



# ISAV2024

چهاردهمین کنفرانس بین المللی آکوستیک و ارتعاشات  
۲۱ و ۲۲ آذر ماه ۱۴۰۳ کرج - ایران



## تشخیص عیوب بالپین در سیستم تعلیق خودرو با استفاده از شبکه‌های عصبی LSTM

یوسف بهرامی مسیبی<sup>۱</sup>، میرمحمد اتفاق<sup>۲</sup>، رضا حسن نژاد قدیم<sup>۳\*</sup>

<sup>۱</sup> ایران، تبریز، بلوار ۲۹ بهمن، دانشگاه تبریز، دانشکده مهندسی مکانیک، کدپستی ۱۴۷۶۶-۵۱۶۶۶، دانشجوی دکتری.

<sup>۲</sup> ایران، تبریز، بلوار ۲۹ بهمن، دانشگاه تبریز، دانشکده مهندسی مکانیک، کدپستی ۱۴۷۶۶-۵۱۶۶۶، دانشیار.

\*پست الکترونیکی نویسنده مسئول: [hassannejhad@tabrizu.ac.ir](mailto:hassannejhad@tabrizu.ac.ir)

### چکیده

با توجه به پیشرفت علم و تکنولوژی، نیاز صنعت به ارتقا تجهیزات و دستگاه‌های پیشرفته بیش از پیش مورد توجه است. در تولید قطعات مکانیکی، عیب‌یابی قطعات تولیدی بخش حیاتی از روند تولید را تشکیل می‌دهد و تفکیک قطعات سالم از قطعات معیوب پیش از عرضه محصول نهایی از اهمیت زیادی برخوردار می‌باشد. قطعات بالپین قطعه‌ای حساس و حیاتی در سیستم تعلیق خودرو می‌باشند. مشخص است که بروز عیب در سیستم تعلیق خودرو، خسارت جانی و مالی زیادی به خودرو و سرنشینان آن حین رانندگی وارد می‌کند. امروزه تحقیقات بسیاری برای عیب‌یابی هوشمند قطعات مکانیکی توسط روش‌های نوین انجام گرفته است ولی تاکنون روشی برای عیب‌یابی بالپین ارائه نشده است. در این پژوهش به کمک روش‌های مبتنی بر آنالیز فرکانسی و شبکه‌های عصبی، یک روش عیب‌یابی هوشمند برای بالپین‌ها پیشنهاد شده است. در روش پیشنهادی، ابتدا سیگنال‌های آکوستیکی از بالپین اخذ شده و محتوای فرکانسی آن استخراج می‌شود. سپس محتوای فرکانسی استخراج شده به عنوان ورودی به یک شبکه عصبی LSTM اعمال می‌شود. این شبکه عصبی با هدف تفکیک قطعات سالم و معیوب آموزش داده می‌شود. ارزیابی روش هوشمند پیشنهادی با استفاده از بالپین‌های بدست آمده از یک خط تولید صنعتی انجام شده است. نتایج حاصل از تست تجربی روش پیشنهادی نشان می‌دهد که دقت عیب‌یابی این روش هوشمند ۱۰۰ درصد بوده و قابلیت تشخیص دقیق عیوب بالپین را دارد.

**کلمات کلیدی:** عیب‌یابی؛ سیستم تعلیق؛ شبکه عصبی LSTM؛ بالپین.

## ۱- مقدمه

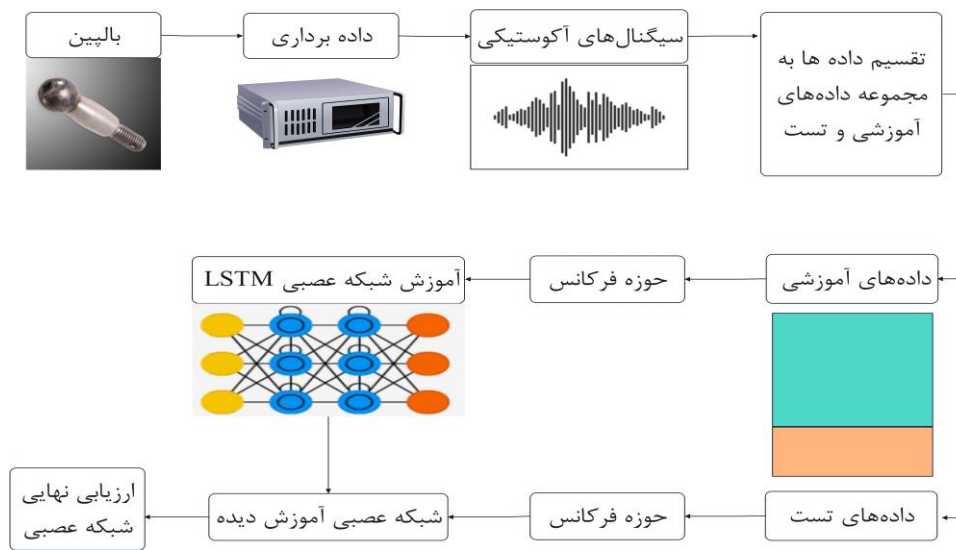
با توجه به رشد صنعت خودرو در عصر حاضر و اهمیت تعیین کننده فاکتورهای امنیت و هزینه، لزوم پایش وضعیت و عیب‌یابی قطعات خودرو بیش از پیش احساس می‌شود [۱]. سیستم تعلیق خودرو یک بخش اساسی در خودرو می‌باشد که نقش حیاتی‌ای در پایداری، کنترل و راحتی خودرو ایفا می‌کند [۲]. یکی از مهم‌ترین و حساس‌ترین قطعات مورد استفاده در سیستم تعلیق خودروها قطعه‌ای به نام بالپین می‌باشد [۳]. بنابراین وقوع خرابی در بالپین خودرو می‌تواند منجر به از دست رفتن کنترل خودرو و تلفات جانی و مالی بسیاری شود. در همین راستا، کنترل کیفی این قطعه در حین فرآیند تولید و تشخیص عیوب آن از اهمیت بسیار زیادی برخوردار است.

