

**МЕТОДЫ И ПРИБОРЫ КОНТРОЛЯ И ДИАГНОСТИКИ МАТЕРИАЛОВ,
ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ**
**METHODS AND DEVICES FOR MONITORING AND DIAGNOSTICS OF
MATERIALS, PRODUCTS, SUBSTANCES AND THE NATURAL ENVIRONMENT**

Научная статья

УДК 620.179.14

DOI: 10.26730/1999-4125-2024-3-88-98

**РАЗРАБОТКА АЛГОРИТМИЧЕСКОГО ОБЕСПЕЧЕНИЯ СИСТЕМЫ
ПОДГОТОВКИ ПРИНЯТИЯ РЕШЕНИЯ ПРИ ОЦЕНКЕ
РАБОТОСПОСОБНОСТИ И ПРОДЛЕНИИ РЕСУРСА ОБОРУДОВАНИЯ
ТЕХНИЧЕСКИХ УСТРОЙСТВ ОПАСНЫХ ПРОИЗВОДСТВЕННЫХ
ОБЪЕКТОВ**

Абабков Николай Викторович^{1,2}, Телегуз Александр Сергеевич²,
Пимонов Максим Владимирович^{1,2}

¹ Кузбасский государственный технический университет имени Т.Ф. Горбачева

² Федеральный исследовательский центр угля и углехимии СО РАН

*для корреспонденции: ababkovnv@kuzstu.ru



Информация о статье

Поступила:

29 марта 2024 г.

Одобрена после

рецензирования:

29 мая 2024 г.

Принята к публикации:

29 мая 2024 г.

Опубликована:

28 июня 2024 г.

Ключевые слова:

неразрушающий контроль,
микрповрежденность,
нейронные сети, остаточный
ресурс, металлические
конструкции, машинное
обучение

Аннотация.

Обеспечение надежности и безопасности металлоконструкций является ключевой задачей для инженеров и специалистов по обслуживанию. В этом контексте неразрушающий контроль (НК) становится неотъемлемой частью процесса мониторинга состояния металлических конструкций. При этом возникают трудности при выборе критерия для оценки работоспособности и интерпретации полученных в результате расчетов значений, что влияет на качество принятия решения о работоспособности и оценке возможности и способа продления ресурса. В работе рассмотрен процесс разработки API (программного интерфейса приложения) машинного обучения на языке программирования Python, предназначенной для решения задачи предсказания текущего состояния металлических конструкций на основе данных неразрушающего контроля (НК). Разработанное API позволило пользователям создавать более сложные и информативные признаки на базе исходных данных, что может повысить точность и способность моделей машинного обучения предсказывать состояние металлических конструкций и данных НК. В результате проведенных исследований по оценке влияния характеристик применяемых алгоритмов МО на качество и скорость прогнозирования состояния металлических конструкций из стали 20 и 12Х1МФ по параметрам неразрушающего контроля (НК) была произведена классификация топологий моделей МО на основе качества прогнозирования и принятия решений. Разработаны научные основы для алгоритмического обеспечения системы подготовки принятия решения при оценке работоспособности и продлении ресурса оборудования технических устройств опасных производственных объектов на основе применения искусственных нейронных сетей, представляющие собой последовательность операций, общих для разных классов и марок сталей, а также для оборудования, которое эксплуатируется в различных условиях (кроме ударных).

Для цитирования: Абабков Н.В., Телегуз А.С., Пимонов М.В. Разработка алгоритмического обеспечения системы подготовки принятия решения при оценке работоспособности и продлении ресурса оборудования технических устройств опасных производственных объектов // Вестник Кузбасского государственного технического университета. 2024. № 3 (163). С. 88-98. DOI: 10.26730/1999-4125-2024-3-88-98, EDN: OSJDCR

Благодарности

Работа выполнена при финансовой поддержке гранта РНФ, соглашение № 22-29-20192, и гранта Кемеровской области – Кузбасса, соглашение №16.

Введение

Металлические конструкции играют важную роль в современном мире, служа как основой для зданий и мостов, так и частями критически важных инфраструктурных систем [1–8]. Поддержание их надежности и безопасности является ключевой задачей для инженеров и специалистов по обслуживанию. В этом контексте неразрушающий контроль (НК) становится неотъемлемой частью процесса мониторинга состояния металлических конструкций [9–17].

Вместе с ростом сложности конструкций возрастает и значимость задач, связанных с обеспечением их долгосрочной эксплуатации. Традиционные методы НК могут быть трудоемкими и требовать значительных временных и финансовых затрат. Именно здесь машинное обучение предоставляет возможность революционизировать методы контроля и обследования, прогнозируя состояние конструкций на основе данных, полученных в результате НК.

К настоящему времени разработан ряд критериев оценки предельного состояния длительно работающего металла на основе физической модели превращения субструктур, изменения полей внутренних напряжений и акустических характеристик в сварных соединениях металлических материалов [4].

Спектрально-акустический метод неразрушающего контроля, который был использован при разработке вышеобозначенных критериев, может как применяться для обнаружения существующих дефектов, так и определять степень изменения структуры металла в процессе длительной эксплуатации. Измеряемые данным методом характеристики, такие как скорость распространения поверхностных акустических волн, коэффициент затухания принятого сигнала, имеют связь с механическими свойствами материалов [4].

Однако широкое применение данного подхода затрудняется из-за трудоемкости получения ряда экспериментальных данных (электронная микроскопия), используемых в зависимостях, и значительных финансовых затрат. Кроме того, возникают трудности в выборе критерия при оценке работоспособности и интерпретации полученных в результате

расчетов значений, что влияет на качество принятия решения о работоспособности и оценке возможности и способа продления ресурса [18–20].

Решение данной проблемы возможно за счет создания алгоритмического обеспечения системы подготовки принятия решения при оценке работоспособности и продлении ресурса металлоконструкций, реализация которой основана на применении нейросетевых моделей и эволюционных методов, а также разработки аппаратно-программного комплекса.

