌دنده‌ی سمت راست: لب-بریدگی، چرخ‌دنده‌ی میانی: ساییدگی و چرخ‌دنده‌ی سمت چپ: سالم [۱۷]




شکل ۳- سیگنال‌های ارتعاشی اکتساب شده از جعبه‌دنده در سه حالت سالم، لب‌بریدگی و ساییدگی دندانه [۱۷]

پیچیده را بر پایه رفتار محلی‌اش به تعدادی مدهای نوسانی ساده که توابع مود ذاتی^۱ نامیده می‌شوند، تجزیه می‌کند. توابع مود ذاتی دارای ویژگی‌های زیر هستند:

^۱ Intrinsic Mode Functions (IMFs)

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 (۱۵ = N_1) و چرخ‌دنده (۱۱۰ = N_2)، نسبت سرعت ۱:۷/۳۳ را برای جعبه‌دنده تولید می‌کند. سیگنال‌های ارتعاشی برای سه حالت سالم، لب‌بریدگی دندانه و ساییدگی دندانه پینیون در مدت ۱۰ ثانیه با نرخ فرکانس نمونه برداری ۱۰ KHz جمع‌آوری شده‌اند [۱۷]. در حالت لب‌بریدگی 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 می‌دهد.



شکل ۱- مجموعه آزمایشگاهی دانشگاه صنعتی امیرکبیر [۱۷]

۳- روش تجزیه مود تجربی

داده‌های مربوط به یک سیگنال، شامل مدهای نوسانی بسیار متفاوتی هستند که با یکدیگر تداخل نموده و داده‌های پیچیده‌ای تولید می‌کنند. روش تجزیه مود تجربی، یک سیگنال

۸- با در نظر گرفتن r_1 به عنوان داده‌ی جدید و تکرار فرآیند شرح داده شده در بالا برای n مرتبه، می‌توان n تابع مود ذاتی از سیگنال $x(t)$ را به دست آورد. بنابراین:

$$r_1 - c_2 = r_2$$

$$\dots$$

$$r_{n-1} - c_n = r_n \quad (۶)$$

۹- هنگامی که r_n یک تابع منوتونیک^۲ باشد، در این صورت هیچ تابع مود ذاتی قابل استخراج نبوده و فرآیند تجزیه متوقف می‌شود. سرانجام می‌توان رابطه (۷) را نوشت:

$$x(t) = \sum_{i=1}^n c_i + r_n \quad (۷)$$

در نهایت، یک سیگنال به n شکل موج با میانگین صفر و یک باقی مانده تجزیه می‌شود.

۴- استخراج ویژگی در حوزه زمان

برای مقایسه کردن و شناسایی حالت ماشین در حوزه 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 دو نوع ماشین بردار پشتیبان و مفاهیم پایه‌ای آن‌ها تشریح خواهند شد.

۵-۱- ماشین بردار پشتیبان دو کلاسه

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. فرض کنید که این داده‌ها با ابرصفحه‌ی $w \cdot x + b = 0$ تفکیک‌پذیر باشند. پارامترهای w و b به ترتیب بردار نرمال و اسکالر می‌باشند و داده‌های آموزش قیود زیر را ارضاء می‌کنند [۱۹ و ۲۰]:

۱- در کل مجموعه داده، تعداد نقاط اکسترمم (بیشینه و کمینه) و تعداد نقاط عبور صفر با هم برابر و یا حداکثر یکی تفاوت داشته باشند.

۲- در هر نقطه میانگین پوش برازش داده شده بر نقاط بیشینه محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد.

روش تجزیه مود تجربی شامل مراحل زیر است [۱]:

۱- تعیین نقاط بیشینه و کمینه محلی.
 ۲- به دست آوردن پوش بالایی و پایینی سری زمانی با استفاده از برازش نقاط بیشینه و کمینه محلی.
 ۳- محاسبه میانگین پوش بالا و پایین داده‌ها که با m_1 نشان داده می‌شود.

۴- با تعیین اختلاف بین سیگنال $x(t)$ و m_1 ، نخستین مؤلفه h_1 به دست می‌آید:

$$x(t) - m_1 = h_1 \quad (۱)$$

۵- بررسی شرط IMF بودن:

$$D_k = \frac{\sum_{t=0}^T |h_1^{k-1}(t) - h_1^k(t)|^2}{\sum_{t=0}^T |h_1^{k-1}(t)|^2}, \quad D_k < 0.1 \quad (۲)$$

۶- اگر شرط پنجم ارضا شود، h_1 در حکم اولین تابع مود ذاتی سیگنال $x(t)$ در نظر گرفته می‌شود. در غیر این صورت، مراحل ۱ تا ۵ دوباره تکرار می‌شود، با این تفاوت که الگوریتم به جای سری زمانی اولیه $x(t)$ روی h_1 اعمال می‌شود:

$$h_1 - m_{11} = h_{11} \quad (۳)$$

که m_{11} میانگین پوش بالا و پایین h_1 است. بعد از k مرتبه تکرار فرآیند غربالگری^۱، تابع مود ذاتی h_{1k} به صورت رابطه (۴) به دست می‌آید:

$$h_{1(k-1)} - m_{1k} = h_{1k} \quad (۴)$$

سپس h_{1k} به عنوان نخستین مؤلفه IMF انتخاب می‌شود، یعنی: $c_1 = h_{1k}$.

۷- با جداسازی c_1 از سیگنال اصلی $x(t)$ ، باقی‌مانده‌ی r_1 به دست می‌آید:

$$r_1 = x(t) - c_1 \quad (۵)$$

^۲ Monotonic Function

^۱ Sifting Process

$$w \cdot x + b \geq +1 \text{ if } y_i = +1 \quad (۸)$$

$$w \cdot x + b \leq -1 \text{ if } y_i = -1 \quad (۹)$$

در اینجا، هدف یافتن ابر صفحه‌ای است که حاشیه بین دو کلاس را بیشینه نماید. این حاشیه را می‌توان با کمینه کردن عبارت $\frac{1}{2} \|w\|^2$ به دست آورد.

