



## عیب یابی جعبه دنده براساس سیگنال صوتی با استفاده از شبکه عصبی پیچشی و تبدیل کاکلیاگرام

بنیامین رمضان پور<sup>۱</sup>، عبدالرضا اوحدی همدانی<sup>۲\*</sup>، فرزانه عبداللهی<sup>۳</sup>

<sup>۱</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی مکانیک، دانشجو کارشناسی ارشد  
<sup>۲\*</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی مکانیک، آزمایشگاه تحقیقاتی آکوستیک، استاد.  
<sup>۳</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی برق، دانشیار.

\*پست الکترونیکی نویسنده مسئول: [a\\_r\\_ohadi@aut.ac.ir](mailto:a_r_ohadi@aut.ac.ir)

### چکیده

عیب یابی با استفاده از سیگنال صدا به علت غیرتماسی بودن سنسورها در مقایسه با عیب یابی با استفاده از سنسورهای تماسی ارتعاشات، در شرایطی که امکان اتصال سنسورها به تجهیزات وجود ندارد، کاربردی تر می باشد. یکی از اساسی ترین چالش ها در استفاده از سیگنال صوتی، تاثیرپذیری نسبتا زیاد آن از نویزهای محیطی است. در این مقاله دو روش پیشنهادی برای کاهش تاثیر نویز محیطی در فرآیند عیب یابی جعبه دنده با چهار عیب مختلف و شدت های متفاوت با استفاده از سیگنال صدا ارائه شده است. در روش اول از تجزیه مود متغیر<sup>۱</sup> برای حذف نویز و داده های غیر ضروری از سیگنال صدا استفاده شده و سپس با استفاده از تبدیل موجک<sup>۲</sup> سیگنال درحوزه زمان به حوزه زمان-فرکانس انتقال داده شده است. در روش دوم برای انتقال سیگنال های صدا حاوی نویز از حوزه زمان به حوزه زمان-فرکانس از تبدیل کاکلیاگرام<sup>۳</sup> استفاده شده است. داده های ایجاد شده در حوزه زمان-فرکانس در هر دو روش برای استخراج ویژگی و کلاس بندی عیوب به یک شبکه عصبی پیچشی<sup>۴</sup> وارد شده اند. میانگین دقت عیب یابی با استفاده از روش کاکلیاگرام برابر ۹۸ درصد می باشد در حالی که میانگین دقت عیب یابی براساس تجزیه مود متغیر و تبدیل موجک برابر ۹۰ درصد است.

**کلمات کلیدی:** عیب یابی جعبه دنده؛ سیگنال صوتی؛ کاکلیاگرام؛ شبکه عصبی پیچشی.

<sup>۱</sup> Variational Mode Decomposition (VMD)

<sup>۲</sup> Wavelet Transform (WT)

<sup>۳</sup> Cochleagram

<sup>۴</sup> Convolutional Neural Network (CNN)

در صنعت، به دلیل اهمیت بالای قطعات و تجهیزات، عیب‌یابی به عنوان یکی از موضوعات حیاتی مطرح می‌باشد. در بسیاری از صنایع، ناپایداری و خرابی در تجهیزات باعث توقف تولید، هزینه‌های اضافی و حتی خطرات برای نیروی کار می‌شود. به همین دلیل، تلاش‌های زیادی برای توسعه سیستم‌های نظارت بر وضعیت تجهیزات و عیب‌یابی صورت گرفته است. در پژوهش‌های پیشین تمرکز بر استفاده از سیگنال ارتعاشات بوده و پژوهش‌های کمتری بر اساس سیگنال صدا صورت پذیرفته است و پژوهش‌هایی که بر اساس سیگنال صدا انجام شده‌اند، در محیط بی‌پژواک انجام شده‌اند که باعث حذف نویز می‌شود که این امر مغایر با شرایطی است که در واقعیت صنعت اتفاق می‌افتد. در پژوهش حاضر عیب‌یابی با بکارگیری سیگنال صوتی و در حضور نویز محیطی انجام می‌شود.

لی و همکاران [1] به تشخیص عیب حفره شدن<sup>۵</sup> در چرخ دنده با استفاده از سیگنال آکوستیک و ارتعاشات پرداختند. در این پژوهش اجتماع دو شبکه عصبی پیچشی و شبکه واحد بازگشتی دردار<sup>۶</sup> جهت کلاس‌بندی سیگنال‌ها استفاده شده است. سیگنال‌های خام ارتعاشات به شبکه واحد بازگشتی دردار و سیگنال‌های خام آکوستیک به شبکه عصبی پیچشی یک بعدی وارد و در نهایت در لایه آخر به هم مرتبط شده و کلاس بندی شدند. دقت این روش برابر ۹۸ درصد می‌باشد که در مقایسه با دقت عیب‌یابی با استفاده از داده‌های ارتعاشات و آکوستیک به صورت جدا که به ترتیب برابر ۹۰ و ۷۵ درصد می‌باشند، بیشتر است. وانگ و همکاران [2] از شبکه پیچشی یک بعدی برای عیب‌یابی بلبرینگ توسط سیگنال‌های خام صدا و ارتعاشات استفاده کردند. این روش می‌تواند انواع مختلف خطاهای بلبرینگ را با استفاده از سیگنال‌های ارتعاشی-آکوستیکی جمع‌آوری شده توسط شتاب‌سنج و میکروفون طبقه‌بندی کند. نتایج آزمایش نشان می‌دهد که این الگوریتم در شرایط نسبت سیگنال به نویز<sup>۷</sup> مختلف، دقت بالاتری در تشخیص عیوب بلبرینگ دارد و به‌ویژه در شرایط نسبت سیگنال به نویز پایین با دقت ۹۸.۸ درصد عملکرد بهتری نسبت به سایر الگوریتم‌ها نظیر بردار ماشین حامی<sup>۸</sup> با دقت ۶۱.۷ درصد دارد.

