

# Евразийский Союз Ученых. Серия: технические и физико-математические науки

Ежемесячный научный журнал  
№ 07 (122)/2024 Том 1

## ГЛАВНЫЙ РЕДАКТОР

**Макаровский Денис Анатольевич**

AuthorID: 559173

Заведующий кафедрой организационного управления Института прикладного анализа поведения и психолого-социальных технологий, практикующий психолог, специалист в сфере управления образованием.

## РЕДАКЦИОННАЯ КОЛЛЕГИЯ

•**Штерензон Вера Анатольевна**

AuthorID: 660374

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт новых материалов и технологий (Екатеринбург), кандидат технических наук

•**Синьковский Антон Владимирович**

AuthorID: 806157

Московский государственный технологический университет "Станкин", кафедра информационной безопасности (Москва), кандидат технических наук

•**Штерензон Владимир Александрович**

AuthorID: 762704

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт фундаментального образования, Кафедра теоретической механики (Екатеринбург), кандидат технических наук

•**Зыков Сергей Арленович**

AuthorID: 9574

Институт физики металлов им. М.Н. Михеева УрО РАН, Отдел теоретической и математической физики, Лаборатория теории нелинейных явлений (Екатеринбург), кандидат физ-мат. наук

•**Дронсейко Виталий Витальевич**

AuthorID: 1051220

Московский автомобильно-дорожный государственный технический университет (МАДИ), Кафедра "Организация и безопасность движения" (Москва), кандидат технических наук

Статьи, поступающие в редакцию, рецензируются. За достоверность сведений, изложенных в статьях, ответственность несут авторы. Мнение редакции может не совпадать с мнением авторов материалов. При перепечатке ссылка на журнал обязательна. Материалы публикуются в авторской редакции.

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций.

Художник: Валегин Арсений Петрович  
Верстка: Курпатова Ирина Александровна

Адрес редакции:  
198320, Санкт-Петербург, Город Красное Село, ул. Геологическая, д. 44, к. 1, литера А  
E-mail: [info@euroasia-science.ru](mailto:info@euroasia-science.ru) ;  
[www.euroasia-science.ru](http://www.euroasia-science.ru)

Учредитель и издатель ООО «Логика+»  
Тираж 1000 экз.

# СОДЕРЖАНИЕ

## МАТЕМАТИКА И МЕХАНИКА

*Губайдуллин К.А.*

РОЛЬ АВТОМАТИЗАЦИИ В ПОВЫШЕНИИ  
ЭНЕРГОЭФФЕКТИВНОСТИ НЕФТЕГАЗОВОГО  
СЕКТОРА .....3

## КОМПЬЮТЕРНЫЕ НАУКИ И ИНФОРМАТИКА

*Журавлев В.В.*

АЛГОРИТМЫ ВЫЯВЛЕНИЯ АНОМАЛИЙ В  
РЕАЛЬНОМ ВРЕМЕНИ С ИСПОЛЬЗОВАНИЕМ  
МАШИННОГО ОБУЧЕНИЯ.....10

## ФИЗИЧЕСКИЕ НАУКИ

*Мирзаев В.Т., Юлдашев Н.Х., Маматов О.М.*

РОЛЬ МЕЖГРАНУЛЬНЫХ БАРЬЕРОВ В  
ФОТОЧУВСТВИТЕЛЬНОСТИ  
ПОЛИКРИСТАЛЛИЧЕСКИХ ПЛЕНОК ИЗ ТВЕРДОГО  
РАСТВОРА  $CdSe_xS_{1-x}$  .....18

## ТЕХНИЧЕСКИЕ НАУКИ

*Дюкарев В.В., Старухин Я.А.*

ОПТИМИЗАЦИЯ АЛГОРИТМОВ МАШИННОГО  
ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ  
РЯДОВ .....24

*Войстроченко Д.И.*

ИНТЕГРАЦИЯ РОБОТИЗИРОВАННЫХ СИСТЕМ В  
ПРОИЗВОДСТВЕННЫЕ ПРОЦЕССЫ .....32

# МАТЕМАТИКА И МЕХАНИКА

УДК: 622.692.4 - Автоматизация и управление в нефтегазовой промышленности  
Шифр специальности: 2.4.3 - Технические науки, специализация "Электроэнергетика"

## РОЛЬ АВТОМАТИЗАЦИИ В ПОВЫШЕНИИ ЭНЕРГОЭФФЕКТИВНОСТИ НЕФТЕГАЗОВОГО СЕКТОРА

*Губайдуллин Калмен Алмазович*  
Консультант в области управленческого консалтинга  
Студент, Университет Шеффилда  
Хьюстон, США

## THE ROLE OF AUTOMATION IN IMPROVING THE ENERGY EFFICIENCY OF THE OIL AND GAS SECTOR

*Kalmen Gubaidullin*  
Consultant in the field of management consulting  
Student, The University of Sheffield  
Houston, USA

DOI: 10.31618/ESU.2413-9335.2024.1.122.2072

### АННОТАЦИЯ

Автоматизация играет ключевую роль в повышении энергоэффективности в нефтегазовом секторе, способствуя оптимизации производственных процессов и снижению энергозатрат. Внедрение автоматизированных систем управления позволяет значительно сократить простой оборудования, повысить безопасность эксплуатации и уменьшить издержки, связанные с человеческим фактором. Современные технологии, такие как искусственный интеллект, машинное обучение и интернет вещей, обеспечивают эффективное управление ресурсами, что особенно важно в условиях разработки трудноизвлекаемых месторождений и эксплуатации в отдаленных регионах. Автоматизация также способствует улучшению экологической устойчивости предприятий за счет снижения выбросов и утечек, а использование передовых систем мониторинга и управления помогает оперативно реагировать на изменения в технологических процессах. Таким образом, автоматизация является важным инструментом для повышения конкурентоспособности нефтегазовых компаний в условиях цифровой трансформации и глобальных изменений в отрасли.

### ABSTRACT

Automation plays a key role in improving energy efficiency in the oil and gas sector, helping to optimize production processes and reduce energy costs. The introduction of automated control systems can significantly reduce equipment downtime, improve operational safety and reduce costs associated with the human factor. Modern technologies such as artificial intelligence, machine learning and the Internet of Things ensure effective resource management, which is especially important in the context of the development of hard-to-recover deposits and exploitation in remote regions. Automation also helps to improve the environmental sustainability of enterprises by reducing emissions and leaks, and the use of advanced monitoring and management systems helps to respond quickly to changes in technological processes. Thus, automation is an important tool for increasing the competitiveness of oil and gas companies in the context of digital transformation and global changes in the industry.

**Ключевые слова:** автоматизация, энергоэффективность, нефтегазовая отрасль, цифровая трансформация, искусственный интеллект, интернет вещей, экологическая устойчивость, производственные процессы, труднодоступные месторождения.

**Keywords:** automation, energy efficiency, oil and gas industry, digital transformation, artificial intelligence, Internet of Things, environmental sustainability, production processes, hard-to-reach deposits.

### Введение

Современная нефтегазовая отрасль сталкивается с множеством вызовов, среди которых на первый план выходят вопросы энергоэффективности и устойчивого развития. Сокращение легкодоступных углеводородных ресурсов, повышение требований к экологической безопасности и усложнение условий добычи требуют от компаний поиска новых подходов к организации производственных процессов. В условиях цифровой трансформации экономики

автоматизация технологических и бизнес-процессов приобретает особую значимость, выступая ключевым фактором, способствующим снижению энергозатрат и повышению общей эффективности предприятий.

Актуальность темы обусловлена стремлением нефтегазовых компаний к снижению операционных затрат и улучшению экологической устойчивости своей деятельности. Внедрение автоматизированных систем управления и контроля, поддерживаемых современными

цифровыми технологиями, позволяет не только оптимизировать использование ресурсов, но и минимизировать влияние человеческого фактора, что особенно важно в условиях разработки трудноизвлекаемых месторождений и работы на удаленных и экстремальных территориях. Автоматизация открывает новые возможности для повышения конкурентоспособности нефтегазовых компаний на международной арене, обеспечивая им гибкость и адаптивность в меняющихся экономических и технологических условиях.

Целью работы является анализ роли автоматизации в повышении энергоэффективности нефтегазового сектора.

### **1. Технологии автоматизации в нефтегазовом секторе**

В условиях перехода к цифровизации, бизнес-процессы в нефтегазовой отрасли подвергаются значительным изменениям. Если ранее они характеризовались как линейный процесс, включающий этапы «вход-обработка-выход», то в условиях цифровой трансформации акценты смещаются. Первоначальный этап становится критически важным, так как на этом этапе закладываются основы для успешного взаимодействия и дальнейшего развития отрасли [1].

Автоматизация технологических процессов в нефтегазовом секторе представляет собой комплекс мероприятий, направленных на модернизацию и усовершенствование инфраструктуры предприятия. Это осуществляется посредством снижения необходимости прямого участия персонала в производственных операциях. В зависимости от особенностей предприятия, автоматизация может охватывать как общие системы жизнеобеспечения (например, системы электроснабжения, сигнализации и пожаротушения), так и специализированные производственные объекты, включая буровые установки и системы регулировки давления.

Основной целью автоматизации производственных процессов является сокращение затрат и повышение эффективности работы. Для достижения этой цели требуется не только оборудование, но и программные средства, способные интегрировать данные с различных датчиков, анализировать их и предоставлять пользователям в удобной форме.

Однако автоматизация не ограничивается только производственными процессами. Для успешного функционирования крупных нефтегазовых предприятий необходимо также автоматизировать бизнес-процессы. Что позволит улучшить управление задачами, облегчит контроль их выполнения и повысит мотивацию сотрудников. Кроме того, автоматизация бизнес-процессов поможет выявить проблемные участки в работе и минимизировать простои, связанные с человеческим фактором.

Однако традиционные системы автоматизации, такие как ERP и BPM, нередко сталкиваются с рядом проблем. Они требуют

значительных финансовых вложений как на этапе внедрения, так и в процессе эксплуатации. Также возникает необходимость в создании дополнительного штата IT-специалистов, что усложняет организационную структуру. Внесение изменений в такие системы может занимать длительное время, что снижает их оперативность и гибкость.

Современным ответом на эти вызовы становятся low-code платформы, которые предлагают альтернативные подходы к автоматизации. Такие решения, как Comindware Business Application Platform, позволяют бизнес-аналитикам самостоятельно вносить изменения в бизнес-логику без участия программистов, интегрируются с существующими системами и значительно снижают зависимость компании от IT-отдела. Это даёт компании большую свободу в управлении бизнес-процессами и повышает удобство работы сотрудников с системой, что, в конечном итоге, способствует повышению общей эффективности предприятия.

Проектирование и внедрение таких систем часто подразумевает модернизацию нескольких ключевых направлений деятельности предприятия. Помимо производственных процессов, автоматизация может охватывать и управленческие элементы, включая контрольные системы и каналы сбыта продукции.

Повышение уровня автоматизации на предприятии обеспечивает улучшение управляемости, гибкость и адаптивность процессов, а также упрощение процедур отчетности и анализа данных. Кроме того, оптимизируются технологические затраты, снижаются потери сырья, что приводит к повышению рентабельности и конкурентоспособности предприятия на рынке.

Персоналу, работающему в нефтегазовой отрасли, больше не требуется постоянно находиться непосредственно на производственном объекте, так как контроль за оборудованием осуществляется удаленно через автоматизированные рабочие места. Это не только повышает уровень безопасности труда, но и способствует снижению аварийности и уменьшению числа несчастных случаев на производстве. Одновременно с этим увеличивается объем добычи, а потери сырья минимизируются.

Преимущества автоматизации производства включают:

- Повышение уровня безопасности и экологичности производства;
- Отсутствие простоев оборудования;
- Снижение потерь сырья и минимизация отходов;
- Дистанционное управление и контроль за производственными процессами;
- Высокая оперативность в сборе и анализе данных;
- Увеличение производительности и улучшение качества конечного продукта [2].

По данным компании Technavio, рынок цифровой трансформации в нефтегазовой отрасли будет расти в среднем на 16,56% в год с 2022 по 2027 год, и его объём к 2027 году достигнет 58,66 млрд долларов. С началом внедрения цифровых технологий нефтегазовая отрасль активно расширяет свой цифровой портфель, делая значительные шаги вперёд. Применение

искусственного интеллекта, машинного обучения, анализа данных, облачных вычислений и роботизированной автоматизации способствует успешной цифровой трансформации в этом секторе. Ниже в таблице 1 будут представлены направления, в которых возможно применение цифровизации.

Таблица 1.

**Направления для применения цифровизации [3].**

Table 1.

**Directions for the application of digitalization [3].**

Название направления	Описание
Удаленное обслуживание	Искусственный интеллект, машинное обучение, аналитика данных, облачные вычисления и интернет вещей (IoT)* снижает необходимость обслуживания
Сейсмическая визуализация	Обработка 3D изображений с помощью ИИ ускоряет данный процесс в 10-100 раз
Прецизионное бурение	Использование машинного обучения и ИИ для управления своим буровым оборудованием
Снижение коррозии на НПЗ	Мониторинг всего НПЗ в режиме реального времени с помощью датчиков с помощью интернета вещей (IoT)
Оптимизация спроса и предложения	Использование блокчейна для безопасных транзакций и облачных вычислений для централизации данных ведет к росту бизнеса.
Управление автопарком	Мониторинга оборудования в режиме реального времени позволяет повысить производительность всей производственной цепочки
Оптимизация логистического маршрута	ИИ и интернет вещей могут сократить расходы на услуги транспортных средств доставки на 20% и затраты на материалы на 2%
Роботизированное бурение	Расширенная аналитика может повысить производительность бурения (сокращение затрат до 20%)
Полевая безопасность	Дополнительная и виртуальная реальность оперативно передает необходимую информацию в режиме реального времени, тем самым повышая безопасность
Оптимизация производительности поля	Цифровые двойники сокращают время поиска информации на 30%, обмена данными на 70% и повышает эффективность согласования документов на 25% и интернет вещей (IoT)* сокращает потребление и выбросы на протяжении всего процесса
Диагностическое обслуживание	Технология профилактического обслуживания используется для незапланированных простоев, может сократить время простоя на 20%
Цифровое прототипирование	Оптимизация технологии конструкции, используя уменьшенную 3D модель
Мониторинг трубопровода	Мониторинг утечек с помощью интернета вещей (IoT)
Подключенные работники	Оснащение сотрудников личными цифровыми устройствами, помогающие в работе (увеличение продуктивности на 15%)
Моделирование выбросов	Интернет вещей (IoE) поможет обнаружить утечки, а с помощью AI/ML можно моделировать выбросы

Одним же из важнейших направлений цифровизации является освоение трудноизвлекаемых запасов нефти. Согласно прогнозам Минэнерго, к 2035 году доля этих запасов в общем объеме российской нефти возрастет с 39 до 80 миллионов тонн в год. Это свидетельствует о значительном увеличении роли таких запасов в энергобалансе страны и подчеркивает необходимость применения цифровых технологий для их эффективного освоения.

Министр энергетики России Николай Шульгинов отметил, что будущее нефтяной отрасли напрямую зависит от успешной разработки трудноизвлекаемых ресурсов. В связи с этим

Минэнерго планирует в 2023 году рассмотреть вопрос о дополнительных стимулах для добычи таких ресурсов, включая расширение применения налога на дополнительный доход (НДД). Это решение подчеркивает важность создания благоприятных условий для развития высокотехнологичной добычи в условиях возрастающей конкуренции и сложных экономических реалий.

Крупнейшие нефтедобывающие компании России активно внедряют цифровые технологии в свою деятельность. Например, ЛУКОЙЛ реализует свою «Информационную стратегию» до 2030 года, включающую программы цифровых двойников, создание экосистем, внедрение цифрового

персонала и роботизацию. Газпром нефть, в свою очередь, осуществляет цифровую трансформацию на всех этапах своей деятельности — от геологоразведки до сбыта продукции, запустив в 2019 году более 150 новых цифровых инициатив и 10 программ трансформации. В Татнефти цифровизация охватывает весь процесс нефтедобычи — от сбора и анализа геолого-технологической информации до принятия решений по оптимальным геолого-техническим мероприятиям.

Роснефть также следует комплексному плану цифровизации, являющемуся частью стратегии «Роснефть-2022». Этот план включает такие программы, как «цифровое месторождение», «цифровой завод», «цифровая цепочка поставок» и «цифровая АЗС». Эти примеры демонстрируют, что цифровизация становится неотъемлемой частью стратегий крупнейших игроков рынка, что позволяет им оставаться конкурентоспособными на международной арене.

Международная конкуренция в сфере патентования, особенно касающегося цифровых технологий, также усиливается. Лидерами по количеству патентов в этой области являются такие компании, как China Petroleum, PetroChina Co. и Saudi Arabian Oil Co. В то же время, американские и европейские компании, такие как Exxon Mobil, Shell, Total Energies и Chevron, поддерживают высокую динамику в получении цифровых патентов, хотя и уступают по количеству лидерам.

Одной из ключевых проблем в области цифровых технологий является их уязвимость перед утечками информации, вызванными переходом сотрудников в другие компании или промышленным шпионажем. Исследования показали, что крупнейшие нефтегазовые компании часто вовлечены в патентные споры, связанные с цифровыми технологиями. Например, Schlumberger является абсолютным лидером по количеству судебных разбирательств в этой сфере, включая выигранное в 2022 году дело против ION Geophysical Corp в Верховном суде США. Этот случай подчеркивает важность защиты интеллектуальной собственности и прав на инновационные разработки, особенно в условиях нарастающей конкуренции [3].

