



НАУЧНАЯ СТАТЬЯ
УДК 621.431.7
DOI: <https://doi.org/10.30932/1992-3252-2023-21-6-13>

Диагностика судовых двигателей на основе вейвлет-нейронной сети и сканирования изображений с помощью программируемой логической схемы



Алексей ЕПИХИН



Сергей КОНДРАТЬЕВ



Евгений ХЕКЕРТ

Алексей Иванович Епихин¹, Сергей Иванович Кондратьев², Евгений Владимирович Хекерт³

^{1, 2, 3} Государственный морской университет им. адмирала Ф. Ф. Ушакова, Новороссийск, Россия.

¹ ORCID 0000-0001-8086-536X, Web of Science Researcher ID: X-2415-2018; Scopus ID: 57321825100; РИНЦ Author ID: 830732.

² ORCID 0000-0001-6145-8718; Web of Science Researcher ID: AAL-1619-2021; Scopus ID: 57321941300; РИНЦ Author ID: 751295.

³ ORCID 0000-0003-0953-3949; Web of Science Researcher ID: AAL-1290-2021, Scopus ID: 57320865700; РИНЦ Author ID: 765031.

✉ ¹ bsmbeton@mail.ru.

АННОТАЦИЯ

Статья посвящена системе диагностики судовых двигателей на основе вейвлет-нейронной сети и сканирования изображений с помощью программируемой логической схемы. Рассматривается метод анализа мультифрактальных вейвлет-моделей.

Для целей неразрушающего контроля, который позволяет точно диагностировать неисправности и принимать эффективные меры по предиктивному обслуживанию, что в свою очередь дает возможность эффективно повысить безопасность и надежность оборудования, снизить затраты на обслуживание, значительный потенциал имеет сочетание вейвлет-нейронных сетей с программируемой на базе ПЛИС (программируемая логическая интегральная схема) платформой обработки изображений в реальном времени.

В статье предложен усовершенствованный подход к диагностике судовых двигателей, который основан на вейвлет-нейронной сети и сканировании изображений с помощью программируемой логической схемы. Вейвлет-пакетное разложение представляет собой метод локального анализа времени и частоты. Он постепенно уточняет сигнал в нескольких масштабах посредством операций масштабирования и перевода, также он может автоматически адаптироваться к требованиям частотно-временного анализа сигнала, чтобы сосредоточиться на его любых деталях. Его преимуществом является хорошая диагностическая точность для информации с различными уровнями шума, а также высокая надежность, поскольку используются данные изображения от нескольких сигналов двигателя.

Ключевые слова: водный транспорт, суда, двигатель, вейвлет-преобразование, изображение, сеть, предиктивное обслуживание.

Для цитирования: Епихин А. И., Кондратьев С. И., Хекерт Е. В. Диагностика судовых двигателей на основе вейвлет-нейронной сети и сканирования изображений с помощью программируемой логической схемы // Мир транспорта. 2023. Т. 21. № 6 (109). С. 110–118. DOI: <https://doi.org/10.30932/1992-3252-2023-21-6-13>.

Полный текст статьи на английском языке публикуется во второй части данного выпуска.
The full text of the article in English is published in the second part of the issue.

ВВЕДЕНИЕ

В последние несколько лет все большее распространение получает метод анализа мультифрактальных вейвлет-моделей. Связано это с тем, что его основной функцией является функция активации, формирования нейрона, объединения взаимных преимуществ, установления автоматического расширения и трансляции. Благодаря этим свойствам мультифрактальные вейвлет-модели эффективно применяются для анализа нестационарных случайных шумов, что позволяет рассматривать их в качестве полезного инструмента для обработки сигналов в области диагностики неисправностей различных технических механизмов и оборудования, таких, например, как судовой двигатель.

Возможности предиктивного обслуживания с использованием вейвлет-нейронных сетей широко изучаются на различных типах датчиков, таких как датчики вибрации, температуры, тока, напряжения и устройства формирования изображений. В рамках проводимых экспериментов особое внимание исследователей в области прогностики, мониторинга состояния и управления состоянием сложных технических систем привлекает анализ изображений благодаря разнообразной информации, которую они предоставляют [1; 2].

В контексте вышеизложенного, для целей неразрушающего контроля значительный потенциал имеет сочетание вейвлет-нейронных сетей с программируемой на базе ПЛИС (программируемая логическая интегральная схема) платформой обработки изображений в реальном времени. Эта платформа представляют собой мощный процессор технического зрения для различных высокоскоростных приложений распознавания и классификации изображений в режиме онлайн, требующих больших вычислительных затрат.

