

MDOI-01-2026.0172
MNR--1-EC4806

یادگیری ماشین برای پیش‌بینی خرابی تجهیزات صنعتی مبتنی بر داده‌های حسگر

مهسا حق نظری

۱- مدیر و مدرس آموزشگاه فنی و حرفه ای؛ دانشجوی کارشناسی ارشد مهندسی و علم کامپیوتر گرایش هوش مصنوعی دانشگاه مهرالبرز، تهران، ایران.

چکیده

خرابی ناگهانی تجهیزات صنعتی یکی از پرهزینه‌ترین چالش‌های عملیاتی در محیط‌های تولیدی و فرآیندی است، زیرا توقف پیش‌بینی‌نشده نه‌تنها ظرفیت تولید را کاهش می‌دهد، بلکه هزینه‌های تعمیر اضطراری، تأخیر در تحویل و کاهش ایمنی را به همراه دارد. در سال‌های اخیر، گسترش حسگرهای صنعتی و انباشت داده‌های عملیاتی، امکان به‌کارگیری روش‌های یادگیری ماشین را برای پیش‌بینی خرابی تجهیزات بر پایه الگوهای رفتاری داده‌های حسگر فراهم کرده است. پژوهش حاضر با رویکردی توصیفی–تحلیلی و با اتکا به شواهد تجربی موجود در ادبیات، به بررسی ظرفیت الگوریتم‌های یادگیری ماشین در پیش‌بینی خرابی تجهیزات صنعتی مبتنی بر داده‌های حسگر می‌پردازد. چارچوب تحلیلی بر این ایده استوار است که ترکیب داده‌های ارتعاش، دما، جریان و سرعت با مدل‌های یادگیری باناظر و عمیق می‌تواند احتمال وقوع خرابی و عمر مفید باقیمانده را با دقت قابل قبول تخمین بزند. یافته‌های حاصل از مقایسه مطالعات نشان می‌دهد که مدل‌های ترکیبی و مبتنی بر حافظه زمانی، به‌ویژه معماری‌های پیوندی شبکه عصبی کانولوشنی و حافظه کوتاه‌مدت بلندمدت، در طبقه‌بندی حالت‌های خرابی دقت بالایی کسب کرده‌اند و در برخی موارد از مدل‌های تک‌الگوریتمی و روش‌های آستانه‌ای مرسوم پیشی گرفته‌اند. با این حال، کیفیت داده، عدم تعادل طبقات خرابی، تفسیرپذیری مدل و تفاوت شرایط آزمایشگاهی با محیط صنعتی واقعی، محدودیت‌های جدی پیش روی استقرار عملی این روش‌ها باقی می‌ماند. نتیجه‌گیری کلی آن است که یادگیری ماشین در صورت تلفیق با راهبردهای پیش‌پردازش داده و ارزیابی هزینه‌محور، می‌تواند به‌عنوان ابزاری مکمل در نظام نگهداری پیش‌بینانه صنعتی به کار گرفته شود، اما جایگزین کامل دانش مهندسی و پایش انسانی نیست.

واژگان کلیدی: یادگیری ماشین، پیش‌بینی خرابی، داده‌های حسگر، نگهداری پیش‌بینانه، تجهیزات صنعتی.



