

УДК 621.436:004.8

МОНИТОРИНГ СОСТОЯНИЯ И ПРОГНОЗИРОВАНИЕ ОСТАТОЧНОГО РЕСУРСА КОМПОНЕНТОВ ДВУХТАКТНЫХ СУДОВЫХ ДИЗЕЛЕЙ ПРИ ПОМОЩИ ГИБРИДНОЙ МОДЕЛИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Соболев Вячеслав Сергеевич¹, аспирант

e-mail: sobolslava02@gmail.com

Жуков Владимир Анатольевич¹, заведующий кафедрой «Судостроения и энергетических установок»

e-mail: zhukov_vla@mail.ru

¹ Государственный университет морского и речного флота имени адмирала С.О. Макарова, Санкт-Петербург, Россия

Аннотация. Рассмотрена гибридная система искусственного интеллекта для мониторинга состояния и прогнозирования остаточного ресурса двухтактных судовых дизелей. Система включает три ключевых модуля: обнаружение аномалий, контекстно-зависимую классификацию неисправностей с учётом режимов нагрузки и прогнозирование деградации. В работе представлен анализ доверительных интервалов и вероятностная калибровка, которые подтверждают надёжность модели. Рассмотрены ограничения, связанные с вычислительной сложностью и нелинейностью процессов деградации.

Ключевые слова: искусственный интеллект, обнаружение аномалий, прогнозирование остаточного ресурса, судовой дизель, гибридная система.

CONDITION MONITORING AND RESIDUAL LIFE FORECASTING OF TWO-STROKE MARINE DIESEL ENGINE COMPONENTS USING A HYBRID ARTIFICIAL INTELLIGENCE MODEL

Vyacheslav S. Sobolev¹, Doctoral Student

e-mail: sobolslava02@gmail.com

Vladimir A. Zhukov¹, Head of the Department of «Shipbuilding and Power Plants»

e-mail: zhukov_vla@mail.ru

¹ Admiral Makarov State University of Maritime and Inland Shipping, Saint Petersburg, Russia

Abstract. A hybrid artificial intelligence system for condition monitoring and residual life prediction of two-stroke marine diesel engines is considered. The system comprises three key modules: anomaly detection, context-sensitive fault classification based on load conditions, and degradation prediction. The paper presents confidence interval analysis and probabilistic calibration, which confirm the model's robustness. Limitations associated with computational complexity and the nonlinearity of degradation processes are discussed.

Keywords: artificial intelligence, anomaly detection, residual life prediction, marine diesel, hybrid system.

Введение

В настоящее время эксплуатация судовых двухтактных дизелей сопряжена с высокими рисками внезапных отказов, вызванных переменными нагрузками и сложными взаимодействиями между компонентами. Традиционные системы технического обслуживания судовых вспомогательных механизмов основаны на статических пороговых значениях или единичных моделях. Такие модели не берут в расчет режим работы двигателя, степень износа деталей и множество других. В следствии чего снижается точность диагностики. Для решения этой проблемы в данном исследовании предлагается гибридная система управления техническим обслуживанием по состоянию. Она состоит из трех ключевых компонентов: обнаружение неисправностей, диагностику и прогнозирование остаточного срока службы. Представленная система учитывает условия нагрузки на каждом этапе. Выходные данные одного модуля являются входными данными для следующего. Это подчеркивает важность согласованности процесса от сбора данных до этапа прогнозирования. Таким образом, объединение этих ключевых компонентов в единую систему подтверждает практическую применимость предложенной системы управления техническим обслуживанием и ремонтами для судовых двигателей.

Материалы и методы

Традиционные системы СВМ в значительной степени зависят от статических пороговых значений или приложений с одной моделью, обучаемых безоговорочно без учета контекста или нагрузки, и, таким образом, представленный подход направлен на улучшение этого путем внедрения гибридного конвейера консенсусного обнаружения аномалий (RUL), который объединяет изолирующую выборку, оценку выбросов на основе гистограммы (НВО) [1] и модели восстановления на основе автоэнкодера, которые работают в определенной системе голосования для присвоения оценки аномалий точке данных, при этом вклад каждой модели в обнаружение аномалий взвешивается с учетом входных характеристик датчика двигателя, подаваемых в алгоритмы, обеспечивая повышенную частоту обнаружения с уменьшением ложных срабатываний, вызванных изменением нагрузки, тем самым фиксируя отклонения, которые являются репрезентативный для каждого измеренного состояния нагрузки.

Рассматривается двухуровневая иерархическая стратегия классификации, в которой направление и состояние нагрузки служат основой для разделения обучающих наборов данных на контекстуальные сценарии нагрузки. В рамках каждого из этих сценариев модели Random Forest (RF), Gradient Boost, XGBoost и LightGBM [2] обучаются на отдельных контекстах, чтобы выявить уникальные признаки неисправностей, характерные для этих режимов, и тем самым снизить вероятность ошибочной классификации из-за влияния изменяющейся нагрузки двигателя.