متخصصین روش‌های مختلفی را برای عیب‌یابی و پایش وضعیت ماشین آلات مکانیکی ارائه و استفاده کرده‌اند [۴]. در این راستا، روش‌های عیب‌یابی مبتنی بر ارتعاشات و آکوستیک به عنوان پرکاربردترین روش عیب‌یابی قطعات مکانیکی شناخته می‌شود [۵]. همچنین در سالهای اخیر با گسترش کاربرد هوش مصنوعی در زمینه‌های مختلف، روش‌های عیب‌یابی بسیاری بر اساس هوش مصنوعی و شبکه‌های عصبی مصنوعی توسعه یافته‌اند [۶]. روش‌های مبتنی بر شبکه‌های عصبی به دلیل هوشمند بودن و همچنین سرعت و دقت بسیار بالاتر در مقایسه با دیگر روش‌ها، توجه بسیاری از محققان را به خود جلب کرده است [۷]. از روش‌های مبتنی بر شبکه‌های عصبی که برای عیب‌یابی قطعات مکانیکی ارائه شده است می‌توان به تحقیقی که توسط فرناندز و همکارانش [۸] انجام شده است اشاره کرد. آنها در کار خود روشی را برای پیش بینی عمر مفید باقیمانده قطعات دستگاه‌های برشی دوار به کمک سیگنال‌های ارتعاشی و با استفاده از شبکه عصبی مصنوعی معرفی کرده‌اند. در یک تحقیق دیگر یو و پین [۹] از شبکه‌های عصبی عمیق کانولوشنی برای عیب‌یابی بلبرینگ‌های استفاده کرده‌اند. روش آنها بر اساس یک طبقه‌بندی هوشمند انتها به آنها توسط شبکه‌های عصبی عمیق برای سیگنال‌های ارتعاشی می‌باشد. با توجه به پیشرفت تجهیزات جنگی، نیاز بیشتری به سرعت و دقت عیب‌یابی تجهیزات جنگی مورد نیاز است که گو و همکارانش [۱۰] در جهت بهبود بخشیدن به عملکرد تجهیزات جنگ افزارها یک الگوریتم عیب‌یابی ماشین آلات دوار را بر اساس شبکه عصبی LSTM<sup>۱</sup> و CNN<sup>۲</sup> طراحی کرده‌اند. در این روش سیگنال‌های ارتعاشی از تجهیزات اخذ شده و به عنوان ورودی شبکه‌های عصبی مورد استفاده قرار می‌گیرند. شبکه‌های عصبی مورد نظر توسط با هدف طبقه‌بندی سیگنال‌ها بر اساس سالم یا معیوب بودن قطعات آموزش داده شده و برای عیب‌یابی آنها مورد استفاده قرار می‌گیرند. کیانو و همکاران [۱۱] برای تشخیص خرابی در بلبرینگ‌های غلطکی که تحت نویزهای شدید و بارهای متغییر قرار دارد یک مدل شبکه عصبی جدید را ارائه داده‌اند. روش آنها بر پایه مدل ورودی دوگانه مبتنی بر شبکه عصبی کانولوشن و شبکه عصبی LSTM است که ورودی آن نیز سیگنال‌های آکوستیکی می‌باشد. خرم و همکاران [۱۲] برای عیب‌یابی هوشمند بلبرینگ‌ها یک شبکه عصبی جدید طراحی کرده‌اند. در این روش برای جلوگیری از کاهش داده‌های ورودی و افزایش دقت عیب‌یابی، از سیگنال‌های ارتعاشی اخذ شده از بلبرینگ‌ها به عنوان ورودی شبکه عصبی استفاده می‌شود. این داده‌ها در یک محدوده زمانی و به روش توالی زمانی انتها به آنها پردازش می‌شوند. با توجه به اینکه خرابی موتور ارتعاشی گوشی‌های هوشمند می‌تواند منجر به کاهش عملکرد آن شود. وانگ و همکاران [۱۳] نیز با ترکیب کردن تبدیل بسته‌های موجک و شبکه‌های عصبی LSTM بهبود یافته، یک روش عیب‌یابی جدید برای تشخیص عیب موتور ارتعاشی گوشی هوشمند ارائه کرده‌اند. همچنین افریدی و همکاران [۱۴] از داده‌های ارتعاشی خام به عنوان ورودی مدل هوشمند خود برای عیب‌یابی بلبرینگ‌ها استفاده کرده‌اند. مدل هوشمند آنها بر اساس شبکه عصبی LSTM طراحی شده است که برای پیش بینی عیوب بلبرینگ‌ها و همچنین طبقه‌بندی آنها بر اساس نوع عیب رخ داده بکار می‌رود.