در سالهای اخیر بخاطر توانایی بالای شبکه عصبی پیچشی در استخراج ویژگی در حوزه زمان-فرکانس و سرعت بالا در عیب‌یابی، توجه ویژه‌ای به این شبکه و تبدیل‌های زمان-فرکانس شده است. لیانگ و همکاران [3] یک روش جدید به نام WT-GAN-CNN برای تشخیص عیوب در ماشین‌های دوار معرفی کردند. این روش با ترکیب تبدیل موجک، شبکه مولد تخصصی و شبکه عصبی پیچشی، دقت بالا و پایداری را در تشخیص عیوب مختلف بلبرینگ با استفاده از سیگنال ارتعاشات ارائه می‌دهد.

ژانگ و همکاران [4] سیگنال‌های ارتعاشات و صوت را با استفاده از تبدیل چیرپلت به حوزه زمان-فرکانس برده و به استخراج ویژگی پرداختند. سپس با روش تحلیل مؤلفه اصلی<sup>۹</sup> کاهش ابعاد داده‌ها انجام شد. در نهایت داده‌های با ابعاد کاهش‌یافته به مدل بردار ماشین حامی با تابع هسته‌ای تابع پایه شعاعی<sup>۱۰</sup> وارد شدند. دقت تشخیص عیوب گزارش شده حاکی از میانگین دقت ۹۸ درصدی این روش در عیب‌یابی بلبرینگ در شرایط‌های مختلف کاری می‌باشد.

ژائو و همکاران [5] یک روش هوشمند برای عیب‌یابی در ماشین‌های دوار بر اساس تجزیه مود متغیر بهبود یافته<sup>۱۱</sup> و شبکه عصبی پیچشی معرفی کردند. نتایج نشان می‌دهد که این روش با استفاده از تجزیه مود متغیر بهبود یافته برای تجزیه سیگنال‌ها به مودهای مختلف و سپس حذف مودهای مخرب، دقت عیب‌یابی با استفاده از تبدیل موجک و شبکه عصبی پیچشی را افزایش داده است. این روش دقت ۹۷ درصد دارد که نسبت به دقت روش‌های سنتی مانند تبدیل فوریه کوتاه مدت<sup>۱۲</sup>، تبدیل موجک و تجزیه مود تجربی<sup>۱۳</sup>

<sup>۵</sup> Pitting

<sup>۶</sup> Gated Recurrent Unite (GRU)

<sup>۷</sup> Signal to Noise Ratio (SNR)

<sup>۸</sup> Support Vector Machine (SVM)

<sup>۹</sup> Principal Component Analysis (PCA)

<sup>۱۰</sup> Radial Basis Function (RBF)

<sup>۱۱</sup> Improved Variational Mode Decomposition (IVMD)

<sup>۱۲</sup> Short-Time Fourier Transform (STFT)

<sup>۱۳</sup> Empirical Mode Decomposition (EMD)

در حدود ۵ درصد بالاتر است. همچنین، دقت مدل شبکه عصبی پیچشی نسبت به سایر مدل‌های شبکه‌های عصبی مانند شبکه عصبی بازگشتی<sup>۱۴</sup> و شبکه‌های حافظه کوتاه مدت بلند مدت<sup>۱۵</sup> که دقتی برابر با ۹۰ درصد دارند، ۷ درصد بالاتر است. در سالهای اخیر توجه زیادی به ویژگی‌های روانشناختی صدا<sup>۱۶</sup> در پردازش سیگنال‌های صوتی شده است. شارون و همکاران [6] تکنیک‌های مختلف نمایش سیگنال‌های صوتی برای طبقه‌بندی با شبکه عصبی پیچشی را بررسی کردند. نتایج نشان می‌دهد که کاکلیاگرام با دقت ۹۴.۱۳ درصد عملکرد بهتری را نسبت به اسپکتروگرام<sup>۱۷</sup> با دقت ۹۱.۹ درصد، اسپکتروگرام صاف‌شده<sup>۱۸</sup> با دقت ۹۳.۴۱ درصد و مل-اسپکتروگرام<sup>۱۹</sup> با دقت ۹۳.۶۴ درصد در تشخیص دستور سخن<sup>۲۰</sup> ارائه می‌دهد. کاکلیاگرام با استفاده از فیلتر گاماتون که مدل شنوایی انسان را تقلید می‌کند، برای سیگنال‌های گفتاری و رویدادهای صوتی که بیشتر در بازه‌های فرکانسی پایین هستند، عملکرد بهتری دارد. کین و همکاران [7] به مقایسه ویژگی‌های روانشناختی صدا استخراج شده از سیگنال‌های آکوستیک و ویژگی‌های معمول که از سیگنال ارتعاشات و صدا استخراج می‌شوند (مانند RMS) پرداختند و بیان کردند که ویژگی‌های روانشناختی صدا در مقایسه با ویژگی‌های معمول صدا برای عیب‌یابی چرخ‌دنده موثرتر هستند. ژانگ و همکاران [8] با استفاده از کاکلیاگرام و شبکه‌های عصبی پالس‌دار<sup>۲۱</sup> که فعالیت‌های عصبی مغز را به صورت بیولوژیکی دقیق‌تری مدل‌سازی می‌کند، به عیب‌یابی بلبرینگ پرداختند و به میانگین دقت ۹۰ درصد دست یافتند و نشان دادند که با بهره‌گیری از سیستم شنوایی انسان می‌توان ساختارهای شنوایی ماشین برای کاربردهای صنعتی توسعه داد.