Однако, несмотря на широкий спектр работ, в которых анализируются возможности использования изображений для мониторинга/диагностики состояния оборудования и установок, существует ограниченное количество исследований, в которых рассматриваются вопросы прогнозирования на базе потоков многосигнальных изображений.

Обозначенные обстоятельства определяют выбор темы данной статьи.

МЕТОДОЛОГИЯ И ЦЕЛЬ ИССЛЕДОВАНИЯ

Над разработкой методов диагностики неисправностей двигателей внутреннего сгорания с использованием дискретного вейвлет-преобразования и нейронной сети в разное время трудились многие авторы. В качестве примеров многочисленных публикаций можно привести работы [3–8].

Ряд работ был посвящен двигателям различных видов транспорта, развитию и обоснованию подхода к прогнозированию надежности оборудования на основе графической информации, который заключается в моделировании потоков деградационных изображений как пространственно-временного процесса и использовании его параметров для оценки времени наработки на отказ системы посвятили свои труды [9–14].

В то же время, высоко оценивая имеющиеся на сегодняшний день результаты, следует отметить, что разработка теории интеллектуального диагностирования неисправностей еще не завершена, поэтому возникает ряд трудностей и ограничений в плане ее непосредственного использования при испытаниях. Кроме того, в более углубленном анализе нуждаются методика, позволяющая эффективно сочетать измерения и анализ неисправностей, сбор данных, отображения интерфейса и алгоритмы диагностики для принятия окончательного решения о состоянии технического средства [15–16].

Таким образом, *цель* статьи заключается в рассмотрении возможностей диагностики судовых двигателей на основе вейвлет-нейронной сети и сканирования изображений с помощью программируемой логической схемы.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Рассматриваемая в рамках проводимого исследования система диагностики неисправностей судового двигателя основывается на информации, которая собирается с различных датчиков, вейвлет-нейронной сети и платформе обработки изображений, что в совокупности дает возможность анализировать поток данных, форму сигнала и, наконец, достигать цели диагностики возникших поломок и повреждений [17–18]. На рис. 1 представлена общая схема системы.

Наиболее информативные, с конструктивной точки зрения, параметры:



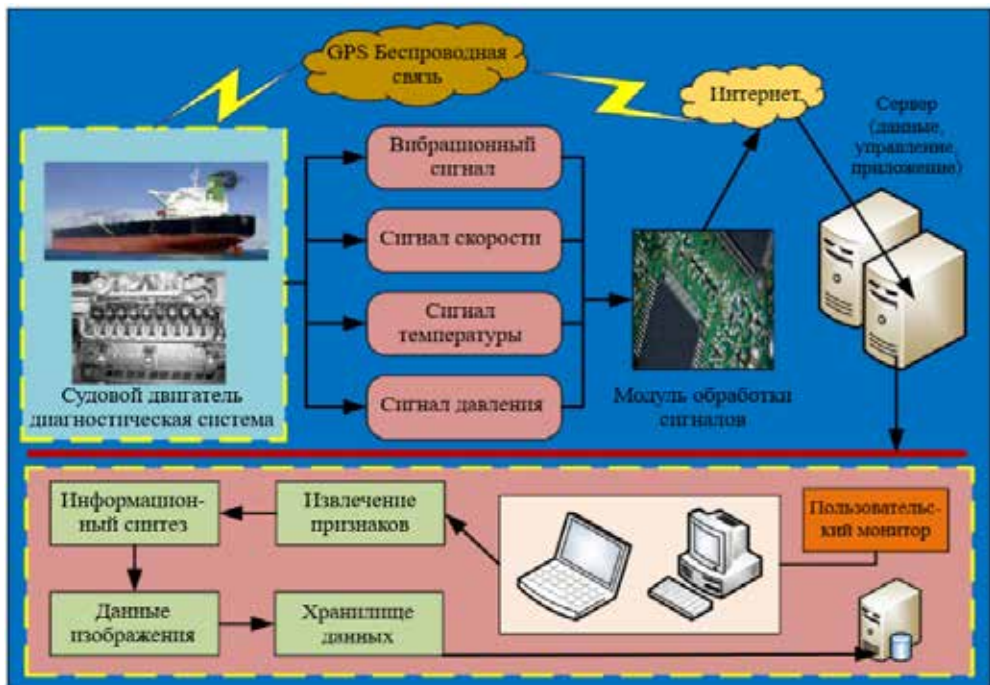


Рис. 1. Общая схема системы диагностики судового двигателя [18].

