

УДК 534.08
DOI: 10.22213/2413-1172-2025-3-42-52

Классификация сигналов виброускорения при различных усилиях затяжки болтовых соединений

Е. М. Сухарев, кандидат технических наук, доцент, Сибирский государственный университет путей сообщения, Новосибирск, Россия

В работе рассматривается применение параметров временной близости и вейвлет-преобразования в сочетании с фрактальными и спектральными характеристиками для классификации сигналов виброускорения, возникающих при различных уровнях затяжки болтовых соединений. Актуальность работы определяется необходимостью совершенствования методов контроля затяжки крепежных соединений на всех этапах жизненного цикла объектов – от проектирования и создания до эксплуатации, важностью надежной работы болтовых соединений, для которых требуется регулярная проверка состояния, и развитием современных методов обработки сигналов на основе машинного обучения, открывающего новые возможности для автоматизации процессов диагностики. Исследование направлено на выявление взаимосвязей между характеристиками вибрационных сигналов и моментом усилия затяжки, что позволяет разработать более точные алгоритмы мониторинга технического состояния соединений. Для сигналов виброускорения вычислялись характеристики близости с использованием динамической трансформации временной шкалы, частоты и амплитуды спектра Фурье, параметры спектральной плотности мощности по Уэлчу, спектральные дескрипторы для оконного преобразования Фурье, фрактальная размерность Хигuchi, детрендированные флуктуации, параметры вейвлет-преобразования. Особое внимание уделено поиску набора признаков малой размерности, включающего характеристики различной природы. Такой подход позволяет выявлять как локальные особенности сигналов (с помощью вейвлет-преобразования), так и их глобальные структурные свойства (посредством фрактального анализа). Использование вейвлет-преобразования позволяет проводить анализ временных изменений сигналов, что способствует выявлению ключевых особенностей в динамике данных. Для каждой модели вычислялись наиболее важные признаки. Результаты демонстрируют возможность формирования диагностически значимых наборов признаков для оценки напряженного состояния соединений, могут быть обобщены и адаптированы для мониторинга технического состояния различных объектов.

Ключевые слова: машинное обучение, виброускорение, фрактальная размерность, динамическая трансформация временной шкалы, вейвлет-преобразование, спектр Фурье, резьбовые соединения.

Введение

Современные промышленные системы и конструкции требуют высокой надежности и безопасности, что делает мониторинг их технического состояния критически важным. Одним из ключевых элементов многих конструкций являются болтовые соединения, которые играют важную роль в обеспечении целостности и устойчивости конструкций. Однако неправильная затяжка болтов может привести к ухудшению эксплуатационных характеристик, а в крайних случаях – к авариям. В связи с этим разработка методов диагностики состояния болтовых соединений на основе анализа вибрационных сигналов представляет собой актуальную задачу.

В данной работе рассматривается применение методов анализа сигналов, таких как динамическая трансформация временной шкалы, вейвлет-преобразование и фрактальный анализ, для классификации сигналов виброускорения, возни-

кающих при различных уровнях затяжки болтовых соединений. Параметры временной близости, основанные на динамической трансформации временной шкалы, позволяют адаптивно изменять временные характеристики сигналов, которые могут быть важными для понимания динамики процессов. Эта методология помогает в выделении значимых особенностей сигналов, что, в свою очередь, способствует более точной интерпретации данных. Вейвлет-преобразование позволяет выявить временные изменения в сигналах, что особенно важно для анализа динамических процессов, в то время как фрактальные методы помогают обнаружить сложные структуры и закономерности, которые могут быть не видны при использовании традиционных подходов. Комбинация этих методов с вычислением параметров временной близости и спектральных характеристик может обеспечить более точное и интерпретируемое описание сигналов, а также влияние на них состояния затяжки болтов.

Предложенный подход к анализу вибрационных сигналов, основанный на сочетании методов динамической трансформации временной шкалы, спектра Фурье, вейвлет-преобразования и фрактального анализа позволяет не только улучшить точность классификации, но и выявить скрытые закономерности в данных, что может быть полезно для разработки более эффективных интеллектуальных систем мониторинга, способных своевременно выявлять отклонения в состоянии соединений.

Использование алгоритмов машинного обучения открывает новые перспективы для усовершенствования анализа сигналов, позволяя более точно выявлять закономерности и аномалии в данных. Эти методы способны обрабатывать большие объемы информации и адаптироваться к изменениям в характеристиках сигналов, что делает их ценными для решения сложных задач в области мониторинга технического состояния. Вибрационные сигналы, полученные от датчика, как правило, требуют обработки для выделения информативных признаков. Внедрение машинного обучения в анализ сигналов не только повышает точность классификации, но и способствует созданию более эффективных и интеллектуальных систем, способных предсказывать потенциальные проблемы и оптимизировать процессы на основе полученных данных [1], что ведет к повышению надежности и безопасности промышленных систем. Применение методов машинного и глубокого обучения для анализа сигналов виброускорения развивается достаточно активно, но требует дальнейшего изучения [2–4]. В частности, необходимо разработать универсальные модели, которые могли бы адаптироваться к различным типам оборудования и условиям эксплуатации.

Усилия при затяжке резьбовых соединений оказывают влияние на параметры колебаний [5, 6]. В отдельных случаях обнаруживается корреляция малого количества параметров с механическими напряжениями, например, для основной собственной частоты.

Вычисление близости временных рядов с использованием динамической трансформации временной шкалы (DTW) используется для измерения схожести между двумя временными рядами путем нахождения оптимального пути деформации (или «выравнивания») этих рядов. Суть метода заключается в том, что он позволяет «растягивать» или «скжимать» временные ряды в разных точках, чтобы минимизировать общее расстояние между ними. Это особенно по-

лезно, когда временные ряды имеют различия в скорости или временных искажениях, но при этом сохраняют общую форму или паттерн.

DTW находит применение в различных областях [7, 8] для анализа сходства временных рядов, включая классификацию и кластеризацию данных, представленных временными рядами при различных условиях их получения [9–11].

Фрактальные характеристики сигнала активно используются для получения параметров и классификации сигналов [12] – они позволяют выявлять сложные нелинейные закономерности в сигналах, которые трудно обнаружить традиционными методами спектрального анализа. В [13] исследована связь между фрактальными и спектральными характеристиками, которая может стать основой для поиска комплексных характеристик сигнала.