موارد ذکر شده بیانگر اهمیت بالای ارائه روشی مقاوم به نویز در عیب‌یابی تجهیزات دوار با استفاده از سیگنال‌های صوتی می‌باشند. زیرا به علت غیرتماسی بودن سنسورهای صدا، استفاده از آن‌ها در محیط‌های صنعتی قابل حصول‌تر از سنسورهای ارتعاشات می‌باشند ولی یکی از مهمترین موانع حصول به دقت بالا در عیب‌یابی با استفاده از سیگنال‌های صدا وجود نویز محیطی فراوان در هنگام استخراج داده است. در این پژوهش تلاش شده است با استفاده از روش‌های پیش‌پردازش سیگنال‌های صوتی و استفاده از شبکه عصبی پیچشی، روشی مقاوم به نویز برای عیب‌یابی جعبه‌دنده ارائه گردد.

در بخش دوم این پژوهش به معرفی شبکه عصبی پیچشی، تجزیه حالت متغیر و تبدیل کاکلیاگرام پرداخته شده است. توضیحات مربوط به شرایط آزمایش و معرفی دادگان استفاده شده در آزمایش در بخش سوم آورده شده‌اند. در بخش چهارم به بررسی نتایج و بحث پیرامون مقایسه روش‌ها پرداخته شده است. و در نهایت در بخش پنجم، جمع‌بندی کلی این مقاله آورده شده است.

## ۲- پیشینه علمی

در این بخش مبانی شبکه عصبی پیچشی، تجزیه مود متغیر و تبدیل کاکلیاگرام به اختصار توضیح داده شده است.

### ۱-۲ شبکه عصبی پیچشی

در پیاده‌سازی شبکه عصبی پیچشی می‌توان از لایه‌های متفاوتی جهت بهبود عملکرد شبکه بهره برد. اصلی‌ترین لایه شبکه عصبی پیچشی، لایه پیچشی می‌باشد. این لایه یک هسته را روی ماتریس ورودی خود کانولوشن می‌کند. بسته به بعد ورودی، هسته می‌تواند یک بردار یا یک ماتریس با بعد بالاتر باشد. برای پردازش تصاویر ارائه شده توسط تبدیل‌های زمان-فرکانس، هسته دو بعدی استفاده شده است و دارای یک سری وزن و یک بایاس به عنوان پارامترهای قابل یادگیری است [9].

<sup>۱۴</sup> Recurrent Neural Network (RNN)

<sup>۱۵</sup> Long Short-Term Memory (LSTM)

<sup>۱۶</sup> Psychoacoustics

<sup>۱۷</sup> Spectrogram

<sup>۱۸</sup> Smoothed Spectrogram

<sup>۱۹</sup> Mel-Spectrogram

<sup>۲۰</sup> Speech Command

<sup>۲۱</sup> Spiking Neural Network (SNN)

رایج‌ترین تابع فعال‌سازی مورد استفاده در شبکه‌های عصبی پیچشی تابع واحد خطی تصحیح شده<sup>۲۲</sup> است [9]، که سرعت همگرایی آموزش را افزایش و از بیش‌برازش جلوگیری می‌کند. لایه نرمال‌سازی دسته‌ای<sup>۲۳</sup> می‌تواند سرعت همگرایی شبکه را با نرمال‌سازی نمونه‌های دسته کوچک<sup>۲۴</sup> بهبود بخشد، به طوری که میانگین و انحراف استاندارد ورودی آن به ترتیب نزدیک به صفر و یک شود [10]. پس از هر لایه فعال‌سازی، معمولاً یک لایه ادغام<sup>۲۵</sup>، ابعاد را با نمونه‌برداری کاهش می‌دهد. داشتن لایه‌های ادغامی در معماری شبکه دو مزیت دارد: اول، با کاهش پارامترهای کلی قابل یادگیری، احتمال بیش‌برازش در شبکه را کاهش می‌دهد. دوم، همگرایی شبکه را تسریع می‌کند. در میان روش‌های انجام عملیات ادغامی، روش ادغام حداکثری<sup>۲۶</sup> بیشترین استفاده را در شبکه‌های پیچشی دارد [10]. در جدول (۱) مشخصات شبکه استفاده شده در این پژوهش آمده است.