## **2. Влияние автоматизации на снижение энергозатрат**

Автоматизация процессов добычи нефти на сегодняшний день приобретает особое значение в нефтяной промышленности, решая ряд критически важных задач. В первую очередь, это обеспечение надежной защиты оборудования в условиях аварийных ситуаций и поддержание непрерывного контроля над технологическими процессами. Автоматизированные системы управления позволяют не только следить за состоянием оборудования, используемого в процессе добычи нефти, но и значительно сократить простой нефтяных скважин, что, в свою очередь, ведет к снижению экономических затрат и увеличению коэффициента извлечения нефти.

Современные автоматизированные системы управления технологическим процессом выполняют комплекс функций, включая измерение и обработку ключевых параметров, таких как температура, давление и вибрации, с последующей передачей данных на центральный контроллер для анализа. Эти системы также обеспечивают автоматическое регулирование параметров процесса, что позволяет оперативно реагировать на изменения в условиях эксплуатации. Важным аспектом является возможность дискретного управления оборудованием и оперативное оповещение о любых отклонениях от заданных параметров, что способствует своевременному принятию мер для предотвращения аварий.

Внедрение автоматизации в нефтедобычу позволяет значительно повысить безопасность производственных процессов и обеспечить контроль над всеми стадиями производства. Это также способствует снижению риска аварийных ситуаций и позволяет оперативно реагировать на изменения в работе оборудования. Ключевым преимуществом автоматизации является повышение эффективности добычи нефти, что особенно важно в условиях современных требований к производительности.

Для эффективной разработки малодебитных месторождений широко используются штанговые насосные установки. Однако при снижении дебита скважин возникает необходимость в оптимизации работы насосных установок, чтобы избежать лишних энергозатрат и уменьшить износ оборудования. Решение данной задачи заключается в совершенствовании систем автоматизации, обеспечивающих выбор оптимального режима работы в зависимости от текущего состояния скважин.

Разработка и эксплуатация труднодоступных месторождений требует применения маломощных насосных установок и создания автоматизированных систем управления, которые учитывают особенности каждого месторождения. Это позволяет снизить негативное влияние несогласованной работы скважин на общий объем добычи и уменьшить износ оборудования.

С учетом современных требований к разработке нефтяных месторождений, необходимо внедрение передовых технологий, включая «безлюдные» системы управления. Такие системы позволяют эффективно контролировать работу удаленных объектов даже в условиях нестабильной связи, что требует использования резервных каналов передачи данных и специализированных протоколов телемеханики.

В условиях удаленного управления объектами возрастает риск кибератак, что требует применения усиленных мер по обеспечению кибербезопасности. Рекомендуется использовать проактивные антивирусные системы и регулярно проводить аудит информационной безопасности для защиты автоматизированных систем управления.

Использование методов анализа и синтеза систем с распределенными параметрами наиболее целесообразно для управления процессом добычи нефти. Нефтяные месторождения, как объекты с распределенными параметрами, требуют применения специфических методик анализа, учитывающих изменение геометрических характеристик пластов во времени. При этом возможно использование различных форм

представления объектов, таких как дифференциальные уравнения, передаточные функции и временные характеристики. Методы анализа и синтеза, такие как АКОР, параметрический и частотный, позволяют оценить динамические свойства системы и разработать оптимальные стратегии управления [4]. Ниже в таблице 2 будут описаны основные стратегии повышения энергоэффективности

Таблица 2.

### Основные стратегии повышения энергоэффективности [4].

Table 2.

#### Key strategies for improving energy efficiency [4].

Наименование стратегии	Описание
Совершенствование производственных процессов	Одним из ключевых подходов к улучшению энергоэффективности является модернизация технологических операций. Внедрение передовых методов производства позволяет существенно уменьшить потери энергии и ресурсов. Автоматизация производственных линий также способствует повышению точности работы оборудования и сокращению простоев, что положительно влияет на общую производительность предприятия.
Использование инновационных технологий и оборудования	Для снижения энергопотребления необходимо активное использование современных энергоэффективных технологий. Применение инверторных компрессоров, светодиодных источников освещения, а также высокоэффективных систем отопления, вентиляции и кондиционирования воздуха (HVAC) существенно сокращает расходы на энергию и повышает экологическую устойчивость предприятий.
Повышение профессиональной подготовки персонала	Эффективное управление энергопотреблением возможно при наличии квалифицированного персонала. Регулярное обучение сотрудников передовым практикам в области энергосбережения, а также навыкам работы с новейшими технологиями, позволяет рационализировать использование энергии и минимизировать издержки.
Внедрение возобновляемых источников энергии	Для снижения зависимости от ископаемых топлив и уменьшения углеродного следа целесообразно интегрировать возобновляемые источники энергии, такие как солнечные батареи и ветрогенераторы, в энергетическую систему предприятия. Это способствует не только экологической, но и экономической устойчивости, снижая долгосрочные затраты на энергообеспечение.
Совершенствование систем управления энергопотреблением	Важным элементом энергосбережения является внедрение интеллектуальных систем управления, которые позволяют контролировать и оптимизировать потребление энергии в режиме реального времени. Такие системы автоматически корректируют работу оборудования, что обеспечивает максимальную эффективность и минимальные потери.
Регулярный энергоаудит и мониторинг	Периодическая оценка энергоэффективности предприятия помогает выявлять и устранять источники потерь энергии. Это позволяет своевременно разрабатывать и внедрять мероприятия, направленные на улучшение энергетических показателей и повышение общей эффективности производственных процессов.

В таблице 3 будут представлены энергоэффективные решения и технологии.

Таблица 3.

**Энергоэффективные решения и технологии [5].**

Table 3.

**Energy efficient solutions and technologies [5].**

Наименование решения	Описание
Современные насосные системы	Внедрение высокоэффективных насосов значительно снижает энергозатраты на перекачку нефти и газа, достигая экономии до 30%. Дополнительное использование частотных преобразователей в управлении насосами позволяет оптимизировать рабочие режимы и снизить энергопотребление еще на 20%. Интеграция герметичных корпусов не только минимизирует потери продукта, но и улучшает экологические характеристики предприятия. Интеллектуальные системы мониторинга и управления обеспечивают своевременное выявление и устранение неисправностей, повышая надежность оборудования.
Энергоэффективные компрессоры	Современные компрессоры, активно используемые в нефтегазовой отрасли, позволяют сократить энергозатраты до 35% благодаря инновационным конструктивным решениям и использованию современных материалов. Автоматические системы управления поддерживают компрессоры в оптимальном режиме работы, что дополнительно уменьшает энергопотребление на 10-15%. Применение частотно-регулируемых приводов адаптирует работу компрессоров под текущие потребности, обеспечивая экономичность и высокую надежность оборудования.
Системы автоматизации и управления	Интеграция интеллектуальных систем автоматизации позволяет значительно снизить потребление энергии за счет оптимизации процессов в режиме реального времени. Передовые датчики и контроллеры обеспечивают постоянный мониторинг и управление всеми этапами производства, что позволяет минимизировать численность персонала и сократить эксплуатационные расходы. Автоматизация также способствует повышению уровня безопасности на предприятии.
Применение альтернативных источников энергии	Использование возобновляемых источников энергии, таких как солнечные и ветровые установки, позволяет снизить зависимость от традиционных энергоресурсов, обеспечивая до 40% потребностей предприятия. Внедрение геотермальной энергии и биогаза способствует сокращению углеродного следа и улучшению экологических показателей. Гибридные системы энергообеспечения обеспечивают стабильную работу предприятия даже при переменной нагрузке, что позволяет оптимизировать энергетическую безопасность и снизить операционные риски [5].

**3. Перспективы развития автоматизации**

Значение разработки трудноизвлекаемых углеводородных запасов в России становится все более актуальным, учитывая прогнозируемое увеличение их доли в общей структуре запасов углеводородов к 2035 году. В то же время ожидается снижение объемов добычи нефти, что подчеркивает необходимость поиска новых решений для поддержания уровня добычи.

В данных условиях приоритетным направлением для повышения эффективности работы нефтегазовых компаний становится внедрение цифровых технологий. На сегодняшний день большинство ведущих нефтегазовых корпораций по всему миру опираются на цифровую трансформацию как на ключевой элемент своей стратегии развития. Такая трансформация позволяет не только повысить конкурентоспособность компаний, но и укрепить их позиции на рынке, улучшая рентабельность и устойчивость бизнеса.

Цифровые технологии в нефтегазовой отрасли направлены на решение нескольких ключевых задач, среди которых увеличение коэффициента нефтеотдачи и снижение эксплуатационных затрат.

Тем не менее, процесс цифровизации сталкивается с рядом вызовов. Одним из них является зависимость от зарубежных технологий, оборудования и программного обеспечения, что особенно актуально в условиях санкций. Уровень импортозамещения пока не позволяет полностью отказаться от иностранной продукции, что замедляет развитие цифровых платформ в России.

Также существует проблема недостаточного финансирования стартапов, связанных с цифровыми проектами в нефтегазовой отрасли. Для успешной реализации таких проектов необходимы специальные полигоны для испытания новых технологий, что требует значительных инвестиций. Примеры таких полигонов можно найти за рубежом, где финансирование идет от государственных органов, например, в США подобные проекты поддерживаются Министерством энергетики.

Для ускорения процесса цифровизации в нефтегазовой отрасли России необходимо решить ряд проблем, среди которых недостаточное финансирование, зависимость от импортных технологий и нехватка квалифицированных специалистов. Решение этих задач позволит



существенно повысить эффективность разработки трудноизвлекаемых запасов и снизить риски, связанные с эксплуатацией месторождений.

Ключевым направлением для дальнейшего исследования и практического применения является интеграция цифровых технологий в процессы принятия решений и управление производством на всех этапах разработки месторождений, что обеспечит устойчивое развитие отрасли в долгосрочной перспективе [6].

#### **Заключение**

Автоматизация становится важнейшим фактором для повышения энергоэффективности в нефтегазовой отрасли, обеспечивая оптимизацию процессов и сокращение энергозатрат. Использование современных автоматизированных систем управления позволяет не только увеличить производительность и снизить риски, связанные с эксплуатацией оборудования, но и способствует улучшению экологических показателей предприятий. Внедрение передовых технологий, таких как искусственный интеллект и интернет вещей, предоставляет новые возможности для разработки трудноизвлекаемых месторождений и эксплуатации в сложных условиях. Таким образом, автоматизация является неотъемлемой частью стратегии развития нефтегазовых компаний, направленной на повышение их конкурентоспособности и устойчивости в условиях цифровой трансформации и глобальных вызовов.

#### **Литература**

1.Плис С.А., Идигова Л.М. Обзор современных взглядов на технологии автоматизации бизнес-процессов нефтегазовой отрасли // *Международный журнал гуманитарных и естественных наук*. 2023. №11-2 (86). С. 133-136.

2.Автоматизация нефтегазового производства. [Электронный ресурс] Режим доступа: <https://evomatics.ru/solutions/avtomatizatsiya-neftegazovogo-proizvodstva/> (дата обращения 09.08.2024).

3.Цифровизация нефтегазового сектора в России и мире: краткий обзор. [Электронный ресурс] Режим доступа: <https://habr.com/ru/companies/onlinepatent/articles/742636/> (дата обращения 09.08.2024).

4.Максименко Д.Ф., Воронин А.Ю. Задачи и проблемы автоматизации процессов добычи нефти // *Форум молодых ученых*. 2019. №1-2 (29). С. 679-684.

5.Цифровые инструменты повышения экономической эффективности разработки. [Электронный ресурс] Режим доступа: <https://magazine.neftegaz.ru/articles/tsifrovizatsiya/784611-povyshenie-ekonomicheskoi-effektivnosti-razrabotki-neftegazovykh-mestorozhdenii-na-osnovevnedreniya/> (дата обращения 09.08.2024).

6.Громаков Е.И., Мамонова Т.Е., Лиепинш А.В., Рымшин А.Н. Развитие перспективной автоматизации в нефтегазовой отрасли. [Электронный ресурс] Режим доступа: [https://oil-industry.net/Journal/archive\\_detail.php?ID=11794&art=234825](https://oil-industry.net/Journal/archive_detail.php?ID=11794&art=234825) (дата обращения 09.08.2024).

#### **References**

1.Plis S.A., Idigova L.M. Review of modern views on business process automation technologies in the oil and gas industry // *International Journal of Humanities and Natural Sciences*. 2023. No.11-2 (86). pp. 133-136.

2.Automation of oil and gas production. [Electronic resource] Access mode: <https://evomatics.ru/solutions/avtomatizatsiya-neftegazovogo-proizvodstva/> (accessed 08/09/2024).

3.Digitalization of the oil and gas sector in Russia and the world: a brief overview. [Electronic resource] Access mode: <https://habr.com/ru/companies/onlinepatent/articles/742636/> (accessed 08/09/2024).

4.Maksimenko D.F., Voronin A.Yu. Tasks and problems of automation of oil production processes // *Forum of Young Scientists*. 2019. No.1-2 (29). pp. 679-684.

5.Digital tools for improving the economic efficiency of development. [Electronic resource] Access mode: <https://magazine.neftegaz.ru/articles/tsifrovizatsiya/784611-povyshenie-ekonomicheskoi-effektivnosti-razrabotki-neftegazovykh-mestorozhdenii-na-osnovevnedreniya/> (accessed 08/09/2024).

Gromakov E.I., Mamonova T.E., Liepinsh A.V., Rymshin A.N. Development of advanced automation in the oil and gas industry. [Electronic resource] Access mode: [https://oil-industry.net/Journal/archive\\_detail.php?ID=11794&art=234825](https://oil-industry.net/Journal/archive_detail.php?ID=11794&art=234825) (accessed 08/09/2024).

# КОМПЬЮТЕРНЫЕ НАУКИ И ИНФОРМАТИКА

## АЛГОРИТМЫ ВЫЯВЛЕНИЯ АНОМАЛИЙ В РЕАЛЬНОМ ВРЕМЕНИ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

*Журавлев Вячеслав Вадимович*  
Основатель Tabliner  
Батуми, Грузия

### REAL-TIME ANOMALY DETECTION ALGORITHMS USING MACHINE LEARNING

*Zhuravlev Viacheslav*  
Tabliner founder  
Batumi, Georgia

DOI: 10.31618/ESU.2413-9335.2024.1.122.2074

#### АННОТАЦИЯ

В данной статье рассматриваются алгоритмы обнаружения аномалий в реальном времени с использованием машинного обучения, с акцентом на адаптивные методы для потоковых данных, ансамблевые подходы и приложения глубокого обучения. Будут проанализированы методы обработки временных рядов, уделяя особое внимание алгоритмам анализа временных последовательностей, методам прогнозирования и оптимизации производительности. В ходе исследования изучаются масштабируемые решения и распределенные системы, рассматриваются архитектуры для обработки больших данных, алгоритмы коллективного обучения, а также баланс между точностью и вычислительной эффективностью. Среди ключевых выводов - эффективность адаптивных методов, таких как STORM и MCOB, в борьбе с дрейфом концепций, надежность ансамблевых подходов, таких как LSAD и AE, и потенциал архитектур глубокого обучения, таких как MemAE и LSTM-VAE, для комплексного обнаружения аномалий. В заключение исследования определены открытые проблемы и направления будущих исследований, включая интерпретируемость моделей, автоматическую настройку гиперпараметров и энергоэффективные алгоритмы. Этот комплексный анализ способствует развитию методов обнаружения аномалий в реальном времени в различных областях.

#### ABSTRACT

This study explores real-time anomaly detection algorithms using machine learning, focusing on adaptive methods for streaming data, ensemble approaches, and deep learning applications. We analyze time series processing techniques, emphasizing algorithms for temporal sequence analysis, forecasting methods, and performance optimization. The research investigates scalable solutions and distributed systems, examining architectures for big data processing, federated learning algorithms, and the balance between accuracy and computational efficiency. Key findings include the effectiveness of adaptive methods like STORM and MCOB in handling concept drift, the robustness of ensemble approaches such as LSAD and AE, and the potential of deep learning architectures like MemAE and LSTM-VAE for complex anomaly detection. The study concludes by identifying open challenges and future research directions, including model interpretability, automatic hyperparameter tuning, and energy-efficient algorithms. This comprehensive analysis contributes to the advancement of real-time anomaly detection techniques across various domains.

**Ключевые слова:** обнаружение аномалий, машинное обучение, обработка в реальном времени, анализ временных рядов, распределенные системы, адаптивные алгоритмы, ансамблевые методы, глубокое обучение, объединенное обучение, масштабируемые архитектуры.

**Keywords:** anomaly detection, machine learning, real-time processing, time series analysis, distributed systems, adaptive algorithms, ensemble methods, deep learning, federated learning, scalable architectures.

#### 1. Введение

В эпоху больших данных и повсеместной цифровизации выявление аномалий в реальном времени становится критически важной задачей для многих отраслей. Аномалии, представляющие собой отклонения от ожидаемого поведения системы, могут сигнализировать о потенциальных проблемах, угрозах безопасности или уникальных возможностях. Машинное обучение предоставляет мощный инструмент для автоматического обнаружения таких отклонений, позволяя обрабатывать огромные объемы данных с высокой скоростью и точностью.

Аномалии можно классифицировать на несколько основных типов: точечные, контекстуальные и коллективные. Точечные аномалии представляют собой отдельные экземпляры данных, значительно отличающиеся от нормы. Контекстуальные аномалии проявляются в определенном контексте, например, необычно высокая температура для конкретного времени года. Коллективные аномалии возникают, когда группа связанных точек данных демонстрирует аномальное поведение относительно всего набора данных.

