

بررسی جامع رویکردهای نگهداری و تعمیرات پیش‌بینانه مبتنی بر هوش مصنوعی در شناورهای دریایی

محمدباقر کیایی^۱، مجتبی یوسفی‌پور^۲

۱- مدرس گروه مکانیک دریایی، دانشکده شناوری، دانشگاه امام خمین‌ای (مد ظله العالی)، kiaei.mb69@gmail.com, ۹۳۸۷۹۹۲۳۹۹
۲- مدرس گروه مکانیک دریایی، دانشکده شناوری، دانشگاه امام خمین‌ای (مد ظله العالی)، mojtaba-you@gmail.com, ۹۰۵۶۳۷۱۳۱۲

چکیده:

با رشد روزافزون صنعت کشتیرانی و نقش کلیدی آن در زنجیره تأمین جهانی، اهمیت بهبود روش‌های نگهداری و تعمیرات در افزایش ایمنی، کاهش هزینه‌ها و ارتقای بهره‌وری عملیاتی شناورها بیش از پیش احساس می‌شود. پژوهش حاضر به بررسی جامع راهبردهای نگهداری و تعمیرات پیش‌بینانه (PdM) مبتنی بر داده در صنعت دریایی می‌پردازد و مروری بر جدیدترین تکنیک‌های مورد استفاده در سامانه‌های مختلف کشتی، ارائه می‌دهد. برخلاف روش‌های سنتی مانند نگهداری واکنشی و پیشگیرانه، نگهداری و تعمیرات پیش‌بینانه با بهره‌گیری از الگوریتم‌های یادگیری ماشین (ML) و یادگیری عمیق (DL) قادر است زمان خرابی را پیش‌بینی کرده و برنامه‌ریزی نگهداری را بهینه سازد. این مقاله به بررسی مدل‌های مختلف، از رگرسیون خطی تا شبکه‌های عصبی پیچشی و حافظه‌دار (مانند شبکه‌های حافظه کوتاه‌مدت بلندمدت (LSTM) و شبکه‌های عصبی پیچشی (CNNs)) می‌پردازد و چالش‌های عملیاتی آن‌ها از جمله نیاز به داده‌های برچسب‌خورده، پیچیدگی محاسباتی و مشکلات مقیاس‌پذیری را تحلیل می‌کند. همچنین، از رویکردهای نوین مانند یادگیری فدرال (FL) و یادگیری انتقالی (TL) به عنوان راهکارهای نویدبخش برای حفظ حریم خصوصی، امنیت داده و کاهش نیاز به منابع متمرکز نام برده می‌شود. نتایج نشان می‌دهد استقرار نگهداری و تعمیرات پیش‌بینانه داده‌محور در ناوگان، کاهش چشمگیر هزینه نگهداری و کاهش محسوس زمان توقف را به دنبال دارد. مدل‌های یادگیری عمیق نسبت به روش‌های کلاسیک دقت بالاتری دارند؛ ولی نیاز داده برچسب‌خورده و منابع محاسباتی زیاد، مانع استقرار عملیاتی در دستگاه کاربر دریایی است. یادگیری فدرال و انتقالی مسیرهای کاهش وابستگی به داده و حفظ حریم خصوصی‌اند؛ اما نبود استاندارد و مجموعه داده خرابی، پذیرش صنعتی را محدود کرده است.

واژه‌های کلیدی:

نگهداری و تعمیرات پیش‌بینانه، یادگیری ماشین، هوش مصنوعی، عمر مفید باقیمانده، پیش‌بینی خرابی

A Comprehensive Review of Artificial Intelligence-Based Predictive Maintenance Approaches in Marine Vessel

Mohammad bagher Kiaei¹, mojtaba usefi pour²

1, 2 Department of Marine Mechanical Engineering, Faculty of Naval Architecture, Imam Khamenei University, Iran

Abstract

With the rapid growth of the shipping industry and its key role in the global supply chain, the importance of improving maintenance methods to enhance safety, reduce costs, and increase the operational efficiency of vessels is more evident than ever. The present study provides a comprehensive review of data-driven predictive maintenance (PdM) strategies in the maritime industry and surveys the latest techniques applied to various ship systems, including propulsion, electrical, auxiliary, and hull structures. Unlike traditional approaches such as reactive and preventive maintenance, predictive maintenance (PdM), empowered by machine learning (ML) and deep learning (DL) algorithms, is capable of forecasting failures and optimizing maintenance scheduling. This paper examines a range of models, from linear regression to recurrent and convolutional neural networks (such as Long Short-Term Memory (LSTM) and Convolutional Neural Networks (CNNs)), and analyzes their operational challenges, including the need for labeled data, computational

complexity, and scalability issues. Furthermore, emerging approaches such as Federated Learning (FL) and Transfer Learning (TL) are highlighted as promising solutions for ensuring privacy, data security, and reducing reliance on centralized resources. Finally, by addressing existing gaps in standardization, insufficient data, and model decision transparency, the paper outlines future research directions toward developing reliable and adaptable predictive maintenance (PdM) systems for the maritime industry.

Keywords

Predictive Maintenance, Machine Learning, Artificial Intelligence, Remaining Useful Life, Failure Prediction

بخش کارآمدتر و پایدارتر کمک می‌کنند [۳، ۴].
با این حال، با وجود این پیشرفت‌ها، چالش‌های استقرار در دنیای واقعی، از جمله مقیاس‌پذیری مدل، کارایی ارتباطی و حریم خصوصی و امنیت داده‌ها، به‌ویژه در رویکردهای یادگیری ماشین متمرکز کلاسیک (CML)، همچنان باقی هستند. به طور دقیق، یادگیری ماشین متمرکز کلاسیک نیازمند بارگذاری مقادیر عظیمی از داده‌های ناوگان به سرورهای مرکزی است که سطح حمله سایبری و خطرات عملیاتی را افزایش می‌دهد، در حالی که باید با انواع و اندازه‌های مختلف شناورها نیز سازگار شود. برای کاهش این مسائل، الگوهای یادگیری غیرمتمرکز مانند یادگیری فدرال اخیراً معرفی شده‌اند که جاذبه امن داده‌ها را تضمین می‌کنند و به کشتی‌ها اجازه می‌دهند به‌عنوان گره‌های لبه عمل کنند. یادگیری فدرال آموزش محلی مدل‌های یادگیری ماشین را روی کشتی‌ها امکان‌پذیر می‌سازد. سرور یادگیری فدرال پارامترهای مدل را جمع‌آوری و تجمیع می‌کند و حریم خصوصی را تضمین می‌نماید، مدل‌ها را بدون نیاز به انتقال داده‌های خام به سرور از طریق دوره‌های تکراری آموزش می‌دهد و یک مدل جهانی متناسب با شرایط خاص شناور ارائه می‌دهد [۵-۷].

مطالعات اخیر جنبه‌هایی از پیش‌بینی عیوب در صنعت دریایی را بررسی کرده‌اند. به عنوان مثال، علی و همکاران بر روی سامانه‌های تشخیص خوردگی برای ساختارهای بدنه تمرکز کردند [۸]، ژانگ و همکاران مدل‌های پیش‌بینی عمر باقیمانده مفید عمر مفید باقی‌مانده (RUL) را مورد کاوش قرار دادند [۹]، در حالی که لیانگ و همکاران بر نقش نظارتی انجمن‌های رده‌بندی دریایی تمرکز کردند [۱۰]. اگرچه این مطالعات اطلاعات قابل توجهی در مورد جنبه‌های مختلف نگهداری و

۱- مقدمه

یکی از مهم‌ترین عامل عملیاتی بودن شناورها در سازمان رزم در نیروی دریایی تعمیر و نگهداری است، راهبردهای سنتی نگهداری و تعمیرات، مانند نگهداری واکنشی و نگهداری پیشگیرانه، محدودیت‌هایی در پیشگیری از حوادث نشان داده‌اند و اغلب به هزینه‌های قابل توجهی منجر شده‌اند. به عنوان مثال، تنها در سال ۲۰۲۳، نیمی از حوادث دریایی گزارش شده به خرابی‌های مکانیکی نسبت داده شد [۱، ۲]. در راستای رسیدگی به این چالش‌ها، تلاش‌های پژوهشی بر توسعه راهبردهای نگهداری و تعمیرات پیش‌بینانه متمرکز شده‌اند. برخلاف نگهداری واکنشی و نگهداری پیشگیرانه، نگهداری و تعمیرات پیش‌بینانه از مدل‌های یادگیری ماشین برای پیش‌بینی فعالانه زوال یا خرابی‌های احتمالی تجهیزات بر اساس بینش‌های مبتنی بر داده‌های عملیاتی مرتبط با شناور استفاده می‌کند.

مفهوم نگهداری و تعمیرات پیش‌بینانه مبتنی بر یادگیری ماشین جزئی جدایی‌ناپذیر از نسل چهارم کشتیرانی (این نسل از کشتیرانی، استفاده گسترده از فناوری‌های نوین برای هوشمندسازی، خودکارسازی و پایداری زیست‌محیطی عملیات دریایی را دنبال می‌کند)، معروف به کشتیرانی ۴.۰^۱ است. این الگو، یکپارچه‌سازی پیشرفت‌های فناورانه نوین مانند اینترنت اشیا کشتی‌ها (IoS) و هوش مصنوعی (AI) را برای تبدیل کشتی‌های سنتی به "کشتی‌های هوشمند" متصور می‌کند. در چارچوب این الگو، این پیشرفت‌ها مدیریت خودکار ناوگان، کاهش زمان از کار افتادگی و برآورده ساختن مقررات زیست‌محیطی را امکان‌پذیر می‌سازند و به یک

¹ Shipping 4.0

تعمیرات پیش‌بینانه ارائه می‌دهند، اما فاقد یک تحلیل جامع از رویکردهای نگهداری و تعمیرات پیش‌بینانه بر اساس سامانه‌های مختلف شناور هستند. با توجه به اطلاعات موجود، مطالعه‌ای وجود ندارد که یک بررسی جامع از رویکردهای نگهداری و تعمیرات پیش‌بینانه دربرگیرنده تمام سیستم‌های اصلی شناور ارائه دهد.

با در نظر گرفتن پتانسیل قابل توجه ادغام استراتژی‌های نگهداری و تعمیرات پیش‌بینانه در حوزه دریایی و شکاف موجود در ادبیات علمی، این کار با هدف ارائه یک مرور کلی از جدیدترین تکنیک‌های نگهداری و تعمیرات پیش‌بینانه مبتنی بر داده که در سیستم‌های مختلف شناور یعنی سامانه پیش‌ران، سیستم‌های الکتریکی، سیستم‌های فرعی و بدنه به کار رفته‌اند، انجام می‌شود. این بررسی ضمن شناسایی روندها، مسائل باز مرتبط و مسیرهای آینده بالقوه را نیز مشخص می‌کند تا تحقیقات بیشتر را تحریک نماید.

۲- رویکردهای نگهداری و تعمیرات در صنعت دریایی

۲-۱- مروری بر استراتژی‌های تعمیر و نگهداری

عملیات نگهداری و تعمیرات در حوزه دریایی به طور سنتی بر نگهداری و تعمیرات واکنشی (RM) متکی بوده است. نگهداری واکنشی به این صورت است که تعمیرات، بلافاصله پس از وقوع خرابی و به عنوان یک پاسخ مستقیم، در شناور انجام می‌شوند. با وجود اینکه تعمیرات واکنشی به مسائل فوری رسیدگی می‌کند، اما به هزینه‌بر بودن و ناکامی (عمدتاً به دلیل توقف‌های غیرمنتظره)، شناخته شده است؛ چرا که بر اقدامات اصلاحی به‌جای پیشگیری تمرکز دارد و نگرانی‌های ایمنی را افزایش می‌دهد. علاوه بر این، به دلیل هزینه‌های عملیاتی کلی^۲ بالا (حدود ۴۰٪) که با عملیات نگهداری و تعمیرات یک کشتی مرتبط است، سازمان‌های دریایی به دنبال بررسی استراتژی‌های بهینه‌سازی جایگزین بوده‌اند [۱۱، ۱۲].

علاوه بر این، طبق کنوانسیون بین‌المللی ایمنی جان اشخاص در دریا^۳، سازمان‌های دریایی موظف به انجام یک

سری بازرسی‌ها هستند، از جمله یک بازرسی اولیه و به دنبال آن بازرسی‌های سالانه، میانی و بازرسی‌های پنج سال یک‌بار در طول عمر عملیاتی کشتی انجام می‌شوند [۱۳، ۱۴]. در راستای رفع این چالش، استراتژی‌های نگهداری و تعمیرات پیش‌گیرانه با هدف قرار دادن اجزای مختلف کشتی معرفی شده‌اند. به طور جزئی، یک استراتژی نگهداری پیش‌گیرانه شامل ایجاد بازرسی‌های نگهداری و تعمیرات برنامه‌ریزی‌شده بر اساس فواصل استاندارد صنعتی یا پیش‌بینی‌های فرسودگی ارائه شده توسط سازنده است. اگرچه نگهداری پیش‌گیرانه در مقایسه با نگهداری واکنشی، خرابی‌ها و توقف‌های غیرمنتظره را کاهش می‌دهد، اما اغلب منجر به هزینه‌های عملیاتی کلی قابل توجهی می‌شود که با تعمیرات غیرضروری و دوره‌های نگهداری و تعمیرات بیش از حد برنامه‌ریزی شده همراه است [۱۵].