1. температура охлаждающей воды;
2. давление, температура и расход масла;
3. давление газов в картере и на выходе из цилиндров;
4. нагрузка дизельного двигателя;
5. частота вращения коленчатого вала и ротора турбокомпрессора;
6. топливоподача по цилиндрам дизельного двигателя;
7. давление наддувочного воздуха.

Эти параметры тесно связаны с отказами в таких системах и механизмах двигателя, как газораспределительный механизм, кривошипно-шатунный механизм, топливная система, система смазки, система охлаждения.

Судовые двигатели внутреннего сгорания работают в зонах с различными метеорологическими условиями, при изменяющемся техническом состоянии основных узлов и деталей.

В эксплуатации происходит ухудшение технического состояния элементов топливной системы высокого давления, цилиндропоршневой группы, агрегатов наддува, выпускной системы дизеля и других узлов, деталей и систем. Ухудшение технического состояния приводит к нарушению работоспособности дизеля (отказу), выражающемуся в изменении значений параметров его работы за пределами, регламентируемыми норма-

тивно-техническими документами, или к полной его остановке.

В результате воздействия эксплуатационных факторов уменьшается масса воздуха, участвующего в процессе сгорания; нарушается спроектированное заводом-изготовителем протекание процессов распыливания топлива, смесеобразования и сгорания; возрастают потери рабочего тела через неплотности деталей цилиндропоршневой группы на линии расширения.

Контрольными параметрами для оценки технического состояния могут служить:

- характеристики процессов топливоподачи, сжатия и сгорания в цилиндре ДВС;
- давление и температура воздуха на входе и выходе из турбоагнетателя;
- виброакустические характеристики;
- содержание продуктов износа в системе смазки или в выпускных газах.

Наиболее оптимальным явился бы смешанный способ контроля, включающий вышеприведенные характеристики.

Как свидетельствует рис. 1, диагностическая система состоит из аппаратной платформы двигателя, схемы формирования сигнала, платы сбора сигнала и терминала ПК. Аппаратная платформа двигателя включает в себя двигатель и датчики (рис. 2). Благодаря плате сбора данных накапливается ин-

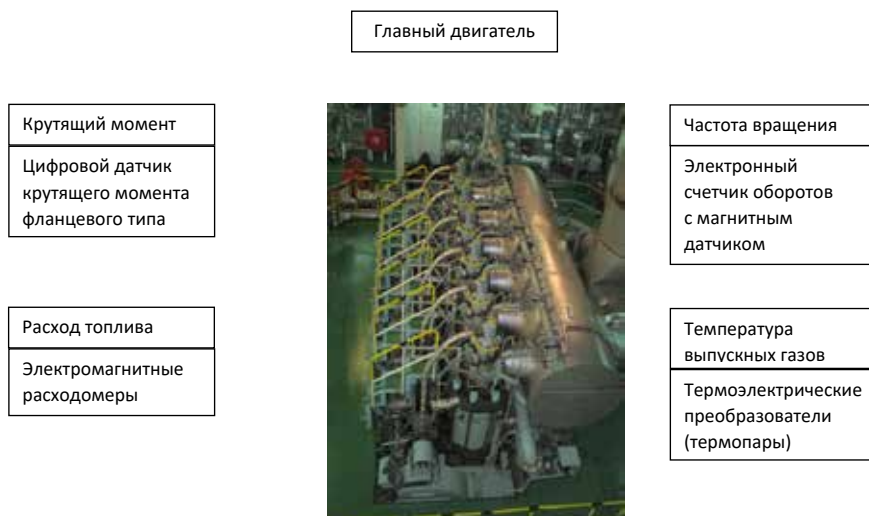


Рис. 2. Параметры контроля технического состояния судового двигателя [выполнено авторами].

формация, поступающая от датчиков. Терминал ПК включает в себя средства хранения и отображения данных LabVIEW, инструменты извлечения признаков MATLAB и объединения информации [19–20].

В контексте мониторинга состояния судового двигателя предлагается использовать несколько типов нейронных сетей для анализа параметров различных систем. Для этого можно разделить анализ на несколько этапов (рис. 3). Первый этап состоит в фильтрации сигналов от помех и шумов, с целью выделения реального сигнала. Это позволяет работать с более чистыми данными и повышает точность анализа.

Второй этап включает непосредственный анализ снимаемых параметров, их сравнение с эталоном, определение текущего состояния и предсказание остаточного ресурса элементов системы. На этом этапе можно применять различные методы анализа данных и алгоритмы машинного обучения для получения более точных результатов.