Целью данной статьи является разработка алгоритмического обеспечения системы подготовки принятия решения при оценке работоспособности и продлении ресурса оборудования технических устройств опасных производственных объектов, включая разработку API (программного интерфейса приложения) машинного обучения на языке программирования Python, предназначенной для решения задачи предсказания текущего состояния металлических конструкций на основе данных НК, которая может стать мощным инструментом как для инженеров, занимающихся обслуживанием конструкций, так и для специалистов по НК. Вопрос разработки API (программного интерфейса приложения) машинного обучения на языке программирования Python был рассмотрен в рамках работы, представленной на XIV МНТК «Инновации в машиностроении – 2023» [21]. Таким образом, настоящая работа является дополнением к ранее представленным исследованиям.

Результаты и обсуждение

Ранее были проведены исследования по применению моделей МО на основе алгоритмов «Случайного леса», «Логистической регрессии» и метода «К-ближайших соседей» для прогнозирования состояния паропроводов по данным акустического и магнитного контроля: время задержки поверхностной волны Релея (R , нс), скорость распространения поверхностной волны Релея (V , м/с), коэффициент затухания поверхностной волны Релея ($K_{\text{зат}}$, 1/мкс), размах амплитуды принятого сигнала (A , б/в) и интенсивность магнитного шума (MNI , б/в). Исследования проведены для оборудования, изготовленного из сталей марок 20 и 12X1МФ,

после разных сроков эксплуатации, в том числе в зонах локализации деформаций [22–29]. Для каждой из сталей были отобраны различные признаки, взятые из перечисленных, не коррелирующие друг с другом, и выполнена оптимизация гиперпараметров для каждого из трех используемых алгоритмов МО, результаты исследования были включены в базу данных [30], которая в дальнейшем используется в разрабатываемом приложении [31].

Интеграция нейросетевой модели с приложением для работы с базой данных характеристик неразрушающего контроля различных марок сталей, разработка интерфейса вывода рекомендаций по оценке продления ресурса технических устройств опасных производственных объектов

Повышение качества обучения линейных классификационных моделей за счет выделения новых признаков, полученных методом *k*-средних, и их сравнение с нелинейным классификатором Random Forest. Последовательное обучение двух линейных моделей значительно дешевле, чем обучение одной нелинейной.

Метод *K*-means (*k*-средних) – это алгоритм кластеризации данных, который используется для разделения данных на группы или кластеры на основе близости между точками данных. Этот метод имеет несколько математических принципов, которые могут быть применены для извлечения признаков и улучшения классификации данных:

1. Определение количества кластеров: перед началом кластеризации необходимо определить количество кластеров, которые будут использоваться для разделения данных. Это количество может быть определено на основе анализа данных или на основе экспертных знаний.

2. Выбор начальных центров кластеров: для начала кластеризации нужно выбрать начальные центры кластеров. Эти центры могут быть выбраны случайным образом или на основе некоторых алгоритмов выбора центра.

3. Обновление центров кластеров: после выбора начальных центров кластеров происходит процесс обновления центров кластеров. Для этого каждая точка данных присваивается ближайшему центру кластера. Затем центры кластеров пересчитываются на основе новых данных.

4. Повторение процесса: процесс обновления центров кластеров повторяется до тех пор, пока не будет достигнуто желаемое количество кластеров или до тех пор, пока центры кластеров не перестанут меняться.

5. Извлечение признаков: после кластеризации можно извлечь признаки из данных, используя информацию о том, какие

точки данных принадлежат к какому кластеру. Например, можно использовать среднее значение или медиану значений признаков для каждого кластера.

Подбор оптимальных гиперпараметров осуществлялся с помощью рандомизированного поиска. Впоследствии оптимальные гиперпараметры модели Random Forest и других классификационных моделей машинного обучения (*KNN* и Логистическая регрессия) для различных комбинаций признаков, подаваемых на вход, были занесены в базу данных [29] и использовались в специализированном программном обеспечении [30]. Программа для расчета текущего состояния и оценки работоспособности оборудования топливно-энергетического комплекса оценивает текущее состояние металлической конструкции из стали 20 и 12Х1МФ и дает прогноз о сроке дальнейшей безаварийной эксплуатации изделия и дате технического обслуживания и ремонта (Рис. 1).

Наибольшую эффективность показали модели на основе алгоритма «Случайного леса», создание и обучение моделей выполнено с использованием библиотеки *scikit-learn*. Также «древесные» модели являются легко интерпретируемыми и позволяют оценить относительную важность признаков (Рис. 2).

Однако алгоритм «Случайного леса» является нелинейным и трудоемким при обучении, что затрудняет прогнозирование текущего состояния конструкции на сталях других марок. Путем выделения новых признаков из обучающих данных методом кластеризации «*k*-средних» и последующим включением этих признаков в линейные модели «Логистической регрессии» и «*K*-ближайших соседей» удалось повысить точность прогнозирования, приблизив ее к результатам, полученным на нелинейной модели, и снизив вычислительные затраты на обучение.

Кривая рабочей характеристики приемника (*receiver operating characteristic*, ROC-кривая) – это графическое представление результатов классификации или предсказания на основе данных. Она позволяет визуализировать соотношение ошибок и их распределение по классам и используется для сравнения эффективности различных моделей машинного обучения и выбора оптимального алгоритма для конкретной задачи (Рис. 3).

На оси абсцисс откладывается доля правильно классифицированных объектов, а на оси ординат – доля ошибок.