در مسائل واقعی، داده‌ها به طور خطی تفکیک‌پذیر نمی‌باشند. در این شرایط با معرفی متغیر غیرمنفی ξ می‌توان مرز همواری ایجاد کرد که حاشیه نرم^۱ نامیده می‌شود. ابر صفحه بهینه با حل مسئله (۱۰) به دست می‌آید [۱۹ و ۲۰]:

$$\min \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \right)$$

subject to

$$\begin{cases} y_i(w \cdot x + b) \geq 1 - \xi_i & i = 1, \dots, N \\ \xi_i \geq 0 \end{cases} \quad (۱۰)$$

که ξ_i فاصله‌ی بین ابر صفحه و نمونه‌های قرار گرفته در طرف اشتباه ابر صفحه را اندازه می‌گیرد و C پارامتر جریمه است. با استفاده از شرایط کان - تاکر^۲، مسئله فوق به حالت دوگانه لاگرانژی تبدیل می‌شود. با معرفی ضرایب لاگرانژ α_i و β_i برای قیود مسئله (۱۰) و تعیین معادلات زینی، مسئله بهینه‌سازی درجه دوم زیر به دست می‌آید [۱۹ و ۲۰]:

$$\min L(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \alpha_i \alpha_j y_i y_j x_i \cdot x_j$$

subject to

$$\begin{cases} \sum_{i=1}^N \alpha_i y_i & i = 1, \dots, N \\ 0 \leq \alpha_i \leq C \end{cases} \quad (۱۱)$$

هر برداری که شرط $0 \leq \alpha_i \leq C$ را برآورده کند، بردار پشتیبان^۳ نامیده می‌شود. با حل مسئله‌ی بهینه‌سازی (۱۱)، ضرایب لاگرانژ α_i به دست می‌آیند؛ بنابراین، تابع تصمیم غیرخطی برای برچسب زدن به داده‌ی جدید برابر است با [۱۹ و ۲۰]:

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i (x_i \cdot x_j) + b \right) \quad (۱۲)$$

در حالتی که در فضای ورودی، دسته‌بندی غیرخطی است، می‌توان روش ماشین بردار پشتیبان را با نگاشت داده‌ها به

جدول ۱- ویژگی‌های آماری در حوزه زمان

No.	Formula	Feature
1	$\frac{1}{N} \sum_{i=1}^N x(i)$	Mean
2	$\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^2}$	Kurtosis
3	$\sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$	Standard deviation
4	$\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2$	Variance
5	$\frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{\left(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2\right)^{\frac{3}{2}}}$	Skewness
6	$\max(x_i)$	Peak
7	$\frac{x_{RMS}}{\left(\frac{1}{N} \sum_{i=1}^N x_i \right)}$	Shape factor
8	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	Root mean square
9	$\max(x_i) - \min(x_i)$	Range
10	$x_{\left(\frac{N+1}{2}\right)}$	Median
11	$\text{mean}(\text{total peak value})$	Mean peak
12	$\frac{\text{Peak}}{\left(\frac{1}{N} \sum_{i=1}^N x_i \right)}$	Impulse factor
13	$-\sum_{i=1}^N x_i^2 \log(x_i^2)$	Entropy
14	$\frac{\text{Peak}}{\left(\left(\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i }\right)^2\right)}$	Clearance factor
15	$\frac{\max(\text{abs}(x))}{RMS}$	Crest factor
16	$\int x(t) ^2 dt$	Energy

¹ Soft Margin

² Kuhn - Tucker Conditions

³ Support Vector

توضیحات مربوط به این نوع از ماشین بردار پشتیبان آمده است. در روش «یک در برابر یک» تعداد $\frac{k(k-1)}{2}$ ماشین بردار پشتیبان ساخته می‌شود؛ به طوری که هر مدل با استفاده از داده‌های دو کلاس آموزش داده می‌شود. برای داده‌های آموزشی متعلق به کلاس‌های i ام و j ام، مسئله‌ی طبقه‌بندی به فرم (۱۷) در می‌آید [۱۹ و ۲۰]:

$$\min \frac{1}{2} \|w^{ij}\|^2 + C \sum_t \xi_t^{ij} (w^{ij})^T$$

subject to

$$\begin{cases} (w^{ij})^T \phi(x_t) + b^{ij} \geq 1 - \xi_t^{ij} & \text{if } y = i \\ (w^{ij})^T \phi(x_t) + b^{ij} \leq -1 + \xi_t^{ij} & \text{if } y \neq i \\ \xi_t^{ij} \geq 0 & j = 1, \dots, l \end{cases}$$

(۱۷)

پس از تعدادی آزمایش، اگر علامت $(w^{ij})^T \phi(x_t) + b^{ij}$ گویای این حقیقت باشد که x_t متعلق به کلاس i ام است، آنگاه رأی برای کلاس i یک واحد افزایش می‌یابد. در غیر این صورت، برای کلاس j یک واحد افزایش می‌یابد. در نهایت، x_t در کلاسی قرار دارد که بیشترین تعداد رأی را داشته باشد.

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 $X(t)$ سیگنال اول در زمان t_1 و $C(t)$ سیگنال دوم در زمان t_2 باشند و زمان تأخیر τ برابر باشد با: $\tau = t_1 - t_2$ ، ضریب همبستگی به صورت رابطه (۱۸) محاسبه می‌شود [۲۱]:

$$\rho_{xc} = \frac{C_{xc}(\tau)}{\sigma_x \sigma_c} \quad (۱۸)$$

که $C_{xc}(\tau)$ 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: $\rho_{xc} = 0$.

فضای ویژگی با ابعاد بالاتر اعمال نمود. در این حالت می‌توان از یک تابع برداری غیرخطی همچون $\phi(x) = (\phi_1(x), \dots, \phi_l(x))$ برای نگاشت بردار ورودی n بعدی x به فضای ویژگی l بعدی استفاده شده است؛ به طوری که تابع تصمیم به فرم (۱۳) تغییر می‌یابد [۱۹ و ۲۰]:

$$f(x) = \text{sign} \left(\sum_{i,j=1}^N \alpha_i y_i K(x_i, x_j) + b \right) \quad (۱۳)$$

که $K(x_i, x_j)$ تابع هسته بوده و به صورت زیر تعریف می‌شود:

$$K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j)) \quad (۱۴)$$

و پارامتر بایاس برابر خواهد بود با:

$$b = y_i - \left(\sum_{i=1}^N \alpha_i y_i K(x_i, x_j) \right) \quad (۱۵)$$

تابع هسته‌ای که در کاربردهای عملی ماشین بردار پشتیبان به طور گسترده‌ای استفاده می‌شود، تابع پایه شعاعی^۱ است که صورت (۱۶) تعریف می‌شود:

$$K(x_i, x_j) = \exp(-\|x - x_i\|^2 / 2\sigma^2) \quad (۱۶)$$

انتخاب پارامترهای جریمه C و σ ، به شدت کارایی ماشین بردار پشتیبان را تحت تأثیر قرار می‌دهد. همان‌طور که خواهید دید در این مطالعه، از الگوریتم بهینه‌سازی ازدحام ذرات برای یافتن مقادیر بهینه‌ی این دو پارامتر استفاده خواهد شد.