جدول ۱. ابعاد شبکه عصبی پیچشی استفاده شده در این پژوهش.

نوع لایه	شکل خروجی	تعداد پارامتر قابل آموزش
2D-CNN_1	(۲۳۰, ۲۳۰, ۶۴)	۲۳۶۸
لایه نرمال‌ساز دسته ای_1	(۲۳۰, ۲۳۰, ۶۴)	۲۵۶
لایه ادغام حداکثری_1	(۱۱۵, ۱۱۵, ۶۴)	۰
2D-CNN_2	(۱۱۵, ۱۱۵, ۳۲)	۱۸۴۶۴
لایه نرمال‌ساز دسته ای_2	(۱۱۵, ۱۱۵, ۳۲)	۱۲۸
لایه ادغام حداکثری_2	(۵۷, ۵۷, ۳۲)	۰
لایه تسطیح کننده <sup>۲۷</sup>	(۱۰۳۹۶۸)	۰
لایه تمام-متصل	(۵)	۵۱۹۸۵۴

## ۲-۲ تجزیه مود متغیر

روش تجزیه مودهای متغیر یکی از جدیدترین روش‌های تجزیه مود است که توسط دراگومیرتسکی و زوسو [11] ابداع شده است. برخلاف روش‌های EMD<sup>۲۸</sup> و EEMD<sup>۲۸</sup> که مبتنی بر آزمایشات هستند، VMD بر پایه نظریه‌های پردازش سیگنال از جمله فیلتر وینر، تبدیل هیلبرت و انتقال سیگنال در فضای فرکانس استوار است. هدف اصلی VMD این است که سیگنال‌ها را به مودهایی تجزیه کند که داده‌های مفید در فرکانسی خاص در هر مود فشرده شوند، که به آن فرکانس مرکزی گفته می‌شود. اصل اساسی روش VMD به‌عنوان حل یک مسئله تغییرات مقید، که در معادله (۱) آمده است، در نظر گرفته می‌شود [11].

$$\min_{u_k, \omega_k} \left\{ \sum_k \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}; \sum_k u_k = f \quad (1)$$

در اینجا  $u_k$  مود  $k$ م و  $\omega_k$  فرکانس مرکزی این مود می‌باشد. برای حل مسئله تغییرات محدود در معادله (۱)، از لاگرانژ افزوده ( $L$ ) که در معادله (۲) معرفی شده است، استفاده می‌شود.

$$L(\{u_k\}, \{\omega_k\}, \eta) = \xi \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \eta(t), f(t) - \sum_k u_k(t) \rangle \quad (2)$$

<sup>۲۲</sup> RELU

<sup>۲۳</sup> Batch normalization layer

<sup>۲۴</sup> Mini-Batch

<sup>۲۵</sup> Pooling layer

<sup>۲۶</sup> Max pooling

<sup>۲۷</sup> Flatten

<sup>۲۸</sup> Ensemble Empirical Mode Decomposition

در معادله (۲)  $\xi$  پارامتر خطا و  $\eta$  ضرب کننده لاگرانژ می‌باشد. این معادله را می‌توان با استفاده از روش  $ADMM^{29}$  که یک روش تکراری است، حل کرد.

ضریب همبستگی پیرسون یک معیار برای مشخص نمودن میزان همبستگی و شباهت دو سیگنال می‌باشد. پس از تجزیه سیگنال‌های صدا به چهار مود، به منظور حذف موده‌های حاوی نویز و یا داده‌های غیرضروری از تحلیل همبستگی پیرسون هر مود در حوزه فرکانس در سیگنال‌های حاوی عیوب با مود متناظر آن در سیگنال سالم استفاده شده است. ضریب همبستگی پیرسون با معادله‌ی (۳) محاسبه می‌شود [12].

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (3)$$

X متغیر اول و Y متغیر دوم می‌باشند.

### ۳-۲ کاکلیاگرام

در حلزونی گوش، غشای پایه<sup>۳۰</sup> مانند یک بانک فیلتر عمل کرده و اجزای فرکانسی موج را استخراج می‌کند. برای مدل‌سازی خاصیت فیلترگذاری فرکانسی غشای پایه از یک بانک فیلتر گاماتون در پیاده‌سازی کاکلیاگرام استفاده می‌شود. فیلترهای گاماتون به صورت یکنواخت روی مقیاس پهنای باند معادل مستطیلی<sup>۳۱</sup> قرار می‌گیرند [13]. فرم ریاضی فیلترهای گاماتون به صورت معادله (۴) است:

$$g(n) = An^{r-1}e^{-2\pi(Bn)} \cos(2\pi f_c n + \phi) \quad (4)$$

در اینجا،  $B_n$  ضریب افت است و پهنای باند فیلتر یا مدت زمان پاسخ ضربه را تعیین می‌کند،  $f_c$  فرکانس مرکزی فیلتر را به رادیان بر ثانیه نشان می‌دهد و  $\phi$  معرف فاز به رادیان است.

