



**VOL 2 (25) 2025**

**JOURNAL OF  
SCIENCE AND RESEARCH**



**ASTANA**

**WWW.JSRJOURNAL.KZ**

# «Journal of Science and Research (JSR)»

Қазақстан Республикасы Ақпарат және қоғамдық  
даму министрлігінің Ақпарат комитетінде  
тіркелген № KZ41VPY00076697, 01.09.2023 ж.

Халықаралық ISSN орталығы (ISSN-L): [3006-4325](https://www.issn-l.org/details.do?issn=3006-4325)

Айына екі рет жарық көреді.



№ 2 (25) 2025

Астана, 2025

**МАЗМҰНЫ**

|                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------|----|
| Аппаратные платформы для систем видеонаблюдения.....                                                   | 4  |
| <i>Нұрбергенов Д.</i>                                                                                  |    |
| Анализ эффективности IoT систем экологического мониторинга в<br>реальных условиях эксплуатации.....    | 19 |
| <i>Куатбеков Ж.</i>                                                                                    |    |
| Инклюзивті білім беру ортасында оқытуды жекелендіру үшін машиналық<br>оқыту алгоритмдерін қолдану..... | 36 |
| <i>Ажимбетов С. К.</i>                                                                                 |    |
| Жасанды интеллектті қолдану арқылы ым тілін оқыту зерттеулерінің<br>библиометриялық талдауы.....       | 47 |
| <i>Досан Ә.</i>                                                                                        |    |

FTAMP 621.398

## Аппаратные платформы для систем видеонаблюдения Д. Нұрбергенов<sup>1</sup>

<sup>1</sup>Евразийский национальный университет имени Л.Н. Гумилёва,  
Астана, Казахстан.

\*E-mail: [diasnkteam@gmail.com](mailto:diasnkteam@gmail.com)

**Научный руководитель:** Медетов Б.Ж. — ассоциированный  
профессор.

**Аннотация.** Работа систем видеонаблюдения в условиях возросших требований к приватности, кибербезопасности и локальной ИИ-аналитике требует осознанного выбора аппаратной платформы. В статье рассматриваются три класса решений System-on-Chip (SoC), Single-Board Computer (SBC) и Compute Module / System-on-Module (COM/SoM) с точки зрения вычислительных возможностей для видеоаналитики, энергоэффективности, интерфейсов камер и сетей, устойчивости хранения, жизненного цикла и совокупной стоимости владения (TCO). Предложена методика экспериментального сравнения (бенчмарки и метрики), приведён минимальный набор таблиц для объективизации результатов. Показано, что выбор платформы зависит от профиля нагрузки (число потоков, кодеки, ИИ-инференс), ограничений по питанию/теплу, серийности, а также нормативных требований к данным.

**Ключевые слова:** видеонаблюдение, edge AI, SoC, SBC, COM/SoM, H.264/H.265, MIPI CSI-2, PoE, TCO, Secure Boot.

### Введение

Аппаратные платформы составляют фундамент современных систем видеонаблюдения, представляя собой сложные вычислительные архитектуры, оптимизированные для обработки видеоданных в реальном времени. К числу таких решений относятся высокоинтегрированные системы на кристалле, готовые к использованию одноплатные компьютеры и специализированные вычислительные модули. Эти технологические платформы стали основой для создания производительных, отказоустойчивых и адаптируемых под конкретные задачи комплексов видеомониторинга. Интенсивное развитие технологий искусственного интеллекта и интернета вещей, сопровождающееся ужесточением требований к безопасности, формирует устойчивый спрос на интеллектуальные системы видеонаблюдения нового поколения. В этих условиях всестороннее исследование аппаратных платформ приобретает первостепенное значение для разработчиков и системных интеграторов. Особую актуальность получает тенденция переноса вычислительной нагрузки на периферийные устройства, что позволяет не только минимизировать задержки при обработке видео, но и существенно разгрузить сетевую инфраструктуру, обеспечивая при этом функционирование систем в режиме реального времени даже при ограниченной пропускной способности каналов связи[1,2]. Современный этап развития аппаратных платформ характеризуется их адаптацией к

решению increasingly сложных задач видеоаналитики. Перед производителями стоит задача создания систем, способных параллельно обрабатывать множество видеопотоков в различных форматах сжатия, выполнять сложный нейросетевой анализ для обнаружения и классификации объектов, одновременно гарантируя отказоустойчивое хранение и защиту данных. Особую сложность представляет достижение оптимального баланса между производительностью, энергопотреблением и тепловыделением, что особенно критично для компактных и автономных устройств, работающих в непрерывном режиме. При проектировании архитектурных решений необходимо принимать во внимание три фундаментальных аспекта: 1. Соблюдение требований конфиденциальности и локализации данных, обусловленное ужесточением нормативно-правового регулирования в области защиты персональной информации. 2. Реализация принципа встроенной безопасности, предполагающая интеграцию механизмов защиты на уровне аппаратной архитектуры. 3. Обеспечение предсказуемости жизненного цикла аппаратного обеспечения, определяющего долгосрочную надежность и ремонтпригодность систем видеонаблюдения. Целью данного исследования является систематизация критериев выбора аппаратных платформ и разработка воспроизводимой методики их сравнительной оценки для систем видеонаблюдения, использующих аналитику на основе искусственного интеллекта [1-3]. В рамках работы рассматривается не только традиционный набор показателей производительности, но и такие значимые параметры, как энергоэффективность, поддерживаемые интерфейсы подключения оборудования, а также совокупная стоимость владения на различных временных горизонтах, что позволяет проводить комплексную оценку целесообразности применения тех или иных аппаратных решений.

#### Цель и методология исследования

Современные тенденции перенос аналитики на периферию (edge), рост требований к приватности и киберустойчивости, а также повышение доли многокамерных конфигураций обуславливают потребность в системной классификации аппаратных платформ видеонаблюдения и их сравнительной оценке по ключевым показателям эффективности. Несмотря на обилие работ по отдельным аспектам (энергоэффективность, ускорители ИИ, сетевые интерфейсы), отсутствует обобщённая сопоставимая модель, позволяющая соотнести технологические подходы (SoC, SBC, COM/SoM) с реальными сценариями эксплуатации и ограничениями по питанию/теплу, сети и хранению.

Провести систематизацию и сравнительный анализ подходов к построению аппаратной основы систем видеонаблюдения с фокусом на эксплуатационную надёжность, энергоэффективность, пропускную способность конвейера видео+ИИ и стоимость владения (TCO) при различной инфраструктурной доступности (indoor/outdoor, PoE/LTE, on-prem/гибрид). В рамках работы определить, какие архитектурные и платформенные решения

демонстрируют наилучшие показатели в зависимости от профилей нагрузки (P1–P4) и ограничений среды. Задачи исследования:

1. Провести анализ и классификацию платформенных подходов (SoC, SBC, COM/SoM) и типовых архитектур (edge-центричные, гибридные).
2. Определить и обосновать критерии оценки эффективности: FPS/Вт, производительность инференса, задержка p50/p95, устойчивость хранения, возможности I/O (MIPI/USB/GigE/PoE), безопасность/соответствие, жизненный цикл и TCO.
3. Разработать воспроизводимую методику и стенд сравнения (камеры, профили P1–P4, измерители энергии и тепла, эмуляция сетевых потерь).
4. Выполнить сравнительный анализ по разработанным критериям на основе актуальных публикаций и/или экспериментальных измерений.
5. Сформировать практические рекомендации по выбору платформ под разные сценарии эксплуатации и масштабы.

#### Методология

Методологическая основа комплексный анализ первичных источников (datasheet'ы и application notes SoC/SBC/COM, стандарты ONVIF/MIPI/TLS) и рецензируемых публикаций 2023–2025 годов (IEEE/Elsevier/MDPI и др.). Отбор выполнялся по релевантности направлениям: энергоэффективность вычислений и кодеков, устойчивость сетевых коммуникаций (PoE/LTE), методы ИИ-инференса на edge, безопасность (Secure Boot/TPM/OTA) и жизненный цикл изделий. Для сравнительной оценки применяются: (i) контент-анализ и качественное сопоставление архитектур; (ii) балльная оценка по семи критериям; (iii) лабораторные измерения на профилях P1–P4. Результаты представляются в виде сравнительных таблиц и графиков, позволяющих выявить сильные/слабые стороны каждой платформы и определить перспективные направления дальнейших исследований.

### **Классы аппаратных платформ**

#### Система на кристалле (SoC)

Данный класс решений представляет собой высокоинтегрированную архитектуру, объединяющую на одном кристалле центральный и графический процессоры, специализированные ускорители искусственного интеллекта, блоки обработки видеопотоков и различные интерфейсные модули. Ключевым преимуществом SoC является достижение максимальной энергоэффективности при заданной вычислительной нагрузке, что обеспечивается оптимизированной структурой и минимальным количеством внешних компонентов. Среди ограничений следует отметить сложность начального освоения, связанную с необходимостью использования специализированных инструментов разработки и соблюдения условий конфиденциальности, продолжительный цикл создания серийного продукта, а также повышенные требования к проектированию систем охлаждения. Эти особенности определяют целесообразность применения SoC преимущественно в продукции крупносерийного производства [3-7].

### Одноплатный компьютер (SBC)

Одноплатные компьютеры представляют собой законченные вычислительные системы, размещенные на единой печатной плате и включающие процессор, оперативную память, постоянное запоминающее устройство и комплекс интерфейсов для подключения периферийного оборудования. Важным достоинством SBC является развитая программная экосистема, поддерживающая различные операционные системы, средства обработки мультимедиа, библиотеки компьютерного зрения и frameworks для работы с нейросетевыми моделями. К преимуществам относятся минимальные сроки внедрения и высокая вариативность конфигураций подключения внешних устройств. В качестве ограничений можно отметить сравнительно низкую энергоэффективность относительно специализированных SoC, а также зависимость от доступности компонентов и долгосрочной технической поддержки [3-11].

Таблица 1. Сравнение SoC и SBC в системах видеонаблюдения

| Характеристика         | SoC                                        | SBC                                                    |
|------------------------|--------------------------------------------|--------------------------------------------------------|
| Назначение             | Высокая интеграция и энергоэффективность   | Гибкость и масштабируемость                            |
| Внешние компоненты     | Минимальное количество внешних компонентов | Поддержка широкого набора периферии                    |
| Применимость           | Компактные и специализированные устройства | Системы, требующие настройки и развития                |
| Оптимизация            | Энергоэффективность и размер               | Функциональность и производительность                  |
| Интеграция компонентов | CPU+GPU+NPU+кодек и на одном кристалле     | Раздельные чипы на плате                               |
| Энергопотребление      | 2-8 Вт в типовом режиме                    | 5-15 Вт в типовом режиме                               |
| Поддержка видеокодеков | Аппаратное ускорение H.264/H.265/AV1       | Программная обработка или базовое аппаратное ускорение |
| Интерфейсы камер       | 2-4 канала MIPI CSI-2                      | 1-2 канала MIPI CSI-2 + USB                            |
| Поддержка ОС           | Специализированные Linux BSP               | Стандартные дистрибутивы Linux                         |

|                    |                            |                                               |
|--------------------|----------------------------|-----------------------------------------------|
| Сетевые интерфейсы | 1-2 порта Gigabit Ethernet | 1-4 порта Gigabit Ethernet + опционально SFP+ |
|--------------------|----------------------------|-----------------------------------------------|

Анализ таблицы 1 показывает, что выбор между SoC (System-on-Chip) и SBC (Single-Board Computer) напрямую влияет на архитектуру, энергоэффективность и гибкость системы видеонаблюдения. SoC-решения обеспечивают более высокую степень интеграции вычислительных и графических блоков, низкое энергопотребление и компактность, что делает их оптимальными для встраиваемых и мобильных систем например, интеллектуальных камер или узлов с автономным питанием.

SBC-платформы, напротив, обладают большей функциональной универсальностью и поддержкой широкого спектра периферийных устройств, что делает их предпочтительными для прототипирования, лабораторных испытаний и масштабируемых серверных решений. Однако это сопровождается повышенным энергопотреблением и большими габаритами, что ограничивает применение SBC в системах с жесткими требованиями к ресурсоемкости и тепловыделению. Таким образом, при проектировании архитектуры интеллектуальных систем видеонаблюдения целесообразно учитывать компромисс между интеграцией и расширяемостью, энергоэффективностью и производительностью, выбирая тип платформы в зависимости от условий эксплуатации, требуемой вычислительной мощности и стратегии масштабирования. В дальнейшем, при оценке производительности и устойчивости, выбор аппаратной платформы становится ключевым фактором, определяющим эффективность всего конвейера обработки видеоданных. Вычислительный модуль (COM/SoM) представляют собой компактные платы, содержащие основные вычислительные компоненты, которые устанавливаются на специально спроектированную плату-носитель. Данная архитектура предлагает сбалансированное сочетание гибкости проектирования и промышленной надежности, обеспечивая возможность модернизации вычислительного ядра, полный контроль над используемыми компонентами и соответствие отраслевым стандартам. Основным недостатком является необходимость проведения исследований и разработок по созданию платы-носителя, что увеличивает первоначальные затраты, однако в условиях серийного производства данные инвестиции демонстрируют свою окупаемость. Основными областями применения вычислительных модулей являются массовое производство, промышленные системы и решения для интернета вещей, где особое значение приобретают требования к компактности, длительному жизненному циклу и оптимизации энергопотребления [8-12].

Архитектурные требования и методика оценки систем видеонаблюдения Интеллектуальные системы видеонаблюдения представляют собой интегрированные аппаратно-программные комплексы, обеспечивающие захват, обработку, хранение, передачу и интеллектуальный



анализ видеопотоков. При их проектировании особое внимание уделяется архитектурным требованиям, направленным на достижение высокой производительности, энергоэффективности, отказоустойчивости, информационной безопасности и масштабируемости. Для обеспечения воспроизводимости результатов используются унифицированные критерии и методики оценки. Видео-подсистема отвечает за формирование, передачу и стабильность видеопотоков. Она должна поддерживать современные стандарты компрессии (H.264/H.265), аппаратное декодирование и кодирование, а также интерфейсы MIPI CSI-2, USB 3.0, GigE и PoE. Важным требованием является возможность мультиканальной обработки с гарантированным фреймрейтом (FPS) без потери данных при высоких разрешениях (до 4K и выше). Для оптимизации пропускной способности применяются буферизация кадров, динамическое управление битрейтом (VBR/CBR) и адаптивная коррекция задержек (latency compensation).

Подсистема искусственного интеллекта (ИИ) реализует функции детекции, классификации и трекинга объектов. Её эффективность определяется вычислительной производительностью (TOPS/TFLOPS), поддержкой режимов вычислений INT8/FP16 и совместимостью с фреймворками оптимизации — TensorRT, OpenVINO, Apache TVM и другими. Ключевым требованием является оптимизация конвейера обработки (decode → preprocess → infer → postprocess → encode/store/alert) с минимальными задержками и энергопотреблением. Дополнительно оценивается степень загрузки вычислительных ресурсов (CPU, GPU, NPU) и эффективность распределения задач в гетерогенной архитектуре.

Хранилище данных должно обеспечивать устойчивую работу при непрерывной циклической записи, поддерживая eMMC, SSD и NAS с высоким ресурсом записи (endurance). Для повышения надёжности реализуются стратегия ретенции, резервное копирование, журналирование и корректная политика синхронизации (fsync). Целостность данных подтверждается средствами контроля (checksums, ECC), а также механизмами самовосстановления файловых систем[9-12].

Сетевая подсистема должна гарантировать отказоустойчивую и безопасную передачу данных, реализуя два независимых канала связи (например, LAN и LTE/5G) с возможностью балансировки и автоматического фейловера. Применяется приоритизация трафика (QoS), поддержка протоколов MQTT/RTSP/RTP/HTTP(S) и механизмов OTA-обновлений с проверкой цифровой подписи и целостности[9,10]. Безопасность системы обеспечивается комплексом аппаратных и программных мер: безопасной загрузкой (Secure Boot), использованием аппаратных модулей доверенной платформы (TPM/TEE), шифрованием данных в хранилище и каналах связи (AES, TLS), ролевой моделью доступа (RBAC), системным журналированием и hardening-политиками ОС[10-15].

Методика оценки включает совокупность метрик, отражающих производительность, надёжность и экономическую эффективность.

Производительность определяется количеством кадров в секунду (FPS) при декодировании потоков H.264/H.265 (1080p/4K) и скоростью инференса (например, YOLOv5/v8) с порогом точности mAP@0.5. Задержки характеризуются медианным и 95-м перцентильным временем отклика ( $t_{p95}$ ). Энергоэффективность выражается как FPS/W или inferences/W.

Надёжность хранения оценивается по MTBF записи и параметрам SMART, а устойчивость сетевой подсистемы по битовой ошибке (BER), вероятности потери пакетов (PLR), джиттеру и деградации при питании по PoE. Экономическая эффективность рассчитывается по совокупной стоимости владения (TCO), включающей капитальные, эксплуатационные и сервисные затраты, а также стоимость жизненного цикла системы[15-17].

Таблица 2. Факторы выбора аппаратных платформ для систем видеонаблюдения

| Фактор                         | Технические детали                                                                                                                                      | Примеры                                                                                                    |
|--------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------|
| Выбор SoC                      | Баланс между производительностью, энергоэффективностью, стоимостью и экосистемой поддержки.                                                             | Rockchip – мультимедиа и ИИ по конкурентной цене; NXP – долгосрочная поддержка для промышленности [11,14]. |
| Вычислительная мощность        | Зависит от сценария: CPU+GPU для ИИ и анализа видео; CPU для медиасерверов.                                                                             | ARM и x86 SBC, разные архитектуры под задачи [14,18].                                                      |
| Интерфейсы камер и подключение | Необходима поддержка высокоскоростных интерфейсов (например, MIPI CSI-2). Выбор между интегрированными и внешними модулями Wi-Fi.                       | MIPI CSI-2 для камер; Wi-Fi встроенный vs внешний модуль [19].                                             |
| Надёжность и хранение данных   | Системы должны обеспечивать отказоустойчивость и соответствие нормативным требованиям. Требуется энергоэффективные решения с высокой плотностью записи. | Надёжные хранилища для CCTV; оптимизация затрат при росте объёма данных [20].                              |
| Бенчмаркинг и показатели       | Оценка CPU, GPU, энергопотребления, использования ресурсов и                                                                                            | Методологии для выявления узких мест; примеры в работах [17,21,22].                                        |

|  |                               |  |
|--|-------------------------------|--|
|  | обработки в реальном времени. |  |
|--|-------------------------------|--|

### **Тренды и инновации**

Недавние тенденции указывают на значительные изменения в том, как технологии внедряются и предоставляются на рынке видеонаблюдения. Интеграторы все чаще сталкиваются с конкуренцией со стороны крупных консолидированных компаний и новых разработчиков технологий, которые часто выходят напрямую на конечных потребителей, минуя традиционные каналы продаж. Эта трансформация меняет динамику конкуренции, вынуждая интеграторов быстро адаптироваться, чтобы оставаться актуальными в меняющемся ландшафте [8,23-27]. Как отмечают отраслевые эксперты, успешными интеграторами будут те, кто внедряет новые технологии и находит инновационные способы повышения ценности для своих клиентов, в то время как те, кто придерживается устаревших подходов, могут столкнуться с трудностями в поддержании темпа [8].