Важным этапом в разработке системы диагностики параметров с использованием нейронных сетей является фильтрация сигналов, получаемых датчиками и подверженных различным помехам и шумам. Такие искаженные аналоговые сигналы, например, акустические или вибрационные, требуют извлечения полезной информации. Для этого предлагается использовать нейронные сети распознавания образов, такие как сети DAE (Denosing Auto Encoder) [21], сети ARM

и сети RBF. Эти нейронные сети способны обрабатывать сигналы и удалять нежелательные искажения, позволяя получить чистый и полезный сигнал для дальнейшего анализа и диагностики.

Решение, принимаемое системой диагностики, может базироваться на данных во временной области или в других областях, например, в частотной, частотно-временной или масштабнo-временной [22–23]. Учитывая задачу комбинирования вейвлет-нейронной сети с программируемой на базе ПЛИС платформой обработки изображений, критически важное значение для получения достоверных данных, имеет форма входного сигнала для нейронной сети. Как показано на рис. 4, в качестве входного сигнала могут использоваться либо один сигнал двигателя, либо несколько сигналов двигателя, полученных из отмеченных выше областей.

Согласно рис. 4 в случае односигнальных моделей входной сигнал может иметь одну из следующих форм:

- односигнальный одноканальный вход, где сигнал двигателя используется как дискретный одномерный вектор или одно полутоновое изображение, как показано на рис. 4 а;
- односигнальный многоканальный вход, где используются цветные изображения из 3 или 4 цветовых каналов, как показано на рис. 4 б.

Для случая многосигнальных моделей входные данные могут быть представлены в одной из следующих форм:



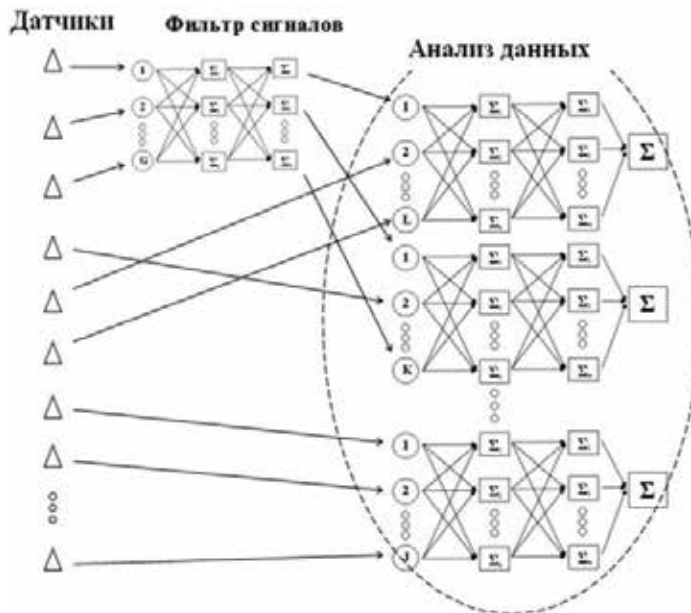


Рис. 3. Этапы подготовки данных для анализа нейронной сетью [выполнено авторами].

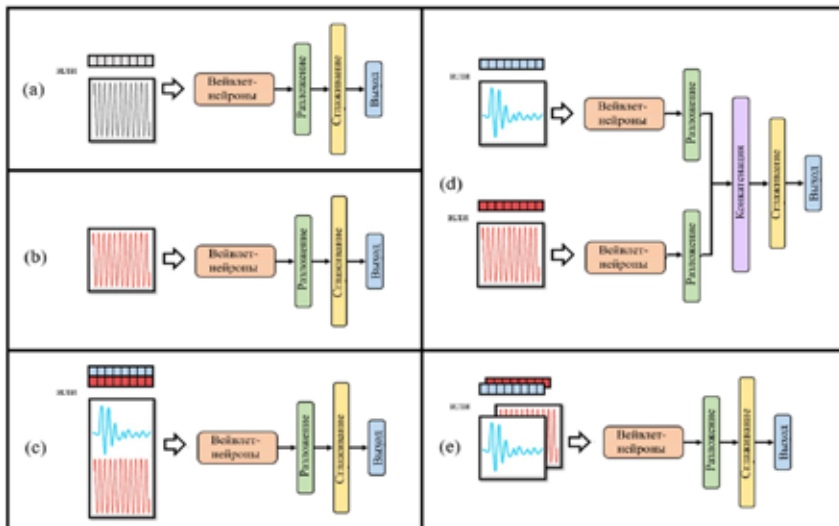


Рис. 4. Различные формы входных данных для вейвлет-нейронной сети [16].