Вейвлет-анализ получил широкое распространение в обработке сигналов благодаря своей способности исследовать нестационарные процессы одновременно во временной и частотной области [14]. В [15] указывается, что вейвлет-преобразование эффективно при проведении мультиразрешающего и мультиполосного анализа сигналов виброускорений и может быть использовано для выявления дефектов рельсового пути и определения их параметров. Изучается применимость вейвлетов различных типов для различных задач с учетом частотного временного и пространственного разрешения [16, 17], в том числе с использованием смартфона, применение многослойных искусственных нейронных сетей на наборах предварительно обработанных данных с помощью вейвлет-преобразований для обнаружения и классификации одиночных и множественных неисправностей [18–20]. По нашему мнению, предпочтительнее аналитические вейвлеты. Указывается на эффективность применения различных типов вейвлетов для задач диагностики [21, 22], в том числе для сигналов виброускорения с высоким уровнем шума и скрытых или слабозаметных неисправностей [23, 24].

Применение в качестве вектора признаков сигнала параметров фрактальной размерности вейвлет-преобразования и параметров временной близости позволило бы, как представляется, преодолеть ограничения каждого из методов в отдельности и значительно повысить точность классификации состояний механических систем. Это соответствует современному тренду в области обработки сигналов и машинного обучения, где гибридные методы становятся стандартом для сложных диагностических задач.

Цель работы – анализ возможности применения методов, основанных на комплексном использовании параметров временной близости, вейвлет-преобразования, спектральных и фрактальных характеристик для классификации сигналов виброускорения при различных усилиях затяжки болтовых соединений.

Объект и методы исследования

Объект исследования представляет собой болтовое соединение фланца с заглушкой с шестью болтами М20, которые затягивали динамометрическим ключом с различным усилием затяжки. На болт воздействовали ударом стальным шариком массой 9 г, скатывающимся по направляющей трубке с высоты 0,2...0,3 м. Виброускорение головки болта регистрировали акселерометром с тремя осями, изготовленным на базе микросхемы ADXL326. Верхняя частота пропускания составила 1,6 кГц, цена наименьшего разряда – 3 мм/с², а погрешность, связанная с влиянием собственных шумов, не превышала 20 единиц АЦП. Для каждого момента затяжки изучались 500 сигналов.

Момент усилий затяжки влияет на появление микроударов между поверхностями, изменение жесткости системы, появление резонанса, изменение частот и амплитуд отраженных волн, появление субгармоник и дробных частот в зазорах. Следовательно, частотные, фрактальные и вейвлетные параметры вибросигналов болтовых соединений могут меняться при изменении моментов затяжки.

Для сигналов виброускорения вычислялись следующие характеристики:

- фрактальная размерность Хигучи;
- детрендированные флуктуации;
- параметры разложения спектральной плотности мощности по Уэлчу;
- временная близость, вычисленная по алгоритму динамической трансформации времени;
- коэффициенты вейвлет-преобразования для различных типов вейвлетов (Морле, «мексиканская шляпа», Гаусса, Хаара Добеши);
- центральная частота материнского вейвлета;
- энергия сигнала и его вейвлет-представления;
- средние и медианные коэффициенты;
- частоты, соответствующие максимальным амплитудам вейвлет-коэффициентов для каждого момента времени;
- средняя доминирующая частота сигнала;
- стандартное отклонение частот, соответствующих максимальным коэффициентам для каждого масштаба;

- спектральные характеристики, полученные с помощью дискретного преобразования Фурье;
- спектральные дескрипторы для оконного преобразования Фурье.

Все вычисления проводились с использованием стандартных библиотек Python. Предварительный анализ корреляций между вычисляемыми характеристиками показал наличие связи между некоторыми из них, что предоставляет дополнительную информацию для оптимизации выбора информативных показателей временных рядов. В работе [25] исследовались модели, содержащие меньшее количество признаков. Предполагалось, что увеличение количества информативных признаков улучшит предсказательные свойства моделей.

Алгоритм динамического выравнивания временных рядов (DTW) позволяет сопоставить точки данных из разных временных шкал. Процесс DTW включает в себя следующие шаги:

- создание матрицы расстояний;
- инициализация границ для определения начальных условий выравнивания;
- заполнение матрицы с учетом минимального расстояния, которое можно получить, переходя из предыдущих ячеек (с учетом возможных смещений по времени);
- обратный проход для нахождения оптимального пути выравнивания, который минимизирует общее расстояние между временными рядами, в итоге алгоритм возвращает значение минимального расстояния между временными рядами.

Вейвлет-преобразование основано на разложении по системе базисных функций (вейвлетов), обладающих свойством временно-частотной локализации. Алгоритм включает следующие этапы: выбор материнского вейвлета, генерация семейства функций с использованием масштабирования и сдвига, интерпретация коэффициентов разложения, вычисление коэффициентов как меры соответствия сигнала вейвлету на заданной частоте и в заданный момент времени.

Алгоритм вычисления фрактальной размерности Хигучи основан на анализе длины траектории сигнала при различных масштабах наблюдения. Для вычисления осуществляются последовательные шаги: для каждого масштаба вычисляется усредненная длина кривой, строится зависимость логарифма длины от логарифма масштаба, фрактальная размерность определяется через наклон полученной линейной зависимости.

Из полученных признаков формируется набор данных, для которого после удаления повторов и пропусков проводился анализ методами машинного обучения, с использованием деревьев решений, метода k-means, метода ближайших соседей, градиентного бустинга и полносвязной нейронной сети.

Результаты

Вычисленные признаки, взятые по отдельности, показали достаточно слабую корреляцию с моментом усилий затяжки. Так, для расстояния, вычисленного с помощью динамической трансформации времени (DTW-distance, DTW-расстояние), коэффициент корреляции Пирсона оказался равным 0,53. Однако часть параметров коррелирует друг с другом. Особенно интересна корреляция коэффициентов разных преобразований между собой. Коэффициент корреляции фрактальной размерности Хигuchi и DTW-расстояния равен 0,81. Сильную корреляцию продемонстрировала пара DTW-расстояние и энергия сигнала, для которой он равен 0,93. График на рисунке 1 демонстрирует зависимость, близкую к линейной.

Корреляцию DTW-расстояния и относительной энергии вейвлет-преобразования можно объяснить следующим. Если два сигнала имеют близкое DTW-расстояние, их энергетические профили (распределение энергии по частотам и времени) также будут схожи. Суммарная энергия вейвлет-коэффициентов показывает меньшую корреляцию. Можно предположить, что это объясняется избыточностью вейвлет-преобразования.

