

А.В. ЕРПАЛОВ, В.В. СИНИЦИН, А.Л. ШЕСТАКОВ
**EWT-CGAN АУГМЕНТАЦИЯ ДАННЫХ ИЗМЕРИТЕЛЬНЫХ
СИСТЕМ**

Ерпалов А.В., Синицин В.В., Шестаков А.Л. EWT-CGAN аугментация данных измерительных систем.

Аннотация. В статье представлен новый метод аугментации данных измерительных систем, разработанный для задач мониторинга состояния промышленного оборудования. Актуальность исследования обусловлена существенными ограничениями традиционных методов генерации синтетических данных, которые не способны адекватно воспроизводить сложные нестационарные сигналы с характерными переходными процессами, трендами и сезонными вариациями, наблюдаемыми в реальных промышленных условиях. Предложенный метод основан на интеграции двух современных методов: эмпирического вейвлет-преобразования (EWT) и условных генеративных состязательных сетей (Conditional GAN). Метод реализуется в три этапа: (1) адаптивная декомпозиция исходных сигналов на моды с помощью EWT, (2) категоризация мод с присвоением меток, (3) генерация синтетических данных с использованием Conditional GAN. Для комплексной оценки качества синтезированных сигналов применялся набор статистических метрик, включая расстояние Wasserstein (WS), коэффициент корреляции Пирсона (PCC) и среднеквадратическую ошибку (RMSE). Экспериментальные исследования проводились на реальных данных температурного датчика, работающего в условиях нестационарных режимов промышленного оборудования. Результаты демонстрируют значительное преимущество предложенного метода по сравнению с традиционным подходом timeGAN: снижение расстояния Wasserstein на 17%, увеличение коэффициента корреляции Пирсона на 57% и уменьшение среднеквадратической ошибки на 21%. Полученные данные свидетельствуют об эффективности метода в воспроизведении ключевых характеристик исходных сигналов. Разработанный метод позволяет создавать набор синтетических данных, необходимых для обучения современных нейросетевых моделей диагностики промышленного оборудования. Его практическое применение позволяет существенно сократить затраты на сбор экспериментальных данных, обеспечивая высокое качество синтезированных сигналов, что подтверждено статистическими метриками.

Ключевые слова: диагностика оборудования, сигналы с датчиков, аугментация, синтетические данные, эмпирическое вейвлет преобразование, генеративные состязательные сети.

1. Введение. В последние годы мониторинг состояния промышленного оборудования становится критически важным для предотвращения аварий и оптимизации производственных процессов. Однако сбор достаточного объема экспериментальных данных для обучения нейросетевых моделей технического состояния оборудования часто затруднен из-за высокой стоимости и длительности таких экспериментов. В этой связи актуальной задачей является разработка методов аугментации данных, способных генерировать синтетические сигналы, близкие к реальным, но не требующих дополнительных затрат на их сбор.

Традиционные методы генерации синтетических данных, такие как простое добавление шума или интерполяция, часто оказываются недостаточно эффективными для воспроизведения сложных нестационарных сигналов, характерных для промышленного оборудования. Эти сигналы могут содержать переходные процессы, тренды и сезонные вариации, которые трудно смоделировать стандартными подходами.

Целью данного исследования является разработка метода аугментации данных измерительных систем, способного решить проблему генерации нестационарных сигналов с сохранением их ключевых характеристик, таких как переходные процессы, тренды и сезонные изменения.

Одним из решением данной проблемы является применение моделей на основе глубоких нейронных сетей, в особенности генеративные сети, которые все больше используются в разных сферах деятельности, включая анализ временных рядов средств измерений в задачах мониторинга состояния промышленного оборудования. Опубликовано большое количество работ, в том числе обзоры по существующим вариациям генеративных состязательных нейронных сетей для разных областей применения [1 – 3].

Модели глубокого обучения типа GAN состоят из двух нейронных сетей: генератора и дискриминатора. Генератор G принимает случайный шум и пытается сгенерировать синтетические данные, распределение которых схоже с обучающим набором данных. Дискриминатор D пытается определить, являются ли сгенерированные данные реальными или «поддельными». Генератор стремится максимизировать частоту отказов дискриминатора, тогда как дискриминатор стремится минимизировать ее. На рисунке 1 показан общий вид архитектуры GAN.

GAN относится к семейству генеративных моделей и является альтернативным методом генерации синтетических данных, который не требует экспертных знаний в предметной области. Генеративные состязательные нейронные сети впервые предложены в работе [4] в 2014 году, где многослойный персептрон использовался как для дискриминатора, так и для генератора. В 2015 году авторы работы [5] предложили глубокую сверточную генеративную состязательную сеть (DCGAN) для генерации синтетических изображений. В дальнейшем исследователи постоянно совершенствовали ранние архитектуры GAN, функции потерь и метрики оценки, одновременно внедряя их в прикладные задачи.




Рис. 1. Общий вид архитектуры генеративной состязательной нейронной сети

В настоящее время разработано большое количество вариаций GAN, однако каждая вариация направлена на решение задач в определенной сфере деятельности. Объясняется это тем, что традиционный GAN имеет недостатки, связанные с нестабильностью обучения из-за исчезновения градиента и коллапса мод. Основные пути решения этих недостатков: теоретические подходы, таких как изменение функции потерь; подходы, основанные на изменениях структур нейронных сетей, включая внутреннюю структуру [6] или добавления условий для входных данных [7].

Для изменения функции потерь авторы работы [8] предложили применять GAN совместно с методом наименьших квадратов (LSGAN). Такой подход предполагает использование в функции потерь метода наименьших квадратов для улучшения стабильности и скорости сходимости. Для изменений внутренней структуры и достижения более стабильной структуры авторы работы [5] предложили применение неконтролируемой глубокой сверточной GAN (DCGAN), которая работает на основе интеграции сверточных нейронных сетей с GAN. Авторы другой работы [6] предложили прогрессивно растущую GAN (PGGAN), использующую подход постепенного роста для генерации данных с высоким разрешением.

Отдельно важно затронуть генеративные состязательные нейронные сети с условиями (Conditional GAN), разработанные авторами работы [7]. Авторы предложили генератор и дискриминатор дополнить вспомогательной информацией (категориальные метки, модальность). Другими словами, в генератор и дискриминатор добавили дополнительный входной слой. Применяя такой метод

генерации данных, можно с помощью одной модели создать несколько наборов данных, разделенных на классы (категории).