По форме ROC-кривой можно сделать выводы о качестве модели и ее способности к обобщению данных. Например, если ROC-кривая имеет форму перевернутой буквы «U» или «V», то это означает, что модель хорошо справляется с классификацией большинства объектов, но плохо предсказывает некоторые

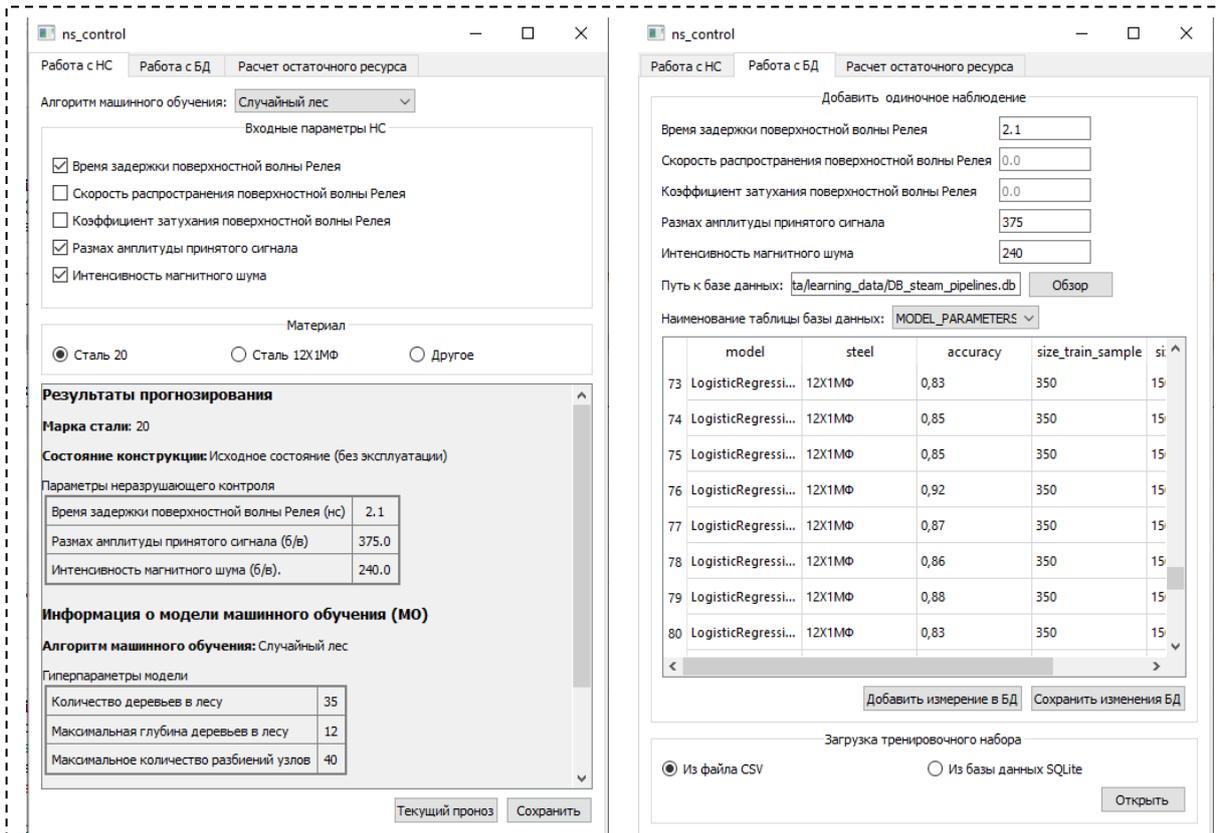


Рис. 1. Интерфейс программы для расчета текущего состояния и оценки работоспособности оборудования топливно-энергетического комплекса

Fig. 1. Program interface for calculating the current state and assessing the performance of equipment in the fuel and energy complex

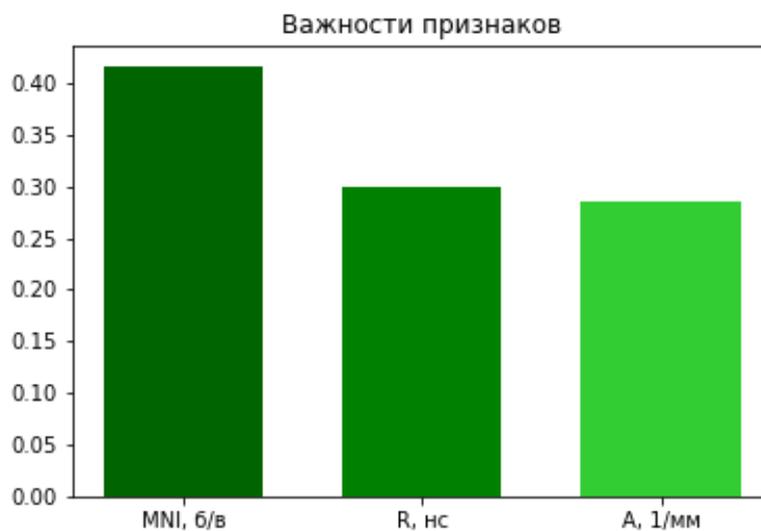


Рис. 2. Важность признаков обученной модели случайного леса

Fig. 2. Importance of features of the trained random forest model

редкие классы. Если же ROC-кривая является прямой линией, то это указывает на то, что модель не способна обобщать данные и плохо классифицирует все классы.

Из Рис. 3 видно, что модель логистической регрессии, вектор признаков которой включает результаты кластеризации, близка по эффективности к нелинейной модели Random Forest.

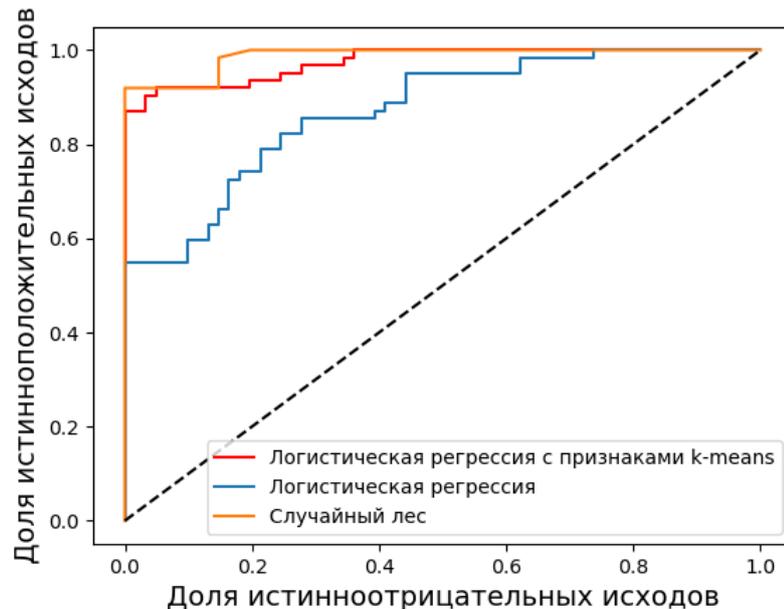


Рис. 3. ROC-кривая, построенная на результатах предсказания двух классов тестовой выборки
 Fig. 3. ROC-curve built on the results of prediction of two classes of test sample

