

پایش وضعیت دیزل ژنراتور با ترکیب داده‌های ارتعاش، صدا و حسگرهای محیطی مبتنی بر مدل‌های یادگیری ماشین

مهدی گودرزی^ا، عبدالله عباسی^{ب*}، محمد عسگری^ج، مهدیه حدادی^د

^ا ایران، سمنان، دانشگاه سمنان، دانشکده مهندسی برق و کامپیوتر، دانشجو

^ب ایران، سمنان، دانشگاه سمنان، دانشکده مهندسی برق و کامپیوتر، هیئت علمی، دانشیار

^ث ایران، تهران، دانشگاه صدا و سیما، دانشکده فنی و مهندسی، هیئت علمی، استادیار

^د ایران، سمنان، دانشگاه سمنان، دانشکده ریاضی و آمار، هیئت علمی، دانشیار

* پست الکترونیکی نویسنده مسئول: a_abbasi@semnan.ac.ir

چکیده

دیزل ژنراتورها در زیرساخت‌های حیاتی مانند بیمارستان‌ها و مراکز داده نقش مهمی در تأمین برق پایدار دارند. هرگونه خرابی یا افت عملکرد این تجهیزات می‌تواند منجر به توقف فرایندها و هزینه‌های سنگین تعمیرات شود. در این پژوهش رویکردی هوشمند برای تشخیص عیب دیزل ژنراتور ارائه شده است که بر پایه تحلیل داده‌های چندحسی شامل ارتعاش، صدا و پارامترهای محیطی و عملکردی (دمای موتور، فشار، رطوبت، ارتفاع، اکسیژن) انجام می‌گیرد. در مطالعه موردی، تأثیر گرفتگی فیلتر هوا در چند سطح مختلف ایجاد شده و داده‌های مربوطه توسط دستگاه پرتابل طراحی شده جمع‌آوری گردید. پس از انجام پیش‌پردازش و استخراج ویژگی، چندین مدل یادگیری ماشین شامل KNN، SVM، جنگل تصادفی و شبکه عصبی مصنوعی برای طبقه‌بندی وضعیت‌ها مورد ارزیابی قرار گرفتند. نتایج نشان داد شبکه عصبی بهترین عملکرد را داشته و توانست وضعیت گرفتگی فیلتر هوا را با دقت ۱۰۰٪ طبقه‌بندی کند. یافته‌های این پژوهش نشان می‌دهد ترکیب حسگرهای چندگانه با الگوریتم‌های یادگیری ماشین، ابزار مؤثری برای تشخیص زودهنگام عیب و پیاده‌سازی نگهداری پیش‌بینانه در دیزل ژنراتورها است و می‌تواند از توقف‌های ناگهانی و هزینه‌های تعمیراتی جلوگیری کند.

کلمات کلیدی: دیزل ژنراتور، تشخیص عیب، حسگرهای چندگانه، یادگیری ماشین، شبکه عصبی، نگهداری پیش‌بینانه.

۱- مقدمه

ژنراتورهای دیزلی به دلیل قابلیت اطمینان و کارایی‌شان در بخش‌های مختلفی از جمله تولید انرژی الکتریکی و کاربردهای صنعتی نقش حیاتی دارند. این ژنراتورها به عنوان منابع برق اضطراری در بیمارستان‌ها، مراکز داده، سازمان‌های دولتی و در عملیات‌های

امداد و نجات و پشتیبانی حوادث غیر مترقبه مورد استفاده قرار می‌گیرند. بنابراین هرگونه خرابی در این ژنراتورها می‌تواند منجر به اختلالات جدی در برنامه‌های پخش و از دست رفتن اطلاعات مهم شود. با وجود استحکامشان، ژنراتورهای دیزلی مستعد خرابی‌هایی هستند که می‌تواند کارایی عملیاتی و ایمنی آنها را به خطر بیاندازد. روش‌های سنتی نگهداری و تشخیص عیب می‌تواند زمان‌بر باشد که در مواقع بحرانی غیرقابل قبول است [۱]. پیشرفت‌های اخیر در فناوری‌های تشخیص عیب، استفاده از تکنیک‌های پیچیده‌تری مانند تحلیل صدا یا ارتعاش، مانیتورینگ دما و تحلیل گازهای خروجی را برای پیش‌بینی و تشخیص به موقع عیوب در ژنراتورهای دیزلی و با دقت بیشتر ممکن ساخته است [۲]. این روش‌ها می‌توانند مشکلات مکانیکی، داغ شدن و ناکارآمدی احتراق را شناسایی کرده و با استفاده از داده‌های به دست آمده، عملیات نگهداری پیش‌بینانه را مدیریت کنند. این رویکرد پیشگیرانه، مدت زمان خرابی و هزینه‌های نگهداری را به حداقل می‌رساند و تامین برق پایدار با قابلیت اطمینان بالا را فراهم می‌کند. در این مقاله به بررسی تأثیر گرفتگی فیلتر هوا بر عملکرد دیزل ژنراتور و همچنین استفاده از روش‌های یادگیری ماشین و شبکه‌های عصبی برای تشخیص این وضعیت پرداخته می‌شود. هدف این است که با استفاده از داده‌های جمع‌آوری شده از سنسورهای مختلف، الگوهای مشخصی را برای تشخیص گرفتگی فیلتر هوا شناسایی کرده و با استفاده از مدل‌های یادگیری ماشین و شبکه‌های عصبی این الگوها را طبقه‌بندی کنیم.

