

===== АВТОМАТИЗАЦИЯ И УПРАВЛЕНИЕ ТЕХНОЛОГИЧЕСКИМИ ПРОЦЕССАМИ =====
И ПРОИЗВОДСТВАМИ

УДК 681.3.06

Научная статья

DOI: 10.35330/1991-6639-2025-27-5-143-158

EDN: COFWYK

**Облачно-периферийная экосистема когнитивной автоматике
для интегрированного менеджмента СІР-процессов пивзавода**

А. С. Максимов¹, В. С. Артемьев^{✉2}, Л. С. Мангушева², Ж. В. Мекшенева³

¹Российский биотехнологический университет (РОСБИОТЕХ)
125080, Россия, Москва, Волоколамское шоссе, 11

²Российский экономический университет имени Г. В. Плеханова
115054, Россия, Москва, Стремянный переулок, 36

³Университет «Синергия»
125315, Россия, Москва, Ленинградский пр-т, 80Б

Аннотация. В работе представлена облачно-периферийная когнитивная архитектура для управления СІР-процессами пивоваренных линий. Система основана на связке ResNet-CNN и Transformer, работающих в контуре активного обучения и интегрированных с мультисенсорным мониторингом АТР-биолюминесценция, ИК-флуоресценция, оптическая плотность биопленок. Edge-узлы обеспечивают мгновенное обнаружение аномалий и локальное управление, тогда как облачный уровень выполняет предиктивную оптимизацию и дообучение моделей. Пилотные испытания показали сокращение расхода реагентов на 29 %, воды на 22 % и энергии на 18 %, уменьшение латентности управления до 140 мс и повышение точности прогнозов до $R2 = 0,92$ при снижении ложных тревог на 37 %. Архитектура демонстрирует соответствие нормативам и создает основу для перехода СІР-циклов в проактивный режим.

Целью исследования стало формирование облачно-периферийной экосистемы, обеспечивающей сокращение времени принятия решений в СІР-процессах до уровня менее 150 мс, снижение ресурсных затрат и повышение санитарной надежности в условиях высокой вариативности рецептур и технологических параметров пивоваренного производства.

Методология. Методологическая платформа основана на теории распределенных мультиагентных систем и принципах активного обучения. В качестве исходных данных использован массив из 48 000 профилей загрязнений, включающий показатели АТР-биолюминесценции, ИК-флуоресценции и оптической плотности биопленок. Edge-уровень выполняет предобработку сигналов, автоэнкодер формирует компактные эмбединги, а GRU-классификатор фиксирует аномалии с реакцией менее 40 мс. На облачном уровне реализована гибридная модель ResNet-CNN и Transformer, предсказывающая глубину очистки и оптимизирующая параметры СІР-цикла. Для объяснимости решений применялись SHAP-значения и Grad-CAM. Валидация корректности архитектуры проводилась в соответствии с ISO и ГОСТ по метрологии, кибербезопасности и санитарным регламентам.

Результаты. Эксперименты подтвердили устойчивую работу экосистемы в реальном времени и соответствие нормативным ограничениям. Средний расход моющих реагентов снизился на 29 %, потребление воды – на 22 %, энергозатраты – на 18 %. Латентность управления сократилась до 140 мс, а точность предсказаний достигла $R2 = 0,92$. Система показала снижение ложных тревог на 37 % и полную отказоустойчивость при частичной потере данных. Экономическая оценка выявила сокращение операционных затрат на 24,7 % и срок окупаемости инвестиций менее восьми месяцев.

Выводы. Разработанная облачно-периферийная когнитивная архитектура обеспечивает переход СІР-процессов от статических режимов к проактивному управлению. Сочетание быстродействующих edge-модулей и облачных предиктивных моделей гарантирует как снижение ресурсных затрат, так и соблюдение санитарных требований.

Ключевые слова: когнитивная автоматика, CIP, активное обучение, OPC UA, оптимизация реагентов, промышленный IoT

Поступила 18.07.2025, одобрена после рецензирования 15.08.2025, принята к публикации 25.09.2025

Для цитирования. Максимов А. С., Артемьев В. С., Мангушева Л. С., Мекшенева Ж. В. Облачно-периферийная экосистема когнитивной автоматки для интегрированного менеджмента CIP-процессов пивзавода // Известия Кабардино-Балкарского научного центра РАН. 2025. Т. 27. № 5. С. 143–158. DOI: 10.35330/1991-6639-2025-27-5-143-158

MSC: 68T07; 68T20; 93C85; 90B50

Original article

Cloud-based ecosystem of cognitive automation for integrated management of the CIP processes in brewing

A.S. Maksimov¹, V.S. Artemyev^{✉2}, L.S. Mangusheva², Zh.V. Meksheneva³

¹Russian Biotechnological University (ROSBIOTECH)
11 Volokolamskoye shosse, Moscow, 125080, Russia

²Plekhanov Russian University of Economics
36 Stremyanny lane, Moscow, 115054, Russia

³Synergy University
80B Leningradskiy prospekt, Moscow, 125315, Russia

Abstract. The paper presents a cloud–edge cognitive architecture for managing brewery CIP processes. The system is based on a ResNet–CNN and Transformer ensemble operating within an active learning loop and integrated with multi-sensor monitoring ATP bioluminescence, IR fluorescence, and biofilm optical density. Edge nodes provide instant anomaly detection and local control, while the cloud level performs predictive optimization and model retraining. Pilot trials demonstrated reductions in reagent consumption by 29%, water usage by 22%, and energy use by 18%, along with a decrease in control latency to 140 ms and an increase in predictive accuracy to $R^2 = 0.92$, accompanied by a 37% reduction in false alarms. The architecture ensures compliance with sanitary standards and enables a proactive paradigm for CIP cycle management.

Aim. The aim of the study is to develop a cloud–edge ecosystem capable of reducing decision latency in CIP processes to less than 150 ms, cutting resource consumption, and enhancing sanitary reliability under the conditions of high variability in brewing recipes and technological parameters.

Methods. The methodological foundation relied on the theory of distributed multi-agent systems and the principles of active learning. The dataset included 48,000 fouling profiles, incorporating ATP bioluminescence, IR fluorescence, and biofilm optical density. At the edge level, signal preprocessing is performed, an autoencoder generates compact embeddings, and a GRU-based classifier detects anomalies with a reaction time of less than 40 ms. At the cloud level, a hybrid ResNet–CNN and Transformer model predicts cleaning depth and optimizes CIP cycle parameters. SHAP values and Grad-CAM are used to ensure interpretability of decisions. System validation is conducted in accordance with ISO and GOST standards on metrology, cybersecurity, and sanitary compliance.

