



## مقایسه‌ای بین تجزیه حالت تجربی و تبدیل موجک در تشخیص نابالانسی ماشین دوار با استفاده از ماشین بردار پشتیبان بهینه

محمد رهبر<sup>1</sup>، علی چائی بخش<sup>2\*</sup>

1- دانشجوی کارشناسی ارشد، مهندسی مکانیک، دانشگاه گیلان، رشت

2- استادیار، مهندسی مکانیک، دانشگاه گیلان، رشت

\* رشت، صندوق پستی 41635-3756، chaibakhsh@guilan.ac.ir

### اطلاعات مقاله

مقاله پژوهشی کامل

دریافت: 14 آبان 1395

پذیرش: 06 بهمن 1395

ارائه در سایت: 01 اسفند 1395

کلید واژگان:

پردازش سیگنال

تجزیه حالت تجربی

ماشین بردار پشتیبان

بهینه‌سازی ازدحام ذرات

ماشین دوار

### چکیده

در این پژوهش مقایسه‌ای بین روش‌های تجزیه حالت تجربی، تجزیه حالت تجربی دسته‌ای و تبدیل موجک گسسته با توابع موجک مادر میر و دابچی در تشخیص عیب نابالانسی ماشین دوار انجام شده است. جهت طبقه‌بندی و تفکیک کلاس سالم از نابالانسی ماشین دوار، از ماشین بردار پشتیبان بهینه شده با الگوریتم بهینه‌سازی ازدحام ذرات استفاده شده، همچنین مقایسه‌ای بین عملکرد ماشین بردار پشتیبان بهینه و غیربهینه نیز انجام شده است. به منظور تهیه داده‌های مورد نیاز ابتدا یک دستگاه شبیه‌ساز عیب در ماشین دوار ساخته، سپس سیگنال‌های ارتعاشی در دو حالت سالم و عیب نابالانسی، توسط سنسورهای شتاب اخذ شدند. پس از پردازش و تجزیه سیگنال‌ها به مؤلفه‌های فرکانسی آن‌ها، چند ویژگی آماری از هر مؤلفه فرکانسی استخراج و به‌عنوان ورودی ماشین بردار پشتیبان، جهت تفکیک کلاس‌ها از یکدیگر مورد استفاده قرار گرفت. نتایج حاصل نشان داد که روش تبدیل موجک گسسته با تابع موجک مادر میر، درصد موفقیت بالاتری در تشخیص عیب نابالانسی نسبت به سایر روش‌ها دارد.

## Comparison between empirical mode decomposition and wavelet transform for unbalance detection on rotating machinery using optimized support vector machine

Mohammad Rahbar<sup>1</sup>, Ali Chaibakhsh<sup>\*1</sup>

1- Department of Mechanical Engineering, University of Guilan, Rasht, Iran.

\* P.O.B. 41635-3756, Rasht, Iran, chaibakhsh@guilan.ac.ir

### ARTICLE INFORMATION

Original Research Paper

Received 04 November 2016

Accepted 25 January 2017

Available Online 19 February 2017

### Keywords:

Signal Processing

Empirical Mode Decomposition

Support Vector Machine

Particle Swarm Optimization

Rotating Machine

### ABSTRACT

In this study, fair comparisons between the empirical mode decomposition, ensemble empirical mode decomposition and discrete wavelet transform with the mother wavelet function of Meyer and Daubechies, were performed for detecting unbalance faults in a rotating machine. In order to classify the healthy class from the unbalance classes, a support vector machine that was optimized by particle swarm optimization algorithm was used. A comparison between the performances of optimized and non-optimized of support vector machines was also carried out. In order to obtain the required data, a rotating machinery fault simulator was developed and vibrational signals were acquired at healthy and unbalance fault conditions by accelerometer sensors. By processing the recorded signals and analysing signal to their frequency components, several statistical features were extracted from each frequency component as input support vector machine for the separation of classes. The obtained results indicated that the discrete wavelet transform with the Meyer mother wavelet obtained a higher success rate than other methods for diagnosing unbalance faults.

### 1- مقدمه

خسارات ناشی از آن جلوگیری کرده، هزینه‌های ناشی از تعمیرات و توقف تولید را به کمترین میزان خود برسانند. با این وجود امکان دارد عیوب مختلفی در ماشین‌آلات دوار رخ دهد. عیب نابالانسی یکی از مهم‌ترین و متداول‌ترین عیوب ماشین‌های دوار است [2]. با توجه به تعدد قطعات در ماشین‌های دوار جهت توسعه روش‌های عیب‌یابی به داده‌هایی از عیوب مختلف در شرایط کاری متفاوت نیاز است. تحلیل ارتعاشات یکی از متداول‌ترین روش‌های تشخیص عیب در ماشین دوار است. رشد هرگونه عیب مکانیکی در ماشین دوار سبب‌شده تا مشخصه‌های دینامیکی، سطح دامنه

ماشین‌های دوار به طور گسترده‌ای در صنعت به کار گرفته شده و از جمله تجهیزات کلیدی و مهم در بسیاری از صنایع به شمار می‌آیند. بروز هرگونه نقص در عملکرد ماشین دوار و گسترش آن سبب توقف خط تولید شده و می‌تواند خسارت‌های مالی زیادی را به همراه داشته باشد. عیب‌یابی به موقع ماشین‌های دوار می‌تواند از بروز بسیاری از حوادث و خسارت‌ها جلوگیری کند [1]. مهندسان و صاحبان صنایع همواره در پی راه‌کارهای مناسبی جهت تشخیص زودهنگام عیوب مختلف در تجهیزات دوار بوده‌اند تا از گسترش و

Please cite this article using:

M. Rahbar, A. Chaibakhsh, Comparison between empirical mode decomposition and wavelet transform for unbalance detection on rotating machinery using optimized support vector machine, *Modares Mechanical Engineering*, Vol. 17, No. 2, pp. 325-332, 2017 (in Persian)

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

پنجره‌بندی سیگنال‌ها مزیت اصلی تبدیل موجک بر سایر روش‌ها و همچنین برای سیگنال‌های غیرایستا مناسب است. از معایب روش تبدیل موجک می‌توان به عدم تشخیص فرکانس لحظه‌ای اشاره کرد. از جمله کاربردهای روش تبدیل موجک در عیب‌یابی بخش‌های مختلف ماشین دوار می‌توان به عیب‌یابی در روتورها [17]، چرخ‌دنده‌ها [18] و یاتاقان‌ها [19, 20] اشاره کرد. با توجه به این‌که عیب نابالانسی در ابتدا به صورت کوتاه و گذرا در سیگنال ظاهر می‌شود، در این پژوهش از روش‌های قدرتمند حوزه زمان-فرکانس جهت شناسایی زودهنگام این عیب استفاده شده است. در این راستا مقایسه‌ای میان روش‌های تجزیه حالت تجربی، تبدیل موجک گسسته و تجزیه حالت تجربی دسته‌ای در عیب‌یابی نابالانسی ماشین دوار نیز انجام شده است. با توجه به تفاوت میان کلاس‌های سالم و عیب نابالانسی، نیاز به تفکیک این دو کلاس از یکدیگر وجود خواهد داشت. برای این منظور از ماشین بردار پشتیبان بهینه‌شده با الگوریتم بهینه‌سازی ازدحام ذرات جهت طبقه‌بندی کلاس‌ها از یکدیگر استفاده شده است.