Одной из главных проблем генеративных состязательных нейронных сетей является определение метрики, по которой дискриминатор оценивает, походит ли сгенерированный сигнал на исходный. Обычно это делается на основе сравнения распределений двух сигналов (исходного и сгенерированного). Авторы работы [9] предложили в качестве метрики использовать расстояние Wasserstein первого порядка (w_1), которое рассчитывается по следующей зависимости

$$w_1(u, v) = \int_{-\infty}^{+\infty} |U_{cdf}(x) - V_{cdf}(x)| dx, \quad (1)$$

где U_{cdf} и V_{cdf} – функции распределений, соответствующие плотностям распределений u и v .

Разработанный метод Wasserstein GAN [9] позволил решить основные проблемы обучения традиционного GAN. В частности, в процессе обучения WGAN не требует строгого баланса между дискриминатором и генератором, что в свою очередь позволяет использовать более простые структуры нейронных сетей. Кроме того, WGAN решает вопрос с явлением отбрасывания мод, которое часто проявляется при использовании традиционного GAN.

На основе описанных вариаций генеративных состязательных нейронных сетей предложены гибридные модели, например Conditional Wasserstein GAN [10]. Модель позволяет генерировать данные по условиям с хорошей сходимостью за счет применения расстояния Wasserstein в дискриминаторе.

Вариации GAN, указанные выше, в основном направлены на обработку изображений, но предоставленные фундаментальные структуры применяются также к сигналам временных рядов. В таком случае генеративный состязательные нейронные сети принято обозначать как «timeGAN».

Описанные выше методы аугментации подходят для генерации большинства сигналов средств измерений. Однако, несмотря на это существует ряд сигналов, генерация которых существующими методами будет некорректна и может привести к сигналам сильно отличающимся от исходных. К таким сигналам могут относиться данные средств измерений с характерными нестационарными переходными участками, сезонными изменениями. Обычно это

сигналы с датчиков, установленных на промышленном оборудовании, которое подвержено внезапным остановкам и имеет нестационарные режимы работы.

К примеру, подобными качествами обладают сигналы с датчиков температуры, установленные на объекте с нестационарными режимами работы. Обычно на временной реализации температуры хорошо дифференцируются зоны включения оборудования и работа под нагрузкой (рост температуры), зоны снятия нагрузки (снижение температуры), зоны временного останова оборудования и зоны длительного простоя оборудования (резкое падение температуры на всех сенсорах).

В работе предложена *EWT-CGAN* аугментация временных данных средств измерений промышленного оборудования на основе комплексного применения эмпирического вейвлет преобразования и генеративной состязательной нейронной сети.

2. Теоретические основы.

Метрики оценки качества синтезированных сигналов. Для оценки качества синтезированных сигналов существует широкий спектр метрик [11, 12], что свидетельствует об отсутствии общепринятого критерия. Обычно метрики подразделяются на количественные и качественные. Наиболее представительной качественной метрикой является органолептический метод. Однако в отличие от оценки изображений, оценить таким методом качество временных рядов сложно. Поэтому обычно проводят анализы *t-SNE* [13] и *PCA* [14] для визуализации того, насколько хорошо сгенерированные распределения напоминают исходные распределения [15].

Количественная оценка включает статистические метрики, используемые для анализа временных рядов, которые сведены в таблице 1. Эти метрики являются одними из наиболее часто используемых для оценки временных рядов и используются для оценки производительности GAN. В первую очередь связано это с тем, что они могут отражать сходство между данными обучения и синтетическими данными.

Здесь x_i – фактическое значение временного ряда x в момент времени i ; y_i – сгенерированное значение временного ряда y в момент времени i ; $\tilde{x}$ и $\tilde{y}$ – средние значения x и y соответственно; f_i выбирается исходя из сезонности и несезонности данных и принимается равным $y_i - M$ и $y_i - 1$ соответственно, где M – период x за сезон.

Таблица 1. Статистические метрики между предсказанными и фактическими значениями

Номер	Наименование	Зависимость
1	Коэффициент корреляции Пирсона	$PCC = \frac{\sum_{i=1}^N (x_i - \tilde{x})(y_i - \tilde{y})}{\sqrt{\sum_{i=1}^N (x_i - \tilde{x})^2 \sum_{i=1}^N (y_i - \tilde{y})^2}}$
2	Процентная среднеквадратическая разница	$PRD = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i)^2}}$
3	Среднеквадратическая ошибка	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2}$
4	Среднее значение квадратов разностей	$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2$
5	Средняя относительная ошибка	$MRE = \frac{1}{N} \sum_{i=1}^N \left \frac{x_i - y_i}{x_i - f_i} \right $
6	Средняя абсолютная ошибка	$MAE = \frac{1}{N} \sum_{i=1}^N x_i - y_i $

Помимо рассмотренных существуют метрики оценки производительности GAN на основе сходства между двумя изображениями. Большинство метрик успешно применяются и для данных временных рядов. К таким метрикам относятся Inception score (IS) [16], Frechet Inception Distance (FID) [17] и индекс структурного сходства (SSIM) [17].

Кроме того, существуют универсальные метрики, которые подходят для разных типов данных, в том числе и для временных рядов. Например, максимальное среднее расхождение (MMD) [18] является мерой сходства/различия между двумя распределениями вероятностей или расстояние Wasserstein (1).

Эмпирическое вейвлет преобразование. С развитием цифровой индустрии и оснащением предприятий большим количеством разных по типу средств измерений, возникла потребность в разработке новых методов обработки реальных данных. Конкретно методов, позволяющих работать с нестационарными сложными сигналами без предварительной экспертной оценки и сегментации сигнала.

Одной из современных тенденций в обработке нестационарных сигналов является применение новых методов декомпозиции сигналов, которые в отличие, например, от традиционного преобразования Фурье, декомпозируют сигнал не на заранее определенные базисы (синусоиды), а на некоторые процессы (детерминированные/ случайные), подобранные эмпирическим путем. Впервые подобный метод представлен в 1998 году Н. Хуангом в работе [19] – эмпирическая модовая декомпозиция (EMD). Позднее на основе этой идеи разработаны методы вариационной модовой декомпозиции [20], эмпирического вейвлет преобразования [21], эмпирического Фурье преобразования [22], которые решали вопросы ограниченного применения метода и неточной декомпозиции на моды.

