



A New Hybrid Intelligent Technique Based on Improving the Compensation Distance Evaluation Technique and Support Vector Machine for Bearing Fault Diagnosis

ARTICLE INFO

Article Type

Original Research

Authors

Nezamivand Chegini S.¹ MSc,
Bagheri A.*¹ PhD,
Najafi F.¹ PhD

How to cite this article

Nezamivand Chegini S, Bagheri A, Najafi F. A New Hybrid Intelligent Technique Based on Improving the Compensation Distance Evaluation Technique and Support Vector Machine for Bearing Fault Diagnosis. Modares Mechanical Engineering. 2019;19(4):865-875.

¹Dynamic, Control & Vibration Department, Mechanical Engineering Faculty, University of Guilan, Rasht, Iran

*Correspondence

Address: Mechanical Faculty, University of Guilan, Rasht, Iran
Phone: +98 (13) 33843854
Fax: +98 (13) 33691065
bagheri@guilan.ac.ir

Article History

Received: June 13, 2018
Accepted: November 18, 2018
ePublished: April 06, 2019

ABSTRACT

In this paper, a new hybrid intelligent method is presented for detecting the bearing faults in the various rotating speeds. The vibration signals are collected in four conditions, including the normal state, the faulty inner race, the faulty outer race, and the faulty bearing element. Firstly, twenty-two statistical features in the time domain and four frequency features, three Wavelet packet decomposition (WPD), and the first five intrinsic mode functions obtained by the empirical mode decomposition (EMD) are extracted from the original signal; finally, the feature vector for each signal sample has 424 features. However, in the high dimensional feature matrix, there may exist the insensitive features to the presence of defects. Therefore, in this study, the compensation distance evaluation technique (CDET) is used to select the optimal features. Then, the selected features are used as the inputs of the support vector machine (SVM) classifier to diagnose the bearing conditions. In the CDET method, there is a threshold indicator that plays a decisive role in choosing the desired attributes. Also, the SVM method has some parameters that need to be set during the fault detection process. Therefore, the particle swarm optimization (PSO) algorithm is used to determine the optimal threshold in the CDET method and the optimal SVM parameters, so that the prediction error of the bearing conditions and the number of the selected features are minimized. The obtained results demonstrate that the selected features are well able to differentiate between different bearing conditions at various speeds. Comparing the results of this paper with other fault detection methods indicates the ability of the proposed method.

Keywords Bearing Fault Diagnosis; Feature Extraction; Feature Selection; Support Vector Machine; Particle Swarm Optimization

CITATION LINKS

- [1] Fault diagnosis of rotating machinery using an improved HHT based on EEMD and sensitive ..
- [2] Sensitive method for detecting tooth faults in gearboxes based on wavelet denoising and empirical mode ...
- [3] An improvement EMD method based on the optimized rational Hermite interpolation approach and its application to gear fault ...
- [4] An improved EMD method based on the multi-objective optimization and its application to fault feature extraction of rolling ...
- [5] Robust condition monitoring of rolling element bearings using de-noising and envelope analysis with signal decomposition ...
- [6] Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time-frequency vibration ...
- [7] Optimum multi-fault classification of gears with integration of evolutionary and SVM ...
- [8] Optimisation of SVM methodology for multiple fault taxonomy of rolling bearings from acceleration ...
- [9] Early damage detection of roller bearings using wavelet packet decomposition, ensemble empirical mode decomposition and support vector ...
- [10] New clustering algorithm-based fault diagnosis using compensation distance evaluation ...
- [11] ART-KOHONEN neural network for fault diagnosis of rotating machinery
- [12] Multiple fault classification using support vector machine in a machinery fault ...
- [13] A fault diagnosis method for rotating machinery based on PCA and Morlet kernel ...
- [14] Diagnostics of gear deterioration using EEMD approach and PCA ...
- [15] Bearing fault diagnosis using multiclass support vector machines with binary particle swarm optimization and regularized Fisher's ...
- [16] A two-stage feature selection and intelligent fault diagnosis method for rotating machinery using hybrid filter and wrapper ...
- [17] Face feature selection with binary particle swarm optimization and support vector ...
- [18] Bearing data ...
- [19] A cointegration-based monitoring method for rolling bearings working in time-varying operational ...
- [20] Intelligent condition monitoring of a gearbox using artificial neural ...
- [21] PSOSCALF: A new hybrid PSO based on Sine Cosine Algorithm and Levy flight for solving optimization ...

روش ترکیبی هوشمند جدید برای عیب‌یابی یاتاقان بر پایه بهبود روش انتخاب ویژگی ارزیابی جبران فاصله و ماشین بردار پشتیبان

سعید نظامیوندچگینی MSc

گروه دینامیک، کنترل و ارتعاشات، دانشکده مهندسی مکانیک، دانشگاه گیلان،
رشت، ایران

احمد باقری * PhD

گروه دینامیک، کنترل و ارتعاشات، دانشکده مهندسی مکانیک، دانشگاه گیلان،
رشت، ایران

فرید نجفی PhD

گروه دینامیک، کنترل و ارتعاشات، دانشکده مهندسی مکانیک، دانشگاه گیلان،
رشت، ایران

چکیده

در این مقاله، یک روش جدید برای عیب‌یابی یاتاقان‌ها در سرعت دورانی‌های مختلف ارائه شده است. سیگنال‌های ارتعاشی در چهار حالت سالم، رینگ داخلی معیوب، رینگ خارجی معیوب و المان ساچمه معیوب جمع‌آوری شده‌اند. ابتدا ۲۲ ویژگی آماری در حوزه زمان و ۴ ویژگی در حوزه فرکانس از سیگنال اصلی، ۳ سطح تجزیه حاصل از تبدیل بسته‌ی موجک (WPD) و ۵ مولفه اول حاصل از تجزیه مود تجربی (EMD) استخراج شده‌اند و در نهایت، بردار ویژگی برای هر نمونه سیگنال دارای ۴۲۴ ویژگی است. ماتریس ویژگی با ابعاد بزرگ ممکن است شامل ویژگی‌های غیرحساس به عیب باشد. از این رو در این مطالعه از روش انتخاب ویژگی ارزیابی جبران فاصله (CDET) برای انتخاب ویژگی‌های بهینه استفاده شده است. سپس، از ویژگی‌های منتخب به‌عنوان ورودی طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM) برای پیش‌بینی وضعیت یاتاقان استفاده شده است. در روش CDET، شاخص آستانه‌ای وجود دارد که نقش تعیین‌کننده‌ی در انتخاب ویژگی‌های مطلوب ایفا می‌نماید. همچنین، روش SVM دارای پارامترهایی است که لازم است حین عیب‌یابی تنظیم شوند. از این رو در این مطالعه از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای تعیین مقادیر بهینه شاخص آستانه در روش CDET و پارامترهای بهینه SVM استفاده شده است، به‌طوری که خطای پیش‌بینی شرایط یاتاقان و تعداد ویژگی‌های منتخب کمینه شوند. نتایج به‌دست‌آمده در این مقاله نشان می‌دهد که ویژگی‌های انتخاب‌شده به‌خوبی قادر به تفکیک شرایط مختلف یاتاقان در سرعت‌های مختلف هستند. مقایسه نتایج این مقاله با دیگر روش‌های عیب‌یابی، دلالت بر توانمندی روش پیشنهادی می‌کند.

کلیدواژه‌ها: عیب‌یابی یاتاقان، استخراج ویژگی، انتخاب ویژگی، ماشین بردار پشتیبان، الگوریتم بهینه‌سازی ازدحام ذرات

تاریخ دریافت: ۱۳۹۷/۰۳/۲۳

تاریخ پذیرش: ۱۳۹۷/۰۸/۲۷

*نویسنده مسئول: bagheri@guilan.ac.ir

۱- مقدمه


یاتاقان‌ها یکی از اجزای مهم ماشین‌های دوار به شمار می‌آیند، به‌طوری که خرابی این جزء ممکن است باعث از کارافتادگی کامل ماشین‌ها شود. از این رو، تشخیص حضور عیب و مشخصات آن نقش بسیار مهمی در حوزه نگهداری ماشین‌ها ایفا می‌کند. تاکنون روش‌های مختلفی برای پیش‌بینی وضعیت یاتاقان‌ها توسط محققان پیشنهاد شده که از بین آنها، تحلیل سیگنال‌های ارتعاشی به‌طور ویژه مورد توجه بوده است. از طرفی سیگنال‌های ارتعاشی اکتساب‌شده از سیستم‌های دوار، غیرخطی و غیرایستا هستند و از این رو روش‌های معمول در حوزه زمان و فرکانس قادر به تشخیص شرایط مختلف عیب نیستند. در سال‌های اخیر، روش‌های هوشمند پیشرفته‌ای در حوزه زمان-فرکانس برای استخراج ویژگی از سیگنال‌ها ارائه شده است. این تکنیک‌ها معمولاً به‌صورت ترکیبی از روش‌های پیش‌پردازش، استخراج ویژگی، پس‌پردازش و شناسایی الگو هستند.