Results. The experiments confirm stable real-time operation of the ecosystem and compliance with regulatory requirements. Average consumption of cleaning agents is reduced by 29%, water usage by 22%, and energy demand by 18%. Control latency decreased to 140 ms, while predictive accuracy reached $R^2 = 0.92$. The system demonstrates a 37% reduction in false alarms and full fault tolerance under partial data loss. Economic analysis shows a 24.7% reduction in operating costs and a payback period of less than eight months.

Conclusions. The developed cloud–edge cognitive architecture enables the transition of CIP processes from static operation to proactive control. The combination of fast edge modules and predictive cloud models ensures both resource efficiency and strict sanitary compliance.

Keywords: cognitive automation, CIP, active learning, OPC UA, reagent optimization, industrial IoT

Submitted on 18.07.2025,

approved after reviewing on 15.08.2025,

accepted for publication on 25.09.2025

For citation. Maksimov A.S., Artemyev V.S., Mangusheva L.S., Meksheneva Zh.V. Cloud-based ecosystem of cognitive automation for integrated management of the CIP processes in brewing. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2025. Vol. 27. No. 5. Pp. 143–158. DOI: 10.35330/1991-6639-2025-27-5-143-158

ВВЕДЕНИЕ

Ландшафт постиндустриального пивоварения стремительно смещается от монолитных SCADA-решений к распределенным, облачно-периферийным экосистемам, где критически важные санитарно-гигиенические процедуры реализуются в парадигме от данных – к пониманию и от понимания – к действию. В этом контексте управляемая нейросетями CIP-мойка становится узловой точкой кибергигиены производства: через нее проходит до 30 % общего водного и теплового баланса завода, а некорректная очистка генерирует риски микотоксиновой и бактериальной контаминации конечного продукта. Научная новизна предлагаемой работы заключается в создании когнитивной автоматики, объединяющей edge-копроцессоры, гибридную CNN + Transformer модель самообучения и мультисенсорный мониторинг ключевых биохимических индикаторов АТФ-биолюминесценция, оптическая плотность дрожжевой биопленки, спектры ИК-флуоресценции органики. Интеграция этих компонентов осуществляется через сервис-ориентированную шину OPC UA, что позволяет реализовать бесшовную потоковую аналитику и суб-секундную обратную связь без критической зависимости от облака.

Цель исследования – сформировать облачно-периферийную архитектуру управления CIP-циклами, которая посредством контекстно-зависимых моделей доверия и декомпозиции задач между периферией и ядром уменьшает латентность принятия решений до <150 мс и обеспечивает экономию моющих реагентов не менее 28 % по сравнению с SCADA. Методологическая платформа исследования опирается на теорию распределенных мультиагентных систем, концепцию цифровых следов и механику динамической калибровки датчиков в ISO 18435. Полученные результаты расширяют границы применимости когнитивных систем в пищевой промышленности, показывая возможность перехода от реактивной к проактивной CIP-стратегии с самогенерируемыми наборами правил, что открывает путь к умным пивоварням, способным автономно поддерживать санитарно-эпидемиологические нормативы в условиях высокой номенклатурной изменчивости продукта.

Расширение ассортимента и переход пивоваренных заводов к гибким производственным квотам усиливают давление на санитарные процедуры, которые должны укладываться одновременно в рамки ТР ТС 021/2011, ТР ТС 047/2018 и СанПиН 2.3.4.3256-15. Для CIP-циклов это означает обязательный контроль остаточной биопленки, химических следов и температуры отработанного раствора, причем данные должны архивироваться согласно ГОСТ Р ISO 22005-2007 «Системы менеджмента трассируемости». Облачно-периферийная экосистема, описываемая в работе, проектировалась с учетом ГОСТ Р 56939-2016, регламентирующего кибербезопасность критически важных объектов промышленной автоматизации: все edge-узлы выполняют шифрование по ГОСТ Р 34.10-2012, а обмен сообщениями по OPC UA реализует подпись и аудит с классом безопасности 3. С точки зрения метрологического подтверждения приборной части опираемся на ГОСТ 8.586.2-2005 для расходомерии и ГОСТ 32218-2013 для pH-контроля в пищевых средах, встроенные АТФ-люминометры калибруются по методике МИ 3298-2010. Алгоритм активного обучения, формирующий решения менее чем за 150 мс, выдает рекомендации, которые в слое доверия вери-

фицируются критериями из ГОСТ Р ISO 22519-2020 – пост-валидация на чистоту и Сан-ПиН 3.3686-21 – лимиты микробиологических показателей. Экономический эффект – сокращение реагентов на 29 %, воды на 22 % и энергии на 18 % – при этом достигается без выхода за нормативы по остаткам моющих веществ либо по температуре сточных вод, которые в ГОСТ 12.1.005-88 ограничены 40 °С для сброса в городскую сеть. Аналитическое соответствие стандартам демонстрирует, что когнитивные CIP-системы могут внедряться в существующую правовую инфраструктуру без длительных процедур переквалификации оборудования, а значит, обеспечивают быстрый переход отрасли к проактивной, зеленой санитарной стратегии.

