



کاهش نویز سیگنال‌های ارتعاشی بر اساس تحلیل طیف تکین و عیب‌یابی بلبرینگ‌ها با استفاده از شبکه عصبی

مصنوعی

مهدی حسینیان^{۱،۲} - مهدی صالحی^{۱،۲}

۱- گروه مهندسی مکانیک، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران

۲- مرکز تحقیقات فناوری‌های نوین ساخت و تولید، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، اصفهان، ایران

mehdi.salehi@pmc.iaun.ac.ir

چکیده:

عیب‌یابی و تشخیص خرابی بلبرینگ‌های غلتشی بالاترین اولویت تحلیلگران ارتعاشات است. تاکنون روش‌های بسیاری جهت عیب‌یابی بلبرینگ‌های غلتشی در حوزه فرکانس و نیز زمان-فرکانس ارائه شده است. در این مقاله به بیان یک روش جدید و بسیار کارآمد جهت تشخیص عیوب بلبرینگ‌ها در حوزه زمان می‌پردازیم. بیشتر روش‌های سری زمانی پیچیده و سیگنال‌های استخراجی تحت تأثیر نویز می‌باشند. تحلیل طیف تکین (SSA) به عنوان یک تکنیک کارآمد در زمینه تحلیل سری‌های زمانی می‌باشد که از نظر اجرا آسان و نویزدا است. در این روش سیگنال ارتعاشی اندازه‌گیری هر یک از عیوب بلبرینگ به مؤلفه‌های اساسی تجزیه می‌شوند، که پس از انتخاب تعدادی از مؤلفه‌ها اساسی جهت بازسازی سیگنال ارتعاشی، ویژگی‌های آماری در حوزه زمان از سیگنال بازسازی شده استخراج می‌شوند. این ویژگی‌ها به عنوان ورودی‌های شبکه عصبی مصنوعی (ANN) جهت تشخیص و طبقه‌بندی عیوب بلبرینگ‌ها اعمال می‌گردد. خروجی‌های شبکه عصبی، عیوب بلبرینگ‌ها هستند که با انتخاب تعداد مناسب نرون‌های لایه پنهان (لایه میانی)، حداکثر دقت در تشخیص عیوب حاصل می‌شود. همچنین با اضافه کردن یک نویز سفید گوسی به سیگنال‌ها کارایی روش SSA و میزان دقت شبکه عصبی در عیب‌یابی بررسی گردید. نتایج، پیاده‌سازی موفق و کارآمد تحلیل طیف تکین در عیب‌یابی بلبرینگ‌ها با کمترین خطا را نشان می‌دهد.

کلید واژگان: تحلیل طیف تکین، شبکه عصبی مصنوعی، عیب‌یابی، سیگنال ارتعاشی، بلبرینگ

Noise reduction of vibrational signals based on singular spectrum analysis and fault diagnosis of ball bearing using artificial neural network

Mehdi Hassanian^{1,2}, Mehdi Salehi^{1,2}

1- Department of Mechanical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Esfahan, Iran

2- Modern Manufacturing Technologies Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Esfahan, Iran

†Corresponding Author Email: mehdi.salehi@pmc.iaun.ac.ir

Abstract :

Fault detection and determination of rolling-element bearings is the highest priority in vibration analysis. Various methods have been proposed for fault detection in rolling-element bearings in frequency and time-frequency domains. In this work, a novel and effective method for fault detection in ball bearings in time domain is proposed. Most time domain methods are complex with high noise concentration in extracted signals. Single spectrum analysis (SSA) is an effective and simple to implement technique for noise removal in time domain series. In this method, the vibration signals for measuring each of ball bearing faults are decomposed into their main components and after selecting some of these components for reconstruction of vibration signal, the statistical characteristics of time domain are extracted from the reconstructed signal. These characteristics are used as inputs of Artificial Neural Networks (ANN) for fault detection and classification of ball bearings. The outputs of the ANN are the faults of ball bearings and determining the suitable number of hidden neurons (middle layer) will maximize the accuracy of fault detection. Adding a Gaussian white noise to signals, performance of SSA method and the accuracy of fault detection using ANN were also investigated. The results show the successful and effective implementation of SSA in fault detection of ball bearings with minimum error.

