

doi: 10.17586/2226-1494-2026-26-2-393-401

УДК 004.032.26, 004.94, 539.37

Прогнозирование максимальных напряжений в системе «вал–вкладыш» с помощью нейронной сети

Алексей Иванович Боровков¹, Анна Станиславовна Карчевская^{2✉},
Алексей Дмитриевич Новокшенов³, Анастасия Игоревна Матвеева⁴,
Сергей Сергеевич Щербаков⁵, Никита Михайлович Климович⁶,
Дарья Александровна Подгайская⁷, Михаил Михайлович Полещук⁸

^{1,2,3,4} Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, 195251, Российская Федерация

⁵ Национальная академия наук Беларуси, Минск, 220072, Республика Беларусь

^{5,7} Объединенный институт машиностроения НАН Беларуси, Минск, 220072, Республика Беларусь

^{6,8} Белорусский государственный университет, Минск, 220030, Республика Беларусь

¹ vicerector.ap@spbstu.ru, <https://orcid.org/0000-0003-3177-0959>

² karchevskaya_as@spbstu.ru✉, <https://orcid.org/0009-0008-2905-8448>

³ novoksh_ad@spbstu.ru, <https://orcid.org/0000-0001-5874-5994>

⁴ matveeva_ai@spbstu.ru, <https://orcid.org/0009-0009-8189-0300>

⁵ sherbakovssr@yandex.by, <https://orcid.org/0000-0001-6404-6129>

⁶ Nikita.klimovitch@yandex.ru, <https://orcid.org/0009-0001-7204-1974>

⁷ dapodgayskaya@gmail.com, <https://orcid.org/0009-0009-8988-6939>

⁸ mikhailpaliashchuk@yandex.ru, <https://orcid.org/0000-0003-2701-2194>

Аннотация

Введение. Надежность работы машин во многом зависит от точности прогноза напряженно-деформированного состояния деталей трибофатических систем, особенно при высоких эксплуатационных нагрузках. Традиционные конечно-элементные расчеты обеспечивают высокую точность, однако характеризуются значительными вычислительными затратами и ограниченной возможностью быстрого варьирования параметров. В последние годы в инженерной практике все чаще применяются методы машинного обучения. Среди них нейронные сети представляют особый интерес, так как они позволяют описывать нелинейные зависимости между параметрами нагрузки и напряжениями, а также существенно ускоряют расчет по сравнению с традиционными моделями. **Метод.** Предложен подход к прогнозированию максимальных напряжений в системе «вал–вкладыш» с применением трехмерного конечно-элементного моделирования и последующего построения нейросетевой модели. Сформирована база данных, включающая результаты численных экспериментов при различных комбинациях изгибных и контактных нагрузок. Для обучения использовалась трехслойная полносвязная нейронная сеть с различными функциями активации каждого слоя. Выполнена оценка качества модели с помощью стандартных метрик Mean Squared Error, Mean Absolute Error и коэффициента детерминации R^2 . **Основные результаты.** Полученная нейронная сеть продемонстрировала высокую точность при прогнозировании максимальных напряжений как в вале, так и во вкладыше. Для обучающей выборки значение R^2 составило 0,99991, а для тестовой — 0,99984, что подтверждает минимальные отклонения от данных конечно-элементных расчетов. Значение MAE составило менее 0,006, а максимальная относительная ошибка на тестовой выборке не превысила 3,2 %. **Обсуждение.** Разработанная нейросетевая модель показала способность к воспроизведению результатов конечно-элементного анализа для системы «вал–вкладыш», обеспечивая при этом значительное сокращение времени вычислений по сравнению с традиционным конечно-элементным моделированием. Модель построена для ограниченного диапазона нагрузок, поэтому дальнейшие исследования будут направлены на расширение исходного набора и включение новых материалов, что позволит оценить масштабируемость подхода и его устойчивость при усложнении условий.

Ключевые слова

нейронные сети, машинное обучение, трибофатическая система, максимальные напряжения, напряженно-деформированное состояние, чугуны «МОНИКА», механика твердого тела, конечно-элементное моделирование, контактное взаимодействие

© Боровков А.И., Карчевская А.С., Новокшенов А.Д., Матвеева А.И., Щербаков С.С., Климович Н.М., Подгайская Д.А., Полещук М.М., 2026

Благодарности

Работа выполнена при поддержке Санкт-Петербургского государственного автономного учреждения "Фонд поддержки научной, научно-технической, инновационной деятельности", проект № 23-РБ-09-27 от 15.12.2023, а также при поддержке Белорусского республиканского фонда фундаментальных исследований (проект № T24СПбГ-003).

Ссылка для цитирования: Боровков А.И., Карчевская А.С., Новокшенов А.Д., Матвеева А.И., Щербаков С.С., Климович Н.М., Подгайская Д.А., Полещук М.М. Прогнозирование максимальных напряжений в системе «вал–вкладыш» с помощью нейронной сети // Научно-технический вестник информационных технологий, механики и оптики. 2026. Т. 26, № 2. С. 393–401. doi: 10.17586/2226-1494-2026-26-2-393-401

Prediction of maximum stresses in the “shaft–insert” system using a neural network

Aleksei I. Borovkov¹, Anna S. Karchevskaia²✉, Aleksei D. Novokshenov³,
Anastasia I. Matveeva⁴, Sergei S. Sherbakov⁵, Nikita M. Klimovich⁶,
Daria A. Podgayskaya⁷, Mikhail M. Poleschuk⁸

