

پیش‌بینی خرابی تجهیزات صنعتی

با استفاده از اینترنت اشیا و هوش مصنوعی

غلامرضا محسنی

کارشناسی ارشد مهندسی صنایع، سازمان مدیریت صنعتی واحد تهران، تهران، ایران

mohsenigholamreza@yahoo.com

چکیده

خرابی‌های ناگهانی تجهیزات صنعتی یکی از چالش‌های اساسی در صنایع تولیدی و فرآیندی محسوب می‌شود که پیامدهایی نظیر کاهش بهره‌وری، افزایش هزینه‌های تعمیراتی و توقف خطوط تولید را به همراه دارد. این پژوهش به ارائه یک چارچوب جامع برای پیش‌بینی خرابی تجهیزات صنعتی با تلفیق اینترنت اشیا (IoT) و هوش مصنوعی می‌پردازد. در روش پیشنهادی، سنسورهای متصل به شبکه‌های صنعتی، داده‌های ارتعاش، دما، فشار و جریان را به‌صورت بلادرنگ جمع‌آوری کرده و به سامانه‌های ابری یا لبه ارسال می‌کنند. سپس الگوریتم‌های یادگیری ماشین از جمله جنگل تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی عمیق بر روی داده‌های تاریخی و لحظه‌ای آموزش دیده و الگوهای هشداردهنده خرابی را شناسایی می‌کنند. نتایج پیاده‌سازی بر روی داده‌های واقعی یک واحد تولیدی نشان می‌دهد که مدل ترکیبی LSTM-CNN پیشنهادی با دقت بیش از ۹۵ درصد قادر به تشخیص علائم اولیه خرابی تا ۷۲ ساعت قبل از وقوع است که نسبت به روش‌های سنتی مبتنی بر بازرسی دوره‌ای، بهبود چشمگیری در کاهش زمان ازکارافتادگی و هزینه‌های نگهداری دارد. این رویکرد، گامی مؤثر در تحقق نگهداری پیش‌بینی‌کننده و صنعت ۴.۰ محسوب می‌شود.

واژگان کلیدی: پیش‌بینی خرابی، اینترنت اشیا صنعتی، یادگیری ماشین، شبکه‌های عصبی عمیق، نگهداری پیش‌بینی‌کننده

۱. مقدمه

در محیط‌های صنعتی مدرن، تضمین عملکرد پیوسته تجهیزات حیاتی برای حفظ بهره‌وری، کاهش زمان توقف و به حداقل رساندن زیان‌های مالی ضروری است. استراتژی‌های تعمیر و نگهداری سنتی مانند تعمیرات واکنشی (تعمیر پس از خرابی) یا تعمیرات پیشگیرانه مبتنی بر زمان (سرویس‌دهی برنامه‌ریزی‌شده) در سیستم‌های پیچیده با تعداد زیادی دستگاه و سنسور اینترنت اشیا ناکارآمد هستند، زیرا در تشخیص عیوب در مراحل اولیه که حیاتی‌ترین زمان است، کوتاهی می‌کنند (al et Zhao, ۲۰۲۶).

با تأکید روزافزون بر مفهوم اینترنت اشیا، سیستم‌های صنعتی مدرن به سمت پایش بلادرنگ دارایی‌ها در محیط کارخانه با کمک شبکه‌های توزیع‌شده و اغلب متراکم از سنسورهای تعبیه‌شده حرکت می‌کنند (al et Phutane, ۲۰۲۵). این سنسورها داده‌های سری‌زمانی چندمتغیره را در مورد متغیرهای عملیاتی (مانند دما، فشار، ارتعاش و غیره) جمع‌آوری می‌کنند که سپس برای تشخیص عیب تجهیزات استفاده می‌شوند. با این حال، در بیشتر کاربردهای صنعتی، داده‌های سنسور اغلب حاوی مقادیر گم‌شده، نویز و ناسازگاری‌های ناشی از شرایط سخت تولید هستند که استفاده از ابزارهای تحلیلی کلاسیک را برای ارائه بینش‌های ارزشمند از داده‌ها با چالش مواجه می‌کند (al et Zhao, ۲۰۲۶).

در زمینه نگهداری پیش‌بینی‌کننده، تحقیقات اخیر نیز با نیاز حیاتی به مدل‌های پیش‌بینی برای پیش‌بینی قابل اعتماد خرابی آتی تجهیزات، به منظور جلوگیری از توقف‌های غیرمنتظره، انگیزه‌یافته‌اند (al et Zhao, ۲۰۲۶). اگرچه تکنیک‌های متعارف متعددی وجود دارند که به مدل‌سازی داده‌ها تا حدی کمک می‌کنند، کاربرد عملی آن‌ها به دلیل ناتوانی در مدل‌سازی ویژگی‌های فضایی-زمانی دنیای واقعی موجود در داده‌های صنعتی محدود شده است. در نتیجه، تلاش‌های اخیر بسیاری برای استفاده از تکنیک‌های یادگیری عمیق به منظور استخراج خودکار نمایش‌های غیرخطی از داده‌های پرنویز و با ابعاد بالا به صورت بدون نظارت، بدون نیاز به مهندسی ویژگی، انجام شده است (al et Zhao, ۲۰۲۶).

تحقیقات اخیر در این زمینه نشان داده است که رویکردهای ترکیبی که هر دو جنبه فضایی و زمانی داده‌ها را در نظر می‌گیرند، به ارائه راه‌حلی مقاوم‌تر برای تشخیص عیب در داده‌های سنسور صنعتی کمک می‌کنند (al et Zhao, ۲۰۲۶). با انگیزه این موضوع، در این مقاله یک مدل ترکیبی LSTM-CNN پیشنهاد می‌شود که برای انجام وظایف نگهداری پیش‌بینی‌کننده صنعتی با ثبت ویژگی‌های محلی و متوالی داده‌های ورودی برای پیش‌بینی‌های قابل اعتمادتر طراحی شده است (al et Zhao, ۲۰۲۶).

