

УДК 681.5:004

## АДАПТИВНЫЕ МЕТОДЫ ОБРАБОТКИ И ХРАНЕНИЯ ВРЕМЕННЫХ РЯДОВ В СИСТЕМАХ ПРОМЫШЛЕННОЙ АВТОМАТИЗАЦИИ

**Журавлева Марина Олеговна,**

студентка, Российский технологический университет Московский институт радиотехники, электроники и автоматики, г. Москва

### Аннотация

В статье рассматриваются методы обработки и хранения временных рядов в системах промышленной автоматизации с акцентом на адаптивные подходы. Актуальность темы связана с ростом объемов данных, формируемых датчиками, контроллерами, SCADA-системами и промышленными архивами. Показано, что традиционные методы фиксированной дискретизации, пороговой регистрации и статического сжатия не всегда учитывают изменение динамики технологического процесса и могут приводить к избыточному накоплению данных либо потере диагностически значимых характеристик сигналов. Проведена систематизация адаптивных методов, включая изменение частоты дискретизации, событийную регистрацию, сжатие с контролем ошибки, фильтрацию, очистку и многоуровневое хранение данных. Отдельное внимание уделено потоковой обработке, edge-архитектурам и распределению вычислений между уровнями Edge-Fog-Cloud. Рассмотрены методы обнаружения аномалий как механизм управления параметрами регистрации и архивирования временных рядов. Выполнено сравнение подходов по критериям коэффициента сжатия, точности восстановления, сохранности переходных процессов, устойчивости к шумам, вычислительной сложности и пригодности для работы в реальном времени. Определены ограничения практического применения, связанные с выбором параметров, ресурсами оборудования и требованиями к достоверности данных. Показано, что комбинированное применение адаптивных методов обеспечивает баланс между сокращением объема данных и сохранением их диагностической ценности.

**Ключевые слова:** временные ряды, промышленная автоматизация, адаптивная дискретизация, событийная регистрация, сжатие данных, фильтрация сигналов, потоковая обработка, edge-архитектура, обнаружение аномалий, предиктивная диагностика, системы хранения данных, SCADA

## ADAPTIVE METHODS FOR PROCESSING AND STORAGE OF TIME SERIES IN INDUSTRIAL AUTOMATION SYSTEMS

**Zhuravleva Marina Olegovna,**

Student, Russian Technological University – Moscow Institute of Radio Engineering, Electronics and Automation, Moscow

e-mail: marina\_030405@mail.ru

## ABSTRACT

The paper examines methods for processing and storing time series in industrial automation systems with a focus on adaptive approaches. The relevance of the study is обусловлена ростом объемов данных, формируемых датчиками, контроллерами, SCADA systems, and industrial historians. It is shown that traditional methods based on fixed sampling, threshold-based recording, and static compression do not adequately account for variations in process dynamics and may lead either to excessive data accumulation or to the loss of diagnostically significant signal characteristics. A systematization of adaptive methods is presented, including adaptive sampling, event-based recording, error-controlled compression, filtering, data cleaning, and multi-level storage strategies. Special attention is given to stream processing, edge architectures, and the distribution of computation across the Edge-Fog-Cloud hierarchy. Anomaly detection methods are considered as a mechanism for controlling data acquisition and storage parameters. A comparative analysis of the approaches is carried out based on compression ratio, reconstruction accuracy, preservation of transient processes, noise robustness, computational complexity, and suitability for real-time operation. Practical limitations related to parameter selection, hardware constraints, and data reliability requirements are identified. It is shown that the combined application of adaptive methods provides a balance between data reduction and the preservation of diagnostic information.

**Keywords:** time series, industrial automation, adaptive sampling, event-based recording, data compression, signal filtering, stream processing, edge architecture, anomaly detection, predictive maintenance, data storage, SCADA

Рост объемов данных в системах промышленной автоматизации связан с развитием распределенных систем управления, высокочастотных датчиков и промышленного интернета вещей. Временные ряды непрерывно фиксируют динамику технологических параметров: температуры, давления, вибрации, тока и скорости. Увеличение плотности измерений повышает нагрузку на системы передачи, хранения и обработки данных [1, 4].

