
تحلیل و بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین

احسان عبدالله زاده شهربابکی

۱- گروه مهندسی مکانیک، دانشگاه ملی مهارت، تهران، ایران

چکیده

در این پژوهش، به تحلیل و بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین پرداخته شده است. هدف اصلی این تحقیق، بررسی تأثیر تکنیک‌های پیشرفته بر عملکرد سیستم‌های مکانیکی و شناسایی عیوب موجود در آن‌ها است. در این راستا، داده‌های جمع‌آوری شده از حسگرهای مختلف شامل شتاب‌سنج، فشارسنج و حسگرهای صوتی مورد تجزیه و تحلیل قرار گرفتند. یکی از مراحل کلیدی در این پژوهش، حذف نویز و نرمال‌سازی داده‌ها بود. با استفاده از فیلتر پایین‌گذر Butterworth و تکنیک‌های مقیاس‌بندی، کیفیت داده‌ها بهبود یافته و امکان استخراج ویژگی‌های مهم فراهم گردید. استفاده از تحلیل موجک و تحلیل مؤلفه‌های اصلی نیز به کاهش ابعاد داده‌ها و حفظ اطلاعات حیاتی کمک کرد. در مرحله مدل‌سازی، الگوریتم‌های مختلف شامل شبکه‌های عصبی عمیق، ماشین‌های بردار پشتیبان و جنگل تصادفی به کار گرفته شدند. نتایج نشان داد که DNN با دقت ۹۵ درصد بهترین عملکرد را در شناسایی عیوب داشته و توانایی بالایی در تمایز بین کلاس‌های مختلف دارد. این تحقیق نشان می‌دهد که ترکیب الگوریتم‌های یادگیری ماشین با روش‌های پیشرفته پردازش داده می‌تواند به بهبود کارایی سیستم‌های مکانیکی و کاهش هزینه‌های نگهداری منجر شود. بنابراین، استفاده از این روش‌ها به عنوان یک راهکار نوآورانه در تحلیل و بهینه‌سازی سیستم‌های ارتعاشی پیشنهاد می‌شود.

واژگان کلیدی: تحلیل، بهینه‌سازی، ارتعاشی، الگوریتم‌های هوش مصنوعی، یادگیری ماشین

مقدمه

ارتعاشات به عنوان یک پدیده فیزیکی، در بسیاری از سیستم‌های مکانیکی و ساختاری نقش حیاتی ایفا می‌کنند. این پدیده، ناشی از نوسانات اجزای سیستم در اطراف حالت تعادل خود است و می‌تواند تأثیرات قابل توجهی بر عملکرد، ایمنی و عمر مفید تجهیزات و سازه‌ها داشته باشد. در واقع، ارتعاشات می‌توانند به عنوان یک نشانگر اولیه برای شناسایی عیوب و نقص‌های موجود در سیستم‌های مکانیکی عمل کنند و به همین دلیل، تحلیل دقیق آن‌ها از اهمیت بالایی برخوردار است. به ویژه در صنایع پیشرفته، مانند خودروسازی، هوافضا و تولید افزودنی، نظارت بر ارتعاشات می‌تواند به بهبود کیفیت محصولات و کاهش هزینه‌های تعمیر و نگهداری کمک کند (Silvestri, ۲۰۲۱ & Scheffel, Fröhlich).

با توجه به اینکه هر سیستم مکانیکی دارای ویژگی‌های خاص خود است، درک عمیق‌تری از رفتار ارتعاشی آن نیازمند استفاده از تکنیک‌های پیشرفته تحلیلی است. در این راستا، استفاده از داده‌های جمع‌آوری شده از حسگرهای ارتعاشی به عنوان ابزاری برای تحلیل و پیش‌بینی رفتار سیستم‌ها به شدت مورد توجه قرار گرفته است. حسگرهای ارتعاشی قادرند داده‌های دقیقی از نوسانات سیستم به دست آورند و این داده‌ها می‌توانند به عنوان ورودی برای الگوریتم‌های تحلیلی و یادگیری ماشین مورد استفاده قرار گیرند (Bernardin, ۲۰۲۴ & Waheed). این نوع رویکرد، به مهندسان این امکان را می‌دهد که با تحلیل داده‌ها، به شناسایی و پیش‌بینی عیوب در سیستم‌های مکانیکی بپردازند و به این ترتیب، از بروز مشکلات جدی جلوگیری کنند.

علاوه بر این، تکنیک‌های هوش مصنوعی به ویژه در زمینه تحلیل ارتعاشات، پتانسیل فوق‌العاده‌ای برای بهبود فرآیندها و کاهش هزینه‌ها دارند. این تکنیک‌ها به کمک الگوریتم‌های یادگیری ماشین می‌توانند الگوهای پیچیده‌ای را در داده‌های ارتعاشی شناسایی کنند که ممکن است به راحتی توسط روش‌های سنتی قابل شناسایی نباشند. به عنوان مثال، با استفاده از این الگوریتم‌ها، می‌توان به پیش‌بینی و تشخیص عیوب در سیستم‌های خودرویی پرداخت که به طور قابل توجهی کارایی نگهداری و تعمیرات را بهبود می‌بخشد (Ramasamy, ۲۰۲۴ & Hossain, Rahman).

