

# تشخیص عیب یاتاقان‌های غلتشی با استفاده از سیگنال‌های ارتعاشی بر اساس

## تحلیل طیف تکین و شبکه عصبی مصنوعی

مهدی حسینیان

دانشجوی کارشناسی ارشد گروه مهندسی مکانیک

واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

mehdi.hassanian@gmail.com

مهدی صالحی\*

استادیار گروه مهندسی مکانیک

واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

mehdi.salehi@pmc.iaun.ac.ir

تاریخ دریافت: ۱۳۹۵/۰۶/۱۸

تاریخ پذیرش: ۱۳۹۶/۱۲/۲۶

### چکیده

در کاربردهای صنعتی، پایش وضعیت و عیب‌یابی بیرینگ‌ها از اهمیت زیادی برخوردار است. تحلیل ارتعاشی، انتشار صدا، دمانگاری و تحلیل روانکار از جمله روش‌های تشخیصی جهت شناسایی عیوب بیرینگ‌ها می‌باشند. یکی از قابل اطمینان‌ترین روش‌ها جهت عیب‌یابی تجهیزات دوار، مطالعه بر روی سیگنال ارتعاشی می‌باشد. تاکنون روش‌های مختلفی جهت عیب‌یابی بیرینگ‌های غلتشی توسط سیگنال‌های ارتعاشی در حوزه زمان ارائه شده است. بیشتر روش‌های سری زمانی، پیچیده و سیگنال‌های استخراجی تحت تأثیر نویز می‌باشند. تحلیل طیف تکین<sup>۱</sup> که به عنوان یک تکنیک جدید و کارآمد در زمینه تحلیل سری‌های زمانی مطرح می‌باشد به لحاظ اجرا آسان و مصون از نویز می‌باشد. در این روش سیگنال ارتعاشی اصلی هر یک از عیوب بیرینگ غلتشی به مؤلفه‌های اساسی تجزیه می‌شوند، که پس از انتخاب تعدادی از مؤلفه‌ها و بازسازی سیگنال ارتعاشی، مشخصه‌های آماری در حوزه زمان از سیگنال بازسازی شده استخراج می‌شوند. این مشخصه‌ها به عنوان ورودی‌های شبکه عصبی مصنوعی<sup>۲</sup> جهت تشخیص و طبقه‌بندی عیوب بیرینگ‌ها اعمال می‌گردد. خروجی‌های شبکه عصبی، عیوب بیرینگ‌ها هستند که با انتخاب تعداد مناسب نرون‌های لایه پنهان (لایه میانی)، حداکثر دقت در تشخیص عیوب حاصل می‌شود. نتایج، پیاده‌سازی موفق و کارآمد تحلیل طیف تکین در عیب‌یابی بیرینگ‌های غلتشی با کمترین خطا را نشان می‌دهد.

**واژگان کلیدی:** تحلیل طیف تکین، شبکه عصبی مصنوعی، عیب‌یابی، بیرینگ غلتشی، سیگنال ارتعاشی

### ۱. مقدمه

ارتعاش بیرینگ‌ها به دلیل اهمیت‌شان در صنعت، در سال‌های اخیر مورد توجه محققین بوده است. این امر سبب

پایش وضعیت و عیب‌یابی در سیستم‌های مکانیکی با هدف جلوگیری از بروز آسیب جدی در تجهیز و پیشگیری از توقف‌های ناخواسته از اهمیت ویژه‌ای برخوردار است. تحلیل

توسعه تکنیک‌های مختلف عیب‌یابی آنها از طریق تحلیل ارتعاش گردیده است.

روش‌های زیادی نظیر تبدیل فوریه زمان کوتاه<sup>۳</sup>، تکنیک‌هایی نظیر تحلیل انولوپ<sup>۴</sup> برای تحلیل ارتعاش بیرینگ‌ها از گذشته تا کنون مورد استفاده قرار گرفته است. به دلیل ماهیت ضربه‌ای و گذرای سیگنال‌های ارتعاشی در بیرینگ‌ها تشخیص دقیق عیوب این تجهیزات با استفاده از تبدیل فوریه امکان‌پذیر نمی‌باشد. بر این اساس، تحلیل سیگنال‌ها به صورت هم‌زمان در حوزه زمان و فرکانس با استفاده از تبدیل ویولت<sup>۵</sup> مورد توجه قرار گرفت.

در این میان جایگاه سری‌های زمانی به عنوان یک روش متفاوت و کارآمد خالی به نظر می‌رسید. یک راه حل، تلاش در جهت یافتن روشی ناپارامتری است که در کنار برخورداری از توانمندی بالا، نسبت به نویز موجود در سری زمانی مورد مطالعه نیز استوار باشد. روش‌های بسیاری به منظور کاهش سطح نویز وجود دارد که در میان آنها، روش‌های مبتنی بر تجزیه مقادیر تکین از توانمندی بیشتری برخوردار هستند. روش تحلیل طیف تکین<sup>۶</sup>، یک روش ناپارامتری نسبتاً جدید است که به کمک تجزیه مقادیر تکین به کاهش سطح نویز، مدل‌سازی و پیش‌بینی سری‌های زمانی می‌پردازد. سادگی، عدم وابستگی به پیش‌فرض‌های محدودکننده رایج در سایر روش‌ها همچون ایستا و خطی بودن سری زمانی، کارایی مناسب در تحلیل سری‌های زمانی از جمله دلائل گسترش روزافزون استفاده از این روش در علوم مختلف است [۱].

در این مقاله هدف، استفاده از روش قدرتمند تحلیل سری زمانی جهت تجزیه سیگنال ارتعاشی اصلی به تعدادی مؤلفه است، به طوری که بتوان آنها را به عنوان مؤلفه‌های اساسی یا نویز در نظر گرفت. روش تحلیل طیف تکین شامل دو مرحله است: تجزیه و بازسازی. هریک از مرحله‌های مذکور نیز شامل دو مرحله است. تجزیه شامل: جایدهی<sup>۷</sup> و تجزیه مقادیر تکین<sup>۸</sup>؛ بازسازی شامل: میانگین‌گیری قطری<sup>۹</sup> و

گروه‌بندی<sup>۱۰</sup> می‌باشد. سیگنال‌های ارتعاشی با استفاده از تحلیل طیف تکین، به مؤلفه‌های اساسی تجزیه و با انتخاب تعدادی از این مؤلفه‌ها و ترکیب آنها، سیگنال بازسازی شده به دست می‌آید که از آن جهت استخراج بردار مشخصه استفاده می‌گردد. برای این منظور از کدنویسی متلب بهره گرفته شده است.