۲- تحلیل صدا، ارتعاش، دما و گازهای خروجی برای تشخیص عیوب ژنراتور

تحلیل صدا به عنوان یک روش غیرتهاجمی^۱ و مؤثر برای نظارت و نگهداری صحیح از ژنراتورهای دیزلی شناخته شده است. استفاده از سیگنال‌های صوتی برای شناسایی عملکرد غیر صحیح مزایای متعددی از جمله نظارت دائمی و تشخیص زودهنگام عیوب را ارائه می‌دهد. در یک مطالعه، از هوش مصنوعی به صورت الگوریتم‌های یادگیری عمیق^۲ بدون نظارت^۳ مانند CNN^۴ (شبکه عصبی پیچشی) برای تشخیص عیب در ژنراتورهای دیزلی استفاده شده است. محققان داده‌های صوتی را از ژنراتورهای دیزلی قبل و بعد از راه‌اندازی ضبط کردند و این ضبط‌ها را به تصاویر اسپکتروگرام^۵ تبدیل کردند. این تصاویر برای آموزش مدلی برای تشخیص صداهای طبیعی و غیرطبیعی استفاده شدند. در نهایت این ساختارافزایش دقت ۳ درصدی نسبت به روش‌های طبقه‌بندی دودویی^۶ سنتی را نشان داد [۳].

تحلیل ارتعاش نیز به عنوان یک ابزار حیاتی برای تشخیص عیب در ژنراتورهای دیزلی شناخته شده است. با تحلیل ارتعاشات تولید شده توسط موتور، می‌توان علائم اولیه مشکلات مکانیکی مانند عدم تعادل، ناهماهنگی، سایش و سایر عیوب که می‌تواند منجر به خرابی شود را شناسایی کرد. در یک مطالعه، روش تحلیل ارتعاش برای تخمین نوسانات سرعت توربوشارژر در موتورهای دیزلی استفاده شد. این روش به طور مؤثر ارتعاشات را با عملکرد توربوشارژر مرتبط کرد و دقت بالایی در شرایط عملیاتی مختلف نشان داد [۴]. مانیتورینگ دما نیز نقش حیاتی در تشخیص عیب برای موتورهای دیزلی دارد. این روش به عنوان یک روش غیرتهاجمی برای شناسایی ناهنجاری‌ها و پیش‌بینی خرابی‌های احتمالی استفاده می‌شود. دماهای بالا هم می‌توانند نشان‌دهنده مشکلاتی مانند خرابی عایق، اصطکاک بیش از حد یا انسداد جریان هوا باشند. در یک مطالعه، از مدل‌های مبتنی بر دمای گاز خروجی برای پیش‌بینی خرابی‌های انژکتورهای دیزلی استفاده شد که دقت بالایی را در تشخیص زود هنگام خرابی‌ها نشان داد [۵]. تحلیل گازهای خروجی نیز یک ابزار حیاتی برای تشخیص عیب در موتورهای دیزلی است. با نظارت بر ترکیب و دمای گازهای خروجی، می‌توان مشکلات مرتبط با

^۱ روشهای عمدتاً پیشگیرانه برای تعمیر موتور و همچنین روشهایی که نیاز به بازکردن و تعمیرات اساسی نمی‌باشد.

^۲ یادگیری عمیق (Deep learning)، از شبکه‌های عصبی مصنوعی برای انجام محاسبات پیچیده بر روی حجم زیادی از داده‌ها استفاده می‌کند. یادگیری عمیق، نوعی از یادگیری ماشین (machine learning) است که بر اساس ساختار و عملکرد مغز انسان کار می‌کند.

^۳ این الگوریتم‌ها، بدون نیاز به دخالت انسان، الگوهای پنهان یا گروه‌های مختلف موجود در داده‌ها را کشف می‌کنند.