با بررسی تحقیقات صورت گرفته در زمینه عیب‌یابی قطعات مکانیکی، مشاهده می‌شود که تا کنون روش هوشمندی برای عیب‌یابی بالپین‌ها معرفی نشده است. همچنین، امروزه در بیشتر موارد از اپراتور انسانی و بازرسی چشمی و شنوایی برای کنترل کیفی قطعه بالپین استفاده می‌شود. از جمله مهم‌ترین معایب روش فوق، صرف زمان بیشتر و دقت پایین در تشخیص عیوب می‌باشد. بنابراین از طرفی با توجه به اهمیت بالپین در سیستم تعلیق خودرو و از طرف دیگر با توجه به اینکه تحقیقات قابل توجهی برای عیب‌یابی این

<sup>۱</sup> Long Short-Term Memory<sup>۲</sup> Convolutional Neural Network

قطعه انجام نشده است، هدف از پژوهش حاضر، ارائه یک روش هوشمند برای تشخیص عیوب بالپین می‌باشد. در روش ارائه شده برای شناسایی عیوب بالپین، ابتدا سیگنال‌های آکوستیکی از قطعات مختلف اخذ می‌شود. سیگنال‌های اخذ شده به دو دسته داده‌های آموزشی و داده‌های تست تقسیم می‌شوند. سپس محتوای فرکانسی داده‌های اخذ شده استخراج شده و به عنوان ورودی شبکه عصبی مصنوعی مورد استفاده قرار می‌گیرد. در همین راستا، ابتدا از محتوای فرکانسی داده‌های آموزشی و برچسب آنها (نوع عیب بالپین) برای آموزش شبکه عصبی مصنوعی استفاده می‌شود. پس از پایان یافتن فرایند آموزش شبکه عصبی مصنوعی، وزن‌ها و ابرپارامترهای بهینه شبکه تعیین می‌شود. سپس با داشتن پارامترهای بهینه شبکه عصبی، داده‌های تست به شبکه عصبی مصنوعی اعمال شده، و دقت طبقه‌بندی شبکه عصبی با استفاده از این داده‌ها ارزیابی می‌شود. شبکه عصبی مورد استفاده در تحقیق حاضر یک مدل مبتنی بر شبکه‌های عصبی حافظه طولانی-کوتاه مدت (LSTM) می‌باشد. فلوجارت روش پیشنهادی در شکل (۱) ترسیم شده است.



شکل ۱. فلوجارت روش عیب‌یابی هوشمند پیشنهادی.

## ۲- مواد و روش‌ها

سیگنال‌های آکوستیکی، بیانگر داده‌های یک سری زمانی می‌باشند که داده‌های آن بصورت متوالی پشت سرهم قرار گرفته‌اند. یکی از محدودیت‌های روش‌های سنتی، ناتوانی آنها در مدلسازی خواص توالی در یک سیگنال اخذ شده توسط سنسور است [۱۵]. علاوه بر این مدل‌هایی که قابلیت پردازش داده‌های متوالی را دارند، دارای مشکل وابستگی بلندمدت می‌باشند [۱۶]. مشکل وابستگی بلندمدت به این معنی است که شبکه داده‌های فعلی را حفظ می‌کند و داده‌های قبلی را فراموش می‌کند، درحالی‌که داده‌های فراموش شده در آموزش شبکه مورد نیاز است [۱۵]. به منظور حل چالش وابستگی‌های بلندمدت، استفاده از شبکه‌های عصبی بازگشتی (RNN) در پردازش سری‌های زمانی، گسترش قابل ملاحظه‌ای پیدا کرده است [۱۷]. علیرغم اینکه شبکه‌های عصبی بازگشتی قابلیت حفظ ورودی‌های مرحله قبل در طول شبکه را دارند، ولیکن دارای مشکل ناپدید شدن گرادیان می‌باشند. در همین راستا برای حل مشکل شبکه‌های عصبی بازگشتی، شبکه‌های حافظه طولانی کوتاه-مدت که به اختصار از آن به عنوان LSTM یاد می‌شود معرفی شده‌اند [۱۲].