روش کار به این صورت است که ابتدا سیگنال‌های ارتعاش در حوزه زمان توسط یک شتاب‌سنج بر پوسته موتور الکتریکی در محل قرارگیری بیرینگ‌های غلثشی اندازه‌گیری می‌شود. سیگنال‌های اندازه‌گیری شده شامل: بیرینگ سالم، بیرینگ با حلقه داخلی معیوب، بیرینگ با حلقه خارجی معیوب، بیرینگ با ساچمه معیوب می‌باشد. در گام بعدی یک سری پارامتر آماری نظیر مقدار موثر، انحراف معیار و ... به عنوان مشخصه عیب اختیار و در ورودی یک شبکه عصبی اعمال می‌شود؛ خروجی مطلوب شبکه عصبی، معایب بیرینگ‌ها می‌باشد. در پایان با انتخاب تعداد نرون‌های لایه‌های میانی مناسب‌ترین چیدمان شبکه جهت حداکثر دقت مورد بررسی قرار می‌گیرد.

تحلیل طیف تکین در بسیاری از کاربردها نظیر تحلیل داده‌های هواشناسی [۲]، پایش وضعیت [۳]، تشخیص خرابی سایدگی روتور و استاتور [۴] استفاده شده است. تلاش‌های بسیاری در حوزه عیب‌یابی بیرینگ‌ها انجام گرفته که در ادامه به مختصری از آن اشاره می‌شود.

مورگانا تام و همکاران برای تحلیل سیگنال‌های ارتعاشی بیرینگ‌های یک موتور الکتریکی و یک گیربکس، از تحلیل طیف تکین استفاده نمودند. در این تحقیق یک‌بار مقادیر تکین و بار دیگر انرژی مؤلفه‌های اصلی را به عنوان ورودی شبکه عصبی پس‌انتشار<sup>۱۱</sup> برای تشخیص عیب بیرینگ‌ها مورد استفاده قرار دادند [۵].

گلفشان و سانلی‌تورک بر مبنای رویکرد کاهش نویز، به بررسی تجزیه مقادیر تکین و ماتریس هنکل برای عیب‌یابی بلیرینگ‌ها با به کارگیری شبکه عصبی پرداختند [۶].

کیلوندو و همکاران تأثیر پارامترهای سرعت، بار و اندازه عیب بیرینگ را در تحلیل طیف تکین و تحلیل انولوپ بررسی کرده و طبق مقایسه نشان دادند که مشخصه‌های سیگنال در تحلیل طیف تکین (SSA) حساسیت کمتری به تغییر پارامترهای مذکور نسبت به مشخصه‌ای مانند مقدار مؤثر در تحلیل انولوپ دارند [۷].


البوغرابی و ترندافیلووا از خاصیت کاهش نویز تحلیل طیف تکین بدین صورت بهره بردند که تعدادی از مؤلفه‌های اساسی سیگنال ارتعاشی را طوری انتخاب کردند که ۹۰ درصد سیگنال اصلی بازسازی گردد و از آن سیگنال‌ها برای تحلیل در مدل اتورگرسیو که یکی از ساده‌ترین روش‌های مدل‌سازی داده‌های سری زمانی می‌باشد، استفاده نموده و در آخر عیوب با یک طبقه‌بندی‌کننده بازشناسایی گشتند [۸]. از جمله تحقیقاتی که در رابطه با تشخیص عیب در بیرینگ‌های غلتشی منتشر شده است می‌توان به مقالات یان [۹]، کانکار [۱۰]، کومار [۱۱]، رفیعی [۱۲] و ایتویی [۱۳] اشاره کرد. در این مقاله‌ها به روشی مشابه، ولی با این تفاوت که برای پردازش داده‌ها از تکنیک‌های حوزه زمان-فرکانس استفاده شده است، عیب‌یابی با یک شبکه عصبی مصنوعی انجام می‌گیرد.

در مقاله حاضر، نخست به پیشینه عیب‌یابی بیرینگ‌های غلتشی با این روش اشاره می‌شود. در بخش ۲ مشخصات داده‌های ارتعاشی را توضیح داده و در قسمت ۳ به بیان مبانی تحلیل طیف تکین پرداخته می‌شود. بخش ۴ به استخراج مشخصه‌های سیگنال ارتعاشی در حوزه زمان اختصاص یافته و در بخش ۵ با استفاده از شبکه عصبی، عیوب بیرینگ شناسایی و طبقه‌بندی می‌گردد. در پایان به بحث و نتیجه‌گیری می‌پردازیم.

## ۲. داده‌های ارتعاشی

سیگنال‌های چهار حالت بیرینگ سالم ( ${}^2H$ )، عیب در حلقه داخلی ( ${}^{13}IF$ )، عیب در حلقه خارجی ( ${}^{14}OF$ ) و عیب در

ساچمه ( ${}^5BF$ ) از پایگاه داده تست بیرینگ دانشگاه کیس وسترن رزرو<sup>۱۶</sup> آمریکا استخراج شده است. همان‌طور که در شکل ۱ مشاهده می‌گردد، بیرینگ‌های مورد بررسی در این آزمایش درون محفظه بیرینگ یک موتور الکتریکی با توان ۲ اسب بخار که به وسیله یک واسط انتقال دهنده گشتاور به یک توان سنج متصل است، قرار دارند. این مجموعه دارای حسگر ارتعاش (شتاب‌سنج)، کارت داده‌برداری و یک کامپیوتر می‌باشد.