^{1,2,3,4} Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, 195251, Russian Federation

⁵ National Academy of Sciences of Belarus, Minsk, 220072, Belarus

^{5,7} The Joint Institute of Mechanical Engineering of the National Academy of Sciences of Belarus, Minsk, 220072, Belarus

^{6,8} Belarusian State University (BSU), Minsk, 220030, Belarus

¹ vicerector.ap@spbstu.ru, <https://orcid.org/0000-0003-3177-0959>

² karchevskaya_as@spbstu.ru✉, <https://orcid.org/0009-0008-2905-8448>

³ novoksh_ad@spbstu.ru, <https://orcid.org/0000-0001-5874-5994>

⁴ matveeva_ai@spbstu.ru, <https://orcid.org/0009-0009-8189-0300>

⁵ sherbakovssr@yandex.by, <https://orcid.org/0000-0001-6404-6129>

⁶ Nikita.klimkovitch@yandex.ru, <https://orcid.org/0009-0001-7204-1974>

⁷ dapodgayskaya@gmail.com, <https://orcid.org/0009-0009-8988-6939>

⁸ mikhailpaliashchuk@yandex.ru, <https://orcid.org/0000-0003-2701-2194>

Abstract

The reliability of machines largely depends on the accuracy of predicting the stress–strain state of components in tribo-fatigue systems, especially under high operating loads. Traditional finite element analysis provides high accuracy but requires significant computational resources and offers limited flexibility for rapid parameter variation. In recent years, machine learning methods have been increasingly applied in engineering practice. Among them, neural networks are of particular interest, as they allow nonlinear relationships between loads and stresses to be captured while significantly reducing computation time compared to traditional models. This work proposes an approach for predicting maximum stresses in the “shaft–insert” system by combining three-dimensional finite element modeling with subsequent neural network training. A database was created containing the results of numerical experiments for different combinations of bending and contact loads. A fully connected neural network with three hidden layers and different activation functions was used for training. The quality of the model was assessed using standard metrics: Mean Squared Error, Mean Absolute Error (MAE), and the coefficient of determination R^2 . The trained neural network demonstrated high accuracy in predicting maximum stresses both in the shaft and in the insert. For the training set, the R^2 value reached 0.99991, and for the test set it was 0.99984, confirming minimal deviations from finite element results. The MAE was less than 0.006, while the maximum relative error in the test set did not exceed 3.2 %. The developed neural network model demonstrated the ability to reproduce the results of finite element analysis for the “shaft–insert” system while providing a substantial reduction in computation time compared to traditional finite element simulations. The model was constructed for a limited range of loads; therefore, further research should focus on expanding the dataset and including additional materials, which will make it possible to evaluate the scalability of the approach and its robustness under more complex conditions.

Keywords

neural networks, machine learning, tribo-fatigue system, stress–strain state, maximum stresses, MONICA, solid mechanics, finite element modeling, contact interaction

Acknowledgements

This work was supported by the Russian Science Foundation (project No. 23-RB-09-27, 15.12.2023) and the Belarusian Republican Foundation for Fundamental Research (project No. T24SPbG-003).

For citation: Borovkov A.I., Karchevskaia A.S., Novokshenov A.D., Matveeva A.I., Sherbakov S.S., Klimovich N.M., Podgayskaya D.A., Poleschuk M.M. Prediction of maximum stresses in the “shaft–insert” system using a neural network. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2026, vol. 26, no. 2, pp. 393–401 (in Russian). doi: 10.17586/2226-1494-2026-26-2-393-401

Введение

Современное машиностроение характеризуется постоянным ростом эксплуатационных нагрузок и повышением требований к долговечности и надежности

узлов трения. В этих условиях ключевое значение приобретает точность прогнозирования напряженно-деформированного состояния трибофатигических систем, от которого напрямую зависят износостойкость и сопротивление усталости [1, 2]. В последние годы в ис-

следованиях активно используется концепция трибофаттики, объединяющая подходы трибологии и механики усталости. Она позволяет рассматривать процессы износа и накопления повреждений в комплексе, включая определение опасных объемов и зон концентрации напряжений [3].

Классические методы расчета, основанные на конечно-элементном моделировании, продемонстрировали высокую эффективность при анализе контактных задач и усталостных процессов [2, 3]. С их помощью получены фундаментальные результаты для систем «вал–вкладыш» и новых конструкционных материалов. В частности, для чугуна «МОНИКА» (название чугуна образовано от легирующих элементов Mo, Ni и Cu, которые определяют его микроструктуру и совокупность свойств) показано, что он обладает повышенной износостойкостью, сочетает высокую прочность с растущей пластичностью и демонстрирует улучшенную усталостную долговечность по сравнению с традиционными чугунами сплавами [4, 5]. Эти работы заложили основу для использования чугуна «МОНИКА» в составе трибофатических систем, включая парные контакты типа «вал–вкладыш».

Однако применение конечно-элементного моделирования связано с большими вычислительными затратами и ограниченными возможностями варьирования параметров при поиске оптимальных условий эксплуатации. Для преодоления этих ограничений в инженерной практике все чаще применяются методы машинного обучения. В работе [6] показано, что машинное обучение и нейронные сети становятся важным инструментом в трибологии, в том числе для моделирования износа, контактных напряжений и усталости.

В [7, 8] представлена эффективность машинного обучения для анализа трибологических процессов. Например, методы машинного обучения использовались для оптимизации микротекстурированных поверхностей и повышения их трибологических характеристик, а также для прогноза долговечности при фреттинговой усталости. Эти результаты подтверждают высокую перспективность применения искусственных нейронных сетей в смежных задачах.