مقدمه

تحول دیجیتال در صنعت معاصر، مرز میان نگهداری واکنشی و نگهداری پیش‌بینانه را به‌طور بنیادین جابه‌جا کرده است و داده‌های حجیم تولیدشده توسط حسگرهای دما، ارتعاش، فشار، جریان و سرعت به ماده خام اصلی تصمیم‌گیری درباره سلامت تجهیزات تبدیل شده‌اند؛ در چنین بستری، یادگیری ماشین به‌عنوان مجموعه‌ای از روش‌های آماری و محاسباتی که بدون برنامه‌نویسی صریح، الگوها را از داده استخراج می‌کند، امکان پیش‌بینی خرابی پیش از وقوع آن را فراهم ساخته و از این رو کانون توجه پژوهشگران حوزه نگهداری و قابلیت اطمینان قرار گرفته است. ظهور صنعت نسل چهارم، تغییر تحول‌آفرینی در بخش تولید ایجاد کرده و سیستم‌های هوشمند و به‌هم‌پیوسته‌ای را مستقر ساخته است که اینترنت اشیاء صنعتی، سیستم‌های امنیتی و هوش مصنوعی را با هدف بهبود کارایی، بهره‌وری و عملکرد کلی عملیاتی یکپارچه می‌کند. در این چارچوب، نگهداری پیش‌بینانه به‌عنوان پارادایم پایش پیوسته شاخص‌های سلامت تجهیز و انجام مداخله نگهداری تنها در زمان و مکان موردنیاز، چشم‌انداز کاهش هفتاد تا هشتاد و پنج درصدی توقف پیش‌بینی‌نشده را نسبت به راهبردهای پیشگیرانه زمان‌محور ترسیم می‌کند و هم‌زمان عمر مفید اجزا را گسترش می‌دهد و زمان‌بندی تکنسین‌ها را بهینه می‌سازد. گسترش زیرساخت حسگرهای اینترنت اشیاء صنعتی، سکوهای محاسبات لبه و استانداردهای ارتباطی صنعتی، پیش‌شرط‌های فنی لازم برای پیاده‌سازی فراگیر و کم‌تأخیر نگهداری پیش‌بینانه را در کارخانه‌های تولیدی با مقیاس‌ها و بخش‌های متفاوت فراهم آورده است. ادبیات موجود نشان می‌دهد که مدل‌های یادگیری ماشین با تکیه بر سوابق عملیاتی و سیگنال‌های حسگر، می‌توانند الگوهای پنهان رفتار تجهیز را شناسایی کرده و احتمال خرابی را در افق زمانی آینده تخمین بزنند؛ این ظرفیت در صنایعی مانند سیمان، نفت و گاز، فولاد و تولید خودرو که هزینه توقف ناگهانی خط تولید بسیار سنگین است، اهمیت راهبردی دارد. مرور نظام‌مند پژوهش‌های اخیر نیز گویای آن است که ترکیب اینترنت اشیاء صنعتی با الگوریتم‌های یادگیری باناظر و بدون ناظر، دقت تشخیص زودهنگام عیب را به‌طور محسوس افزایش داده و زمان توقف پیش‌بینی‌نشده را کاهش می‌دهد. در یک مطالعه تجربی بر روی تجهیزات دوار، معماری پیوندی شبکه عصبی کانولوشنی و حافظه کوتاه‌مدت بلندمدت که بر سیگنال خام ارتعاش آموزش دیده بود، به دقت طبقه‌بندی نود و هفت و سه دهم درصد دست یافت و در مقایسه با مدل‌های تک‌الگوریتمی مانند ماشین بردار پشتیبان با دقت هشتاد و چهار و یک دهم درصد، جنگل تصادفی با هشتاد و نه و چهار دهم درصد و شبکه عصبی ساده با نود و دو و شش دهم درصد، برتری آشکاری نشان داد. به‌طور مشابه، یک معماری ترکیبی حافظه کوتاه‌مدت بلندمدت و شبکه عصبی کانولوشنی با پردازش سری‌های زمانی خام ارتعاش از طریق لایه‌های کانولوشنی یک‌بعدی برای استخراج ویژگی‌های محلی و لایه‌های حافظه دوجهته برای مدل‌سازی وابستگی زمانی، دقت طبقه‌بندی هفتاد و هفت و هشت دهم درصدی، سطح زیر منحنی نود و نه و یک صدم درصد و خطای ریشه میانگین مربعات سی و هشت و چهار دهم چرخه را در پیش‌بینی عمر مفید باقیمانده به دست آورد. یافته دیگر آن است که مدل‌های ترکیبی و انبوهشی، در مواجهه با عدم تعادل طبقات خرابی عملکرد بهتری دارند. در یک چارچوب جامع نگهداری پیش‌بینانه، معماری ترکیبی حافظه کوتاه‌مدت بلندمدت و ماشین تقویت گرادیان با طراحی سه‌لایه اینترنت اشیاء، لبه و ابر، بر روی مجموعه‌ای از دو میلیون و چهارصد هزار خوانش حسگر از مراکز ماشین‌کاری، کمپرسورهای صنعتی و سیستم‌های نوار نقاله در سه کارخانه در طول هجده ماه آموزش دید و به دقت تشخیص خطای نود و چهار و هفت دهم درصد، امتیاز اف نهصد و بیست و سه هزارم و سطح زیر منحنی نود و هفت و هشتاد و هشتم درصد دست یافت و در آزمون عملیاتی شش‌ماهه، کاهش شصت و هفت و سه دهم درصدی توقف پیش‌بینی‌نشده و کاهش سی و یک و چهار دهم درصدی هزینه‌های نگهداری را به همراه داشت. در حوزه تجهیزات خاص، مطالعات موردی تصویر روشن‌تری از امکان‌سنجی عملی ارائه می‌دهند؛ در پژوهش مربوط به کوره دوار کارخانه سیمان،