1. многосигнальный одноканальный вход, где все сигналы либо:

- размещаются на одном рисунке (складываются по вертикали), образуя большое одноканальное изображение (см. рис. 4 с);
- сохраняются как отдельные изображения, но используются с мультимодальными сетями с различными путями свертки и последующего сглаживания для каждого сигнала, требующими последующего объединения (см. рис. 4 d).

2. многоканальный вход нескольких сигналов – каждое изображение сигнала отображается в одном канале, а после все изображе-

ния складываются для формирования трехмерной матрицы, как показано на рис. 4 e.

Как известно, основная идея вейвлет-нейронной сети заключается в использовании вейвлет-нейронов вместо традиционных нейронов, а затем в разложении сигнала с помощью многоразрешающего анализа вейвлетов [24]. Далее можно использовать нейронную сеть для аппроксимации любой функции, при этом представляется возможным использовать вейвлет-преобразование и нейронную сеть, связанные между собой. Вейвлет-нейронная сеть сочетает в себе хорошую способность вейвлет-преобразования

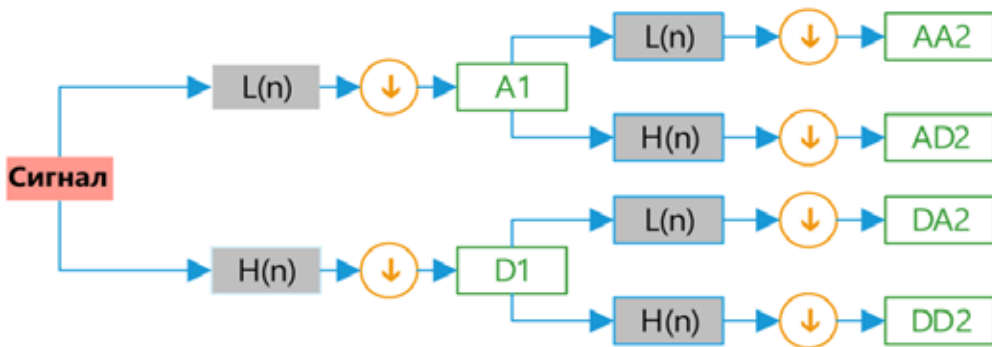


Рис. 5. Общая схема двухслойного вейвлет-разложения пакетов [26].

к временно-частотной локализации и способность нейронной сети к самообучению и аппроксимации функций. Благодаря использованию вейвлетных масштабных коэффициентов и коэффициентов перевода при вейвлетных преобразованиях, ряд после всех модификаций становится более гибким и может обладать эффективными возможностями аппроксимации функций и распознавания образов.

Для формулы генерации вейвлета $\psi(t)$, если функция $x(t)$ удовлетворяет квадратичной интегрируемости, то непрерывное вейвлет-преобразование (WT) определяется как:

$$C_{\psi}(f_s, f_t) = \int_{-\infty}^{\infty} x(t)\psi(t|f_s, f_t)dt, \quad (1)$$

в свою очередь:

$$\psi(t|f_s, f_t) = \frac{1}{\sqrt{f_s}}\psi\left(\frac{t-f_s}{f_t}\right), \quad (2)$$

где $\psi(t|f_s, f_t)$ – вейвлет-функция; f_s, f_t – коэффициент масштабирования и коэффициент трансляции соответственно.

Последовательность входных сигналов $x(n)$ длины N дискретизируется для получения дискретного вейвлет-преобразования:

$$A(n|j, k) = DS \left[\sum_n x(n)l_j^*(n-2^j k) \right], \quad (3)$$

$$D(n|j, k) = DS \left[\sum_n x(n)h_j^*(n-2^j k) \right], \quad (4)$$

где A – низкочастотный коэффициент; D – высокочастотный коэффициент; $l(n)$ и $h(n)$ – фильтр низких и высоких частот соответственно; $l^*(n)$ и $h^*(n)$ – сопряженные функции $l(n)$ и $h(n)$ соответственно; j и k – коэффициент масштабирования и коэффициент трансляции соответственно; DS – дискретизация вниз.

После разложения входного сигнала на высокочастотный и низкочастотный поддиапазоны с помощью вышеописанного процесса полученный низкочастотный поддиапазон может быть использован в качестве входного сигнала, после чего вейвлет-разложение выполняется для получения следующего уровня высокочастотного и низкочастотного поддиапазонов и т. д. С увеличением прогрессии вейвлет-разложения повышается и разрешение в частотной области.