بین روش‌های تحلیل سیگنال، روش تجزیه مود تجربی (EMD) و بهبودیافته‌های آن به‌طور گسترده‌ای در عیب‌یابی مورد استفاده قرار گرفته‌اند. لی و زوو^[1] به‌منظور عیب‌یابی ماشین‌های دوار، تبدیل هیلبرت-هوانگ را به‌کمک روش تجزیه مود تجربی کلی بهبود داده و روشی بر پایه همبستگی بین سیگنال ارتعاشی و مولفه‌های حاصل از تجزیه آن برای انتخاب مناسب‌ترین مولفه ارائه نموده‌اند. جین و همکاران^[2] از تکنیک بی‌نویزسازی سیگنال به‌کمک موجک و روش تجزیه مود تجربی، روشی را برای تشخیص عیوب دندان‌های چرخ‌دنده‌ها ارائه نموده‌اند. در برخی از پژوهش‌ها^[3, 4] محققان با بهبود روش استخراج منحنی‌های پوش، تکنیک تجزیه مود تجربی را ارتقا داده و سپس از الگوریتم‌های حاصل برای عیب‌یابی چرخ‌دنده‌ها و یاتاقان‌ها استفاده نموده‌اند. نگوین و همکاران یک تکنیک عیب‌یابی مقاوم برای یاتاقان‌های غلتشی ارائه کرده‌اند^[5]. آنها رویکردی جدید بر پایه بی‌نویزسازی به‌کمک روش EMD، طبقه‌بندی‌کننده بی‌زین و آستانه‌گذاری مولفه‌های دارای نویز پیشنهاد کرده‌اند. سپس با بهره‌گیری از تبدیل بسته‌ی موجک، تبدیل هیلبرت و محاسبه پوش سیگنال، تکنیکی برای شناسایی حالت یاتاقان ارائه داده‌اند.

در روش‌های شناسایی هوشمند عیب، پس از بی‌نویزسازی و تجزیه سیگنال، از تکنیک‌های استخراج و انتخاب ویژگی‌های مناسب و شناسایی حالت سیستم استفاده می‌شود. بردولویی و تیوری^[6-8] در یک مجموعه تحقیقات، یک روش طبقه‌بندی چندکلاسه برای تعیین عیب چرخ‌دنده‌ها و یاتاقان‌ها ارائه نموده‌اند. آنها قبل از یادگیری و تست نهایی ماشین بردار پشتیبان (SVM)، پارامترهای این شبکه را توسط الگوریتم‌های بهینه‌سازی ژنتیک و زنبور عسل بهینه نموده‌اند. توابع آماری مانند کشیدگی، انحراف‌معیار و چولگی استخراج‌شده از حوزه زمان و فرکانس، ویژگی‌هایی هستند که به‌عنوان ورودی SVM استفاده شده‌اند. تبریزی و همکاران^[9] برای شناسایی زودهنگام عیب در یاتاقان‌ها، از تجزیه بسته‌ی موجک (WPD) برای بی‌نویزسازی سیگنال‌های ارتعاشی استفاده نموده‌اند. سپس، مولفه‌های پرمعنی سیگنال را به‌کمک تجزیه مود تجربی کلی (EEMD) استخراج نموده‌اند. آنها ماتریس ویژگی را به‌کمک ویژگی انرژی نرمالیزه‌شده مولفه‌های سیگنال تشکیل داده و از آن به‌عنوان ورودی ماشین بردار پشتیبان استفاده نموده‌اند.

در دیگر مطالعات برای افزایش دقت عیب‌یابی، از ویژگی‌های متفاوت دیگری نظیر سطوح مختلف تبدیل بسته‌ی موجک، ویژگی‌های حوزه زمان و فرکانس مربوط به مولفه‌های حاصل از روش EMD و EEMD استفاده نموده‌اند. به هر حال با افزایش تعداد ویژگی‌ها، بردار ویژگی خام نه‌تنها شامل ویژگی‌های مفید است، بلکه شامل ویژگی‌های نامرتب و زاید خواهد بود. از این رو استفاده از یک روش انتخاب ویژگی ضروری به نظر می‌رسد. در برخی از پژوهش‌ها^[10, 11] از تکنیک ارزیابی جبران فاصله (CDET) برای انتخاب مناسب‌ترین ویژگی از فضای ویژگی‌ها استفاده شده است. فاطیما و همکاران^[12] با استفاده از SVM، به مطالعه طبقه‌بندی عیوب در یاتاقان‌ها در پنج سرعت مختلف پرداخته‌اند. آنها ابتدا ۱۲ ویژگی در حوزه زمان از سیگنال، استخراج و سپس از روش ارزیابی فاصله برای انتخاب مناسب‌ترین ویژگی به‌عنوان ورودی SVM چندکلاسه استفاده کرده‌اند. دوک و همکاران^[13] پس از استخراج ویژگی آنروپی انرژی مربوط به مولفه‌های حاصل از روش EMD، از روش تحلیل مولفه اصلی (PCA) برای کاهش فضای ویژگی بهره برده‌اند. سپس از سه مولفه اصلی اول به‌عنوان ورودی ماشین بردار پشتیبان بهبودیافته با تابع موجک مورله و

روش ترکیبی هوشمند جدید برای عیب‌یابی یاتاقان بر پایه بهبود روش انتخاب ویژگی ارزیابی... ۸۶۷
 ۳ بر حسب HP و به ترتیب در سرعت دورانی‌های ۱۷۹۷، ۱۷۷۲، ۱۷۵۰ و ۱۷۳۰ بر حسب rpm توسط یک سنسور شتاب با نرخ نمونه‌برداری ۱۲KHz جمع‌آوری شده‌اند. در این مطالعه، برای بررسی حالت چندکلاسه عیب، چهار حالت سالم، ساچمه معیوب، رینگ داخلی معیوب و رینگ خارجی معیوب مورد توجه قرار گرفته است.



شکل ۱) مجموعه آزمایشگاهی شناسایی عیب در یاتاقان [18]

جدول ۱) جزئیات یاتاقان غلتشی [18]

پارامتر	مقادیر (mm)
قطر رینگ داخلی	۲۵
قطر رینگ خارجی	۵۲
ضخامت	۱۵
قطر ساچمه	۸
قطر گام	۳۹

۳- روش‌ها

در این بخش، روش‌های مورد استفاده در این مطالعه به‌طور خلاصه شرح داده خواهند شد.

۳-۱- روش تجزیه مود تجربی

روش تجزیه مود تجربی برای تحلیل سیگنال‌های غیرایستا و غیرخطی پیشنهاد شده است. این روش می‌تواند هر سیگنال پیچیده را به‌طور تطبیقی‌پذیری به یک سری توابع مود ذاتی (IMFs) از فرکانس بالا به فرکانس پایین تجزیه کند. سیگنال تجزیه شده را می‌توان به‌صورت زیر نوشت [19]:

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

که $c_i(t)$ ، امین تابع مود ذاتی و $r_n(t)$ باقیمانده سیگنال $x(t)$ را نشان می‌دهد. هر IMF شرایط زیر را ارضا می‌کند:

۱- در کل مجموعه داده، تعداد نقاط اکسترمم (بیشینه و کمینه) و تعداد نقاط عبور صفر با هم برابر 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.

۳-۲- استخراج ویژگی

به دلیل ماهیت غیرخطی بودن دینامیک یاتاقان‌ها و غیرایستابودن سیگنال‌های ارتعاشی، اگر تنها به بررسی سری‌های زمانی مربوط به داده‌های ارتعاشی اکتفا شود، اطلاعات چندانی نمی‌توان در خصوص نوع و اندازه عیب به دست آورد. بنابراین، در اینجا از روش‌های مختلف استخراج ویژگی استفاده خواهد شد.

در این مقاله، برای تشکیل بردار ویژگی برای هر سیگنال ارتعاشی به‌صورت زیر عمل شده است:


الگوریتم PSO استفاده کرده‌اند. یانگ و وو از رویکرد ترکیبی تجزیه مود تجربی کلی، فرآیند تحلیل مولفه اصلی و شبکه عصبی مصنوعی برای تشخیص عیب در جعبه‌دنده‌ها استفاده نموده‌اند [14]. زبانی و همکاران با معیار فیشر و الگوریتم بهینه‌سازی ازدحام ذرات باینری (BPSO)، روشی برای انتخاب مناسب‌ترین مجموعه از ویژگی‌های استخراج شده از سیگنال‌های ارتعاشی یاتاقان‌ها ارائه نموده‌اند. سپس، از ویژگی‌های منتخب به‌عنوان ورودی‌های SVM چندکلاسه استفاده نموده‌اند [15]. یانگ و همکاران [16] روشی شامل دو مرحله برای عیب‌یابی یاتاقان‌ها ارائه نموده‌اند. در مرحله اول، به‌کمک روش ReliefF، مجموعه اولیه‌ای از همه ویژگی‌ها انتخاب شده است. در مرحله دوم، مجموعه ویژگی بهینه و پارامترهای الگوریتم SVM طوری تعیین شده‌اند که خطای پیش‌بینی وضعیت یاتاقان و تعداد ویژگی‌ها کمینه شوند. بین و همکاران [17] روشی ارائه نموده‌اند که قادر است ویژگی‌های مناسب را به‌طور مستقیم از مجموعه ویژگی‌های اصلی، انتخاب و هم‌زمان پارامترهای SVM را بهینه نماید.

در اکثر الگوریتم‌های انتخاب ویژگی نظیر CDET، پارامتری تحت عنوان آستانه وجود دارد که نقش ویژه‌ای در تعیین ویژگی‌های بهینه ایفا می‌نماید. لازم به ذکر بوده که مقدار این پارامتر در چند پژوهش [10-12] به‌صورت سعی و خطا تعیین شده است. در این مقاله، پس از تجزیه سیگنال به‌کمک تبدیل بسته‌ای موجک و تجزیه مود تجربی، ویژگی‌های حوزه زمان و فرکانس مربوط به مولفه‌ها و سطوح حاصل از تجزیه برای تشکیل ماتریس ویژگی استخراج شده‌اند. با توجه به ابعاد بسیار بالای ماتریس ویژگی حاصل، از الگوریتم CDET برای انتخاب مناسب‌ترین ویژگی استفاده شده است. در این مقاله، مقدار پارامتر آستانه بهینه در CDET و پارامترهای بهینه SVM به‌کمک الگوریتم PSO به‌گونه‌ای تعیین شده‌اند که خطای تشخیص شرایط یاتاقان و ابعاد بردارهای ویژگی کمینه شود. نتایج نشان می‌دهند که روش پیشنهادی دارای توانمندی بسیار خوبی در شناسایی نوع و اندازه عیب در یاتاقان است.