متغیرهای دمای پوسته، دمای یاتاقان، ارتعاش، بار موتور و سرعت دوران به‌عنوان ورودی مدل یادگیری ماشین به کار رفتند و نتایج نشان داد که مقادیر پیش‌بینی‌شده هماهنگی مناسبی با مقادیر واقعی هدف دارند و مدل می‌تواند پیش از رسیدن تجهیز به شرایط بحرانی، زمان مناسب برای اقدام نگهداری را فراهم کند (رنجبر شرقی و همکاران، ۱۴۰۵). این یافته اهمیت انتخاب متغیرهای فیزیکی مرتبط با سازوکار خرابی را برجسته می‌سازد؛ در واقع، دقت مدل بیش از آنکه صرفاً تابع پیچیدگی الگوریتم باشد، به انطباق متغیرهای ورودی با فیزیک زوال تجهیز وابسته است. تحلیل خرابی‌های کوپلینگ با تکیه بر داده‌های پایش وضعیت نیز نشان داده است که ترکیب روش‌های تحلیل ارتعاش با رویکرد یادگیری ماشین می‌تواند حالت‌های مختلف خرابی را از حالت سالم تفکیک کند و مبنای صدور هشدار پیش‌بینانه قرار گیرد (صادقی و همکاران). در همین راستا، طراحی و ساخت حسگر ارتعاش و به‌کارگیری آن در تشخیص عیب الکتروموتور با یادگیری ماشین، گامی عملی در جهت بومی‌سازی زیرساخت داده موردنیاز این حوزه تلقی می‌شود (امینی، ۱۴۰۵). پایش وضعیت یاتاقان‌های غلتشی به روش ارتعاشی با بهره‌گیری از مدل یادگیری ماشین نیز از دیگر شواهدی است که توانمندی این رویکرد را در تشخیص زودهنگام عیب تجهیزات دوار تأیید می‌کند (کاجی و همکاران). از سوی دیگر، مدل‌های انبوهشی مانند جنگل تصادفی و ایکس‌جی‌بوست نیز در پیش‌بینی خرابی تجهیزات صنعتی عملکرد قابل توجهی نشان داده‌اند؛ در یک خط تولید صنعتی با مجموعه داده بوش که شامل چهار هزار و دویست و شصت و چهار ویژگی ناهمگون برای بیش از یک میلیون قطعه و تنها پنجاه و هشت صدم درصد خرابی برچسب‌خورده بود، مدل ایکس‌جی‌بوست با مهندسی ویژگی مقیاس‌پذیر به سطح زیر منحنی نود و شصت و شش صدم و ضریب همبستگی متیوز هفتصد و نود و سه هزارم دست یافت و نشان داد که ترکیب فشرده‌سازی ویژگی‌های اسمی مبتنی بر وزن شواهد با زیرساخت پردازش توزیع‌شده، پیش‌بینی خرابی در سطح تولید را ممکن می‌سازد. با این همه، شکاف میان دقت آزمایشگاهی مدل‌ها و قابلیت اتکای آن‌ها در محیط صنعتی واقعی، پرسشی جدی را پیش روی پژوهشگران قرار داده است: داده‌های حسگر صنعتی اغلب ناهنجار، ناقص، نامتعادل از نظر طبقات خرابی و تحت تأثیر شرایط متغیر عملیاتی هستند و مدل‌هایی که در یک خط تولید آموزش دیده‌اند، لزوماً در خط دیگری با همان دقت عمل نمی‌کنند. مرورهای نظام‌مند نشان می‌دهند که دقت رویکردهای کنونی بین هشتاد و سه تا نود و هشت درصد متغیر است، اما چالش‌هایی مانند داده‌های گمشده و مبادله میان دقت و تفسیرپذیری همچنان حل‌نشده باقی مانده‌اند. از سوی دیگر، تجربه مطالعات موردی در تجهیزات دوار و کوره‌های صنعتی نشان می‌دهد که انتخاب هوشمندانه متغیرهای ورودی و مهندسی ویژگی، عاملی تعیین‌کننده در موفقیت مدل است و صرف به‌کارگیری الگوریتم پیچیده بدون درک فیزیک خرابی، نتیجه پایدار به بار نمی‌آورد؛ در همین ارتباط، توجه به عوامل انسانی و آموزش کاربران در بهره‌گیری از سامانه‌های هوشمند نیز شرطی لازم برای اثربخشی عملی این فناوری است (تاج‌آبادی، ۱۴۰۱). بنابراین، پژوهش حاضر بر آن است تا با نگاهی نظام‌مند به شواهد تجربی موجود، ظرفیت‌ها و محدودیت‌های یادگیری ماشین را در پیش‌بینی خرابی تجهیزات صنعتی مبتنی بر داده‌های حسگر بررسی کند و تصویری واقع‌بینانه از جایگاه این فناوری در نگهداری پیش‌بینانه ارائه دهد.

بیان مسئله

مسئله اصلی این پژوهش از یک تنش بنیادین میان غنای داده و توان تصمیم‌گیری در محیط صنعتی سرچشمه می‌گیرد: تجهیزات صنعتی امروزی پیوسته داده تولید می‌کنند، اما بخش بزرگی از این داده‌ها بدون تحلیل نظام‌مند باقی می‌ماند و در نتیجه، خرابی‌ها همچنان در لحظه‌ای رخ می‌دهند که هیچ هشدار عملیاتی از پیش صادر نشده است. نگهداری پیش‌بینانه بر این فرض استوار است که سیگنال‌های ضعیف و زودهنگام زوال تجهیز، پیش از آنکه به شکست عملکردی بیانجامند، در داده‌های حسگر قابل ردیابی هستند؛ اما تبدیل این فرض نظری به یک سامانه قابل اتکا، با دشواری‌های متعددی روبه‌روست.



