

DOI: 10.34031/2071-7318-2026-11-5-125-133

^{1,*}Гринёк А.В., ¹Фищенко А.М., ¹Бойчук И.П., ²Башкатов В.А., ³Перелыгин Д.Н.¹ООО «Сигматек»²Северная морская компания LTD³Белгородский государственный технологический университет им. В.Г. Шухова

*E-mail: grinyokann@gmail.com

ПРОГНОЗИРОВАНИЕ ИНТЕНСИВНОСТИ ИЗНОСА ПОРШНЕВЫХ КОЛЕЦ СУДОВОГО ГЛАВНОГО ДВИГАТЕЛЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Аннотация. В статье показаны результаты применения нейронной сети для аппроксимации данных экспериментальных исследований износа керамометаллического покрытия поршневых колец судовых двигателей. Предложена структурная схема, качественно описывающая неоднозначный характер связи износа с набором эксплуатационных параметров. Проведены измерения покрытия поршневых колец действующих судовых двигателей 6S50ME-C-GI с электронным управлением. Установлено, что от состояния поршневых колец судового главного двигателя зависит ряд параметров, определяющих условия функционирования и надежность работы двигателя в целом. Проведен факторный анализ влияния конструктивных и технологических параметров на износ поршневых колец. В качестве основных факторов, влияющих на износ, выбраны удельный расход цилиндрического масла и мощность двигателя. Для обработки накопленных данных использовалась нейронная сеть. С учетом размера обучающих данных показана структура сети, описывающая функционально связь расхода топлива и мощности двигателя с износом, определены массивы данных для её работы и проведено обучение сети. В результате работы нейронной сети получена аппроксимирующая поверхность износа колец и комбинации значащих параметров, при котором износ максимален. Полученные результаты могут быть применены на практике для выработки алгоритма, прогнозирующего календарную дату капитального ремонта цилиндра с учетом факторов износа.

Ключевые слова: поршневые кольца, износ, нейросети, диагностика, обслуживание цилиндропоршневой группы.

Введение. В процессе эксплуатации судовых двигателей внутреннего сгорания необходимо точно контролировать износ поршневых колец. Важность этого подчёркивается тем, что несвоевременная и не запланированная замена поршневых колец приводит к простаиванию судна и соответственно огромным потерям для судовладельца [1]. Поэтому необходимо проводить обслуживание только в запланированный период и только при действительной необходимости.

Контроль состояния колец выполняется, в основном, путём замера толщины кольца в четырёх точках по периметру с шагом 90° и определении их остаточной деформации. Для этих целей необходимо иметь доступ внутрь цилиндра, что является сложной задачей с учетом размеров современных судовых главных дизелей. К тому же на это необходимо отводить время, в течение которого судно будет простаивать.

Для оптимизации контроля поршневых колец разрабатываются и исследуются различные методы безразборного контроля состояния цилиндропоршневой группы (ЦПГ). В работе [1] проводили измерения толщины покрытия поршневых колец ряда двигателей и составили статистическую базу по изменениям этого покрытия. Эта база данных была применена для разработки

математической модели износа поршневых колец. Так же авторами проведены исследования влияния различных факторов эксплуатации на износ поршневых колец. В работе [2] разработали математическую модель для исследования параметров, влияющих на работу и износ ЦПГ.

В патенте [3] предлагается контролировать износ колец визуально, через продувочные и выпускные окна, по количеству заранее нанесённых на кольца лунки. В патенте [4] предлагается использование вибрационного контроля для определения износа колец. Степень износа ЦПГ можно контролировать по содержанию железа в картерном масле и выпускных газах. На этом базируются исследования в работах [5–8]. В статье [9] используются вероятностные методы оценки износа ЦПГ. Основываясь на средних показателях износа конкретного двигателя, предлагается судить о текущем состоянии ЦПГ по различию температур блока цилиндров [10]. Состояние поршневых колец и их износ в процессе эксплуатации так же исследуется в работах [11–15].

