



یک روش هوشمند جدید برای شناسایی عیب یاتاقان‌ها بر پایه مفهوم هم‌انباشتگی و انتخاب ویژگی بهینه در شرایط کاری سرعت متغیر با زمان

سعید نظامیوند چگینی^{۱*}، محمدباقر سلیمزاده کاکرودی^۲ و احمد باقری^۳

^۱ دکتری، دانشکده مهندسی مکانیک، گروه دینامیک، کنترل و ارتعاشات، دانشگاه گیلان، رشت

^۲ کارشناسی ارشد، گروه مهندسی مکانیک، مهندسی مکانیک، موسسه آموزش عالی احرار، رشت

^۳ استاد، دانشکده مهندسی مکانیک، گروه دینامیک، کنترل و ارتعاشات، دانشگاه گیلان، رشت

نوع مقاله، تاریخ دریافت: ۱۳۹۷/۰۸/۰۲؛ تاریخ بازنگری: ۱۳۹۸/۰۹/۰۶؛ تاریخ پذیرش: ۱۳۹۸/۱۱/۰۱

چکیده

در این مقاله، یک روش ترکیبی هوشمند جدید برای شناسایی عیب یاتاقان در شرایط سرعت متغیر با زمان پیشنهاد شده است. سیگنال‌های ارتعاشی در دو حالت سالم و رینگ داخلی معیوب در سرعت متغیر با زمان جمع‌آوری شده‌اند. در این مطالعه، از تکنیک تجزیه مود تجربی کلی و روش اثر جوهانسون برای استخراج روابط هم‌انباشته از داده‌های ارتعاشی استفاده شده است. سپس، با بکارگیری روش تبدیل بسته‌های موجک و ویژگی‌های آماری در حوزه زمان، ماتریس ویژگی متناظر با روابط هم‌انباشتگی محاسبه شده است. در مرحله بعد، از روش ارزیابی جبران فاصله برای انتخاب ویژگی‌های اولیه استفاده شده است. از ویژگی‌های منتخب اولیه به عنوان ورودی طبقه‌بندی کننده ماشین بردار پشتیبان برای پیش‌بینی وضعیت یاتاقان استفاده شده است. در نهایت، پارامترهای بهینه ماشین بردار پشتیبان و مجموعه ویژگی‌های بهینه به کمک الگوریتم بهینه‌سازی ازدحام ذرات باینری تعیین شده‌اند. نتایج به دست آمده نشان می‌دهند که مجموعه ویژگی‌های بهینه به خوبی قادر به تفکیک وضعیت‌های مختلف یاتاقان در سرعت متغیر می‌باشند. مقایسه نتایج این مقاله با دیگر روش‌های عیب‌یابی، دلالت بر توانمندی روش پیشنهادی دارد.

کلمات کلیدی: عیب‌یابی یاتاقان؛ شرایط کاری متغیر با زمان؛ هم‌انباشتگی؛ استخراج ویژگی؛ انتخاب ویژگی.

A New Intelligent Method for Bearing Fault Detection Based on Co-integration Concept and Selecting the Optimal Feature Set at Time-Varying Speed Conditions

S. Nezamivand Chegini^{1,*}, M. B. Salimzadeh Kakroudi², A. Bagheri³

¹ Ph.D. Student, Mech. Eng., Guilan Univ., Rasht, Iran.

² MSc of Mechanical Engineering, Ahrar Institute of Technology and Higher Education, Rasht, Iran.

³ Prof., Dep. of Mech. Eng., Guilan Univ., Rasht, Iran.

Abstract

In this paper, a new hybrid intelligent method is suggested for the bearing fault detection at time – varying speed conditions. The vibration signals have been collected for two states as healthy bearing and defected inner race under variable speeds. In this study, the ensemble empirical mode decomposition (EEMD) technique and Johanson trace method are utilized for extracting the co-integration relationships from the vibration data. Then, the feature matrix corresponding to the co-integration relationships is calculated using the wavelet packet decomposition (WPD) method, and the time -domain statistical features. In the next stage, the compensation distance evaluation technique (CDET) has been used to determine the preselected feature subsets. The preselected features are utilized as input data of the support vector machine (SVM) to predict the bearing state. Finally, The optimal SVM parameters and the optimal feature subsets are determined using the binary particle swarm optimization (BPSO) algorithm. The obtained results demonstrate that the optimal features are well able to differentiate between different bearing states at time-varying speeds. Comparing the results of this article with other fault detection methods indicates the ability of the proposed method.

Keywords: Bearing Fault Detection; Time-Varying Working Conditions; Co-integration; Feature Extraction; Feature Selection.

۱- مقدمه

در اکثر مطالعات، عیب‌یابی یاتاقان‌ها در شرایط سرعت دورانی و بارگذاری ثابت، مورد بررسی قرار گرفته‌اند؛ اما معمولاً یاتاقان‌ها در شرایط سرعت و بارگذاری متغیر کار می‌کنند. سیگنال‌های ارتعاشی به دست آمده از ماشین‌های دوار در این شرایط، غیرخطی و غیرایستا هستند و از این رو روش‌های معمول در حوزه زمان و فرکانس، قادر به تشخیص شرایط مختلف عیب نیستند.

تکنیک‌های عیب‌یابی معمولاً به صورت ترکیبی از روش‌های پیش‌پردازش، استخراج و انتخاب ویژگی، پس‌پردازش و شناسایی الگو می‌باشند. در بین روش‌های پردازش سیگنال، روش تجزیه مود تجربی و بهبود یافته‌های آن در زمینه عیب‌یابی به طور گسترده‌ای استفاده شده‌اند. لی^۱ و همکاران [۱]، روشی جدید برای تجزیه سیگنال و شناسایی عیب در یاتاقان‌ها بر پایه‌ی بهبود تجزیه مود ذاتی کلی و تبدیل فوریه ارائه کردند. سانگ^۲ و همکاران [۲]، از روش تجزیه مقدار منفرد^۳ برای بی‌نویز کردن سیگنال چرخ‌دنده استفاده کرده‌اند. سپس، از ضریب همبستگی برای انتخاب توابع مود ذاتی حساس و از تبدیل هیلبرت برای یافتن مشخصه‌ی فرکانسی سیگنال استفاده کرده‌اند. ژو^۴ و همکاران [۳]، با ترکیب روش‌های آنروپی جایگزینی چند متغیره^۵، ماشین بردار پشتیبان و الگوریتم بهینه‌سازی ازدحام ذرات یک روش عیب‌یابی ارائه کرده‌اند. تبریزی^۶ و همکاران [۴]، برای شناسایی زود هنگام عیب در یاتاقان‌ها، از تجزیه بسته‌ای موجک و تجزیه مود تجربی کلی به ترتیب برای بی‌نویز سازی و تجزیه سیگنال‌های ارتعاشی استفاده نموده‌اند. آن‌ها ماتریس ویژگی را به کمک ویژگی انرژی نرمالیزه شده مربوط به مولفه‌های سیگنال، تشکیل داده و از آن به عنوان ورودی ماشین بردار پشتیبان استفاده نموده‌اند.

با افزایش تعداد ویژگی‌های استخراج شده از سیگنال‌های ارتعاشی، بردار ویژگی نه تنها شامل ویژگی‌های مفید است، بلکه شامل ویژگی‌های نامرتبط و زائد خواهد بود. از این رو،

استفاده از روش‌های انتخاب ویژگی، یکی از موضوعاتی است که اخیراً مورد توجه محققان بوده است. باقری و همکاران روشی هوشمند جهت شناسایی عیب چرخ‌دنده‌ها بر مبنای انتخاب ویژگی‌های مناسب به کمک الگوریتم بهینه‌سازی ازدحام ذرات، روش تجزیه مود تجربی و ماشین بردار پشتیبان ارائه کرده‌اند [۵]. یانگ^۷ و وو [۶] از رویکرد ترکیبی تجزیه مود تجربی کلی، تحلیل مولفه اصلی و شبکه عصبی مصنوعی^۸ برای تشخیص عیب در جعبه‌دنده‌ها استفاده نمودند. زبانی^۹ و همکاران [۷]، با معیار فیشر و الگوریتم بهینه‌سازی ازدحام ذرات باینری، روشی برای انتخاب مناسب‌ترین مجموعه از ویژگی‌های استخراج شده از سیگنال‌های ارتعاشی یاتاقان‌ها ارائه نموده‌اند. سپس، از ویژگی‌های منتخب به عنوان ورودی ماشین بردار پشتیبان چند کلاسه استفاده نموده‌اند. فاطیما^{۱۰} و همکاران [۸]، از روش ارزیابی جبران فاصله^{۱۱} برای انتخاب ویژگی‌های پر معنی و از روش ماشین بردار پشتیبان برای عیب‌یابی چند کلاسه یاتاقان‌ها در سرعت‌های مختلف استفاده کرده‌اند. ژانگ^{۱۲} و همکاران [۹]، از روش Relief-F برای حذف ویژگی‌های غیرحساس به حضور عیب و از الگوریتم بهینه‌سازی ازدحام ذرات باینری برای بهبود روش ماشین بردار پشتیبان و انتخاب مجموعه ویژگی بهینه استفاده کرده‌اند. این^{۱۳} و همکاران [۱۰] روشی ارائه نموده‌اند که قادر است، ویژگی‌های مناسب را به طور مستقیم از مجموعه ویژگی‌های اصلی انتخاب نموده و هم‌زمان پارامترهای ماشین بردار پشتیبان را بهینه نماید. تبریزی^{۱۴} و همکاران [۱۱] یک روش ترکیبی جدید برای شناسایی عیب در یاتاقان‌ها در شرایط کاری متغیر با زمان بر پایه‌ی تکنیک هم‌انباشتگی، روش تجزیه مود تجربی کلی و ماشین بردار پشتیبان ارائه داده‌اند. هوانگ^{۱۵} و همکاران [۱۲] از تبدیل بسته‌ای موجک بهبود یافته برای استخراج ویژگی از سیگنال‌های ارتعاشی مربوط به یک مجموعه جعبه‌دنده