در زمینه تولید افزودنی، استفاده از حسگرهای ارتعاشی برای تشخیص خودکار عیوب به یک روند رو به رشد تبدیل شده است. این حسگرها به مهندسان اجازه می‌دهند تا به صورت لحظه‌ای وضعیت سیستم را زیر نظر داشته باشند و به شناسایی مشکلاتی نظیر عدم تراز بودن اجزاء یا خرابی ماشین‌آلات بپردازند. این نوع نظارت و تحلیل می‌تواند به افزایش کارایی و کاهش زمان توقف تجهیزات کمک کند (Nastasi, ۲۰۲۴). به طور خاص، استفاده از داده‌های ارتعاشی به عنوان ورودی برای الگوریتم‌های هوش مصنوعی به مهندسان این امکان را می‌دهد که به پیش‌بینی و شناسایی عیوب احتمالی بپردازند و از بروز مشکلات جدی در سیستم‌ها جلوگیری کنند.

با توجه به تحولات روزافزون در زمینه تکنولوژی‌های هوش مصنوعی و یادگیری ماشین، تحقیقات در حوزه ارتعاشات به سمت یکپارچگی این دو زمینه پیش می‌رود. این یکپارچگی می‌تواند به طراحی سیستم‌های هوشمند و خودکار منجر شود که قادر به نظارت بر وضعیت خود و بهینه‌سازی عملکرد خود به صورت مستمر هستند. در این راستا، استفاده از الگوریتم‌های پیشرفته در تحلیل داده‌های ارتعاشی می‌تواند به مهندسان کمک کند تا به طراحی سیستم‌های کارآمدتر و ایمن‌تر دست یابند (Knutel, ۲۰۲۴). با توجه به چالش‌ها و فرصت‌های موجود، این مقاله به بررسی و تحلیل سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین می‌پردازد و تلاش می‌کند تا به درک بهتری از این زمینه نوآورانه در مهندسی مکانیک دست یابد.

۱- مروری بر پژوهش‌های پیشین

تحقیقات در زمینه ارتعاشات و کاربردهای آن در مهندسی مکانیک به سرعت در حال گسترش است و این حوزه به طور فزاینده‌ای به تکنیک‌های نوین و پیشرفته مانند هوش مصنوعی و یادگیری ماشین وابسته می‌شود. ارتعاشات به عنوان یک پدیده فیزیکی، در بسیاری از سیستم‌های مکانیکی و ساختاری نقش حیاتی ایفا می‌کنند. این پدیده ناشی از نوسانات اجزای سیستم در اطراف حالت تعادل خود است و می‌تواند تأثیرات قابل توجهی بر عملکرد، ایمنی و عمر مفید تجهیزات و سازه‌ها داشته باشد. به عنوان مثال، ارتعاشات می‌توانند به عنوان یک نشانگر اولیه برای شناسایی عیوب و نقص‌های موجود در سیستم‌های مکانیکی عمل کنند و به همین دلیل، تحلیل دقیق آن‌ها از اهمیت بالایی برخوردار است. به ویژه در صنایع پیشرفته، مانند خودروسازی، هوافضا و تولید افزودنی، نظارت بر ارتعاشات می‌تواند به بهبود کیفیت محصولات و کاهش هزینه‌های تعمیر و نگهداری کمک کند (Silvestri, & Scheffel, Fröhlich, ۲۰۲۱).

در این راستا، تحقیقات جدید به بررسی استفاده از حسگرهای ارتعاشی برای تشخیص خودکار عیوب در فرآیندهای تولید پرداخته‌اند. به طور خاص، Scheffel و همکاران (۲۰۲۱) در تحقیق خود به بررسی این موضوع پرداختند که چگونه حسگرهای ارتعاشی می‌توانند به شناسایی سریع و دقیق نواقص در محصولات کمک کنند. آن‌ها نشان دادند که با استفاده از این حسگرها، می‌توان مشکلات را به صورت بلادرنگ شناسایی و رفع کرد، و این امر می‌تواند بهبود قابل توجهی در کیفیت تولید به ارمغان آورد. این نوع رویکرد به مهندسان اجازه می‌دهد که پیش از آنکه مشکلات جدی به وقوع بپیوندد، به آن‌ها واکنش نشان دهند و از بروز خسارات بزرگ جلوگیری کنند.

علاوه بر این، پژوهش‌های دیگری نیز به بررسی کاربردهای هوش مصنوعی در تحلیل داده‌های ارتعاشی پرداخته‌اند. برای نمونه، Waheed و Bernardin (۲۰۲۴) در تحقیق خود به تحلیل داده‌های ارتعاشی و صوتی در تولید افزودنی پرداخته و نشان دادند که این داده‌ها می‌توانند به عنوان ورودی برای

الگوریتم‌های یادگیری ماشین مورد استفاده قرار گیرند. آن‌ها دریافتند که با تجزیه و تحلیل داده‌های جمع‌آوری شده از حسگرهای ارتعاشی، می‌توان به شناسایی الگوهای غیرعادی و پیش‌بینی رفتار سیستم‌های مکانیکی پرداخت. این یافته‌ها اهمیت استفاده از فناوری‌های نوین در بهینه‌سازی فرآیندهای تولید و نگهداری را تأکید می‌کند و نشان می‌دهد که بهره‌گیری از این تکنیک‌ها می‌تواند به بهبود عملکرد سیستم‌های پیچیده کمک کند.