شکل ۱. تجهیزات تست بیرینگ دانشگاه کیس وسترن رزرو [۱۴]

عیوب به صورت نقطه‌ای با قطرهای ۰/۱۸ و ۰/۳۶ و ۰/۵۳ میلی‌متر و عمق ۰/۲۸ میلی‌متر به‌طور جداگانه بر روی هر بیرینگ در حلقه داخلی، خارجی و روی ساچمه و به روش تخلیه الکتریکی ایجاد شده‌اند (عیب حلقه خارجی در موقعیت‌های ساعت ۱۲، ۳ و ۶ می‌باشند). سیگنال‌های ارتعاشی با فرکانس ۱۲ و ۴۸ کیلوهرتز برای هر کدام از عیوب در سمت شفت خروجی و سمت فن قفسه موتور با سایزهای مذکور و در بارهای مختلف (صفر، یک، دو، سه اسب بخار) نمونه‌برداری شده است.

در این تحقیق برای تحلیل و عیب‌یابی از سیگنال‌های ثبت شده با فرکانس ۱۲ کیلوهرتز، با عیوب در سمت شفت خروجی موتور ( ${}^7DE$ ) و در کوچک‌ترین سایز عیب یعنی ۰/۱۸ میلی‌متر در بار ۳ اسب بخار در نظر گرفته شده است. برای حلقه خارجی از داده‌های ناحیه بار<sup>۱۸</sup> (ساعت ۶) استفاده گردیده است. در شکل ۲ شماتیک مجموعه آزمایشگاهی و موقعیت بیرینگ و شتاب‌سنج مورد استفاده در این تحقیق


نشان داده شده است و شکل ۳ اجزاء بیرینگ را نمایش می‌دهد. شرایط مختلف کاری بیرینگ در جدول ۱ آمده است.



شکل ۲. شماتیک مجموعه آزمایشگاهی و موقعیت بیرینگ و شتاب‌سنج مورد استفاده در این مقاله

جدول ۱. شرایط کاری بیرینگ با اندازه عیوب مختلف

| دور  | بار              | سایز عیب<br>(میلی متر)      |
|------|------------------|-----------------------------|
| ۱۷۹۷ | ۰ (دور بر دقیقه) | بدون عیب، ۰/۱۸<br>۰/۵۳ ۰/۳۶ |
| ۱۷۷۵ | ۱ (اسب بخار)     | بدون عیب، ۰/۱۸<br>۰/۵۳ ۰/۳۶ |
| ۱۷۵۰ | ۲                | بدون عیب، ۰/۱۸<br>۰/۵۳ ۰/۳۶ |
| ۱۷۳۰ | ۳                | بدون عیب، ۰/۱۸<br>۰/۵۳ ۰/۳۶ |



شکل ۳. اجزاء بیرینگ [۱۵]

### ۳-۱. جای‌دهی

سیگنال ارتعاشی بیرینگ  $f$  که یک سری زمانی غیر صفر با مقادیر حقیقی و  $N$  نقطه داده را در نظر بگیرید:

$$f = (x_1, \dots, x_N) \quad (۱)$$

فرض کنید  $L$  (طول پنجره<sup>۱۹</sup>) عدد صحیح  $1 < L < N$ ،  $K$  تأخیر<sup>۲۰</sup> و  $K = N - L + 1$  است. جای‌دهی در واقع به عنوان یک نگاشت جهت تبدیل سری زمانی رابطه ۱ به تعداد  $K$  بردار هر کدام با طول  $L$  می‌باشد.

$$X_i = (x_i, \dots, x_{i+L-1})^T, \quad (۲)$$

$$(1 \leq i \leq K)$$

ماتریس مسیر<sup>۲۱</sup>  $X$  به صورت رابطه ۳ به دست خواهد آمد.


$$X = [X_1: \dots: X_K] = (x_{ij})_{i,j=1}^{L,K} \quad (۳)$$

$$= \begin{pmatrix} x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ x_3 & x_4 & x_5 & \dots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{pmatrix}$$

ستون‌های ماتریس مسیر، بردارهای تأخیر<sup>۲۲</sup> هستند. سطرها و ستون‌های این ماتریس، زیر سری‌هایی از سری اصلی (سیگنال ارتعاشی اصلی) می‌باشند. در ماتریس مسیر، عناصر روی قطرهایی که  $i+j$  آنها مقدار یکسانی می‌باشد، برابرند. چنین ماتریسی که عناصر روی قطرهای فرعی آن با هم برابرند، ماتریس هنکل<sup>۲۳</sup> نامیده می‌شود [۱۶]. مشاهده می‌گردد به ازای هر  $L$  و  $N$  مشخص درایه‌های سطر اول و ستون آخر یا ستون اول و سطر آخر، همان داده‌های سیگنال ارتعاشی بیرینگ می‌باشند. شکل ۴ قسمتی از سیگنال ارتعاشی ثبت شده برای حالت عیب در ساچمه را نشان می‌دهد.

### ۳. مبانی روش تحلیل طیف تکین

جزر  $\lambda_i$  مقادیر تکین<sup>۲۴</sup> نامیده می‌شود [۱۶] و تعداد مقادیر تکین غیر صفر، رتبه ماتریس است. طیف تکین برای حالت عیب ساچمه با طول پنجره  $L=15$  در شکل ۵، رسم شده است.




شکل ۵. طیف تکین برای حالت عیب ساچمه با طول پنجره

$$L=15$$

### ۳-۳. میانگین‌گیری قطری

ماتریس‌های  $X_i$  به‌دست آمده در مرحله تجزیه دارای خاصیت هنکلی نیستند، بنابراین نمی‌توان با استفاده از آنها تقریبی از سیگنال ارتعاشی اصلی به‌دست آورد. میانگین‌گیری قطری روش مناسبی برای حل این مشکل است. در واقع با میانگین‌گیری قطری، می‌توان یک ماتریس را به یک سیگنال ارتعاشی برگرداند. هر ماتریس تجزیه شده رابطه ۴، توسط الگوریتم میانگین‌گیری قطری روابط ۷، به یک سیگنال ارتعاشی جدید  $g_1, \dots, g_N$  تبدیل می‌شود. به بیان دیگر در این مرحله  $d$  مؤلفه اساسی با طول  $N$  خواهیم داشت.  $y_{ij}$  درایه‌های یک ماتریس  $L \times K$  با نام  $X_i$  است که  $1 \leq i \leq L$  و  $1 \leq j \leq K$

$$g_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m,k-m+1} & \text{for } 1 \leq k < L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+1} & \text{for } L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m,k-m+1} & \text{for } K^* < k \leq N \end{cases}$$



