

Методы машинного обучения в мониторинге рабочего поведения морского двухтактного дизельного двигателя



А. И. Епихин,
канд. техн. наук,
начальник кафедры
эксплуатации судовых
энергетических установок
Государственного морского
университета (ГМУ)
им. адм. Ф. Ф. Ушакова,



С. И. Кондратьев,
д-р техн. наук,
ректор ГМУ
им. адм. Ф. Ф. Ушакова,



Е. В. Хекерт,
д-р техн. наук,
проректор ГМУ
им. адм. Ф. Ф. Ушакова

С развитием интеллектуального судостроения все больше данных датчиков добавляется к диагностике работы судовых систем. Огромный массив информации предъявляет повышенные требования к мониторингу рабочего поведения двигателей. В связи с этим актуальной проблемой является использование методов машинного обучения для определения состояния работы энергетических установок судов.

Сегодня компьютеры способны выполнять многие задачи, которые раньше решали люди. Это реализуется с помощью машинного обучения при наличии достаточного количества данных. Поскольку компьютеры могут получать и хранить очень большие объемы информации, а также быстро их обрабатывать, в решении многих задач они позволяют достигать лучших результатов, чем человек.

Существуют различные методы машинного обучения, и хорошей производительности можно добиться, выбрав подходящий подход с наилучшей параметризацией. Разумеется, лучшие, чем у человека, результаты зависят от типа задачи и данных.

Широкое распространение методы машинного обучения находят в техническом обслуживании судовых систем. Машинное отделение судна — это сложный механизм, состоящий из множества элементов и взаимосвязанных частей. Поскольку автоматизация приобретает все большее значение на судах нового поколения, данные от сотен или даже тысяч датчиков могут обрабатываться и записываться в режиме реального времени [1, 2]. Соответственно, чтобы аккумулировать и преобразовывать эти сведения в полезную информацию, необходимы инструменты интеллектуального анализа.

Методы мониторинга состояния, основанные на данных, анализируют измеряемые характеристики с помощью моделей машинного обучения, чтобы обнаружить аномальное пове-

дение судовых систем и обеспечить поддержку принятия решений. Основная цель моделей, управляемых данными, — как можно раньше идентифицировать наличие отклонений от номинальных условий эксплуатации в потоковых данных датчиков в режиме реального времени. Эти отклонения могут быть признаком приближающегося отказа системы [3, 4].

Технология диагностики неисправностей на основе машинного обучения является чувствительной, потенциально более дешевой и высокоэффективной альтернативой для выявления неисправностей двигателя по сравнению с регулярным ручным обслуживанием, таким как корректирующее и профилактическое. Кроме того, диагностическая модель на основе машинного обучения может быть точно настроена с помощью алгоритмов оптимизации и исторических данных для получения наилучшего результата.

В то же время важным вопросом при разработке системы мониторинга и диагностики рабочего поведения морских двигателей на основе машинного обучения является выбор подходящего алгоритма, который способен работать с различной информацией, с неопределенностью или несовершенством, а также строить отношения «многие ко многим» между получаемыми от датчиков данными и режимами износа.

Большинство современных систем диагностики двигателей в основном разрабатываются с использованием одного интеллектуального алгоритма. Однако



Рис. 1. Алгоритм использования машинного обучения в процессе мониторинга рабочего поведения морского двухтактного дизельного двигателя

у разных алгоритмов есть свои достоинства и недостатки. При этом надежность и отказоустойчивость модели мониторинга работы судовой системы весьма ограничены при использовании только одного алгоритма. Таким образом, заслуживает внимания вопрос о том, как использовать преимущества различных диагностических систем машинного обучения с помощью объединенного метода.

Различные алгоритмы машинного и глубокого обучения для автоматического обнаружения неисправностей компонентов судового двигателя на основе реконструкции без учителя рассматривают в своих трудах Д. О. Пушкарев, Ю. В. Киселев, А. Г. Кузнецов, Zhijing Xu, Jiuyu Sun, Yuhao Huo, Qilin Xiao.