Особое развитие в последние годы получили суррогатные модели на основе нейронных сетей, которые позволяют существенно ускорять расчеты напряженно-деформированного состояния и воспроизводить результаты конечно-элементного анализа. Например, глубокие нейронные сети применялись для быстрого восстановления распределений напряжений [9], сравнивались по точности при моделировании поликристаллических и упругопластических материалов [10, 11], использовались для оценки ошибок конечно-элементных моделей [12]. В ряде исследований рассмотрены новые архитектуры и методы: применение графовых нейронных сетей для работы с нерегулярными сетками [13], сравнение различных подходов для панельных конструкций [14], использование искусственных нейронных сетей для постобработки топологической оптимизации [15] и прогноза усталостной долговечности на основе данных конечно-элементного моделирования [16]. Совокупно эти работы демонстрируют возмож-

ности нейросетей в построении точных и быстрых предсказательных моделей в механике твердого тела.

Несмотря на значительные успехи, большинство существующих исследований сосредоточено на задачах материаловедения или на отдельных трибологических процессах. Применение нейросетей в комплексных трибофатических системах, где одновременно действуют контактные и вне-контактные нагрузки, пока ограничено. Это открывает возможность для разработки новых суррогатных моделей, адаптированных к задачам трибофаттики и учитывающих специфику эксплуатации деталей.

Цель настоящей работы заключается в разработке нейросетевой суррогатной модели для прогнозирования максимальных напряжений в системе «вал–вкладыш» с чугуном «МОНИКА». Для достижения поставленной цели решаются следующие задачи:

- формирование базы данных результатов численных расчетов напряженно-деформированного состояния при различных комбинациях нагрузок;
- обучение нейронной сети на основе метода Левенберга–Марквардта;
- оценка точности модели по стандартным метрикам (Mean Square Error (MSE), Mean Absolute Error (MAE), коэффициент детерминации (R^2));
- анализ применимости нейросетевого подхода для воспроизведения результатов конечно-элементного моделирования.

В работе рассматривается ограниченная постановка задачи с двумя входными параметрами (контактной и изгибающей нагрузками), что позволяет изолированно оценить способность нейросетевой модели воспроизводить результаты конечно-элементного анализа. Такой подход обеспечивает валидацию метода на простейшем, но физически содержательном примере, прежде чем переходить к более сложным системам с множеством различных входных параметров.

Материалы и методы

Рассмотрим систему «вал–вкладыш», которая является примером простейшей трибофатической системы, предназначенной для испытаний на фрикционно-механическую усталость и позволяющей изучить взаимное влияние нормальных и изгибных нагрузок на распределение напряжения. В системе «вал–вкладыш» вал выполнен из стали, по упругим характеристикам соответствующей конструкционным сталям типа Ст45 (AISI 1045), а вкладыш выполнен из чугуна «МОНИКА» [17].

Чугун «МОНИКА» обладает повышенной долговечностью и меньшей склонностью к хрупким усталостным разрушениям по сравнению с традиционными высокопрочными чугунами, а также уникальным для конструкционных материалов сочетанием прочности и пластичности — при росте прочности пластичность не снижается, а увеличивается [18, 19]. Использование чугуна «МОНИКА» в качестве материала вкладыша позволяет оценить, как сочетание повышенной пластичности и прочности влияет на напряженное состояние пары по сравнению с традиционными сплавами.

Соответствующие каждому материалу системы «вал–вкладыш» характеристики приведены в табл. 1.

Для построения предсказательной модели была разработана и верифицирована трехмерная конечно-элементная модель в среде Ansys Workbench (рис. 1). Модель включала объемные элементы и учитывала контактное взаимодействие между валом и вкладышем.

Жесткое закрепление (A) наложено на коническую часть вала по всем степеням свободы. Контактная нагрузка (B) в виде нормальной силы приложена к верхней поверхности вкладыша. Изгибающая сила (C) действует на свободный конец вала. Для боковых поверхностей вкладыша заданы ограничения нормальных перемещений (D), а также контактное взаимодействие между деталями (E). Коэффициент трения принят равным $\mu = 0,3$. Диапазон нагрузок соответствует реальным режимам испытаний трибофатической пары: сила контактной нагрузки до 3000 Н, изгибающая сила от –200 Н до +200 Н. В зависимости от сценария нагружения рассматривались комбинации контактной и изгибающей силы.

Построенная конечно-элементная модель обеспечивает воспроизводимость ключевых факторов, определяющих напряженно-деформированное состояние трибофатической пары. На основе численных экспериментов были получены максимальные значения напряжений во вкладыше и в вале. Полученные зависимости и база данных легли в основу построения суррогатной модели с помощью нейронной сети.

Теоретические основы построения суррогатных моделей

Суррогатная модель не описывает объект напрямую, а аппроксимирует некоторую сложную модель этого

объекта на основе обучающего набора данных. При заданных размеченных данных, состоящих из пар входа и выхода $(x_1, y_1), \dots, (x_n, y_n)$ задача сводится к поиску аппроксимирующей функции, способной преобразовывать пространство параметров $f: X \rightarrow Y$. Искомая функция описывается выражением:

$$f(\mathbf{x}, \mathbf{w}) = \mathbf{y},$$

где $\mathbf{x}$ — вектор входов; $\mathbf{y}$ — выход (отклик) суррогатной модели; $\mathbf{w}$ — вектор параметров (весовых коэффициентов) нейросетевой модели.