Керамометаллическое покрытие является частью износа поршневых колец и может быть использовано как один из факторов, определяющий необходимость проведения капитального ремонта цилиндра по достижению пороговых

значений, согласно рекомендации производителя. Кроме прочего, математическое моделирование износа колец в рамках иерархических моделей пропульсивных систем [16] может повысить качество моделирования сложных систем.

Целью работы является создание математической модели на основе эмпирических данных, связывающей параметры эксплуатации и износ колец дизельного двигателя. Предложенный подход с использованием модели в виде ИНС (Искусственная Нейронная Сеть) обеспечит потенциал расширения и дополнения модели новыми данными и параметрами.

Материалы и методы. Были проведены наблюдения по износу поршневых колец. Замеры проводились с помощью толщинометра Elcometer 456. По результатам измерений по рекомендуемой производителем двигателей методике произведена оценка зависимости износа керамометаллического покрытия колец в зависимости от эксплуатационных параметров.

Факторы, которые влияют на износ поршневых колец, можно разделить на три группы:

- Внешние факторы, они определяют условия в камере сгорания, формируют атмосферу, в которой происходят рабочие процессы. Влияние на атмосферу оказывают следующие факторы:

содержание серы в топливе, температура наддува, влажность воздуха.

- Внутренние факторы: температура в точке касания пар трения и сила трения.

- Поверхностные факторы, которые определяются количеством смазки внутри цилиндра.

Рассмотрев природу названных факторов более подробно, можно, условно, присвоить каждому из факторов знак «+» или «-», в зависимости от влияния этих факторов на износ поршневых колец.

На рис. 1 приведена общая структурная модель износа поршневых колец, на которой показана качественная связь износа со многими параметрами:

N_e – средняя эффективная мощность за период, кВт;

T – средняя температура наддува за период, °C;

n – частота оборотов двигателя;

V_n – скорость движения поршня;

φ – средняя относительная влажность за период, %;

S – массовое содержание серы в топливе, %;

q_m – удельный расход цилиндрического масла, г/кВтч.




Рис. 1. Комплексная модель износа поршневых колец (обозначения приведены выше)

Сложность такой модели заключается в том, что взаимное влияние факторов может носить неоднозначный характер.

Соответственно износ покрытия поршневых колец будет определяться как сумма функций износа от рассмотренных факторов:

$$\Sigma \sigma = f(N_e) + f(\varphi_{\text{отн}}) + f(T) + f(S) + f(q_m) \quad (1)$$

Основная часть. Замеры остаточного покрытия поршневых колец проводились в пределах от 421 до 827 часов наработки. Частота замеров зависела от рейсового задания судна. Относительная ошибка замеров составила 0,26 %, при систематической ошибке измерительного прибора $\pm 1,5$ %. При определении остаточной толщины покрытия поршневых колец была принята

ошибка измерения $\pm 1,5$ %. При анализе износа поршневых колец на установившемся режиме двигателя в течение длительного времени были получены значения распределения износа по составляющим. Гистограмма распределения влияния факторов износа представлена на рис. 2.




Рис.2. Гистограмма распределения влияния факторов износа

В процессе исследования были накоплены данные, характеризующие факторы и степень износа поршневых колец и рабочих параметров цилиндропоршневой группы. Для обработки имеющихся данных предлагается использовать нейронную сеть [17], которая по входным признакам будет определять степень износа поршневых колец.

Для решения поставленной задачи аппроксимации интенсивности износа будет достаточно возможностей простой сети с прямым распространением [18–20].

