



# ISAV2024

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



## تشخیص عیوب سرسیلندر موتور احتراق داخلی در انتهای خط تولید به کمک پردازش سیگنال صوتی و شبکه عصبی پیچشی

علیرضا گلی کریم آبادی<sup>۱</sup>، مریم قصابزاده سریزدی<sup>۲\*</sup>، عبدالرضا اوحدی<sup>۳</sup>، سید اشکان موسویان<sup>۴</sup>

<sup>۱</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، مرکز فناوری خودرو، دانشجوی کارشناسی ارشد.

<sup>۲</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، مرکز فناوری خودرو، استادیار.

<sup>۳</sup> ایران، تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی مکانیک، آزمایشگاه تحقیقاتی آکوستیک، استاد.

<sup>۴</sup> ایران، تهران، دانشگاه فنی و حرفه‌ای، گروه مهندسی کشاورزی، عضو هیئت علمی.

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

### چکیده

این پژوهش به بررسی روشی نوآورانه برای تشخیص عیوب سرسیلندر در موتورهای احتراق داخلی می‌پردازد. عیوب مورد بررسی شامل لقی محوری میل بادامک، گرفتگی لوله مکش روغن و خالی بودن استکانی‌ها است که در انتهای خط تولید و مرحله تست گرم با استفاده از پردازش سیگنال‌های صوتی شناسایی می‌شوند. این عیوب در خط تولید رایج بوده و تشخیص آنها، به ویژه لقی محوری میل بادامک، با روش‌های سنتی دشوار است. در این پژوهش، برای تشخیص عیوب از ترکیب پردازش سیگنال و شبکه عصبی استفاده می‌شود. سیگنال‌های صوتی در سه دور کاری مختلف (۱۳۰۰، ۱۷۰۰ و ۲۵۰۰ دور در دقیقه) و در حالت بی‌باری توسط دستگاه ضبط صوت دستی ثبت شده‌اند که انتخابی مقرون به صرفه و کاربردی است و می‌تواند به راحتی در محیط‌های صنعتی مختلف استفاده شود. داده‌های صوتی ضبط شده به دلیل شرایط کاری خط تولید دارای نویز شدید هستند که این امر باعث پیچیدگی عیب‌یابی می‌شود. برای پردازش سیگنال و استخراج ویژگی، از طیف نگارها همراه با فیلتربانک‌های مل و گاماتون استفاده شده است. این روش‌ها امکان تحلیل دقیق‌تر فرکانس‌های صوتی را فراهم می‌کنند و می‌توانند الگوهای صوتی مرتبط با عیوب را بهتر شناسایی کنند. برای طبقه‌بندی داده‌ها از شبکه عصبی پیچشی استفاده شده است که برای تعداد داده‌های کم نتایج خوبی را برای تفکیک داده‌ها ارائه می‌دهد. نتایج پژوهش نشان می‌دهد که طیف‌نگارها در استخراج ویژگی کارآمدتر از روش‌های رایج دیگر مانند تبدیل موجک پیوسته هستند و در دوره‌های کاری ۱۷۰۰ و ۲۵۰۰ دور در دقیقه، تمام عیوب با دقت تقریبی ۹۸٪ تشخیص داده می‌شوند. این روش به ویژه در تشخیص عیوبی مانند لقی محوری میل بادامک، که با روش‌های سنتی قابل تشخیص نیستند، مؤثر است. همچنین، این روش قادر است بین گرفتگی لوله مکش روغن و خالی بودن استکانی‌ها، که معمولاً توسط کارشناسان خط تولید به عنوان یک عیب واحد تشخیص داده می‌شوند، تمایز قائل شود.

## کلمات کلیدی: موتور احتراق داخلی؛ عیب‌یابی؛ پردازش سیگنال صوتی؛ شبکه عصبی.

### ۱- مقدمه

کنترل کیفیت محصولات تولید شده در صنایع مختلف، به ویژه در صنعت خودروسازی، از جایگاه ویژه‌ای برخوردار است. امروزه، در اکثر خطوط تولید خودرو، آزمون‌های کیفی متعدد و متنوعی بر روی محصول نهایی انجام می‌شود. اهمیت این موضوع به حدی است که عدم انجام این آزمون‌ها می‌تواند خطر بروز حوادث برای مصرف‌کنندگان را به طور چشمگیری افزایش دهد.