Обучение модели с учителем заключается в оптимизации параметров $\mathbf{w}$, обеспечивающих наилучшее согласование расчетных и предсказанных значений:

$$\mathbf{w} := \underset{\mathbf{w}}{\operatorname{argmin}} \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i, \mathbf{w}))^2.$$

Для их настройки применяются различные методы оптимизации: стохастический и адаптивный градиентный спуск, метод Ньютона, Гаусса–Ньютона, Левенберга–Марквардта и др. Из-за ограниченного объема выборок, полученных путем численных расчетов, стандартные методы обучения нейронных сетей могут приводить к переобучению. При ограниченном объеме данных особое значение имеет регуляризация, позволяющая избежать переобучения и повысить устойчивость предсказаний.

В качестве алгоритма оптимизации выбран метод Левенберга–Марквардта, который сочетает устойчивость градиентного спуска на ранних стадиях обучения и высокую скорость сходимости метода Гаусса–Ньютона при приближении к минимуму.

Целевая функция метода имеет вид:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{s=1}^m [e_s(\mathbf{w})]^2,$$

$$e_s(\mathbf{w}) = y_s(\mathbf{w}) - \mathbf{d}_s,$$

где $\mathbf{d}$ — вектор экспериментальных данных; $y_s(\mathbf{w})$ — предсказанные значения суррогатной модели; $e_s(\mathbf{w})$ — невязки между предсказанными и эталонными значениями.

Таблица 1. Характеристики материалов системы «вал–вкладыш»

Table 1. Material characteristics

Материал	E , ГПа	ν , усл. ед.
Ст45 (AISI 1045)	200	0,30
Чугун «МОНИКА»	168	0,28

Примечание: E — модуль Юнга; ν — коэффициент Пуассона.




Рис. 1. Трехмерная модель системы «вал–вкладыш» и ее граничные условия (a); модель контактной поверхности (b)

Fig. 1. Geometry of the “shaft–insert” system and geometric conditions (a); geometry of the contact surface (b)

Таким образом, использование метода Левенберга–Марквардта обеспечивает устойчивое обучение нейронной сети при ограниченном объеме данных и делает возможным построение компактной, интерпретируемой модели для инженерных задач с малыми выборками.

Основная метрика, по которой определяется точность модели, — MSE. Дополнительно рассчитывается R^2 и MAE. Оптимальная нейронная сеть дает минимальный MSE и максимальный R^2 на валидации:

$$MSE = \sum_{i=1}^N \frac{1}{N} (y_i - d_i)^2,$$

где y_i — предсказанное значение; d_i — ожидаемое значение; N — количество экспериментов.

Построение нейронной сети

Для автоматизации построения суррогатной модели использовался разработанный в рамках работы модуль построения нейросетевых моделей AICore, являющийся составной частью подсистемы CML-Bench®. RomAI¹.

Перед началом построения архитектуры нейронной сети была выполнена предварительная обработка данных. В модели два входных параметра — изгибающая и контактная нагрузки и два выходных параметра — максимальные напряжения во вкладыше и в вале. Были отобраны 146 испытаний², в которых диапазон для силы контактной нагрузки от 0 до 3000 Н, для изгибающей — от 0 до 200 Н, причем изгибающая сила может менять направление, таким образом диапазон становится в два раза шире — от –200 Н до 200 Н. Исходный набор данных разделен случайным образом на обучающую и тестовую выборки. В тренировочной выборке 124 точки, в тестовой 22. Входные параметры прошли стандартизацию, а выходные значения были приведены к единому масштабу с помощью нормализации. Это позволило обеспечить корректное обучение сети и снизить риск численных искажений. Обучение выполнялось методом Левенберга–Марквардта с шагом $\mu = 0,01$ в течение 100 эпох.

Оптимально подобранная архитектура нейронной сети содержит три полносвязных скрытых слоя (рис. 2). В первом слое используется 12 нейронов, где активация выполняется с помощью гиперболического тангенса (tanh). Во втором слое задействовано 11 нейронов, которые работают с сигмоидальной функцией активации (sigmoid), а третий слой 12 нейронов (sigmoid).

Трехслойная полносвязная архитектура обеспечивает оптимальный баланс между сложностью и точностью аппроксимации. При меньшем числе слоев модель не воспроизводит нелинейную зависимость между




Рис. 2. Архитектура нейронной сети с оптимальными параметрами:

x_1 — входной параметр, отвечающий за контактную нагрузку; x_2 — входной параметр изгибающей силы; y_1 — выходной параметр, отражающий напряжение в вале; y_2 — выходной параметр напряжения во вкладыше

Fig. 2. Neural network architecture with optimal parameters:

x_1 is input parameter responsible for contact load; x_2 is input parameter of bending force; y_1 is output parameter reflecting shaft stress; y_2 is output parameter of bearing stress

нагрузками и напряжениями, тогда как дальнейшее увеличение глубины сети не дает прироста точности и приводит к переобучению. Подобранная структура соответствует малому числу входных и выходных параметров, сохраняя при этом достаточную гибкость для описания их взаимосвязей.

Оценка качества модели на обучающей и валидационной выборках³ демонстрирует уверенную точность предсказаний. R^2 для обучающей выборки составил 0,99991, что указывает на практически полное совпадение расчетных значений с исходными данными. Для тестовой выборки значение R^2 равно 0,99984, что подтверждает высокую точность аппроксимации и устойчивость модели на данных, не участвовавших в обучении.