نخست، داده‌های حسگر صنعتی اغلب دارای نویز، مقادیر گمشده، ناهمگامی زمانی و نمونه‌های نادر خرابی هستند و مدل‌هایی که بر چنین داده‌هایی آموزش می‌بینند، در معرض بیش‌برازش به وضعیت‌های سالم و ناتوانی در تشخیص خرابی‌های نادر قرار دارند. دوم، بسیاری از پژوهش‌ها دقت مدل را بر مجموعه‌داده‌های آزمایشگاهی یا تاریخی ارزیابی می‌کنند، در حالی که شرایط عملیاتی صنعتی پویا، متغیر و گاه متناقض است و مدل آموزش‌دیده در یک بازه زمانی، ممکن است با تغییر رژیم کاری یا فرسودگی حسگر، اعتبار خود را از دست بدهد. سوم، مسئله تفسیرپذیری مطرح است: تصمیم‌گیرنده صنعتی نه‌تنها به پیش‌بینی وقوع خرابی، بلکه به فهم دلیل آن و اطمینان از مبنای هشدار نیاز دارد، و مدل‌های جعبه‌سیاه بدون سازوکار توضیح‌پذیری، در عمل با مقاومت کارشناسان نگهداری مواجه می‌شوند. چهارم، ارزیابی مدل صرفاً با معیار دقت طبقه‌بندی کافی نیست، زیرا هزینه یک هشدار نادرست با هزینه از دست رفتن یک خرابی واقعی یکسان نیست و مدلی که دقت بالا دارد اما نرخ هشدار نادرست آن بالاست، می‌تواند هزینه‌های نگهداری پیشگیرانه غیرضروری را به‌شدت افزایش دهد. در نهایت، نبود مجموعه‌داده‌های عمومی معیار برای بسیاری از تجهیزات صنعتی، مقایسه منصفانه مدل‌ها و بازتولید نتایج را دشوار کرده و شکافی میان ادعاهای پژوهشی و واقعیت کارگاهی پدید آورده است. پژوهش حاضر در پی آن است که این مجموعه مسائل را در یک چارچوب منسجم بررسی کند و نشان دهد که پیش‌بینی خرابی مبتنی بر داده حسگر، پیش از آنکه یک مسئله صرفاً الگوریتمی باشد، یک مسئله داده‌محور، زمینه‌محور و تصمیم‌محور است.

اهمیت و ضرورت پژوهش

ضرورت این پژوهش را می‌توان از سه منظر اقتصادی، عملیاتی و دانشی تبیین کرد. از منظر اقتصادی، توقف ناگهانی تجهیزات صنعتی یکی از بزرگ‌ترین منابع هدررفت سرمایه در زنجیره تولید است و هزینه تعمیر اضطراری، خرید قطعات با قیمت فوری، از دست رفتن مواد اولیه در فرآیند و تأخیر در تعهدات قراردادی، مجموعاً بار مالی سنگینی بر بنگاه تحمیل می‌کند؛ در چنین شرایطی، حتی بهبود اندک در دقت و به‌موقع‌بودن پیش‌بینی خرابی می‌تواند صرفه‌جویی قابل توجهی ایجاد کند. از منظر عملیاتی، نگهداری پیش‌بینانه مبتنی بر داده حسگر این امکان را فراهم می‌آورد که تعمیرات از یک برنامه زمان‌بندی‌شده و تقویمی به یک اقدام شرط‌محور و مبتنی بر وضعیت واقعی تجهیز تبدیل شود؛ این تغییر پارادایم، هم بار تعمیرات غیرضروری را کاهش می‌دهد و هم پنجره زمانی لازم برای تأمین قطعه و هماهنگی نیروی متخصص را در اختیار قرار می‌دهد. از منظر دانشی، پژوهش حاضر به دلیل تمرکز بر داده‌های حسگر و نه صرفاً سوابق خرابی، شکاف موجود در ادبیات داخلی را پر می‌کند؛ بسیاری از مطالعات پیشین یا به تحلیل علت‌یابی پس از خرابی پرداخته‌اند یا مدل‌سازی را بدون توجه کافی به ویژگی‌های خاص داده صنعتی انجام داده‌اند، در حالی که ارزش واقعی یادگیری ماشین در این حوزه، وابسته به نحوه انتخاب، پالایش و تفسیر همان داده‌هایی است که حسگرها در اختیار قرار می‌دهند. افزون بر این، با گسترش طرح‌های هوشمندسازی صنایع کشور، نیاز به چارچوب‌های بومی و قابل اجرا برای پیش‌بینی خرابی بیش از پیش احساس می‌شود و نتایج این پژوهش می‌تواند مبنای طراحی سامانه‌های هشدار زودهنگام در صنایع مختلف قرار گیرد.