Нейронная сеть для аппроксимации данных об износе создана с использованием пакета Neural Networks Toolbox Matlab. Построена сеть, состоящая из входного слоя, скрытого слоя и выходного слоя. В качестве аппроксимирующей сети выбрана двухслойная сеть прямого распространения. Скрытый слой состоит из 40 нейронов с передаточной функцией тангенциальной сигмиды:

$$f(x) = \text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

На рис. 3 представлена схема построения нейронной сети в среде MATLAB. Цифрами под блоками обозначены количество параметров на входе и выходе нейронной сети и количество нейронов для скрытого и выходного слоя. Значение w – это вес нейрона, на который умножается входное значение. А обозначение b является коэффициентом смещения.

Оптимальное количество слоёв и нейронов в слоях подбиралось на основании результатов обучения нейронной сети. Слишком сложная архитектура нейронной сети, чрезмерно большое количество входных параметров и слишком долгое обучение на одной и той же выборке данных могут привести к переобучению сети и, соответственно, ошибкам в её ответах. Так же для нейронной сети со сложной и большой архитектурой требуется большая выборка обучающих данных. При этом нейронная сеть со слишком малым количеством слоёв или нейронов может быть не эффективной, что зависит от задач выполняемой этой сетью.




Рис. 3. Структура аппроксимирующей нейронной сети

Основным принципом обучения сети такого вида является обратное распространение ошибки. Функцией производительности по умолчанию для сетей с прямой связью является среднеквадратическая ошибка mse – среднеквадратическая ошибка между выходными данными сети и целевыми выходными данными.

При построении сети входными параметрами для обучения выбраны мощность двигателя и удельный расход цилиндрического масла. Выбор двух параметров определяется возможностью его визуализации построением поверхности аппроксимации.




Рис. 4. Настройки нейронной сети: а – алгоритм обучения; б – процесс обучения сети

Как видно из рис. 4б, сеть достигла оптимального результата обучения после 49 циклов итераций.

Обучение сети прекращалось при возникновении любого из условий:

- Достигнуто максимальное количество epochs (повторений).
- Градиент производительности падает ниже $mingrad$.

Важной особенностью для получения хорошего результата работы нейронной сети является подготовка данных, в данном случае нормирование функции. Оптимальным диапазоном для входных данных является диапазон (0;1) или (-1;1). При выборе сигмоиды в качестве функции активации рекомендуют уменьшить интервал до (0,1;0,9). Таким образом, мощность двигателя для входного слоя должна быть масштабирована до этого предела. Наилучшим выходом из положения является выражение мощности в процентах, а точнее в долях единицы. На рис. 4 показаны настройки алгоритма обучения и процесс обучения.

- Шаг обучения μ начинал превышать его максимально допустимое значение $\mu_{max} = 1e10$.

Производительность валидации увеличилась более чем max_fail в разы с момента последнего снижения (при использовании валидации).

На рис. 5 показаны параметры обучения: градиент «gradient», параметр адаптации алгоритма « μ », среднеквадратичное отклонение «ssX», и ошибка проверки «val fail».




Рис. 5. Параметры обучения

Результаты. В результате обучения получена аппроксимационная зависимость, описывающая связь выбранных факторов с износом. Тестовая выборка показала сходимость обученной сети с данными измерений с отклонением до 9%.

Результаты приведены в таблице 1. В дальнейшем, для уменьшения отклонения, следует использовать большую выборку экспериментальных данных для более эффективного обучения нейронной сети и более двух входных параметров [21].