#### **Появление ИИ и облачных решений**

Рост искусственного интеллекта (ИИ) и облачных технологий изменил правила игры для отрасли. Решения для наблюдения с поддержкой ИИ революционизируют видеоаналитику, автоматизируя такие задачи, как распознавание лиц и анализ поведения. Это достижение позволяет операторам-людям сосредоточиться на критически важных обязанностях, одновременно повышая безопасность за счет обнаружения угроз в реальном времени [28]. Интеграция облачных решений также обеспечивает масштабируемость, эффективное хранение данных и экономическую эффективность, делая их все более привлекательными для предприятий любого размера [29].

#### **Кибербезопасность и конфиденциальность**

С быстрым внедрением новых технологий усиливается внимание к кибербезопасности и конфиденциальности. По мере того, как интеграторы систем безопасности включают ИИ и аналитику в свои системы, потенциал уязвимостей в области кибербезопасности возрастает. Следовательно, постоянная оценка и проверка новых технологических решений являются обязательными для обеспечения того, чтобы клиенты выбирали надежных партнеров, способных предоставлять устойчивые решения для безопасности [8][27]. Кроме того, последствия для конфиденциальности, возникающие в результате использования ИИ, вызвали дискуссии о соблюдении различных национальных, государственных и местных законов [8].

#### **Интеграция и взаимосвязанность**

Взаимосвязь физической и кибербезопасности никогда не была более выраженной. Современные меры безопасности все больше зависят от интеграции с системами видеонаблюдения, поскольку слабая кибербезопасность может выявить уязвимости в механизмах физического контроля доступа [30]. Эта тенденция подчеркивает необходимость того,

чтобы предприятия инвестировали в надежные меры кибербезопасности для защиты как своих цифровых активов, так и физических объектов [30].

#### Обеспечение перспективности за счет инноваций

Заглядывая вперед, можно сказать, что отрасль готова к дальнейшему развитию, движимому достижениями в области ИИ, граничных вычислений и технологий интеллектуального наблюдения. Эти инновации не только повышают операционную эффективность, но и открывают путь к более проактивным мерам безопасности. Способность граничных вычислений обрабатывать видеоданные в реальном времени позволяет проводить немедленный анализ, что необходимо для приложений, варьирующихся от управления дорожным движением до мониторинга производственных процессов [31]. Внедрение этих технологий будет иметь решающее значение для предприятий, стремящихся поддерживать высокий уровень безопасности и адаптироваться к постоянно усложняющемуся технологическому ландшафту [28][32].

#### Примеры внедрения

В современных корпоративных условиях системы видеонаблюдения стали неотъемлемой частью повышения физической безопасности, мониторинга операций и предотвращения преступной деятельности. Два примечательных примера демонстрируют ощутимые преимущества, которые эти системы предоставляют в реальных сценариях. Растущая зависимость от таких технологий обусловлена необходимостью обеспечения безопасности на рабочих местах в различных средах, включая оживленные офисные помещения и крупные производственные объекты [33].

Одно из внедрений включало интеллектуальную систему видеонаблюдения, настроенную со встроенными модулями для обнаружения злоумышленников. В этой системе использовались алгоритмы, которые обучались на вводимой информации, чтобы точно идентифицировать несанкционированный доступ и оповещать соответствующий персонал. Эффективность этой системы была продемонстрирована высокими показателями обнаружения: 51% для обнаружения злоумышленников, 92,63% для обнаружения пожара, 80% для обнаружения праздношатания и 93,54% для обнаружения падения, что показывает ее надежность в отношении различных проблем безопасности [22].

Другой корпоративный пример демонстрирует систему обнаружения злоумышленников, построенную с использованием технологии Raspberry Pi. Эта система захватывает видео при обнаружении движения и сохраняет отснятый материал на облачном сервере для последующего анализа. При обнаружении присутствия человека через GSM-модуль отправляются оповещения для уведомления пользователей о потенциальной угрозе. Такие приложения видеонаблюдения не только укрепляют безопасность, но и оптимизируют время реагирования в критических ситуациях [22].

#### Интеграция ИИ и IoT

Интеграция искусственного интеллекта (ИИ) и устройств Интернета вещей (IoT) еще больше расширила возможности систем видеонаблюдения в розничной торговле. Например, ведущий европейский ритейлер внедрил решение на основе ИИ для анализа поведения покупателей с помощью камер видеонаблюдения. Эта система использовала алгоритмы машинного обучения для мониторинга активности в магазине, обнаруживая такое поведение, как воровство или праздничное поведение. Аналитика предоставила полезные данные, которые повысили операционную эффективность и улучшили взаимодействие с клиентами [29][34].

Кроме того, использование видеоаналитики в розничной торговле помогает снизить операционную нагрузку за счет автоматизации процесса мониторинга. Алгоритмы анализируют видеопотоки для обнаружения необычной активности, значительно повышая эффективность мер безопасности при минимизации рисков как для сотрудников, так и для активов [34]. Эта трансформация не только обеспечивает безопасность, но и способствует повышению производительности бизнеса за счет лучшего понимания поведения и предпочтений клиентов [29].

Эти примеры подчеркивают эволюцию ландшафта видеонаблюдения, демонстрируя, как инновационные технологии могут решать различные проблемы безопасности, одновременно способствуя общей операционной эффективности бизнеса.

#### Проблемы и ограничения

Развертывание технологий видеонаблюдения, особенно тех, которые используют искусственный интеллект (ИИ), сильно зависит от правовых и нормативных рамок. По меньшей мере 15 штатов в США приняли законы о распознавании лиц, которые ограничивают использование этой технологии, при этом правила, касающиеся сбора, использования и хранения биометрических данных, различаются в разных юрисдикциях [9]. Это несоответствие может усложнять соблюдение требований, что делает обязательным для команд по безопасности, работающих с ИИ, тщательное исследование соответствующих законов и, возможно, обращение за профессиональной юридической консультацией для снижения рисков, связанных с несоблюдением. В ситуациях, когда нормативные акты неоднозначны, часто безопаснее принять более строгие меры, чем необходимо, чтобы избежать потенциальных юридических последствий [9].

#### Этические дилеммы

Этические последствия использования ИИ в видеонаблюдении представляют собой серьезные проблемы. Хотя исторически камеры видеонаблюдения показывали снижение уровня преступности, повсеместный характер наблюдения вызывает обеспокоенность общественности по поводу конфиденциальности [8]. Кроме того, системы ИИ подвергаются пристальному вниманию из-за предвзятости и потенциала ложных срабатываний (false positive), что может привести к неправомерным

обвинениям и дальнейшим этическим дилеммам, связанным с их развертыванием [8].

#### Кибербезопасность и конфиденциальность

По мере того как технологии ИИ продолжают развиваться, вопросы кибербезопасности и конфиденциальности остаются в центре внимания среди проблем, с которыми сталкиваются как интеграторы, так и пользователи. Новые технологии могут создавать уязвимости, способные скомпрометировать конфиденциальные данные и подорвать эффективность систем безопасности. Интеграция ИИ и аналитики в системы наблюдения требует более глубокого понимания этих рисков, поскольку обеспечение безопасности и конфиденциальности людей становится более сложным с внедрением проактивных систем, анализирующих видеопотоки в реальном времени [8,10].

#### Требования к ресурсам и навыкам

Внедрение сложных систем видеонаблюдения с использованием ИИ и граничных вычислений требует больших инвестиций в ресурсы и наличия специализированных навыков. Например, разработка и развертывание систем на кристалле (SoC) включает передовые производственные ресурсы и опыт, что может стать барьером для небольших организаций или стартапов, которым может не хватать необходимого финансирования и технической поддержки [1]. Кроме того, быстрые темпы технологического прогресса в отрасли требуют от интеграторов постоянно быть в курсе новых технологий, что может быть серьезной проблемой [8].

#### Стоимость и сложность

Экономическая эффективность является серьезной проблемой для организаций, стремящихся внедрить системы наблюдения на основе ИИ. Хотя эти системы могут распределять вычислительную нагрузку на граничные устройства (edge devices), тем самым минимизируя затраты на централизованную инфраструктуру, первоначальные инвестиции в интеграцию таких технологий могут быть значительными [33]. Сложность внедрения этих систем часто требует тщательного баланса между стоимостью, производительностью и масштабируемостью, что может отпугнуть некоторые организации от перехода на передовые решения видеонаблюдения [8,33].

#### Точность машинного зрения

Достижение высокой точности машинного зрения для видеонаблюдения имеет важное значение, но может быть сложной задачей. Такие факторы, как частота кадров, разрешение и оптимизация алгоритмов, влияют на результаты работы. Снижение частоты кадров может упростить требования к обработке, но также может повлиять на эффективность алгоритмов обнаружения, подчеркивая необходимость тщательной оптимизации для обеспечения возможностей обработки в реальном времени [17,33].

### **ЗАКЛЮЧЕНИЕ**

Проведенное исследование систематизирует критерии выбора аппаратных платформ для современных систем видеонаблюдения,

работающих в условиях высоких требований к ИИ-аналитике и кибербезопасности. Анализ показал, что каждый из рассмотренных классов решений System-on-Chip (SoC), Single-Board Computer (SBC) и Compute Module (COM/SoM) занимает четкую нишу.

- SoC являются оптимальным выбором для массового серийного производства, где критически важны максимальная энергоэффективность и высокая степень интеграции.
- SBC остаются незаменимыми для быстрого прототипирования и мелкосерийных проектов благодаря развитой программной экосистеме и минимальному времени выхода на рынок.
- COM/SoM представляют собой сбалансированное решение для промышленных и кастомизированных систем, сочетая надежность и гибкость проектирования несущей платы (carrier board) под конкретные задачи задачи.

Ключевым вкладом работы является предложенная методика сравнительной оценки, основанная на измеримых метриках производительности, энергоэффективности (FPS/W), надежности хранения и сетевой устойчивости. Она позволяет объективизировать выбор платформы в зависимости от профиля нагрузки и эксплуатационных ограничений.

Выбор аппаратной платформы сегодня выходит за рамки чисто технических характеристик. На фоне ужесточения требований к конфиденциальности данных и роста киберугроз, такие аспекты, как поддержка Secure Boot, наличие TPM и возможность реализации концепции Privacy-by-Design, становятся обязательными. Будущее систем видеонаблюдения будет определяться способностью аппаратных решений обеспечивать не только производительность, но и доверие.

### **Список литературы:**

1. Popescu S. M., Mansoor S., Wani O. A. [и др.] Artificial intelligence and IoT driven technologies for environmental pollution monitoring and management // *Frontiers in Environmental Science*. 2024. DOI: 10.3389/fenvs.2024.1336088.
2. Alotaibi E., Nassif N. Artificial intelligence in environmental monitoring: in-depth analysis // *Artificial Intelligence*. 2024. Т. 4, № 84. С. 102-115.
3. Nguyen M. T., Tran H., Nguyen H. [и др.] Energy harvesting for devices in wireless sensor networks: A Review // *EAI Endorsed Transactions on IoT*. 2023. Т. 9, № 2. С. 45-62.
4. System on Chip (SoC) vs Single Board Computer (SBC) - key differences and applications // *Electronics Today*. 2023. № 5. С. 28-34.
5. Comparative analysis of COM and SBC architectures for embedded systems // *Journal of Hardware Engineering*. 2024. Т. 12, № 1. С. 45-58.
6. Modern SBC modules and their applications in industrial IoT // *Embedded Systems Review*. 2023. № 3. С. 22-29.

7. Video analytics applications for IoT surveillance systems // Security Technology Research. 2024. T. 8, № 2. C. 15-24.
8. System on Module versus Single Board Computer: architectural differences // Computing Platforms Journal. 2023. T. 6, № 4. C. 33-41.
9. Selection methodology for single board computers in embedded projects // Embedded Engineering. 2024. № 1. C. 27-35.
10. Performance evaluation of high-end single board computers // Computer Architecture Letters. 2023. T. 15, № 3. C. 88-96.
11. Single Board Computers: architecture, memory and I/O systems // Processor Design Quarterly. 2024. № 2. C. 44-52.
12. Benchmark framework for anonymous video analytics in surveillance systems // IEEE Transactions on Image Processing. 2023. T. 32. C. 210-225.
13. Raspberry Pi Compute Module 4: architecture and performance analysis // Embedded Systems Engineering. 2024. T. 10, № 1. C. 18-26.
14. Comparative study of compute modules and single-board computers // Journal of Embedded Computing. 2023. T. 7, № 2. C. 55-63.
15. Embedded SBCs in smart home automation systems // IoT Systems Review. 2024. № 4. C. 31-39.
16. SBC-based edge computing platforms for Industrial IoT // Industrial Automation Journal. 2023. T. 9, № 3. C. 42-50.
17. Security camera chipset selection methodology // Surveillance Technology. 2024. T. 5, № 1. C. 23-31.
18. Challenges in digital surveillance storage systems // Data Storage Research. 2023. T. 11, № 2. C. 67-75.
19. Edge HPC architectures for AI-based video surveillance // High Performance Computing. 2024. T. 8, № 4. C. 89-97.
20. Implementation of real-time intelligent video surveillance systems // Journal of Real-Time Imaging. 2023. T. 6, № 3. C. 104-112.
21. Integration of video analytics with surveillance infrastructure // Security Informatics. 2024. № 2. C. 38-46.
22. Single board computers for AI projects: comprehensive analysis // Artificial Intelligence Hardware. 2023. T. 4, № 1. C. 72-80.
23. Challenges in video surveillance technology adoption // Security Systems Journal. 2024. T. 7, № 2. C. 51-59.
24. Video surveillance trends and market analysis // Security Technology Forecast. 2023. № 6. C. 28-36.
25. Cloud video surveillance: emerging trends and technologies // Cloud Computing Review. 2024. T. 12, № 3. C. 45-53.
26. Enterprise surveillance systems: future trends // Business Security Quarterly. 2023. № 4. C. 62-70.
27. Edge computing frameworks for real-time activity recognition // Distributed Computing Systems. 2024. T. 9, № 1. C. 33-41.
28. Edge computing boxes with camera modules: implementation aspects // Embedded Vision Systems. 2023. T. 5, № 2. C. 77-85.



- 29.Video surveillance systems in corporate security // Corporate Protection Journal. 2024. № 3. С. 41-49.
- 30.Modern video surveillance techniques for retail security // Retail Technology Research. 2023. Т. 8, № 4. С. 58-66.
- 31.Implementation challenges of AI in video surveillance // AI Systems Engineering. 2024. Т. 6, № 2. С. 29-37.
- 32.Sanislav T. Energy Harvesting Techniques for Internet of Things. University of Kentucky Press, 2025. 234 с.
- 33.Video surveillance market analysis: 2030 outlook // Market Research Digest. 2023. № 7. С. 15-23.

## Бейнебақылау жүйелеріне арналған аппараттық платформалар

**Д. Нұрберген**

Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана,  
Қазақстан.

E-mail: [diasnkteam@gmail.com](mailto:diasnkteam@gmail.com)

**Ғылыми жетекшісі:** Медетов Б.Ж. - Қауымдастырылған профессор.

**Андатпа.** Бейнебақылау жүйелерінің жұмысы құпиялыққа, киберқауіпсіздікке және жергілікті ЖИ-талдауға қойылатын талаптар күшейген жағдайда аппараттық платформаны саналы түрде таңдауды қажет етеді. Мақалада видеоаналитикаға қажетті есептеу мүмкіндіктері, энергия тиімділігі, камералар мен желілер интерфейстері, деректерді сақтау тұрақтылығы, өмірлік цикл және иеленудің жиынтық құны (TCO) тұрғысынан System-on-Chip (SoC), Single-Board Computer (SBC) және Compute Module / System-on-Module (COM/SoM) санатындағы үш шешім қарастырылады. Эксперименттік салыстыру әдістемесі (бенчмарктер мен метрикалар) ұсынылып, нәтижелерді объектив түрде көрсетуге арналған ең қажетті кестелер берілген. Платформа таңдауы жүктеме профиліне (ағын саны, кодектер, ЖИ-инференс), қуат/жылу шектеулеріне, серия көлеміне, сондай-ақ деректерге қойылатын нормативтік талаптарға байланысты екені көрсетіледі.

**Түйін сөздер:** бейнебақылау, edge AI, SoC, SBC, COM/SoM, H.264/H.265, MIPI CSI-2, PoE, TCO, Secure Boot.

## Hardware platforms for video surveillance systems

**D. Nurbergenov**

L.N. Gumilyov Eurasian National University, Astana, Kazakhstan.

\*E-mail: [diasnkteam@gmail.com](mailto:diasnkteam@gmail.com)

**Academic advisor:** Medetov B.Zh. — Associate Professor.

**Abstract.** Operation of video surveillance systems amid heightened requirements for privacy, cybersecurity, and on-device AI analytics necessitates a deliberate choice of hardware platform. This article examines three solution classes System-on-Chip (SoC), Single-Board Computer (SBC), and Compute Module / System-on-Module (COM/SoM) in terms of computational capabilities for video analytics, energy efficiency, camera and network interfaces, storage durability, lifecycle, and total cost of ownership (TCO). We propose an experimental comparison methodology (benchmarks and metrics) and provide a minimal set of tables to objectively present the results. It is shown that platform selection depends on the workload profile (number of streams, codecs, AI inference), power/thermal constraints, production scale, and regulatory requirements for data.

**Keywords:** video surveillance, edge AI, SoC, SBC, COM/SoM, H.264/H.265, MIPI CSI-2, PoE, TCO, Secure Boot.

FTAMP 14.05.07

## Анализ эффективности IoT-систем экологического мониторинга в реальных условиях эксплуатации

Ж. Куатбеков<sup>1</sup>

<sup>1</sup>Евразийский национальный университет имени Л.Н. Гумилёва,  
Астана, Казахстан.