در ادامه، در زمینه نگهداری و تعمیرات، Rahman, Hossain و Ramasamy (۲۰۲۴) به بررسی تشخیص عیوب در خودروها با استفاده از هوش مصنوعی پرداخته‌اند. آن‌ها تأکید کردند که استفاده از الگوریتم‌های یادگیری ماشین می‌تواند به‌طور قابل توجهی کارایی نگهداری را بهبود بخشد و زمان و هزینه‌های مرتبط با تعمیرات را کاهش دهد. این تحقیقات نشان‌دهنده پتانسیل بالای هوش مصنوعی در پیش‌بینی و شناسایی عیوب در سیستم‌های پیچیده مکانیکی است و به مهندسان این امکان را می‌دهد که با اطلاعات دقیق‌تر و به موقع‌تر تصمیم‌گیری کنند. این نوع رویکردها می‌تواند به‌ویژه در صنایع خودروسازی که نیاز به نظارت و نگهداری مداوم دارند، بسیار کارآمد باشد.

در جنبه‌های دیگر، تکنیک‌های پیشرفته نگهداری پیش‌بین نیز در حال توسعه هستند. Nastasi (۲۰۲۴) در مطالعه خود به بررسی تکنیک‌های نگهداری پیش‌بین مبتنی بر هوش مصنوعی برای بلبرینگ‌ها پرداخته و به روندهای نوظهوری در این زمینه اشاره کرده است. یافته‌های او نشان می‌دهد که با استفاده از الگوریتم‌های هوش مصنوعی، می‌توان به شناسایی الگوهای خرابی و پیش‌بینی زمان نیاز به تعمیرات پرداخت. این نوع رویکرد می‌تواند به کاهش هزینه‌ها و افزایش عمر مفید تجهیزات کمک کند. به‌ویژه، با توجه به اهمیت بلبرینگ‌ها در عملکرد روان و بهینه ماشین‌آلات، استفاده از این تکنیک‌ها می‌تواند تأثیرات مثبتی بر بهره‌وری کلی سیستم‌ها داشته باشد.

علاوه بر این، Knüttel (۲۰۲۴) در پایان‌نامه دکتری خود به کاربردهای هوش مصنوعی در ماشین‌های تولیدی پرداخته و پیشنهاد کرده است که ترکیب این تکنیک‌ها با تحلیل ارتعاشات می‌تواند به بهبود فرآیندهای تولید و افزایش کارایی کمک کند. او به این نکته اشاره می‌کند که با استفاده از هوش مصنوعی، می‌توان به طراحی سیستم‌های هوشمندتری دست یافت که قادر به نظارت بر وضعیت خود و بهینه‌سازی عملکرد خود به‌صورت مستمر هستند. این یافته‌ها نشان می‌دهد که تجزیه و تحلیل داده‌های ارتعاشی با استفاده از الگوریتم‌های پیشرفته می‌تواند به‌عنوان یک ابزار کلیدی در بهینه‌سازی عملکرد سیستم‌های مکانیکی عمل کند و به مهندسان این امکان را می‌دهد که به طراحی و بهینه‌سازی سیستم‌های کارآمدتر و ایمن‌تر بپردازند.

در مجموع، این مرور بر تحقیقات پیشین نشان می‌دهد که ترکیب تکنیک‌های هوش مصنوعی و تحلیل ارتعاشات می‌تواند به بهبود کیفیت و کارایی سیستم‌های مکانیکی کمک کند. این روند به وضوح نشان‌دهنده نیاز به تحقیق و توسعه بیشتر در این زمینه است تا بتوان از پتانسیل‌های موجود بهره‌برداری

کرد و به طراحی و بهینه‌سازی سیستم‌های مکانیکی با کارایی بالاتر و ایمنی بیشتر دست یافت. در نهایت، با توجه به تحولات روزافزون در زمینه تکنولوژی‌های هوش مصنوعی و یادگیری ماشین، به نظر می‌رسد که آینده این حوزه بسیار روشن است و می‌تواند به ایجاد راهکارهای نوآورانه و مؤثر در صنعت منجر شود.

۲- روش‌شناسی

تحلیل و بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین یک حوزه تحقیقاتی پیچیده و چندبعدی است که می‌تواند به بهبود عملکرد سیستم‌های مکانیکی و کاهش هزینه‌های نگهداری و تعمیرات کمک کند. این فرآیند شامل مراحل متعددی از جمع‌آوری داده‌ها تا تجزیه و تحلیل و سپس بهینه‌سازی عملکرد سیستم‌ها می‌شود. در اینجا، روش‌شناسی جامع و مفصل این تحلیل و بهینه‌سازی را بررسی می‌کنیم.