دیگر بخش‌های این مقاله بدین صورت تدوین یافته‌اند که در بخش دوم، مجموعه آزمایشگاهی تشریح خواهد شد. در بخش سوم به تشریح روش‌های عیب‌یابی مورد استفاده در این مقاله پرداخته خواهد شد. جزئیات روش پیشنهادی در بخش چهارم آمده و بخش پنجم، به تحلیل نتایج حاصل از این مقاله پرداخته شده و در نهایت، مقاله در بخش ششم نتیجه‌گیری شده است.

۲- مجموعه آزمایشگاهی

برای سیگنال‌های ارتعاشی در این مقاله از مجموعه آزمایشگاهی گرفته شده از وب‌سایت CWRU استفاده شده است [18]. این داده‌ها به‌طور گسترده‌ای توسط محققان برای ارزیابی الگوریتم‌های پیشنهادی خود مورد استفاده قرار گرفته‌اند [4, 13, 15, 16]. مطابق با شکل ۱، این مجموعه شامل یک موتور (سمت چپ)، کولپلینگ (وسط) و موتور دینام (سمت راست) است. عیوب ایجاد شده در یاتاقان‌ها به‌کمک روش‌های ماشین‌کاری الکتریکی ایجاد شده‌اند. سیگنال‌های ارتعاشی به‌کاررفته در این مقاله، مربوط به یاتاقان از نوع SKF 6205-2RS JEM است. مشخصات این یاتاقان در جدول ۱ ارائه شده است. عیوب ایجاد شده در المان‌های ساچمه، رینگ داخلی و رینگ خارجی دارای عمق ۰/۲۷۹mm و قطرهای مختلف ۰/۱۷۷۸، ۰/۳۵۵۶، ۰/۵۳۳۴ و ۰/۷۱۱۲ بر حسب mm هستند. داده‌های ارتعاشی برای چهار بارگذاری مختلف صفر، ۱، ۲ و



شکل ۲) درخت تجزیه تبدیل بسته‌ای موجک در سطح ۳

پس از استخراج ویژگی از تمامی سیگنال‌های ارتعاشی، ماتریس ویژگی به شکل کلی زیر حاصل می‌شود:

$$FM = [f_{m,c,j}] \quad (۲)$$

که در آن $m = 1, 2, \dots, M_C$ ، $c = 1, 2, \dots, C$ و $j = 1, 2, \dots, J$ است.

در این ماتریس، $F_i = f_{m,c,j}$ ویژگی زام متناظر با نمونه سیگنال m ام تحت شرایط c ام است. M_C تعداد سیگنال‌های متناظر با وضعیت c ، J تعداد ویژگی‌های استخراج شده از هر سیگنال ارتعاشی و C تعداد شرایط مختلف است. شماره ویژگی‌های متناظر با هر کدام از روش‌های استخراج ویژگی بالا در جدول ۳ ارائه شده‌اند.

در این مقاله، تعداد ویژگی‌ها برای هر نمونه سیگنال برابر با $J=۴۲۴$ و تعداد شرایط مورد بررسی یعنی C برابر با کلاس‌های مختلف عیب یا اندازه‌های مختلف عیب است.

جدول ۳) ویژگی‌های استخراج شده

ویژگی‌ها	روش استخراج ویژگی
F ₁ -F ₂₀	ویژگی‌های حوزه زمان از سیگنال اصلی
F ₂₁ -F ₁₂₀	ویژگی‌های حوزه زمان برای پنج IMF اول
F ₁₂₁ -F ₁₂₄	ویژگی‌های حوزه فرکانس از سیگنال اصلی
F ₁₂₅ -F ₁₄₄	ویژگی‌های حوزه فرکانس از پنج مولفه اول
F ₁₄₅ -F ₄₂₄	ویژگی‌های حوزه زمان از ۱۴ ضریب حاصل از تبدیل بسته‌ای موجک

۳-۳- بهبود روش ارزیابی جبران فاصله برای انتخاب مناسب‌ترین ویژگی‌ها

اگر ابعاد فضای ویژگی‌های استخراج شده از داده‌های آموزش بسیار بزرگ باشد، در این صورت ماتریس ویژگی نه تنها شامل ویژگی‌های حساس به عیب است، بلکه ویژگی‌های غیرحساس و اضافی نیز در این ماتریس ظاهر خواهند شد. به کارگیری یک ماتریس ویژگی با ابعاد بسیار بالا به عنوان ورودی‌های طبقه‌بندی‌کننده‌های مختلف، منجر به افزایش زمان محاسبات، کاهش کارایی و دقت روش‌های هوشمند در پیش‌بینی وضعیت یک سیستم می‌شود. از این رو، در پژوهش‌های اخیر از روش‌های مختلف انتخاب ویژگی نظیر تحلیل مولفه‌های اصلی [15]، تحلیل تفکیک‌کننده فیشر (FDA) [13] و تکنیک ارزیابی جبران فاصله [10] برای حل مساله کاهش فضای ویژگی و انتخاب ویژگی‌های موثر استفاده شده است. در این مقاله، روشی برای بهبود تکنیک ارزیابی جبران فاصله ارائه خواهد شد و سپس از این روش بهبودیافته برای انتخاب

۱- از هر سیگنال خام، ویژگی‌های آماری حوزه زمان مطابق با جدول ۲ استخراج شده است (ویژگی‌های F₁-F₂₀).

۲- هر سیگنال ارتعاشی توسط الگوریتم تطبیقی EMD به مولفه‌های مختلف تجزیه شده است. از آنجایی که چند مولفه اول سیگنال نسبت به بقیه IMFها دارای اطلاعات بیشتری از عیب هستند [19]، لذا در این مطالعه پنج مولفه اول، انتخاب و ویژگی‌های جدول ۲ برای هر IMF منتخب استخراج شده‌اند (ویژگی‌های F₂₁-F₁₂₀).

۳- از هر سیگنال خام، ویژگی‌های حوزه فرکانس مطابق با جدول ۲ به دست آمده‌اند (ویژگی‌های F₁₂₁-F₁₂₄). همین ویژگی‌ها برای IMFهای منتخب محاسبه شده‌اند (ویژگی‌های F₁₂₅-F₁₄₄).

۴- یکی از ابزارهای مناسب استخراج ویژگی در زمینه عیب‌یابی، استفاده از روش تجزیه بسته‌ای موجک است. این روش در تحلیل فرکانس پایین و بالای سیگنال‌های غیرایستا دارای عملکرد خوبی است. از طرفی انتخاب نوع موجک مادر بر کارایی روش تجزیه WPD بسیار اثرگذار است. در پژوهشی [20] نشان داده شده که موجک db44 مناسب‌ترین موجک در زمینه شناسایی عیوب یاتاقان و جعبه‌دنده است. از این رو، در این مطالعه از موجک db44 برای تحلیل سیگنال‌های ارتعاشی، استفاده و مطابق با شکل ۲، بیشترین عمق مربوط به درخت تجزیه برابر با ۳ در نظر گرفته شده است. در نهایت، برای هر کدام از چهارده ضریب به دست آمده از WPD، ویژگی‌های آماری حوزه زمان ارائه شده در جدول ۲ استخراج شده‌اند (ویژگی‌های F₁₄₅-F₄₂₄).

جدول ۲) ویژگی‌های آماری در حوزه زمان و فرکانس

ویژگی‌های آماری		
حوزه زمان		
میانگین:	میانگین ریشه مربعات:	میانگین:
$F_1 = \frac{1}{N} \sum_{i=1}^N x(i)$	$F_8 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	$F_{15} = \frac{x_{RMS}}{(\frac{1}{N} \sum_{i=1}^N x_i)}$
ماکزیمم:	مقدار پیک:	ضریب ایمپالس:
$F_2 = \max(x(i))$	$F_9 = \max(x_i)$	$F_{16} = \frac{Peak}{(\frac{1}{N} \sum_{i=1}^N x_i)}$
مینیمم:	میانگین پیک‌ها:	ضریب کلیرینس:
$F_3 = \min(x(i))$	$F_{10} = \text{mean}(total\ peak)$	$F_{17} = \frac{Peak}{((\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i })^2)}$
میان:	انحراف معیار:	ویژگی ترکیبی ۱:
$F_4 = x(\frac{N+1}{2})$	$F_{11} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$	$F_{18} = \log(F_{13} + \frac{RMS}{0.078})$
انرژی:	چولگی:	ویژگی ترکیبی ۲:
$F_5 = \int x(t) ^2 dt$	$F_{12} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2)^{\frac{3}{2}}}$	$F_{19} = \log(F_{13}^{F_{14}} + \frac{RMS}{0.078})^{F_7}$
آنتروپی:	کشیدگی:	انرژی تیگر-کایزر:
$F_6 = -\sum_{i=1}^N x_i^2 \log(x_i^2)$	$F_{13} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2)^2}$	$F_{20} = \sum_{i=1}^N \Psi[x(i)]$
دامنه:	ضریب اوج:	$\Psi[x(i)] = [x(i)]^2 - x(i) - 1$
$F_7 = \max(x_i) - \min(x_i)$	$F_{14} = \frac{\max(abs(x))}{RMS}$	
حوزه فرکانس		
میانگین فرکانسی:	انحراف معیار فرکانسی:	مرکز فرکانسی:
$F_{21} = \frac{1}{K} \sum_{k=1}^K s(k)$	$F_{23} = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$	$F_{22} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$
ریشه میانگین مربعات فرکانسی:		
$F_{24} = \sqrt{\frac{\sum_{k=1}^K (f_k - F_{21})^2 s(k)}{\sum_{k=1}^K s(k)}}$		