Для случая многосигнальных моделей (рис. 4 *c, d, e*) используется дискретное пакетное вейвлет-преобразование (DWPT). Оно по сути является расширением и оптимизацией дискретного вейвлет-преобразования (DWT). В отличие от DWT на каждом уровне процесса разложения сигналов происходит не только дальнейшее разложение низкочастотного поддиапазона, но и высокочастотного поддиапазона [25]. DWPT рассчитывает оптимальный путь разложения сигнала путем минимизации функции стоимости, которая разлагает сигнал, передаваемый во входном канале. На рис. 5 показано двухслойное разложение вейвлет-пакета.

Итак, в процессе тестирования предложенной системы диагностики судового двигателя, задавая различные значения пикселей изображения и устанавливая семь тестовых времен с помощью таймера, был проведен анализ и проверка скорости захвата изображения системой и скорость потери кадров. На рис. 6 видно, что при пикселях изображения $1024 * 768$ с увеличением разности времени тестирования, начиная с 30 сек. наблюдается потеря пакетов данных изображения. В это время общее количество собранных кадров составляет 7750, с учётом количества поте-






Рис. 6. Тест производительности при разрешении 1024 * 768 пикселей [выполнено авторами].



Рис. 7. Результаты диагностики судового двигателя [выполнено авторами].

рянных пакетов на один пакет, скорость потери пакетов составляет 0,043 %. При дальнейшем увеличении времени тестирования общее количество кадров увеличивается, скорость потери кадров начинает снижаться, и максимальная скорость захвата системы достигает 168 кадров в секунду.

Для дальнейшей проверки реального применения системы диагностики в полевых условиях из системы микрокомпьютерного мониторинга на судне было получено 50 наборов кривых мощности двигателя за последние шесть месяцев, включающих все режимы отказов. Результаты диагностики с использованием адаптивной вейвлет-нейросетевой модели и платформы обработки изображений в реальном времени представлены на рис. 7.

Как свидетельствует рис. 7, в 39 наборах кривых мощности была получена правильная классификация неисправностей с помощью системы диагностики, и один набор был оценен неверно.

ВЫВОДЫ

Резюмируя полученные результаты, отметим, что для повышения точности диагностики неисправностей судового двигателя в статье предложен подход, который основан на сочетании технологии вейвлет-нейронных сетей с мультиинформационным синтезом изображений с помощью программируемой логической схемы. Вейвлет-пакетное разложение представляет собой метод локального анализа времени и частоты. Он постепенно уточняет сигнал в нескольких масштабах посредством опе-

раций масштабирования и перевода, также он может автоматически адаптироваться к требованиям частотно-временного анализа сигнала, что позволяет сосредоточиться на его любых деталях.

Результаты диагностики показывают, что эффективность распознавания поломок и отказов судового двигателя может соответствовать реальным эксплуатационным требованиям объекта и найти свое применение на практике.

СПИСОК ИСТОЧНИКОВ

1. Tianlong Lu, Zhen Lu, Yuchuan Gao, Lei Shi, Huaiyin Wang, Tianyou Wang. Investigation on suitable swirl ratio and spray angle of a large-bore marine diesel engine using genetic algorithm. *Fuel*, 2023, Vol. 345, 128187. DOI: 10.1016/j.fuel.2023.128187.
2. Епихин, А. И. Подход нечеткой кластеризации в распределенных информационных системах судовых двигателей. *Морские интеллектуальные технологии*. – 2023. – № 2–1 (60). – С. 75–79. DOI: 10.37220/MIT.2023.60.2.008.
3. Marko, K. A., Bryant, B., Soderborg, N. Neural network application to comprehensive engine diagnostics. In: *IEEE International Conference on Systems, Man and Cybernetics*, Chicago, IL, 1992, pp. 1016–1022.
4. Глушков С. П., Жидких В. О. Выбор вейвлет-образующей функции для анализа динамических характеристик сигнала двигателя внутреннего сгорания // *Вестник Сибирского государственного университета путей сообщения*. – 2017. – № 1 (40). – С. 51–56. [Электронный ресурс]: http://www.stu.ru/particular/get_teamwox_file.php?id=28121&ext=.pdf [полный текст номера]. Доступ 20.11.2023.
5. Shatnawi, Y., Al-Khassaweneh, M. Fault Diagnosis in Internal Combustion Engines Using Extension Neural Network. *IEEE Transactions on Industrial Electronics*, 2014, Vol. 61, Iss. 3, pp. 1434–1443. DOI: 10.1109/TIE.2013.2261033 [ограниченный доступ].
6. Ravikumar, K. N., Madhusudana, C. K., Kumar, H., Gangadharan, K. V. Classification of gear faults in internal combustion (IC) engine gearbox using discrete wavelet





transform features and K star algorithm. *Engineering Science and Technology*, 2022, Vol. 30, 101048. DOI: <https://doi.org/10.1016/j.jestch.2021.08.005>.