⁷ C. Y. Yang

⁸ Artificial Neural Network (ANN)

⁹ R. Ziani

¹⁰ S. Fatima

¹¹ Componsation Distance Evaluation Technique (CDET)

¹² X. Zhang

¹³ H. T. Yin

¹⁴ A. Tabrizi

¹⁵ W. Huang

¹ Y. Lei

² M. Song

³ Singular Value Decomposition (SVD)

⁴ F. Xu

⁵ Multiscale Permutation Entropy

⁶ A. Tabrizi

های عیب را به کمک تبدیل بسته‌های موجک و تبدیل فوریه زمان کوتاه استخراج کرده‌اند. در کار آن‌ها، تحلیل تفکیک‌کننده خطی^۷ و تحلیل تفکیک‌کننده حساس محلی^۸ به عنوان تکنیک کاهش ابعاد فضای ویژگی استفاده شده است. سیستم طبقه‌بند در مطالعه‌ی آن‌ها سیستم استخراج فازی مبتنی بر شبکه عصبی تطبیقی بوده است.

هدف اصلی این مقاله، توسعه روش‌های عیب‌یابی یاتاقان‌ها در شرایط کاری سرعت متغیر است. از آنجایی که سیگنال‌های ارتعاشی اکتساب شده در شرایط کاری متغیر با زمان، غیر ایستا هستند، بنابراین، ویژگی‌های آماری این داده‌ها وابسته به زمان می‌باشند. به عبارت دیگر، ویژگی‌های استخراج شده از سیگنال‌های خام اکتساب شده در شرایط کاری متغیر، علاوه بر نوع عیب موجود در اجزای ماشین‌های دوار، وابسته به پارامترهای دیگری نظیر شرایط کاری ماشین‌های دوار از حیث بارگذاری و سرعت هستند. اکثر کارهای انجام شده در گذشته برای شناسایی عیب اجزای ماشین‌های دوار در شرایط کاری ایستا قابل کاربرد هستند. از طرفی، معمولاً اجزای اصلی ماشین‌های دوار به ویژه یاتاقان‌ها در شرایطی کار می‌کنند که سرعت دورانی در حال افزایش و یا کاهش است، به طوری که ممکن است، شدت این تغییرات قابل ملاحظه باشد و با اتکا به روش‌های معمول پردازش سیگنال نمی‌توان به نشانه‌های مربوط به وضعیت یاتاقان از حیث سالم و یا معیوب بودن دست یافت. یکی از اهداف و نوآوری‌های این مقاله، ارائه رویکردی جهت استخراج ویژگی‌هایی است که دارای بیشترین حساسیت به وقوع و حضور عیب حتی با اندازه‌های بسیار کوچک در یاتاقان است. برای این منظور، در این مطالعه روشی پیشنهاد شده است که بر پایه‌ی ترکیب روش‌های تجزیه مود تجربی کلی، مفهوم هم-انباشتگی و تبدیل بسته‌های موجک برای استخراج بردارهای ایستا و غیرحساس به شرایط کاری یاتاقان است. در تکنیک پیشنهادی، ابتدا از روش تجزیه مود تجربی کلی برای تجزیه سیگنال‌ها و از روش هم‌انباشتگی برای استخراج روابط ایستا از مولفه‌های غیرایستا استفاده شده است. سپس، با اعمال تبدیل بسته‌های موجک به روابط هم‌انباشتگی و استخراج

استفاده نموده‌اند. آن‌ها از این ویژگی‌ها با ابعاد بالا به عنوان ورودی روش انتخاب ویژگی مجموعه‌های ناهموار^۱ و حذف ویژگی‌های نامرتب با عیب استفاده نموده‌اند. سپس، با به‌کارگیری الگوریتم ژنتیک، مجموعه ویژگی بهینه را برای عیب‌یابی تعیین کرده‌اند. نظامیوند چگینی و همکاران [۱۳]، تکنیک هوشمند عیب‌یابی جدیدی برای شناسایی عیوب چند کلاسه یاتاقان‌ها در سرعت‌های متفاوت بر پایه‌ی روش تبدیل بسته‌های موجک، روش انتخاب ویژگی FDAF-score، الگوریتم بهینه‌سازی ازدحام ذرات باینری^۲ و ماشین بردار پشتیبان چند کلاسه پیشنهاد نموده‌اند. نتایج حاصل از کار آن‌ها دلالت بر توانمندی تکنیک پیشنهادی در تشخیص عیوب مختلف با اندازه‌های بسیار کوچک دارد. نویسندگان در کار دیگری [۱۴]، به منظور انتخاب مناسب‌ترین ویژگی‌ها، با به‌کارگیری روش الگوریتم بهینه‌سازی ذرات، روش انتخاب ویژگی ارزیابی جبران فاصله را به گونه‌ای بهبود داده‌اند که دقت شناسایی شرایط حاکم بر یاتاقان‌ها به حداکثر برسد. یان و جیا^۳ [۱۵]، روش شناسایی عیب چند کلاسه‌ی جدیدی برای تشخیص عیب یاتاقان در شرایط کاری مختلف پیشنهاد نموده‌اند. در مطالعه آن‌ها، ویژگی‌ها به کمک سه استراتژی مشخصات آماری، تبدیل فوریه سریع و تجزیه مود وردشی به دست آمده‌اند. سپس، ویژگی‌های پرمعنی و حساس توسط روش انتخاب ویژگی لاپلاسی^۴ انتخاب شده‌اند. واکاریا^۵ و همکاران [۱۶]، رویکردی برای شناسایی عیب یاتاقان در چهار وضعیت یاتاقان سالم، ساچمه‌ی معیوب، رینگ داخلی معیوب و رینگ خارجی معیوب طراحی نموده‌اند. در مطالعه آن‌ها، بردار ویژگی هر سیگنال شامل ویژگی‌هایی همچون، کشیدگی، چولگی، میانگین، ریشه‌ی میانگین مربع و آنتروپی شانون است. سپس، حساس‌ترین ویژگی‌ها به کمک روش‌های فیلتر نظیر روش‌های Chisquare و Relief تعیین شده‌اند. آتویی^۶ و همکاران [۱۷]، یک فرآیند جدید برای شناسایی شرایط یاتاقان مانند ساچمه‌ی معیوب، رینگ داخلی و رینگ خارجی معیوب در سرعت‌های مختلف معرفی نموده‌اند. آن‌ها ویژگی-

¹ Rough Sets Method (RS)

² Binary Particle Swarm Optimization (BPSO) Algorithm

³ X. Yan and M. Jia

⁴ Laplacian Feature Selection Method

⁵ V. Vakharia

⁶ I. Attoui

⁷ Linear Discriminant Analysis (LDA)

⁸ Locality Sensitive Discriminant Analysis (LSDA)

شده یک شکاف کوچک با عرض کم‌تر از ۱ میلی‌متر و عمق ۱۰۰ میکرومتر است. برای هر وضعیت یاتاقان، ۲۰ سیگنال ارتعاشی با فرکانس نمونه‌برداری ۱/۳ kHz اکتساب شده است. این سیگنال‌ها، در شرایطی جمع‌آوری شده‌اند که سرعت موتور از ۱۵۰ تا ۱۵۰۰ دور در دقیقه افزایش می‌یابد. دو نمونه از سیگنال‌های جمع‌آوری شده در دو حالت سالم و معیوب در شکل ۲ آمده‌اند.

۳- روش‌ها


۳-۱- روش تجزیه مود تجربی کلی

روش تجزیه مود تجربی یکی از روش‌هایی است که به طور وسیعی برای تحلیل سیگنال‌های غیرایستا و غیرخطی استفاده می‌شود. این روش می‌تواند هر سیگنال پیچیده را به طور تطبیق‌پذیری به یک سری توابع مود ذاتی^۲ (IMFs) از فرکانس بالا به فرکانس پایین تجزیه کند. در نهایت، سیگنال تجزیه شده را می‌توان به صورت رابطه (۱) نوشت [۱۸]:

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

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

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



شکل ۱- مجموعه آزمایشگاهی [۱۱]

ویژگی‌های حوزه زمان، ماتریس ویژگی استخراج شده‌اند. از طرف دیگر، استخراج طیف وسیعی از ویژگی‌ها از داده‌های ارتعاشی و تشکیل ماتریس ویژگی با ابعاد بزرگ، منجر به پیچیدگی محاسباتی و کاهش دقت تکنیک‌های هوشمند در شناسایی عیب یاتاقان می‌شود. هدف دیگر این مطالعه، ارائه تکنیکی به منظور انتخاب مناسب‌ترین مجموعه ویژگی‌ها با کم‌ترین ابعاد است، به گونه‌ای که شناسایی عیب به کمک روش ماشین بردار پشتیبان دارای بیشترین دقت باشد. برای نیل به این هدف، از روش ارزیابی جبران فاصله برای پیش - انتخاب ویژگی و حذف ویژگی‌های زائد و بی‌معنی استفاده شده است. سپس، از الگوریتم بهینه‌سازی ازدحام ذرات باینری برای انتخاب مجموعه ویژگی بهینه با کم‌ترین تعداد ویژگی و تعیین پارامترهای کلیدی ماشین بردار پشتیبان و بهبود این طبقه‌بند در شناسایی وضعیت یاتاقان استفاده شده است.