در بخش دوم تئوری روش‌های مورد استفاده در این پژوهش بیان شده است. توضیحاتی پیرامون دستگاه شبیه‌ساز عیب در ماشین دوار در بخش سوم قرار دارد. در بخش چهارم نحوه اخذ سیگنال و روش‌های مختلف پردازش سیگنال و نیز طبقه‌بندی کلاس سالم از نابالانسی با استفاده از روش ماشین بردار پشتیبان بهینه آمده است. در بخش پنجم نیز به تجزیه و تحلیل نتایج حاصل از این پژوهش پرداخته شده است. در بخش آخر هم نتایج و پیشنهادات آورده شده است.

## 2- تئوری‌ها و روش‌های پردازش سیگنال

تئوری تمامی روش‌های پردازش سیگنال مورد استفاده در این پژوهش و نیز تئوری ماشین بردار پشتیبان و الگوریتم بهینه‌سازی ازدحام ذرات در ادامه آورده خواهد شد.

### 2-1- تجزیه حالت تجربی

هر سیگنال با استفاده از روش تجزیه حالت تجربی به مجموعه‌ای از توابع تک مؤلفه‌ای به نام توابع حالت ذاتی تجزیه خواهد شد. یک تابع حالت ذاتی مشابه یک تابع هارمونیک است، با این تفاوت که مانند یک تابع هارمونیک دارای دامنه و بسامد ثابت نبوده و بسامدهای گوناگونی با دامنه‌های متفاوت دارد. در هر مرحله از تجزیه سیگنال به مؤلفه‌های فرکانسی آن ابتدا مؤلفه‌هایی با فرکانس بالا جدا و این روند تا آن‌جا ادامه پیدا کرده که در نهایت مؤلفه‌ای با کمترین فرکانس باقی بماند. برای در نظر گرفته شدن یک شکل موج به‌عنوان تابع حالت ذاتی باید دو شرط زیر را به صورت هم‌زمان داشته باشد [5].

- 1- تعداد اکسترمم‌ها و تعداد نقاط صفر آن با یکدیگر برابر بوده، و یا حداکثر به میزان یک عدد متفاوت باشند.
  - 2- مقدار متوسط پوش بالا و پایین منحنی در هر نقطه برابر با صفر باشد.
- توابع حالت ذاتی به صورت مراحل زیر از یک سری زمانی به دست خواهد آمد.
- 1- تعیین نقاط بیشینه و کمینه محلی سیگنال ورودی
  - 2- به دست آوردن پوش بالای منحنی از طریق وصل کردن نقاط بیشینه محلی سری زمانی به یکدیگر و تکرار این عمل با نقاط کمینه محلی جهت ایجاد پوش پایین منحنی
  - 3- محاسبه میانگین پوش بالا و پایین منحنی

ارتعاشات و طیف فرکانسی ماشین تغییر کند. با این حال بسیاری از اطلاعات مفید به صورت محتوای پنهان در سیگنال‌ها بوده و به آسانی قابل مشاهده نیستند. هدف از پردازش سیگنال به دست آوردن اطلاعات مهم غیرقابل استخراج از سیگنال اولیه است. برای این منظور می‌توان از پردازش سیگنال در سه حوزه زمان، فرکانس و زمان-فرکانس بهره برد که هر یک دارای معایب و مزایای خاصی است. روش‌های حوزه زمان به دلیل شفافیت زمانی و سادگی همچنان مورد توجه بوده، ولی نمی‌توانند به تنهایی تمامی اطلاعات سودمند سیگنال را در اختیار کاربر قرار دهند. به دلیل آن‌که بیشتر عیوب مکانیکی ویژگی‌های خود را به صورت فرکانس‌های غالب نشان می‌دهند، روش‌های حوزه فرکانس می‌توانند اطلاعات مفیدی را در اختیار قرار داده و نسبت به روش‌های حوزه زمان برتری بیشتری دارند. روش تبدیل فوریه سریع یکی از روش‌های مهم حوزه فرکانس است. با وجود کارایی قابل توجه این روش می‌توان به معایبی چون ناتوانی در پردازش سیگنال‌های ناپایدار و گذرا و همچنین نداشتن شفافیت زمانی اشاره کرد [3].

پارامترهای حوزه فرکانس معمولاً در فرآیندهای عیب‌یابی نسبت به حوزه زمان موثرتر هستند. با این وجود اتکا بر یکی از این دو حوزه ممکن است چندان قابل اطمینان نباشد. به دلیل تغییرات سیگنال‌های ارتعاشی ماشین‌های دوار و غیرایستا بودن آن‌ها نمی‌توان از تفسیر اطلاعات زمانی یا فرکانسی آن‌ها به خوبی برای تعیین نوع، محل و زمان عیب بهره جست. در پاره‌ای از مواقع این تغییرات به گونه‌ای بوده که نیاز به پردازش‌های غیرخطی نیز وجود خواهد داشت. از جمله مزایای پردازش سیگنال در حوزه زمان-فرکانس می‌توان به دسترسی هم‌زمان به اطلاعات فرکانسی و زمانی یک سیگنال، توانایی پردازش سیگنال‌های ناپایدار، امکان دسترسی به باندهای فرکانسی مختلف و توانایی تشخیص بخش‌های فرکانس بالای زودگذر اشاره کرد [4].