Keywords: Singular spectrum analysis, Artificial neural network, Fault diagnosis, Roller element bearing

در اکثر موارد، سیگنال‌های گرفته شده از ماشین که در دسترس ما قرار دارند سیگنال‌های زمانی هستند، معمولاً تحلیل آنها بسیار سخت و دشوار است. در واقع سیگنال‌های زمانی را باید پردازش کرد تا به سیگنال‌های مطلوب تبدیل شوند و به اطلاعاتی که در آنهاست، دست یافت. روش‌های زمانی هم‌اکنون در صنعت، در مواردی که احتیاج به جابجایی عیب به صورت دقیق نیست استفاده دارند. در عوض از روش‌های فرکانسی بیشتر در مواردی استفاده می‌شود که به دقت و حساسیت بیشتر نیاز است. روش‌های تحلیل سیگنال ارتعاشی در حوزه زمانی می‌تواند کمک شایان توجهی به عیب‌یابی بلبرینگ‌ها و چرخنده‌ها کند. روش‌های حوزه زمان، به علت سادگی و سرعت بالای محاسبه آنها همچنان مورد توجه می‌باشند [۱].

در این میان جایگاه سری‌های زمانی به عنوان یک روش متفاوت و کارآمد خالی به نظر می‌رسد. 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، 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 دلایل گسترش روزافزون استفاده از این روش در علوم مختلف است [۲]. SSA در بسیاری از کاربردها نظیر سیگنال‌های الکترو-میوگرافی (نوار عضله) [۳]، تحلیل داده‌های هواشناسی [۴]، پایش وضعیت [۵]، تشخیص خرابی سایدگی روتور و استاتور [۶] استفاده شده است. در مقاله حاضر نخست به پیشینه عیب‌یابی بلبرینگ‌های غلظتی با این روش اشاره شد. در بخش ۳ به بیان مسئله پرداخته شده، بخش ۴ مبانی تحلیل طیف تکین پرداخته می‌شود بخش ۵ به داده‌های تجربی ارتعاش اختصاص داده شده است. در بخش‌های ۶ و ۷ با استخراج ویژگی‌های سیگنال ارتعاشی در حوزه زمان توسط شبکه عصبی، عیوب بلبرینگ شناسایی و طبقه‌بندی می‌گردد. بحث و نتایج پیاده‌سازی SSA و شبکه عصبی را در بخش ۸ بررسی می‌نماییم. بخش ۹ به نتیجه‌گیری و ارائه پیشنهاد اختصاص یافته است و در پایان مقایسه‌ای میان نتایج مقاله‌های مشابه انجام می‌گردد.

۲- مروری بر تحقیقات انجام شده

پیدایش روش SSA اغلب به مقاله‌های برومهد و کینگ نسبت داده می‌شود [۷]. تحقیق‌های این دو نفر و جذابیت روش SSA منجر به کاربرد آن در حوزه‌های مختلفی از علوم همچون علوم فیزیکی، اقتصادی، زیستی و مهندسی شده است. در این خصوص، بیش از صدها مقاله به نگارش درآمده است که بر اساس نتایج آنها در مدل

بندی بسیاری از داده‌ها، روش SSA در مقایسه با سایر روش‌های موجود، دارای توانمندی بالاتری است.

پلازا و لویز در مطالعه‌ای از دو روش تحلیل تکین مؤلفه‌های اساسی و تحلیل گروهی مؤلفه‌های اساسی همبسته جهت پایش زبری سطح بر مبنای تحلیل طیف تکین برای سیگنال‌های ارتعاشی بوجود آمده در قطعه کار و ابزار برش بهره بردند. تعدادی آزمایش با وضعیت‌های متفاوت جهت ارزیابی پایش زبری سطح انجام شد. ثابت می‌شود تحلیل گروهی مؤلفه‌های اساسی همبسته مؤثرترین روش با پیش‌بینی مطلوب و قابل اطمینان و با هزینه تحلیلی - محاسباتی کمتر می‌باشد [۸].

کیلوندو و همکاران تاثیر پارامترهای سرعت، بار و اندازه عیب بلبرینگ را در تحلیل طیف تکین و تحلیل انولوپ بررسی کرده و طبق مقایسه نشان دادند که ویژگی‌های سیگنال در SSA حساسیت کمتری نسبت به ویژگی‌ای مانند مقدار موثر در تحلیل انولوپ دارند [۹].

البوغرابی و ترندافیلوا از خاصیت کاهش نویز SSA 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 بازناسایی گشتند [۱۰].

گل‌افشان و سانلی‌تورک بر مبنای رویکرد کاهش نویز، به بررسی تجزیه مقادیر تکین و ماتریس هنکل برای عیب‌یابی بلبرینگ‌ها با بکارگیری شبکه عصبی پرداختند [۱۱].

