

КОНТРОЛЬ ДОСТОВЕРНОСТИ ПОКАЗАНИЙ СРЕДСТВ ИЗМЕРЕНИЙ ТЕХНИЧЕСКОГО МОНИТОРИНГА С ИСПОЛЬЗОВАНИЕМ КАСКАДА АВТОЭНКODЕРОВ

© 2025 Д.В. Галышев, А.Д. Яковенко, О.Л. Ибряева, А.Л. Шестаков

Южно-Уральский государственный университет

(454080 Челябинск, пр. им. В.И. Ленина, д. 76)

E-mail: galyshevdu@susu.ru, iakovenkoad@susu.ru, ibriaevaol@susu.ru, a.l.shestakov@susu.ru

Поступила в редакцию: 17.08.2025

В статье предложен метод обеспечения достоверности измерений в системах технического мониторинга — каскадная модель C-LPC-AE, сочетающая извлечение информативных спектральных признаков на основе линейного предсказательного кодирования (LPC) и двухступенчатую архитектуру сверточных автоэнкодеров. Метод предназначен для диагностики состояния подшипников и одновременной верификации корректности работы измерительных датчиков, что особенно актуально в условиях цифровой индустрии, где требуется высокая автономность и надежность систем мониторинга. Первая ступень каскада, обученная на сигналах исправного подшипника при нормальном креплении датчика, выполняет обнаружение аномалий по ошибке реконструкции. Вторая ступень, обученная на данных с ослабленным креплением акселерометра, анализирует природу аномалии и позволяет дифференцировать аномалии подшипника от искажений сигнала, вызванных нарушением монтажа датчика. Ключевым преимуществом подхода является отсутствие необходимости в данных с реальными отказами оборудования: обучение осуществляется исключительно на легко воспроизводимых состояниях — нормальном режиме и моделируемой неисправности крепления. Эксперименты проведены на данных, полученных с испытательного стенда SpectraQuest, включающего подшипники с искусственно созданным дефектом внешнего кольца. Результаты демонстрируют высокую чувствительность модели к фактическим дефектам подшипника и нарушениям монтажа сенсора. Использование LPC-признаков обеспечивает компактное представление сигнала и снижает вычислительную нагрузку, что делает предложенный подход перспективным для внедрения в промышленные системы диагностики в реальном времени.

Ключевые слова: вибродиагностика, диагностика подшипников, ослабленное крепление датчика, автоэнкодер, обнаружение аномалий, технический мониторинг, линейное предсказательное кодирование, спектральный анализ, достоверность измерений.

ОБРАЗЕЦ ЦИТИРОВАНИЯ

Галышев Д.В., Яковенко А.Д., Ибряева О.Л., Шестаков А.Л. Контроль достоверности показаний средств измерений технического мониторинга с использованием каскада автоэнкодеров // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2025. Т. 14, № 4. С. 5–24. DOI: 10.14529/cmse250401.

Введение

С развитием цифровой индустрии и переходом к автономным системам технического мониторинга все большее значение приобретает достоверность данных, поступающих от средств измерений. Надежность принимаемых решений, особенно в условиях полной или частичной автоматизации, напрямую зависит от качества входных сигналов. Даже при использовании высокоточных алгоритмов диагностики и прогнозирования, недостоверные измерения могут привести к ложным срабатываниям, неверной интерпретации состояния оборудования и, как следствие, к экономическим потерям или аварийным ситуациям [1, 2].

Одной из типичных причин искажения данных является нарушение монтажа измерительных датчиков, в частности — ослабление крепления акселерометра. Такое нарушение

может изменить механическую жесткость узла, сместить резонансные частоты датчика и существенно повлиять на спектральный состав сигнала, даже при отсутствии дефектов в самом объекте диагностики. В результате система мониторинга может интерпретировать эти артефакты как признаки неисправности оборудования, что снижает ее доверие и эффективность.

Эта проблема особенно актуальна в задачах вибродиагностики, где подшипники качения, являясь критически важными элементами механических систем в авиационной, автомобильной и станкостроительной отраслях [3], требуют непрерывного мониторинга. Надежность их работы напрямую влияет на безопасность и экономическую эффективность эксплуатации оборудования [4]. Традиционные методы диагностики основаны на анализе вибрационных сигналов с применением подходов временной и спектральной обработки [5]. Методы временного анализа, как правило, опираются на статистические характеристики сигнала [6, 7], в то время как спектральный анализ позволяет выявлять частотные компоненты, характерные для конкретных типов дефектов [8–10]. Особое внимание уделяется анализу в области резонансной частоты датчика, где амплитуда сигнала, связанного с дефектом, значительно возрастает, что повышает чувствительность диагностики [11–13]. Однако традиционные подходы зачастую требуют ручного подбора признаков и остаются чувствительными к шумам и внешним помехам, что ограничивает их эффективность на ранних стадиях обнаружения неисправностей.

Современные подходы, основанные на машинном и глубоком обучении, демонстрируют высокую точность диагностики [14, 15], но сталкиваются с рядом ограничений: высокой вычислительной сложностью [16, 17], необходимостью в больших объемах размеченных данных и чувствительностью к шумам и артефактам [18]. Методы аугментации данных, переноса обучения и генеративных моделей [19–22] частично решают проблему нехватки обучающих выборок, но по-прежнему требуют доступа к данным с реальными дефектами.

В этом контексте особый интерес представляют методы обнаружения аномалий [23–25], в частности — автоэнкодеры, обучающиеся только на нормальных режимах работы [26–28]. Однако и они подвержены ложным срабатываниям, возникающим из-за шума, ограниченного объема обучающих данных или нестандартных режимов работы [29]. Одним из факторов, провоцирующих ложные срабатывания, являются искажения, вызванные неисправностью самого измерительного оборудования. Так, например, нарушение крепления акселерометра может изменить его резонансную частоту [1, 2], что приводит к искажению спектрального состава сигнала и, как следствие, снижает повторяемость и надежность исходных данных, на которых впоследствии строится весь процесс обработки.

В данной работе предлагается каскадная модель C-LPC-AE, направленная на обеспечение достоверности измерений в системах технического мониторинга. Подход сочетает линейное предсказательное кодирование для компактного представления спектральных данных и двухступенчатую архитектуру автоэнкодеров, где первая модель выявляет отклонения от нормы, а вторая верифицирует корректность работы измерительного датчика. Обучение осуществляется без привлечения данных о реальных отказах оборудования, что делает метод практичным для промышленного применения. Для предварительной обработки применяется метод линейного предсказания (LPC), позволяющий сжать спектральную информацию до компактного набора коэффициентов.

Предложенный метод решает три ключевые задачи: обеспечение достоверности измерений, снижение вычислительной сложности за счет компактных LPC-признаков и выявление

артефактов, возникающих вследствие сбоя в измерительном оборудовании. Результаты могут быть востребованы не только в вибродиагностике, но и в более широком классе систем мониторинга, где критически важно различать реальные неисправности оборудования и искажения, вызванные нарушениями в работе измерительной аппаратуры.

Основные результаты и вклад данной работы заключаются в следующем:

1. Разработана модель обработки вибросигналов, объединяющая LPC-анализ и каскадную архитектуру нейросетей, что позволяет разделять аномалии в состоянии оборудования и в работе средств измерений.
2. Предложен двухэтапный алгоритм верификации данных, не требующий примеров реальных отказов оборудования для обучения.
3. Предложен метод, сочетающий спектральный анализ и линейное предсказательное кодирование (LPC), обеспечивающий компактное и информативное представление данных при низкой вычислительной нагрузке.
4. Экспериментально подтверждена эффективность подхода в дифференциации двух типов отклонений: дефектов подшипника и искажений сигнала, вызванных нарушением монтажа акселерометра, что критически важно в автоматических системах контроля.
5. Предложенный метод соответствует требованиям цифровой индустрии к автономности, надежности и вычислительной эффективности, что делает его перспективным для внедрения в интеллектуальные средства измерений нового поколения.

Статья организована следующим образом. В разделе 1 описывается предложенный метод C-LPC-AE, включающий этапы предобработки сигналов на основе линейного предсказательного кодирования, извлечения компактных признаков и построения каскадной архитектуры автоэнкодеров для дифференциации аномалий. В разделе 2 представлены экспериментальные данные, описывается установка SpectraQuest, процедура формирования выборок и этапы выделения LPC-признаков, включая выбор оптимального порядка модели и визуализацию признаков пространства. В разделе 3 приведены параметры архитектуры автоэнкодеров и результаты тестирования каскадной модели на различных состояниях подшипника и датчика. В заключении обобщаются полученные результаты и обсуждается применимость предложенного подхода для автоматического контроля достоверности показаний средств измерений в условиях цифровой индустрии.