در میان اجزای مختلف خودرو، موتور احتراق داخلی از اهمیت ویژه‌ای برخوردار است و بررسی‌های کیفی آن نقش حیاتی در تضمین ایمنی و عملکرد بهینه خودرو ایفا می‌کند. یکی از مراحل کلیدی در فرآیند کنترل کیفیت، تست گرم‌در انتهاهای خط تولید است. در این مرحله، موتورهای روی استندهای مخصوص قرار گرفته و در شرایط بی‌باری روشن می‌شوند. سپس، با استفاده از روش‌های پیشرفته یا سنتی، از طریق تحلیل سیگنال‌های صوتی و ارتعاشی و همچنین بررسی وضعیت روغن، سلامت موتور ارزیابی می‌شود.

یکی از مزایای قابل توجه عیب‌یابی به کمک سیگنال‌های صوتی<sup>۱</sup> و ارتعاشی، عدم نیاز به دخالت مستقیم و تخریب سیستم مورد بررسی است. در مقایسه با استفاده از سیگنال‌های ارتعاشی، بهره‌گیری از سیگنال‌های صوتی در فرآیند عیب‌یابی انتهای خط تولید می‌تواند راهکاری ساده‌تر و مقرون به صرفه‌تر باشد. این روش دارای مزایای متعددی است که آن را به گزینه‌ای مطلوب برای صنایع تبدیل کرده است. نخست، عدم نیاز به نصب و جداسازی سنسور، کاربرد آن را در محیط‌های با دمای بالا امکان‌پذیر می‌سازد. همچنین، سنسورهای صوتی، به دلیل عدم اتصال مستقیم به بدنه، از محدودیت‌های ناشی از هندسه نامنظم و سطوح روغنی و لغزنده مصون هستند. علاوه بر این، سهولت پیاده‌سازی و هزینه اندک تجهیزات مورد نیاز، عیب‌یابی مبتنی بر سیگنال صوتی را به راهکاری جذاب و کارآمد برای بخش صنعت بدل کرده است [۱]. البته این سیستم‌ها نسبت به نویز حساس هستند که می‌تواند نقطه ضعف آنها به حساب آید.

در زمینه عیب‌یابی به کمک سیگنال صوتی و ارتعاشی فعالیت‌ها و پژوهش‌های مختلفی انجام شده است که به چند نمونه اشاره می‌شود. تیاگو و همکاران [۲] در سال ۲۰۲۱ به ساخت یک سنسور صوتی قابل نصب بر روی خودرو در حال حرکت پرداختند که توانایی شناخت عیوب احتراق ناقص و عیوب مربوط به تسمه را داشت؛ این سنسور اطلاعات مربوطه را پس از دریافت از طریق بلوتوث به تلفن شخص مشتری ارسال می‌کرد و در تلفن مشتری به کمک تبدیل موجک گسسته و شبکه عصبی مصنوعی به صورت زمان واقعی به عیب‌یابی پرداخته می‌شد. نسیم و همکاران [۳] در سال ۲۰۲۳ یک سیستم هوشمند تشخیص زودهنگام خرابی برای خودروها با استفاده از یادگیری ماشین ارائه کردند. این سیستم برای تشخیص خرابی‌ها در مراحل اولیه بر مبنای تحلیل صدای خودرو طراحی شده است. از یک میکروفون برای ضبط صدای خودرو و الگوریتم یادگیری ماشین برای تحلیل صدا و تشخیص خرابی‌ها استفاده شد. در این تحقیق داده‌های صوتی موتور خودرو را در شرایط عادی و غیرعادی از چندین تعمیرگاه جمع‌آوری و از ویژگی‌های حوزه زمان، فرکانس و زمان-فرکانس برای تشخیص شرایط عادی و غیرعادی خودرو استفاده کردند. سپس داده‌های خودروهای غیرعادی برای طبقه‌بندی به ۱۵ عیب کلاسیک خودرو مورد استفاده قرار گرفت. نتایج نشان داد که الگوریتم جنگل تصادفی<sup>۳</sup> با استفاده از ویژگی‌های زمان-فرکانس بالاترین دقت را با ۹۷٪ در تشخیص شرایط عادی/غیرعادی و ۹۲٪ در طبقه‌بندی عیوب خاص خودرو دارد. وی و همکاران [۴] در سال ۲۰۱۹ طی پژوهشی به نظارت آنلاین شرایط روانکاری و اصطکاک

<sup>1</sup> Hot Test

<sup>2</sup> Mechanical Fault Detection Using Audio Signal (MFDA)