Выявление аномалий в реальном времени сопряжено с рядом уникальных вызовов. Во-

первых, алгоритмы должны работать с высокой скоростью, обрабатывая потоковые данные без существенных задержек. Во-вторых, они должны адаптироваться к изменяющимся паттернам в данных, что требует постоянного обучения и обновления моделей. В-третьих, необходимо минимизировать количество ложных срабатываний, сохраняя при этом высокую чувствительность к реальным аномалиям [1].

Машинное обучение предлагает ряд подходов для решения этих задач. Супервизорные методы, такие как случайный лес или глубокие нейронные сети, могут эффективно обнаруживать известные типы аномалий, если доступен размеченный набор данных. Однако в реальных сценариях часто приходится иметь дело с неразмеченными данными, что приводит к необходимости использования несупервизорных методов, таких как изоляционный лес или алгоритмы кластеризации [2].

Ключевой концепцией в контексте выявления аномалий является понятие нормального поведения системы. Алгоритмы машинного обучения строят модель нормального состояния на основе исторических данных, а затем используют эту модель для оценки новых поступающих данных. Отклонения от этой модели рассматриваются как потенциальные аномалии.

Одним из важных аспектов работы с потоковыми данными является концепция скользящего окна. Это метод позволяет алгоритмам фокусироваться на последних наблюдениях, адаптируясь к изменениям в распределении данных с течением времени. Размер окна может варьироваться в зависимости от конкретной задачи и характеристик данных [1].

Важно отметить, что выбор конкретных алгоритмов и архитектур зависит от специфики задачи, характеристик данных и требований к производительности системы. В следующих разделах мы подробно рассмотрим современные подходы к решению этой комплексной проблемы, уделяя особое внимание адаптивным методам, ансамблевым подходам и применению глубокого

обучения для выявления аномалий в реальном времени.

## **2. Современные алгоритмы выявления аномалий**

Эволюция алгоритмов выявления аномалий в реальном времени привела к развитию трех ключевых направлений: адаптивные методы для потоковых данных, ансамблевые подходы и применение глубокого обучения. Каждое из этих направлений предлагает уникальные преимущества в контексте обработки динамических данных и выявления сложных паттернов аномалий.

Адаптивные методы для потоковых данных фокусируются на способности алгоритмов непрерывно обучаться и адаптироваться к изменяющимся характеристикам входного потока. Ключевой концепцией здесь является инкрементное обучение, позволяющее обновлять модель без полного переобучения на всем наборе данных. Алгоритм STORM (STream Outlier Miner) представляет собой эффективное решение для обнаружения многомерных выбросов в потоковых данных. STORM использует кластеризацию на основе плотности и адаптивные пороговые значения для идентификации аномалий. Его преимущество заключается в способности обрабатывать высокоскоростные потоки данных с минимальными требованиями к памяти.

Другим значимым адаптивным методом является MCOD (Micro-cluster-based Continuous Outlier Detection), который комбинирует кластеризацию и статистический анализ для выявления локальных и глобальных выбросов. MCOD поддерживает динамическое обновление микрокластеров, что позволяет ему эффективно адаптироваться к дрейфу концепций в данных. Алгоритм демонстрирует высокую точность при обработке многомерных потоковых данных с нестационарными распределениями.

Для иллюстрации процесса адаптивного выявления аномалий рассмотрим следующую схему (рис. 1).

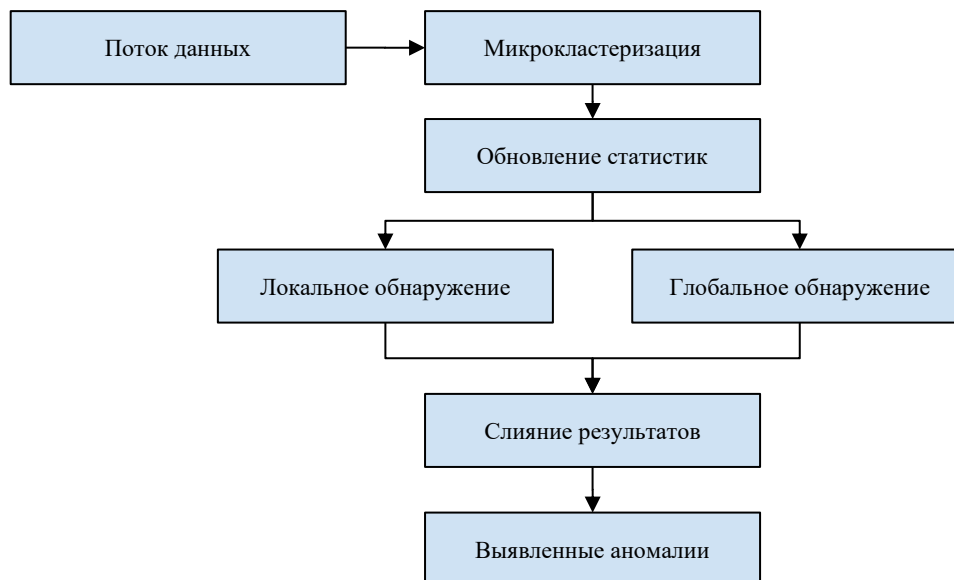


Рисунок 1 – Процесс адаптивного выявления аномалий

Схема иллюстрирует процесс адаптивного выявления аномалий, начиная с потока данных, который подвергается микрокластеризации. Затем происходит обновление статистик, на основании которых выполняются локальное и глобальное обнаружение аномалий. Результаты обоих типов обнаружения объединяются, и на выходе формируются выявленные аномалии.

Ансамблевые подходы представляют собой мощный инструмент для повышения точности и устойчивости процесса выявления аномалий. Основная идея заключается в комбинировании результатов нескольких базовых детекторов для получения более надежного итогового решения. LSAD (Lightweight Streaming Anomaly Detection) — это эффективный ансамблевый алгоритм, который использует комбинацию нескольких лёгких детекторов, таких как изоляционный лес и локальный фактор выброса (LOF). LSAD применяет динамическое взвешивание результатов базовых детекторов, адаптируясь к изменениям в характеристиках потока данных [2].

Другой значимый ансамблевый метод — AE (Anomaly Ensemble) — использует разнообразные базовые детекторы и технику стекинга для обучения мета-классификатора. AE демонстрирует высокую эффективность в сценариях с неоднородными типами аномалий, где отдельные детекторы могут иметь различную производительность на разных участках пространства признаков.

Рассмотрим псевдокод базовой структуры ансамблевого алгоритма:

```

def ensemble_anomaly_detection(data_stream):
    base_detectors = [detector1, detector2, detector3]
    weights = [0.33, 0.33, 0.33] # Начальные веса

    for data_point in data_stream:
        anomaly_scores = []
        for detector in base_detectors:
            score = detector.score(data_point)
  
```

```

anomaly_scores.append(score)
  
```

```

ensemble_score = sum(w * s for w, s in
zip(weights, anomaly_scores))
  
```

```

if ensemble_score > threshold:
    report_anomaly(data_point)
  
```

```

update_weights(weights, anomaly_scores)
  
```

Этот псевдокод иллюстрирует процесс комбинирования результатов базовых детекторов и динамического обновления весов для адаптации к изменениям в потоке данных.

Применение глубокого обучения открывает новые возможности для выявления сложных и нелинейных паттернов аномалий. Автоэнкодеры представляют собой инструмент для несупервизорного обнаружения аномалий в потоковых данных. MemAE (Memory-augmented Autoencoder) — это инновационный подход, который расширяет стандартный автоэнкодер дополнительным модулем памяти. Это позволяет модели эффективно запоминать нормальные паттерны и точнее идентифицировать отклонения. MemAE демонстрирует высокую производительность на сложных многомерных данных, особенно в сценариях с редкими аномалиями [3].

LSTM-VAE (Long Short-Term Memory Variational Autoencoder) представляет собой гибридную архитектуру, объединяющую преимущества рекуррентных нейронных сетей и вариационных автоэнкодеров. Эта модель особенно эффективна для обнаружения аномалий в временных рядах и последовательных данных. LSTM-VAE способен захватывать долгосрочные зависимости и моделировать сложные распределения вероятностей, что делает его мощным инструментом для выявления контекстуальных аномалий [10].

Для иллюстрации архитектуры LSTM-VAE рассмотрим следующую схему (рис. 2).

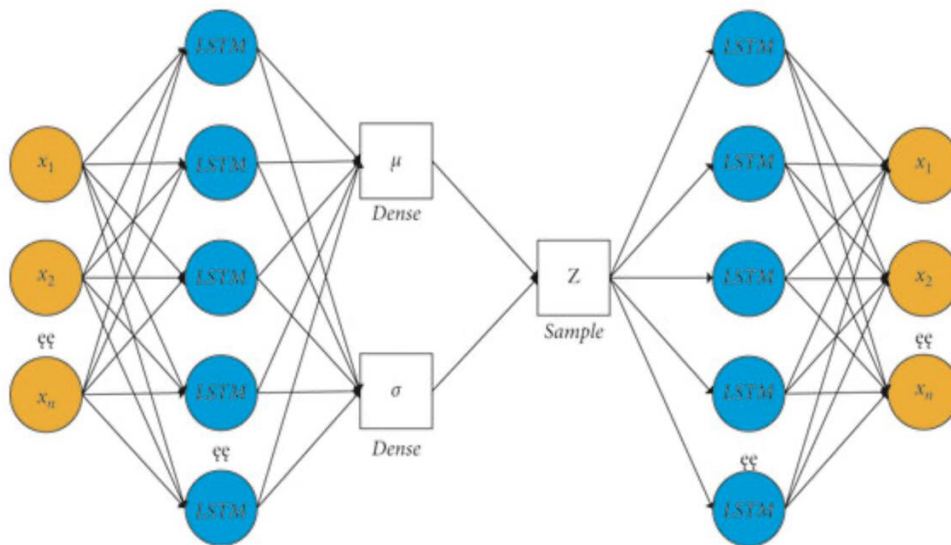


Рисунок 2 – Архитектура LSTM-VAE [10]

Эта схема демонстрирует процесс кодирования входной последовательности в латентное пространство с помощью LSTM-энкодера, затем производится сэмплирование из этого пространства, и декодер восстанавливает исходную последовательность. Аномалии выявляются путем сравнения оригинальной и реконструированной последовательностей [10].

Важно отметить, что выбор конкретного алгоритма зависит от специфики задачи, характеристик данных и вычислительных ресурсов. Адаптивные методы особенно эффективны в условиях быстро меняющихся потоков данных, ансамблевые подходы обеспечивают робастность и универсальность, а методы глубокого обучения превосходят в задачах с сложными нелинейными паттернами аномалий. Интеграция этих подходов в единую систему представляет собой перспективное направление для создания высокоэффективных решений по выявлению аномалий в реальном времени [2,3].

### 3. Обработка временных рядов в реальном времени

Выявление аномалий в временных рядах в реальном времени представляет собой комплексную задачу, требующую специализированных алгоритмов, способных эффективно обрабатывать потоковые данные с учетом их темпоральной структуры. Ключевыми аспектами этой области являются алгоритмы анализа временных последовательностей, методы прогнозирования и выявления отклонений, а также оптимизация производительности для работы в режиме реального времени [4,5].

Алгоритмы анализа временных последовательностей в контексте выявления аномалий фокусируются на идентификации необычных паттернов, учитывая временную зависимость данных. ARIMA-GARCH

(AutoRegressive Integrated Moving Average - Generalized AutoRegressive Conditional Heteroskedasticity) представляет гибридный подход, сочетающий моделирование тренда и сезонности с анализом волатильности. Этот метод особенно эффективен для финансовых временных рядов, где аномалии часто связаны с изменениями в волатильности.

Другой значимый алгоритм - Matrix Profile, предложенный Yeh и др., обеспечивает эффективный способ обнаружения мотивов и дискордов в временных рядах [4]. Ключевое преимущество Matrix Profile заключается в его способности работать с многомерными временными рядами и выявлять аномалии различной продолжительности. Рассмотрим псевдокод для инкрементальной версии Matrix Profile:

```
def incremental_matrix_profile(time_series,
window_size):
    mp = initialize_matrix_profile(time_series,
window_size)
    for new_point in stream:
        update_time_series(time_series, new_point)
        update_matrix_profile(mp, time_series,
new_point)
        anomaly_score = calculate_anomaly_score(mp)
        if anomaly_score > threshold:
            report_anomaly(new_point)
```

Псевдокод демонстрирует процесс обновления Matrix Profile при поступлении новых данных и вычисления оценки аномальности на основе обновленного профиля.

В свою очередь методы прогнозирования и выявления отклонений позволяют обнаружить аномалии в реальном времени. Prophet, разработанный Facebook, представляет собой

робастную модель для прогнозирования временных рядов, способную учитывать сезонность, праздники и тренды. Интеграция Prophet с алгоритмами выявления аномалий позволяет эффективно идентифицировать отклонения от ожидаемого поведения временного ряда [5].

DeepAR, предложенный Amazon, использует рекуррентные нейронные сети для создания

вероятностных прогнозов [9]. Этот подход особенно эффективен для многомерных временных рядов с сложными зависимостями. DeepAR может быть адаптирован для выявления аномалий путем сравнения фактических значений с предсказанными распределениями.

Для иллюстрации процесса выявления аномалий на основе прогнозирования, рассмотрим следующую схему (рис. 3).

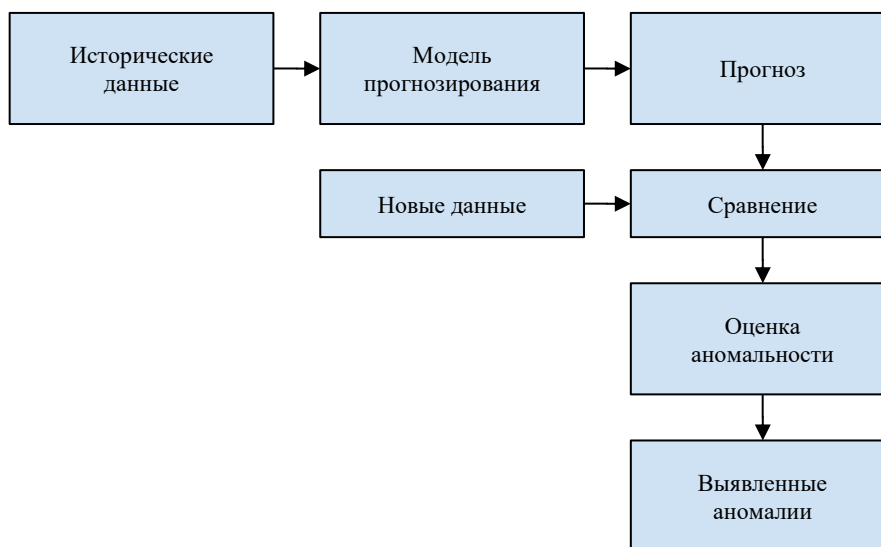


Рисунок 3 – Процесс выявления аномалий на основе прогнозирования

Эта схема иллюстрирует процесс, где модель прогнозирования обучается на исторических данных, генерирует прогноз, который затем сравнивается с фактическими новыми данными для выявления аномалий.

Оптимизация производительности для работы в реальном времени является критическим аспектом при разработке систем выявления аномалий в временных рядах. Алгоритм SAND (Streamtime Anomaly Detection) представляет собой эффективное решение, использующее скользящее окно и инкрементальные обновления для минимизации вычислительных затрат. SAND применяет динамическую сегментацию временного ряда и локальную нормализацию для адаптации к нестационарным процессам.

Другой подход к оптимизации - использование аппроксимационных методов, таких как Sketch-based Anomaly Detection. Этот метод использует вероятностные структуры данных (например, Count-Min Sketch) для аппроксимации распределения данных с ограниченным использованием памяти. Такой подход позволяет обрабатывать высокоскоростные потоки данных с минимальными задержками.

Рассмотрим пример использования Count-Min Sketch для аппроксимации распределения:

```

class CountMinSketch:
    def __init__(self, width, depth):
        self.width = width
        self.depth = depth
  
```

```

self.sketch = [[0] * width for _ in range(depth)]
self.hash_functions = self._generate_hash_functions()
  
```

```

def update(self, item):
    for i, hash_func in enumerate(self.hash_functions):
        j = hash_func(item) % self.width
        self.sketch[i][j] += 1
  
```

```

def estimate_frequency(self, item):
    return min(self.sketch[i][self.hash_functions[i](item) % self.width]
               for i in range(self.depth))
  
```

```

def detect_anomalies(stream, cms, threshold):
    for item in stream:
        cms.update(item)
        frequency = cms.estimate_frequency(item)
        if frequency < threshold:
            yield item # Потенциальная аномалия
  
```

Данный код демонстрирует базовую реализацию Count-Min Sketch и его применение для выявления потенциальных аномалий в потоке данных.

Интеграция описанных подходов - алгоритмов анализа временных последовательностей, методов прогнозирования и техник оптимизации - позволяет создавать эффективные системы выявления аномалий в временных рядах, способные работать

в режиме реального времени. Ключевым фактором успеха таких систем является баланс между точностью обнаружения аномалий и вычислительной эффективностью, что достигается через тщательный выбор и настройку алгоритмов в зависимости от специфики конкретной задачи и характеристик анализируемых временных рядов [4,5].