۳- بیان مسئله و روش انجام

در این پژوهش، هدف، استفاده از 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. هر یک از مرحله‌های مذکور نیز شامل دو مرحله است. تجزیه شامل: جایدهی و تجزیه مقادیر تکین؛ بازسازی شامل: میانگین‌گیری قطری و گروه‌بندی. 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 بدست می‌آید که از آن جهت استخراج بردار مشخصه استفاده می‌گردد. از کدنویسی متلب جهت پیاده‌سازی مسئله بهره گرفته شده است. در این تحقیق سیگنال‌های ارتعاشی در حوزه زمان توسط یک شتاب سنج بر پوسته موتور الکتریکی در محل قرار-گیری بلبرینگ‌های غلظتی اندازه‌گیری می‌شود. سیگنال‌های اندازه‌گیری شده شامل: بلبرینگ سالم، بلبرینگ با حلقه داخلی معیوب، بلبرینگ با حلقه خارجی معیوب، بلبرینگ با ساچمه معیوب می‌باشد. در گام بعدی یک سری پارامتر آماری نظیر مقدار مؤثر، انحراف معیار و... به-عنوان مشخصه عیب اختیار و در ورودی یک شبکه عصبی اعمال می-شود؛ خروجی شبکه عصبی، معایب بلبرینگ‌ها می‌باشد.

۴- تحلیل طیف تکین

۴-۱- جایدهی

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

$$f = (x_1, \dots, x_N) \quad (1)$$

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

$$X_i = (x_i, \dots, x_{i+L-1})^T, \quad (1 \leq i \leq K) \quad (2)$$

ماتریس مسیر X به صورت رابطه (۳) بدست خواهد آمد.

$$X = [X_1: \dots: X_K] = (x_{ij})_{i,j=1}^{L,K} = \begin{pmatrix} x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ x_3 & x_4 & x_5 & \dots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{pmatrix} \quad (3)$$

ستون‌های ماتریس مسیر، بردارهای تأخیر 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 نامیده می‌شود [۱۲]. 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.

۴-۲- تجزیه مقدار تکین

در این گام ماتریس مسیر بر اساس SVD تجزیه می‌گردد؛ بدین صورت که اگر $S = XX^T$ یک ماتریس $L \times L$ و $\lambda_1, \lambda_2, \dots, \lambda_L$ مجموعه مقادیر ویژه S به طوری که:

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$$

یکامتعامد متناظر با مقادیر ویژه باشند، SVD ماتریس مسیر را به صورت **Error! Reference source not found.** می‌توان نوشت.

$$X = X_1 + X_2 + \dots + X_d \quad (1)$$

جائیکه d تعداد مقادیر ویژه غیر صفر ماتریس S یا به عبارت دیگر $d=L$ و X_i به صورت (۱) خواهد بود.

$$X_i = \sqrt{\lambda_i} U_i V_i^T, \quad (i = 1, \dots, d) \quad (1)$$

بردار V_i نیز از معادله (۲) بدست خواهد آمد.

$$V_i = X^T U_i / \sqrt{\lambda_i} \quad (2)$$

جزر λ_i مقادیر تکین نامیده می‌شود [۱۲] و تعداد مقادیر تکین غیر صفر، رتبه ماتریس است.

۴-۳- میانگین‌گیری قطری

ماتریس‌های X_i بدست آمده در مرحله تجزیه دارای خاصیت

هنکلی نیستند، بنابراین نمی‌توان با استفاده از آنها تقریبی از سیگنال ارتعاشی اصلی بدست 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 $1 \leq j \leq K$. در واقع مؤلفه‌های اساسی حاصل تجزیه ماتریس مسیر و سپس میانگین‌گیری قطری می‌باشند.

(۷)

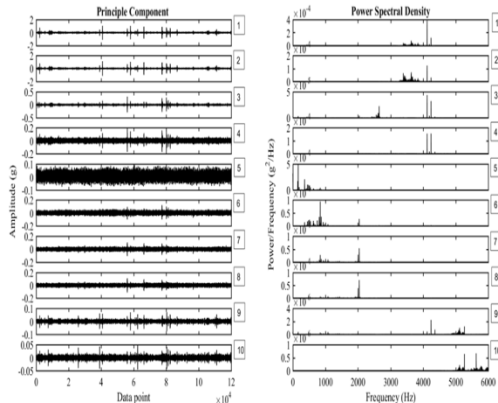
$$g_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m,k-m+1} & \text{for } 1 \leq k \leq L \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+1} & \text{for } L^* \leq k \leq N \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m,k-m+1} & \text{for } K^* < k \leq N \end{cases}$$

$$L^* = \min(L, K) \text{ و } K^* = \max(L, K)$$

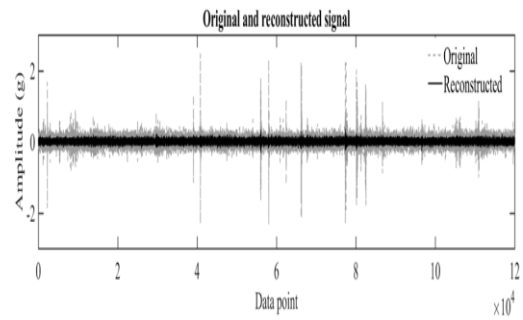
۴-۴- گروه‌بندی

در این مرحله تعدادی از مؤلفه‌های اساسی بدست 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 را دارند برای بازسازی سیگنال ارتعاشی انتخاب می‌گردد. اینکار سبب حذف نویزها می‌شود. 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.