۲-۵- ماشین بردار پشتیبان چند کلاسه «یک در برابر یک»

گاهی اوقات، با مسائلی 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. دو نوع استراتژی برای ساخت ماشین بردار پشتیبان چند کلاسه^۲ وجود دارد: «یک در برابر همه»^۳ و «یک در برابر یک»^۴ [۱۹ و ۲۰]. از آنجایی که در این مقاله تنها از نوع «یک در برابر یک» استفاده شده است، بنابراین در ادامه،

¹ Radial Basis Function

² Multi - Class SVM

³ One- Against- All (OAA)

⁴ One- Against- One (OAO)

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 [۲۲]. 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 مسئله مورد نظر است. برای یک مسئله d - بعدی، هر ذره دارای دو بردار سرعت و موقعیت است. فرآیند بهینه‌سازی در این الگوریتم 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 [۲۲]:

$$\vec{V}_i(t+1) = w\vec{V}_i(t) + c_1r_1(\vec{X}_{pBest_i} - \vec{X}_i(t)) + c_2r_2(\vec{X}_{gBest} - \vec{X}_i(t)) \quad (19)$$


$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (20)$$

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 بازه $[0,1]$ هستند. در این مقاله، مقادیر c_1 ، c_2 و w مطابق مرجع [۲۳] 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 است؛ بنابراین، پیاده‌سازی این الگوریتم نسبت به الگوریتم‌هایی نظیر الگوریتم بهینه‌سازی ژنتیک ساده‌تر بوده و دارای حجم محاسبات کم‌تری است. به همین دلیل در این مقاله از این الگوریتم در فرآیند عیب‌یابی مجموعه جعبه‌دنده استفاده شده است.

۸- روش پیشنهادی

روش پیشنهادی در این مقاله، ترکیبی از روش‌های تجزیه مود تجربی، الگوریتم بهینه‌سازی ازدحام ذرات و ماشین بردار پشتیبان از نوع «یک در برابر یک» است. در اینجا، هر سیگنال ارتعاشی توسط روش تجزیه مود تجربی به مؤلفه‌های ساده‌تری تجزیه می‌شود. در شکل ۴ یک سیگنال ارتعاشی چرخ‌دنده به همراه چهار تابع مود ذاتی نخست آن نشان داده شده است.



شکل ۴ - تجزیه یک سیگنال ارتعاشی به کمک تجزیه مود تجربی

تمامی IMFهای به دست آمده از روش تجزیه مود تجربی، لزوماً دارای اطلاعات مناسبی از عیب نمی‌باشند، بنابراین در اینجا، مناسب‌ترین IMFها با استفاده از همبستگی متقابل انتخاب شده‌اند. برای این منظور، همبستگی متقابل بین سیگنال اصلی و هر کدام از IMFها محاسبه شده است. هر چه قدر مقدار همبستگی متقابل بین یک IMF خاص و سیگنال اصلی بزرگ‌تر باشد، نشان دهنده‌ی این است که IMF مزبور نسبت به IMFهای دیگر به سیگنال اصلی شبیه‌تر بوده و اطلاعات بیشتری از سیگنال را شامل است. نتایج حاصل از محاسبه همبستگی متقابل برای حالت سالم، لپ‌پریدگی دندان و ساییدگی دندان در جداول ۲ تا ۴ ارائه شده‌اند. مطابق این جداول، برای هر سه حالت چرخ‌دنده، سه IMF اول دارای بالاترین مقدار ضریب

نمونه سیگنال استخراج شده‌اند؛ اما از آنجایی که ممکن است تمامی توابع آماری مزبور برای نمایان ساختن عیوب مختلف مناسب نباشند، در این مطالعه، برای هر کدام از مؤلفه‌های IMF1، IMF2 و IMF3 از بهترین ویژگی آماری استفاده شده است. فرم کلی ماتریس ویژگی به صورت زیر معرفی می‌گردد:

$$FM = \begin{bmatrix} IMF1 & IMF2 & IMF3 \\ f_{11} & f_{12} & f_{13} \\ \vdots & \vdots & \vdots \\ f_{n1} & f_{n2} & f_{n3} \end{bmatrix} \quad (21)$$

که f_{ij} ها ($j=1,2,\dots,n$ و $i=1,2,3$) ویژگی متناظر با تابع مورد ذاتی i ام و نمونه سیگنال j ام است. برای هر f_{ij} در رابطه ۲۱، می‌توان از هر کدام از ویژگی‌های ارائه شده در جدول ۱ استفاده نمود؛ در نتیجه، ماتریس‌های ویژگی بسیار زیادی قابل تشکیل هستند که ممکن است، همه آن‌ها قادر به پیش‌بینی دقیق وضعیت جعبه‌دنده نباشند. از این رو هدف اصلی این مطالعه، تشکیل ماتریس ویژگی بهینه‌ای است که بتواند شرایط حاکم بر جعبه‌دنده را به خوبی تفکیک نماید. بنابراین، در این مقاله از الگوریتم بهینه‌سازی ازدحام ذرات برای استخراج f_{ij} های بهینه و تعیین پارامترهای طبقه‌بندی کننده ماشین بردار پشتیبان استفاده شده تا دقت طبقه‌بندی عیوب به حداکثر برسد.

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

۱- هر سیگنال ارتعاشی به بخش‌هایی دارای ۱۲۵۰

نمونه داده تقسیم می‌شود.

۲- هر بخش از سیگنال مرحله‌ی ۱ توسط روش تجزیه

مود تجربی به مؤلفه‌های مختلفی تجزیه می‌شود.

۳- مناسب‌ترین IMF ها توسط ضریب همبستگی

متقابل انتخاب می‌شوند. با توجه به این که

سیگنال‌های ارتعاشی مجموعاً به ۲۴۰ بخش

تقسیم شده‌اند و تنها سه IMF اول بیشترین

ضریب همبستگی را دارند، بنابراین با انتخاب سه

IMF اول، جمعاً 240×3 مؤلفه IMF به دست آمده

است.

۴- شصت درصد از داده‌ها به «داده‌های آموزش»

اختصاص یافته و مابقی برای «داده‌های آزمایش

نهایی» استفاده می‌شود.

همبستگی هستند، اما از IMF3 به بعد ضریب همبستگی کاهش پیدا کرده است؛ یعنی، سه تابع مود ذاتی اول، شامل بیشترین مقدار اطلاعات مفید از سیگنال اصلی می‌باشند. بنابراین، در روش ارائه شده در این مقاله، تنها از سه IMF اول استفاده شده است.