^۴ Convolutional Neural Networks

^۵ اسپکتروگرام (spectrogram) نمایشی از طیف فرکانسی سیگنال در طول زمان است. اسپکتروگرام یک نقشه رنگی هست که برحسب زمان و فرکانس نمایش داده می‌شود و به ما کمک می‌کند تا متوجه شویم که طیف فرکانسی سیگنال در طول زمان به چه صورت تغییر می‌کند

^۶ طبقه بندی دودویی یا باینری به مسائلی از طبقه بندی که دارای دو برچسب کلاس هستند به طور مثال صفر و یک یا (yes , no) مسائل طبقه بندی دو کلاسه گفته می‌شود

احتراق را شناسایی کرد. در یک مطالعه، از الگوریتم‌های یادگیری عمیق برای پیش‌بینی انتشار^۱ NO_x استفاده شد که دقت بالایی را در پیش‌بینی و کنترل انتشار نشان داد [۶].

۳- نقش هوش مصنوعی در تقویت حس‌گرهای چندگانه برای تشخیص عیب

کاربرد هوش مصنوعی (AI) در سیستم‌های تشخیص عیب در حال تغییر نحوه نگهداری و نظارت بر ژنراتورهای دیزلی است. با ترکیب هوش مصنوعی با فناوری‌های حس‌گرهای چندگانه، سیستم‌ها می‌توانند به یک رویکرد دقیق‌تر و پیشگیرانه‌تر در تشخیص و جلوگیری از عیبه‌ها دست یابند. سیستم‌های مبتنی بر هوش مصنوعی از الگوریتم‌های پیشرفته، از جمله یادگیری ماشین و شبکه‌های عصبی استفاده می‌کنند تا از داده‌های از قبل ذخیره شده، بیاموزند و پیش‌بینی‌های آگاهانه‌ای درباره سلامت ژنراتورهای دیزلی انجام دهند. به عنوان مثال، با تحلیل فرکانس و دامنه داده‌های صدا و ارتعاش، هوش مصنوعی می‌تواند مسائل مکانیکی خاصی مانند خرابی بلبرینگ‌ها یا روتورهای نامتعادل را قبل از وقوع خرابی شناسایی کند. حس‌گرهای دما که توسط هوش مصنوعی مانیتور می‌شوند، می‌توانند مشکلات مربوط به داغ شدن را زود هنگام شناسایی کنند و تحلیل گازهای خروجی می‌تواند بینشی درباره کارایی احتراق و وجود نشت‌های داخلی فراهم کند [۷ و ۹].

جدول ۲: تحلیل مقایسه‌ای تکنیک‌های تشخیصی مبتنی بر هوش مصنوعی برای دیزل ژنراتورها

دسته بندی تکنیک‌های هوش مصنوعی	کاربرد تشخیصی	مزایا	محدودیت‌ها
یادگیری عمیق (شبکه‌های عصبی کانولوشنال)	تشخیص ناهنجاری در داده‌های صوتی و تصویری	بسیار مؤثر در تشخیص الگو؛ در ساختارهای پیچیده عملکرد خوبی دارد	نیازمند مجموعه داده‌های بزرگ و منابع محاسباتی قابل توجه
یادگیری ماشین (kNN, SVM، شبکه‌های عصبی)	نظارت بر دما، تجزیه و تحلیل فشار	قابل تطبیق با شرایط متغیر؛ زمان پاسخ‌گویی سریع	حساس به نویز؛ مستعد به بیش‌برازش ^۲
مدل‌های ترکیبی - CNN، CNN-RNN، LSTM	تجزیه و تحلیل آگزوز و نگهداری پیش‌بینانه	به طور مؤثر داده‌های مکانی و زمانی را ذخیره می‌کند؛ دقت پیش‌بینی را بهبود می‌بخشد	راه‌اندازی و یکپارچه‌سازی پیچیده؛ تقاضای بالای محاسباتی
یادگیری تقویتی	بهینه‌سازی عملیاتی	بصورت بهینه برنامه‌های نگهداری را یاد می‌گیرد	همگرایی کند؛ نیازمند داده‌های تعاملی گسترده
مدل‌های مولد ^۳ (GANs، VAE)	تقویت داده و شبیه‌سازی	مفید برای تولید داده‌های مصنوعی جهت آموزش سناریوهای با داده کم	ممکن است داده‌های غیر واقعی تولید کند؛ تنظیم دشوار

^۱ عبارت NO_x به دو اکسید مهم نیتروژن که عبارتند از NO و NO_2 اشاره می‌کند. برخلاف خود نیتروژن که ترکیبی بی‌ضرر است اکسیدهای آن خصوصاً دو مورد ذکر شده بسیار خطرناک اند و برای سلامتی انسان و محیط زیست مضر می‌باشند. این اکسیدها در محفظه‌های احتراق تشکیل می‌شوند و همراه با گازهای حاصل از احتراق وارد محیط زیست می‌شوند.