یکی از چالش‌های مهم روش CDET، انتخاب پارامتر مناسب ξ است. البته در یک پژوهش [10]، مقدار $\xi = 0.5$ برای این پارامتر در نظر گرفته شده است. اما انتخاب هر مقدار دلخواه برای پارامتر ξ ممکن است منجر به حذف ویژگی‌هایی شود که حاوی اطلاعات مفیدی از سیگنال اصلی هستند یا ویژگی‌هایی انتخاب شوند که زاید و غیرحساس به حضور عیب هستند. از این رو، همان طور که در بخش ۴ خواهید دید، روشی به منظور تعیین مقدار بهینه برای پارامتر ξ به کمک الگوریتم بهینه‌سازی PSO ارائه خواهد شد. سپس، با محاسبه مقدار بهینه ξ ، مناسب‌ترین زیرمجموعه از فضای ویژگی انتخاب می‌شود. این روش در این مقاله، تکنیک ارزیابی جبران فاصله بهینه‌شده (OCDET) نامیده می‌شود.

۳-۴- ماشین بردار پشتیبان

این الگوریتم از مجموعه‌ای به نام مجموعه داده‌های آموزش یاد می‌گیرد و سعی می‌کند تا آن را جامع کند و پیش‌بینی‌های صحیحی را با توجه به داده‌های جدید به دست آورد. در ادامه، مفاهیم پایه‌ای روش ماشین بردار پشتیبان تشریح داده 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. ابرصفحه جداکننده بهینه $f(x) = w \cdot x + b$ را می‌توان با حل مساله بهینه‌سازی زیر به دست آورد [19]:

$$\min \left(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \right) \quad (12)$$

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

که ξ_i فاصله بین ابرصفحه و نمونه‌های قرارگرفته در طرف اشتباه ابرصفحه را اندازه می‌گیرد و C پارامتر جریمه است. با معرفی ضرایب لاگرانژ α_i و β_i برای قیود مساله ۱۲ 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، آن گاه می‌توان پارامترهای بهینه ابرصفحه را محاسبه نمود. در نهایت، تابع طبقه‌بندی را می‌توان به صورت زیر نوشت:

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i (x_i \cdot x_j) + b \right) \quad (13)$$

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 $\phi(x) = (\phi_1(x), \dots, \phi_l(x))$ برای نگاشت بردار ورودی n بعدی x به فضای ویژگی ابعادی استفاده نمود، به طوری که تابع تصمیم به شکل زیر تغییر می‌یابد:

$$f(x) = \text{sign} \left(\sum_{i,j=1}^N \alpha_i y_i K(x_i, x_j) + b \right) \quad (14)$$

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

$$K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j)) \quad (15)$$

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

مناسب‌ترین ویژگی‌ها استفاده می‌شود. مراحل فرآیند انتخاب ویژگی با روش CDET به شرح زیر است [10]:

۱- پارامتر میانگین فاصله متناظر با ویژگی λ_m برای سیگنال‌هایی که دارای اطلاعاتی از کلاس c هستند، به صورت زیر محاسبه می‌شود:

$$d_{c,j} = \frac{1}{M_C(M_C - 1)} \sum_{l,m=1}^{M_C} |f_{m,c,j} - f_{l,c,j}| \quad (3)$$

$$l, m = 1, 2, \dots, M_C \quad l \neq m$$

سیس، میانگین فاصله برای تمامی کلاس‌ها از رابطه زیر محاسبه می‌شود:

$$d_j^{(w)} = \frac{1}{C} \sum_{c=1}^C d_{c,j} \quad (4)$$

۲- فاکتور واریانس متناظر با ویژگی λ_j برای $d_j^{(w)}$ به صورت زیر تعریف و محاسبه می‌شود:

$$v_j^{(w)} = \frac{\max(d_{c,j})}{\min(d_{c,j})} \quad (5)$$

۳- میانگین ویژگی λ_m مربوط به تمامی سیگنال‌ها برای کلاس c از رابطه زیر محاسبه می‌شود:

$$u_{c,j} = \frac{1}{M_C} \sum_{m=1}^{M_C} f_{m,c,j} \quad (6)$$

سیس، میانگین فاصله بین سیگنال‌هایی که متعلق به کلاس‌های مختلف هستند، به صورت زیر محاسبه می‌شود:

$$d_j^{(b)} = \frac{1}{C(C - 1)} \sum_{c,e=1}^C |u_{e,j} - u_{c,j}| \quad (7)$$

$$c, e = 1, 2, \dots, C \quad c \neq e$$

فاکتور واریانس متناظر با ویژگی λ_j برای $d_j^{(b)}$ از رابطه زیر محاسبه می‌شود:

$$v_j^{(b)} = \frac{\max(|u_{e,j} - u_{c,j}|)}{\min(|u_{e,j} - u_{c,j}|)} \quad (8)$$

$$c, e = 1, 2, \dots, C \quad c \neq e$$

۴- فاکتور تصحیح برای ویژگی λ_m طبق رابطه زیر تعریف می‌شود:

$$\lambda_j = \frac{1}{\frac{v_j^{(w)}}{\max(v_j^{(w)})} + \frac{v_j^{(b)}}{\max(v_j^{(b)})}} \quad (9)$$

۵- ضریب $\bar{\alpha}_j$ که شاخصی برای ارزیابی ویژگی λ_m است، به صورت زیر تعریف می‌شود:

$$\bar{\alpha}_j = \frac{\alpha_j}{\max(\alpha_j)} \quad (10)$$

که در آن

$$\alpha_j = \lambda_j \frac{d_j^{(b)}}{d_j^{(w)}} \quad (11)$$

۶- شاخص $\bar{\alpha}_j$ برای تمامی ویژگی‌ها محاسبه شده و سپس با مقدار آستانه $\xi \in [0, 1]$ که از پیش تعیین شده است، مقایسه می‌شود. اگر $\bar{\alpha}_j > \xi$ باشد، ویژگی λ_m به عنوان ویژگی موثر و مناسب برای فرآیند عیب‌یابی انتخاب و در غیر این صورت از

۴- روش هوشمند پیشنهادی

در این مقاله، یک روش ترکیبی جدید هوشمند برای عیب‌یابی چندکلاسه برای یاتاقان‌ها ارائه شده است. این روش ترکیبی از روش تجزیه مود تجربی، روش‌های استخراج ویژگی و تبدیل بسته‌ای موجک و الگوریتم‌های بهبودیافته SVM-OAO و CDET است. در الگوریتم ترکیبی پیشنهادی، گستره وسیعی از ویژگی‌های مختلف نظیر حوزه زمان، حوزه فرکانس و زمان-فرکانس مربوط به سیگنال‌های خام، مولفه‌های حاصل از تجزیه EMD و سطوح مختلف تبدیل بسته‌ای موجک استخراج می‌شوند. سپس، به کمک الگوریتم پیشنهادی OCDET به منظور انتخاب مناسب‌ترین زیرمجموعه از این ویژگی‌ها استفاده خواهد شد. در نهایت، از این ویژگی‌های بهینه به عنوان ورودی ماشین بردار پشتیبان بهبودیافته با PSO استفاده خواهد شد. فلوچارت روش ارائه شده در این مقاله در شکل ۳ آمده است.

مراحل روش پیشنهادی به صورت زیر هستند:

۱- ۶۰٪ سیگنال‌ها به "داده‌های آموزش برای تخمین پارامتر اختصاص یافته است و مابقی برای "داده‌های تست نهایی" استفاده می‌شود.

۲- هر سیگنال از مجموعه "داده‌های آموزش برای تخمین پارامتر" توسط روش EMD به مولفه‌های ساده‌تری تجزیه می‌شود.

۳- از هر نمونه سیگنال مطابق با بخش ۳-۲، ویژگی‌های حوزه زمان، فرکانس و همچنین ویژگی‌های مربوط به ضرایب حاصل از تبدیل بسته‌ای موجک استخراج می‌شود. در این مرحله برای هر سیگنال ۴۲۴ ویژگی به دست می‌آید.

۴- ماتریس ویژگی به گونه‌ای تشکیل می‌شود که سطرها آن متناظر با سیگنال‌ها و ستون‌های آن متناظر با ویژگی‌ها هستند. سپس، داده‌های مربوط به هر ستون به گونه‌ای نرمالیزه می‌شوند که مقادیر آنها در بازه [۰,۱] قرار گیرند.

۵- داده‌های آموزش نرمالیزه شده حاصل از مرحله قبل به دو مجموعه داده "داده‌های آموزش" و "داده‌های اعتبارسنجی" تفکیک می‌شود. از مجموعه داده آموزش و اعتبارسنجی به ترتیب برای ساخت و آموزش طبقه‌بندی‌کننده SVM استفاده می‌شود.