دیگر بخش‌های این مقاله به صورت زیر تدوین یافته‌اند: 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 است. در بخش پنجم، به تحلیل نتایج حاصل از این مقاله پرداخته شده است. در نهایت، مقاله در بخش ششم نتیجه‌گیری شده است.

۲- مجموعه آزمایشگاهی

در این مقاله، از داده‌های اکتساب شده در گروه دینامیکی ماشین‌آلات و سازه‌های پیشرفته در گروه مهندسی مکانیک و هوافضا دانشگاه استراسکلاید^۱ استفاده شده است. مطابق شکل ۱، این مجموعه آزمایشگاهی شامل، یک موتور DC (۱ اسب بخار و ۲۰۰۰ دور در دقیقه)، یاتاقان، سیستم بارگذاری مکانیکی، شتاب‌سنج و سیستم اکتساب داده است [۱۱]. یاتاقان مورد استفاده در این آزمایش، از نوع شیار عمیق SKF 6308 است. در این مطالعه، دو وضعیت یاتاقان سالم و رینگ داخلی معیوب بررسی شده است. عیب ایجاد

¹ The Dynamics of Advanced Structures and Machinery (DASM) Group at Department of Mechanical and Aerospace Engineering of Strathclyde University

² Intrinsic Mode Functions (IMFs)



شکل ۲- دو نمونه سیگنال ارتعاشی، الف) سیگنال سالم و ب) سیگنال معیوب [۱۱]

• در هر نقطه، میانگین پوش برازش داده شده بر نقاط پیشینه‌ی محلی و پوش برازش داده شده بر نقاط کمینه محلی باید صفر باشد.

روش تجزیه مود تجربی دارای مشکلات مهمی نظیر، پدیده‌ی اختلاط مودها و اثرات انتهایی در موده‌های استخراج شده است. وو^۱ و هوانگ^۲ [۱۹] روشی که تجزیه مود تجربی کلی^۳ نامیده می‌شود، برای حل مشکلات مزبور ارائه کرده‌اند.

این روش سیگنال اصلی را که به آن نویز سفید اضافه شده است، به کمک روش تجزیه مود تجربی به یکسری توابع مود ذاتی تجزیه می‌کند. در واقع با این تکنیک می‌توان از به وجود آمدن پدیده‌ی اختلاط مود جلوگیری کرد.

مراحل تجزیه سیگنال به کمک EEMD را می‌توان به صورت زیر خلاصه کرد [۱۹]:

۱. اضافه کردن سیگنال نویز سفید تصادفی به سیگنال اصلی اکتساب شده:

$$xn_j(t) = x(t) + Amp * n_j(t) \quad j = 1, 2, \dots, M \quad (2)$$

۲. تکرار مراحل (۱) و (۲) تا M دفعه.

۳. محاسبه‌ی میانگین‌های گروه IMF های متناظر به عنوان نتیجه‌ی نهایی:

$$IMF_i(t) = \frac{\sum_{j=1}^M c_{ij}}{M}, \quad i = 1, \dots, I \quad (4)$$

که I کمینه تعداد IMF ها است. چالش اساسی این روش، تعیین تعداد سیگنال‌های نویزی و دامنه نویز است که در این مقاله مطابق [۱۹] به ترتیب مقادیر ۱۰۰ و ۰.۲ در نظر گرفته شده است.

۴. محاسبه‌ی میانگین‌های گروه IMF های متناظر به عنوان نتیجه‌ی نهایی:

۱. اضافه کردن سیگنال نویز سفید تصادفی به سیگنال اصلی اکتساب شده:

$$xn_j(t) = x(t) + Amp * n_j(t) \quad j = 1, 2, \dots, M \quad (2)$$

² Z. Wu

² N. Huang

⁴ Ensemble Empirical Mode Decomposition (EEMD)

۳-۲- هم‌انباشتگی

ایده اصلی مفهوم هم‌انباشتگی همان یافتن ترکیبات خطی ایستا از بخش‌های مختلف سیگنال‌های غیر ایستا است. از آنجایی که سیگنال‌های ارتعاشی اکتساب شده از ماشین‌های دوار در شرایط کاری متغیر با زمان دارای رفتاری غیرایستا هستند، لذا با به کارگیری مفهوم انباشتگی می‌توان سری‌های زمانی را یافت که ایستا هستند.

فرض کنید که سری زمانی Y_t مانا نباشد، ولی با تفاضل گیری مانا شود، در این صورت Y_t دارای یک ریشه واحد است و آن را با $I(1)$ نشان می‌دهند. $I(1)$ را اصطلاحاً انباشته از درجه یک می‌گویند. از طرفی دیگر، اگر درجه انباشتگی دو متغیر Y_t و X_t یکسان بوده و برابر d باشد و ترکیب خطی مانند $u_t = \beta_1 X_t + \beta_2 Y_t$ وجود داشته باشد که دارای انباشتگی از مرتبه $d-b$ است ($b > 0$)، آنگاه بردار $\beta' = [\beta_1 \beta_2]$ را بردار هم‌انباشته کننده یا بردار هم‌انباشتگی می‌گویند. اگر $d = b = 1$ باشد، آنگاه $u_t \sim I(0)$ خواهد بود، یعنی ترکیب خطی از Y_t و X_t مانا شده است. این ترکیب خطی را رابطه هم‌انباشتگی یا رابطه تعادلی می‌گویند که می‌تواند برای توصیف روابط بلند مدت به کار رود، هر چند که قادر به توصیف نوسانات کوتاه مدت نمی‌باشد. به همین دلیل مدل‌های دیگری مطرح شده‌اند که هم نوسانات کوتاه مدت و هم روابط تعادلی را مورد استفاده قرار می‌دهند [۲۰]. این مدل‌ها معروف به مدل‌های تصحیح خطا یا تصحیح تعادلی هستند.

$$Y_t = \sum_{j=1}^p A_j Y_{t-j} + \varepsilon_t \quad (5)$$

برای مدل فوق، می‌توان یک مدل تصحیح خطای برداری^۱ به صورت زیر به دست آورد:

$$\Delta Y_t = \pi Y_{t-1} + \sum_{j=1}^{p-1} A_j^* \Delta Y_{t-j} + \varepsilon_t \quad (6)$$

$$A_j^* = -\sum_{k=j+1}^p A_k; \quad j = 1, 2, \dots, p-1 \quad (7)$$

$$\Pi = (A_1 + A_2 + \dots + A_p) - I \quad (8)$$

که Π را ماتریس پارامتر می‌نامند. در هر مدل تصحیح خطا، اثرات کوتاه مدت را نشان می‌دهد؛ در حالی که Π بیانگر

رابطه بلند مدت یا رابطه هم‌انباشتگی است. برای یافتن بردارهای هم‌انباشتگی، ابتدا باید باقی‌مانده رگرسیون را به صورت زیر محاسبه شود:

$$\Delta y_{it} = \sum_{t'}^p \phi_{1t'} \Delta y_{i(t-t')} + \bar{U}_{it} \quad (9)$$

$$y_{i(t-1)} = \sum_{t'}^p \phi_{2t'} \Delta y_{i(t-t')} + \hat{V}_{it} \quad (10)$$

که p درجه مدل، ϕ_1 و ϕ_2 ماتریس‌های ضرایب و \bar{U}_{it} و \hat{V}_{it} باقیمانده هستند. سپس، بردارهای هم‌انباشته کننده به عنوان بردارهای ویژه در مسئله مقدار ویژه زیر تعیین می‌شوند:

$$|\lambda_i S_{i11} - S_{i10} S^{-1}_{i00} S_{i01}| = 0 \quad (11)$$

که ماتریس‌های کوواریانس در رابطه ۱۱ به صورت زیر تعریف می‌شوند:

$$S_{i00} = \frac{1}{T} \sum_{t=1}^T \bar{U}_{it} \bar{U}_{it}' \quad (12)$$

$$S_{i01} = \frac{1}{T} \sum_{t=1}^T \bar{U}_{it} \hat{V}_{it}' \quad (13)$$

$$S_{i10} = \frac{1}{T} \sum_{t=1}^T \hat{V}_{it} \bar{U}_{it}' \quad (14)$$

$$S_{i11} = \frac{1}{T} \sum_{t=1}^T \hat{V}_{it} \hat{V}_{it}' \quad (15)$$

ماتریس پارامتر را می‌توان به صورت $\Pi = \alpha \beta'$ نوشت. بردارهای ویژه به دست آمده از رابطه ۱۱ که متناظر با مقادیر ویژه غیر صفر هستند، همان روابط هم‌انباشتگی می‌باشند. برای تعیین مقادیر ویژه غیر صفر، از آزمون اثر^۲ جوهانسون استفاده می‌شود که به صورت آزمون فرضیه زیر بیان می‌شود:

$$H_0: \lambda_1 = 0, \dots, \lambda_r = 0, \lambda_{r+1} = \lambda_{r+2} = \dots = \lambda_m = 0 \quad (16)$$

فرضیه H_0 بیانگر آن است که مرتبه ماتریس Π برابر r و فرضیه H_1 بیانگر آن است که مرتبه ماتریس Π برابر m است. آماره آزمون فرضیه در روش اثر جوهانسون به صورت رابطه (۱۷) است:

² Trace

¹ Vector Error Correction Model (VECM)

تحلیل تفکیک کننده فیشر^۱ [۷]. تحلیل مولفه‌های اصلی [۲۱] و تکنیک ارزیابی جبران فاصله [۲۲] برای حل مسئله کاهش فضای ویژگی و انتخاب ویژگی‌های موثر استفاده شده است.