شکل ۴. سیگنال ارتعاشی برای عیب ساچمه

### ۳-۲. تجزیه مقدار تکین

در این گام ماتریس مسیر بر اساس SVD تجزیه می‌گردد؛ بدین صورت که اگر  $S = \mathbf{X}\mathbf{X}^T$  یک ماتریس  $L \times L$  و  $\lambda_1, \lambda_2, \dots, \lambda_L$  مجموعه مقادیر ویژه  $S$ ، به‌طوری‌که  $U_1, U_2, \dots, U_L$  و  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$  بردارهای ویژه یک‌ماتماد متناظر با مقادیر ویژه باشند، تجزیه مقدار تکین ماتریس مسیر را به صورت رابطه ۴ می‌توان نوشت.

$$\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_d \quad (۴)$$

جایی که  $d$  تعداد مقادیر ویژه غیر صفر ماتریس  $S$ ، یا به عبارت دیگر  $d=L$  و  $X_i$  به صورت رابطه ۵ خواهد بود.

$$\mathbf{X}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T, \quad (۵)$$

$$(i = 1, \dots, d)$$

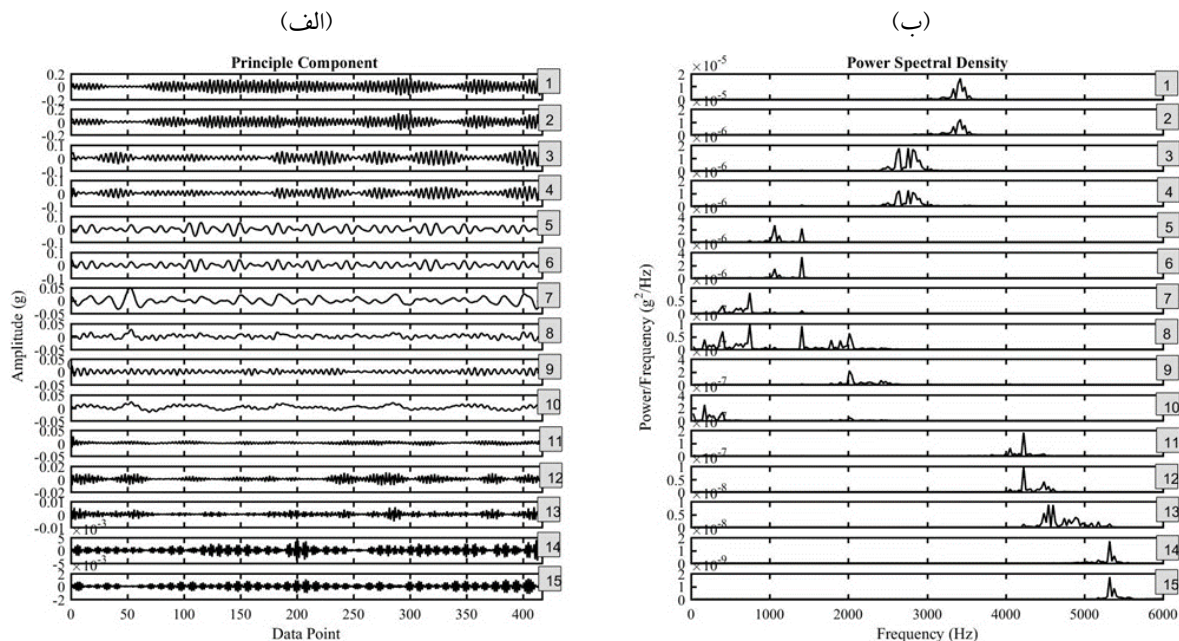
بردار  $V_i$  نیز از معادله رابطه ۶ به‌دست خواهد آمد.

$$\mathbf{V}_i = \mathbf{X}^T \mathbf{U}_i / \sqrt{\lambda_i} \quad (۶)$$

$$\begin{cases} \text{for } 1 \leq k < L^* \\ \text{for } L^* \leq k \leq K^* \\ \text{for } K^* < k \leq N \end{cases} \quad (۷)$$

سیگنال ارتعاشی بیرینگ در حالت عیب ساچمه با  $L=15$  آمده است. در واقع مؤلفه‌های اساسی حاصل تجزیه ماتریس مسیر و سپس میانگین‌گیری قطری می‌باشند.

که:  $L^* = \min(L, K)$  و  $K^* = \max(L, K)$  می‌باشند. در شکل‌های ۶-الف و ۶-ب به ترتیب، پانزده مؤلفه اساسی به همراه چگالی طیف توان متناظر با آن، مربوط به تجزیه




شکل ۶. الف) مؤلفه‌های اساسی برای حالت عیب ساچمه (ب) چگالی طیف توان هر کدام از مؤلفه‌های اساسی

سیگنال ارتعاشی اصلی و بازسازی شده در شکل ۷-الف و سیگنال باقی‌مانده در شکل ۷-ب مشخص شده است. برای حالات دیگر (حالت بدون عیب، عیب در حلقه داخلی و خارجی) نیز بعد از تجزیه با توجه به گراف‌های به‌دست آمده، مؤلفه‌های اساسی جهت بازسازی سیگنال ارتعاشی انتخاب می‌گردند. به بیان دیگر در این مرحله بعد از ترکیب مؤلفه‌های اساسی انتخابی، یک ماتریس  $L \times K$  خواهیم داشت که پس از میانگین‌گیری قطری به یک سیگنال ارتعاشی بازسازی شده تبدیل می‌شود.

### ۴-۳. گروه‌بندی

در این مرحله تعدادی از مؤلفه‌های اساسی به‌دست آمده در مرحله تجزیه، جهت بازسازی سیگنال ارتعاشی انتخاب می‌شوند؛ بدین صورت که با مقایسه نمودارهای مؤلفه‌های اساسی، آنهایی که بیشترین توان را در پایین‌ترین محدوده فرکانسی دارند برای بازسازی سیگنال ارتعاشی انتخاب می‌گردد. اینکار سبب حذف نویزها می‌شود. در اینجا برای عیب در ساچمه، سیگنال بازسازی شده از ترکیب مؤلفه‌های اساسی پنجم، ششم، هفتم، هشتم و نهم حاصل شده است.