Выявлена также корреляция между энергией вейвлет-преобразования и максимальной амплитудой коэффициентов (график представлен на рисунке 2), которую можно объяснить тем, что существенная часть сигнала сосредоточена в узкой частотной области. Достаточно сильная корреляция проявлялась для вейвлетов Морле и МНАТ. Для вейвлета Добеши (анализировался только вейвлет четвертого порядка) корреляция намного слабее. Это дополнительно подтверждается корреляцией энергии сигнала и стандартного отклонения частот максимальных коэффициентов вейвлет-преобразования (которое характеризует разброс частот в сигнале) с параметрами спектра Фурье и разложения плотности энергии по Уэлчу.

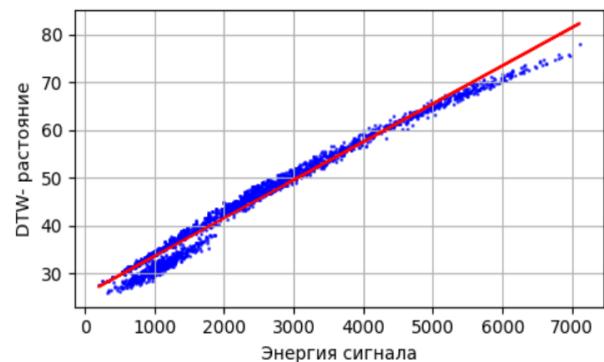


Рис. 1. Связь DTW-расстояния и энергии сигнала

Fig. 1. Relationship between DTW distance and signal energy

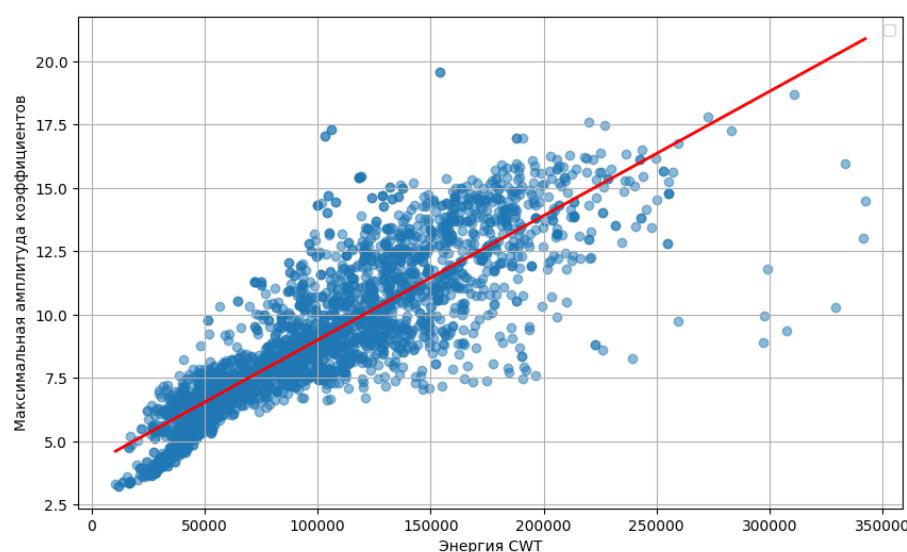


Рис. 2. Связь максимальной амплитуды коэффициентов и энергии вейвлет-преобразования для вейвлета МНАТ

Fig. 2. Relationship between the maximum wavelet coefficients' amplitude and energy for MHAT wavelet transform

Для оценки важности признаков использовался регрессионный метод дерева решений. На рисунке 3 показана корреляция между предсказанными и реальными значениями момента для тестовых данных. При использовании всего набора признаков наиболее важным оказался признак временной близости, вторым – фрактальной размерности, третьим – медианной частоты вейвлет-преобразования, на которой вейвлет-преобразование достигает максимальной амплитуды по времени, другими словами, – частоты, вокруг которой сосредоточена основная энергия, полученная с помощью вейвлет-преобразования.

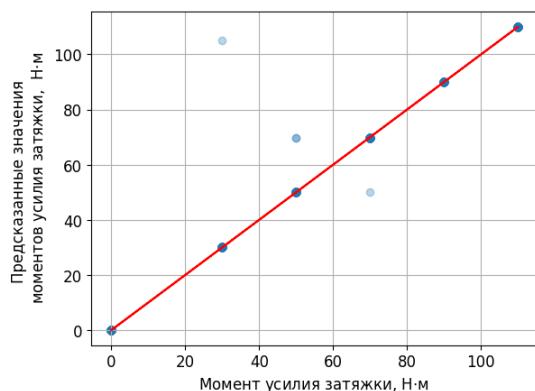


Рис. 3. Связь тестовых и предсказанных значений момента для модели дерева решений

Fig. 3. Relationship between test and predicted torque values for decision tree model

Предсказания момента усилий затяжки по этой модели показали точность в пределах 0,98 для тренировочных и тестовых данных. Точность рассчитывалась как среднеквадратичная ошибка – квадратный корень из среднего квадрата разностей между фактическими и предсказанными значениями.

Если использовать только амплитуды и частоты фурье-спектра, точность модели становится ниже. При этом наиболее важными являются первая и вторая частоты разложения, вклад остальных пренебрежимо мал. Добавление к этим признакам фрактальной размерности приводит к существенному увеличению метрик качества модели, при этом фрактальная размерность становится наиболее важным признаком. Если использовать только параметры вейвлет-преобразования, метрики качества улучшаются по сравнению с моделью для преобразования Фурье.

Если использовать только параметры оконного преобразования Фурье, то точность модели несколько снижается, при этом наиболее важные признаки – стандартное отклонение цен-

троида, средняя частотная энтропия, стандартное отклонение энергии окна.

Для модели регрессии методом k ближайших соседей точность, вычисленная как среднеквадратичное отклонение предсказанных значений от точных при числе соседей, равном 3, составила порядка 1 Н·м на тестовых и на тренировочных данных. На рисунке 4 представлена зависимость предсказанных значений от реальных для тестового набора данных, если в качестве признаков выбирались: DTW-distance, фрактальная размерность, энергия сигнала и ее отношение к энергии вейвлет-преобразования, а также первые частоты и амплитуды спектра Фурье и разложения по Уэлчу. В данном случае выбирались следующие параметры модели: число соседей – 3, метрика расстояний – манхэттенская.