\*E-mail: [gumahan1307@gmail.com](mailto:gumahan1307@gmail.com)

**Научный руководитель:** Медетов Б.Ж. — старший преподаватель.

**Аннотация.** В работе выполнен обзор современных IoT-подходов для экологического мониторинга с акцентом на эксплуатационные условия и сопоставимую эффективность. Проанализированы 30 публикаций 2023–2025 гг. (Scopus, IEEE, MDPI, Frontiers), охватывающих Mesh/WSN (IEEE 802.15.4), LPWAN (LoRaWAN, NB-IoT, Sigfox), Wi-Fi/Ethernet, BLE и гибридные архитектуры (BLE-LPWAN, WSN-Cloud) с интеграцией методов машинного обучения и edge-обработки. Предложена унифицированная система критериев оценки (энергоэффективность, надёжность связи, качество данных, масштабируемость, TCO, устойчивость к внешним условиям, интегрируемость) и проведена балльная сравнительная оценка (1–5). Показано, что LPWAN и BLE обеспечивают максимальную автономность в распределённых сценариях, Mesh превосходит по надёжности в урбанизированной среде, а Wi-Fi/Ethernet оптимален при наличии питания и требований к высокой точности и малым задержкам. Гибридные решения формируют сбалансированный компромисс при разнородных условиях эксплуатации за счёт разделения функций сбора, предобработки и магистральной передачи. Практическая значимость заключается в формировании методической основы выбора архитектуры под конкретные сценарии (удалённые природные территории, городская среда, лабораторно-промышленные площадки) и в рекомендациях по сочетанию энергосбора, duty-cycling, самокалибровки и стандартных протоколов (MQTT/CoAP/LwM2M) для снижения TCO и повышения устойчивости системы.

**Ключевые слова:** Интернет вещей; экологический мониторинг; WSN; LPWAN; BLE; Mesh (IEEE 802.15.4); энергоэффективность; надёжность связи; калибровка датчиков; edge-обработка; машинное обучение.

### Введение

В последние годы в области экологического мониторинга наблюдается стремительное развитие технологий Интернета вещей (IoT) и искусственного интеллекта (AI). Данный процесс обусловлен необходимостью повышения точности измерений, энергоэффективности и автономности сенсорных систем, а также переходом к интегрированным платформам анализа данных в реальном времени. Согласно современным исследованиям [1], [2], [7–11], [19–20], [29], синергия IoT и AI формирует новую парадигму интеллектуальных киберфизических систем, где сенсорные узлы выполняют не только функции сбора информации, но и локальную обработку, фильтрацию и интеллектуальную интерпретацию данных с использованием алгоритмов машинного обучения.

Работа Popescu et al. [1] представляет архитектуры, в которых AI-агенты взаимодействуют с распределёнными IoT-сенсорами, обеспечивая интеллектуальный контроль параметров водной, воздушной и почвенной среды. Исследование Alotaibi и Nassif [2] демонстрирует, что использование нейросетевых моделей и алгоритмов SVM повышает точность прогнозирования и позволяет выявлять нелинейные зависимости в экологических временных рядах. Эти подходы свидетельствуют о смещении парадигмы от пассивного сбора данных к адаптивным, самообучающимся системам мониторинга, способным к контекстной оптимизации.

Работы в журналах *Environmental Advances* [7] и *IJSRA* [9] подчёркивают значимость облачных и краевых вычислений для обеспечения масштабируемости, надёжности и гибкости IoT-платформ. В исследовании IJETT [11] обоснована эффективность гибридных Cloud–Edge-архитектур, а публикации MDPI Informatics [19] и MDPI Processes [20] демонстрируют сравнительный анализ различных вычислительных схем по критериям задержек передачи, устойчивости и энергопотребления. Эти результаты показывают, что интеграция интеллектуальных алгоритмов с распределёнными вычислительными ресурсами является ключевым направлением развития экологических систем наблюдения.

Отдельное внимание уделяется автономным и самоорганизующимся IoT-сетям. В статье *Frontiers in Environmental Science* [29] предложена концепция распределённого принятия решений, при которой AI-агенты оптимизируют энергопотребление, маршрутизацию и частоту передачи данных в реальном времени. Данная архитектура демонстрирует переход от централизованных моделей к адаптивным экосистемам, способным функционировать в сложных условиях эксплуатации при минимальном участии оператора.

Следующий раздел будет посвящён анализу проблематики энергоэффективности, калибровки и надёжности IoT-систем [3–6], [12–16], [18], [21–25], где рассматриваются ключевые технические ограничения, влияющие на стабильность и точность экологического мониторинга. В завершении главы будет сформулирована цель настоящего исследования, заключающаяся в систематизации и сравнительном анализе подходов к построению IoT-систем экологического мониторинга с акцентом на реальные условия эксплуатации. Кроме того, будет представлена методология анализа, основанная на изучении тридцати публикаций 2023–2025 годов из ведущих баз данных Scopus, IEEE, MDPI и Frontiers, что позволит сформировать промежуточные выводы и задать основу для дальнейших аналитических разделов. Проблематика энергоэффективности, калибровки и надёжности IoT-систем

Современные системы экологического мониторинга, основанные на Интернете вещей (IoT), сталкиваются с рядом технологических вызовов, напрямую влияющих на устойчивость, точность и длительность их функционирования. К числу наиболее значимых относятся вопросы

энергоэффективности сенсорных узлов, надёжности каналов связи и корректности получаемых данных. Анализ научных публикаций 2023–2025 годов показывает, что именно эти аспекты определяют практическую жизнеспособность IoT-сетей при эксплуатации в реальных условиях.

В исследовании Nguyen M.T. и др. показана классификация технологий энергосбора, включая солнечные панели, вибрационные и термоэлектрические генераторы [3]. Эти решения позволяют уменьшить зависимость сенсорных узлов от традиционных источников питания и существенно продлить срок автономной работы. Sanislav T. [4] развивает данную идею, предлагая концепцию миниатюрных систем energy harvesting для удалённых IoT-сетей, применяемых в сельскохозяйственных и природоохранных зонах. Эти разработки демонстрируют переход от энергоёмких систем к устойчивым и самообеспечивающимся сенсорным платформам.

В работе Riva C. [5] проведён сравнительный анализ схем автономного питания LoRaWAN-сетей, где особое внимание уделено балансу между стабильностью передачи данных и уровнем энергопотребления. Похожие выводы представлены в публикации Ramadhan A. и др. [6], где рассматриваются методы duty cycling и адаптивного управления передачей пакетов. Такие решения позволяют снизить энергозатраты до 50% без ухудшения точности мониторинга, что делает их актуальными для систем непрерывного наблюдения за экологическими параметрами.

Качество и достоверность данных являются вторым важным направлением совершенствования IoT-систем. В работе Frontiers in Sustainable Cities отмечено, что точность низкобюджетных сенсоров существенно зависит от частоты и корректности калибровки [12]. Невозможность регулярного обслуживания в реальных условиях приводит к накоплению ошибок и искажению данных. В связи с этим активно развиваются методы автоматической и самонастраивающейся калибровки. В исследованиях MDPI Sensors [14] и arXiv [16] показано, что применение нейросетевых автоэнкодеров и алгоритмов машинного обучения позволяет компенсировать дрейф показаний без использования эталонных станций. Такие технологии делают возможным создание самообучающихся сенсорных систем с высоким уровнем автономности.

Надёжность связи и устойчивость передачи данных остаются третьим критическим компонентом IoT-инфраструктуры. Сравнительный анализ, проведённый в публикациях MDPI IoT Journal [22] и MDPI Sensors [23], показывает, что выбор протокола передачи данных (LTE, LoRa, NB-IoT) определяет стабильность системы в различных условиях среды. LoRa и NB-IoT демонстрируют наилучшие результаты при низком энергопотреблении и большой дальности, тогда как LTE обеспечивает высокую пропускную способность для плотных городских зон. Работы MDPI Atmosphere [21] и MDPI Sensors [25] дополняют эти результаты, предлагая алгоритмы

интеллектуальной фильтрации и причинно-ориентированной обработки сигналов для устранения шумов и повышения достоверности данных.

Таким образом, анализ литературы [3–6], [12–16], [18], [21–25] отражает тенденцию к объединению трёх направлений: повышения энергоэффективности, интеллектуальной самокалибровки и обеспечения устойчивой связи. В совокупности они формируют основу новой архитектуры IoT-систем, где энергоавтономные узлы с интеллектуальными сенсорами взаимодействуют в самоорганизующихся сетях. Промежуточный вывод заключается в том, что дальнейшее развитие IoT для экологического мониторинга требует комплексного подхода, объединяющего аппаратные инновации, алгоритмическую адаптацию и надёжные коммуникационные протоколы. Эти аспекты станут методологической основой анализа в следующем разделе статьи.

#### **Цель и методология исследования**

Выявленные в ходе анализа современные тенденции и проблемные аспекты функционирования IoT-систем экологического мониторинга указывают на необходимость их системной классификации и сравнительной оценки по ключевым параметрам эффективности. Несмотря на значительное количество работ, посвящённых отдельным аспектам от энергоэффективности до интеллектуальной обработки данных, отсутствует обобщённая модель, позволяющая сопоставить различные технологические подходы с точки зрения их применимости в реальных условиях эксплуатации.

#### **Цель исследования**

Целью настоящей статьи является проведение систематизации и сравнительного анализа подходов к построению IoT-систем экологического мониторинга с фокусом на их эксплуатационную надёжность, энергоэффективность и точность работы в условиях различной инфраструктурной доступности. В рамках исследования предполагается определить, какие архитектурные решения и коммуникационные технологии демонстрируют наилучшие показатели эффективности в зависимости от сценариев применения от урбанизированных зон до удалённых природных территорий. Для достижения поставленной цели решаются следующие задачи:

- Провести анализ и классификацию архитектурных подходов к IoT-системам (Mesh, LPWAN, WiFi/ETH, BLE, гибридные решения).
- Определить и обосновать критерии оценки эффективности систем экологического мониторинга.
- Провести сравнительный анализ технологий по разработанным критериям на основе актуальных научных публикаций.
- Сформировать рекомендации по выбору оптимальных решений для различных условий эксплуатации.

#### **Методология**

Методологическая основа исследования базируется на комплексном анализе тридцати научных публикаций, опубликованных в 2023–2025 годах в журналах Scopus, IEEE, MDPI, Frontiers и других международных изданиях.

Отбор источников осуществлялся по релевантности ключевым направлениям: энергоэффективность сенсорных сетей, надёжность IoT-коммуникаций, методы интеллектуальной калибровки и машинного обучения для обработки данных.

Для проведения сравнительной оценки были выбраны семь ключевых критериев эффективности:

- Энергоэффективность среднее энергопотребление узла, автономность, поддержка sleep-режимов.
- Надёжность связи потери пакетов, устойчивость к помехам, стабильность канала.
- Качество данных точность измерений, корректность калибровок, стабильность временных рядов.
- Масштабируемость возможность расширения сети, поддержка большого числа узлов.
- Совокупная стоимость владения (ТСО) оборудование, обслуживание, замена источников питания.
- Устойчивость к внешним условиям способность функционировать при экстремальных температурах и влажности.
- Интегрируемость и совместимость поддержка стандартных протоколов и взаимодействие с облачными системами.

Применён метод контент-анализа, включающий качественное сравнение архитектурных подходов, а также балльную оценку технологий по каждому из критериев. Результаты анализа будут представлены в виде сравнительных таблиц и графических моделей, что позволит выявить сильные и слабые стороны каждой технологии и определить перспективные направления дальнейших исследований.

### **Классификация IoT-подходов в экологическом мониторинге**

Современные IoT-системы экологического мониторинга демонстрируют значительное разнообразие архитектурных решений, отличающихся по пропускной способности, энергопотреблению, дальности связи и устойчивости к внешним воздействиям. Наиболее распространённые технологические подходы включают Mesh/WSN, LPWAN, WiFi/Ethernet, BLE и гибридные архитектуры, каждая из которых имеет собственные преимущества и ограничения.

#### **Mesh / WSN-сети**

Сети на основе протоколов IEEE 802.15.4, ZigBee и Thread широко применяются для создания децентрализованных систем с высокой отказоустойчивостью и точностью передачи данных. В исследованиях MDPI Sensors [18] и MDPI Sensors [23] показано, что Mesh-топологии позволяют минимизировать потери пакетов и обеспечивать устойчивую маршрутизацию даже при выходе из строя отдельных узлов. Такие решения особенно эффективны в условиях плотной инфраструктуры и при необходимости непрерывного контроля за параметрами окружающей среды.

#### **LPWAN-технологии**

Класс низкоэнергетических широкополосных сетей (LoRaWAN, NB-IoT, Sigfox) обеспечивает значительное увеличение дальности связи при минимальном энергопотреблении. Работы Sanislav T. [4], Riva C. [5], Ramadhan A. и др. [6], а также исследования MDPI Water [17] и MDPI Sensors [28] демонстрируют, что LPWAN-сети способны функционировать в течение нескольких лет без замены источников питания. Эти решения находят применение в распределённых системах мониторинга качества воздуха, воды и почвы, особенно в удалённых и труднодоступных регионах.

#### WiFi / Ethernet-системы

WiFi и Ethernet применяются преимущественно в стационарных системах экологического контроля, где требуется высокая точность и скорость передачи данных. Исследования MDPI Informatics [19] и MDPI IoT Journal [22] показывают, что данные технологии обеспечивают минимальные задержки и высокую стабильность, однако требуют значительных энергетических ресурсов и не подходят для автономных сенсорных узлов. Тем не менее, они являются оптимальным выбором для лабораторных и промышленных приложений с постоянным источником питания.

#### BLE-сети

Bluetooth Low Energy (BLE) используется для мобильных и indoor-приложений, где важна компактность и низкое энергопотребление. В публикациях IJETT [11] и Frontiers in Chemistry [13] подчёркивается потенциал BLE-сетей в организации персональных систем мониторинга и локальных станций контроля качества воздуха. Их основное преимущество заключается в возможности интеграции с мобильными устройствами и низкой стоимости развертывания.

#### Гибридные архитектуры

Комбинации технологий (BLE–LPWAN, WSN–Cloud) и интеграция искусственного интеллекта формируют новое поколение гибридных IoT-систем. Работы Popescu S. M. и др. [1], Alotaibi E. и Nassif N. [2], а также Frontiers in Environmental Science [29] показывают, что такие решения обеспечивают баланс между энергоэффективностью, точностью и интеллектуальной обработкой данных. Гибридные системы сочетают преимущества локальных и глобальных сетей, обеспечивая распределённую обработку, адаптацию к условиям среды и высокую надёжность функционирования.

Представленная классификация не задаёт предпочтений между технологиями, а задаёт рамку для формализованной оценки. В следующем разделе мы вводим критерии эффективности (энергоэффективность, надёжность связи, качество данных, масштабируемость, ТСО, устойчивость к условиям, интегрируемость), а далее применяем их для сравнительного анализа технологий в типовых сценариях эксплуатации.

#### Критерии оценки эффективности IoT-подходов

Для проведения систематического анализа различных IoT-архитектур в экологическом мониторинге необходимо определить совокупность критериев,



позволяющих объективно оценить их эксплуатационную эффективность. Ниже представлены основные показатели, выделенные на основе анализа современных исследований 2022–2025 годов.

### 1. Энергоэффективность

Энергоэффективность критична для автономных IoT-систем и определяется сочетанием режимов связи, профилей сна и типа источника питания/энергосбора. Сопоставление публикаций (Nguyen M. T. и др. [3]; Sanislav T. [4]; Ramadhan A. и др. [6]; *MDPI Water* [17]; *MDPI Sensors* [26–30]) показывает: чем выше удельная мощность доступного энергосбора и чем агрессивнее duty-cycling, тем дольше срок автономной работы при неизменной метрике качества данных. Для наглядности в таблице 1 сведены усреднённые диапазоны выходной мощности и типовые особенности распространённых технологий энергосбора, применяемых в экологическом мониторинге. Представлены усреднённые значения выходной мощности и основные эксплуатационные характеристики различных типов источников энергии, используемых в современных IoT-платформах экологического мониторинга.

Таблица 1. Сравнительная характеристика источников энергии для автономных IoT-устройств

| Тип источника энергии    | Средняя выходная мощность, мВт/см <sup>2</sup> | Преимущества                                     | Ограничения                         |
|--------------------------|------------------------------------------------|--------------------------------------------------|-------------------------------------|
| Солнечная (PV)           | 18–25                                          | высокая плотность энергии при освещении          | зависимость от уровня освещения     |
| Вибрационная (Piezo)     | 1–3                                            | применима для транспорта, промышленных установок | низкая выходная мощность            |
| RF-энергосбор            | 0.2–0.5                                        | подходит для умных зданий, малые устройства      | малая дальность и низкая мощность   |
| Термоэлектрическая (TEG) | 0.8–2.0                                        | стабильна при перепадах температуры              | ограниченная генерация энергии      |
| Гибридная (PV + Piezo)   | 12–20                                          | устойчивость, резервирование энергии             | сложность схемы и высокая стоимость |

Солнечные и гибридные источники обеспечивают наибольшую плотность энергии ( $\approx 18\text{--}25$  мВт/см<sup>2</sup>), что оптимально для стационарных/полуавтономных узлов с умеренной частотой телеметрии;

термо- и вибрационные решения уступают по мощности, зато работают там, где недоступен свет или присутствуют постоянные колебания/градиенты температуры; RF-энергосбор пока вспомогателен из-за низкой удельной мощности. Отсюда следует, что выбор питания напрямую задаёт допустимую частоту опроса, режим передачи и ресурс сети, и должен рассматриваться вместе с коммуникационной технологией и алгоритмами энергоменеджмента.

## 2. Надёжность связи

Надёжность связи характеризует стабильность и непрерывность передачи данных между узлами сети. Исследования MDPI Water [17], MDPI IoT Journal [22] и MDPI Sensors [28] демонстрируют, что протоколы LPWAN и 802.15.4 обеспечивают устойчивую связь при низком энергопотреблении и большой дальности передачи. Этот параметр критически важен при эксплуатации в условиях помех, высокой влажности или нестабильной топологии сети.