Таблица 1

Результаты обработки экспериментальных данных нейронной сетью

Мощность двигателя, %	Удельный расход цилиндрического масла, г/кВтч	Интенсивность износа по ИНС, мкм/ч	Фактическая интенсивность износа, мкм/ч	Отклонение, %
54	0,8	0,011023	0,01061	-3,8
54	1,2	0,01105	0,01055	-4,5
82	0,8	0,01495	0,01413	-5,5
82	1,2	0,01015	0,01106	9
55	0,85	0,01087	0,01058	-2,7
55	0,8	0,01113	0,01058	-4,9
56	0,82	0,01105	0,01083	-1,9
56	0,85	0,01077	0,01082	0,5
56	0,86	0,01070	0,01082	1,1
57	0,85	0,01083	0,01107	2,2
57	0,87	0,01064	0,01021	-4,1
58	0,87	0,01070	0,01024	-4,2
58	0,88	0,01059	0,01024	-3,2
58	0,91	0,01033	0,00984	-4,7
59	0,93	0,01015	0,01007	-0,8
61	0,94	0,01007	0,01053	4,5
63	0,96	0,00997	0,01046	4,9
65	0,96	0,01027	0,01070	4,2
66	0,97	0,01026	0,01076	4,9
66	1	0,00978	0,00999	2,1
67	1,01	0,00980	0,01020	4,1
69	1,03	0,00986	0,01002	1,6
69	1,06	0,00978	0,01000	2,3
73	1,08	0,01008	0,01085	7,6
74	1,09	0,01013	0,01037	2,3
75	1,12	0,01032	0,01055	2,2
76	1,15	0,01059	0,01073	1,3
77	1,16	0,01059	0,01092	3,2
77	1,2	0,01123	0,01204	7,2
80	1,2	0,01060	0,01086	2,5

На рис. 6 представлена аппроксимирующая поверхность, построенная нейронной сетью и описывающая связь интенсивности износа с мощностью и удельным расходом цилиндрического масла. По оси абсцисс и ординат – мощность и удельный расход масла, по оси аппликат – интенсивность износа керамометаллического покрытия. Из поверхности видно, что существуют комбинации экстремальных значения мощности, при которых износ максимален. На максимальной мощности при малом расходе топлива износ колец снижается. Данная информация должна быть включена в эксплуатационные документы.

Выводы. В работе получены зависимости, определяющие связь интенсивности износа поршневых колец исследуемого двигателя с режимами работы двигателя. Это позволяет повысить эффективность и оптимизировать проведение обслуживания ЦПГ.

Определен неоднозначный характер влияния факторов на износ. Полученные результаты могут быть применены на практике для разработки алгоритма, прогнозирующего календарную дату капитального ремонта цилиндра с учетом факторов износа.

Полученная при помощи нейронной сети аппроксимирующая зависимость с увеличением набора данных измерений и наблюдений может

быть расширена путем ввода новых параметров, таких как влажность и температура.

Кроме того, в совокупности с численными структурными иерархическими моделями технологических процессов нейронные модели могут

использоваться при создании цифровых двойников судна.




Рис. 6. Визуализация аппроксимирующей поверхности интенсивности износа, построенная нейронной сетью