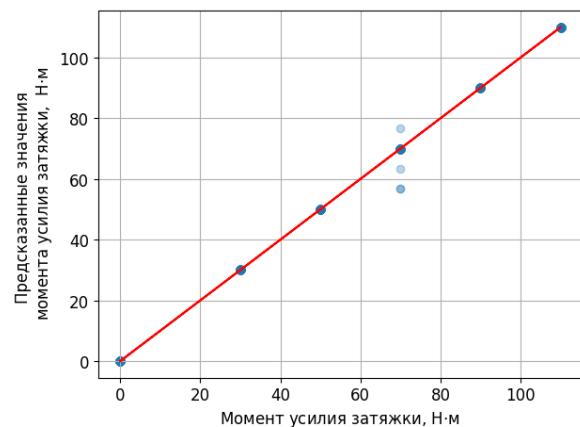


Рис. 4. Связь тестовых и предсказанных значений момента для модели ближайших соседей

Fig. 4. Relationship between test and predicted torque values for the nearest neighbor model

При использовании только двух параметров – энергии сигнала и энергии вейвлет-преобразования – точность существенно снижается. Так, для метода ближайших соседей среднеквадратичное отклонение существенно возрастает – до 12 Н·м на тренировочных данных и до 14 Н·м на тестовых.

Для оценки эффективности и обобщающей способности классификации была применена кросс-валидация для классификатора по методу ближайших соседей. Получено, что модель не переобучена и устойчива к случайным вариациям данных, усредненная точность составила 95...99 % в зависимости от количества используемых признаков, при этом уменьшение числа ближайших соседей в модели слабо влияет на точность. Это свидетельствует о хорошей обобщающей способности модели.

Также осуществлялась кластеризация с использованием метода k -средних. Качество кластеризации оценивалось вычислением индекса силуэта (silhouette score) и индекса Дэвиса – Болдина (Davies-Bouldin index). Оба индекса показали, что данные метод обладает слабой возможностью кластеризации.

Если выбрать меньшее число кластеров, кластеризация становится более точной. Если разбить все данные на три диапазона по принципу, что первая группа соответствует нулевому значению момента усилия затяжки, вторая – значениям момента 50, 70 или 90 Н·м, третья – значениям 30 или 110 Н·м, и вместо значения момента усилия затяжки использовать признак принадлежности к диапазону, точность кластеризации резко возрастает. Вероятность попадания данных в предсказанный кластер близка к 95 %, если в качестве признаков использовать всего два из всей совокупности – фрактальную размерность и DTW-расстояние. Если добавить параметры вейвлет-преобразования, точность возрастает до 98 %. Более того, при использовании только двух параметров – энергии сигнала и энергии вейвлет-преобразования – точность остается достаточно высокой. Для оценки качества классификации использовались обычные для машинного обучения метрики: точность (Precision) – доля правильно предсказанных положительных примеров к общему числу предсказанных положительных примеров; полнота (Recall) – доля правильно предсказанных положительных примеров к общему числу фактических положительных примеров; F1-score – гармоническое среднее между точностью и полнотой. Все три метрики при использовании вычислялись для классификации методом случайного леса и оказались в пределах 0,98...0,99. Мера точности (Accuracy), вычисляемая как общая доля правильно классифицированных экземпляров (как положительных, так и отрицательных) к общему количеству экземпляров, также была достаточно высокой. Такие значения метрик указывают на высокое качество классификации в данном случае. Точность также оценивалась как среднеквадратичное отклонение предсказаний принадлежности к одному из диапазонов моментов усилий затяжки от истинных значений. Значение этой величины находилось в пределах 0,08...0,09, тогда как значения принадлежности были равны 0, 1 и 2 для трех разных диапазонов, что также говорит о высоком качестве классификации.

Была применена модель XGB Regressor (метод градиентного бустинга над ансамблем де-

ревьев). Она строит ансамбль деревьев последовательно, на каждом шаге пытаясь исправить ошибки предыдущих деревьев с помощью градиентного спуска по функции потерь (например, среднеквадратичной ошибки для регрессии). Это позволяет модели постепенно улучшать точность предсказаний и избегать переобучения при правильной настройке параметров. Точность модели, как на тренировочных, так и на тестовых данных, близка к 0,99 при использовании следующих параметров сигнала: фрактальная размерность, амплитуда первого члена спектра мощности по Уэлчу, DTW-расстояние, энергия сигнала, стандартное отклонение частот вейвлет-преобразования, индекс для коэффициента с максимальной энергией вейвлет-преобразования, стандартное отклонение для частот вейвлет-преобразования.

На рисунке 5 показана зависимость предсказанных значений момента усилия затяжки от измеренных параметров в случае модели XGB Regressor при использовании вейвлета Морле. Если оставить только три параметра – амплитуду первого члена разложения спектральной плотности, стандартное отклонение частот вейвлет-преобразования и фрактальную размерность Хигuchi, точность модели остается достаточно высокой и слабо меняется при выборе типа вейвлета.

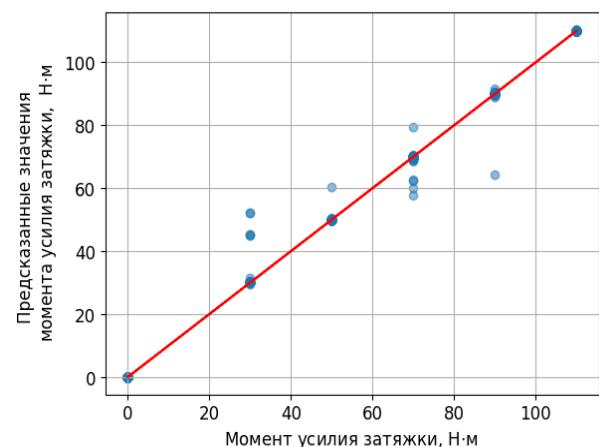


Рис. 5. Зависимость предсказанных значений момента усилия затяжки от измеренных для модели XGB Regressor

Fig. 5. Dependence of the predicted values of the tightening torque on the measured values for the XGB Regressor model

Добавление фрактальной размерности улучшает качество всех рассмотренных моделей. Однако если из списка параметров модели удалить часть вейвлет-характеристик, например,