شبکه‌های LSTM در واقع نوعی خاصی از شبکه‌های عصبی بازگشتی می‌باشند که از افزایش یا کاهش بیش از حد گرادیان جلوگیری می‌کنند. علاوه بر این، شبکه عصبی LSTM به دلیل داشتن یک سلول حافظه خاص، می‌تواند مشکل وابستگی‌های بلندمدت را نیز برطرف کند. در واقع ایده اصلی LSTM یک منطق دروازه‌دار است، که یک معماری مبتنی بر حافظه را امکان‌پذیر می‌سازد [۱۲]. یک سلول از شبکه LSTM دارای سه دروازی اصلی شامل دروازه‌ی فراموشی، دروازه‌ی ورودی و دروازه‌ی خروجی است. چنانچه در

شکل (۲) نیز نمایش داده شده است، این سه دروازه به ترتیب برای سه عملیات فراموش کردن اطلاعات غیر مرتبط، اضافه/بروزرسانی کردن اطلاعات جدید و انتقال اطلاعات بروزرسانی شده مورد استفاده قرار می‌گیرند.

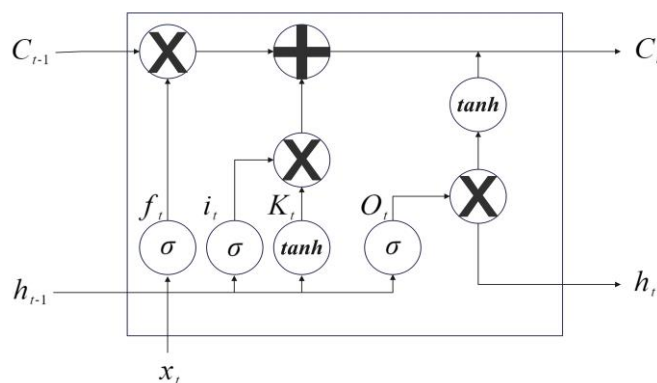


شکل ۲. ساختار کلی یک سلول LSTM.

در شکل (۲)،  $C_{t-1}$  و  $h_t$ ،  $C_t$ ،  $h_{t-1}$  به ترتیب بیانگر وضعیت سلول در زمان قبلی، وضعیت پنهان در زمان قبلی، وضعیت سلول در زمان فعلی و وضعیت پنهان در زمان فعلی می‌باشند. وضعیت سلول حامل اطلاعات اصلی است که در کار حاضر معادل داده‌های موجود در سیگنال آکوستیکی می‌باشند. وضعیت سلول با عنوان حافظه بلندمدت نیز شناخته می‌شود. وضعیت پنهان نیز به عنوان حافظه کوتاه مدت شناخته می‌شود. جزئیات دقیقتر از یک سلول LSTM در شکل (۳) نمایش شده است. در اولین مرحله از یک سلول LSTM، دروازه فراموشی در مورد حفظ یا فراموش کردن داده‌های قبلی تصمیم‌گیری می‌کند. این فرآیند با عملیات ریاضی زیر انجام می‌شود:

$$f_t = \sigma(W_{ff} \cdot h_{t-1} + W_{fx} \cdot x_t) \quad (1)$$

که در آن  $h_{t-1}$  وضعیت پنهان در گام زمانی قبلی و  $x_t$  اطلاعات ورودی در زمان فعلی می‌باشند. در تمامی روابط،  $W_{mm}$  ماتریس وزن‌هایی می‌باشد که  $m$  را به  $n$  متصل می‌کند.  $\sigma$  نیز بیانگر تابع غیر خطی سیگموئید می‌باشد.



شکل ۳. جزئیات عملکرد یک سلول LSTM.

با اعمال تابع سیگموئید، خروجی دروازه فراموشی  $f_t$  به مقداری بین صفر تا یک نگاشت می‌شود. پس از محاسبه خروجی دروازه فراموشی، این مقدار در وضعیت سلول گام زمانی قبلی ضرب می‌شود تا مقدار اطلاعاتی که باید حفظ یا فراموش شوند تعیین گردد. مشخصاً اگر مقدار  $f_t$  برابر صفر باشد، تمام اطلاعات سلول قبلی فراموش شده و اگر مقدار آن برابر یک باشد، تمام اطلاعات سلول قبلی حفظ می‌شود. در مرحله دوم، محاسبات دروازه ورودی انجام شده و در مورد داده‌های جدیدی که می‌بایست در وضعیت