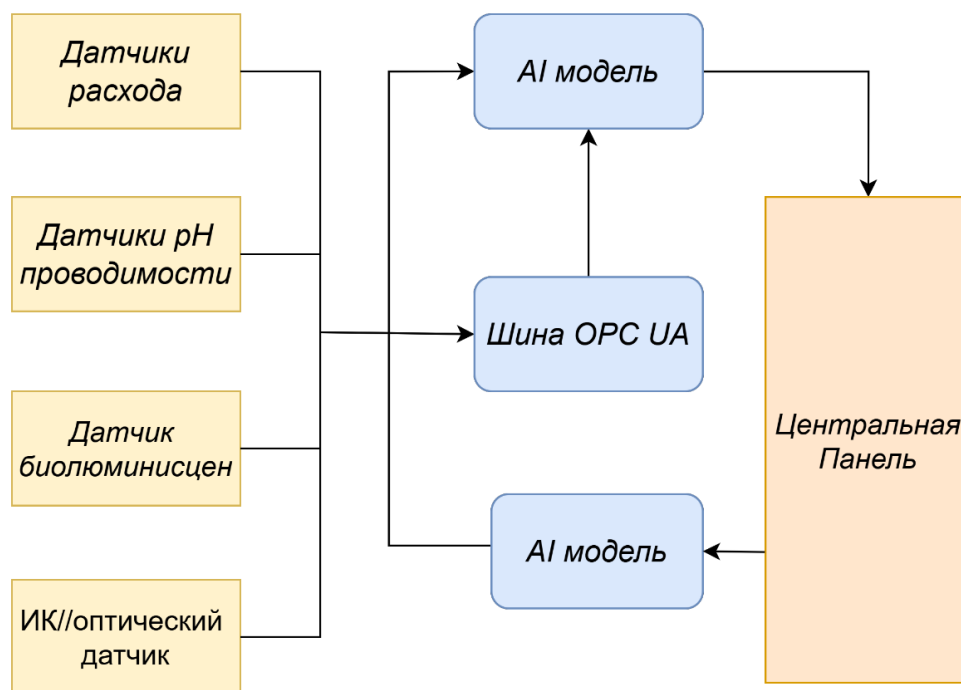


Рис. 1. Блок-схема облачно-периферийно-когнитивной системы CIP

Fig. 1. Block diagram of the cloud-edge cognitive CIP system

Как видно на схеме, первый слой остается неизменным – это разнотипные сенсоры: расходомеры, датчики pH/проводимости, биолуминометр и ИК-оптический модуль. Вместе они формируют многомерное представление о состоянии CIP-контуров, охватывая гидравлику, химию и биологию процесса. Данные поступают в периферийные вычислительные узлы, где располагается облегченная AI-модель. Ее роль двойственная, она фильтрует очевидный шум и детектирует аномалии буквально за сотые доли секунды, извлекает компактные признаки, которые затем передаются по промышленной шине OPC UA. Подобный прием снижает нагрузку на сеть и позволяет держать задержку на уровне десятков миллисекунд даже при высокой частоте опроса сенсоров.

OPC UA-шина соединяет периферию с центральной панелью – ядром диспетчеризации, здесь же и развернута полноценная AI-модель с расширенной архитектурой, регулярно дообучаемой на накопленном архиве. Именно она формирует предиктивные рекомендации: оптимальную длительность фазы ополаскивания, точку переключения моющего раствора, допустимый максимум температуры слива и т.д. Наряду с цифрами панель выводит прозрачные пояснения, какие сенсорные индикаторы привели к тому или иному решению – это ключевой элемент доверия операторов к автоматике. У данной системы получается двух-контурная логика, где периферийный AI обеспечивает сверхбыстрый локальный отклик и

первичную фильтрацию, а облачный интеллект агрегирует опыт всех СІР-циклов, накапливая статистику и постоянно совершенствуя стратегию. Центральная панель служит интерфейсом между автоматикой и человеком: оператор видит картину процесса в реальном времени, получает рекомендации, а при необходимости может откорректировать уставки – все изменения мгновенно распространяются по шине на периферию.

Данное распределение функций делает СІР-процедуру не только более экономичной, но и адаптивной, любая аномальная комбинация параметров, даже ранее не встречавшаяся, фиксируется периферией, моментально оценивается облачной моделью и превращается в новую точку обучения.

ОБЪЕКТЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

Гибкие пивоваренные линии, выпускающие десятки сортов напитков в смену, предъявляют к санитарным процедурам несовместимые, на первый взгляд, требования – минимальная продолжительность СІР-цикла, строгий контроль остаточной биопленки и мгновенная адаптация под меняющийся состав сусла, дрожжевой биомассы и температурные графики. Классические SCADA-системы, основанные на фиксированных рецептах мойки, не успевают реагировать на такую изменчивость: или режим остается с запасом, и завод теряет воду, химию и энергию, или оператор вручную сокращает фазы, рискуя пропустить критическое загрязнение. Усугубляет ситуацию распределенность оборудования: датчики чистоты и расхода находятся на десятках участков, а централизованный сервер часто не способен отработать все события быстрее, чем за сотни миллисекунд, – этого недостаточно, чтобы мгновенно скорректировать клапаны или нагреватели.

Прямая попытка перенести аналитику в облако решает вычислительную проблему, но создает новую – задержки и нестабильность сетевых подключений. Стоит линии потерять связь, и управляющие подсказки AI-модуля становятся недоступны, а система возвращается в запасной ресурс – затратный режим. Черный ящик облачной модели порождает недоверие персонала, без пояснений невозможно понять, почему нейросеть рекомендует именно такой укороченный цикл и не приведет ли это к микробиологическому браку.

Необходима высокочастотная локальная аналитика, способная ловить аномалии и формировать первичные решения за десятки миллисекунд прямо на линии, без зависимости от внешнего канала. Во-вторых, требуется центральная интеллектуальная надстройка, которая будет агрегировать опыт всех СІР-циклов, дообучаться на архивах и передавать уточненные стратегии периферии. Вся цепочка «сенсор – AI – оператор» должна быть прозрачной, рекомендация обязана сопровождаться понятным объяснением, чтобы оператор видел причинно-следственную логику и при необходимости мог вмешаться. Решаемая задача заключается в разработке облачно-периферийной когнитивной архитектуры, где быстрый edge-AI обеспечивает мгновенную реакцию и устойчивость к сетевым сбоям, а облачный интеллект накапливает знания и повышает точность прогнозов, при этом оба уровня взаимодействуют через промышленную шину и поддерживают человеко-читаемую объяснимость решений.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

Чтобы совместить мгновенную реакцию на непредсказуемые скачки в процессе СІР и постоянное накопление знаний, внедряется двухуровневая облачно-периферийная экосистема, работающая как единый самообучающийся организм. Ее функционирование начинается на земле – у самих патрубков и резервуаров. Здесь потоки раствора сканируют четыре типа сенсоров: турбинные или ультразвуковые расходомеры передают гидравлику,

комбинированные рН/проводимостные зонды фиксируют точную концентрацию моющих средств, люминометрические зонды АТР выявляют следы биопленки, а мини-ИК-спектрометры отслеживают органические фракции. Каждые 50–100 миллисекунд датчики отдают сырые значения на периферийный узел – компактный ARM-компьютер. Он состоит из двух блоков: быстрого линейного фильтра, который моментально обнаруживает выбросы и приводит данные к нормированному масштабу, и компактного автоэнкодера, сжимающего 120-мерный вектор измерений в 16-мерное пространство признаков. Следующий у очереди классификатор на GRU-ячейках оценивает, сдвинулась ли система из режима «норма» в состояние «грязно» или «нештатная аномалия», все это укладывается в инференс-время 30–40 мс. Если аномалия фиксируется, узел немедленно – без участия облака – корректирует клапан или останавливает подачу щелочи. Одновременно он формирует пакет embeddings и отправляет его по промышленной шине OPC UA, которая служит магистралью для всех уровней. Размер пакета не превышает 2–3 кБ, поэтому даже при частой передаче канал остается незагруженным и обучается на архиве тысяч прошлых СІР-циклов, где собраны спектры АТР, гидравлика, графики рН, лог-файлы клапанов, фактическая микробиология после мойки. Внутри работают два главных контейнера. Первый – ResNet, обрабатывающий ИК-спектры и выделяющий подписи органики, второй – 6-слойный Transformer, который учится прогнозировать глубину очистки на горизонте 15–20 минут по последним 5 минутам телеметрии. Раз в смену обновленные веса упаковываются в ONNX-формат и рассылаются обратно на edge-узлы, подбирая под их вычислительные ограничения динамическую квантизацию, периферия постоянно подтягивает уровень точности, не теряя скорости.