Специфика этой нагрузки определяется не только количеством измерений, но и структурой самих сигналов. Промышленные временные ряды включают стационарные участки, переходные процессы, шумы измерения и аномальные отклонения, связанные с изменением режимов работы оборудования [3]. Такая неоднородность усложняет выделение информативных изменений и требует методов обработки, способных учитывать динамику процесса.

Традиционная регистрация данных в SCADA-системах и промышленных архивах основана на фиксированной дискретизации или пороговой записи. Фиксированная дискретизация формирует избыточные данные на стационарных участках, а пороговая запись снижает объем хранения, но зависит от выбора параметров и не учитывает изменение характеристик сигнала во времени [2].

Снижение объема данных частично обеспечивается методами сжатия временных рядов. Они используют аппроксимацию сигналов или избыточность измерений. Алгоритмы кусочно-линейной аппроксимации, включая Swinging Door, контролируют ошибку восстановления, но обычно применяют статические параметры и не адаптируются к динамике процесса [5].

Современные задачи анализа технологических данных – предиктивное обслуживание, обнаружение аномалий и оптимизация режимов – требуют сохранения

информативных характеристик сигналов при ограниченных ресурсах хранения. Это определяет необходимость адаптивных методов, изменяющих параметры обработки и архивирования в зависимости от текущего состояния процесса [6].

Адаптивная обработка временных рядов включает изменение частоты дискретизации, порогов событийной регистрации, параметров фильтрации, сжатия и хранения. Такой подход согласует структуру данных с динамикой технологического процесса, снижает объем архива и сохраняет диагностически значимую информацию [7].

Временные ряды выступают основным представлением технологической информации в автоматизированных системах управления. Они фиксируют состояние процесса во времени и включают аналоговые сигналы датчиков, дискретные состояния оборудования, диагностические параметры и агрегированные показатели. Вибрация, токовые нагрузки и другие диагностические признаки используются для оценки технического состояния оборудования [3].

Формирование временных рядов происходит на уровне контроллеров и измерительных модулей с последующей передачей данных в системы хранения. На этом этапе выполняются фильтрация, масштабирование и синхронизация, влияющие на точность и структуру данных. Поэтому качество последующего анализа зависит не только от метода хранения, но и от предварительной обработки сигналов.

Промышленные сигналы содержат длительные стационарные участки и кратковременные переходные процессы. Такая структура создает неравномерное распределение информативности: в стабильных режимах данные часто избыточны, а при резких изменениях требуется высокая детализация [4]. Именно это противоречие определяет актуальность адаптивных методов обработки и хранения временных рядов.

Предиктивная диагностика требует сохранения экстремумов, скорости изменения и спектральных характеристик сигнала. Потеря этих признаков снижает точность анализа и затрудняет выявление ранних признаков неисправностей [6]. Рост числа датчиков и частоты измерений усиливает требования к обработке и хранению данных, что при ограниченных вычислительных ресурсах, пропускной способности каналов связи и объеме хранилищ требует перехода к адаптивным методам.

На базовом уровне обработка временных рядов включает методы дискретизации. Фиксированная дискретизация обеспечивает равномерную запись значений, но не учитывает динамику процесса и формирует избыточные данные [1]. Адаптивная дискретизация изменяет частоту опроса в зависимости от характеристик сигнала, включая скорость изменения и уровень колебаний [7].

Снижение объема данных также достигается за счет событийной регистрации, при которой временной ряд формируется по значимым изменениям сигнала. Запись выполняется при превышении порога отклонения или наступлении события. В промышленных системах такой подход реализуется через механизмы регистрации по исключению и уменьшает объем передаваемых и сохраняемых данных [6]. Адаптивные варианты дополнительно учитывают режим работы оборудования и текущую динамику сигнала.