## 3. Качество данных и точность измерений

Точность и достоверность данных определяют научную и практическую ценность IoT-систем. Работы Frontiers in Sustainable Cities [12], Frontiers in Chemistry [13], MDPI Sensors [14–16], MDPI Atmosphere [21] и MDPI Sensors [25] подчёркивают необходимость регулярной калибровки сенсоров и внедрения алгоритмов машинного обучения для коррекции смещений. Повышение точности достигается за счёт самокалибровки, фильтрации шумов и контекстной обработки данных.

## 4. Масштабируемость

Масштабируемость определяет способность системы поддерживать увеличение количества узлов без потери производительности. Исследования MDPI Sensors [18] и MDPI Sensors [23] показывают, что децентрализованные Mesh-сети на основе IEEE 802.15.4 обеспечивают высокую гибкость и адаптивность при расширении IoT-инфраструктуры, что особенно актуально для крупномасштабных экологических проектов.

## 5. Совокупная стоимость владения (TCO)

Совокупная стоимость владения включает расходы на оборудование, обслуживание, замену элементов питания и лицензии. В работах Riva C. [5], MDPI Informatics [19] и MDPI Applied Sciences [24] показано, что низкозатратные решения на базе LPWAN и BLE обладают значительным преимуществом по TCO по сравнению с WiFi/Ethernet, особенно при развёртывании распределённых сетей.

## 6. Устойчивость к внешним условиям

Этот критерий характеризует способность системы функционировать при воздействии экстремальных температур, влажности, пыли и механических вибраций. В исследованиях Sanislav T. [4], Ramadhan A. и др. [6] и MDPI Sensors [27] описаны схемы термостабилизации, влагозащиты и энергозащищённого корпуса, повышающие долговечность сенсорных узлов.

## 7. Интегрируемость и совместимость

Интегрируемость отражает способность IoT-систем взаимодействовать с другими платформами и стандартами обмена данными. Работы Popescu S. M. и др. [1], MDPI Informatics [19] и Frontiers in Environmental Science [29] показывают, что поддержка протоколов CoAP, MQTT и гибридных облачно-краевых решений обеспечивает лёгкую интеграцию с интеллектуальными аналитическими системами и платформами обработки больших данных.

Совокупность указанных критериев формирует основу для последующего сравнительного анализа IoT-подходов. На их базе будет построена таблица сравнительных оценок, что позволит определить оптимальные решения для различных условий эксплуатации систем экологического мониторинга.

### Сравнительный анализ подходов

Как видно из рисунка 1, распределение точек подтверждает таблицу сравнительных баллов и демонстрирует характерный компромисс между автономностью и дальностью связи. Ниже приведена балльная оценка (шкала 1–5) по выбранным критериям для пяти классов решений: BLE, WiFi/Ethernet, LPWAN, Mesh (IEEE 802.15.4) и гибридные архитектуры. Оценки получены на основе синтеза результатов, представленных в источниках [1–30]; шкала нормирована так, что 5 лучший показатель по критерию.

Таблица 1. Сравнительная оценка IoT-подходов по ключевым критериям энергоэффективности и надёжности связи

| Подход                        | Энергоэффективность | Надёжность связи | Качество | Масштабируемость |
|-------------------------------|---------------------|------------------|----------|------------------|
| BLE                           | 5                   | 3                | 4        | 3                |
| WiFi/Ethernet                 | 2                   | 4                | 5        | 4                |
| LPWAN (LoRaWAN/NB-IoT/Sigfox) | 5                   | 4                | 3        | 5                |
| Mesh (IEEE 802.15.4)          | 4                   | 5                | 4        | 4                |
| Гибрид BLE–LPWAN / WSN–Cloud  | 5                   | 5                | 4        | 5                |

Пояснения к оценкам и интерпретация.

1. Энергоэффективность. LPWAN и BLE получают максимально высокие баллы за счёт низкой энергозатраты радиointерфейса и поддержки duty cycling; показано в исследованиях по energy harvesting и оптимизации протоколов [3], [4], [6], [17], [26–30]. WiFi/Ethernet имеет худшие показатели из-за высокого энергопотребления сетевого стека и радиомодуля [19].
2. Надёжность связи. Mesh-сети (802.15.4) демонстрируют максимальную устойчивость благодаря мультитоп-маршрутизации и

самовосстановлению топологии [18], [23]. LPWAN и гибридные решения обеспечивают высокую надёжность на больших расстояниях при правильной конфигурации сети и нагрузке [17], [28]; BLE уступает из-за ограниченной дальности и помехозащищённости в перегруженных диапазонах.

3. Качество данных и калибровка. Наилучшие условия для высокоточных измерений создают WiFi/Ethernet-системы (стационарное питание, высокая пропускная способность, низкие задержки) это облегчает сложные процедуры калибровки и онлайн-валидации [12-16], [21], [25]. Для LPWAN ограниченная полоса и редкая передача усложняют онлайн-коррекцию; оценка ниже, хотя внедрение ML-калибровки постепенно улучшает показатели [14], [16], [25].
4. Масштабируемость. LPWAN и гибриды имеют наивысший балл за счёт большой зоны покрытия и малой нагрузки на узлы; Mesh уступает при сверхбольшом числе узлов из-за роста накладных расходов маршрутизации, но остаётся конкурентоспособным в городских/промышленных сетях [18], [23], [28].
5. Совокупная стоимость владения (TCO). LPWAN и BLE выгодны по стоимости массового развёртывания и обслуживания при длительной автономной работе [5], [24]; WiFi/Ethernet дорожают из-за требований к питанию, инфраструктуре и поддержке [19].
6. Устойчивость к внешним условиям. LPWAN/mesh-узлы часто проектируются как полевые (влагозащита, температурные режимы), что обеспечивает высокий балл [4], [6], [27]. Стационарные WiFi-решения чувствительнее к условиям размещения и помеховой обстановке.
7. Интегрируемость и совместимость. Гибридные архитектуры и WiFi/Ethernet получают максимальные оценки благодаря полноценной поддержке IP-стека, MQTT/CoAP и облачно-краевой интеграции [1], [19], [29]. BLE и LPWAN немного уступают из-за ограничений протоколов и типовых профилей.

Визуализация соотношения энергоэффективности (ось X) и дальности связи (ось Y) для пяти классов технологий приведена на рисунке 1.




Рисунок 1. Соотношение «Энергоэффективность – Дальность связи» для основных IoT-технологий (BLE, Wi-Fi/Ethernet, LPWAN, Mesh,

гибридные).

Примечание: ось Y представлена в логарифмическом масштабе (основание 10) для корректного сравнения дальностей.

Методологическая ремарка. Баллы отражают консолидированную экспертную оценку по источникам [1–30] и предназначены для сравнительного ранжирования технологий по относительной эффективности. В следующем разделе показатели будут использованы для выбора оптимальных архитектур под разные сценарии эксплуатации (удалённые природные территории, урбанизированные зоны, лабораторные/промышленные площадки) и для обоснованного выбора архитектур под разные сценарии эксплуатации (удалённые природные территории, урбанизированные зоны, лабораторно-промышленные площадки).

### **Обсуждение результатов анализа**

Интерпретация сравнительной оценки (см. таблицу в разделе 7) показывает, что ни одна технология не является универсальной для всех условий эксплуатации. Выбор архитектуры должен определяться профилем среды (удалённая/урбанизированная/промышленная), доступностью энергопитания, требуемой частотой измерений и допусками по задержкам. Ниже обобщены выводы для трёх типовых сценариев применения.

Удалённые природные территории (редкая инфраструктура, жёсткие условия, длительная автономия)

Требования: многолетняя автономная работа, большая дальность связи, устойчивость к климатическим воздействиям, допустимы умеренные задержки и низкая частота передачи.

Результаты и вывод: согласно оценкам по критериям энергоэффективности, масштабируемости и устойчивости, наилучшие показатели демонстрируют LPWAN-сети (LoRaWAN/NB-IoT) и их гибриды (BLE–LPWAN) с локальным сбором и предварительной фильтрацией данных на узле. Энергосбор (солнечный/термоэлектрический) и duty cycling позволяют обеспечить многолетнюю автономность; применение алгоритмов самокалибровки и уплотнения данных компенсирует редкую передачу. Mesh и WiFi/Ethernet уступают по дальности и TCO без инфраструктуры питания.

Рекомендации:

- Комбинация LPWAN + локальная предобработка/самокалибровка.
- Энергетическая архитектура с energy harvesting и динамическими профилями сна.
- Передача агрегированных показателей/событий, периодические сессии полноценной телеметрии.

Урбанизированные зоны (плотная застройка, помехи, высокая вариативность нагрузки)

Требования: устойчивость к помехам и вариациям канала, самовосстановление топологии, умеренная/высокая частота измерений, разумная стоимость масштабирования.

Результаты и вывод: Mesh (IEEE 802.15.4) получает максимальный балл по надёжности благодаря мультитоп-маршрутизации и самовосстановлению, что критично при отказах узлов и неоднородной застройке. Для задач высокой плотности датчиков возможна гибридизация: Mesh на «последней миле» + LPWAN/сотовая подсистема для магистральной доставки сводных данных. BLE применим точно (indoor/персональные узлы), а WiFi/Ethernet на стационарных опорных станциях с питанием.

Рекомендации:

- Mesh-кластеризация с адаптивной маршрутизацией и балансировкой нагрузки.
- Опорные шлюзы на Ethernet/WiFi; магистраль LPWAN/сотовая.
- Непрерывная калибровка низкобюджетных сенсоров (ML-коррекция, эталонные узлы).

Лабораторные и промышленные площадки (доступ к питанию, потребность в высокой точности и низких задержках)

Требования: высокая пропускная способность и качество данных, поддержка сложных процедур калибровки в онлайн, минимальные задержки, интеграция с корпоративными ИТ.

Результаты и вывод: WiFi/Ethernet демонстрирует максимальные оценки по качеству данных и интегрируемости. Наличие питания снимает ограничение по энергопрофилю, что позволяет повышать частоту измерений, применять вычислительно сложные алгоритмы предобработки и калибровки, а также обеспечивать строгие SLA по задержкам. Для опасных/экстремальных зон целесообразны смешанные схемы с полевыми LPWAN/mesh-узлами и проводными сборами на уровнях цеха/лаборатории.

Рекомендации:

- Проводной/WiFi-контур для высокочастотной телеметрии и онлайн-калибровки.
  - Интеграция с MQTT/CoAP и облачно-краевой аналитикой; CI/CD для моделей ML.
  - Резервирование каналов и локальные буферы для отказоустойчивости.
- Сквозные соображения (для всех сценариев)

- Калибровка и качество данных. Низкобюджетные сенсоры требуют регулярной или автоматической калибровки; без неё деградируют точность и устойчивость временных рядов. Наилучший эффект дают гибридные схемы: эталонные узлы + ML-самокоррекция.
- Управление энергией. Энергоэффективность критический фактор вне лабораторий. Комбинирование duty cycling, адаптивной частоты опроса и энергосбора радикально увеличивает срок службы.
- Интеграция и совместимость. Поддержка стандартов (MQTT, CoAP, LwM2M), единых профилей данных и открытых API ускоряет масштабирование и снижает ТСО.

Сопоставление балльных оценок и контекста эксплуатации показывает, что для различных сценариев оптимальны разные классы технологий. Это

подтверждает необходимость мультиуровневого подхода, сочетающего преимущества протоколов и топологий в единой IoT-экосистеме и служит основой для итоговых выводов. LPWAN и BLE-гибриды обеспечивают наилучшее сочетание автономности и энергоэффективности, Mesh подходит для устойчивых городских сетей, а WiFi/Ethernet для задач, где приоритетом является точность и интеграция. Эти результаты подтверждают необходимость мультиуровневого подхода, сочетающего преимущества различных протоколов и топологий в единой архитектуре IoT-экосистемы. В заключительном разделе будут подведены общие итоги анализа и обозначены направления дальнейших исследований.




Рисунок 2. Поток данных в интеллектуальной IoT-системе экологического мониторинга (сенсоры → связь → шлюз/edge-обработка → облако → ML-анализ → визуализация).

Edge-уровень снижает объём передаваемых данных за счёт фильтрации и сжатия, повышая энергоэффективность и устойчивость канала; облачный уровень обеспечивает долговременное хранение и обучение моделей для прогнозирования. Для увязки результатов анализа с архитектурой функционирования системы на рисунке 1 представлена обобщённая схема потока данных в IoT-платформе экологического мониторинга: от сенсорных узлов и коммуникационного модуля к шлюзу с edge-обработкой, облачному хранилищу, модулю машинного обучения и подсистеме визуализации/принятия решений. Проведённый обзор показал, что современные IoT-системы экологического мониторинга находятся на этапе активной интеграции с интеллектуальными технологиями обработки данных и энергетически автономными решениями. Анализ подходов продемонстрировал, что эффективность таких систем определяется не только выбором коммуникационного протокола, но и балансом между энергоэффективностью, точностью измерений, надёжностью связи и способностью адаптироваться к условиям эксплуатации.

Сравнительная оценка показала, что наилучшие результаты достигаются при гибридных архитектурах, сочетающих преимущества различных технологий: дальность и энергоэкономичность LPWAN, устойчивость Mesh-сетей, точность и пропускную способность WiFi/Ethernet, а также мобильность BLE. Такой мультиуровневый подход обеспечивает как масштабируемость, так и устойчивость IoT-экосистемы при работе в разнородных условиях от удалённых природных зон до промышленных объектов.

### **ЗАКЛЮЧЕНИЕ**

Ключевыми направлениями дальнейшего развития выступают: повышение энергоавтономности за счёт использования energy harvesting и интеллектуального управления питанием; совершенствование алгоритмов самокалибровки и коррекции данных; создание единых стандартов интеграции между узлами и аналитическими платформами. Особое значение приобретает переход от изолированных решений к распределённым интеллектуальным сетям, способным самостоятельно оптимизировать обмен, фильтрацию и анализ данных в реальном времени.

В целом, развитие экологического мониторинга на основе IoT направлено к построению самоорганизующихся, надёжных и адаптивных систем, минимизирующих человеческое вмешательство и обеспечивающих высокое качество информации для принятия решений в области охраны окружающей среды и устойчивого развития.

Практическая значимость проведённого анализа заключается в том, что его результаты могут служить методической основой при выборе технологической архитектуры для конкретных условий мониторинга от выбора протоколов связи до оптимизации энергопрофиля и схем обработки данных. Представленные выводы формируют концептуальную базу для разработки унифицированных IoT-платформ нового поколения, ориентированных на устойчивость, энергоэффективность и интеллектуальную автономию.

### **Список литературы:**

1. Popescu S. M., Mansoor S., Wani O. A. и др. Artificial intelligence and IoT driven technologies for environmental pollution monitoring and management // *Frontiers in Environmental Science*. — 2024. — DOI: 10.3389/fenvs.2024.1336088.
2. Alotaibi E., Nassif N. Artificial intelligence in environmental monitoring: in-depth analysis // *Artificial Intelligence*. — 2024. — Т. 4, № 84.
3. Nguyen M. T., Tran H., Nguyen H. и др. Energy harvesting for devices in wireless sensor networks: A Review // *EAI Endorsed Transactions on IoT*. — 2023.
4. Sanislav T. Energy Harvesting Techniques for Internet of Things (IoT) [Электронный ресурс]. — University of Kentucky Publications, 2025. — URL: [https://uknowledge.uky.edu/context/slis\\_facpub/article/1082/viewcontent/Energy\\_Harvesting\\_Techniques\\_for\\_Internet\\_of\\_Things.pdf](https://uknowledge.uky.edu/context/slis_facpub/article/1082/viewcontent/Energy_Harvesting_Techniques_for_Internet_of_Things.pdf) (дата обращения:



- 14.10.2025).
5. Riva C. A Comparative Study on Energy Harvesting Battery-Free LoRaWAN // *Electrica Journal*. — 2022. — С. 40–47.
  6. Ramadhan A. и др. Energy saving on IoT using LoRa: a systematic literature review [Электронный ресурс]. — URL: <https://www.researchgate.net/publication/359055085> (дата обращения: 14.10.2025).
  7. Artificial intelligence in environmental monitoring – narrative review // *Environmental Advances* (Elsevier). — 2024.
  8. Chisom O. N., Biu P. W., Umoh A. A. и др. Reviewing the role of AI in environmental monitoring and conservation // *World Journal of Advanced Research and Reviews*. — 2024. — Т. 21, № 1.
  9. Digital tools and AI: Using technology to monitor carbon emissions // *IJSRA*. — 2024. — URL: <https://ijsra.net/sites/default/files/IJSRA-2024-1995.pdf> (дата обращения: 14.10.2025).
  10. AI and IoT for Environmental Monitoring, Applications and Challenges // *IJRPR*. — 2024. — URL: <https://ijrpr.com/uploads/V6ISSUE5/IJRPR47067.pdf> (дата обращения: 14.10.2025).
  11. AI-Powered Environmental Monitoring and Conservation Strategies // *IJETT*. — 2024. — Т. 72, № 8. — URL: <https://ijettjournal.org/Volume-72/Issue-8/IJETT-V72I8P101.pdf> (дата обращения: 14.10.2025).
  12. Are low-cost sensor networks ready for urban digital twins? // *Frontiers in Sustainable Cities*. — 2025.
  13. Carbon-based sensors for AQ networks: IoT and ML integration // *Frontiers in Chemistry*. — 2024.
  14. Calibration methods for low-cost particulate matter sensors: review // *MDPI Sensors*. — 2024.
  15. Long-term evaluation of commercial air-quality sensors (QUANT) // *Atmospheric Measurement Techniques*. — 2024.
  16. Unsupervised calibration for low-cost IoT sensors via self-learning // *arXiv preprint*. — 2025. — URL: <https://arxiv.org/abs/2501.04512> (дата обращения: 14.10.2025).
  17. LoRa-based water quality monitoring system: field deployment and performance // *MDPI Water*. — 2024.
  18. Energy-efficient WSNs: design strategies for environmental IoT // *MDPI Sensors*. — 2024.
  19. Edge vs Cloud vs Hybrid for IoT environmental monitoring // *MDPI Informatics*. — 2024.
  20. Monitoring and Predicting Air Quality with IoT and ML devices // *MDPI Processes*. — 2024.
  21. Low-cost air quality sensors: biases, corrections, and field calibration // *MDPI Atmosphere*. — 2024.
  22. Review of IoT systems for air quality based on LTE and LoRa networks // *MDPI IoT Journal*. — 2024.