همانطور که در شکل ۱ مشاهده می‌گردد سیگنال اصلی ارتعاش بلبرینگ با عیب در حلقه داخلی به ۱۰ مؤلفه اساسی تجزیه گردیده است و بعد از انتخاب و ترکیب مؤلفه‌های پنجم، ششم، هفتم و هشتم، سیگنال بازسازی شده (شکل ۲) حاصل می‌گردد که نویززدایی هم شده است.



شکل ۱- (الف) مؤلفه‌های اساسی برای حالت عیب در حلقه داخلی (ب) چگالی طیف توان هر کدام از مؤلفه‌های اساسی



شکل ۲- سیگنال ارتعاشی اصلی (خط چین) و بازسازی شده (خط پیوسته) از مؤلفه‌های اساسی پنجم، ششم، هفتم و هشتم برای حالت عیب در حلقه داخلی

۴-۵- تفکیک پذیری

مطالعه تفکیک‌پذیری در SSA نشان می‌دهد که مؤلفه‌ها به چه میزان از هم قابل تفکیک‌اند. فرض کنید که F^1, F^2 دو سری زمانی (در اینجا سیگنال ارتعاشی بازسازی شده و باقیمانده) با طول N و $F = F^1 + F^2$ باشند (مجموع دو سیگنال یعنی سیگنال ارتعاشی اصلی است)، همبستگی وزنی که میزان وابستگی بین این دو سری است به صورت رابطه (۳) تعریف می‌شود؛ جاییکه $F^1 = f_1^2, F^2 = f_1^1$

$$\rho_{12}^{\omega} = \frac{(F^1, F^2)_{\omega}}{\|F^1\|_{\omega} \|F^2\|_{\omega}} = \frac{\sum_{i=1}^N \omega_i f_1^1 f_1^2}{\sqrt{\sum_{i=1}^N \omega_i f_1^1 f_1^1} \sqrt{\sum_{i=1}^N \omega_i f_1^2 f_1^2}} \quad (3)$$

جاییکه ω_i به صورت رابطه (۹) تعریف می‌شود.

$$\omega_i = \begin{cases} i & \text{for } 1 \leq i < L^* \\ L^* & \text{for } L^* \leq i < K^* \\ N - i + 1 & \text{for } K^* \leq i \leq N \end{cases} \quad (5)$$

L^* و K^* در قسمت ۳-۳ تعریف شده است.

اگر قدر مطلق مقدار ρ_{12}^{ω} نزدیک صفر باشد، آن دو سری تفکیک‌پذیری خوبی دارند و اگر قدر مطلق مقدار ρ_{12}^{ω} نزدیک یک باشد گوییم که آنها تفکیک‌پذیری خوبی ندارند [۱۳].

۴-۶- تعیین پارامتر طول پنجره

در مرحله تجزیه، طول پنجره L بایستی مشخص گردد. انتخاب صحیح آن به مسأله بستگی دارد. مقدار خیلی بزرگ L برای سربهای زمانی با ساختار پیچیده ممکن است تجزیه نامناسبی را حاصل کند که باعث تفکیک‌ناپذیری مؤلفه‌های سیگنال ارتعاشی شود [۱۴]. برای تعیین مقدار L ، مقادیر مختلفی را برای آن در نظر گرفته و سیگنال ارتعاشی اصلی را بر اساس آن تجزیه و بازسازی می‌کنیم، سپس همبستگی وزنی سیگنال ارتعاشی بازسازی شده با سیگنال باقیمانده را محاسبه نموده و طول پنجره‌ای که کوچکترین همبستگی وزنی نزدیک صفر را حاصل می‌دهد، به عنوان طول پنجره برگزیده جهت تجزیه و پیاده‌سازی SSA استفاده می‌نماییم. در این تحقیق طول

پنجره 5، 10، 15، 20 برای سیگنال‌ها در نظر گرفته شد که در $L=10$ کوچکترین همبستگی وزنی بدست آمد.

۵- داده‌های ارتعاشی تجربی

سیگنال‌های چهار حالت بلبرینگ سالم (H)، عیب در حلقه داخلی (IF)، عیب در حلقه خارجی (OF) و عیب در ساچمه (BF) از پایگاه داده تست بلبرینگ دانشگاه کیس وسترن رزرو آمریکا استخراج شده است. همانطور که در شکل ۱ مشاهده می‌گردد، بلبرینگ‌های مورد بررسی در این آزمایش درون محفظه بلبرینگ یک موتور الکتریکی با توان ۲ اسب بخار که به‌وسیله یک واسط انتقال دهنده گشتاور به یک توان‌سنج متصل است، قرار دارند. این مجموعه دارای حسگر ارتعاش (شتاب‌سنج)، کارت داده‌برداری و یک کامپیوتر می‌باشد.