7. Ghaedi, A., Pour, E. S., Hosseinzadeh, F. Application of the discrete wavelet transform and probabilistic neural networks in IC engine fault diagnostics. *Indian Journal of Fundamental and Applied Life Sciences*, 2015, Vol. 5 (S1), pp. 1587–1592. [Электронный ресурс]: www.cibtech.org/sp.ed/jls/2015/01/jls.htm (online). Доступ 27.11.2023.

8. Czech, P., Wojnar, G., Burdzik, R., Konieczny, L., Warczek, J. Application of the discrete wavelet transform and probabilistic neural networks in IC engine fault diagnostics. *Journal of Vibroengineering*, 2014, Vol. 16, Iss. 4, 1268, pp. 1619–1639. [Электронный ресурс]: <https://www.extrica.com/article/15251>. Доступ 27.11.2023.

9. Кириллов А. В., Деста А. Б., Дубесса М. Х., Акалу Й. А. Применение нейронных сетей для диагностики и предупреждения отказов датчиков турбореактивного двухконтурного двигателя. *Перспективы науки*. – 2021. – № 11 (146). – С. 35–37. EDN: ZBQMDY

10. Енчев С. В., Товкач С. С. Вейвлет-анализ параметров систем автоматического управления авиационных двигателей. *Научный вестник МГТУ ГА*. – 2014. – № 204. – С. 90–96. [Электронный ресурс]: <https://avia.mstuca.ru/jour/article/view/593>. Доступ 27.11.2023.

11. Monday, H. N., Li, J., Nneji, G. U. [et al]. A wavelet convolutional capsule network with modified super resolution generative adversarial network for fault diagnosis and classification. *Complex and Intelligent Systems*, 2022, pp. 4831–4847. DOI: <https://doi.org/10.1007/s40747-022-00733-6>.

12. Wenliao Du, Jianfeng Tao, Yanming Li, Chengliang Liu. Wavelet leaders multifractal features based fault diagnosis of rotating mechanism. *Mechanical Systems and Signal Processing*, 2014, Vol. 43, Iss. 1–2, pp. 57–75. DOI: <https://doi.org/10.1016/j.ymssp.2013.09.003>.

13. Dong, D. W., Hopfield, J. J., Unnikrishnan, K. P. Neural Networks for Engine Fault Diagnostics. In: *Proceedings of the 1997 IEEE Workshop*, 1997, pp. 636–644.

14. Kobayashi, T., Simon, D. L. A Hybrid Neural Network-Genetic Algorithm Technique for Aircraft Engine Performance Diagnostics. In: *Proceedings of the 37th AIAA/ASME/SAE/ASEE Joint Propulsion Conference and Exhibit*, Salt Lake City, Utah, 2001, paper no. AIAA-2001–3763.

15. Sadollah, A., Travieso-Gonzalez, C. M. [Eds]. *Recent Trends in Artificial Neural Networks: from Training to Prediction*. London, IntechOpen, 2020, 150 p. ISBN 978-1-78985-420-6.

16. Luo, Qiwu; Yigang, He; Sun, Yichuang. Time-efficient fault detection and diagnosis system for analog circuits. *Automatika*, 2018, Vol. 59, pp. 303–311. DOI: 10.1080/00051144.2018.1541644.

17. Ma, Y., Han, R., Wang, W. Prediction-Based Portfolio Optimization Models Using Deep Neural Networks. *IEEE access*, 2020, Vol. 8, pp. 115393–115405. DOI: 10.1109/ACCESS.2020.3003819.

18. Song, J., Xue, G., Pan, X., Ma, Y., Li, H. Hourly Heat Load Prediction Model Based on Temporal Convolutional Neural Network. *IEEE access*, 2020. Vol. 8, pp. 16726–16741. DOI: 10.1109/ACCESS.2020.2968536.