Над разработкой динамических линейных моделей сигналов многомерных датчиков с 1-минутной частотой судового дизель-генератора для прогнозирования распределения будущих сигналов трудятся С. В. Сальников, Е. М. Солодкий, Д. Д. Вишняков, Р. Ю. Юдин, Shi-Lu Dai, Min Wang, Cong Wang.

Вместе с тем, несмотря на имеющуюся на сегодня информацию, в данной предметной плоскости остается много нерешенных вопросов. В частности, отдельного внимания заслуживает проблема обучения кластерных алгоритмов на рабочих данных, чтобы определить об-

ласти, относящиеся к нормальным условиям эксплуатации, а затем проверить, входят ли новые полученные данные в эти кластеры.

Также в дальнейшем развитии нуждается подход, позволяющий преодолеть недостаток неточных и ошибочных данных для диагностики судовых двигателей, благодаря сбору сведений, созданных на основе моделей цифровых двойников.

Таким образом, цель статьи заключается в рассмотрении возможностей использования методов машинного обучения в мониторинге рабочего поведения судового двигателя. В качестве объекта исследования будет использоваться морской двухтактный дизельный двигатель.

Методы машинного обучения основаны на данных, поэтому для обучения и проверки моделей необходима стандартизация экспериментальных данных и аналитики процессов их обработки [5, 6]. Для исследования будем использовать алгоритм, представленный на рис. 1, состоящий из пяти основных этапов. Некоторые шаги состоят из подзадач, которые необходимо выполнить перед переходом к следующему шагу. Для создания и обучения модели интеллектуального анализа данных будет использоваться машина опорных векторов, машина экстремального обучения и глубокое обучение, которые способны прогнозировать

состояние двигателя на основе входных данных.

Идентификация состояния надежности судового двигателя и параметров его работы независимо от используемого метода обычно включает в себя расчет расстояния между точками в сформулированном пространстве [4]. Однако вычисление расстояния в функциональном пространстве может быть сложным и трудоемким, поэтому предлагаем заменить каждую временную характеристику ее значением, рассчитанным по следующим формулам:

$$[vs_i] = \int_{t_0}^{t_k} vs_i(t) dt \quad (1)$$

$$\langle vs_i \rangle = \frac{1}{t_k - t_0} \int_{t_0}^{t_k} vs_i(t) dt \quad (2)$$

$$E_{vs_i} = \int_{t_0}^{t_k} vs_i^2(t) dt \quad (3)$$

$$P_{vs_i} = \frac{1}{t_k - t_0} \int_{t_0}^{t_k} vs_i^2(t) dt \quad (4)$$

$$\overline{m_{vs_i}^1} = \int_{t_0}^{t_k} t \cdot vs_i(t) dt p(RS_i) \quad (5)$$

$$\overline{m_{vs_i}^2} = \int_{t_0}^{t_k} t^2 \cdot vs_i(t) dt \quad (6)$$

Таблица 1. Датчики, использованные в исследовании, и количество ненулевых измерений за тестовый период

Датчик	Ненулевые измерения
Температура окружающего воздуха	39 776
Температура в помещении двигателя	9931
Цилиндр — температура отработавших газов на выходе	39 498
Цилиндр — температура гильзы со стороны выхлопных газов	39 497
Температура гильзы со стороны насоса	39 497
Цилиндр — давление сжатия	39 776
Цилиндр — максимальное давление	39 776
Цилиндр — среднее индикаторное давление	17 974
Топливный индекс	39 776
Температура охлаждающей воды на выходе	39 776
Мощность главного двигателя	39 769
Часы работы главного двигателя	39 775
Число оборотов главного двигателя	39 776
Крутящий момент главного двигателя	39 769