1. Предлагаемый метод каскада автоэнкодеров с признаками линейного предсказательного кодирования C-LPC-AE

1.1. Линейное предсказательное кодирование

Для извлечения информативных признаков из временного сигнала в предлагаемом методе применяется линейное предсказательное кодирование (LPC, Linear Predictive Coding). Этот подход широко используется при обработке акустических и вибрационных сигналов и зарекомендовал себя, в частности, в задаче классификации дефектов подшипников, где позволил сжать исходный амплитудный спектр до 50 коэффициентов, тем самым значительно снизив вычислительную сложность модели [30].

Ключевым предположением метода LPC является предположение о том, что n -й образец временного ряда можно аппроксимировать взвешенной суммой Q предыдущих образ-

цов [31]:

$$\hat{s}[n] = - \sum_{i=1}^Q a_i * s[n-i], \quad (1)$$

где s — временной ряд, Q — порядок модели, а a_i — коэффициенты модели. Таким образом, предсказание в любой момент времени представляет собой линейную комбинацию Q предыдущих отсчетов. Остаточный сигнал определяется как:

$$e[n] = s[n] - \hat{s}[n]. \quad (2)$$

Задача сводится к нахождению коэффициентов a_i , минимизирующих энергию остаточного сигнала:

$$p = \sum_n e^2[n] = \sum_n \left(s[n] + \sum_{i=1}^Q a_i * s[n-i] \right)^2. \quad (3)$$

Для вычисления оптимальных коэффициентов частные производные функции p по a_i приравниваются к нулю:

$$\frac{\partial p}{\partial a_k} = 2 \sum_n \left(s[n] + \sum_{i=1}^Q a_i * s[n-i] \right) s[n-k], \quad (4)$$

где $k = \overline{1, Q}$.

Уравнение (4) можно переписать в виде системы Q линейных уравнений Юла—Уокера, выраженных через автокорреляционные функции:

$$\sum_n s[n]s[n-k] + \sum_{i=1}^Q a_i \sum_n s[n-i]s[n-k] = 0 \quad (5)$$

или, эквивалентно,

$$\sum_{i=1}^Q a_i R[i-k] = -R[k] \quad (6)$$

для $k = \overline{1, Q}$, где $R[m] = \sum_n s[n]s[n-m]$ — автокорреляция сигнала с лагом m .

В матричной форме система записывается как:

$$\mathbf{R}\mathbf{a} = -\mathbf{r}, \quad (7)$$

где

$$\mathbf{R} = \begin{pmatrix} R[0] & R[1] & \cdots & R[Q-1] \\ R[1] & R[0] & \cdots & R[Q-2] \\ \vdots & \vdots & \ddots & \vdots \\ R[Q-1] & R[Q-2] & \cdots & R[0] \end{pmatrix}, \quad (8)$$

$$\mathbf{a} = [a_1 \ a_2 \ \cdots \ a_Q]^T, \quad (9)$$

$$\mathbf{r} = [R[1] \ R[2] \ \cdots \ R[Q]]^T. \quad (10)$$

Матрица \mathbf{R} имеет структуру Топлица, что позволяет эффективно решать систему (7) с помощью рекурсии Левинсона—Дарбина. Этот метод последовательно строит модели от

первого до Q -го порядка, обновляя коэффициенты на каждом шаге с вычислительной сложностью $O(Q^2)$ вместо $O(Q^3)$ при прямом обращении матрицы.

1.2. Предобработка сигналов

Сигналы акселерометра по каждой из трех осей предварительно преобразуются в амплитудный спектр с использованием быстрого преобразования Фурье. Для дальнейшего анализа выбирается ограниченный диапазон частот: нижняя граница подбирается так, чтобы исключить низкочастотные составляющие, как правило, обусловленные механическими шумами и вибрациями, не связанными с состоянием подшипника; верхняя граница определяется с запасом, чтобы гарантировать покрытие резонансной частоты датчика.

Полученный спектр содержит значительное число коэффициентов, что затрудняет их прямое использование в моделях машинного обучения из-за высокой размерности и избыточности. Для снижения вычислительной сложности и извлечения информативных признаков спектральные данные далее обрабатываются методом линейного предсказательного кодирования (LPC), описанным в разделе 1.1. Этот шаг позволяет сжать спектральную информацию до фиксированного набора LPC-коэффициентов, переходя от обработки длинных спектров к более компактному и устойчивому к артефактам представлению. Полученные таким образом коэффициенты для каждой из осей датчика объединяются в единую матрицу:

$$\mathbf{S} = \begin{pmatrix} a_{1,1} & a_{1,2} & \cdots & a_{1,p} \\ a_{2,1} & a_{2,2} & \cdots & a_{2,p} \\ a_{3,1} & a_{3,2} & \cdots & a_{3,p} \end{pmatrix}, \quad (11)$$

где p — порядок модели LPC.

В зависимости от конфигурации измерительного узла для анализа может использоваться как одна, так и несколько осей акселерометра. В данной работе рассматривается трехосевой вариант как наиболее общий: использование всех трех каналов позволяет задействовать избыточность данных, повысить устойчивость к шуму и улучшить способность модели выявлять аномальные состояния. При необходимости методика может быть адаптирована и для одноосевого сенсора.

1.3. Каскад автоэнкодеров

После преобразования сигналов акселерометра и вычисления LPC-коэффициентов объединенная матрица признаков подается на вход первого автоэнкодера. Данная модель обучается исключительно на данных нормальных рабочих режимов оборудования и предназначена для первичного обнаружения аномалий. Для определения факта аномалии применяется порог, рассчитываемый по правилу пяти сигм:

$$\text{Threshold} = \mu_{train} + 5\sigma_{train}, \quad (12)$$

где μ_{train} — среднее значение ошибки восстановления на обучающей выборке, а σ_{train} — ее стандартное отклонение. Если ошибка восстановления превышает заданный порог, считается, что в сигнале зафиксирована аномалия, и данные передаются на обработку второму автоэнкодеру.

Второй автоэнкодер выполняет функцию оценки достоверности показаний средства измерения и обучается на сигналах с ослабленным креплением датчика, что позволяет отличать реальные дефекты подшипника от искажений, вызванных некорректной установ-

кой акселерометра. Таким образом, осуществляется верификация корректности измерений и исключение ложных диагностических заключений, вызванных сбоями в работе измерительной системы, что особенно важно в системах технического мониторинга в условиях цифровой индустрии, где критичны надежность и автоматический контроль достоверности поступающих данных.

Если ошибка восстановления на втором автоэнкодере превышает порог (12), ситуация интерпретируется как наличие реального дефекта подшипника. В противном случае аномалия, зафиксированная первым автоэнкодером, рассматривается как следствие неправильного крепления датчика.

Структура предлагаемой модели каскада автоэнкодеров показана на рис. 1. Ее ключевое преимущество заключается в том, что обучение обеих моделей (на нормальном состоянии и на состоянии с ослабленным креплением) возможно на данных, полученных в реальных условиях эксплуатации, без необходимости собирать труднодоступные и редко встречающиеся записи о фактических отказах.