23. LoRaWAN sensors and use-cases for environmental IoT applications // MDPI Sensors. — 2023.
24. Power management and multi-parameter LoRa-based environmental sensing // MDPI Applied Sciences. — 2024.
25. Causality-driven feature selection for calibration of low-cost sensors // MDPI Sensors. — 2024.
26. Energy harvesting in WSN: current technologies and trends // MDPI Sensors. — 2024.
27. Powering Agri-IoT sensors using natural temperature gradients // MDPI Sensors. — 2024.
28. Comparative study of LPWAN protocols for IoT environmental networks // MDPI Sensors. — 2024.
29. Integrating Artificial Intelligence Agents with the Internet of Things for Enhanced Environmental Monitoring Applications in Water Quality and Climate Data // Frontiers in Environmental Science. — 2025. — URL: <https://www.frontiersin.org/articles/10.3389/fenvs.2025.015924/full> (дата обращения: 14.10.2025).
30. RF Energy Harvesting Techniques for Battery-less Wireless Sensing: Industry 4.0 and Internet of Things – A Review // IEEE Access. — 2024. — URL: <https://ieeexplore.ieee.org/document/10432689> (дата обращения: 14.10.2025).

### **Қоршаған ортаның экологиялық жағдайын қашықтықтан бақылау жүйесін әзірлеу**

**Ж. Куатбеков**

Л.Н.Гумилев атындағы Еуразия ұлттық университеті, Астана,  
Қазақстан.

E-mail: [gumahan1307@gmail.com](mailto:gumahan1307@gmail.com)

**Ғылыми жетекшісі: Медетов Б.Ж. - аға оқытушы.**

**Аңдатпа.** Бұл құжат жұмыс жағдайлары мен салыстырмалы өнімділікке назар аударып, қоршаған ортаны бақылаудың заманауи IoT тәсілдеріне шолу жасайды. Біз Mesh/WSN (IEEE 802.15.4), LPWAN (LoRaWAN, NB-IoT, Sigfox), Wi-Fi/Ethernet, BLE, және WLELP-интеграциялау архитектурасы (SNB-Cloud, гибриді) қамтитын 2023 және 2025 жылдар аралығында (Scopus, IEEE, MDPI, Frontiers) жарияланған 30 жарияланымға талдау жасадық. машиналық оқыту және шеттерді өңдеу әдістері. Бағалау критерийлерінің бірыңғай жүйесі (энергия тиімділігі, байланыс сенімділігі, деректер сапасы, ауқымдылық, ТШО, сыртқы жағдайларға төзімділік және интеграциялық) ұсынылады және салыстырмалы баллды бағалау (1-5) орындалады. LPWAN және BLE таратылған сценарийлерде максималды автономияны қамтамасыз ететіні, Mesh қалалық орталарда сенімділігі жағынан жоғары, ал Wi-Fi/Ethernet қуат қолжетімді болғанда және жоғары дәлдік пен төмен кідіріс талаптары қажет болғанда оңтайлы екені көрсетілген. Гибриді шешімдер деректерді жинау, алдын ала өңдеу және магистральдық беру функцияларын бөлу арқылы гетерогенді жұмыс жағдайында теңдестірілген ымыраға келеді. Тәжірибелік маңыздылығы нақты сценарийлер үшін

архитектураны таңдаудың әдіснамалық негізін қалыптастыруда (шалғайдағы табиғи аумақтар, қалалық орталар, зертханалық және өнеркәсіп орындары) және ТШО-ны азайту және жүйені жақсарту үшін энергияны жинау, жұмыс циклі, өзін-өзі калибрлеу және стандартты хаттамаларды (MQTT/CoAP/LwM2M) біріктіру бойынша ұсыныстарда жатыр.

**Түйін сөздер:** Интернет заттары; қоршаған ортаны бақылау; WSN; LPWAN; BLE; Тор (IEEE 802.15.4); энергия тиімділігі; байланыс сенімділігі; сенсорды калибрлеу; шеттерін өңдеу; машиналық оқыту.

## Development of a Remote Environmental Monitoring System

**Zh. Kuatbekov**

L.N. Gumilyov Eurasian National University, Astana, Kazakhstan.

\*E-mail: [gumahan1307@gmail.com](mailto:gumahan1307@gmail.com)

**Academic advisor:** Medetov B.Zh. — Senior Lecturer.

**Abstract.** This paper provides a review of modern IoT approaches for environmental monitoring, focusing on operational conditions and comparable performance. We analyzed 30 publications published between 2023 and 2025 (Scopus, IEEE, MDPI, Frontiers), covering Mesh/WSN (IEEE 802.15.4), LPWAN (LoRaWAN, NB-IoT, Sigfox), Wi-Fi/Ethernet, BLE, and hybrid architectures (BLE-LPWAN, WSN-Cloud) with the integration of machine learning and edge processing methods. A unified system of evaluation criteria (energy efficiency, communication reliability, data quality, scalability, TCO, resilience to external conditions, and integrability) is proposed, and a comparative score assessment (1-5) is performed. It is shown that LPWAN and BLE provide maximum autonomy in distributed scenarios, Mesh is superior in reliability in urban environments, and Wi-Fi/Ethernet is optimal when power is available and high accuracy and low latency requirements are required. Hybrid solutions form a balanced compromise under heterogeneous operating conditions by separating the functions of data collection, preprocessing, and trunk transmission. The practical significance lies in the formation of a methodological basis for selecting an architecture for specific scenarios (remote natural areas, urban environments, laboratory and industrial sites) and in recommendations for combining energy harvesting, duty-cycling, self-calibration, and standard protocols (MQTT/CoAP/LwM2M) to reduce TCO and improve system resilience.

**Keywords:** Internet of Things; environmental monitoring; WSN; LPWAN; BLE; Mesh (IEEE 802.15.4); energy efficiency; communication reliability; sensor calibration; edge processing; machine learning.

FTAMP 20.00.00

## Инклюзивті білім беру ортасында оқытуды жекелендіру үшін машиналық оқыту алгоритмдерін қолдану

**Ажимбетов С. К.**

Астана халықаралық университеті, Астана, Қазақстан

*\*E-mail: sazhimbetov@gmail.com*

**Аннотация.** Бұл мақалада инклюзивті білім беру жүйесінде машиналық оқыту алгоритмдерін қолдану арқылы оқыту процесін жекелендірудің ғылыми және әдістемелік негіздері қарастырылады. Зерттеудің мақсаты – жасанды интеллект технологияларын пайдалана отырып, ерекше білім беру қажеттіліктері бар оқушылар үшін бейімделген білім беру ортасын құрудың тиімді тәсілдерін айқындау. Библиометриялық талдау нәтижелері көрсеткендей, соңғы жылдары бұл бағыттағы зерттеулер айтарлықтай артқан және олардың басым бөлігі оқыту сапасын арттыру мен жеке оқу траекториясын қалыптастыруға бағытталған. Мақалада педагогикалық, техникалық және этикалық аспектілерді біріктіре отырып, инклюзивті білім беруде жасанды интеллектті қолданудың болашағы мен шектеулері талданады.

**Түйін сөздер:** инклюзивті білім беру, машиналық оқыту, жасанды интеллект, бейімделген оқыту, персонализация, білім беру технологиялары.

### Кіріспе

Қазіргі таңда білім беру саласында жасанды интеллект пен машиналық оқыту технологияларын пайдалану білім беру жүйесін жаңғыртудың маңызды бағытына айналып отыр. Цифрландыру үдерісі оқыту сапасын арттырумен қатар, оқушылардың жеке қабілеттерін ескеретін бейімделген оқу ортасын құруға мүмкіндік береді. Әрбір оқушының танымдық ерекшеліктері мен оқу қарқыны әртүрлі болғандықтан, дәстүрлі оқыту тәсілдері барша білім алушылардың қажеттіліктерін толық қамтамасыз ете алмайды [1]. Осы себепті соңғы жылдары білім беруді дербестендіру немесе персонализациялау мәселесіне ерекше назар аударылуда.

Машиналық оқыту әдістері оқушылардың оқу тарихы мен мінез-құлқына негізделген деректерді талдау арқылы олардың оқу стиліне сай тапсырмаларды автоматты түрде таңдауға мүмкіндік береді. Мұндай тәсіл оқушылардың оқу жетістіктерін арттырумен қатар, мұғалімдерге оқу процесін тиімді жоспарлауға жәрдемдеседі [2]. Мысалы, нейрондық желілер мен шешім ағаштары сияқты алгоритмдер оқу материалын күрделілігіне қарай бейімдеп, әр оқушы үшін жеке оқу траекториясын қалыптастыра алады.

Инклюзивті білім беру тұжырымдамасы барлық балалардың, соның ішінде ерекше білім беру қажеттіліктері бар оқушылардың да сапалы білімге тең қолжетімділігін қамтамасыз етуге бағытталған [3]. Дегенмен инклюзивті ортада әр оқушының қабылдау ерекшеліктері мен оқу қарқыны әрқилы болғандықтан, мұғалімге оқу мазмұнын бейімдеу үлкен әдістемелік қиындықтар тудырады. Осындай жағдайда жасанды интеллект негізіндегі

адаптивті жүйелер оқушылардың қажеттіліктерін ескеріп, оқыту процесін жекешелендірудің тиімді тетігі бола алады [4].

Жасанды интеллект пен машиналық оқыту технологияларын инклюзивті білім беру жүйесіне енгізу – тек техникалық жаңалық қана емес, сонымен қатар педагогикалық тиімділікті арттыруға бағытталған ғылыми міндет. Бұл зерттеудің өзектілігі – инклюзивті білім беру жағдайында оқытуды дараландырудың алгоритмдік және әдістемелік негіздерін айқындауда. Мақалада машиналық оқыту әдістерінің мүмкіндіктері, олардың инклюзивті ортада қолданылуы мен тиімділігі қарастырылып, осы бағыттағы қазіргі ғылыми зерттеулерге талдау жасалады.

### **Әдебиеттерге шолу және теориялық негіздер**

Білім беруді дараландыру (персонализация) идеясы педагогика мен психология саласында бұрыннан зерттеліп келе жатқан мәселе. Дж. Дьюи, Л. С. Выготский және Б. Блум еңбектерінде жеке ерекшеліктерді ескеретін оқыту қағидаларының маңыздылығы ерекше атап өтілген. Алайда цифрлық технологиялардың дамуы бұл ұғымды жаңа деңгейге көтерді. Қазіргі заманғы ақпараттық жүйелер мен жасанды интеллект әдістері оқушының оқу үдерісін нақты деректер негізінде бейімдеп, жеке оқу траекториясын автоматты түрде құруға мүмкіндік береді [5].

Машиналық оқыту әдістері білім беру саласында негізінен үш бағытта қолданылады: оқушылардың оқу үлгерімін болжау, оқу материалын бейімдеу және оқыту сапасын бағалау. Білім аналитикасы мен білім беру деректерін өңдеу (Learning Analytics және Educational Data Mining) салалары осы бағыттардың теориялық негізін құрайды [6]. Зерттеулер көрсеткендей, шешім ағаштары, кластерлеу, нейрондық желілер және регрессиялық модельдер оқушылардың үлгерімін болжауда және жеке ұсыныстар жасауда тиімді нәтижелер береді [7].

Персонализацияланған оқыту жүйелері тек білім беру мазмұнын бейімдеумен шектелмей, оқушының мотивациясын, эмоциялық жағдайын және танымдық ерекшеліктерін де ескере алады. Мұндай тәсіл адам мен машина өзара әрекеттесетін интеллектуалды оқыту ортасын қалыптастырады. Мәселен, Deep Learning негізіндегі модельдер оқушының мінез-құлық үлгілерін анықтап, шаршау немесе қызығушылық деңгейін талдай алады [8]. Бұл өз кезегінде оқыту процесінің тиімділігін арттырып, оқу барысын үнемі қолдап отыруға мүмкіндік береді.

Инклюзивті білім беру контекстінде жасанды интеллекттің рөлі ерекше маңызға ие. Ерекше білім беру қажеттіліктері бар балалар үшін оқу материалын бейімдеу қолжетімділікті арттырады және когнитивтік жүктемені азайтады [9]. Мысалы, сөйлеу бұзылыстары бар балаларға арналған жүйелер табиғи тіл өңдеу алгоритмдерін (Natural Language Processing) қолдану арқылы жаттығулардың күрделілігін біртіндеп арттыра алады. Ал көру қабілеті шектеулі оқушылар үшін компьютерлік көру (Computer Vision) технологиялары оқулық мазмұнын дыбыстық форматқа түрлендіруде тиімді қолданылады.

Дегенмен ғылыми әдебиеттерде бірнеше шектеулер мен шешілмеген мәселелер бар. Біріншіден, көп зерттеулер машиналық оқыту алгоритмдерінің техникалық сипаттамасына бағытталып, педагогикалық және психологиялық тиімділік жағын жеткілікті түрде ашпайды. Екіншіден, инклюзивті ортаға арналған деректер жиынтығының жеткіліксіздігі модельдердің жалпы тиімділігін төмендетеді [10]. Үшіншіден, кейбір жүйелер оқушылардың эмоциялық жағдайын немесе әлеуметтік өзара әрекеттесуін елемей, тек академиялық көрсеткіштерге сүйенеді.

Осыған байланысты қазіргі зерттеулердің басым бағыты – жасанды интеллект әдістерін педагогикалық тұрғыдан негіздеп, инклюзивті ортада қолдануға бейімдеу болып табылады. Білім алушылардың әртүрлі қажеттіліктерін ескеретін адаптивті оқыту жүйелерін жобалау үшін педагогикалық дизайн мен алгоритмдік модельдеуді ұштастыру қажет. Бұл бағытта теориялық және қолданбалы зерттеулердің үйлесімі білім беруді цифрлық трансформациялаудың жаңа кезеңіне жол ашады.

### Әдіснама

Бұл зерттеу жұмысының әдіснамалық негізі библиометриялық талдауға сүйенеді. Зерттеу барысында Bibliometrix құралы арқылы ғылыми жарияланымдардың сандық көрсеткіштері мен тақырыптық бағыттары талданды. Талдау деректері 2020 жылдан 2025 жылға дейінгі аралықтағы 52 түрлі дереккөзден алынған 100 ғылыми еңбекті қамтиды. Орташа жылдық өсу қарқыны 37,18 пайызды құрап, бұл бағыттағы зерттеулердің айтарлықтай серпін алғанын көрсетті. Әрбір мақалаға шаққандағы орташа дәйексөз саны 10,93 болды, ал зерттеу дерекқорындағы жалпы сілтемелер саны 906-ға жетті.

Зерттеу барысында негізгі талдау бірліктері ретінде мақалалар, конференция материалдары және кітап тараулары алынды. Барлығының ішінде 51 конференция еңбегі мен 29 ғылыми мақала ерекше орын алды. Бұл деректер жасанды интеллект пен машиналық оқыту технологияларын білім беру саласында қолдану мәселесінің халықаралық ғылыми қауымдастықта кеңінен зерттеліп жатқанын дәлелдейді.


Авторлар арасындағы ынтымақтастық деңгейі жоғары екені анықталды: әрбір мақалада орта есеппен 6,44 автор қатысқан және халықаралық авторлық үлес 18 пайызды құрады. Бұл көрсеткіштер зерттеудің көпсалалы сипатын, сондай-ақ білім беру технологияларының интернационалдық зерттеу нысанына айналғанын көрсетеді [11].

Библиометриялық көрсеткіштерге сәйкес, зерттелген ең ықпалды дереккөздердің қатарында *Communications in Computer and Information Science*, *Lecture Notes in Networks and Systems*, *Education Sciences*, *Sustainability (Switzerland)* және *Journal of Research on Technology in Education* сияқты журналдар мен конференция жинақтары болды. Бұл басылымдарда жасанды интеллект, адаптивті оқыту және дербестендірілген білім беру тақырыптары жиі қарастырылған [12].

Жылдар бойынша талдау нәтижесінде 2021 және 2024 жылдары жарияланымдардың дәйексөз алу деңгейі айтарлықтай артқаны байқалды.

2024 жылы әрбір мақалаға шаққандағы орташа дәйексөз саны 23,79 болды. Бұл кезеңде *Bond (2024)* және *Crompton (2024)* сияқты зерттеулер ерекше ықпал еткен [13]. Аталған авторлардың еңбектерінде жоғары білім беру жүйесінде жасанды интеллектті интеграциялау мен дербестендірілген оқыту тәжірибесін талдау маңызды нәтижелер берді.

Библиометрикалық талдау нәтижесінде мақалалар арасында кілттік сөздер, цитаталар, тақырып аты, аңдатпа бөлімдерінен көп кездесетін сөздер 1 суретте көрсетілген.



Сурет 1. Библиометрикалық талдау нәтижесіндегі мақалаларда қолданылатын сөздің кездесуі

Библиометрикалық талдау нәтижесінде мақалалар арасында кілттік сөздер, цитаталар, тақырып аты, аңдатпа бөлімдерінен көп кездесетін сөздер 1 кестеде жазылған.

Кесте 1. Библиометрикалық талдау нәтижесіндегі мақалаларда қолданылатын сөздің кездесуі

|                                      |   |            |            |            |
|--------------------------------------|---|------------|------------|------------|
| artificial intelligence              | 1 | 394,346705 | 0,02083333 | 0,12498181 |
| artificial intelligence in education | 1 | 294,748736 | 0,02040816 | 0,11336127 |
| education                            | 1 | 61,5894255 | 0,01587302 | 0,0591264  |
| teaching                             | 1 | 28,690244  | 0,01587302 | 0,0470866  |
| students                             | 1 | 16,5373846 | 0,01449275 | 0,0386467  |
| personalized learning                | 1 | 11,8574398 | 0,01388889 | 0,03119036 |
| contrastive learning                 | 1 | 7,79449517 | 0,01351351 | 0,03360957 |
| adversarial machine learning         | 1 | 3,66150332 | 0,01298701 | 0,02734296 |
| artificial intelligence (ai)         | 1 | 4,92958615 | 0,01315789 | 0,02488448 |
| engineering education                | 1 | 2,93203422 | 0,01219512 | 0,02038472 |
| personalizations                     | 1 | 0,25004414 | 0,01204819 | 0,01525048 |
| teachers'                            | 1 | 0,59807549 | 0,01204819 | 0,01784733 |

|                                      |   |            |            |            |
|--------------------------------------|---|------------|------------|------------|
| ai in education                      | 1 | 0,12625779 | 0,01162791 | 0,01308903 |
| federated learning                   | 1 | 0,10755495 | 0,01162791 | 0,01615973 |
| learning experiences                 | 1 | 2,69382817 | 0,01282051 | 0,01928284 |
| adaptive learning                    | 1 | 0,59749312 | 0,01176471 | 0,01383886 |
| ai                                   | 1 | 0,22681992 | 0,01111111 | 0,00972483 |
| ethics                               | 1 | 0,434134   | 0,01149425 | 0,01215479 |
| learning                             | 1 | 0          | 0,01098901 | 0,0078385  |
| artificial intelligence technologies | 1 | 0,06647116 | 0,01136364 | 0,01002777 |

Кілттік сөздерді талдау нәтижесінде жиі кездескен ұғымдар *artificial intelligence*, *personalized learning*, *adaptive learning*, *education* және *students* болды. Бұл бағыттың зерттеу өзегі машиналық оқыту әдістері арқылы оқу процесін жекелендіру және білім алушылардың ерекшеліктерін ескеретін цифрлық білім беру экожүйесін қалыптастыру екенін көрсетті [14].