Таблица 2. Серии испытаний с интервалами временных меток

Серия испытания	Настройка числа оборотов, мин ⁻¹	Количество экземпляров	%	Интервал времени
A	87	512	43,12	Май
B	86	3	0,27	Октябрь
C	87	23	1,24	Январь
D	90	209	20,47	Июль
E	89	24	1,08	Сентябрь
F	84	178	13,56	Август
G	74	316	20,16	Март
$D_{\text{сум}}$	—	1265	100	Декабрь

$$\overline{(t - m_{vsi})^1} = \int_{t_0}^{t_k} (t - \overline{m_{vsi}}) \cdot v_{si}(t) dt \quad (7)$$

$$\overline{(t - m_{vsi})^2} = \int_{t_0}^{t_k} (t - \overline{m_{vsi}})^2 \cdot v_{si}(t) dt \quad (8)$$

$$\overline{t_{vsi}^1} = \frac{\int_{t_0}^{t_k} t \cdot v_{si}(t) dt}{\int_{t_0}^{t_k} v_{si}(t) dt} \quad (9)$$

$$\overline{t_{vsi}^2} = \frac{\int_{t_0}^{t_k} t^2 \cdot v_{si}(t) dt}{\int_{t_0}^{t_k} v_{si}(t) dt} \quad (10)$$

$$\overline{(t - t_{vsi})^1} = \frac{\int_{t_0}^{t_k} (t - \overline{t_{vsi}}) \cdot v_{si}(t) dt}{\int_{t_0}^{t_k} v_{si}(t) dt} \quad (11)$$

$$\overline{(t - t_{vsi})^2} = \frac{\int_{t_0}^{t_k} (t - \overline{t_{vsi}})^2 \cdot v_{si}(t) dt}{\int_{t_0}^{t_k} v_{si}(t) dt} \quad (12)$$

$$\overline{t_{vsi^2}^1} = \frac{\int_{t_0}^{t_k} t \cdot v_{si}^2(t) dt}{\int_{t_0}^{t_k} v_{si}^2(t) dt} \quad (13)$$

$$\sigma_{vsi^2}^2 = \frac{\int_{t_0}^{t_k} (t - \overline{t_{vsi^2}})^2 \cdot v_{si}^2(t) dt}{\int_{t_0}^{t_k} v_{si}^2(t) dt} \quad (14)$$

$$\Delta t_{vsi} = \frac{\int_{t_0}^{t_k} v_{si}(t) dt}{v_{si}(0)} \quad (15)$$

$$\Delta T_{vsi} = \sqrt{\frac{\int_{t_0}^{t_k} (t - \overline{t_{vsi^2}})^2 \cdot v_{si}^2(t) dt}{\int_{t_0}^{t_k} v_{si}^2(t) dt}} \quad (16)$$

- где — *i*-й зарегистрированный вибрационный или шумовой сигнал;
- t_0 — время начала сигнала v_s ;
- t_k — время окончания сигнала v_s ;
- 1 — интеграл сигнала;
- 2 — среднее значение сигнала;
- 3 — энергия сигнала;
- 4 — средняя мощность сигнала;
- 5 — простой момент первого порядка;
- 6 — простой момент второго порядка;
- 7 — центральный момент первого порядка;
- 8 — центральный момент второго порядка;
- 9 — нормированный простой момент первого порядка;
- 10 — нормированный простой момент второго порядка;
- 11 — нормированный центральный момент первого порядка;
- 12 — нормированный центральный момент второго порядка;

- 13 — абсцисса центра тяжести квадрата сигнала;
- 14 — дисперсия квадрата сигнала;
- 15 — эквивалентный диаметр сигнала;
- 16 — средняя ширина сигнала.

Характеристики являются основными параметрами, используемыми при анализе сигналов. Чтобы определить полезность заданной характеристики в процессе идентификации, можно рассчитать ее концентрацию. Характеристика считается концентрированной, если стандартное отклонение (s) значения характеристики (D) в группе временных рядов, зарегистрированных для одного и того же состояния надежности (DSG), составляет менее 15% от среднего значения:

$$\sigma_{D(DSG)} \leq \bar{D}(DSG) \cdot 0,15 \quad (17)$$

где $D(DSG)$ — характеристика сигнала; DSG — группа временных рядов, зарегистрированных для одного и того же состояния надежности.