Создание API библиотеки для оценки текущего состояния и прогнозирования остаточного ресурса металлоконструкций по данным неразрушающего контроля

API (интерфейс программирования приложения) упрощает процесс программирования при создании приложений, абстрагируя базовую реализацию и предоставляя только объекты или действия, необходимые разработчику.

Программа предназначена для оценки текущего состояния металлической конструкции по данным неразрушающего контроля и может быть использована при оценке работоспособности и продления ресурса технических устройств на опасных производственных объектах (Рис. 1). Функциональные возможности программы включают:

- предсказание текущего состояния конструкции по выбранным параметрам неразрушающего контроля на основе выбранного алгоритма машинного обучения с оценкой точности предсказания;
- экспорт и импорт базы данных с фиксированной структурой, а также внесение в нее изменений;
- возможность поиска оптимальных параметров выбранного алгоритма машинного обучения по данным неразрушающего контроля, предоставленным пользователем.

С учетом вышеупомянутых этапов подготовки разрабатываемый API должен включать следующий функционал:

1. Загрузка данных:

- поддержка загрузки данных из файлов CSV и баз данных SQLite;
 - возможность указания местоположения файла или соединения с базой данных.
- #### 2. Подготовка данных:
- парсинг и обработка данных из источника для подготовки их к дальнейшей обработке и анализу;
 - преобразование данных в формат, пригодный для обучения моделей машинного обучения.
- #### 3. Выделение новых признаков:
- разработка функций и методов, позволяющих анализировать и преобразовывать существующие признаки для создания новых, более информативных признаков;
 - возможность применения различных методов инженерии признаков, таких как масштабирование и нормализация;
 - автоматизированное выделение наиболее значимых признаков на основе анализа данных и задачи предсказания.
- #### 4. Обучение моделей:
- отбор признаков, наиболее подходящих для заданного пользователем алгоритма машинного обучения и выбранной марки стали;
 - оптимизация гиперпараметров модели;
 - обучение модели на предоставленных данных.
- #### 5. Оценка качества модели:
- реализация метрик оценки производительности модели, таких как точность, чувствительность и другие, в зависимости от задачи;

- предоставление результатов оценки для анализа.

6. Сохранение модели:

- возможность сохранения обученной модели в файл или базу данных для последующего использования.

7. Прогнозирование:

- поддержка ввода новых данных, предоставленных в формате, совместимом с обученной моделью;

- возможность получения предсказаний текущего состояния металлической конструкции на основе введенных данных.

8. Обработка ошибок:

- обработка и сообщение об ошибках, возникающих в процессе загрузки данных, обучения модели или предсказания.

9. Интерфейс пользователя:

- создание пользовательского интерфейса, который может быть использован для взаимодействия с API через приложение.

10. Документация:

- предоставление подробной документации, описывающей методы и параметры API, а также примеры использования.

API с таким функционалом позволит пользователям создавать более сложные и информативные признаки на базе исходных данных, что может повысить точность и способность моделей машинного обучения предсказывать состояние металлических конструкций. Такое обновление и улучшение моделей становится важным в условиях постоянной эволюции состояния конструкций и данных НК.

В дальнейшей перспективе функционал API может быть расширен: добавлена возможность обновления обученных моделей с учетом новых признаков и возможность применения обучения с подкреплением по мере роста базы обучающих примеров.

Классификация топологий искусственных нейронных сетей на основе оценки и анализа качества прогнозирования и принятия решений.

Классификационные модели машинного обучения (МО), используемые для прогнозирования текущего состояния металлических конструкций, по топологии могут быть разделены следующим образом:

1. Ансамблевые модели, основанные на деревьях. В данных моделях используются комбинации нескольких базовых, как правило, однотипных моделей для дальнейшего обобщения результатов их предсказаний с целью увеличения производительности. Базовые модели обучаются независимо друг от друга, поэтому их обучение может проходить в параллельных потоках. Случайный лес (Random Forest) является ансамблем решающих деревьев. Он обучает несколько деревьев на случайных

подмножествах данных и усредняет их прогнозы, что улучшает обобщение и устойчивость к переобучению. Градиентный бустинг (Gradient Boosting) также является ансамблевой моделью. Он обучает более простые модели (чаще всего это неглубокие Random Forest) последовательно, каждый из этапов исправляет ошибки предыдущего. Этот алгоритм фокусируется на тех областях данных, где простая модель ошибается. Обучение модели Градиентного бустинга также можно распараллелить в рамках одной итерации.

2. Модели, полученные в результате стекирования (Stacking) простых моделей МО. Stacking объединяет прогнозы нескольких базовых моделей с помощью метамодели. Метамодель обучается принимать решения на основе прогнозов базовых моделей. Тренировку базовых моделей можно проводить параллельно, но при обучении метамодели в качестве признаков выступают целевые переменные базовых моделей, что исключает многопоточность вычислений. Как показали исследования (Рис. 3), стекирование алгоритма кластеризации k -средних и логистической регрессии позволило улучшить качество модели.

3. Базовые модели

3.1 Линейные модели. Линейные модели ограничены в моделировании сложных взаимосвязей. В таких случаях необходимо применение методов выделения признаков с целью снижения размера признакового пространства, что позволит проецировать линейно неразделимые данные в более высокую размерность, где они линейно разделимы. Логистическая регрессия (Logistic Regression) использует логистическую функцию для преобразования линейной комбинации признаков в вероятность принадлежности к классу. Также в задачах классификации применяются такие линейные модели, как линейный дискриминантный анализ (LDA) и метод опорных векторов (SVM). Линейные модели обладают простотой и быстротой обучения, а также хорошо интерпретируемы.