<sup>3</sup> Random Forest

در موتورهای احتراق داخلی پرداختند. در این مطالعه، با استفاده از انتشار آکوستیک<sup>۱</sup> و توسعه مدل‌های جدید، همراه با تحلیل بهینه‌سازی شده تبدیل موجک بسته‌ای<sup>۲</sup> موفق به نظارت دقیق بر شرایط روانکاری بین رینگ و لاینر در موتورهای احتراق داخلی شدند. نتایج نشان داد که این روش قادر به تشخیص و تمایز بین روانکارهای مختلف و همچنین تشخیص روغن‌های استفاده شده است. چوپرا و همکاران [۵] در سال ۲۰۱۶ به بررسی عیوب یک موتور احتراق داخلی پرداختند؛ کلاس‌های مختلف این پژوهش شامل حالت سالم و ۳ حالت معیوب بوده است. سیستم عیب‌یابی طراحی شده به کمک یک رمزگذار خودکار<sup>۳</sup> از خروجی تبدیل فوریه سریع سیگنال حوزه زمان ویژگی‌ها را استخراج کرده و به کمک روش طبقه‌بندی سافت‌مکس<sup>۴</sup> به تفکیک داده‌ها پرداخته است. دقت این الگوریتم ۹۸٪ اعلام شده است. دپتوا و همکاران [۶] در سال ۲۰۱۶ به تشخیص صوتی برای ارزیابی وضعیت فنی موتور احتراق داخلی پرداختند. آنها از یک موتور دیزل با سیستم تزریق سوخت ریل مشترک استفاده کردند. ایشان در ۱۳ اندازه‌گیری، سطح فشار صوتی را مورد بررسی قرار دادند که شامل نویز پایه و ۶ حالت عیب مختلف در دو سرعت موتور (۱۰۰۰ و ۲۰۰۰ دور در دقیقه) بوده است. آنها تفاوت‌های سطح صوت در فرکانس‌های مختلف را برای هر حالت عیب تحلیل کردند. نتایج نشان می‌دهد که هر عیب الگوی صوتی خاص خود را دارد. در نهایت، ایشان استفاده از روش‌های درخت تصمیم<sup>۵</sup> را برای تشخیص کارآمد عیوب پیشنهاد دادند. ژیانگ و همکاران [۷] در سال ۲۰۱۷ به تشخیص عیب لقی سوپاپ در موتورهای احتراق داخلی با استفاده از روش تشخیص شروع ضربه پرداختند. در این پژوهش، با استفاده از سیگنال‌های ارتعاشی اندازه‌گیری شده بر روی سرسیلندرهای موتور و بدون نیاز به مقایسه با حالت سالم، موفق به تشخیص زمان دقیق بسته شدن سوپاپ‌ها شدند. نتایج آزمایش‌های انجام شده بر روی یک موتور دوازده سیلندر نشان داد که این روش قادر به استخراج دقیق لحظه شروع ضربه بسته شدن سوپاپ و نظارت بر لقی سوپاپ با استفاده از تنها یک ویژگی است. علوی و همکاران [۸] در سال ۲۰۲۲ به بررسی کاربرد سیگنال‌های صوتی در تشخیص عیوب چرخ‌دنده با استفاده از روش‌های یادگیری عمیق پرداختند. ایشان عیوب سایش و ترک چرخ‌دنده در یک جعبه دنده خودرو را مورد بررسی قرار دادند. در این مطالعه، یک معماری ترکیبی از شبکه عصبی کانولوشنی و حافظه کوتاه مدت طولانی<sup>۶</sup> پیشنهاد شد و تحت سه سناریوی مختلف عیب مورد ارزیابی قرار گرفت. نتایج نشان داد که عملکرد کلی این الگوریتم در تمامی سناریوها بهتر از سایر طبقه‌بندها بوده است.

