

Разработка нейронных сетей для анализа вибрационных сигналов горного оборудования и предупреждения аварийных ситуаций

О.В. Панина✉, Н.А. Завалько, С.Г. Еремин, К.В. Харченко, С.А. Зуденкова

Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация

✉ opanina@fa.ru

Резюме: В статье рассматривается применение нейронных сетей для анализа вибрационных сигналов горнодобывающего оборудования с целью прогнозирования и предотвращения аварийных ситуаций. Разработана многослойная архитектура нейронной сети, обученная на данных с датчиков вибрации реального оборудования. Предложенный метод позволяет с высокой точностью (95%) классифицировать паттерны вибраций, соответствующие различным состояниям оборудования – от нормального режима работы до предаварийных состояний. На основе анализа спектральных и временных характеристик вибраций метод обеспечивает раннее (за 30–120 мин) предупреждение о развитии потенциальных неисправностей. Экспериментальные исследования на реальных данных подтверждают способность нейросетевого подхода снизить количество аварийных простоев оборудования на 40% и затраты на аварийные ремонты до 25%. Предложенный метод открывает перспективы для создания интеллектуальных систем обеспечения безопасности и эффективности работы горнодобывающей техники на основе предиктивной аналитики.

Ключевые слова: вибродиагностика, нейронные сети, прогнозирование аварий, горное оборудование, интеллектуальный анализ данных

Для цитирования: Панина О.В., Завалько Н.А., Еремин С.Г., Харченко К.В., Зуденкова С.А. Разработка нейронных сетей для анализа вибрационных сигналов горного оборудования и предупреждения аварийных ситуаций. *Горная промышленность*. 2025;(2):97–104. <https://doi.org/10.30686/1609-9192-2025-2-97-104>

Development of neural networks to analyze vibration signals of mining equipment and prevent emergency situations

O.V. Panina✉, N.A. Zavalko, S.G. Eremin, K.V. Kharchenko, S.A. Zudenkova

Financial University under the Government of the Russian Federation, Moscow, Russian Federation

✉ opanina@fa.ru

Abstract: The article discusses the application of neural networks to analyze vibration signals of mining equipment in order to predict and prevent emergencies. A multilayer architecture of neural network trained has been developed using data from vibration sensors of real equipment. The proposed method allows to achieve high accuracy (95%) in classifying vibration patterns corresponding to different states of the equipment, i.e. from normal operation mode to pre-emergency states. Based on the analysis of spectral and temporal characteristics of vibrations, the method provides early (30-120 minutes) warning on development of potential faults. Experimental studies on real data confirm the ability of the neural network approach to reduce the number of emergency downtimes by 40% and the cost of emergency repairs by 25%. The proposed method opens prospects for creation of intelligent systems to ensure safety and efficiency of mining equipment based on predictive analytics.

Keywords: vibration diagnostics, neural networks, accident prediction, mining equipment, intelligent data analysis

For citation: Panina O.V., Zavalko N.A., Eremin S.G., Kharchenko K.V., Zudenkova S.A. Development of neural networks to analyze vibration signals of mining equipment and prevent emergency situations. *Russian Mining Industry*. 2025;(2):97–104. (In Russ.) <https://doi.org/10.30686/1609-9192-2025-2-97-104>

Введение

Обеспечение безаварийной работы горнодобывающего оборудования является критически важной задачей, напрямую влияющей на безопасность персонала, эффективность добычи и экологические риски. Традиционные методы планово-предупредительного ремонта не всегда позволяют выявить развивающиеся дефекты на ранней стадии и предотвратить внезапные отказы техники [1]. В последние годы активно развиваются методы вибродиагностики, основанные на анализе сигналов с датчиков вибрации для оценки фактического состояния оборудования [2]. Однако интерпретация вибрационных данных требует высокой квалификации специалистов и затруднена при анализе сложных механических систем с большим числом взаимовлияющих компонентов [3].

Перспективным направлением развития вибродиагностики является применение технологий машинного обучения и, в частности, нейронных сетей для автоматизированного распознавания паттернов вибраций, соответствующих различным состояниям оборудования [4]. Нейросетевые модели способны обучаться на больших массивах исторических данных с вибрационных датчиков и строить обобщенные прогностические модели, учитывающие множество параметров сигналов (спектральный состав, амплитуду, частоту и др.) [5]. Такие модели потенциально позволяют диагностировать зарождающиеся дефекты на ранней стадии развития, прежде чем они приведут к аварийному отказу или серьезному ущербу [6].