عیوب به صورت نقطه‌ای با قطرهای ۰/۱۸ و ۰/۳۶ و ۰/۵۳ میلی‌متر و عمق ۰/۲۸ میلی‌متر بطور جداگانه بر روی هر بلبرینگ در حلقه داخلی، خارجی و روی ساچمه و به روش تخلیه الکتریکی ایجاد شده‌اند (عیب حلقه خارجی در موقعیت‌های ساعت ۱۲، ساعت ۳ و ساعت ۶ می‌باشند). سیگنال‌های ارتعاشی با فرکانس ۱۲ و ۴۸ کیلو هرتز 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) نمونه برداری شده است.

در این تحقیق برای تحلیل و عیب‌یابی از سیگنال‌های ثبت شده با فرکانس ۱۲ کیلو هرتز، با عیوب در سمت شفت خروجی موتور (NDE) و در بزرگترین سایز عیب یعنی ۰/۵۳ میلی‌متر در بی باری در نظر گرفته شده است. برای حلقه خارجی از داده‌های ناحیه بار (ساعت ۶) استفاده گردیده است. شکل ۳ تجهیزات آزمایش بلبرینگ و شکل ۴ اجزاء بلبرینگ را نمایش می‌دهد. مشخصات بلبرینگ در جدول ۱ آمده است.

جدول ۱- مشخصات بلبرینگ سمت NDE؛ بلبرینگ شیار عمیق،

6203-2RS JEM SKF

قطر گام (mm)	قطر ساچمه (mm)	ضخامت (mm)	قطر خارجی (mm)	قطر داخلی (mm)
۲۸/۵	۶/۷	۱۲	۴۰	۱۷



شکل ۳- تجهیزات آزمایش بلبرینگ دانشگاه کیس وسترن رزرو [۱۵]

$$PV = \max|x_n| \quad (11)$$

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

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

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

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

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

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

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


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

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

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

۷- طراحی شبکه عصبی جهت تشخیص عیب

شبکه‌های عصبی کارائی فوق العاده‌ای برای کاربردهایی نظیر تشخیص الگو و طبقه‌بندی دارند. با توجه به خاصیت اصلی شبکه‌های عصبی یعنی بدست آوردن رابطه بین ورودی و خروجی، در این تحقیق از یک شبکه عصبی از نوع پس انتشار پیشرو برای پردازش ویژگی‌های سیگنال ارتعاشی بیرینگ‌ها بدلیل عملکرد مناسب این شبکه‌ها در عیب‌یابی سیستم‌های غیر خطی استفاده می‌شود. در ساختار 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 لوبزگ-مارکوارت، به دلیل همگرایی سریعتر در آموزش شبکه‌ها برای استفاده در تحقیق حاضر انتخاب شده است. البته باید اشاره کرد این الگوریتم به حافظه کامپیوتری بیشتری نیاز دارد. 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 شده ویژگی‌های حوزه زمانی (روابط (۱۰) تا (۱۹)) سیگنال‌های ارتعاش (سیگنال‌های باز سازی شده)



شکل ۴- اجزاء بیرینگ [۱۶]

۶- استخراج ویژگی در حوزه زمان

اکثر مشکلات مکانیکی در بیرینگ‌ها به صورت علائم ارتعاش و یا تغییر در ویژگی‌های ارتعاشی ظاهر می‌گردد. از طرف دیگر هر عیب علائم ارتعاشی مخصوص و منحصر به فرد خود را ایجاد می‌کند. بدین ترتیب می‌توان با استخراج ویژگی هر عیب و سپس تحلیل ارتعاشات به عیوب آن پی برد. برای اجرای برنامه پایش وضعیت و تشخیص عیوب ماشین‌های دوار، قبل از هر چیز انتخاب تعداد کافی از پارامترها و ویژگی‌های مناسب که توانایی توصیف ارتعاشات ماشین را داشته باشند، امری ضروری است. تعداد این ویژگی‌ها در صورتی که بیش از تعداد مورد نیاز انتخاب شوند، منجر به صرف زمان و هزینه مضاعف جهت تحلیل وضعیت ماشین خواهند شد. همچنین اگر تعداد ویژگی‌ها کمتر از تعداد لازم انتخاب شوند، در این صورت اطلاعات کافی برای تشخیص درست عیب به دست نخواهد آمد. یکی از کارآمدترین روشها در استخراج و تعیین این ویژگی‌ها استفاده از پارامترهای آماری در حوزه زمان است. از ویژگی‌های معروف در حوزه زمان می‌توان به ریشه میانگین مربعات، فاکتور کورتوسیس و کرسٹ فاکتور و غیره اشاره کرد. در واقع انتخاب پارامترهای ویژگی مناسب، اصلی‌ترین مسئله در طبقه‌بندی عیوب می‌باشد و انتخاب صحیح آنها موجب بالا رفتن قدرت طبقه‌بندی می‌شود.