3.2. Метод K -ближайших соседей (k -NN). Технически K -NN не тренирует модель, вместо этого K -NN классифицирует объект, основываясь на классах его K -ближайших соседей. K -NN является простым и часто используемым классификатором, обладает хорошей способностью к обработке нелинейных взаимосвязей. К недостаткам классификатора следует отнести чувствительность к выбросам и необходимость масштабирования признаков.

3.3. Методы неконтролируемого обучения. К неконтролируемому обучению относятся самообучающиеся алгоритмы, которые не используют информацию о целевой переменной, что позволяет увеличить объем тренировочной

выборки (не нужно выделять тестовую выборку). Часто такие алгоритмы используются для кластеризации данных и как методы отбора и выделения признаков. Метод k -средних (k -means) разбивает данные на k кластеров, минимизируя среднеквадратичное отклонение между точками и центроидами кластеров. К неконтролируемому обучению также относится метод главных компонент (PCA), используемый для снижения размерности пространства признаков.

Выводы

1. Разработанное API позволило пользователям создавать более сложные и информативные признаки на базе исходных данных, что может повысить точность и способность моделей машинного обучения предсказывать состояние металлических конструкций. Такое обновление и улучшение моделей становится важным в условиях постоянной эволюции состояния конструкций и данных НК.

2. Рассмотрена область влияния ключевых характеристик представленных моделей МО, влияющих на качество и скорость обучения, к которым следует отнести: количество обучающих примеров, размерность признакового пространства, гиперпараметры модели, способы обработки пропущенных данных и выбросов и многопоточную обработку данных. В результате проведенных исследований по оценке влияния характеристик применяемых алгоритмов МО на качество и скорость прогнозирования состояния металлических конструкций из стали 20 и 12Х1МФ по параметрам неразрушающего контроля (НК) была произведена классификация топологий моделей МО на основе качества прогнозирования и принятия решений.

3. Разработанные научные основы алгоритмического обеспечения системы подготовки принятия решения при оценке работоспособности и продлении ресурса оборудования технических устройств опасных производственных объектов на основе применения искусственных нейронных сетей представляют собой последовательность операций, общих для разных классов и марок сталей, а также для оборудования, которое эксплуатируется в различных условиях (кроме ударных).

Список литературы

1. Гринь Е. А. Повышение рабочего ресурса элементов теплосилового оборудования электростанций с учетом макроповреждаемости металла». Автореферат дис. ... доктора технических наук. М., 2010.

2. Makhutov N. A. Generalized regularities of deformation and fracture processes // *Her. Russ. Acad. Sci.* 2017. №87. Pp. 217–228.

3. Rezinskikh V. F., Grin' E. A. Reliability and safety of thermal power stations in Russia at the present stage: problems and future objectives // *Therm. Eng.* 2010. №57. Pp. 1–8.

4. Смирнов А. Н. Эволюция микроструктуры и критерии предельного состояния при прогнозировании работоспособности теплоустойчивых сталей: диссертация ... доктора технических наук : 05.16.01, 05.02.11. Новосибирск, 2004. 397 с.

5. Клюев В. В. Деграция диагностики безопасности. Москва : Издательский дом «Спектр», 2012. 128 с.

6. Березина Т. Г., Бугай Н. В., Трунин И. И. Диагностирование и прогнозирование долговечности металла теплоэнергетических установок. Киев : Техника, 1991. 120 с.

7. Структурно-фазовые состояния перспективных металлических материалов: Коллективная монография: под ред. Громова В. Е. Новокузнецк : Изд-во НПК, 2009. 613 с.

8. Getsov L., Rybnikov A., Semenov A., Semenov S., Tikhomirova E. Thermal fatigue of singlecrystal superalloys: Experiments, crack-initiation and crack-propagation criteria // *Mater. Tehnol.* 2015. №49. Pp. 773–778.

9. Konovalov S., Ivanov Y., Gromov V. Fatigue-induced evolution of AISI 310S steel microstructure after electron beam treatment // *Materials.* 2020. Т. 13. № 20. Pp. 1–13.

10. Куманин В. И. Структура, поврежденность и работоспособность теплостойкой стали при длительной эксплуатации // *МиТОМ.* 1980. №12. С.26–29.

11. Ковпак В. И. К вопросу о прогнозировании остаточной долговечности металлических материалов // *Проблемы прочности.* 1981. №10. С. 95–99.

12. Антикайн П. А., Зыков А. К. Изготовление объектов котлонадзора. Справочное издание. Металлургия. 1988. 328 с.

13. Куманин В. И. Структура, поврежденность и работоспособность теплостойкой стали при длительной эксплуатации // *МиТОМ.* 1980. №12. С.26–29.

14. Котельников В. В. Акимов Д. А., Козельская С. О., Гурьянова Е. О. Разработка программного обеспечения и методики прогнозирования ресурса эксплуатации сложных конструкций на основе результатов хронологической диагностики технического состояния и искусственного интеллекта // *Контроль. Диагностика.* 2022. Т. 25. № 1. С. 26–37.

15. Botvina L. R., Kushnarenko V. M., Tyutin M. R., Levin V. P., Morozov A. E., Bolotnikov A. I. Fracture Stages and Residual Strength of Pipe Steel after Long-Term Operation // *Phys. Mesomech.* 2021. №24. Pp. 475–485.

16. Котельников В. В. Методика прогнозирования эксплуатационной безопасности

конструкций на основе применения комплексного неразрушающего контроля и методов искусственного интеллекта // Сварка и диагностика. 2021. № 1. С. 23–28.

17. Smirnov A. N., Ozhiganov E. A., Danilov V. I., Gorbatenko V. V., Murav'ev V. V. The dependence of local deformations and internal stress fields on welding technique for grade VSt3sp structural steel: I. The influence of welding technique on the mechanical characteristics and acoustic emission parameters of grade VSt3sp steel // Russian Journal of Nondestructive Testing. 2015. Vol. 51. № 11. Pp. 705–712. DOI: 10.1134/S1061830915110066.