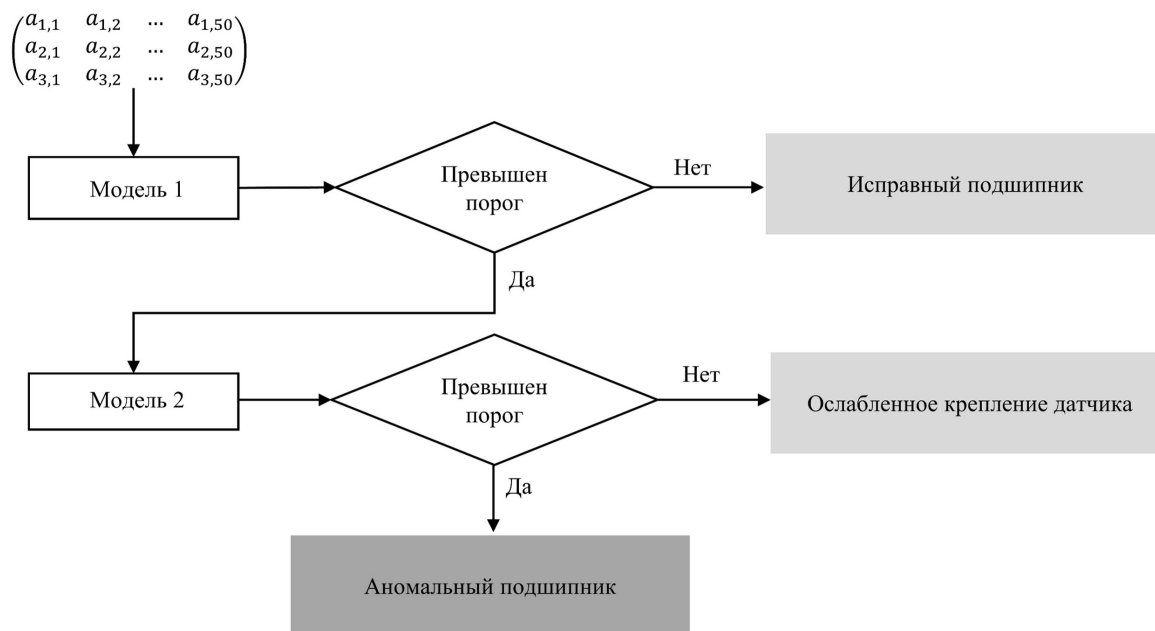


Рис. 1. Схема предлагаемой модели каскада автоэнкодеров

Следует учитывать, что ошибка восстановления каждого из автоэнкодеров может содержать случайные колебания даже при отсутствии реальных отклонений в сигнале. Это может привести к ложным срабатываниям системы. Для повышения надежности диагностики и снижения влияния таких колебаний производится сглаживание ошибки реконструкции с использованием скользящего окна.


2. Постановка эксперимента и выделение LPC признаков из данных

2.1. Экспериментальная установка

Экспериментальные данные для исследования были получены на испытательной установке SpectraQuest, оснащенной трехосевым вибропреобразователем AP2038P-100 с частотой

той установочного резонанса в осевом направлении 35 кГц. В рамках эксперимента использовались два дюймовых подшипника: один исправный, который служил эталоном, и один с искусственно введенным дефектом внешнего кольца, что позволяло моделировать аномальное состояние подшипника. Частота вращения подшипников в ходе испытаний фиксировалась на уровне 50 Гц, что соответствует номинальному режиму работы двигателя. Опора, на которой установлен диагностируемый подшипник и акселерометр, показана на рис. 2.

Фиксирующий винт



Трехосевой акселерометр

Рис. 2. Опора с закрепленным на ней акселерометром

В ходе эксперимента были записаны четыре типа сигналов, соответствующих следующим состояниям подшипников: исправный подшипник, исправный подшипник с ослабленным креплением датчика, подшипник с дефектом внешнего кольца и подшипник с дефектом внешнего кольца и ослабленным креплением датчика. Имитация плохого закрепления осуществлялась путем ослабления фиксирующего винта на четверть оборота.

Сначала проводилась серия экспериментов с исправным подшипником, при этом поочередно регистрировались сигналы как для нормального, так и для ослабленного крепления датчика. Из-за небольшой перестановки датчика после каждого ослабления отдельные серии экспериментов не являются точными повторениями, что вносит разнообразие в данные. Аналогично проводилась серия экспериментов с подшипником, имеющим дефект внешнего кольца. Частота дискретизации сигналов во всех экспериментах составляла 100 кГц. Первые четыре фрагмента каждого эксперимента записывались в течение 2.5 минут, пятый фрагмент — 2 минуты. Таким образом, суммарная длительность сигналов для каждого класса составила 12 минут.

На рис. 3 показано, что во временной области сигналы для нормального и ослабленного крепления датчика практически неразличимы, однако при переходе к амплитудному спектру различия становятся заметными. Эти изменения спектра, вызванные неисправностью измерительного средства, могут привести к ложным срабатываниям диагностической модели, что особенно важно учитывать при разработке систем технического мониторинга.

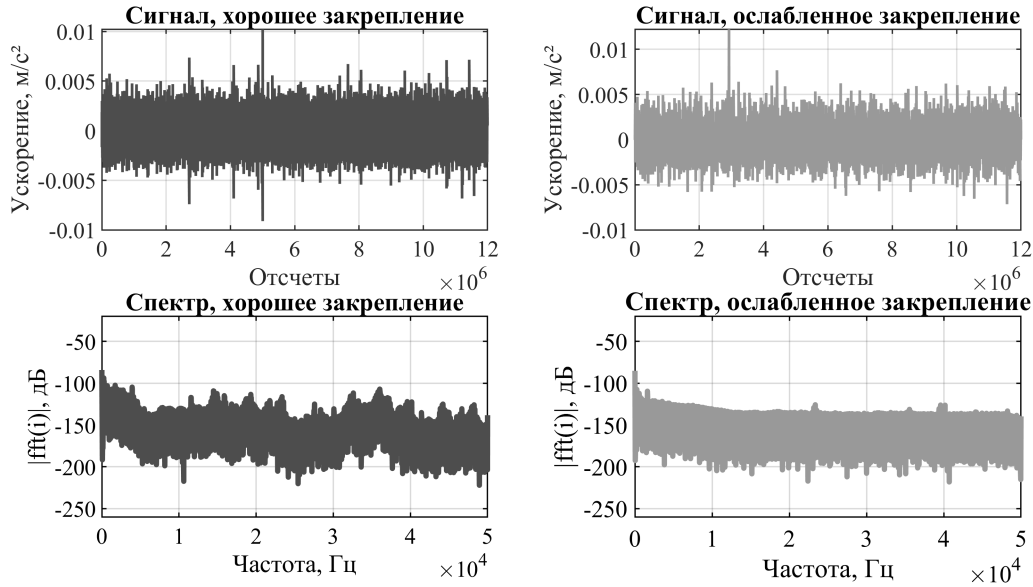


Рис. 3. Сигналы и их спектры для исправного подшипника при хорошем и ослабленном креплении датчика

2.2. Предобработка и выделение LPC-признаков из экспериментальных данных

На первом этапе обработки исходные временные сигналы были разбиты на короткие фрагменты фиксированной длины. В соответствии с результатами, представленными в работе [30], продолжительность фрагмента в 0.2 секунды оказывается достаточной для решения задач диагностики состояния подшипников. Для увеличения объема выборки применялось скользящее окно с перекрытием 0.1 секунды. Этот подход не только расширяет количество обучающих примеров, но и сохраняет временную зависимость между соседними фрагментами, что позволяет учитывать контекст изменения сигнала и снижает вероятность ложных срабатываний диагностической модели.

При частоте дискретизации 100 кГц каждый фрагмент содержал 20000 отсчетов, а шаг смещения окна составлял 10000 отсчетов. В результате сегментации для каждого из четырех классов было получено по 7195 временных рядов.

После сегментации для каждого временного ряда вычислялся спектр Фурье в диапазоне частот от 500 Гц до 40000 Гц. Такой диапазон исключает низкочастотные компоненты, напрямую связанные с частотой вращения подшипника, и включает резонансную частоту датчика, что делает его достаточным для выявления как дефектов подшипника, так и неисправностей измерительной системы.

Для выбора порядка p модели LPC использовались три стандартные функции потерь:

$$\text{FPE}(p) = \frac{N + (p + 1)}{N - (p + 1)} \hat{\sigma}^2, \quad (13)$$

$$\text{AIC}(p) = N \ln \hat{\sigma}^2 + 2p, \quad (14)$$

$$\text{MDL}(p) = N \ln \hat{\sigma}^2 + p \ln N, \quad (15)$$

где N — количество элементов временного ряда, а $\hat{\sigma}^2$ — оценка дисперсии. Результаты расчета функций потерь для полученных сигналов представлены на рис. 4.