۶- از الگوریتم بهینه‌سازی PSO برای یافتن مقادیر بهینه پارامترهای C و σ در الگوریتم SVM و پارامتر آستانه ξ در الگوریتم انتخاب ویژگی CDET استفاده می‌شود. برای این منظور، تابع هدف به صورت زیر تعریف می‌شود:

$$Objective = \left((\alpha - 1) \frac{Incorrectly\ Classified}{Classified\ Samples} + \alpha \frac{R}{N} \right) \times 100 \quad (19)$$

که R تعداد ویژگی‌های انتخاب شده در هر مرحله بهینه‌سازی و N تعداد کل ویژگی‌ها هستند. پارامتر α مطابق با یک پژوهش [16] برابر با ۰/۱ در نظر گرفته شده است. کران‌های بالا و پایین متغیرهای تصمیم در جدول ۴ آمده‌اند.

۷- برای ارزیابی روش پیشنهادی، از داده‌های تست نهایی استفاده شده است. برای این منظور، به کمک طبقه‌بندی‌کننده بهینه به دست آمده در مرحله ۶، کلاس داده‌ها و در نتیجه، شرایط حاکم بر یاتاقان تشخیص داده می‌شود.

جدول (۴) دامنه تغییرات متغیرهای طراحی

پارامتر	کران پایین	کران بالا
C	e^{-5}	e^5
σ	e^{-5}	e^5
ξ	۰	۱

$$K(x, x_j) = \exp\left(-\frac{\|x - x_j\|^2}{\sigma^2}\right) \quad (16)$$

انتخاب پارامترهای جریمه C و σ ، به شدت کارایی SVM را تحت تاثیر قرار می‌دهد. همان طور که خواهید دید در این مطالعه، از الگوریتم بهینه‌سازی PSO برای یافتن مقادیر بهینه 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 دَواری اشاره نمود که دارای چندین منبع عیب هستند. در چنین شرایطی معمولاً از دو نوع استراتژی برای ساخت SVM چندکلاسه "یک در برابر همه (OAA)" و "یک در برابر یک (OAO)" استفاده می‌شود. در این مقاله تنها از نوع "یک در برابر یک" استفاده شده است.

۳-۵- الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی تجمعی ذرات، یک تکنیک بهینه‌سازی بر پایه جمعیت بوده که از رفتار اجتماعی گروه‌های ماهی‌ها و پرندگان الهام گرفته شده است [21]. در این الگوریتم از افرادی که ذره نامیده می‌شوند، برای یافتن بهترین پاسخ در فضای جست‌وجو 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 به صورت زیر است:

$$Position: \vec{X}_i = \{X_{i1}, X_{i2}, \dots, X_{id}\}$$

$$Velocity: \vec{V}_i = \{V_{i1}, V_{i2}, \dots, V_{id}\}$$

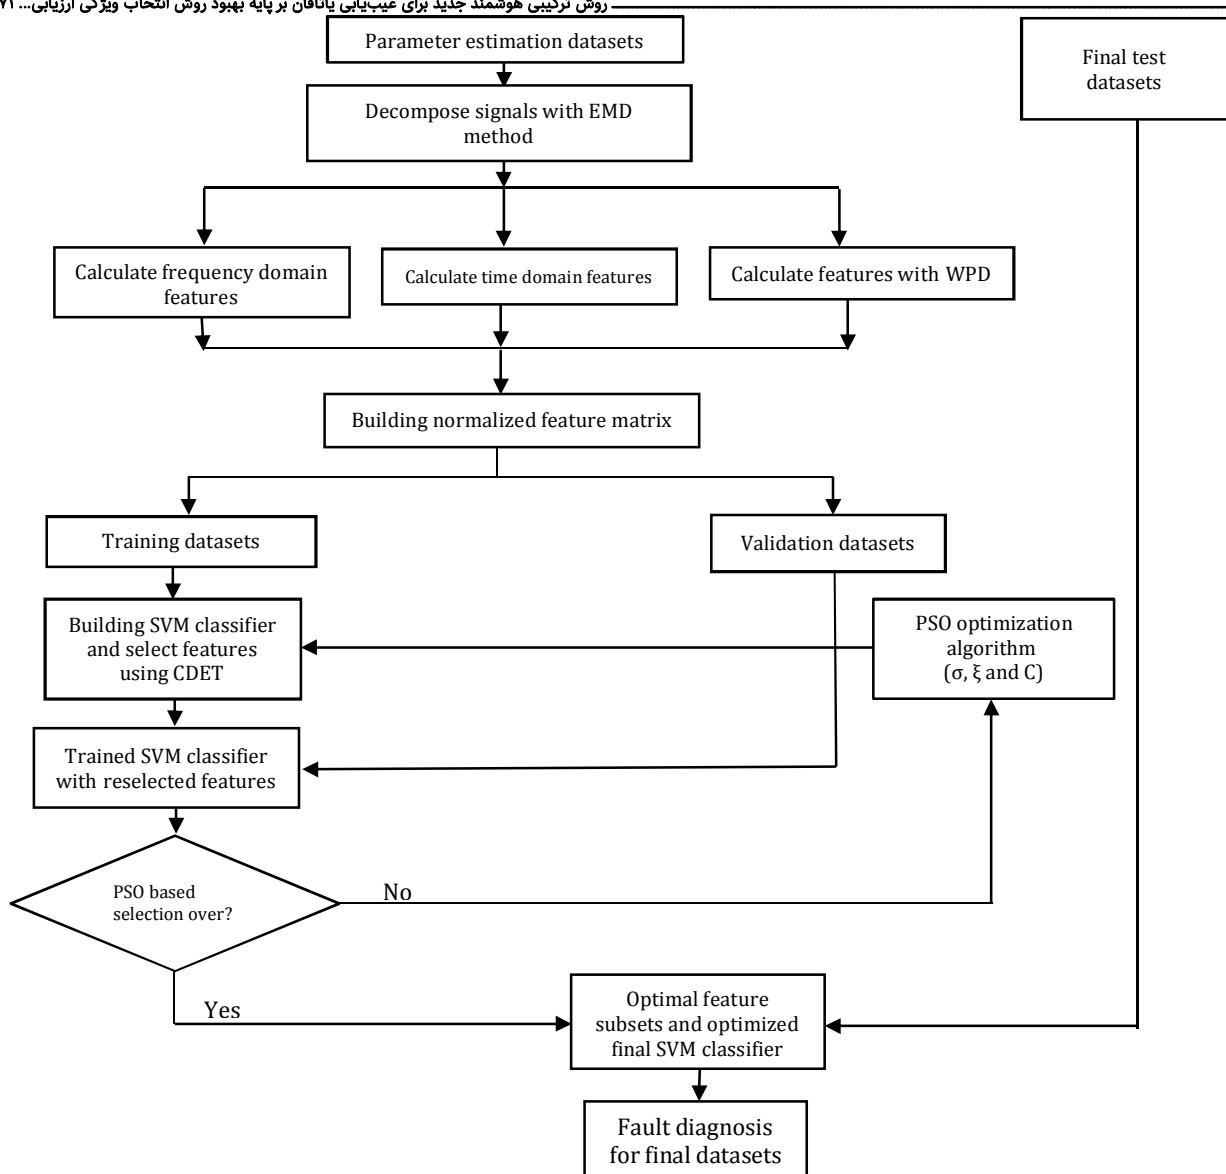
الگوریتم PSO شامل دو مرحله مقداردهی اولیه و محاسبات است. در فاز مقداردهی اولیه، به هر ذره، یک موقعیت اولیه و یک سرعت اولیه به صورت تصادفی اختصاص داده می‌شود. در فاز محاسبات، هر ذره برای یافتن موقعیت بعدی خود و حرکت در فضای جست‌وجو، از بهترین تجربه شخصی خود (\vec{X}_{pBest}) و بهترین تجربه کل ذرات (\vec{X}_{gBest}) به صورت زیر استفاده می‌کند [21]:

$$\vec{V}_i(t+1) = w\vec{V}_i(t) + c_1r_1(\vec{X}_{pBest_i} - \vec{X}_i(t)) + c_2r_2(\vec{X}_{gBest} - \vec{X}_i(t)) \quad (17)$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (18)$$

که $\vec{V}_i(t+1)$ بردار سرعت ذره در تکرار t+1 و $\vec{X}_i(t+1)$ بردار موقعیت ذره نام است. c_1 ضریب یادگیری شخصی و c_2 ضریب یادگیری اجتماعی هستند. r_1 و r_2 دارای مقادیر تصادفی در بازه [۰,۱] هستند. در این مقاله، مقادیر c_1 ، c_2 و w مطابق با یک مرجع [21] در نظر گرفته شده‌اند.

در الگوریتم PSO، ابتدا موقعیت و سرعت ذرات به صورت تصادفی تولید می‌شوند. سپس، با محاسبه مقدار تابع هدف، \vec{X}_{pBest} برای هر ذره و \vec{X}_{gBest} برای کل جمعیت تعیین می‌شوند. در هر تکرار، مقدار پارامترهای c_1 ، c_2 و w محاسبه می‌شوند. سرعت و موقعیت هر ذره توسط روابط ۱۷ و ۱۸ بروز می‌شوند. پس از تعیین موقعیت جدید ذرات، مقدار تابع هدف برای هر ذره جدید محاسبه می‌شود. اگر مقدار تابع هدف در ذره جدید، کمتر از مقدار تابع هزینه در \vec{X}_{pBest} آن ذره باشد، در این صورت \vec{X}_{pBest} بروز می‌شود. در نهایت، مقادیر تابع هزینه در \vec{X}_{pBest} و \vec{X}_{gBest} با هم، مقایسه و کمترین آنها به عنوان بهینه کلی در تکرار فعلی انتخاب می‌شود. این فرآیند تا برآورده شدن شرط خاتمه ادامه می‌یابد.