جدول ۲- ضرایب همبستگی بین سیگنال حالت سالم با IMF های حاصل از تجزیه مود تجربی

Value	IMF1	IMF2	IMF3	IMF4
D.S	0.6403	0.7180	0.2413	0.0255
Value	IMF5	IMF6	IMF7	IMF8
D.S	0.0024	0.0030	5.9280e ⁻⁴	-8.6290e ⁻⁴
Value	IMF9	IMF10	IMF11	
D.S	9.4516e ⁻⁵	3.6724e ⁻⁴	2.8442e ⁻⁵	

جدول ۳- ضرایب همبستگی بین سیگنال حالت لب‌پریدگی دندان با IMF های حاصل از تجزیه مود تجربی

Value	IMF1	IMF2	IMF3	IMF4
D.S	0.6196	0.6783	0.4220	0.0503
Value	IMF5	IMF6	IMF7	IMF8
D.S	0.0032	0.0030	7.2529e ⁻⁴	-7.7884e ⁻⁴
Value	IMF9	IMF10	IMF11	
D.S	2.0408e ⁻⁵	-3.8681e ⁻⁴	7.5969e ⁻⁵	

جدول ۴- ضرایب همبستگی بین سیگنال حالت ساییدگی دندان با IMF های حاصل از تجزیه مود تجربی

Value	IMF1	IMF2	IMF3	IMF4
D.S	0.6853	0.6179	0.3575	0.0395
Value	IMF5	IMF6	IMF7	IMF8
D.S	0.0028	9.4791e ⁻⁴	1.7996e ⁻⁴	-4.1753e ⁻⁴
Value	IMF9	IMF10	IMF11	
D.S	2.0880e ⁻⁵	-6.06882e ⁻⁶	5.2213e ⁻⁴	

در اینجا، از مشخصه‌های آماری جدول ۱ برای تشکیل ویژگی‌هایی که به حضور عیوب و نوع آن‌ها حساس می‌باشند، استفاده شده است. این ویژگی‌ها از IMF های اول تا سوم هر

فلوچارت روش پیشنهادی در شکل ۵ نشان داده شده است.

همان‌طور که در بخش ۲ گفته شد، در این مقاله از داده‌های ارتعاشی به کار گرفته شده در [۱۷] استفاده شده است. نویسندگان از تبدیل موجک پیوسته، روش تجزیه مود تجربی و تابع همبستگی گوسی محلی به منظور استخراج ویژگی از سیگنال‌های ارتعاشی استفاده نموده‌اند. سپس، از این ویژگی‌ها به عنوان ورودی‌های ماشین بردار پشتیبان بهره گرفته‌اند؛ اما در روش پیشنهاد شده در اینجا، روشی هوشمند به منظور انتخاب ویژگی‌های بهینه از میان گستره وسیع‌تری از ویژگی‌های آماری و بهبود روش شناسایی الگو ماشین بردار پشتیبان به کمک الگوریتم بهینه‌سازی ازدحام ذرات معرفی شده است.

۹- نتایج و تحلیل

الگوریتم بهینه‌سازی ازدحام ذرات، دارای طبیعتی تصادفی است. این امر باعث می‌شود که بردارهای ویژگی انتخاب شده توسط این الگوریتم در اجراهای مختلف با هم متفاوت باشند. بر این اساس، پس از پیاده‌سازی روش پیشنهادی در نرم‌افزار MATLAB، آن را ۴۰ بار به اجرا درآورده و ویژگی‌های انتخاب شده توسط الگوریتم بهینه‌سازی مزبور در حالتی ثابت شده‌اند که طبقه‌بندی کننده ماشین بردار پشتیبان وضعیت جعبه‌بندی را به درستی پیش‌بینی نموده است. سپس، پر تکرارترین ویژگی مربوط به هر IMF، به عنوان یکی از مولفه‌های بردار ویژگی نهایی انتخاب شده‌اند.

نتایج حاصل از این روش برای IMF های اول، دوم و سوم به ترتیب در شکل‌های ۶، ۷ و ۸ نشان داده شده‌اند. همان‌طور که مشاهده می‌شود، برای IMF های اول، دوم و سوم به ترتیب، ویژگی‌های فاکتور شکل، انحراف معیار و انرژی بیشتر از بقیه ویژگی‌ها ظاهر شده‌اند.

بردارهای ویژگی حاصل از مشخصه‌های آماری پیشنهاد شده توسط الگوریتم بهینه‌سازی ازدحام ذرات در شکل ۹ رسم شده‌اند. همان‌طور که مشاهده می‌شود، داده‌های متناظر با شرایط مختلف چرخ‌دنده به خوبی از یکدیگر تفکیک شده‌اند. البته اگر بردار ویژگی برای هر نمونه سیگنال تنها دارای دو مؤلفه باشد، در این صورت، انتخاب زوج ویژگی‌های (انرژی IMF3، انحراف معیار IMF2) و (انحراف معیار IMF2، فاکتور

۵- از IMF های داده‌های آموزش، ویژگی‌های آماری گرفته شده در قسمت ۲، استخراج می‌شود.

۶- ماتریس ویژگی حاصل از مرحله قبل به دو مجموعه داده «داده‌های آموزش ماشین بردار پشتیبان» و «داده‌های اعتبارسنجی» تفکیک می‌شود.

۷- از مجموعه داده آموزش مرحله‌ی ششم، برای ساخت طبقه‌بندی کننده ماشین بردار پشتیبان از نوع «یک در برابر یک» و از مجموعه داده اعتبارسنجی برای آموزش این طبقه‌بندی کننده استفاده می‌شود.