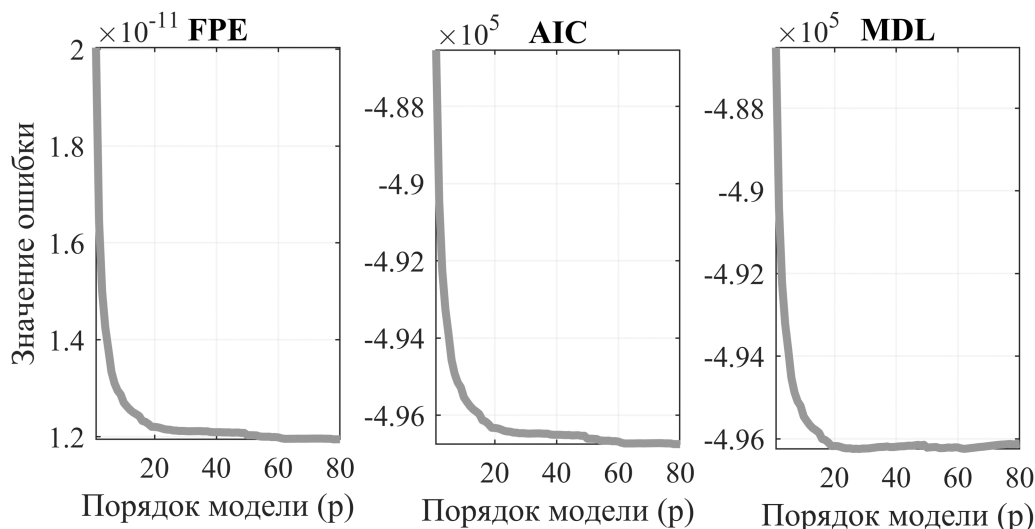


Рис. 4. Зависимость функций потерь (FPE, AIC и MDL) от порядка модели LPC

Как видно из рис. 4, все кривые функций потерь сначала быстро убывают при увеличении порядка модели, однако после определенного значения их снижение практически прекращается. Это соответствует классическому правилу «локтя»: порядок модели выбирается в точке, после которой дальнейшее увеличение числа коэффициентов не приводит к существенному улучшению качества восстановления. В рамках данной работы в качестве компромиссного решения между точностью моделирования и вычислительной эффективностью выбран порядок $p = 50$. На рис. 5 представлены средние значения LPC-коэффициентов для всех четырех рассматриваемых случаев, визуализированные в виде изображений в соответствии с матрицей (11).

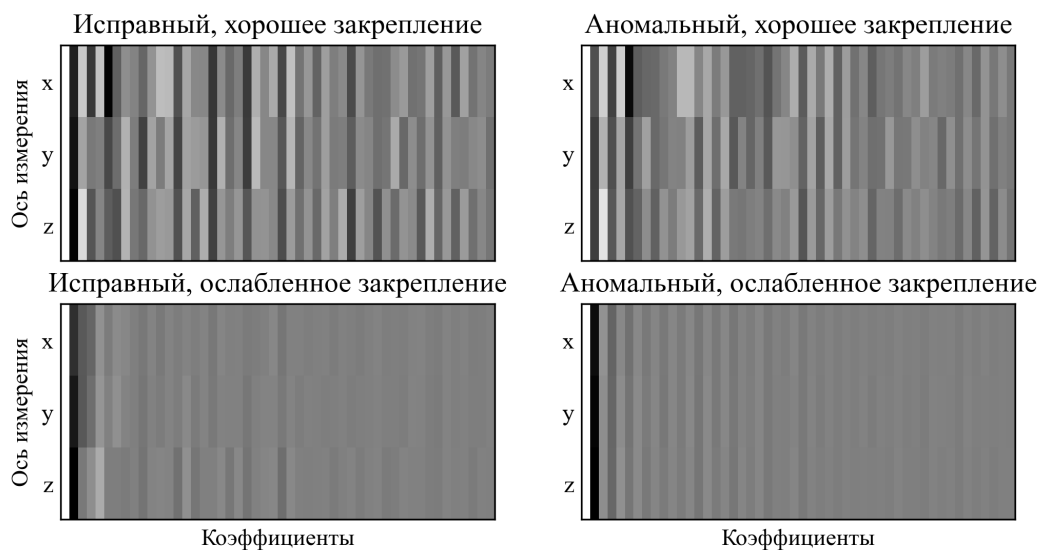


Рис. 5. Средние значения матриц коэффициентов для каждого из 4 возможных случаев, представленные в виде изображений

Для анализа разделимости классов и визуализации полученных признаков 150-мерные векторы (полученные из матриц LPC-коэффициентов размером 3×50) были спроецированы в двумерное пространство с помощью метода РаСМАР [32], рис. 6. Этот метод сочетает преимущества нелинейного уменьшения размерности, сохраняя как глобальную структуру данных, так и локальные взаимосвязи между точками, что особенно важно для задач классификации.

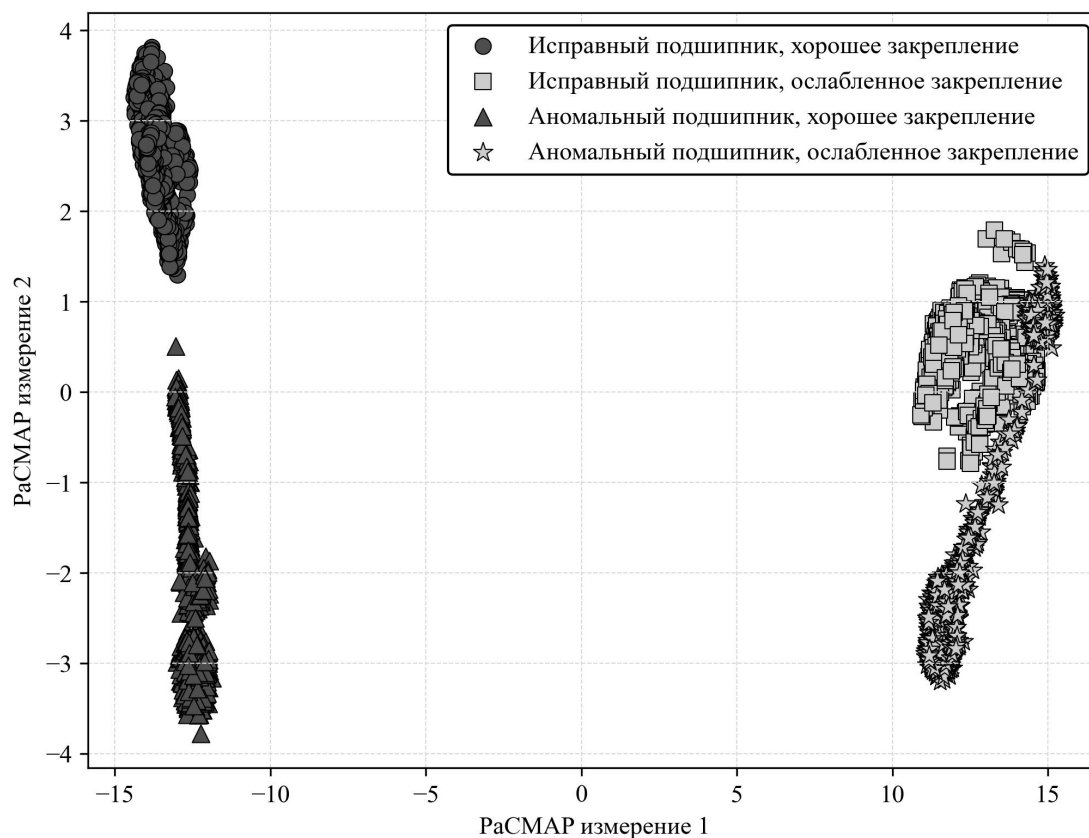


Рис. 6. Отображение полученных после предобработки данных в двухмерном пространстве с использованием метода РаСМАР

Анализ распределения признаков после снижения размерности демонстрирует четкое разделение данных для исправного и дефектного подшипника при нормальном закреплении датчика, а также выраженные различия между сигналами при нормальном и ослабленном креплении акселерометра.

При этом наблюдается частичное перекрытие кластеров, соответствующих дефектному и исправному подшипнику в случае ослабленного закрепления. Это указывает на то, что в таких условиях признаки сигналов становятся сходными, что может привести к тому, что модель будет классифицировать их как один и тот же класс данных.

3. Параметры и тестирование каскадной модели C-LPC-AE

3.1. Параметры автоэнкодеров

Предлагаемая в данной работе каскадная модель строилась с использованием двух идентичных сверточных автоэнкодеров, обучаемых на двух различных классах состояний подшипника. Первый автоэнкодер обучался на данных, полученных с исправного подшип-

ника при корректном закреплении акселерометра, тогда как второй автоэнкодер использовался для обработки сигналов, полученных при ослабленном креплении датчика.

Архитектура каждого автоэнкодера включает энкодер и декодер, объединенные симметричной структурой. На вход подаются двумерные массивы признаков размером 3×50 , где три строки соответствуют измеряемым каналам акселерометра, а 50 столбцов — LPC-коэффициентам. Такая организация данных сохраняет пространственные взаимосвязи между коэффициентами одного порядка.

Энкодер состоит из двух сверточных слоев (Conv2D с ядром 3×3 и активацией ReLU) с промежуточными слоями субдискретизации (MaxPooling2D с окном 2×1), что обеспечивает последовательное сжатие пространственных признаков и выделение устойчивых паттернов. После сверточных слоев данные переводятся в одномерное представление (Flatten) и проецируются в латентное пространство размерности 8 с помощью полносвязного слоя Dense.