سوالات پژوهش

۱. الگوریتم‌های یادگیری ماشین چگونه می‌توانند از داده‌های حسگر صنعتی برای پیش‌بینی خرابی تجهیزات استفاده کنند و کدام دسته از این الگوریتم‌ها در این زمینه کارآمدترند؟

۲. ویژگی‌های داده‌های حسگر صنعتی چه تأثیری بر عملکرد مدل‌های پیش‌بینی خرابی دارند و کدام مراحل پیش‌پردازش برای بهبود قابلیت اتکای مدل ضروری است؟



۳. مدل‌های یادگیری ماشین در مقایسه با روش‌های آستانه‌ای و سنتی پایش وضعیت، چه مزیت‌های عملی در تشخیص زودهنگام خرابی تجهیزات صنعتی نشان می‌دهند؟
۴. محدودیت‌های تفسیرپذیری، تعادل طبقات و تعمیم‌پذیری مدل‌های یادگیری ماشین در محیط صنعتی واقعی چگونه بر اعتبار پیش‌بینی‌ها اثر می‌گذارند؟
۵. چه راهبردهایی برای تلفیق خروجی مدل‌های یادگیری ماشین با تصمیم‌گیری نگهداری پیش‌بینانه و کاهش هزینه‌های توقف و تعمیر وجود دارد؟

اهداف پژوهش

هدف کلی: بررسی ظرفیت و محدودیت‌های یادگیری ماشین در پیش‌بینی خرابی تجهیزات صنعتی بر پایه داده‌های حسگر و ارائه چارچوبی تحلیلی برای به‌کارگیری آن در نگهداری پیش‌بینانه.

اهداف جزئی:
۱. شناسایی و دسته‌بندی الگوریتم‌های یادگیری ماشین قابل استفاده در پیش‌بینی خرابی تجهیزات صنعتی مبتنی بر داده حسگر.
۲. تحلیل نقش ویژگی‌های داده حسگر و مراحل پیش‌پردازش در بهبود دقت و پایداری مدل‌های پیش‌بینی.
۳. مقایسه عملکرد مدل‌های یادگیری ماشین با روش‌های آستانه‌ای و سنتی پایش وضعیت بر اساس شواهد تجربی موجود.
۴. بررسی چالش‌های تفسیرپذیری، عدم تعادل داده و تعمیم‌پذیری مدل‌ها در محیط‌های صنعتی واقعی.
۵. ارائه راهکارهای عملی برای پیوند خروجی مدل‌های پیش‌بینی با تصمیم‌گیری نگهداری و کاهش هزینه‌های عملیاتی.

روش پژوهش

پژوهش حاضر از نوع توصیفی–تحلیلی و مبتنی بر مرور نظام‌مند شواهد تجربی است. جامعه آماری پژوهش را مطالعات منتشرشده در بازه زمانی ۲۰۱۵ تا ۲۰۲۶ تشکیل می‌دهد که به کاربرد یادگیری ماشین در پیش‌بینی خرابی تجهیزات صنعتی بر پایه داده‌های حسگر پرداخته‌اند. برای گردآوری منابع، پایگاه‌های علمی فارسی و انگلیسی شامل مگیران، سیویلیکا، پایگاه نشریات علمی ایران، آی‌تریپل‌ای، الزویر، اسپرینگر و زنودو با ترکیبی از کلیدواژه‌های «یادگیری ماشین»، «پیش‌بینی خرابی»، «داده‌های حسگر»، «نگهداری پیش‌بینانه» و معادل‌های انگلیسی آن‌ها جستجو شد و پس از حذف موارد تکراری و غربالگری بر اساس ارتباط عنوان، چکیده و روش، مجموعه‌ای از مطالعات تجربی و مروری که دارای داده واقعی یا تحلیل عملکرد مشخص بودند برای استخراج شواهد انتخاب شدند. معیار ورود شامل گزارش صریح نوع داده حسگر، الگوریتم به‌کاررفته و شاخص عملکرد، و معیار خروج شامل مطالعات صرفاً مفهومی بدون ارزیابی تجربی بود. داده‌های استخراج‌شده در چهار محور دسته‌بندی شدند: نوع تجهیز و حسگر، راهبرد پیش‌پردازش و مهندسی ویژگی، خانواده الگوریتم و معماری مدل، و شاخص‌های ارزیابی شامل دقت، فراخوانی، امتیاز اف و توانایی تشخیص زودهنگام. تحلیل داده‌ها به‌صورت مقایسه‌ای–تفسیری انجام شد؛ به این معنا که ابتدا عملکرد مدل‌ها در هر مطالعه به‌صورت جداگانه ثبت شد، سپس الگوهای تکرارشونده در برتری مدل‌های ترکیبی و مبتنی بر حافظه زمانی شناسایی و در قالب گزاره‌های تحلیلی تدوین گردید. در این مسیر، به تفاوت‌های زمینه‌ای مطالعات از نظر نوع صنعت، مقیاس داده و شرایط عملیاتی نیز توجه شد تا نتایج به‌صورت مشروط و زمینه‌مند تفسیر شوند و از



تعمیم بی‌قید نتیجه‌گیری‌های آزمایشگاهی به محیط صنعتی پرهیز شود. همچنین تلاش شد میان شواهد فارسی و انگلیسی تعادل برقرار شود تا تصویر حاصل هم از نظر مبانی نظری و هم از نظر تجربه صنعتی داخلی از انسجام کافی برخوردار باشد.