سلول ذخیره شوند تصمیم گیری می‌شود. این مرحله از دو بخش تشکیل می‌شود. بخش اول یک لایه سیگموئید و بخش دوم یک لایه  $\tanh$  است که به بخش اول اضافه می‌شود. روابط دروازه ورودی بصورت زیر است:

$$i_t = \sigma(W_{ih}.h_{t-1} + W_{ix}.x_t) \quad (۲)$$

$$K_t = \tanh(W_{kh}.h_{t-1} + W_{kx}.x_t) \quad (۳)$$

$$C_t = f_t \times C_{t-1} + i_t \times K_t \quad (۴)$$

که در روابط فوق لازم به ذکر است که تابع  $\tanh$  مقادیری در بازه  $-1$  تا  $+1$  تولید می‌کند. بر اساس مقدار  $K_t$  در روابط فوق، برخی از اطلاعات به به وضعیت سلول اضافه یا از آن کم می‌شوند. به این صورت که برای مقادیر منفی  $K_t$  داده‌های ورودی از وضعیت سلول کم شده و برای مقادیر مثبت  $K_t$  داده‌های ورودی به وضعیت سلول اضافه می‌شوند. در مرحله سوم و آخر، در مورد اینکه چه مقادیری از حالت سلول به خروجی سلول منتقل شوند تصمیم گیری می‌شود. این مرحله که محاسبات مربوط به دروازه خروجی را شکل می‌دهد، در واقع عملیات فیلترکردن اطلاعات ورودی می‌باشد. ابتدا مطابق با رابطه زیر یک تابع سیگموئید به وضعیت سلول اعمال می‌شود:

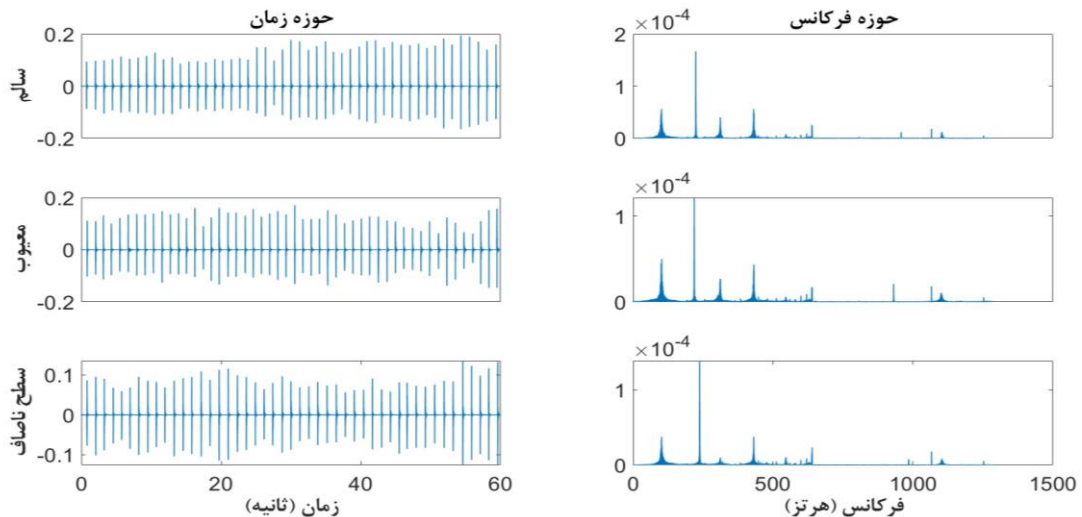
$$O_t = \sigma(W_{oh}.h_{t-1} + W_{ox}.x_t) \quad (۵)$$

سپس تابع  $\tanh$  به وضعیت سلول در گام زمانی فعلی اعمال شده و در خروجی لایه سیگموئید ضرب می‌شود تا وضعیت پنهان  $h_t$  در گام زمانی فعلی محاسبه گردد. بنابراین وضعیت پنهان در گام زمانی فعلی، تابعی از خروجی زمان فعلی و وضعیت سلول در گام زمانی فعلی می‌باشد.

برای آموزش شبکه‌های عصبی مصنوعی، معمولاً از قاعده پس انتشار خطا استفاده می‌شود. در این قاعده ابتدا داده‌های آموزشی وارد شبکه عصبی می‌شوند. سپس محاسبات مربوط به تمام لایه‌ها انجام شده و خروجی شبکه عصبی مصنوعی محاسبه می‌گردد. در این مرحله میزان خطای خروجی شبکه و خروجی مورد انتظار با استفاده از یک تابع خطا محاسبه می‌گردد. در صورتی که میزان خطا از یک مقدار از پیش تعیین شده بیشتر باشد، مقدار خطا در طول یک فرآیند بازگشتی، به کل شبکه عصبی پس انتشار داده می‌شود. در طول فرآیند پس انتشار خطا، مقدار گرادیان خروجی هر لایه از شبکه عصبی نسبت به وزن‌های آن لایه محاسبه می‌گردد. بنابراین با در دست داشتن گرادیان‌های هر لایه از شبکه عصبی، از الگوریتم‌های مبتنی بر گرایان برای تعیین وزن‌های بهینه آن لایه استفاده می‌شود. این فرآیند تا زمانی که خطای شبکه به یک مقدار مشخص همگرا شده و یا تعداد تکرارهای الگوریتم (اپوک‌ها) از یک حد مشخصی بیشتر شوند ادامه می‌یابد. در پایان فرآیند آموزش، مقادیر بهینه برای وزن‌های هر لایه از شبکه عصبی تعیین می‌گردند. در کار حاضر الگوریتم بهینه‌سازی در نظر گرفته شده برای قاعده پس انتشار، الگوریتم بهینه سازی آدام می‌باشد. جزئیات مربوط به این الگوریتم در مرجع [۱۸] بیان شده است.