Декодер выполняет обратное преобразование: данные проходят через полносвязный слой, восстанавливающий пространственную форму (Reshape), затем через два блока увеличения размерности (UpSampling2D) и сверточные слои с активацией ReLU. Для коррекции размеров применяется слой Cropping2D, а финальный сверточный слой с линейной активацией формирует выходное изображение, соответствующее реконструированному входным данным. В качестве функции ошибки применялась среднеквадратичная ошибка MSE (Mean Squared Error):

$$MSE = \frac{1}{M \cdot p} \sum_{i=1}^M \sum_{n=1}^p \left(\hat{x}_n^{(i)} - x_n^{(i)} \right)^2, \quad (16)$$

где $x_n^{(i)}$ — значение n -го коэффициента для i -го канала, $i = 1, \dots, M$, $\hat{x}_n^{(i)}$ — соответствующий восстановленный отсчет. (В нашем случае, $M = 3$, $p = 50$.)

Модели 1 и 2, соответствующие классу исправного подшипника и исправного подшипника с ослабленным креплением датчика вибрации, обучались с идентичными гиперпараметрами: 50 эпох, размер батча 64, оптимизатор Adam с шагом обучения 10^{-4} , выбранными на основе серии предварительных экспериментов. Для обучения использовались 10 минут экспериментальных данных, соответствующих 5996 образцам. Окно сглаживания соответствовало 0.5 секундам.

3.2. Тестирование каскадной модели C-LPC-AE

Для оценки обобщающей способности предложенной каскадной модели автоэнкодеров тестирование проводилось на отложенных выборках. Первая ступень каскада представляет собой автоэнкодер, обученный на данных с исправного подшипника с корректным креплением акселерометра (10 минут, 5996 образцов). На рис. 7 представлены значения его ошибки реконструкции для различных типов сигналов. Для исправного случая с хорошим креплением конец тренировочных данных обозначен штрих-пунктирной линией. Как видно, ошибка реконструкции на тестовых данных несколько выше, чем на обучающих, однако остается ниже установленного порогового значения, за исключением единичного случая ложного срабатывания.

Для остальных трех типов данных — аномальный подшипник с хорошим креплением датчика, исправный подшипник с ослабленным креплением акселерометра и аномальный подшипник с ослабленным креплением — ошибка реконструкции вычислялась на протяжении всех 12 минут сигналов и, как можно видеть на рис. 7, во всех случаях превышала по-

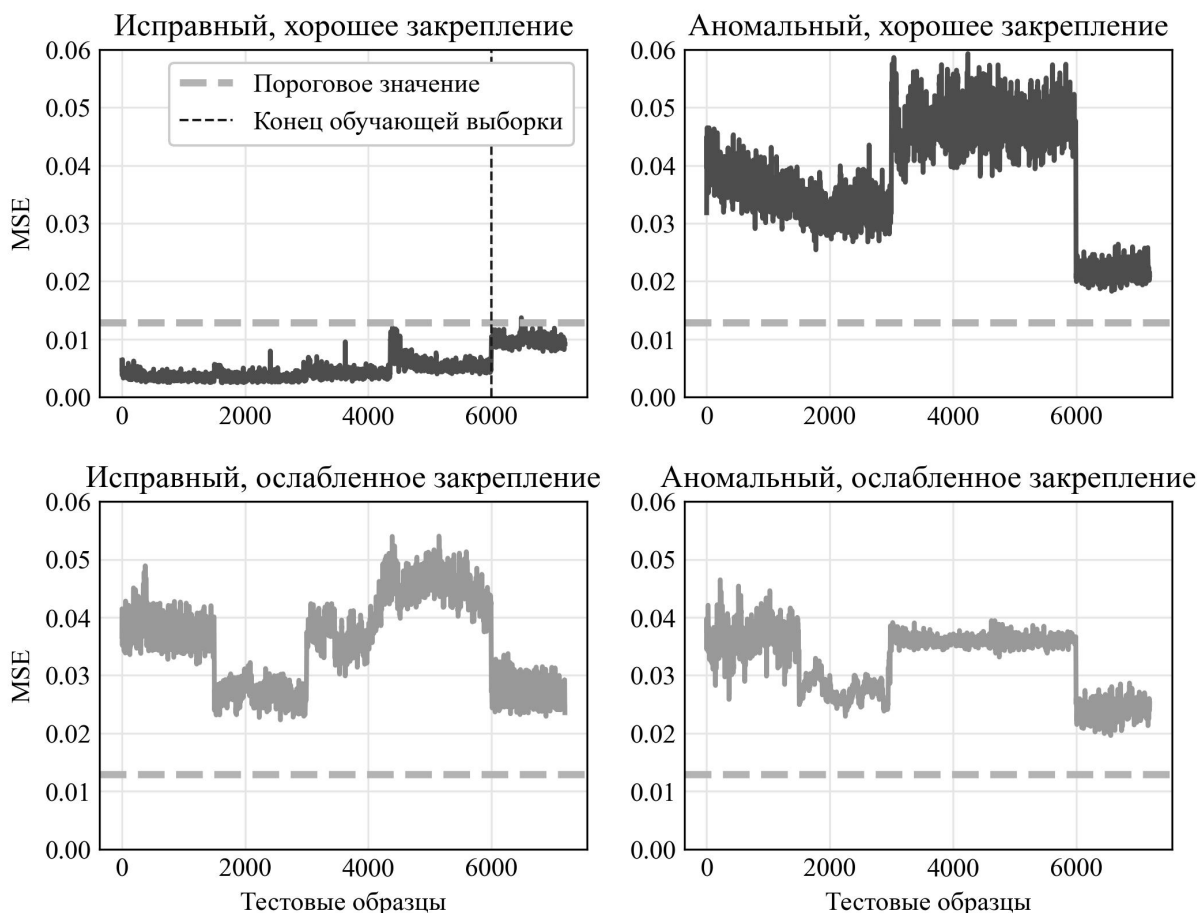


Рис. 7. Ошибка реконструкции первой модели автоэнкодера для разных типов данных

роговое значение. Это демонстрирует способность первой ступени каскадной модели выявлять отклонения от нормального состояния подшипника. Однако данный уровень реакции модели не позволяет различить, являются ли отклонения следствием аномалии подшипника или ослабления крепления датчика. Для этого необходима вторая ступень каскадной модели S-LPC-AE, предназначенная для дифференциации источников этих аномалий.

Результаты тестирования второго автоэнкодера, обученного на данных исправного подшипника с ослабленным креплением датчика, представлены на рис. 8. Аналогично первой модели, конец тренировочных данных обозначен штрих-пунктирной линией. Следует отметить, что в тестировании не использовались данные исправного подшипника с корректным креплением, поскольку данный автоэнкодер предназначен для обработки сигналов только в случае выявления отклонений на первой ступени каскадной модели.

Обученная модель демонстрирует высокие значения ошибки реконструкции для аномального подшипника с корректным креплением датчика, что позволяет уверенно выявлять этот тип отклонения.

В случае аномального подшипника с ослабленным креплением датчика наблюдается смешение сигналов, и часть срабатываний модели может интерпретироваться как неисправность крепления, а часть — как реальная аномалия подшипника. Это объясняется высокой схожестью характеристик сигналов при ослабленном креплении, что затрудняет их однозначное разделение, как было показано на рис. 6. На рис. 8 (нижний график) 37% срабатываний указывают на ослабление крепления датчика, а 63% — на наличие аномалии