MSE на обучающей выборке составляет порядка $6,68 \cdot 10^{11}$, а на тестовой — около $1,69 \cdot 10^{12}$. Это указывает на некоторое увеличение отклонений при переходе к новым данным, но значения остаются в допустимых пределах с учетом масштаба задачи. MAE также невелика: около 0,0032 при обучении и 0,0060 на тесте. Такие показатели подтверждают устойчивость и высокую точность модели при прогнозировании напряжений.

Результаты

Сравнение предсказанных напряжений с расчетами по полной конечно-элементной модели показало высокую точность работы нейронной сети как на обучаю-

¹ [Электронный ресурс]. Режим доступа: <https://sapr.ru/article/26897?ysclid=ml8jpbxy452509805> (дата обращения: 10.11.2025).

² Карчевская А.С., itmo_paper_NN_insert-shaft_system [Электронный ресурс] / А.С. Карчевская. Санкт-Петербург: GitHub, 2025. Режим доступа: https://github.com/Skholastika/itmo_paper_NN_insert-shaft_system (дата обращения: 10.11.2025).

³ Карчевская А.С., itmo_paper_NN_insert-shaft_system [Электронный ресурс] / А.С. Карчевская. Санкт-Петербург: GitHub, 2025. Режим доступа: https://github.com/Skholastika/itmo_paper_NN_insert-shaft_system (дата обращения: 10.11.2025).




Рис. 3. Сравнение предсказанных значений со значениями полной модели на обучающей (а) и тестовой (б) выборках
 Fig. 3. Comparison of predicted values with values from the full model on training (a) and test (b) samples

щей, так и на тестовой выборке (рис. 3). Наибольшая относительная ошибка на обучающей выборке составила 1,68 %, а при тестировании — 1,69 %, что свидетельствует о хорошей способности модели к обобщению.

Динамика обучения подтверждает устойчивую сходимость предложенной нейросетевой модели. На графике (рис. 4) для наглядности приведено изменение квадратного корня из среднеквадратичной ошибки (Root Mean Squared Error, RMSE) в процессе обучения нейронной сети. Ошибка на обучающей и тестовой выборках последовательно снижается с начального значения равного 1 до порядка 0,05 в течение 13 эпох и затем продолжает снижаться, демонстрируя стабильную сходимость модели вплоть до 100 эпохи. Параллельное снижение полученных графиков без расхождения указывает на отсутствие переобучения и хорошую обобщающую способность модели. Равномерный характер снижения ошибки свидетельствует о хорошо подобранных гиперпараметрах обучения.




Рис. 4. Изменение ошибки при обучении нейронной сети
 Fig. 4. Error variation in neural network training

Распределение относительных ошибок подтверждает высокое качество предсказаний (рис. 5). Для обучающей выборки ошибки сосредоточены вблизи нулевого значения. Для напряжений во вкладыше пик распре-




Рис. 5. Плотность распределения относительной ошибки для обучающей (а) и тестовой (б) выборок. Квантили 25 %, 50 %, 75 % и 95 % отмечены на кривых для вкладыша и вала
 Fig. 5. Relative error distribution density for training (a) and test (b) samples. Quantiles of 25 %, 50 %, 75 %, and 95 % are marked on the curves for the insert and the shaft

деления приходится на 0,1 %, при этом более 95 % значений не превышают 0,9 %. Для напряжений в вале также наблюдается пик на уровне 0,1 %, а 95 % ошибок не выходят за пределы 1,2 %.

На тестовой выборке распределение имеет похожий характер, но слегка расширяется, что ожидаемо при переходе к независимым данным. Для напряжений во вкладыше пик ошибки составляет 0,2 %, при этом более 95 % значений остаются ниже 1,5 %. Для напряжений в вале пик также равен 0,1 %, а 95 % ошибок не превышают 3,2 %.

Совокупность полученных метрик и распределений ошибок показывает, что предложенная нейросетевая модель может рассматриваться как аппроксимирующая модель, воспроизводящая результаты конечно-элементного анализа в исследованном диапазоне нагрузок. Точность предсказаний находится на уровне, достаточном для инженерных оценок и предварительных расчетов при оптимизации параметров трибофатических систем.

Заключение

Проведенное исследование подтвердило возможность применения нейросетевых моделей для воспроизведения результатов конечно-элементного анализа трибофатических систем. Модель демонстрирует стабильную сходимость без признаков переобучения,

низкий уровень ошибок и высокую обобщающую способность. Даже на независимой валидационной выборке относительная погрешность остается в пределах 3,2 %. Нейронная сеть способна адекватно описывать взаимосвязь между нагрузкой и максимальными напряжениями, обеспечивая сокращение вычислительных затрат при сохранении необходимой точности.

Вместе с тем результаты относятся к ограниченной постановке задачи, в которой рассматриваются две нагрузочные компоненты и одна пара материалов. Такая конфигурация позволяет изолированно оценить корректность подхода, но не отражает всего разнообразия эксплуатационных условий. Поэтому перспективным направлением дальнейших исследований является расширение состава входных параметров.

Представленные результаты формируют основу для дальнейшего развития цифровых моделей трибофатических систем, где нейросетевые методы могут использоваться как инструмент ускоренного прогноза напряженно-деформированного состояния и анализа влияния параметров нагружения на долговечность элементов. Планируется расширить исследование на большее число материалов, в том числе различные чугуны, а также рассмотреть более широкий диапазон условий нагружения. Это позволит оценить устойчивость метода при сложных сценариях эксплуатации и повысить универсальность разработанной модели.