При помощи RUL можно получать профили деградации для каждого цилиндра. Модели глубокого обучения такие, как рекуррентные нейронные сети с управляемыми вентилями (GRU) и долгой краткосрочной памятью (LSTM) [2] сочетают в себе классификацию неисправностей с прогнозированием и фиксирует временные закономерности. Коэффициенты нагрузки рассчитываются по первому главному компоненту с резервным автоэнкодером. Они влияют на деградацию, позволяя количественно оценить влияние нагрузки на двигатель. Это повышает адаптивность и надёжность модели, калибруя прогнозы с учётом неопределённости.



Объединение этих ключевых концепций формирует основу для реализации замкнутого цикла управления техническим состоянием и прогнозирования для двухтактных судовых двигателей. Таким образом, с помощью таких методов, как обнаружение аномалий, кластеризация и маркировка неисправностей, классификация неисправностей и оценка остаточного срока службы, можно создать комплексную систему, ориентированную на нагрузку и контекст, для совершенствования стратегий технического обслуживания судовых двигателей в зависимости от их состояния. Это взаимодействие схематично представлено на рис. 1, где показаны три ключевых уровня системы.




Рисунок 1 – Гибридная система технического обслуживания по состоянию (CBM) на основе искусственного интеллекта

Система преобразует данные датчиков в признаки—«отпечатки» неисправностей. Диагностика выявляет аномалии, их оценки с учётом экспертных знаний и статистики формируют метки для классификации дефектов. Далее RUL–модель отслеживает деградацию цилиндров. Этот цикл – основа предлагаемой системы.

Модуль обнаружения аномалий – это первый этап работы системы CBM, на котором неисправные рабочие циклы отделяются от нормальных, и каждому неисправному циклу присваивается показатель аномальности. Все входные данные для алгоритмов были предварительно обработаны для снижения уровня шума и избыточности [3], а признаки с коэффициентом корреляции Пирсона выше 0,95 или практически нулевой дисперсией были удалены, и остались только релевантные признаки. Чтобы сохранить преемственность во времени, для интерполяции недостающих данных использовались усредненные значения по циклам, а оставшийся набор данных был нормализован с помощью стандартизации z–показателей, чтобы получить нулевое среднее значение и единичную дисперсию. После обработки нормализованная матрица признаков подана на вход ансамблю из четырёх алгоритмов обнаружения аномалий: Isolation Forest (IF), HBOS, PCA и k-NN [2]. Каждый метод основан на разных допущениях. IF выявляет выбросы по длине путей разделения, HBOS — по гистограммной вероятности атрибутов, PCA — по ошибкам реконструкции в подпространстве главных компонент, k-NN — по среднему расстоянию до ближайших соседей.

В качестве наиболее подходящей настройки для каждого режима работы была выбрана конфигурация, которая обеспечивала максимальную разницу между частотой аномалий в дефектных и исправных сегментах при низком уровне ложноположительных срабатываний. Для каждого цикла подсчитывалась необработанная оценка аномалий. $S_{t,j}$ генерируется каждым детектором $j \in \{1, \dots, M\}$ с $M = 4$. Для сравнительного анализа данные были нормализованы по принципу «минимум-максимум». Затем на основе консенсуса по баллам был сформирован непрерывный индекс, который определяется следующим образом:

$$\bar{S}_t = \frac{1}{M} \sum_{j=1}^M \widetilde{S}_{t,j}, \quad (1)$$

где обнаружена ошибочная точка данных $S_t \geq \tau_s$. Порог τ_s устанавливается на $(1 - \gamma)$ базовый процентиль, где γ равно целевому уровню загрязнения для данной нагрузки; если базовый уровень чистоты ограничен, то $\mu + 2\sigma$. Используется правило для номинальных данных. Показатели аномалий объединяются с набором входных данных, которые передаются в конвейер кластеризации для улучшения идентификации и маркировки кластеров со схожими характеристиками с использованием знаний предметной области для присвоения меток.

В качестве основы для контролируемого конвейера классификации неисправностей был использован ансамбль древовидных моделей, поскольку они способны улавливать сложные нелинейные взаимосвязи между признаками, эффективно обрабатывать различные наборы данных и сохранять надежность при наличии шума, который часто встречается в эксплуатационных данных судовых двигателей. Основу иерархической подсистемы классификации неисправностей составили следующие ключевые модели: множественный выбор RF, градиентный бустинг (GBM), экстремальный градиентный бустинг (XGBoost) и облегченная градиентная бустинг-машина (LightGBM), которые дополняли друг друга.

Помимо детерминированной точности, для оценки достоверности решений классификатора использовалась вероятностная калибровка. Средние апостериорные вероятности и их 95 % доверительные интервалы приведены в таблице 1.