В последние годы широкое распространение получил метод эмпирического вейвлет преобразования (EWT), предложенный Ж. Жилем в 2013 году [23]. Метод EWT заключается в построении семейства вейвлетов, адаптированных к обрабатываемому сигналу. С точки зрения преобразования Фурье – это эквивалентно построению набора полосовых фильтров. EWT сочетает в себе концепцию адаптивной декомпозиции EMD и обширную теорию вейвлет-преобразования.

Метод EWT – широко используемый метод сегментации сигналов. Принцип сегментации включает: адаптивное сегментирование спектра Фурье путем выделения локальных максимумов и построение набора полосовых фильтров пригодных для обработки сигналов и извлечения амплитудно-модулированных (AM) и частотно-модулированных (FM) компонентов сигнала.

Нормализованная ось Фурье, которая имеет периодичность 2π , разбита на N последовательных частей, т.е. $A_n = [\omega_{n-1}, \omega_n]$ ($\omega_0 = 0, \omega_N = \pi$), где ω_n – граничная точка между двумя частями и соответствующие значение это минимум между двумя соседними максимальными значениями в спектре Фурье. Очевидно, что $\bigcup_{n=1}^N A_n = [0, \pi]$. На рисунке 2 показана сегментация спектра с помощью EWT. Точка ω_n определяется как центральная точка A_n . Затем определяется ширина переходной области $T_n = 2\tau_n$.




Рис. 2. Сегментация спектра с помощью EWT

Используя метод построения вейвлетов Литтлвуда-Пейли и Мейера, строится эмпирическая вейвлет функция. После определения A_n эмпирический вейвлет используется как полосовой фильтр. Эмпирическая вейвлет функция $\widehat{\psi}_n(\omega)$ и эмпирическая масштабная функция $\widehat{\phi}_n(\omega)$ определяются по формулам

$$\widehat{\phi}_n(\omega) = \begin{cases} 1, (|\omega| \leq (1-\gamma)\omega_n) \\ \cos \left\{ \frac{\pi}{2} \beta \left[\frac{1}{2\gamma\omega_n} (|\omega| - (1-\gamma)\omega_n) \right] \right\}, (1-\gamma)\omega_n \leq \omega \leq (1+\gamma)\omega_n, \\ 0, \text{others} \end{cases} \quad (2)$$

$$\widehat{\psi}_n(\omega) = \begin{cases} 1, (1+\gamma)\omega_n \leq |\omega| \leq (1-\gamma)\omega_{n+1} \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\omega_{n+1}} (|\omega| - (1-\gamma)\omega_{n+1}) \right) \right]; (1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{1}{2\omega_n} (|\omega| - (1-\gamma)\omega_{n+1}) \right) \right]; (1-\gamma)\omega_n \leq |\omega| \leq (1+\gamma)\omega_n \\ 0, \text{others} \end{cases}, \quad (3)$$

где переходная функция $B(x)$, коэффициент γ и переходная фаза τ_n определяются из зависимостей (4).

$$\begin{aligned} \beta(x) &= x^4 (35 - 84x + 70x^2 - 20x^3), \\ \gamma &< \min_n \left(\frac{\omega_{n-1} - \omega_n}{\omega_{n-1} + \omega_n} \right), \quad \tau_n = \gamma\omega_n. \end{aligned} \quad (4)$$

После EWT коэффициент аппроксимации и коэффициент детализации могут быть выражены следующим образом

$$W_{f1}(0, t) = \langle x, \phi_1 \rangle = \int x(\tau) \overline{\phi_1(\tau - t)} d\tau = F^{-1} [x(\omega) \widehat{\phi}_1(\omega)], \quad (5)$$

$$W_{f2}(n, t) = \langle x, \psi_n \rangle = \int x(\tau) \overline{\psi_n(\tau - t)} d\tau = F^{-1} [x(\omega) \widehat{\psi}_n(\omega)]. \quad (6)$$

Тогда функциональное выражение восстановленного сигнала выглядит следующим образом

$$\begin{aligned} x(t) &= W_{f1}(0, t) * \varphi_1(t) + \sum_{n=1}^N W_{f2}(n, t) * \psi_n(t) = \\ &= F^{-1} \left[\widehat{W}_f(n, \omega) \varphi_1(\omega) + \sum_{n=1}^N \widehat{W}_f(n, \omega) \widehat{\psi}_n(\omega) \right], \end{aligned} \quad (7)$$

где «*» – оператор свертки, $W_{f1}(0, \omega)$ и $W_{f2}(n, \omega)$ – преобразование Фурье коэффициентов аппроксимации $W_{f1}(0, t)$ и $W_{f2}(n, t)$ соответственно. Сигнал f раскладывается в сумму нескольких однокомпонентных сигналов

$$x(t) = \sum_{k=0}^{N-1} x_k(t). \quad (8)$$

В общем виде блок-схема алгоритма метода EWT представлена на рисунке 3.




Рис. 3. Блок-схема алгоритма метода EWT

3. EWT-CGAN аугментация.

Обоснование выбора EWT и Conditional GAN. Объединение методов EWT и Conditional GAN обусловлено необходимостью решения ключевой проблемы генерации нестационарных сигналов промышленного оборудования – сохранения характерных особенностей переходных процессов, трендов и сезонных вариаций, которые традиционные методы типа timeGAN воспроизводят недостаточно точно.

Метод EWT выбран в качестве метода декомпозиции сигналов по нескольким причинам. Во-первых, в отличие от классического вейвлет-анализа или преобразования Фурье, EWT адаптируется к спектральным характеристикам конкретного сигнала, что критично для обработки нестационарных данных с изменяющимися во времени частотами. Во-вторых, EWT обеспечивает четкое разделение мод без явления «смешивания», характерных для других методов эмпирических декомпозиций. Это позволяет выделить физически значимые компоненты сигнала: высокочастотные шумы, «средние» частоты, связанные с изменениями режимов работы оборудования, и низкочастотные тренды. Наконец, EWT менее чувствителен к краевым эффектам по сравнению с другими адаптивными методами, что важно для работы с относительно короткими реализациями сигналов.