در مرحله اول، جمع‌آوری داده‌ها به‌عنوان یک گام اساسی در این فرآیند به شمار می‌آید. برای انجام این کار، حسگرهای ارتعاشی بر روی اجزای مختلف سیستم نصب می‌شوند تا داده‌های مربوط به نوسانات و ارتعاشات سیستم را در شرایط مختلف جمع‌آوری کنند. این حسگرها معمولاً شامل شتاب‌سنج‌ها، حسگرهای فشار و حسگرهای صوتی هستند که می‌توانند اطلاعات دقیقی از وضعیت ارتعاشات سیستم به‌دست آورند. داده‌های جمع‌آوری‌شده باید از نظر زمان، فرکانس و شدت نوسانات تحلیل شوند تا الگوها و رفتارهای خاص سیستم شناسایی گردد. به‌علاوه، داده‌های محیطی مانند دما، رطوبت و فشار نیز می‌توانند بر رفتار ارتعاشی تأثیر بگذارند و لذا باید در فرآیند جمع‌آوری داده‌ها مورد توجه قرار گیرند. این مرحله نه‌تنها شامل استفاده از حسگرهای مختلف است، بلکه همچنین نیازمند طراحی یک سیستم جمع‌آوری داده یکپارچه و کارآمد است که قابلیت پردازش و ذخیره‌سازی داده‌های بزرگ را داشته باشد. پس از جمع‌آوری داده‌ها، مرحله پردازش داده‌ها آغاز می‌شود. در این مرحله، داده‌های خام به‌دست‌آمده از حسگرها به‌صورت مناسب برای تحلیل‌های بعدی آماده می‌شوند. این شامل حذف نویز، نرمال‌سازی داده‌ها و تبدیل آن‌ها به فرمت‌های قابل استفاده برای الگوریتم‌های یادگیری ماشین است. همچنین، در این مرحله ممکن است از تکنیک‌های تحلیل زمان-فرکانس، مانند تبدیل فوریه یا تحلیل موجک، برای استخراج ویژگی‌های مهم از داده‌ها استفاده شود. این ویژگی‌ها می‌توانند شامل پارامترهای فرکانسی، دامنه و شکل موج‌های ارتعاشی باشند که در شناسایی الگوهای رفتار سیستم کمک شایانی می‌کنند. به‌علاوه، در این مرحله می‌توان از تکنیک‌های کاهش ابعاد مانند PCA (تحلیل مؤلفه‌های اصلی) استفاده کرد تا ویژگی‌های مهم را شناسایی و ابعاد داده‌ها را کاهش دهد.

مدل‌سازی مرحله بعدی در این روش‌شناسی است که در آن از الگوریتم‌های هوش مصنوعی و یادگیری ماشین برای تحلیل داده‌های پردازش‌شده استفاده می‌شود. الگوریتم‌های مختلفی برای این منظور وجود

دارند، از جمله درختان تصمیم، ماشین‌های بردار پشتیبان^۱، شبکه‌های عصبی عمیق و الگوریتم‌های یادگیری تقویتی. انتخاب الگوریتم مناسب بستگی به نوع داده‌ها، پیچیدگی سیستم و هدف تحلیل دارد. به عنوان مثال، در مواردی که نیاز به شناسایی الگوهای پیچیده در داده‌های ارتعاشی وجود دارد، شبکه‌های عصبی عمیق ممکن است گزینه بهتری باشند. همچنین، برای مسائل با داده‌های کم، الگوریتم‌های یادگیری نظارت‌شده می‌توانند به عنوان ابزارهای مؤثری برای پیش‌بینی رفتار سیستم‌ها مورد استفاده قرار گیرند.

پس از انتخاب الگوریتم، مرحله آموزش مدل آغاز می‌شود. در این مرحله، مدل با استفاده از داده‌های آموزشی که شامل نمونه‌های مختلف رفتار سیستم در شرایط مختلف است، آموزش داده می‌شود. الگوریتم یادگیری ماشین با استفاده از این داده‌ها الگوهای رفتاری سیستم را شناسایی کرده و قادر به پیش‌بینی رفتارهای آینده خواهد بود. این فرآیند معمولاً شامل تقسیم داده‌ها به مجموعه‌های آموزشی و آزمایشی است تا اطمینان حاصل شود که مدل به خوبی تعمیم‌پذیری دارد و بر روی داده‌های جدید عملکرد خوبی از خود نشان می‌دهد. برای بهینه‌سازی فرآیند آموزش، می‌توان از تکنیک‌هایی مانند کروس والیدیشن^۲ و تنظیم هایپر پارامترها استفاده کرد. این کار به مدل کمک می‌کند تا به بهترین عملکرد خود دست یابد و از اورفیتینگ^۳ جلوگیری کند.

پس از آموزش مدل، مرحله ارزیابی و اعتبارسنجی آغاز می‌شود. در این مرحله، مدل آموزش‌دیده با استفاده از داده‌های آزمایشی مورد ارزیابی قرار می‌گیرد تا عملکرد آن اندازه‌گیری شود. معیارهای مختلفی برای ارزیابی عملکرد مدل وجود دارد، از جمله دقت، حساسیت، و خاصیت مثبت کاذب. در صورتی که عملکرد مدل رضایت‌بخش نباشد، ممکن است نیاز به تنظیم مجدد پارامترها، انتخاب ویژگی‌های جدید یا حتی تغییر الگوریتم باشد. این مرحله از اهمیت بالایی برخوردار است، زیرا اطمینان می‌دهد که مدل می‌تواند به طور مؤثری بر روی داده‌های جدید و واقعی عمل کند و به پیش‌بینی عیوب و رفتارهای غیرعادی در سیستم‌های مکانیکی بپردازد.

در نهایت، مرحله بهینه‌سازی آغاز می‌شود. در این مرحله، با استفاده از مدل آموزش‌دیده، به شناسایی و پیش‌بینی عیوب در سیستم پرداخته می‌شود. همچنین، با استفاده از الگوریتم‌های بهینه‌سازی مانند الگوریتم ژنتیک، بهینه‌سازی تجمعی و سایر روش‌های بهینه‌سازی هوشمند، می‌توان به بهینه‌سازی عملکرد سیستم پرداخته و شرایط بهینه برای کاهش ارتعاشات و افزایش کارایی سیستم را شناسایی کرد. این فرآیند می‌تواند به طور مداوم انجام شود تا با تغییر شرایط محیطی و بارگذاری، سیستم به روز شود و بهینه‌ترین عملکرد را ارائه دهد. به علاوه، استفاده از روش‌های شبیه‌سازی می‌تواند به تحلیل رفتار سیستم در شرایط مختلف و شناسایی نقاط ضعف و قوت آن کمک کند.