$$f_{c,ERB} = \left[ \left( \frac{f_{c,Hz}}{Q_{ear}} \right)^p + B_{min}^p \right]^{\frac{1}{p}} \quad (5)$$

در معادله (۵)  $Q_{ear}$  کیفیت مجانبی فیلتر در فرکانس‌های بالا را نشان می‌دهد و  $B_{min}$  نشان دهنده حداقل پهنای باند فیلتر در فرکانس‌های پایین است. سه مدل متداول فیلترهای باند معادل مستطیلی، مدل گرینوود ( $Q_{ear} = 7.23, B_{min} = 22.85$  و  $p = 1$ )، مدل لیون ( $Q_{ear} = 8, B_{min} = 125$  و  $p = 2$ ) و مدل گلاسبرگ و مور ( $Q_{ear} = 9.26, B_{min} = 24.7$  و  $p = 1$ ) می‌باشند. با استفاده از رابطه (۶) می‌توان رابطه بین موقعیت سلول مویی در حلزون گوش و فرکانس مرکزی فیلتر را محاسبه کرد.

$$f_{c,m} = -Q_{ear}B_{min} + (f_h + Q_{ear}B_{min})e^{-\frac{ms}{Q_{ear}}} \quad (6)$$

در معادله (۶)،  $M$  تعداد فیلترها،  $S$  ضریب گام و  $f_h$  بالاترین فرکانس در بانک فیلتر است.

$$s = \frac{Q_{ear}}{M} \log \left( \frac{f_h + Q_{ear}B_{min}}{f_l + Q_{ear}B_{min}} \right) \quad (7)$$

در رابطه (۷)،  $f_l$  پایین‌ترین فرکانس در بانک فیلتر است. در نهایت، پس از فیلتر کردن سیگنال با فیلترهای گاماتون، انرژی اجزای فرکانسی پنجره با هم جمع می‌شود و کاکلیاگرام ایجاد می‌شود.

$$C(m, t) = \sum_{n=0}^{N-1} |\hat{x}(m, n)|w(n) \quad , m = 1, 2, 3, \dots, M \quad (8)$$

در اینجا،  $\hat{x}(m, n)$  سیگنال فیلتر شده توسط فیلترهای گاماتون است،  $w(n)$  یک تابع پنجره است و  $C(m, t)$  هارمونیک  $m$  مربوط به فرکانس مرکزی  $f_{c,m}$  برای قاب  $t$ م می‌باشد.

<sup>۲۹</sup> Alternate Direction Method of Multipliers

<sup>۳۰</sup> Basilar Membrane



<sup>۳۱</sup> Equivalent Rectangular Bandwidth (ERB)

### ۳- شرح آزمایش و مجموعه داده

در این پژوهش از دادگان استخراج شده توسط علوی و همکاران [14] از دستگاه آزمایش جعبه‌دنده که در آزمایشگاه تحقیقات آکوستیک دانشگاه صنعتی امیرکبیر توسط حیدری و همکاران [15] طراحی و ساخته شده است، استفاده شده است. در این دستگاه آزمایشی از یک جعبه‌دنده خودروی پژو/سیتروئن BE3 استفاده شده است. یک موتور القایی ۷.۵ کیلوواتی جعبه‌دنده را از طریق یک سیستم قرقره و تسمه به حرکت درمی‌آورد. در این آزمایش چهار عیب متداول در چرخدنده‌ها شامل، ترک<sup>۳۲</sup>، سایش<sup>۳۳</sup>، لب‌پریدگی<sup>۳۴</sup> و پوسته شدن<sup>۳۵</sup>، در سه شدت خفیف، متوسط و شدید بررسی شدند که در جدول (۲) مشخصات عیوب آورده شده است. از سه میکروفن برای استخراج سیگنال صدا استفاده شده، هر آزمایش به مدت ۱۰ ثانیه به طول انجامیده و سه مرتبه تکرار شده است. سرعت دورانی شفت ورودی برابر ۳۰ هر تیز بوده است.

جدول ۲. شناسه عیوب جعبه‌دنده.

شناسه عیب	عیب	شناسه عیب	عیب
CR1	ترک ۲۰٪	W5	سایش ۵ میکرون
CR2	ترک ۵۰٪	W10	سایش ۱۰ میکرون
CR3	ترک ۸۰٪	W20	سایش ۲۰ میکرون
S1	پوسته شدن خفیف	CH5	لب‌پریدگی ۵٪
S2	پوسته شدن متوسط	CH10	لب‌پریدگی ۱۰٪
S3	پوسته شدن شدید	CH15	لب‌پریدگی ۱۵٪



شکل ۱. مجموعه جعبه‌دنده و محل قرارگیری میکروفن‌ها [14].



(الف) (ب) (ج) (د)


شکل ۲. عیوب سایش (الف سالم، ب عیب خفیف، ج متوسط و د شدید) [16].