Осылайша, библиометриялық талдау зерттеу тақырыбының өзектілігін және соңғы жылдары оның ғылыми қауымдастықта белсенді түрде дамып келе жатқандығын дәлелдеді. Нәтижесінде алынған мәліметтер кейінгі бөлімдерде жүргізілетін теориялық және практикалық талдауларға негіз болды.

### Нәтижелер

2020–2025 жылдар аралығында инклюзивті білім беру мен машиналық оқыту технологияларын біріктіру мәселесіне арналған ғылыми жарияланымдар саны айтарлықтай өскені байқалды. Жалпы алғанда, талдау аясында 100 құжат қарастырылды, олардың ішінде 52 түрлі дереккөз (журналдар, конференциялар, кітаптар және т.б.) қамтылған. Орташа жылдық өсу қарқыны **37,18%**, бұл бағыттың ғылыми қауымдастықта жоғары қызығушылық тудырып отырғанын көрсетеді [15].

Зерттелген еңбектердің орташа жасы **1,78 жыл**, бұл саланың әлі де жаңа және дамып келе жатқан бағыт екенін дәлелдейді. Әрбір құжатқа шаққандағы орташа дәйексөз саны **10,93** болғандықтан, тақырыптың ғылыми маңыздылығы мен зерттеулердің сапасы жоғары деңгейде екені байқалады [16].

Жылдар бойынша жарияланым санының арту тенденциясы анық көрінеді. 2020 жылы тек 7 еңбек жарық көрсе, 2025 жылы олардың саны 34-ке жеткен. Әсіресе 2024 жылы жарияланымдар саны мен дәйексөздердің күрт өсуі байқалды, бұл жылдағы орташа дәйексөз саны **23,79** құрады. Мұндай серпін ғылыми қызығушылықтың артып, AI және инклюзивті білім беру мәселелерінің жаһандық зерттеу кеңістігінде маңызға ие бола бастағанын дәлелдейді.

2021 жылдан бастап жарияланымдарда AI технологияларын қолданудың этикалық, педагогикалық және техникалық аспектілері көбірек қарастырылған. Бұл үрдіс Bozkurt (2021) және Crompton (2024) еңбектерінде ерекше көрініс тапқан, онда зерттеушілер жасанды интеллект арқылы жеке оқу тәжірибесін жақсартудың мүмкіндіктерін талдаған



Зерттеу нәтижелері бойынша ең көп жарияланымдар келесі беделді дереккөздерде тіркелген:


- Communications in Computer and Information Science (5 мақала);
- Lecture Notes in Networks and Systems (4 мақала);
- ACM International Conference Proceeding Series (3 мақала);
- Education Sciences (3 мақала).

Бұл басылымдар көбіне білім берудегі цифрлық трансформация мен интеллектуалды жүйелердің дамуына арналған зерттеулерге назар аударады.

Сондай-ақ **Sustainability (Bozkurt, 2021)** және **Journal of Research on Technology in Education (Crompton, 2024)** журналдары ең жоғары дәйексөз алған еңбектермен ерекшеленеді. Бұл мақалаларда авторлар инклюзивті білім беру жүйесінде адаптивті оқыту алгоритмдерінің тиімділігін жан-жақты талдаған. 100 мақаланың 364 авторы бар, яғни бір еңбекке орта есеппен **6,44 автор** келеді. Бұл зерттеу бағытының көпсалалы және халықаралық сипатта дамып жатқанын көрсетеді. **Халықаралық авторлық қатысу үлесі – 18%**, бұл көрсеткіш әлемнің әр түкпірінен ғалымдардың ортақ ғылыми қызығушылығының жоғары екенін айғақтайды.

Сонымен қатар бірде-бір мақала жеке автор тарапынан жазылмаған, бұл да ғылыми ынтымақтастық пен ұжымдық ізденістің маңызын көрсетеді.

Кілт сөздер жиілігі бойынша ең жиі кездескен ұғымдар мыналар: **“artificial intelligence” (83 per), “artificial intelligence in education” (60), “personalized learning” (16), “adaptive learning” (7), “inclusive education” (6).** Бұл терминдердің жиілігі зерттеулердің негізгі бағыты — AI технологияларын инклюзивті және дербестендірілген білім беру жүйесіне енгізу екенін айқын көрсетеді. 2024 жылдан бастап **“generative AI”, “ethical technology”** және **“federated learning”** секілді жаңа тақырыптар жиі талқылана бастаған. Бұл жасанды интеллектті білім беру процесінде қолданудың жаңа этикалық және техникалық өлшемдері қалыптасып келе жатқанын білдіреді. Библиометрикалық талдау нәтижесінде мақалаларда көп қолданылатын кілттік сөздерді 2-суреттен қарауға болады.



Сурет 2. Библиометрикалық талдауда көп қолданылған кілттік сөздер

Библиометриялық талдау нәтижесінде ең көп дәйексөз алған зерттеу **Bond (2024)** еңбегі, ол 220 рет дәйексөзделген. Бұл жұмыста жоғары білім саласында жасанды интеллекттің оқыту тәжірибесін бейімдеу мен қолжетімділікті арттырудағы рөлі жан-жақты талданған [17]. Одан кейінгі орында **Bozkurt (2021)** және **Crompton (2024)** авторларының еңбектері тұр. Олар AI негізіндегі бейімделген оқыту жүйелерінің педагогикалық тиімділігін және оқушылардың жеке ерекшеліктеріне сәйкес оқу процесін ұйымдастыру мүмкіндіктерін зерттеген. Жалпы алғанда, 2020-2025 жылдар аралығындағы библиометриялық талдау жасанды интеллект пен машиналық оқыту әдістерін білім беруде, әсіресе инклюзивті ортада қолдануға деген ғылыми қызығушылықтың күрт артқанын көрсетті. Бұл салада зерттеулердің сапасы, жарияланым саны және халықаралық әріптестік деңгейі тұрақты өсіп келеді.

Негізгі бағыттар адаптивті оқыту жүйелері, студенттердің оқу нәтижелерін болжау, жеке оқу траекторияларын құру және этикалық қауіпсіздік мәселелері. Осы үрдістер болашақта инклюзивті білім беру ортасын технологиялық тұрғыда жаңғыртып, оқушылардың мүмкіндіктерін теңестіруге жол ашады.

### Талқылау

Бұл зерттеудің нәтижелері көрсеткендей, инклюзивті білім беру саласында машиналық оқыту алгоритмдерін қолдану бағытындағы ғылыми зерттеулер соңғы онжылдықта қарқынды дамып келеді. Зерттеулердің көпшілігі жеке оқу траекторияларын қалыптастыруға, студенттердің үлгерімін болжауға және оқу процесіндегі қиындықтарды ерте кезеңде анықтауға бағытталған [18]. Бұл үрдіс білім беруді цифрландыру мен жасанды интеллект технологияларының интеграциялануының табиғи нәтижесі болып табылады.

Инклюзивті білім беру контекстінде алгоритмдердің басты артықшылығы оқушылардың жеке ерекшеліктерін ескере отырып, оқу контентін автоматты түрде бейімдеу қабілеті. Мысалы, нейрондық желілер мен шешім ағаштары негізінде құрылған жүйелер оқушылардың өткен тапсырмалардағы мінез-құлқын талдай отырып, оларға келесі материалдардың күрделілік деңгейін реттей алады [19]. Бұл тәсіл, өз кезегінде, ерекше білім беру қажеттіліктері бар оқушылардың оқу процесіне белсенді қатысуына мүмкіндік береді. Сонымен қатар, библиометриялық талдау көрсеткендей, ғылыми қауымдастықтың назарында көбіне оқыту процесін бейімдеудің техникалық және әдіснамалық аспектілері тұр. Дегенмен, әлеуметтік және педагогикалық факторларға аз көңіл бөлінгені байқалады [20]. Бұл теңгерімсіздік, әсіресе инклюзивті ортада маңызды, себебі мұндай контекстте технологиялар тек көмекші құрал ғана емес, сонымен бірге әлеуметтік өзара әрекеттестіктің делдалы болып табылады.

Зерттеулердің бір бөлігі (мысалы, [21]) көрсеткендей, бейімделген білім беру платформаларының тиімділігі тек алгоритмдердің дәлдігімен емес, сондай-ақ пайдаланушылардың сенімі мен педагогтардың қабылдау деңгейімен тығыз байланысты. Мұғалімдер мен білім алушылар платформамен қалай өзара әрекеттесетінін түсіну үшін сапалық зерттеу

әдістерін қолдану маңызды. Сондықтан келешекте тек техникалық шешімдерді жетілдірумен шектелмей, адам-машина өзара әрекеттестігінің педагогикалық және психологиялық аспектілерін зерттеу қажет.

Библиометриялық нәтижелерге сүйене отырып, 2020 жылдан кейінгі кезеңде инклюзивті білім беру мен жасанды интеллект саласындағы зерттеулердің айтарлықтай өскені байқалады. Бұл үрдіс COVID-19 пандемиясының әсерінен қашықтықтан оқыту мен цифрлық платформаларға сұраныстың артуымен байланысты [22]. Алайда, бұл зерттеулердің басым бөлігі дамыған елдерде жүргізілген. Қазақстан секілді дамушы елдерде мұндай технологияларды енгізудің әдістемелік және инфрақұрылымдық қиындықтары әлі де бар [23].

Мысалы, отандық контексте бейімделген жүйелердің көпшілігі тек оқу контентін ұсынуға бағытталған, бірақ оқушылардың когнитивтік және эмоционалдық жағдайларын ескеруге қабілетті модельдер сирек кездеседі. Бұл бағытта терең оқыту мен табиғи тілдерді өңдеу технологияларын қолдану перспективалы болып саналады [24]. Осындай модельдер білім алушының эмоционалдық реакциясын талдау арқылы, мысалы, мәтіндік жауаптардағы немесе бет әлпетіндегі өзгерістер негізінде, оның оқу мотивациясын анықтай алады.

Талдау нәтижелері көрсеткендей, машиналық оқыту алгоритмдерін инклюзивті білім беру жүйесіне енгізу тек технологиялық міндет емес, сонымен қатар әлеуметтік және этикалық жауапкершілікті қажет ететін күрделі процесс. Жасанды интеллект жүйелерінің шешім қабылдау логикасы ашық әрі түсінікті болуға тиіс, себебі бейімделу механизмі дұрыс түсіндірілмеген жағдайда, ол оқушылар арасындағы теңсіздікті күшейтіп жіберуі мүмкін [25]. Сондықтан болашақ зерттеулерде «түсіндірілетін жасанды интеллект» (Explainable AI) қағидаттарын пайдалану маңызды рөл атқаруы тиіс.

Қорытындылай келе, қазіргі ғылыми әдебиеттерде машиналық оқыту әдістерінің инклюзивті білім беруді қолдаудағы әлеуеті жоғары деп бағаланады. Алайда, теориялық модельдер мен нақты практикалық шешімдердің арасында алшақтық бар. Осы олқылықты жою үшін педагогика, психология және информатика салаларының интеграциясын күшейту қажет. Бұл өз кезегінде, білім алушылардың жеке қабілеттерін ескеретін, шын мәнінде инклюзивті және бейімделген цифрлық экожүйелерді құруға мүмкіндік береді.

### **Қорытынды**

Зерттеу нәтижелері машиналық оқыту алгоритмдерінің инклюзивті білім беру процесін жеке қажеттіліктерге бейімдеуде үлкен әлеуетке ие екенін көрсетті. Мұндай технологиялар білім алушылардың үлгерімін талдауға, олардың оқу стилін анықтауға және оқыту мазмұнын тиімді реттеуге мүмкіндік береді. Бұл әсіресе ерекше білім беру қажеттіліктері бар оқушылар үшін маңызды, себебі жеке оқу жолын қалыптастыру олардың білімге қолжетімділігін арттырады және мотивациясын күшейтеді.

Зерттеу барысында анықталғандай, инклюзивті ортада жасанды интеллект жүйелерін қолдану тек техникалық тұрғыдан емес, педагогикалық және этикалық тұрғыдан да тең дәрежеде қарастырылуы қажет. Бейімделген оқыту жүйесі тиімді болуы үшін ол білім алушының психологиялық жағдайын, когнитивтік қабілетін және әлеуметтік өзара әрекеттесуін ескеруге тиіс. Осы бағытта технологиялар мен адам арасындағы өзара түсіністік пен сенімділікті арттыру маңызды рөл атқарады.

Сонымен қатар, зерттеу білім беру жүйесінде жасанды интеллектті енгізудің отандық контекстке бейімделу қажеттілігін де көрсетті. Бұл Қазақстан жағдайында инфрақұрылымдық және әдістемелік қолдауды күшейтуді, мұғалімдердің цифрлық құзыреттілігін арттыруды және деректермен жұмыс істеу мәдениетін дамытуды талап етеді.

Жалпы алғанда, машиналық оқыту алгоритмдерін қолдану арқылы инклюзивті білім беруді дамыту тек оқыту тиімділігін арттыру емес, сонымен қатар әлеуметтік теңдік пен білімге тең қолжетімділікті қамтамасыз етудің маңызды қадамы болып табылады. Болашақ зерттеулер осы технологиялардың педагогикалық құндылығын тереңірек түсінуге, олардың оқушыларға әсерін бағалауға және шынайы өмір жағдайларында тәжірибелік үлгілерін қалыптастыруға бағытталуы тиіс.

#### **Пайдаланылған әдебиеттер**

1. Anderson, T., & Dron, J. (2011). *Three generations of distance education pedagogy*. International Review of Research in Open and Distributed Learning, 12(3), p. 9. URL: <https://doi.org/10.19173/irrodl.v12i3.890>
2. Holmes, W., Bialik, M., & Fadel, C. (2019). *Artificial Intelligence in Education: Promises and Implications for Teaching and Learning*. Center for Curriculum Redesign, p. 3. URL: <https://curriculumredesign.org/wp-content/uploads/AI-in-Education-Promises-and-Implications.pdf>
3. Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). *Systematic review of research on artificial intelligence applications in higher education*. International Journal of Educational Technology in Higher Education, 16(1), p. 7. URL: <https://doi.org/10.1186/s41239-019-0171-0>
4. Luckin, R. (2017). *Towards artificial intelligence-based assessment systems*. Nature Human Behaviour, 1(3), p. 5. URL: <https://doi.org/10.1038/s41562-016-0028>
5. Baker, R. S., & Inventado, P. S. (2014). *Educational data mining and learning analytics*. In Learning Analytics, Springer, p. 8. URL: [https://doi.org/10.1007/978-1-4614-3305-7\\_4](https://doi.org/10.1007/978-1-4614-3305-7_4)
6. Brusilovsky, P., & Millán, E. (2007). *User models for adaptive hypermedia and adaptive educational systems*. In The Adaptive Web, Springer, p. 3. URL: [https://doi.org/10.1007/978-3-540-72079-9\\_1](https://doi.org/10.1007/978-3-540-72079-9_1)
7. Woolf, B. P. (2010). *Building Intelligent Interactive Tutors*. Morgan Kaufmann, p. 15. URL: <https://doi.org/10.1016/C2009-0-64351-9>
8. Al-Azawei, A., Serenelli, F., & Lundqvist, K. (2016). *Universal Design for Learning (UDL): A content analysis of peer-reviewed journal papers from 2012*

- to 2015. *Journal of the Scholarship of Teaching and Learning*, 16(3), p. 10. URL: <https://doi.org/10.14434/josotl.v16i3.19295>
9. UNESCO. (2020). *Education and disability: Analysis of data from 49 countries*. UNESCO Institute for Statistics, p. 12. URL: <https://uis.unesco.org/en/news/education-and-disability>
10. OECD. (2021). *Artificial Intelligence in Society*. OECD Publishing, p. 7. URL: <https://doi.org/10.1787/eedfee77-en>
11. Mhlana, D. (2023). *Open AI in education, the responsible and ethical use of ChatGPT towards lifelong learning*. *Journal of Applied Learning and Teaching*, 6(1), p. 10. URL: <https://doi.org/10.37074/jalt.2023.6.1.9>
12. Wang, Y., & Heffernan, N. (2013). *The student modeling challenge*. *International Journal of Artificial Intelligence in Education*, 23(1–4), p. 4. URL: <https://doi.org/10.1007/s40593-013-0001-6>
13. Raza, S. A., Qazi, W., & Umer, B. (2022). *Machine learning for educational data analytics: A review*. *Computers and Education: Artificial Intelligence*, 3, p. 5. URL: <https://doi.org/10.1016/j.caeai.2022.100072>
14. Shayan, P., et al. (2021). *AI-based adaptive learning: A systematic review of effectiveness and challenges*. *Computers & Education*, 174, p. 8. URL: <https://doi.org/10.1016/j.compedu.2021.104303>
15. Romero, C., & Ventura, S. (2020). *Educational data mining and learning analytics: An updated survey*. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), p. 10. URL: <https://doi.org/10.1002/widm.1355>
16. Kumar, V., & Chandrasekaran, S. (2021). *Machine learning models for adaptive learning systems in inclusive education*. *Education and Information Technologies*, 26(4), p. 11. URL: <https://doi.org/10.1007/s10639-021-10495-0>
17. Lee, S., & Park, H. (2022). *Personalized learning in inclusive classrooms using AI algorithms*. *Computers in Human Behavior Reports*, 8, p. 6. URL: <https://doi.org/10.1016/j.chbr.2022.100212>
18. Ochoa, X., & Worsley, M. (2021). *AI in education: Where are we and where are we going?* *British Journal of Educational Technology*, 52(4), p. 9. URL: <https://doi.org/10.1111/bjet.13103>
19. Nguyen, A., Gardner, L. A., & Sheridan, D. (2020). *Adaptive learning systems and neural networks in inclusive education*. *International Journal of Inclusive Education*, 24(12), p. 7. URL: <https://doi.org/10.1080/13603116.2018.1516827>
20. Huang, R. H., Liu, D. J., & Tlili, A. (2021). *Handbook on Facilitating Flexible Learning During Educational Disruption*. Smart Learning Institute of Beijing Normal University, p. 14. URL: <https://unesdoc.unesco.org/ark:/48223/pf0000375118>
21. Holmes, W., & Tuomi, I. (2022). *Ethics and trust in AI-driven education*. *European Journal of Education*, 57(1), p. 13. URL: <https://doi.org/10.1111/ejed.12485>
22. Zhang, L., & Zhao, J. (2021). *COVID-19 and AI in education: Challenges and opportunities*. *Computers and Education: Artificial Intelligence*, 2, p. 5. URL: <https://doi.org/10.1016/j.caeai.2021.100034>



23. Kenzhebekova, G., & Azhimbetov, S. (2024). *Challenges of implementing AI-based adaptive learning systems in Kazakhstan*. *Kazakh Journal of Education and Science*, 12(2), p. 6.
24. Yessengaliyeva, A., & Kim, J. (2023). *Deep learning for emotion recognition in inclusive learning platforms*. *Journal of Educational Multimedia and Hypermedia*, 32(4), p. 8. URL: <https://www.learntechlib.org/primary/p/222942/>
25. Dos Santos, A., & Li, M. (2022). *Explainable AI for equitable adaptive learning*. *Computers & Education*, 190, p. 9. URL: <https://doi.org/10.1016/j.compedu.2022.104597>

## Применение алгоритмов машинного обучения для персонализации обучения в инклюзивной образовательной среде

Ажимбетов С. К.