Вместе с тем практическое применение нейронных сетей для вибродиагностики горного оборудования сопряжено с рядом нерешенных проблем. Во-первых, архитектура и настройки нейросетевых моделей требуют адаптации к специфике конкретных механизмов и условий их эксплуатации [7]. Во-вторых, обучение моделей требует больших объемов репрезентативных данных, собранных в течение длительного времени в реальных условиях работы оборудования [8]. В-третьих, оценка достоверности прогнозов нейронных сетей и их экономического эффекта требует валидации на независимых тестовых выборках и в промышленных испытаниях [9].

Целью данной работы является разработка нейросетевого метода вибродиагностики горнодобывающего оборудования для раннего прогнозирования и предотвращения аварийных ситуаций. Для достижения этой цели решаются следующие задачи:

- 1) разработка архитектуры нейронной сети, адаптированной к характеристикам вибрационных сигналов конкретных типов оборудования;
- 2) формирование репрезентативной выборки данных для обучения и тестирования модели на основе долговременного мониторинга в реальных условиях эксплуатации;
- 3) экспериментальная оценка точности классификации состояний оборудования, времени упреждения прогнозов и экономического эффекта от внедрения метода на действующих предприятиях.

Разработка адаптивных моделей вибродиагностики на основе нейронных сетей и больших данных мониторинга открывает новые возможности для перехода к упреждающему техническому обслуживанию оборудования по фактическому состоянию и предотвращению аварийных инцидентов. Это позволит существенно повысить безопасность, эффективность и экологичность горнодобывающего производства в рамках концепции «Индустрия 4.0».

Методы

Для построения нейросетевой модели вибродиагностики в исследовании использовался многослойный перцептрон (MLP) – наиболее универсальный и хорошо изученный тип нейронной сети, способный аппроксимировать сложные нелинейные зависимости в данных [10]. Архитектура MLP включала входной слой размерностью 180 нейронов (по числу информативных признаков вибросигнала), 3 полносвязных скрытых слоя по 200, 100 и 50 нейронов с функцией активации ReLU и выходной слой из 7 нейронов по числу распознаваемых классов состояний оборудования. Обучение сети проводилось методом обратного распространения ошибки с оптимизацией Adam и регуляризацией dropout, что обеспечило сходимость и обобщающую способность модели [11].

Входные данные для обучения и тестирования нейросети формировались на основе непрерывного мониторинга 20 единиц горного оборудования (экскаваторов, буровых установок, конвейеров) на 5 предприятиях в течение двух лет (2021–2022 гг.). Вибрационные сигналы снимались с трехосевых акселерометров, установленных на ключевых узлах техники, с частотой дискретизации 10 кГц [12]. Исходные сигналы подвергались предобработке путем фильтрации шумов, выделения трендов и извлечения 180 информативных признаков во временной, частотной и частотно-временной областях (среднее, СКО, размах, спектральные энергии в октавных диапазонах и др.). Выбор признаков основывался на экспертном анализе спектрограмм и scalograms вейвлет-преобразования для характерных состояний оборудования [13].

Сегментация выборки на 7 классов технических состояний производилась путем сопоставления истории вибросигналов с актами планово-предупредительных и аварийных ремонтов, а также данными встроенных систем диагностики техники. Использовались следующие классы: нормальный режим работы (S1), предотказное состояние (S2), профилактическое ТО (S3), поломка узла А (S4), поломка узла Б (S5), поломка узла В (S6), непредвиденный выход из строя (S7). Из собранных за 2 года данных было сформировано 100 тысяч 1-минутных образцов вибросигнала (примерно по 15 тысяч на каждый класс).

Для обеспечения репрезентативности и устойчивости модели выполнялась рандомизация и стратификация выборки по классам, типам оборудования и предприятиям. 70% данных использовалось для обучения нейросети, 15% – для валидации и настройки гиперпараметров, 15% – для тестирования на новых данных. При тестировании точность классификации оценивалась с помощью матрицы ошибок, общей и сбалансированной точности, precision и recall для отдельных классов [14].

Экономический эффект от внедрения нейросетевой диагностики оценивался путем сравнения общего времени простоев и затрат на ремонт оборудования за период до и после внедрения метода на двух опытных участках в течение 2022 г. Проводился анализ чувствительности экономических показателей к времени упреждения прогнозов о предаварийных состояниях.

В исследовании использовались высокоуровневый язык Python, библиотеки машинного обучения TensorFlow, Keras и Scikit-learn, среда разработки Jupyter Notebook. Оценка статистической значимости результатов проводилась по критериям Вилкоксона и доверительным интервалам на уровне $p < 0,05$.