۸- برای انتخاب مناسب‌ترین ویژگی برای هر IMF و پارامترهای ماشین بردار پشتیبان، از الگوریتم بهینه‌سازی ازدحام ذرات استفاده می‌شود. برای این منظور، تابع هدفی که باید کمینه شود، به صورت رابطه (۲۲) تعریف می‌گردد:

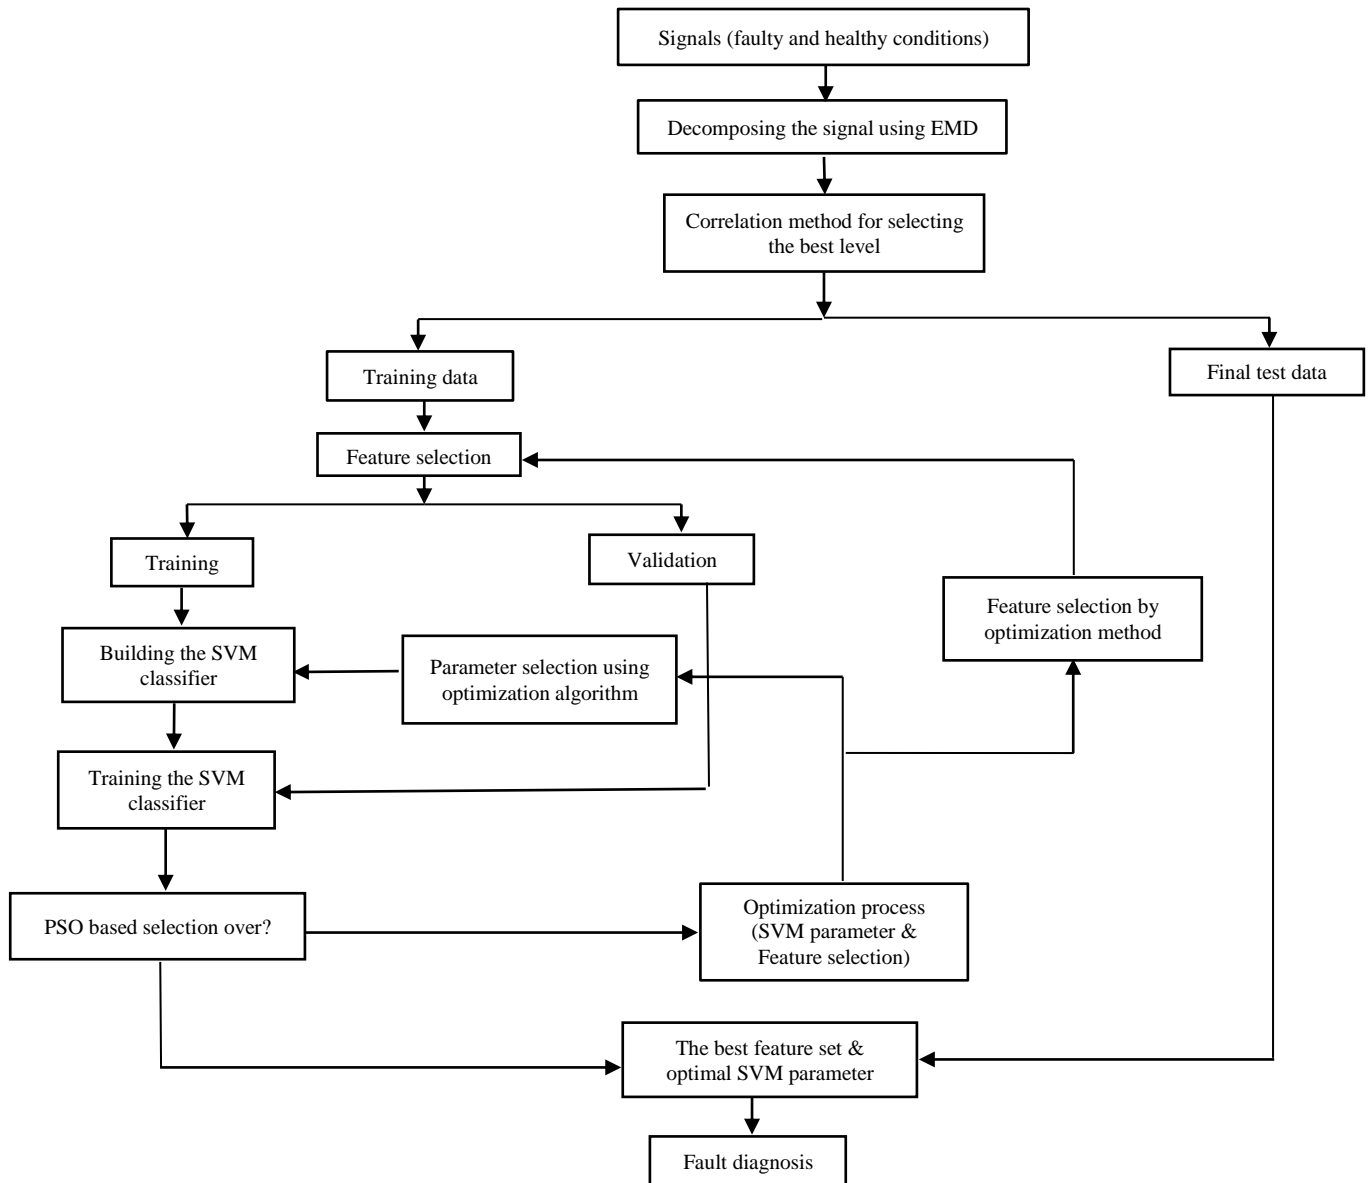
$$Fitness = \frac{Incorrectly\ Classified}{Classified\ Sample} \times 100 \quad (22)$$

متغیرهای تصمیم‌گیری در این بهینه‌سازی عبارتند از: پارامتر جریمه C، پارامتر تابع هسته ماشین بردار پشتیبان σ و نوع ویژگی. صورت و مخرج کسر فوق به ترتیب تعداد پیش‌بینی‌های نادرست و تعداد کل نمونه‌ها می‌باشند. کران‌های بالا و پایین پارامترهای C، σ و نوع ویژگی در جدول ۵ آمده‌اند.