در مقابل نگهداری واکنشی و نگهداری پیش‌گیرانه، نگهداری و تعمیرات پیش‌بینانه با هدف افزایش طول عمر تجهیزات و کاهش خرابی‌ها، بازرسی‌ها را بهینه می‌کند تا با استفاده از روش‌های مبتنی بر داده مانند یادگیری ماشین (ML)، زمان توقف و هزینه‌ها را به حداقل برساند. به طور خاص، نگهداری و تعمیرات پیش‌بینانه از داده‌های دریافتی از کشتی‌های دریایی (مانند ارتعاشات، دما و غیره) بهره می‌برد و پیش‌بینی‌هایی از خرابی‌های مورد انتظار تجهیزات تولید می‌کند. مطالعات نشان می‌دهد که نگهداری و تعمیرات پیش‌بینانه پتانسیل کاهش هزینه‌های عملیاتی کلی نگهداری و تعمیرات تا ۴۵٪ در مقایسه با استراتژی‌های نگهداری و تعمیرات سنتی را دارد، در حالی که خطرات ایمنی را نیز کاهش می‌دهد و حجم کاری خدمه را نیز کم می‌کند [۱۶، ۱۷].

۲-۲- روش‌های پیشرفته نگهداری و تعمیرات: مدل‌محور و مبتنی بر یادگیری ماشین

این بخش به توصیف روش‌های مختلفی می‌پردازد که برای نگهداری و تعمیرات پیش‌بینانه در صنعت دریایی به کار گرفته می‌شوند. در این راستا، دو دسته اصلی از روش‌ها متمایز می‌شوند: مدل‌های مبتنی بر فیزیک و مدل‌های داده‌محور (یادگیری ماشین و یادگیری عمیق).

^۲ OPEX

^۳ SOLAS

۲-۲-۱- روش‌های مبتنی بر فیزیک برای نگهداری و تعمیرات پیش‌بینانه

نگهداری و تعمیرات پیش‌بینانه با پیش‌بینی خرابی‌های عملیاتی احتمالی، هدف بهینه‌سازی بازه‌های زمانی پرمصرف نگهداری و بازرسی‌ها را دنبال می‌کند. روش‌های مبتنی بر فیزیک بر مدل‌های ریاضی تکیه دارند که به طور خاص برای تخمین وضعیت فرسودگی یک قطعه بر اساس مقادیر مشاهده شده سیستم طراحی شده‌اند. با وجود اینکه این روش‌ها به دلیل سادگی و نیاز محاسباتی کم می‌توانند مزایایی داشته باشند، اما ممکن است به تصویر کشیدن تمامی جزئیات پیچیده فیزیکی یک سیستم را چالش‌برانگیز کنند. علاوه بر این، تغییرات احتمالی در شرایط عملیاتی سیستم‌ها یا تأثیر عواملی که در مدل گنجانده نشده‌اند، می‌توانند بر دقت پیش‌بینی‌ها تأثیر بگذارند. از جمله روش‌های مدل‌محور برجسته می‌توان به فیلترهای کالمن (KFs) و تحلیل وایبول^۴ اشاره کرد [۱۰، ۱۸-۲۰].

۲-۲-۲- روش‌های داده‌محور برای نگهداری و تعمیرات پیش‌بینانه

در حال حاضر، اکثر کشتی‌های عملیاتی یک تحول دیجیتال را در راستای اصول کشتیرانی ۴.۰ تجربه کرده‌اند [۲۱]. این کشتی‌ها اغلب به عنوان کشتی‌های فعال‌شده سایبری (CESS) شناخته می‌شوند که در یک اکوسیستم جامع عمل می‌کنند. این اکوسیستم شامل (الف) کشتی، (ب) یک مرکز کنترل مستقر در خشکی (SCC)، که مسئول راهبری سیستم مدیریت اضطراری، کشتی‌های فعال‌شده سایبری و (ج) پروتکل‌های ارتباطی مورد استفاده بین کشتی‌های فعال‌شده سایبری و مرکز کنترل مستقر در خشکی است. علاوه بر این، کشتی‌های فعال‌شده سایبری شامل هر دو سیستم فناوری اطلاعات (IT) و فناوری عملیاتی (OT) است که برای عملیات کشتی ضروری هستند [۲۲]. بر اساس این سیستم‌های سیستم فناوری اطلاعات و فناوری عملیاتی، حجم وسیعی از داده‌های عملیاتی روزانه توسط حسگرهای روی کشتی تولید و جمع‌آوری می‌شوند. هوش مصنوعی این امکان را برای سازمان‌های دریایی فراهم کرده است تا پتانسیل این داده‌ها را به طور موثر مهار کنند و آن‌ها را قادر سازند تا

نیازهای خدماتی مختلفی (مانند نگهداری و تعمیرات پیش‌بینانه، پیش‌بینی مصرف سوخت و غیره) را برآورده کرده و تصمیم‌گیری بهینه را امکان‌پذیر سازند [۲۳، ۲۴]. برخلاف روش‌های سنتی مبتنی بر مدل، روش‌های مبتنی بر یادگیری ماشین برای مدل‌های پیشرفته نگهداری و تعمیرات پیش‌بینانه مناسب‌تر در نظر گرفته می‌شوند و توانایی‌های زیر را ارائه می‌دهند: (الف) یادگیری الگوها از مجموعه داده‌های پیچیده و بزرگ؛ (ب) انطباق با ماشین‌ها بدون نیاز به طراحی مدل‌های فیزیکی دقیق؛ (ج) انجام پیش‌بینی‌های دقیق در زمان واقعی؛ و (د) مقاومت در برابر داده‌های نویزی و ناقص [۲۵-۲۷].

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که بر توسعه مدل‌های هوشمند متمرکز است. این مدل‌ها قادرند از الگوها و بینش‌های مختلفی که از داده‌های ورودی پردازش می‌شوند، یاد بگیرند تا تصمیم‌گیری کنند [۲۸]. یادگیری ماشین به سه دسته اصلی تقسیم می‌شود: یادگیری با نظارت^۵، یادگیری بدون نظارت و یادگیری تقویتی^۶ که در ادامه توضیح داده می‌شوند:

- یادگیری با نظارت: این روش به مجموعه داده‌های برچسب‌گذاری شده متکی است که شامل هر دو ورودی (X) و خروجی متناظر (Y) آن می‌شود تا یک تابع نگاشت ($f: X \rightarrow Y$) را یاد بگیرد. وظایف نظارت شده مثال‌زدنی در حوزه دریایی شامل طبقه‌بندی^۷ و رگرسیون^۸ هستند که به ترتیب برای تشخیص خرابی ماشین‌آلات و پیش‌بینی فعالانه خرابی‌های احتمالی استفاده می‌شوند.
- یادگیری بدون نظارت^۹: این روش به کشف الگوها در داده‌هایی می‌پردازد که فاقد خروجی‌های برچسب‌گذاری شده هستند. تکنیک‌های پرکاربرد در یادگیری بدون نظارت شامل خوشه‌بندی^{۱۰} و کاهش ابعاد^{۱۱} هستند.

⁵ Supervised Learning

⁶ Reinforcement Learning (RL)

⁷ Classification

⁸ Regression

⁹ Unsupervised Learning

¹⁰ Clustering

¹¹ Dimensionality reduction

⁴ Weibull analysis

خوشه‌بندی امکان گروه‌بندی نقاط داده مشابه را فراهم می‌کند، درحالی‌که کاهش ابعاد، ابعاد داده را کاهش می‌دهد و درعین‌حال ساختار آن‌ها را حفظ می‌کند. در حوزه دریایی، الگوریتم‌های یادگیری بدون نظارت می‌توانند برای شناسایی الگوهای مربوط به مصرف سوخت و رفتارهای مکانیکی غیرعادی یا برای ساده‌سازی داده‌های پیچیده دریایی جهت تحلیل و بصری‌سازی استفاده شوند.

- یادگیری تقویتی^{۱۲}: این روش بر یادگیری یک سیاست در یک محیط خاص تمرکز دارد، با در نظر گرفتن هزینه‌ها و پاداش‌های تجمعی با هر عمل. کاربردهای مثال‌زدنی یادگیری تقویتی (RL) در حوزه دریایی شامل ناوبری خودمختار کشتی و بهینه‌سازی زمان‌بندی بازرسی‌های نگهداری و تعمیرات پیش‌بینانه است.

علاوه بر این، کاربردهای فعلی یادگیری ماشین از شبکه‌های ارتباطی دریایی (MCNs) برای امکان انتقال بی‌سیم داده‌ها که توسط مرکز کنترل ساحلی (SCC) (مانند ستاد شرکت) و سیستم‌های ماهواره‌ای ارائه می‌شود، استفاده می‌کنند. با این حال، این ساختارها با چالش‌هایی مانند تأخیرهای ارتباطی، در دسترس بودن طیف و مشکلات اتصال متناوب روبرو هستند [۲۹]. علاوه بر این، کاربردهای یادگیری ماشین متمرکز کلاسیک نگرانی‌های امنیتی و مقیاس‌پذیری قابل توجهی را ایجاد می‌کنند. به عنوان مثال، از آنجایی که مدل‌های یادگیری ماشین متمرکز کلاسیک برای انتقال داده‌های عملیاتی به یک سرور، نیاز به ارتباط کشتی به ساحل دارند، خطراتی در مورد احتمال دسترسی غیرمجاز یا سوء استفاده از داده‌های کشتی که برای آموزش مدل‌های یادگیری ماشین استفاده می‌شوند، وجود دارد. علاوه بر این، ترکیب چندین کشتی که مقادیر زیادی داده تولید می‌کنند، می‌تواند منجر به چالش‌های مقیاس‌پذیری شود [۳۰، ۳۱].

در راستای رفع این چالش‌ها، یادگیری فدرال معرفی شده است که به کشتی‌ها این امکان را می‌دهد تا به‌عنوان گره‌های لبه (یعنی دستگاه کاربرها^{۱۳} یادگیری فدرال) عمل کرده و مدل‌ها را در کشتی با هدف حل مشترک یک وظیفه یادگیری و تنها انتقال پارامترهای مدل و داده‌های خود آموزش دهند. این فرآیند توسط یک سرور یادگیری فدرال هماهنگ می‌شود که مدل جهانی را بر اساس تعداد دورهای از پیش تعریف شده، به‌روزرسانی و به دستگاه کاربرها باز می‌گرداند. رویکرد آموزش غیرمتمرکز یادگیری فدرال، حریم خصوصی و امنیت داده‌ها را افزایش می‌دهد و سطح حمله سایبری را در مقایسه با یادگیری ماشین متمرکز کلاسیک کاهش می‌دهد، در حالی که با گنجاندن گره‌های دستگاه کاربر بیشتر (یعنی کشتی‌ها) در فرآیند آموزش، مقیاس‌پذیری مدل را پشتیبانی می‌کند و آن را برای کاربردهای دریایی مانند نگهداری و تعمیرات پیش‌بینانه بسیار مناسب می‌سازد [۴، ۳۲].

در کاربردهای دنیای واقعی، دسترسی به داده‌های برجسب‌گذاری شده اغلب محدود است. جمع‌آوری این داده‌ها، به ویژه در مواجهه با سیستم‌های قدیمی، پرهزینه، زمان‌بر یا غیرعملی در نظر گرفته می‌شود. یادگیری انتقالی با افزایش عملکرد مدل‌های یادگیری ماشین از طریق انتقال دانش از دامنه‌های منبع مرتبط، این چالش‌ها را برطرف می‌کند و نیاز به داده‌های عملیاتی گسترده را کاهش می‌دهد [۳۳].

در زمینه نگهداری و تعمیرات پیش‌بینانه دریایی، یادگیری انتقالی راه حلی برای مقیاس‌پذیری مدل‌ها جهت تطبیق با سازندگان قطعات و فناوری‌های مختلف ارائه می‌دهد. به عنوان مثال، دانش به دست آمده از یک موتور دیزل (DE) هیبریدی یک کشتی فله‌بر می‌تواند به یک موتور دیزل تک‌سوز یک کشتی مسافربری منتقل شود. شکل ۱، تفاوت‌های بین آموزش CML (یادگیری ماشین متمرکز کلاسیک)، FL (یادگیری فدرال) و TL (یادگیری انتقالی) را نشان می‌دهد.

¹³ clients

¹² Reinforcement Learning (RL)


$$RUL(t) = t_e - t \quad (1)$$

زمان تا خرابی (TTF): زمان تا خرابی به عنوان زمان باقی مانده قبل از رسیدن یک دارایی به نقطه خرابی تعریف می شود. برخلاف عمر مفید باقی مانده (RUL)، TTF بر محاسبه زمان مطلق خرابی تمرکز دارد. تفاوت بین TTF و عمر مفید باقی مانده (RUL) در شکل ۲ نشان داده شده است [۳۷]. اگر زمانی باشد که خرابی رخ می دهد و t زمان فعلی باشد، TTF را می توان به صورت زیر بیان کرد:

$$TTF(t) = t_f - t \quad (2)$$

زمان تعمیر (TTR): به عنوان زمان مورد نیاز برای تعمیر یک دارایی دریایی و بازگرداندن آن به شرایط عملیاتی عادی تعریف می شود [۳۸]. فرض کنید t_r زمانی باشد که دارایی به طور کامل بازیابی شده است، درحالی که t_f زمان خرابی است، TTR را می توان به صورت زیر بیان کرد:


$$TTR(t) = t_r - t_f \quad (3)$$



شکل ۲. تمایز بین عمر مفید باقیمانده (RUL)، زمان تا خرابی (TTF) و زمان تعمیر (TTR) را به وضوح نشان می دهد [۳۸].