^۲ بیش‌برازش (Overfitting) یکی از خطاهای مدل‌سازی در علم داده است. این خطا هنگامی اتفاق می‌افتد که مدل ویژگی‌های داده‌های آموزشی را به‌جای یادگیری، حفظ کرده باشد، یعنی بیش‌ازحد روی آن آموزش دیده باشد؛ درنتیجه، این مدل فقط در مجموعه‌ی داده‌های آموزشی مفید خواهد بود و نه در مجموعه‌ی داده‌های دیگر که هنوز آن‌ها را ندیده است.

^۳ مدل مولد یا Generative Model مدل یادگیری ماشین است که هدف آن یادگیری الگوهای اساسی یا توزیع داده‌ها به‌منظور تولید داده‌های جدید و مشابه است. در اصل، مانند آموزش دادن به یک کامپیوتر است که داده‌های خود را براساس آنچه قبلاً دیده است تصور کند

۴- بررسی روش‌های هوشمند در تشخیص عیب و نگهداری دیزل ژنراتورها

۴-۱ بررسی تأثیر گرفتگی فیلتر هوا بر عملکرد دیزل ژنراتور

فیلتر هوا یکی از اجزای حیاتی در دیزل ژنراتورها است که وظیفه تصفیه هوای ورودی به موتور را بر عهده دارد. گرفتگی فیلتر هوا می‌تواند تأثیرات منفی زیادی بر عملکرد ژنراتور داشته باشد، از جمله:

۱. کاهش کارایی موتور: کاهش جریان هوا به موتور منجر به کاهش توان تولیدی و راندمان کلی موتور می‌شود.
۲. افزایش مصرف سوخت: موتور برای جبران کاهش جریان هوا، میزان سوخت تزریقی را افزایش می‌دهد که منجر به افزایش مصرف سوخت می‌شود.
۳. افزایش انتشار آلاینده‌ها: احتراق ناقص به دلیل کمبود هوا منجر به افزایش انتشار آلاینده‌ها می‌شود.
۴. افزایش دما و فشار داخلی موتور: کاهش جریان هوا می‌تواند باعث افزایش دما و فشار داخلی موتور شده و در نهایت به ایرادات مکانیکی منجر شود.

برای بررسی این تأثیرات، داده‌هایی از یک ژنراتور Deutz 912 با ۴ سیلندر جمع‌آوری شد. ورودی هوا به صورت مرحله به مرحله مسدود شده و در هر مرحله داده‌های مختلف از ۸ سنسور مختلف شامل سیگنال‌های ارتعاش، صدا، حسگر اکسیژن، دما، فشار، ارتفاع، رطوبت و دمای موتور جمع‌آوری شدند.

۴-۲ استفاده از روش‌های یادگیری ماشین و شبکه‌های عصبی برای تشخیص گرفتگی فیلتر هوا

هدف از استفاده از روش‌های یادگیری ماشین و شبکه‌های عصبی در این مطالعه، تشخیص گرفتگی فیلتر هوا بر اساس داده‌های جمع‌آوری شده از سنسورهای مختلف است. با استفاده از این روش‌ها، می‌توان الگوهای مشخصی را برای هر سطح از گرفتگی فیلتر هوا شناسایی کرده و آنها را طبقه‌بندی کرد.

۴-۲-۱ جمع‌آوری داده‌ها

داده‌های مورد استفاده در این مطالعه شامل پنج مجموعه داده مختلف بودند که هر کدام بیانگر وضعیت خاصی از دریچه بودند:

- Data1: دریچه باز
- Data2: دریچه ۹۰٪ بسته
- Data3: دریچه ۸۰٪ بسته
- Data4: دریچه ۷۰٪ بسته
- Data5: دریچه ۵۰٪ بسته

هر کدام از این داده‌ها شامل اندازه‌گیری‌هایی از ۸ نمونه سیگنال‌های ارتعاش، صدا، حسگر اکسیژن، دمای محیط، فشار هوا، ارتفاع از سطح دریا، رطوبت و دمای موتور هستند که با استفاده از یک دستگاه ثبت داده با نرخ ۱۰ هرتز (۱۰ نمونه در هر ثانیه) نمونه برداری شده‌اند.