در این مقاله، از روش ارزیابی جبران فاصله برای انتخاب مجموعه ویژگی اولیه و حذف ویژگی‌های زائد استفاده شده است. مراحل فرآیند انتخاب ویژگی با روش CDET به شرح زیر است [۲۲]:

۱. پارامتر میانگین فاصله متناظر با ویژگی z ام برای سیگنال‌هایی که دارای اطلاعاتی از کلاس c هستند، به صورت رابطه (۱۹) محاسبه می‌شود:

$$d_{c,j} = \frac{1}{M_C(M_C - 1)} \sum_{l, m=1}^{M_C} |f_{m,c,j} - f_{l,c,j}| \quad (19)$$

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

سیس، میانگین فاصله برای تمامی کلاس‌ها از رابطه (۲۰) محاسبه می‌شود:

$$d_j^{(w)} = \frac{1}{C} \sum_{c=1}^C d_{c,j} \quad (20)$$

۲. فاکتور واریانس متناظر با ویژگی z ام برای $d_j^{(w)}$ به صورت رابطه (۲۱) تعریف و محاسبه می‌شود:

$$v_j^{(w)} = \frac{\max(d_{c,j})}{\min(d_{c,j})} \quad (21)$$

۳. میانگین ویژگی z ام مربوط به تمامی سیگنال‌ها برای کلاس c از رابطه (۲۲) محاسبه می‌شود:

$$u_{c,j} = \frac{1}{M_C} \sum_{m=1}^{M_C} f_{m,c,j} \quad (22)$$

سیس، میانگین فاصله بین سیگنال‌هایی که متعلق به کلاس‌های مختلف هستند، به صورت رابطه (۲۳) محاسبه می‌شود:

$$d_j^{(b)} = \frac{1}{C(C-1)} \sum_{c, e=1}^C |u_{e,j} - u_{c,j}| \quad (23)$$

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

$$\lambda_{tr} = -T \sum_{i=r+1}^m \ln(1 - \hat{\lambda}_i), \quad i = 1, \dots, m \quad (17)$$

λ_{tr} فرضیه H_0 را آزمون می‌کند که آیا r بردار هم‌انباشتنگی وجود دارد یا خیر.

۳-۳- استخراج ویژگی در حوزه زمان

به دلیل ماهیت غیرخطی بودن دینامیک یاتاقان‌ها و غیرایستا بودن سیگنال‌های ارتعاشی، اگر تنها به بررسی سری‌های زمانی مربوط به داده‌های ارتعاشی اکتفا شود، اطلاعات چندانی نمی‌توان در خصوص نوع و اندازه‌ی عیب به دست آورد؛ بنابراین، در اینجا از روش‌های مختلف استخراج ویژگی استفاده خواهد شد. یکی از روش‌های رایج تشکیل ماتریس ویژگی، استخراج ویژگی‌های آماری در حوزه زمان از داده‌های ارتعاشی است. لیست ویژگی‌های به کارگرفته شده در این مقاله، در جدول ۱ ارایه شده است.

پس از استخراج ویژگی از تمامی سیگنال‌های ارتعاشی، ماتریس ویژگی به فرم کلی (۱۸) حاصل می‌شود:

$$FM = [f_{m,i,j}] \quad (18)$$

که در آن $j = 1, 2, \dots, J$ و $i = 1, 2, \dots, C$ ، $m = 1, 2, \dots, M_C$ در این ماتریس، $F_i = f_{m,i,j}$ ویژگی z ام متناظر با نمونه سیگنال m ام تحت شرایط i 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.

۳-۴- انتخاب ویژگی به کمک روش ارزیابی جبران فاصله

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 طبقه‌بندی کننده‌های 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،

¹ Fisher Discriminate Analysis (FDA)

جدول ۱- ویژگی‌های آماری در حوزه زمان

ویژگی	فرمول	ویژگی	فرمول	ویژگی	فرمول	ویژگی	فرمول
میانگین	$F_1 = \frac{1}{N} \sum_{i=1}^N x(i)$	میانگین ریشه مربعات	$F_7 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	دامنه	$F_{13} = \max(x_i) - \min(x_i)$		
ماکزیمم	$F_2 = \max(x(i))$	مقدار پیک	$F_8 = \max(x_i)$	ضریب اوج	$F_{14} = \frac{\max(\text{abs}(x))}{RMS}$		
مینیمم	$F_3 = \min(x(i))$	میانگین پیک‌ها	$F_9 = \text{mean}(\text{total peak})$	ضریب شکل	$F_{15} = \frac{x_{RMS}}{(\frac{1}{N} \sum_{i=1}^N x_i)}$		
میانه	$F_4 = x(\frac{N+1}{2})$	انحراف معیار	$F_{10} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$	ضریب ایمپالس	$F_{16} = \frac{\text{Peak}}{(\frac{1}{N} \sum_{i=1}^N x_i)}$		
انرژی	$F_5 = \int x(t) ^2 dt$	چولگی	$F_{11} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^3}{(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2)^{\frac{3}{2}}}$	ضریب کلیرنس	$F_{17} = \frac{\text{Peak}}{((\frac{1}{N} \sum_{i=1}^N \sqrt{ x_i })^2)}$		
آنتروپی	$F_6 = - \sum_{i=1}^N x_i^2 \log(x_i^2)$	کشیدگی	$F_{12} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^4}{(\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2)^2}$	انرژی تیگر - کایزر	$F_{20} = \sum_{i=1}^N \Psi[x(i)]$		

$\Psi[x(i)] = [x(i)]^2 - x(i-1)x(i+1)$

$x(i)$ سیگنال ارتعاشی در لحظه i ام و \bar{x} میانگین سیگنال ارتعاشی می‌باشند.

$$\alpha_j = \lambda_j \frac{d_j^{(b)}}{d_j^{(w)}} \quad (27)$$

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

۳-۵- طبقه‌بندی کننده ماشین بردار پشتیبان

این الگوریتم از مجموعه‌ای داده‌ها 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. این روش یادگیری محاسباتی اولین بار توسط

فاکتور واریانس متناظر با ویژگی j ام برای $d_j^{(b)}$ از رابطه (۲۴) محاسبه می‌شود:

$$v_j^{(b)} = \frac{\max(|u_{e,j} - u_{c,j}|)}{\min(|u_{e,j} - u_{c,j}|)} \quad (24)$$

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

۴. فاکتور تصحیح برای ویژگی j ام مطابق رابطه (۲۵) تعریف می‌شود:

$$\lambda_j = \frac{1}{\frac{v_j^{(w)}}{\max(v_j^{(w)})} + \frac{v_j^{(b)}}{\max(v_j^{(b)})}} \quad (25)$$

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

$$\bar{\alpha}_j = \frac{\alpha_j}{\max(\alpha_j)} \quad (26)$$

که در آن

می‌شود. در فاز محاسبات، بردارهای سرعت و موقعیت هر ذره به کمک بهترین تجربه شخصی آن (\vec{X}_{pBest}) و بهترین تجربه کل ذرات (\vec{X}_{gBest}) به صورت زیر بروز می‌شود [۲۴]:

$$\vec{V}_i(t+1) = w\vec{V}_i(t) + c_1 r_1 (\vec{X}_{pBest_i} - \vec{X}_i(t)) + c_2 r_2 (\vec{X}_{gBest} - \vec{X}_i(t)) \quad (28)$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (29)$$

که $\vec{V}_i(t+1)$ و $\vec{X}_i(t+1)$ به ترتیب بردارهای سرعت و موقعیت ذره i ام در لحظه $t+1$ می‌باشند. r_1 و r_2 متغیرهایی تصادفی در بازه $[0, 1]$ هستند. در این مطالعه، فاکتورهای یادگیری c_1 و c_2 و ضریب وزنی w طبق [۲۵] تنظیم شده‌اند.