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Kaminski W., Michalska-Pozoga I. Possibility of Marine Low-Speed Engine Piston Ring Wear Prediction during Real Operational Conditions // *Energies*. 2023. Vol. 16. No. 3. 1433. DOI: 10.3390/en16031433.
2. Tuninetti V., Menacer B., Narayan S. Theoretical analysis of the piston ring pack for predicting friction and power loss in an internal Combustion Engine // *Structural Integrity and Life*. 2024. Vol. 24. No. 2. Pp. 193–198. DOI: 10.69644/ivk-2024-02-0193.
3. Авт. свид. № 1770817 СССР, МПК G01N 3/56. Способ измерения величины износа поршневых колец судового двигателя/ Карпов Л. И., Бурьянов В. Н.; заявитель Центральный научно-исследовательский и проектно-конструкторский институт морского флота. №4852137/28; заявл. 11.07.1990; опубл. 23.10.1992. 3 с.
4. Пат. 009611051, Российская Федерация, МПК G01M 15/00 (1995.01). Способ определения степени изношенности элементов цилиндропоршневой группы судового дизеля/ Котешов А. А.; заявитель Котешов А. А. № 96110151/06; заявл. 21.05.1996; опубл. 20.08.1998. 1 с.
5. Нечаев Е.П. Безразборный контроль интенсивности изнашивания деталей цилиндропоршневой группы дизелей // *Вестник МГТУ*. 2013. № 4 (16). С. 771–776.
6. Овчаренко С.М., Минаков В.А. Теоретическое и экспериментальное исследование закономерностей изнашивания деталей дизеля типа Д49 // *Известия Транссиба*. 2013. № 3 (15). С. 55–61.
7. Сагин С.В. Оптимизация расхода высокощелочного цилиндрического масла судовых малооборотных дизелей // *Universum: Технические науки: электронный научный журнал*. 2016. № 7 (28). URL: <http://7universum.com/ru/tech/archive/item/3385> (дата обращения: 23.12.2025).
8. Овчаренко С.М. Распознавание катастрофического изнашивания деталей дизеля на основе модели нейронной сети // *Омский научный вестник*. 2006. № 10 (48). С. 49–51.
9. Дзюбин Д.В., Иванов В.И. Методы оценки износа пары цилиндр-поршневое кольцо в двигателях внутреннего сгорания транспортных и технологических машин // *Омский научный вестник*. 2009. №3 (83). С. 114–117.
10. Erulan G., Saleem M., Chandan S., Nema A. Thermal and Static analysis of Engine Piston rings. // *International Journal of Ambient Energy*. 2019. Vol. 1. No. 43. Pp. 300–304. DOI: 10.1080/01430750.2019.1636875.
11. Bouzana A., Guermat A., Belarifi F. Experimental Results of a Hydrodynamic Friction Behaviour of a Linear Contact at Low Sliding Velocity // *International Conference on Tribology (BalkanTRib'17At: Cappadocia/TURKEY)*. 2017. 1177.

12.Ferreira, R., Carvalho Ó., Pires J., Sobral L., Carvalho S., Silva F. A New Tribometer for the Automotive Industry: Development and Experimental Validation // *Experimental Mechanics*. 2022. Vol. 62. Pp. 483–492. DOI: 10.1007/s11340-021-00805-7.

13.Ferreira R., Martins J., Carvalho O., Sobral L., Carvalho S., Silva F. Tribological solutions for engine piston ring surfaces: an overview on the materials and manufacturing // *Materials and Manufacturing Processes*. 2019. Vol. 5(35). Pp. 1–23. DOI: 10.1080/10426914.2019.1692352.

14.Khachkinayan A., Zharkov Yu., Zubkov V., Novakovich V., Ermakov V. Investigation of piston ring wear engines by the mathematical statistics method // *Journal of Physics Conference Series*. 2021. Vol. 2 (2131). 022038. DOI: 10.1088/1742-6596/2131/2/022038.

15.Wakuri Y., Kitahara T., Hamatake T., Soejima M. Characteristics of Piston Ring Friction Influences of Piston Ring Specifications. *Transactions of the Japan Society of Mechanical Engineers Part C*. 1996. Vol. 62(599). Pp. 2811–2817.

16.Гринек А.В., Бойчук И.П., Фищенко А.М., Алексянц С.Ю., Слепов О.Е., Чирков Е.Н. Объектно-ориентированное моделирование су-

довых пропульсивных систем // *Вестник Астраханского государственного технического университета. Серия: Морская техника и технология*. 2025. № 1. С. 88–99. DOI:10.24143/2073-1574-2025-1-88-99. EDN ZPIOPM.

17.Покусаев М.Н., Касимов Н.Н. Система диагностики судовых энергетических установок с применением нейросетевых моделей // *Вестник АГТУ. Сер.: Управление, вычислительная техника и информатика*. 2012. № 2. С. 88–93

18.Huang S., Zhang H.C. Neural networks in manufacturing: A survey // *Electronic Manufacturing Technology Symposium Fifteenth IEEE/CHMT International*. 1993. Pp. 177–190.

19. Современное машиностроение: наука и образование 2025, под редакцией: А.Н. Евграфова, А. А. Поповича. Санкт-Петербург: ПОЛИТЕХ-ПРЕСС. 2025. DOI: 10.18720/SPBPU/2/i25-199.