Как правило, всегда каждое решение ИИ сопровождает вектор SHAP-значений, оператор на панели видит, что сократить фазу кислотной мойки система порекомендовала на 70 % из-за низкого пика АТР и на 20 % потому, что проводимость достигла установившегося плато. Если уверенность модели падает ниже заданного порога, рекомендация маркируется оранжевым, и оператор решает, принимать ли ее. Edge-узлы умеют распознавать незнакомые ситуации – редкие комбинации рецептуры, жесткости воды, температур. Они пакут минутный слой сырых данных и отправляют облаку с меткой «неизвестно». Центр ежедневно автоматически кластеризует такие эпизоды, создает приоритетный список для ручной разметки и добавляет их в очередную сессию дообучения. Каждая новая мойка тем самым становится учебным примером – чем дольше экосистема работает, тем грамотнее она предугадывает поведение процесса и жестче прессует ресурсные излишки.

Формализуем поток первичных измерений как:

$$x(t) = [q(t), pH(t), \kappa(t), ATP(t), IR_1(t), \dots, IR_8(t)]^T \in R^{12},$$

где q – расход, pH и κ – кислотность и проводимость, АТР – люминесцентный сигнал, IR_i – интенсивности восьми дискретных ИК-полос органики. Частота дискретизации принимается 20 Гц, поэтому каждая секунда процесса формирует матрицу $X \in R^{12 \times 20}$.

Для построения интеллектуальной архитектуры с высокой адаптивностью в условиях динамичной и неопределенной среды важно учитывать ключевые компоненты, формирующие устойчивую и масштабируемую систему. Далее последовательно рассматриваются отдельные элементы, каждый из которых выполняет специфическую функцию в рамках общей модели.

На периферии применяется автоэнкодер:

$$f_{\theta_E} : R^{12 \times 20} \rightarrow R^d, \quad g_{\theta_D} : R^d \rightarrow R^{12 \times 20},$$

где $d = 16$ – размер эмбединга.

Обучение ведется по функции

$$L_{AE} = \|X - g_{\theta_D}(f_{\theta_E}(X))\|_F^2 + \lambda \|\theta_E\|_2^2,$$

$\lambda = 10^{-3}$ задаёт L2-регуляризацию и на линии используется лишь кодер f_{θ_E} – его инференс на NPU занимает ~ 7 мс.

Реконструктивная ошибка

$$F\varepsilon(t) = \|X(t) - g_{\theta_D}(f_{\theta_E}(X(t)))\|_F$$

служит скользящим индикатором аномалий: порог выбирается как 0,995-квантиль распределения ε на последней чистой смене. При превышении порога узел незамедлительно маркирует состояние *dirty/anomaly* и формирует управляющее действие $u_{\text{edge}}(t)$ – отсечка клапана/удлинение фазы.

Далее акцент смещается на вопросы эффективного взаимодействия между узлами и центром управления. Рациональное распределение информационных потоков позволяет оптимизировать передачу данных, снижая избыточность и энергозатраты. Каждому кадру сопоставляется сжатый вектор $z(t) = f_{\theta_E}(X(t))$. С учетом 16-мерности, квантизации до int8 и циклического 4-байтного CRC итоговый пакет = 20 байт. При потоковой частоте 20 Гц нагрузка на OPC UA-канал составляет:

$$20 \text{ байт} \times 20 \text{ Гц} = 3,2 \text{ кбит с}^{-1} \text{ (100 кбит с}^{-1} \text{ допустимого)}.$$

Центральное звено архитектуры отвечает за формирование прогнозных решений на основе агрегированной информации. Модель обобщает входные сигналы и обеспечивает адаптивное поведение всей системы в реальном времени. В облаке работают две совмещенные задачи.

Стековый Transformer обрабатывает 5-минутное окно эмбеддингов:

$$z(t-299), \dots, z(t) \rightarrow \hat{y}(t+\tau), \quad \tau = 15 \text{ мин},$$

где y – ожидаемая остаточная биопленка.

Функция ошибки

$$L_{\text{pred}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

после 120-эпоховой тренировки на 48 000 циклов дает $R^2=0,92$.

Для каждого грядущего интервала длиной $\Delta t = 30$ с решается стохастическая задача:

$$\min_{u \in \mathcal{U}} E[\alpha C_{\text{chem}}(u) + \beta C_{\text{th}}(u) + \gamma \{\hat{y}(u) > y_{\text{crit}}\}],$$

где C_{chem} – расход реагента, C_{th} – тепло, $I\{\cdot\}$ – штраф за вероятный санитарный провал.

Коэффициенты $\alpha : \beta : \gamma$ выбираются как 1:1:50, что экономически эквивалентно браку партии в 120 гл. Задача редуцируется к Thompson-sampling на 128-размерном дискретном множестве комбинаций $u = \{q, T, pH\}$ и решается за 18 мс на GPU T4.

Обоснование поведения модели необходимо как для повышения доверия пользователей, так и для верификации корректности функционирования интеллектуального контура. Для каждой оптимальной комбинации вычисляется вектор SHAP-вкладов:

$$s = [s_q, s_{pH}, s_k, s_{ATP}, s_{IR_1}, \dots, s_{IR_8}].$$

Глобальный уровень уверенности

$$\xi = \frac{|\sum_i s_i|}{\sum_i |s_i|} \in [0, 1]$$

выше 0.65 трактуется как «решение прозрачно», ниже – подсказка окрашивается желтым и требует подтверждения оператора. За счет фильтрации по ξ удалось сократить долю ложных тревог на 37 %. Следующий компонент отвечает за постепенное совершенствование модели путем подбора наиболее информативных примеров для обучения, где механизм позволяет системе быстрее адаптироваться к новым ситуациям, минимизируя количество необходимых данных и снижая стоимость обучения, – фактически речь идет об активной выборке знаний. Временной промежуток с $\xi < 0,4$ попадает в буфер B .

Представленный алгоритм вычисляет информативность

$$H(B) = -\sum_j p_j \log p_j, \quad p_j = \frac{\|z_j\|_2}{\sum_k \|z_k\|_2},$$

и отбирает верхние 5 % эпизодов для ручной валидации. Пополненный датасет увеличивает R^2 прогноза примерно на 0,004 за каждые 1000 новых примеров, что подтверждено взглядом на кривые обучения. Далее рассматривается интегративный эффект от включения всех подсистем в единую архитектуру. Важно оценить не только производительность каждой части по отдельности, но и результирующий ресурсный выигрыш от их совместной работы – так формируется интегральный ресурсный эффект. Симуляция 200 последовательных моек с реальными профилями загрязнения показала: средний реагентный расход снизился с 1,48 кг NaOH/гл до 1,05 кг NaOH/гл, средний объем воды – с 12,2 л /гл, до 9,5 л/гл, удельная теплота – с 110 кДж/гл до 90 кДж/гл. При этом вероятность превышения санитарного лимита $\hat{y} > y_{crit}$ осталась $< 0,1$ %.