اخیراً، الگوریتم بهینه‌سازی ازدحام ذرات باینری در بسیاری از پژوهش‌های عیب‌یابی، مورد استفاده قرار گرفته‌اند. در الگوریتم BPSO، هر ذره با بیت‌هایی ساخته می‌شوند که فقط شامل اعداد صفر و یا یک هستند. در BPSO مشابه PSO، سرعت هر ذره توسط رابطه‌ی ۲۸ محاسبه می‌شود. در این الگوریتم، موقعیت هر ذره در جهت d به صورت رابطه (۳۰) محاسبه می‌شود [۹]:

$$x_{id}(t+1) = \begin{cases} 1, & \text{if } rand() < s(v_{id}(t+1)) \\ 0, & \text{otherwise} \end{cases} \quad (30)$$

که $rand()$ یک عدد تصادفی در بازه $[0, 1]$ است. $S(x)$ یک تابع سیگموئید است که به صورت رابطه (۳۱) تعریف می‌شود:

$$s(x) = \frac{1}{1 + e^{-x}} \quad (31)$$

۴- روش پیشنهادی

در این مقاله، یک روش ترکیبی هوشمند جدید برای عیب‌یابی یاتاقان‌ها در شرایط کاری سرعت متغیر با زمان ارائه شده است. یکی از اهداف اصلی این مقاله، استخراج ویژگی‌های حساس به حضور عیب از سیگنال‌هایی است که غیرایستا هستند. از این رو، در روش پیشنهادی از روش‌های هم‌انباشتی، تجزیه مود تجربی و روش‌های معمول در حوزه زمان برای استخراج سری‌های زمانی ایستا استفاده شده است. روش هوشمند پیشنهادی، مشابه دیگر روش‌های عیب‌یابی شامل، چهار بخش پیش‌پردازش، استخراج ویژگی، انتخاب ویژگی و شناسایی الگو می‌باشد. فلوجارت روش ارائه شده در این مقاله در شکل ۳ نشان داده شده است. مراحل روش پیشنهادی به صورت زیر می‌باشند:

وینیک^۱ پیشنهاد شده است [۲۳]. ایده اصلی این روش، ایجاد یک مرز خطی بین دو کلاس و تنظیم کردن آن به گونه‌ای است که فاصله بین دو کلاس که حاشیه نامیده می‌شود، بیشینه شود. این حاشیه بر اساس نزدیک‌ترین نقاط دو کلاس محاسبه شده و بردارهای پشتیبان نامیده می‌شود. هنگامی که بردارهای پشتیبان انتخاب می‌شوند، اطلاعات لازم برای تعریف طبقه‌بندی کننده فراهم می‌شود.

اگر داده‌های آموزش در فضای ورودی، به طور خطی قابل تفکیک نباشند، می‌توان از یک ابرصفحه استفاده نمود که تفکیک‌پذیری خطی را در فضایی با ابعاد بالاتر ایجاد می‌کند. برای نیل به این هدف، از تبدیلی استفاده می‌شود که داده‌ها را از فضای ورودی N -بعدی به فضای ویژگی Q -بعدی انتقال می‌دهد. برای پیاده‌سازی چنین تبدیلی از یک تابع هسته $\phi(x)$ و ضرب نقطه‌ای $\langle \phi(x_i), \phi(x_j) \rangle$ استفاده می‌شود. توابع خطی، چند جمله‌ای، پایه شعاعی (گوسی) و سیگموئید از جمله توابع هسته رایج می‌باشند. تابع پایه شعاعی، یکی از رایج‌ترین توابع هسته‌ای است که در بسیاری از کاربردها مانند عیب‌یابی ماشین‌های دوار مورد استفاده قرار گرفته است [۹].

پارامتر جریمه C که در فرآیند تعیین ابر صفحه بهینه مورد استفاده قرار می‌گیرد و پارامتر σ در تابع هسته گوسی، دو پارامتری هستند که کارایی SVM را تحت تاثیر قرار می‌دهد. همان‌طور که خواهید دید، در این مطالعه، از الگوریتم بهینه‌سازی BPSO برای یافتن مقادیر بهینه‌ی این دو پارامتر استفاده خواهد شد.

۳-۶- الگوریتم بهینه‌سازی ازدحام ذرات باینری

الگوریتم بهینه‌سازی ازدحام ذرات^۲ یکی از الگوریتم‌های بر پایه جمعیت و هوش دسته‌جمعی است که در بسیاری از کاربردهای عملی استفاده شده است. در این الگوریتم، هر ذره با دو بردار سرعت و موقعیت نشان داده می‌شود. فرآیند بهینه‌سازی با PSO شامل دو مرحله مقدار دهی اولیه و محاسبات است. در فاز مقدار دهی اولیه، به هر ذره به طور تصادفی یک موقعیت اولیه و یک سرعت اولیه اختصاص داده

¹ V.N. Vapnik

² Particle Swarm Optimization (PSO)

۸- «داده‌های آموزش برای تخمین پارامترها» به دو دسته «داده‌های آموزش» و «داده‌های اعتبار سنجی» تفکیک می‌گردد که از آن‌ها به ترتیب برای ساخت و آموزش طبقه‌بند SVM استفاده شده است.

۹- تمامی ویژگی‌ها با روش CDDET ارزیابی می‌شوند. ویژگی‌هایی که شاخص ارزیابی فاصله آن‌ها از مقدار آستانه $\zeta = 0.5$ بیشتر باشند، به عنوان ویژگی‌های اولیه انتخاب می‌شوند [۲۲].

۱۰- ویژگی‌های اولیه انتخاب شده در مرحله قبل به عنوان ورودی SVM داده می‌شوند. با استفاده از الگوریتم BPSO مقادیر بهینه پارامترهای C و σ در الگوریتم SVM و مجموعه ویژگی بهینه طوری تعیین می‌شوند که دقت آموزش SVM حداکثر گردد. تابع برازش به صورت زیر تعریف شده است:

$$Cost Function = (1 - \alpha)A_{tr} + \alpha N \quad (34)$$

A_{tr} خطای پیش‌بینی وضعیت یاتاقان، N تعداد ویژگی‌های انتخاب شده و α ضریب وزنی می‌باشند. در این مطالعه، اثر تغییر پارامتر α بر دقت شناسایی عیب، مورد بررسی قرار گرفته است.

۱۱- بردارهای ویژگی متناظر با داده‌های تست نهایی به کمک مجموعه ویژگی بهینه استخراج می‌شوند و سپس با استفاده از SVM بهینه شده، کلاس داده‌های تست نهایی مشخص می‌شود.

هر ذره در الگوریتم BPSO از $N = N_p + N_c + N_g$ تشکیل شده است که N_p برابر با تعداد انتخاب شده توسط روش CDDET است. اگر مقدار یک بیت برابر با "۱" باشد، ویژگی مورد نظر انتخاب و در صورتی که برابر با صفر باشد، حذف می‌شود. N_c و N_g به ترتیب برابر با طول بیت‌های پارامترهای C و σ می‌باشند. مقدار اعشاری پارامترهای C و σ طبق رابطه‌ی (۳۵) به دست می‌آیند.

$$X_d = \frac{\sum_{i=1}^N (bit(i) \cdot 2^{i-1})}{2^{N-1}} (X_{dMax} - X_{dMin}) + X_{dMin} \quad (35)$$

که X_d مقدار اعشاری برای C و σ ، N تعداد بیت‌ها، i به معنی بیت i ام است و $bit(i)$ برابر با یک یا صفر است. X_{dMin} و X_{dMax} به ترتیب کران‌های پایین و بالای پارامترهای C و σ هستند. در این مقاله، پارامترها C و σ به ترتیب به بازه‌های $[0.001, 1.001]$ و $[0.1, 1.0]$ محدود هستند؛ همچنین،

۱- ابتدا هر یک از سیگنال‌های جمع‌آوری شده به ۵ قسمت مساوی تقسیم می‌شوند؛ هر بخش شامل ۶۰۰۰ داده است.

۲- هر یک از بخش‌های به دست آمده در مرحله قبل توسط الگوریتم EEMD به IMF های تشکیل دهنده‌اش تجزیه می‌شود. سپس، سه IMF اول حاصل از تجزیه به منظور استخراج ویژگی انتخاب می‌شوند. برای یافتن ترکیب خطی مانا از IMF ها از تکنیک هم‌انباشتگی استفاده شده است. سری زمانی y_{it} برای هر سیگنال از IMF های پنج بخش آن تشکیل می‌شود:

$$y_{it} = \begin{pmatrix} IMF_{i1} \\ \vdots \\ IMF_{i5} \end{pmatrix} \cdot i = 1, \dots, m \quad (32)$$

که $m=3$ تعداد IMF های انتخاب شده است.

۳- روابط هم‌انباشتگی میان IMF های غیرایستا به کمک مفهوم هم‌انباشتگی و آزمون اثر جوهانسون به دست می‌آیند. با تعیین بردارهای هم‌انباشتگی $(\beta_1, \dots, \beta_r)$ ، ترکیب خطی مانا بین IMF های منتخب به صورت زیر محاسبه می‌شود:

$$u = B' * y_{it} = \begin{pmatrix} \beta'_1 y_{it} \\ \dots \\ \beta'_r y_{it} \end{pmatrix} = \begin{pmatrix} u_{i1} \\ \dots \\ u_{ir} \end{pmatrix} \quad (33)$$

۴- رابطه هم‌انباشتگی اول که دارای بیشترین رفتار ایستایی است، توسط روش تبدیل بسته‌ای موجک به ضرایب مختلفی تجزیه می‌شود. در این مطالعه مشابه $[Y]$ از موجک db44 برای تجزیه روابط هم‌انباشتگی ایستا تا سه سطح تجزیه استفاده شده است.

۵- از هر کدام از ضرایب موجک به دست آمده، ویژگی‌های آماری در حوزه زمان که در جدول ۱ ارائه شده‌اند، استخراج می‌شوند.

۶- ماتریس ویژگی بدین صورت است که سطرهای آن متناظر با سیگنال‌ها و ستون‌های آن متناظر با ویژگی‌ها می‌باشند. سپس، داده‌های مربوط به هر ستون به گونه‌ای نرمالیزه می‌شوند که مقادیر آن‌ها در بازه $[0, 1]$ قرار گیرند.