#### 4. Масштабируемые решения и распределенные системы

Масштабируемость и распределенная обработка становятся критическими факторами при разработке систем выявления аномалий для больших объемов данных в реальном времени. Эффективные решения в этой области фокусируются на трех ключевых аспектах:

архитектуры для обработки больших объемов данных, алгоритмы федеративного обучения и балансировка между точностью и вычислительной эффективностью [6].

Архитектуры для обработки больших объемов данных в контексте выявления аномалий часто основываются на принципах потоковой обработки и распределенных вычислений. Lambda-архитектура, предложенная Нейтаном Марцем, представляет собой гибридный подход, сочетающий пакетную и потоковую обработку для достижения баланса между задержкой, пропускной способностью и отказоустойчивостью [7]. В контексте выявления аномалий, Lambda-архитектура может быть реализована следующим образом (рис. 4).



Рисунок 4 – Lambda-архитектура

Она позволяет обрабатывать поступающие данные в режиме реального времени на уровне скорости, одновременно выполняя более глубокий анализ на уровне пакетной обработки. Уровень обслуживания объединяет результаты обоих уровней, обеспечивая комплексное выявление аномалий.

Для реализации распределенной обработки в системах выявления аномалий широко применяются фреймворки, такие как Apache Flink и Apache Spark Streaming. Эти платформы предоставляют высокоуровневые API для разработки масштабируемых приложений потоковой обработки. Рассмотрим пример

использования Apache Flink для распределенного выявления аномалий:

```

public class DistributedAnomalyDetection {
    public static void main(String[] args) throws
    Exception {
        StreamExecutionEnvironment env =
        StreamExecutionEnvironment.getExecutionEnvironment();

        DataStream<Event> input = env.addSource(new
        FlinkKafkaConsumer<>("topic", new
        EventDeserializationSchema(), properties));
  
```

```

DataStream<AnomalyResult> anomalies = input
    .keyBy(Event::getSource)
    .window(TumblingEventTimeWindows.of(Time.
minutes(5)))
    .process(new AnomalyDetectionFunction())
    .filter(result -> result.isAnomaly());

anomalies.addSink(new AlertSink());

env.execute("Distributed Anomaly Detection");
}
}

```

Данный код демонстрирует базовую структуру распределенного приложения для выявления аномалий с использованием Apache Flink, где данные обрабатываются параллельно в распределенном кластере.

Алгоритмы федеративного обучения представляют собой перспективное направление для распределенного выявления аномалий, особенно в сценариях, где данные распределены между несколькими узлами или организациями. Федеративное обучение позволяет обучать модели на распределенных наборах данных без необходимости централизации данных, что решает проблемы конфиденциальности и снижает нагрузку на сеть [8].

FedAvg (Federated Averaging), предложенный McMahan и др., является базовым алгоритмом федеративного обучения, который может быть адаптирован для задач выявления аномалий [6]. В контексте обнаружения аномалий, FedAvg может быть модифицирован следующим образом:

1. Каждый узел обучает локальную модель выявления аномалий на своих данных.

2. Узлы отправляют параметры своих моделей центральному серверу.

3. Сервер агрегирует параметры, формируя глобальную модель.

4. Обновленная глобальная модель распространяется обратно на узлы.

Этот процесс повторяется итеративно, позволяя создать общую модель выявления аномалий без обмена необработанными данными между узлами.

Балансировка между точностью и вычислительной эффективностью является ключевым аспектом при разработке масштабируемых систем выявления аномалий. Адаптивные методы, такие как ADWIN (ADaptive WINdowing), позволяют динамически регулировать размер окна анализа в зависимости от характеристик потока данных, оптимизируя использование ресурсов.

Другой подход к оптимизации – использование иерархических моделей, где простые и быстрые детекторы применяются на нижних уровнях иерархии для фильтрации очевидных случаев, а более сложные и ресурсоемкие модели задействуются только для анализа неопределенных ситуаций. Это позволяет значительно снизить вычислительную нагрузку без существенной потери точности.

Рассмотрим схему иерархической системы выявления аномалий (рис. 5).

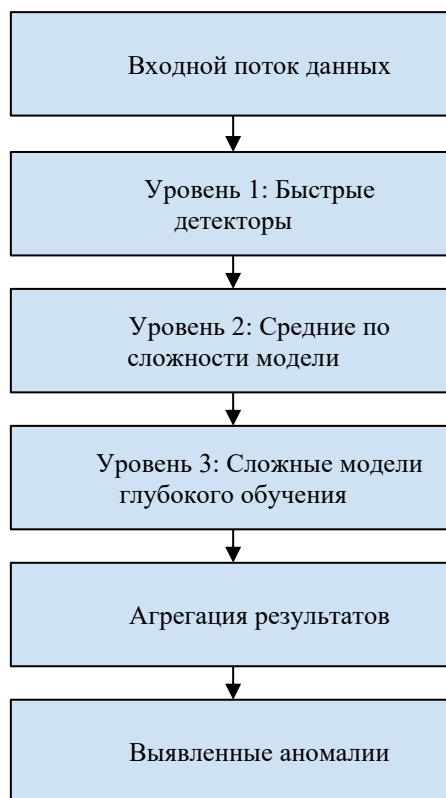


Рисунок 5 – Иерархическая система выявления аномалий



Такая структура позволяет эффективно обрабатывать большие объемы данных, направляя только наиболее сложные случаи на верхние уровни анализа.

Для дальнейшей оптимизации производительности в распределенных системах выявления аномалий применяются техники приближенных вычислений, такие как Locality-Sensitive Hashing (LSH) для быстрого поиска ближайших соседей или Bloom фильтры для эффективной проверки членства в множестве. Эти методы позволяют значительно ускорить обработку данных при незначительном снижении точности.

Следует отметить, что разработка масштабируемых решений для выявления аномалий в распределенных системах требует комплексного подхода, сочетающего эффективные архитектуры, алгоритмы федеративного обучения и методы оптимизации. Ключевым фактором успеха является адаптивность системы к изменяющимся характеристикам потока данных и вычислительным ресурсам, что достигается через постоянный мониторинг производительности и динамическую настройку параметров алгоритмов и архитектуры системы [6-8].

### 5. Заключение

Выявление аномалий в реальном времени с использованием машинного обучения представляет собой динамично развивающуюся область на пересечении аналитики больших данных, искусственного интеллекта и распределенных вычислений. Проведенный анализ современных подходов и технологий позволяет сделать ряд ключевых выводов и наметить перспективные направления дальнейших исследований.

Современные алгоритмы выявления аномалий демонстрируют значительный прогресс в адаптивности, точности и вычислительной эффективности. Адаптивные методы, такие как STORM и MCODE, успешно справляются с проблемой дрейфа концепций в потоковых данных. Ансамблевые подходы, в частности LSAD и AE, повышают робастность детекции за счет комбинирования различных моделей. Применение глубокого обучения, особенно архитектур MemAE и LSTM-VAE, открывает новые возможности для выявления сложных нелинейных паттернов аномалий.

Обработка временных рядов в реальном времени требует специализированных подходов, учитывающих темпоральную структуру данных. Методы, основанные на прогнозировании, такие как Prophet и DeepAR, в сочетании с алгоритмами анализа временных последовательностей, например Matrix Profile, позволяют эффективно выявлять аномалии в динамически меняющихся временных рядах. Оптимизация производительности, достигаемая за счет использования аппроксимационных методов и инкрементальных обновлений, играет критическую роль в обеспечении работы систем в режиме реального времени.

Масштабируемость и распределенная обработка становятся ключевыми факторами при работе с большими объемами данных. Lambda-архитектура и современные фреймворки потоковой обработки, такие как Apache Flink и Spark Streaming, предоставляют мощную инфраструктуру для создания высокопроизводительных систем выявления аномалий. Алгоритмы федеративного обучения, в частности модифицированные версии FedAvg, открывают новые возможности для распределенного обнаружения аномалий с учетом требований конфиденциальности данных.

Потенциальные применения технологий выявления аномалий в реальном времени охватывают широкий спектр областей, включая мониторинг промышленных систем, финансовый сектор, здравоохранение, умные города и интернет вещей. По мере развития технологий 5G и edge computing ожидается дальнейшее расширение сферы применения этих методов, что потребует разработки еще более эффективных и адаптивных алгоритмов.

### Список литературы:

- 1.Chandola V., Banerjee A., Kumar V. Anomaly detection: A survey //ACM computing surveys (CSUR). – 2009. – Т. 41. – №. 3. – С. 1-58.
- 2.Liu F. T., Ting K. M., Zhou Z. H. Isolation-based anomaly detection //ACM Transactions on Knowledge Discovery from Data (TKDD). – 2012. – Т. 6. – №. 1. – С. 1-39.
- 3.Chalapathy R., Chawla S. Deep learning for anomaly detection: A survey //arXiv preprint arXiv:1901.03407. – 2019.
- 4.Yeh C. C. M. et al. Matrix profile I: all pairs similarity joins for time series: a unifying view that includes motifs, discords and shapelets //2016 IEEE 16th international conference on data mining (ICDM). – Ieee, 2016. – С. 1317-1322.
- 5.Taylor S. J., Letham B. Forecasting at scale //The American Statistician. – 2018. – Т. 72. – №. 1. – С. 37-45.
- 6.McMahan B. et al. Communication-efficient learning of deep networks from decentralized data //Artificial intelligence and statistics. – PMLR, 2017. – С. 1273-1282.
- 7.Warren J., Marz N. Big Data: Principles and best practices of scalable realtime data systems. – Simon and Schuster, 2015.
- 8.Bifet A., Gavalda R. Learning from time-changing data with adaptive windowing //Proceedings of the 2007 SIAM international conference on data mining. – Society for Industrial and Applied Mathematics, 2007. – С. 443-448.
- 9.Salinas D. et al. DeepAR: Probabilistic forecasting with autoregressive recurrent networks //International journal of forecasting. – 2020. – Т. 36. – №. 3. – С. 1181-1191.
- 10.Liu M., Wei S., Jiang P. A hybrid modeling of mobile app dynamics on serial causality for malware detection //Security and Communication Networks. – 2021. – Т. 2021. – №. 1. – С. 9994588.

**ФИЗИЧЕСКИЕ НАУКИ**

UDC 538.911, 935, 958, 975

**РОЛЬ МЕЖГРАНУЛЬНЫХ БАРЬЕРОВ В ФОТОЧУВСТВИТЕЛЬНОСТИ  
ПОЛИКРИСТАЛЛИЧЕСКИХ ПЛЕНОК ИЗ ТВЕРДОГО РАСТВОРА  $CdSe_xS_{1-x}$** *Мирзаев В.Т., Юлдашев Н.Х., Маматов О.М.**Ферганский политехнический институт, Fergana Polytechnic Institute,***ROLE OF INTERGRANULE BARRIERS IN PHOTOSENSITIVITY OF POLYCRYSTALLINE FILMS  
FROM  $CdSe_xS_{1-x}$  SOLID SOLUTION***Mirzaev V.T., Yuldashev N.Kh, Mamatov O.M.*

DOI: 10.31618/ESU.2413-9335.2024.1.122.2075

**АННОТАЦИЯ**

Экспериментально изучена люкс-амперная характеристика фоточувствительных поликристаллических пленок из твердого раствора  $CdSe_{0.8}S_{0.2}$ , полученных методом термического испарения в вакууме. Выполнен теоретический расчет, учитывающий внутренние поверхностно-граничные микропотенциальные барьеры, с помощью которой качественно удовлетворительно описаны результаты эксперимента.

**ABSTRACT**

The lux-ampere characteristic of photosensitive polycrystalline films from the solid solution  $CdSe_{0.8}S_{0.2}$  obtained by thermal evaporation in vacuum has been studied experimentally. A theoretical calculation has been performed, taking into account internal surface-boundary micropotential barriers, with the help of which the experimental results have been described qualitatively and satisfactorily.

**Ключевые слова:** фоторезистивная поликристаллическая пленка, твердый раствор  $CdSe_xS_{1-x}$ , термический отжиг, люкс-амперная характеристика, межзеренная граница, микропотенциальный барьер.

**Key words:** photoresistive polycrystalline film,  $CdSe_xS_{1-x}$  solid solution, thermal annealing, lux-ampere characteristic, intergrain boundary, micropotential barrier.

**Introduction.** In the manufacture of photoresistive semiconductor films, the main factor is the heat treatment process (HT), which can be used not only to achieve the desired degree of photosensitivity, but also to influence many electrophysical parameters and structures of films in a controlled manner [1-3]. Special technological methods for the production of photosensitive films from CdSe and  $CdSe_xS_{1-x}$ , including HT processes in vacuum and various media, are described in detail in [3-6]. The lux-ampere characteristic (LAC) of such films at low light intensities  $L \leq 10$  lux, unlike typical crystalline photoconductors made of cadmium chalcogenides with two deep levels [1] contains two characteristic sites with different slopes instead of one, and the temperature dependence of the dark conductivity reveals an anomalous character [4-6]. The causes of these phenomena are naturally related to the influence of the interface of crystalline grains on photoelectric and kinetic processes in polycrystalline semiconductor films [7-10]. The purpose of this work is to study

$CdSe_xS_{1-x}$  LAC films obtained using the technology [3-6], taking into account the internal surface-boundary micropotential barriers. The photoelectric properties of  $CdSe_xS_{1-x}$  solid solution films are purposefully easy to control over a wide range depending on the method, time, temperature HT and the relative content of chalcogens X.

**Methodology and experimental results.**

Electron microscopic and X-ray diffraction studies have shown that the grown layers have a polycrystalline columnar structure mainly with hexagonal modification. The sizes of the individual crystallites were 1-2.5 microns. Additional annealing of the films leads to a change in the structure of the surface and, especially, the intercrystalline regions. The correct cut of the vertices disappears, which acquire a rounded shape, and the columnar structure extends over the entire thickness of the film. According to Hall measurements, the films before and after HT had n-type electrical conductivity.




Fig.1. LAC of films  $CdSe_{0.8}S_{0.2}$ , sensed by the methods “vacuum +  $CdCl_2$ ” (1-3) and “air +  $CdCl_2$ ” (4) at  $T = 300$  (1, 4), 210 (2) and 350 (3) °C.

Figure 1 shows LAC films subjected to HT by different methods, which were shot at room temperature. Under the influence of incandescent lamp radiation. It can be seen that curves 1 and 4 LAC coincide qualitatively and contain four characteristic sections: linear – *ab* (weakly sensitive section) and *de* (highly sensitive section), sublinear *bc* and superlinear *cd*. However, the photosensitivity of a film heat-treated in pure vacuum (curve 1) in the entire range of light intensity values is almost an order of magnitude behind the photosensitivity of a film heat-sensitive in vacuum in the presence of  $CdCl_2$  vapors (curve 2). Note that

such a difference in the photosensitivity of films with increasing light intensity first increases in the *cd* "switching" region, and then decreases slightly in the *de* region. It is known [1] that typical LACs with *bc*, *cd*, and *de* sites detect both mono- and polycrystalline photoconductors containing two types of deep impurities: s- recombination centers and r-sensitizing centers. Other authors have not previously observed the initial linear section of *ab* LAC. To clarify the mechanisms of photoconductivity of the studied films, additional Hall measurements they carried out both in direct and alternating current at different temperatures.




Fig. 2. Dependences of the mobility (1, 2) and concentration (1', 2') of electrons on the light intensity for films  $CdSe_{0.8}S_{0.2}$  sensed by the methods "vacuum + CdCl<sub>2</sub>" (1, 1'), "air + CdCl<sub>2</sub>" (2, 2') and the dependence  $\mu$  (L) on a double logarithmic scale (dotted curve) for films that were sensed by the "air + CdCl<sub>2</sub>" method.

Figure 2 shows the dependences of the concentration of  $n(L)$  and the mobility of  $\mu(L)$  electrons on the light intensity  $L$  for films  $CdSe_{0.8}S_{0.2}$  at room temperature. As can be seen from the figure, in the range of light intensity values  $L \leq 10$  lux (section *ab* LAC in Fig.2), the electron concentration does not change (curves 1', 2'), and carrier mobility  $\mu$  increases significantly (curves 1,2) with increasing. This means that at relatively low light intensities, the recharge of r- and s-centers in the volume of crystalline grains is weak and does not cause photoconductivity, at the same time, intergranular potential barriers - drift barriers vary significantly and, naturally, lead to a change in carrier mobility. Consequently, the photoconductivity of thermally sensitive polycrystalline  $CdSe_xS_{1-x}$  films in the  $L \leq 10$  lux region is due to the rearrangement of surface barriers at the boundaries of crystallites. From curves 1' and 2' in Fig. 2. It is also seen that with a further increase in light intensity from a value of  $L \approx 10$  lux, the concentration of carriers begins to increase sharply in accordance with the cd LAC region (1,4 in Fig. 1), and their mobility tends to saturation. Thus, the high photosensitivity of the studied films is also due, as in CdSe single crystals, to the presence of semiconductor and s - centers in the volume, which are created by single and double-charged cadmium vacancies [1].

**Theory.** To accurately calculate the stationary photoconductivity of inhomogeneous samples, it is necessary to solve a system of kinetic equations and Poisson equations for the spatial charge region near the crystallite boundary using, firstly, the equations of

integral neutrality (charge balance during carrier exchange between the quasi-neutral volume of a crystalline grain and its surface) as boundary conditions, and secondly, the equations of generation-recombination balance sheet (see, for example, [2] equations (2.1) – (2.6) and (4.2), (4.3)). However, such a rigorous approach for polycrystalline samples is quite time-consuming and it is not always possible to physically interpret the theoretical results obtained. Therefore, the photoconductivity of homogeneous photoresistors is described using either a concentration (n-) or barrier ( $\mu$ -) mechanism, depending on which changes more strongly - the concentration or mobility of carriers of one sign under the influence of illumination. When the photosensitive films under consideration are illuminated, electron-hole pairs are generated in the volume of crystallites and the concentration of free charge carriers increases, and a potential difference arises between the volume of the crystallite and its surface<sup>1</sup>, as a result, the height of the intercrystalline (drift) barriers decreases and, consequently, the mobility of the main carriers increases.