20.Simonova L.A., Egorova E.I., Akhmadiev A.I. Neural Networks in Manufacturing // *Russian Engineering Research*. 2022. Vol. 42. Pp. 278–281. DOI: 10.3103/S1068798X22030224.

21.Bashkatov V., Khudyakov S., Ignatenko A. Gas fuel combustion and related problems // *Journal of Physics: Conference Series*. 2021. Vol. 2061. Pp. 012059. DOI: 10.1088/1742-6596/2061/1/012059.

Информация об авторах

Гринек Анна Владимировна, кандидат технических наук, доцент. E-mail: grinyokann@gmail.com. ООО «Сигматек». Россия, 191119, город Санкт-Петербург, Днепропетровская ул, д. 33 литера А, помещ. 10(4н).

Фищенко Артем Михайлович, инженер. E-mail: fishenko2012@gmail.com. ООО «Сигматек». Россия, 191119, город Санкт-Петербург, Днепропетровская ул, д. 33 литера А, помещ. 10(4н).

Бойчук Игорь Петрович, кандидат технических наук, доцент. E-mail: igor_boichuk@mail.ru. ООО «Сигматек». Россия, 191119, город Санкт-Петербург, Днепропетровская ул, д. 33 литера А, помещ. 10(4н).

Башкатов Владимир Александрович, старший механик. E-mail: Bashkatov_vladimir@inbox.ru. Северная морская компания LTD, Глазго, G81 2QR, Шотландия, Великобритания.

Перельгин Дмитрий Николаевич, старший преподаватель. E-mail: mehanikus@mail.com. Белгородский государственный технологический университет им. В.Г. Шухова. Россия, 308012, г. Белгород, ул. Костюкова 46, БГТУ им. В. Г. Шухова.

Поступила 19.12.2025 г.

© Гринёк А.В., Фищенко А.М., Бойчук И.П., Башкатов В.А., Перельгин Д.Н., 2026

^{1,*}Grinek A.V., ¹Fishenko A.M., ¹Boychuk I.P., ²Bashkatov V.A., ³Perelygin D.N.

¹Sigmatek LLC

²Northern Marine Company LTD

³Belgorod State Technological University named after V.G. Shukhov

PREDICTION OF PISTON RING WEAR IN MARINE MAIN ENGINE USING NEURAL NETWORKS

Abstract. The article shows the results of using a neural network to approximate the data of experimental studies of the wear of the ceramic-metal coating of the piston rings of ship engines. A structural diagram is proposed that qualitatively describes the ambiguous nature of the relationship between wear and a set of

operational parameters. The coating of piston rings of operating ship engines 6S50ME-C-GI with electronic control was measured. The condition of the piston rings of the marine main engine determines a number of parameters that determine the operating conditions and reliability of the engine. Factor analysis of the effect of structural and technological parameters on the wear of piston rings was carried out. The specific consumption of cylinder oil and engine power are selected as the main factors affecting wear. A neural network was used to process the accumulated data. Taking into account the size of the training data, the network structure is shown, which describes the functional relationship between fuel consumption and engine power with wear, data arrays for its operation are determined and the network is trained. As a result of the operation of the neural network, an approximating surface of wear of rings and a combination of significant parameters is obtained, at which wear is maximum. The obtained results can be applied in practice to develop an algorithm that predicts the calendar date of overhaul of the cylinder, taking into account wear factors.

Keywords: piston rings, wear, neural networks, diagnostics, maintenance of the cylinder piston group.