با توجه به موارد ذکر شده مشخص است که سیگنال صدا نقش مهمی در شناسایی عیوب و تشخیص مشخصه‌های موتور دارد. هدف این پژوهش، ایجاد الگوریتمی هوشمند برای عیب‌یابی با استفاده از پردازش سیگنال صوتی و شبکه عصبی در انتها یک خط تولید موتور است. این مطالعه از نظر نوع عیب، سیستم داده‌برداری و محل جمع‌آوری داده‌ها با تحقیقات قبلی متفاوت است. در این پژوهش، از طیف نگارها برای استخراج ویژگی استفاده شده که معمولاً در پردازش گفتار کاربرد دارند. کاربرد این روش‌ها در عیب‌یابی موتورهای احتراق داخلی تاکنون محدود بوده است. علاوه بر این، استفاده از فیلتربانک گاماتون نوآوری دیگری در این زمینه محسوب می‌شود. شرایط تست در این پژوهش، به دلیل انجام آزمایش‌ها در خط تولید و وجود عوامل خارجی مانند خودروهای حمل بار، کارشناسان و جرثقیل‌ها، محیطی بسیار پر سر و صدا ایجاد کرده است. این امر تفاوت اصلی بین این مطالعه و پژوهش‌های آزمایشگاهی پیشین است. شرکت سازنده موتور قصد دارد با استفاده از یک دستگاه قابل حمل و سبک، عیوب مختلف را درون خط تولید بررسی کند. استفاده از چنین دستگاهی برای ضبط صدا مزایای قابل توجهی دارد. این دستگاه امکان جمع‌آوری داده‌های صوتی را در نقاط مختلف خط تولید با سهولت بیشتری فراهم می‌کند. همچنین، به دلیل قابل حمل بودن، می‌توان از آن برای بررسی سریع و آنی موتورها در هر مرحله از فرآیند تولید استفاده کرد. این امر به شناسایی زود هنگام عیوب و کاهش زمان توقف خط تولید کمک می‌کند. از آنجا که سرسیلندر یکی از مهم‌ترین قطعاتی است که خرابی آن باعث افزایش هزینه تولید می‌شود، این پژوهش بر

<sup>1</sup> Acoustic Emission

<sup>2</sup> Wavelet Pocket Transform

<sup>3</sup> Auto Encoder

<sup>4</sup> Softmax

<sup>5</sup> Decision Tree

<sup>6</sup> LSTM

روی عیوب مربوط به آن تمرکز کرده است. استفاده از دستگاه ضبط صوت قابل حمل در بررسی عیوب سرسیلندر، امکان مقایسه سریع الگوهای صوتی موتورهای سالم و معیوب را فراهم می‌کند. این امر به تشخیص دقیق‌تر و سریع‌تر عیوب احتمالی در این بخش حساس موتور کمک می‌کند و در نهایت، به بهبود کیفیت محصول نهایی و کاهش هزینه‌های مرتبط با تعمیرات منجر می‌شود.

بخش دوم این پژوهش به معرفی عیوب و روش انجام آزمایش پرداخته است. معرفی طیف نگارها در جهت استخراج ویژگی در بخش سوم توضیح داده شده است. در بخش چهارم به معرفی شبکه عصبی پیچشی در جهت تفکیک داده‌ها پرداخته شده است. نهایتاً بخش پنجم به بررسی نتایج اختصاص داده شده و در انتها جمع‌بندی مقاله ارائه شده است.

## ۲- معرفی عیوب و روش انجام آزمایش

در این پژوهش، موتور مورد بررسی یک نمونه احتراق داخلی پرخوران با حجم ۱،۷ لیتر و قدرت حداکثر ۱۵۰ اسب بخار است که با تیراژ بالا تولید می‌شود، لذا بررسی کیفی آن اهمیت بسزایی دارد. سرسیلندر، به عنوان یکی از بخش‌های اصلی موتور، شامل قطعات متعددی از جمله میل بادامک است که وظیفه کنترل سوپاپ‌ها را بر عهده دارد. ساخت نادرست این قطعه می‌تواند منجر به افت عملکرد، کاهش طول عمر و افزایش سروصدای موتور شود. در خط تولید مذکور، گاهی موتورهای مونتاژ شده با میل بادامک دارای لقی محوری خارج از تolerانس مشاهده می‌شوند. در حالی که لقی استاندارد برای میل بادامک بین ۰،۰۷ تا ۰،۲۲ میلی‌متر است، عیب لقی محوری (شکل ۱) برای سه سطح کم، متوسط و زیاد به ترتیب به اندازه ۰،۳، ۰،۶ و ۱ میلی‌متر ایجاد شد. این ابعاد پس از تراشکاری با ساعت اندازه‌گیری (شکل ۲) مورد بررسی قرار گرفته است. استکانی‌های خالی یکی از عیوب رایج دیگر در این خط تولید است که می‌تواند ناشی از گرفتگی لوله مکش روغن و یا ورودی روغن به سرسیلندر باشد که در این پژوهش هر دو مورد بررسی قرار گرفته است. برای پیاده‌سازی این دو عیب به ترتیب از لوله دارای گرفتگی و چسب برای کور کردن ورودی روغن استکانی سرسیلندرها (شکل ۳ و ۴) استفاده شده است. گرفتگی استکانی نیز در سه سطح با ایجاد گرفتگی برای استکانی ۱ تا ۳ سیلندر پیاده‌سازی شده است. پس از پیاده‌سازی عیوب، موتور مذکور بر روی جایگاه تست قرار گرفت و صدای موتور در سه دور ۱۳۰۰، ۱۷۰۰ و ۲۵۰۰ (د.د.د) در دو موقعیت توسط دستگاه دستی ضبط صدا ZOOM H4n (شکل‌های ۵ و ۶) ضبط گردید. علت ضبط صدا با این دستگاه اعلام نیاز شرکت سازنده موتور به یک دستگاه عیب‌یابی قابل حمل، سبک و کم هزینه بود. همچنین استفاده از دستگاه‌های جمع‌آوری اطلاعات و سنسورهای گران قیمت صوتی در خط تولید کاری پرهزینه است و پیچیدگی آنها مانع از بکارگیری این تجهیزات توسط کارشناسان خط تولید می‌شود. دستگاه مذکور توانایی دریافت اطلاعات با حداکثر فرکانس داده‌برداری ۹۶ کیلوهرتز و نرخ بیت ۲۴<sup>۱</sup> بیت را دارا است؛ همچنین این دستگاه، داده فیلتر نشده را در خروجی ثبت می‌کند که با این مشخصات نیازهای الگوریتم عیب‌یابی را تامین می‌کند. در انجام آزمایش‌ها فرکانس داده‌برداری ۴۸ کیلوهرتز و نرخ بیت معادل ۱۶ بیت در نظر گرفته شده است. در نهایت برای انجام تست‌ها از تعداد حدود ۲۰ موتور (به علت عدم وجود محدودیت در داده گرفتن از موتور سالم) و یک موتور معیوب (به علت هزینه بالای تامین موتور برای شرکت) داده برداری شد. داده‌ها از موتور معیوب با سه بار تکرار، در دو نقطه، سه دور کاری و در بازه‌های ده ثانیه‌ای جمع‌آوری شد.