Таблица 1. Средние предсказанные вероятности по классам и 95% доверительные интервалы

Показатель достоверности	Среднее	Низкий уровень	Высокий уровень
Истинное значение P (Норма)	0.7644	0.7600	0.7693
Предсказанное P (Норма)	0.9246	0.9228	0.9263
Истинное P (Утечка FIV)	0.5988	0.5875	0.6095
Предсказанное P (Утечка FIV)	0.8708	0.8665	0.8754
Истинное P (Утечка насоса)	0.6965	0.6910	0.7022
Предсказанное P (Утечка насоса)	0.8977	0.8952	0.9004

Прогнозы классификации неисправностей с высокой степенью достоверности были получены для нормального класса. Точность прогнозирования модели превысила 92 %, при этом повышенная достоверность была обусловлена постоянным наличием признаков, связанных с давлением и температурой, в нормальном состоянии. В то же время прогнозы

по классу утечек Клапан впрыска топлива (FIV) показали самую низкую степень достоверности — 69 % — из-за их слабой и рассредоточенной во времени физической реализации. Прогнозы по классу утечек в насосах показали среднюю степень достоверности — 89 % — из-за совпадения показателей давления и температуры. Анализ распределения вероятностей в модели показал, что прогнозы с низкой степенью достоверности были связаны с событиями, характеризующимися частичной деградацией, что указывает на то, что неопределённость в модели имеет физическую подоплёку, а не является случайной.

Контекстно-зависимый контролируемый классификатор пожертвовал небольшим количеством ошибок при классификации неисправностей, чтобы обеспечить интерпретируемость, характерную для каждого режима нагрузки, подкреплённую откалиброванными уровнями достоверности, подтверждающими надёжность контекстно-зависимого классификатора. Смещение в сторону нормального режима работы, а также четкие индикаторы неисправностей, связанных с утечкой топлива из форсунок и насосов, и различные режимы нагрузки, как показывают матрица неточностей и анализ важности признаков, определяют рабочие границы, в пределах которых можно принимать надёжные решения.




Рисунок 2 – Кривая потеря авторегрессионной модели с долгой краткосрочной памятью при износе клапана впрыска топлива

Система была эмпирически протестирована на двух конкретных неисправностях: засорении впускного клапана и утечке на всасывании насоса в двухтактном двигателе. В случае, если систему планируется масштабировать для работы с различными конфигурациями двигателей, типами неисправностей и связанными с ними подсистемами, крайне важно, чтобы она была адаптируема с минимальными изменениями или вообще без них, что позволит широко использовать ее в качестве инструмента диагностики и прогнозирования для судовых двигателей. В исследованиях [4] продемонстрировали, что для достижения универсальности и повышения производительности необходимо использовать ансамблевое обнаружение аномалий на нескольких двигателях.

Две неисправности, вызванные внешними факторами: утечка в клапане впрыска топлива и утечка на всасывании насоса, имеют схожие признаки, особенно при высоких нагрузках, [5] что приводит к появлению сложных признаков неисправности, которые

трудно идентифицировать. Таким образом, совмещение признаков неисправности затрудняет диагностику. Установка этой системы на реальном судне потребует тщательной оценки доступных компьютерных ресурсов.

Заключение

Представлена система мониторинга состояния и прогнозирования остаточного ресурса для компонентов судовых дизельных двигателей, на основе искусственного интеллекта. На примере выпускного клапана и топливного насоса. Были проанализированы две неисправности в представленном оборудовании и выявлены достоинства и недостатки гибридной системы. Экспериментально подтверждена высокая достоверность классификации. Учёт режимов нагрузки и вероятностная калибровка позволили снизить число ложных срабатываний и повысить интерпретируемость решений. Так же выявлены ограничения, возникающие из-за затруднений в обработке больших объемов данных и нелинейности процессов. Предложенный подход может быть адаптирован к различным конфигурациям двигателей и типам неисправностей. Это показывает его перспективу к возможности внедрения в системы технического обслуживания по состоянию судовых энергетических установок.

Список литературы:

1. Гагаев С. Ю. Проблемы и перспективы развития внутреннего водного транспорта в российской федерации //Научный взгляд в будущее. – 2016. – Т. 1. – №. 2. – С. 46-50.
2. Суда внутреннего и смешанного (река-море) плавания. Санитарные правила и нормы: СанПиН 2.5.2-703-98. – Москва: Минздрав России, 1998. – 144 с.
3. Правила предотвращения загрязнения окружающей среды. Российский речной регистр. Москва. – 2016 г.;
4. Регистровая книга Российского речного регистра. – URL: <http://www.rivreg.ru/activities/class/regbook/> (дата обращения 01.04.2026)
5. Экономико-математические методы и модели в управлении морским транспортом: Учеб. для студентов морских вузов. / Е.Н. Воевудский, Н.А. Коневцева, Г.С. Махуренко, И.П. Тарасова; под ред. Е.Н. Воевудского. - М.: Транспорт, 1988. - 384 с.
6. Богданов Д.В. Построение сетей коммуникации будущих специалистов в системе высшего образования. // Великие реки 2015: Материалы международной научно-методической конференции. ФГБОУ ВО «ВГУВТ». – 2015. – URL: <http://вф-река-море.рф/2015/PDF/35.pdf> (дата обращения 01.04.2026)