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

جدول ۵- دامنه تغییرات متغیرهای طراحی

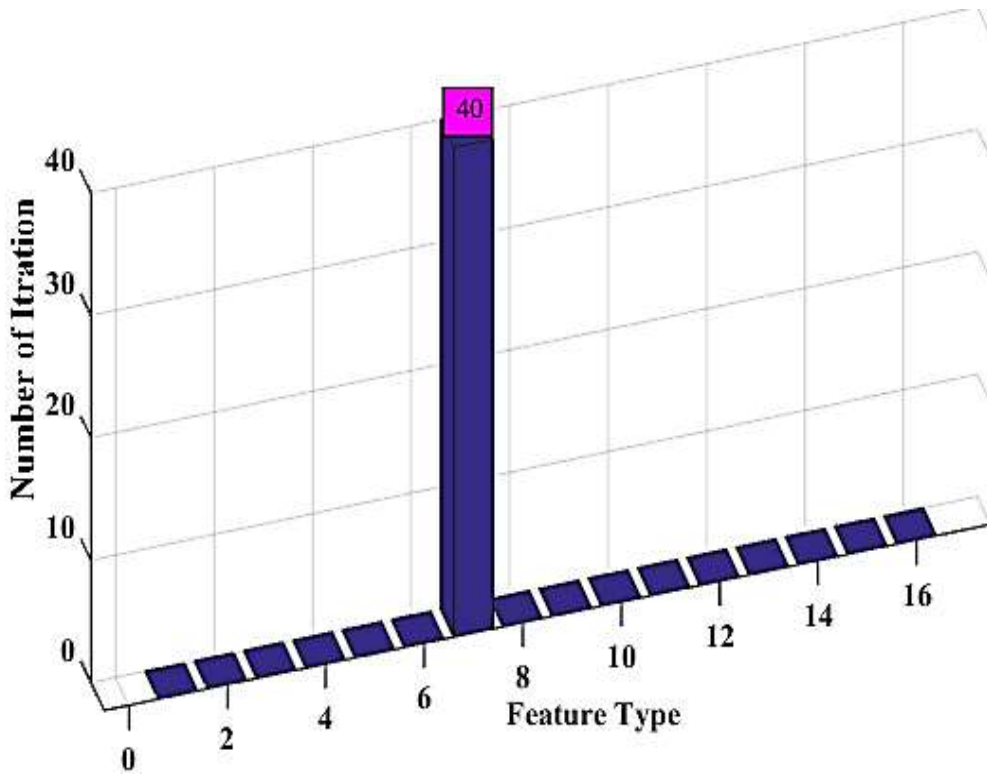
Variable	Lower bound	Upper bound
C	0.1	10
σ	0.1	1
Feature Type	1	16



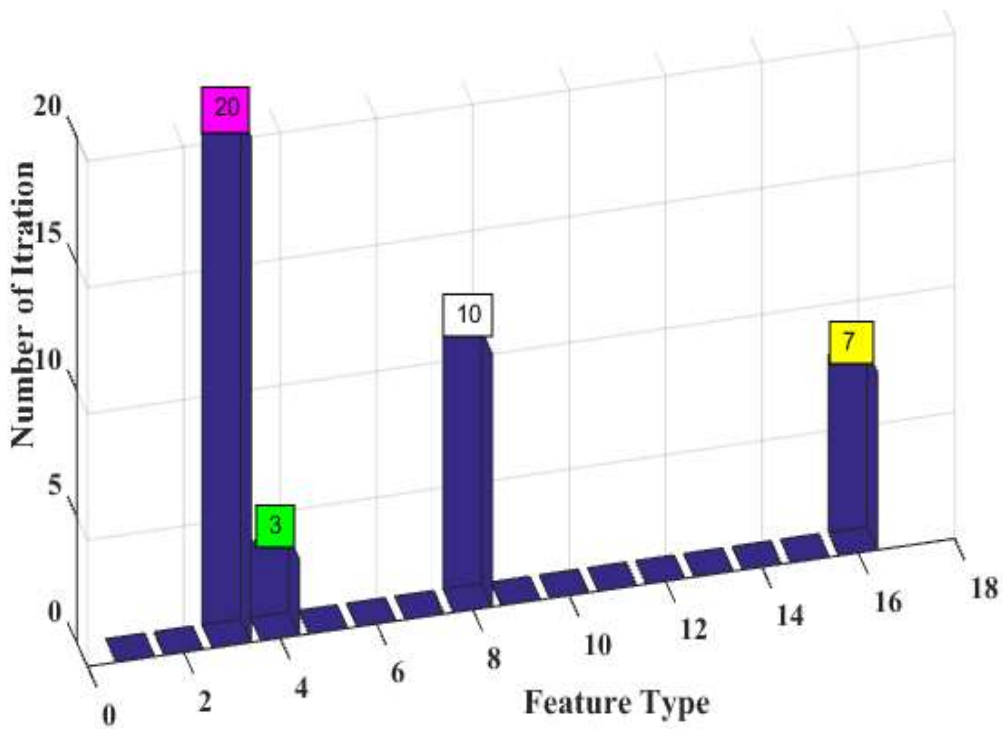
شکل ۵- فلوجارت روش پیشنهادی

روش پیشنهاد شده در [۲۰]، در شناسایی حالت سالم و لب‌پریدگی دندان‌ها دارای خطای ۵/۲۶۳۲ درصد در مرحله آموزش است؛ اما، با استفاده از روش ترکیبی ارائه شده در این مقاله می‌توان، هر سه حالت چرخ‌دنده را چه در مرحله آموزش و چه در مرحله آزمایش نهایی به درستی پیش‌بینی کرد. این نتایج، برتری روش ارائه شده در این مقاله را نسبت به دیگر تحقیقات ارائه شده در اینجا تایید نموده و قابلیت روش پیشنهاد شده را اثبات می‌کند.

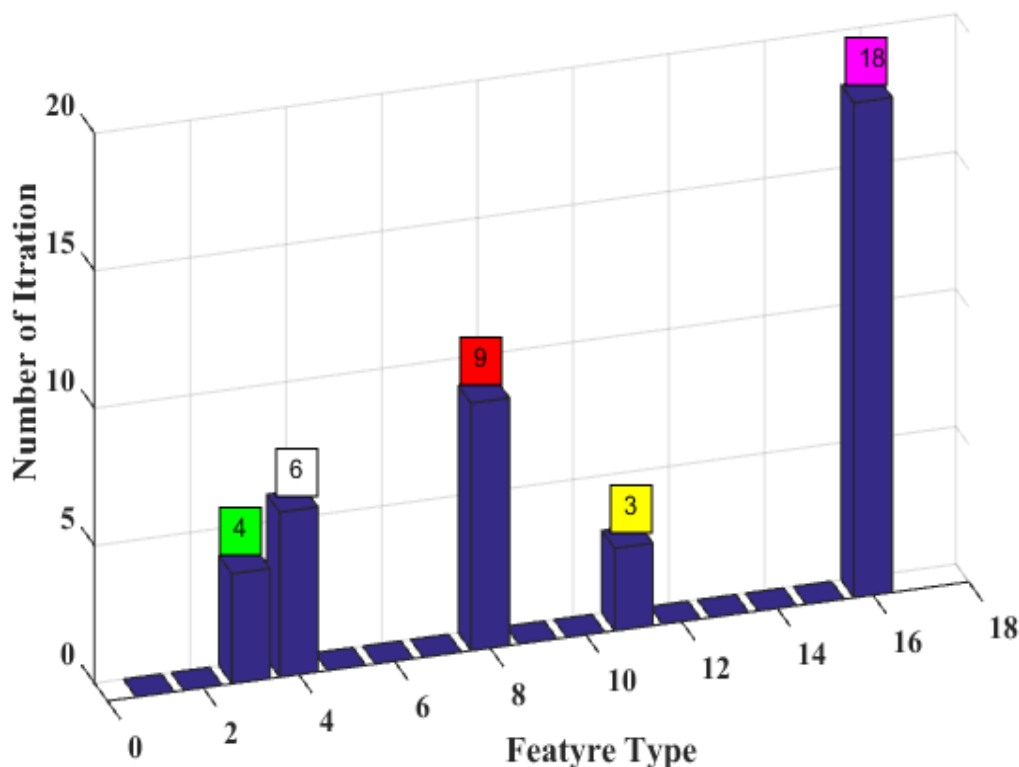
شکل IMF1 می‌تواند منجر به تفکیک بسیار خوب شرایط مختلف چرخ‌دنده شود. حال به منظور ارزیابی توانمندی روش پیشنهادی، نتایج حاصل از مراجع [۵، ۱۷ و ۲۰] و این مقاله، در جدول ۶ ارائه شده‌اند. مطابق این جدول، روش ارائه شده در [۵] تنها در مورد آزمایش نهایی سائیدگی دندان‌ها دارای خطای تشخیص ۳/۱۳ درصد است. الگوریتم ارائه شده در [۱۷]، دارای خطای ناچیز ۰/۶۷ درصد در تشخیص لب‌پریدگی و سائیدگی دندان‌ها در مرحله آزمایش نهایی است.