<sup>۳۲</sup> Crack


<sup>۳۳</sup> Wearing

<sup>۳۴</sup> Chipped teeth


<sup>۳۵</sup> Spalling



شکل ۳. عیوب ترک. (الف) عیب خفیف، (ب) متوسط و (ج) شدید [16].



شکل ۴. عیوب لب‌پریدگی. (الف) عیب خفیف، (ب) متوسط و (ج) شدید [16].



شکل ۵. عیوب پوسته شدن. (الف) عیب خفیف، (ب) متوسط و (ج) شدید [16].

#### ۴- بحث و بررسی نتایج

در این قسمت نتایج حاصل از استفاده از VMD، برای نویز زدایی، به همراه تبدیل تبدیل موجک با نتایج حاصل از کاکلیاگرام مقایسه شده‌اند.

#### ۱-۴ روش اول (VMD-WT)

در روش VMD-WT در ابتدا سیگنال‌های صدا با استفاده از VMD به چهار مود تجزیه می‌شوند؛ سپس با استفاده از تحلیل همبستگی ضریب پیرسون، همبستگی هر مود در سیگنال حاوی عیب با مود متناظر آن در سیگنال سالم در حوزه فرکانس بررسی می‌شوند که در جدول (۳) نمونه از این مقایسه آورده شده است.

جدول ۳. ضرایب همبستگی پیرسون برای سیگنال‌های عیوب مختلف و سیگنال سالم.

مود	ترک متوسط	سایش متوسط	لب‌پریدگی متوسط	پوسته شدن متوسط
۱	۰.۹۸۳	۰.۹۷۲	۰.۹۶۵	۰.۹۸۴
۲	۰.۵۶۱	۰.۳۳۲	۰.۳۹۳	۰.۳۸۸
۳	۰.۷۱۰	۰.۶۹۳	۰.۸۱۷	۰.۷۲۳
۴	۰.۵۳۱	۰.۴۹۲	۰.۷۲۹	۰.۵۱۹

با تکرار این روش برای عیوب خفیف و شدید نتایج مشابه حاصل می‌شوند که بیانگر این هستند که ضرایب همبستگی پیرسون در مود اول در عیوب مختلف و مود اول حالت سالم دارای مقادیر نزدیک به ۱ می‌باشند که نشان دهنده همبستگی بالا است. در مود

سوم نیز مقادیر به مقدار ۰.۷ نزدیک می‌باشند که بیانگر همبستگی به نسبت قابل توجه در این مودها است. با استفاده از این تحلیل مودهای اول و سوم از سیگنال‌ها حذف شدند. در ادامه با استفاده از مودهای دوم و چهارم سیگنال‌های صدا بازسازی شدند.

در ادامه دو سیگنال صدا مربوط به هر یک از آزمایش‌ها برای آموزش<sup>۳۶</sup> و ارزیابی<sup>۳۷</sup> و یک سیگنال صدا برای آزمون<sup>۳۸</sup> شبکه عصبی در نظر گرفته شدند. سپس برای افزایش تعداد داده هر یک از سیگنالها به چهل قسمت مساوی تقسیم شدند که با هم هم‌پوشانی نداشته‌اند. در نتیجه تعداد ۸۰ عدد سیگنال برای آموزش و ارزیابی (۶۰ عدد برای آموزش و ۲۰ عدد برای ارزیابی) و ۴۰ عدد برای آزمون در نظر گرفته شدند. سپس با استفاده از تبدیل موجک گسسته سیگنال‌ها به حوزه زمان-فرکانس برده و با استفاده از شبکه عصبی پیچشی به استخراج ویژگی و کلاس بندی پرداخته شد. در جداول (۴) الی (۶) نتایج حاصل از این روش برای عیوب با سه شدت مختلف (شدید، متوسط و خفیف) آورده شده است. در این جداول نتایج استفاده از تبدیل موجک بدون استفاده از تجزیه مود متغیر نیز قابل مشاهده است.

جدول ۴. دقت عیب‌یابی عیوب شدید با استفاده از روش WT و VMD-WT.

روش	شماره میکروفن	۱	۲	۳
WT		٪۹۳.۵	٪۹۳	٪۷۴.۷
VMD-WT		٪۹۳.۷	٪۹۴	٪۹۳

جدول ۵. دقت عیب‌یابی عیوب متوسط با استفاده از روش WT و VMD-WT.

روش	شماره میکروفن	۱	۲	۳
WT		٪۹۰.۶	٪۹۰	٪۶۵.۳
VMD-WT		٪۹۲	٪۸۹	٪۸۹.۵

جدول ۶. دقت عیب‌یابی عیوب خفیف با استفاده از روش WT و VMD-WT.

روش	شماره میکروفن	۱	۲	۳
WT		٪۸۸.۶۵	٪۸۹	٪۶۲
VMD-WT		٪۸۹.۳	٪۸۹	٪۸۸.۷

در میکروفن ۳ به علت قرار گیری در نزدیکی موتور القایی، تاثیر نویز محیطی بیشتر بوده و دقت استفاده از سیگنال‌های این میکروفن در مقایسه با میکروفن ۱ و ۲ کمتر است ولی با استفاده از VMD می‌توان تا حد مطلوبی دقت میکروفن سوم را بهبود بخشید و به دو میکروفن دیگر نزدیک کرد که حاکی از این است که در شرایطی که نصب میکروفن در نزدیکی چرخنده امکان پذیر نیست می‌توان از VMD جهت حذف نویز استفاده کرد.