۳- تحلیل مبتنی بر اجزا در رویکردهای نگهداری و تعمیرات پیش بینانه

این بخش به ارائه تحلیل عمیقی از کاربردهای نگهداری و تعمیرات پیش بینانه از منظر مبتنی بر اجزا می پردازد و بر سیستم های کلیدی در کشتی های دریایی تمرکز می کند.



شکل ۱. تفاوت های بین سه رویکرد آموزش یادگیری ماشین را نشان می دهد: (A) یادگیری ماشین متمرکز کلاسیک، (B) یادگیری فدرال و (C) یادگیری انتقالی (TL).

۳-۲-۲- تکنیک های کلیدی در نگهداری و تعمیرات پیش بینانه

نگهداری و تعمیرات پیش بینانه یک رویکرد دگرگون کننده برای مدیریت دارایی ها در صنعت دریایی محسوب می شود. با بهره گیری از بینش های مبتنی بر داده، نگهداری و تعمیرات پیش بینانه می تواند وضعیت تجهیزات و مشکلات آن ها را تشخیص دهد و همچنین خرابی های احتمالی آینده را پیش بینی^{۱۴} کند تا در نهایت به افزایش طول عمر تجهیزات کمک کند [۳۴، ۳۵]. در این زمینه، تکنیک های مختلفی در ادبیات نگهداری و تعمیرات پیش بینانه یافت می شوند که هر یک نقاط قوت منحصر به فردی را به همراه دارند و به چالش ها و نیازهای متفاوتی پاسخ می دهند. این تکنیک ها عبارتند از:


عمر مفید باقی مانده (RUL): عمر مفید باقیمانده به عنوان زمان باقی مانده ای تعریف می شود که یک دارایی می تواند به طور کارآمد عمل کند، قبل از اینکه به پایان عمر مفید (EOL) خود برسد [۳۶]. اگر t_e زمان پیش بینی شده EOL باشد و t زمان فعلی باشد، عمر مفید باقی مانده (RUL) را می توان به صورت زیر بیان کرد:

¹⁴ Prognose

۳-۱- سیستم‌های پیش‌ران و فرعی

تولید برق برای عملکرد، کارایی و ردپای زیست‌محیطی یک کشتی حیاتی است، از این‌رو نگهداری از آن اهمیت ویژه‌ای دارد. از قرن بیستم، موتورهای احتراق داخلی (ICEs) و به‌ویژه موتورهای دیزل دریایی (DEs)، به دلیل کارایی عملیاتی و اقتصادی بالا، فناوری‌های اصلی برای تولید برق بوده‌اند. با این حال، از آنجایی که موتورهای دیزل دلیل انتشار بالای اکسیدهای نیتروژن (NOx) هستند، شرکت‌های دریایی برای همسویی با استراتژی کاهش گازهای گلخانه‌ای که توسط سازمان بین‌المللی دریانوردی (IMO) اجرا می‌شود، سیستم‌های جایگزین را بررسی کرده‌اند [۳۹-۴۱].

خرابی سیستم‌های پیش‌ران و فرعی می‌تواند تأثیر قابل‌توجهی بر ایمنی، پایداری زیست‌محیطی و عملکرد اقتصادی داشته باشد. به‌طور کلی، عوامل مسئول خرابی در سیستم‌های پیش‌ران را می‌توان به دو دسته اصلی تقسیم کرد: عوامل غیرقابل پیش‌بینی و عوامل قابل پیش‌بینی. عوامل غیرقابل پیش‌بینی شامل شرایط سخت محیطی، خطاهای عملیاتی، یا حتی خوردگی اجزای کلیدی نام برد. عوامل قابل پیش‌بینی شامل عوامل تنشی هستند که می‌توانند از مراحل طراحی یا ساخت قطعات (مانند نقص مواد و غیره) یا به دلیل خستگی تجهیزات در طول زمان و منجر به تخریب تدریجی شوند [۴۲]. خرابی‌های رایج در سیستم پیش‌ران با موارد زیر مرتبط هستند: (الف) سیستم سوخت (مانند گرفتگی فیلترها، خرابی تزریق و غیره)؛ (ب) روانکاری ناکافی سیستم با روغن؛ (ج) سیستم خنک‌کننده؛ و (د) سیستم ورودی و خروجی موتور (مانند گرفتگی در سوپاپ‌ها، فیلترهای هوا و غیره) [۴۲-۴۹]. عوامل کلیدی که به خرابی‌های مرتبط با پیش‌ران کمک می‌کنند، در شکل ۳ نشان داده شده‌اند.



شکل ۳. عوامل کلیدی موثر در خرابی‌های مرتبط با پیش‌ران

در راستای ارزیابی وضعیت سیستم‌های پیش‌ران دریایی، الگوریتم‌های مختلف نگهداری و تعمیرات پیش‌بینانه مبتنی بر یادگیری ماشین در منابع علمی موجود هستند. مدل‌های رگرسیون خطی (LR) باهدف تخمین نقاط داده از طریق یک ابرصفحه^{۱۵} مورد استفاده قرار گرفته‌اند.

به‌عنوان مثال، چلیوتیس و همکاران با پیش‌بینی دمای گاز خروجی (EGT) یک موتور دو زمانه ۵ سیلندر در یک کشتی باری Handymax با استفاده از مدل رگرسیون چندجمله‌ای رنج و تشخیص عروق با نمودارهای کنترل میانگین متحرک وزن‌دار نمایی به پایش وضعیت آن پرداختند [۵۰]. به همین ترتیب، کانگ و همکاران با استفاده از تحلیل مؤلفه‌های اصلی (PCA) برای به‌حداقل‌رساندن ابعاد داده و یک مدل رگرسیون حداقل قدرمطلق باقیمانده (LAR) برای پیش‌بینی بار موتور وضعیت یک موتور دوگانه‌سوز (دیزل-گاز طبیعی) را پایش کردند [۵۱].

با این حال، درحالی که مدل‌های خطی نسبتاً آسان برای پیاده‌سازی هستند و در مقایسه با تنظیمات پیچیده یادگیری عمیق به داده‌های کمتری نیاز دارند، اما فاقد توانایی لازم برای شناسایی روابط پیچیده و غیرخطی هستند که به طور معمول در داده‌های ماشین‌آلات یافت

¹⁵ Hyperplane

می‌شود. علاوه بر این، این مدل‌ها نسبت به داده‌های پرت^{۱۶} حساس هستند که می‌تواند منجر به پیش‌بینی‌های منحرف شده و در نتیجه کاهش قابلیت اطمینان کلی آنها در سناریوهای واقعی شود [۵۲-۵۴].

در حوزه ارزیابی سامانه‌های پیش‌رانه، روش‌های هسته^{۱۷} مانند ماشین بردار پشتیبان^{۱۸} نیز در ادبیات پژوهشی مورد توجه قرار گرفته‌اند. ماشین بردار پشتیبان (SVM) یک رویکرد یادگیری نظارت شده است که هدف آن شناسایی یک ابرصفحه است که دو کلاس را به صورت بهینه از یکدیگر تفکیک کند. به طور مشابه، رگرسیون بردار پشتیبان^{۱۹} کاربرد ماشین بردار پشتیبان (SVM) را برای وظایف رگرسیون گسترش می‌دهد [۵۵]. کورادو و همکاران، کاربرد رگرسیون بردار پشتیبان (SVR) را برای پیش‌بینی تخریب توربین گاز در یک سامانه پیش‌رانه ترکیبی دیزل-الکترونیک و گاز شبیه‌سازی شده مورد بررسی قرار دادند [۵۶، ۵۷]. علاوه بر این، وورکاپیچ و همکاران، توابع هسته چندجمله‌ای و پیرسون VII را در یک مدل رگرسیون بردار پشتیبان (SVR) برای پیش‌عملکرد یک موتور دیزل (DE) دو زمانه در یک کشتی حامل گاز مایع به کار گرفتند [۵۸]. با این حال، با وجود مزایایشان، روش‌های هسته مانند رگرسیون بردار پشتیبان (SVR) به دلیل پیچیدگی محاسباتی بالا، می‌توانند منجر به افزایش زمان آموزش و استنتاج شوند. علاوه بر این، با افزایش حجم مجموعه داده، ممکن است مسائل مقیاس‌پذیری نیز ایجاد شود، درحالی‌که این روش‌ها به توابع هسته نیز حساس هستند و انتخاب نامناسب می‌تواند بر دقت و قابلیت تعمیم‌پذیری آنها تأثیر منفی بگذارد [۵۹، ۶۰].

شبکه‌های عصبی مصنوعی^{۲۰} (ANNs) از ساختار و عملکرد شبکه‌های عصبی بیولوژیکی الهام گرفته‌اند. این شبکه‌ها از سه لایه متمایز تشکیل شده‌اند: (الف) لایه ورودی که داده‌های ورودی به شبکه را پردازش می‌کند؛ (ب) لایه‌های پنهان که محاسبات پیچیده‌ای را انجام می‌دهند؛ و (ج) لایه خروجی که نتایج نهایی را تولید

می‌کند [۵۵]. معماری‌های مختلف شبکه‌های عصبی مصنوعی برای سناریوهای نگهداری و تعمیرات پیش‌بینانه دریایی به کار گرفته شده‌اند. به عنوان مثال، لورنسن و همکاران، کاربرد یک شبکه پرسپترون چندلایه با ساختار^{۲۱} (FNN) ساده را برای ارزیابی وضعیت زوال یک سامانه پیش‌رانه CODLAG بررسی کردند. نویسندگان شبیه‌سازی‌های گسترده‌ای را برای تعیین پارامترهای بهینه مدل (مانند توابع فعال‌سازی، حل‌کننده‌ها، ساختار شبکه و غیره) به منظور بهبود عملکرد پیش‌بینی انجام دادند. نتایج نشان داد که استفاده از حل‌کننده Broyden-Fletcher-Goldfarb-Shanno و تابع فعال‌سازی تانژانت هایپربولیک منجر به بهبود عملکرد شد [۶۱]. علاوه بر این، گوئررو و همکاران ناهنجاری‌ها را در یک موتور دیزل دو زمانه با سرعت پایین، بر اساس بارهای مختلف، مورد مطالعه قرار دادند. برخلاف کارهای پیشین، نویسندگان از تحلیل هارمونیک و حساسیت برای مرتبط ساختن دینامیک احتراق سیلندر با ضرایب فوریه به عنوان گام اول استفاده کردند تا سپس یک شبکه پرسپترون چندلایه با ساختار را برای تخمین توان متوسط موتور دیزل آموزش دهند [۶۲]. شبکه‌های عصبی مصنوعی می‌توانند برای کاربردهای مختلف نگهداری و تعمیرات پیش‌بینانه مناسب باشند و امکان مدل‌سازی روابط پیچیده داده‌ای و همچنین پردازش انواع مختلف داده‌ها (مانند سری‌های زمانی، تصاویر و غیره) را فراهم می‌کنند. با این حال، معایب آنها از جمله نیاز به حجم زیادی از داده‌های تاریخی برچسب‌گذاری شده برای آموزش آنها و همچنین خطر بیش‌برازش در غیاب رگولاریزاسیون مناسب، نیز باید در نظر گرفته شود، [۶۳، ۶۴].

شبکه‌های عصبی بازگشتی (RNNs)^{۲۲} به طور گسترده برای مدیریت داده‌های ترتیبی به کار رفته‌اند، اما توانایی یادگیری الگوها در داده‌های ورودی با گام‌های زمانی بزرگ را ندارند. برای رفع این چالش، شبکه‌های حافظه کوتاه‌مدت بلندمدت (LSTM)^{۲۳} معرفی شده‌اند که با ترکیب مکانیزم‌های گیتینگ در ساختار شبکه‌های عصبی بازگشتی، به طور مؤثر مسئله وابستگی‌های

¹⁶ Outliers

¹⁷ Kernel methods

¹⁸ Support Vector Machine - SVM

¹⁹ Support Vector Regression - SVR

²⁰ Artificial Neural Networks - ANNs

²¹ Feed-Forward Network (FNN)

²² Recurrent Neural Networks - RNNs

²³ Long Short-Term Memory - LSTM

بلندمدت را مدیریت می‌کنند و آنها را برای کاربردهای نگهداری و تعمیرات پیش‌بینانه بسیار مناسب می‌سازند [۶۵]. هان و همکاران با موفقیت یک شبکه شبکه‌های حافظه کوتاه‌مدت بلندمدت را برای ارزیابی وضعیت موتور دیزل با تخمین عمر باقیمانده مفید (RUL) آن به کار گرفتند. نویسندگان مدل را در سناریوهای نزدیک به دنیای واقعی در برابر سایر جایگزین‌های مبتنی بر یادگیری عمیق (DL)، نه تنها با استفاده از پروفایل‌های بار مختلف، بلکه با افزودن نویز گوسی سفید به داده‌های ورودی، ارزیابی کردند [۶۶]. علاوه بر این، گریبستاد و همکاران، کاربرد یادگیری انتقالی را برای رفع مسائل کمبود داده، با تمرکز بر پیش‌بینی عمر مفید باقی‌مانده (RUL) کمپرسورهای هوا، بررسی کردند. این پژوهش از یک مدل شبکه‌های حافظه کوتاه‌مدت بلندمدت تنظیم شده با بهینه‌سازی ازدحام ذرات^{۲۴} (PSO) بر روی یک مجموعه داده عمومی کمپرسور استفاده کرد. متعاقباً، اجزای مدل از پیش آموزش‌دیده منتقل شده و با یک مجموعه داده کمپرسور هوای دریایی تطبیق داده شدند. نتایج تجربی نشان داد که این رویکرد یادگیری انتقالی به طور قابل توجهی از مدل‌های پایه بهتر عمل کرده و اثربخشی این رویکرد را در سناریوهایی با داده‌های محدود تا خرابی برجسته می‌کند [۶۷].