19. Yüce, A., Nur Deniz, F., Tan, N. Interactive Analysis of Integer Order Approximation Methods in LabVIEW

Environment. 1st International Mediterranean Science and Engineering Congress (IMSEC 2016), Çukurova University, Congress Center, October 26–28, 2016, Adana / TURKEY, paper ID 686, pp. 2357–2365. [Электронный ресурс]: https://www.researchgate.net/profile/Furkan-Deniz/publication/348326399-Kesir_dereceli_transfer_fonksiyonlari_icin_tamsayi_dereceli_yaklasim_yontemlerinin_LabVIEW_ortaminda_interaktif_analizi_Interactive_Analysis_of_Integer_Order_Approximation_Methods_in_LabVIEW_Envirnonme/links/5ff82609a6fdccdb83b7523/Kesir-dereceli-transfer-fonksiyonlari-icin-tamsayi-dereceli-yaklasim-yontemlerinin-LabVIEW-ortaminda-interaktif-analizi-Interactive-Analysis-of-Integer-Order-Approximation-Methods-in-LabVIEW-Envirnonm.pdf?_tp=eyJjb250ZXh0Ijp7ImZpcnN0UGFnZSI6InB1YmxpY2F0aW9uIiwicGFkZSI6InB1YmxpY2F0aW9uIn19. Доступ 27.11.2023.

20. Ruiz de Miras, J. Fractal Analysis in MATLAB: A Tutorial for Neuroscientists. In: A. Di Ieva (ed.). *The Fractal Geometry of the Brain*, Springer Series in Computational Neuroscience, 2016, pp. 523–532. DOI: 10.1007/978-1-4939-3995-4_33.

21. Yue Gao, Dai-Jun Zhang, Cui-Na Jiao, Ying-Lian Gao, Jin-Xing Liu. Spatial Domain Identification Based on Graph Attention Denoising Auto-encoder, 2023. In: *Advanced Intelligent Computing Technology and Applications: 19th International Conference, ICIC 2023, Zhengzhou, China, August 10–13, 2023, Proceedings, Part III*, pp. 359–367. DOI: https://doi.org/10.1007/978-981-99-4749-2_31.

22. Abdelmaksoud, M., Torki, M., El-Habrouk, M., Elgeneidy, M. Convolutional-neural-network-based multi-signals fault diagnosis of induction motor using single and multi-channels datasets. *Alexandria Engineering Journal*, 2023, Vol. 73, pp. 231–248. DOI: 10.1016/j.aej.2023.04.053.

23. Jian Zhang, Yangqian Meng, Dai Liu, Long Liu, Xiuzhen Ma, Changzhao Jiang, Xiannan Li, Li Huang. Modelling and multi-objective combustion optimization of marine engine with speed maintaining control target. *Thermal science and engineering progress*, 2023, Vol. 41, pp. 12–18. DOI: 10.1016/j.tsep.2023.101852.

24. Chao Luo, Haiyue Wang. Fuzzy forecasting for long-term time series based on time-variant fuzzy information granules. *Applied soft computing*, 2020, Vol. 88, pp. 65–72. DOI: 10.1016/j.asoc.2019.106046 [ограниченный доступ].

25. Zhou, W., Wu, J., Liu, A., Zhang, W. A., Yu, L. Neurodynamics-based distributed model predictive control of a low-speed two-stroke marine main engine power system. *ISA Transactions*, 2023, Vol. 138, pp. 341–358. DOI: 10.1016/j.isatra.2023.03.006.

26. Zhenyi Kuai, Guoyong Huang. Fault Diagnosis of Diesel Engine Valve Clearance Based on Wavelet Packet Decomposition and Neural Networks. *Electronics*, 2023, Vol. 12, 353. DOI: 10.3390/electronics12020353.

27. Ofner, A. B., Kefalas, A., Posch, S., Pirker, G., Geiger, B. C. In-cylinder pressure reconstruction from engine block vibrations via a branched convolutional neural network. *Mechanical systems and signal processing*, 2023. Vol. 183, 109640. DOI: 10.1016/j.ymssp.2022.109640. ●

Информация об авторах:

Епихин Алексей Иванович – кандидат технических наук, доцент, начальник кафедры эксплуатации судовых механических установок Государственного морского университета имени адмирала Ф. Ф. Ушакова, Новороссийск, Россия, bsmbeton@mail.ru.

Кондратьев Сергей Иванович – доктор технических наук, профессор, ректор Государственного морского университета имени адмирала Ф. Ф. Ушакова, Новороссийск, Россия, sikondr@gmail.com.

Хекерт Евгений Владимирович – доктор технических наук, профессор, проректор Государственного морского университета имени адмирала Ф. Ф. Ушакова, Новороссийск, Россия, zur_tga@nsma.ru.

Статья поступила в редакцию 20.11.2023, одобрена после рецензирования 27.12.2023, принята к публикации 29.12.2023.