## ۲-۴ روش دوم (کاکلیاگرام)

در این روش برای انتقال سیگنال‌ها از حوزه‌ی زمان به حوزه زمان-فرکانس از تبدیل کاکلیاگرام استفاده شده است، که در جدول (۷) نتایج آورده شده‌اند. نتایج جدول (۷) برتری کامل کاکلیاگرام به تبدیل موجک حتی به همراه کاهش نویز با استفاده از VMD را نشان می‌دهد، که بیانگر توانایی مطلوب بانک فیلتر گاماتون در کاهش تاثیر عوامل محیطی در دقت عیب‌یابی با استفاده از سیگنال صدا است.

<sup>۳۶</sup> Train

<sup>۳۷</sup> Validation

<sup>۳۸</sup> Test

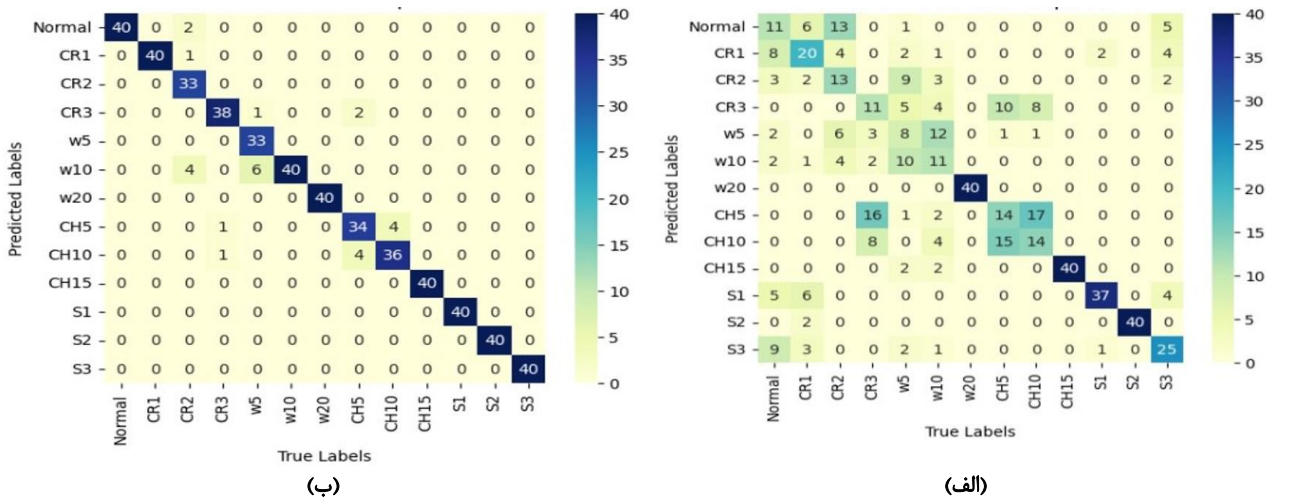


جدول ۷. دقت عیب‌یابی با استفاده از روش کاکلیاگرام.

شدت	شماره میکروفن	۱	۲	۳
عیوب شدید		٪۱۰۰	٪۱۰۰	٪۱۰۰
عیوب متوسط		٪۹۸.۳	٪۹۸.۵	٪۱۰۰
عیوب خفیف		٪۹۸	٪۹۷	٪۹۹.۳

### ۳-۴ تفکیک شدت عیوب

در این بخش برای بررسی مقایسه توانایی روش مبتنی بر کاکلیاگرام و روش مبتنی بر تبدیل موجک در تفکیک شدت عیوب در عیب‌یابی از تمام دادگان با شدت عیوب مختلف به صورت هم‌زمان استفاده شده است که ماتریس‌های پیچیدگی عیب‌یابی با استفاده از سیگنال‌های میکروفن سوم در شکل (۶) آورده شده است. شناسه عیوب استفاده شده در ماتریس‌های پیچیدگی مطابق جدول (۲) می‌باشند.



شکل ۶. ماتریس پیچیدگی عیب‌یابی با استفاده از (الف) تبدیل موجک (ب) تبدیل کاکلیاگرام.

دقت عیب‌یابی با استفاده از تبدیل موجک برابر ۵۴.۶ و با تبدیل کاکلیاگرام برابر ۹۵ درصد می‌باشد که نشانگر این است که در حالی که تبدیل موجک عملاً قادر به تفکیک شدت عیوب و حتی شناسایی عیوب مختلف در عیب‌یابی با استفاده از سیگنال صدا با میکروفن سوم نمی‌باشد، کاکلیاگرام با دقت مناسبی عیوب با شدت‌های مختلف را تفکیک می‌کند.