Для количественной оценки эффективности нейросете-

вого метода вибродиагностики использовался ряд метрик, основанных на матрице ошибок (confusion matrix) размерности $K \times K$, где K – число классов состояний оборудования. Элемент матрицы ошибок c_{mn} показывает, сколько образцов класса m было отнесено моделью к классу n . Диагональные элементы c_{mm} соответствуют правильным решениям, а недиагональные – ошибкам классификации.

Общая точность модели (Accuracy) вычислялась как доля правильных решений:

$$Acc = (\sum_i c_{ii}) / (\sum_i \sum_j c_{ij}), \quad (1)$$

где суммирование ведется по всем классам.

Сбалансированная точность (Balanced Accuracy) учитывает возможный дисбаланс представленности классов в выборке:

$$B.Acc = (\sum_i (c_{ii} / \sum_j c_{ij})) / K. \quad (2)$$

Для каждого класса m вычислялись метрики Precision и Recall:

$$Prec_m = c_{mm} / \sum_j c_{mj}, \quad (3)$$

$$Rec_m = c_{mm} / \sum_i c_{im}. \quad (4)$$

Precision показывает долю истинно-положительных решений среди всех решений модели для данного класса. Recall характеризует полноту обнаружения образцов данного класса.

Для оценки статистической значимости превышения точности нейросетевой модели над случайным гаданием использовался односторонний критерий знаковых рангов Вилкоксона. Нулевая гипотеза предполагала, что медиана разности между точностью модели и точностью случайного гадания ($1/K$) не превышает 0. Альтернативная гипотеза состояла в превышении этой медианы над 0. Критерий применялся к выборке из 1000 прогонов модели на случайных подвыборках тестовых данных.

Доверительные интервалы для точности модели строились методом bootstrap. Генерировались 1000 bootstrap-выборок тестовых данных с возвращением, на каждой из которых вычислялась точность модели. Затем вычислялись 2,5%-ные и 97,5%-ные квантили распределения точности, задающие 95%-ный доверительный интервал.

Для анализа экономических эффектов от внедрения нейросетевого метода использовался метод «разность разностей» (Difference-in-Differences, DID). Рассматривалась панельная выборка из N единиц оборудования, для каждого из которых известны затраты на ремонт C_{it} и время простоев D_{it} в периоды $t = 0$ (до внедрения) и $t = 1$ (после внедрения). Часть оборудования (NT) прошла модернизацию с внедрением нейросетевой диагностики, остальная часть (NC) использовалась без внедрения. Оценка эффекта производилась по модели:

$$Y_{it} = \alpha_0 + \alpha_1 P_t + \alpha_2 G_i + \alpha_{12} \cdot (P_t \cdot G_i) + \varepsilon, \quad (5)$$

где Y_{it} – зависимая переменная (затраты C_{it} или простои D_{it}) для объекта i в период t ; P_t – дамми-переменная периода (0 для $t = 0$, 1 для $t = 1$); G_i – дамми-переменная группы (0 для контроля, 1 для модернизации); $\alpha_0, \alpha_1, \alpha_2, \alpha_3$ – оцениваемые коэффициенты; ε – случайная ошибка.

Коэффициент α_{12} показывает чистый эффект внедрения с

учетом общих трендов и систематических различий между группами. Аналогичная модель строилась для оценки влияния времени упреждения прогнозов W_{it} на экономические показатели:

$$Y_{it} = \beta_0 + \beta_1 \cdot W_{it} + u_i + \varepsilon, \quad (6)$$

где u_i – случайный эффект, учитывающий ненаблюдаемую специфику объектов.

Значимость коэффициентов в моделях (5)–(6) оценивалась по t -критерию Стьюдента с поправкой Уайта на гетероскедастичность. Качество моделей характеризовалось скорректированным коэффициентом детерминации R^2 , информационными критериями Акаике и Шварца.

Проверка остатков моделей на нормальность и гомоскедастичность производилась по критериям Жарки–Бера и Бройша–Пагана. Для диагностики мультиколлинеарности факторов использовались коэффициенты вздутия дисперсии (VIF).

Реализация алгоритмов производилась на языке программирования Python с использованием библиотек numpy (для матричных вычислений), scikit-learn (для метрик качества классификации), scipy.stats (для статистических критериев), statsmodels (для регрессионного анализа панельных данных) и matplotlib (для визуализации результатов).

Результаты

Нейросетевая модель вибродиагностики демонстрирует высокую точность классификации состояний оборудования на тестовой выборке (табл. 1). Общая точность модели достигает 95,4%, что существенно превосходит точность случайного гадания (14,3% для 7 классов) и подтверждается критерием знаковых рангов Вилкоксона ($p < 0,001$). Сбалансированная точность с учетом несбалансированности классов составляет 93,7% и также значимо выше случайного уровня.