REFERENCES

1. Kaminski W., Michalska-Pozoga I. Possibility of Marine Low-Speed Engine Piston Ring Wear Prediction during Real Operational Conditions. *Energies*. 2023. Vol. 16. No. 3. 1433. DOI: 10.3390/en16031433.
2. Tuninetti V., Menacer B., Narayan S. Theoretical analysis of the piston ring pack for predicting friction and power loss in an internal Combustion Engine. *Structural Integrity and Life*. 2024. Vol. 24. No. 2. Pp. 193–198. DOI: 10.69644/ivk-2024-02-0193.
3. Karpov LI., Buryanov V.N. Method for measuring the wear value of piston rings of a marine engine. Patent RF, no. 4852137/28, 1992.
4. Koteshev A.A. Method for determining the degree of wear of elements of the cylinder-piston group of a marine diesel engine. Patent RF, no. 009611051, 1998.
5. Nechayev E.P. In-place monitoring of wear intensity of parts of the cylinder-piston group of diesel engines [Bezrazborny'j kontrol' intensivnosti iznashivaniya detalej cilindroporshnevoj gruppy' dizelej]. *Bulletin of Moscow State Technical University*. 2013, Vol. 4. No. 4. Pp. 771–776.
6. Ovcharenko, S. M. Theoretical and experimental study of wear patterns of diesel engine parts type D49 [Teoreticheskoe i eksperimental'noe issledovanie zakonomernostej iznashivaniya detalej dizelya tipa D49]. *Transsib News*. 2013. Vol. 15. No. 3. Pp. 55–61.
7. Sagin, S. V. Optimization of consumption of highly alkaline cylinder oil of marine low-speed diesel engines [Optimizaciya rasxoda vy'sokoshhelochnogo cilindrovogo masla sudovy'x maloborotny'x dizelej] *Universum: Technical sciences: electronic scientific journal*. 2016. Vol. 28. No. 7. URL: <http://7universum.com/ru/tech/archive/item/3385>
8. Ovcharenko, S. M. Recognition of catastrophic wear of diesel engine parts based on a neural network model [Raspoznavanie katastroficheskogo iznashivaniya detalej dizelya na osnove modeli nejronnoj seti] *Omsk Scientific Bulletin*. 2006. Vol. 48. No. 10. Pp. 49–51.
9. Dzyubin, D. V. Methods for assessing the wear of a cylinder-piston ring pair in internal combustion engines of transport and technological machines [Metody' ocenki iznosa pary' cilindroporshnevoe kol'cho v dvigatelyax vnutrennego sgoraniya transportny'x i texnologicheskix mashin]. *Omsk Scientific Bulletin*. 2009. Vol. 83. No. 3. Pp. 114–117.
10. Erulan G., Saleem M., Chandan S., Nema A. Thermal and Static analysis of Engine Piston rings. *International Journal of Ambient Energy*. 2019. Vol. 1. No. 43. Pp. 300–304. DOI: 10.1080/01430750.2019.1636875.
11. Bouzana A., Guermat A., Belarifi F. Experimental Results of a Hydrodynamic Friction Behaviour of a Linear Contact at Low Sliding Velocity. *International Conference on Tribology (BalkanTRIB'17At: Cappadocia/TURKEY)*. 2017. 1177.
12. Ferreira, R., Carvalho Ó., Pires J., Sobral L., Carvalho S., Silva F. A New Tribometer for the Automotive Industry: Development and Experimental Validation. *Experimental Mechanics*. 2022. Vol. 62. Pp. 483–492. DOI: 10.1007/s11340-021-00805-7.
13. Ferreira R., Martins J., Carvalho O., Sobral L., Carvalho S., Silva F. Tribological solutions for engine piston ring surfaces: an overview on the materials and manufacturing. *Materials and Manufacturing Processes*. 2019. Vol. 5(35). Pp. 1–23. DOI: 10.1080/10426914.2019.1692352.
14. Khachkinayan A., Zharkov Yu., Zubkov V., Novakovich V., Ermakov V. Investigation of piston ring wear engines by the mathematical statistics method. *Journal of Physics Conference Series*. 2021. Vol. 2 (2131). 022038. DOI: 10.1088/1742-6596/2131/2/022038.
15. Wakuri Y., Kitahara T., Hamatake T., Soejima M. Characteristics of Piston Ring Friction Influences of Piston Ring Specifications. *Transactions of the Japan Society of Mechanical Engineers Part C*. 1996. Vol. 62. No. 599. Pp. 2811–2817.
16. Grinek A. V., Boychuk I. P., Fishchenko A. M., Aleksyants S. Yu., Slepov O. E., Chirkov E. N. Object-oriented modeling of ship propulsion systems