۷- هفتاد درصد از سیگنال‌ها به «داده‌های آموزش برای تخمین پارامترها» و مابقی به «داده‌های تست نهایی» اختصاص یافته داده می‌شوند.

می‌شود، هنگامی که پارامتر α دارای مقداری کم‌تر از ۰/۰۱ است، با وجود آن که روش پیشنهادی در مرحله آموزش دارای میانگین دقت ۱۰۰ درصد است، اما این تکنیک در مرحله‌ی تست نهایی دارای خطای قابل توجهی است؛ همچنین، به ازای مقادیر $\alpha < 0.05$ ، رویکرد پیشنهادی در هر دو مرحله‌ی آموزش و تست نهایی دارای خطای قابل توجهی است. در نهایت، با توجه به بخش بزرگنمایی شده در شکل ۶، هنگامی که پارامتر α در بازه‌ی [۰/۰۱، ۰/۰۵] قرار می‌گیرد، تکنیک پیشنهادی چه در مرحله‌ی آموزش و چه در مرحله‌ی تست نهایی دارای دقت ۱۰۰ درصد است. از این رو در این مطالعه مشابه [۹]، مقدار پارامتر α برابر با ۰/۰۱ در نظر گرفته شده است.

۵-۳- انتخاب مناسب‌ترین ویژگی‌ها

برای تشکیل ماتریس ویژگی، رابطه هم‌انباشتگی اول مربوط به سری‌های زمانی به دست آمده توسط تبدیل بسته‌ای موجک تا سه سطح (۱۴ ضریب) تجزیه می‌شود. از هر کدام از ضرایب موجک، ویژگی‌های آماری ارائه شده در جدول ۱ استخراج می‌شوند. در نهایت، بردار ویژگی متناظر با هر نمونه سیگنال دارای $(16 \times 14 \times 3)$ ویژگی است.

به کارگیری ماتریس ویژگی با ابعاد بالا به عنوان ورودی طبقه‌بندی کننده، باعث افزایش پیچیدگی محاسباتی و کاهش دقت پیش‌بینی عیب می‌شود. در این تحقیق، برای حذف ویژگی‌های زائد و غیرمرتبط از روش ارزیابی جبران فاصله استفاده شده است. معیار ارزیابی فاصله برای هر کدام از ویژگی‌ها محاسبه و مشابه [۸] با مقدار آستانه $\zeta = 0.5$ مقایسه می‌شود. ویژگی‌هایی که دارای امتیازی کم‌تر از مقدار آستانه $\zeta = 0.5$ هستند، حذف شده و بقیه به عنوان مجموعه ویژگی‌های اولیه انتخاب شده‌اند. در شکل ۷ معیار ارزیابی فاصله برای تمامی ویژگی‌ها برای رابطه هم‌انباشتگی اول ترسیم شده است. مقدار آستانه تعیین شده در این شکل به صورت خط چین مشخص شده است. تعداد ویژگی‌های پیشنهادی انتخاب شده برای روابط هم‌انباشتگی اول برابر با ۸۰ است؛ همچنین، مجموعه ویژگی بهینه به دست آمده توسط روش پیشنهادی دارای ۱۷ عضو است و با علامت «■» مشخص شده‌اند.

تعداد بیت‌های مربوط به پارامترهای C و σ به ترتیب ۸ و ۱۶ در نظر گرفته شده است [۹]. در نهایت تعداد متغیرهای تصمیم‌گیری در فرآیند بهینه‌سازی برابر $N_p + N_c + N_g$ است.