энергию вейвлет-прообразования (суммарную энергию коэффициентов), оставив фрактальную размерность, качество моделей снижается. Если использовать вейвлет «мексиканская шляпа» (МНАТ), то предсказательные свойства модели несколько ухудшаются. Возможная причина – МНАТ – симметричный гладкий вейвлет с фиксированной формой, который эффективен для анализа резких изменений, но может быть менее устойчив к высокочастотному шуму по сравнению с другими вейвлетами. Он хорошо подходит для задач, требующих высокого пространственного разрешения при низких требованиях к спектральному разрешению. Для вейвлета Гаусса первого порядка точность модели примерно такая же, как для вейвлета Морле, при этом добавление фрактальной размерности практически не меняет метрики качества. Вейвлет МНАТ является вейвлетом Гаусса второго порядка (вычисляется взятием производной), поэтому он

имеет более узкое временное окно, но менее устойчив к высокочастотному шуму по сравнению с вейвлетом Гаусса первого порядка. Модель, основанная на вейвлете Хаара, показала еще меньшую точность. Этот вейвлет грубее аппроксимирует сигнал, если необходимо высокое разрешение по частоте. Однако, как показало сравнение исходного сигнала и восстановленного для разных типов вейвлетов, большую точность дает вейвлет Хаара (ошибка восстановления менее 10^{-16}), что показано на рисунке 6 для одного из сигналов (при аппроксимации сигнала по вейвлету МНАТ использована нормализация). Заметим также, что восстановление сигнала требует тщательной настройки параметров и должно быть предметом отдельного исследования. Для непрерывных вейвлетов сложность восстановления возрастает из-за их неортогональности и перекрытия базисных функций (см. рис. 6).

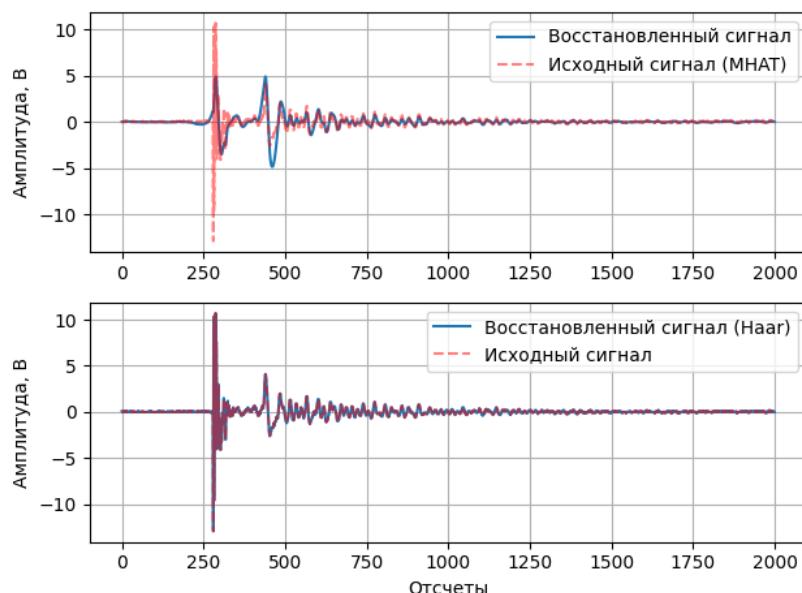


Рис. 6. Сравнение исходного и восстановленного сигналов для разных типов вейвлетов

Fig. 6. Comparison of original and reconstructed signals for different wavelet types

Добавление в вектор, использующий параметры вейвлет-преобразования признаков, характеристики оконного преобразования Фурье (использовалось окно Ханна) не влияет на точность. Возможно, это связано с корреляцией части спектральных дескрипторов оконного преобразования Фурье с характеристиками вейвлет-преобразования.

На рисунке 7 показана корреляция стандартного отклонения энергии окна (band_energy_std) и максимального амплитудного коэффициента для вейвлет-преобразования при использовании

вейвлета «мексиканская шляпа» при значениях момента усилия затяжки, отличных от нуля. Для других вейвлетов обнаружены похожие корреляции. Наблюдавшееся различное поведение подобных зависимостей при затянутом и не затянутом соединении может служить основой для бинарной классификации состояния.

Анализировалось применение модели на основе полносвязной нейронной сети (Fully Connected Neural Network – FNN). Структура модели: размерность входного слоя равна количеству признаков; каждый признак передается

на вход сети как отдельное значение; первый скрытый слой содержит 128 нейронов. Он использует функцию активации ReLU (пропускает только положительные значения и обнуляет отрицательные). Это помогает избежать проблемы затухающих градиентов. После первого скрытого слоя применяется Dropout с коэффициентом 0,3. После второго скрытого слоя снова применяется Dropout с коэффициентом 0,3. Третий скрытый слой содержит 32 нейрона. Выходной слой содержит 1 нейрон. Для функции потерь использовалось MSE (Mean Squared Error). MSE минимизирует среднеквадратичное отклонение между предсказанными и истинными значениями. Оптимизатор – Adam – адаптирует скорость обучения для каждого параметра модели, что делает обучение более эффективным. При обучении модели на каждой эпохе данные разбиваются на батчи размером 32. Часть данных (20 %) используется для валидации, чтобы отслеживать, как модель работает на данных, которые она не видела во время обучения. Для уменьшения переобучения, признаки которого наблюдались при апробации модели, был добавлен дополнительный слой Dropout с коэффициентом 0,2, что значительно улучшило качество модели. При использовании 53 характеристик временного ряда (спектральных, фрактальных, параметров вейвлет-преобразования Морле, спектральных дескрипторов оконного преобразования Фурье) модель дает среднеквадратичную ошибку около 1 Н · м для различных режимов работы модели.

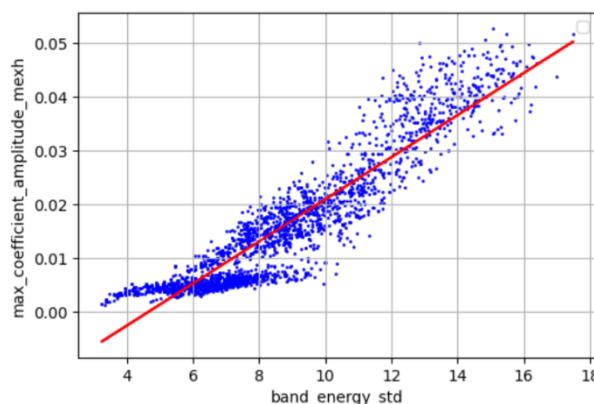


Рис. 7. Связь максимального амплитудного коэффициента для вейвлет-преобразования и стандартного отклонения энергии окна при использовании вейвлета МНАТ при значениях момента усилия затяжки, отличных от нуля

Fig. 7. Relationship between the maximum wavelet coefficient amplitude and energy window standard deviation for MHAT wavelet transform under non-zero bolt-tightening torque conditions

На рисунке 8 показана зависимость предсказанных значений момента усилия затяжки от измеренных для модели полно связной нейросети.