Использование Conditional GAN вместо стандартного timeGAN обусловлено тремя факторами. Первый – возможность управления процессом генерации через категориальные метки мод, что позволяет сохранять их индивидуальные характеристики. Второй – устойчивость Conditional GAN к «коллапсу мод», который часто наблюдается при генерации разнородных временных рядов. Третий фактор – гибкость: одна обученная модель может генерировать сигналы для разных режимов работы оборудования, изменяя входные метки.

Комбинация EWT и Conditional GAN создает синергетический эффект. EWT обеспечивает содержательную декомпозицию сигнала на физически интерпретируемые компоненты, а Conditional GAN точно воспроизводит распределение каждой моды. Такой подход особенно эффективен для сигналов с резкими переходами между режимами (например, пуск/останов оборудования), где традиционные методы генерации часто дают «размытые» или статистически несостоятельные результаты.

Описание архитектуры метода. Предложенная EWT-CGAN аугментация основана на комплексном применении эмпирического вейвлет преобразования (EWT) и генеративной состязательной нейронной сети с условными переменными (Conditional GAN).

Подобная связка позволяет корректно генерировать нестационарные сигналы средств измерений, близкие к реальным, в отличие от простого применения генеративных состязательных нейронных сетей. Архитектура *EWT-CGAN* аугментации представлена на рисунке 4.

Основой *EWT-CGAN* аугментации является генеративная состязательная сеть с условными переменными на входе. Однако исходный сигнал не сразу подается на дискриминатор, а предварительно декомпозируется на моды. Каждой моде присваивается категориальная метка (*label*). Таким образом на вход в дискриминатор (*D*) подаются одновременно и моды исходного сигнала и их обозначения в виде меток. Генератор (*G*) в этом случае учится синтезировать сигналы одновременно для всех мод исходного сигнала. Другими словами, в одной генеративной состязательной нейронной сети происходит обучение генерации одновременно нескольких разных процессов, соответствующих разным модам исходного сигнала. Последним этапом работы является сложение полученных синтезированных мод сигнала. При этом на стадии сложения мод есть возможность подкорректировать сигнал: сгладить низкочастотную составляющую, добавить/убрать тренд.




Рис. 4. Общий вид архитектуры EWT-CGAN аугментации

Настройки декомпозиции сигнала. Настройка процесса декомпозиции сигналов методом EWT в данном исследовании основывалась на оптимальном выборе количества мод, что является ключевым параметром для качественного анализа промышленных сигналов. Для сигналов от температурных датчиков установлено, что разложение на три характерные моды обеспечивает наиболее полное и физически обоснованное представление данных:

1. Высокочастотная мода – отражает шумовые составляющие сигнала.
2. Среднечастотная мода – соответствует рабочим режимам и переходным процессам.
3. Низкочастотная мода – описывает температурные тренды и долгосрочные изменения.

Такое разделение выбрано на основе анализа спектральной плотности мощности для 50 различных сигналов от температурных датчиков. Эксперименты показали, что увеличение числа мод свыше трех приводит к появлению искусственных компонент, а уменьшение – к потере значимых физических характеристик.

Для верификации качества декомпозиции использовались следующие критерии:

- энергетическая сбалансированность (разница энергий исходного и восстановленного сигналов не превышала 1%);
- минимальная взаимная корреляция между модами ($< 0,15$);
- физическая интерпретируемость каждой компоненты;
- сохранение ключевых особенностей исходного сигнала (переходных процессов, экстремумов, точек перегиба).

Такие параметры декомпозиции обеспечивают оптимальное представление сигналов для последующей обработки методом Conditional GAN, сохраняя при этом все существенные особенности исходных данных. Важно отметить, что предложенная конфигурация (три моды) показала свою эффективность именно для сигналов температурных датчиков промышленного оборудования, работающего в нестационарных режимах. Для сигналов другой природы (например, вибрационных или акустических) параметры декомпозиции могут потребовать корректировки.

Создание генератора и дискриминатора. Генератор представляет собой двухвходовую нейронную сеть, которая создает сигнал на основе массива случайных чисел и связанной с ним категориальной метки.

Алгоритм создания генератора:

- Создается массив случайного шума заданной размерностью.
- Категориальные метки преобразуются во входные векторы.
- Объединяются результаты из двух входов в один массив.
- Увеличивается частота дискретизации полученных массивов с помощью серии одномерных транспонированных сверточных слоев с нормализацией данных и слоями активации ReLU.

Количество транспонированных сверточных слоев и их настройки выбираются экспериментально на основе анализа длины входного сигнала и его частотных характеристик. Для исследуемого в работе процесса (1201 точка) выбрано 5 слоев. Для сигналов большей длины или с более сложными переходными процессами количество слоев может быть увеличено до 6–7.

В общем виде структуру генератора можно представить в виде последовательности транспонированных сверточных слоев, слоев нормализации и слоев активации (рисунок 5).

В качестве дискриминатора задается двухвходовая нейронная сеть, которая классифицирует «реальный» / «сгенерированный» сигнал и определяет их категориальные метки.

Алгоритм создания дискриминатора:

- На вход подается сигнал с генератора.
- Категориальные метки преобразуются в векторы.
- Результаты двух входов объединяются в один массив.
- Уменьшается размерность массивов, используя 1-D

сверточные слои с функций активации leakyReLU и масштабным коэффициентом 0,2. Коэффициент выбран как компромисс между устойчивостью к «затуханию» градиентов (при меньших значениях) и сохранением информации (при больших). Количество сверточных слоев и их настройки выбираются экспериментально.

В общем виде структуру дискриминатора можно представить в виде последовательности сверточных слоев и слоев активации (рисунок 5).




Рис. 5. Общая структура генератора (слева) и дискриминатора (справа)

Настройки процесса обучения нейросетевой модели. Ниже приведены рекомендации по настройке обучения модели:

- Для корректного обучения модели рекомендуется задавать количество эпох не менее 1000. Точное значение определяется по критерию сходимости метрик WS и PCC, когда дальнейшее обучение не улучшает их значения более чем на 1%.

- Размер пакета (Batch Size) выбирается исходя из размера исходного сигнала и вычислительных мощностей. Обычно принимается одно из следующих значений: 64, 128 или 256.

- Скорость обучения выбирается на основе grid-поиска в диапазоне [0,0001; 0,001] для обеспечения стабильного снижения потерь без колебаний.