Методы сжатия дополняют указанные подходы и уменьшают объем хранения данных. Алгоритмы без потерь используют кодирование разностей и повторяющихся значений, тогда как методы с потерями основаны на аппроксимации сигнала с заданной точностью. Кусочно-линейные алгоритмы обеспечивают контроль ошибки восстановления и широко применяются в промышленных системах хранения [5].

Качество данных определяется также этапами предварительной обработки. Фильтрация и очистка устраняют шумы, выбросы и пропуски, а адаптивные методы изменяют параметры сглаживания и восстановления с учетом структуры сигнала и режима

процесса [3]. Для длительного хранения применяется агрегирование, при котором временные ряды преобразуются в укрупненные интервалы с расчетом средних значений, экстремумов и дисперсий [4].

Реализация обработки в режиме реального времени достигается за счет потоковых методов, выполняемых на уровне контроллеров, промышленных шлюзов и edge-устройств. Это позволяет снизить нагрузку на центральные системы до записи данных в архив [5]. Дополнительно используются методы обнаружения аномалий, позволяющие выявлять отклонения и адаптивно изменять параметры дискретизации, регистрации и сжатия, обеспечивая более детальное сохранение информативных участков временного ряда [6].

Методы хранения временных рядов реализуются в специализированных базах данных и промышленных архивах. Индексирование по времени, компрессия и многоуровневое хранение позволяют сохранять актуальные данные с высокой детализацией, а архивные – в агрегированном виде [5]. Эффективность хранения напрямую зависит от способов формирования временного ряда, прежде всего от методов дискретизации.

Дискретизация определяет точность представления сигнала, объем данных и возможности последующего анализа. Фиксированная частота опроса обеспечивает равномерную запись, но не учитывает изменчивость процесса и приводит к избыточности на стационарных участках [1]. В противоположность этому адаптивная дискретизация изменяет частоту регистрации по текущим характеристикам сигнала, повышая плотность данных в динамических режимах и снижая ее в стационарных [7].

Критерии адаптации основаны на анализе свойств сигнала. Наиболее распространенным является скорость изменения: при росте производной частота дискретизации увеличивается для точного воспроизведения переходных процессов. Дополнительно используется локальная дисперсия, отражающая уровень колебаний и нестабильность процесса: ее рост приводит к увеличению частоты регистрации, а снижение – к укрупнению временного шага [3].

Практическая реализация адаптивной дискретизации включает также пороговые методы, изменяющие частоту при превышении заданных границ сигнала. Они отличаются простотой, но требуют настройки параметров под конкретный процесс. Более сложные подходы учитывают режим работы оборудования – пуск, переходные процессы, номинальную эксплуатацию и аварийные состояния – и изменяют частоту регистрации на основе совокупности параметров.

Современные методы рассматривают адаптивную дискретизацию как задачу минимизации объема данных при ограничении ошибки представления сигнала. Для этого применяются модели оценки информативности измерений и методы машинного обучения [7]. При реализации таких алгоритмов требуется учитывать влияние шумов и кратковременных выбросов, поэтому используются гистерезис и предварительная фильтрация.

Адаптивная дискретизация позволяет перераспределить плотность временного ряда в соответствии с динамикой процесса и снизить объем данных без потери информации о переходных процессах [4]. Дополнительное сокращение объема достигается за счет перехода к событийной регистрации.

Событийная регистрация фиксирует только значимые изменения сигнала, формируя временной ряд по факту наступления условий, отражающих изменение состояния процесса. Это снижает объем данных при сохранении информативных характеристик [8]. Базовый вариант основан на пороге изменения: новая точка сохраняется при превышении разности между текущим и последним записанным значением заданного порога, который определяется требованиями к точности и чувствительности системы.

Расширением событийной регистрации является подход с отклонением от прогнозируемого значения. Используется модель сигнала, и запись выполняется при превышении допустимого расхождения между фактическим и ожидаемым значением, что позволяет учитывать динамику процесса. В промышленных архивах данный принцип реализуется через регистрацию по исключению (exception reporting), при которой данные передаются и сохраняются только при значимых изменениях, снижая нагрузку на каналы связи и системы хранения [4].