شکل ۲: بررسی اندازه لقی محوری میل بادامک به کمک ساعت اندازه‌گیری.




شکل ۱: میل بادامک و جایگاه نشست آن بر روی سرسیلندر و معرفی تراست سرسیلندر (کادر قرمز رنگ).

<sup>1</sup> Bit Rate




شکل ۴: لوله مکش روغن دارای گرفتگی پس از تخلیه.



شکل ۳: گرفتگی ورودی روغن موتور به استکانی‌ها.



شکل ۶: نحوه اندازه‌گیری صدای موتور در مرحله تست گرم (موقعیت دوم).



شکل ۵: نحوه اندازه‌گیری صدای موتور در مرحله تست گرم انتهای خط تولید با دستگاه ZOOM H4n (موقعیت اول).

### ۳- استفاده از طیف‌نگارها در جهت استخراج ویژگی

در این پژوهش روش‌های استخراج ویژگی بر فرض ناپایدار بودن سیگنال استوار است چرا که تمامی استندهای تست توانایی کنترل موتور در یک دور ثابت را ندارند و عملاً دور موتور در یک بازه مشخص نزدیک به دور موتور تعریف شده نوسان می‌کند. همچنین به این مورد باید مواردی همچون نویز محیطی، صدای صحبت کارشناسان و تغییر پارامترهایی مانند دمای موتور را که موجب تغییر جنس صدا می‌شود اضافه کرد. در این پژوهش از پردازش‌های حوزه زمان-فرکانس استفاده شد که از جمله آنها می‌توان به تبدیل موجک پیوسته<sup>۱</sup> و طیف‌نگارها<sup>۲</sup> اشاره کرد. در این بخش فقط به بررسی طیف‌نگارها پرداخته خواهد شد. لازم به ذکر است که در این پژوهش طیف‌نگارها نسبت به تبدیل موجک، نتایج بهتری ارائه می‌دهند. دقت مربوط به روش‌های مختلف در بخش ۵ (جدول ۱) قابل مشاهده است.

#### ۳-۱- طیف‌نگار مل

در روش تبدیل طیف‌نگار مل سعی شده است تا با استفاده از تقریبی از شنوایی انسان، نمایشی از سیگنال صوتی ارائه شود که برای تحلیل و پردازش صوت مناسب‌تر باشد. این روش با تبدیل مقیاس فرکانسی خطی به مقیاس مل، که تقریبی از درک شنوایی انسان است، یک نمایش دوبعدی از سیگنال صوتی در حوزه زمان-فرکانس ایجاد می‌کند. در فرآیند تولید طیف‌نگار مل تبدیل فوریه زمان کوتاه روی سیگنال اعمال می‌شود، سپس طیف توان محاسبه می‌شود؛ پس از آن فیلتربانک مل بر روی طیف توان اعمال می‌شود که فرکانس‌ها را به مقیاس مل نگاشت کرده و در نهایت لگاریتم خروجی فیلترها محاسبه می‌شود. این روش امروزه در امر عیب‌یابی کاربردی است [۹]. رابطه ۱ توضیح کاملی از این روش را به نمایش می‌گذارد. در این رابطه  $F_{mel}$  تعیین کننده تعداد فیلترها،  $T$  تعیین کننده تعداد فریم زمانی،  $F$  فرکانس و  $COE(F_{mel}, F)$  نشان دهنده ماتریس ضرایب فیلتر مل است. نهایتاً  $STFT(F, T)$  به تبدیل فوریه زمان کوتاه اشاره دارد [۱۰].