### ۵- جمع‌بندی

در این پژوهش دو روش مقاوم به نویز محیطی برای عیب‌یابی جعبه‌دنده با استفاده از سیگنال صدا و شبکه عصبی پیچشی ارائه شد. نتایج روش مبتنی بر کاکلیاگرام در حالات مختلف با نتایج روش مبتنی بر تبدیل موجک و VMD، که از رایج‌ترین روش‌ها در پردازش سیگنال‌های ارتعاشات و صدا در حوزه عیب‌یابی ماشین‌های دوار می‌باشند، مقایسه شد. میانگین دقت عیب‌یابی برای شدت عیوب خفیف، متوسط و شدید با استفاده از کاکلیاگرام به ترتیب برابر ۹۸.۱، ۹۸.۹ و ۱۰۰ درصد می‌باشند در حالی که متوسط دقت روش مبتنی بر تبدیل موجک و VMD برای عیوب خفیف، متوسط و شدید به ترتیب برابر ۸۹، ۹۰.۱۶ و ۹۳.۶ درصد می‌باشند که نشان دهنده توانمندی بالای بانک فیلتر گاماتون در کم اثر کردن نویز محیط در سیگنال صدا می‌باشد. در بخش تفکیک شدت عیوب نیز نتایج بیانگر دقت بالای تبدیل کاکلیاگرام با دقت ۹۵ درصد نسبت به تبدیل موجک با دقت ۵۴.۶ درصد می‌باشد. با توجه به نتایج پژوهش پیشرو می‌توان بیان کرد در عیب‌یابی قطعات دوار با استفاده از سیگنال صدا، کاکلیاگرام جایگزین توانمندی برای تبدیل‌های سنتی زمان-فرکانس مانند تبدیل موجک می‌باشد.

## مراجع

1. X. Li, J. Li, Y. Qu, D. He, " Gear pitting fault diagnosis using integrated CNN and GRU network with both vibration and acoustic emission signals", *Applied Sciences* 9(4), p.768. (2019).
2. X. Wang, D. Mao, X. Li, " Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network. Measurement", *Measurement* 173, p.108-518 (2021).
3. P. Liang, C. Deng, J. Wu, Z. Yang, "Intelligent fault diagnosis of rotating machinery via wavelet transform, generative adversarial nets and convolutional neural network", *Measurement* 159, 107-768 (2020).
4. J. Zhang, X. Hu, X. Zhong, H. Zhou, "Fault diagnosis of axle box bearing with acoustic signal based on chirplet transform and support vector machine." *Shock and Vibration* 2022, no. 1, 9868999 (2022).
5. Q. Xiao, S. Li, L. Zhou, W. Shi, "Improved variational mode decomposition and CNN for intelligent rotating machinery fault diagnosis." *Entropy* 24, no. 7: 908 (2022).
6. R.V. Sharan, H. Xiong, S. Berkovsky, "Benchmarking audio signal representation techniques for classification with convolutional neural networks." *Sensors* 21, no. 10-3434 (2021).
7. P.V. Kane, A.B. Andhare, "Critical evaluation and comparison of psychoacoustics, acoustics and vibration features for gear fault correlation and classification." *Measurement* 154, 107-495 (2020).
8. Y. Zhang, S. Dora, M. Martínez-García, S. Bhattacharyya and, "Machine hearing for industrial acoustic monitoring using cochleagram and spiking neural network." *IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM)*. IEEE, (2022).
9. Z. Li, F. Liu, W. Yang, S. Peng, J. Zhou, " A survey of convolutional neural networks: analysis, applications, and prospects." *IEEE transactions on neural networks and learning systems*, 33(12), pp.6999-7019, (2021).
10. J. Gu, Z. Wang, J. Kuen, L. Ma, A. Shahroudy, B. Shuai, T. Liu, X. Wang, G. Wang, J. Cai, T. Chen, " Recent advances in convolutional neural networks." *Pattern recognition*, 77, pp.354-377., (2018).
11. K. Dragomiretskiy, D. Zosso, "Variational mode Decomposition ." *IEEE Transactions Signal Processing*, 62(3): 531-544 (2014).
12. I. Cohen, Y. Huang, J. Chen, J. Benesty, " Pearson correlation coefficient." *Noise reduction in speech processing*. pp.1-4. (2009).
13. R. V. Sharan and T. J. Moir, "Cochleagram image feature for improved robustness in sound recognition." *IEEE International Conference on Digital Signal Processing (DSP)*, IEEE, pp. 441-444 (2015).
14. H. Alavi, A. Ohadi, S.T. Tofighi, " A novel targeted method of informative frequency band selection based on lagged information for diagnosis of gearbox single and compound faults." *Mechanical Systems and Signal Processing* 170: 108828 (2022).
15. H. Heidari, A. Ohadi " Application of wavelet energy and Shannon entropy for feature extraction in gearbox fault detection under varying speed conditions." *Neurocomputing*, 133, pp.437-445, (2014).
16. S.T. Tofighi, H. Alavi, A. Ohadi, " Incipient fault detection of helical gearbox based on variational mode decomposition and time synchronous averaging." *Structural Health Monitoring*, 22(2), pp.1494-1512, (2023).