Obviously, both processes lead to a change in the electrical conductivity of the films under the influence of lighting. The LAC of a photoresistor with three levels in the band gap of a semiconductor, due to a change in the concentration of free electrons ( $n$  is the photoconductivity mechanism), can be obtained from the equations of kinetics of electronic transitions (from the conditions of detailed equilibrium in the stationary

<sup>1</sup> Despite this process, there is no noticeable photo-EMF in the film along the propagation of light, since the signs of the

barrier photo-EMF at the boundaries of neighboring symmetrical crystallites are opposite.

case) with their addition by the equation of electron neutrality of the semiconductor volume [1]

$$L = \gamma_{ns}n(n + m) \frac{\gamma_{nr}n + g_s\gamma_{pr}N_{vr}}{n(g_r\gamma_{ns} + g_s\gamma_{nr}) + g_s\gamma_{ps}N_{vr}}, (1)$$

here

$$g_r = \frac{\gamma_{pr} \cdot r}{\gamma_{pr} \cdot r + \gamma_{ps} \cdot s}, g_s = \frac{\gamma_{ps} \cdot s}{\gamma_{pr} \cdot r + \gamma_{ps} \cdot s}, N_{vr} = N_v \exp(-E_{vr}/kT), N_v = 2 \left[ \frac{2\pi m_p^* kT}{h^2} \right]^{\frac{3}{2}},$$

$\gamma_{pi}, \gamma_{ni}$  - hole and electron capture coefficients  $i$  - centers,  $r, s, m$  - concentrations of electrons trapped  $r$ -,  $s$ -,  $m$ - levels, respectively,  $n$  - the concentration of free electrons (the  $m$ -level is created by small donors, for example, Cl atoms). It can be seen from expression (1) that for  $n \ll m = \text{const}$  for high light intensities, when  $\gamma_{pr}N_{vr}, \gamma_{ps}N_{vr} \ll \gamma_{nr} \cdot n$  The LAC is linear, which corresponds to a highly sensitive section of the de curves 1 and 4 in Fig.1. If the vacancy concentration in the recombination centers does not depend on  $n$  [1],

then in the intermediate intensity region, formula (1), in accordance with curves 1 and 4, describes a superlinear LAC, which is extended by no more than one order of magnitude of the change in light intensities. It also follows from (1) that LAC is linear in the region of low light intensities, and in the experiment in a relatively large region of light intensity it is sublinear with an index  $\alpha=0.5$ . On the other hand, if LAC, due to the concentration of electrons, is approximated in some area of intensity using the function

$$n^* = n_0(1 + AL^\beta), (2)$$

$$\text{where } \beta = \frac{L}{n} \left[ \frac{dn}{dL} \right]^{-1} (3)$$

$n = n^* - n_0$  - Concentration of photo carriers, as can be seen from Fig.2 (curve  $n(L)$ )  $\beta \approx 0$  in the region of low light intensities. This means that at low excitation intensities in the studied photoresistors, instead of the - mechanism, it is necessary to consider the - mechanism, i.e. the barrier mechanism of photoconductivity.

surface bending of energy zones at the boundaries between two crystalline grains of a polycrystal. For simplicity, we assume that the bipolar diffusion length of charge carriers exceeds the Debye shielding length  $L_D = \left( \frac{\epsilon\epsilon_0 kT}{2e^2 n} \right)^{1/2}$ , then the photo-EMF of the Damper will not lead to a change in the height of the barriers, therefore we neglect it.

The barrier photo-EMF, which occurs due to the movement of excess charge carriers in different directions in the area of energy barriers, lowers the initial height of the barriers. The difference between the height of the barrier before and after illumination is a barrier photo-EMF. An example of such a barrier is the

As is known, the Hall mobility of electrons in samples with drift barriers is determined by the expression:

$$\mu = \mu_0 \exp\left(\frac{-E_\mu}{kT}\right), (4)$$

where  $\mu_0$ - Hall mobility in a homogeneous sample;  $E_\mu$ - the height of the drift barriers.

Suppose that the LAC of a photoresistor caused by a change in the height of the barriers can be represented as

$$\mu^* = \mu(1 + BL_{\square}^Y), (5)$$

where  $\mu$  - the Hall mobility of equilibrium electrons, determined from (4), B is a constant value independent of  $L$ . When comparing (4) and (5), it can be seen that the change in the height of the drift barriers

in this case logarithmically depends on the light intensity

$$\Delta E_\mu(L) = kT \ln(1 + BL_{\square}^Y). (6)$$

At the same time, for the barrier indicator LAC  $\gamma$  we obtain the expression

$$\gamma = \frac{L}{1 - \exp\left[\frac{-\Delta E_\mu(L)}{kT}\right]} \cdot \frac{1}{kT} \cdot \frac{d\Delta E_\mu(L)}{dL}. (7)$$

To obtain an analytical expression for  $\Delta E_\mu(L)$  taking into account the recombination processes in the quasi-neutral volume, SCR and on the surface of crystalline grains, as well as the redistribution of charge on the surface and between volume levels, very cumbersome mathematical calculations are required.

$$\Delta E_\mu(L) = kT \ln \left[ 1 + \frac{n_0}{p_0} f(L) \right], \quad (8)$$

$$\text{where } f(L) = -\frac{1}{2} \left( 1 + \frac{v_0}{v_s} \exp(E_\mu/kT) \right) + \left[ \frac{1}{4} \left( 1 + \frac{v_0}{v_s} \exp(E_\mu/kT) \right)^2 + \frac{k\eta L}{v_0 n_0} \exp(E_\mu/kT) \right]^{\frac{1}{2}} \quad (9)$$

$n_0, p_0$  – equilibrium concentrations of electrons and holes in the crystallite volume;  $v_0 = D\delta n/L_D$  – the rate of recombination in a quasi-neutral volume,  $v_s = \gamma_{nt} N_t$ ;  $\gamma_{nt}, N_t$  – the capture coefficient for electrons and the concentration of surface traps;  $k, \eta$  – is the light absorption coefficient and the internal quantum yield.

It can be seen from (5)-(9) that at very low light intensities, the Hall mobility of electrons, indeed, it varies according to the power law with  $\gamma=1$ , i.e. in this case  $B = \frac{k\eta v_s}{p_0 v_0} \cdot [v_s \exp(-E_\mu/kT) + v_0]^{-1}$  the LAC is linear. At the same time, the height of the barrier

In [1], the calculation was performed  $\Delta E_\mu(L)$  for the surface barrier, neglecting the recharge of volumetric levels in the SCR under the influence of lighting during inversion bends of the zones ( $\frac{E_\mu}{kT} \gg 1$ ), when a single discrete level of the acceptor type acts effectively on the surface, which exchanges carriers mainly with the valence band:

decreases significantly with growth and, consequently, mobility increases dramatically (cf. section ab of curves 1 and 4 LAC in Fig.1 and dependence in Fig.2). With a further increase in light intensity, the indicator quickly reaches the value  $\gamma = 0.5$  (at the same time  $B = \left( \frac{k\eta n_0}{v_0 \beta_0^2 / p_0^2} \right)^{1/2} \cdot \exp(E_\mu/2kT)$ ). This theoretical result is also confirmed by experiment (the bc section of curves 1 and 4 LAC in Fig.1).

Based on (2) and (5), i.e. taking into account simultaneously  $n$  - and  $\mu$  - the mechanisms of photoconductivity, calculate the multiplicity of changes in the resistance of the longitudinal photoresistor

$$K = \frac{R_0}{R} = \beta \kappa d (1 + BL^\gamma) \left[ \ln \frac{AL^\beta + \exp(\beta \kappa d)}{AL^{\beta+1}} \right]^{-1}. \quad (10)$$

**Discussion of the results.** According to the experimental and theoretical results obtained above, on LAC optimally sensitized longitudinal photoresistors, regardless of the HT method, according to the value of the LAC indicator  $\alpha = \beta + \gamma$  The following characteristic ranges of values of the intensity of the exciting light can be distinguished:

- I. a)  $0 < L \leq L_1' \approx 1Lux$ , where  $\alpha = \gamma \cong 1$ ;  $\beta = 0$  (region *ab* LAC in Fig.1);
- б)  $L_1' \leq L \leq L_1 \approx 10Lux$ , where  $\alpha = \gamma \cong 0.5$ ;  $\beta = 0$  (region *bc* LAC).

In this case, from (10) we get

$$K = K_\mu = 1 + BL^\gamma. \quad (11)$$

In this relatively weak photosensitive LAC region, the barrier mechanism of photoconductivity completely dominates. The reason for the absence of the  $n(L)$  dependence seems to be the superiority of surface recombination of nonequilibrium carriers over bulk or exceptionally good carrier exchange between surface and bulk levels.

II.  $L_1 \leq L \leq L_2 \approx 10^2Lux$ , where according to Fig.1  $\alpha \approx 3.5, \beta \approx 3.0, \gamma \approx 0.5$ , (region *cd* LAC). If the following conditions are met  $BL^\gamma \gg 1$  и  $AL^\beta \gg 1, \exp(\beta \kappa d)$ , then from (10) we have

$$K = K_\mu \cdot K_n = BL^\gamma \beta \kappa d \frac{AL^\beta}{\exp(\beta \kappa d)} \sim L^\alpha. \quad (12)$$

In this superlinear section of LAC, the  $r$  and  $i$  centers of the semiconductor are recharged, as a result of which, as the light intensity increases, the contribution of the concentration mechanism of photoconductivity increases sharply and at the end of

this region it exceeds the contribution due to the  $\mu$  - mechanism.

III.  $L > L_2$ , where  $\alpha = \beta \cong 1; \gamma = 0$  (region *de* LAC). Here, according to (10), the multiplicity of  $K$  can be expressed by the following formula:

$$K = K_{II} 0_{max}, \quad (13)$$

where  $K_{II,max} = 3AB\kappa d L_2^{7/2} / \exp(3\kappa d)$  - the maximum value of  $K$  on the site *cd* ( $\alpha_2 = \beta_2 + \gamma_2$ ),  $K_0 = A\kappa d(L - L_2) \cdot \exp(-\kappa d)$ .

It can be seen from the latest formulas that at high light intensities, when  $L > L_2$ , the multiplicity of the photoconductivity of the film  $K$  is equal to the product

of multiplicities due to changes in barriers  $K_\mu$  and concentration  $K_n$  free charge carriers, and in accordance with Fig.1, the proportion of the barrier mechanism increases with L  $K_\mu = K_{II,\mu} = BL_2^{\beta_2}$  it remains unchanged, but  $K_n = \frac{K_{II,max}}{K_{\mu_0}}$

It depends linearly on the light intensity. If in formula (10) we put  $\beta=1$  и  $\gamma=0$ ,  $B=0$  (i.e.  $\Delta\mu=0$ ), then it boils down to the formula obtained in [11], which is valid for homogeneous samples.

**Conclusion.** The theoretical analysis of LAC photosensitive polycrystalline films  $CdSe_{0.8}S_{0.2}$  carried out here is qualitative and phenomenological in nature and satisfactorily describes the main features of the experiment. It can be developed by more accurate quantitative calculations of the photoconductivity of polycrystals with a specific model of impurity centers in SCR and on the surface of microcrystals.

### Literature

- [1]. Lashkarev V.S., Lyubchenko L.K., Sheinkman M.K. Nonequilibrium processes in semiconductors. – Kiev.: Naukova dumka, 1981. - 270 p.
- [2]. Zuev A.L., Sachenko V.B., Tolpygo K.B. Nonequilibrium processes on the surface of semiconductors. - M.: Energiya, 1979. – 178 p.
- [3]. Ergashev Zh., Yuldashev N.H. Photoelectric effect in semiconductor film structures. Monograph. "Technika", Ferghana-2017, 180 p.
- [4]. Ayibzhanov M., Karimov M.A., Saidov M.S., Yuldashev N.Kh. Anomalous temperature dependence and infrared quenching of equilibrium conductivity in polycrystalline CdSe films // Physics and Technology of semiconductors-St. Petersburg. 1996.-№9 (30).- Pp. 1578-1584.
- [5]. Yuldashev, N.Kh., Mamadiyeva, D.T., Mirzaev, V.T. and Xidirov, D.Sh. (2022) Effect of Heat Treatment Conditions on Photo sensitivity of CdSe<sub>x</sub>S<sub>1-x</sub> Polycrystalline Films. Journal of Applied Mathematics and Physics, 10, 3208-3217. <https://doi.org/10.4236/jamp.2022.1010213>
- [6]. Karimov M.A., Yuldashev N.H. The role of the grain interface in the lux-ampere characteristic of a polycrystalline film of a solid solution CdSe<sub>x</sub>S<sub>1-x</sub> // Surface. X-ray synchrotron and neutron research - Moscow . 2006. - No. 5. - pp.88-92.
- [7]. Abbas, N.K., Naji, I.S., Abdulmajeed, A.A. (2013) Electrical Properties of Thermally Evaporated CdSe<sub>x</sub>S<sub>1-x</sub> Thin Films. International Review of Physics (IREPHY). 7. 70-75.
- [8]. Trofimov, Y.V., et al. (2012) Physicochemical Features of Dielectrical Nano-Barrier Layers in CdSe<sub>x</sub>S<sub>1-x</sub> Films Formed by Screen Printing Method. Lithuanian Journal of Physics, 52, 219-223. <https://doi.org/10.3952/physics.v52i3.2473>
- [9]. Abidinov, A.Sh Jafarov, M.A., Mammadova, S.A. (2006) Relaxation of photoconductivity of chemically deposited CdSe<sub>1-x</sub>Tex films. Baku State University.: "Physics and Astronomy", 2, 95-98.
- [10]. Meshkov, A.S., Ostretsov, E.F., Pogosov, W.V., Ryzhikov, I.A. and Trofimov. Yu.V. (2008) Photoconductivity of CdS-CdSe Granular Films: Influence of Microstructure. Semiconductor Science and Technology, 25, Article ID: 065013. <https://doi.org/10.1088/0268-1242/25/6/065013>
- [11]. Vdovenkov A.A., Krolevets K.M., Komashko V.A., Skarzhevskaya E.P. Investigation of the longitudinal mode of operation of film photoresistors // Microelectronics / Collection of scientific papers – Moscow, 1978. -No.5. - pp. 296-309.

# ТЕХНИЧЕСКИЕ НАУКИ

## ОПТИМИЗАЦИЯ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ

*Дюкарев Владимир Витальевич*

*Руководитель направления, Департамент противодействия мошенничеству, Сбербанк*

*Старухин Ярослав Алексеевич*

*Москва, РФ*

*Senior Data scientist, McKinsey & Company, Boston, USA*

## OPTIMIZATION OF MACHINE LEARNING ALGORITHMS FOR TIME SERIES FORECASTING

*Vladimir Diukarev*

*Head of Data Analytics, Anti-Fraud Department, Sberbank*

*Moscow, Russian Federation*

*Yaroslav Starukhin*

*Senior Data scientist, McKinsey & Company, Boston, USA*

*DOI: 10.31618/ESU.2413-9335.2024.1.122.2076*

### АННОТАЦИЯ

Статья фокусируется на оптимизации алгоритмов машинного обучения для анализа и прогнозирования временных рядов, что имеет критическое значение в различных областях, от финансов до метеорологии. В работе подробно рассматриваются методы машинного обучения, включая рекуррентные нейронные сети и глубокое обучение, и их применение для анализа данных, изменяющихся со временем. Основное внимание уделяется адаптивным моделям, которые могут учитывать временные изменения и сезонные колебания. Разработка и оптимизация этих моделей предполагают использование техник управления скоростью обучения и ранней остановки для повышения точности прогнозирования. Особое внимание уделяется автоматизированному машинному обучению (AutoML), которое облегчает разработку и валидацию моделей, автоматизируя рутинные аспекты и позволяя специалистам сосредоточиться на более сложных задачах.

### ANNOTATION

The article focuses on optimizing machine learning algorithms for time series analysis and forecasting, which is of critical importance in various fields, from finance to meteorology. The paper discusses in detail machine learning methods, including recurrent neural networks and deep learning, and their application to analyze data that changes over time. The focus is on adaptive models that can account for temporal changes and seasonal fluctuations. The development and optimization of these models involve the use of learning rate control and early stop techniques to improve prediction accuracy. Special attention is paid to automated machine learning (AutoML), which facilitates the development and validation of models, automating routine aspects and allowing specialists to focus on more complex tasks.

**Ключевые слова:** машинное обучение, алгоритмы машинного обучения, искусственный интеллект, ИИ, современные технологии.

**Keywords:** machine learning, machine learning algorithms, artificial intelligence, AI, modern technologies.

### Введение

Анализ временных рядов представляет собой изучение последовательностей данных, которые организованы во временной последовательности. Этот метод анализа занимает центральное место в области машинного обучения, поскольку он способствует выявлению шаблонов, которые могут быть не очевидными при первичной оценке данных. В частности, в сфере финансов такие закономерности могут служить основой для прогнозирования будущих событий на основе анализа исторических данных.