- Рекомендуется процесс обучения проводить с использованием графического процесса (GPU) с целью сокращения времени вычисления.

- В качестве оптимизатора рекомендуется выбирать Adams, что обосновано адаптивностью скорости обучения и эффективностью при работе с зашумленными градиентами. Кроме того, оптимизатор Adams устойчив к различным начальным условиям благодаря адаптивному расчету моментов градиентов.

- Скорость затухания скользящих среднего градиента (gradientDecayFactor) в общем случае рекомендуется задавать равным 0,5, что обеспечивает баланс между учетом истории градиентов и быстрой адаптацией. Кроме того, слишком высокие значения ($> 0,9$) приводят к инерционности при смене режимов, а слишком низкие ($< 0,3$) вызывают излишние колебания процесса обучения.

- Скорость затухания скользящих квадратичного градиента (squaredGradientDecayFactor) в общем случае рекомендуется задавать равной 0,99 для длительного усреднения квадратов градиентов и стабилизации обучения при редких, но значительных выбросах. При наличии выраженных выбросов допускается уменьшение squaredGradientDecayFactor до 0,95.

4. Применение EWT-CGAN аугментации для реальных сигналов промышленного оборудования. EWT-CGAN аугментация апробирована на реальных данных средств измерений, представляющие собой сигналы с температурного датчика, установленного на агрегате с характерными нестационарными режимами работы.

Для аугментации использовано 495 временных реализаций процесса изменения нормированной температуры. Каждая реализация

состоит из 1201 отчета по времени. Фрагмент одной реализации показан на рисунке 6.




Рис. 6. Фрагмент временной реализации с температурного датчика

Выполнена аугментация данных температуры двумя методами: традиционным методом *timeGAN* и предложенным *EWT-CGAN*.

EWT-CGAN аугментация предполагает использование эмпирического вейвлет преобразования, для которого задались настройки, при которых каждая реализация декомпозировалась на три моды. В дальнейшем каждой моде присваивалась категориальная метка (1, 2 или 3, соответствующая номеру моды).

Структура генератора и структура дискриминатора выбиралась одинаковыми как для *timeGAN*, так и для *EWT-CGAN*. Гиперпараметры генератора и дискриминатора задавались также одинаковыми (таблица 2 и таблица 3).

Количество транспонированных сверточных слоев генератора (5 слоев, таблица 2) и размер ядер (5×1 , 10×1 и т.д.) выбраны экспериментально на основе анализа длины входного сигнала (1201 точка) и его частотных характеристик.

Количество сверточных слоев и размер ядер дискриминатора (5 слоев, таблица 3) выбраны на основе анализа качества генерации: добавление слоев сверх 5 не улучшало показатели Wasserstein и PCC, но увеличивало время обучения.

На основе выполненного grid-поиска величина скорости обучения составила 0,0002.

Проведено несколько запусков модели с разными начальными весами (инициализация *Xe* и *Glorot* – нормальное распределение). Результаты показали, что вариативность метрик (WS, PCC, RMSE) не превышает 5%, что подтверждает стабильность обучения.

Таблица 2. Гиперпараметры генератора

Операция	Размер ядра	Шаг	Число фильтров	Нормализация	Функция активации
Объединение входов	–	–	–	Нет	
Свертка	5×1	1	512	Да	ReLU
Свертка	10×1	4	256	Да	ReLU
Свертка	12×1	4	128	Да	ReLU
Свертка	5×1	4	64	Да	ReLU
Свертка	7×1	2	1	Нет	–

Таблица 3. Гиперпараметры дискриминатора

Операция	Размер ядра	Шаг	Число фильтров	Нормализация	Функция активации
Объединение входов	–	–	–	Нет	
Свертка	17×1	2	512	Нет	leakyReLU
Свертка	16×1	4	256	Нет	leakyReLU
Свертка	16×1	4	128	Нет	leakyReLU
Свертка	8×1	4	64	Нет	leakyReLU
Свертка	8×1	1	1	Нет	–

Характерный вид реализации температурного сигнала после аугментации разными методами показан на рисунке 7.




Рис. 7. Графики исходного и аугментированного разными методами сигнала температуры

Выполнена оценка качества аугментации сигнала с применение статистических метрик, описанных ранее. Вычисленные значения метрик для сигналов, полученных методами *timeGAN* и *EWT-CGAN* по отношению к исходному сигналу, сведены в таблицу 4.

Таблица 4. Метрики оценки качества аугментации

Метрики	MAE	MSE	RMSE	PRD	MRE	PCC	WS
<i>timeGAN</i>	0,281	0,132	0,364	1,898	0,218	0,133	0,212
<i>EWT-CGAN</i>	0,236	0,082	0,286	1,494	0,377	0,313	0,176
Сравнение	16%	38%	21%	21%	–	–	17%

Из таблицы 4 видно, что сигналы, сгенерированные методом *EWT-CGAN*, статистически более подобны исходному сигналу. Практически все метрики, в том числе наиболее значимая – расстояние Wasserstein, для метода *EWT-CGAN* на 20% ниже, чем для традиционного метода *timeGAN*. Коэффициент корреляции Пирсона (PCC) так же показал лучшую сходимость сигналов, сгенерированных методом *EWT-CGAN*, с исходным, в отличие от сигналов, сгенерированных методом *timeGAN*. Разница коэффициента достигает 57%. Однако рассчитанная средняя относительная ошибка (MRE) показала обратный эффект. Вероятно, это связано с особенностями вычислений коэффициента, в котором одним из основных показателей выступает сезонность процесса (п. 4 таблицы 1).

Другим методом оценки качества аугментации сигнала является непосредственное сравнение плотностей распределений исходного сигнала и сгенерированного. На рисунке 8 показаны сравнения плотностей распределений исходного сигнала и сгенерированного методами *EWT-CGAN* и *timeGAN* соответственно с рассчитанными значениями коэффициентов эксцесса и асимметрии.

Анализируя плотности распределений, важно отметить, что при генерации сигнала методом *timeGAN* плотность распределения сдвигается влево, что свидетельствует о преобладании более низких амплитудных значений. Для метода *EWT-CGAN* плотность распределения, наоборот, смещена вправо – в область с большими по величине амплитудами.