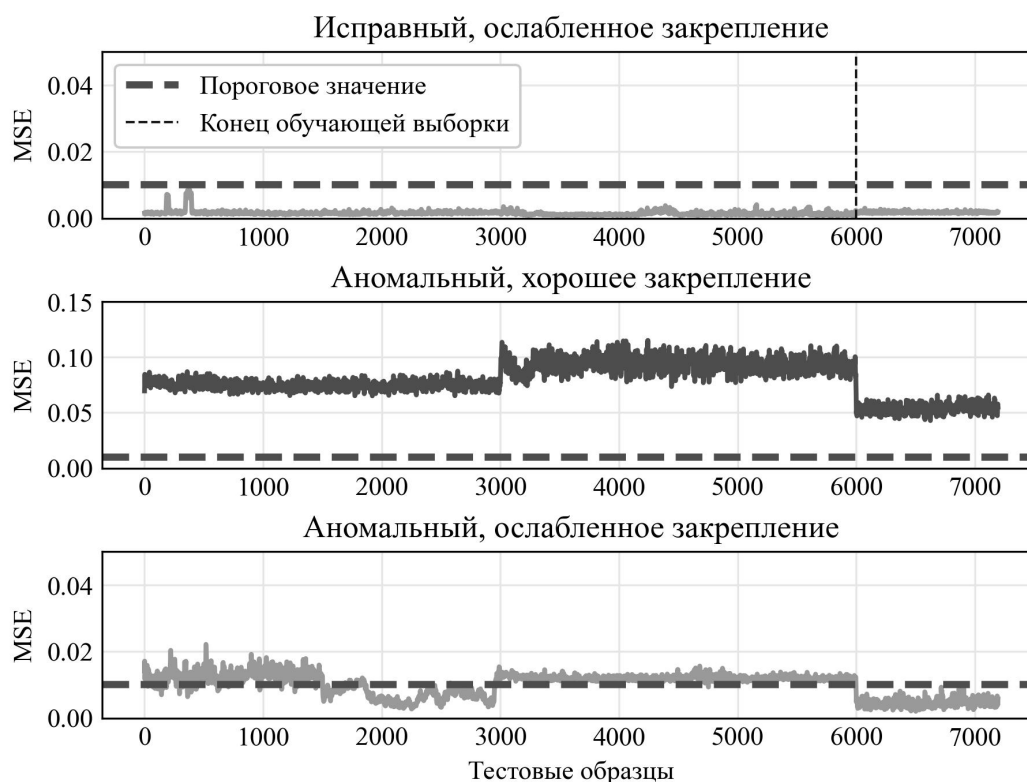


Рис. 8. Ошибка реконструкции второй модели автоэнкодера для разных типов данных

подшипника. Такой результат является удовлетворительным: при выявлении проблемы с креплением датчика достаточно устранить ее механически, после чего модель сможет корректно зафиксировать реальное anomальное состояние подшипника, что подтверждается высокой ошибкой реконструкции для данных с anomальным подшипником при правильной установке сенсора.

Таким образом, каскадная модель C-LPC-AE эффективно различает основные типы отклонений: нормальное состояние подшипника, аномалии в подшипнике и артефакты, вызванные ослаблением крепления датчика. В случае anomального подшипника с ослабленным креплением наблюдается частичное смешение сигналов: часть отклонений может интерпретироваться как проблема с креплением, а часть — как реальная неисправность подшипника, что отражает реальную сложность задачи. В практических условиях такие сигналы можно выделять в отдельную «зону неопределенности», требующую дополнительной проверки. При устранении механических проблем с креплением датчика сигналы перестают содержать искажения, вызванные некорректной установкой, и любые превышения порога реконструкции второго автоэнкодера теперь могут быть надежно интерпретированы как реальные аномалии подшипника.

Заключение

В данной работе предложен метод обеспечения достоверности измерений в системах технического мониторинга на основе каскадной архитектуры сверточных автоэнкодеров C-LPC-AE. Подход сочетает эффективное извлечение информативных признаков на основе линейного предсказательного кодирования и двухступенчатое обнаружение аномалий с использованием сверточных автоэнкодеров, что позволяет не только выявлять дефекты

оборудования, но и дифференцировать их от артефактов, вызванных нарушениями в работе измерительной системы.

Ключевой особенностью предложенной архитектуры является ее обучение на нормальных и нештатных состояниях измерительного узла — в частности, на сигналах с ослабленным креплением датчика. Это устраняет необходимость сбора данных о реальных отказах, которые редки, труднодоступны и часто не могут быть получены в контролируемых условиях.

Экспериментальные результаты подтвердили высокую чувствительность модели к изменениям в состоянии подшипника и способность автоматически фильтровать ложные тревоги, вызванные неисправностями сенсоров. Использование LPC-признаков обеспечивает компактное и информативное представление сигнала, снижая вычислительную нагрузку и упрощая интеграцию модели в промышленные системы реального времени. Предложенный подход повышает надежность и автономность мониторинга, что особенно важно для цифровой индустрии.

Исследование выполнено при финансовой поддержке Министерства науки и высшего образования Российской Федерации (государственное задание на выполнение фундаментальных научных исследований № FENU-2023-0010 (2023010ГЗ)).

Литература

1. Randall R., Smith W. Detection of faulty accelerometer mounting from response measurements // *Journal of Sound and Vibration*. 2020. Vol. 477. P. 115318. DOI: 10.1016/j.jsv.2020.115318.
2. Abboud D., Elbadaoui M., Becquerelle S., Lalmi M. Detection of Sensor Detachment in Aircraft Engines Using Vibration Signals // *Proceedings of the 10th International Conference on Rotor Dynamics – IFToMM* / ed. by K.L. Cavalca, H.I. Weber. Cham: Springer International Publishing, 2019. P. 351–365. DOI: 10.1007/978-3-319-99268-6_25.
3. Peng B., Bi Y., Xue B., *et al.* A Survey on Fault Diagnosis of Rolling Bearings // *Algorithms*. 2022. Vol. 15, no. 10. DOI: 10.3390/a15100347.
4. Kannan V., Zhang T., Li H. A Review of the Intelligent Condition Monitoring of Rolling Element Bearings // *Machines*. 2024. Vol. 12, no. 7. DOI: 10.3390/machines12070484.
5. Wu G., Yan T., Yang G., *et al.* A Review on Rolling Bearing Fault Signal Detection Methods Based on Different Sensors // *Sensors*. 2022. Vol. 22, no. 21. DOI: 10.3390/s22218330.
6. Li L., Qu L. Cyclic statistics in rolling bearing diagnosis // *Journal of Sound and Vibration*. 2003. Vol. 267, no. 2. P. 253–265. DOI: 10.1016/S0022-460X(02)01412-8.
7. Karacay T., Akturk N. Experimental diagnostics of ball bearings using statistical and spectral methods // *Tribology International*. 2009. Vol. 42, no. 6. P. 836–843. DOI: 10.1016/j.triboint.2008.11.003.
8. Gupta P., Pradhan M. Fault detection analysis in rolling element bearing: A review // *Materials Today: Proceedings*. 2017. Vol. 4, no. 2, Part A. P. 2085–2094. 5th International Conference of Materials Processing and Characterization (ICMPC 2016). DOI: 10.1016/j.matpr.2017.02.054.

9. Gao C., Liu S., Zhang X. A new method of adaptive Fourier modal decomposition and its application to rolling bearing fault diagnosis // *Structural Health Monitoring*. 2025. DOI: 10.1177/14759217251347534.
10. Li D.Z., Wang W., Ismail F. An Enhanced Bispectrum Technique With Auxiliary Frequency Injection for Induction Motor Health Condition Monitoring // *IEEE Transactions on Instrumentation and Measurement*. 2015. Vol. 64, no. 10. P. 2679–2687. DOI: 10.1109/TIM.2015.2419031.
11. Zhen L., Zhengjia H., Yanyang Z., Xuefeng C. Bearing condition monitoring based on shock pulse method and improved redundant lifting scheme // *Mathematics and Computers in Simulation*. 2008. Vol. 79, no. 3. P. 318–338. DOI: 10.1016/j.matcom.2007.12.004.
12. Butler D. The Shock-pulse method for the detection of damaged rolling bearings // *Non-Destructive Testing*. 1973. Vol. 6, no. 2. P. 92–95. DOI: 10.1016/0029-1021(73)90116-3.
13. He Y., Hu M., Feng K., Jiang Z. Bearing Condition Evaluation Based on the Shock Pulse Method and Principal Resonance Analysis // *IEEE Transactions on Instrumentation and Measurement*. 2021. Vol. 70. P. 1–12. DOI: 10.1109/TIM.2021.3050679.
14. Zhang Q., Deng L. An Intelligent Fault Diagnosis Method of Rolling Bearings Based on Short-Time Fourier Transform and Convolutional Neural Network // *Journal of Failure Analysis and Prevention*. 2023. Vol. 23. P. 795–811. DOI: 10.1007/s11668-023-01616-9.
15. Yue Y., Wang H., Zhang S. Mel frequency mapping for intelligent diagnosis of rolling element bearings across different working conditions // *Applied Acoustics*. 2024. Vol. 220. P. 109944. DOI: 10.1016/j.apacoust.2024.109944.
16. Xie F., Li G., Song C., Song M. The Early Diagnosis of Rolling Bearings' Faults Using Fractional Fourier Transform Information Fusion and a Lightweight Neural Network // *Fractal and Fractional*. 2023. Vol. 7, no. 12. DOI: 10.3390/fractalfract7120875.
17. Qin Y., Yang R., Shi H., *et al.* Adaptive Fast Chirplet Transform and Its Application Into Rolling Bearing Fault Diagnosis Under Time-Varying Speed Condition // *IEEE Transactions on Instrumentation and Measurement*. 2023. Vol. 72. P. 1–12. DOI: 10.1109/TIM.2023.3282660.
18. Raj K.K., Kumar S., Kumar R.R. Systematic Review of Bearing Component Failure: Strategies for Diagnosis and Prognosis in Rotating Machinery // *Arabian Journal for Science and Engineering*. 2024. Vol. 50. P. 5353–5375. DOI: 10.1007/s13369-024-09866-x.
19. Yuan Y., Wei J., Huang H., *et al.* Review of resampling techniques for the treatment of imbalanced industrial data classification in equipment condition monitoring // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 126. P. 106911. DOI: <https://doi.org/10.1016/j.engappai.2023.106911>.
20. Liang P., Yu Z., Wang B., *et al.* Fault transfer diagnosis of rolling bearings across multiple working conditions via subdomain adaptation and improved vision transformer network // *Advanced Engineering Informatics*. 2023. Vol. 57. P. 102075. DOI: 10.1016/j.aei.2023.102075.
21. Liu S., Jiang H., Wu Z., Li X. Data synthesis using deep feature enhanced generative adversarial networks for rolling bearing imbalanced fault diagnosis // *Mechanical Systems and Signal Processing*. 2022. Vol. 163. P. 108139. DOI: 10.1016/j.ymsp.2021.108139.