В контексте машинного обучения, анализ временных рядов используется для изучения и моделирования данных, изменяющихся с течением времени. Это может включать, например, акции, экономические показатели или климатические данные. Модели, основанные на временных рядах, способны предсказывать будущие изменения,

опираясь на прошлые и текущие данные. К примеру, такие модели могут спрогнозировать изменение стоимости акций или определить периоды пикового спроса на определённые товары.

Тема прогнозирования является актуальной, так как получение наиболее точного прогноза будущего позволяет принимать наиболее выгодные решения для достижения положительных результатов в любой сфере человеческой деятельности, в том числе, финансовой. Например, точное прогнозирование может увеличить доходы компаний на 10-20% за счет более точного планирования и оптимизации ресурсов. Что в свою очередь обусловлено тем, что в последние годы значительно повысилась эффективность автоматизированного машинного обучения (AutoML), особенно систем автоматизированного глубокого обучения (AutoDL), но недавние работы сосредоточены на задачах с таблицами,



изображениями или NLP. До сих пор мало внимания уделялось общим фреймворкам AutoDL для прогнозирования временных рядов, несмотря на огромный успех в применении различных новых архитектур к таким задачам [1].

Целью данной работы является рассмотрение процесса и возможностей оптимизации алгоритмов машинного обучения для прогнозирования временных рядов.

### 1. Анализ временных рядов

Анализ временных рядов является частью статистического анализа и использует уникальные методы, основанные на динамической природе временных последовательностей. Важные аспекты анализа временных рядов включают исследование наличия трендов, периодических закономерностей и стационарности данных.

В отличие от других видов статистического анализа, таких как описательный, прогнозный и предписывающий анализ, временные ряды требуют учета их уникальных характеристик:

- Временные ряды по своей природе являются последовательностями с определенной временной

структурой, что делает их нестатичными и требует особого подхода к анализу динамики данных.

- Значения во временных рядах связаны с предыдущими наблюдениями, что создает сложности при анализе трендов, сезонных колебаний и аномалий.

В контексте временных рядов пропущенные значения могут образовывать временные пробелы, что представляет собой проблему для традиционных методов импутации данных, используемых в статическом анализе.

На графических представлениях временных рядов эти пробелы видны как разрывы в последовательности данных (рис. 1), что подчеркивает трудности логического заполнения пропусков с помощью обычных методов восстановления данных, применяемых к статическим данным. Такие проблемы требуют специализированных подходов и алгоритмов, что подчеркивает необходимость адаптации методов машинного обучения для работы с динамичными, временно-структурированными данными.




Рис.1. Пример пробелов в временных рядах [8].

В свою очередь в области прогнозирования временных рядов, используются три ключевых метода: стационарность, автокорреляция и спектральный анализ.

Стационарность временного ряда представляет собой фундаментальное свойство, характеризующееся инвариантностью статистических моментов первого и второго порядка во времени. Данное свойство существенно упрощает процедуры анализа и прогнозирования. Нестационарные процессы, в свою очередь, могут демонстрировать различные формы динамики, включая детерминированные тренды, циклические колебания и сезонные вариации.

Для верификации гипотезы о стационарности временного ряда применяется комплекс графических методов. К ним относятся: временной график, отображающий динамику ряда; график автокорреляционной функции, демонстрирующий зависимость между значениями ряда в различные

моменты времени; и график частной автокорреляционной функции, отражающий эту зависимость при элиминировании влияния промежуточных наблюдений.

Автокорреляция, определяемая как степень зависимости между значениями ряда, разделенными временными интервалами, играет ключевую роль в анализе временных рядов. Высокие значения автокорреляции свидетельствуют о наличии сильной внутренней структуры ряда. Для квантификации автокорреляции применяется корреляционная функция Пирсона, вычисляемая для различных временных лагов. Статистически значимая автокорреляция может указывать на присутствие в ряде долгосрочных тенденций, циклических компонент или сезонных паттернов.

Спектральный анализ представляет собой метод декомпозиции временного ряда на частотные составляющие. Данный подход позволяет

идентифицировать периодические компоненты в структуре ряда, что особенно эффективно для выявления скрытых циклических паттернов [2].

В контексте анализа временных рядов особое значение приобретают модели, способные описать последовательную зависимость элементов ряда. Среди таких моделей выделяются авторегрессионные модели и модели скользящего среднего, каждая из которых обладает уникальными характеристиками и областями применения.

Авторегрессионная модель (AR) описывает временной ряд, в котором текущее значение зависит от предыдущих наблюдений. Математически это выражается уравнением:

$$x_t = \alpha + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \phi_3 x_{t-3} + \dots + \epsilon_t$$

где  $\alpha$  представляет константу (свободный член),  $\phi_i$  - параметры авторегрессии, а  $\epsilon_t$  - стохастическую компоненту. Данное уравнение демонстрирует, что каждое наблюдение есть результат суперпозиции случайной компоненты и линейной комбинации предшествующих наблюдений.

Стационарность процесса авторегрессии обусловлена определенными ограничениями на параметры модели. В частности, для модели первого порядка AR(1) необходимо соблюдение условия  $|\phi| < 1$ . При нарушении данного условия возникает кумулятивный эффект, приводящий к нестационарности ряда. Для моделей высших порядков существуют аналогичные, но более сложные условия стационарности.

В противоположность модели AR, модель скользящего среднего (MA) предполагает зависимость текущего значения ряда от предыдущих ошибок прогноза. Формально это выражается уравнением:

$$x_t = \mu + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \theta_3 \epsilon_{t-3} - \dots$$

где  $\mu$  - константа, равная среднему значению ряда,  $\epsilon_t$  - текущая ошибка,  $\epsilon_{t-i}$  - ошибки в предыдущие моменты времени, а  $\theta_i$  - параметры модели скользящего среднего. Таким образом, текущее значение ряда формируется как сумма стохастической компоненты и взвешенной суммы предыдущих случайных воздействий.

Между процессами AR и MA существует фундаментальная связь, известная как "двойственность". Это свойство позволяет преобразовывать уравнение MA в уравнение AR бесконечного порядка и наоборот. Данный феномен известен как обратимость модели. Аналогично условиям стационарности, существуют специфические условия обратимости для моделей MA.

В прикладном аспекте анализа временных рядов часто возникает необходимость оценки влияния экзогенных событий на динамику ряда.

Такие задачи включают в себя оценку эффективности экономических политик, изменений в законодательстве или других дискретных событий. Методология интервенционного анализа позволяет количественно оценить воздействие одного или нескольких дискретных событий на значения временного ряда, что имеет существенное значение для принятия управленческих решений и оценки эффективности различных мер [3].

## 2. Применение машинного обучения

Применение машинного обучения (МО) в контексте прогнозирования временных рядов представляет собой значительный прогресс по сравнению с традиционными статистическими методами. Модели машинного обучения, способные улавливать сложные закономерности и взаимосвязи в данных, обеспечивают надежную основу для повышения точности прогнозирования [4].

В области анализа временных рядов прогнозирование будущих значений остается одной из ключевых задач. Как отметил известный статистик Джордж Бокс, "все модели неверны, но некоторые полезны". Эта мысль точно отражает суть работы с временными рядами, где постоянно приходится искать баланс между сложностью модели и её практической применимостью.

Регрессионные модели, несмотря на кажущуюся простоту, продолжают играть важную роль в анализе данных. Линейная регрессия, например, обладает преимуществом легкой интерпретируемости результатов, что критично в ряде прикладных задач. При необходимости учета нелинейных зависимостей используется полиномиальная регрессия, позволяющая уловить более сложные паттерны в данных.

Развитие алгоритмов на основе деревьев решений привело к появлению ансамблевых методов, таких как Random Forests и Gradient Boosting Machines. Эти методы существенно повышают точность прогнозов, комбинируя результаты множества базовых моделей. Подобный подход можно сравнить с группой экспертов, каждый из которых дает свой прогноз, а затем формируется "усредненное мнение". Практика показывает, что такой метод часто превосходит по эффективности более сложные единичные модели.

Нейронные сети открыли новые горизонты в прогнозировании временных рядов. Особого внимания заслуживают рекуррентные архитектуры, такие как LSTM (Long Short-Term Memory), способные эффективно обрабатывать долгосрочные зависимости в данных. Интересным примером адаптации нейросетевых архитектур является модель Seq2Seq, изначально разработанная для задач машинного перевода, но нашедшая успешное применение и в прогнозировании временных рядов [5,6].




Рис. 2. Seq2Seq с RNN-кодером и декодером

Однако, эффективность любого алгоритма во многом зависит от качества входных данных. Здесь ключевую роль играет инженерия признаков - область, требующая как технических навыков, так и глубокого понимания предметной области. Создание лаговых переменных, расчет скользящих статистик, учет сезонности - все эти методы помогают "подсказать" модели, на какие аспекты данных следует обратить внимание.

Важно отметить, что увеличение количества признаков не всегда ведет к улучшению модели. В практике анализа данных нередко случается, когда избыточное количество признаков приводит к переобучению модели. Для решения этой проблемы применяются методы отбора признаков, такие как рекурсивное исключение или Lasso-регуляризация, помогающие выделить наиболее информативные предикторы.

Процесс прогнозирования временных рядов с использованием методов машинного обучения представляет собой многоэтапную процедуру, каждый шаг которой критически важен для создания эффективной модели.

Начальным этапом служит предварительная обработка данных. На этой стадии исследователи сталкиваются с необходимостью решения ряда задач: обработка пропущенных значений, идентификация и корректировка выбросов, а также нормализация или стандартизация временного ряда. Качество выполнения этих операций напрямую влияет на точность и надежность конечной модели. Как однажды заметил известный статистик Джон Тьюки, "Данные могут быть грязными, но не должны быть грязными настолько, чтобы это мешало анализу".

Следующий этап - разделение данных на обучающую и тестовую выборки - требует особого внимания при работе с временными рядами. Сохранение хронологической структуры данных является ключевым фактором. Для этого обычно

применяются специализированные методы, такие как перекрестная проверка по времени, позволяющие более точно оценить способность модели прогнозировать будущие значения.

Далее происходит настройка гиперпараметров модели. Для этого исследователи прибегают к различным методам: от простого поиска по сетке до более сложных подходов, таких как случайный поиск или байесовская оптимизация. Цель этого этапа - найти такую конфигурацию модели, которая минимизирует ошибку прогнозирования, не приводя при этом к переобучению.

В свою очередь оценка эффективности моделей временных рядов требует использования специфических метрик. Основными из которых являются: средняя абсолютная ошибка (MAE), среднеквадратичная ошибка (RMSE) и средняя абсолютная процентная ошибка (MAPE) - каждая из этих метрик имеет свои особенности и области применения. Поэтому выбор конкретной метрики будет зависеть от специфики решаемой задачи и характера данных.

Для дальнейшей оптимизации моделей также применяются различные стратегии. Так, например, ансамблирование моделей позволяет повысить надежность прогнозов путем комбинирования результатов нескольких алгоритмов. Регуляризация, в частности методы L1 (Lasso) и L2 (Ridge), помогает бороться с переобучением.

В целом, применение методов машинного обучения в прогнозировании временных рядов демонстрирует значительные преимущества по сравнению с традиционными подходами. Однако, как и любой метод, машинное обучение в этой области имеет свои ограничения, которые необходимо учитывать при выборе подхода к решению конкретной задачи прогнозирования. Подробный анализ преимуществ и ограничений представлен в таблице 1.

Таблица 1.

**Преимущества и ограничения машинного обучения в прогнозировании временных рядов [5]**

Преимущества	Ограничения
Способность обрабатывать большие объемы данных, значительно превосходящие возможности ручного анализа	Уязвимость к непредсказуемым событиям, которые могут существенно снизить точность прогнозов
Повышение точности и эффективности прогнозирования рыночных изменений и оптимизации инвестиционных стратегий	Необходимость в обширных и качественных исторических данных, что может быть проблематично при ограниченном доступе к информации
Быстрая адаптация к изменениям рыночной среды благодаря способности переобучаться на новых данных	Риск переобучения модели, особенно при работе с ограниченными или зашумленными данными
Возможность выявления сложных нелинейных зависимостей и скрытых паттернов в данных	Сложность интерпретации результатов некоторых сложных моделей, что может затруднить их практическое применение
Автоматизация процесса прогнозирования, снижающая влияние человеческого фактора и субъективности	Высокие требования к вычислительным ресурсам, особенно для сложных моделей глубокого обучения

**3. Автоматизированное машинное обучение (AutoML)**

Появление AutoML можно рассматривать как естественный этап эволюции в области машинного обучения. По мере того как алгоритмы становились все сложнее, а данные - все объемнее, исследователи начали задаваться вопросом: можем ли мы автоматизировать сам процесс создания моделей? Этот вопрос лежит в основе парадоксальной идеи использования машинного обучения для оптимизации машинного обучения.

Ранние подходы к AutoML фокусировались на оптимизации гиперпараметров, используя методы вроде случайного поиска или байесовской оптимизации. Однако вскоре стало ясно, что этого недостаточно. Выбор алгоритма, предобработка данных, инжиниринг признаков - все эти этапы требовали не менее тщательной оптимизации.

Здесь процесс сталкивается с фундаментальной проблемой: как формализовать процесс, который традиционно полагался на интуицию и опыт эксперта? Это не просто технический вызов, но и философский вопрос о природе человеческого понимания и возможности его алгоритмизации.

Развитие AutoML шло параллельно с прогрессом в области метаобучения. Идея заключалась в том, чтобы учиться не только на данных конкретной задачи, но и на опыте решения множества предыдущих задач. Это привело к созданию систем, способных "понимать"

характеристики датасетов и выбирать подходящие модели и параметры на основе этого понимания.

Однако настоящий прорыв произошел с появлением эволюционных подходов к AutoML, ярким представителем которых является FEDOT. Этот фреймворк представляет собой качественно новый уровень автоматизации, где оптимизируется не просто выбор модели или настройка параметров, а вся структура процесса обработки данных и моделирования.

FEDOT реализует концепцию "композитного AutoML", где каждое решение представлено в виде графа операций. Этот подход имеет глубокие корни в теории эволюционных вычислений и системной биологии. Подобно тому, как в природе сложные организмы эволюционируют путем комбинирования и модификации более простых "строительных блоков", в FEDOT сложные модели создаются путем эволюционной оптимизации графов, состоящих из элементарных операций обработки данных и моделирования.

Ключевая инновация FEDOT заключается в его способности к многоцелевой оптимизации. В реальных задачах редко бывает достаточно оптимизировать только точность модели. Часто приходится балансировать между точностью, вычислительной эффективностью, интерпретируемостью и другими факторами. FEDOT решает эту проблему, используя концепцию Парето-оптимальности, что позволяет находить не одно "лучшее" решение, а множество решений, оптимальных по разным критериям.




Рис.3. Пример составления таблицы с признаками для прогнозирования временного ряда [8].

Особенно интересен подход FEDOT к работе с временными рядами. Здесь фреймворк не просто применяет стандартные методы, а позволяет эволюционировать специализированные структуры, учитывающие временную природу данных. Например, операция "lagged" автоматически встраивается в оптимальное место в графе обработки, а ее параметры (такие как размер окна) оптимизируются вместе со всей структурой модели.

Однако, несмотря на все достижения, AutoML и FEDOT в частности сталкиваются с серьезными вызовами. Один из них - проблема интерпретируемости. Как объяснить решения, принимаемые сложной, автоматически сгенерированной моделью? Это не просто технический вопрос, но и этическая проблема, особенно в контексте применения таких моделей в критически важных областях.

Другой вызов связан с вычислительной сложностью. Эволюционные алгоритмы, лежащие в основе FEDOT, требуют значительных вычислительных ресурсов. Как найти баланс между глубиной поиска и практической применимостью? Этот вопрос становится особенно актуальным в эпоху "зеленого ИИ", когда экологический аспект вычислений выходит на первый план.

В заключение стоит отметить, что развитие AutoML и таких систем как FEDOT знаменует собой новый этап в эволюции искусственного интеллекта. Наблюдается переход от создания алгоритмов, решающих конкретные задачи, к созданию метаалгоритмов, способных автоматически генерировать решения для широкого спектра проблем. Это приближает к идее "общего искусственного интеллекта", способного адаптироваться к различным задачам без явного программирования.

Одновременно это ставит глубокие философские вопросы о природе интеллекта и творчества. Может ли автоматизированная система действительно заменить человека-исследователя? Или роль человека просто смещается на более высокий уровень абстракции? Эти вопросы остаются открытыми, и их решение, вероятно, будет определять направление развития

искусственного интеллекта в ближайшие десятилетия.

#### 4. Практическая реализация

В данном разделе будет рассмотрено практическое применение фреймворка FEDOT для автоматического построения и оптимизации моделей машинного обучения. Он предоставляет мощный инструментарий для работы с временными рядами, позволяя эффективно решать задачи прогнозирования.