(الف)



(ب)

شکل ۷. الف) سیگنال ارتعاشی اصلی (خط چین) و بازسازی شده (خط پیوسته) از مؤلفه‌های اساسی پنجم، ششم، هفتم، هشتم و نهم برای حالت عیب ساچمه (ب) سیگنال ارتعاشی باقی مانده برای حالت عیب ساچمه

### ۳-۵. تفکیک پذیری

مطالعه تفکیک پذیری در SSA نشان می‌دهد که سیگنال ارتعاشی بازسازی شده و باقی مانده به چه میزان از هم قابل تفکیک‌اند. فرض کنید که  $F^1, F^2$  دو سری زمانی (در اینجا سیگنال ارتعاشی بازسازی شده و باقی مانده) با طول  $N$  و  $F = F^1 + F^2$  باشند (مجموع دو سیگنال یعنی سیگنال ارتعاشی اصلی است)، همبستگی وزنی<sup>۲۵</sup>، که میزان وابستگی بین این دو سری است به صورت رابطه ۸ تعریف می‌شود؛

$$\rho_{12}^{\omega} = \frac{(F^1, F^2)_{\omega}}{\|F^1\|_{\omega} \|F^2\|_{\omega}} \quad (8)$$

$$= \frac{\sum_{i=1}^N \omega_i f_i^1 f_i^2}{\sqrt{\sum_{i=1}^N \omega_i f_i^1 f_i^1} \sqrt{\sum_{i=1}^N \omega_i f_i^2 f_i^2}}$$

جایی که  $F^1 = f_i^1, F^2 = f_i^2$  و  $\omega_i$  به صورت رابطه ۹ تعریف می‌شود.

$$\omega_i = \begin{cases} i & \text{for } 1 \leq i < L^* \\ L^* & \text{for } L^* \leq i < K^* \\ N - i + 1 & \text{for } K^* \leq i \leq N \end{cases} \quad (9)$$

$L^*$  و  $K^*$  در قسمت ۳-۳ تعریف شده است.

اگر قدر مطلق مقدار  $\rho_{12}^{\omega}$  نزدیک صفر باشد، آن دو سری تفکیک پذیری خوبی دارند و اگر قدر مطلق مقدار  $\rho_{12}^{\omega}$  نزدیک یک باشد می‌گوییم که آنها تفکیک پذیری خوبی ندارند [۱۷].

### ۳-۶. تعیین پارامتر طول پنجره

در مرحله تجزیه، طول پنجره  $L$  بایستی مشخص گردد. انتخاب صحیح آن به مسئله بستگی دارد. مقدار خیلی بزرگ  $L$  برای سری‌های زمانی (در این مقاله سیگنال ارتعاشی) با ساختار پیچیده ممکن است تجزیه نامناسبی را حاصل کند که باعث تفکیک ناپذیری مؤلفه‌های اساسی شود [۱۸]. برای تعیین مقدار  $L$ ، مقادیر مختلفی را برای آن در نظر گرفته و سیگنال ارتعاشی اصلی بر اساس آن تجزیه و بازسازی می‌شود، سپس همبستگی وزنی سیگنال ارتعاشی بازسازی شده با سیگنال باقی مانده را محاسبه نموده و طول پنجره‌ای که کوچک‌ترین همبستگی وزنی نزدیک صفر را حاصل می‌کند، به عنوان طول پنجره برگزیده جهت تجزیه و پیاده‌سازی SSA استفاده می‌گردد. برای عیب در ساچمه کوچک‌ترین همبستگی وزنی با مقدار  $0.052$  در طول

$$\text{CrF} = \frac{\max|x_n|}{\sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}} \quad (14)$$

$$\text{ImF} = \frac{\max|x_n|}{\frac{1}{N} \sum_{n=1}^N |x_n|} \quad (15)$$

$$\text{ShF} = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}}{\frac{1}{N} \sum_{n=1}^N |x_n|} \quad (16)$$

$$\text{ClF} = \frac{\max|x_n|}{\left(\frac{1}{N} \sum_{n=1}^N \sqrt{|x_n|}\right)^2} \quad (17)$$

$$\text{Sk} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^3}{\left(\sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2}\right)^3} \quad (18)$$

$$\text{KV} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^4}{\left(\sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2}\right)^4} \quad (19)$$

$$x_{\text{normalized}} = a + \frac{(x_n - \min(x_n))(b - a)}{\max(x_n) - \min(x_n)} \quad (20)$$

جائیکه  $x_n$  سیگنال ارتعاشی و  $\bar{x}$  میانگین آن می‌باشد،  $N$  تعداد داده‌ها و  $(n = 1, 2, \dots, N)$  تا  $a$  تا  $b$  بازه نرمال‌سازی است.

#### ۵. تشخیص عیب با استفاده از شبکه عصبی

شبکه‌های عصبی کارائی فوق‌العاده‌ای برای کاربردهایی نظیر تشخیص الگو و طبقه‌بندی دارند. از یک شبکه عصبی از نوع پس انتشار پیشرو<sup>۳۷</sup> برای پردازش مشخصه‌های سیگنال ارتعاشی بیرینگ‌ها به‌دلیل عملکرد مناسب این شبکه‌ها در عیب‌یابی سیستم‌های غیرخطی استفاده می‌شود. در ساختار

پنجره  $L=15$  حاصل می‌شود؛ طول پنجره به‌دست آمده تعداد مقادیر تکین و مؤلفه‌های اساسی را تعیین می‌کند.

#### ۴. استخراج مشخصه

اکثر مشکلات مکانیکی در بیرینگ‌ها به صورت علائم ارتعاش و یا تغییر در مشخصه‌های ارتعاشی ظاهر می‌گردد. از طرف دیگر هر عیب علائم ارتعاشی مخصوص و منحصر به فرد خود را ایجاد می‌کند. بدین ترتیب می‌توان با استخراج مشخصه هر عیب و سپس تحلیل ارتعاشات به عیوب آن پی برد. یکی از کارآمدترین روش‌ها در استخراج تعیین این مشخصه‌ها استفاده از پارامترهای آماری در حوزه زمان است.