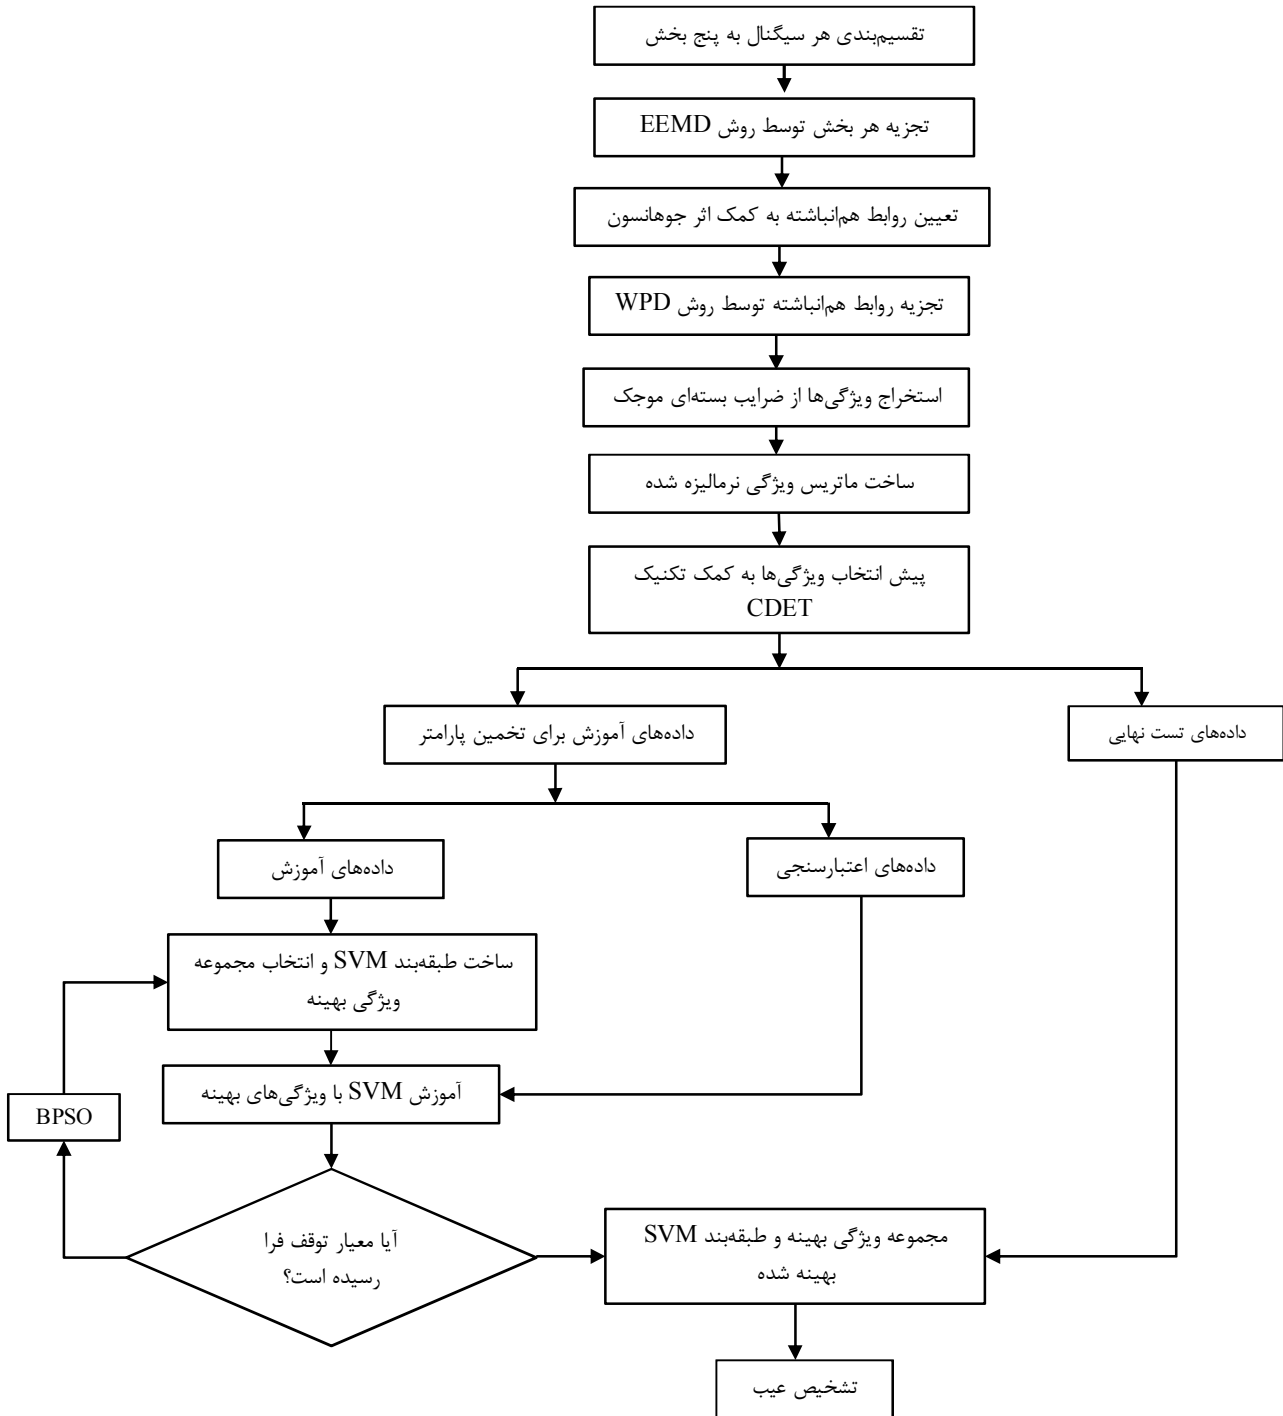
۵- نتایج

۵-۱- تعیین روابط هم‌انباشتگی


همان‌طور که در فلوچارت شکل ۳ دیده می‌شود، اولین گام روش پیشنهادی تقسیم‌بندی سیگنال‌ها و تجزیه آن‌ها به کمک روش EEMD است. برای نمونه، سه IMF اول سیگنال شکل ۲-ب در شکل ۴ ارائه شده‌اند. پس از تجزیه هر سیگنال، سری زمانی مربوط به آن به کمک سه IMF اول حاصل از تجزیه تشکیل می‌شود. از آنجایی که سیگنال‌های اکتساب شده در شرایط سرعت متغیر، غیرایستا هستند، بنابراین، سری زمانی مزبور غیرایستا است. در این مقاله، برای استخراج ترکیب خطی ایستا و هم‌انباشته از سری زمانی تشکیل شده، از مفهوم هم‌انباشتگی و آزمون اثر جوهانسون استفاده شده است. برای مثال، نتایج آزمون جوهانسون مربوط به سیگنال نمایش داده شده در شکل ۲-ب در جدول ۲ ارائه شده‌اند. جدول مزبور تعداد روابط ایستای قابل استخراج از IMF ها را نشان می‌دهد. r رتبه ماتریس مقادیر ویژه است که تعداد رابطه‌های هم‌انباشتگی را مشخص می‌کند. مقدار h که همواره مساوی یک است، فرضیه صفر را رد می‌کند؛ بنابراین، برای این سیگنال، چهار رابطه هم‌انباشتگی و ایستا وجود دارد. عبارت «P-Value» مقدار احتمال لازم برای رد کردن فرضیه صفر، عبارت Test «statistics» آماره آزمون، عبارت «C-Value» مقدار بحرانی و «Eigenvalue» مقدار ویژه در آزمون اثر جوهانسون را نشان می‌دهند. چهار رابطه هم‌انباشتگی به دست آمده برای IMF اول سیگنال معیوب شکل ۲-ب به در شکل ۵ نشان داده شده‌اند.

۵-۲- بررسی اثر تغییر پارامتر α بر دقت شناسایی عیب


اثر تغییر پارامتر α معرفی شده در تابع برازش رابطه‌ی ۳۴ بر میانگین دقت شناسایی عیب در هر دو مرحله‌ی آموزش و تست نهایی مورد بررسی قرار گرفته و نتایج آن در شکل ۶ نشان داده شده است. همان‌طور که در این شکل دیده



شکل ۳- فلوچارت روش عیب‌یابی پیشنهادی




شکل ۶- معیار ارزیابی فاصله برای همه ویژگی‌های استخراج شده از رابطه هم‌انباشتی اول



شکل ۷- معیار ارزیابی فاصله برای همه ویژگی‌های استخراج شده از رابطه هم‌انباشتی اول


از ۴۰ سیگنال ارتعاشی مورد استفاده در این مطالعه، از ۲۸ نمونه برای آموزش روش هوشمند پیشنهادی و انتخاب ویژگی‌های بهینه و از ۱۲ نمونه سیگنال باقی‌مانده برای ارزیابی این روش استفاده شده است. در فاز آموزش، از ۲۸ سیگنال، ۱۴ سیگنال برای ساخت شبکه SVM و ۱۴



شکل ۴- توابع مود ذاتی حاصل از تجزیه سیگنال شکل ۲-ب

جدول ۲- نتایج آزمون هم‌انباشتی برای سیگنال معیوب شکل ۳-الف

Eigenvalue	C- Value	Test statistics	P-Value	h	r
۰,۵۲۰۸	۶۰,۰۶۲۳	۲۱۳۶۷,۳۸۳	۰,۰۰۱	۱	۰
۰,۵۱۶۹	۴۰,۱۷۵۱	۱۶۹۵۴,۳۸۱۶	۰,۰۰۱	۱	۱
۰,۵۰۸۷	۲۴,۲۷۴۷	۱۲۵۹۰,۲۹۳۴	۰,۰۰۱	۱	۲
۰,۵۰۴۸	۱۲,۳۲۰۶	۸۳۲۶,۷۶۹۴	۰,۰۰۱	۱	۳
۰,۴۹۶۱	۴,۱۳۰۲	۴۱۱۱,۳۰۶۵	۰,۰۰۱	۱	۴



شکل ۵- چهار رابطه هم‌انباشتی برای IMF اول سیگنال معیوب در شکل ۲-ب

دو مرحله آموزش و تست نهایی در ترم‌های آماری «میانگین دقت پیش‌بینی عیب (mean)» و «انحراف معیار نتایج پیش‌بینی عیب (std)» به صورت عبارت $\text{mean} \pm \text{std}$ در جدول ۴ گزارش شده‌اند؛ همچنین، پارامترهای بهینه مربوط به الگوریتم SVM و ویژگی‌های بهینه در این جدول ارائه شده‌اند.

همان‌طور که در جدول ۴ دیده می‌شود، روش سوم چه در مرحله آموزش و چه در مرحله تست نهایی، دارای بیشترین خطا در شناسایی عیب است. عدم به کارگیری تبدیل بسته‌ای موجک در مرحله استخراج ویژگی، علت اصلی ضعف روش سوم است. اگر چه روش‌های اول و دوم در مرحله آموزش، وضعیت یاتاقان را به طور دقیق پیش‌بینی نموده‌اند، اما در مرحله تست نهایی دارای خطاهای پیش‌بینی قابل توجهی هستند. نتایج حاصل از روش‌های اول و دوم به ترتیب تاثیرگذاری روش انتخاب ارزیابی جبران فاصله و روش ترکیبی هم‌انباشتگی - تبدیل بسته‌ای موجک بر میزان دقت شناسایی عیب را نشان می‌دهند. نتایج جدول ۴ نشان می‌دهند که روش پیشنهادی چه در مرحله آموزش و چه در مرحله تست نهایی قادر است، وضعیت یاتاقان را حتی با عیب بسیار کوچک در شرایط سرعت متغیر به طور دقیق پیش‌بینی نماید. این نتیجه دلالت بر توانمندی روش هوشمند ترکیبی ارائه شده در این مقاله دارد.

همچنین در جدول ۴ می‌توان یافت که پاسخ‌های حاصل از روش دوم دارای بیشترین انحراف معیار هستند. به عبارت دیگر، پراکندگی پاسخ‌های به دست آمده توسط این روش نسبت به سایر روش‌ها بیشتر است؛ همچنین، پیش‌بینی داده‌ها توسط روش پیشنهادی، دارای کم‌ترین انحراف معیار نسبت به سایر روش‌هاست. این نتیجه نشان می‌دهد که روش ارائه شده در این مقاله، در اجزای مختلف دارای پایداری بسیار خوبی در پیش‌بینی وضعیت یک نمونه داده است. به عبارت دیگر، روش پیشنهادی در پیش‌بینی داده‌ها در مرحله اعتبارسنجی و تست نهایی در هر ۳۰ بار اجرای خود به طور دقیق عمل کرده است.

۶- نتیجه‌گیری

در این مقاله، روش ترکیبی جدیدی برای عیب‌یابی یاتاقان‌های دارای عیب بسیار کوچک در شرایط کاری سرعت متغیر

سیگنال برای تعیین پارامترهای بهینه SVM و تشکیل ماتریس ویژگی بهینه به‌کار گرفته شده‌اند. پس از تعیین ویژگی‌های اولیه، مجموعه ویژگی بهینه و پارامترهای SVM به کمک الگوریتم بهینه‌سازی BPSO به گونه‌ای تعیین شده‌اند که دقت پیش‌بینی عیب به بیشترین مقدار خود رسیده و ابعاد فضای ویژگی بهینه تا حد ممکن کمینه گردد.

۵-۴- مقایسه با روش‌های دیگر

برای مقایسه توانمندی روش انتخاب ویژگی و تشخیص عیب پیشنهاد شده در این مقاله با دیگر روش‌ها، از سه روشی استفاده شده است که در جدول ۳ تشریح شده‌اند.

در روش ۱ [۱۰]، مولفه‌ها و روابط هم‌انباشته مربوط به سیگنال‌های ارتعاشی به ترتیب به کمک روش‌های EEMD و آزمون اثر جوهانسون استخراج شده‌اند. ماتریس ویژگی به کمک ویژگی‌های آماری استخراج شده از ضرایب موجک تشکیل شده‌اند. مجموعه ویژگی بهینه و پارامترهای SVM، توسط روش BPSO تعیین شده‌اند. از این روش به منظور بررسی اثر به کارگیری تکنیک CDET در روش ارائه شده در این مقاله استفاده شده است.

مراحل عیب‌یابی در روش ۲ مشابه روش پیشنهاد شده در این مقاله است با این تفاوت که در این روش روابط هم‌انباشته و ضرایب موجک جهت تشکیل ماتریس ویژگی استخراج نمی‌شوند. در روش ۳، روابط هم‌انباشته میان IMF های هر سیگنال ارتعاشی به کمک روش ترکیبی تجزیه مود تجربی کلی و اثر جوهانسون استخراج شده‌اند. سپس، با استخراج ویژگی‌های آماری از روابط هم‌انباشته، ماتریس ویژگی تشکیل می‌شود. در مرحله بعد، مشابه روش پیشنهادی، از روش‌های CDET، BPSO و SVM برای تعیین مجموعه ویژگی بهینه و شناسایی عیب استفاده شده است. هدف از بررسی این روش، ارزیابی توانمندی تکنیک استخراج ویژگی از ضرایب موجک و اثر آن در شناسایی عیب در روش پیشنهادی است.