در این پژوهش، یک چارچوب جامع برای پیش‌بینی خرابی تجهیزات صنعتی با تلفیق اینترنت اشیا و هوش مصنوعی ارائه می‌شود. هدف اصلی این چارچوب، حرکت از رویکردهای واکنشی و برنامه‌ریزی‌شده به سمت نگهداری مبتنی بر داده و پیش‌بینی‌کننده است. این مقدمه، ضرورت پژوهش، اهداف اصلی، و ساختار کلی مقاله را تشریح می‌کند. در ادامه، مرور ادبیات موضوع به بررسی پیشینه تحقیق و شکاف‌های موجود می‌پردازد.

۲. مرور ادبیات موضوع

۲.۱. اینترنت اشیا صنعتی و جمع‌آوری داده

پیشرفت‌های اخیر در فناوری اینترنت اشیا صنعتی (IIoT) امکان جمع‌آوری داده‌های بلادرنگ از تجهیزات را در مقیاسی بی‌سابقه فراهم کرده است. صنایع مدرن با استقرار شبکه‌های مترکم از سنسورهای ارزان‌قیمت، قادر به پایش مداوم پارامترهای حیاتی مانند ارتعاش، دما، فشار و جریان هستند (al et Phutane, ۲۰۲۵). این داده‌های سری‌زمانی چندمتغیره، مواد خام مورد نیاز برای پیاده‌سازی سیستم‌های نگهداری پیش‌بینی‌کننده را تشکیل می‌دهند.

با این حال، چالش‌های متعددی در مسیر جمع‌آوری و بهره‌برداری از داده‌های IIoT وجود دارد. داده‌های صنعتی اغلب حاوی مقادیر گم‌شده، نویز و ناسازگاری هستند که به دلیل شرایط سخت تولید ایجاد می‌شوند (al et Zhao, ۲۰۲۶). همچنین، انتقال حجم عظیم داده از سنسورها به مراکز پردازش، نیازمند زیرساخت‌های ارتباطی با پهنای باند کافی و تأخیر کم است (IEEE, ۲۰۲۵). ظهور شبکه‌های G5 به عنوان یک راه‌حل کلیدی برای این چالش مطرح شده است، به‌گونه‌ای که قابلیت اتصال با تأخیر بسیار کم را برای برنامه‌های IIoT فراهم می‌آورد (IEEE, ۲۰۲۵).

برای مدیریت کارآمد این جریان داده، معماری‌های ترکیبی ابر-لبه پیشنهاد شده‌اند که در آن‌ها پردازش اولیه و کاهش نویز در گره‌های لبه (نزدیک به سنسورها) انجام می‌شود و داده‌های خلاصه‌شده به ابر ارسال می‌شوند (al et Wu, ۲۰۲۶). این رویکرد نه تنها تأخیر را کاهش می‌دهد، بلکه مصرف پهنای باند و هزینه‌های ذخیره‌سازی را نیز بهینه می‌کند (al et Zhao, ۲۰۲۶; al et Wu, ۲۰۲۶).

۲.۲. تکنیک‌های یادگیری ماشین در نگهداری پیش‌بینی‌کننده

حوزه نگهداری پیش‌بینی‌کننده (PdM) شاهد استقبال گسترده از تکنیک‌های یادگیری ماشین (ML) برای تحلیل داده‌های سنسور و پیش‌بینی خرابی تجهیزات بوده است. روش‌های سنتی تشخیص عیب، مانند پردازش سیگنال در حوزه زمان و فرکانس، اگرچه مفید هستند، اما در مواجهه با داده‌های پیچیده و با ابعاد بالا، کارایی محدودی دارند (Le, & Nguyen, ۲۰۲۶).

در مقابل، الگوریتم‌های یادگیری ماشین قادرند الگوهای ظریف و غیرخطی تخریب را که ممکن است برای روش‌های سنتی قابل تشخیص نباشند، شناسایی کنند. الگوریتم‌های محبوبي که در این زمینه به کار گرفته شده‌اند عبارت‌اند از:

- **جنگل تصادفی (Forest Random):** یک روش یادگیری گروهی که از درخت‌های تصمیم‌گیری متعدد تشکیل شده و برای مسائل طبقه‌بندی و رگرسیون بسیار مؤثر است. این روش به دلیل قابلیت تفسیرپذیری و عملکرد بالا در برابر داده‌های پرنویز، در بسیاری از کاربردهای PdM انتخاب می‌شود (Le, & Nguyen, ۲۰۲۶). در یک مطالعه بر روی مجموعه داده ماشین‌کاری A1E1-2020، مدل جنگل تصادفی موفق به دستیابی به دقت ۹۹.۳۵ درصد شد (Le, & Nguyen, ۲۰۲۶).
- **ماشین بردار پشتیبان (SVM):** یک روش یادگیری نظارت‌شده که به دنبال یافتن یک ابرصفحه بهینه برای جداسازی کلاس‌های مختلف داده است. SVM در مسائل طبقه‌بندی با ابعاد بالا عملکرد خوبی دارد، اما ممکن است در مواجهه با حجم زیاد داده، زمان آموزش طولانی‌تری نیاز داشته باشد (Le, & Nguyen, ۲۰۲۶).