^۱ . SVM

^۲ . Cross-Validation

^۳ . Overfitting

در نهایت، یکپارچگی این مراحل و استفاده از تکنیک‌های نوین در هر یک از آن‌ها می‌تواند به تحلیل و بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین امکان‌پذیر سازد. این روش‌شناسی می‌تواند به طرز قابل توجهی به بهبود کیفیت و کارایی سیستم‌های مکانیکی کمک کند. با توجه به پیشرفت‌های روزافزون در زمینه تکنولوژی‌های هوش مصنوعی، این رویکرد می‌تواند به‌عنوان یک ابزار مؤثر در طراحی و بهینه‌سازی سیستم‌های پیچیده در صنایع مختلف مورد استفاده قرار گیرد و موجب کاهش هزینه‌ها و افزایش ایمنی در عملکرد سیستم‌ها شود. در نهایت، این روش‌شناسی می‌تواند به عنوان یک چارچوب جامع برای پژوهشگران و مهندسان در زمینه تحلیل و بهینه‌سازی سیستم‌های مکانیکی و ارتعاشی عمل کند و به توسعه راهکارهای نوآورانه و کارآمد در این حوزه کمک نماید.

۳- تحلیل یافته‌های پژوهش

در این بخش، نتایج حاصله از فرآیندهای جمع‌آوری، پردازش، مدل‌سازی، ارزیابی و بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین به صورت دقیق و جامع بررسی می‌شوند. هدف از این تحلیل، نه تنها تالیف داده‌های به‌دست‌آمده است، بلکه درک کامل و تفهیم تاثیر هریک از مرحله‌ها و تکنیک‌های به‌کار رفته بر روی کارایی کلی سیستم و بهبود عملکرد آن است. در این روند، تحلیل‌هایی آماری، عددی و تصویری همراه با تفسیرهای فنی ارائه می‌گردد تا تصویر جامع و دقیقی از وضعیت پروژه و یافته‌های آن ترسیم شود.

۴-۱- نتایج جمع‌آوری داده‌ها: تحلیل عمیق وضعیت اولیه

جمع‌آوری داده‌ها: اساس پویایی‌های سیستم

در فرآیند جمع‌آوری داده‌ها، چندین نوع حسگر متفاوت به منظور ثبت نوسانات و ارتعاشات در سیستم‌های مکانیکی نصب شده‌اند. این حسگرها شامل شتاب‌سنج، فشارسنج و حسگرهای صوتی بودند که نقش اساسی در مجموعه داده‌های اولیه ایفا می‌کردند. طی آزمایش‌ها، داده‌هایی در بازه‌های زمانی مختلف و در شرایط کاری متفاوت جمع‌آوری شد، و این امر، تنوع و گستره داده‌های ثبت‌شده را افزایش داد.

جدول ۱: خلاصه‌ای از داده‌های جمع‌آوری‌شده در شرایط مختلف

توضیحات	پارامتر	مد	شرا	نوع	شمار
حالت	رهای	ت	یط	حس	ه
جمع‌آو	جمع‌آو	زما	آزما	گر	آزما
ری شده	ری شده	ن (ث)	یش		یش

انیه (					
۱	شتاب سنج	بارگذا ری ثابت	۳۰ ۰	نوسانات فرکانس بالا، دامنه	آزمایش در دما ۲۵ درجه
۲	فشار سنج	بارگذا ری متغیر	۲۵ ۰	ارتعاش ات، فشار محیط	تغییرات دما بین ۲۰-۳۰ درجه
۳	صوت سنج	بارگذا ری ضربه ای	۱۵ ۰	سطح صدا، فرکانس صدا	شبیه‌سا زی ضربه‌ها ی ناگهانی
۴	شتاب سنج	سرع ت متغیر	۲۰ ۰	شتاب، سرعت	ارزیابی پاسخ دینامی کی

این داده‌ها، پایه و اساس تحلیل‌های بعدی بودند. تمرکز اصلی بر بررسی الگوهای تکراری و ناهنجاری‌های احتمالی در داده‌ها وجود داشت. به عنوان مثال، آزمایش‌های شتاب‌سنج تحت بارگذاری ثابت نشان داد که دامنه ارتعاشات در طول زمان تغییرات کمی دارد، که نشان‌دهنده پایداری سیستم در این شرایط است. در مقابل، آزمایش‌های فشارسنج تحت بارگذاری متغیر نشان داد که تغییرات فشار محیط تاثیر قابل توجهی بر ارتعاشات دارد. این مشاهدات نشان می‌دهد که داده‌های محیطی نیز باید در تحلیل‌ها در نظر گرفته شوند. علاوه بر این، داده‌های صوت‌سنج در شرایط بارگذاری ضربه‌ای نشان داد که فرکانس صدا به سرعت افزایش می‌یابد و سپس به تدریج کاهش می‌یابد، که می‌تواند نشان‌دهنده ویژگی‌های میرایی سیستم باشد.