Дальнейшее развитие событийной регистрации связано с адаптацией порогов. Их значения изменяются в зависимости от состояния сигнала и режима работы оборудования: в стационарных режимах пороги увеличиваются, в переходных – уменьшаются. В качестве критериев используются производная, дисперсия и контекст процесса [7]. Для повышения устойчивости к шумам применяются гистерезисные схемы, вводящие отдельные пороги включения и отключения записи. Комбинированные схемы дополняют событийную регистрацию периодической записью, что позволяет сохранить временную структуру данных. При этом снижение объема данных достигается без существенной потери информативности, хотя чувствительность метода остается зависимой от выбора порогов [6].

Событийная регистрация обычно используется совместно с методами сжатия, которые обеспечивают дополнительное уменьшение объема данных. Методы без потерь используют кодирование разностей и повторяющихся значений, однако их эффективность снижается при наличии шумов [1]. Более высокий коэффициент сжатия обеспечивают методы с потерями, основанные на аппроксимации сигнала с контролем допустимой ошибки [5]. Наиболее распространенным является кусочно-линейное представление, реализуемое, в частности, алгоритмом Swinging Door, который сохраняет точки только при выходе сигнала за допустимые границы отклонения [4].

Развитие методов сжатия связано с внедрением адаптивных подходов. Параметры аппроксимации изменяются в зависимости от характеристик сигнала: в стационарных режимах допустимая ошибка увеличивается, в переходных – уменьшается. Критериями адаптации служат скорость изменения сигнала, локальная дисперсия и наличие значимых событий [7]. Дополнительно используется многомерное сжатие, учитывающее корреляции между параметрами и позволяющее снизить объем данных за счет совместного кодирования, что особенно эффективно при обработке большого числа взаимосвязанных сигналов [4].

При этом степень сжатия должна согласовываться с требованиями анализа. Избыточное упрощение приводит к потере кратковременных изменений и искажению характеристик процесса, что снижает эффективность диагностики и прогнозирования. Поэтому методы сжатия применяются совместно с процедурами предварительной обработки данных.

Фильтрация и очистка временных рядов направлены на повышение качества данных перед их хранением и анализом. Промышленные сигналы содержат шумы, выбросы и пропуски, которые снижают эффективность сжатия и точность диагностики [3]. Для подавления шумов используются скользящее среднее, медианный фильтр и экспоненциальное сглаживание. Однако чрезмерная фильтрация может исказить переходные процессы и экстремальные значения.

Адаптивная фильтрация позволяет устранить это ограничение за счет изменения параметров обработки в зависимости от состояния сигнала: в стационарных режимах сглаживание усиливается, а при переходных процессах ослабляется. Такой подход сохраняет форму сигнала и снижает влияние помех, обеспечивая согласование качества данных с задачами последующего анализа [6].

Обработка выбросов направлена на выявление значений, не соответствующих физической логике процесса или статистическим характеристикам сигнала. При этом критерии должны учитывать режим работы оборудования, поскольку резкие изменения могут отражать реальные переходные процессы. Восстановление пропусков применяется при потере данных из-за сбоев связи или отказов оборудования: короткие интервалы заполняются интерполяцией, более длительные – моделями прогнозирования или значениями, восстановленными по коррелированным сигналам. Такие данные должны маркироваться как реконструированные [4]. Дополнительно учитывается дрейф сигнала, связанный с изменением характеристик датчиков, температурным влиянием или нарушением калибровки, что требует анализа длительных интервалов и сопоставления с эталонными параметрами.

Очистка временных рядов должна сохранять редкие диагностически значимые события. Кратковременные отклонения могут быть ранними признаками неисправности, поэтому фильтрация должна подавлять помехи без искажения структуры сигнала. Это определяет требования к последующим этапам обработки, реализуемым в потоковом режиме.