در اینجا از ۱۰ ویژگی آماری که از روابط (۱۰) تا (۱۹) بدست می‌آیند و به ترتیب عبارتند از میانگین، مقدار پیک، انحراف معیار، مقدار موثر، فاکتور کرسٹ، فاکتور ضربه، فاکتور شکل، فاکتور لقی، چولگی و مقدار کورتوسیس استفاده می‌شود [۱۷، ۱۸]. این ویژگی‌ها را در محدوده ۰ تا ۱ نرمالایز نموده و به عنوان ورودی شبکه عصبی در نظر می‌گیریم. از روش مقیاس‌گذاری ویژگی برای نرمالایز نمودن داده‌ها استفاده می‌نماییم، که از رابطه (۲۰) بدست می‌آید. محاسبات با استفاده از برنامه نوشته شده در نرم افزار متلب، انجام و بردارهای ویژگی به صورت آماری استخراج شدند.

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

بوده و خروجی‌های شبکه عصبی، عیوب بلبرینگ‌ها (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 داشته و تعداد بهینه نرون‌ها در لایه میانی از سعی و خطا بدست می‌آید. 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 می‌گیریم. همچنین برای تابع کارایی معمول مورد استفاده در شبکه‌های پیشخور از مجموع مربعات خطاها استفاده شده است [۱۹].

$$\text{سالم} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad \text{عیب حلقه داخلی} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix}$$

$$\text{عیب ساچمه} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 0 \end{bmatrix} \quad \text{عیب حلقه خارجی} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \quad (21)$$

از جعبه ابزار nntool در نرم افزار متلب جهت پیاده سازی شبکه عصبی برای تشخیص عیب استفاده شده است. برای این منظور به این صورت عمل می‌شود که بعد از اجرای دستور فوق، داده‌های آموزش، آزمایش و هدف را وارد و سپس نوع شبکه، الگوریتم آموزش، تابع انتقال، تعداد لایه‌ها و نرون‌ها را تعیین کرده و شبکه عصبی را ایجاد می‌نماییم.

در شبکه ایجاد شده با داده‌های آموزش (70 درصد کل داده‌ها) شبکه عصبی را آموزش می‌دهیم و با داده‌های آزمایش (30 درصد کل داده‌ها) عیوب را شبیه‌سازی نموده و در پایان با استفاده از ماتریس درهم‌ریختگی درصد تشخیص صحیح عیوب را بررسی می‌کنیم.

جدول ۲- درصد تشخیص عیوب توسط شبکه عصبی با ۱۹ نرون در لایه میانی

از جعبه ابزار nntool در نرم افزار متلب جهت پیاده سازی شبکه عصبی برای تشخیص عیب استفاده شده است. برای این منظور به این صورت عمل می‌شود که بعد از اجرای دستور فوق، داده‌های آموزش، آزمایش و هدف را وارد و سپس نوع شبکه، الگوریتم آموزش، تابع انتقال، تعداد لایه‌ها و نرون‌ها را تعیین کرده و شبکه عصبی را ایجاد می‌نماییم.

در شبکه ایجاد شده با داده‌های آموزش (70 درصد کل داده‌ها) شبکه عصبی را آموزش می‌دهیم و با داده‌های آزمایش (30 درصد کل داده‌ها) عیوب را شبیه‌سازی نموده و در پایان با استفاده از ماتریس درهم‌ریختگی درصد تشخیص صحیح عیوب را بررسی می‌کنیم.

جدول ۲- درصد تشخیص عیوب توسط شبکه عصبی با ۱۹ نرون در لایه میانی

نوع عیب	میانگین درصد تشخیص عیب
سالم	۹۸/۴۶
عیب در کنس داخلی	۹۸/۸۷
عیب در ساچمه	۹۹/۴۴
عیب در کنس خارجی	۹۹/۷۸

جدول ۳- ماتریس درهم ریختگی برای عیوب مختلف بلبرینگ Pr

	H	IF	BF	OF
H	۸۹	۰	۱	۰
IF	۰	۷۷	۰	۰
BF	۲	۰	۸۶	۰
OF	۰	۰	۰	۸۹

۸- بحث و نتایج

۹- نتیجه‌گیری

۱- با توجه به مطالب و نتایج ذکر شده، یکی از نکات بسیار مهم و اساسی در صنایع مختلف به خصوص صناعی که تجهیزات دواری مثل توربین و کمپرسور دارا می‌باشند، نیاز به داشتن یک سیستم عیب‌یابی به صورت اتوماتیک و هوشمند دانست و از آنجا که روش SSA در مقایسه با سایر روشهای عیب‌یابی نتایج خوب و قابل قبولی را ارائه می‌دهد، می‌تواند به عنوان روشی مناسب در جهت تشخیص هوشمند عیوب به کار برده شود.