Анализ коэффициента эксцесса показал, что исходный сигнал соответствует нормальному закону распределения, а сгенерированные не соответствуют. При этом для сигнала, сгенерированного методом *timeGAN*, коэффициент эксцесса равен 2,43, а для метода *EWT-CGAN* – равен 2.




Рис. 8. Плотности распределений исходного сигнала и сгенерированного методом timeGAN (слева), исходного и сгенерированного методом EWT-CGAN (справа)

Аналогичная картина наблюдается при рассмотрении исходного сигнала и сгенерированного по двум методам в виде диаграммы размахов (рисунок 9).




Рис. 9. Диаграмма размахов нормированных амплитуд для исходного и сгенерированных сигналов

Видно, что среднее значение для сгенерированных сигналов смещено относительно исходного, а общий вид плотности распределений для сгенерированных сигналов несколько отличается от исходного. Вероятно, такое расхождение связано с относительно небольшим по длине фрагментом реализации (1201 точка). Большие по размеру фрагменты данных требуют заметно больших

вычислительных ресурсов и не рассматривались в работе. Кроме того, важно отметить, что для аугментации с применением GAN (timeGAN и *EWT-CGAN*) необходимо обучать нейронную сеть не для одной реализации, а для набора реализаций одной и той же длины. В работе использовалось 495 реализаций по 1201 точек каждая. Другими словами, рассмотрена реализация длиной 594 495 точек, фрагментированная на 495 реализаций.

Оценка вычислительных ресурсов и масштабируемость.

Адаптивное разложение сигнала на моды методом EWT зависит от длины сигнала. Для реализации из 1201 точки время обработки составляет порядка 0,1–0,5 секунды на CPU (Intel Core i7). Для 495 реализаций общее время декомпозиции не превышает 5 минут, что демонстрирует низкие требования к ресурсам на этапе декомпозиции.

Основная вычислительная нагрузка приходится на обучение генератора и дискриминатора. В сравнении с классическим timeGAN, *EWT-CGAN* требует на 15–20% больше времени из-за обработки нескольких мод. Однако ключевое преимущество – возможность обучения одной модели для всех мод (благодаря категориальным меткам), что сокращает общие затраты по сравнению с обучением отдельных GAN для каждой моды. На GPU (NVIDIA Tesla V100) обучение модели для 495 реализаций (1201 точка каждая) занимает ~1,5 часа (1000 эпох), что сопоставимо с timeGAN, но обеспечивает более высокое качество генерации.

Для крупных производственных систем с тысячами датчиков возможна распределенная обработка путем параллельной декомпозиции сигналов на узлах CPU и обучения *EWT-CGAN* на кластерах GPU.

5. Заключение. Разработан метод *EWT-CGAN* аугментации временных рядов, основанный на комбинированном использовании эмпирического вейвлет-преобразования сигналов и генеративной состязательной нейронной сети. Предложенный метод отличается от существующих своей адаптивностью и способностью учитывать в сигналах тренды, выбросы и переходные процессы, что позволяет синтезировать сложные сигналы, близкие к реальным эксплуатационным условиям, без необходимости проведения дорогостоящих экспериментов или разработки математической модели объекта с виртуальными испытаниями. Предложенный метод *EWT-CGAN* аугментации данных обеспечивает формирование релевантного обучающего набора для нейросетевых моделей, используемых для оценки технического состояния промышленного оборудования, с меньшим уровнем ошибок.

Метод апробирован на реальных данных, полученных с температурного датчика. Количественная оценка эффективности метода проводилась с использованием статистических метрик. Результаты показали, что сигналы, сгенерированные методом *EWT-CGAN*, статистически более близки к исходным данным. Все метрики, включая ключевую – расстояние Wasserstein, для метода *EWT-CGAN* оказались в среднем на 20% ниже. Коэффициент корреляции Пирсона для метода *EWT-CGAN* более чем на 50% выше, что подтверждает высокую степень сходства сгенерированных сигналов с исходными. Однако при анализе плотностей распределений амплитуд наблюдаются некоторые различия в форме распределения и, соответственно, в коэффициенте эксцесса, как для метода *EWT-CGAN*, так и для метода *timeGAN*. Вероятно, это связано с относительно короткими фрагментами реализаций, что обусловлено ограниченными вычислительными ресурсами.

Литература

1. Musa N., Gital A.Y., Aljojo N., et al. A systematic review and Meta-data analysis on the applications of Deep Learning in Electrocardiogram. *J. Ambient Intell. Humaniz. Comput.* 2023. vol. 14. no. 7. pp. 9677–9750. DOI: 10.1007/s12652-022-03868-z.
2. Zhang D., Ma M., Xia L. A comprehensive review on GANs for time-series signals. *Neural Comput. Appl.* 2022. vol. 34. no. 5. pp. 3551–3571. DOI: 10.1007/s00521-022-06888-0.
3. Brophy E., Wang Z., She Q., Ward T. Generative Adversarial Networks in Time Series: A Systematic Literature Review. *ACM Comput. Surv.* 2023. vol. 55. no. 10. DOI: 10.1145/3559540.
4. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets. *Adv. Neural Inf. Process. Syst.* 2014. vol. 27. pp. 2672–2680.
5. Radford A., Metz L., Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 4th Int. Conf. Learn. Represent. (ICLR 2016). 2016. pp. 1–16.
6. Karras T., Aila T., Laine S., Lehtinen J. Progressive growing of GANs for improved quality, stability, and variation. 6th Int. Conf. Learn. Represent. (ICLR 2018). 2018. pp. 1–26.
7. Mirza M., Osindero S. Conditional Generative Adversarial Nets. arXiv preprint arXiv:1411.1784. 2014. pp. 1–7.
8. Mao X., Li Q., Xie H., Lau R.Y.K., Wang Z., Smolley S.P. Least Squares Generative Adversarial Networks. *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*. 2017. vol. 2017. pp. 2813–2821. DOI: 10.1109/ICCV.2017.304.
9. Arjovsky M., Chintala S., Bottou L. Wasserstein GAN. *Proceedings of the 34 th International Conference on Machine Learning*. 2017. vol. 70. pp. 214–223.
10. Fabbri C. Conditional Wasserstein Generative Adversarial Networks. 2017.
11. Akcay S., Atapour-Abarghouei A., Breckon T.P. GANomaly: Semi-supervised Anomaly Detection via Adversarial Training. *Lect. Notes Comput. Sci.* 2019. vol. 11363. pp. 622–637. DOI: 10.1007/978-3-030-20893-6_39.
12. Zenati H., Foo C.-S., Lecouat B., Manek G., Chandrasekhar V.R. Efficient GAN-Based Anomaly Detection. 2018.