اگرچه شبکه‌های حافظه کوتاه‌مدت بلندمدت برای کاربردهای نگهداری و تعمیرات پیش‌بینانه که شامل داده‌های حسگر ترتیبی می‌شوند، بسیار مناسب هستند و می‌توانند وابستگی‌های بلندمدت را بدون افت عملکرد ثبت کنند، اما برخی معایب آن‌ها نیز باید مورد توجه قرار گیرند. به طور دقیق‌تر، شبکه‌های حافظه کوتاه‌مدت بلندمدت (LSTM): (الف) منابع محاسباتی فشرده‌ای دارند (یعنی پیچیدگی بالای آن‌ها می‌تواند به زمان‌های آموزش طولانی‌تر منجر شود)، (ب) به عنوان پیکربندی‌ای از شبکه‌های عصبی مصنوعی (ANNs)، مستعد بیش‌برازش^{۲۵} هستند، به خصوص در غیاب رگولاریزاسیون کافی، (ج) عملکرد آن‌ها می‌تواند به طور قابل توجهی تحت تأثیر تنظیم ضعیف پارامترهای بیشینه قرار گیرد [۶۸، ۶۶].

شبکه‌های عصبی پیچشی^{۲۶} (CNNs) قادر به شناسایی و استخراج ویژگی‌ها از طریق عملیات پیچشی هستند و در ابتدا عمدتاً برای وظایف بینایی کامپیوتر به کار می‌رفتند [۵۵، ۶۹، ۷۰]. در حوزه نگهداری و تعمیرات پیش‌بینانه، شبکه‌های عصبی پیچشی به عنوان بخشی از معماری‌های ترکیبی برای ثبت مؤثر وابستگی‌های زمانی مورد استفاده قرار گرفته‌اند. به عنوان مثال، جی و همکاران، یک شبکه ترکیبی متشکل از یک شبکه‌های عصبی پیچشی، یک شبکه‌های حافظه کوتاه‌مدت بلندمدت دوجهته (BiLSTM) و یک لایه توجه را برای ارزیابی وضعیت موتور دیزل (DE) دوگانه‌سوز یک کشتی حمل‌کننده گاز طبیعی مایع بر اساس مقادیر دمای گاز خروجی (EGT) توسعه دادند. مدل پیشنهادی از نقاط قوت (۱) شبکه‌های عصبی پیچشی برای استخراج مؤثر ویژگی‌ها از داده‌های ورودی، (۲) شبکه‌های حافظه کوتاه‌مدت بلندمدت دوجهته (BiLSTM) برای ثبت وابستگی‌های زمانی، (۳) مکانیزم توجه امکان تخصیص پویا و مبتنی بر اهمیت به وزن‌دهی ویژگی‌های ورودی را فراهم می‌سازد. این شبکه در برابر سایر شبکه‌های پایه و ترکیبی ارزیابی شد و از نظر دقت پیش‌بینی عملکرد بالاتری را نشان داد [۷۱]. به طور مشابه، لی و همکارانش کاهش عملکرد تزیق سوخت را بر اساس داده‌های حاصل از یک موتور ۴ زمانه ۹ سیلندر با سرعت متوسط دوگانه‌سوز بررسی کردند و یک شبکه CNN-GRU^{۲۷}-Convolutional Block Attention Module را برای پیش‌بینی عمر مفید باقی‌مانده موتور معرفی کردند [۷۲]. در همین راستا، لیو و همکاران نیز یک مدل Deep CNN-Bidirectional-GRU را برای پیش‌بینی روندهای EGT یک سیستم پیش‌ران هیبریدی الکتریکی دوگانه‌سوز توسعه دادند [۷۳]. پژوهش‌ها همچنین به حداقل رساندن نیازهای محاسباتی برای آموزش مدل روی سیستم‌های داخلی کشتی را نیز بررسی کرده‌اند. به عنوان مثال، کالافاتلیس و همکاران، تکنیک‌های بهینه‌سازی مختلف را بر روی مدل CNN+AE برای پیش‌بینی عمر مفید باقی‌مانده یک پاک‌کننده سوخت سنگین^{۲۸} در یک کشتی باری فله‌بر

²⁶ Convolutional Neural Networks- CNNs

²⁷ Gated Recurrent Unit

²⁸ HFO purifier

²⁴ Particle Swarm Optimization - PSO

²⁵ Overfitting

کرد که عمر باقیمانده مفید (RUL) ظرفیت سلول را پیش‌بینی می‌کند [۷۸]. درحالی‌که ماشین بردار مرتبط در توانایی مدل‌سازی الگوهای غیرخطی شباهت‌هایی با رگرسیون بردار پشتیبان دارند، اما محدودیت‌هایی نیز از خود بروز می‌دهند که مانع از پذیرش گسترده آن‌ها می‌شود. به طور خاص، ماشین‌های بردار مرتبط می‌توانند مصرف منابع محاسباتی بالایی داشته باشند، به‌ویژه زمانی که برای مجموعه داده‌های بزرگ به کار می‌روند و به‌شدت به پیش‌پردازش داده‌ها وابسته هستند، زیرا مقیاس‌بندی نامناسب می‌تواند به مسائل همگرایی منجر شود [۷۹، ۸۰].

علاوه بر این، لیو و همکاران، یک چارچوب ترکیبی برای ارزیابی وضعیت باتری‌های دریایی توسعه دادند. این چارچوب الگوریتم خوشه‌بندی فضایی مبتنی بر چگالی کاربردها با نویز (DBSCAN) ^{۳۲} را برای تشخیص عیوب و یک ترانسفورماتور را برای پیش‌بینی ناهنجاری‌های ولتاژ یکپارچه کرد. ترانسفورماتورها شبکه‌های عصبی هستند که بر اساس مکانیزم‌های خودتوجهی قادر به پردازش نمایش‌های چندسطحی در داده‌های ترتیبی هستند [۸۱، ۸۲]. این چارچوب بر روی یک کشتی بزرگ مسافربری الکتریکی اعتبارسنجی شد و توانایی آن در غلبه بر تأخیرات موجود در سامانه مدیریت باتری سنتی را به نمایش گذاشت [۸۳].

ترانسفورماتورها مزایای قابل‌توجهی برای کاربردهای نگهداری و تعمیرات پیش‌بینانه ارائه می‌دهند و امکان پردازش توالی‌های طولانی داده را بدون محدودیت‌های حافظه‌ای موجود در سایر شبکه‌ها (مانند شبکه‌های عصبی بازگشتی (RNNs)) فراهم می‌کنند. با این حال، محدودیت‌های آن‌ها نیز باید برای توسعه نگهداری و تعمیرات پیش‌بینانه در نظر گرفته شود، از جمله موارد زیر: (الف) مصرف قابل‌توجه منابع محاسباتی و حافظه، (ب) نیاز به داده‌های گسترده برای تعمیم مؤثر و جلوگیری از بیش‌برازش و (ج) تنظیم پارامترهای بیشینه که می‌تواند چالش‌برانگیز و زمان‌بر باشد [۸۴، ۸۵].

برخلاف رویکردهای یادگیری ماشین کلاسیک که پیش‌تر ذکر شد، کاراندیکار و همکاران، یک طرح مبتنی بر یادگیری فدرال را پیشنهاد کردند که فناوری بلاک‌چین

ارزیابی کردند. این مطالعه تکنیک‌هایی مانند توقف زودهنگام و هرس مدل، از جمله ثابت، چندجمله‌ای کاهشی و رگولاریزاسیون‌های L1 و L2 را بررسی کرد. در میان این موارد، استفاده از توقف زودهنگام و رگولاریزاسیون L2 مؤثرترین عملکرد را نشان داد که دقت پیش‌بینی، پیچیدگی مدل و زمان آموزش را به تعادل می‌رساند [۷۴]. شبکه‌های عصبی پیچشی می‌توانند هم برای وظایف نگهداری و تعمیرات پیش‌بینانه مبتنی بر سری‌های زمانی (مانند شبکه‌های عصبی پیچشی یک‌بعدی، پیکربندی‌های ترکیبی) و هم برای وظایف نگهداری و تعمیرات پیش‌بینانه مبتنی بر تصویر مفید باشند. به طور خاص، شبکه‌های عصبی پیچشی توانایی شناسایی خودکار الگوهای مکانی یا زمانی را از داده‌های ورودی ارائه می‌دهند. با این حال، با وجود مزایایشان، آن‌ها نیازمند: (۱) حجم زیادی از داده‌ها برای تعمیم مؤثر، (۲) منابع محاسباتی بالا برای آموزش و استنتاج (که استقرار آن‌ها در سیستم‌های لبه‌ای در سناریوهای یادگیری فدرال را دشوار می‌کند) و (۳) پیکربندی دقیق پارامترهای بیشینه به دلیل پیچیدگی معماری‌شان، به ویژه در موارد مدل‌های ترکیبی، هستند [۷۵-۷۷].

۲-۳- رویکردهای نوین نگهداری و تعمیرات پیش‌بینانه در سامانه‌های الکتریکی کشتی‌ها

مسائل متداول در سامانه‌های الکتریکی کشتی‌ها شامل، اما نه محدود به: (۱) آسیب‌دیدگی کابل‌ها و سیم‌کشی‌ها، (۲) نارسایی باتری‌ها، (۳) اختلال در عملکرد ژنراتورها، آلترناتورها و ترانسفورماتورها و (۴) خرابی سامانه‌های روشنایی است. در راستای رسیدگی به این چالش‌ها و بهینه‌سازی عملکرد، پژوهش‌های متعددی به بررسی یکپارچه‌سازی سامانه‌های نگهداری و تعمیرات پیش‌بینانه ^{۲۹} پرداخته‌اند.

به‌عنوان مثال، تانگ و همکاران، حالات کاهش سلول‌های یون لیتیوم مورد استفاده در شناورهای هیبریدی را مورد کاوش قرار دادند. به تفصیل، پژوهش آن‌ها یک رویکرد بیزی ^{۳۰} برای ماشین بردار پشتیبان (SVM) با نام ماشین بردار مرتبط (RVM) ^{۳۱} را معرفی

²⁹ Predictive Maintenance - PdM

³⁰ Bayesian approach

³¹ Relevance Vector Machine - RVM

³² Density-Based Spatial Clustering of Applications with Noise - DBSCAN

را برای افزایش بیشتر امنیت و حریم خصوصی یکپارچه می‌کند. به طور دقیق، این چارچوب قراردادهای هوشمند را معرفی می‌کند که جایگزین سرور سنتی یادگیری فدرال شده و پارامترهای مختلف مدل را بر روی بلاکچین ذخیره و مدیریت می‌کنند. نویسندگان با موفقیت این چارچوب را در یک مورد کاربردی باتری دریایی، با استفاده از یک مدل رگرسیون خطی (LR) برای پیش‌بینی وضعیت سلامت (SOH)^{۳۳} آن‌ها به صورت غیرمتمرکز ارزیابی کردند [۸۶]. درحالی‌که چارچوب پیشنهادی نویدبخش پیشرفت در حریم خصوصی و عدم تمرکز است، اما به آزمایش‌های بیشتری با مدل‌های یادگیری عمیق پیچیده‌تر نیاز دارد تا مقیاس‌پذیری و اثربخشی آن در وظایف نگهداری و تعمیرات پیش‌بینانه و همچنین الزامات تأخیر مورد بررسی قرار گیرد، زیرا مکانیزم‌های اجماع می‌توانند بر زمان آموزش دستگاه کاربر یادگیری فدرال تأثیر بگذارند. علاوه بر این، یکپارچه‌سازی یادگیری فدرال و بلاکچین ممکن است پیچیدگی معماری و پیاده‌سازی آن را افزایش دهد، زیرا هر دو فناوری نیازمند منابع محاسباتی قابل‌توجهی هستند.

۳-۳- رویکردهای نوین مدل‌سازی و پیش‌بینی خرابی‌های بدنه و سازه کشتی

ایمنی عملیاتی و عمر باقیمانده مفید (RUL) یک شناور، به طور قابل‌توجهی تحت تأثیر یکپارچگی سازه‌ای بدنه آن قرار دارد. بر اساس مقررات تعیین شده توسط انجمن بین‌المللی مؤسسات رده‌بندی (IACS)^{۳۴}، بازرسی‌های بدنه هم در طول فاز ساخت کشتی و هم در طول فاز عملیاتی خدماتی آن انجام می‌شود. به طور خاص، در فاز ساخت، بازرسی‌های دستی برای تأیید اینکه مواد و فرایندهای ساخت مطابق با مقررات و استانداردهای مربوطه انجام شده‌اند، صورت می‌گیرد. درحالی‌که بازرسی‌های عملیاتی یا بر اساس یک برنامه نگهداری واکنشی یا نگهداری پیشگیرانه در کشتی‌سازی‌ها انجام می‌شوند [۸۷-۸۹، ۱۳]. علاوه بر این، در طول

عملیات یک شناور، خرابی‌ها در ساختار بدنه به دلایل زیر رخ می‌دهند:

خوردگی: خوردگی یک پدیده طبیعی و اجتناب‌ناپذیر است که در سطح بیرونی بدنه کشتی رخ می‌دهد. به طور خاص، در اثر تعامل طولانی‌مدت بدنه با محیط دریایی، واکنش‌های الکتروشیمیایی مختلف باعث اکسیدشدن مواد فلزی می‌شوند که منجر به حداقل رسیدن چگالی و انعطاف‌پذیری سازه می‌گردد [۸، ۸۷].