از آنجایی که الگوریتم‌های بهینه‌سازی دارای طبیعتی تصادفی هستند و در هر بار اجرای آن‌ها ممکن است پاسخ‌های به دست آمده متفاوت باشند، از این رو هرکدام از روش‌های ۱ تا ۳ و روش پیشنهادی در این مطالعه ۳۰ بار به اجرا در آمده‌اند. در نهایت، نتایج مربوط به دقت تشخیص عیب در

جدول ۳- توضیح روش‌ها

روش	تشریح روش
روش ۱ [۱۰]	تجزیه سیگنال به کمک EEMD + استخراج روابط هم‌انباشه + استخراج ویژگی‌های آماری از ضرایب WPD + تعیین ویژگی‌های بهینه از مجموعه ویژگی اصلی و پارمترهای بهینه SVM به کمک BPSO
روش ۲	تجزیه سیگنال به کمک EEMD + استخراج ویژگی‌های آماری از ضرایب WPD + پیش‌انتخاب ویژگی‌ها با الگوریتم CDET + تعیین ویژگی‌های بهینه از مجموعه ویژگی اصلی و پارمترهای بهینه SVM به کمک BPSO
روش ۳	تجزیه سیگنال به کمک EEMD استخراج روابط هم‌انباشه + استخراج ویژگی‌های آماری از روابط هم‌انباشته + پیش‌انتخاب ویژگی‌ها با الگوریتم CDET + تعیین ویژگی‌های بهینه از مجموعه ویژگی اصلی و پارمترهای بهینه SVM به کمک BPSO

جدول ۴- مقایسه کارایی روش پیشنهادی با دیگر روش‌ها

روش	پارامترهای بهینه	تعداد ویژگی‌های بهینه	میانگین دقت در مرحله آموزش	میانگین دقت در مرحله تست نهایی
روش پیشنهادی	C = 8.62 $\sigma = 87.71$	17	100±0.0	100±0.0
روش ۱	C = 13.33 $\sigma = 52.59$	269	100±0.0	87.5±0.0
روش ۲	C = 58.43 $\sigma = 111.10$	5	100±0.0	85.0±8.58
روش ۳	C = 74.11 $\sigma = 6.38$	6	75±0.0	82.22±5.24

ذرات باینری و ماشین بردار پشتیبان برای انتخاب مناسب-ترین مجموعه ویژگی و ساخت یک روش هوشمند به منظور شناسایی عیب استفاده شده است. نتایج نشان می‌دهند که مجموعه ویژگی بهینه حاصل از پیاده‌سازی روش پیشنهادی، قادر به تفکیک بهتر شرایط یاتاقان است، به طوری که با به کارگیری مجموعه ویژگی بهینه، ماشین بردار پشتیبان قادر است، شرایط یاتاقان را حتی در سرعت‌های متغیر به طور دقیق پیش‌بینی نماید؛ همچنین، مقایسه نتایج این مقاله با دیگر روش‌ها، توانمندی هر کدام از تکنیک‌های به کار گرفته شده در روش پیشنهادی را تایید می‌کند.

ارائه شده است. از آنجایی که سیگنال‌های ارتعاشی در شرایط مزبور دارای رفتاری غیرایستا هستند، از این رو از تکنیک ترکیبی روش تجزیه مود تجربی و اثر جوهانسون برای استخراج روابط ایستا استفاده شده است. سپس، به کمک ضرایب موجک استخراج شده از این روابط ایستا و ویژگی‌های آماری در حوزه زمان، ماتریس ویژگی تشکیل شده است. از آنجایی که این ماتریس ممکن است شامل ویژگی‌هایی زائد و غیرحساس به حضور عیب باشد، در این مطالعه از روش ارزیابی جبران فاصله برای حذف ویژگی‌های غیرمرتبط و زائد استفاده شده است. سرانجام، از الگوریتم بهینه‌سازی ازدحام

۶- تشکر و قدردانی

از جناب آقای دکتر علی‌اکبر تبریزی و همکاران از دانشگاه پلی‌تکنیک تورینو ایتالیا که داده‌های ارتعاشی مجموعه آزمایشگاهی گروه دینامیکی ماشین‌آلات و سازه‌های پیشرفته در گروه مهندسی مکانیک و هوافضا را در اختیار نویسندگان این مقاله قرار داده‌اند، کمال تشکر و قدردانی می‌شود.

۷- مراجع

- [10] Yin H, Qiao J, Fu P, Xia XY (2014) Face feature selection with binary particle swarm optimization and support vector machine. *J Inf Hiding Multimed Signal Process* 5(4): 731-739.
- [11] Tabrizi AA, Al-Bugharbee H, Trendafilova I, Garibaldi L (2017) A cointegration-based monitoring method for rolling bearings working in time-varying operational conditions. *Meccanica* 52(4-5): 1201-1217.
- [12] Huang W, Kong F, Zhao X (2018) Spur bevel gearbox fault diagnosis using wavelet packet transform and rough set theory. *J Intell Manuf* 29(6): 1257-1271.
- [13] Nezamivand Chegini S, Bagheri A, Najafi F (2019) A new intelligent fault diagnosis method for bearing in different speeds based on the FDAF-score algorithm, binary particle swarm optimization and support vector machine. *Soft Comput*.
- [۱۴] نظامیوندچگینی س، باقری ا، نجفی ف، (۱۳۹۸) روش ترکیبی هوشمند جدید برای عیب‌یابی یاتاقان بر پایه بهبود روش انتخاب ویژگی ارزیابی جبران فاصله و ماشین بردار پشتیبان. *مجله مهندسی مکانیک مدرس* ۱۹(۴): ۸۶۵-۸۷۵.
- [15] Yan X, Jia M (2018) A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing. *Neurocomputing* 313: 47-64.
- [16] Vakharia V, Gupta VK, Kankar PK (2016) Bearing fault diagnosis using feature ranking methods and fault identification algorithms. *Procedia Eng* 144: 343-350.
- [17] Attoui I, Fergani N, Boutasseta N, Oudjani B, Deliou A (2017) A new time-frequency method for identification and classification of ball bearing faults. *J Sound Vib* 397: 241-265.
- [18] Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, Yen NC, Tung CC, Liu HH (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc R Soc Lond A Math Phys Sci* 454 (1971): 903-995.
- [19] Wu Z, Huang N (2009) Ensemble empirical mode decomposition: a noise - assisted data analysis method. *Adv Adapt Data Anal* 1(1): 1-41.
- [20] Johansen S (1995) Likelihood-based inference in cointegrated vector autoregressive models. Oxford University Press, Oxford.
- [21] Dong S, Sun D, Tang B, Gao Z, Yu W, Xia M (2014) A fault diagnosis method for rotating machinery based on PCA and Morlet kernel SVM. *Math Probl Eng*.
- [1] Lei Y, Liu Z, Ouazri J, Lin J (2017) A fault diagnosis method of rolling element bearings based on CEEMDAN. *Proc Inst Mech Eng Pt C J Mechan Eng Sci* 231(10): 1804-1815.
- [2] Song M, Xiao S (2017) A fault diagnosis method of gear based on SVD and improved EEMD. In *Intelligent Computing, Networked Control, and Their Engineering Applications*, Springer, Singapore 65-74.
- [3] Xu F, Wai Tat TSE P, Fang YJ, Liang JQ (2018) A fault diagnosis method combined with compound multiscale permutation entropy and particle swarm optimization-support vector machine for roller bearings diagnosis. *Proc Inst Mech Eng J* 1350650118788929.
- [4] Tabrizi A, Garibaldi L, Fasana A, Marchesiello S (2015) Early damage detection of roller bearings using wavelet packet decomposition, ensemble empirical mode decomposition and support vector machine. *Meccanica* 50(3): 865-874.
- [۵] باقری ا، نظامیوند چگینی س، رضائی دشتیمان م، فرید نجفی (۱۳۹۷) عیب یابی چرخدنده بر پایه انتخاب مناسب ترین ویژگی به کمک الگوریتم بهینه سازی ازدحام ذرات. *مکانیک سازه‌ها و سازه‌ها* ۴۹-۶۴: ۸(۳).
- [6] Yang CY, Wu TY (2015) Diagnostics of gear deterioration using EEMD approach and PCA process. *Measurement* 61: 75-87.
- [7] 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.
- [8] Fatima S, Mohanty AR, Naikan VNA (2015) Multiple fault classification using support vector machine in a machinery fault simulator. In *Vibration Engineering and Technology of Machinery* 1021-1031.
- [9] 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.

- [24] Shi Y, Eberhart R (1998) A modified particle swarm optimizer. In: The 1998 IEEE International Conference on Evolutionary Computation Proceedings, Anchorage, AK 69-73.
- [25] Nezamivand Chegini S, Bagheri A, Najafi F (2018) PSOSCALF: A new hybrid PSO based on sine cosine algorithm and Levy flight for solving optimization problems. Appl Soft Comput.
- [22] Yaguo L, Zhengjia H, Yanyang Z, Xuefeng C (2008) New clustering algorithm-based fault diagnosis using compensation distance evaluation technique. Mech Syst Signal Pr 22: 419-435.
- [23] Vapnik V (1995) The nature of statistical learning theory. Springer Verlag, New York.