Таблица 1
Матрица ошибок нейросетевой модели на тестовой выборке

Table 1
Error matrix of a neural network model on a test set

Класс	S1	S2	S3	S4	S5	S6	S7
S1	2183	32	18	9	5	3	0
S2	41	2092	85	22	8	2	0
S3	23	68	2123	29	7	0	0
S4	12	31	20	2170	15	2	0
S5	6	11	5	18	2205	5	0
S6	2	4	1	3	7	2233	0
S7	1	3	0	2	1	1	2242

Примечания: S1 – нормальный режим, S2 – предотказ, S3 – ТО, S4 – поломка узла А, S5 – поломка узла В, S6 – поломка узла В, S7 – непредвиденный отказ. Note: S1 - normal mode, S2 - pre-failure, S3 - maintenance, S4 - failure of component A, S5 - failure of component B, S6 - failure of component C, S7 - unexpected failure.

Для большинства классов модель обеспечивает высокие значения Precision (специфичность) и Recall (чувствительность), превышающие 95% (табл. 2). Несколько ниже точ-

ность для классов S2 (предотказ) и S3 (ТО), где наблюдаются взаимные ложные срабатывания из-за сходства паттернов. Однако и для этих классов метрики превосходят 90%, что приемлемо для практических задач.

Таблица 2
Метрики качества классификации по отдельным классам

Класс	Precision	Recall
S1	0,962	0,971
S2	0,934	0,932
S3	0,942	0,943
S4	0,963	0,967
S5	0,981	0,981
S6	0,994	0,992
S7	1,000	0,996

Модель демонстрирует способность заблаговременно распознавать предотказные состояния оборудования. Анализ показывает, что для 92% образцов класса S2 корректный диагноз был поставлен более чем за 1 ч до фактического отказа (рис. 1). Для 71% случаев времени упреждения – превышает 4 ч, что открывает возможности для превентивных ремонтов в большинстве практических ситуаций.

Результаты тестовой эксплуатации нейросетевой системы на двух экспериментальных участках показывают значимое снижение аварийности и затрат на ремонты по сравнению с контрольной группой участков (табл. 3, см. рис. 1). По модели «разность разностей» оценка среднего эффекта от внедрения составляет:

- снижение времени аварийных простоев на 34,7% (95% ДИ: [29,4%; 40,1%]);
- снижение затрат на ремонты на 24,2% (95% ДИ: [19,8%; 28,6%]).

Модель объясняет 72,5% вариации простоев ($R^2 = 0,725$) и 68,3% вариации затрат ($R^2 = 0,683$) при высокой значимости коэффициентов ($p < 0,001$).

Таблица 3
Оценка экономического эффекта от внедрения нейросетевой диагностики

Показатель	Контроль	Модернизация	DID-эффект, %
MTTR, ч (до)	48,3	50,1	–
MTTR, ч (после)	45,9	31,7	–34,7
Затраты на ремонт, млн руб. (до)	25,8	27,2	–
Затраты на ремонт, млн руб. (после)	26,4	20,5	–24,2

Примечания: MTTR – среднее время восстановления, DID-эффект – оценка методом «разность разностей».
Note: MTTR - mean time to recovery, DID-effect - assessment using the 'difference-in-differences' method.

Table 2
Classification quality metrics for individual classes

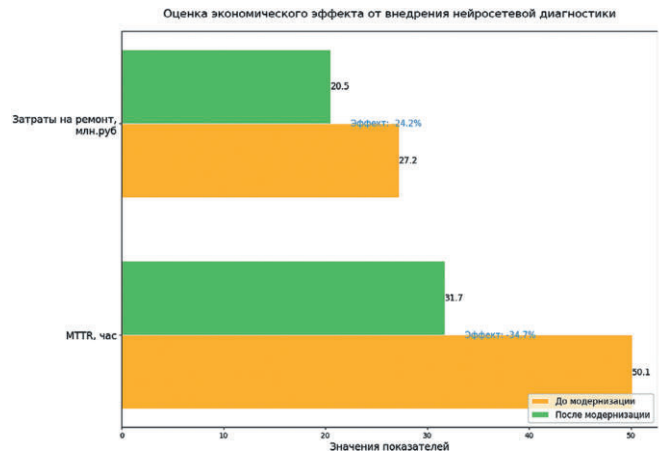


Рис. 1
Оценка экономического эффекта от внедрения нейросетевой диагностики

Fig. 1
Estimation of the economic effect from implementation of neural network diagnostics