Кроме того, предполагается, что:

- характеристика может быть использована для однозначной идентификации состояния надежности, если она удовлетворяет условию, описанному в формуле (18);
- характеристика может быть использована для однозначной идентификации типа состояния неспособности, если она удовлетворяет условию, описанному в формуле (19) для всех состояний неспособности.

$$\sigma_{D(DSG_{IA})} + \sigma_{D(DSG_A)} \leq |\bar{D}(DSG_{IA}) - \bar{D}(DSG_A)|, \quad (18)$$

где $D(DSG)$ — характеристика сигнала; DSG_{IA} — группа временных рядов, зарегистрированных для состояний неспособности; DSG_A — группа временных рядов, зарегистрированных для состояний способности.

$$\sigma_{D(DSG_{IA}^i)} + \sigma_{D(DSG_{IA}^j)} \leq |\bar{D}(DSG_{IA}^i) - \bar{D}(DSG_{IA}^j)|, \quad (19)$$

где $D(DSG)$ — характеристика сигнала; DSG_{IA}^i — группа временных рядов, зарегистрированных для i -го состояния неспособности.

Для проведения эксперимента использовались параметры и режимы работы судового двигателя Sulzer 6AL20/24. Данные о работе двигателя включают в себя 10-минутные усредненные журналы со 140 датчиков на борту судна. Датчики расположены в главном двигателе и периферийных

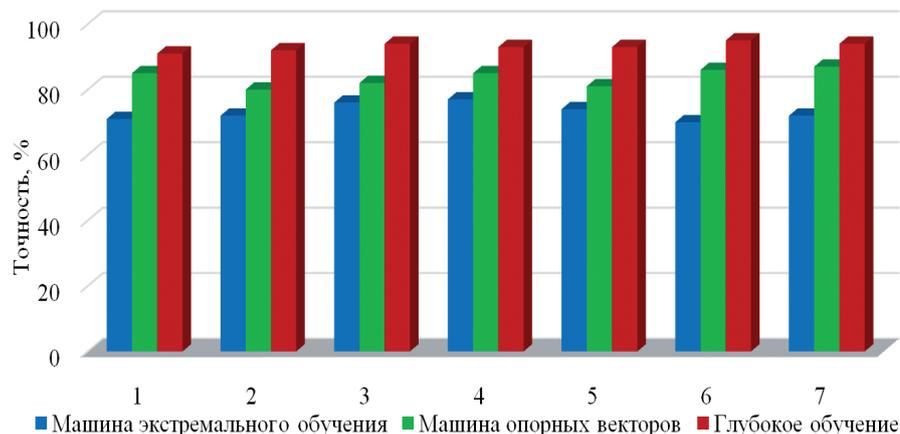


Рис. 2. Сравнение точности прогноза расхода топлива двигателем

системах. Они измеряют давление сжатия, максимальное давление и температуру выхлопных газов во время цикла сгорания, а также температуру гильзы как со стороны выхлопа, так и со стороны насоса гильзы цилиндра. Более детальная информация представлена в табл. 1.

В качестве выходной переменной в проводимом эксперименте был выбран расход топлива двигателя при трех настройках оборотов (табл. 2) и в различных режимах и погодных условиях, что позволило лучше отобразить стандартные сценарии морского путешествия.

Для обучения моделей использован программный инструментарий Weka и реализованные в нем оценки: RMSE, RAE. Итак, для оценки различных алгоритмов модель прогнозирования расхода топлива, основанная на глубоком обучении, сравнивается с экстремальной обучающей машиной и алгоритмом машины опорных векторов. Сравнивалась и анализировалась точность прогноза в процессе мониторинга рабочего поведения морского двухтактного дизельного двигателя (рис. 2).