Процесс реализации начинается с подготовки данных. В данном случае для демонстрации возможностей FEDOT будем использовать набор данных о трафике автомагистрали, содержащий почасовые значения объема трафика. Первым шагом является загрузка и предварительная обработка данных:

```
import pandas as pd
from sklearn.preprocessing import StandardScaler
# Загрузка данных
data = pd.read_csv('ts_traffic.csv')
# Масштабирование данных
scaler = StandardScaler()
data['value'] = scaler.fit_transform(data[['value']])
# Сохранение обработанных данных
data.to_csv('processed_ts_traffic.csv',
index=False)
```

После подготовки данных переходим к настройке задачи прогнозирования. FEDOT требует четкого определения типа задачи и параметров прогнозирования:

```
from fedot.api.main import Fedot
from fedot.core.repository.tasks import Task,
TaskTypeEnum, TsForecastingParams
from fedot.core.data.data import InputData
from fedot.core.data.data import InputData
train_test_data_setup
# Определение задачи и горизонта
прогнозирования
forecast_length = 144
task = Task(TaskTypeEnum.ts_forecasting,
TsForecastingParams(forecast_length=forecast_l
ength))
# Загрузка обработанных данных
```

```
input_data = InputData.from_csv_time_series(task,
'processed_ts_traffic.csv', target_column='value')
```

Важным этапом является корректное разделение данных на обучающую и тестовую выборки. Для временных рядов это особенно критично, так как необходимо сохранить временную структуру данных:

```
# Разделение на обучающую и тестовую
выборки
train_data, test_data = train_test_data_setup(input_data)
```

После переходим к созданию и настройке модели. FEDOT использует эволюционные алгоритмы для автоматической оптимизации архитектуры модели и ее гиперпараметров:

```
# Инициализация модели
model = Fedot(problem='ts_forecasting',
task_params=task.task_params, timeout=10,
n_jobs=-1)
# Обучение модели
chain = model.fit(features=train_data)
# Получение прогноза
```

```
forecast = model.predict(features=test_data)
# Обратное преобразование прогноза
forecast_values = scaler.inverse_transform(forecast.predict.reshape
(-1, 1))
```

Для оценки качества модели и наглядного представления результатов важно визуализировать полученный прогноз:

```
import matplotlib.pyplot as plt
plt.figure(figsize=(10, 5))
plt.plot(test_data.idx,
scaler.inverse_transform(test_data.target.reshape(-1,
1)), label='Actual', color='blue')
plt.plot(test_data.idx, forecast_values,
label='Forecast', linestyle='--', color='red')
plt.xlabel("Time")
plt.ylabel("Traffic Volume")
plt.title("Traffic Volume Forecast")
plt.legend()
plt.show()
```

Итоговый результат визуализации представлен на рисунке 4, где можно наглядно оценить качество прогноза, сравнив его с фактическими значениями.




Рис. 4 – Прогноз модели AutoML FEDOT

Более того, продолжая работу с FEDOT, предоставляется возможность более тонкой настройки и оптимизации модели. Фреймворк предоставляет широкий спектр инструментов для улучшения производительности и адаптации к специфике задачи.

Одним из ключевых аспектов является выбор метрики качества. FEDOT позволяет задать конкретную метрику для оценки эффективности модели:

```
from fedot.core.repository.quality_metrics_repository
import QualityMetricEnum
model.fit_config = {'metric':
QualityMetricEnum.mae}
```

В данном случае была использована средняя абсолютная ошибка (MAE) в качестве целевой метрики.

Следующим шагом может быть создание более сложного пайплайна, комбинирующего различные алгоритмы и методы обработки данных:

```
from fedot.core.pipelines.node import
PrimaryNode, SecondaryNode
node_lagged = PrimaryNode('lagged')
node_lagged.custom_params = {'window_size':
24}
node_ridge = SecondaryNode('ridge',
nodes_from=[node_lagged])
node_arima = SecondaryNode('arima',
nodes_from=[node_lagged])
final_node = SecondaryNode('linear',
nodes_from=[node_ridge, node_arima])
```

Этот пайплайн включает лаговое преобразование данных, за которым следуют параллельные ветви Ridge-регрессии и ARIMA, объединенные на финальном этапе линейной моделью.

FEDOT также предоставляет возможность настройки стратегии оптимизации. Например, можно выбрать тип генетического алгоритма:

```
from
fedot.core.composer.optimisers.gp_optimizer import
GeneticSchemeTypeEnum
model.composer.optimiser.parameters.genetic_scheme_type = GeneticSchemeTypeEnum.steady_state
```

Здесь применяется схема "steady state", которая может быть эффективна для определенных типов задач.

После настройки всех параметров, можно запустить процесс обучения и прогнозирования:

```
chain = model.fit(features=train_data,
target_node=final_node)
forecast = model.predict(features=test_data)
```

Таким образом, использование FEDOT значительно упрощает и автоматизирует процесс построения и оптимизации моделей для прогнозирования временных рядов. Благодаря применению эволюционных алгоритмов, FEDOT эффективно находит оптимальные комбинации методов и гиперпараметров, что приводит к повышению точности и надежности прогнозов.

Важно отметить, что такой подход особенно ценен при работе со сложными временными рядами, где традиционные методы могут оказаться недостаточно эффективными. FEDOT позволяет исследователям и практикам сосредоточиться на интерпретации результатов и принятии решений, автоматизируя трудоемкий процесс подбора и настройки моделей.

### Заключение

Таким образом, можно сказать, что оптимизация алгоритмов машинного обучения для анализа временных рядов значительно улучшает способность предсказывать будущие значения временного ряда на основе исторических данных. Эффективность предложенных в исследовании моделей подтверждается высокой точностью и обобщающей способностью, как на обучающем, так и на валидационном наборах данных. Внедрение автоматизированных систем, таких как AutoML, способствует ускорению разработки и оптимизации моделей, позволяя точно и эффективно реагировать на изменения в данных. Применение адаптивных техник оптимизации и интеграция различных подходов обучения обеспечивают значительное улучшение в прогнозировании временных рядов, открывая новые перспективы для их использования в самых разнообразных секторах.

### Литература

1. Efficient Automated Deep Learning for Time Series Forecasting. [Электронный ресурс] Режим доступа: <https://paperswithcode.com/paper/efficient-automated-deep-learning-for-time> (дата обращения 8.05.2024).

2. Анализ временных рядов. [Электронный ресурс] Режим доступа: <https://habr.com/ru/companies/otus/articles/732080/> (дата обращения 8.05.2024).

3. Анализ временных рядов. [Электронный ресурс] Режим доступа: <https://dit.isuct.ru/IVT/BOOKS/IS/is7/Modules/sttimeer.html> (дата обращения 8.05.2024).

4. Time Series Forecasting Using Machine Learning. [Электронный ресурс] Режим доступа: <https://medium.com/enjoy-algorithm/time-series-forecasting-using-machine-learning-d137485dd43e> (дата обращения 8.05.2024).

5. Efficient Automated Deep Learning for Time Series Forecasting. [Электронный ресурс] Режим доступа: <https://paperswithcode.com/paper/efficient-automated-deep-learning-for-time> (дата обращения 8.05.2024).

6. Применение машинного обучения и глубокого обучения в анализе временных рядов в области финансов. [Электронный ресурс] Режим доступа: <https://vc.ru/u/2265994-aleksey-andropov/834531-primenenie-mashinnogo-obucheniya-i-glubokogo-obucheniya-v-analize-vremennyh-ryadov-v-oblasti-finansov> (дата обращения 8.05.2024).

7. Обработка временных рядов в машинном обучении: Практическое руководство. [Электронный ресурс] Режим доступа: <https://www.yourtodo.ru/posts/obrabotka-vremennyih-ryadov-v-mashinnom-obuchanii-prakticheskoe-rukovodstvo/> (дата обращения 8.05.2024).

8. Прогнозирование временных рядов с помощью AutoML. [Электронный ресурс] Режим доступа: <https://habr.com/ru/articles/559796/> (дата обращения 8.05.2024).

9. Настройка AutoML для обучения модели прогнозирования временных рядов с помощью Python (SDKv1). [Электронный ресурс] Режим доступа: <https://learn.microsoft.com/ru-ru/azure/machine-learning/how-to-auto-train-forecast?view=azureml-api-1> (дата обращения 8.05.2024).

### References

1. Efficient Automated Deep Learning for Time Series Forecasting. [Electronic resource] Access mode: <https://paperswithcode.com/paper/efficient-automated-deep-learning-for-time> (accessed 05/28/2024).

2. Time series analysis. [Electronic resource] Access mode: <https://habr.com/ru/companies/otus/articles/732080/> (accessed 05/28/2024).

3. Time series analysis. [Electronic resource] Access mode: <https://dit.isuct.ru/IVT/BOOKS/IS/is7/Modules/sttimeer.html> (accessed 05/28/2024).

4. Time Series Forecasting Using Machine Learning. [Electronic resource] Access mode: <https://medium.com/enjoy-algorithm/time-series-forecasting-using-machine-learning-d137485dd43e> (accessed 05/28/2024).

5. Efficient Automated Deep Learning for Time Series Forecasting. [Electronic resource] Access mode:

<https://paperswithcode.com/paper/efficient-automated-deep-learning-for-time> (accessed 05/28/2024).

6. The application of machine learning and deep learning in time series analysis in finance. [Electronic resource] Access mode: <https://vc.ru/u/2265994-aleksey-andropov/834531-primenenie-mashinnogo-obucheniya-i-glubokogo-obucheniya-v-analize-vremennyh-ryadov-v-oblasti-finansov> (accessed 05/28/2024).

7. Time series processing in machine learning: A Practical guide. [Electronic resource] Access mode: [https://www.yourtodo.ru/posts/obrabotka-vremennyih-](https://www.yourtodo.ru/posts/obrabotka-vremennyih-ryadov-v-mashinnom-obuchenii-prakticheskoe-rukovodstvo/)

[ryadov-v-mashinnom-obuchenii-prakticheskoe-rukovodstvo /](https://vc.ru/u/2265994-aleksey-andropov/834531-primenenie-mashinnogo-obucheniya-i-glubokogo-obucheniya-v-analize-vremennyh-ryadov-v-oblasti-finansov) (accessed 05/28/2024).

8. Time series forecasting using AutoML. [Electronic resource] Access mode: [https://habr.com/ru/articles/559796 /](https://habr.com/ru/articles/559796/) (accessed 05/28/2024).

9. Configuring AutoML to train a time series forecasting model using Python (SDKv1). [Electronic resource] Access mode: <https://learn.microsoft.com/ru-ru/azure/machine-learning/how-to-auto-train-forecast?view=azureml-api-1> (accessed 05/8/2024).

---

## ИНТЕГРАЦИЯ РОБОТИЗИРОВАННЫХ СИСТЕМ В ПРОИЗВОДСТВЕННЫЕ ПРОЦЕССЫ

---

*Войстроченко Дмитрий Игоревич*  
Руководитель проектов, ООО "Роботек"  
Москва, Россия

*Voistrochenko Dmitrii Igorevich*  
DOI: [10.31618/ESU.2413-9335.2024.1.122.2073](https://doi.org/10.31618/ESU.2413-9335.2024.1.122.2073)

### АННОТАЦИЯ

В статье исследуется интеграция роботизированных систем в производственных процессах. В рамках исследования проведен обзор состояния рынка робототехники в глобальном контексте. Выявлены основные тенденции в роботизации производственных процессов, отдельное внимание обращено на такие методы повышения эффективности производства, как автоматизация и бережливое производство. В исследовании обозначены основные вызовы и препятствия, связанные с роботизацией и автоматизацией производственных процессов, предложены решения проблем, а также представлены прогнозы по дальнейшему развитию соответствующей отрасли.

### ABSTRACT

The article examines the integration of robotics in production processes. The study provides an overview of the state of the robotics market in a global context. The main trends in the robotization of production processes are identified, special attention is paid to such methods of increasing production efficiency as automation and lean manufacturing. The study identifies the main challenges and obstacles associated with robotics and automation of production processes, suggests solutions to problems, and also presents forecasts for the further development of the relevant industry.

**Ключевые слова:** роботизация, эффективность производства, автоматизация, бережливое производство, перспективы и вызовы роботизации.

**Keywords:** robotization, production efficiency, automation, lean manufacturing, prospects and challenges of robotics.

### Введение

В настоящее время в различных отраслях промышленного производства наиболее остро стоит вопрос эффективной организации производственных процессов, с целью обеспечения высокого уровня конкурентоспособности. При решении данного вопроса, предприниматели довольно часто обращают свое внимание на автоматизацию производственных процессов на предприятии и внедрение различных технологических решений. Зачастую организации стремятся оптимизировать свою работу, максимально модернизируя ее посредством интеграции роботизированных систем в производственные процессы, что определяет актуальность исследуемой темы.

Цель исследования выявить роль роботизации в производственных процессах.

Статья носит обзорный характер. В работе представлен детальный обзор интеграции роботизированных систем в производственных процессах. Проведена оценка места рынка

робототехники в мировой экономике, выявлены сектора экономики представляющие крупнейшими потребителями роботов, а также определены ведущие регионы по рынку промышленной робототехники. В статье анализируются технологии роботизации, как один из способов повышения эффективности производственных процессов. Выявлено влияние роботизации на экономическую и социальную сферы, более того обозначены вызовы и издержки, сопутствующие данной технологии; предложены пути решения соответствующих проблем. Выявлены особенности бережливого производства, а также взаимосвязь данной технологии с роботизацией и автоматизацией. Представлены прогнозы по дальнейшей интеграции роботизированных систем в производственные процессы.

Применены системный подход, графическая интерпретация информации, анализ динамики уровней временного ряда, расчет индексов роста показателей.



**1. Сущность роботизации производственных процессов.** Робототехника является одной из ключевых технологий будущего, в которой проблемы механики, новых инженерных и информационных технологий и аппаратных схем получения информации об окружающей среде переплетаются с проблемами искусственного интеллекта и создания систем управления сложными динамическими объектами в условиях неопределенности. В последние годы робототехника переживает новый виток развития, охватывая все больше направлений деятельности человека.

Робототехника традиционно подразделяется на два сегмента: промышленная робототехника и сервисная робототехника для личного или профессионального использования. Однако традиционная граница между этими сегментами постепенно размывается в результате развития промышленного использования сервисной робототехники; мобильной промышленной робототехники, которая позволяет быстро перенастраивать роботов с одной деятельности на другую; появления «кобототехники» (robotique collaborative), обеспечивающей совместное выполнение человеком и роботом сложных задач.[6]


При этом часто предполагается, что внедрение роботизации характерно для крупного производства, но это ошибочное мнение. Небольшие предприятия также принимают решение в пользу промышленных роботов, руководствуясь многими преимуществами данной техники.

Большинство роботов используются в производственных операциях, которые можно разделить на три категории: погрузка, разгрузка, операции по обработке, сборка и контроль. [5]

Чтобы оценить место рынка робототехники в мировой экономике, важно принимать во внимание его сложный, составной характер. Как уже упоминалось ранее, робототехника подразделяется на промышленную и сервисную. Причём как по предназначению, так и по целевым аудиториям данные виды роботов различаются кардинально. Таким образом, необходимо оценить место, которое занимает рынок робототехники в мировой экономике при учете указанных различий сегментов. Стоит заметить, что ключевым источником данных по статистике глобального рынка робототехники являются Доклады о мировой робототехнике за последние пять лет (с 2019 по 2023 гг.), ежегодно выпускаемые Международной федерацией робототехники. [11]

Для понимания масштабов интеграции роботизированных систем полезен показатель общемирового прироста числа действующих роботов. Так, рис. 1 демонстрирует планомерный рост объемов поставки промышленных роботов в мире. В 2019-2020 гг. в связи с эпидемиологической обстановкой произошел спад наблюдаемого показателя, однако пандемия COVID-19 лишь подчеркнула реальную потребность современного общества в интеграции роботизированных систем, что, в свою очередь, привело к увеличению спроса на промышленных роботов.[14]

Рис. 1. Объемы поставки промышленных роботов в мире, тыс. шт., 2013-2023 гг.



Как следует из данных статистики, представленных на рис. 2, электротехника и электроника на протяжении последних лет сохраняют статус крупнейшего потребителя роботов – на сектор пришлось 30% от общего числа всех установок. Далее следуют автомобильная

промышленность (25%), металлургия (10%), пластмассы и химические продукты (5%), а также пищевая промышленность (3%).


Однако электротехническая и электронная промышленность не всегда была основным

потребителем промышленных роботов, лишь с 2020 года она удерживает эту позицию.

В 2018 и 2019 годах мировой спрос на электронные устройства и компоненты значительно снизился. Эта отрасль оказалась одной из наиболее пострадавших от торгового конфликта между Китаем и США, поскольку азиатские страны являются лидерами в производстве электронных продуктов и компонентов. Так, именно автомобильная промышленность имела позицию крупнейшего потребителя промышленных

роботов. Однако во время пандемии COVID-19 спрос на потребительскую электронику резко вырос, а электронные компоненты являются ключевыми элементами во всех видах машиностроения, включая автомобилестроение и промышленное оборудование. Ограниченные производственные мощности и сбои в цепочках поставок из-за пандемии продемонстрировали необходимость дополнительной производственной мощности в электротехнической промышленности. [10]

Рис. 2. Количество поставляемых роботов по отраслям, тыс.ед./г.