Международный университет Астаны, Астана, Казахстан.

\*E-mail: [sazhimbetov@gmail.com](mailto:sazhimbetov@gmail.com)

**Аннотация.** В данной статье рассматриваются научные и методические основы персонализации учебного процесса в системе инклюзивного образования с использованием алгоритмов машинного обучения. Цель исследования – определить эффективные подходы к созданию адаптивной образовательной среды для учащихся с особыми образовательными потребностями с применением технологий искусственного интеллекта. Результаты библиометрического анализа показывают, что в последние годы исследования в этом направлении значительно возросли, и большинство из них направлены на повышение качества обучения и формирование индивидуальных образовательных траекторий. В статье анализируются перспективы и ограничения применения искусственного интеллекта в инклюзивном образовании, с учётом педагогических, технических и этических аспектов.

**Ключевые слова:** инклюзивное образование, машинное обучение, искусственный интеллект, адаптивное обучение, персонализация, образовательные технологии.

## Application of Machine Learning Algorithms for Personalizing Learning in an Inclusive Educational Environment

Azhimbetov S. K.

Astana International University, Astana, Kazakhstan

\*E-mail: [sazhimbetov@gmail.com](mailto:sazhimbetov@gmail.com)

**Abstract.** This article examines the scientific and methodological foundations of personalizing the learning process in the inclusive education system through the use of machine learning algorithms. The purpose of the study is to identify effective approaches to creating an adaptive educational environment for students with special educational needs using artificial intelligence technologies. The results of bibliometric analysis show that research in this field has significantly increased in recent years, with most studies focusing on improving the quality of education and developing individual learning trajectories. The article analyzes the prospects and limitations of applying artificial intelligence in inclusive education, integrating pedagogical, technical, and ethical aspects.

**Keywords:** inclusive education, machine learning, artificial intelligence, adaptive learning, personalization, educational technologies.

FTAMP 20.00.00

## Жасанды интеллектті қолдану арқылы ым тілін оқыту зерттеулерінің библиометриялық талдауы

Ә. Досан

Астана халықаралық университеті, Астана, Қазақстан.

\*E-mail: [ali.dosan17@gmail.com](mailto:ali.dosan17@gmail.com)

**Аңдатпа.** Бұл зерттеуде жасанды интеллектті білім беру жүйесіне енгізу саласындағы ғылыми жарияланымдарға библиометриялық талдау жүргізілді. Деректер Scopus мәліметтер базасынан жиналып, RStudio және VOSviewer бағдарламалары арқылы өңделді. Зерттеу нәтижелері бойынша жарияланымдар санының соңғы жылдары тұрақты өсіп келе жатқандығы байқалды. Сонымен қатар, ең көп жарияланымдар Education and Information Technologies және BMC Medical Education журналдарында шоғырланғаны анықталды. Елдер арасындағы ынтымақтастық желісінде Финляндия, Жаңа Зеландия, Жапония және АҚШ жетекші орында тұр. Ал «artificial intelligence», «education», «teaching», «chatGPT» секілді кілтті сөздер зерттеудің өзекті тақырыптарын айқындайды. Зерттеу нәтижелері жасанды интеллектті білім беруде қолдану бағытындағы ғылыми трендтерді түсінуге және болашақ зерттеулердің бағытын анықтауға мүмкіндік береді.

**Түйін сөздер:** Жасанды интеллект, инклюзивті білім беру, библиометриялық талдау, интеллектуалды ым тілі, Rstudio бағдарламасы

### Кіріспе

Соңғы онжылдықтағы мүмкіндігі шектеулі балалар жөніндегі статистикалық есептер жаңа туған нәрестелер арасында есту қабілетінің бұзылуымен туылғандардың санының артып келе жатқанын көрсетеді. Бұл жағдай олардың және қоғамның басқа мүшелерінің арасында қарым-қатынас кедергісін тудырады. Дүниежүзілік денсаулық сақтау ұйымының (ДДҰ) деректері бойынша, 2005 жылы әлем бойынша есту қабілетінде ақауы бар адамдардың саны шамамен 278 миллион болған [1]. Он жылдан кейін бұл көрсеткіш 360 миллионға дейін өсіп, шамамен 14%-ға артқан. Содан бері бұл сан геометриялық прогрессиямен ұлғайып келеді. ДДҰ-ның соңғы есебіне сәйкес, 2025 жылы әлем бойынша 1,5 миллиард адам есту қабілетінің төмендеуінен зардап шеккен, оның ішінде 430 миллион адам есту қабілетін мүлдем жоғалтқан, бұл дүниежүзі халқының шамамен 5%-ын құрайды. Оның ішінде 396 миллион адам (92%) ересектер, ал 34 миллион (8%) балалар. ДДҰ сарапшыларының болжауынша, 2050 жылға қарай бұл көрсеткіш екі еселеніп [1], шамамен 700 миллион адамға яғни әрбір 10 адамның біреуі жетуі мүмкін. Есту және сөйлеу қабілеті шектеулі адамдардың осылайша көбеюі олардың қоғаммен қарым-қатынас орнату мүмкіндігін арттыруды және коммуникациялық тосқауылдарды жоюды қажет етеді.

Сурдотіл аудармашылары ым тілін ауызша сөзге және керісінше аудару арқылы есту қабілеті бұзылған адамдармен байланыстағы коммуникациялық алшақтықты жоюға көмектеседі. Алайда ым тілі құрылымының икемділігі мен

білікті сурдотіл мамандарының әлем бойынша жетіспеушілігі аудармашыларды тартуда қиындықтар туғызады [3]. Дүниежүзілік саңыраулар федерациясының деректері бойынша, әлемде 70 миллионнан астам адам 300-ден астам түрлі ым тілін қолданады [2]. Сондықтан дәстүрлі сурдотіл аудармашыларын толықтыра алатын технологиялық жүйе қажет болды.

Жасанды интеллект (ЖИ) саласындағы соңғы жетістіктер ым тілді тануда жаңа мүмкіндіктер ашып [4], сурдотіл аудармасы үдерістеріне ЖИ технологияларын енгізуге жол ашты. Соңғы жылдары интеллектуалды камераларға ерекше көңіл бөлінуде, себебі олар робототехникада, ауызша аударма қызметтерінде, нақты уақытта бірнеше адамды тану жүйелерінде, ойын индустриясында, виртуалды шындық орталарында, табиғи тіл арқылы қарым-қатынаста, үстел үсті ортада қол қозғалысын бақылауда және адам мен компьютердің өзара әрекеттесуінде кеңінен қолданылады [9].

Ым тілі дүние жүзіндегі саңырау және нашар еститін адамдар үшін негізгі байланыс құралы ретінде қолданылады. Бұл олардың және есту қабілеті қалыпты адамдар арасындағы коммуникациялық алшақтықты жою мен әлеуметтік өзара әрекеттестікті қамтамасыз етудің ең тиімді және нәтижелі тәсілі [7].

Ым тілді интеллектуалды тану жүйелері саласындағы зерттеулер мен жетістіктерге қарамастан, әлі де көптеген мүмкіндіктер бар және жаңа интеллектуалды шешімдер қажет [8]. Сондықтан бұл зерттеу ым тілді танудың интеллектуалды жүйелері саласында жарияланған зерттеулерге жүйелі және жан-жақты шолу жасауға бағытталған.

Ым тілі бұл ақпаратты жеткізу үшін дененің жоғарғы бөлігін, яғни қол қимылдарын, бет-әлпет мимикасын, ерін қимылдарын оқу, бастың изеуін және дене позаларын пайдалануды қамтиды. Ым тілді танудың негізгі әдістері визуалды және киілетін сенсорлық құрылғылар, мысалы, сенсорлы қолғаптар [12]. Қолғап әдісінде пайдаланушының қолғаптарына бекітілген механикалық немесе оптикалық датчиктер саусақтардың қозғалысын электрлік сигналдарға түрлендіріп, қолдың орналасуын анықтауға мүмкіндік береді. Визуалды қабылдау әдісінде алақанның пішіні, саусақтардың орналасуы және буын бұрыштары сияқты белгілер бағаланып, содан кейін тану үшін пайдаланылады. Бұл әдіс ым қимылдарының суреттері мен бейнежазбаларын камера арқылы түсіріп, оларды кескінді өңдеу технологиялары арқылы талдауды талап етеді [13].

Қарым-қатынас адам өмір сүруінің ең маңызды құралы. Ол ойларды, сезімдерді және пікірлерді алмасудың негізгі әрі тиімді тәсілі. Алайда, әлем халқының айтарлықтай бөлігі бұл мүмкіндіктен айырылған көптеген адамдар есту қабілетінің жоғалуы, сөйлеу қабілетінің бұзылуы немесе осы екеуінің қатар болуынан зардап шегеді. Бір немесе екі құлақтың есту қабілетінің жартылай немесе толық жоғалуы есту кемістігі (тугоухость) деп аталады. Ал мылқаулық адамның сөйлеуін қиындататын және сөйлей алмауына әкелетін бұзылыс. Егер адам бала кезінде есту мен сөйлеу қабілетін жоғалтса, оның тіл




үйрену қабілеті де тежеледі, бұл өз кезегінде есту мутизмі деп аталатын сөйлеу бұзылысына әкеледі [14].

## **2 Библиометриялық талдау және әдістеме**

Бұл бөлімде соңғы жылдары жарияланған ым тілін танудың интеллектуалды жүйелеріне арналған зерттеулерге библиометриялық талдау жүргізілді. Талдау соңғы кезеңде жарық көрген 649 ғылыми мақаланың негізінде RStudio бағдарламалық ортасы арқылы жүзеге асырылды [5]. Зерттеудің мақсаты ым тілін тану саласындағы қазіргі ғылыми үрдістер мен даму бағыттарын айқындау, сондай-ақ соңғы жылдардағы зерттеу белсенділігінің артуын көрсету. Соңғы жылдары жасанды интеллект пен машиналық оқытудың жедел дамуы ым тілін тану жүйелерін жетілдіруге жаңа мүмкіндік берді. Осыған байланысты бұл тақырыптағы зерттеулер саны айтарлықтай көбейіп, олардың мазмұны технологиялық және әдістемелік тұрғыдан кеңейе түсті. Деректерді жинау үшін келесі түйінді сөздер пайдаланылды: «Ым тілін тану», «Интеллектуалды жүйелер», «Жасанды интеллект», «Машиналық оқыту», «Нейрондық желі», «Сараптамалық жүйе», «Бұлыңғыр жүйе» және «Білімге негізделген жүйелер». Мақалаларды іздеу стратегиясы төмендегідей болды: ((«ым тілі» ЖӘНЕ «тану») ЖӘНЕ («машиналық оқыту») NEMECSE («жасанды интеллект»)) ҚҰЖАТ ТҮРІ: (ғылыми мақала) ИНДЕКС: ((Scopus деректер қоры)).

Талдау жарияланымдардың елдер, мекемелер, журналдар және авторлар арасындағы таралуы, дәйексөздер саны және түйінді сөздердің бірлесіп кездесу жиілігі бойынша жүргізілді. Мұндай талдау ASLR (Automatic Sign Language Recognition) саласындағы белсенді зерттеу орталықтарын, ынтымақтастық желілерін және жетекші ғалымдарды анықтауға мүмкіндік береді. Библиометриялық талдау барысында RStudio ортасында орнатылған bibliometrix және biblioshiny пакеттері қолданылды. Бұл құралдар ғылыми мақалалар бойынша сандық және визуалды талдаулар жасауға, жарияланым динамикасын, авторлар арасындағы байланыстарды және түйінді сөздердің жиілігін айқындауға мүмкіндік берді [6].

Библиометриялық талдау процедурасы 1-суретте көрсетілген. Процестің алғашқы екі кезеңі Scopus дерекқорынан кең ауқымды әдебиеттерді жинақтауды қамтиды (2025 жылдың 20 қазанына дейінгі мерзім бойынша). Scopus дерекқорын таңдау себебі оның индекстелетін журналдары әлемдік деңгейде беделді болып саналады және ым қимылдарды тану жүйелері саласындағы заманауи әрі маңызды зерттеулерді қамтиды. Осылайша, Scopus дерекқоры зерттеу тақырыбына қатысты жарияланған ең өзекті ғылыми еңбектерді жинауға және талдауға мүмкіндік береді. Бұл деректер негізінде ым тілін оқыту мен жасанды интеллекттің қолданылу бағыттарындағы ғылыми үрдістер мен зерттеу динамикасын анықтау жүзеге асырылды [16].



Сурет 1. Scopus дерекқорындағы жарияланымдарды жинау және зерттеу нәтижелерін талдау блог-схемасы.

ЫМ тілді интеллектуалды тану жүйелеріне арналған зерттеу мақалаларын анықтау үшін іздеу барысында әртүрлі кілт сөздер пайдаланылды. Алдымен авторлар Scopus дерекқорында «ЫМ тілді тану» («Sign Language Recognition») кілтті сөзі бойынша іздеу жүргізіп, 2024-2025 жылдар аралығында жарияланған 1312 ғылыми мақаланы анықтады.

Зерттеудің негізгі мақсаты ым тілді интеллектуалды жүйелер тұрғысынан талдау болғандықтан, екінші кезеңде іздеу «Интеллектуалды жүйелер» және «ЫМ тілді тану» деген екі кілт сөздің үйлесімімен нақтыланды. Бұл іздеу нәтижесінде барлығы 26 ғылыми мақала табылды. Алайда, бұл сандар соңғы жылдағы зерттеу үрдістерін толық сипаттау үшін жеткіліксіз болды. Сондықтан іздеу аясын кеңейтіп, ым тілді тану жүйелерінде қолданылатын әртүрлі интеллектуалды жүйелердің түрлерін қамтитын әдебиеттер қосымша қарастырылды. Бұл жүйелердің түрлеріне жасанды интеллект, шешім қабылдауды қолдау жүйелері, машиналық оқыту, нейрондық желілер, expertтік жүйелер, бұлдыр логика жүйелері және білімге негізделген жүйелер жатады.

Барлық осы кілт сөздер «ЖӘНЕ» және «НЕМЕСЕ» логикалық операторлары арқылы біріктіріліп, іздеу сұранысы құрастырылды. Іздеу нәтижесінде 652 құжат анықталды және бастапқы 26 мақаламен біріктіріліп, әрі қарай талдау үшін пайдаланылды. Қайталанатын және мазмұны ұқсас мақалаларды болдырмау мақсатында төртінші кезеңде мәліметтер сүзгіден өткізілді. Нәтижесінде барлығы 649 жарияланған мақала библиометриялық талдау үшін таңдалып алынды. Бесінші кезеңде талдау RStudio бағдарламалық құралы арқылы жүзеге асырылды. Бұл құрал библиометриялық желілерді құру

және визуализациялау үшін қолданылады [15]. Талдау нәтижелері келесі бөлімдерді көрсетілген.

### 3 Нәтижелер және оларды талқылау

Интеллектуалды ым тілді тану жүйелері және жалпы ым тілі саласында соңғы жылдары жарияланған зерттеулердің библиометриялық бағалау нәтижелері жеке осы бөлімде көрсетілген. Зерттеу нәтижелері көрсеткендей, интеллектуалды жүйелер мен білім беру технологиялары саласында соңғы уақыттарда жарияланған мақалалар бірқатар беделді халықаралық журналдарда жарық көрген. Барлық журналдардың көлемі үлкен болғандықтан, соңғы жариялаған белсенді 10 журнал көрсетілді, олардың әрқайсысы ым тілі мен жасанды интеллектті білім беру саласында қолдануға қатысты зерттеулерді қамтиды.


| Source                                                        | h_index | g_index | m_index | TC | NP | PY_start |
|---------------------------------------------------------------|---------|---------|---------|----|----|----------|
| ANNUAL REVIEW OF BIOMEDICAL DATA SCIENCE                      | 1       | 1       | 1.000   | 2  | 1  | 2025     |
| BMC MEDICAL EDUCATION                                         | 2       | 4       | 2.000   | 23 | 4  | 2025     |
| BRITISH JOURNAL OF EDUCATIONAL TECHNOLOGY                     | 1       | 1       | 1.000   | 2  | 1  | 2025     |
| DISCOVER SUSTAINABILITY                                       | 1       | 1       | 1.000   | 10 | 1  | 2025     |
| EDUCATION AND INFORMATION TECHNOLOGIES                        | 3       | 3       | 3.000   | 19 | 3  | 2025     |
| IFLA JOURNAL                                                  | 1       | 1       | 1.000   | 4  | 1  | 2025     |
| INFORMATION (SWITZERLAND)                                     | 1       | 1       | 1.000   | 1  | 4  | 2025     |
| INTERNATIONAL ELECTRONIC JOURNAL OF MATHEMATICS EDUCATION     | 1       | 1       | 1.000   | 1  | 1  | 2025     |
| INTERNATIONAL JOURNAL FOR EDUCATIONAL INTEGRITY               | 1       | 1       | 1.000   | 1  | 1  | 2025     |
| INTERNATIONAL JOURNAL OF ARTIFICIAL INTELLIGENCE IN EDUCATION | 1       | 1       | 1.000   | 24 | 1  | 2025     |

Кесте 1. Ым тілін тану бойынша ең белсенді 10 журнал

Жоғарыда көрсетілген мәліметтерге сәйкес, Education and Information Technologies журналы ең белсенді басылымдардың бірі болып табылады онда 3 мақала жарияланған. Одан кейін BMC Medical Education журналы (2 мақала) тұр. Қалған журналдардың әрқайсысында бір мақаладан тіркелген. Көптеген жарияланымдар білім беру технологиялары, деректер ғылымы және жасанды интеллекттің педагогикамен байланысы тақырыптарына бағытталған. Мысалы, British Journal of Educational Technology мен International Journal of Artificial Intelligence in Education журналдары білім беру процесін жетілдіруде интеллектуалды жүйелерді қолдану мәселелеріне басымдық береді. Сонымен қатар, Discover Sustainability және IFLA Journal журналдарында тұрақты даму және ақпараттық қоғам мәселелері қозғалады. Жалпы алғанда, деректер зерттеліп отырған бағыттың интердисциплинарлық сипатын, яғни білім беру, ақпараттық технологиялар және жасанды интеллект салаларының өзара тоғысуын көрсетеді.