Литература

1. Sosnovskiy L.A. *TRIBO-FATIGUE: Wear-Fatigue Damage and its Prediction*. Springer, 2005. 373 p. <https://doi.org/10.1007/978-3-540-27027-0>
2. Sosnovskiy L.A., Sherbakov S.S., Khonsari M.M., Bogdanovich A.V. From fatigue and tribology to tribo-fatigue // *International Journal of Materials and Structural Integrity*. 2022. V. 14. N 2-4. P. 164–237. <https://doi.org/10.1504/ijmsi.2021.10050854>
3. Sosnovskiy L.A., Bogdanovich A.V., Yelovoy O.M., Tyurin S.A., Komissarov V.V., Sherbakov S.S. Methods and main results of Tribo-Fatigue tests // *International Journal of Fatigue*. 2014. V. 66. P. 207–219. <https://doi.org/10.1016/j.ijfatigue.2014.04.006>
4. Комиссаров В.В., Таранова Е.С., Дробышевский П.С., Замятин В.О., Тюрин С.А., Сосновский Л.А. Об опыте изготовления и эксплуатации зубчатых колес из нового конструкционного материала «Моника» // *Вестник ИжГТУ имени М.Т. Калашникова*. 2017. Т. 20. № 2. С. 107–112. <https://doi.org/10.22213/2413-1172-2017-2-107-112>
5. Bendikiene R., Bahdanovich A., Cesnavicius R., Ciuplys A., Grigas V., Jutas A., et al. Tribo-fatigue behavior of austempered ductile iron Monica as new structural material for rail-wheel system // *Medziagotyra*. 2020. V. 26. N 4. P. 432–437. <https://doi.org/10.5755/j01.ms.26.4.25384>
6. Meng Y., Xu J., Ma L., Jin Z., Prakash B., Ma T., Wang W. A review of advances in tribology in 2020–2021 // *Friction*. 2022. V. 10. N 10. P. 1443–1595. <https://doi.org/10.1007/s40544-022-0685-7>
7. Ge Z., Hu Q., Wang R., Fei H., Zhu Y., Wang Z. Machine learning-driven optimization of micro-textured surfaces for enhanced tribological performance: a comparative analysis of predictive models // *Coatings*. 2024. V. 14. N 12. P. 1539. <https://doi.org/10.3390/coatings14121539>
8. Nowell D., Nowell P.W. A machine learning approach to the prediction of fretting fatigue life // *Tribology International*. 2020. V. 141. P. 105913. <https://doi.org/10.1016/j.triboint.2019.105913>
9. Liang L., Liu M., Martin C., Sun W. A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis // *Journal of The Royal Society Interface*. 2018. V. 15. N 138. P. 20170844. <https://doi.org/10.1098/rsif.2017.0844>

References

1. Sosnovskiy L.A. *TRIBO-FATIGUE: Wear-Fatigue Damage and its Prediction*. Springer, 2005, 373 p. <https://doi.org/10.1007/978-3-540-27027-0>
2. Sosnovskiy L.A., Sherbakov S.S., Khonsari M.M., Bogdanovich A.V. From fatigue and tribology to tribo-fatigue. *International Journal of Materials and Structural Integrity*, 2022, vol. 14, no. 2-4, pp. 164–237. <https://doi.org/10.1504/ijmsi.2021.10050854>
3. Sosnovskiy L.A., Bogdanovich A.V., Yelovoy O.M., Tyurin S.A., Komissarov V.V., Sherbakov S.S. Methods and main results of Tribo-Fatigue tests. *International Journal of Fatigue*, 2014, vol. 66, pp. 207–219. <https://doi.org/10.1016/j.ijfatigue.2014.04.006>
4. Komissarov V.V., Taranova E.S., Drobyshevsky P.S., Zamyatin V.O., Tyurin S.A., Sosnovskiy L.A. About experience of manufacture and maintenance of gears from the new structural material “Monika”. *Vestnik IzhGTU imeni M.T. Kalashnikova*, 2017, vol. 20, no. 2, pp. 107–112. (in Russian). <https://doi.org/10.22213/2413-1172-2017-2-107-112>
5. Bendikiene R., Bahdanovich A., Cesnavicius R., Ciuplys A., Grigas V., Jutas A., et al. Tribo-fatigue behavior of austempered ductile iron Monica as new structural material for rail-wheel system. *Medziagotyra*, 2020, vol. 26, no. 4, pp. 432–437. <https://doi.org/10.5755/j01.ms.26.4.25384>
6. Meng Y., Xu J., Ma L., Jin Z., Prakash B., Ma T., Wang W. A review of advances in tribology in 2020–2021. *Friction*, 2022, vol. 10, no. 10, pp. 1443–1595. <https://doi.org/10.1007/s40544-022-0685-7>
7. Ge Z., Hu Q., Wang R., Fei H., Zhu Y., Wang Z. Machine learning-driven optimization of micro-textured surfaces for enhanced tribological performance: a comparative analysis of predictive models. *Coatings*, 2024, vol. 14, no. 12, pp. 1539. <https://doi.org/10.3390/coatings14121539>
8. Nowell D., Nowell P.W. A machine learning approach to the prediction of fretting fatigue life. *Tribology International*, 2020, vol. 141, pp. 105913. <https://doi.org/10.1016/j.triboint.2019.105913>
9. Liang L., Liu M., Martin C., Sun W. A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis. *Journal of The Royal Society Interface*, 2018, vol. 15, no. 138, pp. 20170844. <https://doi.org/10.1098/rsif.2017.0844>