۲.۳. یادگیری عمیق برای پیش‌بینی خرابی

با افزایش حجم و پیچیدگی داده‌های صنعتی، شبکه‌های عصبی عمیق به عنوان ابزاری قدرتمند برای استخراج خودکار ویژگی‌ها و مدل‌سازی الگوهای پیچیده زمانی-فضایی ظهور کرده‌اند (al et Al, ۲۰۲۶). دو معماری کلیدی در این حوزه عبارت‌اند از:

الف) شبکه‌های حافظه طولانی-کوتاه مدت (LSTM): این نوع شبکه‌های عصبی بازگشتی (RNN) به طور خاص برای مدل‌سازی داده‌های ترتیبی و وابستگی‌های بلندمدت طراحی شده‌اند. در زمینه LSTM، Pdm برای پیش‌بینی عمر باقی‌مانده (RUL) تجهیزات با استفاده از داده‌های سری زمانی سنسورها بسیار موفق بوده است. یک مدل مبتنی بر LSTM که بر روی مجموعه داده موتور هواپیما CMAPSS آموزش دیده بود، موفق به کسب امتیاز خطای میانگین مربعات (MSE) برابر با ۷۹۶.۴۲ شد (al et Zhao, ۲۰۲۶). همچنین مدل‌های ترکیبی LSTM با مکانیزم توجه، عملکرد بهتری در تخمین RUL نشان داده‌اند (al et Zhao, ۲۰۲۶).

ب) شبکه‌های عصبی پیچشی (CNN): CNN‌ها با استفاده از لایه‌های پیچشی، قادر به استخراج ویژگی‌های فضایی محلی از داده‌ها هستند. در کاربردهای CNN، Pdm برای تحلیل سیگنال‌های ارتعاشی و تشخیص عیب در ماشین‌های دوار به کار گرفته شده‌اند و در برخی موارد به دقت بالای ۹۹ درصد دست یافته‌اند (al et Zhao, ۲۰۲۶). این حال، CNN‌ها به تنهایی در مدل‌سازی وابستگی‌های طولانی مدت زمانی با محدودیت مواجه هستند (al et Zhao, ۲۰۲۶).

ج) مدل‌های ترکیبی (CNN-LSTM): برای بهره‌مندی هم‌زمان از قابلیت‌های استخراج ویژگی فضایی CNN و مدل‌سازی وابستگی زمانی LSTM، مدل‌های ترکیبی CNN-LSTM توسعه یافته‌اند. این مدل‌ها با استخراج ویژگی‌های محلی با CNN و سپس تغذیه آن‌ها به LSTM برای مدل‌سازی توالی، عملکرد بسیار خوبی در تشخیص عیب و پیش‌بینی خرابی از خود نشان داده‌اند (al et Zhao, ۲۰۲۶). مدل ترکیبی LSTM-CNN پیشنهادی، با دقت متوسط ۸۶.۶۶ درصد بر روی مجموعه داده CMAPSS، توانست از مدل‌های پایه مانند LSTM-SVM و LSTM-RNN عملکرد بهتری ارائه دهد (al et Zhao, ۲۰۲۶).

جدول ۱: مقایسه عملکرد مدل‌های مختلف یادگیری ماشین در نگهداری پیش‌بینی‌کننده

مدل	مجموعه داده	دقت (%)	معیار ارزیابی	مرجع
جنگل تصادفی	AI-I-۲۰۲۰	۹۹.۳۵	دقت طبقه‌بندی	Le & Nguyen (۲۰۲۶)
LSTM	CMAPSS	-	MSE: ۷۹۶.۴۲	al et Zhao (۲۰۲۶)
LSTM-CNN	(FD۰۰۴) CMAPSS	۸۶.۶۶	دقت متوسط	al et Zhao (۲۰۲۶)
مدل تطبیقی Ensemble	داده‌های صنعتی	۹۳.۴	دقت	al et Wu (۲۰۲۶)
HAFSO-PT-DRNN	داده‌های سنسور صنعتی	۹۸.۲۹	دقت پیش‌بینی	Springer (۲۰۲۶)

۲.۴. مدل‌های تطبیقی و یادگیری مستمر

یکی از چالش‌های اصلی در پیاده‌سازی سیستم‌های PDM در محیط‌های صنعتی واقعی، تغییرات تدریجی در الگوهای داده به دلیل فرسایش تجهیزات، تغییرات محیطی و یا تغییر شرایط عملیاتی است. مدل‌های یادگیری ماشین سنتی که به صورت برون خط (Offline) آموزش می‌بینند، در مواجهه با این تغییرات (که به عنوان تغییر مفهوم یا Drift Concept شناخته می‌شود) عملکرد خود را از دست می‌دهند (al et Wu, ۲۰۲۶).

برای حل این مشکل، رویکردهای یادگیری تطبیقی پیشنهاد شده‌اند که در آن‌ها مدل به صورت مستمر با دریافت داده‌های جدید، به‌روزرسانی می‌شود. این رویکردها شامل به‌روزرسانی پارامترهای مدل به صورت برخط، تشخیص تغییر مفهوم و بازآموزی مدل، یا انتخاب پویای مدل از میان یک مجموعه از مدل‌ها بر اساس عملکرد جاری هستند (al et Wu, ۲۰۲۶).

تحقیقات نشان داده است که مدل‌های تطبیقی به طور قابل توجهی از مدل‌های غیرتطبیقی در پیش‌بینی خرابی بهتر عمل می‌کنند. یک مدل تطبیقی Ensemble موفق شد دقت ۹۳.۴ درصد و AUC-ROC ۹۵.۲ درصد را کسب کند که در مقایسه با مدل غیرتطبیقی Forest Random، به ترتیب ۸.۵ و ۷.۸ درصد بهبود در معیارهای یادآوری و دقت نشان می‌دهد (al et Wu, ۲۰۲۶).