Потоковая обработка выполняется непосредственно при поступлении данных и снижает задержки, объем передачи и нагрузку на центральные системы [4]. В рамках edge-архитектуры операции фильтрации, событийной регистрации, сжатия, агрегирования и первичного обнаружения аномалий переносятся ближе к источнику данных – на контроллеры, промышленные шлюзы и локальные серверы. Поточковые алгоритмы используют скользящие окна и инкрементальные статистики (средние значения, дисперсии, производные, экстремумы), что позволяет изменять параметры обработки без хранения полной истории сигнала.

Адаптивность потоковой обработки проявляется в динамическом изменении параметров: размера окна, порогов записи, коэффициентов сглаживания и допустимой ошибки сжатия. В стабильных режимах объем данных сокращается, а при переходных процессах и аномалиях повышается детализация [7]. Такая обработка реализуется в рамках распределенной архитектуры Edge-Fog-Cloud, где Edge выполняет первичную обработку с минимальной задержкой, Fog – локальную агрегацию и буферизацию, а Cloud – долговременное хранение и аналитическую обработку [4].

Распределение обработки напрямую связано с организацией хранения данных. Решение о степени детализации может приниматься до записи в архив, что снижает объем передаваемой информации и нагрузку на хранилище при сохранении диагностически значимых участков временного ряда.

Хранение временных рядов определяется требованиями к скорости записи, доступности данных и глубине архива. Многоуровневые модели позволяют сохранять актуальные данные с высокой детализацией, а устаревшие – в агрегированном или сжатом виде [4, 5]. Downsampling используется для уменьшения временного разрешения данных при длительном хранении: для укрупненных интервалов рассчитываются средние значения, минимумы, максимумы и дисперсии. При этом чрезмерное укрупнение может привести к потере кратковременных изменений и снижению информативности данных [1].

Retention policy задает правила хранения данных разной значимости: аварийные участки, переходные процессы и диагностические признаки сохраняются с большей детализацией и на более длительный срок, тогда как данные стационарных режимов могут агрегироваться или удаляться [6]. Такой подход дополняется адаптивным хранением, при котором параметры архивирования изменяются по характеристикам временного ряда. В стационарных режимах увеличивается степень сжатия и агрегации, а при переходных

процессах и аномалиях повышается частота записи и снижается допустимая ошибка сжатия [7].

Реализация этих подходов осуществляется в специализированных базах временных рядов, обеспечивающих индексирование по времени, компрессию, агрегацию и высокую скорость записи больших объемов данных [5]. При этом хранение должно учитывать требования к целостности и прослеживаемости: необходимо фиксировать параметры обработки, включая методы фильтрации, сжатия и агрегирования. Ограничением остается сложность настройки, поскольку некорректный выбор параметров может привести либо к потере диагностически значимой информации, либо к избыточному накоплению данных.

Ключевым механизмом адаптивного хранения является обнаружение аномалий. Аномальные участки отражают нарушение устойчивости процесса, смену режима или развитие неисправности и требуют более детального сохранения [6]. Для их выявления используются статистические методы, основанные на порогах, контрольных картах, z-оценках и анализе локальной дисперсии, которые обладают низкой вычислительной сложностью и пригодны для работы в реальном времени [3].

Для более сложных зависимостей применяются методы машинного обучения, включая кластеризацию, Isolation Forest, One-Class SVM и метод главных компонент, формирующие модель нормального состояния системы [6]. Глубокие модели, такие как автоэнкодеры и рекуррентные нейронные сети, позволяют выявлять скрытые паттерны, однако требуют значительных вычислительных ресурсов и обучающих данных.

Результаты обнаружения аномалий используются для управления параметрами обработки и хранения. При выявлении отклонений система может увеличить частоту дискретизации, снизить пороги записи и уменьшить допустимую ошибку сжатия, обеспечивая более детальное сохранение данных. В нормальном режиме допускается более высокая степень сжатия и агрегации [7]. Ограничения таких подходов связаны с задержкой обнаружения, ложными срабатываниями и пропуском аномалий, что требует применения буферизации и гибридных методов анализа.