22. Iglesias G., Talavera E., González-Prieto Á., *et al.* Data Augmentation techniques in time series domain: a survey and taxonomy // *Neural Computing and Applications*. 2023. Vol. 35. P. 10123–10145. DOI: 10.1007/s00521-023-08459-3.
23. Lebedev D.K. Sensitivity of the Rolling Bearings Diagnostic Method Depending on the Number of Measuring Points of a Multipoint Temperature Sensor // 2025 27th International Conference on Digital Signal Processing and its Applications (DSPA). 2025. P. 1–5. DOI: 10.1109/DSPA64310.2025.10977932.
24. Гоглачев А.И. Классификация потокового временного ряда на основе нейросетевых технологий и поведенческих шаблонов // *Вестник ЮУрГУ. Серия: Вычислительная математика и информатика*. 2024. Т. 13, № 3. С. 79–94. DOI: 10.14529/cmse240305.
25. Краева Я.А. Обнаружение аномалий временного ряда на основе технологий интеллектуального анализа данных и нейронных сетей // *Вестник ЮУрГУ. Серия: Вычислительная математика и информатика*. 2023. Т. 12, № 3. С. 50–71. DOI: 10.14529/cmse230304.
26. Givnan S., Chalmers C., Fergus P., *et al.* Anomaly Detection Using Autoencoder Reconstruction upon Industrial Motors // *Sensors*. 2022. Vol. 22, no. 9. DOI: 10.3390/s22093166.
27. Ahmad S., Styp-Rekowski K., Nedelkoski S., Kao O. Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines // 2020 IEEE International Conference on Big Data (Big Data). 2020. P. 4093–4102. DOI: 10.1109/BigData50022.2020.9378015.
28. Malviya V., Mukherjee I., Tallur S. Edge-Compatible Convolutional Autoencoder Implemented on FPGA for Anomaly Detection in Vibration Condition-Based Monitoring // *IEEE Sensors Letters*. 2022. Vol. 6, no. 4. P. 1–4. DOI: 10.1109/LENS.2022.3159972.
29. Shestakov A.L., Lebedev D.K., Sinitsin V.V., *et al.* Intelligent Multipoint Temperature Sensors Data Processing for Rolling Bearings Diagnosis // 2024 XXXIV International Scientific Symposium Metrology and Metrology Assurance (MMA). 2024. P. 1–6. DOI: 10.1109/MMA62616.2024.10817658.
30. Mohammad M., Ibryaeva O., Sinitsin V., Eremeeva V. A Computationally Efficient Method for the Diagnosis of Defects in Rolling Bearings Based on Linear Predictive Coding // *Algorithms*. 2025. Vol. 18, no. 2. DOI: 10.3390/a18020058.
31. Thimmaraja Y.G., Nagaraja B.G., Jayanna H.S. Speech enhancement and encoding by combining SS-VAD and LPC // *International Journal of Speech Technology*. 2021. Vol. 24. P. 165–172. DOI: 10.1007/s10772-020-09786-9.
32. Wang Y., Huang H., Rudin C., Shaposhnik Y. Understanding How Dimension Reduction Tools Work: An Empirical Approach to Deciphering t-SNE, UMAP, TriMap, and PaCMAP for Data Visualization // *Journal of Machine Learning Research*. 2021. Vol. 22, no. 201. P. 1–73. URL: <http://jmlr.org/papers/v22/20-1061.html>.

Гальшев Дмитрий Вячеславович, студент кафедры «Прикладная математика и программирование», Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

Яковенко Артем Дмитриевич, аспирант, Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

Ибряева Ольга Леонидовна, канд. физ.-мат. наук, доцент, старший научный сотрудник «НИЛ технической самодиагностики и самоконтроля приборов и систем», Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

Шестаков Александр Леонидович, докт. техн. наук, проф., заведующий «НИЛ технической самодиагностики и самоконтроля приборов и систем», Южно-Уральский государственный университет (национальный исследовательский университет) (Челябинск, Российская Федерация)

DOI: 10.14529/cmse250401

CONTROL OF MEASUREMENT RELIABILITY IN TECHNICAL MONITORING INSTRUMENTS USING A CASCADE OF AUTOENCODERS

© 2025 D.V. Galyshev, A.D. Yakovenko, O.L. Ibrayeva, A.L. Shestakov

South Ural State University (pr. Lenina 76, Chelyabinsk, 454080 Russia)

E-mail: galyshevdu@susu.ru, iakovenkoad@susu.ru, ibriaevaol@susu.ru, a.l.shestakov@susu.ru

Received: 17.08.2025

The paper proposes a method for ensuring measurement reliability in technical monitoring systems – a cascaded model C-LPC-AE that combines informative spectral feature extraction based on Linear Predictive Coding (LPC) with a two-stage architecture of convolutional autoencoders. The method is designed for bearing condition diagnostics and simultaneous verification of sensor operational integrity, which is particularly relevant in digital industry environments requiring high autonomy and reliability of monitoring systems. The first stage of the cascade, trained on signals from a healthy bearing with properly mounted sensors, performs anomaly detection based on reconstruction error. The second stage, trained on data with a loosened accelerometer mount, analyzes the nature of the anomaly and enables differentiation between bearing faults and signal distortions caused by improper sensor installation. A key advantage of the approach is that it does not require data from actual equipment failures: training is performed exclusively on easily reproducible conditions – normal operation and simulated sensor mounting faults. Experiments were conducted using data from the SpectraQuest test rig, including bearings with an artificially introduced outer race defect. The results demonstrate high model sensitivity to actual bearing defects and sensor mounting issues. The use of LPC-based features ensures compact signal representation and reduces computational load, making the proposed approach promising for integration into real-time industrial diagnostic systems.

Keywords: vibration diagnostics, bearing diagnostics, loosened sensor mounting, autoencoder, anomaly detection, technical monitoring, linear predictive coding, spectral analysis, measurement reliability.

FOR CITATION

Galyshev D.V., Yakovenko A.D., Ibrayeva O.L., Shestakov A.L. Control of Measurement Reliability in Technical Monitoring Instruments Using a Cascade of Autoencoders. Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering. 2025. Vol. 14, no. 4. P. 5–24. (in Russian) DOI: 10.14529/cmse250401.

This paper is distributed under the terms of the Creative Commons Attribution-Non Commercial 4.0 License which permits non-commercial use, reproduction and distribution of the work without further permission provided the original work is properly cited.