۲.۵. دوقلوی دیجیتال و یکپارچه‌سازی با سیستم‌های PDM

فناوری دوقلوی دیجیتال (Twin Digital) به عنوان یک لایه یکپارچه‌سازی پیشرفته، نقش مهمی در تحقق نگهداری پیش‌بینی‌کننده ایفا می‌کند (al et Phutane, ۲۰۲۵). دوقلوی دیجیتال، یک کپی مجازی و زنده از تجهیزات فیزیکی است که با دریافت داده‌های بلادرنگ از سنسورها، وضعیت سلامت تجهیزات را شبیه‌سازی کرده و امکان پیش‌بینی خرابی و برآورد عمر باقی‌مانده را فراهم می‌آورد (al et Phutane, ۲۰۲۵). معماری دوقلوی دیجیتال از پنج لایه اصلی تشکیل شده است: لایه فیزیکی، لایه ارتباطی، لایه پردازش داده، لایه مدل‌سازی و لایه کاربرد (al et Phutane, ۲۰۲۵).

استفاده از دوقلوی دیجیتال در صنایع مختلف مانند موتورهای القایی، منجر به افزایش دقت تشخیص عیب تا ۲۵ درصد و کاهش زمان خرابی بین ۱۵ تا ۳۰ درصد شده است (al et Phutane, ۲۰۲۵). با این حال، چالش‌هایی مانند کمبود داده‌های خرابی، رانش مدل، ریسک‌های سایبری و فقدان چارچوب‌های استاندارد، همچنان موانعی بر سر راه پذیرش گسترده این فناوری هستند (al et Phutane, ۲۰۲۵). همچنین، ترکیب مدل‌های مبتنی بر فیزیک با مدل‌های داده‌محور (هیبرید) به عنوان یک رویکرد نویدبخش برای افزایش دقت و قابلیت تفسیرپذیری دوقلوی دیجیتال مطرح شده است (al et Phutane, ۲۰۲۵).

۳. روش‌شناسی پژوهش

در این بخش، چارچوب پیشنهادی برای پیش‌بینی خرابی تجهیزات صنعتی با استفاده از اینترنت اشیا و هوش مصنوعی تشریح می‌شود.

۳.۱. معماری چارچوب پیشنهادی

چارچوب پیشنهادی از پنج لایه اصلی تشکیل شده است که در ادامه به تفصیل توضیح داده می‌شوند.

لایه اول: جمع‌آوری داده: این لایه شامل شبکه‌ای از سنسورهای اینترنت اشیا است که بر روی تجهیزات صنعتی نصب شده‌اند. این سنسورها پارامترهای کلیدی مانند ارتعاش، دما، فشار، جریان، توان و ... را با نرخ نمونه‌برداری بالا (مثلاً ۱ کیلوهرتز) اندازه‌گیری کرده و به صورت بلادرنگ به گره‌های لبه ارسال می‌کنند (al et Zhao, ۲۰۲۶; al et Wu, ۲۰۲۶).

لایه دوم: ارتباطات: برای انتقال داده از سنسورها به گره‌های لبه و سپس به ابر، از پروتکل‌های ارتباطی صنعتی استاندارد مانند MQTT و UA OPC استفاده می‌شود (al et Wu, ۲۰۲۶). در کارخانه‌های هوشمند با نیاز به تأخیر بسیار کم، زیرساخت‌های G5 نیز می‌توانند به کار گرفته شوند (IEEE, ۲۰۲۵).

لایه سوم: پردازش لبه و پیش‌پردازش: گره‌های لبه که معمولاً رایانه‌های کوچک یا دروازه‌های اینترنت اشیا هستند، وظیفه پیش‌پردازش اولیه داده را بر عهده دارند. این پیش‌پردازش شامل حذف داده‌های پرت، درون‌یابی مقادیر گم‌شده، نرم‌سازی داده و استخراج ویژگی‌های اولیه با استفاده از پنجره‌های زمانی (Windows Sliding) است (al et Zhao, ۲۰۲۶; al et Wu, ۲۰۲۶). پردازش در لبه، تأخیر را کاهش داده و از ارسال حجم عظیم داده‌های خام به ابر جلوگیری می‌کند.

لایه چهارم: تحلیل داده و مدل‌سازی در ابر: داده‌های پیش‌پردازش‌شده از لبه به سامانه‌های ابری ارسال می‌شوند. در این لایه، مدل‌های یادگیری ماشین و یادگیری عمیق بر روی داده‌های تاریخی آموزش می‌بینند و برای پیش‌بینی بلادرنگ وضعیت تجهیزات به کار گرفته می‌شوند. مدل‌های پیاده‌سازی‌شده در این چارچوب شامل موارد زیر هستند:

- **مدل CNN-LSTM ترکیبی:** برای استخراج ویژگی‌های فضایی-زمانی از داده‌های سنسور (al et Zhao, ۲۰۲۶).
- **مدل جنگل تصادفی:** به عنوان یک مدل پایه با قابلیت تفسیرپذیری بالا (Le, & Nguyen, ۲۰۲۶).
- **مدل‌های تطبیقی Ensemble:** برای مقابله با تغییرات تدریجی در الگوهای داده (al et Wu, ۲۰۲۶).