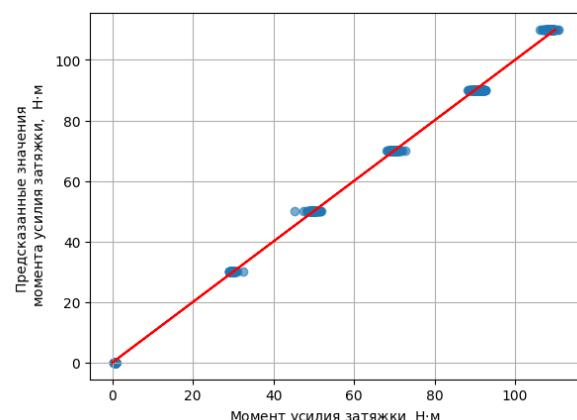


Рис. 8. Зависимость предсказанных значений момента усилия затяжки от измеренных для модели полно связной нейросети

Fig. 8. Dependence of the predicted values of the tightening torque on the measured values for the fully-connected neural network model

При использовании только характеристик вейвлет-преобразования среднеквадратичная ошибка возрастает до 3 Н · м.

Выводы

- Для рассмотренных моделей удалось сформировать малоразмерные векторы признаков сигнала виброускорения на основе временной близости, вейвлет-преобразования, спектральных и фрактальных характеристик, которые могут служить для оценки величины момента усилия затяжки. Часть характеристик взаимозаменяемы без потери точности модели. Наиболее важные признаки: временная близость, фрактальная размерность, медианная частота вейвлет-преобразования. При этом ни одна из характеристик сигнала в отдельности не проявляет корреляции с моментами усилий затяжки.

- Для большинства комбинаций признаков важность временной близости была максимальной. Наиболее важные признаки, полученные для вейвлет-преобразования: энергия преобразования для оконного преобразования Фурье, стандартное отклонение энергий, стандартное отклонение частот по окнам сигнала, средняя энтропия сигнала по окнам. Добавление к вектору признаков фрактальной размерности или детрендированных флуктуаций существенно увеличивает метрики точности. Коэффициент корреляции между предсказанными и реальными значениями моментов усилий затяжки в этом случае близок к единице.

3. В случае малого числа кластеров возможно достижение высокой точности кластеризации.

Библиографические ссылки

1. Mendonça M.O.K., Apolinário I.F., Diniz P.S.R. (2024) Introduction to signal processing and machine learning theory. *Signal Processing and Machine Learning Theory*, pp. 1-34. DOI: 10.1016/b978-0-32-391772-8.00007-7
2. Xiaofeng Dong, Zhuo Miao, Yuchao Li, Huan Zhou, Wenqian Li (2024) One data-driven vibration acceleration prediction method for offshore wind turbine structures based on extreme gradient boosting. *Ocean Engineering*, vol. 307, p. 118176. DOI: 10.1016/j.oceaneng.2024.118176
3. Namkyoung Lee, Joohyun Woo, Sungryul Kim (2024) A deep reinforcement learning ensemble for maintenance scheduling in offshore wind farms. *Applied Energy*, vo. 377, part A, p. 124431. DOI: 10.1016/j.apenergy.2024.124431
4. Barbara Zaparoli Cunha, Christophe Droz, Abdel-Malek Zine, Stéphane Foulard, Mohamed Ichchou (2023) A review of machine learning methods applied to structural dynamics and vibroacoustic. *Mechanical Systems and Signal Processing*, vol. 200, p. 110535. DOI: 10.1016/j.ymssp.2023.110535
5. Куц М. С. Экспериментальное исследование влияния усилия затяжки болтов на резонансные частоты консольно закрепленной балки // Известия высших учебных заведений. Машиностроение. 2018. № 9 (702). С. 37–43. DOI: 10.18698/0536-1044-2018-9-37-43
6. Brøns M., Thomsen J.J., Sah S.M., Tcherniak D., Fidlin A. (2021) Estimating bolt tension from vibrations: Transient features, nonlinearity, and signal processing. *Mechanical Systems and Signal Processing*, 150, Article 107224. DOI: 10.1016/j.ymssp.2020.107224
7. Goncharov A.V., Strijov V.V. (2018) Analysis of Dissimilarity Set Between Time Series. *Computational Mathematics and Modeling*, 29, pp. 359-366. DOI: 10.1007/s10598-018-9415-4
8. Kate R.J. (2016) Using dynamic time warping distances as features for improved time series classification. *Data Mining and Knowledge Discovery*, 30, pp. 283-312. DOI: 10.1007/s10618-015-0418-x
9. Shifaz A., Pelletier C., Petitjean F., Geofrey I. (2023) Elastic similarity and distance measures for multivariate time series. *Knowledge and Information Systems*, no. 65, pp. 2665-2698. DOI: 10.1007/s10115-023-01835-4
10. Yutao Liu, Yong-An Zhang, Ming Zeng, Jie Zhao (2024) A novel distance measure based on dynamic time warping to improve time series classification. *Information Sciences*, vol. 656, p. 119921. DOI: 10.1016/j.ins.2023.119921
11. Gowrisankar A., Banerjee S. (2023) Framework of fractals in data analysis: theory and interpretation. *European Physical Journal Special Topics*, no. 232, pp. 965-967. DOI: 10.1140/epjs/s11734-023-00890-w
12. Agathiyan A., Fataf N.A.A., Gowrisanka A. (2023) Explicit relation between Fourier transform and fractal dimension of fractal interpolation functions. *European Physical Journal Special Topics*, vol. 232, pp. 1077-1091. DOI: 10.1140/epjs/s11734-023-00779-8
13. Mallat S. (1999) *A Wavelet Tour of Signal Processing*, Cambridge University Press, New York, 1999. DOI: 10.1016/B978-0-12-374370-1.X0001-8
14. Методы обработки сигналов акселерометров на железнодорожном транспорте с использованием вейвлет-преобразования / А. М. Боронахин, А. В. Большаякова, Д. М. Клионский, Д. Ю. Ларионов, Р. В. Шалымов // Известия высших учебных заведений России. Радиоэлектроника. 2024. Т. 27, № 1. С. 6–16. DOI: <https://doi.org/10.32603/1993-8985-2024-27-1-6-16>
15. Chatterjee P. (2015). *Wavelet Analysis in Civil Engineering* (1st ed.). CRC Press. DOI: 10.1201/b18057
16. Chen J., Lin C., Peng D. and Ge H. (2020) Fault Diagnosis of Rotating Machinery: A Review and Bibliometric Analysis. *IEEE Access*, vol. 8, pp. 224985-225003. DOI: 10.1109/ACCESS.2020.3043743
17. Гусев Г., Епин В., Цветков Р., Шестаков А. К вопросу о развитии методов измерения вибрации строительных конструкций // Вестник Пермского федерального исследовательского центра. 2023. № 4. С. 32–40. DOI: 10.7242/2658-705X/2023.4.3
18. Guo T., Zhang T., Lim E., López-Benítez M., Ma F., Yu L. (2022) A Review of Wavelet Analysis and Its Applications: Challenges and Opportunitie. *IEEE Access*, vol. 10, pp. 58869-58903. DOI: 10.1109/ACCESS.2022.3179517
19. Gang Wang, Carlos Lopez-Molina, Guillermo Vidal-Diez de Ulzurrun, Bernard De Baets (2019) Noise-robust line detection using normalized and adaptive second-order anisotropic Gaussian kernels. *Signal Processing*, vol. 160, pp. 252–262. DOI: <https://doi.org/10.1016/j.sigpro.2019.02.027>
20. Ahmed Silik, Mohammad Noori, Wael A. Altabay, Ramin Ghiasi, Zhishen Wu. (2021) Comparative Analysis of Wavelet Transform for Time-Frequency Analysis and Transient Localization in Structural Health Monitoring, Structural Durabilityand Health Monitoring, vol. 15, iss. 1, pp. 1–22. DOI: 10.32604/sdhm.2021.012751
21. Amezquita-Sánchez J.P., Adeli H. (2016) Signal Processing Techniques for Vibration-Based Health Monitoring of Smart Structures. *Archives of Computational Methods in Engineering*, vol. 23, pp. 1–15. DOI: 10.1007/s11831-014-9135-7
22. Qarib H. and Adeli H. (2016) A comparative study of signal processing methods for structural health monitoring. *Journal of Vibroengineering*, vol. 18, no. 4, pp. 2186–2204. DOI: 10.21595/jve.2016.17218
23. Беляев А. А., Кононов Д. П., Кротов С. В. Проблемы диагностики современных тепловозных двигателей // Бюллетень результатов научных исследований. 2024. Вып. 1. С. 7–20. DOI: 10.20295/2223-9987-2024-01-7-20
24. Jing Lin, Liangsheng Qu (2000), Feature extraction based on morlet wavelet and its application for mechanical fault diagnosis. *Journal of Sound and Vibration*,