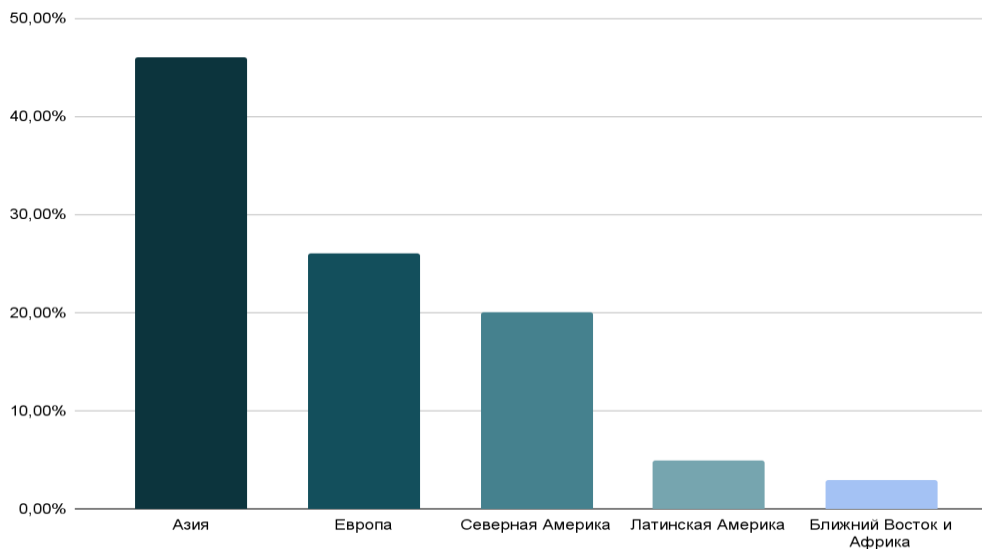


Что касается географических регионов, Азия является наиболее быстрорастущим в мире рынком промышленных роботов. Уже в 2019 году на этот регион приходилось более 67% рынка промышленной робототехники. Основным драйвером этого роста является спрос на промышленных роботов со стороны малых и средних предприятий в Китае, Японии, Южной Корее и Индии. С 2013 года Китай является крупнейшим рынком роботов в мире и продолжает динамично расти.

Европа является вторым ведущим регионом по рынку промышленной робототехники. При этом Германия предстает крупнейшим европейским рынком и единственной европейской страной, входящей в мировую пятерку рынков робототехники.

На пять основных рынков, включая Китай, Японию, Республику Корея, США и Германию, приходится около 75% от общего объема продаж робототехники в 2023 году. [13]

Рис. 3. Доля рынка робототехники по регионам, 2023 г.



Согласно данным Markets & Markets, мировой рынок промышленных роботов в настоящее время переживает взрывной рост, достигая 42,2 миллиарда долларов. Предполагается, что уже в 2026 году произойдет удвоение данного показателя до 75,3 миллиарда долларов.[12]

Таким образом, востребованность рынка робототехники демонстрирует заинтересованность предприятий в интеграции роботизированных систем для повышения эффективности всех производственных процессов.

**2.Роботизация как компонент автоматизации производства.** Роботизация и автоматизация в производстве прочно укрепились в современной индустрии. Эти технологии вносят изменения во всю организацию рабочего процесса.

Процесс роботизации начинается с анализа производственных операций и определения задач, которые могут быть автоматизированы. Далее производится выбор подходящих роботов или автоматизированных систем, их интеграция в производственную линию и настройка для выполнения конкретных функций. Немаловажную роль играет обучение персонала, который будет работать с новыми технологиями.[5]

Роботизированные комплексы включают в себя множество преимуществ. Так, автоматизация технологии производства оказывает глубокое экономическое воздействие на предприятие, способствуя снижению затрат и повышению эффективности операций. Оснащение производственных линий умными системами позволяет добиться оптимизации повседневной работы, приводя к более продуктивному использованию ресурсов и сокращению времени простоя оборудования. Экономия на заработной плате работников и уменьшение погрешностей, свойственных человеческому фактору, тоже являются значительными экономическими выгодами автоматизации. [2]

Среди ключевых экономических преимуществ автоматизации следует выделить:

- Увеличение объема производства при сохранении или сокращении численности персонала, в результате чего последует снижение затрат на труд.

- Уменьшение доли бракованной продукции благодаря улучшенному контролю качества и точности процессов.

- Сокращение расходов на техническое обслуживание за счет предотвращения аварийных ситуаций и неисправностей.

- Механизация и автоматизация производства приводят к заметным трансформациям в социальных условиях и структуре рынка труда. [Там же]

Автоматические системы, замещающие традиционные рабочие процессы, вносят изменения как в требования к квалификации работников, так и в общую динамику занятости. Отмечается повышенная потребность в специалистах высокого уровня, владеющих умениями программирования, обслуживания и управления современным оборудованием.

Воздействие автоматизации на социальные условия и рынок труда включает уменьшение количества низкоквалифицированных рабочих мест в связи с заменой ручного труда на машины и программное обеспечение, а также увеличение продуктивности труда, что может вести к росту заработных плат в секторах с высоким уровнем автоматизации.

Одним из основных вызовов является потенциальная угроза для рабочих мест. Роботы и автоматизированные системы могут выполнить многие задачи, которые раньше выполняли работники. Это может привести к уменьшению числа рабочих мест, особенно в тех отраслях, где трудовая сила используется массово. Однако, с другой стороны, автоматизация может привести к

созданию новых рабочих мест в новых отраслях и секторах, таких как технологии и инженерия. [8]

Еще одним вызовом является высокая стоимость внедрения автоматизации и роботизации в производственные процессы. Для производителей это может стать значительным финансовым бременем, особенно для тех малых и средних предприятий, которые не имеют достаточных ресурсов для проведения таких изменений. Однако, в долгосрочной перспективе автоматизация помогает снизить затраты на производство, что позволяет компаниям сэкономить. [9]

Также, автоматизация и роботизация производства имеют потенциальные социальные последствия. Например, дополнительная автоматизация в производственных процессах может привести к росту рынка труда в области технологий и инженерии. Однако, работники, потерявшие свои рабочие места в результате автоматизации, могут оказаться лишенными работы в более традиционных отраслях. [Там же]

Возможные решения вызовов, связанных с роботизацией и автоматизацией производства, могут включать следующие действия. Во-первых, необходимо создавать образовательные программы, которые могут помочь работникам освоить новые навыки и переквалифицироваться. Это может помочь им найти новые рабочие места и продолжить свою карьеру в более высококвалифицированных отраслях. [2]

Другим способом решения проблемы является введение более гибких форм трудоустройства, таких как удаленная и контрактная работы, которые могут помочь специалистам перейти на новые рабочие места. Компании также могут принимать меры для улучшения трудовых условий и рационализации рабочих процессов, что может привести к повышению мотивации работников и увеличению их производительности. [2]

Одним из самых важных шагов для преодоления вызовов, связанных с роботизацией и автоматизацией производства, является грамотное планирование. Компании должны оценить свои потребности и ресурсы, чтобы определить, какие изменения им необходимы, и какие именно технологии и инструменты им могут пригодиться. Они также должны рассмотреть возможности для инвестирования в новые технологии и оборудование, чтобы убедиться, что они оправдают себя в долгосрочной перспективе. [Там же]

Следовательно, роботизация и автоматизация открывают широкие перспективы для развития производственных процессов, но требуют осмысленного подхода и грамотного управления, чтобы успешно реализовать их потенциал и обеспечить устойчивое развитие предприятия.

**3. Взаимосвязь роботизации и Бережливого производства.** Бережливое производство – это управленческая концепция, центральная идея которой заключается в устранении семи типов производственных потерь:

1. Перепроизводство (производство, опережающее спрос);

2. Лишняя транспортировка (перемещения товарно-материальных ценностей в ходе процесса создания продукта, не приносящее в конечном счете прибыль);

3. Ожидание (деталь простаивает в ожидании начала следующего этапа обработки; специалисты ожидают поставку материалов или инструментов и т.д.);

4. Запасы (компоненты, незавершенное производство, готовая продукция);

5. Лишние передвижения (движения людей или техники, не являющиеся необходимыми для производства продукта);

6. Лишняя обработка (дублирование функций, несовершенство инструментов или конструкции изделия и т.д.);

7. Дефекты (затраты на поиск и исправление недостатков).[4]

Автоматизация и роботизация производства могут способствовать устранению потерь, а также поддержанию и совершенствованию бережливой производственной системы, благодаря таким значимым характеристикам, как:

● **Стабильность.** Роботы обеспечивают стабильность производственного процесса и качества продукта, снижают количество отклонений и сокращают потери.

● **Скорость.** Роботы обеспечивают более высокую производительность и помогают сократить время простоя.

● **Точность.** Роботы обеспечивают точность выполнения рабочих процедур и позволяют снизить процент брака.

● **Гибкость.** Современные роботы имеют гибкие возможности настройки, сокращают время, необходимое для грамотного налаживания оборудования, и дают возможность внедрить быструю переналадку (Single-Minute Exchange of Die) и даже «переналадку в одно касание» (One-Touch Exchange of Die).[3]

Описанные характеристики доказывают, что автоматизация и роботизация производств согласуется с концепцией Бережливого производства. Однако типичным является заблуждение, что покупка самых современных промышленных роботов автоматически делает предприятие «бережливым».[3]

Несмотря на очевидные преимущества, роботы не являются гарантом «бережливости» производства по своей сути – бережливими их делает грамотное применение в процессах, где уже была проведена работа по выявлению и устранению потерь. Если процессы на предприятии неэффективны, то роботы лишь «автоматизируют беспорядок» и в разы увеличат объемы потерь.[7]

На особо крупных сборочных заводах используются сотни роботов, занятых во множестве операций, таких как перенос деталей, обслуживание станков, сварка, окончательная отделка, покраска и т.п. Их согласованная работа способна повысить точность и стабильность процессов, обеспечить высокий уровень качества, сократить время цикла, но роботизация

производства не гарантирует полное отсутствие ошибок. Излишний холостой ход робота может являться причиной задержек производственного процесса и привести к производственным потерям; неграмотная настройка может сказаться на качестве готовой продукции, увеличить количество брака и т.д. Простои дорогого оборудования могут стать одним из самых серьезных источников потерь в бюджете любой компании. Для Бережливого производства крайне важно обеспечить оптимальное время цикла роботизированных ячеек.[4]

Формирование бережливой производственной системы является величайшим вызовом и одной из самых сложных и амбициозных целей многих современных предприятий. Поэтому привлечение промышленных роботов при формировании и развитии производственной системы должно происходить продуманно и с обязательным учетом многих показателей: финансовая целесообразность; планируемое число выпуска готовой продукции; уровень образования персонала; текущий уровень развития производственной системы на конкретном предприятии; требования к автоматизации процесса или технологии и т.п. [1]

#### **Заключение**

Благодаря постоянному развитию технологий и переходу к новому этапу развития – 4-й промышленной революции (Industry 4.0) – применение роботов все больше расширяется. Ускорение цифровизации и автоматизации, а также упрощение использования промышленных роботов стимулирует их распространение. Если раньше наибольшим спросом промышленные роботы пользовались в автомобильной промышленности, то в настоящее время они находят применение в сфере электроники и электротехники, а также других отраслях.

Согласно долгосрочным прогнозам (до 2030 г.) компании IDATE DigiWorld, важнейшим рынком робототехники в течение этого периода останется обрабатывающая промышленность, в основном благодаря появлению коботов. В течение этого периода будут активно развиваться сектора логистики и здравоохранения. Более того, к 2030 г. «умное» сельское хозяйство будет занимать значительную часть мирового рынка, что будет обусловлено сочетанием промышленных, потребительских и экологических требований.[13]

Свой вклад в развитие робототехники внесут различные виды цифровизации производства в рамках «Индустрии 4.0», а также развитие автономных транспортных средств, решающих проблемы мобильности.

Однако для получения большей прибыли предприятия должны интегрировать роботизацию в соответствии с технологиями, способными в максимально короткие сроки повысить эффективность производственных процессов. Так, автоматизация и бережливое производство имеют ключевое значение для повышения качества

продукции, снижения затрат и обеспечения безопасности на предприятии.

Интеграция роботизированных систем и бережливого производства поможет предприятиям не только оптимизировать производственные процессы, но и укрепить свои позиции на рынке.

#### **Список использованной литературы:**

1. Аналитическое исследование: Мировой рынок робототехники. Национальная ассоциация участников рынка робототехники. 2016. [Электронный ресурс] Режим доступа: [http://robotforum.ru/assets/files/000\\_News/NAURR-Analiticheskoe-issledovanie-mirovogo-rinka-robototehniki-\(yanvar-2016\).pdf](http://robotforum.ru/assets/files/000_News/NAURR-Analiticheskoe-issledovanie-mirovogo-rinka-robototehniki-(yanvar-2016).pdf) (дата обращения: 29.08.2024).

2. Бирасланов С., Новикова Л.В. Автоматизация и роботизация производства // Материалы XIV Международной студенческой научной конференции «Студенческий научный форум». [Электронный ресурс] Режим доступа: <https://scienceforum.ru/2022/article/2018031745> (дата обращения: 30.08.2024).

3. Вумек Д. П. Бережливое производство: Как избавиться от потерь и добиться процветания вашей компании / Д.П. Вумек, Д. Джонс. М.: Альпина Паблишер. 2013. 472 с.

4. Грачев М. Что такое бережливое производство и зачем его внедрять? [Электронный ресурс] Режим доступа: <https://rb.ru/opinion/lean-manufacturing/> (дата обращения: 29.08.2024).

5. Зарипов, И. Р. Перспективы распространения технологии роботизации процессов в России / И. Р. Зарипов. // Молодой ученый. 2021. № 19 (361). С. 13-15. [Электронный ресурс] Режим доступа: <https://moluch.ru/archive/361/80875/> (дата обращения: 29.08.2024).

6. Искандарова В. Г. Комплексный подход к процессам роботизации – механизации производственных участков // Журнал естественнонаучных исследований Т. 5. № 1. 2020. [Электронный ресурс] Режим доступа: <https://naukaru.ru/ru/nauka/article/36946/view>

7. Литвинов И.Е. Бережливое производство как основа для повышения эффективности производства / И.Е. Литвинов, А.Н. Коркишко, М.С. Чухлатый, А.В. Набоков // Экономика и предпринимательство. 2019. № 2 (103). С. 1132-1136.

8. Пономарева, Г. Т. Автоматизация и роботизация как одно из направлений инновационного развития экономики / Г. Т. Пономарева, А. Р. Рафикова // Вопросы экономики и управления. 2018. № 4 (15). С. 1-8. [Электронный ресурс] Режим доступа: <https://moluch.ru/th/5/archive/97/3383/> (дата обращения: 29.08.2024).

9. Тимофеев А.Г., Злобин П.В. Концепция «безлюдного» производства // Известия Российского экономического университета им. Г.В. Плеханова. 2015. № 4 (22). С. 388–399.

10. Copigneaux B. Service robots: Global robotique: un marché à très fort potentiel qui atteindra

90 milliards d'euros en 2030 // IDATE DigiWorld. 2019. URL: <https://fr.idate.org/robotique-un-marche-a-tres-fort-potentiel-qui-atteindra-90-milliards-deuros-en-2030/> (accessed: 26.08.2024)

11.Executive Summary World Robotics 2019. Industrial Robots // International Federation of Robotics. 2019. URL: <https://ifr.org/downloads/press2018/Executive%20Summary%20WR%202019%20Industrial%20Robots.pdf> (accessed: 26.08.2024)

12.IFR. Positive Impact of Industrial Robots on Employment. URL: [http://robohub.org/wp-content/uploads/2013/04/Metra\\_Martech\\_Study\\_on\\_robot\\_2013.pdf](http://robohub.org/wp-content/uploads/2013/04/Metra_Martech_Study_on_robot_2013.pdf) (accessed: 26.08.2024)

13.Robotics Technology Market Size, Share, and Trends 2024 to 2034 URL:<https://www.precedenceresearch.com/robotics-technology-market> (accessed: 26.08.2024)

World Robotics Report 2022. Industrial Robots // International Federation of Robotics. 2022. URL: <https://ifr.org/worldrobotics/> (accessed: 26.08.2024)

# Евразийский Союз Ученых.

## Серия: технические и физико-математические науки

Ежемесячный научный журнал

№ 07 (122)/2024 Том 1

### ГЛАВНЫЙ РЕДАКТОР

**Макаровский Денис Анатольевич**

AuthorID: 559173

Заведующий кафедрой организационного управления Института прикладного анализа поведения и психолого-социальных технологий, практикующий психолог, специалист в сфере управления образованием.

### РЕДАКЦИОННАЯ КОЛЛЕГИЯ

**Штерензон Вера Анатольевна**

AuthorID: 660374

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт новых материалов и технологий (Екатеринбург), кандидат технических наук

**Синьковский Антон Владимирович**

AuthorID: 806157

Московский государственный технологический университет "Станкин", кафедра информационной безопасности (Москва), кандидат технических наук

**Штерензон Владимир Александрович**

AuthorID: 762704

Уральский федеральный университет им. первого Президента России Б.Н. Ельцина, Институт фундаментального образования, Кафедра теоретической механики (Екатеринбург), кандидат технических наук

**Зыков Сергей Арленович**

AuthorID: 9574

Институт физики металлов им. М.Н. Михеева УрО РАН, Отдел теоретической и математической физики, Лаборатория теории нелинейных явлений (Екатеринбург), кандидат физ-мат. наук

**Дронсейко Виталий Витальевич**

AuthorID: 1051220

Московский автомобильно-дорожный государственный технический университет (МАДИ), Кафедра "Организация и безопасность движения" (Москва), кандидат технических наук

Статьи, поступающие в редакцию, рецензируются. За достоверность сведений, изложенных в статьях, ответственность несут авторы. Мнение редакции может не совпадать с мнением авторов материалов. При перепечатке ссылка на журнал обязательна. Материалы публикуются в авторской редакции.

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций.

Художник: Валегин Арсений Петрович  
Верстка: Курпатова Ирина Александровна

Адрес редакции:  
198320, Санкт-Петербург, Город Красное Село, ул. Геологическая, д. 44, к. 1, литера А  
E-mail: [info@euroasia-science.ru](mailto:info@euroasia-science.ru) ;  
[www.euroasia-science.ru](http://www.euroasia-science.ru)

Учредитель и издатель ООО «Логика+»  
Тираж 1000 экз.