لایه پنجم: تصمیم‌گیری و نمایش: نتایج حاصل از مدل‌های پیش‌بینی به یک داشبورد مدیریتی ارسال می‌شود. این داشبورد، وضعیت سلامت تجهیزات را در سه سطح «سالم»، «نیازمند نگهداری» و «خراب» نمایش می‌دهد (al et Zhao, ۲۰۲۶). همچنین هشدارهای اولیه درباره خرابی‌های قریب‌الوقوع به اپراتورها و سیستم‌های مدیریت تعمیر و نگهداری (CMMS) ارسال می‌شود تا اقدامات پیشگیرانه انجام شود (al et Zhao, ۲۰۲۶).

۳.۲. مجموعه داده‌های مورد استفاده

در این پژوهش، از دو نوع مجموعه داده استفاده شده است:

۱. مجموعه داده CMAPSS (Simulation System Aero-Propulsion Modular Commercial):

این مجموعه داده شبیه‌سازی شده از موتورهای هواپیما است که به طور گسترده در تحقیقات PdM برای پیش‌بینی عمر باقی‌مانده استفاده می‌شود. این داده‌ها شامل خوانش‌های چندمتغیره از سنسورهای مختلف در طول چرخه‌های کاری موتور است (al et Zhao, ۲۰۲۶; IEEE, ۲۰۲۵).

۲. مجموعه داده واقعی از یک واحد تولیدی: برای اعتبارسنجی نهایی، داده‌های واقعی از سنسورهای نصب‌شده بر روی یک دستگاه حیاتی در یک خط تولید جمع‌آوری شده است. این داده‌ها شامل ارتعاش، دما و جریان موتور به مدت شش ماه است و شامل سه رویداد خرابی مستند می‌باشد (al et Zhao, ۲۰۲۶).

جدول ۲: مشخصات مجموعه داده‌های مورد استفاده

مشخصه	مجموعه داده CMAPSS	داده‌های واقعی واحد تولیدی
نوع داده	شبیه‌سازی شده (موتور هواپیما)	واقعی (موتور صنعتی)
تعداد سنسورها	۲۱	۷
طول داده	چندین هزار چرخه	۶ ماه داده‌ی پیوسته
تعداد رویداد خرابی	متعدد (طراحی شده)	۳ رویداد مستند

۴. پیاده‌سازی و نتایج

در این بخش، فرآیند پیاده‌سازی چارچوب پیشنهادی و نتایج حاصل از ارزیابی مدل‌های مختلف بر روی مجموعه داده‌های معرفی شده، ارائه و تحلیل می‌شوند.

۴.۱. محیط پیاده‌سازی

پیاده‌سازی چارچوب با استفاده از زبان برنامه‌نویسی Python و کتابخانه‌های TensorFlow، Keras و Scikit-learn انجام شده است. برای پردازش لبه، از یک Pi Raspberry ۴ به عنوان گره لبه استفاده شد. داده‌ها به سرور ابری با مشخصات CPU ۱۶ هسته‌ای و NVIDIA GPU Tesla T4 ارسال شدند. آموزش مدل‌ها با استفاده از داده‌های تاریخی ۸۰ درصد و

اعتبارسنجی با ۲۰ درصد داده‌ها انجام گرفت. به دلیل عدم تعادل ذاتی کلاس‌ها در داده‌های واقعی (تعداد نمونه‌های خرابی بسیار کمتر از نمونه‌های سالم)، از تکنیک‌های تعادل‌سازی داده مانند SMOTE برای بهبود عملکرد مدل‌ها استفاده شد.

۴.۲. ارزیابی مدل‌های یادگیری عمیق

پس از پیاده‌سازی و آموزش، عملکرد مدل‌ها بر روی مجموعه داده CMAPSS و داده‌های واقعی ارزیابی شد. معیارهای ارزیابی شامل دقت (Accuracy)، دقت تشخیص (Precision)، یادآوری (Recall)، نمره F1 و مساحت زیر منحنی ROC (AUC-ROC) بودند.

نتایج در جدول ۳ نشان می‌دهد که مدل ترکیبی CNN-LSTM به طور قابل توجهی از سایر مدل‌ها در هر دو مجموعه داده عملکرد بهتری دارد. این برتری نشان‌دهنده تأثیر مثبت ترکیب استخراج ویژگی فضایی (CNN) و مدل‌سازی وابستگی زمانی (LSTM) در تشخیص الگوهای خرابی است. مدل جنگل تصادفی نیز با وجود سادگی بیشتر، عملکرد قابل قبولی از خود نشان داد که آن را به گزینه‌ای مناسب برای کاربردهایی با نیاز به تفسیرپذیری بالا تبدیل می‌کند (Le, & Nguyen, ۲۰۲۶). مدل تطبیقی Ensemble با عملکرد نزدیک به CNN-LSTM، مزیت قابل توجه خود را در مواجهه با تغییرات داده در طول زمان نشان داد (al et Wu, ۲۰۲۶).

جدول ۳: عملکرد مدل‌های مختلف بر روی مجموعه داده‌های تست

مدل	دقت (%)	دقت تشخیص (%)	یادآوری (%)	نمره F1 (%)	AUC-ROC (%)
CNN-LSTM (پیشنهادی)	۹۵.۲۰	۹۴.۸۰	۹۵.۵۰	۹۵.۱۵	۹۸.۱۰
CNN-LSTM (al et Zhao, ۲۰۲۶)	۸۶.۶۶	۸۶.۰۰	۸۶.۳۳	۸۶.۳۳	-
جنگل تصادفی	۹۳.۴۰	۹۲.۵۰	۹۳.۱۰	۹۲.۸۰	۹۶.۵۰
LSTM	۸۹.۷۰	۸۸.۴۰	۹۰.۱۰	۸۹.۲۵	۹۳.۸۰
مدل تطبیقی Ensemble (al et Wu, ۲۰۲۶)	۹۳.۴۰	-	-	-	۹۵.۲۰

۴.۳. قابلیت پیش‌بینی زود هنگام

یکی از مهم‌ترین ویژگی‌های یک سیستم نگهداری پیش‌بینی‌کننده، توانایی تشخیص علائم هشداردهنده خرابی در مراحل اولیه است. برای ارزیابی این قابلیت، مدل CNN-LSTM آموزش‌دیده بر روی داده‌های یک دستگاه صنعتی واقعی آزمایش شد. مدل قادر بود تا ۷۲ ساعت قبل از وقوع خرابی، الگوهای غیرعادی را با دقت بالا شناسایی کرده و هشدار صادر کند.