۴-۲-۲ پیش‌پردازش داده‌ها

پیش از آموزش مدل‌ها، برای بهتر شدن کیفیت طبقه‌بندی داده‌ها، از چندین مرحله پیش‌پردازش استفاده می‌شود:

استخراج ویژگی‌ها: ستون‌های مرتبط با سیگنال‌های ارتعاش، صدا، حسگر اکسیژن، دما، فشار، ارتفاع، رطوبت و دمای موتور استخراج شدند.

ترکیب داده‌ها: تمامی مجموعه داده‌ها با هم ترکیب شده و یک مجموعه داده کلی ساخته شد.

استانداردسازی: برای هر ویژگی، میانگین و انحراف معیار محاسبه شده و داده‌ها به کمک این مقادیر استاندارد شدند.

تقسیم داده‌ها به دسته‌های آموزشی و آزمایشی: داده‌ها به دو دسته آموزشی (۸۰٪) و آزمایشی (۲۰٪) تقسیم شدند. این تقسیم‌بندی به مدل‌ها اجازه می‌دهد که بر اساس داده‌های آموزشی آموزش ببینند و سپس بر اساس داده‌های آزمایشی ارزیابی شوند.

۴-۲-۳ مدل‌سازی

چندین مدل یادگیری ماشین برای طبقه‌بندی داده‌ها استفاده شد. این مدل‌ها شامل SVM^1 ، KNN^2 ، Random Forest و شبکه عصبی بودند که از بین آنها روش شبکه‌های عصبی بهترین پاسخ را داشت.

۵- شبکه عصبی

شبکه‌های عصبی مصنوعی، یا شبکه‌های عصبی، یک تکنیک شناخته شده یادگیری ماشین برای پردازش داده از طریق لایه‌های تحلیلی است. شبکه‌های عصبی به دلیل توانایی‌شان در یادگیری ویژگی‌های پیچیده و غیربدری از داده‌ها، ابزارهای قدرتمندی برای طبقه‌بندی هستند علت نام‌گذاری شبکه‌های عصبی مصنوعی، شباهت این الگوریتم به مغز انسان است. مغز انسان شامل نورون‌های به هم پیوسته با دندریتهایی^۳ است که ورودی‌ها را دریافت می‌کنند. نورون، از این ورودی‌ها، یک سیگنال الکتریکی تولید کرده و از طریق آکسون^۴ به خروجی می‌دهد و سپس این سیگنال‌ها را به وسیله ترمینال‌های آکسونی بین دیگر نورون‌ها منتشر می‌کند [10].

۶-۱- اجزای شبکه عصبی

مشابه نورون‌ها در مغز انسان، شبکه‌های عصبی مصنوعی از نورون‌های به هم پیوسته تشکیل شده است که به آن‌ها گره^۵ نیز گفته می‌شود. این گره‌ها از طریق آکسون‌هایی که به آن‌ها یال^۶ می‌گویند با هم در ارتباط هستند. در یک شبکه عصبی، گره‌ها در کنار هم قرار می‌گیرند و لایه‌ها را تشکیل می‌دهند. لایه اول شامل داده خام مثل مقادیر عددی، متن، تصاویر و صوت هستند که بین گره‌ها تقسیم شده‌اند. سپس هر گره، اطلاعات را از طریق یال‌های شبکه، به لایه بعدی ارسال می‌کند. [11,12].

^۱ support vector machine


^۲ K-nearest neighbor

^۳ Dendrites

^۴ Axon

^۵ Node

^۶ Edge



شکل ۴. گره‌ها، وزن‌ها و تابع فعال‌سازی در یک شبکه عصبی ساده

شکل بالا گره‌ها، یال‌ها/وزن‌ها و تابع جمع/فعال‌سازی در یک شبکه عصبی ساده را نشان می‌دهد. هر یال، یک وزن عددی دارد که بر اساس تجربه، قابل تغییر یا فرمول‌سازی است. اگر مجموع یال‌های متصل به هم، شرط یک آستانه^۱ را برطرف کنند، یک نورون در لایه بعدی فعال می‌شود. این حد آستانه توسط تابع فعال‌سازی^۲ تعیین می‌شود. با این حال، اگر مجموع یال‌های متصل، شرط آستانه را برطرف نکنند، فعال‌سازی انجام نمی‌شود که انگار هیچ اتفاقی نیفتاده است.