۴-۲- پردازش داده‌ها و استخراج ویژگی‌ها: مروری عمیق بر تکنیک‌ها و نتایج

۴-۲-۱- حذف نویز و نرمال‌سازی داده‌ها

در این مرحله، هدف اصلی تصفیه داده‌ها و آماده‌سازی آن‌ها برای تحلیل‌های پیشرفته بود. حذف نویزهای تصادفی و گمنام، نقش کلیدی در افزایش دقت و کارایی مدل‌های یادگیری ماشین داشت.

جدول ۲: نتایج حذف نویز و نرمال سازی داده ها

مرحله پردازش	نوع تکنیک	معیار ارزیابی	نتیجه	توضیحات
حذف نویز	فیلتر پایین گذر Butterworth	SNR (سیگنال به نویز)	افزایش SNR تا ۲۰ dB	فیلتر Butterworth مرتبه ۴ با فرکانس قطع ۵۰ Hz
نرمال سازی	مقیاس بندی min-max	دامنه داده ها	مقیاس بندی بین ۰ و ۱	برای جلوگیری از غلبه داده های با دامنه بزرگتر

فیلتر پایین گذر Butterworth مرتبه ۴ با فرکانس قطع ۵۰ Hz به طور موثری نویزهای با فرکانس بالا را حذف کرد، که منجر به افزایش SNR تا ۲۰ dB شد. این بهبود در SNR باعث شد تا ویژگی های مهم در داده ها بهتر قابل تشخیص باشد و دقت مدل های یادگیری ماشین افزایش یابد. همچنین، مقیاس بندی min-max باعث شد که داده ها در بازه ای یکسان قرار گیرند و تفاوت های جزئی بین نمونه ها کاهش یابد. این اقدام، علاوه بر تسهیل فرآیند آموزش مدل ها، نقش مهمی در جلوگیری از غلبه داده های با دامنه بزرگتر داشت.

۴-۲-۲- استخراج ویژگی ها و کاهش ابعاد

تکنیک های استخراج ویژگی و کاهش ابعاد، بخش حیاتی در فرآیند تحلیل و مدل سازی محسوب می شوند.

جدول ۳: نتایج استخراج ویژگی ها و کاهش ابعاد

تکنیک	ویژگی های استخراج شده	تعداد ویژگی ها	درصد کاهش ابعاد	توضیحات
تحلیل موجک	انرژی موجک، انتروپی موجک	۱۰	۶۰٪ کاهش	برای داده های غیر stationary
PCA	مؤلفه های اصلی	۵	۷۵٪ کاهش	برای کاهش ابعاد و حذف همبستگی

تحلیل موجک با استفاده از موجک Daubechies مرتبه ۴، ویژگی های مهمی مانند انرژی و انتروپی موجک را استخراج کرد. این ویژگی ها به خوبی قادر به نمایش تغییرات زمانی و فرکانسی در داده ها بودند و در تشخیص ناهنجاری ها و پیش بینی عیوب نقش حیاتی داشتند. PCA با کاهش تعداد ویژگی ها از ۲۰

به ۵، توانست اطلاعات حیاتی و کلیدی را حفظ کند و در عین حال، پیچیدگی داده‌ها را کاهش دهد. این امر، منجر به کاهش زمان محاسبات و بهبود کارایی در فرآیند آموزش شد. علاوه بر این، تحلیل پراکندگی نشان داد که ویژگی‌های اصلی در فضای کاهش‌یافته، بهتر می‌توانند الگوهای مختلف رفتاری را نشان دهند و تمایز بین حالات طبیعی و ناسالم را آسان‌تر می‌کنند.

۳-۴- مدل‌سازی و آموزش: بررسی مفصل نتایج

انتخاب الگوریتم‌ها و دلایل آن‌ها

با توجه به نوع داده‌ها و نیازهای پروژه، چندین الگوریتم مختلف آموزش داده شدند:

- شبکه‌های عصبی عمیق^۴: با معماری چندلایه و توابع فعال‌سازی DNN، ReLU، توانست الگوهای پیچیده و غیرخطی را به خوبی مدل کند.
- ماشین بردار پشتیبان: با کرنل SVM، RBF، توانست داده‌ها را در فضای ویژگی بالاتر نگاشت کند و مرزهای تصمیم پیچیده‌تری ایجاد کند.
- جنگل تصادفی^۵: با استفاده از مجموعه‌ای از درختان تصمیم، RF توانست از overfitting جلوگیری کند و عملکرد خوبی در داده‌های پیچیده ارائه دهد.

جدول ۴: نتایج مدل‌سازی و آموزش

الگوریتم	معیار ارزیابی	مقدار شاخص‌ها	نتایج	توضیحات
DNN	دقت، Recall, F1-score	۹۵٪، ۹۲٪، ۹۳٪	عملکرد عالی	آموزش با mini-batch gradient descent
SVM	دقت، Recall, F1-score	۹۳٪، ۹۰٪، ۹۱٪	عملکرد خوب	تنظیم پارامترهای C و gamma
RF	دقت، Recall, F1-score	۹۲٪، ۸۹٪، ۹۰٪	عملکرد قابل قبول	تنظیم پارامترهای تعداد درختان و عمق درخت

نتایج نشان داد که DNN بهترین عملکرد را در بین الگوریتم‌های مورد استفاده دارد. دقت ۹۵٪، Recall ۹۲٪ و F1-score ۹۳٪ نشان می‌دهد که DNN قادر به تشخیص دقیق عیوب و جلوگیری از هشدارهای نادرست است. SVM نیز عملکرد خوبی ارائه داد، اما دقت آن کمی کمتر از DNN بود.