13. Maaten L. van der Hinton G. Visualizing Data using t-SNE. *Journal of Machine Learning Research*. 2008. vol. 9. pp. 2579–2605.
14. Bryant F.B., Yarnold P.R. Principal-components analysis and exploratory and confirmatory factor analysis. *Reading and understanding multivariate statistics*. Washington, DC, US: American Psychological Association, 1995. pp. 99–136.
15. Yoon J., Jarrett D., van der Schaar M. Time-series generative adversarial networks. *Adv. Neural Inf. Process. Syst.* 2019. vol. 32. pp. 1–11.
16. Salimans T., Goodfellow I., Zaremba W., Cheung V., Randford A., Chen X. Improved techniques for training GANs. *30th Conference on Neural Information Processing Systems (NIPS 2016)*. Barcelona, 2016.
17. Heusel M., Ramsauer H., Unterthiner T., Nessler B., Hochreiter S. GANs trained by a two time-scale update rule converge to a local Nash equilibrium. *Adv. Neural Inf. Process. Syst.* 2017. vol. 2017. pp. 6626–6637.
18. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image quality assessment: From error visibility to structural similarity. *IEEE Trans. Image Process.* 2004. vol. 13. no. 4. pp. 600–612. DOI: 10.1109/TIP.2003.819861.
19. Huang N.E., Shen Z., Long S.R., Wu M.C., Shih H.H., Zheng Q., Yen N.-C., Tung C.C., Liu H.H. The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. *Proc. R. Soc. A Math. Phys. Eng. Sci.* 1998. vol. 454. pp. 903–995. DOI: 10.1098/rspa.1998.0193.
20. Dragomiretskiy K., Zosso D. Variational Mode Decomposition. *IEEE Trans. Signal Process.* 2014. vol. 62. no. 3. pp. 531–544. DOI: 10.1109/TSP.2013.2288675.
21. Gilles J. Empirical wavelet transform. *IEEE Trans. Signal Process.* 2013. vol. 61. no. 16. pp. 3999–4010. DOI: 10.1109/TSP.2013.2265222.
22. Singh P., Joshi S.D., Patney R.K., Saha K. The Fourier decomposition method for nonlinear and non-stationary time series analysis. *Proc. R. Soc. A Math. Phys. Eng. Sci.* 2017. vol. 473. no. 2199. DOI: 10.1098/rspa.2016.0871.
23. Gilles J. Empirical Wavelet Transform. *IEEE Trans. Signal Process.* 2013. vol. 61. no. 16. pp. 3999–4010. DOI: 10.1109/TSP.2013.2265222.

Ерпалов Алексей Викторович — канд. техн. наук, заместитель директора, центр виброиспытаний и мониторинга состояния конструкций, НИИ опытного машиностроения, ФГАУО ВО «ЮУрГУ (НИУ)». Область научных интересов: вибропрочность конструкций, применение нейросетевых технологий в задачах мониторинга технического состояния, аугментация данных средств измерений. Число научных публикаций — 42. erpalovav@susu.ru; проспект Ленина, 76, 454080, Челябинск, Россия; р.т.: +7(351)267-9900.

Синицин Владимир Владимирович — канд. техн. наук, заместитель заведующего, НИИ технической самодиагностики и самоконтроля приборов и систем, ФГАУО ВО «ЮУрГУ (НИУ)». Область научных интересов: техническая диагностика, прогнозирование остаточного ресурса промышленного оборудования, верификация математических моделей. Число научных публикаций — 33. sinitscinvv@susu.ru; проспект Ленина, 76, 454080, Челябинск, Россия; р.т.: +7(351)267-9900.

Шестаков Александр Леонидович — д-р техн. наук, профессор, председатель совета ректоров вузов урфо, заслуженный работник высшей школы, президент, ФГАУО ВО «ЮУрГУ (НИУ)». Область научных интересов: динамика измерений, самодиагностика средств измерений, самодиагностика промышленных систем. Число научных публикаций — 235. president@susu.ru; проспект Ленина, 76, 454080, Челябинск, Россия; р.т.: +7(351)267-9900.

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

A. ERPALOV, V. SINITSIN, A. SHESTAKOV
**EWT-CGAN DATA AUGMENTATION FOR MEASUREMENT
SYSTEMS**

Erpalov A., Sinitsin V., Shestakov A. **EWT-CGAN Data Augmentation for Measurement Systems.**

Abstract. The article presents a new data augmentation method for measurement systems, designed for industrial equipment condition monitoring tasks. The relevance of the study stems from the significant limitations of traditional synthetic data generation methods, which fail to adequately reproduce complex non-stationary signals with characteristic transient processes, trends, and seasonal variations observed in real industrial environments. The proposed method integrates two advanced techniques: empirical wavelet transform (EWT) and conditional generative adversarial networks (Conditional GAN). The method is implemented in three stages: (1) adaptive decomposition of raw signals into modes using EWT, (2) mode categorization with label assignment, and (3) synthetic data generation using Conditional GAN. A set of statistical metrics was used to comprehensively assess the quality of synthesized signals, including Wasserstein distance (WS), Pearson correlation coefficient (PCC), and root mean square error (RMSE). Experimental studies were conducted on real-world temperature sensor data obtained under non-stationary industrial equipment conditions. The results demonstrate a significant advantage of the proposed method over the traditional TimeGAN approach: a 17% reduction in Wasserstein distance, a 57% increase in Pearson correlation coefficient, and a 21% decrease in RMSE. These findings confirm the method's effectiveness in reproducing key characteristics of the original signals. The developed method enables the creation of synthetic datasets required for training modern neural network models in industrial equipment diagnostics. Its practical application significantly reduces the costs associated with experimental data collection while ensuring high-quality synthesized signals, as validated by statistical metrics.

Keywords: equipment diagnostics, sensor signals, data augmentation, synthetic data, empirical wavelet transform, generative adversarial networks.