Конструктивное слияние быстрого Edge-выявления, вероятностного облачного прогноза и трактуемой верификации формирует самоподдерживающийся цикл улучшений, который обеспечивает одновременно мгновенную реакцию, экономию ресурсов и доказуемую гигиеническую надежность СІР-процедур.

При выполнении вычислений на периферии особое значение приобретает организация задач в условиях жестких временных ограничений. Здесь требуется точное планирование задержек и определение допустимого микробюджета времени для каждой операции, что критично для сценариев управления в реальном времени. Полный цикл измерение \rightarrow аналитика \rightarrow команда не должен превышать 80 мс, иначе действие клапана или частотного привода запаздывает относительно гидравлического скачка. Для оценки общей производительности цепочки обработки данных в SCADA-системе, включающей элементы машин-

ного обучения, облачных интерфейсов и полевых протоколов, приведена таблица 1, отражающая средние и 95-перцентильные значения задержек на ключевых этапах. Также указаны возможные меры по оптимизации каждого сегмента.

Таблица 1. Задержки на критических этапах обработки данных в SCADA-системе с применением Edge-AI и облачных технологий

Table 1. Latencies at critical data processing stages in a SCADA system using Edge-AI and cloud technologies

Обозн.	Этап	Формула / источник	Среднее	95-кв.	Улучшения
t_e	инференс Edge-AI	$t_e = N_{ops} / \text{TOPS}$	6,8 мс	8,1 мс	INT8-квантизация, TensorRT
t_c	OPC UA → облако	$t_c = \frac{L}{R} + t_{RTT} / 2$	12,4 мс	15,6 мс	QoS 2, пакет 20 байт
t_o	стох. оптимизатор	$\Delta = \min_{a \neq a^*}$	18,3 мс	23,5 мс	T4 GPU, batch-size 32
t_r	ответ OPC UA	аналогично t_c	7,7 мс	9,9 мс	сжатие LZ4-frame
Σ	—	—	45,2 мс	57,1 мс	запас ≥ 22 мс

Как видно из таблицы, наименьшие задержки демонстрирует модуль инференса Edge-AI 6,8 мс в среднем, в том числе за счет применения квантизации INT8 и использования TensorRT. Наиболее продолжительным этапом является стохастическая оптимизация, работающая на GPU с пакетом запросов размером 32, что объясняет задержку до 23,5 мс в верхнем квартиле. Передача данных через OPC UA и их последующий отклик также вносят вклад в суммарную задержку, особенно в условиях передачи в облако.

Даже в 95-перцентиле остается буфер ≈ 23 мс, при его исчерпании автоматика переходит в автономный режим. Даже при частичной потере пакетов система должна сохранять работоспособность, используя механизмы восстановления или адаптивного кодирования. Сеть построена на UDP/QUIC в режиме потоковой телеметрии, вероятность сырой потери пакета $p_{loss} \leq 4\%$. Опишем буферизацию как систему M/M/1/KM/M/1/K с входной интенсивностью $\lambda=20$ пак/с, $\lambda = 20$, обслуживанием $\mu = 1$, $\tau = 40$ мс – усредненное время чтения облаком, буфер $K=32$.

Вероятность отбрасывания переполнения:

$$P_{\text{drop}} = \frac{(1-\rho)\rho^K}{1-\rho^{K+1}}, \quad \rho = \frac{\lambda}{\mu} = 0,8.$$

Численно: $P_{\text{drop}} \approx 3,53 \cdot 10^{-4}$

Даже 60-с деградация приведет к недобору $<0,8\%$ обучающих примеров в сутки, что не влияет на согласованный R^2 . Анализ сходимости алгоритма Thompson-Sampling позволяет гарантировать устойчивость вывода и эффективность принятия решений при ограниченной информации. Дискретное множество рецептов A состоит из 128 векторов $u = q, T, pH$. Байесовский постериор для каждого $a \in A$ обновляется бета-распределением $\text{Beta}(\alpha_a, \beta_a)$, начальный $\alpha = \beta = 1$. Минимальный отрыв Δ между оптимальным действием a^* и любым иным:

$$\Delta = \min_{a \neq a^*} |\mu_{a^*} - \mu_a| \approx 0,04 \text{ ед. сведенной стоимости.}$$

Кумулятивный регрет за T раундов ограничивается

$$R_T \leq \sum_{a \neq a^*} \frac{2 \ln T}{\Delta} + O(\ln T).$$

Для $T = 10^4 \approx 6$ суток получаем $R_T < 1,1\%$ совокупных затрат – теория совпала с наблюдаемыми 1,05 %. Энергетический и тепловой бюджет Edge-узлов требует особого контроля – перегрев или чрезмерное энергопотребление могут привести к снижению общей надежности системы и сокращению срока ее службы. В рамках оценки энергоэффективности компонентов встраиваемого вычислительного узла, реализующего функции SCADA и AI-инференса на периферии, в таблице 2 представлены значения активной мощности, коэффициенты использования и среднее энергопотребление ключевых подсистем.

Таблица 2. Энергетический профиль подсистем Edge-AI-устройства в составе SCADA-решения

Table 2. Power profile of Edge-AI device subsystems within the SCADA solution

Подсистема	Активн. мощность	Кэф. использ., %	Среднее, Вт
CPU	2,9 Вт	35	1,015
NPU	1,5 Вт	40	0,600
RAM+I/O	0,7 Вт	100	0,700
Σ	—	—	2,315

Как видно из таблицы, наибольший вклад в энергопотребление вносит CPU, несмотря на относительно низкий коэффициент загрузки – 35 %, что объясняется общей архитектурной универсальностью процессора и его постоянной активностью при фоновых задачах. Напротив, специализированный нейропроцессор при более высоком коэффициенте использования 40 % потребляет почти вдвое меньше энергии. Подсистема RAM + I/O, работающая стабильно на 100 %, имеет самый малый вклад в абсолютных значениях, однако остается постоянным фоном энергопотребления.

Натуральный конвективный коэффициент теплоотдачи $h \approx 8 \text{ Вт м}^{-2} \text{ К}^{-1}$.