18. Муравьев В. В., Муравьева О. В., Стрижак В. А. Акустическая тензометрия и структурокопия железнодорожных колес [и др.] Ижевск : Изд-во ИжГТУ имени М.Т. Калашникова, 2014. 180 с.

19. Murav'ev V. V., Murav'eva O. V., Petrov K. V. Connection between the properties of 0.4 Cr steel bar stock and the speed of bulk and rayleigh waves // Russian Journal of Nondestructive Testing. 2017. Vol. 53. №8. Pp. 560–567. DOI: 10.1134/S1061830917080046.

20. Muravev V. V., Lenkov S. V., Tapkov K. A. In-Production Nondestructive Testing of Internal Stresses in Rails Using Acoustoelasticity Method // Russian Journal of Nondestructive Testing. 2019. Vol. 55. №1. Pp. 8–14.

21. Абабков Н. В., Телегуз А. С., Пимонов М. В. Создание API библиотеки для оценки текущего состояния и прогнозирования остаточного ресурса металлоконструкций по данным неразрушающего контроля // Инновации в машиностроении (ИнМаш-2023): Сборник трудов XIV МНТК. Кемерово: КузГТУ, 2023. С. 146–151.

22. Zuev L. B. Chernov–Luders and Portevin–Le Chatelier deformations in active deformable media of different nature // Journal of Applied Mechanics and Technical Physics. 2017. №58(2). Pp. 328–334.

23. Zuev L. B. Autowave mechanics of plastic flow in solids // Physics of Wave Phenomena. 2012.

Vol. 20. № 3. Pp. 166–173.

24. Danilov V. I., Barannikova S. A., Zuev L. B. Localized Strain Autowaves at the Initial Stage of Plastic Flow in Single Crystals // Technical Physics. 2003. Vol. 48. № 11. P. 1429–1435.

25. Danilov V. I., Gorbatenko V. V., Orlova D. V., Danilova L. V., Smirnov A. N. Luders Deformation in Weld Joints // Steel in Translation. 2018. Vol. 48. №2. Pp. 87–92.

26. Зуев Л. Б., Данилов В. И., Баранникова С. А., Плосков Н. А. О природе упругопластического инварианта деформации // ЖТФ. 2018. Т. 88. №6. С. 855–859.

27. Danilov V. I., Gorbatenko V. V., Zuev L. B. On the kinetics of mobile Chernov–Luders band fronts // AIP Conference Proceedings. 2016. Vol. 1783. 020035.

28. Gorbatenko V. V., Danilov V. I., Zuev L. B. Elastoplastic transition in material with sharp yield point // AIP Conference Proceedings. 2015. Vol. 1683. 020058.

29. Danilov V. I., Orlova D. V., Zuev L. B. On the kinetics of localized plasticity domains emergent at the pre-failure stage of deformation process // Materials and Design. 2011. 32. 1554–1558.

30. Абабков Н. В., Ефременкова М. В., Никитенко М. С., Пимонов М. В., Смирнов А. Н., Телегуз А. С. Свидетельство о регистрации базы данных 2023620325, 20.01.2023. База данных структурных, акустических и магнитных характеристик в металле оборудования топливноэнергетического комплекса // Заявка № 2022623693 от 14.12.2022.

31. Смирнов А. Н., Абабков Н. В., Никитенко М. С. [и др.] Программный модуль оценки состояния горнодобывающего оборудования на основе закономерностей изменения структурно-фазового состояния и полей внутренних напряжений металла // Вестник Кузбасского государственного технического университета. 2022. № 6(154). С. 50–58.

© 2024 Авторы. Эта статья доступна по лицензии Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (<https://creativecommons.org/licenses/by/4.0/>)

Авторы заявляют об отсутствии конфликта интересов.

Об авторах:

Абабков Николай Викторович, заведующий кафедрой технологии машиностроения ФГБОУ ВО «Кузбасский государственный технический университет имени Т.Ф. Горбачева», г. Кемерово, ул. Весенняя, 28 к.т.н., доцент, e-mail: ababkovnv@kuzstu.ru, ORCID: <http://orcid.org/0000-0003-0794-8040>

Телегуз Александр Сергеевич, научный сотрудник лаборатории перспективных методов управления горнотехническими системами Института угля ФИЦ УУХ СО РАН, г. Кемерово, пр-т Ленинградский, 10, e-mail: alexanderteleгуз@rambler.ru, ORCID: <https://orcid.org/0009-0008-4293-4959>

Пимонов Максим Владимирович, доцент кафедры технологии машиностроения ФГБОУ ВО «Кузбасский государственный технический университет имени Т.Ф. Горбачева», г. Кемерово, ул. Весенняя, 28, к.т.н., e-mail: pimonomv@kuzstu.ru, ORCID: <https://orcid.org/0000-0001-9509-4692>

Заявленный вклад авторов:

Абабков Николай Викторович – постановка исследовательской задачи, сбор и анализ данных, обзор соответствующей литературы, выводы, корректировка текста.

Телегуз Александр Сергеевич – сбор и анализ данных, обзор соответствующей литературы, выводы, написание текста.

Пимонов Максим Владимирович – научный менеджмент, обзор соответствующей литературы, концептуализация исследования, выводы, написание текста.

Все авторы прочитали и одобрили окончательный вариант рукописи.

Original article

DEVELOPMENT OF ALGORITHMIC SUPPORT FOR A DECISION-MAKING PREPARATION SYSTEM WHEN ASSESSING THE PERFORMANCE AND EXTENDING THE LIFE OF EQUIPMENT OF TECHNICAL DEVICES OF HAZARDOUS PRODUCTION FACILITIES

Nikolay Viktorovich Ababkov^{1,2}, Alexander Sergeevich Teleguz²,
Maxim Vladimirovich Pimonov^{1,2}

¹T. F. Gorbachev Kuzbass State Technical University

²The Federal Research Center of Coal and Coal-Chemistry SB RAS

*for correspondence: ababkovnv@kuzstu.ru



Article info

Received:

29 March 2024

Accepted for publication:

29 May 2024

Accepted:

29 May 2024

Published:

28 June 2024

Keywords:

non-destructive testing,
microdamage, neural networks,
residual life, metal structures,
machine learning

Abstract.