Эффективность применяемых решений оценивается по совокупности критериев: коэффициенту сжатия, точности восстановления, сохранности переходных процессов, вычислительной сложности и пригодности для работы в реальном времени [5]. Фиксированная дискретизация обеспечивает полное представление сигнала, но приводит к избыточности данных [1]. Событийная регистрация снижает объем данных, однако ее эффективность зависит от выбора порогов [8]. Кусочно-линейное сжатие, включая алгоритм Swinging Door, обеспечивает контролируемую точность представления сигнала, но может приводить к потере кратковременных пиков и высокочастотных компонентов [5].

Адаптивные методы дискретизации, событийной регистрации и сжатия изменяют параметры обработки в зависимости от динамики сигнала. Это позволяет сохранять информативные участки временного ряда при снижении общего объема данных, однако требует корректной настройки критериев адаптации [7]. Дополнительное влияние на качество данных оказывают методы предварительной обработки: фильтрация и очистка повышают точность последующего анализа, но при некорректной настройке могут приводить к потере значимых изменений [3].

Для длительного хранения применяются агрегирование и *downsampling*, позволяющие существенно сократить объем архива. Однако такие методы приводят к потере детальной структуры сигнала и ограничивают возможности анализа кратковременных событий [4]. В свою очередь, потоковая обработка и *edge*-архитектуры позволяют снизить объем передаваемых данных и перераспределить вычислительную нагрузку, выполняя обработку ближе к источнику. Их применение ограничено ресурсами устройств и требованиями к задержкам [4].

Дополнительную адаптацию обеспечивает обнаружение аномалий, позволяющее выделять информативные участки временного ряда и изменять стратегию архивирования. Ограничения таких методов связаны с ложными срабатываниями и зависимостью от качества модели [6]. В результате наибольшая эффективность достигается при комбинированном использовании адаптивной дискретизации, событийной регистрации, сжатия и анализа аномалий, что обеспечивает баланс между сокращением объема данных и сохранением информативности.

Оценка эффективности таких решений должна учитывать не только степень сжатия, но и сохранение технологически значимых характеристик сигнала [5]. Коэффициент сжатия отражает отношение исходного объема данных к объему после обработки, однако не может использоваться изолированно, поскольку высокая степень сжатия может сопровождаться потерей диагностических признаков [1]. Существенным показателем является также ошибка восстановления, оцениваемая по средним и максимальным отклонениям, особенно важным при анализе критических пиков [5].

Ключевым критерием остается сохранность переходных процессов, включая резкие изменения, фронты сигналов и локальные экстремумы. Их потеря снижает ценность данных для диагностики и анализа динамики объекта. Для вибрационных и диагностических сигналов дополнительно требуется сохранение спектральных характеристик, поскольку фильтрация, сжатие и агрегация не должны искажать частотные компоненты, используемые для выявления дефектов оборудования.

При практической реализации учитываются вычислительные ограничения. Задержка обработки определяет пригодность метода для систем реального времени, поэтому ресурсоемкие алгоритмы применяются на верхних уровнях архитектуры, а на контроллерах и edge-устройствах используются методы с низкой вычислительной сложностью [4]. Требования к процессорному времени и памяти определяют выбор алгоритмов, особенно при обработке большого числа каналов.

Устойчивость к шумам влияет на стабильность работы алгоритмов: низкая устойчивость приводит к избыточной записи данных и снижению эффективности сжатия [3]. Важным фактором является также интерпретируемость методов, поскольку пороговые и статистические подходы проще внедряются и настраиваются в промышленной среде, тогда как модели машинного обучения требуют дополнительной валидации и объяснения результатов [6].

Комплексная оценка адаптивных методов должна учитывать степень сжатия, сохранение информативности, вычислительные затраты и возможность работы в реальном времени. Однако практическое применение таких методов связано с рядом ограничений, прежде всего с выбором параметров адаптации: порогов событийной регистрации, допустимой ошибки сжатия, параметров фильтрации и критериев изменения частоты дискретизации. Эти параметры зависят от характеристик оборудования и условий эксплуатации, что затрудняет их универсальное определение [7].