### ۳- نتایج تجربی

برای ارزیابی روش ارائه شده در تحقیق حاضر، از بالپین‌هایی با شرایط عیب مختلف استفاده شده است. بالپین‌های مورد بررسی از سه دسته سالم، معیوب و قطعات دارای سطح ناصاف تشکیل شده‌اند. برای فرآیند داده‌برداری، از روش تست ضربه استفاده شده است. مدت زمان تست هر قطعه یک دقیقه در نظر گرفته شده و فرکانس نمونه‌برداری میکروفن آکوستیکی نیز ۲۵.۶ کیلوهرتز می‌باشد. سیگنال‌های اخذ شده از بالپین‌های با شرایط عیب مختلف در دو حوزه زمان و فرکانس نیز در شکل (۴) نمایش داده شده است.



شکل ۴. سیگنال‌های اخذ شده از بالپین‌ها با شرایط عیب مختلف.

با توجه به این مسئله که تقریباً هر  $\frac{1}{3}$  ثانیه یک ضربه چکش به قطعات اعمال شده است، هر یک از سیگنال‌های آکوستیکی یک دقیقه‌ای به ۴۵ سیگنال  $\frac{1}{3}$  ثانیه‌ای تقسیم شده است. بنابراین در نهایت تعداد ۱۳۵ سیگنال در دست خواهد بود. از این مقدار دو سوم از داده‌ها (۹۰ سیگنال) برای آموزش شبکه‌ها و یک سوم باقی مانده (۴۵ سیگنال) برای تست شبکه‌ها در نظر گرفته شده است. برای ارزیابی شبکه عصبی LSTM در تشخیص عیوب بالپین، سه ابر پارامتر اصلی وجود دارند که باید تعیین شوند. این سه پارامتر شامل سرعت یادگیری، تعداد سلول‌های شبکه عصبی LSTM و اندازه دسته‌های آموزشی می‌باشند. عموماً برای تعیین این پارامترها از یک فرایند جستجو استفاده می‌شود. پس از پایان فرایند جستجوی ابر پارامترهای، مقادیر بهینه برای سرعت یادگیری، تعداد سلول‌های شبکه عصبی و اندازه دسته‌ها به ترتیب برابر  $0.005$ ،  $300$  و  $18$  تعیین شده است. با آموزش شبکه عصبی LSTM با پارامترهای بهینه تعیین شده، دقت  $100\%$  درصد برای هر دو گروه داده آموزشی و تست بدست می‌آید. بنابراین روش پیشنهادی قادر به شناسایی دقیق و بی نقص عیوب بالپین می‌باشد. به منظور مقایسه روش پیشنهادی با روش‌های مشابه، سیگنال‌های مورد بررسی با شبکه عصبی پرسپترون نیز مورد بررسی قرار گرفته‌اند. شبکه عصبی پرسپترون یکی از مشهورترین شبکه‌های عصبی طبقه بندی کننده است. پس آموزش شبکه عصبی پرسپترون با استفاده از داده‌های فرکانسی بالپین، این شبکه عصبی دقت  $100\%$  درصد برای داده‌های آموزشی و دقت  $95.55\%$  درصد را برای داده‌های تست بدست می‌دهد. بنابراین مشخص است که روش پیشنهادی عملکرد بهتری را نسبت به روش مورد مقایسه دارد. برای بررسی‌های دقیق‌تر، ماتریس درهم ریختگی روش پیشنهادی و شبکه عصبی پرسپترون در شکل (۵) نمایش داده شده است.

تست			آموزش			کلاس صحیح
۱۰۰%	۰	۰	۱۰۰%	۰	۰	
۰	۱۰۰%	۰	۰	۱۰۰%	۰	سطح ناصاف
۱۳%	۰	۸۷%	۰	۰	۱۰۰%	سالم
کلاس پیش‌بینی شده			کلاس پیش‌بینی شده			