Ensuring the reliability and safety of steel structures is a key challenge for engineers and maintenance professionals. In this context, non-destructive testing (NDT) becomes an integral part of the process of monitoring the condition of metal structures. At the same time, difficulties arise when choosing a criterion for assessing performance and interpreting the values obtained as a result of calculations, which affects the quality of decision-making on performance and assessing the possibility and method of extending the resource. The paper discusses the process of developing an API (application program interface) for machine learning in the Python programming language, designed to solve the problem of predicting the current state of metal structures based on non-destructive testing (NDT) data. The developed API allowed users to create more complex and informative features based on raw data, which can improve the accuracy and ability of machine learning models to predict the condition of metal structures. Such updating and improvement of models becomes important in the context of constant evolution of the state of structures and NDT data. As a result of the research conducted to assess the influence of the characteristics of the applied ML algorithms on the quality and speed of predicting the state of metal structures made of structural steel and 0.12C-1Cr-1Mo-1Va steel according to non-destructive testing (NDT) parameters, a classification of topologies of ML models was made based on the quality of prediction and decision making. The scientific foundations of the algorithmic support of the decision-making preparation system for assessing the performance and extending the service life of technical devices of hazardous production facilities have been developed based on the use of artificial neural networks; they represent a sequence of operations common to different classes and grades of steel, as well as for equipment that is operated in different conditions (except drums).

For citation: Ababkov N.V., Teleguz A.S., Pimonov M.V. Development of algorithmic support for a decision-making preparation system when assessing the performance and extending the life of equipment of technical devices of hazardous production facilities. *Vestnik Kuzbasskogo gosudarstvennogo tekhnicheskogo universiteta*=Bulletin of the Kuzbass State Technical University. 2024; 3(163):88-98. (In Russ., abstract in Eng.). DOI: 10.26730/1999-4125-2024-3-88-98, EDN: OSJDCR

Acknowledgements

The work was carried out with the financial support of the RNF grant, Agreement No. 22-29-20192, and the Kemerovo Region–Kuzbass grant, Agreement No. 16.

REFERENCES

1. Grin' Ye.A. Povysheniye rabocheho resursa elementov teplosilovogo oborudovaniya elektrostantsiy s uchedom makropovrezhdayemosti metalla» avtoreferat dis. ... doktora tekhnicheskikh nauk. Moscow. 2010.
2. Makhutov N.A. Generalized regularities of deformation and fracture processes. *Her. Russ. Acad. Sci.* 2017; 87:217–228.
3. Rezin'skikh V.F., Grin' E.A. Reliability and safety of thermal power stations in Russia at the present stage: problems and future objectives. *Therm. Eng.* 2010; 57:1–8.
4. Smirnov A.N. Evolyutsiya mikrostruktury i kriterii predel'nogo sostoyaniya pri prognozirovaniy rabotosposobnosti teploustoychivyykh staley: dissertatsiya ... doktora tekhnicheskikh nauk : 05.16.01, 05.02.11 Novosibirsk. 2004. 397 s.
5. Klyuyev V.V. Degradatsiya diagnostiki bezopasnosti. Moskva: Izdatel'skiy dom «Spektr»; 2012. 128 s.
6. Berezina T.G., Bugay N.V., Trunin I.I. Diagnostirovaniye i prognozirovaniye dolgovechnosti metalla teploenergeticheskikh ustanovok. Kiyev: Tekhnika; 1991. 120 s.
7. Strukturno-fazovyye sostoyaniya perspektivnykh metallicheskikh materialov: Kollektivnaya monografiya: pod red. Gromova V.Ye. Novokuznetsk: Izd-vo NPK; 2009. 613 s.
8. Getsov L., Rybnikov A., Semenov A., Semenov S., Tikhomirova E. Thermal fatigue of singlecrystal superalloys: Experiments, crack-initiation and crack-propagation criteria. *Mater. Tehnol.* 2015; 49:773–778.
9. Konovalov S., Ivanov Y., Gromov V. Fatigue-induced evolution of AISI 310S steel microstructure after electron beam treatment. *Materials.* 2020; 13(20):1–13.
10. Kumanin V.I. Struktura, povrezhdennost' i rabotosposobnost' teplostoykoy stali pri dlitel'noy ekspluatatsii. *MiTOM.* 1980; 12:26–29.
11. Kovpak V.I. K voprosu o prognozirovaniy ostatochnoy dolgovechnosti metallicheskikh materialov. *Problemy prochnosti.* 1981; 10:95–99.
12. Antikayn P.A., Zykov A.K. Izgotovleniye ob'yektov kotlonadzora. Spravochnoye izdaniye. Metallurgiya. 1988. 328c.
13. Kumanin V.I. Struktura, povrezhdennost' i rabotosposobnost' teplostoykoy stali pri dlitel'noy ekspluatatsii. *MiTOM.* 1980; 12:26–29.
14. Kotel'nikov V.V. Akimov D.A., Kozel'skaya S.O., Gur'yanova Ye.O. Razrabotka programmnogo obespecheniya i metodiki prognozirovaniya resursa ekspluatatsii slozhnykh konstruksiy na osnove rezul'tatov khronologicheskoy diagnostiki tekhnicheskogo sostoyaniya i iskusstvennogo intellekta. *Kontrol'. Diagnostika.* 2022; 25(1):26–37.
15. Botvina L.R., Kushnarenko V.M., Tyutin M.R., Levin V.P., Morozov A.E., Bolotnikov A.I. Fracture Stages and Residual Strength of Pipe Steel after Long-Term Operation. *Phys. Mesomech.* 2021; 24:475–485.
16. Kotel'nikov V.V. Metodika prognozirovaniya ekspluatatsionnoy bezopasnosti konstruksiy na osnove primeneniya kompleksnogo nerazrushayushchego kontrolya i metodov iskusstvennogo intellekta. *Svarka i diagnostika.* 2021; 1:23–28.
17. Smirnov A.N., Ozhiganov E.A., Danilov V.I., Gorbatenko V.V., Murav'ev V.V. The dependence of local deformations and internal stress fields on welding technique for grade VSt3sp structural steel: I. The influence of welding technique on the mechanical characteristics and acoustic emission parameters of grade VSt3sp steel. *Russian Journal of Nondestructive Testing.* 2015; 51(11):705–712. DOI: 10.1134/S1061830915110066.
18. Murav'yev V.V., Murav'yeva O.V., Strizhak V.A., [et al.] Akusticheskaya tenzometriya i strukturoskopiya zheleznodorozhnykh koles. Izhevsk: Izd-vo IzhGTU imeni M.T. Kalashnikova; 2014. 180 s.
19. Murav'ev V.V., Murav'eva O.V., Petrov K.V. Connection between the properties of 0.4Cr steel bar stock and the speed of bulk and rayleigh waves. *Russian Journal of Nondestructive Testing.* 2017; 53(8):560–567. DOI: 10.1134/S1061830917080046.
20. Muravev V.V., Lenkov S.V., Tapkov K.A. In-Production Nondestructive Testing of Internal Stresses in Rails Using Acoustoelasticity Method. *Russian Journal of Nondestructive Testing.* 2019; 55(1):8–14.
21. Ababkov N.V., Teleguz A.S., Pimonov M.V. Sozdaniye API biblioteki dlya otsenki tekushchego sostoyaniya i prognozirovaniya ostatochnogo resursa metallokonstruksiy po dannym nerazrushayushchego kontrolya. *Innovatsii v mashinostroyenii (InMash-2023): Sbornik trudov XIV MNTK.* Kemerovo: KuzGTU; 2023.
22. Zuev L.B. Chernov–Luders and Portevin–Le Chatelier deformations in active deformable media of different nature. *Journal of Applied Mechanics and Technical Physics.* 2017. 58(2):328–334.
23. Zuev L.B. Autowave mechanics of plastic flow in solids. *Physics of Wave Phenomena.* 2012; 20(3):166–173.
24. Danilov V.I., Barannikova S.A., Zuev L.B. Localized Strain Autowaves at the Initial Stage of Plastic Flow in Single Crystals. *Technical Physics.* 2003; 48(11):1429–1435.
25. Danilov V.I., Gorbatenko V.V., Orlova D.V., Danilova L.V., Smirnov A.N. Luders Deformation in Weld Joints. *Steel in Translation.* 2018; 48(2):87–92.