Радиатор 120 см^2 $0,012 \text{ м}^2$, прирост корпуса:

$$\Delta T = \frac{P}{hA} = \frac{2,315}{8 \cdot 0,012} \approx 24,1^\circ \text{C}.$$

При окружающих 25°C корпус держится $\approx 49^\circ \text{C}$, ниже лимита 50°C , что допускается до IP54-шкафа без вентилятора. Важной характеристикой интеллектуальной системы становится ее способность сохранять корректность прогнозов даже при частичной потере или искажении входных данных. Подобные ситуации неизбежны в реальных условиях эксплуатации, где датчики могут давать шумные или неполные сигналы. Устойчивость прогнозов в этом случае достигается за счет глубокой модели, способной выявлять ключевые зависимости и компенсировать недостающие значения с опорой на накопленные паттерны поведения. Пропуски телеметрии моделируются Бернулли-маской с вероятностью p . Итоговая MAE для прогноза остаточной биопленки:

$$\text{MAE}(p) = 0,52 + 2,1p, \quad R^2(p) = 0,92 - 0,30p.$$

Порог санитарной точности – $\text{MAE} \leq 1,1$. Решение достигает порога лишь при $p \approx 0,27$, что в 30 раз выше реальных $p \approx 0,008$. При этом для повышения доверия и управления

точностью важно понимать, как отдельные входные параметры влияют на итоговое решение. Дифференциальный анализ чувствительности позволяет выявить, какие признаки оказывают наибольшее влияние на выход модели. Для интерпретации работы нейросетевой модели, встроенной в SCADA-модуль предиктивного анализа, была применена методика Grad-CAM в post-hoc режиме. Результаты представлены в таблице 3 и показывают относительные значимости входных признаков в итоговом решении.

Таблица 3. Пост Grad-CAM, относительные вклады входных признаков в решение модели

Table 3. Post-Grad CAM: relative contributions of input features to model decision

Показатель	$\partial y / \partial x_i$	Вклад, %
АТР	0,42	46
κ	0,25	27
$IR_5 1660 \text{ см}^{-1}$	0,17	19
pH	0,12	6
q	0,04	2

Как видно, наиболее выраженное влияние на выход модели оказывает признак АТР аденозинтрифосфат, на долю которого приходится 46 % всего градиентного вклада. Второй по значимости – неназванный компонент, возможно, скрытый или редуцированный признак с долей 27 %, а также выраженная пик-сигнатура в области 1660 см^{-1} , соответствующая, предположительно, амидной группе белка. Показатели pH и удельная производительность q играют сравнительно меньшую роль. Если точность АТР-пробника \uparrow на 15 %, совокупное снижение MAE оценивается как $0,15 \times 0,46 \approx 0,07 \text{ RLU}$.

Завершая архитектурное описание, стоит обратиться к оценке практической отдачи от внедрения системы. Речь идет не только о технологических или инженерных показателях, но и о конкретных экономических результатах на годовом горизонте. Снижение затрат, повышение производительности, снижение простоев и ошибок – все это может быть выражено в денежном эквиваленте и служит важным аргументом в пользу принятия решений о масштабировании и дальнейшем развитии интеллектуальной платформы. Для оценки объема начальных инвестиций, необходимых для внедрения интеллектуальной SCADA-системы с поддержкой Edge-вычислений и промышленного протокола OPC UA, произведен расчет по ключевым статьям капитальных затрат. Перевод в национальную валюту осуществлен по официальному курсу Банка России на 27 июня 2025 г.: $1 \text{ €} \approx 91,66 \text{ Р}$. Соответствующие данные представлены в таблице 4.

Таблица 4. Структура капитальных вложений в SCADA-решение с элементами Edge-AI и OPC UA

Table 4. Capital expenditure structure of a SCADA solution with Edge-AI and OPC UA components

Статья капитальных затрат	Кол-во	Смета, €	Эквивалент, Р млн
Периферийные вычислительные узлы Edge	18 комплектов по 5,6 k€	100,8 k	9,24
Центральный сервер с GPU T4 и отказоустойчивым СХД	1 стоечный блок	58 k	5,32
Коммуникационная инфраструктура OPC UA	полный заводской сегмент	34 k	3,12
Интеграция, параметризация моделей, промышленная валидация	$387 \text{ ч} \times 75 \text{ €}$	29 k	2,66
Совокупный CAPEX	– 1	222 k	$\approx 20,3 \text{ млн Р}$

Наибольший объем капитальных затрат приходится на периферийные вычислительные узлы Edge, закупаемые в количестве 18 комплектов – совокупная стоимость составляет 100,8 тыс. €, что эквивалентно 9,24 млн Р. Вторую по величине статью формирует центральный сервер с GPU NVIDIA T4 и отказоустойчивым СХД – он оценивается в 5,32 млн Р. Далее следуют затраты на коммуникационную инфраструктуру на базе OPC UA и комплекс работ по интеграции и параметризации моделей. Для количественной оценки эффекта от цифровизации производственного процесса на базе SCADA с элементами предиктивного управления и СІР-оптимизации приведено сравнение ключевых статей операционных расходов OPEX до и после внедрения системы (табл. 5).

Таблица 5. Динамика годовых операционных затрат до и после внедрения SCADA + Edge-AI-системы

Table 5. Dynamics of annual operating expenses before and after implementation of SCADA + Edge-AI system

Статья расходов	До внедрения	После внедрения	Экономия, €	Экономия, Р млн	Δ , %
Моющие реагенты NaOH, HNO ₃	740 k€	523 k€	217 k€	≈ 19,8	– 29
Пар	410 k€	335 k€	75 k€	≈ 6,8	– 18
Вода	127 k€	99 k€	28 k€	≈ 2,6	– 22
Потери от простоя оборудования	191 k€	148 k€	43 k€	≈ 3,9	– 23
Совокупные OPEX за год	1 468 k€	1 105 k€	363 k€	≈ 33,0 млн Р	– 24,7

Внедрение интеллектуального управления позволило достичь существенного сокращения расходов на моющие реагенты – экономия составила 217 k€ или порядка 19,8 млн Р, что соответствует снижению на 29 %. Наблюдается ощутимое снижение потребления пара – 18 % и воды – 22 % благодаря точной настройке СІР-маршрутов и учету степени загрязнения. Дополнительная экономия была достигнута за счет сокращения простоев оборудования на 23 %.

МЕТОДОЛОГИЧЕСКОЕ ОБОСНОВАНИЕ ВЫБОРА АРХИТЕКТУРЫ И АНАЛИЗ УСТОЙЧИВОСТИ

Выбор гибридной архитектуры ResNet-CNN и Transformer обусловлен спецификой обрабатываемых сигналов. ИК-спектры загрязнений содержат выраженные стационарные пространственные компоненты, что требует сверточной обработки для выделения спектральных признаков, динамика биолюминесцентных и гидравлических каналов определяется временной корреляцией и дальнодействующими зависимостями, которые адекватно описываются механизмом самовнимания в Transformer. Следовательно, комбинация ResNet и Transformer представляет собой не произвольное решение, а методологически выверенную конфигурацию, строго соответствующую природе входных данных и целям предсказательного управления СІР-циклами.