Как видно на рис. 2, точность прогнозирования расхода топлива, полученная с помощью алгоритма глубокого обучения, составляет более 92 %, что значительно лучше, чем у других алгоритмов.

Окончательное решение о выборе подходящего алгоритма зависит от конечного использования, а именно меньшее количество переменных, необходимых для качественного предсказания, может быть преобладающим, особенно для моделей, которые работают с большим количеством экземпляров и большим объемом данных и требуют

большого времени обработки и более требовательных платформ [8–10].

И наоборот, если приоритетом является высокая точность предсказания, то выбор падает на алгоритм машины опорных векторов. Кроме того, на том же наборе данных можно создать модель с применением фильтра без контроля, основанного на интерквартильном интервале, для выявления выбросов и экстремальных значений (обнаружение аномалий). Эта модель позволит оценивать условия работы и распознавать необычные состояния двигателя или ранние ухудшения его функционирования.

Подводя итоги, отметим, что в данном исследовании модели машинного обучения на основе глубокого обучения машины опорных векторов и экстремального обучения использовались для мониторинга рабочего поведения морского двухтактного дизельного двигателя. Для оценки результативности и точности данных алгоритмов в процессе эксперимента использовался показатель расхода топлива. Полученные данные свидетельствуют, что наилучшую точность прогнозирования дает алгоритм глубокого обучения.

Предложенные в статье модели и подходы можно применять для диагностики работы судовых двигателей с целью достижения лучшего взаимодействия человека и компьютера, а также повышения эффективности и точности мониторинга функциональных характеристик различных частей и элементов судовых энергетических установок. ■

Источники

1. Мухамеджанов А. И., Хабибуллин И. И. Обзор методов машинного обучения

для прогнозирования технического состояния газотурбинных двигателей // Вестн. КГТУ им. А. Н. Туполева. 2023. Т. 79, № 3. С. 70–77.

2. Астреин В. В., Кондратьев С. И. О проблеме и задачах автоматического мониторинга в СППР безопасности судовождения // Эксплуатация морского транспорта. 2022. № 2 (103). С. 148–153.
3. Stoll A., Benner P. Machine learning for material characterization with an application for predicting mechanical properties // GAMM-Mitteilungen. 2021. Vol. 44, Iss. 1. P. 112–119.
4. Боран-Кешишьян А. Л., Астреин В. В., Кондратьев С. И. Формализация общей стратегии принятия решений для достижения комплексной безопасности судна // Морские интеллектуальные технологии. 2019. № 1–2 (43). С. 127–131.
5. Colone L., Dimitrov N. Predictive repair scheduling of wind turbine drivetrain components based on machine learning // Wind Energy. 2019. Vol. 22, Iss. 9. P. 45–52.
6. Епихин А. И., Кондратьев С. И., Хекерт Е. В. Применение нейронных сетей на базе многослойного перцептрона с использованием нечеткой логики для технической диагностики судовых технических средств // Эксплуатация морского транспорта. 2020. № 3 (96). С. 111–119.
7. Chengjin Qin, Yanrui Jin. Anti-noise diesel engine misfire diagnosis using a multi-scale CNN-LSTM neural network with denoising module // CAAI Transactions on Intel. Technol. 2023. Vol. 8, Iss. 3. P. 76–84.
8. Жуков В. А., Черный С. Г., Соболев А. С. Подход машинного обучения при прогнозировании состояния дизельного двигателя с использованием данных контроллера двигателя // Морская радиоэлектроника. 2022. № 4. С. 36–41.
9. Епихин А. И. Использование искусственной нейронной сети для определения уровня износа цилиндропоршневой группы судового двигателя // Морские интеллектуальные технологии. 2023. № 1–1 (59). С. 112–119.
10. Епихин А. И., Фадеев М. И., Васган И. Ю. Мониторинг и прогнозирование расхода топлива судами с помощью нейронных сетей // Эксплуатация морского транспорта. 2023. № 2 (107). С. 104–107.