روش تجزیه حالت تجربی<sup>1</sup> از مهم‌ترین روش‌های پردازش سیگنال در حوزه زمان-فرکانس بوده که توسط هوانگ و همکاران (1998) معرفی و مورد مطالعه بسیار قرار گرفت [5]. با اعمال این روش می‌توان هر سیگنال را به تعدادی تابع حالت ذاتی<sup>2</sup> تجزیه و از آن‌ها در پردازش سیگنال‌های غیرخطی و غیرثابت استفاده کرد. امکان تعیین فرکانس لحظه‌ای سیگنال ترکیب این روش با تبدیل هیلبرت از جمله مزایای روش تجزیه حالت تجربی است. این روش در عیب‌یابی بخش‌های مختلف ماشین دوار مانند عیب‌یابی چرخ‌دنده‌ها [6]، عیب‌یابی یاتاقان‌ها [7, 8] و عیب‌یابی روتور [9] به کار گرفته می‌شود. اگرچه روش تجزیه حالت تجربی یکی از قوی‌ترین روش‌های پردازش سیگنال است، ولی مشکلاتی چون پدیده اختلاط حالت‌ها و نداشتن معیار توقف قوی در فرآیند غربال را داراست. فلاندرین و همکاران (2005) جهت رفع برخی از مشکلات روش تجزیه حالت تجربی پیشنهاد افزودن نویز سفید را مطرح کردند [10]. هوانگ و همکاران (2009) روش تجزیه حالت تجربی دسته‌ای<sup>3</sup> را جهت رفع مشکل اختلاط حالت‌ها معرفی کردند [11]. از این روش نیز به طور گسترده‌ای در عیب‌یابی بخش‌های مختلف ماشین‌های دوار استفاده می‌شود که از جمله آن می‌توان به عیب‌یابی یاتاقان‌ها [12, 13]، عیب‌یابی روتورها [14] و عیب‌یابی چرخ‌دنده‌ها [15] اشاره کرد. تبدیل موجک<sup>4</sup> از دیگر روش‌های پردازش سیگنال در حوزه زمان-فرکانس و توسط مالات (1989) معرفی و بسیار مورد مطالعه قرار گرفته است [16]. نابرابری طول پنجره‌ها در

<sup>1</sup> Empirical Mode Decomposition

<sup>2</sup> Intrinsic Mode Functions

<sup>3</sup> Ensemble Empirical Mode Decomposition

<sup>4</sup> Wavelet Transform

$$x_j(t) = x(t) + D(t) \quad j = 1.2. \dots M \quad (5)$$

در آن  $M$  تعداد از پیش تعیین شده تلاش‌ها و  $D$  دامنه نویز سفید اضافه شده است.

2- داده همراه با نویز اضافه شده به روش تجزیه حالت تجربی به توابع حالت ذاتی به صورت رابطه (6) تجزیه می‌شود.

$$x_j(t) = \sum_{i=1}^{N_j} c_{ij} + u_{N_j} \quad (6)$$

که در آن نشان‌دهنده  $c_{ij}$  نشان‌دهنده  $i$ مین تابع حالت ذاتی از  $N_j$  زمین تلاش است،  $u_{N_j}$  نشان‌دهنده باقی‌مانده از تلاش  $N_j$  و  $N_j$  تعداد توابع حالت ذاتی تلاش  $N_j$  است.

3- مرحله اول و دوم چندین بار با نویزهای سفید مختلف تکرار خواهد شد.

4- میانگین توابع حالت ذاتی هم شماره از مرحله سوم محاسبه شده به‌عنوان توابع حالت ذاتی نهایی به صورت رابطه (7) در نظر گرفته می‌شود.

$$C_i(t) = \frac{1}{M} \left( \sum_{j=1}^M c_{ij} \right) \quad i = 1.2. \dots I \quad (7)$$

در آن  $I$  حداقل تعداد توابع حال ذاتی در میان همه تلاش‌هاست.

تعداد تلاش‌های دسته و دامنه نویز اضافه شده، دو پارامتر تعیین‌کننده در عملکرد روش تجزیه حالت تجربی دسته‌ای است. برای این که تجزیه حالت تجربی دسته‌ای به خوبی عمل کند دامنه نویز اضافه شده باید خیلی کوچک انتخاب نشود. هوانگ و همکاران [11] در بسیاری از موارد مقدار دامنه نویز اضافه شده را 0.2 انحراف معیار از داده‌ها در نظر گرفته‌اند. ژوو و همکاران [21] پس از بارها آزمایش با مقادیر مختلف این دو پارامتر و هنگام در نظر گرفتن تعداد 100 تلاش‌های دسته و 0.2 دامنه نویز اضافه شده به نتایج رضایت‌بخشی دست یافتند. به این دلیل در این پژوهش نیز دو پارامتر دامنه نویز اضافه شده و تعداد تلاش‌های دسته به ترتیب 0.2 و 100 در نظر گرفته شده است.

### 2-3- تبدیل موجک

به طور کلی تبدیلات موجک به دو دسته اصلی تبدیل موجک گسسته<sup>1</sup> و تبدیل موجک پیوسته<sup>2</sup> تقسیم‌بندی می‌شوند. سیگنال در تبدیل موجک به نمونه‌های کوچک یا بزرگ شده موجک مادر شکسته می‌شود. برخلاف تبدیل فوریه که از موج سینوسی استفاده می‌کند، در تبدیل موجک از توابع موجک مادر با شکل نامنظم استفاده می‌شود که همین امر سبب شده است تا بتوان سیگنال‌هایی با تغییرات سریع را راحت‌تر تحلیل کرد [22]. با توجه به این که در چند مرجع از توابع موجک مادر خانواده میر و دابچی در عیب‌یابی ماشین دوار استفاده شده بود [24,23]، در این پژوهش نیز از توابع موجک مادر میر و دابچی 10 استفاده شده است.

تبدیل موجک پیوسته سیگنال ورودی  $x(t)$  به صورت رابطه (8) تعریف می‌شود.

$$CWT(s, z) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-z}{s}\right) dt \quad (8)$$

در آن  $s$  و  $z$  به ترتیب پارامترهای مقیاس و انتقال،  $\psi(t)$  نیز تابع موجک مادر است.

در این پژوهش از تبدیل موجک گسسته استفاده شده که به صورت رابطه (9) بیان می‌شود.

4- تفریق میانگین پوش بالا و پایین از سیگنال ورودی و تولید نخستین مؤلفه سیگنال به صورت رابطه (1)

$$h_1(t) = x(t) - m_1(t) \quad (1)$$

در آن  $m_1(t)$  میانگین پوش بالا و پایین منحنی،  $h_1(t)$  نخستین مؤلفه سیگنال و  $x(t)$  سیگنال ورودی است.

5- اگر  $h_1(t)$  هر دو شرط تابع حالت ذاتی را به صورت هم‌زمان داشته به‌عنوان اولین تابع حالت ذاتی سیگنال شناخته می‌شود، در غیر این صورت  $h_1(t)$  به‌عنوان تابع اصلی فرض و مراحل یک تا چهار بر آن تکرار شده تا  $h_{11}(t)$  به صورت رابطه (2) تعریف شود.

$$h_{11}(t) = h_1(t) - m_{11}(t) \quad (2)$$

6- مرحله پنجم  $k$  مرتبه تکرار شده تا زمانی که  $h_{1k}(t)$  هر دو شرط مربوط به تابع حالت ذاتی را داشته باشد. در این صورت  $c_1 = h_{1k}$  به‌عنوان اولین تابع حالت ذاتی در نظر گرفته می‌شود.