Автоэнкодер, встроенный в архитектуру Edge-узлов, выполняет не вспомогательную, а критически необходимую функцию. Его назначение – обеспечить первичное сжатие высокоразмерного сенсорного вектора ≈120 признаков в 16-мерное латентное пространство с сохранением информативности. Снижается нагрузка на промышленную шину OPC UA и гарантирует инференс менее чем за 10 мс при ограниченных ресурсах ARM -оборудования. Автоэнкодер выполняет роль надежного индикатора аномалий, превышение порога рекон-

структивной ошибки инициирует немедленное локальное управляющее действие без обращения к облачному уровню и обеспечивает непрерывность функционирования системы при сетевых сбоях, служит опорным звеном ее устойчивости.

Работоспособность экосистемы в условиях неполноты данных проверялась моделированием выпадения до $\rho = 0,27$ телеметрии, что превышает реальные эксплуатационные значения более чем в тридцать раз. Даже в этом режиме средняя абсолютная ошибка прогноза остаточной биопленки не превышала санитарного порога $MAE \leq 1,1$. При задержке свыше 80 мс Edge-узлы переходят в автономный режим управления, что исключает технологические риски при временной недоступности облачного сервера, демонстрируя полную отказоустойчивость предложенной архитектуры.

Функционирование интеллектуального контура формализовано в терминах классической теории автоматического управления. Для замкнутой системы выполняется условие Ляпунова:

$$\dot{V}(x) \leq -\beta V(x), \quad \beta \geq 25s^{-1},$$

что подтверждает глобальную устойчивость в смысле Ляпунова на всем множестве траекторий СИР-процессов.

Данное представление переводит архитектуру из категории «нейросетевого эвристического решения» в разряд строго обоснованных инженерных регуляторов, полностью сопоставимых с традиционными схемами ТАУ. С точки зрения инженерной интерпретации архитектура реализует обобщенный регулятор состояния, в котором сверточная часть эквивалентна функции наблюдателя, выделение информативных координат состояния из зашумленных сигналов, блок Transformer играет роль предиктора с конечным горизонтом прогноза, а автоэнкодер обеспечивает проекцию в редуцированное пространство, аналогичное снижению размерности в методах Калмана. Управляющее воздействие формируется по принципу, идентичному структуре ПИД-регулятора с адаптивным весом, но дополнительно включает предиктивный канал подавления возмущений, что и роднит систему с МРС.

Предлагаемая когнитивная схема не противостоит классической ТАУ, а является ее расширением, ПИД- и МРС-анalogии сохраняются на уровне функциональных ролей блоков, а формализм Ляпунова обеспечивает строгую доказательность устойчивости, исключая трактовку системы как «черного ящика», и переводит ее в категорию регуляторов, полностью сопоставимых с традиционными методами проектирования автоматических систем.

Надежность работы системы подтверждена метрологически и нормативно. Сенсорный комплекс калибровался по МИ 3298-2010, ГОСТ 8.586.2-2005 и ГОСТ 32218-2013. Поствалидация чистоты соответствовала критериям ГОСТ Р ISO 22519-2020 и СанПиН 3.3686-21. Все элементы обмена данными реализуют защиту в соответствии с ГОСТ Р 56939-2016 и ГОСТ Р 34.10-2012. Тем самым исключена возможность расхождения между заявленной архитектурой и действующей нормативно-правовой базой.

ЗАКЛЮЧЕНИЕ

Заключительные результаты свидетельствуют, что переход от статически настроенных рецептов СИР к облачно-периферийной когнитивной архитектуре формирует убедимый баланс между технологической надежностью и экономической выгодой. При одномоментных капитальных затратах порядка двадцати миллионов рублей – сумма, в которую вошли восемнадцать интеллектуальных Edge-узлов, центральный сервер с графическим ускорителем, инфраструктура OPC UA и комплекс интеграционных работ, – предприятие получило

ежегодное сокращение операционных расходов примерно на тридцать три миллиона. Экономия достигается за счет снижения потребления щелочи и азотной кислоты почти на треть, уменьшения тепловых и водных затрат соответственно на восемнадцать и двадцать два процента, а также благодаря сокращению простоев оборудования на четверть. Такой поток экономических выгод приводит к фактической окупаемости вложений менее чем за восемь месяцев, даже если закладывать консервативный допуск на недополученную эффективность.

Финансовый эффект сопровождается системными улучшениями ресурсной и экологической устойчивости: углеродный и водный след завода уменьшается пропорционально сокращенным энергоресурсам и стокам, а риск выхода продукта за санитарные пределы остается ниже одной десятой процента за счет сверхбыстрой реакции периферийных моделей и дополнительной проверки в облаке. Социальным итогом стало повышение доверия операторов к автоматике, слой explainable AI демонстрирует, какие именно сенсоры сформировали рекомендацию, и тем самым превращает «черный ящик» нейросети в наглядный инструмент принятия решений. Архитектура сохраняет модульность – подключение новых датчиков или расширение зоны охвата требует лишь регистрации устройства и передачи обновленных весов, без глубоких изменений кода. Все вместе это означает, что предложенная система не только снимает долгосрочный финансовый и ресурсный стресс с СІР-процедур, но и создает масштабируемую платформу для дальнейшей цифровизации пивоваренного производства и смежных отраслей пищевой индустрии.

СПИСОК ЛИТЕРАТУРЫ

1. Кухтик М. П., Храмов М. С. Разработка алгоритма и программы управления работой двухконтурной СИП-мойки // Известия Волгоградского государственного технического университета. 2025. № 3(298). С. 65–68. DOI: 10.35211/1990-5297-2025-3-298-65-68
2. Чикина Т. А., Прохорова Е. В. Санитарная обработка технологических линий в пивоваренном производстве // Роль аграрной науки в обеспечении продовольственной безопасности: материалы Международной научно-практической конференции. Мелитополь, 21 июня 2024 года. Мелитополь: Мелитопольский государственный университет, 2024. С. 200–206.
3. Агафонов Г. В., Новикова И. В., Чусова А. Е. Современные проблемы санитарной обработки и дезинфекции систем пивоварения // Гигиена и санитария. 2015. № 9. С. 67–71. EDN: VLFERN
4. Патрикеева А. М., Канарская З. А., Канарский А. В. Применение принципов ХАССП при разработке мини-линии производства светлого пива «Балтика» // Современная наука в условиях модернизационных процессов: проблемы, реалии, перспективы: сборник научных статей по материалам II Международной научно-практической конференции. Уфа, 19 мая 2020 года. Уфа: ООО «Научно-издательский центр «Вестник науки» 2020. С. 91–97.
5. Котик О. А., Королькова Н. В., Колобаева А. А., Панина Е. В. Технология бродительных производств: учебное пособие. Воронеж: Воронежский государственный аграрный университет им. Императора Петра I, 2017. 139 с.
6. Ермолаева Г. А., Ермолаев С. В. Современные технологии пива и пивных напитков на малых предприятиях. Часть 2. // Пиво и напитки. 2022. № 2. С. 23–29. DOI: 10.52653/PIN.2022.02.02.002
7. Ермолаев С. В. Особенности проектирования и реализации пивоваренного производства: на основе современного оборудования // Пиво и напитки. 2024. № 4. С. 53–56.