[Ob`ektно-orientirovannoe modelirovanie sudovy`x propul'sivny`x sistem]. Bulletin of Astrakhan State Technical University. Series: Marine Engineering and Technology. 2025. No. 1. Pp. 88–99. DOI: 10.24143/2073-1574-2025-1-88-99. EDN ZPIOPM.

17. Pokusaev, M. N. Diagnostic system for ship power plants using neural network models [Sistema diagnostiki sudovy`x e`nergeticheskikh ustanovok s primeneniem nejrosetevy`x modelej]. Bulletin of ASTU. Series: Management, computing technology and informatics. 2012. No.2. Pp. 88–93.

18. Huang S., Zhang H.C. Neural networks in manufacturing: A survey. Electronic Manufacturing

Technology Symposium Fifteenth IEEE/CHMT International. 1993. Pp. 177–190.

19. Modern Mechanical Engineering: Science and Education 2025: proceedings of the 14th International Scientific Conference, Russia, June 18, 2025. DOI 10.18720/SPBPU/2/i25-199.

20. Simonova L.A., Egorova E.I., Akhmadiev A.I. Neural Networks in Manufacturing. Russian Engineering Research. 2022. Vol. 42. Pp. 278–281. DOI: 10.3103/S1068798X22030224.

21. Bashkatov V., Khudyakov S., Ignatenko A. Gas fuel combustion and related problems. Journal of Physics: Conference Series. 2021. Vol. 2061. Pp. 012059. DOI: 10.1088/1742-6596/2061/1/012059.

Information about the authors

Grinek, Anna V., PhD, associate professor. E-mail: grinyokann@gmail.com. Sigmatek LLC. Russia, 191119, Sankt-Peterburg, Dnepropetrovskaya st., 33/A/10(4H).

Fishenko, Artem M., engineer. E-mail: fishenko2012@gmail.com. Sigmatek LLC. Russia, 191119, Sankt-Peterburg, Dnepropetrovskaya st., 33/A/10(4H).

Boychuk, Igor P., PhD, associate professor. E-mail: igor_boichuk@mail.ru. Sigmatek LLC. Russia, 191119, Sankt-Peterburg, Dnepropetrovskaya st., 33/A/10(4H).

Bashkatov, Vladimir A., chief engineer. E-mail: Bashkatov_vladimir@inbox.ru. Northern marine management ltd, Glasgow, G81 2QR, United Kingdom

Perelygin, Dmitrij N., senior lecturer. E-mail: mehanikus@mail.com. Belgorod State Technological University named after V.G. Shukhov. Russia, 308012, Belgorod, st. Kostyukova, 46.

Received 19.12.2025

Для цитирования:

Гринёк А.В., Фищенко А.М., Бойчук И.П., Башкатов В.А., Перельгин Д.Н. Прогнозирование интенсивности износа поршневых колец судового главного двигателя с использованием нейронных сетей // Вестник БГТУ им. В.Г. Шухова. 2026. № 5. С. 125–133. DOI: 10.34031/2071-7318-2026-11-5-125–133

For citation:

Grinek A.V., Fishenko A.M., Boychuk I.P., Bashkatov V.A., Perelygin D.N. Prediction of piston ring wear in marine main engine using neural networks. Bulletin of BSTU named after V.G. Shukhov. 2026. No. 5. Pp. 125–133. DOI: 10.34031/2071-7318-2026-11-5-125-133