7- جدا کردن اولین تابع حالت ذاتی را از سیگنال  $x(t)$  و به‌دست‌آوردن اولین باقی‌مانده  $u_1$  به صورت رابطه (3).

$$u_1(t) = x(t) - c_1(t) \quad (3)$$

8- در نظر گرفتن سیگنال  $u_1(t)$  به‌عنوان سیگنال اصلی و تکرار مراحل اول تا هفتم جهت به‌دست‌آوردن دومین تابع حالت ذاتی.

مراحل بالا  $n$  بار تکرار شده تا  $n$  تابع حالت ذاتی به‌دست آید. این الگوریتم زمانی متوقف می‌شود که  $u_n(t)$  هر سیگنال تک فرکانسی شده، مؤلفه فرکانسی قابل استخراج دیگری نداشته باشد. سیگنال  $x(t)$  با اتمام عملیات غربال‌گری به صورت رابطه (4) تجزیه می‌شود.

$$x(t) = \sum_{i=1}^n c_i + u_n \quad (4)$$

### 2-2- تجزیه حالت تجربی دسته‌ای

اختلاط حالت‌ها شاید رایج ترین مسأله‌ای باشد که هنگام کار با الگوریتم تجزیه حالت تجربی با آن مواجه خواهید شد. یک سیگنال خاص ممکن است هر بار به توابع حالت ذاتی یکسانی جداسازی نشود. این مشکل کار را برای استخراج ویژگی، آموزش مدل و تشخیص الگو سخت می‌کند. روش تجزیه حالت تجربی قادر به جداسازی حالت‌ها با فاصله فرکانسی و دامنه مشخصی است. برای نمونه فرکانس تابع حالت ذاتی دوم در دامنه برابر، حداکثر می‌تواند حدود نصف فرکانس تابع حالت ذاتی اول باشد. روش تجزیه حالت تجربی دسته‌ای با ایده اضافه کردن نویز سفید در تمام مراحل تجزیه سیگنال برای حل این مشکل معرفی شد. این کار پدیده اختلاط حالت‌ها را به طور مؤثری از بین خواهد برد. همه داده‌ها تقریباً آغشته به نویز است. در مواردی که داده‌ها از مشاهدات جداگانه‌ای به‌دست می‌آید که خود آغشته به نویزهای مختلفی است، روش میانگین دسته جهت بهبود دقت اندازه‌گیری به خوبی عمل می‌کند و یک روش قدرتمند تجربی به حساب می‌آید. نویز جهت عمومیت بخشیدن به این ایده بارها و بارها به سیگنال‌های ورودی اضافه می‌شود. هرچند امکان دارد اضافه کردن نویز منجر به نسبت کمتر سیگنال به نویز شود، ولی نویز سفید اضافه شده می‌تواند با توزیع یکنواخت به طور مؤثری فرآیند تجزیه به روش تجزیه حالت تجربی را تسهیل بخشد. مقادیر کم نسبت سیگنال به نویز تأثیری بر روش تجزیه ندارد، بلکه به طور قابل ملاحظه‌ای پدیده اختلاط حالت‌ها را از بین می‌برد [11].

روش تجزیه حالت تجربی دسته‌ای را می‌توان در مراحل زیر بیان کرد:

1- نویز سفید به صورت رابطه (5) به داده اضافه می‌شود.

<sup>1</sup> Discrete Wavelet Transform

<sup>2</sup> Continuous Wavelet Transform

توسط تبدیل  $\phi(x)$  که داده‌ها را از فضای ورودی  $N$  بعدی به فضای  $Q$  بعدی نگاشت می‌کند، به صورت رابطه (10) انجام می‌شود.

$$s = \phi(x) \quad s \in \mathbb{R}^Q, x \in \mathbb{R}^N \quad (10)$$

انتقال به فضایی با ابعاد بالاتر سبب افزایش محاسبات خواهد شد. از توابع کرنل برای حل این مشکل استفاده می‌شود.

تابع کرنل  $k(x,y)$  به صورت رابطه (11) تعریف می‌شود.

$$k(x,y) = \phi(x)\phi(y) \quad (11)$$

انتخاب تابع کرنل از اهمیت بالایی برخوردار است و کارایی ماشین بردار پشتیبان را تحت تأثیر قرار می‌دهد. از انواع توابع کرنل می‌توان به خطی<sup>5</sup>، چندجمله‌ای<sup>6</sup> و تابع پایه شعاعی گاوسی<sup>7</sup> اشاره کرد. در این پژوهش از تابع کرنل پایه شعاعی گاوسی استفاده شده که به صورت رابطه (12) است.

$$k(x,y) = \frac{-|x-y|^2}{2\sigma^2} \quad (12)$$

ماشین بردار پشتیبان حاشیه سخت اجازه هیچ‌گونه تخطی را به داده‌ها نداده، در حالی که در بیشتر مواقع تعدادی داده پرت وجود خواهد داشت که از مرز خود تخطی و تفکیک کامل را غیرممکن ساخته‌اند. برای حل این مشکل از پارامتر تخطی  $\xi_i$  و نیز پارامتر جریمه  $C$  استفاده می‌شود. این روش ماشین بردار پشتیبان حاشیه نرم نامیده می‌شود.

حاشیه به صورت رابطه (13) تعریف می‌شود.

$$\text{margin} = \frac{2}{\|w\|^2} \quad (13)$$

مسئله بهینه‌سازی به صورت رابطه (14) است.

$$\min(0.5 \|w\|^2 + C \sum_{i=1}^N \xi_i) \quad (14)$$

به شرطی که رابطه (15) برقرار باشد.

$$y_i (w \cdot x) + b \geq 1 - \xi_i \quad \xi_i \geq 0 \quad (15)$$

در آن  $w$  و  $b$  بردارهای اسکالر برای تعیین موقعیت ابرصفحه استفاده می‌شوند، همچنین  $\xi_i$  فاصله بین ابرصفحه و داده‌های قرار گرفته که در سمت اشتباه نسبت به ابرصفحه است. با استفاده از روش لاگرانژ و حل مسئله بهینه‌سازی، تابع تصمیم‌گیری غیرخطی به صورت رابطه (16) به دست خواهد آمد.

$$f(x) = \text{sign} \left( \sum_{i=1}^N y_i a_i k(x_i, x_j) + b \right) \quad (16)$$

## 5-2- الگوریتم بهینه‌سازی ازدحام ذرات

الگوریتم بهینه‌سازی ازدحام ذرات توسط کندی (1995) جهت مدل کردن حرکت جمعی پرندگان و یا انواع ماهیان پیشنهاد شد [26]. ذرات در این الگوریتم در فضای جستجو پخش شده، هر ذره تحت تأثیر تجربه و دانش خود و همسایگانش تغییر مکان خواهد داد. به این دلیل موقعیت سایر ذرات، بر چگونگی جستجوی یک ذره اثر خواهد گذاشت. ذرات از یکدیگر تعلیم یافته و براساس تجربه به دست آمده به سمت بهترین همسایگان خود تغییر مکان می‌دهند. هر ذره در این الگوریتم مکان خود را هر لحظه در فضای جستجو براساس بهترین مکانی که آن را تجربه کرده و نیز بهترین مکان موجود در کل همسایگی خود تنظیم خواهد کرد [27].