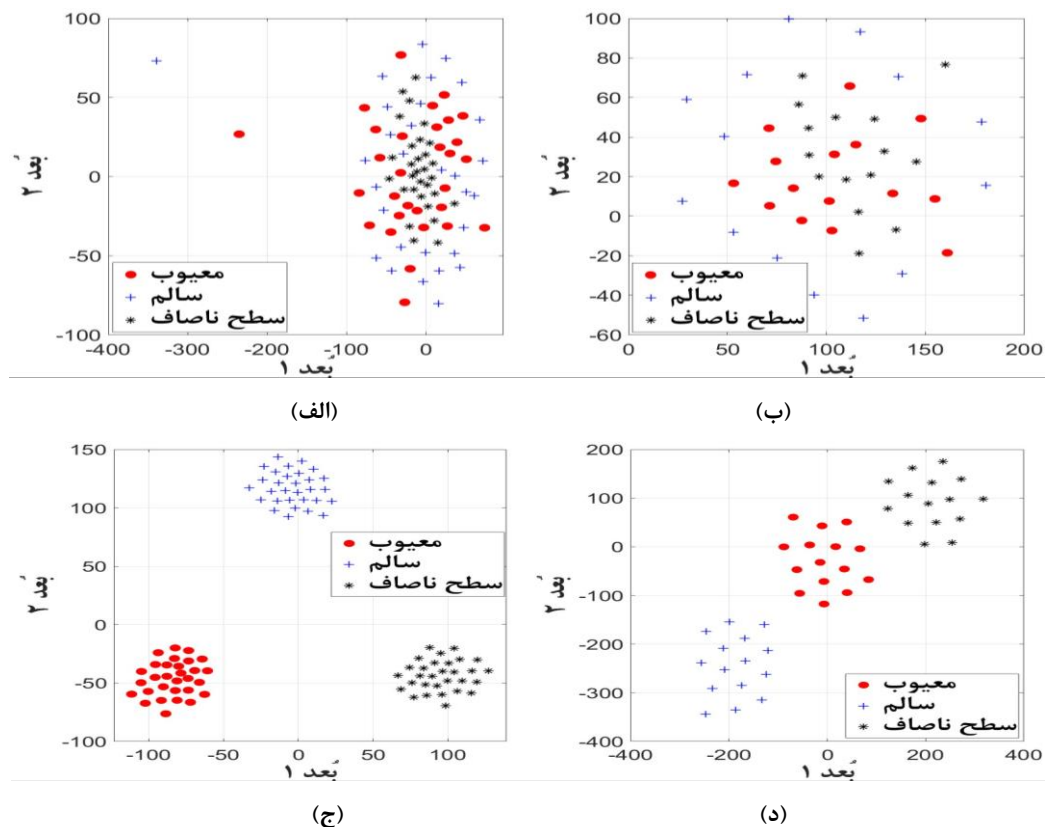
(ب)

تست			آموزش			کلاس صحیح
۱۰۰%	۰	۰	۱۰۰%	۰	۰	
۰	۱۰۰%	۰	۰	۱۰۰%	۰	سطح ناصاف
۰	۰	۱۰۰%	۰	۰	۱۰۰%	سالم
کلاس پیش‌بینی شده			کلاس پیش‌بینی شده			

(الف)

شکل ۵. ماتریس درهم‌ریختگی برای روش پیشنهادی (ب) شبکه عصبی پرسپترون.

با بررسی دقیق شکل (۵) مشخص است که روش پیشنهادی، در طبقه‌بندی سیگنال‌های بالپین عملکرد بهتری نسبت به شبکه عصبی پرسپترون دارد. در ادامه نمودار داده‌های اولیه ورودی به شبکه عصبی و همچنین خروجی شبکه عصبی LSTM پس از کاهش ابعاد آنها در شکل (۶) نمایش داده شده است.



شکل ۶. نمودار داده‌ها پس از کاهش ابعاد (الف) داده‌های آموزشی (ب) داده‌های تست (ج) خروجی روش پیشنهادی برای داده‌های آموزشی (د) خروجی روش پیشنهادی برای داده‌های تست.

با بررسی دقیق شکل (۶) مشخص می‌شود که داده‌های اولیه (هر دو گروه داده آموزش و تست) کاملاً با یکدیگر مخلوط شده و تفکیک آنها ممکن نیست. به بیان دیگر ویژگی‌های آنها کاملاً باهم‌دیگر همپوشانی داشته و اجازه تفکیک آنها را نمی‌دهد. چنانچه در شکل (۶-ج) و شکل (۶-د) نمایش داده شده است، پس از انتقال داده‌های به حوزه فرکانس و اعمال شبکه عصبی LSTM بر روی آنها، داده‌ها مربوط به بالپین با عیوب مختلف کاملاً از یکدیگر تفکیک شده‌اند. بنابراین قدرت طبقه‌بندی روش پیشنهادی کاملاً مشهود می‌باشد.

#### ۴- نتیجه‌گیری

در راستای تشخیص هوشمند عیوب بالپین، در کار حاضر یک روش عیب‌یابی مبتنی بر شبکه‌های عصبی و سیگنال‌های ارتعاشی ارائه شده است. در این روش ابتدا محتوای فرکانسی سیگنال‌های اخذ شده از بالپین‌ها محاسبه شده و سپس از شبکه‌های عصبی مصنوعی برای طبقه‌بندی آنها بر اساس نوع عیب بالپین استفاده شده است. شبکه عصبی مورد استفاده در کار حاضر، شبکه عصبی LSTM می‌باشد. برای ارزیابی روش مورد نظر، بالپین‌هایی با شرایط مختلف (سالم، معیوب و سطح ناصاف) مورد بررسی قرار گرفته‌اند. همچنین روش پیشنهادی به یک روش مشابه دیگر که مبتنی بر شبکه عصبی پرسپترون است، مورد مقایسه قرار گرفته است. نتایج حاصل از آنالیز سیگنال‌های اخذ شده از بالپین‌ها نشان می‌دهد که دقت طبقه‌بندی شبکه عصبی LSTM، ۱۰۰٪ است.