۲- تحلیل طیف تکین در از بین بردن نویزها نقش موثری داشته و از نظر اجرا و پیاده سازی آسان می‌باشد.

۳- استفاده از روش SSA برخلاف روش‌های دیگر که منجر به کاهش ابعاد ماتریس ورودی شبکه و در نتیجه از دست دادن بخشی از داده‌ها می‌شود، طول سیگنال ارتعاشی در این روش ثابت می‌ماند.

۴- مطالعات انجام شده نشان می‌دهد شرط اصلی موفقیت در عیب‌یابی این است که ابتدا بایستی شناخت کاملی نسبت به اجزاء مختلف ماشین و فرکانسهای مربوط به هریک از آنها در اختیار داشته، سپس با استفاده از روشهای هوشمند نسبت به طبقه‌بندی عیوب اقدام نمود.

در جدول ۴ مقایسه‌ای میان روش ارائه شده در این تحقیق و روشهای دیگر صورت گرفته است که در تمامی مقاله‌ها، داده‌های ارتعاشی استفاده شده از پایگاه داده تست بلبرینگ دانشگاه کیس وسترن رزرو آمریکا می‌باشد و برای حالت‌های عیوب مختلف بلبرینگ (سالم، عیب ساچمه، عیب در حلقه داخلی و خارجی) در نظر گرفته

در تحقیق حاضر سیگنال‌های ارتعاشی حالت‌های مختلف خرابی بلبرینگ 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. جاییکه N طول سیگنال، f_s نرخ نمونه برداری 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 10×1152 خواهد بود). در این مقاله ۷۰ درصد کل داده‌ها (ماتریسی با ابعاد 10×808) به صورت تصادفی برای آموزش و ۳۰ درصد باقیمانده (ماتریسی با ابعاد

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- مقایسه‌ی عملکرد روش ارائه شده در این پژوهش با روش‌های دیگر

مرجع	مشخصه عیوب	میانگین دقت (درصد)	تعداد حالت طبقه بندی (سال، عیب ساچمه، عیب در کنس داخلی و خارجی)	تعداد مجموعه داده آموزش یا آزمایش	نام روش
[۲۰]	۱- مقادیر تکین ۲- انرژی	۹۶/۵۳-۱۰۰ ۹۵-۱۰۰	۴	آموزش: ۳۳۶ آزمایش: ۱۴۴	تحلیل طیف تکین و شبکه عصبی پس انتشار پیشرو
[۱۰]	ضرایب مدل اتو رگرسیون زمان ثابت خطی	۹۸/۸-۱۰۰	۴	آموزش: ۴۶۴ آزمایش: ۴۶۴	تحلیل طیف تکین و اتو رگرسیون
[۲۱]	۶ آنتروپی در مقیاس زمانی متفاوت	۹۷/۴۲	۴	آموزش: ۵۲۵ آزمایش: ۲۳۷	آنتروپی چند مقیاس و ماشین بردار پشتیبان
[۲۱]	مقدار موثر، چولگی و مقدار کروتوسیسی و ماکزیمم	۷۵/۶۴	۴	آموزش: ۵۲۵ آزمایش: ۲۳۷	ویژگی‌های حوزه زمان و ماشین بردار پشتیبان
[۲۲]	۴ مدل ترکیب گوسی	۸۱-۱۰۰	۴	آموزش: ۳۸۴ آزمایش: ۳۸۴	بازسازی فضای فاز، طبقه‌بندی کننده مدل ترکیب گوسی و بیزین
[۲۳]	شاخص توان و ۱۷ بردار مرجع	۹۶	۴	آموزش: ۹۴۰ آزمایش: ۹۴۰	مدل مخفی مارکوف و خوشه‌بندی میانگین k
[مقاله حاضر]	میانگین، مقدار پیک، انحراف معیار، مقدار موثر، فاکتور کرسر، فاکتور ضربه، فاکتور شکل، فاکتور لقی، چولگی و مقدار کروتوسیسی	۹۹/۱۳	۴	آموزش: ۸۰۸ آزمایش: ۳۴۴	تحلیل طیف تکین و شبکه عصبی پس انتشار پیشرو