هر ذره با دو پارامتر  $v_i(t)$  و  $X_i(t)$  تعریف خواهد شد که به ترتیب معرف وضعیت مکانی و سرعتی مربوط به ذره نام است. موقعیت هر ذره در زمان‌های

$$\text{DWT}(j, k) = \frac{1}{\sqrt{2^j}} \int_{-\infty}^{+\infty} x(t) \psi\left(\frac{t-2^j k}{2^j}\right) dt \quad (9)$$

در آن  $2^j k$  و  $2^j$  به ترتیب جایگزین پارامترهای  $s$  و  $z$  و  $j$  یک عدد صحیح است.

تجزیه سیگنال توسط تبدیل موجک گسسته با استفاده از دو فیلتر بالاگذر و پایین‌گذر صورت می‌پذیرد. هر سیگنال با استفاده از این روش به دو بخش فرکانس بالا (جزئیات<sup>1</sup>) و فرکانس پایین (تقریب<sup>2</sup>) تقسیم می‌شود. جزئیات، بخش‌های فرکانس بالای سیگنال را شامل و تقریب، رفتار و شکل کلی سیگنال را دنبال می‌کند. تجزیه سیگنال می‌تواند به صورت اختیاری تا چندین مرحله ادامه یابد. سیگنال تقریب قبلی در هر مرحله تجزیه دوباره به دو سیگنال تقریب و جزئیات تجزیه می‌شود. در این پژوهش تعداد پنج مرحله تجزیه تبدیل موجک جهت مقایسه‌ای بین روش‌های تبدیل موجک و تجزیه حالت تجربی در نظر گرفته شده است. در روش‌های تجزیه حالت تجربی و تجزیه حالت تجربی دسته‌ای نیز پنج تابع حالت ذاتی اول انتخاب شده است.

## 4-2- ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از روش‌های یادگیری نظارت شده بوده که توسط وپنیک (1992) معرفی شده که یکی از قدرتمندترین روش‌های طبقه‌بندی داده است [25]. در این روش جهت طبقه‌بندی کردن کلاس‌ها از یک ابرصفحه<sup>3</sup> بین دو دسته از داده‌ها استفاده می‌شود. این ابرصفحه به کمک تعدادی بردار پشتیبان تعریف می‌شود. هدف ماشین بردار پشتیبان تعیین و ایجاد مرزی بین دو گروه مختلف از داده‌ها به گونه‌ای که حاشیه<sup>4</sup> بین این دو گروه بیشینه شود. این مرز در وسط حاشیه بین دو گروه قرار خواهد گرفت. نزدیک‌ترین نقاط داده‌ای که برای تعریف حاشیه استفاده شده‌اند، بردارهای پشتیبان نامیده می‌شوند. نمونه‌ای از یک ابرصفحه بهینه بین دو مجموعه کلاس مثبت و منفی در شکل 1 نشان داده شده است. هر بار با اضافه شدن داده جدید به این کلاس‌بندی، باتوجه به موقعیت نسبی آن به ابرصفحه، طبقه‌بندی انجام و کلاس آن مشخص خواهد شد.

در مواردی که مرز خطی در فضای ورودی برای تفکیک دو کلاس مناسب نباشد می‌توان ابرصفحه‌ای ایجاد کرد که امکان جداسازی خطی و غیرخطی را در ابعاد بالاتر فراهم می‌کند. در ماشین بردار پشتیبان این کار




Fig. 1 Data classification using support vector machine.

شکل 1 طبقه‌بندی داده‌ها با استفاده از ماشین بردار پشتیبان

<sup>1</sup> Details  
<sup>2</sup> Approximations  
<sup>3</sup> Hyperplane  
<sup>4</sup> Margin

<sup>5</sup> Linear

<sup>6</sup> Polynomial

<sup>7</sup> Gaussian Radial Basis Function



Fig. 2 Rotating machinery fault simulator device overview

شکل 2 نمای کلی دستگاه شبیه‌ساز خطا ماشین دوار




Fig. 3 Sensors and disks installation

شکل 3 نحوه نصب سنسورها و دیسک‌ها

موتور، 2 کلاس و تقسیم کردن هر سیگنال به 5 بخش و در نهایت 180=6×3×2×5 سیگنال به دست خواهد آمد. از 60% داده‌ها جهت فرآیند آموزش ماشین بردار پشتیبان و از 40% باقی مانده‌ها جهت تست ماشین بردار پشتیبان استفاده شده است.

هر یک از روش‌های تجزیه حالت تجربی، تجزیه حالت تجربی دسته‌ای و تبدیل موجک گسسته با توابع موجک مادر دابچی 10 و میر، بر هریک از این 180 بخش جهت پردازش سیگنال اعمال می‌شوند. سیگنال پس از اعمال دو روش تجزیه حالت تجربی و تجزیه حالت تجربی دسته‌ای به تعدادی توابع حالت ذاتی تجزیه می‌شود. با توجه به این‌که عیوب ریز و کوچک خود را در فرکانس‌های بالا نمایش می‌دهند، از پنج تابع حالت ذاتی اول جهت استخراج ویژگی استفاده شده است. با اعمال تبدیل موجک گسسته نیز سیگنال به تعداد جزئیات مورد نظر ما تجزیه می‌شود. جهت قابل مقایسه شدن روش‌های تبدیل موجک گسسته با تجزیه حالت تجربی و تجزیه حالت تجربی دسته‌ای، تعداد مراحل تجزیه به روش تبدیل موجک گسسته، پنج سطح در نظر گرفته شده است. در این روش نیز ابتدا فرکانس‌های بالا استخراج شده و به تدریج فرکانس‌ها کاهش یافته، از این جهت توانسته قابل مقایسه با روش‌های یادشده شود. پنج جزئیات اول به دست آمده از روش تبدیل موجک گسسته که حاوی فرکانس‌های بالاست جهت استخراج ویژگی در نظر گرفته می‌شوند. از سیگنال تقریب جهت قابل قیاس شدن با سایر روش‌ها صرف نظر شده است. پنج تابع حالت ذاتی اول و پنج سطح جزئیات حاصل از تجزیه به روش تبدیل موجک گسسته حاوی فرکانس‌های غالب مهم و اطلاعات مفید بوده و جهت استخراج ویژگی انتخاب می‌شوند.