References

1. Randall R., Smith W. Detection of faulty accelerometer mounting from response measurements. *Journal of Sound and Vibration*. 2020. Vol. 477. P. 115318. DOI: 10.1016/j.jsv.2020.115318.
2. Abboud D., Elbadaoui M., Becquerelle S., Lalmi M. Detection of Sensor Detachment in Aircraft Engines Using Vibration Signals. *Proceedings of the 10th International Conference on Rotor Dynamics – IFToMM / ed. by K.L. Cavalca, H.I. Weber*. Cham: Springer International Publishing, 2019. P. 351–365. DOI: 10.1007/978-3-319-99268-6_25.
3. Peng B., Bi Y., Xue B., *et al.* A Survey on Fault Diagnosis of Rolling Bearings. *Algorithms*. 2022. Vol. 15, no. 10. DOI: 10.3390/a15100347.
4. Kannan V., Zhang T., Li H. A Review of the Intelligent Condition Monitoring of Rolling Element Bearings. *Machines*. 2024. Vol. 12, no. 7. DOI: 10.3390/machines12070484.
5. Wu G., Yan T., Yang G., *et al.* A Review on Rolling Bearing Fault Signal Detection Methods Based on Different Sensors. *Sensors*. 2022. Vol. 22, no. 21. DOI: 10.3390/s22218330.
6. Li L., Qu L. Cyclic statistics in rolling bearing diagnosis. *Journal of Sound and Vibration*. 2003. Vol. 267, no. 2. P. 253–265. DOI: 10.1016/S0022-460X(02)01412-8.
7. Karacay T., Akturk N. Experimental diagnostics of ball bearings using statistical and spectral methods. *Tribology International*. 2009. Vol. 42, no. 6. P. 836–843. DOI: 10.1016/j.triboint.2008.11.003.
8. Gupta P., Pradhan M. Fault detection analysis in rolling element bearing: A review. *Materials Today: Proceedings*. 2017. Vol. 4, no. 2, Part A. P. 2085–2094. 5th International Conference of Materials Processing and Characterization (ICMPC 2016). DOI: 10.1016/j.matpr.2017.02.054.
9. Gao C., Liu S., Zhang X. A new method of adaptive Fourier modal decomposition and its application to rolling bearing fault diagnosis. *Structural Health Monitoring*. 2025. DOI: 10.1177/14759217251347534.
10. Li D.Z., Wang W., Ismail F. An Enhanced Bispectrum Technique With Auxiliary Frequency Injection for Induction Motor Health Condition Monitoring. *IEEE Transactions on Instrumentation and Measurement*. 2015. Vol. 64, no. 10. P. 2679–2687. DOI: 10.1109/TIM.2015.2419031.
11. Zhen L., Zhengjia H., Yanyang Z., Xuefeng C. Bearing condition monitoring based on shock pulse method and improved redundant lifting scheme. *Mathematics and Computers in Simulation*. 2008. Vol. 79, no. 3. P. 318–338. DOI: 10.1016/j.matcom.2007.12.004.
12. Butler D. The Shock-pulse method for the detection of damaged rolling bearings. *Non-Destructive Testing*. 1973. Vol. 6, no. 2. P. 92–95. DOI: 10.1016/0029-1021(73)90116-3.
13. He Y., Hu M., Feng K., Jiang Z. Bearing Condition Evaluation Based on the Shock Pulse Method and Principal Resonance Analysis. *IEEE Transactions on Instrumentation and Measurement*. 2021. Vol. 70. P. 1–12. DOI: 10.1109/TIM.2021.3050679.
14. Zhang Q., Deng L. An Intelligent Fault Diagnosis Method of Rolling Bearings Based on Short-Time Fourier Transform and Convolutional Neural Network. *Journal of Failure Analysis and Prevention*. 2023. Vol. 23. P. 795–811. DOI: 10.1007/s11668-023-01616-9.

15. Yue Y., Wang H., Zhang S. Mel frequency mapping for intelligent diagnosis of rolling element bearings across different working conditions. *Applied Acoustics*. 2024. Vol. 220. P. 109944. DOI: 10.1016/j.apacoust.2024.109944.
16. Xie F., Li G., Song C., Song M. The Early Diagnosis of Rolling Bearings' Faults Using Fractional Fourier Transform Information Fusion and a Lightweight Neural Network. *Fractal and Fractional*. 2023. Vol. 7, no. 12. DOI: 10.3390/fractalfract7120875.
17. Qin Y., Yang R., Shi H., *et al.* Adaptive Fast Chirplet Transform and Its Application Into Rolling Bearing Fault Diagnosis Under Time-Varying Speed Condition. *IEEE Transactions on Instrumentation and Measurement*. 2023. Vol. 72. P. 1–12. DOI: 10.1109/TIM.2023.3282660.
18. Raj K.K., Kumar S., Kumar R.R. Systematic Review of Bearing Component Failure: Strategies for Diagnosis and Prognosis in Rotating Machinery. *Arabian Journal for Science and Engineering*. 2024. Vol. 50. P. 5353–5375. DOI: 10.1007/s13369-024-09866-x.
19. Yuan Y., Wei J., Huang H., *et al.* Review of resampling techniques for the treatment of imbalanced industrial data classification in equipment condition monitoring. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 126. P. 106911. DOI: 10.1016/j.engappai.2023.106911.
20. Liang P., Yu Z., Wang B., *et al.* Fault transfer diagnosis of rolling bearings across multiple working conditions via subdomain adaptation and improved vision transformer network. *Advanced Engineering Informatics*. 2023. Vol. 57. P. 102075. DOI: 10.1016/j.aei.2023.102075.
21. Liu S., Jiang H., Wu Z., Li X. Data synthesis using deep feature enhanced generative adversarial networks for rolling bearing imbalanced fault diagnosis. *Mechanical Systems and Signal Processing*. 2022. Vol. 163. P. 108139. DOI: 10.1016/j.ymsp.2021.108139.
22. Iglesias G., Talavera E., González-Prieto Á., *et al.* Data Augmentation techniques in time series domain: a survey and taxonomy. *Neural Computing and Applications*. 2023. Vol. 35. P. 10123–10145. DOI: 10.1007/s00521-023-08459-3.
23. Lebedev D.K. Sensitivity of the Rolling Bearings Diagnostic Method Depending on the Number of Measuring Points of a Multipoint Temperature Sensor. 2025 27th International Conference on Digital Signal Processing and its Applications (DSPA). 2025. P. 1–5. DOI: 10.1109/DSPA64310.2025.10977932.
24. Goglachev A.I. Classification of Streaming Time Series Based on Neural Network Technologies and Behavioral Patterns. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2024. Vol. 13, no. 3. P. 79–94. DOI: 10.14529/cmse240305.
25. Kraeva Y.A. Anomaly Detection in Time Series Based on Data Mining and Neural Network Technologies. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2023. Vol. 12, no. 3. P. 50–71. DOI: 10.14529/cmse230304.
26. Givnan S., Chalmers C., Fergus P., *et al.* Anomaly Detection Using Autoencoder Reconstruction upon Industrial Motors. *Sensors*. 2022. Vol. 22, no. 9. DOI: 10.3390/s22093166.

27. Ahmad S., Styp-Rekowski K., Nedelkoski S., Kao O. Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines. 2020 IEEE International Conference on Big Data (Big Data). 2020. P. 4093–4102. DOI: 10.1109/BigData50022.2020.9378015.
28. Malviya V., Mukherjee I., Tallur S. Edge-Compatible Convolutional Autoencoder Implemented on FPGA for Anomaly Detection in Vibration Condition-Based Monitoring. IEEE Sensors Letters. 2022. Vol. 6, no. 4. P. 1–4. DOI: 10.1109/LSENS.2022.3159972.
29. Shestakov A.L., Lebedev D.K., Sinitsin V.V., *et al.* Intelligent Multipoint Temperature Sensors Data Processing for Rolling Bearings Diagnosis. 2024 XXXIV International Scientific Symposium Metrology and Metrology Assurance (MMA). 2024. P. 1–6. DOI: 10.1109/MMA62616.2024.10817658.
30. Mohammad M., Ibryaeva O., Sinitsin V., Ereemeeva V. A Computationally Efficient Method for the Diagnosis of Defects in Rolling Bearings Based on Linear Predictive Coding. Algorithms. 2025. Vol. 18, no. 2. DOI: 10.3390/a18020058.
31. Thimmaraja Y.G., Nagaraja B.G., Jayanna H.S. Speech enhancement and encoding by combining SS-VAD and LPC. International Journal of Speech Technology. 2021. Vol. 24. P. 165–172. DOI: 10.1007/s10772-020-09786-9.
32. Wang Y., Huang H., Rudin C., Shaposhnik Y. Understanding How Dimension Reduction Tools Work: An Empirical Approach to Deciphering t-SNE, UMAP, TriMap, and PaCMAP for Data Visualization. Journal of Machine Learning Research. 2021. Vol. 22, no. 201. P. 1–73. URL: <http://jmlr.org/papers/v22/20-1061.html>.