در این پژوهش از ۱۰ مشخصه آماری استفاده شده، که از روابط ۱۰ تا ۱۹ به‌دست می‌آیند و به‌ترتیب عبارتند از؛ میانگین<sup>۲۶</sup>، مقدار پیک<sup>۲۷</sup>، انحراف معیار<sup>۲۸</sup>، مقدار مؤثر<sup>۲۹</sup>، فاکتور کرس<sup>۳۰</sup>، فاکتور ضربه<sup>۳۱</sup>، فاکتور شکل<sup>۳۲</sup>، فاکتور لقی<sup>۳۳</sup>، چولگی<sup>۳۴</sup> و مقدار کرتوسیس<sup>۳۵</sup> [۱۹، ۲۰]. این مشخصه‌ها در محدوده ۰ تا ۱ نرمالایز و به عنوان ورودی شبکه عصبی در نظر گرفته می‌شود. از روش مقیاس‌گذاری ویژگی<sup>۳۶</sup> برای نرمالایز نمودن داده‌ها استفاده می‌گردد که از رابطه ۲۰ به‌دست می‌آید.

$$\text{Av} = \frac{1}{N} \sum_{n=1}^N x_n \quad (10)$$

$$\text{PV} = \max|x_n| \quad (11)$$

$$\text{SD} = \sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2} \quad (12)$$

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2} \quad (13)$$



این نوع شبکه‌ها هیچ حلقه‌ای وجود ندارد و هر نرون در هر لایه، از تمامی نرون‌های لایه قبل ورودی می‌گیرد. از میان روش‌های مختلف آموزش به روش پس انتشار، الگوریتم لونبرگ-مارکواریت<sup>۳۸</sup>، به دلیل همگرایی سریع‌تر در آموزش شبکه‌ها برای استفاده در تحقیق حاضر انتخاب شده است. این شبکه در سه لایه ورودی، لایه میانی (پنهان) و لایه خروجی طراحی شده که لایه ورودی آن دارای ۱۰ نرون و لایه خروجی دارای ۴ نرون می‌باشد. ورودی‌های شبکه عصبی، همان مقادیر نرمالایز شده‌ی مشخصه‌های حوزه زمانی (روابط ۱۰ تا ۱۹) سیگنال‌های ارتعاش (سیگنال‌های بازسازی شده) بوده و خروجی‌های شبکه عصبی، عیوب بیرینگ‌ها (شامل عیب در حلقه داخلی، عیب در حلقه خارجی، عیب در ساچمه و حالت سالم) می‌باشد. تعداد نرون‌های لایه میانی به میزان دقت خواسته شده بستگی دارد. افزایش نرون‌ها در لایه میانی دقت محاسبه را بالا و در مقابل سرعت کار را پایین می‌آورد. تابع انتقال تانژانت سیگموئید در لایه میانی و تابع همانی در لایه خروجی برای این شبکه در نظر گرفته شده است. از ابزار موجود در نرم افزار متلب جهت پیاده سازی شبکه عصبی برای تشخیص عیب استفاده شده است [۲۱، ۲۲].

در هنگام آموزش شبکه عصبی، مجموعه جواب (هدف‌ها<sup>۳۹</sup>) را داشته و شبکه با جواب صحیح آموزش داده می‌شود و در مرحله آزمایش با دادن داده‌های مشخص، انتظار پاسخ‌های مشخص است، که هر مقدار این پاسخ‌ها (خروجی‌ها<sup>۴۰</sup>) به هدف‌ها نزدیک باشد درصد خطا کمتر می‌گردد. در واقع می‌توان گفت کار شبکه عصبی تنظیم وزن‌های ورودی هر نرون می‌باشد تا باعث یادگیری کل یک شبکه عصبی بشود. شبکه‌های عصبی مصنوعی یاد می‌گیرند که مسئله‌ای را حل کنند و در واقع برنامه‌ریزی قبلی نمی‌شوند.

## ۶. بحث و نتایج

در تحقیق حاضر سیگنال‌های ارتعاشی حالت‌های مختلف خرابی بیرینگ با استفاده از تحلیل طیف تکین به مؤلفه‌های اساسی تجزیه و آن دسته از مؤلفه‌ها که بیشترین توان آنها در محدوده فرکانس پایین قرار دارند برای بازسازی سیگنال انتخاب می‌شوند. سیگنال‌های بازسازی شده به  $(\frac{N}{(60/rpm) \times f_s})$  بخش تقسیم می‌گردد (برای چهار حالت خرابی بیرینگ، ماتریسی با ابعاد  $4 \times 288$  خواهیم داشت) جایی که  $N$  طول سیگنال،  $f_s$  نرخ نمونه‌برداری و rpm دور موتور است. ۱۰ مشخصه در حوزه زمان را برای هر بخش سیگنال ارتعاشی محاسبه و داده‌ها نرمالایز می‌گردد (که ابعاد ماتریس نهایی  $10 \times 1152$  خواهد بود). در این مقاله ۷۰ درصد کل داده‌ها (ماتریسی با ابعاد  $10 \times 808$ ) به صورت تصادفی برای آموزش و ۳۰ درصد باقی‌مانده (ماتریسی با ابعاد  $10 \times 344$ ) برای آزمایش در نظر گرفته شده است. ماتریس هدف نیز با ابعاد  $4 \times 808$  برای چهار حالت به صورت بردارهای رابطه ۲۱ خواهد بود.

$$\begin{array}{l}
 \begin{array}{c} \text{عیب حلقه داخلی} \\ = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \end{array} \\
 \begin{array}{c} \text{عیب حلقه خارجی} \\ = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \end{array} \\
 \begin{array}{c} \text{عیب ساچمه} \\ = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \end{array} \\
 \begin{array}{c} \text{سالم} \\ = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} \end{array}
 \end{array} \quad (21)$$

در مرحله نخست، داده‌های مربوط به آموزش، به عنوان ورودی‌های شبکه عصبی طراحی شده اعمال و شبکه را آموزش داده و در گام بعدی با استفاده از داده‌های آزمایش، خروجی‌های شبکه شبیه‌سازی می‌گردند. تعداد نرون‌های لایه میانی به روش سعی و خطا به طوری که خطای میانگین

مربعات<sup>۴۱</sup> حداقل گردد به دست آمده است. با تعداد نرون ۱۵، کمترین خطا برای شبکه عصبی طراحی شده حاصل می‌شود. جهت مشخص نمودن تعداد و درصد تشخیص درست و نادرستی عیوب از ماتریس درهم آمیختگی بهره برده می‌شود. در جدول ۲ میانگین درصد تشخیص درست عیوب برای ۱۰ بار اجرای شبکه عصبی درج شده است؛ میزان دقت به دست آمده برای شبکه عصبی برابر میانگین کل چهار حالت یعنی ۹۷/۷۵ درصد می‌باشد. جدول ۳ تعداد تشخیص‌های درست و نادرست شبکه عصبی را در قالب ماتریس درهم ریختگی<sup>۴۲</sup> نشان می‌دهد.