شکل ۳) فلوچارت روش عیب‌یابی پیشنهادی

۵- نتایج و بحث

۵-۱- داده‌های ارتعاشی

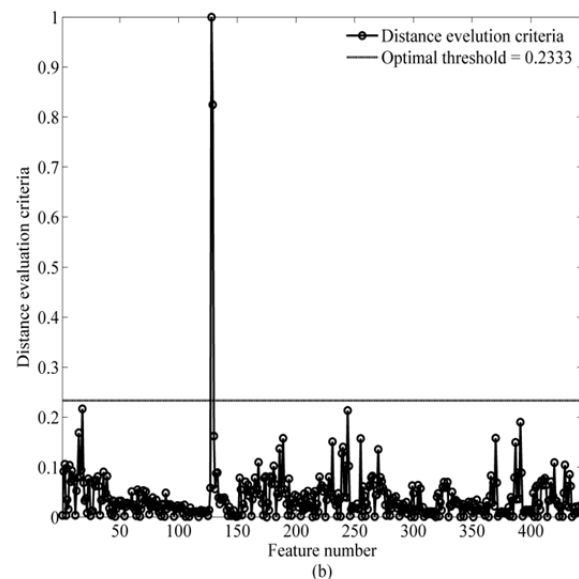
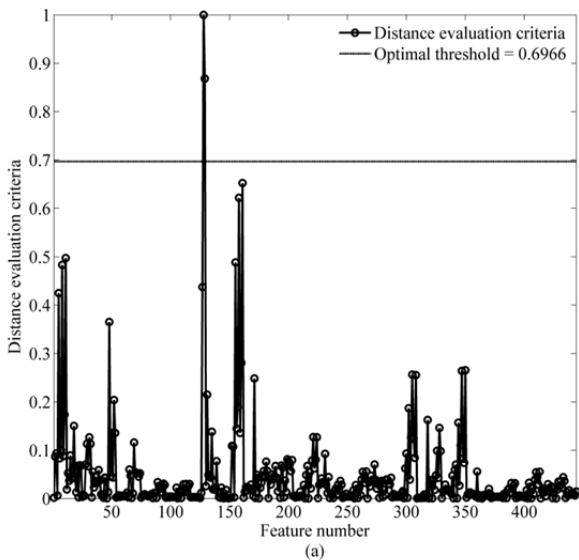
بنابراین، استخراج ویژگی از این سیگنال‌ها و معرفی یک روش شناسایی هوشمند عیب که قادر به تشخیص عیب به‌طور خودکار باشد، ضروری به نظر می‌رسد.

جدول ۵) توضیح داده‌های در نظر گرفته شده در فرآیند عیب‌یابی


اندازه عیب (mm)	شرایط کاری	تعداد نمونه‌های تست	تعداد نمونه‌های آموزش	تعداد کلاس	موارد مطالعاتی
---	سالم	۳۲	۴۸	۴	مورد ۱: تشخیص نوع عیب
۰/۱۷۷۸	عیب در هر سه المان				
---	سالم	۴۰	۶۰	۵	مورد ۲: تشخیص اندازه‌های مختلف عیب رینگ داخلی
۰/۱۷۷۸~۰/۷۱۱۲	رینگ داخلی				
---	سالم	۳۲	۴۸	۴	مورد ۳: تشخیص اندازه‌های عیب رینگ خارجی
۰/۱۷۷۸~۰/۵۳۳۴	رینگ خارجی				
---	سالم	۴۰	۶۰	۵	مورد ۴: تشخیص اندازه‌های مختلف عیب المان غلتشی
۰/۱۷۷۸~۰/۷۱۱۲	المان غلتشی				

برای ارزیابی عملکرد روش پیشنهادی، از داده‌های ارتعاشی اکتساب شده از مجموعه آزمایشگاهی شکل ۱ استفاده شده است. توضیحات مربوط به موارد مطالعاتی به‌کارگرفته شده در این مقاله در جدول ۵ ارائه شده است. از مورد ۱ برای سنجش توانمندی روش پیشنهادی در تشخیص نوع عیب با قطر ۰/۱۷۷۸mm در سرعت‌های مختلف استفاده شده است. هدف از به‌کارگیری موارد دوم تا چهارم، شناسایی اندازه‌های مختلف عیب در سرعت دورانی‌های متفاوت است. در هر کدام از موارد ۲ تا ۴، داده‌های ارتعاشی متناظر با عمق‌های مختلف عیب ۰/۱۷۷۸، ۰/۳۵۵۶، ۰/۵۳۳۴ و ۰/۷۱۱۲mm هستند. برای نمونه، سیگنال‌های ارتعاشی متناظر با شرایط مختلف در دو اندازه عیب ۰/۱۷۷۸ و ۰/۵۳۳۴mm در سرعت دورانی ۱۷۵۰rpm در نمودار ۱ نشان داده شده است. همان‌طور که در این نمودار دیده می‌شود، مشخصات شوک‌ها و دامنه سیگنال‌های ارتعاشی در شرایط مختلف و اندازه‌های مختلف عیب، با یکدیگر متفاوت هستند. اما تنها با بررسی این مشخصه‌ها، تشخیص دقیق نوع عیب و شدت آن یک مساله بسیار دشوار است.

فاصله $\bar{\alpha}$ ، برای تمامی ویژگی‌ها برای دو مورد مطالعاتی عیب رینگ داخلی و عیب رینگ خارجی ارایه شده است. ویژگی متناظر با مقدار $\bar{\alpha} = 1$ ، به‌عنوان حساس‌ترین پارامتر برای طبقه‌بندی عیوب در نظر گرفته می‌شود. مقدار آستانه بهینه به‌دست‌آمده توسط الگوریتم PSO برای عیب رینگ داخلی و خارجی به‌ترتیب برابر با ۰/۶۹۶۶ و ۰/۲۳۳۳ هستند. مطابق با نمودار ۳، ویژگی‌های F_{128} (ریشه میانگین مربعات فرکانسی IMF اول) و F_{129} (میانگین فرکانسی IMF دوم) حساس‌ترین بردار ویژگی برای دو مورد مطالعاتی ۲ و ۳ هستند. توزیع دو ویژگی برای اندازه‌های مختلف عیب رینگ داخلی و خارجی به‌ترتیب در نمودارهای ۴- a و b ارایه شده است. مشاهده می‌شود که با انتخاب بردار ویژگی به‌کمک روش پیشنهادی، شرایط مختلف حاکم بر یاتاقان به‌خوبی از یکدیگر قابل تفکیک هستند. همچنین، در نمودار ۴ مشاهده می‌شود که فاصله بین حالت سالم و دیگر اندازه‌های مختلف عیب در رینگ‌های داخلی و خارجی زیاد است. چنین وضعیتی به ما کمک می‌کند تا با آسودگی خاطر، کلاس‌های سالم و معیوب را تشخیص دهیم.



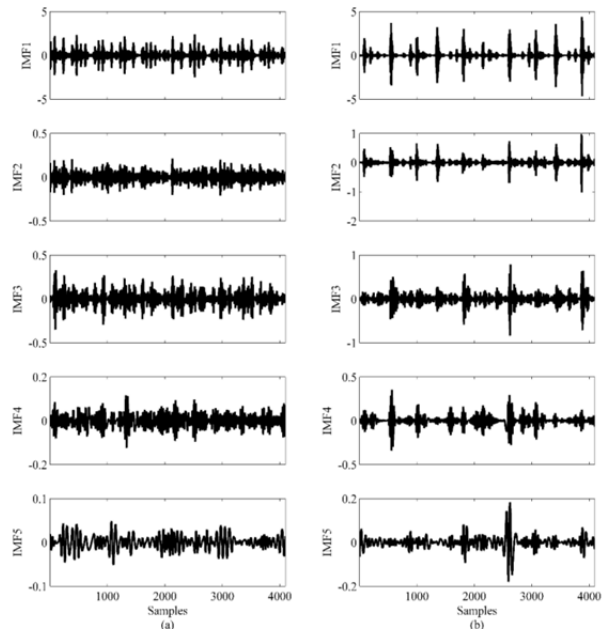
نمودار ۳) معیار ارزیابی فاصله برای همه ویژگی‌ها و مقدار آستانه بهینه: (a) عیب رینگ داخلی، (b) عیب رینگ خارجی



نمودار ۴) سیگنال‌های ارتعاشی برای چهار حالت مختلف: (a) سالم، (b) و (c) رینگ داخلی با عمق‌های ۰/۱۷۷۸ و ۰/۵۳۳۴mm، (d) و (e) رینگ خارجی با عمق‌های ۰/۱۷۷۸ و ۰/۵۳۳۴mm، (f) و (g) المان ساچمه با عمق‌های ۰/۱۷۷۸ و ۰/۵۳۳۴mm

۵-۲- انتخاب مناسب‌ترین ویژگی به‌کمک روش پیشنهادی

مطابق با فلوجارت شکل ۳، با به‌کارگیری روش EMD، داده‌های ارتعاشی مورد استفاده برای آموزش شبکه SVM و انتخاب مناسب‌ترین ویژگی، تجزیه می‌شوند. برای نمونه، پنج مولفه اول حاصل از تجزیه سیگنال ارتعاشی نمودارهای ۱- c و e که متناظر با عیوب رینگ داخلی و رینگ خارجی با اندازه ۰/۵۳۳۴mm هستند، در نمودار ۲ نشان داده شده است.