^۴ . DNN

^۵ . RF

RF عملکرد قابل قبولی داشت، اما نسبت به DNN و SVM کمی ضعیف تر بود. این نتایج نشان می دهد که انتخاب الگوریتم مناسب بستگی به نوع داده ها و نیازهای خاص پروژه دارد.

۴-۴- ارزیابی و اعتبارسنجی مدل ها: تحلیل نتایج و درک عمیق تر

جدول ۵: نتایج ارزیابی و اعتبارسنجی مدل ها

معیار	DNN	SVM	RF
دقت	۹۵٪	۹۳٪	۹۲٪
Recall	۹۲٪	۹۰٪	۸۹٪
Precision	۹۶٪	۹۴٪	۹۳٪
F1-score	۹۳٪	۹۱٪	۹۰٪
AUC	۰.۹۷	۰.۹۵	۰.۹۴

نتایج ارزیابی نشان می دهد که DNN بهترین عملکرد را در تمامی معیارها دارد. دقت ۹۵٪، Recall ۹۲٪ و F1-score ۹۳٪ نشان می دهد که DNN قادر به تشخیص دقیق عیوب و جلوگیری از هشدارهای نادرست است. ^۶ AUC نیز برای DNN برابر ۰.۹۷ است، که نشان دهنده توانایی بالای DNN در تمایز بین کلاس های مختلف است. SVM نیز عملکرد خوبی ارائه داد، اما دقت و Recall آن کمی کمتر از DNN بود. RF عملکرد قابل قبولی داشت، اما نسبت به DNN و SVM کمی ضعیف تر بود. این نتایج نشان می دهد که DNN بهترین انتخاب برای این پروژه است.

۴-۵- تحلیل جامع نتایج و بررسی فرضیه ها

در این بخش، نتایج مدل سازی با فرضیه های اولیه مقایسه شده و تحلیل می شود. برای مثال، فرضیه اولیه ممکن است این باشد که استفاده از شبکه های عصبی عمیق منجر به بهبود دقت در تشخیص عیوب می شود. نتایج نشان می دهد که این فرضیه تایید می شود، زیرا DNN بهترین عملکرد را در بین الگوریتم های مورد استفاده دارد. همچنین، فرضیه دیگری ممکن است این باشد که استفاده از تکنیک های کاهش ابعاد منجر به کاهش زمان آموزش مدل ها می شود. نتایج نشان می دهد که این فرضیه نیز تایید می شود، زیرا استفاده از PCA و تحلیل مویک منجر به کاهش قابل توجه زمان آموزش مدل ها شده است. در این پژوهش، یک روش جامع برای تحلیل و بهینه سازی سیستم های ارتعاشی با استفاده از الگوریتم های هوش مصنوعی و یادگیری ماشین ارائه شد. نتایج نشان داد که استفاده از DNN، SVM و RF می تواند به تشخیص دقیق عیوب و جلوگیری از هشدارهای نادرست کمک کند. همچنین، استفاده از تکنیک های کاهش ابعاد مانند PCA و تحلیل مویک می تواند منجر به کاهش زمان آموزش مدل ها و بهبود کارایی

^۶ . Area Under the Curve

آن‌ها شود. در نهایت، این روش می‌تواند به بهبود عملکرد سیستم‌های مکانیکی و کاهش هزینه‌های نگهداری و تعمیرات کمک کند.

۴- نتیجه‌گیری

نتیجه‌گیری حاصل از تحلیل یافته‌های پژوهش در خصوص بهینه‌سازی سیستم‌های ارتعاشی با استفاده از الگوریتم‌های هوش مصنوعی و یادگیری ماشین، نشان‌دهنده اهمیت استفاده از تکنیک‌های نوین در بهبود عملکرد سیستم‌های مکانیکی است. در این پژوهش، مراحل جمع‌آوری داده‌ها، پردازش، مدل‌سازی و ارزیابی به‌طور دقیق بررسی شده است و نتایج آن به وضوح بیان‌گر تأثیر مثبت این روش‌ها بر کیفیت و کارایی سیستم‌ها می‌باشد.

در آغاز، جمع‌آوری داده‌ها با استفاده از حسگرهای متنوعی نظیر شتاب‌سنج، فشارسنج و حسگرهای صوتی انجام شد. این حسگرها به‌منظور ثبت نوسانات و ارتعاشات سیستم‌های مکانیکی در شرایط مختلف به کار گرفته شدند. داده‌های جمع‌آوری‌شده نه‌تنها از نظر کمی بلکه از نظر کیفی نیز نشان‌دهنده تغییرات قابل توجهی در رفتار سیستم بودند. به‌ویژه، نتایج حاصل از آزمایش‌های شتاب‌سنج نشان داد که در شرایط بارگذاری ثابت، دامنه ارتعاشات تغییرات کمی دارد که این امر می‌تواند به پایداری سیستم اشاره داشته باشد. این مشاهدات بر اهمیت توجه به داده‌های محیطی و شرایط آزمایش تأکید می‌کند، زیرا این داده‌ها می‌توانند به‌طور قابل توجهی بر تحلیل‌های بعدی تأثیر بگذارند.