References

1. Musa N., Gital A.Y., Aljojo N., et al. A systematic review and Meta-data analysis on the applications of Deep Learning in Electrocardiogram. *J. Ambient Intell. Humaniz. Comput.* 2023. vol. 14. no. 7. pp. 9677–9750. DOI: 10.1007/s12652-022-03868-z.
2. Zhang D., Ma M., Xia L. A comprehensive review on GANs for time-series signals. *Neural Comput. Appl.* 2022. vol. 34. no. 5. pp. 3551–3571. DOI: 10.1007/s00521-022-06888-0.
3. Brophy E., Wang Z., She Q., Ward T. Generative Adversarial Networks in Time Series: A Systematic Literature Review. *ACM Comput. Surv.* 2023. vol. 55. no. 10. DOI: 10.1145/3559540.
4. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets. *Adv. Neural Inf. Process. Syst.* 2014. vol. 27. pp. 2672–2680.
5. Radford A., Metz L., Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 4th Int. Conf. Learn. Represent. (ICLR 2016). 2016. pp. 1–16.

6. Karras T., Aila T., Laine S., Lehtinen J. Progressive growing of GANs for improved quality, stability, and variation. 6th Int. Conf. Learn. Represent. (ICLR 2018). 2018. pp. 1–26.
7. Mirza M., Osindero S. Conditional Generative Adversarial Nets. arXiv preprint arXiv:1411.1784. 2014. pp. 1–7.
8. Mao X., Li Q., Xie H., Lau R.Y.K., Wang Z., Smolley S.P. Least Squares Generative Adversarial Networks. Proc. IEEE Int. Conf. Comput. Vis. (ICCV). 2017. vol. 2017. pp. 2813–2821. DOI: 10.1109/ICCV.2017.304.
9. Arjovsky M., Chintala S., Bottou L. Wasserstein GAN. Proceedings of the 34 th International Conference on Machine Learning. 2017. vol. 70. pp. 214–223.
10. Fabbri C. Conditional Wasserstein Generative Adversarial Networks. 2017.
11. Akcay S., Atapour-Abarghouei A., Breckon T.P. GANomaly: Semi-supervised Anomaly Detection via Adversarial Training. Lect. Notes Comput. Sci. 2019. vol. 11363. pp. 622–637. DOI: 10.1007/978-3-030-20893-6_39.
12. Zenati H., Foo C.-S., Lecouat B., Manek G., Chandrasekhar V.R. Efficient GAN-Based Anomaly Detection. 2018.
13. Maaten L. van der Hinton G. Visualizing Data using t-SNE. Journal of Machine Learning Research. 2008. vol. 9. pp. 2579–2605.
14. Bryant F.B., Yarnold P.R. Principal-components analysis and exploratory and confirmatory factor analysis. Reading and understanding multivariate statistics. Washington, DC, US: American Psychological Association, 1995. pp. 99–136.
15. Yoon J., Jarrett D., van der Schaar M. Time-series generative adversarial networks. Adv. Neural Inf. Process. Syst. 2019. vol. 32. pp. 1–11.
16. Salimans T., Goodfellow I., Zaremba W., Cheung V., Randford A., Chen X. Improved techniques for training GANs. 30th Conference on Neural Information Processing Systems (NIPS 2016). Barcelona, 2016.
17. Heusel M., Ramsauer H., Unterthiner T., Nessler B., Hochreiter S. GANs trained by a two time-scale update rule converge to a local Nash equilibrium. Adv. Neural Inf. Process. Syst. 2017. vol. 2017. pp. 6626–6637.
18. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image quality assessment: From error visibility to structural similarity. IEEE Trans. Image Process. 2004. vol. 13. no. 4. pp. 600–612. DOI: 10.1109/TIP.2003.819861.
19. Huang N.E., Shen Z., Long S.R., Wu M.C., Shih H.H., Zheng Q., Yen N.-C., Tung C.C., Liu H.H. The empirical mode decomposition and the Hubert spectrum for nonlinear and non-stationary time series analysis. Proc. R. Soc. A Math. Phys. Eng. Sci. 1998. vol. 454. pp. 903–995. DOI: 10.1098/rspa.1998.0193.
20. Dragomiretskiy K., Zosso D. Variational Mode Decomposition. IEEE Trans. Signal Process. 2014. vol. 62. no. 3. pp. 531–544. DOI: 10.1109/TSP.2013.2288675.
21. Gilles J. Empirical wavelet transform. IEEE Trans. Signal Process. 2013. vol. 61. no. 16. pp. 3999–4010. DOI: 10.1109/TSP.2013.2265222.
22. Singh P., Joshi S.D., Patney R.K., Saha K. The Fourier decomposition method for nonlinear and non-stationary time series analysis. Proc. R. Soc. A Math. Phys. Eng. Sci. 2017. vol. 473. no. 2199. DOI: 10.1098/rspa.2016.0871.
23. Gilles J. Empirical Wavelet Transform. IEEE Trans. Signal Process. 2013. vol. 61. no. 16. pp. 3999–4010. DOI: 10.1109/TSP.2013.2265222.

Erpalov Aleksey — Ph.D., Deputy director, Center for vibration testing and structural condition monitoring, research institute of experimental mechanical engineering, South Ural State University (National Research University). Research interests: structural vibration resistance, application of neural network technologies in technical condition monitoring tasks, measurement data augmentation. The number of publications — 42. erpalovav@susu.ru; 76, Lenin Ave., 454080, Chelyabinsk, Russia; office phone: +7(351)267-9900.

Sinitstin Vladimir — Ph.D., Deputy head, Research laboratory of technical self-diagnostics and self-monitoring of instruments and systems, South Ural State University (National Research University). Research interests: technical diagnostics, residual life prediction of industrial equipment, verification of mathematical models. The number of publications — 33. sinitstinvv@susu.ru; 76, Lenin Ave., 454080, Chelyabinsk, Russia; office phone: +7(351)267-9900.

Shestakov Aleksander — Ph.D., Dr.Sci., Professor, Chairman of the council of rectors of universities of the ural federal district, honored worker of higher education, President, South Ural State University (National Research University). Research interests: measurement dynamics, self-diagnostics of measuring instruments, self-diagnostics of industrial systems. The number of publications — 235. president@susu.ru; 76, Lenin Ave., 454080, Chelyabinsk, Russia; office phone: +7(351)267-9900.

Acknowledgements. This work was financially supported by Ministry of Science and Higher Education of the Russian Federation (FENU-2023-0010).