یافته‌های پژوهش

یافته‌های این پژوهش نشان می‌دهد که داده‌های حسگر، زمانی که با راهبردهای مناسب پیش‌پردازش و استخراج ویژگی همراه شوند، می‌توانند به یک بستر اطلاعاتی قابل اتکا برای پیش‌بینی خرابی تبدیل شوند، اما این تبدیل خودبه‌خود رخ نمی‌دهد و به شدت وابسته به نحوه مواجهه با ماهیت ناهمگون داده صنعتی است. در مطالعاتی که داده‌های ارتعاش، دما، جریان و سرعت به‌طور هم‌زمان و با نرخ نمونه‌برداری کافی جمع‌آوری شده بودند، مدل‌های یادگیری ماشین توانستند الگوهای زودهنگام زوال را پیش از آنکه به شکست عملکردی منجر شوند تشخیص دهند و این تشخیص، در مواردی با فاصله زمانی معنادار نسبت به روش‌های آستانه‌ای مرسوم همراه بود. یکی از پرتکرارترین یافته‌ها در ادبیات، برتری مدل‌های مبتنی بر حافظه زمانی در تحلیل داده‌های توالی‌دار حسگر است؛ زیرا سیگنال‌های صنعتی نه‌تنها در هر لحظه حامل اطلاعات وضعیت هستند، بلکه الگوی تغییرات آن‌ها در طول زمان، نشانه اصلی نزدیک‌شدن به خرابی است. در یک مطالعه تجربی بر روی تجهیزات دوار، معماری پیوندی شبکه عصبی کانولوشنی و حافظه کوتاه‌مدت بلندمدت که بر سیگنال خام ارتعاش آموزش دیده بود، به دقت طبقه‌بندی ۹۷٫۳ درصد دست یافت و در مقایسه با مدل‌های تک‌الگوریتمی مانند ماشین بردار پشتیبان با دقت ۸۴٫۱ درصد، جنگل تصادفی با ۸۹٫۴ درصد و شبکه عصبی ساده با ۹۲٫۶ درصد، برتری آشکاری نشان داد؛ این برتری به‌ویژه در شرایط تغییر سرعت و بار و در نسبت سیگنال به نویز پایین نیز حفظ شد. یافته دیگر آن است که مدل‌های ترکیبی و انبوهشی، در مواجهه با عدم تعادل طبقات خرابی عملکرد بهتری دارند. در پژوهشی که بر داده‌های صنعتی یک سامانه فرزکاری با ده هزار رکورد انجام شد، مدل ترکیبی مبتنی بر یادگیری عمیق و مدل‌های انبوهشی توانست به دقت ۹۶٫۱۷ درصد، دقت پیش‌بینی ۹۷٫۸۶ درصد، فراخوانی ۹۴٫۴ درصد و امتیاز اف ۹۶٫۱ درصد برسد و بدین ترتیب مدل‌های منفرد را با اختلاف حدود هفت درصد پشت سر بگذارد؛ نکته مهم آن است که این مدل با به‌کارگیری راهبردهای رفع عدم تعادل، توانست نرخ تشخیص نمونه‌های خرابی نادر را به‌طور معنادار افزایش دهد. این یافته با نتایج مرورهای نظام‌مند نیز همسو است که نشان می‌دهند ترکیب الگوریتم‌های باناظر با سازوکارهای وزن‌دهی طبقات، دقت تشخیص زودهنگام را بهبود می‌بخشد و زمان توقف پیش‌بینی‌نشده را کاهش می‌دهد.

در حوزه تجهیزات خاص، مطالعات موردی تصویر روشن‌تری از امکان‌سنجی عملی ارائه می‌دهند. در پژوهش مربوط به کوره دوار کارخانه سیمان، متغیرهای دمای پوسته، دمای یاتاقان، ارتعاش، بار موتور و سرعت دوران به‌عنوان ورودی مدل یادگیری ماشین به کار رفتند و نتایج نشان داد که مقادیر پیش‌بینی‌شده هماهنگی مناسبی با مقادیر واقعی هدف دارند و مدل می‌تواند پیش از رسیدن تجهیز به شرایط بحرانی، زمان مناسب برای اقدام نگهداری را فراهم کند. این یافته اهمیت انتخاب متغیرهای فیزیکی مرتبط با سازوکار خرابی را برجسته می‌سازد؛ در واقع، دقت مدل بیش از آنکه صرفاً تابع پیچیدگی الگوریتم باشد، به انطباق متغیرهای ورودی با فیزیک زوال تجهیز وابسته است. در مطالعه‌ای دیگر بر روی موتورهای سه‌فاز در یک کارخانه سیمان، ترکیب حافظه کوتاه‌مدت بلندمدت برای پیش‌بینی مقادیر آینده ارتعاش، سرعت و توان با الگوریتم جنگل جداسازی برای شناسایی انحراف از رفتار نرمال، امکان پایش پیوسته و مداخله پیش از وقوع خرابی را فراهم کرد و بهبود محسوسی در دقت پیش‌بینی نشان داد. این الگو نشان می‌دهد که رویکرد دولایه—نخست پیش‌بینی روند سیگنال و سپس تشخیص ناهنجاری در روند پیش‌بینی‌شده—می‌تواند به‌عنوان یک راهبرد میانی میان مدل‌های کاملاً داده‌محور و روش‌های مبتنی بر آستانه عمل کند و تفسیرپذیری بیشتری برای کارشناسان نگهداری فراهم آورد. همچنین در تحلیل خرابی کوپلینگ با