vol. 234, iss. 1, pp. 135–148. DOI: 10.1006/jsvi.2000.2864

25. Сухарев Е. М. Применение методов машинного обучения для анализа зависимости сигналов вибруоскорения от усилий затяжки болтовых соединений // Вестник ИжГТУ имени М. Т. Калашникова. 2024. Т. 27, № 3. С. 79–85. DOI: 10.22213/2413-1172-2024-3-79-85

References

1. Mendonça M.O.K., Apolinário I.F., Diniz P.S.R. (2024) Introduction to signal processing and machine learning theory. *Signal Processing and Machine Learning Theory*, pp. 1-34. DOI: 10.1016/b978-0-32-391772-8.00007-7
2. Xiaofeng Dong, Zhuo Miao, Yuchao Li, Huan Zhou, Wenqian Li (2024) One data-driven vibration acceleration prediction method for offshore wind turbine structures based on extreme gradient boosting. *Ocean Engineering*, vol. 307, pp. 118176. DOI: 10.1016/j.oceaneng.2024.118176
3. Namkyoung Lee, Joohyun Woo, Sungryul Kim (2024) A deep reinforcement learning ensemble for maintenance scheduling in offshore wind farms. *Applied Energy*, vo. 377, part A, p. 124431. DOI: 10.1016/j.apenergy.2024.124431
4. Barbara Zaparoli Cunha, Christophe Droz, Abdel-Malek Zine, Stéphane Foulard, Mohamed Ichchou (2023) A review of machine learning methods applied to structural dynamics and vibroacoustic. *Mechanical Systems and Signal Processing*, vol. 200, p. 110535. DOI: 10.1016/j.ymssp.2023.110535
5. Kuts M.S. (2018) [Experimental study of the influence of bolt tightening force on the resonant frequencies of a cantilevered beam]. *Izvestija Vysshih Uchebnykh Zavedenij. Mashinostroenie*, no. 9 (702). DOI: 10.18698/0536-1044-2018-9-37-43 (in Russ.).
6. Brøns M., Thomsen J.J., Sah S.M., Tcherniak D., Fidlin A. (2021) Estimating bolt tension from vibrations: Transient features, nonlinearity, and signal processing. *Mechanical Systems and Signal Processing*, 150, Article 107224. DOI: 10.1016/j.ymssp.2020.107224
7. Goncharov A.V., Strijov V.V. (2018) Analysis of Dissimilarity Set Between Time Series. *Computational Mathematics and Modeling*, 29, pp. 359-366. DOI: 10.1007/s10598-018-9415-4
8. Kate R.J. (2016) Using dynamic time warping distances as features for improved time series classification. *Data Mining and Knowledge Discovery*, no. 30, pp. 283-312. DOI: 10.1007/s10618-015-0418-x
9. Shifaz A., Pelletier C., Petitjean F., Geofrey I. (2023) Elastic similarity and distance measures for multivariate time series. *Knowledge and Information Systems*, no. 65, pp. 2665-2698. DOI: 10.1007/s10115-023-01835-4
10. Yutao Liu, Yong-An Zhang, Ming Zeng, Jie Zhao (2024) A novel distance measure based on dynamic time warping to improve time series classification. *Information Sciences*, vol. 656, p. 119921. DOI: 10.1016/j.ins.2023.119921
11. Gowrisankar A., Banerjee S. (2023) Framework of fractals in data analysis: theory and interpretation. *European Physical Journal Special Topics*, no. 232, pp. 965-967. DOI: 10.1140/epjs/s11734-023-00890-w
12. Agathiyan A., Fataf N.A.A., Gowrisankar A. (2023) Explicit relation between Fourier transform and fractal dimension of fractal interpolation functions. *European Physical Journal Special Topics*, vol. 232, pp. 1077-1091. DOI: 10.1140/epjs/s11734-023-00779-8
13. Mallat S. (1999) *A Wavelet Tour of Signal Processing*, Cambridge University Press, New York, 1999. DOI: 10.1016/B978-0-12-374370-1.X0001-8
14. Boronakhin A.M., Bolshakova A.V., Klionskiy D.M., Larionov D.Yu., Shalymov R.V. (2024) [Techniques for Accelerometer Reading Processing on Railway Transport Using Wavelet Transform]. *Izvestiya Vysishikh Uchebnykh Zavedenii Rossii. Radioelektronika*, vol. 27, no. 1, pp. 6-16. DOI: 10.32603/1993-8985-2024-27-1-6-16 (in Russ.).
15. Chatterjee P. (2015). *Wavelet Analysis in Civil Engineering* (1st ed.). CRC Press. DOI: 10.1201/b18057
16. Chen J., Lin C., Peng D. and Ge H. (2020) Fault Diagnosis of Rotating Machinery: A Review and Bibliometric Analysis. *IEEE Access*, vol. 8, pp. 224985-225003. DOI: 10.1109/ACCESS.2020.3043743
17. Gusev G., Epin B., Tsvetkov P., Shestakov A. (2024) [Toward the development of methods measurement of vibration of building structures]. *Vestnik Permskogo Federal'nogo Issledovatel'skogo Tsentra*, no. 4, pp. 32-40. DOI: 10.7242/2658-705X/2023.4.3 (in Russ.).