درصد می‌باشد، درحالی‌که دقت طبقه‌بندی شبکه عصبی پرسپترون ۹۵.۵۵ درصد است. دربخش نتایج نشان داده شده است که روش هوشمند مبتنی بر شبکه‌های LSTM، باپین‌های مختلف را بر حسب حالت عیب آن‌ها با بالاترین دقت و کمترین خطا تفکیک می‌کند. با توجه به اینکه روش‌های هوشمند نسبت به روش‌های سنتی (عیب یابی چشمی) سریع تر و بوده و دقت ۱۰۰ درصدی آنها نیز در تحقیق حاضر نشان داده شده است، نتیجه می‌شود که روش پیشنهادی می‌تواند دارای کارکردهای عملی و صنعتی نیز باشد.

## مراجع

- [1] P.A. Balaji, V. Sugumaran, Comparative study of machine learning and deep learning techniques for fault diagnosis in suspension system, *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 45 (2023) 215.
- [2] Y. Wang, X. Zheng, L. Wang, G. Lu, Y. Jia, K. Li, M. Li, Sensor fault detection of vehicle suspension systems based on transmissibility operators and Neyman–Pearson test, *Reliability Engineering & System Safety*, 232 (2023) 109067.
- [3] V.I. Astashchenko, E.V. Purtova, T.V. Shveeva, A.V. Purtov, Development of technology and experience in the production of truck ball pins made of economically alloyed steel, *Yugra State University Bulletin*, 19 (2023) 133-140.
- [4] J.C.A.J. Correa, A.A.L. Guzman, *Mechanical vibrations and condition monitoring*, Academic Press, 2020.
- [5] R.B. Randall, *Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications*, John Wiley & Sons, 2021.
- [6] S. Xie, H. Tan, C. Yang, H. Yan, A review of fault diagnosis methods for key systems of the high-speed train, *Applied Sciences*, 13 (2023) 4790.
- [7] B.A. Tama, M. Vania, S. Lee, S. Lim, Recent advances in the application of deep learning for fault diagnosis of rotating machinery using vibration signals, *Artificial Intelligence Review*, 56 (2023) 4667-4709. 10.1007/s10462-022-10293-3.
- [8] T.F. De Barrena, J.L. Ferrando, A. García, X. Badiola, M.S. de Buruaga, J. Vicente, Tool remaining useful life prediction using bidirectional recurrent neural networks (BRNN), *The International Journal of Advanced Manufacturing Technology*, 125 (2023) 4027-4045.
- [9] W. Yu, P. Lv, An end-to-end intelligent fault diagnosis application for rolling bearing based on MobileNet, *IEEE Access*, 9 (2021) 41925-41933.
- [10] Z. Guo, Y. Hao, H. Shi, Z. Wu, Y. Wu, X. Sun, A fault diagnosis algorithm for the dedicated equipment based on the CNN-LSTM mechanism, *Energies*, 16 (2023) 5230.
- [11] M. Qiao, S. Yan, X. Tang, C. Xu, Deep convolutional and LSTM recurrent neural networks for rolling bearing fault diagnosis under strong noises and variable loads, *Ieee Access*, 8 (2020) 66257-66269.
- [12] A. Khorram, M. Khaloeei, M. Rezghi, End-to-end CNN+ LSTM deep learning approach for bearing fault diagnosis, *Applied Intelligence*, 51 (2021) 736-751.
- [13] R. Wang, Z. Feng, S. Huang, X. Fang, J. Wang, Research on voltage waveform fault detection of miniature vibration motor based on improved WP-LSTM, *Micromachines*, 11 (2020) 753.
- [14] Y.S. Afridi, L. Hasan, R. Ullah, Z. Ahmad, J.-M. Kim, LSTM-Based Condition Monitoring and Fault Prognostics of Rolling Element Bearings Using Raw Vibrational Data, *Machines*, 11 (2023) 531.
- [15] O. Das, D.B. Das, D. Birant, Machine learning for fault analysis in rotating machinery: A comprehensive review, *Heliyon*, 9 (2023).
- [16] S. Mushtaq, M.M. Islam, M. Sohaib, Deep learning aided data-driven fault diagnosis of rotatory machine: A comprehensive review, *Energies*, 14 (2021) 5150.
- [17] R. Sabir, D. Rosato, S. Hartmann, C. Gühmann, LSTM based bearing fault diagnosis of electrical machines using motor current signal, 2019 18th IEEE International conference on machine learning and applications (ICMLA), IEEE, 2019, pp. 613-618.
- [18] Z. Zhang, Improved adam optimizer for deep neural networks. In 2018 IEEE/ACM 26th International Symposium on Quality of Service (IWQoS) 2018 Jun 4 (pp. 1-2), Ieee. doi, 10.