پوشش زیستی: پوشش زیستی یک مشکل رایج در سطوح زیر آب بدنه است که باعث تشکیل ساختارهای لجن‌مانند از ارگانسیم‌های دریایی (مانند جلبک‌ها و غیره) می‌شود. این پدیده تأثیر منفی بر راندمان عملکرد شناور یعنی افزایش پسا (drag) و افزایش مصرف سوخت دارد [۹۰-۹۲].

خستگی سازه‌ای: تغییر شکل‌های سازه‌ای بدنه کشتی، در اکثر موارد، ناشی از آسیب‌های تکراری تماسی است، مانند آنچه که توسط امواج، عملیات پهلویی، یا حتی از تنش بیش از حد ناشی از بارگذاری بیش از حد محموله ایجاد می‌شود [۸۷].

فرسودگی پوشش: لایه‌های پوششی بر روی سطوح بدنه اعمال می‌شوند تا از آن‌ها در برابر پوشش زیستی و خوردگی محافظت کنند. با این حال، لایه ضد رسوب به دلیل قرار گرفتن طولانی‌مدت در معرض محیط دریایی به تدریج فرسوده می‌شود که منجر به خطرات سازه‌ای می‌گردد [۸۷، ۹۳].

۳-۴- رویکردهای نوین در مدل‌سازی و پیش‌بینی خرابی‌های بدنه و سازه کشتی

برای مثال، جوآنگ و همکاران، یک مدل رگرسیون گام‌به‌گام را برای پیش‌بینی نرخ خوردگی لوله‌های فولاد کربن با در نظر گرفتن سرعت جریان و دما توسعه دادند [۹۵]. جی و همکاران نیز یک چارچوب جامع برای پیش‌بینی وضعیت پوشش‌های رزین اکریلیک در شرایط مختلف دریایی پیشنهاد کردند. این پژوهشگران شاخص‌های کلیدی پوشش (مانند براقیت، رنگ و غیره) را به عنوان ورودی به مدل‌های مختلف (رگرسیون خطی (LR))، الگوریتم ژنتیک^{۳۵} و مدل‌های تعمیم‌یافته

³³ State-of-Health - SOH

³⁴ International Association of Classification Societies - IACS

³⁵ Genetic algorithm

عملکرد فوق‌العاده‌ای را حتی در مجموعه داده‌های جدولی ساختاریافته کوچک (مانند داده‌های حسگر) از خود نشان دهند؛ با این حال، عملکرد آن‌ها ممکن است با افزایش داده‌های آموزشی به حد اشباع برسد، که این در تضاد با پیکربندی‌های پیچیده‌تر یادگیری عمیق است که می‌توانند دقت پیش‌بینی خود را بهبود بخشند [۱۰۰-۱۰۳].

علاوه بر این، پژوهشگران از شبکه‌های عصبی مصنوعی نیز برای مدل‌سازی الگوهای زوال یا تخریب^{۴۲} در ساختارهای بدنه استفاده کرده‌اند. برای مثال، سیپولینی و همکاران یک مدل رگرسیون چندکلاسی^{۴۳} مبتنی بر معماری ANN عمیق را برای تخمین وضعیت اجزای مختلف شناور، شامل بدنه، پروانه، توربین گاز و کمپرسور توربین گاز یک سیستم پیشران CODLAG پیشنهاد کردند [۱۰۴]. به طور مشابه، اسپاندونیدیس و همکاران یک مدل شبکه‌های عصبی مصنوعی را برای ارزیابی تخریب سیستم‌های پروانه-بدنه توسعه دادند. این رویکرد با استاندارد صنعتی ISO-19030 ارزیابی شد [۱۰۵] و با استفاده از داده‌های عملیاتی یک کشتی باری فله‌بر، نتایج تجربی عملکرد پیش‌بینی برتر شبکه‌های عصبی مصنوعی را به نمایش گذاشت [۱۰۶]. هر دو این مثال‌ها، اثربخشی شبکه‌های عصبی مصنوعی را در کاربردهای نگهداری و تعمیرات پیش‌بینانه نگهداری و تعمیرات پیش‌بینانه برای ساختارهای بدنه نشان می‌دهند. با این حال، استفاده از پیکربندی‌های مرتبط با شبکه‌های عصبی مصنوعی نیز چالش‌های متعددی را به همراه دارد، از جمله نیاز به مجموعه داده‌های برجسته‌گذاری شده گسترده برای تعمیم مؤثر و فقدان شفافیت در استدلال آن‌ها که به عنوان "جعبه سیاه" در نظر گرفته می‌شوند و اعتماد اپراتورها را بیشتر تحت تأثیر قرار می‌دهند [۱۰۷، ۱۰۸].

۴- چالش‌های کنونی و مسیرهای آینده در

سامانه‌های نگهداری و تعمیرات پیش‌بینانه دریایی

اگرچه سامانه‌های نگهداری و تعمیرات پیش‌بینانه پتانسیل بهبود کارایی عملیاتی و کاهش زمان

ایرینگ^{۳۶} وارد کرده و شاخص پیری را پیش‌بینی نمودند. طبق نتایج مطالعه، الگوریتم ژنتیک بالاترین عملکرد پیش‌بینی را به دست آورد [۹۶].

روش‌های مبتنی بر درخت^{۳۷} نیز در ارزیابی ساختارهای بدنه مورد استفاده قرار گرفته‌اند که درختان تصمیم (DT)^{۳۸} شناخته‌شده‌ترین رویکرد در این زمینه هستند. درختان تصمیم و روش‌های ترکیبی آن‌ها، مدل‌های یادگیری نظارت‌شده ناپارامتریک هستند که برای وظایف طبقه‌بندی و رگرسیون به کار می‌روند و به دلیل سادگی و قابلیت تفسیرپذیری مورد استقبال قرار گرفته‌اند [۹۷]. در همین راستا، جی و همکاران یک چارچوب ترکیبی برای پیش‌بینی وضعیت خوردگی سازه‌های فولادی بدنه معرفی کردند. رویکرد آن‌ها ابتدا از یک مدل شبکه‌های حافظه کوتاه‌مدت بلندمدت برای پیش‌بینی پارامترهای محیطی دینامیک دریایی در طول زمان استفاده می‌کند. خروجی‌های پیش‌بینی‌شده سپس با داده‌های عملیاتی سامانه شناسایی خودکار (AIS)^{۳۹} ترکیب می‌شوند تا بردارهای ورودی جدیدی تولید شوند. این بردارها سپس توسط یک مدل جنگل تصادفی (RF)^{۴۰} که با بهینه‌سازی ازدحام ذرات (PSO)^{۴۱} بهینه شده است، پردازش می‌شوند [۹۸]. مثال امیدوارکننده دیگری از استفاده از یک مدل نگهداری و تعمیرات پیش‌بینانه مبتنی بر درخت، کار پیرا و همکاران است. در این پژوهش، نویسندگان به پیش‌بینی خوردگی در سازه‌های بدنه شناور را با استفاده از یک مدل مبتنی بر درخت رگرسیون پرداختند، که متغیرهایی مانند ماده و سن عنصر، نوع مخزن و مایع ذخیره‌شده را در نظر می‌گرفت [۹۹]. اگرچه مدل‌های یادگیری فدرال از بیش‌برازش جلوگیری کرده و داده‌های نویزدار و پرت را بهتر از یک درخت واحد مدیریت می‌کنند و امتیازهای اهمیت ویژگی را ارائه می‌دهند، اما ممکن است قابلیت تفسیرپذیری کمتری نسبت به درختان تصمیم (DT) داشته باشند. علاوه بر این، یادگیری فدرال می‌تواند

³⁶ Generalized Eyrin models

³⁷ Tree-based methods

³⁸ Decision Trees - DT

³⁹ Automatic Identification System - AIS

⁴⁰ Random Forest - RF

⁴¹ Particle Swarm Optimization - PSO

⁴² Degradation patterns

⁴³ Multiclass regression model

از کارافتادگی شناور را دارند، اما همچنان چندین چالش باقی مانده که مانع از پذیرش آن‌ها در دنیای واقعی می‌شود.

به عنوان مثال، نبود استانداردهای یکنواخت و چارچوب‌های نظارتی برای فناوری‌های نگهداری و تعمیرات پیش‌بینانه، بر پذیرش آن‌ها تأثیر می‌گذارد. این شکاف ناشی از سرعت پایین پذیرش پیشرفت‌ها در صنعت است [۸، ۱۰]. برای رفع این موضوع، تلاش‌های آتی باید بر توسعه دستورالعمل‌ها و پروتکل‌های استاندارد شده بر اساس ابزارهای متن‌باز^{۴۴} متمرکز شود تا این شکاف برطرف شده و سازگاری و اعتماد به فناوری تضمین شود. نمونه‌هایی از این موارد شامل دستورالعمل‌های اخیراً تأسیس شده برای امنیت سایبری و کشتی‌های خودمختار توسط سازمان بین‌المللی دریانوردی (IMO) و سازمان طبقه‌بندی آمریکایی^{۴۵} است [۱۰۹، ۱۱۰].

یکی از الزامات برای آموزش سامانه‌های نگهداری و تعمیرات پیش‌بینانه دقیق، در دسترس بودن داده‌های عملیاتی باکیفیت بالا از شناورها است. در حال حاضر، مجموعه داده‌های "زمان تا خرابی" دریایی در دسترس عموم محدود هستند که منجر به اشباع پژوهش بر روی اجزای خاص شده، در حالی که سایر اجزا ناشناخته باقی مانده‌اند. برای حل این مشکل، پژوهش‌های آتی باید تکنیک‌های هوش مصنوعی مولد و دوقلوهای دیجیتال را برای تولید داده‌های مصنوعی و ترویج همکاری‌های دانشگاه-صنعت (مانند فضاهای داده و غیره) بررسی کنند. علاوه بر این، دقت پیش‌بینی نیز می‌تواند تحت تأثیر انحراف داده (تغییر ویژگی‌های آماری داده‌های ورودی) قرار گیرد که ناشی از ارتقای، اصلاحات، یا حتی زوال حسگرها در کشتی‌ها است [۱۰، ۱۱۱]. برای رفع این مشکل و اطمینان از قابلیت اطمینان سیستم، پژوهش‌ها باید بر روی تکنیک‌های پایش خودکار داده‌ها و استراتژی‌های آموزش مدل (مانند یادگیری آنلاین، آموزش افزایشی^{۴۶}، یادگیری فدرال، یادگیری انتقالی و غیره) انجام شود [۱۰، ۱۱۲، ۱۱۳].

خطرات قابل توجهی نیز از استفاده از کاربردهای نگهداری و تعمیرات پیش‌بینانه مبتنی بر یادگیری ماشین کلاسیک (CML) ناشی می‌شود. مدل‌های یادگیری ماشین کلاسیک تهدیدات امنیتی قابل توجه، ناکارآمدی‌های ارتباطی و چالش‌های مرتبط با مقیاس‌پذیری و محدودیت‌های محاسباتی داخلی کشتی را به همراه دارند [۱۱۴، ۱۱۵]. پژوهش‌های آتی باید بر توسعه راهکارهای نگهداری و تعمیرات پیش‌بینانه مبتنی بر الگوهای یادگیری ماشین غیرمتمرکز (مانند یادگیری فدرال (FL))، با بهره‌گیری از نقاط قوت یادگیری انتقالی، تمرکز کنند. به طور خاص، این امر می‌تواند شامل بررسی تکنیک‌های مختلف تجمیع یادگیری فدرال همراه با روش‌های رمزنگاری، استراتژی‌های انتخاب دستگاه کاربر برای بهینه‌سازی آموزش و طراحی راهکارهایی با در نظر گرفتن منابع محاسباتی موجود در کشتی‌ها باشد.

در نهایت، فقدان شفافیت در استدلال مدل، بر پذیرش در حوزه دریایی تأثیر بیشتری می‌گذارد. به طور دقیق، راه‌حل‌های یادگیری ماشین اغلب به عنوان "جعبه‌های سیاه" عمل می‌کنند و عدم اطمینان در میان اپراتورها ایجاد می‌کنند، زیرا آن‌ها قادر به تفسیر استدلال مدل نیستند [۱۱۶]. برای رفع این مشکل، چارچوب‌های نظارتی مانند قانون هوش مصنوعی اروپا^{۴۷} معرفی شده‌اند. پژوهش‌های آتی در مورد سامانه‌های نگهداری و تعمیرات پیش‌بینانه باید بر همسویی با مقررات هوش مصنوعی، یکپارچه‌سازی روش‌های توضیح‌پذیری مدل در سامانه‌های موجود و افزایش شفافیت در تصمیم‌گیری‌های آن‌ها تمرکز کنند [۱۱۷، ۱۱۸].