نمونه‌ای از تجزیه سیگنال به پنج تابع حالت ذاتی توسط روش‌های تجزیه حالت تجربی و تجزیه حالت تجربی دسته‌ای به ترتیب در شکل‌های 4 و 5، همچنین نمونه‌ای از تجزیه سیگنال به روش تبدیل موجک گسسته به

بعدی بر مبنای دانش خود آن ذره و همسایگانش تعیین خواهد شد. موقعیت بعدی ذره از جمع موقعیت کنونی ذره با سرعت آن به دست خواهد آمد. نتیجه تجربه اجتماعی همسایگان و تجربه فردی هر ذره در بردار سرعت تأثیرگذار خواهد بود. هر ذره سرعت خود را به صورت ترکیب خطی تجربه شخصی و تجربیات همسایگان خود به روزرسانی خواهد کرد. بهترین موقعیتی که ذره تا آن لحظه به آن دست یافته و  $X_{gbest}$  نیز بهترین موقعیتی که تمامی ذرات به آن دست یافته‌اند. هر ذره برای این‌که به بهترین پاسخ ممکن برسد موقعیت خود را به صورت رابطه (17) تغییر خواهد داد:

$$v_i(t+1) = qv_i(t) + e_1 r_1 (X_{pbest}(t) - X_i(t)) + e_2 r_2 (X_{gbest}(t) - X_i(t)) \quad (17)$$

در آن  $e_1$  و  $e_2$  ضرایب شتاب، این ضرایب ثابت‌های مثبتی است که برای وزن‌دهی اجزای خودی و جمعی استفاده می‌شود.  $t$  بیان‌کننده شماره تکرار،  $r_1$  و  $r_2$  اعداد تصادفی که توزیع آن‌ها بین صفر و یک و  $q$  پارامتر وزن اینرسی است.

موقعیت جدید هر ذره از مجموع موقعیت گذشته و سرعت جدید آن ذره براساس رابطه (18) به دست خواهد آمد.

$$X_i(t+1) = X_i(t) + v_i(t+1) \quad (18)$$

### 3- طراحی و ساخت ماشین دوار

جهت اخذ سیگنال‌های ارتعاشی در شرایط سالم کاری و نابلانسی به طراحی و ساخت یک دستگاه شبیه‌ساز عیب در ماشین دوار پرداخته شد. در این دستگاه از سه یاتاقان غلتشی با قطر 15 mm و در این پژوهش از شش سنسور شتاب‌سنج پیزوالکتریک استفاده شده است. دو سنسور به صورت افقی و عمودی بر هر یاتاقان نصب شده است. الکتروموتور مورد استفاده در این پژوهش از نوع سه فاز بدنه آلومینیومی تک دور، ولتاژ نامی 380 ولت، قدرت خروجی 0.5 HP (0.37 kW)، روتور قفس سنجایی و فرکانس کار 50 Hz است. دستگاه ثبت‌کننده داده 16 کاناله جهت ثبت و ذخیره سیگنال‌های ارتعاشی اخذشده توسط سنسورها به کار گرفته شده است. این دستگاه قابلیت 150 هزار نمونه‌برداری در ثانیه را داراست. سه دیسک از جنس آلومینیوم به قطرهای 14، 15 و 17 سانتی‌متر میان یاتاقان‌ها قرار داده شده است. سوراخ‌هایی بر این دیسک‌ها تعبیه شده که با اتصال پیچ و مهره به آن‌ها بتوان عیب نابلانسی را ایجاد کرد. در این دستگاه از پیچ و مهره‌ای به وزن 35 گرم بر دیسک 17cm مابین یاتاقان غلتشی اول و دوم استفاده شده است. جهت تغییر دور موتور نیز از اینورتر سه فاز 220V استفاده شده است. در شکل 2 نمای کلی دستگاه شبیه‌ساز عیب در ماشین‌های دوار آورده شده است. موتور، دیسک‌ها، اینورتر و نیز نحوه نصب سنسورها بر یاتاقان‌های غلتشی در شکل 3 نمایش داده شده است.

### 4- انجام آزمایش و پردازش سیگنال

ابتدا سیگنال‌های ارتعاشی در شرایط سالم از دستگاه شبیه‌ساز عیب ماشین دوار گرفته شد، سپس با اتصال پیچ و مهره به دیسک اول، عیب نابلانسی ایجاد و در این شرایط نیز سیگنال‌ها توسط شش سنسور شتاب‌سنج و دیتالاگر ثبت و ضبط شدند. سیگنال‌های ارتعاشی در سه دور موتور 600، 1200 و 1500 RPM و با فرکانس نمونه‌برداری 5kHz اخذ شده‌اند. هر یک از سیگنال‌ها در مدت زمان دو ثانیه اخذ شده و شامل 10000 نقاط داده است. به دلیل زمان‌بر بودن پردازش این مقدار نقاط داده، هر سیگنال به پنج بخش 2000 نقاط داده‌ای تقسیم شده است. با توجه به داشتن 6 سنسور، 3 دور




Fig. 6 Decomposition of vibration signal with Meyer mother wavelet.

شکل 6 تجزیه سیگنال ارتعاشی با موجک مادر میپر




Fig. 7 Decomposition of vibration signal with db10 mother wavelet.

شکل 7 تجزیه سیگنال ارتعاشی با موجک مادر دابچی 10

بازه بهینه‌سازی به صورت  $1 \leq C \leq 100$  و  $0.01 \leq \sigma \leq 5$  در نظر گرفته شده است. در این بازه‌ها چندین بار الگوریتم بهینه‌سازی ازدحام ذرات اعمال و بیشترین درصد موفقیت با کمترین تعداد بردار پشتیبان به‌عنوان هدف نهایی در نظر گرفته شده است.

هر چه تعداد بردارهای پشتیبان کمتر باشد قدرت تفکیک‌پذیری کلاس‌ها از یکدیگر بیشتر خواهد شد. نتایج حاصل از آن در جدول 1 و نتایج ماشین بردار پشتیبان غیربهینه نیز در جدول 2 گزارش شده است. به دلیل آن‌که از هر پنج مؤلفه فرکانسی حاصل از تجزیه پنج ویژگی آماری استخراج شده تعداد ویژگی‌های ماشین بردار پشتیبان 25 مورد است. با توجه به این‌که 180 سیگنال به‌دست آمده است، پس در هر دور موتور 60 سیگنال مورد استفاده قرار خواهد گرفت. 60٪ این داده‌ها (36 نمونه) جهت آموزش شبکه و 40٪ باقی‌مانده داده‌ها (24 نمونه) برای آزمایش ماشین بردار پشتیبان استفاده می‌شود؛ بنابراین ماتریس ورودی جهت آموزش ماشین بردار پشتیبان به صورت  $36 \times 25$  و ماتریس ورودی جهت آزمایش ماشین بردار پشتیبان به صورت  $24 \times 25$  است.