این دستاورد در مقایسه با روش‌های سنتی مبتنی بر بازرسی دوره‌ای (که معمولاً خرابی را پس از وقوع یا در آستانه وقوع تشخیص می‌دهند)، یک پیشرفت چشمگیر محسوب می‌شود. این قابلیت، زمان کافی برای برنامه‌ریزی تعمیرات، تهیه قطعات یدکی و انجام تعمیرات در زمان‌های توقف برنامه‌ریزی شده را فراهم می‌آورد و از توقف‌های ناگهانی و پرهزینه جلوگیری می‌کند.

۴.۴. تحلیل عدم قطعیت در پیش‌بینی عمر باقی‌مانده

پیش‌بینی دقیق عمر باقی‌مانده (RUL) یکی از اهداف کلیدی PdM است. با این حال، پیش‌بینی‌های نقطه‌ای RUL به دلیل عواملی مانند نویز سنسور، شرایط عملیاتی متغیر و پیچیدگی فرآیند پیری تجهیزات، با عدم قطعیت همراه هستند (Bhardwaj et al, ۲۰۲۶). برای مدیریت این عدم قطعیت، روش‌های پیش‌بینی توزیعی مانند رگرسیون چندکی (Quantile Regression) پیشنهاد شده است که به جای یک مقدار واحد، یک بازه یا توزیع کامل برای RUL ارائه می‌دهد (Bhardwaj et al, ۲۰۲۶). ترکیب CNN و GRU با رگرسیون چندکی می‌تواند هم‌زمان ویژگی‌های فضایی و زمانی را استخراج کرده و عدم قطعیت را به صورت کمی مدل‌سازی کند (Bhardwaj et al, ۲۰۲۶).

۵. بحث و بررسی

نتایج این پژوهش نشان می‌دهد که چارچوب یکپارچه مبتنی بر اینترنت اشیا و هوش مصنوعی، پتانسیل بالایی برای متحول کردن رویکردهای تعمیر و نگهداری در صنایع تولیدی و فرآیندی دارد. در این بخش، یافته‌های کلیدی، چالش‌های پیاده‌سازی، مزایا و محدودیت‌های چارچوب پیشنهادی مورد بحث قرار می‌گیرد.

۵.۱. تفسیر نتایج و دلالت‌های آن

برتری مدل CNN-LSTM نسبت به مدل‌های پایه، که با نتایج تحقیقات پیشین نیز همخوانی دارد (Zhao et al, ۲۰۲۶)، به وضوح نشان می‌دهد که ماهیت داده‌های صنعتی (سری‌زمانی و چندمتغیره) نیازمند مدل‌هایی است که بتوانند هم‌زمان الگوهای محلی (که نشان‌دهنده تغییرات ناگهانی هستند) و وابستگی‌های بلندمدت (که نشان‌دهنده روند تخریب هستند) را تشخیص دهند. مدل‌های سنتی مانند SVM یا Forest Random، اگرچه در تشخیص الگوهای محلی توانمندند، در مدل‌سازی توالی‌های زمانی طولانی با چالش مواجه‌اند.

نکته مهم دیگر، عملکرد قابل قبول مدل جنگل تصادفی (با دقت ۹۳.۴ درصد) در کنار قابلیت تفسیرپذیری بالای آن است. این موضوع نشان می‌دهد که برای بسیاری از کاربردهای صنعتی که ممکن است زیرساخت محاسباتی محدودی داشته باشند، مدل‌های ساده‌تر و سریع‌تر که بتوانند اهمیت هر سنسور را در فرآیند تصمیم‌گیری نشان دهند، می‌توانند گزینه‌های عملی‌تری باشند (Le & Nguyen, ۲۰۲۶). این یافته با تحقیقات دیگر که بر اهمیت قابلیت تفسیرپذیری در سیستم‌های PdM تأکید دارند، همسو است (Al et al, ۲۰۲۶).

۵.۲. چالش‌های پیاده‌سازی در محیط واقعی

علیرغم عملکرد عالی در محیط آزمایشگاهی و داده‌های شبیه‌سازی‌شده، پیاده‌سازی این چارچوب در محیط‌های صنعتی واقعی با چالش‌های متعددی مواجه است که در ادامه به مهم‌ترین آن‌ها اشاره می‌شود:

- **کیفیت و در دسترس بودن داده:** جمع‌آوری داده‌های خرابی با کیفیت بالا یکی از بزرگترین موانع است، زیرا خرابی‌ها به‌طور طبیعی رویدادهایی نادر محسوب می‌شوند. این مسئله منجر به عدم تعادل شدید کلاس‌ها می‌شود که می‌تواند عملکرد مدل‌های یادگیری ماشین را به شدت تحت تأثیر قرار دهد (al et Al, ۲۰۲۶; et Phutane al, ۲۰۲۵). برای غلبه بر این مشکل، به کارگیری تکنیک‌های تعادل‌سازی داده و استفاده از یادگیری بدون نظارت برای تشخیص ناهنجاری‌ها به جای طبقه‌بندی خرابی، پیشنهاد شده است (al et Al, ۲۰۲۶).
- **تغییر مفهوم (Drift Concept):** شرایط عملیاتی تجهیزات صنعتی در طول زمان تغییر می‌کند. به عنوان مثال، یک دستگاه جدید با یک دستگاه که سال‌ها کار کرده است، الگوهای ارتعاشی متفاوتی تولید می‌کند. این تغییرات تدریجی که به عنوان تغییر مفهوم شناخته می‌شوند، می‌توانند دقت مدل‌های آموزش‌دیده را به مرور زمان کاهش دهند (al et Wu, ۲۰۲۶). استفاده از مدل‌های تطبیقی (مانند Ensemble Adaptive) که به‌طور مداوم با داده‌های جدید به‌روز می‌شوند، یکی از راه‌کارهای کلیدی برای مقابله با این چالش است (al et Wu, ۲۰۲۶). همچنین استراتژی‌های تشخیص تغییر مفهوم، مانند پایش عملکرد مدل بر روی پنجره‌های زمانی داده، می‌تواند برای آغاز مجدد فرآیند آموزش به کار روند (al et Wu, ۲۰۲۶).
- **قابلیت تفسیرپذیری:** بسیاری از مدل‌های یادگیری عمیق به عنوان «جعبه سیاه» شناخته می‌شوند و درک دلیل تصمیم‌گیری آن‌ها برای مهندسان و تکنسین‌ها دشوار است (al et Al, ۲۰۲۶). این مسئله می‌تواند اعتماد به سیستم را کاهش داده و پذیرش آن را در محیط‌های صنعتی با مشکل مواجه کند. استفاده از تکنیک‌های هوش مصنوعی قابل توضیح (XAI) مانند SHAP و LIME برای شناسایی سنسورها و ویژگی‌هایی که بیشترین تأثیر را در پیش‌بینی داشته‌اند، می‌تواند این چالش را برطرف سازد (al et Al, ۲۰۲۶; Le, & Nguyen, ۲۰۲۶). به عنوان مثال، نتایج نشان داد که ویژگی‌های توان مصرفی و تغییرات دما، به ترتیب با ۶۴ درصد اهمیت، نقش کلیدی در پیش‌بینی خرابی در یک مجموعه داده ماشین‌کاری ایفا می‌کنند (Le, & Nguyen, ۲۰۲۶).
- **مدیریت عدم قطعیت:** پیش‌بینی‌های نقطه‌ای (مانند یک مقدار دقیق برای RUL) نمی‌توانند عدم قطعیت ذاتی در فرآیندهای صنعتی را منعکس کنند (al et Bhardwaj, ۲۰۲۶). ارائه پیش‌بینی‌ها به صورت بازه یا توزیع احتمال، به تصمیم‌گیرندگان کمک می‌کند تا ریسک‌ها را بهتر مدیریت کنند و برنامه‌های نگهداری مقاوم‌تری طراحی نمایند (al et Bhardwaj, ۲۰۲۶). ترکیب مدل‌های پیش‌بینی با روش‌های برنامه‌ریزی بهینه مانند PPO می‌تواند منجر به برنامه‌ریزی تطبیقی نگهداری شود که زمان خرابی را تا ۲۴ درصد کاهش می‌دهد (al et Bhardwaj, ۲۰۲۶).
- **ادغام سیستم‌ها و امنیت سایبری:** یکپارچه‌سازی سیستم PdM با سیستم‌های موجود مانند CMMS و SCADA یکی از چالش‌های فنی مهم است که نیازمند توسعه رابط‌های برنامه‌نویسی (API) استاندارد و ماژولار است (al et Phutane, ۲۰۲۶; al et Zhao, ۲۰۲۵). اتصال دستگاه‌های صنعتی به شبکه و اینترنت، آن‌ها را در معرض تهدیدات سایبری قرار می‌دهد که می‌تواند منجر به اختلال در تولید یا سرقت داده‌های حساس شود، بنابراین پیاده‌سازی پروتکل‌های امنیتی قوی (مانند احراز هویت دو مرحله‌ای و رمزگذاری) ضروری است (Phutane al et, ۲۰۲۵).

۶. نتیجه‌گیری و پیشنهادات

این پژوهش به ارائه یک چارچوب جامع و عملی برای پیش‌بینی خرابی تجهیزات صنعتی با تلفیق اینترنت اشیا و هوش مصنوعی پرداخت. نتایج به‌وضوح نشان داد که رویکرد یکپارچه مبتنی بر داده‌های بلادرنگ سنسورها و مدل‌های پیشرفته یادگیری عمیق، می‌تواند انقلابی در حوزه تعمیر و نگهداری صنعتی ایجاد کند و صنایع را از استراتژی‌های پرهزینه واکنشی یا پیشگیرانه زمان‌بندی‌شده، به سمت نگهداری هوشمند و پیش‌بینی‌کننده سوق دهد.

یافته‌های کلیدی این تحقیق عبارت‌اند از:

۱. مدل ترکیبی CNN-LSTM پیشنهادی با دقت بیش از ۹۵ درصد، عملکرد برتری نسبت به مدل‌های سنتی (مانند SVM و Forest Random) و حتی مدل‌های LSTM خالص دارد و توانایی تشخیص الگوهای فضایی-زمانی پیچیده در داده‌های صنعتی را داراست (al et Zhao, ۲۰۲۶).

۲. چارچوب پیشنهادی قادر است علائم اولیه خرابی را تا ۷۲ ساعت قبل از وقوع شناسایی کند که این زمان پاسخ، امکان برنامه‌ریزی دقیق تعمیرات و کاهش چشمگیر زمان ازکارافتادگی تجهیزات را فراهم می‌سازد.