در جدول ۱ نشان داده شده است که اگرچه روش‌های کلاسیک و مدل‌های خطی از نظر هزینه محاسباتی به صرفه‌ترند، اما توان تبیین رفتارهای غیرخطی و پویا را ندارند و سقف دقت آن‌ها در سناریوهای دریایی محدود است. در مقابل، مدل‌های عمیق به‌ویژه LSTM و CNN بالاترین قدرت پیش‌بینی RUL را ارائه می‌دهند، اما هزینه محاسباتی و نیاز به داده خرابی واقعی، مانع استقرار مستقیم آن‌ها در دستگاه کاربر سامانه‌های دریایی است. در این میان، یادگیری انتقالی و یادگیری فدرال رویکردهای میانی واقع‌بینانه و با قابلیت به‌کارگیری عملی در صنعت

⁴⁴ Open source tools

⁴⁵ American Bureau of Shipping

⁴⁶ Incremental training

⁴⁷ European AI Act

محسوب می‌شوند که ضمن حفظ پذیرش‌پذیری عملیاتی، هستند.

قادر به کاهش نیاز به داده و افزایش امنیت داده‌ای

جدول ۱. مقایسه جامع روش‌های داده‌محور در نگهداری و تعمیرات پیش‌بینانه (PdM) دریایی از منظر عملکرد، هزینه و امنیت داده

امنیت / حریم خصوصی	هزینه محاسباتی	سطح دقت نسبی در دریایی	مزیت کلیدی	روش
کم (داده باید جابجا شود)	بسیار کم	پایین	سادگی، مناسب داده کم، قابل اعتماد	<i>LR / Ridge / LAR</i>
کم	کم	پایین تا متوسط	کاهش ابعاد مؤثر، مناسب قبل از مدل‌های دیگر	<i>PCA + Regression</i>
کم (داده باید متمرکز شود)	متوسط تا زیاد	متوسط	عملکرد خوب روی داده‌های متوسط	<i>SVM / SVR</i>
کم	متوسط	متوسط	تفسیرپذیر - مقاوم نسبت به نویز	<i>Random Forest / Decision Trees</i>
کم	متوسط	متوسط تا خوب	یادگیری روابط غیرخطی	<i>ANN / FNN</i>
کم	زیاد	بالا	بهترین عملکرد روی سنسورهای زمانی (RUL)	<i>LSTM / CNN</i>
کم	بسیار زیاد	بالا	عملکرد بهتر در موارد پیچیده	<i>PSO-tuned LSTM / hybrid DL</i>
متوسط	متوسط	متوسط تا بالا	حل کمبود داده‌های خرابی، استفاده مجدد از مدل‌های از پیش آموزش‌دیده	<i>Transfer Learning (TL)</i>
بسیار بالا (بهترین)	متوسط تا زیاد	اغلب خوب (مشروط)	عدم نیاز به انتقال داده، امنیت مناسب ناوگان	<i>Federated Learning (FL)</i>
کم	بسیار کم	پایین تا متوسط	مناسب تحلیل آماری نرخ خرابی	مدل‌های کلاسیک (<i>Weibull / Poisson</i>)

۵- نتیجه‌گیری

این بررسی، یک تحلیل دقیق از چشم‌انداز فعلی نگهداری و تعمیرات پیش‌بینانه را ارائه می‌دهد که شکل‌دهنده شیوه‌های نگهداری در صنعت دریایی است. مشارکت‌های کلیدی این پژوهش شامل تحلیل ادبیات رویکردهای نگهداری و تعمیرات پیش‌بینانه به‌کاررفته در سامانه‌های حیاتی مانند پیش‌ران، کمکی، الکتریکی، بدنه و اجزای سازه‌ای است. به طور دقیق، بر اساس تحلیل انجام شده در این کار، هیچ رویکرد واحدی نمی‌تواند به‌عنوان یک راه‌حل جامع عمل کند، بلکه هر سیستم نیازمند یک رویکرد سفارشی است که مزایا و محدودیت‌های منحصر به فرد هر مدل را در نظر می‌گیرد.

این پژوهش همچنین چالش‌های بحرانی که مانع از پذیرش نگهداری و تعمیرات پیش‌بینانه می‌شوند را شناسایی و مسیرهای بالقوه برای غلبه بر آن‌ها را مورد بحث قرار می‌دهد. به طور خاص، درحالی‌که مدل‌های یادگیری عمیق از نظر مقیاس‌پذیری و عملکرد پیش‌بینی از مدل‌های یادگیری ماشین سنتی بهتر عمل می‌کنند، اما برای آموزش مؤثر و جلوگیری از بیش‌برازش (انطباق

بیش از حد)^{۴۸}، به مجموعه داده‌های برجسته‌گذاری شده بزرگ و باکیفیت بالا نیاز دارند. یک محدودیت کنونی در حوزه نگهداری و تعمیرات پیش‌بینانه دریایی، کمبود مجموعه داده‌های "زمان تا خرابی" در دسترس عموم است که منجر به تمرکز پژوهش‌ها تنها بر روی اجزای خاص شده است. علاوه بر این، اکثر کارهای بررسی شده، بر به‌کارگیری یادگیری مبتنی بر یادگیری ماشین کلاسیک تمرکز دارند که خطرات قابل‌توجهی مانند نگرانی‌های مربوط به حریم خصوصی داده‌ها، آسیب‌پذیری‌های امنیتی و مسائل مقیاس‌پذیری را به همراه دارد. به همین دلیل، یادگیری فدرال و یادگیری انتقالی نیز در این کار به‌عنوان جایگزین‌های امیدوارکننده‌ای معرفی شده‌اند که می‌توانند برخی از این چالش‌ها را کاهش داده و پژوهش را به سمت غیرمتمرکزسازی سوق دهند. علاوه بر این، برای اطمینان از انطباق با مقررات نوظهور، فقدان شفافیت در تصمیم‌گیری‌ها نیز مورد بحث قرار می‌گیرد و یکپارچه‌سازی تکنیک‌های توضیح‌پذیری مدل در

⁴⁸ Overfitting

سامانه‌های نگهداری و تعمیرات پیش‌بینانه برای افزایش اعتماد در میان اپراتورها ضروری تلقی می‌شود. در نهایت این مرور نشان داد که اگرچه روش‌های کلاسیک آماری و یادگیری ماشین (نظیر (LR) و (SVM)) برای تحلیل‌های اولیه و سناریوهای با محدودیت داده، همچنان قابل اتکا و از نظر محاسباتی اقتصادی هستند، اما دقت پیش‌بینی و حساسیت آنها در محیط‌های عملیاتی متغیر شناورها محدود است و در مواجهه با افزایش ابعاد و پیچیدگی داده، ضعف مقیاس‌پذیری و حساسیت به انتخاب هسته مشاهده می‌شود. در مقابل، معماری‌های عمیق‌تر مانند شبکه‌های عصبی مصنوعی^{۴۹} (ANNs) و به‌ویژه شبکه‌های حافظه کوتاه‌مدت بلندمدت (LSTM) با قابلیت مدل‌سازی وابستگی‌های زمانی طولانی، در پیش‌بینی RUL موتورهای دریایی عملکرد برتر ارائه کرده‌اند و در آزمایش‌های نزدیک به دنیای واقعی برتری خود را نسبت به مدل‌های پایه نشان داده‌اند. با این حال، نیاز بسیار بالا به داده‌های برچسب‌خورده خرابی و ریسک بیش‌برازش بدون رگولایزاسیون مناسب، به‌همراه هزینه محاسباتی، استقرار مستقیم این مدل‌ها را در سناریوهای لبه یعنی روی خود شناور دشوار کرده است. بر همین بستر، رویکردهای نوین مانند یادگیری انتقالی و یادگیری فدرال، راه‌حل‌های واقع‌بینانه‌تری برای شرایط صنعت دریایی محسوب می‌شوند: انتقالی، اثربخشی خود را در شرایط فقدان داده‌های عمومی خرابی واقعی اثبات کرده است (کمبود دائمی داده تا خرابی واقعی در کشتی‌ها یک واقعیت صنعتی است) و فدرال، پتانسیل حل مسئله حفظ حریم خصوصی و عدم تمرکز داده را دارد. بنابراین مسیر پژوهشی آینده نباید صرفاً «قدرت مدل» را بزرگ‌تر کند، بلکه باید «اثربخشی‌پذیری صنعتی» را حداکثر کند. نگهداری و تعمیرات پیش‌بینانه اکنون از مرحله قابلیت‌سنجی علمی عبور کرده و به مرحله «امکان‌پذیری عملی با شروط» رسیده است. زمانی بیشترین ارزش شکل می‌گیرد که مدل‌های یادگیری عمیق، با معماری‌های سبک، یادگیری انتقالی و فدرال ادغام شوند و در قالب چرخه‌های واقعی کشتی قابل استقرار باشند. ایجاد داده‌های عمومی استاندارد خرابی و استانداردسازی

تجربی، پیش‌نیاز حیاتی گذار از وضعیت «موارد پژوهشی پراکنده» به «راه‌حل صنعتی پذیرفته‌شده» است.

فهرست اختصارات

AI	Artificial Intelligence	هوش مصنوعی
		سیستم
		شناسایی
AIS	Automatic Identification System	خودکار
		کشتی‌های
		فعال‌شده
CESs	Cyber-Enabled Ships	سایبری
		سیستم پیش‌رانه
		ترکیبی دیزل-
CODLAG	Combined Diesel-Electric and Gas	الکتریک و گاز
DE	Diesel Engine	موتور دیزل
DL	Deep Learning	یادگیری عمیق
DT	Decision Tree	درخت تصمیم
		دمای گاز
EGT	Exhaust Gas Temperature	خروجی
		سیستم
		ذخیره‌سازی
ESS	Energy Storage System	انرژی
		میانگین
		متحرک وزن‌دار
EWMA	Exponentially Weighted Moving Average	نمایی
FL	Federated Learning	یادگیری فدرال
FNN	Feed-Forward Network	شبکه پیش‌خور
		شناور تولید،
		ذخیره‌سازی و
FPSO	Floating Production Storage and Offloading	تخلیه شناور
GT	Gas Turbine	توربین گاز
		پیش‌رانه
		الکتریکی
HE	Hybrid Electric Propulsion	هیبریدی
HFO	Heavy Fuel Oil	سوخت سنگین

⁴⁹ Artificial Neural Networks - ANNs

			دریایی	سیستم
			یادگیری	گرمایش، تهویه
ML	Machine Learning		ماشین	و تهویه مطبوع
			فناوری	انجمن
OT	Operational Technology		عملیاتی	بین‌المللی
			تحلیل	مؤسسات
PCA	Principal Component Analysis		مؤلفه‌های اصلی	رده‌بندی
			نگهداری و	موتور احتراق
			تعمیرات	داخلی
PdM	Predictive Maintenance		پیش‌بینانه	سازمان
PF	Particle Filter		فیلتر ذرات	بین‌المللی
			نگهداری	دریانوردی
PM	Preventive Maintenance		پیشگیرانه	اینترنت اشیا
			بهینه‌سازی	کشتی‌ها
PSO	Particle Swarm Optimization		ازدحام ذرات	فناوری
RF	Random Forest		جنگل تصادفی	اطلاعات
			یادگیری	فیلتر کالمن
RL	Reinforcement Learning		تقویتی	حداقل
			نگهداری	قدرمطلق
RM	Reactive Maintenance		واکنشی	باقیمانده
			شبکه عصبی	لیتیوم-آهن-
RNN	Recurrent Neural Network		بازگشتی	فسفات
			عمر باقیمانده	گاز طبیعی
RUL	Remaining Useful Life		مفید	مایع‌شده
			مرکز کنترل	لیتیوم-نیکل-
SCC	Shore-based Control Center		مستقر در خشکی	منگنز-کبالت-اکسید
SOH	State-of-Health		وضعیت سلامت	رگرسیون خطی
			کنوانسیون	حافظه
			بین‌المللی	کوتاه‌مدت
SOLAS	International Convention for the Safety of Life at Sea		ایمنی جان اشخاص در دریا	بلندمدت
			یادگیری	لیتیوم-
TL	Transfer Learning		انتقالی	تیتانیوم-اکسید
TTF	Time to Failure		زمان تا خرابی	شبکه ارتباطی
TTR	Time to Repair		زمان تا تعمیر	دریایی
				نفت گازوئیل