Дополнительную сложность создает изменчивость режимов работы. Методы, эффективные в стационарном состоянии, могут работать некорректно при пуске, останове и переходных процессах, что требует динамической перенастройки алгоритмов. На устойчивость обработки также влияют шумы измерения и погрешности датчиков: при отсутствии фильтрации и гистерезиса возможны частые изменения параметров, рост нагрузки и снижение эффективности методов [3].

Существенным ограничением остается риск потери диагностически значимой информации. Малые отклонения сигнала могут быть ранними признаками неисправности, однако при агрессивном сжатии или завышенных порогах они исключаются из временного ряда, что снижает эффективность предиктивной диагностики [6]. Интеграция адаптивных

методов в существующие системы также затруднена, поскольку многие промышленные решения используют фиксированные алгоритмы архивирования и не поддерживают динамическое изменение параметров.

Ограничения накладываются и на вычислительном уровне. Ресурсы контроллеров и edge-устройств ограничивают применение сложных алгоритмов, включая модели машинного обучения, что требует упрощенных подходов или распределения вычислений между уровнями системы [4]. Сравнение методов дополнительно осложняется отсутствием единых критериев оценки и дефицитом открытых промышленных данных, поскольку реальные данные часто недоступны из-за требований безопасности и конфиденциальности.

В ряде отраслей применение методов с потерями ограничено требованиями к достоверности и воспроизводимости данных: исходные измерения должны сохраняться без искажений, что снижает эффективность сжатия [5]. В этих условиях особое значение приобретает корректный выбор методов и параметров обработки.

Несмотря на указанные ограничения, адаптивные методы позволяют согласовать структуру данных с динамикой технологического процесса. Адаптивная дискретизация перераспределяет плотность измерений во времени и повышает детализацию переходных процессов, событийная регистрация и сжатие сокращают объем данных при сохранении формы сигнала, а фильтрация и очистка обеспечивают устойчивость обработки к шумам.

Потоковая обработка и edge-архитектуры переносят вычисления ближе к источнику данных, снижая нагрузку на центральные системы. Адаптивное хранение обеспечивает дифференцированный подход к архивированию, при котором стационарные участки сохраняются в агрегированном виде, а переходные процессы и аномалии – с высокой детализацией. Методы обнаружения аномалий усиливают этот подход, автоматически выделяя участки с повышенной диагностической значимостью.

Наибольшая эффективность достигается при комбинированном применении адаптивной дискретизации, событийной регистрации, сжатия, фильтрации и анализа аномалий. Такая интеграция обеспечивает баланс между сокращением объема данных и сохранением их диагностической ценности и рассматривается как ключевое направление развития систем промышленной автоматизации.

Дальнейшее развитие данного направления связано с автоматизацией выбора параметров адаптации, использованием многомерного анализа временных рядов и интеграцией методов хранения с системами предиктивной диагностики. Эти решения позволяют повысить эффективность обработки промышленных данных и обеспечить более рациональное использование ресурсов в системах автоматизации.

#### **Список литературы:**

1. Chiarot, G. Time Series Compression Survey / G. Chiarot, C. Silvestri // ACM Computing Surveys. 2023. Vol. 55, No. 10. Article 198. DOI 10.1145/3560814.
2. Costa, H. J. D. An Evolving Multivariate Time Series Compression Algorithm for IoT Applications / H. J. D. Costa, M. Silva, I. Sánchez-Gendriz, C. M. D. Viegas, I. Silva // Sensors. 2024. Vol. 24, No. 22. Article 7273. DOI 10.3390/s24227273.
3. Hu, C. Survey of Time Series Data Generation in IoT / C. Hu, Z. Sun, C. Li, Y. Zhang, C. Xing // Sensors. 2023. Vol. 23, No. 15. Article 6976. DOI 10.3390/s23156976.
4. Kumar, R. Analysis of multi-dimensional Industrial IoT (IIoT) data in Edge-Fog-Cloud based architectural frameworks: a survey on current state and research challenges / R. Kumar, N. Agrawal // Journal of Industrial Information Integration. 2023. Vol. 35. Article 100504. DOI 10.1016/j.jii.2023.100504.