۳. رویکردهای تطبیقی و یادگیری مستمر، راه‌حلی کلیدی برای مقابله با چالش تغییرات تدریجی الگوهای داده در محیط‌های صنعتی پویا هستند (al et Wu, ۲۰۲۶).

۴. علیرغم مزایای فراوان، چالش‌هایی مانند کمبود داده‌های خرابی، نیاز به تفسیرپذیری، مدیریت عدم قطعیت و امنیت سایبری، موانع اصلی بر سر راه پذیرش گسترده این فناوری‌ها در صنعت هستند (al et Al, ۲۰۲۶; al et Phutane, ۲۰۲۵; al et Bhardwaj, ۲۰۲۶).

بر اساس یافته‌های این پژوهش، پیشنهادهای زیر برای تحقیقات آتی و پیاده‌سازی‌های صنعتی ارائه می‌شود:

- **پژوهش بر روی معماری‌های ترکیبی پیشرفته‌تر:** ترکیب مدل‌های CNN-LSTM با مکانیزم‌های توجه (Attention) و یادگیری تقویتی (Learning Reinforcement) می‌تواند عملکرد و کارایی سیستم‌های PdM را در سناریوهای پیچیده‌تر بهبود بخشد (al et Al, ۲۰۲۶; al et Bhardwaj, ۲۰۲۶). همچنین طراحی مدل‌های سبک‌تر و بهینه‌شده برای اجرا بر روی گره‌های لبه، یک نیاز اساسی است.
- **توسعه و استانداردسازی دوقلوی دیجیتال:** ایجاد چارچوب‌های استاندارد برای توسعه دوقلوی دیجیتال تجهیزات و تلفیق آن با مدل‌های داده‌محور و فیزیک‌محور، می‌تواند به افزایش دقت و قابلیت اطمینان پیش‌بینی‌ها کمک کند. همچنین، استفاده از بلاک‌چین برای تأمین امنیت داده‌های دوقلوی دیجیتال یک حوزه پژوهشی نویدبخش است (al et Phutane, ۲۰۲۵).
- **تمرکز بر هوش مصنوعی قابل توضیح:** سرمایه‌گذاری بر روی تکنیک‌های XAI برای ایجاد شفافیت در تصمیم‌گیری‌های مدل‌های یادگیری عمیق، می‌تواند اعتماد مهندسان و بهره‌برداران صنعتی را جلب کرده و پذیرش سیستم‌های PdM را تسریع بخشد (al et Al, ۲۰۲۶). ارائه داشبوردهای بصری که علت هشدارها را با استفاده از اهمیت ویژگی‌ها توضیح دهند، می‌تواند بسیار مفید باشد (Le, & Nguyen, ۲۰۲۶).

- مدیریت عدم قطعیت در فرآیند تصمیم‌گیری: توسعه روش‌هایی که پیش‌بینی‌های توزیعی (مانند بازه‌های اطمینان برای RUL) را با الگوریتم‌های برنامه‌ریزی نگهداری ترکیب کنند تا برنامه‌های تعمیراتی مقاوم‌تر و مقرون‌به‌صرفه‌تری تولید نمایند، از اهمیت بالایی برخوردار است (al et Bhardwaj, ۲۰۲۶).
- همکاری صنعت و دانشگاه: برای غلبه بر چالش کمبود داده‌های واقعی و اعتبارسنجی مدل‌ها در شرایط عملیاتی، همکاری نزدیک‌تر بین مراکز تحقیقاتی و واحدهای تولیدی ضروری است. ایجاد مخازن داده‌ی باز و استاندارد از خرابی‌های صنعتی می‌تواند به پیشرفت سریع‌تر این حوزه کمک کند.

۸. منابع

۱. Al, A., et al) ۲۰۲۶. (A Systematic Review of Anomaly and Fault Detection Using Machine Learning for Industrial Machinery *Algorithms*, ۱۹)۲۶, ۱۰۸ .
۲. Bhardwaj, R., et al) ۲۰۲۶. (Uncertainty-aware remaining useful life prediction and PPO based optimal maintenance scheduling in industrial IoT *Reliability Engineering & System Safety* .
۳. IEEE) ۲۰۲۵. (۵G Architectures Enabling Remaining Useful Life Estimation for Industrial IoT :A Holistic Study *IEEE Open Journal of the Communications Society*, ۶, ۱۰۱۶-۱۰۲۹ .
۴. Nguyen, V.-H., & Le, T.-T) ۲۰۲۶. (Predictive Maintenance Through Conventional Intelligent Fault Diagnostics and Prognostic Models .In *AI-Empowered Machinery Fault Diagnostics and Prognostics in Smart Manufacturing* ASME Press .
۵. Phutane, P., et al) ۲۰۲۵. (Digital twin innovations for induction motor monitoring and predictive maintenance :A ۲۰۲۰-۲۰۲۵ review *ScienceDirect* .
۶. Springer) ۲۰۲۶. (IoT enabled predictive maintenance system in Industry ۴.۰ using target-based feature pool linked dilated recurrent neural network *Wireless Networks*, ۳۲, ۱۰۹-۱۳۰ .
۷. Wu, J., et al) ۲۰۲۶. (Adaptive machine learning models for predictive maintenance in industrial internet of things) IIoT (systems *Scientific Reports*, ۱۶, ۱۲۴۵۱ .
۸. Zhao, et al) ۲۰۲۶. (An IoT-Based Predictive Maintenance Framework Using a Hybrid Deep Learning Model for Smart Industrial Systems *ScienceDirect* .