- [12] Barata, J.; Soares, C.G.; Marseguerra, M.; Zio, E. Simulation modelling of repairable multi-component deteriorating systems for 'on condition' maintenance optimisation. *Reliab. Eng. Syst. Saf.* **2002**, *76*, 255–264.
- [13] Karatuglu, C.; Arslanoglu, Y.; Soares, C.G. Review of maintenance strategies for ship machinery systems. *J. Mar. Eng. Technol.* **2023**, *22*, 233–247.
- [14] International Maritime Organization (IMO). International Convention for the Safety of Life At Sea (SOLAS); IMO: London, UK, 2002.
- [15] IMO. Survey Guidelines Under the Harmonized System of Survey and Certification (HSSC), Resolution A.1120(30); IMO: London, UK, 2017.
- [15] Basri, E.I.; Razak, I.H.A.; Ab-Samat, H.; Kamaruddin, S. Preventive maintenance (PM) planning: A review. *J. Qual. Maint. Eng.* **2017**, *23*, 114–143.
- [16] Ahmad, R.; Kamaruddin, S. An overview of time-based and condition-based maintenance in industrial application. *Comput. Ind. Eng.* **2012**, *63*, 135–149.
- [17] Cvrk, S.; Ilijević, D. Application of diagnostics as a basis of condition based maintenance of the marine propulsion diesel engine. *Brodogr. Int. J. Nav. Archit. Ocean Eng. Res. Dev.* **2020**, *71*, 119–134.
- [18] Cui, Y.; Shi, J.; Wang, Z. Quantum assimilation-based state-of-health assessment and remaining useful life estimation for electronic systems. *IEEE Trans. Ind. Electron.* **2015**, *63*, 2379–2390.
- [19] Skordilis, E.; Moghaddass, R. A condition monitoring approach for real-time monitoring of degrading systems using Kalman filter and logistic regression. *Int. J. Prod. Res.* **2017**, *55*, 5579–5596.
- [20] Wang, J.; Yin, H. Failure rate prediction model of substation equipment based on Weibull distribution and time series analysis. *IEEE Access* **2019**, *7*, 85298–85309.
- [21] de la Pena Zarzuelo, I.; Soeane, M.J.F.; Bermudez, B.L. Industry 4.0 in the port and maritime industry: A literature review. *J. Ind. Inf. Integr.* **2020**, *20*, 100173.
- [22] Kavallieratos, G.; Diamantopoulou, V.; Katsikas, S.K. Shipping 4.0: Security requirements for the cybe enabled ship. *IEEE Trans. Ind. Inform.* **2020**, *16*, 6617–6625.
- [23] Gomez Ruiz, M.A.; de Almeida, I.M.; Perez Fernandez, R. Application of
- [1] Simion, D.; Postolache, F.; Fleacă, B.; Fleacă, E. AI-Driven Predictive Maintenance in Modern Maritime Transport-Enhancing Operational Efficiency and Reliability. *Appl. Sci.* **2024**, *14*, 9439.
- [2] Allianz Global Corporate & Specialty (AGCS). Safety and Shipping Review 2019: An Annual Review of Trends and Developments in Shipping Losses and Safety; AGCS: Munich, Germany, 2019.
- [3] Aiello, G.; Giallanza, A.; Mascarella, G. Towards Shipping 4.0. A preliminary gap analysis. *Procedia Manuf.* **2020**, *42*, 24–29.
- [4] Kalafatelis, A.; Nomikos, N.; Giannopoulos, A.; Trakadas, P. A Survey on Predictive Maintenance in the Maritime Industry Using Machine and Federated Learning. *TechRxiv* **2024**.
- [5] Wang, H.; Yan, R.; Au, M.H.; Wang, S.; Jin, Y.J. Federated learning for green shipping optimization and management. *Adv. Eng. Inform.* **2023**, *56*, 101994.
- [6] Zhang, Z.; Guan, C.; Chen, H.; Yang, X.; Gong, W.; Yang, A. Adaptive privacy-preserving federated learning for fault diagnosis in internet of ships. *IEEE Internet Things J.* **2021**, *9*, 6844–6854.
- [7] Xylouris, G.; Nomikos, N.; Kalafatelis, A.; Giannopoulos, A.; Spantideas, S.; Trakadas, P. Sailing into the future: Technologies, challenges, and opportunities for maritime communication networks in the 6G era. *Front. Commun. Netw.* **2024**, *5*, 1439529.
- [9] Ali, A.A.I.M.; Imran, M.M.H.; Jamaludin, S.; Ayob, A.F.M.; Russtam, M.I.; Suhrab, S.M.N.; Basri, S.B.H.; Mohamed, S.B. A review of predictive maintenance approaches for corrosion detection and maintenance of marine structures. *J. Sustain. Sci. Manag.* **2024**, *19*.
- [10] Zhang, P.; Gao, Z.; Cao, L.; Dong, F.; Zou, Y.; Wang, K.; Zhang, Y.; Sun, P. Marine systems and equipment prognostics and health management: A systematic review from health condition monitoring to maintenance strategy. *Machines* **2022**, *10*, 72.
- [11] Liang, Q.; Knutsen, K.E.; Vanem, E.; Asoy, V.; Zhang, H. A review of maritime equipment prognostics health management from a classification society perspective. *Ocean Eng.* **2024**, *301*, 117619.

- learning. In Proceedings of the 2021 IEEE/CIC International Conference on Communications in China (ICCCWorkshops), Xiamen, China, 28–30 July 2021; pp. 266–271.
- [33] Zhuang, F.; Qi, Z.; Duan, K.; Xi, D.; Zhu, Y.; Zhu, H.; Xiong, H.; He, Q. A comprehensive survey on transfer learning. *Proc. IEEE* **2020**, *109*, 43–76.
- [34] Es-Sakali, N.; Cherkaoui, M.; Mghazli, M.O.; Naimi, Z. Review of predictive maintenance algorithms applied to HVAC systems. *Energy Rep.* **2022**, *8*, 1003–1012.
- [35] Kalafatelis, A.S.; Nomikos, N.; Angelopoulos, A.; Trochoutsos, C.; Trakadas, P. An Effective Methodology for Imbalanced Data Handling in Predictive Maintenance for Offset Printing. In Proceedings of the International Conference on Mechatronics.
- [36] Okoh, C.; Roy, R.; Mehnen, J.; Redding, L. Overview of remaining useful life prediction techniques in through-life engineering services. *Procedia Cirp* **2014**, *16*, 158–163.
- [37] Galar, D.; Kumar, U.; Lee, J.; Zhao, W. Remaining useful life estimation using time trajectory tracking and support vector machines. In *Journal of Physics: Conference Series* 364; IOP Publishing: Bristol, UK, 2012; Volume 364, p. 012063.
- [38] Alhilman, J.; Atmaji, F.T.D.; Athari, N. Software application for maintenance system: A combination of maintenance methods in printing industry. In Proceedings of the 2017 IEEE 5th International Conference on Information and Communication Technology (ICoIC7), Melaka, Malaysia, 17–19 May 2017; pp. 1–6.
- [39] Inal, O.B.; Charpentier, J.F.; Deniz, C. Hybrid power and propulsion systems for ships: Current status and future challenges. *Renew. Sustain. Energy Rev.* **2022**, *156*, 111965.
- [40] Joung, T.H.; Kang, S.G.; Lee, J.K.; Ahn, J. The IMO initial strategy for reducing Greenhouse Gas (GHG) emissions, and its follow-up actions towards 2050. *J. Int. Marit. Safety, Environ. Aff. Shipp.* **2020**, *4*, 1–7.
- [41] Ni, P.; Wang, X.; Li, H. A review on regulations, current status, effects and reduction strategies of emissions for marine diesel engines. *Fuel* **2020**, *279*, 118477.
- Machine Learning Techniques to the Maritime Industry. *J. Mar. Sci. Eng.* **2023**, *11*, 1820.
- [24] Angelopoulos, A.; Giannopoulos, A.; Nomikos, N.; Kalafatelis, A.; Hatziefremidis, A.; Trakadas, P. Federated Learning-Aided Prognostics in the Shipping 4.0: Principles, Workflow, and Use Cases. *IEEE Access* **2024**, *12*, 6437–6454.
- [25] Achouch, M.; Dimitrova, M.; Ziane, K.; Sattarpanah Karganroudi, S.; Dhoub, R.; Ibrahim, H.; Adda, M. On predictive maintenance in industry 4.0: Overview, models, and challenges. *Appl. Sci.* **2022**, *12*, 8081.
- [26] Kalafatelis, A.S.; Trochoutsos, C.; Giannopoulos, A.E.; Angelopoulos, A.; Trakadas, P. A Stacking Ensemble Learning Model for Waste Prediction in Offset Printing. In Proceedings of the 2023 10th International Conference on Industrial Engineering and Applications, Rome, Italy, 9–11 January 2023; pp. 267–272.
- [27] Zheng, H.; Paiva, A.R.; Gurciullo, C.S. Advancing from predictive maintenance to intelligent maintenance with ai and iiot. *arXiv* **2020**, arXiv:2009.00351.
- [28] Durlik, I.; Miller, T.; Dorobczyński, L.; Kozłowska, P.; Kostecki, T. Revolutionizing marine traffic management: A comprehensive review of machine learning applications in complex maritime systems. *Appl. Sci.* **2023**, *13*, 8099.
- [29] Nomikos, N.; Giannopoulos, A.; Kalafatelis, A.; Ozduran, V.; Trakadas, P.; Karagiannidis, G.K. Improving connectivity in 6G maritime communication networks with UAV swarms. *IEEE Access* **2024**, *12*, 18739–18751.
- [30] Sarlas, A.; Kalafatelis, A.; Alexandridis, G.; Kourtis, M.A.; Trakadas, P. Exploring federated learning for speech-based parkinson's disease detection. In Proceedings of the 18th International Conference on Availability, Reliability and Security, Benevento, Italy, 29 August–1 September 2023; pp. 1–6.
- [31] Giannopoulos, A.; Gkonis, P.; Bithas, P.; Nomikos, N.; Kalafatelis, A.; Trakadas, P. Federated learning for maritime environments: Use cases, experimental results, and open issues. *J. Mar. Sci. Eng.* **2024**, *12*, 1034.
- [32] Han, C.; Yang, T. Privacy protection technology of maritime multi-agent communication based on part-federated

- [55] Hurtado, J.; Salvati, D.; Semola, R.; Bosio, M.; Lomonaco, V. Continual learning for predictive maintenance: Overview and challenges. *Intell. Syst. Appl.* **2023**, *19*, 200251.
- [56] Coraddu, A.; Oneto, L.; Ghio, A.; Savio, S.; Anguita, D.; Figari, M. Machine learning approaches for improving condition-based maintenance of naval propulsion plants. *Proc. Inst. Mech. Eng. Part M J. Eng. Marit. Environ.* **2016**, *230*, 136–153.
- [57] Coraddu, A.; Oneto, L.; Ghio, A.; Savio, S.; Figari, M.; Anguita, D. Machine learning for wear forecasting of naval assets for condition-based maintenance applications. In *Proceedings of the 2015 IEEE International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles (ESARS)*, Aachen, Germany, 3–5 March 2015; pp. 1–5.
- [58] Vorkapić, A.; Radonja, R.; Babić, K.; Martinčić-Ipšić, S. Machine learning methods in monitoring operating behaviour of marine two-stroke diesel engine. *Transport* **2020**, *35*, 474–485.
- [59] Wang, H.; Zhu, Z.; Shao, Y. Fast Support Vector Machine with Low-Computational Complexity for Large-Scale Classification. *IEEE Trans. Syst. Man Cybern. Syst.* **2024**, *54*, 4151–4163.
- [60] Wu, C.H.; Tzeng, G.H.; Lin, R.H. A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression. *Expert Syst. Appl.* **2009**, *36*, 4725–4735.
- [61] Lorencin, I.; Andrić, N.; Mrzljak, V.; Car, Z. Multilayer perceptron approach to condition-based maintenance of marine CODLAG propulsion system components. *Pomorstvo* **2019**, *33*, 181–190.
- [62] Guerrero, D.P.; Jimenez-Espadafor, F.J. Torsional system dynamics of low speed diesel engines based on instantaneous torque: Application to engine diagnosis. *Mech. Syst. Signal Process.* **2019**, *116*, 858–878.
- [63] Jabbar, H.; Khan, R.Z. Methods to avoid over-fitting and under-fitting in supervised machine learning (comparative study). *Comput. Sci. Commun. Instrum. Devices* **2015**, *70*, 978–981.
- [64] Agatonovic-Kustrin, S.; Beresford, R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *J. Pharm. Biomed. Anal.* **2000**, *22*, 717–727.
- [42] Vizentin, G.; Vukelic, G.; Murawski, L.; Recho, N.; Orovic, J. Marine propulsion system failures—A review. *J. Mar. Sci. Eng.* **2020**, *8*, 662.
- [43] Cai, C.; Weng, X.; Zhang, C. A novel approach for marine diesel engine fault diagnosis. *Clust. Comput.* **2017**, *20*, 1691–1702.
- [44] Wang, X.; Liu, C.; Bi, F.; Bi, X.; Shao, K. Fault diagnosis of diesel engine based on adaptive wavelet packets and EEMD-fractal dimension. *Mech. Syst. Signal Process.* **2013**, *41*, 581–597.
- [45] Wang, J.; Sun, X.; Zhang, C.; Ma, X. An integrated methodology for system-level early fault detection and isolation. *Expert Syst. Appl.* **2022**, *201*, 117080.
- [46] Xu, X.; Yan, X.; Sheng, C.; Yuan, C.; Xu, D.; Yang, J. A belief rule-based expert system for fault diagnosis of marine diesel engines. *IEEE Trans. Syst. Man Cybern. Syst.* **2017**, *50*, 656–672.
- [47] Velasco-Gallego, C.; Lazakis, I. RADIS: A real-time anomaly detection intelligent system for fault diagnosis of marine machinery. *Expert Syst. Appl.* **2022**, *204*, 117634.
- [48] Bai, H.; Zhan, X.; Yan, H.; Wen, L.; Jia, X. Combination of optimized variational mode decomposition and deep transfer learning: A better fault diagnosis approach for diesel engines. *Electronics* **2022**, *11*, 1969.
- [49] Lv, Y.; Yang, X.; Li, Y.; Liu, J.; Li, S. Fault detection and diagnosis of marine diesel engines: A systematic review. *Ocean Eng.* **2024**, *294*, 116798.
- [50] Cheliotis, M.; Lazakis, I.; Theotokatos, G. Machine learning and data-driven fault detection for ship systems operations. *Ocean Eng.* **2020**, *216*, 107968.
- [51] Kang, Y.J.; Noh, Y.; Jang, M.S.; Park, S.; Kim, J.T. Hierarchical level fault detection and diagnosis of ship engine systems. *Expert Syst. Appl.* **2023**, *213*, 118814.
- [52] Laake, P.; Benestad, H.B.; Olsen, B.R. *Research in Medical and Biological Sciences: From Planning and Preparation to Grant Application and Publication*; Academic Press: Cambridge, MA, USA, 2015.
- [53] Filzmoser, P.; Nordhausen, K. Robust linear regression for high-dimensional data: An overview. *Wiley Interdiscip. Rev. Comput. Stat.* **2021**, *13*, e1524.
- [54] Teng, J.; Yuan, Y. Inject Machine Learning into Significance Test for Misspecified Linear Models. *arXiv* **2020**, arXiv:2006.03167.