5. Tang, Y. Improving Time Series Data Compression in Apache IoTDB / Y. Tang, Y. Zhang, C. Wang, J. Li, J. Chen, J. Wang, G. Huang // Proceedings of the VLDB Endowment. 2025. Vol. 18, No. 10. Pp. 3406–3418. DOI 10.14778/3748191.3748204.
6. Wang, C. Apache IoTDB: Time-series Database for Internet of Things / C. Wang, J. Qiao, X. Huang, S. Song, H. Hou, T. Jiang, J. Rui, J. Sun // Proceedings of the VLDB Endowment. 2020. Vol. 13, No. 12. Pp. 2901–2904. DOI 10.14778/3415478.3415504.
7. Zamanzadeh Darban, Z. Deep Learning for Time Series Anomaly Detection: A Survey / Z. Zamanzadeh Darban, G. I. Webb, S. Pan, C. C. Aggarwal, M. Salehi // ACM Computing Surveys. 2024. Vol. 57, No. 1. Article 15. DOI 10.1145/3691338.
8. Zhou, Z. Adaptive Error Bounded Piecewise Linear Approximation for Time Series / Z. Zhou, Y. Liu, L. Li // Engineering Applications of Artificial Intelligence. 2023. Vol. 126. Article 106892. DOI 10.1016/j.engappai.2023.106892.

**References:**

1. Chiarot, G. Time Series Compression Survey / G. Chiarot, C. Silvestri // ACM Computing Surveys. 2023. Vol. 55, No. 10. Article 198. DOI 10.1145/3560814.
2. Costa, H. J. D. An Evolving Multivariate Time Series Compression Algorithm for IoT Applications / H. J. D. Costa, M. Silva, I. Sánchez-Gendriz, C. M. D. Viegas, I. Silva // Sensors. 2024. Vol. 24, No. 22. Article 7273. DOI 10.3390/s24227273.
3. Hu, C. Survey of Time Series Data Generation in IoT / C. Hu, Z. Sun, C. Li, Y. Zhang, C. Xing // Sensors. 2023. Vol. 23, No. 15. Article 6976. DOI 10.3390/s23156976.
4. Kumar, R. Analysis of multi-dimensional Industrial IoT (IIoT) data in Edge-Fog-Cloud based architectural frameworks: a survey on current state and research challenges / R. Kumar, N. Agrawal // Journal of Industrial Information Integration. 2023. Vol. 35. Article 100504. DOI 10.1016/j.jii.2023.100504.
5. Tang, Y. Improving Time Series Data Compression in Apache IoTDB / Y. Tang, Y. Zhang, C. Wang, J. Li, J. Chen, J. Wang, G. Huang // Proceedings of the VLDB Endowment. 2025. Vol. 18, No. 10. Pp. 3406–3418. DOI 10.14778/3748191.3748204.
6. Wang, C. Apache IoTDB: Time-series Database for Internet of Things / C. Wang, J. Qiao, X. Huang, S. Song, H. Hou, T. Jiang, J. Rui, J. Sun // Proceedings of the VLDB Endowment. 2020. Vol. 13, No. 12. Pp. 2901–2904. DOI 10.14778/3415478.3415504.
7. Zamanzadeh Darban, Z. Deep Learning for Time Series Anomaly Detection: A Survey / Z. Zamanzadeh Darban, G. I. Webb, S. Pan, C. C. Aggarwal, M. Salehi // ACM Computing Surveys. 2024. Vol. 57, No. 1. Article 15. DOI 10.1145/3691338.
8. Zhou, Z. Adaptive Error Bounded Piecewise Linear Approximation for Time Series / Z. Zhou, Y. Liu, L. Li // Engineering Applications of Artificial Intelligence. 2023. Vol. 126. Article 106892. DOI 10.1016/j.engappai.2023.106892.