### 5- بررسی نتایج

درصد موفقیت تشخیص صحیح کلاس سالم از نابالانسی با استفاده از روش ماشین بردار پشتیبان در جدول 1 آورده شده است. نتایج حاکی از آن است که تبدیل موجک گسسته با تابع موجک مادر میپر نسبت به سایر روش‌های پردازش سیگنال مورد استفاده در این پروژه به درصدهای موفقیت بالاتر و




Fig. 4 Decomposition of vibration signal with EMD method

شکل 4 تجزیه سیگنال ارتعاشی با روش تجزیه حالت تجربی




Fig. 5 Decomposition of vibration signal with EEMD method

شکل 5 تجزیه سیگنال ارتعاشی با روش تجزیه حالت تجربی دسته‌ای

جزئیات آن توسط توابع موجک مادر میپر و دابچی 10 در شکل‌های 6 و 7 نشان داده شده است.

تمامی این نمونه‌ها از در حالت نابالانسی و در دور موتور 1200 RPM است. انتخاب ویژگی‌های مناسب جهت توصیف وضعیت ارتعاشی ماشین دوار، امری ضروری به نظر می‌رسد. به این دلیل 10 ویژگی میانگین، واریانس<sup>1</sup>، بیشینه دامنه سیگنال، کورتوسیس<sup>2</sup>، اسکینوس<sup>3</sup>، انحراف از معیار<sup>4</sup>، فاکتور کرس<sup>5</sup>، جذر میانگین مربعات<sup>6</sup>، تفاوت بین بیشینه و کمینه سیگنال و همچنین انرژی سیگنال جهت استخراج ویژگی از هر سیگنال در نظر گرفته شدند. با توجه به این‌که هر کدام از این ویژگی‌ها می‌توانند اثرات مثبت و منفی بر نتایج بگذارند با استفاده از روش کاهش ویژگی رلیف<sup>7</sup>، پنج ویژگی واریانس، کورتوسیس، انحراف از معیار، جذر میانگین مربعات و انرژی سیگنال جهت ادامه کار انتخاب شدند. داده‌های به‌دست آمده، جهت بهبود فرآیند آموزش، در بازه [0,1] نرمال‌سازی می‌شوند. از ماشین بردار پشتیبان بهینه جهت طبقه‌بندی دو کلاس سالم و نابالانسی استفاده شده است. تابع کرنل ماشین بردار پشتیبان از نوع تابع پایه شعاعی گاوسی انتخاب، و پارامتر  $\sigma$  آن و نیز پارامتر تابع جریمه  $C$  توسط الگوریتم بهینه‌سازی ازدحام ذرات بهینه شده است.

<sup>1</sup> Variance  
<sup>2</sup> Kurtosis  
<sup>3</sup> Skewness  
<sup>4</sup> Standard Deviation  
<sup>5</sup> Crest Factor  
<sup>6</sup> Root Mean Square  
<sup>7</sup> Relief

ازدحام ذرات جهت طبقه‌بندی کلاس سالم از نابالانسی استفاده شد. نتایج حاصل نشان داد که همه این روش‌ها به درصدها قابل قبولی در تفکیک دو کلاس سالم از نابالانسی رسیده‌اند. روش تبدیل موجک گسسته با تابع موجک مادر می‌توانسته است نسبت به سایر روش‌ها به درصدهای موفقیت بالاتری برسد، همچنین ماشین بردار پشتیبان بهینه شده توانسته است بسیار بهتر از ماشین بردار پشتیبان با پارامترهای پیش فرض نرم‌افزار متلب عمل کند. برای ادامه کار پیشنهاد می‌شود که توابع موجک مادر بیشتری مورد بررسی قرار گرفته، مقایسه‌ای بین انواع روش‌های طبقه‌بندی کلاس‌ها از جمله روش شبکه عصبی صورت پذیرد، همچنین می‌توان عیوب مختلفی را با استفاده از این دستگاه ایجاد کرد و با روش‌های مورد بررسی در این پژوهش این عیوب را طبقه‌بندی کرد.

#### 7- فهرست علائم

$a$	ضرایب لاگرانژ
$b$	عدد اسکالر
$c$	تابع حالت ذاتی
$C$	پارامتر جریمه
$D$	دامنه نویز سفید
$e$	ضرایب شتاب
$h$	مؤلفه سیگنال
$k$	تابع کرنل
$m$	میانگین پوش بالا و پایین منحنی
$M$	تعداد تلاش‌ها
$q$	پارامتر وزن اینرسی
$r$	عدد تصادفی
$s$	پارامتر مقیاس
$t$	زمان
$u$	باقی مانده سیگنال
$v$	سرعت ذره
$w$	تعریف کننده مرز
$x$	سیگنال ورودی
$X$	موقعیت ذره
$\gamma$	برچسب کلاس ماشین بردار پشتیبان
$z$	پارامتر انتقال
<b>علائم یونانی</b>	
$\psi$	تابع موجک مادر
$\phi$	تبدیل نگاشت
$\sigma$	پارامتر تابع کرنل گاوسی
$\xi$	پارامتر تخطی
<b>زیر نویس‌ها</b>	
pbest	بهترین تجربه فردی
gbest	بهترین تجربه گروهی

#### 8- مراجع

- [1] R. Collacott, *Mechanical fault diagnosis and condition monitoring*: Springer Science & Business Media, pp. 25-35, New York: Wiley, 2012.
- [2] J. Cheng, Y. Yang, Y. Yang, A rotating machinery fault diagnosis method based on local mean decomposition, *Digital Signal*

تعداد بردار پشتیبان کمتری در تفکیک کلاس سالم از نابالانسی دست یافته است. روش تجزیه حالت تجربی دسته‌ای نیز پس از این روش به درصدهای بالایی در تفکیک کلاس‌ها از یکدیگر رسیده است.

با مقایسه نتایج جدول 1 و 2 مشخص می‌شود که ماشین بردار پشتیبان بهینه‌شده توسط الگوریتم بهینه‌سازی ازدحام ذرات بسیار بهتر از ماشین بردار پشتیبان غیربهینه (با پارامترهای پیش فرض نرم‌افزار متلب) عمل کرده است. در واقع ماشین بردار پشتیبان غیربهینه با مقادیر پارامترهای پیش فرض  $C=1$  و  $\sigma=1$ ، به درصدهای موفقیت پایین و بیشترین تعداد بردار پشتیبان ممکن دست یافته است.