<sup>1</sup> Continuous wavelet transform

<sup>2</sup> Spectrogram

$$MEL(F_{mel}, T) = \log(COE(F_{mel}, F) * STFT(F, T)) \quad (1)$$

در رابطه ۱  $STFT$  طبق رابطه ۲ محاسبه می‌شود که در آن  $s[n]$  نماد سیگنال دیجیتال،  $w(t)$  نماد تابع پنجره زمانی و  $N$  نماد طول پنجره زمانی است. پس طبق آنچه پیش از این بیان شد به کمک این دو رابطه می‌توان از طیف نگار مل برای استخراج ویژگی استفاده کرد.

$$STFT(f, t) = \sum_{n=0}^{N-1} s[n]w(t)e^{-j2\pi fn} \quad (2)$$

### ۲-۳- طیف‌نگار گاماتون

در حالی که طیف‌نگار مل از مقیاس مل برای تقریب درک شنوایی انسان استفاده می‌کند، طیف‌نگار گاماتون یک گام فراتر می‌رود و سعی در مدل‌سازی دقیق‌تر سیستم شنوایی انسان دارد. این روش با استفاده از فیلترهای گاماتون، که تقریب بهتری از پاسخ غشای پایه گوش انسان هستند، یک نمایش دوبعدی از سیگنال صوتی در حوزه زمان-فرکانس ایجاد می‌کند. لازم به ذکر است که این روش تاکنون در زمینه عیب‌یابی موتور احتراق داخلی مورد استفاده قرار نگرفته است و در پیشینه پژوهش این طیف‌نگار بررسی‌هایی مانند پردازش گفتار و تشخیص بیماری روانی بر اساس صدا به چشم می‌خورد [۱۱]. محاسبات مربوط به تابع گاماتون توسط رابطه ۳ ارائه می‌شود که منجر به ساخت یک فیلتربانک برای استفاده در حوزه زمان-فرکانس می‌شود [۱۲].

$$g(t) = t^{(N-1)}e^{-at} \text{Cos}(\omega_0 t)u(t) \quad (3)$$

در این رابطه  $a$  پارامتر تعیین کننده پهنای باند،  $\omega_0$  فرکانس مرکزی،  $N$  درجه تابع گاماتون و  $u(t)$  تابع پله است. همانطور که بیان شد به کمک این تابع می‌توان به فیلتربانک گاماتون دست پیدا کرد. با پیاده‌سازی این فیلتربانک بر روی طیف‌نگار می‌توان طیف‌نگار گاماتون را محاسبه کرد.


### ۴- شبکه عصبی پیچشی

در این پژوهش در جهت کلاسه‌بندی و تفکیک داده‌ها از شبکه عصبی پیچشی استفاده شده است. علت استفاده از این شبکه پاسخ مناسب آن برای تفکیک تصاویر با تعداد داده کم است [۱۳]. ساختار این شبکه برای الگوریتم از سه بلوک کانولوشنی تشکیل شده که هر بلوک شامل یک لایه کانولوشن دوبعدی، نرمال‌ساز و پولینگ است. لایه‌های کانولوشنی به ترتیب از ۹۶، ۶۴ و ۳۲ فیلتر استفاده می‌کنند و همگی از تابع فعال‌ساز Relu بهره می‌برند. پس از بلوک‌های کانولوشنی، خروجی به یک بردار یک بعدی تبدیل شده و وارد یک لایه تمام متصل با ۱۰۲۴ نورون می‌شود. در نهایت، یک لایه خروجی با ۸ عدد نورون به کمک تابع فعال‌ساز softmax، طبقه‌بندی نهایی را انجام می‌دهد. این ۸ عدد نورون برای تشخیص نوع و سطح عیب در نظر گرفته شده‌اند. این ساختار به مدل اجازه می‌دهد تا ویژگی‌های مهم تصویر را در سطوح مختلف استخراج کرده و بر اساس آن‌ها طبقه‌بندی را انجام دهد. برای آموزش شبکه تعداد ۶ نمونه ۱۰ ثانیه‌ای برای هر کلاس (در هر سطح ۴ عدد برای آموزش و دو عدد برای تست) به الگوریتم در جهت آموزش و تست داده شد. در این الگوریتم این بازه‌های ۱۰ ثانیه‌ای به داده‌های ۱۶۰۰۰ نمونه‌ای (تقریباً ۰,۳۳ ثانیه‌ای) شکسته شده‌اند.