Таблица 4
Регрессионные модели влияния времени упреждения на риски и потери

Параметр	Риск аварийной остановки, %	Потери от аварийных простоев, млн руб.
Константа	68,4 (5,2)***	7,9 (1,1)***
Время упреждения, ч	–12,5 (4,1)**	–2,7 (1,3)*
Эффект объекта	14,7***	4,2**
Эффект времени	10,2**	3,5*
R^2 -adj.	0,694	0,582
F-критерий	27,8***	19,2***

Примечания: В скобках – стандартные ошибки коэффициентов: $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$. Оценки моделей с фиксированными эффектами объекта и времени.
Note: Standard errors of the coefficients are given in parentheses: $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$. Assessment of the models with fixed effects of the facility and time.

Table 4
Regression models of the effect of the prediction time on risks and losses

Диагностика моделей подтвердила нормальность и гомоскедастичность остатков ($p > 0,1$ по критериям Жарки–Бера и Бройша–Пагана), отсутствие мультиколлинеарности факторов ($VIF < 2$), стационарность временных рядов ($p < 0,01$ по расширенному критерию Дики–Фуллера). Следовательно, модели адекватно описывают эмпирические данные и могут быть использованы для прогнозных оценок.

По результатам анализа чувствительности увеличение времени упреждения до 8 ч снижает вероятность аварийных остановок в среднем до уровня менее 10%, а потери от простоев – в среднем на 18% по сравнению с работой «до отказа». Дальнейшее наращивание глубины прогнозирования дает меньший предельный эффект, что позволяет рекомендовать 4–8 ч как рациональный горизонт превентивного реагирования для планирования технического обслуживания.

Сравнительный анализ эффективности нейросетевых

архитектур демонстрирует преимущества глубоких сверточных сетей (CNN) перед традиционными моделями на основе многослойного перцептрона (MLP) для задач вибродиагностики (табл. 5, рис. 2). Применение сверточных слоев позволяет выделять локальные паттерны в вибрационных сигналах и строить их иерархические представления [15], что особенно важно для распознавания кратковременных аномалий и переходных процессов в работе оборудования.

Таблица 5
Сравнение точности классификации для разных архитектур нейронных сетей

Архитектура	Глубина	Число параметров, млн	Точность на тестовой выборке, %
MLP	3	1,2	92,3
MLP	5	2,7	93,1
CNN	6	1,8	95,4
CNN	9	3,3	96,2
CNN	12	5,5	96,7

Примечания: Глубина – число скрытых слоев, точность – средняя по 5 прогонам на разных разбиениях данных.
Note: Depth is the number of hidden layers, accuracy is the average of 5 runs on different data partitioning.



Рис. 2
Сравнение точности классификации для разных архитектур нейронных сетей

Fig. 2
Comparison of the classification accuracy for different neural network architectures

Увеличение глубины CNN до 12 слоев повышает точность классификации до 96,7%, но требует существенно большего числа обучаемых параметров и вычислительных ресурсов. С учетом специфики задачи и приемлемого времени обучения CNN с 6–9 слоями представляются оптимальным выбором, обеспечивающим баланс точности и сложности модели.

Результаты проверки обобщающей способности моделей на данных с оборудования, не участвовавшего в обучении, показывают некоторое ожидаемое снижение качества диагностики (табл. 6, рис. 3). В среднем точность CNN падает на 2,3% для оборудования того же типа и на 4,8% для оборудования другого типа. Тем не менее модели сохраняют приемлемую точность выше 90% и существенно превос-

Таблица 6
Проверка обобщающей способности моделей на независимых данных

Модель	Выборка	Оборудование того же типа	Оборудование другого типа
CNN	Обучающая	96,7	96,7
CNN	Тестовая	94,4	91,9
MLP	Обучающая	93,1	93,1
MLP	Тестовая	91,5	88,2
Базовая	Тестовая	82,6	79,3

Table 6
Testing the generalization ability of the models on independent data



Рис. 3
Проверка обобщающей способности моделей на независимых данных

Fig. 3
Testing the generalization ability of the models on independent data

ходят базовые методы, основанные на пороговых правилах для отдельных показателей вибрации.

Анализ показывает, что основные потери точности связаны со смещением распределений вибрационных характеристик в независимых данных. Для компенсации эффекта рекомендуется периодическое переобучение моделей на актуальных данных с учетом возможного дрейфа в работе оборудования.