داده‌های پایش وضعیت، مشخص شد که تکنیک تجزیه‌وتحلیل ارتعاش در ترکیب با یادگیری ماشین می‌تواند حالت‌های مختلف خرابی را از حالت سالم تفکیک کند و این تفکیک، مبنای صدور هشدار پیش‌بینانه قرار گیرد.

در مقایسه با روش‌های سنتی، شواهد نشان می‌دهد که مدل‌های یادگیری ماشین در تشخیص زودهنگام خرابی، به‌ویژه در مراحل ابتدایی زوال که سیگنال‌ها هنوز از آستانه‌های ثابت عبور نکرده‌اند، مزیت دارند. روش‌های آستانه‌ای مبتنی بر دامنه ارتعاش یا دمای مجاز، تنها زمانی هشدار می‌دهند که خرابی تا حدی پیشرفت کرده است، در حالی که مدل‌های یادگیری ماشین با یادگیری الگوهای چندمتغیره، می‌توانند ترکیب‌های ظریف از تغییرات را که به‌تنهایی در محدوده مجاز به نظر می‌رسند ولی در مجموع نشانه زوال هستند شناسایی کنند. با این حال، این مزیت مطلق نیست و به کیفیت داده وابسته است. مطالعات نشان می‌دهد که حدود نیم درصد داده‌ها ممکن است به دلیل اختلالات محیطی و خرابی حسگرها ناهنجار باشند و بدون پالایش، این ناهنجاری‌ها می‌توانند به هشدارهای کاذب یا از دست رفتن هشدارهای واقعی منجر شوند. همچنین، پدیده نشت داده در آموزش مدل—جایی که مدل به‌طور ناخواسته به اطلاعات آینده دسترسی پیدا می‌کند—یکی از خطاهای روش‌شناختی رایج است که می‌تواند دقت گزارش‌شده را به‌طور مصنوعی بالا ببرد و در استقرار عملی، عملکرد مدل را به‌شدت افت دهد. از سوی دیگر، شواهد حاصل از مرورهای نظام‌مند در صنایع نفت و گاز نشان می‌دهد که در کنار دقت‌های گزارش‌شده، عواملی مانند هزینه پیاده‌سازی، پیچیدگی جمع‌آوری داده و شرایط عملیاتی سخت، اثربخشی واقعی این روش‌ها را محدود می‌کند و بنابراین نمی‌توان صرفاً بر مبنای شاخص دقت آزمایشگاهی درباره موفقیت یک مدل قضاوت کرد. در مجموع، یافته‌ها حاکی از آن است که یادگیری ماشین در پیش‌بینی خرابی تجهیزات صنعتی، در سطح اثبات مفهوم و در شرایط داده‌ای کنترل‌شده، توانمندی بالایی نشان می‌دهد، اما عبور از این سطح به سامانه عملیاتی پایدار، نیازمند سرمایه‌گذاری در زیرساخت داده، تفسیرپذیری و ارزیابی هزینه‌محور است.

بحث و نتیجه‌گیری

تحلیل یافته‌های این پژوهش نشان می‌دهد که یادگیری ماشین در پیش‌بینی خرابی تجهیزات صنعتی مبتنی بر داده‌های حسگر، به یک پارادایم اثبات‌شده در سطح پژوهشی تبدیل شده است، اما فاصله میان دقت آزمایشگاهی و قابلیت اتکای کارگاهی، همچنان مسئله محوری این حوزه باقی می‌ماند. الگوهای تکرارشونده در مطالعات بررسی‌شده حاکی از آن است که مدل‌های مبتنی بر حافظه زمانی و معماری‌های ترکیبی، به دلیل توانایی در ثبت وابستگی‌های زمانی و تعاملات چندمتغیره، در طبقه‌بندی حالت‌های خرابی و پیش‌بینی عمر مفید باقیمانده عملکرد بهتری دارند؛ این برتری نه فقط از نظر شاخص دقت، بلکه از نظر توانایی تشخیص زودهنگام نیز معنادار است. با این حال، همین مطالعات به‌روشنی نشان می‌دهند که موفقیت مدل بیش از آنکه به انتخاب الگوریتم وابسته باشد، به کیفیت داده، انطباق متغیرهای ورودی با فیزیک خرابی و نحوه ارزیابی مدل بستگی دارد. مدلی که بر داده‌های تاریخی یک تجهیز خاص آموزش دیده است، بدون بازآموزی و انطباق، در مواجهه با تغییر شرایط عملیاتی یا فرسودگی حسگر، اعتبار خود را از دست می‌دهد و این واقعیت، ضرورت طراحی سامانه‌های یادگیری پیوسته و انسان‌محور را برجسته می‌سازد. از منظر تفسیرپذیری، خروجی مدل باید نه‌تنها احتمال خرابی، بلکه سهم متغیرهای مؤثر و مبنای هشدار را نیز نشان دهد؛ در غیر این صورت، کارشناسان نگهداری به‌سختی می‌توانند به هشدارهای مدل جعبه‌سیاه اعتماد کنند و در عمل، تصمیم‌گیری به روش‌های سنتی بازمی‌گردد. از منظر هزینه‌ای نیز، ارزیابی مدل صرفاً با دقت طبقه‌بندی کافی نیست و باید عدم تقارن هزینه هشدار نادرست و از دست رفتن خرابی واقعی در انتخاب آستانه تصمیم‌گیری لحاظ شود. نتیجه‌گیری نهایی آن است که یادگیری ماشین، در صورت تلفیق با پیش‌پردازش داده‌های صنعتی، مهندسی ویژگی زمینه‌محور، ارزیابی هزینه‌محور و سازوکارهای تفسیرپذیری، می‌تواند به‌عنوان یک لایه تحلیلی مکمل در نظام نگهداری