### ۵- بحث و نتیجه‌گیری

در این بخش به بررسی نتایج هر دو الگوریتم طیف نگار مل و گاماتون در تشخیص عیوب و تفکیک سطح عیوب پرداخته شده است. منظور از تفکیک سطح عیوب تعیین مواردی از جمله میزان لقی در میل‌بادامک و تعداد استکانی‌های خالی است چرا که این دو عیب در سه سطح مورد بررسی قرار گرفته‌اند. نتایج به صورت ماتریس به هم ریختگی برای هر دو الگوریتم در دور ۱۳۰۰ دور در دقیقه

(شکل‌های ۷ و ۸) قابل مشاهده است. دقت الگوریتمی که از طیف‌نگار مل و گاماتون استفاده می‌کند برای این دور به ترتیب در تشخیص عیوب برابر ۸۸٫۱٪ و ۸۷٫۹۱٪ و در تفکیک سطح عیب به ترتیب برابر ۷۲٪ و ۸۳٪ می‌باشد. در جدول ۱ دقت تشخیص و تفکیک سطح عیوب ذکر شده برای هر دو الگوریتم و الگوریتمی که از تبدیل موجک بهره می‌برد و سه دور ۱۳۰۰، ۱۷۰۰ و ۲۵۰۰ دور در دقیقه آورده شده است. با توجه به این جدول مشخص است که دقت هر دو الگوریتم در دور ۱۳۰۰ دور در دقیقه نسبت به سایر دوره‌ها پایین‌تر است زیرا نسبت سیگنال به نویز در این دور پایین است. همچنین با اینکه طیف‌نگار گاماتون در تفکیک سطح عیب موفق‌تر عمل کرده است، اما از آنجا که تشخیص عیب در این خط تولید از اهمیت بالاتری برخوردار است پس پیشنهاد نهایی برای عیب‌یابی طیف‌نگار مل است. همانطور که پیش از این بیان شد، طیف‌نگارها در استخراج ویژگی نسبت به تبدیل موجک بهتر عمل کرده‌اند (جدول ۱).



شکل ۷: ماتریس بهم ریختگی برای الگوریتم طیف‌نگار مل در دور ۱۳۰۰. شکل ۸: ماتریس بهم ریختگی برای الگوریتم طیف‌نگار گاماتون در دور ۱۳۰۰.

جدول ۱. دقت تفکیک و تشخیص عیوب در دوره‌ها و الگوریتم‌های مختلف.

الگوریتم و دور موتور	دقت تشخیص	دقت تفکیک سطح عیب
طیف‌نگار مل ۱۳۰۰ د.د.د.	۸۸٫۱٪	۷۲٪
طیف‌نگار گاماتون ۱۳۰۰ د.د.د.	۸۷٫۹۱٪	۸۳٪
تبدیل موجک پیوسته ۱۳۰۰ د.د.د.	۶۲٪	۵۲٪
طیف‌نگار مل ۱۷۰۰ د.د.د.	۹۷٫۹۱٪	۷۸٪
طیف‌نگار گاماتون ۱۷۰۰ د.د.د.	۹۵٫۶۲٪	۹۰٪
تبدیل موجک پیوسته ۱۷۰۰ د.د.د.	۸۵٫۸٪	۶۱٪
طیف‌نگار مل ۲۵۰۰ د.د.د.	۹۸٫۱٪	۹۳٪
طیف‌نگار گاماتون ۲۵۰۰ د.د.د.	۹۴٫۵٪	۹۲٪
تبدیل موجک پیوسته ۲۵۰۰ د.د.د.	۸۹٫۱٪	۷۲٪

## ۶- جمع‌بندی

در این پژوهش سه عیب مختلف از جمله عیوب لقی محوری میل بادامک و گرفتگی ورودی استکانی در سه سطح و عیب گرفتگی لوله مکش روغن در یک سطح مورد بررسی قرار گرفته است. برای داده‌برداری از یک دستگاه ضبط صوت دستی در انتهای خط تولید در سه دور کاری ۱۳۰۰، ۱۷۰۰ و ۲۵۰۰ دور در دقیقه، در حالت بی‌باری موتور و در دو جهت استفاده شده است. از دو طیف‌نگار مل و گاماتون برای استخراج ویژگی و برای تشخیص عیب از شبکه عصبی پیچشی استفاده شده است. با توجه به نتایج مشخص است که سیستم طراحی شده برای عیب‌یابی در این خط تولید تا حد بسیار بالایی توانایی تشخیص عیوب و همین‌طور تشخیص سطح عیوب را