نمودار ۲) مولفه‌های حاصل از تجزیه سیگنال ارتعاشی با روش EMD: (a) عیب رینگ داخلی با عمق ۰/۵۳۳۴mm، (b) عیب رینگ خارجی با عمق ۰/۵۳۳۴mm

پس از تجزیه سیگنال‌ها، ماتریس ویژگی تشکیل می‌شود و به‌کمک الگوریتم بهینه‌سازی PSO مناسب‌ترین ویژگی و پارامترهای بهینه SVM به‌طور هم‌زمان به‌منظور کمیته‌سازی رابطه تعیین می‌شوند. برای مثال، در نمودار ۳ شاخص ارزیابی جبران


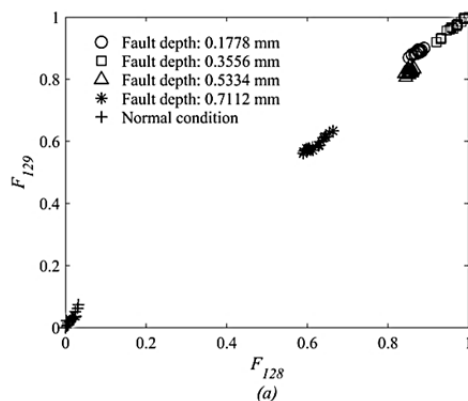
جدول ۶) توضیح روش‌های مختلف به‌منظور مقایسه

روش‌ها	توضیح روش
روش ۱ [8]	از ویژگی‌های کشیدگی، چولگی و انحراف‌معیار برای استخراج ویژگی استفاده شده است. سپس، به‌کمک الگوریتم ماشین بردار پشتیبان وضعیت سیستم کلاسه‌بندی شده است. برای تعیین پارامترهای طبقه‌بندی‌کننده از الگوریتم ژنتیک استفاده شده است.
روش ۲ [9]	سیگنال‌ها به‌کمک تبدیل بسته‌ای موجک بی‌نویز و به‌کمک الگوریتم تجزیه‌مُد تجربی کلی به مولفه‌های مختلف تجزیه می‌شوند. هر بردار ویژگی شامل انرژی انرژری مربوط به سه مود ذاتی اول هر سیگنال بوده که نرمالیزه شده است. سپس از الگوریتم ماشین بردار پشتیبان برای تشخیص حالت سیستم استفاده شده است. پارامترهای ماشین بردار پشتیبان به‌کمک الگوریتم اعتبارسنجی متقابل تعیین شده‌اند.
روش ۳ [17]	مجموعه ویژگی‌های بهینه به‌طور مستقیم از مجموعه ویژگی‌های اصلی به‌کمک بهینه‌سازی ازدحام ذرات باینری، تعیین و به‌طور هم‌زمان پارامترهای ماشین بردار پشتیبان برای تشخیص عیب بهینه شده‌اند.

جدول ۷) مقایسه کارایی روش پیشنهادی با دیگر روش‌های عیب‌یابی

مورد مطالعاتی	روش	پارامترهای بهینه	ویژگی‌های بهینه یا تعداد آنها	میانگین دقت در آموزش	میانگین دقت در تست نهایی
مورد ۱	روش ۱	$C=0/2133$ $\sigma=0/9619$	--	$100 \pm 0/0$	$95 \pm 0/0$
	روش ۲	$C=0/7787$ $\sigma=1/2809$	--	$84/86 \pm 4/12$	$81/04 \pm 4/25$
	روش ۳	$C=92/1569$ $\sigma=8/90025$	۱۷۱ ویژگی	$99/72 \pm 1/05$	$94/47 \pm 1/57$
مورد ۲	روش پیشنهادی	$C=3/2761C$ $\sigma=4/97705$ $\xi=0/6147$	F_{129} و F_{128}	$100 \pm 0/0$	$97/70 \pm 1/40$
	روش ۱	$C=1/7195$ $\sigma=0/9052$	--	100 ± 0	$99/6 \pm 1/22$
	روش ۲	$C=15/4501$ $\sigma=1/8789$	--	$70/33 \pm 2/71$	$73/41 \pm 7/41$
مورد ۳	روش ۳	$C=48/62$ $\sigma=9/28$	۱۷۳ ویژگی	$96/77 \pm 1/06$	$91/58 \pm 4/52$
	روش پیشنهادی	$C=9/87$ $\sigma=2/54$ $\xi=0/6966$	F_{129} و F_{128}	100 ± 0	$99/5 \pm 1/07$
	روش ۱	$C=0/9003$ $\sigma=0/7078$	--	$97 \pm 2/4914$	$93/58 \pm 1/26$
مورد ۴	روش ۲	$C=3/8253$ $\sigma=0/6348$	--	$87/5 \pm 3/212$	$81/45 \pm 4/09$
	روش ۳	$C=49/0201$ $\sigma=8/4904$	۱۶۸ ویژگی	$99/86 \pm 0/76$	$98/02 \pm 1/53$
	روش پیشنهادی	$C=33/0148$ $\sigma=45/5719$ $\xi=0/2333$	F_{129} و F_{128}	100 ± 0	$99/06 \pm 1/45$
مورد ۴	روش ۱	$C=1/4294$ $\sigma=0/9358$	--	$100 \pm 0/0$	$99/6 \pm 1/2205$
	روش ۲	$C=0/8965$ $\sigma=0/892$	--	$76/91 \pm 4/28$	$78/38 \pm 4/14$
	روش ۳	$C=91/7648$ $\sigma=9/0928$	۱۷۵ ویژگی	$98/88 \pm 1/82$	$95/66 \pm 3/27$
	روش پیشنهادی	$C=116/2570$ $\sigma=3/8239$ $\xi=0/8887$	F_{127} , F_{31} و F_{131}	$99/77 \pm 0/57$	$99/91 \pm 0/45$

همان‌طور که در جدول ۷ دیده می‌شود، بیشترین خطا در شناسایی عیب در تمامی موارد ۱ تا ۴، چه در مرحله آموزش و چه تست



نمودار ۴) توزیع ویژگی‌های بهینه به‌دست‌آمده توسط روش پیشنهادی: (a) عیب رینگ داخلی، (b) عیب رینگ خارجی

۵-۳- مقایسه با دیگر روش‌های عیب‌یابی

برای مقایسه توانمندی روش انتخاب ویژگی و تشخیص عیب پیشنهاد شده در این مقاله با دیگر روش‌ها، از سه روش استفاده شده است که در جدول ۶ تشریح شده‌اند.

در روش اول [8]، سه ویژگی آماری کشیدگی، چولگی و انحراف‌معیار از سیگنال‌های ارتعاشی خام استخراج شده است و به‌کمک الگوریتم GA، روش کلاسه‌بندی SVM بهبود یافته‌اند. در این مقاله، در فرآیند بهینه‌سازی با GA، تعداد جمعیت و ماکزیمم تکرار هر دو برابر با ۵۰ هستند. در روش دوم [9]، سیگنال‌ها به‌کمک روش WPD بی‌نویز شده و سپس انرژی نرمالیزه شده از سه IMF اول حاصل از روش EEMD به‌عنوان بردار ویژگی ورودی SVM استفاده شده است. در روش سوم [17]، انتخاب ویژگی‌های بهینه از ماتریس ویژگی‌های سیگنال اصلی با ابعاد بالا و پارامترهای بهینه SVM به‌کمک الگوریتم BPSO به دست آمده‌اند. در این روش، تعداد دفعات تکرار الگوریتم BPSO برابر با ۵۰ و تعداد ذرات در هر تکرار برابر با ۲۰ تنظیم شده است. از آنجایی که الگوریتم‌های بهینه‌سازی دارای طبیعتی تصادفی هستند و در هر بار اجرای آنها ممکن است پاسخ‌های به‌دست‌آمده متفاوت باشند، از این رو هر کدام از روش‌های یک تا سه و روش پیشنهادی در این مطالعه برای عیب‌یابی موارد مطالعاتی تشریح شده در جدول ۵، ۳۰ بار به اجرا در آمده‌اند. در نهایت، نتایج مربوط به دقت تشخیص عیب در دو مرحله آموزش و تست نهایی در ترم‌های آماری "میانگین دقت پیش‌بینی عیب (mean)" و "انحراف‌معیار نتایج پیش‌بینی عیب (std)" به‌صورت عبارت $mean \pm std$ در جدول ۷ گزارش شده‌اند. همچنین، پارامترهای بهینه مربوط به الگوریتم SVM و پارامتر آستانه تشریح شده در این مقاله یعنی ξ و ویژگی‌های بهینه در جدول ۷ ارائه شده‌اند.

برای عیب‌یابی در چهار مورد تشخیص نوع عیب، عیب رینگ داخلی، عیب رینگ خارجی و عیب المان غلتشی با اندازه‌های مختلف استفاده شده است. نتایج نشان می‌دهد که با ارایه روش بهبودیافته OCDET می‌توان مناسب‌ترین مجموعه ویژگی‌ها را برای تفکیک بهتر شرایط مختلف یک یاتاقان انتخاب نمود. به طوری که با به‌کارگیری مجموعه ویژگی جدید، ماشین بردار پشتیبان قادر است تا شرایط یک یاتاقان در سرعت‌های مختلف را با دقت بسیار خوبی پیش‌بینی نماید. همچنین، مقایسه نتایج این مقاله با تحقیقات پیشین، توانمندی روش پیشنهادی را اثبات می‌کند.

تشکر و قدردانی: از کارکنان دانشکده مهندسی مکانیک که امکانات را برای انجام این پژوهش فراهم نمودند، تشکر می‌شود.

تأییدیه اخلاقی: محتویات علمی مقاله حاصل فعالیت نویسندگان بوده و صحت و اعتبار نتایج بر عهده نویسندگان است.
تعارض منافع: مقاله حاضر هیچ گونه منافی با سازمان و اشخاص دیگر ندارد.