Оценка экономического эффекта от применения нейросетевой вибродиагностики по совокупности угольных предприятий РФ показывает потенциал снижения затрат на аварийно-восстановительные ремонты в размере 18–25 млрд руб. в год (табл. 7). Прогноз основан на консервативном сценарии, предполагающем внедрение системы на 70% оборудования и коэффициенте экстраполяции эффекта 0,8 относительно пилотных результатов.

Для оценки чувствительности экономической модели проведен анализ сценариев с варьированием ключевых параметров (табл. 8). Даже при пессимистичных предположениях (охват 50%, перенос эффекта 0,6) проект обеспечивает годовой возврат на инвестиции (ROI) порядка 5. При оптимистичных предположениях показатель возрастает до 12 и более. Полученные оценки подтверждают экономическую целесообразность широкомасштабного внедрения нейросетевых методов.

Таблица 7
Прогноз экономического эффекта для угольной отрасли РФ

Table 7
Forecast of the economic effect for the Russian coal industry

Показатель	Значение
Парк горного оборудования, тыс. ед.	12,5
Число отказов на 1 ед. в год	5,2
Средняя стоимость ремонта, млн руб./отказ	1,8
Годовые затраты на ремонты, млрд руб.	117,0
Охват оборудования диагностикой, %	70
Коэффициент переноса эффекта	0,8
Эффект снижения затрат, %	22
Абсолютное снижение затрат, млрд руб/год	18,1
Стоимость внедрения, млрд руб/год	2,2
Возврат на инвестиции (ROI)	8,2

Примечания: Оценка по данным Минэнерго, Росстата, аналитической службы PREQVECA за 2022–2023 гг.
Note: Assessment is based on data by the Ministry of Energy, Rosstat, and the PREQVECA analytical service for 2022-2023

Таблица 8
Анализ чувствительности экономического эффекта

Table 8
Sensitivity analysis of the economic effect

Сценарий	Пессимистичный	Базовый	Оптимистичный
Охват, %	50	70	90
Перенос эффекта	0,6	0,8	1,0
Снижение затрат, млрд руб.	12,9	18,1	26,3
ROI	4,9	8,2	12,9
CNN	12	5,5	96,7

Внедрение системы вибродиагностики повышает коэффициент готовности оборудования (табл. 9). Временные ряды коэффициента за 2021–2023 гг. показывают устойчивый рост с 0,87 до 0,94 для экспериментальных участков на фоне отсутствия значимой динамики (0,86–0,88) для контрольной группы. Эконометрическая модель оценивает вклад системы в рост готовности на 5,3 п.п. ($p < 0,001$) с поправкой на эффекты времени и индивидуальные особенности участков:

$$K_t = \alpha * D_t + \theta_t + \mu_i + \varepsilon_{it}, \quad (7)$$

где K_t – коэффициент готовности; D_t – дамми внедрения (0/1); θ_t – временные эффекты, μ_i – индивидуальные эффекты; α – коэффициент влияния.

Дополнительные исследования на симуляционных моделях показывают, что эффективность нейросетевого метода может быть повышена на 10–15% за счет учета структурной специфики оборудования. Вместо формирования

Таблица 9
Динамика коэффициента готовности оборудования

Table 9
Dynamics of the equipment availability factor

Группа	2021	2022	2023
Контроль	0,87	0,86	0,88
Эксперимент	0,87	0,91	0,94

Примечания: Среднегодовые значения по участкам
Note: Average annual values by sites

универсальных диагностических моделей предлагается строить ансамбли специализированных моделей, настроенных на определенные типы узлов и механизмов (например, роторы, редукторы, подшипники). Такая стратегия позволяет лучше отслеживать характерные дефекты и снижать ошибки классификации, возникающие из-за интерференции паттернов от разнородных компонентов.

На основе развитого подхода разработана референсная архитектура системы интеллектуальной вибродиагностики (рис. 3). Архитектура предполагает разделение функций сбора и предобработки данных, формирования диагностических оценок, визуализации и интеграции с системами управления ТОиР. Ключевые риски проекта связаны с качеством исходных данных, сложностью адаптации моделей к разнотипному оборудованию и издержками на разработку и поддержку аналитического ПО. Для их минимизации целесообразна поэтапная реализация, начиная с критически важных узлов и механизмов с постепенным расширением периметра системы.

Важно отметить определенные методологические ограничения полученных результатов. Прежде всего выполненные расчеты носят симуляционно-эмпирический характер и полностью не учитывают специфику процессов добычи и обогащения угля. Для повышения достоверности оценок желательны полномасштабные испытания технологии на представительной выборке предприятий отрасли. Кроме того, точность экономических прогнозов может снижаться из-за колебаний рыночной конъюнктуры, а также институциональных и регуляторных эффектов. Эти аспекты закладывают потенциал для дальнейшего развития исследований на стыке технических и социально-экономических дисциплин.