جدول ۲. درصد تشخیص عیوب توسط شبکه عصبی با ۱۵ نرون در لایه میانی

| نوع عیب           | میانگین درصد تشخیص عیب |
|-------------------|------------------------|
| سالم              | ۹۵/۱                   |
| عیب در ساچمه      | ۹۷/۹                   |
| عیب در حلقه داخلی | ۱۰۰                    |
| عیب در حلقه خارجی | ۹۸                     |

جدول ۳. ماتریس درهم ریختگی برای عیوب مختلف بیرینگ

|                   | سالم | عیب در ساچمه | عیب در حلقه داخلی | عیب در حلقه خارجی |
|-------------------|------|--------------|-------------------|-------------------|
| سالم              | ۸۲   | ۰            | ۰                 | ۰                 |
| عیب در ساچمه      | ۲    | ۸۴           | ۰                 | ۰                 |
| عیب در حلقه داخلی | ۰    | ۱            | ۸۶                | ۲                 |
| عیب در حلقه خارجی | ۲    | ۱            | ۰                 | ۸۴                |

## ۷. نتیجه‌گیری و پیشنهادات

در این مقاله تکنیک جدید SSA به منظور تحلیل سیگنال ارتعاشی بیرینگ غلتشی در عیوب مختلف با استفاده از مشخصه‌های آماری سیگنال در حوزه زمان پیاده‌سازی و عیوب توسط شبکه عصبی با دقت بالایی طبقه‌بندی گردید. در بخش استخراج مشخصه‌ها نیز می‌توان با استفاده از روش‌های انتخاب مشخصه، تأثیر هر مشخصه را در خروجی شبکه عصبی بررسی نمود و مشخصه‌هایی که حذف آنها تأثیر قابل توجهی در دقت تشخیص شبکه عصبی ندارند را تعیین کرد. این امر به کاهش اندازه شبکه عصبی و در نتیجه

کاهش حجم محاسبات خواهد انجامید. در جدول ۴ مقایسه‌ای میان روش ارائه شده در این مقاله و روش‌های دیگر صورت گرفته است که در تمامی مقاله‌ها داده‌های ارتعاشی استفاده شده از پایگاه داده تست بیرینگ دانشگاه کیس وسترن می‌باشد و برای حالت‌های عیوب مختلف بیرینگ (سالم، عیب ساچمه، عیب در حلقه داخلی و خارجی) در نظر گرفته شده است. مقایسه‌ها میان درصد صحت تشخیص عیوب نشان می‌دهد که روش تحلیل طیف تکین روشی کارآمد و در حین حال از نظر اجرا آسان می‌باشد.

جدول ۴. مقایسه عملکرد روش ارائه شده در این پژوهش با روش های دیگر

| مرجع         | مشخصه عیوب   | میانگین دقت (درصد) | تعداد حالت طبقه بندی ( سالم، عیب ساچمه، عیب در حلقه داخلی و خارجی) | تعداد مجموعه داده آموزش یا آزمایش | نام روش  |
|--------------|--|--------------------|--|-----------------------------------|--|
| [۵]          | ۱- مقادیر تکین<br>۲- انرژی   | ۹۶/۵۳<br>۹۵-۱۰۰    | ۴  | آموزش: ۳۳۶<br>آزمایش: ۱۴۴         | تحلیل طیف تکین و شبکه عصبی پس انتشار پیشرو               |
| [۸]          | ضرایب مدل اتو رگرسیون زمان ثابت خطی  | ۹۸/۸-۱۰۰           | ۴  | آموزش: ۴۶۴<br>آزمایش: ۴۶۴         | تحلیل طیف تکین و اتو رگرسیون                             |
| [۲۳]         | ۶ آنتروپی در مقیاس زمانی متفاوت  | ۹۷/۴۲              | ۴  | آموزش: ۵۲۵<br>آزمایش: ۲۳۷         | آنتروپی چند مقیاس و ماشین بردار پشتیبان                  |
| [۲۳]         | مقدار موثر، چولگی و مقدار کرتوسیس و ماکزیمم  | ۷۵/۶۴              | ۴  | آموزش: ۵۲۵<br>آزمایش: ۲۳۷         | ویژگی های حوزه زمان و ماشین بردار پشتیبان                |
| [۲۴]         | ۴ مدل ترکیب گوسی   | ۸۱-۱۰۰             | ۴  | آموزش: ۳۸۴<br>آزمایش: ۳۸۴         | بازسازی فضای فاز، طبقه بندی کننده مدل ترکیب گوسی و بیزین |
| [۲۵]         | شاخص توان و ۱۷ بردار مرجع  | ۹۶                 | ۴  | آموزش: ۹۴۰<br>آزمایش: ۹۴۰         | مدل مخفی مارکوف و خوشه بندی میانگین $k$                  |
| [مقاله حاضر] | میانگین، مقدار پیک، انحراف معیار، مقدار موثر، فاکتور کرسست، فاکتور ضربه، فاکتور شکل، فاکتور لقی، چولگی و مقدار کرتوسیس | ۹۵/۱-۱۰۰           | ۴  | آموزش: ۸۰۸<br>آزمایش: ۳۴۴         | تحلیل طیف تکین و شبکه عصبی پس انتشار پیشرو               |

## ۸. مأخذ

- [1] Alessio, S. M., "Digital signal processing and spectral analysis for scientists: concepts and applications", Springer, 2015.
- [2] Ghil, M., Allen, M. R., Dettinger, M. D., Ide, K., Kondrashov, D., Mann, M. E., & Yiou, P., "Advanced spectral methods for climatic time series", *Reviews of geophysics*, vol.40, no.1, 2002
- [3] Alonso, F. J., & Salgado, D. R., "Analysis of the structure of vibration signals for tool wear detection", *Mechanical Systems and Signal Processing*, vol.22, no.3, 2008, pp.735-748.