سهم نویسندگان: سعید نظامیوندچگینی (نویسنده اول)، نگارنده مقدمه/پژوهشگر اصلی/نگارنده بحث (۳۴٪)؛ احمد باقری (نویسنده دوم)، روش‌شناس/پژوهشگر کمکی/نگارنده بحث (۳۳٪)؛ فرید نجفی (نویسنده سوم)، روش‌شناس/پژوهشگر کمکی (۳۳٪)

منابع مالی: منابع مالی خاصی برای انجام این تحقیق استفاده نشده است.

منابع

- 1- Lei Y, Zuo MJ. Fault diagnosis of rotating machinery using an improved HHT based on EEMD and sensitive IMFs. *Measurement Science and Technology*. 2009;20(12):125701.
- 2- Jin Sh, Kim JS, Lee SK. Sensitive method for detecting tooth faults in gearboxes based on wavelet denoising and empirical mode decomposition. *Journal of Mechanical Science and Technology*. 2015;29(8):3165-3173.
- 3- Li Y, Xu M, Wei Y, Huang W. An improvement EMD method based on the optimized rational Hermite interpolation approach and its application to gear fault diagnosis. *Measurement*. 2015;63:330-345.
- 4- Guo T, Deng Z. An improved EMD method based on the multi-objective optimization and its application to fault feature extraction of rolling bearing. *Applied Acoustics*. 2017;127:46-62.
- 5- Nguyen P, Kang M, Kim JM, Ahn BH, Ha JM, Choi BK. Robust condition monitoring of rolling element bearings using de-noising and envelope analysis with signal decomposition techniques. *Expert Systems with Applications*. 2015;42(22):9024-9032.
- 6- Bordoloi DJ, Tiwari R. Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time-frequency vibration data. *Measurement*. 2014;55:1-14.
- 7- Bordoloi DJ, Tiwari R. Optimum multi-fault classification of gears with integration of evolutionary and SVM algorithms. *Mechanism and Machine Theory*. 2014;73:49-60.
- 8- Bordoloi DJ, Tiwari R. Optimisation of SVM methodology for multiple fault taxonomy of rolling bearings from acceleration records. In: Pennacchi P, editor. *Proceedings of the 9th IFToMM international*

نهایی، مربوط به روش دو است. علاوه بر این، پاسخ‌های حاصل از روش دوم دارای بیشترین انحراف معیار هستند. به عبارت دیگر، پراکندگی پاسخ‌های به‌دست‌آمده توسط این روش نسبت به سایر روش‌ها بیشتر است. در این روش از بردار ویژگی انرژی مربوط به مولفه‌های حاصل از روش EEMD برای تشکیل ماتریس ویژگی استفاده شده است. نتایج نشان می‌دهند که استفاده از این ترکیب ویژگی باعث ایجاد خطای قابل ملاحظه‌ای می‌شود. اما در روش اول، به علت بهره‌گیری از ویژگی کشیدگی، چولگی و انحراف معیار، خطای شناسایی عیب به‌طور قابل ملاحظه‌ای کاهش یافته است. علت این حقیقت را می‌توان به حساس بودن این ویژگی‌ها به وجود عیب در اجزای مختلف یاتاقان نسبت داد. همان طور که مشاهده می‌شود، خطای آموزش در روش اول، در همه موارد به غیر از عیب‌یابی مورد سوم، صفر است. همچنین، در مورد مطالعاتی دوم، دقت این روش در پیش‌بینی داده‌های تست نهایی از همه روش‌ها بیشتر بوده و البته بسیار نزدیک به روش پیشنهادی در این مقاله است. مطابق با جدول ۷، روش پیشنهادی در پیش‌بینی داده‌های موارد مطالعاتی اول، دوم و سوم در مرحله اعتبارسنجی و آموزش در هر ۳۰ بار اجرای خود به‌طور دقیق عمل کرده است. نتایج ارایه‌شده در این جدول به‌طور آشکار حاکی از برتری روش پیشنهادی در پیش‌بینی داده‌های تست نهایی مربوط به موارد مطالعاتی اول، سوم و چهارم است. همچنین، پیش‌بینی داده‌ها توسط این روش، دارای کمترین انحراف معیار نسبت به سایر روش‌هاست. این نتیجه نشان می‌دهد که روش ارایه‌شده در این مقاله، در اجراهای مختلف دارای پایداری بسیار خوبی در پیش‌بینی وضعیت یک نمونه داده است. نکته قابل توجه دیگری که در جدول ۷ دیده می‌شود، بردارهای ویژگی به‌دست‌آمده توسط روش سه و تکنیک ارایه‌شده در این مقاله است. همان طور که ملاحظه می‌شود، تعداد ویژگی‌های منتخب توسط روش سوم بسیار زیاد است که منجر به هزینه محاسباتی بیشتر آن خواهد شد. اما رویکرد انتخاب ویژگی پیشنهادی در این مطالعه، منجر به تولید ماتریس ویژگی با ابعاد به‌مراتب کمتر شده است. به‌طور کلی برای موارد عیب‌یابی یک تا سه مجموعه (F_{129} و F_{128}) و برای مورد مطالعاتی چهارم، مجموعه (F_{31} ، F_{127} و F_{131}) به‌عنوان ویژگی‌های بهینه انتخاب شده‌اند.

۶- نتیجه‌گیری

در این مقاله، روش جدیدی برای عیب‌یابی چندکلاسه یاتاقان‌ها با عیوب مختلف و در سرعت دورانی‌های متفاوت ارایه شده است. در روش ارایه‌شده، سیگنال‌های ارتعاشی به‌کمک الگوریتم‌های تجزیه‌ی مود تجزیه‌ی (EMD) و تبدیل بسته‌ی موجک (WPD)، تجزیه و ویژگی‌های حوزه زمان و فرکانس متناظر با هر کدام از مولفه‌های حاصل از تجزیه استخراج شده‌اند. در این مطالعه، از روش انتخاب ویژگی ارزیابی جبران فاصله (CDET) برای انتخاب ویژگی‌های بهینه استفاده شده است. از آنجایی که در روش CDET پارامتری تحت عنوان آستانه وجود دارد که در تعیین تعداد ویژگی‌های مناسب نقش مهمی ایفا می‌کند، بنابراین، در این پژوهش برای محاسبه این مقدار آستانه و تعیین مجموعه ویژگی بهینه با کمترین تعداد، از الگوریتم بهینه‌سازی ازدحام (PSO) استفاده شده و روش انتخاب ویژگی ارزیابی جبران فاصله (OCDET) بهبود یافته است. در مرحله بعد، از مناسب‌ترین بردار ویژگی منتخب به‌عنوان ورودی الگوریتم ماشین بردار پشتیبان بهبودیافته (SVM) استفاده شده است. در این مقاله، از روش ترکیبی جدید

using multiclass support vector machines with binary particle swarm optimization and regularized Fisher's criterion. *Journal of Intelligent Manufacturing*. 2017;28(2):405-417.

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

17- Yin H, Qiao J, Fu P, Xia XY. Face feature selection with binary particle swarm optimization and support vector machine. *Journal of Information Hiding and Multimedia Signal Processing*. 2014;5(4):731-739.

18- Case Western Reserve University. Bearing data center [Internet]. Cleveland: Case Western Reserve University; 2016 [cited 2017 Sep 5]. Available from: <http://csegroups.case.edu/bearingdatacenter/home>

19- Tabrizi AA, Al-Bugharbee H, Trendafilova I, Garibaldi L. A cointegration-based monitoring method for rolling bearings working in time-varying operational conditions. *Meccanica*. 2017;52(4-5):1201-1217.

20- Rafiee J, Arvani F, Harifi A, Sadeghi MH. Intelligent condition monitoring of a gearbox using artificial neural network. *Mechanical Systems and Signal Processing*. 2007;21(4):1746-1754.

21- Nezamivand Chegini S, Bagheri A, Najafi F. PSOSCALF: A new hybrid PSO based on Sine Cosine Algorithm and Levy flight for solving optimization problems. *Applied Soft Computing*. 2018;73:697-726.

conference on rotor dynamics. Cham: Springer; 2015.

9- Tabrizi A, Garibaldi L, Fasana A, Marchesiello S. Early damage detection of roller bearings using wavelet packet decomposition, ensemble empirical mode decomposition and support vector machine. *Meccanica*. 2015;50(3):865-874.

10- Lei Y, He Z, Zi Y, Chen X. New clustering algorithm-based fault diagnosis using compensation distance evaluation technique. *Mechanical Systems and Signal Processing*. 2008;22(2):419-435.

11- Yang BS, Han T, An JL. ART-KOHONEN neural network for fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*. 2004;18(3):645-657.

12- Fatima S, Mohanty AR, Naikan VNA. Multiple fault classification using support vector machine in a machinery fault simulator. In: Sinha JK, editor. *Vibration engineering and technology of machinery: Proceedings of VETOMAC X 2014*, held at the University of Manchester, UK, September 9-11, 2014. Cham: Springer; 2015. pp. 1021-1031.

13- Dong Sh, Sun D, Tang B, Gao Z, Yu W, Xia M. A fault diagnosis method for rotating machinery based on PCA and Morlet kernel SVM. *Mathematical Problems in Engineering*. 2014;2014(10):293878.

14- Yang CY, Wu TY. Diagnostics of gear deterioration using EEMD approach and PCA process. *Measurement*. 2015;61:75-87.

15- Ziani R, Felkaoui A, Zegadi R. Bearing fault diagnosis