برای آموزش شبکه از طریق یادگیری نظارتی، خروجی پیش‌بینی شده توسط مدل با خروجی واقعی (که می‌دانیم صحیح است) مقایسه می‌شود و میزان اختلاف بین این دو اندازه‌گیری می‌شود و به عنوان هزینه^۳ یا مقدار هزینه^۴ شناخته می‌شود. هدف از مرحله آموزش، کاهش مقدار هزینه تا جایی است که پیش‌بینی مدل تا حد زیادی به خروجی صحیح، شبیه بشود. این هدف با تغییر افزایشی وزن‌های شبکه تا جایی که کمترین مقدار هزینه ممکن به دست بیاید، انجام می‌شود. این فرایند آموزش شبکه عصبی، انتشار به عقب^۵ نامیده می‌شود. به جای حرکت از راست به چپ (به صورتی که داده به شبکه عصبی وارد می‌شود)، انتشار به عقب برعکس انجام می‌شود و از لایه خروجی از راست به سمت لایه ورودی به سمت چپ حرکت می‌کند.

۲-۶- انواع سلول‌ها و لایه‌ها در شبکه‌های عصبی

یک شبکه عصبی رایج به سه لایه ورودی، مخفی^۶ و خروجی تقسیم می‌شود. داده در ابتدا از لایه ورودی دریافت می‌شود، جایی که ویژگی‌های گسترده‌ای شناسایی می‌شوند. پس از آن، لایه‌های مخفی داده را تحلیل و پردازش می‌کنند. بر اساس محاسبات قبلی، داده با عبور از هر لایه مخفی ساده‌تر می‌شود. نتیجه نهایی در لایه خروجی نشان داده می‌شود.

لایه‌های میانی به این علت لایه‌های مخفی در نظر گرفته می‌شوند که مثل بینایی انسان، مخفیانه اشیا را بین لایه‌های ورودی و خروجی تجزیه و تحلیل می‌کنند. برای مثال، زمانی که انسان‌ها چهار خط متصل به هم به شکل یک مربع را می‌بینند، به سرعت آن چهار خط را به عنوان یک مربع می‌شناسند. چهار خط را به عنوان چهار خط مستقل و بدون ارتباط با یکدیگر نمی‌بینیم. مغز تنها متوجه لایه خروجی می‌شود. شبکه‌های عصبی تقریباً شبیه به این فرایند عمل می‌کنند، به طوری که داده را در لایه‌های مختلف تشریح و باز می‌کنند و با دست‌کاری لایه‌های مخفی تلاش می‌کنند تا خروجی نهایی را تولید کنند. درحالی‌که تکنیک‌های زیادی برای ترکیب

¹ Threshold

² Activation Function

³ Cost

⁴ Cost Value

⁵ Back-Propagation

⁶ Hidden

گره‌های یک شبکه عصبی وجود دارد، ساده‌ترین شکل آن شبکه روبه‌جلو^۱ است. در یک شبکه روبه‌جلو، سیگنال‌ها تنها در یک جهت در جریان هستند و هیچ حلقه‌ای در شبکه نیست [13].

۳-۶- شبکه مورد استفاده

در این پژوهش، آموزش شبکه عصبی به صورت یادگیری نظارتی انجام شده است. هدف، کمینه کردن تابع هزینه و تنظیم وزن‌ها به گونه‌ای است که خروجی پیش‌بینی شده مدل با مقدار واقعی منطبق شود. برای مسئله طبقه‌بندی چندکلاسه، تابع خطا به صورت تابع هزینه آنتروپی متقاطع^۲ تعریف می‌شود:

$$L = - \sum_{i=1}^C y_i \cdot \log(\hat{y}_i) \quad (1)$$

که در آن :

- C : تعداد کلاس‌ها
- y_i : مقدار واقعی برای کلاس i یکی از کلاس‌ها مقدار ۱ و بقیه ۰
- $\hat{y}_i$: احتمال پیش‌بینی شده توسط شبکه برای کلاس i

در طی آموزش، وزن‌های شبکه از طریق الگوریتم پس‌انتشار خطا^۳ به‌روزرسانی می‌شوند. به‌روزرسانی وزن‌ها طبق رابطه زیر انجام می‌گیرد:

$$w = w - \eta \frac{\partial L}{\partial w} \quad (2)$$

که در آن:

- w : وزن‌های شبکه
- η : نرخ یادگیری
- $\frac{\partial L}{\partial w}$: گرادیان تابع هزینه نسبت به وزن‌ها


در این مقاله بعد آزمایش و خطا و مقایسه خطای هر ساختار، شبکه عصبی با سه لایه مخفی و تعداد نورون‌های ۱۰۰، ۵۰ و ۲۵ انتخاب شد. پارامترهای این مدل به صورت زیر تنظیم شدند:

تعداد اپوک‌ها: ۵۰۰، نرخ یادگیری: ۰.۰۰۱ و الگوریتم آموزشی: trainscg

^۱ Feed-Forward

^۲ Cross-Entropy Loss

^۳ Backpropagation



شکل ۶. ساختار مورد استفاده در این تحقیق

۶- نتایج

۶-۱ دقت مدل‌ها

برای ارزیابی مدل‌ها از معیار دقت (Accuracy) استفاده شده است که نسبت تعداد پیش‌بینی‌های درست به کل نمونه‌ها را نشان می‌دهد. تعریف ریاضی این معیار به صورت زیر است:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

که در آن:


- **TP**: موارد درست تشخیص داده شده به عنوان کلاس مثبت
- **TN**: موارد درست تشخیص داده شده به عنوان کلاس منفی
- **FP**: مواردی که مدل اشتباه، مثبت تشخیص داده
- **FN**: مواردی که مدل اشتباه، منفی تشخیص داده

این معیار برای مقایسه عملکرد مدل‌های SVM، KNN، Random Forest و شبکه عصبی در این مقاله استفاده شد. نتایج دقت مدل‌های مختلف به شرح جدول زیر بود:

جدول ۳. مقایسه نتایج روش‌های مختلف

مدل	دقت (Accuracy)
SVM	82.79%
KNN	85.60%
Random Forest	99.91%
شبکه عصبی	100%

برای تست اعتبار شبکه از یک سری داده که در روز دیگری ضبط شده بود استفاده شد و شبکه عصبی توانست داده‌های مربوط به وضعیت "دریچه با ۵۰ درصد گرفتگی" را با دقت ۱۰۰٪ طبقه‌بندی کند. این مدل با استفاده از دو لایه مخفی و تعداد نورون‌های ۵ و ۲۵ توانست به خوبی الگوهای پیچیده موجود در داده‌ها را شناسایی کند.



شکل ۷. مقایسه دقت مدل‌های مختلف

۲-۶ تحلیل نتایج

SVM : مدل SVM توانست با دقت ۸۲.۷۹٪ داده‌ها را طبقه‌بندی کند. این مدل با استفاده از هسته خطی و روش ^۱ onevsall آموزش داده شد. این مدل در شناسایی الگوهای خطی در داده‌ها عملکرد خوبی داشت، اما در مقایسه با مدل‌های دیگر نتوانست به دقت بالایی دست یابد.

KNN : مدل KNN با دقت ۸۵.۶۰٪ عملکرد بهتری نسبت به SVM داشت. این مدل بر اساس نزدیک‌ترین همسایه‌ها در فضای ویژگی تصمیم‌گیری می‌کند و در شناسایی الگوهای محلی و غیربدیهی کارآمد است.

Random Forest : مدل Random Forest با دقت ۹۹.۹۱٪ بهترین عملکرد را در بین مدل‌های مختلف داشت. این مدل با استفاده از ۱۰۰ درخت تصمیم‌گیری توانست به خوبی الگوهای موجود در داده‌ها را شناسایی و طبقه‌بندی کند. **شبکه عصبی** : شبکه عصبی با دقت ۱۰۰٪ در طبقه‌بندی داده‌های مربوط به وضعیت "دریچه با ۵۰ درصد گرفتگی" بهترین عملکرد را داشت.

۷- نتیجه‌گیری

ادغام تکنیک‌های پیشرفته تشخیص عیب مانند تحلیل صدا یا ارتعاش، مانیتورینگ دما و تحلیل گازهای خروجی با سیستم‌های مبتنی بر هوش مصنوعی پتانسیل زیادی برای بهبود قابلیت اطمینان و کارایی ژنراتورهای دیزلی دارد. این روش‌ها امکان تشخیص زودهنگام و دقیق عیب‌ها را فراهم می‌کنند و استراتژی‌های نگهداری پیش‌بینانه و پیشگیرانه را امکان‌پذیر می‌سازند که به کاهش زمان خرابی و هزینه‌های نگهداری منجر می‌شود. با وجود محدودیت‌های کنونی در استفاده از حس‌گرهای چندگانه و کاربردهای هوش مصنوعی، پژوهش‌های آینده و پیشرفت‌های فناوری می‌توانند این چالش‌ها را برطرف کرده و به توسعه سیستم‌های تشخیص عیب مؤثرتر و قابل اعتمادتر منجر شوند. استفاده از مدل‌های مختلف یادگیری ماشین در مورد یک ژنراتور مورد استفاده در سازمان صدا و

^۱ روش "one-vs-all" (یک در برابر همه) یکی از تکنیک‌های متداول برای انجام طبقه‌بندی چندکلاسه با استفاده از الگوریتم‌های طبقه‌بندی دودویی (binary classifiers) است. در این روش، یک مدل طبقه‌بندی دودویی برای هر کلاس ایجاد می‌شود. هر مدل یک کلاس را از بقیه کلاس‌ها جدا می‌کند.