پیش‌بینانه صنعتی به کار گرفته شود و پنجره زمانی لازم برای اقدام پیشگیرانه را در اختیار تصمیم‌گیرندگان قرار دهد؛ اما این فناوری جایگزین دانش مهندسی، قضاوت انسانی و زیرساخت داده‌ای سالم نیست و بدون این پیش‌نیازها، دقت‌های بالای گزارش‌شده در پژوهش‌ها به ارزش عملی پایدار تبدیل نمی‌شوند. پژوهش‌های آینده باید بر مجموعه‌داده‌های صنعتی واقعی با برچسب‌گذاری دقیق، ارزیابی میدانی مدل‌ها در شرایط عملیاتی متغیر و توسعه چارچوب‌های تصمیم‌گیری یکپارچه متمرکز شوند تا شکاف میان ادعای پژوهشی و واقعیت کارگاهی کاهش یابد.

منابع و مآخذ

تاج‌آبادی، نازنین. (۱۴۰۱). «یادگیری ماشین». مجله علوم مهندسی، شماره ۴۵.

رنجبر شرقی، مریم؛ تاجی، جلال؛ رسائی، حسن. (۱۴۰۵). «ارائه یک رویکرد مبتنی بر یادگیری ماشین برای صدور هشدار انجام نگهداری و تعمیرات: مطالعه موردی کوره دوار در کارخانه سیمان». دانشگاه خاتم.

صادقی، رضا؛ حسین‌زاده کاشان، علی؛ استادی، بختیار. «تحلیل خرابی‌های کوپلینگ با داده‌های پایش وضعیت با رویکرد یادگیری ماشین». مگیران.

امینی، مژگان. (۱۴۰۵). «طراحی و ساخت سنسور ارتعاش و تشخیص عیب الکتروموتور با یادگیری ماشین». دانشگاه علم و صنعت ایران.

کاجی، محمدرضا؛ پرویزیان، جمشید؛ سیلانی، محمد. «پایش وضعیت یاتاقان‌های غلتشی به روش ارتعاشی با بهره‌گیری از مدل یادگیری ماشین». نشریه مهندسی مکانیک، دانشگاه صنعتی امیرکبیر.

Mehregan, M. R., Rezasoltani, A., Khani, A. M., & Husseinzadeh Kashan, A. (2026). A Hybrid Deep Learning-Based Machine Learning Model for Predicting Industrial Machinery Failures in Preventive Maintenance. International Journal of Industrial Engineering & Production Research, 37(1), 153–170.

Sharma, R. K., Devi, M., & Chandra, S. (2026). Machine Learning-Based Predictive Fault Detection in Industrial Rotating Machinery Using Hybrid CNN-LSTM Architecture. International Journal of Advanced Multidisciplinary Application, 3(5), 86–94.

Bej, D., De, A., Raj, A., Bhattacharya, A., Roy, B., & Dutta, K. P. (2025). A Real-time Predictive Maintenance System using Machine Learning and IoT for Industrial Equipment Monitoring. Proceedings of RAISD 2025. Atlantis Press.

Abdulmaged, A. (2026). Predictive Maintenance in the Oil and Gas Industry: A Literature-Based Analysis of Techniques and Their Impact on Equipment Reliability. Journal of Petroleum Research and Studies, 16(3.(

Zaidi, H., Shenfield, A., Zhang, H., & Ikpehai, A. (2026). A Systematic Review of Anomaly and Fault Detection Using Machine Learning for Industrial Machinery. Sheffield Hallam University Research Archive.

Musiał, K., Barduk, A., & Iwańczyk, K. (2026). Machine Learning for Equipment Failure Prediction in Smart Manufacturing Plants: A Review. EAI Endorsed Transactions on Industrial Networks and Intelligent Systems.