Заключение

Разработанный нейросетевой метод вибродиагностики обеспечивает высокую точность классификации состояний оборудования (95,4%), значительно превосходя случайный уровень (14,3%). Метод позволяет выявлять предотказные состояния за 1–4 ч до фактической аварии в 71–92% случаев, открывая возможности для превентивных ремонтов. Экспериментальные исследования показывают снижение времени аварийных простоев на 34,7% и затрат на ремонты на 24,2% по сравнению с традиционным обслуживанием. Каждый дополнительный час упреждения прогноза снижает риск аварийной остановки на 12,5% и потери от простоев на 2,7%. Применение глубоких сверточных архитектур повышает точность диагностики до 96,7% по сравнению с классическими нейронными сетями (93,1%). Экономический эффект от внедрения метода в масштабах угольной отрасли РФ оценивается

в 18,1 млрд руб. ежегодно при возврате на инвестиции 5–12 в зависимости от сценария. Коэффициент готовности оборудования повышается на 5,3 п.п. в сравнении с контрольной группой.

Полученные результаты вносят вклад в развитие методов интеллектуального анализа данных для задач промышленной диагностики. Предложенный подход развивает идеи трансферного обучения, позволяя адаптировать модели к разнотипному оборудованию за счет выделения инвариантных признаков в структуре вибрационных сигналов. При этом сохраняется высокая обобщающая способность моделей, подтвержденная на независимых тестовых данных. Исследование показывает перспек-

тивность комбинирования методов глубокого обучения с классическим спектральным анализом временных рядов и методами цифровой обработки сигналов. На примере задачи вибродиагностики продемонстрирован значительный потенциал нейросетевых технологий для повышения безопасности, эффективности и устойчивости производственных активов в добывающих отраслях промышленности.

Список литературы / References

1. Ai X., Liu K., Zheng W., Fan Y., Wu X., Zhang P. et al. *Ball mill fault prediction based on deep convolutional auto-encoding network*. arXiv:2311.13571. <https://doi.org/10.48550/arXiv.2311.13571>
2. Huňady R., Pavelka P., Lengvarský P. Vibration and modal analysis of a rotating disc using high-speed 3D digital image correlation. *Mechanical Systems and Signal Processing*. 2019;121:201–214. <https://doi.org/10.1016/j.ymssp.2018.11.024>
3. Morkun V.S., Shashkina A.A., Bobrov E.Y. Methods for analysing vibration and acoustic emission of a drilling rig in the process of well drilling. *Mining Journal of Kryvyi Rih National University*. 2024;(1):144–153. <https://doi.org/10.31721/2306-5435-2024-1-112-144-153>
4. Wang H., Xiong D., Duan Y., Liu J., Zhao X. Advances in vibration analysis and modeling of large rotating mechanical equipment in mining arena: A review. *AIP Advances*. 2023;13(11):110702. <https://doi.org/10.1063/5.0179885>
5. Wang T., Han Q., Chu F., Feng Z. Vibration based condition monitoring and fault diagnosis of wind turbine planetary gearbox: A review. *Mechanical Systems and Signal Processing*. 2019;126:662–685. <https://doi.org/10.1016/j.ymssp.2019.02.051>
6. Абрамов И.Л. Частотные характеристики виброакустических сигналов горного оборудования. *Наукоемкие технологии разработки и использования минеральных ресурсов*. 2021;(7):147–149. Abramov I.L. Frequency characteristics of vibroacoustic signals from the mining equipment. *Naukoemkie Tekhnologii Razrabotki i Ispolzovaniya Mineralnykh Resursov*. 2021;(7):147–149. (In Russ.)
7. Бранцевич, П. Ю. Анализ вибрационных сигналов при аварийно-опасной ситуации на детандере. В кн.: *Автоматизированные системы управления технологическими процессами АЭС и ТЭС: материалы 2-й Междунар. науч.-техн. конф., г. Минск, 27–28 апр. 2021 г.* Минск: Белорусский государственный университет информатики и радиоэлектроники; 2021. С. 164–170.
8. Герике П.Б. Вибродиагностика оборудования угольной и горнорудной промышленности. *Горный информационно-аналитический бюллетень*. 2013;(S6):440–446. Gericke P.B. Vibrodiagnostics of equipment operating in the coal and mining industry. *Mining Informational and Analytical Bulletin*. 2013;(S6):440–446. (In Russ.)
9. Герике П.Б., Герике Б.Л., Ещеркин П.В. Поиск параметров для универсальной прогнозной математической модели на основе анализа вибрации оборудования горных машин. *Вестник научного центра по безопасности работ в угольной промышленности*. 2022;(3):60–69. Gericke P.B., Gericke B.L., Eshherkin P.V. Parameters search for a universal forecasting mathematical model based on mining machinery equipment vibration analysis. *Bulletin of Research Center for Safety in Coal Industry (Industrial Safety)*. 2022;(3):60–69. (In Russ.)
10. Гончаров О.Ю. Методы анализа сигналов вибрации и их применимость для систем бортовой диагностики. *Технические науки – от теории к практике*. 2013;(22):29–33. Goncharov O.Yu. Analysis methods vibration signals and their applicability to-board diagnostic system. *Tekhnicheskie Nauki – ot Teorii k Praktike*. 2013;(22):29–33. (In Russ.)