10. Khorrami M.S., Mianroodi J.R., Siboni N.H., Goyal P., Svendsen B., Benner P., Raabe D. An artificial neural network for surrogate modeling of stress fields in viscoplastic polycrystalline materials // *npj Computational Materials*. 2023. V. 9. N 1. P. 37. <https://doi.org/10.1038/s41524-023-00991-z>
11. Kapoor S., Mianroodi J.R., Khorrami M., Siboni N.S., Svendsen B. Comparison of two artificial neural networks trained for the surrogate modeling of stress in materially heterogeneous elastoplastic solids // *arXiv*. 2022. arXiv:2210.16994. <https://doi.org/10.48550/arXiv.2210.16994>
12. Jain S., Kapania R.K., Hammerand D.C. Development of a surrogate model for FEM error prediction using deep learning // *Proc. of the AIAA Science and Technology Forum and Exposition (AIAA SciTech Forum)*. 2022. P. 0972. <https://doi.org/10.2514/6.2022-0972>
13. Wu J., Du C., Dillenburg B., Kraus M.A. Fast prediction of stress distribution a GNN-based surrogate model for unstructured mesh FEA // *Proc. of the IASS Symposium 2024 Redefining the Art of Structural Design*. 2024. P. 1–10.
14. Mokhtari N., Cai Y., Jelovica J. Comparison of deep learning techniques for prediction of stress distribution in stiffened panels // *Thin-Walled Structures*. 2025. V. 215. Part A. P. 113494. <https://doi.org/10.1016/j.tws.2025.113494>
15. Persia J.T., Sung M.K., Lee S., Burns D.E. Neural network-based surrogate model in postprocessing of topology optimized structures // *Neural Computing and Applications*. 2025. V. 37. N 15. P. 8845–8867. <https://doi.org/10.1007/s00521-025-11039-2>
16. Marković E., Marohnić T., Basan R. A surrogate artificial neural network model for estimating the fatigue life of steel components based on finite element simulations // *Materials*. 2025. V. 18. N 12. P. 2756. <https://doi.org/10.3390/ma18122756>
17. Сосновский Л.А., Жмайлик В.А., Псырков Н.В., Замятин В.О., Комиссаров В.В. Чугун с шаровидным графитом и высоким сопротивлением усталости. Патент № 15617 Беларусь. Заявл. 04.10.2010; опубл. 30.04.2012. заявитель Республиканское унитарное предприятие «Гомельский завод сельскохозяйственного машиностроения «Гомсельмаш», Общество с ограниченной ответственностью «Научно-производственное объединение ТРИБОФАТИКА»
18. Bahdanovich A., Sherbakov S., Lis I., Bendikiene R., Cesnavicius R., Grigas V. Some regularities of life time and damage for the new structural material MoNiCA during sliding friction and mechano-sliding fatigue // *Solid State Phenomena*. 2021. V. 320. P. 90–96. <https://doi.org/10.4028/www.scientific.net/ssp.320.90>
19. Sosnovskiy L.A., Sherbakov S.S. New cast iron MONICA loses its brittleness with increasing strength // *International Journal of Materials and Structural Integrity*. 2023. V. 15. N 1. P. 24–41. <https://doi.org/10.1504/ijmsi.2023.135888>
10. Khorrami M.S., Mianroodi J.R., Siboni N.H., Goyal P., Svendsen B., Benner P., Raabe D. An artificial neural network for surrogate modeling of stress fields in viscoplastic polycrystalline materials. *npj Computational Materials*, 2023, vol. 9, no. 1, pp. 37. <https://doi.org/10.1038/s41524-023-00991-z>
11. Kapoor S., Mianroodi J.R., Khorrami M., Siboni N.S., Svendsen B. Comparison of two artificial neural networks trained for the surrogate modeling of stress in materially heterogeneous elastoplastic solids. *arXiv*, 2022. arXiv:2210.16994. <https://doi.org/10.48550/arXiv.2210.16994>
12. Jain S., Kapania R.K., Hammerand D.C. Development of a surrogate model for FEM error prediction using deep learning. *Proc. of the AIAA Science and Technology Forum and Exposition (AIAA SciTech Forum)*, 2022, pp. 0972. <https://doi.org/10.2514/6.2022-0972>
13. Wu J., Du C., Dillenburg B., Kraus M.A. Fast prediction of stress distribution a GNN-based surrogate model for unstructured mesh FEA. *Proc. of the IASS Symposium 2024 Redefining the Art of Structural Design*. 2024, pp. 1–10.
14. Mokhtari N., Cai Y., Jelovica J. Comparison of deep learning techniques for prediction of stress distribution in stiffened panels. *Thin-Walled Structures*, 2025, vol. 215, part A, pp. 113494. <https://doi.org/10.1016/j.tws.2025.113494>
15. Persia J.T., Sung M.K., Lee S., Burns D.E. Neural network-based surrogate model in postprocessing of topology optimized structures. *Neural Computing and Applications*, 2025, vol. 37, no. 15, pp. 8845–8867. <https://doi.org/10.1007/s00521-025-11039-2>
16. Marković E., Marohnić T., Basan R. A surrogate artificial neural network model for estimating the fatigue life of steel components based on finite element simulations. *Materials*, 2025, vol. 18, no. 12, pp. 2756. <https://doi.org/10.3390/ma18122756>
17. Sosnovskii L.A., Zhmailik V.A., Psyrkov N.V., Zamyatnin V.O., Komissarov V.V. Cast iron with globular graphite and high fatigue resistance. *Patent BY 15617*, 2012. (in Russian)
18. Bahdanovich A., Sherbakov S., Lis I., Bendikiene R., Cesnavicius R., Grigas V. Some regularities of life time and damage for the new structural material MoNiCA during sliding friction and mechano-sliding fatigue. *Solid State Phenomena*, 2021, vol. 320, pp. 90–96. <https://doi.org/10.4028/www.scientific.net/ssp.320.90>
19. Sosnovskiy L.A., Sherbakov S.S. New cast iron MONICA loses its brittleness with increasing strength. *International Journal of Materials and Structural Integrity*, 2023, vol. 15, no. 1, pp. 24–41. <https://doi.org/10.1504/ijmsi.2023.135888>