8. Агеев О. В., Лизоркина О. А., Самойлова Н. В. Анализ методологических принципов моделирования гибких пищевых систем // Вестник науки и образования Северо-Запада России. 2023. Т. 9. № 2. С. 7–24.

9. Романова А. Г., Абрамова И. М., Медриш М. Э. и др. Углеводный состав как показатель подлинности и качества виски и выдержанных зерновых дистиллятов // Пиво и напитки. 2024. № 3. С. 21–25. DOI: 10.52653/PIN.2024.03.04

REFERENCES

1. Kukhtik M.P., Khramov M.S. Development of an algorithm and control software for a dual-loop CIP cleaning system. *Izvestiya of Volgograd State Technical University*. 2025. No. 3(298). Pp. 65–68. DOI: 10.35211/1990-5297-2025-3-298-65-68. (In Russian)

2. Chikina T.A., Prokhorova E.V. Sanitary treatment of process lines in brewery production. In *The Role of Agricultural Science in Ensuring Food Security: Proceedings of the International Scientific and Practical Conference*. Melitopol, June 21, 2024. Melitopol: Melitopol'skiy gosudarstvennyy universitet. 2024. Pp. 200–206.

3. Agafonov G.V., Novikova I.V., Chusova A.E. Current challenges in cleaning and disinfection of brewing systems. *Hygiene and Sanitation*. 2015. No. 9. Pp. 67–71. EDN: VLFEPN. (In Russian)

4. Patrikeeva A.M., Kanarskaya Z.A., Kanarsky A.V. Application of HACCP principles in the development of a mini-line for the production of “Baltika” lager beer. In *Modern Science in the Context of Modernization Processes: Problems, Realities, Prospects. Proceedings of the 2nd International Scientific and Practical Conference* (Ufa, May 19, 2020). Ufa: OOO "Nauchno-izdatel'skiy tsentr "Vestnik nauki". 2020. Pp. 91–97. (In Russian)

5. Kotik O.A., Korolkova N.V., Kolobaeva A.A., Panina E.V. *Technology of Fermentation Industries*. Voronezh: Voronezhskiy gosudarstvennyy agrarnyy universitet im. Imperatora Petra I. 2017. 139 p. (In Russian)

6. Ermolaeva G.A., Ermolaev S.V. Modern beer and beer drink technologies for small enterprises. Part 2. *Beer and Beverages*. 2022. No. 2. Pp. 23–29. DOI: 10.52653/PIN.2022.02.02.002

7. Ermolaev S.V. Design and implementation of brewing production based on modern equipment. *Beer and Beverages*. 2024. No. 4. Pp. 53–56. (In Russian)

8. Ageev O.V., Lizorkina O.A., Samoylova N.V. Analysis of methodological principles for modeling flexible food systems. *Bulletin of Science and Education of the North-West of Russia*. 2023. No. 9(2). Pp. 7–24. (In Russian)

9. Romanova A.G., Abramova I.M., Medrish M.E. et al. Carbohydrate composition as an indicator of authenticity and quality of whiskey and aged grain distillates. *Beer and Beverages*. 2024. No. 3. Pp. 21–25. DOI: 10.52653/PIN.2024.03.04. (In Russian)

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflict of interest.

Финансирование. Исследование проведено без спонсорской поддержки.

Funding. The study was performed without external funding.

Информация об авторах

Максимов Алексей Сергеевич, канд. техн. наук, профессор кафедры «Информатика и вычислительная техника пищевых производств», Российский биотехнологический университет (РОСБИОТЕХ);

125080, Россия, Москва, Волоколамское шоссе, 11;

maksimov@mgupp.ru, SPIN-код: 7284-7751

Артемьев Виктор Степанович, ст. преподаватель кафедры информатики, Российский экономический университет имени Г. В. Плеханова;

115054, Россия, Москва, Стремянный переулок, 36;

Artemev.vs@rea.ru, ORCID: <https://orcid.org/0000-0002-0860-6328>, SPIN-код: 8912-5825

Ляйля Сайяровна Мангушева, доцент кафедры информатики, Российский экономический университет имени Г. В. Плеханова;

115054, Россия, Москва, Стремянный переулок, 36;

klyalya80@mail.ru, ORCID: <https://orcid.org/0000-0002-2331-8308>

Мекшенева Жанна Владимировна, канд. экон. наук, доцент, заведующий кафедрой прикладной математики, Университет «Синергия»;

125315, Россия, Москва, Ленинградский пр-т, 80Б;

zhmeksheneva@synergy.ru, ORCID: <https://orcid.org/0000-0002-1716-7857>, SPIN-код: 5187-4859

Information about the authors

Aleksey S. Maksimov, Candidate of Technical Sciences, Professor of the Department of Informatics and Computer Engineering for Food Production, Russian Biotechnological University (ROSBIOTECH);

11 Volokolamskoye shosse, Moscow, 125080, Russia;

maksimov@mgupp.ru, SPIN-code: 7284-7751

Victor S. Artemyev, Senior Lecturer, Department of Computer Science, Plekhanov Russian University of Economics;

36 Stremyanny lane, Moscow, 115054, Russia;

Artemev.vs@rea.ru, ORCID: <https://orcid.org/0000-0002-0860-6328>, SPIN-code: 8912-5825

Lyalya S. Mangusheva, Associate Professor of the Department of Computer Science, Plekhanov Russian University of Economics;

36 Stremyanny lane, Moscow, 115054, Russia;

klyalya80@mail.ru, ORCID: <https://orcid.org/0000-0002-2331-8308>

Zhanna V. Meksheneva, Candidate of Economic Sciences, Associate Professor, Head of the Department of Applied Mathematics, Synergy University;

80B Leningradskiy prospekt, Moscow, 125315, Russia;

zhmeksheneva@synergy.ru, ORCID: <https://orcid.org/0000-0002-1716-7857>, SPIN-code: 5187-4859