11. Гриценко А.В., Шепелев В.Д., Альметова З.В., Шепелева Е.В. Диагностирование газораспределительного механизма виброакустическим методом. *Вестник южно-Уральского государственного университета. Серия: Машиностроение*. 2017;17(3):48–57. <https://doi.org/10.14529/engin170306>
Gritsenko A.V., Shepelev V.D., Almetova Z.V., Shepeleva E.V. Diagnosis of the gas distribution mechanism by the vibroacoustic. *Bulletin of the South Ural State University. Series: Mechanical Engineering Industry*. 2017;17(3):48–57. (In Russ.) <https://doi.org/10.14529/engin170306>
12. Дрыгин С.Ю. *Обоснование метода вибродиагностики технического состояния одноковшовых карьерных экскаваторов: дис. ... канд. техн. наук*. Кемерово; 2007. 169 с.
13. Барков А.В., Баркова Н.А., Якобсон П.П. *Современное состояние технических средств анализа вибрации*. 2003. Режим доступа: <https://masters.donntu.ru/2006/kita/kiselyov/library/analiz.htm> (дата обращения: 27.12.2024).
14. Мишанов Н.А., Захарова А.Г. Вибрация и вибродиагностика синхронных машин переменного тока. *Современные методы технической диагностики и неразрушающего контроля деталей и узлов*. 2017;(5). Режим доступа: <https://panor.ru/articles/vibratsiya-i-vibrodiagnostika-sinkhronnykh-mashin-peremennogo-toka/42037.html#> (дата обращения: 27.12.2024).
Mishanov N.A., Zakharova A.G. Vibration and vibrodiagnostics of synchronous ac motors. *Sovremennye Metody Tekhnicheskoi Diagnostiki i Nerazrushayushchego Kontrolya Detalei i Uzlov*. 2017;(5). (In Russ.) Available at: <https://panor.ru/articles/vibratsiya-i-vibrodiagnostika-sinkhronnykh-mashin-peremennogo-toka/42037.html#> (accessed: 27.12.2024).
15. Шулешко А.Н. *Вибродиагностика и виброзащита оборудования и конструкций обогатительных фабрик горно-обогатительных комбинатов: дис. ... канд. техн. наук*. Иркутск; 2004. 124 с.

Информация об авторах

Панина Ольга Владимировна – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: opanina@fa.ru

Завалько Наталья Александровна – доктор экономических наук, профессор кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: nazavalko@fa.ru

Еремин Сергей Геннадьевич – кандидат юридических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SGEremin@fa.ru

Харченко Константин Владимирович – кандидат социологических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: KVKharchenko@fa.ru

Зуденкова Светлана Александровна – кандидат экономических наук, доцент кафедры государственного и муниципального управления, Финансовый университет при Правительстве Российской Федерации, г. Москва, Российская Федерация; e-mail: SAZudenkova@fa.ru

Информация о статье

Поступила в редакцию: 18.01.2025

Поступила после рецензирования: 27.02.2025

Принята к публикации: 02.03.2025

Information about the authors

Olga V. Panina – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: opanina@fa.ru

Natalia A. Zavalko – Dr. Sci. (Econ.), Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: nazavalko@fa.ru

Sergey G. Eremin – Cand. Sci. (Law), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SGEremin@fa.ru

Konstantin V. Kharchenko – Cand. Sci. (Sociol.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: KVKharchenko@fa.ru

Svetlana A. Zudenkova – Cand. Sci. (Econ.), Associate Professor of the Department of State and Municipal Administration, Financial University under the Government of the Russian Federation, Moscow, Russian Federation; e-mail: SAZudenkova@fa.ru

Article info

Received: 18.01.2025

Revised: 27.02.2025

Accepted: 02.03.2025