شکل ۶- تعداد دفعات انتخاب ویژگی‌ها برای IMF اول توسط الگوریتم بهینه‌سازی ازدحام ذرات



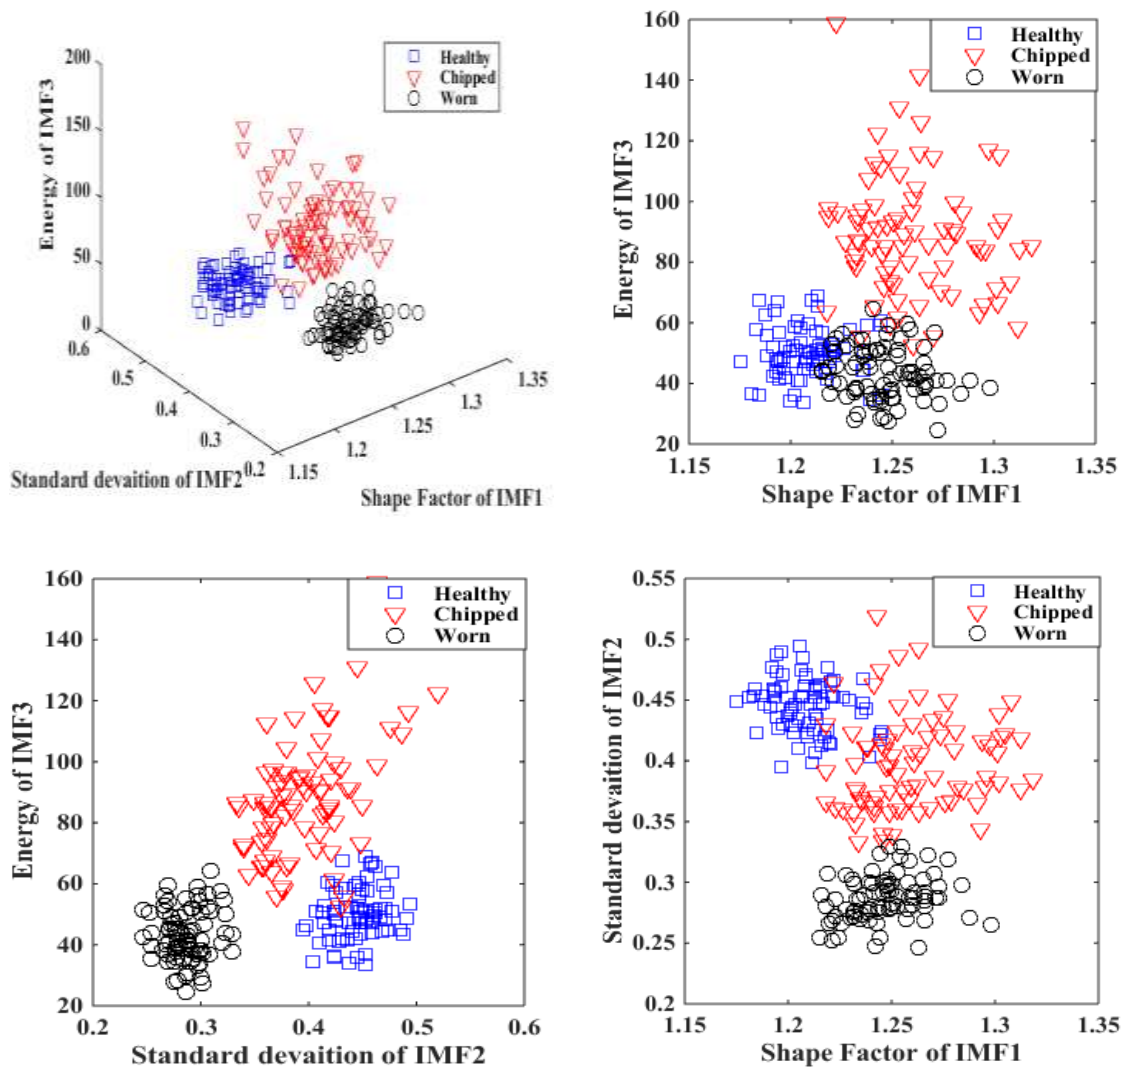
شکل ۷- تعداد دفعات انتخاب ویژگی‌ها برای IMF دوم توسط الگوریتم بهینه‌سازی ازدحام ذرات



شکل ۸- تعداد دفعات انتخاب ویژگی‌ها برای IMF سوم توسط الگوریتم بهینه‌سازی ازدحام ذرات

جدول ۶- مقایسه نتایج حاصل از روش پیشنهادی با روش‌های ارائه شده در [۵، ۱۷ و ۲۰]

Method	Characteristics feature	Classifier parameter	Healthy		Chipped tooth		Worn tooth	
			Train (%)	Test (%)	Train (%)	Test (%)	Train (%)	Test (%)
SVM (OAO)+FFT+GA [5]	Standar deviation Skewness Kurtosis	$C = 3.6774$ $\sigma = 0.2472$	100	100	100	100	100	96.875
Linear - SVM+ EMD [17]	Local Gaussian correlation	---	100	100	100	99.33	100	99.33
SVM (OAO)+EMD [20]	Energy	$C=10$ $\sigma = 0.8$	94.7368	100	94.7368	100	100	100
Presented method	IMF1 = shape factor IMF2 = Standar deviation IMF3 = energy	$C=1.7590$ $\sigma = 0.5107$	100	100	100	100	100	100