Авторы

Боровков Алексей Иванович — кандидат технических наук, главный конструктор, Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, 195251, Российская Федерация, <https://orcid.org/0000-0003-3177-0959>, vicerector.ap@spbstu.ru

Карчевская Анна Станиславовна — инженер, Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, 195251, Российская Федерация, <https://orcid.org/0009-0008-2905-8448>, karchevskaya_as@spbstu.ru

Новокшенов Алексей Дмитриевич — кандидат технических наук, доцент, Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, 195251, Российская Федерация, <https://orcid.org/0000-0001-5874-5994>, novoksh_ad@spbstu.ru

Матвеева Анастасия Игоревна — инженер, Санкт-Петербургский политехнический университет Петра Великого, Санкт-Петербург, 195251, Российская Федерация, <https://orcid.org/0009-0009-8189-0300>, matveeva_ai@spbstu.ru

Щербаков Сергей Сергеевич — доктор физико-математических наук, профессор, академик-секретарь Физико-технического отделения НАН Беларуси, Национальная академия наук Беларуси, Минск, 220072, Республика Беларусь; главный научный сотрудник, Объединенный институт машиностроения НАН Беларуси, Минск, 220072, Республика Беларусь, <https://orcid.org/0000-0001-6404-6129>, sherbakovssr@yandex.by

Authors

Aleksei I. Borovkov — PhD, Chief Design Officer, Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, 195251, Russian Federation, <https://orcid.org/0000-0003-3177-0959>, vicerector.ap@spbstu.ru

Anna S. Karchevskaia — Engineer, Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, 195251, Russian Federation, <https://orcid.org/0009-0008-2905-8448>, karchevskaya_as@spbstu.ru

Aleksei D. Novokshenov — PhD, Associate Professor, Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, 195251, Russian Federation, <https://orcid.org/0000-0001-5874-5994>, novoksh_ad@spbstu.ru

Anastasia I. Matveeva — Engineer, Peter the Great St. Petersburg Polytechnic University, Saint Petersburg, 195251, Russian Federation, <https://orcid.org/0009-0009-8189-0300>, matveeva_ai@spbstu.ru

Sergei S. Sherbakov — D.Sc. (Physics & Mathematics), Professor, Academic Secretary of Physical and Mathematical Department, National Academy of Sciences of Belarus, Minsk, 220072, Belarus; Chief Researcher, The Joint Institute of Mechanical Engineering of the National Academy of Sciences of Belarus, Minsk, 220072, Belarus, <https://orcid.org/0000-0001-6404-6129>, sherbakovssr@yandex.by

Климкович Никита Михайлович — старший преподаватель, Белорусский государственный университет, Минск, 220030, Республика Беларусь; младший научный сотрудник, Объединенный институт машиностроения НАН Беларуси, Минск, 220072, Республика Беларусь, <https://orcid.org/0009-0001-7204-1974>, Nikita.klimkovitch@yandex.ru

Подгайская Дарья Александровна — заведующий лабораторией, Объединенный институт машиностроения НАН Беларуси, Минск, 220072, Республика Беларусь, <https://orcid.org/0009-0009-8988-6939>, dapodgayskaya@gmail.com

Полешук Михаил Михайлович — инженер-программист, Белорусский государственный университет, Минск, 220030, Республика Беларусь, <https://orcid.org/0000-0003-2701-2194>, mikhailpaliashchuk@yandex.ru

Nikita M. Klimkovich — Senior Lecturer, Belarusian State University (BSU), Minsk, 220030, Belarus; Junior Researcher, The Joint Institute of Mechanical Engineering of the National Academy of Sciences of Belarus, Minsk, 220072, Belarus, <https://orcid.org/0009-0001-7204-1974>, Nikita.klimkovitch@yandex.ru

Daria A. Podgayskaya — Head of Laboratory, The Joint Institute of Mechanical Engineering of the National Academy of Sciences of Belarus, Minsk, 220072, Belarus, <https://orcid.org/0009-0009-8988-6939>, dapodgayskaya@gmail.com

Mikhail M. Poleschuk — Software Engineer, Belarusian State University (BSU), Minsk, 220030, Belarus, <https://orcid.org/0000-0003-2701-2194>, mikhailpaliashchuk@yandex.ru

Статья поступила в редакцию 17.10.2025
Одобрена после рецензирования 13.02.2026
Принята к печати 15.03.2026

Received 17.10.2025
Approved after reviewing 13.02.2026
Accepted 15.03.2026



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»