- M.; Farhan, L. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *J. Big Data* **2021**, *8*, 1-74.
- [76] Santos, C.F.G.D.; Papa, J.P. Avoiding overfitting: A survey on regularization methods for convolutional neural networks. *ACM Comput. Surv. CSUR* **2022**, *54*, 1-25.
- [77] Thanapol, P.; Lavangnananda, K.; Bouvry, P.; Pinel, F.; Leprevost, F. Reducing overfitting and improving generalization in training convolutional neural network (CNN) under limited sample sizes in image recognition. In Proceedings of the 2020-5th IEEE International Conference on Information Technology (InCIT), Chonburi, Thailand, 21-22 October 2020; pp. 300-305.
- [78] Tang, W.; Roman, D.; Dickie, R.; Robu, V.; Flynn, D. Prognostics and health management for the optimization of marine hybrid energy systems. *Energies* **2020**, *13*, 4676.
- [79] Schmolck, A.; Everson, R. Smooth relevance vector machine: A smoothness prior extension of the RVM. *Mach. Learn.* **2007**, *68*, 107-135.
- [80] Bishop, C.M.; Tipping, M. Variational relevance vector machines. *arXiv* **2013**, arXiv:1301.3838.
- [81] Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A.; Aidan, N.; Kaiser, L.; Polosukhin, I. Attention is all you need. In Proceedings of the 31st Annual Conference on Neural Information Processing Systems (NIPS): Advances in Neural Information Processing Systems, Long Beach, CA, USA, 4-9 December 2017; pp. 6000-6010.
- [82] Liu, Y.; Hu, T.; Zhang, H.; Wu, H.; Wang, S.; Ma, L.; Long, M. itransformer: Inverted transformers are effective for time series forecasting. *arXiv* **2023**, arXiv:2310.06625.
- [83] Liu, Y.; Jin, H.; Yang, X.; Tang, T.; Song, Q.; Chen, Y.; Liu, L.; Jiang, S. Early Fault Diagnosis and Prediction of Marine Large-Capacity Batteries Based on Real Data. *J. Mar. Sci. Eng.* **2024**, *12*, 2253.
- [84] Yang, X.; Yan, B.; Li, H.; Chen, Y. ReTransformer: ReRAM-based processing-in-memory architecture for transformer acceleration. In Proceedings of the 39th International Conference on Computer-Aided Design, Virtual, 2-5 November 2020; pp. 1-9.
- [85] Khan, S.; Naseer, M.; Hayat, M.; Zamir, S.W.; Khan, F.S.; Shah, M. Transformers
- [65] Yu, Y.; Si, X.; Hu, C.; Zhang, J. A review of recurrent neural networks: LSTM cells and network architectures. *Neural Comput.* **2019**, *31*, 1235-1270.
- [66] Han, P.; Ellefsen, A.L.; Li, G.; Asoy, V.; Zhang, H. Fault prognostics using LSTM networks: Application to marine diesel engine. *IEEE Sens. J.* **2021**, *21*, 25986-25994.
- [67] Gribbestad, M.; Hassan, M.U.; Hameed, I.A. Transfer learning for Prognostics and health Management (PHM) of marine Air Compressors. *J. Mar. Sci. Eng.* **2021**, *9*, 47.
- [68] Kang, J.; Park, J.; Choi, S.; Sim, J. Q-LATte: An Efficient and Versatile LSTM Model for Quantized Attention-Based Time Series Forecasting in Building Energy Applications. *IEEE Access* **2024**, *12*, 69325-69341.
- [69] Li, Z.; Liu, F.; Yang, W.; Peng, S.; Zhou, J. A survey of convolutional neural networks: Analysis, applications, and prospects. *IEEE Trans. Neural Networks Learn. Syst.* **2021**, *33*, 6999-7019.
- [70] O' Shea, K. An introduction to convolutional neural networks. *arXiv* **2015**, arXiv:1511.08458.
- [71] Ji, Z.; Gan, H.; Liu, B. A deep learning-based fault warning model for exhaust temperature prediction and fault warning of marine diesel engine. *J. Mar. Sci. Eng.* **2023**, *11*, 1509.
- [72] Li, X.; Cao, H.; Ma, Z. Research on Remaining Useful Life Prediction of Dual-fuel Main Engine Based on CBAM Attention Mechanism. In Proceedings of the 2023 3rd International Conference on Artificial Intelligence, Automation and Algorithms, Beijing, China, 21-23 July 2023; pp. 91-99.
- [73] Liu, B.; Gan, H.; Chen, D.; Shu, Z. Research on fault early warning of marine diesel engine based on CNN-BiGRU. *J. Mar. Sci. Eng.* **2022**, *11*, 56.
- [74] Kalafatelis, A.S.; Stamou, N.; Dailani, A.; Theodoridis, T.; Nomikos, N.; Giannopoulos, A.; Tsoulakos, N.; Alexandridis, G.; Trakadas, P. A Lightweight Predictive Maintenance Strategy for Marine HFO Purification Systems. In Proceedings of the 21st European Mediterranean Middle Eastern Conference on Information Systems (EMCIS), Athens, Greece, 2-3 September 2024.
- [75] Alzubaidi, L.; Zhang, J.; Humaidi, A.J.; Al-Dujaili, A.; Duan, Y.; Al-Shamma, O.; Santamaria, J.; Fadhel, M.A.; Al-Amidie,

- [98] Ji, H.; Wang, H.; Chen, Q.; Ma, X.; Cai, Y. Corrosion behavior prediction for hull steels under dynamic marine environments by jointly utilizing LSTM network and PSO-RF model. *Ocean Eng.* **2024**, *300*, 117371. [
- [99] Pereira, A.A.; Neves, A.C.; Ladeira, D.; Caprace, J.D. Corrosion prediction of FPSOs hull using machine learning. *Mar. Struct.* **2024**, *97*, 103652.
- [100] Belgiu, M.; Dragut, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* **2016**, *114*, 24–31.
- [101] Mao, Q.; Cao, Y. Can a Single Tree Outperform an Entire Forest? *arXiv* **2024**, arXiv:2411.17003.
- [102] Probst, P.; Boulesteix, A.L. To tune or not to tune the number of trees in random forest. *J. Mach. Learn. Res.* **2018**, *18*, 1–18.
- [103] Breiman, L. Random forests. *Mach. Learn.* **2001**, *45*, 5–32.
- [104] Cipollini, F.; Oneto, L.; Coraddu, A.; Murphy, A.J.; Anguita, D. Condition-based maintenance of naval propulsion systems with supervised data analysis. *Ocean Eng.* **2018**, *149*, 268–278.
- [105] ISO 19030; Ships and Marine Technology—Measurement of Changes in Hull and Propeller Performance. International Organization for Standardization: Geneva, Switzerland, 2016.
- [106] Spandonidis, C.; Paraskevopoulos, D. Evaluation of a Deep Learning-Based Index for Prognosis of a Vessel's Propeller-Hull Degradation. *Sensors* **2023**, *23*, 8956.
- [107] Zhang, Z.; Beck, M.W.; Winkler, D.A.; Huang, B.; Sibanda, W.; Goyal, H. Opening the black box of neural networks: Methods for interpreting neural network models in clinical applications. *Ann. Transl. Med.* **2018**, *6*, 216.
- [108] Lu, Y.; Shen, M.; Wang, H.; Wang, X.; van Rechem, C.; Fu, T.; Wei, W. Machine learning for synthetic data generation: A review. *arXiv* **2023**, arXiv:2302.04062.
- [109] International Maritime Organization (IMO). Guidelines on Maritime Cyber Risk Management; Resolution MSC-FAL. 1/Circ. 3; International Maritime Organization: London, UK, 2017.
- [110] IMO; MSC. Outcome of the Regulatory Scoping Exercise for the Use of Maritime Autonomous Surface Ships (MASS); IMO: London, UK, 2021.
- in vision: A survey. *ACM Comput. Surv. CSUR* **2022**, *54*, 1–41.
- [86] Karandika, N.; Knutsen, K.; Wang, S.; Lovoll, G. Federated Learning on Trusted Data for Distributed PHM Data Analysis. In Proceedings of the PHM Conference, Turin, Italy, 6–8 July 2022.
- [87] Lin, B.; Dong, X. Ship hull inspection: A survey. *Ocean Eng.* **2023**, *289*, 116281.
- [88] Wen, F.; Pray, J.; McSweeney, K.; Gu, H. Emerging inspection technologies—enabling remote surveys/inspections. In Proceedings of the Offshore Technology Conference, OTC, Houston, TX, USA, 6–9 May 2019; p. D011S002R003.
- [89] Melnyk, O.; Onyshchenko, S.; Onishchenko, O.; Shibaev, O.; Volyanskaya, Y. A Comprehensive Approach to Structural Integrity Analysis and Maintenance Strategy for Ship's Hull. *J. Marit. Res.* **2024**, *21*, 36–44.
- [90] Townsin, R. The ship hull fouling penalty. *Biofouling* **2003**, *19*, 9–15.
- [91] Moser, C.S.; Wier, T.P.; Grant, J.F.; First, M.R.; Tamburri, M.N.; Ruiz, G.M.; Miller, A.W.; Drake, L.A. Quantifying the total wetted surface area of the world fleet: A first step in determining the potential extent of ships' biofouling. *Biol. Invasions* **2016**, *18*, 265–277.
- [92] Valchev, I.; Coraddu, A.; Kalikatzarakis, M.; Geertsma, R.; Oneto, L. Numerical methods for monitoring and evaluating the biofouling state and effects on vessels' hull and propeller performance: A review. *Ocean Eng.* **2022**, *251*, 110883.
- [93] Davies, J.; Truong-Ba, H.; Cholette, M.E.; Will, G. Optimal inspections and maintenance planning for anti-corrosion coating failure on ships using non-homogeneous Poisson Processes. *Ocean Eng.* **2021**, *238*, 109695.
- [94] Chliveros, G.; Tzanetatos, I.; Kamzelis, K. MaVeCoDD dataset: Marine vessel hull corrosion in dry-dock images. *Mendeley Data* **2021**.
- [95] Jung, K.H.; Lee, J.H. Prediction of Corrosion Rate for Carbon Steel Using Regression Model with Commercial LPR Sensor Data. *Appl. Sci.* **2024**, *14*, 10836.
- [96] Ji, H.; Ma, X.; Cai, Y.; Jiao, S. Predictive mapping and analysis of aging severity for acrylic resin coatings in global marine environments. *J. Mater. Sci.* **2024**, *59*, 14790–14806.
- [97] Blockeel, H.; Devos, L.; Frenay, B.; Nanack, G.; Nijssen, S. Decision trees: From efficient prediction to responsible AI. *Front. Artif. Intell.* **2023**, *6*, 1124553.

- [111] Ackerman, S.; Raz, O.; Zalmanovici, M.; Zlotnick, A. Automatically detecting data drift in machine learning classifiers. *arXiv* **2021**, arXiv:2111.05672.
- [112] Velasco-Gallego, C.; Lazakis, I. Mar-RUL: A remaining useful life prediction approach for fault prognostics of marine machinery. *Appl. Ocean Res.* **2023**, *140*, 103735.
- [113] Kotsev, A.; Minghini, M.; Tomas, R.; Cetl, V.; Lutz, M. From spatial data infrastructures to data spaces—A technological perspective on the evolution of European SDIs. *ISPRS Int. J. Geo-Inf.* **2020**, *9*, 176.
- [114] Nguyen, D.C.; Ding, M.; Pathirana, P.N.; Seneviratne, A.; Li, J.; Poor, H.V. Federated learning for internet of things: A comprehensive survey. *IEEE Commun. Surv. Tutor.* **2021**, *23*, 1622-1658.
- [115] Bharati, S.; Mondal, M.R.H.; Podder, P.; Prasath, V.S. Federated learning: Applications, challenges and future directions. *Int. J. Hybrid Intell. Syst.* **2022**, *18*, 19-35.
- [116] Ribeiro, M.T.; Singh, S.; Guestrin, C. “Why should i trust you?” Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco, CA, USA, 13-17 August 2016; pp. 1135-1144.
- [117] Madiega, T. Artificial Intelligence Act; European Parliament (European Parliamentary Research Service): Brussels, Belgium, 2021.
- [118] Cummins, L.; Sommers, A.; Ramezani, S.B.; Mittal, S.; Jabour, J.; Seale, M.; Rahimi, S. Explainable predictive maintenance: A survey of current methods, challenges and opportunities. *IEEE Access* **2024**, *12*, 57574-57602.