#### 6- نتیجه گیری

هدف از این پروژه مقایسه‌ای بین روش‌های مختلف پردازش سیگنال در حوزه زمان-فرکانس جهت تشخیص زودهنگام عیب نابالانسی ماشین دوار بوده است. در این راستا دستگاه شبیه‌ساز عیب در ماشین‌های دوار طراحی و ساخته شد. از ماشین بردار پشتیبان بهینه شده با الگوریتم بهینه‌سازی

جدول 1 درصدهای موفقیت ماشین بردار پشتیبان بهینه

**Table 1** Success rate of optimized support vector machine

روش	دور موتور (RPM)	درصد موفقیت	پارامتر $\sigma$	پارامتر $C$	تعداد بردار پشتیبان
	600	66.67	4.92	55	17
EMD	1200	87.5	4.64	93	16
	1500	87.5	3.45	5.27	28
	600	87.5	4.1	4.32	22
EEMD	1200	83.33	3.58	4.78	27
	1500	87.5	3.74	61	27
	600	87.5	4.64	20.7	21
Meyer	1200	99.99	3.37	25.4	24
	1500	79.17	4.71	18.4	19
	600	91.67	3.5	1	30
db10	1200	91.67	3.87	15	26
	1500	79.17	2.52	42.6	32

جدول 2 درصدهای موفقیت ماشین بردار پشتیبان با پارامترهای پیش فرض

**Table 2** Success rate of support vector machine with default parameters

روش پردازش سیگنال	دور موتور (RPM)	درصد موفقیت	تعداد بردار پشتیبان
	600	41.67	36
EMD	1200	66.67	36
	1500	66.67	36
	600	75	36
EEMD	1200	54.17	36
	1500	66.67	36
	600	70.83	36
Meyer	1200	83.3	36
	1500	66.67	36
	600	66.67	36
db10	1200	62.5	36
	1500	66.67	36

- [15] C. Yang, T. Wu, Diagnostics of gear deterioration using EEMD approach and PCA process, *Measurement*, Vol. 61, pp. 75-87, 2015.
- [16] S. G. Mallat, A theory for multiresolution signal decomposition: the wavelet representation, *IEEE transactions on pattern analysis and machine intelligence*, Vol. 11, No. 7, pp. 674-693, 1989.
- [17] J. A. Corral-Hernández, J. A. Antonino-Daviu, Influence of the Start-up System in the Diagnosis of Faults in the Rotor of Induction Motors using the Discrete Wavelet Transform, *Procedia Computer Science*, Vol. 83, pp. 807-815, 2016.
- [18] A. Belsak, J. Flaker, Diagnostics Cracks in Gears with Wavelet Analysis, in *ICF12*, Vol. 20, No. 3, pp. 116-133, 2013.
- [19] A. Ziaja, I. Antoniadou, T. Barszcz, W. J. Staszewski, K. Worden, Fault detection in rolling element bearings using wavelet-based variance analysis and novelty detection *Vibration and Control*, Vol. 22, No. 2, pp. 396-411, 2016.
- [20] D. H. Pandya, S. H. Upadhyay, S. P. Harsha, Fault diagnosis of high-speed rolling element bearings using wavelet packet transform *Signal and Imaging Systems Engineering*, Vol. 8, No. 6, pp. 390-401, 2015.
- [21] X. Zhang, J. Zhou, Multi-fault diagnosis for rolling element bearings based on ensemble empirical mode decomposition and optimized support vector machines, *Mechanical Systems and Signal Processing*, Vol. 41, No. 1, pp. 127-140, 2013.
- [22] T. Itoh, *Numerical techniques for microwave and millimeter-wave passive structures*: Wiley-Interscience, pp. 65-85, 1989.
- [23] A. Tabrizi, L. Garibaldi, A. Fasana, S. Marchesiello, Early damage detection of roller bearings using wavelet packet decomposition, ensemble empirical mode decomposition and support vector machine, *Meccanica*, Vol. 50, No. 3, pp. 865-874, 2015.
- [24] G. Bin, J. Gao, X. Li, B. Dhillon, Early fault diagnosis of rotating machinery based on wavelet packets—Empirical mode decomposition feature extraction and neural network, *Mechanical Systems and Signal Processing*, Vol. 27, pp. 696-711, 2012.
- [25] L. Jack, A. Nandi, Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms, *Mechanical systems and signal processing*, Vol. 16, No. 2-3, pp. 373-390, 2002.
- [26] Z. Liu, H. Cao, X. Chen, Z. He, Z. Shen, Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings, *Neurocomputing*, Vol. 99, pp. 399-410, 2013.
- [27] A. Nejat, H. R. Kaviyani, Aerodynamic optimization of megawatt class horizontal axis wind turbine blade with particle swarm optimization algorithm, *Modares Mechanical Engineering*, Vol. 16, No. 11, pp. 1-11, 2017. (in Persian فارسی)
- Processing*, Vol. 22, No. 2, pp. 356-366, 2012.
- [3] G. H. Granlund, H. Knutsson, *Signal processing for computer vision*: Springer Science & Business Media, pp. 45-55, 2013.
- [4] B. Boashash, *Time-frequency signal analysis and processing: a comprehensive reference*: Academic Press, pp. 105-115, 2015.
- [5] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, H. H. Liu, The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis, in *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, Vol. 454, No. 1971, pp. 903-995, 1998 .
- [6] S. Loutridis, Damage detection in gear systems using empirical mode decomposition, *Engineering Structures*, Vol. 26, No. 12, pp. 1833-1841, 2004.
- [7] J. Zheng, J. Cheng, Y. Yang, Generalized empirical mode decomposition and its applications to rolling element bearing fault diagnosis, *Mechanical Systems and Signal Processing*, Vol. 40, No. 1, pp. 136-153, 2013.
- [8] M. Amarnath, I. P. Krishna, Empirical mode decomposition of acoustic signals for diagnosis of faults in gears and rolling element bearings, *IET Science, Measurement & Technology*, Vol. 6, No. 4, pp. 279-287, 2012.
- [9] C. Guo, M. Al-Shudeifat, J. Yan, L. Bergman, D. McFarland, E. Butcher, Application of empirical mode decomposition to a Jeffcott rotor with a breathing crack, *Sound and Vibration*, Vol. 332, No. 16, pp. 3881-3892, 2013.
- [10] P. Flandrin, P. Gonçalves, G. Rilling, EMD equivalent filter banks, from interpretation to applications, *Hilbert-Huang transform and its applications*, pp. 57-74, 2005.
- [11] Z. Wu, N. E. Huang, Ensemble empirical mode decomposition: a noise-assisted data analysis method, *Advances in adaptive data analysis*, Vol. 1, No. 01, pp. 1-41, 2009.
- [12] Y. Imaouchen, M. Kedadouche, R. Alkama, M. Thomas, A Frequency-Weighted Energy Operator and complementary ensemble empirical mode decomposition for bearing fault detection, *Mechanical Systems and Signal Processing*, Vol. 82, pp. 103-116, 2017.
- [13] Z. Feng, M. J. Zuo, R. Hao, F. Chu, J. Lee, Ensemble empirical mode decomposition-based Teager energy spectrum for bearing fault diagnosis, *Vibration and Acoustics*, Vol. 135, No. 3, pp. 031013, 2013.
- [14] W. B. Zhang, J. X. Zhu, Y. S. Pu, Y. P. Su, A New Purification Method for Rotor Center's Orbit by Using Ensemble Empirical Mode Decomposition, *Advanced Materials Research*, Vol. 986, pp. 801-804, 2014.