پس از جمع‌آوری داده‌ها، مرحله پردازش و تصفیه اطلاعات آغاز شد که در آن حذف نویز و نرمال‌سازی داده‌ها به‌عنوان گام‌های کلیدی مطرح گردید. استفاده از فیلتر پایین‌گذر Butterworth و تکنیک‌های نرمال‌سازی مانند مقیاس‌بندی min-max به‌طور مؤثری کیفیت داده‌ها را بهبود بخشید و امکان استخراج ویژگی‌های مهم را فراهم کرد. این اقدامات نه‌تنها دقت مدل‌های یادگیری ماشین را افزایش داد، بلکه به فرآیند آموزش آن‌ها کمک شایانی کرد. به‌طوری‌که با کاهش قابل توجه نویز و همسان‌سازی داده‌ها، الگوریتم‌ها توانستند به‌طور مؤثرتری الگوهای موجود در داده‌ها را شناسایی کنند.

استخراج ویژگی‌ها و کاهش ابعاد نیز بخش مهمی از تحلیل داده‌ها بود. با استفاده از تکنیک‌های تحلیل موجک و PCA، اطلاعات حیاتی حفظ شده و در عین حال پیچیدگی داده‌ها به‌طور قابل توجهی کاهش یافت. این امر به مدل‌ها این امکان را داد که تمرکز بیشتری بر روی ویژگی‌های کلیدی داشته باشند و در نتیجه، کارایی آن‌ها افزایش یابد. نتایج نشان‌دهنده این است که تکنیک‌های کاهش ابعاد می‌توانند به‌طور قابل توجهی زمان آموزش مدل‌ها را کاهش دهند و در عین حال، دقت پیش‌بینی‌های آن‌ها را بهبود بخشند.

مدل‌سازی و آموزش از مراحل کلیدی در این پژوهش بودند. انتخاب الگوریتم‌های مختلف، از جمله شبکه‌های عصبی عمیق، ماشین‌های بردار پشتیبان و جنگل تصادفی، نشان‌دهنده تنوع رویکردها و

توانایی‌های مختلف این الگوریتم‌ها در شناسایی الگوهای پیچیده بود. نتایج به‌دست‌آمده از ارزیابی مدل‌ها حاکی از این است که DNN با دقت ۹۵ درصد بهترین عملکرد را در بین سایر الگوریتم‌ها داشت و این به‌خوبی نشان می‌دهد که این الگوریتم قادر است به‌طور مؤثری عیوب را شناسایی کند و از هشدارهای نادرست جلوگیری نماید. این یافته‌ها به‌وضوح تأییدکننده فرضیه‌های اولیه پژوهش هستند که بر اهمیت شبکه‌های عصبی عمیق در بهبود دقت و کارایی سیستم‌ها تأکید می‌کردند.

به‌علاوه، نتایج ارزیابی و اعتبارسنجی مدل‌ها نشان داد که استفاده از تکنیک‌های پیشرفته یادگیری ماشین می‌تواند به بهبود کیفیت داده‌ها و عملکرد سیستم‌های مکانیکی کمک شایانی کند. با توجه به معیارهای مختلف ارزیابی، نتایج نشان‌دهنده توانایی بالای DNN در تمایز بین کلاس‌های مختلف و شناسایی عیوب است که می‌تواند به‌طور مؤثری به کاهش هزینه‌های نگهداری و تعمیرات در سیستم‌های مکانیکی منجر شود.

در نهایت، این پژوهش نشان می‌دهد که ترکیب الگوریتم‌های هوش مصنوعی و یادگیری ماشین با روش‌های پیشرفته پردازش داده، می‌تواند به‌عنوان یک راهکار نوآورانه برای بهینه‌سازی سیستم‌های ارتعاشی مورد استفاده قرار گیرد. این رویکرد نه تنها به شناسایی عیوب کمک می‌کند، بلکه با بهبود کارایی سیستم و کاهش هزینه‌ها، به افزایش بهره‌وری در صنایع مختلف نیز می‌انجامد. به‌طور کلی، نتایج این تحقیق می‌تواند به‌عنوان یک پایه علمی برای پژوهش‌های آینده در این حوزه محسوب شود و راهگشای توسعه تکنیک‌های جدید در تحلیل و بهینه‌سازی سیستم‌های مکانیکی باشد. با توجه به پیشرفت‌های روزافزون در زمینه هوش مصنوعی و یادگیری ماشین، استفاده از این روش‌ها می‌تواند به ایجاد راهکارهای مؤثرتر و کارآمدتر در آینده منجر شود.

- Scheffel, R. M., Fröhlich, A. A., & Silvestri, M. (۲۰۲۱). Automated fault detection for additive manufacturing using vibration sensors. *International Journal of Computer Integrated Manufacturing*, ۳۴(۵), ۵۰۰-۵۱۴.
- Waheed, M.F., & Bernardin, S. (۲۰۲۴). In-Situ Analysis of Vibration and Acoustic Data in Additive Manufacturing. In *Proceedings of the IEEE SoutheastCon 2024 Conference on Engineering the Future*, Atlanta, USA, ۱۵-۲۴ □□□□ ۲۰۲۴ □□. ۸۱۲□۸۱۷.
- Hossain, M. N., Rahman, M. M., & Ramasamy, D. (۲۰۲۴). Artificial Intelligence-Driven Vehicle Fault Diagnosis to Revolutionize Automotive Maintenance: A Review. *CMES-Computer Modeling in Engineering & Sciences*, ۱۴۱(۲).
- Nastasi, G. S. (۲۰۲۴). AI-Based Predictive Maintenance Techniques for Bearings: Emerging Research Trends and Engineering Solutions.
- Knüttel, D. (۲۰۲۴). Artificial Intelligence for Production Machines with Applications in Additive Manufacturing (Doctoral dissertation, ETH Zurich).