Жүргізілген библиометриялық талдау нәтижесінде елдер арасындағы бірлескен жарияланымдар желісі (co-authorship network) анықталды. Бұл талдау RStudio бағдарламасы арқылы іске асырылып, нәтижелер кесте түрінде және визуалды түрде көрсетілді. Визуалды түрі 2-суретте көрсетілген.

## Country Collaboration Map




Сурет 2. 2025 жылда ең көп жарияланымдар жасаған елдердің және академиялық мекемелердің аймақтық рейтингі

Талдау көрсеткендей, интеллектуалды ым тілі мен білім беру технологиялары саласындағы зерттеулерде ең тығыз ғылыми байланыстар Жапония, Индонезия, Біріккен Араб Әмірліктері және Пәкістанмен байланысты елдер арасында байқалды. Мысалы: Жапония Финляндиямен (171.48), Жаңа Зеландиямен (171.48), Израильмен (138.03), Норвегиямен (138.03), Швециямен (138.03), Ұлыбританиямен (138.03) және АҚШ-пен (138.03) тығыз әріптестік қатынаста болған. Индонезия Қытаймен (117.24), Германиямен (117.24), Филиппинмен (117.24), Малайзиямен (109.69) және Таиландпен (101.00) жоғары деңгейдегі ынтымақтастық орнатқан. Біріккен Араб Әмірліктері Түркиямен, Үндістанмен, Сауд Арабиясымен, Грециямен және Ұлыбританиямен ортақ зерттеулер жүргізіп, байланыс күші 54.30 шамасында болған. Пәкістан Оманда (69.33), Түркияда (69.33) және БАӘ-де (69.33) бірлескен жарияланымдар жасаған. Сонымен қатар, Канада мен Иран арасындағы байланыс күші 54.27 деп бағаланған.

Бұл көрсеткіштер елдердің бірлескен ғылыми белсенділігін және зерттеу саласындағы халықаралық серіктестік ауқымын айқындайды. Жапония мен Индонезия — желінің орталық түйіндері, себебі олар көптеген елдермен тікелей байланысты және өз саласында ықпалды. Желінің визуализациясы елдер арасындағы байланыстардың тығыздығын көрсетеді: түйіндердің көлемі елдің ғылыми белсенділігін сипаттаса, сызықтардың қалыңдығы олардың бірлескен жарияланымдар жиілігін көрсетеді. Қалың сызықтар (мысалы, Жапония-Финляндия және Индонезия-Германия) жоғары деңгейлі зерттеу серіктестігін білдіреді.

Жалпы алғанда, бұл нәтижелер интеллектуалды ым тілі саласындағы зерттеулердің тек бір ел аясында ғана емес, көптеген халықаралық коллаборациялар арқылы жүзеге асырылатынын көрсетеді. Мұндай байланыстар жаһандық ғылыми ортада білім мен тәжірибе алмасуға ықпал

Scopus дерекқорынан жиналған жарияланымдардың негізінде кілт сөздердің Co-occurrence Network (бірлесіп кездесуі) талданды. Зерттеу нәтижелері VOSviewer және RStudio құралдары арқылы өңделді. Сурет 3 визуалды көрінісін көруге болады.



Сурет 3. Кілт сөздердің Co-occurrence Network желісі

Анализ нәтижесінде ең жиі кездесетін негізгі кілт сөздер төмендегідей болды:

- artificial intelligence (жасанды интеллект) жиілігі 448.155, бұл тақырыптың зерттеу фокусындағы басым рөлін көрсетеді;
- teaching (оқыту) және education (білім беру) ұғымдары да жиі қолданылып, жасанды интеллекттің педагогикалық салада кеңінен зерттеліп жатқанын дәлелдейді;
- chatgpt, ai in education, artificial intelligence in education сияқты терминдердің болуы білім беруде жаңа технологиялардың, соның ішінде генеративті жасанды интеллекттің қолданылуына қызығушылықтың артқанын көрсетеді.

Сонымен қатар educational technology, engineering education, және higher education сияқты сөздер білім беру жүйесінің әртүрлі деңгейінде цифрлық технологияларды интеграциялау үрдісін сипаттайды. Жалпы, бұл кілт сөздер жиынтығы соңғы жылдары жасанды интеллекттің білім беру саласындағы зерттеулерде жетекші бағыттардың бірі екенін айқын көрсетеді.

## Қорытынды

Бұл зерттеу ым тілді интеллектуалды тану жүйелері мен олардың даму үрдістерін библиометриялық тұрғыдан талдауға бағытталды. Зерттеу нәтижелері бұл саладағы ғылыми ізденістердің соңғы жылдары айтарлықтай жанданып, жасанды интеллект пен машиналық оқыту әдістерінің ым тілді тану саласында кеңінен қолданылып жатқанын көрсетті. RStudio және VOSviewer құралдарын пайдалану арқылы алынған нәтижелер ғылыми бағыттардың эволюциясын, негізгі зерттеу орталықтарын және жетекші кілт сөздердің

байланыс желілерін нақты сипаттауға мүмкіндік берді. Жүргізілген библиометриялық талдау нәтижесінде соңғы онжылдықта ым тілді танудың интеллектуалды жүйелері бойынша зерттеу жұмыстарының саны тұрақты өсім көрсетіп отырғаны анықталды. Бұл тенденция ақпараттық технологиялар мен инклюзивті білім беру салаларындағы қызығушылықтың артып келе жатқанын дәлелдейді. Жасанды интеллект технологиялары әсіресе нейрондық желілер мен терең оқыту алгоритмдері ым тілді автоматты тану жүйелерін жетілдіруде негізгі рөл атқаратыны байқалды.

Елдер арасындағы ғылыми ынтымақтастық желісін талдау нәтижесінде Жапония, Индонезия, Біріккен Араб Әмірліктері және Пәкістан сынды елдер жетекші орынға шықты. Бұл мемлекеттердің зерттеушілері бір-бірімен және басқа елдермен белсенді академиялық байланыстар орнатып, ым тілі мен жасанды интеллект технологияларын біріктіретін инновациялық жобаларды жүзеге асыруда. Әсіресе Жапония мен Финляндия, Индонезия мен Германия арасындағы ғылыми серіктестік байланыстарының жоғары деңгейде екендігі байқалды. Мұндай коллаборациялар жаһандық ғылыми кеңістіктегі тәжірибе алмасуды, әдіснамалық және технологиялық интеграцияны күшейтеді. Сонымен қатар кілт сөздердің жиілік талдауы жасанды интеллект пен білім беру ұғымдарының өзара тығыз байланысын айқындады. «Artificial intelligence», «teaching», «education», және «ChatGPT» терминдерінің жиі кездесуінен байқағанымыздай, қазіргі уақытта білім беру жүйелерінде генеративті жасанды интеллект технологияларын қолдану кеңінен зерттеліп келеді. Бұл бағыт педагогикалық инновацияларды дамытудың жаңа кезеңіне жол ашып отыр. Сондай-ақ «educational technology», «engineering education» және «higher education» сияқты терминдердің жиілігі жасанды интеллекттің білім беру жүйесінің әртүрлі деңгейлерінде интеграцияланып жатқанын дәлелдейді.

Жалпы алғанда, жүргізілген библиометриялық талдау нәтижелері ым тілді интеллектуалды тану саласының интердисциплинарлық сипатқа ие екенін көрсетті. Бұл сала тек компьютерлік ғылымдар мен инженерия шеңберінде ғана емес, сонымен қатар педагогика, когнитивті ғылым, психология және әлеуметтік интеграция салаларымен тығыз байланысты. Осы тұрғыдан алғанда, интеллектуалды жүйелер тек технологиялық шешім ғана емес, сондай-ақ қоғамның әлеуметтік теңдігі мен инклюзиясына ықпал ететін маңызды құрал болып табылады.

Зерттеу нәтижелерінен келесі маңызды қорытындылар шығаруға болады:

- Жасанды интеллект пен машиналық оқыту ым тілді тану жүйелерінің сапасы мен дәлдігін арттырудағы негізгі технологиялық бағыттар.
- Халықаралық ғылыми ынтымақтастық ым тілді интеллектуалды жүйелерді дамытуда шешуші рөл атқарады; әсіресе Азия және Еуропа елдерінің серіктестігі айқын байқалады.



- Білім беру саласындағы зерттеулер жасанды интеллектті оқыту үдерістеріне енгізудің әлеуетін кеңінен ашып отыр, бұл педагогикалық практиканы дербестендіру мен бейімдеудің жаңа мүмкіндіктерін ұсынады.

Кілт сөздердің жиілігі мен өзара байланысы зерттеу бағыттарының фокусының «жасанды интеллект» және «оқыту технологиялары» салаларына қарай ауысқанын көрсетеді. Осылайша, интеллектуалды ым тілді тану жүйелері қазіргі таңда тек ғылыми ізденістердің нысаны ғана емес, сондай-ақ әлеуметтік инклюзияны қамтамасыз етудің стратегиялық тетігіне айналып отыр. Мұндай жүйелердің дамуы саңырау және есту қабілеті шектеулі адамдардың қоғаммен тиімді қарым-қатынас орнатуына мүмкіндік береді. Алдағы уақытта жасанды интеллект пен терең оқыту әдістерін жетілдіру бұл технологияларды қолжетімді әрі нақты өмірде кеңінен қолдануға мүмкіндік береді. Болашақ зерттеулер бағыттары ретінде келесі ұсыныстарды айтуға болады:

- ым тілді тану жүйелерін нақты уақыт режимінде бейімдеу және көптілді ортаға енгізу;

- генеративті жасанды интеллект (мысалы, ChatGPT және мультимодальды үлгілер) негізінде автоматтандырылған сурдотіл аудармашыларын әзірлеу;

- инклюзивті білім беру жүйесіне интеллектуалды көмекші құралдарды интеграциялау.

Қорытындылай келе, ым тілі мен жасанды интеллекттің түйіскен жерінде жаңа ғылыми бағыт қалыптасып келеді. Бұл бағыт қоғамдағы коммуникациялық теңсіздікті азайтуға, ерекше қажеттіліктері бар тұлғалардың әлеуметтенуіне және білім алу мүмкіндіктерін кеңейтуге зор үлес қосады.

#### **Пайдаланылған әдебиеттер**

1. World Health Organization. Deafness and Hearing Loss [Электронды ресурсы]. – [URL: https://www.who.int/news-room/fact-sheets/detail/deafness-and-hearing-loss](https://www.who.int/news-room/fact-sheets/detail/deafness-and-hearing-loss)
2. World Federation of the Deaf. Deaf People and Sign Languages in the World [Электронды ресурсы]. – [URL: https://wfdeaf.org](https://wfdeaf.org)
3. Kudriavtseva, A. Challenges of Sign Language Interpretation in Modern Society. – International Journal of Linguistics, 2021.
4. Rastgoo, R., Kiani, K., Escalera, S. Sign Language Recognition: A Review and the Future Roadmap. – Pattern Recognition Letters, 2021.
5. Buribayev Z., Aouani M., Zhangabay Z. ж.б. Enhancing Kazakh Sign Language Recognition with BiLSTM Using YOLO Keypoints and Optical Flow // Applied Sciences. 2025. Vol. 15, No. 10: 5685. DOI: 10.3390/app15105685. [URL: https://doi.org/10.3390/app15105685](https://doi.org/10.3390/app15105685)
6. Zhang Y., Sarker D., Mitsven S. Artificial intelligence in sign language recognition: a bibliometric analysis of 2 720 articles // Computers & Electrical Engineering. 2024. DOI: 10.1016/j.compeleceng.2024.109854.

[URL: https://doi.org/10.1016/j.compeleceng.2024.109854](https://doi.org/10.1016/j.compeleceng.2024.109854)

7. Chemnad K. ж .б. Digital accessibility in the era of artificial intelligence — A systematic review // PMC. 2024.

[URL: https://www.ncbi.nlm.nih.gov/articles/PMC10905618/](https://www.ncbi.nlm.nih.gov/articles/PMC10905618/)

8. ZainEldin H. ж .б. A comprehensive review of artificial intelligence, deep learning and machine learning technologies for Deaf–Mute community including sign language interpretation // Artificial Intelligence Review. 2024. DOI: 10.1007/s10462-024-10816-0.

[URL: https://link.springer.com/article/10.1007/s10462-024-10816-0](https://link.springer.com/article/10.1007/s10462-024-10816-0)

9. Melo-López V.-A., Basantes-Andrade A., Gudiño-Mejía C.-B., Hernández-Martínez E. The Impact of Artificial Intelligence on Inclusive Education: A Systematic Review // Education Sciences. 2025. Vol. 15, No. 5: 539. DOI: 10.3390/educsci15050539.

[URL: https://doi.org/10.3390/educsci15050539](https://doi.org/10.3390/educsci15050539)

10. Aitim A., Sattarkhuzhayeva D., Khairullayeva A. Development of a hybrid CNN-RNN model for enhanced recognition of dynamic gestures in Kazakh Sign Language // Eastern-European Journal of Enterprise Technologies. 2025. DOI: 10.15587/1729-4061.2025.315834.

[URL: https://doi.org/10.15587/1729-4061.2025.315834](https://doi.org/10.15587/1729-4061.2025.315834)

11. Daniuseviciute-Brazaite L., Paulauskaite-Taraseviciene A. Research Trends in AI for Inclusive Education: A Bibliometric Analysis. 2024.

[URL: https://ssrn.com/abstract=5050474](https://ssrn.com/abstract=5050474)

12. Amirgaliyev Y., Ataniyazova A., Buribayev Z. Application of neural networks ensemble method for the Kazakh sign language recognition // Bulletin of Electrical Engineering & Informatics. 2024. Vol. 13, No. 5: 3275-3287.

[URL: https://beei.org/index.php/EEI/article/download/7803/3904](https://beei.org/index.php/EEI/article/download/7803/3904)

13. Mukhanov S., Uskenbayeva R., Cho Y. I., Dauren K., Nurzhan L., Amangeldi M. Gesture recognition of the Kazakh alphabet based on machine and convolutional neural network methods // Procedia. 2024.

[URL: https://www.sciencedirect.com/science/article/pii/S1877050924017757](https://www.sciencedirect.com/science/article/pii/S1877050924017757)

14. “Kazakh Scientist Develops AI to Translate Sign Language into Kazakh” // The Astana Times. 15 February 2025.

[URL: https://astanatimes.com/2025/02/kazakh-scientist-develops-ai-to-translate-sign-language-into-kazakh/](https://astanatimes.com/2025/02/kazakh-scientist-develops-ai-to-translate-sign-language-into-kazakh/)

15. RStudio: Posit PBC. RStudio Desktop / RStudio Server [Электронды ресурс]. – [URL: https://posit.co/download/rstudio-desktop/](https://posit.co/download/rstudio-desktop/)

16. Scopus: Elsevier. Scopus – Abstract and citation database [Электронды ресурс]. – [URL: https://www.elsevier.com/products/scopus](https://www.elsevier.com/products/scopus)



## Библиометрический анализ исследований по обучению жестовому языку с использованием искусственного интеллекта

Ә. Досан

«Международный университет Астана», Астана, Казахстан.

\*E-mail: [ali.dosan17@gmail.com](mailto:ali.dosan17@gmail.com)

**Аннотация.** В данном исследовании проведён библиометрический анализ научных публикаций, посвящённых внедрению искусственного интеллекта в систему образования. Данные были собраны из базы Scopus и обработаны с использованием программ RStudio и VOSviewer. Результаты показали устойчивый рост количества публикаций за последние годы. Кроме того, установлено, что наибольшее количество работ сосредоточено в журналах Education and Information Technologies и BMC Medical Education. В сети международного сотрудничества лидирующие позиции занимают Финляндия, Новая Зеландия, Япония и США. Такие ключевые слова, как «artificial intelligence», «education», «teaching», «ChatGPT» отражают основные направления исследований. Полученные результаты позволяют глубже понять научные тренды в области применения искусственного интеллекта в образовании и определить направления будущих исследований.

**Ключевые слова:** искусственный интеллект, инклюзивное образование, библиометрический анализ, интеллектуальный жестовый язык, программа RStudio.

## Bibliometric Analysis of Research on Sign Language Teaching Using Artificial Intelligence

A. Dossan

Astana International University, Astana, Kazakhstan.

\*E-mail: [ali.dosan17@gmail.com](mailto:ali.dosan17@gmail.com)

**Abstract.** This study presents a bibliometric analysis of scientific publications on the integration of artificial intelligence into the education system. Data were collected from the Scopus database and processed using RStudio and VOSviewer software. The results show a steady increase in the number of publications in recent years. In addition, it was found that most publications are concentrated in the Education and Information Technologies and BMC Medical Education journals. In the international collaboration network, Finland, New Zealand, Japan, and the USA occupy leading positions. Keywords such as “artificial intelligence,” “education,” “teaching,” and “ChatGPT” highlight the main research topics. The findings help to better understand scientific trends in the application of artificial intelligence in education and determine the direction of future research.

**Keywords:** Artificial intelligence, inclusive education, bibliometric analysis, intelligent sign language, RStudio software.