شکل ۹- بردارهای ویژگی حاصل از انتخاب ویژگی‌های بهینه توسط الگوریتم بهینه‌سازی ازدحام ذرات

گردید. طبق نتایج به دست آمده از روش فوق، سه IMF اول، حاصل از روش تجزیه مود تجربی بالاترین ضریب همبستگی را با سیگنال اصلی داشته و جهت استخراج ویژگی‌های آماری انتخاب شدند. سپس، جهت تشکیل ماتریس ویژگی از انواع توابع آماری مختلف استفاده گردید. در قدم بعدی، از روش ماشین بردار پشتیبان برای طبقه‌بندی حالت چرخ‌دنده بهره گرفته شد و در نهایت، از الگوریتم بهینه‌سازی ازدحام ذرات جهت انتخاب مناسب‌ترین ویژگی و تعیین پارامترهای ماشین بردار پشتیبان استفاده شد. نتایج نشان می‌دهند که اگر برای IMFهای اول، دوم و سوم به ترتیب ویژگی‌های فاکتور شکل،

۱۰- نتیجه‌گیری

در این مقاله، روش نوینی جهت عیب‌یابی چرخ‌دنده در حالت چند کلاسه، بر اساس استراتژی انتخاب بهترین مؤلفه‌های حاصل از تجزیه سیگنال‌های ارتعاشی و تشکیل بهترین ماتریس ویژگی، با ترکیب روش‌های تجزیه مود تجربی، مفهوم همبستگی متقابل، ماشین بردار پشتیبان از نوع «یک در برابر یک» و الگوریتم بهینه‌سازی ازدحام ذرات ارائه شد. به منظور استخراج ویژگی‌های محلی سیگنال ارتعاشی، از روش تجزیه مود تجربی بهره گرفته شد؛ سپس، از مفهوم همبستگی متقابل جهت انتخاب مناسب‌ترین IMF استفاده

[10] Dalian Y, Liyong M (2015) Gear fault diagnosis based on support vector machine optimized by artificial bee colony algorithm. *Mech Mach Theory* 90: 219-229.

[11] Ziani R, Felkaoui A, Zegadi R (2017) Bearing fault diagnosis using multiclass support vector machines with binary particle swarm optimization and regularized fisher's criterion. *J Intell Manuf* 28(2): 405-417.

[12] Zhang X, Zhang Q, Chen M, Sun Y, Qin X, Li H (2018) A two-stage feature selection and intelligent fault diagnosis method for rotating machinery using hybrid filter and wrapper method. *Neurocomputing* 275: 2426-2439.

[13] Tabrizi A, Garibaldi L, Fasana A, Marchesiello S (2014) 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* 389-398.

[14] Dhamandeh SL, Chaudhari BM, (2016) Detection of Combined gear-bearing fault in single stage spur gear box using artificial neural network. *Procedia Eng* 144: 759-766.

[15] Pirra M, Fasana A, Garibaldi L, Marchesiello S (2012) Damage identification and external effects removal for roller bearing diagnostics. *European Conference of the Prognostics and Health Management Society, Germany* 1-8.

[16] Djebala A, Babouri MK, Ouelaa, N (2015) Rolling bearing fault detection using a hybrid method based on empirical mode decomposition and optimized wavelet multi-resolution analysis. *Int J Adv Manuf Tech* 79: 2093-2105.

[17] Zamanian AH, Ohadi A (2011) Gear fault diagnosis based on gaussian correlation of vibrations signals and wavelet coefficients. *Appl Soft Comput* 11: 4807-4819.

[18] Zhong J, Ma W, Lin J, Ma L, Jia X (2014) Fault diagnosis approach for rotating machinery based on dynamic model and computational intelligence. *Measurement* 59: 73-87.

[19] Widodo A, Yang BS (2007) Support vector machine in machine condition monitoring and fault diagnosis. *Mech Syst Signal Process* 21(6): 2560-2574.

[20] Tabrizi AA (2015) Development of new fault detection methods for rotating machines (roller bearings). PhD thesis, University of Politecnico di Torino.

[21] Jin S, Kim SJ, Lee KS (2015) Sensitive method for detecting tooth faults in gearboxes based on wavelet denoising and empirical mode decomposition. *J Mech Science Tech* 29(8): 3165-3173.

انحراف معیار و انرژی انتخاب شوند، حالت‌های چرخ‌دنده از یکدیگر به خوبی تفکیک شده و ماشین بردار پشتیبان 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] Lei Y, Lin J, He Z, Zuo M (2013) A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mech Syst Signal Process* 35: 108-126.

[2] Ben Ali J, Fnaiech N, Saidi L, Chebel-Morello B, Fnaiech F (2015) Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Appl Acoust* 89: 16-27.

[۳] چایی‌بخش ع، رهبر م (۱۳۹۵) مقایسه‌ای بین تجزیه حالت تجربی و تبدیل موجک در تشخیص نابالانسی ماشین دوار با استفاده از ماشین بردار پشتیبان بهینه. *مجله علمی پژوهشی مهندسی مکانیک مدرس* ۳۳۲-۳۲۵: ۱۷(۲).

[4] Rajeswari C, Sathiyabhama B, Devendiran S, Manivannan K (2014) A gear fault identification using wavelet transform, rough set based GA, ANN and C4.5 algorithm. *Procedia Eng* 97: 1831-1841.

[5] Bordoloi DJ, Tiwari R (2014) Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time-frequency vibration data. *Measurement* 55: 1-14.

[6] Bordoloi DJ, Tiwari R (2014) Optimum multi-fault classification of gears with integration of evolutionary and SVM algorithms. *Mech Mach Theory* 73: 49-60.

[7] Bordoloi DJ, Tiwari R, (2015) 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* 21: 533-542.

[8] Liu Z, Cao H, Chen X, He Z, Shen Z (2013) Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings. *Neurocomputing* 99: 399-410.

[9] Jack LB, Nandi AK (2002) Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms. *Mech Syst Signal Process*, 16 (2-3): 373-390.

- [23] Ratnaweera A, Halgamuge SK, Watson HC (2004) Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients. IEEE T Evolut Comput 8(3):240-255.
- [22] Shi Y, Eberhart R, (1998) A modified particle swarm optimizer. In: The 1998 IEEE International Conference on Evolutionary Computation Proceedings, Anchorage, AK 69-73.