18. Guo T., Zhang T., Lim E., López-Benítez M., Ma F., Yu L. (2022) A Review of Wavelet Analysis and Its Applications: Challenges and Opportunitie. *IEEE Access*, vol. 10, pp. 58869-58903. DOI: 10.1109/ACCESS.2022.3179517
19. Gang Wang, Carlos Lopez-Molina, Guillermo Vidal-Diez de Ulzurrun, Bernard De Baets (2019) Noise-robust line detection using normalized and adaptive second-order anisotropic Gaussian kernels. *Signal Processing*, vol. 160, pp. 252-262. DOI: <https://doi.org/10.1016/j.sigpro.2019.02.027>
20. Ahmed Silik, Mohammad Noori, Wael A. Altaibey, Ramin Ghiasi, Zhishen Wu (2021) Comparative Analysis of Wavelet Transform for Time-Frequency Analysis and Transient Localization in Structural Health Monitoring. *Structural Durabilityand Health Monitoring*, vol. 15, iss. 1, pp. 1-22. DOI: 10.32604/sdhm.2021.012751
21. Amezquita-Sánchez J.P., Adeli H. (2016) Signal Processing Techniques for Vibration-Based Health Monitoring of Smart Structures. *Archives of Computational Methods in Engineering*, vol. 23, pp. 1-15. DOI: 10.1007/s11831-014-9135-7
22. Qarib H. and Adeli H. (2016) A comparative study of signal processing methods for structural health monitoring. *Journal of Vibroengineering*, vol. 18, no. 4, pp. 2186-2204. DOI: 10.21595/jve.2016.17218
23. Belyaev A.A., Kononov D.P., Krotov S.V. (2024) [Problems of diagnostics of modern diesel engines]. *Bul-*

letin of scientific research results, no. 1, pp. 7-20. DOI: 10.20295/2223-9987-2024-01-7-20 (in Russ.).

24. Jing Lin, Liangsheng Qu (2000), Feature extraction based on morlet wavelet and its application for mechanical fault diagnosis. *Journal of Sound and Vibration*, vol. 234, iss. 1, pp. 135-148. DOI: 10.1006/jsvi.2000.2864

25. Sukharev E.M. (2024) [Application of Machine Learning Methods to Analyze the Dependence of Vibration Acceleration Signals on the Tightening Forces of Bolted Connections]. *Vestnik IzhGTU imeni M.T. Kalashnikova*, vol. 27, no. 3, pp. 79-85. DOI: 10.22213/2413-1172-2024-3-79-85 (in Russ.).

Classification of Vibration Acceleration Signals at Different Tightening Forces of Bolted Connections

E.M. Sukharev, PhD in Engineering, Associate Professor, Siberian State Transport University, Novosibirsk, Russia

The paper considers the application of time proximity parameters and wavelet transform in combination with fractal and spectral characteristics for classification of vibration acceleration signals occurring at different tightening levels of bolted joints. The study is aimed at identifying the relationships between the characteristics of vibration signals and the tightening state, which allows improving the diagnostics and monitoring of the technical condition of joints. For vibration acceleration signals, proximity characteristics were calculated using dynamic transformation of the time scale, frequency and amplitude of the Fourier spectrum, Welch power spectral density parameters, spectral descriptors for the windowed Fourier transform, Higuchi fractal dimension, detrended fluctuations, and wavelet transform parameters. The use of the wavelet transform allows analyzing the time changes of signals, which helps to identify key features in the data dynamics. At the same time, fractal methods help to detect complex structures and patterns, which can significantly improve the classification accuracy. This work is aimed at developing effective approaches to the analysis of vibration signals using machine learning methods, which is important for improving the reliability and safety of bolted joints in various industries.

Keywords: machine learning, vibration acceleration, fractal dimension, dynamic time warping, wavelet transform, Fourier spectrum, threaded connections.

Получено 22.07.2025

Образец цитирования

Сухарев Е. М. Классификация сигналов вибровибрации при различных усилиях затяжки болтовых соединений // Вестник ИжГТУ имени М. Т. Калашникова. 2025. Т. 28, № 3. С. 42–52. DOI: 10.22213/2413-1172-2025-3-42-52

For Citation

Sukharev E.M. (2025) [Classification of Vibration Acceleration Signals at Different Tightening Forces of Bolted Connections]. *Vestnik IzhGTU imeni M.T. Kalashnikova*, vol. 28, no. 3, pp. 42-52. DOI: 10.22213/2413-1172-2025-3-42-52 (in Russ.).