26. Zuev L.B., Danilov V.I., Barannikova S.A., Ploskov N.A. O prirode uprugoplasticheskogo invarianta deformatsii. *ZHTF*. 2018; 88(6):855–859.

27. Danilov V.I., Gorbatenko V.V., Zuev L.B. On the kinetics of mobile Chernov–Luders band fronts. *AIP Conference Proceedings*. 2016; 1783:020035.

28. Gorbatenko V.V., Danilov V.I., Zuev L.B. Elastoplastic transition in material with sharp yield point. *AIP Conference Proceedings*. 2015; 1683:020058.

29. Danilov V.I., Orlova D.V., Zuev L.B. On the kinetics of localized plasticity domains emergent at the pre-failure stage of deformation process. *Materials and Design*. 2011; 32:1554–1558.

30. Ababkov N.V., Yefremenkova M.V., Nikitenko M.S., Pimonov M.V., Smirnov A.N., Teleguz

A.S. Svidetel'stvo o registratsii bazy dannykh 2023620325, 20.01.2023. Baza dannykh strukturnykh, akusticheskikh i magnitnykh kharakteristik v metalle oborudovaniya toplivnoenergeticheskogo kompleksa. Zayavka № 2022623693 ot 14.12.2022.

31. Smirnov A.N., Ababkov N.V., Nikitenko M.S. [et al.] Programmnyy modul' otsenki sostoyaniya gornodobyvayushchego oborudovaniya na osnove zakonomernostey izmeneniya strukturno-fazovogo sostoyaniya i poley vnutrennikh napryazheniy metalla. *Vestnik Kuzbasskogo gosudarstvennogo tekhnicheskogo universiteta*. 2022; 6(154):50–58.

© 2024 The Authors. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

The authors declare no conflict of interest.

About the authors:

Nikolay V. Ababkov, Head of the Department of Mechanical Engineering Technology, T.F. Gorbachev Kuzbass State Technical University, Kemerovo, st. Vesennaya, 28 Ph.D., Associate Professor, e-mail: ababkovnv@kuzstu.ru, ORCID: <http://orcid.org/0000-0003-0794-8040>

Alexander S. Teleguz, researcher at the Laboratory of Advanced Methods for Managing Mining Engineering Systems, Institute of Coal, Federal Research Center for Mining Management of the Siberian Branch of the Russian Academy of Sciences, Kemerovo, Leningradsky Ave., 10, e-mail: alexanderteleguz@rambler.ru, ORCID: <https://orcid.org/0009-0008-4293-4959>

Maxim V. Pimonov, Associate Professor of the Department of Mechanical Engineering Technology, T.F. Gorbachev Kuzbass State Technical University, Kemerovo, st. Vesennaya, 28, Ph.D., e-mail: pimonovmv@kuzstu.ru, ORCID: <https://orcid.org/0000-0001-9509-4692>

Contribution of the authors:

Ababkov Nikolay Viktorovich – formulation of the research problem, collection and analysis of data, review of relevant literature, conclusions, text correction.

Teleguz Alexander Sergeevich – data collection and analysis, review of relevant literature, conclusions, text writing.

Pimonov Maxim Vladimirovich – scientific management, review of relevant literature, conceptualization of the study, conclusions, writing the text.

All authors have read and approved the final manuscript.