- bleshooting for the Process Industries, 2 ed. New Jersey: Pearson Professional Education, 2005.
17. X. Zhang, B. Wang, and X. Chen, "Intelligent fault diagnosis of roller bearings with multivariable ensemble-based incremental support vector machine," *Knowledge-Based Systems*, vol. 89, pp. 56-85, 2015.
 18. B. Sreejith, A. K. Verma, and A. Srividya, "Fault diagnosis of rolling element bearing using time domain features and neural networks," in *2008 IEEE Region 10 and the Third international Conference on Industrial and Information Systems*, pp. 1-6, 2008.
 19. H. Demuth, M. Beale, and M. Hagan. *Neural Network Toolbox™ 6: User's Guide (6 ed.)*, 2010.
 20. B. Muruganatham, M. A. Sanjith, B. Krishnakumar, and S. A. V. Satya Murty, "Roller element bearing fault diagnosis using singular spectrum analysis," *Mechanical Systems and Signal Processing*, vol. 35, pp. 150-166, 2013.
 21. G.-l. Xiong, L. Zhang, H.-s. Liu, H.-j. Zou, and W.-z. Guo, "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, pp. 270-279, 2010.
 22. G. F. Wang, Y. B. Li, and Z. G. Luo, "Fault classification of rolling bearing based on reconstructed phase space and Gaussian mixture model," *Journal of Sound and Vibration*, vol. 323, pp. 1077-1089, 2009.
 23. T. Boutros and M. Liang, "Detection and diagnosis of bearing and cutting tool faults using hidden Markov models," *Mechanical Systems and Signal Processing*, vol. 25, pp. 2102-2124, 2011.
 1. P. Girdhar, *Practical Machinery Vibration Analysis and Predictive Maintenance*, 1 ed. Jordan Hill: IDC Technologies, 2004.
 2. S. M. Alessio, "Singular Spectrum Analysis (SSA)," in *Digital Signal Processing and Spectral Analysis for Scientists: Concepts and Applications*, ed Cham: Springer International Publishing, pp. 537-571, 2016.
 3. J. Barrios-Muriel, F. Romero, F. J. Alonso, and K. Gianikellis, "A simple SSA-based de-noising technique to remove ECG interference in EMG signals," *Biomedical Signal Processing and Control*, vol. 30, pp. 117-126, 2016.
 4. M. Ghil, "Advanced spectral methods for climatic time series," *Reviews of Geophysics*, vol. 40, 2002.
 5. F. J. Alonso and D. R. Salgado, "Analysis of the structure of vibration signals for tool wear detection," *Mechanical Systems and Signal Processing*, vol. 22, pp. 735-748, 2008.
 6. W. J. Wang, J. Chen, X. K. Wu, and Z. T. Wu, "THE APPLICATION OF SOME NON-LINEAR METHODS IN ROTATING MACHINERY FAULT DIAGNOSIS," *Mechanical Systems and Signal Processing*, vol. 15, pp. 697-705, 2001/07/01/ 2001.
 7. H. Hassani, "Singular spectrum analysis: methodology and comparison," *Journal of Data Science*, vol. 5, pp. p. 239-257, 2007.
 8. E. García Plaza and P. J. Núñez López, "Surface roughness monitoring by singular spectrum analysis of vibration signals," *Mechanical Systems and Signal Processing*, vol. 84, pp. 516-530, 2017.
 9. B. Kilundu, X. Chimentin, and P. Dehom-breux, "Singular Spectrum Analysis for Bearing Defect Detection," *Journal of Vibration and Acoustics*, vol. 133, p. 051007, 2011.
 10. H. Al-Bugharbee and I. Trendafilova, "A fault diagnosis methodology for rolling element bearings based on advanced signal pretreatment and autoregressive modelling," *Journal of Sound and Vibration*, vol. 369, pp. 246-265, 2016.
 11. R. Golafshan and K. Yuce Sanliturk, "SVD and Hankel matrix based de-noising approach for ball bearing fault detection and its assessment using artificial faults," *Mechanical Systems and Signal Processing*, vol. 70-71, pp. 36-50, 2016.
 12. N. Golyandina and A. Zhigljavsky, *Singular Spectrum Analysis for Time Series*, 1 ed. Berlin Heidelberg: Springer 2013.
 13. N. Golyandina, V. Nekrutkin, and A. Zhigljavsky, *Analysis of Time Series Structure: SSA and Related Techniques* 1ed. London: Chapman and Hall/CRC, 2001.
 14. J. B. Elsner and A. A. Tsonis, *Singular Spectrum Analysis: A New Tool in Time Series Analysis*, 1 ed. New York: Springer US, 1996.
 15. K. A. Loparo. *Bearing data center*, 2013.
 16. R. C. Eisenmann, *Machinery Malfunction Diag-*