برای دوره‌های مختلف دارد. دقت میانگین تشخیص و تفکیک سطح عیوب برای دوره‌های کاری ۱۷۰۰ و ۲۵۰۰ دور در دقیقه به ترتیب برابر ۹۸٪ و ۹۰٪ است. همچنین سیستم توانایی تشخیص و تفکیک سطح عیوب را در دور کاری ۱۳۰۰ دور در دقیقه به ترتیب با دقت نزدیک به ۸۸٪ و ۸۳٪ دارد. لازم به ذکر است برای بررسی این عیوب شرایط تست به گونه‌ای بوده است که خط تولید در حال فعالیت بوده و با این حال سیستم توانایی خود را برای عیب‌یابی اثبات کرده است.

## ۷- تقدیر و تشکر:

نویسندگان مراتب قدردانی خود را از شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو) به جهت حمایت مادی از این مقاله ابراز می‌دارند.

## مراجع

1. Tang, L., Tian, H., Huang, H., Shi, S., & Ji, Q. (2023). A survey of mechanical fault diagnosis based on audio signal analysis. *Measurement*, 113294. [2] Kreith F, Kreider JF. Principles of solar engineering. Hemisphere-McGraw Hill; 1978.
2. De V. Lima, T. L., Filho, A. C., Belo, F. A., Souto, F. V., Silva, T. C., Mishina, K. V., & Rodrigues, M. C. (2021). Noninvasive methods for fault detection and isolation in internal combustion engines based on chaos analysis. *Sensors*, 21(20), 6925.
3. Nasim, Fawad, Sohail Masood, Arfan Jaffar, Usman Ahmad, and Muhammad Rashid. "Intelligent Sound-Based Early Fault Detection System for Vehicles." *Computer Systems Science & Engineering* 46, no. 3 (2023).
4. Wei, Nasha, et al. "An investigation into the acoustic emissions of internal combustion engines with modelling and wavelet package analysis for monitoring lubrication conditions." *Energies* 12.4 (2019): 640.
5. Chopra, P., & Yadav, S. K. (2015). Fault detection and classification by unsupervised feature extraction and dimensionality reduction. *Complex & intelligent systems*, 1, 25-33.
6. Deptuła, A., Kunderman, D., Osiński, P., Radziwanowska, U., & Włostowski, R. (2016). Acoustic diagnostics applications in the study of technical condition of combustion engine. *Archives of Acoustics*, 41(2), 345-350.
7. Jiang, Z., Mao, Z., Wang, Z., & Zhang, J. (2017). Fault diagnosis of internal combustion engine valve clearance using the impact commencement detection method. *Sensors*, 17(12), 2916.
8. Alavi, Hassan, and Abdolreza Ohadi. "The application of audio signals in gear fault diagnosis based on deep learning methods: an end-to-end approach." *The 12th International Conference on Acoustics & Vibration (ISAV2022)*.
9. Khurana, A., Mittal, S., Kumar, D., Gupta, S., & Gupta, A. (2023). Tri-integrated convolutional neural network for audio image classification using Mel-frequency spectrograms. *Multimedia Tools and Applications*, 82(4), 5521-5546.
10. Ngo, D., Hoang, H., Nguyen, A., Ly, T., & Pham, L. (2020). Sound context classification basing on join learning model and multi-spectrogram features. *arXiv preprint arXiv:2005.12779*.
11. Jacome, K. G. R., Grijalva, F. L., & Masiero, B. S. (2023). Sound events localization and detection using bio-inspired gammatone filters and temporal convolutional neural networks. *IEEE/ACM transactions on audio, speech, and language processing*, 31, 2314-2324.
12. Pour, A. F., Asgari, M., & Hasanabadi, M. R. (2014, October). Gammatonegram based speaker identification. In *2014 4th International Conference on Computer and Knowledge Engineering (ICCKE)* (pp. 52-55). IEEE.
13. Xiao, D., Huang, Y., Qin, C., Liu, Z., Li, Y., & Liu, C. (2019). Transfer learning with convolutional neural networks for small sample size problem in machinery fault diagnosis. *Proceedings of*



*the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 233(14), 5131-5143.*