- [4] Wang, W. J., Chen, J., Wu, X. K., & Wu, Z. T., "The application of some non-linear methods in rotating machinery fault diagnosis", *Mechanical Systems and Signal Processing*, vol.15, no.4, 2001, pp.697-705.
- [5] Muruganatham, B., Sanjith, M. A., Krishnakumar, B., & Murty, S. S., "Roller element bearing fault diagnosis using singular spectrum analysis" *Mechanical systems and signal processing*, vol.35, no.1-2, 2013, pp.150-166.
- [6] Golafshan, R., & Sanliturk, K. Y., "SVD and Hankel matrix based de-noising approach for ball bearing fault detection and its assessment using artificial faults", *Mechanical Systems and Signal Processing*, 70, 2016, pp.36-50.
- [7] Kilundu, B., Chimentin, X., & Dehombreux, P., "Singular spectrum analysis for bearing defect detection", *Journal of vibration and acoustics*, vol.133, no.5, 2011, p.051007.
- [8] Al-Bugharbee, H., & Trendafilova, I., "A fault diagnosis methodology for rolling element bearings based on advanced signal pretreatment and autoregressive modelling", *Journal of Sound and Vibration*, vol.369, 2016, pp.246-265.
- [9] Yan, R., Gao, R. X., & Chen, X., "Wavelets for fault diagnosis of rotary machines: A review with applications" *Signal processing*, vol.96, 2014, pp.-15.
- [10] Kankar, P. K., Sharma, S. C., & Harsha, S. P., "Fault diagnosis of rolling element bearing using cyclic autocorrelation and wavelet transform", *Neurocomputing*, vol.110, 2013, pp.9-17.
- [11] Kumar, S. S., & Kumar, M. S., "Application of Artificial Neural Network in the Investigation of Bearing Defects", *World Academy of Science, Engineering and Technology, International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*, vol.9, no.8, 2015, pp. 1113-1116.
- [12] Rafiee, J., Arvani, F., Harifi, A., & Sadeghi, M. H., "Intelligent condition monitoring of a gearbox using artificial neural network", *Mechanical systems and signal processing*, vol.21, no.4, 2007, pp.1746-1754.
- [13] I. Attoui, N. Fergani, N. Boutasseta, B. Oudjani, and A. Deliou, "A new time–frequency method for identification and classification of ball bearing faults," *Journal of Sound and Vibration*, vol.397, 2017, pp.241-265.
- [14] Loparo, K. A., "Bearing data center", *Case Western Reserve University*, 2013.
- [15] Abbasion, S., Rafsanjani, A., Farshidianfar, A., & Irani, N., "Rolling element bearings multi-fault classification based on the wavelet denoising and support vector machine" *Mechanical Systems and Signal Processing*, vol.21, no.7, 2007, pp.2933-2945.
- [16] Golyandina, N., & Zhigljavsky, A., "Basic SSA", *Singular Spectrum Analysis for Time Series* Springer, Berlin, Heidelberg, 2013, pp.11-70).
- [17] Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. A., "Analysis of time series structure: SSA and related techniques", Chapman & hall crc monographs on statistics & applied probability, 2001.
- [18] Elsner, J. B., & Tsonis, A. A., "Singular spectrum analysis: a new tool in time series analysis", Springer Science & Business Media, 2013.
- [19] Zhang, X., Wang, B., & Chen, X., "Intelligent fault diagnosis of roller bearings with multivariable ensemble-based incremental support vector machine", *Knowledge-Based Systems*, vol.89, 2015, pp.56-85.
- [20] Sreejith, B., Verma, A. K., & Srividya, A., "Fault diagnosis of rolling element bearing using time-domain features and neural networks", In *Industrial and Information Systems, 2008. ICIIS 2008. IEEE Region 10 and the Third international Conference on* (pp.1-6). IEEE.
- [21] Demuth, H., Beale, M., & Hagan, M., "Neural network toolbox™ 6." *User's guide*, 10, 11, 2008.

- [22] M. T. Hagan, H. B. Demuth, M. H. Beale, and O. D. Jesús, “*Neural Network Design*”, 2 ed. US: Martin Hagan, 2014.
- [23] Xiong, G. L., Zhang, L., Liu, H. S., Zou, H. J., & Guo, W. Z., “A comparative study on ApEn, SampEn and their fuzzy counterparts in a multiscale framework for feature extraction” *Journal of Zhejiang University SCIENCE A*, vol.11, no.4, 2010, pp.270-279.
- [24] Wang, G. F., Li, Y. B., & Luo, Z. G., “Fault classification of rolling bearing based on reconstructed phase space and Gaussian mixture model”, *Journal of Sound and Vibration*, vol.323, no.3-5, 2009, pp.1077-1089.
- [25] Boutros, T., & Liang, M., “Detection and diagnosis of bearing and cutting tool faults using hidden Markov models” *Mechanical Systems and Signal Processing*, vol.25, no.6, 2011, pp.2102-2124.

پی نوشت:

1. Singular Spectrum Analysis (SSA)
2. Artificial Neural Networks (ANN)
3. Short Time Fourier Transformation
4. Envelope Analysis
5. Wavelet Transformation
6. Singular Spectrum Analysis (SSA)
7. Embedding
8. Singular Value Decomposition (SVD)
9. Diagonal Averaging
10. Grouping
11. Back Propagation Neural Network (BPNN)
12. Healthy
13. Inner Raceway Fault
14. Outer Raceway Fault
15. Ball Fault
16. Case Western Reserve University (CWRU)
17. Drive End
18. Load Zone
19. Window Length
20. Lag
21. Trajectory Matrix
22. Lagged Vectors
23. Hankel Matrix
24. Singular Value (SV)
25. Weighted Correlation
26. Average
27. Peak Value
28. Standard Deviation
29. Root Mean Square
30. Crest Factor
31. Impulse Factor
32. Shape Factor
33. Clearance Factor
34. Skewness
35. Kurtosis Value
36. Feature Scaling
37. Feed-Forward Back Propagation
38. Levenberg-Marquardt
39. Targets
40. Outputs
41. Mean Squared Error
42. Confusion Matrix