سیما نشان داد که شبکه عصبی بهترین عملکرد را در طبقه‌بندی وضعیت دریچه‌های هوا دارد. شبکه عصبی با دقت ۱۰۰٪ نشان داد توانایی بالایی در تشخیص الگوهای پیچیده و غیربدیهی دارد. این مطالعه تأکید می‌کند که تکنیک‌های یادگیری ماشین و شبکه‌های عصبی می‌توانند به طور مؤثری در کاربردهای صنعتی برای نظارت و طبقه‌بندی وضعیت تجهیزات مورد استفاده قرار گیرند.

۸- مراجع

1. Ciaburro, G. (2022). Machine fault detection methods based on machine learning algorithms: A review. *Mathematical Biosciences and Engineering, 19*(11), 11453-11490.
2. Ciaburro, G. 2022. Machine fault detection methods based on machine learning algorithms: A review. Mathematical Biosciences and Engineering, 19. (11), 11453-11490. 10.3934
3. Allam, Sabry & Abdo, Mohammed & Rabie, Mohammed. 2018. Diesel Engine Fault Detection Using Vibration and Acoustic Emission Signals. International Journal of Advances in Scientific Research and Engineering. 4. 10.31695/IJASRE.2018.33005.
4. Michael G. Thurston, Matthew R. Sullivan, Sean P. McConky. 2023. Exhaust-gas temperature model and prognostic feature for diesel engines, Applied Thermal Engineering, Volume 229, 2023, 120578, ISSN 1359-4311, 10.1016/j.applthermaleng.2023.120578.
5. Yu, Yang & Wang, Yanyan & Li, Jiaqiang & Fu, Mingliang & Shah, A.N. & He, Chao. 2021. A Novel Deep Learning Approach to Predict the Instantaneous NO_x Emissions From Diesel Engine. IEEE Access. PP. 1-1. 10.1109/ACCESS.2021.3050165.
6. Karatug, Ç., & Arslanoğlu, Y. 2022. Development of condition-based maintenance strategy for fault diagnosis for ship engine systems. Ocean Engineering, 256, 111515. 10.1016/ 2022.1.
7. Issa, M., Ibrahim, H., Hosni, H., Ilinca, A., & Rezkallah, M. 2020. Effects of Low Charge and Environmental Conditions on Diesel Generators Operation. Engineering, 1, 137-152. 10.3390.
8. Fabbiano, Laura & Vacca, Gaetano & Dinardo, Giuseppe. 2018. A smart and intuitive machine condition monitoring in the Industry 4.0 scenario. Measurement. 126. 10.1016/ 2018.05.041.
9. Fonte, Manuel & Freitas, Manuel. 2009. Marine main engine crankshaft failure analysis: A case study. Engineering Failure Analysis. 16. 1940-1947. 10.1016/j.engfailanal.2008.10.013.
10. Tharanga, K. & Liu, Shuyong & Zhang, Shuai & Wang, Yuan. 2020. Diesel Engine Fault Diagnosis with Vibration Signal. Journal of Applied Mathematics and Physics. 08. 2031-2042. 10.4236/jamp.2020.89151.
11. Ameer H. Sabry, Ungku Anisa Bte Ungku Amirulddin. 2024. A review on fault detection and diagnosis of industrial robots and multi-axis machines, Results in Engineering, Volume 23. 102397, ISSN 2590-1230, 10.1016/j.rineng.2024.102397.
12. Cao, Wenjing & Wang, Jiabiao & Chen, Jiajie & Xu, Jing. 2023. Diesel generator sensor fault diagnosis model based on LMD-SVM algorithm. 190-194. 10.1109/ ICPRE 59655.
13. Shen, Qianqiao, Guiyong Wang, Yuhua Wang, Boshun Zeng, Xuan Yu, and Shuchao He. 2023. "Prediction Model for Transient NO_x Emission of Diesel Engine Based on CNN-LSTM Network" Energies 16, no. 14: 5347. 10.3390/en16145347
14. Hou, Wenkui, Wanyu Li, and Pengyu Li. 2023. Fault Diagnosis of the Autonomous Driving Perception System Based on Information Fusion. Sensors 23, no. 11: 5110. /10.3390/s23115110.
15. Surucu, O., Gadsden, S. A., & Yawney, J. 2023. Condition Monitoring using Machine Learning: A Review of Theory, Applications, and Recent Advances. Expert Systems with Applications, 221, 119738. 10.1016/j.eswa.2023.119738